

平成28年度 博士学位論文

生体情報解析による
ドライバモニタ技術の高度化に関する研究

指導教員

主査	小栗 宏次	教授
副査	戸田 尚宏	教授
副査	何 立風	教授

愛知県立大学大学院 情報科学研究科 博士後期課程
平成26年度入学 2014841004

岸本 圭史

目次

第1章	序論	1
1.1	研究の背景と目的	1
1.1.1	運転行動のモデル化によるドライバー行動予測に関する研究	4
1.1.2	生体信号解析による注意力低下状態の検出に関する研究	5
1.1.3	脈波からの血圧推定技術の高精度化に関する研究	5
1.2	本論文の構成	6
第2章	ITSによる交通事故低減への取り組み	7
2.1	安全技術とITS	7
2.2	各国のITSプロジェクト	8
2.2.1	日本におけるITSプロジェクト	8
2.2.2	米国におけるITSプロジェクト	11
2.2.3	欧州におけるITSプロジェクト	11
2.2.4	実用化された各車両メーカーの最新安全技術	12
2.3	ドライバーモニタリングに関する研究事例	17
2.3.1	眠気・疲労検知研究	17
2.3.2	不注意運転検知研究	18
2.3.3	運転行動予測研究	19
第3章	運転行動のモデル化によるドライバー行動予測	21
3.1	本研究で用いるモデリング手法	21
3.1.1	Dynamic Bayesian Network	21
3.1.2	Dynamic Bayesian Networkで記述できるモデル構造	26
3.2	運転行動のモデリングによる停止確率予測	28
3.2.1	Dynamic Bayesian Networkに基づく運転行動モデリング	28
3.2.2	先行研究のモデリング手法	28
3.2.3	過去の運転行動を考慮した運転行動のモデリング	29
3.2.4	停止確率予測	32
3.2.5	運転データ取得実験	35
3.2.6	考察	40
3.2.7	被験者別の停止確率予測結果	42
第4章	生体信号解析による注意力低下状態の検出	45
4.1	パターン認識とは	45
4.1.1	Support Vector Machine	46

4.1.2	弱学習器の集団学習	51
4.2	パターン認識に基づく生体情報からの Cognitive Distraction 検知	62
4.2.1	視覚情報	62
4.2.2	心臓と心電図	65
4.2.3	生体情報計測機器	66
4.2.4	Cognitive Distraction 模擬実験	69
4.2.5	取得データに対するノイズ処理	71
4.2.6	特徴量抽出とその評価	77
4.2.7	パターン認識による学習と検知性能評価	86
4.2.8	特徴量追加の効果	90
4.2.9	考察	94
4.3	負担度を考慮した Cognitive Distraction 検知への応用	97
4.3.1	二値判別器の拡張による多値判別法	97
4.3.2	負担度を考慮した Cognitive Distraction 検知手法	99
4.3.3	考察	101
第 5 章	脈波からの血圧推定技術の高精度化	103
5.1	血圧の原理と測定方法	103
5.1.1	血圧概要	103
5.1.2	血圧の基準と高血圧症	103
5.1.3	血圧測定法	107
5.2	光電容積脈波を用いた血圧値推定	111
5.2.1	脈波と循環動態との関係	111
5.2.2	脈波と血圧値の計測実験	112
5.2.3	血圧値推定手法	116
5.2.4	血圧値推定結果	120
5.2.5	考察	122
5.3	非線形手法を用いた血圧推定の拡張	127
5.3.1	学習データの分割とオーバーラップによる補正学習	127
5.3.2	学習の信頼度に基づくデータ選別	133
第 6 章	結論	137
	謝辞	139
	参考文献	140
	本研究における学外発表	149

第1章 序論

1.1 研究の背景と目的

1885年、ダイムラー（独）により自動車は実用化され、その後1908年にフォードによる大量生産が開始されたことで世界に急速に普及し、人々の便利な移動手段として幅広く受け入れられることとなった。自動車は便利な反面、交通事故、環境負荷物質の排出といったマイナスの部分が存在する。このようなマイナス面を取り除くために自動車は100年以上に渡り進化を続けているものの、ガソリン駆動、ドライバーによる運転といった根本的な構造については変化がない。自動車は近代産業を支える重要な基盤技術であるため、モータリゼーションのさらなる進展は必須といえる。

近年における技術の発展により、自動車の根本的な部分について変革が進んでいる。ガソリン駆動についてはハイブリッドエンジンおよび電気自動車が既に実用化されており、環境負荷物質低減が進められている。ドライバーによる運転についても様々な安全運転支援システムが発達し、衝突回避ブレーキ、車線逸脱防止といった運転操作の一部の自動化が進んでいる。最終的にはドライバーが運転操作を行わず、加速・操舵・制動を全て自動車自身で行う自動運転システムの構築を目指し、産学官が連携して技術開発を行っている。

自動運転システムを巡って、近年においてはGoogleによるデモンストレーションが話題となり、世界各国の関心を集めている。Googleは2009年より自動運転車両開発をスタートし、実験レベルではあるが完全自動運転で公道での走行を果たしている。我が国においても自動走行システムの構築を目指すべく、政府発表の官民ITS構想・ロードマップ[1]において官民連携による自動走行システムの開発やその普及に向けた環境整備の指針が発表された。この指針では自動化型をレベルに応じて表1.1で示す4段階に分類している。レベル1を「安全運転支援システム」と定義し、これにはドライバーへ注意喚起を行う情報提供機器も含まれる。レベル2~4が「自動走行システム」と定義されるが、その中でレベル2とレベル3が「準自動走行システム」とし、レベル4のみを「完全自動走行システム」としている。これは準自動走行システムまでは原則としてドライバーが最終責任を有するのに対し、完全自動走行システムではシステム（ドライバー以外）が最終的な責任を有するためである。自動走行システムを実現するためには技術開発だけでなく、自動車が無人で走行することに対する社会的な受容や制度を検討する必要があるため、導入にはハードルが高いといえる。現時点で実用化されている技術はレベル1とレベル2の一部であり、レベル3~4は2020年代以降の市場化が期待されている。

表 1.1: 安全運転支援システム・自動走行システムの定義

分類	概要	システム例
レベル1: 単独型	加速・操舵・制動のいずれかの操作をシステムが行う	・衝突軽減ブレーキ ・歩行者情報提示
レベル2: システムの複合化	加速・操舵・制動のうち複数の操作を一度にシステムが行う	・追従追尾システム ・衝突回避のためのステアリング ・複数レーンでの自動走行
レベル3: システムの高度化	加速・操舵・制動を全てシステムが行い、システムが要請した時のみドライバーが対応する	・自動合流
レベル4: 完全自動走行	加速・操舵・制動を全てシステムが行い、ドライバーが全く関与しない	・完全自動走行




図 1.1: 2015 年までの交通事故発生件数・死者数・負傷者数の推移 [16]

この様に自動運転システムの検討が急速に進んでいる背景には、近年における交通事故の発生状況が挙げられる。図 1.1 に警察庁より発表された 2015 年までの交通事故発生件数、死亡者数、負傷者数の推移を示す。それぞれの件数および人数は近年において減少傾向であったが、死亡者数が 2014 年では 4,113 人であったことに対し 2015 年で 4,117 人となり、15 年ぶりに増加に転じた。内閣府が掲げた第 9 次交通安全基本計画における目標である「平成 27 年までに 24 時間死者数を 3,000 人以下」を達成することができなかったため、「世界一安全な道路交通の実現」を目指している我が国にとってはこの事態を厳しく受

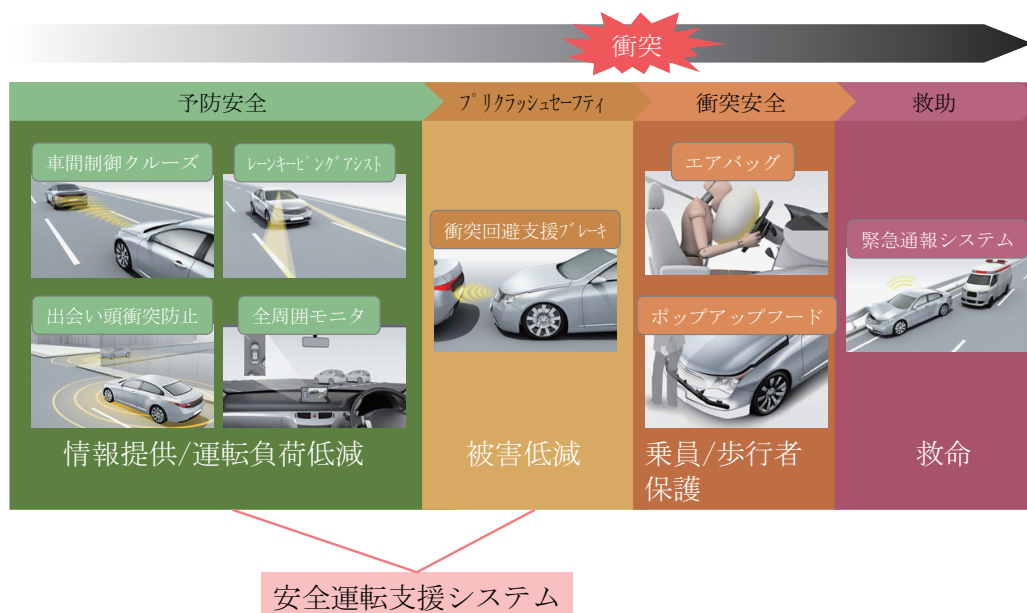


図 1.2: 実用化されている自動車の安全技術

け止める必要がある。

交通事故による死者数の大半は安全運転義務違反（運転操作不適，漫然運転，脇見運転，安全不確認等）によるものであり，全体の 57.6%を占める [1]。これに酒酔い運転，一時不停止，信号無視等を含めると，ドライバーが係わることによる交通死亡事故は全体の 65%を占めることになる。自動運転が実現できればドライバー起因の交通事故をゼロにすることができるが，完全な自動走行は 2030 年以降に実用化が始まると見られており，それまでは別の技術によって事故低減を図る必要がある。近年，先進運転支援システム（ADAS:Advanced Driving Assistant System）と呼ばれる安全技術に注目が集められ，自動車の安全性を高める様々な技術開発が進められている。

これまでに実用化されてきた自動車の安全技術の例を 1.2 に示す。安全技術は「予防安全」，「プリクラッシュセーフティ」，「衝突安全」，「救助」の 4 つに大別され，衝突を回避するための安全運転支援システムは「予防安全」と「プリクラッシュセーフティ」である。これらの安全運転支援システムに欠かせない技術がセンシング技術である。GPS データの活用，カメラの高解像度化，無線技術の発達等により，自動車の周辺環境を取り巻く事故の発生要因をいち早く検知し，ドライバーを安全に導くことが可能となった。自動車の周辺環境だけでなく，事故発生要因の大半を占めるドライバー自身のセンシング技術も近年急速に発達しつつある。人の視線や瞼の開閉度を検知するカメラ技術，座るだけで心電図を取得できる体圧センサ埋め込み式シート，脈波を容易に取得できる脈波計内蔵ステアリング等のセンシング技術で，ドライバーの生体データを容易に取得可能となった。ドライバーの生体データから，事故に繋がる様々な行動を検知することが可能になりつつある。

本研究では，この様なドライバーの行動や状態を検知する技術を情報科学により更なる高度化を目指す。情報科学技術の一つである信号処理により，「運転状態検知の高度化」，「センシング技術の高度化」に焦点を当てた。

「運転状態検知の高度化」については、交通死亡事故原因の第一位である「漫然運転」と第二位の「運転操作不適」に着目した。漫然運転は考え事や注意散漫といった「認知行動の遅れ」、または眠気や疲労の蓄積といった「生理的变化」によって発生する。運転操作不適は、停止行動の遅れや急加速といった不適切な運転行動によるものである。本研究ではドライバーの生体データを用いて、これらの事故要因の検知を行った。

また「センシング技術の高度化」については、緊張やストレスと関係がある「血圧」のセンシング技術の高度化を行った。

本論文の研究テーマを次の3つとする。テーマ1は「ドライバーの行動予測」、テーマ2は「注意散漫な状態 (Cognitive Distraction) の検知」、テーマ3は「光電容積脈波を用いた血圧推定」、とする。

1.1.1 運転行動のモデル化によるドライバー行動予測に関する研究

運転操作不適による事故を回避するための安全技術として、ブレーキ操作支援が挙げられる。ブレーキ操作支援は必ずしもドライバーが必要としている場合にのみ動作するとは限らないため、支援機能がかえってドライバーにとって不快なものになってしまうことがある。ドライバーオリエンテッドで考えた場合、ドライバーが次に行うであろう運転行動を予測することで支援機能の動作タイミングをアダプティブにすることが可能になり、ドライバーにとってより快適に安全を提供することが可能になると考えられる。

ドライバーの運転行動予測に関する研究は近年盛んに行われている [2]~[13]。Petlandら [5] は Switching Kalman Filter Model を用いて模擬的な運転行動推定を行っている。熊谷ら [6][7] は Dynamic Bayesian Network を基に展開した HMM (Hidden Markov Model) と SLDS (Switching Linear Dynamical System) を用いて、ドライバーの停止行動を予測する事について論じている。阿部ら [8][9] は運転行動がドライバーの心理状態に大きく影響されることに着目し、ドライバーの自律神経活動から推定された心理状態に基づく行動予測を行っている。これらの研究ではいずれもドライバーの直前の行動から次の行動を予測している。しかし、人間の複雑な行動はプリミティブな動作（基本動作）の合成で表される [14][15] という観点から、人間の行動を捉えるためには直前の行動のみを考慮するよりも、過去の一連の行動の流れを考慮することによって、より高精度な行動予測が可能となると推測される。従って運転行動を予測する場合においても、過去からの運転行動の連続性を考慮した上で次の運転行動を予測することは有効であると考えられる。

本研究では車両速度およびペダル操作量から、過去の一連の運転行動を考慮したフィードバック型の運転行動モデルを構築した。そのモデルを用いて運転行動シミュレーションを行い、シミュレーション結果に基づくドライバーの運転行動予測を行った。予測する運転行動は事故回避に最も有効である「停止行動」とし、走行中の車両がブレーキ操作によって一定速度まで減速してから何秒後に停止するかの予測を試みた。また、本研究では事故が最も発生しやすい道路形状は交差点であること [16] に着目し、特に交差点付近での停止行動の予測を行った。

これに加えて、過去何秒間の運転行動を考慮することが停止行動予測に最も有効であるかを検討した。さらに、運転行動モデルの個人適合理化、および運転傾向がモデルに与える影響について考察した。

1.1.2 生体信号解析による注意力低下状態の検出に関する研究

事故を低減させるための予防安全技術として、インフラからの情報提供、車両周辺監視システム、ドライバーモニタリングシステム等が提案されている。国土交通省の調査によると、事故の多くは「発見の遅れ」、「判断の誤り」といった事故直前のドライバーの行動に起因するとしている [17] ため、ドライバーモニタリング技術による予防安全技術は事故を低減のための有効な手段といえる。

宮治ら [18] の報告によると、交通事故の潜在危険を孕むヒヤリハット要因の多くは注意力低下による漫然運転であるとしている。このことから、ドライバーが注意散漫となり、運転に集中ができない状態 (Distraction) を検知するドライバーモニタリング技術が求められる。Distraction の中でも会話や思考による認知負荷に係わるものは Cognitive Distraction と呼ばれ、中でも事故原因の多くは Cognitive Distraction であるため、現在 Cognitive Distraction 検出に関する研究が盛んに行われている。Kutilla ら [19][20][21] は、運転中のドライバーに暗算等の課題 (サブタスク) を与えることで Cognitive Distraction を模擬し、Cognitive Distraction 時のドライバーの視覚情報をパターン認識手法の一つである Support Vector Machine (SVM) を用いてドライバーの状態検知を行った。

現段階におけるこれらの検知研究では、通常状態と認知的負荷状態の二種類を判別するだけに止まっており、ドライバーがどのような認知的負荷状態であるかを判別することは行っていない。実用システムを考えた場合、認知的負荷状態の種類を正確に検知することができれば、負荷の種類に応じた安全機能を選択することができ、ドライバーにとってより適切な運転支援を提供することが可能になると考えられる。パターン認識手法に基づいてドライバーの生体情報を分類することで、ドライバーの認知的負荷状態を多クラスに識別する手法を提案する。車載環境でのリアルタイム検出を実現するために、パターン認識手法として多値判別が可能であり、計算コストの少ない ECOC 法 (Error-Correcting Output Coding) を採用した。さらに、ECOC 法を拡張することで検知精度の向上を図った。実験において、提案手法による従来の ECOC 法に対する検知性能を比較検証した。

1.1.3 脈波からの血圧推定技術の高精度化に関する研究

運転中のドライバーは精神的緊張やストレスを常を感じながら運転操作を行っている。緊張やストレスは急ぎ運転、あるいは操作ミス等の非安全行動に繋がるため、取り除かれることが望ましい。また緊張やストレスは交感神経の緊張から血管収縮となり、血圧の上昇を引き起こすことが知られている。小野らの調査によると、安全運転時と乱暴運転時 (スラローム走行) とを比較すると最高血圧が平均で 25mmHg 上昇するとしている [22]。運転中における血圧上昇はドライバーの潜在的な事故要因と関連することから、運転中の血圧をモニタリングし、ドライバーに注意喚起を促すことができれば事故低減に繋がると考えられる。

血圧の計測方法は上腕にカフを巻いて測定する方法が最も一般的であるが、拘束性が高く、長時間の計測を行うことが困難である。近年、比較的簡易に測定ができる脈波を解析することで、血圧値を推定する手法が多く提案されている。脈波とは、心臓から駆出された血液の衝撃により生じた動脈の脈動が末梢へ伝搬する波のことである [23]。この脈動の伝搬速度 (PWV: Pulse Wave Velocity) が動脈の硬さを評価する指標として、臨床分野におい

て用いられる [24]. PWV は心電図と脈波を計測し, 各々の変曲点の時間差 (PTT : Pulse Transmission Time) から求めることができる. 血管に十分な伸展性がある場合において脈動の伝搬は遅く, 動脈硬化が進むにつれて脈動の末梢への伝搬は速くなる. PWV を用いた血圧値推定に関する研究として, Espina ら [25] は, 腰に巻いたベルトから取得した心電波形と, 耳に装着したクリップ型のセンサから得られる脈波を用いて, 連続的な血圧モニタリングを行っている. Sheng ら [26] はクリップ型の脈波計を耳と指先に装着し, PTT から血圧値推定を行っている. 鈴木ら [27] は光電容積脈波 (PPG : photoplethysmography) からパラメータを抽出し, 重回帰分析により血圧値を推定している.

いずれの研究においても推定手法として線形手法を用いているため, 非線形性を有するパラメータに対して十分な回帰を行うことができない. Sakanashi ら [28] によると血管壁の材料特性は非線形性を有するとしており, 血圧と脈波とは非線形な関係があると考えられる. 本論文ではパラメータの非線形性に対応した回帰手法である非線形重回帰分析, 及びサポートベクター回帰を用いて血圧値を推定し, 従来の線形手法による推定値と比較を行った. さらに補正学習手法を適用することで, JIS 規格である推定精度の誤差標準偏差を 8mmHg 未満とすることを目指した.

1.2 本論文の構成

本論文は大きく 6 章で構成される. 第 1 章～第 2 章は序論と研究背景, 第 3 章はドライバーの停止行動予測の研究, 第 4 章は注意散漫な状態 (Cognitive Distraction) の検知に関する研究, 第 5 章は脈波からの血圧値推定に関する研究, 第 6 章では結論を述べる.

詳細を下記に示す.

第 2 章では世界各国の ITS プロジェクトと, 本研究に関連するドライバーモニタリング技術に関する基礎研究について述べる.

第 3 章ではドライバー行動予測で必要となる, モデリング技法の一種である Dynamic Bayesian Network と, Hidden Markov Model と Auto-Regressive Hidden Markov Model のモデル構造について述べる. その後, AR-HMM に基づくドライバー行動予測の手法と, 停止行動予測結果について述べる.

第 4 章では Cognitive Distraction 検知に用いたパターン認識手法である SVM と AdaBoost について解説する. 次に SVM, AdaBoost による検知結果を示し, さらにドライバーの負担度を考慮した Cognitive Distraction 検知への応用について述べる.

第 5 章ではまず血圧の原理と脈波について, 次に血圧の推定手法と推定結果, さらに推定精度向上のための推定手法の拡張について述べる.

最後に, 第 6 章で本研究のまとめと考察を述べる.

第2章 ITSによる交通事故低減への取り組み

2.1 安全技術とITS

ITS（高度道路交通システム：Intelligent Transport Systems）は最先端の情報通信技術などを用いて、人・道路・自動車を一体のシステムとして構築するものであり、安全運転の支援、交通管理の最適化、道路管理の効率化などを図るものとしている（図2.1）。中でも交通事故の低減は世界各国において最重要課題とされており、ITSによる事故低減が大きく期待されている。

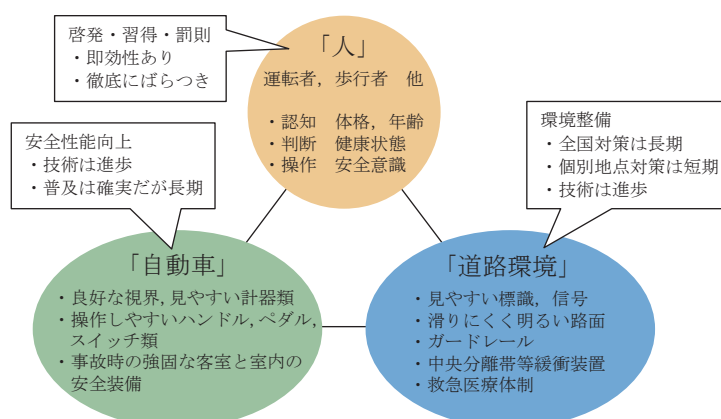


図 2.1: ITS のコンセプト [29]

日本においては内閣府が「交通安全基本計画 [30]」を策定し、交通事故低減に向けた計画を掲げている。2006年3月の第8次交通安全基本計画では「2012年までに交通事故死亡者を5,000人以下とし世界一安全な交通の実現を目指す」という目標に対して、その実績は4,948人であり、計画通りの減少を示している。しかし、2011年3月に第9次交通安全基本計画で掲げた「交通事故による死者数3,000人以下」という目標に対しては実績が4,117人であり、減少はしているものの目標未達となった。このような交通事故による死者数が減りにくい背景として、

- (1) 高齢者人口の増加
- (2) シートベルト着用率の頭打ち

表 2.1: 各国の交通事故低減目標

	交通安全目標	関連施策・法規
日本	2020 年までに 24 時間交通事故死亡者を 2,500 人以下 2020 年までに交通事故負傷数を 50 万人以下	第 10 次交通安全基本計画 (2016 年中央交通安全対策会議)
米国	2020 年まで交通事故死亡者数 30,000 人以下	米・陸上交通長期予算法 (2015 年 Fixing America's Surface Transportation Act)
欧州	2020 年までに道路事故を半減 2050 年までに道路事故の死者数をゼロに近づける	2011 年 EU 交通白書

(3) 飲酒運転による交通事故件数の下げ止まり

等が挙げられる。高齢者社会が進む中で、高齢者ドライバーによる事故の対策が今後重要となってくる。

2016 年 3 月の第 10 次交通安全基本計画において、以下の新しい目標が掲げられた。

- (1) 2020 年までに 24 時間死者数を 2,500 人以下とし、世界一安全な道路交通を実現する。
- (2) 2020 年までに死傷者数を 50 万人以下にする。

この年間の 24 時間死傷者数 2,500 人に、2015 年の 24 時間死者数と 30 日以内死傷者の比率 (1.18) を乗ずると約 3,000 人となる。この場合、人口 10 万人当たりの 30 日以内死傷者数は 2.4 人となる。国際道路交通データベース (IRTAD) が公表しているデータによると、2013 年の日本における 30 日以内死傷者数は 4.0 人であるが、2020 年に 2.4 人にまで下げることができれば世界で最も少ない国となる。交通安全基本計画の最優先の目標は死傷者の減少であるが、事故そのものの減少や死傷者数の減少にも取り組み、2020 年までに年間の死傷者数を 50 万人以下とすることを目指す。

また、米国、欧米においても、交通事故低減に向けての長期計画を掲げており、各種の施策や法規が制定されている (表 2.1)。1990 年代後半からテレマティクス (道路交通情報提供による道路交通問題の解決) に係わる諸プロジェクトが世界的に推進されたが、2000 年を過ぎた頃から、研究開発の主眼は道路交通安全問題の解決に置かれるようになった。現在は、政府、産業界、大学・研究機関が連携して、交通事故低減目標達成に向けて様々なプロジェクトが世界各地で取り組まれている。

以下の節より、世界各国の代表的な ITS プロジェクトの概要と、ドライバーモニタリングによる安全運転支援に対する取り組みについて述べる。

2.2 各国の ITS プロジェクト

2.2.1 日本における ITS プロジェクト


初期の ITS プロジェクト

日本の ITS 技術開発の着手は世界的に早く、1973 年には通産省 (現・経済産業省) で CACS (Comprehensive Automobile Traffic Control. System : 自動車総合管制システム)

と呼ばれる自動車の経路誘導システムなどの実証実験が行われた。その後は、警察庁、運輸省（現・国土交通省）、建設省（現・国土交通省）、郵政省（現・総務省）主導で研究開発、実証実験が行われた。1995年2月に「高度情報通信社会推進本部」において「高度情報通信社会推進に向けた基本方針」が示され、ITSの推進が政府の計画に明確に位置づけられた。これを受け、関連五省庁（警察庁、通商産業省、運輸省、郵政省、建設省）が協力して、「高度道路交通システム（ITS）推薦に関する全体構想」が制定された。

1996年公表の全体構想では、日本において実現すべきITSの将来像が20の利用者サービス（後に21番目の利用サービスが追加された）として2015までの計画としてまとめられた（表2.2）。

表 2.2: ITS21 の開発分野と開発・展開計画 [29]



日本において初期に発足したプロジェクトとして、ASV（Advanced Safety Vehicle:先進安全自動車）、AHS（走行支援道路システム:Advanced Cruise-Assist Highway Systems）、DSSS（安全運転支援システム:Driver Safety Support Systems）が挙げられる。

ASVは国土交通省自動車交通局による安全自動車に関する研究開発プロジェクトで、1991年から5ヵ年計画で進められた。ASVでは、乗用車、トラック・バス、二輪車の実用可能な安全装置を順次開発し実用化するとともに、運転支援システムの基本理念とその考え方を整理し、技術指針を策定した。

AHSはドライバーの安全運転を支援することを目的とした、国土交通省道路局主導のプロジェクトである。ここでは、情報表示板などを利用して危険情報を提供するシステムや、危険な状況に対応して自動車が自動的にハンドル・ブレーキを操作するシステムの研究が進められた。

DSSSは警察庁が主体となったプロジェクトであり、UTMS（Universal Traffic Manage-

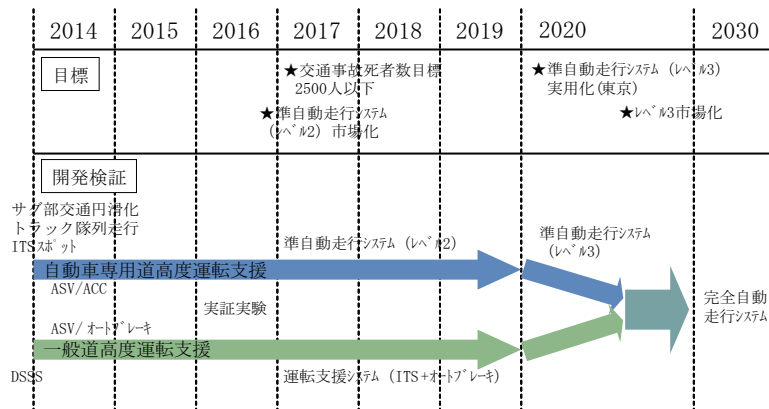


図 2.2: SIP の自動走行システム開発ロードマップ

ment Systems：新交通管理システム）のサブシステムの一つとして位置付けであった。これは交差点における交通事故の減少やドライバーの判断負荷の軽減を目指して、速度情報提供システム、右折衝突警報システム、追突防止システムなどの開発・実証実験が行われた。

近年の ITS プロジェクト

近年は情報通信技術の進歩と様々なデータ活用により、ITS 発展の過渡期にある。2014 年に策定された「世界最先端 IT 国家創造宣言」において、「車の自律系システムと道路との情報交換等を組み合わせ、運転支援技術の高度化を図るとともに、実用化に向けた公道上での実証を実施し、2020 年代中には、自動走行システムの試用を開始」との目標が掲げられ、多くの国内メーカーが自動走行システムの実用化・普及に向けた競争を進めている。このような中、政府は 2014 年から戦略的イノベーション創造プログラム（以下、SIP）において自動走行システムの研究開発計画を発表し、官民連携による研究開発が進められている。これまで国において検討されてきた自動走行システムは主に自動車専用道での支援が議論の中心であったが、これはエリアを絞ることにより技術的なハードルを下げるためであった。しかし現在掲げている交通安全目標（表 2.1 参照）を達成するためには一般道も対象とする必要がある。SIP では自動車専用道と一般道の双方を対象とした自動走行システム開発ロードマップを公表している。2010 年代半ばを目途に準自動走行システム（レベル 2^{注 1}）を市場化、2020 年代前半にはレベル 3^{注 2}を市場化、さらに 2020 年代後半以降には完全自動走行システムの市場化を目標としている。

具体的な研究項目は表 2.3 に示す。これらの研究項目を進めることで自動走行システムによる事故・渋滞の低減、利便性の向上を目指している。

注 1 加速・操舵・制御のうち複数の操作を同時に自動車が行う状態

注 2 加速・操舵・制御を全て自動車がいき、緊急時のみドライバーが対応する状態

表 2.3: SIP における自動走行システムの研究開発内容

(1) 地図情報高度化(ダイナミックマップ)の開発	自動走行システムを実現するために必要な交通状況(交通規制, 車両, 歩行者等)の情報, 周辺構造物, 衛星測位等を統合した地図データベースの開発実用化
(2) ITS による先読み情報の生成技術の開発と実証実験	車両が自らの進路上の交通環境を適切に把握して, 必要な制御や支援を実現(例: 信号情報等の動的な交通管理情報の取得, 歩行者通信端末による歩行者の動静状況把握と歩行者への移動支援)
(3) センシング能力の向上技術開発と実証実験	車両の環境認識センサー性能の高度化, 高度画像認識性能評価に供する映像認識システムの開発等
(4) ドライバーと自動走行システムのHMI技術の開発	システムと運転者の意思疎通(HMI: Human Machine Interface)を図るための, ドライバーとシステムの操作介入・権限移譲等のHMI技術の開発
(5) システムセキュリティの強化技術の開発	車車間, 路車間, 歩車間通信等へのセキュリティシステム開発

2.2.2 米国における ITS プロジェクト

米国における車両一台についての走行距離 (mile) 当たりの交通事故死亡者数は, 1972 年の 54,589 人をピークに減少傾向を示している。これは車体の衝撃吸収性能の向上, ABS 等の車両安全システムの装備, 交通法規強化, 飲酒やシートベルト着用取締りの効果などが効果をあげているためである [32]。人口の増加に伴い, 1990 年代から 2000 年代前半にかけて交通事故死亡者数は一旦増加傾向を示したが, 2014 年の時点で 32,675 人まで減少している。近年は下げ止まり傾向であり, 2009 年から 2014 年にかけて 32,000 人付近で推移している。

米国政府では, これまでに ITS プロジェクトとして ISTEA (Intermodal Surface Transportation Efficiency Act), TEA-21 (Transportation Equity Act for the 21st Century), SAFETEA-LU (Safe, Accountable, Flexible, Efficient Transportation Equity Act: A Legacy for Users), MAP-21 (Moving Ahead for Progress in the 21st Century), FAST Act (Fixing America's Surface Transportation Act) を提案してきた。表 2.4 に各プロジェクトの概要をまとめる。

2.2.3 欧州における ITS プロジェクト

EU25ヶ国全体の統計 [33] によると, 欧州における交通事故死亡者数は 1990 年に 70,700 人であったことにに対し, 2015 年には 26,000 人まで減少している。2011 年に EU 交通白書 [34] で定められた「2020 年までに交通事故死亡者数を半減する」という目標値達成が期待されている。欧州の交通事故減少の要因も, 日本や米国と同様に, 衝突吸収性能の向上, ABS 等の車両安全システムの装備, 飲酒・シートベルト着用等の取締りの強化が効果を上げていと報告されている。欧州においても, さらなる交通事故死亡者数低減のための各種 ITS プロジェクトが制定されている。

欧州の ITS プロジェクトは FP (Framework Program) という名称で, 1984 年より 5 年前後の期間でまとめられている。近年においては FP5 (1999-2002), FP6 (2002-2006), FP7 (2007-2014) の各プロジェクトが施行された。概要を表 2.5 にまとめる。

表 2.4: 米国における ITS プロジェクト

予算	成果
ISTEA (FY1993-1997) \$1,553 億	<ul style="list-style-type: none"> ・ ITS の国家アーキテクチャ構築 ・ 自動走行技術の研究開発 ・ 電子料金収受システム (EZPass) 開発
TEA-21 (FY1998-2003) \$2,180 億	<ul style="list-style-type: none"> ・ IVI (Intelligent Vehicle Initiative) プロジェクト制定 (高精度マップ, 協調型安全システム, 運転者の作業負担定量化) ・ 交通情報配信サービス (511 交通情報) を展開 ・ ドライバーディストラクションに関するガイドライン制定 ・ 5.9GHz 帯域の無線通信技術の開発
SAFETEA-LU (FY2005-2009) \$2,864 億	<ul style="list-style-type: none"> ・ 協調型 ITS 安全システム技術の研究開発 ・ 次世代緊急通報の試験実施 ・ 複数の警報システムの統合 ・ 協調型交差点事故防止システムの開発 ・ 5.9GHz インフラの展開
MAP-21 (FY2012-2014) \$1,050 億	<ul style="list-style-type: none"> ・ 新設州際道路の有料化を事業認可 ・ 公共交通機関の全国的な安全基準制定
Fast Act (FY2016-2020) \$3,050 億	(施行中)

2014 年 1 月より, FP7 の後継フレームワークプログラムである Horizon 2020 が開始された。期間は FP7 と同様に 7 年間 (2014-2020) である。全体の予算は FP7 の 532 億ユーロに比べて 770 億ユーロに増額されているが, 研究開発予算は FP7 時と同等程度かやや減少すると見られている。

2.2.4 実用化された各車両メーカーの最新安全技術

トヨタ自動車

トヨタ自動車は予防安全技術のパッケージである「Toyota Safety Sense」を開発。トヨタブランド車におけるコンパクトカー向けには「Toyota Safety Sense C」, ミディアム・上級車向けには「Toyota Safety Sense P」, レクサスブランド車には「Lexus Safety System +」を設定する。これまでトヨタの予防安全装備は上級車に限定して設定されているが, コンパクトカーを含め 3 年間で安全運転装備の広範的な普及を目指すとしている。2015 年から導入を開始し, 2017 年までに日本, 北米, 欧州のほぼ全ての乗用車に設定する。

各予防安全技術について表 2.6 に示す。コンパクトカー向けの「Toyota Safety Sense C」は比較的安価なレーザーレーダーとカメラを用いることで, 衝突回避支援型 PCS (Pre-crash safety), レンディパーチャアラート, オートマチックハイビームを実現している。中型車以上向けの「Toyota Safety Sense P」においてはミリ波レーダーを採用し, PCS の作動領域を向上させている。レクサス向けの「Lexus Safety System +」は「Toyota Safety Sense P」とほぼ同じであるが, LDA の機能アップを図っている。

その他の安全技術として「LED アレイ AHS」, 「シースルービュー」, 「協調型運転支援システム」が挙げられる。「LED アレイ AHS」は LED を細かく制御することで先行車および

表 2.5: 欧州における ITS プロジェクト [35]

FP5	プロジェクト内容	期間
ADASE	・ 予防安全システムの開発推進	01.8 - 04.9
AWAKE	・ ドライバー不注意予防警報システム開発	01.9 - 04.8
PROTECTOR	・ 歩行者モバイル機器との協調安全システム開発	01.1 - 02.12
SAVE-U	・ 歩行者・自転車検知, 警報システム開発	02.3 - 05.2
ACTMAP	・ 車載デジタル地図のリアルタイム更新技術の開発	02.4 - 04.9
CARTALK	・ 車車間通信を用いた運転支援システム開発	01.8 - 04.7
FP6	プロジェクト内容	期間
AIDE	・ 高性能な HMI を開発	04.3 - 08.2
PReVENT	・ 車載危険予知センサー, 通信機器の開発	04.2 - 08.9
HUMANIST	・ ドライバー行動, 認知, HMI の研究	04.3 - 08.2
EASIS	・ 車載システム構成の標準化	04.1 - 06.12
SENSATION	・ 居眠り, 眠気を主体とした生体信号解析	04.3 - 08.2
Cooperative Systems	・ 路車協調システムの開発	05.8 - 06.9
FP7	プロジェクト内容	期間
SAFERIDER	二輪ドライバ向けインタフェース開発	08.1 - 10.12
HAVE-IT	次世代 ADAS (先進運転支援システム) 開発	08.2 - 11.7
INTERSAFE-2	通信を利用した交差点安全システムの開発	08.6 - 11.5
INTERACTIVE	アプリ統合化による安全運転支援システムの開発	10.1 - 13.6
UDRIVE	ドライバ行動分析	12.10 - 16.9

対向車を眩惑を防ぎ、さらに従来よりも広い範囲の照射を実現する。また先行車と対向車がすれ違う際の両車間を照射し、横断歩行者などの発見を支援する。「シースルービュー」は車両を上から見下ろしたような映像をディスプレイに表示する。車両の外側から見下ろしたような映像を表示する従来の方式に加え、ドライバーの視線で車両を透かしたような映像を表示することができる。「協調型運転支援システム」は ITS の専用周波数 (760MHz) による路車間・車車間通信を活用することで車両単体では捉えきれない情報を取得し、事故低減を防ぐシステムである。路車間通信では見通しの悪い交差点周辺における対向車・歩行者の情報を収集する。車車間通信では先行車両の加減速情報を活用することで、従来のレーダークルーズコントロールの高度化を図る。

日産自動車

日産自動車は街中、駐車場、高速道路等のあらゆるシーンに対応する全方位セーフティ機能をユーザに提供すると訴求している。その中で特にエマージェンシーブレーキ (自動ブレーキ) の普及に努めており、安全技術に対する関心が高い。2015 年度中に日本で販売している EV、商用車を含むほぼ全ての車両にエマージェンシーブレーキ (自動ブレーキ) を設定するとしている。また、2020 年までに自動運転技術の段階的な実用化を目指しており、自動ブレーキの普及は自動運転につながる要素技術である「カメラ認知技術」や「操作自動化技術」による安全性をより早く市場に展開することを狙いとしている。日産自動車の自動ブレーキはミリ波レーダー方式、カメラ方式、レーザーレーダー方式の 3 種類を使い分けており、車種グレードにより搭載される方式が異なる (表 2.7)。

