

B1TB2077

## 卒業論文

# 交通シーン理解を目的とした 定性推論と定量推論の融合に関する研究

小林 颯介

2014年 9月 30日

東北大学  
工学部 情報知能システム総合学科

# 交通シーン理解を目的とした 定性推論と定量推論の融合に関する研究\*

小林 颯介

## 内容梗概

近年、先端運転支援システム (ADAS; Advanced Driver Assistance Systems) の開発に関連して、交通シーンの危険を検知するための研究への注目が高まっている。交通シーンの危険をなるべく早くかつ網羅的に検知することは、ADASのみならず自動運転車の開発にも非常に有用な技術である。交通シーンの危険検知の研究は多くなされているが、その多くが観測した情報を直接的に危険パターンと結びつけた予測にとどまっており、また実際の交通シーンのような幅広い状況を想定した評価実験は行われていない。本稿ではまず、それらの既存研究とは異なり、約 200 種類にも及ぶ大規模なデータセットを作成し実験を行った井之上ら (2014) の重み付き仮説推論による危険予測モデルを紹介する。さらに、その手法の問題点である物理情報を精細に扱えない点を解決するために、論理推論と物理シミュレーションによる衝突検知を組み合わせた融合モデルを新たに提案し、評価実験によりその有用性を示す。

## キーワード

自然言語処理, 先端運転支援システム, ADAS, 重み付き仮説推論, 物理シミュレーション, 論理推論

---

\*東北大学 工学部 情報知能システム総合学科 卒業論文, B1TB2077, 2014年9月30日.

# 目次

1	はじめに	1
2	関連研究	4
2.1	危険予測に関する研究	4
2.2	仮説推論	4
2.3	仮説推論による危険予測モデル	5
3	論理推論と物理シミュレーションの融合による危険予測モデル	12
3.1	問題の定式化	13
3.2	仮説推論と物理シミュレーションを併用した危険予測	13
3.3	知識表現	16
3.4	物理シミュレーション	18
3.5	評価実験	21
4	おわりに	23
	謝辞	24
	付録	29
A	物理シミュレーション時の軌跡生成	29
B	物理シミュレーション時の衝突判定	31

## 目次

1	交通シーンにおける潜在危険の例 . . . . .	1
2	仮説推論による危険予測のフレームワーク . . . . .	6
3	問 jaf10 における最良の説明 . . . . .	10
4	新モデルにおけるデータフロー . . . . .	14
5	2つの構造体の変化 . . . . .	19
6	問 5-2 の交通シーンイラスト . . . . .	22
7	問 5-2 に対するシステムの軌跡予測図 . . . . .	23
8	目標軌道が与えられたときの操作入力 . . . . .	31
9	衝突判定 . . . . .	32

# 1 はじめに

近年、先端運転支援システム（ADAS; Advanced Driver Assistance Systems）の開発への関心が高まっている [1][2]。ADASの基礎となる車載センサー装置（カメラやレーダー）や画像認識技術の発展によって、昨今ではADASに関する研究開発は勢いづいている。またADASは、DARPA Grand and Urban Challenges<sup>1</sup>のような競技大会を通して注目を集める高度道路交通システムの基幹技術の1つである。

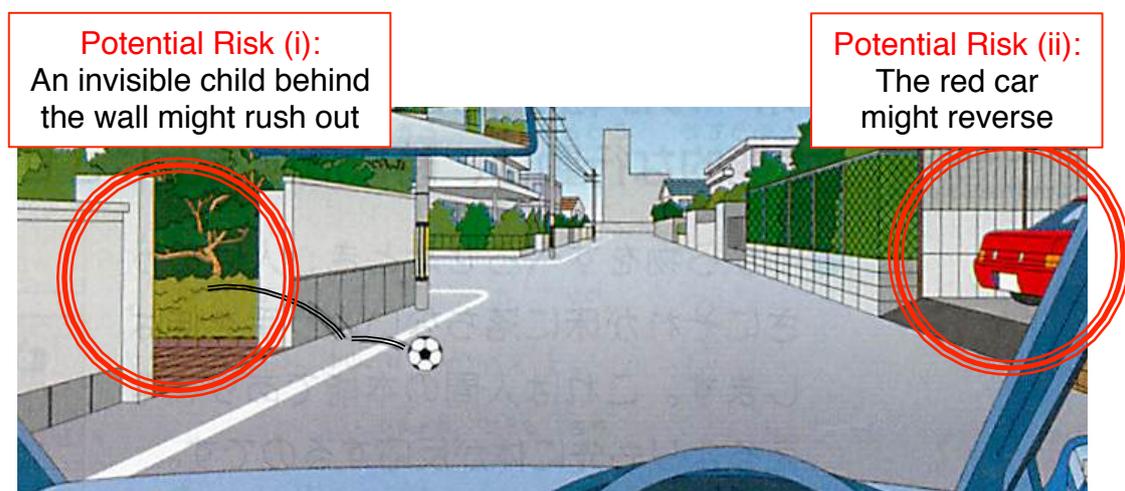


図 1: 交通シーンにおける潜在危険の例

ADASにおいては、ドライバーが適切に危険に反応できるよう出来るだけ早く交通シーン内の危険を検知することが重要である。本稿では潜在危険を予測するようなモデルを扱う。本稿においては潜在危険の定義を、平均的な人間が察知するのに数秒かかるような潜在的に危険な状況とする。例えば、図1に示すような交通シーンでは少なくとも2つの潜在危険が存在している。1つめは左側の塀の後ろ側から子どもがサッカーボールを追いかけて飛び出してきそうだとということである。2つめは右側の赤い車がバックして出てきそうだとということである。交通シーン内の潜在危険を自動的に検知するためには、各移動体（例：乗り物、歩行者）の行動を遠い先まで予測する必要がある。その予測のためには、直接的には観測されないものの推論によって導くことのできるような潜在的な情報も必要

<sup>1</sup><http://archive.darpa.mil/grandchallenge/>

となる。潜在的な情報とは、例えば、移動体の意思（例：赤い車がバックする）や見えない物体の存在（例：塀に隠れた子ども）などが挙げられる。

しかしながら、交通シーンでの危険検知の既存研究のほとんどでは、位置や速度やライトの状態といったような観測として直接的に得られる情報のみに頼った行動予測が研究されている [3][4][5][6]。例えば、Ortizら (2011)[6] は、信号機の状態やブレーキペダルの具合といった観測情報のみを素性にした多層パーセプトロンを用いて行動予測を行うモデルを提案している。なお、そのシステムは実際の交通シーンのような幅広い状況を想定しての評価は行われていない。

本稿では、まず交通シーンの危険予測に関する既存研究を概観したのち、その中から、一階述語論理を用いた仮説推論による新しい危険予測モデル [井之上ら, 2014, 国際会議に投稿中] を特に詳しく紹介する。このモデルでは数種類の知識ベース（例：意思知識、概念関係知識）を組み合わせることで観測情報から潜在的な情報を推論することができ、また、同時に交通シーン内で最尤の危険を特定することができる。危険予測問題を仮説推論による証明問題に落としこむことにより、異なる抽象度の証拠を組み合わせることで潜在危険を見つけ出すことを可能にしている。例えば、図 2 に示された交通シーンが与えられたとき、このモデルは図 2(i) の潜在危険につながるような 2 つの潜在的な情報: (i) 「塀の後ろには人がいるかもしれない」と (ii) 「ボールを追いかける子どもがいるかもしれない」の組み合わせの関連を捉えることができる。また、仮説推論の宣言的な性質のおかげで、危険予測システムの構築において、推論の順序を気にすることなく洗練された知識ベースの構築に集中することができるメリットがある。実際の交通シーンでモデルの評価を行うために、井之上らは 200 問以上の予測問題を教本やウェブサイトから収集し、幅広いシーンの実世界危険予測問題のベンチマーク用データセットを新たに作成している。

上記の井之上らのモデルには幾つかの課題が存在する。そのうちの 1 つは、推論に際して物理的情報を適切に扱えていないという問題がある。実世界から認識装置で得た情報を定性的な論理表現に変換する必要がある、その際に推論時に本来必要である情報が抜け落ちてしまうためである。定量的な情報を定性的に表現する研究は行われているが [7][8][9][10][11][12][13][14][15][16]、定性表現に落としこむ以上情報の欠落は避けられず、論理推論のみで危険予測を行う限りはつきまとう課題となっている。

そこで、本稿では、定量的な情報の欠落が原因で一部の仮説に対して本来行え

るはずの説明が行えないという井之上らのモデルの欠点を補うために、物理シミュレーションを融合させて相互的に推論を行っていくモデルを新たに提案する。すなわち、物理法則に基づいた各物体を考慮した定量的な衝突判定を物理シミュレーションにより行い、その結果を「 $x$ が $y$ と衝突した」という定性的な意味表現に変換してから定性的に論理推論を行う。さらに定性的な論理推論により、物体の潜在的な意思を推論できた際は、再度その意志に基づいた物理シミュレーションにより衝突判定を行う。以上のように推論エンジンと物理シミュレータを相互的に情報を推論しあうことを繰り返し、最終的には潜在危険を予測する。このモデルを実装したシステムを6種類の仮想交通シーンについて適用し、その性能を評価した。

