

表紙

【タイトル / Title】

人の思考様式を模した交通事故リスク推定モデルの構築とその検証
～多層補集合モデルによる車室内リスクの可視化～

Development and Validation of a Human-Inspired Risk Prediction Model for Traffic
Accidents:

Visualizing In-Cabin Risk Using a Multi-layered Supplemental Union Model

【著者 / Authors】

吉井 勝司 / Katsushi Yoshii

【所属 / Affiliation】

フリーランス / Freelance

【責任著者 / Corresponding Author】

吉井 勝司 / Katsushi Yoshii

Email: katushi.y.1995@gmail.com

【投稿日 / Submission Date】

2025/06/10

タイトル (Title)

人の思考様式を模した交通事故リスク推定モデルの構築とその検証
～多層補集合モデルによる車室内リスクの可視化～

Development and Validation of a Human-Inspired Risk Prediction Model for Traffic Accidents: Visualizing In-Cabin Risk Using a Multi-layered Supplemental Union Model

著者 (Authors)

吉井 勝司

所属 (Affiliation)

フリーランス

要旨 (Abstract)

本研究では、従来のブラックボックス型機械学習とは異なり、人間のリスク判断の思考様式に着想を得た新たな交通事故リスク推定モデルを構築した。本モデルは、事故発生時の車室内のリスクを対象とし、各説明変数（例：車両損壊度、乗員属性、デバイス有無）ごとに個別の回帰モデルを作成し、それらを積層的に統合する「多層補集合モデル」として設計した。

このアプローチでは、人が「大きい」「小さい」「高い」「低い」といった相対的な印象を段階的に重ねて判断を行う構造を模倣し、各要因が持つ意味の“ずれ”や“重なり”をそのままモデルに取り込んでいる。精度の追求よりも、“直感的に理解できるモデル構造”や“現場での納得感”を重視した設計であり、従来手法とは異なる価値を有している。

評価においては、±1クラスの許容やクラスごとの平均整合性など、柔軟で現実的な指標を導入し、モデルの傾向把握能力や説明性を重視した。結果として、外傷リスクの傾向を実測値とおおむね一致する形で予測可能であり、現場判断の支援や事故予防の視点提供に資することが確認された。

本研究は、交通事故が偶発的ではなく、多くの条件が積み重なって起こる「必然的構造」であるという立場に立ち、人の判断様式を再現するようなモデルの構築に挑戦したものである。

キーワード (Keywords)

交通事故リスク、 外傷予測モデル、 多層補集合モデル、 機械学習、 回帰説明変数、 リスク評価指標

Abstract

In this study, we developed a novel traffic accident risk prediction model inspired by human cognitive processes, in contrast to conventional black-box-type machine learning approaches. The proposed model targets risks within the vehicle cabin at the moment of a crash and employs a layered "multi-layered supplemental union model," which integrates individual regression models built for each explanatory variable (e.g., vehicle damage severity, occupant characteristics, presence of safety devices).

This approach mimics the structure of human reasoning, which relies on the accumulation of relative impressions such as "larger," "smaller," "higher," or "lower." The model incorporates the ambiguity and overlap inherent in each factor without reduction, emphasizing intuitive understandability and practical interpretability over pure predictive accuracy—thereby offering value distinct from traditional methods.

The evaluation introduces flexible and realistic performance metrics, including ± 1 class tolerance and average consistency across classes, to emphasize trend capture and model explainability. As a result, the model demonstrated a high level of agreement with actual injury trends, supporting its potential use in real-world decision-making and preventive safety applications.

This study is based on the premise that traffic accidents are not random, but rather occur as a consequence of the accumulation of multiple factors—a "deterministic structure." It represents an effort to construct a model that reproduces human-like decision-making patterns.

Keywords

Traffic Accident Risk, Injury Prediction Model, Multi-layered Supplemental Union Model, Machine Learning, Regression-based Features, Risk Evaluation Metrics

1. はじめに

本研究は、交通事故における「見落とされがちな潜在的リスク」の可視化と、リスクの構造理解を目的とし、実データに基づいた機械学習モデルの構築を試みたものである。交通事故における負傷や死亡リスクは、事故状況、デバイスの有無、個人の特性など多様な要因が複雑に関係しており、その全体像を一つの統計モデルで捉えることは難しい。特に、現実の事故データにはばらつきや偏りが存在し、従来型のモデルでは潜在的リスクまで正確に予測することは困難である。

そこで本研究では、人がリスクを直感的に判断するプロセスに着目し、個別の回帰モデルを多数構築した上で、それらを積層的に組み合わせることで、統合的かつ柔軟な「多層補集合モデル」を提案する。

各回帰モデルにおける決定係数 (R^2) は必ずしも高くはない (0.1~0.3 程度) もの、それぞれは異なる視点でリスクの傾向を捉えている。これは、個々のモデルが説明しきれなかった残差の中に、他の視点から見た新たな意味や要因が含まれている可能性を示している。したがって、それらのモデルを積層的に組み合わせることにより、交通事故リスクという複雑な社会現象の構造を多面的に捉えることが可能となる。

本研究で採用したモデリングアプローチは、単一の高精度モデルによる説明を目指すのではなく、人間が複数の判断軸をもとにリスクを直感的に認識する過程に着想を得たものである。それぞれの小さなモデル (回帰モデル) を“補完的に”重ね合わせることで、従来では見落とされがちだった潜在的なリスクの構造を可視化するリスク推定モデルと、その新たな手法を提案する。

機械学習を用いた交通事故リスク推定モデルは、回帰・分類手法を応用した様々な研究が存在する (例: [3][4])。しかし、これら従来手法の多くは説明変数を一括で処理するアプローチであり、人の判断のような構造的な思考様式や相対的評価の積層性を反映するものではなかった。本研究では、人間の推論に近い形で各説明変数の個別影響を段階的に評価し、それらを統合してリスクを推定する“多層補集合モデル”を提案する点に新規性がある。

本研究は、筆者らが以前に報告したリスク推定手法[6]を基盤とし、説明変数の構造的活用と評価指標の多様化に焦点を当てた発展的研究である。

2. データとリスク構造の捉え方

2.1 リスクの多因子構造と前提仮説

本研究では、米国運輸省道路交通安全局(NHTSA)の Crash Investigation Sampling System

(CISS)データ (2017-2022 年) に記録された実際の交通事故データを用いて、リスク推定モデルの構築を行った。

CISS は、米国内で発生した交通事故の中から代表性のあるサンプルを抽出し、詳細な現場調査と医療記録に基づいて構築された高信頼性の事故データベースである [1]。