表 2.6: トヨタ自動車の予防安全装置

Toyota Safety Sense C

衝突回避支援型プリクラッシュセーフティ(PCS)	レーザーレーダーとカメラを用いて前方の障害物を検知し、衝突の危険がある場合、まずドライバーにブザーとディスプレイ表示で警報を出すことでブレーキを踏むように促す。ドライバーが衝突の危険に気づいてブレーキを踏んだ場合は、強力なブレーキアシストが作動。
レーンディパーチャーアラート(LDA)	カメラによって走行車線の白線や黄線を認識し、車線逸脱の可能性を検知した場合にはブザーとディスプレイ表示でドライバーに警報を出すことで、車線逸脱による衝突事故の回避を支援。
オートマチックハイビーム(AHB)	カメラによって対向車のヘッドランプ、または先行車のテールランプを検知し、ハイビームとロービームを自動で切り替えることで、他の車両のドライバーの眩惑を低減するとともに、自車の前方視界確保を支援。

Toyota Safety Sense P (ミディアム・上級車向け)

歩行者検知機能付衝突回避支援型プリクラッシュセーフティ	ミリ波レーダーとカメラを用いて前方の車両や歩行者を検出し、警報、ブレーキアシスト、自動ブレーキで衝突回避支援、および被害軽減を図る。Toyota Safety Sense C の作動最大速度は 80km/h であるが、最高速まで作動領域を広げている。
レーダークルーズコントロール	先行車との車間距離の検知にミリ波レーダーを使用し、設定車速内で先行車の車速に合わせて速度を調整することで一定の車間距離を保ちながら追従走行する。

Lexus Safety System +

レーンディパーチャーアラート(LDA)	電動パワーステアリングを制御し、車線内走行をしやすいようにドライバーのステアリング操作をサポートする。
---------------------	---

自動ブレーキ以外においては、車線逸脱警報、アラウンドビューモニター、踏み間違い衝突防止システムを、最近発売した多くの車種に設定している。これらの技術を活用することで全方位の予防安全を実現するとしている(表 2.8)。

ホンダ

ホンダは新たな安全運転システム「Honda SENSING」を開発し、2015年2月に発売した高グレード車種である新型 Legend にフルセットで搭載した。ミリ波レーダーと単眼カメラにより表 2.9 で示す 8 種類の安全装備を作動させる。その中で、「歩行者事故低減ステアリング」は世界初の技術として注目されている。センシング技術においては、ミリ波レーダーは角度を従来の 20 度から 30 度に広げることにより、電波の反射率が低く検知が難しいとされてきた歩行者にまで検知対象を拡大した。また、単眼カメラは車両前方約 60m までの歩行者や対象物の属性や大きさなどを識別、より精度の高い認識を可能にした。

普及グレード車種においてはシティブレーキシステムをコンパクトカーと軽乗用車に設定した。このシステムは低速走行中に前方車両に追突する可能性があるとしてシステムが判断した場合に作動し、自動的に停止または減速することにより衝突回避や被害軽減を図るものである。また Honda SENSING にある誤発進抑制機能と同様の機能も有する。

表 2.7: 日産自動車の自動ブレーキの方式比較

ミリ波レーダー方式	ミリ波レーダーで前方車両との衝突の危険を検知。ディスプレイ表示やブザーに加え、アクセルペダルの反力と緩やかなブレーキングによる体感的な警報でドライバーに回避操作を促す。万が一、ドライバーが回避操作を行わない場合には、緊急ブレーキを作動して衝突を回避、または被害を軽減する。
カメラ方式	フロントに配置したカメラが前方の車両や歩行者を検知。10～80km/h で作動し、自動的に停止または減速して、衝突回避または被害軽減を図る。30km/h 以下で衝突を回避する能力を有する。また停止車両と歩行者には 60km/h 以上では作動しない。
レーザーレーダー方式	赤外線レーザーレーダーで前方の車両を検知。衝突の危険性があるとメーター内の警告灯とブザーでドライバーに注意喚起するとともに、自動的に緊急ブレーキを作動させて衝突を回避または衝突の被害を軽減する。約 5～30km/h の範囲で作動し、約 15km/h 以下で衝突回避の能力がある。

富士重工

富士重工は 2008 年に世界初のステレオカメラのみによる生得回避ブレーキ、AT 誤発進抑制制御、全車速追従機能付きコントロールなどを搭載した EyeSight を導入した。これに改良を重ね、2014 年には EyeSight Ver.3 を発表。ステレオカメラ画像をカラー化し、さらに視野角、視認距離を約 40% 拡大することで各種制御を高精度化した。

2017 年に向けた将来の構想として Future EyeSight を発表している。これはステレオカメラによる前方視認技術を軸として、360 度センシング、地図情報などを活用し、自動車専用道路で同一車線上での渋滞追従機能を実現する。2020 年には車線変更を含めた高速道路での自動運転を目指す。

マツダ

マツダは先進安全技術を「i-ACTIVESENSE」と称しており、2015 年の新型車種に採用されている。「i-ACTIVESENSE」の危険認知支援技術として「ハイビームコントロールシステム」、「車線逸脱警報システム」、運転支援技術として「レーダークルーズコントロール」、衝突回避支援・被害軽減技術として「スマート・シティ・ブレーキ」、「AT 誤発進抑制機構」などが搭載されている。

欧州メーカー

ダイムラーは Mercedes-Benz ブランドのフラッグシップ車 S-Class において高度な運転支援技術を数多く採用している。ステレオカメラとレーダーを併用し、車間距離の維持だけでなくステアリング操作も支援する「Distronic Plus with Steering Assist」、先行車や前方を横切る車両との衝突の危険性を検知し、ブレーキアシストを行う「BAP Plus with Cross Traffic Assist」を搭載している。また、衝突時に後席シートベルトが膨張するエアバッグも新たに搭載した。

表 2.8: 日産自動車の予防安全装置

前方安全

インテリジェントペダル	追従走行中の先行車に近づいたとき車間を維持する操作をアシスト。
インテリジェントクルーズコントロール	ドライバーが設定した速度（約 40 から 100km/h）を上限として、停止～約 100km/h の範囲で先行車との車間を保つよう走行。先行車が停止したときは自車もそれに応じて停車する。
ハイビームアシスト	対向車や先行車、街灯の有無などを室内のカメラが検知して、ハイビームとロービームを自動で切り替える。

側方安全

後側方車両検知警報	車両後部の左右に設置したサイドセンサーで後側方の隣接レーンの車両を検知し、サイドミラー横のインジケーターで車両の存在を知らせる。
後側方衝突防止支援システム	車両を元のレーン内に戻す力を短時間発生させ、隣接レーンの車両との接触を回避するよう運転操作を支援する。
車線逸脱警報	意図せずに走行車線を逸脱しそうな場合、ブザーとディスプレイ表示で注意を喚起。
車線逸脱防止支援システム	車両を車線内に戻す方向に力を発生させるよう各輪のブレーキをコントロールし、ドライバーがクルマを車線内に戻す操作を促す。

後方安全

後退時衝突防止支援システム	車両後部の左右に設置したサイドセンサーと車両後部のソナーにより、後方を横切る車両を検知し、ドライバーの注意を喚起する。
後側方衝突防止支援システム	車両を元のレーン内に戻す力を短時間発生させ、隣接レーンの車両との接触を回避するよう運転操作を支援する。
車線逸脱警報	意図せずに走行車線を逸脱しそうな場合、ブザーとディスプレイ表示で注意を喚起。
車線逸脱防止支援システム	車両を車線内に戻す方向に力を発生させるよう各輪のブレーキをコントロールし、ドライバーがクルマを車線内に戻す操作を促す。

全方向安全

アラウンドビューモニター	4つのカメラが撮影した画像を処理し、クルマを真上から見ているかのような映像を表示することで駐車を支援する
踏み間違い衝突防止システム	フロントソナーとバックソナーにより障害物と自車の距離を検知。アクセルペダルをブレーキペダルと間違えて強く踏み込んでしまった場合、エンジン出力やブレーキを制御して過度な加速や障害物への衝突防止を支援する。

BMW は 2013 年に最新の Park Assist（駐車支援）を搭載。ステアリング操作だけでなく、従来はドライバ自身が行っていたアクセル、ブレーキ、シフトの操作も自動で行う。「Night Vision with Dynamic Light Spot」は、フロントグリル内の赤外線カメラにより、最長 300 メートル先までの人間や動物をコントロールディスプレイに映し出し、衝突の危険を警告する。検知した人間や動物に向けてヘッドライトを投射し、ドライバーに早い段階で危険の可能性を警告する。

Volkswagen の「Automatic Post-Collision Braking System」は、エアバッグセンサーで衝突や追突時の衝撃を検出し、自動で車両を 10km/h 以下にまで減速させることで 2 次衝突のリスクを軽減する。このシステムはハイクラスだけでなくコンパクトクラスにも搭載されている。

Volvo の「Pedestrian and Cyclist Detection with Full Auto Brake」は、従来の歩行者

表 2.9: Honda SENSING に搭載された機能

衝突軽減ブレーキシステム	ミリ波レーダーで対象物の位置や速度を検知，単眼カメラで対象物の大きさや形状を識別し，前走車，対向車や歩行者を検出．前走車や歩行者との衝突の恐れがある場合に，音と表示，アクセルペダルの振動で知らせる．
路外逸脱抑制機能	単眼カメラで走行車線を検知．車両が車線を逸脱しような場合，ステアリング振動と表示で警告を行うとともに，車線内へ戻すようステアリングを制御する．
歩行者事故低減ステアリング	ミリ波レーダーと単眼カメラで路側の歩行者や白線などを検知．歩行者側の車線を逸脱し，歩行者との衝突が予測された場合に，音と表示に加え，ステアリングを回避方向へ制御することで，ドライバーの回避操作を促す．
車線維持支援システム	単眼カメラで走行車線を検知．車両が車線の中央を維持するように，高速道路でのステアリング操作を支援し，運転負荷軽減を図る．
渋滞追従機能付 ACC	ミリ波レーダーと単眼カメラで前走車との車間距離と速度差を検知．適切な車間距離を保つようにアクセルやブレーキを制御する．
標識認識機能	単眼カメラで道路標識（最高速度，はみ出し通行禁止等）を検知．ディスプレイに表示することで標識への注意を促し，安全運転を支援する．
誤発進抑制機能	停車中または極低速走行中，近距离に前走車などがあることをミリ波レーダーが検知．急にアクセルペダルを踏み込んだ場合に急加速を制限し，音と表示およびアクセルペダルの振動で警告する．
先行車発進お知らせ機能	停車時に，先行車との車間距離が 10m 以内で，先行車の発進をミリ波レーダーが検知した場合，先行車の発進を音と表示で知らせる．

検知に加えて自転車を検知を可能にした．衝突の危険がある場合は光と音による警告と同時に自動でフルブレーキを作動させ，追突を回避または軽減する．

2.3 ドライバーモニタリングに関する研究事例

ドライバーモニタリングとは，ドライバーが眠気や疲労といった異常時に警報や運転補助を行うためにドライバーを監視するという意味である．各国の ITS プロジェクトに基づき，現在ドライバーモニタリングに関する研究開発が盛んに行われている．本節ではいくつかのドライバーモニタリングに関する基礎研究を紹介する．

2.3.1 眠気・疲労検知研究

ドライバーモニタリングに関する研究は欧州が先行しており，SENSATION プロジェクト [36] では生体信号解析による眠気検知を主眼とした研究を行っている．ここで，いくつかの研究例を示す．

- 安士は [37] ハンドルに埋め込んだ電極でドライバの心拍数を検出し，眠気度と疲労度を検出している．眠気度は心拍数データと補正演算から，疲労度は LF, HF, 眠気度から計算している．
- Martin Golz ら [38] は，Microsleep 検出手法として EEG, EOG, ECG, EMG, 視線を用い，SVM による分類が有効であることを示した．

- Goran Kecklund ら [39] は、自動車運転時のドライバーの眠気指標の作成について、あくび、体動、姿勢変動、まばたき、運転データ（特に脱線）、ドライバーの注意力について評価した。解析手法は、ビデオ解析により、これらの指標が有効であるかどうかを検証したもので、いずれも有効であることを示した。
- Roman Rosipal ら [40] は、EEG を用い、ドライビングシミュレータを用いた実験から、睡眠、覚醒検出を行なった。この際、脳波解析には Hierarchical Gaussian Mixture を用い、睡眠検出率は 78% で覚醒検出率は予測結果と実験結果との相関が低いことを示した。
- Shuyan Hu ら [41] は、EOG を用いた眠気検出を行い、Karolinska drowsiness score [42] を用いて 3 段階で評価を行なった。この結果、Alert : 90%, Sleepy : 57.14%, Very Sleepy : 91.80% で検出が可能であった。
- Jussi Virkkala ら [43] は、眼球移動量の閾値処理により眠気検出を行なった。この結果、slow wave sleep 検出 : 93.3% (両目を用いた検出) 90.8% (片目を用いた検出), NREM 検出 : 84.4% (両目を用いた検出) 73.8% (片目を用いた検出) を導いた。

日本においても、EEG, ECG といった生体信号や、ハンドル操作などの車両挙動解析による眠気検知の研究が行われている。

- 柳平ら [44] は運転者の心拍解析により心拍数と HF の連続的な変化を調べた結果、眠気の増加とともに交感神経活動の低下、副交感神経活動の上昇、脈波間隔が長くなることを導いた。
- 奥村ら [45] は大型トラックでの長時間運転後のドライバーの眠気度評価を行った。その結果、ヨーレートの標準偏差、ヨーレートのスペクトル強度、アクセル開度の微分値の平均値、操舵角周波数のスペクトル強度、操舵角の標準偏差が眠気と相関があることが明らかとなった。
- 沼田ら [46] は運転中のドライバーの脳波 (α/β) と瞬目持続時間と心拍数を用いて重回帰予測モデルを作成した。モデルの出力値と眠気との相関を調べた結果、相関係数は最高で 0.710 であった。

2.3.2 不注意運転検知研究

不注意運転を促す会話や思考といった要因を Distraction と呼び、現在、車内における Distraction を検知する研究が盛んに行われている。欧州のプロジェクトである AIDE (Adaptive Integrated Driver-vehicle interfacE) [47] が先行している。AIDE では、道路標識やミラーといった対象物を注視した状態である Visual Distraction と、会話や思考などの認知負荷による Cognitive Distraction の検知研究を行っている。

ここで、他の代表的な Distraction 検知に関する研究を列挙する。

- 萩原ら [48] は、ドライバに「数字を見て音読させるタスク」と「数値を聞いて音読させるタスク」の双方を課した結果、視覚的な負荷がドライバへ与える影響が強いとしている。

- Hirayama ら [49] は、ドライバの視線移動のパターンからドライバーが Cognitive Distraction であるか通常状態であるかを識別する手法を述べている。
- 秋山ら [50] は、漫然運転を誘発させる目的でサブタスクを与えた結果、ドライバーの視線移動が減少し、視点がある 1 点に集中すると報告している。
- 伊藤ら [51] らは、暗算を行いながら運転をしているドライバーの視線停留時間を解析することで、ドライバーの暗算による注意力低下状態の検知を行っている。
- Sternberg ら [52] は、最初に記号を呈示し、被験者に記憶してもらい、次にその中の任意の記号を呈示し、被験者が理解した時までの時間を計測し、情報量が増加した時の反応時間が増加したことを確認している。
- Victor ら [53] は、ディスプレイ上で矢印を読み取る認知負荷を与え、前方視点分布範囲の縮小、視点角度の標準偏差の減少を報告している。
- Engstrom ら [54] は、ドライバーにディスプレイ上で矢印を読み取る認知負荷を与え、合成視線角度の標準偏差が減少することを報告している。なお、合成視線角度は、ピッチ角度とヨー角度の平方和の平方根として算出している。

2.3.3 運転行動予測研究

心電図や脳波といったドライバーの生体情報から心身状態を推定することは可能であるが、自動車の運転に関しては最終的にステアリングおよびアクセル・ブレーキペダルの操作として車両に伝えられるため、ドライバーの操作情報は運転状態を検知するための重要なパラメータとなる。近年、ステアリング、ペダルストローク量といった操作情報や、車速、レーン位置といった車両情報をモデリングし、ドライバーの運転行動を予測する研究が行われている。そのいくつかをここで紹介する。

- 景山ら [2] は前方の道路曲率から求められるフィードフォワード項と、前方注視モデルから求められるフィードバック項からドライバーの制御モデルを構築する手法を提案している。
- 星野ら [3] は速度や操舵角等の車両情報から運転行動を表現するドライバモデルを構築し、ドライバの疲労度をリアルタイムで評価する手法を提案している。
- Peng ら [4] は車線変更する車両の挙動をモデル化し、通常運転を 92.5%、危険運転を 80% 検出することができるとしている。モデリングには HMM を用いている。
- Pentlad ら [5] は、ハンドル角・アクセル操作量から、停止・右左折・車線変更・追い越し等の行動を予測している。予測にはカルマンフィルタを用い、ドライバーの状態を確率推定してドライバーのモデルを切り替えている。
- 熊谷ら [6][7] は、実車運転で得られたドライバーのハンドル・ペダル操作量の情報を基に、交差点での右左折等の行動を予測している。手法として、HMM (Hidden Markov Model) と SLDS (Switching Linear Dynamic System) を用いている。

- 阿部ら [8][9] は、アクセル・ブレーキ操作量と車速情報を AR-HMM (Auto-Regressive Hidden Markov Model) を用いて運転行動モデルを構築し、ブレーキ操作によって何秒以内に停止するかを予測している。また、運転行動はドライバーの心身状態に係わるとして、心電図からの急ぎ心理状態の推定し、心理状態に基づくモデル切り替えによって行動予測の精度を向上させる試みも行っている。
- 坂口ら [10] は、運転操作や車両周辺の情報モデリングし、ドライバーの几帳面さ等の運転傾向の推定を行っている。
- Oliver ら [11] は、ペダル操作、ハンドル角、車両の前後画像、ドライバーの注視画像、レーン位置等の情報を HMM によってモデリングし、追い越し、右左折、車線変更、発進、停止の予測を行っている。

第3章 運転行動のモデル化によるドライバー行動予測

本章の前半で運転行動モデルを構築する際に用いる Dynamic Bayesian Network (DBN) のアルゴリズムを紹介する。後半で構築したモデルに基づく運転行動予測手法について述べる。

3.1 本研究で用いるモデリング手法

3.1.1 Dynamic Bayesian Network

ここで運転行動モデルを構築する際に用いる Dynamic Bayesian Network (DBN) のアルゴリズムを紹介する。また DBN で記述できるモデル構造として一般的に用いられる Hidden Markov Model (HMM) と、その発展形である Auto-Regressive Hidden Markov Model (AR-HMM) についても解説を行う。

ベイズ推定

ベイズ推定とは入力した観測値を「与えられた」ものとして考え、その与えられた観測値から未知母数の値がどのような様であるのか推論を行い、確信度として定義される主観確率を基盤としている。つまり、モデルパラメータ θ を仮に確率変数とみなして、パラメータの値の確信度を確率密度分布を用いて表現する。そして、データが観測された後にパラメータが取るであろう値の確率密度分布（事後確率密度分布） $p(\theta|X)$ を推定する。一般に、データが観測されると事後確率密度分布 $p(\theta|X)$ は、データと整合性の良いパラメータほど大きな値を持つような分布となり、これをベイズ学習と呼ぶ。

Bayesian Network

Bayesian Network (BN) は、不確実性を含む事象の予測や合理的な意思決定、障害診断などに利用することのできるベイズ推定を用いた確率モデルの一種である。ある確率分布を表現し、その確率分布によって計算対象を近似（モデル化）し、様々な条件により変化する確率分布を計算し、予測や最適な意思決定を行う。この確率分布の計算は、確率推論と呼ばれる。確率モデルの研究は幅広い分野で行われており、人工知能の分野では、BN と確率推論アルゴリズムの研究として長い歴史がある。BN の特徴は、因果的な構造をネットワークとして表し、その上で確率推論を行うことで不確実な事象の起こりやすさやその可能性を予測するものである。

BNは、確率変数とその間の依存関係を表すグラフ構造、条件付確率の集合によって定義される。変数はノードとして、変数間の依存関係は原因から結果となる変数の向きを持つ有向リンクで図示する。例えば、確率変数 X_i, X_j の間の条件付依存性をBNでは $X_i \rightarrow X_j$ と表す。リンクの先に来るノードを子ノード、リンクの元にあるノードを親ノードという。

親ノードが複数あるとき、子ノード X_j の親ノードの集合を $Pa(X_j) = \{X_1^j, \dots, X_i^j\}$ と表す。このとき、 X_j と $Pa(X_j)$ の依存関係は次の条件付確率によって定量的に表される。

$$P(X_j | Pa(X_j)) \tag{3.1}$$

さらに、 n 個の確率変数 X_1, \dots, X_n のそれぞれを子ノードとして同様に考えると、全ての確率変数の同時確率分布は次式で表すことができる。

$$P(X_1, \dots, X_n) = \prod_{j=1}^n P(X_j | Pa(X_j)) \tag{3.2}$$

こうして各子ノードとその親ノードの間のリンクを張って構成したBNによって、これらの変数間の確率的な依存関係がモデル化できる (図 3.1)。




図 3.1: Bayesian Network

変数が離散の場合、式 (3.2) の右辺にある条件付確率は、子ノードと親ノードがとる全ての状態のそれぞれにおける確率値を定めた表 (条件付確率表:CPT) を使うことで完全表現できる。

一般的に書くと、親ノードがある状態 $Pa(X_j) = x$ (x は親ノード群の各値で構成されたベクトル) のもとでの n 通りの離散状態 (Y_1, \dots, Y_n) を持つ変数 X_j の条件付確率分布は $p(X_j = y_1 | x), \dots, p(X_j = y_n | x)$ となる (ただし $\sum_{i=1}^n p(y_i | x) = 1.0$)。これを各行として、親ノードがとりうる全ての状態 $Pa(X_j) = x_1, \dots, x_m$ のそれぞれについて列を構成した表 3.1 の各項目に確率値を定めたものが X_j にとっての CPT となる。

このBNのある一つの子ノードに注目した依存関係を、一つの目的変数 (従属変数: Y) と、それに対する説明変数 (独立変数: X) の間の依存関係として見ると、BNは $X - Y$ 空間をCPTに従って離散化し、個々の確率値を割り当てた不連続な確率分布によるモデル化である。その自由度は比較的高いものとなっており、線形から非線形型な依存関係まで

表 3.1: 条件付確率表 (CPT)

$p(y_1 Pa(X_j) = x_1)$	\cdots	$p(y_1 Pa(X_j) = x_m)$
\vdots	\ddots	\vdots
$p(y_n Pa(X_j) = x_1)$	\cdots	$p(y_n Pa(X_j) = x_m)$

柔軟に近似することができる。また各項目毎に十分な数の統計データがあれば、変数の各状態についての頻度を正規化して、各項目の確率値を求めることが容易にできる。

Bayesian Network の確率推論

BN を使うことで、一部の変数を観測した時のその他の変数についての確率分布を求めたり、確率値が最も大きい状態をその変数の予測結果として得ることができる。観測された変数の情報 (e) から、求めたい確率変数 (X) の確率値、即ち事後確率 $P(X|e)$ を求め、それにより X の期待値や確信度最大の値 (MAP 値)、ある仮説の確信度 (いくつかの変数が特定の値の組をとる同時確率) などが評価するわけである。

BN による確率的推論は、

- i) 観測された変数の値 e をノードにセットする。
- ii) 親ノードも観測値も持たないノードに事前確率分布を与える。
- iii) 知りたい対象の変数 X の事後確率 $P(X|e)$ を得る。

という手順で行われる。iii) における事後確率を求めるために、観測された情報からの確率伝搬 (変数間の局所計算) によって各変数の確率分布を更新していく確率伝搬法 (Belief Propagation) と呼ばれる計算法が使われる。図 3.2 の構造のもとでの計算の実行例を示す。




図 3.2: 簡単な構造での確率伝搬

$X_1 \rightarrow X_2, X_2 \rightarrow X_3$ の間に依存性があり、条件付確率が与えられているとする。今、計算しようとしている b ノードを X_2 として、上流にある親ノードに与えられる観測情報を e^+ 、下流の子ノードに与えられる観測情報を e^- と書く。計算したい事後確率 $P(X_2|e)$ は、 e を e^+ と e^- に分け、 X_2 と e^- に注目してベイズの定理を使うと次式のようなになる。

$$\begin{aligned}
 P(X_2|e) &= P(X_2|e^+, e^-) \\
 &= \frac{P(e^-|X_2, e^+)P(X_2|e^+)}{P(e^-|e^+)} \tag{3.3}
 \end{aligned}$$

また e^+ と e^- は X_2 を固定した時には条件付独立となるので、 $\alpha = \frac{1}{P(e^-|e^+)}$ を X_2 の値によらない正規化定数とすれば、次のように変形できる。

$$P(X_2|e) = \alpha P(e^-|X_2)P(X_2|e^+) \quad (3.4)$$

このうち e^+ による X_2 への寄与分、つまり親ノードから伝搬する確率を $P(X_2|e^+) = \pi(X_2)$ と書く。これは、 $P(X_1|e^+)$ と X_2 の CPT を使って、 X_1 についての周辺化（式 (3.5)）によって求めることができる。

$$\pi(X_2) = \sum_{X_1} P(X_2|X_1)P(X_1|e^+) \quad (3.5)$$

$P(X_1|e^+) = \pi(X_1)$ は観測値が与えられているならば、その値は決定できる。観測値がなく、さらに親ノードを持たない最上流のノードであるならば、事前確率を与える。その上流に親ノードを持つ場合は式 (3.5) を再帰的に適用していけば最終的には最も上流にあるノードによってその値が求まる。

一方、式 (3.4) の子ノード側の e^- の寄与分、つまり子ノードから伝搬する確率を $P(e^-|X_2) = \lambda(X_2)$ とすると、これを計算するためには、既に定義されている条件付確率 $P(X_3|X_2)$ と使って X_3 の全状態について周辺化する次式を用いればよい。

$$\lambda(X_2) = \sum_{X_3} P(e^-|X_2, X_3)P(X_3|X_2) \quad (3.6)$$

観測から得られる情報 e^- は X_2 の値によらず独立であることを利用すると、これは次式のように書き直せる。

$$\lambda(X_2) = \sum_{X_3} P(e^-|X_3)P(X_3|X_2) \quad (3.7)$$

ここで、 $P(X_3|X_2)$ は CPT として与えられている。 $P(e^-|X_3) = \lambda(X_3)$ は観測情報が与えられているならば値が確定できる。また観測値がなく、その下流に子ノードを持たない下端のノードの場合には、無情報であるから一様確率分布であるとして X_3 の全ての状態について等しい値とする。また一般の構造のネットワークの場合、さらに下流に子ノードを持つならば、式 (3.7) を再帰的に適用していけば、最終的には最も下流にあるノードによって値が求まるので、観測値がなくても $\lambda(X)$ を計算することが可能である。

従って、以上式 (3.5), (3.7) を、式 (3.4) に代入すればノード X_2 の事後確率が求まる。同様に次式によって任意のノードの事後確率も局所的に計算できる。

$$P(X_j|e) = \alpha \lambda(X_j) \pi(X_j) \quad (3.8)$$

BN のリンクの向きを考慮しないグラフ構造内の全てのパスがループを持たない場合、その BN は Singly Connected なネットワークと呼ばれる。Singly Connected な BN の場合には、親ノード、子ノードが複数存在するような構造のネットワークでも、条件付独立性の性質を使うことで、各ノードについて上流からの伝搬、下流からの伝搬、上流への伝搬、下流への伝搬の 4 種について先の確率伝搬計算を図 3.3 のように行うことができる。また、その計算量はノード数に対して線形オーダーである。

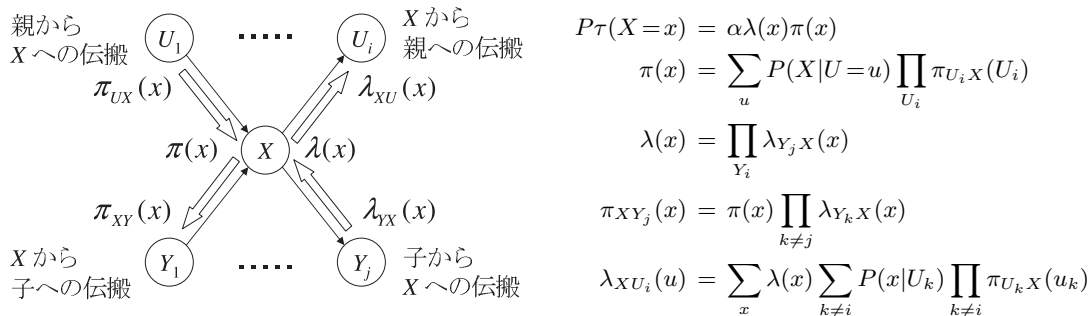


図 3.3: 確率伝搬計算

リンクの向きを考慮しないでネットワークを見た時に、どこか一つでもパスがループしている部分がある時、このBNは multiply connected と呼ばれる。この場合には単純にリンクに沿って確率を伝搬していくだけでは、その計算の収束性が保証できない。しかし、Junction Tree アルゴリズムと呼ばれる手法が開発されたことで、様々な構造に対するBNの有用性が高まった。

Junction Tree アルゴリズム

Junction Tree アルゴリズムは、multiply connected なネットワークの確率伝搬法を効率的に実行するために開発されたアルゴリズムである。

これはまず、適切な親ノードを併合する操作を繰り返してノードのクリークをクラスタとして生成し、元のBNのノードをクリークとして結合した singly connected な木構造からなる Junction Tree (または moral graph) と呼ばれる無向グラフに変換する。次に、こうしてできた singly connected な木構造に従ってクリーク毎に確率伝搬を行うことでやはり確率値が計算できる。複雑なネットワークの場合には、グラフ変換にかかる計算コストが大きくなるが、一度グラフ構造の変換に成功した後に何度も確率計算を行うような場合には非常に効率の良い確率伝搬を実行することができる。

ただし Junction Tree アルゴリズムは、ノード数が増え、グラフ構造が複雑になるにつれ、変換操作自体の計算コストが無視できない問題となる。特にネットワーク構造が常に変わらない場合には一度だけ変換を行えば良いが、状況によってネットワーク構造が変化する場合にはその都度グラフ構造を変換しなければならず、変換のための計算コストは深刻な問題となってくる。また、グラフ構造の性質によっては効率の良い Junction Tree に変換できず、結果として巨大なクラスタが生じることも起こりうる。その場合にはクラスタ内の確率計算のために多数の確率変数の全状態の組み合わせについての計算が必要のために計算量が増大する。

Dynamic Bayesian Network

DBN は、BN を離散時間における確率課程を想定した上で表現できるように、通常の状態空間モデルの変数 (入力変数, 隠れ変数, 出力変数) に加えて新たに時間を表す変数 t を定義した、BN の拡張版といえるグラフィカルモデルである。

時間 t における確率変数の集合を Z_t , Z_t における i 番目のノードを Z_t^i と定義すると, DBN は有向非巡回グラフ (DAG: Directed Acyclic graph) で表され, $P(Z_1)$ を与える BN である B_1 と, $P(Z_t|Z_{t-1})$ を与える時間二分片 BN (2TBN: Two-slice Bayesian Network) である B_{\rightarrow} のペア (B_1, B_{\rightarrow}) を用いて, 次式によって計算することができる.

$$P(Z_t|Z_{t-1}) = \prod_{i=1}^N P(Z_t^i|Pa(Z_t^i)) \quad (3.9)$$

ここで, $Pa(Z_t^i)$ は Z_t^i の親ノードにあたる変数の集合である.

さらに式 (3.9) を時間 T まで展開することで DBN は定義され, その結果得られる同時確率分布は次式で与えられる.

$$P(Z_1:T) = \prod_{t=1}^T \prod_{i=1}^N P(Z_t^i|Pa(Z_t^i)) \quad (3.10)$$

DBN では連続系列データを扱うために, 最も単純な因果モデルとして一次マルコフ性を仮定する. つまり, 各変数は直前の変数のみから影響を受ける. ここで DBN の例として, HMM を DBN の形式で表現したものを図 3.4 に示す.




図 3.4: DBN の例

DBN と HMM の相違点として, DBN では状態の分散を表現するために確率変数の集合 $X_t^1, \dots, X_t^{N_h}$ を隠れ状態で表すことで, 複数の状態変数の組み合わせを取ることが可能であるのに対し, HMM では状態空間が一確率変数 X_t のみで構成されている. また, HMM や KFM では, グラフ構造が取り得るトポロジ (接続形態) が制限されているのに対して, DBN ではより一般的なトポロジを取ることが可能である. 図 3.4 において, X を隠れノード, Y を観測ノードとみなすと, このグラフは $X_{t+1} \perp X_{t-1} | X_t$ (マルコフ性) 及び $Y_t \perp T_{t'} | X_t (t' \neq t)$ の条件付独立仮定が成立しており, HMM と等価であることが確認できる. 図 3.4 を見てわかるように, DBN は同一の BN を時間ステップ分だけ繰り返して連結したようなモデルとなっている.

3.1.2 Dynamic Bayesian Network で記述できるモデル構造

Hidden Markov Model

図 3.4 は DBN の一形態である HMM (Hidden Markov Model : 隠れマルコフモデル) であり, ここでは 3 スライスのみが表示されているが, スライスは無限に繰り返される.

モデルの定義は最初の3スライスを示すだけで行う事ができる。また、この節中では白色のノードは可観測であり、灰色ノードは隠れている事（非可観測）を示す。他のDBNでもそうであるように、このモデルにおいても親ノードが与えられた時の条件付き確率を定義しなければならない。具体的には、 X_{t-1} を親ノードとした時の X_t の確率テーブル、つまり状態遷移確率と X_t を親ノードとした時の Y_t の出力確率（ Y_t が離散値であれば出力確率テーブル、 Y_t がガウス分布の連続ベクトルであれば平均ベクトルと共分散行列）を定義しなくてはならない。同様に、親ノードを持たない1スライス目の状態 Y_1 については、初期状態確率 $P(X_1 = i) = \pi(i)$ を定義しなければならない。以上をまとめると出力が連続量ベクトルであるHMMは式(3.11)の様に定式化される。

$$\begin{aligned} P(X_i = i) &= \pi(i) \\ P(X_t = j | X_{t-1} = i) &= A(i, j) \\ P(Y_t | X_t = i) &= N(y_t; \mu_i, |\Sigma_i) \end{aligned} \tag{3.11}$$

ここで、 $\pi(i)$ は初期状態確率、 $A(i, j)$ は状態遷移確率、 $N(y(t); \mu, \Sigma)$ は $y(t)$ が平均ベクトル μ 、共分散行列 Σ の正規分布確率変数である事を示す。

Auto-Regressive Hidden Markov Model




図 3.5: AR-HMM のダイアグラム

図 3.5 に AR-HMM のブロック図を示す。このモデルを用いることにより、 Y_t が内部状態 X_t にだけ影響を受けるのではなく、 Y_{t-1} によって Y_t を予測する事が可能となる。このモデルは、

$$\begin{aligned} P(X_i = i) &= \pi(i) \\ P(X_t = j | X_{t-1} = i) &= A(i, j) \\ P(Y_t | X_t = i, Y_{t-1} = y_{t-1}) &= N(y_t; W_i y_{t-1} + \mu_i, |\Sigma_i) \end{aligned} \tag{3.12}$$

と表す事ができる。ここで、 W_i は X_t が状態 i であるという事前条件付きの回帰行列である。このモデルを使い運転行動モデルを記述して運転行動を予測する事により、HMM より良好な予測結果が得られた事が、産業技術総合研究所の赤松氏・熊谷氏らにより報告されている [6][7]。

3.2 運転行動のモデリングによる停止確率予測

3.2.1 Dynamic Bayesian Network に基づく運転行動モデリング

本研究では車両速度およびペダル操作量から，過去の運転行動を考慮したフィードバック型の運転行動モデルを構築した．そのモデルを用いて運転行動シミュレーションを行い，シミュレーション結果に基づくドライバーの運転行動予測を行った．予測する運転行動は事故回避に最も有効である「停止行動」とし，走行中の車両がブレーキ操作によって一定速度まで減速してから何秒後に停止するかの予測を試みた．以上の流れを図 3.6 に示す．

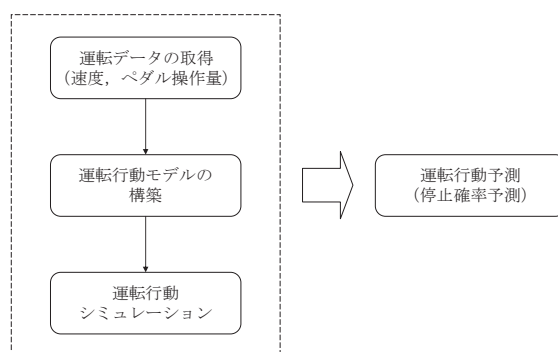


図 3.6: 運転行動のモデリングとシミュレーションによる停止行動予測の流れ

3.2.2 先行研究のモデリング手法

速度やペダル操作量を出力として車両の加速運動をモデルによって記述する場合，速度は前回の速度に対してペダル操作による変動分が付加される挙動を示す．この考え方より，阿部ら [8][9] は出力の AR 項を入力にフィードバックする AR-HMM によって運転行動モデルを構築している．

AR-HMM を用いた運行行動モデルでは，DBN を以下のように定義している．

$$\delta_j(t+1) = \sum_i a_{i,j} \delta_i(t) \quad (3.13)$$

$$y(t) = N(\mu_i + w_i y(t-1), \Sigma_i) \quad (3.14)$$

ここで $\delta_i(t)$ は時刻 t において状態が s_i である確率， $y(t)$ は時刻 t における出力である．出力 $y(t)$ は以下の式で速度，ペダル操作量を記述する．

$$y(t) = \begin{bmatrix} y_1(t) \\ y_2(t) \end{bmatrix} \quad (3.15)$$

$$y_2(t) = St_a(t) + St_b(t) \quad (3.16)$$

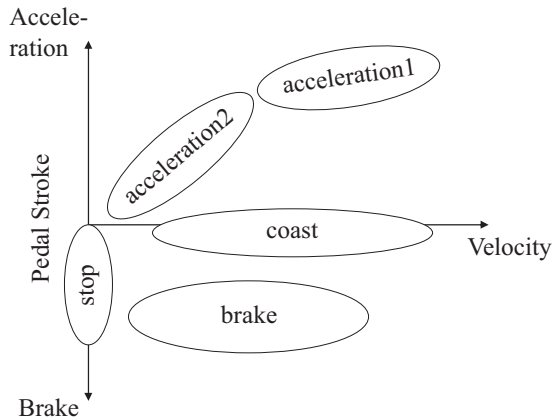


表 3.2: 各状態の速度とペダル操作

状態	速度	ペダル操作
停止	$\doteq 0$	< 0
加速 1	> 0	> 0
加速 2	> 0	$\gg 0$
惰行	> 0	$\doteq 0$
減速	> 0	< 0

図 3.7: 運転行動状態分布のイメージ

ここで $y_1(t)$ は速度, $St_a(t) \in [0, 1]$ はアクセルペダル操作量, $St_b(t) \in [0, 1]$ はブレーキペダル操作量を表す. w_i は式 (3.17) で表される固定値を用いる.

$$w_i = \begin{bmatrix} 1 & k_i \\ 0 & 0 \end{bmatrix} \quad (3.17)$$

ここで k_i はそれぞれの状態において, ペダル操作量と, 1 タイムスライスの間に速度が増加する割合を線形近似した係数である. その他のパラメータ $a_{i,j}, \mu_i, \Sigma_i$ については EM アルゴリズムによって推定する.