本稿の構成は以下の通りである。まず、2章では、ADASに関する関連研究を概観し、井之上らのモデルと本稿の提案モデルで用いられている重み付き仮説推論についても説明する。さらに、2.3節では特に井之上らの論理推論による危険予測モデルについての詳細を述べる。その後、3章では本稿の提案モデルとなる論理推論と物理シミュレーションの融合モデルを紹介し、最後に4章で本研究の全体の総括を行う。

## 2 関連研究

### 2.1 危険予測に関する研究

交通シーンにおける危険予測の研究は、車両の経路計画問題や行動計画問題に関連して数多く行われている [1][2]。中でも人々の専らの関心は、位置や速度や信号の状態などの観測情報を直接的に用いて車両の軌跡を予測する方法にある [3][17][18]。その一方で、観測情報から推論せねばならない潜在的な情報、すなわち見えない物体の存在や物体の意思などの情報の活用は、危険予測において重要な要素であるにも関わらず、それを詳細に扱った研究はほぼない。

Lattner ら (2005)[19] や Souza ら (2011)[20] は、潜在的な情報を危険予測の重要な証拠として用いているという点では著者の立場に似ている研究だと言える。例えば、Lattner ら (2005)[19] は定理証明によって危険予測を行うアプローチをとっている。Lattner ら (2005)[19] は論理の知識ベースを作り、物体の種類や歩行者の速度というような情報を定性的に変換した知識表現から潜在的な情報を推論しながら、観測情報から交通シーン内の危険の存在を証明する。しかしながら、定理証明器は危険が証明できるか否かを判定することしかできない。しかし、井之上らのモデルでは証明の品質を考慮に入れることができ、交通シーン内での証拠性の観点から証明の良さを評価することができる (詳細は 2.3.2 節で述べる)。

### 2.2 仮説推論

井之上らの手法、及び本稿の提案手法では交通シーンの観測情報から新たに推論を行う際に仮説推論 (アブダクション) を利用する。仮説推論とは最尤の説明を得るための推論であり、診断システムや計画認識システム [21][22] のような知識ベースシステムで広く使われている。仮説推論の枠組みの利点は、その宣言的な性質と証明されていない命題を仮定することができる点にある。2.3.2 節で後述するが、仮説推論ベースでの危険予測モデルもこれらの利点を受け継いでいる。形式的には、論理仮説推論は以下のように定義される。

- 入力: 背景知識  $B$ 、観測情報  $O$ 。ただし  $B$  は一階述語論理式の集合、 $O$  は一階述語論理で書かれたリテラルの集合。
- 出力:  $H \cup B \models O$  かつ  $H \cup B \not\models \perp$  となるような説明  $H$  (一階述語論理で書かれたリテラルの集合)。  $H$  の各要素は説明要素と呼ぶ。

本稿では、背景知識の論理式に出現する全ての変数は、それが明示的に存在量化であると述べられていない限りは、最も広い範囲のスコープで単一化されるものとする。その一方で、説明と観測に出現する変数は暗黙的に存在量化されたものであるとする。

典型的には、観測  $O$  が与えられたとき、 $O$  を説明するような仮説  $H$  を得る。それを仮説候補と呼び、 $B$  が与えられた時の  $O$  の仮説候補の集合を  $\mathcal{H}_{O,B}$  と表すこととする。仮説推論の目標は、ある評価尺度によって仮説候補の中から最良の説明を見つけ出すことである。本稿では仮説推論を、 $\mathcal{H}_{O,B}$  の中からスコアが最大となる説明  $\hat{H}$  を見つけ出すタスクとして定式化する。正式には、 $score$  を  $\mathcal{H}_{O,B} \rightarrow \mathbb{R}$  という関数（スコア関数）としたとき  $\hat{H} = \arg \max_{H \in \mathcal{H}_{O,B}} score(H)$  を見つけ出す。今日までにコストベースや確率ベースなどのいくつかの種類スコア関数が提案されているが [23][22][24]、井之上らの実験では Hobbs ら (1993)[22] の重み付き仮説推論を用いており、本稿でも同様にこれを用いる。

## 2.3 仮説推論による危険予測モデル

この章では、井之上ら (2014, 国際会議に投稿中) の論理推論による危険予測モデルについて説明する。井之上らの論文は国際会議に投稿中であり、現時点では公開されていないため、その手法を詳細に説明する。

### 2.3.1 問題の定式化

本章のモデルでは時刻  $t$  における運転手  $d$  の立場における危険予測問題を以下のように定義される。

- 入力: ある時刻  $t$  に運転手  $d$  が見た交通シーンの画像の説明であるような一階述語論理で書かれたリテラルの集合  $s_{d,t}$
- 出力: オブジェクトと行動の組  $(o_i, a_i)$  からなる潜在危険  $r_i$  の集合  $R$

画像記述は記号的情報や物理的情報を定性的に表現した命題の集合であるが、後の 2.3.3 節において画像記述の表現について詳しく述べる。例えば、図 1 のシーンでは以下の様な処理が行われる。まず、入力となる画像記述は  $\{wall(Wall), ball(Ball), car(RedCar), left-front-of(Now, Wall, Me), \dots\}$  である。そして、この際の潜在危険であるようなオブジェクト-行動の組は  $\{x, will-rush-out\}$  や  $\{RedCar, will-rush-out\}$  (この  $x$  は塀の後に隠れている子ども) である。

運転手  $d$  の運転する車両はカメラやレーダーセンサーのような認識装置を搭載していると仮定されている。また、それにより得た情報を、認識した物体と定数との整合性を保持した論理式集合へと変換可能であり、そのような変換済の論理式集合が与えられるものと仮定されている。

### 2.3.2 仮説推論による危険予測

このモデルの基本的なアイデアを以下に述べる。予測のルールの抽象度を出来る限り一般的な形に留め、異なる抽象化レベルのいくつかの証拠に基づいた推論を行うような一般的な予測ルールによって最良の説明を探し出すことを目標とする。最良の説明を探し出す過程は、観測情報を危険予測に役立つような潜在的な素性空間へ写像する行為だとみなすこともできる。潜在的な素性空間を導入することの有用性は人工知能分野において広く確かめられてきた [25][26][27][28]。特に有用だと考えられる潜在的な情報は、交通シーンに登場する各物体の BDI 情報である。BDI とは信念 (Belief)・欲求 (Desire)・意図 (Intention) という、人間が行うような三段階の心的状況を表す術語である。BDI 情報を用いることができれば、各物体の次の行動が予測することができ、よりよい危険予測が行えるようになる。BDI 情報は観測することができないが、交通シーンの状況や各物体の行動に関する観測情報から推論できることがある。

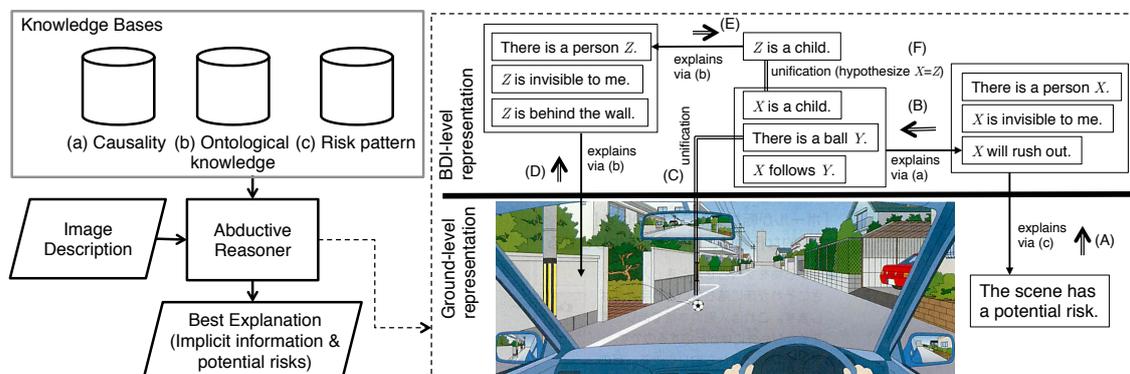


図 2: 仮説推論による危険予測のフレームワーク。小矢印はデータフローを表す。

全体のフレームワークは図 2 に示す。以上のような考えのもと定式化を行い、潜在危険の予測問題を仮説推論による定理証明としてみなす。仮説推論を危険予測の問題に応用したのは井之上らが初であるが、この考え方は仮説推論による談

話関係認識研究 [23][21][22][29][30][31] の考え方に似ている。すなわち、画像の記述  $s$  が与えられたときに「危険が存在する」という命題に対して背景知識ベースと  $s$  から証明を試みることにする。具体的には、画像記述と危険存在の命題を観測  $O$  とみなして仮説推論を行う。背景知識  $B$  には大別して、(a) 意思 (例: 「赤信号が点いている」という観測事実からの「歩行者が止まりそうだ」という推論)、(b) 概念階層 (例: 「トラックが走っている」を「大きな車が走っている」に一般化)、(c) 危険のパターン (例: 「ある隠れた人物が飛び出してきうる」) の 3 つに関する知識を用意する。

