

# 修 士 論 文

## 運転状況を考慮した脇見状態推定手法

Detection of Inattentive Driving by Fusing  
Multiple Observation Cues



東京大学大学院  
情報理工学系研究科  
電子情報学専攻

66440

堀 口 研 一

指導教員

佐藤 洋一 准教授

平成20年2月

# 概要

本研究は、運転時の首振り動作を伴う脇見の高精度な検出手法の構築を目的とする。従来研究では、主にドライバーの顔向きから脇見の検出を試みるものが多い。しかし、顔向きのみを用いたアプローチでは、安全確認などの首振り動作を伴う運転動作が脇見として誤検出される可能性がある。このような問題に対処するために、我々はその時の顔向き以外にドライバーの運転動作情報と自車情報を用いて運転状況を考慮する脇見検出手法を提案する。ドライビングシミュレータを用いた実験により提案手法の有効性を確認した。

# 目次

<b>第1章</b>	<b>序論</b>	<b>1</b>
1.1	本研究の背景及び目的	1
1.2	本論文の構成	2
<b>第2章</b>	<b>関連研究</b>	<b>3</b>
2.1	脇見の検出に関する既存研究	3
2.1.1	顔向き角度を用いた脇見検出	3
2.1.2	顔向き以外の観測量を用いた脇見検出	6
2.2	脇見の分析研究	8
2.3	ドライバのモデル化	12
2.3.1	ドライバ状態のモデル化	13
2.3.2	ドライバ行動のモデル化	18
2.4	脇見行動及びドライバのモデル化の既存研究のまとめ	22
<b>第3章</b>	<b>提案手法概要</b>	<b>23</b>
3.1	Dynamic Bayesian Network を用いた脇見状態推定	23
3.2	遷移確率及び観測確率の学習方法	26
<b>第4章</b>	<b>データ取得</b>	<b>27</b>
4.1	実験システム概要	27
4.2	頭部姿勢情報取得	32
4.3	データ集約機構	34
<b>第5章</b>	<b>実験</b>	<b>36</b>
5.1	走行コース	36
5.2	脇見行動発生方法	37
5.3	脇見状態検出方法	38

5.4	推定結果に対する評価方法 . . . . .	39
5.4.1	受信者動作特性曲線 (ROC カーブ) . . . . .	39
5.4.2	精度 (precision) /再現率 (recall) /F 値 (F-measure) . . . . .	40
5.5	実験 1 : 提案手法の有効性検証 . . . . .	41
5.5.1	使用モデル説明 . . . . .	41
5.5.2	実験結果 . . . . .	42
5.5.3	考察 . . . . .	46
5.6	実験 2 : 視線方向情報の利用 . . . . .	51
5.6.1	使用モデル説明 . . . . .	51
5.6.2	実験結果 . . . . .	52
5.6.3	考察 . . . . .	54
5.7	実験 3 : ラベル付けを使用しない視線方向情報の利用 . . . . .	54
5.7.1	使用モデル説明 . . . . .	54
5.7.2	視線に関する学習方法 . . . . .	55
5.7.3	実験結果 . . . . .	58
5.7.4	考察 . . . . .	58
5.8	実験 4 : 安全確認状態の導入 . . . . .	64
5.8.1	実験 1 との違い . . . . .	64
5.8.2	実験結果 . . . . .	64
5.8.3	考察 . . . . .	68
<b>第 6 章</b>	<b>結論</b>	<b>70</b>
6.1	頭部姿勢及び運転操作情報や自車両状態情報を考慮した脇見状態推定	70
6.2	視線情報を加味した脇見状態推定 . . . . .	71
6.3	安全確認状態を加えた脇見状態推定 . . . . .	71
6.4	今後の課題 . . . . .	71
	謝辞	73
	参考文献	74
	発表文献	78

# 目次

2.1	実験環境	4
2.2	水平方向の顔及び目の動き	4
2.3	前方注視時の顔向き角度分布	5
2.4	前方外注視時の顔向き角度分布 (1)	5
2.5	前方外注視時の顔向き角度分布 (2)	5
2.6	ランダム森アルゴリズム概図	7
2.7	ドライバ脇見心理モデル	9
2.8	簡略化ドライバ脇見心理モデル	9
2.9	推定脇見時間	10
2.10	事故事例における推定脇見時間分布	10
2.11	脇見時間決定モデル	12
2.12	疲労度推定 Bayesian Network モデル	14
2.13	疲労度推定用 Action units	16
2.14	疲労度推定 DBN モデル	16
2.15	有限オートマトン	17
2.16	(a)Driving Simulator (b)simulated world	18
2.17	ドライバ行動の Markov dynamic Model	19
3.1	一般的な DBN モデル	24
4.1	Driving Simulator : 三菱プレシジョン製	27
4.2	DS における視界環境	28
4.3	実験システム概図	30
4.4	実際のシステム	31
4.5	イベント検証用カメラ撮影画像例	31
4.6	三次元頭部姿勢推定用カメラ	32
4.7	頭部姿勢追跡画像例	33
4.8	データ同期集約機構	34

5.1	DS 使用コース	36
5.2	ターゲット投影例	38
5.3	使用スピーカー	38
5.4	例：ROC カーブ	39
5.5	脇見推定 DBN モデル	42
5.6	実験結果例 1：被験者 0，(a) 東名大和サグコース	44
5.7	実験結果例 2：被験者 3，(a) 東名大和サグコース	44
5.8	従来手法との比較結果：(a) 東名大和サグコース，赤：従来手法，青： 提案手法	45
5.9	従来手法との比較結果：(b) 首都高速 3 号線コース，赤：従来手法，青： 提案手法	45
5.10	被験者 3：各走行時の TP,FP,FN	47
5.11	頭部ヨー角 [deg] の観測確率分布，青：通常状態，赤：脇見状態	48
5.12	アクセルペダル [%] の観測確率分布，青：通常状態，赤：脇見状態	49
5.13	ハンドル角速度 [deg/frame] の観測確率分布，青：通常状態，赤：脇 見状態	49
5.14	ウインカーの観測確率分布，青：通常状態，赤：脇見状態	50
5.15	脇見推定 DBN モデル：視線	51
5.16	視線方向定義	52
5.17	実験結果例 1：被験者 0	53
5.18	実験結果例 2：被験者 1	53
5.19	視線未使用/使用比較結果，赤：未使用，青：使用	53
5.20	脇見推定 DBN モデル：視線（ラベルなし）	55
5.21	$P(Z_t Y_t)$ 学習用データ例：前方及びバックミラー	56
5.22	視線方向学習データの度数分布グラフ	57
5.23	頭部ヨー角と視線方向の間の観測確率 $P(Z_t Y_t)$ の学習結果 赤： 前方，緑：バックミラー，青：左サイドミラー，紫：左窓方向，水色： 右サイドミラー，茶：右窓方向	59
5.24	実験結果例：被験者 0，(a) 東名大和サグ	60
5.25	視線未使用/使用比較結果，(a) 東名大和サグ，赤：未使用，青：使用	60
5.26	視線未使用/使用比較結果，(b) 首都高速 3 号線，赤：未使用，青：使用	61

5.27	視線方向と脇見状態の間の観測確率 $P(Y_t X_t)$ の学習結果，青：通常状態，赤：脇見状態，FWD：前方，BM：バックミラー，LSM：左サイドミラー，LW：左窓方向，RSM：右サイドミラー，RW：右窓方向	61
5.28	$P(Z_t Y_t)$ 及び脇見状態における頭部ヨー角の度数分布の比較，紫：左窓方向，茶：右窓方向	63
5.29	学習データの隠れ状態正解ラベル定義	65
5.30	安全確認状態未使用/使用比較結果，(a) 東名大和サグ，赤：未使用，青：使用	65
5.31	安全確認状態未使用/使用比較結果，(b) 首都高速3号線，赤：未使用，青：使用	66
5.32	実験結果例：被験者0	67
5.33	安全確認状態未使用/使用比較 (TP, FP, FN)	68
5.34	安全確認状態未使用/使用時の頭部ヨー角の観測確率比較，青：通常状態，赤：脇見状態，緑：安全確認状態	69

# 表目次

2.1	使用観測量	6
2.2	重要度評価結果	7
2.3	協見分析に利用した運動状態量	10
2.4	Fatigue index	13
2.5	利用観測量	15
2.6	Fig.2.13 における Action Units の定義	15
2.7	Fuzzy System に用いた入力状態量	18
2.8	SVM Feature Set	20
2.9	使用観測量	21
3.1	遷移行列の例	25
3.2	観測行列の例	25
4.1	DS から取得可能な観測量	29
5.1	各コース特徴比較	37
5.2	混同行列	40
5.3	使用する観測量一覧	42
5.4	被験者間比較結果	46

# 第1章 序論

## 1.1 本研究の背景及び目的

近年の交通事故データによると、原付以上運転者（第1当事者）の法令違反別の交通事故数における脇見による事故の割合は最近20年間以上徐々に増え続け近年では15%以上を占めている [30]。2004年の改正道路交通法による運転中のカーナビゲーションや携帯電話の注視の禁止等の影響のため脇見運転による事故数は近年停滞しているものの、種々のITS機器の普及によるドライバへの視覚的情報処理の負担が再び脇見運転による事故の増加につながる恐れもある。

脇見運転による事故の削減には様々な対策が検討されているが、風景等単調な道路を減らすといった脇見そのものを減らす対策のみならず、脇見を検出し適切に警告を行うことも重要である。

脇見の検出に関する既存の研究として、顔向きを用いた脇見検出手法が提案されている [33] [34]。これらは非接触・非侵略襲的であるビデオ画像から、Appearanceベースあるいは特徴ベースにより顔向きや視線方向を推定し脇見検出に用いている。しかし、これらの脇見検出手法では、運転状況を考慮せず顔の向きや視線方向のみに着目しており、運転操作に必要な顔向き変化と真の脇見（例えば、車線変更時の周囲確認と単なる風景の注視）の区別はなされていない。ドライバへの心理的付加を最小限に留めるためにも脇見の過大・過小検出を避けなければならず、そのためには運転操作や自車両状態情報などドライバの置かれた状況を考慮するが必要である。

一方、近年ITSの分野において、様々な観測量を用いてドライバの行動や状態をモデル化し認識する手法が研究されている。脇見行動もドライバのふるまいの一種であるとすれば、このモデル化のアプローチは脇見状態検出に対しても有効であると考えられる。

既存研究の主なモデル化対象には車線変更や停止などの運転動作 [12] [20] [21] や、ドライバの疲労度や集中度 [26] [4] などがある。これらのモデル化に対してよく用いられる手法には、Hidden Markov Model (HMM) [12] [20] [21] や Bayesian Network (BN) [26]、Dynamic Bayesian Network (DBN) [4] [13] などがあり、これらは前述

の行動群や様々なドライバ状態のモデル化において一定の成果を挙げている。

これらの手法は、観測情報と非観測情報との間に確率的な因果関係が存在するとし、それらを有向グラフを用いて記述する。従来研究ではHMMは時系列情報を扱うため、運転行動のモデル化に用いられてきた[12][20][21]。また、BNは複雑なネットワークポロジの記述性を有しているため、ドライバ状態の推定に用いられてきた[26]。しかしそのどちらも脇見のような複雑な要素の関係性と時系列情報の両方を表現するのに十分な記述性を有していない。これに対しDBNは、要素間の複雑な接続形態と時系列情報の両方を記述するのに十分な記述性を有している。

以上の背景を踏まえ、本研究では首振り動作の他に、ドライバの頭部姿勢や自転車両状態などの各種情報を考慮することで、首振り角度のみでは判定できないような場合においても脇見をより正確に検出することを目的とする。我々は、特に脇見に顕著な特徴である複雑な要素の関係性に着目し、この関係性を十分記述可能で、且つ時系列での観測情報を利用可能なモデルとしてDBNを用いて脇見状態の推定を行う。

## 1.2 本論文の構成

第2章では、脇見行動の検出や脇見行動の分析、またドライバの状態や行動のモデリング手法に関する関連研究について述べる。第3章では、提案手法の概要について述べる。第4章では、提案手法に必要なデータ取得方法について述べる。第5章では、提案手法の有効性の確認や手法の改良に対する評価実験の説明と結果について述べる。最後に第6章では提案手法に対するまとめと今後の課題について述べる。

## 第2章 関連研究

### 2.1 脇見の検出に関する既存研究

脇見検出に関する既存研究では、主にドライバの顔向き（頭部姿勢角）や視線方向を用いて前方不注視を検出し警告する手法が検討されている [33] [29] [34]。またこれら手法の基幹技術として、ドライバの顔向きの推定 [18] [19] や眼の検出/追跡 [15] [9]、視線方向の推定 [27] などの技術の研究も盛んに行われている。

#### 2.1.1 顔向き角度を用いた脇見検出

中越ら [33] は、視線方向よりも技術的課題の少ない顔向き（左右方向）による脇見検出の可能性を検討した。具体的には、

- (1) 注視点左右移動時の眼球運動と頭部回転運動（顔向き）の関係の分析
- (2) 前方不注視を推定する顔向き角度の検討

を行った。

注視点左右移動時の眼球運動と頭部回転運動（顔向き）の関係の分析での実験概要を Fig.2.1 に示す。被験者前方のスクリーン上に視対象をプロジェクタで投影し、正面から視対象に注視点を移すときの眼球運動と頭部の左右回転角度（顔向き角度）を測定した。眼球運動はアイマークレコーダを用い、顔向き角度は頭上のカメラで撮影した映像から被験者の頭部につけた指針の位置を読み取り算出した。注視対象は二桁の数字とし1秒おきにランダムに表示し、被験者には合図とともに正面から注視点を移して数字を読み上げまた正面に戻すという作業を行わせた。

被験者10名で行われた実験結果を Fig.2.2 に示す。この結果より、視対象物までの左右角度が20[deg]を超えると、顔向き角度が眼球運動を上回り、顔を動かす傾向が顕著になることがわかった。従来研究によると、市街地走行での前方注視時の注視点分布はほぼ20[deg]以内と報告されている [7]。従って市街地走行での注視点範

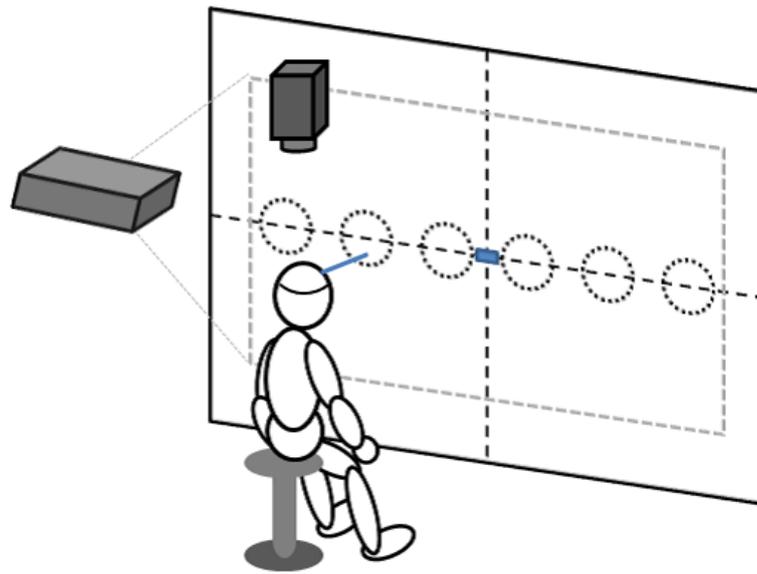


Fig. 2.1: 実験環境

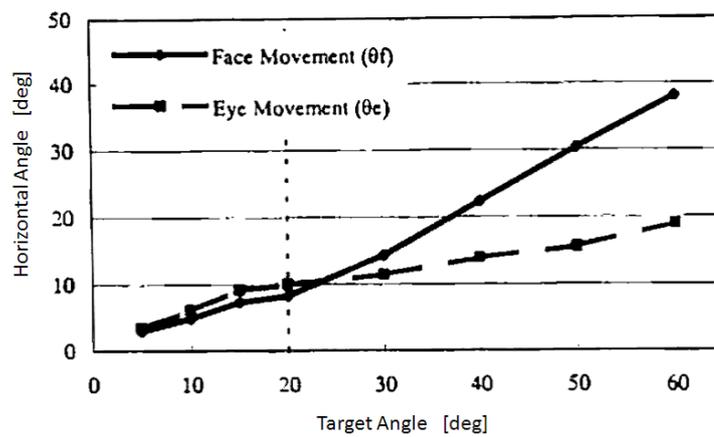


Fig. 2.2: 水平方向の顔及び目の動き

圏を超える注視点移動では顔の向きが顕著になり，顔向き角度に着してドライバの前方不注視を推定できる可能性を確認した。

次に中越らは，前方不注視を推定する顔向き角度の検討を行った．具体的には，視対象物として車載ディスプレイ上の地図，ルームミラー，左右サイドミラー，車両左右側方の景色を設定し，前方注視時並びに各視対象物注視時の顔向き角度の分布を被験者10名に対して測定した．実験では実車を用いて被験者に直線路を約50[km/h]で走行させ，顔向きはドライバの前方に設置したカメラで撮影した映像から算出した．

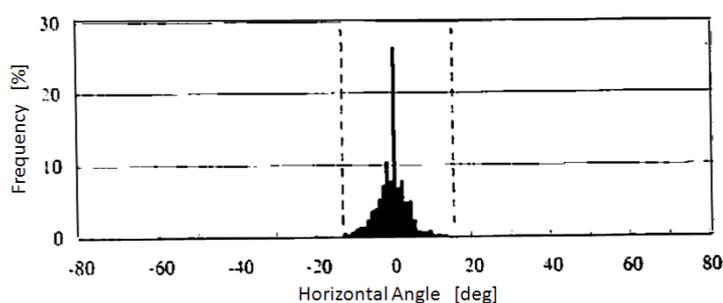


Fig. 2.3: 前方注視時の顔向き角度分布

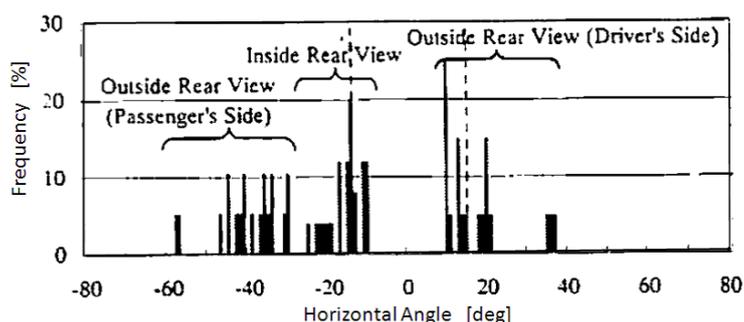


Fig. 2.4: 前方外注視時の顔向き角度分布 (1)

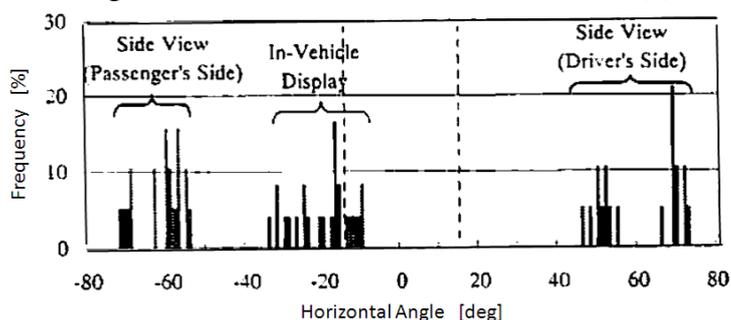


Fig. 2.5: 前方外注視時の顔向き角度分布 (2)

実験結果を Fig.2.3-Fig.2.5 に示す．実験結果では前方注視時の顔向きの99[%]以上が左右15[deg]以内に入っているのに対し，各視対象物注視時の顔向き角度は一部の視対象物では15[deg]を超えない場合もあるが，大半が15[deg]を超えていた．以上から中越らは，顔向き角度が15[deg]以上の時ドライバは前方不注視状態の可能性が高いとした．

しかし，中越らのアプローチは通常の運転に必要な安全確認などの動作に対しての考慮がなされていない．このように顔向き角度に対して一定の閾値を設け顔向きが閾値以上であれば脇見と推定する場合，頻繁に誤検出をする可能性が考えられる．

### 2.1.2 顔向き以外の観測量を用いた脇見検出

Kari Torkkola ら [25] は、ドライバの操作情報や自車両の状態から脇見行動の検出が可能かどうかを検討した。具体的には、被験者にドライビングシミュレータを運転させ、ミラーでは確認できない位置に提示されたターゲットを注視させることで擬似的に「死角注視行動」を発生させた。その時の各種観測量に対してランダム森 (Random Forest [2]) という手法を適用し、死角注視行動状態の予測分類器を作成した。観測に用いた状態量を Table.2.1 に示す。なお、実際に入力には Table.2.1 にある観測量を、一定フレーム数の平均や分散、一定フレーム間隔の差分、エントロピーや定常性などの状態量に変換したのちに用いた。

Table. 2.1: 使用観測量

変数	説明
steering Wheel	ハンドル角度
accelerator	アクセルペダルの位置
distToLeftLaneEdge	左側の車線の端から左前輪までの垂直距離
crossLaneVelocity	distToLeftLaneEdge の変化率
crossLaneAcceleration	crossLaneVelocity の変化率
steeringError	車線に対して平行に走行するための理想的なハンドル角度と現ハンドル角度との差分
aheadLaneBearing	車両前方 60[m] の道路の角度

ランダム森とは Breiman がにより提案された、ブートストラップというリサンプリングの方法でサブデータを作成し、それぞれのサブデータセットの決定木を組み合わせて予測分類器を構築する手法である。アルゴリズムの概要図を Fig.2.6 に示す。

この手法は決定木作成のアルゴリズムの中でも精度が高く、また観測量の種類が多い大きなデータに対しても効率的に作動することを特徴としている。これにより、各種観測量について様々な変換を加えた全状態量に対して最適な決定木を作成可能とした。

Kari Torkkola らはまず、ドライビングシミュレータを走行時のデータを元にランダム森を用いて予測分類器を作成し、脇見検出に有効な観測量の検討を行った。有効