阿部ら [8][9] のモデルでは状態数を 5 とし, 停止状態 (stop), 加速状態 1 (acceleration1), 加速状態 2 (acceleration2), 惰行状態 (coast), 減速状態 (brake) と定義している. これら各状態のイメージを図 3.7, 各状態に対する出力の定義を表 3.2 に示す.

3.2.3 過去の運転行動を考慮した運転行動のモデリング

3.2.2 節で紹介した AR-HMM を用いた運転行動モデルでは直前の行動から次の行動を予測している. しかし, 人間の行動は過去の一連の行動の流れから生ずるものであるため, 人間の行動を捉えるためには直前の行動のみを考慮するよりも, 過去の一連の行動の流れを考慮することによって, より高精度な行動予測が可能となると推測される. 従って運転行動を予測する場合においても, 過去からの運転行動の連続性を考慮した上で次の運転行動を予測することは有効であると考えられる.

よって本研究では車両速度およびペダル操作量から, 過去の一連の運転行動を考慮したフィードバック型の運転行動モデルを構築した.

モデリングに用いる運転データ

運転行動モデルの構築には, 不確実性を含む事象の予測に利用することができる確率モデルの一種である DBN を用いた. DBN は HMM, AR-HMM 等の様々なモデル構造を記述することができる. 本研究においては過去の運転行動を考慮するために, 出力値をフィー

ドバックするモデル特性を持つ AR-HMM を採用した。モデル構築に用いる運転データとして、以下の2つを用いた。

(1) 車両速度： V

(2) ペダル操作量： P

ペダル操作量 P については、

$P \in [0, 1]$ ： アクセル操作量

$P \in [-1, 0]$ ： ブレーキ操作量

を表す。また、 $P = 1$ はアクセル開度最大、 $P = -1$ はブレーキ開度最大、 $P = 0$ はアクセル・ブレーキ共に開度 0 の状態を示している。

Current Driving Trigger (CDT)

過去の運転行動を考慮するために、過去の運転データを切り出す必要がある。この過去の運転データを Current Driving Trigger (CDT) と定義した。また考慮するステップ数を n として、CDT を $CDT_{1...n}$ と再定義する。 CDT_1 は考慮するステップ内における現時点からみて直前の運転データであり、 CDT_n は現時点から最も遠い時点での運転データである。さらに速度とペダル操作量をモデリングするために、CDT を速度の CDT (CDT_V) とペダル操作量の CDT (CDT_P) に分解した。図 3.8 に速度とペダル操作量の CDT の例を示す。図中の実線は速度の CDT、破線は正值がアクセル操作量の CDT、負値がブレーキ操作量の CDT である。これはある時刻 t_1 にブレーキ操作によって停止した場合における t_1 から t_2 までの 10 秒間の CDT を表している。この CDT は、ドライバーが停止約 7 秒前からアクセルをリリースし、ブレーキを複数回に分けて踏むことで徐々に停止をした場合に得られたものを示している。

CDT の遷移を考慮したモデリング

CDT の連続的な遷移を記述することができれば、過去の運転行動を考慮したモデルが構築できると考えられる。CDT の遷移を考慮するために、AR-HMM によるフィードバック型のモデル構造式を考案した。運行動モデルを構築するために、DBN を以下のように定義する。

$$\delta_j(t+1) = \sum_i a_{i,j} \delta_i(t) \quad (3.18)$$

$$y(t) = N(\mu_i + w_i y(t-1), \Sigma_i) \quad (3.19)$$

ここで $\delta_i(t)$ は時刻 t において状態が s_i である確率、 $y(t)$ は AR-HMM における時刻 t での出力ベクトルである。出力 $y(t)$ を以下のように書き換えることで、速度、ペダルの CDT




図 3.8: 時刻 t_1 から t_2 までの 10 秒間の運転行動を表す Current Driving Trigger

を記述する.

$$\begin{bmatrix} y_{CDTV}(t) \\ y_{CDTP}(t) \end{bmatrix} = N \left(\begin{bmatrix} \mu_V \\ \mu_P \end{bmatrix} + \begin{bmatrix} \tilde{w} & O_{n,n} \\ O_{n,n} & \tilde{w} \end{bmatrix} \begin{bmatrix} y_{CDTV}(t-1) \\ y_{CDTP}(t-1) \end{bmatrix} \right) \quad (3.20)$$

$$\mu_V = [O_{1,n-1} \ \mu_{Vn}]^T \quad (3.21)$$

$$\mu_P = [O_{1,n-1} \ \mu_{Pn}]^T \quad (3.22)$$

$$\tilde{w} = \begin{bmatrix} O_{n-1,1} & E_{n-1} \\ 0 & O_{1,n-1} \end{bmatrix} \quad (3.23)$$

ここで,

$y_{CDTV}(t)$: 時刻 t における速度の CDT

$y_{CDTP}(t)$: 時刻 t におけるペダル操作量の CDT

n : CDT の長さ ($n = 1$ が 0.1 秒)

μ_V : 速度の出力の平均値

μ_P : ペダル操作量の出力の平均値

\tilde{w} : 重み付け行列

E_n : n 行 n 列の単位行列

$O_{m,n}$: m 行 n 列の零行列

を表している。 n の値が 1 の場合は直前の運転行動のみを考慮するので、従来研究の手法 [8][9] と等価となる。

モデリングの手順

運転行動のモデリングは以下の手順で行った。

- (1) ドライビングシミュレータ実験によって速度、ペダル操作量データを取得する。
- (2) 速度、ペダル操作量を数秒間の CDT に変換する。
- (3) 実験データより得られた CDT を全て考慮すると計算時間が増大するため、K-means によるクラスタリングで CDT の代表値と所属クラスを決定する。
- (4) クラス i から j に遷移する回数 ($N_{i,j}$) をカウントし、求めた回数より式 (3.24) に従ってクラス i から j への遷移確率 $a_{i,j}$ を求める。

$$a_{i,j} = \frac{N_{i,j}}{\sum_{k=1}^C N_{i,k}} \quad (3.24)$$

ここで、 C はクラス数を表す。

- (5) 遷移確率をモデルパラメータとし、"Bayes Net Toolbox for Matlab"[55] を用いて AR-HMM によるモデリングを行う。

モデリングを行うにあたり、過去何秒間の運転行動を考慮するかが正確な予測を行うための重要な要素となる。本研究では、過去 0.1 秒から 5.0 秒までの運転行動を 0.1 秒ずつ増加させながら停止確率予測を繰り返し、過去何秒間の運転行動が予測に適しているかを検討した。

3.2.4 停止確率予測

以上で解説した運転行動モデルを用いて、運転行動シミュレーションに基づく停止行動の予測を行った。

運転行動シミュレーション

以下、シミュレーションの開始速度が v_i であるときの停止確率を予測するものとして解説する。シミュレーション手順として、まず速度が v_i であり、かつブレーキが踏まれている状態の CDT の平均値 (CDT_{avg}) を求める。 CDT_{avg} は式 (3.25) によって表される。

$$CDT_{avg} = E[\{CDT | CDT_{V1} = v_i, CDT_{P1} < 0\}] \quad (3.25)$$

ここで、 $E[\]$ は集合の平均値、 CDT_{V1} と CDT_{P1} はモデルから出力された速度、もしくはペダル操作量の CDT における現時点からみて直前の値である。図 3.9 に、 CDT_{avg} を入

力値とする運転行動のシミュレーションの流れを示す。 CDT_{avg} を運転行動モデルに入力し、次の時刻の CDT を取得する。求められた CDT を再びモデルに入力し、さらに次の時刻の CDT を求める。これを繰り返すことで CDT を逐次的に求め、 CDT_{V1} に着目することでシミュレーション上の車両挙動を捉えることができる。ここでシミュレーションの出力値が $CDT_{V1} < 0 \cap CDT_{P1} < 0$ という条件を満たせば、その時点で車両が停止したことを意味する。図 3.10 は、同じ運転行動モデルで 3 回シミュレーションを行った場合の各シミュレーションの出力を表している。出力値はシミュレーションの度に異なるが、これは AR-HMM のランダムな状態遷移に依存するためである。

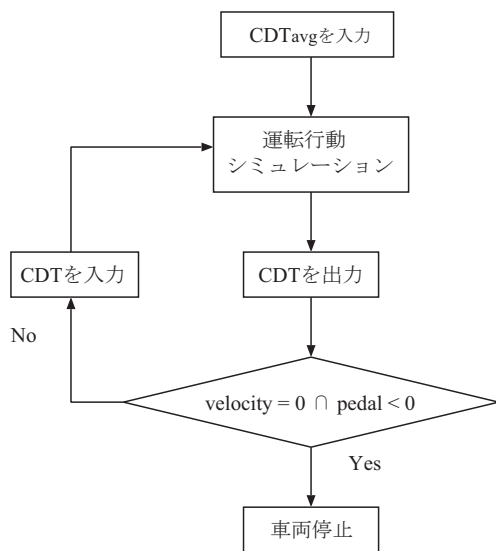


図 3.9: CDT_{avg} を入力値とした運転行動シミュレーションの流れ




図 3.10: 同じ運転行動モデルを用いて、3 回のシミュレーションによって得られた出力値

停止確率予測手法

熊谷ら [6][7] は、車両が減速してある速度に達した時刻 T から何ステップ後に停止するか
の予測 (n ステップ後停止確率予測) を行った。時刻 T から n ステップ後に停止する確
率は式 (3.26) で表される。

$$P_{STOP}(t) = P(\text{velocity}(t) < \text{Const}_{\text{velocity}}) \times P(\text{pedal}(t) < \text{Const}_{\text{pedal}}) \quad (3.26)$$

これに対して阿部ら [8][9] は、実際の運転行動予測において時刻 t における停止確率より
も時刻 t までに停止する確率がより有用であるとみなし、ある時刻から何ステップ以内に
停止するか
の予測 (n ステップ以内停止確率予測) を行っている。本研究においても実用
性を考慮し、 n ステップ以内停止確率予測を行った。予測方法は式 (3.27) で表される。

$$P_{STOP}(T+n) = 1 - \prod_{t=T+1}^{T+n} P(\text{velocity}(t) > 0 \cup \text{pedal}(t) > 0 | \text{velocity}(t-1) > 0 \cup \text{pedal}(t-1) > 0) \quad (3.27)$$

時刻 T から n ステップ以内に停止する確率は式 (3.27) で定義される時刻 T
から n ステップ以内に停止する確率は、出力 $y(T)$ および状態確率 $\delta_i(T)$ の推定値が得ら
れたとき、式 (3.28) のように計算することができる。

$$\begin{aligned} \bar{y}_i &= y(T) \\ P_{\overline{STOP}_{j,i}}(T+n) &= P(N(\mu_i + w_i \bar{y}_j(T+n-1), \Sigma_i) \in \overline{STOP}) \\ \delta_i(T+n) &\sim \frac{\sum_j \delta_j(T+n-1) a_{j,i} P_{\overline{STOP}_{j,i}}(T+n)}{\sum_{j,k} \delta_j(T+n-1) a_{j,k} P_{\overline{STOP}_{j,k}}(T+n)} \\ \bar{y}_i(T+n) &\sim \frac{\sum_j \delta_j(T+n-1) a_{j,i} N(\mu_i + w_i \bar{y}_j(T+n-1), \Sigma_i, \overline{STOP})}{\sum_j \delta_j(T+n-1) a_{j,i} P_{\overline{STOP}_{j,i}}(T+n)} \\ \tilde{y}_i(T+n) &\sim \sum_i \delta_i(T+n) \bar{y}_i(T+n) \\ P(\bar{y}(T+n) \in \overline{STOP} | \tilde{y}(T+n-1) \in \overline{STOP}) &\sim \sum_{i,j} \delta_j(T+n-1) a_{j,i} P_{\overline{STOP}_{j,i}}(T+n) \end{aligned} \quad (3.28)$$

ここで $y(t) \in \overline{STOP}$ は $\text{velocity}(t) > 0 \cup \text{pedal}(t)$ であり、すなわち非停止であることを
意味する。本研究において、 $\text{velocity}(t)$ は $\text{CDT}_{V_1}(t)$ 、 $\text{pedal}(t)$ は $\text{CDT}_{P_1}(t)$ に相当す
る。 $P_{\overline{STOP}_{j,i}}(T+1)$ は時刻 $T+n-1$ において状態が j であり、かつ出力が非停止であ
り、時刻 $T+n$ に状態が i に移ったという事前条件付きの、時刻 $T+n$ における出力が非
停止である確率を意味する。また、 $N(\mu_i + w_i \bar{y}_j(T+n-1), \Sigma_i, \overline{STOP})$ は正規分布に対
し、 $P(y_1 < 0 \cap y_1 < 0)$ を 0 とした分布とする。この逐次計算により式 (3.27) は式 (3.29)
のように書き表すことができる。

$$\begin{aligned}
P_{STOP}(T+n) &= 1 - \prod_{t=T+1}^{T+n} P(\tilde{y}_i(t) \in \overline{STOP} \mid \tilde{y}_i(t-1) \in \overline{STOP}) \\
&= 1 - \prod_{t=T+1}^{T+n} \sum_{j,i} \delta_j(T+n-1) a_{j,i} \cdot P_{STOP_{j,i}}(T+t) \quad (3.29)
\end{aligned}$$

3.2.5 運転データ取得実験

本研究ではドライビングシミュレータを用いた走行実験を行い，取得した速度，及び，ペダル操作量のデータに基づいた停止確率予測を行った。

運転データ取得実験

ドライビングシミュレータの外観は図 3.11 であり，実車から切り出したモックアップ型となっている．このドライビングシミュレータの構成図と配置図を図 3.12，図 4.25 に示す．プロジェクタから 80 インチのスクリーンに向けて，FORUM8 社の UC-win/Road によって作成したドライビングシミュレータ（図 3.14）を投影した．このコースは片側二車線で，複数の信号交差点が設置されている（図 3.15）．さらに，コース上には先行車，後続車，対向車が存在し，通常交通環境を模擬している．



図 3.11: ドライビングシミュレータの外観




図 3.12: ドライビングシミュレータの構成図




図 3.13: ドライビングシミュレータの配置図 (平面視, 単位: mm)



図 3.14: ドライビングシミュレータの画面




図 3.15: 信号交差点を含んだ走行コース
(被験者は赤色の矢印の方向に従って走行. 一周約 1,790m.)

実験方法

被験者 10 名（21 歳～26 歳）による走行実験を行った。被験者にはドライビングシミュレータ上のコースを、制限速度 50km/h の一般道を想定した上で普段通りの運転をしてもらった。交差点での右左折や車線変更は行わず、直進のみを行うように指示した。また交差点付近の信号機には必ず従い、安全に走行するよう指示した。データ取得を行う前に 5 分間の習熟運転を行い、その後 10 分間のデータ取得実験を行うようにした。

停止確率予測結果

図 3.16 に、式 (3.27) より求めた一被験者の停止予測確率と実験中の実停止確率を示す。停止予測確率は、被験者がブレーキを踏むことで速度が 5m/s まで減速してから、何秒以内に停止するかを予測したものである。図 3.16 では過去 1 秒間の運転行動を考慮した上で、停止行動の予測を試みている。実験中の実停止確率は、ブレーキペダルが踏まれながら車速が 5m/s 以上の速度から 5m/s 以下となる条件が満たされた回数を全数とした場合の、経過時間内に停止した回数の割合として算出した。予測確率の精度を向上させるために、考慮する過去の運転行動の時間長（CDT 長）を変化させた上で停止確率予測を試行し、何秒間の運転行動を考慮することが停止確率予測の精度向上に有効であるかを検討した。




図 3.16: 停止予測結果（実線：予測確率 破線：実停止確率）

CDT 長が停止行動予測に与える影響

CDT 長を変化させた上での予測精度を定量的に評価するために、式 (3.30) で示す誤差評価値 (e_{pred}) を定義した。これは実停止確率と予測確率との二乗誤差であり、値が低いほど予測精度が良いことを意味する。

$$e_{pred} = \frac{1}{T} \sum_{n=1}^T (P_{pred}(n) - P_{expr}(n))^2 \quad (3.30)$$




図 3.17: CDT 長の変化に伴う誤差評価値（全被験者の平均値）

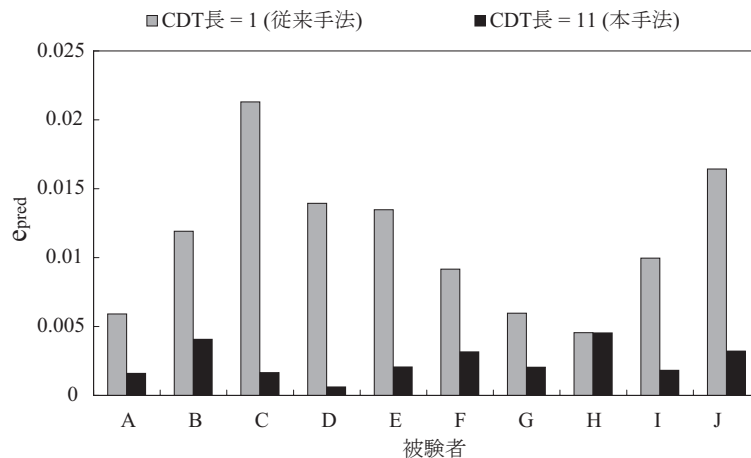


図 3.18: 従来手法と本手法を用いた停止確率予測の誤差評価値 e_{pred} （被験者別）

CDT 長を 0.1 秒から 5.0 秒まで 0.1 秒刻みで変化させ、それぞれの場合に対して誤差評価値を算出し、比較を行った。比較した結果を図 3.17 に示す。これは全被験者の平均値を表している。また、CDT 長が 1 である場合は直前の運転行動のみを考慮するため、従来手法と等価である。CDT 長を 1 から増加させるに伴い予測誤差は減少している。そして CDT 長が 11 である場合に、つまり 1.1 秒の運転行動を考慮することで最適な予測を行うことができた。しかし、CDT 長を過度に増加させることにより停止行動と関わりのない運転データを予測に用いてしまうため、予測精度は減少する結果となった。

CDT 長が 11 である場合での予測結果と、従来研究における予測結果との比較を各被験者において行った。その比較を図 3.18 に示す。全被験者において過去の運転行動を考慮する本手法によって予測誤差が減少し、減少率は最大で 4.45%、平均で 29.48%となった。




図 3.19: 被験者別の最適 CDT 長




図 3.20: 最適 CDT 長を用いることによる予測誤差の減少率

3.2.6 考察

個人適合化

前節においては各被験者に対して共通の CDT 長を用いて停止予測を行ったが、個人に適合した値を用いることによってより高精度な予測が行えることが考えられる。ここで各被験者において予測誤差を最小にする CDT 長を求め、それを最適 CDT 長と定義した。図 3.19 は各被験者の最適 CDT 長を表している。被験者によって最適 CDT 長は異なり、最小で 4、最大で 23 となった。

各被験者に対して最適 CDT 長を用いた場合と、前章で求めた共通の CDT 長を用いた場合との予測誤差の比較を行った。図 3.20 は各場合における予測誤差と、誤差の減少率を表している。全被験者において個人適合化させた CDT 長を用いることで予測誤差の減少が確認でき、最大の減少率は 28.57%であった。また全被験者の減少率を平均すると 67.67%であった。




図 3.21: 最適 CDT 長と平均ブレーキペダル操作量との比較




図 3.22: 最適 CDT 長と平均アクセルペダル操作量との比較

最適 CDT 長と運転傾向との関係


被験者によって最適 CDT 長が異なる原因はモデル構築の際に用いる運転データが異なるためであり、つまり被験者の運転傾向に依存するものと思われる。ここでは被験者の運転傾向をアクセル、ブレーキの平均操作量によって求めた。

図 3.21 は各被験者の実験中における平均ブレーキ操作量を示しており、ブレーキを強く踏む傾向のある被験者の最適 CDT 長は短くなり、逆に浅く踏む被験者の最適 CDT 長は長くなる傾向が確認できる。また相関分析を行ったところ相関係数は 0.84 となり、最適 CDT 長と平均ブレーキ操作量との間にやや強い相関が存在した。この結果より、ブレーキを強く踏み短時間で停止しようとする被験者に対しては、比較的短い時間の運転行動を考慮することが停止予測に有効であることが推測される。図 3.22 は各被験者の実験中における平均アクセルペダル操作量を示しているが、平均ブレーキ操作量と同様な傾向を確

認することができなかった。相関分析を行ったところ相関係数は0.23となったため、最適 CDT 長との相関は存在しなかった。これは停止を行う数秒前においてはアクセル操作をほとんど行わないためであり、アクセル操作量は最適 CDT 長に影響しないといえる。


3.2.7 被験者別の停止確率予測結果

3.2.5 小節では全被験者における CDT 長の最適値、3.2.6 小節では個人適合化させることによって得られた各被験者における最適 CDT 長を求めた。それぞれの値を用いた場合の停止確率予測結果と、実停止確率との比較を各被験者において行った。図 3.23 から図 3.32 に各被験者の停止確率予測結果と、誤差評価値を示す。青色が実験中における実停止確率、緑色が直前の行動のみを考慮する従来手法 [8] による予測確率、赤色が共通の CDT 長を用いた場合の予測確率、水色が被験者毎の最適 CDT 長を用いた場合の予測確率を示している。全被験者において、最適 CDT 長を用いることによって予測精度が向上した。




誤差評価値 (従来手法)	誤差評価値 (共通 CDT 長)	誤差評価値 (最適 CDT 長)
0.0059	0.0016	0.0012

図 3.23: 被験者 A 停止確率予測結果




誤差評価値 (従来手法)	誤差評価値 (共通 CDT 長)	誤差評価値 (最適 CDT 長)
0.0119	0.0044	0.0028

図 3.24: 被験者 B 停止確率予測結果




誤差評価値 (従来手法)	誤差評価値 (共通 CDT 長)	誤差評価値 (最適 CDT 長)
0.0213	0.0028	0.0008

図 3.25: 被験者 C 停止確率予測結果




誤差評価値 (従来手法)	誤差評価値 (共通 CDT 長)	誤差評価値 (最適 CDT 長)
0.0139	0.0006	0.0005

図 3.26: 被験者 D 停止確率予測結果




誤差評価値 (従来手法)	誤差評価値 (共通 CDT 長)	誤差評価値 (最適 CDT 長)
0.0135	0.0021	0.0019

図 3.27: 被験者 E 停止確率予測結果




誤差評価値 (従来手法)	誤差評価値 (共通 CDT 長)	誤差評価値 (最適 CDT 長)
0.0092	0.0032	0.0019

図 3.28: 被験者 F 停止確率予測結果




誤差評価値 (従来手法)	誤差評価値 (共通 CDT 長)	誤差評価値 (最適 CDT 長)
0.0060	0.0024	0.0012

図 3.29: 被験者 G 停止確率予測結果




誤差評価値 (従来手法)	誤差評価値 (共通 CDT 長)	誤差評価値 (最適 CDT 長)
0.0046	0.0052	0.0033

図 3.30: 被験者 H 停止確率予測結果



誤差評価値 (従来手法)	誤差評価値 (共通 CDT 長)	誤差評価値 (最適 CDT 長)
0.0100	0.0018	0.0013

図 3.31: 被験者 I 停止確率予測結果



誤差評価値 (従来手法)	誤差評価値 (共通 CDT 長)	誤差評価値 (最適 CDT 長)
0.0164	0.0032	0.0029

図 3.32: 被験者 J 停止確率予測結果

第4章 生体信号解析による注意力低下状態の検出

本章ではまず Cognitive Distraction 検知に用いたパターン認識手法である SVM と AdaBoost について解説する。その後、各アルゴリズムによる検知結果を示し、さらにドライバーの負担度を考慮した Cognitive Distraction 検知への応用について述べる。

4.1 パターン認識とは

パターン認識 (Pattern Recognition) とは、観測されたパターンをあらかじめ定められた複数クラスの内の一つに対応させる手法である。パターン認識システムの構成を図 4.1 に示す。まず、前処理 (Pre-processing) 部でノイズ除去、正規化 (Normalization) 処理を行う。次に、特徴抽出 (Feature Extraction) によりパターン認識に必要な特徴量 (Feature) を抽出する。特徴量は、特徴ベクトル (Feature Vector) とも呼ばれ、数次元から数十次元で構成され、特徴量で構成される空間は特徴空間 (Feature Space) と呼ばれる。最終的に、特徴ベクトルをクラスラベルへと写像する処理が識別 (Classification) であり、これは特徴ベクトル x の空間をいくつかの部分に分割し、それぞれの部分に対応する c の値 (クラスラベル) を割り付けることになる。




図 4.1: パターン認識システムのブロック図

特徴ベクトルが高次元で複雑な構造をしている場合、判別分析法や K-means 法といった線形手法で識別処理を行うことは困難である。これまで、非線形なデータに対するパターン認識の代表的手法としてニューラルネットワークを用いることが一般的であった [56]。しかし、ニューラルネットワークは局所解に陥ることが多く、最適な解が必ずしも得られない等、問題点が多い。近年、2クラスに識別するパターン認識手法として Support Vector Machine (SVM) [57] が様々な分野で応用されている [58][59][60]。SVM は非線形なデータ分離が可能なこと、パラメータの次元に依存せず精度良い学習が可能なことから非線形データに適しているとされている。また、ニューラルネットワークと比較して SVM がよい結果を示している報告もある [61]。ITS の分野においても SVM は近年用いられることが

多く、Kutilla ら [19][20][21] は実車を運転中のドライバーの Cognitive Distraction を検知するのに用いている。4.1.1 節において SVM のアルゴリズムについて詳しく述べる。また同様に、ニューラルネットワーク等の非線形を用いる手法が局所解に落ち込むという問題を解決しようとする Boosting という手法がある。これは多数の弱解を学習によって作り出し、それらを統合することによって良い識別方法を作り出すという手法である。Boosting の各種アルゴリズムを 4.1.2 節で述べる。

4.1.1 Support Vector Machine

Vapnik[57] によって提案された SVM は、機械学習 (machine learning) アルゴリズムの一つであり、2つのクラスを識別する識別器を構成するための学習法である。多クラスの識別器を構成するためには、複数の SVM を組み合わせるなどの工夫が必要となる。導入から数年で、物体認識、顔認識、台風解析、言語処理、多数の事例に適用されてい [58][59][60]。SVM の基本的な概念としては、より高次元の特徴空間に学習データを写像することにより線形分離可能にする (図 4.2)。その特徴空間における2つのクラスの距離 (マージン) を最大化するように分離超平面を構成する。線形分離可能 (linearly separable) であるとは、学習データを正確にクラス分類する超平面が存在する場合のことを指す。




図 4.2: SVM の基本的概念

SVM の基本形

以下では SVM の目標を 2つのクラスへの分類とする。訓練サンプルを

$$\{(x_i, y_i) | i = 1, 2, \dots, n\} \quad (4.1)$$

とし、入力パターン $x_i \in R^d$ 、クラスラベル $y_i \in \{\pm 1\}$ とする。

SVM の基本形は線形しきい素子であり、入力 x に対して、2 値の出力 y を以下の線形識別関数に従って出力する。

$$y = \text{sign}(\mathbf{w} \cdot \mathbf{x} + b) \quad (4.2)$$

ここで \mathbf{w} は重みベクトル、 b はバイアス項と呼ばれる。また $\text{sign}(a)$ は

$$\text{sign}(a) = \begin{cases} 1 & (a \geq 0) \\ -1 & (a < 0) \end{cases} \quad (4.3)$$




図 4.3: SVM による線形分離 (○がクラス 1 のサンプル, □がクラス-1 のサンプル, ●と■はサポートベクターを示す.)

と定義する. 幾何学的には, 入力空間である R^d を $w^T x + b = 0$ で定義される超平面で 2 つに分離し, 一方を 1, 他方を -1 と対応させていることになる.

線形 SVM

訓練サンプルの集合として, N 個の特徴ベクトル x_1, \dots, x_N と, それぞれのサンプルに対する正解のクラスラベル y_1, \dots, y_N が与えられているとする. また, この訓練サンプルの集合は線形分離可能であるとする. 図 4.3 に, SVM によって線形分離されたデータの例を示す.

SVM では, 訓練サンプルを完全に識別する超平面の中で最も優れているものは, 二つのクラスの「真ん中」を通るものである. SVM は超平面を決定するために「マージン最大化」を行う. マージンとは, 超平面と各訓練サンプルとの距離の中で最小値になるものをいう. 図 4.3 においては●と■で示された訓練サンプルは超平面との距離が最小となる. このようなサンプルは, 超平面の周りにあり, 超平面をサポートしているように見えるため, 「サポートベクター」と呼ばれる.

もし訓練サンプル集合が線型分離可能なら,

$$y_i(w \cdot x_i + b) \geq 1, \quad i = 1, \dots, N \quad (4.4)$$

となるパラメータが存在する. このとき, 二つのサポートベクターは

$$(w \cdot x^+) + b = 1 \quad (4.5)$$

$$(w \cdot x^-) + b = -1 \quad (4.6)$$

で表される. また x^+ は以下の式で表される.

$$x^+ = x^- + \lambda w \quad (4.7)$$

式(4.5)(4.7)より λ の値を求める.

$$\begin{aligned}
 \mathbf{w} \cdot (\mathbf{x}^- + \lambda \mathbf{w}) + b &= 1 \\
 \mathbf{w} \cdot \mathbf{x}^- + b + \lambda \mathbf{w} \cdot \mathbf{w} &= 1 \\
 -1 + \lambda \mathbf{w} \cdot \mathbf{w} &= 1 \\
 \lambda &= \frac{2}{\mathbf{w} \cdot \mathbf{w}}
 \end{aligned} \tag{4.8}$$

以上の式より, マージンを得ることができる.

$$\begin{aligned}
 \text{Margin} &= |\mathbf{x}^+ - \mathbf{x}^-| = |\lambda \mathbf{w}| \\
 &= \lambda |\mathbf{w}| = \lambda \sqrt{\mathbf{w} \cdot \mathbf{w}} \\
 &= \frac{2\sqrt{\mathbf{w} \cdot \mathbf{w}}}{\mathbf{w} \cdot \mathbf{w}} = \frac{2}{\sqrt{\mathbf{w} \cdot \mathbf{w}}}
 \end{aligned} \tag{4.9}$$

よってマージンの大きさは $\frac{2}{\sqrt{\mathbf{w} \cdot \mathbf{w}}}$ となる.

マージン最大化を目的としたSVMの学習とは, 以下の制約付き最適化問題を解くことと等価である.

目的関数: $\text{minimize } \mathbf{w} \cdot \mathbf{w}$

制約条件: $y_i(\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1, \quad i = 1, \dots, N$

目的関数が二次関数で, 制約条件が全て線形な最適化問題は2次計画問題と呼ばれる. 制約付きの最適化問題は, ラグランジュの未定乗数法を用いることにより, より簡単な問題に帰着することが多い. ラグランジュ乗数を $\alpha_i \geq 0$ とすると,

ラグランジュ関数 $L(\mathbf{w}, b, \boldsymbol{\alpha})$ は,

$$L(\mathbf{w}, b, \boldsymbol{\alpha}) = \frac{1}{2} \|\mathbf{w}\|^2 - \sum_{i=1}^n \alpha_i (y_i (\mathbf{x}_i^\top \mathbf{w} + b) - 1) \tag{4.10}$$

を得る. 最適化問題を解くためには, \mathbf{w}, b について L を最小化し, $\boldsymbol{\alpha}$ について最大化すればよい. 最適解においては, L の勾配が0になるため, 次式が成り立つ.

$$\frac{\partial L}{\partial b} = 0, \quad \frac{\partial L}{\partial \mathbf{w}} = 0 \tag{4.11}$$

この式(4.11)より, 次のような関係が導かれる.

$$\sum_{i=1}^n \alpha_i y_i = 0 \tag{4.12}$$

$$\mathbf{w} = \sum_{i=1}^n \alpha_i y_i \mathbf{x}_i \tag{4.13}$$

これを式(4.10)に代入すると, $\boldsymbol{\alpha}$ のみに関する最大化問題となる.

$$\text{目的関数: } \text{maximize } \sum_i \alpha_i - \frac{1}{2} \sum_{i,j=1}^N \alpha_i \alpha_j y_i y_j \mathbf{x}_i^\top \mathbf{x}_j$$




図 4.4: ソフトマージンを導入した SVM

$$\text{制約条件: } \alpha_i (\geq 0) \quad (i = 1, \dots, N), \quad \sum_{i=1}^N \alpha_i y_i$$

最適な α から式 (4.13) を用いて, w を求めることができる. また, b は,

$$b = -\frac{1}{2}(w^\top x_A + w^\top x_B) \quad (4.14)$$

により求められる. ここで, x_A, x_B は, それぞれクラス A, B に属する SV である.

ソフトマージン SVM

前節では訓練サンプルが線形分離可能という仮定のもとであったが, そうでない問題を扱うことのほうが断然多い. これに対抗する手段は 2 つあり, そのうちの 1 つは「ソフトマージン法」である.

ソフトマージンとは, 多少の誤識別は許容するように式 (4.4) の制約を緩和するという考え方である. つまり,

$$t_i(w^\top x_i + b) \geq 1 - x_i, \quad i = 1, \dots, N \quad (4.15)$$

とするのである. この x_i はスラック変数と呼ばれる非負の変数である. 当然, 誤識別は少ないほうがよいので, $\sum_i x_i$ は最小にしたい. そこで目的関数は以下のように置き換わる

$$\text{目的関数: } \text{minimize } w \cdot w + C \sum_i x_i$$

ここで C は誤識別の許容度合を示す正の定数で, 大きいほど誤識別を認めないことになる.




