


修 士 論 文

歩行者挙動と運転行動の学習に基づく くモーションプランのモデル化

Motion Planning based on Learning
Models of Pedestrian Behavior and
Driving Maneuver

指導教員

上條 俊介 准教授



東京大学大学院
情報理工学系研究科
電子情報学専攻

学籍番号・氏名 48-146437 橋本 順祥

提出日

2016 年 2 月 4 日

概要

近年、自動運転や運転支援システムへの需要が高まる中で、そうしたシステムが交通環境で人間と共存するためには、人間ドライバーのように状況を高次元に理解して、自然な運転行動をとることが求められる。特に歩行者を含むシナリオは複雑性を増し、安全性と潤滑性を確保するためには、歩行者の行動および車両の操縦、双方に対する高度なモデルが必須となる。本論文では、歩車間事故が多発し、危険性が高いと同時に潤滑さの望まれる信号交差点に焦点を当て、歩行者の行動モデルおよび左折時のモーションプランニングモデルの提案を行う。歩行者行動モデルでは、位置やモーションのみならず、意思やコンテキストを考慮し、それらの関係性をダイナミックベイジアンネットワークを用いて確率モデル化を行う。このモデルでは、歩行者の観測位置と歩行者信号の状態の入力に対して、粒子フィルタを用いることで、歩行者の横断意思という高次元状態量を逐次的に推定することが可能である。またドライバーの運転モデルでは、gap acceptance のような歩行者とのインタラクション行動を解析、学習を行った。そして、これと歩行者モデルを結合したモーションプランニング手法は、自然なドライビング行動を再現可能であることを示した。

目次

第 1 章	序論	1
1.1	研究背景	1
1.2	研究目的	3
1.3	本論文の構成	3
第 2 章	信号交差点における歩行者横断行動モデル	5
2.1	研究背景	5
2.2	関連研究	8
2.2.1	運動モデルに基づく歩行者行動推定	8
2.2.2	コンテキスト/意思に基づく歩行者行動推定	12
2.2.3	歩行者交通行動の統計モデル	13
2.3	ダイナミックベイジアンネットワーク	14
2.3.1	ベイズ推定	14
2.3.2	ベイジアンネットワーク	14
2.3.3	ダイナミックベイジアンネットワーク	15
2.3.4	状態推定手法	16
2.3.5	先行事例	21
2.4	提案モデル	22
2.4.1	歩行者状態空間	22
2.4.2	ダイナミックベイジアンネットワークの構成	25
2.4.3	状態遷移モデル	26
2.4.4	状態推定手法	30
2.5	評価実験	33
2.5.1	データ収集	33
2.5.2	パラメータ学習	36
2.5.3	性能評価	39
2.6	結論	57
第 3 章	信号交差点における左折モーションプランニング手法	58
3.1	研究背景	58

iv 目次

3.2	関連研究	60
3.2.1	運転行動の認識モデル	60
3.2.2	運転行動の統計モデル	61
3.2.3	モーションプランニングモデル	61
3.3	提案手法	63
3.3.1	加加速度制御モデル	63
3.3.2	コンフリクト領域モデル	64
3.3.3	Gap Acceptance モデル	65
3.3.4	Potential Gap 探索モデル	67
3.3.5	Yield 選択モデル	68
3.3.6	Clearing モデル	68
3.4	シミュレーションによる評価実験	70
3.4.1	実験データ	70
3.4.2	シミュレーション方法	70
3.4.3	シミュレーション結果	72
3.5	車載システムによる評価実験	82
3.5.1	実験データ	82
3.5.2	システム作動例	82
3.6	結論	95
第 4 章	結論と今後の課題	96
4.1	本研究のまとめ	96
4.2	今後の課題	96
	謝辞	98
	発表文献	99
	参考文献	100

目次

2.1	横断歩道周辺におけるモーション変化点	7
2.2	3 変数ベイズネットワーク例のグラフ表現	15
2.3	状態空間モデルのグラフ表現例	16
2.4	提案モデルにおける状態変数の図例	25
2.5	歩行者横断行動モデルの二時刻間におけるグラフ表現	26
2.6	実験対象交差点 * ¹	34
2.7	カメラ画像と位置ラベル例	35
2.8	PFG 開始時における横断意思確率	37
2.9	特定条件下におけるモーション遷移確率	38
2.10	横断歩道前特定条件下における歩行速度分布	40
2.11	横断歩道上特定条件下における歩行速度分布	41
2.12	横断ケースにおける状態推定 ($\sigma_n = 0.1\text{m}$)	47
2.13	横断ケースにおける状態推定 ($\sigma_n = 0.4\text{m}$)	48
2.14	横断ケースにおける状態推定 ($\sigma_n = 1.0\text{m}$)	49
2.15	待機ケースにおける状態推定 ($\sigma_n = 0.1\text{m}$)	50
2.16	待機ケースにおける状態推定 ($\sigma_n = 0.4\text{m}$)	51
2.17	待機ケースにおける状態推定 ($\sigma_n = 1.0\text{m}$)	52
2.18	横断意思の認識精度の PFG 経過時間による変化	53
2.19	横断意思の認識精度の横断歩道までの距離による変化	53
3.1	交差点左折時の速度変化例	59
3.2	速度/加速度/加加速度の制御例	64
3.3	加速開始時の歩行者-車両軌道間距離の累積分布	65
3.4	Yielding/Gap acceptance シーンの概観	66
3.5	通過時マージンの概要	69
3.6	実験対象交差点 * ²	71
3.7	横断歩道通過時の歩行者-車両軌道間最小距離	73
3.8	横断歩道進入時の速度	74
3.9	提案モデルによるシミュレーション	77

vi 図目次

3.10	提案モデルによるシミュレーション	78
3.11	Alhajyaseen モデルによるシミュレーション	79
3.12	Alhajyaseen モデルによるシミュレーション	80
3.13	シミュレーションと実車両の速度	81
3.14	Soft-yield ケース: $t = 0.0\text{s}$	85
3.15	Soft-yield ケース: $t = 3.1\text{s}$	86
3.16	Soft-yield ケース: $t = 4.8\text{s}$	87
3.17	Soft-yield ケース: $t = 6.5\text{s}$	88
3.18	Soft-yield ケース: $t = 8.7\text{s}$	89
3.19	Hard-yield ケース: $t = 0.0\text{s}$	90
3.20	Hard-yield ケース: $t = 7.6\text{s}$	91
3.21	Hard-yield ケース: $t = 11.2\text{s}$	92
3.22	Hard-yield ケース: $t = 13.3\text{s}$	93
3.23	Hard-yield ケース: $t = 16.9\text{s}$	94

表目次

2.1	データセットの概要	35
2.2	実験交差点における信号現示周期	35
2.3	PFG 開始後における横断意思推定結果の正規化混同行列	46
2.4	対象横断歩道ごとの横断意思推定結果の正規化混同行列	46
2.5	井料モデル [1] による PFG 開始時における横断意思推定結果の正規化混同行列	46
2.6	モーション推定結果の正規化混同行列	54
2.7	IMM-KF によるモーション推定結果の正規化混同行列	54
2.8	グループ推定結果の正規化混同行列	55
2.9	横断歩道前/上におけるグループ推定結果の正規化混同行列	55
2.10	位置推定誤差の比較 (平均/標準偏差)	56
2.11	グループ推定正誤時別の位置推定誤差 (平均/標準偏差)	56
3.1	実ドライバーとの Gap Acceptance の差異	72

第 1 章

序論

本研究では、交差点における歩行者の横断挙動およびドライバーの左折行動を学習し、それに基づくモーションプランニングのモデル化を行う。歩行者行動解析では、交通信号現示のようなコンテキスト (文脈情報) と歩行者挙動の関係性のモデル化を提案する。これにより、歩行者の横断歩道に対する横断意思や駆け出しの認識が可能となる。この歩行者挙動の解析の上で、歩行者の通行状況を把握しながら左折するドライバーの行動を学習し、人間のドライバーに近いスムーズな左折行動をプランニングモデルを提案する。歩行者の挙動やそれを認識して運転しているドライバーの自然な運転行動を学習することは、自律走行や安全運転支援に必須である。いずれのモデルに対しても、実際の交通シーンから取得したデータを用いて学習および検証を行う。

1.1 研究背景

近年、高度道路交通システム (Intelligent Transport Systems: ITS) による、道路交通の安全性向上や効率化、環境への負荷軽減が期待されており、急速に需要の高まっている自動運転やそれに準ずる先進運転システム (Advanced Driver Assistance Systems: ADAS) はその最たる例である。これら自動運転や ADAS の実現が私たちの暮らしをより便利に、快適に、安全にすることは間違いない。搭乗者は運転から解放され、移動中に運転以外の行為に時間を活用できることができる。無人の輸送システムは物流の活性化につながる。また、システムによる高速、高精度かつ交通ルールを遵守した認識や判断、操作によって、90 %を超える自動車事故の原因となっているヒューマンエラー [2] を排し、安全性の向上、交通事故の低減が期待される。高精度かつ最適化された車両制御によって、車線数の増加や車間距離の短縮が可能となり、道路容量が増加する。それに伴い、渋滞の解消、移動/輸送の効率化や省エネルギーが実現する。また、高齢化の進む日本、特に過疎化も進む地方において、高齢者の安全な移動手段としても期待される。自動車を個人で所有するスタイルも変化し、カーシェアリングのように公共交通機関として発達することも考えられ、自動運転の実現は私たちの生活を現在とまったく異なるものにするだろう。

しかしながら、自動運転の実現には多くの課題が存在する。まず、現在地から目的地までの

2 第1章 序論

ルートを策定し、正しい車線を走行し、正しく交差点で右左折するといったことには自車の位置を正確に推定することが必要となる。この自車両位置推定 (self-localization) の技術には、人工衛星からの信号を用いて測位を行う GPS(Global Positioning System: 全地球測位システム) が中心的だが、カメラ等のその他のセンサや地図情報を用いて精度向上が行われている [3, 4, 5, 6, 7]。次に、安全に移動するためには、動的に変化している自車両を囲む環境を把握しなければならない。例えば、歩行者や車両、障害物、道路領域、レーンの位置の特定、交通信号や標識などの理解が必要となる [8, 9, 10, 11, 12, 13]。ただし、今後の IT や ITS の発展により、V2V/V2I/V2P コミュニケーション (車車間/路車間/歩車間通信) などによって部分的に提供され得る [14]。さらに、歩行者や他車両などの移動体に対しては、未来の状態を予測し、自車両との危険が生じ得るかを評価する [15, 16, 17]。こうした周囲の状況に対して、自車両の行動計画 (モーションプランニング) を立てる [18, 19, 20]。そしてこれを実現するためには、加速や操舵、制動といった制御を正確に行わなければならない [21]。このように完全な自動運転は多くの技術要素の上で初めて成立するものである。

これらの課題を同時に達成することは難しく、システムの精度や統合度に応じて段階的に達成し得る。米国運輸省道路交通安全局 (NHTSA) は、自律走行車開発に関する政策方針 [22] で自動化のレベルを以下のように定義している。

レベル 0 - No-Automation 常にすべての主制御 (加速/操舵/制動) を運転手が行う。ただし、前方衝突警告や車線逸脱警告などの主制御システムを操作しない運転支援システムはこのレベルに含まれる。

レベル 1 - Function-specific Automation 主制御システムの一つまたは複数をシステムが担う。ただし、複数の場合もそれぞれのシステムは独立に機能する。自動ブレーキ機能や横滑り防止装置はこのレベルに含まれる。

レベル 2 - Combined Function Automation 複数の主制御システムを協調的にシステムが行う。速度制御、操舵制御を兼ねたアダプティブクルーズコントロールはこのレベルに含まれる。ただし、運転手は常に運転状況を監視操作する必要がある。

レベル 3 - Limited Self-Driving Automation 加速/操舵/制動の全ての制御をシステムが担う。運転手は運転および状況の監視から常時行う必要はないが、緊急時などにシステムが要請したときは運転手が運転操作を代わらなくてはならない。

レベル 4 - Full Self-Driving Automation 運転手が制御に関与しない完全な自動運転、無人での走行も含まれる。

近年のミリ波レーダーやカメラといったセンサの性能や計算処理能力の向上を経て、ADAS として部分的な自動化の導入や、実道路環境での実証実験が行われる段階に突入している。富士重工業と日立製作所・日立オートモティブシステムズが開発した「EyeSight」では、ステレオカメラを用いた 3 次元的な画像認識を行う。周囲の歩行者や車両を検出し、衝突が予測される場合、警報あるいは自動ブレーキが作動し、前方車両との車間距離を保つようなクルーズコントロール機能や車線逸脱時の警報システムも有する。これは自動化レベル 2 に該当する。また、Tesla Motors 社のコンセプトは、車両のハードウェアをそのままに、搭載されているソ

ソフトウェアをアップデートすることにより、段階的に機能を追加して自動運転の実現をするものである。2015年10月のソフトウェアアップデートで追加された「オートパイロット」機能では、クルージングや衝突回避、パーキング等におけるレベル2の自動化を実現し、さらに他のTesla社の車両の走行情報から学習し、機能が高度化していく。Google社は2015年11月時点で既に190万キロメートルもの試験走行を公道において安全に行っており、大きな注目を集めている。「Google Car」のプロトタイプではハンドルやブレーキを廃しており、最終的にレベル4の自律走行 (self-driving car) を目指していると言える。このように自動車業界にIT企業が参入しており、上記の自動運転における課題の解決には、人間が操作してきた自動車というハードウェアのみならず、人間のドライバーの代わりとなる人工知能 (AI) や情報処理の視点が不可欠であることを示している。

その他の多くの企業においても、高速道路や郊外、渋滞中など限られたシーンにおいて実用化レベルにある自動システムを発表しており、法的理由等から自動化レベル2での使用が求められるものの、レベル3に該当する技術を有するものも含まれると考えられる。ただし、こういった環境では、認識すべき対象は少なく、多くの場合移動に必要な操縦、制御も少なく単純である。また、オープンスカイ環境でのGPSによる自己位置推定精度は高い。対照的に都市部での自動運転には課題が多い。高層ビル群は衛星からの信号を遮蔽または反射し、GPSの精度を低下させる。また、交通密度は高くなり、必然的に歩行者や他車両との距離も近くなるため、衝突を防ぐためには高度な行動予測に基づいて、人間のドライバーや歩行者との共存が重要となる。停止や右左折等の操作回数も格段に多くなり、こうした都市部での複雑な状況への対応する能力なしでは自動運転は実現しない。

1.2 研究目的

本研究の目的は、特に都市部のように交通密度が高い状況において、高度な自動運転を実現するための行動モデルの提案である。そうした状況では、たとえ車両が他者に決して能動的に衝突しないシステムであったとしても、周囲の歩行者やドライバー、搭乗者が脅威を感じる走行は好ましくない。また、人間の目から見て意図を読み取れない、予測し難い行動をとることも、受動的な衝突を起こし得る。このような理由から、自然な操縦を学習し、可能な限りそれに倣う必要がある。

こうした目的の実現のためにも、まず人間が行っているような高次の状況把握を行う必要がある。第2章で提案する信号交差点における歩行者行動の確率モデルは、歩行者の自然な行動を学習し、横断歩道に対する横断意思という高次の状態を認識するためのものである。そして、第3章では、一般的なドライバーの交差点左折行動を学習し、この歩行者モデルと組み合わせることによる、モーションプランニング手法を構築する。

1.3 本論文の構成

本論文は以下のように構成される。

4 第1章 序論

第2章では、信号交差点における歩行者行動モデルに関する研究の詳細を述べる。まず、第2.1節において、本研究の背景について述べる。第2.2節で歩行者行動認識に関する先行研究を、第2.3節で提案モデルの軸となるダイナミックベイジアンネットワークの基本的な理論を紹介する。第2.4節では歩行者行動の確率モデルの提案を行い、第2.5節でそのモデルに対するの評価実験に関して述べる。最後に、第2.6節で結論を述べる。

第3章では、信号交差点における左折時の操縦モデルに関する研究の詳細を述べる。まず第3.1節で本研究の背景を述べ、第3.2節で関連研究を導入する。第3.3節では、提案手法を述べる。第3.4節、第3.5節ではそれぞれシミュレーション、車載システムによる実験について述べる。そして、第3.6節で結論を述べる。

最後に第4章で全体の結論と今後の課題を述べる。

第 2 章

信号交差点における歩行者横断行動モデル

2.1 研究背景

本章では、信号交差点の横断歩道における歩行者横断行動モデルおよびそれを用いた認識システムを提案する。交差点は交通シーンにおいて歩行者と自動車の軌道が交差する主要な領域であり、最も複雑な領域の一つである。特に日本の都市部のような交通密度の高い地域では、自動車と歩行者のコンフリクトが高い頻度で起こり得る。それゆえ、日本では歩車間事故の半数近くが交差点で起きており [23]、安全システムの観点から非常に重要である。特に左折ドライバーにとって、左手側の歩道領域 (near-side) には大きな死角が存在する上、その直近する歩道領域から歩行者が横断を開始するため、巻き込み事故が起きやすい。このような複雑さを伴う交差点において、自律走行によって安全かつスムーズに通行したり、安全支援システムが誤警報を最小限に抑えた上で適切に機能するためには、歩行者が横断に際しどのような挙動を示すかという知識が必須となる。

一般的に交通流の多い交差点は信号を備えており、交通流を制御している。そのため、歩行者およびドライバーの行動は信号によって左右されているといえ、非常に重要な因子である。日本では、歩行者用信号現示は 3 つに分かれている。歩行者青信号 (PG: pedestrian green)、歩行者青信号点滅 (PFG: pedestrian flashing green)、歩行者赤信号 (PR: pedestrian red) である。PG 時は歩行者は横断歩道を渡ることが許され、PR 時は許されていない。その間に位置する PFG 時は横断の開始が禁じられ、既に開始している歩行者は近い方の歩道へ引き返すまたは渡り切ることが求められる。しかしながら、現実には引き返すケースはほとんど見られず、さらには、多くの歩行者が PFG 開始後に横断を始める。そして多くの場合、加速と駆け込みを伴い、そうした行為は右左折車両にとって非常に危険である。

信号交差点で歩行者の行動を観察すると、実際に信号の状態に応じたいくつかの傾向を発見することができる。例えば、PFG 時には二つの特徴的な行動が見られる。横断のために加速するか、停止するために減速するかである。こうした傾向を、歩行者が歩行、走行、停止といったモーションを変えた時点の横断歩道までの距離と信号現示に対する時間を表す図 2.1 に

6 第2章 信号交差点における歩行者横断行動モデル

示す。このデータは実際の信号交差点の横断歩道で収集されたものであり、評価実験に用いられたため、詳細は2.5節に示す。横軸はPFG開始の瞬間を原点にとった時間であり、10sの赤線はPRの開始を表す。縦軸は横断歩道入口までの距離を表し、-23mは横断歩道出口を表す。図中“x”記号の色はモーション変化の種類を表し、例えば青色は歩行状態(*walking*)から停止状態(*standing*)への変化である。図を一瞥すると、いくつかのクラスタが見受けられる。まず、PG時には横断歩道入口前後10mで走るのをやめる歩行者が多くいるのがわかる。これは歩行者が十分な余裕を持って横断歩道を渡れり切れると判断するためと考えられる。次に、歩行者信号がPFGへと移り変わると、横断歩道に接近していた歩行者が現信号サイクル内での横断のためにしばしば走り始める。そして、多くの歩行者が横断を終える前に、横断歩道後半で走るのをやめる。また、PFGの開始数秒前にも10m以上離れたところから駆け出す歩行者がおり、これは信号の変化をおおよそ予測し、横断するためには加速する必要があると判断したからであろう。最後に、次のPGまで待つことを決めた歩行者は横断歩道手前2~6mで停止することがわかる。このように、歩行者は信号の状態および自分と横断歩道と位置関係から行動を決定していることが導ける。

交通信号は歩行者と自動車が安全、潤滑に移動できるように交通流を制御しているが、先述の通り、歩行者はしばしば信号によって急かされ、右左折車両への注意なしに横断歩道への駆け込むような危険な行為を生む。加えて、特に左折車ドライバーにとって、歩道上に広い死角が存在し、事故の原因となり得る。したがって、自動運転システムや安全支援システムがこうした歩行者に注意を払うことは非常に重要といえる。しかしながら、そうしたシステムが単純に横断歩道に向かって歩いてくる歩行者をすべて横断してくるものと仮定しては、不必要な停止や誤警報を招き、潤滑な交通の妨げになったり、他車両との衝突を生みうる。このように、システムとして安全を確保しながら潤滑に機能するためには、歩行者の意思や行動を適切に認識することが重要であり、本研究の動機である。




図 2.1. 横断歩道周辺におけるモーション変化点

2.2 関連研究

自動車交通において、歩行者の安全確保は最も優先されるべきものの一つであり、その重要性の高さから ITS や交通工学、人工知能、ロボティクスといった多岐にわたる分野で研究がなされている。特に自動運転の需要が近年において、より一層注目が集まっているといえよう。その最たる例は歩行者検出技術であり、この 20 年間の間に大きな進歩を遂げ [24, 25, 26, 27, 28, 29], 実用がなされている。しかしながら、単なる検出と位置計測のみでは車両の制御を司るには不十分である。とりわけ歩行者密集度の高い都市部のような場所においては、高頻度の検出は車両にブレーキをかけてしまうか、完全な停止状態にしてしまう。交通事故を減らすと同時に、交通を潤滑にするためには、検出のみならず歩行者の行動を高次に認識・予測する、より進んだ安全システムが必要となる。こうした背景から近年になり歩行者の位置予測や行動認識に注目が集まり、盛んに研究が進んでいる。

2.2.1 運動モデルに基づく歩行者行動推定

前述のように、歩行者検出やセンシング技術の進歩により、歩行者の位置を自動車から観測することが可能となった。しかしながら、位置の計測値は必ず計測誤差を含んでおり、その大小にもよるものの、計測値をそのまま真の位置として仮定するのは危険である。このノイズを含む観測列の中から尤もらしい時系列的な位置を推定 (トラッキング) することが必須である。また、検出を行った上で、安全システムとして機能したり、自律走行におけるモーションプランニングを行うためには、現在もしくは過去の位置を推定するだけでなく、未来の位置も予測することも必要となる。そのため、位置が時間的にどのように移り変わるモデル化することが一般的である。この位置の時間的変化を特徴づけるモデルをダイナミクス (dynamics) と呼ぶ。ダイナミクスのモデルの例としては、対象物体は一定速度で移動する、とする constant-velocity (CV) モデルが挙げられる。また、人が移動する際、その移動の仕方は歩行状態や停止状態など、いくつかに分けることができる。そして、それらの分類はダイナミクスを特徴づけるものであり、これをモーション (motion) と呼ぶ。このダイナミクスや、それを高次に理解するモーション識別の研究が多く行われてきた。

軌跡を用いた手法

歩行者位置のトラッキング手法として最も一般的なものの一つはカルマンフィルタ (Kalman filter, KF) [30] である。カルマンフィルタは、歩行者の移動モデルとして一つの線形動的システム (linear dynamic system, LDS) を仮定した場合の位置の推定 (現在) および予測 (未来)、平滑化 (過去) アルゴリズムである。より一般的には、カルマンフィルタは雑音下の入力データストリームに対して、再帰的に潜在的なシステムの状態 (state) を推定するもので、システムの線形性を仮定して、トラッキングや制御などの様々なアプリケーションに用いられている。線形動的システムは、ガウス白色雑音によって励振をうける線形演算子からなるマルコフ

連鎖モデルで表現されるものであり、時刻 t のシステムの状態 \mathbf{x}_t と観測 \mathbf{z}_t に対して、以下の状態方程式 (2.1) および観測方程式 (2.2) が仮定される。

$$\mathbf{x}_t = F\mathbf{x}_{t-1} + \mathbf{w}_t \quad (2.1)$$

$$\mathbf{z}_t = H\mathbf{x}_t + \mathbf{v}_t \quad (2.2)$$

ただし、 F, H はそれぞれ状態遷移モデル (state transition model)、観測モデル (observation model) を、 $\mathbf{w}_t, \mathbf{v}_t$ は平均 $\mathbf{0}$ 、共分散行列がそれぞれ Q, R の多変数正規分布に従う駆動雑音 (process noise) および観測雑音 (observation noise) を表す。式 (2.1), (2.2) はそれぞれ以下のような確率表現に置き換えることもできる。

$$P(X_t = \mathbf{x}_t | X_{t-1} = \mathbf{x}_{t-1}) = N(\mathbf{x}_t; F\mathbf{x}_{t-1}, Q) \quad (2.3)$$

$$P(Z_t = \mathbf{z}_t | X_t = \mathbf{x}) = N(\mathbf{z}_t; H\mathbf{x}, R) \quad (2.4)$$

一般的に、歩行者位置のトラッキングにおいては、constant velocity(CV) モデルが用いられる。例えば、地面平面上の2次元的な位置と速度を状態 $\mathbf{x}_t = (x, y, \dot{x}, \dot{y})^T$ 、それに対する位置の観測を $\mathbf{z}_t = (\bar{x}, \bar{y})^T$ とすると、状態遷移モデル F および観測モデル H は式 (2.5) で表される。ただし、 Δt は観測時間間隔である。

$$F = \begin{pmatrix} 1 & 0 & \Delta t & 0 \\ 0 & 1 & 0 & \Delta t \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{pmatrix}, H = \begin{pmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{pmatrix} \quad (2.5)$$

CV モデルは速度が一定であることを仮定したモデルであるが、駆動雑音によって加速/減速が許容される。

この線形演算およびガウス分布で記述されるシステムに対し、Kalman filter は、一時刻前の事後分布と状態遷移モデルから新しい時刻における事前分布を予測し (予測ステップ)、新しい時刻における観測量によって事前分布を修正して事後分布を求める (更新ステップ)。

KF は画像空間 [31] や地面平面 [32]、3次元空間上での歩行者位置のトラッキング [33] に用いられてきた。また、非線形なモデルにも適用したものとして、extended Kalman filter(EKF) や unscented Kalman filter(UKF) があり、同様に歩行者トラッキングに応用されてきた [34, 35]。しかしながら、駆動雑音で許容される範囲以上の急な停止や方向転換には対応できず、ダイナミクスの変化の大きい歩行者の行動に対し、単一のダイナミカルモデルのみで対応することは難しい。

そこで、複雑なダイナミクスの変化を考慮するために複数の線形動的モデルを同時に用いたのが、interacting multiple models Kalman filter(IMM-KF)[36] である。IMM-KF は対象の運動を特徴づける離散的な状態を仮定し、それぞれ別々の線形動的モデルでモデル化を行う (スイッチング線形動的システム)。交通シーンにおける歩行者の状態に対しては以下のようなモデル付けが行われてきた [37, 38]。

- Standing: constant position(CP) Model
- Walking: constant velocity(CV) Model

10 第2章 信号交差点における歩行者横断行動モデル

- Starting: constant acceleration(CA) Model
- Stopping: constant deceleration(CD) Model
- Turning: constant turn(CT) Model

時刻 t においてシステムがとる線形動的モデルを M_t で表すと、式 2.3,2.4 は以下のように書き換えられる。

$$P(X_t = \mathbf{x}_t | X_{t-1} = \mathbf{x}_{t-1}, M_t = i) = N(\mathbf{x}_t; F_i \mathbf{x}_{t-1}, Q_i) \quad (2.6)$$

$$P(Z_t = z | X_t = \mathbf{x}) = N(z; H\mathbf{x}, R) \quad (2.7)$$

$$P(S_t = j | S_{t-1} = i) = M(i, j) \quad (2.8)$$

IMM-KF の 1 時刻間の手続きは、reinitialization ステップ/Filtering ステップ/Update ステップ/Fusion ステップに分かれる。まず、reinitialization ステップでは、状態遷移確率行列を用いて歩行者が各モデルにある確率：モデル確率の予測を行う。この時各モデルにおいて、一時刻前のモデルの占める比率を用いて、一時刻前の状態の加重平均をとる。Filtering ステップでは、各モデルにおいて仮定された LDS に対する Kalman Filter を行う。Update ステップでは、各モデルの filtering ステップにおける状態推定値と観測との尤度比をとり、これをモデル確率とする。Fusion ステップでは、モデル確率を重みとして各モデルの状態推定値の加重平均をとり、システム全体の状態推定値とする。

IMM-KF は推定されているモデルに応じて状態の予測を行うことができるだけでなく、歩行者のモーションをセマンティックに認識できる点においても、KF と比べて応用性が高い。

こうしたダイナミクスに対するモデル化に対し、Chen らは、位置/速度/方向を特徴量としてデータベースとのマッチングを行い、類似した特徴量の軌跡があれば、それを Long-term Prediction として扱う手法を提案した [39, 40]。また、Goldhammer らは、停止状態から歩行状態へ移行する際の頭部位置の軌跡をシグモイド関数等をフィッティングし、位置予測を行った [41]。

画像を用いた手法

前項で述べた手法は歩行者の時系列的な位置：軌道の特徴量としてとらえたものである。しかしながら、位置計測には必ず誤差が含まれるため、ダイナミクスの変化の認識には遅延が生じる。つまり、歩行者のダイナミクスの変化によって、予測される軌道と離れた観測が得られたとしても、それが観測誤差によるものなのかダイナミクスの変化によるものなのか判断するには、さらに観測を重ねなければならないのである。これに対し、ダイナミクスの変化、例えば停止、歩行、走行の違いは見た目上での違いとして現れるため、視覚的特徴量の観察はより早い検出が可能であると考えられる。また Schmidt らの実験研究 [42] では、縁石付近の歩行者が車道に侵入してくるかにおける人間の判断には、軌道のみでは不十分で、頭部や脚部の動きの観察が不可欠であることを示した。これは物理的な軌道に先んずる視覚的な手がかりがあることを示唆している。そこでここでは、歩行者行動の認識の手がかりとして視覚的特徴を用いるアプローチを述べる。

Kohler らは固定カメラにおける動画像を元にした Motion History Image(MHI) から、停

止している歩行者の歩き出しの検出を行っている [43, 44, 45]. MHI は, エッジ画像もしくは歩行者領域 2 値画像を経過時間に応じてディケイさせながら重ね合わせて生成する履歴画像であり, この MHI の HOG 特徴量に対して Support Vector Machine(SVM)[46] を適用し, 停止状態か歩行を開始したかの識別を行う. また, Kohler らは MHI をその他の歩行動作の識別にも応用している [47].

