

実効性のある「安全性評価手法の原案」の提案書

令和8年3月24日

国立研究開発法人新エネルギー・産業技術総合開発機構

Ver1_04 からのアップデート内容

変更箇所	変更内容
1, 4	委託元を記入。語句小変更。
Fig. 3-2-1	変更
Fig. 3-8-8	変更
Fig. 3-5-21/3-5-22	説明追加
4.2.2	センサ起因の認識リスクについて言及
3.5	整理。エージェントモデル説明一部 APPENDIX へ移動
所感	削除
表紙	発行元追加
3.8	APPENDIX へ移動
Fig.3-3-2	変更
Fig.3-4-1/3-4-2/3-4-3	変更
用語集	修正・追加
APPENDIX	‘交通流シミュレーション設定の詳細’を削除
Table 3-5-5	‘リスク管理のエージェントモデル・パラメータの設定’を追加

Ver1_05 からのアップデート内容

変更箇所	変更内容
全体	誤字・脱字・用語の不一致を修正。表現をより明確に修正・加筆。

Ver1_06 からのアップデート内容

変更箇所	変更内容
3.3.1	最大減速度のマイナス符号の誤記を修正。
Fig. 3-7-1	『安全余裕度』を『回避余裕度』に修正
3.7	文章の追加

Ver1_07 からのアップデート内容

変更箇所	変更内容
全体	フォーマット微調整
APPENDIX C	表 C-1 内容追記。シナリオ構造化データの例(図 C-3)を追加。図表の出現順にナンバリング修正

Ver1_08 からのアップデート内容

変更箇所	変更内容
表 4-2-1.	secを入れた。
全体	図表全部に英文表記を加えた。フォーマット微調整

Ver2_00 からのアップデート内容

変更箇所	変更内容
表 4-2-1	図 3-6-12 の表示が崩れていたのを修正
参考文献	[8]修正

内容

1. はじめに.....	6
1.1. 国際法規の動向.....	6
1.2. 関連規格.....	7
1.2.1. ISO 26262:2018 (機能安全).....	7
1.2.2. ISO/PAS 21448:2022 (SOTIF).....	7
1.2.3. ISO 34502.....	8
1.2.4. ISO/PAS 8800.....	8
1.2.5. SAE INTERNATIONAL J3237_202508.....	8
1.3. その他標準化団体・研究機関等の取組み.....	8
1.3.1. ASAM (ASSOCIATION FOR STANDARDIZATION OF AUTOMATION AND MEASURING SYSTEMS).....	8
1.3.2. BMW SIFAD ⁶⁾	9
1.3.3. TERASIM (MCITY) ^{15)、16)}	10
1.3.4. ワールドモデルとフィジカル AI.....	10
2. 実効性のある安全性評価フレームワークの提案.....	12
2.1. 考え方；帰納的アプローチと演繹的アプローチ.....	12
2.2. 既知／未知リスクシナリオでのシミュレーション活用によるテスト方法の意義.....	12
2.3. 動的時空間としてのマイクロ／マクロのリスクシナリオ生成方法.....	14
2.3.1. HIRA、ODD を支援するニアミスデータ解析とリスクシーンの類型化.....	15
2.3.2. リスクシナリオデータセットの生成.....	15

2.3.3.	不確定リスクの統計的条件設定	15
2.4.	回避余裕度 (CONTROLLABILITY) ²²⁾ のための運転行動を評価する指標 (SCT) の意義 ...	16
3.	実効性のある自動運転車の安全性評価のフレームワークの詳細	18
3.1.	ニアミス走行データの取得 (&ODD)	18
3.2.	ニアミス走行データの解析	20
3.2.1.	映像解析から自車と他車の危険に至るまでの動的軌跡抽出	20
3.2.2.	リスクシーンの類型化	23
3.3.	SCT 評価指標の数理モデルとリスク定義	26
3.4.	マイクロ評価 ; リスクシナリオの生成	29
3.4.1.	リスクシナリオの絞込み方法	29
3.4.2.	マイクロ評価用リスクシナリオデータセット	32
3.5.	マクロ評価	35
3.5.1.	交通流シミュレーションの妥当性確保	35
3.5.2.	ベース交通流の設定	36
3.5.3.	交通流リスク (エージェントモデル) の設定	40
3.5.4.	マクロ評価用リスクシナリオデータセット	51
3.5.5.	マクロ評価結果	54
3.6.	運転行動の安全性評価 (マイクロ評価、マクロ評価)	58
3.6.1.	運転行動の安全性評価の方法	58
3.6.2.	運転行動の安全性評価の実践例	60
3.7.	回避余裕度を用いた安全性評価と許容基準の提案	66

4. まとめと提言	68
4.1. 実効性のある安全性評価フレームワークと6つの要件の提案	68
4.2. 実効性のある自動運転車の安全性評価フレームワークの詳細と今後の展望	68
5. 参考文献	73
6. 用語集	75
APPENDIX	83
A. 高速道 FOT 検討会 & シミュレーション試行評価	83
(A) FOT 検討会と参加者からのフィードバック	83
(B) 各社シミュレーション試行評価（接続性評価）	85
B. 標準データセット・フォーマット	92
C. 安全性評価のための生成 AI 活用に関する研究	96
D. ニアミス発生情報表示マップ	106

1. はじめに

レベル3以上の自動運転システム(L3+ADS、Automated Driving System)に対する実効性のある安全性評価手法については、ISO規格や国際法規の策定を始め国際的に活発な議論が進められている。一方で、これら規格や法規自体が具体的な製品開発プロセスや安全性評価手法の実装方法までを包含するものではなく、具体的な製品開発フレームワークとしては確立しているとは言えない¹⁾。結果として、L3+ADSの安全性をどのように設計・評価・実証するかというフレームワークの構築は、OEMを中心とした製造者側の裁量に大きく委ねられており、製品開発においては規格適合と実効的な安全性評価との間にギャップが生じているのが現状である。このため、L3+ADSのための製品開発フレームワーク、とりわけ安全性評価フレームワークについて、具体的かつ実装可能な形で確立することが強く求められている。

本稿は、国際法規や国際標準の動向や、最新の事業者や第三者の活動等の背景を整理した上で、ルールベースやエンドツーエンド(E2E)で構築されたブラックボックスとしての運転機能を評価する手法を提案する。本提案は「動的時空間としてのマイクロ/マクロのリスクシナリオ生成方法」、「シミュレーション活用による既知/未知リスクシナリオでのテスト方法」、「安全運転行動を評価する指標(SCT)」などを特徴としており、一連の「実効性のある安全性評価フレームワーク」を示すものである。

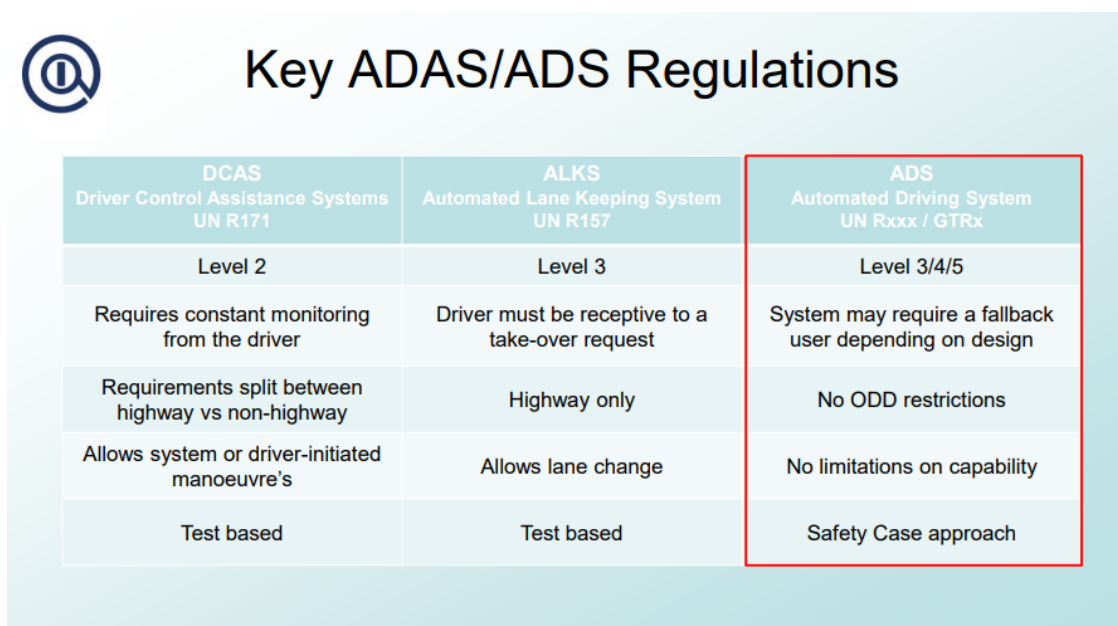
尚、本研究は国立研究開発法人新エネルギー・産業技術総合開発機構が実施する「デジタルライフライン整備事業/デジタルライフラインの先行実装に関するデータ連携システムの研究開発/C.自動運転サービス支援道」の委託事業の成果である。

1.1. 国際法規の動向

自動運転車が満たすべき国際基準および国際法規は多岐にわたる。国際標準としては、機能安全を扱うISO 26262、意図しない挙動に起因するリスクを対象とするISO 21448、AI利用を想定したISO/PAS 8800、ならびに現在策定中の規格を含むISO 3450Xシリーズが挙げられる。一方、国際法規としては、自動運転機能の型式認証を規定するUNR-157、高度運転支援機能を対象とするUNR-171、および現在策定が進められているUNR-ADSなどがある。

国際法規 WP29 では「自動運転車は運行設計領域において合理的に予見される防止可能な人身事故を生じさせないこと」を安全目標とした規定から始まり、UNR-ADSドラフト²⁾では、公道実車実証、テストコース環境での試験、そして、仮想化シミュレーションの3つを有効に活用した安全性評価が提案されている。仮想化シミュレーション活用の提案は、UNR-171(DCAS/Level 2)法規³⁾にも同様の記述が展開され、その必要性が伺える。UNR-157(ALKS/Level 3、ODDはHighway only)では、対象車速がこれまでの60km/h (UNR-157/00)が130km/h (UNR-157/01)⁴⁾に引き上げられている。更に、最新のUNR-ADSドラフト⁵⁾では、L3+ADSを対象に、“No ODD restrictions”と表現されると共に、UNR-157、UNR-171がTest basedであったのに対し、Safety Case approachへ表現が変わっている(図1-1-1)。Safety Case(安全論証)とは、ADSが定義されたODDにおいて、要求事項に適合し、unreasonable risk(説明不能なリスク)が存在しないことを論理的に説明可能に

したものと示されている(BMW SIFAD⁶⁾)。これは、L3+ADS が「ODD 制限無し」を前提とすると、従来型テストでは制度的にも実務的にも対応できないことを WP29 が明確に認識した結果であると考えられる。



DCAS Driver Control Assistance Systems UN R171	ALKS Automated Lane Keeping System UN R157	ADS Automated Driving System UN Rxxx / GTRx
Level 2	Level 3	Level 3/4/5
Requires constant monitoring from the driver	Driver must be receptive to a take-over request	System may require a fallback user depending on design
Requirements split between highway vs non-highway	Highway only	No ODD restrictions
Allows system or driver-initiated manoeuvres	Allows lane change	No limitations on capability
Test based	Test based	Safety Case approach

Fig. 1-1-1 Introduction to the (Draft) ADS regulation UNR and GTR (OICA、CLEPA、WP.1、04.06.2025 資料より引用)

1.2. 関連規格

国際法規に呼応する形で、ADS に関する国際標準の各 ISO 制定の努力がされてきた。

1.2.1. ISO 26262:2018 (機能安全)

ISO26262:2018⁷⁾は、車両のハードウェア・ソフトウェアの故障や誤要求に起因するリスク低減には有効である。一方で、ADS に固有の不確実性や意図した振る舞い自体の安全性を扱うことができないという本質的制約を持つ。しかし、リスクアセスメント（ここでは FMEA）が基盤となり ASIL での安全設計レベルの定量化になっているこの機能安全の考え方は、故障でない危険事象を扱う場合（SOTIF 等、後述）にも反映されることが望ましい。

1.2.2. ISO/PAS 21448:2022 (SOTIF)

ISO/PAS 21448:2022⁸⁾は、知覚・判断の機能不十分性に起因するハザードをシナリオ中心に扱い、反復的改善を重視する。一方で、L3+ADS に必要な定量的リスク基準のコンポーネントレベルへの分解方法や統計的検証手法については明確に規定していない。ISO 21448 は ISO 26262 が扱えない領域を補完し、同様にリスクアセスメント(HIRA: Hazard Identification and Risk Assessment)が重要基盤になっている。一方で、定量的安全論証を成立させるための方法論が不足している。ここでもこ

の機能安全と SOTIF の「方法論の空白」を埋めることが課題である。

1.2.3. ISO 34502

ISO 34502⁹⁾は、Pegasus project が提案した Scenario-based approach を反映しており、演繹的な網羅性を鑑みた critical scenario 導出の考え方、走行外乱、認識外乱、車両外乱、を FTA 的に Hazard 要素として洗い出し機能安全と SOTIF の「方法論の空白」を埋める努力が見られる。ただ、具体的なリスクシナリオの生成方法までには至っておらず、事例は、60km/h (UNR-157/00) の一例に留まっている。また、ODD やリスクアセスメントによるシナリオ生成の方法論は事業者側に委ねられている。

1.2.4. ISO/PAS 8800

ISO/PAS 8800¹⁰⁾は、車両の安全クリティカル部品に AI(特に機械学習)が広く使われるようになってきたことを受けて策定された。ISO/PAS 8800 の目的は、ISO 26262 および ISO 21448 のアプローチを機械学習の特性に適合させて拡張することである。機械学習を用いる車載システム向けに既存規格を拡張するが、L3+ADS に必要な車両レベルの定量リスク基準をコンポーネント性能へ分解する方法は前提扱いに留まっているため、統計的枠組みでこれを補完する必要がある。

加えて、AI 導入により安全の焦点は、実装からデータおよびツールへと移行することも示されており、このパラダイム変化に対応する必要がある。

1.2.5. SAE International J3237_202508

SAE International J3237_202508(Dynamic Driving Task Assessment Metrics for Automated Driving Systems)¹¹⁾は、タイトルの通り動的運転行動要件の安全性に関する指標を、航空機の安全設計に適用されている Safety envelope の考え方から、重要な 7 項目の要件を定義している。この要件に対し、RSS 指標や我々の提案している Safety Cushion Time (SCT) ¹²⁾指標は全 7 項目に適合している。一方で、TTC や PET は静的指標と捉えられ、3~4 項目の要件には適合せず DDT の評価指標としては不十分とされている。

1.3. その他標準化団体・研究機関等の取組み

1.3.1. ASAM (Association for Standardization of Automation and Measuring Systems)

ASAM ¹³⁾は、1998 年にドイツで設立された、自動車産業における計測・テスト・自動化システムに関する国際的な非営利標準化団体である。特に近年では、Pegasus プロジェクト ¹⁴⁾ で提案された自動運転技術における 6-layers の走行環境モデルやシナリオ生成等に関する各種標準規格を策定してきた (OpenDRIVE、OpenSCENARIO、OSI 等)。実際に、ECU テスト、実験データ管理 (ODS) など、開発現場におけるデータやツールの互換性を確保する実装レベルの標準規格を主旨としてソ

ソフトウェアの開発方法の効率化、各シミュレーションモデルの結合インターフェースの決定など、産業界やアカデミア等のボトムアップ活動で、自動運転や ADAS の開発・評価の実効性を上げることに貢献している。論証等を目的とした ISO などを演繹的アプローチとするなら、ASAM 活動は各ユースケースを具体化するもので、帰納的アプローチと言える。また、先述の ISO でも ASAM 標準規格が引用される例が増えており、デファクト標準規格として広く利用されている。(図 1-3-1)

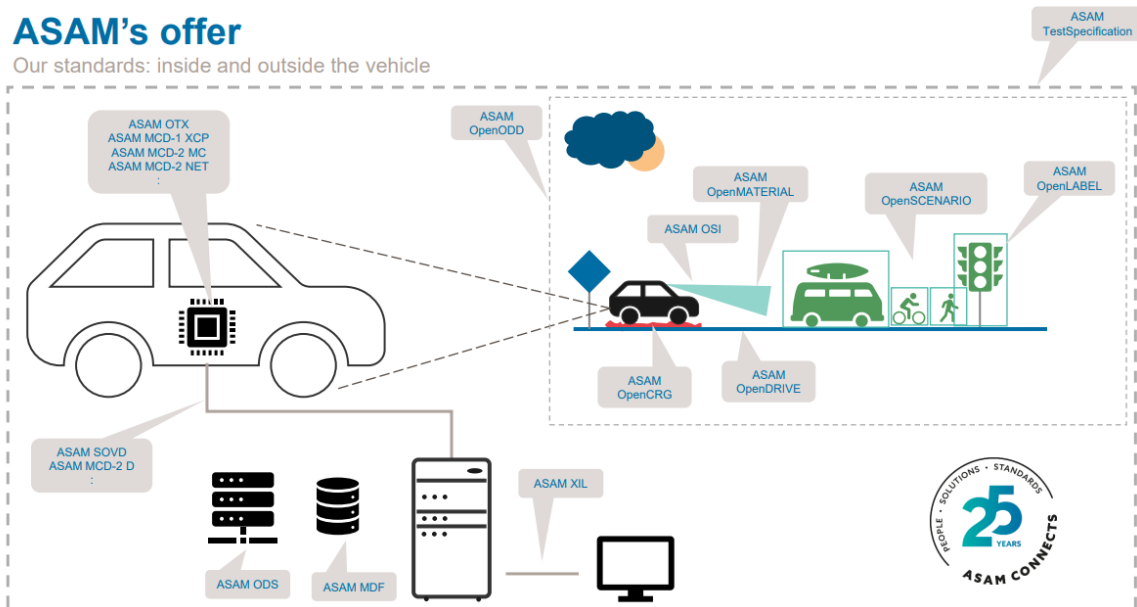


Fig. 1-3-1 ASAM's standards: inside and outside the vehicle より引用

1.3.2. BMW SIFAD ⁶⁾

UNR-ADS の改定原案に対応する安全性論証を先取りする形で、BMW より提案された SIFAD は L3 型式認証のための安全論証フレームワークである。

SIFAD は、体系的な安全性評価システムを構築する枠組みであり、従来の ISO 26262 に基づく製品開発プロセスを基盤としつつ、レベル 3 以上の自動運転システム(L3+ADS)において新たに要求される安全性評価を対象として拡張されている。本フレームワークでは、ハザード定義およびリスクアセスメント(HIRA、 Hazard Identification and Risk Assessment)により問題を明確化し、安全コンセプト(Safety Concept)においてその解決構造を設計することを基本方針としている。さらに、ハードウェアおよびソフトウェア設計を含むシステム全体を対象に、ベイジアンネットワークを用いた統計的評価手法を導入し、安全性の定量的評価を行うことを定めている。設計および評価の指針となる基準としては、ポジティブリスクバランス (PRB、 Positive Risk Balance) を前提としたリスク受容基準(RAC、 Risk Acceptance Criterion)を採用し、その指標として事故率(Incident Rate)を用いている。SIFAD は、L3+ADS において不可欠となる統計的安全性評価の考え方と実装方法を体系的かつ具体的に示しており、実際の製品開発手法として高い実用性を有する。

SIFAD では、ポジティブリスクバランス(PRB)のリスク受容基準(RAC)として事故率(Incident Rate)が採用されている。しかし、事故率のみを RAC とすることには、いくつかの課題が存在する。

これらの課題に対しては、事故率に加えて回避余裕度(SCT、 Safety Cushion Time)をリスク受容基準として用いることで、問題を解決できる可能性があり、2.4 章で後述する。

1.3.3. TeraSim (MCity)^{15)、16)}

また、同様にデータを基にした帰納的なアプローチでありながら統計的な偶発リスクも評価する MCity の TeraSim アプローチも UNR-ADS ドラフトに適合の可能性のある実装フレームワークと言える。評価体系として、ドライバライセンステスト(DLT、 Driver License Test)およびドライバインテリジェンステスト(DIT、 Driver Intelligence Test)を定義し、このうち DIT は L3+ ADS において要求される統計的安全性評価を担う位置づけとなっている。DIT は、TeraSim によって構築された自然ドライビング環境(NDE、 Naturalistic Driving Environment)を用い、車両および歩行者を含む交通流を統計的に再現する点に特徴がある。これにより、実交通に近い相互作用を含んだ大規模シナリオ生成と評価が可能となっており、統計的安全性評価の実装という観点から高い実用性を有する。このように TeraSim(MCity) は、シミュレーションを用いた実運用レベルの安全性評価フレームワークを提示している。しかし、ここでも、リスク受容基準(RAC)として事故率(Incident Rate)が採用されているため、SIFAD と同様の課題がある。

1.3.4. ワールドモデルとフィジカル AI

近年、NVIDIA Alphamayo¹⁷⁾に代表される、生成 AI を用いた自動運転評価環境が登場している。これらの環境は、実世界を再現するワールドモデルと、エンドツーエンド(E2E)自動運転システムとして機能するフィジカル AI から構成される。両者を統合することで、従来のシミュレータと自動運転システム(ADS)を組み合わせた評価手法と同様に、クローズドループな仮想実験環境を提供する点に特徴がある。一方で、生成 AI の導入により、従来の物理ベースあるいはルールベースのシミュレーションでは想定されなかった新たな課題が生じる。そのひとつは、ワールドモデルは映像言語モデル(VLM、 Vision Language Model)に起因する課題を内包しており、代表的な問題としてハルシネーション(Hallucination)が挙げられる。これは、例えば赤信号と青信号が同時に点灯するといった、物理法則や交通ルール上は発生し得ない状態を生成する可能性があり、従来型シミュレーションでは想定されなかった誤動作に繋がりがかねない (図 1-3-2)。

また、フィジカル AI は行動生成の内部過程がブラックボックス化しやすく、判断根拠や動作理由の説明性に課題がある。このため、シミュレーションによる安全性評価においてこれらの生成 AI ベースアーキテクチャを利用する場合には、評価結果そのものだけでなく、生成過程が評価に与える影響を考慮しなければならない。



(Generated using NVIDIA Cosmos at Kanagawa Institute of Technology and IDAJ Inc.)
Fig. 1-3-2 An example of hallucination using World Foundation Model: WFM

2. 実効性のある安全性評価フレームワークの提案

2.1. 考え方；帰納的アプローチと演繹的アプローチ

事故・ニアミス等の市場データを起点とした本提案は、帰納的アプローチと言える。帰納的なアプローチでは、ODDに基づく公道実証テスト（FOT: Field Operational Test）が実効性を支える役割を果たしている。一方、演繹的なアプローチでは、ISO34502 や JAMA 安全性評価ガイドライン¹⁸⁾に示されるように、リスクアセスメントにより無限に存在するリスク事象を有限の対象へと絞り込んでいく考え方が示されている。いずれのアプローチにおいても、HIRA がその原点にあり、安全性評価では、まずハザード事象を洗い出し、リスクの高い事象から順次シナリオを絞り込むことで有限な評価時空間を決定することが重要である。HIRA および ODD は事業者側の設計要件であるが、ニアミスデータ収集と解析、およびその結果として得られるリスクシーンの類型化や映像からの軌跡抽出方法等は合理的な開発および認可の両面に不可欠なものであり、HIRA、ODD の策定を支援することができる。

このような観点から、帰納的アプローチと演繹的アプローチはどちらも重要であり、それぞれを担う研究機関の知見を融合し、いち早くシミュレーションを活用した評価法を確立していくことは、我が国の自動運転開発の国際競争力向上からも極めて重要な位置づけとなる。

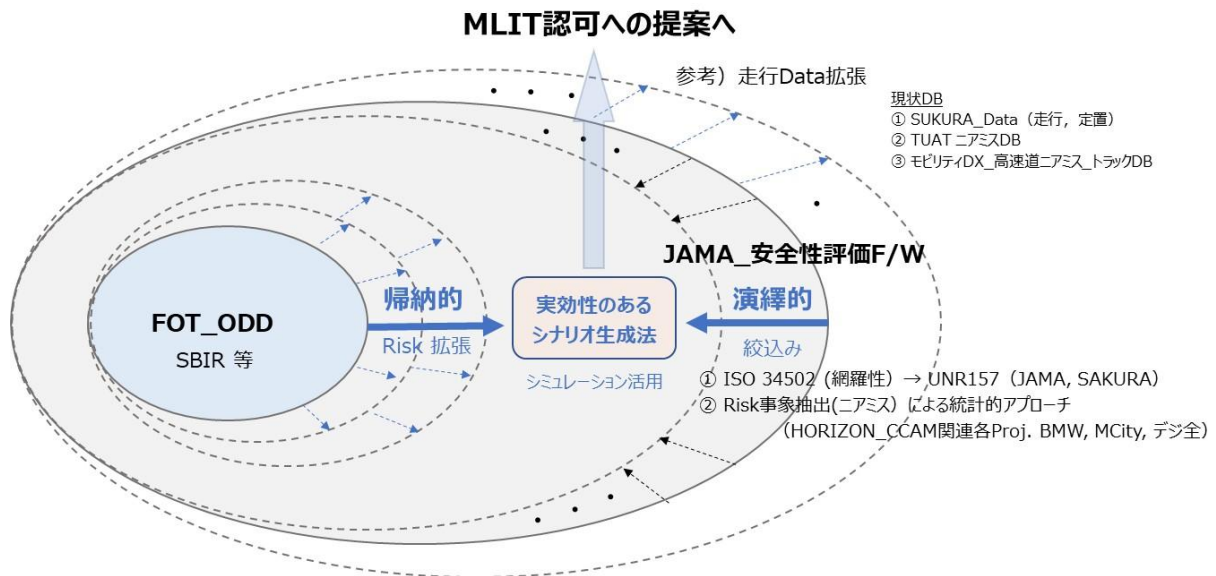


Fig. 2-1-1 Integration of Inductive and Deductive Approaches in Safety Assessment
安全性評価における帰納的アプローチと演繹的アプローチの融合

2.2. 既知/未知リスクシナリオでのシミュレーション活用によるテスト方法の意義

図 2-1-1 の考え方を、ロングテール問題の図に置き換え、ODD の位置づけや SOTIF での 4 象限（既知安全、既知危険、未知危険、未知安全（対象外））への対応に対する本プロジェクトの提案するシミュレーション活用による安全性評価テスト方法の意義や関係性を図 2-2-1 に示す。

これまでの Pegasus プロジェクトや ISO34502 で提案されているシナリオ生成は、自車と他車の位置の関係性（自車を囲む 8 通り）の組み合わせモデルを基に 58 通りの分類を参照対象として提案している。しかし、これらの分類においてはリスクがどの程度、各シナリオで発生するかは明確でなく、事故データ、ニアミスデータ等のエビデンスに基づく既知リスク（危険）との対応関係が分かりにくい。また、SOTIF では、リスク対応への難易度レベルともいべき既知安全、既知リスク、未知リスクが定義されているにも関わらず、未知リスクのエッジケースに関する議論に注目が集まりがちであり、リスクへの対応方法が曖昧で全体としてバランスを欠いている。現実的には、HIRA に基づく ODD の拡張にともない、既知リスク条件から未知リスク条件へどう対応するのかの説明性が重要である。さらに、現状では、既知リスク条件、未知リスク条件に対応する明確なテスト方法が存在せず、演繹的に妥当性のある安全性評価の考え方が実効性のある安全性評価に繋がらない原因になっている。

本プロジェクトでは、これまでの課題を踏まえ、特に、(A) 既知リスク条件に対応する「シミュレーションでのマイクロ評価のテスト方法」、(B) 未知リスク条件に対応する「偶発性を引出すランダム実験によるマクロ評価での統計的テスト方法」を提案する。詳細は 3 章以降で述べるが、要点を以下に示す。

- (A) ミクロ評価は既知リスク条件に対応するシミュレーションによるテスト方法の提案である。ただし、その範囲は事業者のリスクアセスメントによる ODD 条件によって決まる。
- (B) マクロ評価は未知リスク条件に対応する統計的テスト方法の提案である。偶発性を引出すランダム実験での予測を目的とするためシミュレーションでのみ実行可能である。
- (A)および(B)のテストにより ADS 運転行動を評価することで、ODD の拡張に繋がるとともに、製造業者の設計努力の説明性を向上させることが可能である。
- 本シミュレーションによるテスト方法の本提案は、リスクアセスメント（HIRA; Hazard Identification and Risk Assessment)に基づく設計行為に対するリスクシナリオ（既知+未知）評価方法と位置付けることができ、自動運転の社会実装への貢献が期待できる。
- ただし、自然環境を相手とした走行環境には 100%の安全を保証することは不可能であり、リスクをゼロに限りなく近づけるためには、設計努力の継続と実績（事実）に基づくフィードバックが不可欠である。市場調査機能の必要性が議論されている背景にはこのような事情があると想定できる。

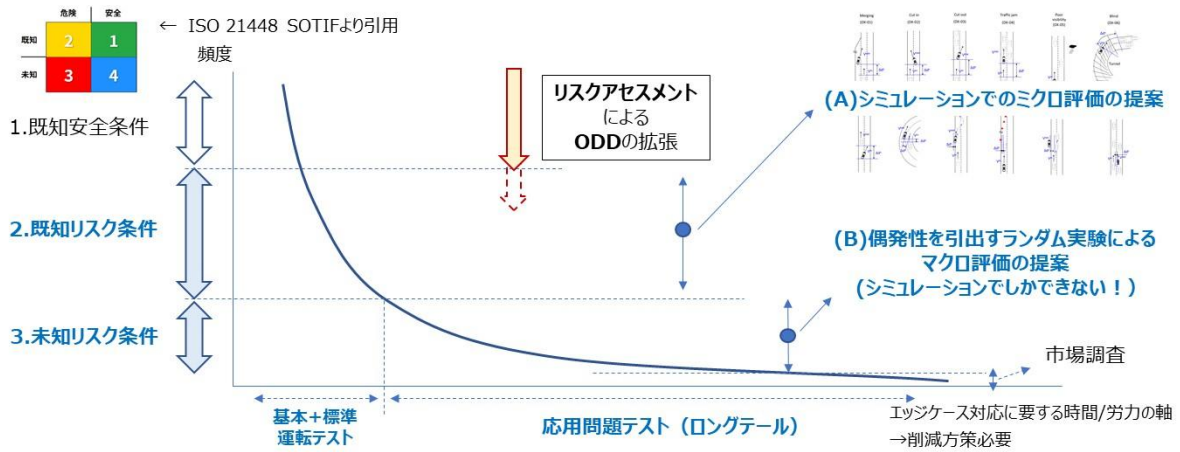


Fig. 2-2-1 Test Method Utilizing Simulation to Address Known/Unknown Risk Scenarios

2.3. 動的時空間としてのマイクロ/マクロのリスクシナリオ生成方法

次に、今回提案の「実効性のある自動運転車の安全性評価のフレームワーク」を図 2-3-1 に示す。以降、リスクシナリオの生成方法にフォーカスし、これら各プロセスについて概要を説明する。

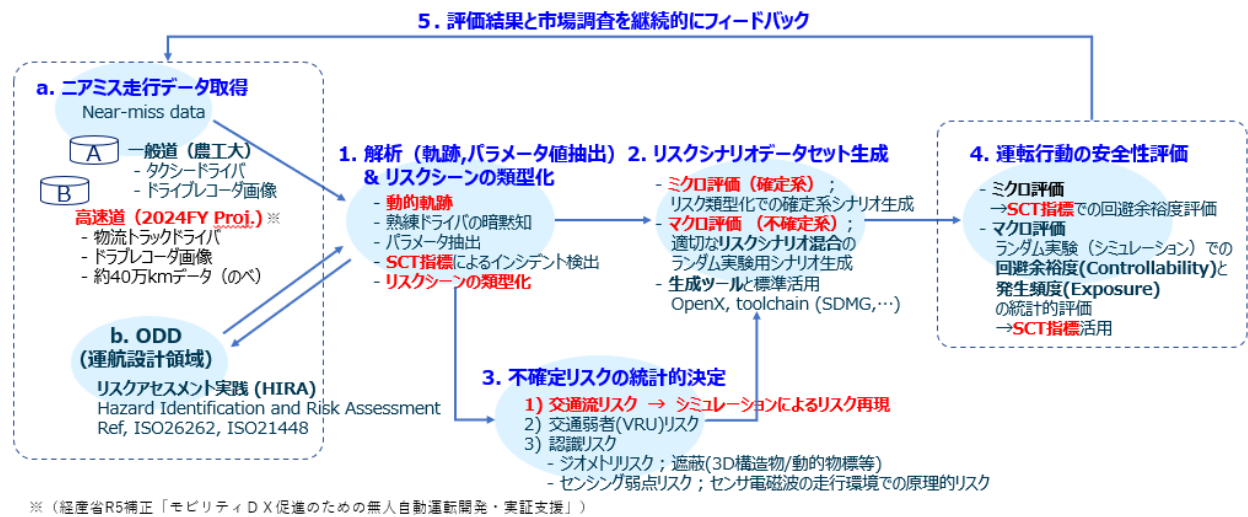


Fig. 2-3-1 Framework for Generating Micro/Macro Risk Scenarios and Safety Assessment Methods Using Simulation

2.3.1. HIRA、ODD を支援するニアミスデータ解析とリスクシーンの類型化

まず最初に市場調査によって得られた事故、ニアミス等を用いて、HIRA を支援するためのデータ解析とリスクシーンの類型化を行う。本プロジェクトでは 2024 年度の経済産業省自動車課のモビリティDX のプロジェクト¹⁹⁾で取得された高速道の物流トラック事業者による高速道での約 40 万 km のドライブレコーダデータから得られたニアミス走行データをソースとした。(一般道では、特に歩行者等の交通弱者と自車の関係性情報に詳しい農工大ニアミスデータが有効である。但し、データ量は十分とは言えず、今後、走行データのさらなる拡張・共有が課題である。)

詳細は 3 章以降で記述するが、データ解析とリスクシーンの類型化の要点は以下の通り。

- 映像解析から自車と他車の危険に至るまでの動的軌跡の抽出
- 各種パラメータ抽出
- SCT 指標によるインシデント検出
- リスクシーンの類型化：今回は、RoAD to the L4_テーマ3 プロジェクトと連携して類型化を行った。トラック OEM の専門家が中心となり熟練ドライバの暗黙知と経験データを整理した 829 項目のリスクシーン（ニアミス相当）を基に、高速道で高頻度に発生しているリスクシーンとして 12（典型類型）シーンを抽出した。加えて発生頻度は高くはないが、考慮すべきシーンとして 6（逆走など特殊シーン類型）を選び、計 18 分類にリスクシーンを類型化した。この類型にドライブレコーダデータから抽出したニアミスデータを振分けデータを蓄積した。

2.3.2. リスクシナリオデータセットの生成

先述のように、(A) 既知リスク条件に対応する「シミュレーションでのマイクロ評価」、(B) 未知リスク条件に対応する「偶発性を引出すランダム実験によるマクロ評価」を行うために、マイクロ評価テスト用とマクロ評価テスト用の 2 通りのリスクシナリオデータセットの生成を行う。ここでは(A)マイクロ評価用リスクシナリオデータセットについて概要を説明する。

12 のリスクシナリオ類型に蓄積されたニアミスデータを、SCT（後述 2.4 参照）の最小値が 3sec 以下（ニアミス大、中、小、衝突相当）という条件で絞込み、シミュレーションのマイクロ評価のためのリスクシナリオデータセットとする。この時 1-リスクシナリオは、SCT 最小値をトリガとした前後約 15sec（前 10sec、後 5sec）の時空間において、他車に対する自車の運転行動の結果、危険に至ったものとして定義している。これを類型毎の確定系リスクシナリオと呼ぶ。

2.3.3. 不確定リスクの統計的条件設定

次に (B) マクロ評価用リスクシナリオデータの生成について概略を説明する。

走行環境には、不確定なリスクが多く存在する。Pegasus project が定義した 6-Layers は走行環境を良く表したモデルである。これらをシミュレーションの観点からは、ASAM OpenDRIVE が主に道路構造などの静的要件を定義し、ASAM OpenSENARIO が、各交通参加者の関係性としてのそれぞれの動的軌跡を物理量として定義している。しかし、これらはリスクとしての不確定要素を表現し