対象とするデータには、事故状況、負傷者の個別情報、デバイス装着状況などが含まれており、25 種類の説明変数と 14 種類の目的変数を抽出して分析に用いた。目的変数には、MAIS (最大傷害度) や ISS (傷害重症度スコア) といった外傷指標に加え、部位別 AIS、負傷数、致死リスクなど、事故による影響を多面的に捉える指標群を含む。一方、説明変数は以下の 3 つに分類される

(※脚注または本文中に [2] 国立病院機構災害医療センター, 「AIS・ISS・MAIS の用語解説」, 2020 年版 災害医療研修資料 を参照文献として明記)

- 事故特性 (損壊度、衝突方向、衝突回数など)
- デバイス・着座位置 (シートベルト・エアバッグの有無、座席位置など)
- 個体特性 (年齢、性別、身長、体重、BMI、既往歴数など)

本研究では、「事故は偶然ではなく、複数の要因が重なって発生する“必然”である」という前提に立ち、リスクを構成する各因子をできる限り定量的に表現・評価することを重視した。ここで、リスクの基礎的な構造は以下のような単純な関数関係で表されると仮定する

$$\text{リスク} = f(\text{損壊度}, \text{年齢}, \text{シートベルトなど}) + e$$

ここで e は、未観測要因や想定外の因子、その他の複雑な影響をまとめた不定項である。この残差項を可能な限り減らし、直感的に納得可能な構造的予測モデルを構築することが、本研究の中心的な課題である。

従来の機械学習手法では、こうした多数のパラメータ (25 種類) を一括でモデルに入力し、非線形関係を統計的に再現しようとするケースが一般的である。しかし、人間はこれらの全てを一度に処理して判断しているわけではない。

むしろ、「損壊度」「年齢」「デバイスの有無」など、限られた視点を重ね合わせながら直感的なリスク判断を行っている。このような“段階的・積層的判断”に対して、従来の一括処理型モデルは直感から乖離し、いわゆる“ブラックボックス”として映りやすい。

本研究では、人間の思考構造に着想を得て、「説明変数と目的変数の関係を個別に定式化した小さな回帰モデル」を構築し、それらを積層的に統合するモデル手法を採用する。

2.2 説明変数・目的変数の構成と分布傾向

本研究で用いる目的変数 (表 2-1) および説明変数 (表 2-2~2-5) の構成と分布傾向を以下に示す。説明変数については性質に応じて、連続値/カテゴリ型、個人特性/事故要因/

デバイス関連のように分類・整理している。

目的関数	データ数	平均	標準偏差	最小	最大
MAIS	9872	1.01	1.07	0	6
ISS	9889	12.34	8.56	0	75
death	9889	0.03	0.18	0	1
Nymber of AIS	9889	1.45	0.89	0	6
AIS Head	9635	0.87	1.24	0	6
AIS Face	9888	0.45	0.89	0	5
AIS Neck	9881	0.32	0.68	0	4
AIS Thorax	9865	1.02	1.38	0	5
AIS Abdomen	9872	0.57	1.11	0	5
AIS Spine	9872	0.48	1.05	0	5
AIS UpperEx	9874	0.39	0.97	0	5
AIS LowerEx	9885	0.74	1.16	0	5
AIS Unspecified	9889	0.39	0.97	0	5
AIS Other	9869	0.61	1.12	0	5

▶ 表 2.1：目的変数一覧（MAIS, ISS など 14 指標）

説明変数	平均	標準偏差	最小	最大
年齢 (Age)	40.87	19.15	2	100
身長 (Height)	169.97	11.02	63	213
体重 (Weight)	81.89	22.48	13	222
(BMI) ※計算値	28.23	6.94	10.1	90.7
車の損傷度 (Damage_Level)	1.52	0.7	1	3
既往歴の数 (Number_of_Medical_History)	0.6	1	0	7
モデルイヤー (MODELYR)	2014.6	5.2	2000	2022

▶ 表 2-2：説明変数一覧（連続値：個人特性・事故要因）

説明変数	分類	件数
性別 (Gender)	1:男性	4722
	2:女性	5041
	3:妊婦	109
既往歴の有無 (Medical_History)	0:なし	6332
	1:あり	3540
血液凝固障害 (MH_IMPAIREDCOAG)	0:なし	9598
	1:あり	274
妊娠 (MH_PREGNANT)	0:なし	9799
	1:あり	73
筋骨格障害 (MH_IMPLANTFUS)	0:なし	9187
	1:あり	685
心臓血管疾患 (MH_CARDIOCOND)	0:なし	9385
	1:あり	487
骨粗鬆症 (MH_OSTEOCOND)	0:なし	9664
	1:あり	208
変性脊椎疾患 (MH_SPINEDEGEN)	0:なし	8612
	1:あり	1260
肥満 (MH_OBESITY)	0:なし	7521
	1:あり	2351
その他の疾患 (MH_COMORBOTH)	0:なし	9319
	1:あり	553

▶ 表 2-3：説明変数一覧（カテゴリー型：個人特性）

MAIS カテゴリーデータ (事故要因)		
説明変数	分類	件数
衝突の種類 (Collision_Type)	1:単独	2666
	2:同一方向	2046
	3:反対方向	690
	4:車線変更・方向転換	2357
	5:交差点	1579
	6:その他	534
イベントタイプ (Event_Type)	1:シングル衝突	5711
	2:多重衝突	4161
衝突の方向(Direction_1st)	0:水平以外	339
	1:1時方向	1087
	2:2時方向	656
	3:3時方向	235
	4:4時方向	55
	5:5時方向	88
	6:6時方向	852
	7:7時方向	111
	8:8時方向	87
	9:9時方向	332
	10:10時方向	615
	11:11時方向	1267
	12:12時方向	4148

▶ 表 2-4：説明変数一覧（カテゴリー型：事故状況要因）

MAIS カテゴリーデータ (安全デバイス)		
説明変数	分類	件数
シートベルト (SB)	0:着用	9094
	1:非着用	778
エアバッグ (AB)	0:展開	6251
	1:非展開	3621
座席 (Seat)	11:前席左	8174
	13:前席右	1671
	21:2列目左	15
	23:2列目右	9
	22:2列目中央	2
	33:3列目右	1
シートスライド (Seat_Slide)	2:最前列	570
	3:前から2番目	1821
	4:中央	2724
	5:後ろから2番目	2374
	6:最後列	2383

