

神奈川工科大学
工学教育研究推進機構

先進自動車研究所

2020 年度
研究報告

走行環境リスク予測のためのコンテキストセンシングに関する研究

先進自動車研究所 井上秀雄
先進自動車研究所 上原健一
株式会社 NTT データ オートモビリジェンス研究所

目次

1. 背景と目的	1
2. セイフティクッションアプローチ	2
3. PEGASUS との対応	10
4. データ駆動型リスク予測アルゴリズムフレームワーク	12
5. Data driven AI	14
5.1. ニアミスデータベースの構築	15
5.1.1. システム構成	16
5.1.2. ニアミスシーンデータベーステーブル構成	17
5.2. ニアミスデータの利用	18
5.2.1. リスク予測モデルデータセット	19
5.2.2. GARDEN DB	20
6. Context sensing	23
6.1. コンテキストセンシングにおける 13 項目の危険因子の取得方法	24
6.1.1. 検討結果	25
6.1.2. 課題	29
6.2. 車両制御システムの検討	31
7. シミュレーション環境の検討	33
8. まとめ	36
参考文献	37

1. 背景と目的

近年、高齢者による交通事故報道などを契機に、高齢者の運転免許証自主返納を促す社会的風潮となっている。2019年に自主返納した人の数が、過去最多の60万1022人（前年比17万9832人増）となった。

しかし、自動車が生活に欠かせない交通手段となっている地域では、返納が進まないなどの地域格差が問題となっている。そこで、自動運転などの運転支援技術の開発が急務になっている。

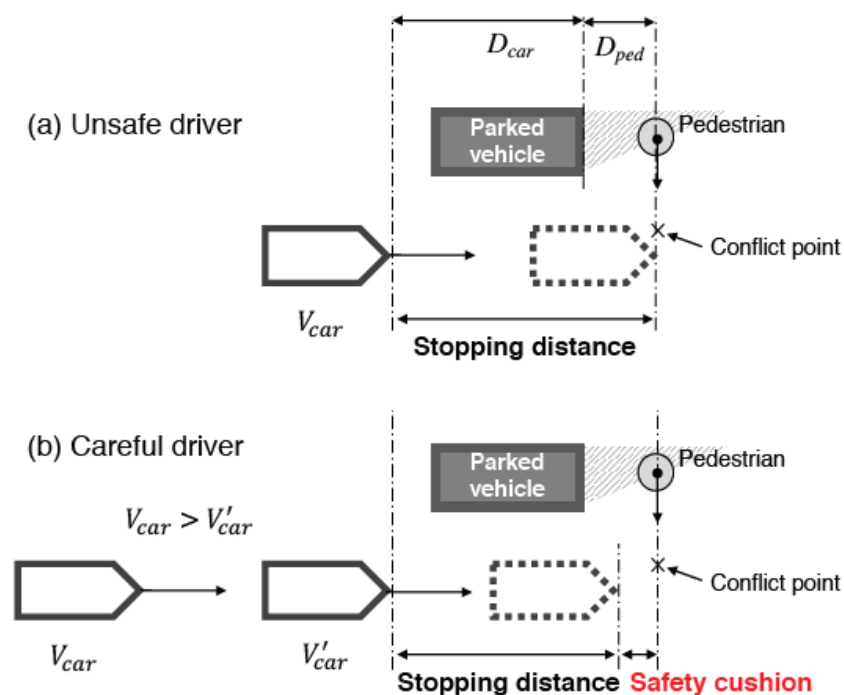
運転時に危機的状況に陥った際の自動回避システムとして、AEB（衝突被害軽減ブレーキ）の実用化が進んでいるが、さらなる安全のためには、危機的状況に陥ること自体を回避することが望ましい。

熟練ドライバーは、走行環境文脈からリスクを予知し、あらかじめ減速するといった予防的行動をとることで危機的状況に陥ることを未然に防いでいる。本研究では、この熟練ドライバーが行うような、交通環境文脈認識～潜在的リスク予測～予防的措置（減速等）といったいわゆる「かもしれない運転」をシステムで実現することを目的としている。

なお、本研究では、交通環境文脈認識のことをコンテキストセンシングと呼称する。

2. セイフティクッションアプローチ

既往研究⁽²⁾で提示されたセイフティクッションについて、「Fig. 2-1 Safety cushion の定義」の駐車車両の車陰から歩行者が飛び出してくる例を基に説明する。「Fig. 2-1 Safety cushion の定義」の Careful driver(「Fig. 2-1 Safety cushion の定義」の下図)は、セイフティクッションアプローチによる運転を制御する例であり、Unsafe driver(「Fig. 2-1 Safety cushion の定義」の上図)は制御しない例である。Unsafe driver では、駐車車両の車陰から歩行者が飛び出してくる可能性を考慮せず、自車の速度を減速しない場合の停止距離(Stopping distance)を示し、緊急ブレーキが必要な例である。一方、Careful driver では、駐車車両の車陰から歩行者が飛び出してくる可能性を考慮し、自車の速度を減速する場合の停止距離(Stopping distance)を示し、スムーズで安全な車両の停止が可能な例である。Unsafe driver と Careful driver とで車両の停止距離(Stopping distance)の差がセイフティクッション(Safety cushion)である。つまりセイフティクッションは、死角からの歩行者や自転車の突然の飛び出しなどの予期しない交通状況が発生した場合に十分な制動距離を確保するための余裕である。



(2)より引用

Fig. 2-1 Safety cushion の定義

既往研究⁽²⁾では、セーフティクッションを表す指標として、ドライバと歩行者(自転車)との間で発生するニアミス事象に対する時間的切迫度を表すセーフティクッションタイム(SCT; Safety cushion time)を次式で表現している。

$$SCT = \frac{\left\{ (D_{car}(t^*) + D_{ped}(t^*)) + \frac{V_{car}^2(t^*)}{2a_{max}} \right\}}{V_{car}(t^*)} - \tau$$

t^* は歩行者が飛び出した時刻, D_{car} は死角を生む角と自車の間の距離, D_{ped} は死角を生む角と歩行者の間の距離, V_{car} は歩行者が飛び出した時刻の自車の速度, a_{max} は緊急自動ブレーキの作動に関わる平均減速度(-6 m/s²), τ (0.25sec)はむだ時間を示す。セーフティクッションタイム(SCT; Safety cushion time)とは言い換えれば, 緊急自動ブレーキがあと何秒遅れていたら, 衝突が起きてしまうかという時間であり, 時間的切迫度を定量化する指標である。

既往研究⁽⁴⁾⁽⁷⁾では、ヒヤリハットデータを教師データとし、SCTを予測する試みがなされており、以下の重回帰式が提示されている。

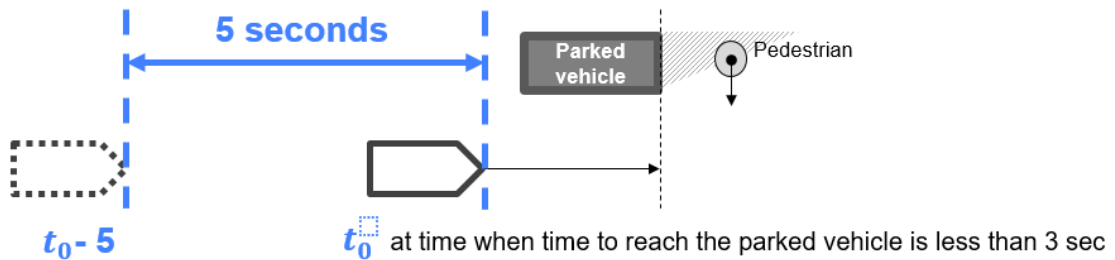
$$Total-SCT = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \beta_4 X_4 + \dots + \beta_{14} X_{14}$$

$$Total-SCT = \beta_0 + \underbrace{\text{Driving behavior}}_{\text{controllable}} + \underbrace{\text{Driving Context}}_{\text{Risk scenario}}$$

ここで β_0 は切片項であり、 X_1 はドライバのふるまいを表す因子（LHP）である。

LHPはLong-term Hazard Potentialの略称でニアミス前5秒間におけるドライバの行動を速度に関わる指標の重みづけ線形和によって表現したもので以下の式で表される。

$$LHP = w_1 \cdot v_{max} + w_2 \cdot \tilde{v} + w_3 \cdot \dot{v}$$




Parameter	Description
v_{max}	Maximum of velocity in interval $t \in [t_0-5, t_0]$ normalized to $v_{max} \in [0, 1]$
\tilde{v}	Median of velocity in interval $t \in [t_0-5, t_0]$ normalized to $\tilde{v} \in [0, 1]$
\dot{v}	Mean of acceleration in interval $t \in [t_0-3, t_0]$ normalized to $\dot{v} \in [0, 1]$