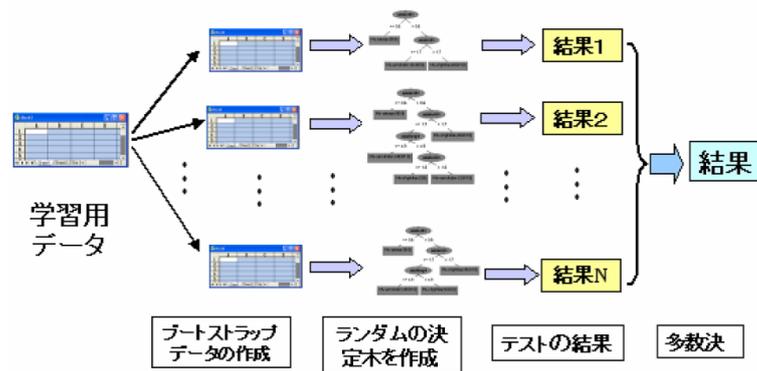


Fig. 2.6: ランダム森アルゴリズム概図

Table. 2.2: 重要度評価結果

変数	重要度
distToLeftLaneEdge	100
accelerator	87.99
steeringWheel_rv9	73.76
distToLeftLaneEdge_rv9	65.44
distToLeftLaneEdge_rd5_ra9	65.23

性の尺度は、まず各状態量ごとに単独で分類器に対する重要度を評価して重要度の低いものを省いた後、残った各状態量ごとの組み合わせを用いて相対的な重要度を算出することで評価された [11]。重要度の評価結果を Table.2.2 に示す。なお、Table.2.2 における”rv9”、”rd5”及び”ra9”はそれぞれ”過去9フレームのデータの分散”、”5フレーム前のデータとの差分”、”過去9フレームのデータの平均”を意味する。

この結果、車線の端との距離、アクセルペダルの位置、ハンドル角度などが脇見検出で有効であるとの知見が得られた。しかし、この研究ではドライバの頭部姿勢などの情報は脇見をしているかどうかのラベル付けのみに用いられており検出時の観測量としては用いられていない。また Kari Torkkola ら問題設定として、死角を見ようとする動作が脇見として分類しているがこれは安全確認を行った結果生じた動作なので、本質的な脇見を検出したとは言えない。

## 2.2 脇見の分析研究

脇見運転に関する研究には、脇見行動を単なる前方不注意とは別の観点から考察し、脇見に対する何らかの知見を得、そこから脇見運転の防止につながる技術を研究するアプローチもとられている。

田久保ら [35] は、交通事故に関連した状況下での運転行動の分析とモデル構築を目的とし、ドライバの脇見行動への判断に関する考察とモデルの検討を行った。

分析方法としてはまず、情報提供装置の一種であるカーナビゲーション装置への脇見による追突事故に関してドライバの脇見行動を分析し、その結果をもとに追従走行時の情報提供装置に対する脇見行動を模擬した走行実験をドライビングシミュレータを用いて実施し、脇見鼓動のモデル化を行った。この研究では、「脇見」を「運転中に車両進行方向の道路状況及び先行車以外の対象に注視点を移動させること」と定性的に定義した。

田久保らは、脇見行動を「脇見対象の発生」から脇見の「終了」/「中断」に至る一連の行動と考え、ドライバの心理状態や判断などを模式的に記述した心理モデル (Fig.2.7) を考案した。このモデルは、走行中に不可欠で即時的な脇見を必要とする対象 (信号など) から、脇見の必要性が低い対象 (カーオーディオなど) までの多様な脇見対象に対して必要性やドライバの感情などを統合した「脇見に対する要求度」と、自車/他車/環境の現状から予測される将来的な走行状態の「危険性評価」との比較により脇見の実行がなされるモデルとなっている。ここで「危険性」とは「脇見に必要な時間」と「予測される状態」から決まるものとする。

このドライバの脇見心理のモデル化に際して本来は個別要素ごとに基本概念が詳細に定式化されることが望ましいが、その要素の多くが人間の内面的な情報処理過程であり、外部から観察、推定することが困難である。そのため田久保らは、モデルを Fig.2.8 のように簡略化し、要求度/危険性を包括して脇見の実行を判断する部分、諸条件から脇見の可能な時間を設定する部分、脇見の終了を判断する部分とすることでモデル化の実現を図った。

田久保らは、モデルに対する知見を得るために、脇見事故の発生傾向や個々の事例に対する詳細な分析を行った。具体的には、各事例ごとに衝突前後の追従車及び先行車の相対的な位置関係と運動状態から総合的な事故再現を行い、脇見時間を推定した (Fig.2.9)。推定脇見時間の分布を Fig.2.10 に示す。

次に田久保らは、事故の検証から得られた情報のうち、Table.2.3 に示す状態量について重回帰分析を行い、各要因の事故に対する影響程度を明らかにした。

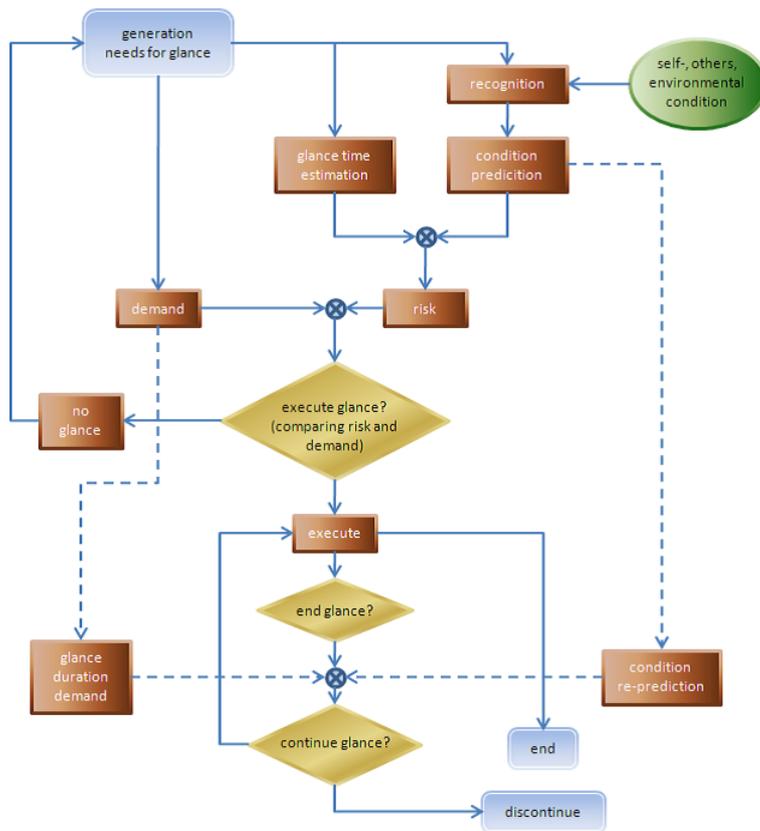


Fig. 2.7: ドライバ脇見心理モデル

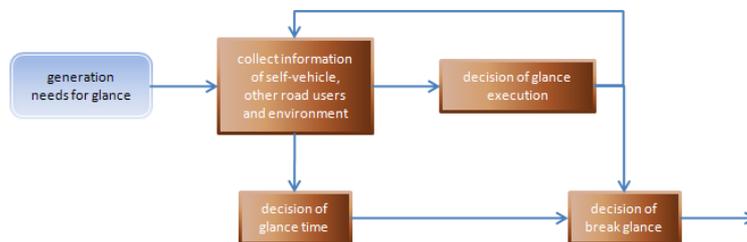


Fig. 2.8: 簡略化ドライバ脇見心理モデル

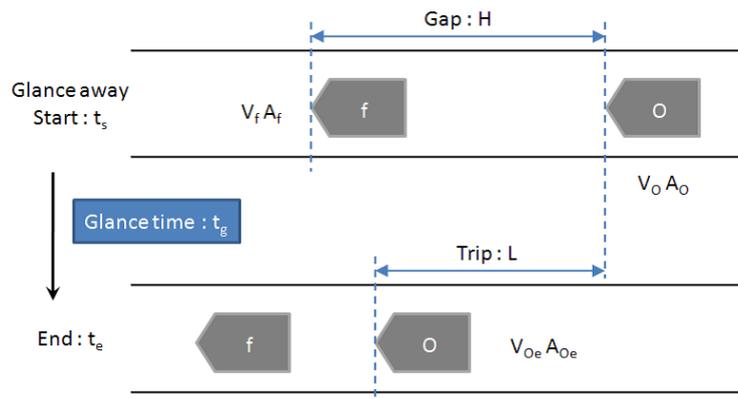


Fig. 2.9: 推定脇見時間

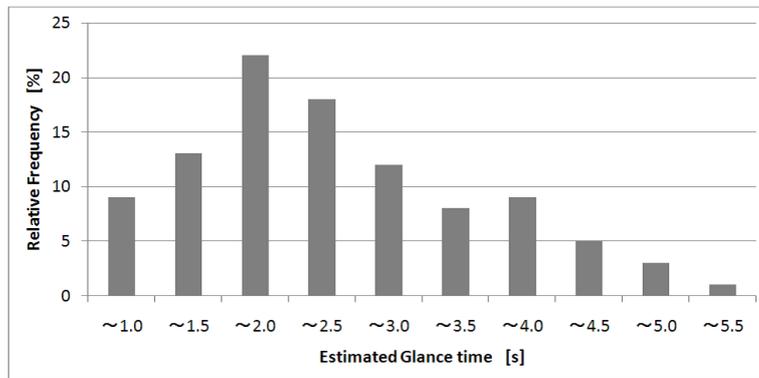


Fig. 2.10: 事故事例における推定脇見時間分布

Table. 2.3: 脇見分析に利用した運動状態量

$V_0$	追従車速度 (カーナビゲーションシステムあり) [m/s]
$A_0$	追従車加速度 [m/s <sup>2</sup> ]
$V_1$	先行車速度 [m/s]
$A_1$	先行車加速度 [m/s <sup>2</sup> ]
$H$	先行車と追従車の距離 [m]
$V_0 - V_1$	相対速度 [m/s]
$A_0 - A_1$	相対加速度 [m/s <sup>2</sup> ]
$H/V_0$	擬似衝突余裕時間 [s]
$H/(V_0 - V_1)$	衝突余裕時間 [s]

この分析から以下の3つの定性的解釈がなされた。

- 相対速度が高い（先行車への接近速度が高い） 脇見時間が短い
- 先行車の速度や加速度が高い（漢籍的に先行車が自車から離れる可能性が高い） 脇見時間が長い
- 擬似衝突余裕時間が長い（衝突までの擬似的な余裕度が大きい） 脇見時間が長い

最後に田久保らは、事故の検証分析結果から得られた「脇見時間が自車と先行車との運動状態の指標の影響を受けて決定される」という仮説の確認を行うために、ドライビングシミュレータを用いた脇見発生の模擬走行実験を行った。実験シナリオ、脇見タスクを下記に示す。

- 実験シナリオ：模擬道路（全長約10km）において、提示される先行車に対して、追従走行を行う。追従の車間距離等については、「被験者の感覚で普段と同様な追従走行を行う」と教示した。従って、追従の車間距離などは被験者の自由選択となる。習熟のための追従走行の後、脇見タスクを実行する。一定の走行距離となるまで脇見のタスクが適宜繰り返される。
- 脇見のタスク：メータ類と同じ高さで被験者の正面から左40cmの、グローブボックス前面に設置した小型モニタ（5inch型）に提示された15桁の数字を「可能な限り多くの桁まで」読み上げる。数時の順序は無作為とした。ドライバが危険と判断した時点で数字の読み上げは中断する。読み上げが終了または中断した後、新たな数値を提示する。読み上げの開始については「本人が適当と判断した時点」であり、読み上げ回数も被験者に一任される。追従状態も含めて、脇見タスクの多くの条件をドライバに一任することによって、危険度の判断をドライバ自身のメンタルモデルの内部で完結させることを意図している。

事故分析と模擬走行実験から得られた知見によって、Fig.2.8のドライバの脇見行動の簡易モデルの情報取得結果による脇見可能時間の設定プロセスは、具体的にFig.2.11の構造であるという結論に至った。即ち、先行者と後続車（自車）の運動状態から衝突時間に関する値の算出が行われ、同時に車間距離や速度に関する危険度を設定する。複数の脇見時間の候補の中から個人の特性に応じた脇見時間の基本

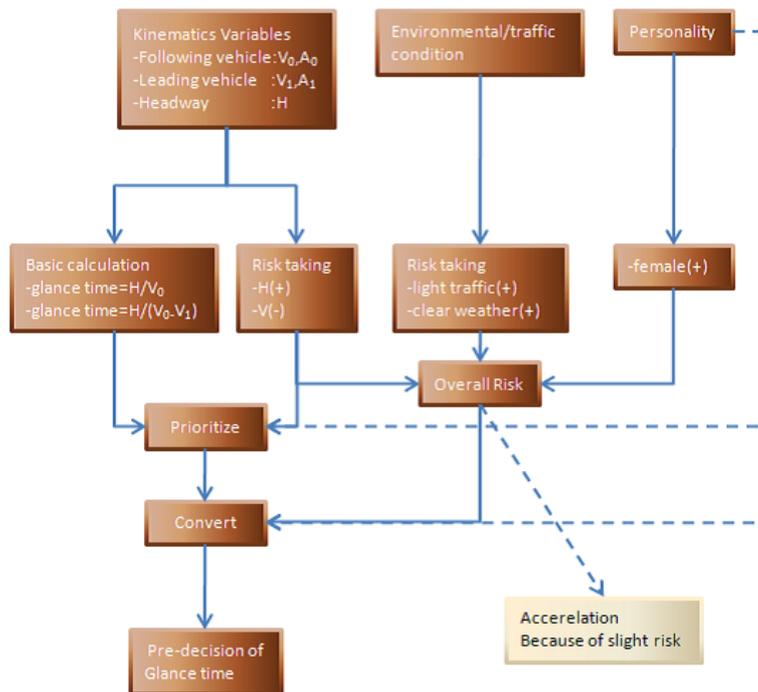


Fig. 2.11: 脇見時間決定モデル

値が決定される。基本値に対して、個人特性（女性では脇見時間は長い）、交通環境状況（晴天や交通閑散時に脇見時間が長い）などの危険度に関する要因を付加した変換が行われ、脇見時間が決定される。

他方、総合的な危険度の判断によって、危険度が低いと判断された場合、脇見時間が長く設定されるのと同時に加速行動が行われる場合があることもわかった。

## 2.3 ドライバのモデル化

近年 ITS の分野において、様々な観測情報を用いてドライバの状態や行動をモデル化し、通常の運転やドライビングシミュレータを用いた走行実験で得られたデータを用いて学習と評価を行う研究が盛んに行われ一定の成果を挙げている。またドライバの脇見行動は、様々な要素が複雑に影響し合いながら生じるドライバの振舞いと考えることができる。よって既存の様々なモデリング手法のアプローチを脇見行動に適用することは大変有用であると考えられる。このドライバのモデル化に関する研究は大きく分けて、

- ドライバの心理/精神状態を推定対象とする研究

- ドライバの運転行動を推定対象とする研究

に分けられる。

### 2.3.1 ドライバ状態のモデル化

ドライバ状態のモデル化に関する研究には、ドライバの疲労度 [14] [26] [4] [5] , 警戒/注意度 [1] などを扱ったものがある。以下では、その中のいくつかの研究について紹介し、そこで用いられた手法について簡単に説明する。

#### Bayesian Network を用いた疲労度の推定

Zhu ら [26] らは、カメラから得られるドライバの表情や動作の情報と、ドライバの置かれた状況の情報 (contextual information) を Bayesian Network (BN) [10] を用いて統合しドライバの疲労度を推定した。

Bayesian Network [36] とは、各変数間の定性的な関係性を有向非環グラフ (Directed Acyclic Graph : DAG) を用いて表し、定量的な関係を条件付き確率を用いて表したものである。BN はその変数間の条件付き独立性を仮定することで、多くの変数の関係性を記述することに長けた手法である。

Zhu らが疲労度の推定に用いた観測量は、瞬きの動き、視線の動き、頭部の動き、及び表情である。これらの観測量を適切な処理により Fatigue index (Table.2.4) と呼ばれる指標に変換し BN の入力として用いた。

Table. 2.4: Fatigue index

観測量	index 名	説明
瞬きの動き	PERCLOS	目の閉じている割合
	AECS	まぶたの閉じる速度
頭部の動き	NodFreq	頭位傾斜の頻度
視線の動き	GAZEDIS	注視点の分布
	PERSAC	時間におけるサッケード運動の割合
表情	YawnFreq	あくびの発生頻度

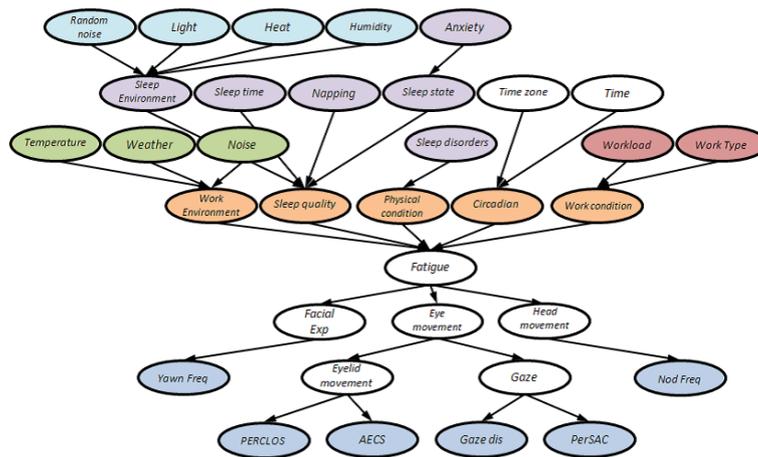


Fig. 2.12: 疲労度推定 Bayesian Network モデル

用いたBNのネットワークトポロジーを Fig.2.12 に示す．このモデルでは Fatigue index を用いて疲労度を推定する機構の他に，疲労度に大きく影響を与える要素群とそれに関係する要素群を加えることにより入力に含まれる曖昧さの抑制を試みた．

Zhu らが疲労度に大きく影響を与えるとして BN に加えた要素群は，

- Work environment ( 仕事の環境 )
- Sleep quality ( 睡眠の質 )
- Physical condition ( 体調 )
- Circadian ( 一日における時間帯 )
- Work condition ( 仕事の状態 )

である．なおこのモデルのパラメータ設定は疲労度に関する関連研究から抽出された統計と Zhu らの独自研究より得られた主観的知識から決定された．

### Dynamic Bayesian Network を用いた疲労度の推定

Gu ら [4] は，疲労度が表情に現れる場合に段階的に軽度の疲労を表す現象から次第に重度の疲労を表す現象へと状態が時間的に推移するモデルを Dynamic Bayesian Network(DBN) [8] [22] を用いてモデル化し，疲労度の推定を行った．

Table. 2.5: 利用観測量

検出器	観測量
Eye Tracker	瞳孔の移動
Gaze Detector	視線方向
Head Motion Detector	頭部の動き
Facial Feature Tracker	顔の上部/下部特徴量
Furrow Detector	鼻のしわ

Table. 2.6: Fig.2.13 における Action Units の定義

AU#	説明	AU#	説明
AU7	まぶたを固定	AU55	頭を左に傾ける
AU26	口をあぐり開ける	AU61	視線を左に移す
AU51/52	左右に振りむく	AU25	唇をわずかに開く
AU58	頭部を後屈させる	AU43	眼を閉じる
AU9	鼻にしわを寄せる	AU56	頭を右に傾ける
AU27	口を広げる	AU62	視線を右に移す

Dynamic Bayesian Network とは Bayesian Network を時系列情報が扱えるように拡張したモデリング手法である。Guらは Bayesian Network(2.3.1 参照) と一次 Hidden Markov Model(HMM) を用いて DBN を構築した。

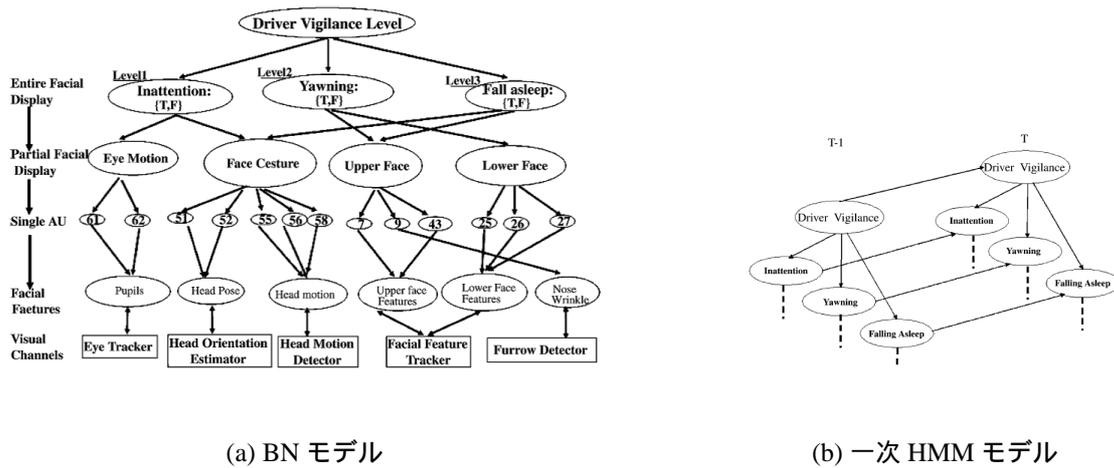
Hidden Markov Model [22] とは、ある観測できない状態量(隠れ状態変数)を、観測可能な状態量から推測する手法の一つである。隠れ状態変数が一つであり、且つ離散値のみをとる DBN を HMM と呼ぶ。つまり HMM は DBN の特殊な場合を記述したモデルと解釈できる。一次 HMM とは一次マルコフ性を有する HMM を表す。入力に用いた観測量を Table.2.5 に示す。

Guらは、Table.2.5 に示した各種観測量をより意味のある単位(Action Units(AU) [3]) に変換し DBN の入力として用いた。各 AU の説明を Table.2.6 に示す。このように画像から得られた情報を細かく細分化することで曖昧さを抑制することができた。

推定に用いた DBN モデルを各フレームに依存性 Fig.2.14(a) と、時間にまたがった依存性 Fig.2.14(b) とに分けてグラフ化したものを Fig.2.14 に示す。