▶ 表 2-5：説明変数一覧（カテゴリー型：安全デバイス関連）

3. モデル構築の考え方

交通事故リスクを予測する際、従来の機械学習モデルでは、事故状況や個人特性、安全デバイスの有無など多数の説明変数を一括で入力し、複雑な非線形関係を統計的に学習することが一般的である。

しかし、こうしたモデルは「すべての情報を同時に処理する」という点で、人間の思考様式とは異なる。人は、「損壊度」「年齢」「デバイスの有無」など、特定の要素ごとに段階的・積層的に判断を下す傾向があり、直感的な納得感を得る上でもこの思考構造は重要である。

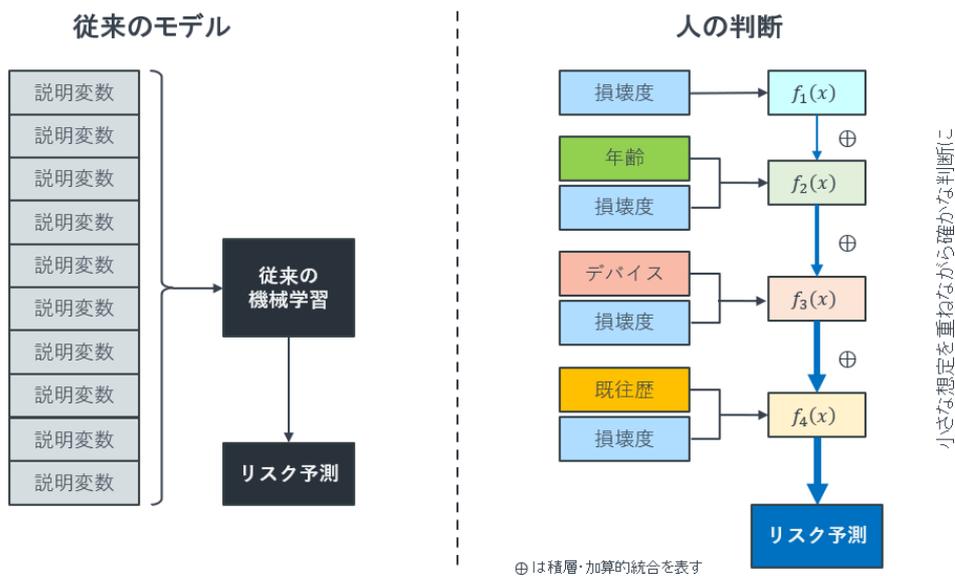
本研究では、このような人の判断プロセスを模倣し、14 種類の目的変数それぞれに対し

て、25 個の説明変数を用いた個別回帰モデル（小モデル）を構築した。そして、各小モデルの出力値を“回帰説明変数”として再定義し、それらを多層的に統合することで最終的なリスク推定モデルを構成する。このような構造を「多層補集合モデル（Multi-layered Complementary Union Model）」と呼び、従来の一括処理モデルとは異なる新たなアプローチを提案する。

3.1 人の推定プロセスに着想を得たモデル構築

図 3.1 に示すように、従来の機械学習モデルは多数の変数を一括で処理し、ブラックボックス的な出力を生成する。一方で、人は「損壊度」「年齢」「シートベルト」など、意味的に区切られた視点ごとに小さな判断を重ね、最終的に総合的な判断へと至る傾向がある。

本研究ではこの思考様式に着目し、各説明変数に対して独立した回帰モデル $f_1(x)$, $f_2(x)$, ... を構築し、それぞれから得られた予測値を「回帰説明変数」として再定義した。このアプローチにより、個別要因の寄与を明示的に可視化しつつ、人間の判断過程に近いモデル構築を実現する。