(7)より引用

Fig. 2-2 Long-term Hazard Potential

X₂~X₁₄ は下表に示す走行環境文脈を13項目に分類した危険因子（Ygapを除く）であり、これらがコンテキストセンシングの対象となる危険因子である。

Table 2-1 危険因子

Context properties	type	Definition
Static properties	Ygap [m]	Blind object to lateral distance [m]
	Area type	Residential area/Urban and business area/Rural area/Other
	Road type	Other/One way/Both way
	Sidewalk type	
	Intersection type	Other/ T and Y types/ 4 type/ More/ Straight
	Road width	Lanes: other/ 1/ 2/ 3/ 4/ 5 over
	Crosswalk	Without/ With
Dynamic properties	Parked vehicle	0~2/3~5/More
	Pedestrian	0~2/3~9/More
	Traffic	0~2/3~9/More
	Leading vehicle	Without/ With
Other properties	Time	6:00~10:00/10:00~16:00/16:00~20:00/20:00~6:00
	Weather	Sunny and cloudy/Rain and Snow
	Age of pedestrian	Unknown/Elderly/Mature/Young/Child

(4)より引用

危険因子の Sidewalk type は歩道形状の分類であり，具体例を下図に示す．



(4)より引用

Fig. 2-3 Sidewalk type

重回帰式の β_1 は LHP に関する偏回帰係数であり， $\beta_2 \sim \beta_{14}$ は危険因子 $X_2 \sim X_{14}$ に関する偏回帰係数である．各偏回帰係数は，既往研究⁽⁴⁾によって以下のシナリオについて算出されている．

- 無信号交差点角の死角からの歩行者の道路横断シナリオ
- 無信号交差点角の死角からの自転車の道路横断シナリオ
- 駐車車両背後の死角からの歩行者の道路横断シナリオ

無信号交差点角の死角からの歩行者の道路横断シナリオにおける危険因子毎の偏回帰係数を以下に示す。シナリオ毎に寄与度の高い危険因子の偏回帰係数が求められている。

Table 2-2 偏回帰係数（対歩行者 無信号交差点）

	Variable	Coefficient β_i	P-value
Standard SCT	Intercept (β_0)	8.9275	2.60e-14
Driver behavior	LHP	-3.7247	< 2e-16
	Ygap	-2.5815	2.16e-14
	Vel. limit		
	Area type		
	Road type	-1.8832	0.0108
	Sidewalk type	-1.5481	0.0113
	Intersection type		
Driving context	Road width	-0.9674	0.1297
	Cross walk		
	Parked vehicle	-3.3446	0.0209
	Pedestrian		
	Traffic	-4.6141	0.1317
	Leading vehicle		
	Weather		
	Time		

(4)より引用

無信号交差点角の死角からの自転車の道路横断シナリオにおける危険因子毎の偏回帰係数を以下に示す。

Table 2-3 偏回帰係数 (対自転車 無信号交差点)

	Variable	Coefficient β_i	P-value
Standard SCT	Intercept (β_0)	10.9027	< 2e-16
Driver behavior	LHP	-2.5334	8.17e-14
	Ygap	0.3677	1.86e-11
	Vel. limit	-0.8428	0.15008
	Area type		
	Road type		
	Sidewalk type		
	Intersection type	-2.7685	0.00178
Driving context	Road width	-0.7789	0.04344
	Cross walk		
	Parked vehicle		
	Pedestrian		
	Traffic	-1.9014	3.43e-05
	Leading vehicle	-1.1611	0.04768
	Weather		
	Time	-1.8307	0.00550

(4)より引用

駐車車両背後の死角からの歩行者の道路横断シナリオにおける危険因子毎の偏回帰係数を以下に示す。

Table 2-4 偏回帰係数 (対歩行者 駐車車両)

	Variable	Coefficient β_i	P-value
Standard SCT	Intercept (β_0)	8.4584	< 2e-16
Driver behavior	LHP	-3.5717	< 2e-16
	Ygap	-2.2005	1.11e-12
	Vel. limit	-1.3062	0.000353
	Area type		
	Road type		
	Sidewalk type	-0.9588	0.010800
	Intersection type		
Driving context	Road width		
	Cross walk		
	Parked vehicle	-2.9302	0.068102
	Pedestrian		
	Traffic	-2.0078	0.094230
	Leading vehicle		
	Weather	-0.9431	0.127466
	Time	-0.8084	0.019020

(4)より引用

本研究では、コンテキストセンシングによって危険因子を認識し、SCT 予測モデルによってリスク値を算出するアプローチをとるものとする。

3. PEGASUS との対応

ドイツの自動運転の安全性に関する産学共同プロジェクトである PEGASUS RESEARCH PROJECT では、6レイヤのシナリオ構造が示されている⁽⁵⁾。

Table 3-1 PEGASUS シナリオ構造

Layer	Title	具体例
Layer 6	Digital Information	V2X デジタル地図 等
Layer 5	Environment	天候 光条件 等
Layer 4	Objects	車両 歩行者 等
Layer 3	Temporary manipulation of Layer 1 and Layer 2	一時的な交通規制 等
Layer 2	Traffic Infrastructure	交通信号 等
Layer 1	Road-Level	道路構造 等



(5)より引用

Fig. 3-1 PEGASUS シナリオ構造

13項目の危険因子と PESASUS 6レイヤとの対応を整理した。
結果を下表に示す。

Table 3-2 13項目の危険因子と PESASUS レイヤとの対応

#	危険因子	PEGASUS レイヤ
1	Area type	対応なし
2	Road type	Layer 1
3	Sidewalk type	Layer 1
4	Intersection type	Layer 1
5	Road width	Layer 1
6	Cross walk	Layer 1
7	Parked vehicle	Layer 4
8	Pedestrian	Layer 4
9	Traffic	Layer 4
10	Leading vehicle	Layer 4
11	Time	Layer 5
12	Weather	Layer 5
13	Age	対応なし

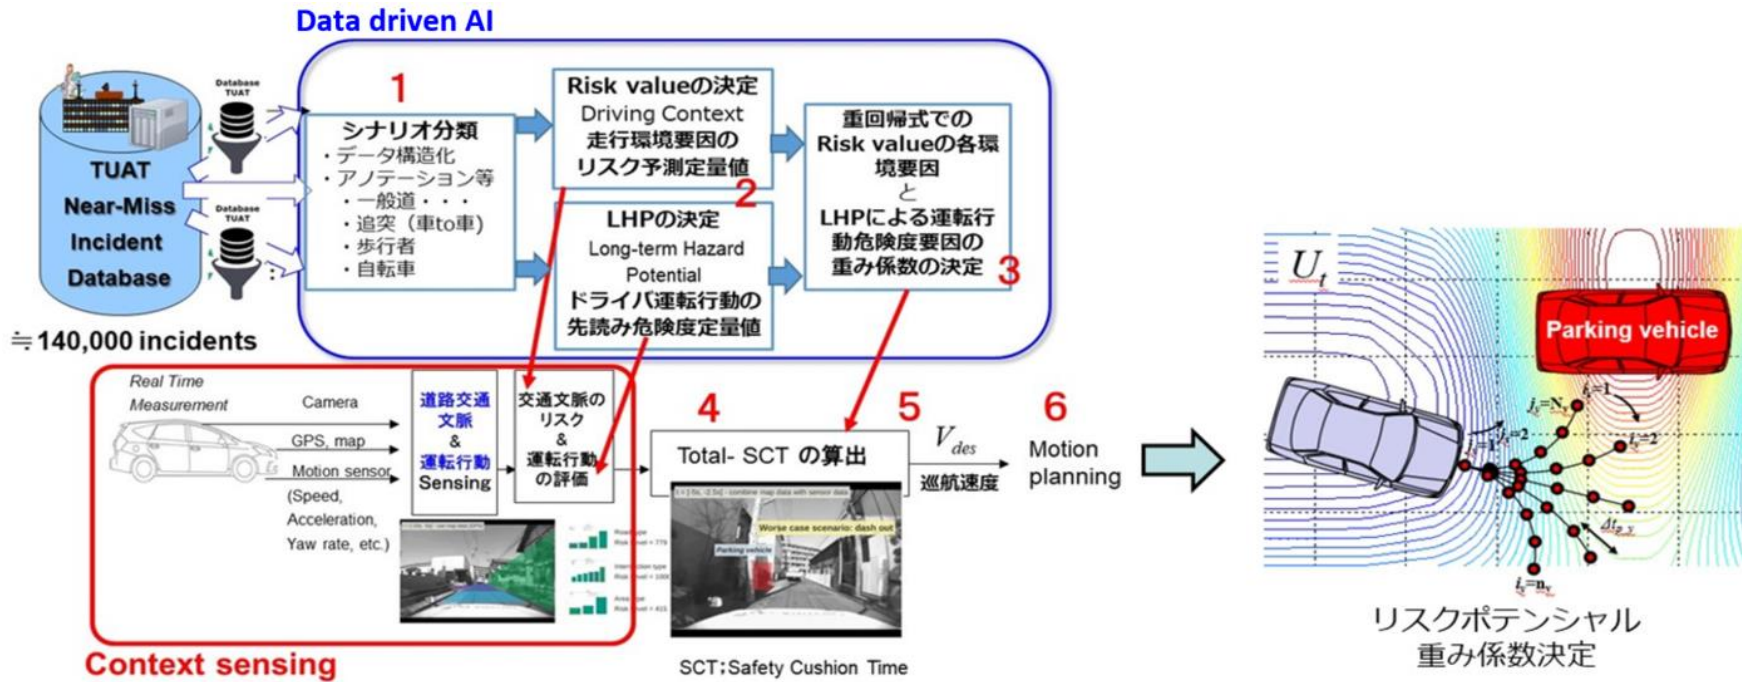
4. データ駆動型リスク予測アルゴリズムフレームワーク

既往研究⁽⁷⁾によって提示された、セイフティクッションアプローチに基づいたデータ駆動型リスク予測アルゴリズムフレームワーク (Dynamic Risk Management ; DRM) の全体図を「Fig. 4-1 データ駆動型リスク予測アルゴリズムフレームワーク」に示す。