Keller らは, Dense Optical Flow を用いた 2 つのシステムを提案している [38]. Optical Flow は, 連続する 2 枚の画像間における, テクスチャの速度ベクトル場を表現したものである. 歩行中には, 胴体や左右の脚部はそれぞれ異なる動きをするので, その違いを考慮することができ, 歩行者を単純な一つの移動するオブジェクトと捉えるよりも情報量は多くなる. そして, この視覚的特徴を用いることで, 位置情報のみを用いる場合よりも軌道予測や行動識別の性能を向上させることが可能であることを検証するために, 自車両の進行軌道に向かって歩いてくる歩行者がそのまま横断もしくは停止する状況における比較実験を行っている. また同時に, 歩行者位置と Optical Flow の時系列データに対して, 非線形な一次マルコフモデル (Gaussian Process Dynamical Model: GPDM[48]) や非線形な高次マルコフモデル (Probabilistic Hierarchical Trajectory Matching: PHTM) を適用することによる性能向上の検証も行っている. GPDM は, 潜在空間から特徴空間 (ここではオプティカルフローベクトル) へのマッピングと, 潜在空間上の時間ごとの変位をガウス過程 (Gaussian Process) でモデリングするものである. ガウス過程とは, すべての出力が多変量正規分布から生成されていると考えるもので, その多変量正規分布のパラメータを学習データそのもので構成するノンパラメトリックといわれる手法である (一般にパラメトリックな手法では, 各マッピング関数に対してそのパラメータを求める必要があり, しばしば高次なものとなるためたくさんの学習データが必要となる). PHTM では, 時系列の特徴ベクトルからなる軌跡と近い学習データを探索し (Trajectory Matching [49]), それを用いてモデル確率の推定と軌道予測を行う.

これらいずれの研究においても, IMM-KF を基づくシステムとの比較では, 画像特徴を用いた提案システムの方が早くモーションの変化を検出しており, ダイナミクスの変化が位置情報に先んじて視覚情報に生じていることが伺える. しかしながら, これらの車載カメラを前提とした研究ではカメラの自己運動分の補正は行われているものの, 大きな自己運動や観察する方向の変化に耐え得る特徴であるとは考え難い.

3 次元姿勢を用いた手法

Quintero らは, 時系列的な 3 次元姿勢 (身体関節位置とその変位) を特徴量として GPDM を用いることで歩行者のダイナミクスのモデル化を行い, 歩行し続けるシナリオと停止するシナリオにおいて軌道予測を行った [50]. この研究で注目すべきは, モデルの学習を CMU が実験室内でモーションキャプチャシステムを用いて計測した高精度 3 次元モーションデータ [51] で行い, 同様なデータでテストを行うと同時に, KITTI のステレオ画像データセット [52] から推定された低精度の 3 次元姿勢でもテストを行っている点である. これは, 3 次元姿勢が歩行者を観測する方向といった観測環境に依存しない特徴量であるがゆえに可能であり, 自己運動のある車載センサに対しても応用性が高いと考えられる. さらに [53, 54] では, naive

Bayse によるモーション識別を加え、その結果によってモーションごとに学習された GPDM を切り替えた。

2.2.2 コンテキスト/意思に基づく歩行者行動推定

前項で紹介した研究は、歩行者から直接観測可能なもののみに焦点を当ててきた。歩行者の動作は、歩行者自身の持つ意思という内的要因や歩行者を取り巻く環境・状況(コンテキスト)という外的要因に影響を受けて定まる。

例えば、交通シーンにおける歩行者は必ず目的地を持っているはずであるし、横断歩道に向かって歩いてくる歩行者は「前方の横断歩道を渡ろう」といった考えを持っているはずである。また、車道を横断したければ信号現示に従い、信号がなければ接近する車両に注意するように、意思を安全に実現するために交通ルールを守り、自身を取り巻く交通状況を適切に評価している。このように交通シーンにおける歩行者の行動は意思やコンテキストによって決まっている。人間は自身が無意識にそうして行動するように、他者の行動も理解しており、多くのドライバーは歩行者と車両、それらの置かれた環境といったコンテキストから歩行者の意思をある程度予測することができる。例えば、車道に向かって歩いてきた歩行者が自車両の存在に気付いている様子で、自車両との距離が近ければ、停止する可能性は高い。逆に、自車両との距離が遠ければ、そのまま自車両の前を横断するかもしれない。このような背景から、意思やコンテキストといった要因をモデル化し、歩行者行動をシステムとして高次に理解しようとする研究が近年いくつか見られている。

Kooiji らは、上記の例を踏まえ、自車両の進行する車道に向かって歩いてきた歩行者の横断・停止の意思決定に対して、接近する自車両による危険性/歩行者の自車両への意識/車道との空間的配置という三つの要因をピックアップし、Dynamic Bayesian Network(DBN)を用いて歩行者ダイナミクスとの依存関係をモデリングした [55]。また Kooiji らは、自車両を中心とした座標系上での位置に応じて LDS を切り替える、すなわち空間的コンテキストに基づいたモデルも提案している [56]。

Schulz らは位置や頭部姿勢を観測値として Latent-dynamic Conditional Random Fields(LDCRF)を用いることで Crossing/Stopping および Straight-Walking/Bending-In の識別を行い [57]、さらにその結果をもとに SLD を制御することで軌道予測を行った [58]。LDCRF は条件付き確率場: Conditional Random Fields(CRF)[59]に隠れ状態の層を加えて拡張したものでありであり、ジェスチャー認識にも用いられている [60]。

上記のモデルが最大でも 1 秒先の短時間予測を目的としていたのに対し、Bonnin らはより早く正確な歩行者横断意思の認識を実現した [61]。歩行者と自車の軌道の交差点までの予測到達時間や車道を基準とした歩行者の進行方向などさまざまなコンテキストに基づく特徴に対して、パーセプトロンを適用することで、歩行者の横断/停止の識別を行った。更に、横断歩道付近においては、横断歩道までの距離や予測到達時間を入力として追加することで、認識性能を向上させており、コンテキストの重要性を検証した。Volz らは SVM[46]を用い、[61]と同様な 15 種類のコンテキスト特徴量の現在時刻から 4 時刻前まで、計 75 の値を考慮したが、そ

れらを横断意思の識別精度への寄与の小さい順に取り除くことで、重要性の高い特徴量とその時刻を解析した [62].

交通シーンにおいて歩行者は無秩序に動いてはいない。歩行者は常に交通状況を評価し、目的を持ち、行動計画を立てながら動作しており、コンテキスト情報を考慮することは妥当である。ITS の観点から見ても、歩行者や他車両、インフラストラクチャーとの通信によって、様々なコンテキスト情報は提供され得ると言える。本稿で提案する交差点における歩行者行動モデルも、こうした背景に基づいている。

2.2.3 歩行者交通行動の統計モデル

前項では、歩行者の行動は周囲の交通状況や環境に強い結びつきを持っていることを述べた。交通工学の分野では、交通シーンにおける歩行者の行動は統計学的見地から広く解析されてきた。浜岡らは、歩行者が交差点を横断する際に、頭部を回転させて接近する右左折車両を確認する行為の位置ごとの頻度を調査した [63]。歩行者の横断行動が交通状況や道路構造など様々な要因の影響を受けていることが、移動速度や gap acceptance(連続する車両間を横切って横断するか否かの判断)、待ち時間などの観点から分析されている ([64, 65, 66, 67, 68])。

特に信号付横断歩道および交差点では、歩行者の横断領域、タイミングはインフラストラクチャーや自動車によって制限される。井料ら [1]、Zhang[69, 70] らは信号付横断歩道での歩行者の横断/待機の意思決定や歩行速度を解析した。彼女らは信号現示や歩行者と横断歩道の関係性、横断歩道長を考慮した確率モデルを提案した。さらに、井料らは歩行者の加速/減速と青信号点滅時間内で渡り終えるために必要な速度などとの関係性の分析を行った [71]。Zeng らは social force model を用いて交差点周りの軌道モデルを提案した [72, 73]。Social force model は、歩行者を質点とみなし運動方程式を考えるもので、そこでの仮想的な外力として、目的地や横断歩道境界、信号現示から受ける引力や衝突回避のために他歩行者/右左折車両から受ける斥力のモデルを提唱した。

こうした交通工学における研究では、どのような因子がどのように行動に影響を与えるかという説明のためのマクロな観点での解析がなされており、それを用いてシミュレーションを行い、インフラストラクチャーの改善を行うという目的のものも多い。自動運転や安全支援システムとしてオンラインに歩行者の行動を理解するために、こうしたモデルを再解釈することは本稿の目的の一つである。

2.3 ダイナミックベイジアンネットワーク

本論文では、ダイナミックベイジアンネットワークという確率モデルの枠組みの中で、交差点における歩行者行動のモデル化を行う。本章では、モデルの提案に先立ち、ダイナミックベイジアンネットワークおよびその基盤となるベイズ推定およびベイジアンネットワークの基礎的な理論を導入する。

2.3.1 ベイズ推定

ベイズ推定は、観測された事象からその原因となった事象を、以下で表されるベイズの定理によって、確率的な枠組みで推定する手法である。

$$P(A|B) = \frac{P(A)P(B|A)}{P(B)} = \frac{P(A)P(B|A)}{\sum_A P(A)P(B|A)} \propto P(A)P(B|A) \quad (2.9)$$

この式は条件付き確率に関する恒等式であるが、ある事象 B に対する情報を得た際、 B の原因である A (つまり B は A に対する証拠である) に対する分布 $P(A|B)$ (事後分布) は、 B を得る前の分布 $P(A)$ (事前分布) を、 A を仮定した際に B が得られる確率 $P(B|A)$ (尤度) で改訂ことによって得られると解釈することができる。例えば、 B が値 A に対するエラーを含む計測値であるとする、計測結果である B からその原因となっている A の値の分布を推定する手続きとなる。この時、 A の値の分布に関して、事前になんらかの情報を持っている (ただし一様分布でも良い)。

2.3.2 ベイジアンネットワーク

ベイジアンネットワーク (Bayesian Network) は、複数の確率変数間の因果関係を条件付き確率として記述することにより事象の推論を行うグラフィカルモデルである。ベイジアンネットワークは有向非巡回グラフで表され、確率変数と確率変数間の条件付依存関係、その条件付確率の3つによって定義される。ノードは確率変数を表し、離散変数および連続変数を設定することができる。有向エッジはノード間の条件付依存関係を表し、原因となる変数のノードから結果となる変数のノードの方向に張られ、順に親ノード、子ノードと呼ばれる。ベイジアンネットワーク内のあるノード X_i は、 X_i に対するすべての親ノードの値に依存して決定される。この親ノードの集合を $\pi(X_i)$ と書くと、 X_i との条件付依存関係は条件付確率 $P(X_i|\pi(X_i))$ で表される。この際、条件付確率には任意のものを設定でき、親/子ノードともに離散変数であれば、それぞれがとる全ての状態の組み合わせに対して確率値を列挙した表 (条件付確率表) により表現される。また、連続変数であれば、非線形/非ガウシアンな関係性もモデル化することができる。確率変数 X_1, X_2, \dots, X_n をノードとして持つベイジアンネットワーク全体で見たとき、全ての確率変数の同時確率分布は以下のようになる。

$$P(X_1, X_2, \dots, X_n) = \prod_i P(X_i|\pi(X_i)) \quad (2.10)$$




図 2.2. 3 変数ベイジアンネットワーク例のグラフ表現

ただし、 $\pi(X_i)$ が空集合、つまりノード X_i が親ノードを持たない場合、 $P(X_i|\pi(X_i)) = P(X_i)$ となる。

例えば、確率変数 X に依存して決まる確率変数 Y と、 X, Y に依存して決まる可観測確率変数 Z があるとき、これらの確率変数とその関係性は図 2.2 のようなベイジアンネットワークとして表される。また、 $\pi(Y) = X$ 、 $\pi(Z) = X, Y$ であり、同時確率分布は以下のように表される。

$$P(X, Y, Z) = P(X)P(Y|X)P(Z|X, Y) \quad (2.11)$$

観測は原因と結果の関係における結果にあたる。よって、ベイジアンネットワークにおいて、エッジは可観測ノードに向かって張られ、グラフの末端に存在することになる。ここで、前項で示したベイズの定理によって、グラフの非観測部分を推定することができる。図 2.2 の例では、観測 Z を得た際の X および Y の事後分布は以下のように求められる。

$$P(X, Y|Z) = \frac{P(X)P(Y|X)P(Z|X, Y)}{\sum_{X, Y} P(X)P(Y|X)P(Z|X, Y)} \quad (2.12)$$

ここで右辺分子は同時確率分布：式 (2.11) と等しく、各項はベイジアンネットワーク構築時に条件付確率（親ノードを持たないノードは事前確率）として定義されるものである。また、分母は単なる正規化項であるため、計算可能である。

2.3.3 ダイナミックベイジアンネットワーク

ダイナミックベイジアンネットワーク (Dynamic Bayesian Network) は、同一のベイジアンネットワークを連続的に結合したものであり、ノードは隣合うベイジアンネットワークのノードともエッジによる結合ができる。ただし、自ベイジアンネットワークからは片方の隣接するネットワークに向かってのみエッジを張ることができ、逆にもう片方の隣接するネットワークから自ネットワークに向かってエッジが張られる。このネットワーク間のエッジも含めて、両端を除く全てのネットワークは同一グラフ構造をとる。

こうした特性から、ダイナミックベイジアンネットワークは時系列データのモデル化に用いることが可能である。例えば、時系列状態推定に用いられる、隠れマルコフモデル (hidden Markov model: HMM) は、非観測ノードが離散値のみをとる、ダイナミックベイジアンネッ

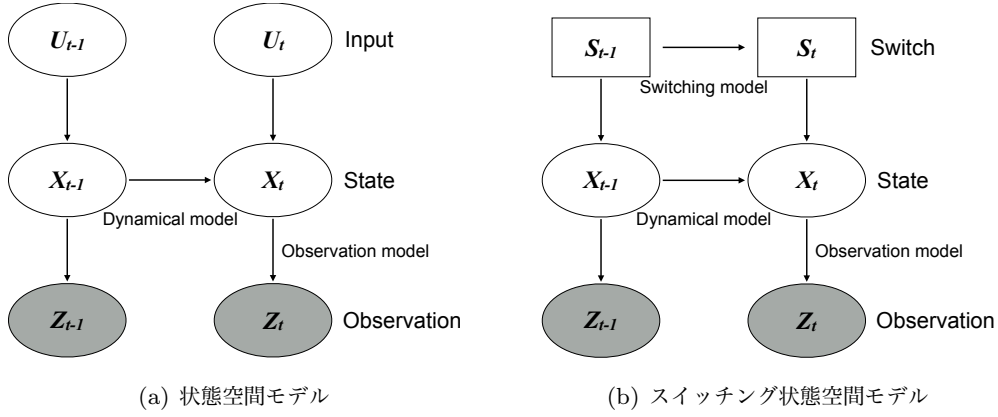


図 2.3. 状態空間モデルのグラフ表現例

トワークの特殊例といえる。

また、制御工学における状態空間モデル (state-space model: SSM) もダイナミックベイジアンネットワークの一例であると言え、図 2.3(a) のようにグラフ表現することができる。状態空間モデルは一般に以下 Dynamical model : 式 (2.3)/Observation model : 式 (2.4) のように表される。

$$\mathbf{x}_t = f(t, \mathbf{x}_{t-1}, \mathbf{u}_t) \quad (2.13)$$

$$\mathbf{z}_t = h(t, \mathbf{x}_t, \mathbf{u}_t) \quad (2.14)$$

2.2.1 節で述べた線形動的システムは、線形・ガウス型、入力なしの状態空間モデルといえ、歩行者のダイナミクスであれば、 X_t は歩行者の真の位置、 Z_t は X_t の計測値に相当し、CV モデルを仮定すると dynamical model は式 (2.1) に、observation model は式 (2.2) に相当する。さらに、状態空間モデルを拡張したスイッチング状態空間モデルも同様にダイナミックベイジアンネットワークと解釈することができ、グラフ表現を図 2.3(b) に示す。ただし、簡単のため入力 U を省略している。

このようにダイナミックベイジアンネットワークは多くの確率過程モデルの一般形と捉えることができ、柔軟に複雑なモデルを構築することが可能である。

2.3.4 状態推定手法

前項でダイナミックベイジアンネットワークによるモデル表現の柔軟性について触れた。本項では、そのダイナミックベイジアンネットワークの状態を時系列データから推定する方法について述べる。

ダイナミックベイジアンネットワークを動的システムとみなすことで、ベイジアンフィルタリングの原理により、その状態を推定することができる。ベイジアンフィルタリングは、システムの状態 \mathbf{x}_t の事後確率を、得られた観測値 $\mathbf{z}_{1:t}$ から、再帰的に推定するものである。各時刻において事前分布 $P(\mathbf{x}_t | \mathbf{z}_{1:t-1})$ は、マルコフ過程の仮定により一時刻前の事後分布 $P(\mathbf{x}_{t-1} | \mathbf{z}_{1:t-1})$ と状態遷移モデル $P(\mathbf{x}_t | \mathbf{x}_{t-1})$ によって予測される。これは以下のように位置

時刻前の状態で周辺化することによって得られる.

$$P(\mathbf{x}_t | \mathbf{z}_{1:t-1}) = \int P(\mathbf{x}_t | \mathbf{x}_{t-1}) P(\mathbf{x}_{t-1} | \mathbf{z}_{1:t-1}) d\mathbf{x}_{t-1} \quad (2.15)$$

新たな観測値 z_t が可能になると, 事後分布 $P(\mathbf{x}_t | \mathbf{z}_{1:t})$ は観測尤度 $P(z_t | \mathbf{x}_t)$ で事前分布を修正することによって得られる. 事後分布は, ベイズの定理 (2.9) と式 (2.15) により更新式として求められる.

$$\begin{aligned} P(\mathbf{x}_t | \mathbf{z}_{1:t}) &= \frac{P(z_t | \mathbf{x}_t) P(\mathbf{x}_t | \mathbf{z}_{1:t-1})}{P(z_t | \mathbf{z}_{1:t-1})} \\ &\propto P(z_t | \mathbf{x}_t) \int P(\mathbf{x}_t | \mathbf{x}_{t-1}) P(\mathbf{x}_{t-1} | \mathbf{z}_{1:t-1}) d\mathbf{x}_{t-1} \end{aligned} \quad (2.16)$$

ダイナミックベイジアンネットワークにおける状態推定問題は以下のようにいくつかのバリエーションを考え得る.

フィルタリング (Filtering) ある時刻までの観測系列をもって, その時刻の状態を事後分布 $P(X_t | \mathbf{z}_{1:t})$ を推定する.

予測 (Prediction) ある時刻までの観測系列をもって, h 時刻 ($h > 0$) 先の未来の状態の分布 $P(X_{t+h} | \mathbf{z}_{1:t})$ を推定する.

固定ラグ平滑化 (Fixed-lag smoothing) ある時刻までの観測系列をもって, l 時刻 ($l > 0$) 前の過去の状態の分布 $P(X_{t-l} | \mathbf{z}_{1:t})$ を推定する.

固定区間平滑化 (Fixed-interval smoothing) 全時刻の観測系列をもって, ある時刻の状態の分布 $P(X_t | \mathbf{z}_{1:T})$ をオフライン推定する.

ビタビ復号 (Viterbi decoding) 観測系列を最も良く説明する状態系列 $\arg \max_{x_{1:t}} P(x_{1:t} | \mathbf{z}_{1:t})$ を推定する.

ここで, 本論文で議論する車載安全システムとして歩行者を保護するために必要となるのは, フィルタリングおよび予測である. 多くの場合予測問題はフィルタリング手法を応用することで解けるため, ここではフィルタリング手法に焦点を当てる.

非観測ノードに連続変数を含むか含まないか (つまりすべてが離散量であるか) により, 区別することが必要となる. 先に述べた車載安全システムへの応用を考えれば, 歩行者の位置のような連続変数を必ず含み前者に該当するはずであるし, 後者の場合, 隠れマルコフモデルへと変換し, Forward-Backward アルゴリズムを適用することで, 近似を用いない正確な事後分布の推定が可能となるため, ここでは後者については論じない. ただし, N 個のノードが最小で M 個の離散値を取るダイナミックベイジアンネットワークは, 少なくとも M^N 個の状態を取り得る隠れマルコフモデルと等価であるため, 問題によっては状態数が莫大になり, この解法は現実的でない. 近似を用いる手法を含め, より効率的な手法を用いる必要がある場合があることに注意が必要である. 前者, つまり非観測ノードに連続変数を含むほとんどの場合においては, 事後分布は閉形式で正確な表現ができず, 近似を用いる必要がある. 以下でこのような場合における状態推定方法を紹介する.

カルマンフィルタ

先に、非観測ノードに連続変数を含むほとんどの場合においては、事後分布は閉形式で正確な表現ができないことを述べたが、例外として遷移モデルと観測モデルが共役な場合が挙げられる。線形・ガウス型状態空間モデルはこれに該当し、事後分布は常に正確なガウス分布で表現され得る。なぜならば、一時刻前の事後分布 $P(\mathbf{x}_{t-1}|\mathbf{z}_{1:t-1})$ がガウス分布であると仮定すれば、 \mathbf{x}_{t-1} の線形変換とガウス雑音の足しあわせである $P(\mathbf{x}_t|\mathbf{z}_{1:t-1})$ もガウス分布であり、さらにこれとガウス分布で表される観測尤度 $P(\mathbf{z}_t|\mathbf{x}_t)$ を組み合わせた事後分布 $P(\mathbf{x}_t|\mathbf{z}_{1:t})$ もガウス分布になるからである。

2.2.1 でも紹介したカルマンフィルタは、この線形・ガウス型状態空間モデルにおけるフィルタリング問題に対する解法と言える。以下の予測ステップと更新ステップを行うことで、時刻 $t-1$ の推定状態と時刻 t の観測から、時刻 t の状態を推定する。ただし、時刻 m 時点における時刻 n に対する状態の推定値を $\hat{\mathbf{x}}_{n|m}$ とし、同様に誤差の共分散行列を $P_{n|m}$ で表す。

予測ステップ

$$\text{状態予測値: } \hat{\mathbf{x}}_{t|t-1} = F\hat{\mathbf{x}}_{t-1|t-1} \quad (2.17)$$

$$\text{誤差共分散予測値: } P_{t|t-1} = FP_{t-1|t-1}F^T + Q \quad (2.18)$$

更新ステップ

$$\text{観測残差: } \mathbf{e}_t = \mathbf{z}_t - H_t\hat{\mathbf{x}}_{t|t-1} \quad (2.19)$$

$$\text{観測残差共分散: } S_t = R_t + H_tP_{t|t-1}H_t^T \quad (2.20)$$

$$\text{最適カルマンゲイン: } K_t = P_{t|t-1}H_t^TS_t^{-1} \quad (2.21)$$

$$\text{状態推定値: } \hat{\mathbf{x}}_{t|t} = \hat{\mathbf{x}}_{t|t-1} + K_t * \mathbf{e}_t \quad (2.22)$$

$$\text{誤差共分散推定値: } P_{t|t} = (I - K_tH_t)P_{t|t-1} \quad (2.23)$$

また、一時刻以上の予測を行う場合は、Predict ステップのみを繰り返す。

非線形・ガウス型状態空間モデルに対しては、一次近似を行うことができる。

$$\mathbf{x}_t = f(\hat{\mathbf{x}}_{t-1|t-1}) + A_{\hat{\mathbf{x}}_{t-1|t-1}}(\mathbf{x}_{t-1} - \hat{\mathbf{x}}_{t-1|t-1}) + B\mathbf{u}_t + \mathbf{w}_t \quad (2.24)$$

$$\mathbf{z}_t = g(\hat{\mathbf{x}}_{t|t-1}) + C_{\hat{\mathbf{x}}_{t|t-1}}(\mathbf{x}_t - \hat{\mathbf{x}}_{t|t-1}) + \mathbf{v}_t \quad (2.25)$$

ただし、 $\hat{\mathbf{x}}_{t|t-1} = f(\hat{\mathbf{x}}_{t-1|t-1})$ であり、 $A_{\hat{\mathbf{x}}}, C_{\hat{\mathbf{x}}}$ は f, g のヤコビ行列である。

$$A_{\hat{\mathbf{x}}} = \left. \frac{\partial f}{\partial \mathbf{x}} \right|_{\hat{\mathbf{x}}}, \quad C_{\hat{\mathbf{x}}} = \left. \frac{\partial g}{\partial \mathbf{x}} \right|_{\hat{\mathbf{x}}} \quad (2.26)$$

拡張カルマンフィルタは、この状態依存の遷移、観測行列を持つ一次近似モデルに対して、通常のカルマンフィルタを適用するものである。

また、スイッチング状態空間モデルにおいて事後分布は、一つのスイッチに対して一つのガウス分布が対応する混合ガウス分布で近似できると仮定するのが自然である。つまり、スイッチ数が M の場合、一時刻前の事後分布 $P(\mathbf{x}_{t-1}, S_{t-1}|\mathbf{z}_{1:t-1})$ は、 M 個のガウス分布の足しあわせであるとする。この時、ある新たなスイッチ $S_t = j$ に対して、各一時刻前のスイッチ

$S_t = i$ からパラメータ θ_j を用いた通常のカルマンフィルタによる更新が行われる．これにより，事後分布 $P(\mathbf{x}_t, S_t | \mathbf{z}_{1:t-1}, S_{t-1})$ は M^2 個の混合ガウス分布となる．しかし，初めに仮定したように M 個の混合ガウス分布に戻る必要があり，これに対していくつかの手法が考えられる．

SecondOrder Generalized Pseudo-Bayesian(GPB2) アルゴリズム [74, 75] では，一時刻前のスイッチ $S_{t-1} = i$ および新しいスイッチ $S_t = j$ の各組み合わせに対して，パラメータ θ_j を用いたカルマンフィルタを行い， $P(\mathbf{x}_t, S_t = j, S_{t-1} = i | \mathbf{z}_{1:t})$ を得る．ここで各 S_t に対して，moment matching により S_{t-1} を周辺化する．周辺化前の分布は，重み p_{ij} とともに以下のように書ける．

$$P(X_t, S_t = j, S_{t-1} = i | \mathbf{z}_{1:t}) = p_{ij} N(X_t; \boldsymbol{\mu}_{ij}, \Sigma_{ij}) \quad (2.27)$$

S_{t-1} の周辺化により，最終的な事後分布はモデル確率 p_j を用いて以下のように書ける．

$$P(X_t, S_t = j | \mathbf{z}_{1:t}) = p_j N(X_t; \boldsymbol{\mu}_j, \Sigma_j) \quad (2.28)$$

ただし，各パラメータは以下のように求められる．

$$\begin{aligned} p_i &= \sum_j p_{ij}, \quad p_{j|i} = \frac{p_{ij}}{\sum_j p_{ij}} \\ \mu_j &= \sum_i \mu_{ij} p_{j|i}, \quad \Sigma_j = \sum_i \Sigma_{ij} p_{j|i} + \sum_i (\mu_{ij} - \mu_j)(\mu_{ij} - \mu_j)^T p_{j|i} \end{aligned} \quad (2.29)$$

これに対し，interacting multiple models(IMM) カルマンフィルタ [76, 75] では，初めに新たなスイッチ各 $S_t = j$ に対して，モデル確率の予測と moment matching により一時刻前の S_{t-1} を周辺化し， $P(\mathbf{x}_{t-1}, S_t = j | \mathbf{z}_{1:t-1})$ を得る．これに対してパラメータ θ_j を用いたカルマンフィルタを行うことで $P(X_t, S_t = j | \mathbf{z}_{1:t})$ を求める．GPB2 アルゴリズムでは M^2 回のカルマンフィルタを実行するのに対し，IMM カルマンフィルタでは M 回の実行となる．

また，First Generalized Pseudo-Bayesian(GPB1) アルゴリズム [77] では，事後分布は単一のガウス分布で表し，新たなスイッチ $S_t = j$ ごとにパラメータ θ_j を用いたカルマンフィルタとモデル確率の更新により $P(X_t, S_t = j | \mathbf{z}_{1:t})$ を求めた後， S_t に対する周辺化を行う．

Assumed Density Filter

Assumed density filter は事後分布を限定された分布族 \mathcal{F} に従うと仮定するものである．一時刻前の事後分布 $\tilde{\alpha}_{t-1} \in \mathcal{F}$ に対し，モデルによる更新を行って $\hat{\alpha}_t$ を得る．しかしながら，多くの場合 $\hat{\alpha}_t \notin \mathcal{F}$ であるため， \mathcal{F} に属し，最も近い分布を以ってして近似する．すなわち， $\tilde{\alpha}_t = \arg \min_{q \in \mathcal{F}} D(\hat{\alpha}_t || q)$ を求める．もし， \mathcal{F} が指数分布族であれば，moment matching によって解ける [78]．

例えば，線形・ガウス型の遷移モデルと非線形・非ガウス型の観測モデルに対して，事後分布をガウス分布で近似する．

$$P(\mathbf{x}_{t-1} | \mathbf{z}_{1:t-1}) \approx \tilde{\alpha}(\mathbf{x}_{t-1} | t-1) = N(\mathbf{x}_{t-1}; \tilde{\mathbf{x}}_{t-1:t-1}, \tilde{P}_{t-1|t-1}) \quad (2.30)$$

20 第2章 信号交差点における歩行者横断行動モデル

この時、一時刻前の事後分布に対する線形変換とガウス雑音の足しあわせにより、ガウス分布の予測を得る。

$$P(\mathbf{x}_t | \mathbf{z}_{1:t-1}) \approx \tilde{\alpha}(\mathbf{x}_{t|t-1}) = N(\mathbf{x}_t; A\tilde{\mathbf{x}}_{t-1:t-1}, A\tilde{P}_{t-1|t-1}A^T + Q) \quad (2.31)$$

更新は以下のようになる。

$$\begin{aligned} \hat{\alpha}(\mathbf{x}_{t|t}) = P(\mathbf{x}_t | \mathbf{z}_{1:t}) &= \frac{P(\mathbf{z}_t | \mathbf{x}_t) P(\mathbf{x}_t | \mathbf{z}_{1:t-1})}{\int_{\mathbf{x}_t} P(\mathbf{z}_t | \mathbf{x}_t) P(\mathbf{x}_t | \mathbf{z}_{1:t-1})} \\ &\approx \frac{P(\mathbf{z}_t | \mathbf{x}_t) \tilde{\alpha}(\mathbf{x}_{t|t-1})}{\int_{\mathbf{x}_t} P(\mathbf{z}_t | \mathbf{x}_t) \tilde{\alpha}(\mathbf{x}_{t|t-1})} \end{aligned} \quad (2.32)$$

この時、非線形・非ガウス型の観測モデルの仮定から、 $\hat{\alpha}(\mathbf{x}_{t|t})$ は非ガウス分布である。Assumed density filter ではこの $\hat{\alpha}(\mathbf{x}_{t|t})$ の平均および分散パラメータを求めることで、新たな事後分布のガウス分布による近似 $\tilde{\alpha}(\mathbf{x}_{t|t})$ を得るのである。

Kooji ら [55] のコンテキストを活用した歩行者行動モデルにおける状態推定では、この assumed density filter が用いられている。

粒子フィルタ

これまで述べたフィルタリング手法は、ネットワークの構成や事後分布が限定されていた。任意のトポロジーおよび条件付確率を持つダイナミックベイジアンネットワークに対して適用可能な唯一の手法として、離散化およびサンプリングを用いる粒子フィルタがある。