▶ 図 3-1：従来モデルと人の判断の構造比較

3.2 回帰説明変数の導出

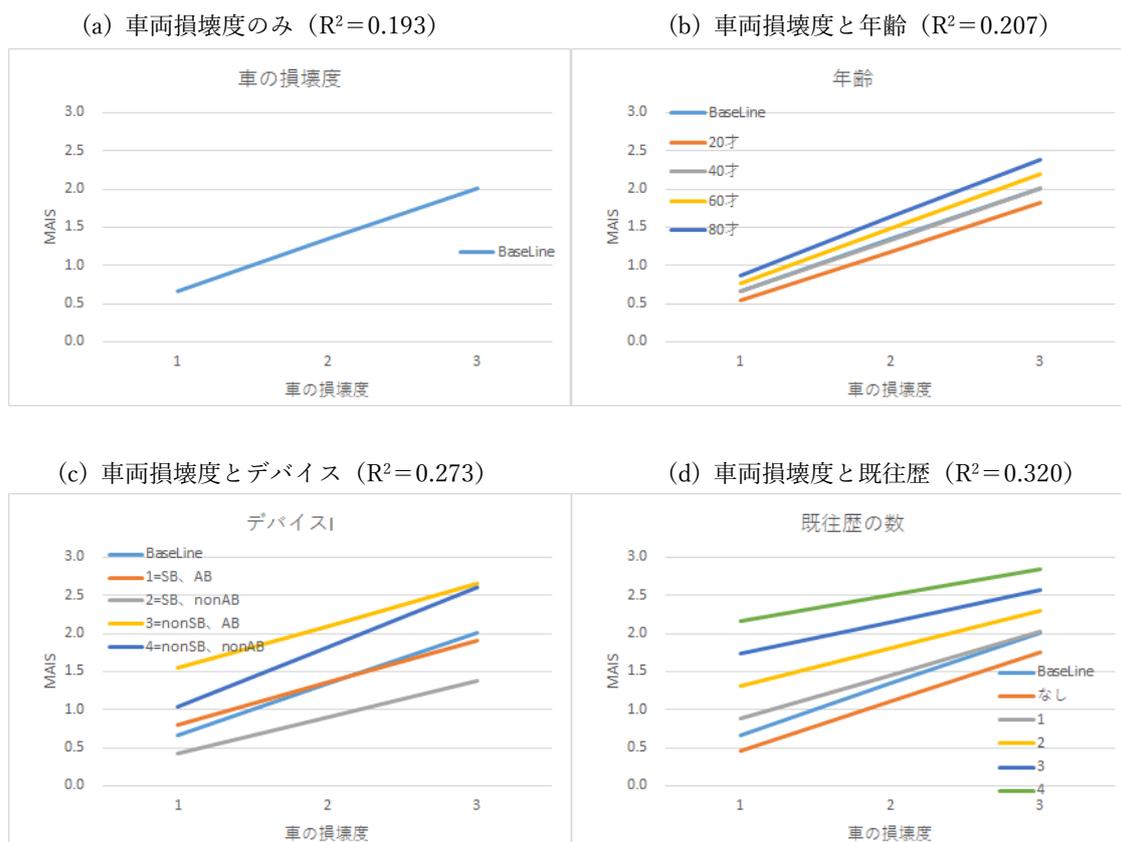
各説明変数 X_i に対して、以下のような回帰モデルを構築する。

$$\text{回帰説明変数} = \beta_0 + \beta_1 \cdot \text{損壊度} + \beta_2 \cdot X_i + \beta_3 \cdot (\text{損壊度} \cdot X_i)$$

このとき、目的変数は MAIS などの外傷指標であり、出力される回帰説明変数は、元の

X_i とは異なり、目的変数と同一スケール（例：0～6）に変換される。これにより、連続値・カテゴリ型を問わず、全ての説明変数が共通のスケールに統一され、学習効率と比較可読性が高まる。

また、各回帰モデルの決定係数（ R^2 ）は必ずしも高くなく（多くが0.1～0.3程度）、「弱い予測子」に過ぎないが、これらを積層的に統合することで、多面的なリスク構造の再現が可能となる。



▶ 図 3.2：回帰モデルによるリスク傾向の可視化例

これらの図からも分かるように、損傷度が高まるにつれ MAIS が増加する傾向が一貫して見られる。また、各変数（年齢・デバイス・既往歴）ごとのモデルは、それぞれ異なる残差構造を補完しており、複数モデルの積層によってリスク全体の輪郭が浮かび上がる。

3.3 多層補集合モデルの構成

このようにして得られた回帰説明変数群を統合し、最終的なリスク推定モデルを構成する。統合の考え方は「補集合の積」に基づいており、以下のように表現される。

$$\text{リスク} = f(\text{損壊度}) \times \prod_{i=1}^n (1 + \beta_i \cdot \text{回帰説明変数}_i) + \sum_{j=1}^m \gamma_j \cdot X \text{回帰説明変数}_j$$

この式は、次の2つの構造を併せ持つ：

- **補集合的構造 (積)**：多数の要因が同時に成り立つとき、リスクが一気に上昇する (相互作用的要素)
- **加算的構造 (和)**：特定の要因が単独でもリスクに寄与する (個別影響的要素)

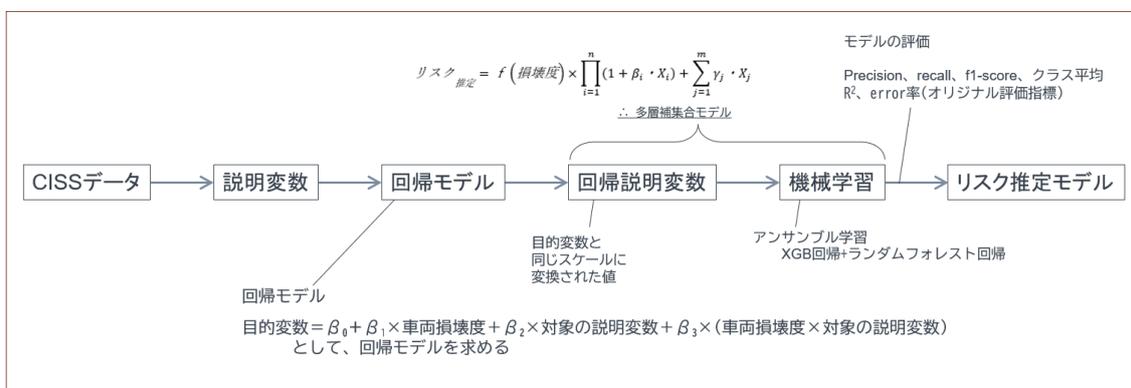
また、モデル全体の説明力を表す指標として、回帰モデル群の決定係数 R^2 を用いた以下の式により、補完的な積層寄与の総合効果を表現できる

$$R_{total}^2 = 1 - \prod_{i=1}^n (1 - R_i^2)$$

この式は、各小モデルの R^2 が小さくとも、全体としては補完的に積み上がり、実用的な予測力を獲得できることを意味している。

4. モデル構築手法

本章では、実際のリスク推定モデルを構築するための手順を3段階に分けて説明する。本研究では、各目的変数に対して25個の説明変数を用いた回帰モデルを個別に構築し、それらを基にした多層的なリスク推定モデルを作成した。全体の流れは図4.1に示す通りである。



▶ 図4-1：学習とリスク推定の全体構造 (多層補集合モデル)

4.1 回帰モデルの構築と変数変換

まず、各説明変数 X_i (年齢、BMI、既往歴、SBの有無など) と目的変数 (MAIS など) との関係を示すため、以下の形式の単回帰モデルを構築した

$$\hat{y}_i = \beta_0 + \beta_1 \cdot \text{損壊度} + \beta_2 \cdot X_i + \beta_3 \cdot (\text{損壊度} \cdot X_i)$$

ここで、 \hat{y}_i は目的変数に対する回帰予測値であり、“回帰説明変数”として扱われる。この変換により、元のスケールが異なる説明変数がすべて目的変数と同一スケールの連続値に統一され、学習の安定性と変数解釈の一貫性が高まる。

4.2 多層補集合モデルへの統合

構築した回帰説明変数 (25 個) は、それぞれの目的変数ごとに機械学習モデルの入力特徴量 (features) として利用された。

本研究では、以下の2つのアンサンブル学習手法を用いてリスク推定モデルを構築した

- ランダムフォレスト回帰 (Random Forest Regressor)
→ 高リスク事象の予測においてロバスト性が高い
- XGBoost 回帰 (XGB Regressor)
→ 小さな誤差の最少化や低リスク層の判別に有利