Fig. 2.13: 疲労度推定用 Action units



(a) BN モデル

(b) 一次 HMM モデル

Fig. 2.14: 疲労度推定 DBN モデル

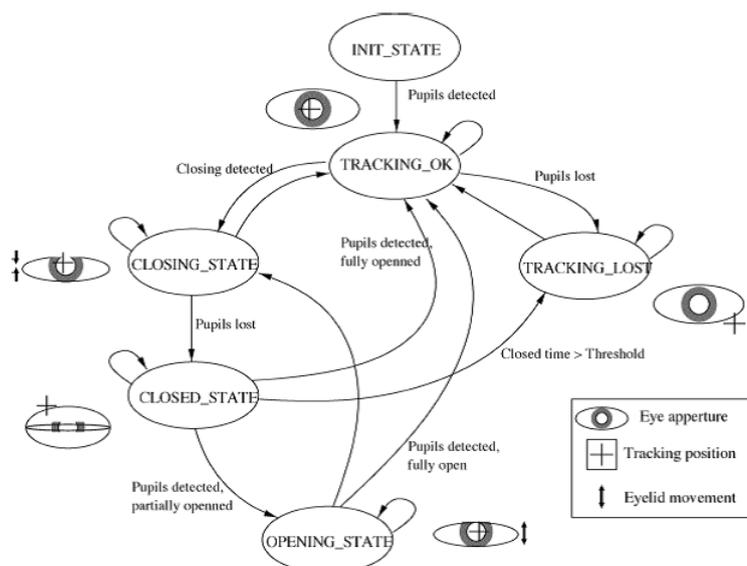


Fig. 2.15: 有限オートマトン

### Fuzzy System 及び有限オートマトンを用いた警戒度の推定

Luis M. Bergasa ら [1] は、近赤外線撮像システムで得た画像データを用いて瞳孔及び鼻孔の検出を行い、そこから得られたデータを目及び頭部の動きに関する適切な状態量に変換し、Fuzzy System により Real-Time で動く運転者の警戒度推定システムの開発を試みた。

目に関するデータの状態量への変換では、瞳孔の検出結果を独自に開発した有限オートマトンに入力し状態の遷移を評価することでよりロバストな状態量の抽出を行った。有限オートマトン (Finite State Machine(FSM)) とは、有限個の状態と遷移と動作の組み合わせからなるふるまいのモデルである。この有限オートマトンの次の状態と出力は入力と現在の状態とによって決定される。この研究で用いられた有限オートマトンのモデルを Fig.2.15 に示す。

次に頭部は、近赤外撮像システムから得られた瞳孔及び鼻孔の座標から二次元頭部モデルとの照合により顔の位置及び向きを推定し、その結果を適切な状態量に変換した。Luis M. Bergasa らが用いた状態量を Table.2.7 に示す。これらの値を Fuzzy System に入力することによりドライバ不注意レベル (Driver's Inattentiveness Level(DIL)) を算出した。

パラメータの学習には、生理学の研究に基づく特徴的な振る舞いを各ドライバーが模して得られたデータが用いられた。

Table. 2.7: Fuzzy System に用いた入力状態量

状態量	Level	用語
目の閉じている割合	5	small, medium small, medium, medium large, large
目を閉じている継続時間	3	small, medium, large
またばきの頻度	3	small, medium, large
頭部を下方に垂れる頻度	3	small, medium, large
顔の位置	5	small, medium small, medium, medium large, large
視線の固定	5	small, medium small, medium, medium large, large

### 2.3.2 ドライバ行動のモデル化

ドライバ行動のモデル化を扱った研究には、車線変更行動 [21] [12] [16] [23] [37]、右折行動 [13] [20] や停止行動 [6] [17] などがある。この中で、特に周囲の状況やドライバの心理状態などが複雑に影響する運転行動である車線変更のモデル化に関する研究をいくつか紹介し、そこで用いられた手法について簡単に説明する。

#### Hidden Markov Model を用いた車線変更行動の推定

Alex Pentland ら [21] は、Hidden Markov Model(2.3.1 参照) に Kalman filter を適用した Markov Dynamic Model を用いてドライバの車線変更行動を推定した。

Kalman filter とは、誤差のある観測値を用いてある動的システムの状態を推定、あるいは制御するための無限インパルス応答フィルタの一種である。推定に用いられたデータは、アクセルとブレーキの踏み込み量、ハンドル角度である。



Fig. 2.16: (a)Driving Simulator (b)simulated world

Alex Pentland らは、推定対象となる運転者の操作を小スケールの行動に分割し、その中で予備動作にあたる状態列のみを用いて運転者が現在何を行動に移そうとしているのかを推定した (Fig.2.17)。

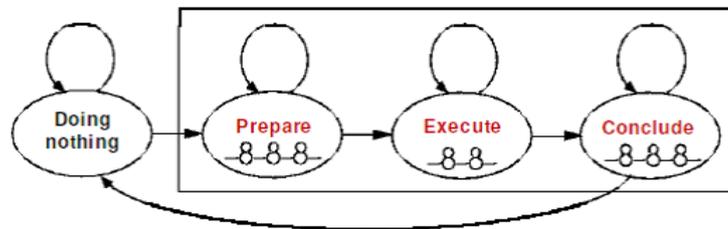


Fig. 2.17: ドライバ行動の Markov dynamic Model

実験に用いたデータはドライビングシミュレータ (Fig.2.16) から取得された。実験時には被験者に対して1秒間指示を提示し、その後ドライバは現在の状況を実験監督者に伝え、どう実行するかプランを伝えた後に運転行動を実行に移すという方法をとった。車線変更における小スケールの行動群は以下の6つである。この中で車線変更の予備動作に当たるのは、1)~3)となる。

- 1) 現在の車線において中心線に車両を合わせる
- 2) 周囲を見回し隣の車線が開いているかを確認する
- 3) 車線変更へ向けてハンドルをきる
- 4) 車線変更中
- 5) 車線変更を終えるためにハンドルをきる
- 6) 新しく走る車線に対して中心線に合わせる

評価には、時間経過に対する推定精度の変化を用いた。行動開始から1.5秒後(行動開始命令が出てから2秒後)で、平均認識精度が95.24% ± 3.1%という結果が得られた。しかし、この時点で既に運転者は車線間を移動し始めており、未然に推定するという当初の目的を果たせていないという問題点が残った。

Table. 2.8: SVM Feature Set

	Feature
Set1	Acceleration,Lane Position 0,Lane Posion 30,Heading
Set2	Acceleration,Lane Position 0,Lane Posion 30,Heading,Lead Car distance
set3	Acceleration,Lane Position 0,Lane Posion 20,Lane Posion 30,Heading Longitudinal acceleration,Lateral acceleration
Set4	Acceleration,Lane Position 0,Lane Posion 30,Heading,Steering Angle
Set5	Lane Posion 0,Lane Posion10,Lane Position 20,Lane Posion 30

### Support Vector Machines を用いた車線変更行動の推定

Hiren Mansukhlal Mandalia [16] らは、Support Vector Machines に線形カーネルを適用し、Real-Time での車線変更検出システムの構築を試みた。データは、多車線の高速道路を4人の被験者が実際に走行した際に記録されたものを使用した。記録された特徴量は、アクセルの踏み込み量、ステアリング舵角、速度、先行車との距離、車線における位置である。推定では、これらの特徴量を組み合わせ、どの特徴量セットを用いたときに最も推定精度が高いか検証した。

Hiren Mansukhlal Mandalia らは、まず Support Vector Machines の学習に用いる training data の window size についての知見を得るために、1～5秒の中で様々な条件で試行錯誤した結果、1.2秒の window size において最もよい結果を得た。評価には、用いた特徴量の組み合わせごとに偽陽性 (falsepositive) の検出の割合が1%の場合と5%の場合について、時間経過とともに移り変わる検出精度の変化を用いた。組み合わせを Table.2.8 に示す。

Set5 の組み合わせによる推定結果では5%の偽陽性下で、推定開始から1.2秒で最大97.94%の推定精度を得た。しかし、カーブを走行中の推定では著しく推定精度が落ちることや、学習に用いるカーネルの選択に関する実験で偽陽性の割合によっては線形カーネルよりも良い結果が得られたものがある (偽陽性1%) など課題となる点も多い。

### 視線情報とベイズ推定法を用いた車線変更の推定

鈴木ら [37] は、運転時の視線方向の挙動に注目し、右車線変更時の視線方向の挙動と直進時の視線方向の挙動をそれぞれ学習することにより視線情報からベイズ推

Table. 2.9: 使用観測量

観測量	説明
O1	視線の水平方向成分の移動分散
O2	視線の鉛直方向成分の移動分散
O3	視線の水平方向成分の位置
O4	視線の鉛直方向成分の位置

定法により右車線変更を推定する手法を提案した。

ベイズ推定法とは、観測データ  $O$  と分類クラス  $\omega_i$  の事前確率と事後確率の関係式

$$P(\omega_i|O) = \frac{P(O|\omega_i)P(\omega_i)}{P(O)} \quad (2.3.1)$$

から、 $O$  が観測された時に式 2.3.1 に基づいて尤度  $P(O|\omega_i)P(\omega_i)$  を計算し、各クラスの中で最も尤度の高いクラスを推定結果とする手法である。実験にはドライビングシミュレータを使用し、後のイベント確認用にハンドル、アクセル、及びブレーキの操作量を記録した。また、視線方向情報の観測にはアイマークレコーダを使用した。ベイズ推定に用いた観測量を Table.2.9 に示す。なお、分散は注目時点の 11 秒前から 1 秒前までの 10 秒間、計 625 店におけるデータをもとに算出した。

この手法は各時点での視線の座標や移動分散の値から行動クラスをマッピングしているだけなので、時系列に沿った状態の変化を記述できていない。しかし、車線変更の行動前の推定において一定の成果を挙げており、このことから運転行動における視線情報の有用性が高いことがわかった。

## 2.4 脇見行動及びドライバのモデル化の既存研究のまとめ

ドライバのモデル化には主にドライバの心理/精神状態を推定対象とするものとドライバの運転行動を推定対象とするものがあり、その各々に対して様々な手法や観測量を用いた研究が盛んに行われていることを紹介した。ドライバのモデル化に用いられる手法には様々なものがあるが、中でも観測量と推定対象の因果関係の記述に長けた手法 (Bayesian Network, Dynamic Bayesian Network) や時系列の情報の記述に長けた手法 (Hidden Markov Model, Dynamic Bayesian Network) などが主流となっている。また、推定に用いられる観測量も車内で取得可能な限られたデータの中で技術の進歩とともに様々なものが用いられている。その中でも特にドライバに関する情報 (頭部位置, 頭部姿勢, 視線方向) や操作情報 (ハンドル角度, アクセルペダル位置, ブレーキペダル位置など), 車両に関する情報 (速度, 加速度, 車線における位置など) がドライバの状態や行動の推定に有用であることが報告されている。

ドライバの脇見行動は、脇見事故の分析研究 [35] でも述べられているように多くの要素が複雑に影響して発生する事象であり、先行研究のように顔向き of 角度の大きさのみに着目した脇見検出では、過学習の問題が懸念される。また既存研究では、運転に必要な首振り動作なども危険状態に含まれているが、この動作自体は安全な運転をする上で必要な動作である。しかし安全確認などの運転に必要な動作と脇見行動とを分けて検出を行うような研究は見当たらない。こういった問題を考慮した手法の検討が必要である。

## 第3章 提案手法概要

脇見行動はドライバの置かれた状況や意図，ドライバの心理状態などが複雑に影響し合って発生する．しかし，ドライバの心理状態や意図などは直接計測することはできない．そこでドライバの脇見行動をモデル化することにより周りの観測可能な情報から脇見行動を推定することを試みる．

ここで脇見行動の性質を考慮すると，モデル化の手法には，

- 複雑な要素間の関係性を記述可能であること
- 時系列情報を扱えること

などが求められる．これらを考慮してモデル化に関する既存手法を考察すると，Hidden Markov Model は時系列データを扱えるという利点はあるが，扱う観測量が増えるとその分条件付き確率表（Conditional Probability Table(CPT)）が指数関数的に大きくなり計算効率が悪化するため多要素を用いたモデルの記述に不向きである．また Bayesian Network は複雑な要素間の関係性を記述するのに長けたモデルであるが，過去の状態遷移などを考慮するような時系列情報を扱うことはできない．そこで本研究では複雑な要素間の関係性と時系列情報の両者を記述可能な Dynamic Bayesian Model を用いてドライバの脇見状態の推定を試みる．

### 3.1 Dynamic Bayesian Network を用いた脇見状態推定

本手法では，ドライバの頭部姿勢角情報及び運転状況の観測履歴から各時点での脇見度合を Dynamic Bayesian Network (DBN) を用いて算出する．DBN とは，隠れ状態変数（直接観測できない変数）と観測変数（直接観測可能な変数）との間に何らかの因果関係がある時に，定性的な関係性を有向グラフを用いて記述し，定量的な関係性を確率を用いて記述する手法である．DBN ではこの定量的関係性を学習しておき，ある時刻までの観測変数の状態履歴からその時刻の隠れ状態変数の値の尤もらしさを確率的に算出する．なお，DBN では隠れ状態変数及び観測変数の状態量

に離散量，連続量とも用いることが可能だが，本手法では一部の観測量を除きすべて離散量として扱う．

以下具体例を以て説明する．各時刻  $t$  において，観測量を  $Z_t = \{Z_t^{(1)}, Z_t^{(2)}, \dots, Z_t^{(N)}\}$  とおくと，それまでに得られた全ての観測量は  $Z_{1:t}$  と表せる．次に時刻  $t$  において脇見行動をとっているかどうか（脇見状態：OFF/ON）を  $X_t$  としたとき，時刻  $t$  までの観測量が与えられた場合の脇見状態の確率は  $P(X_t|Z_{1:t})$  と表すことができる．この値を算出することにより脇見行動を定量的に推定する．そのため，まず学習により脇見状態間の遷移確率  $P(X_{t+1}|X_t)$ ，及び脇見状態と観測量の間の観測確率  $P(Z_t|X_t) = P(Z_t^{(1)}, Z_t^{(2)}, \dots, Z_t^{(N)}|X_t)$  を明らかにする必要がある．ここで，各観測量間の独立性を仮定すると同時確率  $P(Z_t^{(1)}, Z_t^{(2)}, \dots, Z_t^{(N)}|X_t)$  は

$$P(Z_t^{(1)}, Z_t^{(2)}, \dots, Z_t^{(N)}|X_t) = \prod_{k=1}^N P(Z_t^{(k)}|X_t) \tag{3.1.1}$$

と変換できる．よって各観測量ごとに  $P(Z_t^{(k)}|X_t)$  を学習することで脇見状態と観測量の間の観測確率  $P(Z_t|X_t)$  が学習される．DBNの一般的なモデル図を図3.1に示す．

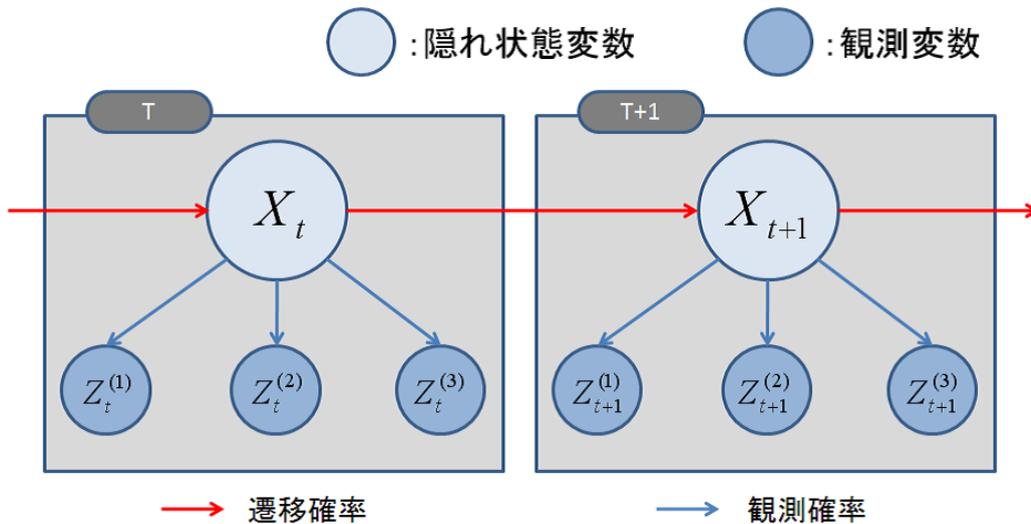


Fig. 3.1: 一般的な DBN モデル

ここで脇見状態間の遷移確率とは，ある時刻  $t$  において脇見状態  $X_t$  が OFF もしくは ON の値をとる時に，次の時刻  $t+1$  において脇見状態  $X_{t+1}$  が OFF もしくは ON の値をとる確率である．本手法では隠れ状態である脇見状態が OFF/ON と離散的な状態量をとるため，遷移確率は遷移前，遷移後のインデックスで記述された行列で表記できる．これを特に遷移行列という．同様に，脇見状態と観測量の間の観測確

Table. 3.1: 遷移行列の例

	$X_{t+1}=\text{OFF}$	$X_{t+1}=\text{ON}$
$X_t=\text{OFF}$	$a$	$1 - a$
$X_t=\text{ON}$	$b$	$1 - b$

Table. 3.2: 観測行列の例

	$Z_t^{(k)}=1$	$Z_t^{(k)}=2$	...	$Z_t^{(k)}=m$
$X_t=\text{OFF}$	$a_1$	$a_2$	...	$1 - \sum_{i=1}^m a_i$
$X_t=\text{ON}$	$b_1$	$b_2$	...	$1 - \sum_{i=1}^m b_i$

率とは、ある時刻  $t$  において脇見状態  $X_t$  が OFF もしくは ON の値をとる時に、観測量  $Z_t^{(k)}$  が  $z^{(k)}$  の値をとる確率である。本手法では一部を除き観測量も離散的な値に変換して扱うため、観測確率は観測量ごとに脇見状態と観測量の値のインデックスで記述された行列で表現できる。これを特に観測行列という。遷移行列及び観測行列の例を Table.3.1, Table.3.2 に示す。なお、遷移確率は遷移前の脇見状態、観測確率は脇見状態ごとに正規化されている。

遷移確率及び観測確率の学習方法については 3.2 で詳細を説明する。

以下学習により、脇見状態間の遷移確率  $P(X_{t+1}|X_t)$ 、及び脇見状態と観測量の間の観測確率  $P(Z_t|X_t)$  が既知であるとする。このとき、目的とする脇見状態の確率分布  $P(X_t|\mathbf{Z}_{1:t})$  は、まず脇見状態  $X_t$  が OFF/ON それぞれの場合について、式 3.1.2 を用いて直前の脇見状態の確率分布と先の  $P(X_{t+1}|X_t)$  及び  $P(Z_t|X_t)$  より尤度を計算し、両者を正規化することにより算出される。この過程は再帰的手法をとっており、各時刻における観測量を与えることで、直前の脇見状態の確率分布を考慮した各時刻の脇見状態の確率分布を推定することができる。

$$\begin{aligned}
 P(X_{t+1}|\mathbf{Z}_{1:t+1}) &= \prod_k P(X_{t+1}|Z_{1:t+1}^{(k)}) \\
 &= \prod_k P(X_{t+1}|Z_{1:t}^{(k)}, Z_{t+1}^{(k)}) \\
 &= \alpha \prod_k P(Z_{t+1}^{(k)}|X_{t+1}, Z_{1:t}^{(k)})P(X_{t+1}|Z_{1:t}^{(k)}) \\
 &= \alpha \prod_k P(Z_{t+1}^{(k)}|X_{t+1})P(X_{t+1}|Z_{1:t}^{(k)}) \tag{3.1.2} \\
 &= \alpha \prod_k P(Z_{t+1}^{(k)}|X_{t+1}) \sum_{x_t} P(X_{t+1}|x_t, Z_{1:t}^{(k)})P(x_t|Z_{1:t}^{(k)}) \\
 &= \alpha \prod_k P(Z_{t+1}^{(k)}|X_{t+1}) \sum_{x_t} P(X_{t+1}|x_t)P(x_t|Z_{1:t}^{(k)})
 \end{aligned}$$

ただし  $\alpha = \frac{1}{P(\mathbf{Z}_{t+1})}$  : 定数

### 3.2 遷移確率及び観測確率の学習方法

本手法では，全ての時刻において脇見状態及び観測量がともに既知であるデータから遷移確率及び観測確率の学習を行う．脇見状態及び各観測量は一部を除きすべて離散量としているので遷移確率及び観測確率は対応するフレームのカウントにより算出される．具体的な算出式を3.2.1，3.2.2に示す．なお， $\sum\{y\}$ は条件 $y$ を満たすフレーム数を表す．各時刻における脇見状態，及び観測量の取得方法については第4章にて述べる．

$$P(X_{t+1} = i | X_t = j)_{i,j \in \{\text{OFF}, \text{ON}\}} = \frac{\sum\{(X_{t+1} = i) \text{ and } (X_t = j)\}}{\sum\{X_t = j\}} \quad (3.2.1)$$

$$P(Z_t^{(k)} = z | X_t = j)_{j \in \{\text{OFF}, \text{ON}\}} = \frac{\sum\{(Z_t^{(k)} = z) \text{ and } (X_t = j)\}}{\sum\{X_t = j\}} \quad (3.2.2)$$

## 第4章 データ取得

### 4.1 実験システム概要

本手法では，統計的手法を用いて遷移確率及び観測確率を学習する．そのため，学習データとして各時刻における正確な脇見状態及び観測量の値を必要とする．また，教師付き学習に用いる学習データの取得では，明確に脇見を定義可能な環境下で実験を行う必要がある．そこで本研究ではドライビングシミュレータ（DS）という完全に制御された環境下で実験を行うことによりこれらの問題を解決した Fig.4.1 [31] ．



Fig. 4.1: Driving Simulator : 三菱プレシジョン製

本ドライビングシミュレータは車両を囲う正八角形の形状をした投影面に，プロジェクタを用いて周囲環境及び周辺車両を 360 度全方位に投影する．また，左右のサイドミラーに対しては車両を囲う投影面とは別に投影面を用意し，より現実感の強い情景がミラーに映りこむように工夫されている（ Fig.4.2 ）．これにより実環境

での運転に極めて近い視界環境が構築されている。

また、操作環境も実車を可能な限り再現しており、ステアリング操作やペダル類の操作はもちろん、様々な情報を取得可能である。DSより取得可能な観測量を Table.4.1 に示す。

