

# 第 1 章 序論

## 1.1 研究の背景と目的

近年、道路インフラの整備や交通安全に対する啓蒙活動・指導取締りの強化によるシートベルト着用率向上、エアバッグ装着車の普及、緊急医療体制の整備などにより、国内における交通事故死者数は減少傾向にあり、平成 24 年中では 4411 人となり 12 年連続で減少した(図 1.1) [1]。ピーク時(昭和 45 年=16,765 人)の 3 割以下となり、交通事故発生件数および負傷者数も 9 年連続で減少している。

しかし、交通事故死者数の対前年比減少率は 1.0 %であり、この 10 年でも比較的小さく、未だ居眠り運転や飲酒運転など重大な事故に直結する交通事故によって尊い命が犠牲になっているなど、交通事故情勢は依然として厳しい状況にある。上記で述べたシートベルト着用率やエアバッグ装着車の普及はすでに 95 %を越えており、これから更なる事故発生件数の減少を成すためには画期的な新技術導入が急務である。

日本における法令違反別事故死原因の内訳(図 1.2)[1]によると漫然運転が首位である。漫然運転は平成 24 年度だけでなく 7 年連続首位であり、未だ有効な解決手段を見出せていないのが現状である。また、漫然運転の中でも特に居眠り運転は意識低下状態に陥ることから重大な事故に直結することが知られている。重大な事故に直結する事故として居眠り運転の他に飲酒運転が挙げられるが、居眠り運転は飲酒運転と違い血中アルコール濃度のような客観的な数値化ができないという点が、居眠り運転が減らない原因である。このような事情から高精度な居眠り運転検知手法が求められている。

更に漫然運転と並び死亡事故原因として多くの割合を占めるのは脇見運転である。近年の脇見運転は、従来までの車外にある対象に注視するというよりも、車内のカーナビ・オーディオに代表される車内スイッチを操作することが要因と考えられている。車内空間の快適性を向上させるための装置が脇見運転に繋がっており、これも居眠り運転と同じく解決が急務な問題である。

本研究では、これら重大な事故要因を抑止するためドライバモニタリング技術に着目し、ドライバを監視しつつ重大な事故に繋がる行動を検知することを目的として実施する。具体的には、上記の「居眠り運転」と「脇見運転」に着目し、居眠り運転検知アルゴリズムと脇見運転の前兆行動である運転姿勢変化を推定するアルゴリズムを開発する。

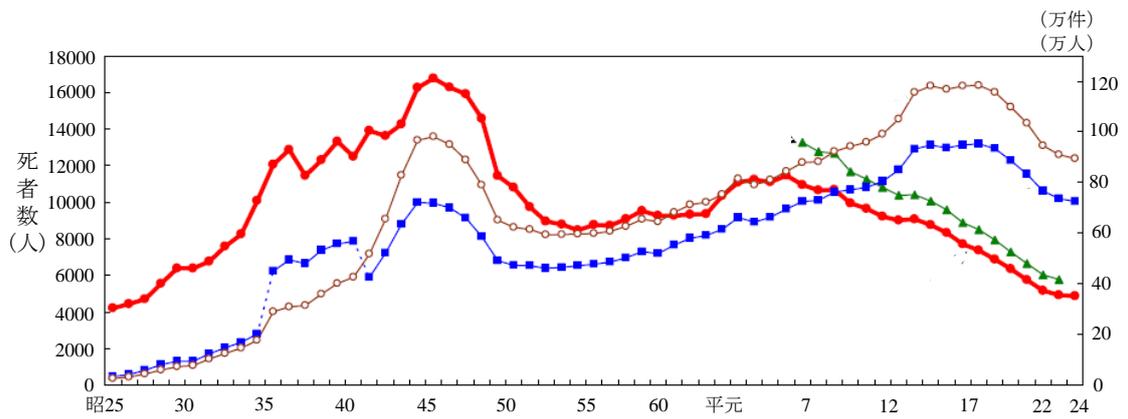


図 1.1：交通事故発生件数・死者数・負傷者数の推移(昭和 25 年～平成 24 年)  
 (引用：警視庁交通局 交通死亡事故の特徴及び道路交通法違反取締り状況について)

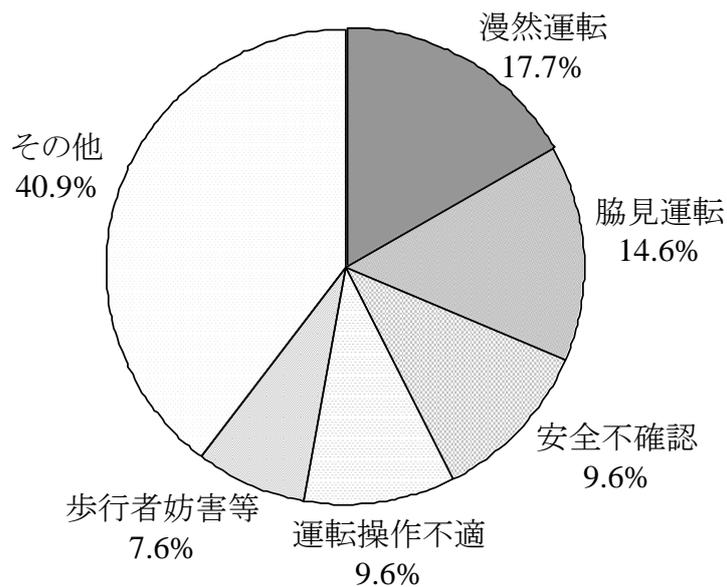


図 1.2：平成 24 年度，法令違反別事故死原因の内訳  
 (引用：警視庁交通局 交通死亡事故の特徴及び道路交通法違反取締り状況について)

### ドライバの眠気レベル推定アルゴリズムの開発

居眠り運転を検知することを目的とした研究は盛んに行われており[2]～[9]、石田ら[2]はカメラ画像から得られる顔表情を特徴量とし居眠り運転検知を行っている。Paiら[3]は脳波を用いての検知、Tsuchidaら[4]らはカメラ画像と心拍変動量の両方を用いての検知を行っている。これらの研究では利用する特徴量が異なるものの、kNNやニューラルネットワークといったパターン認識手法により、10秒～30秒の決められた区間で独立して眠気の有る無し、または眠気レベルを推定している。しかし、人間の眠気というのは急激な変化では無く、徐々に覚醒低下状態に推移していくものである[10]という観点から、眠気を捉えるためには過去の眠気推移を考慮することによって、より高精度な居眠りレベル推定が可能となると推測される。本研究では、閉眼度情報、心拍情報、呼吸情報、シートからのドライバ荷重情報から、過去の眠気推移を考慮した手法を提案した。ドライビングシミュレータによる居眠り運転模擬実験を実施し、被験者の顔表情に基づく眠気レベルを正解値とし本手法により推定を行った。

### 運転姿勢推定アルゴリズムの開発

ドライバの運転姿勢をモニタリングする研究では、加藤ら[11]はダッシュボードに赤外線カメラを設置し、その撮影画像からドライバの運転姿勢を推定する手法を提案した。しかし、カメラでは主に太陽光のコントラスト変化に代表される車外環境の変化や、撮影可能範囲外にドライバが移動した際に推定することが困難であるなどの課題を残している。カメラ以外の装置を用いた手法としては、伊藤ら[12]によりシートに圧力分布センサを設置し、あらかじめ決められた4つの動作をパターン認識手法により推定する手法が試みられた。しかし、最終的な姿勢がよく似た2つの動作について推定が困難であることと、座り直し(一度シートから離れて改めて座ること)を行った際に推定率が変化するということが問題として挙げられている。このような先行研究の報告から、ドライバの運転姿勢を推定する研究においては、精度だけでなく車外環境の変化やドライバの初期着座位置の変化により安定的な推定が困難であることが現状の問題である。この問題を解決するためには、刻一刻と変わる車外環境やドライバの初期着座位置に依存しない推定方法の確立が課題である。本研究における運転姿勢推定では、先行研究での課題を解決するために、3点で固定されシート比較し座り直しを行った際の変化が少ないと考えられるシートベルトに着目した推定を行った。

## 1.2 本論文の構成

本論文の第 2 章ではドライバの予防安全技術に関する取り組み(特にドライバモニタリング)について述べ、その中で本研究の意義を述べる。第 3 章では居眠り運転推定アルゴリズム開発に関する計測機器・アルゴリズム・実験方法・推定結果について述べ、本提案アルゴリズムの有意性を示す。第 4 章では運転姿勢推定アルゴリズム開発に関する計測機器・アルゴリズム・実験方法・推定結果について述べ、本提案アルゴリズムの有意性を示す。そして第 5 章では、2つの開発したアルゴリズムのまとめと今後の課題を踏まえ、結論を述べる。

## 第2章 安全技術による事故防止への取り組み

本章では、安全技術の中での状態検知技術の必要性について、近年の安全技術動向を中心に言及する。特に、本論文で取り上げる「居眠り運転レベル推定」と「運転姿勢推定」に関して従来研究の課題を取り上げ、研究目的を明確にする。

### 2.1 事故低減のための安全技術

交通事故の要因は「車」・「道」・「人」の三要素が相互に絡み合っ生じる。自動車産業の分野では、交通事故防止の観点から様々な車両安全に取り組んでおり、これまで衝突安全から予防安全分野に至るまで様々な製品を実用化し、自動車がもたらす負の作用を低減すべく開発に取り組んできている。衝突安全とは、事故が起きた後の乗員や歩行者などへの被害をできるだけ軽減しようとするものであり、衝突または衝突不可避の状態をいち早くセンシングし、それが検出された場合は瞬時に安全システムを作動させるものである。その代表例はエアバッグシステムである。

一方、予防安全とは、事故そのものを未然に防止しようとするものである。ドライバーが「走る」・「曲がる」・「止まる」といった運転操作を行う際、一般に、認知→判断→操作という手順を踏む。この手順が上手く機能していない場合には、認知遅れ、判断遅れ、操作遅れを引き起こし事故のリスクが高まる。そこで、予防安全はドライバーに対し、認知判断面での支援や運転時の操作負荷を軽減することを主眼において開発されている。予防安全ではドライバー自身が制御ループの主要な役割を果たすため、車両側が認知・判断・操作などの支援を行う場合には、どのタイミングでどのように支援するのかドライバーにとって受け入れられるかを考慮しないと、お節介な警報やドライバーが意味を理解できない状況が頻発することになるので注意が必要である。受容性は、ドライバーによる個人差も大きいですが、同じ個人であってもそのときの心理状態や周辺環境によって変動していくものである。運転リスクの大小が刻一刻と変化していく中で、いかにドライバーアクティブな運転支援を行うかについても、最近活発に議論されている[13]。リスク・ホメオタシス説[14]によると、人間は自動車が安全になれば、その分、ドライバーは危険な運転をする可能性があるとも言われており、折角の予防安全が効果を発揮できない可能性もある。従って、車両とドライバーとが共存する領域を扱う予防安全分野では、人間そのものを研究対象とする動きが活発化しており、ドライバーの受容度を推定するための研究[15]や、警報頻度やタイミングの適正化を提唱するシステム[16]、運転システムがドライバーの運転行動に与える影響についての研究[17]が盛んに行われるようになった。

## 2.2 安全技術の動向

### 2.2.1 技術動向と代表的な安全システム紹介

次に現在活用されている安全技術について説明する。前節でも述べたが、ドライバーは「認知」「判断」「操作」という手順を踏んで安全走行をしている。安全技術はこの手順に基づきカテゴリに分けられている(図 2.1)。まずは、事故に近づかないためには適切な情報の認知が必要である。そのような視点から運転支援分野のうち、まず重要な支援として認知支援があげられる。現在実用化されている認知を支援するシステムとして、HID(High Intensity Discharge Lamp), AFS(Adaptive Front Lighting System), BGM(Back Guide Monitor), ナイトビジョン, フロントサイドモニタ等がある。

一方、操作の支援まで行う運転支援システムには周辺監視用のレーダやカメラ等を装備した ACC(Adaptive Cruise Control), LKA(Lane Keeping Assist System)や IPA(Intelligent Parking Assist)が実用化されている。これらの運転支援システムは車両側が自ら得られる情報に基づいて支援する自律型運転支援システムである。

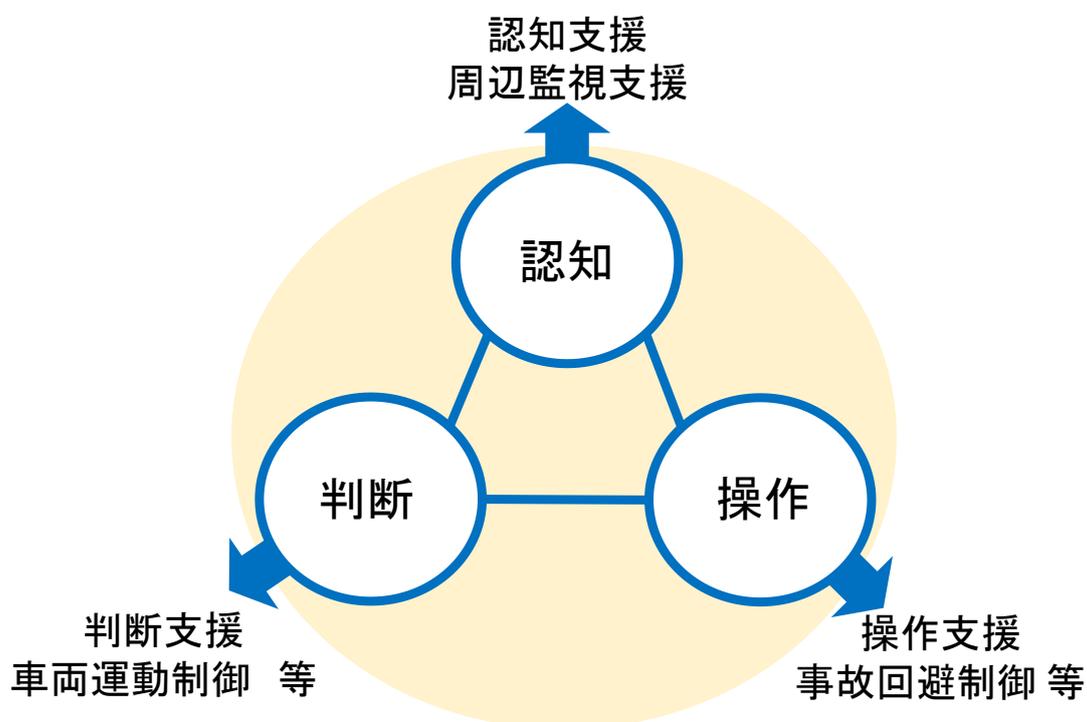


図 2.1 : 「認知」「判断」「操作」ごとに安全技術が発達

しかし、安全運転のために必要な情報としては自車が物理的に得ることが困難なものもある。ブラインドコーナや右左折時の車両の接近、また、自動車専用道における先行事故車や渋滞状況の情報等である。今後、事故を起こさない、また事故に近づかないた

めに、危険の可能性がある場合は警告によりドライバに早期に知らせるシステムの開発が進められていくがこれらシステムの実現のために、例えば道路インフラと車両の通信連携による情報提供システムのプロジェクトも実現に向けて進められている。

このように運転支援システムとして人的要因を防止するために各種の開発が行われてきている。これらのシステムは交通事故の人的要因に対しドライバをサポートまたは負担を減らすことによりヒューマンエラーによる事故を未然に防止することを狙っているが、あくまで、運転責任はドライバにあることが前提であり、普及に際してはこのような思想の理解も不可欠である。予防安全の分野では車両を制御することで走行安定性の確保を目的としたABS(Anti-lock Brake System)、TCS(Traction Control System)、ESC(Electronic Stability Control)システムが実用化されている。車両が操縦不能状態となり、事故につながる場合にその不能状態の発生を抑制することを目的として開発されている。また、最近ではVDIM(Vehicle Dynamics Integrated Management)が開発され、一部車両で実用化されている。VDIMはエンジン、ブレーキ、ステアリングなど、それぞれ単独で制御していた機能を一つのシステムとして統合制御し、理想的な車両運動性能とより高い予防安全性を目指したシステムである。衝突安全分野では被害軽減の技術として、PCS(Pre-Crash Safety System)が開発され、実用化されている。事故が起こる直前に危険の認知・判断・回避操作を支援するシステムで、前方の車両や障害物をミリ波レーダ等で検知し、衝突危険性が高いと判断した場合はドライバに警告し、ブレーキ操作を促し、更にブレーキ操作がない場合にはプリクラッシュブレーキを作動させて速度を低減し、万一の衝突に備えてシートベルトを引き込んで、乗員の衝突被害を軽減するシステムである。

事故が起こってしまった場合の衝突安全システムにはエアバッグに代表される乗員保護システムがある。正面衝突・側面衝突・後突・横転等の衝突形態に対する効果が認められてきている。衝突安全に対する今後の期待は乗員保護のみでなく、特に、交通弱者である歩行者・高齢者に対する被害軽減が要求される。この歩行者保護については、歩行者の衝撃を緩和する歩行者保護ボデーが一般的に普及しているが、一部の車両ではポップアップフードも採用されてきた。また、事故後の乗員救出や、二次災害防止、事故情報のシステムも開発され実用化してきている。

次節より、運転支援、予防安全、衝突安全の各々について現状のシステムと今後の動向について代表例を紹介する。

## 2. 2. 2 運転支援システムの動向

### ●AFS(Adaptive Front Lighting System)

AFS はカーブを走行時にステアリング舵角と車の速度からカーブの旋回半径に適したランプの制御角度を算出し、ヘッドランプの向きを左右方向に作動させるシステムである。ドライバの注視点は、車速が早いと遠くに、車速が遅いと近くなるので、それにあわせて自動でランプの角度を振る。

このシステムによって、コーナリング時の視認距離が従来よりも向上する。AFS の将来技術の一例としてナビ強調 AFS と IHS(Intelligent Headlamp Control System)がある。このシステムはステアリング情報に加えてナビの地図情報も活用して配光を制御する。これにより、従来の AFS でのステアリング情報のみの場合に発生するカーブの入り口でのスイプルの開始遅れが改善され、ドライバの注視点の方向をいち早く照らすことができるようになる。

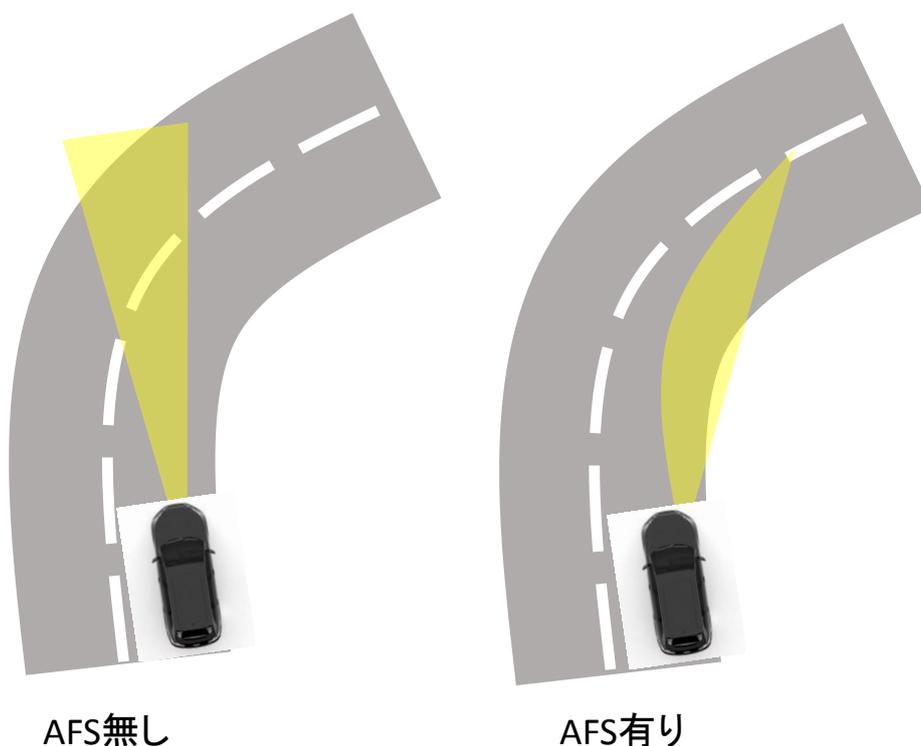


図 2.2 : AFS イメージ概要

### ●ACC(Adaptive Cruise Control)

ACC は操作支援まで行う運転支援システムの代表的な例であり、近年、多くの車に装着されてきている。このシステムは設定した車速維持だけでなく、車間距離を検出するレーダセンサを用い、自車と前方車との車間距離を検出して車速を制御するシステムである。高速道路や自動車専用道路などで自車線上の先行車を検出し、車速に比例した車間距離を保ちながら追従走行を行うことに適している。

近年では渋滞時のストップアンドゴーのような状況でのドライバーのアクセル操作やブレーキ操作の負担を軽減するものも出てきている。尚、このシステムの中で、レーダセンサは検出物との車間距離、相対速度などを的確に検出して車間制御を行うコンピュータに情報を送信するセンサで、ACC システムの中で最も重要なセンサであると同時にプリクラッシュセーフティシステム用センサとしても共用している。

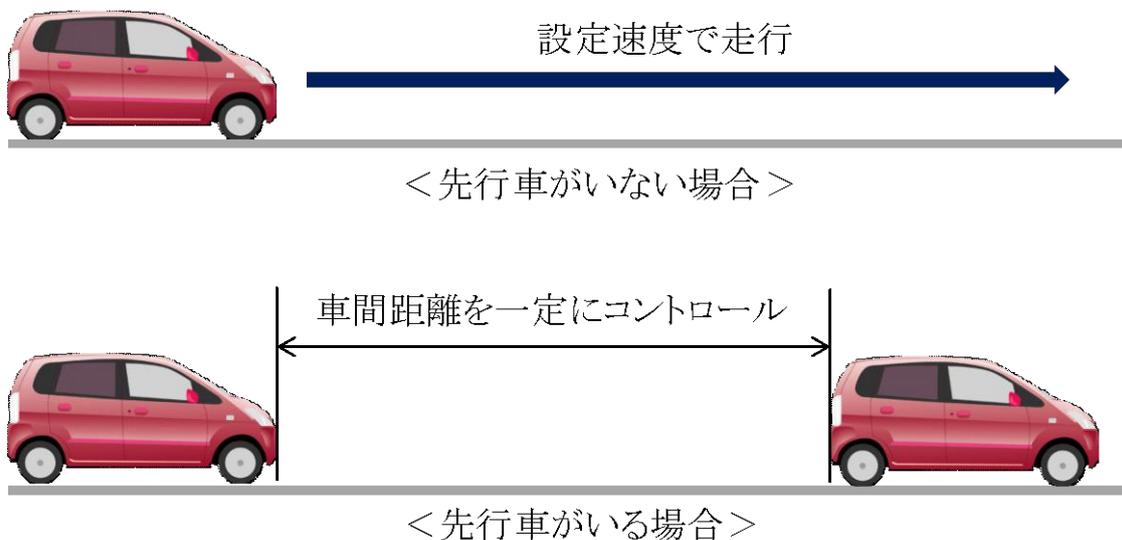


図 2.3 : ACC 概要説明

### ●LKA(Lane Keeping Assist System)

車線内走行時のステアリング操作を支援して、運転負担を軽減するシステムである。車線からの逸脱が予想される場合、警報により、ドライバーに注意を喚起し、車線逸脱を知らせる警報機能や車線内の中央付近を走行しやすいうように、小さい操舵力を連続的に制御することで、ドライバーのステアリング操作を支援する車線維持支援機能を有する。

車両前方の道路の白線を検出するカメラユニットからの自車横位置情報、前方道路情報、舵角センサによるステアリング操舵角度および自車速度により、EPS（電動パワーステアリング）を通じて、操舵をアシストする。

## 車線維持のための操作支援制御

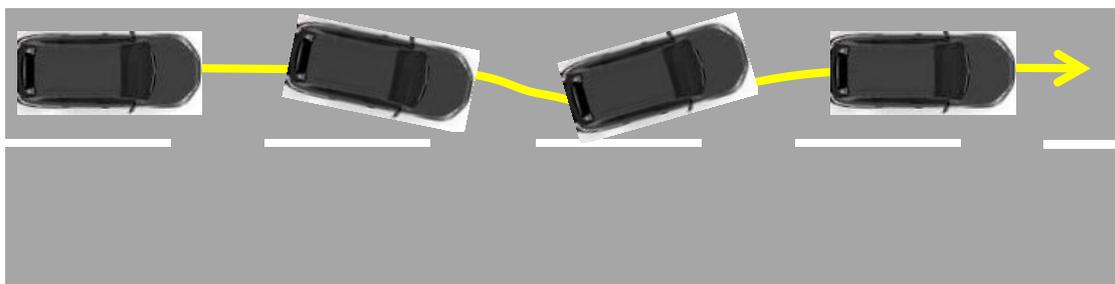


図 2.4 : LKA 概要説明

### 運転支援システムの今後

交通事故で最も多いのは、ドライバーによる認知エラーであることが知られている。その認知エラーを防ぎ、危険に近づかないようにするために、まず視界の確保をすることと共に認知に必要な周辺情報を提供することが重要となる。そのために悪天候や悪条件下で視界を補助するための技術や、車両周辺情報を提供するための周辺モニタシステムや歩行者を認識し、警報するシステムなどが開発され、普及していくと考えられる。

これらの要求に応えるべく周辺認識センサの開発が進められており、システム性能を引き出すためのアルゴリズムの開発やセンサハードウェアの開発が普及のための低価格化への対応が必要とされている。

もう一つの主要な開発項目はドライバーモニタである。運転の主役は最終的にはドライバー自身であり、運転中のドライバー状態を把握し適切な支援や警報を行うことも重要な技術となる。特に最近では飲酒運転への対応も非常に注目を浴びている。これらの開発にはドライバーの状態を検出するモニタリング技術とその結果を元にドライバーに違和感を与えずに支援、警報をするための HMI 技術の開発も非常に重要と言える。

## 2. 2. 3 予防安全システムの動向

### ●ESC(Electronic Stability Control)

予防安全システムとして制動時の車輪ロック防止装置である ABS (Anti-lock Brake System), 発進・加速時のホイールスピン防止装置である TCS (Traction Control System), 横滑り防止装置の ESC (Electronic Stability Control) 等の車両運動制御システムが製品化されている。

ESC は世界の車両メーカーから, VSC, VSA, VDC, ESP, DSC などのシステム名で世の中に出ている。事故統計調査で ESC の装着により, 車両単独事故・正面衝突事故が大幅に低減するというデータが報告されている[18]。このような事故率低減効果が明らかになるにつれ, 世界各国で装着義務化の動きが出てきている。ESC は急なハンドル操作時や滑りやすい路面を走行中に車両の横滑りを感知すると, 自動的に車両の進行方向を保つように車両を制御する。ESC のコンピュータからの指令に基づいて各車輪に適切にブレーキをかけ, エンジンの出力も制御することにより, 車両の進行方向を修正, 維持し, 横滑りの発生を防止する。

車両の前方がカーブの外側に押し出されようとした際、ESCが内側後輪にブレーキをかけて、車両の方向を修正する。

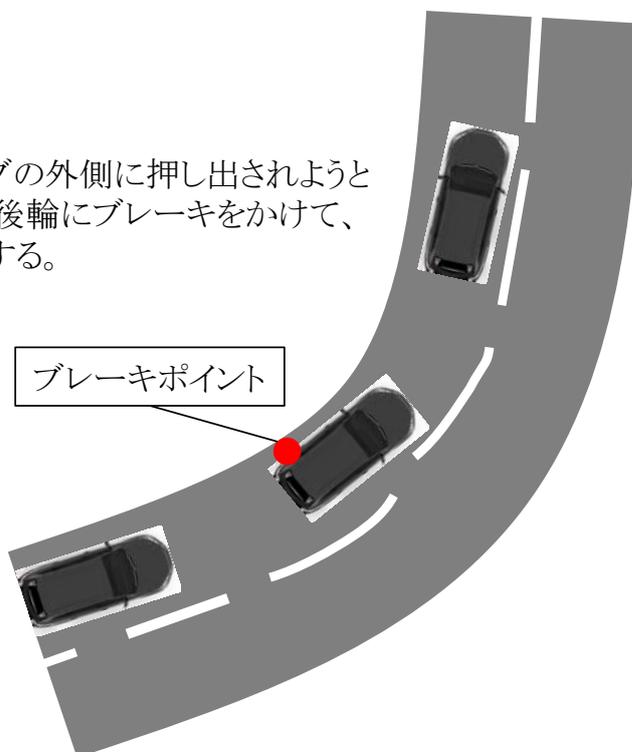


図 2.5 : ESC 概要説明

## ●VDIM(Electronic Stability Control)

従来の予防安全技術である ABS, TCS, ESC, 等は車両が限界を超えそうになり車両が滑り出して初めて介入する制御である。最近では、それらの制御を統合することで運動性能面や安全面の飛躍的向上を目指し、車両挙動を理想状態にするために、VDIM と呼ぶ制御概念が導入されている。

VDIM は、エンジン、ブレーキ、ステアリングなど、それぞれ単独で制御していた機能を一つのシステムとして統合制御することで、理想的な運動性能とより高い予防安全性とを両立させる先進の機能である。たとえば濡れた路面のカーブなど車が横滑りする可能性のあるときには、エンジン出力制御、ブレーキ制御を働かせることで滑り出しを抑制し、更に V G R S (Variable Gear Ratio Steering) を用いたアクティブステアリング統合制御によって前輪の切れ角をコントロールし車両姿勢を安定させるシステムである。

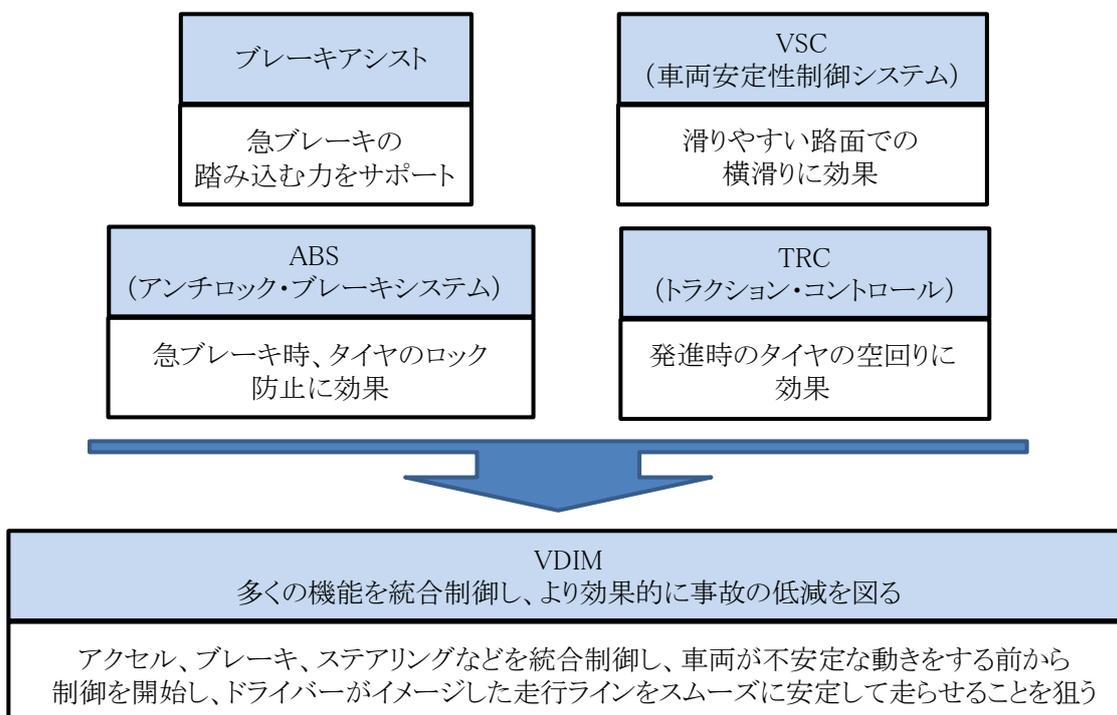


図 2.6 : VDIM 概要説明

## 2. 2. 4 衝突安全システムの動向

### ●PCS(Pre-Crash Safety System)

PCS 技術は、衝突の可能性を事前に検知してドライバーに知らせるとともに、万が一、衝突が避けられない場合には、必要な装備を衝突に備えて作動させることで、乗員の被害を軽減する技術である。このシステムは 2003 年に初めて商品化された。ミリ波レーダで進路上の車両や障害物を検知し、まず衝突の可能性が高まった場合に衝突警報（ブザー鳴動、メータ表示）され、ブレーキアシストがスタンバイされる。更に衝突不可避と判断されるとブレーキ介入制動とシートベルトの巻き取りにより衝突時の被害軽減に備える。図 2.3 に参考としてトヨタ自動車株式会社のプリクラッシュセーフティシステムの概要を示す。

その後 2004 年には、前方カメラの搭載により、画像認識情報を加えることで、検知能力が向上された。更に、2006 年には、前述した室内カメラによるドライバモニタシステムの追加により顔向き検知を行い、正面を向いていない状態で衝突の可能性が高いと判断した場合に、早いタイミングで警報するシステムへと進化している。最新のシステムでは、検知性能を一層向上させた新型ミリ波レーダと新開発のステレオカメラを採用し、ミリ波レーダで検知した情報にステレオカメラによる立体物認識情報を付与することで、車両や障害物の検知に加え、「歩行者」の検知をも実現させた。またヘッドランプ内蔵の近赤外線投光器により、夜間の検知をサポートしている。更に後方専用のミリ波レーダも初めて搭載された。リアバンパ内に設置されたミリ波レーダで後方車両の接近を検知し、追突の危険性があると判断した場合、まずハザードランプを点滅させ、後方車両に注意を喚起する。更に後方車両が接近した場合には、フロントヘッドレストに内蔵されたセンサで頭部位置を検出し、追突前に「プリクラッシュインテリジェントヘッドレスト」を適切な位置まで移動させ、追突された際の鞭打ち傷害の軽減に備えている。今後、PCS は更なる交通事故の被害抑制のために、システムが作動対象とする事故形態の拡張と、警報や制御介入するタイミングの早期化などの技術開発が求められる。また、搭載車両の普及促進に向けて、ユーザーへの認知活動、システムの低コスト化が進められている。

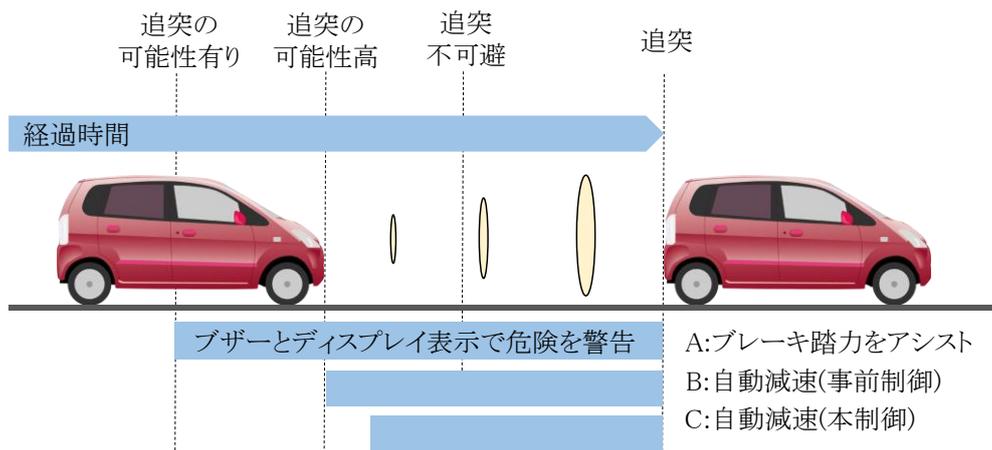


図 2.7：プリクラッシュセーフティシステム概要

## 2.2.5 安全技術動向まとめ

安全技術動向のまとめとして図 2.8 に既存の安全技術を一覧にまとめる。このように安全技術は日進月歩で進化している。技術の進化は日本に限ったことではなく世界中で安全技術に関する競争が展開されている。次節では自動車先進国，ドイツ，スウェーデンの例を出し，欧州と日本の安全技術について比較する。

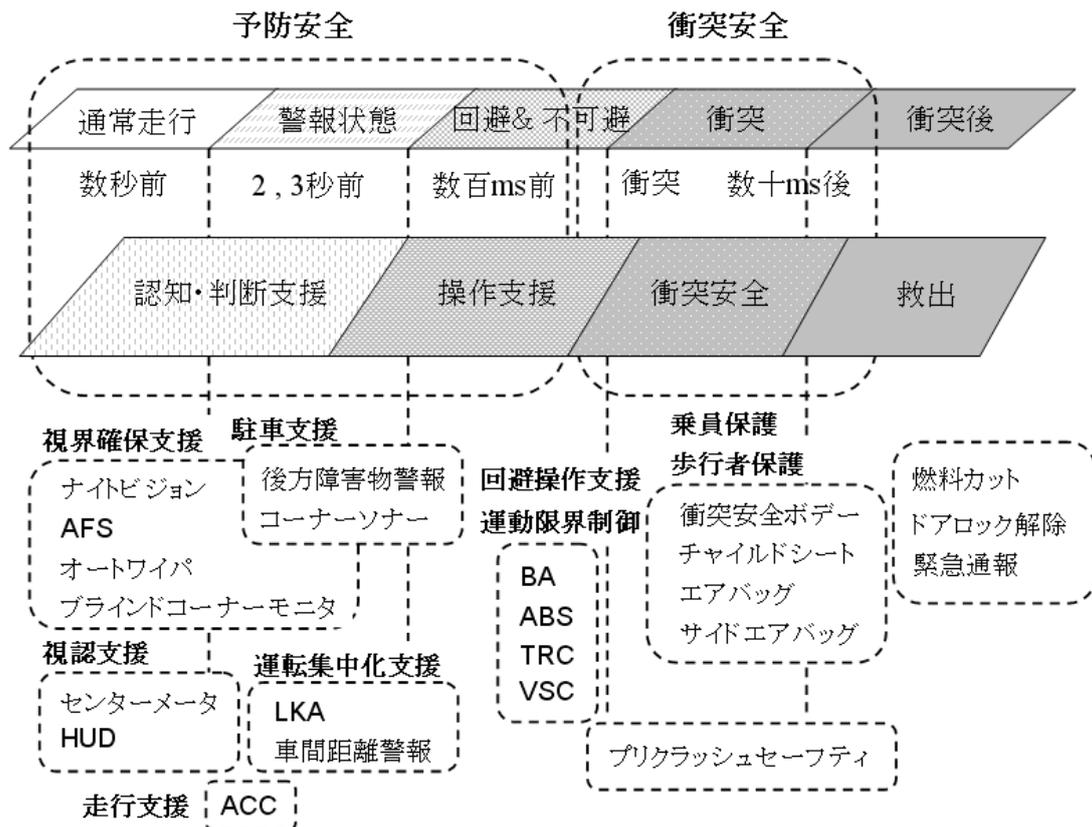


図 2.8：事故直前から事故直後までの安全技術一覧

## 2.2.6 欧州と日本の安全技術の比較

世界の自動車メーカーの中で安全志向の高いメーカーである日本のトヨタ自動車，ドイツの Mercedes-Benz・ベンツ，スウェーデンの VOLVO を例に予防安全技術を比較する．表 2.1 は各社の予防安全技術の中で近年開発された代表的なものを一覧にした表である．表から読み取れるように安全技術名，機能共に類似したシステムを開発し自車に搭載している．このことから国事情により安全技術の発達方向に違いは見られず，世界共通で同じような危険を回避するシステムの開発が進められていることが分かる．これを逆から解釈すると，日本国内で解決が急務となっている安全に関する課題は，世界的に見ても当てはまると言える．

表 2.1：各国の安全思考の高い自動車メーカーの技術一覧

トヨタ自動車の技術	Mercedes-Benz の技術	VOLVO の技術	技術概要
プリクラッシュセーフティシステム	Pre-Safe	プリクラッシュセーフティ (シティ・セーフティとヒューマンセーフティ)	自動車に搭載したレーダーやカメラからの情報に基づき、運転者へ警告やブレーキ補助を行う。
レーダークルーズコントロール	Distronic	アダプティブクルーズコントロール	先行者と走行レーンを認識・判断し先行車を追従するシステム
プリクラッシュセーフティシステムを含む	Attention Assist	ドライバ・アラート・コントロール	疲労、眠気を検知しドライバに警告を実施するシステム
レーンキーピングアシスト	—	・レーンデパーチャーウォーニング ・レーンキーピング・エイド	白線を逸脱した場合に警告を実施する。場合により、車線維持装置を発動するシステム。
ブラインドコーナーモニター	Blind Spot Assist	ブラインドスポット・インフォメーション・システム	運転者から死角になるポイントをカメラで補助するシステム
—	Speed Limit Assist	ロードサイン・インフォメーション	標識を車が認識し、車内の表示機能により表示するシステム
—	—	クロス・トラフィック・アラート	後進時に左右から近づいてくる車の存在を知らせるシステム
インテリジェント AFS	—	アクティブ・ハイビーム	車のライトの照射角を自動調整することで運転支援を行うシステム
ナイトビュー	—	—	赤外線カメラでの撮影映像を表示し、夜間の運転を補助するシステム
ナビブレーキアシスト	Brake assist plus	—	一時停止標識を捕らえてブレーキを補助するシステム

## 2.3 安全技術の中のドライバモニタリング

### 2.3.1 ドライバモニタリング

かつて米国 NHTSA からの委託で行われた米国での交通事故原因に関する詳細な調査(2001 年) では、事故原因の内、環境的要因が 5.4 %、車両的要因がわずか 0.5 %であるのに対し、人的要因(ヒューマンエラー) が 99.2 %を占めるとの驚くべき結果が報告されている(事故には複合の要素が絡み合うため合計は 100 %を越える)[19].1979 年にインディアナ大学の Treat らによって発表された同様の調査では、それぞれ、34.9 %、9.1 %、90.3 %であったことを考えると、この数十年間にインフラ整備、車両の安全対策が進み、相対的にヒューマンエラーの比率が高まったと考えることができる。同様の調査はこれまでに欧州・日本でも行われ、いずれも事故原因の 90 %以上が少なからずヒューマンエラーが生じてもそれをカバーする技術などの重要性が増大していく。この技術は運転支援システムと呼ばれ、国土交通省の先進安全自動車(ASV) 推進計画を始めとする各種プロジェクトで積極的に技術開発が進められている[20]。中でも今後は、ヒューマンエラーの多数を占めると言われているドライバ自身の不注意や不安全行動による事故をいかに低減するかという視点が重要になると思われる。

これらの問題に対処するために数多く研究開発されているシステムがドライバモニタリングシステムである。ドライバモニタリングの究極目標は、ドライバが認知→判断→操作を適正に行える状態にあるか否かを、リアルタイムに判断することである。そのサイクルを壊すヒューマンファクターとしては眠気、疲労、注意力、焦り、快適性、緊張度、脇見、感情など様々な要因があり、それらを全てセンシングすることが理想である。ドライバの「生理」「行動」「心理」状態を物理量として知ることができればそれらは推定可能と言われ、古くから様々なアプローチで研究されているが、人間をセンシング対象として扱う困難さから、これまで十分な検証性能を持った製品は実現されていない。そのような状況下で、何を優先して開発すべきであるかを考えた結果、法令違反別死亡事故要因のワースト 1 である漫然運転への対応が急務であるとの結論に至った。中でも漫然運転に分類される居眠り事故の致死率は、一般の人身事故に比べ 9 倍以上と群を抜いて高いと言われていることから、居眠り運転検知技術の早期開発が望まれている。

また、本研究では居眠り運転などドライバの生理的な現象が要因となる事故のほかに、ドライバ自身の不注意からくる交通事故要因「運転中に運転以外の動作を行う」ことにより発生する不注意事故にも着目する。近年の自動車は走る・曲がる・止まるという自動車の基本特性向上からくる安心感に加え、カーナビゲーションシステムの普及、各種コントロールボタンの増加に伴い、運転という行為自身を軽視し、運転中にも関わらず他の行為を行いやすい状況にある。このことを示すように法令違反別死亡事故要因での

脇見, 不注意運転は漫然運転に次ぐ大きな要因となっている。

上記背景より, 本研究ではドライバモニタリングに包括される「居眠り運転推定」「ドライバ運転姿勢推定」に着目し, 2つのテーマの検知率向上を目標に据え実施した。

### 2. 3. 2 居眠り運転検知技術の動向

ドライバの眠気検出に関する研究事例を表 2.2 にまとめる。検出方法は, 車両情報や操作情報を用いる方法とドライバの生体情報を用いる方法に大別される。いずれの方法も真の眠気を直接計測しているわけではなく, 眠気と相関がある物理量を計測し, その結果から眠気を推測している。

車両情報を用いる方法では, ステアリングの操舵パターンなどからの推定方法[21]がよく知られ, 1983 年には早くも製品化されている。これは操舵パターンや走り始めてからの運転積算時間などからマイコンがドライバの状態を想定し, 休憩を促すシステムであった。最近ではカメラにより車線内での蛇行運転を検出し, その周波数と振幅の特徴から覚醒状態を推定するシステム[22] や, 白線認識カメラやレーザレーダ, その他のセンサを組合せ, 蛇行率・操舵量・操舵の単調度からドライバの注意力レベルを判断し, 必要に応じて音声で注意を促すシステム[23] が開発されている。注意力低下判定にはファジー推論を導入し, 十分な走行実験を重ねてドライバの感性にあった警報タイミングを実現し, 注意力が低下していると判断した場合は早めに警報する機能も備えている。この方法は簡便ではあるが, ファジー推論の学習に数時間を要すると言われており, また, 突発的な眠気の検出が困難であるなど課題も多い。さらに, 今後は ACC(Active Cruise Control) の普及など車両制御の自動化に伴い, 眠気の判定に使えるドライバ操作情報量が減少していくことが予想される中で, 検出精度をいかに確保していくかが課題である。

一方, 生理指標を計測するものとしては, 循環系・呼吸系・中枢神経系・視覚系・基礎代謝系など, 様々な方式が提案されている。循環系では心電図(ECG)による心拍や, 血圧・脈圧, 呼吸系では換気量, 中枢神経系では脳電図(EEG)による脳波, 視覚系では眼電図(EOG)による眼球運動や瞬目, 基礎代謝系では皮膚電気活動(EDA)や体温, 発汗, 内分泌系ではコルチゾールやアドレナリンといった具合に様々な生理指標から覚醒度を推定する多くの研究[24]がなされている。その中でも, 瞬目を検出する方法は他の方法に比べて覚醒度低下をよく反映することが知られ, 眠気を早期に検知できる可能性があるものとして有望視されている。

瞬目を正確に計算する方法としては EOG(Electro-Oculogram)がよく用いられる。EOGを解析することで, 視覚依存性の強い作業下で高頻度に自発発生するサッケード眼球運動が, 覚醒低下時に低周波成分増加が生じることが確認されている。これを応用して眠気状態を推定できることが期待されるが, 計測のためには電極を眼瞼部に貼

表 2.2 : ドライバの眠気推定事例

	計測対象	計測手段	推定の着眼点
車両情報 操作情報	操舵パターン 車線と車両のズレ 車速・車間距離	ステアリング角センサ 白線認識カメラ レーザレーダ	操舵周波数 操舵パターン ふらつきパターン
生体情報	心拍 呼吸 脳波 発汗, 体温 眼球運動 瞬き	心電図 (ECG) 圧力センサ 脳電図 (EEG) 温湿度センサ 眼電図 (EOG) カメラ	心拍数 心拍数変動分散 $\alpha$ 波 $\theta$ 波含有率 発汗量 深部体温変化 瞼開閉度 瞬き回数

る必要があり、ドライバへの煩わしさから現実的ではない。それを解決する方法として、眼鏡フレームに搭載した近赤外 LED とホトダイオードで眼球運動に伴う受光量変化を計測しサッケード眼球運動を検出する方法[25] や、瞬きに伴う受光量変化により瞬目速度と振幅を検出、詳細解析することで眠気を推定する方法[26] なども検討されているが、いずれの方式も計測器を着用することへの抵抗感が解消されたわけではなく、一部ユーザーを除きコンシューマ向け製品として応用できるものではないと思われる。一方、インストルメントパネル等に設置したカメラにより、ドライバの顔画像を完全無拘束で遠隔撮像し、画像処理により眠気に相関がある物理量を検出する方式が考えられている。EOG 計測をパンチルトズームカメラに置き換えた眼球運動計測も一部で検討されている[27] が、事例としては瞬目状態に着目した方式が多い[28]~[33]。それらの多くは、瞬目時間(閉眼時間) や眼の開度、瞬目回数などから推定するものであるが、この中では、長い閉眼時間の出現比率や一定時間にドライバが眼を閉じている時間割合(PERCLOS) が有効との報告が多い。これは眠気が増すと瞬目の閉眼時間が長くなるという知見に基づくもとである。

瞬目以外でコンシューマ向け眠気検出装置として実用化に向けた開発が行われているものに、心拍センサを使用した眠気状態検出装置がある[34]。これは、ステアリングに設置した電極を両手で握ることで心拍信号を計測し、心拍数の低下量で眠気の兆候を、心拍ゆらぎの高周波成分である HF の上昇により眠気発生を検出するものである。

しかしながら、心拍センサを使った眠気検出は一定時間以上の連続した心拍信号データを必要とすること、実際の運転では両手で安定してステアリングを握っている時間は限定されるなどの制約があり、運転中のドライバの状態をリアルタイムに常時モニタリングすることは困難である。次に近年開発され実用化された居眠り検知システムについて紹介する。

### 瞼開閉度検出システム(トヨタ自動車)

トヨタ自動車は2008年にドライバの目の開閉度から居眠り運転を検知するシステムを実用化した。このシステムはステアリング回転軸上部に設置したカメラでドライバの顔を撮影し、上下瞼の位置や顔の向きを検知するものである。眠気を検知すると事前警告する。

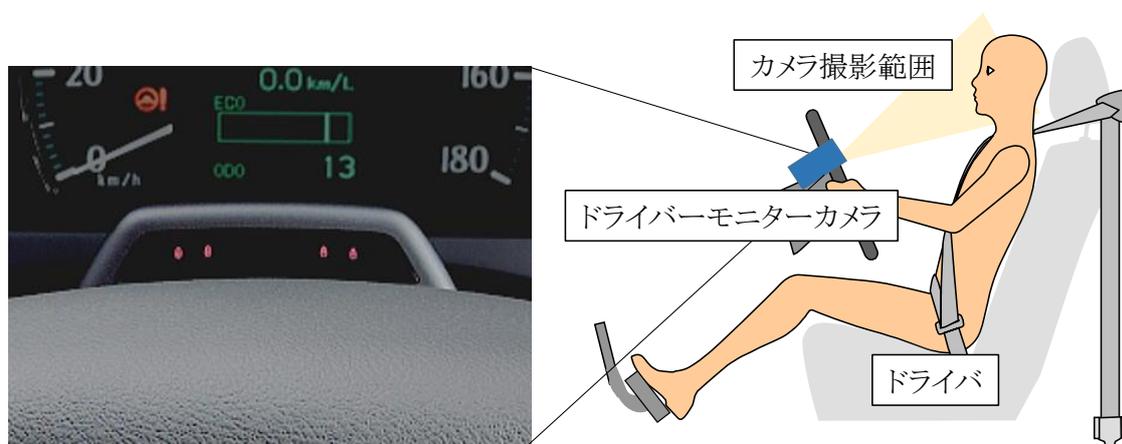


図 2.9 : 瞼開閉度検出システム概要説明

### アテンションアシスト(メルセデスベンツ)

アテンションアシストはドライバの状態を検知して、疲労していたり注意散漫になっていたるときに音とメッセージで警告をするシステムである。このシステムは運転やオーディオを始めとする装備の操作など検出に用いるパラメータは70以上にのぼる。中でも大きな役割を果たしているのがステアリング舵角である。