データ駆動型リスク予測アルゴリズムフレームワークは、Data driven AI と Context sensing に大別される。

Data driven AI は、ヒヤリハットデータをシナリオ毎に分類し、各シナリオの危険因子と LHP を算出の上、シナリオにおける SCT 実測値を目的変数、危険因子と LHP を説明変数とした重回帰分析を行い、Total-SCT を予測するための重回帰式を出力する。

Context sensing は、実車にて車速から運転行動の評価 (LHP の算出)、およびカメラ等のセンサを利用したコンテキストセンシングによる危険因子の認識を行うものである。



(7)より引用し一部加筆

Fig. 4-1 データ駆動型リスク予測アルゴリズムフレームワーク

5. Data driven AI

本章では、Data driven AI の検討結果を記す。Data driven AI は、ヒヤリハットデータをシナリオ毎に分類し、各シナリオの危険因子と LHP を算出の上、シナリオにおける SCT 実測値を目的変数、危険因子と LHP を説明変数とした重回帰分析を行い、Total-SCT を予測するための重回帰式を出力する。

データ駆動型リスク予測アルゴリズムフレームワークにおける Data driven AI の位置付けを下図内に黄色太線で示す。

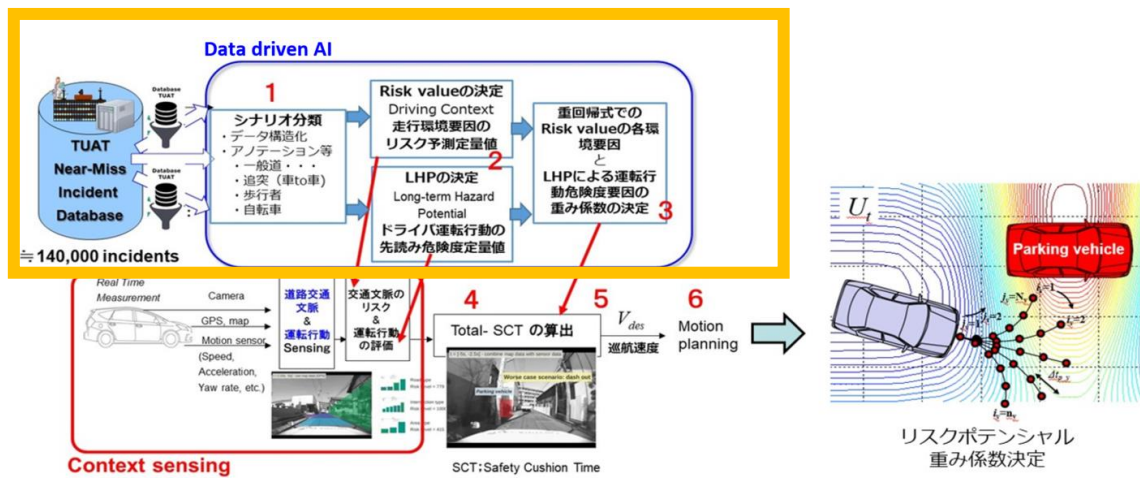


Fig. 5-1 フレームワークにおける Data driven AI の位置付け

5.1. ニアミスデータベースの構築

ニアミスデータとは、交通道路環境に起因するリスク(Risk Value)の算出に必要なデータセットである。ニアミスデータは、危険因子情報(アノテーション)、車載センサデータ情報、車載カメラデータ情報から構成される。ドライビングインテリジェントシステムを構築するに当たって、ドライビングインテリジェントシステムおよびシミュレータからニアミスデータを利用できることが必須である。そのため、ニアミスデータをドライビングインテリジェントシステムから利用可能なデータベース環境(ニアミスデータベース環境)を構築した。データ駆動型リスク予測アルゴリズムフレームワークにおけるニアミスデータベースの位置付けを下図内に黄色太線で示す。

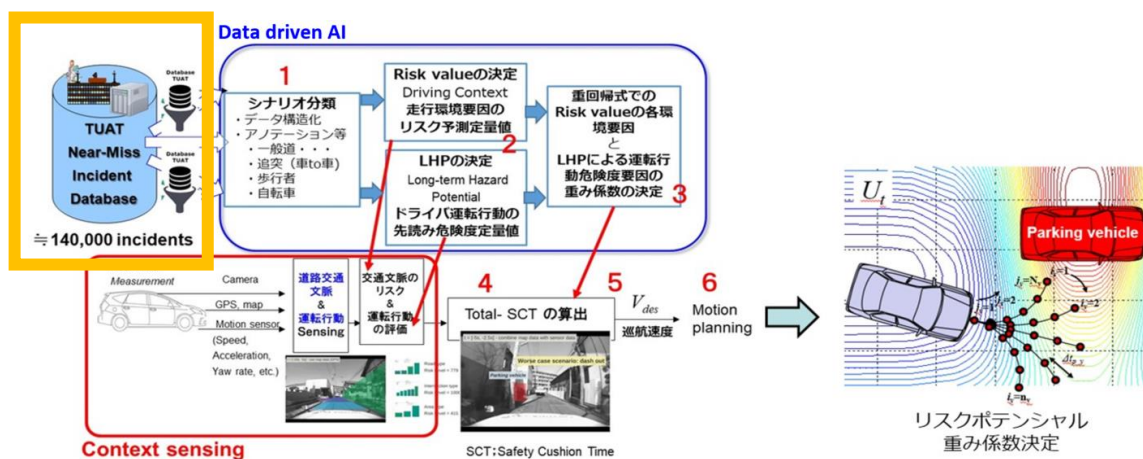


Fig. 5-2 フレームワークにおけるニアミスデータベースの位置付け

5.1.1. システム構成

ニアミスデータベース(Near-Miss Incident Database)は Microsoft SQL Server2019 上に構築し, ニアミスインシデントシーン動画(Near-Miss Incident Movie)は, ファイルサーバ上に格納し, データベースからファイル名でポイントするものとした. システム構成の概要図を以下に示す.