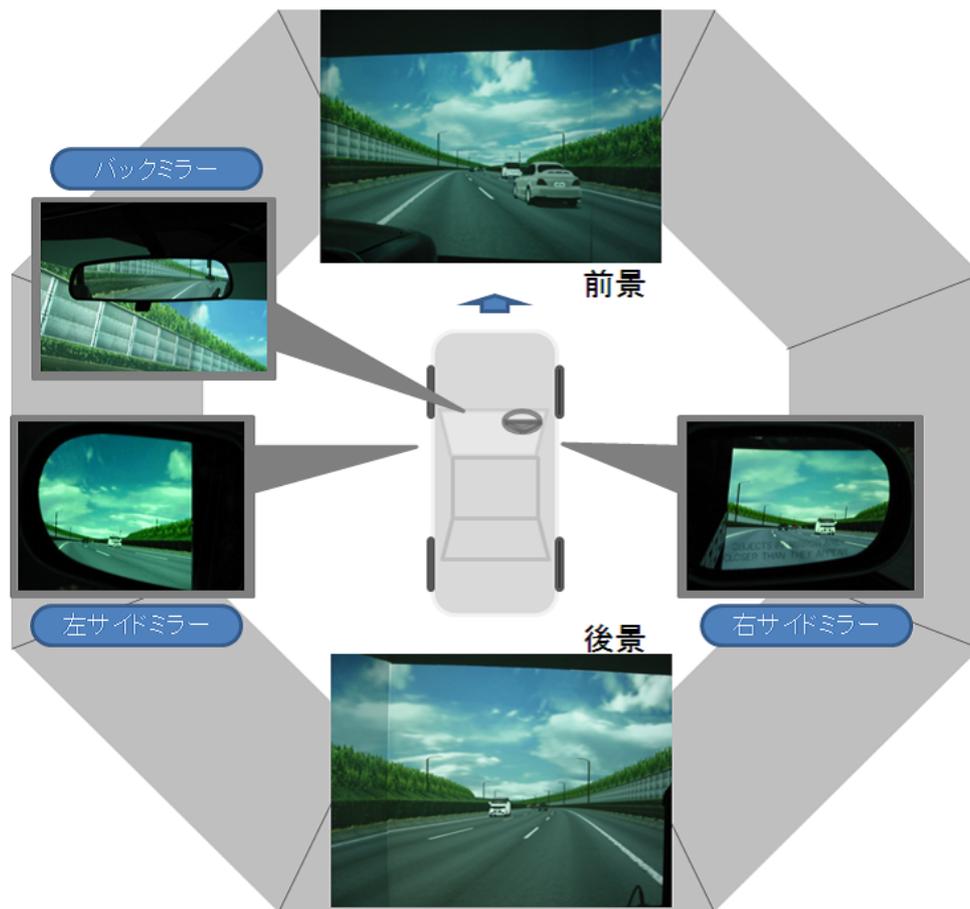


Fig. 4.2: DS における視界環境

Table. 4.1: DS から取得可能な観測量

分類	名称	備考
運転席入力データ	ステアリング操舵角	[deg]
	アクセル操作	[%]
	フットブレーキ操作	0.0 ~ 0.8
	シフトポジション	0:N,1:L,2:2,3:D,4:R,5:P
	パーキングレバー	0:OFF,1:ON
自転車データ	位置座標 (X)	[m]
	位置座標 (Y)	[m]
	位置座標 (Z)	[m]
	姿勢角 (Roll)	[deg]
	姿勢角 (Pitch)	[deg]
	姿勢角 (Heading)	[deg]
	速度	[km/h]
	加速度	[m/s <sup>2</sup> ]
	現在走っている交差点 I D	
	現在走っているメイン道路 I D	
	現在走っているサブ道路 I D	
	前方交差点 I D	
	後方交差点 I D	
	次の交差点までの距離	[m]
	センターラインからの距離	[m]
	センターラインに対する姿勢角	[rad]

本研究で実験に使用したシステムを Fig.4.3 , Fig.4.4 に示す . 我々はDS の運転席前方及び左方に , 頭部位置推定システム用の3 台のカメラを設置した ( Fig.4.3 , Fig.4.6 ) . また , 運転席上部後方に , 車線変更など各時刻での運転行動やイベントの検証用に運転席及び前方を広く録画する広角レンズ搭載カメラを1 台設置した ( Fig.4.3 ) . このイベント検証用カメラで撮影された画像を Fig.4.5 に示す . その他に脇見発生用ターゲットの投影に用いるプロジェクタを後部座席位置の左右外側に合計2 台設置した ( Fig.4.3 ) . このプロジェクタは最大 , 上下 30[deg] , 左右 40[deg] の範囲に投影可能な広角レンズを搭載している . これらのプロジェクタの設置位置は , 首を振らなければ運転席から目視できない位置にターゲットが投影されるように決定した . なお , 脇見発生用ターゲットについての詳細は 5.2 にて述べる .

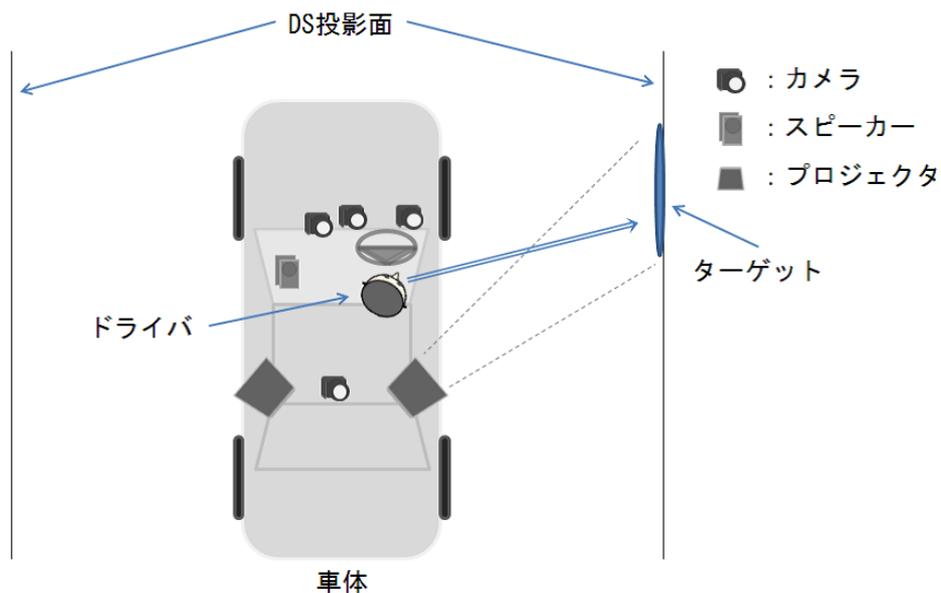


Fig. 4.3: 実験システム概図



Fig. 4.4: 実際のシステム



(a) 右ターゲット例



(b) 左ターゲット例

Fig. 4.5: イベント検証用カメラ撮影画像例

## 4.2 頭部姿勢情報取得

ドライバの頭部姿勢情報の取得には、当研究室で開発された文献 [28] の頭部姿勢推定手法を用いた。Fig.4.7 に頭部姿勢追跡画像例を示す。このシステムは、事前にかメラパラメータをキャリブレーションにより取得しておく必要がある。本研究では文献 [24] のキャリブレーションツールを用いてキャリブレーションを行った。この追跡システムは、初期化時に顔の特徴点を抽出しその後はパーティクルフィルタを用いて特徴点を追跡することにより 30[fps] でのリアルタイムな頭部の位置・姿勢の推定を可能にしている。しかし本研究では実験後に様々な考察を行う必要があったため、追跡結果動画及びイベント確認用動画を同期をとった状態で保存する必要があり、結果として平均 28.8[fps] 程度のフレームレートで頭部姿勢データを取得した。なお本手法では、この頭部姿勢推定システムで得られる情報のうち、脇見状態を最も反映すると考えられるヨー角（鉛直軸周りの回転角度）のみを観測情報として用いた。



(a) 前面図



(b) 側面図

Fig. 4.6: 三次元頭部姿勢推定用カメラ



(a) 正面



(b) ルームミラー



(c) 左脇見



(d) 左サイドミラー



(e) 右脇見



(f) 右サイドミラー

Fig. 4.7: 頭部姿勢追跡画像例

### 4.3 データ集約機構

これまでに説明した様々なシステムから出力される各種データに対して，本研究では通信によりリアルタイムで同期をとりながら集約する機構を構築した．データ同期集約機構の概要を Fig.4.8 に示す．

DS のシステムでは 60[fps] で全データが取得される．また，DS にはそのデータを UDP 通信により特定 IP アドレスに向けて送信する仕組みが既があり，その機能を本研究では利用した．

一方，脇見発生用ターゲットの提示情報やドライバの頭部姿勢の推定情報もリアルタイムで取得する必要がある．そこで本研究では，文献 [32] を参考に TCP によるサーバ・クライアント通信プログラムを構築し，頭部姿勢推定システム及び脇見発生用ターゲット提示プログラムにはクライアントプログラムを，DS のデータを取得/保存するプログラムにはサーバプログラムを組み込んだ．

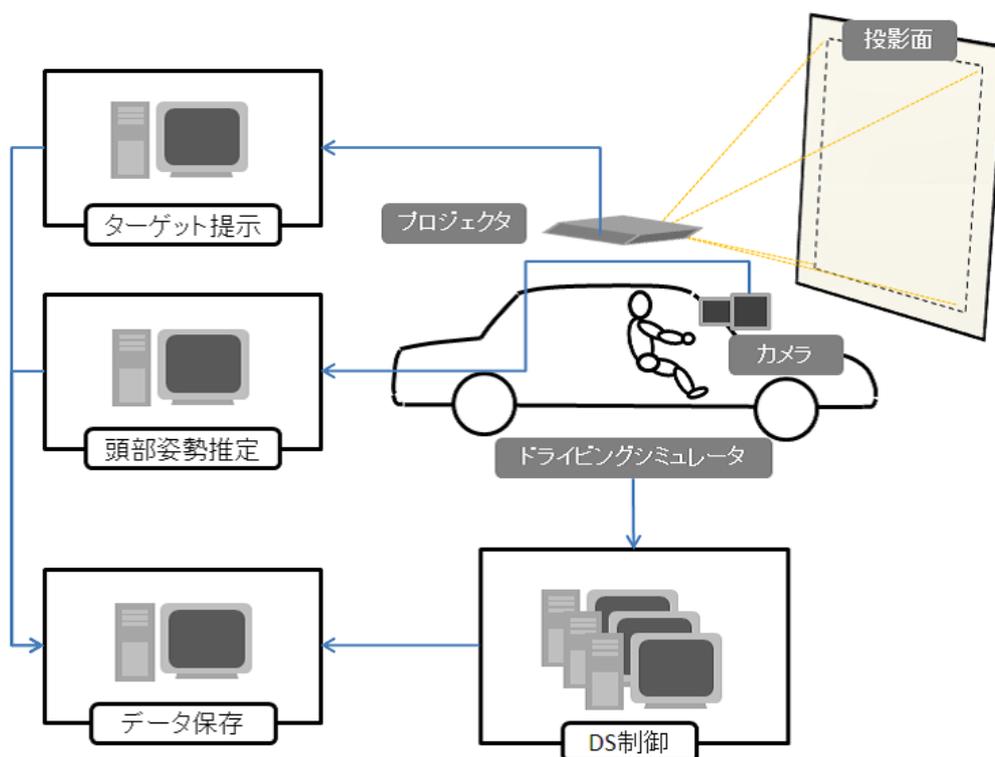


Fig. 4.8: データ同期集約機構

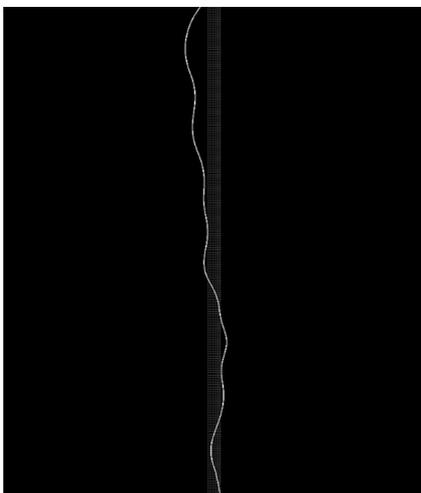
脇見発生用ターゲット提示プログラムは、提示状態の変更時に新たな変更状態をサーバに送信する。サーバでは受け取ったデータをターゲットフラグに格納し保持しておく。またDSから送信された全データは、60[fps]の頻度でサーバのデータバッファ上に更新される。ここで先に述べたように、頭部姿勢推定システムは完全な30[fps]でのデータ取得及び送信が可能でなかったため、サーバプログラム上でのデータ保存は頭部姿勢推定システムに同期をとった形で保存する方法をとった。具体的には、頭部姿勢推定システムからサーバプログラムがデータを受信するたびに、サーバプログラム上でのターゲットフラグの値、及びDSからのデータが保存されたバッファの値を見て、頭部姿勢推定プログラムの頭部姿勢推定結果とともに保存する。これにより動画像と同期のとれたデータの取得が可能となった。

## 第5章 実験

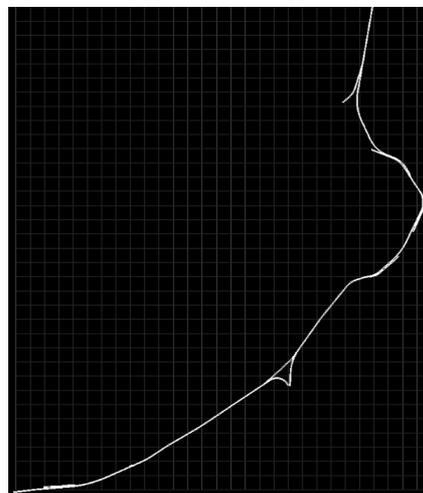
本研究では，被験者4名に対してドライビングシミュレータを走行中に実際に脇見行動を誘発させ，その時の各種データを第4章で説明した実験システムにより取得した．以下ではその詳細について説明する．

### 5.1 走行コース

本研究では，実在する高速道路を忠実に再現した規定コース（2コース）をDSで走行する実験を行った．使用コースは(a)東名大和サグコース，(b)首都高速3号線コースである．走行回数は(a)平均3.75回，(b)平均8.00回である．それぞれのコース図を Fig.5.1 に示す．



(a) 東名大和サグコース



(b) 首都高速3号線コース

Fig. 5.1: DS 使用コース

各コースの特徴を Table.5.1 に示す．なおデータ取得の際に，(a)の東名大和サグコースはコース長が長いために20000フレームを目処に実験を終了したが，(b)の首

Table. 5.1: 各コース特徴比較

コース名	全長	特徴	合流/分岐
東名大和サグ	約 20[km]	<ul style="list-style-type: none"> <li>・緩やかなカーブが断続的に続く</li> <li>・変化に乏しく単調</li> </ul>	なし
首都高速 3 号線	約 4.8[km]	<ul style="list-style-type: none"> <li>・カーブやトンネルなどが多い</li> <li>・変化に富み複雑</li> </ul>	あり

都高速 3 号線コースはコース終了まで走行した。本研究でこのように特性の異なるコースを用いて実験を行う理由は、本研究の目的と大きく関わる。本研究の目的とは 2.4 でも述べたように、安全確認などの運転に必要な首振り行動と脇見行動とを分けて検出することである。しかし、安全確認はドライバーが必要に応じて行うものであり、その必要性はコース特性やドライバーの置かれた状況に大きく依存する。つまり、合流や分岐などが少ないコースでは安全確認を行う必要性の生じる状況が限られており、比較的脇見状態推定の難易度は低く、また逆に合流や分岐、トンネルなどがあり変化に富むコースでは様々な状況で安全確認の必要性が生じ、比較的脇見状態推定の難易度が高いと考えられる。様々な環境における提案手法の有効性を考察するためにこのように特性の異なるコースで実験を行う。

## 5.2 脇見行動発生方法

本研究では、被験者に対して DS で規定コースを走行中にターゲットを目視するタスクを与え、これにより首振り動作を伴う脇見状態が発生する状況を再現した。なおターゲットは、このとき被験者には、首を左右に振る運転動作として、安全の範囲内で車線変更を頻繁に行うように指示した。

タスクで使用するターゲットは、プロジェクタ及び脇見発生用ターゲット提示プログラムを用いて DS 投影面上に投影した (Fig.5.2)。提示の時間間隔、投影に使用するプロジェクタの選択 (投影の左右方向)、プロジェクタ投影可能範囲内でのターゲットの提示位置、及び提示するターゲットの種類は全てランダムとした。1 ターゲット当たりの提示時間は 5[sec]、各ターゲット提示の提示間隔は 41.6[sec/回]、ターゲットの種類は 51 種類とした。提示するターゲットには道路標識やドライバーの興味を引く画像、四字熟語などを用いた。また、ドライバーに心的負荷を与えずにより自然に近い脇見を発生させるために、スピーカの音を用いて左右どちらの方向に

ターゲットが提示されるかを提示直前1秒前に知らせる方法をとった．スピーカは Fig.5.3 (4.3 参照) に示すように，助手席の足元に設置した．

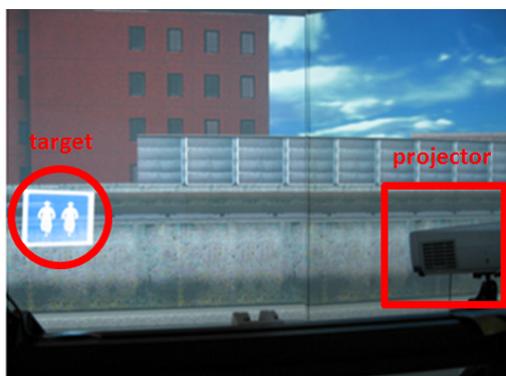


Fig. 5.2: ターゲット投影例



Fig. 5.3: 使用スピーカー

また，より自然な脇見状態を再現するために，ターゲットを目視するタイミング，目視する継続時間は被験者の危険認識で自由に決められるものとした．そして，ドライバの頭部ヨー角の絶対値が一定値  $\psi$  以上で，且つターゲットが提示されているフレームを脇見している状態と定義した．これを数式により表現すると，5.2.1 式となる．

$$X_t = \begin{cases} \text{ON}, & \text{if}\{(|yaw| \geq \psi) \text{and}(Target = \text{ON})\} \\ \text{OFF}, & \text{otherwise} \end{cases} \quad (5.2.1)$$

ただし，5.2.1 式の定義で脇見状態の正解データを作成した場合，ターゲット提示中に車線変更などを行って安全確認行動をとった（運転に必要な首振り行動を行った）ときなどに誤ったラベル付けが行われてしまう可能性がある．そこで，音を用いてターゲットの提示方向がアナウンスされるさらに5秒前に，間もなくターゲット提示が行われる旨を音により知らせる方法をとった．

### 5.3 脇見状態検出方法

本研究では，3.2 で述べた学習方法によって得られた遷移確率  $P(X_{t+1}|X_t)$ ，観測確率  $P(Z_t|X_t)$ ，これまでに得た観測量  $Z_{1:t}$  及び 3.1.2 式から脇見状態の確率  $P(X_t = \text{ON}|Z_{1:t})$  を推定する．このとき脇見状態の推定値を  $\hat{X}_t$  と置くと，脇見状態推定結

果は特に言及がない限り 5.3.1 式のように定義される．なお， $\xi$  は脇見検出に用いる閾値である．

$$\hat{X}_t = \begin{cases} \text{ON}, & \text{if}\{P(X_t = \text{ON}|\mathbf{Z}_{1:t}) > \xi\} \\ \text{OFF}, & \text{otherwise} \end{cases} \quad (5.3.1)$$

## 5.4 推定結果に対する評価方法

### 5.4.1 受信者動作特性曲線（ROCカーブ）

信号とノイズを識別する能力を評価する信号検出理論という分野において受信者動作特性曲線（Receiver Operating Characteristic curve：ROC 曲線）というものがある．この ROC 曲線は，二値分類器に対して閾値を変化させた時にそれに応じて変化する分類器の感度並びに偽陽性率を，縦軸に感度，横軸に偽陽性率をとり図式的にプロットしたものである．本研究でも，脇見状態を推定結果により二値化する分類器を構築するので，この手法を用いた評価を検討した．なお，この ROC カーブでは推定が有効であるときに曲線が左上に近づいていき，評価値としては ROC カーブ右下の面積が 1 に近ければより有効な推定手法であると判断される Fig.5.4．

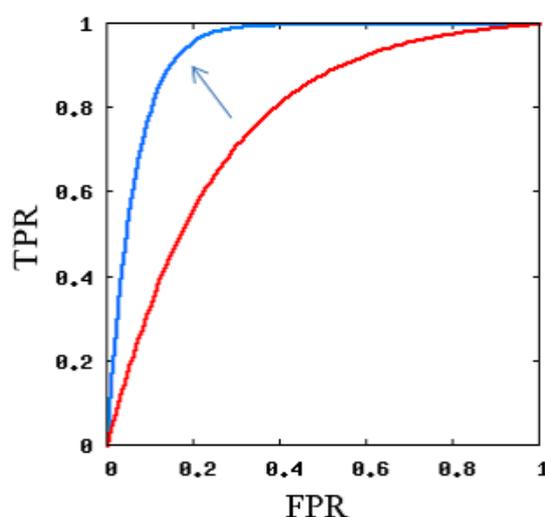


Fig. 5.4: 例：ROC カーブ

二値分類器の二値を陰性/陽性とすると，感度とは真値が陽性のものを陽性と出力する率である．この感度は別名を真陽性率（True Positive Rate）ともいう．ま

Table. 5.2: 混同行列

		真値	
		p	n
推定値	p'	True Positive : TP	False Positive : FP
	n'	False Negative : FN	True Negative : TN

た、陰性を陰性と出力する率を特異度と呼び、1-特異度が偽陽性率 (False Positive Rate) となる。

二値分類器では真値及び出力結果の場合により一般に4通りに分類することができる。分類結果を Table.5.2 に示す。このとき真陽性率 ( $TPR$ ) 及び偽陽性率 ( $FPR$ ) の算出式は 5.4.1 式となる。

$$TPR = \frac{TP}{TP + FN} \quad FPR = \frac{FP}{FP + TN} \quad (5.4.1)$$

ここで 5.4.1 式のうち  $FPR$  の導出式について注目すると、分母に  $TN$  が含まれていることがわかる。これに対して脇見検出に関する既存研究 [25] では、脇見行動のように頻繁に発生しない現象に対する推定において、ROC カーブは効果的にその能力を評価できないと言及している。つまり  $TP, FP, FN \ll TN$  が成り立つ場合、 $FPR$  は常に小さな値をとり続けるため、必然的にグラフは理想的な形をとってしまうのである。よって ROC カーブは本研究のシステムの評価を行うには不適當である。

#### 5.4.2 精度 (precision) /再現率 (recall) /F 値 (F-measure)

文献 [25] では、5.4.1 で挙げた問題点を考慮し、精度 (precision) /再現率 (recall) /F 値 (F-measure) という尺度でシステムを評価がなされた。この評価方法は、情報検索システムの検索性能の評価などによく用いられる手法である。精度とは、検出結果中に正解をどれだけ含んでいるかという正確性の指標であり、別名を適合度という。また再現率とは、真値が陽性であるもののうち、どれだけ検出できているかという網羅性の指標である。F 値とは、精度と再現率の調和平均である。一般にシステムの精度を上げれば再現率が下がり、再現率を上げれば精度が下がる傾向にあるため、それを合わせて評価するための指標として用いられる。三値はそれぞれ 1 に近いほど良い評価であることを意味する。それぞれの値の導出式を 5.4.2 に示す (5.2

