

道路政策の質の向上に資する技術研究開発
成果報告レポート
No. 2021-2

研究テーマ

カメラ画像および複数の観測データを融合した
次世代交通計測手法に関する研究開発

研究代表者：東京理科大学准教授	柳沼 秀樹
共同研究者：東京理科大学教授	石垣 綾
東京理科大学教授	西山 裕之
東京理科大学教授	谷口 行信
日本大学大学准教授	石坂 哲弘
埼玉大学准教授	小嶋 文
東北大学准教授	原 祐輔
筑波大学准教授	和田 健太郎
東京工業大学准教授	瀬尾 亨

令和 6 年 5 月

新道路技術会議

「道路政策の質の向上に資する技術研究開発」（令和 3 年度採択）
研究概要

番号	研究課題名	研究代表者
No.2021-2	カメラ画像および複数の観測データを融合した次世代交通計測手法に関する研究開発	東京理科大学 准教授 柳沼秀樹

道路ネットワーク上での常時交通計測体制を実現するため、CCTV カメラや ETC2.0 プローブなどの複数の観測データと AI 技術を活用した次世代交通計測システムの開発を研究目的とする。その上で、本研究成果を実務に速やかに展開して道路 DX を推進する研究開発

1. 研究の背景・目的

これからの道路整備では、WISENET2050 に示されているように、サービスレベル向上を目指した新たな施策が展開される。交通防災拠点（バスタ）や TDM/TSM などの新たなサービスの設計・評価・運用には、時空間的に高分解能なデータが必須となる。本研究課題では、複数の観測データと AI 技術を活用した次世代交通計測システムを開発する。さらに、クラウド上にシステムを実装することで、実務におけるデータ取得コストの逡減に寄与し、道路 DX の推進を目指す。

2. 研究内容

本研究課題では、以下に示す具体的な 3 つの研究課題を設定し、それらを相互に連携して実施することで目的を達成した。

[A] 次世代型交通計測による道路 DX 推進に向けたデータ利活用の検討・検証

全国の実務者を対象に、提案するシステムが具備すべきシーズ・ニーズを把握する。その上で、プロトタイプシステム実装し、ケーススタディ適用を通じて有効性を明らかにする。

[B] AI 解析とカメラ画像を活用した交通移動体の高精度検知手法の開発

道路上の既設 CCTV カメラに対応した交通計測特化型 AI モデルを構築する。さらに、効率的かつ効果的なモデルの学習手法を提案し、これらの精度改善効果を検証する。

[C] 複数の観測データを融合した交通量等データの生成・補正手法の開発

上記[B]での移動体検知結果や ETC2.0 プローブ等を利用して交通量等データ生成・補正モデルを構築する。具体的には、マイクロデータ（交通量や速度、車両軌跡等のカメラレベル）とマクロデータ（リンクおよび OD 交通量等のネットワークレベル）を対象として、その精度を検証する。

3. 研究成果

本研究課題において得られた主な知見・成果は以下に示すとおりである。

[A] 次世代型交通計測による道路 DX 推進に向けたデータ利活用の検討・検討

国土交通省を中心に全国の産官学を対象に、研究期間を通じて延べ 40 回以上の意見交換会を実施した。その結果、(1)交通データ取得に関する現状課題、(2)AI 解析に求める性能要件、(3)今後の施策評価等で求められるデータ、(4)次世代交通計測システムの機能要件、に関するニーズを把握した。その上で、「ニーズに基づく人間中心設計」と「ペインリリーバに基づくユーザー体験の改善」を設計思想として、クラウド型システムを実装した。実務者による試行結果より、地図ベースで AI 処理と可視化を一体化した GUI は使い勝手が良く実務利用で有益との評価を得た（図 1）。

[B] AI 解析とカメラ画像を活用した交通移動体の高精度検知手法の開発

交通計測特化型 AI は、畳み込みニューラルネットワークを基本として、精度低下が著しい交通・環境・設置条件への対応、多様なモード（二輪車や歩行者）と車種分類にモデルを拡張した（図 2）。また、実務上の課題である学習データセット構築および学習について、(1)XAI（説明可能な AI）を活用した戦略的転移学習手法、(2)ドメイン適応に基づく自己学習手法、(3)デジタルツインを活用した仮想学習手法を提案した。その結果、多くの地点・時間帯で±10%以内の検知精度を達成し、実務利用に耐えうる性能を効率的かつ効果的に引き出すことに成功した。

[C] 複数の観測データを融合した交通量等データの生成・補正手法の開発

カメラ画像内を対象としたミクロレベルでは主に、(1)[B]での移動検知と追跡アルゴリズムを適用した車両軌跡データ、(2)通過カウンライン自動最適化による車線別車種別交通量データ、(3)衛星・航空写真画像を用いた実空間距離計測と車線別車種別走行速度データを取得可能とし、複数の地点とカメラ画角で良好な精度を確認した。また、ネットワーク全体を対象としたマクロレベルでは主に、センサスやトラカン、プローブデータを融合して、(1)時系列 LSTM とガウス過程回帰を融合した時間帯別リンクおよび OD 交通量予測、(2)敵対生成学習 (GAN) を活用した属性別アクティビティデータを生成可能とし、概ね良好な現況再現精度を確認した。

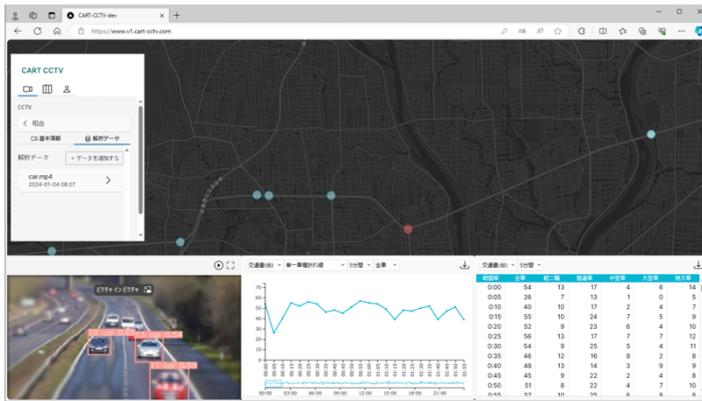


図 1：次世代交通計測システムのインターフェース画面

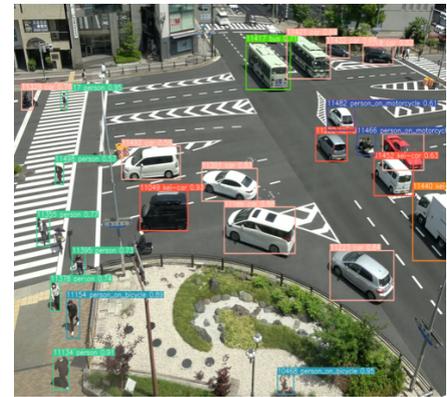


図 2：提案 AI による移動体検知

4. 主な発表論文

本研究課題で得られた成果について、研究期間中に 21 本の論文として取りまとめた。以下に主な成果を示す。なお、研究期間終了後も継続して成果を取りまとめて発表している。

- Obara, K., Yaginuma, H., Terabe, S., Uno, H., Suzuki, Y., Proposal of Self-Learning Algorithm Based on Domain Adaptation for Vehicle-Specific Traffic Measurement AI, *Transportation Research Board 103rd Annual Meeting*, No.24-21013, 2024.
- 尾原健太郎, 柳沼秀樹, 寺部慎太郎, 海野遥香, 鈴木雄:二輪車および歩行者に対応した交通計測 AI の開発および地点別自己学習手法の提案, *土木学会論文集・特集号(土木計画学)*, Vol.79, No.20, 2023.
- 山下聖太郎, 山田健登, 柳沼秀樹:複数の観測データを融合した交通データ生成 AI の構築, 第 35 回日本道路会議, 2023. 【奨励賞受賞】
- Ishijima, Y., Yaginuma, H., Terabe, S., Uno, H., Suzuki, Y.: Interpretability of machine-learning based travel behavior models using XAI, *16th International Conference on Travel Behavior Research IATBR*, 2022.

5. 今後の展望

本研究課題が提案した次世代交通計測システムは、実務者ニーズに基づく必要要件を具備した成果となっているが、現場での実運用を踏まえた改善の余地がある。特に、交通計測特化型 AI モデルの夜間における計測精度の向上、AI モデルの地点別学習のさらなる効率化と高精度化が挙げられる。また、国交省のデータプラットフォーム xROAD のサブアプリとして連携を目指したい。

6. 道路政策の質の向上への寄与

本研究課題は、今後導入が必須となる AI 技術を活用した交通量計測に対して、実務利用を前提とした複数データと AI 技術を融合した理論構築とシステム実装を行なった。これにより、次期道路交通センサスでの導入や災害時の部分的な常時モニタリングなどの実務に速やかに展開可能となり、人手観測よりも高精度・高品質・低コストでの交通計測を実現とした。また、本研究の一部は、国総研や地方整備局での検討にすでに利活用されており、実務の現場で貢献している。

7. ホームページ等

特になし

第1章 はじめに

1.1 本研究の背景

近年、我が国の道路整備は、これまでの道路リンク整備から交通拠点整備および拠点間を有機的に接続するネットワーク整備、さらにはTDM/TSMなどの道路需要マネジメントなどの新たなフェーズに移行しつつある。また、社会資本整備審議会道路分科会国土幹線道路部会「高規格道路ネットワークのあり方 中間とりまとめ」を受けて、国土交通省道路局ではWISENET2050が示しており「2050年、世界一、賢く・安全で・持続可能な基盤ネットワークシステム」として、道路のサービスレベル向上を目指した施策展開が検討されている。

より質の高い道路交通システムの実現を志向した政策の評価や新たなサービスの設計・運用には、「データ」に基づく検討・評価のPDCAサイクルが必須であり、これらの基盤となるデータプラットフォームとソリューションの構築が「道路のDX推進」の一環として進められている。国土交通省では部分的ではあるがデータプラットフォームであるxROADが公開されており、これを嚆矢としてデータ収集・解析・可視化・評価・リコメンドを一気通貫で実現する仕組みが求められている。

そのような中で、道路上に配備されているCCTVカメラ画像とAI解析技術を活用した交通量等の計測が試行されており、従来までの交通データとは比較にならない時間的・空間的に高分解能な交通ビッグデータを取得できる可能性を秘めている。しかしながら、これまでの検証から計測精度は、大きく3つの条件（①渋滞・混雑時の交通状況，②夜間や雨天等の環境状況，③カメラ画角・画質等の設置状況）によって計測精度が著しく低下しており、実務への適用は厳しい状況にあるため、精度向上は急務である。さらに、高度化・多様化・詳細化する施策評価に向けては、自動車の交通量や速度の

みならず、車両の移動軌跡や移動経路、多様な車種、異なるモード（自動二輪車、自転車、歩行者）等の計測が求められる。

カメラ画像から交通データを所得するためには、「検知」と「追跡」の2つの処理が重要となる。すなわち、撮影された動画画像から移動体（自動車や歩行者等）を「検知」し、検知した同一の移動体を「追跡」して移動軌跡を生成する処理である。精度向上には、移動体の検知と追跡に関する研究開発が必須となる。既設のCCTVカメラ画像（動画）を基本として、交通統計調査（道路交通センサス等）や交通観測（トラフィックカウンタ、ETC2.0プローブ情報等）などの複数の観測データを融合した交通に特化した移動体の検知と追跡に関する研究開発を行い、道路ネットワーク上の常時観測データ取得可能とする次世代型交通計測システムの構築が求められる。

1.2 本研究の目的

本研究課題は、既設のCCTVカメラを利活用した常時交通計測体制の実現と実務への速やかな展開を念頭に「AI画解析技術に基づく高精度な車両検知手法」と「複数の観測データを融合した交通量等データの生成・補正手法」をコアとする次世代交通計測システムの構築を目的としている。本研究を遂行する上で、以下に示す3つのテーマを具体的な研究目標として設定した。

具体的には、以下の3つのテーマに取り組む。
[テーマ1] 次世代型交通計測による道路DX推進に向けたデータ利活用の検討・検証

交通データを利用する全国の実務者（行政、道路管理者、コンサルタント等）に対して、利活用における課題、AI解析精度の改善に向けた技術的課題等、要望等の意見をヒアリングし、本研究が具備すべきニーズを把握する。常時観測体制に向けた次世代交通計測システムの設

計および実装に取り組む。なお、継続的にヒアリングを実施し、常に意見収集と研究のフィードバックを行う。また、本研究で得られたデータを実務的課題に適用したケーススタディ分析を実施して、本検討の有効性を明らかにする。

[テーマ2]AI解析とカメラ画像を活用した交通移動体の高精度検知手法の開発

道路上のCCTV画像から交通移動体を高精度に検知する手法を開発する。畳み込みニューラルネットワーク(CNN)と深層学習を下敷きとするAI技術を活用して、交通移動体の検知に特化したAIモデルを開発する。また、環境(交通状況、環境状況、設置状況等)、車種(基本的な車種分類、バス、タクシー等の公共交通等)、モード(自動二輪車、自転車、歩行者)の3つの課題に対応した拡張に取り組む。実務利用においては、学習データの効率的な生成方法や地点別の学習モデルについても開発検討を行う。

[テーマ3]複数の交通データを融合した交通量等計測データ生成・補正手法の開発

上記テーマ2の検討より得られる移動体データから交通量や速度、移動軌跡、利用経路やODなどの交通データを生成する必要がある。車両の詳細な挙動(ミクロ)とネットワークレベルでの移動(マクロ)について、交通統計調査(道路交通センサ等)や交通観測(ETC2.0プローブ、トラフィックカウンタ等)などの複数の観測データを活用した融合モデルを検討する。また、検知精度が不十分な地点から得られたデータは歪みを持つため、データを拡大・補正する手法が必要となる。複数の観測データから密度比等の機械学習理論を援用した方法論やガウス過程等を用いたエミュレーション技術の援用した検討を行う。

1.3 本研究の意義と道路政策への貢献

本研究は、より質の高い道路交通システムの実現を志向した政策の評価や新たなサービスの設計・運用を検討する上で必要となる時空間的に高分解能な常時観測データの獲得を目指して、実務利用を想定した実装までを検討する点に大きな意義がある。また、カメラ画像を中心とする複数の観測データとAIや交通モデルを融合させた方法論を構築するアプローチにも特色があり、特に交通モデルと機械学習を融合する方法論は新規性・独創性を有している。

カメラ画像および複数の観測データを融合し

た次世代交通計測手法が本格運用した際には、全国レベルで常時計測が可能となり、世界的に見ても稀な大規模交通観測データプラットフォームが構築できるため、真の意味で道路DXの実現に資すると期待される。従前の交通調査体系や施策評価の刷新に寄与し、短期的・長期的、局所的・大局的など多様な交通施策や新たなサービス設計、マネジメントが検討可能となる。さらに、データ駆動型による本格的なエビデンスベースでの政策立案(EBPM)への活用が期待される。

1.4 研究体制

本研究は、大学所属の9名の研究者と共に、各大学の学生からのサポートを受けながら研究を推進する。本研究では、情報科学(情報工学・経営工学)と土木工学(交通計画)の各分野で高い研究能力を有する研究者が連携して主要な3つのテーマに取り組む。

テーマ	研究者(所属・役職)	専門分野	実施内容
主査	柳沼秀樹(理科大・講師)	交通行動分析	全体統括
テーマ1 実務ニーズ把握とDX	小嶋文(埼玉大・准教授) 石坂哲弘(日大・准教授) 石垣綾(理科大・准教授) <small>※理工・経営工学科所属</small>	地域交通計画 交通システム 社会学・DX	<ul style="list-style-type: none"> 実務者や開発者へのヒアリング ニーズ・ニーズの把握 社会実装に向けたDX検討 交通計測システム設計・実装 ケーススタディ分析
テーマ2 交通検知AI検討	西山裕之(理科大・准教授) <small>※理工・経営工学科所属</small> 谷口行信(理科大・教授) <small>※工・情報工学科所属</small>	機械学習 画像解析	<ul style="list-style-type: none"> 交通検知AIモデル構築 車種・環境に対応した拡張 AIモデルの学習・高精度化 高速演算アルゴリズム構築
テーマ3 データ生成・補正検討	原祐輔(東北大・准教授) 和田健太郎(筑波大・准教授) 瀬尾亨(東工大・准教授)	交通行動分析 交通流理論 交通流理論	<ul style="list-style-type: none"> ミクロ挙動モデル構築 マクロ移動モデル構築 データ拡大・補正モデル構築 交通エミュレーション構築 モデル統合検討・検証

図-1 研究体制

参考文献

- 国土交通省道路局: WISENET2050・政策集(2023)
https://www.mlit.go.jp/road/wisenet_policies/pdf/wisenet2050_policy.pdf

第2章 次世代交通計測による道路DX推進 に向けたデータ利活用の検討・検証

2.1 本章の検討内容と成果の概要

全国の実務者（行政，道路管理者，コンサルタント，学識者等）を対象に，研究期間内に延べ40回以上の意見交換会を実施し，本研究課題が提案する次世代交通計測システムが具備すべきシーズとニーズを把握・整理した。また，道路DXにおけるシステムプロダクトの設計思想として，人間中心設計（HCD）やペインリリーバ/ゲインクリエータの概念を導入し，下記の2つのテーマでの成果を踏まえて，実務者の計算機性能や通信環境に依存しないクラウド型サービスとして次世代交通計測システムのプロトタイプシステムを実装した。

[1] 次世代交通計測システムに関する実務者 ニーズの把握

本研究開発が目指す「次世代交通計測システム」が具備すべき実務的なニーズの把握を目的として，システムのユーザーとなる行政や道路管理者，コンサルタントの実務者を中心にインタビュー調査を実施した。研究期間内の3年間で継続的に延べ40回以上の調査を実施し，全体的なフィードバックを繰り返し行いながら，協働でシステムを作り上げた。以下に調査から得られた知見を整理する。

(1) CCTVとAI技術を活用した交通量調査に関するニーズと性能要件

初年度からの継続調査で大きく以下の3点が挙げられた。整理した要件は[テーマ2]で構築する交通計測特化型AIモデルの仕様に反映した。

- 観測精度は，日交通量で±10%かつバラツキが小さいことが求められる。実務者が安心してデータを利用するためには昼夜で安定した精度（＝信頼性）の確保が必要。
- 観測対象は，現行の調査体系と整合した車種分類（大きさ，用途，利用形態）への対応が業務遂行上求められており，さらに自転車と歩行者に関するニーズが高い。
- 道路監視ではCCTVカメラを旋回させることが多く，カメラ画角が常に同じとは限らない。デフォルト画角（プリセット）に依存しない計測AIが必要。

(2) システムに求める実務での利活用シーン

利活用シーンは，大きく「平常時・災害時における交通状態のモニタリング」と「渋滞対策や整備効果評価のための分析」に分類された（図2.1-1）。前者はリアルタイム性が求められるため，簡易であること，高速処理であることが要件となる。



図2.1-1 本システムに求められる利活用シーン

一方、後者はデータを蓄積して各種分析に活用するため、高精度・高品質であること、時間的・空間的分解能が高いことが要件となる。システムではこれらに可能な限り対応した実装を行う。

(3) システムに求める具体的な要件

実務面でのデータ取得における課題と障害から次世代交通計測システムが備えるべき要件を以下の通り整理した。なお、現時点での未対応要件は継続して開発に取り組む。

- 各局・各事務所で捜査可能であり、不慣れな人でも利用できて、作業時間の高速化・効率化が図られる：クラウド型でユーザーインターフェースを備えた仕様
- データ形式が統一されており、資料にそのまま活用できる多様なグラフ描画や任意のファイルに出力できる：複数のグラフによる可視化とcsvでのデータ出力に対応
- 交通量データの過去・別地点での比較や気象情報や事故などのイベント情報の他のデータが表示できる：API経由で他のデータを取得・表示（データ権利関係で未対応）

以上の整理は、今後の施策展開におけるデータ利活用に関する体系的な知見として、有益な情報であり、本研究課題の大きな成果の1つに位置付けられる。

[2] 道路DXに資する次世代交通計測システムの基本設計・実装

国土交通省道路局では、道路DXの一環として道路データプラットフォーム「xROAD」の構築が進められており、本研究も最終的にはxROADとの連携を想定して開発を進めた。本研究では、交通計測およびデータ生成におけるDX化を念頭に、以下の2点をシステム設計方針として提案・実践した。

- ユーザーニーズに基づく人間中心設計（Human Centered Design: HCD）の適用
- ペインリリーバーによるユーザー体験（User eXperience: UX）の改善

すなわち、前者の要求事項を実務者ニーズから明らかにするアプローチ、後者のユーザーが直面している障害（ペイン）を取り除くことでプロダクトの価値向上とUXを向上させるアプローチを融合して、現場の実務者に寄り添ったシステム設計と実装を行なった。なお、このような設計思想は他のDX検討にも応用可能な一般的なフレームワークであり、この考え方自体も本研究の成果と言える。

[3] 次世代交通計測システムの実装と評価

上記での検討を踏まえて、実務者が利用可能なシステムを実装した（図2.1-2）。システム実装においては、CCTVカメラ画像とAI解析による交通量および速度計測（テーマ2とテーマ3の一部）を実現することを目指した。本システムの特徴を下記に示す。

- 利用者が視覚的にわかりやすい地図ベースとして、直感的な操作でグラフでの可視化を実現するユーザーインターフェースを導入
- CCTVカメラデータをアップロードするだけで数分後には計測結果が閲覧可能なクラウド型システムとして実装
- 交通量や速度の解析結果は統一フォーマットでダウンロード可能

このシステムにより、従前では時間と費用を要していた作業が大幅に効率化されることで、業務量や業務時間の削減に資するシステムを実装することができた。本研究課題の成果を速やかに実務に展開可能とする成果である。

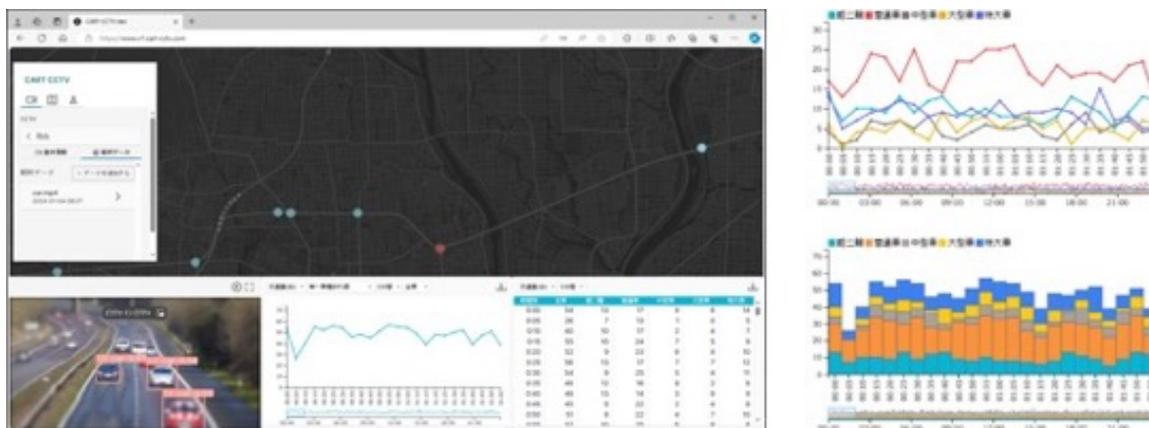


図2.1-2 実装したシステムの実行画面とデータ可視化例

2.2 実務者ヒアリング調査による知見の整理

ここでは、研究期間中の3カ年において実施した実務者ヒアリング調査の概要を取りまとめる。紙面の都合上、表による結果の取りまとめを中心に示す。

(1) R3年実務者ヒアリング調査：基本ニーズの把握と整理

1) 実務者ヒアリング調査の実施概要

本研究の初年度（R3）に実施した実務者ヒアリング調査では、次世代交通計測システムを検討する上で基本となる現状把握を中心に、システム求められる基本ニーズの把握と整理を中心に実施した。ヒアリング調査は、行政が10、道路・交通管理者が4、コンサルタント等が3の計17の実務者に実施した。ヒアリング調査期間は令和3年12月24日（金）～令和4年2月22日（火）であった。

2) ヒアリング調査の実施内容

調査項目は主に3つを設定した。①交通実態調査の実情、②CCTVの運用実態とAIによる交通計測の利活用状況、③交通実態調査の今後。これにより、道路DXの推進に資する次世代交通計測システムの要件ならびに開発方針を検討する。ヒアリングにより得られた知見を整理した結果を表2.2-1に示す。

表2.2-1 R3ヒアリングでの知見の整理

ヒアリングに得られた知見	具体的内容
◆CCTV・AI技術を活用した交通データ取得に関する知見	
観測精度のニーズ	・日交通量で観測誤差±10%以内 ・時間交通量で観測誤差±5%以内 ・車種別(小型・大型)交通量においても同等の精度
観測対象のニーズ	・車両の大きさ(バイク、中型、特大、料金体系区別) ・車両用途(貨物・トラック・トレーラー、ダブル連結トラック、バス) ・利用形態(レンタカー、営業車、車載重量、自動運転車) ・自動車以外の移動体(自転車、歩行者、次世代モビリティ)
観測データのニーズ	・異常車軌、逆走などの突発事象や渋滞発生状況の観測・検知 ・車両の軌跡や急制動などの挙動の観測・データ化 ・人手の観測に頼っている方向別交通量等のデータ取得
運用体制の構築	・観測のための画角を保持できる運用体制の構築、管制員への周知 ・AIカメラのメーカーと交通量調査の技術者、それぞれの知見の共有 ・ハードウェアとソフトウェアの互換性を踏まえた機能更新
道路監視と交通観測の両立	・常時観測用のCCTVを別途設置 ・道路監視と常時観測を両立できる運用方法の確立 ・プリセットフリーで観測可能なAI技術の確立
◆複数の観測データの融合に関する知見	
各種データへの属性情報の付与	・属性(年齢・性別・職業・国籍等)や利用目的等のパーソナルな情報 ・複数の調査・観測データの関連付けによる情報の充実
ハンドリングしやすいデータセット	・分析範囲・期間に合わせた柔軟なデータ取得 ・ハンドリングしやすい解析システム
常時観測かつ面的な交通観測データの充実	・常時観測、広範囲、多数地点のデータの取得 ・詳細な起終点が分析できるデータの取得
◆次世代交通計測手法の将来的な活用場面に関する知見	
常時観測とリアルタイムなデータ活用	・リアルタイム交通状況把握 ・路上駐車観測 ・歩行者・自転車の乱横断の観測 ・山間部における中心線からのみだし走行の検知 ・自動運転に関わるビッグデータポータルサイトへのビルドアップ
新規事業の効果検証	・交通拠点整備による効果検証 ・物流拠点整備による交通流動の変化 ・サイクルツーリズムの効果検証
災害時等の有事における行動分析	・災害・荒天時の迂回行動観測 ・冬の交通実態把握
信頼性と説明性が高いデータへの昇華	・AI技術による観測データの活用事例の増加と認知度の向上 ・既往データとの併用・補完による信頼性の高いデータの構築

(2) R4年度実務者ヒアリング調査：システムの要件と利活用シーン

1) 実務者ヒアリング調査の実施概要

本研究の2年目（R4）に実施した実務者ヒアリング調査では、次世代交通計測システムを実装する上で必要となる機能要件を中心に、前年度からの内容も継続して調査・整理を行なった。

ヒアリング調査は、行政が10、道路・交通管理者が1、コンサルタント等が1の計12の実務者に実施した。ヒアリング調査期間は令和4年10月14日（金）～令和5年2月24日（金）であった。

2) ヒアリング調査の実施内容

調査項目は主に3つを設定した。①交通実態を把握するデータのニーズ、②交通データ観測・入手に関する現状の課題・障害、③システムに求めること。これにより、道路DXの推進に資する次世代交通計測システムの要件ならびに実装方針を検討する。ヒアリングにより得られた知見を整理した結果を表2.2-2から表2.2-2にかけて示す。

表2.2-2 利活用シーンに関する知見

分類項目	具体的内容
○事業効果検証	・新規路線の開業効果 →面的に交通状況を観測したうえで評価、経年的に変化を分析
○渋滞対策検討	・ピンポイント渋滞対策、主要渋滞箇所対策の効果指標 →渋滞対策の効果を示す指標を算出するためのデータ収集 ・渋滞発生要因の詳細分析 →交通量や滞留・渋滞長に加え、車両の挙動に関するデータを収集し、詳細なデータ分析によって渋滞の原因を特定
○事故対策検討	・事故対策の検討 ・交通事故の潜在的な危険性の分析 →車両挙動を観測し、事故に関する交通コンフリクトを分析
○交差点運用の検討	・適切な信号現示の検討 →複雑な交差点や規模の大きな交差点における適切な現示の検討 ・適切な交差点形状・横断歩道位置の検討 →自動車・歩行者にとって安全な交差点空間の検討
○公共交通機関、交通拠点の円滑な運用検討	・交通結節点とその周辺における適切な運用方法の検討 →バス路線が集中する地域における面的なバス交通の実態把握 →交通拠点を利用する人々の人流データの取得、傾向の分析 ・公共交通機関の適切な運用方法の検討 →バスレーン整備によるバスの定時性確保効果の検証
○異常気象・災害時における交通状況把握	・異常気象、災害時における面的な交通状況をリアルタイムに観測 →通行可能な場所・不通となっている場所の迅速な確認 →上記を踏まえた道路利用者への情報提供 ・降雪時におけるスタック車両の有無とそれによる滞留車両の数の確認 →現地における必要な支援内容の検討に活用
○観光者の交通行動把握	・観光地の渋滞に関する地域ごとの特性把握 →観光施設の立地・分布やレンタカー利用者の観光者の行動による渋滞発生時の特性の分析・把握 →イベント開催時における局所的・即時的な交通混雑状況の分析・把握 ・サイクルツーリズム等の様々なモビリティによる観光行動の分析 →自転車の周辺行動の分析
○異常事象の予知	・過去の実績データを踏まえた異常事象発生予知に関する研究 →事故などで通行止になった事例から交通状況・道路状況のデータを分析し、通常時との違いを把握、それを踏まえた事象を予知
○交通混雑期における動的な情報提供	・観光シーズンにおける道路利用者への交通情報提供の実施 →リアルタイムな交通状況モニタリングとそれを踏まえた情報提供
○自動運転車への情報提供	・リアルタイムな交通状況把握とそれに基づく自動運転車への情報提供 →将来的に自動運転車が一般的となることを想定し、CCTV等から取得した情報を自動運転車へのリアルタイムな情報提供

分類項目	具体的内容
○面的な交通状況の把握	・面的な交通量の変化の把握 →新規整備と並行する幹線道路における交通状況の変化 →幹線道路における交通対策とそれによる生活道路への影響 ・大規模イベント実施時における局所的な交通渋滞状況の把握 →自動車の通行規制エリアの外周部における交通状況の面的な把握 ・旅行速度の計測 →ナンバープレート調査による旅行速度の計測 →渋滞対策の効果を示す指標として活用
○これまでは取得できなかったデータの取得	・詳細な車両挙動の観測 →車線変更や急減速・急加速の状況をVTR判読からデータを収集 →渋滞や事故等の事象の原因分析に活用可能なデータの取得 ・異常事象の検知 →渋滞や事故、スタック、落下物等の自動検知 →降雨、降雪による路面状況の変化の自動検知 ・観光需要を分析するための車種区分の観測 →観光大型バス、レンタカーの交通実態の把握 ・歩行者・自転車の挙動の把握 →交通結節点における利用者の人流データの取得 →交差点における歩行者・自転車の挙動の分析
○観測環境の充実	・迅速な対応の実現 →地域の要望に合わせて、交通状況を即時確認できるシステムの構築 ・時系列的に連続したデータが取得可能な環境の構築 →季節や時間を問わず、交通データを取得可能な環境の構築

表2.2-3 交通データの課題に関する知見

分類項目	具体的内容
●データの地点・時間が限定的	○調査地点数が限定的 →観測機器が設置されている地点は限定されている →交通状況を把握したい地点に感知器・CCTVがないことも多い ○データの期間が限定的 →交通調査は代表日に実施されることが多い →時系列的に連続したデータが不足している ○既存データの不足 →過去のデータは集計値になっていて、遡って詳細な分析ができない →道路交通センサスのデータだけでは把握しきれない地点がある ○可搬型カメラを活用したデータ収集 →上記の事情から、データを充実させるために可搬型カメラを用いて新たにデータの取得・補完を行っている
●センシングに関わるインフラの不足	○CCTVの設置数の限界 →画像解析技術の向上によって様々なデータが取得できても、CCTVの設置箇所が限定的で、収集できる情報には空間的に限界がある ○センシングに関わるインフラの充実 →交通データを取得するための観測機器の充実が必要である →一方でそれらを適切に運用・維持管理できる体制構築が求められる
●AIカメラの機能向上・普及	○AIカメラの精度確保・安定 →夜間や荒天時における観測精度の確保し、通常時との比較ができるように安定化を図ることが求められる ○AIカメラの機能向上 →道路整備効果や対策効果の検証にも活用できる観測精度の確保 →AI判読に適した画角を取得できる配置・機材の採用 ○AIカメラの技術・ソフトウェアの認知不足 →活用実績を蓄積するために関係者に技術・ソフトウェアを周知
●ITSインフラのスペック不足	○データ保存期間、サーバーの容量不足 →動画データの保存可能期間が数日しかなく、サーバー容量が不足 ○ネットワーク回線、PCスペックの不足 →通信速度が低く、大容量のデータをダウンロードに時間を要する →データダウンロード中はPCの動作が重く、他の作業ができない ○個人情報保護への配慮 →道路上のCCTVには個人が映りこむことがあるため、保管が困難
●データ授受の手間	○サーバーに保存されたデータのコピー →データ授受のためにサーバーに保存されたデータを外部メディアにコピーする必要があり、大容量のデータは時間がかかる ○データのやり取りの手間 →現状では大容量のデータのやり取りは、外部メディアを受け渡しているため、その準備・調整に時間を要している
●データ取得の努力・費用・時間	○新たにデータを取得するための努力・費用 →交通量調査実施のために、業務発注・調査実施・データ整理などが必要になるため、そのための努力・時間・費用が膨大 ○データクレンジング・確定値作業の努力 →事故や規制の状況、気象情報等と照合や異常値を取り除くなどして、確定値を生成する作業に時間を要している →現状では自動化が困難で、人手による作業を行っている ○AIカメラで取得したデータの精度検証作業 →観測機器が増えると、国の基準に合わせた精度検証を行う作業が膨大になる

