

AI 技術を活用した都市高速道路の交通流予測と 交通事故重大度分析

AI 技術を活用した都市高速道路の交通流予測と
交通事故重大度分析プロジェクト

2025年8月

公益社団法人日本交通政策研究会

1. “日交研シリーズ”は、公益社団法人 日本交通政策研究会の実施するプロジェクトの研究
成果、本研究会の行う講演、座談会の記録、交通問題に関する内外文献の紹介、等々を印刷
に付して順次刊行するものである。
2. シリーズはAよりEに至る5つの系列に分かれる。

シリーズAは、本研究会のプロジェクトの成果である書き下ろし論文を収める。

シリーズBは、シリーズAに対比して、より時論的、啓蒙的な視点に立つものであり、
折にふれ、重要な問題を積極的にとりあげ、講演、座談会、討論会、その他の方法によっ
てとりまとめたものを収める。

シリーズCは、交通問題に関する内外の資料、文献の翻訳、紹介を内容とする。

シリーズDは、本研究会会員が他の雑誌等に公けにした論文にして、本研究会の研究調査
活動との関連において復刻の価値ありと認められるもののリプリントシリーズである。

シリーズEは、本研究会が発表する政策上の諸提言を内容とする。
3. 論文等の内容についての責任はそれぞれの著者に存し、本研究会は責任を負わない。
4. 令和2年度以前のシリーズは印刷及び送料実費をもって希望の向きに頒布するものとする。

公益社団法人日本交通政策研究会

代表理事 山 内 弘 隆
同 原 田 昇

令和2年度以前のシリーズの入手をご希望の向きは系列番
号を明記の上、下記へお申し込み下さい。

〒102-0073 東京都千代田区九段北 1-12-6

守住ビル 4階

公益社団法人日本交通政策研究会

電 話 (03) 3263-1945 (代表)

F a x (03) 3234-4593

E-Mail: office@nikkoken.or.jp

日交研シリーズ A-925

令和6年度自主研究プロジェクト

「AI技術を活用した都市高速道路の交通流予測と交通事故重大度分析」

刊行：2025年8月

AI技術を活用した都市高速道路の交通流予測と交通事故重大度分析
Leveraging AI models for Analysis of Traffic Flow Prediction and Accident Severity
in Urban Expressway around Tokyo Metropolitan Area

主査：武藤 慎一（山梨大学教授）
Shinichi MUTO

要 旨

現代社会はVUCA（Volatility：変動性、Uncertainty：不確実性、Complexity：複雑性、Ambiguity：曖昧性）の時代と呼ばれ、急速かつ予測困難な変化、不確実な情報、そして複雑で曖昧な要因によって、従来システムが機能不全になる例が多くなっている。その一つが高速道路であり、近年、老朽化や維持管理などの既存問題に加え、新技術の進展、需要と供給の不均衡、交通状況の変動、交通事故の深刻化など、新たな課題に直面している。VUCAの時代に、高速道路を効率的かつ持続的に利用するためには、これらの課題への早急な対応が必要である。そのためは、これまで以上に正確かつリアルタイムの交通流予測を行う必要があり、また重大化しやすい高速道路上の交通事故に対し、重大性と重大化要因との関係性についても慎重な検討が必要である。そこで本研究では、ETC等に基づくビッグデータを活用した交通流予測と、高速道路上の交通事故の重大性に寄与する要因分析を行うことを目的とする。

まず、適用するモデルについて、ARIMAモデルやLSTM（Long Short-Term Memory）モデルなどの整理を行った。その中で、LSTMモデルは、近年急速に発展してきたAI技術、特に機械学習モデルを用いた有効なモデルであるものの「ブラックボックス」的な性質ゆえに、モデルの内部構造や予測根拠が解釈しづらいことを示した。そこで、注意機構を導入した「Attention LSTMモデル」を開発し、交通需要および交通渋滞に対する影響要因を特定化した。そしてモデルを適用した結果より、Attention LSTMモデルの予測精度を他の単一LSTMモデルや従来のARIMA等の時系列モデルと比較し、誤差が小さく、精度の高いことを示した。

高速道路上の交通事故分析に関しても、AI技術を利用したランダムフォレストやXGBoostの適用可能性を検討した。その結果、ランダムフォレストやXGBoostの適用により、交通事故の重大性に与える要因として、地理的位置による地形特性、SA・PAの集中度合い、速度、運転者の年齢などのあることを明らかにした。さらに、XGBoostにSHAP（SHapley Additive exPlanations）を追加して分析することにより、XGBoostモデルの結果の可読性を向上させられることを示した。

適用事例としては、開発した「Attention LSTMモデル」を用いて、中央自動車道の八王子IC－河口湖IC間と、海老名JCT周辺の圏央道および東名高速道路の交通流予測を行った。八王子IC－河口湖IC間では高精度な日交通需要量予測が行えることを示し、さらに、海老名JCT周辺では、ボトルネックに伴う交通渋滞時を含む交通流予測を精度よく行えることを示した。交通事故分析では、ランダムフォレストやXGBoostを適用した上で、SHAP（SHapley Additive exPlanations）を用いることにより、交通事故の重大化要因の可視化を行うことができた。

今後は、渋滞緩和のための時間帯別料金や時間帯別流入調整といった交通政策、自動運転技術の導入や合流支援システムの導入などの政策評価を行う必要がある。さらに、交通事故に関しても、その発生要因を除去し事故を抑制するための政策を検討する必要がある。

キーワード： 交通流予測、交通事故要因分析、Attention LSTMモデル、XGBoost、SHAP

Keywords: Traffic Flow Prediction, Accident Severity Evaluation, Attention LSTM Model, XGBoost, SHAP

目 次

第1章 はじめに	1
1.1 研究背景	1
1.1.1 高速道路の概要	1
1.1.2 高速道路が直面する課題	1
1.1.3 次世代高速道路運用の提案	3
1.1.4 研究課題	4
1.2 研究課題と目的	6
1.3 本稿の構成	7
第2章 既往研究の整理	8
2.1 高速道路に関する既往研究	8
2.2 交通流解析と交通需要管理に関する既往研究	8
2.3 交通事故分析に関する既往研究	10
2.4 既往研究整理のまとめ	11
第3章 研究プロセス	13
3.1 データ収集	13
3.1.1 交通流データ（ETCデータ）	13
3.1.2 交通事故データ	13
3.2 対象地域	13
3.2.1 中央自動車道	14
3.2.2 首都圏中央連絡自動車道（圏央道）	14
3.2.3 東名高速道路	14
3.2.4 対象3路線	15
3.3 研究方法	15
第4章 IC間の交通流予測	16
4.1 本章の概要	16
4.2 LSTMモデルの利点	17
4.2.1 RNNの概要	17
4.2.2 LSTMモデルの原理	19

4.3	予測結果	21
4.3.1	総合的な予測結果	21
4.3.2	変動時の予測結果	23
4.4	本章のまとめ	25
第5章	ボトルネックにおける交通流予測.....	26
5.1	本章の概要	26
5.2	関連研究	27
5.3	研究方法	29
5.4	データ概要	31
5.5	数値計算結果	34
5.5.1	モデルフィッティング	34
5.5.2	予測精度結果	35
5.6	本章のまとめ	38
第6章	AIモデルに基づく交通事故の重大性要因分析.....	40
6.1	既存研究の整理	40
6.2	研究対象地域とデータ	42
6.3	事故調査データに基づく分析.....	45
6.3.1	事故調査データ	45
6.3.2	XGBoost法によるモデル作成.....	47
6.3.3	SHAP法によるモデル解釈	48
6.3.4	数値計算結果	49
6.4	本章のまとめ	53
第7章	おわりに	56
7.1	本研究の主な成果と貢献	56
7.1.1	IC間での交通流予測	56
7.1.2	ボトルネックにおける交通流予測.....	57
7.1.3	AIモデルに基づく事故の重大性要因分析.....	57
7.2	今後の研究課題	58
7.2.1	AIモデルに基づく分析の限界と課題	58
7.2.2	次世代高速道路の実現に関する考察と今後の課題.....	59

研究メンバーおよび執筆者（敬称略・順不同）

主査：武藤慎一	山梨大学大学院総合研究部工学域 教授（執筆担当）
メンバー：青木優	（一財）日本総合研究所 主任研究員
池田駿介	山梨大学大学院医工農学総合教育部工学専攻 M1
石川良文	南山大学総合政策学部 教授
大西亮	山梨大学大学院医工農学総合教育部工学専攻 M2
上泉俊雄	パシフィックコンサルタンツ株式会社 交通基盤事業本部道路部
佐々木邦明	早稲田大学理工学術院創造理工学部 教授
徐芸昊	山梨大学大学院医工農学総合教育部工学専攻 M2
田村昂	山梨大学大学院医工農学総合教育部工学専攻 M2
仲条仁	株式会社Create-C 代表取締役/CEO
福田敦	日本大学大学院理工学研究科 教授
Nontachai TITHIPONGTRAKUL	株式会社Create-C
松岡斉	（財）日本総合研究所 理事長
劉星委	山梨大学大学院総合研究部工学域 特任助教（執筆担当）
和田裕行	パシフィックコンサルタンツ株式会社 社会イノベーション事業 本部交通政策部

第1章 はじめに

1.1 研究背景

1.1.1 高速道路の概要

1965 年、わが国最初的高速道路である名神高速道路が開通した。これが高速道路時代の幕開けとなり、以来、約 60 年間にわたり高速道路整備が進められてきた。その結果、高速道路の総延長は 10,000km を超え、インターチェンジ (IC) は 1,000 箇所以上に達している。高速道路は、基幹的交通網として主要都市間を結び、経済基盤を強化してきた。この約 70 年の間に高速道路管理は、当初の政府全額出資による日本道路公団 (JH) から、日本高速道路株式会社 (NEXCO) グループや首都高速道路株式会社など、複数の民間企業による分散型に変わった。日本の東部、中部、西部をそれぞれ管轄する 3 つの事業体から成る NEXCO は、国内高速道路網の最も広範な部分を管理運営している。その総延長は、2019 年時点で 8,500km に迫り (COVID-19 の影響を考慮し 2019 年以降のデータは割愛する)、全国的高速道路網全体の 80%以上を占め、1 日あたりの交通量は 500 万台を超える。輸送需要がまだ増大するとされているわが国では、早急に効果的な交通管理戦略を策定する必要がある。

一方、NEXCO が管理する路線を含めわが国的高速道路は、インフラの老朽化という深刻な問題に直面している。NEXCO 中日本では、同社が管理する高速道路 (国道や有料道路を含む) の総延長は 2,000km を超える。名神高速道路や東名高速道路といった主要路線では全線開通から 50 年以上が経過し、供用開始 30 年以上を経過した区間が約 60%、50 年以上を経過した区間が約 25%を占めている。2032 年にはこの比率が倍増し、供用開始 50 年以上を経過した区間が全体の 50%以上に達すると予測されている。NEXCO 東日本および NEXCO 西日本が管理する高速道路においても同様の懸念が存在し、状況は楽観を許さない。2022 年 9 月時点で、NEXCO 東日本の管理下にある高速道路は 3,943km を超え、供用開始 30 年以上を経過した区間が 50%以上、2030 年までには 80%に達すると予想されている。NEXCO 全体で見ると、2050 年までには、供用開始 50 年以上経過する区間は 50%以上になるとされており、インフラ老朽化は加速度的に進行していくと考えられる。

1.1.2 高速道路が直面する課題

高速道路は、交通インフラの中の最重要施設であり、人および物の効率的な移動を支えている。その一方で、現代社会は VUCA (Volatility : 変動性、Uncertainty : 不確実性、Complexity : 複雑性、Ambiguity : 曖昧性) の時代と称され、急速かつ予測困難な変化、不明瞭な情報、そ

して複雑に絡み合う要因が従来のシステムを機能不全にしようとしている。現在の高速道路は、老朽化や維持管理などの既存問題に加え、新技術の進展、需要と供給の不均衡、交通状況の変動など、新たな問題にも直面している。高速道路を継続的かつ持続可能的に利用するためには、これらの課題への早急な対応が必要である。本節では、高速道路が直面する社会的、環境的、技術的、そして運営的課題について概説する。

インフラの老朽化：現在の高速道路のうち、約 80%が開通から 30 年以上経過している。インフラの老朽化は、維持管理費の増大や安全面でのリスクの増加に直結する。これらの構造物の更新・改良は今日的課題であり、多額の投資と技術革新による解決策が求められている。

容量制約と渋滞：都市化の進展と自動車保有台数の増加（特に首都圏において顕著）は、高速道路の交通容量に対する大きな負荷になっている。渋滞は移動時間の増大、排出ガス量の増加、そして大気環境の悪化を招く。車線の増設や新規高速道路の建設による容量拡大は、都市開発が進んでいる現状、環境問題への配慮、財政的制約などにより困難を伴う。そのため、渋滞による環境被害や時間損失などの問題は、さらに深刻化すると指摘されている。

高齢ドライバーの安全：高齢運転者（70 歳以上）は、反応時間や視力の低下、その他加齢に伴う身体機能の変化などが認められ、それが運転に支障をもたらす。その結果、最近の高齢運転者が関与する重大事故につながっている。高齢運転者の交通事故に対応できる機能を備える自動車あるいは高速道路の設計は、高齢ドライバーの安全性向上と交通事故の低減に寄与する。

気候変動と道路機能の回復力（レジリエンス）：気候変動は、洪水、暴風雨、熱波といった異常気象の頻度と規模を増大させ、高速道路に対し重大なリスクをもたらす。気候変動の抑止のためには、高速道路の維持管理や建設時の環境配慮型技術の導入や自動車のカーボンニュートラル化支援の充実などが必要になる。また、気候変動を要因とする災害が発生した場合には、早急に道路機能を回復するレジリエンス力の強化にも注力する必要がある。

新技術の開発および導入：高度道路交通システム（ITS）、自動運転、スマートインフラなどの新技術の開発および導入は、高速道路利用の利便性や安全性、快適性の向上につながる。その一方で、新技術の開発や導入には、多額の費用が必要になる。さらに、サイバーセキュリティ強化、データ処理能力の向上、システム間の相互運用性の改善などの追加作業が必要になる可能性もある。

データ収集の限界：従来の交通データ収集方法、例えば固定地点に設置される装置（オン／オフランプ検知器、ループ検知器、カメラなど）は、空間的な網羅性に限界がある。また、これらは時間的な制約もあるため、リアルタイムでの交通状況の把握が難しいという問題がある。

交通流モデルの更新：従来型の交通流モデルは静的なものが多く、実際の交通状況の動的な

特性を十分に捉えきれていなかった。天候、地形、土地利用、非日常的なイベントなどの交通流に影響を与える重要な変動要因が無視されている。さらに、容量推定モデルにおいては、運転者の行動特性、車種構成、路面状況などの動的要因も十分に考慮されていない。これに対し海外では、AI 技術によるリアルタイム処理や予測モデリングが適用され、交通分野に変革をもたらしている。例えば、駐車場情報システム、料金所の混雑解析、動的信号制御などに AI モデルが用いられている。その結果、高速道路運用における最適化の実現に多大な貢献をしている。

資金調達と経済性：高速道路の建設、維持、改良に必要な資金の確保は、依然として重要な課題である。柔軟な料金設定や開発利益還元戦略（Value Capture）などの新たな資金調達方法の検討は、安定的な資金確保のためには非常に重要になる。

1.1.3 次世代高速道路運用の提案

NEXCO 各社および国土交通省は、上記のような課題に対し「次世代高速道路構想」を打ち出している。高速道路の持続可能な発展と、特に VUCA（変動性、不確実性、複雑性、曖昧性）時代において前述の諸課題を解決するためには、高速道路の建設あるいは維持管理に関わる新たな計画を示す必要があった。VUCA 時代は不確実で曖昧な状況である一方、技術革新や新たなモビリティサービスを生み出す機会も多くある。NEXCO 各社および国土交通省は、これから生み出される技術を含めた新技術を基に、「次世代高速道路構想」を策定している。

新技術とは、機械学習の進歩、大規模データセットへのアクセス、飛躍的に向上する計算能力などのことであり、特に人工知能（AI）は急速な発展を遂げ、様々な分野に変革をもたらしつつある。同時に、デジタルトランスフォーメーション（DX）は、質の高いビッグサービスを収集するための高度なツールを提供し、社会課題に対するより効率的な解決策を提示し得る可能性を秘めている。複雑な課題に取り組み、次世代高速道路のビジョンを実現できるのは、これらの先進技術があるからといえる。

次世代高速道路のコンセプトは、効率性、安全性そして接続性（コネクティビティ）の向上とされている。これを最先端技術とデータ駆動型アプローチを統合して実現し、これからの高速道路利用の進化を目指すものである。次世代高速道路構想の具体的内容は、後述の章で詳述する。ここでは、その簡単な紹介のみを行う。

データ連携：公共交通システムなどの外部情報であるオープンデータと接続し、それと高速道路関連データとを連動させることにより、詳細で精度の高い交通量や渋滞、高速道路利用に関する情報が獲得できる。こうしたデータ連携は、利用者および事業者双方にとって、より価値ある情報に基づいた意思決定を可能にすることにつながる。

次世代型料金システム：GPS やその他の新技術をうまく活用できれば、実際の渋滞状況に応じた料金を課す動的料金システムの導入が可能になる。このシステムによって、公正な料金設定が実現できることから、高速道路資源の効率的な配分を達成することになる。

革新的モビリティサービス（旅客交通）：ここでは、モビリティハブの設置について提示されている。モビリティハブとは、高速道路をバスネットワーク、空飛ぶクルマ、リニア中央新幹線そしてラストマイル・モビリティと接続し、高速道路を中心に多様な交通手段を結合させるというものである。この結合により、高速道路利用から他の交通手段利用への接続性が向上することから、利用者のアクセシビリティや利便性が向上する。さらに、DX の技術などを用いて、モビリティハブでの乗り換えをシームレスにする検討もなされている。