図 4.5: 線形分離不可能なデータ分布




図 4.6: 高次元空間での線形分離

カーネル法

ソフトマージン法は線形分離な枠組の中で SVM を拡張するものであった。これに対し「カーネル法」は、完全に非線型な曲面を見つける方法である。

カーネル法の基本的アイデアは、元の空間自身をより次元の高い空間に変形することである。図 4.5 は 2 次元空間でのデータ分布を表しているが、○と□を線形に分離することができない。しかし図 4.6 のような 3 次元空間に変形すれば、○と□を線形分離することが可能となる。

高次元空間への変換を Φ で表すことにする。変換された空間では、距離が定義されていないと 2 つの集合を最適に分離する超平面を見つけることができない。変換後の空間での距離は、元の空間での距離と関係があるほうが都合がよい。よって、点 \mathbf{x} と点 \mathbf{x}' の組に対してカーネル関数 $K(\mathbf{x}, \mathbf{x}')$ を定義する。カーネル関数は、

$$K(\mathbf{x}, \mathbf{x}') = \Phi(\mathbf{x})^T \Phi(\mathbf{x}') \quad (4.16)$$

という関係を満たすものである。カーネル関数は高次元空間で測られた距離に相当するものである。これにより、マージンを通常の距離の変わりにカーネル関数を用いて測り、このマージンをもとに最適化を行って分離超平面を求めると、もとの空間では非線形の境界になる。カーネル関数の例として、次のようなものがある。

$$K(\mathbf{x}, \mathbf{x}') = (\mathbf{x}^T \mathbf{x}' + 1)^P \quad (\text{多項式カーネル}) \quad (4.17)$$

$$K(\mathbf{x}, \mathbf{x}') = \exp\left(-\frac{\|\mathbf{x} - \mathbf{x}'\|^2}{\sigma^2}\right) \quad (\text{ガウシアンカーネル}) \quad (4.18)$$

多項式カーネルの次数を決定するパラメータ p 、ガウシアンカーネルの広がり決定するパラメータ σ は、いずれも最適な値を設定しなければならない。

4.1.2 弱学習器の集団学習

集団学習とは

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。非線形分離が可能である SVM はその条件を満たしているといえるが、特徴量の個数に依存して内積計算が増大するため、結果を得るまでの計算時間が非常にかかるという欠点がある。またモデルが複雑であるがゆえに、データの雑音成分に過剰にしまうことが起こりうるため、汎化性能が低下するといった問題も発生する。

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バギングと Boosting について述べる。Boosting については、フィルタによるブースティングと AdaBoost について詳しく述べる。また AdaBoost には学習の仕方により Real AdaBoost と Gentle AdaBoost と Modest AdaBoost に分けることができるため、各々のアルゴリズムについて解説を行う。

バギング

バギングはブストラップ法により例題をリサンプリングして異なる仮説を多数作り、それから集合体を構成することによって最終的な仮説を作る方法一般を指す。

バギングの一般的な手続きは次のようになる。まず N のこの例題 $(x_1, y_1), \dots, (x_N, y_N)$ からなる訓練集合が与えられているとする。

step1 例題より m 回復元抽出し例題を集め、これを用いて仮説 h を学習する。

step2 step1 を B 回行い、仮説を B 個 $(h(x; \theta_i); i = 1, \dots, B)$ 構成する。

step3 回帰問題の場合には

$$H(x) = \frac{1}{B} \sum_{i=1}^B h(x; \theta_i) \quad (4.19)$$

により、判別問題では

$$\begin{aligned} H(x) &= \operatorname{argmax}_{y \in Y} |\{i | (h(x; \theta_i) = y)\}| \\ &= \operatorname{argmax}_{y \in Y} \sum_{i=1}^B I(h(x; \theta_i) = y) \end{aligned} \quad (4.20)$$

により最終的な仮説を構成する。




図 4.7: 学習に用いた例題 (青:+1 のクラス, 赤:-1 のクラス)

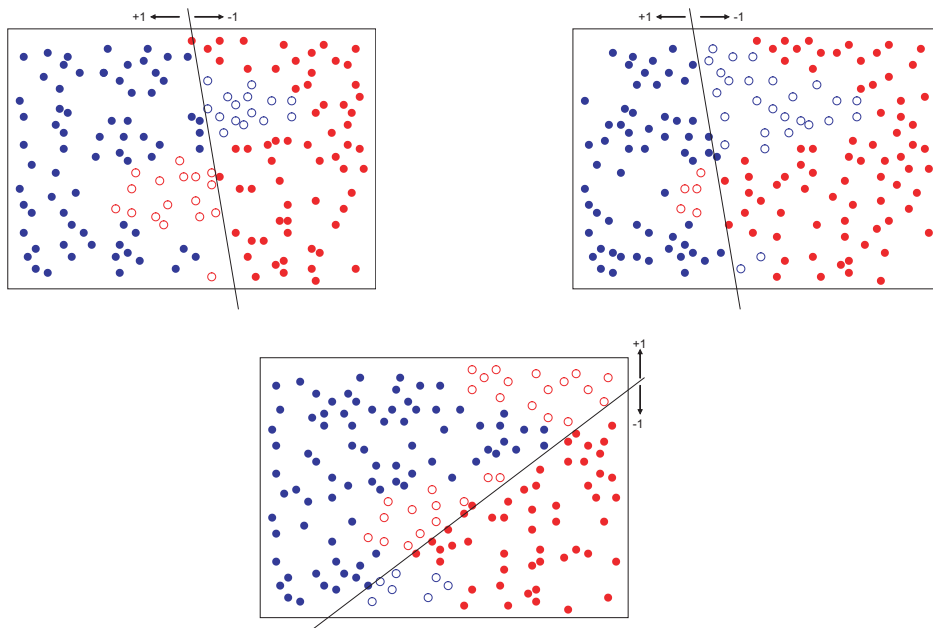


図 4.8: ブートストラップサンプルと弱仮説

これよりバギングによる学習の具体例を示す。図 4.7 のような分布のデータを、学習の例題として用いた。ラベルの違いは色 (青と赤) で表している。

図 4.8 に、異なる 3 つのブートストラップサンプルによって学習された判別機と、判別結果を示す。これらはブートストラップにより得られた例題、その例題により学習された判別機、および適当な大きさの格子点上の値の判別結果を示している。また塗りつぶされた例題は判別機によって正しく判別された例題、中抜きは判別を誤った例題を表している。

図 4.9 はブートストラップによる仮説の生成を 3 回行い、バギングした結果である。この例では誤り率が大きく改善されるわけではないが、区分線形に近かった境界面が異なる学習結果が統合され滑らかで安定した判別曲面に変わっている。

バギングの働きは推定量の偏りと分散御関係から説明されることが多い。推定量は与え




図 4.9: バギングによる最終結果

られる観測値によって異なるが，この推定量の分布で平均した仮説を

$$\bar{h}(x) = E(h(x; \theta)) \quad (4.21)$$

と書くことにする．単一の仮説の平均 2 乗誤差の推定量の分布に関する平均を

$$e = E\{E_p((Y - h(X; \theta))^2)\} \quad (4.22)$$

推定量の分布に関して平均をとった仮説の平均 2 乗誤差を

$$\bar{e} = E_p((Y - \bar{h}(X; \theta))^2) \quad (4.23)$$

とすると次の関係式が成り立つ．

$$\begin{aligned} e &= E\{E_p((Y - h(X; \theta))^2)\} \\ &= E\{E_p((Y - \bar{h} + \bar{h} - h(X; \theta))^2)\} \\ &= E\{E_p((Y - \bar{h} + \bar{h})^2 + 2(Y - \bar{h}(X))(\bar{h}(X) - h(X; \theta)) \\ &\quad + (\bar{h}(X) - h(X; \theta))^2)\} \\ &= E_p\{(Y - \bar{h}(X))^2\} + E_p\{E((\bar{h}(X) - h(X; \theta))^2)\} \\ &= \bar{e} + E_p\{E((\bar{h}(X) - h(X; \theta))^2)\} \end{aligned} \quad (4.24)$$

最後の行の第 2 項は推定量の違いによる仮説の分散を表しているので明らかに正であり， $e \geq \bar{e}$ がいえる．すなわち上で定義した平均 2 乗誤差の意味では，平均した仮説 \bar{h} のほうが単一の仮説 h を用いるより良い推定が行えることになる．しかしながら推定量の分布は道であるので，これをブートストラップ推定量で置き換えたものがバギングであると考えることができる．

バギングは平均 2 乗誤差を減少させることによって不安定な推定量を安定にする働きがあると考えられ，また不安定な推定量ほどその効果は大きいと予想される．よって，過学習をおこしやすい不安定な学習機械を使う場合にバギングは有利であるといわれている．

フィルタによる Boosting

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、これを組み合わせて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、 N_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。

上記のアルゴリズムの働きを、例を使って検証したものを図 4.10 に示す。極端に偏ったサンプリングによって各仮説が大きく異なったものとなり、効率的に学習が行われている様子が分かる。

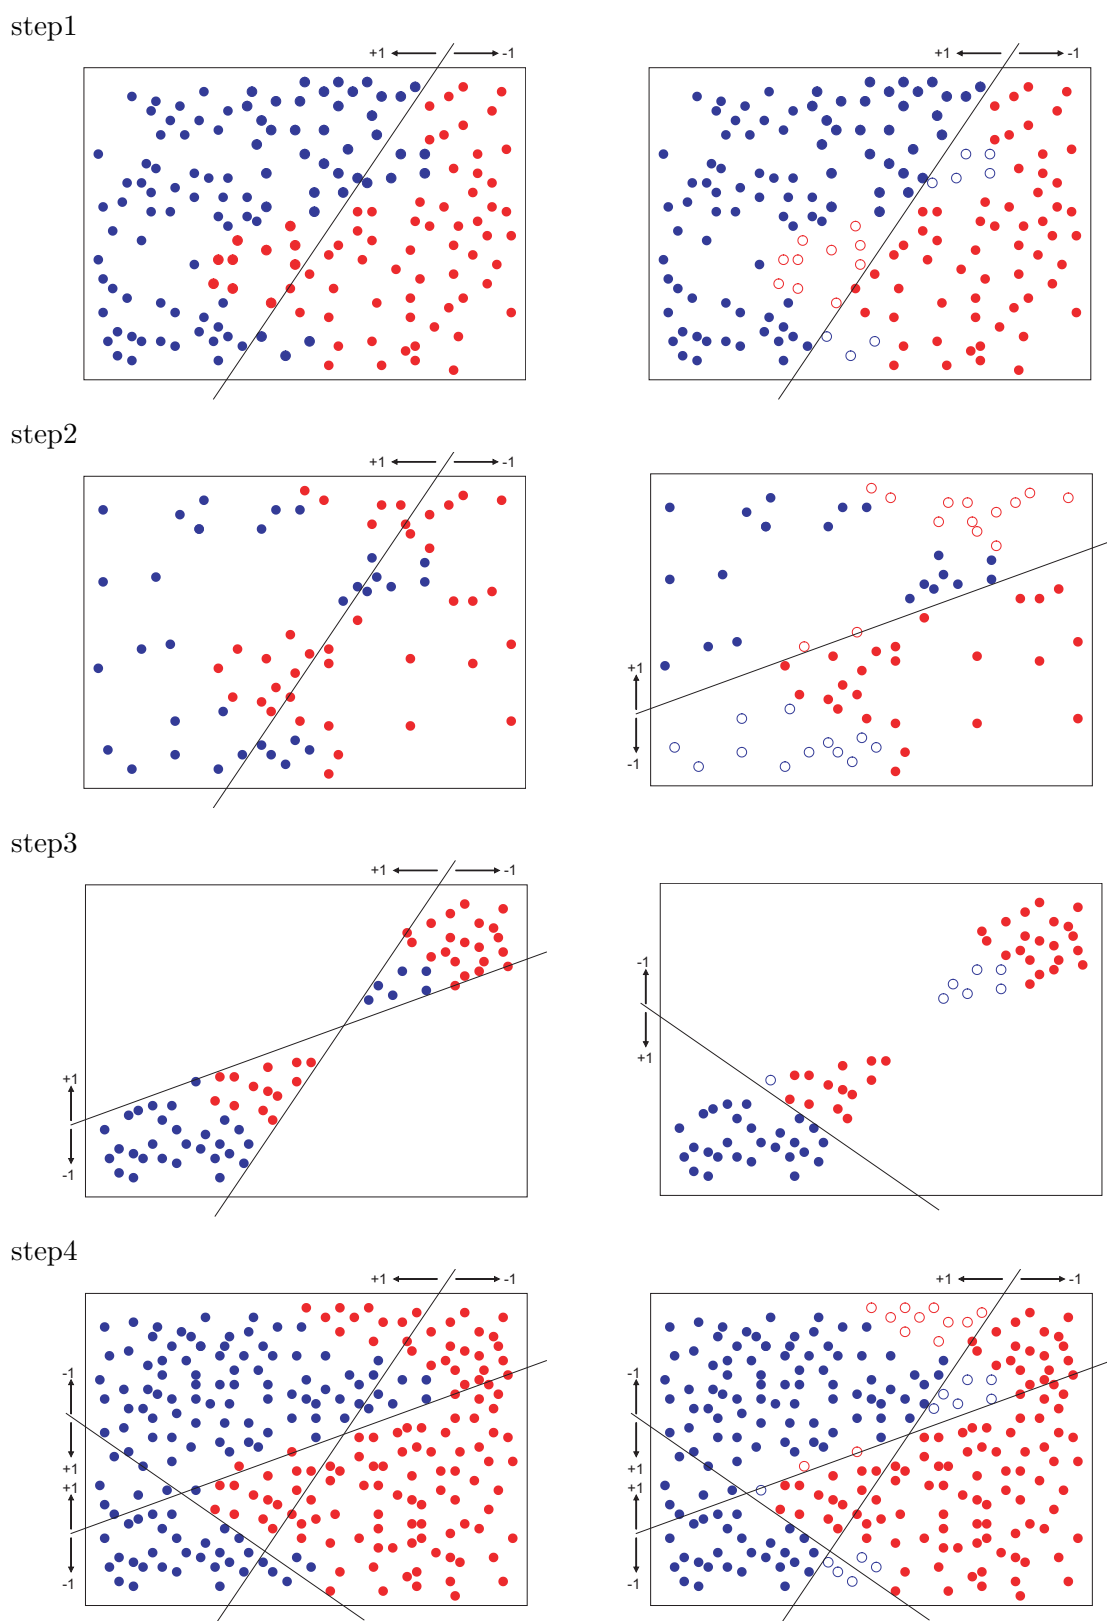


図 4.10: フィルタによるブースティング. 白抜きの円は弱仮説の判別が誤っている例題を示す.




図 4.11: 誤り率の改善




図 4.12: 必要な例題数

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 ϵ 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

$$g(\epsilon) = 3\epsilon^2 - 2\epsilon^3 \quad (4.25)$$

以下になる。関数 g は図4.11の通りであるので、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 ϵ 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、

$$\begin{aligned} N_1\epsilon_1 &= 1 \\ \Rightarrow N_1 &= \frac{1}{\epsilon_1} \end{aligned} \quad (4.26)$$

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

$$\begin{aligned} N_2 &= N_1 \left(\frac{1}{2} \times \frac{1}{\epsilon_1} + \frac{1}{2} \times \frac{1}{1 - \epsilon_1} \right) \\ &= \frac{N_1}{2\epsilon_1(1 - \epsilon_1)} \end{aligned} \quad (4.27)$$

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 ϵ_1, ϵ_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

$$N_3 = \frac{N_1}{\epsilon_1 + \epsilon_2} \quad (4.28)$$

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

$$\left(1 + \frac{1}{2\epsilon_1(1-\epsilon_1)} + \frac{1}{\epsilon_1 + \epsilon_2}\right)N_1 \quad (4.29)$$

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 $\epsilon_1 = \epsilon_2 = \epsilon$ とすると図 4.12 に示したように ϵ 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。

AdaBoost

AdaBoost[64] は Freund と Schapire によって提案されたパターン認識のための学習アルゴリズムの一つである。高い識別性能が得られる、識別が容易である等の利点により、近年盛んにパターン認識等へ応用されている。AdaBoost による学習は、逐次的に学習データの重みを変化させながら異なる識別器を作り、これら複数の識別器の重み付き多数決によって最終的な識別関数を与える。個々の識別器は弱識別器 (weak classifier) もしくは弱仮説 (weak hypothesis) と呼ばれ、それらを組み合わせたものは強識別器 (strong classifier) と呼ばれる。

d 次元入力 $x_i \in R^d$ とそれに対する正解 $y_i \in \{\pm 1\}$ の組を学習データとして用いる。 T 個の弱識別器 $h_t(x), t = 1, \dots, T$ を、信頼度 α_t で重み付けをして結合することにより強識別器 $H(x)$ を構成する (図 4.13)。




図 4.13: AdaBoost の基本的概念

t 回目の学習における重みを $D_t(i)$ とする。重みの初期値はすべて同じ値 $D_1(t) = 1/N$ とし、正しく識別できなかったデータの重みを大きくすることにより、次の弱識別器において重点的に学習される。弱識別器の作成はこの重み D_t をどのように決定するかが問題となる。2 値の判別問題の場合、分布 D_t のもとで誤り率

$$\epsilon_t = \Pr_{D_t}\{h_t(x_i) \neq y_i\} = \sum_{h_t(x_i) \neq y_i} D_t(i) \quad (4.30)$$

をできるだけ小さくするように弱識別器 h_t を選びだすと考えればよい。

次に、弱識別器を組み合わせるために、その識別器の信頼度 $\alpha_t \in R$ を選ぶ必要がある。前述のように、最終的な識別器は弱識別器を信頼度 α で重み付けた多数決によって構成されることとなる。2値識別問題の場合の AdaBoost の具体的なアルゴリズムを以下に示す。

学習データ $(x_1, y_1), \dots, (x_n, y_n)$ が与えられているとする。ただし、 $x_i \in X, y_i \in Y = \{-1, +1\}$ とする。

Step 1 $D_1(i) = 1/N$ によって初期化する。

Step 2 $t = 1, \dots, T$ に対して

- 分布 D_t に基づき弱識別器を学習する。つまり式 (4.30) の最小化を行い、 $h_t : X \rightarrow Y$ を得る。
- 誤り率を用いて以下のように信頼度 $\alpha_t \in R$ を計算する。

$$\alpha_t = \frac{1}{2} \ln \left(\frac{1 - \epsilon_t}{\epsilon_t} \right) \quad (4.31)$$

- 次式により、分布 D_t を更新する。

$$D_{t+1}(i) = \frac{D_t(i) \exp(-\alpha_t y_i h_t(x_i))}{Z_t} \quad (4.32)$$

ただし、 Z_t は、 $\sum_i D_{t+1}(i) = 1$ とするための規格化因子で

$$Z_t = \sum_{i=1}^n D_t(i) \exp(-\alpha_t y_i h_t(x_i)) \quad (4.33)$$


である。

Step 3 最終的な識別器はすべての弱識別器の信頼度で重み付けて多数決をとり、次式により強識別器 $H(x)$ を得る。



$$H(x) = \text{sign} \left(\sum_{t=1}^T \alpha_t h_t(x) \right) \quad (4.34)$$

一般に弱識別器には CART(Classification and Regression Trees) や Decision Stump が用いられることが多い [63]。CART とは次元の値の大小に基づき、決定木を作成し分類を行う手法である。CART を弱識別器に用いた AdaBoost では、データへの重み付けを変えて複数個の CART の学習を行い、それらを精度に応じた重みを与えて線形結合することで最終的な出力を得る。AdaBoost による学習過程を、例を使って検証したものを図 4.14 に示す。



step1



step2
($t = 1$)



($t = 2$)



step3





図 4.14: AdaBoost による学習. 白抜きの円は弱仮説の判別が誤っている例題を示し, 円の大きさは例題の重みを示す.

AdaBoost の派生アルゴリズム

AdaBoost には様々な派生アルゴリズムが存在し、それぞれ学習器 α の信頼度の決定方法の違いがある。式 (4.31) で示した信頼度 α の決定法は Real AdaBoost と呼ばれる。これより、代表的なアルゴリズムである Real AdaBoost, Gentle AdaBoost[65], Modest AdaBoost[66] について解説する。

Real AdaBoost

Real AdaBoost[64] では信頼度 α を式 (4.31) のように定めている。この式より、学習サンプルの過半数を正しく識別することができれば、すなわち式 (4.30) における ϵ_t が 0.5 未満であれば、 α_t は正の値をとり、 ϵ_t が小さくなるほど、 α_t は大きな値をとるようになる。これにより誤りの少ない、正確な弱学習器ほど最終的な貢献度が高くなる。さらに式 (4.32) により、 t 回目で誤ったデータに対して α_t に応じて高い重みを与え、 $t+1$ 回目で重点的に学習を行なうことにより、最終的に正しく識別できるようにする。

Gentle AdaBoost

Gentle AdaBoost[65] では、学習器が正しく +1 と判別する割合 P_t^{+1} と、学習器が正しく -1 と判別する割合 P_t^{-1} から信頼度 α を決定している。 P_t^{+1} と P_t^{-1} は以下のように定義される。

$$P_t^{+1} = P_{D_t}(y = +1 \cap h(x)) \quad (4.35)$$

$$P_t^{-1} = P_{D_t}(y = -1 \cap h(x)) \quad (4.36)$$

ここで $h(x)$ は学習器の出力値である。これらの値から、信頼度 α を以下の式で求める。

$$\alpha = \frac{P_t^{+1} - P_t^{-1}}{P_t^{+1} + P_t^{-1}} \quad (4.37)$$

ここで注意することは、信頼度 α とは学習器が +1 の識別をどれだけ正確に行えるかの尺度であるということである。よって、-1 の識別が正確に行える (P_t^{-1} が高い) ことは、信頼度 α を下げる要因となる。式 (4.37) ではこのことを考慮した上で、学習器が +1 と識別する割合を求めている。

Modest AdaBoost

Gentle AdaBoost の発展型が Modest AdaBoost[66] である。このアルゴリズムでは $D_t(i)$ の反転行列である \overline{D}_t を用いている。

$$\overline{D}_t(i) = ((1 - D_t(i))\overline{Z}_t) \quad (4.38)$$

ここで \overline{Z}_t は、 $\sum_{i=1}^N \overline{D}_t(i) = 1$ とするための規格化因子である。これまで紹介した AdaBoost アルゴリズムでは $D_t(i)$ を用いることで、前回の学習で誤判別したデータに対して高い重みを付けるようにしていた。それに対して $\overline{D}_t(i)$ を適用すると、前回の学習で正し

く判別できたデータに対して高い重み付けが行えるようになる。 \overline{D}_t を用いて以下の式を定義する。

$$\overline{P}_t^{+1} = P_{\overline{D}_t}(y = +1 \cap h(x)) \quad (4.39)$$

$$\overline{P}_t^{-1} = P_{\overline{D}_t}(y = -1 \cap h(x)) \quad (4.40)$$

これらは前回の学習で正しく判別できたデータに対して、新たに用意した学習器がどれだけ正確に判別できるかの尺度を表している。これを用いて、Modest AdaBoost の信頼度 α は以下のように定義される。

$$\alpha = P_t^{+1}(1 - \overline{P}_t^{+1}) - P_t^{-1}(1 - \overline{P}_t^{-1}) \quad (4.41)$$

この信頼度 α を用いると、もし前回の学習での判別率が高かった場合に、学習器の重みを減らすことができるようになる。つまり過学習を抑えながら学習器の重みの変更可能となる。この過程において、以下の式、

$$1 - \overline{P}_t^y, \in \{-1, +1\} \quad (4.42)$$

は 0 になりうる。この場合は前回の学習で判別が完全に行われているため、学習器の重みの更新は行われなくなる。

4.2 パターン認識に基づく生体情報からの Cognitive Distraction 検知

これより，ドライバーの Cognitive Distraction 検知に用いる生体情報について述べる．本研究では視線角度，瞳孔径といった視覚情報と，心電図から得られた心拍情報を用いている．まず 4.2.1 節では視覚情報について述べ，4.2.2 節では心電図について述べる．

4.2.1 視覚情報

視覚系

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 [67]．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 4.15) 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 [68]．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．

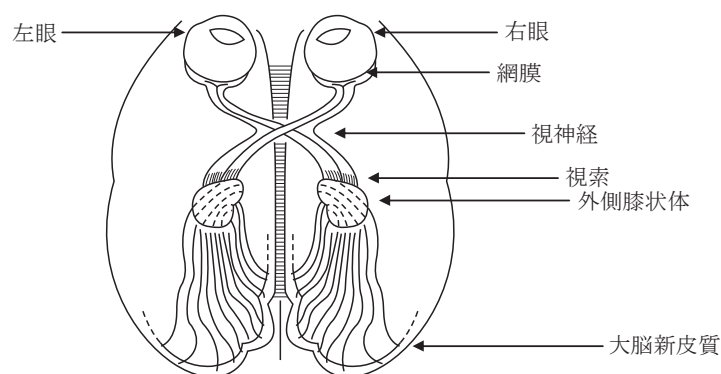



図 4.15: 視覚系の基本構造

視野

視野には静止視野と動視野の2種類で定義されている。目を動かさないで明るい直径1cm程度の円形指標が見える範囲を静止視野といい、およそ水平方向で200deg、垂直方向で120degに及ぶ。さらに目を動かすことでこの範囲が広がり、これを動視野という [69]。

図4.16は視野内から情報を受容するとき、目を動かさないで見ている範囲、目の動きを伴って見ている範囲、目と頭の動きを伴って見ている範囲を示している。



- (1) 弁別視野：高精度な情報受容が可能な範囲
- (2) 注視視野：眼球運動だけで情報探索が可能な範囲
- (3) 安定注視視野：頭部運動が加わり、注視動作が安定に行える範囲
- (4) 誘導視野：視覚情報の存在と内容の大略が分かる程度の範囲
- (5) 補助視野：情報の積極的な受容にほとんど関与しない範囲

図 4.16: 情報受容における視野の機能分布




図 4.17: 各視作業をしているときの視野の大きさ [69]




図 4.18: 瞳孔の位置

視覚機能は視野全体において一様ではなく、細かく物体を見分けられる網膜の範囲は中心窩（fovea）と呼ばれ、狭い範囲に限られている。視野周辺部は視標の存在がわかる程度（sensation field）であり、やや中心部に近づくとその形や大きさなどもわかるようになる（visibly field）。さらに中心部ではノイズの中から対象の物体を見つけ出すことが可能（conspicuity field）となり、必要な情報をノイズの中から分離して検出して作業が可能な範囲（working conspicuity field）はさらに狭い（図 4.17）。

中心視（foveal vision）は中心窩の広がりに対応する中心から半径 5deg 以内の視野、周辺視（peripheral vision）は半径 5deg 以遠の視野を指す。小さな文字や詳細な情報を得ようとする場合は、対象物体を中心視によって捉えられる。一方で、周辺視は明るさの変化や運動する物体の知覚などの時間的情報の受容に優れている。このような機能分担によって、視覚情報の処理が効率よく行われている。

瞳孔

眼球の最前部は角膜で、その後に虹彩、水晶体と続く、眼球の入光部の開口の大きさは虹彩によって調節される。この虹彩によって形成された光学系の開口部が瞳孔（図 4.18）である。この瞳孔の動きには、光学的には以下の 3 つの機能があると考えられている [70]。

- (1) 目に入射する光量の調節
- (2) 目の光学系の開口部を小さくすることで、被写界深度や焦点深度を増大させる
- (3) 特に明るい光の場合に、瞳孔を小さくすることによって色収差、球面差を減少させる

瞳孔は瞳孔散大筋と括約筋のバランスによってその大きさが決定されている。このバランスがさまざまな要因によって影響され、瞳孔の大きさは絶えず変動し得る状態になっている。仮に、明るさが一定で、水晶体の屈折状態が一様であったとしても散大と縮小を繰り返している。

瞳孔は外界から眼球内に取り込む光の量を調節するとともに、興味などの精神活動によっても変化することが知られている [73]。中山ら [74] の報告によると、静止画のグラフを学習者に提示し、音声によってグラフの値を読ませる課題を与えると、被験者がその課題に従ってグラフの値を読む間、瞳孔径は拡大し、回答後、瞳孔径は元の大きさにまで戻るとしている。春日ら [75] は、飲酒運転時のドライバーの瞳孔径が時間経過と共に縮小することから、飲酒後徐々に運転環境への関心が薄れ、注意力が低下すると結論付けている。

また、飲酒量が多い方が瞳孔径の縮小幅が大きくなっており、飲酒量が注意力低下の大きさに影響を与えることも示している。このことから、瞳孔径の拡大・縮小幅を一つの特徴量とすることで Cognitive Distraction 検知の精度向上を図ることができると考えられる。

4.2.2 心臓と心電図

心臓の構造

心臓（図 4.19）は全身に血液を拍出するポンプの働きをしている。心筋には、筋肉の収縮・拡張により血液を送る固有心筋と、固有心筋を動かすための電気刺激の発生と伝導を行っている特殊心筋がある。電気刺激は右心房にある洞房結節（SA node : sinoatrial node）から発生し、心房を介し右心房の下方にある房室結節（AV node : atrioventricular node）へと伝わる。この刺激により心房の収縮が行われる。更に電気信号は房室結節から、心室へと電気刺激が伝わっていく。

ここで、心房と心室とでは、電気刺激を受ける時間差があるために、心房の収縮に遅れて心筋の収縮が起こる。これにより心房から心室へと血液をうまく送ることができる。

心電図

心電図は、心臓で発生した電氣的刺激を身体の各部位で検出、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。ヒトの心電図は 1887 年 Waller により Lippman の毛管電気計を用い、初めて記録された [76]。それ以来、電極の改良、誘導法の改善などめざましく発展し、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。図 4.20 は基本的な心電図の波形を示したものである。測定法、測定を行った環境によってことなり、図の通りに記録されるとは限らない。心電図のそれぞれの波には名前があり、それぞれ心臓の運動によるものである。

P 波：小さな波で心房の興奮によって生じる

QRS 波：Q, R, S の各波からなり、心室の興奮によって生じる

T 波：心室の興奮が醒めていくことによって生じる

U 波：T 波の後に出現する緩やかな波のことで、成因は不明




図 4.19: 心臓の構造




図 4.20: 基本心電図の波形

心電図誘導法には様々な方法が提案されているが、一般的に用いられるのは標準四肢誘導と呼ばれる方法である [77]。第 I 誘導とは、左右の手の間に発生する電圧を検出する誘導法であり、左手が右手に対して + 電位になったときに心電図記録上で正電位となるように規定されている。同様に第 II, 第 III 誘導は、それぞれ左足 (+) と右手 (-) との間の誘導, 左足 (+) と左手 (-) との間の誘導である。いずれの場合も、右足が基準電位としてのアース電極 (E) とみなされる。

4.2.3 生体情報計測機器

視覚情報計測システム

視覚情報を取得する装置として, SeeingMachines 社 [79] の faceLAB システムを用いた。システムは 2 台のカメラ (図 4.21) 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。サンプリングレートは 60Hz であり, 視線・頭部位置と回転角度 (x 軸, y 軸, z 軸), 瞬目・サックード発生箇所, 左右眼開閉度, 瞳孔径等の情報をリアルタイムで計測する。

視線・頭部方向追跡の計測基準点を, 図 4.22 に示す。視線方向計測基準点は 6 点で, 頭部方向計測基準点は 3 点としている。視線角度は, 図 4.23 に示す縦方向回転のピッチ角成分 (上方向を正值) と横方向回転のヨー角成分 (左方向への回転を正值) として出力される。頭部の回転についても同様に定義される。




図 4.21: faceLAB カメラシステムの構成




図 4.22: 視線・頭部方向計測基準点




図 4.23: 視線ピッチ角とヨー角の定義

ドライバーの視線および頭部を追跡するために、2台のカメラをドライビングシミュレータのダッシュボード上に配置した（図 4.24, 図 4.24）。配置する際には、被験者の顔全体がカメラで捉えられる、ステアリング操作によってカメラの視界が遮られない等の点に注意して行った。

カメラから得られた画像を専用ソフトによって処理することで、各視線情報をリアルタイムで取得する。図 4.26 は faceLAB システムの画像解析ソフトの画面であり、これによって各種情報がグラフィカル表示される。




図 4.24: faceLAB システムの設置個所




図 4.25: faceLAB システムを含めたドライビングシミュレータの構成（平面視，単位：mm）

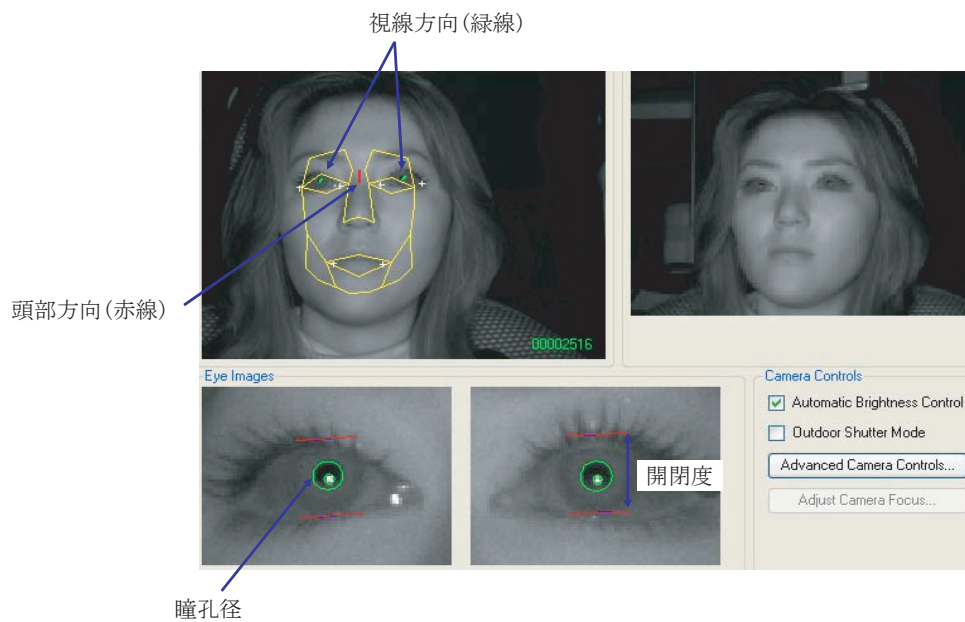


図 4.26: 専用ソフトによる視覚情報のリアルタイム計測

心電計

心電図取得のためにデジテックス研究所製 AP1000 (ポリメイト, 図 4.27) を用いた. 本研究では胸部 3 点電極で計測する標準四肢誘導の第 II 誘導 (図 4.28) により, サンプリングレート 1000Hz で心電図を測定した. 高サンプリングレートによる測定は交流ノイズの混入が起るため, バッテリーによる直流環境下において測定を行った.




図 4.27: 心電計 (AP1000 ポリメイト)




図 4.28: 心電図計測方法 (第 II 誘導)

4.2.4 Cognitive Distraction 模擬実験

サブタスク負荷による Cognitive Distraction の模擬

被験者 10 名による, Cognitive Distraction 模擬実験を行った. 被験者の情報は表 4.1 に示す通りである.

運転中の被験者に会話や思考のような Cognitive Distraction を模擬的に作り出すために, 先行研究 [19] に従いサブタスクとして暗算タスクおよび会話タスクの 2 種類を課した. 暗算タスクは 1000 から 7 を連続減算する. その際, 回答は発話させた. 会話タスクは被験者が普段から通る道 (例. 学校から自宅) の経路案内を行わせた. その際, 信号や目印となる建物をできる限り詳細に説明させた. こうした経路案内のサブタスクは文献 [80] で両眼の注視点にずれが生じることが報告されている. また, サブタスクの付加による反応時間の遅れも報告 [52] されているため, サブタスクは Cognitive Distraction をつくり出すために有効なものであると考えた.

ドライビングシミュレータでの運転は, はじめに習熟走行し, その後にサブタスク無しの走行, 会話タスクを付加した走行, 暗算タスクを付加した走行の順で行った. 各走行は 5 分間ずつであり, 間に 3 分間の休憩を設けた (図 4.29).

表 4.1: 実験被験者

被験者	A	B	C	D	E	F	G	H	I	J
年齢	21	23	22	23	21	22	22	21	23	21
性別	男	女	男	女	男	女	男	男	男	男
運転歴 (年)	2	5	3	3.5	1	3	3	3	3.5	2




図 4.29: 実験手順

走行コース

Cognitive Distraction を模擬するために, ドライビングシミュレータを用いた実験を行った. ドライビングシミュレータによる実験は, 実車での実験と異なり事故を起こすことがないため, ドライバーの疲労や居眠りのような危険運転を観察する際に危険が伴わない. また, 複数の被験者に対し, 同様の交通状況による実験が可能であるなどの利点が挙げられる. 本研究では, モックアップのドライビングシミュレータを用い, 前方のスクリーンに投影されるコースを走行する. コースの作成には FORUM8 社の UC-win/Road を用いた.

実験では郊外道路を模擬した片側二車線道路を用いた（図 4.30, 図 4.31）. 道路脇に建物を複数設置し, 緩やかなカーブ（曲率半径は最大で約 700m, 最小で約 80m）が連続している. 被験者にはこのコースを 60km/h で定速走行するよう指示した.



図 4.30: シミュレータ上の郊外道路




図 4.31: 郊外道路外観（一周約 6,080m）

4.2.5 取得データに対するノイズ処理

視線角度データに対するノイズ除去手法

視線データ上のノイズ

faceLABによって取得される視線角度データには、被験者が瞬きをする、もしくはサッカードが発生することによって高周波信号が混入する。瞬きによる高周波信号は解析の際に障害となるため除去されることが望ましいが、サッカードによって発生する高周波信号は視線の動きを表しているため、除去されるべきではない。よってノイズ除去手法として、サッカードによる高周波信号を残しつつ瞬きノイズを除去することが求められる。図 4.32 に、視線データ上と瞬き発生箇所を示す。瞬きが発生したフレームでは、スパイク状の高周波ノイズが混入していることが観測される。その他の高周波信号はサッカード、もしくはその他の原因で発生したノイズであると考えられる。よって瞬きによって発生したスパイク状の高周波信号のみに着目し、この信号を除去するフィルタを構築した。




図 4.32: 視線角度データ上の瞬きノイズ

瞬き、サッカード取得実験

ノイズ除去へのアプローチとして、まず瞬きとサッカードによって発生する高周波信号を実験によって取得し、その解析を行った。

実験では、ランダムな場所に出現する白のマーキングを目で追うことで瞬きとサッカードを発生させるようなことを実施した。図 4.33 に実験に用いたマーキング作成プログラムを示す。白のマーキングは中央もしくは4隅を5秒間隔で移動する。移動する場所はランダムに決定されるが、運転中はほぼ常に中央を注視していることを考慮して、必ず中央を介してから他の場所に移動するように設定した。

マーキング作成プログラムを用いて、被験者の両目の視線データを取得した。データの例を図 4.34 に示す。図中の青線は右目視線角度（ピッチ角）、緑線で囲まれた区間は瞬き

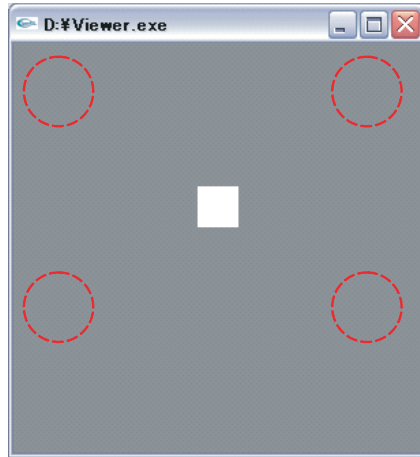


図 4.33: マーキング作成プログラム. マーキングは 5 秒間隔で 4 隅のいずれかの場所にランダムに移動する.




図 4.34: 視線データと瞬き, サッカード発生箇所




図 4.35: 視線回転角速度

の発生箇所, 赤線はサッカードが発生した箇所を表わしている. 実験後にビデオ映像から人の目によって瞬き発生箇所を確認した. サッカードについては 5 秒間隔で発生箇所を示した.