粒子フィルタ (particle filter, または逐次モンテカルロ法: Sequential Monte Carlo)[79] は、与えられたデータに対してパラメータや状態値の事後分布をパーティクルと呼ばれる大量のサンプルで近似、推定する手法である。同様にサンプリングによって事後分布を近似するマルコフ連鎖モンテカルロ法 (Markov chain Monte Carlo methods)[80] が、一定期間もしくは一定量のデータに対して一括的に推定を行うバッチ処理方式であるのに対し、粒子フィルタはデータストリーム上で逐次的に推定を行う。

各々のパーティクルは状態空間内の値 $\mathbf{x}_t^{(i)}$ と重み $w_t^{(i)}$ を持ち (時刻 t , i 番目のパーティクル), 事後分布は以下のように近似される。

$$P(\mathbf{x}_t | \mathbf{z}_{1:t}) \approx \sum_i w_t^{(i)} \delta(\mathbf{x}_t | \mathbf{x}_t^{(i)}) \quad (2.33)$$

ただし、全パーティクルの重みの合計は1である ($\sum_i w_t^{(i)} = 1$)。一般的な Sampling Importance Resampling アルゴリズムでは、サンプリングステップ (sampling step), 重点サンプリングステップ (importance sampling step), 再サンプリングステップ (re-sampling step) という三ステップに分けられる。

サンプリングステップは予測にあたり、各パーティクルが遷移モデル $P(\mathbf{x}_t | \mathbf{x}_{t-1})$ によって直前の状態から状態空間内を移動する。この時、もし想定した遷移モデルから容易にサンプルを得られない場合、提案分布と呼ばれる別の確率分布 $q(\mathbf{x}_t | \mathbf{x}_{0:t-1}, \mathbf{z}_{0:t})$ を用いて、サンプリングを行うことができる。

重点サンプリングステップは修正に相当し、 i 番目のパーティクルの重みは一般的に以下のようにより時刻前のものから更新および正規化によって決定される。

$$w_t^{*(i)} = w_{t-1}^{(i)} \frac{P(\mathbf{z}_t | \mathbf{x}_t^{(i)}) P(\mathbf{x}_t^{(i)} | \mathbf{x}_{t-1}^{(i)})}{q(\mathbf{x}_t^{(i)} | \mathbf{x}_{0:t-1}^{(i)}, \mathbf{z}_{0:t})} \quad (2.34)$$

$$w_t^{(i)} = \frac{w_t^{*(i)}}{\sum_i w_t^{*(i)}} \quad (2.35)$$

最後に、少数のパーティクルを除きほぼ全ての重みがゼロに近付くこと (粒子の縮退と呼ばれる) を防ぐために再サンプリングステップが行なわれる。まず有効粒子数 N_{eff} [81] の推定量 $\widehat{N_{eff}}$ [82] を計算し、もし閾値 N_{thr} より少なかった場合に再サンプリングを実行する。

$$N_{eff} = \frac{N}{1 + \text{var}_{q(\cdot | \mathbf{z}_{0:k})}((w_t^{*(i)})^2)} \quad (2.36)$$

$$\widehat{N_{eff}} = \frac{1}{\sum_i (w_t^{(i)})^2} \quad (2.37)$$

再サンプリングステップでは、パーティクルの数の分布が実行前の重みの分布と比例するように、重みの小さなパーティクルを破棄し、重みの大きなものを複製する。つまり、現在の粒子の集合から、重みに比例した確率で実行前と同数の粒子をサンプルし、置き換える。この操作直後、すべてのパーティクルは同じ重みを持つ。

2.3.5 先行事例

前項までで述べた、原因と結果の関係性を多層的に確率モデル化することが可能である特性から、ベイジアンネットワークやダイナミックベイジアンネットワークは人間の行動認識に多く応用されてきた。なぜなら、人間の行動は環境や意思などが複雑に影響をおよぼし決定されるからである。また、ほとんどの場合一人一人行動の傾向は異なる上、同一の人間であっても時間や状況で変わってくる。同時に、多くの問題において、センサによる状態量の観測が行われ、そこには必ずノイズが含まれる。こうした不確かさが存在する問題において、確率的枠組みによる推定は不可欠だからである。以下はダイナミックベイジアンネットワークを用いた人間の行動認識の先行研究である。

Patterson らは、駐車場やバス停の位置といった外部知識を有効に用いることで、誤差を多く含む GPS データストリートから、徒歩か車かバスかという人の交通モードの推定を行った [83]。Mitra らは会話認識を [84]、Suk らはハンドジェスチャー認識を [85] 行った。Wenhui らは、人のストレス度と表情、眼/頭部の動きの関係性のモデル化を行い、動画からストレス推定を行った [86]。Chung-Lin らは、サッカーの試合の動画中におけるゴールなどのイベントの認識を用いて行った [87]。Park らは、ベイジアンネットワークとダイナミックベイジアンネットワークを多層的に組み合わせ、動画内の人間の行動、インタラクションの認識を行った [88]。Yingning らは、ショッピングセンターにおける、歩行者の頭部姿勢の変化パターンをモデル化し、店舗への入店意思を推定した [89]。

2.4 提案モデル

本節では、前節で導入したダイナミックベイジアンネットワークを用いた、交差点における歩行者の横断行動モデルの提案を行う。歩行者の運動特性に限らず、その意思や信号や横断歩道との相対関係といった様々なコンテキスト情報を考慮し、その関係性を確率的に定式化する。

2.4.1 歩行者状態空間

本項では、ダイナミックベイジアンネットワークの状態空間として確率変数を定める。まず、歩行者の状態として以下を考える。

D : 横断意思 (crossing decision). 直行する方向の交通流に対する信号が青になる前に横断歩道を横断するか、次の PG まで待機するかという意味である。

$$D_t \in \{cross, wait\} \quad (2.38)$$

横断歩道付近における歩行者の行動はこの状態変数に左右され、軌跡のコンフリクトが生じ得る右左折車にとって非常に重要である。すなわち、もし歩行者が横断することを決定すると、少なくとも渡り切るまで移動し続け、ドライバーもしくは車載安全システムはその歩行者の動きを監視し続ける必要がある。逆に、歩行者が待機する意思決定をした場合、その歩行者は車道に侵入する前に止まると考えられ、危険な状況を生じ得ず、その前を通過することができる。この横断意思を知ることはドライバーあるいはシステムの意思決定に対して非常に有益である。

M : モーション (motion type).

$$M_t \in \{standing, walking, running\} \quad (2.39)$$

それぞれの値は、停止状態、歩行状態、走行状態を表す。走行状態は両足が地面から浮く瞬間がある状態と定義する。逆に歩行状態は少なくとも片方の足が常に地面に接する。走行状態は運動の激しさや脚の回転数の速さの観点から多様性を持っているが、歩行状態を含めそれらは連続的であると同時に、一つの運動モデル: CV モデルで近似することができる。しかしながら、こうした動作は歩行者の意図を暗示するものであり、このように基本的な動作として区別することは重要である。例えば、走行動作は歩行者の急ぎに伴うものであり、走っている歩行者はほぼ確実に横断意思を持っていると言えよう。

Sp : 移動速度 (travelling speed). 一次元のスカラー量である。

Dr : 移動方向 (travelling direction). 地面平面に固定された座標系における移動ベクトルの方向である。

P : 位置 (position). 地面平面上における 2 次元量である.

$$P_t = \begin{bmatrix} x_t \\ y_t \end{bmatrix} \quad (2.40)$$

歩行者の横断歩道の横断シナリオで、歩行者は横断歩道との相対的な位置関係によって、行動を決定すると考えられるため、その相対位置を考慮できる座標系で考える.

Z : 観測位置 (position measurement). 真の位置 P に対する観測値である.

$$Z_t = \begin{bmatrix} z_{xt} \\ z_{yt} \end{bmatrix} \quad (2.41)$$

これらの歩行者に対する状態変数に加え、交差点交通におけるコンテキストとして以下の変数を定める.

Sf : 歩行者信号現示 (pedestrian signal phase). 信号現示は歩行者がいつ横断歩道を横断可能かを定めるものであり、歩行者行動に大きく影響を与える.

$$Sf_t \in \{PG, PFG_PR\} \quad (2.42)$$

2.1 で述べたように、日本において歩行者信号現示は PF, PFG, PR の 3 種類あるが、ここでの変数としては、PFG と PR を結合して考える. これは、その後の横断を制度上禁止する PFG の開始が、歩行者の行動を横断するか次の PG まで待機するかを分け、意思決定後の歩行者にとって PFG か PR かは大きく影響を与えないと考えるためである. 本研究では、V2I 通信により信号現示の遷移スケジュールが与えられると仮定し、各時刻における真の信号現示が得られるものとする.

Se : 信号経過時間 (signal elapsed time). 信号現示が変化してからの経過時間である. 歩行者はおおよそその経過時間 (および残り時間) を見積もることができ、信号現示と同様、歩行者行動を左右するものと考えられる. また、信号現示と同様、V2I 通信により真の経過時間が得られるものとする.

V : 待機車 (turning vehicle).

$$V_t \in \{no_vehicle, vehicle_exist\} \quad (2.43)$$

それぞれの値は、横断歩道周辺に右左折待機車が存在しない/する状態を表す. 特に PFG 開始後には、ドライバーがこれ以上横断を開始する歩行者はいないと判断し、車両の右左折が開始されることが考えられる. そこへ駆け込むのはリスクが大きいため、こうした右左折車の存在は歩行者の意思決定、行動に影響を及ぼし得る. また、PG 時は歩行者は優先権を有するものの、右左折車両を長く待たせない気遣いから走る等して急ぐ歩行者も見られる.

G : グループ (group).

$$G \in \{alone, in_group\} \quad (2.44)$$

それぞれの値は、単独での移動、同行者を連れての移動を表す. 同行者との移動は意思疎通や行動の同期が必要となるため、走ったり、PFG 開始後の無理な横断のような、急

24 第2章 信号交差点における歩行者横断行動モデル

激な運動特性の変化は避ける傾向にあると考えられる。横断歩道周りの観測の中で集団が解散することはないと考え、単一の歩行者の対しては、時間に依存せず一定値である。
Sd: 横断方向 (crossing side).

$$Sd \in \{near_side, far_side\} \quad (2.45)$$

右左折車両との交通流と交差する領域は、その周辺でのみ走るといった歩行者行動が起こるが、横断歩道において near-side 寄りに位置している。このため、near-side 歩行者は横断の前半において、far-side 歩行者は後半にこの領域に差し掛かることとなり、この差異は歩行者行動にも影響を及ぼし得る。観測の中で歩行者が逆方向に向かって引き返すことはないとし、単一の歩行者の対しては、時間に依存せず一定値である。

Cl: 横断歩道長 (crosswalk length). 横断歩道が長いほど横断に時間を要し、PR になってしまったり、車両とのコンフリクトが起こり得るため、PFG 開始後の無理な横断は避けると考えられる。単一の横断歩道上の歩行者を観測している上では、時間に依存せず一定値である。

Dp: 他歩行者との最短距離 (distance to closest pedestrian). 歩行者は公共空間での移動において、他人との距離は一定以上に保つ一方、集団として同行者と行動している時は逆におよそ一定に保つ。つまり、この値は G に大きな影響を受けると考えられる。

W: 横断歩道相対所在 (whereabouts).

$$W_t \in \{before, on\} \quad (2.46)$$

それぞれの値は、横断歩道前か横断歩道上かを表す。これら二つにおける行動特性は大きく異なる。横断歩道の横断を企てている場合、PG の間に横断歩道に進入するために急ぐことがある。横断歩道に向かって走ってきたものの、横断歩道へ到達すると走るのをやめるといった行動はよく見受けられる。こうした行動は PFG 時にも見られ、本来は禁止されている PFG 開始後の横断歩道への進入であっても、横断歩道上においては歩行者が強い優先権があると考えての行動と考えられる。また、次の PG まで横断を待つと考えた場合は横断歩道手前で停止するが、横断歩道上で歩行者が停止することは滅多にない。もちろん横断歩道後も行動特性は異なるが、安全システムの観点からは重要でないため、本稿では対象としない。

この値は歩行者の位置 P_t により一意に定まるため、 P_t の関数としての表記と併用する。つまり、 W_t および $W(P_t)$ は同じ値を表す。

L^{in}, L^{out}, L^d : 横断歩道入口/横断歩道出口/一時的目的地までの距離 (distance to crosswalk entrance/exit, destination). 横断歩道に向かっている間は横断歩道に到達するまでの距離 L^{in} が、横断歩道上では横断歩道を出るまでの距離 L^{out} が、歩行者の行動特性を左右すると考え、これを一時的な目的地と考える。 L^d は横断歩道前か横断歩道上かでそれぞれ L^{in}, L^{out} を示す。これも W と同様に位置 P_t により一意に定まるため、 P_t の関数としての表記と併用する。

$$L^d(P_t) = \begin{cases} L^{in}(P_t) & (W(P_t) = before) \\ L^{out}(P_t) & (W(P_t) = on) \end{cases} \quad (2.47)$$

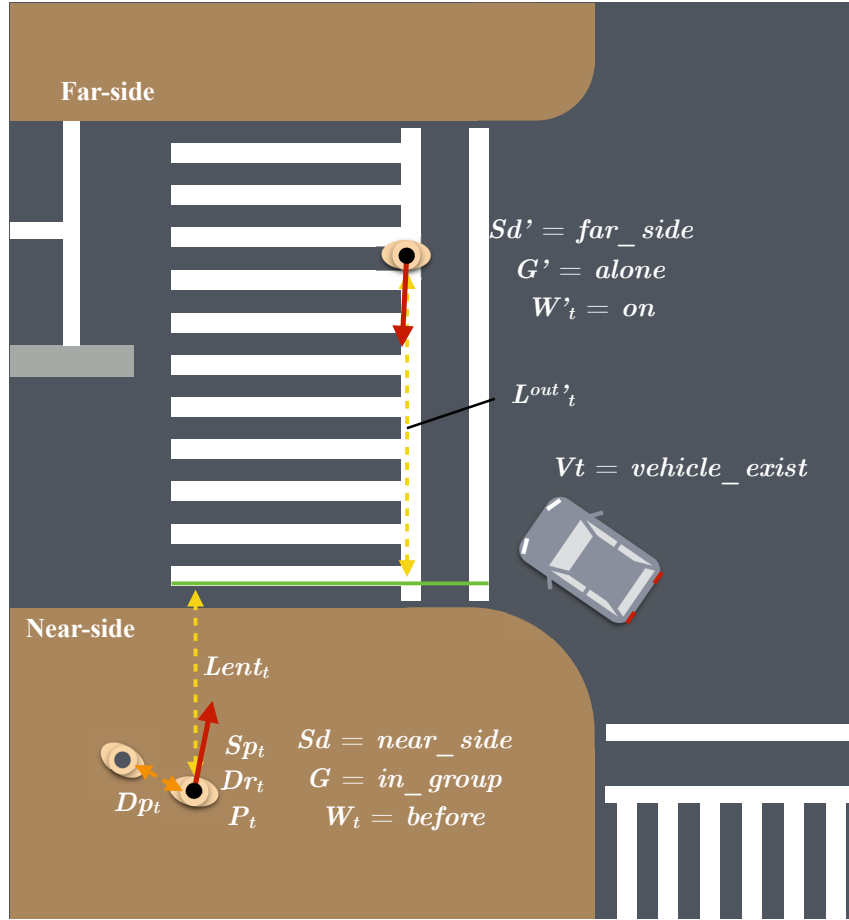


図 2.4. 提案モデルにおける状態変数の図例

図 2.4 にいくつかの状態変数に対する図例を示す。

2.4.2 ダイナミックベイジアンネットワークの構成

前項で定義した交差点横断歩道周辺における歩行者状態空間内で、実際の歩行者の行動フローに従ったモデルを構築する。ここでは以下のような行動フローを仮定する。

はじめに、歩行者は状況进行评估する。ここで取り扱うシナリオにおいて、状況とは信号現示や横断歩道との位置関係、右左折車両の有無などに相当する。状況に応じて、歩行者は意思決定を行う。これは、横断/待機の意思決定や動作の変更に相当する。最後に、歩行者は意思や動作に応じて物理的に移動する。

このフローを踏まえて、図 2.5 に提案するダイナミックベイジアンネットワークのグラフ表現を示す。ただし、煩雑さを避けるため、 Sf_t, Se_t, V_t, G, Sd を Contexts: C_t としてまとめて表現している。また、離散/連続/可観測変数はそれぞれ矩形/楕円形/影付きノードで表現されている。また、一時刻内/二時刻間の依存関係は実線/点線エッジで描画されている。そして、このグラフ表現から、ネットワーク全体の状態遷移モデルを以下のように分解することが

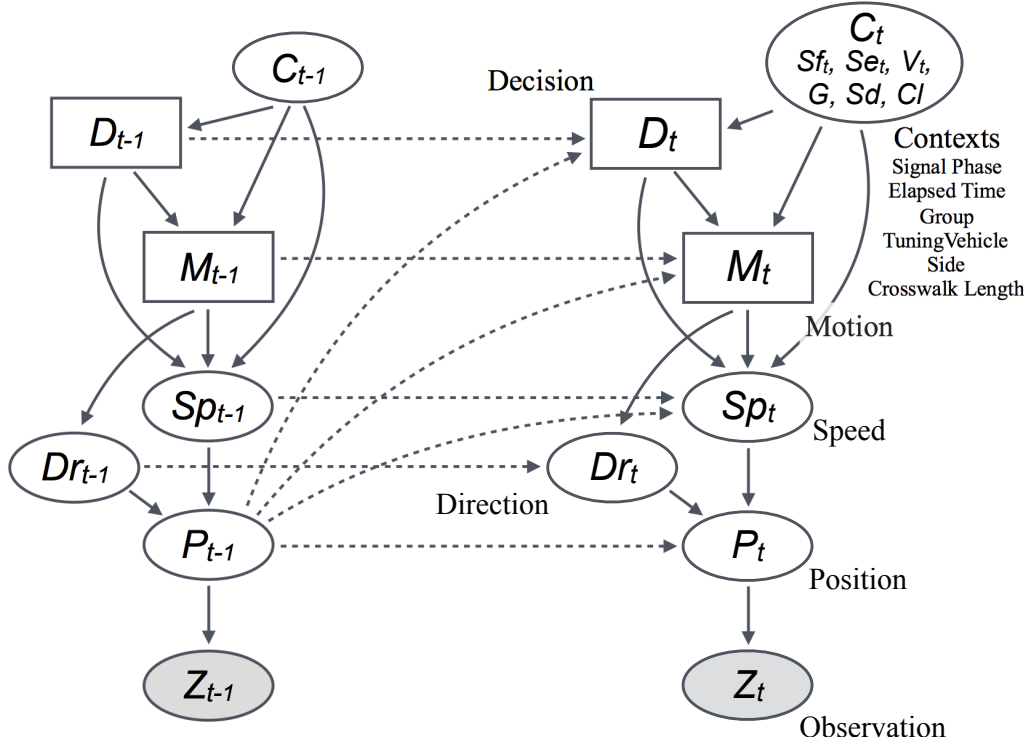


図 2.5. 歩行者横断行動モデルの二時刻間におけるグラフ表現

できる.

$$\begin{aligned}
 &P(D_t, M_t, Sp_t, Dr_t, P_t | D_{t-1}, M_{t-1}, Sp_{t-1}, Dr_{t-1}, P_{t-1}, Sf_t, Se_t, V_t, G, Sd, Cl) \\
 &= P(D_t | D_{t-1}, P_{t-1}, Sf_t, Se_t, V_t, G, Cl) \\
 &\quad \times P(M_t | M_{t-1}, D_t, P_{t-1}, Sf_t, Se_t, V_t, G, Sd, Cl) \tag{2.48}
 \end{aligned}$$

$$\times P(Sp_t, Dr_t, P_t | Sp_{t-1}, Dr_{t-1}, P_{t-1}, D_t, M_t, Sf_t, Se_t, V_t, G, Sd, Cl) \tag{2.49}$$

2.4.3 状態遷移モデル

状態遷移モデル (2.48) の各項は、それぞれの状態変数が一時刻前から確率的にどのように変化するのかを表す。これらのモデルを用いて、提案システムは巨大な状態空間の中から生起確率の低い状態を除去して、真の状態を推定する。サブモデルを以下のように定める。また、状態遷移モデルに加えてフィルタリングの過程で用いられる観測尤度モデルも定める。

横断意思決定モデル

横断歩道前 ($W_t = before$) の歩行者の横断か待機かの意思決定に対して、以下のルールを仮定する (横断歩道上 ($W_t = on$) の歩行者は *cross* 意思のみを持つ)。

1. PG 間、歩行者は *cross* 意思のみを持つ。
2. PFG 開始時、歩行者は *cross* か *wait* かの意思決定を行う。

3. PFG/PR 間において、歩行者は低確率で横断意思を変更する。

二つ目のルールに関して、井料ら [1] によって提案されたモデルを用いる。PFG 開始時に *wait* 意思を選択する確率をロジスティック関数によって決定される。これらのルールは以下のように定式化される。

$$\begin{aligned}
 & P(D_t = \text{wait} | D_{t-1} = d_{t-1}, P_{t-1} = \mathbf{p}_{t-1}, Sf_t = sf_t, Se_t = se_t, V_t = v_t, G = g, Cl = cl) \\
 &= \begin{cases} \text{(a)} & 0 & (sf_t = PG) \\ \text{(b)} & \frac{1}{1 + \exp(V_d(L^{in}(\mathbf{p}_{t-1}), \tilde{v}_t, \tilde{g}))^{-1}} & (sf_t = PFG_P R, se_t = 0) \\ \text{(c)} & \begin{cases} 1 - q_{w \rightarrow c} & (d_{t-1} = \text{wait}) \\ q_{c \rightarrow w} & (d_{t-1} = \text{cross}) \end{cases} & (sf_t = PFG_P R, se_t > 0) \end{cases} \quad (2.50) \\
 & P(D_t = \text{cross}) = 1 - P(D_t = \text{wait}) \quad (2.51)
 \end{aligned}$$

ここで、 V_d は影響する因子：説明変数の線形和である。本研究ではこの説明変数として、一時刻前の横断歩道までの距離、現時刻の待機車 V_t 、グループ G 、横断歩行長 Cl を考える。ただし、待機車およびグループに関しては、関数 V_d 内ではダミー変数 $\tilde{v} = \{no_vehicle : 0, vehicle_exist : 1\}$, $\tilde{g} = \{alone : 0, in_group : 1\}$ として計算される。

$$V_d(L^{in}(\mathbf{p}_{t-1}), \tilde{v}_t, \tilde{g}) = a_0 + a_1 L^{in}(\mathbf{p}_{t-1}) + a_2 \tilde{v} + a_3 \tilde{g}_t + a_4 cl \quad (2.52)$$

このロジスティック回帰と呼ばれる分析手法は、ドライバーや歩行者の gap acceptance model のような交通シーンでの意思決定モデルに広く用いられている [90, 67]。井料ら [1] も横断歩道までの距離や横断歩行長、PFG 開始時点の速度を説明変数とし、歩行者の横断行動をモデル化した。しかしながら、本稿では歩行者の移動速度は 2.4.3 で述べるように意思やその他のコンテキストによって決定されると想定しているため、速度はここでは説明変数として考慮されるべきではない。パラメータ a_0 a_3 は最尤推定によって決定される。

パラメータ $q_{w \rightarrow c}$, $q_{c \rightarrow w}$ は、PFG/PR 間のある時刻に、横断意思を *wait* から *cross* へ/*cross* から *wait* へと切り替える確率である。この確率は車両の無理な右左折や相互作用などによって動的に変化するものと考えられるが、これは今後の課題である。本稿ではこの三つ目のルールについては論じず、以降「意思決定」は二つ目のルールのみを指し示す。

モーション遷移モデル

歩行者はモーションをいかなる時刻にも変え得る。そのため、歩行者は毎時刻モーションを別のものへと切り替えるかの意思決定をしているものと仮定する。モーション切り替えの確率は横断-待機の意思決定と同様な形でロジスティック回帰によって定める。

$$\begin{aligned}
 & P(M_t \mid M_{t-1} = m_{t-1}, D_t = d_t, P_{t-1} = \mathbf{p}_{t-1}, \\
 & \quad Sf_t = sf_t, Se_t = se_t, V_t = v_t, G = g, Sd = sd, Cl = cl) \\
 &= \frac{1}{1 + \exp(V_m^{\{ \cdot \}}(\cdot))^{-1}} \\
 & \quad (\text{where } M_t \neq m_{t-1}) \quad (2.53)
 \end{aligned}$$

28 第2章 信号交差点における歩行者横断行動モデル

ここで $V_m^{\{\cdot\}}(\cdot)$ は以下の省略であり，説明変数の線形和を表す．

$$V_m^{\{\cdot\}}(\cdot) = V_m^{\{W(\mathbf{p}_{t-1}), sf_t, d_t, m_{t-1}, M_t\}}(se_t, L^d(\mathbf{p}_{t-1}), \tilde{v}_t, \tilde{g}, \tilde{sd}, cl) \quad (2.54)$$

ここでは説明変数として，現時刻の信号経過時間 se_t ，一時刻前の横断歩道入口/出口までの距離 $L^d(P_{t-1})$ ，現時刻の待機車 V_t ，グループ G ，横断方向 Sd ，横断歩行長 Cl を用いている．ただし，待機車，グループおよび横断方向に関しては，関数 V_m 内ではダミー変数 $\tilde{v} = \{no_vehicle : 0, vehicle_exist : 1\}$ ， $\tilde{g} = \{alone : 0, in_group : 1\}$ ， $\tilde{sd} = \{near_side : 0, far_side : 1\}$ として計算される．これと同時に， V_m はその他の依存する条件変数 $W(P_{t-1}), Sf_t, D_t, M_{t-1}$ の組み合わせによって異なる係数および定数を持つ．例えば，横断歩道までの距離 $L(P_{t-1})$ に対する係数を b_1 とすると，異なる信号現示下においてそれは $b_1^{before, PFG, cross, running, walking}$ と $b_1^{before, PG, cross, running, walking}$ のように異なる値をとる．つまり，条件変数の組み合わせごとに異なる線形関数 V_m を用意することを意味する．これは，歩行者のとりモーションの分布がコンテキスト：信号現示や横断歩道との位置関係や意思に応じて全く異なると考えているからである．これらのパラメータは最尤推定を用いて定められる．

式 (2.54) は歩行者がモーションを別のものへと切り替える確率のみを定義する．そのため，一時刻前と同じモーションにとどまる確率は，残りの確率となる．例えばある時刻に歩行状態にあったとすると，次の時刻でも歩行状態にある確率は以下のように定められる．ただし，その他の条件変数は簡単のため省略している．

$$\begin{aligned} P(M_t = walking | M_{t-1} = walking) \\ = 1 - P(M_t = standing | M_{t-1} = walking) \end{aligned} \quad (2.55)$$

$$- P(M_t = running | M_{t-1} = walking) \quad (2.56)$$

ダイナミクスモデル

運動モデルは以下のように三つのモデルへと分解する．

$$\begin{aligned} P(Sp_t, Dr_t, P_t | Sp_{t-1}, Dr_{t-1}, P_{t-1}, D_t, M_t, Sf_t, Se_t, V_t, G, Sd, Cl) \\ = P(Sp_t | Sp_{t-1}, D_t, M_t, P_{t-1}, Sf_t, Se_t, V_t, G, Sd, Cl) \\ \times P(Dr_t | Dr_{t-1}, M_t) P(P_t | P_{t-1}, Sp_t, Dr_t) \end{aligned} \quad (2.57)$$

歩行者の移動速度は二つの側面から決定されると仮定し，式 (2.57) の右辺初項はさらに二つのモデルへと分解を行う．

$$\begin{aligned} P(Sp_t | Sp_{t-1}, D_t, M_t, P_{t-1}, Sf_t, Se_t, V_t, G, Sd, Cl) \\ \propto P(Sp_t | Sp_{t-1}, M_t) P(Sp_t | D_t, M_t, P_{t-1}, Sf_t, Se_t, V_t, G, Sd, Cl) \end{aligned} \quad (2.58)$$

まず，移動速度は一定であると仮定する．ただし，駆動雑音として各時刻小さな変化が許容される．この駆動雑音の分布はゼロ平均ガウシアンに従うとする．これを Constant-Speed model と呼ぶ．これは式 (2.58) の初項に相当する．

$$\begin{aligned} Sp_t | M_t = m_t = \begin{cases} Sp_{t-1} + \nu_t & (m_t = walking, running) \\ 0 & (m_t = standing) \end{cases} \quad (2.59) \\ \nu_t \sim N(0, \sigma_{s, m_t}^2) \end{aligned}$$

この Constant-Speed model に加えて、状況や歩行者意思/モーションに応じて取り得る速度分布を考える。これは式 (2.58) の第二項に相当し、これを Context-Speed model と呼ぶ。 $M_t = walking, running$ の時の速度分布に対して、井料ら [1] の提案する動的なパラメータを持つガンマ分布を用いる。

$$\begin{aligned} P(Sp_t \mid D_t = d_t, M_t = m_t, P_{t-1} = \mathbf{p}_{t-1}, \\ Sf_t = sf_t, Se_t = se_t, V_t = v_t, G = g, Sd = sd, Cl = cl) \\ \sim \text{Gamma}(Sp_t; k_s^{\{\cdot\}}(\cdot), \theta_s^{\{\cdot\}}(\cdot), \gamma_s^{\{\cdot\}}(\cdot)) \end{aligned} \quad (2.60)$$

ただし、ガンマ分布の確率密度関数はガンマ関数 Γ を用いて以下のように定義される。

$$f(x; k, \theta) = \frac{(x - \gamma)^{k-1} \exp(-(x - \gamma)/\theta)}{\theta^k \Gamma(k)} \quad (2.61)$$

ガンマ分布は歪度や尖度のような性質が形状母数 k および尺度母数 θ 、加えてシフト量 γ によって特徴づけられる。また、 $k_s^{\{\cdot\}}(\cdot), \theta_s^{\{\cdot\}}(\cdot), \gamma_s^{\{\cdot\}}(\cdot)$ は以下の省略である。

$$k_s^{\{\cdot\}}(\cdot) = k_s^{\{W(\mathbf{p}_{t-1}), sf_t, d_t, m_t\}}(se_t, L^d(\mathbf{p}_{t-1}), v_t, g, sd, cl) \quad (2.62)$$

$$\theta_s^{\{\cdot\}}(\cdot) = \theta_s^{\{W(\mathbf{p}_{t-1}), sf_t, d_t, m_t\}}(se_t, L^d(\mathbf{p}_{t-1}), v_t, g, sd, cl) \quad (2.63)$$

$$\gamma_s^{\{\cdot\}}(\cdot) = \gamma_s^{\{W(\mathbf{p}_{t-1}), sf_t, d_t, m_t\}}(se_t, L^d(\mathbf{p}_{t-1}), v_t, g, sd, cl) \quad (2.64)$$

これはモーション遷移モデルで用いた説明変数の線形関数と同様な形で、ここでも現時刻の信号経過時間 Se_t 、一時刻前の横断歩道入口/出口までの距離 $L^d(P_{t-1})$ 、現時刻の待機車 V_t 、グループ G 、横断方向 Sd 、横断歩行長 Cl を説明変数とし、その他の条件変数 $W(P_{t-1}), Sf_t, D_t, M_t$ の組み合わせによって異なる係数および定数が用いられることを意味する。これらのパラメータは最尤推定によって定められる。また $M_t = standing$ の時、移動速度はゼロに固定される。

式 (2.58) のように、提案する速度モデルは正規分布とガンマ分布の積に比例する。条件変数を C_t としてまとめ ($C_t = \{Sp_{t-1}, D_t, M_t, P_{t-1}, Sf_t = sf_t, Se_t = se_t, V_t = v_t, G = g, Sd = sd, Cl = cl\}$)、Context-Speed model のガンマ分布の確率密度関数を $G_{cx}(Sp|C_t)$ 、Constant-Speed model の正規分布の確率密度関数を $N_{cs}(Sp|C_t)$ として表すと、以下のよう

$$P(Sp_t|C_t) = \frac{N_{cs}(Sp_t|C_t)G_{cx}(Sp_t|C_t)}{\int N_{cs}(Sp|C_t)G_{cx}(Sp|C_t)dSp} \quad (2.65)$$

また、歩行者の移動方向 Dr_t は一定であるとする。ただし、Constant-Speed model 同様、ゼロ平均ガウシアン of 駆動雑音によって各時刻小さな変化が許容されるとし、これを Constant-Speed model と呼ぶ。

$$Dr_t|_{M_t=m_t} = Dr_{t-1} + \epsilon_t, \quad \epsilon_t \sim N(0, \sigma_{d,m_t}^2) \quad (2.66)$$

歩行者位置 P_t は、移動速度および方向によって一時刻前の位置をシフトさせることで一意に定まる。

$$P_t = P_{t-1} + Sp_t \begin{bmatrix} \cos(Dr_t) \\ \sin(Dr_t) \end{bmatrix} \quad (2.67)$$

位置観測モデル

歩行者位置はゼロ平均ガウシアンノイズを含んで計測されるものと仮定する.

$$Z_t = P_t + \mathbf{w}_t, \quad \mathbf{w}_t \sim N(\mathbf{0}, \sigma_m^2 \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}) \quad (2.68)$$

ただし, 実用のシステムにおいてはセンサの誤差傾向に応じたモデルを用いる必要がある.

