

交通オントロジと説明生成に基づく交通危険予測

Traffic Risk Prediction Based on Traffic Ontology and Explanation Generation

高橋 諒*¹ 井之上 直也*¹ 栗谷 康隆*² 山本 風人*¹ 乾 健太郎*¹
 Ryo Takahashi Naoya Inoue Yasutaka Kuriya Kazeto Yamamoto Kentaro Inui

*¹東北大学 Tohoku University
 *²株式会社デンソー DENSO CORPORATION

We develop an Advanced Driver Assistance System (ADAS) that can recognize potential risks in traffic scenes and provide the reasoning for its prediction. In this study, we extend our previous risk prediction model combining logic-based reasoning with physics simulation, based on ontology-based traffic scene understanding research. Our evaluation on a real-life traffic incident database demonstrates the potentiality of our approach.

1. はじめに

自動車の安全に関する分野において、先端運転支援システム (ADAS) が注目を集めている [Lefèvre 14]. ADAS における主要な目標の一つは、交通シーンに潜む危険な状況を検出することであり、特に、(1) 交通シーンにおける様々な物体の相互作用を考慮した移動体の未来の行動変化を予測し、(2) その行動変化に基づき軌道を予測して衝突判定を行う必要がある。例えば、図 1 の交通シーンに潜む危険として、「タクシーが人を乗せるために急停止し、それにより自車が急停止したタクシーに衝突する」ことが考えられるが、これを予測するためには、「タクシーは人の前で止まるものである」「先行するタクシーが急停止したら自車に危険が及ぶ距離である」ということを危険予測システムが理解している必要がある。

また、近年 ADAS には、システムの意味決定の説明を提示することも求められている。全米自動車協会 (AAA) の調査*¹によると、自動運転車の意思決定の根拠が不明瞭であることが理由で、75% の人が自動運転車に乗ることに恐怖心を抱いている。ADAS が意思決定の説明付けを提示することにより、恐怖心の緩和の一助になると考えられる。

交通危険予測における主流なアプローチは、定量情報のみに基づいたシミュレーションにより移動体が未来に取りうる軌道を予測して衝突を検知する手法である。例えば [Broadhurst 05] は、危険を回避する最も安全な軌道を生成するために、各移動体についての未来の軌道をモンテカルロシミュレーション法に基づいて予測した。しかし、定量情報に基づく手法では、前述のような移動体の意思変化を含む予測が難しい。また、予測された危険に対する十分な説明を付けることができない。

一方、幾つかの先行研究は、交通シーンにおける物体同士の複雑な相互作用をモデル化するためにオントロジを用い、それぞれのタスクにおいて一定の成果を取ってきた。例えば [Armand 14] は、都市交通のシーン理解のためのオントロジを構築し、自車がどの物体に注意しなければならないかを予測できるシステムを提案した。しかし、これらの先行研究は、交差点等の限定的な状況を記述するものであり、実世界の多様な交通シーンに対応することを想定していない。

そこで本研究では、まず実世界の多様な交通シーンに対応した交通オントロジを構築する。次に、構築したオントロジに基づいて、仮説推論に基づく移動体の行動予測モデルを構築し、

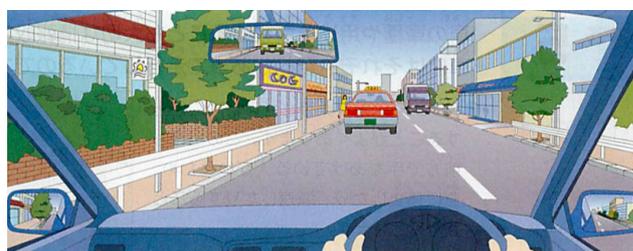


図 1: 潜在的な危険を含む交通シーン。先行するタクシーの左前方に手を上げている女性がいる。(文献 [kik 99] より引用。)

これを物理シミュレーションと融合することで危険を検知するモデルを構築する。本研究では、論理推論に基づく行動予測と物理シミュレーションを併用する [小林 15] のモデルを基盤として、(1) オントロジに基づく交通シーン理解の研究の知見を導入し、(2) 行動予測に用いられる背景知識を拡張する。