図 2 を用いて、ある一つの危険の説明を例にとって推論の過程を解説する。危険の説明は以下のように生成される。

- (A) 入力としてシーンが与えられ、潜在危険の知識 (c) を用いて「自分の死角にいる人物  $X$  が飛び出してくる」ということを仮定する。
- (B) 意思と行動の知識 (a) を用いて、人物  $X$  がボール  $Y$  を追いかける子どもであると仮定する。
- (C) 観測情報されたボールがボール  $Y$  と同一のものであると仮定する。
- (D) 自分の死角にいるある人物  $Z$  が観測された塀の後ろにいると仮定する。
- (E) 人物  $Z$  が子どもだと仮定する。
- (F)  $Z$  と  $X$  は同一のものであると仮定する。

このような説明に基づき、「観測されたボールを追いかける子どもが壁の後ろから飛び出してくる」という危険性のあるオブジェクトと行動の組を特定することができる。

仮説推論を使うことによる主な利点は、その宣言的な性質にある。例えば、宣言的なモデルでは先ほどの図 2 の推論過程 (A) ~ (F) の各順番を特に定める必要はない。仮説推論エンジンは知識ベース内の推論規則の最適な適用法を自動的に求めることができる。一方、宣言的でなく手続き的なモデルでは、知識をいつでもどのように使うのかを全て決めてモデルを実行する必要がある。そのため、そのようなアプローチでは幾つもの推論を柔軟に組み合わせる必要がある場合には予測が困難になると考えられる。

### 2.3.3 知識表現

意味表現 仮説推論の際に使う言語表現について説明する。これらは一階述語論理に基づいている。

定数 全ての交通シーンに対して、次のような定数を用いた。

*Me*:自車, *MyLane*:自車線, *OppositeLane*:対向車線, *MyWalkingLane*:自車線側の歩道, *OppositeWalkingLane*:対向車線側の歩道, *Now*:現在時刻, *Future*:近い未来のとある時刻。また、交通シーンにおける全てのオブジェクトは各個体毎に定数があてられて表現される。(例: *RedCar*, *MotorCycle*)

述語 交通シーン内のオブジェクトの属性やオブジェクト間の関係を記述するために、次のような述語を用いた。

1. オブジェクトの属性: 物体の概念的な類型を表現する単項述語。交通シーンにおけるオブジェクトを運転教本を参考にして約 50 種類に分類し、それぞれに述語が定義される。例として、 $signal(x)$  は  $x$  が信号機であることを表している。
2. オブジェクトの意思: 物体の抱えている意思を表現する単項述語。次の 5 つの述語を定義される:  $will-rush-out(x)$ ,  $will-avoid(x)$ ,  $will-go-front(x)$ ,  $will-stop(x)$ ,  $will-slow-down(x)$ 。潜在危険を予測するためには各物体の意思を推論することが肝要である。
3. オブジェクトの状態: ある時刻における物体の状態を表現する二項述語。約 20 種類が定義される。例として、 $left-head-lamp-on(t,x)$  は時刻  $t$  において車両  $x$  の左ヘッドランプが点滅していることを表している。その時刻  $t$  は本稿では上で述べた定数 *Now* もしくは *Future* で表される。
4. 道路の状態: 路面の状態を表現する単項述語。 $wet(x)$ ,  $icy(x)$ ,  $muddy(x)$ ,  $snowy(x)$  の 4 つが定義される。
5. オブジェクト間の位置関係: ある時刻における複数オブジェクト間の位置関係を表現する複項述語。約 15 種類が定義される。例えば、 $in-front-of(t,x,y)$  は時刻  $t$  において物体  $x$  が物体  $y$  の前に位置することを表す。
6. シーン危険性: 物体  $p$  にとっての危険  $r$  が存在することを表す述語  $risk(r,p)$  が定義される。

背景知識 上で述べた意味表現を用いて、常識的知識を論理式の形で背景知識  $B$  に記述する。背景知識は以下の様な 3 種類の知識で構成される。

#### 状態と意思の関係の知識

物体の意思を推論するために、状態と意思の関係を知識として記述する。例えば、 $\forall x, y \text{ large-vehicle}(x) \wedge \text{in-front-of}(\text{Now}, x, y) \rightarrow \text{will-avoid}(y)$  のように書くことで、「大きい車  $x$  が別の車両  $y$  の前にいるとき、 $y$  は  $x$  を避ける」という推論の知識を記述する。知識は 100% 成り立つようなものとは限らず、あくまで傾向を記述したものである。

#### 概念階層関係の知識

概念間の階層関係や排他性を知識として記述する。例えば、 $\forall x \text{ bicycle}(x) \rightarrow \text{vehicle}(x)$  のように書くことで、「自転車が乗り物の一種である」という IS-A 関係を知識として記述する。また、 $\forall x \text{ car}(x) \wedge \text{bicycle}(x) \rightarrow \perp$  のように書くことで、「車でありながら同時に自転車であるような物体は存在しない」という排他性の知識を記述する。

#### 危険のパターンの知識

観測情報と、上の知識で導いた情報に基づいて、交通シーンの状況と潜在危険の対応関係を定義する。例えば、 $\forall x, y \text{ in-front-of}(\text{Now}, x, y) \wedge \text{will-stop}(y) \rightarrow \text{risk}(r, y)$  のように書くことで、「車両  $y$  の前にいる物体  $x$  が停止するであろう状況では、 $y$  にとって危険である」という危険パターンを記述する。

### 2.3.4 評価実験

潜在的な情報の推論が交通シーンと潜在危険の関係のモデリングに役に立つのか確かめるために井之上らは実験を行っている。データセットには、運転教育のための幾つかのウェブサイト<sup>2</sup>や教本（中部日本自動車学校出版「危険予測マスター」,1999）から危険予測問題を抽出したものをを用いている。その各問題は図1のように、運転手視点のシーン画像に1~3個の典型的な危険が人手で付与し、さらに交通シーンを論理式の形に人手で変換し、運転手に潜在危険を引き起こすようなオブジェクト-行動の組も抽出されている。なお、各シーン画像について全て

<sup>2</sup><http://www.honda.co.jp/safetyinfo/kyt/training/>  
<http://www.jaf.or.jp/eco-safety/safety/danger/>  
<http://www.bridgestone.co.jp/csr/tiresafety/training/>  
<http://www.nasva.go.jp/fusegu/kikentaxi.html>

の妥当な潜在危険が列挙されているわけではない。また、ベースラインモデルとして観測情報を直接利用する単純な機械学習による危険予測モデルを作成して実験を行い、その結果を提案モデルと比較している。

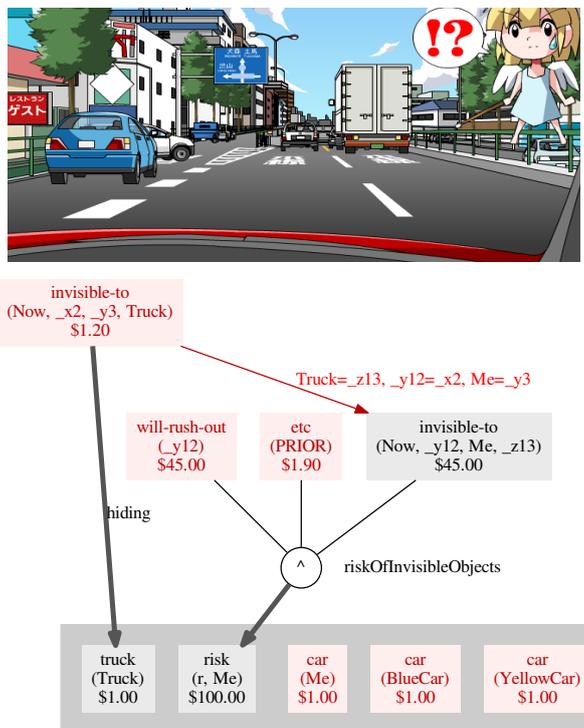


図 3: 問 jaf10 における最良の説明（観測は簡略化したもの）。  
<http://www.jaf.or.jp/eco-safety/safety/danger/>

井之上らのモデルの実験結果についてのエラー分析を以下に記す。33 個の事例では論理推論モデルは上位 5 個の出力で模範解を出力されなかった。さらに、この事例について本モデルが説明候補全体の中に（上位 5 個以外に）模範解を生成できているかをチェックしたところ、33 問中 24 問は模範解が候補仮説中にあることが判明した。

なぜその 24 問では模範解が下位にランク付けされてしまったのかを理解するために、模範解が妥当な推論規則で推論されうるか否かを井之上らは人手でチェックしている。その 24 問中 21 問は合理的な推論では模範解が導出しえないと考えられるものであり、大多数の非合理的な推論は物体らの位置や形のような物理的情報を欠いていることが原因で発生していると述べられている。典型的なエラー

の例を図3に示す。この例での模範解となる潜在危険は「左方の白い車が飛び出してくるだろう」だが、仮説推論モデルが第1位として出力したものは「トラックの陰に隠れた何者かが飛び出してくるだろう」だった。しかしながら、状況的には、青い車によって白い車が自車を視認しづらい状態になっていることを理解すべきである。この推論をシステムが行うには、車の三次元形状やドライバーの顔の位置などの物理的情報に関する推論を行う必要があるが、井之上らの定性的な知識表現ではこれらの精細な情報を扱っていない。なお、残り3問は現在の推論規則で合理的に模範解が導出されうるが、推論規則の重み設定が適切でなかったために求められる出力が下位になってしまったと考えられている。将来的には、井之上ら(2012)[32]が提案したような機械学習の方法によって本モデルの推論規則や観測の重みスコアを調整して新たに実験が行う予定であると述べられている。