グループ尤度モデル

Zeng ら [72, 73] によってモデル化が行われているように, 歩行者は公共空間において同行者とはおおそ一定の距離を保とうとし, そうでない他歩行者とは一定の距離以上近づくことを避けていると考える. そこで, 他歩行者との最短距離 Dp_t をグループ G の尤度としてみる事ができる. Dp_t はグループ G に応じて異なるパラメータを持つガンマ分布に従うとし, これを尤度関数とする.

$$P(Dp_t|G = g) \sim \text{Gamma}(Dp_t; k^{\{g\}}, \theta^{\{g\}}, \gamma^{\{g\}}) \quad (2.69)$$

2.4.4 状態推定手法

歩行者を観測し, 横断意思やモーションを含めた状態をオンライン推定もしくは予測するために, 上で定めたダイナミックベイジアンネットワークに対して, ベイジアンフィルタリングの原理を適用する. ただし, 提案モデルでは状態遷移モデルにおいて離散状態と連続状態が混在し, 非ガウシアンノイズの条件付確率分布を含むため, 式 (2.16) における積分部分は計算不可能であり, 事後分布をガウス分布あるいは混合ガウス分布と仮定, 近似することは難しいと考えられる. 2.3.4 項にてベイジアンネットワークに対する状態推定手法をいくつか述べたが, ここではサンプリングに基づき事後分布を推定する粒子フィルタを用いる.

提案モデルでは各粒子がダイナミックベイジアンネットワークの各ノードに対応する値および重みを持っている. そしてそれぞれの粒子はフィルタリングの過程で, 2.4.3 項で提案した状態遷移モデルによって, 状態空間内を移動する.

粒子の初期化

2.4.3 項で提案した状態遷移モデルは一時刻前の状態から新たな時刻の状態を予測するものであるが, フィルタリングの開始時にはそれとは独立して各粒子に初期値を与える必要がある. この粒子の初期化処理はその後の時刻の仮定と同様, 初期時刻に与えられる観測位置 Z_0 および信号情報 S_0 を用いて行う.

まず, 初期横断意思 D_0 は 2.4.3 項でのルールと同様に, $Sf_0 = PG$ もしくは $W(Z_0) = on$ の場合は $D_0 = cross$ を与える. $Sf_0 = PFG_PR$ の場合は, ロジスティック関数によって $P(D_0 = wait)$ を定める. ただし, 2.4.3 項で用いたロジスティック関数に対し, 信号経過時間 Se_0 を説明変数に加え, また現時刻の位置を初期時刻の観測位置で置き換える.

初期モーション M_0 は, $M_0 = standing, running$ である確率をロジスティック関数によって定め, $M_0 = walking$ を残りの確率とする. ただし, 説明変数における現時刻の位置を初期時刻の観測位置で置き換える.

初期移動速度 Sp_0 は, Constant-speed model によって与える. ただし, 説明変数における現時刻の位置を初期時刻の観測位置で置き換える.

初期移動方向 Dr_0 は, $W(Z_0) = before$ の場合は横断歩道入口を, $W(Z_0) = on$ の場合は横断歩道出口を向く方向を平均とする正規分布からサンプリングする.

フィルタリング

初期化处理によって一度各粒子に状態値を与えた後は, 2.3.4 項で述べたサンプリングステップ, 重点サンプリングステップ, 再サンプリングステップによって, 逐次的に状態推定が行われる. 各時刻初めに各粒子において, 現在の信号現示 Sf_t と一時刻前の横断意思 D_{t-1} と位置 P_{t-1} および 2.4.3 項で横断-待機意思決定モデルとして定めた条件付確率に基づいて, 新しい横断意思 D_t がサンプリングされる. 同様な形で, 新たなモーション M_t が 2.4.3 項の動作遷移モデルに従って決定される. その後に移動速度 Sp_t , 移動方向 Dr_t , 位置 P_t が 2.4.3 項の運動モデルによって与えられるが, 旅行速度 Sp_t に対する複雑なモデル (2.65) からは容易にサンプル値を得ることができない. そこで提案分布として Context-Speed model のガンマ分布 $G_{cx}(Sp|C_t)$ を同じ平均値および分散値を持つ正規分布で近似する. この確率密度関数を $N_{cx}(Sp|C_t)$ とする. 元のガンマ分布のパラメータ k, θ を用いて, この正規分布の平均値, 分散値はそれぞれ $k\theta, k\theta^2$ となる. この近似された正規分布および Constant-Speed model, 二つの正規分布の積は以下のように再び正規分布であるので (2.70), 容易にサンプル値を得ることができる.

$$\begin{aligned} u &\sim N(\mu_u, \sigma_u), \quad v \sim N(\mu_v, \sigma_v) \\ uv &\sim N\left(\frac{\mu_u\sigma_v^2 + \mu_v\sigma_u^2}{\sigma_u^2 + \sigma_v^2}, \sqrt{\frac{\sigma_u^2\sigma_v^2}{\sigma_u^2 + \sigma_v^2}}\right) \end{aligned} \quad (2.70)$$

重点サンプリングステップでは, 2.4.3 項で述べた観測モデルおよびグループ尤度モデルと, 上で述べた提案分布と状態遷移モデルの違いを考慮して, 粒子の重みを更新する. 提案モデルでは状態遷移モデルと提案分布との違いが旅行速度分布のモデル内のみであり, 式 (2.34) は以下のように書ける.

$$w_t^{*(i)} = w_{t-1}^{(i)} P(Z_t|P_t^{(i)}) P(Dp_t^{(i)}|G^{(i)}) \frac{\frac{N_{cs}(Sp_t^{(i)}|C_t^{(i)}) G_{cx}(Sp_t^{(i)}|C_t^{(i)})}{\int N_{cs}(Sp|C_t^{(i)}) G_{cx}(Sp|C_t^{(i)}) dSp}}{\frac{N_{cs}(Sp_t^{(i)}|C_t^{(i)}) N_{cx}(Sp_t^{(i)}|C_t^{(i)})}{\int N_{cs}(Sp|C_t^{(i)}) N_{cx}(Sp|C_t^{(i)}) dSp}} \quad (2.71)$$

ここで, G_{cx} の歪度が小さく, N_{cs} の分散が大きいと仮定する. この時, 分母の積分値は分子の積分値に近づき, 等式は以下のように書くことができる.

$$w_t^{*(i)} \approx w_{t-1}^{(i)} P(Z_t|P_t^{(i)}) P(Dp_t^{(i)}|G^{(i)}) \frac{G_{cx}(Sp_t^{(i)}|C_t^{(i)})}{N_{cx}(Sp_t^{(i)}|C_t^{(i)})} \quad (2.72)$$

またここでは複数の歩行者の推定を同時に行うことを考えているため、各歩行者の一時刻前の位置、速度、方向から新たな時刻における位置の単純な予測を行い、これを用いて最短距離にいる歩行者を決定し、 Dp_t とする。

この粒子の重みの更新後、2.3.4 項で述べたように、多くの粒子の重みが 0 に近く、推定において意味をなさない状態になっている場合、再サンプルステップを実行する。

粒子フィルタのリセット

現実問題に粒子フィルタを適用する場合、粒子が真値の周辺に存在しない状態に陥り、推定精度が著しく悪化することが起こり得る。これは、有限個の粒子で確率分布を近似していることや非常に稀な事象のモデル化にも限界があることが原因である。本手法でも歩行者の一般的な行動をモデル化しているため、例えば周囲の歩行者を避けるために急に軌道を変更したり、高齢者が一般人に比べ非常に低速な歩行をする場合には推定精度の悪化は避けられない。ただし、このような状況においては、観測値と粒子の分布も大きく矛盾することとなるので、これを検出し、粒子の分布の修正 (リセット) を行うことであれば、良好なトラッキング状態に復帰することが望める。ここでは、履歴センサリセット (hysteresis sensor resettings: HSR)[91] を採用する。この手法では、正規化前の粒子の重みの総和 $\zeta_t = \sum_i w_t^{*(i)}$ から、粒子の分布の真値からの乖離を推定する。以下式の τ_t が 0 を上回った時にリセットを行う。

$$\begin{aligned}\zeta_t^{long} &= \eta^{long} \zeta_t + (1 - \eta^{long}) \zeta_{t-1}^{long} \\ \zeta_t^{short} &= \eta^{short} \zeta_t + (1 - \eta^{short}) \zeta_{t-1}^{short} \\ \tau_t &= 1 - \frac{\zeta_t^{short}}{\zeta_t^{long} \zeta^{threshold}}\end{aligned}\tag{2.73}$$

ただし、 $\eta^{long}, \eta^{short}$ は、 $0 \leq \eta^{long} \ll \eta^{short} \leq 1$ を満たす定数である。上式より、 ζ_t が小さい状態が数時刻続いた場合、 $\zeta_t^{short} / \zeta_t^{long}$ が $\zeta^{threshold}$ を下回り、リセットが行われることとなる。リセットは、各粒子を $\tau_t / (1 + \tau_t)$ の確率で、 Z_t を用いて初期化と同様な手順でサンプリングして得る新しい粒子で置き換える。

2.5 評価実験

前節では信号付交差点における歩行者横断行動モデルの提案を行った。本節では、実交通シーンのデータを用いて行った当モデルに対する評価実験について記す。

2.5.1 データ収集

本項では評価実験に用いた交通データセットの収集方法とその概要について述べる。提案モデルは ADAS や自動運転のような車載システムを目指したものであるが、本実験では固定カメラを用いてデータ収集を行った。その理由は、どのようなシステムであっても異なるのは観測モデルであり、その上にある歩行者行動の確率モデルは変わらず、この確率モデルの学習に際しては学習データの質が良い方が好ましいからである。また、車載システムから学習と評価に十分な量のデータを取得することには時間も要する。ただし、後述の通り、車載システムのような強い誤差環境下もシミュレーションして評価を行っている。提案モデルは車載システムのみに適用可能なものではないため、将来的な ITS 社会においては、インフラストラクチャー側で歩行者の観測および状態推定を行い、V2I 通信によって車両に提供することも考えられる。

今回、図 2.6 に示す東京都新宿区の交差点に位置する二つの横断歩道を対象として、歩行者および車両の交通データの収集を行った。本稿では、それぞれの横断歩道を横断歩道西 (長さ 23m/幅 4m)、横断歩道南 (長さ 10m/幅 5m) とする。この交差点に隣接するビル内、地上 50m 前後の高さにカメラ (10fps, 842 × 480pixel) を複数台設置し、撮影を行った。撮影は 2 回 (6 月/10 月)、両日とも 11 14 時にかけて行った。^{*2}

対象の横断歩道の歩行者信号が青 (PG) となってから、直行する横断歩道の歩行者信号が青になるまでをその横断歩道の 1 サイクルとみなし、ランダムにサイクルを抽出し、各サイクル内でのラベル付けを行った。図 2.7 にカメラ画像の例を示す。カメラの画像上で歩行者の重心から地面へ下ろした垂線と地面の交点および動作 (*{standing, walking, running}*), 横断方向 (*{near_side, far_side}*) をラベリングする。また、横断前から横断後まで他歩行者との距離や顔を向き合わせる等の相互行動を観察し続けることによって、単独/集団 (*{alone, in_group}*) での移動かを推定する。各時刻における真の横断意思は知ることができないので、2.4.3 の仮定に基づき、対象の信号サイクルの間に実際に横断しなかった歩行者の PFG 開始後のみに *wait* とし、それ以外は *cross* とラベルをつける。横断歩道や車線境界の白線等を基準として、カメラ画像と図 2.6 の航空写真との射影変換を求める。ただし、航空写真の 1 ピクセルが対応する実寸距離は既知であり、対象区域において地面は平坦であると仮定する。これを用いて、カメラ画像座標系における歩行者位置をグローバルな座標系に変換することができる。それぞれの歩行者軌跡に対し、カルマン平滑化を行い、これを真の軌跡とみなす。また、対象の横断歩道を横切る右左折車両においても、車両前方先端から地面に下ろした垂線と地面の交点をラ

^{*2} Google マップ (<http://maps.google.co.jp/>) より引用



図 2.6. 実験対象交差点 *1

ベリングし、歩行者と同様な形に射影変換によって位置座標を得る。ラベル付けを行ったサイクル、歩行者数、右左折車両数を表 2.1 に示す。歩行者の各横断方向、同行者の有無、横断行動に対し、十分なデータ数を得ていることがわかる。

それぞれ横断歩道における信号現示の周期は一定であり、表 2.2 に示す。

このようにして得られたデータセットに対し、4 分割交差検証を適用して提案モデルの評価を行った。K 分割交差検証 (K-fold cross-validation) は、データセットを K 個に分割し、 $K - 1$ 個によるモデル学習、残りの 1 つによる評価を K 回繰り返して、それらの結果の平均



図 2.7. カメラ画像と位置ラベル例

表 2.1. データセットの概要

		横断歩道西	横断歩道南	計
信号サイクル	計	74	34	108
歩行者	計	713	208	921
	横断方向 (Sd)			
	near-side	374	104	478
	far-side	339	104	443
	グループ (G)			
	alone	533	148	681
右左折車	group	180	60	240
	横断意思 (D)			
	cross	614	184	778
	wait	99	24	123
右左折車	計	168	46	214
	左折車	117	31	148
	右折車	51	15	66

表 2.2. 実験交差点における信号現示周期

横断歩道西	PG	PFG	PR			
横断歩道南	PR			PG	PFG	PR
現示時間 (秒)	34	10	12	24	8	12

を得るものである。

2.5.2 パラメータ学習

前節で述べた通り、提案するダイナミックベイジアンネットワークは、ノードの表す変数群をエッジの表す条件付確率によって結びつけて構成されているものである。これらの条件付確率にはパラメータによって定められるものであり、パラメータ群はデータセットより学習する必要がある。本節では学習結果の概要について述べる。ただし、本節で示す結果例は全データを用いて学習した結果であり、前述の通り評価実験の際は交差検証を行っている。

横断-待機意思決定モデル

2.4.3 節の述べたように、PFG 開始時に行われる横断意思決定はロジスティック関数によって確率モデル化した。このロジスティック関数内の線形式 (2.50) の係数/定数は最尤推定によって求める。学習結果の視覚化例を図 2.8 に示す。横軸は PFG 開始時における横断歩道までの距離、縦軸は横断 (*cross*) を選択する確率である。凡例は Group, WaitingVehicle および横断歩道長 (横断歩道西: 23m, 横断歩道南: 10m) を表している。まず、PFG 開始時に横断歩道に近いほど横断を選択する確率が高くなると考えられ、その傾向が学習されている。次に、黒と青の曲線の比較により、同行者がいることにより待機を選択する確率が高くなっていることがわかる。これは、同行者とは意思および行動を揃える必要があり、より急ぐ必要のない行動を選ぶものと考えられる。次に、右左折待機車の存在が横断確率を下げている (黒/緑の曲線)。PFG 時の横断開始は本来許されていないため、それを侵して右左折車を待たせることを避けたり、急いで渡ることによって右左折車と衝突が高まることを考慮していると考えられる。また、横断歩道長が短いほど横断確率が高まるが (黒/赤の曲線)、これは車両とコンフリクトする領域である横断歩道を短い時間で抜けられるためであろう。

モーション遷移モデル

PFG 開始時に行われる横断意思決定同様、各時刻にモーションが遷移する確率もロジスティック関数によってモデル化しており、線形式 (2.54) の係数/定数を最尤推定で求める。ただし、有意水準 10% の t 検定を行い、有意でないと判断された説明変数は排除した。これら係数/定数は遷移前/後の動作やその他コンテキストの条件変数の組み合わせごとに定められるが、その組み合わせは 48 通りとなる。しかしながら、その組み合わせの多くは起こる可能性が非常に低く、十分なデータが得られない。例えば、横断歩道上で立ち止まることは稀であり、また待機意思を持った歩行者が横断歩道上に出ることはない。このような条件変数の組み合わせに対しては、説明変数によって変化しない非常に小さな確率を与える。

観測下で頻繁に起こったモーション遷移に対する学習結果の視覚化例を図 2.9(a)(横断歩道前: $W = before$), 2.9(b)(横断歩道上: $W = on$) に示す。凡例は遷移前モーション、遷移後モーション、信号現示、横断意思、信号経過時間、右左折待機車の有無を表す。ただし、すべてにおいて $G = alone$, $Sd = near_side$, $Cl = 23m$ である。縦軸はある時刻にモーションが遷移する確率であり、横軸は図 2.9(a) においては横断歩道までの距離、図 2.9(b) においては





図 2.8. PFG 開始時における横断意思確率

横断歩道出口までの距離を示す。まず、横断歩道前でのモーション遷移を表す図 2.9(a) より、PFG 時に横断意思を持った歩行者は、右左折待機車がいることによって走り出す確率が高まることわかる (黄色/赤の曲線)。また、待機意思を持った歩行者は横断歩道数メートル手前で止まる傾向が学習されている (青の曲線)。次に、横断歩道上を表す図 2.9(b) には、横断し終えるまでの残り距離が長いほど、また信号時間および右左折待機車の存在に応じて、走り出す確率が高まる傾向があることが読み取れる。走り出すという動作は、急な加速と高い移動速度を表すと同時に、歩行者の焦り等も反映しているため、安全の観点から重要となるものである。


ダイナミクスモデル

2.4.3 節では、歩行者の運動モデルにおいて、移動速度 S_p が横断意思 D や信号現示 S_f などさまざまな影響を受けて決定することを Context-Speed model として提案した。速度分布として用いる Gamma 分布のパラメータは説明変数の線形和であるとし (式 (2.63)), かつ条件変数の組み合わせによって定められるこれらの係数/定数を最尤推定で求める。特定の意思やコンテキストの条件下での、この速度分布の学習結果の視覚化例を図 2.10(横断歩道前: $W = before$), 2.11(横断歩道上: $W = on$) に示す。すべて歩行速度 ($M = walking$) を表し、凡例は信号現示, 横断意思, 信号経過時間, 横断歩道入口/出口までの距離を表す (図 2.11(a) ではさらにグループ G が続く)。ただし、すべてにおいて $G = alone$ (図 2.11(a) を除く), $S_d = near_side$, $Cl = 23m$ である。この学習結果が実際の歩行者の速度傾向を反映しているものと仮定して、以下に考察を加える。

まず、図 2.10(a) の青と緑、赤と水色の曲線の比較より、横断歩道に向かっている歩行者は



(a) 横断歩道前



(b) 横断歩道上

図 2.9. 特定条件下におけるモーション遷移確率

横断歩道に近づくと速度を落とすことがわかる。これは PG 間、もしくは PFG 開始直後に横断歩道に到達し、安全に横断可能と判断するためと考えられる。また、青と赤、緑と水色の曲線の比較より、PG 開始時から時間の経過にしたがって、速度が上がるのがわかる。歩行者がおおよその PG の長さを予測し、横断のために急ぐのであろう。図 2.10(b) の青と緑の曲線より、PFG 時にも同様に、経過時間によって横断歩行者の速度が上がるのが読み取れる。同時に PG よりも速度は上がっている。また、図 2.10(b) の赤と水色の曲線は、待機を決めた歩行者が横断歩道に近づくとつれ、停止するために減速することを示している。図 2.11(a) における、青と緑、赤と水色の曲線の比較は、同行者がいる ($G = in_group$) によって、いない場合 ($G = alone$) より速度が落ちることを示している。これは同行者と歩調を合わせるためと考えられる。また、図 2.11(b) から、横断歩道前と同様に横断歩道上においても、PFG の経過時間によって速度を上げ、横断歩道出口に近づくと速度が落とすことがうかがえる。

このような学習結果から歩行者の移動速度は意思や信号といったコンテキストに強く影響を受けていることがうかがえ、こうした関係性を考慮することで、状態推定に大きく寄与するものと考えられる。


2.5.3 性能評価

前節では実交通データを用いた提案モデルの学習について述べた。本節では、その学習モデルを用いて歩行者の状態推定を行った結果について述べる。


対象横断歩道に向かって移動してくる歩行者の状態推定では、提案するダイナミックベイジアンネットワークと粒子フィルタのシステムに各時刻における歩行者観測位置 Z_t とともに信号現示 Sf_t 、信号時間 Se_t および右折待機車の有無 V_t を入力として与える。信号情報は V2I 通信等によって与えられると仮定している。 V_t は車載システムを想定すれば自車両が待機車となり得る。また、横断歩道長 Cl も V2I 通信やナビゲーションサービスの一部として提供されうるので既知とする。歩行者観測位置 Z は、歩行者の真の位置 \bar{P} に対してガウスノイズ \hat{w} を与えることでシミュレーションした。

$$Z_t = \bar{P}_t + \hat{w}_t, \quad \hat{w}_t \sim N(\mathbf{0}, \sigma_n^2 \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}) \quad (2.74)$$

ここで、唯一の観測値である Z の誤差の、提案モデルの性能への影響を量るために、3つのノイズレベルを用いた ($\sigma_n = 0.1, 0.4, 1.0\text{m}$)。これにより、観測誤差のほとんどない理想的な条件下での提案モデルの最大限の性能から、実アプリケーションとして大きな誤差が避けられない条件下での性能までを考察する。ただし、データセットにおいて一時刻あたり (0.1 秒) の歩行者の平均移動量が 0.14mであることを考慮すると、シミュレーションされた観測誤差はかなり大きい。 σ_n は既知であるとして、式 (2.68) の σ_m には同じ値を与える。これらの入力に対して、提案システムは各時刻に歩行者の横断意思 D_t やモーション M_t 、その他ダイナミックベイジアンネットワークのすべてのノードに対する推定を返す。推定は、歩行者と横断歩道までの距離が 20m になった時点から開始し、横断した場合は横断し終えた時点で終了する。



(a) PG 時の信号経過時間/横断歩道までの距離の影響




(b) PFG 時の横断意思/信号経過時間/横断歩道までの距離の影響


図 2.10. 横断歩道前特定条件下における歩行速度分布

フィルタリング事例

本項では、提案するダイナミックベイジアンネットワークおよび粒子フィルタによる状態推定がいかなる働きをするかを二つの歩行者事例を用いて示す。



(a) PG/PFG 時のグループの影響



(b) PFG 時の信号経過時間/横断歩道出口までの距離の影響

図 2.11. 横断歩道上特定条件下における歩行速度分布

図 2.12～2.14 は、PFG 開始時に near-side から横断歩道に接近していた歩行者が横断を決定し、横断歩道前半で走り始め、横断歩道後半に差し掛かり走るのをやめたケースである。(a), (b), (c) はそれぞれ、提案システムによって推定された軌道 (マゼンダ)、観測位置 (黄色) および真の軌道 (黒) を表す図、提案システムによって推定された横断意思/モーション確率の

42 第2章 信号交差点における歩行者横断行動モデル

グラフ、提案システムによる推定位置の誤差と観測位置の誤差のグラフを表す。PFG 開始の瞬間は、(a), (b) では黄色の点線、(c) ではそれぞれの軌道上の黄色の円で表されており、その時点で歩行者は横断歩道の手前およそ 7,8m の位置にいるが、観測位置誤差の大小に関わらず、迷うことなく *cross* 意思を認識していることがそれぞれの (a) から読み取れる。また、(a), (b) ではマゼンダの点線、(c) ではマゼンダの円は歩行者の走り出した瞬間を示しているが、どの誤差ケースにおいてもその前後で *running* に対する推定確率が上がっている。シアンの点線/円は歩行者が走るのをやめた瞬間を表しており、これもどのケースにおいてもその前後で *walking* 推定確率が上がる。ただし、このモーションの変化に対する反応は、観測位置誤差の増大によって遅れが生じている。これは誤差によってモーション推定の手がかりとなる速度の検出することが難しくなるためといえよう。

これとは対照的に、図 2.15~2.17 は、PFG 開始時に near-side から横断歩道に接近していた歩行者が次の PG までの待機を選択し、横断歩道手前で停止するケースである。図およびグラフは、前例と同じものを表す。このケースでも、前ケースと同じく PFG 開始時に歩行者は横断歩道手前およそ 7,8m の位置にいるが、システムはほとんど迷うことなく *wait* の意思を認識している。また、歩行者が停止した瞬間は (a), (b) では青の点線、(c) ではそれぞれの軌道上の青の円で表されており、どの誤差ケースにおいてもわずかに先立つ形で素早く検出している。これは、横断歩道手前およそ 2,3m の位置で停止することを確率モデルという形で理解しているからである。

横断意思推定

本項では、全歩行者データに対する横断意思の推定結果を示す。表 2.3 は、観測内全時刻における推定結果の正規化混同行列を表す。ただし、PFG 開始後 ($S_t = PFG_PR$) かつ歩行者前 ($W_t = before$) のみを含む。これは、本稿では 2.4.3 項での述べたように、PG 間もしくは横断歩道上においては歩行者は *cross* 意思のみを持っていると仮定しており、データに対する正解ラベルも提案モデルによる推定も *cross* のみであるため、評価に適さないためである。表 2.3 を見ると、*wait* はどの位置観測の誤差レベルにおいても非常に高くなっている。ただし、これは横断歩道前での停止後や PR 時のような待機意思が明らかである時刻のものも含んでいるため、必ずしも適切な評価基準ではない。これに対し、*cross* は誤差の増大に伴い、精度が悪化している。これは認識の上で重要となる速度が大きな誤差によって正しく評価できなくなり、より信号の経過時間といったコンテキストに重きを置く結果、起こる可能性の低い駆け込み等を認識できなくなるためと考えられる。

表 2.4 は、データを収集した 2 つの横断歩道それぞれにおける推定結果である。ただし、表 2.3 と同様、PFG 開始後かつ横断歩道前のみの推定結果を含む。表から、観測ノイズが大きいケースにおいて、横断歩道西での *cross* 認識精度が横断歩道南に比べて悪化していることがわかる。それぞれの横断歩道の長さは 23m と 10m と大きく差があり、歩行者の横断挙動も異なると推察される。これに対して、横断歩道長を確率モデルの変数として組み込むことによって、その他のパラメータを変えることなく、二つの横断歩道を取り扱った。これは井料ら [1] による 3 ヶ所の交差点の計 7 ヶ所の横断歩道における調査に基づいており、ここでは横断意思

決定においては横断歩道依存の変数としては横断歩道長のみが有意に影響していると示している。今回 2 つの横断歩道のみのデータを用いたことが学習に悪影響を及ぼしたことが考えられ、今後より多くの横断歩道において検証を行うことが必要である。同時に、ロジスティック関数やガンマ関数を用いた回帰が適切であるかも再検討が必要である。

また、井料ら [1] による、PFG 開始時の歩行者の速度、横断歩道までの距離および横断歩道長を説明変数とするロジスティック回帰で横断意思を予測するモデルの推定結果を表 2.5 に示す。この表における推定は PFG 開始時にのみ行うものであり、PFG 開始後の全時刻を含む表 2.3 との一概な比較はできないものの、表 2.3 の誤差レベル $\sigma_n = 0.1\text{m}$ が両クラスとも高い正解率となっている。このモデルは PFG が開始したのを見てから急ぎ始めるような横断歩行者を説明できないため、提案モデルのように PFG 開始後にも観測および推定を続けることが必要であることを示唆している。

これら 2 つの表で表される認識結果は、PR 間や横断歩道から十数メートル離れた地点のような、様々な時刻や歩行者位置における結果をすべて含んでおり、必ずしも評価指標として適切とは言えない。そこでこのシステムの実用的な性能を評価するための図を 2 種類示す。図 2.18 は、歩行者が横断に対する意思決定を行う PFG 開始時点基準とした時間を横軸としてとった、横断意思の認識精度のグラフである。*wait* に対しては時間の経過とともに認識率が向上しており、歩行者の行動に減速といった行動が徐々に現れてくると考えられる。逆に *cross* に対する認識精度は PFG 開始時から横ばいである。これは、PFG 開始数秒経過後になお歩道にいる歩行者は横断する可能性が低いとシステムが理解し、*wait* に認識が寄るためと考えられる。図 2.19 は、歩行者の横断歩道までの距離を横軸とした、横断意思の認識精度のグラフである。*wait* に対してはほぼ全範囲で高い精度を保っているのに対し、*cross* に対しては歩行者が横断歩道に近づくにつれて認識率が向上している。これは歩行者が横断歩道に近づくにつれて、横断意思によってその行動が分離してくることを示してしていると同時に、PFG 時に横断歩道から遠くにいる歩行者ほど横断してくる確率は低いと考えられるため、提案モデルの予測は *wait* に寄る傾向があるもとと考えられる。 $\sigma_n = 0.1, 0.4, 1.0\text{m}$ において、それぞれ横断歩道の 10, 6, 3m 前から両クラスに対する認識精度はおおよそ 80% 以上を保っている。これは、歩行者が横断歩道に侵入し得るおよそ 2~7 秒から、実際に侵入するか否かを予測できることを示し、車両側のモーションプランニングや誤警報の削減の助けとなる。