仮説推論に基づく行動予測モデルを用いることによって、(1) 予測された行動についての説明を生成することができ、(2) 知識ベースに明示的には記述されていない交通状況においても、不足する状況を仮定によって補いながら推論を進めることができるため、多様な交通シーンに頑健に対応できると予想される。評価実験では、我々の交通危険予測システムの有効性を示すために、実事例に潜在的な危険を付与したデータセットを作成し、評価を行った。

2. 背景

2.1 関連研究

多くの移動体を含む都市交通のシーン理解のために、オントロジに基づいたアプローチが提案されている。[Armand 14] は、都市交通のシーン理解のためのオントロジを構築し、さらに各移動体のコンテキスト中での状態や取るべき行動を推論できるように規則を記述し、自車がどの物体に注意しなければならないかを予測できるシステムを提案した。[Mohammad 15] は、危険評価のためのオントロジを構築し、特に前方に歩行者がいる交通シーンにおいて、その歩行者がどれだけ危険であるかを予測する実験でシステムの有効性を確かめた。[Zhao 15] は、危険を回避し、安全な意思決定を下すためのオントロジを構築し、特に信号により統制されていない交差点と狭い道路での意思決定を実時間で下すことができることを確認した。

オントロジに基づいたほとんどのアプローチは記述論理 (De-

Contact: 6-6-05 Aramaki Aza Aoba, Aobaku, Sendai, Miyagi 980-8579, Japan. ryo.t@ecei.tohoku.ac.jp

*¹ <http://publicaffairsresources.aaa.biz/wp-content/uploads/2016/02/Automotive-Engineering-ADAS-Survey-Fact-Sheet-FINAL-3.pdf>

scription Logic) を形式的な基盤とするオントロジ記述言語を利用している。記述論理はその宣言的な表現力を利点に持ち、記述された知識は人間および計算機が同時に解釈可能であり、交通危険予測の結果が説明的である。しかし、これらの先行研究には、センサー機器による観測情報が完全であるという仮定がおかれている。ADAS に搭載されることになる物体検出・認識器の進歩は昨今著しいが [Ambardekar 14], 誤認識は当然発生し得るため、不完全な観測を上手く扱える枠組みが必要である。また、これら先行研究の枠組みは限定的なシーンを理解するためのものであり、実世界の様々な交通シーンに頑健に対応することを想定していない。

2.2 仮説推論

仮説推論とは最良の説明(仮説)を導く推論であり、診断、自然言語理解など、主に事象の説明が必要となる分野で広く用いられている [Hobbs 93]。形式的には次のように定義される。

入力: 背景知識 B と観測 O 。ただし、 B, O は一階述語論理式の集合。

出力: 仮説 H 。ただし、 H は $H \cup B \models O, H \cup B \not\models \perp$ を満たす原子論理式の連言。

この条件を満たす H を候補仮説と呼び、その中で最良の仮説を解仮説と呼ぶ。背景知識 B と観測 O に対する解仮説 $\hat{H}_{B,O}$ は、候補仮説の集合 \mathcal{H} の中で最小のコストを持つ候補仮説であり、 $\hat{H}_{B,O} = \arg \min_{H \in \mathcal{H}} Cost_{B,O}(H)$ と定義される。ここで、 $Cost_{B,O}(H)$ は候補仮説 H が持つコストを返す関数であり、本稿では、重み付き仮説推論 [Hobbs 93] の評価関数を用いる。重み付き仮説推論では、観測 O と仮説 H は存在限量されたリテラルの連言として表され、各リテラルは正の実数のコストを持つ(以後、 $l_i^{8.100}$ のように表記する)。背景知識 B はホーン節の集合からなり、前件のリテラルには正の実数の重みが割り当てられている(以後、 $l_1^{0.6} \wedge l_2^{0.6} \Rightarrow l_3$ のように表記する)。推論の手続きとコストの計算の詳細は文献 [山本 12] を参照されたい。