### 2.3.3 居眠り運転検知に関する研究の課題

本節では、前節で述べた居眠り運転検知を目的とした研究や実用化されたシステムから現状の課題を抽出し、本研究で解決すべき課題について述べる。以下表 2.3 は近年の先行研究の研究結果をまとめたものである。各研究グループ共、推定段階数や特徴量として用いている指標が異なることから、横並びの比較はできない。しかし、いずれの研究グループも、居眠り運転検知を行う際の流れである、「実験」→「指標からの特徴量抽出」→「判別アルゴリズム適用」という手順の中で、「指標からの特徴量抽出」に力を入れた研究である。その成果として正解値や相関値を算出しているが、正解値は 8 割以上の水準を出しているのにも関わらず、正相関の基準と言われている 0.7 以上の相関値を算出できたグループは未だ無い。その理由として、本研究では判別アルゴリズムに問題があるのではないかと考えた。各研究グループともに判別アルゴリズムについては一般的なパターン認識手法や重回帰分析に代表される多変量解析手法をそのまま適用しており、工夫を行っていない。このような一般的な判別アルゴリズムで共通していることは、解析区間ごとに独立して推定(眠気レベルの判定)を行っていることである。独立した推定について図 2.10 に示す。一般的な推定方法では Y1 では f1 の特徴量のみを用いて推定、Y2 では f2 の特徴量のみ用いて推定と区間ごとに独立して推定を行っている。眠気レベルのように徐々にレベルが変わっていく傾向のあるものを推定する場合は、その特徴的な傾向を判別アルゴリズムに組み込むことで精度向上を図ることが可能と考えられる。よって、本研究では、眠気の特徴を解析し、解析結果を判別アルゴリズムに反映することで、眠気レベル推定の高精度化を目指していく。

表 2.3 : 居眠り運転検知を目的とした先行研究例

グループ名	推定段階数	指標	推定値
Pai ら [3]	2	脳波	正解率 : 85%
Tsuchida ら [4]	3	瞼開閉情報 心拍情報	正解率 : 75% 相関 : 0.56
沼田ら [10]	5	脳波 瞼開閉情報 心拍情報	相関 : 0.69



表 2.4：居眠り運転検知を目的とした先行研究例

グループ名	推定のための装置	結果	課題
加藤ら[11]	車載カメラ	周辺光量など安定した状態であれば高精度で推定可能 (定量的な結果無し)	太陽光コントラスト変化により、推定が外れやすくなる。
伊藤ら[12]	座面圧力計測装置	座り直し前：8割 座り直し後：5割	座面圧力は座る度に一意に計測できない。よって、精度にばらつきが生じる。

しては、伊藤ら[12]によりシートに圧力分布センサを設置し、あらかじめ決められた4つの動作をパターン認識手法により推定する手法が試みられた。しかし、最終的な姿勢がよく似た2つの動作について推定が困難であることと、座り直し(一度シートから離れて改めて座ること)を行った際に推定率が変化するということが問題として挙げられている。また、カメラ、シートへの圧力分布センサ両方の課題として、ドライバの体格や服装などの影響により、汎用的な特徴量を抽出しにくいという問題もある。さらに同一被験者でも日ごとの服装や動作の微妙な変化を考慮したうえで高い推定率を出すためには、1箇所のセンサに頼るのではなく、数多くのセンサを設置し動作を同時計測し、その出力の組み合わせによって正解を求める方法が好ましい。また、リアルタイムで動作を推定していくためには高速な学習アルゴリズムを用いる必要もある。

このような先行研究の報告からも分かる通り、ドライバの運転姿勢推定は前述した居眠り運転検知として推定精度を追い込む段階より前であり、車外環境の変化やドライバの初期着座位置の変化により安定的な推定が困難であることが現状の問題である。この問題を解決するためには、刻一刻と変わる車外環境やドライバの初期着座位置に依存しない推定方法を確立する必要がある。そこで、本研究では上記問題を解決することを主眼におき、3つの固定点で位置決めされることにより、シートと比べ座り直しを行った際の初期位置変化が少ないと考えられるシートベルト(図 2.11)に着目し、シートベルトからの体圧変化情報によるドライバ運転姿勢推定手法を提案する。

次になぜシートベルトを選択したかについて述べる。一部のレース用のシートベルトを除き、一般的な車に搭載されているシートベルトは3点の固定点と2本のベルトから構成されている。このベルトは乗員の快適性を損なわず、事故時には保護できるよう一



図 2.11 : 3 点式シートベルト

定のテンションで緩やかに乗員を拘束する特性を持つ。この特性により、シートベルトに圧力センサを取り付け、出力信号を取得する場合、前述した服装による精度への影響も排除でき、かつ、カメラのような光量の問題も払拭することが可能である。また、2本あるベルト両方に圧力センサを取り付けることで、位置が異なる2つの出力信号を取得することができる。この点も安定的な推定に対し有利に働くと考えられる。本研究においてはこれらの利点を実験で確認し、そして先行研究と同一の実験を行い推定精度の向上を目指す。

# 第3章 ドライバの眠気レベル推定アルゴリズムの開発

本章では、第2章で述べたドライバの眠気レベル推定の必要性に基づき、近年の予防安全技術と連携できる高精度な眠気レベル推定アルゴリズムの提案を行う。

## 3.1 安全面に基づく居眠り運転検知の多段階化

第2章で述べた予防安全技術の中での居眠り検知に関する研究事例についてまとめると、従来の研究では、居眠り検知を行う際の評価方法は、「眠っている」「眠っていない」の2つに判別する事例、又は眠気と相関があると言われている指標との相関評価を事例に分類できる。しかし、実際に居眠り運転検知システムとして用いる場合には、プリクラッシュセーフティシステムのように検知後に覚醒させるシステムと連動させて使用する。よって、ドライバの眠気検知を行う際は既存の予防安全技術との連携を考慮し、検知するタイミングを定義する必要がある。

はじめに、検知するタイミングについて検討する。既存の予防安全技術は通常運転から事故発生までの間に「認知判断支援」「操作支援」「衝突安全」の3段階に分けることができる。予防安全の括りでいうと「認知判断支援」と「操作支援」が該当する。認知判断支援とはドライバに対し注意を促す支援であり、例えば河村らにより提案されているオートグルーピングシステム[35]や各務らによる香り提示による覚醒支援などが挙げられる[36]。一方、「操作支援」とはドライバを無視し車両自体に制御を与える支援を指す。例えばプリクラッシュセーフティシステムなどがこれに該当する。よって、事故発生までの間に2段階の支援の介入が可能であるため3段階の眠気レベルを定義することが最低条件となる。

次に、3段階の基準について述べる。「認知判断支援」「運転操作支援」の2つの支援介入タイミングと顔表情評定値5段階（顔表情評定値については3.3.1節で述べる）について検証を行った北島ら[10]によると、通常走行から事故発生までを時系列的に図3.1のように表すことができる。この図から顔表情からの眠気レベルが0と1の場合は支援の必要は無い「Low Level」、眠気レベルが2のときは認知判断支援が必要となる「Middle Level」、眠気レベルが3と4のときは操作支援が必要となる「High Level」と基準を決めることができる。この3段階の基準により現在既存の安全技術との連携

ドライバ支援	支援無し	認知判断 支援	運転操作 支援
ドライバ状態	通常運転	意識低下	操舵不能
顔表情評定値	0 1	2	3 4
本研究での 眠気レベル	Low Level	Middle Level	High Level



図 3.1 : 支援レベルによる眠気レベルの定義

し易い居眠り検知システムとすることができる。

本研究では図 3.1 に従い、Low Level, Middle Level, High Level での眠気レベル推定を行っていく。

### 3.2 実用面からの要件に基づく計測機器の選定

前節で述べた通り、ドライバの居眠り検知に関しては古くから研究がなされており、使用される計測機器(使用特徴量)も多種多様である。しかし、どの特徴量も一長一短であり、単一センサからの居眠り検知では高精度が期待できない。そこで、実用面からの要件を列挙し、その要件に基づき複数のセンサを用いて居眠り検知を行う必要がある。以下に要件を列挙する。この要件は株式会社デンソーでのドライバモニタリングシステムの開発要件である(表 3.1)。本研究でもこれを参考に機器選定を行う。そして、表 3.1 に加え、全てのドライバがセンシング対象であることという条件を含める。

居眠り運転を引き起こす病気として、昼間に突然強い眠気に襲われる睡眠時無呼吸症候群(SAS)が有名である。この SAS 患者数は国内に数百万いるとされ、その潜在患者は 5 人に 1 人とも言われている。塩見らは運転免許を保有する 1529 名の SAS 患者について、SAS 重症度と過去 5 年間における運転事故の関係について調査した[37]。その結果、SAS 重症度を示す 2 種類の尺度である無呼吸底呼吸指数(AHI) およびエプワース眠気尺度(ESS) のいずれにおいても、重症度が高くなるにつれ居眠り事故率が有意に上昇していることが分かっている。だからといって、SAS 患者だけを対象に居眠り検知しても事故は低減できない。なぜなら、SAS などの睡眠リズム障害を自覚していない

表 3.1：ドライバモニタリング開発要件

要件	詳細説明
ドライバの安全運転環境を妨げないこと	センサがドライバの安全視界を妨げることがあってはならない。また、事故の衝撃などで乗員がセンサに衝突しても人体がダメージを受けにくい搭載位置や形状であることが必要である。更に、ドライバにセンサを装着するなど運転への煩わしさを感じさせることがないようにセンサは非拘束・非接触であることが望ましい。
車両搭載が物理的に可能で厳しい使用環境に耐え得ること	車両搭載可能なサイズで、電磁波ノイズの厳しい車両環境において安定的な精度で計測可能なものとする。
リアルタイムセンシングが可能なこと	逐次変化していくドライバの状態を運転開始直後から速やかにセンシングでき、かつ昼夜間問わず常時センシングが可能なことが必要である。
浅い眠気から深い眠気まで検出レンジが広く、また瞬眠も判定可能なこと	ドライバ自身が眠気を自覚するような深い眠気状態では、眠気が増すほど覚醒させることは困難になるため、できるだけ早い段階、すなわち浅い眠気がセンシングできると望ましい。また、平均的な眠気推定だけでなく瞬眠のような現象についても瞬時判定可能なアルゴリズムである必要がある。

潜在患者が相当数存在するのに加え、眠気は健常者においても日常的に経験していることからわかるように決して病気だけの問題ではないからである。最近の研究では、眠気はサーカディアンリズムやサーカセミアンリズムといった周期の大きなリズムと、ウルトラディアンリズムといった2時間周期の小刻みな体内時計に支配される人間固有のリズムが影響していることが分かっている。つまり、健常者においても様々な時間帯に眠気に襲われ、それに長時間運転や単調な走行環境が重なるとさらに眠気を助長することになる。従って、居眠り運転はいつ誰にでも突然襲ってくる可能性があるものとして、対象者を限定せずセンシングすることが重要である。

以上、5項目が開発要件として定義されている。先行研究などで使用されているセンサは視覚系(カメラ)、ステアリング操舵情報、ECG、EOG、EEG、呼吸が挙げられる。このセンサの中から上記要件を満たすセンサを選定する。しかし、ECG や EEG などは電極を用いることが一般であるが、自動車分野の研究の中ではこのような電極を要するセンサを非接触でデータを取得可能にする研究も行われており、それらの研究の進度も考慮して選定を行う。

## 車載カメラの利用

車載カメラは居眠り検知に用いる際、瞬目は閉眼度など比較的眠気と相関の高い特徴量を算出できることが知られている。また、ドライバに対し非接触でデータを取得でき、解析には一定以上の時間を要さず逐次的な変化に対応可能である(図 3.2)。よって、居眠り検知に対し最も実用的であるため本研究でも用いることとした。しかし、車載カメラにも弱点があり、それはメガネやサングラスを着用しているドライバに対し、データ取得が不可能になる点や眼は意識的に動かすことができ、眠気による変化なのかそれとも他の要因による変化なのか判別することが困難である。よって、他のセンサを用いることで弱点を補う。

## シート型圧力センサ(心電データ, 呼吸データ, 荷重データ)の利用

心電データや呼吸データなどはドライバに専用センサを取り付けデータ取得することが一般的であるが、最近ではシートに特殊な圧力センサを取り付け心電や呼吸といった情報を取得できるシートが開発されている。他にも帽子型の脳波センサや腕時計型の心電センサなど多くの研究がなされているが、シート型センサは一般道走行時においても真値との誤差が 5 %以内に留まるほど高精度なものが開発されている(図 3.3)[38]。また、心電や呼吸以外にもシートという形状から運転中ドライバの荷重変動も捉えることが可能である。よって、本研究ではこれらの理由からシート型圧力センサで取得可能な心電、呼吸、荷重の 3 つのデータも使用することとした。これら 3 つの特徴として、カメラの弱点である眼鏡やサングラスの着用に影響を受けない。また、ドライバが意識的に変化させることのできない心電を含んでおり、誤データになる可能性が軽減される。以下に、居眠り検知に用いるセンサの特性についてまとめる(表 3.2)。尚、計測方法についてはシート型圧力センサを用いた場合である。理想的なセンサの条件を複数のセンサを用いることで満たすことが分かる。

表 3.2 : 居眠り検知に用いるセンサ特性

	計測方法	解析区間	外的要因	意識的に変動させられるか
理想的なセンサ	非侵襲	瞬間的な解析が可能	無し	不可能
カメラ	非侵襲	瞬間的な解析が可能	有り (眼鏡)	可能
心電	非侵襲	2分程度必要	無し	不可能
呼吸	非侵襲	1分程度必要	無し	可能
荷重変動	非侵襲	1分程度必要	無し	可能

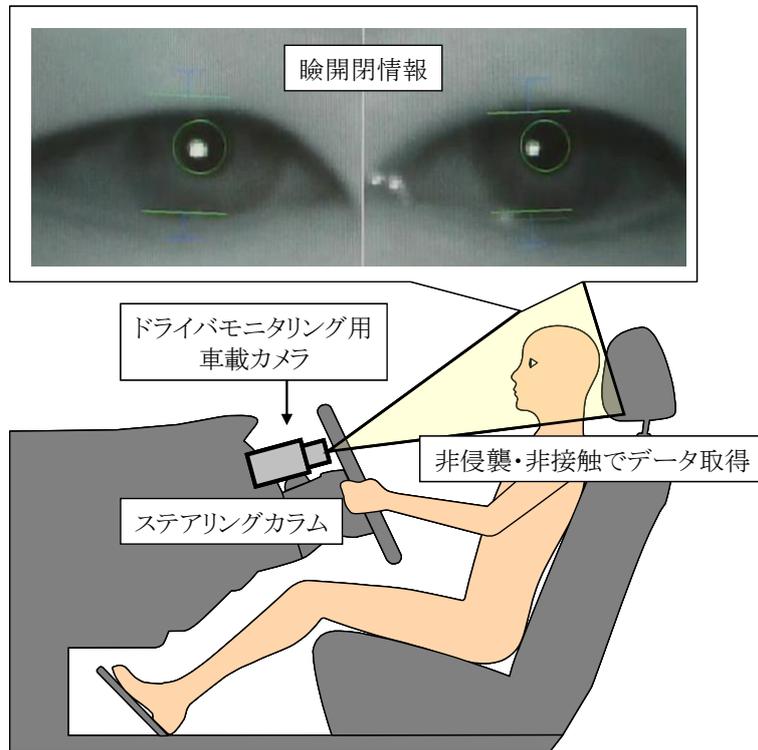


図 3.2 : 車載カメラ特性



図 3.3 : 心拍情報・呼吸情報・荷重情報取得可能なシート型センサ  
(引用 : ITSWC2010 アイシン精機ブース)

### 3.3 ドライバの眠気関連情報の計測と解析手法

#### 3.3.1 顔表情からの眠気レベル

ドライバの居眠りを推定する研究では、眠気の正解値として用いられるものとして、車両挙動から求められる車線逸脱量や脳波から得られる $\alpha$ 波、そしてビデオ映像からの顔表情値など数多くある。この中でも、ドライバの顔表情は眠気評価基準として実用的であるとされている。この方法の論理的根拠としては、先行研究[39]によりドライバの様々な眠気レベルの観察が信頼性・一貫性のあるものとして報告されている点である。また、このビデオ映像による評価は疲労の評価方法としても使われている[40][41]。Zilberg の開発した眠気レベル判定基準[42]は先行研究のように5つのレベル(瞬目、閉眼度、体の動き、あくびなどの指標に基づく Alert から Extremely drowsy) から成り、本研究でも眠気レベルの正解値としてこれを用いた。以下表 3.3 は Zilberg が定めた眠気レベル判定基準である。5つのレベルそれぞれに対し、人間がビデオ映像を見ながら評価できるよう詳細に示されている。また、図 3.4 に評価を行う際の眠気評価値の例について示す。

	Alert	Slightly drowsy	Moderately drowsy	Significantly drowsy	Extremely drowsy
眠気評価値	0	1	2	3	4
顔表情		...		...	

図 3.4 : 眠気評価基準の一例[9]

表 3.3 : Zilberg による眠気レベル判定基準

Drowsiness Level	Drowsiness State	Video Image Indicators
0	Alert	Normal fast eye blinks, often reasonably regular. Apparent focus on driving with occasional fast sideway glances; Normal facial tone; Occasional body movements.
1	Slightly Drowsy	Increase in duration of eye blinks. And possible increase in the rate of eye blinks; Increase in duration and frequency of sideway glances; Appearance of "glazed-eye" look and abrupt irregular movements rubbing face/eyes, moving restlessly on the seat. Occasional yawning.
2	Moderately Drowsy	Occasional disruption of eye focus; Significant increase in the eye blink duration ; Disappearance of eye blink patterns observed during the alert state; Reduction on the degree of eye opening; Occasional disappearance of facial tone; Episodes without any body movement.
3	Significantly Drowsy	Discernible episodes of almost complete eye closure, eyes are never fully open; Significant disruption of eye focus; Periods without any body movement (longer than for level2) and facial tone followed by abrupt large body movements.
4	Extremely Drowsy	Significant increase in duration of the eye closure episodes; Longer durations of episodes with no body movements and sometimes followed by large isolated "correction" movements.

### 3. 3. 2 心拍情報(心拍変動と自律神経系)

#### 心臓の構造と心電図

心臓は、特に脊椎動物の持つ筋肉質な臓器であり、律動的な収縮によって血液の循環を行うポンプの役目を担っている。脊椎動物において、細胞が代謝を維持するには常に血液によってエネルギー源や酸素を受け取り、老廃物や二酸化炭素を運び出す必要がある。そのため、心臓が機能を停止することは生き物の存続条件の一つである代謝・呼吸ができなくなることであり死を意味する。人間の心臓は、二心房二心室であり、二対の心房・心室系からなる構造を持つ。呼吸は両性類と異なり肺のみで行い、また内温性を維持するために高い代謝率を保たなければならず、爬虫類のように肺呼吸を一時停止するゆとりがないため、動脈血を駆出する左心系と静脈血を肺に駆出する右心系が完全に分離されている(図 3.2)。

次に心電図について説明する。心電図は心臓で発生した電氣的刺激を身体各部位で検出、増幅、記録を行ったものである。心臓が活動することで体表に電位変化が生じる。心電図はこの電位の時間変化を記録したものである。人間の心電図は 1887 年 Waller により Lippman の血管電気計を用い、初めて記録された[43]。それ以来、電極の改良、誘導法の改善などが発展し、今日では心臓の病気に関する検査だけでなく、自律神経評価など様々なところで利用されている。心電図の波にはそれぞれ名前があり、出現の順番に P 波、QRS 波、T 波と呼ばれる(図 3.5)。

このような心電図の記録方法は、体表面に電極を置いて体内に生じた微少な電流を増幅して記録を行う必要がある。このためには通常、体表面に 2 個の電極を置き、これらの間の電圧に対して増幅器を用いて増幅して記録する。心電図として記録される心起電力は、電氣的には 1mV 前後、周波数では 0.1~300Hz、インピーダンスとしては 1~20k オーム程度の生体電気現象である。心電図を記録する方法(誘導法)については、国際的な取り決めがあり、12 個の誘導法を用いる標準 12 誘導法が広く用いられている。この 12 誘導は、双極誘導(bipolar lead) と単極誘導(unipolar lead) に分けられる。いずれも 2 つの電極間の電位差を記録する方法であるが、前者は 2 つの電極が同程度に心起電力の影響を受ける部位に電極を置いて記録したものであり、後者は一方の電極(近接電極)を心起電力の影響を強く受けるような心臓の近くに置き、他の電極を心臓から距離的に遠い部位ないし電氣的に電位が小さく安定した部位に電極を置いて記録する。標準的な心電図誘導法としては、双極誘導として標準肢誘導(第 1, 2, 3 誘導)、単極誘導としては単極肢誘導(aVR, aVL, aVF 誘導) および単極胸部誘導が用いられ、これらの 6 個の肢誘導および 6 個の胸部誘導を記録する心電図誘導法を標準 12 誘導法と呼んでいる。この 12 誘導についてその特徴と方法について説明する。尚、本研究での心電図計測法は最も明瞭な波形が取得可能な第二誘導により計測した。

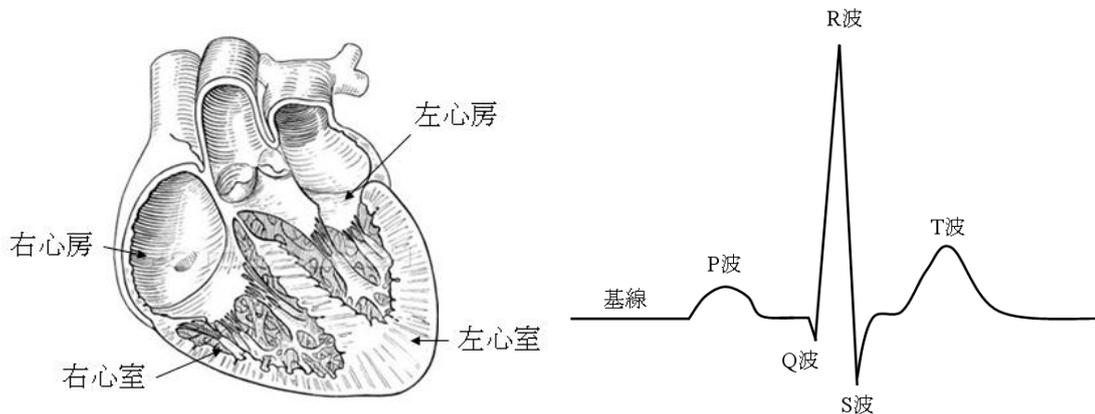


図 3.5 : 心臓と心電図概要

第一誘導	左室の側壁を見る誘導である
第二誘導	心臓を心尖部から見る誘導。四肢誘導で波形が最も明瞭に描かれる
第三誘導	右室側面と左室下壁を見る誘導である
aVR 誘導	右肩から心臓を見る誘導である。逆転した波形が見られる
aVL 誘導	左肩から心臓を見る誘導である
V1 誘導	心臓をほぼ真下から見る誘導である
V2 誘導	主に右室側から心臓を見る誘導である
V3 誘導	心室中隔と左室前壁から心臓を見る誘導である。移行帯が見られる
V4 誘導	心室中隔と左室前壁方向を見る誘導である
V5 誘導	左室前壁と側壁を見る誘導である
V6 誘導	左室側壁を見る誘導である

### 自律神経系と心拍数

心電図からは自律神経系に関連する様々な特徴量を抽出することが可能である。R-R 間隔(RRI:R-R Interval) は心拍数や心拍変動を算出することができる。心臓の活動は自律神経系の影響を受けるため、居眠り運転も含め精神活動とも密接に関係している。自律神経は交感神経と副交感神経の二つの神経系統から成り立っており、内蔵の機能を支配している。自律神経の機能は、強い恐怖を感じたとき、興奮したとき、激しい怒りを感じたとき、緊張したとき、悩みや不安を抱えているときなどの精神的な刺激に対して、それらに反応して交感神経を優位にする。また、体を動かしたり、寒さや暑さなどの物理的な刺激にも反応する。自律神経の働きは、その時々状況下で、体を上手く適応させることにあり、交感神経と副交感神経という二つの神経を必要に応じてスイッチを切替えるように、各器官の働きを調節している。この働きにより人間の体や心の健康を保つようにしている。

## 心電図計測機器

本研究で心電図計測に用いる機器とその解析方法について説明する。心電図取得のためにデジテックス研究所製 AP1000 polymate を用いた(図 3.6)。サンプリングレートは1000Hzである。高サンプリングレートによる測定は交流ノイズ混入の生じ易いため、バッテリーによる直流環境下において測定を行い、計測時に Notch Filter(60Hz Lowpass Filter) を施した。心電図計測後は polymate 専用ソフトである APviewer(図 3.7) を用いて、データをデジタル信号に変換した。

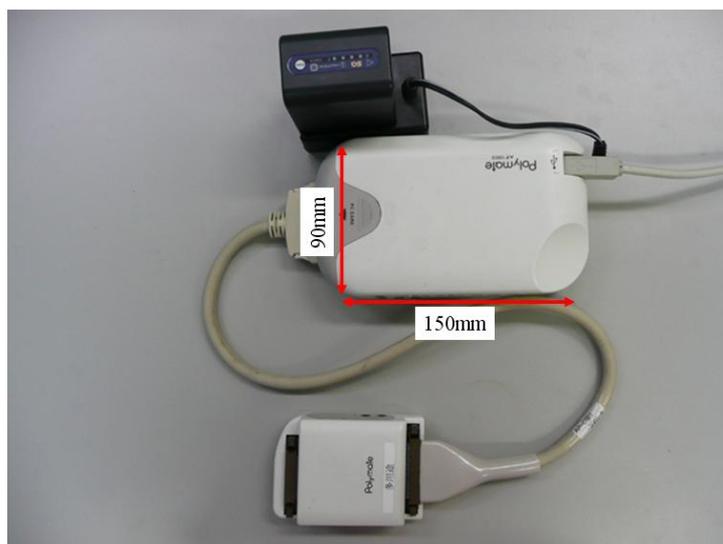


図 3.6 : AP1000 polymate

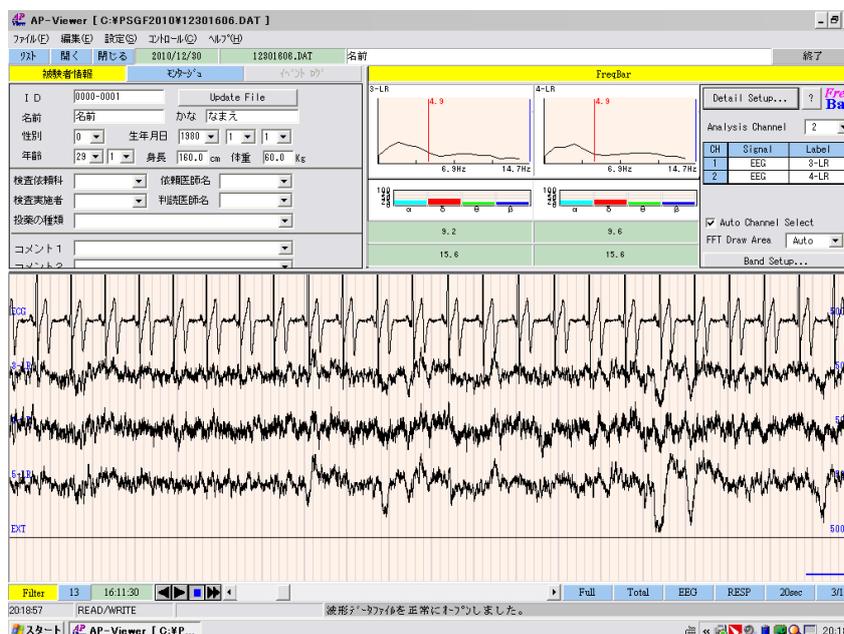


図 3.7 : APviewer

### 3. 3. 3 呼吸情報(呼吸変動と自律神経系)

#### 自律神経系と呼吸変動

肺は脊椎動物の器官の一つであり、肺臓とも呼ばれる。空気中から得た酸素を体内に取り込んだり、老廃物である二酸化炭素を空気中に排出する役割を持つ。この肺により人間は呼吸を行っている。人間の肺は胸部の大部分を占め、主に気道と血管からなりこれらは肺胞で接してガス交換を行っている。肺胞は 3 億個で総表面積は約  $60m^2$  である。肺は横隔膜・肋間筋に囲まれた胸郭の中にある。肺の表面を覆っている膜を胸膜と言い、胸膜は横隔膜や肋間筋を裏打している。肺を覆っている胸膜を臓側胸膜と言い、横隔膜や肋間筋を裏打ちしている胸膜を壁側胸膜と言う。臓側胸膜と壁側胸膜は連続していて一枚の扁平な袋になっている。この袋の中を胸腔と言う。人間の肺は左右に二つあり、右肺は上から順に上葉・中葉・下葉・からなり、左肺は上葉・下葉からなる。この 5 つの肺葉を大葉と言う。左肺に中葉がないのは、左右の肺を隔てる縦隔にある心臓が体幹の中心よりも左に寄っており、その分スペースが小さいためである。大葉は更に細かく 10 の肺区域に分けられる。

肺は心臓を囲う位置にある。そして肺は横隔膜の動きにより呼吸を行い、空気の流入流出によって体積の増減を繰り返している。この体積の増減は心臓への圧迫に繋がっている。前節で述べた通り心拍数は自律神経系と深い関係にあり、肺の体積増減は自律神経系への影響を与えているものと考えられる。このことから呼吸はドライバの居眠りを推定するために有効な特徴量として成り得る。呼吸単体での居眠り検知は行われていないが、大須賀らは特徴量の一つとして用いており、本研究でも呼吸情報を用いることとした。

#### 呼吸計測機器

本研究で呼吸情報を取得するために用いる計測機器について説明する。呼吸情報取得にはフタミ・エム・イーエ社の呼吸ピックアップ AP-C021 を用いた(図 3.8)。呼吸ピックアップはバンド状であり胸部又は、腹部に巻き付け呼吸時の拡張収縮活動から呼吸を検出するものである。バンドの中心部には電気抵抗変化を捉える圧力センサが組み込まれており、このセンサが拡張収縮活動を捉える(図 3.9, 図 3.10)。センサは心電図取得にも用いた Polymate に接続することによりサンプリングレート 1000Hz でのデジタル信号として出力することができる。

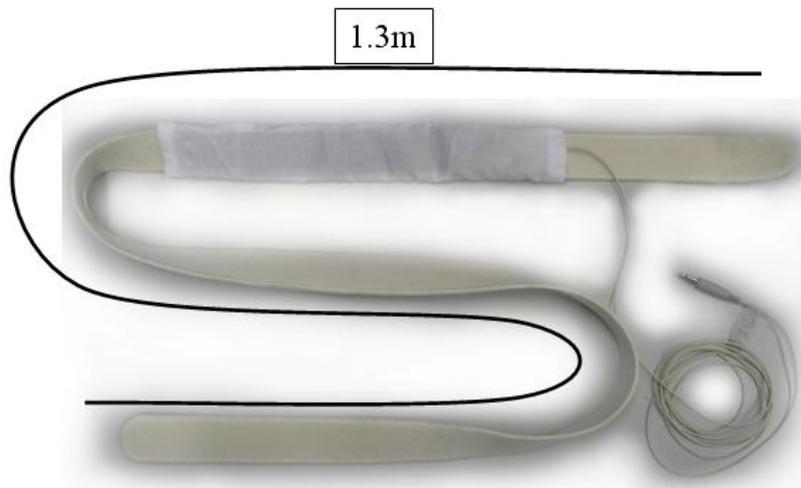


図 3.8 : 呼吸ピックアップ全体図

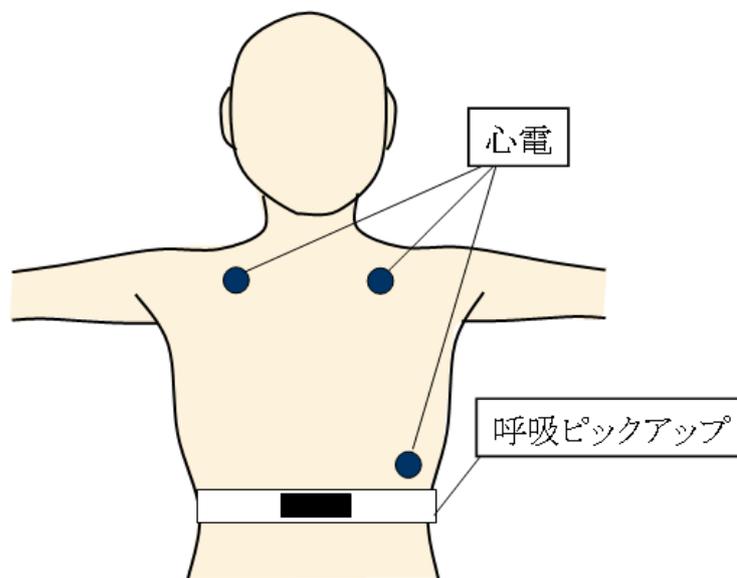


図 3.9 : 呼吸ピックアップ装着図

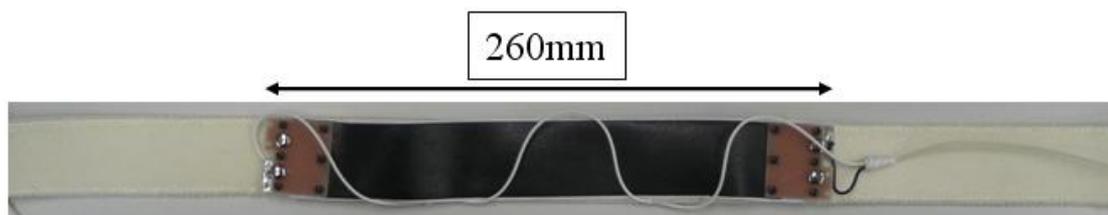


図 3.10 : センサ部拡大図

### 3. 3. 4 カメラからの瞼開閉情報

#### 視覚

人間は視覚により外界の情報の 90%を得ていると言われている[44]. そのため自動車の安全性研究において、人間の視線方向、閉眼時間、瞬き回数等がドライバーの状態推定の情報量として活用されており、人間の目からの生体情報の取得は重要なテーマとなっている。

視覚とは、可視光を物理的入力とした感覚のことであり、いわゆる五感のひとつである。視覚によって人間は、外界に存在する物体の色、形、運動、テクスチャ、奥行き等についての情報、物体のカテゴリについての情報、物体の位置関係のような外界の空間的な情報等を得ることができる。視覚は光情報をもとに外界の構造を推定する過程とみなせる。視覚系の基本構造(図 3.11)は、大きく分けて網膜までの眼光学系と、網膜から大脳中枢に至るまでの視覚神経系に分けることができる[45]。まず、光パターンとして与えられる視覚刺激は眼球 (eye ball) でとらえられ、網膜 (retina) に 2 次元画像として投影される。両眼から出た視神経 (optic nerve) は視神経交差 (optic chiasma)、視索 (optic tract) を経て、間脳の外側膝状体 (lateral geniculate body) に至る。視神経交差で全ての神経線維が交差するのではなく、それぞれの半分が交差する。また視覚情報の主要経路は、外側膝状体 (lateral geniculate body) を経て大脳皮質に向かう経路である。

#### 眼球の構造

眼球の直径は 24mm~25mm 程度で、角膜の部分が前方に突き出した球体をしている。前方は角膜に覆われ、その内側に虹彩、その奥に水晶体がある。外界から眼球に入った光線は、角膜—房水—水晶体—硝子体を経由して網膜に達する。

角膜は無色透明で、形状は回転長円形に近く、頂頭の曲率半径は 8mm である。角膜の後ろには、眼球に入る光の量を調節する虹彩がある。虹彩には光量調節以外に辺縁光を遮断して像のぼけを改善するという機能もある。同様に虹彩の中央に開いている小窓のようなものと考えられ、瞳孔によって光量の調節が行われる。

水晶体は透明な線維で構成され、中心から外に向かって層構造をしている。角膜と水晶体の間には、眼房水が満たされている。結像は角膜面での屈折と水晶体でのレンズ効果によって行われ、おもに水晶体の前面の局面を変えてピント調節を行う。水晶体の曲率を生業しているのは毛様筋であり、輪状線維が縮小することによって水晶体が厚くなる。

水晶体と網膜の間にはゼリー状の硝子体が満たされている。網膜は外界の像の結像面である。角膜と水晶体の間の房水と、水晶体と網膜の間の硝子体液は常に古い液と新しい液が交換されており、網膜が圧迫されない程度に適度な眼圧を保つ。この交換のバランスがくずれたり、交換が行われなかったりすると眼球にさまざまな障害が生じる。

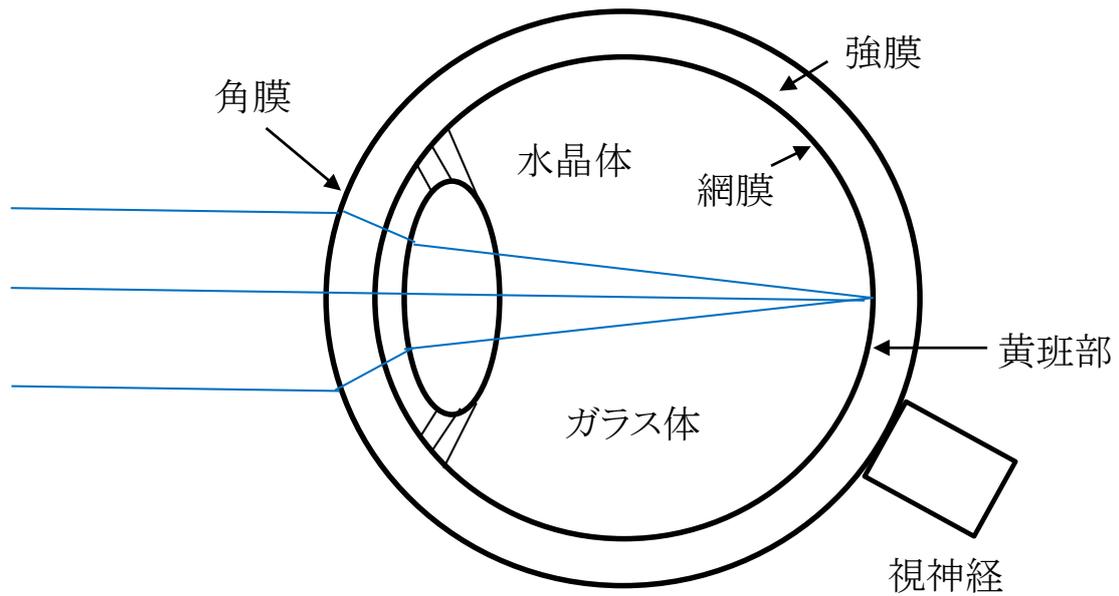


図 3.11 : 視覚系の基本構造

### 瞼開閉度と居眠りの関係

人間は睡眠を取る際に生理的に眼を閉じる。睡眠とは意味のある精神活動を停止した状態にすることで脳を休ませるためのものである。よって、開眼した状態であると脳は休まらず無意識のうちに閉眼する。また、閉眼の度合は心拍変動や呼吸と違い、眠気の進行に対し非常に即時的に反応する特徴を持つ。つまり、居眠りを検知するためには瞼の開閉度(閉眼度)は最も重要であり、有効な指標と言える。

### 瞼開閉度計測機器

本研究では、瞼開閉度を取得する装置として、SeeingMachines 社[46]の faceLAB システムを用いた(図 3.12, 図 3.13). このシステムは 2 台のカメラによって構成され、ステレオ視することで様々な生理指標を取得することができる. サンプルングレートは 60Hz であり、視線の回転角度(x 軸,y 軸,z 軸), 瞬目, 左右閉眼度などの情報をリアルタイムで計測する. また, 2 台のカメラの間には赤外線照明器を備えており, 暗室環境においてもデータ取得が可能となる. 本研究で行う居眠り運転模擬実験は夜間を想定しているため, 消灯した暗室で実験を行うが, この赤外線照明器により正確なデータ取得が可能である.

このシステムの使う際は, 顔の画像に対し所定の個数の特徴点を指定し個人毎に最適なヘッドモデルを作成する必要がある. 本研究では, 目の両端・唇端部を特徴点として用いた. また, 注視方向を決定するためにキャリブレーション(カメラ校正)を行う必要がある. ヘッドモデル作成時に被験者にカメラ A とカメラ B を交互に凝視してもらい視線方向のトラッキング領域を決定する. 次に, 最終的な視線情報キャリブレーションとして別途ディスプレイ上の数点を一定時間ずつ凝視させる. 最後に作成したヘッドモデルのクオリティを確認する.

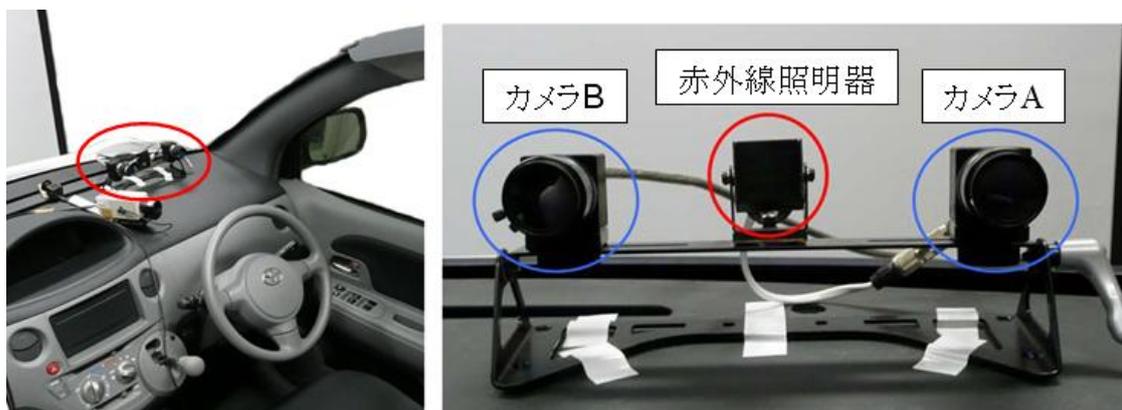


図 3.12 : Seeing Machines 社 FaceLAB システム

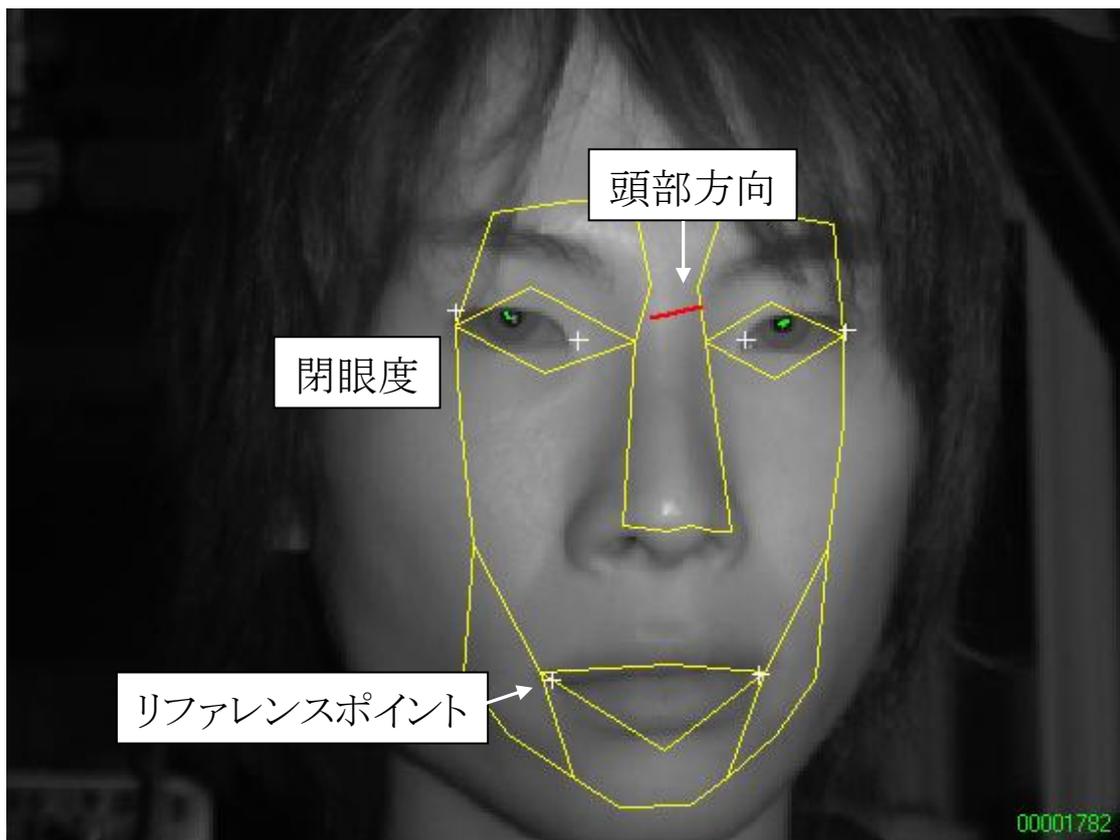


図 3.13 : faceLAB システムを用いたフェイスモデル作成

### 3.3.5 シートからの荷重情報

シートから得られる荷重変動は、身体的なゆらぎを捉えることでドライバの状態を推測することができる。居眠り運転時では座り直し回数の増加や、荷重が進行方向に移動することが先行研究により報告されている[47]。しかし、前節までで説明した心拍情報・呼吸情報・視線情報と比較すると荷重変動がドライバの状態推定に用いられた例は少なく、未だその有効性について検証されていない。本研究では荷重変動と居眠りの関係性について基礎実験を行い調査した。

#### 3.3.5.1 ドライバの荷重変動計測機器

##### 計測機器概要

本研究では、ドライバの荷重変動を計測するためにアイシン製のシート型圧力センサを用いた。図 3.14 に示すようにセンサは上辺 402mm, 右辺左辺 258mm, 下辺 416mm であり、ほぼ正方形をしている。完全な正方形でない理由はドライバの着座状態に最適化されたシートに対しマッチさせるためである。このシート型圧力センサは

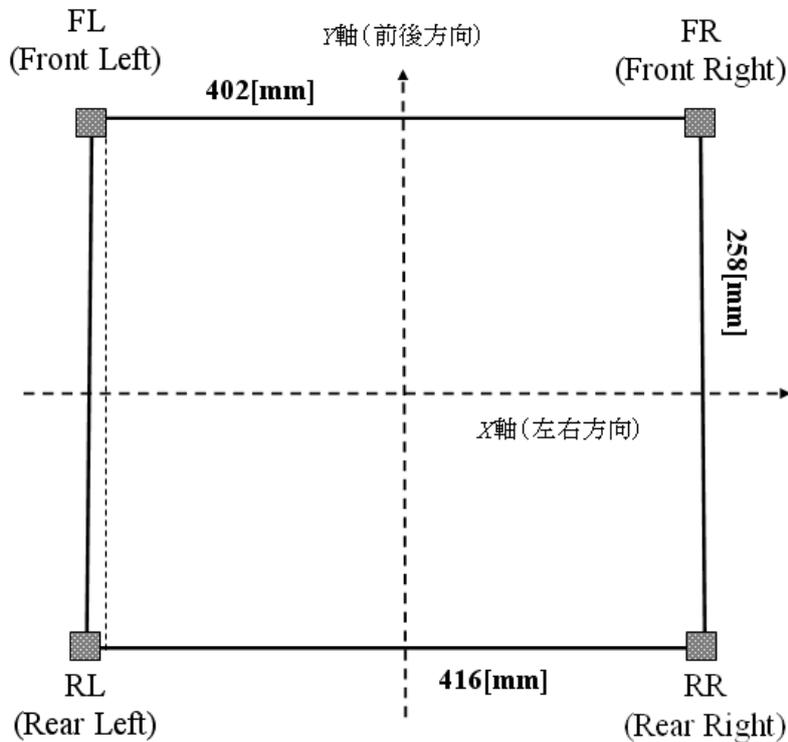


図 3.14 : faceLAB システムを用いたフェイスモデル作成

4箇所の各頂点でそれぞれ独立した状態で荷重を計測できる。センサからは  $V$  で出力され、サンプリングレートは  $20\text{Hz}$  である。尚、シート型圧力センサは本研究で用いるドライビングシミュレータ (3.5 節参照) の運転座席に埋め込まれており、着座時に違和感などをあたえることは無い。シート荷重センサの各頂点は左上を FL(Front Left), 右上を FR(Front Right), 左下を RL(Rear Left), 右下を RR(Rear Right), 左右方向を  $x$  方向、前後方向を  $y$  方向と定義する。

#### シート型圧力センサからの荷重変動算出方法

シート型圧力センサの出力は電圧  $V$  である。このままでは解析に向かない。よって、出力電圧を校正し解析に用い易い形にする必要がある。本センサの校正と荷重への変換式を一般化すると式(3.1)(3.2) と定義することができる。そして、(3.1) と(3.2) をまとめると(3.3)と定義できる。

$$V_{out} = V_1 - (V_1 - (\text{切片})) \quad (3.1)$$

$$\text{荷重}[kg] = \frac{((V_{cal}) - (\text{切片}))}{\text{傾き}} \quad (3.2)$$

$$\text{荷重}[kg] = \frac{(V_i - V_1)}{\text{傾き}} \quad (3.3)$$

切片と傾きの関係が明確であれば、荷重へ変換可能である。各頂点の出力と荷重の関係については、頂点ごとに値が決まっており本研究では仕様書に従い決められた値により校正を行う。式(3.4)～式(3.7) は定められた値に従い、本センサの出力を校正する際に実際に用いた式である。

$$FL = \frac{(V_{out,FL} - V_{0,FL}/0.00447)}{9.8065} \quad (3.4)$$

$$FR = \frac{(V_{out,FR} - V_{0,FR}/0.00447)}{9.8065} \quad (3.5)$$

$$RL = \frac{(V_{out,RL} - V_{0,RL}/0.00442)}{9.8065} \quad (3.6)$$

$$RR = \frac{(V_{out,RR} - V_{0,RR}/0.00437)}{9.8065} \quad (3.7)$$

次に、校正後の値からシートの荷重変動(座面の重心位置)を得るために以下の算出式(3.8～3.9)を適用する。 $G_x$ は  $x$  方向の重心位置、 $G_y$ は  $y$  方向の重心位置である。

$$G_x = \frac{F_{FL} * 7 + F_{FR} * 409 + F_{RR} * 416}{F_{FL} + F_{FR} + F_{RL} + F_{RR}} \quad (3.8)$$

$$G_y = \frac{F_{FL} * 7 + F_{FR} * 409 + F_{RR} * 416}{F_{FL} + F_{FR} + F_{RL} + F_{RR}} \quad (3.9)$$

このように求められた FL, FR, RL, RR,  $G_x$ ,  $G_y$ に基づき特徴量を検討していく。

### 3.3.5.2 安静着座時の眠気レベルと荷重変動の関係調査

眠気レベルの増加によりドライバの荷重変動にどのような変化が生じるのかを簡易的な実験から調査する。具体的にはシート型圧力センサを組み込んだシートに被験者を眠るまで着座させ、そのときの荷重変動を観測する。図 3.15 は実験の様子である。眠気レベルに関しては 3.3.1 節で説明した Zilberg の眠気評定値基準に従う。評定には検査者を 3 人用意し、最終的な眠気レベルは 3 人の平均値としている。

この実験では眠気レベルが 4 に達するまでに約 1200 秒(20 分)を要した。図 3.19,3.20 は眠気レベルと  $x$  軸  $y$  軸それぞれの荷重変動の変化である。縦軸はそれぞれ LR からの距離である。シート型圧力センサからの  $x$  軸と  $y$  軸は LR を原点としたときの距離に基づいている。



図 3.15 : 安静実験の様子

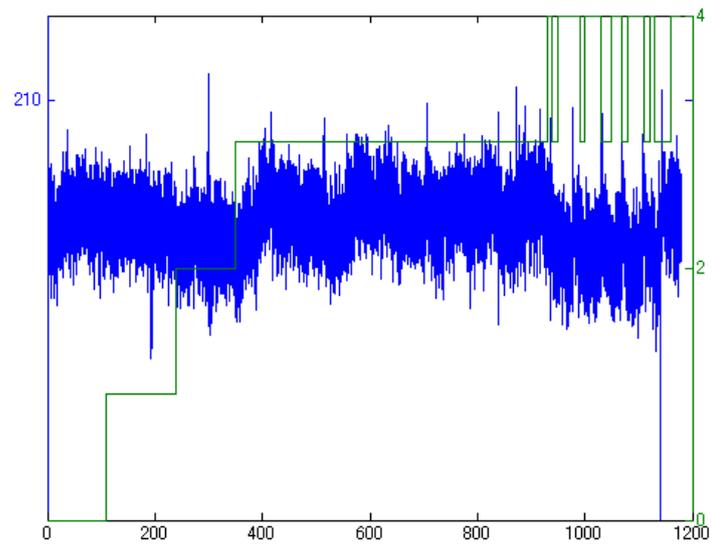


図 3.16 : 眠気レベルと x 軸方向の  
荷重変動

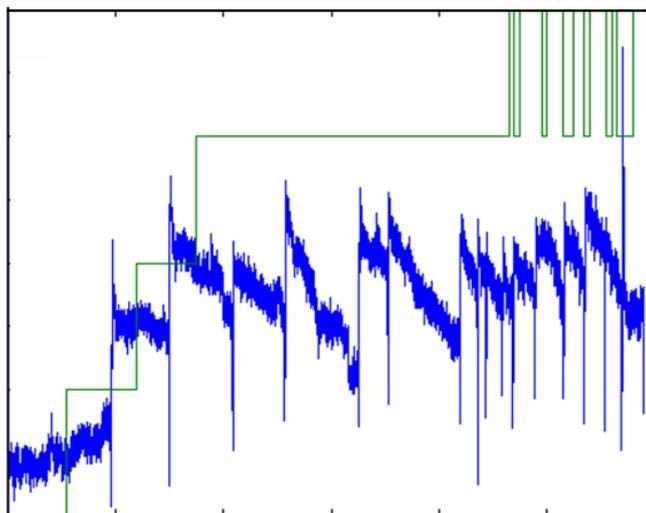


図 3.17 : 眠気レベルと y 軸方向の荷重変動

図 3.16 より, x 軸荷重変動に関しては時系列的に変動が無く眠気レベル増加との関連性が見出せない. 一方, y 軸荷重に関しては眠気レベル増加と共に変動しており, 眠気レベルとの関連性が伺える. この y 軸の変動はドライバの頭部が意識低下に揺らいだためであり, この事象に関しては先行研究[47]で報告されている内容と同一である. この結果から安静着座状態においては眠気と荷重変動に関係性があることを示すことができた. しかし, 問題になってくるのは運転操作を行ってもこの傾向が確認できるかという点である. 運転操作にはペダル操作とステアリング操作があるが, これらの操作を行うことで荷重変動に影響が出ることは明白である.