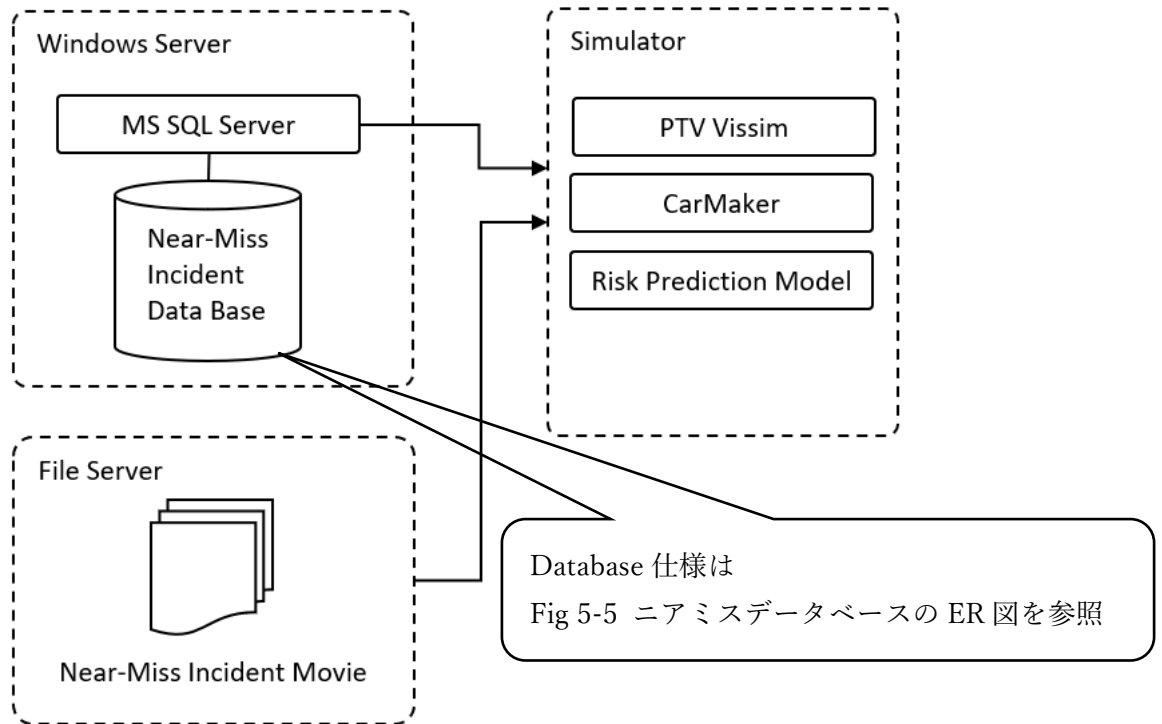


Fig. 5-3 ニアミスデータベースシステム構成

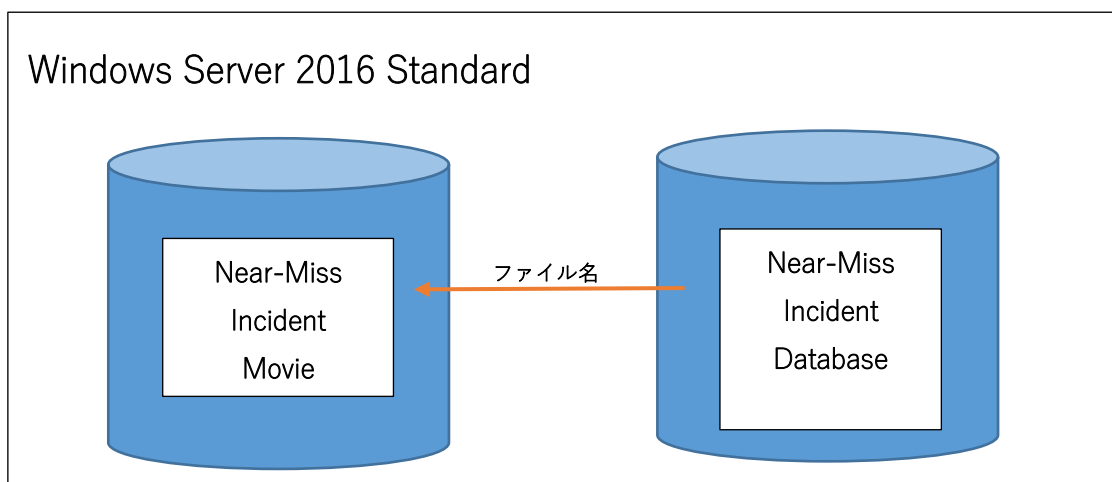


Fig. 5-4 ニアミスインシデントシーン動画とデータベースの関係

5.1.2. ニアミスシーンデータベーステーブル構成

ニアミスデータベースのテーブル一覧と ER図(Entity Relationship Diagram)を下表に示す。

Table 5-1 ニアミスデータベースのテーブル一覧

テーブル名	説明
TEvent	ニアミス事象を格納する
TDetail	ニアミス事象の詳細情報を格納する
TSpeed	ニアミス事象のセンサーデータを格納する

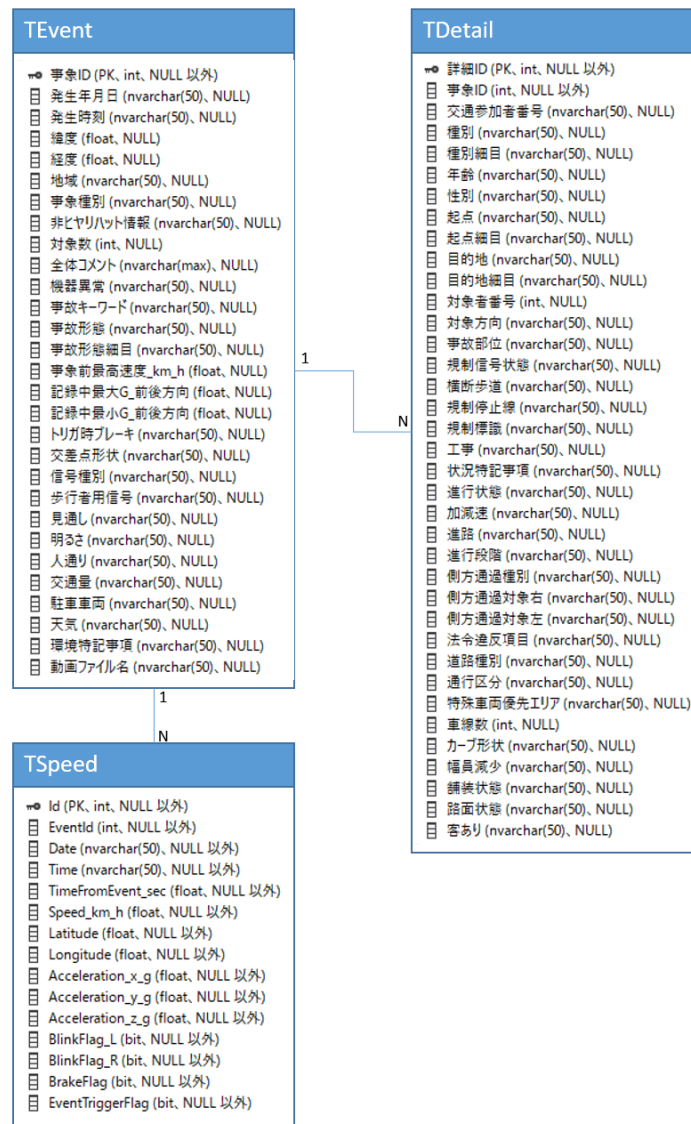


Fig. 5-5 ニアミスデータベースの ER 図

5.2. ニアミスデータの利用

ドライビングインテリジェントシステムを構築するに当たって、ドライビングインテリジェントシステムおよびシミュレータからニアミスデータを利用できることが必須である。

データ駆動型リスク予測アルゴリズムフレームワークにおけるニアミスデータベース利用の位置付けを下図内に黄色太線で示す。

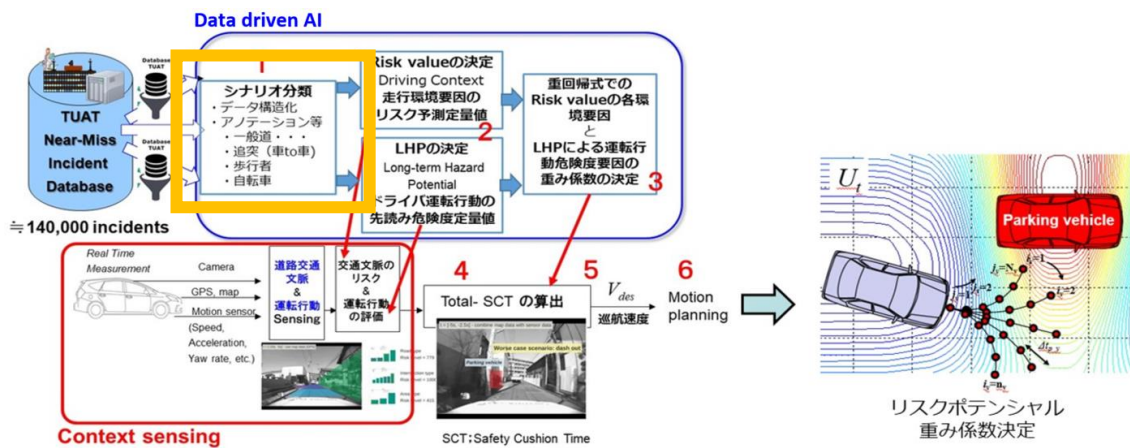


Fig. 5-6 フレームワークにおけるニアミスデータベース利用の位置付け

5.2.1. リスク予測モデルデータセット

リスク予測運転を実現するリスク予測モデルにて使用するデータセットを以下に示す。

これらのデータは、コンテキストセンシングによって認識した危険因子と一致するものであり、コンテキストセンシングによって取得した危険因子をニアミスデータベースとして蓄積する。

Table 5-2 リスク予測モデルにて使用するデータセット一覧

データ項目	取得方法	PEGASUS レイヤ対応
車線数	車載カメラ画像認識	Layer 1
横断歩道(有無)	車載カメラ画像認識	Layer 1
駐車車両(有無)	車載カメラ画像認識	Layer 4
歩行者数	車載カメラ画像認識	Layer 4
交通量	車載カメラ画像認識	Layer 4
先行車両(有無)	車載カメラ画像認識	Layer 4
地域区分	OpenStreetMap, 国土地理院	対応なし
通行区分	OpenStreetMap, 国土地理院	Layer 1
天候	OpenWeatherMap, 気象庁	Layer 5
時刻	GNSS センサ	Layer 5