瞬きとサッカードによって高周波信号が発生するが, 信号成分に違いがあると予想される. 瞬き, 及び, サッカードによる高周波信号の違いを明らかにするために, 視線データを微分することで視線回転角速度を求め, その比較を行った. 視線回転角速度 $V(t)$ は以下の式で求めることができる.

$$V(t) = (d(t) - d(t - 1)) \times Hz \quad (4.43)$$

ここで $d(t)$ は時刻 t での視線回転角度, Hz は faceLAB のサンプリング周波数である. これに基づいて求められた視線回転角速度を図 4.35 に示す. この図から, 瞬きとサッカード




図 4.36: 視線角度データ




図 4.37: FFT による周波数解析結果

発生箇所が高周波信号が混入していることが観測され、サッカード速度は最高で毎秒 600° といわれている [81] が、図 4.35 のデータではその範囲内となっていた。瞬きについては、発生箇所においてサッカードよりも速い視線回転角速度を示した。しかしこれは瞬きによるノイズであるため、実際の速度ではない。また、瞬きもサッカードも発生していない箇所での高周波ノイズは、faceLAB が視線をトラッキングできなかつたために生じたエラーノイズである。

実験で得られた視線角度データ（図 4.36）に対して FFT による周波数解析を行った。図 4.37 にその結果を示す。この図より、高周波成分をカットするノイズ除去を行わないとノイズ成分が多分に含まれてしまうことがうかがえる。サッカードは速くとも 1 秒間に 3 回程度が限度であるため [82]、3Hz 以上の成分は瞬き、もしくはエラーノイズであるといえる。

この実験において、サッカードに比べて瞬きは高周波成分において、視線データにより強い変化をもたらすことが明らかとなった。またサッカードは速くとも 1 秒間に 3 回程度が限度であるが [82]、瞬きはそれ以上の回数行うことができる。このことよりも、瞬きはサッカードよりも高い周波数成分を含むことが推測される。よってサッカードによって発生した高周波成分を残しつつ、瞬きノイズを除去するためのフィルタには、サッカードが発生する周波数帯域 (3Hz 以下) は通過させることが要求される。

瞬きノイズ除去フィルタ

以上で示したことを背景として、サッカードの信号を維持しながら瞬きノイズを除去するフィルタを考案した。

まず、13 点のメディアンフィルタを適用することで細かいノイズを除去する。これは先行研究 [19][20][21] でも用いている手法である。その後、1Hz ローパスフィルタによって図 4.38 のような低周波信号を生成し、オリジナル信号との交差点を求める。もし交差点区間が十分に狭く（つまり高い周波数成分であり）、さらに区間内の両信号の差の最大値が閾値以上であれば、図 4.39 のように低周波信号に置き換える。以上の流れによって、瞬きやサッカードによる突出した信号ノイズを除去することができる。

サッカードを残すノイズ除去フィルタ構築のためには、交差点区間の幅、つまりどれだ




図 4.38: 瞬き, サッカーデータに基づくノイズ除去




図 4.39: ノイズを含む視線データ




図 4.40: 瞬き, サッカードを共に除去した信号




図 4.41: 瞬きのみを除去した信号

け高い周波数成分を扱うかが問題となる．ここではサッカードを 3Hz 以下の信号として、ノイズ除去フィルタを構築した．

図 4.34 のデータに対してノイズ除去を実行した．図 4.40 に瞬きとサッカードを共に除去した信号，図 4.41 に 3Hz 以下の信号を残すフィルタによるノイズ除去後の信号を示す．図 4.40 では瞬きの他に通常の視線移動と思われる信号まで除去されているが，図 4.41 ではある程度それが保持されている．ノイズ除去後の視線データ（図 4.42）に対して周波数解析をした結果を図 4.43 に示す．ノイズ除去前では瞬き，もしくはエラーノイズと思われる 3Hz 以上の成分が多く含まれていたが，ノイズ除去によってその成分が減少している．




図 4.42: ノイズ除去後の視線角度データ




図 4.43: FFT による周波数解析結果

瞳孔径角度データに対するノイズ除去手法

図 4.44 は通常運転時における右目瞳孔径の元波形である。faceLAB の特性上、被験者が瞬きをすることで瞳孔径が 0mm であると判断されるため、非常にノイズが多いデータとなる。よって瞳孔径を正しく捉えるために瞬きノイズ除去フィルタを構築した。




図 4.44: 瞳孔径データの元波形

高周波ノイズを取り除くために通常用いられるバターワースフィルタでノイズ除去を行うと、元波形の高周波成分のパワーが大きいため正しくノイズ除去を行うことができない。ここでは瞳孔の可動範囲が 2mm~8mm であること [70][71] に着目し、瞳孔径が 2mm 以下となった場合に前後の値から線形補間する手法を用いた。

図 4.45 は瞳孔径データのイメージ図であり、緑線が元波形、青線が線形補間値である。ノイズの起点フレームを a 、終点フレームを b 、フレーム i における瞳孔径の元データ値を $x(i)$ としたとき、式 (4.44)(4.45) に従って区間 $i \in [a + 1, b - 1]$ のノイズ除去データ $y(i)$ を求める。




図 4.45: 瞳孔径データに対する線形補間




図 4.46: 線形補間, バターワースフィルタによるノイズ除去




図 4.47: 線形補間, バターワースフィルタによるノイズ除去

$$j \in [1, b - a - 1] \quad (4.44)$$

$$y(a + j) = x(a) + \frac{j(x(b) - x(a))}{b - a - 1} \quad (4.45)$$

瞬きノイズが除去された信号に対してさらにバターワースフィルタを通すことによって、細かいノイズを除去する。図 4.46 の青線が元波形，緑線が線形補間後の波形，赤線がバターワースフィルタ通過後の波形である。以上の手順により，瞬きおよび計測誤差による細かいノイズを除去することができる。

線形補間とバターワースフィルタによるノイズ処理を行うことで，タスク別の瞳孔径をより正確に比較することができる。図 4.47 は瞬きノイズ除去後のタスク別瞳孔径の比較を示している。通常運転時には精神的負荷が少ないために瞳孔径は縮小傾向にあるが，サブタスクを付加することで精神的負荷が増大し，それに伴って瞳孔径が増加する傾向がみられた。

4.2.6 特徴量抽出とその評価

取得データからの特徴量抽出

本研究では表 4.2 で示される特徴量について，Cognitive Distraction 検知に有効であるかを評価した．各特徴量は，いずれも精神的負荷によって変化が起きると先行研究において報告されている．これより，Cognitive Distraction 模擬実験で得られたデータから各特徴量を抽出する過程を述べる．

表 4.2: 取得データからの特徴量抽出

種別	特徴量	
視線・頭部位置の移動量	右目視線角度ピッチ角	合成視線角度の標準偏差
	右目視線角度ヨー角	
	左目視線角度ピッチ角	合成視線角度の標準偏差
	左目視線角度ヨー角	
	頭部回転角度ピッチ角	合成視線角度の標準偏差
	頭部回転角度ヨー角	
瞳孔径	右目瞳孔径	
	左目瞳孔径	
対象物追跡率	右目視線品質指標，平均値	
	左目視線品質指標，平均値	
	頭部位置品質指標，平均値	
心電図	RRI，平均値	
車両挙動	レーンキープ量標準偏差	

視覚情報の特徴量

精神的負荷により視線の範囲が狭くなることが報告されており [50][83]，欧州の研究においても同様に，サブタスクによる認知負荷を与えて車両進行方向の視標に視線が集中することが報告されている [19][20][21]．Victor らによる先行研究ではこの点に注目し，合成視線角度の標準偏差を特徴量として Cognitive Distraction 検知を行っている [53]．したがって本研究においても同様に視線角度の標準偏差を用いる．また，頭部運動は眼球運動に同期して働く [54] ため，視線が集中することにより頭部の回転にもばらつきが起きると考える．そこで視線と同様にその標準偏差を算出して用いる．標準偏差は先行研究 [53] を参考に，過去 5 秒間分のデータから次式 (4.46) および式 (4.47) により算出する．

$$x(i) = \sqrt{x_{pitch}(i)^2 + x_{yaw}(i)^2} \quad (4.46)$$

$$\sigma(i) = \sqrt{\frac{1}{4} \sum_{j=i-4}^i (x(j) - \bar{x})^2} \quad (4.47)$$

ここで， $x(i)$ は合成視線（頭部回転）角度， $x_{pitch}(i)$ はピッチ角度， $x_{yaw}(i)$ はヨー角度， $\sigma(i)$ は視線（頭部回転）角度の標準偏差を表す．

視線移動範囲の他に、瞳孔径についても精神的負荷に影響するといわれている。中山 [74] らや春日 [75] らは、注意力が低下するに伴って瞳孔径が拡大すると報告している。よって本研究では、4.2.5 節で述べたノイズフィルタ通過後の瞳孔径データを特徴量として用いることにした。

また先行研究に [19][20][21] において、検知対象がどの程度追跡できるかの程度を示す品質指標を特徴として加えることで検知精度が向上したと報告している。よって本研究では上記の特徴量に加えて、視線および頭部の品質指標を Cognitive Distraction 検知に用いる特徴量として選択した。品質指標については、5 秒間の窓間隔における平均値を用いることとした。

心電図の特徴量

心臓の活動は自律神経の影響を受けるため、精神活動とも密接に関係している。心拍は交感神経と副交感神経のバランスによって速さが決定し、一般的に交感神経が優位るとき心拍数が増加し、副交感神経優位るとき減少する。また、怒りや恐怖などのストレスで交感神経が優位になり、心拍数は増加する。永岑ら [84] や田場ら [85] は安静時において、精神的負荷課題を与えることで心拍数が増加することを報告している。ドライバーが Cognitive Distraction である場合、運転以外の会話や思考等の影響が心拍数に表れ、RRI が減少すると考えられる。したがって、本研究においては RRI を Cognitive Distraction 検知のための特徴量の一つとして用いる。

次に、心電図波形から RRI を算出するためのピーク検知アルゴリズムについて述べる。ただし、R 波のピーク電圧の閾値を $R_{min} = 400mV$ 、また通常、R 波は 0.5~1.0 秒の間隔で起こるため、R 波が現れるまでの最短時間を $t_{min} = 0.5$ 秒と設定した。時刻 t において心電図波形 $f(t)$ がピークとなるための条件は、

$$f(t) - f(t-1) > 0 \quad (4.48)$$

かつ

$$f(t) > R_{min} \quad (4.49)$$

である。しかし、ノイズ等の影響により t を一意に決定できない場合が存在する。そこで式 (4.48) の条件を $f(t)$ より過去の値を用いて、すべての i について次式を満たすように変更する。

$$f(t-i) - f(t-(i-1)) > 0, \quad i = 0, \dots, n \quad (4.50)$$

本研究では $n = 3$ とした。式 (4.49) および式 (4.50) を満たすものを R 波のピーク候補とした。ピーク候補より t_{min} 間、新たなピーク候補が見つからなかったとき、そのピーク候補の発生時間をピーク発生時間 P_n とし、 RRI_n は次式からピーク発生時間の差分により求められる。

$$RRI_n = P_{n+1} - P_n \quad (4.51)$$

視線での特徴量抽出に従い 5 秒の時間窓で RRI を算出し、その平均値を求めて利用する。

車両挙動の特徴量

サブタスクによる影響はブレーキの反応時間等の車両の挙動にも影響を与えることが知られている [86]. また, 車両の走行車線中央からの距離を表わすレーンキープ量 (図 4.48) は, ドライバーの心身状態を表す指標として先行研究で用いられている. Johan ら [87] は, Cognitive Distracion によってレーンキープ量の標準偏差が減少すると報告している. Maria ら [88] は, 車両のセンターラインからのずれ量を基にした眠気検知を行っている. Kutila ら [19][20][21] は, 車両位置の標準偏差を特徴量とし, SVM への入力値の一つとして Cognitive Distracion 検知を行っている. 本研究においては車両のふらつき量からドライバーの Cognitive Distracion を評価するために, レーンキープ量の標準偏差を評価指標として用いることにした.

時刻 t におけるレーンキープ量を $s(t)$ とする. ある期間 N におけるレーンキープ量の標準偏差 SD は式 (4.52) で表すことができる. 本研究では視線・頭部角度の場合と同様に, レーンキープ量標準偏差を求める際の窓間隔 N を 5 秒とした.

$$SD = \sqrt{\frac{1}{N} \sum_{t=1}^N (s(t) - \bar{s})^2} \quad (4.52)$$

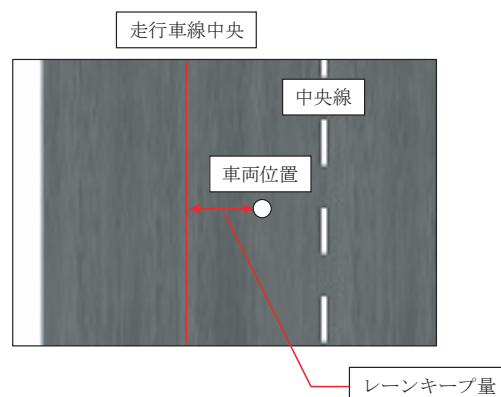


図 4.48: レーンキープ量の定義

視線および頭部回転角度の評価

走行コースをサブタスク無しで通常運転走行した時の被験者の前方の視点分布と, 暗算もしくは会話による認知負荷走行時の被験者の前方視点分布を図 4.49~図 4.54 に示す. 前方視点分布については, 通常運転時は周辺部まで広く分散しているが, 暗算タスク運転時は狭い範囲に視点が集まった. また, 会話による認知負荷時にも暗算と同様に視点分布が狭くなる傾向がみられた.




図 4.49: 前方視線分布 (左目, 通常運転)




図 4.50: 前方視線分布 (右目, 通常運転)




図 4.51: 前方視線分布 (左目, 暗算タスク運転)




図 4.52: 前方視線分布 (右目, 暗算タスク運転)




図 4.53: 前方視線分布 (左目, 会話タスク運転)




図 4.54: 前方視線分布 (右目, 会話タスク運転)

次に、通常運転時における頭部回転角度分布と、暗算もしくは会話運転時における頭部回転角度分布を図 4.55～図 4.57 に示す。視線角度とは逆に、頭部回転角はサブタスク負荷時に増加した。ここでも取得データに先行研究 [19][20][21] と同様の傾向が認められた。




図 4.55: 頭部回転角度分布 (通常運転)




図 4.56: 頭部回転角度分布 (暗算タスク運転)




図 4.57: 頭部回転角度分布 (会話タスク運転)

サブタスクの有無による特徴量の差異を調べるためにサブタスク無し (通常運転) とサブタスク有りについて視線角度および頭部回転角度標準偏差を比較した。図 4.58 と図 4.59 はそれぞれの標準偏差平均値を示している。サブタスク有りとサブタスク無しでの視線角度標準偏差の差異は僅かではあるものの、サブタスク有りの時の標準偏差が減少するという先行研究 [19][20][21] の傾向と一致した。この結果より、サブタスクを被験者に課した時の視線移動量および頭部移動量の標準偏差をドライバーの Cognitive Distraction 状態検知の特徴量とすることは妥当であると判断できる。




図 4.58: 視線角度標準偏差の比較




図 4.59: 頭部回転角度標準偏差の比較

瞳孔径の評価

faceLAB によって瞳孔径をリアルタイムにモニタリングすることが可能である。図 4.60 は通常運転および暗算タスク運転時における瞳孔径の画像である。双方を比較すると、暗算タスク運転時には通常運転時より瞳孔径が明らかに拡大していることが確認できる。これは運転中に暗算負荷をかけることにより運転に対する注意力が低下したためだと考えられる。



図 4.60: faceLAB による瞳孔径のモニタリング

左図：通常運転時の瞳孔径

右図：暗算タスク運転時の瞳孔径

タスク負荷によって瞳孔径がどの程度拡大したかを評価した。タスク別の瞳孔径の比較を図 4.61 に示す。通常運転時においては精神的負荷が少ないために瞳孔径は縮小傾向にあるが、サブタスクを付加することで精神的負荷が増大し、それに伴って瞳孔径が増加する傾向がみられた。このことから、瞳孔径は Cognitive Distraction 検知に用いる特徴として有効であるといえる。




図 4.61: 瞳孔径の比較

心電図の評価

polymate で取得した通常運転時、および暗算タスク運転時における心電図波形を図 4.62 に示す。タスクによって精神的負荷が増大するために心拍数が増加し、RRI が減少していることが確認できる。




図 4.62: 運転中の心電図波形

左図：通常運転時の心電図

右図：暗算タスク運転時の心電図

図 4.63 は実験中における二次タスク別の平均 RRI である。この比較において、運転中の二次タスクによって RRI が減少する傾向が見られた。よってタスク負荷時に計測された心電図データは、Cognitive Distraction 検出に有効な指標であることがうかがえる。




図 4.63: RRI の比較

車両挙動の評価

実験で取得したレーンキープ量と、その標準偏差を図 4.64 に示す。このデータの場合、レーンキープ量標準偏差は通常運転時と暗算タスク運転時との間に大きな差は見られない。平均値において、通常運転時での標準偏差は 0.0323 であり、暗算タスク運転時での標準偏差は 0.0312 であった。




図 4.64: タスク別のレーンキープ量および標準偏差の比較

左図：通常運転時のレーンキープ量と標準偏差

右図：暗算タスク運転時のレーンキープ量と標準偏差

次に、レーンキープ量標準偏差の全被験者における平均値を示す（図 4.65）。平均値においてタスク間で差はあるものの、その差は僅かであるため、Cognitive Distraction 検知に用いる特徴量としては妥当でないと判断した。




図 4.65: レーンキープ量標準偏差の比較

特徴量評価のまとめ

以上の評価を表 4.3 にまとめる。視線・頭部角度標準偏差，瞳孔径，RRI についてはタスク間における差が確認できたので，Cognitive Distraction 検知に用いる特徴量として採用した。しかしレーンキープ量標準偏差についてはタスク間での差が微小であったために特徴量としては用いないこととした。

表 4.3: Cognitive Distraction 検知に用いる特徴量評価

種別	特徴量	増減	
視線・頭部位置の移動量	右目視線角度ピッチ角	合成視線角度の標準偏差	減少
	右目視線角度ヨー角		
	左目視線角度ピッチ角	合成視線角度の標準偏差	減少
	左目視線角度ヨー角		
	頭部回転角度ピッチ角	合成視線角度の標準偏差	減少
	頭部回転角度ヨー角		
瞳孔径	右目瞳孔径	増加	
	左目瞳孔径	増加	
心電図	RRI, 平均値	減少	

4.2.7 パターン認識による学習と検知性能評価

パターン認識に用いたソフトウェア

SVMは先行研究[19][20][21]に従い、T. Joachimsによって開発されたSVMlight[89]を利用した。カーネル関数にはガウスカーネルを用いた。ソフトマージンSVMにおける制約条件の緩和を示すパラメータ（コストファクター C ）およびガウスカーネルの分布の広がり示すパラメータ γ のそれぞれのパラメータ値は、グリッドサーチによる決定を行う。後節の実験では、Positive データ数が Negative データ数の倍の量あるためにコストファクター $cf = 0.5$ とした。また AdaBoost には GML AdaBoost Matlab Toolbox[90] 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 4.4）。

表 4.4: AdaBoost アルゴリズムの種類と特徴

アルゴリズム	特徴
Real AdaBoost[64]	誤り率を常に最大に保つように学習する
Gentle AdaBoost[65]	学習器が+1 と判別する割合を算出する
Modest AdaBoost[66]	前回の出力値を考慮することで、過学習を抑制する

Vezhnevets A.[66]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 [91] 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。

検知性能の評価方法

学習の評価は二分割交差検定によって行った。図 4.66 のように通常運転を Negative データ (-1) とし、サブタスクありの運転を Positive データ (+1) とする。それぞれのデータを二分割し、Test set1 を用いて学習を行った場合は Test set2 で性能の評価を行い、同様に、Test set2 で学習を行った場合は Test set 1 で評価を行った。




図 4.66: 学習データと評価データの作成

これにより得られた、正解率 (*Accuracy*), 適合率 (*Precision*), 再現率 (*Recall*) 及び F 値を識別性能に用いた. *Accuracy*, *Precision* 及び *Recall* は, Positive として出力された f_p , 真に Positive である f_n を用いて次式により定義される.

$$t_p = f_p \cap f_n \quad (4.53)$$

$$t_n = \neg(f_p \cup f_n) \quad (4.54)$$

$$Accuracy = \frac{t_p + t_n}{t_p + f_p + f_n + t_n} \quad (4.55)$$

$$Precision = \frac{t_p}{t_p + f_p} \quad (4.56)$$

$$Recall = \frac{t_p}{t_p + f_n} \quad (4.57)$$

$$F = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (4.58)$$

ただし, f_p は Positive 出力データの真値であり, サブタスク有り運転のデータの真値 (+1) を表わし, f_n は Negative 出力データの真値であり, 通常運転時のデータの真値 (-1) を表す.

SVM と AdaBoost での検知結果の比較

faceLAB から取得した視覚情報の中で, 先行研究 [19][20][21] で用いられている視線・頭部角度標準偏差と品質指標のみを特徴量として選択し, 検知を行った. 本研究では *Precision* と *Recall* の調和平均である F 値を用いて評価を行う. また, 本研究では Cognitive Distraction を暗算タスクと会話タスクによって模擬し,

- (1) 通常運転と暗算タスク
- (2) 通常運転と会話タスク
- (3) 通常運転と両サブタスク (暗算タスク+会話タスク)

のそれぞれについて Cognitive Distraction の検出を行った.

まず, SVM によるパターン認識の結果を示す. 本研究で用いた SVMlight では, ガウスカーネルは式 (4.59) のように定義される.

$$K(x, x_i) = \exp(-\gamma \|x - x'\|^2) \quad (4.59)$$

SVM ではコストファクター C とガウスカーネルにおけるパラメータ γ の最適値をグリッドサーチによって求める必要がある. 本研究では C と γ を $\{2^{-5}, 2^{-4}, \dots, 2^5\}$ の様に変動させ, それぞれの値における F 値を求めて比較を行う.

SVM による検知結果

γ および C の値に対応する検知精度を図 4.67 に示す. この検知精度は全被験者における F 値の平均を示している. なお, 図中の γ (x 軸) と C (y 軸) はそれぞれ対数値である.

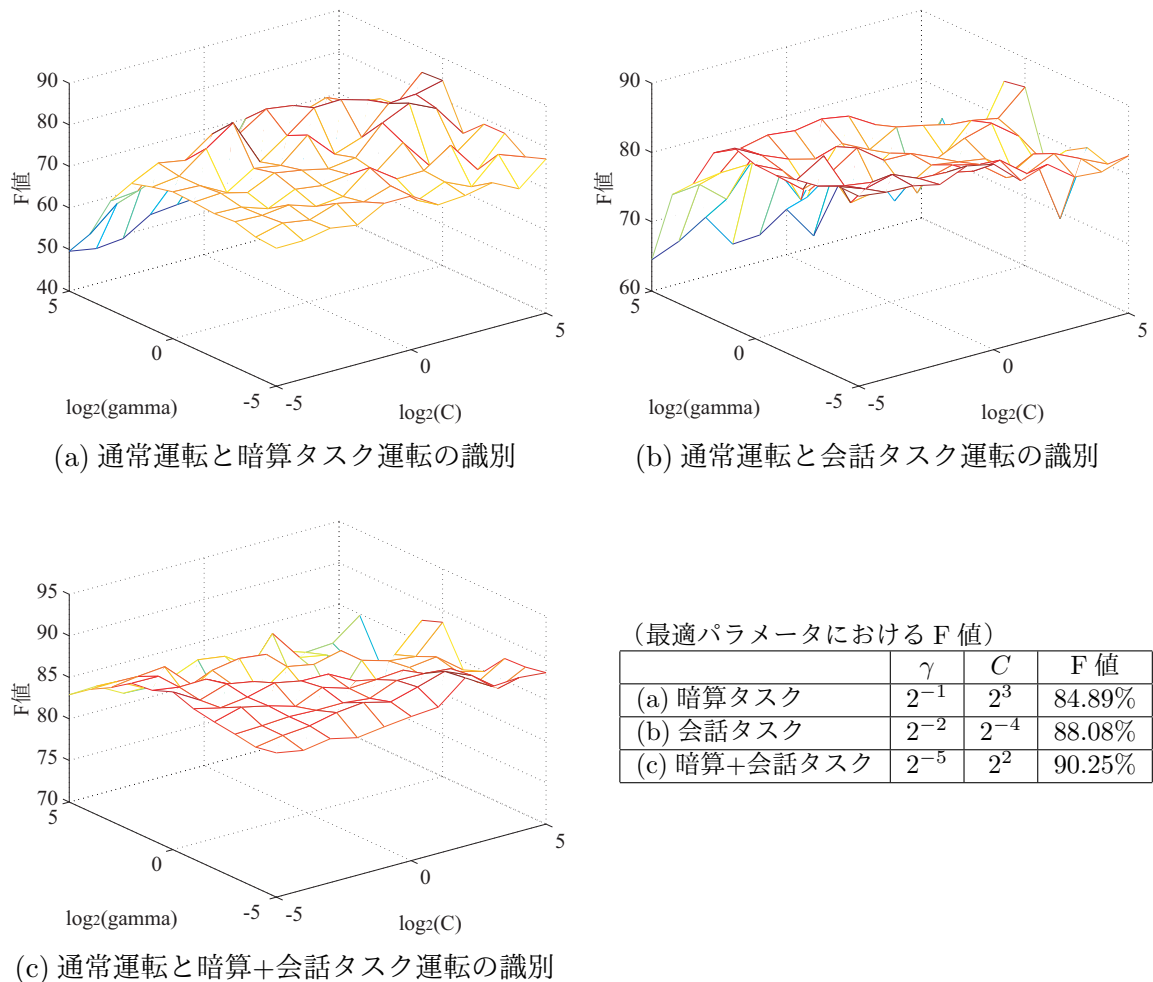




図 4.67: SVM による検知精度

この識別結果では、 γ の値増加に伴って F 値が減少する傾向が見られた。これは、式 (4.59) で示したガウスカーネルの γ が大きくなるとカーネルの値が 1 に近付き、 γ が小さくなると 0 に近付くという性質があることから、 γ が大きくなると本来特徴がそれほど似ていないパターン間でもカーネルの値が大きくなり、結果として各クラスの特徴の違いが吸収されてしまうために認識率が下がったことが原因として考えられる [92]。一方、コストファクター C については値変化に伴う識別精度の増減幅は、 γ と比較して小さいものであった。しかし C の値を大きくしすぎることにより SVM はハードマージンに近づき、SVM の特徴である非線形分離が困難となるため、大きな値に設定することは好ましくないと考えられる。


最適パラメータを用いた場合の検知精度は、暗算タスク運転の検知については F 値において 84.89%、会話タスク運転の検知は 88.08%、両タスク運転の検知は 90.25% であった。一方、先行研究 [19][20][21] で示された暗算時の平均 *Accuracy* の 74.2% であり、本研究で得られた結果とは差異が生じている。これは先行研究は実車を使用しており、実験データの取得環境が異なるために検知精度も大きく変化してしまうが起因していると考えられる。



(a) 通常運転と暗算タスク運転の識別



(b) 通常運転と会話タスク運転の識別



(c) 通常運転と暗算+会話タスク運転の識別

(a) 暗算タスク

	最適弱識別器数	F 値
Real AdaBoost	32	83.31%
Gentle AdaBoost	25	83.27%
Modest AdaBoost	57	83.41%

(b) 会話タスク

	最適弱識別器数	F 値
Real AdaBoost	12	87.70%
Gentle AdaBoost	4	88.03%
Modest AdaBoost	44	87.89%

(c) 暗算+会話タスク

	最適弱識別器数	F 値
Real AdaBoost	2	90.07%
Gentle AdaBoost	12	90.12%
Modest AdaBoost	26	90.47%


図 4.68: AdaBoost による検知精度

AdaBoost による検知結果


続いて、AdaBoost による検知結果を図 4.68 示す。AdaBoost には表 4.4 で示したように信頼度の決定法が異なる 3 種のアルゴリズムが存在する。よってそれぞれのアルゴリズムを用いて検知を行い、F 値の比較によって評価を行う。さらに、識別精度は弱識別器の個数にも依存するため、各アルゴリズムに対して弱識別器の個数を 1 から 100 まで変動させた上で識別を繰り返した。

暗算タスク運転の検知については、Modest AdaBoost を用いることで最も精度が高くなった。Real / Gentle AdaBoost を用いた場合は、弱識別器数が 30 を超えた付近から過学習によって精度が低下する結果となった。会話タスクの検知では、Gentle / Modest AdaBoost がほぼ同じ識別精度となった。しかし Real AdaBoost を用いた場合は弱識別器数増加に伴って精度が大きく低下した。両タスクの検知においては、弱識別器数増加によって過学習が発生するものの、Modest AdaBoost を用いた場合が最も精度が高くなった。


SVM の精度と比較すると、暗算タスク運転の検知および会話タスク運転の検知につい



(a) 通常運転と暗算タスク運転の識別



(b) 通常運転と会話タスク運転の識別



(c) 通常運転と暗算+会話タスク運転の識別

(最適パラメータにおける F 値)

	γ	C	F 値
(a) 暗算タスク	2^{-3}	2^5	89.27%
(b) 会話タスク	2^{-4}	2^{-5}	90.71%
(c) 暗算+会話タスク	2^0	2^{-3}	93.18%


図 4.69: SVM による検知精度 (瞳孔径追加)

ては SVM が優位であり、両タスク運転の検知においては AdaBoost が優位であった。しかしその差はいずれも僅かであるため、検知精度について優劣をつけることができない結果となった。


4.2.8 特徴量追加の効果

瞳孔径追加による SVM 検知精度への影響


SVM へ入力する特徴量に瞳孔径を加えた場合の検知精度の結果を図 4.69 に示す。瞳孔径を加えることにより、暗算タスク運転の検知精度は約 4.4%、会話タスク運転の検知精度は約 2.5%、両タスク運転の検知精度は約 2.9% 上昇した。瞳孔径を加えない場合の検知と同様、 γ の値増加に伴って検知精度が減少する傾向が見られた。



(a) 通常運転と暗算タスク運転の識別



(b) 通常運転と会話タスク運転の識別



(c) 通常運転と暗算+会話タスク運転の識別

(a) 暗算タスク

	最適弱識別器数	F 値
Real AdaBoost	95	88.88%
Gentle AdaBoost	26	88.91%
Modest AdaBoost	12	89.67%

(b) 会話タスク

	最適弱識別器数	F 値
Real AdaBoost	25	90.72%
Gentle AdaBoost	9	90.86%
Modest AdaBoost	71	90.63%

(c) 暗算+会話タスク

	最適弱識別器数	F 値
Real AdaBoost	16	93.27%
Gentle AdaBoost	4	93.42%
Modest AdaBoost	27	93.13%

図 4.70: AdaBoost による検知精度 (瞳孔径追加)

瞳孔径追加による AdaBoost 検知精度への影響

瞳孔径を追加した場合の AdaBoost による検知精度を図 4.70 に示す。暗算タスク運転の検知については Modest AdaBoost が最もよく検知を行っており、さらに弱識別器増加に伴う過学習による精度低下は見られなかった。会話タスク運転の検知では、Gentle AdaBoost が最も高精度な検知を行うことができた。しかし過学習による精度低下が起り、弱識別器数が 40 を超えた辺りから Modest AdaBoost と優位性が逆転した。両タスク運転の検知についても、Gentle AdaBoost が最も高精度であった。Real AdaBoost については過学習によって検知精度が大きく低下した。

瞳孔径を加えない場合と比べて、暗算タスク運転の検知精度は約 6.3%、会話タスク運転の検知精度は約 2.9%、両タスク運転の検知精度は約 2.6% 上昇した。SVM と比較すると、暗算タスク運転の検知は SVM が優位であり、会話タスク運転および両タスク運転の検知は AdaBoost が優位であったが、検知精度の差は 1% 以下と僅かなものであった。

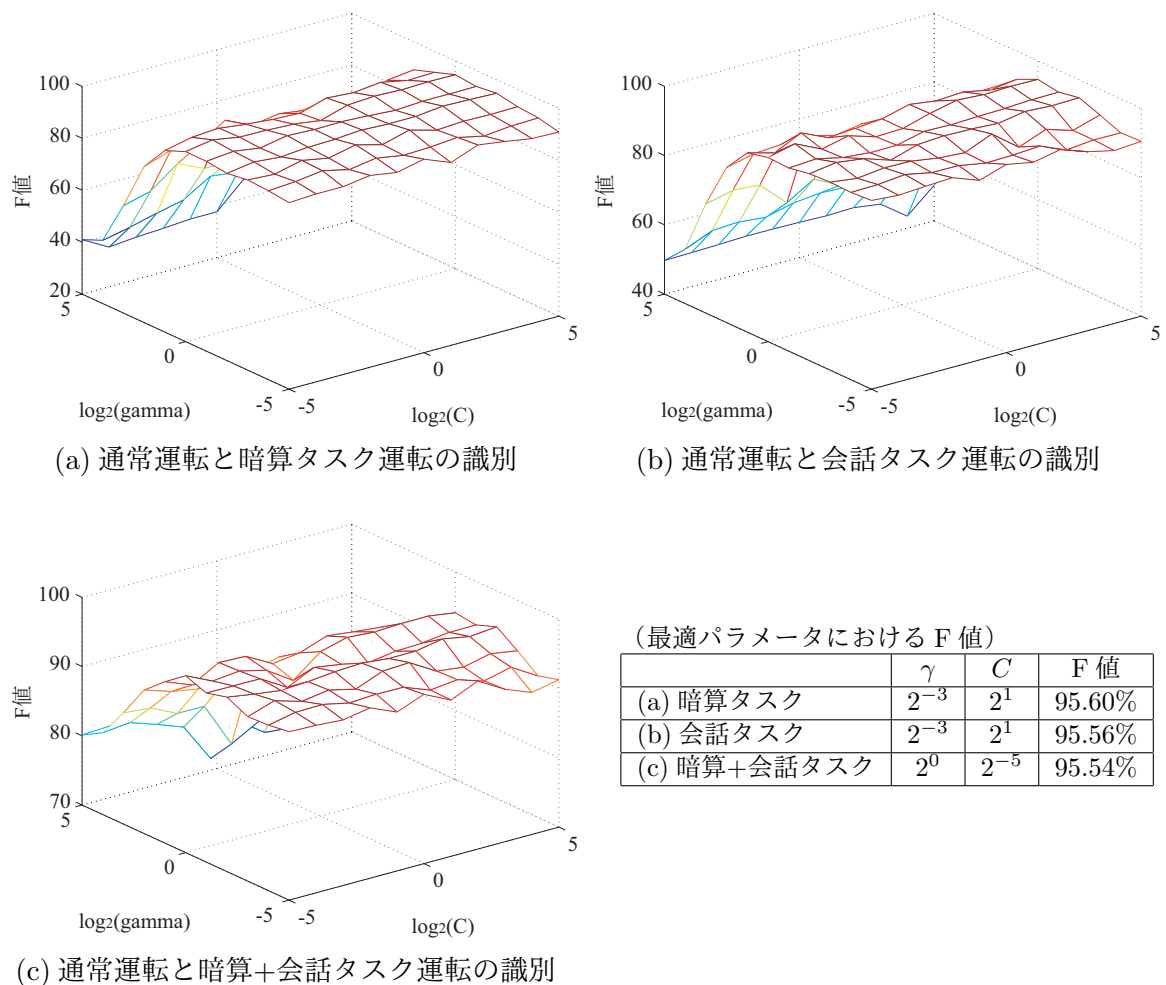


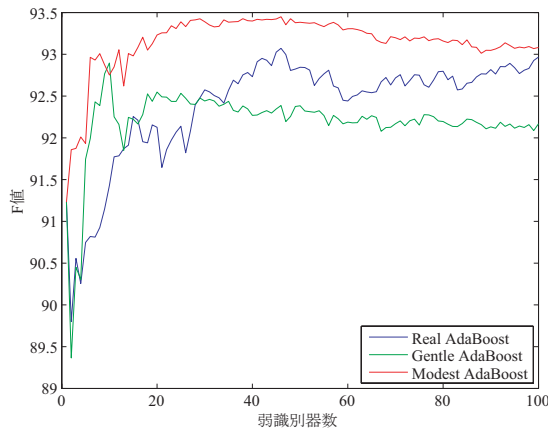
図 4.71: SVM による検知精度 (RRI 追加)

RRI 追加による SVM 検知精度への影響


瞳孔径に加えて, RRI を SVM への特徴量に追加した場合の検知精度の比較を図 4.71 に示す. 特徴量追加によって検知精度は大きく向上し, どのタスク運転の検知においても 95%を超える結果となった. またこれまでと同様, γ の値増加に伴い, 検知精度が減少する傾向を見ることができた.