両者を併用することで、予測性能の安定性と分布全体への対応力を高めることを目指した。

4.3 多層補集合モデルの統合構造

回帰説明変数を統合したリスク推定モデルは、以下のような構造で表される。

$$\text{リスク}_{\text{推定}} = f(\text{損壊度}) \times \prod_{i=1}^n (1 + \beta_i \cdot X_i) + \sum_{j=1}^m \gamma_j \cdot X_j$$

- X_i : 積層により効く回帰説明変数
- X_j : 加算的に効く補助変数

この式は、人が多様な根拠に基づき段階的・積層的に判断を下す構造を模倣したものであり、ブラックボックス的手法では得られない“可視性と説明性”を担保している。

4.4 不均衡データへの対応

本研究では、目的変数（例：MAIS など）の分布において、高リスククラスに該当するサンプル数が少ないという偏りが確認された。これに対し、機械学習モデルの学習過程においては、アンダーサンプリングおよび重み付けによる補正を実施した。一方で、オーバーサンプリングについては、入力変数として回帰説明変数（連続値変換済みの特徴量）を用いていることから、人工的なサンプル増加が意味を持ちにくいと判断し、採用していない。

これらの補正処理は、本モデルの理論的骨格である「多層補集合モデル」の構造には依存しない実装上の工夫であり、予測性能の安定化を目的として導入されたものである。

5. モデル評価とその解釈

5.1 評価の前提と限界

交通事故のリスクを予測するにあたって、本研究では「事故は偶然ではなく、多くの条件が重なって発生する必然である」との立場をとる。しかしながら、実際の事故データにはばらつきや記録上の制限があり、説明変数によってリスクが完全に説明されるわけではない。

したがって、いかに精度の高いモデルを構築しても、ある程度の残差（予測と実測のずれ）は不可避である。

また、データセット自体も“正解”ではない。事故記録は、記録者の判断や現場状況に左右される部分もあり、ばらつきの一因ともなる。これらを考慮せず、単一の評価指標（例えば accuracy や F1-score）のみに依拠すると、モデル本来の意義や活用可能性が正しく評価されない可能性がある。

なお、本研究で採用した±1クラス許容による評価方法や、クラスごとの平均誤差を重視する考え方は、統計学やリスク予測に関する既存研究[5]に基づいており、実データの不確実性を考慮した現実的な評価手法として位置づけられる。

5.2 多軸評価の必要性と工夫

本研究では、従来の一元的な評価指標に依存せず、リスク予測における“曖昧さ”や“実用感覚”を考慮した多面的な評価を導入した。具体的には、以下の3点を評価の柱とした。

(1) ±1クラス許容による分類評価

MAIS (0~6) などの段階的指標に対して、±1クラス以内のずれを「妥当」とみなす評価法である。これは、医療現場や行政判断においても±1の判断幅が実用的とされることに基づく。本研究では、これを Recall と Precision に適用し、以下の4区分で評価した：

- 正しく予測 (予測=実測)
- 小さく予測 (1 クラス小さい)
- 大きく予測 (1 クラス大きい)
- error (2 クラス以上のずれ)

(2) クラス別平均予測値の一致度

各実測クラスにおいて、モデルが出力した予測値の平均が実測値に近いかを評価した。これは、個々の誤差に敏感な指標とは異なり、モデルの構造的な妥当性（予測の重心が合っているか）を捉える指標である。

(3) クラス別の精度評価とバランス

交通事故データにおける重大な課題は、低リスククラス（MAIS=0,1 など）が大多数を占め、高リスク（MAIS=5,6 など）は極端に少数である点である。この不均衡性に対応するため、クラスごとに Precision・Recall・F1-score を評価し、特に高リスククラスでの過小評価（False Negative）を重視して評価を行った。

以下に MAIS のリスク推定モデルの検証結果を記す。

		予測							計
		0	1	2	3	4	5	6	
実測	0	2790	644	43	5	0	0	0	3482
	1	207	3094	880	36	1	0	0	4218
	2	6	204	910	56	2	0	0	1178
	3	1	23	173	496	3	1	0	697
	4	0	2	14	51	95	0	0	162
	5	0	1	9	9	54	23	0	96
	6	0	0	2	4	1	26	3	36
計		3004	3968	2031	657	156	50	3	9869

▶ 表 5-1：MAIS の混合行列

recall	実測	予測							小さく予測	正しく予測	大きく予測	error
		0	1	2	3	4	5	6				
	0	80%	18%	1%	0%	0%	0%	0%	80%	18%	1%	
	1	5%	73%	21%	1%	0%	0%	0%	73%	21%	1%	
	2	1%	17%	77%	5%	0%	0%	0%	77%	5%	1%	
	3	0%	3%	25%	71%	0%	0%	0%	71%	0%	4%	
	4	0%	1%	9%	31%	59%	0%	0%	59%	0%	10%	
	5	0%	1%	9%	9%	56%	24%	0%	24%	0%	20%	
	6	0%	0%	6%	11%	3%	72%	8%	8%	0%	19%	
									75%	16%	2%	

▶ 表 5-2：MAIS クラス別 Recall の評価

precision	予測	0 1 2 3 4 5 6							
		実測	0	93%	16%	2%	1%	0%	0%
	1	7%	78%	43%	5%	1%	0%	0%	
	2	0%	5%	45%	9%	1%	0%	0%	
	3	0%	1%	9%	75%	2%	2%	0%	
	4	0%	0%	1%	8%	61%	0%	0%	
	5	0%	0%	0%	1%	35%	46%	0%	
	6	0%	0%	0%	1%	1%	52%	100%	
	実は小さい		16%	43%	9%	2%	0%	0%	16%
	正しい	93%	78%	45%	75%	61%	46%	100%	75%
	実は大きい	7%	5%	9%	8%	35%	52%		7%
	error	0%	1%	3%	8%	3%	2%	0%	2%

▶ 表 5-3 : MAIS クラス別 Precision 評価

トレーニングデータを含む全データ					
MAIS	precision	recall	f1-score	support	予測平均
0	0.93	0.80	0.86	3482	0.21
1	0.78	0.73	0.76	4218	1.18
2	0.45	0.77	0.57	1178	1.87
3	0.75	0.71	0.73	697	2.69
4	0.61	0.59	0.60	162	3.48
5	0.46	0.24	0.32	96	3.93
6	1.00	0.08	0.15	36	4.67
計				9869	
accuracy	0.75				