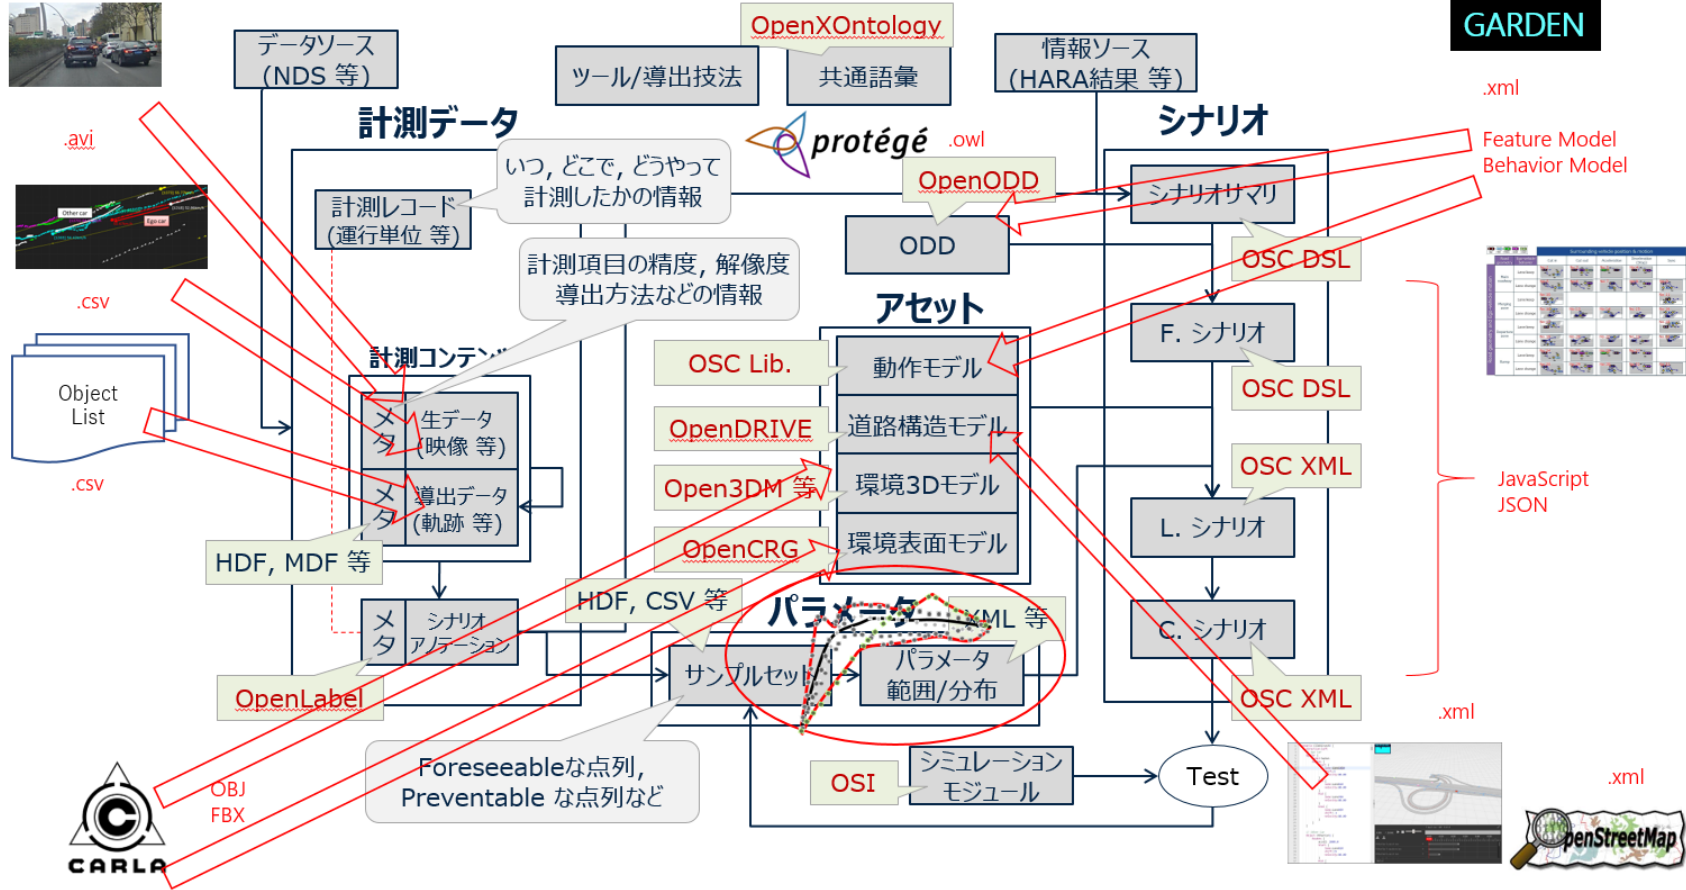
5.2.2. GARDEN DB

GARDEN DB⁽⁶⁾は計測データからシナリオを抽出し、アノテーションを付与する機能を持っている。

GARDEN DB の機能構成図を「Fig. 5-7 GARDEN DB」に示す。

NDS

シミュレーションプラットフォーム (GARDEN DB)



(6)より引用

Fig. 5-7 GARDEN DB

データ駆動型リスク予測アルゴリズムフレームワークにおけるシナリオ分類に GARDEN DB を利用した方が効果的な箇所があるか、今後検討が必要である。

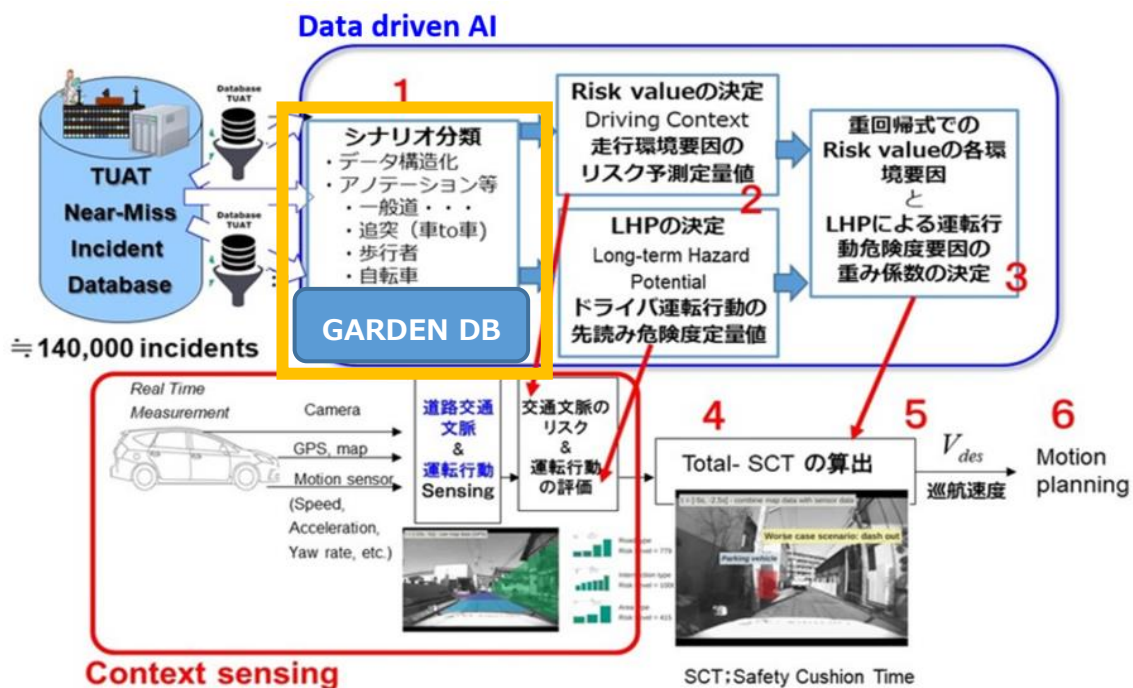


Fig. 5-8 フレームワークにおけるシナリオ分類と GARDEN DB

6. Context sensing

本章では、Context sensing の検討結果を記す。Context sensing は、実車にて車速から運転行動の評価 (LHP の算出)、およびカメラ等のセンサを利用したコンテキストセンシングによる危険因子の認識を行うものである。