なお、定理証明の観点では、仮説推論は「定理 O に対し、背景知識 B を用いて最良の(証明されない命題を含む不完全な)証明 $\hat{H}_{B,O}$ を探索する問題」であり、仮説可能な定理証明器(abductive theorem prover)の一種とみなすことができる。

3. 提案手法

本稿では、交通シーンにおける危険予測問題を次のように定義する。

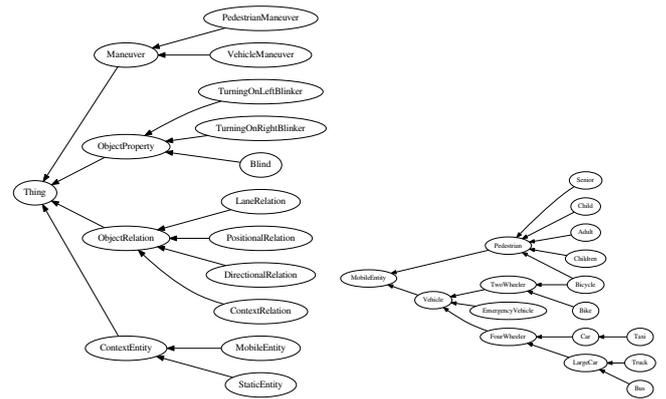
入力: 潜在的な危険を含む交通シーンの記述 s とシーン内の各物体の定量情報 E 。ただし、 s は存在限量されたリテラルの連言で、 E は 3 次元形状・位置・速度の三つ組の集合。

出力: 危険の説明(自車にとっての危険の要因だと考えられる物体 x とその行動 m の組)。

交通シーンの記述 s は 3.2 節で述べるオントロジに基づいて、定量情報 E から自動的に生成される。

なお本研究では、昨今の物体検出技術等の進捗状況より [Ambardekar 14], 映像に基づく物体認識や LiDAR 等の出力を入力として仮定し、認識結果に基づいて、危険予測を首尾よく行う方法論に焦点を当てる。

これ以降、危険予測を行うための全体の枠組みについて説明し(3.1 節)、構築した交通オントロジ(3.2 節)と知識ベース(3.3 節)、交通シーンの記述 s から各移動体 x_i の将来取りうる行動 m_i を推論するモデル(3.4 節)について説明する。



(a) 上位階層. (b) 移動体についての分類階層.

図 2: 構築した交通オントロジの一部.

3.1 論理推論・物理シミュレーションの統合的な危険予測モデル

我々の交通危険予測モデルは、[小林 15] が提案した危険予測モデルに基づく。小林らのモデルは、(1) 交通シーンの記号的な情報に基づいて移動体の未来の行動変化を予測する論理推論部と、(2) その行動変化に基づいて未来の軌道を予測して衝突判定を行う物理シミュレーション部、から構成される。それぞれが予測を分業し、お互いの予測結果を相補的に利用し合うことにより、より精緻な危険予測を狙っている。

図 1 を例として、具体的な処理の流れを説明する。(1) 論理推論部が、「タクシーの左前方に人がいる」という観測情報からタクシーの急停止の可能性を予測する。(2) 物理シミュレーションにより、急停止するタクシーや直進する自車の軌道を生成し、自車とタクシーの衝突を検知する。(3) 論理推論部が、自車とタクシーの未来の衝突から、自車が回避行動を取ることを予測する。終了条件を満たすまでこのようなループ処理を続け、最終的に自車と衝突する物体を危険要因物体として出力する。

本稿で提案する交通危険予測モデルは、小林らのモデルにおける論理推論部を、3.4 節で提案するモデルに置き換えたものである*2。

3.2 交通オントロジ

2.1 節で述べたように、交通シーン理解の文脈で提案されたオントロジは限定的なシーン(例えば、交差点等)を表現する目的で設計されており、実環境において遭遇するさまざまな交通シーンに対して頑健に対応できるかは自明でない。