ここで注意すべき点は、この歩行者の横断意思の各時刻における真値は実際には知ることができないという点である。本稿では、井料ら [1] と同様に、歩行者が PFG 開始時に横断か待機かの意思決定を行うという仮定をおき、対象の信号サイクルの間に実際に横断した歩行者には *cross* を、横断しなかった歩行者には *wait* を、PFG 開始後のすべての時刻の意思に正解としてラベル付けした。多くのケースにおいてこの仮定は正しいように見えるが、観測データの中では PFG 開始後にも歩行者が横断意思を変えたように見受けられるものもあった。例えば、PFG が開始したのを見て一度は加速したものの、車両群の右左折が開始され、横断を諦め減速をするシーンや、逆に横断を諦め止まりかけたものの、他の歩行者が駆け込むのを見て、自らも横断を開始するといったシーンである。提案システムはこうしたシーンにおける加速や減速をとらえ、認識結果が切り替わるケースも少なからずあったが、本項で述べた結果では、

44 第2章 信号交差点における歩行者横断行動モデル

そのように例えその時々歩行者の真の意思と合致していたとしても、実際に横断したか否かで誤認識と評価されていることもあり得ることに留意が必要である。しかしながら、こうした解析は意思に対する憶測によるものになってしまうため、詳細に行うことは避ける。

このように誤っている可能性のあるラベルは推定結果との照らし合わせのみならず、学習データにも混入し得る。ただし、データ量を増やしかつ外れ値を除去する等の適切な処理を行うことでこの問題は解決し得ると考えられる。

モーション推定性能

本項では、全歩行者データに対するモーション推定結果を示す。表 2.6 は推定結果の正規化混同行列を表す。*walking* に対する認識はどの位置観測の誤差レベルにおいても 97% と、高い精度を保っている。これに対し、大きな誤差レベルが *standing* に対する認識精度を下げていることがわかる。大きな誤差が観測の不確実性を増し、歩行者が動いているのか止まっているのかの判断を難しくするためである。*running* は *walking* と誤推定する割合が高い。これは、*walking, running* とともに式 (2.59) で示す同一の運動モデル (Constant-Speed model) を仮定しているからである。Context-Speed model: 式 (2.61) によって、それぞれのモーションに特有な速度を考慮しているものの、二つの分布は完全に分離できるものではない。また、*standing* と同様に、*running* に対する認識精度も誤差レベルの影響を受ける。前述の通り、*walking, running* の識別には速度が重要となるが、大きな観測誤差は速度を正しく評価することを難しくする。

表 2.7 は、同一データに対し 2.2.1 節および 2.3.4 節で示した interacting multiple models カルマンフィルタ (IMM-KF) を適用した際のモーション推定結果である。ただし、*walking* と *running* はともに CV model で近似され、区別できないため、CP model を用いた *standing* と CV model を用いた *walking* の 2 クラスに対する推定となる。*walking* 状態の歩行者を誤認識することはほとんどないが、*standing* の認識精度が低いことがわかる。表 2.6 の提案モデルと比較すると、提案モデルの方が *standing* の認識精度が高い。これは、図 2.9(a) で示したような、待機することを選択した歩行者 ($D = wait$) が横断歩道に対しどの位置で停止しそうかという提案モデルのもつ知識が、認識を助けているからである。これに対し、IMM-KF は横断歩道前であろうと、横断歩道上であろうと各時刻に停止する確率は一定としているため、誤差を含む観測下で運動特性の変化に短時間で反応することは難しい。また、提案モデルは *walking, running* 間での誤識別はあるものの、IMM-KF と同様に一つのクラスとして考慮すれば、IMM-KF と変わらず誤識別はほぼ 0 である。

グループ推定性能

本項では、全歩行者データに対するグループ推定結果を示す。表 2.8 は推定結果の正規化混同行列を表す。*alone* クラスでは位置観測の誤差レベルが大きいほど認識精度が悪化し、逆に *in-group* クラスでは高くなる。これは、誤差レベルが大きくなり、観測尤度の関数が広くなることで、*in-group* クラスの急峻な尤度関数の影響が大きくなり、推定が *in-group* に寄るためと考えられる。

表 2.9 は、横断歩道前 ($W_t = before$) と横断歩道上 ($W_t = on$) で分離した際の推定結果の正規化混同行列を表す。すべての観測誤差レベルにおいて、横断歩道前と比べて横断歩道上での *alone* クラスに対する精度が低くなっている。これは、横断歩道という限られた通行スペースの中で必然的に歩行者間の距離が近くなってしまい、同行者との区別が難しくなるためであり、*in_group* クラスに対する Precision の低下を招いている。ただし、図 2.8 に示したようにグループ状態は横断意思決定に大きな影響があるが、これは横断歩道前でのみ行われるため、この横断歩道上でのグループ認識精度の悪化が意思認識精度に与える影響はないと考えられる。

位置推定性能

本項では、全歩行者データに対する位置推定結果を示す。表 2.10 は、提案モデル (DBN+PF) の推定結果とともに、比較として 2.2.1 節および 2.3.4 節で示したカルマンフィルタ (KF) および IMM-KF を適用した結果である。位置推定において、提案モデルが一般的な KF や IMM-KF と比べ、劣っていることがわかる。これは、KF や IMM-KF の推定は現在の状態と観測のみを元に行っているが、提案モデルはそれと同時に、式 (2.61): Context-Speed model という形で、横断意思やモーション、コンテキストに応じた速度分布を考慮しており、その分布へと寄った推定を行うからである。例えば、平均的な歩行者より速く/遅く歩行しているケースなどにおいて、推定結果が遅延/先行してしまい、真の位置や観測位置の周辺に粒子が存在しなくなってしまう現象が見られた。つまり、運動と横断意思やモーション、コンテキストの関係性をモデル化することによって、それらを認識することが可能になるが、時としてその確率モデルに沿わない挙動を不得意とするといえる。

表 2.11 は、グループ推定の結果が正しかった時/誤っていた時に分けた場合の位置推定誤差である。いずれの観測位置の誤差レベルにおいても、グループ推定が誤っていた際に位置推定精度も悪化していることがわかる。これは観測位置とともに粒子の重み付けを行う、グループに応じた直近の歩行者との距離尤度の影響である。グループ推定の誤っていると、同行者と離れるような、もしくは同行者でない歩行者と近づくような、粒子が選択されてしまう。例えば、*alone* クラスの歩行者に対して *in_group* の粒子が多い状況に陥ってしまうと、直近の歩行者の付近 1m の粒子に対して強い重み付けがされてしまい、真の位置から逸れてしまう。

表 2.3. PFG 開始後における横断意思推定結果の正規化混同行列


		$\sigma_n(m)$					
		0.1		0.4		1.0	
		Estimated		Estimated		Estimated	
		<i>cross</i>	<i>wait</i>	<i>cross</i>	<i>wait</i>	<i>cross</i>	<i>wait</i>
Actual	<i>cross</i>	0.85	0.15	0.76	0.24	0.74	0.26
	<i>wait</i>	0.04	0.96	0.06	0.94	0.06	0.94
Precision		0.79	0.97	0.72	0.95	0.72	0.95

表 2.4. 対象横断歩道ごとの横断意思推定結果の正規化混同行列


		$\sigma_n(m)$						
		0.1		0.4		1.0		
		Estimated		Estimated		Estimated		
		<i>cross</i>	<i>wait</i>	<i>cross</i>	<i>wait</i>	<i>cross</i>	<i>wait</i>	
横断歩道西	Actual	<i>cross</i>	0.84	0.16	0.70	0.30	0.69	0.31
		<i>wait</i>	0.04	0.96	0.06	0.94	0.06	0.94
	Precision	0.70	0.98	0.58	0.96	0.58	0.96	
横断歩道南	Actual	<i>cross</i>	0.86	0.14	0.82	0.18	0.79	0.21
		<i>wait</i>	0.06	0.94	0.05	0.95	0.06	0.94
	Precision	0.89	0.92	0.89	0.91	0.88	0.90	

表 2.5. 井料モデル [1] による PFG 開始時における横断意思推定結果の正規化混同行列


		Estimated	
		<i>cross</i>	<i>wait</i>
Actual	<i>cross</i>	0.81	0.19
	<i>wait</i>	0.16	0.84
Precision		0.91	0.71



(a) 推定軌道




(b) 意思/モーション推定確率




(c) 位置推定誤差


図 2.12. 横断ケースにおける状態推定 ($\sigma_n = 0.1\text{m}$)



(a) 推定軌道




(b) 意思/モーション推定確率




(c) 位置推定誤差


図 2.13. 横断ケースにおける状態推定 ($\sigma_n = 0.4\text{m}$)



(a) 推定軌道




(b) 意思/モーション推定確率




(c) 位置推定誤差


図 2.14. 横断ケースにおける状態推定 ($\sigma_n = 1.0\text{m}$)



(a) 推定軌道




(b) 意思/モーション推定確率




(c) 位置推定誤差


図 2.15. 待機ケースにおける状態推定 ($\sigma_n = 0.1\text{m}$)



(a) 推定軌道




(b) 意思/モーション推定確率




(c) 位置推定誤差


図 2.16. 待機ケースにおける状態推定 ($\sigma_n = 0.4\text{m}$)



(a) 推定軌道




(b) 意思/モーション推定確率




(c) 位置推定誤差


図 2.17. 待機ケースにおける状態推定 ($\sigma_n = 1.0\text{m}$)



(a) $\sigma_n = 0.1m$




(b) $\sigma_n = 0.4m$




(c) $\sigma_n = 1.0m$


図 2.18. 横断意思の認識精度の PFG 経過時間による変化



(a) $\sigma_n = 0.1m$



(b) $\sigma_n = 0.4m$



(c) $\sigma_n = 1.0m$

図 2.19. 横断意思の認識精度の横断歩道までの距離による変化

表 2.6. モーション推定結果の正規化混同行列

	$\sigma_n(m)$					
	0.1		0.4		1.0	
	Estimated		Estimated		Estimated	
	<i>standing</i>	<i>walking</i>	<i>standing</i>	<i>walking</i>	<i>standing</i>	<i>walking</i>
	<i>running</i>		<i>running</i>		<i>running</i>	
<i>standing</i>	0.91	0.09	0.00	0.81	0.17	0.02
<i>walking</i>	0.01	0.98	0.01	0.01	0.97	0.02
<i>running</i>	0.00	0.24	0.76	0.00	0.40	0.59
Precision	0.82	0.98	0.77	0.80	0.97	0.66
				0.76	0.24	0.00
				0.01	0.97	0.02
				0.00	0.54	0.46
				0.82	0.95	0.61

表 2.7. IMM-KF によるモーション推定結果の正規化混同行列

	$\sigma_n(m)$						
	0.1		0.4		1.0		
	Estimated		Estimated		Estimated		
	<i>standing</i>	<i>walking</i>	<i>standing</i>	<i>walking</i>	<i>standing</i>	<i>walking</i>	
Actual	<i>standing</i>	0.66	0.34	0.67	0.33	0.62	0.38
	<i>walking</i>	0.00	1.00	0.00	1.00	0.01	0.99
Precision		0.97	0.98	0.90	0.98	0.77	0.98

表 2.8. グループ推定結果の正規化混同行列

	$\sigma_n(m)$			
	0.1		0.4	
	Estimated		Estimated	
	<i>alone</i>	<i>in-group</i>	<i>alone</i>	<i>in-group</i>
Actual	0.91	0.09	0.86	0.14
<i>in-group</i>	0.12	0.88	0.07	0.93
Precision	0.96	0.81	0.97	0.72
	0.1		1.0	
	Estimated		Estimated	
	<i>alone</i>	<i>in-group</i>	<i>alone</i>	<i>in-group</i>
	0.91	0.09	0.78	0.22
	0.12	0.88	0.06	0.94
	0.96	0.81	0.97	0.63

表 2.9. 横断歩道前/上におけるグループ推定結果の正規化混同行列

		$\sigma_n(m)$					
		0.1		0.4		1.0	
		Estimated		Estimated		Estimated	
		<i>alone</i>	<i>in-group</i>	<i>alone</i>	<i>in-group</i>	<i>alone</i>	<i>in-group</i>
横断歩道前 ($W_t = before$)	Actual	0.94	0.06	0.90	0.10	0.85	0.15
	Precision	0.11	0.89	0.06	0.94	0.07	0.93
横断歩道上 ($W_t = on$)	Actual	0.95	0.87	0.97	0.83	0.96	0.75
	Precision	0.90	0.10	0.83	0.17	0.72	0.28
		0.12	0.88	0.07	0.93	0.04	0.96
		0.96	0.74	0.97	0.64	0.98	0.54

表 2.10. 位置推定誤差の比較 (平均/標準偏差)

	$\sigma_n(m)$		
	0.1	0.4	1.0
DBN+PF	0.09 / 0.05	0.29 / 0.17	0.68 / 0.41
KF	0.06 / 0.04	0.21 / 0.13	0.44 / 0.30
IMM-KF	0.06 / 0.04	0.20 / 0.13	0.43 / 0.29

表 2.11. グループ推定正誤時別の位置推定誤差 (平均/標準偏差)

	$\sigma_n(m)$		
	0.1	0.4	1.0
グループ推定: 正	0.09 / 0.05	0.28 / 0.17	0.62 / 0.38
グループ推定: 誤	0.10 / 0.06	0.39 / 0.20	0.92 / 0.48

2.6 結論

本章では、信号付交差点の横断歩道における歩行者行動モデルおよび認識システムの提案を行った。交差点において、歩行者は信号はもちろん、横断歩道との位置関係や右左折待機車などさまざまなコンテキストを考慮して行動している。そこで、それらの影響因子と歩行者の意図や運動の関係性を、ダイナミックベイジアンネットワークを利用して確率的に記述した。さらに提案システムでは、このダイナミックベイジアンネットワークに対して粒子フィルタを用いることで、歩行者の観測位置や信号の状態といった情報から歩行者の横断意図やモーションをオンライン推定することができる。ただし、信号の状態は、今後の ITS 社会の発展により、車載システムであっても V2I 通信によって獲得し得る。

提案モデル/システムの評価は、実際の交通シーンにおいて 1000 人近い歩行者データを収集して行った。そして、車道に進入してくるまでおよそ 2, 3 秒以上かかる位置にいる歩行者の横断意思を高い精度で認識可能なことを示した。また、移動モーションや同行者の有無といった歩行者状態も同時に推定可能であった。

提案モデルは歩行者の意思や多様なコンテキスト情報に応じた尤もらしい行動、つまり自然な歩行者行動をモデル化したものである。そのため、認識システムではそうした自然な行動と実際の行動を照らし合わせて、意思のような非観測量を推定することになる。入力として与えている位置観測は、各時刻の歩行者の状態を説明するものではあるが、仮定しているコンテキストから起こりにくいと考えられている場合にはそれを軽視してしまうことが起こり、それが位置推定精度の従来手法に対する悪化に現れていると考えられる。今後、観測と意思/コンテキストに基づく行動モデルの適応的な重み付けを行うフィルタリング手法を考慮する必要がある。また、変数間の確率過程をモデル化したロジスティック回帰やガンマ回帰が最適であるかも再検討が必要だ。

このように、提案手法はあくまで歩行者の自然な行動のモデル化であるために、それで説明し切れない異常な行動が見られた場合は、緊急的に別のシステムによる対応が必要となることになる。しかしながら、自然な歩行者行動を理解した上での車両側の自然なモーションプランニングや安全運転支援に対して、効果的であると考えられる。特に、横断意思は交差点周辺における歩行者に対する高次な情報である。次章にてこの歩行者モデルを活用したモーションプランニング手法の提案を行う。

第3章

信号交差点における左折モーションプランニング手法

3.1 研究背景

本章では、信号交差点におけるドライバーの左折行動の学習と、それに基づく自動運転に向けたモーションプランニング手法を提案する。

自動運転を考えるにあたり、衝突を起こさないモーションプランニングは絶対的な要件となるものの、それだけでは不十分である。自動運転車と人間ドライバーや歩行者が交通の中で共存するためには、人間の目から見たときのその動きの「自然さ」が同時に求められる。なぜならば、不自然な行動は周囲の人間を混乱させたり、恐怖を与え、たとえ能動的な衝突を引き起こさないシステムであったとしても、受動的な衝突を被り得るからである。

前章で論じたように、交差点は交通シーンにおいて歩行者と自動車の軌道が交差する複雑な領域であり、自律走行を考えるにあたっても困難が伴う。安全かつスムーズに通過するためには、他の交通参加者の状態や意図を認識することは必須であり、その一環として前章では歩行者という保護すべき対象の意思の認識手法の提案を行った。本章では次なる一步として、自然な運転行動の解析、学習を行う。そこで、対象シナリオとなる交差点における左折運転行動について以下で簡潔に述べ、問題を整理する。

まず、交差点周辺に通行の障害となる歩行者や車両がない状況を free-flow と呼ぶ。free-flow では、車両制動の観点から安全に左折するために減速し (in-flow)、その後加速 (out-flow) が行われる。本稿では、ドライビング行動が歩行者に影響を受ける、より複雑な交差点状況でのモーションプランニングを想定しているため、この free-flow に関しては論じない。それと同時に、自車両の前に先行車がいる場合も、いない場合と行動に差が出ると考えられるので、本論文では扱わない。

もし、free-flow での通過により歩行者とのコンフリクトが想定される状況である場合には、多くの場合 free-flow より強い減速を行い、横断歩道が通行可能となる機会を待つ。この歩行者の横断を優先した減速行動は yield と呼ばれる。また、歩行者の横断状況によって、必要があれば停止を行うが、これを hard-yield と呼ばれる。逆に、停止を伴わない場合は soft-yield




図 3.1. 交差点左折時の速度変化例

と呼ばれる．図 3.1 にこれら hard-/soft-yield および free-flow 時の実際の車両の速度推移の例を示している．ただし，データは 2.5.1 項で述べた，実交通シーンから収集されたものである．

横断歩道を通過 (clear) するためには，自車両軌道を横切る歩行者間の，通過可能な空間/時間差を見つける必要がある．この歩行者間の空間的あるいは時間的なインターバルは gap と呼ばれ，それに対する通過可能性の評価は gap acceptance と呼ばれる．そして，通過した場合は accept した，しなかった場合は reject したと呼ぶ．また，どの歩行者間にも accept 可能な gap がなかった場合，すべての歩行者が自車両前を通過した後に，自車両が通過することになる．

このように，交差点は通過の際に，他のたくさんの歩行者，車両とのインタラクションが起り得る領域であり，複雑さを伴う．必然的に交通密度も高くなり，こうした状況において，他者を混乱させたり，恐怖を与えたりしないためには，人間の目から見て自然な振る舞いをすることが重要である．本章では，ドライバーの運転行動を学習することによって，前章で提案した交差点における歩行者モデルとともに，自然なモーションをプランニングする手法を提案する．

3.2 関連研究

本節では、人間ドライバーの運転モデルならびに運転支援や自律走行のためのモーションプランニングの先行研究に関して述べる。前節で述べたような、人間の自然な運転行動を自律システムとして再現するには、人間自身の行うそれを学習する必要がある。

3.2.1 運転行動の認識モデル

自動運転において、能動的に歩行者や他車両に衝突しないということは絶対的な条件であり、そのようなぶつからないモーションプランニングを実現するためには、そうした対象の行動を適切に認識することが必須である。前章では歩行者に焦点をあて、2.2 で多くの歩行者行動認識の先行研究を紹介するとともに、以降で高次のレベルで行動を理解するためのモデルを提案した。ITS の分野では、同様に、他ドライバーの行動や意図を認識することを目的として、ドライビング行動の解析、モデル化が行われてきた。

Lefvre らは、運転行動のモデル化手法は大きく3つに分けることができるとしている [92]。まず、物理ベースなモデルで、車両の運動を速度/加速度や車両の質量、道路の摩擦係数など、物理法則の観点から記述するものである [93, 94]。しかし、動的な道路交通環境において、このような手法は短い時間の予測にとどまる。

二つ目は、ドライバーが意図している運転行動をベースとしたものである。Driggs-Campbell ら [95]、Amsalu ら [96] は、離散的な意思と連続的な運動量を組み合わせ、それぞれ車線維持/変更の意思、交差点における直進/右左折の意思の認識を行った。車両の運動は長時間にわたって、それを運転するドライバーの意図によって決定されるはずであり、物理ベースなものよりも高次の予測が可能である。

最後に、最も高次のモデルとして、環境や他の交通参加者とのインタラクションを考慮したものである。前章で述べた歩行者同様、ドライバーの運転行動の決定にもその時々状況が影響を及ぼしており、予測を助けるものである。こういった複数の状態量の確率的な関係性の記述には、2.3 節で述べたベイジアンネットワークおよびダイナミックベイジアンネットワークがよく用いられる。Gindele ら [97, 98] は、ドライバーの意図や車両同士の相互作用、そしてそれによって生じる車両の動きの関連性をダイナミックベイジアンネットワークによって確率モデル化し、それらの認識に応用した。Platho らは [99]、複雑な交差点シナリオを、より単純な影響を与える実態/受ける実態の組み合わせに分解し、ベイジアンネットワークを適用してモデル化を行った。また、Regele [100] や Hulsen ら [101] は、オントロジーによって交通における実体とその関連性の記述法/意味付けを提唱した。未来を予測し、リスクを評価するには、こうした他の交通参加者の意思やそれらとのインタラクションを高いレベルで意味付けすることが必須である。自律走行がこのような周囲の状況の的確な認識の上に成り立つのは間違いない。

3.2.2 運転行動の統計モデル

2.2.3 節で歩行者に関して述べたのと同様に、ドライバーの運転行動に関しても交通工学の見地から解析がなされている。その多くは歩行者に対する研究と同様に、大量のデータを収集し、統計的な解析によって運転行動を説明するものである。

特に、右折時(左側通行における)の連続する対向車の間や右左折時の歩行者間をどのような条件で通過(accept)するか否(reject)かを表す gap acceptance は多い。古典的な解析は、連続する歩行者の時間差のような変数に対して決定的な閾値を定めるものであった[102, 39]。しかしながらこうしたモデルは、ドライバー間での運転行動の差異がなく、ドライバー各々も常に一貫性を持っていると仮定したものであるが、実際には運転の習熟度やその時々身体状況など様々な要因が絡んでいるはずで、確率的に定義されるべきものである。Rakha ら[90], Ragland ら[103] らは、右側通行における左折時の対向車に対する gap acceptance 行動を、ギャップ長や待ち時間、雨の強さを説明変数としたロジスティック回帰によって、説明を試みた。また、Schroeder ら[104] は信号交差点における、Salamati ら[105] らはラウンドアバウトにおける、歩行者に対する道を譲る(yield)行為をロジスティック回帰によってモデル化した。

Alhajyaseen ら[106] は右左折車のとる軌道を、Wolfermann ら[107] は加速/減速を含む速度プロファイルを、交差点の幾何構造が与える影響とともに確率的に定式化した。Alhajyaseen らはさらに左折時(左側通行における)の歩行者に対する gap acceptance の解析も行い[108, 109]、これらを組み合わせることによって、左折行動の統合的な統計モデルの構築を試みている[110]。

3.2.3 モーションプランニングモデル

3.2.1 項で述べたような手法により他車両や歩行者等の周囲の環境を把握、認識を行った上で、自律走行システムは自らがいかに行動するかというモーションプランニングを行う。Kye ら[111] は、信号無交差点における対向車などの意思をダイナミックベイジアンネットワークを用いて認識し、その上で報酬関数を利用した Partially Observable Markov Decision Process (POMDP) [112] によって最適な意思決定を行う、自律走行システムを提案した。

また、緊急時の回避策も自動運転や運転支援システムとしてドライバーの安全を支える上で必要となる。Kohler ら[44] は、インフラストラクチャーベースでの歩行者の車道への横断開始の意思の認識を行うとともに、それを元にした車両側の回避軌道のプランニングを提案した。Keller ら[113] らや Braeuchle ら[114] は、センシングノイズや歩行者行動の不確実性を考慮した上で、ブレーキカステアリングのどちらを選択するかも含めた緊急的な衝突回避行動の定式化を行った。

このような衝突を起こさないモーションプランニングは、自律走行に対する絶対的な要件となるものの、それだけでは不十分である。前節で述べたように、人間との交通シーンでの共存

には、運転行動の自然さが求められる。周囲だけでなく、搭乗者に不安感や不快感を与える運転も好ましくない。例えば、住宅街のような見晴らしの悪い交差点では歩行者が急に飛び出し得り、そのようなリスクを予見し、一般的なドライバーは減速を行う。たとえ飛び出してきた際にシステムによる停止が可能であるとしても、そうした人間の感じている潜在的なリスクを無視することは、人間に不安感を与えかねない。Raksincharoensak ら [115], Akagi ら [116] は、このような状況において、リスクポテンシャルをモデル化し、ドライバーが自然に行う運転行動を学習したモーションプランニングを提案した。

本節で見てきたように、運転行動の認識モデルや統計モデルとして定式化を試みる研究は数多くあるものの、自律走行としてそれをさらに再現するものは未だ多くはない。次節では、前節で述べた歩行者行動の認識モデルの上に成り立つ、歩行者とのコンフリクトシーンにおけるモーションプランニング手法を提案する。

3.3 提案手法

本節では、交差点におけるドライバーの左折行動の学習とそれに基づくモーションプランニング手法を提案する。3.1 節で述べたように、左折時に歩行者と交わり得る基本的な行動は in-flow/out-flow, gap acceptance を含む yield のように分けることができる。この様々な意思決定を伴うプロセスをサブモデルに分け、モーションプランニング手法を構築する。ただし、あるサブモデルの仮定のもとに成り立つサブモデルもあるので、記述する順序は左折時に起こるプロセスの順序とは異なる。

ここで、ドライバーが歩行者とのコンフリクトを避けるには、速度を調整するか軌道を調整するかという二つの手段があるが、ドライバーは車両の軌道を変えるのではなく、速度を調整する方を多く選択することが調査されている [117]。本研究では自然なドライビング行動の学習を目的としているため、この原則に基づき、軌道は既にプランニングされ、固定されたものとし、速度の調整のみで交差点を通過するかということについて論じる。また、道路交通における自律走行では、交差点に進入し、通過し切るまでのような短いスパンにおける軌道はあらかじめプランニングされると考えることができ、このことと合わせて考えれば、自車両の未来の軌道は既知と仮定できる。

3.3.1 加加速度制御モデル

交差点ではほとんどのケースにおいて、車両は減速、その後に加速を行い通過する。この時、ドライバーはブレーキとアクセルを活用しながら車両の加減速を制御しているが、Wolfermann ら [107] は減速中 (in-flow)/加速中 (out-flow) に区切って見ると、多くの場合その速度変化は 3 次関数で近似できるとしている。これは速度の 2 階微分、加速度の 1 階微分である加加速度 (jerk) が一次式で表されることを意味する。一般にこの加加速度が大きいと慣性によって受ける力の変化率が大きく、搭乗者は不快に感じると言われている。この加加速度の一次式の傾きを k 、加加速度/加速度/速度の初期値をそれぞれ j_0, a_0, v_0 とすると、 t 秒後のそれぞれの値は以下の式 (3.2)~(3.4) で表される。

$$j_t = kt + j_0 \quad (3.1)$$

$$a_t = \frac{k}{2}t^2 + j_0t + a_0 \quad (3.2)$$

$$v_t = \frac{k}{6}t^3 + \frac{j_0}{2}t^2 + a_0t + v_0 \quad (3.3)$$

$$(3.4)$$

また、図 3.2 にこれらの変数の変化例を示す。黒線の 5 秒を境に、2 種類の加加速度の 1 次式を用いている。

自律走行というコンテキストにおいては、自車両の速度/加速度はセンサ類から知り得る。そこで、提案モデルにおいても、ある時刻においてこの加加速度の一次式における傾き k および初期値 j_0 を定め、その後はそれに基づき、式 (3.2)~(3.4) に従うような制御を遂行する。




図 3.2. 速度/加速度/加加速度の制御例

つまり, k, j_0 の 2 つの値によって, その後の速度プロファイルをプランニングすることとなる. ただし, 提案モデルにおいては, in-flow および out-flow をそれぞれ一組の k, j_0 のプロファイルでプランニングするとは限らず, 後述するように歩行者の横断状況などによって動的に更新され得る. 加加速度は非常にセンシティブな変数であるが, 例えば終端の速度とその時刻のような, 拘束条件を与えることで k, j_0 は決定し得る.

3.3.2 コンフリクト領域モデル

ドライバー-歩行者間で, 互いの行動を見ながら, どちらが先に横断という順序に関する意識的もしくは無意識的な判断が行われていると考えられる. 横断歩道周りでの加速はほとんどの場合において, 横断歩道通過開始の意思を表すが, それに関連したデータを示す. 図 3.3 は, 横断歩道を通るための加速を開始した時点での, 最後に自車両の前を通過した歩行者と自車両軌道との距離の累積分布である. ただし, 歩行者が軌道を通る前は正の値, 通過した後は負の値をとり, 青線は hard-yield, つまり停止状態からの, 赤線は soft-yield, つまり徐行状態からの加速を表す. この図からおおよそ 85% のドライバーは, 自車通過前最後の歩行者が, hard-yield の場合は自車軌道のおおよそ 2.5m に近づくまで, soft-yield の場合はおおよそ 1m に近づくまで, 加速を開始しないことがわかる. この現象は, ドライバーがある歩行者の直後に通過する意思を持っていても, その歩行者がその順序が明確でない距離にいる段階で加速を始めると, その意図した順序を歩行者が見誤って脅威を感じたりや急かされるようなプレッシャーを感じ得るためと考察できる. そこでこの, 歩行者が侵入することで横断順序が決定され, 車両以上の幅を持った領域をコンフリクト領域 (conflict area) と考える. ある歩行者がコンフリクト領域に侵入し, ドライバーがその後に通過が可能と考えた場合に, 加速が開始され得る. この幅はドライバーごとや状況において変わり得る確率変数であるが, 本稿では一定の値を持つものとし, 2.5m とする.