RRI 追加による AdaBoost 検知精度への影響


AdaBoost へ入力する特徴量に RRI を追加した場合の検知結果を図 4.72 に示す. 暗算タスク運転の検知では Modest AdaBoost が最も優位であり, 過学習による検知精度の大きな低下も見られなかった. 会話タスク運転の検知についても Modest AdaBoost が最も優位であったが, 弱学習器増加に伴って Real / Gentle AdaBoost との差が縮まり, 弱識別器数 100 個の時点で精度がほぼ同等となった. 両タスク運転の検知については Gentle



(a) 通常運転と暗算タスク運転の識別



(b) 通常運転と会話タスク運転の識別



(c) 通常運転と暗算+会話タスク運転の識別

(a) 暗算タスク

	最適弱識別器数	F 値
Real AdaBoost	46	93.07%
Gentle AdaBoost	10	92.90%
Modest AdaBoost	46	93.45%

(b) 会話タスク

	最適弱識別器数	F 値
Real AdaBoost	95	92.37%
Gentle AdaBoost	64	92.43%
Modest AdaBoost	17	92.60%

(c) 暗算+会話タスク

	最適弱識別器数	F 値
Real AdaBoost	1	95.52%
Gentle AdaBoost	15	95.83%
Modest AdaBoost	2	95.61%

図 4.72: AdaBoost による検知精度 (RRI 追加)

AdaBoost が最も高精度な検知が行え、さらに過学習による検知精度低下も発生しなかった。Real AdaBoost では弱識別器数が 20 個付近で大きな精度低下が発生したが、Modest AdaBoost では弱学習器増加に伴って徐々に精度が低下する結果となった。

RRI を追加しない場合と比較して、暗算タスク運転の検知精度は約 3.8%、会話タスク運転の検知精度は約 1.7%、両タスク運転の検知精度は約 2.4%上昇した。SVM の検知精度と比較すると、暗算タスク運転および会話タスク運転の検知に関しては SVM が優位であるが、両タスク運転の検知では AdaBoost が優位となった。

4.2.9 考察

検知精度に関する考察

前節において SVM と AdaBoost を用いて Cognitive Distraction 検知を行った結果、F 値において 90% を超える高い検知精度を得ることができた。しかし、アルゴリズム間の精度の差は僅かであり、検知精度についてどちらが優位とは言及することができなかった。近年の研究より、Boosting と SVM は本質的に同一であり、共に最少マージンの最大化に基づく学習アルゴリズムとして単一化できることが明らかとなっている [91]。しかし、学習の仕方に差異が存在する。AdaBoost のような Boosting アルゴリズムの場合は、できるだけ少数の特徴量で分類を実現できるとともに、貢献度の高い特徴量の分析が可能である。一方、SVM の場合は、できるだけ少数の事例で重みベクトルを表現しようとし、多くの特徴空間から特徴量分析を行うことは比較的不得意である。本研究のように、特徴量が比較的少ない場合には上記の Boosting における利点を発揮することができないため、SVM と AdaBoost の精度はほぼ同等となる。しかし今後、検知精度向上のために特徴量を追加する可能性があるため、その場合には特徴量分析が行える Boosting 手法が有利になると考えられる。

計算時間に関する考察

SVM と Boosting は共に最少マージンの最大化に基づく学習アルゴリズムであると述べたが、両者の違いはマージンのノルムである。

AdaBoost は漸近的に以下の線形計画問題を解いていることと同じである。

$$\text{maximize} \quad y_i \sum_{j=1}^J w_j h_j(\mathbf{x}_i) \quad (4.60)$$

$$\|\mathbf{w}\|_1 = 1 \quad (4.61)$$

ここで、 J は仮説の個数である。この場合の計算量は、サンプル数を n とした場合に $O(n)$ となる。SVM は以下の 2 次計画問題の最適化として定式化される^{注 1}。

$$\text{maximize} \quad y_i \cdot (\mathbf{w} \cdot \Phi(\mathbf{x}_i)) \quad (4.62)$$

$$\|\mathbf{w}\|_2 = 1 \quad (4.63)$$

関数 $\Phi(\mathbf{x})$ は事例 \mathbf{x} を高次元空間に写像する関数である。SVM では、事例間の内積をカーネル関数 $K(\mathbf{x}, \mathbf{x}') = \Phi(\mathbf{x})^T \Phi(\mathbf{x}')$ によって求めている。この計算量はサンプル数を n とした場合に $O(n^2)$ となり、サンプル数増加に伴う計算量の増加率は AdaBoost と比べて大きくなる [93]。

本研究においては SVM と AdaBoost を実行する使用言語が異なる (表 4.5) ため、計算時間を単純比較することができないが、両者の実行時間を各アルゴリズムの計算時間として求めた。

^{注 1}ここでは議論を単純化するために、バイアス項 (b) とソフトマージンは考えない。

表 4.5: SVM と AdaBoost の実行環境

ハードウェア	CPU : 3.0GHz (Intel Core2Duo E6850) メモリ容量 : 2GB
プラットフォーム	OS : WindowsXP SP2 Matlab : Version7.4
使用言語	SVM : SVMlight (C 言語) AdaBoost : GML AdaBoost Matlab Toolbox (Matlab)

表 4.6: 学習時間の比較 (単位: 秒)

	サブタスク	視覚情報のみ	RRI 追加
SVM	暗算	23.07	64.09
	会話	23.31	74.42
	暗算+会話	59.58	152.82
AdaBoost	暗算	6.14	7.99
	会話	6.21	7.94
	暗算+会話	9.21	9.61

表 4.7: 識別時間の比較 (単位: 秒)

	サブタスク	視覚情報のみ	RRI 追加
SVM	暗算	4.74	3.85
	会話	5.51	4.00
	暗算+会話	11.52	7.59
AdaBoost	暗算	0.09	0.17
	会話	0.10	0.19
	暗算+会話	0.16	0.34

表 4.6 に各アルゴリズムを用いた時の学習時間、表 4.7 に識別時間を示す。特徴量の個数は、視覚情報のみの場合には 6 個（左右視線角度標準偏差，頭部回転角度標準偏差，左右視線品質指標，頭部位置品質指標）であり，RRI を追加した場合は 7 個となる。視覚情報のみ場合，SVM は AdaBoost に比べて最大で 6 倍以上の学習時間を要した。前述のように，各アルゴリズムの使用言語が異なるために単純比較はできないが，AdaBoost の使用言語である Matlab はインタプリタ型の言語であるため，コンパイラ型の言語に比べて実行速度は一般的に遅い。よって各アルゴリズムを同じ言語環境で実行すれば，実行時間の差はさらに拡大すると考えられる。

RRI を加えた場合には，学習時間は最大で 15 倍以上と差が拡大した。この計算時間の差の拡大は各アルゴリズムの性質にあると考えられる。AdaBoost では特徴量の増加に比例して学習器の個数も増加し，学習時間も学習器の個数に応じて増加する。一方，SVM では特徴量の増加によって特徴空間内におけるサポートベクターを求めることがより困難となり，学習時間は飛躍的に増加することとなる。よって特徴量を 6 個から 7 個に増加させた場合，AdaBoost による学習時間は約 7/6 倍に増加したが，SVM による学習時間はそれ以上に増加する結果となった。

識別時間については，SVM では識別に最大で 11 秒以上の時間を要するのに対し，AdaBoost では最大でも 0.3 秒程度で識別を行うことができた。SVM においては学習時とは異なり，特徴量として RRI を加えることにより識別時間が減少した。これは RRI を含めた場合の検知精度が高いことから，学習器に未知のデータを入力した際の識別がより行いやすいことが計算時間の減少に繋がったと予測される。しかし AdaBoost による識別時間は増加する結果となった。これは識別以外の処理（データの入出力や正規化など）に要する計算時間の割合が高いことに加え，純粋な識別処理時間は特徴量の次元数と弱識別器の

個数に大きく依存しているため、新たな特徴量を追加して特徴量の次元が増えた場合には識別時間は増加する。しかしながら、その識別時間は SVM に比べて十分に短いため、AdaBoost は依然優位であると言える。

今後、特徴量追加による精度向上を試みた場合、特徴量増加による計算時間の増加幅が少ない AdaBoost がさらに優位になると考えられる。

4.3 負担度を考慮した Cognitive Distraction 検知への応用

前章では生体情報をパターン認識手法によって二値判別をし、Cognitive Distraction の検知を行った。しかし実用システムを考えた場合、ドライバーにかかる負担度を検知することができれば、負担度に応じた安全機能を選択することができ、ドライバーにとってより適切な運転支援を提供することが可能になると考えられる。本研究では前章で行った Cognitive Distraction 検知に加えて、ドライバーに対する精神的負担度を検知する手法を考案した。4.3.1 節では負担度検知に必要な多値判別手法について述べる。4.3.2 節では検知性能の評価方法と検知結果について述べる。

4.3.1 二値判別器の拡張による多値判別法

二値判別問題の解決手法として、4.1.1 節で述べた SVM、4.1.2 節で述べた AdaBoost が一般に用いられるが、多値判別については未だ決定的な手法の提案がなされておらず、現在においても多くの手法が提案され続けている。

多値判別には、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 [94] 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、このアプローチに立つ多くの手法が計算量が增大するという欠点がある [95]。

二つ目のアプローチは、二値判別器を組み合わせて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、汎化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 [96][97]。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。4.3.1 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。4.3.1 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。

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 [98]。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

$$(X, Y) \equiv \{x^i, y^i\}_{i=1}^n \quad (4.64)$$

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の 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 (4.65) のようになる．

$$W = \begin{pmatrix} 1 & -1 & -1 \\ -1 & 1 & -1 \\ -1 & -1 & 1 \end{pmatrix} \quad (4.65)$$

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 $z = Ws$ に分解する．

$Z = WS$ 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 [99] 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 (4.66) の様になる．

$$W = \begin{pmatrix} 1 & -1 & -1 \\ -1 & 1 & -1 \\ -1 & -1 & 1 \\ 1 & -1 & 0 \\ 1 & 0 & -1 \\ 0 & 1 & -1 \end{pmatrix} \quad (4.66)$$

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 の値をもつ例題のみを用い， 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 $h_j^i(\mathbf{x}^i)$ としたとき，ハミング距離 d_H^i を式 (4.67) の様に定義する．

$$d_H^i(W(r), H(X)) = \sum_{j=1}^p \left(\frac{1 - \text{sign}(W(r, j)h_j^i(\mathbf{x}^i))}{2} \right) \quad (4.67)$$

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 $\hat{y}^i \in \{1, \dots, G\}$ とする．

$$\hat{y}^i = \arg \min_r d_H^i(W(r), H(X)) \quad (4.68)$$

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 (4.68) 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 [100]．つまり， $class1$ を -1 ， $class2$

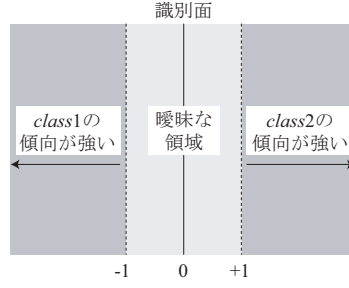


図 4.73: 識別面とクラス傾向

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* の傾向が強くなり，出力値がプラスに大きければ *class2* の傾向が強くなることを意味する（図 4.73）。

Cognitive Distraction 検知において，特徴量の傾向はドライバー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 $h(x)$ 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^i は式 (4.69) の指数関数によって定義される．

$$\begin{aligned}
 d_L^i(W(r), H(X)) &= \sum_{j=1}^p \begin{cases} \exp(|h_j^i(\mathbf{x}^i)|) & \text{if } W(r, j)h_j^i(\mathbf{x}^i) < 0 \\ -\exp(|h_j^i(\mathbf{x}^i)|) & \text{if } W(r, j)h_j^i(\mathbf{x}^i) > 0 \\ 0 & \text{if } W(r, j)h_j^i(\mathbf{x}^i) = 0 \end{cases} \\
 &= \sum_{j=1}^p -\text{sign}(W(r, j)h_j^i(\mathbf{x}^i))\exp(|h_j^i(\mathbf{x}^i)|) \quad (4.69)
 \end{aligned}$$

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．

$$\hat{y}^i = \arg \min_r d_L^i(W(r), H(X)) \quad (4.70)$$

図 4.74 にハミング復号を用いた場合の識別過程，図 4.75 に損失関数を用いた場合の識別過程をそれぞれ示す．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 (4.69) 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．

4.3.2 負担度を考慮した Cognitive Distraction 検知手法

4.3.1 節で述べた多値判別手法を用いて，負担度を考慮した Cognitive Distraction 検知を行った．使用するデータは，4.2 章で用いたものと同じである．




図 4.74: ハミング復号による識別過程

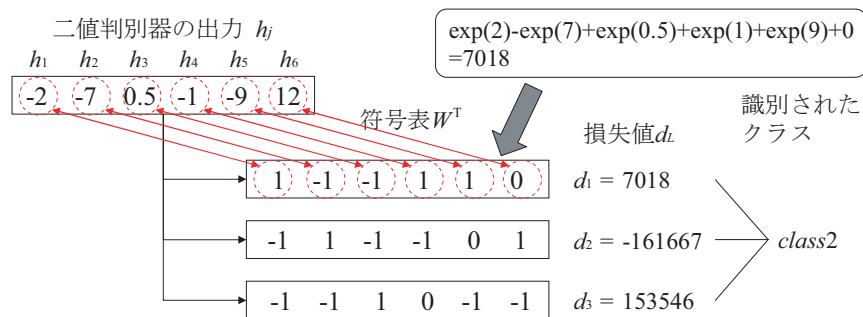


図 4.75: 損失関数に基づく復号による識別過程

検知性能の評価方法

4.2.4 節で述べた過程に従って取得した各サブタスクのデータに対して、五分割交差検定法によって検知性能を評価した。通常運転を *class1*, 暗算タスク運転を *class2*, 会話タスク運転を *class3* として、それぞれのデータを五分割し、Test set を 1 から 5 まで作成する。各 Test set に対して学習と識別を行い、式 (4.71) で示すそれぞれの正解率 (*Accuracy*) の平均値で検知性能を評価する。

$$Accuracy = \frac{\sum_{t=1}^T \sum_{i=1}^n [y_t^i \in H_t(x_t^i)]}{nT} \quad (4.71)$$

ここで、 t は Test set の番号、 T は t の最大値 (五分割交差検定法の場合は 5)、 n はデータの長さ、 y_t は Test set t の正解ラベル、 H_t は Test set t の仮説である。

HD-ECOC, LD-ECOC での検知結果の比較

実験で得られたデータから視線・頭部角度標準偏差, 瞳孔径, RRI を特徴量として選択し, 検知を行った。検知に用いる特徴量は表 4.8 で示す 1 から 15 までの Parameter set に従って選択し, 各 Parameter set を用いて検知を行った。これにより, 検知に最適な特徴量

の組み合わせを検証する。検知はHD-ECOC, LD-ECOCの両手法を用い、二値判別器にはAdaBoostを用いた。

表 4.8: Parameter set に対応した特徴量 (○は特徴量として用いることを意味する)

Parameter set	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
視線	○				○	○	○				○	○	○		○
頭部		○			○			○	○		○	○		○	○
瞳孔径			○			○		○		○	○		○	○	○
RRI				○			○		○	○		○	○	○	○

各 Parameter set に対する検知精度を表 4.9 に示す。検知に用いる特徴量を増加させることにより精度は向上し、全てのパラメータを用いた場合ではLD-ECOCによって平均で95.76%の精度を得ることができた。手法別に比較を行うと、単一の特徴量のみを用いる Parameter set1-4 ではHD-ECOCが精度よく検知ができ、複数の特徴量を用いる Parameter set5-15 ではLD-ECOCが精度よく検知できる傾向が得られた。

4.3.3 考察

検知精度に対する考察を行う。LD-ECOCは判別器の出力値がクラス傾向を表すため、誤ったクラス傾向を強く表わす判別器が一つでも存在すると、復号化において誤ったクラスに判別される可能性が高くなり、検知精度が極端に悪くなる場合がある。一方、HD-ECOCでは符号関数を用いることで各々の判別器を対等に扱った上で復号を行うため、誤った判別器が存在しても比較的安定した検知を行うことができる。特徴量が少ない場合の学習は識別面が不安定になりやすく、結果として誤った判別を行うことが多い。HD-ECOCは誤った判別器が存在しても検知の安定性が高いために、特徴量の少ない場合においてLD-ECOCよりも高精度な検知が行えたと考えられる。しかし、特徴量を増やすことによりLD-ECOCの検知精度が優位になる傾向が得られた。AdaBoostによる二値判別は、特徴量を増やすことで識別面が安定する傾向にあり、それに伴って正しい判別器の個数は増加する。これにより、クラス傾向を反映する損失値の信頼性が増し、検知精度が向上したと考えられる。

表 4.9: 各 Prameter set における Accuracy

	手法	通常	暗算	会話	平均値	LD-ECOC による改善率
parameterset1	HD-ECOC	70.55%	56.39%	45.61%	57.51%	−14.00%
	LD-ECOC	42.49%	43.01%	45.04%	43.51%	
parameterset2	HD-ECOC	74.75%	69.29%	52.82%	65.62%	−8.84%
	LD-ECOC	59.72%	54.79%	55.83%	56.78%	
parameterset3	HD-ECOC	88.28%	76.15%	55.99%	73.48%	+4.08%
	LD-ECOC	84.14%	76.77%	71.74%	77.55%	
parameterset4	HD-ECOC	74.69%	69.02%	42.52%	62.08%	−2.64%
	LD-ECOC	65.70%	64.03%	48.58%	59.43%	
parameterset5	HD-ECOC	81.82%	63.16%	58.20%	67.73%	−3.88%
	LD-ECOC	70.38%	56.68%	64.49%	63.85%	
parameterset6	HD-ECOC	89.03%	75.04%	59.56%	74.54%	+3.35%
	LD-ECOC	83.49%	76.13%	74.05%	77.89%	
parameterset7	HD-ECOC	79.92%	69.08%	53.01%	67.34%	−1.03%
	LD-ECOC	70.22%	66.99%	61.72%	66.31%	
parameterset8	HD-ECOC	91.81%	75.30%	66.08%	77.73%	+4.71%
	LD-ECOC	87.07%	78.62%	81.62%	82.44%	
parameterset9	HD-ECOC	83.76%	75.18%	59.56%	72.83%	+1.06%
	LD-ECOC	76.15%	75.45%	70.07%	73.89%	
parameterset10	HD-ECOC	91.81%	80.33%	63.14%	78.43%	+6.83%
	LD-ECOC	88.28%	83.93%	83.56%	85.26%	
parameterset11	HD-ECOC	92.50%	74.46%	66.93%	77.96%	+6.08%
	LD-ECOC	87.90%	80.19%	84.04%	84.04%	
parameterset12	HD-ECOC	86.31%	74.49%	60.38%	73.73%	+3.17%
	LD-ECOC	80.43%	75.49%	74.76%	76.89%	
parameterset13	HD-ECOC	91.52%	80.52%	66.51%	79.52%	+6.72%
	LD-ECOC	88.66%	83.72%	86.33%	86.24%	
parameterset14	HD-ECOC	92.49%	81.19%	71.08%	81.58%	+6.87%
	LD-ECOC	89.85%	87.40%	88.10%	88.45%	
parameterset15	HD-ECOC	95.45%	89.60%	83.53%	89.53%	+6.23%
	LD-ECOC	95.03%	95.51%	96.75%	95.76%	

第5章 脈波からの血圧推定技術の高精度化

血圧は緊張やストレスと関連があることから、運転中のドライバーの血圧をモニタリングすることは運転支援を行う上で重要とされている。本章では血圧の原理と測定法、および脈波からの血圧推定技術の高精度化について述べる。

5.1 血圧の原理と測定方法

5.1.1 血圧概要

人間の体内に酸素と栄養素を送り届ける血液は、心臓のポンプ機能によって循環している。血液が全身へ送り出される時に心臓が収縮し、その力によって血液が大動脈を通り、抹消動脈へと押し出される。血液が押し出される時に血管壁にかかる圧力が血圧である。心臓が収縮し、血液を送り出される時の血圧を収縮期血圧 (Systolic Blood Pressure: SBP) と呼び、値が最も高くなることから最高血圧という。全身をめぐり、帰ってきた血液が心臓に流れ込む時の血圧を拡張期血圧 (Diastolic Blood Pressure) と呼び、血圧が最も低いことから最小血圧という。つまり、収縮期血圧とは心臓から血圧が出ていく際に血管壁にかかる圧力であり、拡張期血圧は、動脈壁の弾力で決定する。

血圧は心臓の収縮状態や動脈の弾力等の影響を受け、常に変動する。図 5.1 に血液変動の様子を示す。血液変動血圧変動を決定する要因の中で、最も重要なものが次の二つである。一つは心臓から送り出される血液量 (心拍出量)、もう一つは抹消動脈の弾力 (末梢血管抵抗) である。この他に、循環血液量 (体内を循環している血液量)、血液粘稠度、心臓に連なる大動脈の弾力が血圧を決定する。

5.1.2 血圧の基準と高血圧症

血圧が正常範囲を超えて高く維持されている状態のことを高血圧症という。「血圧が高いこと」自体は病気ではないが、血圧が高くなった結果、脳や心臓、肝臓などに余分な負担がかかることになる。この状態が続くと血管が痛みやすくなり、その結果、心筋梗塞や脳出血といった死に直接関わる恐ろしい病気を引き起こす要因になりうる。したがって、血圧が高いということに高血圧症という病名がつけられているのである。

高血圧の定義

どこまでが正常血圧で、どこからが高血圧かを定めた血圧分類は世界共通でただ一つではなく、WHO(世界保健機構)/ISH(国際高血圧学会)、米国高血圧合同委員会、欧州高血圧




図 5.1: 血圧の変動周期

学会/欧州心臓学会によるものなどがある。しかし、血圧値や高血圧に伴う病気は欧米人と日本人で異なり、また血圧に大きな影響を与える食生活も異なっている。そこで、2000年に日本高血圧学会はわが国の「高血圧治療ガイドライン」を制定して発表した。それ以降、高血圧治療はこのガイドラインに沿って行われている。

表 5.1 は 2004 年に日本高血圧学会から発表された血圧の基準である。正常血圧は収縮期血圧が 130mmHg 未満、かつ拡張期血圧が 85mmHg 未満であり、高血圧は収縮期血圧が 140mmHg 以上、または拡張期血圧が 90mmHg 以上とされている。この分類は、米国合同委員会の第 6 次報告で示されたものや、WHO/ISH の委員会が 1999 年に発表したものと同じである。米国合同委員会では 2003 年に第 7 次報告にて、これまでの分類よりも簡略化した分類 (5.2) を発表した。世界的に認められる分類にはなっていない。米国合同委員会の第 7 次報告に続いて発表された欧州高血圧学会/欧州心臓学会による高血圧治療ガイドラインでは、従来の分類表をそのまま採用しており、日本の専門医の多くが現在の分類が妥当と考えている。

表 5.1 には収縮期高血圧という分類があるが、これは高齢になるにしたがって多くなる高血圧である。加齢と共に動脈硬化が進行することで動脈の弾力が失われ、拡張期血圧が低下する。その一方で、体内に血液を送り届けるために高い圧力が必要になり、収縮期血圧が上昇する。

また、正常高値血圧という分類もある。これは高血圧ではないが、完璧な正常血圧とも言えない境界上の血圧である。今後の高血圧予備軍であると考えられることができる。

表 5.1: 日本高血圧学会による成人の血圧分類

分類	収縮期血圧 [mmHg]		拡張期血圧 [mmHg]
至適血圧	< 120	かつ	< 80
正常血圧	< 130	かつ	< 85
正常高値血圧	130~139	または	< 85~89
軽症高血圧	140~159	または	< 90~99
中等症高血圧	160~179	または	< 100~109
重症高血圧	≥ 180	または	≥ 110
収縮期高血圧	≥ 140	かつ	< 90

表 5.2: 米国合同委員会の第7次報告における成人の血圧分類

分類	収縮期血圧 [mmHg]		拡張期血圧 [mmHg]
正常	< 120	かつ	< 80
前高血圧	120~139	または	80~89
ステージ1 高血圧	140~159	または	90~99
ステージ2 高血圧	≥ 160	または	≥ 100

高血圧の分類

高血圧は、その原因が分かっているかどうかによって大きく2つに分類される。血圧が高くなる明らかな原因が分からない高血圧を本態性高血圧あるいは原発性高血圧とよぶ。高血圧症の患者の90~95%は本態性高血圧に含まれる。一方、原因が明らかな高血圧を二次性高血圧あるいは症候性高血圧と呼ぶ。二次性高血圧は、本態性高血圧に比べると血圧が高く、原因疾患による症状を伴うことが多い。表5.3に高血圧症の諸要因についてまとめる。二次性高血圧は主に次の4種類(1)腎性高血圧、(2)腎血管性高血圧、(3)内分泌性高血圧、(4)大血管疾患高血圧、に分けられる。腎性高血圧は二次性高血圧の中で最も多い高血圧で、主に腎炎と腎盂腎炎が原因として起こる。また、腎血管性高血圧は二次性高血圧の中で2番目に多い高血圧である。本態性高血圧の原因は、これであると断言できないが、血圧を上げる要因はいくつかあり、それらが互いに関連して血圧の上昇に関わると考えられている。

本態性高血圧の最も大きな要因として、遺伝によるものが考えられている。また、加齢による血管の老化が原因で引き起こされる動脈硬化や、食事からの塩分の取りすぎ、煙草、酒、ストレス、生活習慣などに起因する環境因子も本態性高血圧を引き起こす重要な要因であるといわれる。これらの因子の相互作用によって、まず、血圧の変動の幅が大きい動揺性高血圧を発症する。動揺性高血圧は、血圧が高血圧状態となるときと正常血圧であるときとがあり、血圧の変動が激しいが、降圧薬などの服用には至らない。その後、高血圧症が進行すると、血圧値が常に高い状態で維持される固定性高血圧となる。このまま高血圧が進行していくと、さらに動脈硬化を生じて脳卒中や心臓病、動脈瘤あるいは腎不全を生じるようになり、最悪死に至ってしまう。

表 5.3: 高血圧の分類と成因

高血圧の種類		成因
本態性高血圧		原因不明
二次性高血圧	腎性高血圧	腎臓脈狭窄, 腎盂腎炎, 糸球体腎炎, 腎腫瘍
	腎血管性高血圧	腎動脈動脈硬化, 腎動脈狭窄
	内分泌性高血圧	甲状腺機能亢進症, クッシング症候群, 高アルドステロン症, 褐色細胞腫, 先端巨大症
	大血管疾患高血圧	大動脈の狭窄症, 大動脈炎症候群, 動脈硬化, 大動脈弁閉鎖不全症
	神経原性高血圧	ストレス, 脳腫瘍, 脳炎, 脳血管障害
	薬物による高血圧	非ステロイド性抗炎症薬, 経口避妊薬, コカイン, アルコールの乱用, 甘草

このように、高血圧症は段階的に進んでいき、気が付いたら取り返しの付かないような病気を呼び起こす危険性を孕んでいる。高血圧症を初期の段階で留めるためには、自分の血圧値を常に知ることが大切である。そのためにも、簡単に血圧値を測定できる計測装置の実現が望まれるのである。

高血圧がはらむ危険性

高血圧が続くことで、その高い圧力を受ける臓器に障害が生じてくる。特に直径100 μ m程度の細動脈に影響し、動脈を構成する毛間壁の中壁が厚くなり、さらに内膜も厚くなるため、血管内腔は狭くなる。また、高血圧の影響は血管内腔を覆う血管内皮にも障害を起こすため、障害部位を修復しようとし、白血球、単球、血小板等がフィブリノーゲン（血液凝固を果たす線維素原）によって粘着・侵入し、そこにマクロファージが蓄積する。加えて、内皮の透過性が亢進するため、脂肪やその他の血漿成分が侵入し、さらに血管内皮で産生・分泌される収縮因子（エンドセリン、アンジオテンシン）や拡張因子（一酸化窒素、アドレノメドリン）が作用することにより、動脈硬化が発生してくると考えられている。高血圧による動脈硬化は、脳動脈、冠動脈、腎動脈、四肢の抹消動脈、目の網膜動脈など、様々な臓器の動脈に生じて循環障害が起こる。

高血圧が長期間持続すると、脳では脳出血、くも膜下出血、脳梗塞を起こしやすくなり、

心臓では狭心症，心筋梗塞を起こしやすくなる．また，心臓は強い圧力で血液を全身に送り出さなければならなくなり，心肥大が起こる．特に大動脈に血液を送り出している左心室が肥大する．心肥大が進むと結果として心不全も起こるようになる（図 5.2）．さらに大動脈にコブ状の拡張した部分ができたり（大動脈瘤），下肢の循環障害のために休み休みでないと歩けなくなったり（間欠性跛行），網膜動脈が出血して視力障害（眼底出血）が起きたりする．さらに血液をろ過して尿を作る糸球体も硬化し，たんぱく尿，腎機能の低下が認められるようになり，腎不全が生じるようになる．

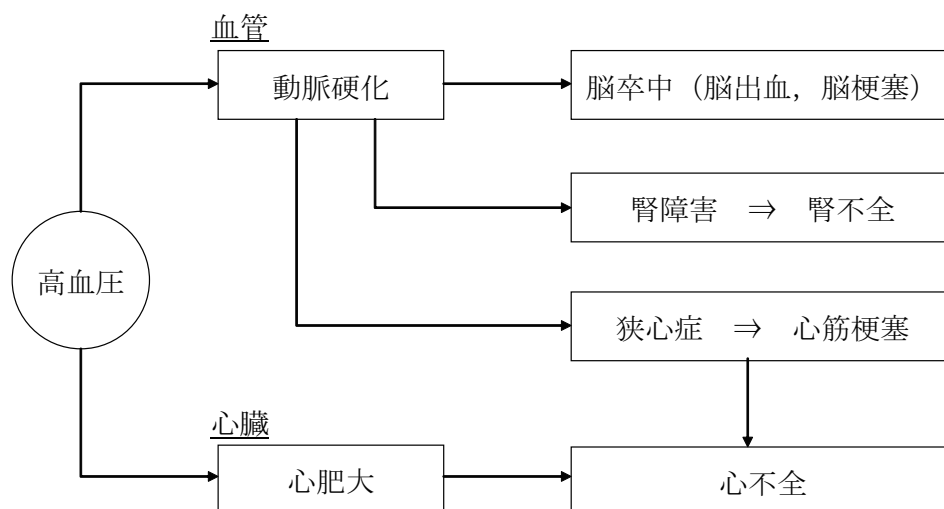


図 5.2: 高血圧により発生する疾患

日本国民の血圧の現状および推移

2010 年の国民健康・栄養調査によると，30 歳以上の日本男性の 60%，女性の 45%が高血圧（収縮期血圧 140mmHg 以上または拡張期血圧 90mmHg 以上，または降圧薬服用中）と判定された [101]．また国による循環器疾患調査である 1980 年 NIPPON DATA80 から 2010 年 NIPPON DATA2010 までの 30 年間の高血圧有病率の解析において，年齢が高いほど有病率が高く，50 歳代以上の男性と 60 歳代以上の女性では 60%を超えている（図 5.3, 5.4）．日本における 2010 年の高血圧有病者は約 4300 万人（男性 2300 万人，女性 2000 万人）である．高血圧有病率は，女性では各年齢階級において下降傾向がみられるが，男性の 50 歳代以上では横ばいあるいは上昇傾向である可能性がある（図 5.3, 5.4）．高齢化に伴い，高血圧有病率は今後さらに増加することが予想される．

5.1.3 血圧測定法

近年において，血圧の測定は誰にでも簡単に行える検査法として広く浸透している．医療現場だけでなく家庭においても血圧測定器を備え，自分自身の血圧を測定して管理する普通となっている．血圧の測定法には観血測定法と非観血測定法の 2 種類がある．各々の測定原理と特徴について述べる．




図 5.3: 高血圧有病率 (男性)




図 5.4: 高血圧有病率 (女性)




図 5.5: 推定有病者数 (男性)




図 5.6: 推定有病者数 (女性)

観血測定法

観血測定法は血管内にカテーテルを直接挿入し、これを介して血圧トランスデューサによって血圧を測定する方法である。カテーテルを被験者の体内に留置することで血圧を連続的にモニタすることができる。さらに血圧だけでなく心内圧や肺動脈圧などの血圧も測定することができ、これらは重症患者に対して循環動態を診る上で重要なパラメータとして利用される。よってこの方法は集中治療の必要な手術後の患者や全身状態の悪い患者の管理には有用な測定法である。もう一つの利点として、非観血測定法において使用されるカフが不要であるため、輸液や輸血、また他の測定点として左右の腕が使われている場合においても血圧の測定ができることが挙げられる。

非観血測定法

観血測定法の欠点は、皮膚の切開や血管の穿刺を必要とし、被験者に対して侵襲的で相当な負担があることである。被験者の負担がない方法として、カフを用いて皮膚の上から間接的に血圧を測定する非観血測定法がある。非観血測定法として代表的な「コロトコフ音法」と「オシロメトリック法」について述べる。

コロトコフ音法

1905年、ロシアの生理学者であるコロトコフが血管雑音の実験において生み出した方法である。[102]。実験ではまず腕にカフを巻き、その中に最高血圧を超える程度の空気を入れ、その後徐々に空気を抜いていったところ、カフ内の圧力が最高血圧に一致した瞬間に血管から明瞭な振動音が測定された。さらに空気を抜き、カフ内の圧力が最低血圧より低くなると振動音が消えることも観測された。この2つの時点の空気圧を正確に把握することが血圧を測定することに繋がるのである。この振動音を発見者の名前を取りコロトコフ音と呼んでいる。

コロトコフ音法による血圧測定で、初めから使われてきたのがリヴァロッチの水銀柱マンメータである[103]。水銀が使われた理由は、比重が約13.5と比較的大きく、20cmの液体を入れる柱があれば200mmHg程の血圧まで測定することができたからである。測定の仕方として、まずカフを被験者に巻き付ける。カフ内にはゴム袋が入れられており、これは細いゴムホースでゴム球に連結されている。ゴム球を握ることでカフに空気が送られ、空気圧で上腕を締め付ける構造になっている。水銀面を見ながら十分に空気を送り込み、その後空気を抜いていき、コロトコフ音が聞こえ始めたらその瞬間の水銀の高さを読み取る。これが最高血圧である。さらに空気を抜き、コロトコフ音が完全に聞こえなくなった瞬間を最低血圧とする。




図 5.7: Korotkov 音法による血圧測定法

オシロメトリック法

オシロメトリック法の測定方法はコトコフ音を用いた方式とほぼ同じであるが、コトコフ音の代わりに測定中に発生する圧力の振動を利用する。カフにより動脈を圧迫し、その圧を収縮期血圧を超えるまで上げた後に徐々に減圧すると、動脈拍動に伴いカフ圧内に強制的に振動（Oscillation）が発生する。この時にカフ圧が最大血圧に相当する。さらにカフ圧を下降させると振動が次第に大きくなり、その後再び振動が弱くなり始める。この時のカフ圧が最低血圧に相当する。

オシロメトリック法はコトコフ音法と比較して一般化された時期が遅く、1970年代にオシロメトリック法による自動血圧計がアメリカで導入された。オシロメトリック法はソフトウェアによる処理が必要であり、医療機器にコンピュータ技術が入り始めた時期に医療機関で普及が進んだ。近年は腕や手首に巻いて測定できる簡易的なオシロメトリック自動血圧計が市販され、簡便な血圧測定に貢献している。




図 5.8: オシロメトリック法による血圧測定法

5.2 光電容積脈波を用いた血圧値推定

ここでは脈波からの血圧推定手法について述べる。5.2.1 節では脈波から抽出されるパラメータについて、5.2.2 節では血圧と脈波と取得実験について、5.2.3 節では本研究で提案する血圧推定手法について、5.2.4 節、5.2.5 節にて結果と考察を述べる。

5.2.1 脈波と循環動態との関係

光電容積脈波

血中ヘモグロビンが光を吸収する性質を利用して血流量を計測する装置を光電式容積脈波計 (PPG: photoplethysmography) と呼ぶ。PPG で取得される信号例を図 5.9 に示す。脈波信号は心臓からの駆出波 (PW: Percussion Wave) と血管壁等から反射波 (TW: Tidal Wave) の合成によって構成され、脈診においては PW 及び TW の波高観測が重要となる。一般に若年者では PW が脈波信号の最高点を占めるが、加齢や動脈硬化が進むにつれて TW が高くなる傾向を示し、場合によっては PW が TW の中に埋没して両者を区別することができなくなる [121]。また、PW と TW の 2 つの波高比を動脈系の弾性を示す指標 (弾性係数) として、臨床へ適用例がある [122]。PW 及び TW 以外の脈波成分として、前波 (Pre-ejection Wave)、切痕 (DN: Dicrotic Notch)、重複波 (DW: Dicrotic Wave) があり、いずれも動脈系の状態に起因して波高、もしくは各成分の時間間隔に影響を与えるケースが多く見られる。

加速度脈波

光電容積脈波は波形の変化が緩やかであるため、図 5.9 で示した各脈波成分を正確に捉えることは困難である。この脈波成分は脈波信号の変曲点であるため、脈波信号を 2 次微分することで波形成分の抽出が可能となり、こうして得られる波形を加速度脈波 (APW: Acceleration Pulse Wave) という [123]。図 5.10 に加速度脈波信号の波形例を示す。脈波信号の変曲点に対応して、a 波から e 波までの波形成分を抽出することができる。a 波と b 波は収縮期前方成分であり、血液の駆出によって生ずる駆動圧波を反映している。それに対し c 波と d 波は収縮期後方成分であり、駆動圧波が末梢に伝搬し反射して戻ってきた反射圧波を反映している。加齢によって反射波が増大し、収縮期後方成分が上昇することが知られているが、血圧値、脳血管疾患・虚血性心疾患等の既往症や現症の有無によっても統計的な傾向があることが示されている [122]。e 波は拡張初期成分であり、大動脈弁閉鎖後の末梢血流を反映している。加齢により血管の抵抗が増加し、末梢血流に影響を与えることが考えられる。

Takazawa ら [124] は、各波形成分を収縮初期陽性波である a 波で除した波高比 (b/a , c/a , d/a , e/a) が加齢に伴い変化するというデータを示している。各波高比はそれぞれ意味が異なるが、特に b/a は器質的な動脈壁の硬化、 d/a は血管内圧の上昇に伴う機能的な動脈硬化を表すパラメータであるとされているため、加速度脈波解析は動脈硬化に伴う血圧値上昇の傾向を推測する有効な手段であると考えられる。




図 5.9: 脈波信号 (左: 若年者 右: 高齢者)




図 5.10: 加速度脈波信号 (左: 若年者 右: 高齢者)

血圧値推定に用いるパラメータ

以上より、脈波及び加速度脈波は循環動態の変化を表す生体指標であるということが出来る。血圧においても、心拍出量と末梢血管抵抗との積で表され、循環動態と密接に関係している。よって、脈波から循環動態のパラメータを抽出することにより、血圧値の推定が可能であると考えられる。

脈波から抽出した各種パラメータを図 5.11 に示す。脈波からは 4 箇所、脈波の 2 次微分波形から 5 箇所の変曲点を抽出し、各波高をパラメータとして用いる。加えて、脈波の各変曲点の時間間隔、脈波波形の面積、2 次微分波形の変曲点の波高比もパラメータとして使用する。

5.2.2 脈波と血圧値の計測実験

計測方法

光電容積脈波信号と同時にリファレンスとして血圧値を取得した。実験風景を図 5.12 に示す。被験者数は 691 人 (男性: 382 人, 女性 309 人) である。光電容積脈波センサ (図 5.13) を左人差し指、カフを右上腕に装着し、被験者には座位状態で 5 分間の安静を保って




図 5.11: 脈波から抽出されたパラメータ

もらった。計測したデータから 5.2.1 節で示したパラメータを抽出し、後半 4 分間の平均値を血圧値推定に使用する。血圧の計測には A&D 社 ME 血圧監視装置 TM-2540R を用いた。この血圧計はオシロメトリック方式で血圧値の計測を行うものである。また脈波信号の計測には (株) デンソー製の光電容積脈波センサ (8mm × 12mm) を用いた。脈波信号のサンプリング周波数は 1000Hz とした。その他被験者には年齢、身長、体重等の個人情報アンケートに記述してもらった。




図 5.12: 計測実験風景




図 5.13: 光電容積脈波センサ

表 5.4: 691 人の被験者から取得した計測データ (平均値 ± 標準偏差)

Age / Sex		Subjects [n]	Height [m]	Weight [kg]	SBP [mmHg]	PR [bpm]
~20	M	4	174.0 ± 7.8	70.8 ± 7.0	119.3 ± 7.7	72.2 ± 7.6
	F	2	156.8 ± 2.5	52.3 ± 8.1	107.2 ± 5.1	85.1 ± 13.4
20~30	M	61	171.2 ± 5.5	64.4 ± 10.1	114.7 ± 11.3	72.4 ± 9.4
	F	40	157.7 ± 4.6	51.4 ± 7.2	99.1 ± 7.9	66.6 ± 7.5
30~40	M	50	171.7 ± 6.3	65.8 ± 8.8	115.9 ± 11.1	68.5 ± 9.5
	F	40	157.2 ± 6.4	50.9 ± 5.9	105.8 ± 11.8	68.3 ± 10.6
40~50	M	49	169.4 ± 6.6	68.4 ± 7.5	123.5 ± 12.5	70.6 ± 10.5
	F	32	157.5 ± 5.2	53.2 ± 7.6	110.1 ± 12.5	66.6 ± 8.2
50~60	M	29	166.9 ± 6.5	66.7 ± 9.6	127.6 ± 13.4	69.8 ± 11.8
	F	10	152.8 ± 4.7	51.6 ± 4.5	125.1 ± 11.7	70.6 ± 8.6
60~70	M	100	165.5 ± 5.7	65.0 ± 8.1	128.8 ± 15.5	68.7 ± 9.4
	F	132	152.8 ± 4.8	52.2 ± 6.8	123.4 ± 16.2	69.4 ± 7.5
70~	M	89	165.2 ± 6.0	63.4 ± 7.9	130.0 ± 13.6	68.1 ± 9.9
	F	53	152.9 ± 4.6	53.1 ± 5.8	124.2 ± 15.9	71.3 ± 8.2

表 5.5: 691 人の被験者から取得した脈波特徴量 (平均値 ± 標準偏差)

Age / Sex		Subjects	b/a	c/a	d/a	e/a
~20	M	4	-0.77 ± 0.09	-0.07 ± 0.11	-0.14 ± 0.07	0.20 ± 0.05
	F	2	-0.80 ± 0.02	-0.01 ± 0.04	-0.16 ± 0.03	0.14 ± 0.01
20~30	M	61	-0.87 ± 0.11	-0.04 ± 0.11	-0.14 ± 0.10	0.18 ± 0.06
	F	40	-0.82 ± 0.13	0.01 ± 0.08	-0.24 ± 0.12	0.16 ± 0.05
30~40	M	50	-0.82 ± 0.14	-0.07 ± 0.11	-0.24 ± 0.12	0.18 ± 0.06
	F	40	-0.68 ± 0.15	-0.08 ± 0.09	-0.35 ± 0.12	0.17 ± 0.05
40~50	M	49	-0.74 ± 0.13	-0.13 ± 0.10	-0.32 ± 0.15	0.21 ± 0.06
	F	32	-0.60 ± 0.17	-0.15 ± 0.09	-0.46 ± 0.14	0.18 ± 0.06
50~60	M	29	-0.63 ± 0.14	-0.20 ± 0.11	-0.43 ± 0.12	0.21 ± 0.07
	F	10	-0.51 ± 0.16	-0.23 ± 0.11	-0.49 ± 0.16	0.18 ± 0.06
60~70	M	100	-0.62 ± 0.13	-0.23 ± 0.11	-0.43 ± 0.12	0.20 ± 0.07
	F	132	-0.53 ± 0.11	-0.26 ± 0.10	-0.47 ± 0.13	0.17 ± 0.06
70~	M	89	-0.60 ± 0.14	-0.24 ± 0.11	-0.45 ± 0.15	0.19 ± 0.08
	F	53	-0.52 ± 0.14	-0.26 ± 0.10	-0.48 ± 0.15	0.15 ± 0.07

計測データの分析

計測実験で取得したデータを表 5.4, 脈波特徴量を表 5.5 に示す. 左から順に身長, 体重, 最高血圧値 (SBP : Systolic Blood Pressure), 脈拍数 (PR : Pulse Rate), 波高比