参照)。

$$\begin{aligned}
 precision &= \frac{TP}{TP + FP} \\
 recall &= \frac{TP}{TP + FN} \\
 F - measure &= \frac{2 * precision * recall}{precision + recall}
 \end{aligned}
 \tag{5.4.2}$$

5.4.2 式より，この評価方法では TN を用いていないことがわかる．そのためこの評価方法は脇見検出のような頻繁に発生しない事柄を検出するのに適していると言える．以下本研究では，評価方法として精度/再現率/F 値を用いる．

## 5.5 実験 1：提案手法の有効性検証

本実験では，まず提案手法の有効性を確認するために，最もシンプルなモデルを用いて脇見状態の推定を行い，従来手法による脇見状態推定との比較を行った．従来手法には，顔向きの閾値化処理の結果を用いた．この閾値化で用いた閾値及びモデルの学習データの脇見状態の正解ラベル付けに用いた閾値  $\psi$  (5.2.1 式) は，従来研究 [33] での知見を参考に 10[deg] と設定した．使用データセットは (a) 東名大和サグコース，及び (b) 首都高速 3 号線コースを使用した．

### 5.5.1 使用モデル説明

本実験で用いた脇見推定モデルは，脇見状態が一次マルコフ過程に従い，且つ各時刻における脇見状態はその時刻の観測変数に影響を及ぼすという仮定のもとに構成したものである (Fig.5.5)．ここで， $X_t$  及び  $Z_t = \{Z_t^{(1)}, \dots, Z_t^{(N)}\}$  は時刻  $t$  における脇見状態及び観測量ベクトルを表す． $X_t$  は状態として OFF, ON } のいずれかの値をとる．また， $N$  は観測の種類数であり，各観測量  $Z_t^{(k)}$  は状態として連続量を離散化した離散値をとる．離散値の数は 3 値のウインカーを除く全観測変数共に 12 とする．使用する観測変数を Table.5.3 に示す．なおこれら観測変数は，従来研究 [35] の知見をもとに経験的に決定した．学習には，leave-one-out 法を用いる．

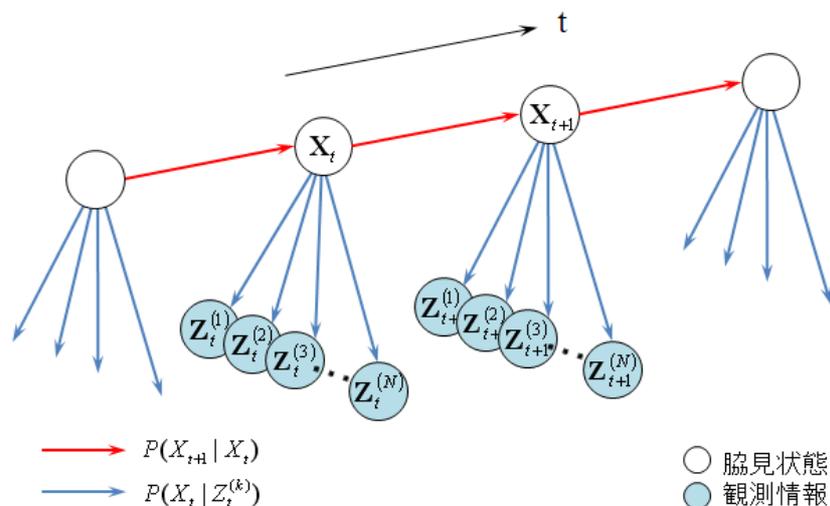


Fig. 5.5: 脇見推定 DBN モデル

Table. 5.3: 使用する観測量一覧

	観測量
運転操作	<ul style="list-style-type: none"> <li>・ステアリング角度 [deg]</li> <li>・アクセル踏み込み量 [%]</li> <li>・ブレーキ踏み込み量 [m]</li> <li>・左右ウインカー</li> </ul>
自車両状態	<ul style="list-style-type: none"> <li>・速度 [km/h]</li> <li>・加速度 [<math>m/s^2</math>]</li> <li>・センターラインとの角度 [rad]</li> <li>・センターラインとの距離 [m]</li> </ul>
ドライバ情報	<ul style="list-style-type: none"> <li>・頭部ヨー角 [deg]</li> </ul> (鉛直軸周り)

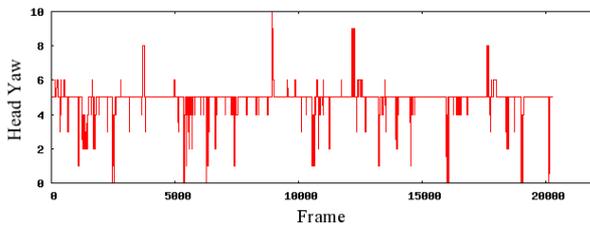
### 5.5.2 実験結果

実験結果例を 5.6, 5.7 に示す. なお, 図は上から順に (a) 頭部ヨー角 (離散値), (b) 従来手法 (頭部ヨー角の閾値化), (c) 提案手法による推定結果, (d) Ground Truth である. また, 推定結果で用いた  $P(X_t = ON | Z_{1:t})$  の閾値  $\xi$  は経験的に 0.8 とした.

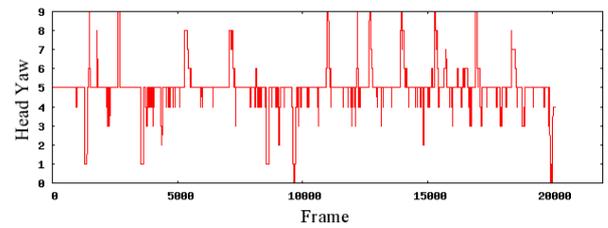
各例の従来手法による推定結果, 提案手法による推定結果, 及び Ground Truth を比較すると, 従来手法に比べ提案手法による推定結果のほうが過検出を抑制できていることがわかる.

次に被験者ごとに算出した平均精度/平均再現率/平均F値の比較図を Fig.5.8 ,Fig.5.9 に示す．縦軸は割合，横軸は被験者番号を表す．ここで Fig.5.8(b) 及び Fig.5.9(b) の再現率のグラフにおいて，従来手法の再現率が全て1となっているのは，頭部ヨ一角による閾値化を行う際に用いた閾値と，脇見状態の正解ラベル付けに用いた閾値  $\psi$  の値が同じためである．

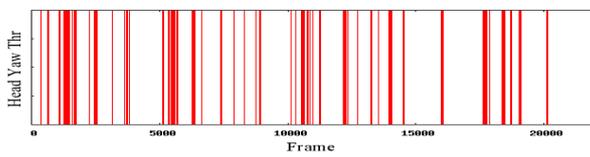
この結果から，多少の見落としのため再現率が低下するが，それ以上に精度が向上するため全体としてF値が従来手法を上回ることがわかった．これにより，頭部ヨ一角に加えてドライバの操作情報や自車両情報を考慮する本研究の提案手法の有効性が確認された．



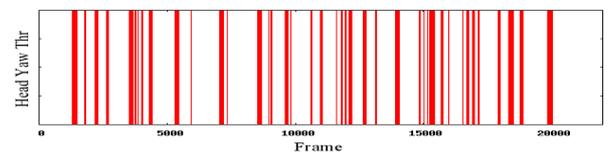
(a) 頭部ヨ一角 (離散値)



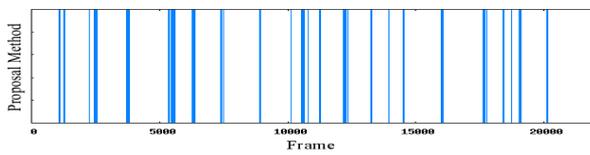
(a) 頭部ヨ一角 (離散値)



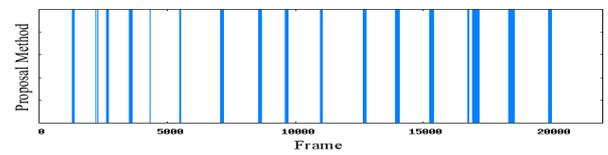
(b) 従来手法による推定結果



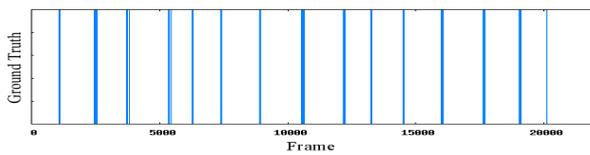
(b) 従来手法による推定結果



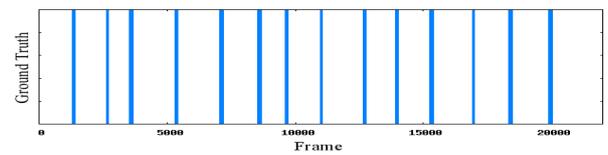
(c) 提案手法による推定結果



(c) 提案手法による推定結果



(d) Ground Truth



(d) Ground Truth

Fig. 5.6: 実験結果例 1 : 被験者 0 , (a) 東名大和サグコース

Fig. 5.7: 実験結果例 2 : 被験者 3 , (a) 東名大和サグコース

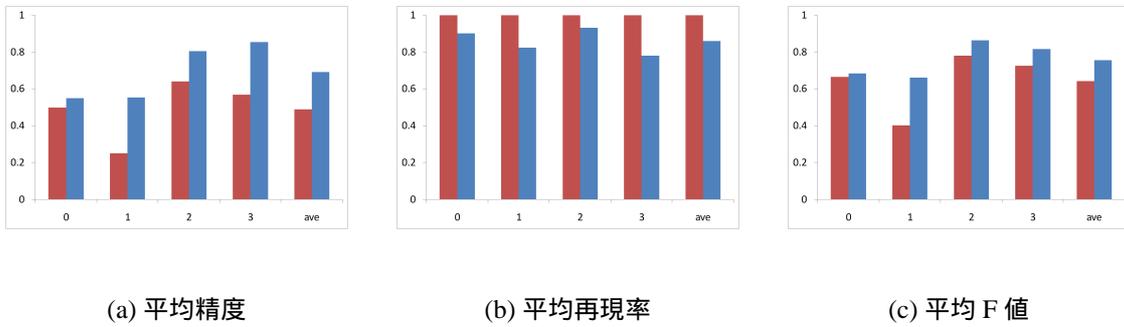


Fig. 5.8: 従来手法との比較結果：(a) 東名大和サグコース，赤：従来手法，青：提案手法

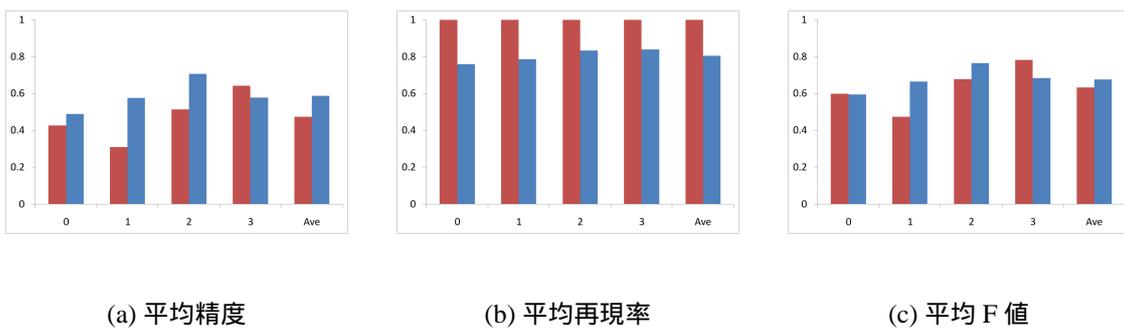


Fig. 5.9: 従来手法との比較結果：(b) 首都高速3号線コース，赤：従来手法，青：提案手法

Table. 5.4: 被験者間比較結果

	0	1	2	3
平均車線変更回数 [回]	19.6	27.8	8.3	11
頭部ヨー角の積算変位置 [deg/20000frames]	5736.18	8328.335	5538.312	4625.759
頭部ヨー角の分散値 [deg <sup>2</sup> /frame]	68.10599	200.007	205.6392	109.949

### 5.5.3 考察

#### 被験者間の精度差について

Fig.5.8(a)において，被験者間で提案手法による推定結果に差が出た．被験者0及び1は推定精度が6割弱であるのに対し，被験者2及び3は推定精度が8割強となっている．なぜこのような結果になったかについて考察する．

Table.5.4に(a)東名大和サグコースにおける各被験者の平均車線変更回数，頭部ヨー角の積算変位置，及び頭部ヨー角の分散値を示す．ここで頭部ヨー角の積算変位置とは，各フレーム間の頭部ヨー角の変位をデータ全体に対して積算し，フレーム数で割ったものに20000を掛けた値である(5.5.1式)．ただし $yaw_t$ は時刻 $t$ における頭部ヨー角値であり， $T$ はデータのフレーム数である．

$$(\text{積算変位置}) = \frac{\sum_{1 \leq t \leq T} |yaw_{t+1} - yaw_t|}{T} * 20000 \quad (5.5.1)$$

まず被験者間の車線変更回数の着目すると，被験者0及び1の一走行あたりの車線変更回数は，被験者2及び3の車線変更回数と比較してかなり多い．この結果から，被験者0及び1の走行中の安全確認回数が被験者2及び3よりもかなり多いと予想される．次に頭部ヨー角の積算変位置に着目すると，被験者0及び1の積算変位置が残りの被験者よりも大きくなっている．被験者1に関しては，被験者2と頭部ヨー角の分散値がほぼ変わらないことから，被験者1は被験者2よりも多数の安全確認をしていると考察できる．また被験者0は一見積算変位置はあまり大きくないが，頭部ヨー角の分散値が他の被験者よりかなり低い値なので，多数の安全確認をしていると考察できる．車線変更時の安全確認は運転中に必要な首振り動作であり，脇見状態に対して誤検出を生じる対象であると考えられる．このことから，車線変更及び安全確認回数の個人差が，推定精度の個人差に影響を与えたと考える．

### コースの精度差について

Fig.5.8, Fig.5.9 について比較をすると (a) 東名大和サグコースに比べて, (b) 首都高速3号線コースのデータにおける精度のほうが被験者4名通じて低くなっている。これは, ドライバの置かれる環境がより複雑になり多様な条件下での安全確認の必要性が増えたためと考えられる。

また 5.9(a) では, 被験者3の精度が従来手法の精度を下回っている。これは全8走行のうち1走行においてFPの数が異常に大きくなったため平均にも影響が及んだ結果である 5.10。この現象の原因はカーブ走行時の頭部ヨー角である。急なカーブを走行時は, 進行方向に対してドライバの意識が集中するため, 頭部ヨー角が前方正面よりやや左右に偏った分布をとり, 離散化によってそれが脇見と判断されたわけである。

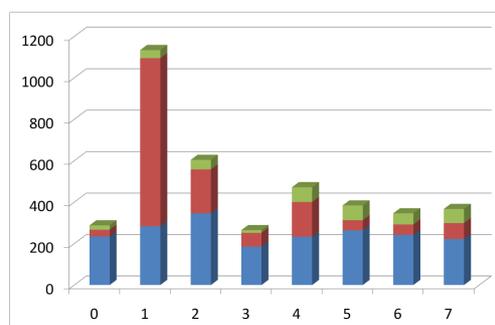


Fig. 5.10: 被験者3：各走行時の TP,FP,FN

### 観測量について

次に, 本実験で得られた各被験者ごとの観測確率 (観測行列) について考察する。脇見状態であるときと通常状態のときに観測確率を比較し両者に差があるとき, その観測量はその被験者の脇見状態を推定するのに有効な観測量であると言える。また, 被験者間で共通して脇見状態を特徴づける観測量を見出すことができれば, 脇見状態推定の汎用化に役立つ知見となる。

まず被験者4名に対する頭部ヨー角の観測確率分布を Fig.5.11 に示す。横軸は離散化時のヨー角値 [deg] である。Fig.5.11 を見ると, 通常状態の頭部ヨー角は比較的中心付近に密集しており, この状態で安全確認を行えば, 頭部ヨー角のみでは脇見状態と判定される可能性が高いことがわかる。

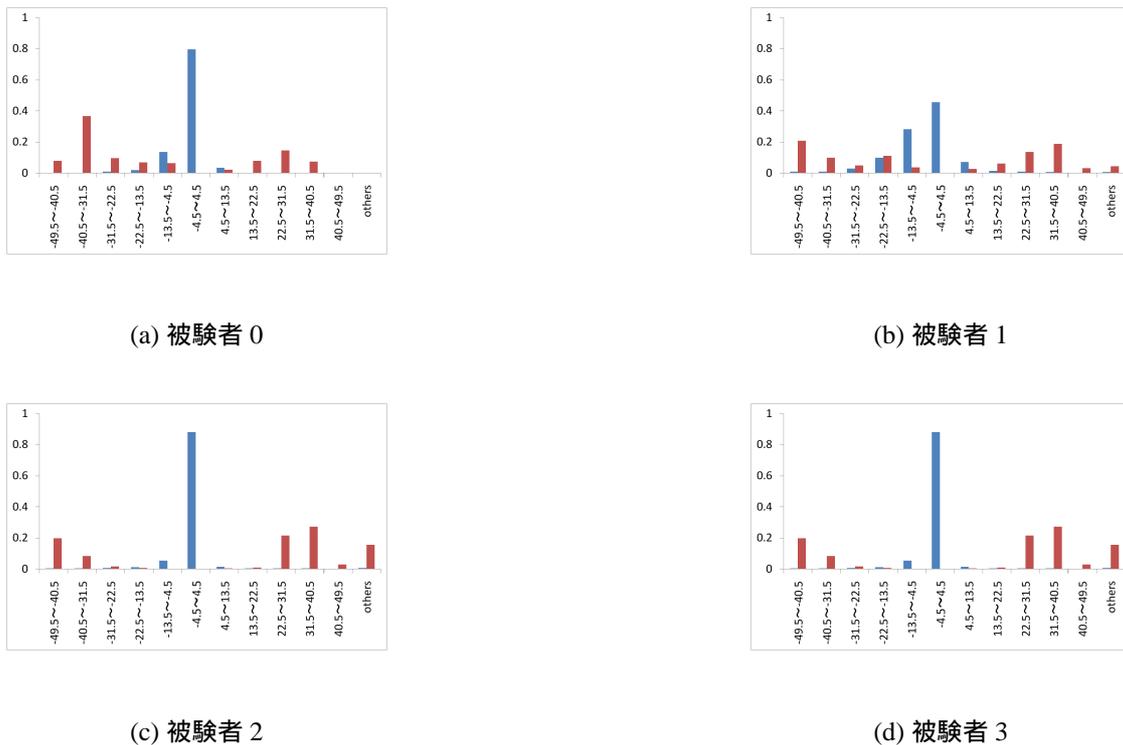
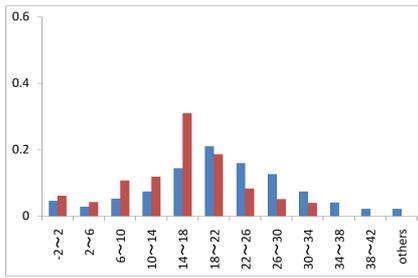
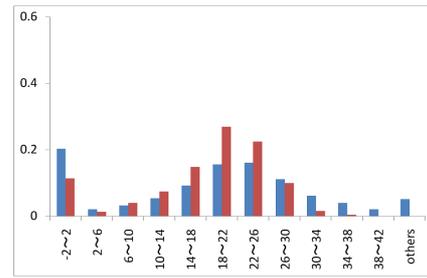


Fig. 5.11: 頭部ヨー角 [deg] の観測確率分布，青：通常状態，赤：脇見状態

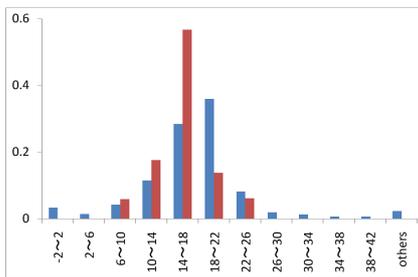
次に各被験者に共通して脇見を特徴づける観測量について考察する．まず各被験者のアクセルペダルの踏み込み量の観測確率分布を Fig.5.12 に示す．横軸は離散化時のアクセル踏み込み量 [%] である．各被験者で多少の差はあるものの，踏み込み量の少ない分布では脇見状態の尤度（尤もらしさ）が通常状態を上回っている．これは脇見状態では無意識にドライバのアクセル踏み込み量が通常状態よりも弱まっていると考えることができる．次にハンドル角速度の観測確率分布を Fig.5.13 に示す．通常状態と脇見状態のハンドル角速度の分布を比較すると，脇見状態のハンドル角速度の分布はより中心付近に集中しているのが見て取れる．これは注視対象に注意が向いた状態で，ハンドル操作が疎かになりハンドルが止まっている状態が続いたためと考えられる．またその他にウインカーの観測確率分布（Fig.5.14）では，左右ウインカーを提示中では通常状態のみ観測されており，車線変更時の安全確認の誤検出抑制に貢献していると考えられる．車線変更中にドライバは脇見をしないと仮定すれば，車線変更状態をウインカーの状態量及びその他の観測量で学習することによりシステムの更なる精度向上に有効であると考えられる．



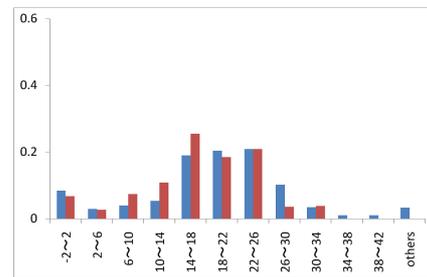
(a) 被験者 0



(b) 被験者 1

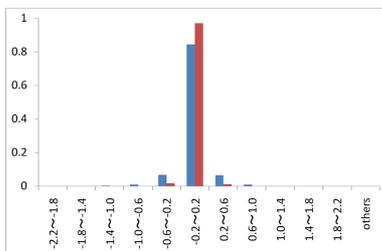


(c) 被験者 2

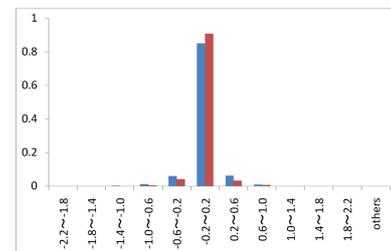


(d) 被験者 3

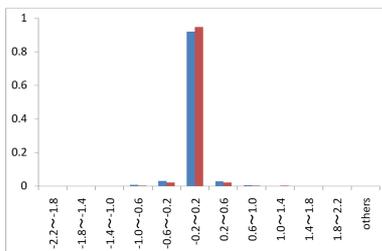
Fig. 5.12: アクセルペダル [%] の観測確率分布，青：通常状態，赤：脇見状態