たものではない。そこで、これらを参考にしながら、ニアミスデータを用いて統計的テストを行うために、次の3つを不確定要素としてのリスクとして定義した。

- (1) **交通流リスク**：主に動的なジオメトリ要件とし前後／横の相対速度の発生によりリスクを表現する。また、これらのリスクは人間ドライバのそれぞれの運転行動によって発生するため、ニアミスデータを用いて、各エージェントモデルとして適合させ統計的なアプローチへ反映する。
- (2) **交通弱者リスク**：一般道では、歩行者、自転車（サイクリスト）、等、安全上重要であるが、これらは危険行動が不確定なハザード要因である。自車から見た不確定リスクとしてニアミスデータからの(1)同様のアプローチが必要である。ただし、今回は、高速道路のため、本項目は対象外とする。
- (3) **認識リスク**：ここでは、ジオメトリ要件として(3)-a 遮蔽リスク（建物の陰からの飛び出し、トラック等交通参加者による遮蔽など）、(3)-b 天候悪化などセンシング弱点事象などでの認識リスクの2領域を定義する。(3)-bはカメラ、Radar、LiDARのそれぞれ可視光、電波、近赤外光の電磁波の物理原理的限界などを示す。今回の高速道路のリスクでは、本リスクの検討は対象外として、交通流リスクに絞って実践した。
(認識リスクについては、既にDIVPプロジェクト^{20) 21)}で多くの検討が行われており、シミュレーションでの評価の可能性についても実証されている。本研究では、認識リスクはODDの対象外の項目も多い事から対象外としたが、ODDの拡張に伴い対象としていく予定。)

2.4. 回避余裕度 (Controllability)²²⁾のための運転行動を評価する指標 (SCT) の意義

SIFAD (BMW) では、ポジティブリスクバランス (PRB: Positive Risk Balance) のリスク受容基準 (RAC: Risk Acceptance Criterion) として事故率が採用されている。しかし、事故率のみを RAC とすることは、いくつかの課題が存在する。第一に、事故率を基準とすると、設計上「事故の発生」を前提とした評価構造となり、倫理的観点からの抵抗が生じる。第二に、事故は極めて希少事象であるため、事故率は非常に小さな値となり、統計的に有意な評価設計が困難となる。第三に、将来、L3+ADS が市場に広く普及した場合、基準となる統計量の変化に柔軟に対応できない。何故なら ADS の普及により交通流全体の安全性が向上し事故率が低下した場合、「人間より事故が少ない」という PRB の根拠自体が揺らぐ可能性があるからである。

これらの課題に対し、事故率に加えて回避余裕度 (SCT、Safety Cushion Time) をリスク受容基準として用いることで、問題を解決できる可能性がある。SCT は、WP29 で最初に示された回避可能性の指標としても適切である。この指標を基準とすることで、設計上は「事故ゼロ」を前提とした評価が可能となり、倫理的にも受容しやすい評価構造を構築できる (以降、「回避余裕度 (Controllability) と表現する)。また、SCT は例えば「 $SCT \leq 1\text{sec}$ 」のような条件で定義することが可能であり、その発生確率は事故率と比べて十分に高い。このため、統計的評価の設計が著しく容易になる。さらに、ADS の普及により交通流が安全化し平均 SCT が増大した場合でも、基準 SCT 値を再設定すること

で、設計上の発生確率を維持できる。このため、PRB を「人間以上の SCT を確保する」と定義し直すことで、SIFAD の大部分の枠組みや定義をそのまま共有できると考えられる。

事故率を RAC とする際の本質的な問題は、事故が「安全余裕が不足した事象」の連鎖の末端に現れる結果事象である点にある。事故そのものを直接評価対象とすると、統計的に利用可能な情報量が極端に小さくなる。実効的な統計的安全性評価を行うためには、事故に至ったか否かという離散的結果ではなく、事故に至るまでの過程を連続量として観測・評価可能な指標を基準とすることがロバストな安全設計には望ましい。

SCT をリスク受容基準とした場合、以下の利点が得られる。SCT は事故未満の状態を大量に観測可能であり、事故という希少事象を直接観測せずとも評価が可能となることから、以下の利点も得られる。事故数ではなく SCT 分布を用いることで、サンプル数不足に起因する評価の不安定性を回避できる。また、「事故が起きなかった」という消極的事実ではなく、「十分な安全余裕が確保されていた」という積極的な根拠を安全論証として提示できる。さらに、市場投入後に KPI として SCT を継続的に監視することで、事故を未然に防止する運用的安全プロセスへの展開も可能となる。

なお、SCT は、今回のシミュレーション活用時に限ったものではなく、実車の評価にも使える定量指標である。(3.3 節記載の SCT 評価指標の数理モデルとリスク定義参照。さらに DIVP プロジェクトは現在実車評価を実施中であり、2025 年度事業の成果としてその結果も近日中に公開される予定である)。

3. 実効性のある自動運転車の安全性評価のフレームワークの詳細

2.3 で記載の「実効性のある自動運転車の安全性評価のフレームワーク」(図 2-3-1) のパイプラインについて、本デジタルライフライン整備事業のプロジェクトでの具体的な実践例を示しながら、項目毎に詳細を説明する。

3.1. ニアミス走行データの取得 (&ODD)

今回、ODD は新東名の L4 トラック走行 100 km 区間(駿河湾沼津 SA~浜松 SA)を想定し、令和 5 年度補正「モビリティ DX 促進のための無人自動運転開発・実証支援事業(データ取得事業)」¹⁸⁾で取得した高速道路の走行データからニアミスデータを抽出して、検討を進めた。

このニアミス走行データは以下のような特徴を持つ。

- (1) 29 台(物流トラック:19 台、乗用車:10 台)にドライブレコーダ(前方、後方、右側方、左側方カメラの 4ch、GNSS 装置)を搭載し、関東~中部~関西の高速道路・自動車専用道路を走行し取得したデータを基にニアミス走行データを抽出。
全車両による総走行距離 約 40 万 km (図 3-1-1) 走行のデータ。
- (2) 一般的な減速度トリガでの記録方式は使用せず、常時録画方式でデータを記録。
これは、RoAD to the L4 プロジェクトテーマ 3(新東名 L4 トラック)の一部メンバからの意見を取り込み実現し、結果として、以下の様な特徴を持つデータが取得できている。
 - ・トラックドライバの多くが危険(潜在的なハザードも含む)と感じている、二輪車のすり抜け、路駐のトラック、落下物、居眠りによる車両のふらつき等 減速度が出ないデータも多く取得した。
 - ・常時記録データから、人間の主観によるニアミスシーンの抽出を行っているため、人間の暗黙知によるリスク(潜在的ハザードも含む)が含まれており、さらに機械的には抽出できないシーン(連続的・複合的なシーンも含め)等も取得できている。
 - ・トラックドライバの視点でのニアミスが取得できており、大型トラックは、乗用車などの小型車に比べ、車両としての機敏な動きがとれないことや、荷崩れなどを防ぐために高い減速度をかけられないことなど、車両としての運動性能の差が大きいことから起因する大型車特有のリスクシーンもトラックドライバからの視点から多く取得できている。
- (3) データ取得後、人による主観評価によりニアミスシーンを抽出し、ニアミス発生時間±30 秒の MP4 動画(例:図 3-1-2)で格納した。

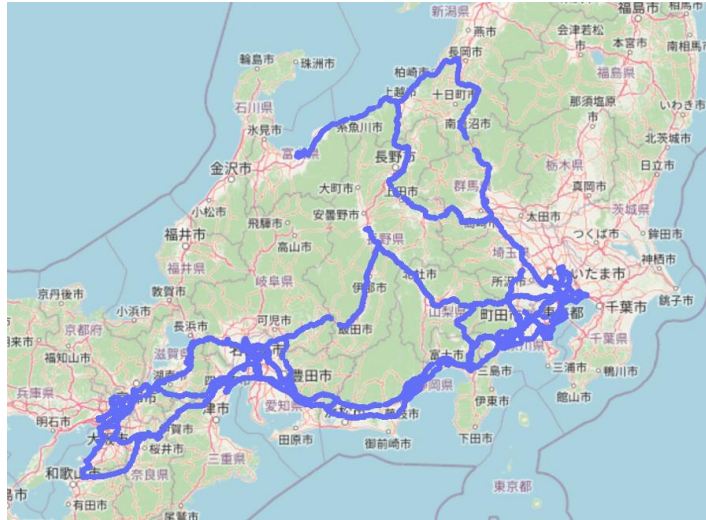


Fig. 3-1-1 Data acquisition areas on expressways and dedicated expressways
 高速道路・自専道でのデータ取得エリア

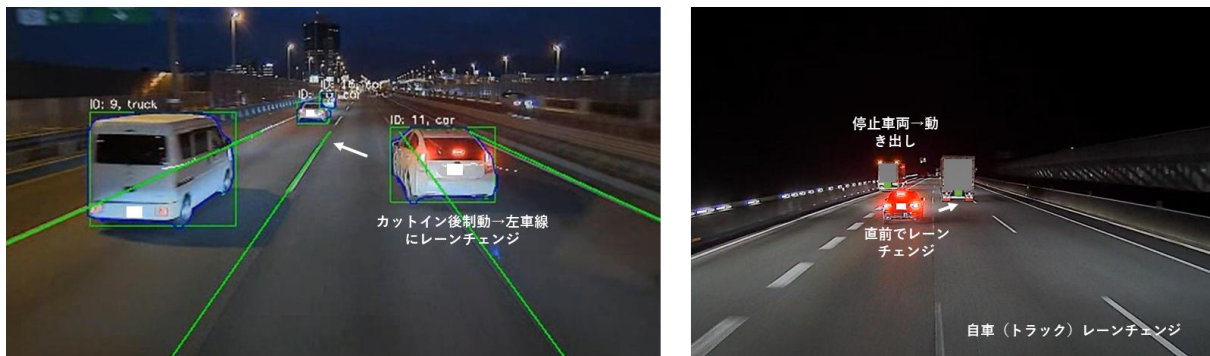


Fig. 3-1-2 Near-miss data examples
 (Lane change after cut-in, merging with stopped vehicles)
 ニアミスデータ例 (カットイン後レーンチェンジ、停止車両の合流)

2026年2月10日時点での、常時録画データからの人による主観評価でのニアミスデータの抽出数は、以下の通り。

Table 3-1-1 Near-miss incidents detected
 ニアミス抽出件数

ニアミスレベル		件数
ニアミス	大	1,476
	中	4,031
	小	8,283
計		13,790

今回、ODD については、新東名のL4トラック走行100km区間（駿河湾沼津SA～浜松SAで発生する可能性のあるニアミスシーンを対象とした。

(ニアミス発生情報表示マップ)

標記で説明した29台の物流トラック・乗用車のニアミスデータには、GNSS情報が含まれているため、その情報からニアミス発生情報表示マップ（ツール）を開発した。これによりODDに応じて、その地域的高速道路・自専道のニアミス情報が参照可能である。本ツールは、「実効性のある自動運転車の安全性評価フレームワーク」を行うための情報ツールとして、ユーザが活用できるように拡張していく。詳細は、APPENDIX Dを参照。

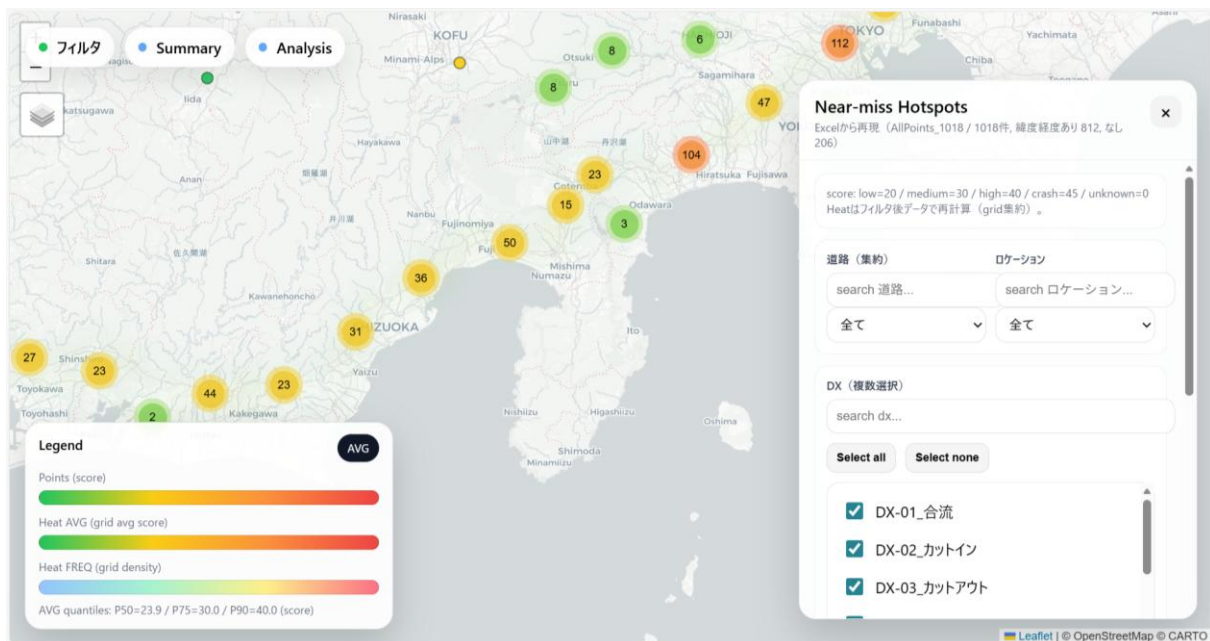


Fig. 3-1-3 Near-miss incident display map
ニアミス発生情報表示マップ

3.2. ニアミス走行データの解析

ここでは、3.4以降で説明する「リスクシナリオデータセット生成」のベースとなる技術・考え方である「3.2.1. 映像解析から自転車と他車の危険に至るまでの動的軌跡抽出」、「3.2.2 リスクシーンの類型化」について解説する。

3.2.1. 映像解析から自転車と他車の危険に至るまでの動的軌跡抽出

主観でニアミスと判断されたドライブレコーダ映像から、自転車および対象車両の動的軌跡を定量的に抽出し、SCT算出に必要なパラメータを取得する。本節では、映像解析によってSCT算出に必要な相対距離を計測する手法について述べる。

本手法は、令和5年度補正「モビリティDX促進のための無人自動運転開発・実証支援事業（データ

取得事業)」事業報告書（令和7年3月）¹⁸⁾で研究開発された手法に基づいている。この手法は、映像解析による相対距離の算出手法として、前後方向相対距離 30m において、前後方向誤差 1.0m、横方向誤差 0.5m 程度の計測精度を実現している。詳細は、同報告書 6 章を参照されたい。

この計測方法は直進道路への適用であったため、今回のプロジェクトでは、カーブでの計測も考慮し改良を加えた。具体的には、白線認識処理を追加することによって、カーブでの横方向距離の精度も確保することができた。以下にそのプロセスの詳細を記す。

(1) 映像解析の処理フロー

ドライブレコーダの映像から SCT 算出用パラメータを抽出するまでの処理フローを以下に示す。



Fig. 3-2-1 Image analysis processing flow
処理フロー

1. ドライブレコーダ映像の入力
2. レンズ歪み補正（キャリブレーション）
3. YOLO²³⁾による物標検出およびトラッキング
4. 各フレームにおけるカメラ位置から対象車両までの距離計測
5. HybridNets による白線認識（車線区画線検出）
6. 自車の車線内横位置の推定
7. 対象車両と白線間の距離推定
8. 自車・対象車両間の横方向距離の算出
9. SCT 算出用パラメータの抽出

2. から 9. までの各プロセスの内容は以下の通り。

(2) レンズ歪み補正

ドライブレコーダのカメラレンズには広角レンズが使用されているため、撮影映像には歪みが生じる。映像中の車両位置や白線位置を正確に推定するためには、この歪みを事前に補正する必要がある。

カメラの内部パラメータ（焦点距離、光学中心、歪み係数）を用いて、OpenCV の機能により各フレームの歪み補正を行う。補正後の画像を以降の物標検出および白線認識の入力として使用する。

(3) YOLO による物標検出・トラッキング

歪み補正後の映像に対して、YOLO (You Only Look Once) をベースとした物体検出モデルを適用し、各フレーム内の車両（四輪車、二輪車、トラック等）をバウンディングボックスとして検出する。更にセグメンテーション処理を行い車両の両端のピクセル位置を決定することで横位置精度を向上させる。

検出された車両に対して、フレーム間のトラッキング処理とともに同一車両の ID を割り当てることで、時系列的な車両の動きを連続的に捕捉する。これにより、対象車両の画像上のフレームごとの位置変化を取得する。

(4) カメラ-対象車両間の距離計測

各フレームにおいて、検出した対象車両の両端のピクセル位置とカメラの内部パラメータ（焦点距離等）を利用し、カメラ位置（≡ 自車位置）から対象車両までの相対距離を計測する。

これにより、各フレームでの自車と対象車両の相対距離の時系列データが得られ、相対速度の算出が可能となる。

(5) HybridNets による白線認識

歪み補正後の画像に対して、HybridNets を用いてセマンティックセグメンテーションによる車線区画線としての白線認識を行う。HybridNets は物体検出、走行可能領域検出、車線検出を同時に行えるマルチタスクモデルであり、車線区画線の領域をロバストに検出できる。

ただし、HybridNets による検出結果は区画線（白線）と想定される領域を示すのみで、一本毎の白線には分割されていない。従って、白線位置推定用パラメータ（地平線高さ(px)および画像下端における想定白線幅(px))を用いて白線に分割し、実空間上の白線位置を推定する。具体的には、地平線高さ情報を基に画像消失点付近の複数の白線が集約される領域をマスクングする、また、画像下端の白線領域を想定白線幅でフィルタリングするといった処理を行って一本毎の白線に分割している。これにより、各フレームにおける車線幅および車線境界の位置情報を取得する。

(6) 自車と白線間の距離推定

HybridNets で検出した左右の白線位置と、自車のカメラ搭載位置（車幅中心からのオフセ

ット) から、自車の左端から左側白線までの距離、および右端から右側白線までの距離を各フレームで算出する。

(7) 対象車両と白線間の距離推定

YOLO で検出し推定した対象車両の左右端と、同フレームでの HybridNets の白線検出結果を照合し、対象車両の両端から最寄りの白線までの距離を推定する。対象車両が自車と同一車線にいるか、隣接車線にいるかの判定もこの情報をもとに行う。

(8) 自車・対象車両間の横方向距離の算出

上記(6)(7)で得られた、自車両端から白線までの距離、および対象車両両端から白線までの距離を統合し、自車と対象車両の横方向距離を算出する。白線を基準座標とすることで、道路のカーブ等による横方向の相対位置のずれを抑制し、自車および他車の想定進行方向(車線方向)を考慮した横方向の相対位置を推定できる。

(9) SCT 算出用パラメータの抽出

上記の映像解析プロセスにより、各フレーム(時刻)における以下のパラメータが取得され、SCT (Safety Cushion Time) の算出に用いられる。

Table 3-2-1 Available parameters

取得できるパラメータ

パラメータ	説明
前後方向相対距離	自車と対象車両の前後方向の距離(各フレーム)
前後方向相対速度	前後方向相対距離の時間微分から算出
横方向相対距離	白線基準による自車・対象車両間の横方向距離
横方向相対速度	横方向相対距離の時間微分から算出
自車走行車線	白線認識に基づく自車の車線位置
自車速度(推定)	車載データから取得または映像のフレーム間解析

これらのパラメータにより、SCT_x(前後方向) および SCT_y(横方向) が計算され、ニアミスリスクの定量的評価が可能となる。算出された SCT の詳細は次節(3.3)で述べる。

3.2.2. リスクシーンの類型化

2.3.1.節で述べた通り、高速道・自専道のニアミスデータのリスク分析を行うにあたり、対象となるリスクシーンの類型化を実施した。先述した通り、類型化の策定においては、ニアミスの発生に寄与する主要な「誘因因子(要因)」に着目した。具体的には、発生頻度の高い事象を網羅した「典型類型(12シーン)」に、逆走や特殊な走行環境下での事象を含む「特殊シーン類型(6シーン)」を加え

た、計 18 シーンの種類を定義した。

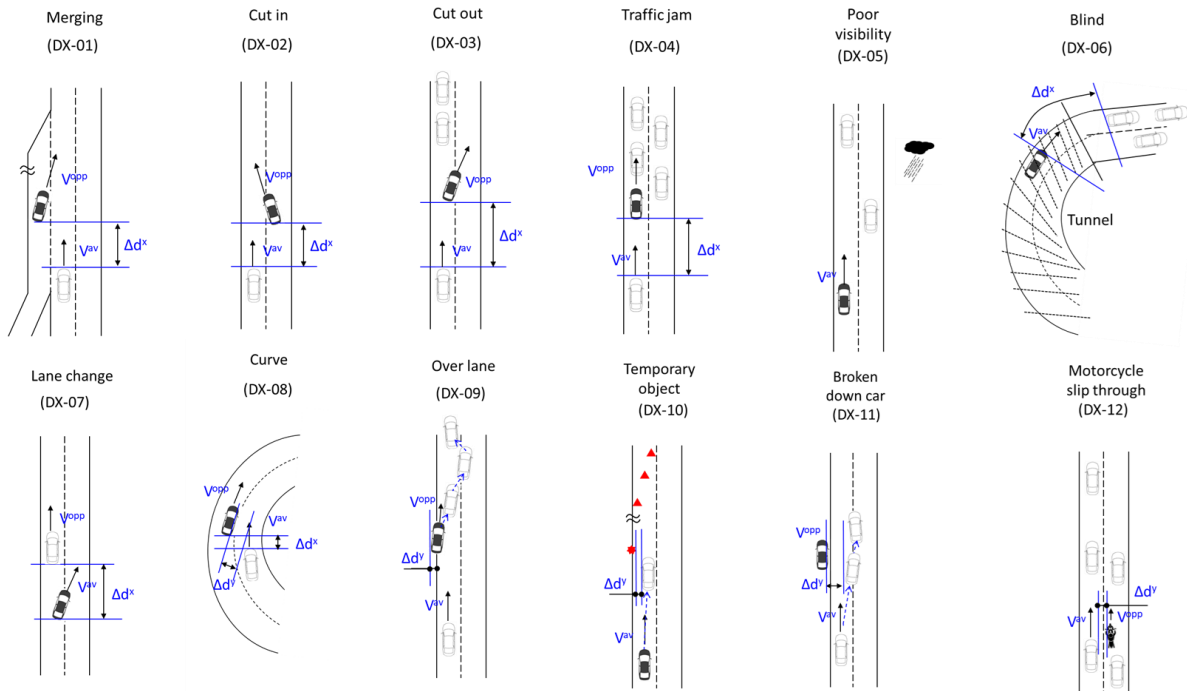


Fig. 3-2-2 Typical categories (12 scenes)
典型類型 (12 シーン)

No	ニアミス誘引因子	具体的なシーン例	No	ニアミス誘引因子	具体的なシーン例
13	ETC Gate (DX_13)	 車線なし	16	Emergency car (DX_16)	 緊急車両の回避
14	SA/PA/AV Hub (DX_14)	 SA出入口の駐停車両	17	Wrong-way car (oncoming car) (DX_17)	
15	Pedestrian /Animal (DX_15)	 落下物回収 故障車の周辺の歩行者	18	Disaster (DX_18)	

Fig. 3-2-3 Special categories (6 scenes)
特殊シーン類型 (6 シーン)

ニアミスデータの各類型への分類およびリスクレベル付け（ニアミス大、中、小）は、評価者の主観評価に基づき実施した。類型化にあたり、ニアミスの誘引因子（要因）は、地形的要因、環境要因、ジオメトリ要因（2車間の物理的位置関係）といった複数の誘引因子が複合的に関与しているが、本

評価では最も支配的な要因に基づき分類を行った。また、人間の判断による抽出は、工数面では課題があるものの、機械的な手法では検知が困難な「人間が感じているリスク（ハザードも含む）」を捉えることが可能であり、有効かつ意味のあるリスクシーンを網羅的に抽出できている。

こうして抽出されたニアミスデータは、次節 3.3 で説明する SCT 評価指標を用いて定量的なリスクの解析を行い、3.4.章以降で説明する「リスクシナリオデータセット」へと構造化される。

参考までに、現時点（2026年2月10日）でのニアミス抽出実績を表 3-2-1 に示す。約 14、000 件のニアミス事象を蓄積しているが、類型（シーン）により抽出件数は異なる。特に「拡張 6 類型」については、希少性が高く一例一例が極めて貴重なデータであると位置づけている。

Table 3-2-1 Number of near misses detected based on subjective judgment (February 10, 2026)

ニアミス抽出件数（2026年2月10日）

ニアミスレベル	件数	合流	カットイン	カットアウト	渋滞	視界不良	ブラインド	レーンチェンジ	カーブ	車線逸脱	落下物	故障車	二輪車	料金所	SA,PA	歩行者	緊急車両	逃走	災害
ニアミス 大	1,476	217	379	23	108	17	17	293	4	96	91	161	42	1	19	5	2	1	0
ニアミス 中	4,031	558	1,275	129	239	61	21	380	30	183	539	474	49	9	65	10	7	2	0
ニアミス 小	8,283	743	3,495	201	328	161	61	334	52	296	955	1,414	151	9	47	20	16	0	0
ニアミス総計	13,790	1,518	5,149	353	675	239	99	1,007	86	575	1,585	2,049	242	19	131	35	25	3	0

また、18 類型については、RoAD to the L4 テーマ 3 で定義された 829 項目のリスクシーン（ニアミス相当事象）に基づき、優先度解析を実施した。具体的には「深刻度×頻度」による評価指標を用いて順位付けを行い、大型トラックの自動運転において特に留意すべき上位 4 つのリスクシーンの類型を抽出した。「深刻度」、「頻度」は、以下の指標である。「深刻度」×「頻度」により、各リスクシーンを評価した。

深刻度：リスクシーンの深刻度合い（危険度）を、3 段階で評価（1 が最小、3 が最大）

頻度：リスクシーンの発生頻度を、3 段階で評価（1 が最少、3 が最多）

1. 二輪車 近接追越し・すり抜け
2. 合流・分岐
3. カットイン／レーンチェンジ
4. 視界不良（路面不良）／故障車・停止車

本検討においては、これら 4 類型の中でも「1.二輪車 近接追越し・すり抜け」は、遭遇頻度が低く、現時点では十分なサンプル数の確保（N500 以上：3.5.3 節参照）が困難であった。そのため、比較的数据蓄積が進んでいる「合流（分岐）」「カットイン」「レーンチェンジ」の 3 類型を重点解析対象として選定した。

これらのリスクシーンに焦点を充て、「データの解析」から「リスクシナリオの生成」さらには「自動運転行動の評価」に至る一連のプロセスの構築およびシミュレーションでの実証を試行した。

3.3. SCT 評価指標の数理モデルとリスク定義

2.4節では、SCT (Safety Cushion Time) 指標の意義・概念について述べた。本節では、SCT 指標の具体的な数理モデル、およびリスクレベル (衝突、ニアミス大、中、小) を判定するための定義について詳述する。

まず、図 3-3-1 に示す 2 車間の相対関係に基づき、直進する自車両 (main 車両) に対して関係車両 (Opponent) がカットインするシーンを想定する。本指標は 2 車間のリスクを「余裕度 (距離、時間)」として定量化したものである。本数理モデルの最大の特徴は、余裕度 (時間) の算定式において、TTC (Time to Collision) 項に「減速度項」を組合わせている点である。具体的にはパラメータとして設定した減速度による制動時間 (および制動距離) を明示的に考慮した上で、具体的な回避余裕度 (時間、距離) を定義している。

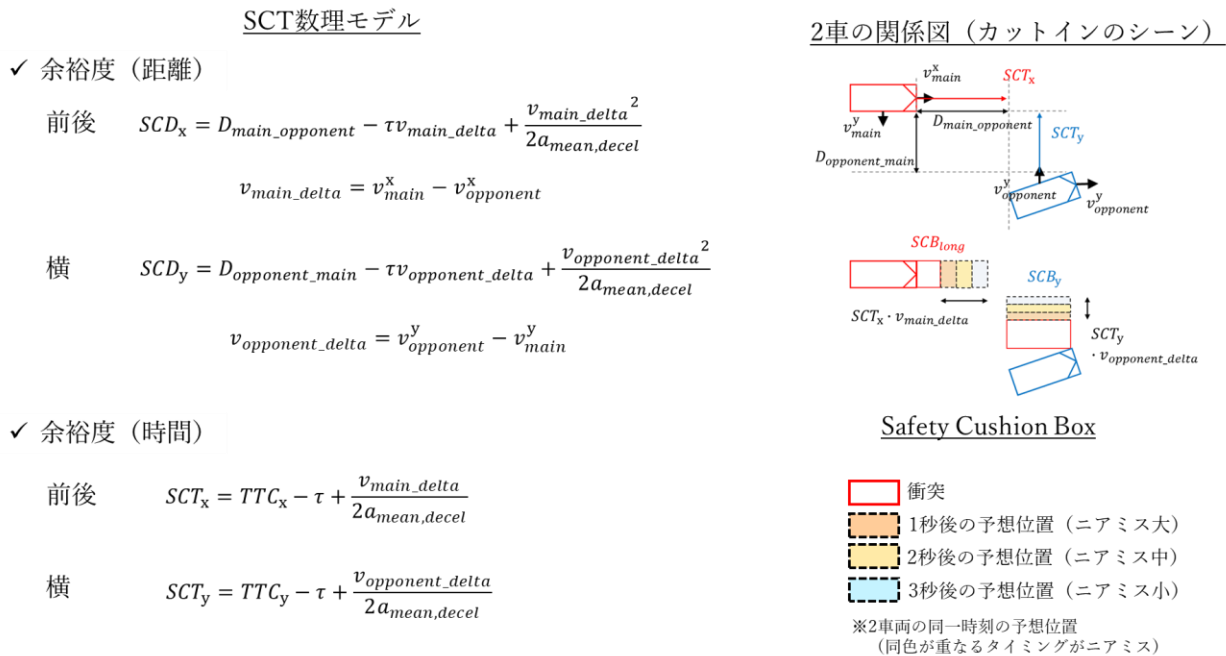


Fig. 3-3-1 Definition of safety cushion time & safety cushion box on expressways and dedicated expressways

高速道・自専道での SCT 数理モデル & Safety Cushion Box の定義

本稿では、パラメータ値を、以下で定義している。

$$a_{main,decel} = 0.3 \quad [G]$$

$$\tau = 0.75 \quad [sec]$$

3.3.1. パラメータ設定の根拠

自車の減速度 $a_{main,decel}$ の設定にあたっては、一般的な車間維持や停止時使用される制動性能を基準とした。ACC (Adaptive Cruise Control system) 等における一般的な減速度は 0.15G から 0.25 G とされており、国際規格 ISO 15622²⁴⁾ においても、ACC の自動減速度は最大でおよそ 0.35 G を

超えないことが基準とされている。一方で、大型トラック・バスにおいては、荷崩れや乗員の転倒防止の観点から、許容される最大減速度は0.3G程度と言われている。この背景を踏まえ、本モデルでは減速度を0.3Gと設定した。また、空走時間 τ については、一般財団法人日本自動車工業会発行の「自動運転の安全性評価フレームワーク Ver4.0」¹⁸⁾ に定義されている一般ドライバの制動遅れ時間を引用し、0.75sec とした。

3.3.2. リスクレベルの判定定義

リスクレベル（衝突、ニアミス大、中、小）の判定は、図 3-3-1 に示す「Safety Cushion Box」概念に基づき、前後方向の余裕時間（SCT_x）と横方向の余裕時間（SCT_y）の重複状況によって定義する。具体的には、設定した減速度（ $a_{\text{main.decel}} = 0.3 \text{ [G]}$ ）による制動を前提とし、以下の基準で判定を行う。

リスクレベル	判定基準（Safety Cushion Box の重複）
衝突	$SCT \leq 0$ 秒で SCT _x 、SCT _y が重複
ニアミス大	$0 \text{ 秒} < SCT \leq 1 \text{ 秒}$ で SCT _x 、SCT _y が重複
ニアミス中	$1 \text{ 秒} < SCT \leq 2 \text{ 秒}$ で SCT _x 、SCT _y が重複
ニアミス小	$2 \text{ 秒} < SCT \leq 3 \text{ 秒}$ で SCT _x 、SCT _y が重複

図 3-3-2 に、ドライブレコーダから抽出した実際のカットインシーンにおける SCT 指標の推移例を示す。グラフ内の SCT_x は前後方向、SCT_y は横方向の余裕時間をそれぞれ表している。自車の右側車線から、車両がカットインすることで、前後方向、横方向の余裕時間が小さくなり、Safety Cushion Box の黄色同士が重複しており、本ケースは、ニアミス中となる。

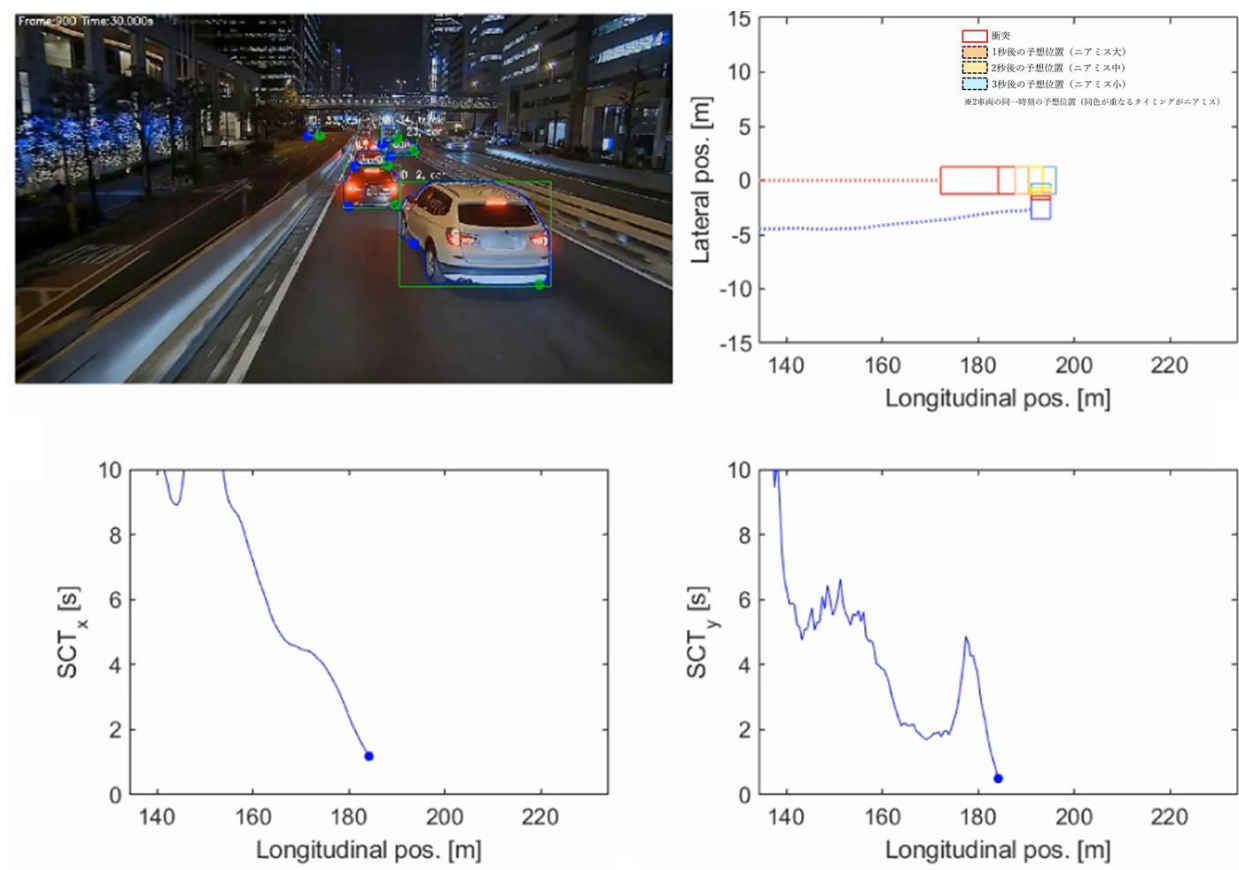


Fig. 3-3-2 An example of data analysis using SCT metrics in cut-in scenes
 カットインシーンでの SCT 指標によるデータ解析例

前述の通り、SCT 指標を用いて自車と他車の接近リスク（ニアミス）を数値化・可視化することで、潜在的なリスクの度合いを動的かつ直感的に表現することが可能となる。従来の TTC などの指標と異なり、運転行動を内包した「時間的・空間的な回避余裕度」を指標とすることで、複雑に変化する交通環境下のリスクレベルを、実態に即した形で定量的に把握できる点が本手法の大きな優位点である。

3.3.3. SCT 指標の活用方法とパイプラインへの適用

本提案のパイプライン（図 2-3-1）において、SCT 指標は主に以下の 3 つの側面から活用される。これにより、定性的な事象から定量的な安全評価までの一貫した処理を実現している。

(1) ニアミスデータの定量的リスク抽出トリガ

リスクを SCT 値によって定量化し、動的な時空間における「ニアミス（インシデント）発生地点・タイミング」を特定するトリガとして活用方法する。

- ・具体的な適用：3.4 節において詳述する通り、SCT 値が 3 秒以下の高いリスクデータを絞り

込むための指標として用いる。

- ・**リスクシナリオ化**:抽出された「ニアミス(インシデント)発生地点・タイミング」を基準に、前後15秒間(発生前10秒、発生後5秒)の区間を「リスクシナリオ」として定義し、解析対象としている。

(2) 運転行動の安全性評価指標(マイクロ評価への適用)