▶ 表 5-4 : MAIS Recall、Precision、F1-score、クラス別平均の総括

5.3 数値評価結果の概観

たとえば、MAIS モデルの予測においては、全体の accuracy は 0.75、Recall (再現率) の誤分類率 (error) は、最も誤りの大きいクラスで 20%程度にとどまり、Precision (適合率) の誤差も最大で約 8%であり、実用上十分な予測能力を示した。クラス別では、低リスククラス (MAIS=0,1) で高い精度を示しつつ、中～高リスククラスでも、平均的に予測傾向の一致が見られた。

他の目的変数 (ISS, AIS 各部位, 致死率など) においても、精度は目的によってばらつきがあるものの、実データとの整合性は概ね良好であり、特に部位別 AIS においては、全体的な構造把握が可能であることが確認された。

以下に、14 種類のモデルにおける総評を記す。

外傷リスク推定モデル	accuracy	R ²	判定
MAIS	0.75	0.77	◎
ISS	0.82	0.61	◎
death	0.99	0.65	◎
Number_of_AIS	0.88	0.65	◎
AIS_Head	0.74	0.48	○
AIS_Face	0.92	0.57	○
AIS_Neck	0.95	0.00	×
AIS_Thorax	0.74	0.61	◎
AIS_Abdomen	0.85	0.47	○
AIS_Spine	0.83	0.48	○
AIS_UpperEx	0.83	0.61	◎
AIS_LowerEx	0.79	0.61	◎
AIS_Unspecified	0.98	0.00	×
AIS_Other	0.98	0.03	×

▶ 表 5-5：14 種類のモデルの総評

5.4 ケーススタディによる確認

表 5.6 に、3 件の具体的な事故データに対してモデルを適用し、実測値と予測値の比較を行った。その結果、全体的な外傷傾向（重症度、部位、負傷数）はおおむね一致しており、現場でのリスク判断を補完できるレベルの信頼性が確認された。

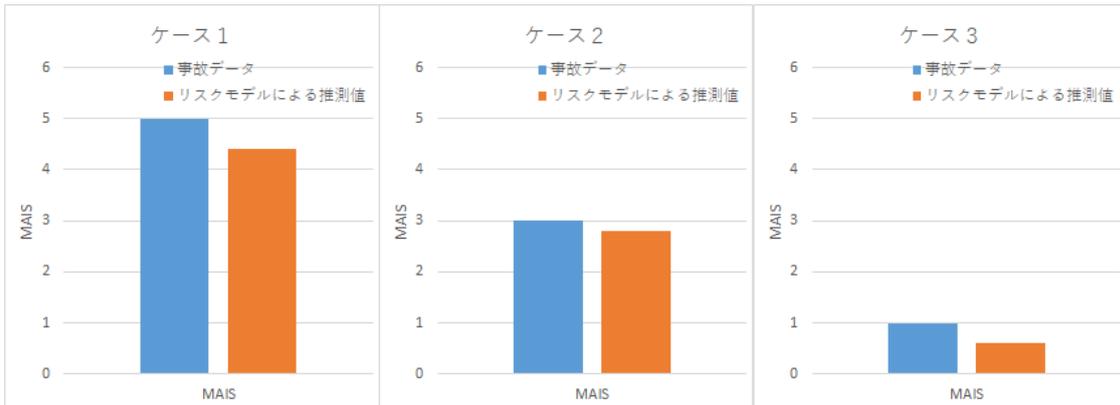
これは、単なる精度評価を超えて、「モデルが現実の感覚とどれだけ一致しているか」という点において有効な検証であり、モデルの現場適用可能性を示唆する重要な根拠となる。

		ケース 1	ケース 2	ケース 3				
事故のシナリオシミュレーション (説明変数)	MODELYR	2015	2016	2017				
	視覚度	3	2	1				
	衝突の種類	単独	単独	単独				
	衝突回数	2	2	2				
	衝突方向	12時方向	12時方向	12時方向				
	年齢	23	54	56				
	身長	180	180	201				
	体重	83	84	84				
	BMI	25.6	25.9	20.8				
	性別	男性	男性	男性				
	シートベルト	着用	着用	着用				
	エアバッグ	作動	作動	作動				
	座席位置	前左	前左	前左				
	シートスライド	中央	やや後ろ	やや後ろ				
	既往歴の数	0	2	0				
	既往歴	0	あり	0				
	血液凝固障害	0	0	0				
	妊娠	0	0	0				
	筋骨格	0	0	0				
	心臓血管	0	0	0				
	骨粗鬆症	0	1	0				
変性脊椎	0	1	0					
肥満	0	0	0					
その他	0	0	0					
	モデル精度	事故データ	推定値	事故データ	推定値	事故データ	推定値	
目的変数 (リスク推定モデル)	MAIS	○	5	4.4	3	2.8	1	0.6
	ISS	○	38	33.2	17	16.6	1	2.3
	負傷/死亡	○	0	0	0	0	0	0
	傷害の数	○	14	13.1	16	12.8	2	2.3
	AIS_Head	○	5	4.2	1	0.9	1	0.2
	AIS_Face	○	1	1	1	0.8	0	0
	AIS_Neck	×	0	1	0	0.2	0	0.1
	AIS_Thorax	○	2	1.9	3	1.9	0	0
	AIS_Abdomen	○	2	1.5	0	0.9	1	0.7
	AIS_Spine	○	0	0.6	3	2.5	0	0
	AIS_UpperEx	○	1	1.1	2	1.8	0	0.3
	AIS_LowerEx	○	3	2.6	0	0.4	0	0
	AIS_Unspecified	×	0	0	0	0	0	0
	AIS_Other	×	0	0	0	0.1	0	0