図 3.3. 加速開始時の歩行者-車両軌道間距離の累積分布

このコンフリクト領域のもと，out-going 歩行者をコンフリクト領域内にいる，もしくは既にコンフリクト領域から出て行った歩行者と定義する．それとは逆に，コンフリクト領域に接近してくる歩行者を on-coming 歩行者と呼ぶこととする．図 3.4 にこうしたシーンの概観を示す．

また，歩行者の状況は動的に変化するため，例えば，遠方の歩行者が駆け出したために通過可能であった gap が消失する可能性がある．そのために必要以上に早い加速開始は，そうした変化により再度の減速を余儀なくされることも起こり得る．これを避けるためにも，通過が可能と考えられそうな gap が十分に近づいてから，それを狙った加速を始めるとも考えられる．

3.3.3 Gap Acceptance モデル

前項で，ドライバーがある歩行者の直後に通過することを意図している場合でも，歩行者がコンフリクト領域と定義した十分な近さに接近してくるまで加速行動を始めないことを示した．そこで，ある歩行者がコンフリクト領域に進入した瞬間に，ドライバーはその歩行者後方の gap を accept するかか意思決定を行うと仮定する．ただし，ここではコンフリクト領域に進入してきた歩行者を entering 歩行者と呼ぶ．

Alhajyaseen らは [108, 109]，同様な左折シチュエーションにおける gap acceptance をモデル化し，ある歩行者がコンフリクト領域 (ここでは車両幅) から出てから次の歩行者がコンフリクト領域に入ってくるまでの時間間隔を変数とし，その累積分布に対して Weibull 関数によるフィッティングを行った．しかしながら，この時間間隔は車両の通過が完了した後に事後的に観測される値であり，動的な歩行者行動により，ドライバーが通過の決断をした時点で予測されていたものとは異なるものとなり得る．また，車両が停止している状況では，通過を開始したか否かでその gap を accept したか否かを区別できる反面，車両が動いている状態での判断の時刻を定められなかったため，停止を伴わない soft-yield に関しては，実際に accept された gap のみが抽出された．つまり，hard-yield における停止前も含め，車が横断歩道に

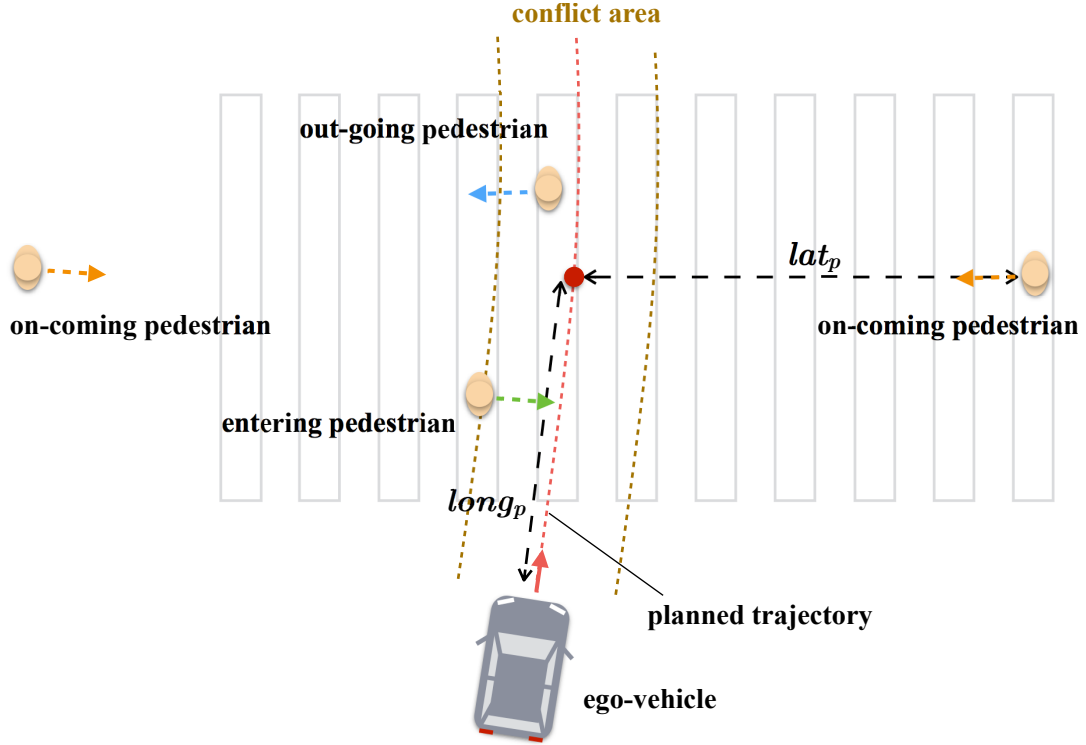


図 3.4. Yielding/Gap acceptance シーンの概観

接近している最中に潜在的に reject された gap の解析がなされなかった。しかしながら、ドライバーは歩行者の状況のみならず、自車両の横断歩道までの距離や速度といった変数も含めて、gap acceptance の判断を行っていると考えられる。そして、停止を行わずに gap の到来を待つ soft-yield も、通過する行動も、人間のドライバーの自然な運転行動として非常に重要である。

本稿ではこの gap acceptance をロジスティック回帰によってモデル化する。ドライバーが gap を accept する確率は以下のロジスティック関数で定められる。ただし、 \mathbf{x} は説明変数のベクトル、 α, β は定数および説明変数に対する係数ベクトルである。

$$L(\mathbf{x}) = \frac{\exp(\alpha + \beta\mathbf{x})}{1 + \exp(\alpha + \beta\mathbf{x})} \quad (3.5)$$

先述の通り、gap acceptance は歩行者ならびに自車両の状態によって決まると考えられる。そこで、on-coming 歩行者の速度、自車両軌道までの距離 (図 3.4 中 lat_p)、自車両のスピード、自車両から歩行者軌道までの距離 (図 3.4 中 $long_p$) を説明変数とする。ロジスティック回帰は確率的な事象の説明に用いられるものであるが、このケースにおいてはどの程度の割合のドライバーが accept する gap かという評価指標となり得る。つまり、実運転データを用いてパラメータ推定し、ロジスティック関数の出力を元に gap を accept/reject することで、多くのドライバーが取りうる行動を自律走行において再現できるのである。例えば、ロジスティック関数の出力が 0.5 以上である gap を accept することとすれば、2 人に 1 人は accept しないような狭い gap を accept することとなる。この閾値を 0.9 などの高い値にすれば、かなり広い

gap のみをとる，安全マージンを広くとったシステムになると言える．

このロジスティック関数による評価はすべての on-coming 歩行者に対して行われ，このうちの最低値によって，entering 歩行者の直後に通過が可能であるかが判断される．最低値を評価するのは，すべての on-coming 歩行者との衝突を回避するためには，最悪の条件を考える必要があるからである．

accept された際は，すべての on-coming 歩行者の状態が accept できるものであったと考えるのが自然であり，学習で用いられる．逆に reject された場合は，実際にはどの on-coming 歩行者が accept できないものにさせたのかはわからない．例えば，歩行中のある on-coming 歩行者ではなく，より後方から走りこんでくる on-coming 歩行者によって，accept できないといった状況があり得るため，単純にコンフリクト領域に最も近い on-coming 歩行者と仮定するのは適切でないと考えられる．そこで，ドライバーは on-coming 歩行者の到達順序が正しく評価できると仮定し，実際に entering 歩行者の次にコンフリクト領域に到達した on-coming 歩行者を学習に用いる．

また，本モデルは 2 章で提案した歩行者モデルを活用する．横断意思のない歩行者 ($D = wait$) は，この評価から除外される．Time-to-collision(TTC) やそれに類する指標のみを元にしたモーションプランニングとは異なる．そうしたシステムでは，歩行者が停止するために減速を開始し，それにより TTC が大きくなるまでシステムは通過可能なことを判断できない．これに対し，提案した歩行者横断モデルは PFG 時に横断歩道の数メートル前から歩行者の待機意思を認識することができ，横断意思のない歩行者を無駄に待つことを避けることができる．ほとんどのドライバーが歩行者の横断意思を認識して，通過可能かを評価していると考えられ，これに近い自然なモーションプランニングへとつながる．

3.3.4 Potential Gap 探索モデル

前項では，歩行者がコンフリクト領域に進入した瞬間に意思決定プロセスを固定することによる，gap acceptance のモデル化を提案した．しかしながら，実際のドライバーはそうした瞬間より前から，おおよそ通過可能な gap を知覚しており，そうした結果が無駄な短い停止を避ける soft-yield という行為につながっていると考えられる．

そこで，提案モデルにおいても潜在的 (potential) な gap の探索を行う．まず，各 on-coming 歩行者のコンフリクト領域への到達時間 t_a を予測する．そして，ある歩行者を起点として，それよりも t_a の大きい後続の歩行者との gap を考え，その gap が t_a 後に accept 可能なものであるかを評価する．起点となる歩行者は t_a の小さい順に選択され，それを preceding 歩行者と呼び，その後続の歩行者を following 歩行者とする．preceding 歩行者の t_a によって，following 歩行者と自車両の状態を予測することによって， t_a 後の lat_p と $long_p$ を推定する．ただし，歩行者は速度一定で進むとし，自車両は 3.3.1 項で定めた方式による現在の加加速度制御を続行するものとする．こうして予測される preceding 歩行者のコンフリクト領域進入への瞬間の状態に対して，前項で定めたロジスティック関数による評価を行う．もし，preceding 歩行者を t_a の大きいものへと切り替えていきながら，accept できる gap が見つかった場合，

その gap における preceding 歩行者を target 歩行者とする。見つからなかった場合は、 t_a 最大の歩行者が target 歩行者となる。この target 歩行者は、その直後に自車両が通過可能であることが予測されることを意味する。

このようにして、潜在的な Gap を探し出し、後述するその到来を考慮したモーションプランニングを行う。

3.3.5 Yield 選択モデル

3.3.1 項で示した加加速度によるプランニングは自由度 2 であり、多様な速度軌道を生み得る。そこで幾つかの制約を設けることでこれらの値を定める必要がある。

横断歩道上/周辺の歩行者群によって、長時間通過できないと考えられる状況で、多くのドライバーは横断歩道手前で停止する。ある時点での速度/加速度に対し、横断歩道の手前の地点で速度/加速度ともにゼロとなり停止する一組の k, j_0 の加加速度プロファイルが一意に定まる (これを k^h, j_0^h とする)。これを hard-yield プロファイルと呼ぶこととする。Alhajyaseen ら [110] らも、gap の accept によって通過を開始するまでの in-flow 間はこの hard-yield プロファイルを用いている (論文中では clearing profile)。横断歩道手前で停止する位置は正規分布に従うとしてモデル化する。

この hard-yield プロファイルは横断歩道手前で停止したことを目的としたプランニングであるが、前項では潜在的な gap の発見方法を示した。もし、この gap の到来が hard-yield プロファイルにおける停止時刻よりも早い場合、hard-yield プロファイルを用いる必要性はない。実際のドライバーも gap の到来を予見しながら、それに対して通過の準備をすることを考える。そこで gap の到来に合わせた加加速度制御法として soft-yield プロファイルを提案する。これは gap の到来時に、通過のための加速の準備ができているようなプランニングで、この準備状態を横断歩道の手前で加速度がゼロになっていると仮定する。この拘束条件によって、hard-yield プロファイルと同様に k, j_0 のプロファイルが一意に定まる (これを k^s, j_0^s とする)。

この hard-yield プロファイルと soft-yield プロファイルの選択は、gap の予測到来時間によって行われるため、歩行者状況の変化によって、動的に変化する。つまり、in-flow 間を、一意に定る hard-yield プロファイルのみでなく、複数のプロファイルでプランニングしていくこととなる。

3.3.6 Clearing モデル

in-flow プロセスが、yield 行動のために、交差点に進入してからおよそ横断歩道の手前までという空間的制約がある中で行われる一方、gap を accept し、横断歩道を通過 (clear) していく out-flow プロセスは通過した先の交通状況などによって、大きく変わり得るものである。そのため、out-flow に対する加加速度プロファイル k^o, j_0^o はそうした状況にプランニングされているものと仮定する。本稿では、 k^o は [108] と同様にガンマ分布に従うとし、横断歩道を通




図 3.5. 通過時マージンの概要

過し切った際の速度/加速度を既知とすることで、残りの j_0^o が定まる。

こうしたプランニングと同時に、車両は歩行者と衝突せずに通過する必要がある。多くのドライバーは歩行者の前方/後方を通過する際に、車両幅以上の十分なマージンを確保する。このマージンを含めた、車両通過時の歩行者と自車両軌道の距離はガンマ分布で近似し、実際の交通データに対しフィッティングを行う。この out-flow プロファイルを実行した際に、すべての out-going 歩行者と on-coming 歩行者に対して、このマージンが確保できるタイミングで、out-flow プロファイルに移行する。ただし、図 3.5 に示すようにこのマージンは歩行者の前方/後方を通過する際、常に確保する必要があるため、out-going 歩行者に対しては、車両前方が歩行者軌道を到達する時点、on-coming 歩行者に対しては、車両後方が歩行者軌道を到達する時点を予測して考慮する。

3.4 シミュレーションによる評価実験

前節では交差点におけるドライバーの左折行動の学習に基づくモーションプランニング法の提案を行った。本節では、実交通シーンのデータの中で提案手法を用いたモーションプランニングのシミュレーションを行い、実際のドライバーの挙動との比較を行う。

3.4.1 実験データ

提案モデルの学習および評価には、歩行者挙動解析の2.5節と同じ、実際の交通シーンから取得したデータを用いた。

本手法は歩行者に対する yield 行動が生じるシーンを対象としているため、評価には交差点の進入から横断歩道を通過するまで歩行者による影響を受けたと考えられる左折車のみを用いる。また、先行車がいる状況に対するモデル化を論じていないため、先行車による影響を受けた左折車は除く。このようにして図3.6に示す、横断歩道西で歩行者とのコンフリクトが起る西向き左折を行う37台、横断歩道南で歩行者とのコンフリクトが起る南向き左折を行うの11台を抽出した。ただし、学習には、先行車に影響を受けたものの最終的に右左折待機車群の先頭で gap acceptance を行ったものや、横断歩道に十分に近づき、左折車による行動の違いがないと考えられる右折車のデータも用いた。テストデータのうち、横断歩道前での停止を伴った hard-yield は25台、停止せずに通過した soft-yield は23台であった。歩行者モデル評価時と同様に4分割交差検定を行った。

*2

3.4.2 シミュレーション方法

本手法は人間ドライバーの自然な運転行動を学習し、平均的なそれを再現することにある。学習によって得られる学習モデルは多くの確率モデルを含むが、ここではその分布の最大をとる値にパラメータを固定して用いることで、一通りのモーションをシミュレーションする。これを平均的なドライバーであると仮定し、実際の運転行動と比較を行う。3.3.3項で述べた gap acceptance 評価式(3.5)に対する閾値は0.7とした。

シミュレーションの開始点は、西向き左折車のケースは図3.6の赤線で示す停止線、南向き左折車のケースは図3.6の緑線で示す横断歩道の端線とする。その時刻の実車両の位置、速度および加速度を本モデルに与える。また、3.3節で述べた前提に基づき、実車両の軌跡は既知のものとして与える。さらに、横断歩道を実車両の車体全体が通過した時刻の、実車両の速度および加速度を既知とする。

また、本手法は3.3.3で述べたように、2章で提案した歩行者行動モデルを考慮している。そこで、シミュレーションに対しては、2.5節で述べた歩行者行動に対するフィルタリング結

*2 Google マップ (<http://maps.google.co.jp/>) より引用

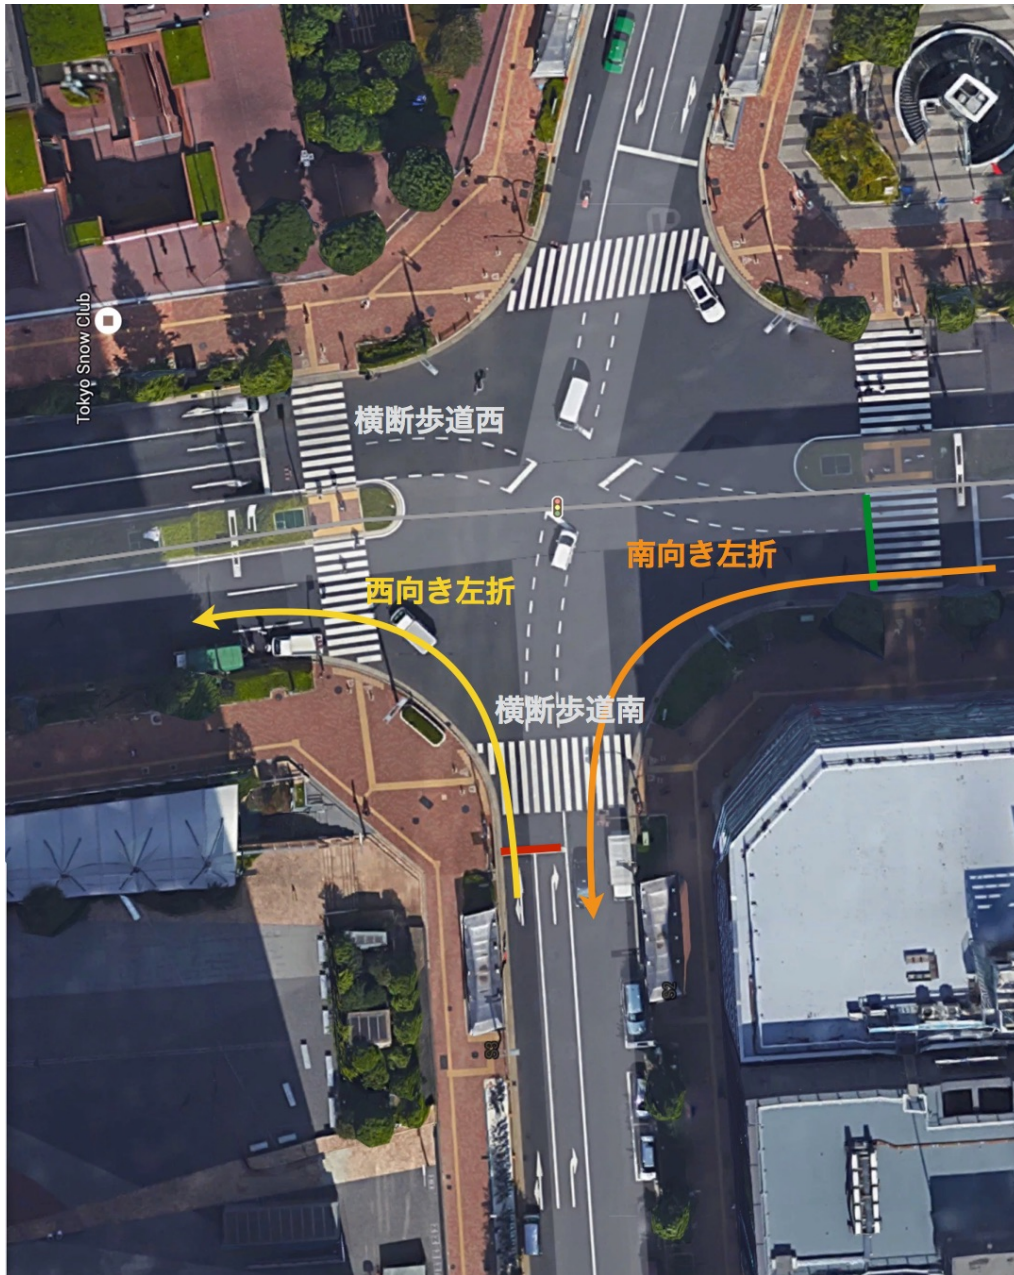


図 3.6. 実験対象交差点 *1

果を歩行者情報として与える。ただし、歩行者観測位置におけるシミュレーションされた誤差 $\sigma_n = 0.4\text{m}$ の結果を用いた。また、2.5 節では横断歩道周辺 20m と広い範囲でのフィルタリングを行ったが、ここではドライバーの限定された視野を考慮して、与える歩行者情報は自転車両軌道から near-side 側は 15m, far-side 側は 20m 以内にいる歩行者のものに限定している。しかしながら、実際のドライバーがどの歩行者を知覚できていたかは知ることができないため、この点で実際のドライバーの運転行動とシミュレーションが異なるものになる可能性が存在し得る。

表 3.1. 実ドライバーとの Gap Acceptance の差異


	計	同一	遅延	先行
提案手法	48	39	8	1

3.4.3 シミュレーション結果


表 3.1 は、テストデータの実際のドライバーとシミュレーションが行った gap acceptance の違いを表すものである。同一はドライバーと同じ gap を accept もしくはすべての歩行者の通過後に通過したケース、遅延はドライバーの accept した gap を reject したケース、先行はドライバーの reject した gap を accept したケースを表す。およそ 80% は実際のドライバーと同じ判断をしていることがわかる。また、遅延が生じたケースを観察すると実際のドライバーがかなり狭いギャップを選択し、結果として歩行者と急接近するシーンも多く見られた。安全の観点から必ずしもテストデータのドライバーが正しい判断であるとは限らない。自然な運転行動の学習という点で考えると、多くのドライバーが accept する gap を確実に見つけ出していると言える。

3.3.6 項では、横断歩道を通過する際に、単にぶつからないだけでなく、ドライバーが歩行者と車両幅以上のマージンをとることを述べた。通過する車両との距離が近くなることは歩行者にも不快感や恐怖を与えることになるので、重要な指標であると考えられる。図 3.7(a) は、歩行者前方/後方通過時の歩行者-車両軌道間距離の各左折シーンごとの最小値の累積密度分布である。テストデータの分布 (observed) と類似したシミュレーション結果 (simulated) となっているように見える。実車両データにおける十分位数を横軸に、シミュレーション結果における十分位数を縦軸にとった Q-Q プロットが図 3.7(b) である。これらのプロットが黒線で表される、原点を通り傾き 1 の線に近いほど、二つが近い分布であると言え、シミュレーション結果が実際の運転行動に近いことが見受けられ、シミュレーションにおいても人間ドライバーと同程度の安全性が保たれているといえよう。

また、横断歩道において高いスピードを出すことも歩行者に恐怖を与えかねない。図 3.8 に横断歩道進入時の速度の累積密度分布と Q-Q プロットを示す。歩行者-車両間距離とは対照的に、分布の大きな差異が見られる。これは、すべてのシミュレーションに対して、等しい outflow プロファイル k^o と hard-yield の場合は出発点となる横断歩道前の停止ポイントを与えているからであり、加えて拘束条件として与える横断歩道を通過し切った際の速度/加速度が各テストデータで異なるとはいえ、このようなおよそ 2m を中心とした狭い分布を生むと考えられる。しかしながら、シミュレーションの目的は、学習の結果として、平均的な運転行動を再現することであり、その目的は達成されていると言える。



(a) 累積分布




(b) Q-Q plot


図 3.7. 横断歩道通過時の歩行者-車両軌道間最小距離

シミュレーション例

ここでは、定性的な分析として、Alhajyaseen ら [110] による左折運転行動モデルとの比較を行う。Alhajyaseen らのモデル現在考えているような、歩行者への yield 行動が必要なシーンでは、交差点に進入すると hard-yield プロファイルに沿って、横断歩道手前で停止する減速行動をとる。このモデルでは [108] を用い、この減速中もしくは停止中には各時刻に歩行者のペアに対し、先行する歩行者がコンフリクト領域（ここでは車両幅）を通過し切る時間と後続する歩行者がコンフリクト領域に進入する時間を予測し、その差を用いて gap acceptance の評価が行われる。ここで、各ドライバーは out-flow に対するプロファイル (k, j_0) の組を持っている (clearing profile)。Gap の評価によって accept できるものが発見された場合は、この clearing プロファイルに切り替えた場合にコンフリクト領域を衝突することなく通過可能かを



(a) 累積分布



(b) Q-Q plot

図 3.8. 横断歩道進入時の速度

予測する。もし、安全に通過可能と判断された場合は clearing プロファイルに切り替える。これを毎時刻繰り返すものである。

3.3.3 項で述べたように、[108]における gap acceptance の解析は、停止中のみ reject を数える上、gap のタイプをペアとなる歩行者の横断方向によって 3 種類に分別しているため、soft-yield も多く含む今回のデータセットでは十分なデータを得られない。そのため、名古屋地域の 8 交差点で長時間の観察により求められている論文中のパラメータを用いる。clearing profile は、提案モデルにおける out-flow プロファイルと同等のものとみなし、同じ k^o および実車両の横断歩道を通過し切った時点での速度/加速度を与えることで決定する。また、歩行者情報としては、カルマンフィルターによって位置および速度の推定結果を与える。つまり、歩行者の意思という状態を考慮せず、TTC(time-to-conflict) が歩行者の状態に対する評価指標となっている。

図 3.9 および図 3.10 は、1 シーンに対するシミュレーション結果の複数時刻にわたる図示である。黄色い丸、黒い丸でそれぞれシミュレーションされた車両、実車両を示すとともに、前章の歩行者モデルでのフィルタリングされた歩行者情報も示されている。便宜上各歩行者の左に固有の番号を振っており、また速度の大きさおよび向きを歩行者記号から伸びる線で表している。

図 3.9(a):

シミュレーション開始直後であり、実車両と同じ初期値を与えているためシミュレーションと実車両に差はない(重なって描画されている)。この時点で target 歩行者を far-side の歩行者 7 としており、この歩行者 7 の自車両軌道通過後に自らが横断歩道を通過するプランニングを行っていることを意味する。この時点では、hard-yield プロファイルが選択されていた。また、ここでは、歩行者 0,1 および 2 が *wait* と認識されている。後の図からもわかるように歩行者 0,1 は横断歩行者であるが、目視の観測では、この時点では歩行者 0 は減速して横断を諦めるような行動をとっていた。PFG 開始からすでに 7 秒経過している。その歩行者 0 を後ろから横断意思を持った歩行者 1 が抜かし、それにつられて歩行者 0 も横断を再度開始するというシーンである。歩行者 1 に関しては提案システムの誤認識であるが、歩行者 0 は目視の観測に沿った認識をしていたように見える。

図 3.9(b)

開始から 3 秒経ち PR となり、歩行者 0 および 1 の横断意思を正しく認識している。また、far-side の歩行者 6 および 7 が走り始めており、それを識別している。この時点で soft-yield プロファイルに切り替わっており、これは歩行者 7 が走り始めたことによって、予測される到来時間が早くなったためと考えられる。

図 3.9(c), 3.9(d), 3.10(a)

歩行者 7 を target 歩行者と設定し、減速しながら横断歩道にアプローチしている。ここで、本来ならば位置および速度から到達時間は最後となり、target 歩行者となると考えられる歩行者 0 であるが、その *wait* 意思が認識されているため、gap acceptance および potential gap 探索から除外されている。

図 3.10(b), 3.10(c)

そして、歩行者 7 をはじめとしてすべての歩行者が自車両前を通過した後に、横断歩道を通過している。

図 3.13 は、実車両およびシミュレーションされた速度の推移である。ただし、図 3.9, 3.10 で描画した時刻を黒点線で示している。図より開始直後には実車両の方が強い減速を行って速度を落として横断歩道にアプローチしていることがわかるが、およそ同タイミングで加速を始め、横断歩道を通過している。

次に、図 3.11 および図 3.12 に、同シーンにおける Alhajyaseen のモデルによるシミュレーション結果を示す。ただし、歩行者の状態推定にカルマンフィルタを用いたこの比較手法では、横断意思やモーションは認識できないため、図 3.9, 3.10 のような歩行者の色付けは行って

いない。

図 3.11(a)～3.11(d)

自転車軌道付近に通過可能な gap はなく、提案モデルと同様な形で横断歩道にアプローチしている。ただし、横断歩道手前で停止するための hard-yield プロファイルに従っている。

図 3.12(a)

速度推移をプロットした図 3.13 とともに見ると、提案モデルはこの時点で加速しはじめているに対し、減速を続けている。これは、横断意思のない歩行者 2 を gap acceptance の対象に含めて、歩行者 7 と歩行者 2 間の gap を reject してしまうためである。

図 3.12(b)

引き続き歩行者 7 と歩行者 2 の間の gap を accept できずに、停止した。

図 3.12(c), 3.12(d)

歩行者 2 の速度が十分に小さくなったことで、通過可能なことを認識し、加速/通過を開始している。

このように、歩行者の距離と速度のみから状況を評価するがゆえに、Alhajyaseen モデルでは不必要な停止が生まれてしまった。逆に提案モデルでは、人間のドライバーが行っていると考えられるように、歩道上の歩行者の横断意思を評価することで、実際の運転行動に近いモーションをプランニングできたと言える。

ただし、図 3.13 を見ると実際のドライバーは 2 つのモデル (hard-yield プロファイル) よりも交差点進入時に強い減速を行った後、速度を調整して gap を通過している。このような運転行動は、soft-yield の際によく見られるが、提案モデルではこれを説明できるモデルはなく、今後の課題である。