分類項目	具体的内容
●ETC2.0プローブ情報の特性の考慮	○ETC2.0の普及率、車種の偏り →地域によって普及率に偏りがあるため、精緻な交通実態把握には、そのためのサンプリングが必要である →大型車の搭載率が高いため、それを考慮して分析を行う必要がある ○ETC2.0プローブ情報のデータ活用のリアルタイム性 →ETC2.0プローブ情報の収集には一定の時間を要するため、現状では迅速な交通状況把握への活用は不向きである ○DRMのバージョンとETC2.0プローブ情報のマッチング →ETC2.0プローブ情報の取得時期によってDRMのバージョンが異なり、時系列的に比較する際にマッチング作業をやり直す必要がある
●AI技術の特性の考慮	○AIによる判読処理 →現状のシステムでは判読処理中の状況を確認することができない ○AI技術におけるブラックボックス部分 →エラーや異常検出が発生した際に、何が原因だったのかが不明瞭で原因特定のために人手作業が発生している ○AI技術による自動判読をするためのCCTV運用上の調整 →道路監視のために画角を動かすと、その時間帯は欠測となってしまう ○AI観測に適した画像の取得 →可搬型カメラやCCTVのプリセット位置の設定にあたり、AI判読に適した画角が分からない
●人手作業による課題	○作業担当者によるデータ判読のゆれ →滞留長や渋滞長の調査、VTRの判読作業等を人手で実施する場合、その精度は調査員の主観・熟練度に依存する
●多様なデータを扱う際の手間	○複数データの連携 →調査対象地点のデータを取得する際、車両感知器・CCTV・ETC2.0プローブ情報等、別々のシステムで作業する必要があり、データの数だけ作業の手間が増加する ○他の分析にも転用しやすいデータベースの構築 →過去のデータの集計単位が粗かったり、印刷を前提とした整理がなされたりして、再集計・整理をする必要がある ○各種交通データの様式がまちまち →データそれぞれでフォーマットが異なるため、分析に着手する前にデータの整理・統合作業があり、これに時間を要している
●日々の作業時間・手間	○細かな作業の積み重ねで時間をとられる →データの集計や資料づくりは、ひとつづつは数時間で完了するが、同様の作業がいくつもあつたため、積み重ねで作業時間が嵩んでいる ○定型・提示報告資料の作成の手間 →定期的に作成する必要がある資料の多くはある程度フォーマットが定まっているものの、人手による作業も多く、手間となっている ○出力フォーマットが煩雑 →フォーマットの作成者や資料の提出先によって、仕様がまちまちでフォーマットの種類が多く、煩雑になっている
●分析作業のハードル	○業務発注前の事前分析 →本来は業務発注前に簡易な分析を行い、事前に交通状況を把握しておくことが理想だが、現在の環境では事前分析を行うことが難しい

表2.2-4 システムに求める要件に関する知見

分類項目	具体的内容
●システムのあり方	○作業時間の高速化・効率化 ○不慣れな人でも交通状況を把握・分析できるツール ○PCスペックが低くても動作がスムーズなシステム ○それぞれの局・事務所で操作可能なシステム ○リアルタイムに交通状況を観測できるシステム ○事前分析に活用できるシステム
●データ生成	○データクレンジング作業の自動化 ○観測なしと欠損のフラグ付け
●データベースの仕様	○異常値・特異値の表示の工夫 ○DRMとのマッチング ○統一的なデータベースの構築
●交通データへの付加情報の充実	○気象情報の付与 ○事故・規制情報の付与 ○カレンダー情報の付与 ○観測地点情報の充実
●分析機能の充実	○クロス集計機能 ○過去のデータとの比較、時系列的整理
●地図を活用した面的な交通状況の把握	○面的な交通状況の表示 ○地図情報の充実・カスタマイズ ○地図上でデータの集計結果(グラフ等)の表示
●分析項目の充実	○ETC2.0プローブ情報に基づく分析 ○定型フォーマットによる報告資料の出力 ○出力フォーマットの充実・カスタマイズ
●分析結果の出力	○描画内容の充実 ○出力データ形式の統一 ○分析に必要なデータ出力をスムーズに ○任意の画像データの分析システム
●その他の便利な機能	○観測場所・時間の予約システム

(3) R5年度実務者ヒアリング調査：システムの評価と改善要望

1) 実務者ヒアリング調査の実施概要

本研究の最終年度(R5)に実施した実務者ヒアリング調査では、作成したシステムの素案に対する印象や使い勝手、改良すべき点についてご指摘を頂くとともに、システムの活用が想定されるシーンや今後の展開についてご意見をうかがった。そのうえで、システムの改良事項と将来的な課題と展開を整理した。ヒアリング調査は、行政を対象に10の実務者に実施した。ヒアリング調査期間は令和6年1月29日(月)～令和6年3月11日(月)であった。

2) ヒアリング調査の実施内容

調査項目は主に3つを設定した。①現状のシステムへの評価・感想、②改良してほしい部分、③機能強化が必要なこと。これにより、次世代交通計測システムの改善方針を検討する。ヒアリングにより得られた知見を整理した結果は、次節にてシステム実装内容と合わせて概説する。

(4) まとめ

次世代交通計測システムの実務利用を念頭に、利活用シーンやシステム要件や改善点を抽出することに成功した。関係各所の協力により成果を得ることができた。この場を借りて感謝申し上げます。

2.3. 次世代交通計測システムの利活用シーンを踏まえた設計と実装

(1) システムの利活用シーンの設定

次世代交通計測システムが実際に利用されると想定されるシーンの整理を行った。前段で整理した結果を踏まえ、ここではCCTVから得られる画像からAI技術を用いて抽出可能な交通データとETC2.0プローブ情報を用いたケースを想定した。データ取得したある一時点を基準とすると、データ取得後すぐに交通実態の把握が求められるケース、取得したデータを蓄積して政策や業務の中で事象の分析を求められるケースの大きく2種類に分類されると想定される。それを、ここでは「リアルタイム×モニタリング」と「蓄積データ×分析・考察」に大別して整理することとした（図2.3-1）。

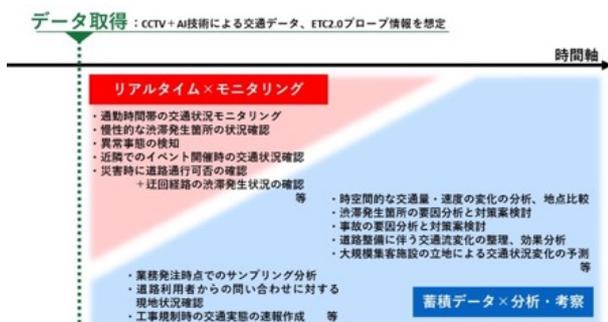


図2.3-1 実務において利用が想定されるシーン

(2) システムに求められる基本機能の整理

ここまでの知見と前節で整理したシステムの利用シーンを想定し、次世代交通計測システムに導入すべき機能を検討した（表2.3-1）。

表2.2-1 システムに求められる基本機能

機能の内容	概要	利用シーン	
		リアルタイム×モニタリング	蓄積データ×分析考察
地図を用いて面的な交通状況を俯瞰的に確認する機能	交通量・速度・渋滞・規制や事故の有無・OD等を地図上で表現することで、面的な交通状況を俯瞰的に観測し、全体像を把握	○	○
地点・区間ごとに詳細な交通データを確認する機能	問合せへの迅速な状況確認、渋滞や事故の対策検討のためのデータ収集のために、地点・区間ごとの交通量・速度・車両挙動・車種別データ等を把握	○	○
実務者が取得した画像・情報を任意にアップロードする機能	観測や分析が必要な地点に対して、実務者が任意に取得したデータをアップロードし、既存データとの比較分析を実施		○
画像を自動判読し、データベースを生成する機能	AI技術を用いて、新規に撮影あるいはアップロードされた画像を自動判読して交通データを観測するとともに、統一されたデータベースとして生成・保存	○	○
交通データの観測地点の情報を追加・編集する機能	既存のデータと任意に取得したデータを照合し、時空間的な比較分析ができるように、観測地点の情報を適宜追加・編集		○

導入すべき機能は大きく分けて、①地図を用いて面的な交通状況を俯瞰的に確認する機能、

②地点・区間ごとに詳細な交通データを確認する機能、③実務者が取得した画像・情報を任意にアップロードする機能、④画像を自動判読し、データベースを生成する機能、⑤交通データの観測地点の情報を追加・編集する機能、の5項目が想定される。

(3) システム実装

前述した仕様等に基づき、次世代交通計測システムのプロトタイプを構築した。以下、システムの機能動作の詳細を示す。なお、機能・動作には大きく分けて以下のものがある。

【広域表示】

WebブラウザからシステムのURLにアクセスすると、システムの画面が表示される。最初の画面では日本地図が表示され、地図内に、登録されたCCTVの設置地点がプロットされている。広域表示画面を図2.3-2に示す。下地となる地図表示はオープンソースであるMapboxが使用されており、「Dark」「Basic」「Light」「Satellite」4種類の表示に対応している。これらは画面左側に表示された「マップスタイル」メニューから切り替え可能となっている。地図表示の切り替え内容を図2.3-3に示す。

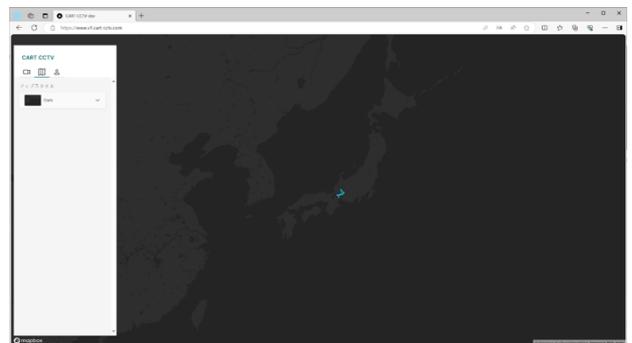


図2.3-2 システムにおける広域表示

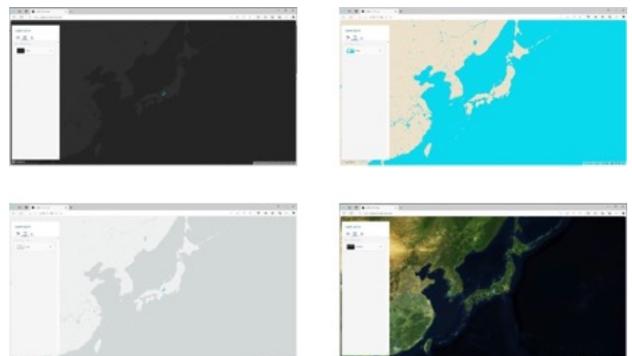


図2.3-3 選択可能な地図スタイル

【リスト表示】

映像を解析する、または解析結果を確認する対象となるCCTV地点は画面左側のメニューか

ら選択可能である。メニューは階層リストとして整理されており、リストの階層は「地方整備局等」「国道事務所」「維持出張所」および各CCTV地点の4層とした。

なお、地点選択は地図上の地点マークをクリックすることでも可能となっている。操作画面におけるリスト表示を図2.3-4に示す。

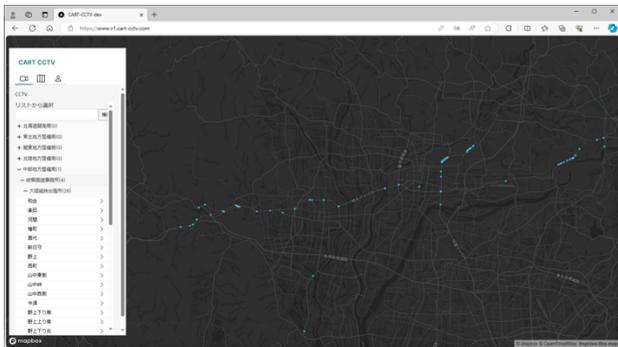


図2.3-4 操作画面におけるリスト表示

【地点選択・表示・操作機能】

リストまたは地図上からCCTV設置地点を選択すると、メニュー部分の表示内容が選択された地点についての表示に切り替わる。

地点表示時には以下の操作が可能となる。

① 基本情報の確認

表示内の「基本情報」タブをクリックすると、CCTV設置地点に関する基本情報を確認することができる。基本情報として、CCTVのID・名称や設置地点の座標・所在地・管理者名・監視している路線・方向・KPが記載されている。地点の基本情報表示の例を図2.3-5に示す。

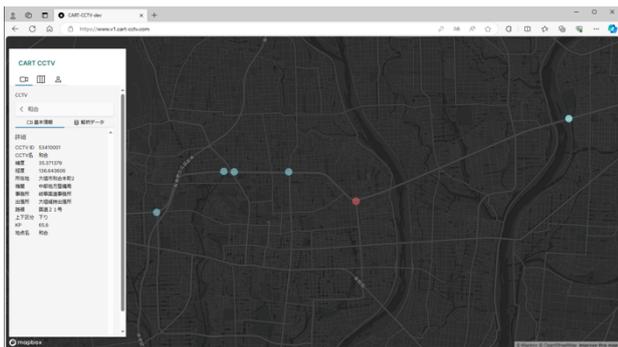


図2.3-4 CCTV設置地点における基本情報の表示

② 画像解析の実施

表示内の「解析データ」タブをクリックすると、その地点について解析済みの動画と解析結果の一覧、および新たな画像解析を実施するための「データを追加する」ボタンが表示される。

その地点について、新たに映像への画像解析を実施し、解析結果データを追加するには「デ

ータを追加する」ボタンをクリックする。ボタンをクリックすると、「映像ファイルをアップロード」ウィンドウが画面中央にポップアップされるので、そのウィンドウ内で解析対象となるファイルを選択するか、またはウィンドウの枠内へドラッグ&ドロップする。「解析データ」の一覧メニューに表示するファイル名や、映像ファイル内において解析を開始する日付時刻および当該日付時刻に対応する再生位置、解析終了となる日付時刻をこのウィンドウ内であわせて指定する。ファイルの選択および各種指定を行ったのち「登録する」ボタンをクリックすると、動画が画像解析システムの動作するサーバへとアップロードされ、画像解析が開始される(図2.3-6)。

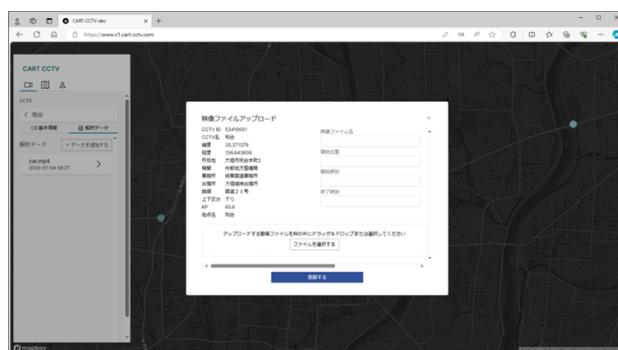


図2.3-6 動画ファイルのアップ画面

【解析結果の表示】

地点表示における解析データ一覧から、表示したデータを選択しクリックすると、解析結果が表示される(図2.3-7)。

表示される解析結果には以下の3種類がある。

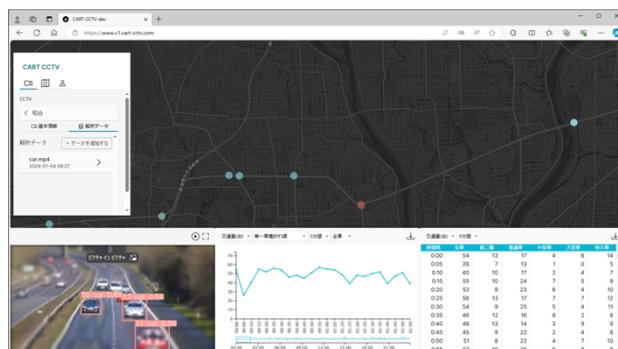


図2.3-7 解析結果の表示

① 解析済み動画

画像解析処理が実行され、映像内の車両が判別されたことを示す「バウンディングボックス」がオーバーレイされた動画を再生し、解析状況を確認することが可能となっている。

② データテーブル表示

画像解析により得られた交通状況の計測データをテーブル(表)として表示できる。画像解析は「交通量」および「速度」の計測に対応しており、また、集計時間の単位として「5分」「15分」「1時間」および「1日」に対応している。また、「交通量」に関しては全車線または車線別の計測が可能となっている。表示部右上のダウンロードボタンを押すことで、CSV形式で保存することができる。

③ グラフ表示

交通状況計測データは、グラフによる表示も可能となっている。テーブル表示と同様、取り扱い項目は交通量および速度、集計時間の単位は「5分」・「15分」・「1時間」・「1日」の4種類とする。グラフの表示形式は、交通量・速度ともに折れ線表示に対応している。また、交通量に関しては、全車種に関する縦棒(ヒストグラム)表示や、車種別の折れ線および積み上げヒストグラム表示も可能となっている(図2.3-8)。また、グラフ表示は、表示部右上のダウンロード端をクリックすることで画像として保存することが可能である。



図2.3-8 交通量に関する各種可視化

【ヒアリングを踏まえた改良】

ETC2.0などの連携データの導入により、システムの地図表示画面上で、交通状況分布の時間経過表示を行えるようにした。表示例を図2.3-9に示す。

地点選択時に、地図右下の再生ボタンをクリックするかスライダーを動かすことにより、連携データの時間変化を表示することができるように機能が拡充された。

図中においては、ETC2.0プローブデータの時間帯別旅行速度を用いて、速度が低下しているリンクを赤色で示している。また、道路交通センサデータの時間帯別交通量を用いて、交通量の増加がみられるリンクの表示幅を太幅で表示している。

このようにして、システムにおいては、CCTV映像の解析結果と、連携データによる周辺の交通状況に関連付けて確認できるようになった。



図2.3-9 関連データおよび時間経過表示の機能強化

(4) システムに関する実務者ヒアリング

本システムについて、ヒアリングを実施した結果を以下に整理する。

表2.3-2に構築したシステムへの第一印象をとりまとめた結果を示す。大別すると、良い評価として6項目、良くない評価として3項目、システムへの懸念点として4項目のご意見といただいた。

表2.3-2 システムに関する評価

◆システムに対する第一印象・評価		
分類項目	具体的内容	
良い評価	○省力化・効率化	・少ない操作回数で、解析・集計・可視化作業ができるのがよい ・ひとつのシステムで、交通データの取得から可視化までの作業を一括でできるのがよい
	○操作性・UI	・直感的に操作できそうなシンプルな作りでよい ・表現が分かりやすい ・CCTVのリストが管理主体ごとに整理されているのがよい ・システムの動作がスムーズと感じた
	○出カデータの種類の	・業務で使用する基本的なデータ：交通量・速度が、任意の集計単位で集計、可視化できるのがよい ・AIによる判断結果を動画で確認できるのがよい
	○CCTV動画の活用	・CCTVを活用することで、車両感知器のない場所の交通データが取得できるようになるのがよい ・動画データがあれば、すぐに交通データを取得できることは有用性が高い ・エッジ処理ではなく任意の動画を解析できるので、自由度が高い
	○複数データの表示	・DRMリンクによるプローブデータの表示等、発展性が感じられる。
良くない評価	○WEBアプリ	・PCにインストール必要のないWEBアプリは使いやすい ・災害時でも通信環境があれば、通常時と同じように使用できるのがよい
	○出カデータの種類の	・交通量と速度は車両感知器からも取得できるため、CCTV・AI技術を活用することの差が分かりにくい ・動画データを活用することで得られる情報の集計、可視化ができるとよい
	○処理時間	・利用ケースによっては、解析に要する時間が長いように感じる
懸念点	○リアルタイム性	・動画をアップロードして解析する必要があるため、リアルタイムなデータ取得の観点で車両感知器に劣る
	○判断精度	・CCTV側の画角・環境が必ずしもAIによる画像判断に適しているとは限らないため、十分な判断精度が確保できるか、懸念がある ・現在は5車種区分での判断がされているが、車種分類の精度がどの程度確保できているか、懸念がある
	○PCの性能	・実際に使用するPCが、スムーズにシステムを動作できるだけの性能を有しているのか、懸念がある
	○通信環境	・WEBアプリの使用、動画のアップロードにおいて、十分は通信速度が確保できるか、懸念がある。
○データ保存	・分析のためにCCTVの動画データを保存しておく必要があり、この方法について懸念がある。	

表2.3-3にプロトタイプシステムの改善点について、各実務者から挙げられた意見をとりまとめた結果を示す。大別すると、14のシステムの改善点が挙げられた。

これらについては、引き続きの研究開発を行い、可能な限り対応することで、実務での速やかな利活用の一助になると考える。

表2.3-2 機能拡充ニーズの整理

機能拡充のニーズ	
分類項目	具体的内容
OAによる解析内容の充実	<ul style="list-style-type: none"> 車両挙動に関するデータの取得と可視化 <ul style="list-style-type: none"> 車線変更、加減速等の車両挙動データの取得とそれを集計・可視化できるシステムがあると、より詳細な交通実態が把握できる 車種区分の充実 <ul style="list-style-type: none"> 車両の大きさや利用目的等による車種区分ができるようになる 特定の観測に適した交通実態の把握ができるようになる 観測対象の充実 <ul style="list-style-type: none"> 歩行者や自転車、次世代モビリティ等に観測対象が広がれば、より多様な交通実態の把握に活用できるようになる 渋滞長や滞留長の観測、可視化 <ul style="list-style-type: none"> 交通渋滞の実態を適切に把握するために渋滞長・滞留長の観測ができることよい CCTVの画角が変更されても同様に解析できるAIの導入 <ul style="list-style-type: none"> 一多少の画角の変化にも対応可能なAIが導入されれば、道路監視を目的とするCCTVとの両立に期待が高まる
〇他のデータとの融合、取得データの活用	<ul style="list-style-type: none"> 他のデータとの融合による面的な交通量の推計 <ul style="list-style-type: none"> 一車両感知器データやETC2.0プローブ情報等と連携して、観測機器がない区間の交通量を推計できると、面的に交通実態が把握できる 複数のカメラの判読結果を融合させた〇〇の把握 <ul style="list-style-type: none"> 一ナンバープレートなどで複数カメラの判読結果をマッチングさせ、〇〇を把握できれば、面的な交通量をより詳細に把握できる 汎用的な座標系の採用 <ul style="list-style-type: none"> 一行政内で使用されている一般的な座標系であることが望ましい
〇ハード面の強化、連携	<ul style="list-style-type: none"> 通信環境の改善、高速化 <ul style="list-style-type: none"> 一システムの活用には通信が必須となるため、スムーズな作業のために十分な通信環境を確保することが望まれる AI解析の処理時間の高速化 <ul style="list-style-type: none"> 一長時間の動画データの解析に要する処理時間の短縮が望まれる 高画質なCCTVの導入 <ul style="list-style-type: none"> 一設置されているCCTVは、設置時期によって画質がまちまちであり、より精度の高い解析を行うために高画質のCCTV導入が望まれる CCTVとのネットワーク化によるリアルタイムでのAI解析 <ul style="list-style-type: none"> 一セキュリティの関係で困難とされているCCTVとのネットワーク化を実現することができれば、リアルタイムでの解析が可能となる
〇データの蓄積 データベース化	<ul style="list-style-type: none"> 解析データの蓄積とその活用 <ul style="list-style-type: none"> 一解析データを十分に蓄積できるようになれば、それを活用してデータ精度を高めたり、比較分析が容易になることが期待される 自転車交通量データベースの作成 <ul style="list-style-type: none"> 一自転車交通量はデータの蓄積に乏しいため、本システムを活用して解析結果をデータベース化できるとよい
〇既存システムとの連携	<ul style="list-style-type: none"> 国土交通省が提供するAIとの解析結果の比較・検証 <ul style="list-style-type: none"> 一別途、AIを使用した動画データ解析システムが存在するため、これとの解析結果の比較、精度の確認ができることよい トラスボスで公開されているデータ等との連携、表示 <ul style="list-style-type: none"> 一車両感知器のデータが集約されているトラスボスなど、公開データと連携し、システム内で一括で確認できるとよい 気象情報との連携、表示 <ul style="list-style-type: none"> 一交通状況は気象に大きく影響されるため、気象情報と連携して、システム上で交通データを併せて確認できるとよい

(5) まとめと今後の課題

次世代交通計測システムの実務者ニーズの継続調査とシステム開発における成果を以下にとりまとめる。

1) ヒアリングの実施による実務者との継続的な意見交換の実施

本研究は三年に渡って、各地方整備局をはじめとした実務者に対してヒアリングを実施し、CCTV・AI技術の活用をテーマに意見交換を行った。その中で次世代交通計測システムの構築に必要な実務者のシズ・ニーズを把握したことに加えて、CCTV・AI技術に関する期待感や課題、その活用状況について状況交換を行うことができた。初年度は令和3年度 全国道路・街路交通情勢調査が行われ、この調査に初めてAI解析による動画判読技術が登用された時期と重なったため、現場で試行錯誤の様子を担当者から伺うことができた。年を追うごとに、CCTV・AI技術を活用する機会が増加し、ヒアリングの中でもその活用実績と、実際に使用した際の成果と課題を伺うことができた。

この継続的な意見交換の実施により、交通データの取得・分析における実務者のニーズを的確に捉えることができたと考える。加えて、成果や課題を共有し、情報交換を進める中で、CCTV・AI技術の活用に対する機運醸成の一翼を担えたのではないかと考える。

2) 実務者のニーズに寄り添った次世代交通計測システムの構築

前述したような実務者からのニーズの把握を経て、次世代交通計測システムの構築を行った。実務者のニーズは実に多種多様であり、実務におけるデータ収集・生成、それを活用した分析、分析結果を踏まえた検討や対策立案、事業評価などに加え、使用するPCや通信・ネットワーク環境等の違いに寄らず、快適に動作するシステムの構築が求められた。結果、リリース版の開発にあたっては、最低限必要な機能に限定し、インストール不要のWEBアプリとすることで、できるだけ環境に左右されずに利用できるシステムを構築するに至った。

プロトタイプでデモンストレーションを行ったヒアリングにおいては、改修すべき点や機能強化が必要な事項についてのご指摘をいただきながら、直感的に操作できるUIや具体的な業務での利用シーンを想定していただく等、一定の評価を得ることができた。

次世代交通計測システムの検討過程ならびに実務者へのヒアリングで得られた知見を踏まえ、今後の課題を以下に整理する。

1) 次世代交通計測システムの機能強化・機能拡充

システムの構築にあたり、三年に渡って継続して実施した実務者へのヒアリング調査から、その観測精度や活用の仕方について一定の課題はあるものの、CCTV・AIを活用した交通データ取得には様々なニーズがあることを把握した。その一方で、システムの利用環境は各地方整備局・事務所でまちまちで、必ずしも設備が充実していない実状も明らかとなった。この実態を鑑みて、本研究で構築したシステムは機能を限定し、業務の中で最低限求められるニーズに合わせることを目指して開発した。

ただし、第3章と第4章で後述する交通計測特化AIや交通データ生成手法を用いれば、システムに実装した以上の交通データが生成可能である。翻って、システムの利用環境を整えば、様々な機能を搭載した次世代交通計測システムでもスムーズに利用できる可能性が秘められている。そこで、今後は、実務者のニーズを継続的に把握しながら、そこで求められる交通データやそれらを用いた分析結果のアウトプットが本システムで実行できるよう、次世代交通計測システムの機能強化・機能拡充を図る必要がある。これによって、生成される交通データをより信頼性の高い、説明力のあるものに

昇華していくことが求められている。これは以降に示すハードウェアの強化と並行して実施することが望ましい。

2) システムの機能強化・機能拡充に資するハードウェアの強化

前述のとおり、実務者におけるシステムの利用環境は必ずしも設備が充実していない実状があり、業務において円滑に本システムを活用するためにはその利用環境の改善が求められるところである。くわえて、システムの根幹をなす CCTV のカメラ、その撮影動画を保存するデータサーバー、データのやり取りを行うための通信環境、AI 解析を行うクラウドサーバー、解析結果を蓄積するためのデータサーバー等も、システムの機能強化・機能拡充のために充実が必要なハードウェアであると考ええる。ハードウェアの強化はその整備と維持・管理に費用を要することから、容易なことではないと理解する一方、真の道路 DX 化を推し進めるうえで必要なハードウェアの強化を行うことが求められている。

3) 各種交通データとの連携とそのためのネットワーク化

本システムは CCTV で撮影した動画を適時アップロードし、その分の交通データの生成および集計・可視化を行うものとなっている。

より使い勝手のよいシステムとするためには、分析のために動画を適時アップロードするのではなく、CCTV と本システムをネットワークでつなぎ、直接データのやりとりができる状態とするのが望ましい。しかし現状では、①サーバーのセキュリティの観点から CCTV とシステムを繋げることが困難、②地方整備局ごとに CCTV やネットワーク機器の仕様が異なるため統一的な仕組みとすることが困難、③通信環境の観点から状态的に動画データを通信することが困難、といった課題を抱えているため、現時点での実装は困難と判断した。

他方、トラボスや xROAD のように、道路に関わるデータを集約しようとする動きも活発になっており、本システムの発展のためには各種交通データとの連携体制を構築することが重要と考える。

そこで、上記の 3 点の課題の解決を図り、CCTV と本システムのネットワーク化を図るとともに、他のデータともネットワーク上で連携可能な体制を整えることが求められる。

4) 関係者間での継続的な協議とそれを踏まえた対応策の実行

前述した 3 つの項目は、業務において次世代

交通計測システムが有効に活用されるために必要なことである一方、本省と各地方整備局、事務所、出張所等、関係者が多岐にわたり、それぞれの環境も異なるため、画一的な対策の実施は難しい状況である。これを紐解いていくには、道路行政に関わる関係者間で、実務において必要なシステムとそのあり方、活用するための環境づくりについて継続的な協議を実施し、実行可能な対応策を展開していくことが求められる。その結果、実務者にとって有用な次世代交通計測システムとその利用環境が整えられると考える。

5) PDCAサイクルによる本システムの成長と道路DXの実現

技術の進展や時代の変化に応じて、人びとの移動のあり方は絶えず変化していくことが想像される。それと連動して、道路行政における課題やその検討に必要な交通データの内容、分析方針も変容していくと考えられる。そこで、システムを利用する実務者のニーズを定期的に集約することでニーズの変化を捉え、リリースしたシステムの機能と乖離が生じていないかを検証するとともに、ニーズの変化に合わせた機能強化を図ることが将来的に求められる。

これを実行することで、本システムを構築する際の考え方のひとつである「ペインリリーバ」を継続的に行い、実務者にとって利用しやすく、効率的なシステムとして常に成長する環境を整えることが重要である。

第3章 AI解析とカメラ画像を活用した交通移動体の高精度検知手法の開発

3.1 本章の検討および成果の概要

道路上の既設CCTVカメラでの利用を想定した交通計測特化型AIモデルを構築し、交通移動体の検知性能を交通量カウント精度で評価した。提案したAIモデルは、テーマ1で明らかになった実務での要求性能を担保すべく、精度低下が著しい交通・環境・設置条件への対応、多様なモード（二輪車や歩行者）、詳細な自動車車種分類に拡張した。さらに実適用上の課題である学習データセット構築とモデル学習に対して、新たな3つの手法、(1)説明可能なAI (XAI) を活用した戦略的転移学習手法、(2)ドメイン適応に基づく自己学習手法、(3)デジタルツインを活用した仮想学習手法を提案し、性能を評価した。

[2] AI解析とカメラ画像を活用した交通移動体の高精度検知手法の開発

(1) 交通計測特化型AIモデルの開発

国土交通省が運用しているCCTVカメラでの利用を前提とする「交通計測特化型AIモデル」を開発した。既存の一般物体検出モデルを拡張する形で交通移動体計測に特化した改良を行

なった。モデルは「検知」と「追跡」の2つの手法で構成されている。テーマ2では「検知」に関する高度化に取り組んでおり、畳み込みニューラルネットワーク (CNN) を下敷きとするYOLO (You Look Only Once) を活用した。なお「追跡」は後述するテーマ3で検討した。本モデルの特徴は下記の通りである。

- 観測誤差±10%以内かつ時間帯で安定した検知性能を確保
 - 精度低下要因となる環境条件（夜間、影などの日照条件、雨天などの気象条件）、交通条件（渋滞時の車両の重なり、車線数などの道路構造、複数の車種混入）、設置条件（カメラ画角、映り込み）に対応
 - 多様な自動車車種（既存の料金体系や調査体系を考慮した7車種）に対応
 - 自動車以外のモードとして二輪車（自転車、自動二輪車）および歩行者に対応
- その結果、本研究では図3に示すように、これまで困難であった多様なモードと車種に対応した交通移動体の検知に成功した。

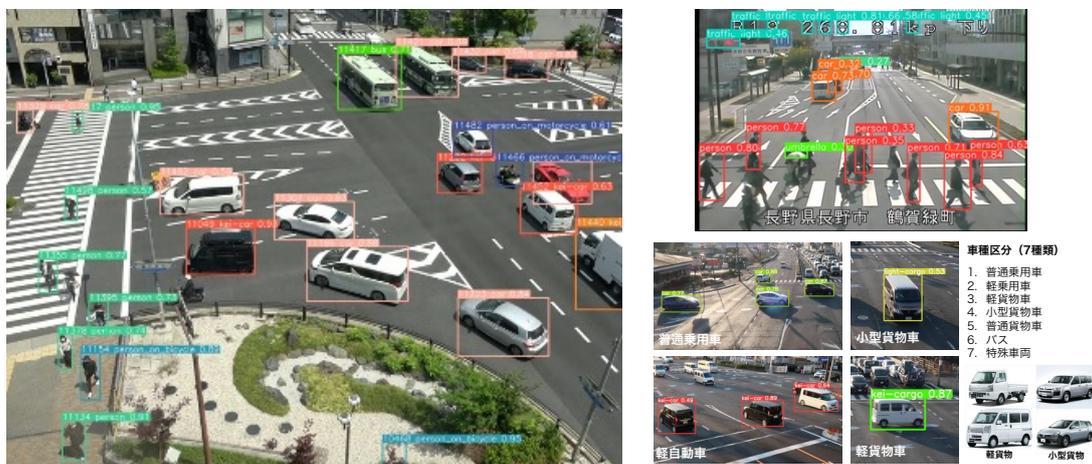


図3. 1-1 交通計測特化型AIモデルによる検知結果

(2) AIモデルの効果的学習アルゴリズムの提案と精度検証

AIモデルはデータを大量に学習することで検知精度を改善することが可能である。一方、学習データを作成するアノテーション作業は未だ手作業で多くの労力と時間を要しており、AI開発におけるボトルネックとなっている。さらに、各種条件が異なる複数地点のCCTV画像に対して、安定した精度を確保した汎化性能が高いAIモデルを開発することは困難であり、数千箇所のCCTVを個別に学習させることは現実的ではない。本研究課題では、交通計測特化型AIモデルに効果的な学習アルゴリズムを提案する。具体的には以下の3つである。