### 3.3.5.3 運転時における有効な特徴量

運転時における有効な特徴量を検討するために, 走行中における荷重データを取得した. 実験に関しては 3.5 節で説明するドライビングシミュレータ及び走行コースにより, 被験者が居眠り運転になるまで運転させた. 図 3.18 と図 3.19 はそのときの眠気レベルと x 軸 y 軸それぞれの荷重変動の変化である. 安静着座状態のときとは異なり, x 軸 y 軸それぞれに異なる傾向が現れた. 安静着座状態では, 変化の無かった x 軸に関してだが, 走行状態では進行方向に対しやや左に傾倒する傾向にある. また, y 軸に関しては眠気レベルの増加と共に, 傾倒は無いが突発的な尖状波形が見られる. この結果

から、居眠り運転時には安静着座時には見られない独特の傾向があり、居眠り検知の特徴量として用いるためには走行中独特の傾向を捉えるものにする必要がある。そこで、有効な特徴量を取得するために表 3.4 に示す 72 パターンの特徴量を作りだし眠気との関連について調査する。

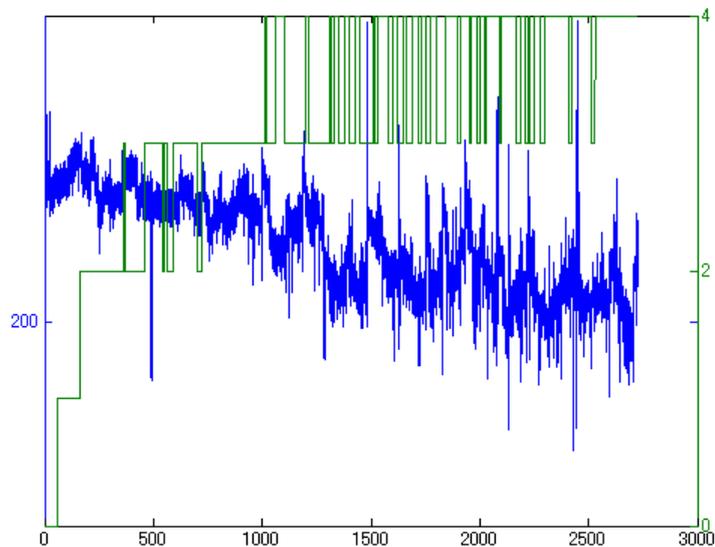


図 3.18 : 眠気レベルと x 軸方向の荷重変動

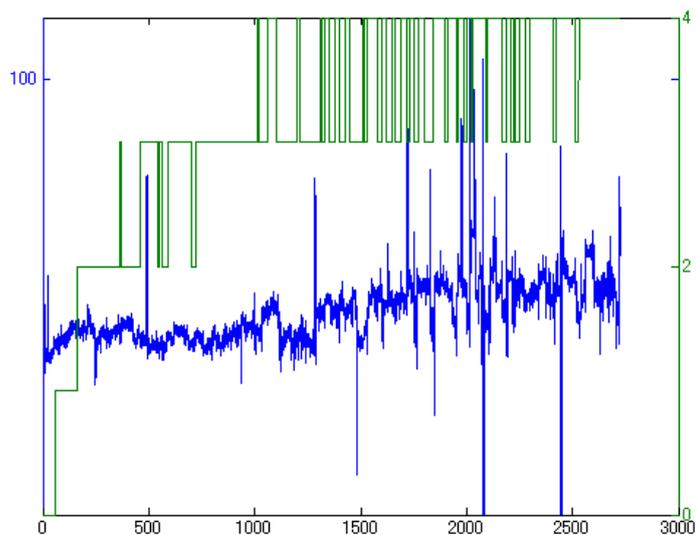


図 3.19 : 眠気レベルと y 軸方向の荷重変動

表 3.4 : シート型圧力センサから抽出した特徴量候補一覧

No	特徴量	説明	No	特徴量	説明
1	A-sd	FL の S. D.	37	(B*C) sd	FR×RL の S. D.
2	A-ave	FL の平均値	38	(B*C) ave	FR×RL の平均値
3	B-sd	FR の S. D.	39	(B/C) sd	FR÷RL の S. D.
4	B-ave	FR の平均値	40	(B/C) ave	FR÷RL の平均値
5	C-sd	RL の S. D.	41	(B-D) sd	FR-RR の S. D.
6	C-ave	RL の平均値	42	(B-D) ave	FR-RR の平均値
7	D-sd	RR の S. D.	43	(B+D) sd	FR+RR の S. D.
8	D-ave	RR の平均値	44	(B+D) ave	FR+RR の平均値
9	(A-B) sd	FL-FR の S. D.	45	(B*D) sd	FR×RR の S. D.
10	(A-B) ave	FL-FR の平均値	46	(B*D) ave	FR×RR の平均値
11	(A+B) sd	FL+FR の S. D.	47	(B/D) sd	FR÷RR の S. D.
12	(A+B) ave	FL+FR の平均値	48	(B/D) ave	FR÷RR の平均値
13	(A*B) sd	FL×FR の S. D.	49	(C-D) sd	RL-RR の S. D.
14	(A*B) ave	FL×FR の平均値	50	(C-D) ave	RL-RR の平均値
15	(A/B) sd	FL÷FR の S. D.	51	(C+D) sd	RL+RR の S. D.
16	(A/B) ave	FL÷FR の平均値	52	(C+D) ave	RL+RR の平均値
17	(A-C) sd	FL-RL の S. D.	53	(C*D) sd	RL×RR の S. D.
18	(A-C) ave	FL-RL の平均値	54	(C*D) ave	RL×RR の平均値
19	(A+C) sd	FL+RL の S. D.	55	(C/D) sd	RL÷RR の S. D.
20	(A+C) ave	FL+RL の平均値	56	(C/D) ave	RL÷RR の平均値
21	(A*C) sd	FL×RL の S. D.	57	Gx-sd	X 軸重心の S. D.
22	(A*C) ave	FL×RL の平均値	58	Gx-ave	X 軸重心の平均値
23	(A/C) sd	FL÷RL の S. D.	59	Gx-sum	X 軸重心の総和
24	(A/C) ave	FL÷RL の平均値	60	Gy-sd	Y 軸重心の S. D.
25	(A-D) sd	FL-RR の S. D.	61	Gy-ave	Y 軸重心の平均値
26	(A-D) ave	FL-RR の平均値	62	Gy-sum	Y 軸重心の総和
27	(A+D) sd	FL+RR の S. D.	63	subGx-sd	X 軸重心の逐次差分の S. D.
28	(A+D) ave	FL+RR の平均値	64	subGx-ave	X 軸重心の逐次差分の平均値
29	(A*D) sd	FL×RR の S. D.	65	subGx-sum	X 軸重心の逐次差分の総和
30	(A*D) ave	FL×RR の平均値	66	subGy-sd	Y 軸重心の逐次差分の S. D.
31	(A/D) sd	FL÷RR の S. D.	67	subGy-ave	Y 軸重心の逐次差分の平均値
32	(A/D) ave	FL÷RR の平均値	68	subGy-sum	Y 軸重心の逐次差分の総和
33	(B-C) sd	FR-RL の S. D.	69	sumGG-sd	荷重重心の逐次差分の S. D.
34	(B-C) ave	FR-RL の平均値	70	sumGG-ave	荷重重心の逐次差分の平均値
35	(B+C) sd	FR+RL の S. D.	71	sumGG-sum	荷重重心の逐次差分の総和
36	(B+C) ave	FR+RL の平均値	72	count	荷重中心変動回数

### 荷重中心変動回数

72 項目目の特徴量である荷重中心変動回数について説明する．これは他の特徴量と異なり,図 3.19 で現れている眠気レベルの増加と共に増える尖状波形を捉えるものである．この特徴量は屋所らにより提案されたものである．調査論文では ACC(Adaptive Cruise Control)を作動し,ドライビングシミュレータを走行中のノイズをステアリング操作のみにし,そのときに生じる荷重中心変動の最大値を閾値としている．この閾値以上のものは姿勢変化と捉え,その回数をカウントすることで眠気(覚醒度低下)を検出する．ステアリング操作のみを行っているときの荷重中心変動は 0.2inch 以下となっており,1.0inch 以上の大きな変動は対象外として,0.2inch 以上 1.0inch 以下のものを姿勢変化や座り直しによる変動と定義して利用する．図 3.20 と図 3.21 は荷重中心変動回数と眠気レベルとの関係について,自身の取得データから算出したものである．図 3.20 に関しては,眠気レベルの増加と共に,荷重中心変動回数も増加しており眠気との関連性が伺える．しかし,被験者が異なる図 3.21 に関しては,図 3.20 ほど眠気レベルとの関連性が見出せない．

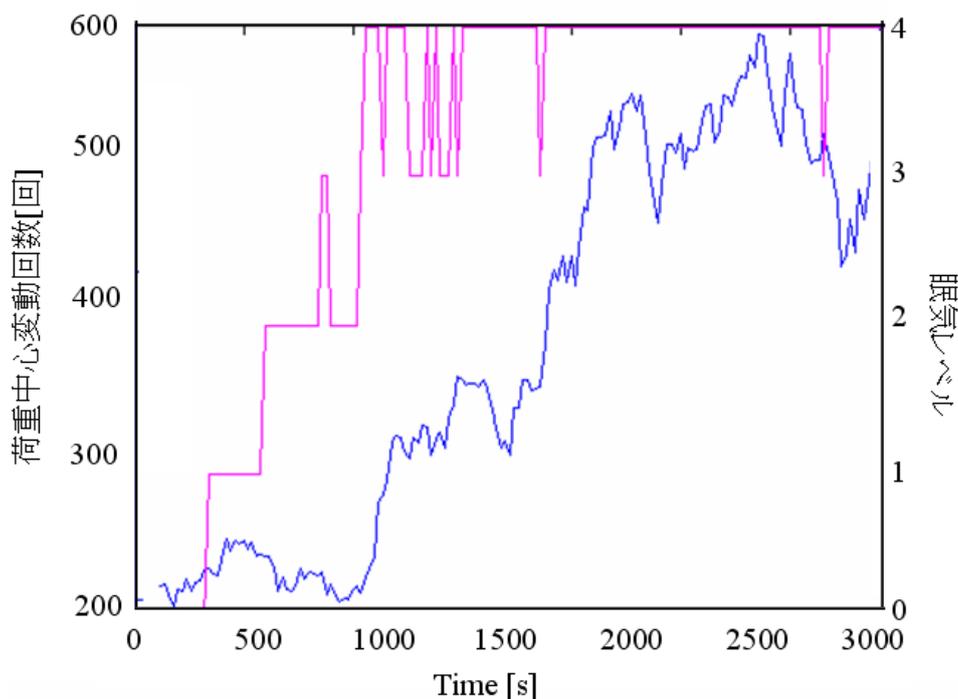


図 3.20 : 眠気レベルと x 軸方向の  
荷重変動

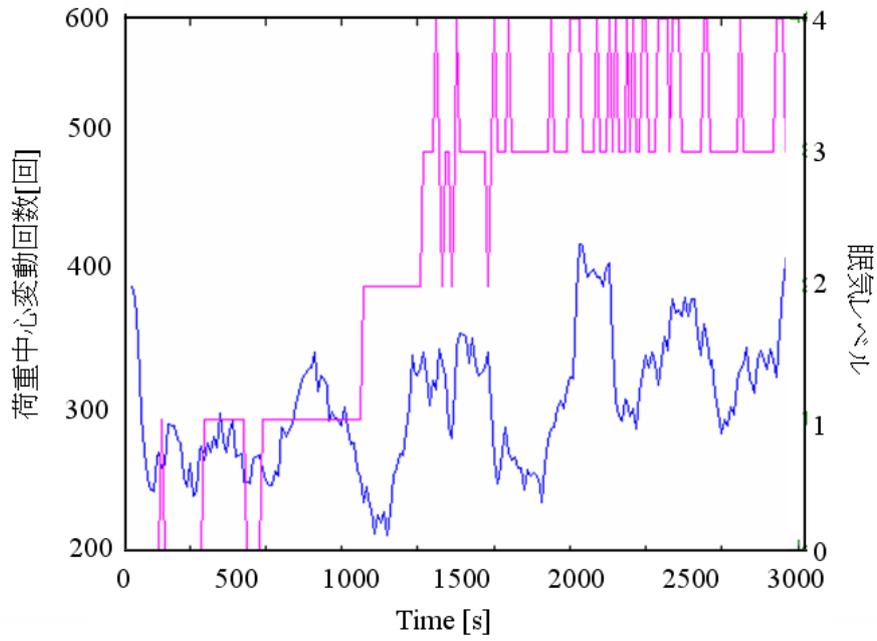


図 3.21 : 眠気レベルと y 軸方向の荷重変動

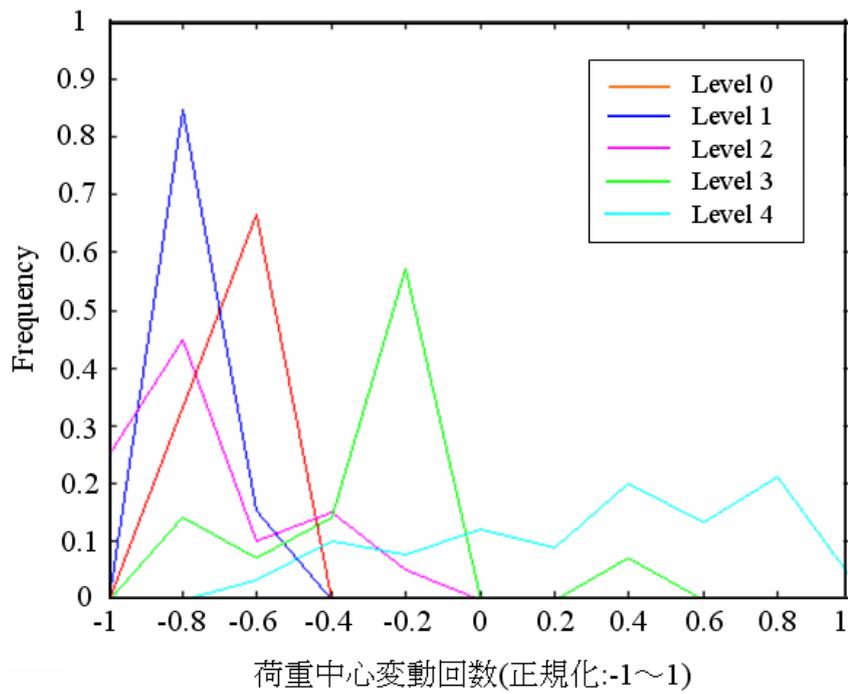


図 3.22 : 眠気レベルごとのヒストグラム表示

そこで、図 3.22 に眠気レベルごとにヒストグラム表示にし、眠気レベルとの関係性の詳細を確認した。眠気レベル 2 と 3 の間は特徴量値が重なっておらず判別できる可能性がある。5 段階ある眠気レベルそれぞれに有効に働くことはないが、一定の基準に関しては判別可能なことを表している。よって、有効に働く場合もあるので候補の一つとして加えた。

#### 3.3.5.4 出現頻度に基づく特徴量選定法

次に抽出した 72 パターンの特徴量の中から有効なものを選定していく。有効に働く特徴量を探るため、一つ一つの特徴量で線形判別分析法、kNN, AdaBoost を用いて眠気レベルを判別できるか推定を行った。眠気レベルは顔表情評定値(012)(34) の二クラス判別で行った。これはシートからの荷重のみでは多段階での推定は困難であるためである。判別基準に関しては二段階に落とす際、最も判別が容易となる基準それぞれ求めて用いた。これよりこの章に限定して眠気レベル(012) を LowLevel, 眠気レベル(34) を HighLevel と称する。

評価方法は LowLevel, HighLevel の推定率(LowLevelAccuracy, HighLevelAccuracy) 及び LowLevel, HighLevel を混合した推定率(Accuracy) を算出し、推定率が高いもの上位 10%の出現頻度によって有効か否かを判断する。表 3.5 は、上位 10 %の出現頻度一覧である。表中の番号は特徴量の項目番号である。この中でよく出現している項目番号の特徴量が有効である。出現頻度の上位 5 つは以下の特徴量である。

- ・ 荷重中心変動回数
- ・ x 軸重心の 1 分間の標準偏差
- ・ x 軸重心の逐次差分の標準偏差
- ・ FR+RR の 1 分間の標準偏差
- ・ FL+RR の 1 分間の標準偏差

先行研究で報告されている通り荷重中心変動回数が最も単体で有効であることが判明した。次いで x 軸重心の 1 分間の標準偏差, x 軸重心の逐次差分の標準偏差となっている。これらは眠気レベルの増加に伴い x 軸重心の乱れが増加しており、この現象を捉えたため上位に入ったと考えられる。また, FR+RR と FL+RR の 1 分間の標準偏差は主にシートの右半分の荷重変動であり、ペダル操作を行う右足側である。ペダル操作やステアリング操作といった操作系も居眠り運転検知に用いられることがあり、この 2 つの特徴量はそのような操作系を捉えたものである。

表 3.5 : 出現頻度の高い特徴量一覧

	LDA			kNN			AdaBoost		
	Low	High	Accuracy	Low	High	Accuracy	Low	High	Accuracy
I	52	70	72	72	70	72	63	64	72
II	63	71	71	63	71	63	72	65	63
III	7	72	70	52	66	69	52	68	69
IV	18	30	63	26	69	71	46	67	70
V	26	46	57	46	58	70	26	31	71
VI	72	57	69	57	59	26	49	58	46
VII	57	69	18	69	72	57	57	59	57

## 3.4 パターン認識手法

### 3.4.1 パターン認識と学習

パターン認識とは、人間の知的活動が、連続量で表現されるパターンとして存在していることに着目し、パターンに対して意味付けし記号化したものをコンピュータ処理によりクラス分けすることである[48]。ここでいうクラスとはそれぞれの記号に対応したパターンの集合の事を指す。

パターン認識を行う一つの方法は、それぞれのクラスをそのクラスに属する特徴パターン（特徴量）によって代表させ、入力された特徴パターンがどのクラスの特徴パターンに似ているかを判断するやり方である。ここで、クラスを代表する特徴パターンを参照パターン、入力された特徴パターンを入力パターンと呼ぶ。参照パターンは、学習により決定する。学習は、パターン認識システムを構築するために行われる処理で、クラスを代表する参照パターンが学習によって決定され、クラスごとにシステムを蓄積される。このような学習を経て認識を行うことが可能となる。つまり、パターン認識の問題は、学習と認識の二つの過程に分けることができる(図 3.23)。学習方法についても2通りあり、属するクラスが分かっているいくつかのパターンを使って行われるやり方を教師付き学習。また、例題の属する正しいクラスが分からない状況での学習を教師なし学習と呼ぶ。

本研究では顔画像表情値による眠気レベルを教師データ（クラス）として用いるため、判別には教師付き学習を行うパターン認識手法のみを用いる。特徴量には心電、呼吸、瞼開閉度、シート荷重から得られるデータを用いる。次節より使用するパターン認識手法について説明していく。

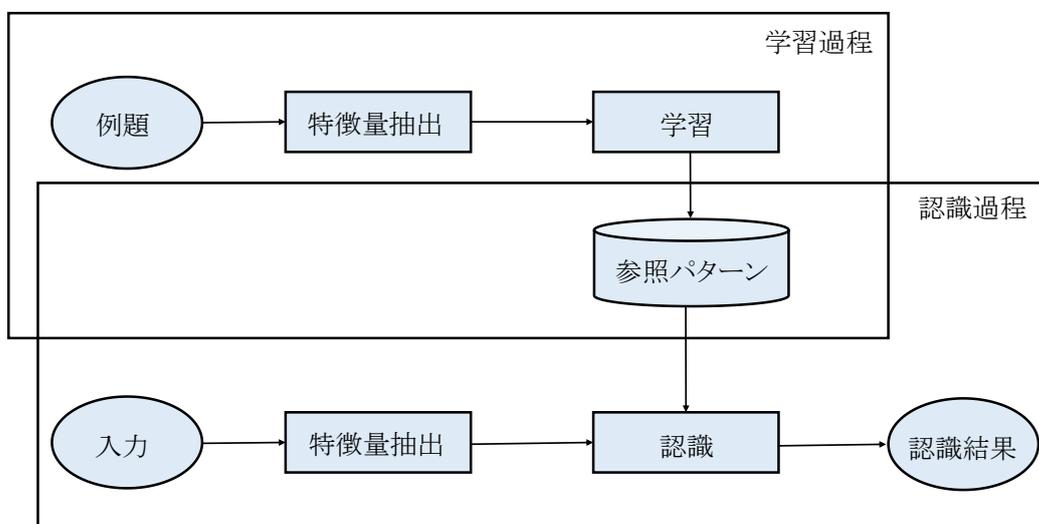


図 3.23 : パターン認識の処理過程

### 3. 4. 2 線形判別分析法

判別分析とは、事前に与えられているデータが異なるグループに分かれることが明らかでない場合、新しいデータが得られた際に、どちらのグループに入るのかを判別するための基準(判別関数)を得るための手法である。判別関数には直線による線形判別関数と、非線形の場合には曲線によるマハラノビス汎距離とがある。基本的には2分類を行う手法であるが3つ以上のグループの判別も可能であり、重判別分析と呼ばれる。本研究では3つ又は4つのグループに判別しているので線形重判別分析を用いた。判別分析法で判別の基準となる判別関数( $y = a_1x_1 + a_2x_2 + \dots + a_nx_n + a_0$ )の基本的な求め方を以下に示す。

(Step1) 第一群, 第二群についてそれぞれ平方和・積和を求める。

$$W_{ii} = \sum (x_i - \bar{x})^2, W_{ij} = \sum (x_i - \bar{x})(x_j - \bar{x}) \quad (3.10)$$

(Step2) 第一群と第二群の平方和・積和を、同じ2変数について足し、自由度  $N_1 + N_2 - 2$  で除す。

$$S_{ij} = \frac{S_{ij}(\text{第一群}) + S_{ij}(\text{第二群})}{N_1 + N_2 - 2} \quad (3.11)$$

(Step3)  $S_{ij}$  を、その  $i$  行  $j$  列に対応させて分散共分散行列  $S$  とし、各変数にかかる係数を  $n$  行 1 列に並べた行列を  $A$ 、第一群の各変数の平均値から第二群の各変数を引いた数  $x_1(\text{第一群}) - x_1(\text{第二群})$  を  $n$  行 1 列に並べた行列を  $X$  とすると以下の式が成り立つ。

$$SA = X \text{ ゆえに } A = S^{-1}X \quad (3.12)$$

(Step4) これにより各変数にかかってくる係数を求めることができる。定数項は、 $a_0 = -1/2[a_1(x_1(\text{第一群平均値}) + x_1(\text{第二群平均値})) + \dots + a_n(x_n(\text{第一群平均値}) + x_n(\text{第二群平均値}))]$

(Step5) 判別得点  $y$  が正のとき第一群、負のとき第二群と判別される。変数が標準化されていれば、係数の大きさは、そのままその変数が判別に与える影響の大きさである。変数が定性的な場合は、ダミー変数を用いる。

$$y = a_{11}x_{11} + a_{12}x_{12} + \dots + a_{21}x_{21} + a_{22}x_{22} + \dots + a_{n1}x_{n1} + a_{n2}x_{n2} + \dots + a_0 \quad (3.13)$$

本研究では上記線形判別分析を行い際に、Matlab の classify 関数を用いた。

### 3. 4. 3 k-最近傍識別法

前節の線形判別分析法は線形な判別面を形成する手法である。しかし、データによっては線形な判別面では切り分けが困難な場合もある。このようなデータが複雑であり線形な判別面では対応しきれない場合に非線形な判別面を形成する手法(非線形分離)が多く用いられる。k-最近傍識別法は非線形な判別面を形成する代表的な手法であり本研究でも用いることとした。k-最近傍識別法は、学習データ全てで学習データの分布を表現する記憶ベース(memory-based approach)の手法である。パターン認識においてこのような記憶ベースの手法は珍しく、多くの場合学習データの分布を少数の代表ベクトルなどによって圧縮して用いる。新しい入力  $x$  を識別するときは、記憶されている学習データの中から  $x$  に近い順に  $k$  個をとり多数決をとる単純なアルゴリズムである。すなわち  $k$  個の中で、クラス  $c$  に属しているものの数がそれぞれ  $l_c$  個だとするとき  $l_c$  を最大にするクラス  $c$  を識別結果とする。この手法は学習データを圧縮しないため特徴空間内においてデータの分布がきれいにまとまっていない場合でも、かなり柔軟に対処できることが特徴である。しかし、一方で  $k$  の値によって識別結果が変化するという問題がある。以下(図 3.24) に k-最近傍識別法によって  $k$  の値を変化させた場合の例について図示する。この例では red-class と blue-class により構成された特徴量空間に、新しい特徴量 green が入力された場合の識別結果について示している。識別結果が  $k$  の値に依存しており、この値を最適に設定する必要がある。

一般的な  $k$  の決定方法としては以下の手順に沿う手法を用いる必要がある。

- 値の候補を用意する
- 各モデルに対してパターンの誤認識率を推定
- 誤認識率の推定値を最小にするモデルを選ぶ

ここで、注意したいのは評価データを用いずに行うという点である。本来、評価データのラベルは未知であるため最適な  $k$  を求める段階で使用することは望ましくない。そこで本研究では交差確認法(CV 法)を用いた[49]。交差確認法のアルゴリズムを以下に示す。尚、 $X$ は学習データである。

- ①  $X$  を  $m$  個のグループ( $x_1, x_2, \dots, x_m$ )に分割
- ②  $X_i$ を除いた( $m-1$ )個のグループパターンで学習した後、 $X_i$ で誤認識率を算出
- ③ ②の手順を  $i = 1, 2, \dots, m$  の全てについて行い  $m$  個の誤認識率を推定

$X_i$ の要素数としては 1 を用いる方法( $L$  法)が一般的である。これは Leave-one-out 法を全パターン行うイメージである。交差確認法により得られた結果の一例を図 3.28 に示す。尚、 $k$  は 1 から 100 の間で最適値を求めた。

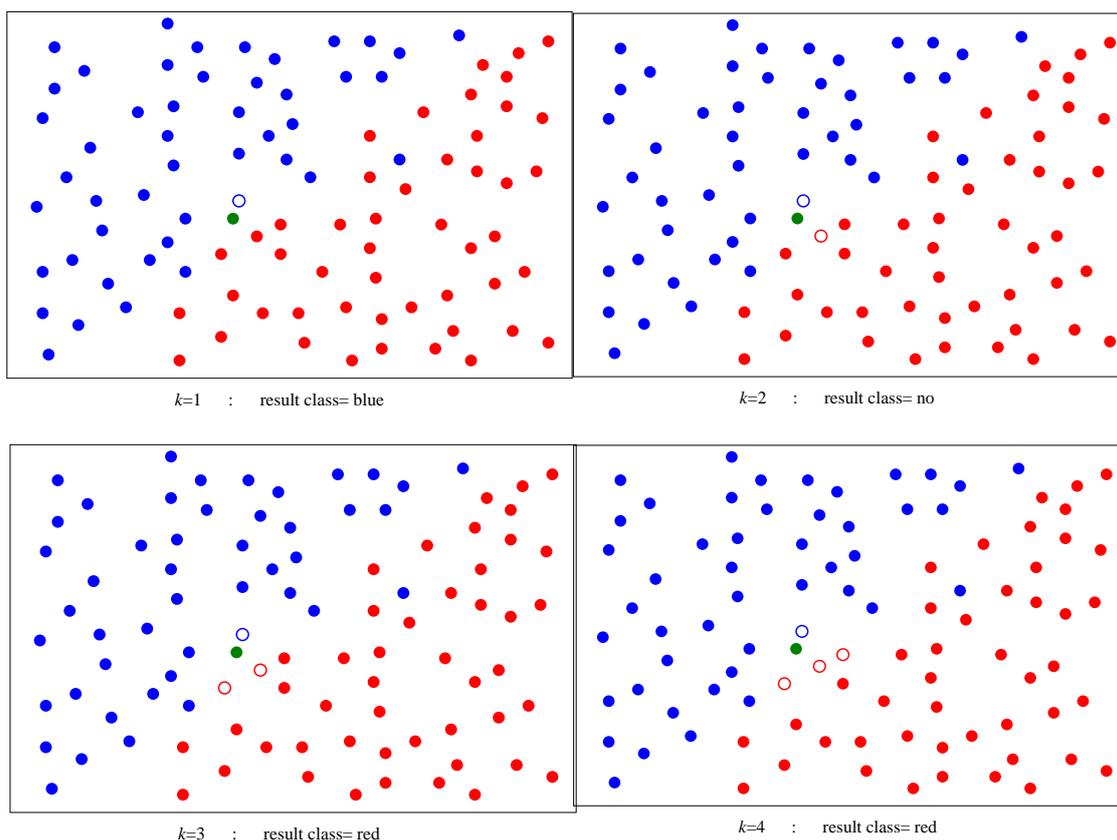


図 3.24 :  $k$  の個数による識別結果への影響

### 3. 4. 4 AdaBoost

#### 3. 4. 4. 1 弱識別器の利用による集団学習

パターン認識によって複雑な問題を解くためには、自由度の高い複雑な学習モデルが必要となる。しかし、複雑なモデルになればなるほど精度と引き換えに計算時間の増大と汎化性能の低下が生じ易くなる。こうした計算時間の増大と汎化性能の低下を同時に避ける手法の一つが集団学習である。集団学習においては複雑で大規模な学習モデルを用いるのではなく、比較的単純な学習モデルと計算量が妥当な学習器を用い、与える例題の重みや初期値の違いなどによって多様な仮説を選び出し、これを組み合わせることによって最終的な仮説を構成し、複雑な学習モデルを構築するのと同様なことを行う。これより集団学習を行うための代表的な手法であるブースティング(boosting)について述べる。ブースティング(boosting)は逐次的に例題の重みを変化させながら異なる学習機械を作り、これを組み合わせることで精度の高い学習機械を構成する手法である。学習アルゴリズムの精度を増強(boost)するという意味でこの言葉が使われる。フィルタによるブースティング(boosting by filter)は弱い学習アルゴリズムによって作られる弱仮

説を逐次的に 3 つ生成し, その多数決をとることによってより誤り率を小さくする構成的な手続きを与えたものである.

**step1**  $N_1$ 個の例題を観測し, 学習アルゴリズムにより第 1 の仮説を生成する.

**step2** 第 1 の仮説をフィルタとして使い, 次のようにして新しく例題を集める.

- 偏りのない(裏表が等確率で出る) コインを投げる(-1,1)が等確率となる乱数を生成する).
- 表が出た場合, 第 1 の仮説が誤って判別する例題が出るまで, 例題を観測し捨てる.
- 裏が出た場合, 第 1 の仮説が正しく判別する例題が出るまで, 例題を観測し捨てる.
- これを繰り返し,  $M_1$  個の例題が集まるまで続ける.

以上のようにして集められた例題は, 第 1 の仮説での正答率が  $1/2$  となる.

**step3** 第 1 と第 2 の仮説をフィルタとして使い, 次のようにして例題を集める.

- 例題を観測し, 第 1 の仮説と第 2 の仮説に判別させる. 両者の判定が同じなら捨て, 異なったらとっておく.
- これを繰り返し,  $N_1$ 個の例題が集まるまで続ける.

**step4** 判別は 3 つの仮説の均等な多数決によって行う.

定理として, 3 つの仮説がそれぞれの学習に使った例題に対して誤り率が 2 以下で合ったとする. このとき組み合わせた仮説の誤り率は

$$g(\epsilon) = 3\epsilon^2 - 2\epsilon^3 \quad (3.14)$$

以下になる. 関数  $g$  は, 単純に弱い学習アルゴリズムを用いて得られた第 1 の仮説の誤り率  $\epsilon$  が  $1/2$  以下であれば, 組み合わせた仮説の誤り率はそれより必ず小さくできる.

フィルタによるブースティングの欠点となるのは, 必要な例題が非常に多くなる場合があるということである. 実際に学習に使用する例題の総数は  $3N_1$  個であるが, 第 2, 第 3 の仮説の学習のためにせっかく観測した例題の一部を捨てている. 仮説の誤り率をそれぞれ  $\epsilon_1, \epsilon_2, \epsilon_3$  とし, 捨て去った例題もふくめ第 2, 第 3 の仮説の学習のために観測した例題の総数をそれぞれ  $N_2, N_3$  とする. 第 2 の仮説のために例題を作る段階で, 誤った例題 1 つを見つけるのに平均何個の例題が必要かを考える.  $N_1$  個の例題のうち平均  $K_{\epsilon_1}$  個が目的のものなので, 目的にかなう例題 1 個を得るためには

$$N_{1\epsilon_1} = 1 \Rightarrow N_1 = \frac{1}{\epsilon_1} \quad (3.15)$$

個の例題を観測しなくてはならない。また第 2 の仮説を学習するための例題の収集には平均で

$$N_2 = N_1 \left( \frac{1}{2} \times \frac{1}{\epsilon_1} + \frac{1}{2} \times \frac{1}{1-\epsilon_1} \right) = \frac{N_1}{2\epsilon_1(1-\epsilon_1)} \quad (3.16)$$

個の例題を観測しなくてはいけないことがわかる。第 3 の仮説のための例題は、第 1 の仮説と第 2 の仮説の出力が異なる確率を考えなくてはならないが、今それぞれの誤り率を  $\epsilon_1, \epsilon_2$  としているので、この確率は  $\epsilon_1 + \epsilon_2$  を越えることはない。したがって平均として必要な例題の観測回数は

$$N_3 = \frac{N_1}{\epsilon_1 + \epsilon_2} \quad (3.17)$$

より少なくなることはない。以上より  $3N_1$  個の例題を集めるためには平均

$$\left( 1 + \frac{1}{2\epsilon_1(1-\epsilon_1)} + \frac{1}{\epsilon_1 + \epsilon_2} \right) N_1 \quad (3.18)$$

回以上の例題を観測する必要があることがわかる。簡単のため  $\epsilon_1 = \epsilon_2 = \epsilon$  とすると  $\epsilon$  が小さくなるほど大きくなる。これは誤り率の小さい良い学習アルゴリズムほどブースティングするためには例題をたくさん無駄にしなくてはならず、言い換えるとブースティングしにくいことがわかる。

#### 3.4.4.2 AdaBoost アルゴリズム

ブースティングは、単純な識別器を複数組み合わせることによって精度の高い識別器を構成する手法である。そして、初期のフィルタによるブースティングの問題点を解決するために提案されたアルゴリズムが AdaBoost である。AdaBoost では、弱識別器による学習アルゴリズムが  $t = 1, \dots, T$  回繰り返し呼び出される。このとき、訓練集合上の分布（各例題の重み）を正誤に応じて更新していき、学習アルゴリズムはこの分布に基づいて弱仮説を選択していく。 $N$  個の訓練集合  $(x_1, y_1), \dots, (x_N, y_N)$  が与えられているとする。二値判別問題の場合はこのとき、 $Y = -1, +1$  となる。 $t$  回目の学習における例題  $i$  の重みを  $D_t(i)$  と定義する。二値判別問題における一般的な AdaBoost の学習手順は次のようになる。

**STEP1** 重みの初期化

$$D_1(i) = \frac{1}{N} \quad (3.19)$$

**STEP2**  $t = 1, \dots, t$  において

(1) 分布  $D_t$  に基づいて弱仮説  $h_t(x)$  を学習. 誤り率  $2t$  最小となる  $h_t$  を選択

$$\epsilon_t = P_{yD_t}\{h_t(x_i) \neq y_i\} = \sum_{i:y_t \neq h_t(x_i)} D_t(i) \quad (3.20)$$

(2) 誤り率に基づいて信頼率  $\alpha_t$  の計算

$$\alpha_t = \frac{1}{2} \ln \left( \frac{1-\epsilon_t}{\epsilon_t} \right) \quad (3.21)$$

(3) サンプル重みを更新

(4) サンプル重みの和が 1 となるように正規化

$$D_{t+1}(i) = \frac{D_t(i) \exp(-\alpha_t y_i h_t(x_i))}{Z_t} \quad (3.22)$$

$$Z_t = \sum_{i=1}^N D_t(i) \exp(-\alpha_t y_i h_t(x_i)) \quad (3.23)$$

**STEP3** 弱仮説に信頼度の重みをつけて多数決

$$H(x) = \text{sign}(\sum_{t=1} \alpha_t h_t(x)) \quad (3.24)$$

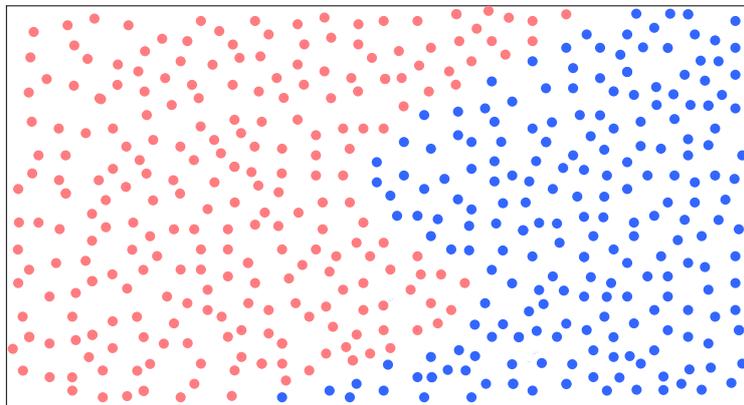


図 3.25 : 例題集合  $x_i, y_i$  の例 (青 :  $y_i = +1$ , 赤 :  $y_i = -1$ )

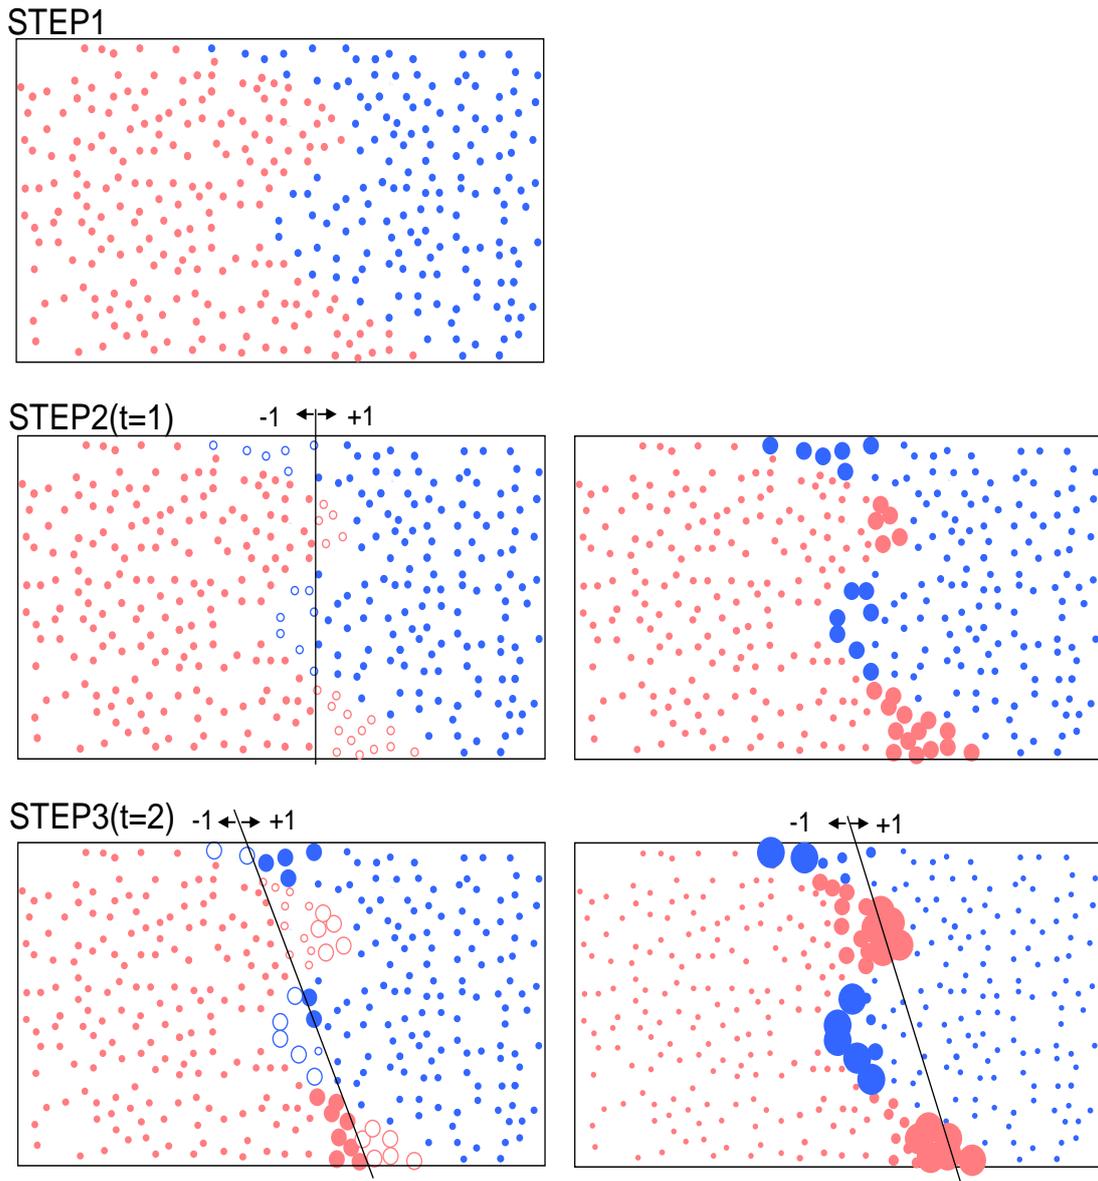


図 3.26 : AdaBoost の学習過程

次に図 3.25 に示した例題集合の例を用いて、二値判別問題における AdaBoost の学習過程の具体例を図 3.26 に示す。各円の大きさは各例題の重み $D_t(i)$ を表しており、特に白抜きのは弱仮説の判別が誤っていた例題を示している。次の学習で、前回誤った例題の重みが大きくなっていることが分かる。そして、例題の個数  $N = 100$ , 学習回数を  $t = 3$  であるとした時、最終仮説は次のように求める。

各学習( $t = j$ )における信頼度 $\alpha_j$ は度 $\alpha_1 = 0.164$ , 度 $\alpha_2 = 0.193$ , 度 $\alpha_3 = 0.232$ であった。これを用いると、各学習結果における各例題の最終仮説は以下の表 3.6 のようになる。また、求められた AdaBoost の学習結果を図 3.27 に示す。

表 3.6 : 各学習での判別結果と最終仮説

t=1	t=2	t=3	H(x <sub>i</sub> )
-1	-1	-1	-1
-1	-1	+1	-1
-1	+1	-1	-1
-1	+1	+1	+1
+1	-1	-1	-1
+1	-1	+1	+1
+1	+1	-1	+1
+1	+1	+1	+1

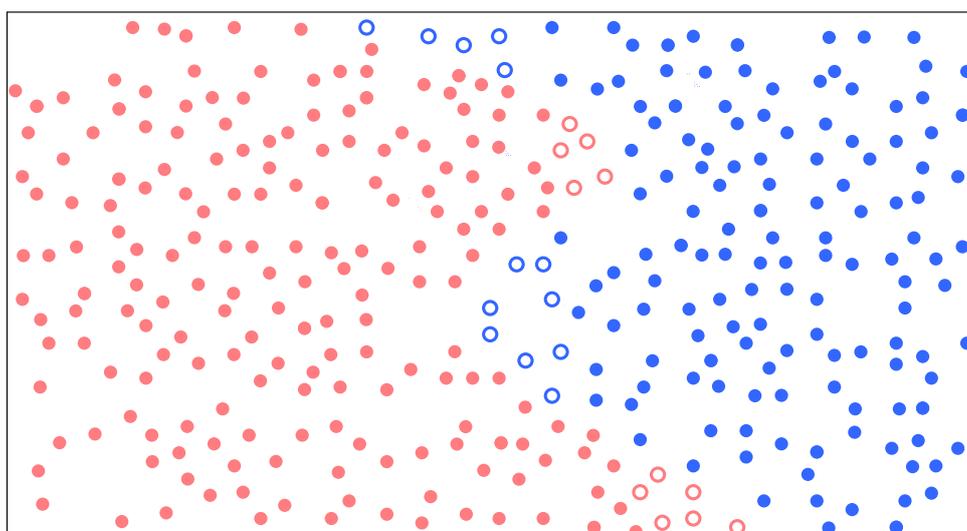


図 3.27 : AdaBoost の最終結果

二値判別問題においては、誤り率 $\epsilon_t > 0.5$ 、すなわち誤り率の方が正解率よりも大きい場合は、仮説の判定を逆転してやることで $\epsilon_t < 0.5$  とすることができる。また、 $t$  回目の学習で得られた仮説の更新後の分布においては誤り率 $\epsilon_t = 0.5$  となる。つまり更新された分布 $D_{t-1}$ は弱識別器 $h_t(x)$ が最も苦手とするものであり、次に選択される弱識別器 $h_{t+1}(x)$ は直前の弱識別器では上手く識別できなかったものを上手く扱えるようなものとなる。

次に AdaBoost アルゴリズムにおける信頼度 $\alpha_i$ がどのように導出され、なぜアルゴリズムが指数損失という損失関数が小さくすることができるのかを説明する。

AdaBoost では、信頼度で重みづけられた仮説の和(判別関数)

$$F(\mathbf{x}) = \sum_{t=1}^T \alpha_t h_t(\mathbf{x}) \quad (3.25)$$

を用いて、以下に定義する損失関数(指数損失) $L$  が逐次最小化されるように分布の更新が行われている。

$$L(F) = \frac{1}{N} \sum_{i=1}^N \exp(-y_i F(x_i)) \quad (3.26)$$

ここで、信頼度  $\alpha_t$  は損失関数を最小化するように決定される。つまり、 $h_1, \dots, h_{t-1}$  が決まっているときに、 $F(\mathbf{x})$  に新たな仮説  $h_t$  を加えて  $L$  が最小となるような  $\alpha_t$  を決定する。このときの損失  $L(F + \alpha_t h_t)$  は、次式のように変形できる。

$$\begin{aligned} L(F + \alpha_t h_t) &= \frac{1}{N} \sum_{i=1}^N \exp(-y_i(F)(x_i) + \alpha_t h_t(x_i)) \\ &= \frac{\exp(\alpha_t)}{N} \sum_i \exp(-y_i F(x_i)) \\ &+ \frac{\exp(\alpha_t) - \exp(-\alpha_t)}{N} \sum_{i: y_t \neq h_t(x_i)} \exp(-y_i F(x_i)) \end{aligned} \quad (3.27)$$

ここで、第1項は  $h_t$  によらない項であるので、第2項のみを考えることとする。

$$D_t(i) = \frac{1}{Z_t}, Z_t = \frac{1}{N} \sum_i \exp(-y_i F(x_i)) \quad (3.28)$$

とすれば、分布  $D_t$  における  $h_t$  の誤り率  $\epsilon_t$  を用いて次のように第2項を表すことができる。

$$\begin{aligned} &\frac{\exp(\alpha_t) - \exp(-\alpha_t)}{N} \sum_{i: y_t \neq h_t(x_i)} \exp(-y_i F(x_i)) \\ &= (\exp(\alpha_t) - \exp(-\alpha_t)) Z_t \epsilon_t \end{aligned} \quad (3.29)$$

すなわち、損失を小さくするためには分布  $\tilde{D}_t$  において誤り率が最小となる  $h_t$  を見つけ出せば良いことがわかる。

次に  $h_t$  が決まった後で損失関数

$$L(F + \alpha_t h_t) = Z_t \{ \exp(-\alpha_t) + (\exp(\alpha_t) - \exp(-\alpha_t)) \epsilon \} \quad (3.30)$$

を最小にする  $\alpha_t$  を考える. 右辺は下に凸な関数であることから  $\alpha_t$  が微分して 0 とおくことにより,

$$\alpha_t = \frac{1}{2} \log \frac{1 - \epsilon_t}{\epsilon_t} \quad (3.31)$$

で最小値をとることが分かる. また,  $2t < 0.5$  であれば

$$L(F + \alpha_t h_t) = L(F) 2\sqrt{(1 - \epsilon_t)\epsilon_t} < L(F) \quad (3.32)$$

となるので,  $\alpha_t$  で重みづけした新しい仮説を 1 つ加えることで, 損失関数を更に小さくできることが分かる.

このようにして, AdaBoost は指数損失のサンプル平均(経験損失)を最小化する. すなわち, 誤り率が最小となる弱識別器を学習することは, 損失関数が最も減少する方向を探索していると解釈できる. 従って, AdaBoost は損失関数を最小化させる最急降下法の 1 つであるとも言える.

### 3.4.5 二値判別の拡張による多値判別法

パターン認識手法の多くは二値判別の判別性能を基準としている. 3.4.4.2 小節で述べた AdaBoost やその他にも SVM など二値判別に特化した手法である. しかし, 現実的な使用を考えた場合には多値判別は必要不可欠なものであり, 現在においても多くの手法が提案され続けている.

多判別には, 大きく分けて二つのアプローチがある. 一つ目のアプローチは, 三クラス以上のラベルを同時に扱う損失関数を考え, その損失関数を何らかの手法により直接最小化することである. Bredensteiner ら[50] は SVM を拡張することで多値判別を実現している. こういったアプローチは理論的な解析が比較的容易であるとされているが, サンプル数が多い場合には, 計算量が増大するという欠点がある[51].