本稿では、実世界の交通危険予測を視野に入れた、行動予測のためのライトウェイトな交通オントロジを構築する。近年、オントロジ記述言語として Web Ontology Language (OWL) が広く用いられているが、本研究では推論を一階述語論理における仮説推論に基づいて行うため、OWL の代わりに一階述語論理を用いて記述した。道路構造のオントロジの設計にあたっては、道路環境の抽象的なモデルとして提案されている、グラフ構造に基づいたモデル [Knaup 10] を参考にした。

我々が構築したオントロジの一部を図 2 に示す。矢印はその向きで is-a 関係を表している。図 2a の上位階層が示すように、エンティティの属性やエンティティ同士の関係の語彙を定義するために独立の階層を用意している。図 2b は交通に関係

*2 物理シミュレーションの結果を受け取って推論する部分については、論理推論部の予測結果が決定的である(衝突するなら避けるか停止する)ため、単に手続きの中に組み込むことで代用した。

する移動体 (*MobileEntity*) についての分類階層を表している (以降, 移動体は *MobileEntity* 以下のエンティティを指す). 分類の粒度の指針は, 人間が交通シーンの危険性を考える上でどのように移動体を分類するかを考察に基づく. 例えば, タクシーは乗用車とは違い, 客を乗せるために急停止しやすいという知識を表現するために, これらは分けて考える必要がある.

3.3 知識ベース

3.2 節で設計したオントロジを用いて, 3 種類の背景知識を構築した.

(1) 行動へ至る状況の知識: ある移動体の行動と, その行動が引き起こされる移動体の周辺状況の関連について記述した知識である. 例えば, 「車両 v は, v の属す車線 l 上, かつ v の前方にいる大型車 c_l を追い越すかもしれない」という知識を, $\forall v, c_l, l. \text{Vehicle}^{0.2}(v) \wedge \text{LargeCar}^{0.2}(c_l) \wedge \text{InFrontOf}^{0.2}(v, c_l) \wedge \text{On}^{0.2}(v, l) \wedge \text{On}^{0.2}(c_l, l) \Rightarrow \text{HasWill}(\text{Overtake}, v, c_l)$. のように記述する. 前件のリテラルの重みを調節することにより, 状況に含まれる各証拠の重要度を反映することができる.

(2) 概念階層の知識: オントロジの階層構造そのものを指す. 一階述語論理式で記述するために, 組の集合に分解した上で記述する. この知識を前述の知識と組み合わせることで, 適切な抽象度で推論を行える. (例: $\forall x. \text{Taxi}^{1.2}(x) \Rightarrow \text{Car}(x)$. (タクシーは乗用車である.))

(3) 行動の知識: 形式的には「行動 \Rightarrow 行動」の知識だが, 前件のリテラルの重みを調節することで, 行動自体の起こりやすさを「行動へ至る状況の知識」とは独立に定めることができる. (例: $\forall v. \text{HasWill}^{1.2}(\text{Stop}, v, \text{None}) \Rightarrow \text{Maneuver}(\text{Stop}, v, \text{None})$. (停止する意思がある移動体 v は, 停止操作を行う))

「行動へ至る状況の知識」については, 推論の頑健性を高めるため, 抽象度の高い知識 (例えば, 「車両は急停止する」と) と抽象度の低い知識 (例えば, 「車両の左側に車線があり, 大型先行車がいる場合は車線変更する」) を段階的に構築し, 仮説推論の評価関数において, より特殊な知識を用いた説明をより良いと評価するような仕組みを取り入れた. これにより, 具体的な説明付けにより行動予測が行えない場合には抽象的な推論に back-off するがその分だけ推論のスコアは下がる, という推論機構を実現する.

また, 本研究では, 推論速度向上のため, 重み付き仮説推論 [Hobbs 93] の評価関数を拡張し, (1) 仮説リテラル同士の単一化のコストは ∞ , (2) *Maneuver*/3 述語以外の観測リテラルからの後ろ向き推論のコストが ∞ , となるような評価関数を用いた. これは, $O \cup B$ を背景知識として, *Maneuver*/3 述語に対する最良の証明探索を行っていることに相当する.