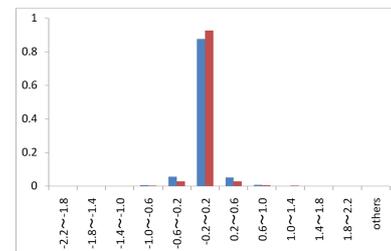
(a) 被験者 0



(b) 被験者 1

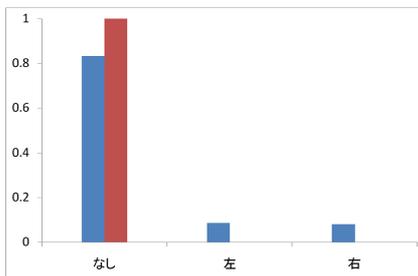


(c) 被験者 2

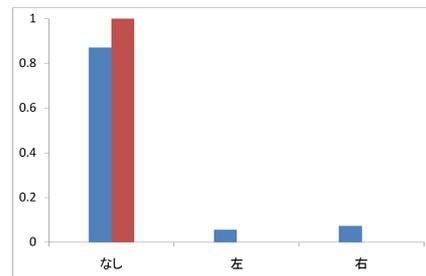


(d) 被験者 3

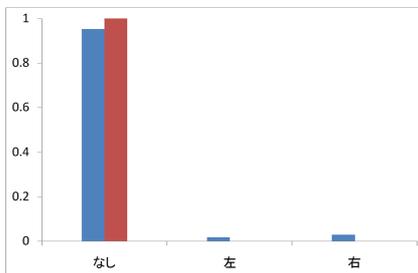
Fig. 5.13: ハンドル角速度 [deg/frame] の観測確率分布，青：通常状態，赤：脇見状態



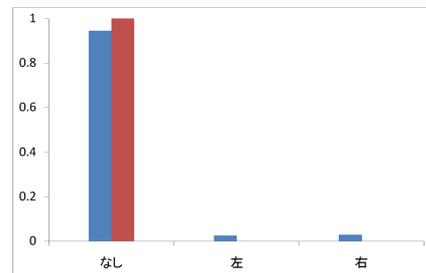
(a) 被験者 0



(b) 被験者 1



(c) 被験者 2



(d) 被験者 3

Fig. 5.14: ウィンカーの観測確率分布，青：通常状態，赤：脇見状態

## 5.6 実験2：視線方向情報の利用

ドライバは運転中に様々な情報を視覚から取得する．その過程でドライバは各種ミラーなど特定の方向を注視する．よって視線方向と運転行動の間には何らかの関係があることが予想される．また，熟練したドライバであればミラーなどを注視する際にとる首振り行動は一定であり，頭部ヨー角と視線方向にも関係性が見られることが予想される．そこで本実験では，頭部ヨー角に対して視線方向という概念を導入しその有効性を検証する．なお，本実験では走行時に撮影したビデオ画像を用いて人による手作業の視線方向の正解ラベル付けを行った．このラベル付けは作業量が膨大になるため，被験者2名（被験者0及び1）に対して(b)首都高速3号線コースの走行データ4走行について学習と評価を行った．学習方法は，leave-one-out法を用いた．

### 5.6.1 使用モデル説明

使用したモデルを Fig.5.15 に示す．主な変更点は頭部ヨー角及び脇見状態の間に視線方向状態ノードが挟まれた点である．なお，頭部ヨー角及び視線方向状態は共に離散値をとるものとする．視線方向の離散値は前方，バックミラー，左右サイドミラー，右方，左方の計6値である．なおビデオ画像を用いた手作業による視線方向のラベル付けでは，バックミラー，左右サイドミラーについてラベル付けを行った後，その他のフレームについて進行方向より左右 15[deg] 以内を前方とし，それより右を右方，左を左方と定義した (Fig.5.16)．このモデルを使用したときの脇見状態確率の算出式は 5.6.1 になる．

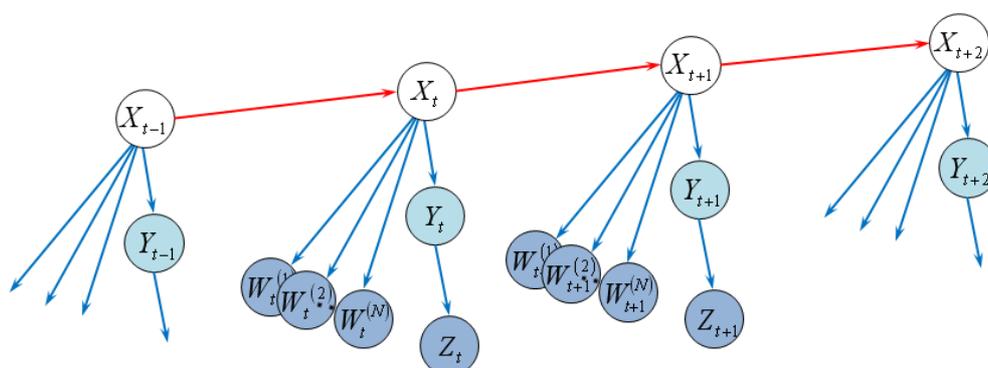


Fig. 5.15: 脇見推定 DBN モデル：視線

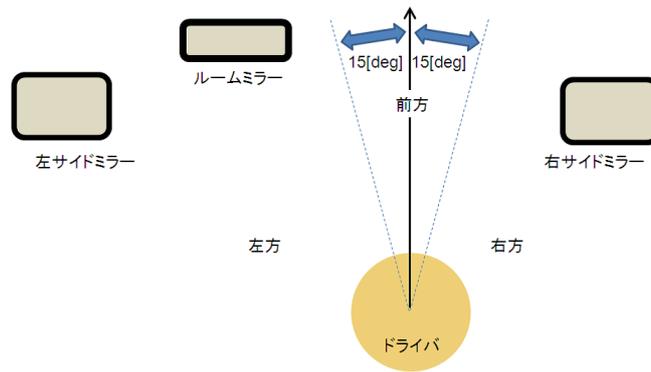


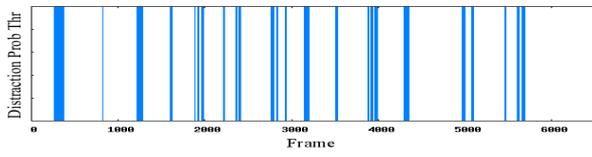
Fig. 5.16: 視線方向定義

$$\begin{aligned}
 & P(X_{t+1} | \mathbf{W}_{1:t+1}, Z_{1:t+1}) \\
 &= P(X_{t+1} | \mathbf{W}_{t+1}, Z_{t+1}, \mathbf{W}_{1:t}, Z_{1:t}) \\
 &= \alpha P(\mathbf{W}_{t+1}, Z_{t+1} | X_{t+1}) P(X_{t+1} | \mathbf{W}_{1:t}, Z_{1:t}) \\
 &= \alpha P(\mathbf{W}_{t+1} | X_{t+1}) P(Z_{t+1} | X_{t+1}) \sum_{x_t} P(X_{t+1} | x_t) P(x_t | \mathbf{W}_{1:t}, Z_{1:t}) \\
 &= \alpha \prod_k P(W_{t+1}^{(k)} | X_{t+1}) \sum_{y_{t+1}} \{P(Z_{t+1} | y_{t+1}) P(y_{t+1} | X_{t+1})\} \sum_{x_t} P(X_{t+1} | x_t) P(x_t | Y_{1:t}, Z_{1:t})
 \end{aligned} \tag{5.6.1}$$

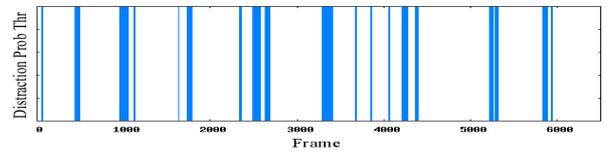
### 5.6.2 実験結果

実験結果例を 5.17, 5.18 に示す．なお，図は上から順に (a) 視線未使用モデル推定結果，(b) 視線使用モデル推定結果，(c) Ground Truth である．また，推定結果で用いた  $P(X_t = \text{ON} | \mathbf{Z}_{1:t})$  の閾値  $\xi$  は経験的に 0.8 とした．

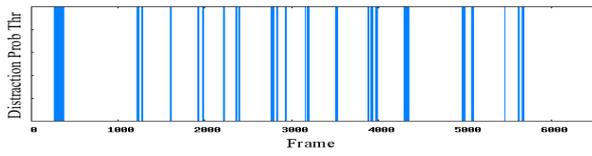
また，被験者 2 名の平均精度，平均再現率，平均 F 値を Fig.5.19 に示す．2 被験者とも再現率において多少の値の減少が見られるものの精度が向上したため，F 値は視線を用いた提案手法の方が良い結果となった．



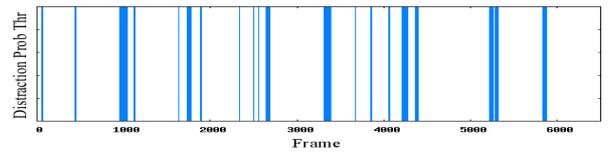
(a) 視線未使用モデル推定結果



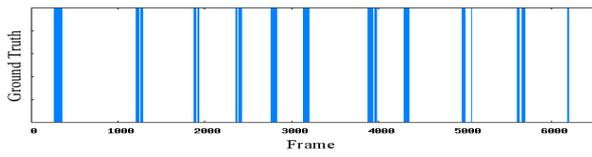
(a) 視線未使用モデル推定結果



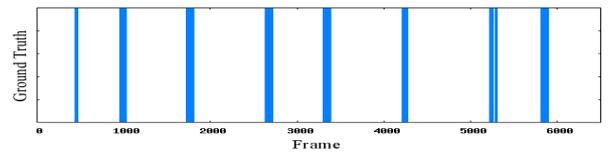
(b) 視線使用モデル推定結果



(b) 視線使用モデル推定結果



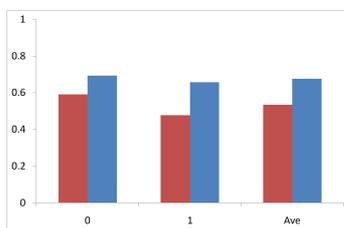
(c) Ground Truth



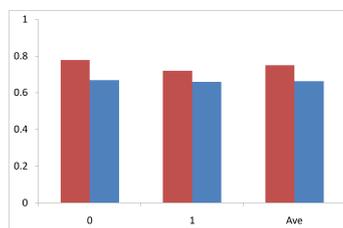
(c) Ground Truth

Fig. 5.17: 実験結果例 1 : 被験者 0

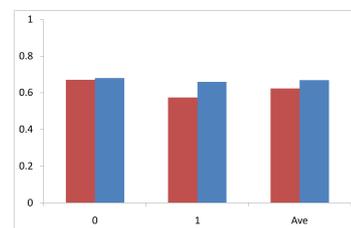
Fig. 5.18: 実験結果例 2 : 被験者 1



(a) 平均精度



(b) 平均再現率



(c) 平均 F 値

Fig. 5.19: 視線未使用/使用比較結果，赤：未使用，青：使用

### 5.6.3 考察

#### 再現率の低下について

5.19(b)の被験者2名の再現率について、視線方向の概念を導入前後での値の低下の原因を考察する。本実験で用いたモデルでは、視線方向は隠れ状態として扱った。そのため、学習時には各フレームにおける視線方向の値を用いているが、評価時には頭部ヨー角の離散値、 $P(Z_{t+1}|Y_{t+1})$ 、及び $P(Y_{t+1}|X_{t+1})$ から $P(Z_{t+1}|X_{t+1})$ を算出している。この作業は、頭部ヨー角から現在の視線方向を推定し、その視線方向の推定値から脇見状態の尤度を決定していると考えられる。本実験で用いた視線方向の定義では、右方及び左方の定義領域は完全に左右サイドミラーの分布領域を包含する形になっている。このとき右方及び左方の分布領域よりも左右サイドミラーの分布領域のほうが分散が小さい分、その領域では尤度が高くなり結果としてより脇見状態と判断される確率が低くなったと考えられる。

## 5.7 実験3：ラベル付けを使用しない視線方向情報の利用

第5.6節では、視線方向情報を利用することにより提案手法の性能が向上することを示した。しかし、ビデオ画像からの手作業による視線方向のラベル付けは、全ての学習データについて行った場合大変な作業量となる。そこで本実験では、視線方向の分布にある仮定を導入することで、手作業による視線方向のラベル付けを行わずにモデルの観測確率の獲得をする手法を提案し、評価を行う。なお、実験には(a)東名大和サグコース、及び(b)首都高速3号線コースでの走行データ(被験者4名)を使用し、学習にはleave-one-out法を用いて評価を行った。

### 5.7.1 使用モデル説明

使用したモデルをFig.5.20に示す。本実験で用いるモデルでは、頭部ヨー角と視線方向の間の観測確率 $P(Z_t|Y_t)$ にガウス分布を仮定することにより、予め視線方向ごとの学習データを準備し、個別に学習した。視線方向は第5.6節同様離散値を用いるが前述の仮定により頭部ヨー角は離散値を用いる必要性がなくなるため、連続量をそのまま用いた。視線方向のとり離散量は、前方、バックミラー、左サイドミラー、左窓方向、右サイドミラー、右窓方向の6値である。なお、頭部ヨー角と視

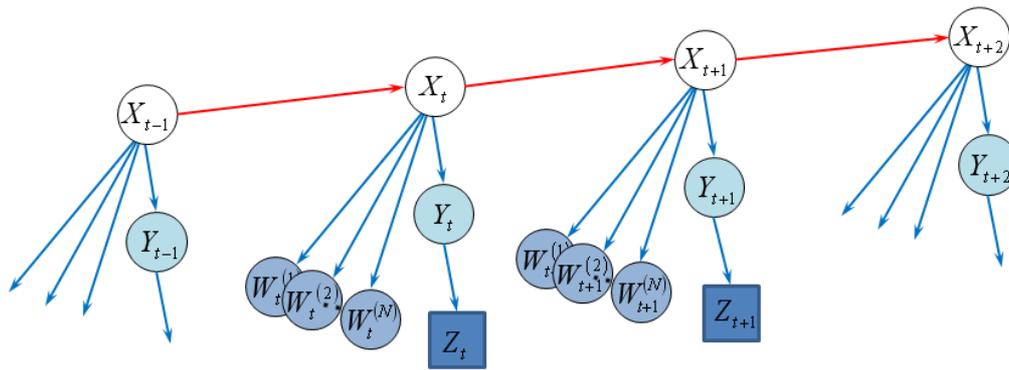


Fig. 5.20: 脇見推定 DBN モデル：視線（ラベルなし）

線方向の間の観測確率  $P(Z_t|Y_t)$ ，及び視線方向と脇見状態の間の観測確率  $P(Y_t|X_t)$  の学習方法の詳細については，5.7.2 で説明する．

脇見状態確率の算出式は，5.6.1 式と同じであるが， $P(Z_t|Y_t)$  はガウス分布を仮定するので，

$$P(Z_t = yaw_t | Y_t = y^{(i)}) = \frac{1}{\sqrt{2\pi}\sigma_i} \exp\left(-\frac{(yaw_t - \mu_i)^2}{2\sigma_i^2}\right) \quad (5.7.1)$$

と表すことができる．ここで  $yaw_t$  は時刻  $t$  における頭部ヨー角の値， $y^{(i)}$  は視線方向の離散値， $\mu_i$ ， $\sigma_i$  はそれぞれ各視線方向ごとの頭部ヨー角の平均と標準偏差である．頭部ヨー角と視線方向の間の観測確率  $P(Z_t|Y_t)$  を学習することは，各視線方向ごとの頭部ヨー角の平均と標準偏差を学習により獲得することと同値である．

### 5.7.2 視線に関する学習方法

頭部ヨー角と視線方向の間の観測確率  $P(Z_t|Y_t)$  の学習

本実験では，頭部ヨー角と視線方向の間の観測確率  $P(Z_t|Y_t)$  を獲得するために視線方向ごとに学習データを取得する実験を行った．具体的には，被験者にドライビングシミュレータの運転席に乗車させ，一定時間間隔で前方と特定視線方向とを交互に注視したときの被験者の頭部のヨー角データを取得するというものである．ここで特定視線方向データ取得に対して前方を見る動作を挟んだ理由は，より自然な流れの中での頭部ヨー角の動きをとらえた学習データを取得するためである．そのデータのうち各視線方向間の過渡期にあたるデータを除いた残りのデータを前方及び特定視線方向の頭部ヨー角の分布データとし平均及び分散を計算した．取得頭部

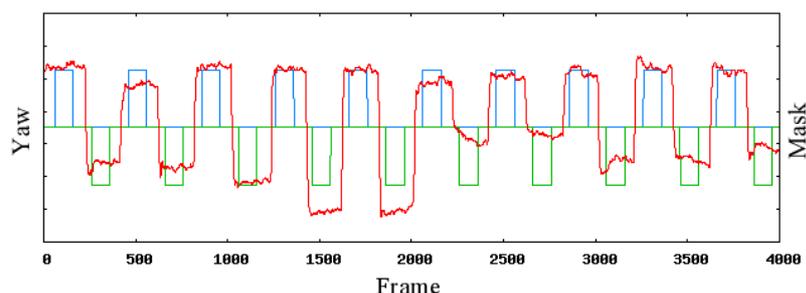


Fig. 5.21:  $P(Z_t|Y_t)$  学習用データ例：前方及びバックミラー

ヨー角データ，及びそのデータに対するサンプリング用マスクの図を Fig.5.21 に示す．ここでサンプリング用マスクとは，値が0でないフレームに対して学習データとしてより分けて取得するためのフラグである．なお横軸はフレーム番号であり，赤が頭部ヨー角，青が前方用学習データ取得マスク，緑がバックミラー用学習データ取得マスクである．

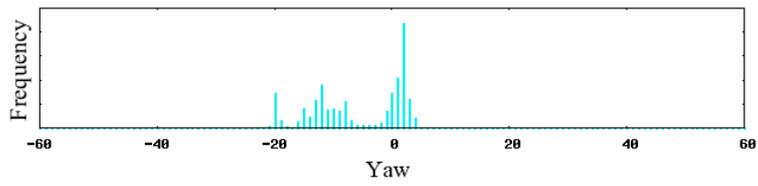
次に実際に各視線方向別に取得した学習データの頭部ヨー角度数分布グラフを Fig.5.22 に示す．横軸は頭部ヨー角 [deg] であり，縦軸は各頭部ヨー角値の度数分布である．Fig.5.22 を見る限り，視線方向ごとの頭部ヨー角の分布をガウス分布で仮定することは妥当であると考えられる．

#### 視線方向と脇見状態の間の観測確率 $P(Y_t|X_t)$ の学習

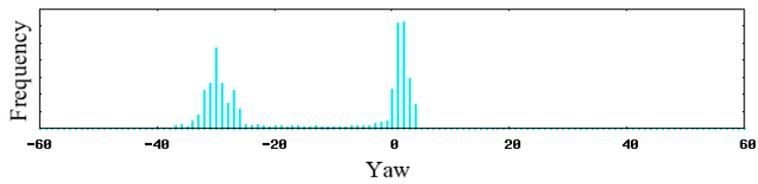
本研究では，観測確率の学習は第 3.2 節で説明したように正解ラベルを用いた教師付き学習を行った．しかし，この視線方向と脇見状態の観測確率  $P(Y_t|X_t)$  の学習では，視線方向の正解ラベルがないため完全な教師付き学習を行うことはできない．そこで本実験では，各フレームにおいて視線方向は先に定義した 6 値のどれかをとると仮定した上で，頭部ヨー角及び既に学習済みの頭部ヨー角と視線方向の間の観測確率  $P(Z_t|Y_t)$  から，視線方向の期待値を計算しそれを正解ラベルの代わりに用いて視線方向と脇見状態の観測確率  $P(Y_t|X_t)$  の学習を行う手法を提案する．

$P(Y_t|X_t)$  の具体的な算出式は，

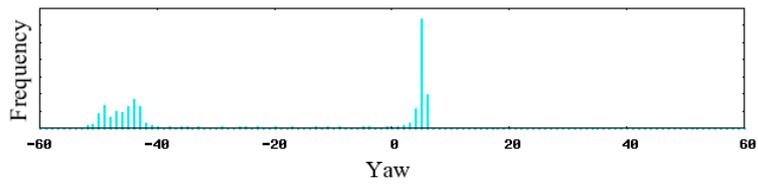
$$E_{t,i}(X_t = j)_{j \in \{\text{OFF}, \text{ON}\}} = \begin{cases} P(Z_t = yaw_t | Y_t = y^i) P(Y_t = y^i), & \text{if } (X_t = j) \\ 0, & \text{otherwise} \end{cases} \quad (5.7.2)$$



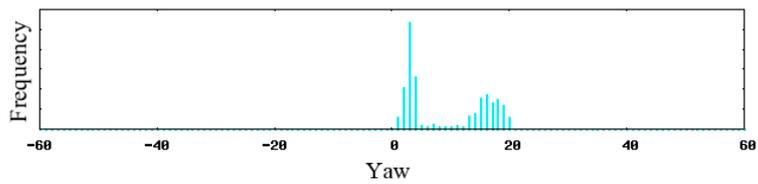
(a) 前方及びバックミラー



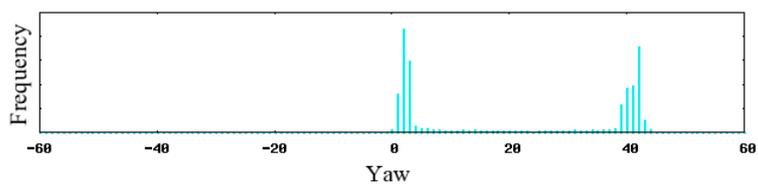
(b) 前方及び左サイドミラー



(c) 前方及び左窓方向



(d) 前方及び右サイドミラー



(e) 前方及び右窓方向

Fig. 5.22: 視線方向学習データの度数分布グラフ

$$P(Y_t = y^i | X_t = j)_{j \in \{\text{OFF}, \text{ON}\}} = \frac{\sum_{k=i} E_{t,k}(X_t = j)}{\sum_{i=\{1,2,3,4,5,6\}} \{\sum_{k=i} E_{t,k}(X_t = j)\}} \quad (5.7.3)$$

となる。つまり、隠れ状態ごとに各視線方向ごとの全フレームにおける期待値の総和を求め、それを隠れ状態ごとに全体の期待値の総和で正規化を行うことで  $P(Y_t | X_t)$  は算出される。なお、5.7.2における各視線方向の事前確率  $P(Y_t = y^i)$  は、本実験では事前知識がないため一様分布とした。