二つ目のアプローチは, 二値判別器を組み合わせることで多値判別を行う手法である. このアプローチは計算量が比較的抑えられること, 実装が容易であることから多くの実用上の問題で用いられている. また, 汎用性能の点においても, 一つ目のアプローチに劣らないことが実験的に示されている[52][53]. 二値判別器の拡張法として代表的な手法として, クラスラベルを符号化ルールに基づいて複数の二値判別問題に分解し, 判別結果を復号化ルールによって元のクラスラベルに戻すという ECOC 法

(Error-Correcting Output Coding) がある. 3.4.5.1 小節ではハミング復号に基づく ECOC 法(HD-ECOC) について述べる. 3.4.5.2 小節ではハミング復号を拡張した損失関数に基づく復号による ECOC 法(LD-ECOC) について述べる.

### 3.4.5.1 ハミング復号に基づく ECOC 法

#### Hamming Decoding ECOC (HD-ECOC)

ECOC 法は Dietterich と Bakiri によって提案された. 多値判別問題を複数の二値判別問題に分割するための手法である[54]. ここで,  $G$  クラス ( $G > 2$ ) の多値判別問題を考える. 訓練サンプルを

$$(X, Y) \equiv \{x^i, y^i\} \quad (3.33)$$

とし, 入力パターンを  $x^i \in R^d$ , クラスラベルを  $y^i \in \{1, \dots, G\}$ ,  $y^i$  に対応した多値スピン  $S^i$  のセットを  $S = (S^1, \dots, S^n)$  とする.

$p$  を二値判別問題 (二値判別器) の個数としたとき, 多値判別問題は符号表と呼ばれる  $p \times G$  行列  $W \in \{1, -1\}^{p \times G}$  によって行われる.  $W$  は対角に+1, 非対角に-1 に並ぶように構成する.  $G=3$  である場合,  $W$  は式(3.34) のようになる.

$$W = \begin{pmatrix} 1 & -1 & -1 \\ -1 & 1 & -1 \\ -1 & -1 & 1 \end{pmatrix} \quad (3.34)$$

この符号表  $W$  を用いて,  $G$  個のクラスラベルを符号語と呼ばれる  $p$  次元ベクトル  $Z = W_S$  に分解する.

$Z = W_S$  を符号化ラベルのセットとし,  $Z_j^i$  を  $i$  番目のクラスラベル  $y^i$  の符号化ラベル  $Z^i = WS^i$  の  $j$  番目の要素とする. 符号表  $W$  が与えられたとき, 入力ベクトルの集合  $X$  と  $Z$  の  $j$  行  $Z_j \equiv (Z_j^1, \dots, Z_j^n)$  をラベルとして学習する. この際, 符号化ラベル  $Z_j^i$  は 1 もしくは -1 であるが, ラベルに 0 を付加した符号化法が Allwein ら[55] によって提案されている. この手法を用いると,  $G=3$  である場合,  $W$  は式(3.35) の様になる.

$$W = \begin{pmatrix} 1 & -1 & -1 \\ -1 & 1 & -1 \\ -1 & -1 & 1 \\ 1 & -1 & 0 \\ 1 & 0 & -1 \\ 0 & 1 & -1 \end{pmatrix} \quad (3.35)$$

この符号表  $W$  を用いる場合は, 符号化ラベル  $Z_j^i$  は 1 もしくは -1 の値を持つ例題のみを用い, 0 を持つ例題を用いないようにして学習を行う. 学習過程においては二値判別器

である SVM や AdaBoost によって仮説  $H(X)$  を得る.

全ての仮説を求めることができたなら, ハミング復号によって  $G$  クラスのラベルを得る.  $W(r)$  を  $W$  行列の  $r$  列目,  $z_j^i$  に対応する仮説を  $h_j^i(x^i)$  としたとき, ハミング距離  $d_H^i$  を式(3.36)の様に定義する.

$$d_H^i(W(r), H(X)) = \sum_{j=1}^p \left( \frac{1 - \text{sign}(W(r, j) h_j^i(x^i))}{2} \right) \quad (3.36)$$

このハミング距離を最小にする  $r$  を, 最終的に求めるクラスラベル  $y^i \in \{1, \dots, G\}$  とする.

$$y^i = \arg \min d_H^i(W(r), H(X)) \quad (3.37)$$

### 3.4.5.2 損失関数に基づく ECOC 法

#### Loss-Based Decoding ECOC (LD-ECOC)

ハミング復号に基づく ECOC 法では, 式(3.37) において符号関数を用いているため, 得られた仮説  $h(x)$  の出力値は  $-1$  もしくは  $1$  の二値となる. SVM や AdaBoost のような二値判別器における符号関数を通す以前の出力値は, 識別平面からのユークリッド距離を表わし, これは識別されたクラスにおける信頼度を示す[56]. つまり,  $class1$  を  $-1$ ,  $class2$  を  $1$  として二値判別を行う場合, 出力値がマイナスに大きければ  $class1$  の傾向が強く, 出力値がプラスに大きければ  $class2$  の傾向が強いことを意味する (図 3.28).

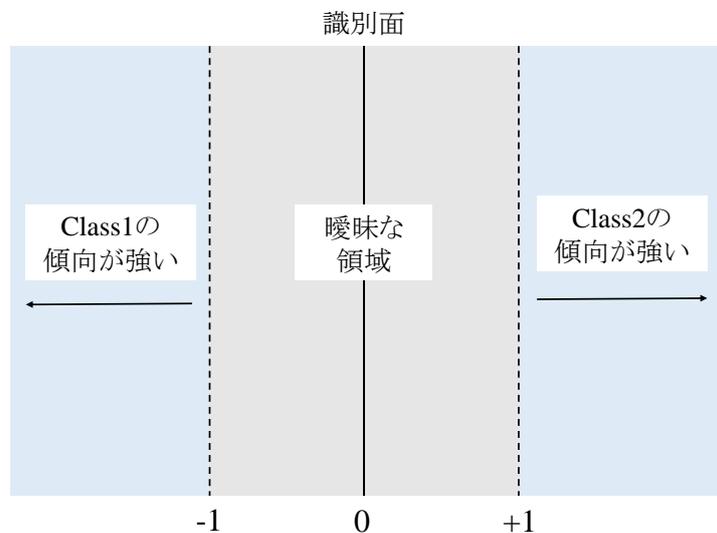


図 3.28 : 識別面とクラス傾向

Cognitive Distraction 検知において、特徴量の傾向はドライバの負担度によって異なり、さらに多くの特徴量の傾向を複合的に捉えるためには、復号化において各二値判別器の出力値が示すクラス傾向を考慮することが負担度決定に有効であると考えられる。本研究では仮説  $h(\mathbf{x})$  を損失関数として捉え、損失値に基づく ECOC 法を提案する。

損失値  $d_L$  は式(3.28) の指数関数によって定義される。

$$d_L^i(W(r), H(X)) = \sum_{j=1}^p \begin{cases} \exp(|h_j^i(x^i)|) & \text{if } W(r, j)h_j^i(x^i) < 0 \\ -\exp(|h_j^i(x^i)|) & \text{if } W(r, j)h_j^i(x^i) > 0 \\ 0 & \text{if } W(r, j)h_j^i(x^i) = 0 \end{cases} \\ = \sum_{j=1}^p -\text{sign}(W(r, j)h_j^i(x^i))\exp(|h_j^i(x^i)|) \quad (3.38)$$

この損失値を最小にする  $r$  を、最終的に求めるクラスラベル  $\hat{y}^i \in \{1, \dots, G\}$  とする。

$$y^i = \arg \min d_L^i(W(r), H(X)) \quad (3.39)$$

どちらも 3 クラス問題であり、符号の長さは 6 である。また、二値判別器の出力値は  $h_j = \{-2, -7, 0.5, -1, -9, -12 \mid j \in [1, 6]\}$  であったとする。ハミング復号によって識別を行った場合、符号関数を用いることで出力値は  $\text{sign}(h_j) = \{-1, -1, 1, -1, -1, 1 \mid j \in [1, 6]\}$  に変換される。この値と符号表とを比較すると、ハミング距離  $d_H$  が最小になる符号は  $d_3 = \{-1, -1, 1, -1, -1\}$  となるため、復号化によって *class3* と識別される。一方、損失関数を用いた場合には符号関数を用いないため、二値判別器の出力値がそのまま使用される。式(3.39) に二値判別器の出力値を入力し、損失値  $d_L$  を求めると、最小値は  $d_3$  であるため、復号化によって *class2* と識別される。

## 3.5 ドライビングシミュレータ運転時の眠気レベル推定

### 3.5.1 ドライビングシミュレータと走行コース

ドライバの居眠り運転検知を目的とする研究では、主にドライビングシミュレータを用いて被験者に単調なコースを走行させることにより居眠りを誘発させる。居眠り運転は第二章でも述べた通り重大な事故に繋がり易い。よって実車環境では危険が伴うため、ドライビングシミュレータが多く用いられる理由である。また、実験条件の再現性に優れているため、同一の走行状況を繰り返し多数の被験者に対して実験できる特徴がある。これらの利点を生かし、まだ未開発の装置やシステムを仮想的に作り上げ、それらの事前評価を行うために広く利用されている。これらのより本研究においてもドライビングシミュレータを用いて実験を行う。

実際に本研究で用いるドライビングシミュレータを図 3.29 と図 3.30 に示す。ハンドルやシートといった運転席回りに実車同様のもの(トヨタ自動車「シエンタ」を使用)を用い、プロジェクタに投影されるコースを走行するものである。また、走行コースに関しては Forum8 社の UC-win/Road により作成する。このシミュレータプログラムでは自車以外に先行車など他の車両も同時に走行させることが可能である。自車以外の車両はコンピュータで制御でき、先行車を用いる実験では実験条件に合わせ細かな制御が可能である。取得できる走行データは走行速度・加速度・車線逸脱量・ペダルストローク量・ハンドル操舵量などがあり、先行車を走らせている場合には先行車の走行データも取得可能である。

次に走行コースについて説明する。居眠りを誘発するコースとして適切なものは単調な道路形状であり、夜間を想定したものが代表的である。Preolle Haraldsson らは、眠気誘発コースとして、単調で道幅が狭くカーブを含む夕方のコースを作成している。本研究でも先行研究に従い、図 3.31 と図 3.32 に示すような眠気誘発コースを作成した。ランダムな S 字カーブを含め自車以外の車両は走行させないものとした。また、夜間を想定している。コースの全長は 20km であり、周回コースであるため時間を無制限に走行することが可能である。



図 3.29 : ドライビングシミュレータ概観

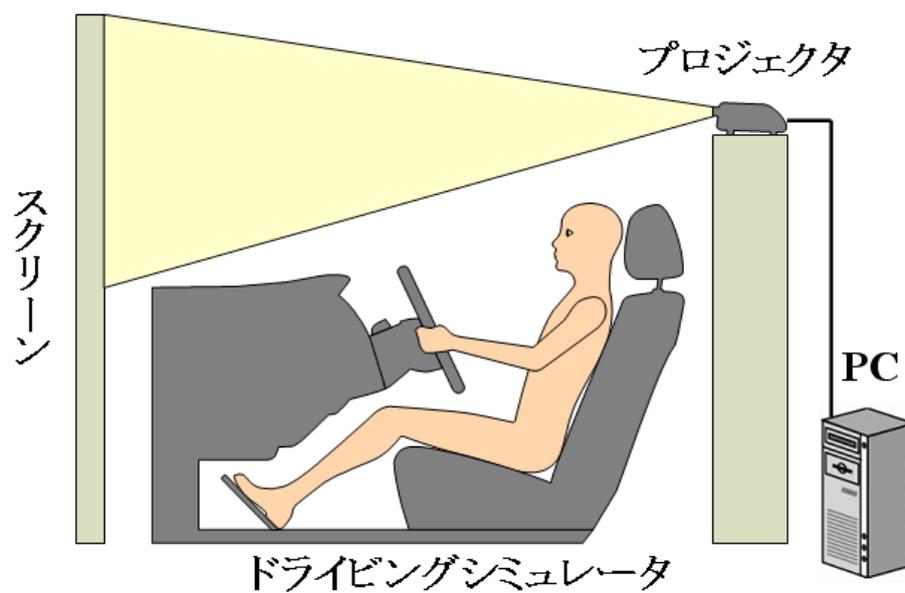


図 3.30 : ドライビングシミュレータ構成



図 3.31 : 眠気誘発コース(プロジェクター投影図)

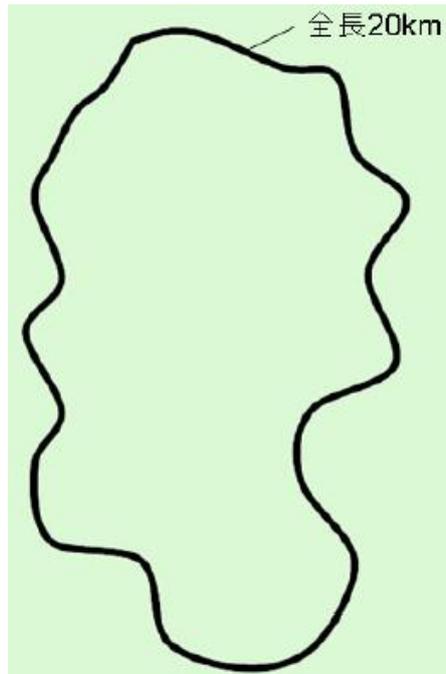


図 3.32 : 眠気誘発コース (コース全体図)

### 3.5.2 眠気誘発コース走行による居眠り運転模擬

居眠り運転模擬実験の概要について説明する。居眠り運転中の心電図・呼吸波形・カメラ画像(瞼開閉度)・シート荷重のデータを取得するために、被験者には図 3.33 に示すよう各データ取得機器を取り付けた。走行コースは前節で説明した眠気誘発コースを用いる。車速は 80km/h 前後を維持するよう指示した。被験者の眠気を誘発するため、実験中は外部の雑音が届きにくい室内で消灯して行った。また、サーカディアンリズムに従い実験開始時間は 13 時～15 時の間とした。実験の終了条件は、最低走行時間 30 分以上で被験者が寝るまでとした。被験者は 4 名(平均年齢 27.5 歳)で一人当たり 3 セット(合計 12 セット)のデータを取得した。いずれも健常な男性でありインフォームドコンセントを取得している。実験開始前には健康状態をアンケート方式により調査し、健康状態が悪い場合には実験を行っていない。

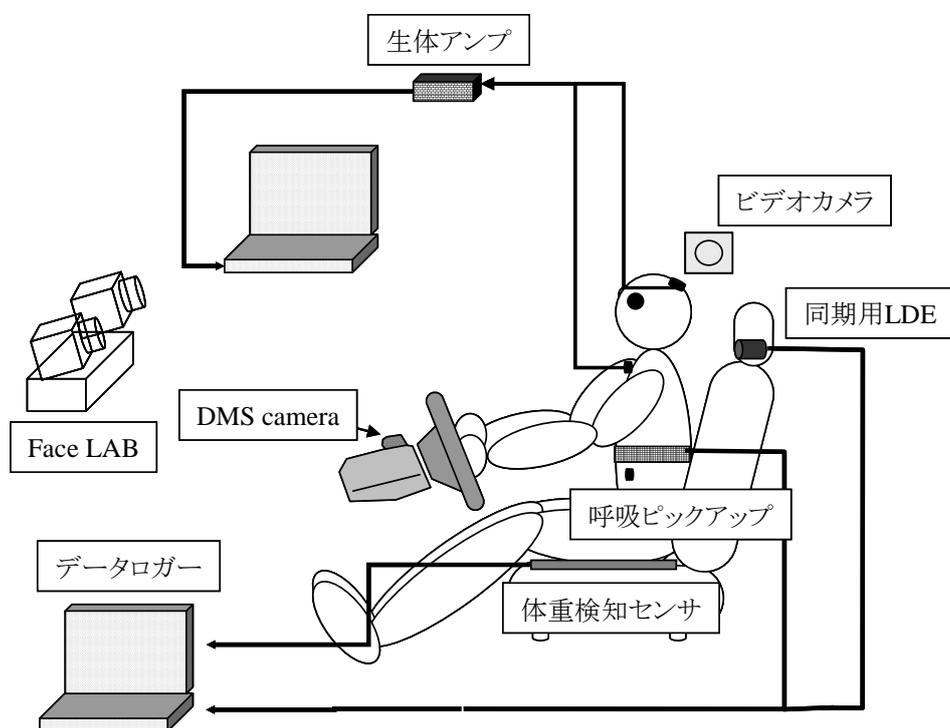


図 3.33 : 居眠り運転模擬実験の実験環境詳細

### 3.5.3 実験取得データからの特徴量抽出

#### 心電情報からの特徴量抽出

3.3.2 節にて心電の概要と自律神経系との関連について述べた。自律神経系は居眠りなどドライバの精神状態により交感神経と副交感神経の優位度が変化する。心電は自律神経系を反映する指標として用いることが可能であるため、自律神経系により大きく変動する特徴量を抽出することで眠気レベル推定を可能とする。

心電からの特徴量は基本的に心拍数から得られる RRI(3.3.2 節参照) から算出する(図 3.34)。この RRI データに対して周波数解析(FFT:Fast Fourier Transform) を施し有効な特徴量を得る。心電に関しては過去 2 分間のデータに対し、10 秒窓での解析区間で解析をしていく。尚、この 10 秒はビデオ映像からの顔表情評定値に評定区間に基づき設定した。

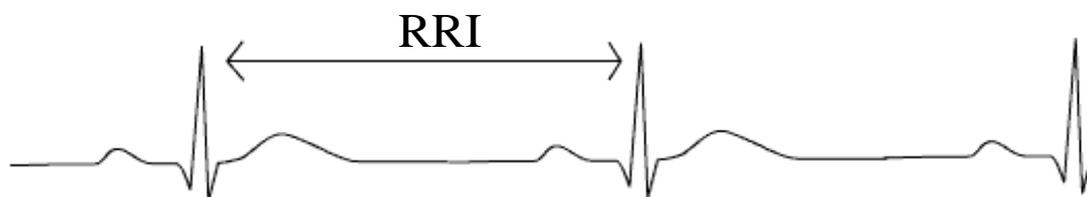


図 3.34 : RRI インターバル

表 3.7 : 心電情報から抽出する特徴量と概要

特徴量名	特徴量概要
心拍数	過去 2 分間の合計心拍数
RRI の S.D.	RRI の 2 分間の標準偏差
RRI 変動の S.D.	RRI の微分値の標準偏差
RRI 変動速度	RRI の 2 回微分
RRI 変動係数	RRI の 2 回微分の符号(+, -)
LF-power	RRI から得られる中間周波数成分(0.05-0.20Hz)の含有度
HF-power	RRI から得られる高周波数成分(0.20-0.35Hz)の含有度
LF/HF	LF-power と HF-power の比
LF/(LF+HF)	LF-power と HF-power の和と LF-power の比

### 呼吸情報からの特徴量抽出

呼吸は肺の活動に行われ、その伸縮が心臓の活動に影響を与える。心臓は自律神経系を反映する臓器であり、このことから呼吸は間接的に自律神経系の影響を受けるため居眠り検知のための特徴量として有効である。また、呼吸単体で考えても、人間の体が入眠状態に陥る直前にあくびが出る、また、活動量が減り単位時間当たりの呼吸回数や深度に影響が出ることが知られている。

本研究で用いる呼吸情報からの特徴量は、伊藤らにより提案された呼吸関連特徴量に基づき抽出を行った。伊藤らは呼吸情報のみから顔表情評定値と呼吸関連特徴量を相関評価し、有効な特徴量について提案した。呼吸の変動は瞬目や心拍と異なり緩やかであり、瞬観的な変化には追従できないものの3分程度の長期的な変動に関しては眠気レベルの傾向を掴むことが可能であると報告されている[57]。図 3.35 は、呼吸ピックアップから取得した呼吸信号である。この呼吸信号に対し閾値処理により、呼気、吸気ピークを算出し、特徴量化した。

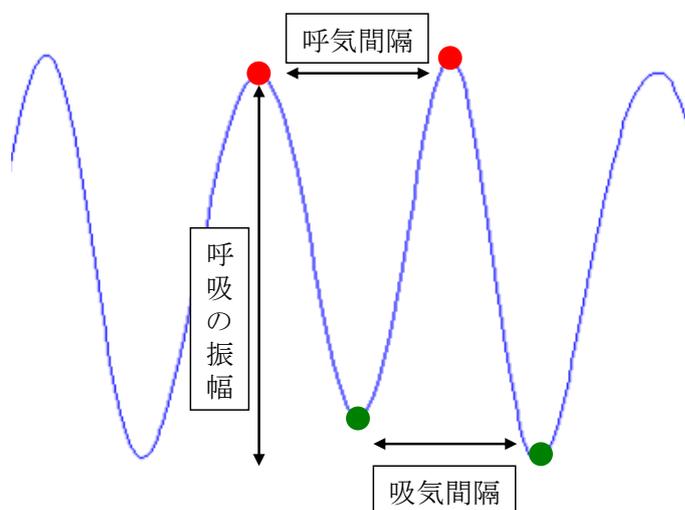


図 3.35 : 呼吸信号

表 3.8 : 呼吸情報から抽出する特徴量と概要

特徴量名	特徴量概要
呼吸間隔	過去 1 分間の平均呼吸間隔
呼吸間隔の S.D.	過去 1 分間の呼吸間隔の標準偏差
吸気間隔	過去 1 分間の平均吸気間隔
吸気間隔の S.D.	過去 1 分間の平均吸気間隔の標準偏差
呼気間隔	過去 1 分間の平均呼気間隔
呼気間隔の S.D.	過去 1 分間の平均呼気間隔の標準偏差
振幅変化率	標準時の振幅からの変化率
振幅の S.D.	振幅の標準偏差
呼気傾き変化率	振幅変化率/呼気時間
呼気傾きの S.D.	過去 1 分間の呼気傾きの標準偏差
深呼吸回数	1 分間で標準時の振幅より 1.5 倍以上の振幅が発生した回数
吸気傾き変化率	振幅変化率/吸気時間
呼気傾き変化率	過去 1 分間の吸気傾きの標準偏差

#### シート荷重情報からの特徴量抽出

シートからの荷重変動に基づく特徴量抽出に関しては、3.3.5 節で述べたとおり本研究の前段階として検討した特長量を用いる。(表 3.9)

表 3.9 : 荷重情報から抽出する特徴量と概要

特徴量名	特徴量概要
荷重中心変動回数	0.2inch~1.0inch 以内の変動回数
X 軸重心の逐次差分の S.D.	横方向重心 1 分間の逐次差分の標準偏差
X 軸重心の S.D.	横方向重心の 1 分間の標準偏差
荷重重心の逐次差分の S.D.	重心変動の 1 分間の逐次差分の標準偏差
荷重重心の平均値	重心変動の 1 分間の逐次差分の平均値
FL+RR の平均	シート左上端と右下端の 1 分間の平均値
FL+RR の S.D.	シート左上端と右下端の 1 分間の標準偏差
FR+RR の平均	シート右上端と右下端の 1 分間の平均値
FR+RR の S.D.	シート右上端と右下端の 1 分間の標準偏差

### 瞼開閉情報からの特徴量抽出

瞼開閉度からの特徴量抽出は,faceLAB から得られるデータの中から閉眼度から算出したものである. ここでの瞼開閉度と閉眼度は同義である. 瞼開閉度と眠気との関連については,多くの先行研究があり,古くから検討がなされてきた.

瞼開閉度の場合,瞼開閉度そのものが眠気との関連が強い特徴量と知られている. 瞼開閉度は1秒以内の瞬目も捉えることが可能であり,本来瞬間的な変化を捉えることに適している. しかし,本研究では真値として用いる顔表情評定値が10秒単位での出力となるため,特徴量化する際に10秒間隔に落として解析していく必要がある. そこで,積算値0.3秒のように0.3秒以上の閉眼状態が生じた回数などのように主に10秒間に眠気関連事象が何度起きたかを特徴量とした. 図3.36はfaceLABから得られる瞼開閉度データの一例である. 全ての特徴量はこのデータを元に抽出する.

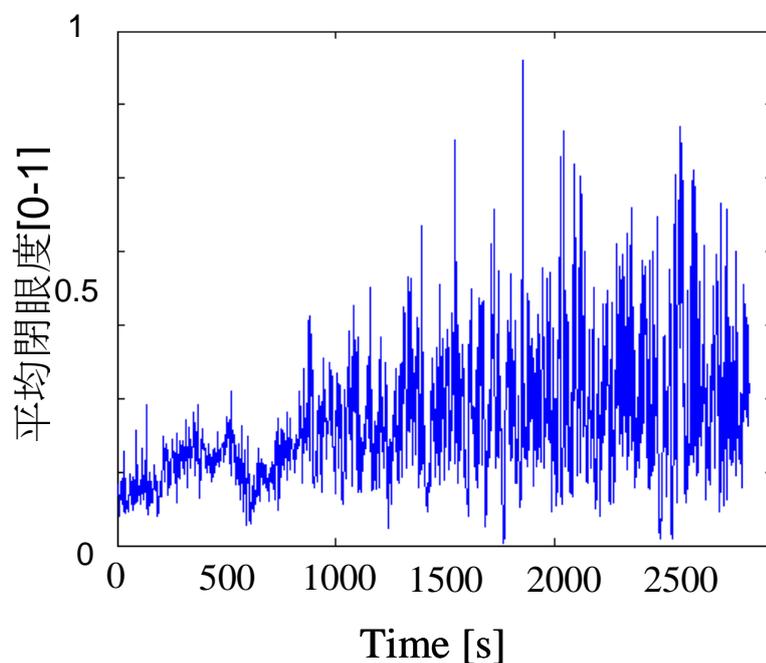


図 3.36 : 瞼開閉度データ

表 3.10 : 瞼開閉情報から抽出する特徴量と概要

特徴量名	特徴量概要
積算値 0.3 秒	閉眼時間が 0.3 秒以上の回数
閉眼持続時間の逆数和	閉眼持続時間の逆数和
LOG 顔ヨ一角の S.D.	顔のヨ一角に対する標準偏差
LOG 顔ロール角の S.D.	顔のロール角に対する標準偏差
最大瞬目間隔	瞬目から瞬目までの間隔の最大値
中間状態率	10 秒中の閉眼度[0-1]が 0.5 以上の時間の割合
平均閉眼時間	10 秒間の平均閉眼時間

### 3. 5. 4 特徴量の最適化手法(Stepwise Algorithm)

抽出した特徴量を有効に活用するためには、特徴量最適化手法を用いて最適な特徴量に選定し使用する必要がある。本節では、特徴量の最適化手法として有名なステップワイズ法について述べる。ステップワイズ変数選択法はパターン認識や重回帰分析を行う際に用いる変数選択法の一つである。まず、最も有用な特徴量の一つを採用する。次の段階では、まだ採用されていない特徴量のうちで最も有用な特徴量の一つを採用する。尚、最初の方で採用された特徴量も、後で採用された特徴量との関係で不要になる場合があるので、新たな特徴量の採用前に、すでに採用された特徴量を取り除くかチェックする必要がある。重回帰分析などの場合、特徴量の採用と除去は偏 F 値による検定で決定されることが一般的である。しかし、パターン認識などの場合は偏 F 値を求めず、自身で基準を設定し、その基準に基づき採用と除去を行う。

本研究においては眠気レベルの推定率が高いほど、精度がよいと言える。そこで、推定率自身を採用と除去の基準と用いることとした。後節からの眠気レベルの推定は、全てステップワイズ法にて最適化した特徴量で行っている。

### 3.5.5 パターン認識による推定と推定性能評価

#### パターン認識に用いたソフトウェア

本研究における解析は主に Matlab を使用し行っている。線形判別分析法に関しては組み関数 `classify` を用いた。 $k$  最近傍識別法に関しては有効な Toolbox や関数がないため、c 言語で作成したものを Matlab に読み込ませ使用している。また AdaBoost に関しては GML AdaBoost Matlab Toolbox を用いた。AdaBoost には様々な派生アルゴリズムが存在し、それぞれ信頼度の決定の仕方が異なる。GML AdaBoost Matlab Toolbox は以下のアルゴリズムを提供している (表 3.11)。

表 3.11 : AdaBoost アルゴリズムの種類と特徴

アルゴリズム	特徴
Real AdaBoost	誤り率を常に最大に保つように学習する
Gentle AdaBoost	学習器が+1 と判別する割合を算出する
Modest AdaBoost	前回の出力値を考慮することで、過学習を抑制する

Vezhnevets A. らは過学習を抑制する Modest AdaBoost が最も優れたアルゴリズムだとしている。このことから、本研究においては Modest AdaBoost を学習アルゴリズムとして採用した。また、弱識別器として決定木を用いた。決定木は Boosting の枠組みによく用いられる最も有名な弱い識別器であり、ひとつの木にひとつの分類ノードしかない最も単純な決定木を用いる。

#### 推定性能の評価方法

眠気レベル推定の評価方法としては以下の4項目を用いる。

- 正解率(推定誤差 0)[%](推定値と正解値が一致)
- 推定誤差 1 [%](推定値と正解値が 1 段階違い)
- 推定誤差 2 [%](推定値と正解値が 2 段階違い)
- 相関値(推定値と正解値の相関)

パターン認識手法を用いる研究の評価方法として、まず推定値と正解値の正解率が重要となる。また眠気レベル推定という本研究の場合、正解率に加え、正解か誤判定かの2値ではなく、正解値に対しどの程度ずれたかという点についても評価する必要がある。そこで、誤判定の中で1段階ずれた割合と2段階ずれた割合についても算出する。完全一致の正解率が同値であったとしても推定誤差 2 の割合が高いと推定性能としては

良いとは言えない。そして、時系列的に推定値と正解値の傾向の一致度について相関値を算出する。相関値は眠気レベル推定を目的とする研究において最も使用頻度の高い評価方法である。これらの評価値を算出する際は同一被験者を学習データに用いない **leave-one-out** 法により、推定を行った。尚、1 セット分のデータに不具合があったのでそのセットは削除している。

顔表情評定値算出区間の 10 秒を 1 フレーム( $t$ ) とし、そのときの正解値を  $F_t$ 、推定値を  $R_t$  とした場合の評価値算出式を以下(式 3.40)~(式 3.42) に示す。図 3.37 は推定値と正解値の例である。

$$\text{正解率(\%)} = \sum_{t=1}^T \frac{[F_t=R_t]}{T} \quad (\text{式 3.40})$$

$$\text{推定誤差 1(\%)} = \sum_{t=1}^T \frac{[F_t-R_t=1]}{T} \quad (\text{式 3.41})$$

$$\text{推定誤差 2(\%)} = \sum_{t=1}^T \frac{[F_t-R_t=2]}{T} \quad (\text{式 3.42})$$

また、相関値に関しては推定値と正解値の相加平均  $f$  と  $r$  を求め、その後相関値 *Relation* を求める(式 3.43)~(式 3.45)。

$$\gamma(\text{正解値の相加平均}) = \frac{1}{T} \sum_{t=1}^T R_t = \frac{R_1+R_2+\dots+R_T}{T} \quad (\text{式 4.43})$$

$$f(\text{推定値の相加平均}) = \frac{1}{T} \sum_{t=1}^T F_t = \frac{F_1+F_2+\dots+F_T}{T} \quad (\text{式 4.44})$$

$$\text{Relation(相関値)} = \frac{\sum_{t=1}^T (F_t-f)(R_t-\gamma)}{\sqrt{\sum_{t=1}^T (F_t-f)^2} \sqrt{\sum_{t=1}^T (R_t-\gamma)^2}} \quad (\text{式 4.45})$$

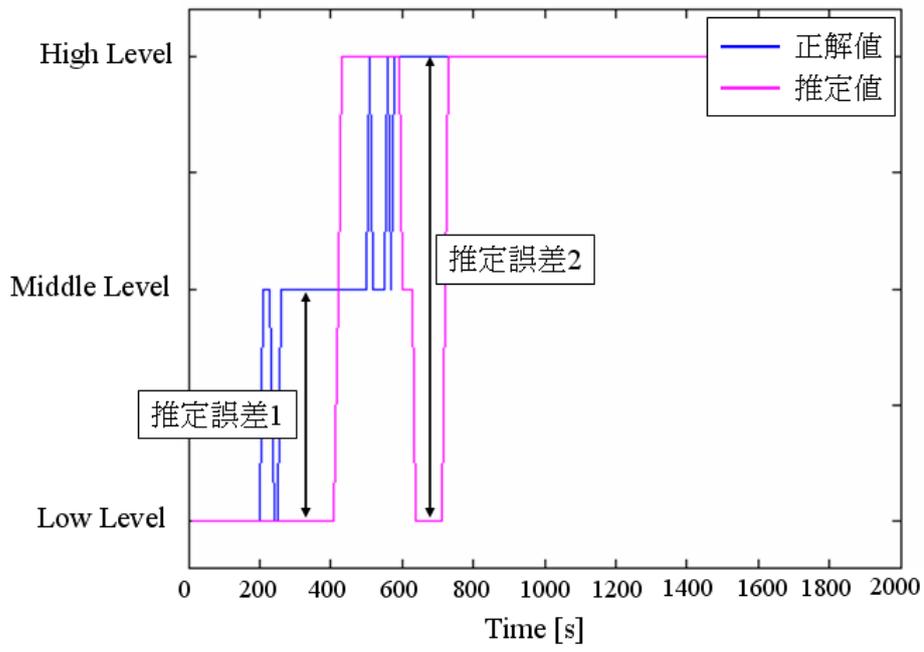


図 3.37 : 推定値と正解値の例

### 3.5.6 パターン認識による推定結果と考察

#### 3.5.6.1 推定結果

パターン認識手法,LDA,kNN,HDECOC,LDECOC の4つを用い3段階眠気レベル推定を行った結果について示していく. 図 3.38 及び表 3.12 は被験者4人11セットの推定結果の平均である. また, 表 3.13, 表 3.14, 表 3.15, 表 3.16 は被験者それぞれの個別の結果である.いずれも正解率, 推定誤差 1, 推定誤差 2, 相関値を算出している. 図 3.38 及び表 3.12 から正解率は LDA で 65.45 %, kNN, HDECOC, LDECOC 共に 77 %となった. LDA のみ他の手法と比較し正解率が低い結果となった. kNN, HDECOC, LDECOC は正解率のみではなく推定誤差, 相関値共に近い値となった. このことからこの3つの手法の判別性能は同等と言える.

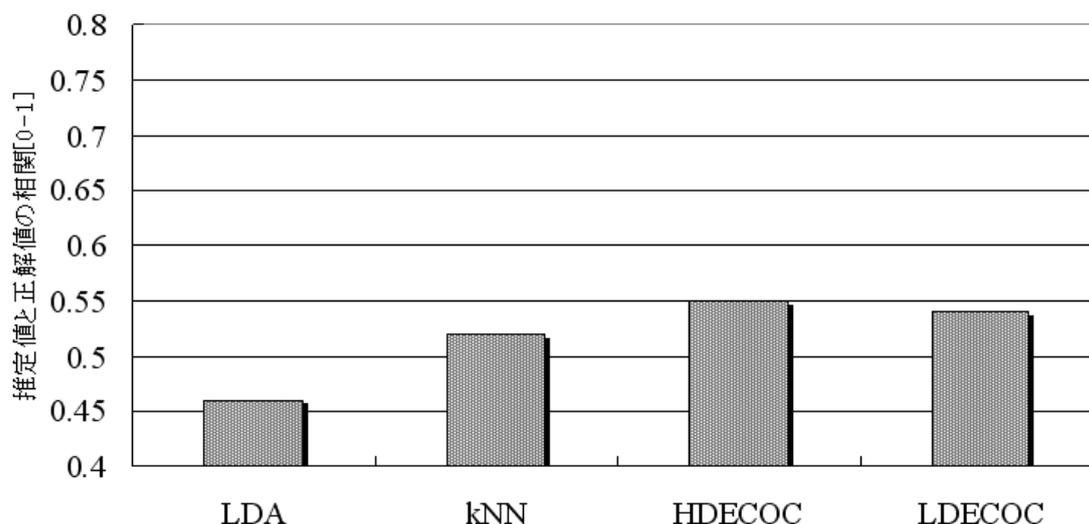


図 3.38 : 眠気レベルの推定値と正解値の相関(手法ごと)

表 3.12 : パターン認識手法を用いた際の眠気レベル推定結果詳細

	LDA	kNN	HDECOC	LDECOC
正解率(%)	65.46	77.42	77.44	77.45
推定誤差 1(%)	19.55	16.09	16.03	16.21
推定誤差 2(%)	15.00	6.50	6.53	6.30
相関値[0-1]	0.46	0.52	0.55	0.54

表 3.13 : 眠気レベル推定結果(個人ごと : LDA)

	LDA					
被験者	A-1	A-2	A-3	B-1	B-2	B-3
正解率(%)	43.88	42.20	71.43	66.50	64.56	75.58
推定誤差 1(%)	40.29	37.00	14.29	25.06	26.70	14.74
推定誤差 2(%)	15.83	20.81	14.23	8.44	8.74	9.68
相関値[0-1]	0.52	0.49	0.66	0.54	0.61	0.56

	LDA					
被験者	C-1	C-2	C-3	D-1	D-2	
正解率(%)	61.14	64.21	73.22	74.06	83.26	
推定誤差 1(%)	8.30	17.37	5.46	20.89	4.98	
推定誤差 2(%)	30.57	18.42	21.31	5.08	11.76	
相関値[0-1]	0.42	0.59	0.23	0.45	NaN	

表 3.14 : 眠気レベル推定結果(個人ごと : kNN)

	kNN					
被験者	A-1	A-2	A-3	B-1	B-2	B-3
正解率(%)	80.56	74.00	79.50	68.54	58.25	83.16
推定誤差 1(%)	15.47	17.34	12.42	21.99	32.03	16.84
推定誤差 2(%)	3.95	8.67	8.07	9.46	9.70	0
相関値[0-1]	0.75	0.75	0.60	0.50	0.53	0.53

	kNN					
被験者	C-1	C-2	C-3	D-1	D-2	
正解率(%)	84.27	75.78	90.16	76.47	84.16	
推定誤差 1(%)	8.29	17.36	5.46	21.92	9.50	
推定誤差 2(%)	7.42	6.84	4.37	1.60	6.33	
相関値[0-1]	0.62	0.70	0.15	0.65	0.54	

表 3.15 : 眠気レベル推定結果(個人ごと : HDECOC)

	HD-ECOC					
被験者	A-1	A-2	A-3	B-1	B-2	B-3
正解率(%)	75.12	80.34	81.34	66.24	54.85	82.94
推定誤差 1(%)	16.90	15.60	17.39	21.99	25.24	16.63
推定誤差 2(%)	7.91	4.04	1.24	11.76	19.90	0.42
相関値[0-1]	0.69	0.76	0.78	0.39	0.38	0.31

	HD-ECOC					
被験者	C-1	C-2	C-3	D-1	D-2	
正解率(%)	84.27	75.78	90.16	76.47	84.16	
推定誤差 1(%)	8.29	17.36	5.46	21.92	9.50	
推定誤差 2(%)	7.42	6.84	4.37	1.60	6.33	
相関値[0-1]	0.62	0.70	0.15	0.65	0.54	

表 3.16 : 眠気レベル推定結果(個人ごと : LDECOC)

	LD-ECOC					
被験者	A-1	A-2	A-3	B-1	B-2	B-3
正解率(%)	75.12	77.45	85.09	65.98	54.36	83.36
推定誤差 1(%)	17.62	19.07	13.04	22.50	25.72	16.63
推定誤差 2(%)	7.19	3.46	1.86	11.50	19.90	0
相関値[0-1]	0.72	0.79	0.82	0.44	0.36	0.33

	LD-ECOC					
被験者	C-1	C-2	C-3	D-1	D-2	
正解率(%)	83.40	76.84	90.71	76.20	83.71	
推定誤差 1(%)	8.29	17.36	5.46	22.19	10.40	
推定誤差 2(%)	8.29	5.78	3.82	1.60	5.88	
相関値[0-1]	0.49	0.71	NaN	0.65	0.57	

### 3.5.6.2 考察

#### 正解率と相関値に関する考察

正解率は LDA で 65.45 %,kNN,HDECOC,LDECOC 共に 77 %となった。また相関値はLDA が0.46, 他の手法が0.5 強となった。正解率は8 割近い値を算出しているのに対し、最も重要な指標である相関値に関しては、正解値と相関関係に無いという結果である。これは実際の眠気レベルに対し追従できていないことを示している。

図 3.39 は knn を用いた推定結果の一例である。正解率は 79.03 %, 推定誤差1は14.84,推定誤差2は 6.11, 相関値は 0.58 である。平均的な結果と比較し高精度の結果である。この結果では正解値が LowLevel である実験開始直後に推定値が MiddleLevel, 場合によって HighLevel を示している。また、実験時間半ばで正解値が HighLevel に達している状態において LowLevel と推定しているケースが多々ある。このような推定値が正解値に対し、2 段階以上突発的に外れてしまい、次のフレームでは正解値を算出するといった現象は、居眠り検知システムとしては致命的な問題である。特徴量空間において新たなデータが入力された場合、そのデータの近傍のクラスに判別される kNN アルゴリズムの特性状、これは入力特徴量が学習データに対し、明らかにはずれた値であることを示している。このことからまず特徴量の分布について考察する必要がある。また、推定結果の算出がフレームごとに独立している点もこのような突発的な誤判定を生み出す要因となっている。パターン認識の場合、各眠気レベルが段階的なものではなく、独立したクラスとして扱う。また、時間変化に関しても独立に推定を行う。運転中に段階的に変化していく眠気レベルに対しては、そのようなドライバの覚醒低下特性についても考慮する必要がある。まとめると、眠気レベルの追従性の向上(相関値の向上) のために特徴量分布の問題とフレーム毎の独立した推定の問題の2つの問題を解決する必要がある。

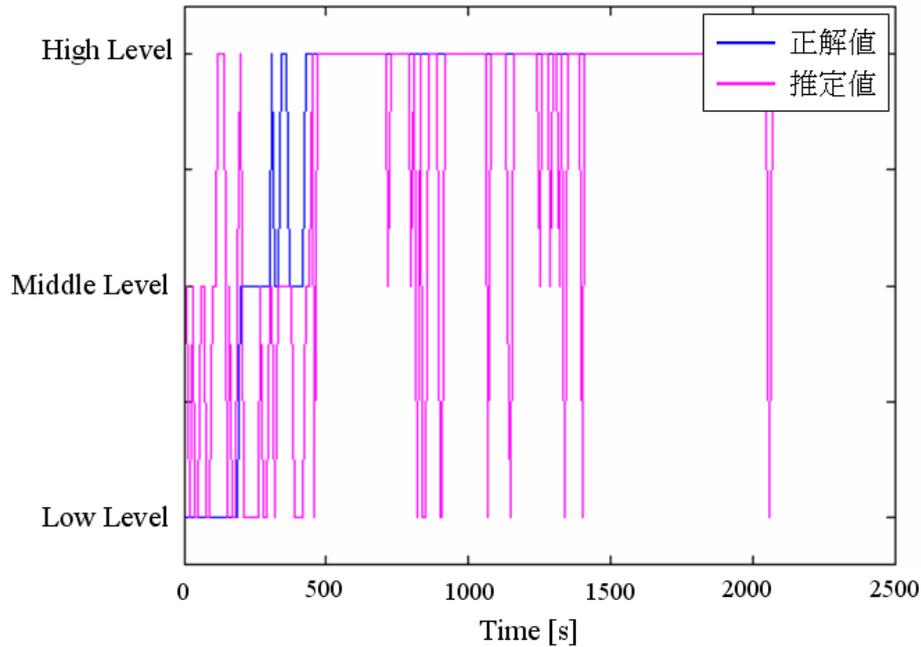


図 3.39 : 推定結果の一例 (kNN)

### 各特徴量の時系列推移に関する考察

前小節において、推定値の突発的な誤判定は特徴量によるものと考察した。本小節では、特徴量の時系列推移から実際に特徴量が変動しているか考察する。図 3.40～3.43 は、平均閉眼時間と荷重情報の推移である。図中の破線より左側が眠気レベル **Low**, **MiddleLevel** であり右側が **HighLevel** である。それぞれ眠気レベルの上昇と共に増加傾向にあり、眠気レベル推定において有効な特徴量であることが分かる。しかし、全体としての傾向は増加傾向にあるもののフレームごとに大きく値が変動していることも分かる。瞼開閉情報、シートからの荷重情報共にドライバの意志や眠気以外の要因においても影響を受け易い特徴量であり、この変動は免れることができない。一方で、本研究では瞼開閉情報の他に心拍情報や呼吸情報など生体情報も特徴量として扱っている。特に心拍情報はドライバの意志では変動させることができないため、フレームごとの変動は少ないように思える。平均心拍数と平均呼吸間隔時間の推移を観察すると、こちらも瞼開閉情報や荷重情報と同じく眠気とともに増加・減少傾向にあるもののフレームごとの変動が生じている。これは生体特有の揺らぎや眠気以外の要因による変動である。

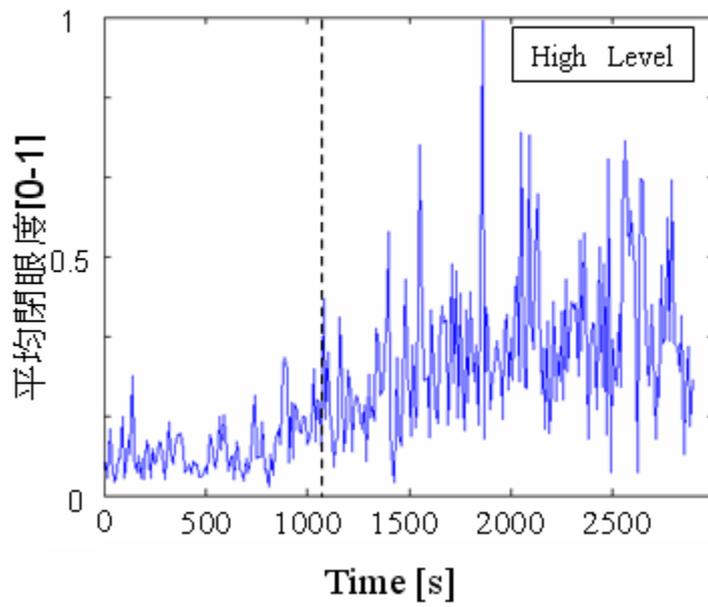


図 3.40 : 平均閉眼時間の推移

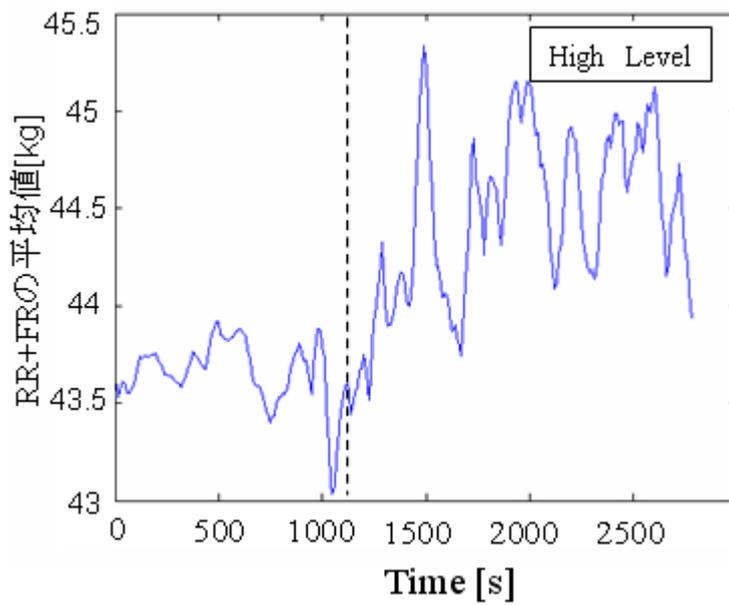


図 3.41 : 荷重情報の推移

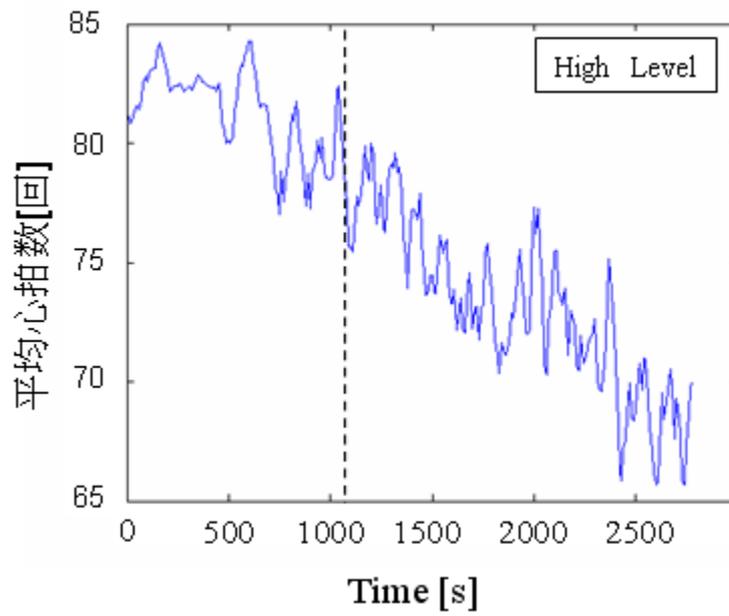


図 3.42 : 平均心拍数の推移

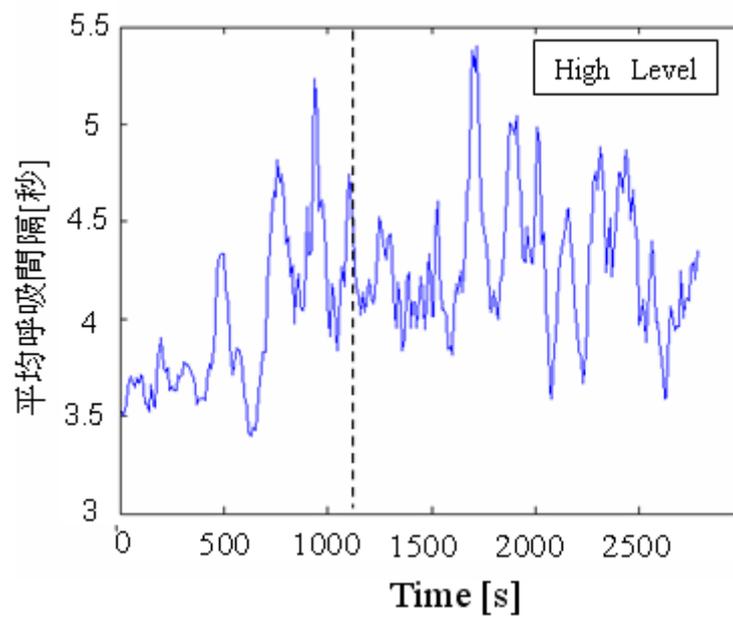


図 3.43 : 平均呼吸間隔時間の推移

### 特徴量の重複に関する考察

特徴量の分布に関して考察する。図 3.44～図 3.47 はそれぞれ瞼開閉度情報、シート荷重情報、呼吸情報、心拍情報の特徴量から抜粋したものである。眠気レベルごとに特徴量の分布をヒストグラム表示したものである。眠気レベルごとにピークがずれていることが好ましい。しかし、どの特徴量分布を見ても眠気表情評定値 5 段階でピークがずれているものは無い。多くの場合が重なり合っており、この特徴量分布では如何に判別能力の高い手法を用いても的確に判別することは不可能である。しかし、図 3.56 など眠気レベル(012)(34)でピークがずれており、この 2 段階判別であれば可能であることが推測できる。他の特徴量でも同様に判別可能な眠気レベルが存在する。つまり、本研究で行っているような同時 3 段階判別は無理としても、特徴量ごとに得意とする判別基準があり、その基準でなら判別が可能である。もし 3 段階判別を的確行うのであれば、3 段階とも同じ特徴量を用いるのではなく判別基準ごとに最適な特徴量を用いて推定することで精度が向上する可能性がある。また、隣接する眠気レベル同士でも互いに特徴量分布が重複しているため、その点についても重複を無くす前処理を行う必要がある。