物流拠点（貨物交通）との連携強化：国内貨物輸送量（トンキロベース）の 50%以上が高速道路を利用している。しかし、IC から最終目的地までが脆弱との指摘があることから、IC 周辺への物流拠点の整備や DX などを活用した連携強化、さらに、IC 直結型物流拠点の整備などにより、効率的な貨物の集荷、保管、配送などの実現を目指すとされる。

次世代高速道路とは、安全性、効率性、持続可能性の向上を目指し、最新技術とビッグデータを活用して、高速道路を中心に他の交通機関や地域の物流施設、さらに利用者とも有機的に接続することにより、利用者中心の高速道路インフラというビジョンを具現化するものである。特に、社会と経済の進化し続けるニーズに対応できるように、より応答性が高く適応能力に優れた高速道路ネットワークの構築を目指している。

次世代高速道路計画では多くの課題解決策の提案が示されている。その中で本研究では、主に交通流予測と交通事故要因分析に焦点を当てる。具体的には、(1)高精度でリアルタイムなデータ分析による交通流予測の改善、(2)交通事故の重大性評価とそれに影響を与える要因の抽出を目的とする。

1.1.4 研究課題

本稿では、前述した課題と主要目的を再度整理して示す。その中で交通流は、他の様々な交通関連事象に影響を及ぼす基本要因である。交通流を理解し制御することで、渋滞や道路インフラの改良といった派生的問題に対しての対処が可能になる。さらに、将来の交通状況を正確かつ迅速にリアルタイムで予測することは、渋滞の未然防止、所要時間の短縮、燃料消費の節約、さらに温室効果ガス排出量の低減につながり、経済および環境の両面に便益をもたらす。

予測を含む交通流解析は、広くは交通需要マネジメントの範囲に含まれる。正確かつリアルタイムな交通流予測が実現すれば、交通サービス提供者は交通需要をより深く理解できる。高速道路は、大容量かつ高速走行を前提として設計されているため、高速走行時には些細な

運転ミスが致命的な結果につながりかねず、交通事故の重大化の原因になる。したがって、高速道路研究において、交通流解析は極めて重要であるとともに、交通事故に関する研究もまた同様に不可欠である。高速道路の安全性向上のためには、交通事故予測も必要ではあるものの、交通事故の原因や寄与因子の解明も重要である。このような洞察は、車線運用改善、道路構造改良、車両安全技術指導、そして運転者安全教育に資するものである。そこで、本研究では交通流解析に加え、交通事故の重大性に関する研究も行う。

現実的には、車両の接触やガードレールへの衝突といった軽微な交通事故を完全に失くすことは困難である。「交通事故ゼロ」は理想的な目標ではあるものの、重大事故を可能な限り削減することが現実的である。本研究では、主に AI モデルを活用して交通事故の重大性を評価することに焦点を当てる。これにより、重大事故を未然に防ぎ、高速道路上での死傷者や物的損害を軽減し、将来的な「交通事故ゼロ」の達成に貢献することを目指す。

既述の通り、現代は VUCA と呼ばれる不確実性の高い時代であると同時に、技術革新や新たなモビリティサービスが目覚ましい発展を遂げている時代でもある。AI の急速な進化、デジタルトランスフォーメーション（DX）の進展、そして大規模交通データの利用可能性向上は、我々が直面する交通課題に対し有益な解決策を提示し得る。広範囲で複雑なネットワークを有する高速道路は、地域の交通システムだけでなく都市開発など広範な影響を及ぼす。AI モデルは他分野での応用が始まっている。しかし、高速道路への適用には、その環境等の複雑性からほとんどなされていない。

この状況は、一方での AI モデル開発の進展と、他方での次世代高速道路ビジョンの実現との間にギャップの存在することを意味している。このギャップを埋めるため、本研究では首都圏の高速道路をケーススタディとし、高速道路の改善と次世代高速道路ビジョンの実現に向けた具体的な解決策の提示を目指す。

日本の高速道路にとって、AI 駆動型の交通解析は新時代の研究方法のきっかけになる可能性がある。単に渋滞を緩和するだけでなく、正確な交通流予測や交通事故解析は、二酸化炭素排出量の削減、交通安全の強化、さらには効率的な輸送の確保を通じた地域経済の発展にまでつながり得る。これは、単なる技術的なアップデートだけではなく、社会的要請でもある。本研究では、わが国の高速道路における AI 駆動型ソリューションの現状、課題、将来の可能性について深く掘り下げる。

1.2 研究課題と目的

前節で述べた AI の最新研究と次世代高速道路ビジョン実現との間のギャップの解消を、本研究の第一の目的とする。具体的には、以下の目標を設定する。

- a) 東京近郊を対象とし、AI モデルを用いて高速道路の交通流予測を行う。特定の IC（インターチェンジ）や JCT（ジャンクション）など、高速道路の重要区間のデータに基づき、交通流データを把握するとともに、リアルタイムでの交通流予測を行う。
- b) AI モデルの結果の可視化および結果の解釈の効率化についても検証する。「ブラックボックス」とされる AI モデル内部の計算プロセスを解明することで、結果の出力過程を透明化し、結果の信頼性を向上させる。
- c) 交通事故解析、特に高速道路における交通事故の重大性を評価し、さらにその発生原因、および影響範囲について明らかにする。
- d) 高速道路の幾何構造、交通流動特性、運転者属性が、交通事故の重大性にどの程度寄与しているのかを明らかにすることによって、日本特有な社会文化的規範下において、どのような対策が効果を発揮するのかを実証的に明らかにする。

本研究では、上記の研究目的に対し、さらに二つの中心的問いを設定する。

問1：時系列データ、特に交通流の時系列データに対し、どのように AI モデルが適用できるのか？ また、その中で有効な AI モデルはどのようなものか？

- a) まず AI モデルの中で、リカレントニューラルネットワーク（RNN）について、どのように交通流データを処理しているのかを整理する。RNN モデルの利用により、IC やボトルネック区間といった特定の場所の交通状況を、どの程度の精度で予測可能かを検証する。
- b) これらの RNN 関連モデルの分析目的および現時点でどのような結果が出力できるのかを明らかにする。それを踏まえ、RNN 関連モデルの改良型モデルは存在するのか、もし存在するとして、それは次世代高速道路における高速道路研究において、どのような洞察を提供し得るのかを整理する。

問2：AI モデルは、交通事故の重大性とその根本原因の解明に対し、どの程度貢献するのか？ どのような要因が交通事故の重大性に影響を及ぼし、それらの変数はどの程度の影響力を持つのか？

- a) AI モデルを用いて、高速道路施設上での交通安全性向上に対する対策評価を行う。その対策を実施する際、他の次世代高速道路への改修を含め、低コストでの実施ができないかを AI モデルを援用して検討する。
- b) AI 駆動型分析に基づき、重大交通事故の主要な要因を特定する。それを踏まえ、どのような交通安全性向上戦略が有効かを明らかにする。

1.3 本稿の構成

本稿は、7章で構成される。第1章では、本研究の序論として研究概要を示す。第2章では、本研究の主要な研究領域に関連する既往文献のレビューを行う。第3章では、データ処理、事例研究の対象選定および研究方法論を含む研究計画について詳述する。第4章では、中央自動車道をケーススタディとして、交通流予測におけるAIモデルの一つである長短期記憶（LSTM）モデルを用いて分析を行い、その精度を検証する。これを踏まえ、第5章ではLSTMモデルに注意メカニズムを導入し、特に交通ボトルネック地点における予測精度と結果の解釈可能性を向上させる試みについて説明する。第6章からは交通事故分析を行う。まずAIモデルを用いて、どの変数が交通事故の重大性に影響をもたらしているのかを明らかにする。最後に第7章では、結論を提示し、本研究の限界と将来の研究の方向性を整理する。さらに、次世代高速道路ビジョンの実現に対する本研究の貢献についても議論する。

第2章 既往研究の整理

2.1 高速道路に関する既往研究

わが国では、自動車保有台数が増加していくとともに、高速道路が整備されその路線網が拡大していった。さらに、経済成長に伴い、人々の移動に対する需要はますます増大し、その需要に対応するため高速道路の建設、管理、運営の高度化が求められ、様々な課題に直面することになった。

まず課題は、高速道路における複雑な交通流の動態に関するものである。この中には渋滞も含まれる。渋滞の伝播は、非線形性とダイナミクスを包含している。Treiber et al. (2013) は、そのモデル化には困難を伴うと述べ、その原因が複雑な交通流動にあるとしている。高速道路を含む交通基盤整備において、複雑な交通流動を解明し、確かな交通流予測を行うことが重要であるとしている。Kerner (2021) は、交通流理論とその実用的応用について、広範な整理を行っている。特に高速道路に焦点を当てた箇所では、交通管理と制御の重要性を強調するために、三相交通理論 (Three-phase traffic theory) を提示している。

Sun et al. (2016) は、交通流の複雑性と不安定性の実態について、テキサス州ヒューストンの US-290 号線にて収集された 32 日間の交通速度データを用いて変化のパターンを明らかにした。その結果、交通パターンは時間帯、曜日、季節、さらには予測不可能な出来事によって大きく変動し得ることが示された。Vlahogianni et al. (2014) は、これまでの短期の交通流予測研究に関し、過去 10 年間の研究の発展経緯と現状調査を行った。そこでは、ITS 関連研究における 10 の課題を列挙し、将来の研究に助言を与えている。彼らが交通流予測分野において、AI モデルが果たした重要な役割に言及していることは注目に値する。

2.2 交通流解析と交通需要管理に関する既往研究

Vlahogianni et al.の指摘を踏まえ、本研究ではまず交通流解析に着目する。交通流解析は、他の交通問題を解決するための基本的かつ重要な情報になる。交通流の研究者は、これまでも国内外に多く存在する。また、様々な分野での AI 技術の飛躍的進歩により、AI 技術による交通流問題の解決については重要な研究分野になっている。

そのような中、Daganzo (1994, 1995) が交通流の基本的解析方法を提示した。Daganzo は、動的な交通流を表現するためにセル・トランスミッション・モデル (CTM) と呼ばれる流体

力学を基にした交通流シミュレーションモデルを考案した。このモデルは、単一の入口と出口を持つ高速道路におけるマクロな交通流理論と、細かな時間別交通流や車両挙動を扱うミクロな交通流理論とを統合したものである。このモデリングの成功は、より正確な交通流の表現を可能にし、高度な交通管理および制御戦略への道を開いた。さらに、Ma, X. et al. (2016) は、リカレントニューラルネットワーク (RNN) の一種である長短期記憶 (LSTM) ネットワークを用いて、中国の北京で収集されたマイクロセンサーデータに基づき、交通速度を予測する手法を提案している。リアルタイムの交通流予測の他に、空間的・時間的変数にも注目する必要がある。永廣ら (2019) は、予測精度の向上のため、阪神高速道路の ETC2.0 により収集された 5 分間データに対し、ニューラルネットワーク (NN) モデルを適用した。NN の適用により、旅行時間の予測精度が向上した。今後、高速道路上のデータ収集量が増加するにつれて NN モデルの学習プロセスが大幅に改善されることから、さらに予測精度が向上するものと考えられている。

Zhang et al. (2020) は、ST-ResNet と呼ばれる深層学習ベースのアプローチを提案している。この研究では、時間選択、期間、およびトレンド特性をモデル化するために、残差 NN を採用した。さらに興味深い成果は、彼らが調査地域を近隣地区に分割し、それによって地域全体の予測問題が、各地域における交通の流入および流出の予測問題に変換されることを示した点である。また、Yao, H.ら (2018) は、空間的關係と時間的關係の両方をモデル化するために、Multi-View Spatial-Temporal Network (DMVST-Net) と名付けられた新しい深層学習フレームワークを導入した。このフレームワークは、時間的ビュー、空間的ビューおよび意味的ビュー (類似地域のモデル化) の 3 つのビューから成り、複雑なタクシーの需要をシミュレーションにより予測できることを示した。

さらに Ni (2020) は、逆の視点から、従来型モデルを理想的な結果と比較検討し、モデルの柔軟性、拡張性、一貫性の限界などを明らかにした。これにより、交通流シミュレーションと交通流理論との間の埋めがたい差異を特定した。Ni は、その差異を埋めるためには、詳細な定式化やキャリブレーションあるいは検証を伴うような特定のモデルによる研究ではなく、一般モデルによる研究アプローチであるべきと強調している。この Ni の研究を受けて、Wang (2021) はこの分野をさらに精査し、交通流が複雑な特性を有するがゆえに、従来モデルはしばしば精度が低いという批判にさらされてきたと指摘した。これに対し、近年、AI モデルがその強力な学習能力と自己適応能力により広く受け入れられており、大規模な交通データの処理において特に効果的である。AI モデルを適用することにより、Wang の懸念が解消するのではないかと期待されている。

Ni、Wang の研究に続き、交通管理における AI の可能性を探求する研究は増えると考えられる。AI は、特に高速道路の文脈において、交通解析の最前線に位置づけられ、この分野に

における長年の課題に対処するための有望なアプローチとされている。わが国の高速道路も例外ではなく、AI の適用開始は遅かったものの、多くの学者が交通流に AI を適用する研究を行ってきた。例えば、日本道路新技術協議会は 2018 年に「AI 技術に基づく短期交通予測手法と包括的交通需要管理の研究開発提案」と称する研究を募集した。その中で Chikaraishi et al. (2020) は、2018 年 7 月の豪雨災害後の大規模な交通混乱が生じている最中に、広島県内でループ検知器を用いて収集された交通データを使用し、ランダムフォレスト、サポートベクターマシン、XGBoost、フィードフォワードニューラルネットワークを適用して交通流予測を行った。その結果、ランダムフォレストと XGBoost が最良の予測精度となることを明らかにした。また、既述の Nagahiro et al. は、阪神高速道路の ETC2.0 のデータに対し NN モデルを使用し、旅行時間の予測精度を向上させた。ETC データの取得量はますます増加しており、NN モデルの学習と精度向上に貢献している。

Varghese et al. (2020) は、様々な大規模交通データセットを用いて深層学習モデルの予測精度を検証し、メタ分析と従来のモデリングアプローチとを比較している。そこでは、深層学習モデルが平均して従来の方法を上回る一方で、精度の度合いは対象とする交通問題の特性や収集可能なデータセットに依存して変動することを明らかにしている。それを受けて、Varghese et al. はさらに交通問題やデータセットの特性に応じてモデル選択が可能になるよう、モデルの整理を行っている。

2.3 交通事故分析に関する既往研究

高速道路での交通事故は、各車の走行速度が速いがために重大事故につながりやすい。また、高速道路では出口が限られているため、一度事故が発生すると一般道よりも影響が大きくなる。そのため、高速道路上での交通事故に関する研究も、これまで多くなされてきた。

Chung は、対数ロジスティック加速故障時間 (AFT) メトリックモデルを開発し、韓国的高速道路システムを対象に、2006 年から 2007 年に記録された 2 年間の事故影響時間データを利用して、事故影響の継続時間を予測した。その結果、交通事故のダイナミクスに関する特性を明らかにした。Zhu, Lin et al. (2018) は、都市ネットワークにおける交通事故の自動検出のための畳み込みニューラルネットワーク (CNN) を提案している。提案された手法は、大規模な都市ネットワークにおいて、従来のニューラルネットワークよりも優れていることを示した。

交通安全は、高速道路システムの効率的な運用にとって極めて重要である。その点を考慮し、Sun Jie et al. (2014) は交通事故を予測するために、サポートベクターマシン (SVM) モ

デルと k-means クラスタリングアルゴリズムを組み合わせたハイブリッドモデルを提案している。このモデルを用いて上海高速道路のデータによる学習を行いシミュレーションした結果、精度は 78.0%を達成した。同様に Qing Cai et al. (2020) も同じ問題に対し、データセットを均衡させるため、より多くのデータを生成する深層畳み込み生成的敵対ネットワーク (DCGAN) モデルという深層学習手法を開発した。67,572 サンプル (625 セットの事故データを含む) を分析することにより、DCGAN 均衡化データに基づく CNN モデルは、衝突につながる交通データを完全に学習し、高予測精度を達成できることを示した。

様々な種類の交通安全問題において、交通事故の重大性を分析することは、通常の小さな交通事故では明らかにならない体系的な問題や特定の危険因子を明らかにすることができる。交通事故予測に加えて、事故の重大性に焦点を当てた研究もある。Miaomiao Yan et al. (2022) は、ベイズ最適化 (BO) とランダムフォレスト (RF) から成る BO-RF モデルを提案した。部分依存プロットの助けを借りて、交通事故の重大性を分析することができる。Jian, Z. et al. (2018) は、フロリダの高速道路分岐エリアから衝突の重大性、道路幾何構造および交通流データを収集し、様々な機械学習および統計的手法により計算を行い結果を比較した。その結果、ランダム法が最良の予測結果となり、順序プロビットモデルが最も精度の低いことを示した。これは、交通分野における AI モデルのアルゴリズムに関する探究を継続する必要があることを示している。

2.4 既往研究整理のまとめ

以上より、最新の交通分野における研究では、AI モデルが積極的に用いられていることが明らかになった。それらの研究では、AI モデルの組み合わせを工夫することで、より良い結果を得ることが検討されている。その一方で、AI モデルの中間計算プロセスや、AI モデルの結果と原因の関係に関する研究は少ない。交通分野では、既存施設の改善を図るために、結果だけでなく原因も知ることが重要である。近年、全世界で COVID-19 の影響を受け、大きな変化が生じた。また、自動運転や電気自動車の普及など、あらゆる新技術が、人々の移動と高速道路利用を変化させてきた。このような現象をメカニズムとして捉え、AI によって予測するためには、AI モデルの中間計算プロセスや原因と結果の関係にも着目した研究が必要である。

わが国は、2030 年代へ入るまでに、次世代高速道路計画を策定している。これからは、その計画の達成に向けた研究が求められ、さらに政策的含意もしっかり示す必要がある。研究と実務のギャップを埋め、日本の高速道路利用をより良くするため、本研究では AI モデル