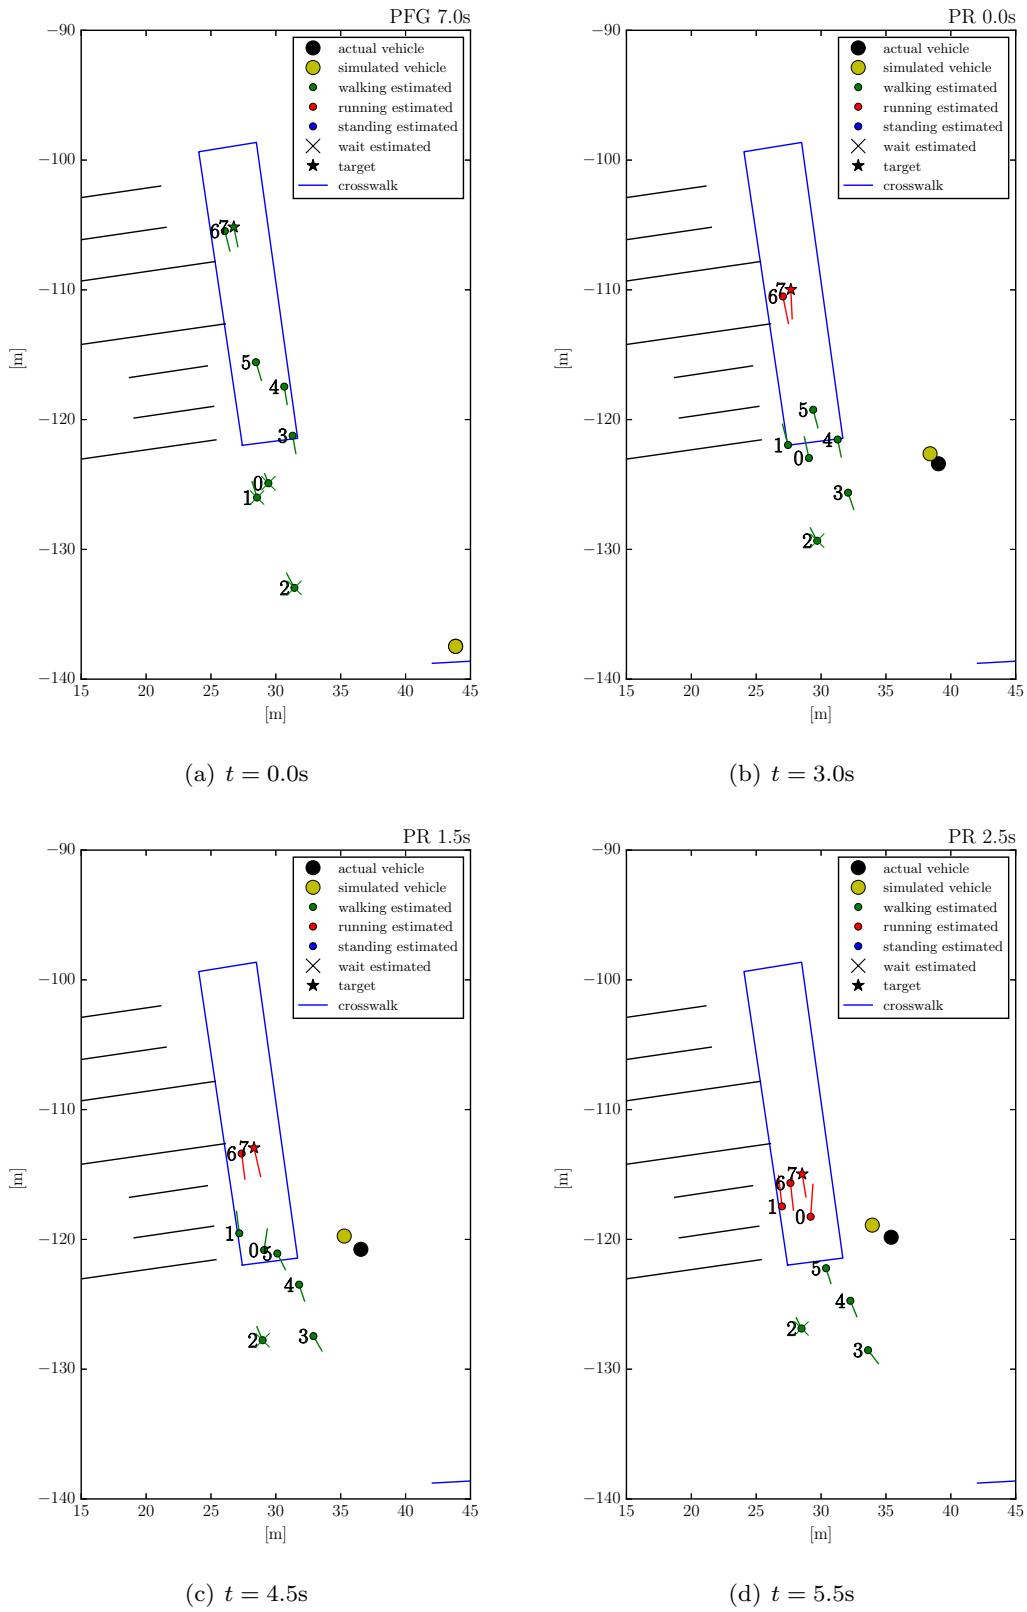


図 3.9. 提案モデルによるシミュレーション

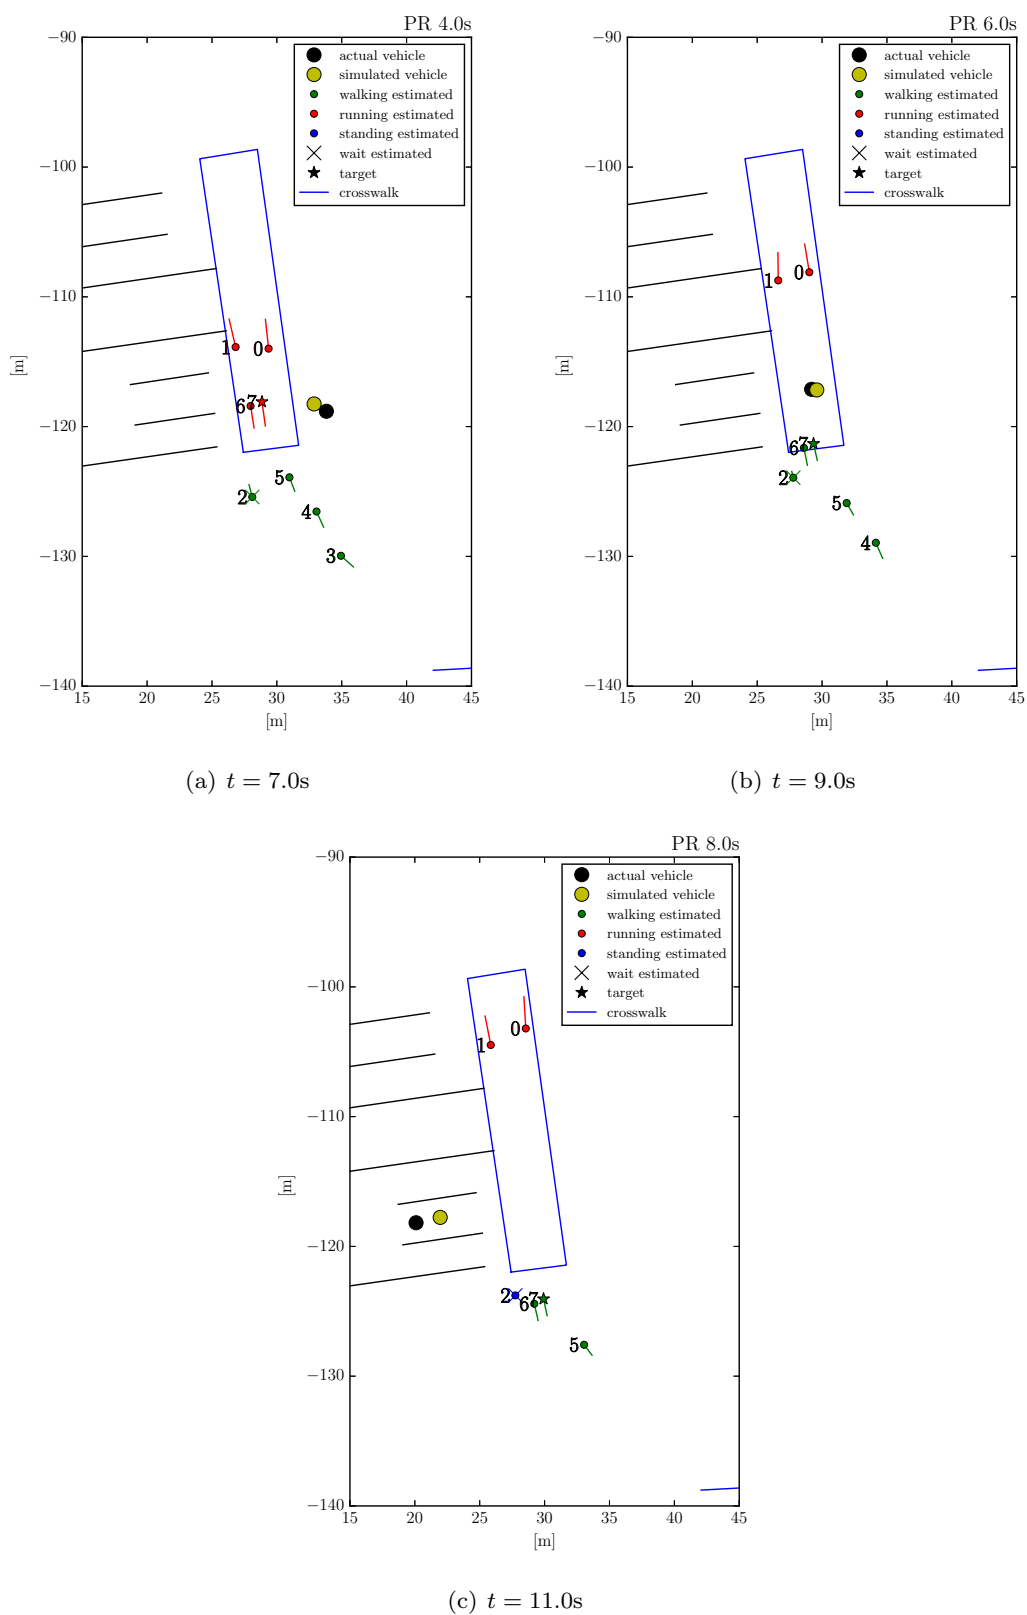


図 3.10. 提案モデルによるシミュレーション

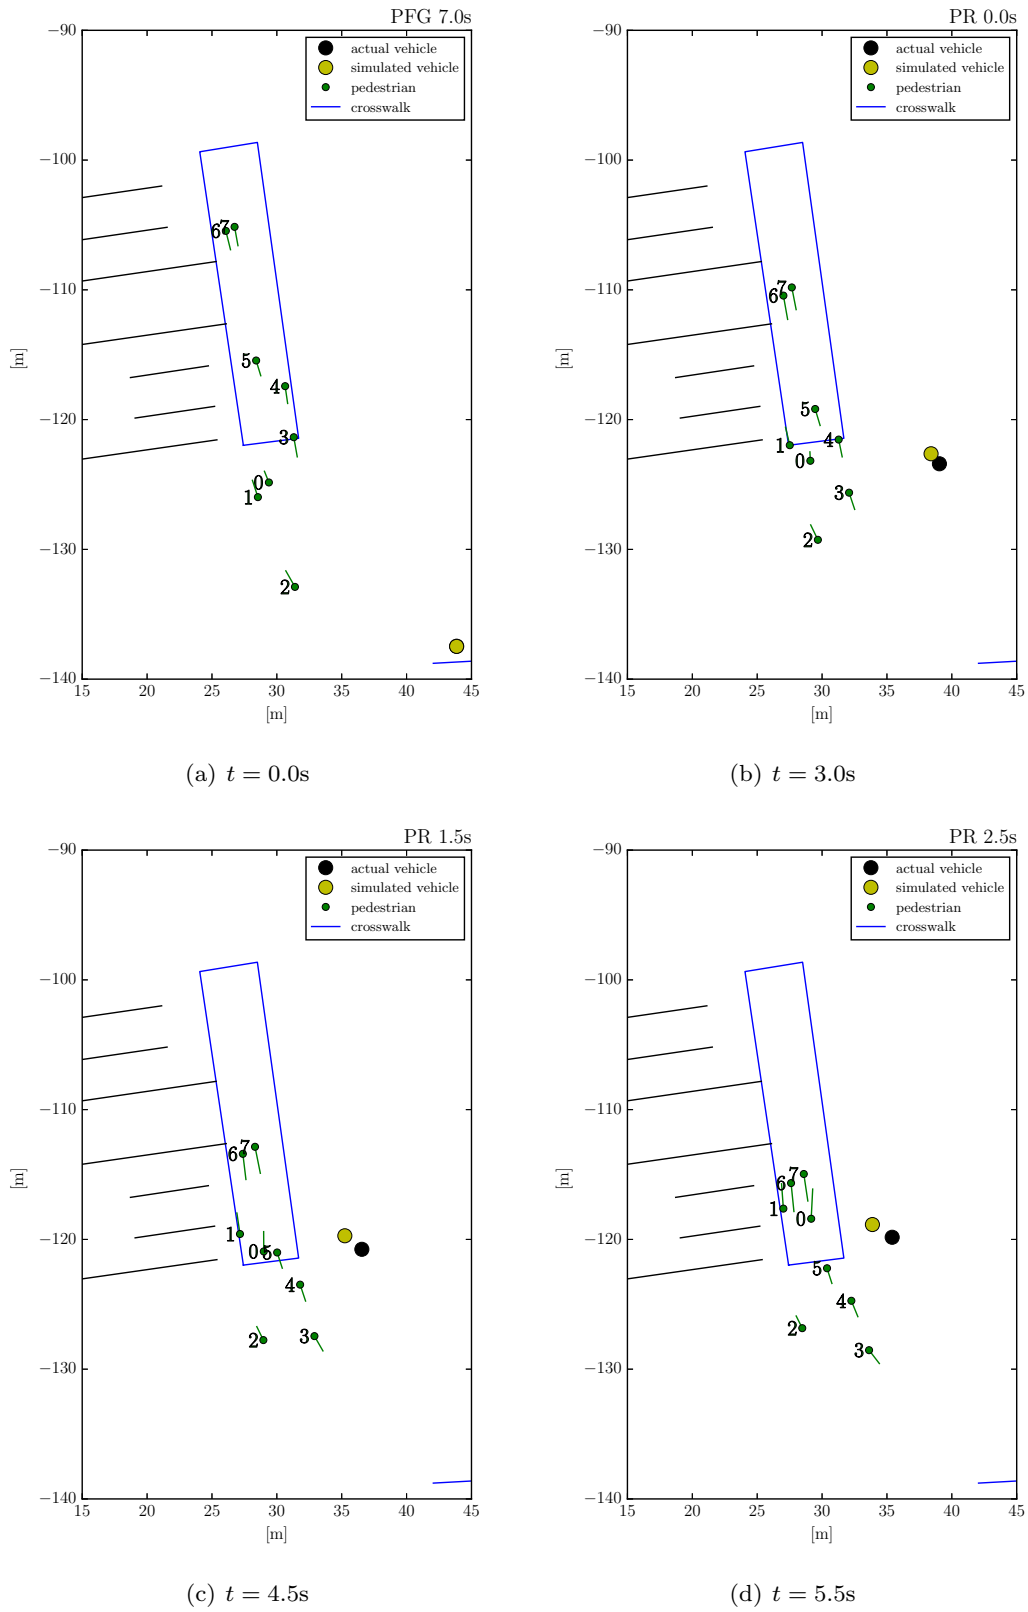


図 3.11. Alhajyaseen モデルによるシミュレーション

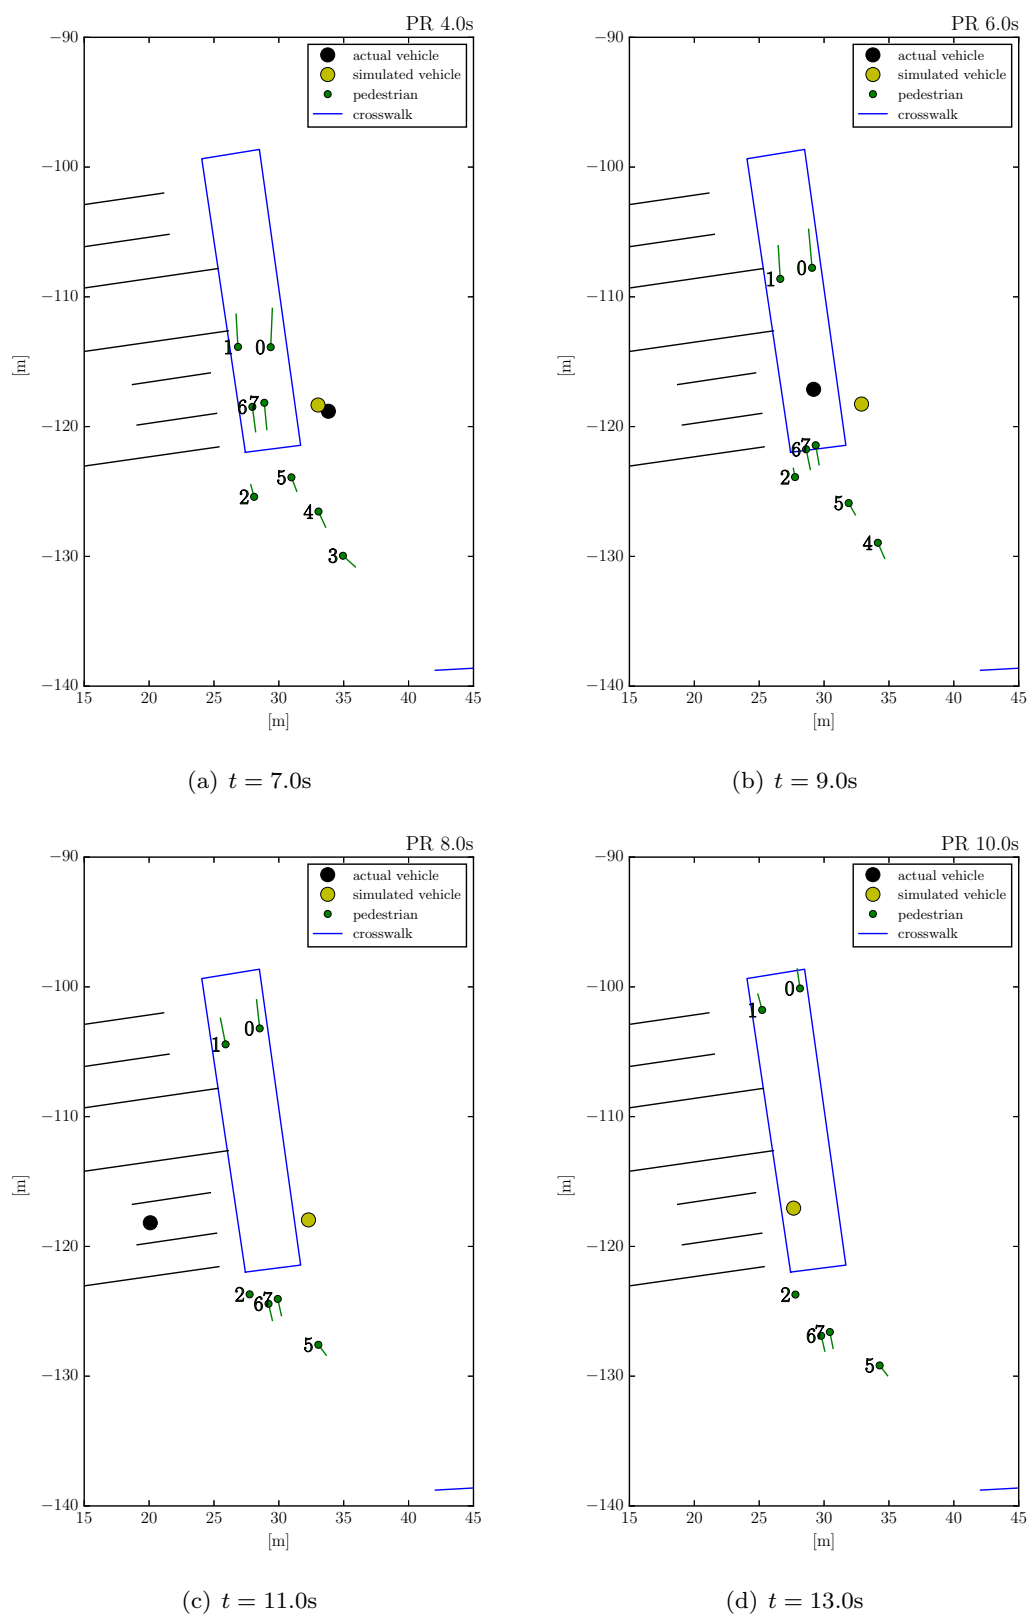


図 3.12. Alhajyaseen モデルによるシミュレーション




図 3.13. シミュレーションと実車両の速度

3.5 車載システムによる評価実験

前節では、実交通シーンのデータを元にしたシミュレーションによって、提案手法が人間ドライバーに近い自律走行を可能にすることを示した。実用性の検証には、シミュレーションという理想的な環境を離れる必要があるが、現在実交通環境において自律走行を実験することは困難である。しかし、運転行動を学習したモデルは、自動運転のみならず安全運転支援においても有効であると考えられる。例えば、ドライバーの危険な運転行動に対して警報を発したり、歩行者群と対する場合で適切な gap を指示したりすることは可能である。本節では、車載の運転システムを仮定し、実際の車載センサで得られるデータから、提案手法が実用的に人間ドライバーの意思決定を補助することが可能であることを定性的に検証する。

3.5.1 実験データ

提案システムの実用性の簡単な検証のために、車載システムを用いたデータ収集を行った。固定カメラを用いて行った図 3.6 の東京新宿の交差点で、西向き左折を複数回行い、自車両運転データおよび歩行者を収集した。車両には左右のサイドミラーおよびフロントウィンドウに計 3 台の単眼カメラを設置し、ジャイロセンサおよび CAN センサを搭載している。

今回の実験においては極端なセンシングエラーによって、モデルの評価ができなくなること避けるために、半自動的なセンシングを行う。自己位置推定では、交差点前の停止線のような特定の位置において、手動でグローバルな位置を決定し、そこを開始点としてジャイロセンサから得られる回転角および CAN データから得られる車速情報を用いて、位置および進行方向を推定する。ただし、このような加算的な計測法は時間の経過とともに誤差が蓄積し得ることに注意する。

また、歩行者はカメラを用いて観測する。各画像において歩行者領域を、一般的な歩行者検出器と同様な形で、手動で矩形に指定し、その下辺中央を歩行者の接地点とする。これを、カメラの地面および車両に対する姿勢のパラメータを元に車両を基準とした座標系に変換する。さらに自己位置推定で求められた車両位置/姿勢を用いて、グローバルな座標系に変換する。ここでは、カメラの地面に対する姿勢が変化しないものとしているが、実際には車両走行中の車両の傾き等によって変化し、位置推定も悪化し得ることに注意する必要がある。

3.5.2 システム作動例

本項で、提案するモーションプランニングモデルが、運転支援システムとしてドライバーの意思決定を助け得ることを、二つの左折ケースを紹介して検討する。

図 3.14~3.18^{*3}は、車両が停止することなく、歩行者間 gap を通過していく soft-yield シーンである。それぞれの図のセットにおいて、(a)3 台のカメラ画像を並べたもの、(b) 車両を基

^{*3} 図中歩行者顔面部はプライバシーの観点から隠している。当研究は本学の倫理委員会に許諾されている。

準とした座標系としてカメラ画像を鳥瞰図に変換したもの、(c) 車両のグローバル座標系での自己位置推定および歩行者行動認識システムによってフィルタリング結果、を表している。以下に簡単な説明を加える。

図 3.14

車両が左折を開始し、横断歩道へと近づいてくる場面である。便宜上、この時刻を時間の原点とする。ここでは左カメラで歩行者 0 が捉えられており、黄色の ROI をつけている。これは提案システムが、potential gap の探索によって、歩行者 0 を target pedestrian としていることを示す。つまり、システムがこのまま横断歩道に接近すれば、歩行者 0 の直後に通過できると考えている。

図 3.15

観測されている歩行者が 3 人に増えている。Target 歩行者が歩行者 2 へ移行しており、歩行者 0-1 間や 0-2 間、1-2 間の gap は通過できないと判断されていることが示されている。車両の自車位置推定の誤差によって歩行者のグローバル座標に対する位置推定が全体的にシフトしていることがわかる。

図 3.16

Far-side にさらに on-coming 歩行者が観測され始めたが、target 歩行者は歩行者 2 のままである。青矩形は、その歩行者の前に通過できる可能性が高いとシステムが評価していることを示す。

図 3.17

歩行者 2 が自車両のコンフリクト領域に進入し、歩行者 2-3 間の gap が accept された瞬間である。赤矩形は、システムがこの歩行者の直後に通過することを提案していることを表す。

図 3.18

図 3.17 に続き、この時刻にシステムが歩行者とのマージンを残しつつ、out-flow プロファイルに移れるということを示した。実際にこのおよそ 1 秒前にドライバーが加速を始めていた。

このように各時刻で今後通過可能でありそうな gap の存在を示すとともに、最終的に適した gap および加速を開始すべきタイミングを提示することが可能である。

図 3.19～3.23 は、車両が停止して歩行者間 gap 探し、通過していく hard-yield シーンである。以下に簡単な説明を加える。

図 3.19

横断歩道アプローチ時、既にたくさんの歩行者が横断歩道上にいる。この時刻を時間の原点として表記する。

図 3.20

歩行者 5 を target 歩行者としており、既に横断歩道を半分わたり終えている。

図 3.21

図 3.20 に続けて、far-side から歩行者 7 が接近してきたため、target 歩行者を 7 へと変更している。


図 3.22

システムが target 歩行者を 7 としている、つまり歩行者 7 の通過を待つという評価に反して、この時刻にドライバーは加速および横断歩道の通過を始めた。


このケースでは、実際のドライバーとは異なる意思決定を行っている。しかしながら、図 3.23 を見ると、通過時に歩行者がかなり近くまで迫っていたことがわかる。また、この時のドライバーも自身が少し危険を感じたと言っており、接触は起こさなかったものの、必ずしも正しい gap 選択ではなかったといえる。このような形で、提案システムは危険と考えられる運転行動に対して、警告等の反応を示せることがわかる。



(a)



(b)




(c)


図 3.14. Soft-yield ケース; $t = 0.0\text{s}$



(a)



(b)



(c)

図 3.15. Soft-yield ケース; $t = 3.1s$









図 3.16. Soft-yield ケース; $t = 4.8s$



(a)





(b)



(c)

図 3.17. Soft-yield ケース; $t = 6.5s$



(b)







図 3.18. Soft-yield ケース; $t = 8.7s$



(a)




(b)




(c)


図 3.19. Hard-yield ケース; $t = 0.0s$



(a)



(b)




(c)


図 3.20. Hard-yield ケース: $t = 7.6s$



(a)




(b)




(c)


図 3.21. Hard-yield ケース: $t = 11.2s$



(a)



(b)




(c)


図 3.22. Hard-yield ケース: $t = 13.3s$



(a)



(b)



(c)

図 3.23. Hard-yield ケース: $t = 16.9\text{s}$

3.6 結論

本章では、信号交差点左折時における運転行動の学習、およびそれに基づくモーションプランニング手法の提案を行った。交差点は自動車と歩行者の軌道がコンフリクトする主要な領域であり、yield や gap acceptance という歩行者も交えた複雑な行動が起こる。必然的に交通密度が高くなる領域でもあり、こうした状況における自律走行において、他者を惑わさない、人間の目から見て自然な行動は必須である。そのため、まず人間ドライバーの運転行動の学習を行った。

提案手法では一連の左折行動をいくつかのサブモデルに分けた。そのうちの gap acceptance のような行動は交通工学で統計的に解析されてきたものであるが、実際に人間の行動を学習し、それを再現する自律システムとして機能し得ることを期待した。また、前章で提案した歩行者行動モデルとの接続により、人間の行うような高次な状況判断を行う。

実交通シーンのデータを元にしたシミュレーションでは、提案するモーションプランニング手法によって一般的なドライバー行動が再現されることを示した。また、前章の提案モデルによって歩行者の横断意思を考慮することで、TTC(Time-to-collision) やそれに類する歩行者状態の評価指標に比べて、自律走行を改善し得ることを考察した。そして、提案モデルが自律走行のみならず、運転支援システムとして、ドライバーの意思決定を補助することも可能であることを、車載のセンサシステムに適用することで示した。

今回の運転モデルでは左折車の先頭車のみを扱ったが、右折車や後続車も今後検討にいれることを展望している。ただし、右折車に関しては、対抗レーンの直進車に対する gap acceptance も絡んだ事象となる。

第 4 章

結論と今後の課題

4.1 本研究のまとめ

本論文では、信号交差点における歩行者行動のモデル化ならびにそれと運転行動の学習に基づく自律走行のためのモーションプランニング手法の提案を行った。

まず、歩行者行動モデルは、交通シーン、特に信号交差点における歩行者が、信号の状態や横断歩道との位置関係や右左折待機車などの文脈 (コンテキスト) に基づき、自らの意思/行動を決定しているとし、そうした関連性を確率的に記述するものである。つまり、歩行者は状況・コンテキストを評価しながら意思決定を行い、それによって物理的な運動を伴うと考え、この一連の流れをダイナミックベイジアンネットワークを用いて確率モデル化した。このダイナミックベイジアンネットワークは、観測値位置や信号情報などを与えて、粒子フィルタを用いることで、横断意思やモーションといった非観測状態をオンラインに推定するシステムとなる。

本稿では、実際の交通シーンにおいて 1000 人分近くのデータを集め、この歩行者横断行動モデルの学習およびフィルタリングシステムの検証を行った。そして、車道に進入してくるまでおよそ 2, 3 秒以上かかる位置にいる歩行者の横断意思を高い精度で認識した。

運転行動のモデル化では、歩行者のインタラクションを含む複雑な左折行動に対し、実際の運転データの解析をもとにいくつかのサブモデルを仮定し、交通工学での統計学的見地も有効に用いつつ、学習を行った。そして、この運転行動の学習および歩行者行動モデルによって、信号交差点におけるモーションプランニング手法を構築した。これにより、実交通シーンのデータを用いたシミュレーションにおいて、人間ドライバーに近い運転行動を再現できた。また、歩行者の横断意思という高次元な情報を認識する歩行者モデルとの融合が、より自然な自律走行へとつながり得ることを示した。

4.2 今後の課題

今回提案した歩行者モデルは、コンテキストや意思に応じた自然な行動パターンを記述するものであるが、そうした尤もらしいパターンに合わない行動をする歩行者に対しては位置のよ

うな低次の状態の推定まで悪化してしまう傾向にあった。特に横断か待機かの識別を誤ってしまうことはシステムの信頼度を下げ、最悪の場合事故を招いてしまう。コンテキストと観測値の適応的な重み付け等を今後検討していく必要がある。

また、横断意思は PFG 時の開始時に決定され、それ以降は変更されないという仮定を置いているが、実際のデータを観察すると動的に変化していると考えられるケースも少なからず存在する。これは意思という実際には観測できない状態量を取り扱っているゆえであるが、意思の変化は挙動の変化に現れると考えられるはずであり、そうした変化点およびその要因の解析は今後の課題である。また、右左折車の有無を変数として扱っているが、右左折車の無理な突っ込みによって生じる減速など、強い意味でのインタラクションは考慮されておらず、今後も解析が必要である。ただし、こうした頻度のあまり多くない現象は、解析データを集めることの難しさが伴う。

3.4.3 項では、歩行者の横断意思の認識によって、より自然な運転行動を再現できた例を示した。しかしながら今回の提案手法では、横断か待機かという 2 値の認識結果によって、歩行者を考慮の対象から外すというシンプルな手法となっている。今後システムの出力する横断/待機の確率も考慮して、より高度なレベルで歩行者モデルとの接続を行う必要がある。また、横断意思は横断歩道周辺における歩行者行動に対する最も高次の情報であると考えられるため、そこが最も重要な点であるが、例えば歩行者が駆け出す確率が高い状況などを確率モデルとして有しており、そうした知識の活用を検討したい。

運転行動のモデル化に関しては、soft-yield の速度調整のような、現在のモデルでは説明し切れないドライバーの運転行動があり、今後さらに深い解析が必要となっている。

謝辞

本研究を進めるにあたり、指導教員として多大なご指導を頂きました上條俊介准教授に深く感謝いたします。研究の指針を与えてくださるとともに、多忙な中、ディスカッションにお付き合いいただき、そして的確な助言をくださいました。有難うございます。

秘書の三輪祐子さんには、様々な事務手続きなどによって研究生活を支えていただきました。有難うございました。

研究員の古艶磊さんには、日々細かいディスカッションに付き合ってください有難うございました。研究者としてのお手本のような姿勢は大変勉強になりました。同じく研究員の許立達さんからも研究のみならず日々たくさんのことを学ばせていただきました。常に研究室の雰囲気明るくしてくださっていることにも非常に感謝しております。

同期の和田雄太郎君および黄宇陽君から常にたくさんの刺激を受け、研究へのモチベーションを高めてくれました。同時に、普段の些細な雑談も研究室生活には欠かせないものでした。二人の同期で本当に良かったと思っています。深く感謝しています。

また、その他の研究室のメンバーからもたくさんの刺激をもらいました。この国際色豊かな研究室に入って、自分の意識が変わったのは間違いありません。また、実験にも度々付き合ってください有難うございました。

共同研究では STARC のみなさまに大変お世話になりました。毎回、的確なコメントや鋭い質問をいただき、実ある研究報告会でした。有難うございました。

最後に、日々研究生活を支えてくださったすべての方に感謝いたします。

2016 年 2 月 4 日

発表文献

国際学会

- [1] Yoriyoshi Hashimoto, Yanlei Gu, Li-Ta Hsu and Shunsuke Kamijo, “A Probabilistic Model for the Estimation of Pedestrian Crossing Behavior at Signalized Intersections,” IEEE 18th International Conference on Intelligent Transportation Systems (ITSC), September 2015
- [2] Yoriyoshi Hashimoto, Yanlei Gu, Li-Ta Hsu and Shunsuke Kamijo, “Probability Estimation for Pedestrian Crossing Intention at Signalized Crosswalks,” IEEE International Conference on Vehicular Electronics and Safety (ICVES), November 2015

論文誌

- [3] Yoriyoshi Hashimoto, Yanlei Gu, Li-Ta Hsu Miho Iryo-Asano and Shunsuke Kamijo, “A Probabilistic Model of Pedestrian Crossing Behavior at Signalized Intersections for Connected Vehicles,” Transportation Research Part C Special Issue (Under 2nd review)

参考文献

- [1] M. Iryo-Asano, W.K.M. Alhajyaseen, and H. Nakamura. Analysis and modeling of pedestrian crossing behavior during the pedestrian flashing green interval. *IEEE Transactions on Intelligent Transportation Systems*, Vol. 16, No. 2, pp. 958–969, 2015.
- [2] National Highway Traffic Safety Administration (USA). A brief statistical summary: Critical reasons for crashes investigated in the national motor vehicle crash causation survey, 2015. <http://www-nrd.nhtsa.dot.gov/pubs/812115.pdf>.
- [3] I. Skog and P. Handel. In-car positioning and navigation technologies - a survey. *Intelligent Transportation Systems, IEEE Transactions on*, Vol. 10, No. 1, pp. 4–21, March 2009.
- [4] Youjing Cui and Shuzhi Sam Ge. Autonomous vehicle positioning with GPS in urban canyon environments. *Robotics and Automation, IEEE Transactions on*, Vol. 19, No. 1, pp. 15–25, Feb 2003.
- [5] O. Pink, F. Moosmann, and A. Bachmann. Visual features for vehicle localization and ego-motion estimation. In *Intelligent Vehicles Symposium, 2009 IEEE*, pp. 254–260, June 2009.
- [6] M.W.M.G. Dissanayake, P. Newman, S. Clark, H.F. Durrant-Whyte, and M. Csorba. A solution to the simultaneous localization and map building (SLAM) problem. *Robotics and Automation, IEEE Transactions on*, Vol. 17, No. 3, pp. 229–241, Jun 2001.
- [7] K. Shunsuke, G. Yanlei, and Li-Ta Hsu. GNSS/INS/On-board camera integration for vehicle self-localization in urban canyon. In *Intelligent Transportation Systems (ITSC), 2015 IEEE 18th International Conference on*, pp. 2533–2538, Sept 2015.
- [8] T. Gandhi and M.M. Trivedi. Pedestrian protection systems: Issues, survey, and challenges. *Intelligent Transportation Systems, IEEE Transactions on*, Vol. 8, No. 3, pp. 413–430, Sept 2007.
- [9] Zehang Sun, G. Bebis, and R. Miller. On-road vehicle detection: a review. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, Vol. 28, No. 5, pp. 694–711, May 2006.