個別のリスクシーンの類型化での車両挙動(運転行動)を対象としたマイクロ評価において、車両および周辺車両の安全性評価指標としてSCTを用いる。

- ・**評価内容**:特定の走行シーンや回避挙動における回避余裕度の推移をSCT値で評価し、自動運転アルゴリズムの妥当性や安全性を検証する。

(3) ニアミス発生確率の算出(マクロ評価への適用)

3.5節で述べるマクロ評価(交通流シミュレーション)の結果に対し、SCT指標の「Safety Cushion Box」の概念を適用してニアミス(インシデント/アクシデント)発生件数を算出する。

- ・**算出方法**:シミュレーション内でのニアミス(インシデント/アクシデント)発生件数を、時間単位(件/時間(h))または走行距離単位(件/km)を集計する。
- ・**最終指標**:これらを集計することで、最終的な「ニアミス(インシデント/アクシデント)発生確率」として定量化し、広域的な安全性の評価指標とする。

補足:パイプラインとの対応

具体的な適用箇所として、(1)(2)については3.4節(マイクロ評価;リスクシナリオ生成)、(3)については3.5節(マクロ評価)において説明する。

3.4. ミクロ評価;リスクシナリオの生成

2.3.2で概略を記載した(A)ミクロ評価テスト用のリスクシナリオの生成方法について、詳細に記載する。先述したように、ここではカットイン、合流、レーンチェンジの3分類について、ミクロ評価用のリスクシナリオのデータセットの生成方法を説明する。

3.4.1. リスクシナリオの絞込み方法

ここでは、カットイン、合流、レーンチェンジについて、それぞれN=500以上のニアミスデータの中から、ミクロ評価用のリスクシナリオを絞り込む方法について説明する。

N=500は、取得されたニアミスデータからリスクを定量的に解析するために統計学的に必要なサンプル数である。詳細は、3.5.3で説明する。

最初に、N500以上のニアミスデータから、リスクの高いデータとして、 $SCT \leq 3$ [秒] で SCT_x 、 SCT_y の Safety Cushion Box が重なるデータを抽出する(図3-4-1参照)

カットインについては、以下となった。

(カットイン)

- ・解析データ : 509 データ
- ・絞込みデータ : 22 データ (SCT ≤ 1 秒 : 6、1 秒 < SCT ≤ 2 秒 : 7、2 秒 < SCT ≤ 3 秒 : 9)

SCT_x、SCT_y の Safety Cushion Box (SCB) が重複する具体的な事例を図 3-4-1、図 3-4-2 に示す。図 3-4-1 の右の図では、カットインのタイミングでの、SCB の重複を右図に示す。黄色部が重なっているため、1 秒 < SCT ≤ 2 秒 (ニアミス中) となる。

SCT_x、SCT_y の Safety Cushion Box が、SCT=2秒で重複

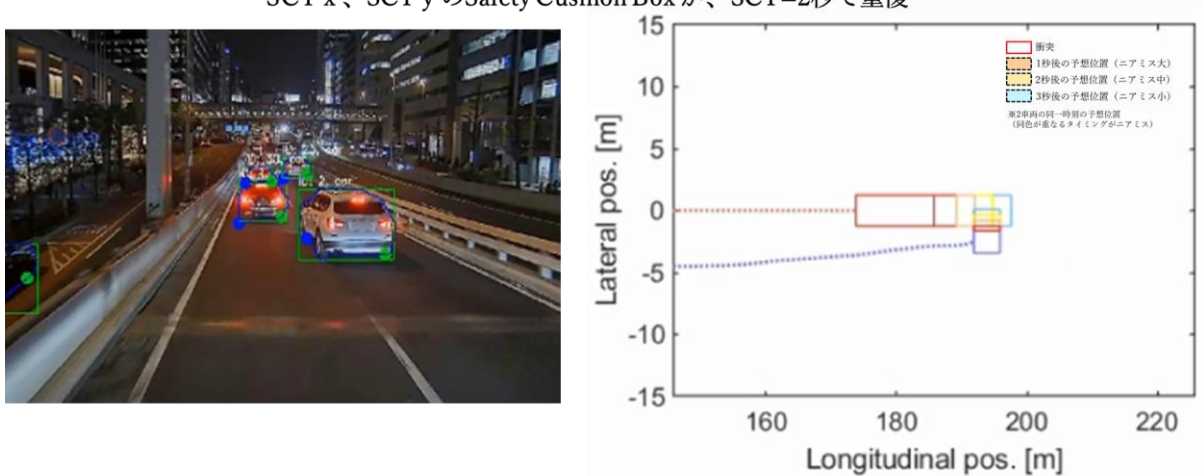


Fig.3-4-1 Analysis results showing duplicate data for the SCT_x and SCT_y as Safety Cushion Boxes
SCT_x、SCT_y の Safety Cushion Box が重複するデータ解析結果

図 3-4-2 では、カットイン後に、相対速度が大きくなるシーンや近距離で前後方向に接近する、カットインデータでの SCT_x ≤ 1 秒での重複の事例を示す。

カットイン後に、Safety Cushion Box が、SCT_x=1秒で重複

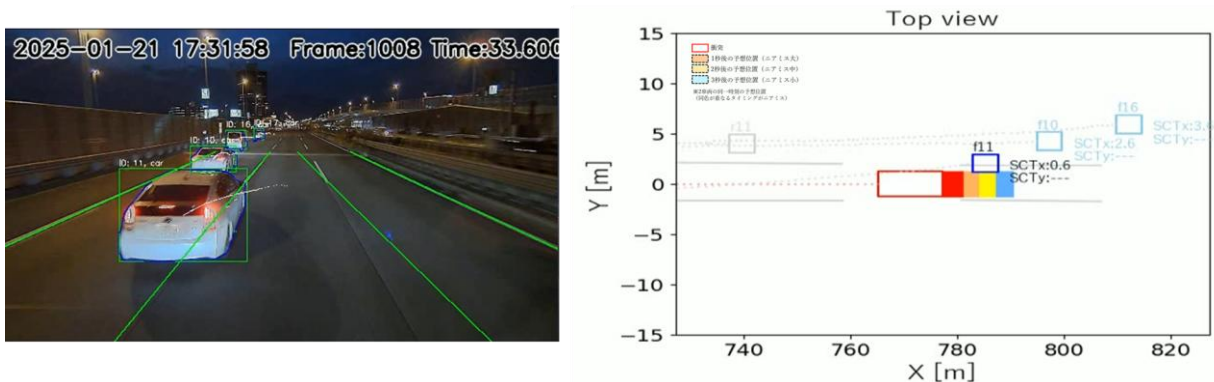


Fig.3-4-2 Data where SCT ≤ 1 second after the cut-in
カットイン後に、SCT_x ≤ 1 秒 のデータ

合流、レーンチェンジも同様な方法で、絞込みを行った。

(合流)

- ・解析データ : 502 データ
- ・絞込みデータ : 34 データ ($SCT \leq 1$ 秒 : 3、 $1 \text{ 秒} < SCT \leq 2$ 秒 : 9、 $2 \text{ 秒} < SCT \leq 3$ 秒 : 22)

(レーンチェンジ)

- ・解析データ : 502 データ
- ・絞込みデータ : 23 データ ($SCT \leq 1$ 秒 : 1、 $1 \text{ 秒} < SCT \leq 2$ 秒 : 10、 $2 \text{ 秒} < SCT \leq 3$ 秒 : 12)

次に、絞込みされたデータをリスクシナリオ (OpenX 形式) 化するための定義 (2.3.2 で記載) の仕方について、具体的にカットインのリスクシナリオを例に説明する。

図 3-4-3 は、カットインのニアミスデータの相対距離 (前後)、相対速度 (前後) の時系列のグラフを示す。横軸 10 秒が SCT 値が最小となるタイミングで、定量的なリスクが最大となる。そこを起点に +5 秒、-10 秒の前後 15 秒間が、動的な時空間のリスクシナリオとした。カットイン車が、1) 白線を横切り、2) 自車の前にカットイン車が進入することで、リスクが高まり (dSCT 値が急下降: 図 3-4-3 右下 dSCT) し、 $dSCT (SCT_x - SCT_y) \rightarrow 0$ [秒] となる。dSCT 値は、 SCT_x (前後方向の余裕時間) に対する SCT_y (横方向の余裕時間) となり、 SCT_x と SCT_y の重複を表す。

以下に、1つのリスクシナリオ (1-リスクシナリオ) の構成をさらに詳しく記載する。

図 3-4-3 で示す様に、「1-リスクシナリオ」は、次の (a) と (b) で構成される。

(a) リスクに至るまでのシナリオ

- ・リスクが高まる前までの、自車の位置、車速、走行車線等、カットイン車との相対的初期の関係性等のパラメータの動的な変化を示す。本例は、自車速度が約 25km/h の渋滞開始地点でのシナリオとなり、今回抽出したカットインの 22 データは、自車の位置、車速、走行車線等の各パラメータの組合せが異なるシナリオとなる。

(b) リスクが発生している区間のシナリオ

- ・リスクが動的に、急激に高まる区間のシナリオとなる。2車の相対的關係は、dSCT で示す様に、横方向の時間余裕 (SCT_y) に対する前後方向の時間余裕 (SCT_x) の差で、動的に危険に近づく様子をリスクシナリオとして示す。

リスクが高まる区間は、(b) であるが、そこに至るまでの (a) の区間は、ODD に基づき決定される条件内での 2車間の初期パラメータであり、(a) と (b) が組み合わさることで、動的なリスク変化が定義できる。

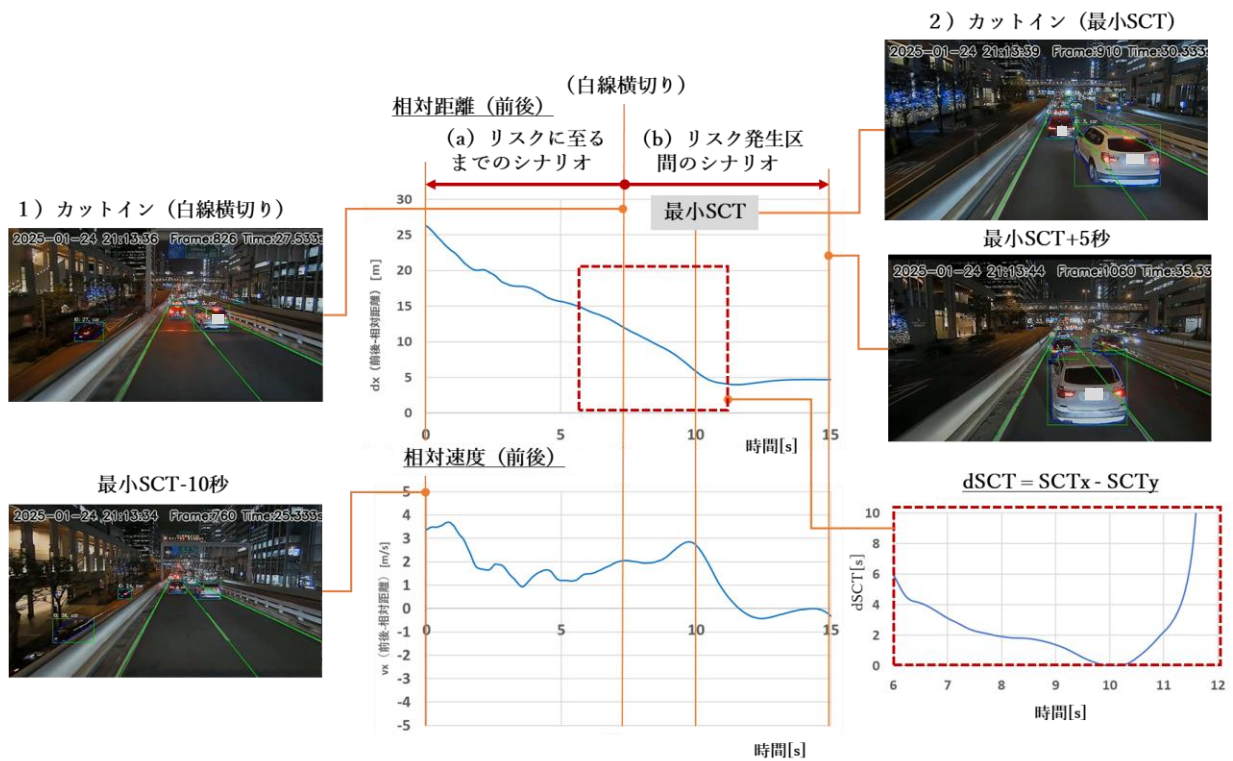


Fig. 3-4-3 Example of a risk scenario as a single scenario

1-シナリオとしてのリスクシナリオ例

(a) で示した各パラメータ (自車の位置、車速、走行車線等) は、リスクが最大 (最小 SCT 値) となる地点での、絞込みされたデータの各パラメータの統計データ (分散値) から、以下の範囲となる。

Table 3-4-1 Parameters extracted through image analysis (cutting in, merging, lane changes)
画像解析により抽出されたパラメータ (カットイン、合流、レーンチェンジ)

分類	データ数	パラメータ					
		dx [m]	vx [m/s]	vy [m/s]	vego [km/h]	dy [m]	
DX-01	Merging	34/502	5 - 51	0.7 - 11	-1.6 - 2.4	0 - 87	
DX-02	Cut-in	22/509	5 - 41	1 - 10	-2.1 - 2.4	26 - 113	
DX-07	Lane-change	13/502	7 - 26	1.3 - 7	-1.6 -1.4	1.8 - 126	-

3.4.2. ミクロ評価用リスクシナリオデータセット

3.4.1. で、カットイン、合流、レーンチェンジについてのデータの絞込みおよび「1-リスクシナリオ」としてのパラメータ範囲の定義の実践例を示したが、標記3類型以外については同様の考え方でよいのかについて、検証する。

表 3-4-2 で、現状のニアミスデータの抽出件数の状況を示す。各類型 (シーン) 毎にデータの収集数に差があり、N500 以上のデータ数が確保できない類型もある。

Table 3-4-2 Number of near-miss incidents extracted (Reproduced from Table 3-2-1)

ニアミス抽出件数 (Table3-2-1 再掲)

ニアミスレベル	件数	合流	カットイン	カットアウト	渋滞	視界不良	ブライインド	レーンチェンジ	カーブ	車線逸脱	落下物	故障車	二輪車	料金所	SA,PA	歩行者	緊急車両	逆走	災害
ニアミス 大	1,476	217	379	23	108	17	17	293	4	96	91	161	42	1	19	5	2	1	0
ニアミス 中	4,031	558	1,275	129	239	61	21	380	30	183	539	474	49	9	65	10	7	2	0
ニアミス 小	8,283	743	3,495	201	328	161	61	334	52	296	955	1,414	151	9	47	20	16	0	0
ニアミス総計	13,790	1,518	5,149	353	675	239	99	1,007	86	575	1,585	2,049	242	19	131	35	25	3	0

またシナリオ毎にリスクの要因が、地形要因が支配的なものや環境要因が支配的なものなど異なるため、「マイクロ評価」用のリスクシナリオの作成の考え方を、大きく二つの群に分けて考えて整理した。

12 類型を、ジオメトリ系としての類似のシナリオ群 (1) と、個別系のシナリオ群 (2) の 2 種類のリスクシナリオに分けて、マイクロ評価用のシナリオとして絞込む。

(1) も (2) も、SCT ≦ 3 [秒] のデータ絞込み基準は同一であるが、(1) は、N 5 0 0 以上のニアミスデータからシナリオを抽出することとし、(2) は、収集したデータ数全てから抽出することとする。

(1) ジオメトリ系のシナリオ

Table 3-4-3 Number of geometry-based scenarios

ジオメトリ系のシナリオの個数

ジオメトリ系	合流 (DX-01)	Cut-in (DX-02)	レーンチェンジ (DX-07)	渋滞 (DX-04)	カットアウト (DX-03)
シナリオ数	32/502	22/509	13/502	(8)	(7)

(2) 個別系のシナリオ (認識リスク等エッジケース的、データ数少)

Table 3-4-4 Number of risk scenarios for micro-level assessment

* () indicates currently under analysis.

マイクロ評価用のリスクシナリオ数 ※ () は、現在解析中。

個別系	視界不良 (DX-05)	ブライインド (DX-06)	カーブ (DX08)	車線逸脱 (DX-09)
シナリオ数	(4)	(5)	(4)	(7)
個別系	Temp.Obj (DX-10)	故障車 (DX-11)	二輪車 (DX-12)	
シナリオ数	(4)	(9)	(4)	

個別系	料金所 (DX-13)	SA,PA (DX-14)	歩行者 (DX-15)	緊急車両 (DX-16)
シナリオ数	(未)	(未)	(未)	(未)
個別系	逆走 (DX-17)	災害 (DX-18)		
シナリオ数	(未)	(未)		

絞込みした各リスクシナリオは、OpenX 形式で、以下のデータセットとして提供する。詳細は、APPENDIX B：「標準データセット・フォーマット」項を参照。

Table 3-4-5 Definition of the standard dataset
標準データセットの定義

項目	内容
ニアミスデータ (Rawデータ)	<ul style="list-style-type: none"> 動的映像 (MP4: Front/Rear/Right/Left) ※マスキング処理済み GNSSデータ (タイムスタンプ、車速、緯度・経度、XYZ-Gセンサー)
アノテーション情報	<ul style="list-style-type: none"> ニアミス集計リスト (xlsx: シーン類型No: 18類型、ニアミスリスク大中小、シーン詳細) アノテーション情報ファイル1 (json: カメラ取付け位置・角度/内部パラメータ、時間) アノテーション情報ファイル2 (json: ↑に、天候、シーンの状況) ※生成AI技術で検討中。
データ解析情報	<ul style="list-style-type: none"> 時系列軌跡データ (csv: フレームNo、時間、相対速度、相対距離、車速、緯度・経度、SCT、TTC、XYZ-G) データ解析View (MP4: Front・Rear動画、SCT_x、SCT_y、SCT-BOX他) 交通流モデルパラメータ (xlsx・csv: 自車速、相対速度xy、相対距離xy、SCTxy、加減速度)
シナリオ形式 (ニアミス、交通流※)	<ul style="list-style-type: none"> OpenSCENARIO (シナリオ定義: 動作・イベント、軌跡) ※軌跡はCSV形式も用意 OpenDRIVE (道路環境、MAP) FBX (外景/外観、3Dアセット) ※主に認識リスク評価時 ※交通流シナリオの形式については、検討中

以下に、実際に抽出したニアミスデータから、作成したシナリオ例を示す。



Fig. 3-4-4 Near-miss source data
ニアミス元データ



Fig. 3-4-5 Generated risk scenarios
生成リスクシナリオ

3.5. マクロ評価

マクロ評価として、不確定リスクの評価を交通流シミュレーションを用いて策定する。シミュレーションはリアル実験の代替として活用できること、評価の大幅な効率化、網羅性の向上が出来、極めて有益であるが、一方で現実をどれだけ忠実に再現出来ているかどうか（デジタルツイン）で、その利用価値が決まる。

シミュレーションの妥当性を検証した上で、市場調査によるニアミスデータから抽出した確定系シナリオとは異なる非確定系シナリオをシミュレーションより創出することを目指す。これにより得られる非確定系シナリオは、通常のシーンでは起こりにくいコーナーケースや複数の交通参加者からなる複雑なシナリオ等が想定される。

3.5.1. 交通流シミュレーションの妥当性確保

創出するリスクシナリオを現実的なものにするために、下記の図 3-5-1 に示すように、基盤となる交通流の上に、リスクを反映するためのエージェントモデルを組み込んだ交通流シミュレーションを構築することとした。

エージェントモデルとは、交通流シミュレーションにおける、ドライバの運転行動を示すもので、車を“個別の意思を持つ主体”として動かすためのモデルである。本研究では、リスクを「状況に応じて受け入れつつ最終的に低減する（リスクを管理する）」ために、車がどのような回避行動を示すのかを実証実験のデータより見出してモデル化した。この各種エージェントモデルの混入により、リスクを含む交通流を設定することができる。

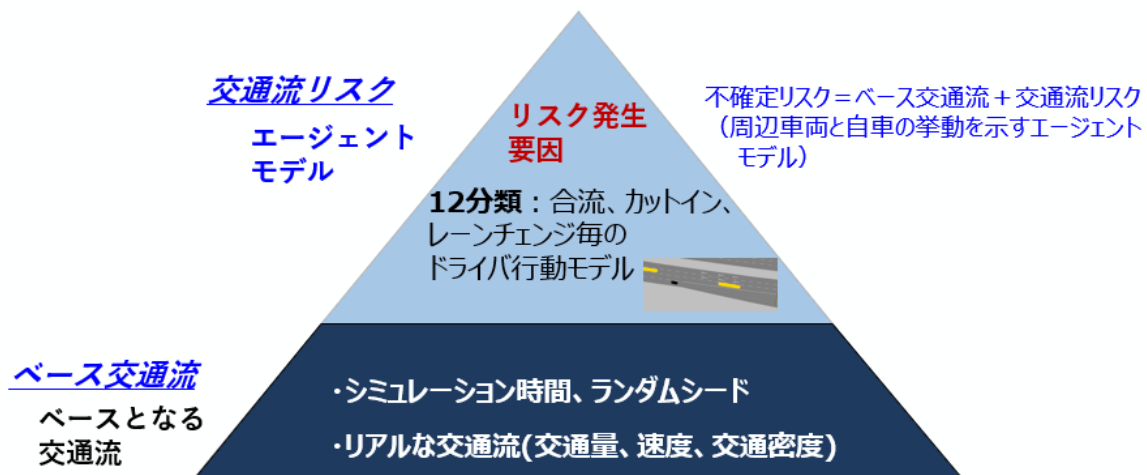


Fig. 3-5-1 Simulation structure of traffic flow risk scenarios
シミュレーションピラミッド

また、今回は、この回避行動をもつトラックエージェントモデルの一つを ADS(評価対象 SUT: System Under Test) と仮定として回避余裕度とその発生頻度を評価した。今後、実際には各種エージェントモデルによりリスク要件を設定した交通流の仮想環境（マクロリスクシナリオ）で、各社の ADS を自車として評価することになる。

交通流シミュレーションの概要を下記に示す。

(1) ベースとなる交通流設定と検証

国交省センサスデータ²⁵⁾を用いて交通流パラメータ(交通量、平均速度)を決定する。統計的観点から、リアルとシミュレーションでの比較データ検証を行い相関性があることを確認した。

(2) リスク管理のエージェントモデル設定と検証

統計的に十分な各 500 サンプル(後述)をもとにエージェントモデルを決定する。統計的なデータ検証(カーネル密度推定:KDE(Kernel Density Estimation)分布²⁶⁾の相関分析)を行い、自転車速度などドライバ行動を決める重要なパラメータがリアルとシミュレーションで高い相関がある事を確認した。

上記により、不確定リスクシナリオを抽出するために妥当な交通流シミュレーション基盤が構築できたと判断している。

以下詳細について、説明する。

3.5.2. ベース交通流の設定

シミュレーション区間は、自動運転車の実証実験でも利用される予定である新東名の遠州森町 PA から新磐田 IC までの 10.6km 区間(下り)とした。対象区間の交通流データが入手できなかったため、代替として浜松浜北 SA 区間の上り方面を対象とした詳細データ²⁷⁾を使用した。どちらも新東名高速道路であることと、この詳細データは時間単位、車線別、車種別と詳細な現況再現を行っていることから、本データを使用することとした。これにより自転車と他車の関係性を表すパラメータを再現するために極めて重要な、速度や車線変更の分布が再現されたモデルとすることが出来た。このデータをもとに、平均速度、交通量をパラメータとして再現した。

(a) 交通流模擬区間

合流 2 カ所を含む新東名 10.6km の区間(図 3-5-2)を用いた。

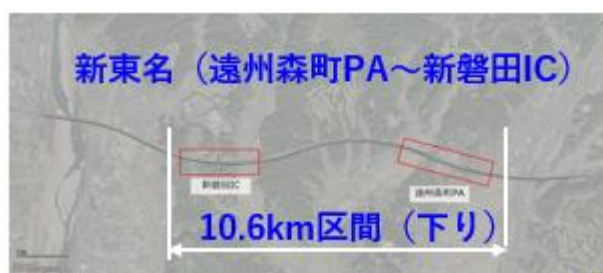


Fig. 3-5-2 Evaluation area
評価区間

(b) 交通流の設定

設定した交通量を表 3-5-1、表 3-5-2、表 3-5-3 に示す。

※Vissim 上での設定値は単位が[台/時間]のため、表の 12 倍の数値が設定されている。

※道路に車両が伝搬するまでの計測前のウォーミングアップとして、15 分間を設定。

表 3-5-1 は本線交通量（5分単位）を示す。車線毎に大型、小型で分けて設定し、交通量の多い、夜の時間帯の実際のデータをもとに1時間分のデータとして用いた。

表 3-5-2 は合流部の交通量を示しており、流入、流出で分け、小型、大型でも分けて設定した。車線別の希望速度分布および車種別の希望速度[km/h]については、表 3-5-3 のように設定した。また、小型、大型の車両速度は、図 3-5-3 のように設定した。

これらは、全て、新東名の統計データより入手できた真値を用いている。

Table 3-5-1 Traffic volume on this route [vehicles]

本線交通量[台]

時間帯	第1車線		第2車線		追越車線		合計
	小型	大型	小型	大型	小型	大型	
21:00	4	30	10	34	20	8	106
21:05	6	28	16	40	26	7	123
21:10	5	35	15	52	24	19	150
21:15	5	38	12	48	23	20	146
21:20	7	33	16	46	23	15	140
21:25	11	33	18	55	33	25	175
21:30	5	43	15	64	26	37	190
21:35	5	37	14	65	29	21	171
21:40	11	37	19	60	37	24	188
21:45	8	32	18	64	23	24	169
21:50	4	42	17	64	29	34	190
21:55	5	32	14	54	33	40	178

Table 3-5-2 Merging section traffic volume [vehicles] (Common for PA/IC)

合流部 交通量[台] (PA/IC 共通)

方向	小型	大型
流入	146.95	41.35
流出	23.48	9.16

Table 3-5- Desired Speed Distribution: Desired Speed by Lane and Vehicle Type [km/h]

希望速度分布 車線別・車種別希望速度 [km/h]

	第1車線	第2車線	追越車線
平均速度 (小型)	83.78	97.42	112.53
平均速度 (大型)	74.25	81.53	95.06
標準偏差 (共通)	9.38	11.71	11.13

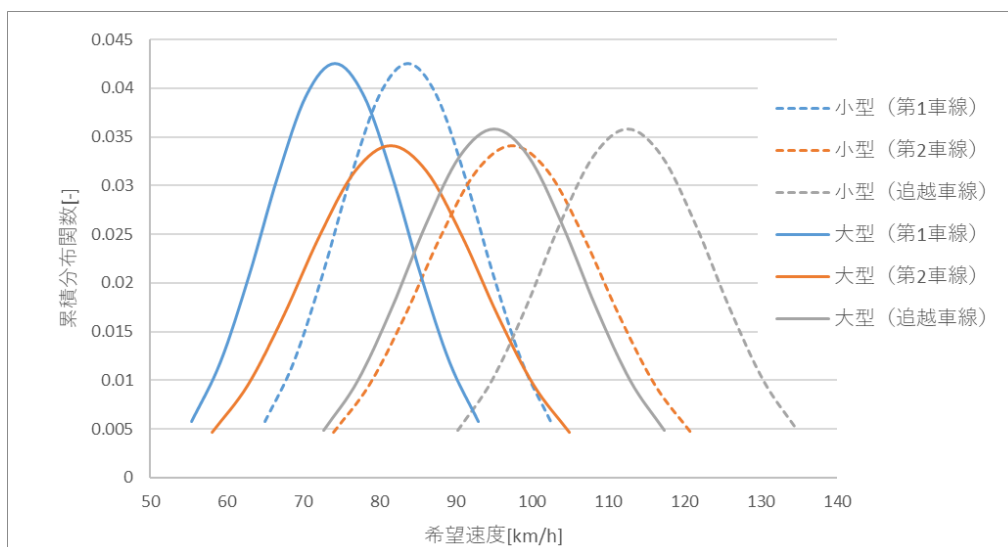


Fig. 3-5-3 Distribution of Desired Speeds
希望速度の分布図

使用した車両モデルは下記の通りである。

1) HGV - Tractor Box Volvo (HGV: Heavy Goods Vehicle 大型貨物車両)



>> Dimensions	
Length:	10.260 m
Width:	2.300 m
Height:	4.010 m

Fig. 3-5-4 HGV1

2) HGV - Semi-Tractor Volvo E + Semi-Trailer Box 3-axles 50%



連結 (Length 16.498m、 Width 2.550m)

Fig. 3-5-5 HGV2

(c) ベース交通流の妥当性評価結果

対象区間でのベース交通流の妥当性を確認するために、対象区間での交通量 (Q) と平均速度 (V) を実測値とシミュレーション値で比較を行った。

なお、交通密度においては、交通量 $Q = \text{交通密度} K \times \text{平均速度} V$ の関係があり、平均速度と交通量より規定される。

実測データとシミュレーションデータの比較を行ったところ、交通量（図 3-5-6）及び平均速度（図 3-5-7）において非常に高い相関が得られた。

高い相関が得られた要因は、設定した交通流シミュレーションにおいて、合流や分岐による必要な車線変更だけでなく、協調車線変更や低速車両の追越し、車線復帰等の自由な車線変更を表現するとともに、車線別の交通量と平均速度を一致させたことによるものと考えられる。このことから車線変更が必要となる状況やその判断基準、さらに他車両の受け入れ行動等も含めて、実際の運転挙動が良く再現できていると考えている。この結果より、ベースとなる交通流設定は妥当と判断した。




Fig. 3-5-6 Comparison of actual and simulated data (Traffic volume Q)
 実測データ と シミュレーションデータの比較 (交通量 Q)




Fig. 3-5-7 Comparison of measured data and simulation data (Average speed V)
 実測データ と シミュレーションデータの比較 (平均速度 V)

3.5.3. 交通流リスク（エージェントモデル）の設定

(a) 母集団のニアミスの特徴抽出に十分なリアルデータ数について

交通流リスクをシミュレーションで再現するためには、エージェントモデルの構築がキーとなる。このための統計的に必要十分なニアミスデータ数として、各分類につき 400~500 サンプルあれば十分であることを、下記の考え方と式より導出した。

目的：ニアミス運転行動を模擬するエージェントモデルを作るために「どれだけの実ニアミスシーンを分析すれば、母集団（実世界）のニアミスの特徴を十分に反映できたと言えるか」

方法：ニアミスがポアソン過程に従うとみなしつつ、「レートの推定誤差を制御」することで、必要サンプル数を計算する。

真のレート： λ (件/km)、総距離： L km、ニアミス件数： K において、ポアソンモデル：

$$K \sim \text{Poisson}(\lambda L)$$

ここから、件数 K の分散・標準偏差：

$$\text{Var}(K) = \lambda L, \quad \text{SD}(K) = \sqrt{\lambda L}$$

レート推定量：

$$\hat{\lambda} = \frac{K}{L}$$

レート推定量の分散は $\text{Var}(\hat{\lambda}) = \text{Var}\left(\frac{K}{L}\right) = \frac{1}{L^2} \text{Var}(K) = \frac{1}{L^2} \lambda L = \frac{\lambda}{L}$

ここで、 $\frac{1}{L^2} \text{Var}(K)$ への変形は、 $\text{Var}(aX) = a^2 \text{Var}(X)$ の『定数倍の分散の性質の公式』を利用している。

したがって標準誤差は

$$\text{SE}(\hat{\lambda}) = \sqrt{\frac{\lambda}{L}}$$

$$\text{SE}(\hat{\lambda}) = \sqrt{\frac{\lambda}{L}} \approx \sqrt{\frac{\hat{\lambda}}{L}}$$

ここから、「相対誤差 E (例： $\pm 20\%$) 以内の 95%信頼区間」を得たいとすると、

$$z_{0.975} \sqrt{\frac{\lambda}{L}} \leq r\lambda$$

両辺整理すると、必要距離 L の条件は

$$L \geq \frac{z_{0.975}^2}{r^2 \lambda}$$

期待ニアミス件数 $K = \lambda L$ に書き換えると、

$$K \geq \frac{z_{0.975}^2}{r^2}$$

必要なニアミス件数 (=必要なシーン数) は、レート λ には依存せず、「許容する相対誤差 E 」と「信頼水準 Z 」だけで決まるという結果になる。

95%信頼区間 ($z_{0.975} \approx 1.96$ 、 $z^2 \approx 3.84$) なら、

$$K \approx \frac{3.84}{r^2}$$

下記に相対誤差ごとの「必要ニアミスシーン数」を示す。

ポアソン過程を前提としたレート推定精度の観点から、必要なニアミス件数 (=シーン数) は以下のようなになる。

Table 3-5-4 The Relationship between tolerance and the required number of near misses
許容誤差と必要ニアミス件数の関係

許容する相対誤差 r	必要ニアミス件数 K_{exp} (\approx 必要シーン数)
±50% (ざっくり)	$3.84/0.5^2 = 3.84/0.25 \approx 15$ 件
±40%	$3.84/0.4^2 = 3.84/0.16 \approx 24$ 件
±30%	$3.84/0.3^2 = 3.84/0.09 \approx 43$ 件
±20%	$3.84/0.2^2 = 3.84/0.04 \approx 96$ 件
±10% (かなり厳しい)	$3.84/0.1^2 = 3.84/0.01 \approx 384$ 件

(いずれも 95%信頼区間ベース)

以上の結果から、最低でも 400 件のニアミスデータを用いて運転行動をエージェントモデルの構築するのが統計的に妥当という結論を得た。今回は余裕をもって 500 件を目標値として設定した。

(b) 交通流リスクの設定

交通流シミュレーションによる安全性評価では、実証実験では得難い複雑な因果関係によるリスクシーンや複数の交通参加者が関わるリスクシーンなどのシナリオの作成を行う。この時、要になるのがエージェントモデルである。今回は、高速道路の合流、カットイン、レーンチェンジの3つのリスクシーンでエージェントモデルを構築した。実証実験のニアミスデータから統計的に必要となる各 500 件を抽出し、リスクの生じる状況とそれを回避するドライバ行動を解析しパラメータを決め、交通流シミュレーションに忠実に再現した。

エージェントモデルを構築する手順を下記に示す。

1) 調整するパラメータ

- ・ リスクシーンでドライバ行動を決める重要なパラメータは次の 5 つである。

自車の速度(speed)とリスクの相手となる他車との相対距離(前後相対距離 dx 、横相対距離 dy)、相対速度(前後相対速度 vx 、横相対速度 vy)。これらの分布をニアミスデータより求め、シミュレーションで同様の分布になるように設定する。

2) 5 つのパラメータを抽出するタイミング

- ・ 合流での取得タイミングは、自車が被合流シーンとして、合流車が本線の白線に接するタイミングとした (図 3-5-8)
- ・ カットインでの取得タイミングは、他車が隣の車線との境界 (白線) に車両が接するタイミングとした (図 3-5-9)
- ・ レーンチェンジでの取得タイミングは、自車が隣の車線との境界 (白線) に車両が接するタイミングとした (図 3-5-10)

※抽出するタイミング (トリガポイント) に関しては、境界線 (白線) に接するタイミングとする研究²⁸⁾、最大横加速度が生じたときをタイミングとする研究²⁹⁾があるが、実証実験データより横方向加速度は安定しないことから一律白線に接するタイミングとした。

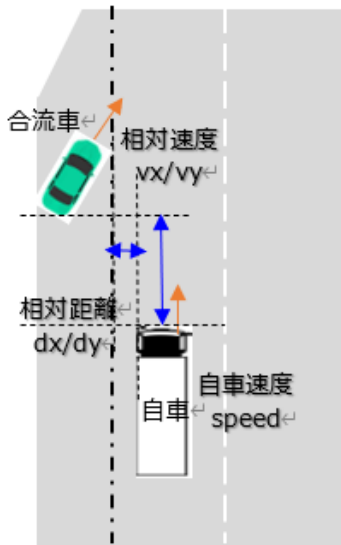


Fig. 3-5-8 Merging




Fig. 3-5-9 Cut-in



Fig. 3-5-10 Lane change

一方で、このエージェントモデルは、運転中のリスクを「状況に応じて受け入れつつ最終的に低減する (リスクを管理する)」ための車の挙動を制御する。エージェントモデルとして定義したトラックの運転挙動の物理パラメータは下記のように設定した (表 3-5-5)。仮の ADS と定義したモデルも表 3-5-5 のトラックエージェントモデルの一つとして、同じ回避機能をもつ。

Table 3-5-5 Risk controlled agent model and parameters

リスク管理のエージェントモデル・パラメータ

シナリオ種別	リスクシーンのバリエーション (パラメータ設定に関連する)	リスク管理行動モデル	Vissim 関連パラメータと設定内容 (現在の設定)
本線合流 (被合流)	シーン: 横並び合流 本線を走行中、合流路から他車が接近。自車と他車の相対速度が少なく、側方距離が縮まる状況。	① 隣接車線が空いている場合は、速やかにレーンチェンジして進路を譲る。	① 相対速度 -3.0m/s 以上、かつ衝突時間: $dx/(dv+3.0) < 10$ 秒、かつ自車及び隣接車線の後続車の減速度が許容できる程度に入れるとき、レーンチェンジして進路を譲る。
		② 空いていない場合は、他車の位置 (前方寄りか後方寄り) と速度 (自車より	② 減速度 -3.0 m/s^2 以下で車線変更車を入れることが出来れば、減速して譲る。そうでな