(a) 説明可能なAIを活用した戦略的転移学習

XAIを活用して精度低下要因を特定し、効果的かつ効果的な学習データセットを構築する方法を提案した。具体的には、Grad-CAMから得られるCNNモデルの判断根拠を類型化し、検知精度が低いターゲットのみを対象に戦略的に学習する。環境・交通・設置の3条件や車種別検知の精度向上に有効であることを確認した。

(b) ドメイン適応型自己学習アルゴリズム

自己学習 (self-learning) や半教師あり学習 (semi-supervised learning) の一種であり、「正解ラベル付き学習データの自動生成」と「生成データによる転移学習」を精度が改善するまで繰り返す手法を提案した。人手を介することなく地点別学習が自動で可能となり、車両の平均検知率が64.8%から81.7%に改善した。

(c) デジタルツイン型自己学習アルゴリズム

上記(b)の手法を拡張した手法であり、ゲームエンジンを利用してCCTVカメラ画像を再現して自己学習する方法を提案した。取得が難しい画角変化や気象変化、日照変化に対応することが可能となり、試算では30ポイント以上の改善が確認した。

これら3つの手法をCCTVカメラ動画に適用した精度検証結果を図3.1-2に示す。カメラ画質が悪く、検知精度が低い地点を対象に12時間分の解析結果を示している。なお、人手によりカウントした結果を真値とし、画面手前から奥に移動する方向をgoing, 奥から手前に移動する方向をcomingとしていることに注意したい。

通常の転移学習では、両方向で影によって昼間の精度が低く、coming方向では車両ライトによる白飛びで大きく精度が低下している。戦略的転移学習の結果、真値に近い学習が行われており、夜間を除いてはほぼ100%の検知精度であることが確認できる。さらに自己学習アルゴリズムは、人手を必要しない方法であるにも関わらず戦略的転移学習を超える精度が得られた。これにより、従前よりも効果的かつ効率的な手法であると示唆される。

以上より、従来よりも高性能・高精度、さらに地点別学習にも対応した交通計測特化型AIモデルおよび学習アルゴリズムを提案することに成功した。今後の研究開発や実務展開に大きなインパクトを与える成果である。

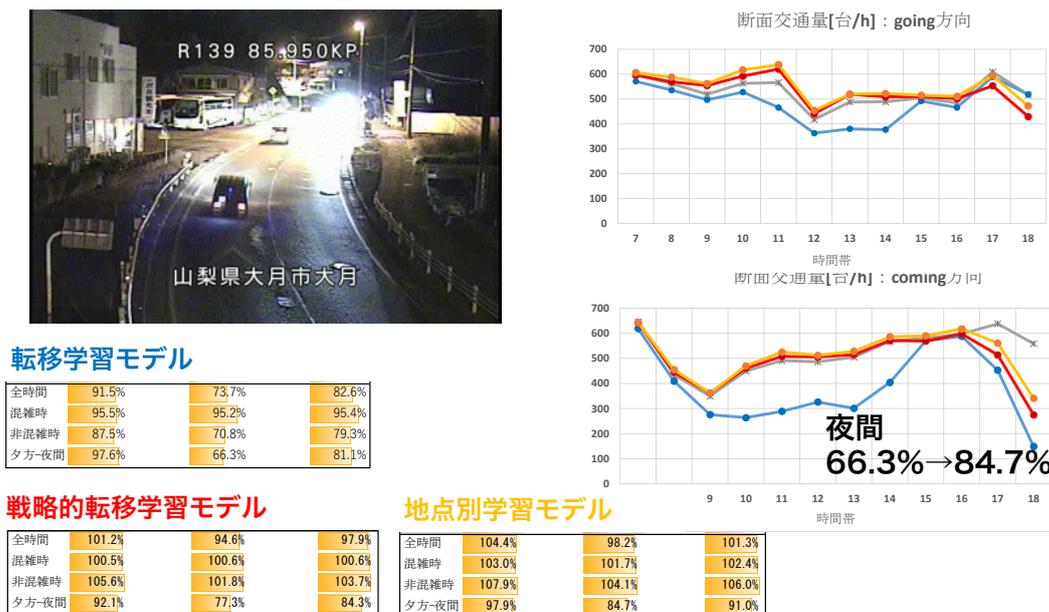


図3.1-2 学習による精度改善の例

3.2 CCTVカメラ画像とAI技術を活用した交通計測特化型AIモデルの構築

(1) はじめに

国土交通省が運用しているCCTVカメラ画像を前提として、AI技術を活用した自動での交通量計測を実現する「交通計測特化型AIモデル」を開発する。これまでの検証から計測精度は、大きく3つの条件(①渋滞・混雑時の交通状況、②夜間や雨天等の環境状況、③カメラ画角・画質等の設置状況)に依存して計測精度が著しく低下しており、実務への適用は厳しい状況にあり、観測精度の向上は急務である。本研究では、実務での利活用シーンや要求される性能を踏まえたモデルの提案を行う。

交通計測特化型AIモデルの基本的な構造を図3.2-1に整理した。

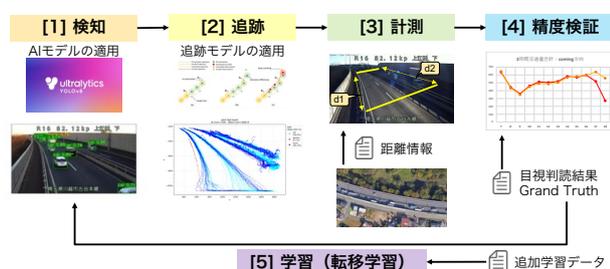


図3.2-1 交通計測特化型AIモデルの基本構造

提案モデルは、CCTVカメラ画像内から車両などの移動体を「検知」するプロセスとその結果をつなぎ合わせて「追跡」するプロセスにより構成される。その上で、追跡結果に対して「計測」を行うことで、断面交通量や速度、移動軌跡などのデータを取得することができる。さらに、取得したデータと真値を比較することで、モデルの精度を検証することが可能となる。もし、所望の精度を満たしていない場合は、データセットを準備した上で「学習」を行うことで、性能の改善が期待される。このようなプロセスをPDCAで回していくことが実務では重要となり、研究ではこれに資する各種手法を開発する。

本章では「検知」と「学習」をメインとして研究開発を実施する。本研究が提案する交通計測特化型AIモデルは、既存の手法と比較して以下のような特徴を有している。

- 従前の精度低下要因に対応しており、特に雨天や積雪などの気象変化、夜間や影などの日照変化、画角の変化に対応
- 多様な自動車車種や二輪車や歩行者などの他モードの移動体検出に対応
- 車線別、方向別の計測に対応

(2) 物体検出モデルの整理

物体検出は、画像内から物体の位置とクラス分類を行う問題である。物体検出は画像内に物体が複数存在する可能性もあるため、物体認識より難しい問題とされている。物体検出においてもディープラーニングを使用したモデルの有効性が示されている。

1) 一般物体検出モデルの概要

物体検出モデルは、物体の位置を推定した後に、その物体のクラス推定を行う two-shot (2段階処理が必要) モデルと物体の位置推定とクラス推定を同時に行う one-shot (1段階モデル) の二つに分けられる。現在は one-shot モデルが物体検出の主流になっている。

one-shot モデルの中で代表的なものが、2015年に発表された Faster R-CNN や、2016年に発表された YOLO である。Faster R-CNN は2段階モデルである R-CNN というモデルの改良版であり、従来の R-CNN は画像から物体候補領域を Selective Search というセグメンテーションの方法で抽出を行っていた。この処理に時間を有することが課題であったが、Faster R-CNN は Selective Search を Resion Personal Network (RPN) という CNN モデルに置き換えたことで高速化を実現した。Faster R-CNN より処理速度に重点をおいたモデルが YOLO である。画像認識を回帰問題として処理することで、処理速度の高速化を図った。処理の手順は、画像を $S \times S$ のグリッドに分割し、分割したグリッド内で B 個のバウンディングボックスの背景の信頼度を計算する。YOLO は新たなモデルも継続して発表され、検出精度の向上が図られている。

本研究では、精度の高さと処理速度を考慮して YOLO をベースとして交通計測特化型 AI モデルの検知処理を構築する。

1) YOLOモデルの概要

YOLO はオリジナルモデルが 2016 年に発表されてからアップデートが繰り返され、現在では YOLOv8 が最新である。YOLO の構造を理解するためには、YOLO のオリジナルモデルに立ち返って構造を確認する必要がある。

YOLO のオリジナルモデルは、畳み込み層 24 層と全結合層 2 層が組み込まれている Google-Net という特徴抽出モデルが導入されたことが始まりである。YOLOv2 からは darknet-19 と呼ばれる、19 の畳み込み層と 5 つのプーリング層を有した特徴抽出モデルが導入された。darknet は現在の YOLO モデルにおいても基本となる構造で、畳み込み層の数が減ったことで処理の高速化が成された。また、YOLOv3 では YOLOv5

でも用いられている darknet-53 という 53 層の畳み込み層が導入され、YOLOv4 においては現在の主流である検出器のフレームワークを分割した構造となっている。YOLOv5 は、YOLOv4 のフレームワークを基本にモデルサイズを柔軟に変更可能なことが利点であり、データ拡張機能などが追加された。

YOLOv5 で用いられているフレームワークは、図 3.2-2 のように、特徴を抽出する Backbone、情報を伝える Neck、情報を出力する Head の主に 3 つに分かれている。CSPnet とは、特徴マップの一部のみを畳み込み、結合することで、精度を落とさずに高速化を実現した手法である。SPP (Spatial Pyramid Pooling) は、複数のカーネルサイズで同時に Pooling することで精細な情報と広域な情報の両方を取得する方法、PAN (Path Aggregation Network) は異なるバックボーンの層から特徴量を Detector に伝えることで入力層に近い層の情報を活用する仕組みとなっている。各分野で優れているモデル、SOTA を達成したモデルを組み合わせることにより、YOLOv5 は、精度と処理速度が大きく向上した。

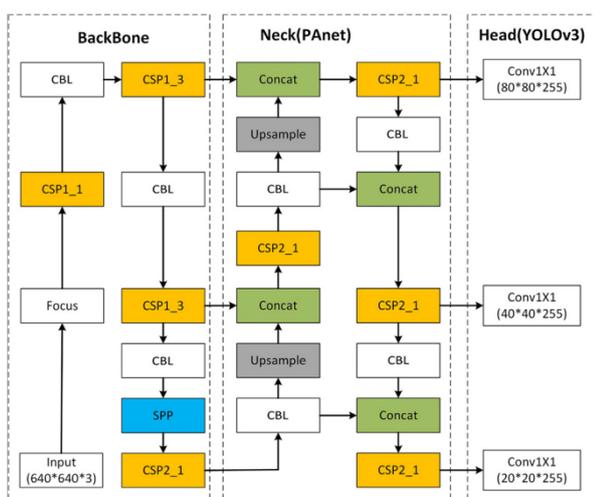


図3.2-2 YOLOのアーキテクチャ

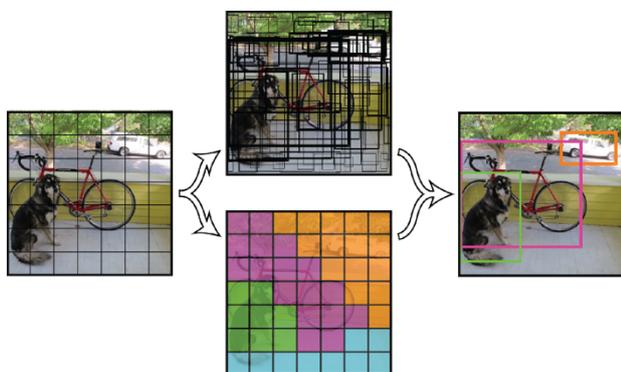


図4.2-3 YOLOの処理フロー

- [1] グリッドセル：入力された画像はまず、いくつかのグリッドセルと呼ばれる領域に分割される。YOLOの弱点として、小さい物体の検出が比較的苦手であるということが挙げられるが、YOLOが物体検出にグリッドセルを用いていることがその原因である。
- [2] バウンディングボックス：次に、グリッドセル内にいくつかのバウンディングボックス(物体の候補領域)が設定され、それぞれのバウンディングボックスのスコアが計算される。スコアとは、そのバウンディングボックスに物体が含まれている確率を示す数値である。
- [3] クラス確率：バウンディングボックスの設定と同時に、各グリッドセルのクラス確率が計算される。これは、各バウンディングボックスに含まれている物体(クラス)が何であるかを表す確率である。
- [4] 出力：算出されたバウンディングボックスのスコアとクラス確率を組み合わせることにより、バウンディングボックスごとのクラスに対するスコアが得られる。このスコアを基にして、数あるバウンディングボックスの中から正しく検出および分類ができているものだけを出力する。

(3) 夜間等の精度低下要因に対応した拡張

YOLO を下敷きとした交通計測特化型 AI モデル各種拡張を試みる。各種条件に対応した入力画像の補正および転移学習によるファインチューニングを実施する。

実務者ニーズの把握において、特に昼夜での安定した精度の確保が実務での AI 計測を普及・促進する上で最重要課題となる。過年度の関東地方整備局管内における複数の CCTV カメラ画像での検証結果より、カメラ画素数や画角、周辺環境に依存するが、ほぼ全ての箇所夜間の精度低下が確認され、ある地点では検知率がほぼ 0%となるケースが見られた。また、夜間の学習データを追加した転移学習した場合、夜間の検知精度は向上するが逆に昼間の検知精度が低下することが確認されている。すなわち、全ての CCTV カメラ画像を対象に、昼夜間でオールラウンドな AI モデルを過学習させる事なく構築することが難しいと考える。

本研究では、多様な状況での転移学習により高精度化して検知精度を高めるアプローチを採用した。

(4) 多様なモードに対応した拡張

物体検出タスクにおいて一般的に用いられているクラス分類ラベルは、COCO データセットを基準にしている。COCO データセットは80個のクラスから構成され、人間、自転車、バイクといったクラス分けが成されている。二輪車の検出を行う場合に COCO データセットのラベルを適用すると、人間部分と二輪車の部分が分かれて検出されるため、二輪車や歩行者の交通量を計測することに適していない。また、自転車やバイクなどの二輪車は、通常人が乗っていることが当然であるため、二輪車は人間と共にまとめてラベル付けを行うことが適切であると考えた。本研究におけるラベル付けの例を図 3.2-4 に示す。二輪車を押して歩行する、person-by-bicycle というラベルについてだが、自動二輪を押して歩行する場合歩行者として扱われるため、自動二輪と自転車をまとめて person-by-bicycle と扱うことにする。

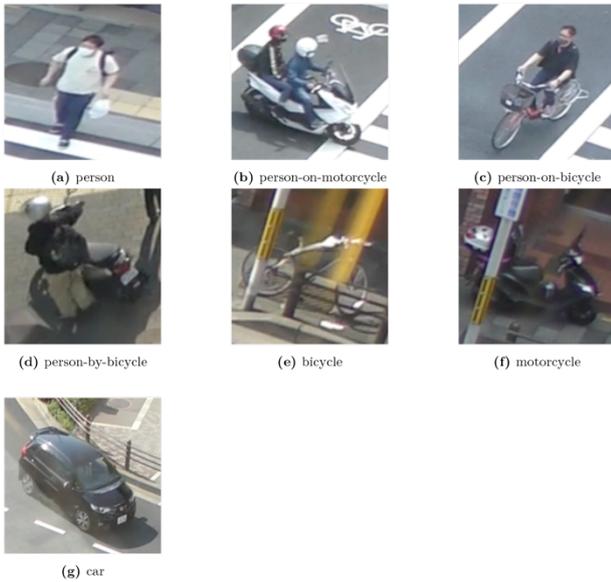


図3.2-4 多様なモードに対応したラベル

(5) 複数の自動車車種に対応した拡張

車種別交通量計測は、実務ニーズが高く、AI モデルの改善が望まれている。本研究では、実際の現場で使われている車種区分と本研究において設定したラベルを表 3.2-1 と図 3.2-4 に示す。本研究においては定義が明確かつ区分が細かい自動車登録番号による区分に準拠したラベルを設定した。

図 3.2-1 車種ラベルの一覧

ラベル	kei-car	car	kei-cargo	light-cargo	bus	cargo	special
自動車登録番号	軽乗用車	乗用車	軽貨物車	小型貨物車	バス	普通貨物車	特殊車
一般交通量調査	小型車			大型車			
警察	普通乗用	普通貨物		大型乗用	大型貨物		



図3.2-5 車種ラベルに対応した車両例

(6) おわりに

本節では、実務ニーズを踏まえた次世代交通計測システムに導入するAI検知モデルの拡張を行った。以降では、国土交通省より提供を受けたCCTVカメラ画像から学習データセットの構築（アノテーション）を行い、転移学習による性能検証を行う。

参考文献

- [1] Yifu Zhang, Peize Sun, Yi Jiang, Dongdong Yu, Fucheng Weng, Zehuan Yuan, Ping Luo, Wenyu Liu, Xinggang Wang, "ByteTrack: Multi-Object Tracking by Associating Every Detection Box", arXiv:2110.06864v3 [cs.CV] 7 Apr 20
- [2] Jinkun Cao, Jiangmiao Pang, Xinhao Weng, Rawal Khirodkar, Kris Kitani, Carnegie Mellon University, Shanghai AI Laboratory, Nvidia, "Observation-Centric SORT: Rethinking SORT for Robust Multi-Object Tracking", arXiv:2203.14360v3 [cs.CV] 16 Mar 2023
- [3] Yunhao Du, Zhicheng Zhao, Yang Song, Yanyun Zhao, Fei Su, Tao Gong, Hongying Meng, "StrongSORT: Make DeepSORT Great Again", arXiv:2202.13514v2 [cs.CV] 22 Feb 2023

3.3 説明可能なAIに基づく戦略的転移学習 アルゴリズムの提案

(1) はじめに

XAI を用いて AI モデルが持つ特性を把握し、戦略的転移学習および結果の可視化を行う。具体的には、Grad-CAM やそれに関連する XAI 手法を YOLO モデルに適用する。Grad-CAM によって、車両検出を行う際に反応が弱いとされるところを分析する。また、それらのデータセットの分布やモデルのもつ特徴を類型化して転移学習を行う。最終的に、転移学習モデルによって生じた性質の変化を分析する。

(2) 転移学習とXAIモデルの整理

1) AIモデルにおける転移学習

転移学習 (Transfer Learning) は、機械学習の分野で急速に進展している手法の 1 つで、あるタスクやドメインで獲得した知識を、異なるものの関連するタスクやドメインに適用し直すことをさす。このアプローチは深層学習において効果的で、データや計算リソースを大幅に削減することが可能となる。転移学習の最も主要な利点は、数十万枚単位の大規模なデータセットで学習された事前学習済みモデルを使用して新しいタスクに転用することができる点にある。この方法では、新たなタスク専用の学習を行う必要がない。したがって計算リソースやデータセット作成のコスト削減に繋がる。本研究の例では、日常のあらゆるオブジェクトが含まれた MSCOCO データセットによって学習された知識を、交通計測のタスクに特化させることを指す。また、一部の層を新しいデータで再学習 (ファインチューニング) することによって、性能を向上させることも目的とする。ファインチューニングでは、モデルの初期層を固定することで、一般的な特徴抽出は事前学習済みモデルのまま保持され、最終層付近では特定のタスクに特化した特徴抽出へと調整される。ファインチューニングの家庭では、新しいデータセットに含まれる特有の特徴を学習することで、特定のタスクへの精度を高められることが期待される。分析した結果より、車両の角度、エッジの抽出しやすさに繋がるコントラストが強く影響している可能性、背景色を重視し、データセット構成やオーグメンテーションに反映させる。

2) XAIによるAIモデルの判断根拠

XAI (説明可能な AI, eXplainable AI) は、AI モデルの意思決定プロセスを明らかにすることを目的とした手法である。通常、深層学習モ

デルは複雑かつ多層的な構造となっているため、その決定に至るまでの過程は「ブラックボックス」と喩えられることが多い。XAI の目的は、この決定過程を人間にわかりやすい形で可視化することである。これにより、出力された結果に対しての説明性や、モデルの特性についての解釈可能性の向上が期待される。CNN モデルにおける適用例としては、Grad-CAM (Gradient-weighted Class Activation Mapping) や LRP (Layer-wise Relevance Propagation) のような手法が、モデルの予測根拠をヒートマップとして出力するための手法として代表的である。

Grad-CAM

Grad-CAM は、Selvaraj らによって CAM (Class Activation Mapping) をベースに開発された CNN の判断根拠を可視化する手法の一つである。はじめに、画像のクラスが c に分類される場合を考える。CAM では、CNN が保持している位置情報 A_{xy}^k と特徴量マップの画素平均をまとめる処理を行う GAP (Global Average Pooling) 層における重み w_c^k の積和を取る。すなわち、積和の値は各画素におけるクラスに対する寄与度と表すことができる。これらの特徴マップは元画像のサイズにリスケールされ、解釈可能な形として出力される。これらの勾配に対して、各画像の GAP を取り、特徴マップの重み付き和により重要度とする。

$$L_{Grad-CAM}^c = ReLU\left(\sum_k \alpha_c^k A^k\right)$$

なお、重み α^c は以下のようになる。

$$\alpha^c = \frac{1}{Z} \sum_{i,j} \frac{\partial Y^c}{\partial A_{ij}^k}$$

ここで、 A_{ij} は特徴量マップ、 Z は正規化定数、 Y^c はクラス c に分類される確率である。また、ヒートマップを出力する際に、勾配と特徴マップを組み合わせたものに対し ReLU 関数を通すことによって、クラスの識別に正の寄与をする領域のみが強調されて表示される。最終的な出力として、ヒートマップ内で反応している領域は CNN が特定のクラスを認識する際に最も重要だと判断した画像領域となる。CAM では GAP 層が存在しないモデルに対しては適用できないため、図 3-3-1 に示す通り、Grad-CAM では重みの代わりに出力に対する勾配を出力することによって、任意の CNN モデルで利用可能となる。

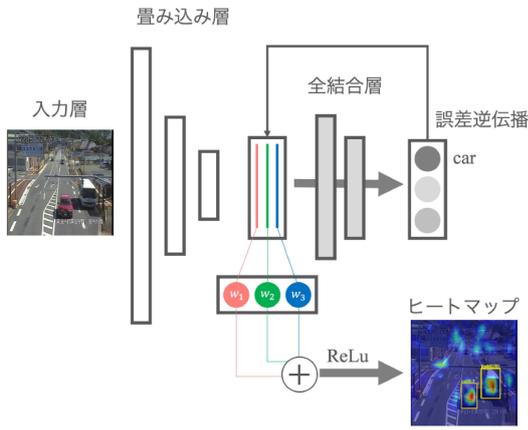


図3.3-1 Grad-CAMの計算概要

Eigen-CAM

Eigen-CAM (Eigen Class Activation Mapping) は、Muhammad らによって提案された CAM 手法の一つである。Grad-CAM と実装で異なる点は、畳み込み層の特徴マップを共分散行列計算によって統計的関連性を算出することにある。これにより、モデルがどのような特徴を連動させて識別に利用しているかが可視化される。また、共分散行列によって算出された固有ベクトルから、データの主要な変動方向を示す。これにより、最も情報量の多い特徴が抽出されるようになる。したがって、視覚的な詳細度をより明確にし、特徴間の関連性を詳細に捉えることができるようになる点が特長となる手法である。本研究では、YOLOv8 モデルの特定レイヤーに対し Eigen-CAM を適用して分析を実施した。

(3) XAIモデルによる精度低下要因の解明

設置条件は、カメラの画角や性能そのものに依存する条件である。場合により完全に検知不可となる状況も存在する。したがって、条件変化にロバストな AI モデルを作成することが求められている。日照条件での精度低下は、逆光や夜間の車両ライトによるオクルージョンが発生することに起因する。また、夜間では CCTV カメラの画質悪化にもつながる。天候条件では、雨や雪などの環境変化によって精度が低下する。これらは、雨や雪などの学習データが相対的に得られにくいことが影響すると考えられている。以下、yolov8 事前学習済みモデルに対して Grad-CAM を適用した結果を示す。

図 3.3-2 は、昼間時の車両に対してある程度角度がついている一般的な画角である。横列は YOLOv8 におけるレイヤー番号を示す。通常時、浅いレイヤーでは車両のパーツやエッジ、白線等の低レベルな特徴に対して反応しているこ

とがわかる。(b), (c) 地点の第 15 レイヤーでは画面奥の領域、第 21 レイヤーでは手前側の領域と、異なるスケールで特徴が抽出されていることがわかる。これは、YOLOv8 モデルの検出ヘッドがスケールごとに分割して出力されるため、大小様々な物体を検出可能になることに起因するものと考えられる。また、車両そのものである前景と、背景が良好に分けられていることが考えられる。

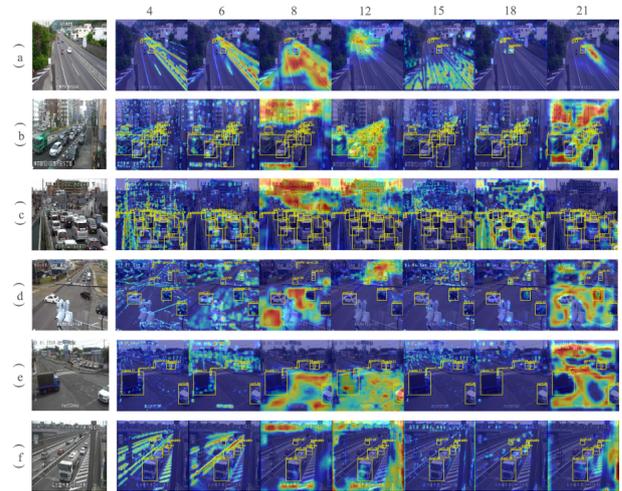


図3.3-2 各CCTV画角におけるGrad-CAMの可視化

1) 夜間時の特徴抽出

図 3.3-3 は、昼間時の車両に対してある程度の角度がとられている一般的な画角である。比較的浅いレイヤーでは、白線部分などの目立つ部分に反応しているように見られるが、昼間ほどの顕著さは見られない。また、昼間と比べて車のエッジ部分への特徴抽出が弱くなっている。(c) の第 12 レイヤーでは道路領域を中心に反応が見られるものの、車両部分との境目が適切に検出されていないことが読み取れる。第 15 レイヤーなどの深い層では、ヘッドライト部分にピンポイントに集中して反応していることがわかる。したがって、夜間では車両全体よりもライトに関して学習されている可能性が高く、ライトが弱く映り込んでいる状態では適切な検出とならないことが示唆される。

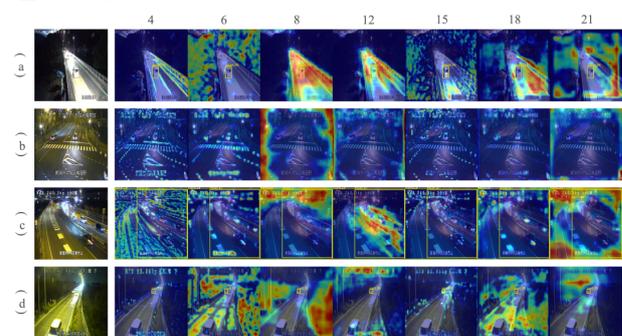


図3.3-3 夜間におけるGrad-CAMの可視化

2) 正面画角の特徴抽出

図 3.3-4 は、車両の正対する位置から撮影された地点の Grad-CAM 結果となっている。車両正面画角の場合、ある程度近距離であれば画角やパーツに対して反応がする傾向が見られるが、第 15 レイヤーに見られるように、車両側面部分のみに反応が限られるようになる。(c) 地点の第 18 レイヤーで見られるように、車両正面部分と比較して側面部分に特に強く反応する傾向が見られ、クラス分類時の判断根拠として重要な役割がある可能性が考えられる。また、水平方向のエッジ、垂直方向のエッジと、それぞれ別のレイヤーで特徴抽出が行われていることがわかり、車両に対して斜め方向の画角から撮影された地点とは異なる挙動を示していることが見受けられる。

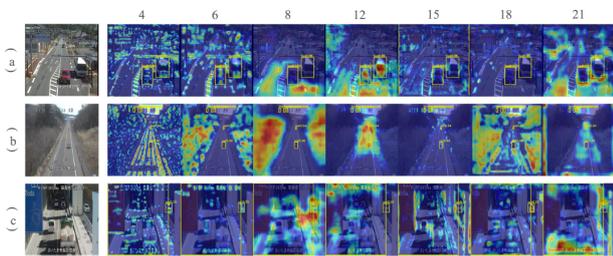


図 3.3-4 正面画角における Grad-CAM の可視化

3) 画角遠近の特徴抽出

図 3.3-5 は、対象とカメラ画角の距離別による比較を示す。(a), (b) 地点で見られるような、中～近距離においては、検出の信頼度が高い結果となっている、特に、車両のテールランプやタイヤなど、特定のパーツに反応が集中している場合、相対的に信頼度が高いような傾向が見られる。また、第 15, 18, 21 レイヤーでは物体の大小別で特徴抽出が行われていることが見受けられる。これらのレイヤーは、YOLOv8 の特長とするスケール別の検出ヘッドに関するため、この機構が適切に働いていることを示している。最も引きの画角である(c) 地点では、小さい物体に関わらずピンポイントで抽出されていることがわかる。(b) 地点の貨物車両の荷台部分では、画質の良い地点においても、テクスチャの似たような物体を誤認するようなケースが見られる。

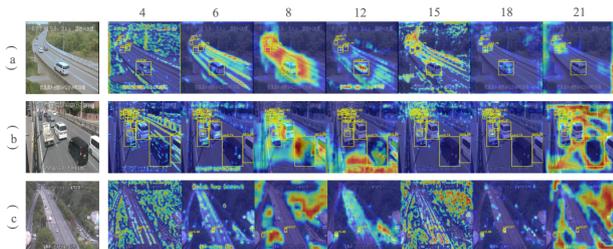


図 3.3-5 画角遠近における Grad-CAM の可視化

4) 撮影条件の特徴抽出

図 3.3-6 は、雨天や降雪、あるいはカメラの汚れ等による悪条件下における比較を実施した。降雨や降雪によるオクルージョンが及ぼす検知への影響は確認できなかった。一方で、画面が霧のような汚れに覆われている場合、植え込みと道路部分の境界の区別がついていないなど、深いレイヤーにおいて適切な特徴抽出がなされていないことがわかる。本来車両のテクスチャ部分に集中して反応するべきところが、散逸した反応が見られ、検出精度に影響を及ぼしている可能性が考えられる。

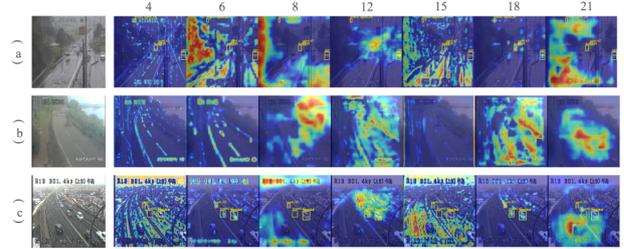


図 3.3-6 正面画角における Grad-CAM の可視化

(4) XAIによる戦略的転移学習の適用と検証

1) 提案手法の適用結果と検証

戦略的転移学習の適用結果を示す。精度検証は物体検知分野で用いられる指標の一つである Average Precision を用いる。これは、適合率再現率によって計算される。Precision を縦軸に、Recall を横軸にとった曲線を PR 曲線とし、曲線より下の領域面積が Average Precision (AP) として計算される。図 3.3-7 に PR 曲線を示す。AP は各クラス別に計算し、それらの平均は mean Average Precision (mAP) と呼ばれる指標になる。

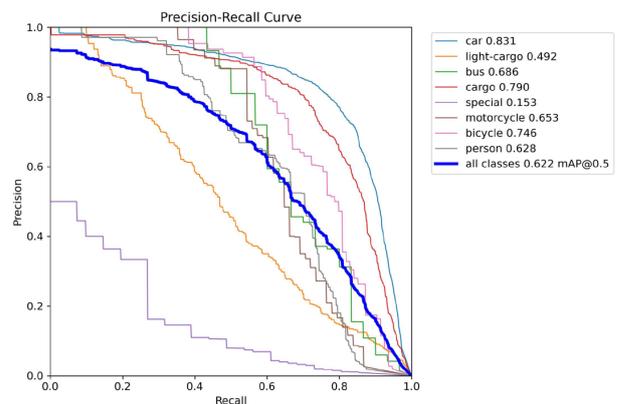


図 3.3-7 転移学習時の PR 曲線

表 3.3-1 に各クラスの AP を示す。事前学習済みモデルと転移学習モデルでラベル数が異なるため、評価するにあたりラベルの対象とな

るものが必ずしも一致しないことに注意したい。全体的に精度の向上が見られる。特に、インスタンス数が 1,000 を超えるようなラベルでは大きな変化が見られる。一方で、特殊車両や軽貨物車両など、寡少かつ事前学習済みモデルで定義されていないラベルに関しては伸び悩みが見られる。

表 3.3-1 各クラスの Average Precision
(上段：事前学習 下段：戦略的転移学習)