データ駆動型リスク予測アルゴリズムフレームワークにおける Context sensing の位置付けを下図内に黄色太線で示す。

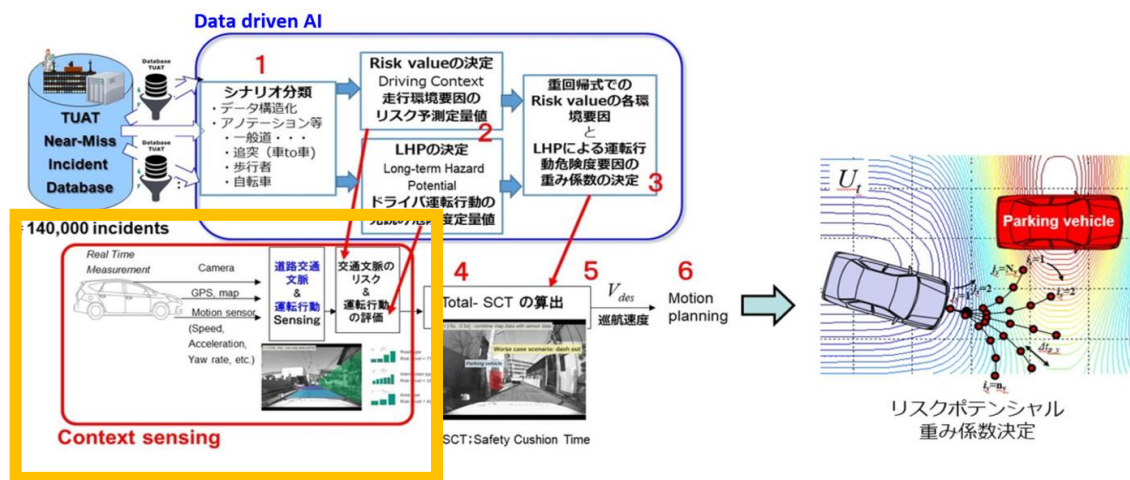


Fig. 6-1 フレームワークにおける Context sensing の位置付け

6.1. コンテキストセンシングにおける 13 項目の危険因子の取得方法

本章では、実車におけるコンテキストセンシングによる 13 項目の危険因子の取得方法を検討した。

データ駆動型リスク予測アルゴリズムフレームワークにおける、13 項目の危険因子取得の位置付けを下図内に黄色太線で示す。

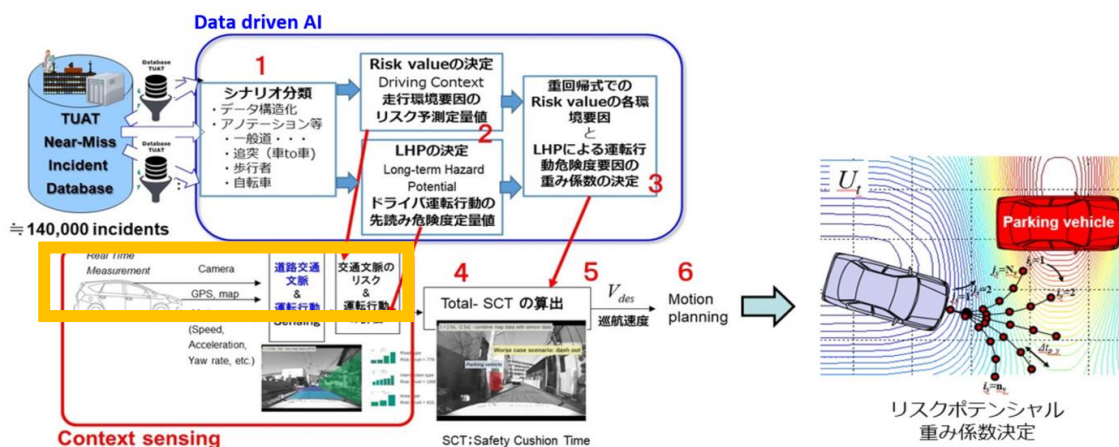


Fig. 6-2 フレームワークにおける 13 項目の危険因子取得の位置付け

6.1.1. 検討結果

検討結果を下表に示す。取得先に○が付与されている項目がカメラ画像認識によって取得する危険因子である。

前提条件を一般道として最高速度は 60km/h に設定し、運転の 5 秒後に到達する範囲の危険因子を対象とした。従って 80m 前方までを危険因子の取得範囲とした。

このような前提条件を決めることが、いわゆる ODD の本質的な主旨に相当する。本来の ODD はシステムの制約条件を決めるものではなく、安全や社会意義において優先すべき機能要件を実現するためにあるべきものである。

Table 6-1 13 項目の危険因子取得方法

危険因子	説明	取得先
Area type	地域(住宅地、市街地、農地等)	国土交通省、国土地理院WEB API
Road type	通行区分(両側通行、一方通行等)	Open Street Map WEB API
Sidewalk type	歩道形状	○ 画像認識またはLiDAR点群解析
Intersection type	交差点形状	【調査要】 Open Street Map WEB APIで取得した画像のパターン認識
Road width	車線数	○ 白線認識 またはOpen Street Map WEB API
Cross walk	横断歩道(有無)	○ 白線認識+ロジック
Parked vehicle	駐車車両(有無)	○ 車両認識
Pedestrian	歩行者数	○ 人認識
Traffic	交通量	○ 車両認識
Leading vehicle	先行車両(有無)	○ 車両認識
Time	時間帯	GNSS又はシステム時刻
Weather	天候	気象庁WEB API
Age	歩行者年齢	【調査要】 MS Face API

以下に、各危険因子の画像認識例を示す。各画像はヒヤリハットデータの画像である。



Fig. 6-3 画像認識による車線の検出例



Fig. 6-4 画像認識による横断歩道の検出例



Fig. 6-5 画像認識による駐車車両の認識例



Fig. 6-6 画像認識による歩行者の認識例



Fig. 6-7 画像認識による車両の認識例



Fig. 6-8 画像認識による先行車両の認識例

6.1.2. 課題

危険因子取得方法の検討を行った結果、抽出された課題を下表にまとめる。

Table 6-2 危険因子取得に関する課題一覧

危険因子	説明	課題
Area type	地域(住宅地, 市街地, 農地等)	-
Road type	通行区分(両側通行, 一方通行等)	-
Sidewalk type	歩道形状	周辺の構造物, ガードレール形状, 生垣等様々なパターンが考えられるため, カメラ認識だけでは限界がある。よって, LiDAR による3次元データの利用も検討する。歩道を検出するためには車道端部の縁石の認識も必要だが, この点に関しても3次元データを利用した方が, カメラ認識より精度が高いと思われる。
Intersection type	交差点形状	OpenStreetMap から取得した線分の交差パターンから認識する方向だが, アルゴリズムが未確立。
Road width	車線数	画像認識のみでは周辺走行車両の影響で車線が隠れる場合がある。 OpenStreetMap の利用も検討する
Cross walk	横断歩道(有無)	画像認識のみでは周辺走行車両の影響で車線が隠れる場合がある。 OpenStreetMap の利用も検討する
Parked vehicle	駐車車両(有無)	走行車両と駐車車両の判別方法
Pedestrian	歩行者数	-
Traffic	交通量	-
Leading vehicle	先行車両(有無)	周辺車両と先行車両の判別方法
Time	時間帯	-
Weather	天候	-
Age	歩行者年齢	MS Face API では, かなり接近しないと年齢の判定は難しい。 そもそも, 死角に存在する歩行者は認識不能。 また, 体格情報の利用も考えられる。