		速いか遅いか)を判断し、加速して前に入れるか、減速して後ろに入れるかを”一貫して”行う。※一貫しないと他車が迷う	ければ減速せずに速度を維持。 車線変更車両の操作開始後は、30%を乗じた安全距離で車線変更車を追従。
カットイン (割り込み)	シーン：至近距離での急な割り込み 隣接車線の車両が、自車のブレーキ制動すべき距離内に急な軌跡で割り込む形で進入。	①割り込み車両の速度および距離に応じ、衝突を回避するために必要な最小限の減速を遅滞なく(反応時間1秒以内を目安)開始する。 ②必要に応じてレーンチェンジで衝突を回避する。	①カットイン車両の操作開始後は、30%を乗じた安全距離で車線変更車を追従。 ②先行車の速度と自車の希望速度の差が平均2.0m/s(分布)以上かつ隣接車線の前方が空いており、隣接前後車両との車間距離が0.5m以上かつ後続車の減速度が -0.9m/s^2 以上で入れるとき、レーンチェンジして追越す。
レーンチェンジ (自車)	シーン：後続接近車両との干渉 自車が車線変更を開始しようとする際、変更先車線の後方から高速で他車が接近。 シーン：前方車両との干渉 自車が車線変更を開始しようとする際、前方車両が何らかの原因で急制動。	① 相手が通過した後、十分な空間が確保されたタイミングで実行する。 ② 動的時空間推定(SCT時間積分による予測等)に基づき、前方車両含む接近車両との将来的な重なりを予見し、車線変更を一時中断(待機)する。	① 隣接車線の前後車両との車間距離が0.5m以上かつ後続車の減速度が -0.9m/s^2 以上で入れるとき、レーンチェンジを実行。 ②車頭中心が隣接車線に到達するまでに前方車両と衝突しないように減速(車線変更は継続)。隣接車線の前方車両に対しては、30%を乗じた安全距離で追従。

以下、合流、カットイン、レーンチェンジについて、それぞれもう少し具体的な設定した運転行動について説明する。

b-1. エージェントモデル：合流

合流については、下記に示す4つのリスク管理のエージェントモデルを設定した。自車はトラックで、被合流シーンで合流路から小型車、または大型車が本線に合流してくるシーンを想定している。事前のレーンチェンジは、事前にリスクを避けるベストな運転行動である。POV(Primary Opponent Vehicle, 主要なターゲットとなる他車)との協調動作である協調レーンチェンジや協調減速も最も効果的なリスク管理行動と言える。

図 3-5-11 に合流シーンを示す。




Fig. 3-5-11 Merging scene

Table 3-5-6 Agent model for merging
合流時のエージェントモデル

パターン No.	割合	名称	POV 車両の行動に対しての SV 車両の反応				
			POV 車両：SN 到達前	POV 車両：希望状態	POV 車両：操作開始	POV 車両：車線移行	POV 車両：操作完了
1	1%	事前レーンチェンジ	HN-SN 間に POV 車両がいれば希望車線を設定	←	←	←	合流区間後、希望車線の設定消去（車線復帰 or 維持）
2	29%	協調レーンチェンジ	操作なし	POV 車両との TTC 10s 以内で車線変更（可能な場合）	←	←	通常の安全距離で先行車に追従（減速 or 操作なし）
3	53%	協調減速	操作なし	POV 車両に加速度 -3.0m/s^2 以上で譲れる場合は緩減速	減衰した安全距離で先行車に接近/追従（減速 or 操作なし）	←	通常の安全距離で先行車に追従（減速 or 操作なし）
4	17%	操作なし	操作なし	←	減衰した安全距離で先行車に接近/追従（減速 or 操作なし）	←	通常の安全距離で先行車に追従（減速 or 操作なし）

※POV 車両の操作開始以降は SV 車両がレーンチェンジしない限り全てカットインのパターン 2 と同様の反応

b-2. エージェントモデル：カットイン

カットインについては、下記に示す 4 つのリスク管理のエージェントモデルを設定した。自車はトラックで、小型車または大型車が自車の前にカットインするシーンを想定している。カットインシーンでの自車のレーンチェンジは、同一車線でのリスクを避ける有効な運転行動である。事前減速も POV と前後方向の衝突リスクを避ける効果的なリスク管理行動と言える。




Fig. 3-5-12 Cut-in scene

Table 3-5-7 Agent model for cut-in

カットイン時のエージェントモデル

パターン No.	割合	名称	POV 車両の行動に対しての SV 車両の反応		
			POV 車両：操作開始	POV 車両：車線移行	POV 車両：操作完了
1	13%	レーンチェンジ	希望車線を隣接車線に設定して車線変更を実施	←	希望車線を消去
2	16%	事前減速	減衰した安全距離で先行車に接近/追従（減速 or 操作なし）	←	通常的安全距離で先行車に追従（減速 or 操作なし）
3	48%	カットイン後減速	操作なし（内部モデル OFF）	減衰した安全距離で先行車に接近/追従（減速 or 操作なし）	通常的安全距離で先行車に追従（減速 or 操作なし）
4	23%	操作なし	操作なし（内部モデル OFF）	←	通常的安全距離で先行車に追従（減速 or 操作なし）

※合流時の反応と相関があると考えられるため、下記のように割合を設定

Table 3-5-8 The Relationship between cut-in and merging in agent models

カットインと合流のエージェントモデルの関係

	カットイン 1	カットイン 2	カットイン 3	カットイン 4	合計
合流 1	1%				1%
合流 2	12%	16%		1%	29%
合流 3			48%	5%	53%
合流 4				17%	17%
合計	13%	16%	48%	23%	100%

b-3. エージェントモデル：レーンチェンジ

レーンチェンジについては、下記に示す 2 つのリスク管理のエージェントモデルを設定した。自車はトラックで、自車がレーンチェンジするシーンを想定している。近接追従走行(図 3-5-14)は、一見リスクが高まるように見えるが、前車が急ブレーキをかける可能性は低く、比較的安全で、実証実験で熟練したトラックドライバによく見られた運転行動である。流れに沿わない遅い前方車両の後方を継続して走行するのはリスクがあり、隣の車線にレーンチェンジしようとするが、その車線に自車の後方から車が来ていることから、ひとまず前車の近接追従走行を行って後続車の自車の追い抜きを待ち、追い抜きが完了した時点で素早くレーンチェンジする運転行動である。




Fig. 3-5-13 Lane-changing scene
レーンチェンジ・シーン




Fig. 3-5-14 Lane changing after following closely
近接追従走行からのレーンチェンジ

Table 3-5-9 Agent model for lane changing
レーンチェンジのエージェントモデル

パターン No.	割合	名称	SV 車両の反応	
			許容待機時間 (6s) 経過前	許容待機時間 (6s) 経過後
1	100%	近接追従走行	デフォルトのパラメータ	車間距離を 2/3 程度に減少
2	100%	車線復帰	デフォルトのパラメータ	車線変更速度差を 1/3 に減少 隣接後続車速+1.0 m/s に減速

※各パターンへの移行条件は“近接追従走行への変化”他のページを参照のこと

Table 3-5-10 Details of the vehicle tracking model
車両追従モデルの内容

パラメータ名称	デフォルト	近接追従走行	車線復帰
CC0 静止車間距離[m]	1.50	0.50	1.50
CC1 車頭時間[s]	0.90	0.60	0.90
CC2 振動距離[m]	4.00	2.67	4.00
CC3 接近時間[s]	-8.00	-5.33	-8.00
安全距離減衰係数[-]	0.30	0.30	0.30
自由 LC 許容減速度[m/s ²]	-0.9~-1.0	-0.9~-1.0	-0.9~-1.0
車線変更速度差[m/s] ※	2.00±	2.00	0.67
希望速度[m/s]	-	変更無	POV+1.0

※車線変更速度差は不明なバラつきを無効化

(e) エージェントモデルの妥当性評価結果

ここで構築したエージェントモデルが正しくリアルを反映できているかを検証した。自動運転の安全性評価においては、定常追従状態よりも、交通流の乱れや車両間の相対位置関係が急変する動的場面が重要である。ここでは、リスク指標 SCT が急変しやすい合流、レーンチェンジ、およびカットインを題材にリスク管理のエージェントモデルを実装している。

検証の結果、合流、カットイン、レーンチェンジの全てにおいて、統計的な判断としてのピアソン相関において、中程度の相関～強い相関が得られて、一致度が高いことを確認した。

検証方法は、次のような方法で実施した。

1.比較するパラメータ

- ・ リスクシーンで重要である、5つのパラメータ、自車の速度(speed)とリスクの相手となる他車の相対距離(前後相対距離 dx、横相対距離 dy)と相対速度(前後相対速度 vx、横相対速度 vy)の分布をリアルとシミュレーションで比較する。

2.比較するタイミング

- ・ 合流での比較タイミングは、自車が被合流シーンとして、合流車が本線の白線に接するタイミングとした。
- ・ カットインでの比較タイミングは、他車が隣の車線との境界(白線)に車両が接するタイミングとした。
- ・ レーンチェンジでの比較タイミングは、自車が隣の車線との境界(白線)に車両が接するタイミングとした。

3.比較方法

- ・ 合流、カットイン、レーンチェンジそれぞれでニアミスが生じたシーン 500個を抽出して、上記タイミングでの5つのパラメータを全て取得し、カーネル密度(KDE)で推定した分布(実証実験分布)で表す。
- ・ 一方で、シミュレーションで取得した上記タイミングでの5つのパラメータを全て取得し、カーネル密度関数(KDE)で推定した分布(シミュレーション)で表す。
- ・ リアル分布とシミュレーション分布の相関を見ることで一致度を検証する。

以下、合流、カットイン、レーンチェンジについての結果を示す。

<合流>

図 3-5-15 は 5つのパラメータである、自車の速度(speed)、リスクの相手となる他車の相対距離(前後相対距離 dx、横相対距離 dy)、相対速度(前後相対速度 vx、横相対速度 vy)を示している。実証実験での合流時シーンにおいて、合流車が本線の白線をまたぐ瞬間での値を全て集めて分布をカーネル密度推定したものが、青線である。一方で、シミュレーションにおいても同様に、合流時シーンにおいて、合流車が本線の白線をまたぐ瞬間での値を全て集めて分布をカーネル密度推定したものが、オレンジ線である。この2つの分布のピアソン相関をとった。

5つの全てのパラメータにおいて、中程度の相関～強い相関(0.54～0.97)が得られた。

このことから、シミュレーションにおいて、合流シーンが正しく実現できていると判断した。

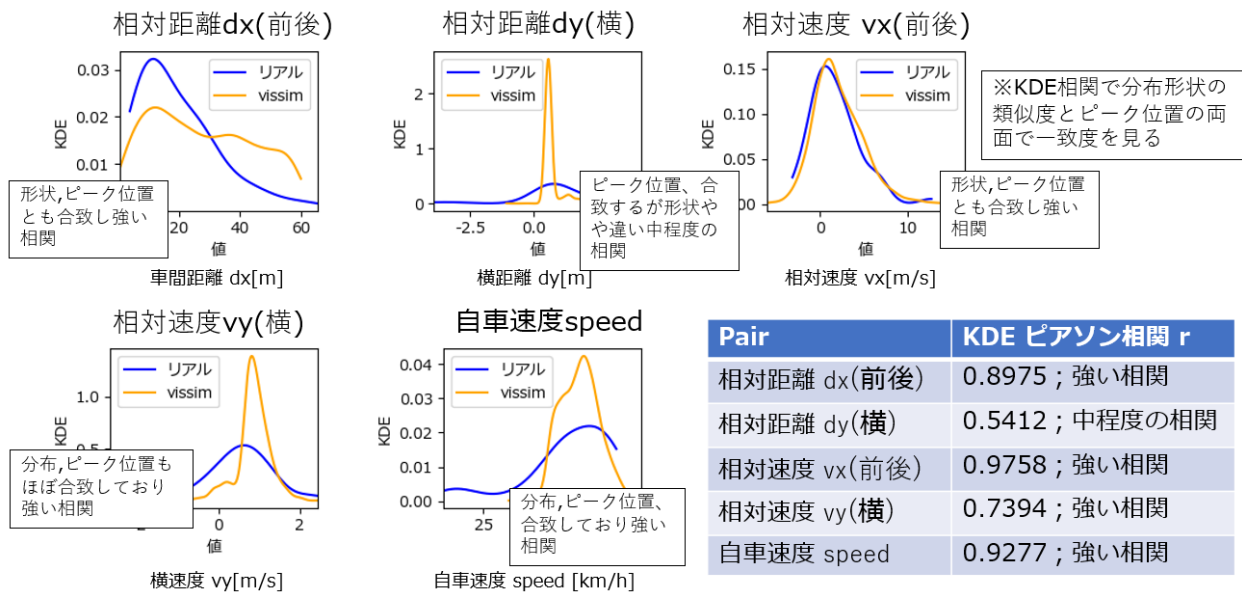


Fig. 3-5-15 Correlations among parameters in merging scenes
合流シーンでの相関

<カットイン>

図 3-5-16 も 5 つのパラメータである、自転車の速度(speed)、リスクの相手となる他車の相対距離(前後相対距離 dx、横相対距離 dy)、相対速度(前後相対速度 vx、横相対速度 vy)を示している。実証実験でのカットインシーンにおいて、前方車が自転車の前にカットインする場合に、カットイン車が今の車線と自転車の車線との境界の白線をまたぐ瞬間での値を全て集めて分布をカーネル密度推定したものが、青線である。一方で、シミュレーションにおいても同様に、カットインシーンにおいて、カットイン車が今の車線と自転車の車線との境界の白線をまたぐ瞬間での値を全て集めて分布をカーネル密度推定したものが、オレンジ線である。この2つの分布のピアソン相関をとった。5つの全てのパラメータにおいて、中程度の相関～強い相関 (0.64～0.94)が得られた。このことから、シミュレーションにおいて、カットインシーンが正しく実現できていると判断した。

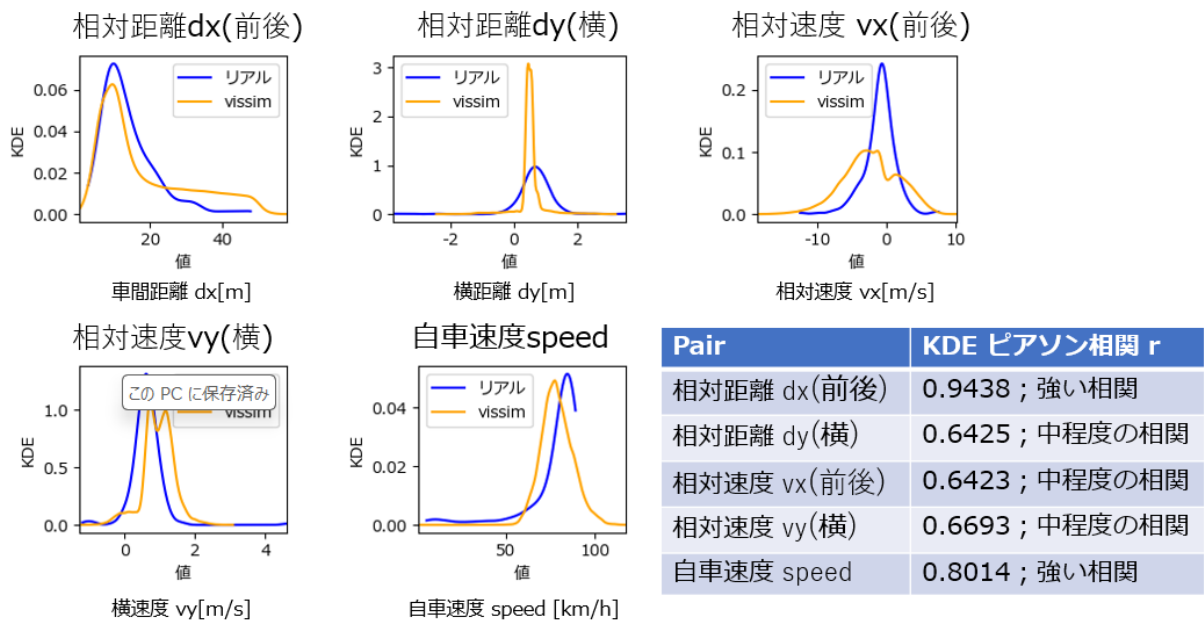


Fig. 3-5-16 Correlations among parameters in cut-in scenes
カットイン・シーンでの相関

<レーンチェンジ>

図 3-5-17 も 5 つのパラメータである、自転車の速度(speed)、リスクの相手となる他車の相対距離(前後相対距離 dx、横相対距離 dy)、相対速度(前後相対速度 vx、横相対速度 vy)を示している。実証実験でのレーンチェンジ・シーンにおいて、自転車が隣へレーンチェンジする場合に、今の車線と隣車線との境界の白線をまたぐ瞬間での値を全て集めて分布をカーネル密度推定したものが、青線である。一方で、シミュレーションにおいても同様に、レーンチェンジ・シーンにおいて、自転車が隣車線との境界の白線をまたぐ瞬間での値を全て集めて分布をカーネル密度推定したものが、オレンジ線である。この 2 つの分布のピアソン相関をとった。

5 つの全てのパラメータにおいて、中程度の相関～強い相関 (0.50～0.93) が得られた。

このことから、シミュレーションにおいて、レーンチェンジ・シーンが正しく実現できていると判断した。

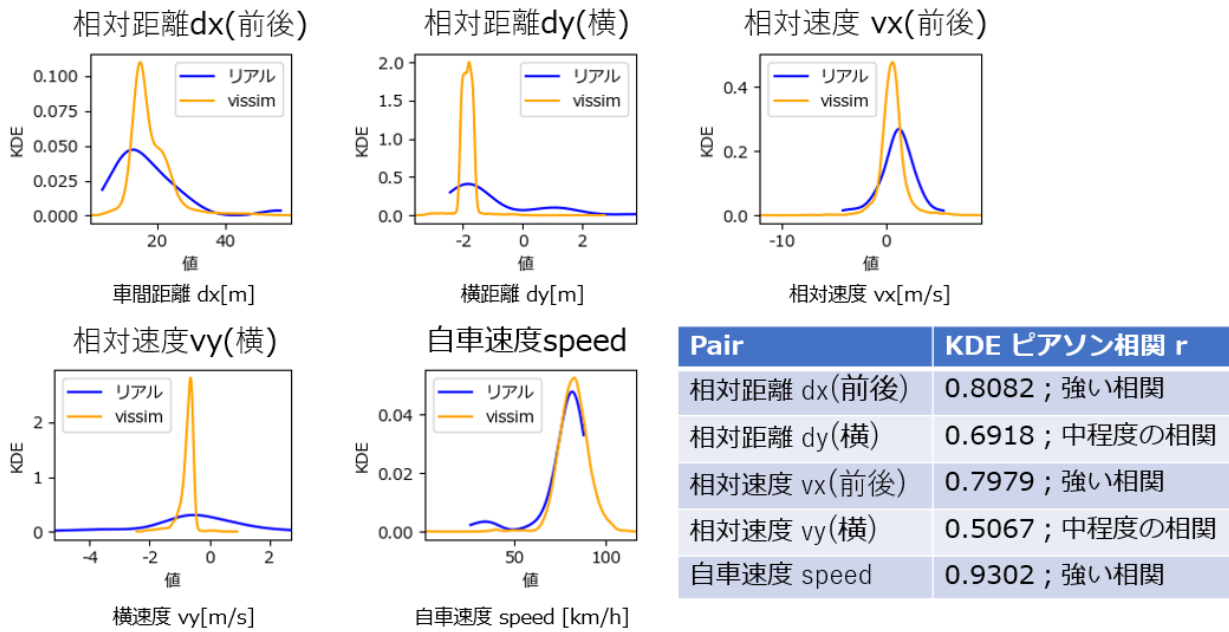


Fig. 3-5-17 Correlations among parameters in lane-changing scenes
レーンチェンジ・シーンでの相関

(f) シミュレーションに必要な時間について

実証実験で走行した全走行距離と全走行時間で得られたニアミス頻度は下記である。但し、本結果は、実証実験で取得した映像データから主観評価によって抽出したニアミスシーン数で、2025年12月時点でのデータである。

Table 3-5-11 Frequency of near-misses in field data
実証実験でのニアミス頻度

	件数	走行時間 [時間]	走行距離 [km]	単位時間当たりの頻度 [件/時間]	単位距離当たりの頻度 [件/km]
ニアミス計	647	1,075	94,961	0.602	0.00681
ニアミス大	96			0.089	0.00101
ニアミス中	158			0.147	0.00166
ニアミス小	393			0.366	0.00414

上記をポアソン分布と仮定し、必要なシミュレーション時間を計算すると下記になる。

Table 3-5-12 Simulation time required

必要なシミュレーション時間

分布	必要サンプル数の算出式（信頼区間考慮）	パラメータ	必要なシミュレーション時間 E=0.05、 r=0.05 の場合	必要なシミュレーション時間 r=0.1 の場合
ポアソン分布	$n = \frac{Z_{\alpha/2}^2 \lambda}{E^2}$ (絶対誤差)	λ : 平均発生率、 $Z_{\alpha/2}$: 信頼水準、 E : 許容絶対誤差	$\frac{(1.96)^2 \times 0.602}{(0.05)^2} = 925.2$ [時間]	
	$n = \frac{Z_{\alpha/2}^2}{2 \cdot r \lambda}$ (相対誤差)	λ : 平均発生率、 $Z_{\alpha/2}$: 信頼水準、 r : 許容相対誤差	$\frac{(1.96)^2}{(0.05)^2 \times 0.602} = 2,552$ [時間]	$\frac{(1.96)^2}{(0.1)^2 \times 0.602} = 638$ [時間]

上記で、 λ : 平均発生率、 $Z_{\alpha/2}$: 信頼水準、 r : 許容相対誤差、を採用し、2552時間を目安とする。

- ・ 前頁の 925 時間（絶対誤差）/2552 時間(相対誤差)は 1 台の車両でデータを取る場合である。
→実証実験の 0.602 回/時を「1 台が 1 時間走った時の期待値」と仮定している。
- ・ 交通流シミュレーションでは、今回 250 台/時が同時に走っており、1 時間で『250 台×時間』のサンプルが取得できることになり、この値で全体を割ることが出来る。
- ・ 現在のシミュレーションでは 2000 台の車両が平均 80km/h で 10km 区間走行しており、総走行時間 = 250 台/時間
- ・ 必要なシミュレーション時間の 2552 時間に対して総走行時間で割り、2552/250 = 10.2 時間（許容誤差 5%）となる。
- ・ 許容誤差 10%の場合の 638 時間に対しては、総走行時間で割り、638/250 = 2.5 時間となる

以上の結果より、必要なシミュレーション時間を 11 時間 (>10.2 時間) と設定した。

3.5.4. マクロ評価用リスクシナリオデータセット

マクロ評価用リスクシナリオデータセットを用いてシミュレーションを実行した。シミュレーション中のトラックを自車両と仮定し、ニアミス(Accident/Incident) の発生頻度を SCT 指標を用いて算出した。(新東名 遠州森町 PA~新磐田 SIC、 10.6km 区間を想定)



Fig. 3-5-18 A scene from the traffic flow simulation

シミュレーションの様子

シミュレーションの条件は下記の通りである。

Table 3-5-13 Traffic flow simulation conditions
シミュレーション条件

シミュレーション条件	内容
シミュレーション時間	11 時間 (1 時間 x11 回(※ランダムシード変更))
発生シナリオ数	15,018 ケース
交通量	14,740 台/時間 (本線)
ランダムシード	11 種類 (42~52)
走行距離 (10.9km 区間)	159,192 km (大型車のみ)
走行時間 (10.9km 区間)	2,082 時間 (大型車のみ)

交通流シミュレータにおいて、ニアミスシーン抽出に必要十分な 11 時間のシミュレーションを実施し、リスク指標 SCT が小さい ($SCT \leq 3$) リスクシナリオを抽出した。特に、リアル実験から得られたリスクシナリオと比べて、複数の交通参加者による複雑なリスクシーンを抽出した。動的時空間的視点を用いて抽出したシナリオである。

この時、確率の変動の影響を低減するために、ランダムシード値を変更しながら複数回のシミュレーションを行い、それら結果の平均値を評価指標とすることとした。

この結果得られたシナリオの事例を下記に示す。

下記は自車が前方に遅い車がいることから、レーンチェンジするシーンであるが、自車がレーンチェンジしたタイミングで、右前方の車がカットインしてくるようなシーン (図 3-5-19) である。

(自車は黄色、カットイン車は青、自分の前方にいた遅い車が白)




Fig. 3-5-19 Comprehensive risk scenarios derived from traffic flow simulations

交通流シミュレーションより得た複合的リスクシナリオ

図 3-5-20 では、リスクの発生時に周辺に存在する、車両 対 車両のシーン全体での最大リスクをヒートマップとして示している。横軸が車両、縦軸も車両となる。このケースでは、交通参加者として 7 台ある例を示している。どの車両とどの車両の間でリスクが生じたかが可視化されている。色と数字はリスクレベルを表し、それぞれ、赤はリスク大、オレンジはリスク中、黄色はリスク小、緑は安全で、数字は、3 はリスク大、2 はリスク中、1 はリスク小、0 は安全を表している。
 (0, 1, 2, 3)=(緑、黄色、オレンジ、赤)=(リスクなし、リスク小、リスク中、リスク大)= (SCT>3 秒、2 秒<SCT≤3 秒、1 秒<SCT≤2 秒、SCT≤1 秒)となる。

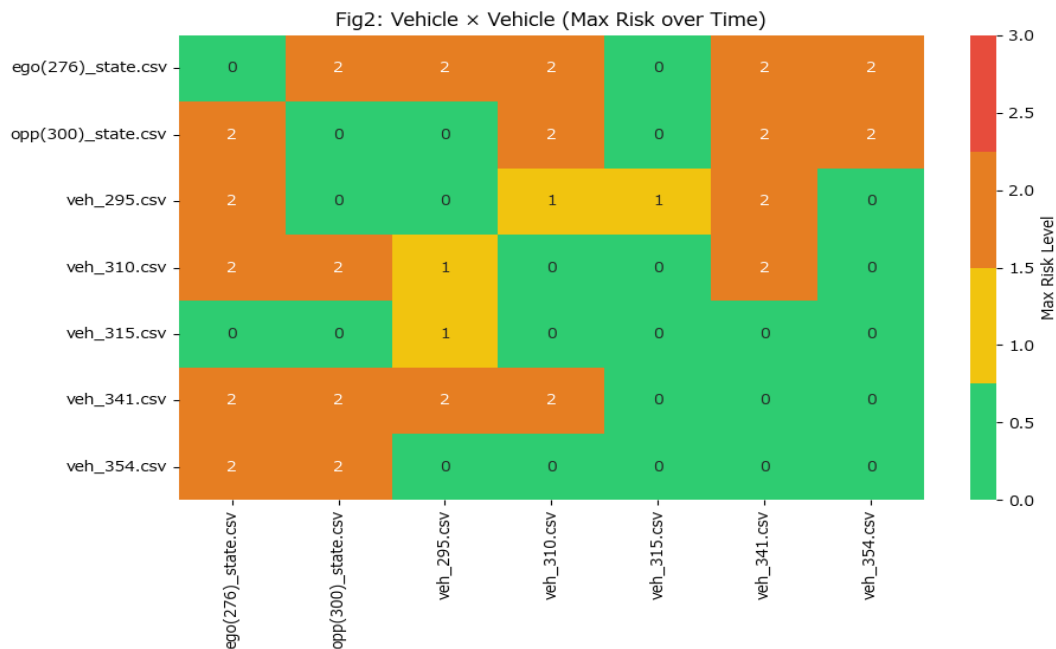


Fig. 3-5-20 Vehicle-to-vehicle risk heatmap for the entire scene (maximum risk)
 シーン全体での車両 x 車両でのリスクヒートマップ (最大リスク)

また、図 3-5-21 では、横軸が時間（左から右へ時間遷移し 200ms 毎にリスクをプロット）で、縦軸は、各交通参加者（車両）である。交通参加者毎のリスク度を時空間（時系列 SCT データ）でヒートマップとして表現したものである。図 3-5-20 と似ているが、車両毎のリスク変化を時間でみたものである。

図 3-5-20 は、シーン全体での n 対 n の最大リスクをみたもの、図 3-5-21 は、車両毎の時間によるリスク変化をみたものである。

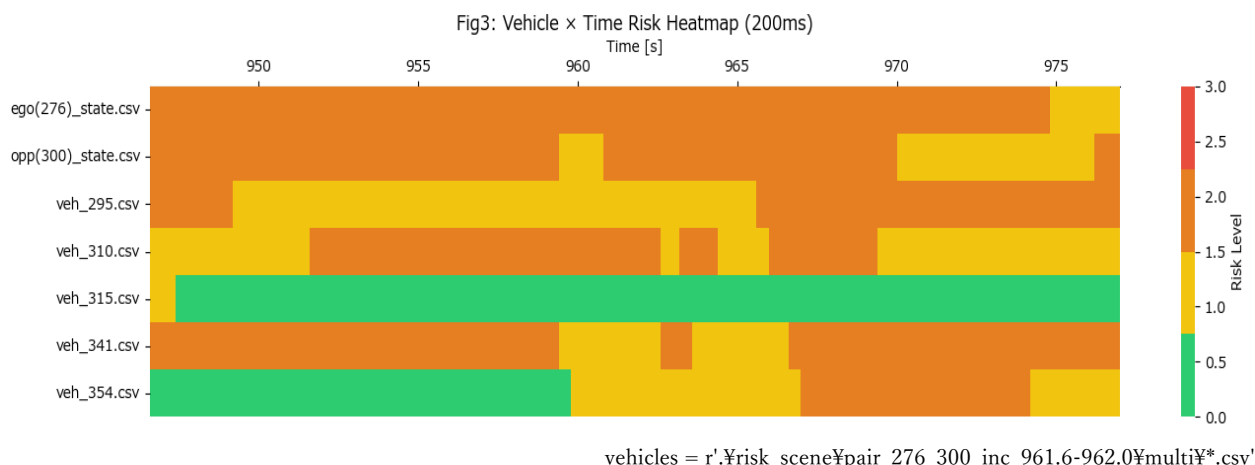


Fig. 3-5-21 Changes in risk over time for each vehicle

車両毎の時間経過によるリスクの変化

このようにリスクを一定の継続時間を持つものとしてとらえた場合、ある特定の時間での 2 車間での関係だけでなく、リスクが伝搬すると思われる周辺にいる複数の交通参加者のリスクも同時に時系列的に表現することで、この道路周辺全体の動的時空間リスクを観察することが可能となる。

このように、シミュレーションを用いて複数交通参加者の時空間リスクを計算することで、リスクの高いものを抽出しシナリオ化することができる。

一般に、自車両の挙動は周辺車両の挙動に連鎖的な影響を及ぼし、その影響は最終的に対象道路区間全体の交通流動特性に波及する。すなわち、複数の交通参加者が相互作用する複雑な交通シナリオに対して、ADS (Automated Driving System: 各社の自動運転モデルを含む) を導入した時、自車両の挙動を変化させながらシミュレーションを実施することで、周辺道路全体のリスク水準がどのように変動するかを定量的に評価することが可能となる。これにより、特に厳しい道路環境条件下における安全運転行動の最適解 (基準値) を導出が可能になる。

3.5.5. マクロ評価結果

マクロ評価は、交通流シミュレーションを用いたランダム実験の時空間で、自車として定義した大型トラック (他のトラックエージェントモデルと同じ回避機能をもつ。表 3-5-5 参照) が遭遇した衝突、ニアミス (大、中、小) のシーンの発生頻度を SCT 指標により評価した。

具体的に自車として定義した大型トラックは、エージェントモデルとして、運転中のリスクを「状況に応じて受け入れつつ最終的に低減する (リスクを管理する)」ために車がどのような挙動を示すのかを実証実験のデータより見出してモデル化しており、詳細は、表 3-5-5 に記載した。従って、このエージェントモデルは ADS (自動運転システム) の評価用リファレンスとして機能し、シミュレーション上のエージェントモデルを各社の ADS アルゴリズムに置き換えることで、仮想環境内での ADS の挙動評価や安全性指標 (SCT/TTC 等) に基づいた継続的な改良を可能にする。

交通流シミュレーションにより複数の交通参加者による複雑なリスクシーンを再現できることは前節で述べたが、マクロ評価結果がリアルな環境を再現できているかを検証するために、実証実験等で得られたニアミス件数と交通流シミュレーションでのニアミス件数を比較した。

実証実験で走行した全走行距離と全走行時間で得られたニアミス頻度は、表 3-5-11 の通りである（但し、本結果は、2025 年 12 月時点での主観評価済みのデータに基づく計算結果）。

実証実験での全走行時間は、1,075 時間、全走行距離は、94,961kmであった。ニアミス大は、この実験で 96 件起こっており、 $0.089 (8.90 \times 10^{-2})$ [件/時間]となる。ニアミス全体では、647 件起こっており、発生頻度としては、 $0.602 (6.02 \times 10^{-1})$ [件/時間]となる。距離で示すと、ニアミス大は、 $0.00101 (1.01 \times 10^{-3})$ [件/km]、ニアミス全体では、 $0.00681 (6.81 \times 10^{-3})$ [件/km] となった。

海外の事例として、米国の SHRP2 プロジェクトでの「Naturalistic Driving Study」³⁰⁾では、100 万時間の 3,500 万マイルの走行データから、1,541 件の事故と 2,705 件のニアミスをデータ化した大規模なデータベースが構築されている。マイルを km に直すと、56,326,900km になる。単純に事故率とニアミスを計算すると、1km あたりの事故率は、 2.74×10^{-5} [件/km]、ニアミス率は、 4.80×10^{-5} [件/km] となる。また 1 時間あたりの事故率は、 1.54×10^{-3} [件/時間]、ニアミス率は、 2.71×10^{-3} [件/時間] となる。SHRP2 プロジェクトの総距離 3500 万マイル、総時間 100 万時間という数字から平均速度を計算すると、35 mph、つまり 56 km/h となる。

実証実験での頻度と SHRP2 を道路環境などの条件が異なるので単純には比較できないが、実証実験でのニアミス大の件数と SHRP2 でのニアミス件数を比較すると、時間でみると、実証実験では 8.90×10^{-2} [件/時間]、SHRP2 では、 2.71×10^{-3} /時間となる。距離でも、それぞれ、実証実験では 1.01×10^{-3} [件/km]、SHRP2 では 4.80×10^{-5} [件/km] となり、実証実験のほうが頻度が高くなっている。これは、実証実験でのニアミス抽出は主観評価において抽出しており、ニアミスを余すところなく収集したいとの思いから、やや過敏に収集したことが原因であると考えられる。

一方で、SHRP2 のデータベースに含まれる 2,705 件のニアミスは、主観的な判断はなく、レーダや車両センサによる計測値と、それらを裏付けるビデオ映像という客観的な根拠に基づいて抽出されており、ニアミス頻度としてはこちらの方が信頼できる値と思われる。

よって、今回の件数の比較は、SHRP2 での頻度との比較を行うこととする。

一方、交通流シミュレーションでのニアミス発生件数を示したものを図 3-5-22 に示す。ニアミスは、リスク評価指標 SCT を用いて、ニアミスレベルと発生頻度を算出している。

シミュレーションは、ランダムシード値（乱数の種）を変更しながら、1 回 60 分のシミュレーションを 11 回実施した。11 回の理由は、3.5.3(f)で示したように、母集団（ニアミス全体の傾向を掴むための全体の集団）を捉えるために必要十分な 11 時間分のデータを収集するためである。

ランダムシード値を変更する意味は、下記の通り統計的に有意な結果を得るためである。

Vissim では以下が確率的に決まる。

- 車両発生時刻
- 車種構成
- 希望速度分布
- 車線変更タイミング
- ギャップ受容

- ドライバ挙動パラメータのばらつき

上記の基本パラメータは、ランダムシードを変えることで、同じ設定でも「交通の流れの揺らぎ」が変わり、交通流全体に影響を及ぼすことになる。即ち、より多様な結果を得ることになる。シミュレーションの結果、衝突 2 回、ニアミス大 2 回、ニアミス中 2 回となった(図 3-5-22)




Fig. 3-5-22 Number of accidents and near misses occurring in the simulation
シミュレーションで発生した衝突・ニアミス件数

この結果から、単位時間当たりの頻度と単位時間あたりの頻度の求めたものを表 3-5-13 に示す。

Table 3-5-14 Table of accidents and near-miss incidents and probabilities
(When an agent model is used)

衝突・ニアミスの発生件数と確率の一覧表 (エージェントモデル有の場合)