Class	Images	Instances	Box(P)	Recall	mAP50	mAP50-95
all	1067	4619	0.363	0.272	0.22	0.14
person	1067	315	0.475	0.346	0.302	0.194
bicycle	1067	107	0	0	0.0161	0.006
car	1067	2875	0.565	0.566	0.517	0.351
motorcycle	1067	51	0.72	0.0784	0.0991	0.0351
bus	1067	19	0.0248	0.316	0.0633	0.0354
truck	1067	1252	0.391	0.326	0.321	0.22

Class	Images	Instances	Box(P)	R	mAP50	mAP50-95
all	1067	4619	0.677	0.598	0.636	0.465
car	1067	2875	0.756	0.848	0.859	0.665
light-cargo	1067	316	0.636	0.519	0.637	0.535
bus	1067	19	0.482	0.421	0.403	0.358
cargo	1067	880	0.717	0.830	0.834	0.649
special	1067	56	0.553	0.250	0.270	0.203
motorcycle	1067	51	0.795	0.667	0.666	0.431
bicycle	1067	107	0.731	0.636	0.719	0.460
person	1067	315	0.743	0.616	0.699	0.422

2) 戦略的転移学習結果の可視化

図 3.3-8 は、転移学習後による Grad-CAM 画像の比較を示す。転移学習前後で顕著な変化が見られた画像として、夜間、前景と背景のコントラスト差が小さい、混雑時の状況が挙げられる。夜間時ではヘッドライトにのみ強く反応していたものが、転移学習後にはわずかに見える車体部分にも反応が広がっていることがわかる。したがって、学習によって、小さく解像度の粗い物体においても反応が見られることがわかる。CCTV カメラに近接した映りの物体に対しては車両の形状を立体的に取るような反応が見られ、特徴抽出のバリエーションが増えたことが推察される。

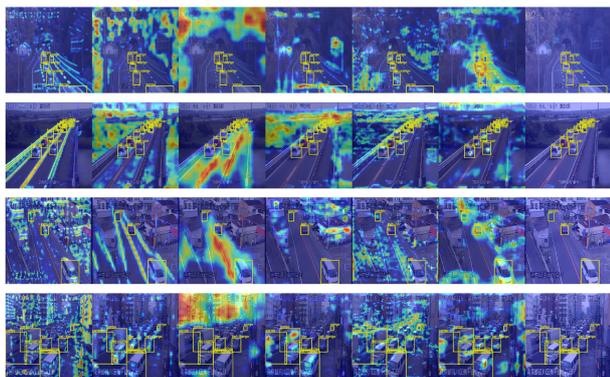


図 3.3-8 戦略的転移学習の可視化

3) 戦略的転移学習結果のドメイン分布

ドメイン分布は、機械学習モデルが生成する特徴量マップを解析する手法の一つである。このプロセスでは、モデルによって検出された物体の特徴量マップをベクトルとして平坦化し、次に UMAP (Uniform Manifold Approximation and Projection) を用いて次元削減と可視化を行う。

UMAP はデータのトポロジーである各データ点間の距離関係を保持することに重点を置いた次元削減手法である。これにより、局所的なデータ構造と大域的なデータ構造を維持するように設計されており、データの全体的な形状や関連性を正確に反映する。また、t-SNE や PCA といった次元削減手法に比べて計算効率が高い。車両のような特定の物体に注目して分析した場合、物体の異なる特徴やバリエーションが明らかになると考えられる。UMAP を用いることで、異なる特徴がどのように関連、類似しているかを可視化し、解釈可能性の向上とすることを目的とする。

図 3.3-9 は柳生大橋（右岸）の全時間帯で推論した UMAP 出力結果を示す。全体的な傾向としては、車両の角度、車両の色味によってクラスターが形成されている。とくに車両の色味に関しては白と黒に大きく大別されている。車両の角度では、車両のフロント方向とリア方向の 2 種類でそれぞれクラスターが形成されており、UMAP では角度と色味に関して大きく次元圧縮が定義されていると考えられる。さらに細かく見ると、データ群が大きく枝分かれしていることがわかる。枝の根元付近では検出サイズの小さい物体、枝先にかけて比較的大きい物体が検出されていることがわかる。また、貨物車系の物体、普通車両系の物体で分類されているが、全体的に軽貨物車両や小型貨物車両が混在している。最も離れたクラスターでは映り込んでいる倉庫が貨物として検出されている。

図 3.3-10 に千住大橋における UMAP 出力結果を示す。慢性的な混雑が見られる地点であり、オクルージョンによる不検出や誤分類が多く見られる。特に、誤検出のパターンでは複数の車両をひとまとめにして検出していることが見られる。これらは大型貨物車両に多く、オクルージョンが発生しているデータでのさらなる学習の必要性が示されている。特筆すべき点としては、事前学習モデルでは得られていなかった白い貨物車両の荷台部分のみで検出されている群が存在している。特徴が少ない部分で検出がされていることがいえ、画像のクローズによる学習の効果があると考えられる。

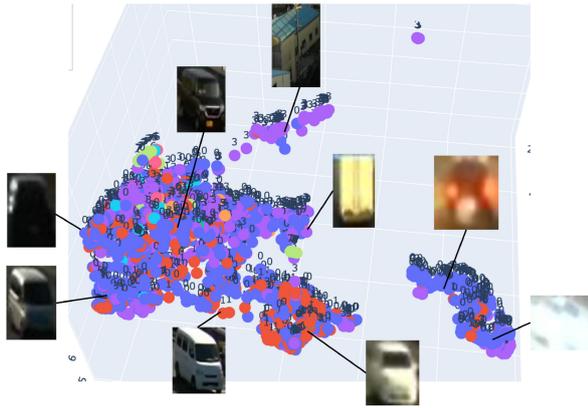


図 3.3-9 戦略的転移学習後の UMAP 画像（全時間）

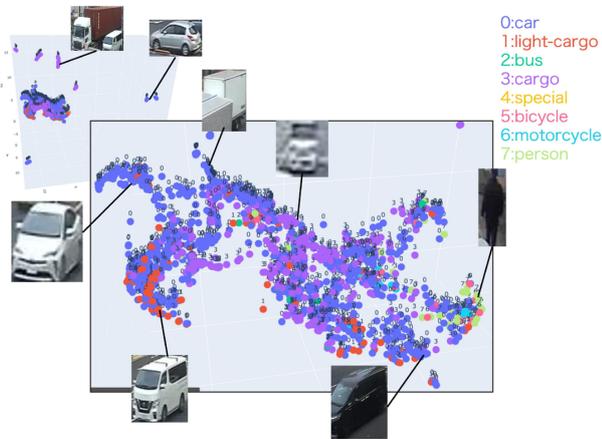


図 3.3-10 戦略的転移学習後の UMAP 画像（昼間）

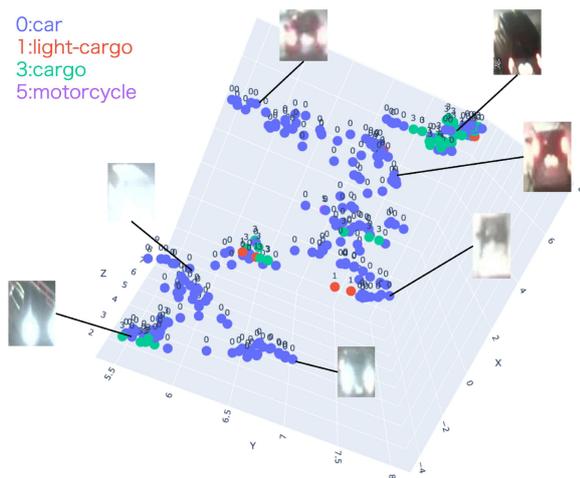


図 3.3-11 戦略的転移学習後の UMAP 画像（夜間）

図 3-3-11 に神宮橋における UMAP 出力結果を示す。本地点はヘッドライトによるレンズフレアが顕著に影響している地点であり、事前学習済みモデルでは計測が困難である。転移学習後モデルでは、昼間と同様に色味別、車両の方向によって大まかに分類されていることがわかる。さらに、従来検出困難であった coming 方向（手前側へ向かう方向）の車両も良好に検出されていることがわかる。色味に関しては、ブレーキランプによる赤、レンズフレアの影響が大きく白味がかっている車両、レンズフレアの影響が大きく黒っぽい車両に大別することができる。このうち、UMAP 画像中央部のクラスターはレンズフレアの影響が顕著に大きく、車種分類が適切になされていない場合がある。

(5) 本研究の成果

XAI アルゴリズムの判断結果を用いて、データ分布の不均衡性を考慮した戦略的な転移学習を実施した。具体的には、コントラストやブレンダーなどの弱点となる特徴を含むデータやオーグメンテーションのパラメータを反映させることで、効率的な学習が可能であることが示唆された。戦略的転移学習によって、従前物体検出が困難であった夜間やレンズフレア発生条件下などでの精度向上に寄与しつつ、アンノテーションの省力化という点で考慮することが可能となった。また、不均衡性を解消するように、分類が曖昧となっているクラスについて重点的にデータオーグメンテーションを実施し、クラス分類に関してもより頑強な推論が可能となった。

3.4 ドメイン適応およびデジタルツインを活用した地点別自己学習の提案と検証

(1) はじめに

AI 解析技術を活用した交通計測手法は、アノテーションデータセットを作成し、転移学習を行うことで、学習対象地点の検出精度が上昇することが確認された。一方、未学習地点では地点固有の背景などのドメイン知識を十分に獲得することが難しい。また、横断歩道上や白いタイルの上においては、学習地点であっても検出精度が低下するという問題が存在する。一般的な解決策として、検出精度が低い条件や地点において更なるアノテーションデータセットを作成し、学習することが挙げられる。しかしながら、全ての観測地点において学習データセットを作成することは不可能である。

本検討では、追加的なアノテーションを必要としない地点毎の自己学習アルゴリズムを構築し、低コストでの精度向上を目指す。具体的には、横断歩道上において検出精度が低下するという事象が存在したことから、背景の影響が大きいと予想し、背景に注目した自己学習に取り組む。さらに、雨天時や降雪時などの稀な状況での自己学習に対応するため、デジタルツインを応用した方法についても提案する。

(2) ドメイン適応に基づく地点別自己学習アルゴリズムの提案

1) 自己学習アルゴリズムの概要

本研究では「正解ラベル付き画像を自動生成」と「生成データによる転移学習」を精度が改善するまで繰り返す手法を提案する。なお、このようなタスクは自己学習 (self-learning) や半教師あり学習 (semi-supervised learning) と呼ばれており、AI 研究の実務展開を行う上で重要な研究課題として位置づけられている。

全体フレームワークを図 3.4-1 に示す。自己学習アルゴリズムにおける学習画像の作成は、Faster-R-CNN をベースとするインスタンスセグメンテーションモデルである Mask-R-CNN を使用する。インスタンスセグメンテーションでは、物体検出に加えて物体の形状まで抽出し、画像をピクセル単位で分類が可能であり、取得した画像を正解ラベルとして活用する。具体的に手順は下記のとおりである。

- ① YOLO を用いて物体検出を行い、対象のみを切り抜いた画像を収集
- ② Mask-R-CNN を用いて輪郭情報を取得

- ③ 取得した輪郭情報を用いて、歩行者を切り抜き、正解画像とラベルを取得
- ④ 正解ラベルをランダムに背景画像に配置して合成した学習画像を生成
- ⑤ 合成画像を複数枚生成して、転移学習を実施

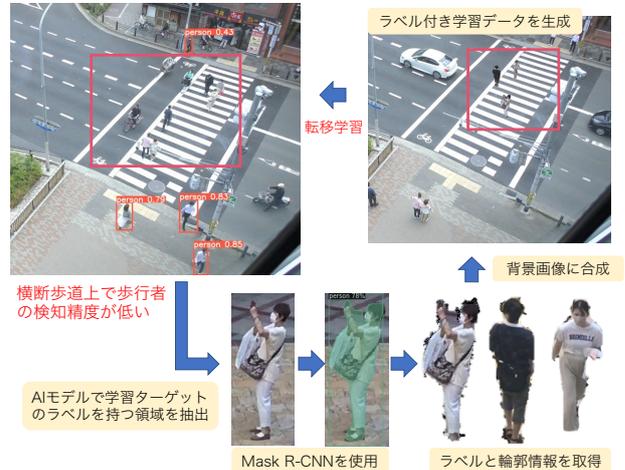


図 3.4-1 提案する自己学習の全体フロー

2) 交差点部における二輪車・歩行者への適用

転移学習時に使用したデータに、背景の合成画像を加えたデータセット、一般道路が背景の合成画像を加えたデータセットを作成し、これを学習データとする (図 3.4-2)。評価データは地点 1 のアノテーションデータのみとし、合成画像の枚数を変化させた場合の mAP を比較すあり、データセット名に関しては地点 1 の観測

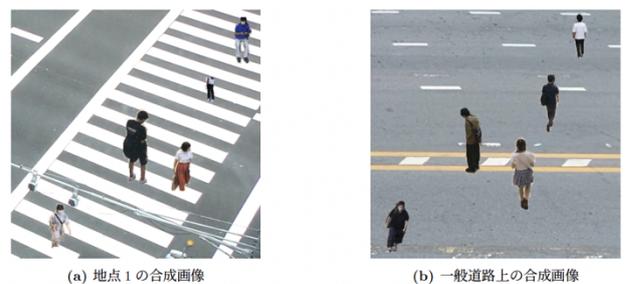


図 3.4-2 学習用に作成した合成画像の例

表 3.4-1 検証用の合成画像データセットの概要

データセット名	背景画像	合成画像枚数	評価データ (地点 1)
normal-mix0	-	0	評価データ (地点 1)
same-point-mix50	観測対象地点 (地点 1-京都斎藤町地内)	50	評価データ (地点 1)
same-point-mix100		100	
same-point-mix200		200	
same-point-mix300		300	
same-point-mix400		400	
same-point-mix570		570	
another-point100	比較地点 (一般道路)	100	評価データ (地点 1)
another-point200		200	
another-point300		300	

る。作成したデータセットは表 3.4-1 の通りで対象地点が same-point, 比較地点は another-point となっている。

観測地点と同一の背景を用いた場合において mAP の増加傾向が確認された。よって、合成画像による学習は精度向上において有効な手段だといえる。この結果を踏まえると、交通量計測 AI の精度を上昇させる手段として、データの地点数を増加させるだけでなく、各クラスのデータのバリエーションを増加させ、観測地点ごとに背景を用いた自己学習を行うことが現実的な手段だと言える。

3) CCTV カメラによる車両検知への適用

戦略的転移学習を実施した学習済みモデルに対して、CCTV カメラに映る車種別での自動車を対象に地点別自己学習を適用した。図 3-5-4 に示すように、学習前には画面全体を覆うような過剰なバウンドボックスが見られた。また、影などの日照変化によって車両検知精度が大幅に確認されており、地点固有の環境要因が検知精度を低下させていた。学習後では、過剰なバウンドボックスは無くなり、安定した結果が得られるようになった。また、平均精度は 64.8% から 81.7% に増加し、20 ポイントほどの改善が見られた。

以上より、本提案手法は自動車、二輪車、歩行者のモード検知に対して有効であり、さらに地点の環境特性に対しても性能を発揮することが確認された。

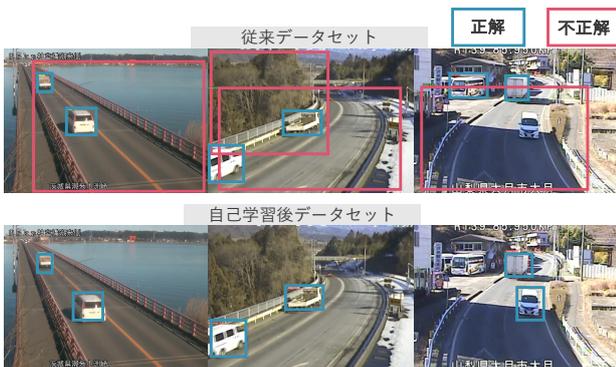


図 3.4-3 提案手法による学習結果の比較

3) デジタルツインによる地点別自己学習アルゴリズムの提案

先述の地点別自己学習アルゴリズムでは、学習対象となる動画画像が手元にあることを前提とした方法であり、工数をかけずに高精度化を実現している。しかしながら、雨天時や降雪時などの動画画像がない場合には、これらの特徴は学習されないため、AI モデルの汎化性能を高め

ることは難しい。そこで、本研究では、地点別自己学習の考え方を下敷きとしてデジタルツインを活用した学習アルゴリズムを提案する。

CCTV カメラ画角の再現には、ゲームエンジンを利用して 3D-CG を作成した。図 3.4-4 は CCTV カメラ画像の画角を再現した結果である。



図 3.4-4 ゲームエンジンによる画角の再現



図 3.4-5 様々な環境条件の再現

このような基本モデルを作成すれば、ゲームエンジン上の機能を利用してワンクリックで様々な環境条件を再現することが可能である。図 3-5-6 には、気象変化として降雨時と降雪時、時間変化として夜間と早朝の再現例を示している。画像処理技術の進歩により、ライティングやマテリアルの再現が非常にリアルであり、一見して CG とは見分けがつかないような画像を作成することが可能である。様々な状況を再現した上で、地点別自己学習を実施した結果、精度が改善することが確認された。

3.5 交通計測特化型AIモデルと提案学習手法による高度化の検証

(1) 交通計測特化型AIモデルの検証フロー

これまでに示した交通計測特化型 AI モデルおよび学習アルゴリズムを活用して、リリース版となる最終モデルの学習と検証を実施する。具体的には、下記のモデルについて検討を行う。

- 交通計測特化型AI「ベースモデル」: 本論が提案する戦略的転移学習を用いて、交通計測特化型AIモデルを学習させる。これにより、全ての地点で適用可能な汎用性を持つ基本モデル（ベースモデル）を構築する。
- 交通計測特化型AI「地点別モデル」: 本論が提案する地点別自己学習を用いて、交通計測特化型AIモデルを学習させる。ここでは、上記のベースモデルに対して、地点別自己学習を行うことで、ベースモデルでは精度改善が必要な地点に専用化したモデル（地点別モデル）を構築する

なお、断面交通量により精度検証を行った。本項の概要を下図に示す。

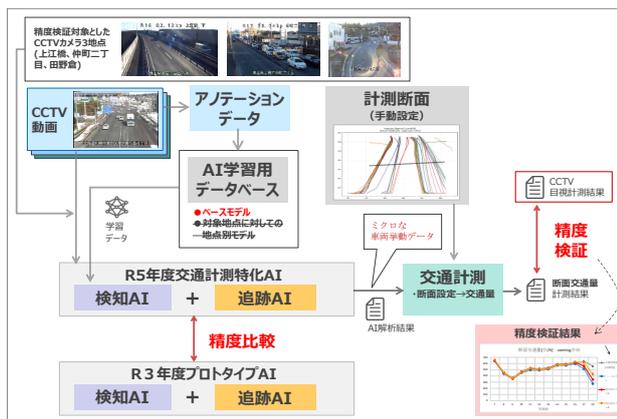


図 3.5-1 提案モデルの検討概要

精度検証では、方向別の断面交通量計測結果と与件の目視計測結果の1時間集計値の比較により精度評価を行う

精度検証における各種設定条件および評価方法については、下記のとおりとした。

- 検証対象とする移動方向は、手前から奥going方向、奥から手前coming方向の2方向とする。
- 1時間単位での精度評価は、目視計測結果を正解値とし、1時間ごとの通過台数、通過人数の正解率を「精度」として評価する。計算式は以下の通りである。
- [精度(%)] = [AI断面計測結果(台)] / [目視計測結果(台)]

- 精度が100%であれば、目視計測結果と完全一致となる。100%未満となった場合は、過小評価（検知漏れ、計測漏れ）、100%より大きな値となった場合は過大評価（重複検知、ダブルカウント）と考えられる。
- 車両における小型車と大型車に分類はして集計する。小型は普通乗用車 (car)、軽乗用車 (kei-car) 軽貨物車 (kei-cargo)、小型貨物車 (light-cargo) とし、大型車は普通貨物車 (cargo)、バス (bus)、特殊 (special) を集計した。

(2) 交通計測特化型AIベースモデルの性能検証例として上江橋における検証結果を示す。

1) 計測断面の位置

上江橋の断面交通量計測は下図緑色で示した計測断面の位置で行った (図 3.5-2)。計測断面の動画像上での位置座標 (左上が原点とし、右方向、下方向が+) は以下の通りである。

2) 断面交通量の計測結果

1時間当たりの断面交通量計測結果を図 3.5-3 に示す。ベースモデル (赤線) は、全時間帯で正解値 (灰色線) と同様なトレンドを示し、精度よく断面交通量を計測できていることが分かる。特に coming 方向では、R3 年度のプロトタイプモデル (青線) に比べ、大幅に改善されていることが分かる。

3) 時間帯別断面交通量の計測精度

時間帯別の断面交通量計測精度を図 3.5-4 に示す。ベースモデル (赤線) の精度は、全時間帯で安定して±10%以内の精度が得られた。

4) 大型車混入率

方向別時間帯別の大型車混入率の計測結果を図 3.5-5 に示す。正解値 (灰色線) とベースモデル (赤線) を比較すると、ベースモデルは大型車混入率が 10~20%程度多く計測される傾向が見られる。しかしながら、R3 年度のプロトタイプモデル (青線) と比較すると、ベースモデルは大型車混入率のトレンドはよく表しており、改善が見られる。

5) 精度検証結果の比較

精度検証結果の比較 (表 3.5-1) を以下に示す。ベースモデルにおいて、going 方向の混雑時、非混雑時、夕方～夜間の 3 時間帯の精度は±10%以内の精度が得られた。going 方向の精度は混雑時を除き 100%を超えており、ややオーバーカウントとなる傾向がある。一方、coming 方向では、3 時間帯で 90%前後の精度となった。coming 方向は、オクルージョンが生じやすく、計測漏れが生じるためだと考えられる。

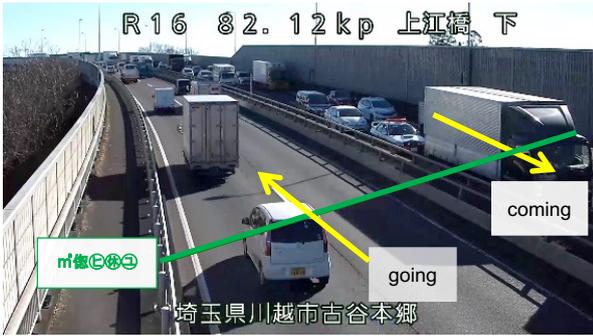


図 3.5-2 上江橋の計測断面の位置



図 3.5-3 方向別断面交通量計測の結果

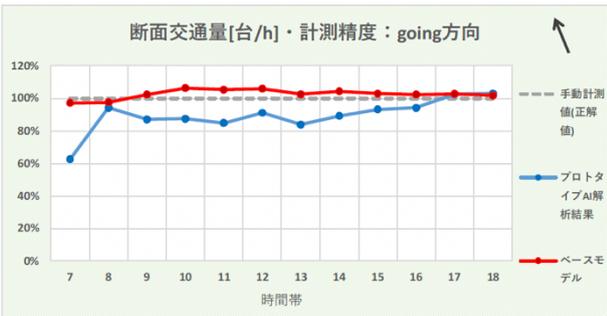


図 3.5-4 方向別断面交通量計測精度の結果



図 3.5-5 方向別大型車混入率の結果

表 3.5-1 上江橋における精度比較表

プロトタイプAI (R3年度)						ベースモデル (R5年度) 比較					
種別・丁目	going	going	coming	coming	ALL	line_index	going	going	coming	coming	ALL
番号	合計	大型車混入率	合計	大型車混入率	合計	番号	合計	大型車混入率	合計	大型車混入率	合計
7	999	55.4%	785	34.8%	1384	7	1198	19.3%	960	24.5%	2158
8	769	55.4%	604	56.1%	1373	8	1216	21.9%	1103	25.6%	2319
9	819	53.4%	552	52.9%	1371	9	1182	29.4%	1063	32.2%	2245
10	979	62.1%	666	51.7%	1645	10	1279	32.7%	953	35.0%	2232
11	938	65.5%	681	45.7%	1619	11	1277	31.4%	957	35.2%	2234
12	960	69.3%	652	52.0%	1602	12	1284	27.5%	1011	34.3%	2295
13	974	58.0%	640	54.7%	1614	13	1275	27.5%	1045	33.9%	2320
14	923	69.1%	615	56.6%	1538	14	1329	26.3%	1128	30.4%	2457
15	1020	56.4%	753	32.3%	1773	15	1315	22.9%	1021	23.7%	2336
16	1268	52.2%	903	32.1%	2171	16	1375	24.6%	1124	21.9%	2499
17	1519	23.8%	1389	11.4%	2904	17	1416	15.5%	1247	13.5%	2663
18	1505	21.9%	1353	10.9%	2858	18	1454	11.7%	1276	12.1%	2732
7	74.1%	494.1%	71.0%	252.8%	72.9%	7	98.3%	172.0%	86.9%	178.0%	93.3%
8	69.5%	380.0%	46.5%	253.8%	54.7%	8	100.4%	154.0%	85.0%	161.1%	92.4%
9	79.3%	364.9%	43.0%	273.7%	56.0%	9	101.5%	146.0%	82.9%	166.4%	91.7%
10	80.0%	274.4%	53.5%	251.0%	64.7%	10	102.0%	144.7%	76.6%	170.3%	89.2%
11	77.1%	323.8%	54.7%	210.7%	65.7%	11	104.9%	155.3%	76.8%	162.5%	90.1%
12	78.0%	419.8%	54.7%	241.4%	66.4%	12	105.4%	176.2%	84.7%	159.3%	95.2%
13	80.0%	379.5%	52.8%	293.3%	66.4%	13	104.8%	179.6%	86.2%	181.7%	95.5%
14	75.2%	431.5%	48.2%	336.5%	61.5%	14	108.3%	175.6%	88.5%	187.3%	98.2%
15	81.6%	477.5%	63.5%	260.4%	72.8%	15	106.2%	197.3%	86.1%	191.2%	95.9%
16	106.1%	904.2%	72.0%	365.1%	88.6%	16	115.1%	425.7%	89.6%	249.5%	102.0%
17	113.1%	322.4%	68.3%	290.5%	88.6%	17	105.4%	210.8%	80.6%	435.9%	80.6%
18	112.4%	329.0%	68.3%	290.5%	88.6%	18	108.6%	110.7%	435.9%	80.6%	80.6%
全時間	84.8%	63.9%	74.3%	63.9%	74.3%	全時間	105.1%	86.0%	95.5%	95.5%	95.5%
混雑時	68.8%	57.8%	63.3%	63.3%	63.3%	混雑時	99.6%	85.9%	92.7%	92.7%	92.7%
非混雑時	77.5%	52.8%	65.1%	65.1%	65.1%	非混雑時	104.6%	83.1%	93.8%	93.8%	93.8%
夕方・夜間	110.7%	72.0%	88.6%	88.6%	88.6%	夕方・夜間	109.5%	89.6%	102.0%	102.0%	102.0%

6) 総合的な精度検証結果の整理

R3年度で精度が低かった3地点(上江橋, 仲町二丁目, 田野倉)に対して, 断面交通量の精度を検証した. 精度検証結果を表3.5-2に示す. なお, 下表の評価は, 精度±10%以内の時は○, 精度が±20%以内の時は△, それ以上の誤差がある時は×とした.

R3年度のプロトタイプで比較的精度が良いのが田野倉のgoingのみであったことに対し, R5年度ベースモデルでは, going方向では全ての地点で±10%以内の精度が得られた. 他方coming方向の仲町二丁目では80%台の精度であった. これはオクルージョンの影響によるものだと考えられ, カメラ画角の変更により精度が向上すると考えられる. 田野倉coming方向

の夕方～夜間の時間帯では77.3%の精度であり課題が残る。これについては、次節にて構築する「地点別モデル」を適用して追加で精度検証を実施する。

表 3.5-2 3地点における計測精度の評価

カメラ名	時間帯	R3年度 プロトタイプAIモデル		R5年度 ベースモデル	
		going ↑ 評価	coming ↓ 評価	going ↑ 評価	coming ↓ 評価
上江橋	全時間	89.3% △	52.9% ×	102.5% ○	102.5% ○
	混雑時	75.8% ×	24.3% ×	97.5% ○	97.5% ○
	非混雑時	88.3% △	47.1% ×	104.3% ○	104.3% ○
	夕方-夜間	100.2% ○	88.6% △	102.4% ○	102.4% ○
仲町二丁目	全時間	84.8% △	63.9% ×	105.1% ○	86.0% △
	混雑時	68.8% ×	57.8% ×	99.6% ○	85.9% △
	非混雑時	77.5% ×	52.8% ×	104.6% ○	83.1% △
	夕方-夜間	110.7% △	72.0% ×	109.5% ○	89.6% △
田野倉	全時間	91.5% ○	73.7% ×	101.2% ○	94.6% ○
	混雑時	95.5% ○	95.2% ○	100.5% ○	100.6% ○
	非混雑時	87.5% △	70.8% ×	105.6% ○	101.8% ○
	夕方-夜間	97.6% ○	66.3% ×	92.1% ○	77.3% ×

7-8時台 混雑時
9-15時台 非混雑時
16-18時台 夕方-夜間

評価凡例
○: 精度±10%以内
△: 精度±20%以内
×: それ以下

going方向は全時間帯で10%以内の精度を達成

coming方向は、R3年度と比較して大きな改善が見られたが、田野倉の夜間では課題が残る

(3) 交通計測特型AI地点別学習の性能検証

例として田野倉における検証結果を示す。ここで、地点別モデル1と地点別モデル2は、夜間の学習データをそれぞれ1%および6%混入したケースである。

1) 計測断面の位置

田野倉の断面交通量計測は下図緑色で示した計測断面の位置で行った(図3.5-6)。計測断面の動画像上での位置座標(左上が原点とし、右方向、下方向が+)は以下の通りである。

2) 断面交通量の計測結果

1時間当たりの断面交通量計測結果を図3.5-7に示す。地点別モデル1(赤線)と地点別モデル2(オレンジ線)は、ベースモデル同様、昼間の台数のトレンドをよく表す。夜間の学習データを増やしたことで、昼間の精度が下がることが懸念されたが、その影響は軽微であると言える。また、17時台、18時台は地点別モデルを適用することにより、計測台数がやや増加することが確認された。

3) 時間帯別断面交通量の計測精度

時間帯別の断面交通量計測精度を図3.5-8に示す。地点別モデル1(赤線)に比べ、地点別モデル2(オレンジ線)の計測精度は、going方向、coming方向共に、17時台～18時台で精度の向上が見られる。しかしながら、課題であったcoming方向の精度は、60%台に留まる。昼間の精度は、ベースモデルと同様に高い精度で、安定しているが地点別モデルではオーバーカウントが増える傾向が見られた。

4) 大型車混入率

方向別時間帯別の大型車混入率の計測結果を図3.5-9に示す。大型車混入率は、地点別モデル1と地点別モデル2で同様な傾向であり、大型車混入率のトレンドをよく表す。

5) 精度検証結果の比較

精度検証結果の比較(表3.5-3)を以下に示す。ベースモデルで課題であったcoming方向夕方～夜間(16～18時台)の精度は、地点別モデル2では、93.6%と±10%以内の精度を達成できた。一方、その他の時間帯、方向については、オーバーカウントの傾向が地点別モデル1よりも大きくなり、going方向の非混雑時の精度は109.7%とその傾向が強くなった。

6) 総合的な精度検証結果の整理

田野倉の夜間の精度向上を目的とし、ベースモデルに対して田野倉の夜間の学習データの割合を増やすことで構築した田野倉の地点別モデルを適用した時の精度検証を行った。構築した田野倉の地点別モデルは、混入した夜間データの割合により2つのモデルを検討した。精度検証結果を表3.5-4に示す。

田野倉の夜間の学習データを混入させて構築した地点別モデル1、2共に夜間の断面交通量計測精度の向上が見られ、ベースモデルで課題であった夕方～夜間の精度が地点別モデル2で93.6%と±10%以内の精度が得られた。このことより、ベースモデルで精度が低い地点、時間帯を重点的に学習させた地点別モデルが精度向上に寄与することが分かった。一方、ベースモデルの時点で精度が良い時間帯では、地点別モデルを適用するとオーバーカウントする傾向が強くなることが分かった。オーバーカウントの発生については今後の課題となる。