なお, 我々の手法がベースとしている [小林 15] も重み付き仮説推論を用いており, 我々と同様の種類の知識を構築しているが, 公理の形が異なっている. 小林らは, 我々とは逆向きの「行動 \Rightarrow 状況」のような形式を用いているが, この形式では, 3.4 節で述べるような仮説推論の利点「証明できない命題を仮説して行動を予測する」を活かせないという問題がある.

3.4 仮説推論に基づく行動予測

図 1 を例として具体的な行動予測の流れを説明する (図 3). まず, 前処理として, 全ての移動体 x について, 観測 O に $\text{Maneuver}(m_i, x_i, obj_i)^{s100}$ を追加する. これは, 「与えられたシーンの記述から尤もらしい各移動体の行動 (x_i は obj_i を対象に m_i する) を求めよ」ということを意味する. この観測 O と 3.3 節で述べた背景知識 B を入力として仮説推論を実行する. 推論の流れは概ね次の通りである. (1) 「行動の知識」を用いて, $\text{Maneuver}(\cdot)$ から $\text{HasWill}(\cdot)$ が後ろ向き推論される. (2) 「行動へ至る状況の知識」を用いて, $\text{HasWill}(\cdot)$ から状況

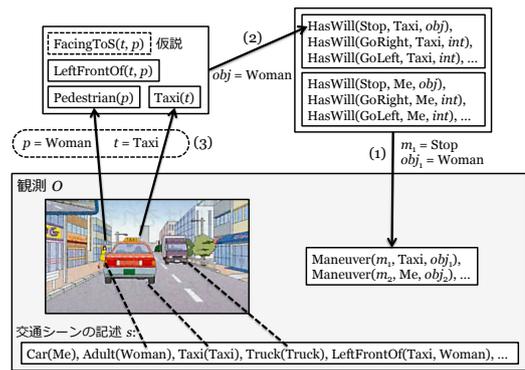


図 3: 仮説推論に基づく行動予測の枠組みの動作例.

を表すようなりテラルが推論される. (3) 「概念階層の知識」を用いて, これらの仮説リテラルと観測リテラルを単一化する.

仮説推論を危険予測問題に用いることの利点は, 主に二つある. 一つ目は, 問題解決に必要な推論を宣言的に記述された背景知識から導けることである. 人手で問題解決の手続きを明示的に与えることなく, 部品の知識を用意しておけば, 仮説推論エンジンが自動的に最良の仮説を返す.

二つ目に, 仮説推論ならば, 観測に含まれていない情報も補った柔軟な推論が可能である. 例えば図 3 においては, $\text{FacingToS}(\text{Taxi}, \text{Woman})$ (タクシー (Taxi) から見て女性 (Woman) がこちらを向いている) が補われた情報である. このような情報は行動の予測に極めて有効にも関わらず, 最先端の画像処理技術を用いても正確に得ることが難しく, 仮説推論によって柔軟に補うことは合理的であると考えられる. 本研究では, 重みの調整を人手で行ったが, 今後は機械学習に基づく調整 [山本 12] を行う予定である.

4. 評価実験

実世界の多様な交通シーンにおける提案モデルの有効性を評価するために, 実在のヒヤリハット事例を用いて提案モデルの予測性能を評価した結果を報告する.

4.1 実験設定

評価用データとして, 東京農工大学により公開されているヒヤリハットデータベースの動画 (2014 年分) *3 から, 特に周囲の状況から危険が予測できると考えられるシーンを 40 件抽出した. 各シーンについて, ヒヤリハットの 2 秒前の交通状況を人手により 3 次元空間に擬似的にモデリングし, 移動体の速度情報を自転車速度などとの比較から付与した. 交通シーンの記述 s は, これらの付与された情報から, 3.2 節の交通オントロジにしたがって自動的に生成した. また, ヒヤリハットの要因となる物体とその行動の情報も同様に人手で付与した. 行動のラベルについては, 我々の交通オントロジ上の 10 種類の述語 (図 2 (a) における *Maneuver* 以下の述語) を用いた.