	件数	全走行時間 [時間]	全走行距離 [km]	単位時間 当たりの頻度 [件/時間]	単位距離 当たりの頻度 [件/km]
ニアミス計	6	2750 時間 (250 台時間*11 時間) (普通車含む全 体)	220,000 km (2000 台 *10km*11 時 間) (普通車含む 全体)	2.2E-03	2.7E-05
衝突	2			7.3E-04	9.1E-06
ニアミス大	2			7.3E-04	9.1E-06
ニアミス中	2			7.3E-04	9.1E-06
ニアミス小	0			0.0E+00	0.0E+00

本結果を、SHRP2 と比較すると、衝突(事故)に関しては、シミュレーション結果では 7.3×10^{-4} [件/時間]、SHRP2 では、 1.54×10^{-3} [件/時間] となり、シミュレーションの方が 1 桁少ない値となっ

ている。これは、SHRP2の全体データは、市街地、交差点、一般道路、高速道路など、あらゆる走行環境を含んだ平均値となっているためである。これに対して高速道路の事故率が1桁少ないという結果は、交通工学的な観点から見て極めて妥当であると考えられる。

参考までに、交通流シミュレーションに交通流リスクを付加しない場合、即ちエージェントモデルを使わずVissimの標準モデルのみで実施した場合のニアミス発生件数は、11時間でゼロであった。

11時間というシミュレーション時間にも関わらずニアミス発生件数が起こらないのでは、ニアミスシナリオを抽出するシミュレーションモデルとしては有効ではない。このことから、エージェントモデルを使いリスクを加速化させる手法は、頻度的には少ないが確率的に起こり得るニアミスの抽出という意味で優れていると言える。

また、今回のエージェントモデルは、1つの決まった設定だけではなく、ユーザの要求によって、幾つかのデータセットを作って使い分けることも可能である。今後、その方向でも検討を進めていく。

3.6. 運転行動の安全性評価（マイクロ評価、マクロ評価）

これまで説明したように、本フレームワークでは、(A) マイクロ評価と (B) マクロ評価 を組合わせた評価を提案する。(A)、(B) それぞれから抽出されたリスクシナリオ (OpenX) を、各社シミュレーションと接続し、自動運転制御ADKで評価を行い、全てのリスクシナリオを「Pass」することが目標となる。

図 3-6-1 に、(A) マイクロ評価、(B) マクロ評価の組合わせたフローを示す。例えば Pass 条件を最小 SCT>2 秒（仮※） とすることで、定量的な基準でADKを評価可能である。

※SCT>2 秒とは、回避余裕度を 2 秒以上確保する ということとなる。

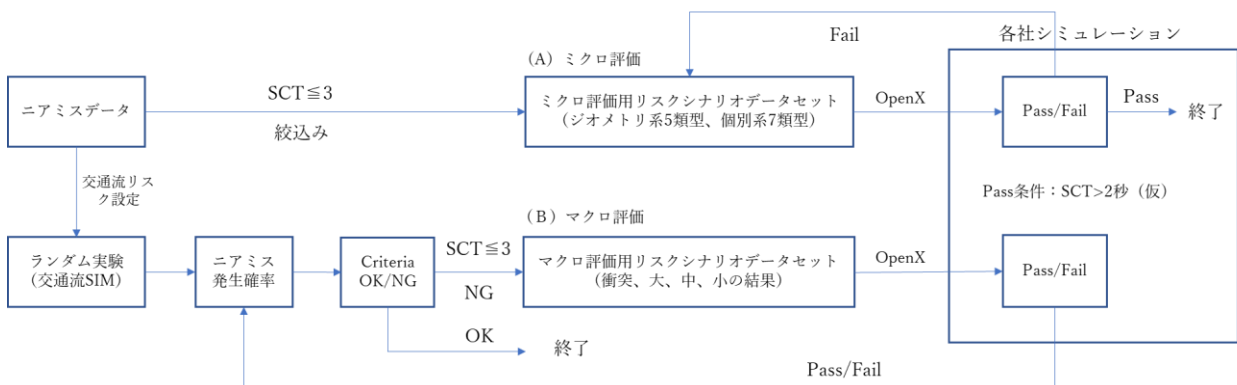


Fig.3-6-1 Specific examples of safety assessments
安全性評価の具体例について

本事業では、FOT(Field operational test)という位置づけで、今回提案する手法で生成した 2 種類のリスクシナリオを用いて、実験参加者自らが各社のシミュレーションを使って評価するという取り組みを行うことにした。

3.6.1. 運転行動の安全性評価の方法

図 3-6-2.に示す一般的な自動運転のシミュレーション環境を例に安全性評価の方法を説明する。OpenX 形式のシナリオ (OpenSENAIRIO、OpenDRIVE) を、①シナリオ Generator に import し、自転車以外の周辺車両の挙動 (軌跡) を再生する。自転車の軌跡は、基本的にはシナリオの初期位置・時間で、②自動運転制御モデルでの制御に切替えることで、リスクシナリオと同一のリスクを再現できる。いずれも真値として入力する。(図.3-6-2 に、概念図を記載)

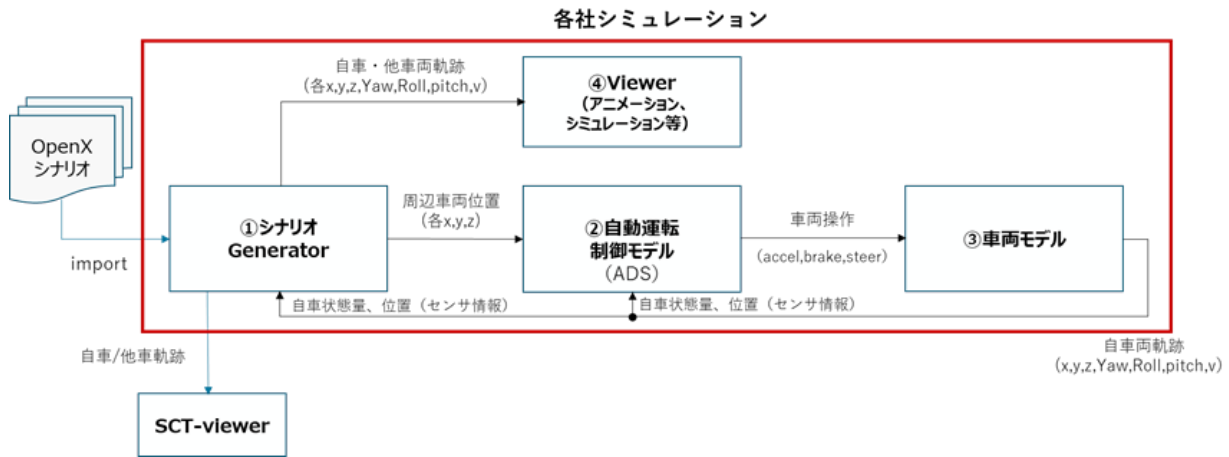


Fig. 3-6-2 Simulation environment for ADS- vehicles
自動運転車のシミュレーション環境

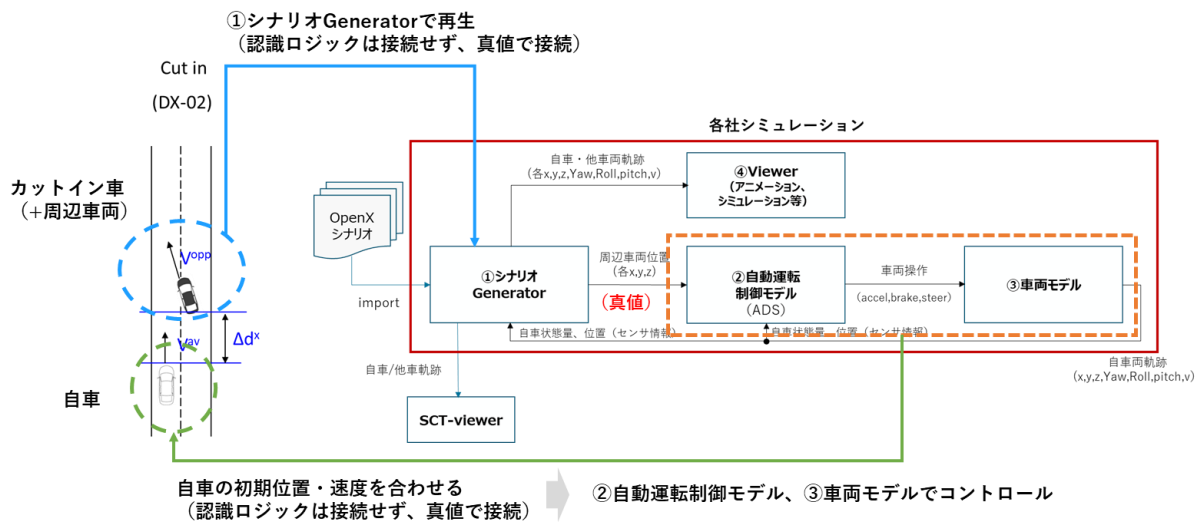


Fig. 3-6-3 Conceptual diagram of methods for rendering surrounding vehicles and the ego-vehicle
周辺車両、自車の再現方法の概念図

なお今回は、認識要素を含まない「真値(ジオメトリ)ベース」のシミュレーションとして実施した。尚、DIVP シミュレータでは、既に認識リスク(センサ電磁波の物理的弱点リスク、遅延、遮蔽の影響など)のモデル化を開発済みでシミュレーションに組み込むことができる。よって、認識リスクを考慮したニーズの場合には、認識性能およびジオメトリ的回避可能性の2ステージの安全性評価が可能と考えている。

まず、各社のシミュレーションに接続して OpenX 形式で生成したリスクシナリオデータセットの入力と接続方法の確認を実施した。また、各社の自動運転制御と接続し Closed Loop での評価が可能か否かを検証した。

3.6.2 では、各社とのシミュレーション試行を行う前にフィージビリティスタディとして実施した先

行検討の内容を説明する。

3.6.2. 運転行動の安全性評価の実践例

ここでは、市販のシミュレーション（IPG 社 CarMaker）を使用して、各社のシミュレーションと同等な評価を行った例を記載する。リスクシナリオは、(A) ミクロ評価用のシナリオ、(B) マクロ評価用のシナリオの2種類を準備した。自動運転制御は、CarMaker 付属の ADAS 制御モデルを使用して、制御のパラメータを変更した評価結果例も示す。（図 3-6-4）

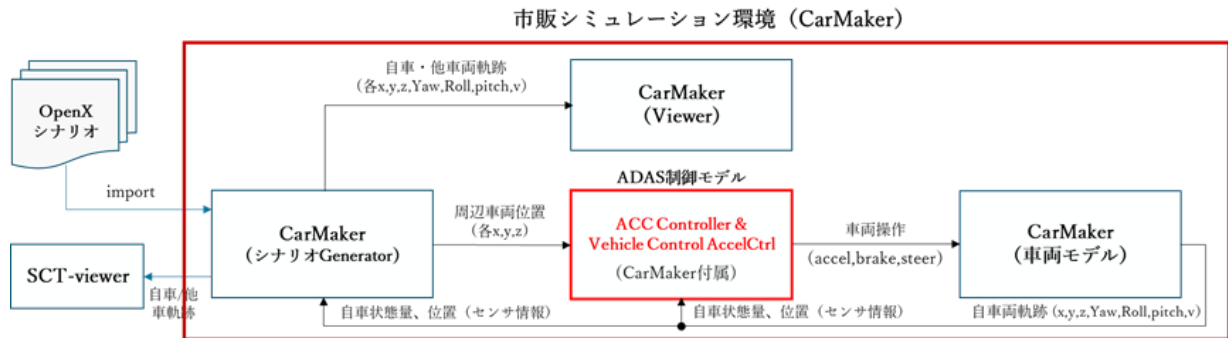


Fig. 3-6-4 Configuration diagram for a commercially available simulation tool (IPG CarMaker)
市販のシミュレーション（IPG 社 CarMaker）構成図

(1) ADAS 制御モデル

ADAS 制御モデルは、CarMaker 付属の「ACC Controller & Vehicle Control AccelCtrl」モデルを使用した。図 3-6-5 に簡単なモデルの構成図を示す。

目標車間距離 (d_{desr}) に対して、実車間距離 (d_{actual})、相対速度差 (Δv)、実 G (G_{actual}) などから、目標 G を算出した。その上で、目標 G になるように、PI コントローラで、アクセル/ブレーキペダルを制御することで、簡易 ACC (Adaptive Cruise Control) 制御による車間追従制御を実現している。ACC 制御状態を変更するためには、いくつかパラメータがあるが、ここでは、目標車間距離を変更することで、維持する安全車間距離が変更できる。




Fig. 3-6-5 ACC Controller & Vehicle Control AccelCtrl

(2) ミクロ評価用リスクシナリオでの評価結果

合流のリスクシナリオは、図 3-6-6 で示す様に、合流車が合流する直前に、自車(大型トラック)が、隣接車線へレーンチェンジで回避するシナリオで、最小 SCT 約 1 秒 (ニアミス大) である。

最小SCT=1.05秒 (ニアミス大)




Fig.3-6-6 Near-miss source data

ニアミス元データ

最小SCT=1.05秒 (ニアミス大)



Fig.3-6-7 Risk scenario replication

再現リスクシナリオ

シミュレーションの入力は、3.6.1.で記載の様に、合流車の軌跡を、シナリオ Generator で再生し、自車の制御は、初期位置 (合流車が、合流する前：約10秒) で、シミュレーションの自動運転制御に切替えて評価した。

評価結果を、以下に示す。ACC 制御の目標車間距離 (安全車間目標距離と想定) は、20m に設定し、制御状態を観察した。

合流 (白線横切り)



合流後 (最小SCT)



Fig.3-6-8 Simulation-based evaluation of ACC control (Target following distance: 20 m)

シミュレーションによる ACC 制御評価 (目標車間：20m)

ADAS (ACC+AEB) 制御により、最小 SCT_x=1.07 秒 (ニアミス大) が、最小 SCT_x=2.6 秒 (ニアミス小) の安全側へ変化した。(図 3-6-9) 詳細には、図 3-6-9 の dx (前後：相対距離)、dy (横：相対距離)、G_x (自車減速度)、SCT_x のグラフで示す様に、合流車両が白線を横切り、自車との横位置がゼロ近くになった時点で、合流車に対し減速 (-0.1G) をすることで、車間を維持さ

せている。ただし、合流車との距離は、最小で約 6m となっており、目標車間距離：20m に対して、結果的に接近した制御になっている。

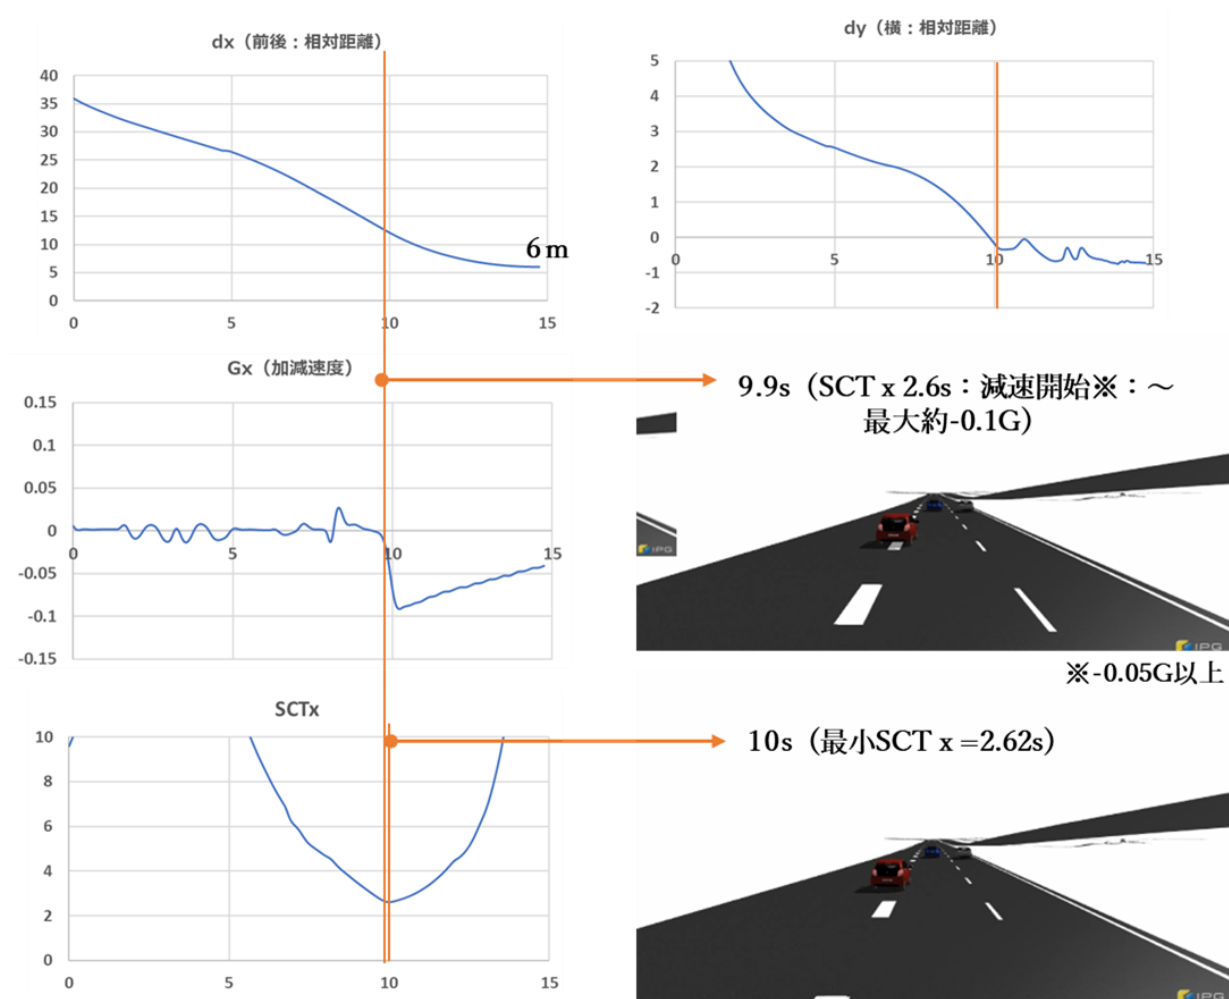


Fig.3-6-9 ACC control status in the simulation
シミュレーションでの ACC の制御状態

次に、ADAS 制御のパラメータである制御開始タイミングに対する検討結果を説明する。関係する合流車の検知に関して、初期は白線を横切った後での制御開始となっていたが、白線を横切る前のタイミングで制御開始する様に、Object sensor の検知範囲を拡大 (16 度→60 度) した場合の制御結果は以下の通りとなった。図 3-6-10 に示す様に、白線を横切る前からアクセル OFF を行い、さらに白線を横切り自車との横位置 (dy) がほぼゼロになったタイミングで、最大約-0.04G の減速を行うことで、目標車間距離 20m に対し、約 24m で制御できた。(最小 SCT は、16 秒)

まとめると、ADAS 制御 (ACC+AEB+FOV 拡大) により、ニアミス大 (SCT=1.07 秒) が、ニアミスではなくなっている。(SCT=16 秒)

この様に、今回ニアミスデータから生成したリスクシナリオは、自動運転の安全性評価を行ない、自動運転の制御を検討する上で有効なシナリオであることが確認できた。

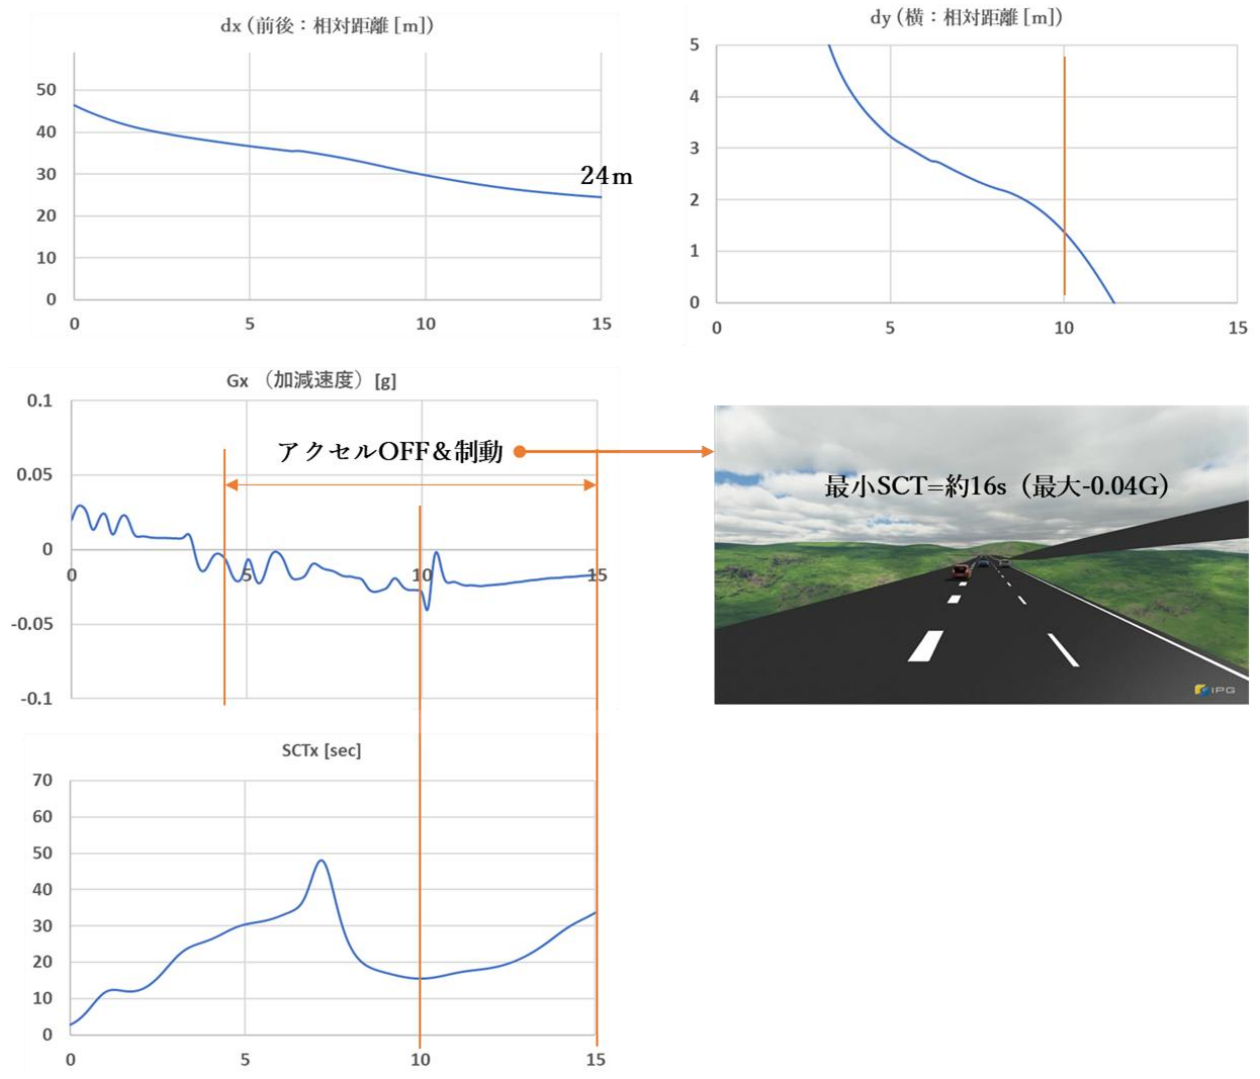


Fig. 3-6-10 ADAS control states in the simulation

シミュレーションでの ADAS の制御状態

(3) マクロ評価用リスクシナリオでの評価結果

3.5. で記載の交通流シミュレーションの結果、発生したシーンをリスクシナリオとして、(1) のマイクロ評価と同様なやり方で、評価を実践した。今回生成したリスクシナリオは、図 3-6-11 で示す様に、合流シーンにおいて合流レーン最先端で停止した車両と衝突するというシナリオである。



Fig. 3-6-11 Collision scenes in risk scenarios for macro-level assessment

マクロ評価用リスクシナリオでの衝突シーン

結果を以下に示す。(図 3-6-12)



Fig. 3-6-12 ADAS control results on micro risk scenario

ADAS 制御の結果 (マイクロ評価シナリオ)

合流レーンから走行してきた合流車が大型トラックと並走状態となり合流できず、合流車線末端ではみ出して停止。自車両は、ACC→AEB 作動により約 0.84G で減速するが、減速途中で後続車 (トラック) に後突される。本ケースは、自動運転にとっては難しいシーンであると言える。減速を抑え、右車線へ回避しようとしても車両が走行しているため、回避は難しい。唯一の可能性は、左の合流車線へ回避して停止する方法かも知れない。実世界では発生の確率は低い可能性はあるが、絶対発生しないとも言い切れず、未知リスクに該当する可能性にあるシーンであると考えられる。

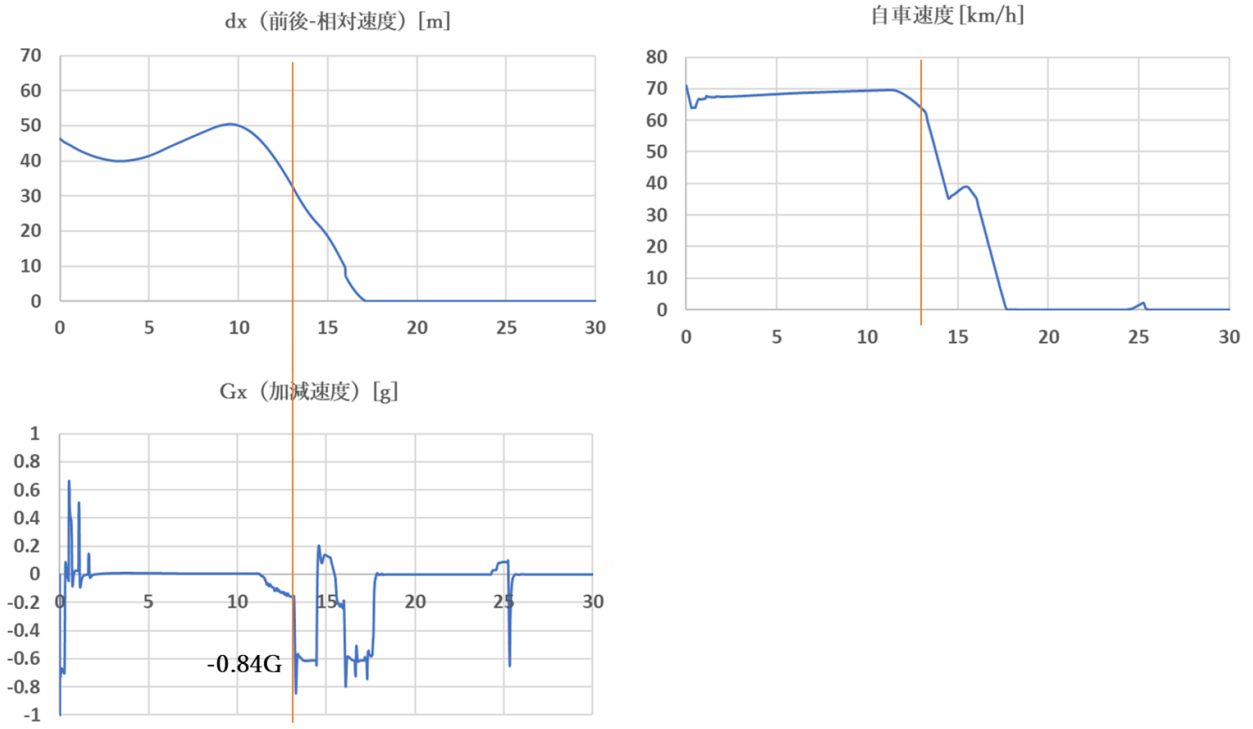


Fig. 3-6-13 ADAS control results on macro risk scenario
 ADAS 制御の結果 (マクロ評価シナリオ)

3.7. 回避余裕度を用いた安全性評価と許容基準の提案

3.5.5.項で詳述した通り、シミュレーションを活用し回避余裕度 SCT (Safety Cushion Time) に基づくインシデントレベル (およびアクシデント) とその発生頻度から安全性を評価する手法は、安全設計努力として「許容不可能なリスクがないこと」を立証する説明性の観点からも妥当なアプローチである。一方で、その許容基準 (Criteria) の策定は、簡単には決められない課題である。今後、バーチャル (設計段階) とリアル (市場実績) の両面からの評価実績を蓄積し許容基準 (Criteria) の妥当性の妥当性を検証してことが肝要である。

航空機や原子炉の安全性設計および論証においては、既に、同様な統計的手法が運用されている。これらを規範とすることで、設計段階において「許容不可能なリスクがないこと」を検証するための目標値を設定することは十分に可能である。

目標案の一例として、以下に示す。自動運転車が事故を起こして良いとは倫理的にも言い難く、衝突 (図 3-7-1 のレベル 5 で、 $SCT \leq 0$ 以下) はゼロ、つまり発生頻度は航空機に倣い 10^{-9} /h 以下、また、これまで述べてきた運転行動の安全余裕のロバスト性として、ニアミス大 (図 3-7-1 のレベル 4 で、 $0 < SCT \leq 1.0\text{sec}$) は 10^{-4} /h 以下 (1 回/年の発生頻度相当) を目標とすることは妥当と考える。

ただし、この数値が独立して意味があるのではない。本質的に重要なのは、設計段階で「許容不可能なリスクがないこと」を証明するために、絞込んだ既知事象および偶発事象のリスクに対して、一つずつ確実に技術対策を講じた設計努力とそのプロセスを明示することである。こうした公明性こそが、認可における価値ある情報に資するものになると考える。

従来、自動運転の安全性評価においては、設計段階で「許容不可能なリスクがないこと」を検証する手法、つまり、既知リスクおよび未知リスクに対する具体的な評価・検証手法が確立されておらず、自動運転の安全性の出口が見えなかった。本プロジェクトでは、運転行動の回避余裕度指標 SCT を核として「ニアミスデータに基づくリスクシナリオの生成手法」「シミュレーション活用による評価手法」「定量的な結果評価」の一連のプロセスを体系化した。これにより、「既知リスク/未知リスクに対する具合的な評価・検証手法」を示すことができた。

本提案が、自動運転における安全性、堅牢性 (ロバスト性)、および信頼性の向上に寄与することを期待する。なお、本データはトラックの視点から得られたものであるが、乗用車を含む混在交通環境を対象としているため、乗用車への適用においても十分な有効性を有する。今後、乗用車関連のデータが拡充されることで、その有効性はさらに高まるものと考えられる。

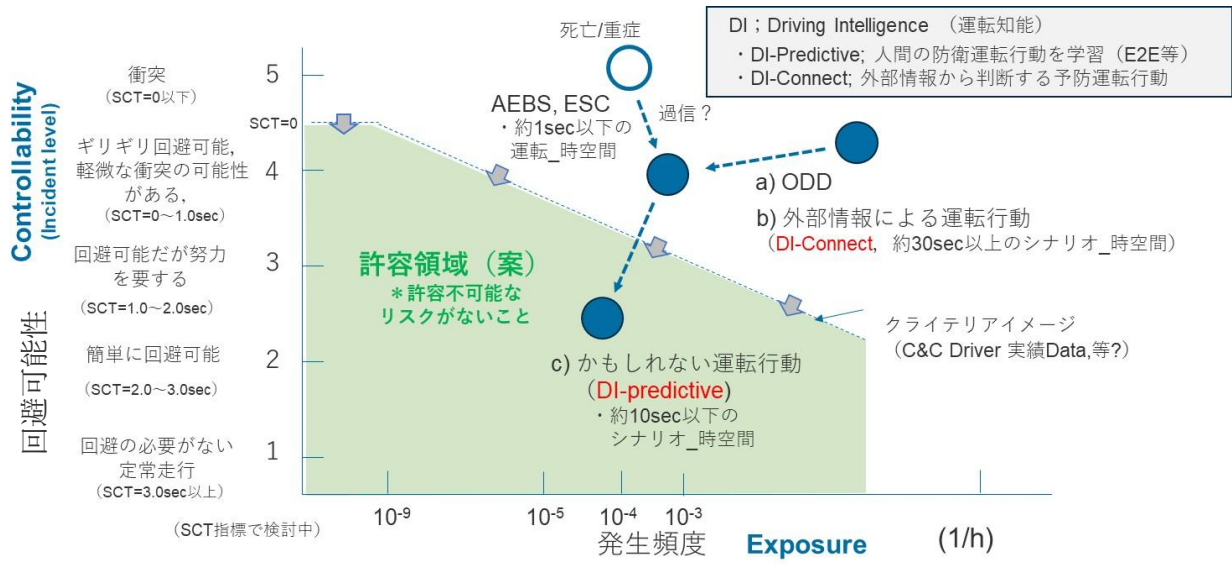


Fig. 3-7-1 The relationship between controllability and exposure
回避余裕度と発生頻度の関係

4. まとめと提言

レベル3以上の自動運転システム(L3+ADS)に対し、国際法規や国際標準の動向、ならびに最新の事業者および第三者機関の活動を整理した。その結果、現時点でUNR-ADSやISO 34506 DISを含む国際的な枠組みは安全確保の方向性を示しているものの、具体的な開発プロセスや評価手順の設計はOEM等事業者側の裁量に委ねられていることが明らかになった。このため、規格適合のための評価と実効的安全評価の間にギャップが生じやすい状況にある。この課題を解決するためには演繹的体系性(論理構造)と帰納的実装性の双方を両立させた、実務的な安全性評価フレームワークの整備が必要である。

本報告では、このギャップを埋めるため、デジタルライフライン推進協議会(デジタル全総)プロジェクトにおける高速道でのL4自動運転トラック等を対象とした実践事例に基づき、シミュレーションを活用した「実効性のある安全性評価フレームワーク」を提案する。

4.1. 実効性のある安全性評価フレームワークと6つの要件の提案

本安全性評価フレームワークにおけるデータの流れを図2-3-1に示した。本報告ではこのフレームワーク全体を安全性評価手法として提案する。さらに、本フレームワークには下記の特徴を有しており、これら6項目も重要な手法要件として、フレームワーク全体と併せて提案する。

- 1) ニアミスデータの活用とドライブレコーダ映像からの解析手法
(自車-他車間の動的軌跡計測とパラメータ抽出手法等)
- 2) ミクロ(確定系)およびマクロ(不確定系)のリスクシナリオ生成方法
- 3) シミュレーションを活用した既知/未知リスクシナリオに対するテスト方法、及び、認識リスクの評価手法
- 4) 安全運転行動を評価する指標としてのSCT(Safety Cushion Time)の活用方法
- 5) 不確定系交通流リスクを反映したエージェントモデルによるシミュレーション生成と統計的評価手法
- 6) リスクシナリオとしての仮想空間モデルと自動運転ソフトウェアを接続するツールチェーン構成要件およびインターフェースの実装手法

以上の提案の詳細と今後の展望について4.2節に示す。

4.2. 実効性のある自動運転車の安全性評価フレームワークの詳細と今後の展望

4.2.1. ニアミスデータの活用とドライブレコーダ映像からの解析手法

一般に、LiDAR等の高精度センサを搭載した実験車両や量産車は、正確な軌跡計測が可能である反面、台数確保が難しく、膨大なトラック物流事業者が走行する広範な条件下でのデータ収集には限界がある。

これに対し、本研究で用いた「ドライブレコーダ映像と GNSS 自車位置情報」を活用した簡易的な動的軌跡計測およびパラメータ抽出手法**は、比較的安価で実装できることから、多種多様な環境下で取得されるニアミスデータから、リスクシナリオを定量的かつ網羅的に特定する上で極めて有効である。したがって社会実装に向けた展開価値は大きいと言える。

一方で、走行データの蓄積および運用基盤に目を向けると、米国の Naturalistic Driving Data (NDD) やドイツの GIDAS (German In-Depth Accident Study) に代表される海外の公開データベースと比較し、日本国内のデータ量は著しく不足しているのが現状である。

より広域な ODD (運行設計領域) において自動運転の安全性を担保し、技術発展を加速させるためには、公的機関による公開データの拡充とともに、データの収集・蓄積の継続的に行う運用体制の構築が強く望まれるところである。

4.2.2. ミクロ (確定系) / マクロ (不確定系) のリスクシナリオ生成方法、及び、認識リスク評価

本解析工程で特定された高速道路における 18 のリスクシーン類型および関連データは、リスクアセスメント (HIRA) に基づく ODD 決定プロセスを強力に支援するものであり、確定系リスクシナリオの生成および評価において不可欠な基盤となるものである。今後は、本プロジェクトの範囲に留まらず、実際の高速道路における死亡・重傷事故類型との照合を通じた更なる精緻化が期待される。また、これらのリスクシーン類型および関連データが「公開リソース」として標準化されることは、車両開発事業者と認可側の双方にとって極めて有意義である。

ミクロ評価 (確定系) のリスクシナリオ生成手法については、第 3 章で詳述した通り、**SCT (Safety Cushion Time) の最小値をトリガとして活用**する点に要諦がある。これにより定量的な時空間パラメータ (リスクシナリオ) の抽出が可能となり、既知のリスクに対する確実な評価へと繋げることができる。