### 3 論理推論と物理シミュレーションの融合による危険予測モデル

2.3章で紹介したモデルにおける評価実験の結果(2.3.4節)を分析したところ、交通シーン内の物理的情報が欠落してしまったために適切な解を出力できない問題があることがわかった。物理的情報を精密に扱って推論することのメリットの例として、死角(可視性)の計算ができるようになることを例に挙げたが、それ以外にもメリットがあるような事例は存在する。例えば、井之上らのモデルでは一般化された危険パターンとして「前の車が減速したら危険である」という知識があるが、このような知識では、前の車が遙か遠くの数十m先にいたとしても危険な状況だと予測してしまう。

このような問題を解決するための単純な方法は、物理シミュレーションによって危険予測を行うことである。物理シミュレーションを用いると、現在の速度や距離等の定量的な物理情報から、未来の位置や軌道等を推論することができるため、今の例のような非合理的な予測を導く推論を防ぐことができる。しかしその反面、物理シミュレーションだけでは記号的な情報を踏まえるなどして交通シーン内の各物体の意思の変化をとらえることは難しい。

そこで、本章では論理推論と物理シミュレーションの両者が苦手な点を補いあうように互いの推論結果を相互的に利用するような新たな危険予測モデルを提案する。基本的なアイデアは、(i)井之上らのモデルにおける位置関係などの物理情報が主に絡んでいる論理推論を物理シミュレーションにおきかえるということと、(ii)物理シミュレーションによる衝突予測の情報をリテラルとして定性的に論理推論を行うということの2つである。

本章の構成は以下のとおりである。まず3.1節では、交通シーンにおいて潜在危険を予測する問題に対して、再度定式化を行う。次に3.2節において、本稿の提案手法である、井之上らの仮説推論モデルと物理シミュレーションモデルを統合させたモデルについて説明する。その後、物理シミュレーションの入出力について3.4節で詳述したのち、論理推論で用いる意味表現と知識ベースについて3.3節で説明する。そして最後に3.5節で、提案手法を仮想的な交通シーンに適用した評価実験の実験設定とその結果について述べる。

### 3.1 問題の定式化

本章では、時刻  $t$  における自車  $d$  の立場における危険予測問題を以下のように再定義する。

- 入力: ある時刻  $t$  に自車  $d$  から見た交通シーンの画像を説明するような一階述語論理の論理式の集合  $s_{d,t}$  (前章と同様) と、交通シーン内の各物体の3次元形状・位置・速さの定量値の組からなる集合  $E_{d,t}$
- 出力: 各物体の軌跡の集合  $P$  と、物理シミュレーションにより衝突が予測された二物体とその衝突時刻の組  $(o_{k,1}, o_{k,2}, t_k)$  の集合  $C$  の組  $r = (P, C)$  の集合  $R$

画像記述の内容については前章の 2.3.3 節において述べたものと同様であるが、位置情報を表す意味表現 (例: *in-front-of*) などは省略してある。新たに推論で用いる意味表現等については、詳しくは 3.3 節でも述べる。前章のモデルと同様に、自車  $d$  は搭載した認識装置により得た情報を、認識した物体と定数との整合性を保持した論理式集合へと変換可能であると仮定する。また、加えて各物体の大まかな三次元形状・位置・速さも取得可能であるとする。

### 3.2 仮説推論と物理シミュレーションを併用した危険予測

本モデルにおけるデータフローを図 4 に示す。本モデルは推論エンジン部と物理シミュレータ部に分かれている。推論エンジンでは、井之上らのモデル同様に論理推論を行う。ただし、位置関係など物理的情報を用いるような背景知識は用意せず、その他の記号的な情報や衝突予測の情報などを用いる推論 (例: 「右のヘッドランプが付いている車は右折する」、「衝突しそうな車は衝突先の車を避ける」) を行い、最良の仮説を出力する。一方、物理シミュレータでは仮説として推論された意思変化の情報を反映しつつ、観測された各物体の現在位置・速度・向き情報等から定量的に未来の軌跡を予測生成し、各物体について衝突する可能性があるか否かを判定し、ある二物体が衝突すると予測できた場合はその結果を返す。このように二つの機構を交互に実行することで、記号的な情報を用いた意思変化の推論や物理的な情報を用いた幾何学的な推論などを併用して潜在危険の検知を行うことができる。

本モデルの物理シミュレーションでは一つの意味から複数の軌跡を生成しうる。そのような複数の軌跡は互いに同時には一つの世界に存在しえず、実際には分岐

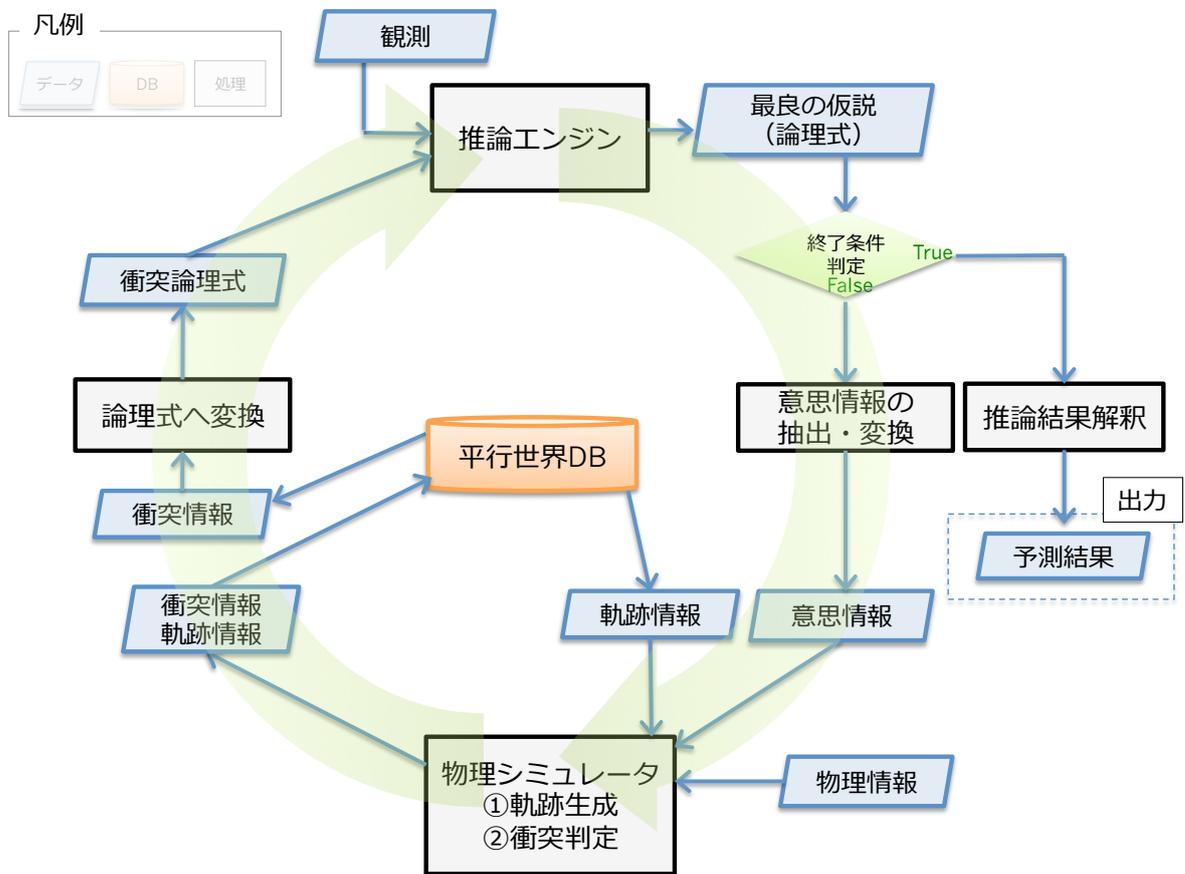


図 4: 新モデルにおけるデータフロー

している仮想的な世界それぞれにおいてのみ仮定されるものである。すなわち、推論においてそのような複数の並行した世界における各仮定は、互いに独立して扱わねばならない。本稿では、そのような独立の並行した世界を各物体の軌跡の組み合わせにより定義し、並行世界と呼ぶこととする。

アルゴリズム 1 に沿って、本モデルのアルゴリズムを説明する。一連の処理はループにより繰り返し行われ、終了条件を満たしたと判定された場合にループを脱し、返り値として潜在危険の集合  $R$  と想定される並行世界の情報の集合  $W$  が得られる。4 行目以下の while ループ内の処理を述べる。まず、5 行目において、関数  $pop(W)$  によって並行世界のキュー  $W$  から要素を 1 つ要素を取り出し、その

---

**Algorithm 1** 推論エンジンと物理シミュレータの相互実行アルゴリズム

---

**Input:** 知識ベース  $B$ , 観測の論理式集合  $O$ , 交通シーン内の各物体の物理情報  $E$ .

**Output:** 危険パターン集合  $R$ , 想定される並行世界の集合  $W$

```
1: Let  $W$  be a queue.
2:  $W \leftarrow \{(\{\}, \{\})\}$ 
3:  $R \leftarrow \{\}$ 
4: while the condition is unsatisfied do
5:    $C_w, P_w \leftarrow pop(W)$ 
6:    $H \leftarrow abduction(B, O \cup C_w)$ 
7:    $R \leftarrow R \cup extractRisks(H)$ 
8:    $I \leftarrow extractWills(H)$ 
9:    $S \leftarrow phySim(I, P_w, E)$ 
10:  for each  $(c, P) \in S$  do
11:     $push(W, (C_w \cup \{c\}, P))$ 
12:  end for
13: end while
14: return  $R, W$ .
```