		今後は、リスク予測ダイレクトのテーマではなく、歩行者／自転車の行動予測の研究テーマで検討する。
--	--	---

6.2. 車両制御システムの検討

コンテキストセンシングアルゴリズムを搭載し、リスクに応じた速度制御を行う車両制御システム構成案を検討した。

データ駆動型リスク予測アルゴリズムフレームワークにおける、車両制御システムの位置付けを下図内に黄色太線で示す。

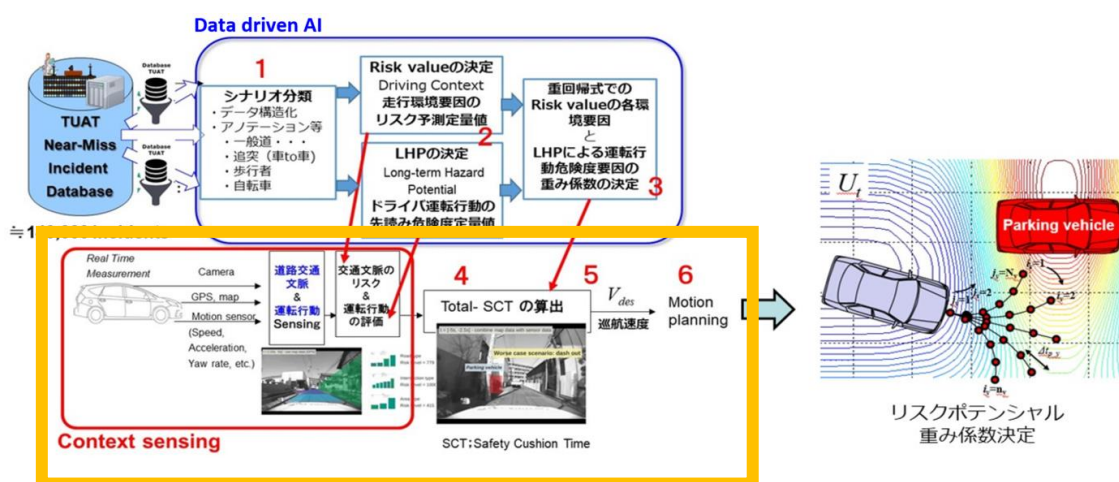


Fig. 6-9 フレームワークにおける車両制御システムの位置付け

車両制御システム構成案を「Fig. 6-10 コンテキストセンシング車両制御システム構成案」に示す。

画像認識処理の計算負荷とLiDAR点群処理の計算負荷を考慮し、画像認識処理とLiDAR点群処理およびメイン処理を別ノードで実行する構成とした。

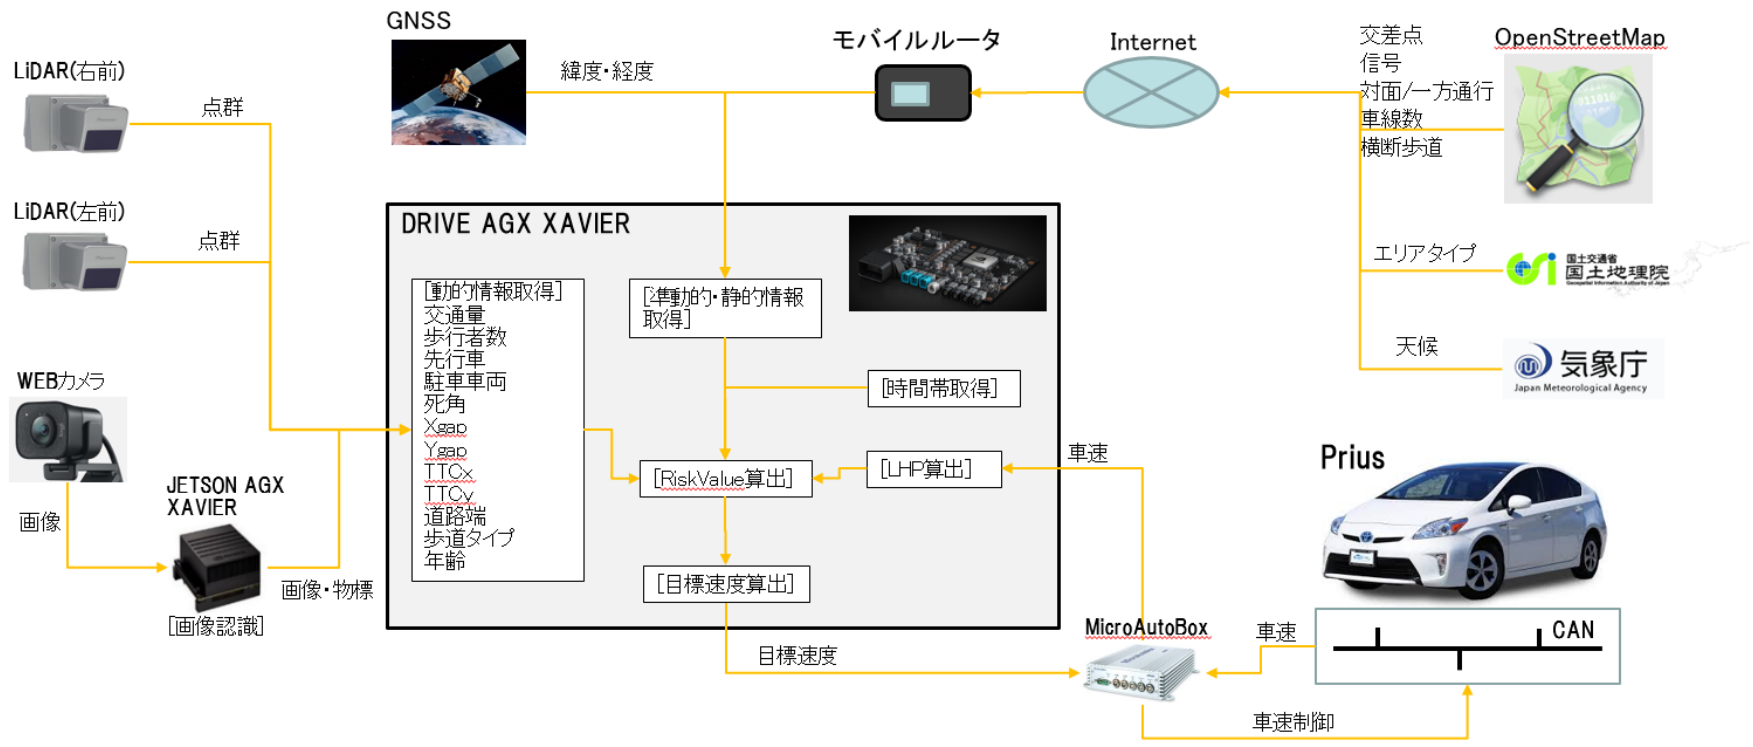


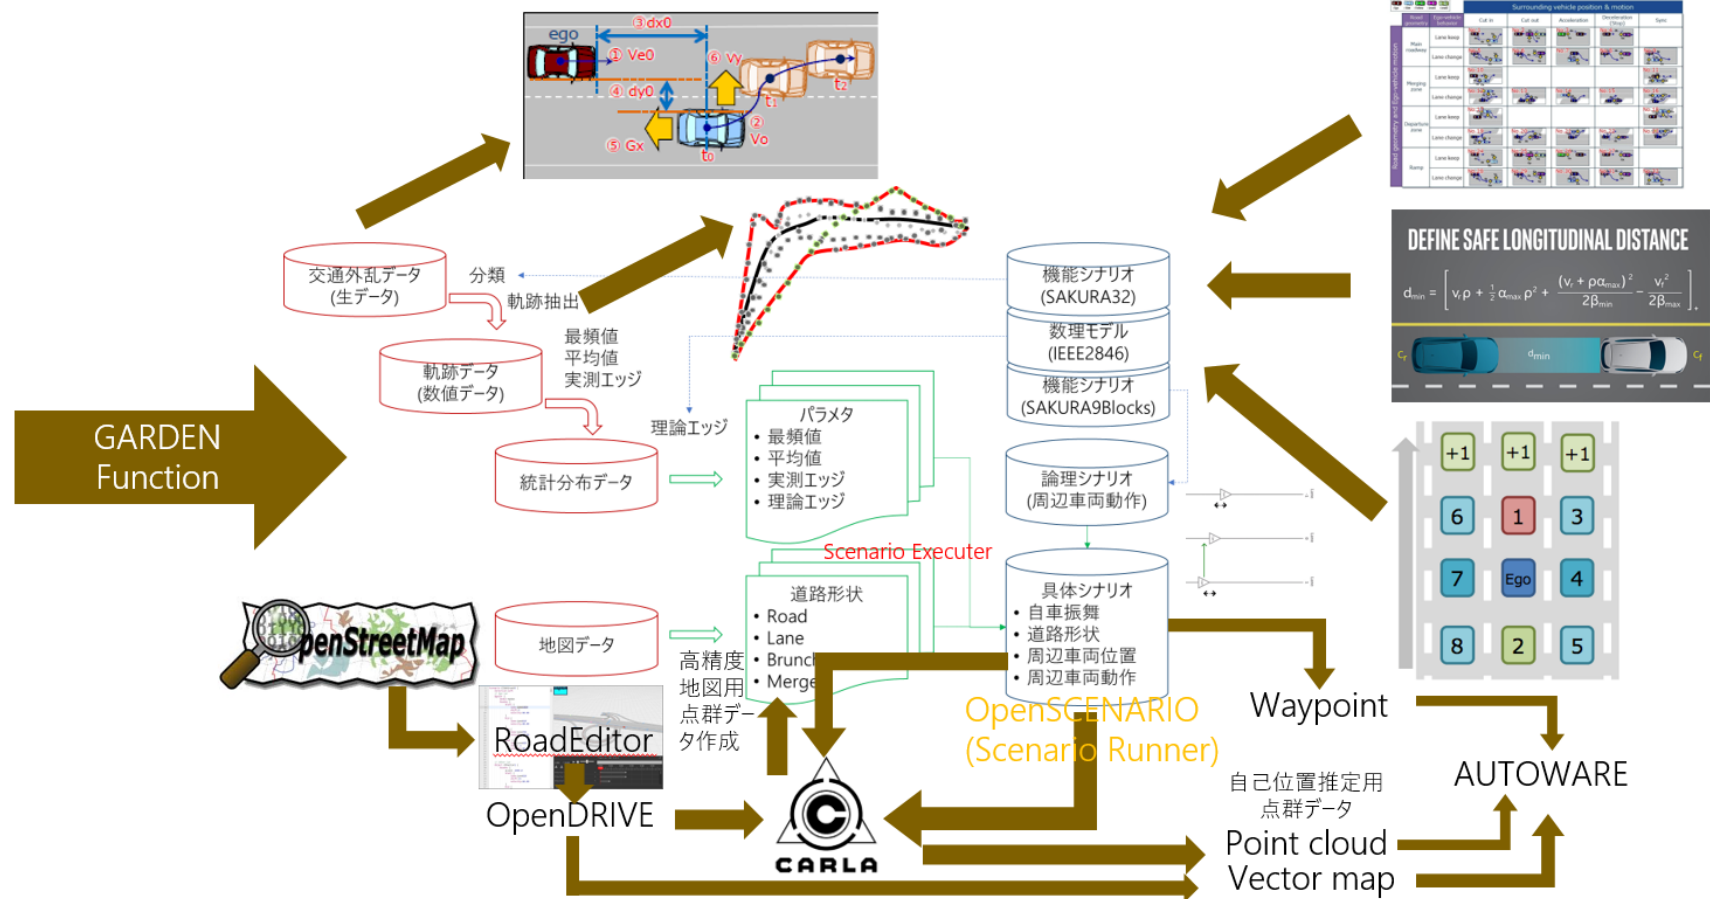
Fig. 6-10 コンテキストセンシング車両制御システム構成案

7. シミュレーション環境の検討

データ解析部が出力する重回帰式を実車に搭載する前に評価する必要がある。評価は、シミュレーションにより行うものとしてそのフレームワークを検討した。

ここで、GARDEN⁽⁶⁾はシミュレーションプラットフォームとして、道路構造やシナリオ生成機能を持っている。GARDEN の機能構成図を「Fig. 7-1 GARDEN」に示す。