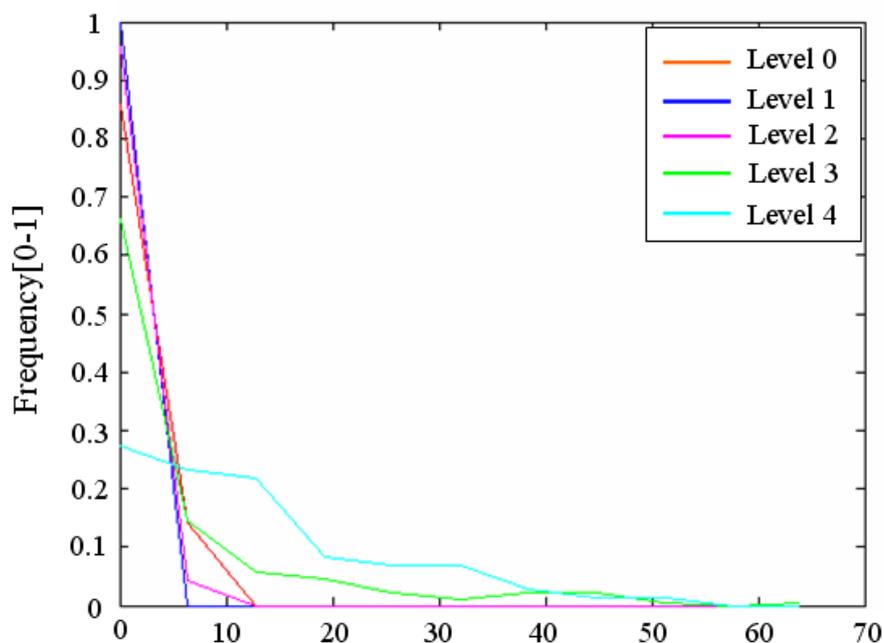


図 3.44 : log 積算 0.3 秒 (カメラ) の眠気レベルとの関係

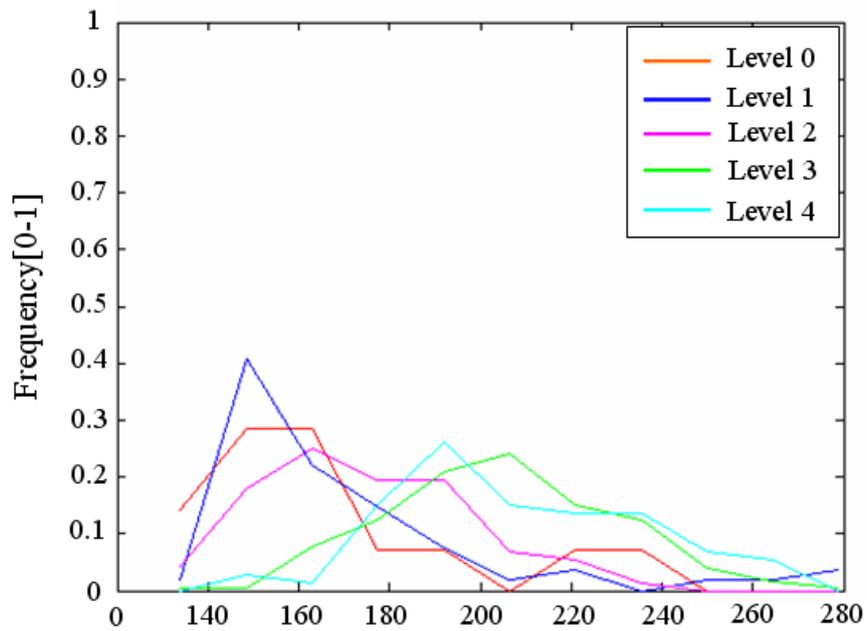


図 3.45 : 荷重中心変動回数(シート)の眠気レベルとの関係

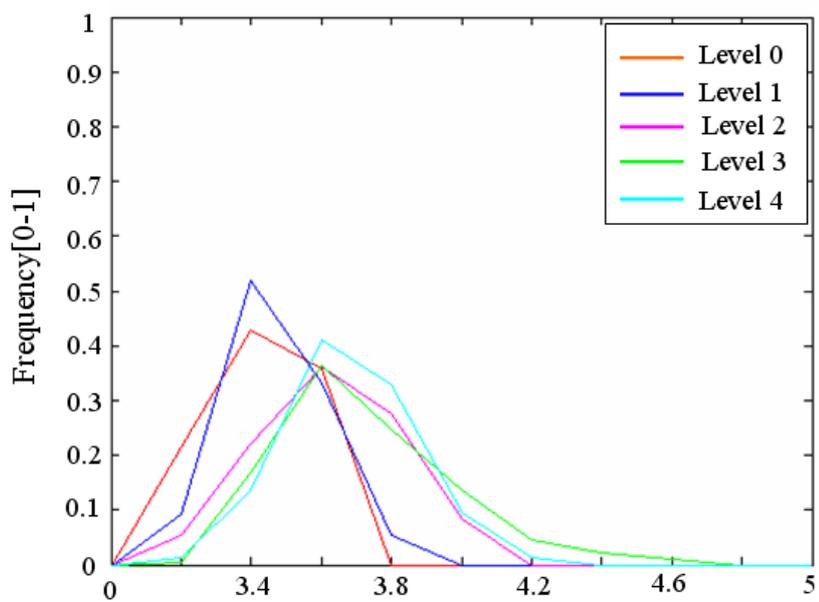


図 3.46 : 呼吸間隔[秒] (呼吸) の眠気レベルとの関係

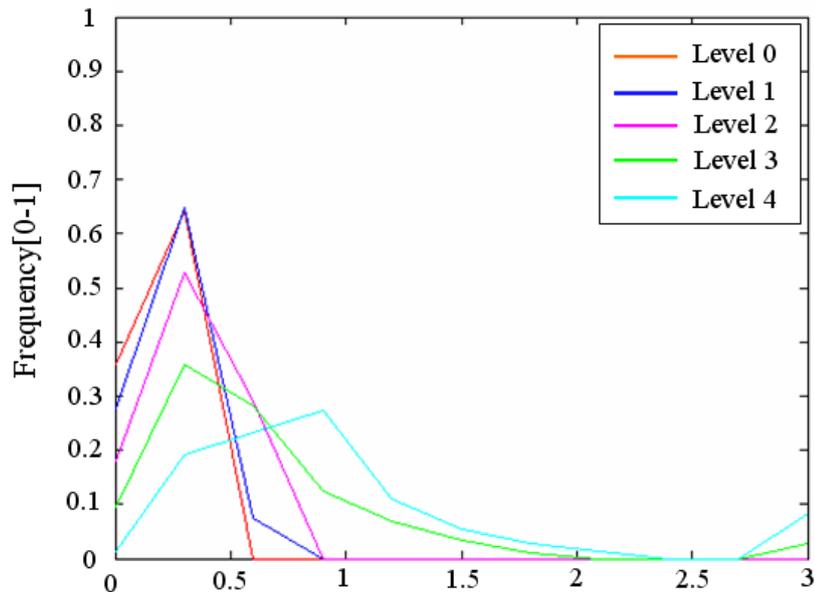


図 3.47 : RRI の S.D. (心拍) の眠気レベルとの関係

### 3.5.6.3 精度向上のための課題

前節で述べた特徴量の重複に関する考察から推定精度(正解値・相関)を向上させるためには、ドライバの意識的な動きや生体の揺らぎに影響を受けた特徴量が入力されても対応できる手法を提案する必要がある。本研究ではこの課題を複雑度の高い多値判別問題として捉えて解決に向けたアプローチを実施する。

ドライバの眠気レベル推定に関する研究に関わらず、”判別”を目的とした研究において、常に有効な特徴量を取得することが可能とは限らない。特徴量が重複した場合においても、明確な判別を行うことが可能な手法があれば、他分野においても活用できると考えられる。

まずは、解決すべき課題について整理する。

#### 課題 1 : Low Level, Middle Level, High Level の 3 レベルを明確に判別できる特徴量が存在しないことによる誤判定の発生

前節「特徴量の考察」で述べた通り、正解値として定義している 3 レベルに対して、明確に判別できる特徴量は存在しない。本研究で用いた眠気関連特徴量は、先行研究にて「ドライバの眠気推移と関連がある」ことが示された特徴量である。しかし、眠気推移と関連があろうとも、本研究にて定義している「運転支援レベルに合わせた眠気レベル」を判別できるとは限らない。しかし、2つのレベルを明確に分けることが可能な特

徴量は存在する。レベルを明確に判別するためには、手法を改良することにより、各特  
徴量の持つ眠気推移との関連性を有効利用することが推定精度向上に繋がると考える。

## **課題 2：生体信号のゆらぎ，眠気以外の要因による生体信号への影響から，特徴量に多 くのはずれ値が発生することによる誤判定の発生**

前節「各特徴量の時系列推移に関する考察」から，本研究で用いた眠気関連特徴量の  
多くは，大きなゆらぎやはずれ値が発生していることが確認できる。これは生体から取  
得できる信号において，常に発生する現象である。本研究では，「眠気」の推移を捉え  
ることに焦点を当てた特徴量を用いているが，生体信号自身は眠気のみで変動す  
るわけでは無く，疲労に代表される他の要因についても変動する。また，生体特有のゆ  
らぎは生体信号を扱う上で必ず発生する。ゆらぎやはずれ値は推定精度に対して影響を  
及ぼすため，手法を改良することにより，これらを抑制することが推定精度向上に繋が  
ると考える。

上記課題の解決に向けたアプローチとして課題 1 に対しては，1つの判別器による 3  
レベル同時判別を取りやめ，Low Level, Middle Level 以上を判別する判別器と，High  
Level, Middle Level 以下を判別する判別器の 2つを用意し，それぞれの判別器に対し  
て最適な特徴量を入力する段階的な判別を実施する。課題 2 に対しては，推定区間(10  
秒間)に依存した推定を取りやめ，過去の推定結果を考慮した推定を実施する。

次節では，上記解決に向けたアプローチの詳細について説明する。

## 3.6 覚醒低下の段階変化を考慮した眠気レベル推定

### 3.6.1 眠気変動の特徴

眠気の変動について考察するため、ビデオ映像から得た被験者の顔表情評定値(眠気レベル)を図 3.48,3.49 に示す。それぞれ、約 40 分の眠気レベルの変動であるが、まず眠気レベルでは 2 段階に渡る大きな変動が無く段階的に 1 段階ずつ眠気レベルが増加していることが分かる。また、1 度眠気レベルが変動するとその後に大きな変動は無く、眠気レベルが安定していることが分かる。この傾向は本研究で取得した 11 セットのデータ全てに言えることである。また、沼田ら[10]は顔表情評定値に基づく眠気の変動について考察しており、12 名の被験者に各々 2.5 時間の走行を指示し、顔表情評定値が変動する間隔について調査したところ、45～251 秒の間で変動すると報告している(平均で約 150 秒)。この知見は本研究での眠気レベル変動と同じである。これらの特徴は使用している特徴量では見られない傾向であり、その特徴量をそのまま用いては推定値に誤判定が生じることは自明である。しかし、本研究で用いている特徴量はいずれも多くの先行研究で眠気との関連性を検討されたものであり、眠気レベルに対し傾向を捉えることは可能である。

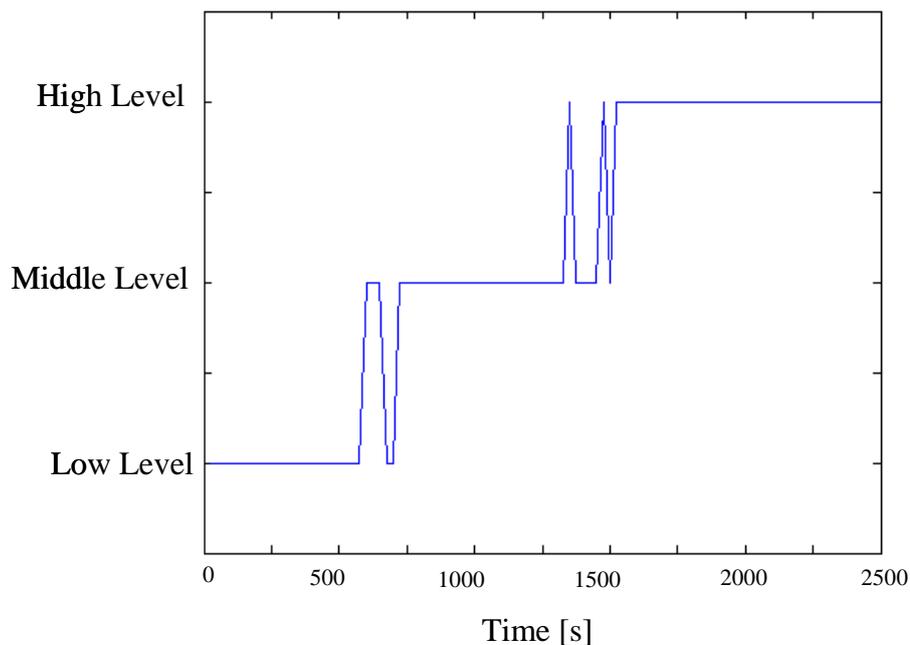


図 3.48 : 顔表情評定値の変動(1)

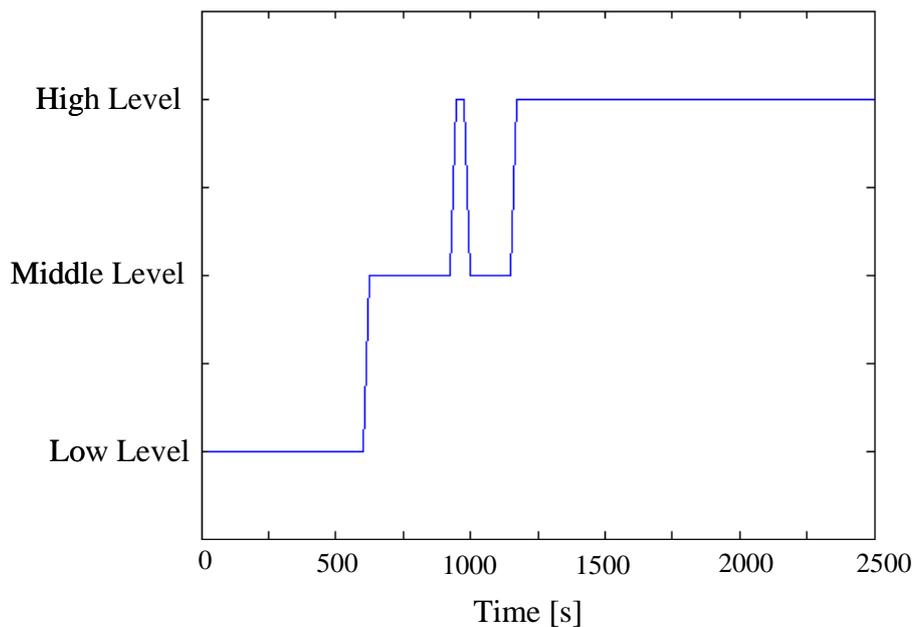


図 3.49 : 顔表情評定値の変動(2)

### 3.6.2 マハラノビス汎距離を利用した多値判別拡張

前節での精度向上のための課題の一つとして、眠気レベル間の特徴量の重複問題を挙げた。特徴量の重複とは各眠気レベル（クラス）の境界が明確でないことが挙げられる。つまり、簡単な例としてある特徴量が 100 という値であった場合に、そのときの正解値が A であることもあれば B であることもあるような曖昧な状態のことを指す。この状態ではとても正確に判別できないことは自明である。この問題を解決するためには重複している範囲を学習過程の段階で考慮する必要がある。

そこで、本研究ではマハラノビス汎距離を利用して重複特徴量を検知し、学習過程から除去する方法を提案する。マハラノビス汎距離は多変数間の相関に基づくものであり、新たなデータに対しその類似性から既知のデータとの関係を明らかにするために用いられる。本研究では、このマハラノビス汎距離を隣合うクラスで求めた。ここで例として LowLevel データ郡と MiddleLevel データそれぞれのマハラノビス汎距離を求め方について説明する。まず、基本的なマハラノビス汎距離の形式的な定義としては、平均が  $\mu = (\mu_1, \mu_2, \mu_3, \dots, \mu_p)^T$  で、共分散行列が  $\Sigma$  であるような多変数ベクトル  $g = (g_1, g_2, g_3, \dots, g_p)^T$  で表される一群の値に対するマハラノビス汎距離は次のように定義できる(式 3.40)。

$$D_M(g) = \sqrt{(g - \mu)^T \Sigma^{-1} (g - \mu)} \quad (3.40)$$

また、本研究で用いるように 2 つのベクトル  $x$  と  $y$  の間の類似性を求める場合は次のように定義できる。(式 3.41)

$$D_M(x, y) = \sqrt{(x - y)^T \Sigma^{-1} (x - y)} \quad (3.41)$$

上記の式に基づき,LowLevel 郡に対しMiddleLevel データの 1 つ 1 つはどの程度の距離 (類似性) があるのか数値化したこの処理により,類似性が高いものは重複データの可能性があるとし検出対象とできる. 距離が小さいものほど重複データの可能性が高く除去する必要がある. 重複データ除去のための閾値であるが, 算出されたマハラノビス汎距離の値で 30 と設定した. この値は, 値を 1 から 100 まで変動させた際の最適値である. 図 3.50 から図 3.53 は重複特徴量検知の処理 4STEP の流れを示したものである.

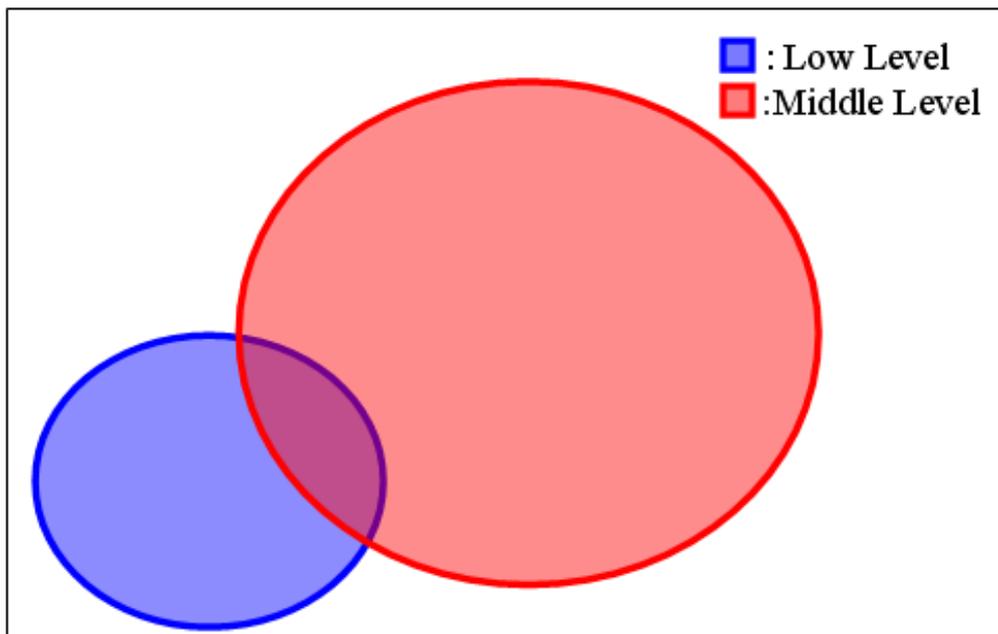


図 3.50 : STEP1

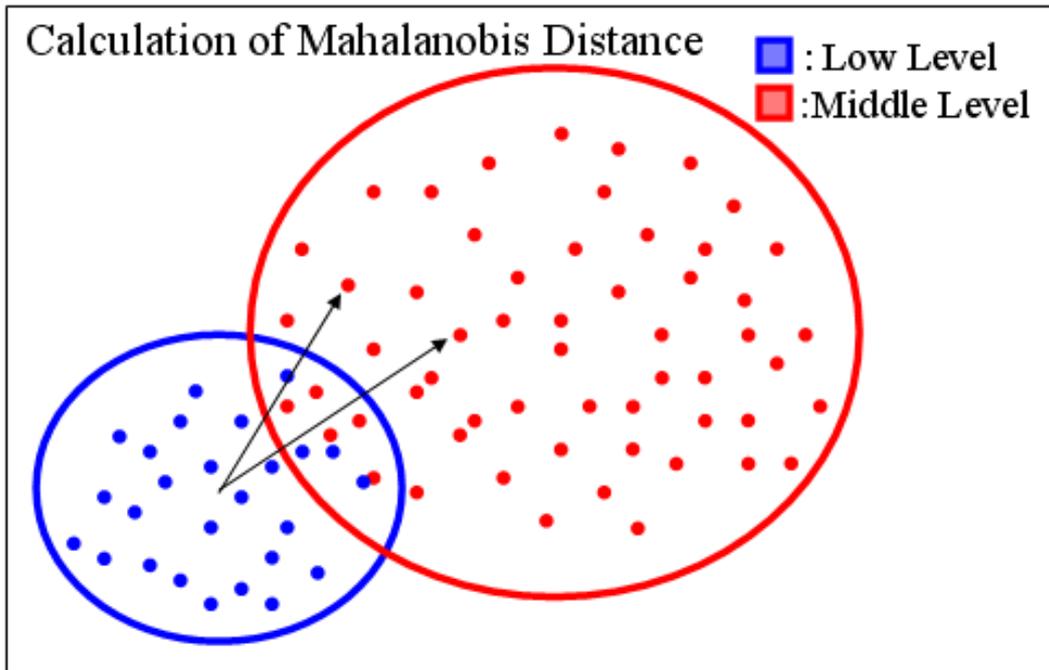


図 3. 51 : STEP2

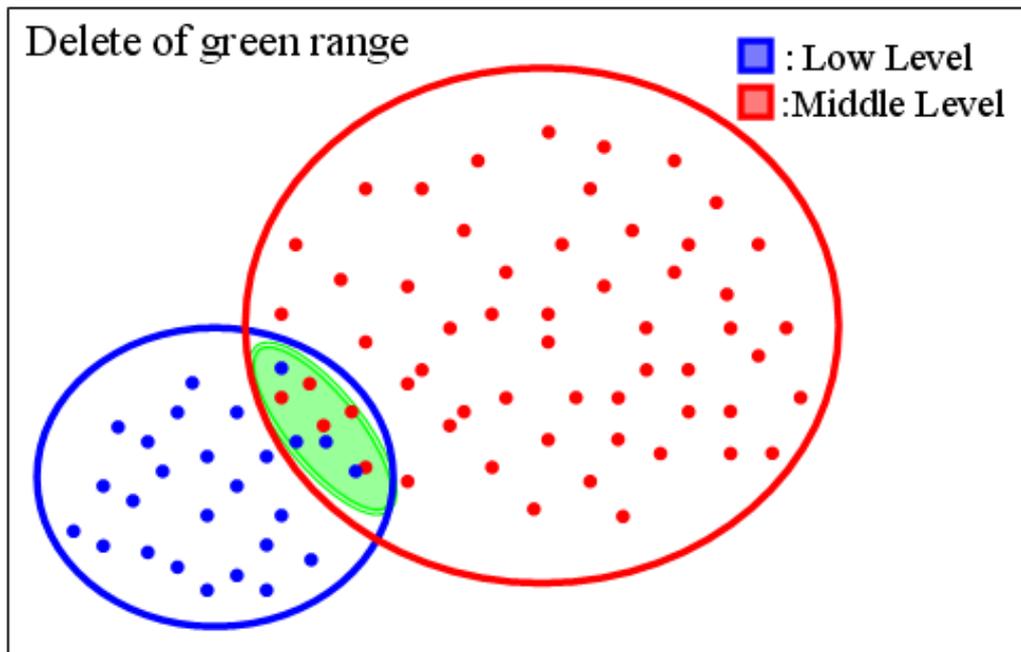


図 3. 52 : STEP3

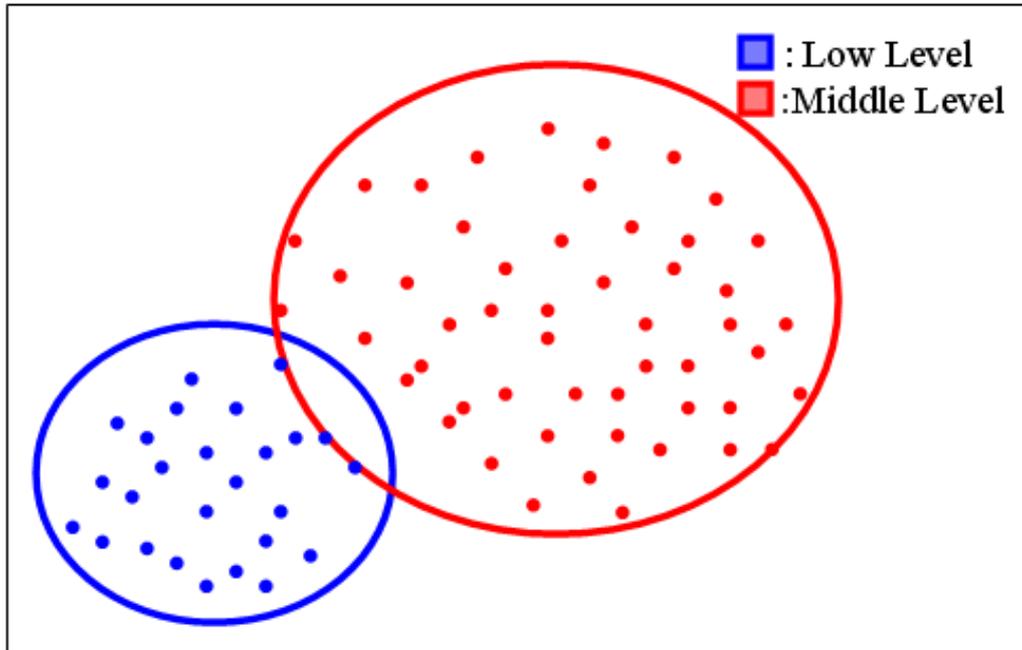


図 3.53 : STEP4

### 3.6.3 判別基準ごとの Expert Model を利用した多値判別拡張

#### Expert Model

前節での一般的なパターン認識手法を用いた際の課題に、3段階を同時に判別できる特徴量は無く、それぞれ得意とする判定基準が異なる点に対する対処を挙げた。通常のパターン認識手法では、判別する全てのクラスを同一の特徴量を用いて一括で多クラスに判別する。しかし、これでは本研究のように多段階を同時に判別できる特徴量が無い場合、判別は不可能になる。そこで、各判別基準ごとに特徴量を最適なものを用いることで解決を図る。つまり、図 3.54 に示すように、3クラス判別の場合は(12)(3)を判別する最適識別器と(1)(23)を判別する最適識別器を特徴量の段階から最適化する。そして、最終的に2つの識別器の識別結果から復号することで判別結果を得る。ECOC法のように2値判別器を複数用いて多値判別を行う手法は他にもあるが、特徴量の段階から最適化を行う点が眠気レベル推定に適している点である。本研究ではこのように構成する2値判別器を Expert Model と呼ぶこととする。

実際に眠気レベル推定に用いる場合の仕様について説明する。Expert Model を構成する上で考慮すべき点は、特徴量の最適化方法・用いる2値判別器・復号法である。本研究では、特徴量の最適化法については stepwise 変数選択法を用いて、(Low

### 通常のパターン認識



### 提案手法

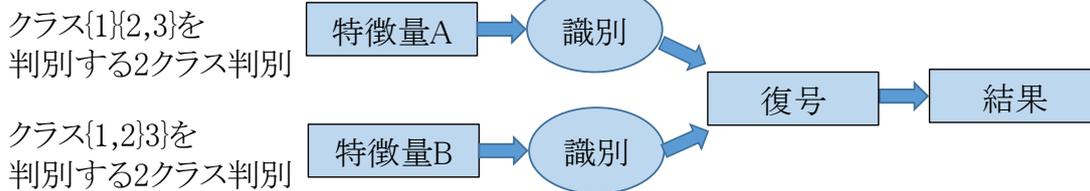


図 3.54 : Class1, 2, 3 という 3 クラス判別の例

Level)(Middle Level, High Level)を判別する最適特徴量と,(Low Level, Middle Level)(High Level) を判別する最適特徴量を選択する。また、2 値判別器には AdaBoost を用いた。復号法については次小節で述べる。

### カスケード方式に基づく復号法

2 値判別器の組合せで多値判別を行う場合、2 値判別器の判別結果をどのように復号するかが大きな問題となる。ECOC 法の場合は、多値判別をできるだけ細かく 2 値判別器に分解し、その中で最もらしい判別を行っている判別器のみをハミング復号により選択し、最終的な判別を行っている。この手法は、多量の 2 値判別器を用いているため、有効な判別器とそうでない判別器を選択して復号する。本手法での 2 値判別は ExpertModel によって、判別基準ごとに最適な 2 値判別器を構成する。よって、判別基準ごとの信頼性が非常に高いものとなるため、段階的な復号法を用いる。つまり、Low Level と Middle Level 以上に判別後、Middle Level 以上と判別されたものに対し、今度は Middle Level か High Level かという判別を行う。これは Expert Model の性能に最終的な精度が依存する復号法である。図 3.55 に復号のルールをまとめる。

- **Low Level** 各 2 値判別器が -1 と判定した場合に Low Level と判別
- **Middle Level** Classifier1 が -1, Classifier2 が 1 と判定した場合に Middle Level と判別
- **High Level** Classifier1 と Classifier2 が共に 1 と判定した際に HighLevel と判別

例外として、(Classifier1 が -1, Classifier2 が 1) このような判別は通常ありえないが、この場合は 2 値判別時の精度が高い識別器を優先する。

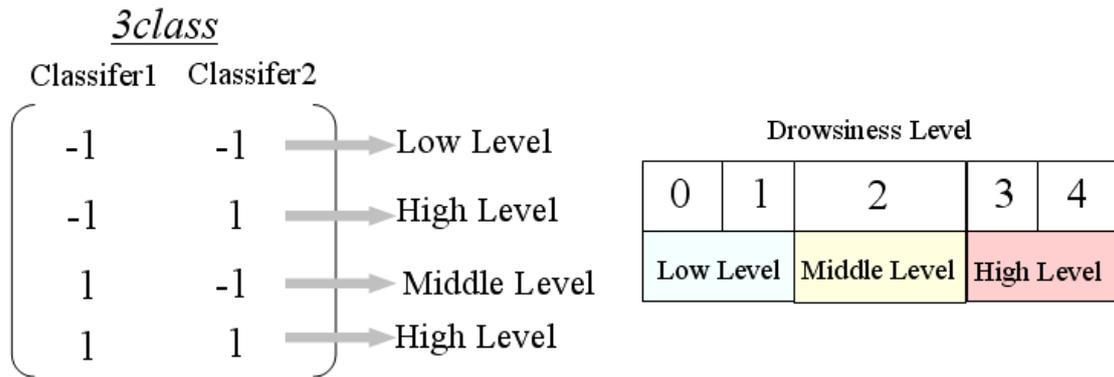


図 3.55 : 復号ルール

### 3.6.4 推定信頼度を重みとした時系列推定の定式化

前節での一般的なパターン認識手法を用いた際の3つの課題を挙げた。この節ではその課題のうち、フレーム毎に独立して推定するため突発的な誤判定が生じる点についての検証と解決策について述べる。図 3.56 の通り、一般的なパターン認識手法では、フレーム毎に独立して推定を行っている。ドライバの眠気は段階を経て変化していくものであり、処理に関しても段階変化を考慮した手法である必要がある。

そこで、本研究ではこのような眠気レベルの段階的な変化に対応するため、眠気の時系列変化に対する知識ベースをルール化して対応する。まず、眠気レベルが段階的に変化する場合、その変動はどの程度の間隔で生じるかが問題となる。北島らは眠気表情評定値の変動は被験者別に 45 秒～251 秒で生じると報告している[10]。これは変動の最低値は 45 秒であり、フレームにすると 4 フレーム分を意味する。つまり 4 フレーム文を考慮にいれ推定を行うことを知識ベースとして用いることが妥当と言える。このことから推定値の過去 4 フレーム分を考慮に入れてもよいが、誤判定も含まれる推定値をそのまま考慮することになり、より誤判定を増やす結果になり兼ねない。推定値ごとにその信頼度に基づき重みを付ける必要がある。岸本らは AdaBoost の信頼度を利用して推定精度を向上させる手法について提案し、その効果についても検証されている[53]。そこで、本研究でも AdaBoost の信頼度を利用して、精度向上を試みる。過去 4 フレーム分の眠気区間の考慮は、眠気推定区間を  $t$  として、AdaBoost 出力値を  $\alpha$  とし、推定値を  $DL(\text{Drowsiness Level})$  とした場合、以下の式で表すことができる。 $n$  はフレーム数を表す 4 である。

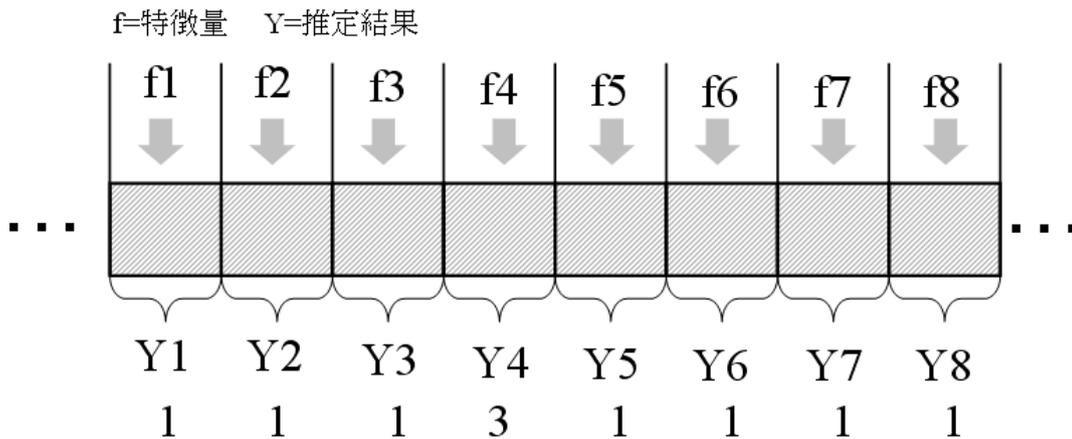


図 3.56 : フレームごとの独立推定

この処理を Expert Model の処理中に入れる. 図 3.57 と図 3.58 は処理適用前と適用後の出力値の変化である. これは眠気レベル(Low Level, Middle Level)(High Level)の2値判別を Expert Model により行ったものである. AdaBoost の出力値は 0 が基準となっており, プラス側だと High Level を表し, マイナス側だと Low Level, Middle Level を表している. 0 に近い程, 信頼度が低いことを表す. フレーム毎に推定を行った場合, 出力値がフレーム毎に基準値 0 をまたぐほど変動しているが, 処理適用後は基準値 0 をまたぐような変動は抑えられている. これにより, 眠気レベル本来の段階的な変化により近くなったと言える.

次に, 実際に大きな変動が抑制されたことにより眠気推定値が正解値に近くなったか検証する. 眠気レベル(Low Level, Middle Level)(High Level)の2値判別を実際に行った際の結果について示す. 図 3.59 は処理適用前の推定結果であり, 正解率は 91.26 %であった. それに対し, 図 3.60 の処理適用後は 94.66 %となっており精度が向上した. この結果より, 眠気の段階変化を考慮は有効であることが分かる. また, 処理適用後は, 眠気レベルの推移区間(High Level と Low Level で正解値が揺らいでいる区間) 以外での誤判定が主に減少していることが分かる. これは眠気への追従性の向上を示しており, 居眠り検知システムとして有効なことを示す結果である.

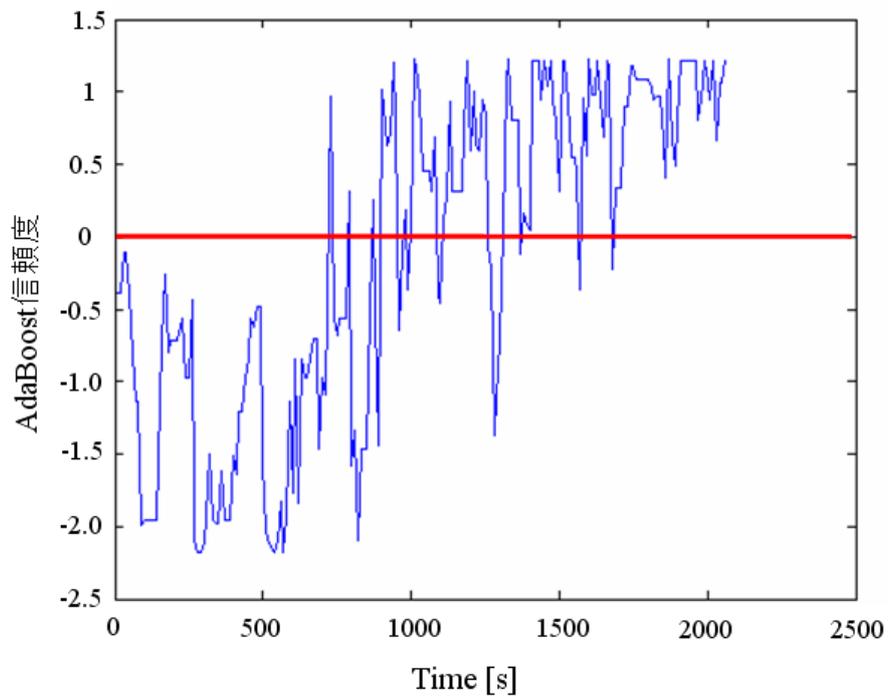


図 3.57 : 処理適用前

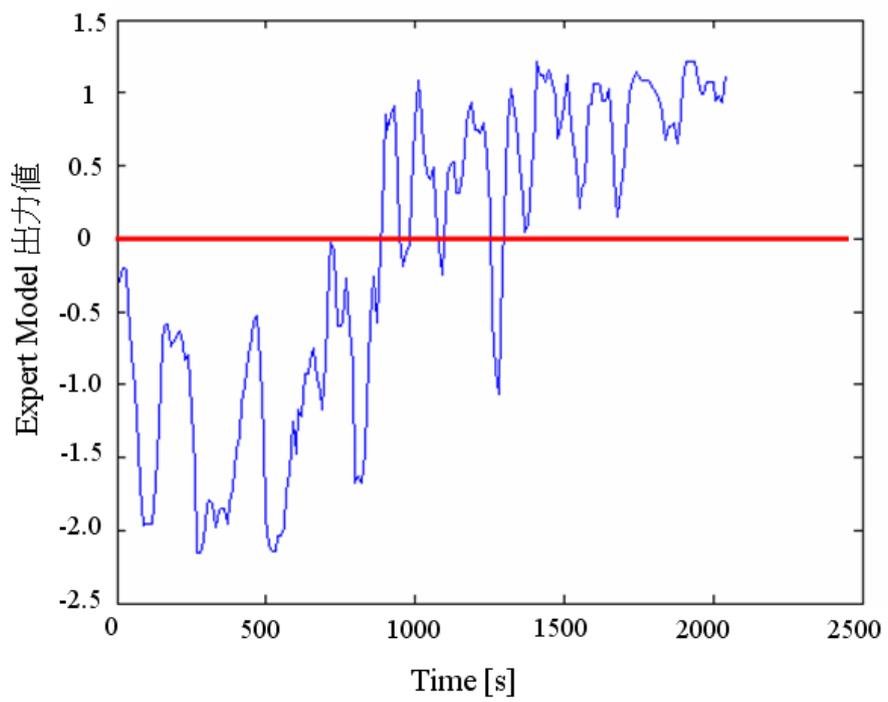


図 3.58 : 処理適用後

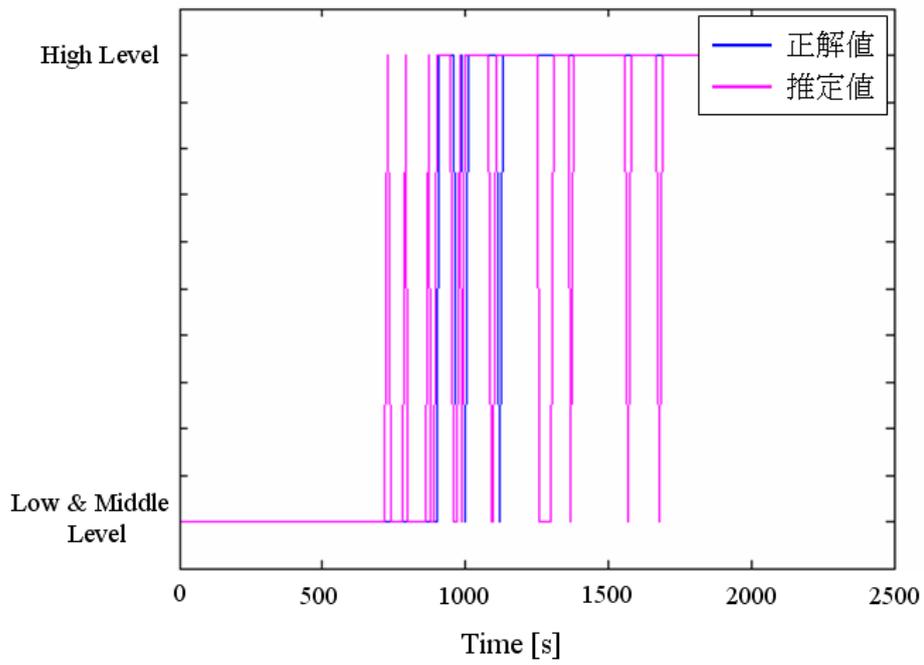


图 3.59 : 处理適用前(推定結果)

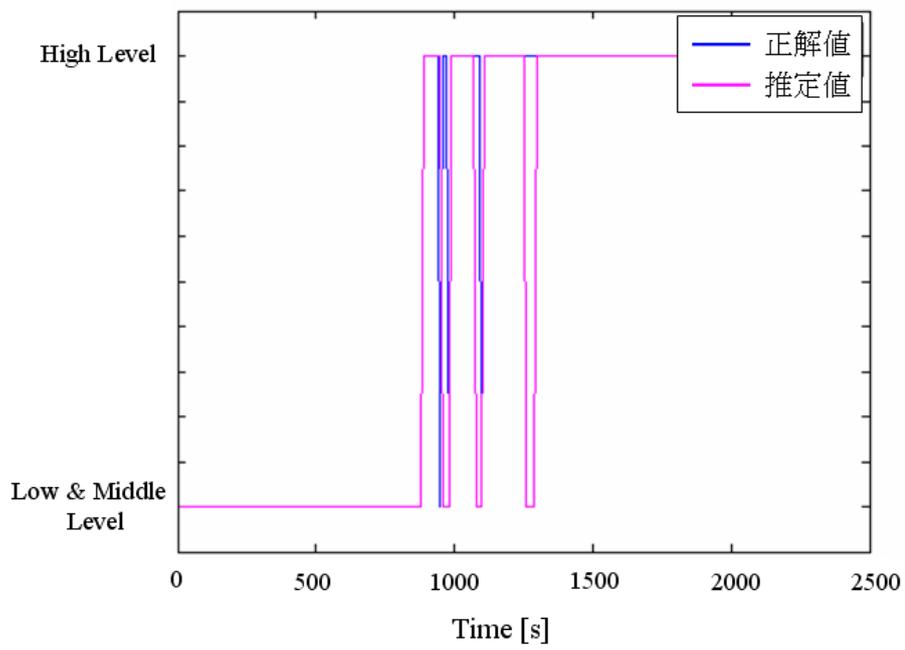


图 3.60 : 处理適用後(推定結果)

### 3.6.5 低信頼度区間検知にも同区推定値補正

前小節では、眠気の段階変化を考慮するため推定信頼度を重みとした時系列推定の定式化について行った。そして、その処理を2値判別時に加えることで2値判別の精度向上を実現し、提案処理の有効性について確認することができた。しかし、現在の提案手法は2値判別時の推定精度に大きく依存する手法であり、3段階推定を行う際に更なる精度向上を見込むために、ExpertModelでの2値判別後に3値判別での複合的な信頼度を算出し、それを利用することで精度向上を目指す。

前小節の推定信頼度の重みを利用した処理の有効性から、AdaBoostの信頼度は眠気レベル推定において利用価値が高い。そこで、3段階判別時の信頼度を一定の基準により算出し、低信頼度区間の検知を行う。この処理の狙いは推定と同時にその結果が誤判定である可能性を評価し、もし誤判定の可能性がある場合に推定結果に反映することである。無論(1) 正解値は不明である(2) 結果は時系列で推定する、という(1)(2)の前提の元で誤判定検知を行うため100%の検知は不可能である。よって、正解値に対し結果補正を行っても影響を最小限に抑えるよう工夫する必要がある。

3値判別時の信頼度の算出方法について述べる。ExpertModelでの判別時に各判別基準ごとに式3.42を用いCL(ConfidenceLevel)を求め、3段階復号時点でのAdaBoost信頼度を以下の式3.43のように算出する。 $\alpha$ 及び $\beta$ はそれぞれのExpertModelのAdaBoost信頼度である。

$$\text{Confidence Level} = \frac{\sum_{i=0}^{n-1} (\text{Label} \times |\alpha|)_{i-1}}{n} \quad (\text{式 3.42})$$

$$\text{Confidence Level} = \sin (|\text{CL}(\alpha_t)| + |\text{CL}(\beta_t)| - 1) \quad (\text{式 3.43})$$

CLは-1もしくは1の値が算出される。-1の場合が誤判定の可能性のある区間である。推定値補正については、眠気は段階的な変化をすることから低信頼度区間と判定されたものは現区間 $t$ に対し、区間 $t-1$ の推定値に置換する。図3.61は低信頼度検知を実際に適用した例である。被験者平均で誤判定区間に対し70%程度の検知率を得た。

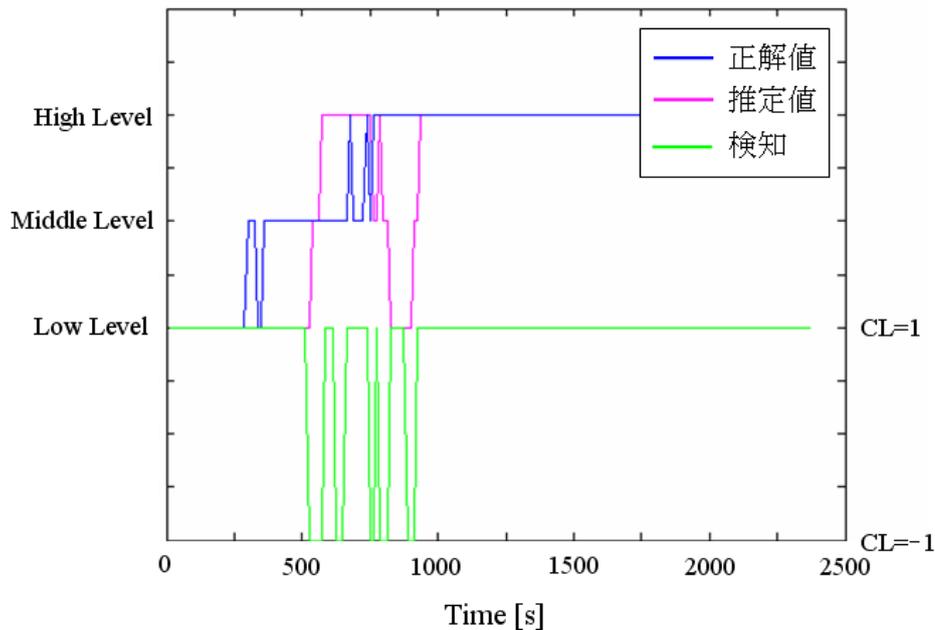


図 3.61：低信頼度検知の適用例

### 3.6.6 提案推定モデルと推定結果

提案手法として、既存のパターン認識手法における改善点と、眠気の段階変化を考慮した手法を提案した。以下の4項目が提案処理である。

- マハラノビス汎距離に基づく重複特徴量検知
- Expert Model による2値判別の最適化
- 眠気の段階変化を考慮し推定信頼度を重みとした時系列推定
- 低信頼度区間検知に基づく推定値補正

上記処理を AdaBoost に組み込んだ。図 3.62 は ExpertModel による2値判別に流れる。図 3.63 は提案手法の全体の流れである。

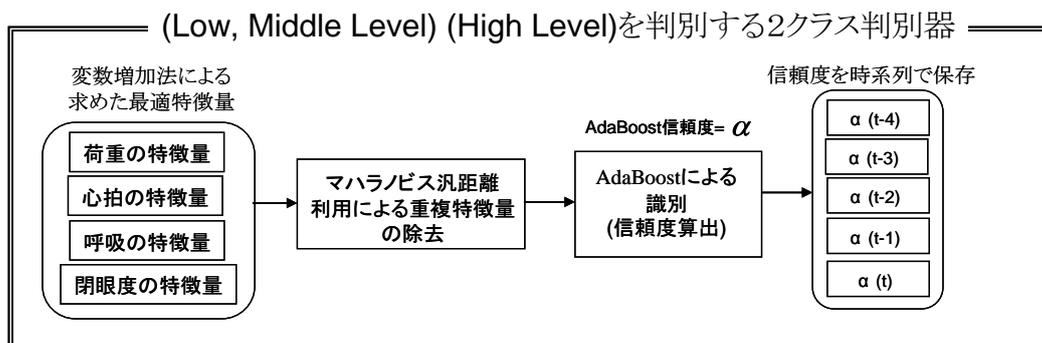


図 3.62：提案モデル(Expert Model)フロー

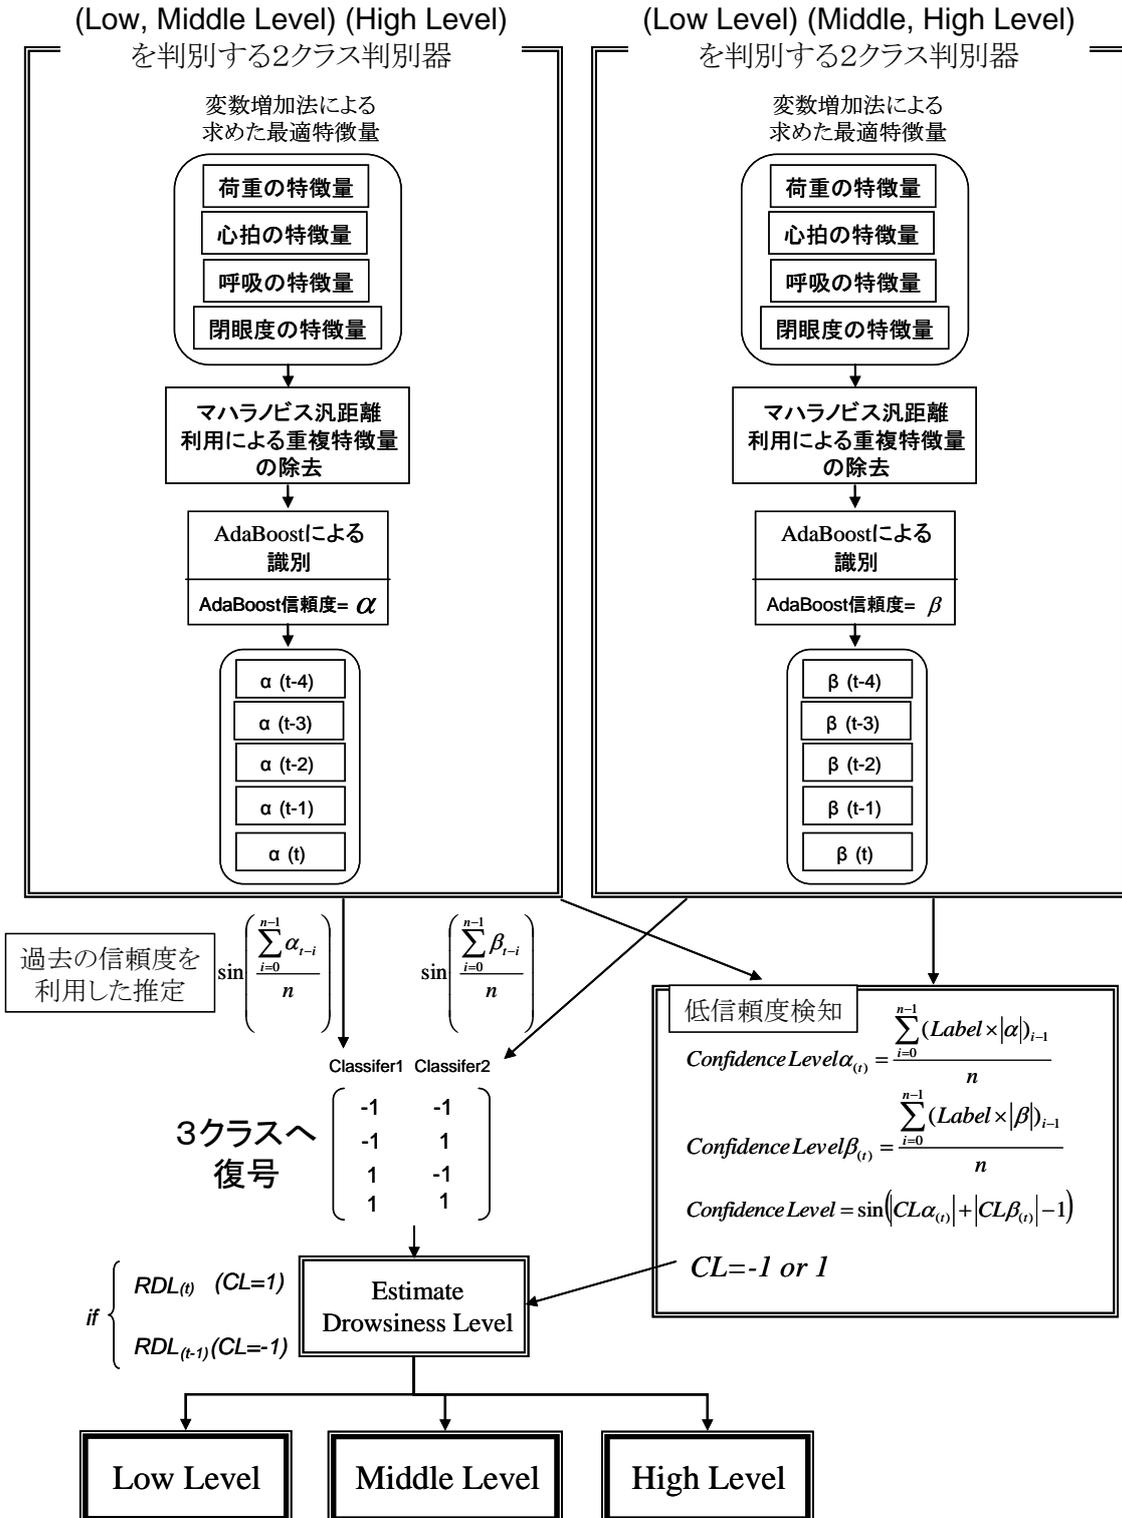


図 3.63 : 提案モデルフロー

提案手法による推定結果について、3.5 節で算出したパターン認識手法との比較を行う。被験者や評価方法などは 3.5 節と同一である。

被験者平均の結果として正解率: 80.01%, 推定誤差 1: 15.93%, 推定誤差 2: 3.89%, 相関値 0.74 となった。いずれの評価指標も他のパターン認識手法を上回る値である。特に推定誤差 2 と最も重要な指標である相関値が良い。相関値に関しては 0.74 の強相関であり、推定値は正解値に対し、追従できていることを示している。推定誤差は 3.89 %であり、2 段階以上の誤判定がほぼ無いと言える。