---

要素を  $W$  から削除する。取り出した要素はある並行世界における、物理シミュレーションによる衝突予測の情報を論理式に変換したものの集合  $C_w$  と各物体の軌跡の情報  $P_w$  である。次に、6行目で関数  $abduction(B, O \cup C_w)$  により、 $C_w$  と観測  $O$  の和集合を新たな観測とし、知識ベース  $B$  を用いて仮説推論エンジンにより推論を行い、最良の説明となるような論理式集合  $H$  を得る。続いて、7行目で関数  $extractRisks(H)$  により  $H$  に含まれる潜在危険を意味する論理式の集合を抽出し、集合  $R$  に追加する。8行目では関数  $extractWills(H)$  により  $H$  から意思変化を意味する論理式の集合を抽出し集合  $I$  に上書きで格納する。そして、9行目では関数  $phySim(I, P_w, E)$  により各物体の意思変化を踏まえた予測軌跡生成と衝突判定を行い、複数想定される並行世界について、それぞれ衝突情報  $c$  と軌跡の情報  $P$  を対としたものを  $S$  に上書きで格納する。10行目から12行目の間では、先の  $S$  の各要素について、11行目の処理を繰り返す。11行目では、その while ループにおいて扱っていた並行世界において予測された新たな衝突情報と軌跡情報で既存の並行世界を更新したような新たな並行世界を作成し、キュー  $W$  に追加する。全ての  $S$  の要素に対して11行目の処理を終えたら、while ループとして4行目の処理に戻る。

ループの終了条件は、「 $n$  回ループが回る」もしくは「 $R$  に初めて要素が入ったときから  $m$  回ループが回る」( $n, m$  は既定するパラメータ)等が考えられる。本稿では前者のように規定回数ループが回ったときに処理を終了とする。その処理終了後に  $R$  が空であった場合は危険を検知できなかったものとする。なお、本稿ではループの初回では各々が適当な速度で直進する意思、すなわち「特に行動変化はない」という意思を持っていると仮定し、そのような意思情報を生成し(アルゴリズム1における  $I$  に代入し)、物理シミュレーションのステップ ( $phySim(I, P_w, E)$ ) へ進むこととする。本稿では扱わないが、応用的にはループ初回で想定する軌跡に、観測情報から直接的に予測するような既存研究のモデルの出力する予測軌跡を用いることも可能である。

### 3.3 知識表現

基本方針として、井之上らの論理推論モデルの2.3.3節で述べた知識表現の中から、物体間の位置関係を表現する意味表現及び関連する背景知識を廃止する。位置情報のような物理的情報は、観測から一階述語論理に変換する過程で情報が抜け落ちる部分であり、そういった物理的な推論を物理シミュレーションで行うことで推論の確度を高めるためである。

例として、井之上らのモデルで使用していた「大きい車  $x$  が別の車両  $y$  の前にいるとき、 $y$  は避ける」という推論の知識 ( $\forall x, y \text{ large-vehicle}(x) \wedge \text{in-front-of}(\text{Now}, x, y) \rightarrow \text{will-avoid}(y)$ ) について考える。この知識は、 $y$  が  $x$  に比べて速く走行しており衝突する恐れがあるならば  $y$  が  $x$  を避けようとするだろう、という経験的な知識に基づいていると考えられる。その経験的な知識の推論を分解すると、(i) 「今の状況からそのままいけば、物体  $y$  が別の物体  $x$  に衝突しそうである」と (ii) 「物体  $y$  が別の物体  $x$  に衝突しそうならば、 $y$  は  $x$  を避ける」という2つの推論に分けられる。この (i) の推論については、まず物理シミュレーションで  $x$  と  $y$  が衝突するか否かの判定を行い、その結果として衝突予測を意味する論理式  $\text{collide}(t, x, y, \text{wname})$  を生成することで行える。そして (ii) の推論についてのみ論理式の形で背景知識として  $\forall x, y \text{ will-avoid}(y) \rightarrow \text{vehicle}(x) \wedge \text{vehicle}(y) \wedge \text{collide}(t, x, y, \text{wname})$  というような知識を書いておけば、その知識を用いた論理推論で推論を行える。よって、このように推論規則を変更しておくことで、モデル全体としては確度の高い物理的な推論を踏まえつつ、最終的に「 $y$  が避ける」という意思を推論することができる。

本稿のモデルでは、井之上らの用いた意味表現を同様に用いるが2つの述語を新たに追加する。1つめに意思を抱くことを表現する述語として、 $\text{has-will}(\text{name1}, \text{will}, \text{name2}, \text{time}, \text{wname})$  を用意する。項には、意思を持つ物体、意思の種類、意思の対象物、意思の実行期限時刻、並行世界のIDの5つをとる。そしてもう1つは、物理シミュレーションによる衝突判定によって生成されるような衝突予測の情報を表現する述語として、 $\text{collide}(\text{coltime}, \text{name1}, \text{name2}, \text{wname})$  を用意する。この項には、衝突時刻、衝突物体A、衝突物体B、並行世界のIDの4つをとる。

新たに追加した2つの述語については、その項に各並行世界のIDを含ませ(例:  $\text{has-will}(\text{YellowCar}, \text{Avoid}, \text{RedCar}, \text{T2}, \text{W-2})$ )、その論理式を用いた推論では新たに生成する仮定にも同じ並行世界のIDを継承させることにより、各並行世界ごとの仮定を独立させたまま、一度にまとめて推論を行うことが可能となる。本稿で説明するモデルでは、そのような述語の特性を活かし、各並行世界における論理式を一括に観測に追加したものを推論エンジンの入力として一度にまとめて推論を実行することで、全体の処理の効率化を図っている。

背景知識については、井之上らのモデルで用いていた概念関係知識はそのまま転用し、そこに新たに知識を書き加えたものを用いた。追加した知識は3種類あり、その詳細を以下に述べる。意思を推論するための知識については、その知識

を用いた推論後には元のリテラルのコスト合計が下がるように推論規則の重みを設定する。これにより、「意思の推論を可能な場合は行う」という目的を、推論エンジンの「コストが最小となるような説明を探し出す」という機能に落としこむことができる。

#### 未来の現象と意思の関係の知識

物体の意思を推論するために、状態と意思の関係を知識として記述する。本稿のモデルでは、未来の衝突を根拠に物体の意思を推論する知識のみを用意する。例えば、 $has-will(name1, Avoid, name2, coltime, wname) \wedge has-will(name2, Avoid, name1, coltime, wname) \rightarrow agent(name1) \wedge agent(name2) \wedge collide(coltime, name1, name2, wname)$  のように書くことで、「移動体  $name1$  と移動体  $name2$  が、ある並行世界  $wname$  において、時刻  $coltime$  に衝突するならば、移動体  $name1$  と移動体  $name2$  は時刻  $coltime$  までにそれぞれ互いを避けようとするだろう」という知識を記述する。

#### 概念階層関係の知識

概念間の階層関係を知識として記述した。例えば、 $agent(x) \rightarrow car(x)$  や  $sufferer(x) \rightarrow person(x)$  というような IS-A 関係の知識を記述し、衝突に関する推論において衝突物体の種類によって異なる意思変化の推論を行えるようにする。

#### 危険のパターンの知識

前章のモデルのような多々あるパターンは本稿の本モデルでは記述せず、単純な「自車の衝突」のみを危険として定義した。

例えば、 $collide(coltime, Me, name2, wname) \rightarrow risk(R, Me, wname)$  と書いた。自車の衝突が物理シミュレーションによる衝突判定により生成される論理式で説明される以外の場合に、この推論規則による仮説が最良の説明に含まれないようにするため、この推論規則の重みは無限大に設定する。

### 3.4 物理シミュレーション

物理シミュレータは、予め与えられた各物体の現在位置・速度・向き・形状等の情報と、推論された意思変化の情報を入力として、各物体の未来の軌跡を複数予測して生成することができる。また、さらにその軌跡をもとに各物体に関して衝突判定を行い、衝突する場合はその衝突時刻等の情報を出力する。

物理シミュレータの入出力に関しては、説明を簡便にするためそれぞれひとかたまりの構造体データとして定義を行う。以下では、入力となる集合の要素である (i) 意思情報の構造体と、出力となる集合の要素である (ii) 衝突情報の構造体について説明する。