図 3.5-6 田野倉の計測断面の位置

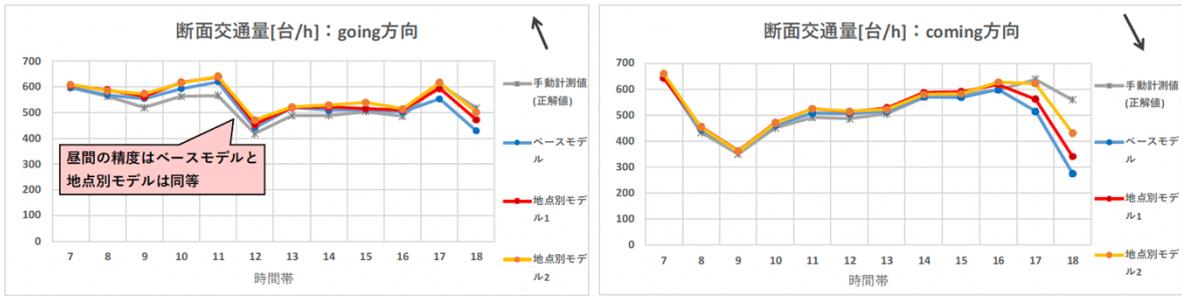


図 3.5-3 方向別断面交通量計測の結果

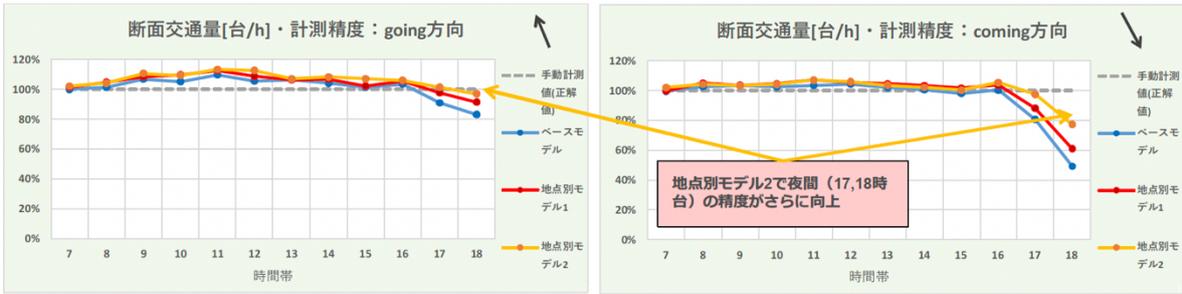


図 3.5-4 方向別断面交通量計測精度の結果

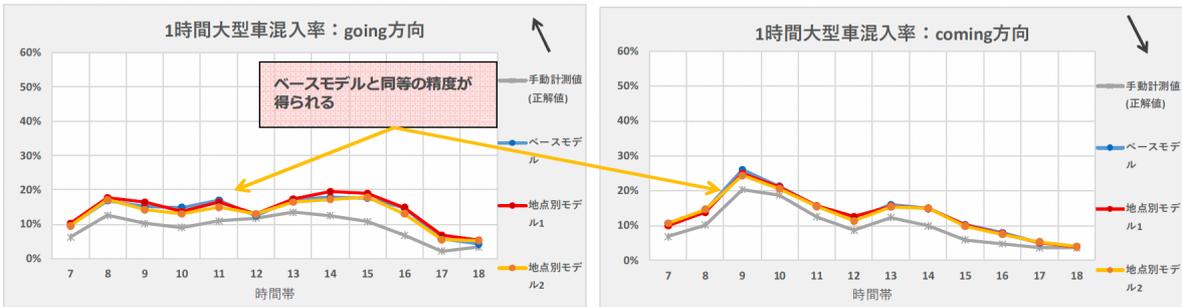


図 3.5-5 方向別大型車混入率の結果

表 3.5-3 学習アルゴリズムの違いによる精度比較表

ベースモデル (R5年度)

line_index	1	名前				ALL
		going	coming	going	coming	
時間帯	合計	going_大型車混入率	coming_合計	coming_大型車混入率	合計	大型車混入率
7	596	9.7%	642	10.6%	1288	
8	569	16.9%	445	14.4%	1014	
9	534	15.2%	362	26.0%	916	
10	592	14.9%	461	21.3%	1053	
11	620	16.9%	598	15.6%	1128	
12	441	12.5%	506	11.9%	947	
13	519	17.1%	515	15.9%	1034	
14	509	17.9%	571	14.9%	1080	
15	510	17.6%	569	10.2%	1079	
16	502	14.7%	598	7.9%	1100	
17	553	5.8%	514	5.1%	1067	
18	429	4.2%	275	4.0%	704	
	精度値	精度値	精度値	精度値		
7	99.8%	157.0%	99.4%	155.5%	99.6%	
8	101.2%	133.5%	102.5%	141.9%	101.8%	
9	106.7%	148.5%	103.4%	128.0%	105.4%	
10	105.2%	164.1%	102.4%	113.9%	103.9%	
11	109.5%	154.6%	103.5%	125.2%	106.7%	
12	105.5%	106.4%	104.1%	137.2%	104.8%	
13	106.4%	126.8%	102.0%	129.7%	104.1%	
14	104.1%	143.3%	100.5%	151.0%	102.2%	
15	101.2%	164.7%	97.9%	174.2%	99.4%	
16	103.5%	216.6%	100.2%	167.6%	101.7%	
17	90.8%	271.1%	80.6%	140.3%	85.6%	
18	83.0%	127.6%	49.2%	111.8%	65.4%	
全時間	101.2%		94.6%		97.9%	
混雑時	100.5%		100.6%		100.6%	
非混雑時	105.6%		101.8%		103.7%	
夕方-夜間	92.1%		77.3%		84.3%	

地点別モデル1 (R5年度)

line_index	1	名前				ALL
		going	coming	going	coming	
時間帯	合計	going_大型車混入率	coming_合計	coming_大型車混入率	合計	大型車混入率
7	606	10.2%	643	10.0%	1249	
8	588	17.7%	455	13.8%	1043	
9	562	16.4%	362	24.9%	924	
10	617	13.6%	470	21.1%	1087	
11	638	16.5%	525	15.6%	1163	
12	454	13.0%	512	12.5%	966	
13	519	17.3%	528	15.5%	1047	
14	522	19.5%	586	14.8%	1108	
15	515	19.0%	590	10.0%	1105	
16	511	14.9%	618	7.6%	1129	
17	594	6.7%	561	5.2%	1155	
18	472	5.3%	341	3.8%	813	
	精度値	精度値	精度値	精度値		
7	101.5%	165.1%	99.5%	146.1%	100.5%	
8	104.6%	140.0%	104.8%	136.6%	104.7%	
9	108.3%	160.3%	103.4%	122.6%	106.3%	
10	109.6%	150.3%	104.4%	112.8%	107.3%	
11	112.7%	150.2%	106.9%	125.7%	110.0%	
12	108.6%	110.9%	105.3%	144.6%	106.9%	
13	106.4%	128.2%	104.6%	126.5%	105.4%	
14	106.7%	156.6%	103.2%	150.6%	104.8%	
15	102.2%	177.6%	101.5%	170.9%	101.8%	
16	105.4%	218.6%	103.5%	162.2%	104.3%	
17	97.5%	315.5%	87.9%	143.4%	92.6%	
18	91.3%	161.1%	61.0%	106.6%	75.6%	
全時間	104.4%		98.2%		101.3%	
混雑時	103.0%		101.7%		102.4%	
非混雑時	107.9%		104.1%		106.0%	
夕方-夜間	97.9%		84.7%		91.0%	

地点別モデル2 (R5年度)

line_index	0	名前				ALL
		going	coming	going	coming	
時間帯	合計	going_大型車混入率	coming_合計	coming_大型車混入率	合計	大型車混入率
7	609	9.5%	659	10.6%	1268	
8	585	17.1%	452	14.6%	1037	
9	574	14.3%	361	24.4%	935	
10	615	13.0%	468	20.5%	1083	
11	641	15.0%	595	15.4%	1166	
12	471	13.0%	515	11.3%	986	
13	522	16.5%	522	15.3%	1044	
14	509	17.2%	580	15.0%	1109	
15	509	17.8%	582	9.8%	1121	
16	514	13.0%	628	7.5%	1142	
17	617	5.5%	621	5.3%	1238	
18	501	5.2%	431	3.9%	932	
	精度値	精度値	精度値	精度値		
7	102.0%	153.7%	102.0%	156.0%	102.0%	
8	104.1%	135.3%	104.1%	144.0%	104.1%	
9	110.6%	139.9%	103.1%	120.2%	107.6%	
10	109.2%	143.6%	104.0%	109.9%	106.9%	
11	113.3%	136.7%	106.9%	124.2%	110.3%	
12	112.7%	110.5%	106.0%	130.3%	109.1%	
13	107.0%	121.8%	103.4%	124.8%	105.1%	
14	108.2%	137.9%	102.1%	152.1%	104.9%	
15	106.9%	166.2%	100.2%	167.4%	103.3%	
16	106.0%	191.6%	105.2%	159.6%	105.5%	
17	101.3%	258.1%	97.3%	147.4%	99.3%	
18	96.9%	157.8%	77.1%	110.2%	86.6%	
全時間	106.3%		100.6%		103.5%	
混雑時	103.0%		102.9%		102.9%	
非混雑時	109.7%		103.6%		106.7%	
夕方-夜間	101.3%		93.6%		97.3%	

表 3.5-4 学習アルゴリズムの違いによる計測精度の評価

	R3年度プロトタイプモデル				R5年度ベースモデル				
	going	評価	coming	評価	going	評価	coming	評価	
田野倉	全時間	91.5%	○	73.7%	×	101.2%	○	94.6%	○
	混雑時	95.5%	○	95.2%	○	100.5%	○	100.6%	○
	非混雑時	87.5%	△	70.8%	×	105.6%	○	101.8%	○
	夕方-夜間	97.6%	○	66.3%	×	92.1%	○	77.3%	×

	R5年度田野倉地点別モデル1				R5年度田野倉地点別モデル2				
	going	評価	coming	評価	going	評価	coming	評価	
田野倉	全時間	104.4%	○	98.2%	○	106.3%	○	100.6%	○
	混雑時	103.0%	○	101.7%	○	103.0%	○	102.9%	○
	非混雑時	107.9%	○	104.1%	○	109.7%	○	103.6%	○
	夕方-夜間	97.9%	○	84.7%	△	101.3%	○	93.6%	○

(4) 性能検証のまとめ

1) 本検討の成果

本項では、R3年度プロトタイプモデルで精度が出なかった田野倉、仲町二丁目、田野倉の3地域に対し、交通計測特化 AI のベースモデルの精度検証を行った。その結果、本年度構築したベースモデルは、R3年度のプロトタイプモデルよりも大幅に精度向上がなされていることを確認した。

また、ベースモデルで解析した際、夜間の精度に課題が残った田野倉に対して、地点別自己学習を適用した地点別モデルで解析した結果の精度検証を行った。その結果、田野倉の夜間の学習データを混入させて構築した地点別モデル1、2共に夜間の断面交通量計測精度の向上が見られ、ベースモデルで課題であった夕方-夜間の精度が地点別モデル2で93.6%と±10%以内の精度が得られた。このことより、ベースモデルで精度が低い地点、時間帯を重点的に学習させた地点別モデルが精度向上に寄与することが分かった。

2) 今後の課題

交通特化型検知 AI ベースモデルにおける今後の課題を下記に示す。

- 仲町丁目のcoming方向では、オクルージョンの影響により精度が80%台にとどまった。これはCCTVカメラの画角を変更するなどハード的な対応で精度が向上すると考えられる。
- 田野倉の夕方-夜間の精度が77.3%と課題が残った。田野倉については、後の地点別モデルを適用し、適用して追加で精度検証を実施する。

交通特化型検知 AI カメラ地点別モデルにおける今後の課題を下記に示す。

ベースモデルの時点で精度が良い時間帯では、地点別モデルを適用するとオーバーカウントする傾向が強くなった。

地点別モデルにどの程度、合成画像を混入させる割合、種類については検討が必要

第4章 複数の観測データを融合した 交通量等データの生成・補正手法の開発

4.1 本章の検討および成果の概要

テーマ2での移動体検知結果やセンサスやトラカン、ETC2.0プローブ等から多様な交通データを生成・補正モデルを構築し、現況再現精度を評価した。カメラ画像内レベルでのマイクロデータとして、衛星画像や航空写真を用いた実空間距離（実空間座標）推定やカウントライン自動最適化を開発し、可能な限り人手を介することなく車線別車種別交通量と速度、車両軌跡データの取得を実現した。また、ネットワークレベルでのマクロデータとして、時系列AIモデルであるLSTMとガウス過程回帰を融合した時間帯別リンク・OD交通量生成モデルを構築し、性能を評価した。さらに、敵対的生成学習を活用した個人属性別のアクティビティデータ（終日の交通行動）生成モデルを構築し、これまでに取得が困難であったドライバーの個人属性を付加した交通量データの生成を試行した。

[3] 複数の観測データを融合した交通量等データの生成・補正手法の開発

(1) ミクロ交通データの生成・補正手法の開発と検証

カメラ画角内におけるミクロスケールでのデータを生成・補正する手法を開発し、その精度を検証した。ここではテーマ2で構築したAIモデルから取得した移動体検知結果を活用し、複数のデータと融合することで交通量や速度、車両軌跡を効率的に生成する。

1) 衛星および航空写真画像を活用した実空間距離の推定

移動体の移動距離や速度を算出するためには、AIによる検知したカメラ画像内の位置座標を実空間における位置座標（緯度・経度）に変換する必要がある。古くから射影変換が使われているが、実空間の位置座標を現地測量等から取

得する必要がある、非常にコストが高い状況にある。そこで、googleが無償提供している衛星画像と民間企業が有償提供している航空写真（5cmおよび25cm解像度）を活用した効率的な変換手法を提案した。複数地点のCCTVカメラ画像に対して検証した結果、距離推定の誤差率は衛星画像で1.9%、航空写真の5cmと25cm解像度で3.4%と4.4%であり、現地測量に頼らずに高い精度を確保した。

2) カメラ画角の変化に対応した計測ラインの自動最適化

交通量や速度は、カメラ画像内に計測ラインを設定して計測を行うが、実務では手作業で設定しており、画角が変化すると再設定が必要となる。また、計測ラインの設定位置によって交通量カウント結果が変化することが過年度の検討より明らかになっている。そこで、カウントラインを自動最適化する手法を構築した。具体的には、Byte Track等の追跡アルゴリズムから取得し車両軌跡データを先述の射影変換による実空間座標に変換し、車両軌跡をクラスタリングによって車線を特定する。その上で、車線別に車両軌跡の密度が最大となる計測ラインを最適化問題として探索することで、最適な計測ラインを自動で取得可能とした。画角変化に対する検証を実施した結果、最適化による更新なしでは画角の変化により計測ラインがずれするため交通量カウントが0となるが、更新ありでは画角変化に追従して計測ラインが最適化されるため適切に交通量カウントが実行された。また、複数のCCTVカメラ画角で最適化を実施した結果、手動設定よりも計測誤差が低いことが明らかとなった。

3) ミクロ交通データ生成の高度化と検証

これまでの研究成果を統合して、カメラ画像から交通量、速度および車両軌跡データの生成を行なった。車両単位での車両軌跡を生成し、

車線別の計測ラインを設定した上で、通過判定と速度算出を同時に行うロジックを構築した。その結果を任意の時間単位（5分や1時間など）、車線別および車種別での交通量と速度を取得可能とした。速度の計測精度は、人手観測と比較して±4km以内の精度であることを確認した（図4.1-1）。

以上より、実空間座標への変換、車線判別および計測ラインの自動化を導入したCCTVカメラ画像とAI技術による高精度な交通計測手法を確立した。さらに、人手によるマニュアル設定を極力排除したことで、合理化と効率化を実現し、現場負担の低減に大きく貢献することに成功したと考える。

(2) マクロ交通データの生成・補正手法の開発と検証

ネットワークレベルにおけるマクロスケールでのデータを生成・補正する手法を開発し、その精度を検証した。ここでは生成したミクロスケールの固定点観測データとETC2.0プローブやセンサ調査でデータ等を融合することで時間帯別リンク交通量およびOD交通量、アクティビティデータを生成するAIモデルを構築した。なお、研究計画を一部変更しているため、本節の内容は当初の予定とは若干異なることにご留意頂きたい。

1) 時系列AIモデルを活用した時間帯別リンク交通量生成モデルの構築と検証

対象領域における時間帯別リンク交通量は、時系列AIモデルであるLSTM（Long Short Term Memory）を活用してモデルを構築した。モデルアーキテクチャやグラフ畳み込み演算（GCN）を活用した道路ネットワーク構造の特徴量、気象データ等を考慮した精度改善を試みた。首都圏を対象とした検証の結果、決定係数0.94、RMSE13.8[car/h]と高い精度が得られたが、一部に系統的なズレを確認した。また、LSTMに代わりにリザーバーコンピューティング手法のEcho State Network（ESN）を適用して計算コスト改善を試みた。ESNはLSTMよりも数百倍高速で推

論可能であるが、予測精度が若干劣ることを確認した。

2) ガウス過程回帰を活用した時間帯別OD交通量生成モデルの構築と検証

対象領域における時間帯別OD交通量は、ガウス過程回帰（GPR）を活用して、上記にて生成したリンク交通量からOD交通量を推定する学習モデルを構築した。GPRを多層化するアプローチやカーネル関数の最適化を実施して精度改善を試みた。東京都市圏を対象とした検証の結果、複数モデルの中でDeep multi-task GPRとMatern5/2カーネルによる生成モデルが決定係数0.75と良好な結果が得られた。

以上の(1)と(2)の成果は、これまで日単位でのリンク交通量に基づく各種評価分析が実施されてきた状況において、評価分析対象期間のプローブデータ等が入手できれば、時間分解能の高い交通量データを生成可能とした。さらに、これまでデータ取得に労力を要した時間帯別OD交通量を生成可能としたことは、実務的にも大きな成果である。

3) 敵対的生成学習を活用したアクティビティデータ生成モデル構築と検証

多様な施策評価に対応すべく、個人の属性や移動目的などのアクティビティ（生活行動）データに関するニーズが見られた。本研究では、生成モデルの一種である敵対的生成ネットワーク（Generative Adversarial Network: GAN）を活用したデータ生成手法を提案した。具体的には、データセットに含まれる変数の分布を学習して仮想的なデータテーブルを生成する手法であり、CTGAN（Conditional Table GAN）とTVAE（Table Variational Auto Encoder）のアルゴリズムを東京都市圏パーソントリップ調査データに適用した。その結果、概ね観測分布と一致するデータを生成することに成功した。

今後はこれらの成果を活用して、上記の(1)から(3)のデータをフュージョンすることで属性情報等を付与した交通データの生成を試みたい。

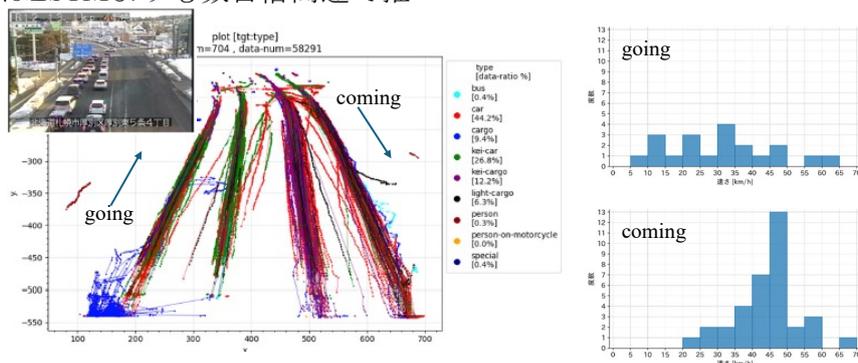


図4.1-1 車線別車種別移動軌跡と速度分布の計測例

4.2 カメラ画像における移動体の速度データ生成手法の構築と検証

(1) はじめに

本節では、実務ニーズを踏まえた多様な交通挙動データの生成を単一カメラ画像の画角から取得する手法を構築する。具体的には、3章にて検討した多様なモード（車種別自動車、二輪車、歩行者）に対応した交通計測特化型AIモデルから得られる移動体検知結果に対して、物体追跡手法を適用することで移動体の軌跡データが取得可能となる。さらに、得られた軌跡データから交通量や速度データを生成・可視化する手法を構築する。自動車、二輪車および歩行者が混在する複雑な交通状況下でのケーススタディ分析を通じて、本提案手法の有効性を確認する。

(2) 移動体追跡手法に関する整理

1) 追跡アルゴリズムの概要

Multi Object Tracking (MOT) とは、複数の特定の物体を追跡するアルゴリズムである。物体検出タスクのみでは動画内の交通量をカウントすることは不可能であるため、動画の複数フレームの中から同一物体を特定してIDの付与を行うことが必要になる。物体追跡タスクの課題は、物体同士が重なることでIDの受け渡しが発生してしまうIDスイッチングという現象や、障害物の影に隠れるなどして新しいIDが付与され追跡が終了してしまう現象が挙げられる。そのため、動画内の物体の数が増えると難易度は上昇する。

2) カルマンフィルタ

カルマンフィルタは、物体追跡タスクの基本になるアルゴリズムであり、得られる観測情報から現在の状態を推定する状態空間モデルの1つである。物体追跡タスクにおいては、物体検出の結果が観測情報になり、前のフレームから求めた状態推定値などを用いることで、フレーム間の物体を結びつける。足立¹⁾の論文を参考にして記述する。

時系列の状態空間モデル

時系列 $y(k)$ の状態空間モデルを考えると、離散時間状態方程式は以下ようになる。

$$x(k+1) = Ax(k)$$

ここで、 $x(k)$ は時刻 k における状態であり、未来の状態を予測するための必要な最小データを表している。 A は状態遷移関数であり、前の状

態から次の状態へ遷移する時間変化の関数を表す。そのため、等速度モデルと定義しているトラッキングモデルの場合においては時間差 Δt が状態遷移関数の要素となる。観測(出力)方程式は以下ようになる。

$$y(k) = c^T x(k) + w(k)$$

ここで、 c は観測係数ベクトルと呼ばれ、事前推定量（物理量）から観測量への変換係数ベクトルになる。また、 $w(k)$ はノイズと呼ばれる、観測誤差になる。これらの式が時系列の状態空間表現である。

線形カルマンフィルタ

線形カルマンフィルタは、状態 $\hat{x}(k-1)$ から次の状態 $\hat{x}^-(k)$ に更新する予測ステップ、最新の観測値を利用して、新しいフレームでの状態を予測して、 $\hat{x}^-(k)$ から $\hat{x}(k)$ に更新するステップに分けられる。ここで、 $\hat{x}(k-1)$ は時刻 $k-1$ の時の状態推定値、 $\hat{x}^-(k)$ は時刻 k の状態推定値だが、時刻 $k-1$ の情報のみを用いて予測した状態であるため、事前推定値と呼ばれる。 $\hat{x}(k)$ は、最新の観測値を利用した時刻 k の状態推定値のため、事後推定値と呼ばれる。

カルマンフィルタの時間更新式は、 $k = 1, 2, \dots, N$ に対して以下の式を計算する。予測ステップにおいては、事前状態推定値と事前誤差共分散行列を導出する。

事前状態推定値：

$$\hat{x}^-(k) = A\hat{x}(k-1)$$

事前誤差共分散行列：

$$P^-(k) = AP(k-1)A^T + \sigma_v^2 bb^T$$

ここで、 $\sigma_v^2 bb^T$ は状態推定の際に生じる誤差項である。更新ステップでは、カルマンゲイン、事後状態推定値および事後誤差共分散行列を以下のように導出する。

カルマンゲイン：

$$g(k) = \frac{P^-(k)c}{c^T P^-(k)c + \sigma_w^2}$$

事前状態推定値：

$$\hat{x}(k) = \hat{x}^-(k) + g(k)(y(k) - c^T \hat{x}^-(k))$$

事後誤差共分散行列：

$$P(K) = (I - g(k)c^T)P^-(K)$$

カルマンゲインに用いられている σ_w^2 は、観測誤

差の分散であるため、観測誤差が大きいほどカルマンゲインの値は小さくなる。よってカルマンゲインは、状態推定値を導出する際に観測値とモデルによって推定した値と、どちらを重視するかを重みを表すものといえる。

3) Strong-SORT

物体追跡モデルの多くは、カルマンフィルタを利用して予測したbounding boxの位置情報から、前後のフレームのマッチングを行なっている。深層学習を取り入れ、外見情報を抽出してトラッキングに取り入れたものが2017年に発表されたdeep-SORTであり、deep-SORTを改良したモデルがStrong-SORT2)である。

Strong-SORTは、外特徴抽出器にBoTが導入されている。BoTは、ResNest50をバックボーンとしているモデルのため、単純なCNNのみであったdeep-SORTと比較して、Strong-SORTは、個体同士の特徴抽出能力が向上している。また、カルマンフィルタについても改善が成されており、新たに導入されたNSAカルマンというアルゴリズムは、物体の検出信頼度に応じて観測ノイズを変化させる役割を果たす。NSAカルマンの入出力とアルゴリズムのステップは表4.2-1に示す。

表4.2-1 NSAカルマンフィルタのアルゴリズム

入力	
観測値	z_k
観測信頼値	c_k
予測状態推定値	$\hat{x}_{k k-1}$
観測モデル(観測係数ベクトル)	H_k
測定値のノイズの共分散	R_k
出力	
更新状態推定値	$\hat{x}_{k k}$
事後誤差共分散行列	$P_{k k}$
アルゴリズムの流れ	
1: 事前状態誤差の導出	$\hat{y}_k = z_k - H_k \hat{x}_{k k-1}$
2: NSA 共分散の導出	$\hat{R}_k = (1 - c_k) R_k$
3: 事前誤差共分散の導出	$S_k = H_k P_{k k-1} H_k^T + \hat{R}_k$
4: 最適カルマンゲインの使用	$K_k = P_{k k-1} H_k^T S_k^{-1} +$
5: 状態推定値の更新	$\hat{x}_{k k} = \hat{x}_{k k-1} + K_k \hat{y}_k$
6: 事後誤差共分散行列の更新	$P_{k k} = (I - K_k H_k) P_{k k-1}$

(3) 車両軌跡データに基づく交通挙動データ生成手法の提案

1) 射影変換による座標変換

物体を検出して追跡することで、特定の物体の移動軌跡が描画可能となったことから、画像内の距離を推定することによって移動速度を算出できるという考えに至る。しかし、画像内の距離は、カメラから遠ざかるにつれて1ピクセルあたりの距離が大きくなるという特性がある。1ピクセルあたりの距離を合わせるために、画像の画角を真上から見た状態に変換することが可能になれば、画像内の距離の比率は一定になる。

このような変換は、射影変換(ホモグラフィ変換)を行うことで可能になり、変換前の座標を (x, y) 、変換後の座標を (x', y') とすると、ホモグラフィ行列は以下のように表される。

$$s \begin{bmatrix} x' \\ y' \\ 1 \end{bmatrix} = \begin{bmatrix} a & b & c \\ d & e & f \\ e & h & 1 \end{bmatrix} \begin{bmatrix} x \\ y \\ 1 \end{bmatrix}$$

上記を展開することで、以下のように変換後の座標を求めることができる。

$$\begin{cases} x' = \frac{ax + by + c}{gx + hy + 1} \\ y' = \frac{dx + ey + f}{gx + hy + 1} \end{cases}$$

ここでは、8個の未知のパラメータを求めることになるため、変換前の座標4点、変換後の座標4点を定める必要がある。図4.2-1に射影変換による可視化結果の例を示す。ここでは、カメラ画像から得られた移動軌跡を図面(実空間)における直上から見た座標に変換している。

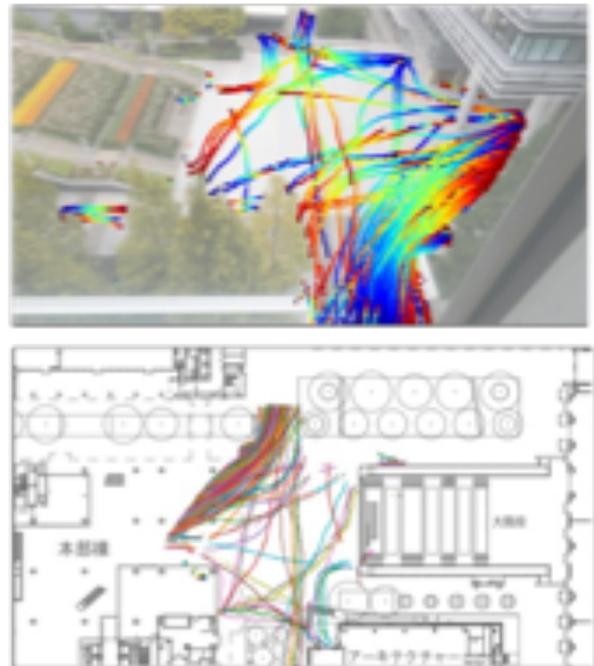


図4.2-1 射影変換の実行結果

2) 速度推定の手順

物体検出モデルのYOLOv5と物体追跡モデルのStrong-SORTを組み合わせて使用し、画像内の物体の座標情報と時間情報を取得する。加えて、取得した情報のホモグラフィ変換を行い、地図上に描画することで距離の推定を可能にした上で、移動速度を算出することが本研究の提案手法である。撮影に用いた画像とGoogle Mapから得られる航空写真の位置情報を合わせて、ホモグラフィ行列を取得した。

速度推定手法の手順について解説する。まず、YOLOv5とStrong-SORTを組み合わせることで物体の検出と追跡を行い、座標を取得する。そして、取得した座標を算出したホモグラフィ行列を用いて変換する。また、各IDごとに追跡開始時と終了時のフレーム差分を取得して、追跡フレーム数を算出する。移動距離は各IDに前後フレームのユークリッド距離を計算し、足し合わせることで総移動ピクセル距離が算出できる。最後に、移動ピクセル距離を地図の縮尺情報などから実距離に変換し、動画のフレームレート情報を取得した上で、総移動距離をフレーム数で割ることで移動速度の算出が可能になる。

3) 速度推定の結果

提案手法を用いて歩行者、自転車の平均速度を導出した結果のヒストグラムが図4.2-2と図4.2-3であり、平均速度は歩行者が7.7km/h、自転車が12.3km/hと算出された。

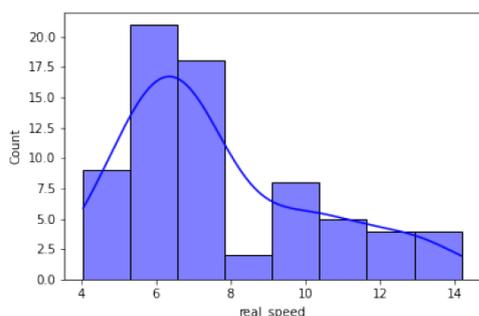


図4.2-2 歩行者の移動速度分布

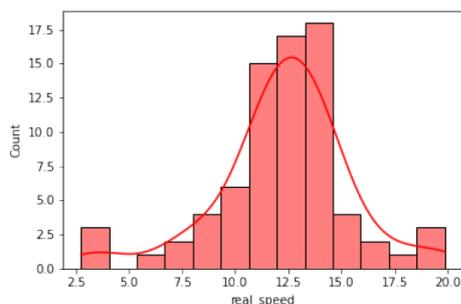


図4.2-3 自転車の移動速度分布

歩行者の平均速度に注目すると、Waterらの調査によれば、通常時における平均歩行速度は4.8km/h、速い時では歩行速度は6.3km/hであると示されており、今回導出された移動速度は少々早い結果となった。考えられる原因は、物体検出時において歩行者と自転車の誤判定が発生している点と、今回用いたGoogle MAPの地図の縮尺の精度が正確でないことが考えられる。一方で、歩行者と自転車の速度差が確認できていることから、今回の手法は時間帯別やモード別の速度差の導出といった分析には有用であると考えられる。

(4) ケーススタディによる検証

1) 時空間上における挙動の可視化

ここでは京都府京都市下京区唐津屋における交差点部での観測家結果を対象にケーススタディ分析を実施した。

分析方法は、8:00-8:30の30分間において歩行者用の信号が青になり横断が発生した13回について、歩行者および自転車の平均速度と移動軌跡を算出した。全13回の平均移動速度を表4.2-2に示す。13回目の座標情報について射影変換を行い地図上に描画したものを図4.2-4に示す。また、Strong-SORTを使用して取得した移動軌跡の出力結果の例を示す。取得した平面座標と時間情報を、時空間グラフとして可視化したものを図4.2-5に示す。また、時空間グラフのy軸と時間情報であるz軸に注目し、2次元座標に表したものを図4.2-6に示す。

表4.2-2 各回における移動速度分布

回数	歩行者 (km/h)	自転車 (km/h)
1	8.6	17.3
2	7.35	13.73
3	7.1	12.72
4	6.71	11.05
5	9.65	12.06
6	7.34	11.52
7	7.47	12.87
8	7.23	14.8
9	8.72	13.07
10	7.1	12.6
11	9.79	13.56
12	7.34	10.64
13	6.81	10.97

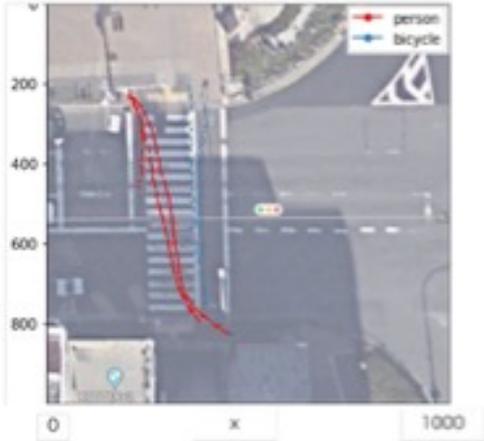


図4.3-4 カメラ画角に対する射影変換結果の可視化

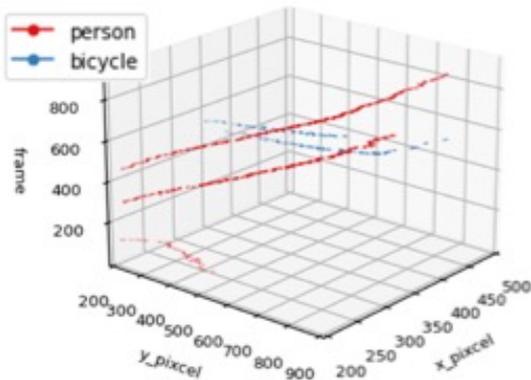


図4.2-5 時空間グラフによる移動軌跡の可視化

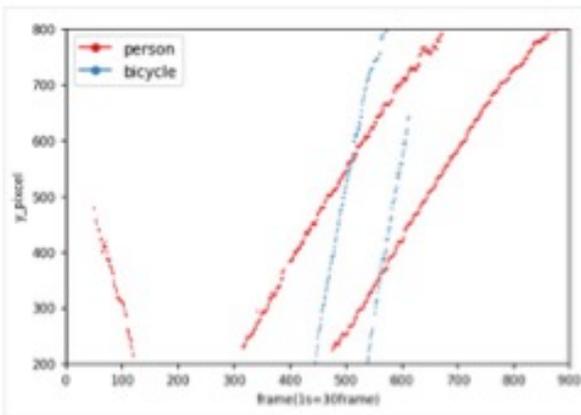


図4.2-6 時間-位置による移動軌跡の可視化

2) 移動軌跡および移動速度の検証

移動速度や移動軌跡に特徴が見られる場合や特異的な状況に着目し、提案手法の有効性を確認するケーススタディ分析を実施する。

低速時における自転車の移動速度

自転車の平均速度が一番遅い12回目の横断について分析を行う。12回目の平均速度は、自転車が10.64km/h、歩行者が7.34km/hであり、時間と位置関係について表したグラフを図4.2-7、地図上へ描画したものが図4.2-8である。自転車の軌跡が歩行者の軌跡を挟む形になっている。よって、自転車は歩行者を避けながら進む必要が生じるため、自転車の速度が遅くなったと考えられる。また、移動軌跡同士が交差している点が多いことに加えて、自転車が歩行者を追い抜いたと確認できる線も存在することから衝突の危険性が高い状況であるといえる。