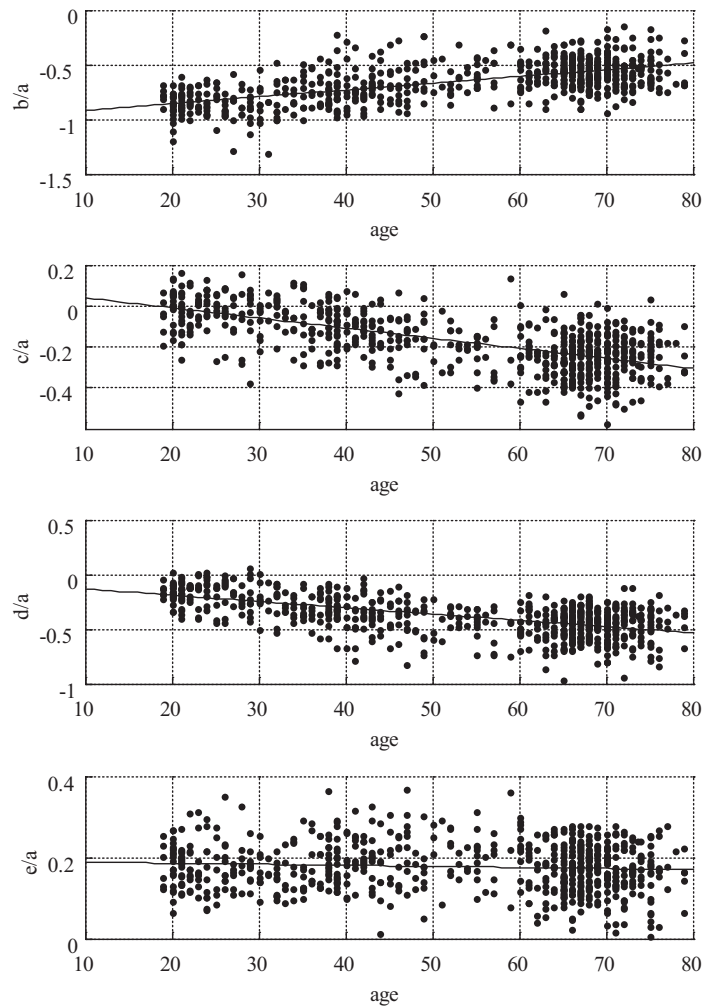


図 5.14: 加齢に伴う加速度脈波の各波高比の変化

(b/a , c/a , d/a , e/a) であり、値は平均値と標準偏差である。

Takazawa ら [124] の分析と同様に、被験者から取得した脈波から加速度脈波を求め、各波高比を算出した。その結果、 b/a は加齢に伴い上昇し、 c/a , d/a , e/a は加齢に伴い下降するという Takazawa ら [124] のデータと同様の傾向を得ることができた (図 5.14)。5.2.1 節で述べたように、各波高比は動脈壁の硬さを表すパラメータであるため、加齢と共に動脈硬化が進行する傾向が示されている。また、血圧値と加速度脈波の波高比との関係を分析したところ、加齢に伴う変化と全く同傾向であった (図 5.15)。すなわち、本実験で計測した脈波は血管情報を含んでおり、さらに加速度脈波が血圧値と相関関係があることから、脈波をパラメータとすることで血圧値の推定が可能であると考えられる。本論文では 5.2.1 節で述べた脈波の各種パラメータを入力として、非線形回帰分析手法を用いることで血圧の絶対値推定を行う。

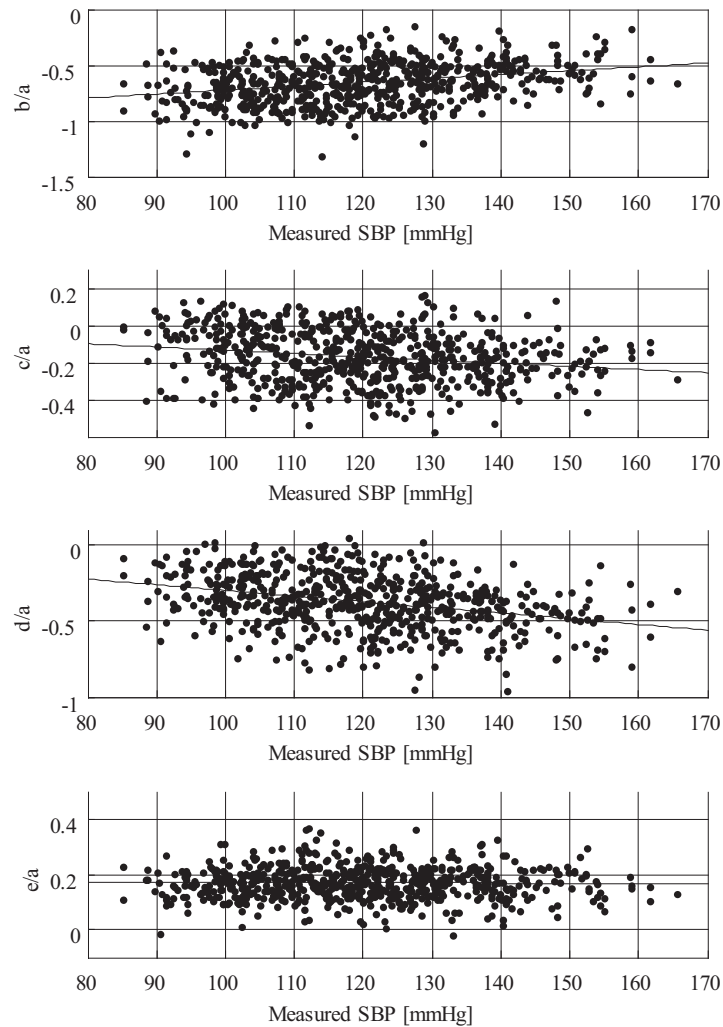


図 5.15: 血圧値と加速度脈波の各波高比との関係

5.2.3 血圧値推定手法

従来 of 推定手法

脈波単一の信号から血圧値を推定する手法として、鈴木ら [27] はステップワイズ法による変数選択と重回帰分析を組み合わせることで行っている。重回帰分析は回帰式が一次方程式で表されるため、説明変数が目的変数に対して線形に増加・減少する場合は有効であるが、非線形性を有する場合においては有効に機能しないことがある。

図 5.16 に、推定に用いるパラメータの一つである加速度脈波の b/a と血圧計測値との分布を示す。血圧値の増加に伴い b/a も増加する傾向にあるが、線形には変化せず、低血圧領域と高血圧領域においては変化が緩やかとなり、非線形性を有することが読み取れる。また、データのばらつきも大きいため、データのばらつきに対してロバストな推定手法が求められる。




図 5.16: 加速度脈波 b/a と血圧計測値との関係




図 5.17: 対数関数によるパラメータの線形近似

非線形重回帰分析

通常重回帰分析（線形重回帰分析）は、目的変数 y に対して説明変数 x_1, x_2, \dots を用いて式 (5.1) の様に表される。

$$y = w_1x_1 + w_2x_2 + \dots + v \quad (5.1)$$

これは一次方程式のため、説明変数は目的変数に対して線形増加（あるいは減少）することが望ましい。しかし、図 5.16 で示した通り、脈波信号は血圧値に対して必ずしも線形には変動しない。図 5.17 に、加速度脈波の波高 b と、 $\log(|b|)$ の血圧値に対する分布を示す。波高 b に対して対数関数を当てはめることにより血圧値との相関が高くなるが、これは非線形性を持ったパラメータが線形に近づいたことを意味する。この様に説明変数を予め線形近似し、その説明変数を用いて線形重回帰分析を行うことで、非線形の重回帰式が構築可能となり、非線形性を持った説明変数の回帰に有効であると考えられる。

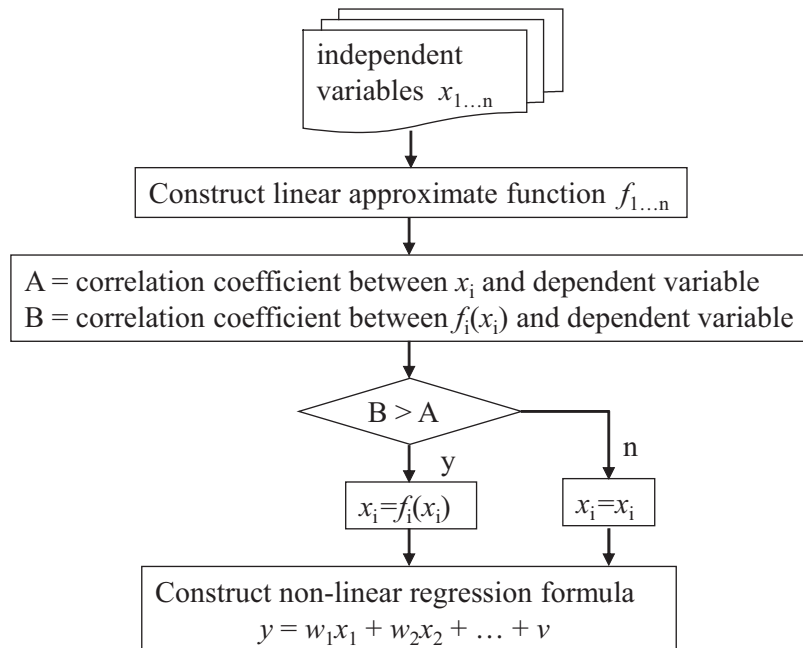


図 5.18: 非線形重回帰分析のアルゴリズム

非線形重回帰式は式 (5.2) の様になる。

$$y = w_1 f(x_1) + w_2 f(x_2) + \dots + v \quad (5.2)$$

ここで f は線形近似関数である。線形近似関数として多項式，指数，対数などが考えられるため，最適な関数を検討する。

線形近似関数を適用することにより，逆に線形性が失われる場合がある。例えば $y = x$ の様な完全な線形式に指数関数や対数関数を当てはめると非線形性を持つことになる。これを回避するために，線形近似関数の適用前後で血圧値との相関値を評価し，線形性が失われる説明変数に対しては線形近似関数を適用しないステップを設けた。アルゴリズムのフローは図 5.18 の様になる。

サポートベクター回帰 (SVR)

サポートベクター回帰 (SVR : Support Vector Regression) とは，2 値判別器として知られるサポートベクターマシン (SVM : Support Vector Machine) の回帰問題への拡張である。SVM と同様に高い汎化性能を持ち，カーネル関数を導入することにより非線形への拡張が可能である。SVR を用いた先行研究として物体認識 [125] や経済予測 [126] などの非線形事象に対しての適用例があり，いずれも効果を上げている。

SVR による非線形回帰の概念図を図 5.19 に示す。SVR は一定距離内の誤差を無視する損失誤差 ϵ を定義し，出力値 y が $-\epsilon \leq y \leq \epsilon$ に収まるような回帰式を求める。しかしデータによっては ϵ から外れる場合があるため，外れた距離をスラック変数 ξ と定義してこれの最小化を行う。

以上の定式化を行う。目的の線形回帰式を式 (5.3) とした場合、推定式は ϵ -インセンシティブ損失関数を用いて式 (5.4) の様に表される。

$$y = g(\mathbf{x}) = \langle \mathbf{w} \cdot \mathbf{x} \rangle + v \quad (5.3)$$

$$L(\mathbf{x}, y, g) = \max(0, |y - g(\mathbf{x})| - \epsilon) \quad (5.4)$$

ここで \mathbf{x} は特徴ベクトル， \mathbf{w} は重みベクトルである。さらにスラック変数を導入すると，最終的な主問題は式 (5.5) の様に定義される。

$$\begin{aligned} \text{minimize} \quad & \|\mathbf{w}\|^2 + C \sum_{i=1}^l (\xi_i^2 + \hat{\xi}_i^2) \\ \text{subject to} \quad & (\langle \mathbf{w} \cdot \mathbf{x}_i \rangle + v) - y_i \leq \epsilon + \xi_i \\ & y_i - (\langle \mathbf{w} \cdot \mathbf{x}_i \rangle + v) - y_i \leq \epsilon + \hat{\xi}_i \\ & \xi_i, \hat{\xi}_i \geq 0 \\ & i = 1, \dots, l \end{aligned} \quad (5.5)$$

これは SVM と同様に，ラグランジュ乗数を導入することにより最適大局解を求めることができる [127]。式 (5.3) は線形の回帰式であるが，非線形関数 $\phi(x)$ を導入し高次元空間に写像することによって，非線形の回帰が可能となる。しかし高次元空間の内積計算を行う必要があり，計算が煩雑であるため，元の次元でこの内積計算を行うことができるカーネル関数を用いることが一般的である。本論文ではカーネル関数としてガウシアンカーネルを用いる。

SVR において，パラメータ ϵ 及び C は経験的に決める必要がある。 ϵ はデータに対する当てはまり度， C は外れ値に対する許容度をそれぞれ意味する。 ϵ を小さくすることでデータに対する当てはまりが良くなり，複雑な回帰式を構築することができるが，背反として過学習に陥ることがある。また C は大きくすることで外れ値に対してロバストな学習が可能になるが，回帰式そのものが不完全となり得る。本論文では ϵ , C それぞれの最適な値を逐次的に探索して求める。




図 5.19: サポートベクター回帰による非線形回帰

5.2.4 血圧値推定結果

推定精度の評価方法

691 の被験者データ中、600 データを回帰式の構築に用い、91 データで最高血圧値の推定を行った。

実測最高血圧値 m_i と提案手法により求めた推定最高血圧値 e_i との相関係数 R (式 (5.6)), 誤差の標準偏差 $SD[\text{mmHg}]$ (式 (5.7)) を評価指標として用いる. n はデータ数, \bar{e} は実測最高血圧値の平均値, \bar{m} は推定最高血圧値の平均値, $s_i = m_i - e_i$ である. R は数値が大きいほど, SD は数値が小さいほど推定精度がよいことを意味する.

$$R = \frac{\sum_{i=1}^n (e_i - \bar{e})(m_i - \bar{m})}{\sqrt{\sum_{i=1}^n (e_i - \bar{e})^2} \sqrt{\sum_{i=1}^n (m_i - \bar{m})^2}} \quad (5.6)$$

$$SD = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (s_i - \bar{e})^2} \quad (5.7)$$

非線形重回帰分析による推定結果

入力データ x に対する線形近似関数 $f(x)$ として、多項式、指数、対数を選択した. 多項式については2次から7次までを評価した. 線形近似関数別の推定精度を表 5.6 に示す. また、図 5.20 に従来手法である線形重回帰分析による推定血圧値と計測値の分布、図 5.21 に最も精度がよい2次多項式による推定血圧値と計測値の分布を示す. 従来手法による推定精度は $R = 0.648$, $SD = 12.168\text{mmHg}$ であるが、線形近似関数を用いることによる精度改善が見られた. 多項式については次数を大きくすることによりデータに対する当てはまりはよくなるが、推定精度の向上は見られなかった. これはデータに対して過剰にフィッティングし、未知データに対する推定がうまく行われなかったためだと考えられる.

表 5.6: 線形近似関数別の推定精度

種類	$f(x)$	R	$SD[\text{mmHg}]$
線形重回帰	x	0.668	11.856
2次多項式	$k_1x^2 + k_2x + k_3$	0.733	10.862
3次多項式	$k_1x^3 + \dots + k_3x + k_4$	0.723	11.009
4次多項式	$k_1x^4 + \dots + k_4x + k_5$	0.720	11.073
5次多項式	$k_1x^5 + \dots + k_5x + k_6$	0.699	11.385
6次多項式	$k_1x^6 + \dots + k_6x + k_7$	0.698	11.408
7次多項式	$k_1x^7 + \dots + k_7x + k_8$	0.702	11.355
指数	$\exp(x)$	0.681	11.667
対数	$\log(x)$	0.689	11.548




図 5.20: 線形重回帰分析による血圧推定結果




図 5.21: 2次多項式を用いた血圧推定結果

SVR による推定結果

全データを入力データ x として用いて SVR による血圧値推定を実施した。パラメータ C と ϵ をそれぞれ変化させながら推定精度の評価を行い、最適な値を求めた。推定精度の評価には相関係数 R を用いることとし、 R が最も高くなる C 、 ϵ を最適値とした。その結果、 $C = 2^4$ 、 $\epsilon = 2^{0.4}$ で最も推定精度が高くなった。また、5.2.4 節で示した非線形重回帰分析による結果よりも推定精度が高くなり、 $R = 0.784$ 、 $SD = 9.993\text{mmHg}$ となった (図 5.22)。




図 5.22: SVR による血圧推定結果

以上では全データから一つの学習機を構築して推定を行ったが、画像処理分野において複数の学習機によるアンサンブル学習を行うことで処理精度を向上させた例がある [128]. 血圧値においては、表 5.4 で示される様に加齢に伴い血圧値のばらつきは増える傾向にある。例えば、70 代男性の血圧値は 20 代男性の血圧値と比較して 13.3% 上昇しているが、標準偏差は 20.3% 上昇しており、ばらつきが増えていると判断できる。女性についても傾向は同じである。全年齢に対して唯一の学習機で推定を行うと、加齢に伴う血圧値のばらつきに対応できないことが考えられるため、年齢層毎に学習機を構築し、各学習機を用いた血圧値推定を行った。

鈴木ら [27] の研究において、60 歳以上では心血管の個人差が大きくなるため最高血圧値のばらつきが大きくなるとしている。よって本論文ではこれに倣い 60 歳を閾値とし、60 歳未満を若年者、60 歳以上を高齢者と定義した。若年者データを入力データとして用いた場合のパラメータ分析を行った結果、 $C = 2^{3.6}, \epsilon = 2^{0.4}$ で最も推定精度が高くなった。高齢者データを用いた場合のパラメータ分析では、 $C = 2^{9.9}, \epsilon = 2^{-5.6}$ で最も推定精度が高くなった。

図 5.23 に年齢層毎に学習した 2 つの SVR を用いた推定結果を示す。 $R = 0.819, SD = 9.167\text{mmHg}$ となり、1 つの SVR のみを用いた場合の結果と比較して精度を向上させることができた。JIS で規定されている血圧計の規格は $SD \leq 8.0\text{mmHg}$ であるが、従来の線形手法による推定よりも規格値に近づけることができ、本手法の有効性を示すことができた。

5.2.5 考察

本論文で提案した線形近似を用いた非線形重回帰分析による推定と SVR を用いた推定について考察を述べる。




図 5.23: 複数の SVR による血圧推定結果

非線形重回帰分析に対する考察

本研究において多項式、指数、対数を用いて血圧推定を行ったが、2次多項式を用いた場合に推定精度が最も向上した。2次より次数を増加させた場合に精度が減少したが、この原因について考察する。

図 5.24 に非線形重回帰分析で使用した説明変数の内、寄与率の大きい上位3つの変数と血圧測定値との分布を示す。尚、図中の曲線は2次式の回帰曲線である。この分布より、推定で使用した説明変数は変曲点を複数持つような複雑な変動はせず、2次式で十分に回帰できたため、2次多項式において推定精度が最も高くなったと考えられる。

SVR に対する考察

全被験者データで学習した場合におけるパラメータ分析のプロットを図 5.25 に示す、傾向として、データの当てはまり度を意味する ϵ は増加に伴い推定精度も向上するが、ある変曲点を過ぎると過学習状態となり、推定精度が徐々に減少する傾向が見られた。外れ値に対する許容度を意味する C については、ある値にて推定精度最大となるが、大きくし過ぎると全てのデータを外れ値と誤認識し、推定が全く行われないう状態となった。

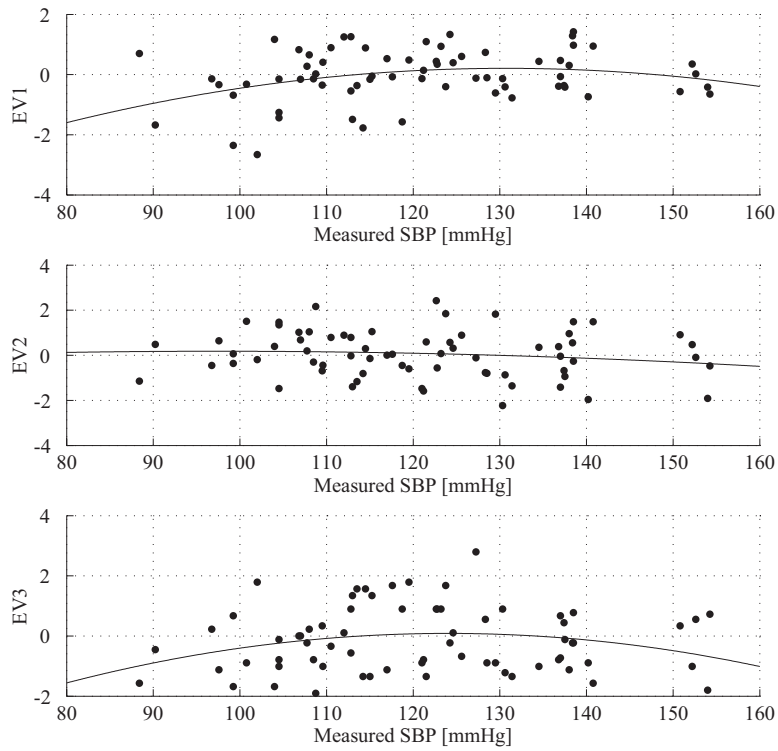


図 5.24: 非線形重回帰分析において寄与率の大きい説明変数と血圧測定値との分布




図 5.25: SVR のパラメータ分析 (全データ)

図 5.26 に若年者のデータのみを用いた場合の結果を示す. 全データを用いた場合の傾向と似ており, ϵ の増加に伴い推定精度が向上し, ある変曲点を推定精度は徐々に減少した. C については推定精度最大となる値が存在するが, 大きくし過ぎると推定が行われない状

態となった。

図 5.27 は高齢者のデータのみを用いた場合の結果であり、傾向は若年者データと同様である。最適値においては若年者データと比較して C は大きく、 ϵ は小さい値となった。これは高齢者においては血圧値のばらつきが大きいいため、学習のロバスト性を上げるために C を大きく、また過剰フィッティングを避けるために ϵ を小さくしたことが学習において有効であったためだと考えられる。




図 5.26: SVR のパラメータ分析 (若年者)




図 5.27: SVR のパラメータ分析 (高齢者)

学習機の個数

本研究では2つのSVRを用いた血圧推定を行ったが、年齢に応じた学習機をさらに増やすことで推定精度が向上することが考えられる。これを実現するためには年齢別の学習データを十分な数だけ用意し、データ不足による未学習を防ぐ必要がある。本論文で取得したデータは年齢によってはデータ数が少ないため2分割に止めたが、3分割以上の学習は年齢別の十分な学習データを用意することが前提となるため、今後の実施要件とする。

推定精度について

本研究において R と SD を用いて推定精度評価を行ったが、全ての血圧値において正しく推定できているかを評価するために、Bland-Altman Plot による分析を行った (図 5.28)。複数のSVRを用いた場合の結果に対して分析しており、横軸が測定血圧値と推定血圧値の平均値、縦軸が差である。これより、低血圧および高血圧に対して推定の誤差が大きい傾向にあることが読み取れる。全ての血圧値に対してロバストに推定できる学習機の構築が課題となる。




図 5.28: Bland-Altman Plot による測定血圧値と推定血圧値の比較

5.3 非線形手法を用いた血圧推定の拡張

前節では脈波特徴量を用いた血圧推定手法について述べた。非線形手法を用いることで線形手法と比較して推定精度を向上させることができたが、低血圧、および高血圧において推定精度が下がる傾向が見られた。本節では低血圧、および高血圧の被験者データに対して高精度な推定を実現する手法、および推定精度の信頼度を求める手法について述べる。

5.3.1 学習データの分割とオーバーラップによる補正学習

重回帰分析による血圧推定の傾向

図 5.29 に非線形重回帰分析による血圧推定結果を示す。赤枠で示した個所は高血圧を低く推定したデータであり、青枠で示した個所は低血圧を高く推定したデータである。傾向として高血圧は低く、低血圧は高く推定してしまうため、推定範囲が狭くなる欠点が存在する。この原因として、重回帰分析の傾向として学習データの分布よりも狭い範囲の推定しか行うことができないからだと考えられる。図 5.30 はイメージであるが、仮に学習データの範囲が 85~155mmHg であった場合、非線形重回帰分析による推定値はこの範囲よりも狭く、100~145mmHg となってしまう。本節では学習範囲の制約から生じる推定精度悪化を抑制する手法について述べる。




図 5.29: 非線形重回帰分析による推定結果

学習データ分割の効果

前節で示した通り、60 歳以上の高齢者、60 歳未満の若年者にデータを分割した上で血圧推定を行ったところ、分割しない場合と比較して推定精度が向上した。これは年齢に応じて複数の学習機を構築することで、加齢に伴う血圧値変動の傾向に対応できたためである。本節でもこれと同様に、データを複数に分割することによる推定精度向上の手法について述べる。




図 5.31: 従来手法による学習機から得られる推定結果




図 5.32: 複数の学習機から得られる推定結果

低・高血圧データに対する補正学習

図 5.31 は一つの学習機のみで推定する従来手法であり，学習データの範囲 (80~160mmHg) に対して推定結果の範囲 (100~145mmHg) が狭くなることを示している．図 5.32 で示す提案手法では学習機が三つ存在し，学習機 ① は全データ範囲 (80~160mmHg) を用いて学習，学習機 ② は低血圧のデータ (80~120mmHg) を用いて学習，学習機 ③ は高血圧のデータ (120~160mmHg) を用いて学習を行う．各々の学習機の推定結果の範囲は学習データの範囲より狭くなるが，トータルの推定範囲は 85~155mmHg となり，単独の学習機のみを用いる従来手法と比較して広い範囲を推定することが可能となる．従来手法では学習精度が低い低・高血圧データに対して専用の学習機を用いて推定することを，本論文では補正学習と呼ぶこととする．

これより，2 パターンの補正学習アルゴリズムを述べる．

補正学習アルゴリズム 1

図 5.34 に補正学習アルゴリズム 1 を示す．

<学習ステップ>

- (1) 全データを用いて学習機 ① を作成
- (2) SBP120 未満のデータから学習機 ② を作成
- (3) SBP120 以上のデータから学習機 ③ を作成

<推定ステップ>

- (1) 全識別データを学習機 ① で推定
- (2) 推定結果が 115 以上 130 未満のデータは推定終了
- (3) 推定結果が 115 未満のデータは学習機 ② で再推定
- (4) 推定結果が 130 以上のデータは学習機 ③ で再推定

学習機 ① のみでは十分に推定ができない低血圧，高血圧データに対して学習機 ② と学習機 ③ を構築する．一度学習機 ① を用いて全識別データを推定し，推定結果が中血圧領域 (115~130mmHg) であればその結果を採用する．推定結果が 115mmHg 未満であれば低血圧データであると判定し，学習機 ② を用いて再度推定する．同様に，推定結果が 130mmHg 以上の高血圧データは学習機 ③ で再推定を行う．それぞれの推定結果を合わせて，最終的な推定値とする．

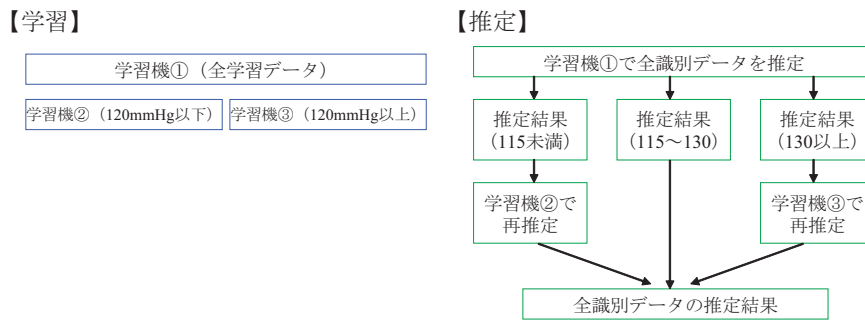


図 5.33: 補正学習アルゴリズム 1

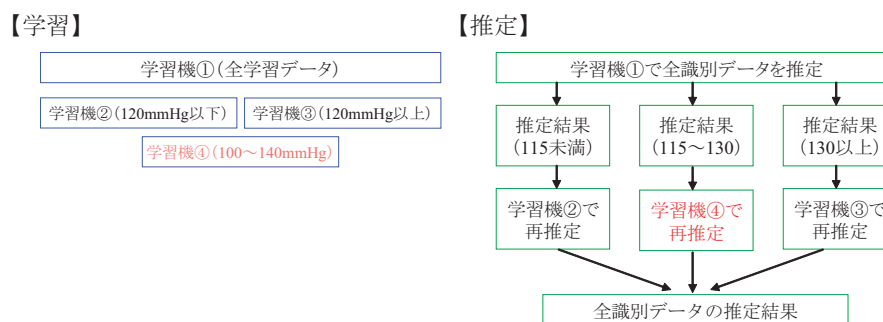


図 5.34: 補正学習アルゴリズム 2

補正学習アルゴリズム 2

図 5.34 に補正学習アルゴリズム 2 を示す。赤字で示した箇所が補正学習アルゴリズム 1 からの変化点であり、学習機が一つ追加されている。

<学習ステップ>

- (1) 全データを用いて学習機 ① を作成
- (2) SBP120 未満のデータから学習機 ② を作成
- (3) SBP120 以上のデータから学習機 ③ を作成
- (4) SBP100 以上 140 未満のデータから学習機 ④ を作成

<推定ステップ>

- (1) 全識別データを学習機 ① で推定
- (2) 推定結果が 115 以上 130 未満のデータは学習機 ④ で再推定
- (3) 推定結果が 115 未満のデータは学習機 ② で再推定
- (4) 推定結果が 130 以上のデータは学習機 ③ で再推定

学習機 ④ は血圧値が 115~130mmHg の中程度の血圧値を対象とした学習機である。学習機 ①~③ により低・中・高それぞれの範囲に最適な推定を行うことを意図している。

補正学習による推定結果

補正学習アルゴリズム 1 による推定結果

図 5.35 に従来手法および補正学習アルゴリズム 1 による推定結果を示す。どちらも推定には非線形重回帰分析を用いている。左図は従来手法による推定結果であり、補正学習による再推定の対象となるデータ範囲を色で示している。右図が補正アルゴリズム 1 による推定結果であり、高血圧と判断されて再推定が行われデータを赤点で示し、低血圧と判断されて再推定が行われたデータを青点で示している。補正学習により推定範囲が拡大し、推定結果を改善させることができた（表 5.7）。

表 5.7: 補正学習アルゴリズム 1 による推定結果

アルゴリズム		R	SD
非線形重回帰分析	補正学習なし	0.7333	10.8623
	補正学習あり	0.7383	10.7902

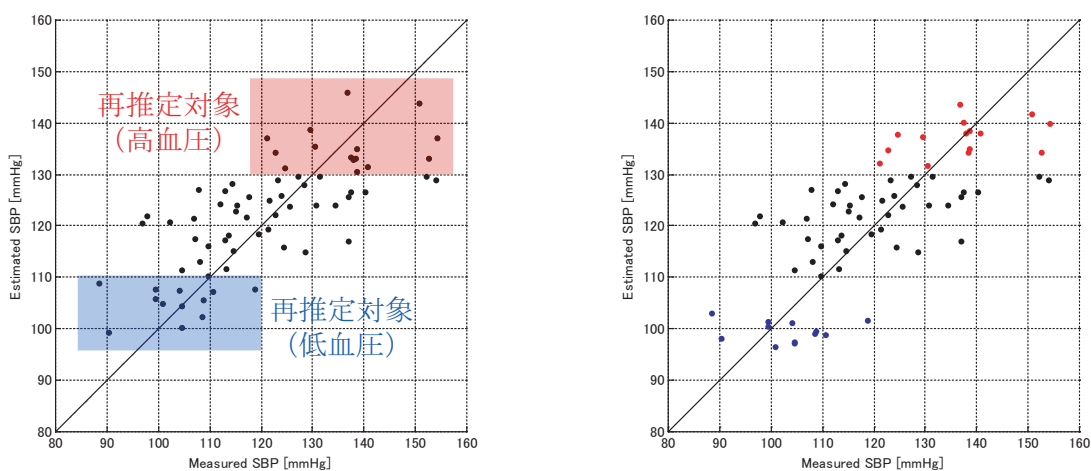


図 5.35: 非線形重回帰分析を補正学習した結果
(左図：従来手法による結果 右図：補正学習アルゴリズム 1 による結果)

図 5.36 に補正学習アルゴリズム 1 を用いて SVR による推定を補正した結果を示す。非線形重回帰分析を補正学習した場合と同様に、推定範囲が拡大し、SVR による推定を大きく改善することができた (表 5.8)。

表 5.8: 補正学習アルゴリズム 1 による推定結果

アルゴリズム		R	SD
SVR	補正学習なし	0.7841	9.9935
	補正学習あり	0.8240	9.0265

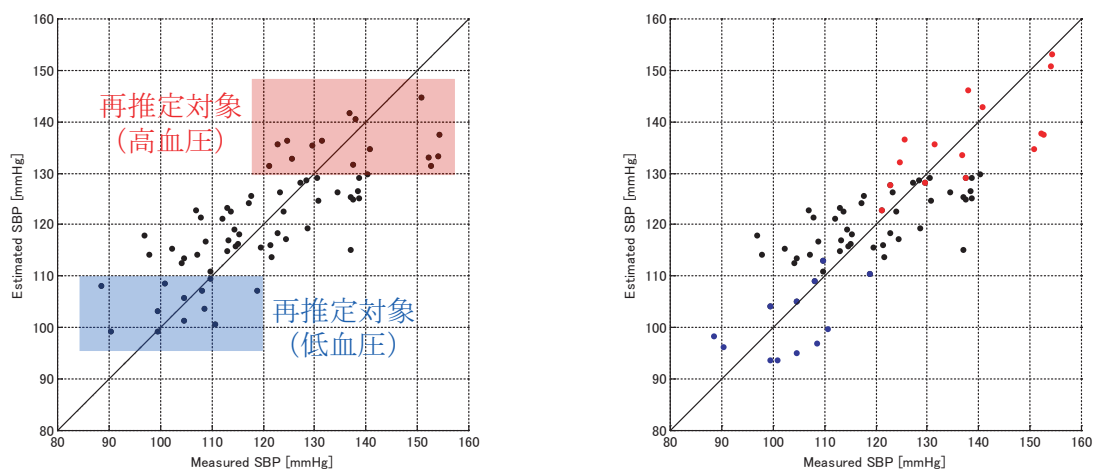


図 5.36: SVR を補正学習した結果
(左図：従来手法による結果 右図：補正学習アルゴリズム 1 による結果)

補正学習アルゴリズム 2 による推定結果

図 5.37 と図 5.38 に従来手法および補正学習アルゴリズム 2 による推定結果を示す。図 5.37 は非線形重回帰分析を補正学習した結果、図 5.38 は SVR を補正学習した結果である。どちらも補正学習することで若干精度が向上しているが、SVR については補正学習アルゴリズム 1 と比較して改善できる度合いが低い結果となった (表 5.9, 表 5.10)。これは補正学習アルゴリズム 1 では中血圧データを補正しない、つまり全ての血圧範囲のデータを用いて学習したことに対し、補正学習アルゴリズム 2 では中血圧データを補正する際に狭い範囲のデータを用いて再学習することで推定範囲が狭くなり、中血圧データの推定精度が悪くなったことが原因だと考えられる。

表 5.9: 補正学習アルゴリズム 2 による推定結果

アルゴリズム		R	SD
非線形重回帰分析	補正学習なし	0.7333	10.8623
	補正学習あり	0.7406	10.7179

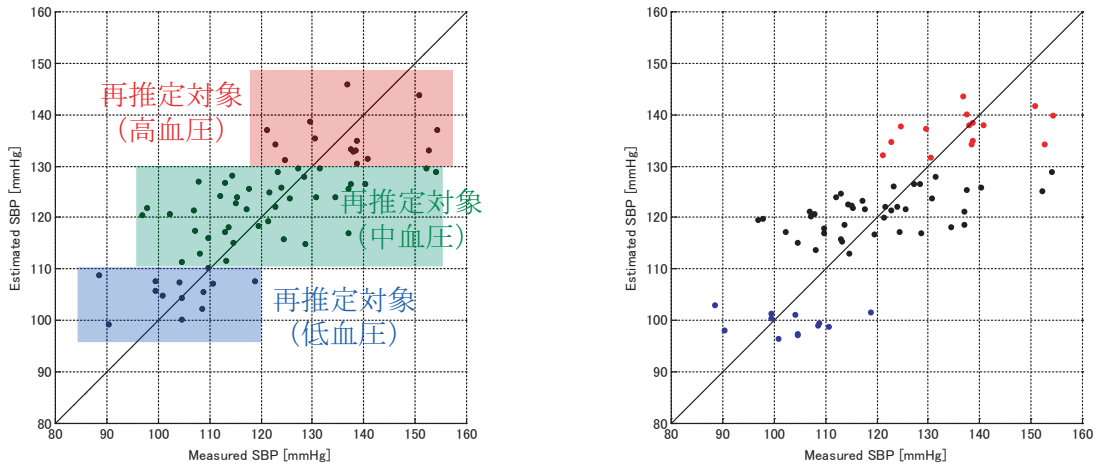


図 5.37: 非線形重回帰分析を補正学習した結果
(左図: 従来手法による結果 右図: 補正学習アルゴリズム 2 による結果)

表 5.10: 補正学習アルゴリズム 2 による推定結果

アルゴリズム		R	SD
SVR	補正学習なし	0.7841	9.9935
	補正学習あり	0.7946	9.6682

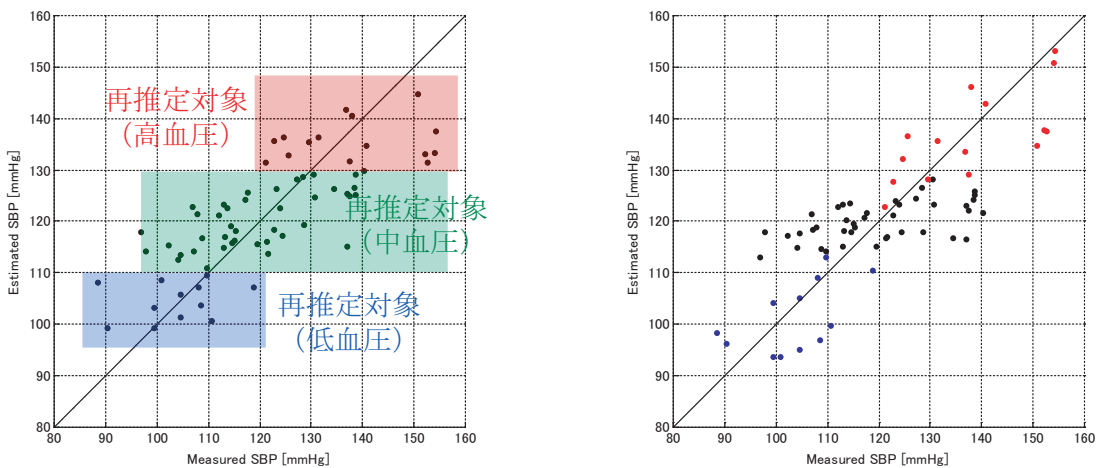


図 5.38: SVR を補正学習した結果
(左図: 従来手法による結果 右図: 補正学習アルゴリズム 2 による結果)

5.3.2 学習の信頼度に基づくデータ選別

外れ値除外による推定精度向上

以上では様々な推定手法について述べてきたが、いずれの手法も全ての識別データに対して推定を行ってきた。しかし実験で取得したデータの全てが理想的なデータとは限らず、脈波取得中におけるセンサの位置ずれ、カフにより取得した血圧値の計測誤差等により、理想値から外れる場合がある。図 5.39 の左図は SVR を用いて血圧値を推定した結果であるが、この分布中のデータには学習機が不完全なために識別が適切に行われなかったデータもあれば、実験で取得した計測値が理想値から外れたために学習機が識別できなかったデータも存在する。仮に外れ値を「推定値と実測値の差の絶対値が 10mmHg 以上」と定義し、外れ値を除外した場合の推定結果が図 5.39 の右図になる。除外前の SD が 9.9935 であったことに対し、除外することで SD が 7.5663 となり、推定精度が向上している（表 5.11）。

ここでは推定精度悪化の要因となる外れ値を機械学習により除去する手法について述べる。

表 5.11: 外れ値を人工的に取り除いた場合の推定結果

アルゴリズム		R	SD
SVR	外れ値除去前	0.7841	9.9935
	外れ値除去後	0.8197	7.5663

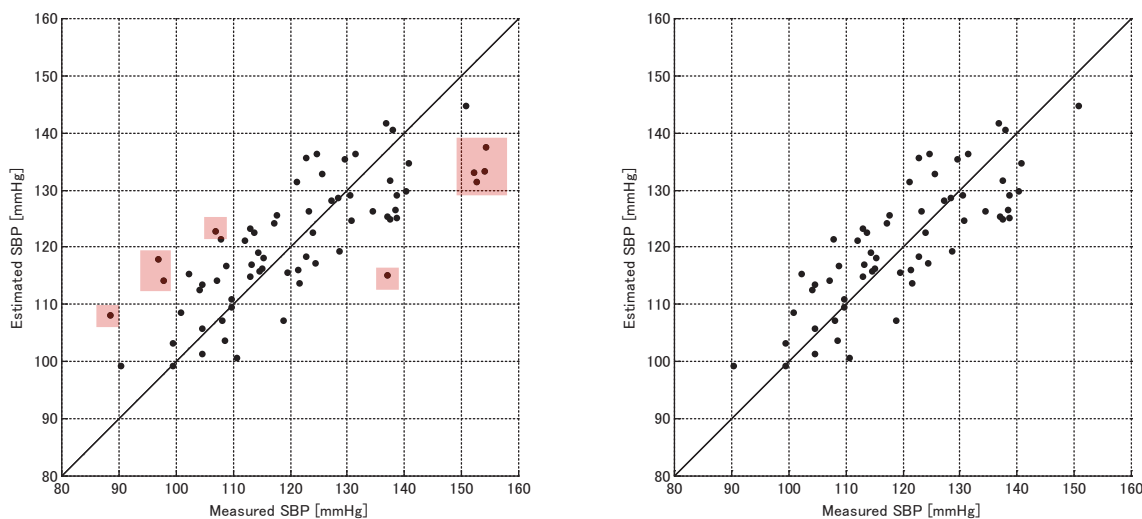


図 5.39: 外れ値を人工的に取り除いた場合の推定結果（左図は通常の SVR による推定結果であり、赤枠で示したデータが外れ値。右図は外れ値を除去した後の結果。）

特徴量の逆推定による外れ値除去手法

重回帰分析を用いてある説明変数 x から目的変数 y を求める場合、式 5.8 の重回帰式を解くことになる。

$$y = ax + b \quad (5.8)$$

式 5.8 中の a は回帰係数, b は定数項である. 式 5.8 の重回帰式は, 説明変数 x と目的変数 y の相関性が高い場合に精度のよい解を得ることができる. 血圧推定に置き換えて言えば, 脈波特徴量 (= 説明変数) と実測血圧値 (= 目的変数) に相関性が高い場合に精度のよい推定を行うことができる. 説明変数 x と目的変数 y の相関性を評価することができれば, 相関性が低い場合に外れ値として扱い, 推定結果から除去することが可能となる.