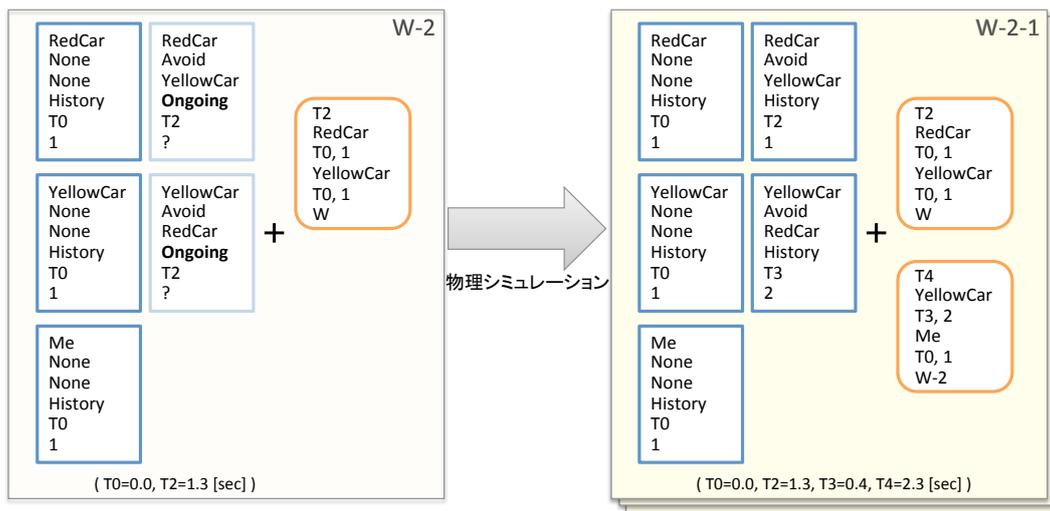


図 5: 2 つの構造体の変化

(i) 意思情報の構造体は、簡潔に言えば、「何が、いつ、何を、何したのか」、あるいは「何が、いつまでに、何を、何するべきなのか」という情報を持っている。前者を表す構造体を、データタイプ = *History* と定義し、後者をデータタイプ = *Ongoing* と定義する。データタイプ = *Ongoing* の構造体は、*has-will* の述語からなる論理式の各項をもとに定義され、この構造体を入力とした物理シミュレーションにより複数の軌跡が生成される。その内の 1 つの軌跡に確定したものがデータタイプ = *History* の構造体である。この構造体の集合により、各物体の行動は定まり、1 つの並行世界が定義される。物理シミュレーションによる衝突判定は、この構造体の集合を入力として行われる。アルゴリズム 1 上の表現におきかえると、データタイプ = *History* の構造体は集合  $P_w$  の要素、データタイプ = *Ongoing* の構造体は集合  $I$  の要素を、それぞれ適当に形に変換したものである。

以下に意思情報の構造体の要素を列挙する。

- 物体の ID: 意思を実行する物体の ID (例: YellowCar, BlueBicycle)

- 意思の名前: 実行する意思の名前 (例: Avoid)
- 意思に関連した物体の ID: 意思の対象物等の物体の ID (例: RedCar)
- データタイプ: シミュレータがその構造体をどう扱うべきかを記述。シミュレーション済みの構造体の場合は History, 新たに推論されたシミュレーション前の構造体の場合は Ongoing となる
- 意思の実行時刻の ID: データタイプが History の場合のみ使用。軌跡生成のプログラムを本構造体の意思に切り替える時刻の ID (例: T3)
- 意思の実行期限の時刻の ID: データタイプが Ongoing の場合のみ使用。軌跡生成のプログラムを本構造体の意思に切り替えられる期限の時刻の ID (例: T2)
- 実行済み意思で選択した軌跡生成番号: データタイプが History の場合のみ使用。確率的に複数生成される軌跡に振られた個別の識別番号 (例: 2)

(ii) 衝突情報の構造体は、物理シミュレーションによって衝突判定が真となった二物体に関する情報をまとめたものある。意思情報の構造体の集合を与えられたとき、データタイプが Ongoing の意思情報の構造体から複数の軌跡を生成し、その全てに個別の識別番号を振る。そして、その生成軌跡全てのパターンについて他物体との衝突判定を行う。衝突が検出された場合、衝突情報とその並行世界の ID をペアとしたものの集合を衝突情報の構造体として出力する。衝突情報の構造体はアルゴリズム 1 上の表現では、 $c$  と  $P$  を合わせたものに元の並行世界の ID である  $w$  を付記したものである。

以下に衝突情報の構造体の要素を列挙する。

- 衝突二物体のそれぞれの ID (例: YellowCar, Me)
- 衝突時刻の ID (例: T4)
- 衝突二物体のそれぞれの、直前の意思の実行開始時刻 (例: T3)
- 衝突二物体のそれぞれの、直前の意思の実行での軌跡生成番号 (例: 2)
- 衝突が起きるとされた元の並行世界の ID (例: W-2)

本稿の実験で用いた物理シミュレータは株式会社デンソーが作成したもの (非公開) である。なお、物理シミュレーションにおける軌跡生成と衝突検知の詳細は付録 A, B に記す。現在の物理シミュレーションは軌跡生成により単なる衝突

判定を行う機能のみだが、将来的に死角計算や接近判定などの別の定量的な判定を行えるようにすることで、前章のモデルで扱っていた推論のうちの多くを定量的に行えるようになることも期待される。

## 3.5 評価実験

### 3.5.1 実験設定

提案モデルが実際に各物体の意思や軌跡を考慮して潜在危険を予測できているのか確かめるべく実験を行った。2.3.4節での実験と同じく「危険予測マスター」(中部日本自動車学校出版, 1999)をテストデータに用い、その中から、(i) 視認できている物体の潜在的な意思の変化が模範解の潜在危険の理由付けに含まれており、かつ、(ii) その理由付けにおいて、現状の物理シミュレーションが対応している「ある物体を右か左に避ける」もしくは「一定の速度で直進する」という意思のみを含むような事例を6問選び評価実験を行った。

入力情報は、知識ベースは3.3節で述べたものを使い、論理式集合は人手で書き下したものを使い、また、物理情報については、位置・速度情報などの、問題文内では厳密に定まっていない定量情報についても、交通シーンのイラストを参考にして現実に即するよう人手で設定した。システムの出力であるリスクパターンの中に、問題の模範解と同じ理由付け(各物体の意思と軌道)で行われているものが含まれていると判断できたときには、その問題を正解できたものとする。本モデルのループ処理の終了条件である最大ループ回数は4に設定した。先述したとおり、物理シミュレータは株式会社デンソーが作成したもの(非公開)を使用した。また、物理シミュレーションにおいて時刻 $t$ の刻み幅は0.1秒とし最大で6.0秒までの軌跡生成と各時刻における衝突判定を行うよう設定した。

### 3.5.2 実験結果

実験の結果、6問中6問において正解することができた。図6の問題に対するシステムが出力した各物体の軌跡を図7に示す。出力では並行世界の軌跡も同時に描かれているが、実際に潜在危険が存在するとしてシステムが予測した並行世界でのYellowCarの軌跡は図中のMeの軌跡と重なるように描かれている軌跡である。この問題における模範解は「対向車が交差道路の車をよけて中央線を越えてきて自車と衝突する」という潜在危険だが、実際に軌跡はその通りのものを描けている。この軌跡を描くような意思情報の構造体の集合も、 $['Me', 'None', 'None', 'TE',$

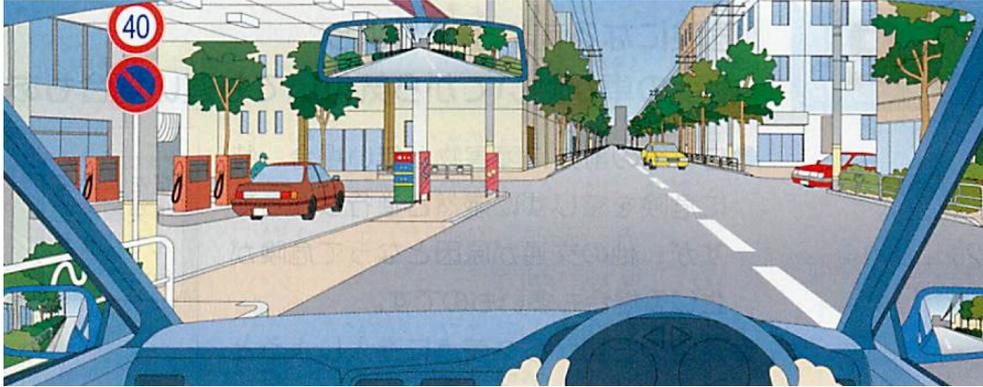


図 6: 問 5-2 の交通シーンイラスト

1], ['RedCar', 'None', 'None', 'T0', 1], ['YellowCar', 'None', 'None', 'T0', 1], ['YellowCar', 'Avoid', 'RedCar', 'T3', 2], ['RedCar', 'Avoid', 'YellowCar', 'T2', 1] となっており、確かに理由付けも適切に意思変化を考慮したものとなっている。

### 3.5.3 今後の課題

6 問中 6 問正解することができたものの、幾つかの課題が浮かび上がった。まず、物理シミュレーションにおける衝突判定については、現在は接触する場合のみ判定が真となる。しかし、交通シーンにおける危険を検知したい際には、厳密に接触するときだけでなく、極めて近い距離をすれちがうようなケースも危険と判定したい。また、今回の実験ではテストした問題数が少ないため、本モデルの潜在危険の予測能力を確かめるためには意思の種類も増やしたのちに多様なシーンで実験する必要がある。