- [10] Yinghua He, Hong Wang, and Bo Zhang. Color-based road detection in urban traffic scenes. *Intelligent Transportation Systems, IEEE Transactions on*, Vol. 5, No. 4, pp. 309–318, Dec 2004.
- [11] J.C. McCall and M.M. Trivedi. Video-based lane estimation and tracking for driver assistance: survey, system, and evaluation. *Intelligent Transportation Systems, IEEE Transactions on*, Vol. 7, No. 1, pp. 20–37, March 2006.
- [12] A. de la Escalera, L.E. Moreno, M.A. Salichs, and J.M. Armingol. Road traffic sign detection and classification. *Industrial Electronics, IEEE Transactions on*, Vol. 44, No. 6, pp. 848–859, Dec 1997.
- [13] R. de Charette and F. Nashashibi. Real time visual traffic lights recognition based on spot light detection and adaptive traffic lights templates. In *Intelligent Vehicles Symposium, 2009 IEEE*, pp. 358–363, June 2009.
- [14] L. Hobert, A. Festag, I. Llatser, L. Altomare, F. Visintainer, and A. Kovacs. Enhancements of V2X communication in support of cooperative autonomous driving. *Communications Magazine, IEEE*, Vol. 53, No. 12, pp. 64–70, Dec 2015.
- [15] G. De Nicolao, A. Ferrara, and L. Giacomini. Onboard sensor-based collision risk assessment to improve pedestrians’ safety. *Vehicular Technology, IEEE Transactions on*, Vol. 56, No. 5, pp. 2405–2413, Sept 2007.
- [16] A. Polychronopoulos, M. Tsogas, A.J. Amditis, and L. Andreone. Sensor fusion for predicting vehicles’ path for collision avoidance systems. *Intelligent Transportation Systems, IEEE Transactions on*, Vol. 8, No. 3, pp. 549–562, Sept 2007.
- [17] S. Lefevre, C. Laugier, and J. Ibanez-Guzman. Risk assessment at road intersections: Comparing intention and expectation. In *Intelligent Vehicles Symposium (IV), 2012 IEEE*, pp. 165–171, June 2012.
- [18] Dave Ferguson, Thomas M Howard, and Maxim Likhachev. Motion planning in urban environments. *Journal of Field Robotics*, Vol. 25, No. 11-12, pp. 939–960, 2008.
- [19] Y. Kuwata, S. Karaman, J. Teo, E. Frazzoli, J.P. How, and G. Fiore. Real-time motion planning with applications to autonomous urban driving. *Control Systems Technology, IEEE Transactions on*, Vol. 17, No. 5, pp. 1105–1118, Sept 2009.
- [20] S. Eilers, J. Boger, and M. Franzle. A path planning framework for autonomous vehicles. In *Robot Motion and Control (RoMoCo), 2013 9th Workshop on*, pp. 203–208, July 2013.
- [21] A. Reschka, J.R. Bohmer, F. Saust, B. Lichte, and M. Maurer. Safe, dynamic and comfortable longitudinal control for an autonomous vehicle. In *Intelligent Vehicles Symposium (IV), 2012 IEEE*, pp. 346–351, June 2012.
- [22] National Highway Traffic Safety Administration (USA). Preliminary statement of policy concerning automated vehicles, 2013. <http://www.nhtsa.gov/>

- staticfiles/rulemaking/pdf/Automated_Vehicles_Policy.pdf.
- [23] 警視庁 (日本). 歩行者の交通人身事故発生状況～平成 27 年上半期～, 2015. http://www.keishicho.metro.tokyo.jp/toukei/jiko/data/jiko_hoko.pdf.
 - [24] M. Enzweiler and D.M. Gavrilă. Monocular pedestrian detection: Survey and experiments. *IEEE Transactions on Pattern Analysis and Machine Intelligence (PAMI)*, Vol. 31, No. 12, pp. 2179–2195, 2009.
 - [25] D. Geronimo, A.M. Lopez, A.D. Sappa, and T. Graf. Survey of pedestrian detection for advanced driver assistance systems. *IEEE Transactions on Pattern Analysis and Machine Intelligence (PAMI)*, Vol. 32, No. 7, pp. 1239–1258, 2010.
 - [26] P. Dollar, C. Wojek, B. Schiele, and P. Perona. Pedestrian detection: An evaluation of the state of the art. *IEEE Transactions on Pattern Analysis and Machine Intelligence (PAMI)*, Vol. 34, No. 4, pp. 743–761, 2012.
 - [27] N. Dalal and B. Triggs. Histograms of oriented gradients for human detection. In *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Vol. 1, pp. 886–893, 2005.
 - [28] P.F. Felzenszwalb, R.B. Girshick, D. McAllester, and D. Ramanan. Object detection with discriminatively trained part-based models. *IEEE Transactions on Pattern Analysis and Machine Intelligence (PAMI)*, Vol. 32, No. 9, pp. 1627–1645, 2010.
 - [29] Tomoki Watanabe, Satoshi Ito, and Kentaro Yokoi. Co-occurrence histograms of oriented gradients for pedestrian detection. In *Advances in Image and Video Technology*, Vol. 5414 of *Lecture Notes in Computer Science*, pp. 37–47. Springer Berlin Heidelberg, 2009.
 - [30] Yaakov Bar-Shalom, X Rong Li, and Thiagalingam Kirubarajan. *Estimation with applications to tracking and navigation: theory algorithms and software*. Wiley, 2001.
 - [31] E. Binelli, A. Broggi, A. Fascioli, S. Ghidoni, P. Grisleri, T. Graf, and M. Meinelcke. A modular tracking system for far infrared pedestrian recognition. In *IEEE Intelligent Vehicles Symposium (IV)*, pp. 759–764, 2005.
 - [32] M. Bertozzi, A. Broggi, A. Fascioli, A. Tibaldi, R. Chapuis, and F. Chausse. Pedestrian localization and tracking system with kalman filtering. In *IEEE Intelligent Vehicles Symposium (IV)*, pp. 584–589, 2004.
 - [33] I.P. Alonso, D.F. Llorca, M.A. Sotelo, L.M. Bergasa, P. Revenga de Toro, J. Nuevo, M. Ocana, and M.A.G. Garrido. Combination of feature extraction methods for svm pedestrian detection. *IEEE Transactions on Intelligent Transportation Systems*, Vol. 8, No. 2, pp. 292–307, 2007.
 - [34] M. Meuter, U. Iurgel, Su-Birm Park, and A. Kummert. The unscented kalman filter for pedestrian tracking from a moving host. In *IEEE Intelligent Vehicles Symposium (IV)*, pp. 37–42, 2008.

- [35] Tao Junli and Klette Reinhard. Tracking of 2d or 3d irregular movement by a family of unscented kalman filters. *Journal of information and communication convergence engineering*, Vol. 10, No. 3, pp. 307–314, 2012.
- [36] X.R. Li and V.P. Jilkov. Survey of maneuvering target tracking. Part V. Multiple-model methods. *Aerospace and Electronic Systems, IEEE Transactions on*, Vol. 41, No. 4, pp. 1255–1321, Oct 2005.
- [37] Nicolas Schneider and DariuM. Gavrilă. Pedestrian path prediction with recursive bayesian filters: A comparative study. In *Pattern Recognition*, Vol. 8142 of *Lecture Notes in Computer Science*, pp. 174–183. Springer Berlin Heidelberg, 2013.
- [38] C.G. Keller and D.M. Gavrilă. Will the pedestrian cross? A study on pedestrian path prediction. *IEEE Transactions on Intelligent Transportation Systems*, Vol. 15, No. 2, pp. 494–506, 2014.
- [39] Zhuo Chen, D.C.K. Ngai, and N.H.C. Yung. Pedestrian behavior prediction based on motion patterns for vehicle-to-pedestrian collision avoidance. In *Intelligent Transportation Systems, 2008. ITSC 2008. 11th International IEEE Conference on*, pp. 316–321, Oct 2008.
- [40] Zhuo Chen and N.H.C. Yung. Improved multi-level pedestrian behavior prediction based on matching with classified motion patterns. In *Intelligent Transportation Systems, 2009. ITSC '09. 12th International IEEE Conference on*, pp. 1–6, Oct 2009.
- [41] M. Goldhammer, M. Gerhard, S. Zernetsch, K. Doll, and U. Brunsmann. Early prediction of a pedestrian's trajectory at intersections. In *Intelligent Transportation Systems - (ITSC), 2013 16th International IEEE Conference on*, pp. 237–242, Oct 2013.
- [42] S. Schmidt, B. Frber. Pedestrians at the kerb - Recognising the action intentions of humans. *Transportation Research Part F: Traffic Psychology and Behaviour*, Vol. 12, No. 4, pp. 300–310, 2009.
- [43] S. Kohler, M. Goldhammer, S. Bauer, K. Doll, U. Brunsmann, and K. Dietmayer. Early detection of the pedestrian's intention to cross the street. In *Intelligent Transportation Systems (ITSC), 2012 15th International IEEE Conference on*, pp. 1759–1764, Sept 2012.
- [44] S. Kohler, B. Schreiner, S. Ronalter, K. Doll, U. Brunsmann, and K. Zindler. Autonomous evasive maneuvers triggered by infrastructure-based detection of pedestrian intentions. In *IEEE Intelligent Vehicles Symposium (IV)*, pp. 519–526, 2013.
- [45] S. Koehler, M. Goldhammer, S. Bauer, S. Zecha, K. Doll, U. Brunsmann, and K. Dietmayer. Stationary detection of the pedestrian's intention at intersections. *IEEE Intelligent Transportation Systems Magazine*, Vol. 5, No. 4, pp. 87–99, 2013.
- [46] Christopher J.C. Burges. A tutorial on support vector machines for pattern recog-

- dition. *Data Mining and Knowledge Discovery*, Vol. 2, No. 2, pp. 121–167, 1998.
- [47] S. Kohler, M. Goldhammer, K. Zindler, K. Doll, and K. Dietmeyer. Stereo-vision-based pedestrian’s intention detection in a moving vehicle. In *Intelligent Transportation Systems (ITSC), 2015 IEEE 18th International Conference on*, pp. 2317–2322, Sept 2015.
 - [48] Jack Wang, Aaron Hertzmann, and David M Blei. Gaussian process dynamical models. In *Advances in neural information processing systems*, pp. 1441–1448, 2005.
 - [49] Hedvig Sidenbladh, MichaelJ. Black, and Leonid Sigal. Implicit probabilistic models of human motion for synthesis and tracking. In *European Conference on Computer Vision (ECCV)*, Vol. 2350 of *Lecture Notes in Computer Science*, pp. 784–800. Springer Berlin Heidelberg, 2002.
 - [50] R. Quintero, J. Almeida, D.F. Llorca, and M.A. Sotelo. Pedestrian path prediction using body language traits. In *IEEE Intelligent Vehicles Symposium (IV)*, pp. 317–323, 2014.
 - [51] Carnegie Mellon University. Cmu graphics lab motion capture database. <http://mocap.cs.cmu.edu/>.
 - [52] A. Geiger, P. Lenz, and R. Urtasun. Are we ready for Autonomous Driving ? The KITTI Vision Benchmark Suite. In *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 3354–3361, 2012.
 - [53] R. Quintero, I. Parra, D.F. Llorca, and M.A. Sotelo. Pedestrian path prediction based on body language and action classification. In *17th IEEE International Conference on Intelligent Transportation Systems (ITSC)*, pp. 679–684, 2014.
 - [54] R. Quintero, I. Parra, D.F. Llorca, and M.A. Sotelo. Pedestrian intention and pose prediction through dynamical models and behaviour classification. In *Intelligent Transportation Systems (ITSC), 2015 IEEE 18th International Conference on*, pp. 83–88, Sept 2015.
 - [55] JulianFranciscoPieter Kooij, Nicolas Schneider, Fabian Flohr, and DariusM. Gavrilu. Context-based pedestrian path prediction. In *European Conference on Computer Vision (ECCV)*, Vol. 8694 of *Lecture Notes in Computer Science*, pp. 618–633. Springer International Publishing, 2014.
 - [56] J.F.P. Kooij, N. Schneider, and D.M. Gavrilu. Analysis of pedestrian dynamics from a vehicle perspective. In *IEEE Intelligent Vehicles Symposium (IV)*, pp. 1445–1450, 2014.
 - [57] A.T. Schulz and R. Stiefelhagen. Pedestrian intention recognition using latent-dynamic conditional random fields. In *Intelligent Vehicles Symposium (IV), 2015 IEEE*, pp. 622–627, June 2015.
 - [58] A.T. Schulz and R. Stiefelhagen. A controlled interactive multiple model filter for combined pedestrian intention recognition and path prediction. In *Intelligent*

- Transportation Systems (ITSC), 2015 IEEE 18th International Conference on*, pp. 173–178, Sept 2015.
- [59] John Lafferty, Andrew McCallum, and Fernando CN Pereira. Conditional random fields: Probabilistic models for segmenting and labeling sequence data. In *the 18th International Conference on Machine Learning (ICML)*, pp. 282–289, 2001.
 - [60] L. Morency, A. Quattoni, and T. Darrell. Latent-dynamic discriminative models for continuous gesture recognition. In *Computer Vision and Pattern Recognition, 2007. CVPR '07. IEEE Conference on*, pp. 1–8, June 2007.
 - [61] S. Bonnin, T.H. Weisswange, F. Kummert, and J. Schmuedderich. Pedestrian crossing prediction using multiple context-based models. In *17th IEEE International Conference on Intelligent Transportation Systems (ITSC)*, pp. 378–385, 2014.
 - [62] B. Volz, H. Mielenz, G. Agamennoni, and R. Siegwart. Feature relevance estimation for learning pedestrian behavior at crosswalks. In *Intelligent Transportation Systems (ITSC), 2015 IEEE 18th International Conference on*, pp. 854–860, Sept 2015.
 - [63] H. Hamaoka, T. Hagiwara, M. Tada, and K. Munehiro. A study on the behavior of pedestrians when confirming approach of right/left-turning vehicle while crossing a crosswalk. In *IEEE Intelligent Vehicles Symposium (IV)*, pp. 106–110, 2013.
 - [64] B. Raghuram Kadali and P. Vedagiri. Effect of vehicular lanes on pedestrian gap acceptance behaviour. *Procedia - Social and Behavioral Sciences*, Vol. 104, pp. 678 – 687, 2013. 2nd Conference of Transportation Research Group of India (2nd CTRG).
 - [65] B Raghuram Kadali and P Vedagiri. Modelling pedestrian road crossing behaviour under mixed traffic condition. *European transport*, Vol. 55, No. 3, pp. 1–17, 2013.
 - [66] Baibing Li. A model of pedestrians’ intended waiting times for street crossings at signalized intersections. *Transportation Research Part B: Methodological*, Vol. 51, pp. 17–28, 2013.
 - [67] Marisamynathan and Vedagiri Perumal. Study on pedestrian crossing behavior at signalized intersections. *Journal of Traffic and Transportation Engineering (English Edition)*, Vol. 1, No. 2, pp. 103–110, 2014.
 - [68] P.P. Koh and Y.D. Wong. Gap acceptance of violators at signalised pedestrian crossings. *Accident Analysis & Prevention*, Vol. 62, pp. 178–185, 2014.
 - [69] X. Zhang, P. Chen, H. Nakamura, and M. Asano. Modeling pedestrian walking speed at signalized crosswalks considering crosswalk length and signal timing. In *Proceedings of the Eastern Asia Society for Transportation Studies*, Vol. 9, 2013.
 - [70] 張馨, 中村英樹, 井料 (浅野) 美帆, 陳鵬. 横断歩道長と歩行者信号現示を考慮した横断歩行速度のモデル化. 土木学会論文集 D3 (土木計画学) , Vol. 70, No. 5, pp. 1031–1040, 2014.
 - [71] M. Iryo-Asano, W.K.M. Alhajyaseen, X. Zhang, and H. Nakamura. Analysis of pedestrian speed change behavior at signalized crosswalks. In *Road Safety & Simu-*

- lation International Conference, pp. 1606–1618, 2015.
- [72] Weiliang Zeng, Peng Chen, Hideki Nakamura, and Miho Iryo-Asano. Application of social force model to pedestrian behavior analysis at signalized crosswalk. *Transportation Research Part C: Emerging Technologies*, Vol. 40, pp. 143–159, 2014.
 - [73] Weiliang Zeng, Hideki Nakamura, and Peng Chen. A modified social force model for pedestrian behavior simulation at signalized crosswalks. *Procedia - Social and Behavioral Sciences*, Vol. 138, pp. 521 – 530, 2014. The 9th International Conference on Traffic and Transportation Studies (ICTTS 2014).
 - [74] C.B. Chang and M. Athans. State estimation for discrete systems with switching parameters. *Aerospace and Electronic Systems, IEEE Transactions on*, Vol. AES-14, No. 3, pp. 418–425, May 1978.
 - [75] Ryan R Pitre, Vesselin P Jilkov, and X Rong Li. A comparative study of multiple-model algorithms for maneuvering target tracking. In *Defense and Security*, pp. 549–560. International Society for Optics and Photonics, 2005.
 - [76] H.A.P. Blom. An efficient filter for abruptly changing systems. In *Decision and Control, 1984. The 23rd IEEE Conference on*, pp. 656–658, Dec 1984.
 - [77] G. Ackerson and K.S. Fu. On state estimation in switching environments. *Automatic Control, IEEE Transactions on*, Vol. 15, No. 1, pp. 10–17, Feb 1970.
 - [78] Thomas P Minka. Expectation propagation for approximate bayesian inference. In *Proceedings of the Seventeenth conference on Uncertainty in artificial intelligence*, pp. 362–369. Morgan Kaufmann Publishers Inc., 2001.
 - [79] Arnaud Doucet, Simon Godsill, and Christophe Andrieu. On sequential monte carlo sampling methods for bayesian filtering. *Statistics and Computing*, Vol. 10, No. 3, pp. 197–208, 2000.
 - [80] Christophe Andrieu, Nando de Freitas, Arnaud Doucet, and MichaelI. Jordan. An introduction to mcmc for machine learning. *Machine Learning*, Vol. 50, No. 1-2, pp. 5–43, 2003.
 - [81] Augustine Kong. A note on importance sampling using standardized weights. *Technical Report No. 348*, 1992.
 - [82] D. B. Rubin. Using the SIR algorithm to simulate posterior distributions. In M. H. Bernardo, K. M. DeGroot, D. V. Lindley, and A. F. M. Smith, editors, *Bayesian Statistics 3*. Oxford University Press, 1988.
 - [83] DonaldJ. Patterson, Lin Liao, Dieter Fox, and Henry Kautz. Inferring high-level behavior from low-level sensors. In *Ubiquitous Computing (UbiComp)*, Vol. 2864 of *Lecture Notes in Computer Science*, pp. 73–89. Springer Berlin Heidelberg, 2003.
 - [84] V. Mitra, Hosung Nam, C.Y. Espy-Wilson, E. Saltzman, and L. Goldstein. Gesture-based dynamic bayesian network for noise robust speech recognition. In *Acoustics, Speech and Signal Processing (ICASSP), 2011 IEEE International Conference on*,

- pp. 5172–5175, May 2011.
- [85] H.-I. Suk, Bong-Kee Sin, and Seong-Whan Lee. Robust modeling and recognition of hand gestures with dynamic bayesian network. In *Pattern Recognition, 2008. ICPR 2008. 19th International Conference on*, pp. 1–4, Dec 2008.
 - [86] Wenhui Liao, Weihong Zhang, Zhiwei Zhu, and Qiang Ji. A real-time human stress monitoring system using dynamic bayesian network. In *Computer Vision and Pattern Recognition - Workshops, 2005. CVPR Workshops. IEEE Computer Society Conference on*, pp. 70–70, June 2005.
 - [87] Chung-Lin Huang, Huang-Chia Shih, and Chung-Yuan Chao. Semantic analysis of soccer video using dynamic bayesian network. *Multimedia, IEEE Transactions on*, Vol. 8, No. 4, pp. 749–760, Aug 2006.
 - [88] S. Park and J.K. Aggarwal. Semantic-level understanding of human actions and interactions using event hierarchy. In *Computer Vision and Pattern Recognition Workshop, 2004. CVPRW '04. Conference on*, pp. 12–12, June 2004.
 - [89] Yingning Huang, Jinshi Cui, F. Davoine, Huijing Zhao, and Hongbin Zha. Head pose based intention prediction using discrete dynamic bayesian network. In *Distributed Smart Cameras (ICDSC), 2013 Seventh International Conference on*, pp. 1–6, Oct 2013.
 - [90] Hesham Rakha, Shereef Sadek, and Ismail Zohdy. Modeling differences in driver left-turn gap acceptance behavior using bayesian and bootstrap approaches. *Procedia - Social and Behavioral Sciences*, Vol. 16, pp. 739–750, 2011. 6th International Symposium on Highway Capacity and Quality of Service.
 - [91] 上田隆一, 新井民夫, 浅沼和範, 梅田和昇, 大隅久. パーティクルフィルタを利用した自己位置推定に生じる致命的な推定誤りからの回復法. 日本ロボット学会誌 = Journal of Robotics Society of Japan, Vol. 23, No. 4, pp. 466–473, may 2005.
 - [92] Stéphanie Lefèvre, Dizan Vasquez, and Christian Laugier. A survey on motion prediction and risk assessment for intelligent vehicles. *ROBOMECH Journal*, Vol. 1, No. 1, pp. 1–14, 2014.
 - [93] Chiu-Feng Lin and A.G. Ulsoy. Vehicle dynamics and external disturbance estimation for future vehicle path prediction. In *American Control Conference, Proceedings of the 1995*, Vol. 1, pp. 155–159 vol.1, Jun 1995.
 - [94] R. Schubert, E. Richter, and G. Wanielik. Comparison and evaluation of advanced motion models for vehicle tracking. In *Information Fusion, 2008 11th International Conference on*, pp. 1–6, June 2008.
 - [95] K. Driggs-Campbell and R. Bajcsy. Identifying modes of intent from driver behaviors in dynamic environments. In *Intelligent Transportation Systems (ITSC), 2015 IEEE 18th International Conference on*, pp. 739–744, Sept 2015.
 - [96] S.B. Amsalu, A. Homaifar, F. Afghah, S. Ramyar, and A. Kurt. Driver behavior

- modeling near intersections using support vector machines based on statistical feature extraction. In *Intelligent Vehicles Symposium (IV), 2015 IEEE*, pp. 1270–1275, June 2015.
- [97] T. Gindele, S. Brechtel, and R. Dillmann. A probabilistic model for estimating driver behaviors and vehicle trajectories in traffic environments. In *13th IEEE International Conference on Intelligent Transportation Systems (ITSC)*, pp. 1625–1631, 2010.
- [98] T. Gindele, S. Brechtel, and R. Dillmann. Learning context sensitive behavior models from observations for predicting traffic situations. In *Intelligent Transportation Systems - (ITSC), 2013 16th International IEEE Conference on*, pp. 1764–1771, Oct 2013.
- [99] M. Platho and J. Eggert. Deciding what to inspect first: Incremental situation assessment based on information gain. In *15th IEEE International Conference on Intelligent Transportation Systems (ITSC)*, pp. 888–893, 2012.
- [100] R. Regele. Using ontology-based traffic models for more efficient decision making of autonomous vehicles. In *Autonomic and Autonomous Systems, 2008. ICAS 2008. Fourth International Conference on*, pp. 94–99, March 2008.
- [101] M. Hulsen, J.M. Zollner, and C. Weiss. Traffic intersection situation description ontology for advanced driver assistance. In *Intelligent Vehicles Symposium (IV), 2011 IEEE*, pp. 993–999, June 2011.
- [102] Per Solberg and JC Oppenlander. Lag and gap acceptances at stop-controlled intersections. Technical report, 1966.
- [103] David R Ragland, Sofia Arroyo, Steven E Shladover, James A Misener, and Ching-Yao Chan. Gap acceptance for vehicles turning left across on-coming traffic: implications for intersection decision support design. *Safe Transportation Research & Education Center*, 2006.
- [104] Bastian J Schroeder and Nagui M Roupail. Event-based modeling of driver yielding behavior at unsignalized crosswalks. *Journal of transportation engineering*, Vol. 137, No. 7, pp. 455–465, 2010.
- [105] Katayoun Salamati, Bastian Schroeder, Duane Geruschat, and Nagui Roupail. Event-based modeling of driver yielding behavior to pedestrians at two-lane roundabout approaches. *Transportation Research Record: Journal of the Transportation Research Board*, No. 2389, pp. 1–11, 2013.
- [106] Wael K.M. Alhajyaseen, Miho Asano, Hideki Nakamura, and Dang Minh Tan. Stochastic approach for modeling the effects of intersection geometry on turning vehicle paths. *Transportation Research Part C: Emerging Technologies*, Vol. 32, pp. 179 – 192, 2013.
- [107] Axel Wolfermann, Wael KM Alhajyaseen, and Hideki Nakamura. Modeling speed

- profiles of turning vehicles at signalized intersections. In *3rd International Conference on Road Safety and Simulation RSS2011, Transportation Research Board TRB, Indianapolis*, 2011.
- [108] Wael KM Alhajyaseen, Miho Asano, Hideki Nakamura, and Nan Kang. Gap acceptance models for left-turning vehicles facing pedestrians at signalized crosswalks. In *Proceedings of the 3rd International Conference on Road Safety and Simulation*, 2011.
 - [109] Wael KM Alhajyaseen, Miho Asano, and Hideki Nakamura. Left-turn gap acceptance models considering pedestrian movement characteristics. *Accident Analysis & Prevention*, Vol. 50, pp. 175–185, 2013.
 - [110] Wael K.M. Alhajyaseen, Miho Asano, and Hideki Nakamura. Estimation of left-turning vehicle maneuvers for the assessment of pedestrian safety at intersections. *IATSS Research*, Vol. 36, No. 1, pp. 66 – 74, 2012.
 - [111] Dong-Kyoung Kye, Seong-Woo Kim, and Seung-Woo Seo. Decision making for automated driving at unsignalized intersection. In *Control, Automation and Systems (ICCAS), 2015 15th International Conference on*, pp. 522–525, Oct 2015.
 - [112] Matthijs TJ Spaan. Partially observable markov decision processes. In *Reinforcement Learning*, pp. 387–414. Springer, 2012.
 - [113] C.G. Keller, Thao Dang, H. Fritz, A. Joos, C. Rabe, and D.M. Gavrila. Active pedestrian safety by automatic braking and evasive steering. *Intelligent Transportation Systems, IEEE Transactions on*, Vol. 12, No. 4, pp. 1292–1304, Dec 2011.
 - [114] Christian Braeuchle, Johannes Ruenz, Folko Flehmig, Wolfgang Rosenstiel, and Thomas Kropf. Situation analysis and decision making for active pedestrian protection using bayesian networks. Proceedings of 6. Tagung Fahrerassistenz: Der Weg zum automatischen Fahren, TV SD, 2013.
 - [115] Pongsathorn Raksincharoensak, Yuta Akamatsu, and Katsumi Moro. Driver speed control modeling for predictive braking assistance system based on risk potential in intersections. *Journal of robotics and mechatronics*, Vol. 26, No. 5, pp. 628–637, oct 2014.
 - [116] Y. Akagi and P. Raksincharoensak. Stochastic driver speed control behavior modeling in urban intersections using risk potential-based motion planning framework. In *Intelligent Vehicles Symposium (IV), 2015 IEEE*, pp. 368–373, June 2015.
 - [117] Lisa D Adams. Review of the literature on obstacle avoidance maneuvers: braking versus steering. Technical report, 1994.