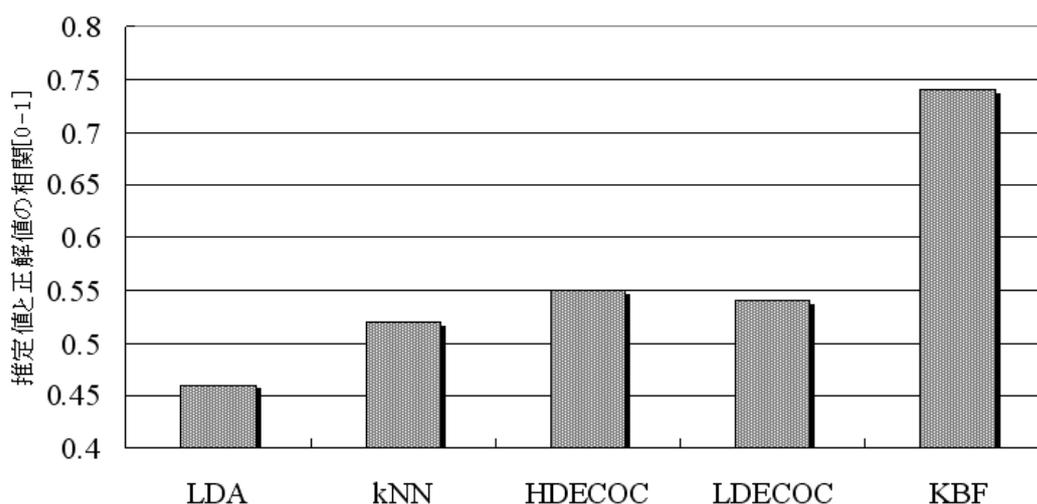


図 3.64 : KBF による推定結果（相関）と他のパターン認識手法との比較

表 3.17 : 提案手法を用いた際の眠気レベル推定結果詳細

	LDA	kNN	HDECOC	LDECOC	KBF
正解率(%)	65.46	77.42	77.44	77.45	80.01
推定誤差 1(%)	19.55	16.09	16.03	16.21	15.93
推定誤差 2(%)	15.00	6.50	6.53	6.30	3.89
相関値[0-1]	0.46	0.52	0.55	0.54	0.74

### 3.6.7 考察

#### 推定値と正解値

覚醒低下の段階変化を考慮した手法を提案し、3段階眠気レベル推定を行った結果として、特に相関が 0.74 と他の手法と比較し、精度を向上を達成した。実際の推定結果の一例を図 3.65, 図 3.66 に示す。図 3.65 は kNN での正解値と推定値を時系列表示したものであり、図 3.66 は、図 3.65 と同一被験者のデータを提案手法により解析した結果である。kNN で多く生じていた 2 段階誤差が抑制されていることが分かる。特に眠気レベルが安定しはじめた区間については推定値に変動は無く、眠気レベルが切り替わる点を的確に捉えていることが分かる。2 段階の誤差の減少については、kNN を含む他の手法で推定誤差 2 が 6.5 % 前後であるのに対し、提案手法では 3.9 % と半分程度に抑制されており、数値上でも減少していることが確認できる。一方で、推定誤差 1 (1 段階誤差) と正解値に関しては、微減、微増と大きな向上はみられないが、精度が悪化していることはない。このことから提案手法においては、2 段階の誤差を的確に抑制することにより、相関を引き上げたと言える。

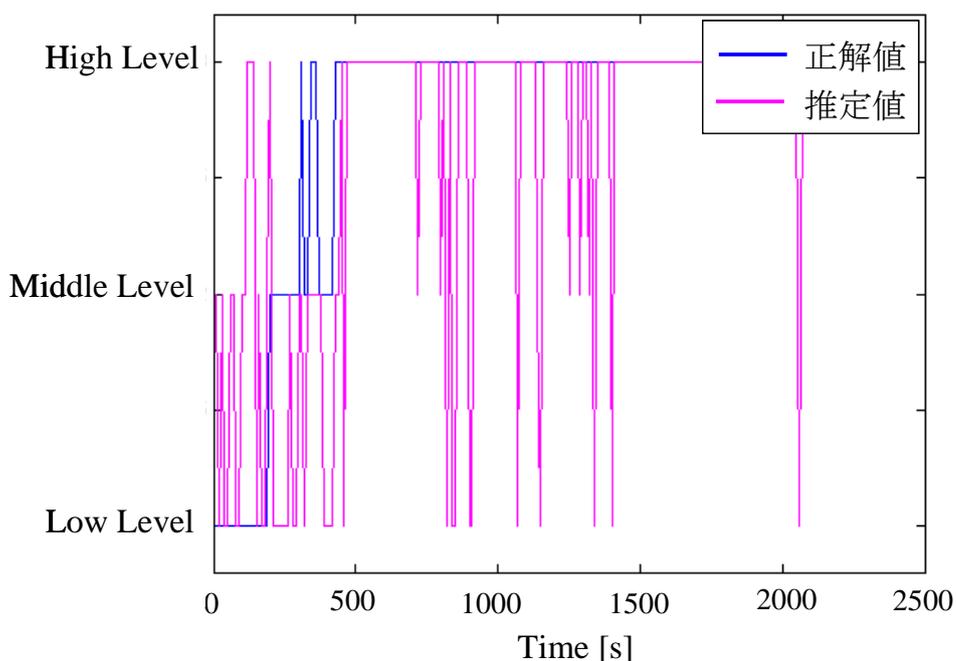


図 3.65 : 低信頼度検知の適用例

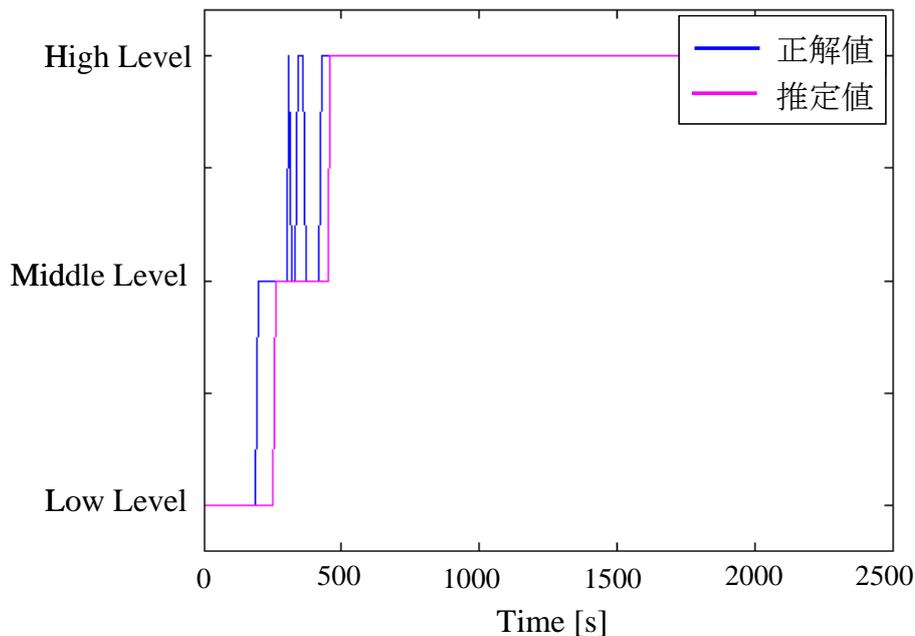


図 3.66 : 低信頼度検知の適用例

### 先行研究との比較

この節では、本研究での提案手法の精度について先行研究と比較する。比較を行う際に注意することとしては、以下のことが挙げられる。

- 正解値（眠気レベル）の定義と段階数
- 推定性能評価方法
- 特徴量抽出に用いる使用機器

まず、正解値の定義については、ドライバの居眠りを検知する研究において標準となる眠気レベルの定義はなされていないため同列に評価することはできない。本研究では正解値に顔表情評定値を用いており、その理由としては顔表情評定値の信頼性について述べている論文があるためである[39]。しかし、他の研究グループではランダムなタイミングで光る LED 照明に、気付いた時点でボタンを押すよう指示しその反応時間を計測したものを正解値とするものもある。よって、正解値が研究ごとに異なる点は考慮しなければならない。

次に性能評価方法に関してだが、これには二種類の注意点がある。一つ目は、推定を行う際の学習・評価方法である。これは評価を行う際に学習データに同一被験者のデータを含むか否かといった点である。多くの研究では、学習データに同一被験者のデータを含む方法で評価を行っており、本研究で検討してきた学習データに同一被験者を含

まない評価(被験者外評価)と同列に比較することができない。この点も学習方法を変え比較する必要がある。

二つ目は評価指標である。これは最終的な評価に正解率か相関などどのような指標を用いているかという点である。この点についても合わせる必要がある。最後に特徴量抽出に用いる使用機器に関してだが、これは推定を行うための特徴量(脳波、心拍、呼吸、瞼開閉情報、荷重情報など)の使用数や組合せが異なるという点に注意が必要である。やはり単一センサでの推定よりも複数センサを用いた場合の方が当然のことながら精度は向上する。

本節では、上記3点を先行研究に対しできる範囲で合わせ推定を行い比較を行う。比較に用いる先行研究はPaiら[3]とtsuchidaら[4]と沼田ら[10]の3つの先行研究である。これら3つは世界的にみても高精度で眠気を推定している研究グループである。以下、表3.18は結果の比較を表にまとめたものである。表中の右欄は本提案手法での精度である。全ての先行研究を上回る精度で推定できていることが分かる。これは本研究で提案した覚醒低下の段階変化を考慮した手法の有効性を示すものである。また、評価方法に関して、他の先行研究では全て個人内評価であるところ、本研究では常時被験者外評価を行ってきた。実際にシステムとなるとときには被験者外評価は当然であり、その点で相関0.74を達成している本研究は、他の研究と比べ高精度で眠気レベルを推定していることを示す。

表 3.18 : 先行研究との推定精度比較

	正解値 定義	段階数	使用情報	評価方法	推定値	提案手法
Paiら	反応 課題	2	脳波情報	被験者内	正解率： 85%	正解率： 90%
Tsuchidaら	顔表情 評定値	3	瞼開閉情報 心拍情報	被験者内	正解率： 75% 相関： 0.56	正解率： 82% 相関：0.8
沼田ら	顔表情 評定値	5	脳波情報 瞼開閉情報 心拍情報	被験者内	相関： 0.69	相関： 0.74

### 3.7 ドライバの眠気レベル推定まとめ

本研究における居眠り運転状態推定では、ドライバの眠気の進行度を瞼開閉情報、心拍情報、呼吸情報、座面圧力情報を入力情報として Low Level, Middle Level, High Level の 3 つのレベルへの判別を行った。推定を行う際の課題は、ドライバの意識的な動きや生体信号のゆらぎにより、3 つのレベルを常時明確に判別できる特徴量が存在しないことである。先行研究において発見されている特徴量は、数十分から数時間の長時間に渡る眠気の変動を、“大まか”に追従するものである。本研究のような眠気レベルの判別を目的とした研究ではレベルの切り替わりを”明確”に捉える必要がある。そこで、本研究では、下記に示す課題に対し、それぞれを解決する手法を提案した。

課題 1 : Low Level, Middle Level, High Level の 3 つのレベルを明確に判別できる特徴量が存在しないことによる誤判定

解決策 : 1 つの判別器による 3 レベル同時判別を取りやめ、Low Level, Middle Level 以上を判別する判別器と、High Level, Middle Level 以下を判別する判別器の 2 つを用意し、それぞれの判別器に対して最適な特徴量を入力する段階的な判別を実施

課題 2 : 生体信号のゆらぎ、眠気以外の要因による生体信号への影響から、特徴量に多くのはずれ値が発生することによる誤判定

解決策 : 推定区間(10 秒間)に依存した推定を取りやめ、過去の推定結果を考慮した推定を実施

(解決策についての詳細は 3.6 章に記述)

更にこれらの解決策は、一般的に下記の条件での多値判別問題において有効であり、他分野においても活用可能である。

条件 1 : 目的とする多クラス判別の判別基準を同時に満たす特徴量は存在しないが、特定のクラスの単独判別であれば、有効な特徴量が存在する場合

条件 2 : 入力特徴量を時系列に並べた場合、細かな変動(ゆらぎ)が存在する場合

## 第4章 ドライバの運転姿勢推定アルゴリズムの開発

本章では、ドライバの体圧変化情報から運転姿勢を推定するアルゴリズムの提案を行う。4.1節では、推定する姿勢を決めるための、公道での危険運転姿勢調査について述べ、4.2節以降ではアルゴリズムの提案について記述する。

### 4.1 公道での運転姿勢推定実態調査

#### 4.1.1 運転姿勢推定の調査方法

調査方法は公道にて、ドライバの姿勢を観測することによって運転姿勢にはどのような状態があるのかを知ることを目的として実施する。ある特定の人を観測してしまうと個人差による影響が反映されることも考えられるので、不特定多数を対象とする。

ビデオカメラを道路情報に設置し、2車線分を撮影する。撮影時間は2008年10月8日(水)の午前8時から9時の1時間である。朝のラッシュに相当する時間であるため単位時間内の交通量が多く、一度に多くのデータが集まるのでこの時間帯とした。撮影場所は長久手アピタと杵ヶ池公園駅の連絡通路である。観測の様子を図4.1と図4.2に示す。連絡通路であるので道路の真上にビデオカメラを設置できるため撮影に適している。

次にドライバの姿勢の分類方法について説明する。分類方法をフローチャートにしたものを図4.3に示す。撮影した動画を静止画に変換する。これは動画より静止画を自分のタイミングで進めて解析した方が効率がよいためである。そして、一台一台のドライバの姿勢を確認していくという方法で進めていった。



図 4.1 : 観測状況 (駅構内の渡り廊下より, ビデオカメラで公道を撮影)



図 4.2 : 観測画像の例

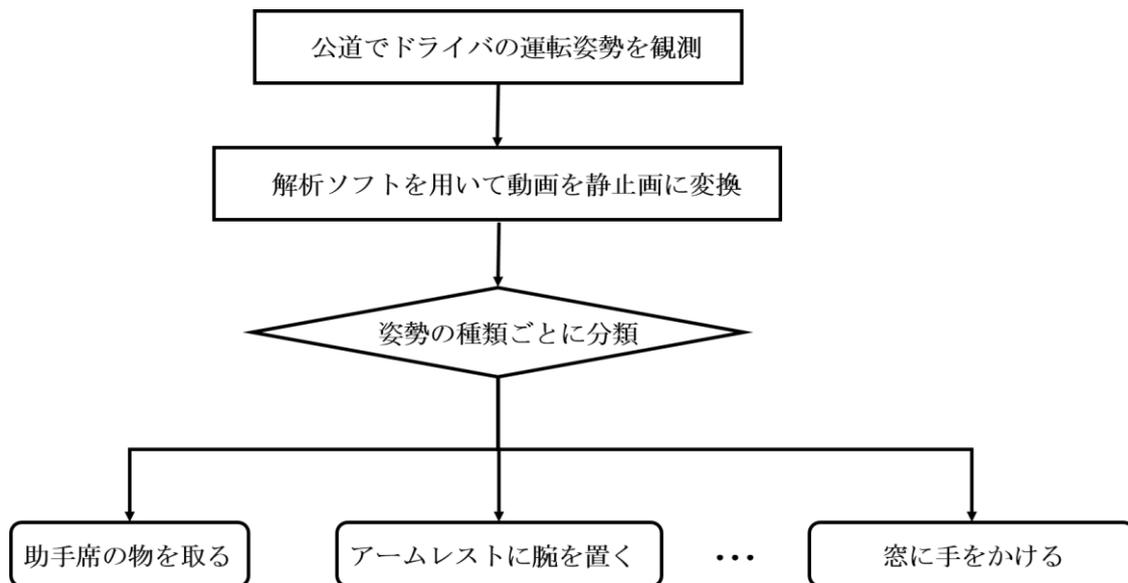


図 4.3 : 調査方法のフローチャート

#### 4. 1. 2 調査結果

結果は通貨車両台数の内から、車内のドライバの動作が認識できるものと認識できないものに分け、認識できるもののうちから導いた割合である。ここでいう認識できないとは光がフロントガラス反射しドライバの状態が見えなかったものや、速度が速すぎて見えなかったもののことである。

通過車両台数は、1187 台でそのうち動作を認識ができたものが915 台、動作を認識ができなかったものが272 台であった。動作を認識ができたものの中で基本姿勢、片手運転、その他の3 つに分類した割合を出したものを表4.1 と図4.4 に示す。基本姿勢での運転が全体の7 割近くを占め、片手運転が3 割を占める結果となった。次に、3 割を占める片手運転の詳細な分類結果について表4.1 と図4.5 に示す。この分類により、運転中にドライバがどのような姿勢をとっているかを知ることができる。片手運転の中で、そのほとんどがアームレストに左手を置き、右手で運転するというものであった。また、次いで頭部を触る動作、コンパネ・ギア操作が多かった。危険運転を予兆するものとして考えていた助手席の物を取る、ケータイでの電話・メールなどは意外と少なかった。しかし、1 時間の観測で少数ではあるが存在したので日常的に行われている行動であると考えて良いだろう。

次に、その他と分類した動作について説明する。これは基本姿勢でもなく、また片手

運転でもないもので危険運転と考えられると判断した動作である。今回の観測では風景を眺める10台、前かがみ3台、両手離し1台という結果で、極少数ではあるが観測された。

調査結果をまとめると、基本姿勢以外で運転しているドライバは3割を占めている。これは、実際のドライバの中で、運転に集中している人が如何に少ないかを表している。危険な動作を行うために基本姿勢を崩しているのではなく、楽な姿勢で運転をすることを目的としているものも多いが、ドライバに運転以外の行為をさせないように集中して運転させるために、姿勢を推定することは重要だと考えられる。

表 4.1：動作分類

挙動の種類	数(台)
アームレストに手を置く	177
頭部を触る	36
膝に手を置く	13
窓に手をかける	17
コンパネ・ギア操作	27
ケータイ操作	1
助手席から物を取る	7
飲食をする	2
助手席に手を伸ばす	1

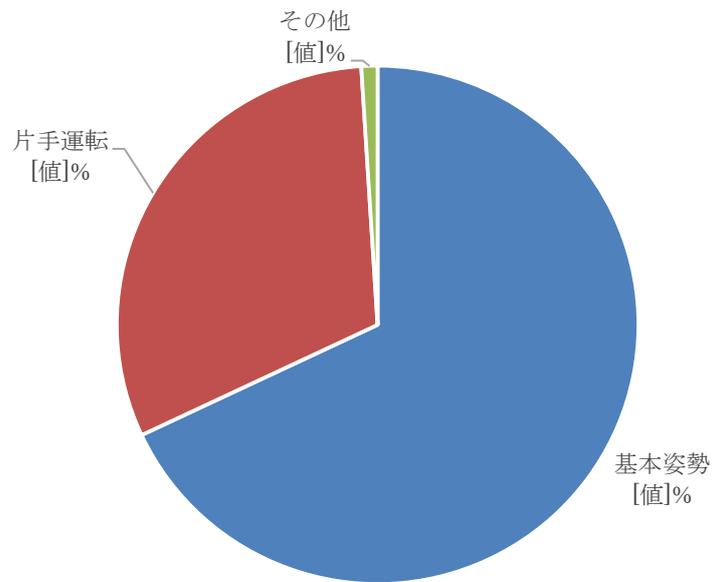


図 4.4 : 動作分類の割合

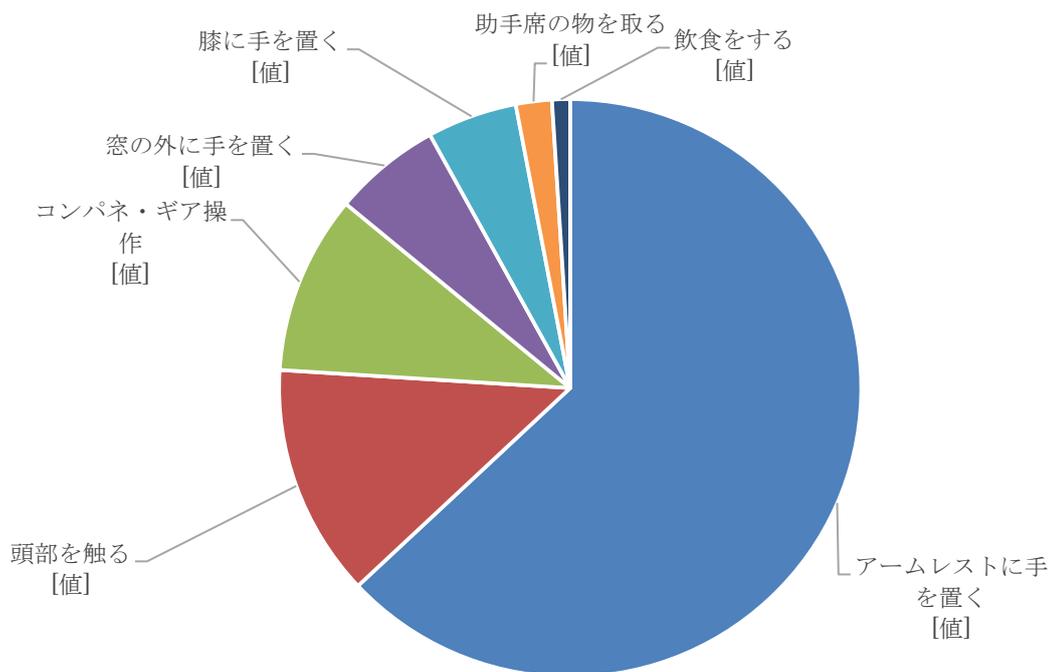


図 4.5 : 片手運転動作分類

## 4.2 運転姿勢変化によるドライバのパフォーマンス評価

### 4.2.1 評価の目的

前節での調査により、公道では基本姿勢以外で運転しているドライバが多くいることが判明した。本節では、基本姿勢以外の動作で運転した場合、どの程度運転技術が低下するかを評価する。その結果からドライバの姿勢推定が重要であることを検証することを目的とする。

### 4.2.2 ドライビングシミュレータを用いた実験方法

実験には、仮想的な自動車走行環境を再現し模擬運転をするための実験機器であるドライビングシミュレータを用いた。ドライビングシミュレータでの実験は実車での実験と異なり、事故を起こすことがないため危険を伴わない。また、実験条件の再現性に優れているため、同一の走行状況を繰り返し多数の被験者に対して実験できる特徴がある。これらの利点を生かし、まだ未開発の装置やシステムを仮想的に作り上げ、それらの事前評価を行うために広く利用されているものである。これらより本研究のようなドライバのパフォーマンスを低下させるような実験には非常に適したものである。本実験で用いるドライビングシミュレータは3.5.1節で用いたものと同じものを用いる。このドライビングシミュレータは自車以外に先行車など他の車両も同時に走行させることが可能である。自車以外の車両はコンピュータで制御でき、先行車を用いる実験では、実験条件に合わせ細かな制御をすることができる。ドライビングシミュレータからは実験毎に被験者の走行データを取得することもできる。取得できる走行データは走行速度・加速度・車線逸脱量・ペダルストローク量・ハンドル切り角などがあり、先行車を走らせている場合には先行車の走行データも取得可能である。

本研究で行うドライバのパフォーマンス評価は、上記に示すドライビングシミュレータから取得できるデータと、3.5.1節で紹介したfaceLABシステムから取得できる頭部移動量、視線移動量のデータを用いて、通常運転時と危険運転時でのデータの差を比較することで評価する。

次に具体的な実験方法について述べる。運転姿勢の変化によるドライバのワークパフォーマンスを評価するため、実験では先行研究[12]で姿勢推定が行われた4つの動作をドライビングシミュレータ運転中に行い、そのときの走行データ・視線情報からワークパフォーマンスの変化を評価した。実験の流れを示したフローチャートを図4.5に示す。実験は実験1・実験2の2つの実験を行った。実験1の影響を排除するため間に休憩をいれている。実験1・実験2ともに走行コースを先行車に追従する形で走行し、走行中にこちらから合図に従い指定した動作を行ってもらおうという流れで進めていく。

\* ランダムなタイミングでブレーキをかける先行車を追従

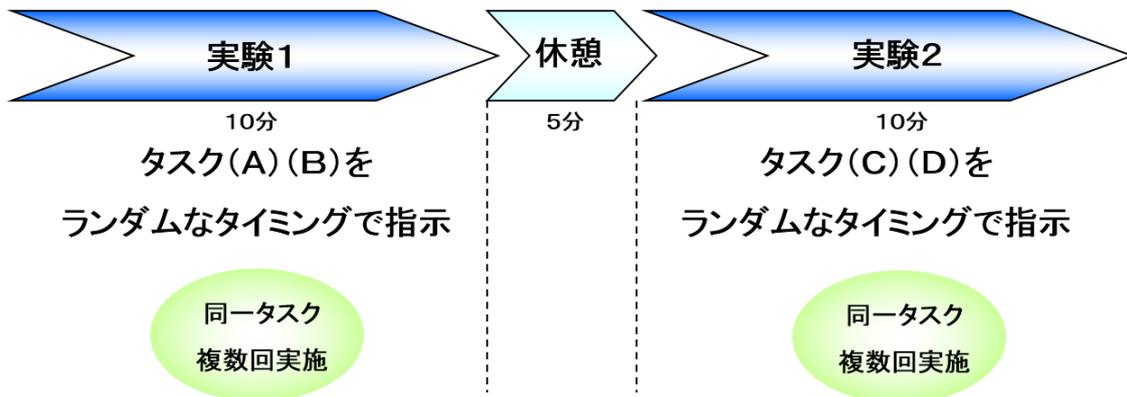


図 4.5 : 片手運転動作分類

以下から走行コースや行う動作についての詳細を述べる。

#### 走行コース・走行条件

実験に用いたコースは、タスクによる影響を評価するためコーナーが無く見通しが良い直線コースを用いて行った。プロジェクターに投影されたコースを図4.6 に示す。先行車は基本的には速度60[km/h] を維持し走行しているが、ランダムなタイミングで減速する。よって被験者も追従する際、その減速に合わせ車間を保つよう走行する。一定の車間を保たせるためにコースには30[m] 毎に線(車間維持線) がひいてあり、その線の間隔を守り走行することも実験の条件とした。



図 4.6 : 運転パフォーマンスに用いた走行コース

### 実験に用いた動作

実験に用いた4つの動作を以下に示す.

- A. 助手席に物を取る動作
- B. スイッチを操作する動作
- C. 後部座席の物を取る動作
- D. 足元の物を取る動作

これらの動作を以後、タスク(A)・タスク(B)・タスク(C)・タスク(D)と呼ぶこととする. 実験中は、当該個所に物を置いておき、それに手を触れハンドルに手を戻すまでを1動作とした. この動作は、実験中に被験者に口頭で合図し行ってもらった. 合図は完全に言い終わるのを待ってから指定された動作を行うよう指示している.

### 被験者

被験者は普通免許を所持している健常成人男女5名で実施した.

## 4. 2. 3 ワークパフォーマンス評価方法

ワークパフォーマンス評価を行う評価基準は、ハンドル操作を重要視した以下の4点についてである.

- 被験者による自己評価
- 最大車線逸脱量
- ふらつき量の標準偏差
- 視線移動範囲変化量

タスクを行うために一時的に片手運転となるためハンドル操作に注目し最大車線逸脱量・ふらつき量の標準偏差を評価項目とした. また、タスクを行う際、対象物に注視点がずれる可能性があることから視線移動範囲の変化量を評価対象とした. さらに、被験者にタスク毎の難易度を5段階で自己申告してもらった.

### 被験者による自己評価

被験者には、タスク毎にそのタスクの難しく感じた点について述べてもらった. そして1 から5 段階にそれぞれ評価してもらった. ここでは運転歴・運転頻度についてもアンケートを行っている.

### 最大車線逸脱量

最大車線逸脱量はタスク実行中に最も車線の中心線からずれた量である. ここでいう中心線とは、走行車線の中心であり図4.6 の点線に当てはまる. ドライビングシミュレータであるが故に、メートルやセンチ単位に直すことはできないが、通常時と比べ何

割増加したかという増減で評価する。

### ふらつき量の標準偏差

ふらつき量は車両センターラインからのずれ量であり、タスク実行中を含む15秒間の標準偏差と定義している(図4.7)。タスク実行時間が平均して5秒程度であることから、その前後5秒を含め15秒とした。

### 視線移動範囲変化量

視線移動範囲はタスク実行中(約5秒間)の前後5秒を含めた15秒間の視線移動範囲を表す。図4.8はタスク実行中と通常時の視線移動範囲の違いを表した一例である。青が通常時、赤がタスク負荷時である。視線移動範囲は視線の横軸の最大値と縦軸の最大値を掛け合わせた範囲と定義する。視線移動範囲変化量はタスクを負荷していない通常時を1としたとき、通常時と比べ何割増加したかを表したものである。

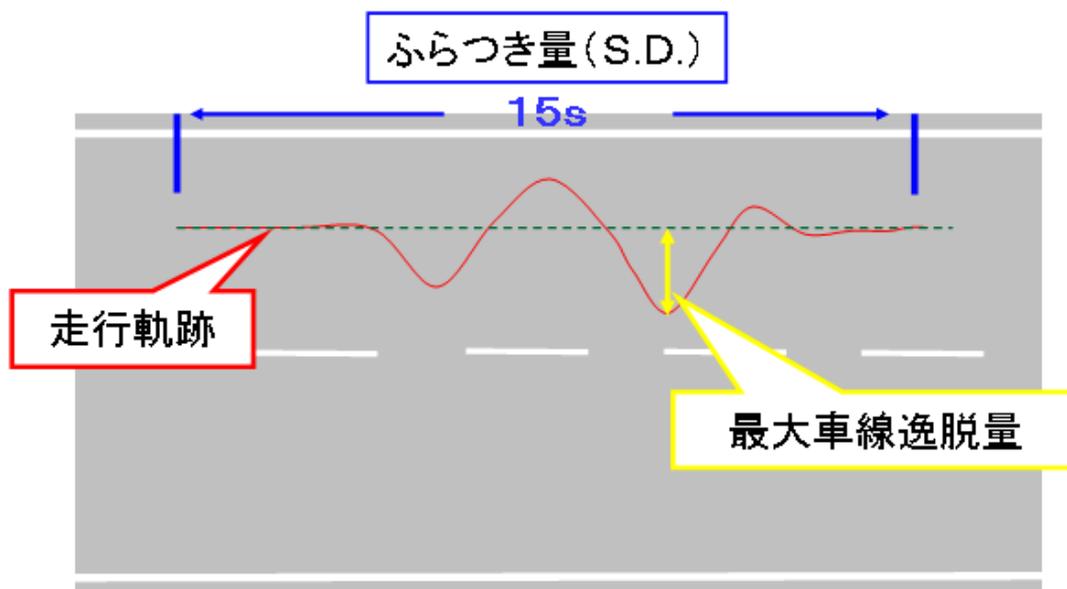


図 4.7 : 最大車線逸脱量・ふらつき量の定義

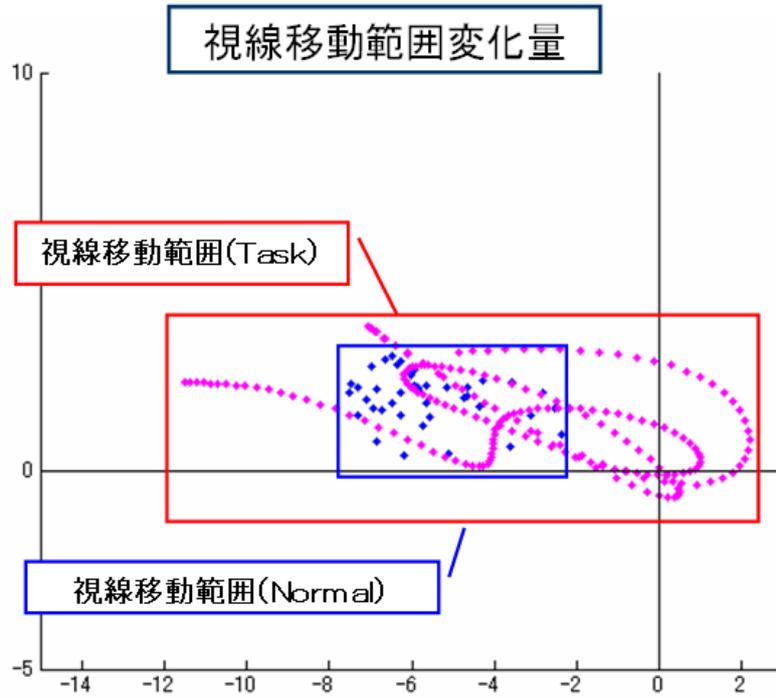


図 4.8 : 視線移動範囲の変化量の定義

表 4.2 : 各タスクの自己評価

	タスク(A)	タスク(B)	タスク(C)	タスク(D)
Sub 1	2	1	5	4
Sub 2	2	1	3	5
Sub 3	3	3	5	5
Sub 4	2	2	4	5
Sub 5	3	2	5	4

表 4.3 : 自己評価の難易度順 (難易度高 : 1 → 難易度低 : 4)

	1	2	3	4
Sub 1	タスク(C)	タスク(D)	タスク(A)	タスク(B)
Sub 2	タスク(D)	タスク(C)	タスク(A)	タスク(B)
Sub 3	タスク(D)	タスク(C)	タスク(B)	タスク(A)
Sub 4	タスク(D)	タスク(C)	タスク(B)	タスク(A)
Sub 5	タスク(C)	タスク(D)	タスク(B)	タスク(B)

## 4. 2. 4 ワークパフォーマンス評価結果

### 自己評価によるタスク分類

各タスクの5段階の自己評価についての結果を表4.1に示す。数値が高いほどそのタスクを運転中に行うことが困難であったことを表す。自己評価の1から5については明確な定義が無くあくまで被験者の主観で決めてもらったが、ここから各タスクの個人ごとの難易度の順位付けをすることはできる。

自己評価を難易度が高いと感じた順に整列し直すと表4.2のようになる。ここから全ての被験者で難易度が高いと感じたタスクはタスク(C)とタスク(D)、難易度が低いと感じたタスクはタスク(A)とタスク(B)となり難易度により2グループに分類できる。以後、難易度が低いタスクのグループを軽タスク、難易度が高いタスクのグループを重タスクと呼ぶ。この結果から軽タスクと重タスクでは明らかにタスクの負担が異なることから、各指標の評価を行う際に、軽タスクと重タスク別々に評価を行っていく。

### タスク(A)とタスク(B) 評価結果

被験者のタスク毎の難易度自己評価によって軽タスクと分類できたタスク(A)、タスク(B)の結果について示す。この2つのタスクについては基本姿勢から姿勢を大きく崩すこと無く行えるため車両挙動に大きな影響は出ないものと考えられる。しかし、全てのタスクである物を取る動作のために視線を向けるため視線移動に影響が及ぶものと考えられる。タスク(A)・タスク(B)の各評価指標の結果についてふらつき量の標準偏差の結果(図4.9)、最大車線逸脱量の結果(図4.10)、視線移動範囲の変化量(図4.11)に示す。ふらつき量の標準偏差に関しては被験者により結果が異なった。被験者2、被験者4についてはふらつき量の標準偏差が通常時と比べ平均で2.1倍、1.6倍と増加し車両挙動が不安定になっていることが見受けられるが、被験者1、被験者5については平均で0.87倍、0.60倍と減少している。また、被験者3については通常時と平均で1.03倍とほぼ変化が無いという結果となった。ふらつき量の標準偏差にタスクの影響が大きく現れている被験者は5人中2人であり、この評価指標が軽タスクであるタスク(A)、タスク(B)に有効な指標であるとはいえない。

次に、最大車線逸脱量に関しては、被験者5のタスク(A)は通常時と比べ平均で0.87倍減少、また被験者1のタスク(A)で1.03倍の増加とほぼ通常時と変わらない結果であったが、その他は全ての被験者で1.2倍から2.3倍に増加しており、タスク(A)、タスク(B)が最大車線逸脱量に影響を与えたことが伺える。

最後に、視線移動範囲は、被験者ごとに差が大きいため通常時を1とした変化量で増減を表している。被験者2のタスク(B)は通常時と比べ1.2倍と増加率が低いが、その他では1.6倍から8.7倍も視線移動範囲が拡大しており、通常時より明らかに注視点が

ずれていることが分かる。視線移動範囲は車両挙動などと比較すると直接的に事故に繋がるものとは考え難いが、事故を誘発する可能性がある。間接的にはあるが運転パフォーマンスに影響を及ぼすものとして有効な指標と考えられる。

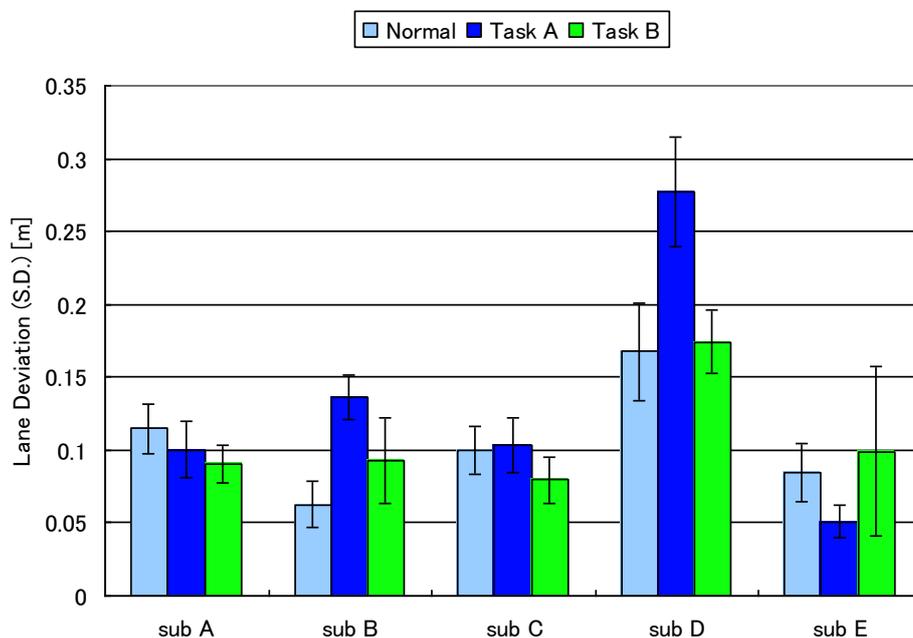


図 4.9 : タスク (A), タスク (B) ぶらつき量の標準偏差

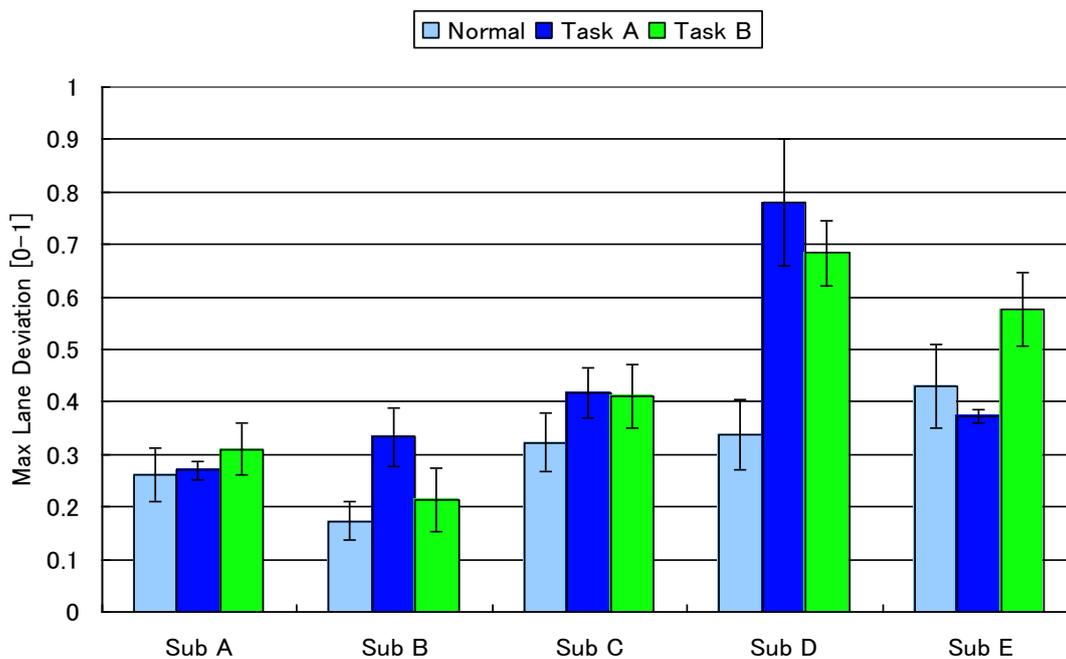


図 4.10 : タスク (A), タスク (B) 最大車線逸脱量

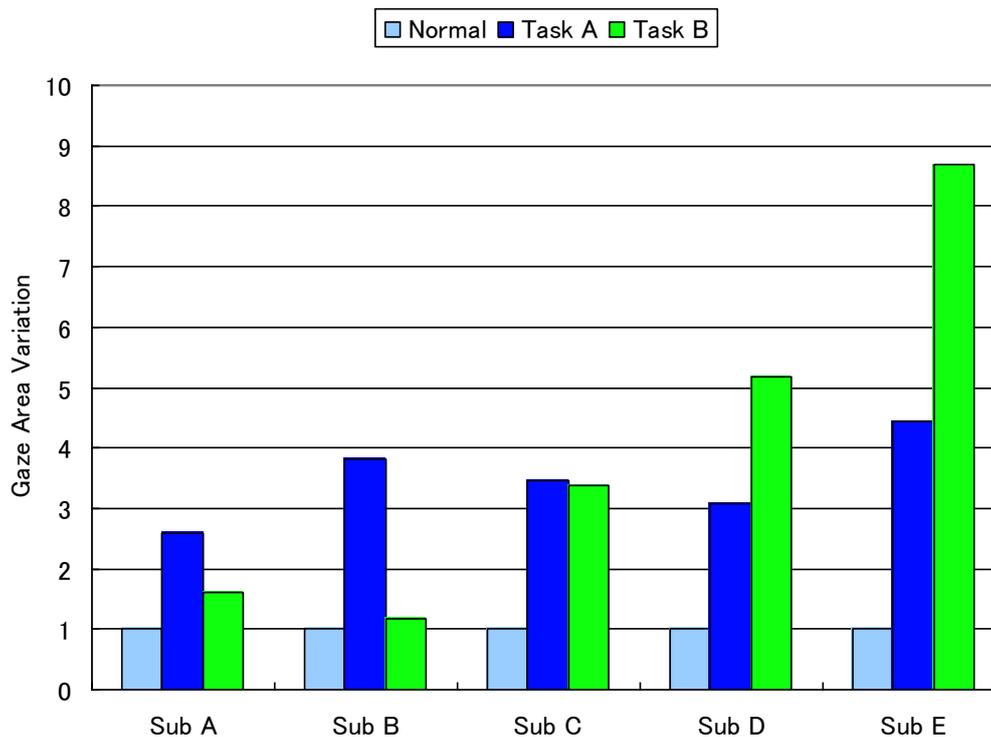


図 4.11 : タスク (A), タスク (B) 視線移動量範囲変化量

### タスク(C)とタスク(D) 評価結果

次に、自己評価で重タスクとして分類されたタスクの実験結果についてだが、姿勢を大きく崩す動作であるため通常時は元より、軽タスクと比べても車両挙動に大きな影響を及ぼすものと考えられる。タスク(C)・タスク(D)の各評価指標の結果についてふらつき量の標準偏差の結果(図4.12)、最大車線逸脱量の結果(図4.13)、視線移動範囲の変化量(図4.14)に示す。

まず、ふらつき量の標準偏差の結果についてだが、タスク(C)で平均で通常時より1.7倍、タスク(D)で2倍程度増加している。車両が通常時よりもふらつくことは、これらのタスクはハンドル操作が煩雑になっていることを示している。タスク(A)、タスク(B)ではふらつき量の標準偏差に関しては傾向としてこれほど大きな変化がみられなかったことから、自己評価で重タスクと分類されたタスクは軽タスクと分類されたタスクに比べワークパフォーマンスが低下することが確認できた。

次に、最大車線逸脱量についてだが、これもふらつき量の標準偏差と同じく全ての被験者で増加傾向がみられた。タスク(C)で平均で1.7倍の増加、タスク(D)で平均で2.2倍の増加である。実験にドライビングシミュレータを用いている為、実車とは厳密には異なるがコースの車線の幅を実路の平均的な走行車線一車線の幅(2.25[m])に当

ではめると、中心線から通常時よりタスク(C) で20[cm] 程度、タスク(D) で30[cm] 程度最大車線逸脱量が増加していることとなる。

最後に視線移動範囲の変化量についてだが、これも通常時と比べ有意な差がみられた。特にタスクC に関しては、通常時の5 倍以上変化する被験者もいる。タスクC は最も姿勢を崩すタスクの為、視線が大きくはずれる傾向にあることが分かる。注視範囲が広がることは注意散漫に繋がる可能性があり、ここからも姿勢を変化させることは事故に繋がる可能性を示唆することができる。