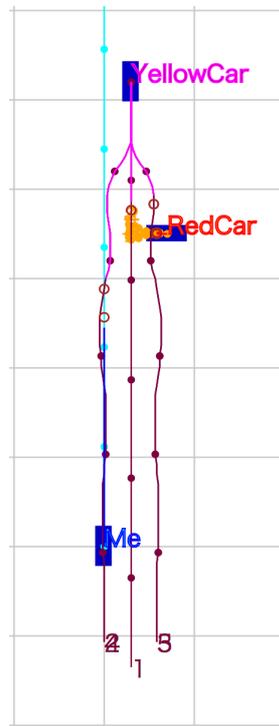


図 7: 問 5-2 に対するシステムの軌跡予測図

## 4 おわりに

本稿では、まず交通シーン理解を通じた危険予測問題に関して、潜在的な情報を宣言的な知識から推論することができる井之上ら (2014, 国際会議に投稿中) のアプローチについて詳述し、その手法が持つ問題点を指摘した。具体的には、定性的な論理推論を用いるために観測情報を定性表現に落としこむ必要があるため、定量的である物理的な位置情報等が失われ、その結果として本来行わなければならない推論が行えないという点である。その問題を解決すべく、既存の論理推論に物理シミュレーションを組み合わせる危険予測を行っていく新たなモデルを提案した。そのモデルを実際に実装し、井之上らが用いたデータセットを用いて実験を行うことで、適切な理由付けによって潜在危険を導くことができることを示した。今後の課題として、より多くの意思の種類や交通状況に対応できるよう物理シミュレーション及び知識ベースを拡張した上で、より大規模に実験を行う必要がある。

## 謝辞

本研究を進めるにあたり、ご指導いただいた乾健太郎教授、岡崎直観准教授に感謝いたします。

本論文の作成及び研究活動全般に渡り、多くの議論を交わし、的確な助言をくださった井之上直也氏に感謝いたします。

本研究について多くの助言をくださった乾・岡崎研究室の皆様感謝いたします。

## 参考文献

- [1] Elizabeth Rendon-Velez, Imre Horváth, and Eliab Z Opiyo. Progress with situation assessment and risk prediction in advanced driver assistance systems: A survey. In *Proceedings of the 16th ITS World Congress*, pp. 21–25, 2009.
- [2] 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.
- [3] Adrian Broadhurst, Simon Baker, and Takeo Kanade. Monte carlo road safety reasoning. In *Proceedings of the IEEE Intelligent Vehicles Symposium*, pp. 319–324. IEEE, 2005.
- [4] Daniel Greene, Juan Liu, Jim Reich, Yukio Hirokawa, Akio Shinagawa, Hayuru Ito, and Tatsuo Mikami. An efficient computational architecture for a collision early-warning system for vehicles, pedestrians, and bicyclists. *Intelligent Transportation Systems, IEEE Transactions on*, Vol. 12, No. 4, pp. 942–953, 2011.
- [5] Andreas Tamke, Thao Dang, and Gabi Breuel. A flexible method for criticality assessment in driver assistance systems. In *Intelligent Vehicles Symposium (IV), 2011 IEEE*, pp. 697–702. IEEE, 2011.
- [6] Michaël Garcia Ortiz, Jannik Fritsch, Franz Kummert, and Alexander Gelperth. Behavior prediction at multiple time-scales in inner-city scenarios. In *Intelligent Vehicles Symposium (IV), 2011 IEEE*, pp. 1068–1073. IEEE, 2011.
- [7] James F. Allen. Maintaining knowledge about temporal intervals. *Commun. ACM*, Vol. 26, No. 11, pp. 832–843, November 1983.
- [8] Christian Freksa. Using orientation information for qualitative spatial reasoning. In A.U. Frank, I. Campari, and U. Formentini, editors, *Theories and*

*Methods of Spatio-Temporal Reasoning in Geographic Space*, Vol. 639 of *Lecture Notes in Computer Science*, pp. 162–178. Springer Berlin Heidelberg, 1992.

- [9] GérardF. Ligozat. Qualitative triangulation for spatial reasoning. In AndrewU. Frank and Irene Campari, editors, *Spatial Information Theory A Theoretical Basis for GIS*, Vol. 716 of *Lecture Notes in Computer Science*, pp. 54–68. Springer Berlin Heidelberg, 1993.
- [10] Christoph Schlieder. Reasoning about ordering. In AndrewU. Frank and Werner Kuhn, editors, *Spatial Information Theory A Theoretical Basis for GIS*, Vol. 988 of *Lecture Notes in Computer Science*, pp. 341–349. Springer Berlin Heidelberg, 1995.
- [11] Reinhard Moratz, Jochen Renz, and Diedrich Wolter. Qualitative spatial reasoning about line segments. In *ECAI 2000. Proceedings of the 14th European Conference on Artificial Intelligence*, pp. 234–238. IOS Press, 2000.
- [12] Reinhard Moratz, Bernhard Nebel, and Christian Freksa. Spatial cognition iii. chapter Qualitative Spatial Reasoning About Relative Position: The Tradeoff Between Strong Formal Properties and Successful Reasoning About Route Graphs, pp. 385–400. Springer-Verlag, Berlin, Heidelberg, 2003.
- [13] Frank Dylla and Reinhard Moratz. Empirical complexity issues of practical qualitative spatial reasoning about relative position. In *In Workshop on Spatial and Temporal Reasoning at ECAI, 2004*.
- [14] Frank Dylla and Reinhard Moratz. Exploiting qualitative spatial neighborhoods in the situation calculus. In *Proceedings of the 4th International Conference on Spatial Cognition: Reasoning, Action, Interaction, SC'04*, pp. 304–322, Berlin, Heidelberg, 2005. Springer-Verlag.
- [15] Alexander Scivos and Bernhard Nebel. The finest of its class: The natural point-based ternary calculus lr for qualitative spatial reasoning. In Christian Freksa, Markus Knauff, Bernd Krieg-Brückner, Bernhard Nebel, and

Thomas Barkowsky, editors, *Spatial Cognition IV. Reasoning, Action, Interaction*, Vol. 3343 of *Lecture Notes in Computer Science*, pp. 283–303. Springer Berlin Heidelberg, 2005.

- [16] Reinhard Moratz. Representing relative direction as a binary relation of oriented points. In *Proceedings of the 2006 Conference on ECAI 2006: 17th European Conference on Artificial Intelligence August 29 – September 1, 2006, Riva Del Garda, Italy*, pp. 407–411, Amsterdam, The Netherlands, The Netherlands, 2006. IOS Press.
- [17] Samer Ammoun and Fawzi Nashashibi. Real time trajectory prediction for collision risk estimation between vehicles. In *Intelligent Computer Communication and Processing, 2009. ICCP 2009. IEEE 5th International Conference on*, pp. 417–422. IEEE, 2009.
- [18] Rajesh Rajamani. *Vehicle dynamics and control*. Springer, 2011.
- [19] Andreas D Lattner, Ingo J Timm, Martin Lorenz, and Otthein Herzog. Knowledge-based risk assessment for intelligent vehicles. In *Proc. of the IEEE International Conference on Integration of Knowledge Intensive Multi-Agent Systems (KIMAS'05), Waltham, Massachusetts, USE*, pp. 191–196, 2005.
- [20] Carlos RC Souza and Paulo E Santos. Probabilistic logic reasoning about traffic scenes. In *Towards Autonomous Robotic Systems*, pp. 219–230. Springer, 2011.
- [21] H. T. Ng and R. J. Mooney. Abductive Plan Recognition and Diagnosis: A Comprehensive Empirical Evaluation. In *KR*, pp. 499–508, 1992.
- [22] J. R. Hobbs, M. Stickel, P. Martin, and D. Edwards. Interpretation as abduction. *Artificial Intelligence*, Vol. 63, pp. 69–142, 1993.
- [23] E. Charniak and R. P. Goldman. A Probabilistic Model of Plan Recognition. In *AAAI*, pp. 160–165, 1991.
- [24] P. Singla and P. Domingos. Abductive Markov Logic for Plan Recognition. In *AAAI-11*, pp. 1069–1075, 2011.

- [25] Honglak Lee, Roger Grosse, Rajesh Ranganath, and Andrew Y Ng. Convolutional deep belief networks for scalable unsupervised learning of hierarchical representations. In *Proceedings of the 26th Annual International Conference on Machine Learning*, pp. 609–616. ACM, 2009.
- [26] Geoffrey Hinton, Li Deng, Dong Yu, George E Dahl, Abdel-rahman Mohamed, Navdeep Jaitly, Andrew Senior, Vincent Vanhoucke, Patrick Nguyen, Tara N Sainath, et al. Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups. *Signal Processing Magazine, IEEE*, Vol. 29, No. 6, pp. 82–97, 2012.
- [27] Quoc V Le. Building high-level features using large scale unsupervised learning. In *Acoustics, Speech and Signal Processing (ICASSP), 2013 IEEE International Conference on*, pp. 8595–8598. IEEE, 2013.
- [28] Yangfeng Ji and Jacob Eisenstein. Representation learning for text-level discourse parsing. In *Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)*, pp. 13–24, 2014.
- [29] S. Raghavan and R. J. Mooney. Bayesian Abductive Logic Programs. In *Star-AI 10*, pp. 82–87, 2010.
- [30] E. Ovchinnikova, N. Montazeri, T. Alexandrov, J. R. Hobbs, M. C. McCord, and R. Mulkar-Mehta. Abductive Reasoning with a Large Knowledge Base for Discourse Processing. In *IWCS*, 2011.
- [31] Jun Sugiura, Naoya Inoue, and Kentaro Inui. Recognizing implicit discourse relations through abductive reasoning with large-scale lexical knowledge. In *NLPAR@ LPNMR*, pp. 76–87, 2013.
- [32] Naoya Inoue, Ekaterina Ovchinnikova, Kentaro Inui, and Jerry Hobbs. Coreference Resolution with ILP-based Weighted Abduction. In *COLING*, pp. 1291–1308, 2012.