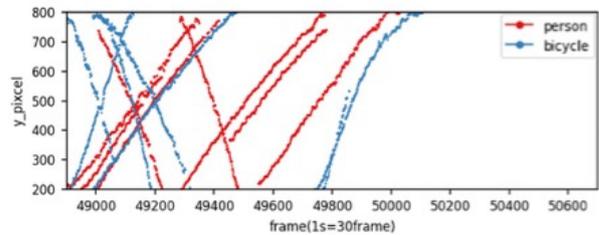


図4.2-7 時間-位置グラフ (12回目)

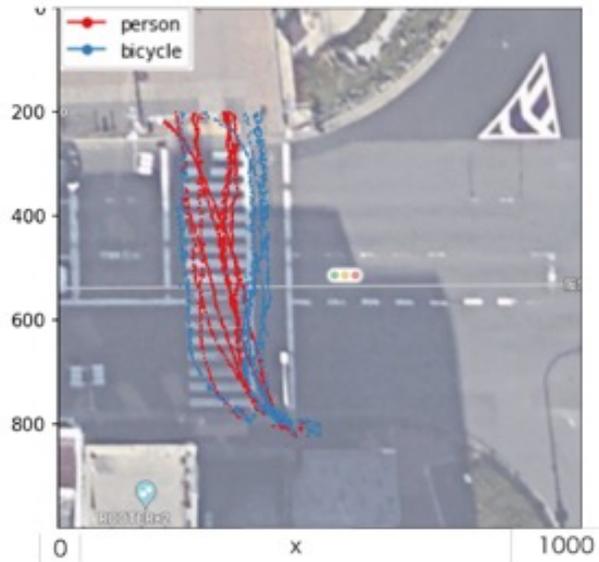


図4.2-8 直上からの移動軌跡 (12回目)

高速時における自転車の移動速度

自転車の平均速度が一番速い8回目に関しても同様に出力結果を図4.2-9に表示する。自転車と歩行者の軌跡がはっきりと分離され、自転車の軌跡が自転車横断帯上に描画されている。また、自転車と歩行者の描画開始位置は同地点だが、開始からしばらくすると綺麗に自転車と

歩行者が分離しているということだ。これは、横断歩道の開始地点にて自転車が歩行者を歩行開始時に既に追い抜いていることを表しているため、横断歩道上での衝突の危険性は少ないと考えられる。

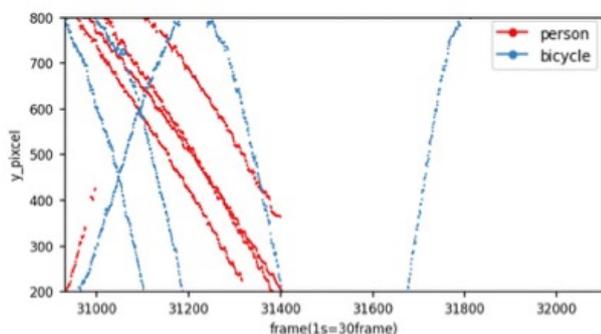


図4.2-9 時間-位置グラフ (8回目)

横断歩道上に車両が停車した場合

今回の分析の中で特殊な状況が5回目の横断時であり、横断歩道上で自動車は停止して歩行者の妨げになっていた。今回の出力結果を、図4.2-10に示す。自転車横断帯上に自動車は停車しているため、自転車は横断帯から離れた地点を通過している。また、歩行者が車の近くを歩行していることが確認できるため横断歩道上は通常と比較し、自転車と歩行者の衝突の可能性が高いと言える。

3) ケーススタディ分析の結果考察

自転車の速度と自転車横断帯に注目して3つの場合の分析を行った。分析結果より、自転車と歩行者の衝突の可能性が低いと考えられる場合は、自転車の横断帯利用率が高く、自転車と歩行者の分離がなされている場合である。

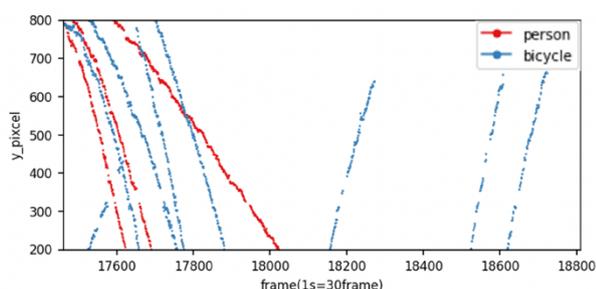


図 4.2-10 時間-位置グラフ (5回目)

また、時間位置グラフに注目した場合、描画の開始地点が自転車と歩行者が同様で、横断歩道中盤において描画線が分離している時に歩行者と自転車が分離できている。加えて、地図上への描画図を確認した場合、横断前においては広がって待機し、横断終了時は歩道の最短距離を取るように狭い範囲を通過していること

も確認できる。

このような面を考慮すると、横断歩道上において自転車と歩行者を分離するための効果的な施策としては、横断歩道の手前に自転車と歩行者の待機場所をペイントすることだと考える。待機場所を指定することで、自転車横断帯の利用率を上昇させ、自転車と歩行者の速度差が自然と生じることより、衝突の可能性が低くなるといえる。本研究の速度推定手法と追跡手法を用いることで各クラスに注目した考察を行うことが可能になった。

(5) 本検討の成果と課題

本研究では、深層学習ベースの物体検出モデルと物体追跡モデルを用いた新たな速度推定手法の提案し、ケーススタディ分析と本手法の適用可能性を検証した。速度推定手法に関しては、YOLOv5とStrong-SORTを組み合わせることで、位置情報と時間情報の取得が可能になり、射影変換によって距離情報を取得することで実現可能となった。また、取得した移動速度と移動軌跡の可視化を行うことで、多様な情報を組み合わせた交通モード別分析と考察も実施できた。

課題として、射影変換の自動化が必須である。画像の特徴量を用いて自動でマッチングを行う手法を開発し、衛生画像とカメラ画像を組み合わせることで全国の観測地点で速度の推定が可能になるだろう。本研究では、カメラ映像を入力情報として処理を行い、地図情報や空間情報に出力することに取り組んだ。今後はより得られる情報も増えることが予想されるため、多様なデータを効果的に活用し、社会に貢献できる次世代交通システムの実現を目指したい。

参考文献

- [1] 足立修一: 線形カルマンフィルタの基礎, 計測と制御, Vol. 56, No. 9, pp. 632-637, 2017.
- [2] Yunhao Du, Yang Song, Bo Yang, and Yanyun Zhao: Strong-SORT Make deep-sort great again, arXiv:2202.13514, 2022.

4.3 衛星および航空写真を活用した実空間距離推定手法の開発と検証

(1) はじめに

交通計測においてカメラ画角内の距離情報は、カウンタライン自動生成や速度計測などの用途で必須であり、画像内の物体やその範囲に関する実空間上での距離情報の取得は重要である。このような実空間距離はカメラ画像のみから測定することができず、現地測量などの他のデータを参考に推定するのが一般的である。これはカメラ画像内の位置座標は画像としてのピクセル座標値であって、実空間上での位置座標（緯度経度）ではないことに起因する。

距離計測を考える上では、様々な対象に適用可能である汎用性が一つのポイントとなる。実際に例えば、令和3年度の研究でも距離に基づいた速度計測を行ったが、その際は道路上の白線を基準に速度を計測したため、白線が表示されたカメラ画像でないと解析できないという課題があった。本研究では、実際のカメラ画像内の2点間線分に対して妥当に距離を計測できることを目指し、距離計測用データの選定と汎用的な距離計測技術の基礎的検討を行った上で、実際の画像を用いた距離計測を試行した。

(2) 衛星・航空写真データの概要

1) Google Map 衛星データ

Google地図で閲覧可能な航空写真とは、Google地図サービス上で航空写真モードに切り替えて表示される地図である。拡大率を自由に變更でき、後述のように距離測定ツールがあるため、任意の解像度の航空写真を容易に取得可能である。Google地図を利用する際の注意点は、形状のゆがみや撮影時の境界線で写真のズレが生じることがある点である。

2) 高解像度航空写真データ

国際航業社の提供する高解像度航空写真は、オルソ画像処理により、高層の建物があつた場合でも倒れこみによる遮蔽が少ないとされている。本研究では、解像度の違いによる精度の違いを検討するため、5cm解像度（1pxあたり5cm）と25cm解像度（1pxあたり25cm）の写真を用いることとした。航空写真の整備状況は図4.3-1に示すように、5cm解像度（橙）は大都市圏のみ整備されている。25cm解像度（緑）は大半の地域で利用可能であるが、山間部等では一部整備されていない地域がある。適用時にはこの点に注意が必要となるが、将来的には当該問題は解消されると考えられる。

(3) 衛星・航空写真データによる射影変換

距離計測の実施に向けて、カメラ画像と航空写真とを組み合わせ、カメラ画像中の距離を実距離に変換する具体的な手法が必要になる。ここでは手法を提示した上で、その手法によって妥当に距離計測を実施できることを目標に進める。

1) 射影変換による距離計測

実務では、汎用性と簡便性を担保するために任意地点に適用可能であること、距離計測の準備作業が容易であること、距離計測処理自体の計算負荷が軽いことが望ましい。この要件を満たす手法として、射影変換による座標変換を検討した。射影変換とは、遠近感のあるカメラ画像を、ある縮尺の平面図に変換する処理である。イメージを以下に示す。青い点線で結ばれている「特徴点」を、遠近感のあるカメラ画像と平面図に対応付けることによって、カメラ画像内の任意の地点を平面図上に写すことが射影変換の要旨である（図4.3-2）。

本研究では、射影変換後の平面図は航空写真とする。すると、カメラ画像内の距離（px単位）が、実距離（m単位）に航空写真上の縮尺を乗じたものに変換される。これによって、カメラ画像から実距離を求めることができる。技術的には、座標値に射影行列を乗じることで射影変換ができるため、計算コストが小さい特徴が利点として挙げられる。

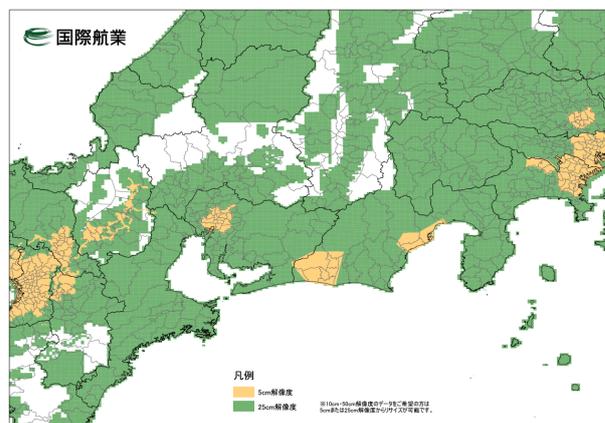


図 4.3-1 高解像度航空写真の整備状況

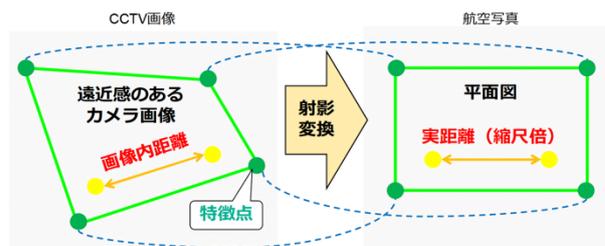


図 4.3-2 射影変換のイメージ

射影変換を行うためには、事前にカメラ画像と平面図で同一地点を示す特徴点の組を4組以上必要定めておく必要がある。この部分は手動で座標値を調べる作業が発生する。特徴点の選び方に自由度を持たせることで汎用性を担保させる点がポイントである。特徴点として選ぶべき点については、以下で検討する。

3) 射影変換の有効性検証

前述の射影変換による距離計測のコンセプトが有効であることを確認するため、実際のデータに対して距離計測を行った。距離が妥当に計測できたならば、この距離計測手法を以降で利用できると判断できる。ここでは、精度の定量化と課題点の洗い出しを目標に検証した。

この検証では具体的に、航空写真から求まる実距離と、射影変換によって求まる推定距離とを比較した。特に、射影変換の特徴点による影響を明らかにするため、特徴点間の距離と、特徴点を介さない地点間の距離について比較検討した。航空写真としては、データ入手の容易さから Google 地図を試験的に用いた。Google 地図では、距離測定ツールが提供されているため、Google 地図で求めた距離をそのまま距離の正解値として用いた。

対象地点の選定に関しては、道路形状によって課題点が異なると考えられるため、ここでは直線に近い上江橋と神宮橋、そして曲線部である箱根新道を対象地点とした。以下、各地点における特徴点の選定結果を図 4.3-3 に示す。

図中の緑の丸が特徴点であり、特徴点によって囲まれる図形を緑色の四角形で示す。また、

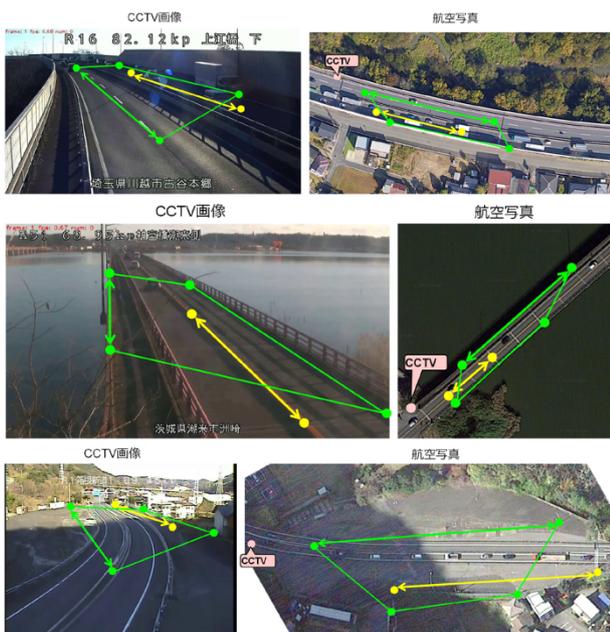


図 4.3-3 対象エリアの画角対応関係 (上段：上江橋，中段：神宮橋，下段：箱根新道)

距離を測定した区間は緑色矢印（特徴点間）と黄色矢印（特徴点を介さない地点間）の区間である。

各地点における距離計測結果を図 4.3-4 に示す。なお、ここでの誤差とは、Google 地図上の距離とカメラ画像の推定距離の差の絶対値を表し、括弧内の値は誤差率を表す。くわえて、誤差率とは、誤差[m]を航空写真距離[m]で除したものである。

上江橋では、特徴点によって囲まれる四角形の範囲内では、特徴点以外同士の距離でも縦断方向では5%誤差で推定できた。また、特徴点によって囲まれる四角形の外側では、距離の誤差が大きくなることが示唆された。神宮橋では、カーブや勾配がなく、広い範囲で特徴点を取れたため、精度よく（誤差2%未満）推定できた。箱根新道では、特徴点以外同士の距離に10%の誤差が生じている。この原因として、カメラ画像上では手前側で特徴点を取れないこと、カメラ・航空画像の解像度が低いこと、建物の特徴点（カメラ画像内の右下の特徴点）の高さが路面より低いことが原因として考えられる。また、建物の特徴点の座標を3px 変えると、黄色の推定距離が3m 変化するといった、位置の感度の鋭敏性が確認された。

これらの知見を踏まえて、特徴点の候補選択基準を図 4.3-5 のように整理した。

□ 上江橋

	Google地図上の距離[m]	CCTV画像の推定距離[m]	誤差
特徴点同士(緑)	81.0	81.1	0.1 m (0.12%)
特徴点以外(黄色)	51.0	53.5	2.5 m (4.9%)

□ 神宮橋

	Google地図上の距離[m]	CCTV画像の推定距離[m]	誤差
特徴点同士(緑)	62.5	62.7	0.2 m (0.32%)
特徴点以外(黄色)	25.1	25.4	0.3 m (1.2%)

□ 箱根新道

	Google地図上の距離[m]	CCTV画像の推定距離[m]	誤差
特徴点同士(緑)	118.5	116.0	2.5 m (2.1%)
特徴点以外(黄色)	95.3	85.1	10.2 m (10.7%)

図 4.3-4 射影変換による距離計測結果



図 4.3-5 特徴点の候補選択基準

(4) 衛星・航空写真データを活用した距離計測の精度検証

1) 検証地点の整理

実務的観点では、対象とするカメラによって、様々な道路形状、様々な画角のものが想定される。こうした条件の多様性に対応するため、検討対象動画としては複数の道路条件のものを選択することとした。ここでは、箱根新道で問題になった勾配に関する影響のほか、道路がカメラの前を横切るような条件下でのレンズによる影響（球面収差）、また曲線部や対向車線の状況について確認した。また、航空写真データとして適切なものを比較するため、5cm 解像度・25cm 解像度の航空写真と、Google 写真を用いて比較検討した。

検証対象地点は、基本的に令和4年度までの研究における対象地点を踏襲した。以下、対象地点とその特徴を表4.3-1に示す。このうち、上江橋、神宮橋、箱根新道については前述で検討済である。

表 4.3-1 検証地点の概要

地点	特徴	航空写真ソース	検討意図
上江橋	緩やかな勾配とカーブ	Google	直線部での試行
神宮橋	勾配なし直線部	Google	直線部での試行
箱根新道	カーブ、山の影 特徴点少ない	Google	特徴点の選定検討
小野幌	交差点 車線が不鮮明	航空写真5cm、25cm、 Google	特徴点の選定検討
姥ヶ山IC	斜め画角	航空写真5cm	球面収差の確認
とやの橋	勾配あり(ランプ)	航空写真5cm	勾配の影響確認 曲線部での試行
千住大橋	勾配あり(陸橋)	航空写真5cm、 Google	勾配の影響確認 対向車線確認

特徴点には先に示した図4.3-5に基づいて選定した。各対象動画について、特徴点の組み合わせを以下に示す。なお、以下に示す航空写真はいずれも解像度5cmのものである。姥ヶ山IC、とやの橋、千住大橋についてはカメラ画像内での遠近や勾配の違いによる距離計測への影響を確認するため、それぞれ計測線を2本引き、各計測線において距離を計測・推定した。

なお、姥ヶ山ICについては、工事中の異なる時期に撮影されたため、カメラ画像と航空写真の間で道路形状が異なる。そこで、工事前後で形状が変化していない部分から特徴点を選んだ。以降では、代表的な結果について、検証結果を整理した。

2) 検証結果の整理

【小野幌】

小野幌の検証結果を表4.3-2に示す。航空写真5cmを用いた場合と比べて、Google 写真を

用いた場合も、航空写真自体の距離のずれは実用上許容できる程度と考えられる。また、推定距離がGoogle 写真を用いることで改善したが、有意な差ではなかったと考えられる。

航空写真25cmを用いた場合も推定距離自体は誤差が増えたものの、実務上は利用に耐えるものと認識している。一方で、航空写真自体において、5cm 解像度と比べて細かな物体が見えないという欠点がある。これに関しては1ピクセルのスケールにおける違いであるため、明瞭な特徴点（センターラインの切れ目、道路のカドなど）を用いることで、この問題は回避できる。

表 4.3-2 解像度別距離計測結果（小野幌）

航空写真ソース	航空写真距離[m]	推定距離[m]	誤差[m] (誤差率)
航空写真5cm	103.3	99.8	3.5 (3.4%)
" 25cm	103.3	98.9	4.4 (4.3%)
Google写真	104.7	102.7	2.0 (1.9%)

【千住大橋】

千住大橋の検証結果を表4.3-3に示す。ここでは航空写真5cmとGoogle 写真で比較した。このケースは特徴点と計測線で縦断勾配が揃ったケースである。この場合も小野幌と同様に、航空写真5cmとGoogle 写真との間に大きな違いは見られなかった。

特徴点の設定パターン別での距離計測結果を図4.3-6に示す。図中において、セルがピンクで塗りつぶされている行は誤差率が10%以上だったものである。縦断勾配の違いで誤差が生じることがわかった（特徴点1・2で手前の計測線を用いた場合、特徴点3で奥の計測線を用いた場合）。また、特徴点1・2のように縦断勾配を揃えても、奥側車線の計測誤差はやや大きい結果となった。

表 4.3-3 解像度別距離計測結果（千住大橋）

航空写真ソース	航空写真距離[m]	推定距離[m]	誤差[m] (誤差率)
航空写真5cm	96.0	96.1	0.1 (0.1%)
Google写真	96.6	96.2	0.4 (0.4%)

		特徴点パターン1	特徴点パターン2	特徴点パターン3			
航空写真ソース	特徴点	計測線	航空写真距離 [m]	推定距離[m]	誤差[m]	(誤差率)	
航空写真5cm	1	手前	96.0	162.8	66.8	(70 %)	
"	2	手前	96.0	193.8	97.8	(101 %)	
"	3	手前	96.0	96.1	0.1	(0.1%)	
"	1	奥	15.0	17.1	2.1	(14%)	
"	2	奥	15.0	16.8	1.8	(12%)	
"	3	奥	15.0	11.8	3.2	(21%)	

図 4.3-6 特徴点パターン別距離計測結果

【姥ヶ山 IC】

姥ヶ山 IC の検証結果を図 4.3-7 に示す。小野幌と同様に、計測手前では、手前側の特徴点を広げると精度が向上した。また、特徴点1では計測手前より計測奥の精度が良かったが、これは特徴点に球面収差の影響があったためと推測される。



図 4.3-7 特徴点パターン別距離計測結果

【とやの橋】

とやの橋の検証結果を図 4.3-8 に示す。特徴点1・2で奥の計測線を用いたときのように、特徴点と計測線の縦断勾配が異なると、非実用的なほど誤差が大きくなることがわかった。



図 4.3-8 特徴点パターン別距離計測結果

3) 検証結果の考察と整理

道路の縦断勾配に関しては、道路形状によってはカメラ画像の範囲内で場所によって変化するものが存在する。上記の検証結果から、そのような場合の対処方針として、勾配部と平面部で領域を区分し、それぞれに対して射影変換行列を求めて射影変換を行うことで誤差を小さくできると推測される(図 4.3-9)。

ここまでの検証結果から、Google 写真を利用した場合でも距離を妥当に求めることができることを確認した。最終的な航空写真の利用方針を図 4.3-10 に示す。撮影時期に関する補足として、実務上はカメラ画像が(準)リアルタイムで取得できる一方、航空写真は撮影時期に限られ、数年前の可能性のある点に留意する必要がある。本研究で取り扱った姥ヶ山 IC のよ

うに、道路工事中などで道路構造が変化している途中の時期においては、Google 写真においても道路構造の変化が反映されていないことがあり、特徴点の選定には注意を要する。また、航空写真の利用方針の根拠として、図のように各航空写真を用いた作業においても、Google 写真を用いた際のメリットがあることが挙げられる。なお、ファイルサイズの違いが作業量に影響するため留意が必要である(図 4.3-11)。

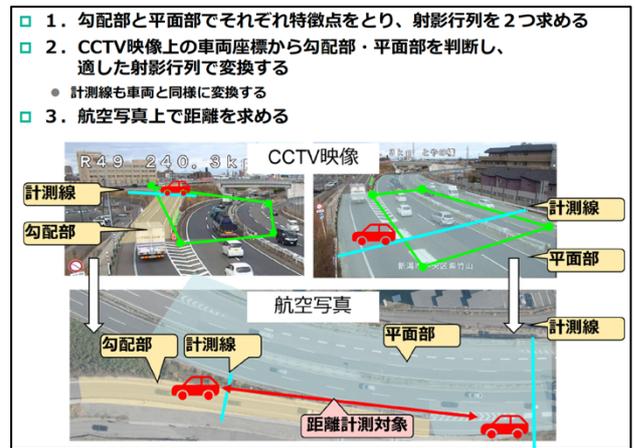


図 4.3-9 勾配変化地点における距離計測方法

- 基本案: Google写真
 - 解像度は25cm相当のため細かい物体(柱等)の特定は難しい
 - 歪みやズレ等が生じうる(右図)
 - 撮影時期による品質のばらつきあり(積雪等)
- 代案: 25cm解像度航空写真
 - Google写真に不具合がある場合
 - 山間部は整備率が低いため注意
 - 都心部で精緻さを求める場合、5cm解像度航空写真の利用も一案
- 今後: 勾配部の計測精度を高めるためには3Dデータではなく道路勾配を入力する設計がよい
 - 道路勾配は図面等から入手でき、扱いやすいと考えられるため

特徴	Google写真	25cm, 5cm解像度航空写真
必要な写真エリアの指定方法	・Googleマップで場所を特定する ○航空写真そのもので場所を特定できる	・業者提示のメニューから場所を探す ×場所を誤るリスクあり
キャプチャ・前処理	・必要な範囲を任意のズーム率でキャプチャする ・広い範囲を高解像度で取り込む場合、複数のキャプチャを結合する	・受領ファイルから、必要な範囲を切り出す ・対象範囲が複数画像にまたがる場合、結合する
ファイルサイズ	○軽く、編集操作が容易	×重く、編集操作がやや手間
編集時の拡大	・写真の解像度が低い場合は、同一箇所をブラウザで閲覧して拡大する	・写真自体の解像度が高いため、編集ソフト内で拡大する

図 4.3-10 衛星・航空写真の選定方針と整理

	Google写真	25cm解像度航空写真	5cm解像度航空写真
ピクセル数(デフォルト)	—	8000x6000	8000x6000
ファイルサイズ(デフォルト)	—	約140MB (TIFF)	約140MB (TIFF)
ピクセル数(トリミング後)	一辺900~1000 ※ズーム率依存	一辺400~600 ※5cm解像度の1/5	2000~3000
ファイルサイズ(トリミング後)	5~10MB (PNG)	1~2MB (PNG)	10~15MB (PNG)
備考	ブラウザ上でズームすると10cm相当の解像度が得られる認識	—	—

図 4.3-11 衛星・航空写真のファイルサイズの違い

(5) 本研究の成果と課題

本項では、距離計測を行うために必要なデータを選定した上で、距離計測方法を提案し、その有効性を検討した。上記検討で得られた知見を表 4.3-4 に示す。

図 4.3-8 衛星・航空写真の選定方針と作業の違い

地点	特徴	検討意図	主な結果
 上江橋	緩やかな勾配とカーブ	直線部での試行	・勾配緩い地点でGoogle写真適用可
 神宮橋	勾配なし直線部	直線部での試行	同上
 箱根新道	カーブ、山の影、特徴点少ない	特徴点の選定検討	・特徴点高さが路面と異なると誤差大
 小野橋	交差点、車線が不鮮明	特徴点の選定検討	・手前側の特徴点が高いと誤差減 ・Googleと5cm写真で誤差有意差なし
 鏡ヶ山IC	斜め画角	球面収差の確認	・手前側の特徴点が高いと誤差減 ・遠方の特徴点に球面収差の影響示唆
 とやの橋	勾配あり(ランプ)	勾配の影響確認 曲線部での試行	・車線と特徴点の勾配が揃うと誤差減
 千住大橋	勾配あり(陸橋)	勾配の影響確認 対向車線確認	・カメラから遠い車線の誤差大 ・勾配あり地点でもGoogle写真適用可

主要な結果としては、特徴点を選ぶ際にカメラ画像の手前側で横方向に広げると誤差が小さくなること、Google 写真と航空写真 5cm で誤差の有意差がないこと、車線と特徴点の個賠が揃うと誤差が小さくなること、勾配がある地点でも Google 写真を適用できることがわかった。このほか、運用面においても、Google 写真を用いることで距離計測の下準備の煩雑さを軽減できることが分かった。以上の結果から、航空写真として Google 写真を用いた距離計測が、実務的にも有効に実施できることを確認した。

今後の課題を以下に列挙する：

- 航空写真画像の解像度は地域によってバラツキがあり、常に高解像度データが手に入る保証がない。そのため、衛星画像などの他のデータを活用すること検討したい。
- 射影変換による距離変換は、二次元座標を対象としており、高さ情報が加味されないため、山間部などの道路傾斜が存在する画角では誤差が増大する傾向にある。そのため、三次元座標での変換方法を検討する必要がある。また、デジタルツインを活用した距離同定の可能性も検証すべきである。

参考文献

- [1] 国際航業（株）超高解像度航空写真提供サービス、高解像度オルソ画像
<https://www.kkc.co.jp/service/lp/11770/>

4.4 交通計測におけるカウントライン最適化モデルの構築と検証

(1) はじめに

交通量計測アルゴリズムは、検知および追跡を担うAIモデルにくわえて、追跡した物体をカウントする仕組みが必要となる。このカウントアルゴリズムは、CCTVカメラ画角内の道路上に仮想的な線分を設定し、この線を車両が通過した場合にカウントすることで車両台数を計測する方式が一般的である。以下では、車両カウントに用いる仮想的な線分をカウントラインと呼称する。

このカウントラインの設定に際して、実務面でさまざまな課題が存在している。運用者による手動設定が一般的であり、経験に基づく試行錯誤が求められる。複数のカメラを運用する現場では、この調整作業には多くの工数を要している状況にある。

- CCTVカメラの実運用上、カメラの画角変更により、計測性能が著しく低下する。
- 日照変化などで影が生じる時間帯では、計測性能が著しく低下する。
- カウントラインは、道路断面に対して一本の直線で設定されるケースが多く、車線別交通量の計測には至っていない。

以上から、自動かつ動的にカウントラインを最適化することが実務上で求められる。

本論では、これまでに十分に考慮されてこなかった交通量計測アルゴリズムのカウントライン最適化を検討する。具体的には、機械学習を活用してカウントラインを自動的に最適な設定を計算し、交通量計測の精度向上を目指す。さらにCCTVカメラの実運用下での適用を主眼に置き、画角変化や環境条件変化に対応可能なカウント最適化モデルと計算アルゴリズムを構築する。

(2) 既往研究の整理

1) 交通計測における計測ライン

Lin^ら¹⁾は、YOLOv4-tinyモデルを改良し、カルマンフィルタを改良し車両IDを付与する方法を提案した。カウントラインによるカウントは適用されず、車両追跡IDのみによって台数を計測している。

Bouaich^ら²⁾は、車両IDの代わりにカウントラインで測定することを試みた。物体検知アルゴリズム部分はk-NNクラスタリングを使用した背景差分法である。検出された車両のバウンディングボックスがカウントラインを通過し

た場合に計数される。カウントライン自体は画面を横切って描かれ、設置基準については言及されていない。このように、ほとんどの場合カウントラインは車線数に関係なく道路を横切るように画面の下部に描かれる。

これらの通り、物体検知・追跡モデルに関して統一した手法が存在するものの、各々独自のアルゴリズムを用いて計数を行っている現状がある。また、カウントラインの設定方法について言及されている研究は極めて少なく、議論がなされていないことがわかる。したがって、計数部分に関する一定の仕組みを作ることが必要であり、最適化を元にした設定方法を構築することが目的となる。以下の既往研究は車線推定や軌跡予測に関する手法であり、カウントライン最適化アルゴリズムの構築に資するものである。

Uduwaragoda^ら³⁾は、カーネル密度推定を使用し、鳥瞰図像から車両軌道の断面が推定した。4~5車線の道路で150の軌道を計算することで、一定の精度で車線が推定できることが示された。Zheng^ら⁴⁾は、道路データベースとプローブデータ軌跡から道路中心線のカーネル密度を推定することにより、低コストで車線を推定する。車線中心線は、最小距離での分割と軌跡の類似性に基づくフィルタリングを使用して計算される。

Fu^ら⁵⁾は、スペクトルクラスタリングによる運動軌道の分類を提案した。軌道の類似性を比較することで、軌道のグループが重なっていても分類できる2層のクラスタリング戦略が可能となった。

Rodriguez-Rangel^ら⁶⁾は、カルマンフィルタとその他の統計的手法を使用して、YOLOv3によって検出された次のバウンディングボックスの位置を予測することにより、速度が推定される。課題は、計算に多量のサンプリングデータが必要となる点である。

以上より、MOT分野では、得られた軌跡をグループ化して分類するという研究はいくつかある。ただし、これらに対して車線別交通量計測へ活用する取り組みはなく、自動設定への拡張が期待される。したがって、本研究の位置付けは、取得した軌跡群から車線推定を実施し、カウントラインが最適となる位置を取得するアルゴリズムを新たに構築することである。

(3) 計測ライン最適化モデルの構築

カウントライン最適化までのシステムフロ

一を図4. 4-1に示す.

はじめに, AIモデル部分で画像中のバウンディングボックス情報が蓄積され, 軌跡情報へとデータの事前処理が行われる. これらの軌跡情報は, フレーム内のx-y座標が含まれている. 次に, ある程度蓄積された軌跡情報より, 車線推定が行われる. また, 射影変化も行われる. これは, 後述するカーネル密度推定を実施するための前処理として行われる. 最終的に, 軌跡群をカーネル密度推定により, 軌跡の密度が最大となる点が返される. これにより, 軌跡が最も集約されている場所, すなわちカウンタラインによって精度が最大化される点を示すこととなる.

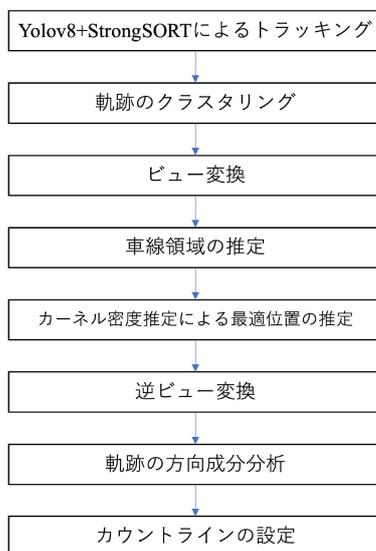


図 4. 4-1 提案モデルのフロー図

1) 物体追跡モデル

移動物体追跡モデルは, ByteTrack⁷⁾やStrongSORT⁸⁾に代表されるような, 検出した物体にIDを割り振り, 追跡するアルゴリズムである. 通常, 物体検知モデルと併せて使用される. カルマンフィルタをベースに, 検出した物体の類似性を比較して追跡する仕組みとなっている. しかし, オクルージョンにより物体検出が途切れ, 追跡していた物体のID が切り替わるIDスイッチングと呼ばれる現象が課題となっている. そのため, IDスイッチングに対してロバストなカウンタライン設定を行う必要がある. 本研究では, Strong-SORTの事前学習済みモデルを使用する.