一方、マクロ評価 (不確定系) のリスクシナリオ生成手法についても、同じく第 3 章で示した知見に基づき、「交通流リスク」を対象とした具体的な実践例を 3.5 節に示した。本手法により、インシデントおよびアクシデントの統計的な発生を予測するための、シミュレーションを活用したランダム実験の枠組みを構築することができた。

尚、センサ起因の認識リスクは極めて重要な評価軸である。本プロジェクトにおいても、FOT 参画のセンサメーカーの協力のもと、DIVP の環境モデルおよび固有のセンサモデルを用いたミリ波レーダのシミュレーション評価を実施し、その有効性を確認した。DIVP では既に 90 項目のセンシング弱点事象がモデル化されており、これらを活用することで、従来の評価範囲を超えた高度な認識リスク評価が可能となる。以上を踏まえ、将来的には認識リスクのシミュレーション手法も安全評価体系の重要要素としてフレームワークに組み込むことを提案する。

4.2.3. シミュレーション活用による既知/未知リスクシナリオでのテスト方法

2.1 節および 2.2 節で示した考え方の通り、ISO21448(SOTIF)が対象とする既知危険 (リスク)、未知危険(リスク)の領域に対して、これまで定量的なテスト方法がこれまで策定されてこなかった。本提案は、新たに、それぞれの領域に対応する以下のテスト方法を提案する。

(A) 既知リスク条件に対応する「シミュレーションでのミクロ評価のテスト方法」

(B) 未知リスク条件に対応する「偶発性を引出すランダム実験によるマクロ評価での統計的テスト方法」(本手法は、統計的な予測評価を目的とするためシミュレーション活用が不可欠である)

なお、具体的な事例については第 3 章に先述している。

ただし、自然環境を相手とした走行環境において100%の安全を保証することはできない。したがってリスクをさらに低減させるためには、設計上の継続的な改善努力と市場実績（ファクト）に基づくフィードバックの蓄積が不可欠である。

4.2.4. 安全運転行動を評価する SCT (Safety Cushion Time) 指標の活用方法

2.4 節で示したように、従来は、事故の発生や事故被害のレベルを Severity としてきた。そのため、C&C ドライバのデータに関する議論でも定量値は事故率で示されてきた。しかし、WP29 で示された回避可能性レベルに対応する定量指標はこれまで無かった。

また、事故率のみを RAC (Risk Acceptance Criteria) とすることには、いくつかの課題が存在する。第一に、事故率を基準とする場合、設計上「事故の発生」を前提とした評価構造となり、倫理的観点からの抵抗が生じる。第二に、事故は極めて希少な事象であるため、事故率は非常に小さな値となり、統計的に有意な評価設計が困難となる。第三に、将来、L3+ ADS が市場に広く普及した場合、基準となる統計量の変化に柔軟に対応できない。何故なら ADS の普及により交通流全体の安全性が向上し事故率が低下した場合、「人間より事故が少ない」という PRB の根拠自体が揺らぐ可能性があるからである。

これらの課題に対し、事故率に加えて回避余裕度(SCT, Safety Cushion Time)をリスク受容基準として用いることで、問題を解決できる可能性がある。SCT は、WP29 で最初に示された回避余裕度 (Controllability) の指標としても適切である、この指標を基準とすることで、設計上は「事故ゼロ」を前提とした評価が可能となり、倫理的にも受容しやすい評価構造を構築できる。また、SCT は例えば「SCT<1sec」のような条件で定義することが可能であり、その発生確率は事故率と比べて十分に高い。このため、統計的評価の設計が著しく容易になる。

SCT 指標は、正に ADS の運転行動の回避余裕度(Controllability)を定量的に示す指標として、本フレームワーク提案の根幹を成す極めて重要な要素である。第3章の実践により、SCT 指標がフレームワーク全体を通して以下の3つの側面に活用できることが3章の実践で検証された。

- (1) ニアミスデータから定量的にリスクを抽出するトリガとしての活用
- (2) ミクロ評価（確定系）における回避余裕度（回避可能性）レベルの定量指標としての活用
- (3) 統計的マクロ評価（不確定系）において、インシデントの回避余裕度(Controllability)レベルと発生頻度(Exposure)の双方を評価する指標としての活用

以上のことから、今後は SCT の活用および展開をさらに広め、実績の蓄積に基づく標準化を進めていくことが不可欠である。

4.2.5. 不確定交通流リスクを反映したエージェントモデルによるシミュレーション生成と統計的評価

3.5 節では不確定系（マクロ）評価手法の実践例を示した。本手法では、交通参加者であるトラックや乗用車の挙動（加減速、車線変更、回避行動等）を各車両のエージェントモデルとして定義し、交通流リスクを表現した。本手法の最大の特徴は、ミクロ評価で検証された類型モデルと物理パラメータに基づく多様なエージェントモデルを混合している点にある。これらのエージェントモデルを交通流内へ確率的に混入させることで、ランダム実験に適した「交通流リスクシナリオ」が生成でき

た。

本検討では、回避行動を有する1つのエージェントモデルをL4自動運転トラック（自車）と仮定し、上記のシナリオ条件下でシミュレーションを実施した。安全性指標としてSCT（Safety Cushion Time）を用いた統計的評価の結果、以下の通りアクシデントおよびインシデントが検出された。

Table 4-2-1 Number of accidents and incidents
アクシデントとインシデントの発生件数

区分	SCT の閾値	検出件数
事故	$SCT \leq 0 \text{ sec}$	2 件
ニアミス（大）	$0 < SCT \leq 1.0 \text{ sec}$	2 件
ニアミス（中）	$1.0 < SCT \leq 2.0 \text{ sec}$	2 件

これらの事象は、走行時間あたりの発生頻度として評価する。例えば、検出された2件の事故については原因解析を行い、同条件下での事故発生頻度が $10^{-9}/\text{h}$ 以下となるよう設計改良を加えることで、事故を発生させない安全設計の妥当性（説明性）の向上に繋げることができる。また、ADSのロバスト性確保の観点からは、ニアミス（大）の発生頻度についても $10^{-4}/\text{h}$ 以下（年1回程度発生）を判定基準（クライテリア）とすることが望ましい。

但し、これらの数値は一つの私案に過ぎない。今後は、シミュレーションの実績の蓄積や、実環境における人間ドライバのデータとの比較を通じて、慎重に議論を継続する必要がある。すなわち、この数値が独立して意味を持つわけではない。本質的に重要なのは、設計段階で「許容不可能なリスクがないこと」を示すことである。そのためには、絞込んだ既知事象および偶発事象のリスクに対して、一つずつ確実に技術的対策を講じ、その設計努力とそのプロセスを明示することが不可欠である。こうした透明性こそが、認可における価値ある情報となると考える。

一方で、検出されたこれらのリスク事象に対して対策を講じることは、確実に安全性の向上に寄与するものであり、同時にシミュレーションテストの有効性を示すものである。

なお、本手法で用いた各エージェントモデルは実データで検証済みであり、高い再利用性を有する。特筆すべきは、リスクを定義しない従来の交通流シナリオのシミュレーションでは事故が全く発生しなかった点である。これは安全性評価において、リスクを包含しないシナリオでの検証は本質的な意味を持たないことを強く示唆している。

4.2.6. リスクシナリオとしての仮想空間モデルと自動運転ソフトウェアを接続するツールチェーン構成およびインターフェースの実装手法

高速道 FOT 検討会に参加した ADS/ADAS ユーザに対し、4.2.1.~4.2.5.の成果物を提供し、シミュレーションによる安全性評価の試行を実施した。その結果、4.2.1.~4.2.5.の各項目はいずれもポジ

タイプに受け入れられ、ユーザ要件に合致していることが確認できた。

この試行において、各社とも経験的に蓄積された試験条件、データは保有しているものの、安全性評価の観点から体系的に整理されたシナリオ生成に苦勞していることが明らかになった。今回提案した、実データに裏付けられたリスクシナリオデータセットは、こうした課題に対する有効な解決手段として期待に応えるものがあることが確認できた。また、興味深い点として、これまで老舗ベンダが提供するシナリオ生成ツールは想定したほど有効に活用されていない実態が明らかになった。その要因は、OpenX が提供する標準に対し、各ベンダツール固有の仕様差（いわゆる方言）への対応が必要であることが影響していると考えられる。このため、本研究では最も基本的 csv.file 形式によるデータセットの提供を行った。その結果、ユーザ側のシミュレーションへの入力として接続できた事例が数件あった。更に、本研究で提示した「運転行動の回避余裕度とその発生頻度を定量化できる S C T 指標」の提示は、安全性評価に携わるエンジニアにとって、これまでの抱えていた評価上の課題を解消する可能性をもつ指標として期待をもって受け入れられた。実際に、「各社が保有するアルゴリズム及び車両モデルで構築するシミュレーション」と「本研究で提供した入力部（リスクシナリオデータセット）および出力部（SCT での安全性評価用 Viewer）」を接続することができ、SCT 指標の有効性を実感したユーザが複数存在した。

以上のように、接続性評価を通じて、本評価法はユーザ要件と方向性が合致しており、安全性評価手法としての実効性を有することが確認できた。一方でツールチェーンアーキテクチャとしては、合理性を欠く部分が残されており、未完成の課題も多い。

今後は、E2E、ADS、ADAS の開発および認可の双方の観点から、オールジャパンとしての国際競争力の強化に貢献するためにも、シミュレーションを活用した「実効性のある安全性評価フレームワーク（Practical Architecture for ADS Safety Assessment: PAASA）」の完成に向け、引き続き取り組んでいく所存である。

5. 参考文献

- [1] Chaitanya Shinde, et.al. ,The Autonomous, Safe Automated Driving: Requirements and Architectures, March 2024
- [2] UN Vehicle Regulations, URL:<https://globalautoregs.com>
- [3] UN Regulation No. 171 – Driver Control Assistance Systems (DCAS), URL: <https://wiki.unece.org/spaces/WP1/pages/310575182/ADS%2BReference%2Bmaterial>
- [4] UN Regulation No. 157/01 – Automated Lane Keeping Systems (ALKS)英語版 正式 PDF (R157e.pdf) ,URL: <https://unece.org/transport/documents/2021/03/standards/un-regulation-no-157-automated-lane-keeping-systems-alks>
- [5] Draft consolidated ADS regulation (tracked changes) , URL: <https://globalautoregs.com/documents/40838> (ADS-18-06/Rev.1 PDF あり)
- [6] BMW SIFAD, Safety integrity framework for automated driving, URL: <https://arxiv.org/abs/2503.20544>
- [7] ISO 26262:2018 – Road vehicles – Functional safety, URL: <https://www.iso.org/standard/68383.html> <https://www.exida.com/marketing/automotive-iso26262.pdf>
- [8] ISO/PAS 21448:2022 – Road vehicles — Safety of the Intended Functionality (SOTIF) , URL: <https://www.iso.org/standard/77490.html>, <https://www.iso.org/obp/ui/en/#iso:std:iso:21448:ed-1:v1:en>
- [9] ISO 34502:2022 – Scenario-based safety evaluation framework for ADS, URL: <https://cdn.standards.iteh.ai/samples/78951/aaa4e667f3d942f7a502044361312a2f/ISO-34502-2022.pdf>
- [10] ISO/PAS 8800 — Road vehicles — Safety and artificial intelligence, URL: <https://www.iso.org/obp/ui/en/>
- [11] SAE J3237_202508 – Dynamic Driving Task Assessment Metrics for Automated Driving Systems, URL: https://saemobilus.sae.org/standards/j3237_202508-dynamic-driving-task-assessment-da-metrics-automated-driving-systems
- [12] Safety Cushion Time (SCT) , A context-aware driver model for determining recommended speed in blind intersection situations, URL: https://tsukuba.repo.nii.ac.jp/record/2003995/files/AAP_163.pdf
- [13] ASAM (Association for Standardization of Automation and Measuring Systems) , URL: <https://www.asam.net/>
- [14] Pegasus Project, URL: <https://www.pegasusprojekt.de/en/>
- [15] MCity (University of Michigan) , URL: <https://mcity.umich.edu/>
- [16] GitHub — Mcity/TeraSim, URL: <https://github.com/mcity/TeraSim>
- [17] NVIDIA Alphamayo, URL: <https://www.nvidia.com/ja-jp/solutions/autonomous-vehicles/alpamayo/>

- [18] JAMA 安全性評価ガイドライン, URL: https://www.jama.or.jp/operation/safety/automated_driving/pdf/framework_ver_4_0.pdf
- [19] 「産業 DX のためのデジタルインフラ整備事業」 成果報告会 /産業DXのためのデジタルインフラ整備事業/デジタルライフラインの先行実装に資する基盤 に関する研究開発/自動運転支援道, URL: <https://www.nedo.go.jp/content/800024987.pdf> (12p-16p)
- [20] 井上秀雄、①仮想空間における自動走行評価環境整備手法の開発, SIP 成果報告書, 2022 URL: https://www.jstage.jst.go.jp/article/sipadusreport/2022/1/2022_108/_article/-char/ja/
- [21] 各年度の DIVP 成果報告書, URL: <https://www.sip-adus.go.jp/rd/rddata/rd06/205.pdf>
- [22] Hendrik Weber and et.al., A framework for definition of logical scenarios for safety assurance of automated driving. *Accident Analysis & Prevention*, URL: <https://doi.org/10.1080/15389588.2019.1630827>
- [23] Joseph Redmo et. al, You Only Look Once: Unified, Real-Time Object Detection, URL: <https://arxiv.org/abs/1506.02640>, Latest YOLO, URL: <https://docs.ultralytics.com/>
- [24] ISO 15622:2018(en), Intelligent transport systems — Adaptive cruise control systems — Performance requirements and test procedures, URL: <https://www.iso.org/obp/ui/es/#iso:std:iso:15622:ed-3:v1:en>
- [25] 国交省のセンシスデータを活用、出典『令和4年度 無人自動運転等の CASE 対応に向けた実証・支援事業（自動運転レベル4等先進モビリティサービス研究開発・社会実証プロジェクト（テーマ3））』報告書, URL: https://www.meti.go.jp/meti_lib/report/2022FY/000540.pdf
- [26] KDE(Kernel Density Estimation); ノンパラメトリックな(分布を事前仮定しない)分布推定方法で、相対速度、速度分布などを推定, URL: <https://club.informatix.co.jp/?p=1176>
- [27] 令和4年度 無人自動運転等の CASE 対応に向けた実証・支援事業（自動運転レベル4等先進モビリティサービス 研究開発・社会実証プロジェクト（テーマ3）） 報告書, URL: https://www.meti.go.jp/meti_lib/report/2022FY/000540.pdf
- [28] CHU, Tien Dung, A STUDY ON MERGING BEHAVIOR AT URBAN EXPRESSWAY MERGING SECTIONS, URL: https://nagoya.repo.nii.ac.jp/record/18564/files/k10733_thesis.pdf
- [29] Enrico Del Re et. al, J Method for Comparison of Surrogate Safety Measures in Multi-Vehicle Scenarios, URL: <https://ar5iv.labs.arxiv.org/html/2304.08998>
- [30] SHRP2 Naturalistic Driving Study, URL: <https://transportationops.org/Bigdata/NDS>

6. 用語集

No	用語	説明
1	パイプライン	安全性評価手法のプロセスの流れ（フロー）を示したもの。元々は石油等の配管（パイプ）がつながっていくイメージを示している。
2	ニアミスデータ	実際には事故にならなかったが、事故に発展する可能性が高かった事象の記録データ。例えば、衝突寸前で回避、急ブレーキ、急ハンドルで事故を回避、歩行者・自転車と接触しそうになったデータ等。日本では一例として、東京農業工業大学の一般道中心のニアミス事例データベースがあり、タクシー車両に搭載したドライブレコーダを用いて、数万～数十万件規模の位置情報、発生状況ラベル付きのニアミス映像データベースがある。ヒヤリハットと同意。
3	リスクシナリオ	リスクの意味である「危険の可能性。危険性・不確実性」に基づき、収集したニアミスデータ等から、将来的に事故など危険を誘発する可能性のある「危険な交通状況（シーン）」をシナリオ化（原因から結末までの動的なプロセス）したもの
4	SCT (Safety Cushion Time)	自車との他車のリスクのあるシーンでの、自車と他車との安全余裕時間（Safety Cushion Time）を定義したもの。（2018年自動車技術会春季大会「セーフティクッション：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」齊藤裕一、井上秀雄ら、文献多数）
5	交通流シミュレーション	道路上の車両の動き（速度、車間距離、車線変更など）をコンピュータ上で再現し、渋滞の発生メカニズム分析、道路計画の事前評価、信号制御の最適化、AD・ADASの制御検討などを定量的に行う技術。（製品としては、SUMO、VISSIM、ASTRAN等がある。）
6	交通流リスク	道路上の車、人、環境が相互に作用する中で、事故が起こりやすい状態や、交通の安全性を損なう要因。単に道路が危険というだけでなく、渋滞、走行速度、車線数、混雑度（交通密度）などの交通流状態が、追突や衝突の確率を変動させる要因として認識されている。 本提案書では、ニアミスデータを解析し、そこから抽出したリスクの要因（リスクシーンの車両相互の相対関係情報）を、交通流シミュレーションのエージェントモデルに組み込み、交通流におけるリスクの再現を試みている。
7	交通弱者 (VRU)	(Vulnerable Road Users) 車両に比べて物理的防護がなく、衝突時の被害リスクが極めて高い道路利用者を指し、例えば、歩行者、自転車、二輪車、車椅子利用者、高齢者、子供など。
8	認識リスク	センサや認識アルゴリズムが物理的なセンシング限界や弱点となる環境条件から物標を正しく把握できない状況に起因するリスク。

9	ジオメトリリスク	2者の動的な位置関係と速度関係から危険を発生してしまう相対運動リスク（運動の幾何学によって生じるリスク）と、交差点形状、車線構成、見通し距離などのインフラ由来のリスク（空間そのものの構造によって生じるリスク）の2つがある。
10	センシング弱点リスク	センサ性能や自然条件によりセンサが周囲環境を正しく把握できない状況（逆光、悪天候等）に起因するリスク
11	リスク	危険の可能性。危険性・不確実性。ハザードによって人やモノに危害・損害が及ぶ「可能性」や「確率」を指す。ハザードにより害が及ぶ不確実性。
12	ハザード	潜在的な危険源・危害要因。危害や損害を与える可能性のある根本的な原因や源のこと。
13	アクシデント	結果として起こった事故。
14	インシデント	結果として発生した不測の出来事、事件、あるいはヒヤリハットのように重大な災害には至らなかったものの、そうなる可能性があった出来事の状態。
15	ハザード・リスク・インシデントの関係	ハザード（危険物）が存在し、そこに近づくリスク（可能性）が現実化すると、インシデント（事故）が発生。 安全管理では、まずハザードを特定（危険源の除去）し、リスクを評価・低減し、インシデントを防止・対応するプロセスが重要。
16	データセット	ある特定の目的のために収集・整理・構造化された「データの集まり」。表形式（CSV等）、画像、テキスト、音声など多様な形式があり、主にAIの学習、統計分析、データ解析の基礎として使われる。 本提案書では、元となるニアミスデータ（映像、TEXT）、画像解析により抽出された動的軌跡情報（CSV）、OpenX形式のシナリオなどの一式をデータセットとして定義している。
17	Ego 車両	自動運転技術や交通シミュレーションの分野で、自律走行システム（AI）が自己の認識・判断・制御の主体としている「自分自身の車両」のこと。周囲の他の車両（Target 車両、Opponent 車両等）と区別し、自動運転の計算・シミュレーションで基準となる対象を指す。
18	POV (Primary Opponent Vehicle)	交通流シミュレーション（vissim等）でのPOV車両とは、ニアミス発生時等に自車両の相手となる車両のことを指す。 自動運転で使用するPOV（Personally Owned Vehicle）車両※とは異なる。（※個人が所有する乗用車に自動運転技術（運転支援システム）を搭載した車両）
19	HN (ハードノーズ)	高速道路や一般道路の分岐・合流部、あるいは中央分離帯の「鼻」のように突き出た先端部分を指す。通常はコンクリートや縁石などで固められており、車両が誤って進入した場合に危険なため、衝突対策や注意喚起が行われる区域です。

20	SN (ソフトノーズ)	高速道路などの分合流部において、本線から分岐する箇所や中央分離帯の先端に設置される、衝突時の衝撃を和らげる緩衝材や構造物のこと。事故時の車両の損傷や乗員への衝撃を最小限に抑える「衝撃吸収機能」を持つノーズ部分を指す。具体的には、本線と合流路を分けている三角形の先端部分で、ノーズ部分がペイントで記されている。
21	Vissim	ドイツの PTV 社が開発した、世界的に利用されているマイクロ交通シミュレーションソフト。自動車、歩行者、自転車、路面電車 (LRT) などの挙動を、1 台・1 人単位で高精度に再現・分析し、渋滞緩和、信号制御、道路計画の効果測定などに利用されている。
22	CarMaker	CarMaker (カーメーカー) は、独 IPG Automotive が提供する、乗用車や小型商用車の開発・検証用シミュレーションソフトウェア。自動運転、ADAS、パワートレイン、車両ダイナミクス分野で、バーチャル空間上に走行シナリオを構築し、設計からテスト、最適化までの全行程 (MIL/SIL/HIL) を高度に実行できる包括的なツール。
23	マイクロ評価	既知リスク条件に対応するシミュレーションでのテスト方法。ただし、その範囲は事業者のリスクアセスメントによる ODD 条件によって決まる。
24	マクロ評価	未知リスク条件に対応する統計的テスト方法の提案。偶発性を引出すランダム実験での予測を旨とするためシミュレーションでしかできない。
25	帰納的アプローチ	多数の具体的事実・データを観察し、共通点を見つけて一般的な法則 (結論) を導き出す手法。(ボトムアップ思考) 本提案書で記載している手法は、このアプローチであり、ニアミスデータや事故データ等を解析し、リスクシナリオを生成している。
26	演繹的アプローチ	既に知られている一般的な原則・ルール (前提) に、具体的な個別の事実を当てはめて結論を導き出す手法 (トップダウン思考) 自動運転分野では、安全を論理的に説明する安全論証のアプローチは、こちらのアプローチとなる。
27	確定リスク	リスクが確率的、または、物理的前提条件として、決定可能な危険 (事故の発生確率や危害の度合いが分かっている)。 ・物理的回避不能な状況: 車両が制御不能になる、または車間距離が物理的な停止距離を下回るなど、運転者の操作に関わらず衝突が避けられない状態。 ・不安全行動の積み重ね: 信号無視、急なカットイン (割り込み)、速度超過、前方不注意 (スマホ操作など) が重なり、回避の余地がない状態。 ・環境と操作の不一致: 視界不良、道路の凍結、歩行者の急な飛び出しなど、リスク要因が重なる状況

		<p>本提案書では、確定リスクを、ドライブレコーダから抽出したニアミスデータを確定リスクのベースとして使用している。</p>
28	不確定リスク	<p>発生確率や結果が事前に予測できない、情報が不十分な危険。 不確定要素としては、以下が考えられる。</p> <ul style="list-style-type: none"> ・人間の不確実な挙動: 相手ドライバの不注意、歩行者の急な飛び出し、居眠り、体調急変など、予測不可能な行動。 ・環境要因: 天候の急変、突風、路面状況の隠れた変化（ブラックアイスバーンなど）。 ・未知の状況: 経験したことのない道路環境や、自動運転技術が想定していない状況（エッジケース）など。 <p>本提案書では、不確定リスクとして以下を定義している。</p> <p style="text-align: center;">◇ 交通流リスク、②交通弱者リスク、③認識リスク※</p> <p>※認識リスクは、遮蔽などのジオメトリ要件で示すものと、カメラ、Radar、LiDARなどのセンサ弱点のような電磁波の物理的要件で示すものに大別している。これらは何れも将来状態が確率的に揺らぐ（これからどうなるか1つに決まらない）。</p>
29	ポジティブリスクバランス(PRB)	<p>自動運転における「ポジティブリスクバランス (Positive Risk Balance: PRB)」とは、自動運転システムがそのシステム全体において、人間が運転するよりも安全である（リスクが低い）ことを論理的・客観的に証明するアプローチ。自動運転が「絶対的に事故を起こさない」ことではなく、「人間よりも事故のリスクが低い」ことを示す、実用的な安全基準として活用されている。</p> <p>RPB の用語の出典は、以下とされている。</p> <ul style="list-style-type: none"> ・ドイツ倫理委員会 報告書 (2017 年) : ドイツ連邦交通・デジタルインフラ省 (BMVI) が設置した「自動運転・コネクテッド運転に関する倫理委員会」の報告書が、公的な議論の出発点とされている。この中で、自動運転システムの導入は「人間の運転よりも事故が少なくなること (Positive Risk Balance)」が正当化の条件として示された。 ・ホワイトペーパー『Safety First for Automated Driving (SaFAD)』(2019 年) :BMW、アウディ、ダイムラー、コンチネンタル、インテルなど 11 社が共同で発行したガイドライン。この文書において、PRB は「自動運転車の導入により、交通参加の残存リスクが低下した状態」と初めて明確に定義され、その検証方法が具体的に提案された。 ・国際標準規格 ISO/TR 4804 および ISO 34502: SaFAD の内容を基に策定された技術報告書 (ISO/TR 4804) や、日本発

		の提案を含むシナリオベースの安全性評価規格 (ISO 34502) において、PRB は安全性実証の重要なフレームワークとして組み込まれている。
30	リスク受容基準 (RAC)	自動運転におけるリスク受容基準 (RAC: Risk Acceptance Criteria) とは、自動運転システムが公道走行や実用化において、「どの程度までのリスクなら許容できるか」を定義した安全性の基準。この基準は、事故の可能性をゼロにすることが困難な中で、自動運転車が引き起こす事故のリスクが、人間が運転する場合と同等、あるいはそれ以下であることを証明するための指標となる。
31	ADS (Automated Driving System: 自動運転システム)	人間が運転操作の主体となる「運転支援 (ADAS)」とは異なり、システムが主体となって車両の操舵、加速、制動を行い、目的地まで自動で走行する技術。国土交通省では、自動運転の自動化レベルを SAE の定義に基づいて以下の様に分類している。 <ul style="list-style-type: none"> ・レベル 1・2 (運転支援) : ドライバが主となり、システムは運転操作を支援する。 ・レベル 3 (条件付き自動運転) : 特定条件下 (高速道路の渋滞など) でシステムが運転タスクを完全に担う。システムが要請した際はドライバが適切に操作に戻る必要がある。 ・レベル 4 (高度自動運転) : 特定条件下 (限定地域など) では、システムがすべての運転タスクを実行する。緊急時もドライバの反応を期待しない (無人運転など)。 ・レベル 5 (完全自動運転) : どんな状況でもシステムが自動運転する。
32	ODD (Operational Design Domain)	運行設計領域のことで、自動運転システムが安全に作動する「場所」「天候」「時間」「交通状況」などの制限条件 (条件付きの運転範囲)。
33	FOT (Field Operational Test)	公道実証テスト。実際の道路で行う実地テスト
34	RoAD to the L4 プロジェクト	経済産業省と国土交通省が推進する「自動運転レベル 4 等先進モビリティサービス研究開発・社会実装プロジェクト (RoAD to the L4: ロード・トゥ・ザ・エルフォー)」。日本の物流・移動手段における深刻なドライバ不足や高齢化を解決するため、特定の条件下で完全自動運転となる「レベル 4」の技術を社会実装することを目指す一大プロジェクト。
35	YOLO (You Only Look Once)	画像や映像に映る物体を「一度見るだけ」で瞬時に検出し、分類する、高速かつ高精度な AI 物体検出アルゴリズム。画像全体を一度の処理で解析するため、リアルタイムの動画認識に優れており、自動運転や監視カメラ、製造ラインの検品などに幅広く利用されている。また、「一度見るだけでよい」というコンセプトから、高速性とリアルタイム性が求められる現代の物体検出タスクにおいてデファクトスタンダード (事実上の標準) となっている。

36	HybridNets	2022年3月に公開された、自動運転車向けの高速かつ高精度な End-to-End の知覚ニューラルネットワークモデル。この技術は、自動運転における複雑な環境認識を1つのシステムで解決する手法として、GitHubなどで公開され注目されている。
37	アノテーション	画像、テキスト、音声などのデータに対して、AI（人工知能）が学習できるように「正解」となるラベルやタグ（メタデータ）を付ける「注釈」作業のこと。機械学習の「教師あり学習」において、高精度な AI モデルを開発するための不可欠なプロセス。
38	エージェントモデル	交通流シミュレーションでの、エージェントモデルとは、車や人を「自律的な個（エージェント）」としてコンピュータ上で再現し、個々の行動ルール（加速、車線変更など）と相互作用から、マクロな交通現象をボトムアップで解析・予測する手法です。
39	協調レーンチェンジ	レーンチェンジ（車線変更）をしようとする車両に対し、隣接車線の後続車が速度を調整するなどして、円滑な合流をサポートする行動を再現する機能です。
40	ASAM	ASAM（Association for Standardization of Automation and Measuring Systems）は、自動車開発のシミュレーション、測定、適合（キャリブレーション）、テスト自動化分野における国際的なデータ標準化団体。自動車メーカーやサプライヤがツール間の互換性とデータ交換を円滑にするための標準規格を定義している。
41	シナリオ Generator	仮想空間内での走行テスト（シミュレーション）に必要なシナリオ（シーン、交通状況、環境条件）を自動的にまたは効率的に生成するツールや機能
42	Closed Loop	車両制御の出力が再び入力に戻る“実時間フィードバック型”シミュレーション（センサ → 判断 → 制御 → 車両挙動 → 再びセンサ、という循環）
43	ADAS （Advanced Driver-Assistance System:先進運転支援システム）	「先進運転支援システム」の総称。カメラ、レーダ、センサ等を用いて周囲の状況を把握し、衝突被害軽減ブレーキや車線維持支援などでドライバの運転をサポートし、事故を防止する技術で、2021年以降、日本でも国産車への搭載が義務化されている
44	運転行動	ドライバの運転行動とは、車を走らせる上で「認知」「判断」「操作」の3つのプロセスを連続して行う行為のこと。目や耳で状況を把握し（認知）、安全か危険かを決め（判断）、ハンドルやブレーキを動かす（操作）一連の動作が、事故を避けるための安全な運転の基本。
45	安全クリティカル部品（Safety-	その部品が故障したり機能不全に陥ったりした際に、自動車の走行、停止、操舵といった基本的な機能に支障をきたし、人命に関わる重大な事故（火災や衝突など）を及ぼす可能性が高い要素・コンポーネントのこ

	Critical Components)	と。重要保安部品とも呼ばれる。ここでの部品(Components)は部品の故障でなく、走行条件での重大事故に至る要因（ハザード）を示すこともある。
46	Pegasus プロジェクトの 6-Layers	ペガサスプロジェクトとは、2016 年から 2019 年にドイツで実施された、自動運転車（レベル 3 以上）の安全性評価基準を確立するための産官学共同プロジェクトで、実走行テストだけでは不可能な膨大なシナリオを、シミュレーションを使って効率的に検証することを目的にしている。（シナリオベースアプローチの手法） 6-Layers とは、自動運転の走行環境を、静的な要素から動的な要素までの 6 つのレイヤー（層）に分けてモデル化する手法。これにより、複雑な実世界の道路環境をシミュレーション上で再現する。
47	FMEA/FTA	自動運転の安全性確保に不可欠な FTA（Fault Tree Analysis）と FMEA（Failure Mode and Effects Analysis）は、故障や事故を未然に防ぐための手法。FTA は事故（トップ事象）から原因へ深掘りする「トップダウン解析」で、FMEA は部品の故障モードから影響を分析する「ボトムアップ解析」。両手法でリスクの特定、評価、対策を実施する。
48	ASIL	ASIL（Automotive Safety Integrity Level：自動車安全度水準）は、ISO 26262 機能安全規格に基づき、車載電子システムの故障リスクを A から D の 4 段階で評価する定量指標。D が最も厳しく、ブレーキやエアバッグなど最高水準の安全確保が求められる。
49	Test based と Safety Case approach	自動車開発における「Test-based（実車試験ベース）」アプローチと「Safety Case（安全論証）」アプローチは、主に自動運転システム（ADS）の安全性をどのように実証・保証するかという点で異なる。最大の違いは、「膨大な走行テストの結果で安全を示すか（Test-based）」、「論理的な根拠に基づいて安全性を説明（安全論証）するか（Safety Case）」という点となる。
50	ADS regulation UNR and GTR	自動運転システム（ADS：Automated Driving Systems）における国際的な規制調和において、UNR（国連規則）と GTR（世界技術規則）は、異なる仕組みで自動運転車の安全基準を定め、普及を促進する重要な役割を果たしている。これらは国連欧州経済委員会（UNECE）の自動車基準調和世界フォーラム（WP29）で議論・制定される。
51	HIRA	HIRA は「Hazard Identification and Risk Assessment」（危険源の特定とリスク評価）を意味し、安全性を確保するための重要なプロセスで、自動運転車両が走行中に直面する可能性のある危険因子（Hazard）をあらかじめ特定し、そのリスクを評価・低減すること。
52	TTC/PET	TTC（Time To Collision）と PET（Post Encroachment Time）は、システムが周囲の環境（他の車両、歩行者など）との「衝突の危険性」を測

	<p>定・評価し、安全性確保や回避操作を行うために用いる「コンフリクト指標（ニアミス指標）」。</p> <p>TTC は、「自車と前方ターゲット（車や歩行者）が、現在の速度と方向を維持した場合に、衝突するまでの残り時間」。時間が短いほど危険性が高い。</p> <p>PET は、「ある車両（または歩行者）が交差点などの通過エリアから離脱した時間と、その同じ位置に別の車両（または歩行者）が到達した時間との時間差」。値が小さいほど、2つの物体がニアミス（衝突寸前）であったことを示す。</p> <p>本提案書 1.2.5 節で記載の様に、SAE International J3237_202508 では、静的指標と捉えられ、全 7 項目中 3~4 項目の要件には適合せず DDT（Dynamic Driving Task：動的運転タスク）の評価指標としては不十分とされている。</p>
--	--

APPENDIX

A. 高速道 FOT 検討会&シミュレーション試行評価

本プロジェクトでは、経済産業省商務情報政策局情報経済課が実施する「2025 年度『自動運転の実用化・普及展開及び標準化・規格化に関わる高速道 FOT テーマ②：シミュレーションを活用した自動運転の安全性評価手法の構築』事業の下で、FOT 検討会を設立した。

FOT 検討会にはスズキ（株）、（株）SUBARU、（株）T2、トヨタ自動車（株）、（株）ロボトラック、AUMOVIO（順不同）に参加いただき、本安全性評価フレームワークに対する助言をいただくとともに、シミュレーションの試行評価（接続性評価）を実施いただいた。これらのフィードバックは「実効性のある安全性評価フレームワーク」の構築を目指す上で、極めて貴重かつ有益なものであった。参加いただいた各社の皆さまに深く感謝の意を表する。

(A) FOT 検討会と参加者からのフィードバック

1) FOT 検討会の開催と参加者

2025 年度『自動運転の実用化・普及展開及び標準化・規格化に関わる高速道 FOT*』として、6 社(図 3-8-2)の参加を得て、第 1 回のキックオフ会を含め計 7 回実施した。各回の主な議事概要は図 3-8-1 のとおりである。




Fig. A-1 Status of the working group on the development of a draft “practical safety assessment framework”

Table A-1 6 participating companies

参加 6 社

高速道 FOT 実験参加者 (6 社)	<ul style="list-style-type: none"> ・ スズキ（株） ・ （株）SUBARU ・ （株）T2 ・ トヨタ自動車（株） ・ （株）ロボトラック ・ オモビオ・オトノモス・モビリティ（株）
------------------------	---

※敬称略

2) 参加者からのフィードバック

第 1 回 FOT 検討会での議論を始め本活動の実施に当たっては、参加者から以下のような意見があった。

- ・ 認証認可を視野に入れた評価基準が確立できる（お墨付きが得られる）活動となるとよい
- ・ 海外各国の認証・認可への対応も視野に入れるべき
- ・ シミュレーションはどこまでできればよいのか、の共通の認識が醸成できると良い

これらから分かるように、開発者共通の悩みがあり、実効性のある安全性評価手法の構築に対して協調して取り組むことに対する期待が高いことが確認できた。

第 2 回 FOT 検討会以降、以下のような意見が得られ、その場で議論しつつ合意を取りながら進めた。それらの結果を踏まえ、本提案書では対応策やより詳しい説明を極力織り込んだ。国際標準 ISO 34502、ISO 21448 (SOTIF) 等の動向に対して、これら標準との比較や整合性の確保に関する意見があり、この点については本稿第 1 章で整理した。

ニアミスデータ活用は、その有用性に関し賛同する意見が多くあった。リスクシナリオ生成に有効であり、分類・分析し形式化することで、評価の現実性を高めることができる点などが理由に挙げられる。第 2 章、第 3 章の「リスクシナリオデータセット生成」で具体的な考え方、方法について解説している。

交通流シミュレーションに関しては、無限にある評価シナリオの有限化の観点で賛同が得られた。一方で、妥当性の確保に関して議論になり、課題感は解消されていないが、「不確定リスクの統計的決定」の考え方・方法を参加者と共有するとともに、3.5 マクロ評価で妥当性確保に向けた取組みを詳しく説明した。