### 5.7.3 実験結果

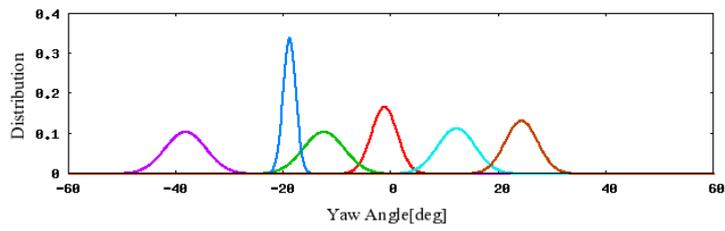
頭部ヨ一角と視線方向の間の観測確率  $P(Z_t | Y_t)$  の学習結果、及び実験結果例を Fig.5.23, Fig.5.24 に示す。また、被験者ごとのシステム性能比較結果を Fig.5.25, Fig.5.26 に示す。本実験結果では、視線情報（ラベルを用いない学習）の導入前後での精度及び再現率の増減は被験者ごとに異なる結果となった。また被験者全体での平均 F 値は (b) 首都高速 3 号線コースでは増加したものの、(a) 東名大和サグコースでは視線情報を導入後に若干値が減少した。

### 5.7.4 考察

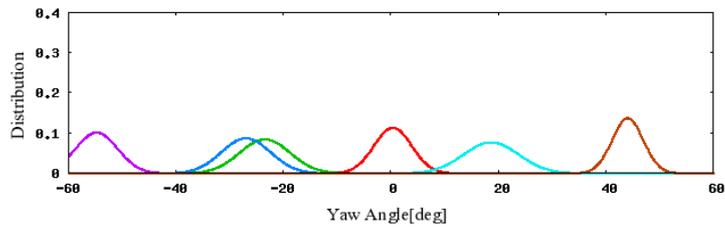
被験者間の精度変化の違いについて

Fig.5.25 では、被験者 2 及び 3 では視線情報の導入時にあまり変化は現れなかったが、被験者 0 及び 1 ではそれぞれ如実に変化が現れた。被験者 0 は視線情報の導入により精度が向上したが、被験者 1 では逆に精度が悪化した。この現象の理由について考察する。

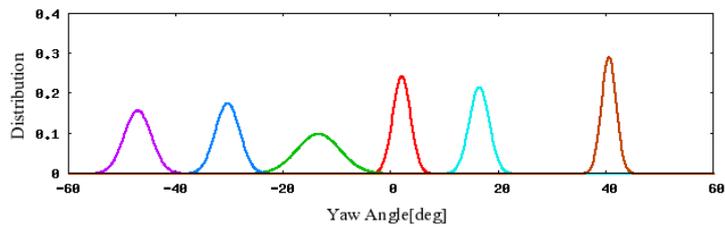
被験者 0 及び 1 の視線方向と脇見状態の間の観測確率  $P(Y_t | X_t)$  の学習結果を Fig.5.27 に示す。本研究では、脇見発生用ターゲットは首を振らなければ目視できない位置に提示されているので、脇見状態における視線方向の分布は左右窓方向に高い値をとるのが理想的である。被験者 0 では脇見状態は大よそ理想的な分布になっているのに対し、被験者 1 では脇見状態はどの視線方向もほぼ一様となり、本来は安全確認をするために目視するミラーでさえも脇見状態に大きく偏った分布になっている。これが視線方向の導入に際して精度の向上/悪化を分けた原因であると考えられる。



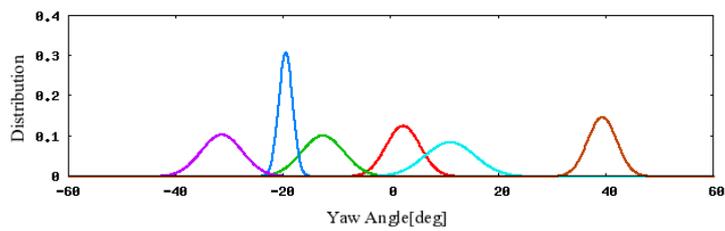
(a) 被験者 0



(b) 被験者 1

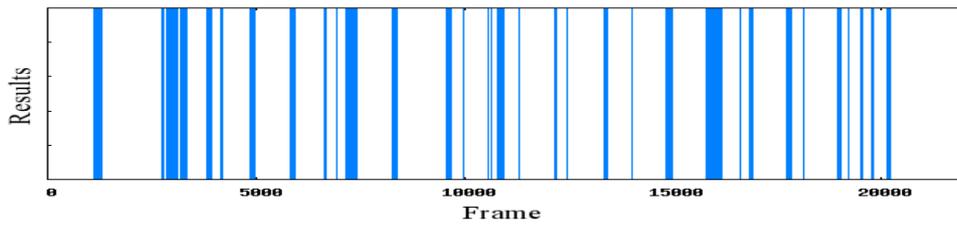


(c) 被験者 2

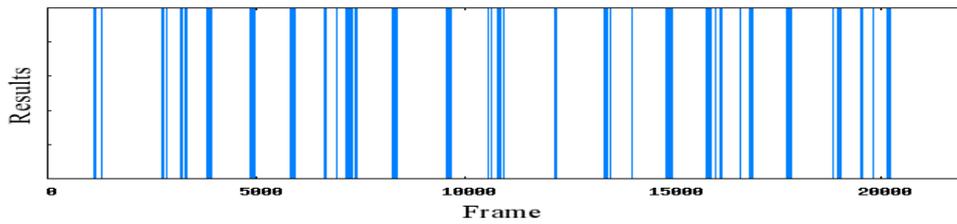


(d) 被験者 3

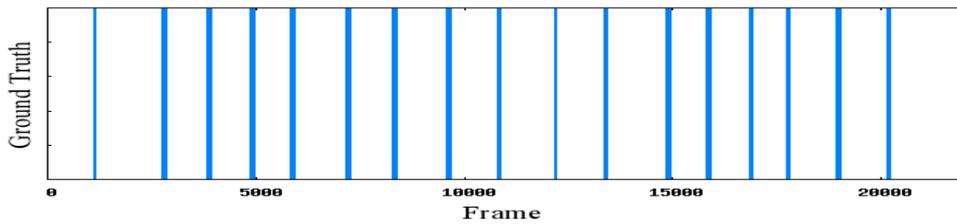
Fig. 5.23: 頭部ヨー角と視線方向の間の観測確率  $P(Z_t|Y_t)$  の学習結果  
 赤：前方，緑：バックミラー，青：左サイドミラー，紫：左窓方向，水色：右  
 サイドミラー，茶：右窓方向



(a) 視線方向情報なし

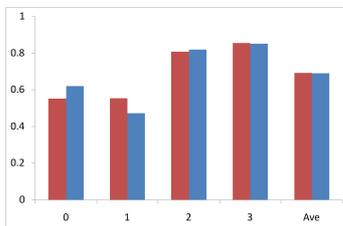


(b) 視線方向情報あり

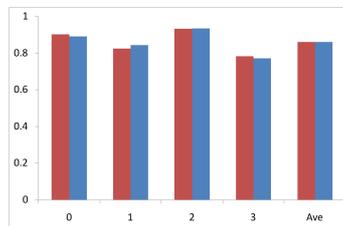


(c) Ground Truth

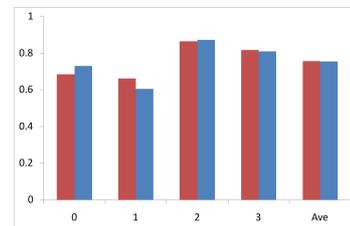
Fig. 5.24: 実験結果例：被験者0，(a) 東名大和サグ



(a) 平均精度



(b) 平均再現率



(c) 平均 F 値

Fig. 5.25: 視線未使用/使用比較結果，(a) 東名大和サグ，赤：未使用，青：使用

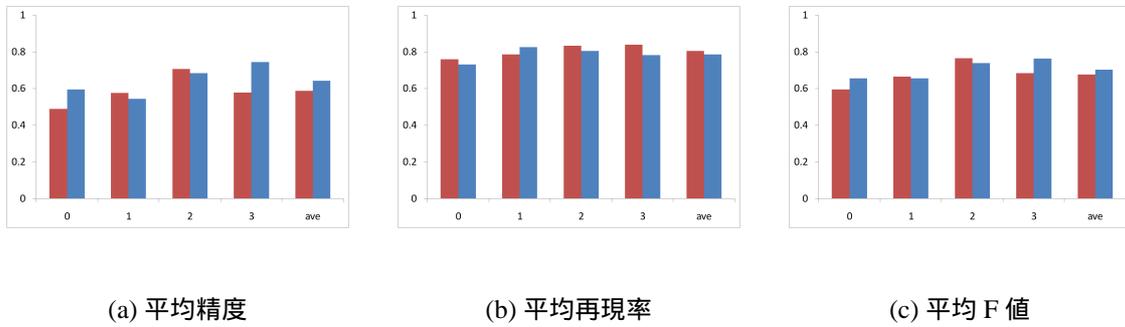


Fig. 5.26: 視線未使用/使用比較結果, (b) 首都高速3号線, 赤: 未使用, 青: 使用

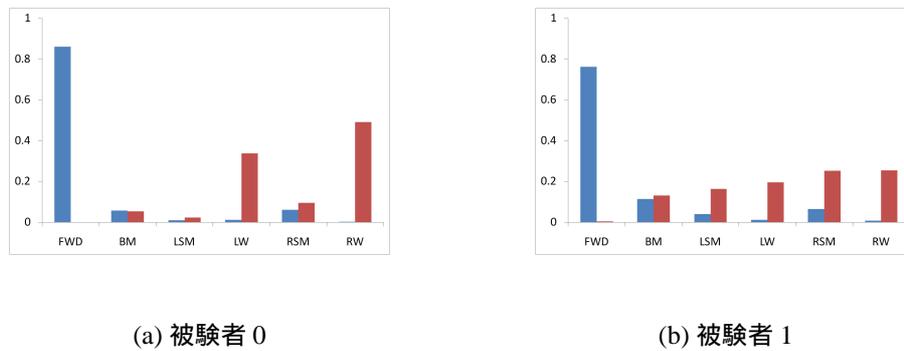


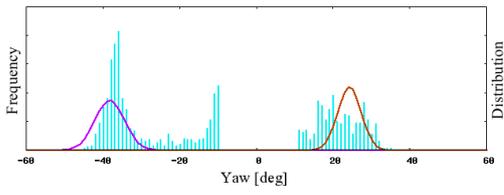
Fig. 5.27: 視線方向と脇見状態の間の観測確率  $P(Y_t|X_t)$  の学習結果, 青: 通常状態, 赤: 脇見状態, FWD: 前方, BM: バックミラー, LSM: 左サイドミラー, LW: 左窓方向, RSM: 右サイドミラー, RW: 右窓方向

被験者1の $P(Y_t|X_t)$ の学習結果について

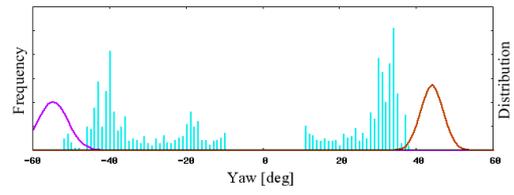
次に被験者1の視線方向と脇見状態の間の観測確率 $P(Y_t|X_t)$ がほぼ一様の分布となった原因について考察する。そこでFig.5.28に被験者0及び1の頭部ヨー角と視線方向の間の観測確率 $P(Z_t|Y_t)$ の学習結果（左右窓方向）と脇見状態における頭部ヨー角の度数分布の比較図を示す。

Fig.5.28を見ると、被験者0ではほぼ走行時の脇見状態の頭部ヨー角の分布と頭部ヨー角と視線方向の間の観測確率 $P(Z_t|Y_t)$ の学習結果で一致しているが、被験者1ではそれらがほとんど重ならず、適切な学習ができていないことがわかる。

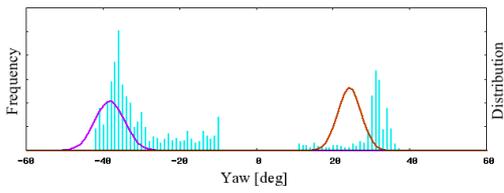
被験者1では、頭部ヨー角と視線方向の間の観測確率 $P(Z_t|Y_t)$ が実際の頭部ヨー角の分布と異なっていたために、脇見状態時の頭部ヨー角に対して適切な視線方向の推定がなされず、左右窓方向を実際に注視していても左右サイドミラーを注視していると誤認識され、結果として視線方向と脇見状態の間の観測確率 $P(Y_t|X_t)$ がほぼ一様の分布となったと考えられる。



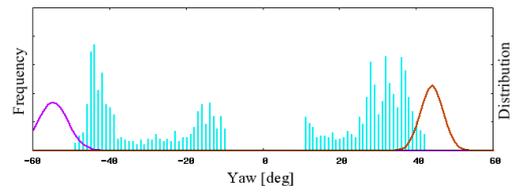
(a) 被験者 0 : 走行 0



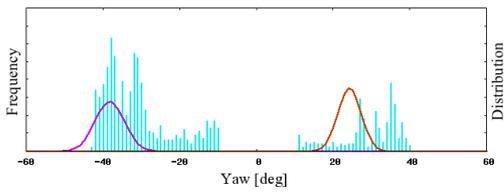
(f) 被験者 1 : 走行 0



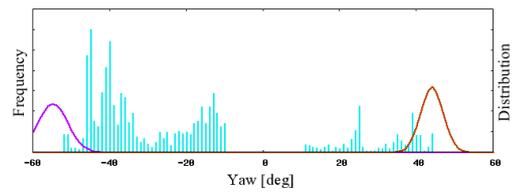
(b) 被験者 0 : 走行 1



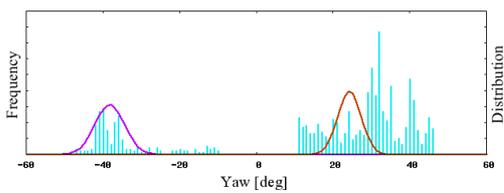
(g) 被験者 1 : 走行 1



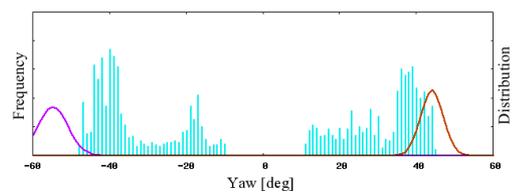
(c) 被験者 0 : 走行 2



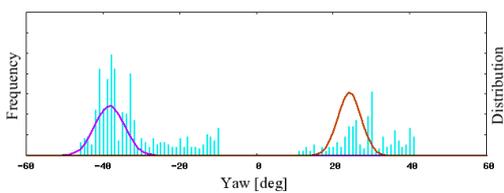
(h) 被験者 1 : 走行 2



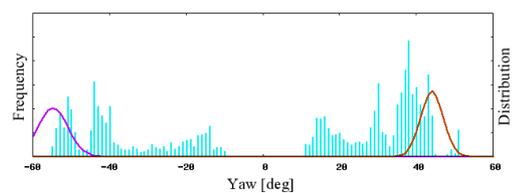
(d) 被験者 0 : 走行 3



(i) 被験者 1 : 走行 3



(e) 被験者 0 : 走行 4



(j) 被験者 1 : 走行 4

Fig. 5.28:  $P(Z_t|Y_t)$  及び脇見状態における頭部ヨ一角の度数分布の比較，紫：左窓方向，茶：右窓方向

## 5.8 実験4：安全確認状態の導入

第5.5節から第5.7では、隠れ状態を通常状態 ( $X_t = \text{OFF}$ ) と脇見行動をとっている状態 ( $X_t = \text{ON}$ ) に分けて学習と評価を行った。ここで本研究の目的に立ち返ると、その目的は脇見状態を安全確認などの運転に必要な首振り行動と分けて適切に検出することであるが、先に定義した通常状態には安全確認行動を行っている状態と特にそのような行動を行わず通常の運転を行っている状態が混在していることになる。

そこで本実験では隠れ状態を通常状態 ( $X_t = 0$ )、脇見行動をとっている状態 ( $X_t = 1$ )、及び安全確認行動をとっている状態 ( $X_t = 2$ ) とする。

使用したデータセットは(a)東名大和サグコースの走行データで、学習には leave-one-out 法を用いた。

### 5.8.1 実験1との違い

実験1との明確な違いは、学習データの脇見状態正解ラベルの定義である。脇見状態の正解ラベルの定義式を5.8.1に示す。具体的には、頭部ヨー角の絶対値が閾値  $\psi$  以上で、且つターゲットが提示中であれば脇見状態 ( $X_t = 1$ )、ターゲットが提示中でなければ安全確認状態 ( $X_t = 2$ )、その他を通常状態 ( $X_t = 0$ ) とするものである。学習データラベルの定義の違いを表す図を Fig.5.29 に示す。

$$X_t = \begin{cases} 1, & \text{if}\{(|yaw| \geq \psi)\text{and}(Target = \text{ON})\} \\ 2, & \text{if}\{(|yaw| \geq \psi)\text{and}(Target = \text{OFF})\} \\ 0, & \text{otherwise} \end{cases} \quad (5.8.1)$$

### 5.8.2 実験結果

実験結果例、及びシステムの性能比較結果を Fig.5.32, Fig.5.30, Fig.5.31 に示す。(a) 東名大和サグコースでの走行データでは、被験者0及び1では頻繁に安全確認をしていたために、安全確認状態を導入していないモデルでは精度良く検出できていなかったが、安全確認状態を導入したことでこれら被験者に対して大幅に精度向上が見られた。しかし、(b) 首都高速3号線での走行データでは、精度に向上が見られるものの再現率で悪化が見られ結果としてF値ではシステムの向上が見られなかった。

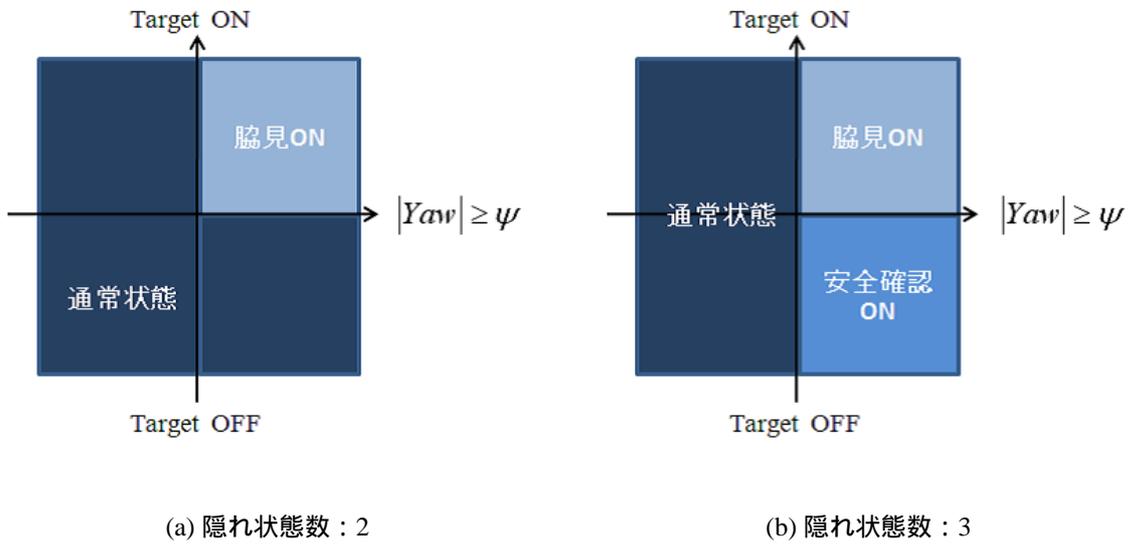


Fig. 5.29: 学習データの隠れ状態正解ラベル定義

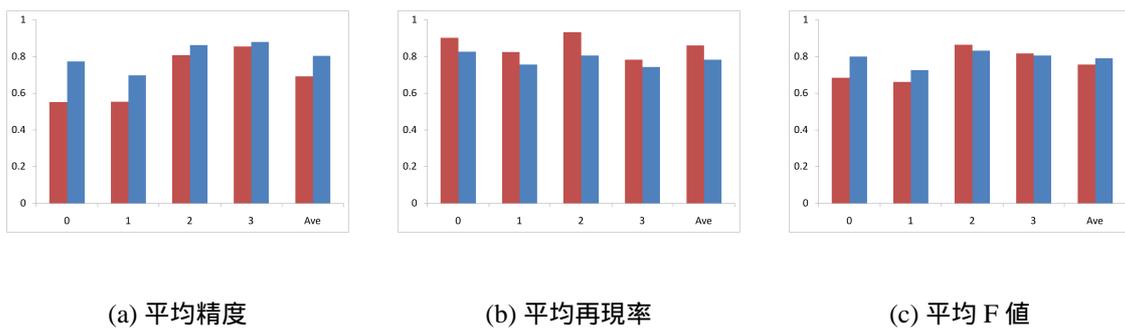


Fig. 5.30: 安全確認状態未使用/使用比較結果, (a) 東名大和サグ, 赤: 未使用, 青: 使用

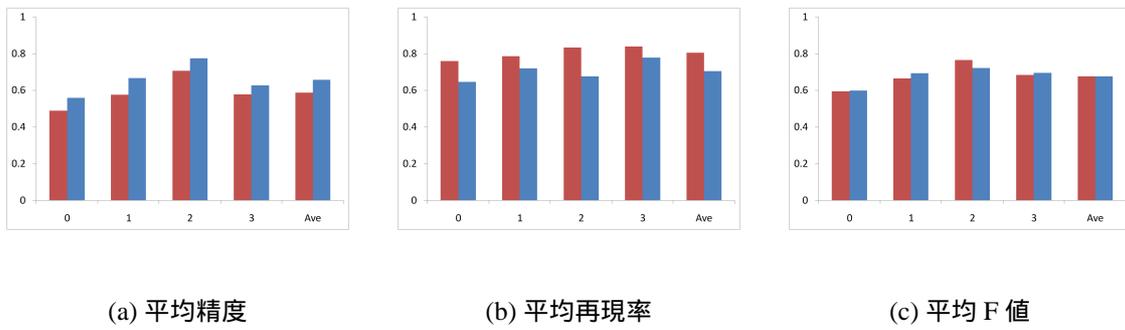
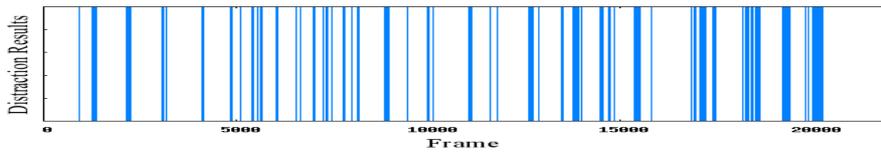
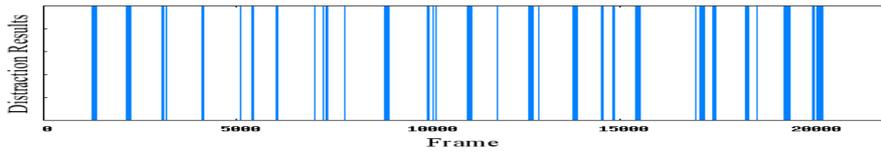