を効果的に使用する。特に、イベントの原因を明らかにすること、交通状態が変化するその過程も明らかにすること、そして AI モデルの計算処理過程も明らかにすることが本研究の焦点になる。

第 3 章では、データ利用、シナリオ選択、対象地域等の研究プロセスについて説明する。

第3章 研究プロセス

3.1 データ収集

3.1.1 交通流データ（ETC データ）

国土交通省の統計によると、ETC の利用率は高く、2019 年時点で約 93%である。本研究では、交通流のデータを NEXCO 各社が管理する ETC により収集する。ETC データによって記録される情報には、車種、入口日時、出口日時、オンランプ IC、オフランプ IC、通行料金が含まれる。ただし、個人を特定できる情報やその他の支払い情報は除外される。NEXCO 各社が管理するエリアは、全国の高速道路の中で最も広い。したがって、本研究で用いる ETC データは、ほぼ全国を網羅できているものと考えられる。

3.1.2 交通事故データ

本研究で用いる交通事故データの主要なソースは、NEXCO 3 社による交通事故調査報告書である。そこには、詳細な交通事故情報が記録されている。以下は、交通事故調査報告書に含まれる情報の一部である。

事故基本情報：事故の日時、事故の場所

関係者情報：運転者の氏名、年齢、性別、連絡先、事故に関与した車両の種類

事故詳細：事故の種類（例：追突、横転、衝突など）、損害の程度（物損または人身傷害）

状況および条件：天候、視程、道路状況

交通事故調査報告書に記録されたデータは、可能な限り事故の状況を再現するものである。しかし、実際の記録プロセスにおいては、欠損データや不明データを避けることはできない。したがって欠損情報のある場合は、その要因をフィルタリングして相関関係を持つ要因を排除するという作業を行っている。

3.2 対象地域

本研究では、東京周辺の 3 つの主要高速道路を対象にする。これら 3 つの主要高速道路は以下のとおりである。




図 3.1 首都圏高速道路路線図

3.2.1 中央自動車道

中央自動車道は、日本の高速道路の中心に位置し、東京と名古屋を結んでいる。その路線は山岳ルートになっており、多数のトンネルと橋梁からなる。高速道路が山岳地を通過することから、利用者は自然あふれる景観と山々の美しさが楽しめる。特に、富士山と中央アルプスの眺望は非常に人気がある。

3.2.2 首都圏中央連絡自動車道（圏央道）

圏央道は、正式名称を首都圏中央連絡自動車道という。これは、日本の関東地域に位置する重要な高速道路である。その名称が示すように、圏央道の主な目的は、首都圏の外縁地域を広域接続することである。東京都心部の交通渋滞を緩和し、関東地域の様々なエリア間のアクセスを改善することを目的にしている。

3.2.3 東名高速道路

東名高速道路は、東京、横浜、そして名古屋を結ぶ重要な連絡路である。総延長は 346km に及ぶ。中央自動車道とは異なり、東名高速道路は日本の工業地帯を通過する。そのため、物流やビジネスなど、広範な利用が見られ、大型貨物車を含む多くの交通が利用している。

3.2.4 対象3路線

これら3つの高速道路は、わが国における極めて重要な高速道路であることがわかる。これらの高速道路はそれぞれ、世界の主要な経済拠点である首都圏に位置するか、首都圏と大都市間をつないで移動サービスあるいは輸送サービスを提供している。これらは日本の交通網において不可欠な役割を果たし、物、サービス、人の移動を支えている。

次の第4章では、AIモデルの助けを借りて中央自動車道のIC間交通流の分析と予測を行う。その後、第5章で東名高速道路と圏央道において重大な混雑を発生させるボトルネックでの交通流予測を行う。

3.3 研究方法

本研究では、主に定量的分析を行う。そのために、以下に示す統計的モデルおよびAIモデル（深層学習モデルあるいは機械学習モデル）を用いる。

LSTM（長短期記憶モデル）

ARIMA（自己回帰和分移動平均モデル）

注意力メカニズム

SVD（特異値分解）

XGBoost（eXtreme Gradient Boosting）

SHAP（SHapley Additive exPlanations）

これらのモデルの詳細は、それぞれ第4章、第5章、第6章および第7章で紹介する。

第4章 IC間の交通流予測

交通流の予測は、交通研究における重要なテーマである。本章では、高速道路の ETC データを活用した交通流予測を行う。様々なシナリオに合わせ、適切な AI モデルを選択し、IC間の交通流を予測する。

4.1 本章の概要

交通状況が複雑化し、交通渋滞が深刻化する中で、交通流を正確に予測することは極めて重要である。科学的かつ正確な交通流予測を行うことは、交通インフラの建設や改良あるいは潜在的な交通容量の拡大に関わる基礎情報になる。交通流予測の重要性から、研究者は交通流予測モデルに関する詳細な研究を行ってきた。さらに、技術の進歩が新たなモデルや技術を継続的に発展させ、予測精度と効率を向上させてきた。

情報技術の絶え間ない発展に伴い、交通流予測手法は、短期的予測に基づくモデル開発へと移行してきた。その中でも AI モデルは、非線形かつ動的なプロセスを良好にモデル化できる能力があるため、交通流予測に最も広く適用されるモデルとして徐々に主流となりつつある。その一つが長期短期記憶（LSTM）モデルである。

第3章で述べたように、中央自動車道は首都圏と中京圏を結ぶ交通量の多い高速道路であり、戦略的に極めて重要な意味を持つ。中央自動車道は 1960 年代に建設され、使用されている。車線の大部分は依然として各方向 2 車線の設計であるため、観光シーズンや週末・祝日には深刻な渋滞が発生している。本研究では、八王子 IC から河口湖 IC までの交通流データを収集した。これら 2 つの IC はそれぞれ以下のような特徴を有している。

八王子市は東京都の西部に位置し、東京都心から約 40km の距離にある。最新の統計では、人口は約 56 万人である。人口および面積の両方において、東京都で最大の都市である。八王子市には 21 の大学および短期大学が所在し、約 10 万人の学生がこの都市で学んでいる。日本有数の学術都市の一つであり、若年層の割合が比較的高い。

河口湖は山梨県に位置し、富士山への近さでもよく知られている。その立地条件から、河口湖 IC は、特に富士山、富士五湖およびその他近隣観光地を訪れる人々にとって、重要な役割を果たしている。河口湖周辺は観光資源が豊富であるものの、地域の地形的制約により開通している高速道路は少ない。その一方で、この地域では大規模なイベントが随時開催され、それが多数の訪問者を引きつけ、交通流の著しい変動をもたらしている。

本研究では、八王子 IC から河口湖 IC までの交通流に関する 1430 セットのデータを用いる。交通流データの単位は 1 日あたりの車両数（台/日）であり、時間間隔は 24 時間である。これら二つの高速道路 IC は、日本の東京近郊にある著名な通勤都市および観光都市に位置している。データの期間は 2006 年 4 月 1 日から 2010 年 2 月 28 日までである。このうち 2006 年 4 月 1 日から 2009 年 3 月 31 日までの交通流データを学習セットとし、2009 年 4 月 1 日から 2010 年 2 月 28 日までの交通流データをテストセットとする。交通流の傾向を図 4.1 に示す。

図 4.1 で可視化できるように、変動は徐々に激しくなる傾向があり、交通流の最小値と最大値の差は拡大している。このような激しい変動は、疑いなく高速道路の円滑な運用に課題をもたらし、また、交通流の予測により多くの不確実性をもたらす。




図 4.1 八王子 IC—河口湖 IC 間の日交通量

4.2 LSTM モデルの利点

様々な AI モデルの中から、時系列ベースの問題処理において良好な結果を示し、比較的小規模かつ単純なニューラルネットワークの一つである LSTM モデルを用いることにした。

4.2.1 RNN の概要

LSTM モデルは、リカレントニューラルネットワーク (RNN) の特殊形態である。その強力な適応性のために、最初に経済指標予測などに応用された。その名の通り、RNN は再帰的なニューラルネットワークであり、隠れ層のニューロン間に接続が存在するため、シーケン

ス情報が保持される。LSTM モデルも同様の構造を持ち、入力層、出力層および隠れ層を含む。その概念を図 4.2 に示す。




図 4.2 RNN の一般的な構造




図 4.3 RNN 構造のフローチャート

数学的な分析を容易にするため、隠れ層を展開し、数学的記号を付して図 4.3 に示す。
ここで、

x_t は入力層値のベクトルを表す。

s_t は隠れ層値のベクトルを表し、現時刻の入力値 x_t と前時刻の値 s_{t-1} に依存する。

o_t は出力層値のベクトルを表す。

U は入力層から隠れ層への重み行列である。

V は隠れ層から出力層への重み行列である。

W は重み行列である。現時刻における重み行列 W は、前時刻の結果から得られる。

図 4.3 から、以下のことがわかる。

$$O_t = g(Vs_t) \quad (4.1)$$

$$s_t = f(Ux_t + Ws_{t-1}) \quad (4.2)$$

Vs_t は、出力層の重み行列、 $g()$ と $f()$ は活性化関数である。

式(4.2)を式(4.1)に代入することにより、式(4.3)を得ることができる。

$$\begin{aligned} O_t &= g(Vs_t) \\ &= Vf(Ux_t + Ws_{t-1}) \\ &= Vf(Ux_t + Wf(Ux_{t-1} + Ws_{t-2})) \\ &= Vf(Ux_t + Wf(Ux_{t-1} + Wf(Ux_{t-2} + Ws_{t-3}))) \\ &= Vf(Ux_t + Wf(Ux_{t-1} + Wf(Ux_{t-2} + Wf(Ux_{t-3} + \dots)))) \end{aligned} \quad (4.3)$$

式(4.3)は、時系列処理のための構造的基礎を与えている。これより、すべての入力値が認証済み出力値に影響を及ぼすことがわかる。式はますます長くなり、モデルでは初期に現れた重要な特徴の記憶を失うことになる。LSTM は、その構造内にある記憶ブロックを設けることにより、この弱点を克服している。

4.2.2 LSTM モデルの原理

LSTM モデルは、隠れ層に記憶ブロックと呼ばれるユニットを持ち、長期間の時系列データの記憶を有して扱うことができる。記憶ブロックは、ネットワークの時間的状態を格納するセル状態と、状態の活性化を制御するゲートを含む。図 4.4 は LSTM のフローチャートを示す。計算処理は以下の 4 つのステップに要約できる。

(1) 破棄する情報の決定

最初のステップでは、セル状態から破棄される情報を決定する。この処理は、主に図 4.4 の赤線部の忘却ゲートにより行われる。数学的定式化は以下の通りである。

$$ft = \sigma(Wf \cdot [h_{t-1}, x_t] + bf) \quad (4.4)$$

Wf は忘却ゲートの重み行列である。 $[h_{t-1}, x_t]$ は、2 つの合成ベクトルである。 bf は忘却ゲートのバイアス項、 σ はシグモイド関数である。重み行列 Wf は、 Wf_h と Wf_x の 2 つの行列から得られる。




図 4.4 LSTM モデルの記憶ブロック

$$[Wf] \begin{bmatrix} h_{t-1} \\ x_t \end{bmatrix} = [Wf_h, Wf_x] \begin{bmatrix} h_{t-1} \\ x_t \end{bmatrix} = [Wf_h \cdot h_{t-1}, Wf_x \cdot x_t] \quad (4.5)$$

(2) 更新情報の決定

次のステップで更新情報を決定する。図 4.4 の青い線がこのプロセスを示している。これは 2 つの部分から構成されている。シグモイド関数は更新が必要な部分を決定する。 $\tanh$ 関数は新しい候補ベクトルを作成する。数学的な定式化は、以下のとおりである。

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t]) + b_t \quad (4.6)$$

$$C = \tanh(W_C \cdot [h_{t-1}, x_t]) + b_C \quad (4.7)$$

(3) セル状態の更新計算

前のステップでは、どの情報を更新する必要があるかを確認した。このステップでは、隠れ層のセルの状態を C_{t-1} から C_t に更新する。

$$C_t = f_t \cdot C_{t-1} + i_t \cdot C \quad (4.8)$$

図 4.4 の緑線で示されるように、前のセル状態 C_{t-1} に忘却ゲート f_t を乗じ、不要な情報を破棄する。次に、現在のセル状態候補 C_t に入力ゲート i_t を乗じ、新しい候補値を得る。式(4.8)より、最終的な新しいセル状態 C_t も得る。このプロセスは、本質的に現在の（短期）記憶と長期記憶を組み合わせたものである。

(4) 出力情報の決定

セルの状態を更新した後、この層で学習した値を出力する。その過程は、図 4.4 のオレンジ線であり、数学的定式化は次のようになる。

$$O_t = \sigma(W_o \cdot [h_{t-1}, x_t]) + b_o \quad (4.8)$$

$$t = O_t h_{t-1} \cdot \tanh(C_t) \quad (4.9)$$

4.3 予測結果

LSTM モデルを適用する際、主に深層学習ライブラリである Keras によって実装される。Keras は高水準ニューラルネットワークの深層学習プログラミング用 API インターフェースであり、主に Python で記述されている。それは高度にモジュール化されており、基盤となる操作は最も一般的な 2 つのライブラリである TensorFlow と Theano である。これらは明確な構造を持っている。


最初の 3 年間のデータを学習用データセットとして使用し、4 年目のデータをモデル検証用データセットとして使用する。LSTM モデルは、最初の 3 年間のデータに基づき、4 年目の交通流状況を予測する。予測計算の後、予測値と実測値を比較し、LSTM 予測の性能を評価する。

ここでは、平均二乗誤差平方根 (RMSE) をモデル誤差の評価指標として使用する。RMSE は、期待値のリストと予測値のリストとの間の平均二乗誤差を意味する。RMSE は時系列の不偏性を測定でき、元のデータと同じ単位を持つ。RMSE が小さいほど誤差分布の分散が小さいことを意味し、より良好な予測であるといえる。


4.3.1 総合的な予測結果

チューニングプロセス中に調整された主要なパラメータは、ニューロン数、訓練エポック数、およびバッチサイズである。このプロセスでは多数の結果が得られた。ここでは紙面の都合上、その一部のみを提示する。


比較チャートを図 4.5 に示す。図 4.5 の結果のとおり、(b)、(c)は(a)と同じ層数および訓練回数を有するものの、(c)のニューロン数は 35 個に増加している。(c)の予測結果は(b)および(a)よりもわずかに優れている。(a)の RMSE と比較して(c)の RMSE は 57.71 減少し、(b)の RMSE と比較して(c)の RMSE は 16.627 減少している。LSTM モデルにおける最小の RMSE 値は 572.529 であり、これは他の全ての予測モデルの値よりも低い。



(a) 15 個のニューロンの LSTM モデル



(b) 25 個のニューロンの LSTM モデル



(c) 35 個のニューロンの LSTM モデル

図 4.5 LSTM モデルの予測結果比較（赤：予測値、青：観測値）

続いて、LSTM モデルによる多変量交通流予測の性能を確認する。ここでは、モデル(c)に基づき、天候と休日情報を交通流データに統合したデータを用いて学習させた多変量予測モデルを用いた。この多変量予測モデルにより計算された RMSE 値は 490.543 である。この結果は、ARIMA モデルおよび単変量の LSTM モデルによる交通流予測結果よりも著しく優れ

ている。したがって、交通流の予測のための入力として関連因子を使用することが、予測精度の向上に顕著な効果を有することが明らかになった。





図 4.6 多変量 LSTM モデルの予測結果（赤：予測値、青：観測値）

4.3.2 変動時の予測結果


交通流予測においては、RMSE 値のみによって予測精度を判断することは十分ではない。実際には、交通流は異常気象や祝日などの偶発的な事象や特殊な状況によって急激に変動する可能性がある。したがって、激しい変動や極値において、交通流を正確に予測できるかも、交通流予測モデルを評価するための重要な指標になる。

ここでは、ARIMA モデルと LSTM モデルの予測結果を比較する。その結果を図 4.7 に示す。それぞれ 5 月 9 日頃と 11 月 9 日頃のものを切り取った比較曲線を示している。青線は実測交通流、赤線は LSTM モデルによって予測された交通流、オレンジ線は ARIMA モデルによって予測された交通流である。


図 4.7 の結果から、実交通流では 2009 年 5 月 9 日および 11 月 9 日の前後において、短期間に 4000 を超える高交通量が発生した。その後、数日間で交通流の値は 2000 未満まで低下している。ARIMA モデルと LSTM モデルは、ともに交通流の全体的な変動傾向に対して正しく反応している。しかし、ARIMA モデルは交通流の急激な変動に対して感度が低く、急激な変動時の予測値は実測値と大きな隔たりがある。対照的に、LSTM モデルは ARIMA モデルと比較して現状の変動を正確に予測することができ、変動時の LSTM モデルの予測値は実測値により近い。




(a) 5月9日前後の LSTM 予測結果



(b) 5月9日前後の ARIMA 予測結果



(c) 11月9日前後の LSTM 予測結果



(d) 11月9日前後の ARIMA 予測結果

図 4.7 変動時の LSTM モデルと ARIMA モデルの予測結果比較
(青：実際の交通量、赤：LSTM 予測値、黄色：ARIMA 予測値)

4.4 本章のまとめ

本章では、LSTM モデルの構造を示すとともに交通流予測に適用した。さらに、その結果を古典的な時系列モデルと比較し、LSTM モデルの推定精度を検証した。LSTM モデルと時系列モデルはともに強力な適応性を持ち、交通流の傾向を迅速かつ正確に予測することができる。

まず、LSTM モデルは長期と短期の記憶を維持するという構造的利点を持ち、複雑な環境条件を伴う交通流予測に対応できる。激しい変動を示す交通流に対して、LSTM モデルは高値および低値ならびに変動傾向をより良好に予測できる。高い適応能力を持つ LSTM モデルは、特に極値に関して、変動傾向をより良好に予測することができる。これは、ビッグデータ、複雑なデータ形式および予測に対する細かな要件を求める交通流予測に適している。