説明変数 x と目的変数 y に相関性がある場合, 式 5.9 の様に説明変数 x と目的変数 y を入れ替えても回帰式が成立する.

$$x' = a'y + b' \quad (5.9)$$

式 5.9 では式 5.8 において目的変数としていた y を説明変数としている. この回帰式から求められる目的変数は x' である. この様に, 目的変数を用いて説明変数を推定することを「逆推定」と呼ぶことにする. x と y の相関性が高ければ, 逆推定によって求められる目的変数 x' と元の推定式内の目的変数 x が近い値となると考えられる.

図 5.40 に特徴量逆推定の概略図を示す. 脈波特徴量 x から血圧値 y を推定し, 推定値 y から特徴量 x' を推定する. x と x' の値が離れていた場合に x と y の相関性が低いと判断し, y を外れ値として推定から除外する.




図 5.40: 特徴量逆推定の概略図

実際の脈波特徴量は多次元であるため, 多次元特徴量に対する逆推定の手法を述べる. 多次元特徴量を説明変数 x_i として, 目的変数 y の推定式が式 5.10 となり, 逆推定式が式 5.11 となる.

$$y = a_1x_1 + a_2x_2 + \cdots a_nx_n + b \quad (5.10)$$

$$x'_1 = a'_1y + a'_1x_1 + \cdots a'_nx_n + b' \quad (5.11)$$

$$x'_2 = a''_1x_1 + a''_2y + \cdots a''_nx_n + b''$$

⋮

$$x'_n = a'^{\cdots n}_1x_1 + a'^{\cdots n}_2x_2 + \cdots a'^{\cdots n}_ny + b'^{\cdots n}$$

ここで, n は次元数 (特徴量の数) である. n 個の逆推定結果から信頼度 α を求める.

$$\lambda = \sum_{i=1}^n \frac{|x_i - x'_i|}{k} \quad (k = \max|x_i - x'_i|) \quad (5.12)$$

$$\alpha = \frac{\lambda}{n} \quad (5.13)$$

α が閾値未満の場合は信頼度が低いと判断し、外れ値として推定結果から除外する。 α が閾値以上であれば信頼度が高いとし、推定結果から除外をしない。

この逆推定手法を血圧値推定に適用した結果を次項に述べる。

外れ値除去手法の適用結果

最も推定精度がよい補正学習アルゴリズム 1 による推定結果に対して外れ値除去手法を適用した結果を示す。 α の閾値の大小によって外れ値とされるデータが変わるため、閾値の最適化を行った (図 5.41)。この信頼度閾値は 1 が最大値であり、データを 1 つも除外しない状態である。信頼度閾値を 1 から小さくすることで除外される被験者が増え、それに伴い SD も小さくなり、 $\alpha = 0.43$ で SD は 7.5749 で最小値となった (表 5.12)。さらに信頼度閾値を小さくすると信頼度が高い被験者も除外され、SD が悪化する結果となった。

図 5.42 は SD が最も低くなった際の分布である。赤点が除外されたデータであり、黒点は除外されなかったデータである。この分布より、血圧値 120mmHg 前後の中血圧データに対しては比較的除外が適切に行われていることが見て取れる。しかし高血圧データについては、推定が適切にできているデータに対しても除外されており、適切な除外が行われない結果となった。これは中血圧のデータ数が多く、中血圧に最適化された除外が行われたためだと考えられる。




図 5.41: 信頼度 α の最適化

表 5.12: 外れ値除外手法の適用結果

アルゴリズム	R	SD
外れ値除外なし	0.8240	9.0265
外れ値除外あり	0.8507	7.5749

※「外れ値除外なし」は表 5.8 の結果を記載




図 5.42: 外れ値除外手法の適用結果

第6章 結論

本研究ではドライバーモニタリング技術の向上を目指して、運転中に取得された生体信号からドライバーの運転状態をモニタする研究を行った。交通死亡事故原因の第一位である「漫然運転」と第二位の「運転操作不適」に焦点を当て、各々の状態のモニタを行った。運転操作不適は「停止行動の遅れ」や「急加速」といった不適切な運転行動によるものであるため、本研究では車両速度およびペダル操作量から運転行動モデルを構築し、そのモデルを用いた運転行動予測を行った。また漫然運転については「認知行動の遅れ」の原因となる Cognitive Distraction の検知を行った。さらに、疲労やストレスの原因となる血圧を簡易に測定できる脈波から推定する研究についても実施した。

ドライバー行動予測研究では、AR-HMM を用いて運転行動モデルを構築し、モデルに基づいた停止行動予測を行った。モデル構築を行うために、ドライビングシミュレータを用いた実験から車両速度とペダル操作量データを取得した。モデル構築の際には、過去の行動の流れを考慮するといった観点から、過去の運転行動を表す Current Driving Trigger (CDT) の遷移を AR-HMM によって記述した。構築したモデルを用いた運転行動のシミュレーションに基づいて停止確率予測を行った結果、直前の行動のみを考慮する従来手法よりも高精度で予測が行えることが示され、さらに考慮する過去の運転行動の時間長（最適 CDT 長）が予測精度に影響することが判明した。また、停止予測を行うための最適 CDT 長は平均ブレーキ操作量との関連性が確認できたことから、運転傾向に応じて最適 CDT 長を設定することは個人適合化に大きく影響することが明らかとなった。今後の展開として、本研究で構築した運転行動モデルと既存の安全技術との融合が考えられ、カメラやレーダーといったセンサ情報のみならず、ドライバーの行動意図を汲んだ上で動作する安全支援システムの開発が期待される。

Cognitive Distraction 検知研究では、被験者に認知的負荷を与えるサブタスクとして暗算タスクおよび会話タスクを与え、Cognitive Distraction 模擬実験を行った。実験では検知に用いる生体情報として、視覚情報と心電図を取得した。視覚情報については、サブタスク運転時において視線角度および頭部回転角度の標準偏差が減少、瞳孔径の拡大が見られた。心電図から算出された RRI の平均値は、サブタスク運転時において減少傾向であった。これらの変化を定量的に捉え、さらにドライバーの Cognitive Distraction を検知するために、パターン認識手法に代表される SVM と AdaBoost による学習および識別を行った。SVM, AdaBoost 共に識別率は F 値において 90%以上の精度を得ることができたが、アルゴリズム間での差は僅差であった。これは両アルゴリズムが最少マージンの最大化を目的とした学習プロセスに基づくためであり、本質的な差がないことに起因すると考えられる。しかし、SVM は内積計算を含むため、特徴量増加に伴い計算量が増大するという大きな欠点がある。よって特徴量増加による更なる検知精度向上を図る場合には、計算量の少ない AdaBoost が優位になると考えられる。今後の課題として、本研究で行った

Cognitive Distraction 検知を発展させ、ドライバーの負担度別に検知することが考えられる。これにより、ドライバーの精神負荷レベルに基づいた安全支援システムの構築が可能となり、交通事故低減の促進に繋がると考える。

二値判別による Cognitive Distraction 検知に加えて、本研究ではドライバーに対する精神的負担度を検知する手法を考案した。ドライバーの視覚情報および生体情報を特徴量として、パターン認識によるドライバーの負担度を考慮した Cognitive Distraction 検知を行った。パターン認識手法としては多値判別が行え、かつ計算コストの少ない ECOC 法を採用した。ハミング距離を用いる HD-ECOC と、損失関数に基づく LD-ECOC 双方の手法による Cognitive Distraction 検知を行ったところ、LD-ECOC を用いることにより最高で 95.76% の検知精度を得ることができた。本研究では実験で取得した全ての特徴量を用いることで最も良い検知精度を得ることができたが、検知の際に全ての特徴量を用いると計算コストが増大し、車載環境におけるリアルタイム検知が困難になることが懸念される。計算コストと検知精度はトレードオフの関係にあるため、実用システム構築の際には双方の要因を考慮した上で、最適な特徴量の組み合わせを求める必要がある。

脈波からの血圧値推定に関する研究では、単一の光電容積脈波信号から血圧と相関があるパラメータを抽出し、血圧値を推定する手法を提案した。従来研究の推定には線形的手法が用いられていたため、特徴量の非線形性に対応できない欠点があった。本論文では非線形に変化する特徴量に対応可能な非線形重回帰分析と SVR の両手法を用いて推定を行った。その結果、従来の線形手法と比較して良好な推定精度を得ることができた。特に SVR においてはパラメータの最適化によりロバスト性の向上や過学習の抑制を行うことができた。そのため、データのばらつきが大きい脈波特徴量を用いた血圧値推定への対応性が高く、最も高精度な推定が行えたと考えられる。

血圧推定の更なる高精度化を目指し、拡張手法である補正学習を提案した。推定精度が比較的悪い低血圧と高血圧データに対して再学習を行うことで、推定精度を向上させることができた。また、精度悪化の要因となる外れ値を除外する方法についても提案し、推定精度を更に向上させることができた。提案した全てのアルゴリズムを組み合わせることで推定精度は $SD=7.5749\text{mmHg}$ となり、JIS 規格である 8mmHg 未満を達成することができた。

本論文にて提案した学習方法により JIS 規格を達成することができたが、全ての被験者に対して十分な推定が行われた訳ではない。あらゆる被験者に対して汎化性を有した更なるロバスト性向上が今後の課題である。

謝辞

本研究を進めるにあたり御指導を頂き、また研究以外においても多大な御支援を賜った小栗宏次教授に心から御礼を申し上げます。本研究に関する的確な助言と御支援を頂いた河中治樹准教授，入部百合絵講師に厚く御礼申し上げます。

ドライバー行動予測研究を行う際に必要となる機材の提供や，研究に関する有益な助言を頂いた(株)東海理化電機製作所 開発部 メカトロニクス開発室室長 宮武秀樹様，阿部喜様に深く感謝致します。また，研究の礎を築いてくださった林克樹氏，石川健氏に深く御礼申し上げます。

Cognitive Distraction 検知研究に必要な計測機器の提供，多くの有用な資料，多大な御協力を頂いた宮治正廣様，段野幹男様に深く感謝の意を表します。また，研究の基礎を作り，データ取得および解析手法確立に多くの時間を割いて頂いた長瀬敦嗣氏に心より感謝致します。

血圧推定研究を遂行する上で数多くのデータをご提供頂き，また的確な助言を頂きました(株)デンソー 河内泰司様，二ツ山幸樹様に深く感謝申し上げます。また，解析データの計測に膨大な時間を割いて頂きました小栗研究室のメンバーに大変感謝致します。

研究を遂行する上で必要となる能力を培うために，多くの御指導と御支援を頂いた木川泰氏をはじめとする小栗研究室の諸先輩方に深く感謝申し上げます。

多忙な中，本研究のために貴重な時間をさいて頂き，多くのアドバイスをくださった小栗研究室の全てのメンバーに心から感謝致します。

最後に，愛知県立大学，大学院にて学ぶ期間支えてくれた両親，妻に心より感謝の念を表します。

参考文献

- [1] 官民 ITS 構想・ロードマップ 2016
http://www.kantei.go.jp/jp/singi/it2/kettei/pdf/20160520/2016_roadmap.pdf
- [2] 景山 一郎 他, "高度運転支援システムに向けたドライバモデル構築に関する研究", 自動車技術会秋季大会学術講演会前刷集, 2015
- [3] 星野 隆允, 景山 一郎, "長時間運転時の人間の疲労評価に関する研究", 自動車技術会春季大会学術講演会前刷集, 2016
- [4] Peng Liu, Arda Kurt, and Umit Ozguner, "Trajectory Prediction of a Lane Changing Vehicle Based on Driver Behavior Estimation and Classification", IEEE ITSC, 2014
- [5] A. Pentlad, A. Liu, "Modeling and Prediction of Human Behavior", Neural Computation 11, 229-242, 1999
- [6] T. Kumagai, M. Akamatsu, Prediction of human driving behavior using dynamic Bayesian networks, IEICE Trans. Inf. & Syst. , E89D-2, pp.857-860 2006.
- [7] T. Kumagai, Y. Sakaguchi, Masayuki Okuwa, Motoyuki Akamatsu, "Prediction of Driving Behavior through Probabilistic Inference ", Proc. of 8th Intl. Conf. Engineering Applications of Neural Net works, Malaga, Sep. 2003.
- [8] 阿部喜, 宮武秀樹, 小栗宏次, "心拍変動を用いた運転行動モデルの切換による運転行動予測", 電子情報通信学会論文誌 A Vol.J91-A No.1 pp.78-86 2007.
- [9] 阿部 喜, 宮武 秀樹, 小栗 宏次, "自動車運転時の急ぎ心理状態が自律神経活動指標及び AR-HMM 運転行動モデルに与える影響", 信学技報, Vol.106, No.181, pp.7-12, July. 2006.
- [10] 坂口靖雄, 赤松幹之, "ドライバの運転行動計測とベイジアンネットを用いた行動解析", ベイジアンネットセミナー BN2002, 人工知能学会人工知能基礎論研究会, pp. 59-61, 2002
- [11] N. Oliver and A. Pentland, "Graphical Models for Driver Behavior Recognition in a SmartCar", Proc. IEEE Intelligent Vehicles Symposium, pp 7-12, 2000
- [12] 宇津木明男, 加藤晋, 赤松幹之, "長距離運転行動データベースに基づく運転行動のモデル化", 計測自動制御学会 システム情報部門学術講演会, 2005

- [13] Rakotonirainy Andry, Maire Frederic, "Context-aware driving behavioural model", Proc. 19th International Technical Conference on the Enhanced Safety of Vehicles ESV'19, Washington DC, 2005
- [14] 鈴木 達也, 井村 順一, "ハイブリッドシステムとして捉える人間行動モデル", 計測と制御, Vol.45, No.12, pp.1055-1061, 2006
- [15] 秋田敏和, 稲垣伸吉, 鈴木達也 (名古屋大), 早川聡一郎, 土田縫夫, "モード分割とその遷移による前方車追従行動のモデル化", ロボティクス・メカトロニクス講演会 2007, 1A2-E09, May 10-12, 2007
- [16] 警察庁 平成 27 年中の交通事故死者数について
https://www.npa.go.jp/pressrelease/2016/01/20160106_01.html
- [17] 国土交通省道路局ホームページ
<http://www.nilim.go.jp/japanese/its/0frame/under/02ahs/index02.htm>
- [18] 宮治 正廣, 段野 幹男, 小栗 宏次, "交通事故防止のためのヒヤリハット事例の統計分析によるドライバー特性の解析", 第 6 回 ITS シンポジウム, 2007
- [19] Kutila, M, "Methods for Machine Vision Based Driver Monitoring Applications", VTT Publications (2006)
- [20] Kutila, M., Jokela, M., Markkula, G., et al., "DRIVER DISTRACTION DETECTION WITH A CAMERA VISION SYSTEM", Proc. IEEE Internatinal Conference on Image Processing 2007
- [21] Jokela, M, Visa, A, Kutila, M., "Implementation and Analysis of the Cockpit ActivityAssessment Module", 2006
- [22] 小野 晶子, 田中 栄一, 宮崎 健二郎, "乱暴な運転が血圧, 脈拍に及ぼす影響", 交通科学研究資料 42, 65-68, 2001-05-21
- [23] 小澤利男, "新しい血圧測定と脈波解析マニュアル", 2008.
- [24] 藤本浩一, 佐野裕司, 渡邊英一, "脈波伝搬速度計測における加速度脈波の応用", 人間工学 48(6), 285-294, 2012
- [25] Javier Espina, Thomas Falck, Jens Muehlsteff, and Xavier Aubert, "Wireless Body Sensor Network for", Proc. 3rd IEEE-EMBS ISSS, pp.11-15, 2006
- [26] H. Sheng, M. Schwarz, J. Boercsoek, "A wireless wearable body sensor network for continuous noninvasive blood pressure monitoring using multiple parameters", Proc. CSCC'11, pp.308-314, 2011
- [27] 鈴木里実, 小栗宏次, "高齢者の心血管特性を考慮したクラス分類による光電脈波信号を用いたカフレス血圧推定", 電学論 (C) , vol.130, no.2, pp.261-266, Feb. 2010

- [28] Sakanashi A, Hasegawa M, Ushiyama Y, "Pressure Pulse Wave for Blood Flow in the Aorta from the Viewpoint of the Nonlinear Toda Lattice", Physics Letters A, Vol.221, 1996, pp.395-399
- [29] 自動車技術会 編, "自動車技術ハンドブック 環境・安全編", 2005
- [30] 内閣府, 第8次交通安全基本計画
<http://www8.cao.go.jp/koutu/kihon/keikaku8>
- [31] VICS ホームページ
<http://www.vics.or.jp/vics/structure.html>
- [32] 2007年 米国事故統計, USDOT HS 811 017
<http://www-nrd.nhtsa.dot.gov/Pubs/811017.PDF>
- [33] 欧州事故統計, <http://www.erso.eu>
- [34] 独立行政法人 日本高速道路保有・債務返済機構, "EU 交通白書 (2011年)"
- [35] 日本自動車研究所, "ITS 協調システムの情報項目の標準化に関する分析・検証 報告書", 2014
- [36] SENSATION Project
<http://www.sensation-eu.org/index.html>
- [37] 安土光男, "心拍変動解析による緊張・眠気・疲労度のリアルタイムモニタ", 自動車技術会秋季大会学術講演会前刷集, 2015
- [38] Martin Golz, "Detection of Microsleep Events -Data Recustion or Data Fusion?", SENSATION 2nd International Conference, Greece, 2007
- [39] Goran Kecklundm, "Observer rating scale of sleepiness", SENSATION 2nd International Conference, Greece, 2007
- [40] Roman Rosipal, "Probabilistic framework for EEG-based drowsiness and vigilance monitoring", SENSATION 2nd International Conference, Greece, 2007
- [41] Shuyan Hu, "Prediction of driver fatigue from physiological signals by SVM", SENSATION 2nd International Conference, Greece, 2007
- [42] Akerstedt T., Gillberg M., "Subjective and objective sleepiness in the active individual", Int J Neurosci, 1990
- [43] Jussi Virkkala, "Automatic estimation of wakefulness and sleep using electro-oculography", SENSATION 2nd International Conference, Greece, 2007
- [44] 柳平 雅俊, 安土 光男, "運転状態推定技術の開発", PIONEERR & Dvol.13, 2004
- [45] 奥島 美帆, "ドライバの覚醒度検出手法の研究", 自動車技術会秋季学術講演会, 2004

- [46] 沼田 仲穂, "自動車運転時の眠気の予測手法についての研究", 日本機械学会論文集, 1997
- [47] EU-FP6-AIDE Project
<http://www.aide-eu.org/objectives.html>
- [48] 萩原 亨 他, "ディストラクションを受けているときのドライバのリスクマネジメントに関する研究", 自動車技術会春季学術講演会, 2016
- [49] Takatsugu Hirayama et al., "Analysis of Peripheral Vehicular Behavior in Driver's Gaze Transition: Differences between Driver's Neutral and Cognitive Distraction States", IEEE ITSC, 2014
- [50] 秋山 知範, 稲垣 敏之, "視点移動の解析によるドライバの漫然運転検出", ヒューマンインタフェースシンポジウム, 2005
- [51] 伊藤 誠, 稲垣 敏之, "運転に対する注意低下の検出のためのセンサヒュージョンアプローチ", 自動車技術会春季大会学術講演会前刷集, 2006
- [52] Sternberg, S., "High-speed scanning in human memory", Science, No.153, pp.654-654, 1966
- [53] Victor, W. T., Harbluk, L. J. and Engstrom, J., "Sensitivity of Eye-movement Measures to In-vehicle Task Difficulty", Transportation Research part F, Vol.8, pp.167-190, 2005
- [54] Engstrom, J., Johansson, E., Ostlund, J., "Effects of Visual and Cognitive Load in Real and Simulated Motorway Driving", Transportation Research part F, Vol.8, pp.97-120, 2005
- [55] K. P. Murphy, "Dynamic Bayesian Networks: Representation, Inference and Learning", Ph.D. Dissertation, U. C. Berkley, Dept. Comp. Sci, 2002
- [56] 木川 泰, 小栗 宏次, "SVMを用いた長時間心電図における高精度 R 波検出フィルタ", 電子情報通信学会論文誌 D Vol.J89-D No.6 pp.1440-1448, 2006
- [57] V. Bapkin, "The Nature of Statistical Learning Theory", Springer, New York, 2000
- [58] H.Byun and S.-W.Lee, "Applications of Support Vector Machines for Pattern Recognition: A Survey", First International Workshop, SVM 2002, LNCS 2388, pp.213-236, 2002
- [59] A. Kitamoto, "Typhoon analysis and data mining with kernel methods", First International Workshop, SVM 2002, LNCS 2388, pp.237-248, 2002
- [60] K.I. Kim, K. Jung, and J.H. Kim, "Color Texture-Based Object Detection: An Application to License Plate Localization", First International Workshop, SVM 2002, LNCS 2388, pp.293-309, 2002

- [61] K. Shin, K.J. Lee, and H. Kim, "Support vector machines approach to pattern detection in bankruptcy prediction and its contingency", ICONIP 2004, LNCS 3316, pp.1254-1259, 2004
- [62] Freund, Y. and Schapire R. E. : A decision - Theoretic Generalization of On-line Learning and an Application to Boosting, Computational Learning Theory : Eurocolt, pp.23-37 (1995)
- [63] 松田 博義, 滝口 哲也, 有木 康雄, "弱識別器に SVM を用いた AdaBoost の検討", 信学技報, Vol.107, No.406(20071213) pp. 109-114, 2007
- [64] Freund Y, Schapire R., "Game theory, on-line prediction and boosting", In Proc. 9th ann. Conf. on Comp. Learning Theory, pp. 325-332, 1996
- [65] J. Friedman, T. Hastie and RJ Tibshirani, "Additive logistic regression: a statistical view of boosting", Annals of Statistics, 2: 337-374, 2000
- [66] Vezhnevets A., Vezhnevets V., "Modest AdaBoost- teaching AdaBoost to generalize better", Graphicon, 2005
- [67] E. Hartmann, "Driver Vision requirements", Institut fur med. Optik de Universitat munchen, Deutschland, SAE 700392
- [68] 乾 敏郎 著 : 視覚情報処理の基礎, サイエンス社 (1990)
- [69] 福田 忠彦 著 : 生体情報システム論, 産業図書 (1995)
- [70] Lowenstein O, Lowenfeld IE. The pupil. In: Davson H, ed. The Eye. New York: Academic Press; pp.255-337, 1969
- [71] 平田 豊, 山地 一禎, 堺 浩之, 白井 支朗, "視覚における瞳孔の機能と網膜像の情報量", 電子情報通信学会論文誌, Vol.J85-D2 No.4 pp.659-667, 2004
- [72] 堺 浩之, 観音 隆幸, 平田 豊, 白井 支朗, "眼屈折状態が輝度-瞳孔径関係に与える影響", 電子情報通信学会論文誌, Vol.J86-D2 No.7 pp.1123-1130, 2003
- [73] 中山 実, 安池 一貴, 清水 康敬, "瞳孔面積変化からの輝度による変化の分離と提示パターンの評価", 日本教育工学雑誌, Vol.15, No.1 pp. 15-23, 1991
- [74] 中山 実, 前迫 孝憲, 清水 康敬, "音声による課題を与えた時の瞳孔面積変化", 科学教育研究, Vol.12, No.3 pp. 90-97, 1988
- [75] 春日 伸予, 若生 純平, 澤田 東一, "飲酒運転による視線の動向に関する研究", 自動車技術会 学術講演会前刷集 No.151-08, 2008
- [76] 佐藤 忠一編著, "ME のあゆみシリーズ ホルター心電図システム", メディカルエレクトロタイムス, 1994
- [77] 久保田 博南著, "バイタルサインモニタ入門", 秀潤社, 2000

- [78] 松永 勝也, "瞳孔運動の心理学", ナカニシヤ出版, 1990
- [79] SeeingMachines
<http://www.seeingmachines.com/>
- [80] 浅野 陽一, 内田 信行, 橋本 健志郎, "注視点計測による対話負荷の定量化に関する研究", 自動車技術会前刷集, No.84-02, pp.13-16, 2002
- [81] 辻田 哲平, 近野 敦, 内山 勝, "パラレルリンク機構を用いた両眼視覚システムの開発", 計測自動制御学会東北支部第 206 回研究集会資料, (2002/12/10)
- [82] 情報通信研究機構
http://www.nict.go.jp/publication/CRL_News/back_number/217/217.htm
- [83] 荒川 俊也, 松尾 典義, 木下 昌裕, "視線挙動にもとづくドライバ漫然運転評価の試み", 自動車技術会前刷集, No.10-05, pp.5-8, 2005
- [84] 永岑 光恵, 室田 真男, 石井 源信, 清水 康敬, "繰り返しの暗算課題遂行における緊張感と心拍数の変化", 日本教育工学会論文誌, No.25, No.4, pp.237-245, 2002
- [85] 田場 信裕, 高良 富夫, 星野 聖, "ストレス負荷時の心拍数と瞳孔反応", 信学技報, Vol.96, No.26, pp.75-79, 1996
- [86] 飯田 健夫, 伊藤 孝幸, "自動車運転時における視覚特性への思考負荷の影響-眼球運動と反応時間による検証-", 交通科学, Vol.28, No.1 No.2 合併号 pp.60-65, 1998)
- [87] Johan Engstrom, "Direct metrics of driver performance", Driver Metrics Workshop, Driver Metrics Workshop
- [88] Maria Rimini-Doering, Dietrich Manstetten, "MONITORING DRIVER DROWSINESS AND STRESS IN A DRIVING SIMULATOR", DRIVER ASSESSMENT, 2001
- [89] SVMlightSupport Vector Machine
<http://svmlight.joachims.org/>
- [90] Graphics & Media Lab Projects - Modest Adaboost
<http://graphics.cs.msu.ru/en/research/boosting/index.html>
- [91] 工藤 拓, 松本 裕治, "部分木を素性とする Decision Stumps と Boosting Algorithm の適用", 情報処理学会自然言語処理研究会, SIGNAL-158, 2003
- [92] 野間 健一, 中井 満, 下平 博, 嵯峨山 茂樹, "非線形時間伸縮を用いた Support Vector Machine による時系列パターンの認識", 信学技報, Vol.100, No.507, pp. 63-68, 2000
- [93] 上甲 信悟, 上野 敦志, 辰巳 昭治, "サポートベクターマシンの高速化に関する研究", 電子情報通信学会総合大会講演論文集, D-12-99, 2005

- [94] Bredensteiner, E. J. and K. P. Bennett, "Multicategory classification by support vector machines" Computational Optimization and Applications, vol. 12, pp. 53-79, 1999
- [95] 白石 友一, 福水 健次, "多値判別における 2 値判別機のゲーム理論的組合せ法", 電子情報通信学会論文誌 D Vol.J91-D No.6 pp.1528-1537, 2008
- [96] Chih-wei Hsu, Chih-jen Lin, "A Comparison of Methods for Multi-class Support Vector Machines", IEEE Trans. Neural Network, vol.13, pp.415-425, 2002
- [97] R. Rifkin and A. Klautau, "In Defense of One-Vs-All Classification", Journal of Machine. Learning Research , vol.5, pp.101-141, 2004
- [98] T. G. Dietterich and G. Bakiri, "Solving multiclass learning problems via error-correcting output codes", Journal of Artificial Intelligence Research, vol.2, pp.263-286, 1995
- [99] E. L. Allwein, R. E. Schapire, and Y. Singer, "Reducing multiclass to binary: A unifying approach for margin classifiers", Journal of Machine Learning Research, vol.1, pp.113-141, 2001
- [100] 梅原 崇一, 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", 電子情報学会論文誌, Vol.J86-D-II, No.7, pp.1090-1098, 2003
- [101] 日本高血圧学会, "高血圧治療ガイドライン 2014"
- [102] 桜井 靖久, 渡辺 敏, "ME 早わかり Q&A 3 血圧・心拍出量計・血流計", 南江堂, 1988
- [103] 久保田 博南, "医療機器—生い立ち・役目と働き・望まれる姿—", 真興交貿, 2010
- [104] Mikyoung Park, HeeJung Kang, Young Huh, Kyung-Chul Kim, "Cuffless and Non-invasive Tonometry Mean Arterial Pressure Measurement by Physiological Characteristics and Applied Pressure", IEEE-EMBS International Summer School and Symposium on Medical Devices and Biosensors, MIT, Boston, USA, Sept.4-6, 2006
- [105] 尾前照雄, "血圧の話", 岩波新書,1996
- [106] "治療の歴史血圧測定",
<http://www.lifescience.jp/ebm/medhist/0402/0402.htm>
- [107] "医療の歴史血圧測定の歴史",
<http://www.k2.dion.ne.jp/.drkimura/ketuatu>
- [108] Bevan AT, Honour AJ, Stott FH, Clin Sci, 36,663-8,1969
- [109] Hinman AT, Engel BT, Bickford AF, Am Heart J, 63,663-8,1962

- [110] 堀口雅美, 田中豪一, 村松健太, 加藤有一, 澤田幸展, ”青年の脈波伝播速度における性とBMI および血圧値との関係”, 札幌医科大学保健医療学部紀要,no.8,p.13-18,Dec.,2005
- [111] 田中秀司, 酒本勝之, 金井寛, ”拡張期血圧の無侵襲連続測定法の開発”, 医用電子と生体工学、22-2,pp.13-18,1984
- [112] 村原雄二, 藤井麻美子, 酒本勝之, 金井寛, ”ケプストラムによる血圧脈波の伝播時間の推定”, 電子情報通信学会誌,J80-D-II,pp.3077-3085,1997
- [113] 村原雄二, 酒本勝之, 金井寛, 荒井隆行, ”強制的下肢動脈血管閉塞による脈波伝播時間の測定法”, 医用電子と生体工学,39-1,pp.1-8,2001
- [114] 菅原基晃, 前田信治, ”血液のレオロジーと血流”, コロナ社,2003
- [115] W. Chen, T. Kobayashi, S. Ichikawa, Y. Takeuchi, T. Togawa, ”Continuous estimation of systolic blood pressure using the pulse arrival time and intermittent calibration”, Medical & Biological Engineering & Computing 2000, Vol.38. pp.569-574
- [116] Carmen C.Y. Poon, Yuan-Ting Zhang, ”Using the Changes in Hydrostatic Pressure and Pulse Transit time to Measure Arterial Blood Pressure”, FrP1C4.11, Proceedings of the 29th Annual International Conference of the IEEE EMBS Cite Internationale, Lyon, France, Aug.23-26, 2007
- [117] Yinbo Liu, Carmen C.Y., et al., ”A Hydrostatic Calibration Method for the Design of Wearable PAT-based Blood Pressure Monitoring Devices”, TheDPo07.10 30th Annual International IEEE EMBS Conference, Vancouver, British Columbia, Canada, Aug. 20-24, 2008
- [118] Yuan-ting Zhang, Carmen C.Y. Poon, Chun- hung Chan, Martin W.W. Tsang and Kin-fai Wu, ”A Health-Shirt using e-Textile Materials for the Continuous and Cuffless Monitoring of Arterial Blood Pressure”, IEEE-EMBS International Summer School and Symposium on Medical Devices and Biosensors, MIT, Boston, USA, Sept.4-6, 2006
- [119] Javier Espina, Thomas Falck, Jens Muehlste, and Xavier Aubert, ”Wireless Body Sensor Net-work for Continuous Cuff less Blood Pressure Monitoring”, IEEE-EMBS International Summer School and Symposium on Medical Devices and Biosensors, MIT, Boston, USA,Sept.4-6, 2006
- [120] 増田達哉, 吉澤誠ら, ”非侵襲小型連続血圧・心拍計測装置を用いた映像刺激の影響評価”, 計測自動制御学会東北支部第 201 回研究集会,2002
- [121] 増田善昭, ”動脈波の臨床”, 2003
- [122] Chlebus H, ”Value of examination of carotid pulse by means of resonance electrophygmographs in relation to intra-arterial pressure tracings”, Am Heart J 64, pp.245-250, 1962.

- [123] 佐野祐司, "加速度脈波による血液循環の評価とその応用"労働科学, vol.61, no.3, pp.129-143, 1985
- [124] Takazawa K, Tanaka N, Fujita M, Matsuoka O, Saiki T, Aikawa M, Tamura S, Ibukiyama C., "Assessment of Vasoactive Agents and Vascular Aging by the Second Derivative of Photoplethysmogram Waveform", Hypertension: Volume 32(2), pp.365-370, 1998
- [125] 安藤慎吾, 草地良規, 鈴木章, 荒川賢一, "サポートベクトル回帰を用いた三次元物体の姿勢推定法", 信学論 (D) , vol.J89-D, No.8, pp-1840-1847, 2006.
- [126] 田辺和俊, 栗田多喜夫, 西田健次, 鈴木孝弘, "サポートベクター回帰を用いた 158 カ国の国債価格付けの再現", 情報知識学会誌 23(1), pp70-91, 2013
- [127] N. Cristianini, J. Shawe-Taylor, "An Introduction to Support Vector Machines and Other Kernel-based Learning Methods", Cambridge University Press, 2000
- [128] 渡邊栄治, 尾関孝史, "複数の階層型ニューラルネットワークによる画像の雑音除去" 信学論 (D) , J93-D(3), pp.409-413, 2010

本研究における業績

学術論文

- 岸本圭史, 小栗宏次, “直前の一定期間の運転行動を考慮した AR-HMM に基づく停止行動予測”, 電子情報通信学会論文誌 A, Vol.J98-A, No.2, pp.200-208, 2009/1
- 岸本圭史, 河中治樹, 小栗宏次, “非線形回帰手法を用いた脈波信号解析によるカフレス血圧値推定”, 電子情報通信学会論文誌 A, Vol.J92-A, No.9, pp.624-632, 2015/2

国際会議（査読あり）

- Yoshifumi Kishimoto, Koji Oguri, ”A Modeling Method for Predicting Driving-Behavior Concerning with Driver’s Past Movements”, IEEE International Conference on Vehicular Electronics and Safety (ICVES 2008), pp.132-136, Columbus Ohio(USA), 2008/9
- Yoshifumi Kishimoto, Haruki Kawanaka, Koji Oguri, ”Cuffless Blood Pressure Estimation by Non-Linear Regression Analysis with Correction Learning”, 12th International Conference on Ubiquitous Healthcare, 4pages, Osaka(Japan), 2015/11

国内学会

- 岸本圭史, “非線形回帰手法を用いた脈波信号解析によるカフレス血圧値推定”, 第54回日本生体医工学会大会, 2015/5

特許

- Koji Oguri, Yoshifumi Kishimoto: State detecting device, state detecting method, and non-transitory computer-readable medium. Aisin Seiki May, 3 2012: US 20120105234