物体追跡モデルによる出力結果は, フレーム番号, 車両ID, バウンディングボックスの中心座標 $\{(x, y)\}$, 幅 $\{w\}$ と高さ $\{h\}$ である. 軌跡情報は一般的にバウンディングボックスの中心座標から抽出されるが, 車両の大きさによって

中心座標の位置にばらつきが生じる. 車両底面と路面との距離が最も小さいバウンディングボックス下部を採用する. そのため, 図4. 4-2のようにバウンディングボックスの左下, 中央下, 右下の3点が候補となり, これらはカメラ画角によって最も誤差が小さくなるものを採用する必要がある. 本研究中では基本的に中央下部設定を採用し, 画角が特筆して横になっているものに関してはそれ以外を採用する.

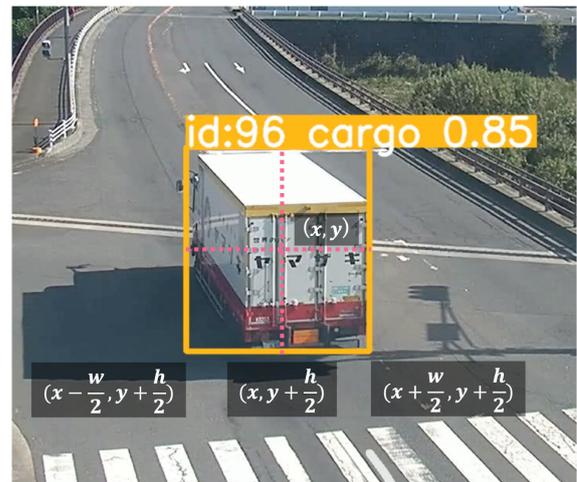


図 4. 4-2 バウンディングボックスの出力例

2) 時系列クラスタリングによる車線推定

本研究では, 車線別交通量の取得を目的としているため, 対象となる車線を推定する必要がある. したがって, 車線別交通量計測のためのカウンタラインの設定には, 蓄積された軌跡情報をもとにクラスターを行い, 車線の位置および幅員の2つを推定する.

車線を分類するために, 追跡した車両の軌跡をグループ化する必要がある. このような軌跡は, 画像中の2次元座標と時間情報を足し合わせた3次元の情報から, 各車両IDの軌跡同士をクラスター分類する. ここで, 動的時間伸縮法(DTW)を用いて, 時間長によらない軌跡のデータポイント間の距離を測定し, 軌跡形状の類似度を比較する. この類似度をもとにk-means法と組み合わせたクラスタリングにより車線分類を行う. 二次元座標と時間情報を持つ各軌跡をA, B とすると,

$$A = \{(x_1, y_1, t_1), (x_2, y_2, t_2), \dots, (x_m, y_m, t_m)\}$$

$$B = \{(x'_1, y'_1, t'_1), (x'_2, y'_2, t'_2), \dots, (x'_n, y'_n, t'_n)\}$$

と表され, ある時点*i*と*j*の間の3次元の距離をユークリッド距離は以下ようになる.

$$d((x_i, y_i, t_i), (x'_j, y'_j, t'_j)) = \sqrt{(x_i - x'_j)^2 + (y_i - y'_j)^2 + (t_i - t'_j)^2}$$

この距離を基に、DTW のコストマトリクス D の各要素 $D[i][j]$ は以下のように定義される。

$$d(a, b) = \sqrt{(x(a) - x(b))^2 + (y(a) - y(b))^2 + (t(a) - t(b))^2}$$

$$D[1][1] = d((x_1, y_1, t_1), (x'_1, y'_1, t'_1))$$

$$D[i][j] = d((x_i, y_i, t_i), (x'_j, y'_j, t'_j)) + \min\{D[i-1][j], D[i][j-1], D[i-1][j-1]\}$$

最終的な距離は $D[m][n]$ となる。DTW の利点は、時間的なスケージングの違いが存在する場合に、2つのシーケンス間の一致度を評価する。全体の類似度を計算するのに適しているが、計算量は $O(mn)$ であり、軌跡データ数に応じてコストの高い計算となっている。

3) 実空間座標への変換

射影変換は、異なる画像間において対応する4点を指定し、射影変換行列を作成する。このとき、射影変換は以下の式によって定義される。ターゲット座標である x, y に対して、射影変換行列を乗じることによって x', y' への座標変換が可能となる。

$$\begin{bmatrix} x' \\ y' \\ w' \end{bmatrix} = \begin{bmatrix} h_{11} & h_{12} & h_{13} \\ h_{21} & h_{22} & h_{23} \\ h_{31} & h_{32} & h_{33} \end{bmatrix} \begin{bmatrix} x \\ y \\ w \end{bmatrix}$$

$$x' = \frac{h_{11}x + h_{12}y + h_{13}}{h_{31}x + h_{32}y + h_{33}}$$

$$y' = \frac{h_{21}x + h_{22}y + h_{23}}{h_{31}x + h_{32}y + h_{33}}$$

上記の式により、画像中の任意の点に変換される。射影変換における対応する4点は、手動によってマッチングする。特徴点は、道路白線や、構造物、橋のジョイント部分など、俯瞰画像と CCTV画像内が明白に一致する地点に設定される。図4.4-3に特徴点の設定例を示す

4) カーネル密度推定による計測位置特定

カウンタラインの最適な位置の特定は、カーネル密度推定 (KDE) によって行われる。KDE は、ノンパラメトリックな確率密度関数を求める手法である。

$$\hat{f}(x) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{x - x_i}{h}\right)$$

ここで、 $\hat{f}(x)$ は点 x における推定される密度、 n はサンプルデータポイントの数、 x_i は個々のデータポイント、 h はバンド幅、 $K(\cdot)$ はカーネル関数で非負である。

本研究の例では、カーネル関数をガウシアンカーネル、バンド幅は $h=30$ とした。バンド幅に関して、カーネル密度の裾野の広さに影響する値であり、特に軌跡とカメラ間の距離によって、各地点で分析に変動が及ぶ可能性が考えられる。射影変換を実施する場合にこれらを決める必要がある。

カーネル密度の最も大きい座標は車両軌跡が最も集約されているところであるとし、計数漏れが最も少なくなると仮定した。KDEによって表現されたコンター図をもとに、最も密度の大きい座標をカウンタラインの中心座標とする。ただし、先述のようにCCTVカメラは透視投影によって表示されており、軌跡の座標は遠近で歪みが生じている。この歪みを解消するために、射影変換を施したのちにKDEの計算が実行される。射影変換は俯瞰からの視点への変換を仮定しているため、道路勾配が存在する場合は歪みが解消されないことが想定される。カーネ



図4.4-3 特徴点のマッチング例

ル密度が最も大きくなる座標をカウントラインの中心座標とする。

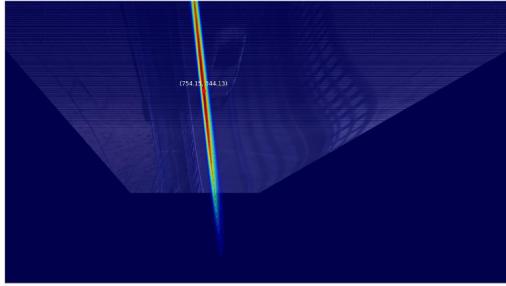


図4.4-4 カーネル密度推定結果例

5) カウントラインの最適化

KDEによって求められた密度最大となる点は、俯瞰画像から元画像へ逆射影変換される。逆射影変換によって元画像上に密度最大となる点が表示され、この点がカウントラインの中心座標として定義される。以上の計算によって得られたカウントラインの中心座標および、軌跡の方向分析によって得られたカウントラインの角度等の設定は、次のように決定される。図4.3-5に示す。カウントラインの角度は、それぞれの車線に含まれる軌跡の方向成分の回帰直線に対して直交する直線を使用する。カウントラインの幅は、各クラスターに属する軌跡座標から、外部パラメータによって調整されたバッファ内に含まれる方向成分の平均をとる。

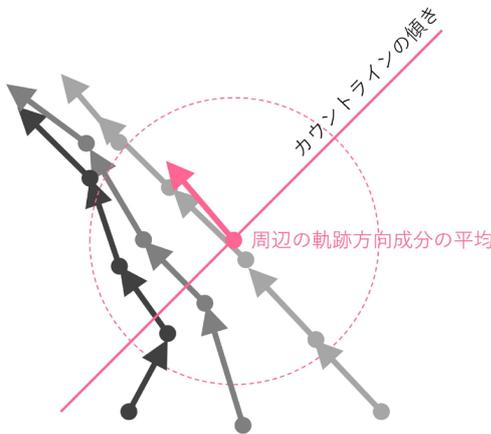


図4.3-5 カウントラインの傾き算出方法

(4) 提案モデルの適用結果と検証

転移学習モデルおよびカウントラインの最適化を施した場合における精度評価を記述する。なお、以下で呼称されるGoing方向は、画面手前側から奥へ向かう方向、Coming方向は画面奥側から手前側で向かう方向を指す。

1) 位置変化を考慮した検証

ここでは、道路上に設置されたカウントライ

ンの位置を変化させることによって得られた精度を比較する。図4.4-6および表4.4-1は神宮橋（潮来側）の単路部において、カウントラインの位置をy軸方向で変化させていったものである。その結果、ある程度の精度が得られているためか、カウントラインを変更した場合でも



図4.4-6 位置変化による計測数（神宮橋）

表4.4-1 カウント数と精度（神宮橋）

カウントライン名	カウントラインの端点	カウント数	真値（車両数）	精度（%）
1000going	(1000, 1000), (1500, 1000)	72	72	100
1000coming	(1500, 1000), (1920, 1000)	78	76	97.4
800going	(900, 800), (1250, 800)	71	72	101.4
800coming	(1300, 800), (1700, 800)	77	76	98.7
600going	(750, 600), (1100, 600)	72	72	100
600coming	(1100, 600), (1400, 600)	77	76	98.7
400going	(700, 400), (900, 400)	72	72	100
400coming	(900, 400), (1100, 400)	76	76	100
200going	(600, 200), (650, 200)	60	72	83.3
200coming	(650, 200), (750, 200)	1	76	1.3



図4.4-7 位置変化による計測数（田野倉）

表4.4-2 カウント数と精度（田野倉）

カウントライン名	カウントラインの端点	カウント数	真値（車両数）	精度（%）
500going	(200, 500), (400, 500)	27	28	103.7
500going	(450, 500), (650, 500)	18	17	94.4
400going	(200, 400), (350, 400)	27	26	96.2
400going	(450, 400), (550, 400)	18	16	92.9
300going	(250, 300), (350, 300)	27	26	96.3
300going	(450, 300), (500, 300)	18	15	89.3
250going	(300, 250), (400, 250)	27	8	29.6
250going	(450, 250), (500, 250)	18	12	66.7
200going	(400, 200), (450, 200)	27	0	0
200going	(450, 200), (500, 200)	18	3	16.7

y=400~1000の間でほぼ同様の精度が確認された。一方、図4.4-7および表4.4-2に示す田野倉における検出結果は、これは、看板等をトラックに誤検出することが影響するため、軌跡にばらつきが生じるために誤差が生じると考えられる。実際に、軌跡を可視化するとカウントラインを通過しない軌跡が存在することがわかる。また、これらの地点でカウントラインの最適化を実施した結果を、図4.4-8と表4.4-3に示す。



図4.4-8 カウントラインの最適化結果

表4.4-3 カウントライン最適化による精度

カウントライン名	カウントラインの端点	カウント数	真値 (車両数)	精度 (%)
田野倉 Going	(382.2, 209.9), (401.8, 226.6)	23	27	85.2
田野倉 Coming	(407.8, 310.4), (464.6, 270.9)	16	18	88.9
神宮橋 (潮来側)Going	(870.3, 405.4), (918.3, 348.0)	82	72	113.9
神宮橋 (潮来側)Coming	(734.6, 396.0), (789.2, 347.1)	72	76	94.7

2) 画角変化を考慮した検証

ここでは、CCTVカメラ映像に画角変化が生じた場合を考慮した検証を行う。なお、使用するデータは、CCTVカメラを模して歩道橋上に設置した複数台のビデオカメラ映像を用いることで、擬似的な画角変化を再現している。画角変化は、ズームイン、カメラのパンなどを意味する。

図4.4-9はカメラのズームイン前後の比較であり、画角1から画角2への変化を示す。元画角を使用し続けた場合、ズームイン後画角では対象とする車線より隣に位置している。表4.4-4より、カウントライン更新の有無で検出制度が大きく異なり、更新した場合の方が、より真値に近い値がとられていることがわかる。図4.4-10を確認すると、大型車両のオクルージョンの影響により、検知が途切れ途切れとなっている。それぞれのオクルージョンを互いに避けるようにカウントラインが最適化されているのではないかと考察される。

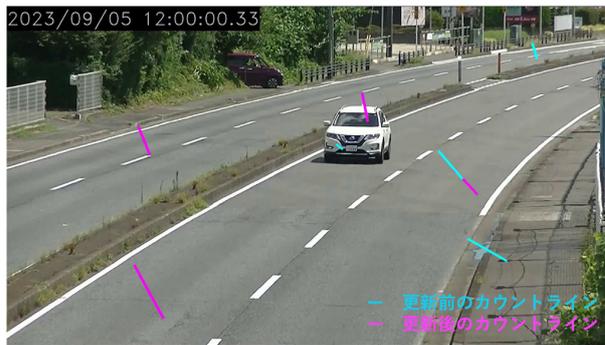


図4.4-9 画角変化による更新結果

表4.4-4 画角変化における精度比較

更新	位置 (x1, y1, x2, y2)	計測値 (台)	真値 (台)	精度 (%)
更新あり	415, 381, 451, 471	27	42	64.3
	1121, 274, 1139, 366	32	39	82.1
	402, 820, 494, 990	37	42	88.1
	1408, 514, 1485, 596	43	42	102.4
更新なし	1658, 116, 1673, 167	0	42	0.0
	1040, 437, 1060, 453	12	39	30.8
	1362, 458, 1438, 547	28	42	66.7
	1454, 737, 1578, 808	0	42	0.0

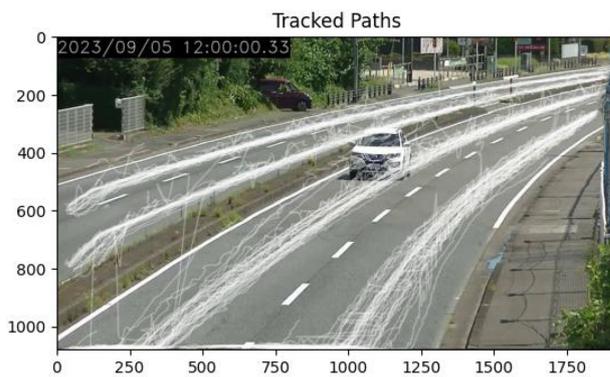


図4.4-10 車両軌跡のプロット

3) 時間変化を考慮した検証

ここでは、時間経過により映像の日照条件等が変化することにより、AI検知の挙動が変化することを想定した検証である。なお、本来時間帯は連続的に変化するものであるが、簡単のために12:00、19:00の2時間帯による観測結果を利用する。図4.4-11では、12:00に最適化されたカウントラインを、19:00に引き続き使用し続けた結果を示す。表4.4-5は、19:00の段階でカウントラインを最適化し直した結果を示す。最適化によってカウントラインの設定位置が移動していることがわかる。ヘッドライトが画角内に映り込み、比較的明るい場所で検知されていると考えられる。実際に、図4.4-12の軌跡分布図を確認すると、手前側は追跡が途切れていることが見受けられる。



図4. 4-11 時間変化による更新結果

表4. 4-5 時間変化における精度比較

更新	位置 (x1, y1, x2, y2)	計測値 (台)	真値 (台)	精度 (%)
更新あり	1342, 209, 1399, 327	43	24	179.2
	1506, 330, 1570, 406	20	27	74.1
	1495, 645, 1587, 704	18	20	90.0
	742, 425, 788, 523	19	22	86.4
	1658, 116, 1673, 167	5	24	20.8
更新なし	1040, 437, 1060, 453	23	27	85.2
	1362, 458, 1438, 547	17	20	85.0
	1454, 737, 1578, 808	18	22	81.8

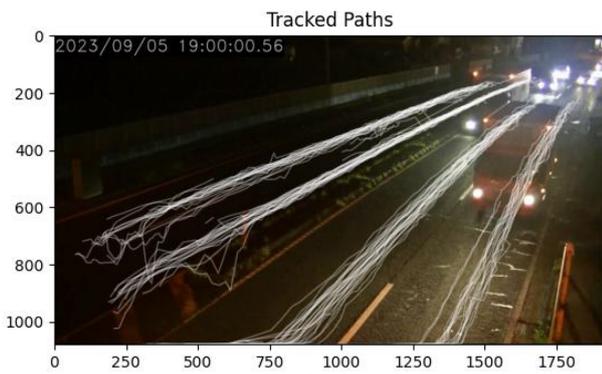


図4. 4-12 車両軌跡のプロット

(5) 本研究の成果と課題

カウントラインを最適化するアルゴリズムを構築し、これらを元に検証を行った。カウントラインを最適化する際に、車線推定やカーネル密度推定による軌跡群の集約、最大となる密度を推定した。これらの結果に基づいてカウントラインの最適な位置および傾きが求められるようになった。これらのカウントラインの位置によって、交通量の計数精度に影響を及ぼすことがわかった。特に、モデルや時間、画角の変化が発生する場合、著しく交通量計測に影響を及ぼす。これらを動的に変化、対応させることで、条件変化に対しても堅牢な交通量計測が可能になることが本研究の貢献するところである。

今後の課題を以下に列挙する：

- 現状、射影変換などの一部アルゴリズムに関しては、精度担保の関係から手動で進め

ることとなっており、完全な自動化には至っていない。また車線推定部分では、交差点やインターチェンジ付近など、完全なクラスタリングが困難な地点が存在する。したがって、地点の特徴ごとに類型化を行い、外部パラメータ設定や、新たな手法によって最適化を行う必要があると考えられる。

- 状態空間モデルを適用し、車両の通行履歴から逐次的にカウントラインを更新させることで、リアルタイム検出での動的な最適化も期待される。

参考文献

- [1] C. J. Lin and J. Y. Jhang. Intelligent traffic-monitoring system based on yolo and convolutional fuzzy neural networks. *IEEE Access*, Vol. 10, pp. 14120–14133, 2022.
- [2] S. Bouaich, M. A. Mahraz, J. Riffi, and H. Tairi. Vehicle counting system in real-time. In *2018 International Conference on Intelligent Systems and Computer Vision (ISCV)*, pp. 1–4, Fez, Morocco, 2018.
- [3] E.R.I.A.C.M. Uduwaragoda, Amal Perera, Dileeka Dias. Generating lane level road data from vehicle trajectories using kernel density estimation. In *IEEE Conference on Intelligent Transportation Systems, Proceedings, ITSC*, pp. 384–391, 2013.
- [4] L. Zheng, H. Song, B. Li, and H. Zhang. Generation of lane-level road networks based on a trajectory similarity-join pruning strategy. *ISPRS International Journal of Geo-Information*, Vol. 8, No. 9, 2019.
- [5] Zhouyu Fu, Weiming Hu, and Tieniu Tan. Similarity based vehicle trajectory clustering and anomaly detection. In *IEEE International Conference on Image Processing 2005*, pp. II–602, Genova, Italy, 2005.
- [6] Héctor Rodríguez-Rangel, et al. Analysis of statistical and artificial intelligence algorithms for real time speed estimation based on vehicle detection with yolo. *Applied Sciences*, Vol. 12, No. 6, p. 2907, 2022.
- [7] Yifu Zhang, Peize Sun, Yi Jiang, Dongdong Yu, Fucheng Weng, Zehuan Yuan, Ping Luo, Wenyu Liu, and Xinggang Wang. ByteTrack: Multi-object tracking by associating every detection box, 2022.
- [8] Yunhao Du, Zhicheng Zhao, Yang Song, Yanyun Zhao, Fei Su, Tao Gong, and Hongying Meng. StrongSORT: Make deep sort great again, 2023.

4.5 CCTVカメラ画像レベルでのマイクロ交通データ生成の検証

(1) はじめに

これまでの成果を踏まえて、CCTVカメラ画像からマイクロ交通量データの生成を試みる。

本節では大きく4つのステップで検討を進めた(図4.5-1)。まずカメラ内の2点間距離や移動体の位置・大きさを推定するため、カメラ画像と航空写真から距離計測する技術開発を行った。次に、次世代交通計測システムとしてのユーザー利便性向上のためAI解析結果から計測断面を自動生成することを試みた。最後にこの2つの検討結果を活用し、実際のCCTV動画を対象に交通量と速度を計測する技術開発を行い、計測結果の検証を行った。

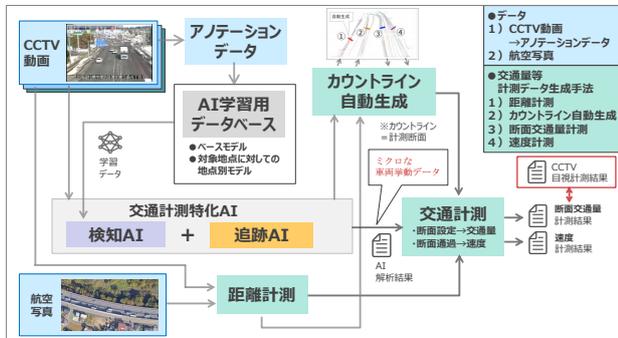


図4.5-1 ミクロ交通データ生成のフロー

(2) 移動軌跡データ生成の検証

AIにより検知した移動体のID別に移動点を時系列に線分で繋ぐことにより、移動軌跡データが作成できる。なお、交通計測に用いる座標点は解析結果ファイルに記載されているBBBoxの左上座標から中央下座標に変換後の値を用いる(図4.5-2)。



図4.5-2 移動軌跡データの生成手順

小野幌および城北における移動軌跡データの生成例を図4.5-3に示す。検知精度の向上により、概ね良好な移動軌跡を生成出来ていることが確認できる。また、検知の開始および終了地点を見ると、車両のIDスイッチがさほど発生していないことが確認できる。以上より、良好な軌跡データ生成が実現できたと判断する。

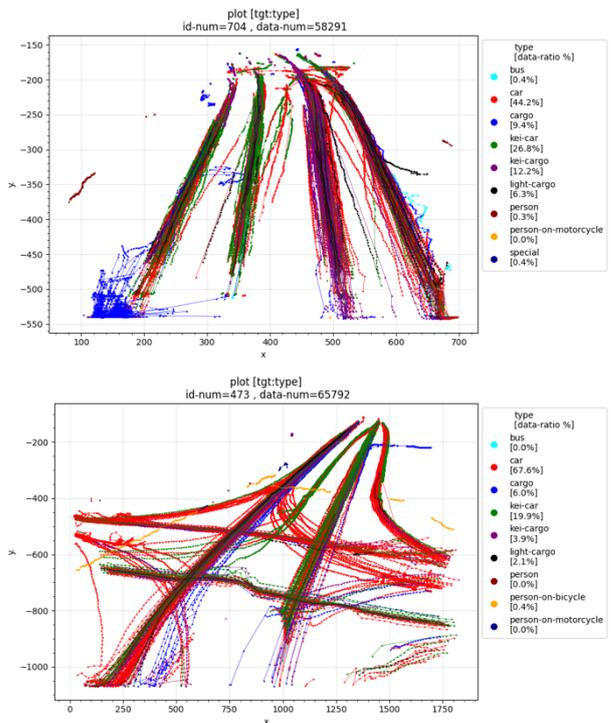


図4.5-3 移動軌跡データの生成
(上段：小野幌 下段：城北)

(3) 断面交通量計測精度の検証

1) 断面交通量の計測方法

計測断面は2つの手法で設定が可能である。

- 前節のカウントライン自動生成(車線別に計測断面を取得可)
- 手動での計測断面の設定(道路面全体に計測断面を配置)

カウントライン自動生成は、AI解析結果等を用いて半自動的に計測断面を生成することができる。また、車線別判定を行っており、車線別計測断面の取得が可能である。ただし、車線別に生成されるため、車線変更中の車両等の計測漏れが発生してしまうおそれがある。交通量を計測するという主目的を達成するためには、上記等の計測漏れを防ぐことが望ましい。そのため、道路面全体に計測断面を設定することを推奨する。断面交通量における計測断面の適用方法としては、方向別交通量総数を2つ目の方法で把握し、車線別交通量は、方向別交通量総数と車線別交通量比率から計算を行う。

計測断面は、カメラ画像内2点を結ぶ線分にて表現する(図4.5-3)。原点は、カメラ画像の左上として、横方向は左から右を正、高さ方向は上から下を正とする。また、横方向をx、縦方向をyと表記する。各端点の位置は、[x,y]で表現し、値はピクセルとする。なお、これ以降、断りが無い限り、断面に対して、「手前から奥」をgoing、「奥から手前」をcomingと表記する。

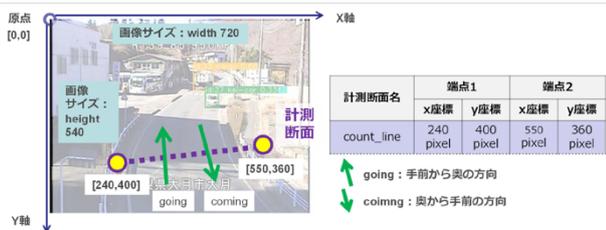


図 4.5-3 計測断面の設定方法

断面交通量は、交通計測特化 AI の解析結果である ID 別移動軌跡データ (ID, 車種タイプ, Bounding box (BBox) の位置座標等) とカメラ内に設定した断面を用いて、移動体の移動軌跡と計測断面線分との交差判定から断面交通量を計測する。計測のデータ間隔は 1 フレーム単位とする (図 4.5-4)。

ここで、断面交通量計測の計測位置は、BBox 中央下を基本とした。これは車両の大きさにより、BBox の height が変化するため、地面付近で Y 座標の位置変化が少ない点を採用することが計測精度の安定性に寄与するためである。一方、人については人同士の重なりや遮蔽が大きい場合は、中央上を計測位置とするのみ一案である。これは、頭だけで検知し、体全体の大きさが分からない場合、height 値が安定しないため、中央下を計測位置とすると計測精度が低下する恐れがあるためである。

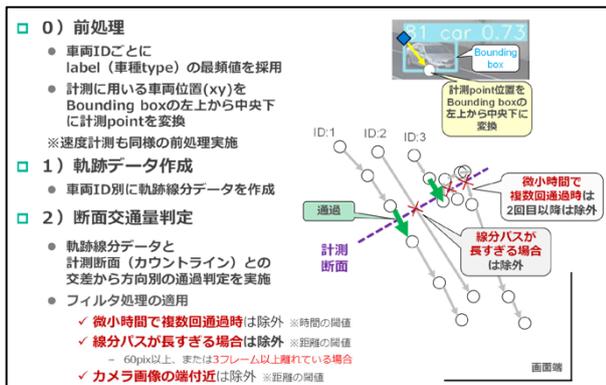


図 4.5-4 断面交通量の計測手順

2) 断面交通量計測の検証

【小野幌】

図 4.5-5 に移動軌跡データおよび断面交通量の計測結果を示す。図中タイトルに表示されている id 数 (id-num) が対象断面を通過した台数を意味しており、going は 19 台、coming は 33 台であった。この結果から、条件設定の範囲において、正しく断面交通量を計測できることを確認した。

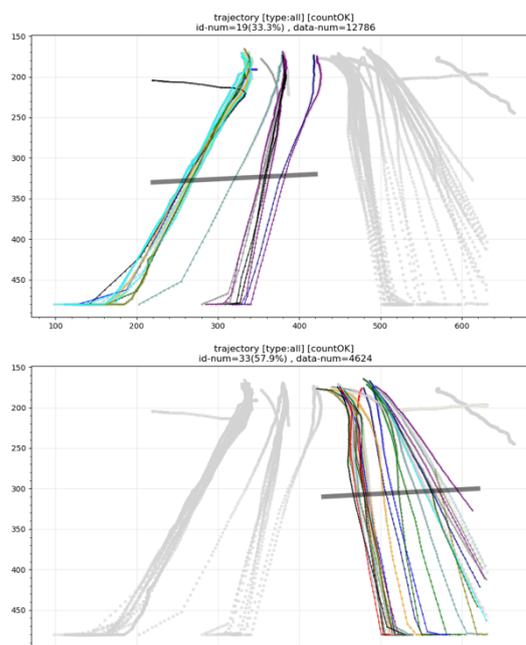


図 4.5-5 小野幌における車両軌跡と計測断面 (上段: going 方向 下段: coming 方向)

【城北】

図 4.5-6 に移動軌跡データおよび断面交通量の計測結果を示す。

車線別の断面交通量は、計測断面を車線ごとに設定することにより、計測可能である。次世代計測システムでは 1 回の交通計測の実行で、複数の計測断面の断面交通量を計測することができる。なお、前記の通りカウントライン自動生成により得られた車線別の計測断面、カメラ地点によっては車線変更の車両に対応した計測断面線となっていない場合がある。その場合は、別途計測断面で方向別交通量総数を把握し、方向別交通量総数と車線別交通量比率から車線別断面交通量を計算する。

3) 課題点の整理

断面交通量計測における課題を下記に示す。

- 断面交通量計測設定値 (フィルタ処理) の違いによる感度分析の実施
- 断面交通量の正解データがあり、断面交通量計測結果がオーバーカウント傾向であった場合の適切な断面交通量計測設定値 (フィルタ処理) の検討
- 遮蔽 (オクルージョン) が発生しやすい計測断面における適切な断面交通量計測設定値 (フィルタ処理) の検討
- 計測断面設定の深度化 (カウントライン自動生成結果の適用方針)
- 交差点内等における OD 交通量の計測

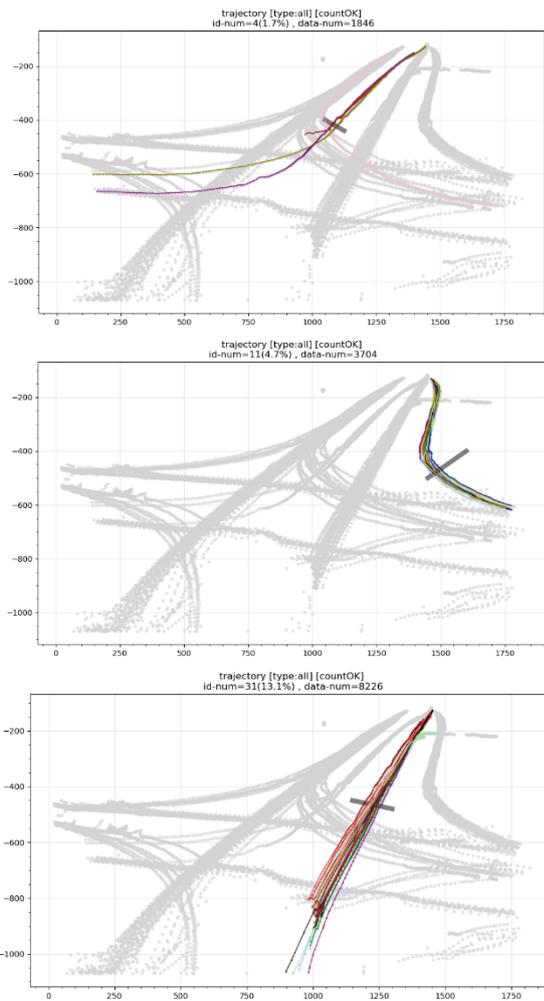


図 4.5-6 城北における車両軌跡と計測断面
(上段：右折車線 中段：直進車線 下段：左折車線)

(4) 速度計測精度の検証

1) 速度計測の方法

速度計測に関して、次世代交通計測システム上で並立する計測である断面交通量計測と手法が整合していると、実務的に扱いやすい。このことを踏まえて、断面交通量計測と同様に、計測ラインを手動で設定し、そのラインの通過時刻を基準に速度を計測する方針とした。

これまで、2本の速度計測ラインを引いて、その直線距離と通過時間から速度を求めることを検討していた。しかしながら、速度計測ラインを2本引くことの煩雑さに懸念があった。また、速度計測ライン間の距離を求める際、ラインが必ずしも車線に垂直に引かれるとは限らず、精度担保に課題があることがわかった。

これを受けて、速度計測ラインを1本のみ引いて、ラインと交差した車両について、前後の軌跡から移動距離と移動時間を求めることで、速度を計測することとした。速度計測イメージは以下の図 4.5-7 に示すとおりである。具体的な手順は以下のとおりである。

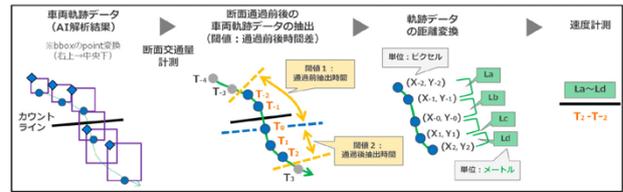


図4.5-7 速度計測の手順

- [1] 車両軌跡データの BBox の point 変換 (右上→中央下)
- [2] 断面交通量計測：カウントラインごとに通過した ID のみを抽出（速度計測でも、前項の断面交通量と同じ交差判定を行う）
- [3] カウントライン通過前後時間差範囲内の車両軌跡データのみを抽出
- [4] 画像内ピクセル座標と別途実施済の当該カメラ画像での射影変換行列から距離を計測
- [5] 移動時間差と移動距離から速度を計測

このうち、手順[1]と[2]は断面交通量計測と共通手順である。手順[3]ではカウントライン通過前後時間差範囲（軌跡抽出範囲）をあらかじめ設定しておき、それによって軌跡データを抽出する。手順[4]では前述の距離計測手法を用いる。

速度計測の際に確認すべきポイントは、手順[3]の軌跡抽出範囲をいくつに設定すべきか、手順[2]のカウントライン（速度計測ライン）をどこに設定すべきか、の大きく2つある。