## 付録

### A 物理シミュレーション時の軌跡生成

ここでは、本稿で用いた物理シミュレータによる物理シミュレーション時の軌跡生成について述べる。なお、この物理シミュレータは株式会社デンソーが作成した（非公開）ものである。

物理シミュレーションにおける歩行者と車両の軌道の計算は [3] の手法に基づき、以下の様な状態変数の式、及びその更新式を用いている。

$$s(t) = \begin{bmatrix} x(t) \\ y(t) \\ v(t) \\ \theta(t) \end{bmatrix} \quad (1)$$

$$s_{person}(t + \Delta t) = \begin{bmatrix} x(t + \Delta t) \\ y(t + \Delta t) \\ v(t + \Delta t) \\ \theta(t + \Delta t) \end{bmatrix} = \begin{bmatrix} x(t) \\ y(t) \\ 0 \\ 0 \end{bmatrix} + \begin{bmatrix} v(t)\cos[\theta(t)] \\ y(t)\sin[\theta(t)] \\ u_1(t) \\ u_2(t) \end{bmatrix} \Delta t \quad (2)$$

$$s_{vehicle}(t + \Delta t) = \begin{bmatrix} x(t + \Delta t) \\ y(t + \Delta t) \\ v(t + \Delta t) \\ \theta(t + \Delta t) \end{bmatrix} = \begin{bmatrix} x(t) \\ y(t) \\ v(t) \\ \theta(t) \end{bmatrix} + \begin{bmatrix} v(t)\cos[\theta(t)] \\ y(t)\sin[\theta(t)] \\ u_1(t) \\ \frac{v(t)}{L}\sin[u_2(t)] \end{bmatrix} \Delta t \quad (3)$$

$$u(t) = \begin{bmatrix} u_1(t) \\ u_2(t) \end{bmatrix} = \begin{bmatrix} a(t) \\ \phi(t) \end{bmatrix} \quad (4)$$

$$P = \{s(0), s(\Delta t), \dots, s(n\Delta t)\} \quad n \text{ は定数} \quad (5)$$

各物体はある時刻  $t$  において 4 次元の状態変数  $s(t)$  をもち、その  $s(t)$  は 2 次元の操作入力  $u$  によって微小時間  $\Delta t$  ごとに遷移していく。その遷移毎の状態変数  $s(t)$  の順序集合が軌道  $P$  である。操作入力  $u(t)$  の式 (4) の  $a$  は加速度、 $\phi$  はステア角を表す。

実際の歩行者は歩行中にすぐさま方向転換を行うことが可能であるのに対して、自動車などの車両は完成や機構の制限を受けて急激な動きの変化はおきない。ゆ

えに、それぞれの状態変数の更新式は、歩行者は式 (2)、車両は式 (3) とする。式 (3) 内の  $L$  は最遠軸距 ( 車両の最前部の車軸から最後部の車軸までの水平距離 ) を表す。

$$u_{None}(t) = \begin{bmatrix} 0 \\ 0 \end{bmatrix} \quad (6)$$

$$u_{Stop}(t) = \begin{cases} \begin{bmatrix} 0 \\ 0 \end{bmatrix} & \dots t < t_s + delay \\ \begin{bmatrix} B \\ 0 \end{bmatrix} & \dots v(t) > 0 \\ \begin{bmatrix} 0 \\ 0 \end{bmatrix} & \dots elsewhere \end{cases} \quad (7)$$

操作入力  $u(t)$  は意思の種類に応じて、(i) 既定の操作入力をそのまま用いるか、(ii) 生成される目標軌道集合  $Q$  を追従するような操作入力  $follow(Q)$  を用いるかのどちらかを選択する。(i) の操作入力では、例えば「意思実行なし」の際の操作入力は式 (6) となり、「停止する」の際の操作入力は式 (7) となる (ただし本稿では「停止する」の意思は用いていない)。一方で (ii) の操作入力では、まず各意思ごとに定められたアルゴリズムで目標軌道が複数生成され、それに沿おうとするような操作入力が動的に生成される。

(ii) についてもは次のような制御式に則って定まる操作入力  $u(t)$  を用いる。

$$e(t) = \begin{bmatrix} e_x(t) \\ e_y(t) \end{bmatrix} = \begin{bmatrix} Q_x(t) - x(t) \\ Q_y(t) - y(t) \end{bmatrix} \quad (8)$$

$$e_\theta(t) = \tan^{-1} \left( \frac{e_y(t)}{e_x(t)} \right) - \theta(t) \quad (9)$$

$$e(t) = \begin{bmatrix} a(t) \\ \phi(t) \end{bmatrix} = \begin{bmatrix} c\kappa_1 + (1 - c)v(t_s) - v(t) \\ \kappa_2 e_\theta(t) \end{bmatrix} \quad (10)$$

$$c = \begin{cases} 1, \dots |e_\theta(t)| \geq th \\ 0, \dots else \end{cases} \quad (11)$$

$$\kappa_1 = 5.0[km/s], \kappa_2 = \frac{1}{\Delta t}, th = \frac{1}{8}\pi \quad (12)$$

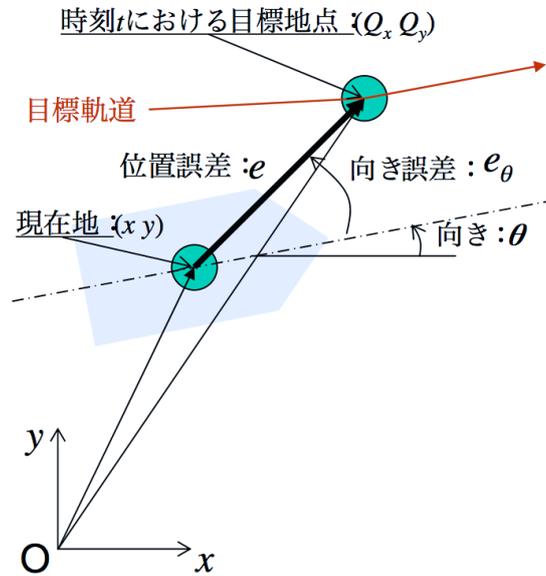


図 8: 目標軌道が与えられたときの操作入力

## B 物理シミュレーション時の衝突判定

ここでは、本稿で用いた物理シミュレータによる物理シミュレーション時の衝突判定について述べる。なお、この物理シミュレータは株式会社デンソーが作成した（非公開）ものである。

衝突判定では、物体を多角形にモデリングした際の端点の1つ以上が、ある時刻  $t$  において他物体の領域内にあれば衝突と判定する。物体 A と物体 B の衝突判定を考えたとき、各物体の頂点座標を  $A = \{a_1, a_2, \dots, a_n\}$ ,  $a_i = [a_{ix}, a_{iy}]^T$ ,  $B = \{b_1, b_2, \dots, b_m\}$ ,  $b_j = [b_{jx}, b_{jy}]^T$  とおき、物体 A と物体 B のそれぞれの頂点についてベクトル  $\alpha$  と  $\beta$  を計算する。

$$\alpha_{ij} = [\alpha_{ijx}, \alpha_{ijy}]^T = a_i - b_j \quad (13)$$

$$\beta_j = [\beta_{jx}, \beta_{jy}]^T = b_{(j+1)\%m} - b_j \quad (14)$$

さらに、 $\alpha_{ij}$  と  $\beta_j$  の内積を求める関数  $f(i, j)$  を考える。

$$f(i, j) = \alpha_{ij} \cdot \beta_j = |\alpha_{ij}| |\beta_j| \cos \gamma = \alpha_{ijx} \beta_{jx} + \alpha_{ijy} \beta_{jy} \quad (15)$$

物体 A の頂点のうち少なくとも 1 つが、物体 B の全ての頂点に対して  $f(i, j) \geq 0$  であれば、衝突していると判断することができる。

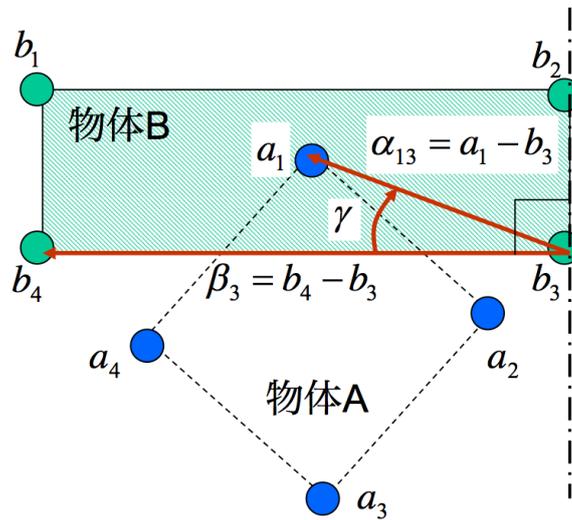


図 9: 衝突判定