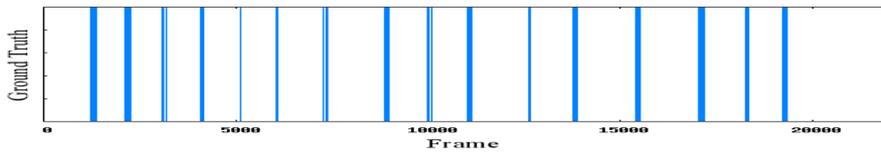
Fig. 5.31: 安全確認状態未使用/使用比較結果，(b) 首都高速 3 号線，赤：未使用，青：使用



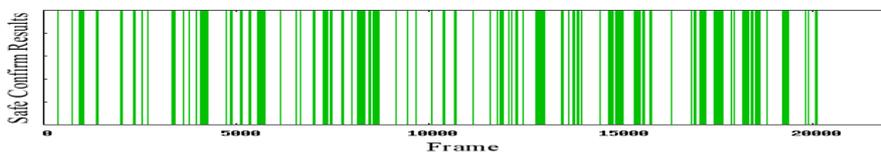
(a) 隠れ状態数：2，脇見状態推定結果



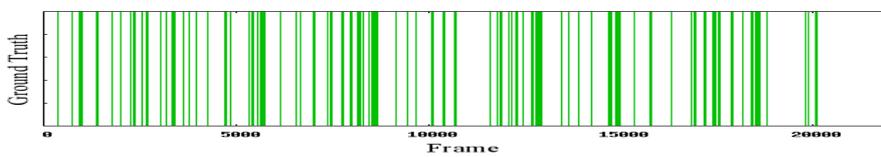
(b) 隠れ状態数：3，脇見状態推定結果



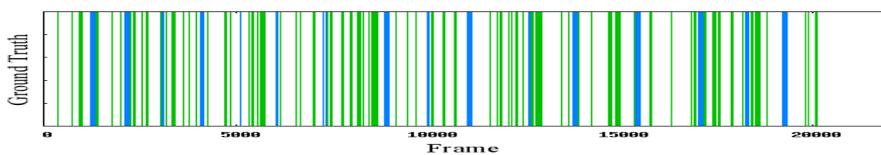
(c) 脇見状態 Ground Truth



(d) 隠れ状態数：3，安全確認状態推定結果



(e) 安全確認状態 Ground Truth



(f) Ground Truth，青：脇見状態，緑：安全確認状態

Fig. 5.32: 実験結果例：被験者 0

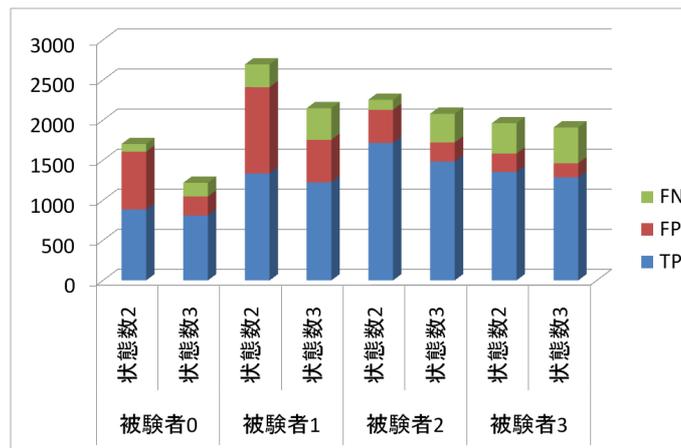


Fig. 5.33: 安全確認状態未使用/使用比較 (TP, FP, FN)

### 5.8.3 考察

#### 安全確認状態導入による観測確率の変化について

安全確認状態を導入することにより、被験者全体に精度の向上と再現率の低下が生じた。本考察では被験者の各観測量の観測確率の変化から、精度の向上及び再現率の低下の要因となった観測量を検討する。

安全確認状態導入前後の1走行あたりのTP（真陽性）、FP（偽陽性）、FN（偽陰性）の値の推移を表すグラフをFig.5.33に示す。縦軸はフレーム数である。なお、全体のフレーム数に対して、TN（真陰性）のフレーム数が大変大きく全体の情報を分かりにくくしてしまうためこのグラフでは記載を省略した。figurename5.33を見ると、個人差はあるものの全被験者においてFPの減少が見られる。特に、安全確認状態を未導入の推定手法でFPの値の高かった被験者0及び1に対してはその傾向が顕著である。また、同2名の被験者ではTP、FP、及びFNの総和が減少傾向にある。これはTN（真陰性）が増加したことを示している。この他、被験者2ではFNの値が増加している。以上から、被験者0及び1はFPがTNに変わり、被験者2ではTPがFNに変わったと考えられる。

これらの現象について原因を考察する。3名の被験者について各観測量の観測確率のうち、現象の要因と最も変化が顕著であった頭部ヨー角について、安全確認状態の導入前後の観測確率の比較図をFig.5.34に示す。

Fig.5.34を見ると、被験者0及び1について安全確認状態における頭部ヨー角の分布がバックミラー及びサイドミラーがあると推測される位置に多く分布しており、

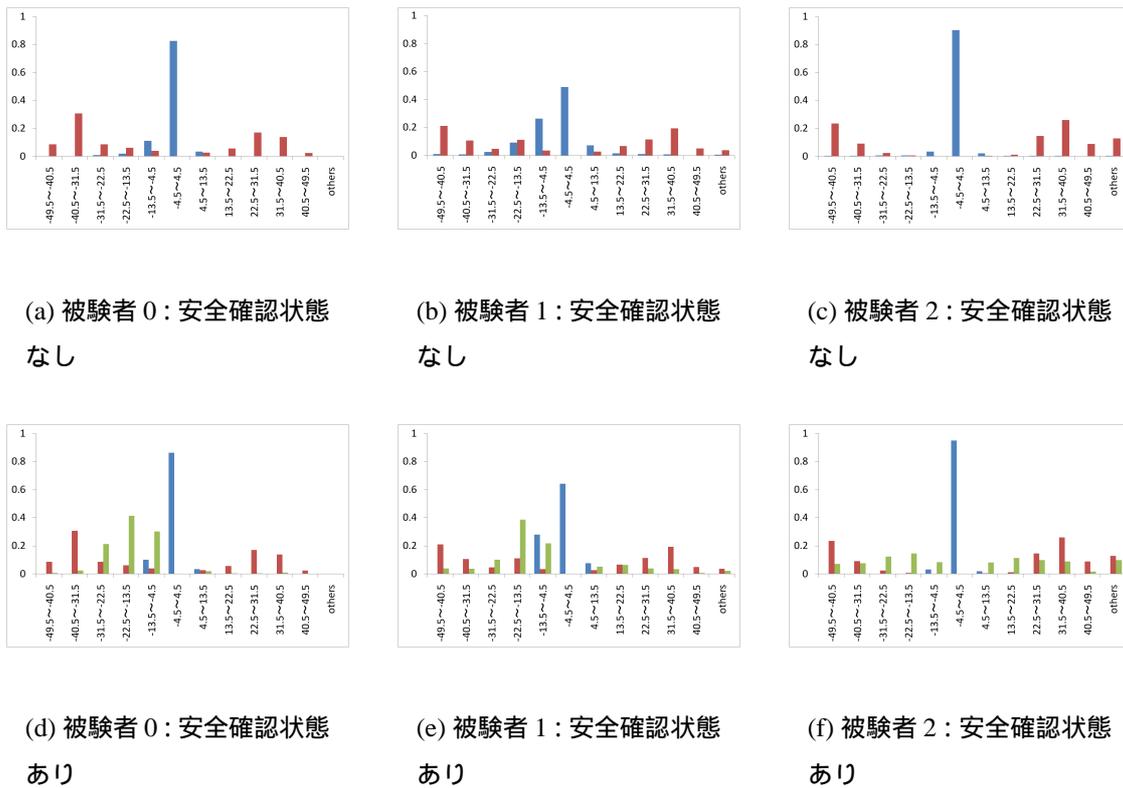


Fig. 5.34: 安全確認状態未使用/使用時の頭部ヨ一角的観測確率比較，青：通常状態，赤：脇見状態，緑：安全確認状態

視線方向情報の導入時同様の効果が得られたためにFPが減少したものと考えられる。また被験者2では，安全確認状態時の頭部ヨ一角的分布が一様分布に近い形で分布しておりこれが結果としてTPの減少に寄与したものと考えられる。しかし被験者2の安全確認状態の頭部ヨ一角的分布がなぜ一様分布に近い形になったのかについては，現状のデータでは推定できない。可能性としては，ミラー以外の様々な方向に対して安全確認を行う（隣接車線への直視など）などの個人の運転の癖などが影響したと考えることもできる。

以上を踏まえ，通常状態，脇見状態，及び安全確認状態について考察をすると，通常状態と安全確認状態では，頭部ヨ一角において差が大きくその他の観測量では特に目立った差異はなく，また，安全確認状態と脇見状態では，頭部ヨ一角が通常状態より大きいという点において類似性があるが，その他観測量では差がありその情報から分けて検出をすることが可能であると考えられる。

## 第6章 結論

### 6.1 頭部姿勢及び運転操作情報や自車両状態情報を考慮した脇見状態推定

従来の脇見検出手法に関する研究では考慮されていなかった脇見行動とドライバの操作情報、自車両情報との因果関係に着目し、首振り動作の他にドライバの運転操作情報やその時の自車両状態などの各種情報を Dynamic Bayesian Network の枠組みで統合することによりドライバの脇見状態を検出する手法を提案した。また、統計学的手法に必要な正確な学習データの取得と、明確に定義された脇見状態の再現という問題に対してドライビングシミュレータという完全に制御された環境下で実験を行うことによりこれを解決した。この過程で頭部姿勢推定システムや脇見発生用ターゲット提示システム、ドライビングシミュレータから得られる各種データを実時間で統合するシステムを構築した。

評価方法には、従来二値化判定システムの評価方法として用いられてきた受信者動作特性曲線（ROC カーブ）について脇見状態推定の評価時に発生する問題点を考察し、精度/再現率/F 値という評価値を用いた。

提案手法の脇見状態検出結果と頭部ヨー角のみを用いて閾値化により行った脇見検出結果との比較実験では、ドライバの操作情報や自車両状態などの各種観測を考慮したことにより推定結果が向上することを確認した。また被験者間の精度差に対して、各被験者の平均車線回数、頭部ヨー角の平均積算変位量（5.5.1 式）、及び頭部ヨー角の平均分散値から、被験者ごとの運転特性が精度に影響を与えることを示した。

観測量ではドライバの運転操作情報であるアクセルペダルの踏み込み量やハンドル角速度などが通常状態と脇見状態とで異なる挙動を示し、脇見検出に有効であることを示し、また車線変更という運転行動と因果関係の強い観測量であるウインカー情報を用いることで更なる精度向上の可能性を検討した。

## 6.2 視線情報を加味した脇見状態推定

頭部ヨー角という曖昧な情報に対して、視線方向というより意味をもった具体的な情報を割り当てることにより、運転行動との因果関係を明確にし、脇見状態の推定精度向上を試みた。まずはじめに、実験中に撮影したビデオ画像から手作業による視線方向の正解ラベル作成を行い、その視線方向情報を学習時に使用したのち、脇見状態を推定した。その推定結果と視線情報を用いずに脇見状態を推定した結果とを比較し、視線情報を用いることによるシステム性能の向上を確認した。またこの実験において、再現率の低下の原因を考察する過程で、特定の注視対象の存在する視線方向（前方、バックミラー、左右サイドミラー）以外の方向に対する視線のモデル化の問題点を検討した。

次に、膨大な作業量となる視線方向の正解ラベル作成を行わずに視線方向情報を用いるための各種観測確率の学習方法を提案した。しかし、先に挙げた特定注視対象の存在する視線方向以外の方向に対する頭部ヨー角分布の学習精度の個人差により、システム全体の脇見推定精度が影響を受けることがわかった。

## 6.3 安全確認状態を加えた脇見状態推定

隠れ状態を通常状態と脇見状態の二値で表現していた提案手法に対して、脇見状態の誤検出対象となる安全確認状態を通常状態と分けて学習する手法を提案した。脇見状態以外としての通常状態をより細分化することにより、状態間の曖昧性が少なくなり、特に誤検出の減少に対して大きく貢献しシステムの性能が向上することを比較実験により確認した。

## 6.4 今後の課題

今後の課題としては、従来研究から得られた知見や経験的な部分から決定してきた観測量の扱いについて、適切な取捨選択を行うことにより脇見状態検出に対して最も適した観測量の組み合わせなどを検討する必要があると考える。また本研究ではあまり具体的に扱うことができなかった状態の時間的遷移について、より高度なモデルやDBNのネットワークトポロジーを適用し、システムに導入することで精度の向上が図れると考えている。

また，脇見状態以外のドライバの内部状態も同様に個別にモデル化し，それら構成要素を統合することで，ドライバの内部状態全体の中の様々な情報を推定できるシステムの構築も行っていきたい．

## 謝辞

本研究を行うにあたり，常日頃から多大な時間を割いて熱心にご指導くださいました佐藤洋一准教授に心より御礼申し上げます。

実験での施設提供や実験時の協力をはじめ，本研究の様々な部分で貴重なご助言をくださいました須田義大教授，山口大助特任助教に深く御礼申し上げます。

研究だけにとどまらず，公私にわたる様々な相談に乗ってくださいました岡部孝弘助教，佐藤いまりさんに深く御礼申し上げます。

順調な研究生生活を送るにあたり，研究以外の様々な部分でサポートをしてくださった秘書の鈴木咲恵さん，新木真理子さん，今川洋子さんに心より感謝いたします。

先輩として学生生活を導いてくださり，研究に関しても多くの助言や実験のサポートなどをしてくださいました熊野史朗さんに心より感謝いたします。

また，私の研究の滞りない遂行に協力していただきました佐藤研究室の皆さんに心より感謝いたします。

最後に何不自由ない学生生活を支援してくださった両親と，精神的な支えとなってくくださった友人全員に深く感謝いたします。

皆様，本当にありがとうございました。

平成 20 年 2 月 1 日

堀口 研一

## 参考文献

- [1] L.M. Bergasa, J. Nuevo, M.A. Sotelo, R. Barea, and M.E. Lopez. "Real-time system for monitoring driver vigilance". *Intelligent Transportation Systems, IEEE Transactions on*, Vol. 7, No. 1, pp. 63–77, March 2006.
- [2] L. Breiman. "Random Forests". *Machine Learning*, Vol. 45, No. 1, pp. 5–32, 2001.
- [3] P. Ekman and W.V. Friesen. "*Facial Action Coding System*". Consulting Psychologists Press, 1978.
- [4] H. Gu and Q. Ji. "An automated face reader for fatigue detection". *Automatic Face and Gesture Recognition, 2004. Proceedings. Sixth IEEE International Conference on*, pp. 111–116, 17-19 May 2004.
- [5] H. Gu, Y. Zhang, and Q. Ji. "Task oriented facial behavior recognition with selective sensing". *Computer Vision and Image Understanding*, Vol. 100, No. 3, pp. 385–415, 2005.
- [6] K. Hayashi, Y. Kojima, K. Abe, and K. Oguri. "Prediction of stopping maneuver considering driver's state". *Intelligent Transportation Systems Conference, 2006. ITSC '06. IEEE*, pp. 1191–1196, 2006.
- [7] Y. Inuzuka, Y. Osumi, and H. Shinkai. "Visibility of Head Up Display (HUD) for Automobiles". In *Proceedings of the Human Factors Society 35th Annual Meeting*, pp. 1574–1578, 1991.
- [8] F.V. Jensen. "*Bayesian Networks and Decision Graphs*". Springer, 2001.
- [9] C. Jiangwei, J. Lisheng, G. Lie, G. Keyou, and W. Rongben. "Driver's eye state detecting method design based on eye geometry feature". *Intelligent Vehicles Symposium, 2004 IEEE*, pp. 357–362, 2004.
- [10] M.I. Jordan. "*Learning in Graphical Models*". Kluwer Academic Publishers, 1998.

- [11] R. Kohavi and G.H. John. "Wrappers for feature subset selection". *Artificial Intelligence*, Vol. 97, No. 1-2, pp. 273–324, 1997.
- [12] N. Kuge, T. Yamamura, and O. Shimoyama. "a driver behavior recognition method based on a driver model framework".
- [13] T. KUMAGAI and M. AKAMATSU. "Prediction of Human Driving Behavior Using Dynamic Bayesian Networks". *IEICE TRANSACTIONS on Information and Systems*, Vol. E89-D, No. 2, pp. 857–860, 2006.
- [14] P. Lan, Q. Ji, and C.G. Looney. "Information fusion with Bayesian networks for monitoring human fatigue". *Information Fusion, 2002. Proceedings of the Fifth International Conference on*, Vol. 1, pp. 535–542, 2002.
- [15] X. Liu, F. Xu, and K. Fujimura. "Real-time eye detection and tracking for driver observation under various light conditions". *Intelligent Vehicle Symposium, 2002. IEEE*, Vol. 2, pp. 344–351, 17-21 June 2002.
- [16] H.M. Mandalia, D. Salvucci, College of Arts, Sciences, and Drexel University. "Pattern Recognition Techniques to Infer Driver Intentions". PhD thesis, Drexel University, 2004.
- [17] JC McCall and MM Trivedi. "Human Behavior Based Predictive Brake Assistance". *Intelligent Vehicles Symposium, 2006 IEEE*, pp. 8–12, 2006.
- [18] Erik Murphy-Chutorian, Anup Doshi, and Mohan Manubhai Trivedi. "Head Pose Estimation for Driver Assistance Systems: A Robust Algorithm and Experimental Evaluation". *Intelligent Transportation Systems Conference, 2007. ITSC 2007. IEEE*, pp. 709–714, 2007.
- [19] J. Nuevo, L.M. Bergasa, M.A. Sotelo, and M. Ocana. "Real-time robust face tracking for driver monitoring". *Intelligent Transportation Systems Conference, 2006. ITSC '06. IEEE*, pp. 1346–1351, 2006.
- [20] N. Oliver and AP Pentland. "Graphical models for driver behavior recognition in a SmartCar". *Intelligent Vehicles Symposium, 2000. IV 2000. Proceedings of the IEEE*, pp. 7–12, 2000.

- [21] A. Pentland and A. Liu. "Modeling and Prediction of Human Behavior", 1999.
- [22] S.J. Russell and P. Norvig. "Artificial Intelligence: A Modern Approach Second Edition". Pearson Education, Inc., 2003.
- [23] D.D. Salvucci. "INFERRING DRIVER INTENT:A CASE STUDY IN LANE-CHANGE DETECTION". In *Proceedings of the Human Factors Ergonomics Society 48th Annual Meeting*, pp. 2228–2231, 2004.
- [24] Klaus Strobl and Wolfgang Sepp. "Camera Calibration Toolbox for Matlab". [http://www.vision.caltech.edu/bouguetj/calib\\_doc/index.html](http://www.vision.caltech.edu/bouguetj/calib_doc/index.html).
- [25] K. Torkkola, N. Massey, and C. Wood. "Detecting driver inattention in the absence of driver monitoring sensors". *Machine Learning and Applications, 2004. Proceedings. 2004 International Conference on*, pp. 220–226, 16-18 December, 2004.
- [26] Z. Zhu and Q. Ji. "Real time and non-intrusive driver fatigue monitoring". *Intelligent Transportation Systems, 2004. Proceedings. The 7th International IEEE Conference on*, pp. 657–662, 3-6 Oct. 2004.
- [27] 奥田幸治, 井東道昌, 稲垣文治, 山本新, 森恵. "ドライバ状態推定のための瞬き及び視線方向の検出". 自動車技術会学術講演会前刷集, No. 10-05, pp. 9–12, 2005.
- [28] 岡兼司, 菅野裕介, 佐藤洋一. "頭部変形モデルの自動構築を伴う実時間頭部姿勢推定". 情報処理学会論文誌: コンピュータビジョンとイメージメディア, Vol. 47, No. SIG10(CVIM15), pp. 185–194, 2006.
- [29] 沓名守通, 井東道昌, 山本修身, 中野倫明, 山本新. "インパネ位置撮像システムによる顔向き検出と運転支援システムへの応用の試み". Technical report, IEICE PRMU, 2006.
- [30] 警察庁交通局. "平成 18 年中の交通事故発生状況". <http://www.npa.go.jp/toukei/koutuu41/20070228.pdf>.
- [31] 須田義大, 高橋良至, 大貫正明. "研究用ユニバーサルドライビングシミュレータ". 自動車技術, Vol. 59, No. 7, pp. 83–88, 2005.
- [32] 第二 IO 編集部 (編). "[書籍版]DirectX9 実践プログラミング". 株式会社 工学社, 2003.

- [33] 中越聡, 木村賢治, 金森等. ”ドライバーの顔向きによる前方不注視の推定と警報反応時間の研究”. 自動車技術会 学術講演会前刷集, No. 58-06, pp. 17–20, 2006.
- [34] 鳥山将司, 井東道昌, 小塚一宏, 中野倫明, 山本新. ”画像処理によるドライバの視線推定検出と脇見検知への適用”. 自動車技術会 学術講演会前刷集, No. 10-05, pp. 13–16, 2005.
- [35] 田久保宣晃, 藤岡健彦. ”運転中の脇見行動に関する分析”. 自動車技術会論文集, Vol. 34, No. 2, pp. 107–112, 2003.
- [36] 本村陽一, 佐藤泰介. ”ベイジアンネットワーク: 不確定性のモデリング技術”. 人工知能学会誌, Vol. 15, No. 4, pp. 575–582, 2000.
- [37] 鈴木正裕, 稲垣伸吉, 鈴木達也, 早川総一郎, 土田縫夫. ”視線情報とベイズ推定による運転行動意図の推定”. 電気学会 産業計測制御研究会, IIC-07-75, pp. 29–34, March 2007.

## 発表文献

### 国内会議（査読あり）

1. 堀口 研一，熊野 史朗，山口 大助，佐藤 洋一，須田 義大，鈴木 高宏，”運転状況を考慮した脇見推定手法”，第 6 回 ITS シンポジウム 2007 Proceedings，December 2007.

### 国内会議（査読なし）

2. 堀口 研一，熊野 史朗，山口 大助，佐藤 洋一，須田 義大，鈴木 高宏，”ドライバの頭部姿勢及び自車情報を用いた脇見状態推定手法”，自動車技術会 2007 年秋季大会学術講演会前刷集，No.110-07，pp.1-6，October 2007.