SCT に関しては、自車が基準になっているが、他車への影響等シーンを広く評価できるとよいとの意見があった。今回、同じく 3.5 マクロ評価の章で、具体的には先行 2 車間のデータ解析を実施しその行動の自車へのリスクとして評価する等、具体的な活用方法を示した。

また AI に関する意見として、ニアミスシーンは現実にあったという事が重要で、AI による類似シーン作成はこの現実重視の考え方から離れてしまうのでは等の疑義も示された。これに対しては Appendix の『安全性評価のための生成 AI 活用の在り方』において、ハルシネーションを抑制しつつ、物理的制約に即した「現実的なリスクシナリオ」を生成する手法を提示した。具体的には、リスクを言語化する「フレーズング」と移動軌跡などの「物理量の定義」を組み合わせ、画像生成 AI 制御用の「ハイブリッドプロンプト」を新規提案し、検証中であることを示した。

今回の活動を踏まえて、他に以下のような意見もあり、さらなる検討が必要である。

- ・ (不足する) データを収集するため、各社保有のニアミスデータと連携すべきである。

このためには、OEM、サプライヤ、保険業界等を含め、ニアミス走行データの利活用のためのスキーム作りに向けた検討が必要である。また、今後継続して検討していくべき項目として、運転行動の安全性評価のクライテリアの考え方や、認可・認証に向けた SCT の一致性および信頼性の確保に関する活動の必要性も指摘された。

Table A-2 List of Key Issues (1)
代表的課題一覧 (1)

#	合計	対応済	継続検討が必要な項目
課題	18	13	4
意見	39	37	2
質問	19	19	0

主要なフィードバック 主要なフィードバック20件を抽出。継続検討が必要な項目はハッチング

No	項目	#	主要なフィードバック内容	対応	状況
1	ニアミスシナリオ	1-1	ニアミスデータを活用する方向性について ■賛同 (2割: 1社) ■概ね賛同 (課題・意見あり) (8割: 5社)	ニアミスデータを活用する方向性について、概ね賛同いただいた。	済
		1-2	提案のフレームワークの方向性をベースに具体化の議論をすすめていくことについて ■賛同 (3割: 2社) ■概ね賛同 (課題・意見あり) (7割: 4社)	提案のフレームワークの方向性をベースに具体化の議論をすすめていくことについて概ね賛同いただいた。	済
		1-3	特殊ケースによるニアミス(緊急車両の扱い、動物の侵入、逆走など)はどのように扱われるのか。	「高速道路リスクの類型化(12分類)」に対し6類型(エッジケース等)を追加。(ET/グート、SA・PA、歩行者・動物、緊急車両、逆走、災害)	済
		1-4	ニアミスデータ活用は、リスクシナリオ生成に有効であり、評価の現実性を高める点で意義があると考え。	4回、5回検討会で「ニアミス走行データの解析」、パラメータ抽出の具体的な結果を提示し議論。	済
		1-5	単なるニアミスデータだけではなく、分析して形式化したものでない安全性の説明力としては不足する。	5回、6回検討会で「リスクシナリオデータセット生成」、具体的な考え方を提示。	済
		1-6	現実のリスク把握が不十分なため、各社が持つ走行データ(ドライブレコーダ)との連携が不可欠では。標準化と差別化の間のトレードオフは難しい課題。	「ニアミス走行データ所収」の観点で重要。外部(OEM各社等)のデータ利活用の観点での議論へ移行して検討する必要。	継続すべき項目
		1-7	(生成AI) ニアミスシナリオは現実にあつたという事が重要だと考えている。これをAIで類似シナリオを作成してしまふ、有限化の考えから離れてしまふ。	5回、6回検討会にて、APPENDIX「安全性評価のための生成AI活用の在り方」において、現実を超えないリスクシナリオの作り方について提示。	済
2	交通流シナリオ	2-1	交通流シミュレータを用いた評価シナリオの有限化に対する方向性について □賛同 (0) ■概ね賛同 (課題・意見あり) (10割: 6社)	交通流シミュレータを用いた評価シナリオの有限化について、概ね賛同いただいた。(5回、6回で「不確定リスクの統計的決定」として議論)	済
		2-2	リスクシナリオ + 交通流の流れで整理が進みルール化できると期待したい。	6回検討会にて「リスクシナリオデータセット生成」でのマイクロマクロ評価にて考え方を説明。	済
		2-3	交通流シミュレータの妥当性の基準	5回、6回検討会で「不確定リスクの統計的決定」として、ベース交通流、交通流リスクの設定とAgent Modelの妥当性検証について提示。	済

Table A-3 List of Key Issues (2)
代表的課題一覧 (2)

No	項目	#	主要なフィードバック内容	対応	状況
3	SCT評価手法	3-1	SCTでは自車が基準になっているが、他車への影響等シナリオを広く評価できるよ	4回、5回で「運転行動の安全性評価」SCT指標として提示。頂いたご意見への回答として、先行2車間のデータ解析を実施。(先行2車の接近によるバードを自車へのリスクとして評価した例)	済
4	標準化活動との整合性確保	4-1	ISO 34502はシナリオベース評価、ISO 21448 (SOTIF) は残留リスク評価を重視していること認識しており、提案フレームワークとの整合性を期待する。	各標準との整合性を継続して整理していく。JARI関係者とすり合わせを行い、結果も随時フィードバックしていく	継続すべき項目
		5	認証・認可に同時対応	5-1 標準的な評価基準(お墨付き)が確立される活動となっていること 5-2 認証認可を見据え、海外各国の「5つ星」にどう対応するか難問。妥当性の検討はさらに難しい。 5-3 SIMはどこまでできれば(対策車) OKなのか?どこまでやればよいとの共通の認識が醸成できると良い。 5-4 クライテリア(青いライン)の決め方が課題。ラインを決めることは協議領域、「ODD 範囲、制約の見直し」等対策でライン内へ持つものは競争領域という理解? 5-5 認可・認証を想定してSCTの一致性、信頼性の確保に向けた活動が必要	原案を3月に国交省へ提案予定。 (WP29の基準制定に向け安全性評価フレームワークの実装を準備。) 今年度は国内で進めていく。原案を3月に国交省へ提案予定。 (WP29の基準制定に向け安全性評価フレームワークの実装を準備。) 6回検討会で原案としての考え方を「シミュレーションを活用した安全性評価の成り」として提示。具体的シナリオの獲得については、実務の利用者が今後「ODD-リスクアセスメント実践」の上で継続して取り組む必要がある。 5回、6回検討会で「運転行動の安全性評価」、運転行動としての安全性評価のまとめ方(案)を提示。今後、交通流シミュレーションでのニアミス頻度等をベースにクライテリアの議論を進めていく必要がある。 6回検討会で議論：農工大とヤマトDBとの比較等で検討中。今後データに基づき検証レベルを上げる。データが集まればロングテールの取組みも強くなる。
6	その他	6-1	シミュレーションは有効で評価に必須。実態の整合の為にデータ積上げが必要。SAKURAの延長、拡大を考えていく必要がある。連携し進める。	(高速道FOTの取組みを理解頂いた。またJARIの取組みや知見をベースに連携して行くことを確認)	済

(B) 各社シミュレーション試行評価(接続性評価)

(1) 接続性評価の狙い

認可を見据えた安全性評価を実施するためには、各社ごとに異なる様々なシミュレーション環境において、共通のリスクシナリオを取り込み、シミュレーションを実行し、共通の指標で評価ができることが必要である。標準的かつ効率的に各システムの連携を実現する「ツールチェーン」整備に向けた課題を洗い出すため、接続性評価を行った。

(2) 接続性評価の実施概要

接続性評価は次の2種類の評価を参加者に依頼して実施した。それぞれの評価の目的は以下の通

りである。

接続性評価①

各社の様々なシミュレーション環境に対して、共通のリスクシナリオを提供できることを確認する。

接続性評価②

異なるツール間における連携を可能にする『ツールチェーン』の実現性及び課題を把握する。

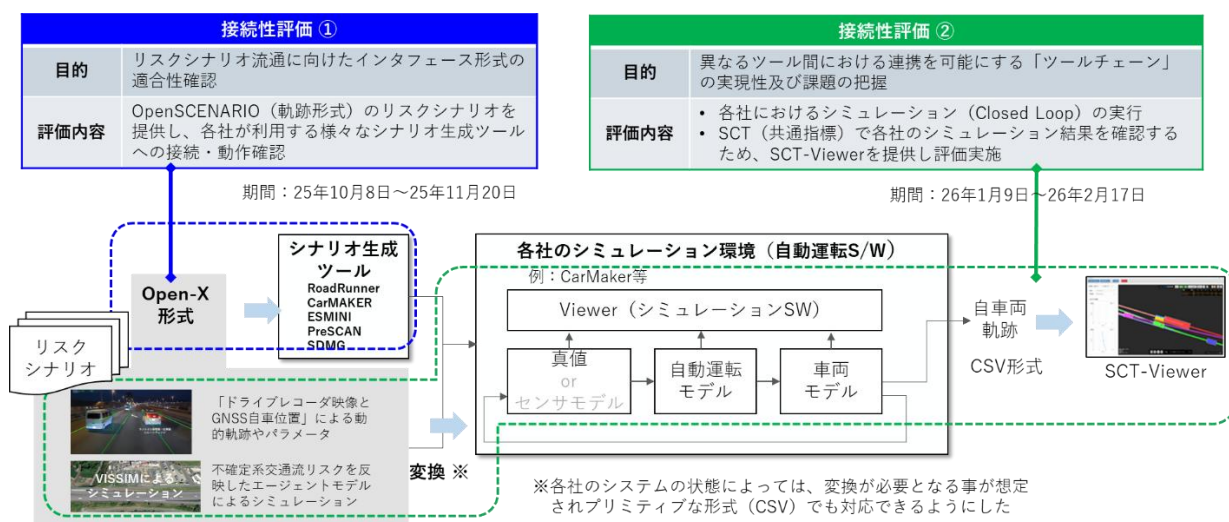


Fig. A-2 Overview of connectivity assessment
接続性評価の概要

(a) 接続性評価

ツールごとに特性があり、OpenSCENARIO のイベント形式での共有には課題があったため、‘軌跡形式’で実施した。様々なシナリオ生成ツールおよびシミュレーション環境の特徴に合わせ、それぞれで軌跡を定義する記述方法の調整は必要であるが、‘軌跡形式’であれば検討したすべての生成ツールにシナリオが展開できることを確認した。

‘軌跡形式’のシナリオ生成のために、OpenDRIVE 向けデータの修正（座標データの位置合わせ）および座標変換等を実施した。また、シミュレータごとに実施した作業としては、OpenSCENARIO の記述（タグ情報、座標変換）を各社システムに合わせて個別に変更・調整する必要があった。

高速道 FOT 参加 6 社のうち、4 社が SCT 評価を完了した（うち 2 社は、制御の効果まで確認）。残りの 1 社は課題と対策を確認済であり、もう 1 社は制御 SW を所有していないため認識評価を実施いただいた。

Table A-4 Issues identified during the evaluation of connectivity with various companies' simulation

各社シミュレーションとの接続性評価における指摘事項

#	実施日	会社名	ヒアリング内容
1	2026年2月3日	A	開発の側面では、シナリオは評価用として意図にあわせて整備している。車線変更時に変更先の車線に他車両が居るケース等を想定してシナリオを組んでいる。
2	2026年2月3日	A	今回提供頂いた合流時の回避シナリオ（ドライバ行動ベース）は、回避しないパターン（減速で対応車を前に入れる）があれば、（LTAやACCの）評価において使いやすい。
3	2026年2月17日	A	自動運転制御SW起動に一定の時間（10S程度）が必要（ADシステムが起動し、周辺車両の行動予測等を実行する時間）
4	2026年2月16日	B	システムリリース後の改善対応でのシミュレーション活用には期待したい。特に性能変更ではないケース（環境変化への対応等）の実事確認はなおさら。
5	2026年2月16日	B	適合の工程でなくとも、開発プロセスの中で、（次工程への）リリース毎に実機テストを課している。シミュレーションで実施できれば相当（期待感実走行工数1/3へ削減）な効果がある。もちろん認識含むシミュレーションのレベルアップが必要だが。
6	2026年2月16日	B	上記の様な要件ベースの評価に加えて、エッジケース（危険事象、認識リスク等）ができれば更に開発効率が向上。
7	2026年2月17日	B	オクルージョン（遮蔽）の考慮等、目的とする評価に必要なシミュレーション環境の要件についても整理・検討が必要。
8	2026年2月17日	C	狙っている（今回のシミュレーション）コネクットの効果は、そもそもニアミスを起こさない事。安全性方向に相当振る制御になっている。
9	2026年2月17日	C	交通流シミュレーションで各車両の関係をSCT評価でき、制御の効果がリスク頻度として確認できることには非常に期待したい。指標の標準化に期待したい。
10	2026年2月17日	C	今後E2Eベースでのシステムが拡大する方向と思う。シミュレーションの範囲も飛躍的に広がると思うが、難は2つで1つはハルシネーションをつぶせること、もう1つは量ではなく、正確に評価する部分のルールを決めておくことと考える。
11	2026年2月17日	C	今後OTA等、システム進化のスピードが求められる環境を想定すると、シミュレーションで（SCT値等指標で）具体的に対応する仕組み作りは必ず必要。
12	2026年2月17日	D	OpenXにおいてシナリオ記述の自由度が高くツール間の互換性確保に課題。
13	2026年2月17日	E	共通シナリオを利用するには、軌跡形式での授受は現実的かつ確実な手法。
14	2026年2月17日	E	今回提供頂いた現実の事象に基づくデータとシナリオのセットは貴重である。走行データとその解析、そのシナリオ化は自社で取り組むには負荷が大変。データをより収集し、活用し易くする為の実データからシナリオデータ生成の処理プロセスの標準化が必要。
15	2026年2月20日	E	システムはLinuxベース。ツール群はクラウドを前提とした提供が望ましい。

(b) 接続性評価のまとめ

共通のリスクシナリオを各社のシミュレーション環境に流し、シミュレーションを実行した上で、共通の指標 SCT で評価するという一連のプロセスが、複数のツールチェーンの中で実行可能であることを確認できた。これまでの FOT 検討会での有効性の議論と合わせ、今回の接続性評価の結果から、我々の提案している安全性評価手法は実効性のある評価手法であると考えている。

今回の接続性評価を通して課題の抽出と対応策を示すことができたが、ツールチェーン整備に向けてはまだ課題は多い。今後も引き続きユーザからの意見や要望を広く集め、ツールチェーンの完成度を向上に取り組んでいく所存である。

今回挙げた要望のほかにも、オクルージョン（遮蔽）再現の必要性など、道路形状や遮蔽物を再現できるシミュレーションの高度化や、それに対応する環境モデルを含むリスクシナリオの拡張を期待するとの意見があった。

また、今回提供した SCT-Viewer は、自他車両の位置や速度の表現にとどまっており、情報量が少ないという指摘もあった。今後、時空間での運転行動の変移を可視化するツールとして、3次元で運転行動の動的表現を可能にするツールと、そのシーンを構成する環境モデルの整備及び高度化が求められる。これらの指摘事項に関しては、今後改善に取り組んでいく予定である。

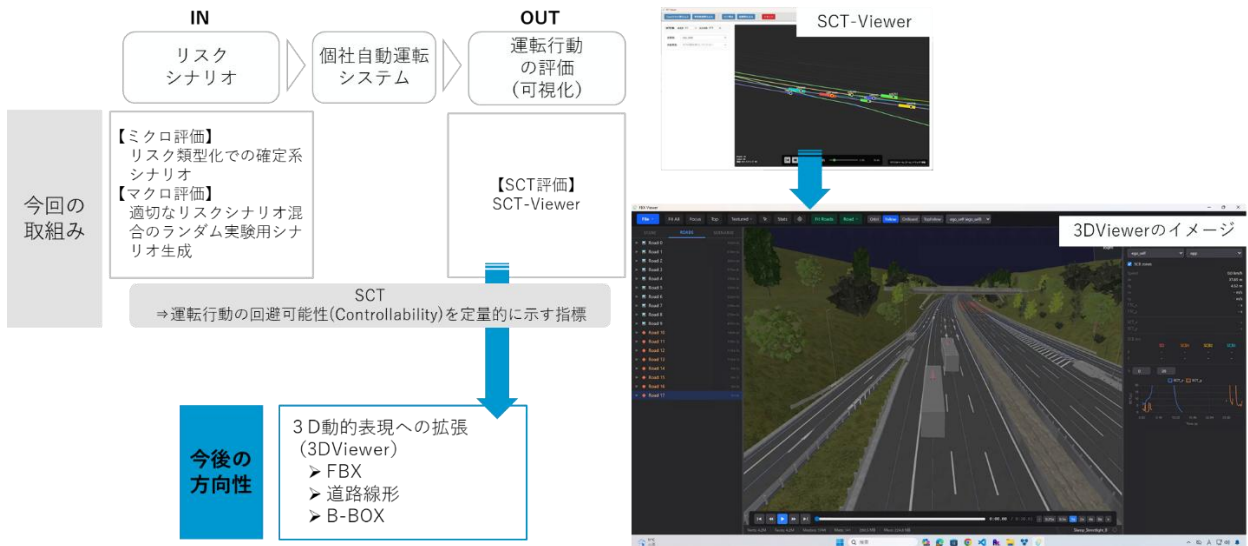


Fig. A-3 Evaluation of driving behavior models using virtual space models as risk scenarios
リスクシナリオとしての仮想空間モデルを活かした運転行動モデルの評価 (可視化)

(3) 接続性評価事例 (SUBARU 様)

自社の独自シミュレーション環境において、遠州森町の合流シナリオを用い、運転制御の ON と OFF の 2 種類の状態での車両軌跡を SCT-Viewer に渡すところまでの一連の流れを実行した。提供したリスクシナリオは、遠州森町における合流シナリオであり、合流車が本線を走行する自車の前に合流しようとする 15 秒間の状況を対象としている。



Near-miss source data
ニアミス元データ



Risk scenario replication
再現したリスクシナリオ

Fig. A-4 Near-miss source data and risk scenario replication using DIVP
ニアミス元データと DIVP で再現したリスクシナリオ

シナリオ生成ツールとして交通流シミュレータを使用し、シミュレーション環境に合わせた地図出力形式に変換した。市販シミュレーション SW および車両モデルに車両位置と地図を読み込み、ニア

ミスシナリオを再現した。V2N による自動運転を想定したサーバが走行計画を算出し、自動運転制御を行った。




Fig. A-5 Block diagram of the simulation environment
シミュレーション環境ブロック図

自車の軌跡は、シナリオの初期位置および時間に合わせ、運転制御モデルでの制御に切替えたもの (ON) と、切り替えないもの (OFF) の 2 パターンで再現した。その結果を SCT-Viewer で SCT x (縦方向) として表現した。

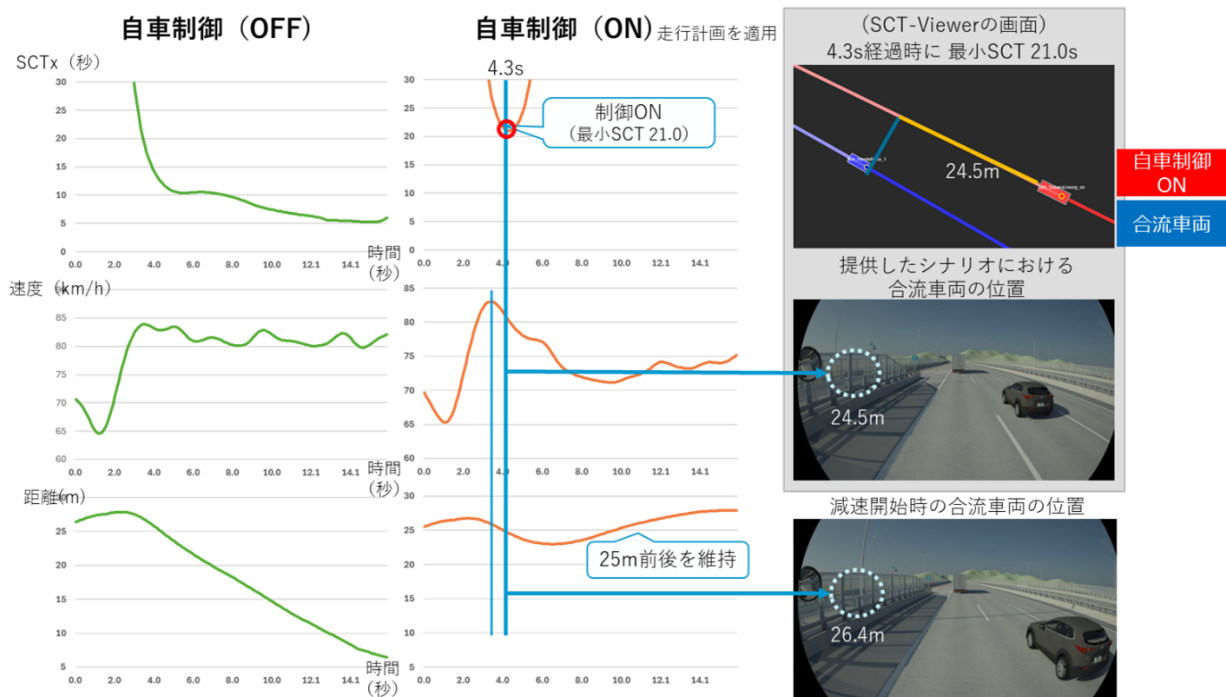


Fig. A-6 Simulation results
シミュレーション実施結果

(4) 接続性評価事例（ロボトラック様）

自社開発シミュレータ上で、リスクシナリオを用いた自車 Closed-Loop シミュレーションを実行した。リスクシナリオの走行軌跡を CSV 形式でエクスポートし、シミュレーション化した。SCT-Viewer に渡すまでの一連の流れを確認した。



Near-miss source data

ニアミス元データ



Risk scenario replication

再現リスクシナリオ

Fig. A-7 Near-miss source data and risk scenario replication using DIVP
ニアミス元データと DIVP で再現したリスクシナリオ再現

首都高 C1 における合流シナリオを利用し、本線走行中の自車の前に合流車が進入してくる状況を再現した。シナリオでは自車両はレーンチェンジすることで合流車を回避する。自社製シミュレータにおいて、車両ダイナミクスに基づく自車の Closed-Loop シミュレーションを実行した。

シナリオ読み込み手順としては、提供された OpenX 形式データ (.xodr/.xosc) からマップ情報および他車軌跡データを抽出し、自社プラットフォーム用に最適化された内部 XML マップおよびシナリオデータ形式へ変換した。シミュレーション実行後、自車 (Ego) の走行軌跡を CSV 形式でエクスポートし、SCT-Viewer に取り込んだ。なお、シナリオの事前確認 (可視化) 用途としてのみ、シナリオ生成ツール esmini を使用している。

提供シナリオでは自車が直前でレーンチェンジして回避するのに対し、自動運転制御では合流車を合流車線上で検知し、事前に減速することで安全に合流させた (SCT 約 3 秒から約 9 秒に改善)。なお、当シミュレータでは高精度地図を参照し、合流車両の挙動を事前に予測して最適速度まで減速する。

B. 標準データセット・フォーマット

(a) 標準データセット・フォーマットの定義

ニアミスデータはヒヤリハットデータとも呼ばれ、これまでも道路交通安全対策や車両安全システム開発、保険業務のために事故解析などの基礎データとして活用されてきた。また昨今では自動運転開発のためのデータとしての重要性が増しつつある。一方で、これまではシミュレーション用のデータとしての議論は十分にされておらず、現存するヒヤリハットデータベースもシミュレーションに十分に活用できているとは言い難い。安全性の向上に加え、車両開発の大幅な効率化のためにも、ニアミスデータのデータセットおよびフォーマットの標準化は不可欠である。加えて、シミュレーションを中心においたツールチェーンを充実させるため、データ連携基盤の構築も進めていく必要がある。

ここでは、ニアミスシーンを構成する安全性評価目的のデータセットおよびフォーマットを定義する。

カメラ情報から抽出したニアミスデータ (Raw データ)、アノテーション情報 (ジオメトリ、座標、リスク類型等のシーン情報)、およびその解析情報 (動的パラメータ群) を共通の構造で整理することで、効率的な収集と条件の異なる環境間での再利用を可能とする。

また、データ流通および相互運用性の観点から、シナリオ形式は、国際標準である ASAM に準拠する。以下にその項目と内容を示す。

Table B-1 List of standard dataset formats
標準データセット・フォーマットの一覧

項目	内容
ニアミスデータ (Rawデータ)	<ul style="list-style-type: none"> 動的映像 (MP4: Front/Rear/Right/Left) ※マスキング処理済み GNSSデータ (タイムスタンプ、車速、緯度・経度、XYZ-Gセンサー)
アノテーション情報	<ul style="list-style-type: none"> ニアミス集計リスト (xlsx: シーン種類No: 18種類、ニアミスリスク大中小、シーン詳細) アノテーション情報ファイル1 (json: カメラ取付け位置・角度/内部パラメータ、時間) アノテーション情報ファイル2 (json: ↑に、天候、シーンの状況) ※生成AI技術で検討中。
データ解析情報	<ul style="list-style-type: none"> 時系列軌跡データ (csv: フレームNo、時間、相対速度、相対距離、車速、緯度・経度、SCT、TTC、XYZ-G) データ解析View (MP4: Front・Rear動画、SCT_x、SCT_y、SCT-BOX他) 交通流モデルパラメータ (xlsx・csv: 自車速、相対速度xy、相対距離xy、SCTxy、加減速度)
シナリオ形式 (ニアミス、交通流※)	<ul style="list-style-type: none"> OpenSCENARIO (シナリオ定義: 動作・イベント、軌跡) ※軌跡はCSV形式も用意 OpenDRIVE (道路環境、MAP) FBX (外景/外観、3Dアセット) ※主に認識リスク評価時 ※交通流シナリオの形式については、検討中

(b) 動的映像からのシナリオ生成

自動運転の安全性を評価するに足るレベルで交通状況を把握するためには、膨大な画像データを収集・分析する必要がある。安全性評価に関わる情報を抽出するために最適な、ニアミストリガからの所得時間範囲について考察する。

今回の取り組みにおいては、動的映像 (カメラ画像) からニアミスデータの収集を実施している。動

的映像から得たニアミス事象をシミュレーション用のシナリオ形式で表現するには、表現される時空間範囲を規定する必要がある。そのため、再現時間（シーンにおけるニアミストリガからの所得時間範囲）設定について定義する必要がある。

その表現に要する時間範囲には、シーン毎に差異がある。例えば、二輪車が自車両の右横をすり抜けるシーンでは、その相対速度差により表現に要する時間は短くなる。一方、自車の前を行く車両のカットインなどでは、特に対象車両がトラックである場合、相対速度差が小さいため時間を要することが予想される。図 B-1 に、12 種類の各カテゴリーに対するニアミストリガを示す。再現時間の範囲は、ニアミストリガを基準として前後±T0 秒として定義する。

分類No	分類	トリガー（データから抽出可能なトリガー）
DX-01	合流	合流車線（白線）を横切る瞬間
DX-02	カットイン	自車のレーンの白線を横切る瞬間
DX-03	カットアウト	先行車が、レーンチェンジして、隣の車線に入り込んだ瞬間（リアタイヤが白線を横切り、白線内に入った瞬間）
DX-04	渋滞	先行車に追従中、先行車が渋滞による（急・意図せぬ）制動（ハザード）または周辺車が渋滞によるハザード点滅した瞬間
DX-05	視界不良	視界不良が、一番ひどくなった瞬間
DX-06	ブラインド	ブラインド（トンネル・周辺車両・カーブなど）抜けて、先行車が見えた瞬間
DX-07	レーンチェンジ	自車が、レーンチェンジし、隣の白線を横切った瞬間
DX-08	カーブ	カーブ中に、リスクが極大（隣接車両・車線逸脱等）になった瞬間
DX-09	車線逸脱	先行車が、最初にふらついて車線を横切るまたは近づいた瞬間
DX-10	落下物	落下物（発煙筒、パイロンなど）を、追い越し（または操舵回避）した瞬間
DX-11	故障車	故障車（停止車など）を、追い越し（または操舵回避）した瞬間
DX-12	二輪車	二輪車が、自車カメラにフレームインした瞬間




Fig. B-1 Triggers for identifying near misses
ニアミスを検出するためのトリガ

各トリガを利用して、実際のドライブレコーダでニアミスを取得し、シミュレーション化した例を以下に示す。

二輪車が自車両の右横をすり抜けるシーンにおいては、相対速度が非常に大きいため、短時間での表現で十分である。




Fig. B-2 Rplcation of a scene involving a motorcycle weaving through traffic using DIVP
DIVP 活用での二輪車すり抜けシーンの再現

一方で、先行車が車線逸脱を繰り返す不安定な挙動を示し、側方を追い越す他車両との間で危険な状況を作り出す（後方の自車両にとってはハザード）シーンの挙動を把握するには、ある程度の時間を要する。



Fig. B-3 Replication of lane departure caused by the wobbling of the ahead vehicle Using DIVP
DIVP 活用での前方車両のふらつきによる車線逸脱再現

これらの事象の違いを踏まえ、ニアミス抽出トリガを基準として再現する時間範囲は、短時間の場合は±10秒以下、長時間の場合は±18秒の範囲とする2水準を設定する。

また、前方車両間で発生するリスクが自車に二次被害をもたらすおそれがあるハザードを考慮すると、18秒の設定では不十分となる可能性もある。このため、シナリオとセットで整備する元データ（ドライブレコーダ画像）の時間範囲は、ニアミス発生時刻を基準として±30秒と定義し、シナリオ化の際に時間範囲延伸が必要となる場合に対応する。




Fig. B-4 Scenario time range for each scene
シーン毎のシナリオ時間範囲

以上のシナリオ時間範囲に関する標準的な考え方に対し、3.4章では具体例として、合流、カットイン、レーンチェンジのリスクシナリオ（動的な時空間のシナリオ）の範囲を、SCT 最小値をトリガとして15秒間（+5秒、-10秒）として定義している。

(c) 標準データセット・フォーマットの標準化について

自動運転に関わる国際標準としてはISO および SAE が知られている。これらのプロセスレベルの標準に対して、シミュレーションの実装レベルでは、事実上 ASAM が国際標準化活動の中心となっている。安全性評価に適した走行環境シミュレーションのベストプラクティスを早期に実現するためには、各社におけるツールチェーンの構築を促す必要があり、そのために ASAM の OpenDRIVE/OpenSCENARIO を活用する。

さらに、より精度の高いシミュレーションを実現するためには、OSI や OpenMATERIAL3D といった国際標準も利用できる。

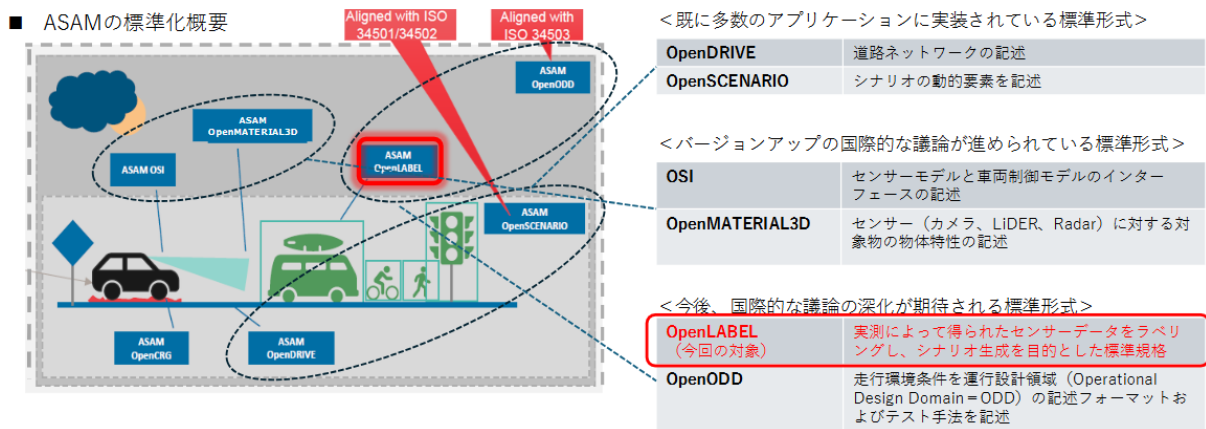


Fig. B-5 Overview of ASAM standardization
ASAM の標準化概要

シナリオの生成に際しては、センサーデータへのアノテーションを定義する OpenLABEL を活用することで、作業の効率化が期待できる。今後は、安全性評価を目的としたアノテーションをより実現しやすするため、有効なデータ項目や構造について検討し、適切な時期に ASAM への拡張提案を実施する予定である。

安全性評価のための拡張提案としては、例えば以下のようなものが考えられる。

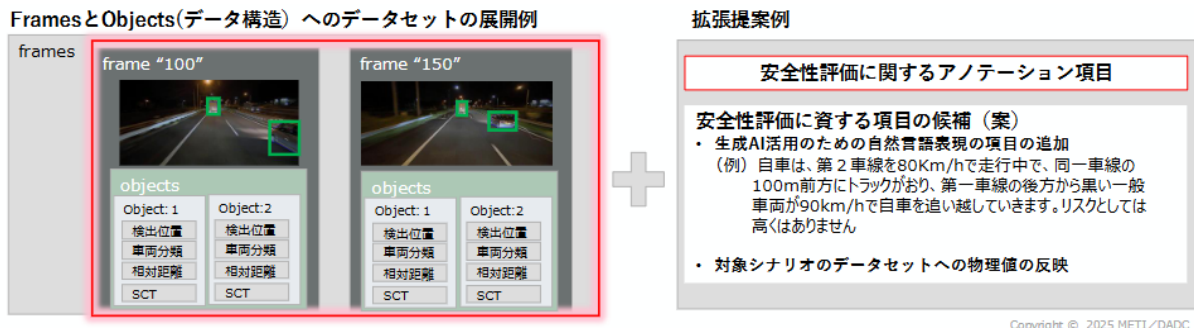


Fig. B-6 Proposal for augmentating risk scenarios for safety assessment
安全性評価のためのリスクシナリオ拡張提案

C. 安全性評価のための生成 AI 活用に関する研究

1) 狙いと概要

生成 AI を活用し、リスクシナリオ生成の“パイプライン処理の効率化（時間削減）”を狙う。今回特に『アノテーション』と『リスクシナリオ生成』に取り組み、有効性を示唆できた。

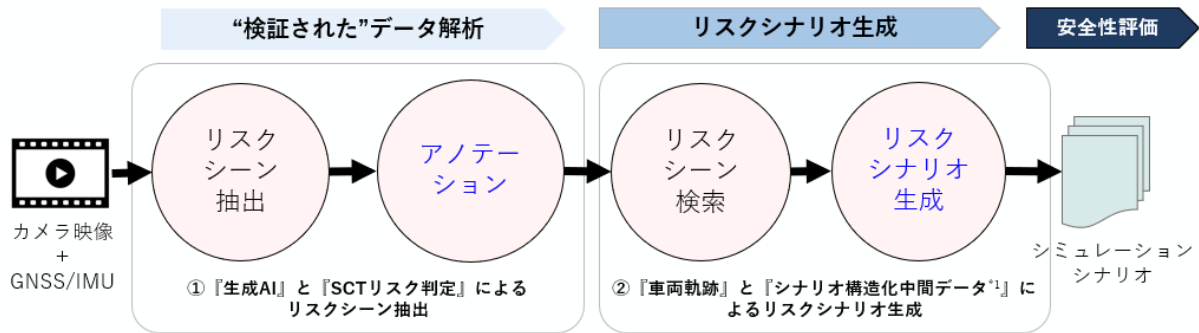


Fig. C-1 Diagram of a risk scenario generation pipeline using AI and generative AI

AI 及び生成 AI 活用のリスクシナリオ生成パイプライン図

2) 生成 AI の課題と解決策

生成 AI でシナリオを自動生成する試みが進む一方、4つの根本的な課題が存在する。物理的評価指標 SCT を用い、さらに物理的条件以外の側面からも生成 AI に適切な制約を与えるシナリオ構造化中間データを用いることで、これらの課題の解決に向けた目途を立てる

Table C-1 Challenges and solutions for generative AI

生成 AI の課題と解決策

	課題項目	内容	解決策
1	妥当性の欠如	生成 AI が物理制約を無視してシナリオを作る	<ul style="list-style-type: none"> 物理条件であるリスク評価手法 SCT を活用することで解決する シナリオ構造化中間データを用いることで、制約をかけて変更し解決する
2	リスク定量化の不備	知覚・システム難度が混在し、真の危険度が見えない。「本当に厳しいシナリオ」と「見かけだけ難しいシナリオ」が混在。	<ul style="list-style-type: none"> SCT を活用し解決する (リスクなし、リスク小、リスク中、リスク大) = (SCT > 3 秒、2 秒 < SCT ≤ 3 秒、1 秒 < SCT ≤ 2 秒、SCT ≤ 1 秒) を参考に制御する)