しかしながら、LSTM モデルのような AI モデルを適用し、異なるモデルと比較することにより、モデルの限界も知ることができる。また、適用場面と範囲も明らかにすることができる。本研究は、交通流予測手法の選択に対する理論的裏付けを示し、LSTM モデルが交通流予測において良好な結果を示すことを明らかにした。特に八王子 IC-河口湖 IC という特徴的な IC 区間において、これらの予測を実際に行い、都市間移動量の変動を予測できた点は本章の最大の成果といえる。高速道路の交通流変化、特に様々な種類の不規則な変化を把握することから、事前あるいは事後の対策を万全にすることができる。これは、渋滞を緩和し、輸送効率を改善し、サービス品質を向上させる上で大きな意義を持つ。

第5章 ボトルネックにおける交通流予測

高速道路の交通流研究における重要な箇所は、IC（インターチェンジ）に加えて、高速道路間の接続点の JCT（ジャンクション）である。IC 間の交通流と比較して、JCT は交通量が多く状況も複雑である。そこで本章では、JCT における交通流に対する AI モデルの適用に焦点を当てる。第3章の内容を踏まえ、LSTM モデルに基づき、交通流予測を行い AI モデルの適用可能性を探索する。

5.1 本章の概要

海老名 JCT は、圏央道と東名高速道路の交差する地点である。高速道路ネットワークにおいて、ジャンクションは重要なハブとして機能する。東名高速道路を経由して関東地方に到達した車両は、圏央道を利用することができる。これにより、東京都心部や他の一般道を通過することなく、目的地へアクセスすることが可能になる。その重要性は以下のとおりである。

経済性：このジャンクションは、東京、横浜、その他関東地方の主要な経済拠点間の円滑な物資輸送や通勤などの旅客交通を円滑化する。このシームレスな接続は、交易、商業および日常の交通を活性化させる。

周辺地域への波及効果：海老名 JCT が生み出す効率性とアクセシビリティは、その周辺地域の開発促進に貢献してきた。これにより、海老名はビジネスおよび居住の両面において、便利で戦略的な立地としての地位を確立した。

交通負荷の軽減：海老名 JCT は2つの主要高速道路を接続する結節点として機能することにより、交通を効率的に分散させる役割を果たし、特にピーク時や交通量の多い季節における渋滞を緩和する効果がある。

観光誘致効果：神奈川県は数多くの観光名所を擁している。海老名 JCT は主要な高速道路に接続しているため、観光客が県内の様々な目的地へスムーズに移動できる効果がある。

以上のとおり、海老名 JCT は神奈川県およびより広範な関東地方の交通環境にとって不可欠な要素である。2つの基幹的高速道路を接続することは、効率的な車両の移動を保証するだけでなく、地域の経済的・社会的基盤を支えるものである。

5.2 関連研究

前章では、LSTM モデルを紹介し、交通流予測に適用した。第 3 章で述べたように、LSTM モデルを含む他の深層学習手法では、その学習プロセスがブラックボックスであり、内部の計算ロジックは理解できるものの、学習過程におけるモデルの詳細を把握することは困難である。このため、交通分野への AI の応用にあたっては「解釈可能性」という問題に直面する。本章では、この解釈可能性の問題に取り組み、負荷も多くななく軽量で理解しやすく、実装も容易な注意力メカニズム（Attention Mechanism）に焦点を当てる。

注意力メカニズムとは、日常生活の「注意」という現象に類似している。図 5.1 は、人間が画像を見る際に、限られた注意をどのように配分するかを示している。一般的に、人間は人の顔、文章のタイトル、記事の最初の文により多くの注意を払う。視覚生理学的現象の理解への有効性から、注意力メカニズムはコンピュータ処理や自然言語処理にも応用されている。注意力メカニズムは、音声認識、ヘルスケア、グラフアテンションネットワーク、レコメンダーシステムなど、いくつかの領域で活発に研究されている。




図 5.1 注意メカニズムの視覚システムへの応用

土木工学の分野において、AI モデルを交通流予測のような現実の問題解決に活用する際、注意力メカニズムは予測場面での様々な影響度の重みを割り当てられるようになる。その結果、ニューラルネットワークの能力を向上させることができる。全てに注意を向けるのではなく、重要なポイントにのみ集中することで、より良い予測を行うことが可能になる。この処理を図 5.2 のようにまとめることができる。将来の交通流を予測する際、注意は過去の交

通流に均等に配分されるわけではない。ある日の午前7時の交通流の値を予測する場合、注意力付きモデルは同日の午前7時の交通流の値およびそれ以前の同じ時刻に近接した時刻の交通流の値により多くの注意を払う。逆に、このモデルは、深夜や早朝のような関連性の低い時間帯の交通流の値にはあまり注意を払わない。




図 5.2 注意メカニズムの交通への適用

交通工学における注意力メカニズムの応用は依然として関心を集めており、近年人気が高まっている。以下の研究がこのトピックに取り組んでいる。Zhang ら（2019）は、日々の移動軌跡の理解を向上させるため、移動モードと速度を自動的に分類する手法を提案した。これは、注意力メカニズムと残差学習を組み込んだ分類ネットワーク構造である DenseNet との組み合わせによって達成される。道路トラポロジーにおける減衰問題に対処するため、Cheng ら（2019）は CNN と RNN に注意力メカニズムを適用した。この統合モデルは、5 分間という実世界の大規模な交通状況データセットを用いたテストにおいて、他の手法を上回る性能を示した。Hao ら（2019）は多段階予測を実行するため、注意力メカニズムを組み込んだ Sequence-to-Sequence モデルを提案した。シンガポールの地下鉄システムから収集された大量の実データを用いて、提案モデルの検証が行われた。提案モデルは、他のベースラインと比較して、よりスケーラブルでロバストであることが示された。Xu ら（2019）は、都市全体のタクシー需要予測のため、注意力メカニズムを備えた新しいグラフおよび時系列学習モデルを提案した。注意力メカニズムは、タクシーの空間的依存性を捉えるために用いられた。タクシー需要の正確な予測を得ることは、タクシーの利用率を高め、人々の移動効率を最適化する可能性がある。提案モデルの実験結果は、ベースラインを 9.3% 上回った。したがって、注意力メカニズムは、特にボトルネック領域の複雑な交通流予測において、良好な結果を得ることができると考えられる。

5.3 研究方法

ここでは、改良されたモデルを注意力付き LSTM モデルと呼び、モデル処理の全体像を示す。本研究の対象は交通流であるため、まず、時間 p の各時間ステップ t において、交通流予測値 $\{\hat{y}_{t+1}, \hat{y}_{t+2}, \dots, \hat{y}_{t+p}\}$ を作成する。時間ステップ k だけ前の交通量は $\{y_{t-k+1}, y_{t-k+2}, \dots, y_t\}$ である。これらは既知の交通量である。問題は、 $\{y_{t-k+1}, y_{t-k+2}, \dots, y_t\}$ を利用して、 $\{\hat{y}_{t+1}, \hat{y}_{t+2}, \dots, \hat{y}_{t+p}\}$ を予測することになる。次に、注意力メカニズムが使用する基本的な枠組み、エンコーダ・デコーダの枠組みを説明する。

エンコーダ・デコーダ・モデルは、主に自然言語処理の分野で用いられる。これは特定のアルゴリズムではなく、むしろ様々なアルゴリズムを活用して多様なタスクを解決できる一般的なフレームワークである。エンコーダは実世界の問題を数学的問題に変換するために使用され、デコーダは数学的な問題を実世界の解に戻す。この数学的問題は、このフレームワーク内の特定のアルゴリズムにより解決できる。我々が扱っているデータが時系列データであり、エンコーダ・デコーダ・フレームワークの細分化である Sequence-to-Sequence モデルは、図 5.3 のように表すことができる。




図 5.3 エンコーダ・デコーダ・モデルの一般的構造図

交通流予測は次のように行う。エンコーダでは入力シーケンス $\{y_{t-k+1}, y_{t-k+2}, \dots, y_t\}$ の各要素を処理し、このシーケンスの特徴をコンテキストベクトルに集約する。その後、デコーダはコンテキストベクトルに基づいて出力シーケンス $\{\hat{y}_{t+1}, \hat{y}_{t+2}, \dots, \hat{y}_{t+p}\}$ を生成する。コンテキストベクトルは基本的なモデルの効果を決定し、入力シーケンスの情報がコンテキストベクトル内に完全に集約できると考えている。しかし、エンコーダとデコーダ間で情報を伝達できるのは、式(5.1)の固定長の「単一」コンテキストベクトルのみである。

$$\hat{y}_{t+p} = \varphi(c, y_{t-k+1}, y_{t-k+2}, \dots, y_t) \quad (5.1)$$

実際に高い精度を実現することは、特に交通流シーケンスが長い場合には困難である。コンテキストベクトルの伝達能力を向上させるため、Sequence-to-Sequence モデルに注意力メカニズムを組合せることが提案されている。注意力メカニズムの特徴は、与えられた交通流値全体を固定長のベクトルとしてエンコードするのではなく、コンテキストベクトルのシーケンスとして以下のようにエンコードすることである。

$$\hat{y}_{t+1} = \varphi_1(c_1, y_{t-k+1}, y_{t-k+2}, \dots, y_t) \quad (5.2a)$$

$$\hat{y}_{t+2} = \varphi_2(c_2, y_{t-k+1}, y_{t-k+2}, \dots, y_t) \quad (5.2b)$$

$$\hat{y}_{t+3} = \varphi_3(c_3, y_{t-k+1}, y_{t-k+2}, \dots, y_t) \quad (5.2c)$$

注意力メカニズムから、与えられた交通流シーケンスの各要素には異なる値が割り当てられることがわかる。一部の要素は他の要素よりも多くの注意を受ける。これは、図 5.1 で赤ちゃんの顔やテキストの最初の行がより多くの注意を受けたのと同様である。このプロセスをより明確にするため、注意力メカニズムの有無によるエンコーダ・デコーダ・フレームワークの構造の比較を示す（図 5.4）。




図 5.4 エンコーダ・デコーダのフレームワーク
(左は注意メカニズムなし、右は注意メカニズムあり)

図 5.4 に示すように、 c_i は注意力メカニズムの中核部分である。最初のステップは、各予測ステップにおける注意力の重みを計算することである。 a_{ij} は式(5.3)で計算される注意力の重みであり、各注意力の値の正規化と見なすことができる。

$$a_{ij} = \frac{f(h_i s_j)}{\sum_{j=1}^k f(h_i s_j)} \quad (5.3)$$

ここで、 a_{ij} は注意力の重み、 f は注意力関数、 k はエンコーダにおける隠れ状態の数、 h_i は時刻 i におけるデコーダの隠れ状態、 s_j は時刻 j におけるエンコーダの隠れ状態である。

$$c_i = \sum_{j=1}^k a_{ij} s_j \quad (5.4)$$

ここで、 c_i は時刻*i*におけるコンテキストベクトルである。

注意力メカニズムの一般的な説明は次のとおりである。注意力メカニズムを構成する3つの要素がクエリ、キー、値である。クエリはキーに対応するアドレス操作を行う。キーと値は注意力の重みを計算するために使われる。クエリは h_i で表され、キーと値は s_j で表される。注意力関数 f は、類似度を計算するために使用される。計算された類似度は、抽出された値の重要度を決定する。類似度が高いほど重要度が高い。重要度に応じて抽出値の重み付き和を計算すると、コンテキストベクトルが得られる。式(5.5)は、使用可能な重み（注目度）を求めるための正規化関数である。注目関数としてスケーリングドット関数が選ばれたのは、それが高速で実行しやすいからである。

$$f(h_i, s_j) = \frac{h_i s_j}{\sqrt{d}} \text{softmax}(\quad) \quad (5.5)$$

ここで、 d は入力シーケンスの次元である。

以下では、LSTM モデルを上記のエンコーダ・デコーダ・フレームワークに組み込む。4.2 節で説明したように、従来の RNN と比較して、LSTM モデルは特殊な隠れ状態を有することに特徴がある。注意力の重みは、隠れ状態の値が次のステップに進む前に関与する。それは、エンコーダとデコーダの両方で作用する。出力は次式で計算される。

$$h'_i = \tanh(W_a[c_i, h_i]) \quad (5.6a)$$

$$\hat{y}_i = W_o h'_i \quad (5.6b)$$

以上が注意力付き LSTM モデルのプロセスである。次に、これをボトルネック部として知られている海老名 JCT の交通流予測に適用する。

5.4 データ概要

海老名 JCT は、圏央道と東名高速道路という2つの重要な高速道路が交差する場所である。非常に重要な JCT であり、ボトルネック部としても良く知られている。圏央道は、首都圏の環状道路を形成し、他のいくつかの主要な放射状高速道路とも交差する。圏央道に西側で交差する高速道路が東名高速道路である。これは、東京と名古屋を結ぶ重要なルートであ

り、NEXCO 中日本が運営する道路の中で最も交通量が多く、一部区間では 1 日に 10 万台以上の車両が利用する。図 5.5 に当該高速道路の模式図を示し、対象地域を示す。これら 2 つの基幹的高速道路の接続点である海老名 JCT が、本章の対象である。



図 5.5 海老名 JCT の概要

高速道路の交通流データに基づき、注意力付き LSTM モデルによる交通流予測を行った。保有するデータは、2017 年 9 月の ETC データセットである。生の ETC データセットには、9000 万トリップ以上の情報が含まれている。全てのトリップについて、オンランプとオフランプの名称、およびオンランプとオフランプの時刻が記録されている。本研究におけるデータ処理の重要なステップの 1 つは、生の ETC データから単位時間あたりの交通流データを取得することである。通常、オンランプを通過する単位時間あたりの交通流量は、オンランプの通過時間を集計することで算出できる。本研究では、単位時間を 15 分としている。これにより、15 分ごとにオンランプを通過するトリップを 1 つのグループとしてカウントし、各グループのトリップ数を集計した。しかし、ETC に使用されるセンサーはジャンクションエリアには設置されていない。そのため、焦点である海老名 JCT を通過するトリップ数を直接取得することはできない。

したがって、オンランプとオフランプの情報に基づいて、海老名 JCT を通過するトリップを推計した。海老名 JCT の位置に基づき、次の 3 つの条件に基づき推計した。

条件 1：オンランプとオフランプが全て圏央道上にあり、かつそれらが海老名 JCT を跨いでいる。

条件 2：オンランプが圏央道上にあり、オフランプが別の高速道路にある。

条件 3：トリップが圏央道を通過する。

条件 1 および条件 2 に該当するトリップは、環状形状である圏央道上のランプ（IC）を観察することで容易に抽出できる。条件 3 に関しては、そのトリップが海老名 JCT の通過を含んでいたかどうかを判定する必要がある。そのため、関連する NEXCO のウェブサイト上のルート検索エンジンを使用し、これに該当するかどうかを確認した。条件 3 を満たす主要な 6 つのパターンを以下に示す。

関越自動車道 - 東名高速道路

上信越自動車道 - 東名高速道路

新潟 - 東名高速道路

東名高速道路 - 中央自動車道

常磐自動車道 - 東名高速道路

東北自動車道 - 東名高速道路

選択されるルートは、交通状況、天候、運転者の好みに左右されるため、厳密な基準があるわけではない。以上により、海老名 JCT を通過した確率の高いトリップを抽出した。

次のステップでは、海老名 JCT を通過する時間を推定する。休憩場所での停車時間や道路状況など、走行過程における不確定要素を考慮し、各行程の平均速度を用いて海老名 JCT 到着時刻を推定する。計算方法を式 (5.7) に示す。

$$T_j = T_{on} + \frac{D_E}{v_{ni}} \quad (5.7)$$

ここで、 T_{on} はデータセット中のオンランプ時間、 D_E はオンランプからオンランプまでの距離である。 T_j はオンランプから海老名 JCT までの所要時間を計算する。

T_j を取得した後、本研究では 15 分間隔で交通流データを集計する。つまり、2017 年 9 月に海老名 JCT を通過した交通流量の推定値は図 5.6 のようになる。




図 5.6 2017 年 9 月の推定交通流量

5.5 数値計算結果

5.5.1 モデルフィッティング

LSTM モデルおよび注意力付き LSTM モデルは、TensorFlow フレームワークを使用して実装される。また、全てのモデルが Adam 最適化アルゴリズムを用いて学習を行う。これにより、公平な条件で各モデルの比較を行うことができる。

交通流のデータセットは 2 つに分割される。最初の 2,688 データを訓練データセットとして使用し、残りの 192 データをテストデータセットとして使用する。本研究におけるモデルへの入力、訓練データセット内の推定交通流データである。これにより、LSTM モデルおよび注意力付き LSTM モデルを用いた予測交通流値を得ることができる。

提案する注意力付き LSTM モデルの性能を、LSTM モデル、ARIMA モデル、およびランダムフォレストと比較する。これらのうち、LSTM モデルと注意力付き LSTM モデルを比較することにより、交通流予測において注意力メカニズムが果たす役割を評価することができる。これら 2 つのモデルの重要な側面は、それぞれの条件下で最適なパラメータを見つけ出す能力である。両モデルとも反復計算を実行する。調整においては、主にエポック数とニューロン数を変更する。データ量を考慮し、モデル訓練中の過学習を避けるため、小さなパラメータから開始する。未知の誤差を回避するため、実験は異なるパラメータ下で 5 回実施した。頑健性テストに合格した場合だけ、評価指標を記録する。以上の結果、評価指標の分布およびその平均値を得ることができる。

5.5.2 予測精度結果

提案する注意力付き LSTM モデルを用いて予測結果を得た。具体的な結果と注意力の重みは、訓練データセットに対するモデル学習後に得られる。次に、192 個の推定交通流データから成るテストデータセットと、予測された海老名 JCT での交通流の結果を使用して、評価指標を計算する。出力の時間間隔は 15 分である。予測結果の精度を判断するにあたり、LSTM モデル、古典的な時系列モデルの 1 つである ARIMA モデル、さらにランダムフォレストモデルの計算も行い、その精度を比較した。表 5.1 は、提案モデル、LSTM モデル、ARIMA、およびランダムフォレストの評価指標値を示したものである。