シミュレーションプラットフォーム (GARDEN 機能)

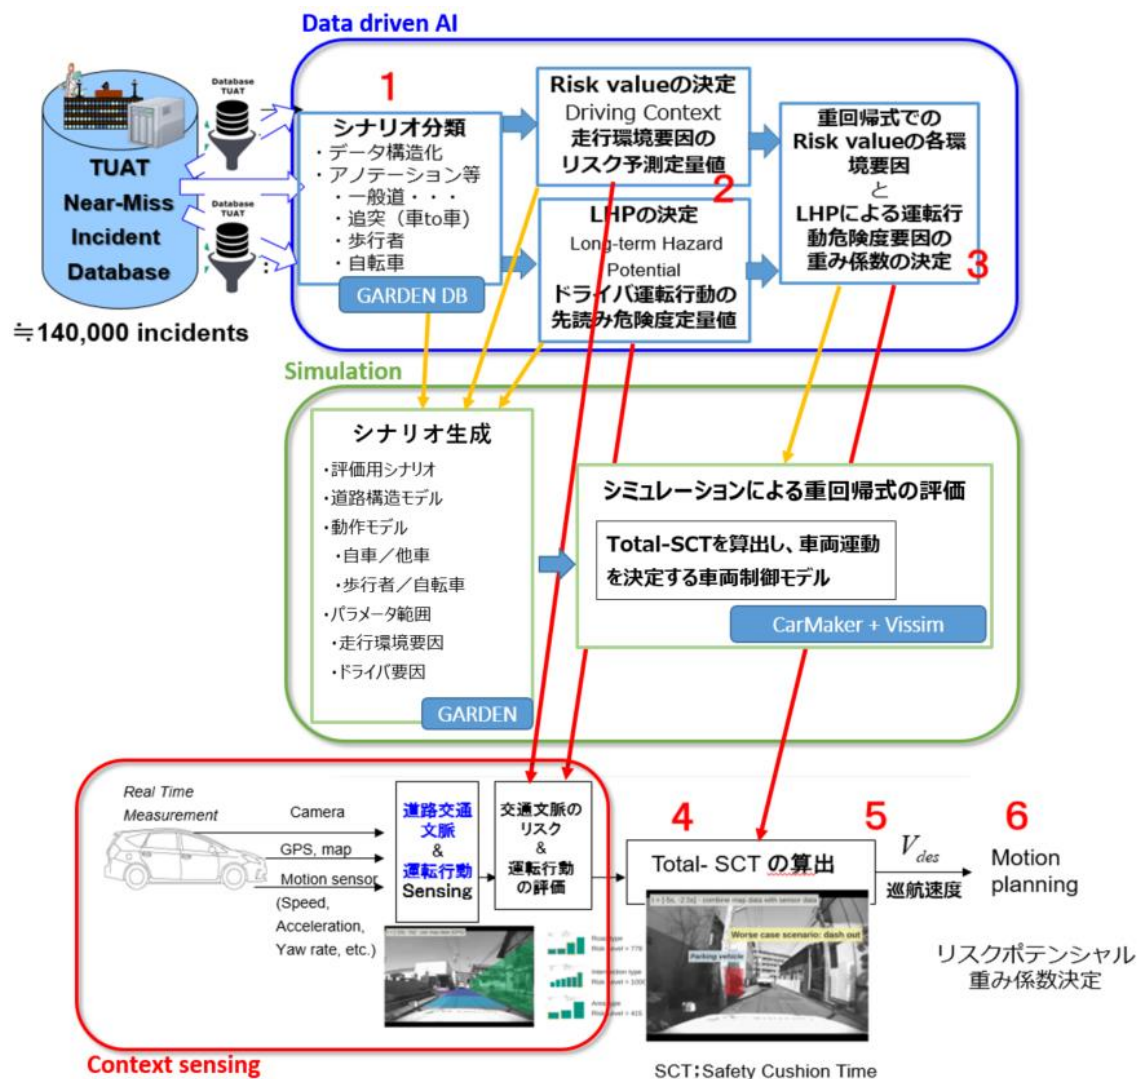


(6)より引用

Fig. 7-1 GARDEN

シミュレーション環境としては、当面は、既往研究⁽¹⁾で利用した CarMaker+Vissim を想定している。シミュレーションシナリオ生成に GARDEN を利用する方向で今後の研究を進めてゆく。

シミュレーションを含めたデータ駆動型リスク予測アルゴリズムフレームワークを下図に示す。



(7)より引用し加筆・修正

Fig. 7-2 シミュレーションを含めた DRM フレームワーク

8. まとめ

本年度の研究成果を以下にまとめる。

- 13項目の危険因子の取得方法の検討した結果、課題を抽出して要件化することができた。13項目の大半はカメラ認識とインターネット上のサービスを組み合わせることで取得できる方向だが、歩道タイプの分類や、距離推定に関しては単眼カメラのみでは難しいと思われるため、今後LiDARを使用することも視野に入れる必要がある。
- ニアミスシーンデータベースの構築を行ったことで、データ駆動型リスク予測アルゴリズムの基盤部分が整備できた。また、ニアミスシーンデータベースの利用として、リスク予測モデルにて使用するデータセットの取得方法を検討した。
- コンテキストセンシング車両制御システムの構成案を示すことができた。画像認識、GNSS、インターネットから情報取得およびLiDARによる点群を入力とし、リスク値を算出の上車両を制御する具体的な構成を提示した。今後は、危険因子取得処理を実装し、実車による評価に繋げてゆく。
- シミュレーションによる重回帰式の評価を含めて、データ駆動型リスク予測アルゴリズムフレームワークを拡張することができた。加えて、GARDENの位置づけを明確化できた。
- 13項目の危険因子とPEGASUSとの対応を整理した。13項目中Area typeとAgeを除く11項目についてPEGASUS Layer1, Layer4, Layer5と対応づけることができたため、13項目の危険因子が国際的な基準からみても、一定の標準性を備えていることが確認された。

参考文献

- (1) 張海鵬：交通環境モデルを用いた走行リスク予測アルゴリズムの評価手法の研究，神奈川県工科大学 修士学位論文，(2019)。
- (2) 斎藤裕一，井上秀雄，ポンサトーン・ラクシンチャラーンサク：セイフティクッション：走行環境文脈と運転行動状態に基づく危険度推定モデルの構築（第一報）-死角での対歩行者ヒヤリハットの形成過程に対する考察-，公益社団法人自動車技術会 2018 年春季大会学術講演会講演予稿集，No.20185429，(2018)。
- (3) 久米伸一，斎藤裕一，井上秀雄，ポンサトーン・ラクシンチャラーンサク：セイフティクッション：走行環境文脈と運転行動状態に基づく危険度推定モデルの構築（第二報），公益社団法人自動車技術会 2019 年春季大会学術講演会講演予稿集，No.20195247，(2019)。
- (4) 神奈川県工科大学 井上研究室，東京農工大学 ポンサトーン研究室：2018 年度 共同研究成果報告書 ヒヤリハットデータを活用した潜在リスク予測技術の研究，(2018)。
- (5) PEGASUS RESEARCH PROJECT：PEGASUS METHOD An Overview, <https://www.pegasusprojekt.de/files/tmpl/Pegasus-Abschlussveranstaltung/PEGASUS-Gesamtmethode.pdf>, (参照日 2020 年 8 月 6 日)。
- (6) 株式会社 NTT データ オートモビリティジェンズ研究所：GARDEN ver. acacia Architecture, (2020)。
- (7) 国立研究開発法人 科学技術研究機構：戦略的イノベーション創出推進プログラム 高齢社会を豊かにする科学・技術・システムの創成 高齢者の自立を支援し安全安心社会を実現する自律運転知能システム, <https://www.jst.go.jp/s-innova/eval/index.html#point05>, (参照日 2020 年 2 月 1 日)。