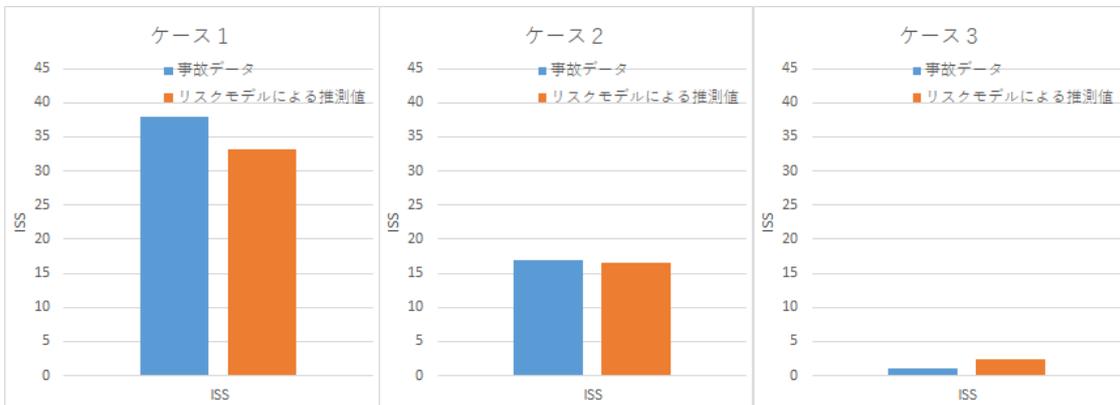
▶ 表 5-6：3つの代表的ケースにおける14種類のリスク推定結果の一覧。上段は入力条件、下段は実測値と本モデルによる推定値を比較。

図 5-7a～5-7c に、3つの代表的な事故ケースに対して MAIS、ISS、負傷数それぞれの予測結果を実測値と比較する形で示した。各図において、数値の一致そのものよりも、リスク傾向や大小関係の再現に注目しており、本モデルの出力が現実の直感と整合することが確認された。

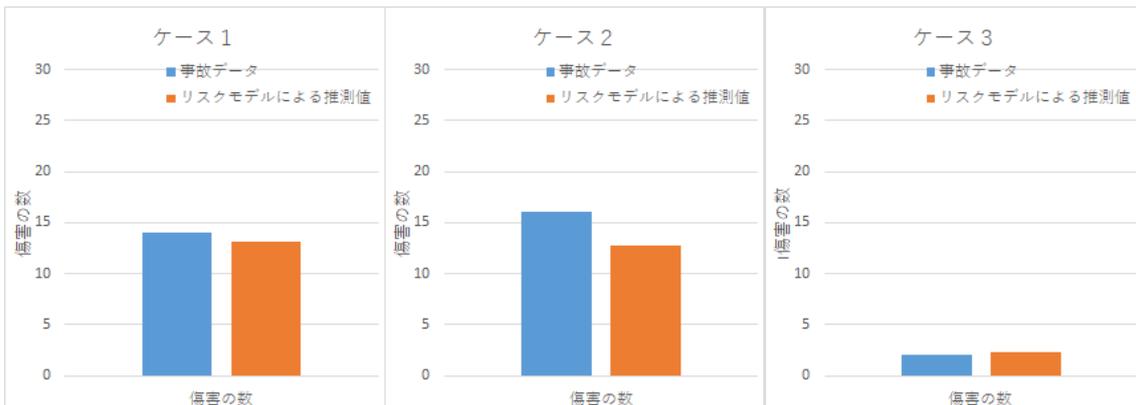
また、図 5-8a～5-8c には、同じく各ケースに対して部位別 AIS の予測精度を視覚化しており、損傷の集中部位の予測傾向が再現されている点も注目に値する。