表 5.1 予測結果の最小指標値

	RMSE	MAE	マップ
注意力付き LSTM モデル	54.63	41.17	6.88
LSTM モデル	57.66	43.68	7.39
ARIMA	69.89	51.35	8.50
ランダムフォレスト	94.50	76.90	11.4

表 5.1 より、他のモデルよりも単純な構造を持つ ARIMA モデルは、LSTM モデルと比較して誤差が大きい。これは先行研究の結果とも一致する。また、ランダムフォレストも同様の予測結果を示している。全てのモデルは、比較の精度を保証するため、同じ訓練セット、テストセットおよび特徴変数を使用している。ランダムフォレストモデルの誤差が大きいのは、訓練中の特徴リストの選択が単純であったためと考えられる。

これらのモデルの中で、LSTM モデルと注意力付き LSTM モデルは良好な予測結果を示している。両モデルを比較すると、注意力付き LSTM モデルは LSTM モデルと比較して、RMSE、MAE および MAPE の数値が、それぞれ 5.6%、6.2% および 7.4% 優れている。これより、注意力付き LSTM モデルは、海老名 JCT の交通流予測においては、最も有用なモデルであることが明らかになった。

LSTM モデルと注意力付き LSTM モデルの予測能力を評価するため、さらにテストを実施した。同じ交通流値に対して異なる方法を用いた場合の予測誤差の比較を表 5.2 に示す。各表の行は、ニューロン数を固定しエポック数を可変とした場合のパラメータ変化を表し、列はエポック数を固定しニューロン数を可変とした場合のパラメータ変化を表す。

表 5.2 異なるパラメータによる予測結果の指標値
(a) LSTM モデルと注意力付き LSTM モデルの RMSE 値

(エポック、ニューロン)	(3,5)	(5,5)	(7,5)	(10,5)
LSTM	60.74	57.66	60.34	61.93
注意力付きLSTM	58.16	55.7	54.63	60.15
(エポック、ニューロン)	(3,10)	(5,10)	(7,10)	(10,10)
LSTM	57.14	67.1	59.62	61.11
注意力付きLSTM	56.37	55.24	56.98	61.59

(b) LSTM モデルと注意力付き LSTM モデルの MAE 値

(エポック、ニューロン)	(3,5)	(5,5)	(7,5)	(10,5)
LSTM	47.18	43.68	45.6	47.66
注意力付きLSTM	43.89	42.25	41.17	45.65
(エポック、ニューロン)	(3,10)	(5,10)	(7,10)	(10,10)
LSTM	43.8	51.54	45.5	47.08
注意力付きLSTM	42.6	41.38	42.99	46.81

(c) LSTM モデルと注意力付き LSTM モデルの MAPE 値

(エポック、ニューロン)	(3,5)	(5,5)	(7,5)	(10,5)
LSTM	7.77	7.39	7.88	8.42
注意力付きLSTM	7.12	7.28	6.89	7.85
(エポック、ニューロン)	(3,10)	(5,10)	(7,10)	(10,10)
LSTM	7.76	9.06	7.97	8.28
注意力付きLSTM	7.16	6.88	7.27	7.9

表 5.2 の結果から、エポック数を固定しニューロン数を徐々に増加させると、当初は指標値が減少し、収束していくことがわかる。また、ニューロン数を固定しエポック数を増加させた場合にも同様の傾向がある。さらに、注意力付き LSTM モデルは、より速く収束に達することがわかる。

LSTM モデルには、時間的依存性探索が考慮できるという特徴がある。そのため、LSTM モデルがほとんどの場合において誤差が小さくなる結果が示されている。その LSTM モデルに注意力メカニズムを組み込んだ注意力付き LSTM モデルは、時間的相関に関わる注意力行列が考慮されていることにより、LSTM モデルと比較しても誤差が小さくなっている。




図 5.7 2つの予測日における時間的注意力の重み

注意力付き LSTM がどのように誤差の縮小に効果を発揮したのかを、図 5.7 に示す時間的な注意力の重み（範囲 0～1）の推移により明らかにする。図 5.7 は、Y 軸に 1 日のモーメントをとり、X 軸は予測された日数である。本研究のデータは 15 分間隔であるため、各ブロックは単位時間ごとの注意力の重みを表す。図 5.7 からは、注意力の重みが主に 2 つの期間、午前 5 時から午前 9 時および午後 4 時から午後 7 時に大きくなっていることがわかる。さらに、午前 5 時から午前 9 時は重みがより大きく、この期間が交通流予測に対してより大きな影響を持つことを示している。一方、1 日目の午後 1 時には大きな重みが現れる。しかし、2 日目には現れない。これは不規則な現象であり、前日に何らかの特殊なケースが発生し、翌日の交通流に影響を与えたことを示唆している。これらの時間帯、特に不規則な時点の出現

は、他の予測モデルに対する注意力付き LSTM モデルの優位性を示している。注意力付き LSTM モデルにより、高速道路の交通流変化パターンをより正確に捉えることができる。これらの結果は、Sequence-to-Sequence 構造と注意力メカニズムが予測に対して有効であることを示している。

さらに、交通流の予測においては、ピーク時間の存在に着目する必要がある。すなわち、予測精度を向上させるためには、ピークと非ピークあるいは平日と休日（週末を含む）を分離して考慮する必要がある。注意力メカニズムの利点は、モデル訓練プロセスにおいて、このような異なる時間帯の重みを学習できることにある。図 5.7 が示すように、数回の訓練により異なる時間帯での注意力の重みを獲得する。特に ITS の発展に伴い交通データの量は増加している。注意力付き LSTM モデルを使用すれば、重みによりデータ特性が分類できることから、事前にデータ分類を行う必要がない。これは、事前のデータ処理の作業負荷を大幅に軽減でき、かつより高精度な予測結果を得ることにつながる。これが注意力付き LSTM モデルの最大の特徴といえる。

5.6 本章のまとめ

本章では、注意力付き LSTM モデルを提案し、注意力付き LSTM モデルに基づく交通流予測を行った。対象地域は海老名 JCT とし、海老名 JCT に関係する IC ペア（オンランプとオフランプ）を選択して、高速道路データセットから海老名 JCT を通過したトリップを推計した。その後、得られたデータセットからモデルの学習および交通流の予測結果の検証を行った。ここでは、15 分間隔で集約した交通流データセットを用いた。

その結果、時間的注意力メカニズムをエンコーダ・デコーダ・フレームワーク内に組み込み、交通流シーケンスを入力する。時間的注意力メカニズムはデコーダに影響を与え、各時間ステップに対して注意力の重みを与える。MAE、RMSE および MAPE を評価指標として使用し、予測結果を評価した。その注意力付き LSTM モデルの予測結果と、通常の LSTM モデル、さらに ARIMA モデル、ランダムフォレストとの予測結果との比較を行った。それより、LSTM モデルでも交通流を良好に予測できたものの、注意付き LSTM モデルによって、交通流をより効果的に予測することができた。

以上の分析結果をまとめると、以下ようになる。

1. 注意力付き LSTM モデルは、エポック数とニューロン数が少ない場合に良好な予測結果を得ることができる。エポック数とニューロン数が少ないということは、時間とコストが少ないということであり、現実への適用における意義は大きい。
2. 同じパラメータを使用した場合、注意力付き LSTM モデルは従来の LSTM よりも誤差が小さい。
3. 結果は、注意力付き LSTM モデルがより速い収束率、より小さい誤差およびより優れた予測性能を有することが示された。

第6章 AI モデルに基づく交通事故の重大性要因分析

前章では、主に高速道路の IC 間の交通流を予測するために LSTM モデルの適用について、予測精度の検証を行った。また、LSTM モデルでの予測にあたり、常々指摘されているブラックボックス問題を解消するため、注意力メカニズムを組み合わせることで JCT における交通流を予測した。

高速道路では、交通流予測に加えて、交通事故という重要な研究テーマが存在する。高速道路は、車両速度が高速であることから一般道路とは異なる特性を有し、そのため高速道路で発生する交通事故は一般道路の交通事故より、重大事故になる可能性が高い。

そこで本章では、高速道路上の交通事故に対し、AI 手法を適用して交通事故の重大性に寄与する要因を分析する。そして、各要因が交通事故にどのような影響を及ぼすかを明らかにし、交通事故防止策検討の一助とする。

6.1 既存研究の整理

既に多くの研究が、交通事故の重大性と、交通状況や幾何学的情報、車両や運転者の情報など、様々な要因との関係を分析している。その研究対象や研究方法は多岐にわたる。本節では、交通事故の重大性に影響を与える要因に関する既存研究を整理する。交通流予測研究と同様に、AI モデルによる良好な結果が得られており、またその応用が拡大していることから、主に AI 手法に基づく研究に焦点を当てる。以下に、先行研究の成果と課題を整理する。

Shaik et al. (2021) は、深層学習技術を含む様々な種類のニューラルネットワークモデルによる事故予測モデルの開発状況をレビューしている。合計 33 件の論文をレビューし、事故の重大度を評価するための様々なニューラルネットワークモデルを分類している。Shaik et al. は、レビューしたモデルが精度と信頼性の点で有益な結果を示していると述べている。さらに、Kumar et al. (2022) は 3 つの異なる機械学習アルゴリズムを提案した。彼らは、これらのモデルがどの程度正確に事故の深刻度を予測できるかを調査するため、米国の実際の交通事故データでこれらをテストした。その結果、提案された事故深刻度予測フレームワークにより、先行研究と比較して 3.55% 精度の向上したことが明らかになった。Daniel et al. (2021) は、交通事故と事故多発地点（ホットスポット）に焦点を当てて分析を行っている。そこでは、決定木を作成しルールを生成するために C5.0 アルゴリズムが使用されている。さらに、教師あり機械学習であるランダムフォレストおよびロジスティック回帰ならびに教師なし機

機械学習である DBSCAN および階層的クラスタリング法が予測モデルとして使用されている。その結果、ランダムフォレストが事故多発地点を予測する上で有効なツールであることが示された。しかし、この論文では各変数の分析が不十分である。例えば、この論文の結論では、オートバイ事故が事故の重大性に影響を及ぼす主な変数とされているだけであり、さらに詳細な要因分析が必要であるといえる。

交通事故予測の効率と精度を向上させるため、融合モデルに注目する研究者がいる。Mubariz et al. (2016) は RFCNN モデルを提案しており、その名称が示唆するように、RFCNN は交通事故の重大度を予測するためにランダムフォレスト (RF) と畳み込みニューラルネットワーク (CNN) モデルを組み合わせたアンサンブル学習モデルである。RFCNN モデルでは、CNN モデルが入力データから特徴を抽出するために使用され、RF モデルが抽出された特徴に基づいて重大度を分類するために使用される。米国の交通事故データセットで検証した結果、この融合モデルは高い精度を有している。さらにこの研究では、ツリーベースのアンサンブル手法が非線形解を学習する能力を有するため、事故の重大度予測においてより優れた性能を示したことが明らかになった。したがって、異なる変数と結果との間の非線形関係を分析するためには、ツリーベースの機械学習モデルが有用であるといえる。

また、データと変数の選択もまた重要な問題である。Jeong et al. (2022) は、ソウルにおける交通事故について、傷害の重傷度に影響を及ぼす主な要因と類型に焦点を当て、包括的な分析を行った。予測に関しては、交通事故の重傷度を予測するのに有効であり、その的中率は 80% 以上であることが判明した。天候や舗装状況といったいくつかの重要な変数が分析に含まれていなかったことを考慮すると、この結果には改善の余地があるともいえる。Yang et al. (2022) は、中国国家自動車事故システムのデータを用いて、事故の深刻度を予測する革新的なアプローチを発表した。この研究では、ランダムフォレスト・アルゴリズムがその高い性能を有することが示された。そこでは、13 の変数が挙げられているものの、データの種類が不十分であったため、結論には限界があった。より質的な分析と、詳細な量的分析を行うことが、これらの研究には必要である。

上記のような文献を検討した結果、交通事故の予測や要因分析、事故の重大性に関する研究は数多く存在するものの、依然として課題が存在する。特に AI の発展に伴い、人工知能や機械学習などの手法が単一モデルでも、またハイブリッドモデルでも受け入れられつつあり、多くの良好な結果が得られている。一方で、機械学習は高い精度を伴うものの、そのブラックボックス的な性質のため理由や計算処理を探究することが困難である。結果を可視化し、解釈可能にすることこそが課題である。また、変数と事故の重大性の間に非線形関係が存在することは分かっているが、具体的にどのような非線形関係が成り立つのかは明らかになっ

ていない。多くの論文が定性的な分析を行っていることを考慮すると、定量的な分析、特に非線形関係の分析を行うことは、得られた知見を実用化する上で極めて重要である。

本章は、AI モデルの視覚的な解釈可能性と、各要因と事故の重大性の間の非線形関係の両方の分析を行う。さらに、様々な機械学習手法や他の変数の予測結果も調査し、交通事故分析における AI モデルとその可視化の信頼性の向上を目指す。この目標を達成するため、適切なデータと AI モデルを選択して議論を行う予定であり、その概要を以下に簡潔にまとめる。

AI モデルの選択においては、前述の文献レビューを通じて、データの状況や適用シナリオを考えた結果、交通事故の重大性の研究ではランダムフォレストと XGBoost モデルが有用と判断した。

XGBoost (Extreme Gradient Boosting) は、ツリーベースモデルと機械学習モデルの両方の利点を統合したものであり、本研究ではこれを採用している。XGBoost モデルは、その効率性と優れた性能で知られている。並列処理による迅速な学習が可能であり、外部からの補完 (imputation) なしに欠損データを管理できる。さらに、各反復処理において統合された交差検証 (cross-validation) がモデルの精度を高め、XGBoost は多様な予測のために強力かつ正確で効率的なツールになる。

XGBoost モデルも一種のツリーモデルであるため、この種のモデルの付加的な特徴として、「SHAP」(SHapley Additive exPlanations) と呼ばれる解釈可能なツールを使用して結果を構造化し分析できる。すなわち、SHAP はモデルの可読性を向上させられるといえる。

SHAP は、予測に対する個々の変数の寄与を定量化でき、機械学習モデルの出力を解釈するための強力なツールになる。その能力は、結果に対する正負の影響も区別でき、6.3 節で説明・要約するように、特徴の重要性を明らかにできる点にある。

6.2 研究対象地域とデータ

首都圏の高速道路の中でも最も交通量の多い東名高速道路を対象にする。東名高速道路は、最も混雑する高速道路の一つであり、他の中央自動車道などと比較しても交通量が多い。2019 年の年間車両走行台数は 753.6 億台 km、年間事故総数は 3,598 件に上る。対照的に、中央自動車道の年間事故件数は 2,433 件である。交通事故に関しては、東名高速道路の上り線での事故が多く、特に東名高速道路の終点(上り)である東京 IC での事故が多発している。また、御殿場 IC 以西の区間における事故件数や交通流量は散在している。そこで本章では、東名高速道路の御殿場 IC から東京 IC までの上り区間を調査対象とした。この区間は全長 83km に

及び、10箇所のランプ（IC/JCT/SIC）を含んでいる。ランプは東から、東京 IC、東名神奈川 IC、横浜青葉 IC、横浜町田 IC、海老名 JCT、厚木 IC、伊勢原 JCT、秦野中井 IC、大井松田 IC、足柄 SIC、御殿場 IC となっている。

生データは、日本高速道路株式会社各社によって収集された事故調査データである。不完全および不正確な入力除外するため、広範なデータクリーニングとフィルタリング処理を経た後、最終的なデータセットは 701 件になった。表 6.1 は、交通事故調査データの詳細な内訳と統計値を示している。

表 6.1 に含まれる 13 変数は、事故現場を可能な限り正確に再現するように構成されている。全 13 変数を大別すると、運転者・車両要因と環境要因の 2 つのグループに分けられる。これらの変数のうち、変数「KP（キロポスト）」は高速道路の起点（0km 地点）からの位置を表す。事故の重大性分析において、KP は事故発生地点の地形詳細を捉える変数としての意味を持つ。

事故調査データのうち、事故の重大性は、各事故における死傷者数として記録され、無傷、軽傷、重傷、死亡の 4 つのカテゴリに分類される。事故の重大性を定量化するために、事故指標 BASIC（Behavior Analysis and Safety Improvement Category）に従って事故重大性スコアを導入する。事故重大性スコアは以下のように計算される。

$$\text{事故重大度スコア} = 1 \times (\text{軽傷者数}) + 2 \times (\text{重傷者数}) + 3 \times (\text{死亡者数})$$

事故の重大性はこのスコアによって反映され、スコアが高いほど重大性が高いことを表す。負傷者がいない場合は 0 点となる。以下では、上記の 13 変数を用いて、この事故重要性を分析する。

表 6.1 事故調査データに基づく従属変数と独立変数の記述統計量

変数	説明	平均
従属変数：事故重大度スコア		
事故の重大度スコア	各事故のスコア	0.41
独立変数：		
時間帯	事故が発生した時刻	12.43
曜日	事故が発生した日 (1=月曜日、2=火曜日、3=水曜日、4=木曜日、5=金曜日、6=土曜日、7=日曜日、8=祝日、ダミー)	4.87
ルール違反	運転者が違反したルールの種類 (1=不適切な積載、2=疲労運転、3=不適切なハンドル操作、4=不適切なブレーキ操作、5=安全運転義務違反、6=漫然運転、7=速度違反、8=後方安全未確認、9=その他、ダミー)。	5.63
速度 (km/h)	事故が発生した速度 (5km/h単位で記録)	56.37
アクシデントポジション (KP)	事故が発生したキロポスト位置	34.49
運転者の年齢	運転者の年齢	41.06
運転者の性別	運転者の性別	1.07
車両タイプ	事故に関与した車種 (1=乗用車、2= 両用車、3=貨物車、4=その他、ダミー)	1.58
天気	事故当時の天候 (1=晴れ、2=曇り、3=霧、4=雨、ダミー)	1.79
レーンズ	事故が発生した車線 (1=第1走行車線、2=第2走行車線、3=追い越し車線、4=登坂車線、5=加速流入車線、6=減速流出車線、7=路肩、8=その他)	2.49
混雑状況	事故発生時の混雑状況 (0=混雑キューに入っていない、1=混雑キューに入っている、2=混雑キューの最後尾、ダミー)	0.77
サンプルサイズ		701