知識の構築および重みの調整にあたっては, 抽出したヒヤリハット事例 40 件のうち 15 件と, 中部日本自動車学校より発行されている学科試験の問題集 [kik 99] を開発データとして用い, 定量評価のために残りのヒヤリハット事例 25 件を用いた. 推論エンジンには Phillip [山本 15] を用いた. なお, 本評価実験では, 物理シミュレーションに簡易なシミュレーション機構を用いたため, 枠組み全体の評価については, 予備的な検討に留めた.

*3 <http://web.tuat.ac.jp/~smrc/drcenter.html>

表 1: 行動予測の性能

モデル	Precision	Recall	F
MAJORITY	24.0 (6/25)	24.0 (6/25)	24.0
DEDUCTIVE	60.0 (15/25)	60.0 (15/25)	60.0
ABDUCTIVE	64.0 (16/25)	64.0 (16/25)	64.0

4.2 交通行動予測の評価実験

まず, 3.4 節の行動予測モデル (以後, ABDUCTIVE と呼ぶ) を個別に評価した結果を報告する. 比較対象のモデルとして, (1) 開発セットで最も多い行動 (Stop) を出力するモデル MAJORITY と, (2) 先行研究の常套手段である, 仮説不可能な定理証明器を用いたモデル DEDUCTIVE を用いる.

実験結果を表 1 に示す*4. まず, MAJORITY モデルの評価結果より, 本評価実験で用いられる問題の難易度が比較的高いことがわかる. これに対し, 提案手法のモデル ABDUCTIVE では, ある程度の精度を出せたことが確認できる. また, ABDUCTIVE と DEDUCTIVE の間では, 期待に反して, ほとんど性能の差がないことがわかった. これは, 3.3 節で述べたように, 抽象的な推論に back-off できるような知識体系になっていることで, DEDUCTIVE でも擬似的に「仮説可能な」定理証明が行われ, 両者の差が縮まったものと考えられる. また今回のデータセットには, 我々が想定している推論に必要な観測が十分に含まれていて, それを補う必要のある問題が少ないことも原因と考えられる.

4.3 物理シミュレーションとの併用の予備実験

全体の枠組みの評価に向けた予備的な実験として, 仮説推論で正しく行動予測を行えた事例 16 件について, 物理シミュレーションに行動予測の結果を与えて移動体の軌道を予測させた. その結果, 現状では多くの事例において意図したとおりに軌道生成が行われず, 自車との衝突の危険を検知できないことがわかった (16 事例中 5 事例). 例えば, データベース ID=176 では, 図 4 (a) のような軌道が生成されていた. 我々が期待していた予測は, 「自車 (Me) はそのまま直進, Car1 がしばらく進み停止, 自車と Car1 が衝突」なのだが, 実際に行われた予測は, 「Car1 がその場で停車, 自車と Car1 が衝突しない」であった. 物理シミュレーションへの入力には, どの程度「急に」停止するかが指定されておらず, 単に初期位置で停止してしまっただけのため, 意図どおりの予測とはならなかった.

一方で, 意図どおりに軌道が生成され, 正しい予測が行われた事例も存在した (16 事例中 4 事例). 例えば, データベース ID=4311 では, 図 4 (b) に示すように, 仮説推論により, 進行中の Car1 が停車中の先行車 Car3 のために車線変更することが予測され, その軌道を正しく再現できた. その後, Car1 は自車 (Me) と衝突することが予測され, 正しく危険が予測されていた.

今後は, 生成する軌道の精度を向上させるために, 車両の軌道予測の研究で用いられている最新の軌道生成モデル [Lefèvre 14] を利用し, より精緻な軌道を描く物理シミュレータを導入し, 評価を続けていく予定である.

5. おわりに

本研究では, 実世界の交通危険予測を視野に入れた交通行動予測のための交通オントロジを提案し, 重み付き仮説推論に基

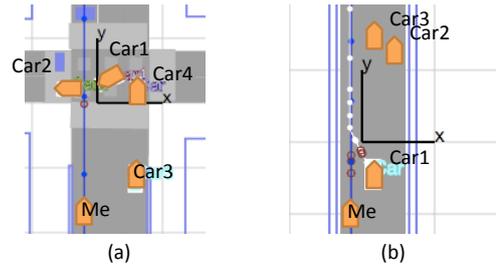


図 4: 物理シミュレーションにより予測された軌道の例.