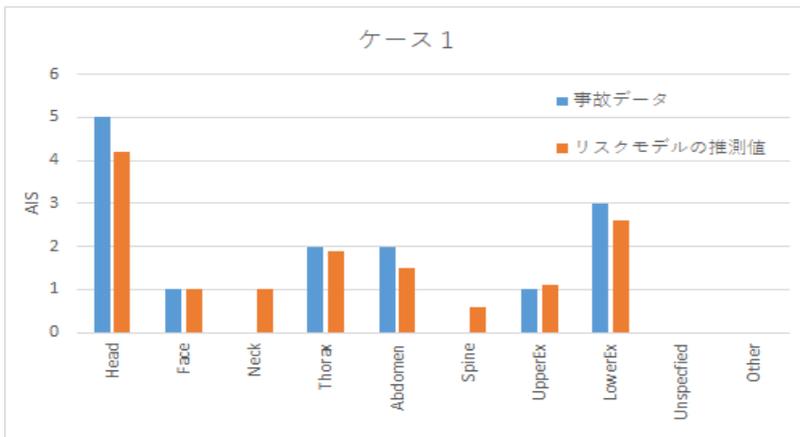
▶ 図 5-7a：各ケースにおける MAIS の実測値と予測値



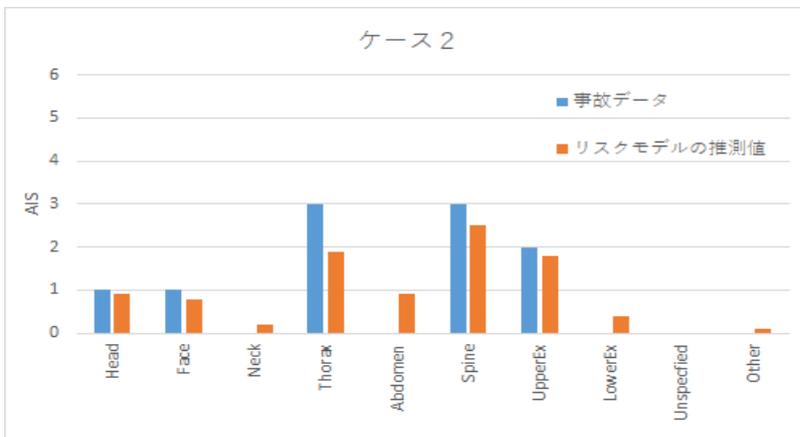
▶ 図 5-7c：各ケースにおける ISS の実測値と予測値



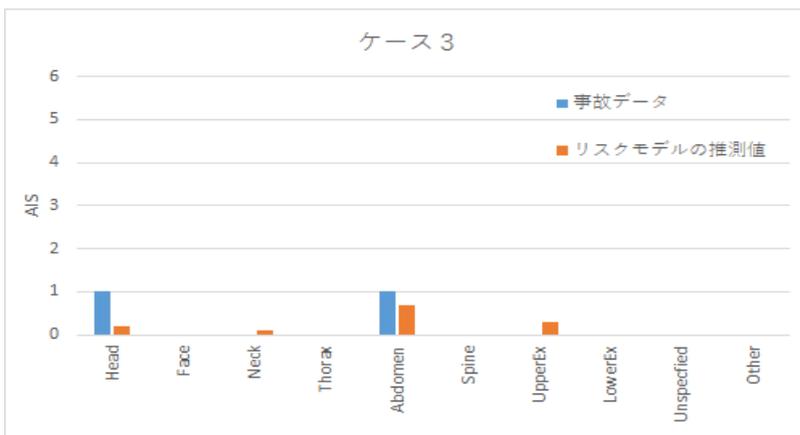
▶ 図 5-7c：各ケースにおける傷害の数の実測値と予測値



▶ 図 5-8a：部位別 AIS の実測値と予測値 ケース 1



▶ 図 5-8b：部位別 AIS の実測値と予測値 ケース 2



▶ 図 5-8c：部位別 AIS の実測値と予測値 ケース 3

なお、本研究で構築した 14 種類のリスクモデルの出力傾向や、MAIS への回帰構造の詳細については、Appendix にて補足資料として示している。

6. 考察

6.1 モデルの意義：人の思考を模した予測構造

本研究で構築した多層補集合モデルは、従来の一括入力型の機械学習モデルとは異なり、「人がリスクを推測する思考手順」に着想を得て設計されたものである。説明変数ごとに回帰モデルを構築し、それらを積層的に統合することで、複雑な社会現象である交通事故リスクを多面的に捉えることを可能とした。

このアプローチでは、個々の回帰モデルの決定係数 (R^2) は必ずしも高くはなかった (0.1 ~ 0.3 程度) が、逆にその低さが「残差の中に他の因子の影響が潜む」ことを意味しており、積み重ねることによってより豊かなリスク像が浮かび上がるという思想に基づいている。

この構造は、実際に人が事故状況を評価する際の思考回路——「損壊が大きい」「高齢である」「シートベルトが未装着である」などの判断を段階的に加味する——と類似しており、モデルの内部構造が“直感的に理解可能”である。たとえば、「損壊が大きく、シートベルトが未装着、高齢である」といった条件が段階的に揃うことで、「重傷のリスクが高い」と人が判断するプロセスに近いモデル構造を有している。

6.2 評価の柔軟性と“曖昧さ”の容認

モデルの評価においても、従来の精度重視型のアプローチ（正解／不正解の二項判定）ではなく、「±1 クラスの許容」や「クラス平均の整合性」といった、より柔軟かつ現実的な評価手法を導入した。

これは、事故データが完全な“理論解”ではなく、現実世界におけるばらつきや記録の制約を含む“観測値”であることに鑑み、過度な厳密性ではなく、構造的妥当性や傾向の一致を重視した評価姿勢である。

一方で、このような曖昧さを許容する評価軸は、従来の機械学習における“正解主義的”な文化とは異なるものであり、今後はその評価手法を明確化・標準化するとともに、他データセットを用いた汎化可能性の検証も重要な課題となる。

6.3 限界と今後の展望

本研究の限界としては、以下の点が挙げられる。

- 説明変数の制約：

本モデルでは 25 個の説明変数を使用したがる、実際の事故リスクを規定する因子はさらに多岐にわたる。天候や道路状態は事故特性に含めたものの、独立した因子としての検討は今後の課題である。また、心理的要因などが含まれていない点も改

善の余地がある。

- **高リスククラスのサンプル不足：**

MAIS=5 や 6 などの重傷・致死事例はサンプル数が極端に少なく、モデルの学習・評価ともに不安定さが残る。この点は今後、データの蓄積や拡張的学習によって改善される余地がある。

- **交互作用の明示性：**

現状は損壊度×各説明変数の交互作用項を含めているが、それらがどのように意味を持ち、どこまで影響を及ぼしているかの可視化・解釈性については更なる検討が必要である。

その一方で、本モデルの応用可能性は広い。たとえば、事故が未発生の場合や条件に対しても、一定のリスク傾向を予測することが可能であり、リスクマップの作成や安全施策の事前評価、あるいは事故予防教育などへの活用が期待できる。

6.4 本モデルの立ち位置と貢献

本研究は、「事故リスクは偶然ではなく、必然的に生じる構造である」という仮説に立ち、現実のばらつきや曖昧さを含み込んだモデル構築を試みた。モデル精度の追求だけではなく、“構造理解”と“直感的妥当性”の両立を目指した点に、本研究の独自性と価値があると考えられる。

これにより、リスクの存在が見過ごされがちな条件に対しても、一定の注意を促す新たな視座を提供できるとともに、将来的な安全設計や政策立案への示唆にもつながる可能性がある。

本研究は、交通事故リスクを「人の思考様式で捉える」ことに挑戦したものであり、モデル精度や理論的厳密性の追求よりも、“構造的に理解可能であること”“現実に即した柔軟さを持つこと”を重視している。

その結果として、従来型モデルとは異なるアプローチから、交通事故リスクの本質に迫る新たな視点を提示できたのではないかと考える。

今後も、実事故の背後に潜む“見えないリスク”を明らかにし、より安全な社会の実現に貢献するため、モデルの進化と活用の可能性を継続的に追求していきたい。

参考文献

- [1] National Highway Traffic Safety Administration (NHTSA). Crash Investigation Sampling System. NHTSA. [オンライン]. 2025 [参照 2025 年 2 月 15 日]. Available from: <https://www.nhtsa.gov/crash-data-systems/crash-investigation-sampling-system>
- [2] 国立病院機構災害医療センター, 「AIS・ISS の用語解説」, 2020 年版 災害医療研修資料.
- [3] IDAJ 株式会社, 「多目的最適化における Deep Learning + RSM + XAI 連携による設計探査の可能性」, IDAJ BLOG, 2023 年 8 月 23 日.
<https://www.idaj.co.jp/blog/software/modefrontier/deep-rsm-xai-240823>
- [4] IDAJ 株式会社, 「modeFRONTIER に関する技術情報」, IDAJ BLOG (ソフトウェア / modeFRONTIER カテゴリ), <https://www.idaj.co.jp/blog/category/software/modefrontier>, (2025 年 5 月閲覧) .
- [5] 松原望・石村貞夫, 「統計学入門」, 東京大学出版会, 1991 年.
- [6] 吉井勝司. 自動車事故における負傷・死亡リスクの新指標: 既往歴と外傷以外の影響. Jxiv, 2025. <https://jxiv.jst.go.jp/index.php/jxiv/preprint/view/1119>