6.3 事故調査データに基づく分析

本節では、事故調査データに記録された変数とデータに基づき、事故の重大性に影響する要因を分析する。用いるモデル（AI モデルを含む）は次のとおりである。

6.3.1 事故調査データ

事故調査データには多くの変数が含まれているが、道路建設に関連する情報は少ない。まず、本節ではデータソースを拡大し、特に道路建設に関連するものも含む。地形情報データとして、日本高速道路株式会社各社から提供された水平線形長（km）、緩和曲線半径（km）、曲線種別などを収集した。それらも位置が記録されており、事故位置情報（KP）を使用して事故と地形情報データが照合できる。表 6.2 は、地形情報データの記述統計であり、水平アライメント長（km）、緩和曲線半径（km）、カーブ種別、横断勾配（%）、勾配種別が含まれている。

表 6.2 地形データの概要

変数	説明	平均
地形変数：		
延長直線（km）	同じ水平直線が続く長さ	1.11
緩和曲線半径（km）	直線と円曲線を結ぶ曲線の半径。	1.46
カーブタイプ	異なる種類の平面線形（0＝直線、1＝半径増加の緩和曲線、2＝半径減少の緩和曲線、3＝円曲線）	2.15
横断勾配（%）	横方向（左右）の勾配のこと	2.54
勾配種別	勾配のタイプ (1=片勾配、2=逆勾配)	1.09
サンプルサイズ	701	

表 6.3 事故調査データと地形データに基づく従属変数と独立変数の概要

変数	説明	平均
従属変数：事故深刻度スコア		
事故の重大度スコア	各事故のスコア	0.41
独立変数：		
時間帯	事故が発生した時刻	12.43
速度 (km/h)	事故が発生した速度 (5km/h単位で記録)	56.37
運転者の年齢	運転者の年齢	41.06
車両タイプ	事故に関与した車種 (1=乗用車、2=両用車、3=貨物車、4=その他、ダミ)	1.58
路面状態	路面の濡れた状況 (1=濡れ、2=曇り、3=乾き)	1.23
レーンズ	事故が発生した車線 (1=第1走行車線、2=第2走行車線、3=追い越し車線、4=登坂車線、5=加速流入車線、6=減速流出車線、7=路肩、8=その他)	2.49
混雑状況	事故発生時の混雑状況 (0=混雑キューに入っていない、1=混雑キューに入っている、2=混雑キューの最後尾、ダミー)	0.77
交通量	事故発生時の交通量	173.23
延長直線 (km)	同じ水平直線が続く長さ	1.11
緩和曲線半径 (km)	直線と円曲線を結ぶ曲線の半径。	1.46
カーブタイプ	異なる種類の平面線形 (0=直線、1=半径増加の緩和曲線、2=半径減少の緩和曲線、3=円曲線)	2.15
横断勾配 (%)	横方向 (左右) の勾配のこと	2.54
勾配種別	勾配のタイプ (1=片勾配、2=逆勾配)	1.09
サンプルサイズ		701

他の変数については、表 6.1 の運転者の性別は、「1」が男性、「2」が女性である。この平均値はわずか 1.07 であり、これは女性運転者の割合が非常に低いことを意味する。もう一つの天候は、多くの研究において不可欠なものである。表 6.3 は、このデータセットでは悪天候が少ないことが示されている。天候の最も直接的なフィードバックは路面の状態（湿潤、一部湿潤、乾燥など）であることを考慮し、この分析では天候変数ではなく、路面状態の変数を使用した。

使用した変数を表 6.3 に示し、合計 13 の変数を道路要因、運転者と車両要因、環境要因の 3 つのグループに分類する。事故の重大性分析の評価指標は、6.2 節と同じで、事故の重大度スコアを用いている。

6.3.2 XGBoost 法によるモデル作成

XGBoost は、eXtreme Gradient Boosting の略である。このアルゴリズムは、2001 年に Friedman によって Gradient Boosting フレームワークの下で提案され、2014 年に Chen と Guestrin によって開発された。XGBoost の最大の特徴は、ツリー構造に基づく機械学習手法という点にあり、高い効率性、柔軟性および移植性を有する。

ツリーベースのモデルとしては、決定木とランダムフォレストが最もよく知られている。ランダムフォレストは、決定木を並列に用いて構築され、最終的な予測は全ての決定木の予測の平均となる。しかし、XGBoost はツリーベースモデルであるものの、それに加えて「ブースティング」という概念による逐次的モデルでもある。新しいツリーは前のツリーの弱点を補うために改善され、最終的な予測は全てのツリーの予測の重み付き平均になる。他の機械学習手法、特にニューラルネットワークモデルと比較すると、XGBoost、ニューラルネットワークとも強力な機械学習アルゴリズムである。しかし、ツリーベースである XGBoost モデルは、構造が単純で、より小さなストレージの占有で済むため、高い計算速度が可能になった。

これらの説明から明らかなように、XGBoost は勾配ブースティングとツリーモデリングの利点を組み合わせ、計算速度、欠損値処理、過学習抑制および予測汎化能力の点で優れている。特に速度とモデル性能の観点から、学術研究や産業界でも広く適用されている。

XGBoost は、モデルを最適化するため、4 つの主要なパラメータが考慮されている。

- (1) ブースティング・ラウンド数(n): このパラメータは一般的にモデル性能を向上させる。
- (2) 学習率(eta): 各ブースティング反復におけるステップサイズを制御する。学習率を小さくすると、モデルはよりロバストになる。
- (3) 各決定木の最大深さ(d): モデルの複雑さのレベルを制御し、オーバーフィッティングを防ぐのに役立つ。

(4) 各ノードに必要な最小インスタンス数(m):これは、モデルが少ないサンプルでノードを作成するのを防ぎ、オーバーフィッティングを回避するのに役立つ。

RMSE と MAE は、パラメータと係数の選択によって、高い予測精度が得られたかを測る評価指標として用いられる。

6.3.3 SHAP 法によるモデル解釈

XGBoost モデルの計算により、事故の重大性と複数の変数との関係を定量的に明らかにできる。ただし、他の機械学習モデルと同様に、XGBoost モデルは事故の重大性に対する各変数の局所的な数値結果での精度の確保には限界がある。より有用な情報を得るために、本研究では SHAP を採用し、事故の重大性に対する各要因のローカルおよびグローバルな影響を明らかにする。SHAP アプローチは、Lundberg and Lee (2017)により示されたものである。SHAP は、式(6.1)に示すように、解釈値を線形モデルとして計算できる。

$$f(x) = g(z') = \varphi_0 + \sum_{i=1}^M \varphi_i z'_i \quad (6.1)$$

ここで、 $f(x)$ は指定されたモデルにおける訓練データセットの予測値であり、ここでは XGBoost モデルによるものである。 $g(z')$ は説明モデルであり、 $f(x)$ の近似式である。また、説明モデルは定数 φ_0 を有し、訓練データセットの予測平均値を表す。 $\varphi_i z'_i$ は関連因子のシャプレー値で、個々の因子が観測されたかどうかを示す。 $z'_i \in \{0,1\}$ は、現在の意思決定処理で各要因が観測されたかどうかを示す（1 は観測されたことを意味し、0 は最終値への寄与がないことを意味する）。シャプレー値の計算に関しては、以下の通りである。

$$\varphi_i = \sum_{S \subseteq M \setminus \{i\}} \frac{|S|!(M-|S|-1)!}{M!} [f_x(S \cup \{i\}) - f_x(S)] \quad (6.2)$$

ここで、 M は因子の総数であり、 S は以下の因子を除いた全因子の部分集合である。 $|S|$ はこの部分集合のサイズである。 $[f_x(S \cup \{i\}) - f_x(S)]$ は因子 i の限界寄与率を示す。 S の部分集合の相対的な重みは $\frac{|S|!(M-|S|-1)!}{M!}$ で表される。

SHAP は、解釈可能性において、理論的な優位性を有する。上記の計算に基づき、事故の重大性とその寄与変数との関係が明らかになる。次項では、さらなる分析を行い、これらの予測結果を示す。

6.3.4 数値計算結果

XGBoost 法は、Python 環境による Scikit-learn パッケージを使用して実装した。まず、事故データセットをランダムに、訓練用サブセット（全データの 70%）とテスト用サブセット（全データの 30%）に分割する。また、上記の 4 つのパラメータの最適な組み合わせを決定するために、グリッドサーチアプローチを採用した。最適モデルは、 $n=50$ 、 $eta=0.015$ 、 $d=9$ 、 $m=2$ のときになった。XGBoost による計算の後、SHAP により事故の重大性と各変数の間に存在する潜在的な関係を明らかにする。まず、図 6.1 に、各変数の順位と重要度を示す。

(1) 独立変数の相対的重要度

御殿場 IC-東京 IC 間における上位 5 変数は、図 6.1 に示すように、緩和曲線の長さ、緩和曲線の半径、運転者の年齢、渋滞状況、車種である。上位 5 変数のうち、2 変数が道路要因、2 変数が車両・運転者要因、1 変数が環境要因に属する。色と密度のドットの分布から、以下の考察が得られる。




図 6.1 独立変数の相対的重要度

図 6.1 の渋滞状況は、右側に位置するドットの大部分が赤色であり、左側のドットの大部分が青色である。赤色は、渋滞状況という変数の値が大きいことを示しており、渋滞の末尾に位置する車両は、事故発生時に重大性が高くなる可能性の高いことを示している。また、渋滞列内の車両は、事故により負傷に至る可能性はそれほど高くなかった。さらに、路面状態も同様の分布を示している。図 6.1 の路面状況は、湿潤路面で発生する交通事故の方が負傷者の出やすいことを示しており、これは直感とも一致する。これに対し、時間帯の分布では異なる色のドットが右側に混在してプロットされており、この結果だけでは、時間帯と事故の重大性との関係を判断することはできない。個々の変数とその影響、特に複雑な非線形関係を分析する際には、各変数の独立性を考慮する必要がある。

(2) 事故の重大性に対する変数の非線形効果

前項での全体的な分布を把握した後、変数ごとの分析に移る。交通事故の重大性に最も影響を与える変数から始める。

緩和曲線の長さは、現在の水平アライメントが持続する距離を指す。図 6.2(a)から、分布曲線全体が U 字型であることがわかる。長さが 0.3km 未満の場合、SHAP 値は 0 より大きく、ドットはより集中している。これは、同じ水平アライメントの続く長さが 0.3km 未満の場合、交通事故がより重大化しやすいことを意味する。ここから推測できることは、長さが短い場合には水平アライメントが、より変化することを意味し、それが重大事故につながる可能性があるということである。水平アライメントの続く長さが 0.3km から 1.8km の間の場合、SHAP 値は 0 未満であり、このときは重大性に影響を与えない、あるいは負の影響を与えることを示している。それが 1.8km を超えると、SHAP 値が 0 より大きくなるだけでなく、分布も広がる。これは、図 6.2(b)に示すように、他の変数間の相互作用の生じている可能性を示している。図 6.2(b)は、水平アライメントの長さと緩和曲線の半径の関係を反映している。図 6.2(a)とは異なり、ここでの各ドットの色は図 6.2(b)における半径の数値を表している。図 6.2(b)の分布によると、0.3km～1.8km の区間では、この区間の半径はほとんどが 2km を超えており、半径の大きさに関わらず SHAP 値はほとんどが 0 未満である。これは事故の重大性に対して負の影響があることを意味する。長さの区間が 1.8km より大きい場合、半径のほとんどは 1.5km 未満であり、これは長距離のカーブした道路を運転することが事故の重大性につながりやすいことを示唆している。




図 6.2 水平アライメントの長さの SHAP 値プロットが事故の重大度に及ぼす影響
(a)長さの SHAP 値-左、(b)相互作用の SHAP 値-右)

また、U 字カーブとは独立して、長さ 4.2km の地点で SHAP 値が 0 を超える一連のドットが存在する。元データと高速道路地図を参照すると、これらのドットは、関東地方で最も

利用されている海老名 SA（サービスエリア）周辺、および圏央道と接続する海老名 JCT（ジャンクション）付近で発生した事故を指す。これは、海老名 SA と海老名 JCT の管理を強化する必要があることを示している。

図 6.3(a)に示す緩和曲線の半径の結果に移る。この結果は SHAP 値に基づいて、SHAP 値が 0 より大きい部分と SHAP 値が 0 未満の部分との 2 つに分けられる。半径 2km が境界値となっており、半径が 2km 未満の場合、ほとんどの SHAP 値は 0 より大きく、これはより重大な事故を引き起こしやすいことを意味する。対照的に、半径が 2km より大きい場合、ほとんどの SHAP 値は 0 未満である。さらに、緩和曲線の半径が 4km より大きい場合、ほとんどの SHAP 値が 0 未満であるものの、SHAP 値の平均値は 2km~4km の区間と比較してわずかに大きい。これは、重大性を軽減するためには、半径を 2km~4km の範囲で設計することが有効であることを示唆している。




図 6.3 4 変数の SHAP 値プロットが事故重大度に及ぼす影響

運転者の年齢と重大性の関係を見ると、図 6.3(b)から興味深い結果が観察できる。一般的な認識とは対照的に、負傷しやすいのは高齢者ではなく、むしろ 30 歳以下の若年層、特に 27 歳以下の者である。

27 歳以下の若い運転者の SHAP 値は高齢運転者のそれを著しく上回り、最高値では 5 倍に達した。このハイリスクなデータは、若い運転者の運転経験の乏しさと過信に起因すると考えられる。しかし、運転者が 27 歳に達すると、SHAP 値は徐々に 0 まで減少し、これはおそらく運転技術の向上を示している。30 歳から 70 歳の範囲では、運転者は負の SHAP 値を示し、重大事故の可能性が低いか、または事故が発生した場合でも比較的軽微にとどまる傾向を示している。このグループに続くのは 70 歳以上の運転者であり、彼らは豊富な運転経験を持つ可能性があるにもかかわらず、しばしば反応時間が長くなり、これが事故の重大性を増加させる一因になっている。

警視庁提供の別のデータによると、2023 年の統計データに基づけば、29 歳以下の運転者は全運転者人口の 13%を占める。その一方、70 歳以上の運転者は 1300 万人を超え、全体の 16.2%に相当する。ハイリスクグループは全運転者人口の 29.2%を占めており、これらの年齢層に、一層の注意を払うことが極めて重要である。

次に、いくつかの特徴的ではあるがランクの低い変数を分析する。本研究の横断勾配は、図 6.3(c)に示すように 3%を境界点として 0%~9%の間である。勾配が 3%以下の場合、SHAP 値はほとんどが 0 未満である。勾配が 3%より大きい場合、SHAP 値は負の値から正の値へと急速に増加し、横断勾配は事故の重大性に寄与する変数となる。横断勾配が 3%より大きい場合、SHAP 値の変化は顕著ではない。これは、可能な限り 3%を超える横断勾配を避けるべきであることを示唆し、しかし、地形や建設上の理由から横断勾配が 3%を超えなければならない場合、SHAP 値が重要でないことを考慮すれば、必ずしも低い横断勾配を追求する必要はないことを示している。

続いて、図 6.3(d)で速度が事故の重大性に与える影響を分析する。SHAP 値は 2 つの部分に分類できる。最初の部分は時速 30km 以下に対応し、そこでは SHAP 値は 0 未満を維持している。これは、これらの車両が交通渋滞に巻き込まれていたとしても、低速での運転が事故の重大性に対しては抑制的な効果を持つことを示している。時速 30km を超えると SHAP 値は 0 を超え、事故の重大性の可能性が高まる。さらに、速度が時速 100km に達すると SHAP 値は最大になり、速度が事故の重大性に大きな影響をもたらしていることがわかる。

6.4 本章のまとめ

本章では、高速道路の交通事故データを用いて、事故の重大性に対する各変数の寄与の程度を定量的に明らかにした。使用した AI モデルはランダムフォレストおよび XGBoost モデルである。

事故発生地点に関しては、御殿場 IC から東京 IC までの区間で、KP 値が 40KP を超えるエリアにおいて、事故の重大性が高まっている。特に、大井松田 IC・足柄 SIC 間では、65KP 付近および 70KP～75KP の範囲において重大事故が増加している。これらの区間には、地形特性上、上り坂と下り坂が混在し急カーブが連続する。これにより、運転の困難さが生じ、重大事故につながっているものと考えられる。この結果より、こうした道路状況に不慣れな運転者に対しては、警告を発する必要がある、そのための標識設置等が必要といえる。複数の標識を設置したり、路面上の進行方向矢印を導入したりすれば、運転者にとって視覚的および触覚的な注意喚起になり、交通事故の重大性抑止につながる。

重大事故が発生しやすい約 50KP の周辺は、大型車両の比率の高さと、SA または PA の集中によって、危険性が高まっている。これは、大型車両専用の交通車線の導入を要求するものである。また、SA・PA の新規設置または既存 SA・PA 施設の改修において、IC との距離に配慮が必要であることを示唆している。以上の知見に基づき、交通事故およびその重大化抑止のための対策および政策が検討されるべきといえる。

これらの結果より、地理的位置が交通事故の重大性に影響を及ぼしている。そこで、次にそれらの地点での地形情報について、追加的な検討を行った。研究対象の東名高速道路は、延長 83km のうち直線部分はわずか 4% である。対象区間の起点である御殿場 IC は富士山の麓に位置し、御殿場 IC から東京 IC までは山々を縫うように道路が建設されている。そのような地形の幾何学的要因と事故の重大性との関係を分析した。