づく行動予測の枠組みを構築し, これを既存の交通危険予測システムと統合した. 本手法の強みは, 重み付き仮説推論に基づく行動予測により, センサー機器の不確実性を自然に補うことができる点である. また, 実世界のヒヤリハット事例により提案モデルを評価した結果, ある程度の精度でヒヤリハットを予測可能であることがわかった.

今後の課題として, 交通危険の説明生成問題に加えて, 交通シーンの危険性の識別にも併せて取り組む予定である. また, 提案モデルの性能向上のために, 知識ベースの重みパラメータの機械学習による自動調整や, より精緻な軌道生成を行う物理シミュレーションの導入などにも取り組む予定である.

謝辞 本研究は JSPS 科研費 15H01702 の助成を受けたものです.

参考文献

- [Ambardekar 14] Ambardekar, A., Nicolescu, M., Bebis, G., and Nicolescu, M.: Vehicle classification framework: a comparative study, *EURASIP Journal on Image and Video Processing*, Vol. 2014, No. 1, p. 29 (2014)
- [Armand 14] Armand, A., Filliat, D., and Ibanez-Guzman, J.: Ontology-based context awareness for driving assistance systems, in *2014 IEEE Intelligent Vehicles Symposium Proceedings*, pp. 227–233, IEEE (2014)
- [Broadhurst 05] Broadhurst, A., Baker, S., and Kanade, T.: Monte Carlo road safety reasoning, in *Intelligent Vehicles Symposium, 2005. Proceedings. IEEE*, pp. 319–324 (2005)
- [Hobbs 93] Hobbs, J. R., Stickel, M. E., Appelt, D. E., and Martin, P.: Interpretation as abduction, *Artificial Intelligence*, Vol. 63, No. 1, pp. 69–142 (1993)
- [kik 99] 危険予測マスター, 中部日本自動車学校 (1999)
- [Knaup 10] Knaup, J. and Homeier, K.: RoadGraph - Graph based environmental modelling and function interpretation situation analysis for driver assistance systems, in *13th International IEEE Conference on Intelligent Transportation Systems*, pp. 428–432, IEEE (2010)
- [Lefèvre 14] Lefèvre, S., Vasquez, D., and Laugier, C.: A survey on motion prediction and risk assessment for intelligent vehicles, *Robomech Journal*, Vol. 1, No. 1, p. 1 (2014)
- [Mohammad 15] Mohammad, M. A., Kaloskamps, I., Hicks, Y., and Setchi, R.: Ontology-based Framework for Risk Assessment in Road Scenes Using Videos, *Procedia Computer Science*, Vol. 60, pp. 1532–1541 (2015)
- [Zhao 15] Zhao, L., Ichise, R., Yoshikawa, T., Naito, T., Kakinami, T., and Sasaki, Y.: Ontology-based decision making on uncontrolled intersections and narrow roads, in *2015 IEEE Intelligent Vehicles Symposium (IV)*, pp. 83–88, IEEE (2015)
- [小林 15] 小林颯介, 井之上直也, 栗谷康隆, 乾健太郎, 近藤敏之, 安部克則, 奥野英一: 物理モデルと論理推論の統合による運転シーンの潜在的危険の予測, 自動車技術会 2015 年春季大会学術講演会, pp. 1076–1081 (2015)
- [山本 12] 山本風人, 井之上直也, 渡邊陽太郎, 岡崎直観, 乾健太郎: 誤差逆伝播を利用した重み付き仮説推論の教師あり学習, 情報処理学会, No. 9, pp. 1–8 (2012)
- [山本 15] 山本風人, 井之上直也, 乾健太郎: 言語処理のための仮説推論エンジン Phillip, 言語処理学会 第 21 回年次大会, pp. 377–380 (2015)

*4 Precision, Recall はそれぞれ, ヒヤリハットの要因物体に対するシステムの予測結果のうち正しかった予測結果の割合, ヒヤリハットデータに付与された要因行動のうち正しく予測された結果の割合を示す.