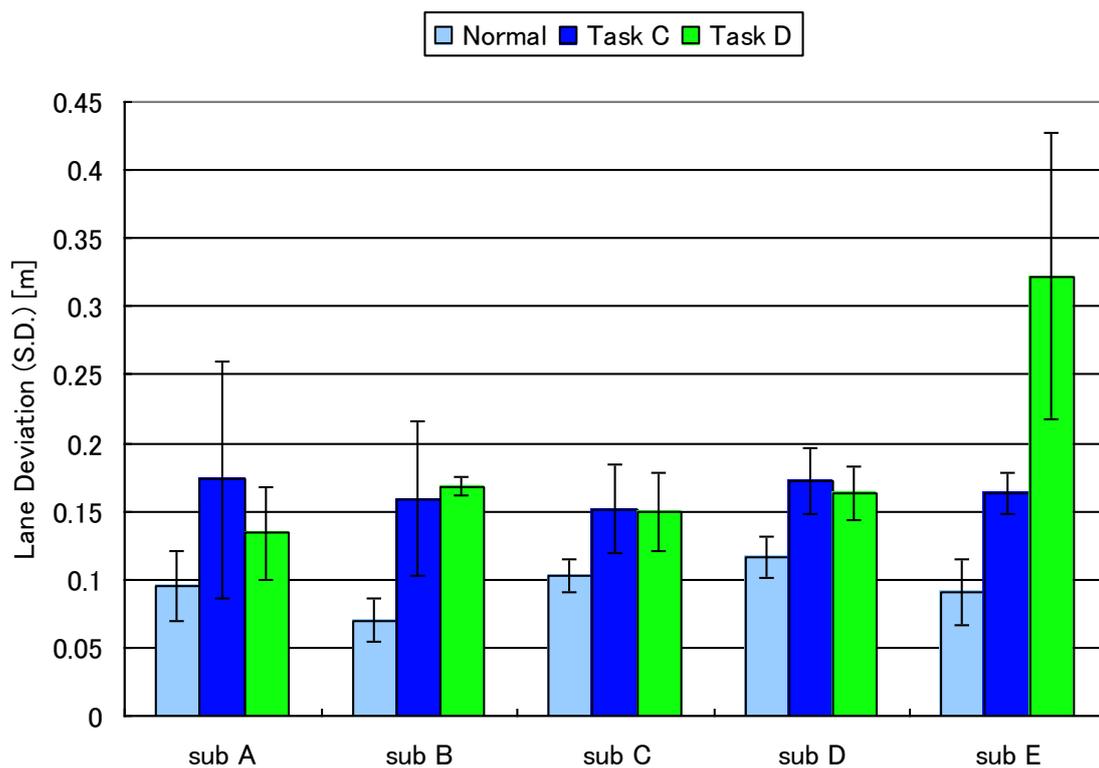


図 4.12 : タスク (C), タスク (D) ふらつき量の標準偏差

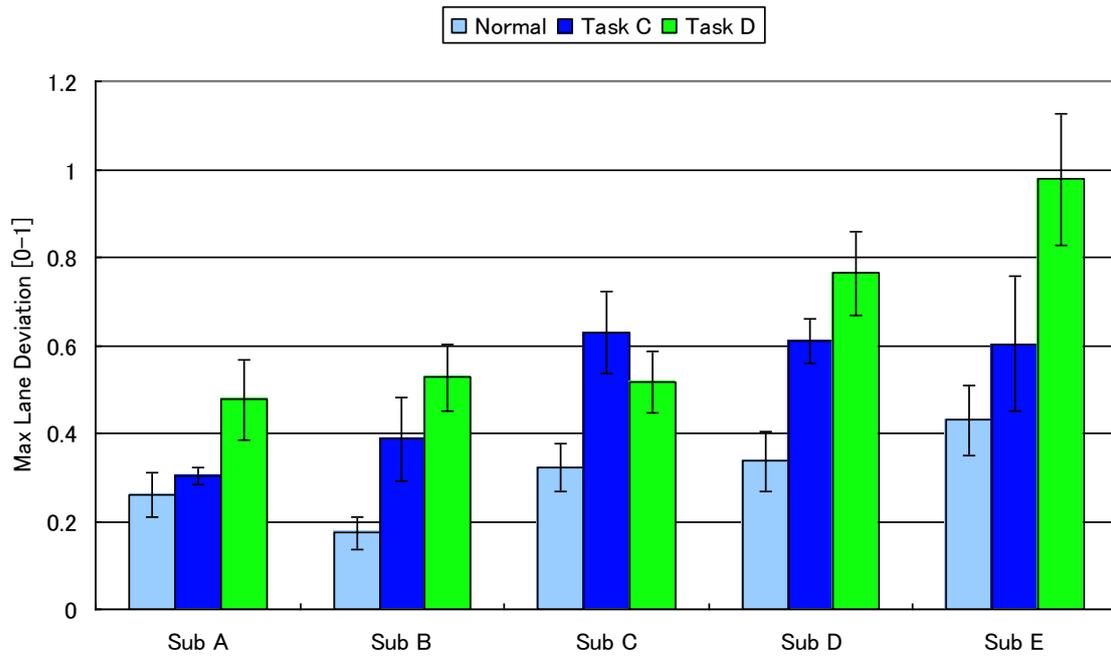


図 4.13 : タスク (C), タスク (D) 最大車線逸脱量

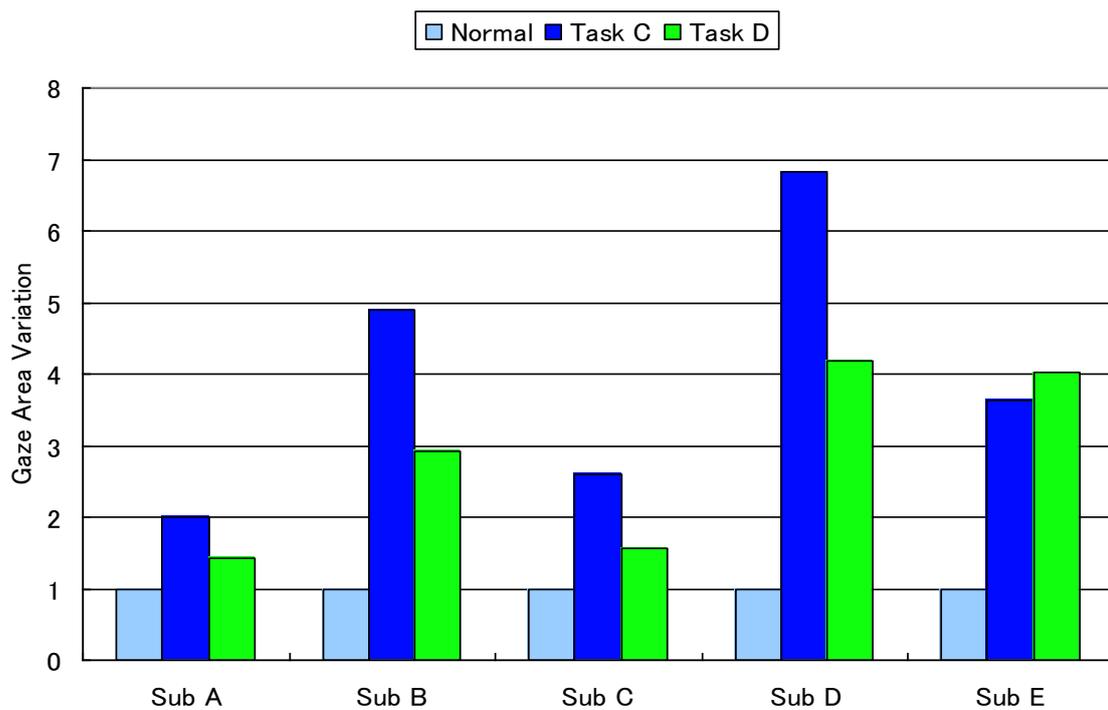


図 4.14 : タスク (C), タスク (D) 視線移動量範囲変化量

ワークパフォーマンスのまとめ結果を表4.4に示す。運転中にこれらの動作を行うことによって、運転操作に大きく影響することが分かった。動作を行うために片手運転になり意識も動作に集中するためハンドル操作が疎かになる。また、注視点もずれてしまう傾向にある。このように運転中に運転以外の動作を行うことは、運転操作の低下が生じる。この動作を早い段階で検知し、注意を促すことができれば事故を未然に防ぐ可能性を見出すことができる。

表 4.4 : 運転姿勢変化によるドライバ公道評価実験結果(単位 : 倍)

	タスク(A)	タスク(B)	タスク(C)	タスク(D)
視線移動範囲変化量	3.5	4	3.9	4
最大車線逸脱量	1.5	1.4	1.7	2.2
ふらつき量	×	×	1.7	2

## 4.3 ドライビングシミュレータによる運転姿勢推定模擬実験

### 4.3.1 推定に用いる体圧計測機器(空気流量センサ)の仕様

運転姿勢推定をするためにシートベルトに取りつけるセンサには、空気流量センサを用いた。空気流量センサとは、図 4.15 に示すようにパット状であり中に空気が入っている。パットに圧力がかかると中の空気が押し出され、その押し出された空気量が波形として生成されるものである。本研究で用いた空気流量センサは、ベッドに組み込まれ、主に医療施設や介護施設などで患者の状態を管理することを目的とし使われているものである。センサは主に体の動きを捉えることができるが、心臓の鼓動や呼吸による肺の活動からくる微量な体動をも検出することが可能であり、心拍数や呼吸数などの情報も得ることができる。センササイズは 50[mm]×100[mm]でありシートベルトの幅とほぼ同じサイズである。空気流量センサからの出力波形は縦軸が[V]、横軸が時間[s]で出力される。サンプリング周波数は 1000[Hz]であり、出力値は定常状態で 3[V]が出力され、0-6[V]の範囲で変動する。空気が流出した場合は プラス(+ )側に、流入した場合はマイナス(-)側に出力値が出力される。dat ファイルとして出力されるのでバイナリから ascii に変換し解析を行った。出力波形の例を図 4.16 に示す。注意すべきは、パットにかかる圧力そのものを波形として生成しているのではないという点である。流れる空気の量を波形として生成しているため、圧力をかけた状態を維持すると空気は流れなくなり波形は生成されない。よって、あくまで圧力ではなく流れる空気流量を波形としているということを常に念頭に置いておく必要がある。この特性から、ドライバが姿勢を変える変化時にのみ波形が生成されることとなり、どの姿勢に変化したかは、初期位置からの姿勢のずれの大小に依存するので姿勢推定に適したセンサと言える。

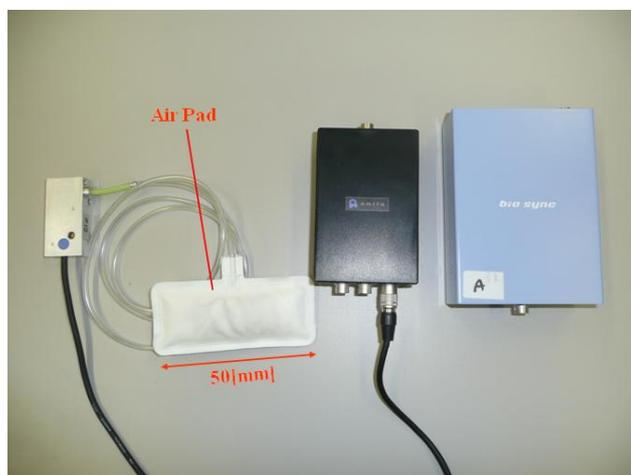


図 4.15：空気流量センサ構成

### 4.3.2 模擬実験方法

ここでは運転姿勢を推定するための実験方法について説明していく。まず、空気流量センサのシートベルト上での取り付け個所であるが、センサ同士は設置個所が離れている方が、類似波形がでにくく好ましい。そこで、普通自動車の3点式シートベルトは2本のベルトで構成されているので、それぞれに1つずつ取り付けることとした。具体的には身体との接触面が最も多いベルト中央部である。図4.16は空気流量センサの設置個所を示したものである。

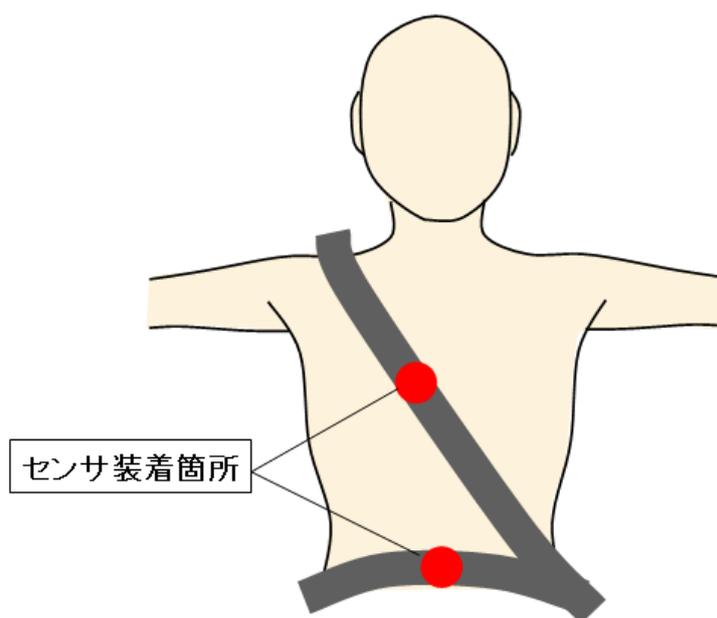


図 4.16 : センサ設置箇所

本研究で、推定する運転姿勢は先行研究[12]で推定が試みられている以下の5つの動作である。各タスクを動作している最中の様子を図4.17に示す。

- A. 助手席に手を伸ばす動作
- B. 座席前方部に手を伸ばす動作
- C. 後部座席に手を伸ばす動作
- D. 運転席足元に手を伸ばす動作
- E. 基本運転姿勢

この動作を行ったときの空気流量センサの出力値に対し識別手法を適用し、動作推定を行う。識別に用いる動作実行時の空気流量センサのデータは図 4.18 のフローチャートに示す順で取得する。被験者には 2 パターンの姿勢推定に用いる空気流量センサのデータ取得実験を行ってもらった。一つ目は、 $4(\text{動作数}) \times 100(\text{回}) \times 2(\text{センサ装着個所})$  の合計 800 回の動作を行ってもらうものである。尚、一人の被験者に対し、一度に 800 回の動作を行ってもらうには疲労による影響も考えられるので 2 度に分けて実験を行った。また、タスク E は基本姿勢を維持するのみであるため、各タスクから基本姿勢に姿勢を変化させた際に同時にデータを取得している。

二つ目は、一つ目の実験の動作を 50 回ずつ行ってもらうものである。一つ目の実験をデータセット 1、二つ目の実験をデータセット 2 と呼ぶこととする。また、実験をはじめる前には、衣服による出力波形変化を抑制するため、被験者の衣服は T シャツでベルト無しの飾りのないズボンとした。さらに、常に同じ動作を行ってもらうよう実験前に次節で説明する正しい運転姿勢に従ってシートポジションを調整してもらった。尚、被験者は男子大学生 7 名（平均年齢 23 歳）である。

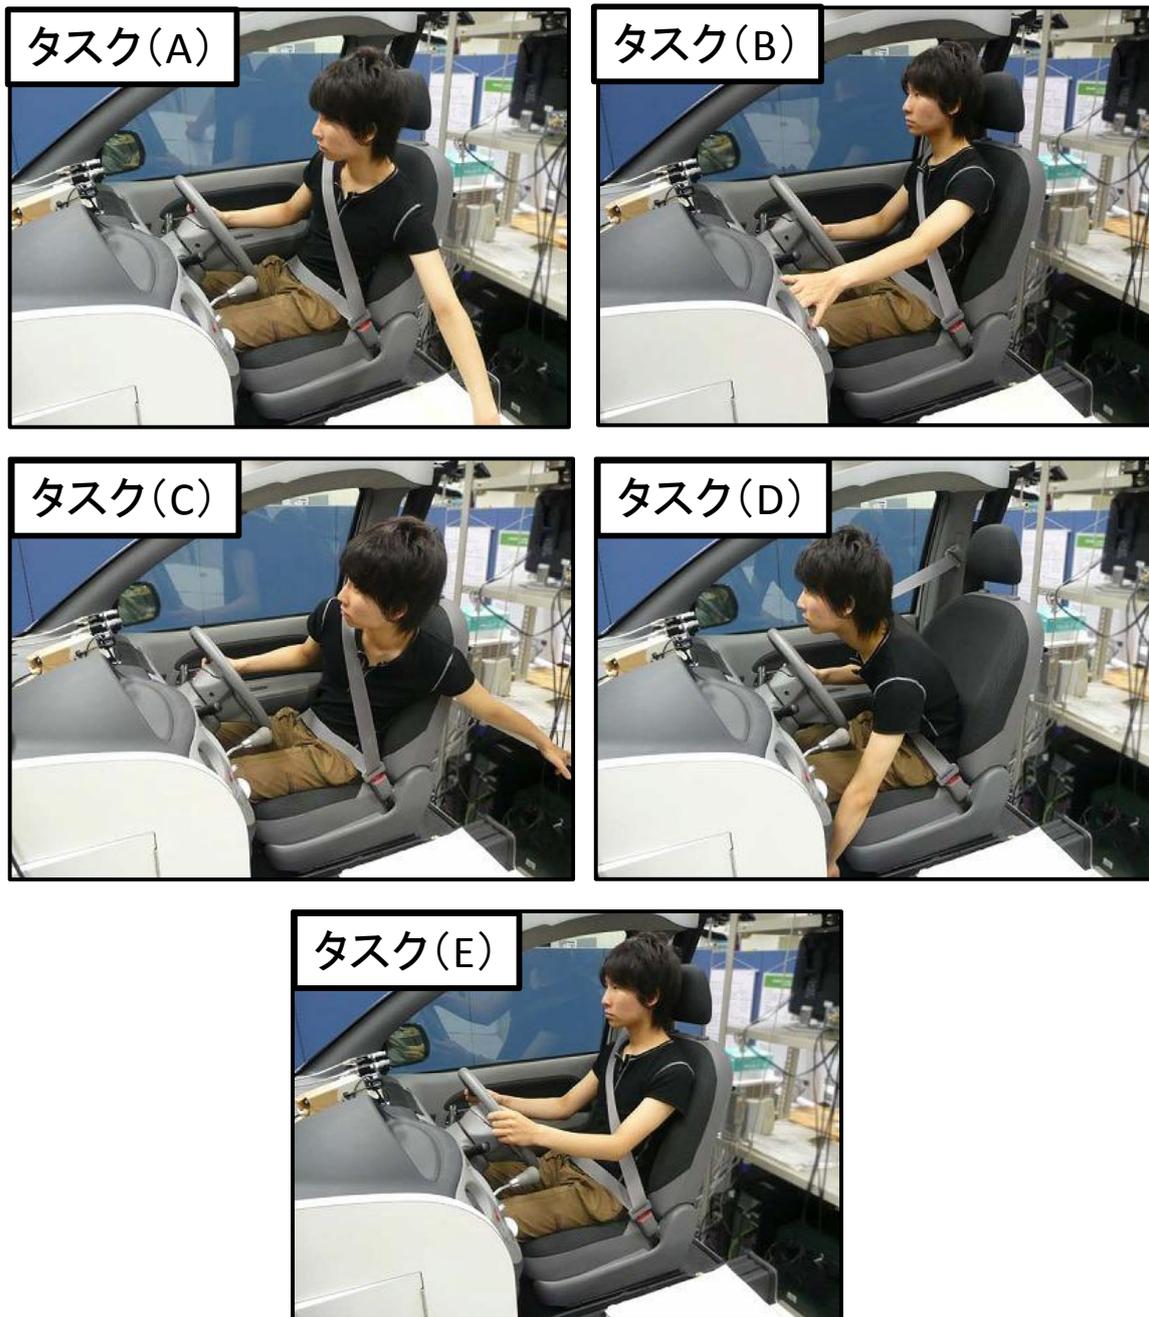


図 4.17 : 各タスク動作中の様子

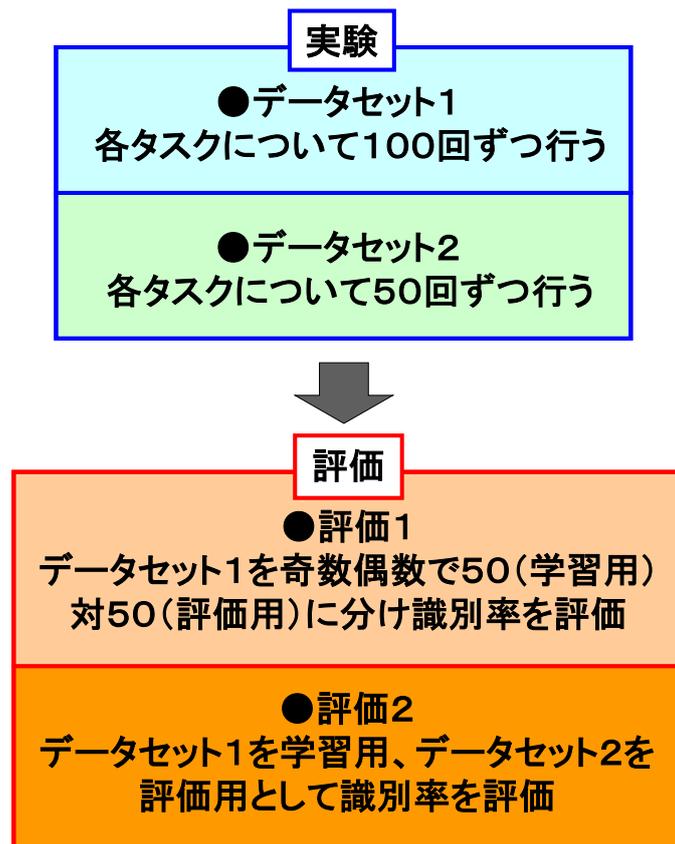


図 4.18 : 実験順序のフローチャート

### 4.3.3 適切な運転姿勢

実験中に被験者に指示する適切な運転姿勢について説明する。適切な運転姿勢を保つためにはシートポジションが重要になってくる。シートポジションが適切でないとハンドルが回せない。ブレーキが踏み込めないという事態が発生する。また、運転姿勢が悪いと咄嗟の反応が遅れる、視線が定まらない等の運転及び安全回避に支障をきたすと考えられる。適切なシートポジションは、個人ごとの体格により異なり、服装によっても変わってくるので運転をする前に、必ず確認し調整する必要がある(図4.19)。

シートは2箇所の調整箇所があり、一つは前後位置、もう一つはシートバック(背もたれ)位置である。

## 前後位置

前後の位置は足の長さで決定する。ブレーキ(マニュアル車ならクラッチ)を深くまで踏み込んだ状態でわずかに膝が曲がる位置を目安にする。

## シートバック (背もたれ) 位置

シートバックの位置は手の長さで決定される。ハンドルの上部を両手で持ったときに両肩がシートバックから離れず、肘がわずかにまがる位置を目安とする。また、このとき背中とシートバックの間に空間ができないようにする。

このルールに従いシートポジションを決める。これはあくまでの目安であり、体をしっかり固定することが重要である。また、ハンドル角も調整可能であるので必要に応じ、シートポジションとのバランスを取る必要がある。この他に運転姿勢を補助する装備の正しい装着方法、位置について説明する。

## シートベルト

シートベルトは衝突時に体が座席から飛び出すことを防ぐものであるが、運転中に体をシートに固定するという役目もある。シートベルトは3点式シートベルトの場合2本のベルトで構成される。上ベルトは肩の鎖骨を通るように、下ベルトはお腹ではなく腰骨にかけるように装着する。

## ミラー

ミラーはルームミラーとサイドミラーの2種類がある。ルームミラーは上記の正しい運転姿勢をとった状態で調整する。目安としてはリアウインドウ全体が見えるように調整する。サイドミラーは車体の一部が映るようにすると位置把握がし易くなる。

この様に正しい運転姿勢をとった状態でミラーやシートベルトを正しく装着することは、運転中に運転姿勢が崩れることを防止する役目も果たしている。もしミラー類が適切な位置に調整されてないとしたら、ドライバはミラーを見るために運転姿勢を崩しミラーを覗き込んだりすることが必要となったり、運転中にミラーを調整し直す必要に迫られる。逆にミラー類が適切な位置に調整されていたとしたら、ドライバは運転姿勢を崩すとミラーが見にくくなるので運転姿勢を維持する。

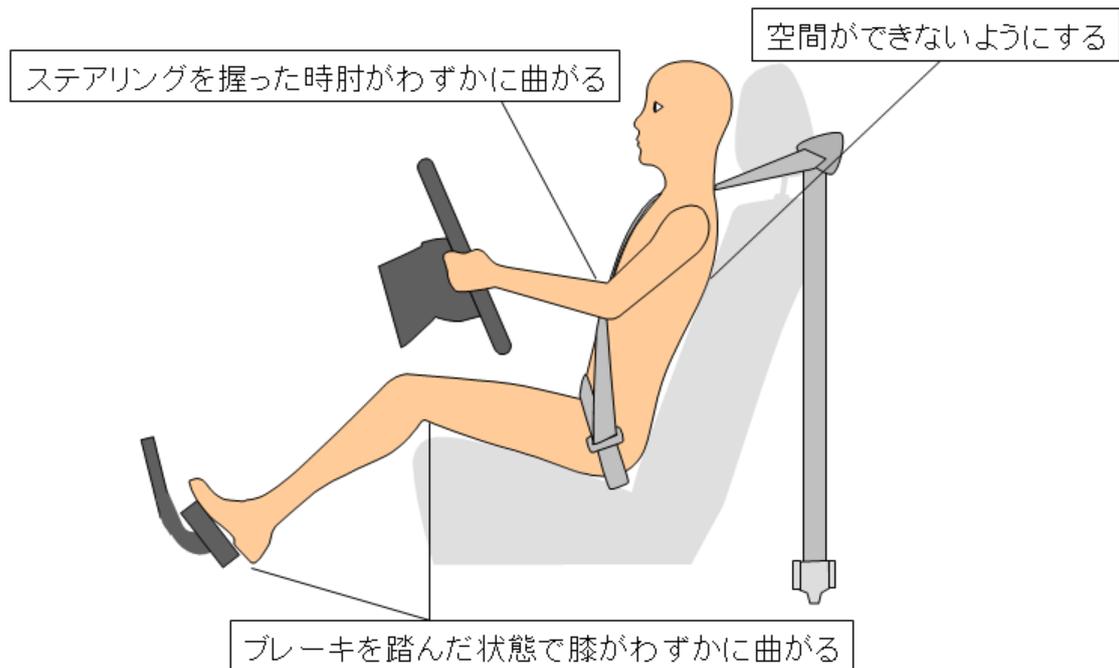


図 4.19：適切な運転姿勢とシートベルト着用法

#### 4.3.4 取得データからの特徴量抽出

##### 前処理

4.3.2節で述べた実験によって取得できる空気流量センサの出力波形は、原波形の状態ではパターン認識手法を適用することはできない。原波形に対し、各タスクを識別するために有効な特徴量を選定し、その形にするために適切な処理を施す必要がある。まず、4つの各タスク実行中の空気流量センサ出力波形をそれぞれ別々に取得しているため、判別を行う前に、判別のための基準を作る必要がある。パターン認識においては、特に多変量解析の前処理として入力データ（ここでは空気流量センサの出力波形）や平均や標準偏差といった代表値で割るなど無次元量化し、互いに比較できるようにするために正規化が行われる。データセット1とデータセット2の平均と標準偏差を一致させるために以下の式を用いて正規化を行った。

$$Z = \frac{X - \mu}{\sigma} \quad (\text{式4.3})$$

$\mu$ はデータセット1の平均、 $\sigma$ はデータセット1の標準偏差である。これを各動作それぞれについて行った。

## 特徴量選定

ここでは学習データおよび検証データに用いた特徴量について説明する。特徴量には、空気流量センサからの出力値をそのままの形で使用するのではなく波形の中で、識別に適している特徴を抽出し使用した。結論から述べるとタスク実行中の空気流量波形の中から以下の4つの特徴量を抽出し使用した。

- タスク実行中の空気流量波形の最大値
- タスク実行中の空気流量波形の最小値
- タスク実行中の空気流量波形の標準偏差
- タスク実行中の空気流量波形の変化量の標準偏差

各タスク実行時の空気流量センサの原波形の例を図4.20に示す。空気流量センサは、圧力がかかるとそれに応じてパットの中の空気が押し出され、その時流れ出る空気量を波形として生成するセンサである。この特性から、タスクの姿勢移動量の大小により流れ出る空気量が異なるので、まず、波形の最大値と最小値を特徴量として使用した。次に、タスクの姿勢移動量により波形の大小が異なることは、波形のばらつきにも影響を与える。よって標準偏差を特徴量とした。そして、波形の緩急、つまりタスクを実行する体の動きの速さを特徴量とするために波形の変化量に着目し、変化量の標準偏差を特徴量とした。

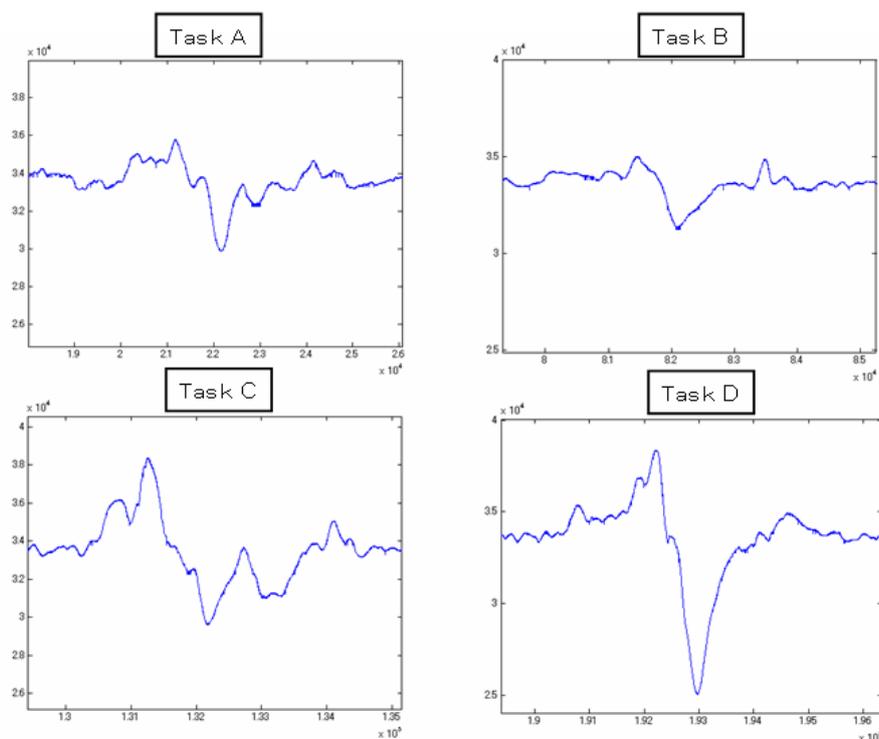


図 4.20：各動作の出力波形の例

## 4.4 運転姿勢推定手法と結果

本節では、運転姿勢推定実験の結果について示す。本研究では、先行研究[12]と比較し、識別精度の向上と、日ごとによる推定精度の変化を抑制することを目的としている。そこで、運転姿勢推定のために実験1,2により取得した空気流量波形データを先行研究でも用いられている線形判別分析法によってタスク(A)からタスク(E)に分類した。図4.18に示すように評価方法は2通りあり、評価1では、データセット1を奇数偶数で50(学習用):50(評価用)に分け識別を行った。評価2では、データセット1を学習用とし、日を変え実験を行ったデータセット2を評価用と推定別を行った。これら二つの評価の推定率から

- ・推定率は先行研究と比べ向上したか
  - ・日ごとによる推定率の変化を抑制することはできたか
- 上記2点について検証することができる。

#### 4. 4. 1 線形な推定式を構築する手法での推定結果

##### 線形判別法による結果

線形判別分析法による評価1 と評価2 の推定結果を示す. 表4.5 は評価1 と評価2 の推定精度の結果であり, 図4.21 は評価1 と評価2 の推定率の変化を示したものである.

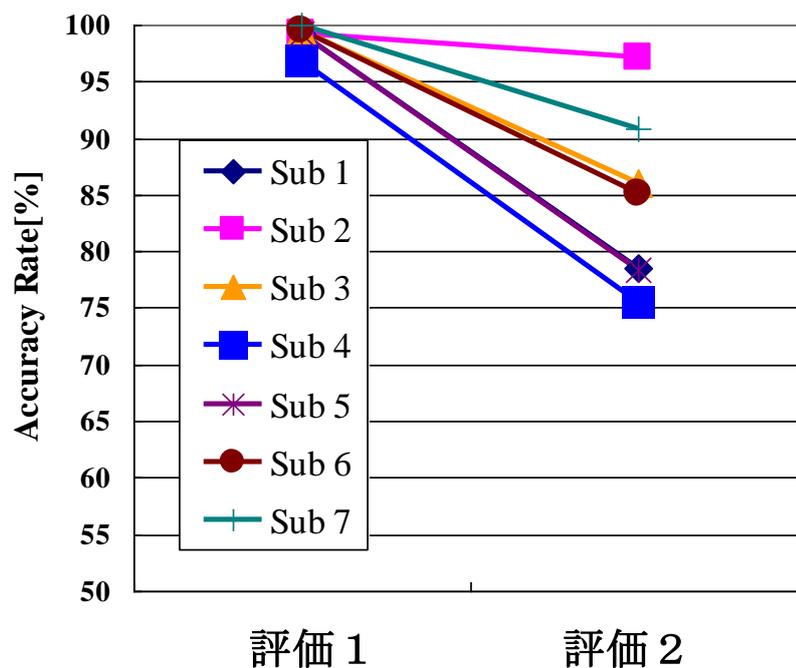


図 4. 21 : 線形判別法による推定結果

表 4. 5 : 線形判別法による推定結果 (数値データ [%])

	Sub1	Sub2	Sub3	Sub4	Sub5	Sub6	Sub7
評価 1	99. 2	99. 2	99. 6	96. 8	99. 2	96. 6	100
評価 2	78. 5	97. 2	86. 0	75. 6	78. 4	85. 2	90. 8

## 線形判別法での識別結果考察

座り直しを行った際の推定率変化の結果として評価1で全ての被験者で推定率が95%以上、評価2の座り直しを行ったデータを用いた場合においても全ての被験者で75%以上という結果を得た。シートにより体圧情報を取得した先行研究(5)では、座り直しを行った際の推定率が被験者ごとに差があるものの30~60%程度に留まったと報告されており、本手法により得られた75%以上という結果は比較的高い値であると言える。この結果より、シートベルトからの体圧変化情報に基づくドライバの運転姿勢推定の可能性について示唆することができた。

次に、識別率が低かった点について考察を進める。識別率が低い被験者としてSub4を例に出すと、Sub4では線形判別分析法でタスク(D)著しく識別率が低い。推定結果を掘り下げてみたところ、本来タスク(C)と識別されるべきものは全てタスク(B)と誤判定されてしまっていることが判明した。これはSub4の識別に用いられているデータの中でタスク(B)とタスク(C)が類似しているため誤判定が起きてしまったと考えられる。誤判定を引き起こす原因となった特徴量について図4.22に示す。これはSub4の腹部での空気流量センサ出力波形の最小値(左図)と腹部での空気流量センサ出力値の標準偏差(右図)である。青でプロットされている点が学習データ、赤でプロットされている点が評価データである。横軸がデータ数であり0-50がタスク(A),51-100がタスク(B),101-150がタスク(C),151-200がタスク(D)のデータである。この二つの特徴量ではタスク(C)の学習データとタスク(B)の評価データが類似しており誤判定を引き起こしたと考えられる。

更に同じく推定率が低いSub5の胸部で空気流量センサ出力波形の標準偏差(左図)と、腹部での空気流量センサの出力波形の標準偏差(右図)を示す(図4.23)。タスク(B)とタスク(D)の学習データと評価データに着目すると、明らかに別の分布を示していることが分かる。これが誤判定を引き起こしたのであると考えられる。

これらの結果より誤判定には二通りの原因があることが分かる。一つめは、評価データが他のタスクの学習データと類似していた場合、二つ目は同一タスクで学習データと評価データが全く異なる分布を示している場合である。この二つの原因を抑制するためには線形判別分析法のような判別空間を線形に構成する識別手法より、さらに複雑な判別空間を構成する識別手法が有効であると考えられる。そこで、判別空間を非線形に構成するAdaBoost アルゴリズムに着目し識別を試みた。AdaBoost アルゴリズムは数ある非線形な識別手法の中でも計算時間が高速であるため、運転姿勢推定のようなりアルタイム性を考慮しなければならない識別には適している。

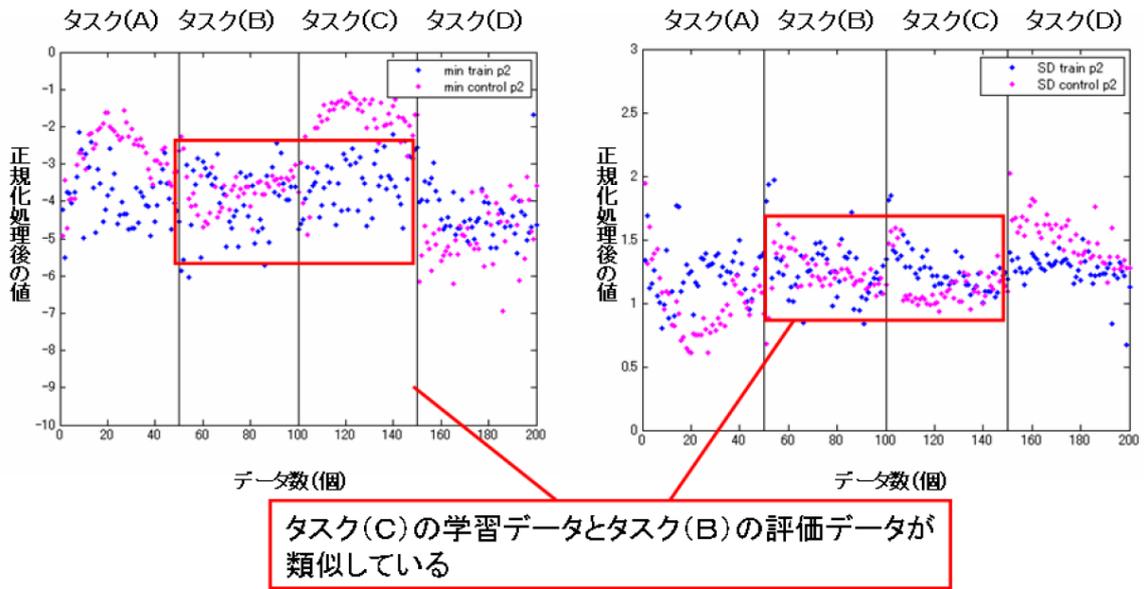


図 4.22 : 誤判定を引き起こす原因となった特徴量 (Sub4)

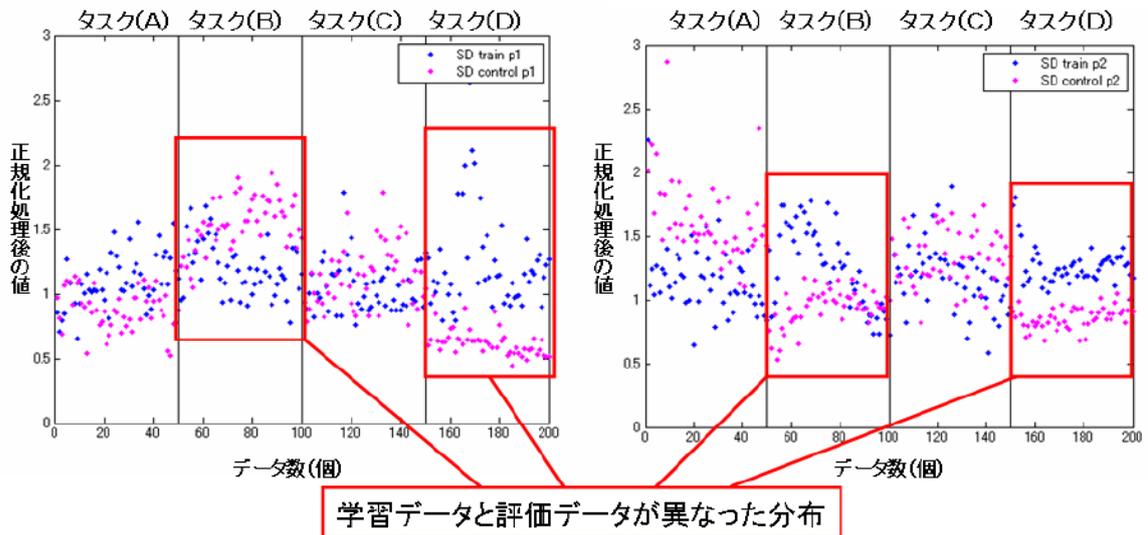


図 4.23 : 誤判定を引き起こす原因となった特徴量 (Sub5)

## 4. 4. 2 非線形な識別式を構築するAdaBoostによる推定結果

### 推定結果

AdaBoost アルゴリズムによる評価1 と評価2 の識別結果を示す. 表6.3 は評価1 と評価2 の識別精度の結果であり, 図6.10 は評価1 と評価2 の識別率の変化を示したものである.尚,AdaBoost アルゴリズムは二値判別手法であるため, ECOC 法を用いて多値判別手法に拡張し識別を行った.

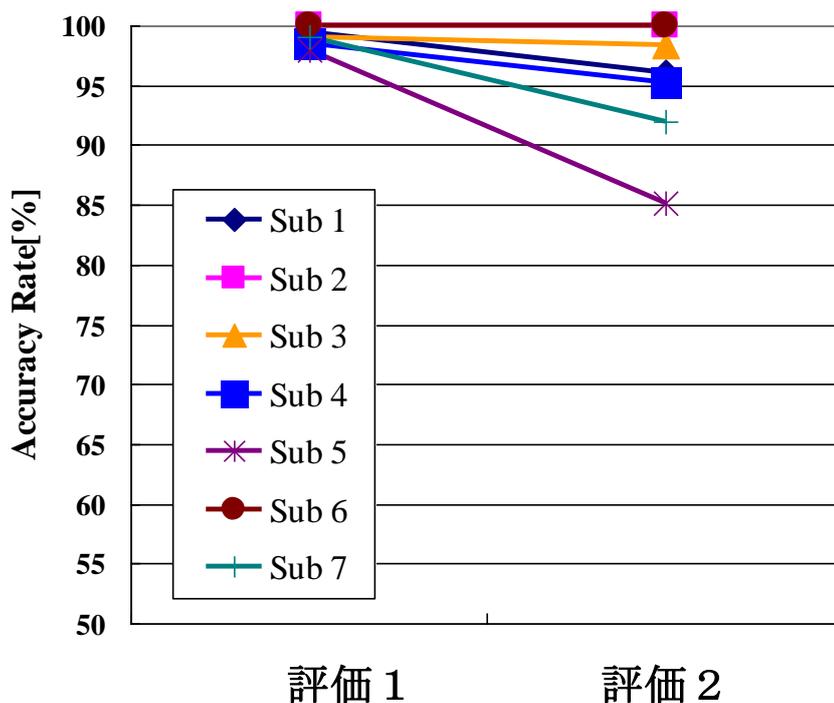


図 4. 24 : AdaBoost による推定結果

表 4. 6 : AdaBoost による推定結果 (数値データ [%])

	Sub1	Sub2	Sub3	Sub4	Sub5	Sub6	Sub7
評価 1	99. 5	100	99. 0	98. 5	98. 0	100	99. 0
評価 2	96. 0	100	86. 4	95. 2	85. 2	100	92. 0

## AdaBoostアルゴリズムでの推定結果考察

図6.10, 表6.4 から推定精度は評価1 で全被験者で平均95 %以上, 評価2 では平均90 %以上となった. 線形判別分析法で問題となったSub4 のタスク(B), タスク(D)での著しく低い推定率についても抑制することができた. これは線形な識別手法では判別が困難であるデータに対しても非線形な推定手法が対応できたことを示している. しかし,線形判別分析法よりも推定精度はよくなったとは言え, Sub3のタスク(B) と Sub5 のタスク(D) については共に識別率90.0 %を割っており他の被験者と比較し良好な推定率とは言えない. 原因は前述した理由と同じで, 評価データが他のタスクの学習データと類似していたこと, 同一タスクで学習データと評価データが全く異なる分布を示していたことであると考えられる. 現在以上に識別率を向上させるためには, 学習データと評価データの類似や異なる分布が生じても対応できるようにセンサ数を増やし, より明確な判別空間を構成することが必要だと考えられる.

## 先行研究との比較

ここでは, 伊藤ら[3] によって行われたドライバの姿勢推定と本研究との比較を行う. 結果としては, 本研究に用いた手法では日にちを変えたデータを用いて評価を行った評価2 においても平均推定率90 %を越える結果を出すことができた. また, データを同じ日に取得したものの評価である評価1 では平均で95 %を越え, 日ごとの変化においても,識別率そのものにおいても先行研究を大きく上回ることができた.

本研究が先行研究を上回ることができた要因としては, まずシート・圧力分布センサ(先行研究), シートベルト・空気流量センサ(本手法) でのセンサとその装着個所の違いが挙げられる. 圧力分布センサはシートに着座した状態から姿勢を移動する際の圧力分布を捉える. よって, 指摘があるように着座位置が変化すると初期の圧力分布自体に違いが生じ, 同じ動きをしたとしても出力されるデータは本来のデータと異なるものとなると考えられる.しかし, シートベルトでは, 固定点が定まっており常に一定の装着状態となることが期待できる. さらに, 空気流量センサは, 荷重がかかっている間は常に出力がある圧力分布センサとは異なり, 静止した状態では出力されない. 何か動きがあった時にのみ反応し, 波形を出力するのでセンサ装着位置のみ固定すれば常に同じ出力を出すことができる. それを裏付けるものとして, 本手法の識別手法に先行研究と同じ, 線形判別分析法(図4.21) を用いても先行研究よりも識別率が良い. さらに本研究では, 推定手法に非線型な判別空間を構成するAdaBoost を用いたことにより精度を向上させている. これらのことによって先行研究を大きく上回ることができたと言える.

## 4.5 空気流量センサの最適位置検討

4.4節にて空気流量センサを用いた運転姿勢推定アルゴリズムについて検討した。本節では、現在取り付けている空気流量センサの位置が最適かどうかについて検討する。現在はのセンサ配置はショルダーストラップとラップストラップの1箇所ずつであり、センサ位置と精度の関係について言及してこなかった。センサ位置を変えることで精度向上が望めるか実験する。

### 4.5.1 最適配置実験方法

空気流量センサ最適配置実験は、図4.25に示す7つのセンサ位置から最も高い推定精度を出すための配置について検討する。実験は、被験者に対し図4.25のセンサ位置それぞれにセンサを設置し、以下の4動作について15回ずつ実施する。

- 助手席に手を伸ばす動作
- 座席前方部に手を伸ばす動作
- 後部座席に手を伸ばす動作
- 運転席の足元に手を伸ばす動作

各動作については、被験者ごとに最終的な姿勢に差がでないよう配慮した。また各動作はドライビングポジションから行い元の姿勢に戻るまでを1動作とした。10秒ごとに定期的な合図を送ることで実施した。尚、被験者は成人男性2名であり、実験を行う際には衣類による影響を排除するため、Tシャツと飾りの無いズボンを着用するよう制約を設けた。また、実験条件を統一するためにシートポジションはブレーキを踏んだときわずかに膝が曲がる、ステアリングの上部を持ったときわずかに肘が曲がる、背中がシートに密着している。この3条件を満たすよう指示した。

評価方法には、各センサ位置に対してleave-one-out法を用いることにより評価した。本来モデルの性能評価は、学習に用いない未知のデータに対する性能を測る。訓練サンプル以外に性能を評価するためのデータを比較的容易に集めることができる場合には、訓練サンプル以外のサンプルを用意することが定石である。つまり、性能を評価するためのサンプルを用意し、そのサンプルに対する性能が最大となる特徴の部分集合を選択することが可能である。この方法は、最も簡単で最も直接的な方法である。しかし、訓練サンプルを集めることが難しく、訓練サンプルが少ない場合には、訓練サンプル以外での評価用データを用意することは困難である。このような場合には、訓練サンプルのみから性能を評価しなくてはならない。かなり多くの計算量が必要であるが、計算パワーさえあれば、比較的簡単に性能を評価できる方法にresampling手法がある。

Leave-one-out法は其中最も単純な方法である。Leave-one-out法では、N個のサンプルが与えられた場合、それをN-1個の訓練サンプルと1個の評価用サンプルとに分割

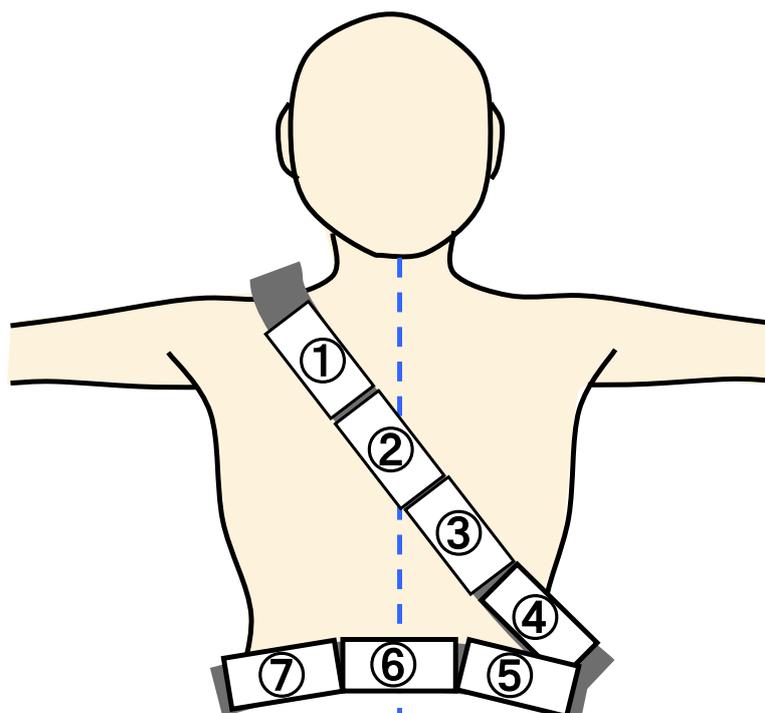


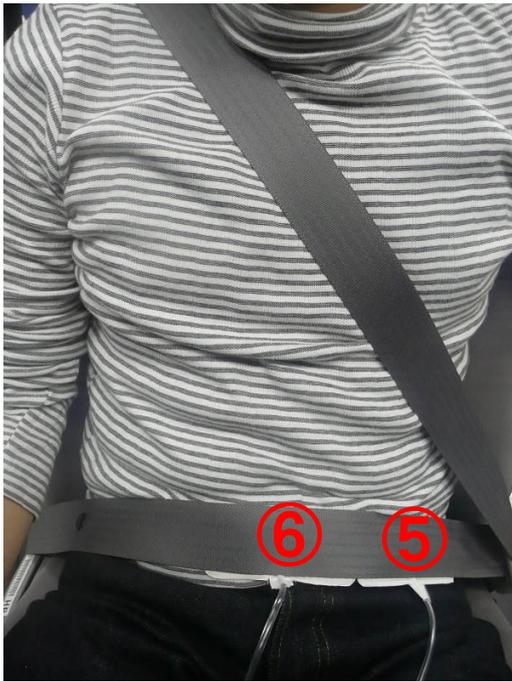
図 4.25 : 最適配置検討でのセンサ検討位置



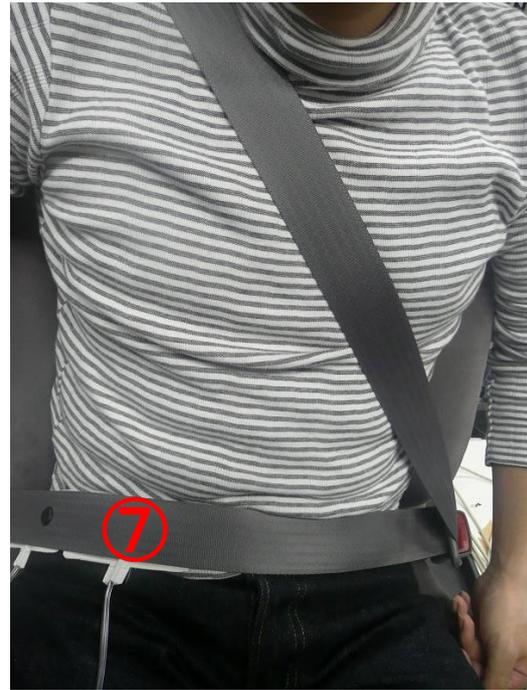
(a) センサ位置 (1) (2)



(b) センサ位置 (3) (4)



(c) センサ位置(5)(6)



(d) センサ位置(7)

し、N-1個の訓練サンプルを用いた学習結果で1個の評価用サンプルを評価する。このような分割の仕方はN通りあるので、その全てに対する評価結果の平均を計算し、それを性能の評価値として利用する。尚、推定を行う際のパターン認識手法には線形判別分析法を用いた。

#### 4.5.2 各センサ位置での実験結果と考察

各センサ位置におけるleave-one-out法により評価した姿勢推定率を図4.26、図4.27に示す。縦軸は推定率[%]、横軸は図4.2.5に示すセンサ位置である。結果をショルダーストラップとラップストラップに分けてみるとショルダーストラップについては両被験者とも位置3において最も高い推定率が算出された。他の位置については被験者により前後するものの位置3と比較すると著しく低い値である。次にラップストラップについて検討する。被験者Aでは位置5~7においてショルダーストラップの位置3と同等程度の推定率が算出された。被験者Bでは、全ての位置で推定率85%を超えており比較的高い値である。その中でも特に位置6については推定率95%であり最も高い値を示している。次に各センサ位置における特性の考察を行う。