これに関し、6.3 節では合計 13 の変数を追加的に検討した。これらは、道路、車両と運転者、および環境という 3 つの主要因に分類できる。そこから、各変数が事故の重大性に与える影響を分析した。このうち上位 5 つの影響要因は、水平アライメントの長さ、緩和曲線の半径、運転者の年齢、渋滞状況、および車種であり、これらのうち 2 つは地形に関するものである。

水平アライメントの長さと緩和曲線のカーブ半径は、重要度ランキングの上位 2 つの変数である。ただし単純に、水平アライメントの長さが長い、または緩和曲線の半径の大きいことが、必ずしも事故の重大性を低減するわけではない。全体として、事故の重大性を低減するためには、長さが 0.3km から 1.8km の間、または半径が 2km から 4km の範囲にある場合が適切である。これは、事故の重大性を減少させるための道路設計および建設に新しい知見

を提供している。地形に応じて、直線的な道路の設置という方向性のみを追求するのではなく、水平アライメントは長さを 0.3km~1.8km の間とし、緩和曲線のカーブ半径は 2km~4km の間とすることで、事故の重大性を軽減できる。このもう一つのポイントは、必ずしも高速道路走行の場合、道路が直線的であることが安全を保障するというものではない。適度なカーブは運転に一定の良好な刺激を与え、その走行をより安全なものにする可能性が示唆された。

次に、横断勾配についてその境界点は 3% であり、勾配が 3% 以下の場合、SHAP 値がほとんど 0 未満であり、交通事故の重大性への影響はほとんどないといえる。横断勾配が 3% を超えると、SHAP 値は負値から正値へ急速に増加し、事故の重大性に大きく寄与することになる。しかし、横断勾配が 4% より大きくなると、SHAP 値はあまり変化しなくなる。これより、横断勾配は可能な限り 3% 以下に保つべきであることが示唆されている。

運転者と車両に関連する変数については、主に運転者の年齢と速度に焦点を当てた。これら 2 つの変数の分析結果からは、使用した変数や AI モデルに違いがあるにもかかわらず、傾向が類似していた。まず年齢に関する知見では、高齢運転者だけでなく 27 歳以下の個人も事故の重大性に寄与していることが明らかになった。その理由は、若年層は「ペーパードライバー」の割合が高く、実際の道路での運転経験が不足しているからといえる。この発見は、例えば、より実践的な教習の提供、高速道路での警告標識の増設などが必要であることを示唆している。

一方、高齢運転者は、主に反応時間が長くなるという生理学的側面が影響する。高齢運転者にとって、安全意識の強化は極めて重要であるが、快適な運転および休憩環境を確保することも同様に重要である。高齢運転者が旅行中に自身の身体的健康状態を把握するのを助けるため、電子血圧計のような健康監視装置を備えた指定休憩エリアを SA に設置することなども検討に値する。

速度に関しては、速度が時速 30km を超えると、SHAP 値が 0 を超え、事故の重大性の可能性の高まることが示された。そして、その影響の度合いは、速度が増すにつれて徐々に高くなった。そして、速度が時速 100km を超えると SHAP 値は最大になり、事故の重大性に大きく関与することが明らかになった。これに対しては、ベース車両による巡航やパトロールカーによる監視および CCTV カメラの設置など、運転速度の規制を引き続き強化する必要がある。

渋滞状況の変数については、図 6.1 と図 6.3 から、渋滞列の末尾に位置する車両が交通事故で重大性が高くなる傾向にある。実際には、多くの運転者が追従走行をする習慣がある。そのため、渋滞列の末尾では追従車両が追突事故を起こし、それが重大なものになる可能性があるといえる。これを防ぐには、渋滞列の末尾の位置を早めに特定すること、その渋滞末

尾付近での警戒情報を提供すること、さらには渋滞末尾での追突事故の危険性を周知し、普段から車間距離を保って安全運転することの啓発が重要といえる。

本章では、重要な知見が様々得られた。しかし、さらなる研究を進める余地がある。一つは、データに関するものである。今回のデータは、女性運転者のサンプルが少なくほとんどが男性運転者であった。そのため、本研究では性別の影響を明らかにすることができなかった。今後は、データ収集を進め、男性と女性の運転行動の違いを分析する必要がある。加えて、本研究で採用したモデルは、東名高速道路でより良い結果を得たことから、他の高速道路でも検証することが望ましい。対象範囲とデータを拡大し、手法の検証をさらに進めていき、モデルの精度を向上させることが重要になる。

第7章 おわりに

社会経済の発展に伴い、自動車保有台数が増加し、高速道路の延長も順調に伸長してきた。それに伴い、様々な課題も顕在化している。交通研究において、高速道路における交通流と交通事故を分析することは、道路の安全性と効率性を向上させるために極めて重要である。AI モデルをはじめとする最先端技術を活用し、正確な交通流の予測を行い、様々な交通パターンを分析することは、積極的な交通管理において重要な役割を果たす。これにより、渋滞の緩和や高速道路全体の効率向上に貢献できると期待される。都市部が拡大し、高速道路が利用されるようになるにつれて、正確な交通流予測の重要性と緊急性はますます高まっている。

一方、現在の交通安全研究に欠かせないのが、事故の重大性分析である。交通ネットワーク、特に高速道路における交通量の増加に伴い、事故の重大性を増幅させる要因や条件の把握が不可欠となっている。本研究では、東名高速道路における交通事故の特性と重大性について検討した。これらの分析は、事故の深刻さをもたらす要因の複雑な相互作用を解明するだけでなく、情報に基づいた介入、政策提言、インフラ改善への道を開くものである。

7.1 本研究の主な成果と貢献

本研究の貢献は、日本の高速道路という特殊な環境における交通流解析と事故解析において、AI モデルを適用し、貴重な分析結果を得たことである。方法論的には、AI モデルから得られた結果を分析・解釈するために、一連の AI モデルとその説明ツールを組み合わせで実装した。具体的には以下の通りである。

高速道路の IC 間における交通流シミュレーションと予測

高速道路 JCT における交通流の予測と解釈

高速道路における交通事故の重大性の要因と相互作用の分析

7.1.1 IC 間での交通流予測

ETC の交通流データを用いて、東京圏の西側に位置する八王子 IC と観光名所に近い河口湖 IC 間の交通流を分析した。第4章では、過去のデータを利用し、AI モデルと従来の交通分析モデルの融合により、リアルタイムでの交通流予測を行った。

用いた AI モデルの中で、LSTM ベースのモデルは、精度と信頼性の面で従来のモデルを常に上回っていることが示された。LSTM モデルは RNN の一種であり、メモリブロックを含むことから時系列を良好に扱うことができる。

第 4 章では、中央自動車道の八王子 IC-河口湖 IC 間の交通流データを適用し、従来の予測手法である ARIMA では誤差を表す RMSE が 621.558 であり、さらに、休日情報と天候を考慮すると、RMSE は 490.543 に向上した。一方、LSTM モデルは交通流変動の傾向を、ARIMA や他の時系列ベースのモデルと比べ良好に予測でき、LSTM モデルの予測精度の高いことが示された。

7.1.2 ボトルネックにおける交通流予測

LSTM による交通流予測は広く行われ、良好な結果が得られている。しかし、研究対象は IC 間交通流に限定されており、JCT などへの適用には課題があった。そこで、第 5 章では研究対象を海老名 JCT に拡大した。海老名 JCT は、東名高速道路と圏央道という 2 つの重要な高速道路の交差点に位置し、構造が複雑で交通量が多く、交通流の予測が困難であった。また、より詳細な交通流予測を実施するため、時間間隔を 15 分間にしている。

予測モデルの選定では、第 4 章で LSTM の性能が良好であったことを考慮し、引き続き LSTM モデルを適用した。それに加えて、LSTM モデルをベースに注意力メカニズムを追加することでネットワーク構造を改善し、モデル結果の可読性および予測精度をさらに向上させた。評価指標も RMSE から 3 種類に拡張した。第 5 章の結果から、注意力付き LSTM モデルは、単一 LSTM モデルや従来の時系列モデルよりも誤差が小さく、精度が高いことを示した。

予測結果について、注意力メカニズムを適用した結果、午前 5 時から午前 9 時までの間と、午後 4 時から午後 7 時までの間、特に午前 6 時から午前 7 時までの間の交通流が、注意が必要で重要な時間帯であることが明らかになった。これは、これらの時間帯が交通流予測に大きな影響を与えることを示している。

注意力付き LSTM モデルの利用により、事前のデータ処理の作業負荷を大幅に軽減でき、かつより高精度な予測結果が得られることが明らかになった。

7.1.3 AI モデルに基づく事故の重大性要因分析

第 6 章では、事故の重大性に関する研究において、日本の大動脈として知られる東名高速道路の代表的な区間である御殿場 IC～東京 IC の事故データを抽出し、機械学習モデルの XGBoost と可視化・解釈性向上ツールの SHAP を用いて、各変数と交通事故の重大性の関係を明らかにした。

XGBoost と SHAP を組み合わせることで、各変数と事故の重大性の間の非線形関係を定量的に計算することが可能になる。これまでは定性的な研究が多かったことに對し、第 6 章の分析では各影響要因の定量的評価を行うことができた。第 6 章では 13 の変数が使用され、それらは道路要因、車両および運転者要因、環境要因の 3 つのグループに分類できる。XGBoost-SHAP モデルの主な結果は以下の通りである。

速度が時速 100km を超えると、事故の重大性への影響は急増する。

東名高速道路では、50KP が重要な閾値となっており、50KP を超えると事故の重大性が大幅に増加する。それは、地形条件などの影響が考えられる。

運転者の年齢については、30 歳と 70 歳がターニングポイントである。30 歳以下の若い運転者、特に 27 歳以下の運転者は、高齢運転者を凌ぐほど重大事故を起こす可能性が高い

XGBoost-SHAP モデルは、交通事故変数の重要性をランク付けし、これらの要因と事故の重大性の相互関係を明らかにした。この結果は、次世代高速道路における老朽化したインフラの更新を行うための基礎的情報になる。

7.2 今後の研究課題

本研究では、交通流予測や事故の重大性要因の解明など、日本の高速道路が抱える諸課題に對し、AI モデルを用いて的確な解決策を提示することができた。

7.2.1 AI モデルに基づく分析の限界と課題

今後の研究のために、限界について説明する。

- (1) AI モデルでは、LSTM モデルやその改良モデル、ランダムフォレスト、XGBoost モデル、その他の AI モデルのいずれであっても、過学習でも劣学習でもない最適化された状態を達成するためにチューニングする必要がある。合理的で効率的なモデルパラメータを選択することが、今後の研究におけるモデルの成功の鍵となる。
- (2) 交通流予測では、IC 間とボトルネック JCT の二つの交通流を取り上げ分析した。提案したモデルを他の IC 間や JCT に適用したり、個別の分析だけでなく、適用シナリオを交通ネットワークに落とし込んだりするなど、研究範囲を拡大することは重要である。
- (3) 本研究では、時間的注意力メカニズムの特徴に着目した。次は、空間的注意力メカニズムをレビューし、首都圏周辺の高速道路ネットワークにおける空間的要因について詳細に分析していくことが必要である。

(4) 事故の重大性分析において、女性運転者のサンプルは少なく、ほとんどが男性運転者であった。今後は、男性と女性の運転行動の違いを分析するために、それらを含むより多くのデータを収集することが必要である。

7.2.2 次世代高速道路の実現に関する考察と今後の課題

第4章と第5章の知見を基にすれば、今後の研究では、改良型 RNN モデルと注意力メカニズムの交通流予測における適用可能性をさらに追求していく必要がある。それらの解釈可能性とリアルタイム予測性が高められれば、より良いモデルになる。さらに、複数の AI モデルの統合は不可欠であり、このような統合によって、変化する交通状況に対して動的な適応が可能になり、より正確な予測を行うことができる。そのためには、洗練されたアルゴリズムの開発も必要になる。

将来的な次世代高速道路への取り組みとしては、これらのモデルをスマートシティのインフラ建設への検討に適用し、交通の流れの最適化、渋滞の緩和、交通安全性の向上を実現することが重要である。これは、次世代高速道路での自動運転と従来の自動車の混在時の各種影響に関する研究や、スムーズで安全な交通の流れを確保するための戦略的開発が含まれる。拡張性と適応性を向上させるためにモデルを改良し続け、交通管理の影響を評価するための研究を実施することが非常に重要である。

我々は、VUCA（変動性、不確実性、複雑性、曖昧性）の時代を生きており、そこでは急速で予測不可能な変化への対応が大きな課題である。今後の研究として、政策変更に対応し、交通流への影響を正確に予測できる AI モデルの開発が必要である。

また、この研究におけるデータの重要性も認識する必要がある。今後の研究では、データ収集への努力を強化し、交通流、速度、その他の変数をより短い間隔でリアルタイムに把握する必要がある。総合的な分析には、交通事故や車両情報などの付随データも重要になる。これをサポートするためには、リアルタイムのデータ収集の要求を満たすために、センサーなどの物理的インフラをさらに配備する必要がある。

もう一つの重要な研究分野は、次世代高速道路のソフト対策とモビリティハブの設計に AI の知見を活用することである。AI を活用した交通予測が、モビリティハブの配置や運用にどのような情報を提供し、特に緊急時の安全性と効率性を高める交通管理戦略の実施をどのように導くことができるかを研究していく必要がある。

第6章の東名高速道路の交通事故の事例研究に基づき、今後は事故の重大性とその根本的な原因についての理解を深めるために、ランダムフォレストや XGBoost などの AI モデルの適用をさらに検討することも重要である。また、他の高速道路や異なるタイプの事故にも分析を拡大し、結果の一般性を検証する必要もある。

さらに、次世代高速道路における AI を活用した政策実現において、費用便益分析への応用も検討する必要がある。これには、AI モデルからの考察が、老朽化したインフラの更新と、安全性と効率性を高めるための関連施設の更新をどのように実施するかの評価も含まれる。これらの結果は、モデルが高速道路の安全性向上に対して実行可能な提言を提供し、より安全で効率的な次世代高速道路システムの開発に貢献できることを保証するものといえる。

【参考文献】

- Ahmed, M. S., & Cook, A. R. (1979). Analysis of freeway traffic time-series data by using Box-Jenkins techniques. <http://worldcat.org/isbn/0309029724>
- Akritis, A. G., & Malaschonok, G. I. (2004). Applications of singular-value decomposition (SVD). *Mathematics and Computers in Simulation*, 67(1-2), 15-31.
<https://doi.org/10.1016/j.matcom.2004.06.004>
- Ali, F., El-Sappagh, S., & Kwak, D. (2019). Fuzzy ontology and LSTM-based text mining: A transportation network monitoring system for assisting travel. *Sensors*, 19(2), Article 234.
<https://doi.org/10.3390/s19020234>
- Althe, F., & De La Fortelle, A. (2018). An LSTM network for highway trajectory prediction. In *IEEE Conference on Intelligent Transportation Systems, Proceedings, ITSC* (pp. 353-359). IEEE.
- Bahdanau, D., Cho, K., & Bengio, Y. (2014). Neural machine translation by jointly learning to align and translate. *arXiv preprint arXiv:1409.0473*. <https://arxiv.org/abs/1409.0473>
- Beck, M. J., & Hensher, D. A. (2020). Insights into the impact of COVID-19 on household travel and activities in Australia – The early days under restrictions. *Transport Policy*, 96, 76-93.
<https://doi.org/10.1016/j.tranpol.2020.06.006>
- Bian, Z., Zuo, F., Gao, J., Chen, Y., Pavuluri Venkata, S. S. C., Duran Bernardes, S., Ozbay, ., Ban, X. J., & Wang, J. (2021). Time lag effects of COVID-19 policies on transportation systems: A comparative study of New York City and Seattle. *Transportation Research*, 145, 269–283.
<https://doi.org/10.1016/j.tra.2021.01.015>
- Box, G. E. P., Jenkins, G. M., & Reinsel, G. C., et al. (2015). *Time series analysis: Forecasting and control*. John Wiley & Sons.
- C-NEXCO Business Outline. (2010-2019).
- Galfano, G., Dalmaso, M., Marzoli, D., Pavan, G., Coricelli, C., & Castelli, L. (2012). Eye gaze cannot be ignored (but neither can arrows). *Q J Exp Psychol (Hove)*, 65(10), 1895-1910.
<https://doi.org/10.1080/17470218.2012.663490>
- Carteni, A., Di Francesco, L., & Martino, M. (2021). The role of transport accessibility within the spread of the Coronavirus pandemic in Italy. *Safety Science*, 133.
<https://doi.org/10.1016/j.ssci.2020.104966>
- Chai, T., & Draxler, R. R. (2014). Root mean square error (RMSE) or mean absolute error (MAE)? Arguments against avoiding RMSE in the literature. *Geoscientific Model Development*, 7(3), 1247-1250. <https://doi.org/10.5194/gmd-7-1247-2014>
- Chen, F., Song, M., & Ma, X. (2017). Investigation on the injury severity of drivers in rear-end collisions