3	シナリオ記述の非統一	シナリオ層と環境・道路層が独立・矛盾する場合があります。	<ul style="list-style-type: none"> シナリオ構造化中間データを用いることで左記が矛盾しない形で作成できる
4	検証方法の未確立	妥当性確認の標準が無く、シナリオ品質を保証できない	<ul style="list-style-type: none"> SCT 条件を活用することで解決する

3) 『生成 AI』と『SCT リスク判定』によるリスクシーン抽出

- ・ドライブレコーダ映像より周辺車両を物体検出し軌跡データとして再構成(LiDAR や Radar 必要なし)
- ・カメラ映像(1 シーン 30 秒程度)から SCT を利用して生成 AI を活用し”ニアミス”と“アノテーション情報”を自動抽出 (人手で行っていた作業を大幅時間削減)




Fig.C-2 Trajectory extraction via object detection and annotation from video
物体検知による軌跡抽出と映像からのアノテーション

4) 『車両軌跡』と『シナリオ記述構造化データ』によるリスクシナリオ生成

ドラレコ映像の合流シーンから生成 AI を活用してシナリオ記述構造化データを作成し、そこから OpenSCENARIO を作成する。生成 AI で直接シナリオ化する方法と比較して、物理的制約を満たしつつ、ユーザの意図した通りのシナリオ化を実現できた。

シナリオ記述構造化データ(YAML)

```

scenario_name: "Merge and Lane Change Scenario"
map_name: "E14_EinbauformschiffA_no_offset.tour"

init:
  - actor: subject_vehicle
    location:
      road_id: 1
      lane_id: 3
      s_offset: 1200.0
      speed: { value: 80, unit: km/h }
  - actor: Front_vehicle
    location:
      road_id: 1
      lane_id: 3
      s_offset: 1280.0 # 80m前方
      speed: { value: 80, unit: km/h }
  - actor: Merge_vehicle
    location:
      road_id: 10
      lane_id: 1
      s_offset: 187.0 # 60m前方
      speed: { value: 80, unit: km/h }
  - actor: OverTake_vehicle1
    location:
      road_id: 1
      lane_id: 2
      s_offset: 1150.0
      speed: { value: 110, unit: km/h }
      value: 100, unit: km/h }

storyboard:
  metaevents:
    - actor: Merge_vehicle
      events:
        - name: SpeedUpEvent
          start_trigger:
            condition_type: ReachPositionCondition
            parameters:
              road_id: 10
              lane_id: 5
              s: 10.0
              tolerance: 5.0
          actions:
            - action_type: SpeedAction
              parameters:
                target_speed: { value: 70, unit: km/h }
              dynamics: { rate: 8.0, shape: linear }
        - actor: Merge_vehicle
          events:
            - name: MergeEvent
              start_trigger:
                condition_type: ReachPositionCondition
                parameters:
                  road_id: 10
                  lane_id: 5
                  s: 50.0
                  tolerance: 5.0
              actions:
                - name: MergeAction
                  action_type: LaneChangeAction
                  parameters:
                    target_lane_absolute: 3
                    distance: 3.0
                    shape: sinusoidal
  
```

リスクシナリオ生成

OpenSCENARIO



合流車はカットインする形で自車の前に合流（リスク大）



生成AI活用

```

init:
  - actor: subject_vehicle
  ..
  - actor: Merge_vehicle
    location:
      speed: { value: 80-100, unit: km/h }
  
```

合流車の速度を80→100 km/hに変更しリスクを高めた
加速シナリオ作成指示

Fig. C-5 Generating dangerous cut-in scenarios using generative AI
生成 AI による危険なカットインシナリオの作成

5) アノテーション：リスクシーンの自動分類

高速道路シナリオにおいて、合流、車線変更、カットイン、カットアウトなどの車両挙動を識別・分類するための走行行動分類フレームワークを図 C-6 に示す。各分類は、物理的な現象であるかどうかで、①軌跡ベース、②生成 AI (VLM)、③ハイブリッド（軌跡ベース+生成 AI）に分けて推定している。

本手法は、物理ベースの軌跡解析と視覚言語モデルを用いた視覚的検証を組み合わせることで、図 C-7 に示すリスクシーンの 12 分類について、複雑かつ曖昧な運転状況におけるロバストな自動分類を実現している。

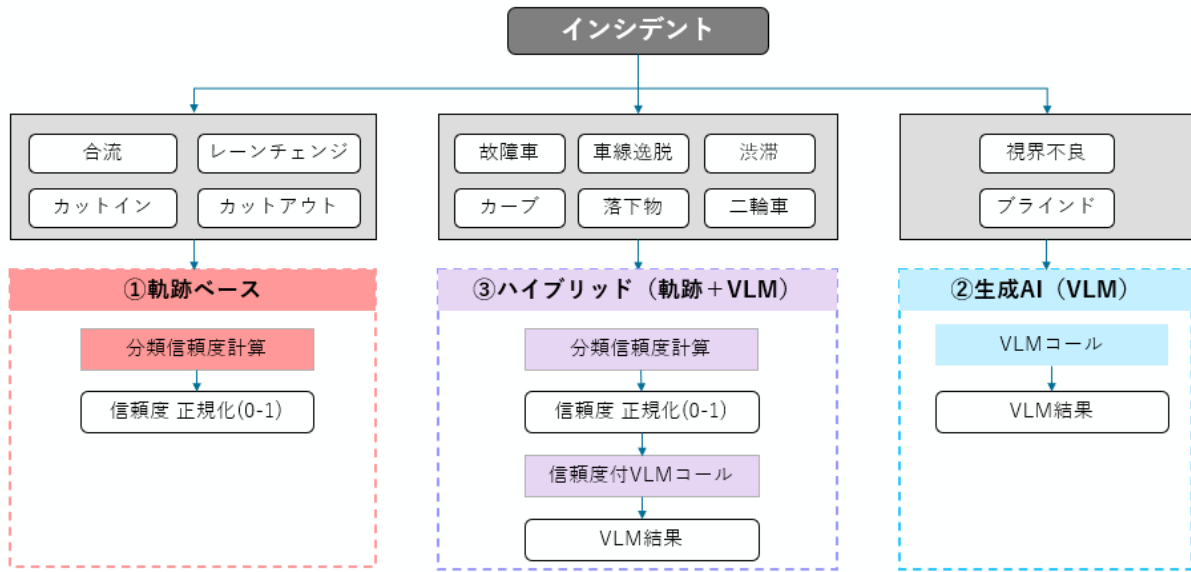


Fig. C-6 Workflow for automatically classifying source data into 12 categories
ソースデータの12分類への自動化のワークフロー

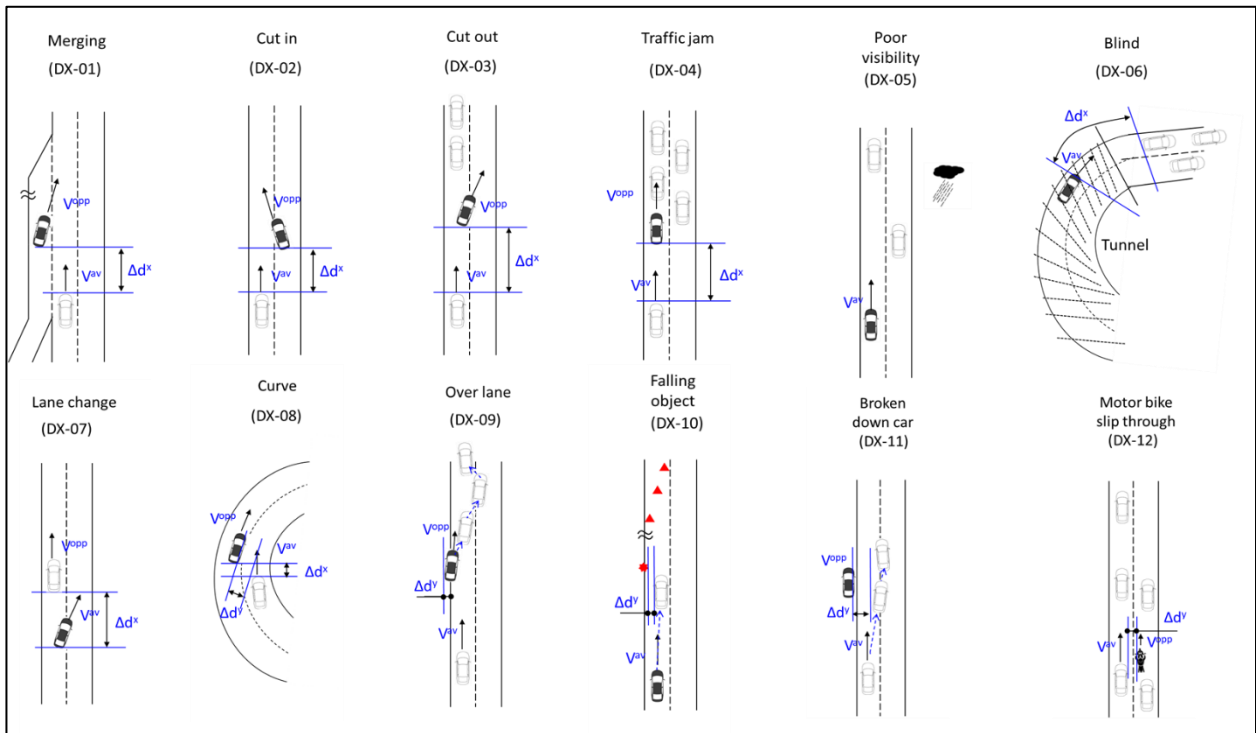


Fig. C-7 12 Categories of risk scenarios
リスクシーンの12分類

表 C-3、表 C-4、表 C-5、表 C-6 は、判定の基準テーブルを表している。
判定基準とパラメータ、閾値、重みでどの分類かを自動分類する。

Table C-3 Table of criteria for determining merging
合流の判定基準テーブル

判定基準	パラメータ	閾値	理由	重み
大きな横方向移動	横方向変位	$>1.2 * \text{LANE_WIDTH}$	高速道路へのランプ合流を、通常の車線変更と区別する。	0.45
ゆっくりとした行動	継続時間	$>2.0\text{s}$	一般的に、合流は一瞬のふらつきではなく、徐々に行われる操作である。	0.15
自車レーン近辺で完了	相対的な縦方向位置	$<30\text{m}$	車両は同じ交通の流れ（前方または後方）に収まる。	0.15
横方向移動一定	横方向の動き	TRUE	車線内での蛇行運転、振動的な動き、ノイズの多い軌跡を除外する。	0.10
保守的行動	横方向の最大速度	$<2.5\text{m/s}$	強引な割り込み（カットイン）行動と合流を区別する。	0.15

Table C-4 Table of criteria for determining lane changing
レーンチェンジの判定基準テーブル

判定基準	パラメータ	閾値	理由	重み
緩やかな横方向移動	横方向変位	$(0.25 * \text{LANE_WIDTH}) < \Delta X < (2.5 * \text{LANE_WIDTH})$	ランプ合流を伴わない、1車線（またはそれ以上）の移動を表す。	0.60
やや強引な行動	横方向最大速度	$<4.0\text{ m/s}$	ットインよりは滑らかだが、合流よりはやや積極的（攻撃的）な挙動である。	0.15
一貫した横方向移動	横方向の動き	TRUE	車線内での蛇行運転、振動的な動き、ノイズの多い軌跡を除外する。	0.10
前方車両	縦方向変位	$>4.0\text{m}$	車両が停止中ではなく、実際に走行していることを保証する。	0.15

各リスクシーンについて、ルールテーブルにより物理的な判定基準が定義・記述されており、複数の運動指標（モーションキュー）をどのように重み付けして分類確度を推定するかが示されている。これらの基準により、マヌーバ識別はルール整合性を保ちつつ、実環境における運転挙動のばらつきに対しても高いロバスト性を確保している。

本アルゴリズムは現在、テストおよび開発段階にあり、ルール定義や信頼度（確度）の閾値については、より広範なシナリオを用いた追加検証を通じて、さらなる調整・改良が可能である。現時点

での実験的検証は、実証実験で取得した DX01（合流）、DX07（レーンチェンジ）、DX02（カットイン）、DX03（カットアウト）シナリオのみに基づいている。そのため、提案手法の包括的な検証および高度化を行うために、より多様なリスクシーン種別および交通条件を含む追加データセットで学習する必要がある。

Table C-5 Table of criteria for cut-in
カットインの判定基準テーブル

判定基準	パラメータ	閾値	理由	重み
緩やかな横方向移動	横方向変位	$(0.3 * \text{LANE_WIDTH}) < \Delta X < (1.2 * \text{LANE_WIDTH})$	ランプ合流を伴わない、1車線（またはそれ以上）の移動を表す。	0.35
自車の前方で終了する	横方向最大速度	$< 2.0 \text{ m/s}$	車両は同じ交通の流れ（前方）に収まる。	0.35
強引な行動	横方向最大速度	$< 1.5 \text{ m/s}$	車線変更よりもより攻撃的（積極的）である。	0.20
一貫した横方向移動	縦方向移動	TRUE	車線内での蛇行運転、振動的な動き、ノイズの多い軌跡を除外する。	0.10

Table C-6 Table of criteria for determining cut-out
カットアウトの判定基準テーブル

判定基準	パラメータ	閾値	理由	重み
緩やかな横方向移動	横方向変位	$(0.3 * \text{LANE_WIDTH}) < \Delta x < (1.2 * \text{LANE_WIDTH})$	ランプ合流を伴わない、1車線（またはそれ以上）の移動を表す。	0.35
	相対的な縦方向位置	$< 2.0 \text{ m/s}$	車両は同じ交通の流れ（後方）から開始する。	0.20
	相対的な縦方向位置	$\Delta y(\text{start}) < \Delta y(\text{end})$	自車と相手車両の間隔広がる。	0.25
一貫した横方向移動	横方向移動	TRUE	車線内での蛇行運転、振動的な動き、ノイズの多い軌跡を除外する	0.10
強引な行動	縦方向最大速度	$< 1.5 \text{ m/s}$	車線変更よりもより攻撃的（積極的）である。	0.10

6) 生成 AI によるリスクシーン 12 分類の自動化の結果

例 1)

複数のリスクシーンが同時に発生する合流シナリオを示す。図 C-8 は、相手車両は本線高速道路へ向かって合流しており、一方で、図 C-9 では自車がそれに対応して車線変更を行っている。さらに図 C-10 では、相手車両が高速道路の交通流に進入している様子が示されている。表 C-7 の分類結果は、この解釈を裏付けるものであり、自車のレーンチェンジが信頼度 98% で検出され、相手車両の合流が信頼度 75% で検出されている。



Fig. C-8 POV merging

Fig. C-9 Ego vehicle lane chaging

Fig. C-10 POV entering main lane

Table C-7 Determination Results

判定結果

分類	信頼率
自車合流	75 %
自車レーンチェンジ	98 %
POV カットイン	64 %
POV カットアウト	49 %
悪天候	67 %

例 2)

低速車両を追い越す際のレーンチェンジシナリオを示す。図 C-11 では、自車両がトラックの後方を走行している様子が示され、図 C-12 では、トラックを追い越すために自車両が右側へレーンチェンジしている。表 C-8 の分類結果では、信頼度 98% で車線変更として正しく識別されている。一方、他車の分類については比較的低い信頼度を示しており、誤った分類の可能性があることが確認された。信頼度の分離をさらに精緻化するためには、より多様なシナリオに対する追加評価が必要であることを示している。



Fig. C-11 Following a slow track
自車が遅い先行車の後ろを走行



Fig. C-12 Ego vehicle lane chaging
自車レーンチェンジ

Table C-8 Determination Results
判定結果

分類	信頼率
POV 合流	65 %
自車レーンチェンジ	98 %
POV カットイン	64 %
POV カットアウト	49 %
悪天候	67 %

7) 生成 AI によるリスクシナリオの生成

自動運転の安全評価向けリスクシナリオ作成は、3つのアプローチで必要十分とする。生成 AI で希少ケースをカバーする。

Table C-9 Comprehensiveness and efficiency in risk scenario generation using AI and gen. AI
リスクシナリオ作成の網羅性と効率性

観点	根拠
網羅性	① 実データ (頻出) + ②交通流シミュレーション (統計的) + ③生成 AI (希少) をカバー
効率性	コスト高い実データ中心にせず、交通流シミュレーション + 生成 AI で拡張

上記の視点で、

- ① 実データでは、実際の交通環境で発生した『リアルなリスクシナリオ』を扱う → SCT<3などの条件で抽出する。
- ② シミュレーションでは、実験では得られない「統計的に起こりうるリスクシナリオ」を扱う。
→ 長時間ランダム・シミュレーションにより抽出する。
- ③ 生成AIでは、LLM等を用いて実データ・シミュレーションでは得られない『コーナーケース』や『未観測シナリオ』を創出する。

具体的なシナリオとしては、下記が考えられる。

例1：逆走車との遭遇

例2：複数エージェントの協調的悪意行動

例3：センサ不良ケース（Perception不良）

- a) センサ死角を突く車両進入、b) 極端な天候条件での視認性低下

今回、上記の例1について、実際に試してみた。

例1)

逆走車のシーンであり、自車の正面から対向車が迫ってくるシーンである。

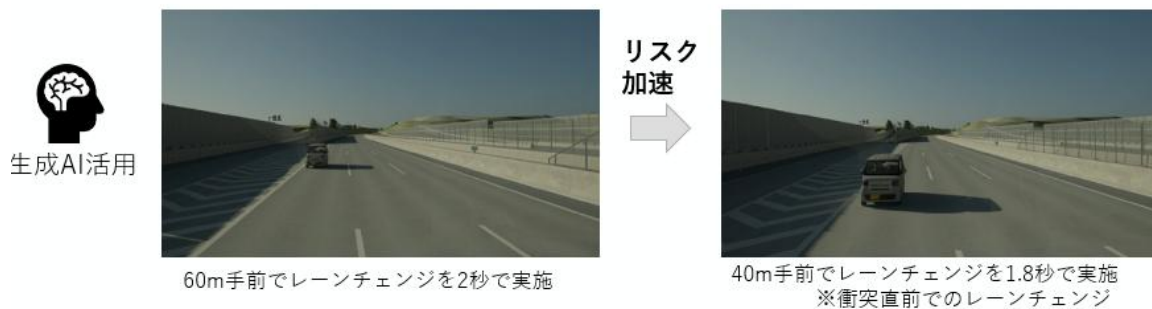


Fig. C-13 Ego vehicle lane changing
自車レーンチェンジ

8) 生成AIによるリスクシナリオの安全性評価のための生成AI活用のまとめ

今回、生成AIを用いたアノテーションおよびリスクシナリオの生成を実施した。その結果、その有効性を示唆する結果を得たものの、定性的な評価に留まっている。

今後は、定量的な評価を多角的に実施することで課題を抽出し、安全性評価に十分に活用出来るレベルまで改良していく必要がある。

D. ニアミス発生情報表示マップ

本作業は、令和5年度補正「モビリティDX促進のための無人自動運転開発・実証支援事業（データ取得事業）」で整備されたニアミス解析データを入力として、ブラウザ上で「ニアミス発生地点」とその属性（DX、道路、ロケーション、速度、リンク等）を探索できる単一HTMLを自動生成する可視化ツールを試作・検証したものである。地図描画にはLeafletを用い、地点の過密をMarkerClusterで緩和し、密度や危険度の連続的な表現はLeaflet.heatで表現する設計とした。Leafletは、地図初期化、タイル追加、ポップアップ付与（bindPopup）などの基本機能を提供している。

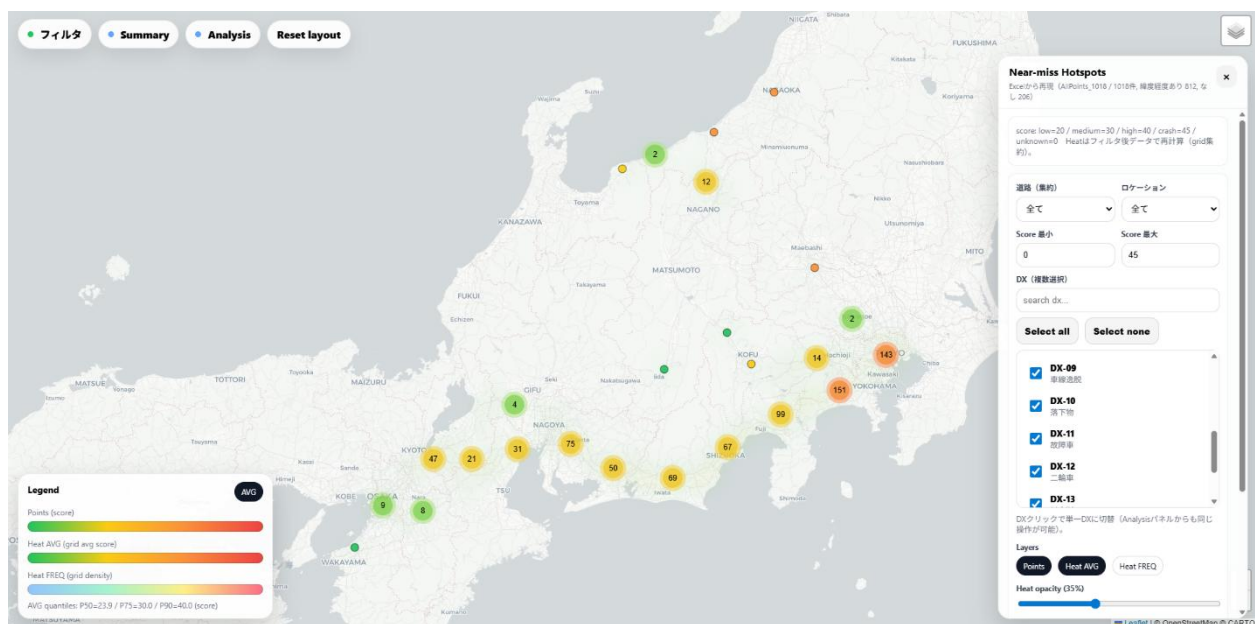


Fig. D-1 Near-miss incident display map (Fig. 3-1-3 再掲)
ニアミス発生情報表示マップ

一方で、全期間・全車両・全シーンの地点属性とルート（線分）座標列を単一HTMLへ埋め込む方式では、データ量が過大となり、読み込み（JS パース）、メモリ消費、操作遅延が支配的な問題となった。MarkerCluster と Leaflet.heat はいずれも大規模データ対策を備えている（例：MarkerCluster の chunkedLoading や、Heat の強度設計等）ものの、総データ量が閾値を越えると根本的な解決にならない。

このため、実装した地図方式は「試作としての成果」として整理し、実運用では地図（特にルート重畳）を採用見送ることとする。後続では軽量なレポート中心（集計・分布・ランキング・シーン抽出）へ移行する方針とする。

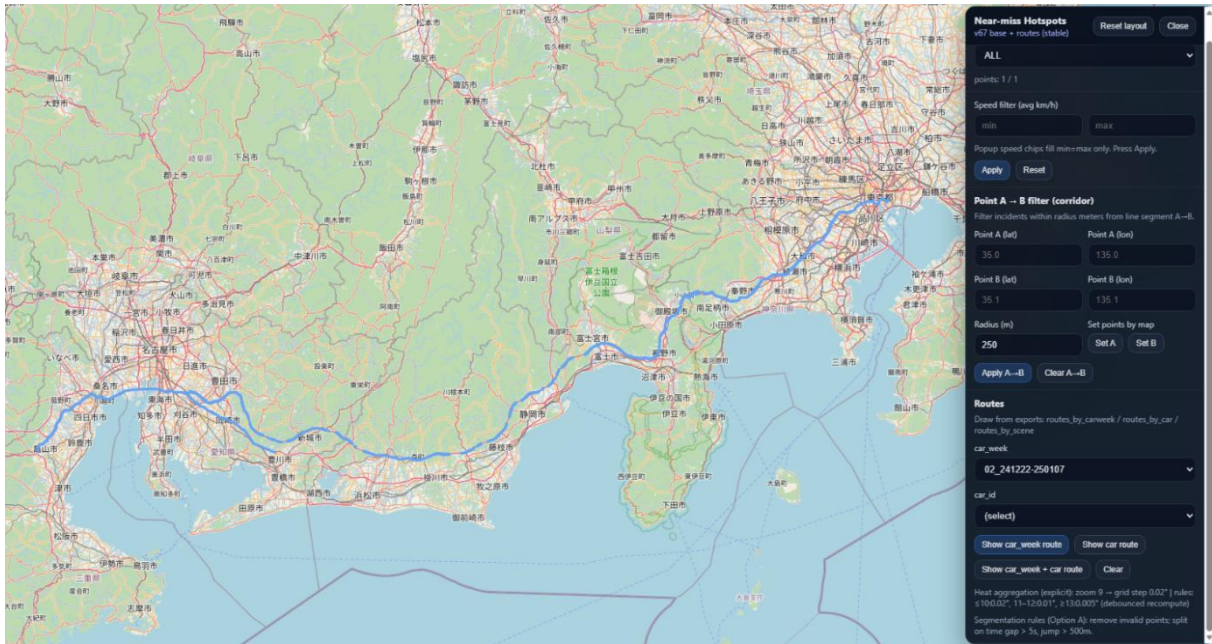


Fig. D-2 ルート見本版




Fig. D-3 Input/Output flow
入出力の流れ

Table D-1 Input table
入力テーブル

区分	形式	必須/任意	内容
ニアミス一覧	Excel(図形x-x)	必須	1行=1件のニアミス(中心緯度経度、DX分類、道路/ロケ、速度、格納先、リンク等)である
車両別ルート	GeoJSON	任意	car_id 単位の走行軌跡である(LineString/MultiLineString)
週別ルート	GeoJSON	任意	car_week 単位の走行軌跡である
シーン別スニ	GeoJSON	任意	1件ニアミスに紐づく短区間軌跡である(scene_key等で紐付ける)。
ドライブレコーダ	緯度、経度	必須	ドライブレコーダの緯度、経度を Overpass API を使用してシーンの時間と相互参照し、道路名、場所、道路タイプを取得する。

Table D-2 Overview of near-misses' list

ニアミス一覧

HDD No.	フォルダ	Scene No.	抽出ファイル名	ニアミス検出位置 (秒)	異常レベル	ニアミスレベル	DX-01	DX-02	DX-03	DX-04	DX-05	DX-06	DX-07	DX-08	DX-09	DX-10	DX-11	DX-12	
					異常レベル	ニアミスレベル	公差	カット	カット	決断	視界不良	ブレイク	レンダリング	カーブ	急峻急降	落下物	故障車	二輪車	
40[08_250124-250131]		10	2025.01.28.01.20.48.279_(front).mp4	45	●	●													
40[08_250124-250131]		11	2025.01.28.01.39.19.912_(front).mp4	31	●	●													
40[08_250124-250131]		12	2025.01.28.01.40.13.360_(front).mp4	0	●	●													

```

day,time,x,y,z,latitude,longitude,speed
2024/11/06,01:57:38.008,-0.252,-0.024,-1.220,35.36652,139.08939,85
2024/11/06,01:57:38.108,+0.040,-0.064,-0.988,35.36652,139.08939,85
2024/11/06,01:57:38.208,+0.108,-0.004,-0.948,35.36652,139.08939,85
    
```

Fig. D-4 Sample data from a drive recorder

ドライブレコーダのデータ

GeoJSON の座標参照系は WGS84 であり、十進度の経度・緯度を用いる。
 また、点座標の順序は [lon、 lat] である (GeoJSON Point の例示として明記されている)。
 Leaflet の GeoJSON ユーティリティも「GeoJSON 点の配列は (longitude、 latitude) を用いる」と記載されている。

データマッピング (代替候補と正規化規則)

列名は Mobility DX データの版により揺れが生じる可能性があるため、候補列のうち存在する列を採用する設計としている。列が存在しない場合は欠損として扱い、その欠損であること自体を Analysis/ログへ出力する方針である。

Table D-3 Data mapping table

データマッピングテーブル

目的	入力列	代替候補	内部	正規化規則
緯度	center_latitude	緯度	lat	数値化する。欠損・範囲外・0、0 は描画対象外（欠損として保持）とする。
経度	center_longitude	経度	lon	同上。GeoJSON は[lon、 lat] 順である。
DX コード	dx_code	分類	dx	文字列化する。空は Unknown として扱う。
DX 名称	dx_name	分類名	dx_label	文字列化する。
道路（集約）	route_group_main	道路	road_group	Overpass API で緯度、経度を使用してデータを取得して、文字列化する。
ロケーション	location	ロケーション	location	Overpass API で緯度、経度を使用してデータを取得して、文字列化する。
平均速度	平均速度	speed_avg	speed_avg	数値化する（km/h）。
最低速度	最低速度	speed_min	speed_min	数値化する。
最高速度	最高速度	speed_max	speed_max	数値化する。
格納先	格納先	store_path	store_path	文字列化する。scene_key 抽出に用いる。
画像データ	BOX リンク	box_link	box_link	URL として表示する。
週 ID	car_week	—	car_week	文字列化する。
車 ID	car_id	—	car_id	文字列化する。
スコア	risk_level 等	ニアミスレベル等	score	数値化（またはカテゴリ→数値写像）し、Heat 強度の入力へ利用する。 Heat は強度レンジが重要である。



Fig. D-5 Embedded data in data nodes

データノードの埋め込みデータ

Table D-4 Output table

出力テーブル

出力（生成物と既定パス）

出力物	形式	既定パス	補足
可視化 HTML	.html	実行ディレクトリ (既定)	配布容易性のため単一 HTML 完結を優先する。
補助ファイル	なし (原則)	—	—

実装機能と実装状況（実装/部分/見送り）

本節は「作ったもの」と「使えるもの」を混同しないため、実装状況を明示する。

Table D-5 Implementation status table

実装状況図テーブル

機能	内容	状態	根拠（仕様・前提）
地図表示	ブラウザで地図を表示し移動・拡大縮小できる	実装	Leaflet の基本機能である。
地点表示	ニアミス地点を点で表示する	実装	Leaflet にはマーカー・ポップアップ等が含まれる。
個点ポップアップ	点を押すと詳細を表示する	実装	bindPopup で付与しクリックで表示できる。
クラスタ表示	点が密集すると数字の塊にまとめる	実装	markercluster の基本機能である。
クラスタ要約ポップアップ	クラスタを押すと内訳（件数等）を出す	部分	clusterclick と getAllChildMarkers が提供される。
ヒートマップ	密度や強度を面で表示する	実装	heat は強度・max・setLatLngs 等を定義する。
ズーム依存集約	拡大率によりヒートの集約粒度を変える	実装	heat はズームで強度がスケールし maxZoom がある。
ルートパネル	走行ルートを線で重ねて表示する	部分 → 見送り	GeoJSON 表示は可能だが、データ量増で重くなり採用を見送った。GeoJSON は Leaflet で表示できる。
ルート分割（セグメント）	不自然な線の繋がりを避け、切れ目を保持する	部分 → 見送り	MultiLine 相当のネスト配列変換が可能である。
速度チップ	ポップアップの速度を押すとフィルタ欄へ入る	部分	popupopen イベントで開いた後に DOM へ操作を付与できる。
A→B コリドーフィルタ	A→B 線の近くの点だけ抽出する	部分	地図クリックイベント等を利用できる。
パネル移動・保存	パネル位置をドラッグ・保存し次回復元する	実装	localStorage はセッションを跨いで保存される。
マルチ CDN ロード	CDN 障害時に別 CDN へ切替える	部分	Leaflet 読込が前提であり、読込失敗を可視化する設計である。
Fatal overlay	読込/実行失敗時に理由を画面に出す	実装	失敗時の白画面回避としてツール側で実装する（外部仕様ではない）。
地図方式（全件）	全期間全件を単一 HTML で操作する	見送り	GeoJSON の精度を上げるとサイズが増えることも指摘され、巨大化が本質課題である。

処理フロー

以下は、入力 Excel から単一 HTML を生成し、ブラウザで表示するまでの処理フローである。

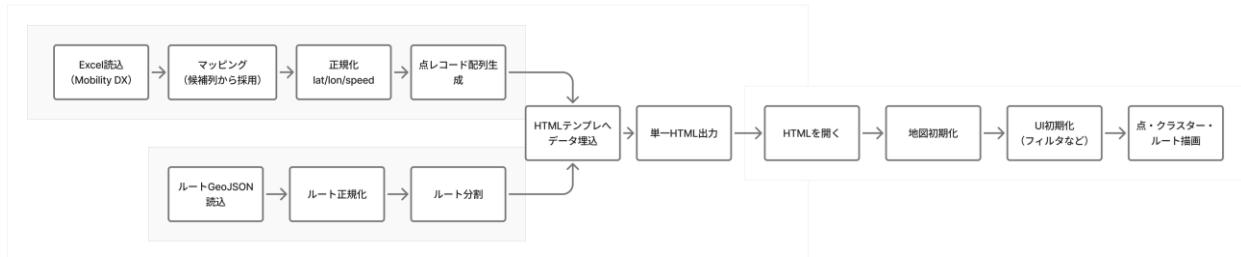


Fig. D-6 Process flow
処理フロー

実装 (短い擬似コード)

テンプレート埋め込み (f-string 衝突回避)

Python の f-string は {...} を式領域として解釈し、{{/}} でリテラル波括弧を表す。巨大 HTML に JS テンプレートリテラル等が混在すると衝突しやすいため、プレースホルダ置換を採る。

```
HTML = r"<script>const DATA = __DATA_JSON__;</script>"
html = HTML.replace("__DATA_JSON__", json_dump(data))
マルチ CDN ロード (概念)
async function loadAny(urls){
  for (const u of urls) if (await tryLoad(u)) return u;
  throw new Error("CDN load failed");
}

await loadAny([leaflet_unpkg, leaflet_jsdelivr, leaflet_cdnjs]);
await loadAny([cluster_unpkg, cluster_jsdelivr, cluster_cdnjs]);
await loadAny([heat_unpkg, heat_jsdelivr, heat_cdnjs]);
```

Leaflet は CSS/JS 読み込みが前提であり、失敗時には地図機能が起動できないため、失敗を画面化することが有効である。

クラスタ要約 (ノード情報)

MarkerCluster はクラスタクリック (clusterclick) でクラスタ境界や子マーカ配列を取得できる。

```
markers.on('clusterclick', (e)=>{
  const ms = e.layer.getAllChildMarkers();
  const n = ms.length;
  // ms のメタから DX 内訳・スコア統計を計算して表示する
});
```

```

マーカ生成とポップアップ
Leaflet は bindPopup によりクリック時にポップアップを表示できる。
const m = L.circleMarker([lat、 lon]、 style);
m.bindPopup(html); // クリックで開く
A→B コリドー距離 (点→線分の最短距離)
function distPointToSegment(p、 a、 b){
// 近似投影でメートル換算し、線分への射影で最近点を求め距離を返す
}
keep = distPointToSegment(point、 A、 B) <= radius_m;

```

Table D-6 Error reproduction and troubleshooting table
失敗再現と対処テーブル

失敗	再現方法	原因	対処
CDN 遮断	ネットワーク遮断/社内FW で CDN ブロック	Leaflet/プラグインが読めず地図初期化不能	マルチ CDN 試行 + Fatal overlay で理由提示。
必須列欠落	lat/lon 列が無い Excel を入力	描画点が 0 になる	代替列候補の確認、欠損リストを表示 (Analysis)。
データ過大	全件/全ルートを埋め込む	HTML が巨大化し操作困難	地図方式の採用見送り (後述)。

制約・前提、採用見送り理由、次の改善

GeoJSON の座標参照系は WGS84 (十進度) であり、座標の精度を過剰に上げるとデータ容量が急増し得る。

GeoJSON 点の座標順は [lon、 lat] である。

Heat は各点の第 3 要素を強度として扱い、max 未指定時は強度が 0.0-1.0 に収まるのが望ましい。

MarkerCluster は多数マーカ向けに chunkedLoading 等を提供し、Chrome で 10、000~50、000 マーカの例示もあるが、これは「点のみ」を主対象とする説明であり、巨大な属性・ルート座標を同時に抱える場合は別の制約が支配的となる。

地図方式を採用見送りした

結論として、単一 HTML に全件 (点+ルート) を埋め込む方式は、ブラウザ負荷 (読み込み・メモリ・操作遅延) が大きく、非技術者が日常的に使う前提 (軽快に探せる) を満たさないため採

用見送りとした。MarkerCluster/Heat の最適化は一定の効果があるが、RFC 7946 でも座標精度がデータ容量に影響し得ることが指摘されており、総量削減なしでは限界がある。

Table D-7 Table of improvements
次の改善テーブル

優先	改善案	狙い
高	地図を廃し、集計・分布・ランキング・シーン抽出のレポート出力へ移行	実運用での軽さを確保する。
高	地図を残す場合は「対象を限定（DX/期間/道路など）し分割出力」	1 ファイル当たりのデータ量を抑える。
中	ルートはオンデマンド表示（必要時のみロード/描画）	常時重畳を避け、操作性を確保する。
中	クラスタ要約（DX 内訳等）を安定動作へ統合	非技術者の説明・レビュー時間を短縮する。
低	ローカル同梱モード（CDN 非依存）	CDN 遮断環境の失敗率を低減する。