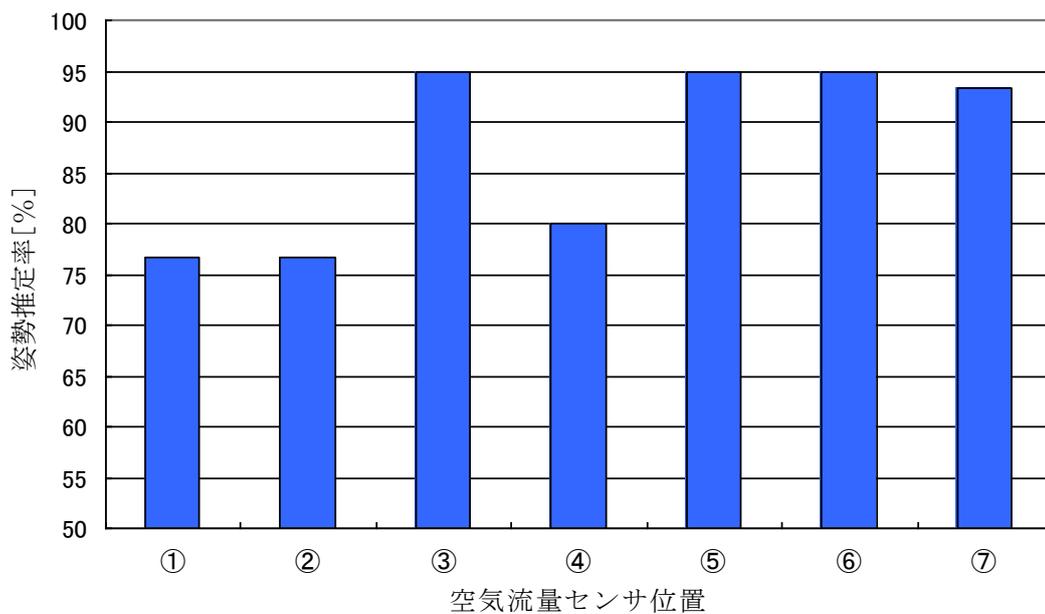


図 4.26 被験者 A の leave-one-out 法による姿勢推定結果

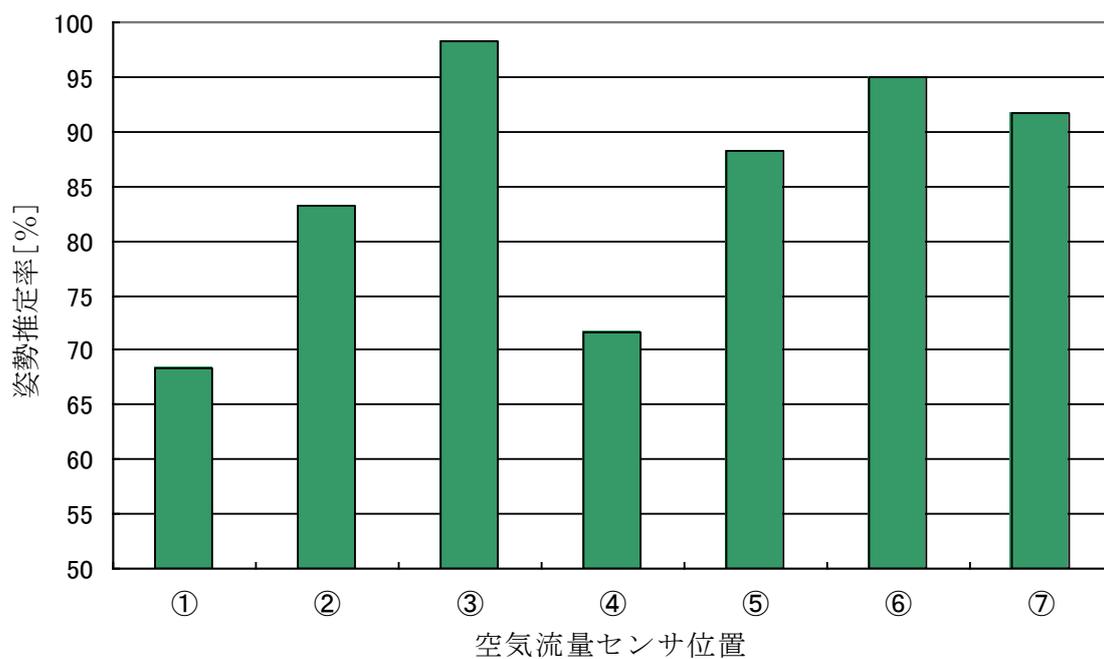


図 4.27 被験者 B の leave-one-out 法による姿勢推定結果

### センサ位置①

位置1におけるセンサ出力値の最小値の特徴量をプロットした図を図4.28に示す。縦軸はセンサ出力値であり、横軸は動作数を表す。横軸1-15はA：助手席に手を伸ばす動作, 16-30はB：座席前方部に手を伸ばす動作, 31-45はC：後部座席に手を伸ばす動作, 46-60はD：足元に手を伸ばす動作を表している。図4.28から各動作について特徴量の値の差が小さいことがわかる。本研究のような物理的な動作量の推定を行う際は、特徴量に明確な差がないと正確に姿勢を分類することが難しい。位置1にて特徴量に差が少ない要因としては、体の右肩部に当たる部位にセンサが設置されているため、どの動作を行う際も大きく動く部分に相当する。よって、センサの出力値も全ての動作で同程度出力され結果出力値の差が小さくなったと言える。

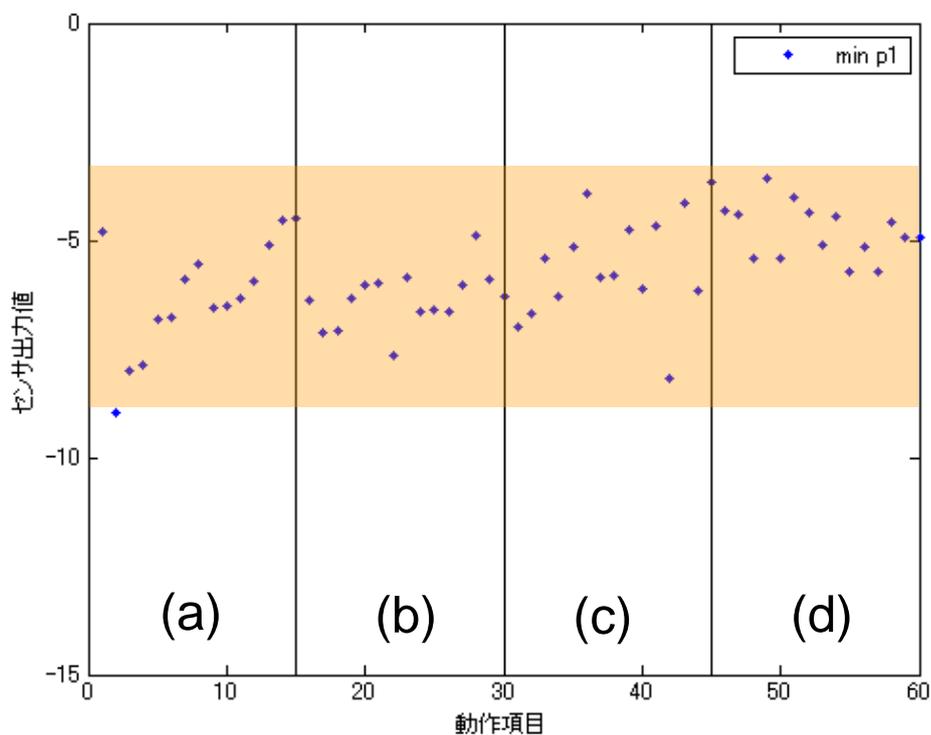


図 4.28 センサ位置①での各動作のセンサ出力値の分布

### センサ位置②

位置2では姿勢(a)(c), (b)(d)で特徴量が類似している。これが誤判定を引き起こす要因となっており、推定率は76.7%に留まった。位置2において姿勢(a)(c), (b)(d)で値が類似した理由としては、姿勢(a)(c)は助手席に手を伸ばす動作、後部座席に手を伸ばす動作であり、いずれもドライバーが横に動く動作である。また、(b)(d)は座席前方部に手を伸ばす動作、足元に手を伸ばす動作であり、いずれもドライバーが前に動く動作である。(a)(c)では動作量は異なる胸部にセンサを設置した際は違いが見られなかった。(b)(d)では胸部での変化よりもむしろ腹部にセンサを設置した場合の方がより違いが明確になると考えられる。それは、足元に手を伸ばす動作と座席前方部に手を伸ばす動作では足元に手を伸ばす動作の方がセンサが腹部により圧迫されやすいからである。

### センサ位置③

センサ位置3については図4.29に示すとおり、特徴量が全体にばらけており推定しやすいという結果になった。特に他の動作と特徴量のレンジが重なることなく、高い推定率を算出できる可能性が高い。

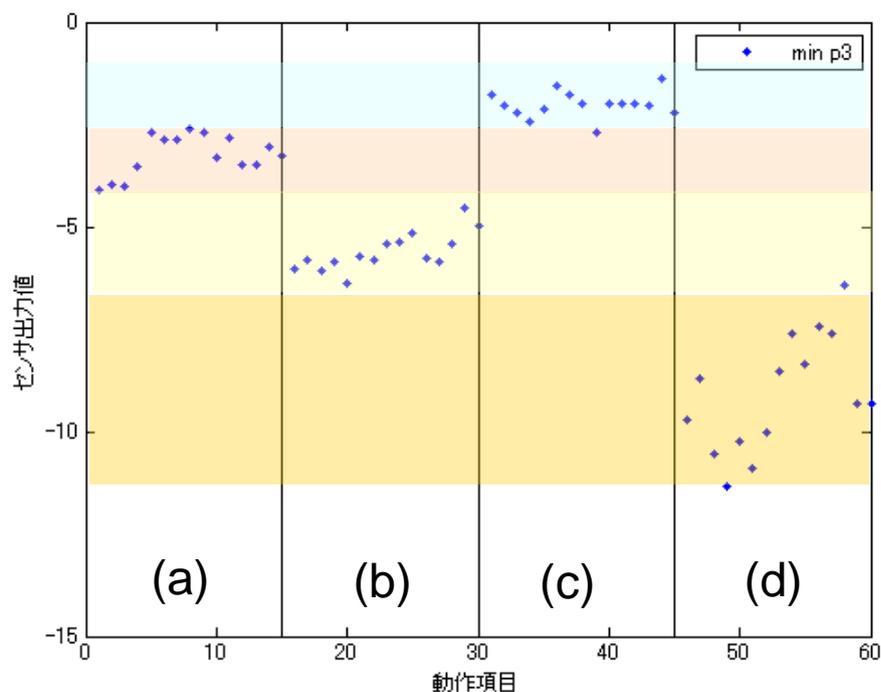


図 4.29 センサ位置③での各動作のセンサ出力値の分布

#### センサ位置④

センサ位置 4 は本来、体とセンサが接していない位置である。今回のセンサ最適配置実験ではシートベルトの全ての面で総当りで試すことが目的であるため試みたが、ほとんど波形が出力されず推定には適していない位置であることが確認できた。図4.30に位置 4 で計測した空気流量センサの出力波形を示す。また、図4.31には位置 3 で計測した空気流量センサの出力波形を示す。位置 3 は上述した通り姿勢推定に適した位置であり、この 2 つの図を比較することで位置④では姿勢を捕らえることが困難であることが分かる。

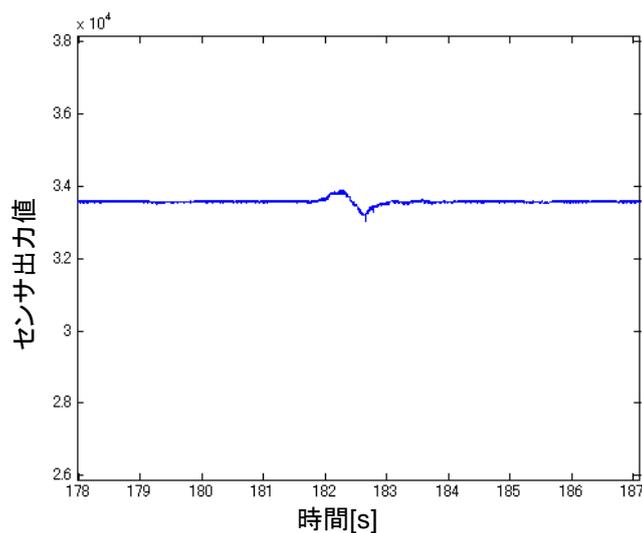


図 4. 30 位置④で計測した空気流量センサの出力波形

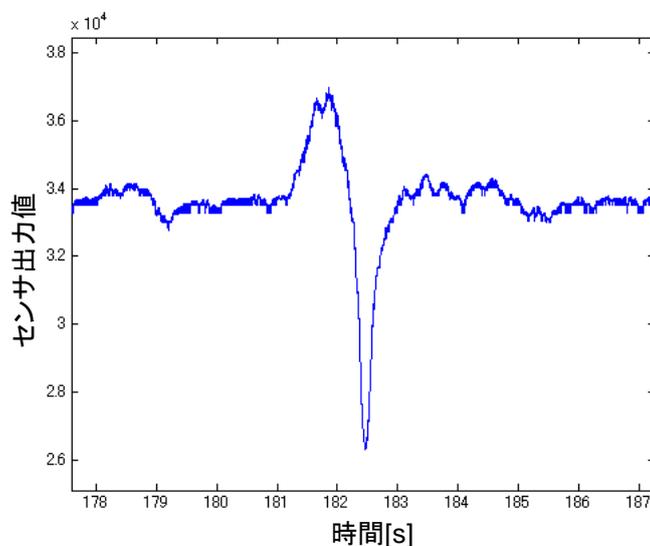


図 4. 31 位置③で計測した空気流量センサの出力波形

### センサ位置⑤, ⑥, ⑦

センサ位置 5, 6, 7 は腹部である。腹部での推定は両被験者共 3 箇所で大きな推定率の違いはなかった。他の位置と比べ 3 箇所とも比較的高い推定率を出していることから姿勢推定に関して有効な位置であると考えられる。腹部では胸部より体の移動が少ないため姿勢変化の動作量が忠実に再現されたためでないかと考える。また、腹部で誤判定が生じたデータについても誤判定姿勢に偏りがなかったことから、比較的姿勢推定に向いていると判断できる。

### 4. 5. 3 各センサ位置での最適組み合わせ検討

センサ位置の最適組み合わせを検討する。効率的に推定を行うために、どの位置にいくつセンサを設置すればよいのかを明確にすることが目的である。センサ 7 箇所における組み合わせ数は以下のようになり、合計で 1 2 7 パターン存在する。

- センサ 1 個の場合： 7
- センサ 2 個の場合： 2 1
- センサ 3 個の場合： 3 5
- センサ 4 個の場合： 3 5
- センサ 5 個の場合： 2 1
- センサ 6 個の場合： 7
- センサ 7 個の場合： 1

最適な個数、配置を明確にするため全てのパターンを試行する。図4.32, 図4.33は各組み合わせ個数での平均推定率である。これらの結果は各位置の組み合わせを全通り行っているため個数ごとに試行回数が異なる。この結果より、センサの組み合わせを 4 つ以上によりどの位置を組み合わせたとしても推定率は 100% になることが判明した。つまり、コストの制約がない状態に限ればセンサを 4 つ設置することで 4 動作の判別が可能となることが分かる。

次に高推定率を出すためのセンサ数の最低個数について検討する。これはセンサの配置(組み合わせ)が重要となってくる。表4.7にセンサを 2 つ組み合わせた場合の全通りの推定率結果について示す。この表をみると推定率が 100% に達している組み合わせは 8 通りである。このうち位置 3 を含んでいるものは全て 100% になっている。また位置 2 と腹部を組み合わせたものや腹部同士を組み合わせたものも姿勢推定に有効であることが判明した。これは他の被験者でも同一の傾向がみられ t。これらから分かる最も効率的なセンサ配置はセンサ数が 2 個であり、胸部の位置 2 または 3 と腹部のいずれかの位置にセンサを配置した場合であると言える。

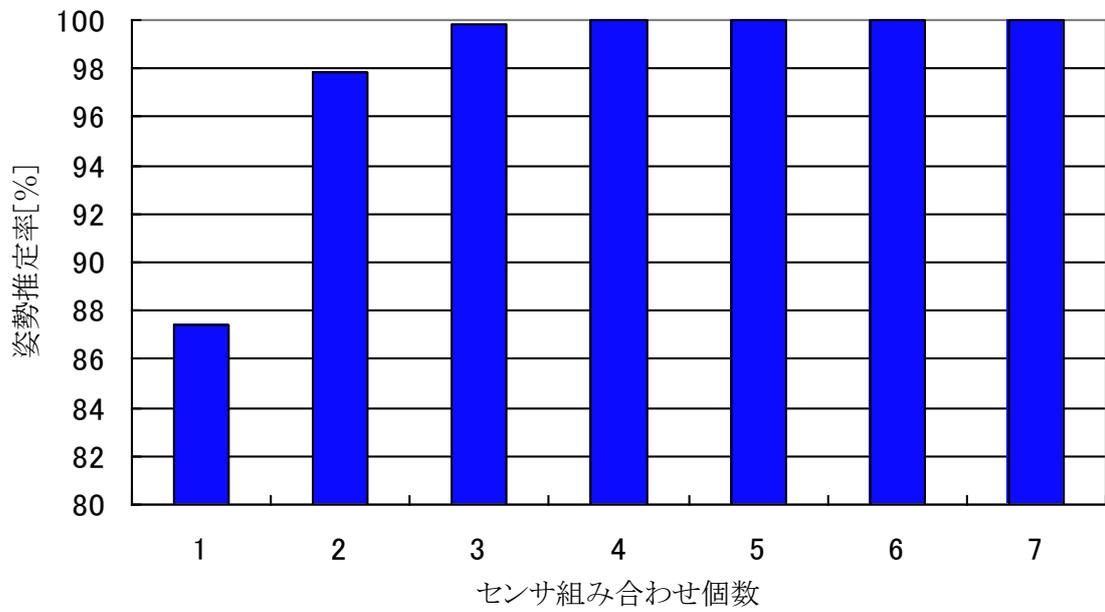


図 4.32 被験者 A の各組み合わせ個数での平均推定率

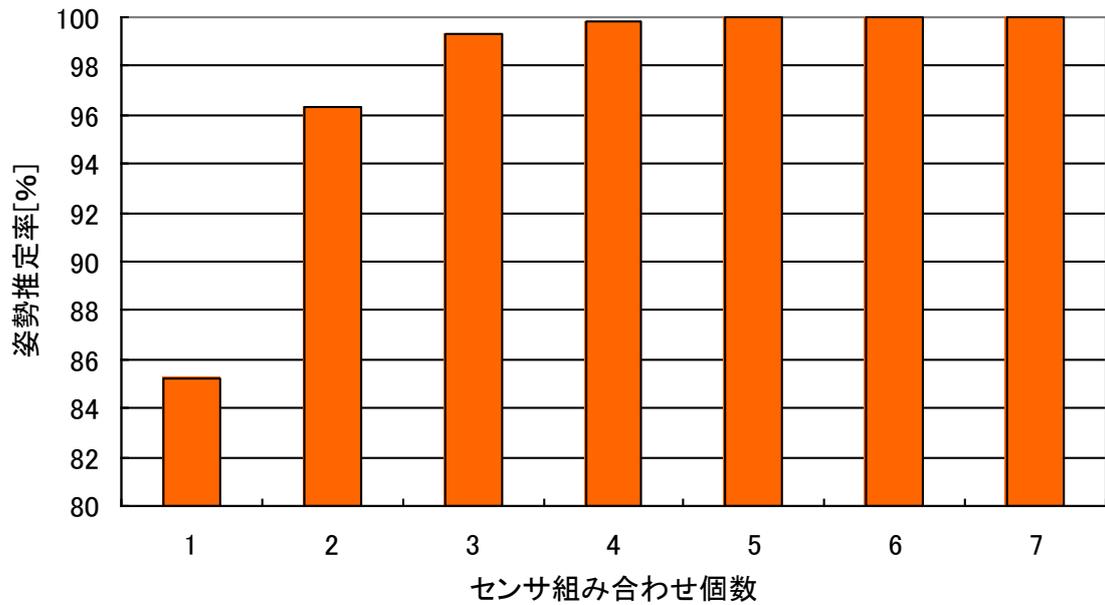


図 4.33 被験者 B の各組み合わせ個数での平均推定率

表 4.7 センサ位置の組み合わせによる推定精度結果

センサ位置		推定率[%]
1	2	93.3
1	3	98.3
1	4	96.7
1	5	96.7
1	6	98.3
1	7	96.7
2	3	96.7
2	4	95.0
2	5	98.3
2	6	100
2	7	100
3	4	100
3	5	100
3	6	100
3	7	100
4	5	98.3
4	6	91.7
4	7	96.7
5	6	98.3
5	7	100
6	7	100

## 4.6 ドライバの運転姿勢推定まとめ

空気流量センサをシートベルトに設置し、異常運転姿勢に判別されるドライバの運転姿勢推定を実施した。推定に用いた異常運転姿勢は事前に運転パフォーマンスを評価し、通常運転と比べて事故が発生する状態にあることを確認した上で実施した。結果として、高精度での推定を達成でき、従来研究に例の無い、シートベルトを用いた運転姿勢推定の可能性を見出すことができた。また、シートベルトへ空気流量センサを設置する際の最適配置についても検討した。検討した最適配置結果はシートベルトからの体圧情報を最も効率的に取得することが可能であり、本研究にて実施した運転姿勢推定に限らず、ドライバの体圧情報を取得する際に有効活用可能な結果である。

## 第5章 結論

本研究では近年の重大な事故の要因の予防策となり得る居眠り運転推定と運転姿勢推定について独自の手法を提案した。

居眠り運転推定に関しては、一般的には脳波、瞼開閉情報に代表されるような眠気と関連のある情報から特徴量を取得し、パターン認識や回帰分析といった識別関数を作成する手法により眠気の有無を判定する。つまり、居眠り運転推定を行うためには、脳波など何の情報を用いるか、どのような特徴量を抽出するか、推定手法に何を用いるかという3つの問題に大別することができる。

本研究では、自動車運転中という環境であるため、ドライバに負担をかけずにデータを取得することが可能な情報である瞼開閉情報、心拍情報、呼吸情報、荷重情報の4つに着目した。いずれもドライバに対し非侵襲でデータを取得するための研究が進んでいる。または実用化されているものであり、現実的であるため使用した。特徴量に関しては眠気と関連があると報告されている有効な特徴量を取得し使用した。ドライビングシミュレータを用い居眠り運転模擬実験を実施し、居眠り運転時の各情報を元に、3段階の顔表情評定値を正解値としパターン認識により推定を行った。推定結果から考察すると、一般的なパターン認識手法(kNN など)を適用した場合には、3段階の眠気レベルにおいて2段階以上の誤判定が多数生じており(2段階の推定誤差 6.5 %程度)、正解値と推定値の相関は 0.56 程度に留まった。相関を向上させるには2段階以上の誤判定の低減が重要であると考えられ、その原因について特徴量の変動について確認したところ、全ての特徴量において推定値に影響を与える程の変動が短時間で生じていた。これは心拍や呼吸に関しては生体特有の揺らぎによる影響が原因であり、瞼開閉情報や荷重情報では眠気以外の要因が影響したためであると考察できる。そこで、本研究では眠気以外の要因の影響を受けた特徴量が入力された場合においても対応できる手法を提案する必要があるという結論に至った。眠気には独特な変化の過程があり、それを手法に組み込むことにより精度が向上するのでは無いかという仮説をたて、眠気の変動について考察を行った。ビデオ映像から取得した顔表情評定値に対し考察を行ったところ、眠気レベルは2段階に渡る大きな変動は無く段階的に推移していた。また、眠気の変動について考察した論文によると、変動は45~250秒の間で生じると報告されており、これは本研究での眠気レベル変動と一致した。そこで、眠気レベルの段階変化を考慮した手法を提案した。具体的には(a)判別時で3レベル同時判別では無く、段階的な推定を実施すること、(b)過去一定区間の推定値の変動を考慮すること、上記2点を手法に組み込んだ。推定結果としては、相関0.8を達成し、2段階誤差を3.8%まで低減させることができた。この精度は他の先行研究と比較しても最も高い精度であり、これは本提案手法の有効性を示すものである。

次に運転姿勢推定については、シートベルトから体圧情報を取得し、それらから抽出した特徴量からパターン認識手法により判別を行うことでドライバの運転姿勢推定を行った。パターン認識手法には、先行研究と比較を行うため線形判別分析法を適用した。結果として、問題点とされていた座り直しを行った際の姿勢推定率の変化を抑制することができた。また、パターン認識手法に非線形な判別空間を構成し、多クラス判別を行うことが可能な ECOC 法を採用した結果、座り直しを行った際に平均で 95.3%の姿勢推定率を得ることができた。シートベルトでの姿勢推定は、カメラからの撮影画像に基づいた手法において問題視されていた車外環境変化への対応や、撮影可能範囲を逸脱した場合の対応にも対処できており、ドライバの運転姿勢を推定する手法としての有効性を示すことができた。

更に、本研究ではシートベルトから体圧変化情報を取得する際の、センサの最適配置、個数についても検討を行った。本検討結果はドライバの運転姿勢推定を行う場合に限らず、シートベルトから体圧変化情報を取得する際には常に有効な結果であり、新規性のある成果である。

# 謝辞

本研究を進めるにあたり、ご協力を賜った皆様に深く御礼申し上げます。

本研究を行うにあたり、多大なご尽力を頂き、ご指導ご鞭撻頂いた小栗宏次教授に心から感謝致します。

本研究を進める際に活発な議論を交わして頂き、更には大学院博士後期課程進学に関して親身にご相談に乗って頂いた河中治樹講師に厚く御礼申し上げます。

本研究に関するご指導に加え、博士後期課程の先輩として多くの学びを提供して下さいました宮治正廣客員教授に感謝致します。

本研究のためにご多忙な時間を割きご指導に当たって下さった博士後期課程の時津直樹氏、中野泰彦氏、坪井務氏に感謝致します。

本研究を進めるに当たり、長年に渡り多くのご助言をして下さった客員共同研究員の岸本圭史氏、高橋千紗氏に感謝致します。

本研究ために貴重な時間を割いて頂き研究に関する議論は勿論のこと、社会人ドクターである私の研究環境の整備にもご助力頂いた高橋さゆり氏、小島孝雄氏、長谷川陽一氏、福島隼人氏、小田賢氏、近藤里帆氏、早田有利氏、磯村敦氏、岸稚佳氏、柴田千里氏、西野咲子氏、本田真氏に感謝致します。

そして最後に、研究活動に集中するために日々の生活支え、常に温かい目で応援して下さいました親族の父、母、祖父、祖母に感謝致します。

言葉のみで感謝を言い表すことはできませんが、この謝辞を持って感謝の意を表させていただきます。

## 参考文献

- [1] 警視庁”平成 22 年中の交通事故統計”
- [2] 石田健二, 蜂須賀知理, 木村禎祐, 上條正義,” 覚醒低下に伴う顔表情の特徴と眠気検知手法への適用”, 自動車技術会論文集, Vol.64, pp.41-45, 2010
- [3] Pai-Yuan Tsai, Weichih Hu, Terry B.J.Kuo, and Liang-Yu Shyu,” A portable Device for Real Time Drowsiness Detection Using Novel Active Dry Electrode System”, IEEE, EMBS, 2009
- [4] Tsuchida, A. Bhuiyan, M.S. Oguri, K.,” Estimation of Driver’s Drowsiness Level using a Neural Network Based Error Correcting Output Coding Method”, IEEE ITSC, pp.1887-1892, 2010
- [5] 大内義彦, 青木義満, 春日伸予, 坂本一朗, 塚田由紀, “画像による開眼度計測を客観的な指標とした居眠り因子の推定”, 電子情報通信学会, 信学技報, Vol.29, pp.45-50, 2005
- [6] 宮川智文, 坂井孝光, 中村清実, “リアルタイム目追跡システムを用いた居眠り警報のための瞬き検出装置の開発”, 電子情報通信学会, 信学技報, Vol.103, No.81, pp.41-45, 2003
- [7] 中野倫明, 杉山和彦, 水野守倫, 山本新, “画像による瞬目計測と居眠り検知への応用”, テレビジョン学会誌, Vol.50, No.12, pp.1949-1956, 1996
- [8] 中野倫明, 杉山和彦, 水野守倫, 山本新, “居眠り検知のための瞬き検出と覚醒度推定”, 電子情報通信学会, 信学技報, Vol.95, No.44, pp.73-80, 1995
- [9] 宮澤拓未, 福本一朗, “生理指標を用いた眠気検出アルゴリズム開発の検討”, 電子情報通信学会, 信学技報, Vol.107, No.218, pp.3-6, 2007
- [10] 沼田仲穂, 北島洋樹, 五井美博, 山本恵一, “自動車運転時の眠気の予測手法についての研究 (眠気変動の予測と居眠り警報タイミングの決定)”, 日本機械学会, Vo.63, No.613, pp.2067-2073, 1997
- [11] 加藤, 藤井, 谷本, “赤外線カメラを用いた車内における人物姿勢検出”, 電子情報通信学会, CS2004-113, IE2004-108, 2004
- [12] Ito, M,” Real time inference of driver’s intent via analysis of pressure distribution on the seat”, 4<sup>th</sup> International Congress on Embedded Real Time Software, CD-ROM, 7 pages, 2008
- [13] 稲垣俊之, “人間機械共生系: システム設計の視点と課題”, 自動車技術会シンポジウム「ヒューマトロニクス」, pp.19-24
- [14] Jeremy S.H. Jackson and Blackman,” A Driving-Simulator Test of Wilde’s

- Homeostasis Theory”, *Journal of Applied Psychology*, Vol.79, pp.950-958, 1994
- [15] 中谷洋明, 堀井秀之, 村山明生, 山口健太郎, “リスク特性とリスクガバナンス構造の類型化及び関係分析の試み”, *社会技術研究論文集*, Vol.3, pp.31-46, 2005
- [16] 相馬仁, 鈴木圭輔, 若杉貴志, 平松金雄, “ドライビングシミュレータによるドライバ特性の把握と運転支援機能の評価”, *国際交通安全学会誌*, Vol.26, No.2, pp.14-20, 2001
- [17] 山田晋, 鈴木達也, 稲垣伸吉, 早川総一郎, 土田縫夫, 津田太司, 藤波宏明, “ハイブリッドシステムモデルに基づく運転行動解析”, *日本人間工学会誌*, Vol.42, No.3, pp.181-189, 2006
- [18] 平成 17 年 2 月 18 日 自動車事故対策機構「スタビリティ・コントロール・システムの効果についての調査結果」
- [19] NHTSA HP, <http://www.nhtsa.gov>
- [20] 日本自動車工業会 HP, <http://www.jama.or.jp>
- [21] 世古恭俊, 片岡幸郎, 妹尾哲夫, “覚醒低下時の運転操作解析”, *自動車技術会学術講演集前刷集*, No.841, pp.69-74, 1984
- [22] 小川哉, 荒川俊也, “ふらつき運転によるドライバ覚醒レベル推定警報システムの開発と脳波によるドライバ状態評価”, *自動車技術会論文集*, Vol.56, No.3, pp.74-78, 2002
- [23] 望月正人, 杉浦康司, *自動車技術科会論文集*, Vol.56, No.3, pp.33-38, 2002
- [24] S.Arimitsu, Y.Hashimoto, H.Yamamoto, K.Itao, H.Hosaka, K.Sasaki, T.Nakagawa, T.Kawachi, “Safety Driving System Based on Monitoring Eye Movements”, 11<sup>th</sup> ITS World Congress, NAGOYA, 2004
- [25] A.Ueno, Y.Uchikawa, “An approach to quantification of human alertness using dynamics of saccadic eye movement –For an application to human adaptive mechatronics–”, *Proceedings of 8<sup>th</sup> International Conference on Mechatronics Technology*, Hanoi, pp.563-568, 2004
- [26] Sleep Diagnostics 社 HP, <http://www.optalert.com>
- [27] 恩塚誠, 梅田和昇, 有光知理, 佐々木健, 中川剛, 河内康司, “画像処理を用いた自動車運転時の疲労評価”, *精密工学会春季大会*, 2003
- [28] 金田雅之, 上野裕史, 月野正隆, “居眠り検出技術に関する研究”, *自動車技術会学術講演会前刷集*, No.941, pp.29-32, 1994
- [29] 中野倫明, 杉山和彦, 水野守倫, 山本新, “居眠り検知のための瞬目検出と覚醒度推定”, *電子情報通信学会技術研究報告*, Vol.95, No.44, pp.73-80, 1995
- [30] 小河賢二, 鈴木尋善, 末永伸正, 西田稔, 下谷光生, 佐竹俊英, “クルマとの調和に貢献する自動車機器技術”, *三菱電機技報*, Vol.70, No.9, pp.897-902, 1996
- [31] 沼田仲穂, 北島洋樹, 五井美博, 山本恵一, “自動車運転時の生理・行動指標によ

- る眠気の検出と居眠り警報”, 三菱自動車テクニカルレビュー, No.10, pp.67-75, 1998
- [32] “PERCLOS, A Valid Psychophysiological Measure of Alertness As Assessed by Psychomotor Vigilance”, Federal Highway Administration, 1998
- [33] Gavin Longhurst, “Sleep-out”, traffic technology international
- [34] 柳平雅敏, 安土光男, “運転状態推定技術の開発 (第3報)”, 自動車技術会学術講演前刷集, No.51-04, pp.11-16, 2004
- [35] Ryota KAWAMURA, Md. Shoaib Bhuiyan, Haruki KAWANAKA, Koji OGURI, “Simultaneous Stimuli of Vibration and Audio for In-vehicle Driver Activation”, 14<sup>th</sup> International IEEE Conference on Intelligent Transportation System(IEEE ITSC), pp.1710-1715, 2011
- [36] 各務勇氣, 柳田康幸, 中野倫明, 山本新, 山田宗男, “運転中のドライバへの香り提示による覚醒効果に関する研究”, 電子情報通信学会技術研究報告, ITS 110(150), pp.49-54, 2010
- [37] 塩見利明, 有田亜紀, 篠渡龍二郎, “睡眠時無呼吸症候群の居眠り運転事故調査”, 呼吸器科, Vol.7(4), pp.331-335, 2005
- [38] S.kogure et al. “Human Physiological Signals Extraction and Estimation Using a Car Seat Built-in Piezo-film Sensor”, 17th ITS world congress, TP022-2, 2010
- [39] W.W.Wiresille, L.A.Ellsworth, “Evaluation of driver drowsiness by trained raters”, Accident Analysis Prevention, 1994, 26, pp.571-581
- [40] S.M.Belz, G.S.Robinson, J.G.Casali, “Temporal separation and self-rating of alertness as indicators of driver fatigue in commercial motor vehicle operators”, Human Factors, 2004, 46, pp.154-169
- [41] S.K.Lal, A.Craig, “Reproducibility of the spectral components of the electroencephalogram during driver fatigue”, Psychophysiol, 2005, Vol.55, No.2, pp.137-143
- [42] Eugene Zilberg, “Methodology and initial analysis for development of non-invasive and hybrid driver drowsiness detection systems”, IEEE, EMBS, 2007
- [43] 心電図の歴史, 札幌厚生病院循環器科 HP, <http://www.gik.gr.jp>
- [44] E. Hartmann, “Driver Vision requirements”, Institut fur med. Optik de Universitat munchen, Deutschland, SAE 700392
- [45] 乾敏郎著: 視覚情報処理の基礎, サイエンス社(1990)
- [46] seeing machines 社 HP, <http://www.seeingmachines.com>
- [47] 屋所健司, 稲垣敏之, “運転座席面にかかる荷重の変動に基づくドライバの覚醒度低下検出”, 筑波大学, リスク工学専攻修士論文, 2006

- [48] 麻生英樹, 津田宏治, 村田昇, “パターン認識と学習の統計学”, 岩波書店, 2003
- [49] M.Mulin, R.Sukthankar, “Complete Cross Validation for Nearest Neighbor Classifiers”, 17<sup>th</sup> International Conference on Machine Learning, 2000
- [50] Bredensteiner, E.J. and K.P.Bennett, “Multicategory classification by support vector machines”, Computational Optimization and Applications, Vol.12, pp.53-79, 1999
- [51] 白石友一, 福水健次, “多値判別における 2 値判別器のゲーム理論的組み合わせ”, 電子情報通信学会論文誌 D, Vol.J91-D, No.6, pp.1528-1537, 2008
- [52] Chinh-wei Hsu, Chih-jen Lin, “A Comparison of Method for Multi-class Support Vector Machine”, IEEE Trans. Neural Network, Vol.13, pp.415-425, 2002
- [53] R.Rifkin and A.Kloutau, “In Defense of One-Vs-All Classification”, Journal of Machine Learning Research, Vol.5, pp.101-141, 2004
- [54] T.G.Dietterich and G.Bakiri, “Solving multiclass learning problems via error correcting output codes”, Journal of Artificial Intelligence Reserch, Vol.2, pp.263-286, 1995
- [55] E.L.Allwein, R.E.Schapire, and Y.Singer, “Reducing multiclass to binary: A unifying approach for margin classifiers”, Journal of Machine Learning Reserch, Vol.1, pp.113-141, 2001
- [56] 梅原宗一, 山崎輝, 須見康雄, “サポートベクタマシンとニューラルネットワークに基づく降水量推定システム”, 電子情報通信学会論文誌, Vol.J86-D, No.7, pp.1090-1098
- [57] 伊藤潤, 小栗宏次, “脳波解析によるドライバの眠気と呼吸に関する基礎的研究”, 愛知県立大学卒業論文, 2011
- [58] 山口, 石井, “エラー訂正符号を用いたパターン識別器の統合法”, 電子情報通信学会論文集, D-2, Vol.J86-D-2, No.2, pp.324-332, 2003
- [59] 山下洋, “パターン認識”, 新世代工学シリーズ「人口知能, オーム社, pp.98-115」, 2000
- [60] 道満恵介, 出口大輔, 高橋友和, 目加田慶人, 井出一郎, 村瀬洋, “色変動を考慮した生成型学習法による道路標識検出器の構築”, 電子情報通信学会, Vol.J93-D, No.8, pp.1375-1385, 2010
- [61] 足立和正, “ドライバーの運転状態モニタ機能をもつドライビングシミュレータ”, 電子情報通信学会論文誌, 2005
- [62] 宇野宏, “予防安全性向上のためのドライバー特性研究”, 国際交通安全学会誌, 2012
- [63] 菊池一範, 本間亮平, 若杉貴志, グエンヴァンクイフン, 岡村宏樹, 菊池弘一, 畠山善幸, “漫然状態検出の可能性に関する実験的考察”, JARI Reserch Journal 20120505

- [64] 福田純一, 阿久津英作, 青木啓二, “修正操舵認識による意識低下推定法の検討”, 自動車技術会 1994 年春季大会, 学術講演会前刷集, Vol.941, 1994
- [65] 福井勝彦, “連続運転時における操舵機能低下の評価法”, 豊田中央研究所 R&D レビュー, 30-3, 1995
- [66] 山本恵一, 樋口伸一, “大型トラックの長時間運転時の覚醒度評価の検討”, 自動車技術会, Vol.46-9, 1992
- [67] Khushaba RN, Kodagoda S, Lal S, Dissanayake G, “Driver drowsiness classification using fuzzy wavelet-packet-based feature extraction algorithm”, IEEE Trans Biomed, 58(1), 121-31, 2011
- [68] Lal SK, Craig A, Boord P, Kirkup L, Nguyan H, “Development of an algorithm for an EEG-based driver fatigue countermeasure”, J safety, 34(3), 321-8, 2003
- [69] Li D, Pedrycz W, Pizzi Nj, “Fuzzy wavelet packet based feature extraction method and its application to biomedical signal classification”, IEEE Trans Biomed, 52(6), 1132-9, 2005
- [70] V. Hargutt, H.P.Kruger, “Compensation for Drowsiness and Fatigue. A Driving Simulation Study”, Proceedings of the International Conference of Traffic and Transportation Psychology (ICTTP), Bern, Switzerland, 2000
- [71] Grace R, Byrne V.E., Bierman D.M., “A drowsy driver detection system for heavy vehicles”, Digital Avionics Systems Conference, Volume 2, 136/1-136/8, 1998
- [72] Picot Antoine, “On-line automatic detection of driver drowsiness using a single electroencephalographic channel”, Engineering in Medicine and Biology Society 30<sup>th</sup> Annual International Conference of the IEEE, ppt.3864-3867, 2008
- [73] Ito T, Mita S, Kozuka K, Nakano T, “Driver blink measurement by the motion picture processing and its application to drowsiness detection”, Intelligent Transportation Systems, The IEEE 5<sup>th</sup> International Conference, 168-173, 2002
- [74] Wierewille W.W, “Overview of research on driver drowsiness definition and driver drowsiness detection”, proceedings of the fourteenth international technical conference on enhanced safety of vehicles, 462-8, 1995
- [75] R Sayed, A Eskandarian, “Unobtrusive drowsiness detection by neural network learning of driver steering”, Journal of Automobile Engineering, Vol.215, No.9, pp.969-975, 2001
- [76] Hayashi K, Ishihara K, Hashimoto H, Oguri K, “Individualized drowsiness detection during driving by pulse wave analysis with neural network”, Intelligent Transportation System IEEE, 901-906, 2005
- [77] Chin-Teng, Che-Jui Chang, Bor-Shyh Lin, Shao-Hang Hung, “A Real Time

- Wireless Brain-Computer Interface System for Drowsiness Detection”, Biomedical Circuits and System IEEE, Vol.4, pp.214-222, 2010
- [78] Esra Vural, Mujdat Cetin, Aytul Ercil, Gwen Littlewort, Marian Bartlett, Javier Movellan, ”Drowsy Driver Detection Through Facial Movement Analysis”, IEEE International Workshop, pp.6-18, HCI 2007
- [79] Takei Y, Furukawa Y, ”Estimation of driver’s fatigue through steering motion”, IEEE Computer Society Press, Vol.2, pp.1765-1770, 2005
- [80] Hong Chung K, “Electroencephalographic study of drowsiness in simulated driving with sleep deprivation”, International Journal of Industrial Ergonomics, Vol.35(4), pp.30-320, 2005
- [81] Bartlett M.S, Littlewort G.C, Frank M.G, Lainscsek C, Fasel I, Movellan J.R, “Automatic recognition of facial actions in spontaneous expressions”, Journal of Multimedia, Vol.1(6), pp.22-35.
- [82] Kanade T, Cohn J.F, Tian Y, “Comprehensive database for facial expression analysis”, Proceedings of the fourth IEEE International conference on automatic face and gesture recognition, pp.46-53, 2000
- [83] Orden K.F.V, Jung T.P, Makeig S, “Combined eye activity measures accurately estimate changes in sustained visual task performance”, Biological Psychology, Vol.52(3), ppt.221-240, 2000
- [84] Zhang Z, Shu Zhang J, “Driver fatigue detection based intelligent vehicle control”, Proceedings of the 18<sup>th</sup> International Conference on Pattern Recognition, pp.1262-1265, IEEE Computer Society Press, 2006
- [85] Bridle J.S., “Training stochastic model recognition algorithms as networks can lead to maximum mutual information estimation of parameters”, Neural Information Processing Systems, Vol.2, pp.211-217, 1990
- [86] Hampshire I.I, J.B., Waibel A.H, “A novel objective function for improved phoneme recognition using time-delay neural networks”, IEEE Transactions on Neural Networks, Vol.1(2), ppt.216-228, 1990
- [87] Sejnowaski T.J., Rosenberg C.R., “Parallel networks that learn to pronounce English text”, Journal of Complex Systems, Vol.1(1), pp.145-168
- [88] 川上満幸, “自動車運転における作業負担に香りが及ぼす影響”, 日本経営工学会論文誌, Vol.51, No.3, ppt.213-219, 2000
- [89] 山本恵一, “車両の蛇行と覚醒度の相関について”, 自動車技術会学術講演会前刷集, Vol.941, pp.25-28, 1994
- [90] 児玉悟, 伊藤正彦, 亀井智成, “皮膚電位を用いた覚醒度検出装置の開発”, 自動車技術会学術講演会前刷集, Vol.912, pp.1213-1216, 1991

- [91] 福井勝彦, “連続運転時における操舵昨日低下の評価法”, 豊田中央研究所 R&D レビュー, Vol.30-3, 1995
- [92] 田辺喜一, 杉山誠, “色度と明度情報を用いた瞬目抽出法の提案”, 電子情報通信学会論文誌(D-II),J77-D-2, 1994
- [93] 黒木康之, 麻生勤, “いねむり運転警報装置の一試案”, 自動車技術会学術講演会前刷集, Vol.772, 1997
- [94] 濱田尊裕, “ドライバの運転状態の検知-個人差に対応した閉眼時間からの意識レベルの検知-”, JST 科学技術文献ファイル,2003
- [95] 奥田幸治, “ドライバ状態推定のための瞬きおよび視線方向の検出”, 自動車技術会学術講演会前刷集, No.10-05, pp.9-12, 2005
- [96] 飯田健夫, “自動車運転時における視覚特性への暗算タスクの影響”, 交通科学, Vol.28, No.1-2, pp.60-65, 1998
- [97] 高橋功次, 中山実, 清水康敬, “ドライブシミュレータ操作時の視点移動と瞳孔面積の変化に関する検討”, 電子情報通信学会技術研究報告, Vol.98, pp.51-58, 1998
- [98] 鳥山将司, 井東道昌, 小塚一宏, “画像処理によるドライバの視線方向検出と脇見検知への適用”, 自動車技術会学術講演会前刷集, No.10-05, 13-16, 2005
- [99] 岡兼司, 菅野裕介, 佐藤洋一, “頭部変形モデルの自動構築に伴う実時間頭部姿勢推定”, 情報処理学会論文誌, コンピュータビジョンとイメージメディア, Vol.47, No.SIG10, pp.185-194, 2006
- [100] N. Oliver A. Pentland, “Graphical Models for Driver Behavior Recognition in a SmartCar”, Proceedings of the IEEE Intelligent Vehicles Symposium, pp.7-12, 2000
- [101] H.Gu, Q.Ji, “An Automated Face Reader for Fatigue Detection”, Proceedings of the 6<sup>th</sup> IEEE International Conference on Automatic Face and Gesture Recognition, p.111-116, 2004
- [102] T. Kumagai, M.Akamatsu, “Prediction of Human Driving Behavior Using Dynamic Bayesian Networks”, IEICE Transactions on information and System, Vol.E89-D, No.2, pp.857-860, 2006
- [103] S.K. Lal and A. Craig, “A critical review of the psychophysiology of driver fatigue”, Biol Psychol, Vol.55(3), pp.173-194,2001
- [104] P.P.Caffier, U.Erdmann and P.Ullsperger, “Experimental evaluation of eye blink parameters as a drowsiness measure”, Eur J Appl Physiol, Vol.89(3-4), pp.319-325, 2003
- [105] J. Connor, P. Norton, S. Ameratunga, E.Robinson, L.Civil, R.Dun, J.Bailey, R. Jackson, “Driver sleepiness and risk of serious injury to car occupants: population based case control study”, Br.Med.J, Vol.324(7346), pp.1125, 2002

- [106] D.F.Dinges, and Grace, R., "PERCLOS: A valid psychophysiological measure of alertness as assessed by psychomotor vigilance", Federal Highway Administ., Office of Motor Carriers. Report No. FHWA-MCRT-98-006, 1998
- [107] T.Jung, S.Makeig, M.Stensmo, and T.J.Sejnowski, "Estimating alertness from EEG power spectrum", IEEE Trans. Biomed.Eng, Vol.44(1), pp.60-69, 1997
- [108] S.K.Lal and A.Craig, "Driver fatigue: electroencephalography and psychological assessment", Psychophysiology, Vol.39(3), pp.313-321, 2002
- [109] S.K.Lal and A.Craig, "Reproducibility of spectrum components of the electroencephalogram during driver fatigue", Int J Psychophysiol, Vol.55(2), pp.137-143, 2005
- [110] K.Y.Liang and S.L.Zeger, "Regression analysis for correlated data", Ann Review of Public Health, Vol.14, pp.43-68, 1993
- [111] Rochford, P.D., Ruehland, W., Chercward, T. and Pierce, R.J., "Evaluation of automated versus manual scoring of polysomnographs on sleep disordered breathing", Australian Sleep Association Meeting, 2006
- [112] F.Sagberg, "Road accidents caused by drivers falling asleep", Accident Analy Prevention, Vol.31(6), pp.639-649, 1999
- [113] J.A.Stern, D.Boyer, and D.Schroeder, "Blink rate: A possible measure of fatigue", Human Factors, Vol.36(2), pp.285-297, 1994
- [114] 山口昌広, "近赤外線画像によるドライバ状態監視システム", 第 6 回センシングシンポジウム講演論文集, Vol.D-3, pp.63-68, 2002
- [115] 田中宏明, "知的運転支援システムによる安全性向上技術", 自動車技術会論文前刷集, Vol.8, No.5, pp.88-94, 2004
- [116] H.Takahiro, A.Kazumasa, N.Tomoaki, Y.Shin, "Detecting Method Applicable to Individual Features for Driver's Drowsiness", IEICE Trans-on-INF. & SYST., Vol.E87-D, No.1, pp.89-96, 2004
- [117] 西村千秋, 小坂明生, 常光和子, 吉沢修治, 南雲仁一, "皮膚電位水準による自動車運転時の覚醒水準評価の試み II - 諸生理量の比較", 人間工学, Vol.23-2, 1987
- [118] 保坂良資, 渡辺瞭, "まばたき発生パターンを指標とした覚醒水準評価の一方", 人間工学, Vol.19-3, 1983
- [119] N.Ueda and K.Saito, "Parametric mixture models for multi-labeled text" Advances in Neural Information Processing System, MIT Press, pp.721-728, 2003
- [120] I.Daubechies, "Orthonormal bases of compactly supported wavelets", Commun. Pure Appl. Math, Vol.1, pp.909-996, 1998
- [121] S.Mallat, "A theory of multiresolution signal decomposition: The wavelet

- representation”, IEEE Trans. Pattern Anal. Mach, Vol.11, No.7, pp.674-693, 1989
- [122] A.Quinquis, “A few practical applications of wavelet packets”, Digital Signal Process, Vol.8, pp.49-60, 1998
- [123] R.R.Coifman and M.V.Wicherhauser, “Entropy-based algorithms for best basis selection”, IEEE Trans, Inf. Theory, Vol.38, No.2, pp.713-718, 1992
- [124] N.Saito, R.R.Coifman, F.B.Geshwind, and F.Warner, “Discriminant feature extraction using empirical probability density estimation and a local basis library”, Pattern Recogn, Vol.35, pp.2841-2852, 2002
- [125] B.G.Hu, R.G.Gosine, L.X. Cao, and C.W.de Silva, “Application of a fuzzy classification technique in computer grading of fish products”, IEEE Trans. Fuzzy Syst., Vol.6, No.1, pp.144-152, 1998
- [126] L.Y.Cai and H.K.Kwan, “Fuzzy classification using fuzzy inference networks”, IEEE Trans Syst, Vol.28, No.3, pp.334-347, 1998
- [127] U.Himmelreich, R.L.Somorjai, N.Dolenko, O.C.Lee, H.M.Daniel, C.E.Mountford, and T.C.Sorrell, “Fast identification and chemical characterization of Candida species using nuclear magnetic resonance spectroscopy and a statistical classification strategy”, Appl Environ Microbiol, Vol.69, pp.4566-4574, 2003
- [128] N.J.Pizzi, “Fuzzy pre-processing of gold standards as applied to biomedical spectra classification”, Artif.Intell.Med, Vol.16, pp.171-182, 1999

# 研究業績

## 学術論文(査読付き)

- (1) “シートベルトからの体圧変化情報に基づくドライバの運転姿勢推定”  
今井章博, 時津直樹, 小栗宏次, 電気学会論文誌 C, Vol.130, No.12, pp.2118-2123,  
2010/12  
(採録)
- (2) “居眠り運転時の特徴的な眠気推移傾向を組み込んだ眠気レベル推定手法の提案”  
今井章博, 小栗宏次, 電子情報通信学会論文誌 D, Vol.96-D, No.4, pp.1012-1019,  
2013/4  
(採録)

## 国際学会

- (1) ” Estimation of Driver’ s Action by using Air Mass Flow Sensor on the Seat Belt”  
Akihiro Imai, Naoki Tokitsu, Koji Oguri, 16th ITS world congress (ITSWC2009),  
Stockholm(Sweden),(2009)
- (2) “ Estimation of Driver’s Drowsiness Level Considering a Characteristic  
Sleepiness Trasition of Drowsy Driving” Akihiro Imai, Koji Oguri, 20<sup>th</sup> ITS world  
congress (ITSWC 2013), Tokyo, (2013)

## 特許

特許名 : 状態推定装置, 状態推定方法及びプログラム  
公告白番号 : WO2012118206A1  
出願番号 : PCT/JP2012/055462

## 国内研究会

- (1) ” ECOC 法を用いた空気流量センサ情報からのドライバ姿勢推定” 今井章博, 時津直樹, 小栗宏次, 電子情報通信学会(IEICE), 信学技報, Vol.109, No.58, pp.31-36, (2009)
- (2) ” 自動車運転時のドライバ姿勢変化による運転パフォーマンスへの影響評価” 今井章博, 時津直樹, 小栗宏次, 電気関係学会東海支部連合大会, ITS, O-374, (2009)
- (3) ” シートベルトからの体圧変化情報によるドライバの姿勢推定” 今井章博, 時津直樹, 小栗宏次, 第7回情報学ワークショップ(WiNF2009), pp.107-112, (2009)
- (4) “シートからの座面圧力変化に基づくドライバの居眠り運転検知” 今井章博, 小栗宏次, 電子情報通信学会, 信学技報, ITS110(420), pp.147-152, (2011)
- (5) “覚醒低下の段階変化を考慮したドライバの眠気レベル推定” 今井章博, 小栗宏次, 電子情報通信学会, 信学技報, Vol.110, No.469, pp.47-52, (2011)