- between cars using a random parameters bivariate ordered probit model. *International Journal of Environmental Research and Public Health*, 14, 1152. <https://doi.org/10.3390/ijerph14091152>
- Chen, M. M., & Chen, M. C. (2020). Modeling road accident severity with comparisons of logistic regression, decision tree and random forest. *Information*, 11. <https://doi.org/10.3390/info11010005>
- Chen, T., Fox, E. B., & Guestrin, C. (2014). Stochastic gradient Hamiltonian Monte Carlo. In *Proceedings of the 31st International Conference on Machine Learning (Vol. 32)*.
- Chen, T., & Guestrin, C. (2014). XGBoost: A scalable tree boosting system. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 785-794).
- Chen, Y., Yang, J., & Han, S. (2023). Prediction of traffic accident severity based on random forest. *Journal of Advanced Transportation*.
- Cheng, X., Zhang, R., Zhou, J., et al. (2018). Deep transport: Learning spatial-temporal dependency for traffic condition forecasting. In *International Joint Conference on Neural Networks (IJCNN)*. IEEE.
- Cho, S.-H., & Park, H.-C. (2021). Exploring the Behaviour Change of Crowding Impedance on Public Transit due to COVID-19 Pandemic: Before and After Comparison. *Transportation Letters*, 13(5-6), 367-374. <https://doi.org/10.1080/19427867.2021.1888068>
- Choi, E., Bahadori, M. T., Sun, J., et al. (2016). An interpretable predictive model for healthcare using reverse time attention mechanism. In *Advances in Neural Information Processing Systems* (pp. 3504-3512).
- Chorowski, J. K., Bahdanau, D., Serdyuk, D., et al. (2015). Attention-based models for speech recognition. In *Advances in Neural Information Processing Systems* (pp. 577-585).
- Chrobok, R., Wahl, E. J., & Schreckenberg, M. (2001). Traffic forecast using simulations of large scale networks. In *Proceedings of the 4th IEEE International Conference on Intelligent Transportation Systems* (pp. 434-439). Oakland, CA: IEEE.
- Ciregan, D., Meier, U., & Schmidhuber, J. (2012). Multi-column deep neural networks for image classification. In *2012 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 3642-3649). IEEE.
- Daganzo, C.F. (1995). The cell transmission model: A dynamic representation of highway traffic consistent with the hydrodynamic theory, *Transportation Research Part B*, Vol.28, No.4, 269-287. [https://doi.org/10.1016/0191-2615\(94\)90002-7](https://doi.org/10.1016/0191-2615(94)90002-7)
- Daganzo, C.F. (1995). The cell transmission model, part II: Network traffic, *Transportation Research*

- Part B, Vol.29, No.2, 79-93. [https://doi.org/10.1016/0191-2615\(94\)00022-R](https://doi.org/10.1016/0191-2615(94)00022-R)
- Do, L. N. N., Vu, H. L., Vo, B. Q., Liu, Z., & Phung, D. (2019). An effective spatial- temporal attention-based neural network for traffic flow prediction. *Transportation Research Part C: Emerging Technologies*, 108, 12-28. <https://doi.org/10.1016/j.trc.2019.09.001>
- Domingos, P. (2012). A few useful things to know about machine learning. *Communications of the ACM*, 78-87.
- Durbin, J., & Koopman, S. J. (2012). *Time series analysis by state space methods*. OUP Oxford.
- Eisenmann, C., Nobis, C., Kolarova, V., Lenz, B., & Winkler, C. (2021). Transport mode use during the COVID-19 lockdown period in Germany: The car became more important, public transport lost ground. *Transport Policy*, 103, 60–67. <https://doi.org/10.1016/j.tranpol.2020.11.009>
- Eye Tracking for Website Optimization. <https://vwo.com/blog/eye-tracking-website-optimization/>
- Faghri, A., & Hua, J. (1992). Evaluation of Artificial Neural Network Applications in Transportation Engineering. *Transportation Research Record*, 1358, 71-80.
- Fouladgar, M., Parchami, M., Elmasri, R., et al. (2017). Scalable deep traffic flow neural networks for urban traffic congestion prediction. In *International Joint Conference on Neural Networks (IJCNN)* (pp. 2251-2258). IEEE.
- Friedman, J. H. (2001). Greedy function approximation: A gradient boosting machine. *The Annals of Statistics*.
- Gers, F. A. (1999). Learning to forget: Continual prediction with LSTM. In *9th International Conference on Artificial Neural Networks: ICANN 99* (pp. 850-855).
- Graves, A., & Schmidhuber, J. (2005). Framewise phoneme classification with bidirectional LSTM and other neural network architectures. *Neural Networks*, 18(5-6), 602-610. <https://doi.org/10.1016/j.neunet.2005.06.042>
- Hao, S., Lee, D. H., Zhao, D. (2019). Sequence to sequence learning with attention mechanism for short-term passenger flow prediction in a large-scale metro system. & *Transportation Research Part C: Emerging Technologies*, 107, 287-300. <https://doi.org/10.1016/j.trc.2019.08.005>
- Hinton, G. E., Osindero, S., & Teh, Y. W. (2006). A fast-learning algorithm for deep belief nets. *Neural Computation*, 18(7), 1527-1554.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation* 9(8), 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Ioannis, P., Georgios, G., Anastasia, N., Aristomenis, K., Ioannis, F., Alexandros, S., & Efthymis, P. (2021). Mapping travel behavior changes during the COVID-19 lock- down: A socioeconomic analysis in Greece. *European Transport Research Review*.

- Ishak, S., Kotha, P., & Alecsandru, C. (2003). Optimization of Dynamic Neural Network Performance for Short-term Traffic Prediction. *Transportation Research Record*, 1836, 45-56.
- Jeong, H., Kim, I., Han, K., & Kim, J. (2022). Comprehensive analysis of traffic accidents in Seoul: Major factors and types affecting injury severity. *Applied Science*.
- Jiao, J., & Azimian, A. (2021). Exploring the factors affecting travel behaviors during the second phase of the COVID-19 pandemic in the United States. *Transportation Letters*, 13(5-6), 331-343. <https://doi.org/10.1080/19427867.2021.1878595>
- Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245), 255-260. <https://doi.org/10.1126/science.aaa8415>
- Kerner, B.S. (2021). *Understanding Real Traffic: Paradigm Shift in Transportation Science*, Springer.
- Kissler, S. M., Tedijanto, C., Goldstein, E., Grad, Y. H., & Lipsitch, M. (2020). Projecting the transmission dynamics of SARS-CoV-2 through the post pandemic period. *Science*, 368(6493), 860-868. <https://doi.org/10.1126/science.abb5793>
- Komatsubara, N. (2019). Graduation thesis: Study on analysis of usage patterns of expressways by vehicle type and service improvement of rest facilities. [In Japanese].
- Kumar, T. S. (2022). Road accident severity prediction using machine learning algorithms. *International Journal of Computer Engineering in Research Trends*, 9.
- Li, W., Xia, S., Chen, F., Qiu, J., Liu, X., & Pan, Z. (2019). HDSTF: A hybrid deep spatio- temporal framework for traffic prediction. In 2019 IEEE International Conference on Signal, Information and Data Processing (ICSIDP) (pp. 1-6). Chongqing, China: IEEE. <https://doi.org/10.1109/ICSIDP.2019.9172711>
- Lundberg, S. M., & Lee, S. (2017). A unified approach to interpreting model predictions. PP. 4768-4777. *Proceedings of the 31st International Conference on Neural Information Processing Systems*.
- Lundberg, S. M., & Lee, S.-I. (2017). A Unified Approach to Interpreting Model Predictions. In I. Guyon, U. V Luxburg, S. Bengio, H. Wallach, R. Fergus, S. Vishwanathan, & R. Garnett (Eds.), *Advances in Neural Information Processing Systems*. Curran Associates, Inc.
- Ma, X., & Hovy, E. (2016). End-to-end sequence labeling via bi-directional LSTM- CNNs-CRF, arXiv:1603.01354. <https://arxiv.org/abs/1603.01354>
- Ma, X., Yu, H., Wang, Y., et al. (2015). Large-scale transportation network congestion evolution prediction using deep learning theory. *PloS One*, 10(3), Article e0119044. <https://doi.org/10.1371/journal.pone.0119044>
- Maknickienė, N., & Maknickas, A. (2012). Application of neural network for forecasting of exchange

- rates and forex trading. In The 7th International Scientific Conference Business and Management 2012 (pp. 10-11).
- Maknickienė, N., & Maknickas, A. (2013). Financial market prediction system with Evolino neural network and Delphi method. *Journal of Business Economics and Management*, 14(2), 403-413. <https://doi.org/10.3846/16111699.2012.701225>
- Manzoor, M., & Umer, M. (2021). Predicting road accident severity using machine learning and deep learning models. *IEEE Access*, 9. <https://doi.org/10.1109/ACCESS.2021.3113709>
- Märgner, V., & Abed, H. E. (2009). ICDAR 2009 Arabic Handwriting Recognition Competition. In 2009 10th International Conference on Document Analysis and Recognition (pp. 1383-1387).
- Martens, J. (2010). Deep learning via Hessian-free optimization. In ICML '10: Proceedings of the 27th International Conference on International Conference on Machine Learning (pp. 735-742).
- Mikolov, T., Karafiát, M., Burget, L., et al. (2010). Recurrent neural network based language model. Eleventh Annual Conference of the International Speech Communication Association.
- Nagahiro, Y., S. Nishioka and H. Okamoto (2019). Improving the Travel Time Information by Using a Neural Network: Effective Use of the ETC 2.0 Data, Giho, Hanshin Expressway Co., Ltd., No.29, p.147-154 [in Japanese].
- National Institute of Infectious Diseases, Japan. (2022). <https://www.niid.go.jp/niid/ja/diseases/ka/corona-virus/2019-ncov/2488-idsc/iasr-news/9425-481p02.html>
- NEXCO Research Institution. (2019). Expressway Traffic Statistics (2019 Edition). [In Japanese].
- Pascanu, R., Mikolov, T., & Bengio, Y. (2012). Understanding the exploding gradient problem. *CoRR*, abs/1211.5063. Retrieved from <http://arxiv.org/abs/1211.5063>
- Petersen, N. C., Rodrigues, F., & Pereira, F. C. (2019). Multi-output bus travel time prediction with convolutional LSTM neural network. *Expert Systems with Applications*, 120, 426-435. <https://doi.org/10.1016/j.eswa.2018.11.031>
- Qing Cai, Mohamed Abdel-Aty, Jinghui Yuan, Jaeyoung Lee, Yina Wu. (2020). Real-time crash prediction on expressways using deep generative models, *Transportation Research Part C: Emerging Technologies*, Volume 117, 2020, 102697. <https://doi.org/10.1016/j.trc.2020.102697>.
- Sakai, T. (Year). Aiming for a Beautiful, Safe and Vital. National Institute for Land and Infrastructure Management Annual Report No.2. [In Japanese].
- Santos, D., Saias, J., Quaresma, P., & Nogueira, V. B. (2021). Machine learning approaches to traffic accident analysis and hotspot prediction. *Computers*, 10(12), Article 157. <https://doi.org/10.3390/computers10120157>

- Savolainen, P. T., Mannering, F. L., Lord, D., & Quddus, M. A. (2011). The statistical analysis of highway crash-injury severities: A review and assessment of methodological alternatives. *Accident Analysis & Prevention*, 43, 1666. <https://doi.org/10.1016/j.aap.2011.03.025>
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural Networks*, 61, 85-117. <https://doi.org/10.1016/j.neunet.2014.09.003>
- Shaik, M., Islam, M., & Hossain, Q. S. (2021). A review on neural network techniques for the prediction of road traffic accident severity. *Asian Transport Studies*, 7.
- Tay, Y., Luu, A. T., & Hui, S. C. (2018). Multi-pointer co-attention networks for recommendation. In *Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining* (pp. 2309-2318).
- Tian, Y., Zhang, K., Li, J., Lin, X., & Yang, B. (2018). LSTM-based traffic flow prediction with missing data. *Neurocomputing*, 318, 297–305. <https://doi.org/10.1016/j.neucom.2018.08.083>
- Treiber, M., Kesting, A. (2013). *Traffic flow dynamics: Data, models and simulation*. Springer.
- Van Hinsbergen, J. W. C., & Sanders, F. M. (2007). Short term traffic prediction models. *Journal. Janacek, G. (2010). Time series analysis forecasting and control. Journal of Time Series Analysis*, 31(4), 303. <https://doi.org/10.1111/j.1467-9892.2010.00664.x>
- Vanajakshi, L., & Rilett, L. R. (2004). A comparison of the performance of artificial neural networks and support vector machines for the prediction of traffic speed. In *2004 IEEE Intelligent Vehicles Symposium* (pp. 194-199). Parma, Italy: IEEE.
- Varghese, V., Chikaraishi, M. & Urata, J. (2020). Deep Learning in Transport Studies: A Meta-analysis on the Prediction Accuracy. *J. Big Data Anal. Transp.* 2, 199–220. <https://doi.org/10.1007/s42421-020-00030-z>
- Vaswani, A., Shazeer, N., Parmar, N., et al. (2017). Attention is all you need. In *Advances in Neural Information Processing Systems* (pp. 5998-6008).
- Veličković, P., Cucurull, G., Casanova, A., et al. (2017). Graph attention networks. *arXiv:1710.10903*. <https://arxiv.org/abs/1710.10903>
- Vlahogianni, E., Karlaftis, Matthew, Golias, John. (2014). Short-term traffic forecasting: Where we are and where we're going. *Transportation Research Part C: Emerging Technologies*. 43. 10.1016/j.trc.2014.01.005.
- Wen, J., Kozak, M., Yang, S., & Liu, F. (2020). COVID-19: Potential effects on Chinese citizens' lifestyle and travel. *Tourism Review*, 76(1), 74-87. <https://doi.org/10.1108/TR-03-2020-0083>
- World Health Organization. (2020). Coronavirus Disease (COVID-2019) Situation Reports. Retrieved

- May 20, 2020, <https://www.who.int/emergencies/diseases/novel-coronavirus-2019/situation-reports>
- Wu, Y., Schuster, M., Chen, Z., Le, Q. V., Norouzi, M., Macherey, W., Krikun, M., Cao, Y., & Gao, Q. (2016). Google's neural machine translation system: Bridging the gap between human and machine translation. arXiv preprint arXiv:1609.08144. <https://arxiv.org/abs/1609.08144>
- Xin, R., Ai, T., Ding, L., Zhu, R., & Meng, L. (2022). Impact of the COVID-19 pandemic on urban human mobility - A multiscale geospatial network analysis using New York bike-sharing data. *Cities*, 126. <https://doi.org/10.1016/j.cities.2021.103515>
- Xing, L., & Sasaki, K. (2019). The Comparison Between ARIMA and Long Short-term Memory for Highway Traffic Flow Prediction. *Journal of the Eastern Asia Society for Transportation Studies*, 13, 1817-1834.
- Xu, Q. H., & Yang, R. (2005). Traffic flow prediction using support vector machine-based method. *Journal of Highway and Transportation Research and Development*, 22(12), 131-134.
- Xu, W., Feng, X., Wang, J., et al. (2019). Energy harvesting-based smart transportation mode detection system via attention-based LSTM. *IEEE Access*.
<https://doi.org/10.1109/ACCESS.2019.2927625>
- Xu, Y., & Li, D. (2019). Incorporating graph attention and recurrent architectures for city- wide taxi demand prediction. *ISPRS International Journal of Geo-Information*, 8(9), 414. <https://doi.org/10.3390/ijgi8090414>
- Yan, M.; Shen, Y. (2022). Traffic Accident Severity Prediction Based on Random Forest. *Sustainability*, 14, 1729. <https://doi.org/10.3390/su14031729>
- Yang, J., Han, S., & Chen, Y. (2023). Prediction of traffic accident severity based on random forest. *Journal of Advanced Transportation*, 8.
- Yao, H., Wu, F., Ke, J., Tang, X., Jia, Y., Lu, S., & Chuxing, D. (2018). Deep multi-view spatial-temporal network for taxi demand prediction. In *Proceedings of the 32nd AAAI Conference on Artificial Intelligence* (pp. 2588-2595). AAAI.
- Zeng, Q., Gu, W., Zhang, X., Wen, H., Lee, J., & Hao, W. (2019). Analyzing freeway crash severity using a Bayesian spatial generalized ordered logit model with conditional autoregressive priors. *Accident Analysis & Prevention*, 127, 87-95. <https://doi.org/10.1016/j.aap.2019.04.005>
- Zeng, Q., Wen, H., Huang, H., Pei, X., & Wong, S. C. (2019). A multivariate random- parameters Tobit model for analyzing highway crash rates by injury severity. *Accident Analysis & Prevention*, 125, 38-48. <https://doi.org/10.1016/j.aap.2019.01.017>
- Zhang, G., Yau, K. K., Chen, G., & Gong, X. (2019). Traffic accidents involving fatigue driving and

- their extent of casualties. *Accident Analysis & Prevention*, 125, 62-73.
<https://doi.org/10.1016/j.aap.2019.01.016>
- Zhang, J. & Hayashi, Y. (2020). Impacts of COVID-19 on the transport sector and measures as well as recommendations of policies and future research: Analyses based on a world-wide expert survey. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.3611806>
- Zhang, J.Z. Li, Z. Pu & C. Xu, (2018). Comparing Prediction Performance for Crash Injury Severity Among Various Machine Learning and Statistical Methods, *IEEE Access*, vol. 6, pp. 60079-60087.
- Zhang, N., Zhang, Y., & Lu, H. (2011). Seasonal autoregressive integrated moving average and support vector machine models: Prediction of short-term traffic flow on freeways. *Transportation Research Record*, 2215(1), 85-92. <https://doi.org/10.3141/2215-10>
- Zhang, R., Xie, P., Wang, C., et al. (2019). Classifying transportation mode and speed from trajectory data via deep multi-scale learning. *Computer Networks*, 162, Article 106861. <https://doi.org/10.1016/j.comnet.2019.106861>
- Zhu, L.F. Guo, R. Krishnan and J. W. Polak. A Deep Learning Approach for Traffic Incident Detection in Urban Networks. (2018). 21st International Conference on Intelligent Transportation Systems (ITSC), Maui, HI, USA, 2018, pp. 1011-1016.
- Zaremba, W., Sutskever, I., & Vinyals, O. (2014). Recurrent neural network regularization. arXiv preprint arXiv:1409.2329.

日交研シリーズ目録は、日交研ホームページ
http://www.nikkoken.or.jp/publication_A.html を参照してください。

A-925 「AI技術を活用した都市高速道路の交通流予測と
交通事故重大度分析」

AI技術を活用した都市高速道路の交通流予測と
交通事故重大度分析プロジェクト

2025年 8 月 発行

公益社団法人日本交通政策研究会