2) 速度計測の検証

速度計測地点は、真値データが存在することから、田野倉と小野幌を対象とした。

速度計測の前提条件として、各ケースにおける速度計測ラインは図 4.5-8 のように定めた。速度計測ラインのうち、haga から始まるもの（haga ライン）は車線別に引いたものであり、1つのラインにつき車両の走行方向（going 方向と coming 方向）は片方のみである。また、このラインはカウントラインの自動生成結果として得られたものである。一方、VRI_line（VRI ライン）は全車線を共通に引いたものであり、同一ラインで going 方向と coming 方向を別々に計測される。こちらはカメラ画像内の位置による AI 検知追跡と距離計測の精度を考慮して、手動で設定したものである。

これらの速度計測ラインについて、当該ラインを通過した車両の台数を以下に示す。このうち AI が AI 検知追跡に基づく軌跡データ、GT が手動作成の Ground Truth（真値）データを指

す。AI と GT いずれも、通過車両台数は前述の交通量計測手法で計測した結果である。また、VRI ラインのみ全車線（上下線）の合計通過台数、haga ラインは車線別の通過台数である。

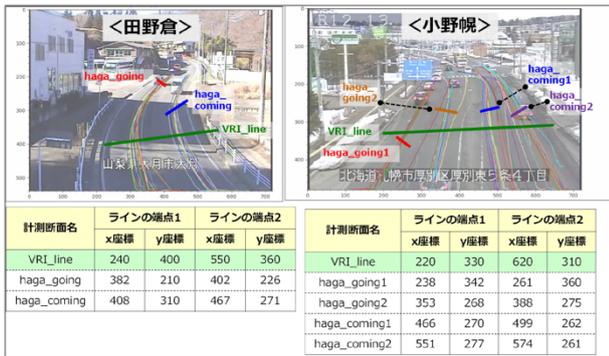


図4.5-8 検証地点における計測ラインの設定

表4.5-1 断面交通量の計測結果

対象地点	計測断面名	計測断面の設定方法	計測断面における断面交通量	
			AI (AI解析結果)	GT (正解データ)
田野倉	VRI_line	手動	42	43
	haga_going	自動生成	24	26
	haga_coming		16	16
	hagaライン合計		40	42
小野幌	VRI_line	手動	55	52
	haga_going1	自動生成	9	10
	haga_going2		6	6
	haga_coming1		15	14
	haga_coming2		7	8
	hagaライン合計		37	38

速度計測結果を詳細に確認するため、各地点の速度ヒストグラムと箱ひげ図を作成した。なお、小野幌のhagaラインのヒストグラムについては、2車線分を合算して集計した。箱ひげ図では、T字の左端が最小値、右端が最大値、箱の左端が25%値、右端が75%値、橙色の線が中央値を表す。

田野倉（図4.5-9）と小野幌（図4.5-10）において、coming方向では計測ライン手動設定（VRI）と計測ライン自動設定（haga）ともに速度の頻度分布が単峰性でまとまっており、代表値を計算しやすい分布であることが分かった。一方、小野幌going方向については、両ラインともに速度が大きく分散していることがわかった。前述の通り交差点近傍であるため、そもそも車両の速度がばらつき、速度の代表値を定めるのが難しい条件であったことがわかる。この中で、hagaラインではVRIラインよりも分布がなめらかであり、速度の代表値を相対的に求めやすいと言える。なお、計測ライン別に見た場合、速度範囲の違いに一定の傾向は見られなかった。

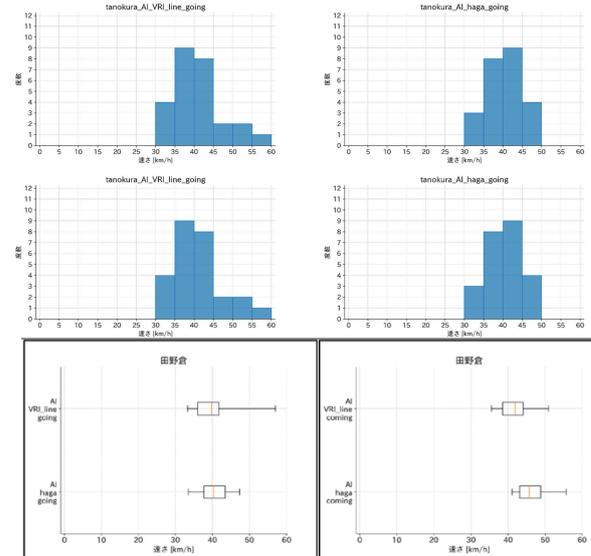


図4.5-9 田野倉における速度分布と箱ひげ図
（左図：計測手動設定，右図：計測自動設定）
（上段：going方向，下段：coming方向）

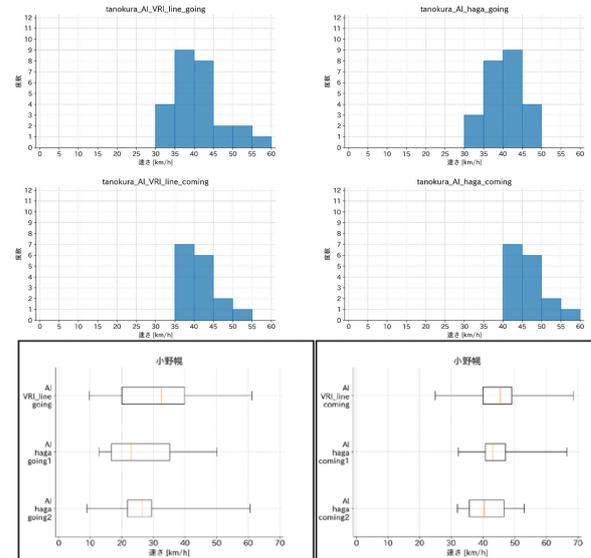


図4.5-10 小野幌における速度分布と箱ひげ図
（左図：計測手動設定，右図：計測自動設定）
（上段：going方向，下段：coming方向）

3) 課題点の整理

交差点に進入する方向のように車線変更が生じる場所では、速度が大きくばらつくことがわかった。この中には、車線変更中のようなイレギュラーな車両挙動が含まれる。この結果の取り扱いに関しては、どの車両の速度を計測したいかというニーズと、実際の車両挙動の両方を考慮して、適切な速度計測方法を踏み込んで検討する必要がある。

また、本検討では実際の速度データがなかったため、速度計測結果については傾向の確認にとどまっている。今後、車両のカメラ動画撮影と速度の直接計測（スピードガン等）を同時に

行った上で、動画に対して提案手法を適用し、実測速度と比較することで妥当性を確認することが望ましい。

(5) 本研究の成果と課題

はじめに速度計測について成果を整理する。AI 検知追跡結果に対して提案した速度計測手法を適用すると、妥当な速度を計測できることが分かった。特に速度計測のための軌跡抽出範囲は基本的に、速度計測ライン通過時点の±1秒区間としてよいことがわかった。速度計測ラインの長さについては、片側1車線の場所や、単路部のような車線の影響を受けない場所であれば、交通量と同じラインで速度を計測しても速度のブレは発生しにくいことが分かった。速度計測ラインの位置については、射影変換時の画像の歪みとAI検知追跡可能な領域の両方を考慮し、基本的には交通量計測と同じく、カメラ画像下側で取得するのが望ましい。その際、交差点近傍等、地点ごとの特性を考慮すべきであることが分かった。

交通計測特化AIの解析結果であるID別移動軌跡データとカメラ内に設定した断面を用いて、移動体の交通量と速度を計測する技術開発を行った。また、その前段として、カメラ画像と航空写真から距離計測する技術および次世代交通計測システムとしてのユーザー利便性向上のためAI解析結果から計測断面を自動生成する技術の開発を行った。本技術開発により、AI解析結果の単純集計では把握することが難しい移動体の交通量と速度を計測する技術を確立した。本技術は、次世代交通計測システムに実装される。

以下に今後の課題を示す。

【断面交通量計測】

- 断面交通量の正解データがあり、断面交通量計測結果がオーバーカウント傾向であった場合の適切な断面交通量計測設定値（フィルタ処理）の検討
- 遮蔽（オクルージョン）が発生しやすい計測断面における適切な断面交通量計測設定値（フィルタ処理）の検討
- 計測断面設定の深度化（カウントライン自動生成結果の適用方針）
- 交差点内等におけるOD交通量の計測

【速度計測】

- 車線変更中のようなイレギュラーな車両挙動を含む場合の速度計測
- 正解データを用いた計測精度検証

4.6 時系列AIモデルを活用した時間帯別リンク交通量データ生成の構築と検証

(1) はじめに

複数のデータを活用してネットワーク上の交通データを生成する手法を検討する。ここでは、リンク交通量に着目して、センサデータを基本としながら、トラカンやAI観測結果などの断面観測データとプローブなどの移動観測データを融合した時系列でのリンク交通量を生成するモデルを構築する。具体的には、時系列データを扱うことが可能なAIモデルであるLSTM (Long Short Term Memory) を活用した生成モデルを検討する。

(2) 既往研究の整理

リンク交通量推定では、これまでも様々な手法が検討されており、近年では機械学習やニューラルネットワーク、それらを組み合わせたモデルを用いた研究が盛んである。特に、時間とともにネットワーク構造が変化するリンク交通量は動的であり、動的リンク予測は交通流の他にも生物学やソーシャルネットワークなどのさまざまな分野で研究が進められている。

小川ら¹⁾は鎌倉市の観光交通量を多変量LSTMにより、60分先の横浜鎌倉線下馬の断面交通量短期予測を行った。多変量LSTMの特徴量として15分単位の交通量の他に降水量や社会イベントを組み込んでおり、1年以上の長期データを基に予測モデルの構築を行い、季節性による交通量の変動にも対応した。その結果、学習モデルは観光交通が持つ季節性を補足し、降雨や社会イベントの影響を予測に反映している可能性を示唆した。

Huseyinら²⁾は空間的特徴を抽出するGCN (Graph Convolutional Network) と時間的特徴を抽出するLSTMを組み合わせ、数日先の長期交通流速度予測モデルを構築した。入力値にはETC2.0速度、ETC2.0サンプル数、降水量、曜日を用い、予測対象道路区間の他に上下流道路区間の情報を取得する簡易道路ネットワークを準備した。曜日別の予測精度では平日の場合高いが、土日は少し低下し、祝日の場合は大きく低下することを確認した。加えて、従来の時系列予測に用いられてきた自己回帰和分移動平均モデル (ARIMAモデル) との精度比較を行って結果、LSTMやGCNなどのディープラーニング手法が従来の時系列予測モデルよりも柔軟な予測が可能であることを示した。

これらの既往研究から、交通状態の時系列予

測には時間的特徴を正確に抽出するディープラーニング手法の導入の他に空間的特徴や空間相関も考慮することで精度向上が期待される。近年では道路ネットワークをグラフ構造と捉え、時間的特徴と空間的特徴を同時に抽出するモデルも出現してきている。

Chen³⁾らはエンドツーエンド動的リンク予測のために、グラフ畳込みネットワーク (Graph Convolution) 組込みLSTMのGC-LSTMを提案した。この新しいディープラーニングモデルにおけるGCNは、各時間スライドに対するネットワークスナップショットのノード構造学習が可能であり。一方、LSTMはネットワークスナップショットに対する時間的特徴の学習を可能とする。さらに、現在の動的リンク予測方法は、除去リンクを扱うことができるだけであり、GC-LSTMは、同時に追加または除去リンクの両方を予測することができた。拡張実験を行い、予測精度、誤り率、加算/移動リンク予測および鍵リンク予測の側面におけるその性能を検証した。しかし、既存のフレームワークは固定されたグラフ構造と与えられた時系列に基づいて空間的・時間的モデリングを構築していたためネットワークの効果的な時空間相関を学習するには限界があった。

Yangら⁴⁾は上記の課題を解決するために新たにSTFAGN (Spatiotemporal Adaptive Fusion Graph Network) と呼ばれる交通流短期予測モデルを新たに構築・提案した。このモデルは融合畳込み層による新しい適応依存行列と異なる期間の空間グラフと時間グラフを組み合わせることでデータ上の隠れた空間的・時間的依存関係を捕捉し、fast-DTWによってマクロな時間的傾向も獲得した。

また、Yi-cheng⁵⁾ は注目機構と残差ネットワークに基づくTSARGCNを提案した。ここでは、GC-LSTMと同様に交通流データの時間的・空間的關係をモデル化した。GC-LSTMと異なる点は各ブランチにおいてグラフ畳込みと時間畳込みをそれぞれアテンション機構と組み合わせる点である。オープンデータセットPEMSD4を用いた実験結果より、TSARGCNのMAEとRMSEはそれぞれ19.24と27.09であり、ARIMA、CONV-LSTM、ASTGCNよりも優れていた。

このようにリンク交通量推定の分野では常に新しい技術が取り入れられ、発展が目まぐるしい分野である。本研究では、これらの手法を活用しながら、時間帯別リンク交通量予測モデルの構築に取り組む。

(3) 時系列AIモデルの基本構造

1) ニューラルネットワークモデル

一般的なニューラルネットワークの説明をする。ニューラルネットワークには、「ニューロン」と呼ばれるノードが存在し、それらを層状かつネットワーク状に繋げて構成される数値モデルである。層の種類には入力層、隠れ層（または中間層）、出力層の3つの層が存在する。処理の流れは入力層でネットワーク全体の入力値を受け取り、隠れ層で計算処理を施し、出力層でネットワーク全体の出力値を算出する仕組みである。隠れ層の計算処理の違いによって様々なニューラルネットワークが存在する。代表的な例では、畳み込みニューラルネットワーク（Convolutional Neural Network: CNN）や再帰型ニューラルネットワーク（Recurrent Neural Network: RNN）が存在する。

図4.6-1の例では、各層におけるニューロンの数は、入力層が2、隠れ層が4、出力層が1である。ニューラルネットワークで行われる処理には、「学習(トレーニング)」「推論(テスト)」に分けられる。学習とは、ある問題を解くためにネットワークのパラメータをチューニングすることである。学習では、ネットワークの出力値と正解値で計算される誤差関数の値により、繰り返し学習を行うことでパラメータのチューニングを行う。誤差関数には、確率的勾配降下法（Stochastic Gradient Descent: SGD）など様々な種類が存在する。一方、推論とはチューニング済みのネットワークを用いて、未知の解答を算出することである。

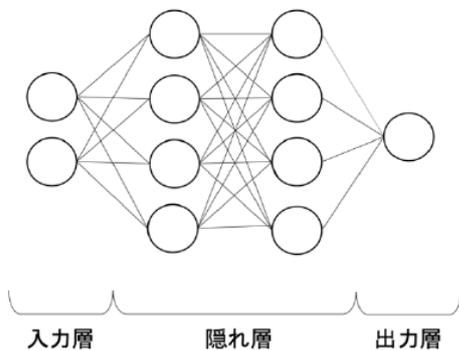


図4.6-1 一般的なニューラルネットワーク

2) リカンレントニューラルネットワーク

次に、LSTMの元となるRNN (Recurrent Neural Network) を説明に移る。RNNとは時系列データを扱うことに長けている再帰型ニューラルネットワークのことである。このRNNの特徴は時系列データを扱えることであり、複数あるRNNレイヤは全て「同じレイヤ」である。図4.6-2の

例では、 x_t は入力値、 h_t は隠れ層（RNNブロック）の出力値である。しかし、RNNは時系列データの長期の依存関係をうまく学習することができない。その理由は、学習のパラメータチューニングの際のBPTT（Backpropagation Through Time）において勾配消失もしくは勾配爆発が起こることに原因がある。

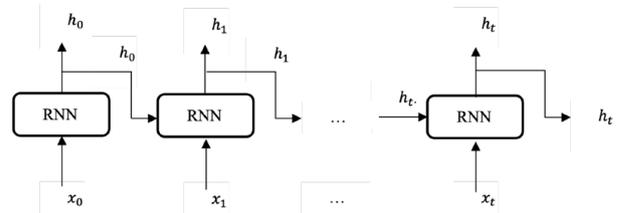


図4.6-2 一般的なRNNの構造

3) LSTM

そこで、RNNに代わり、LSTMというレイヤが存在する。RNNとの違いは「ゲート」と呼ばれる仕組みが加わっている点と記憶セルと呼ばれる経路が存在することである。ゲートとはデータの流れを制御する箇所であり、データから「どれだけゲートを開くか」を学ばせる。このゲートによって情報の取捨選択を行う。記憶セルとはLSTMレイヤ内のみでデータの受け渡しを行い、LSTMの記憶部分に相当する。これらのゲートと記憶セルによって、RNNが苦手とする時系列データの長期依存関係を学習することが可能となる

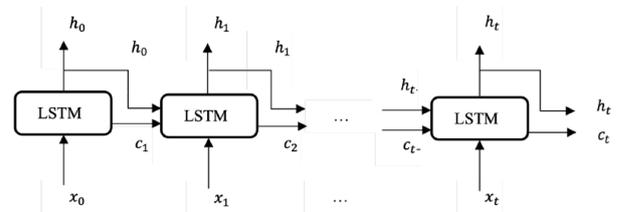


図4.6-3 一般的なLSTMの構造

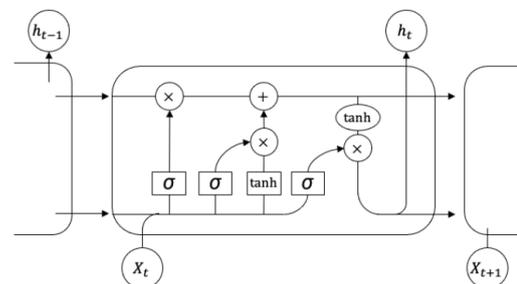


図4.6-4 LSTMの計算グラフ

図4.6-3と図4.6-4より、時刻 t において、 x_t は入力、 h_t は隠れ層の値、 c_t は記憶セルに該当する。この記憶セルには時刻のLSTM記憶が格納されており、これに過去から現在の時刻までに

において必要な情報が全て格納されている。くわえて、**図4.6-4**において、forgetゲート，inputゲート，outputゲート， σ はシグモイド関数を表す。それぞれのゲートおよび隠れ層の値は以下の式で表される。

$$\begin{aligned} f &= \sigma(x_t W_x^f + h_{t-1} W_h^f + b^f) \\ i &= \sigma(x_t W_x^i + h_{t-1} W_h^i + b^i) \\ o &= \sigma(x_t W_x^o + h_{t-1} W_h^o + b^o) \\ h_t &= o \bullet \tanh(c_t) \end{aligned}$$

ここで、 W_x^* は各ゲートにおける入力の重み、 b_x^* は各ゲートにおけるバイアスである。なお、ドットはアダマール積である。

(4) 時系列リンク交通量予測モデルの構築

1) 提案モデルの構造

本研究のモデル構造は、1次元の入力層のリンク交通量のみを入力データとし、シーケンシャルサイズは5時間分とした。出力は1時間先のリンク交通量を予測する。すなわち連続する5時間分のリンク交通量を入力すると、1時間先のリンク交通量を出力する流れである。将来的には入力データに降雨量，気温などの気候情報，道路工事情報，平日と休日，祝日を分けるフラグなどなどさまざまなパターンを試行して行きたい。また，ドロップアウトの設定もして行きたい。ドロップアウトとは過学習の抑制を目的とする処理であり，一定の確率でランダムにニューロンを無視して学習を進める正則化の一種である。全結合層は線型結合を用いた。

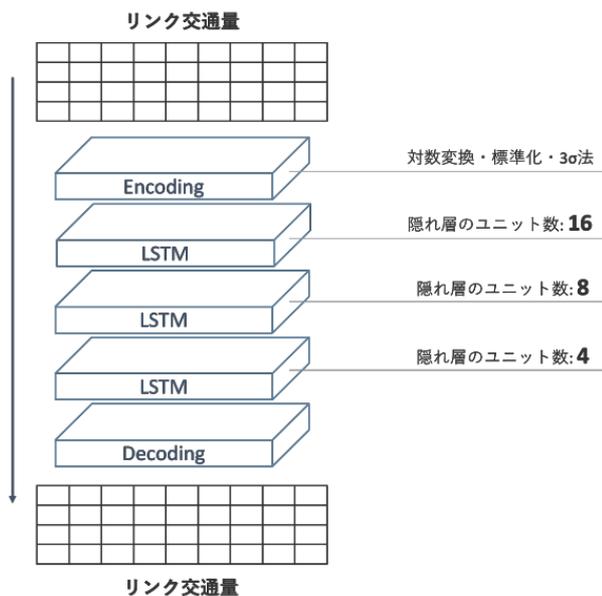


図 4.6-5 時系列リンク交通量の計算フロー

表 4.6-1 LSTM のハイパーパラメータ

ハイパーパラメータ	値
エポック数	500
損失関数	平均二乗誤差 (MSE)
オプティマイザ	RMSProp
シーケンシャルサイズ	5

本モデルの計算フローを**図4.6-5**に示す。また，本モデルのハイパーパラメータは**表4.6-1**にまとめる。

特徴量のエンコーディングには3 σ 法で外れ値処理を施し，ログ変換×標準化でスケールを施した。3 σ 法とはデータが正規分布に従っている場合，平均から標準偏差の3倍以上離れた値は外れ値とみなし，データより排除する手法である。今回は外れ値には平均値を用いて穴埋めを行った。また，ログ変換はデータを正規分布に近づけることを目的に据えて行った。

2) 検証用データの概要

本節における適用データはETC2.0プローブデータから生成したリンク交通量である。ETC2.0プローブデータの概要，およびリンク交通量への集計方法は4-7-2分析用データの概要に記載している。データスパンは2019年6月1日～8/31日までの6時台から22時台までである。2019年6月1日～7/31日までを学習データ，2019年8月1日～8月31日までをテストデータとして学習・検証（テスト）した。

学習・テスト流れは，まず一本のリンクを取り出し，そのリンクに対してシーケンシャルサイズ5で学習を進める。学習が完了次第，続けてテストに入りテストを行い，その結果を精度評価に用いた。学習の流れは**図4.6-6**に示す。

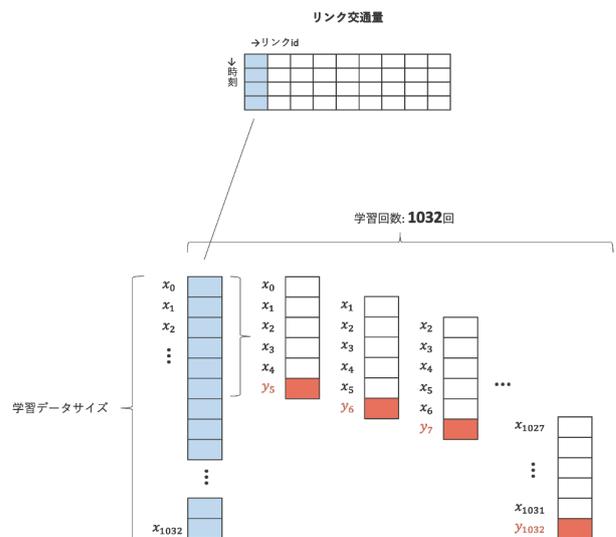


図 4.6-6 モデルの学習計算

3) 検証結果と考察

本研究における LSTM モデルの精度評価結果を表 4.6-2 に示す。精度に着目すると、決定係数 R^2 は 0.9371 と数値上高精度の結果を出力した。しかし、RMSE の値が MAE の値よりも 2 倍以上大きいため、予測を大きく外した点が複数個存在することが確認することができる。これに関して、図 4.6-7 より y-y plot から視覚的に評価する。

表 4.6-2 精度検証の結果

RMSE[car/h]	13.83
MAE[car/h]	6.808
R^2	0.9371
Test time[m.s]	27.35

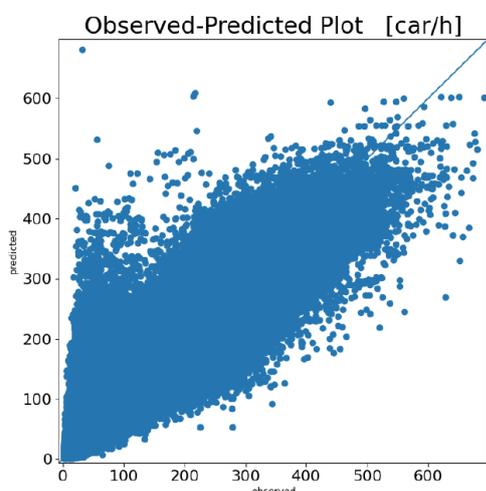


図 4.6-7 観測値と予測値のプロット

今回プロット点は300万点以上存在するためこの図では点の重なり、すなわちプロットの密度を判断することは不可能である。プロットの密度も可視化することで決定係数 R^2 は0.9371の信憑性が増すことになると考えられる。将来的にはプロットの密度を算出するためにカーネル密度関数を用いた可視化を行う。

また、本モデルはLSTM内部の隠れ層のユニット数や隠れ層数、オプティマイザなどのハイパーパラメータが最適化されていない。ハイパーパラメータのチューニングを行うことで更なる精度向上も見込まれる。また、推論時間は27分35秒と多少時間がかかる結果となり、実務上でリアルタイム予測を行うことを考えると推論時間は5分以内に収めたい。しかし、推論時間はデータサイズに大きく依存するため、今回の結果を元にデータサイズに改良を加えることで良化することは容易に予想できる。なお、

学習時間は2日と8時間以上かかっており、学習コストは極めて高いことがわかった。これは LSTM が時系列データを扱うモデルであるため、行列演算に長けている GPU の計算能力を發揮することが難しい。くわえて、本研究はデータサイズ、特にリンク数が極めて多いため時間がかかったとされる。学習コストに関しては、データサイズを小さくすることが有力な対策法ではあるが、学習効果とデータサイズは一般的にトレードオフである。そのため、現在はリザーブコンピューティングという計算コストを省略する時系列予測モデルが存在する。

さらにマクロな観点から見ると、本モデルはリンクごとの予測となっているため、近接するリンクの交通状況は考慮されていない。しかし交通状況は本来、道路ネットワークと呼ばれるほど、リンクとノードで形成されるグラフネットワーク構造を持つ。すなわち、時間相関・空間相関ともに強く作用することは明らかであるが、本モデルでは空間相関は未考慮である。そこで、空間相関を考慮するモデルとして GNN (Graph Neural Network) が存在する。この GNN を用いることで空間相関を捉えた道路ネットワーク上でのリンク交通量を表現し、本モデルの LSTM 等と組み合わせることで時間相関・空間相関の双方を考慮したモデル構築が期待される。

参考文献

- [1] 小川晃平, 福田大輔. 多変量 LSTM による短期交通量予測: 鎌倉市の観光交通を対象として. 土木学会論文集 D3(土木計画学), Vol. 76, No. 5, pp. 1389-1398, 2021.
- [2] Huseyin TIRTOM, 森田格, 辻大樹, 村戸伸行, 力石真. グラフ畳み込みニューラルネットワークを用いた観光地における旅行速度予測. 第 64 回土木計画学研究発表会・講演集, 2021.
- [3] J. Chen, X. Wang, and X. Xu. GC-LSTM: graph convolution embedded LSTM for dynamic networklink prediction. Vol. 52, pp. 7513-7528, 2022.
- [4] Shumin Yang, Huaying Li, Yu Luo, Junchao Li, Youyi Song, and Teng Zhou. Spatiotemporal Adaptive Fusion Graph Network for Short-Term Traffic Flow Forecasting. Mathematics, Vol. 10, No. 9, 2022.
- [5] LIU Yi-cheng, LI Zhi-peng, LV Chun-pu, ZHANG Tao, and LIU Yan. Network-wide Traffic Flow Prediction Research Based on DTW Algorithm Spatial-temporal Graph Convolution. Journal of Transportation Systems Engineering and Information Technology, Vol. 22, No. 3, pp. 147-157, 2022.

4.7 リザーバーコンピューティングを活用した時系列リンク交通量データ生成の高速化

(1) はじめに

交通状況観測の現況としては、国土交通省が5年に1度実施する全国道路・街路交通情勢調査（道路交通センサス）が主であり、この調査では、リアルタイムのデータを収集することはできない。また、近年ではETC2.0プローブデータやCCTVカメラを活用した常時観測が行われているが、これらは普及率の低さや設置地点の網羅性の低さから、これらのデータを活用した交通状況の予測・推定手法は未発達である。

本研究の目的は、常時観測されたリンク交通量データをもとに、各リンクにおける時間別交通量を時系列データとして推定するモデルを構築することである。このモデルを構築することで、各リンクの交通量をリアルタイムで推定することが可能になり、渋滞問題の対策や災害時の異常の早期検知などへの活用が期待できる。そのため手法として、機械学習、特にグラフ畳み込みによる空間特徴の抽出を活用したモデルを構築する。特に「計算時間の短縮」を主眼において、既存モデルと比較検証する。

具体的には、観測されたリンク交通量データにグラフ畳み込み演算を用いて、道路ネットワークの空間構造を明示的に考慮した特徴量を算出する。この特徴量を入力として、ESNによる時系列推定を行う。本モデルの特徴は以下の2点が挙げられる。

- 道路ネットワークの空間構造を明示的に考慮している
- ESNによって時間的な関連性を考慮しつつ計算時間の短縮が期待できる

(2) 既往研究の整理

1) AIモデルを活用したデータ生成

小川ら¹⁾は、多変量LSTMを用い、リンク交通量のデータと降水量・社会イベント情報などを組み合わせて、リンク交通量を短期予測するモデルを提案した。特徴としては、1年という長期間にわたるデータを用いることで、長期的な影響(季節による変動など)を考慮できる点や、社会イベント情報を組み込むことで、観光客の需要を的確に捉えられる点がある。結果として、観光客が増える6月の交通量予測について、比較的高い精度を有することが示された。

吉田ら²⁾は、畳み込みニューラルネットワークを用い、道路リンクの接続関係を考慮したリンク交通量の短期予測モデルを提案した。既存

研究との違いとしては、従来のニューラルネットワークでは考慮できなかった「道路ネットワークの空間構造」を、グラフ構造に畳み込み演算を適用するGraph Convolutional Network (GCN)を用いて明示的に考慮している点が挙げられる。結果として、従来の手法と比較してパラメータを少なくしても同等の予測精度を実現した。

時系列データを扱うニューラルネットワークモデルとして、RNN (Neural Network) やその発展形のLSTM (Long-Short Term Memory) などが提案されてきた。しかし、パラメータ数や学習のコストが大きく、計算時間が膨大になるという欠点が存在する³⁾。すなわち、リアルタイムな推定には不向きであると言える。この欠点を克服する手法として、Jaegerが提案したリザーバーコンピューティング手法の一種であるEcho State Network (ESN) がある⁴⁾。このモデルの利点の一つとして挙げられるのが「計算時間の短縮」であり、リアルタイムの推定に向けたモデルであると考えられる。

2) Echo State Network (ESN)

Echo State Network (ESN) は、リザーバーコンピューティングと呼ばれる手法の一つで、Jaegerが提案したモデル⁴⁾である。RNNの課題の一つである膨大な学習コストの問題を改善したモデルである。ESNがRNNと異なる点としては以下の点が挙げられる。

- 結果を次の時刻に渡すのではなく、層内部の状態を各時刻で更新し、更新した層でそのまま次の時刻の計算を行う
- 学習のとき、層内部のパラメータなどは変えず、ESN層から出力するときのパラメータだけを学習する。具体的には、図4-5-2の赤矢印部分のみを学習する、また、内部パラメータはランダムな初期値で固定する。

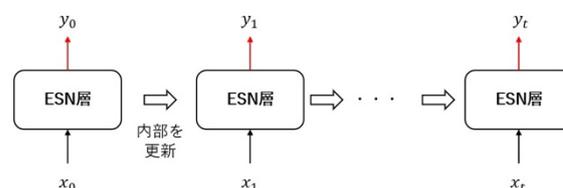


図 4.7-1 ESN の構造

これらの特徴により、RNNよりも計算コストを削減し、高速計算を可能にしながら、時間軸方向の関連を捉えられるモデルになっている。しかしながら、欠点として、学習するパラメータを削減したことにより、精度はRNNと比較して低くなる傾向にある。

本研究では、高速計算可能という点に着目し、ESNを用いて時系列推定を行う。入力を1時間単位の各リンクの交通量の時系列データとし、入力の1時間後のデータを推定し出力するモデルとする。

3) グラフ畳み込み演算

グラフ畳み込みとは、畳み込みニューラルネットワークにおける「対象の近傍のデータを集約する」という操作をグラフに適用したものである。あるノードに対して、グラフ上で隣接するノードの情報（自分自身を加えることもある）に重みを付けて集約する手法である。この手法で算出される値はグラフの構造（空間構造）を考慮した値と考えられ、この値を用いることで、元の情報と比較してより空間構造の影響を加味した推定が可能になると言える。

本研究では、ESNの低精度という課題を補うために、交通量データに対してグラフ畳み込みを行って空間的な構造を加味した特徴量を生成し、生成した特徴量をESNの入力とするアプローチをとる。グラフ畳み込みの手法としては、グラフ上の近さだけでなく接続関係も考慮できるRelational Graph Convolutional Network (R-GCN)^{5),6)}を用いる。また、畳み込む際の重みについては、ランダムな初期値とした。

(3) グラフ畳み込み演算

1) AIモデルを活用したデータ生成

モデル全体の構造を図4.7-2に示す。交通量の時系列データ(1時間単位)を入力とし、まず、入力データに対して時間別に畳み込み処理を行う(畳み込み層)。畳み込みを2回行って、2リンク先までのネットワーク上の空間構造を考慮した特徴量を生成する。その後、時間別に正規化を行ったのちにESNを用いて1時間先の交通量を出力する、という流れで処理を行う。

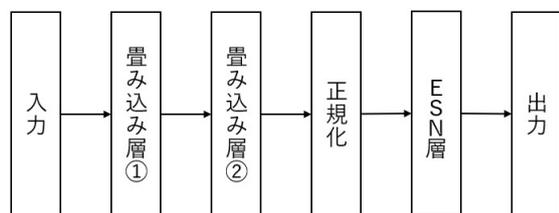


図 4.7-2 提案モデルの構造

2) シミュレーションデータの概要

本研究で構築したモデルについて、シミュレーションデータを用いた推定精度の評価および考察を行う。本研究では、Sioux Falls Networkを活用する⁷⁾。Sioux Falls Networkは、交通量配

分によく用いられるベンチマークデータである。既存の研究成果に基づいて、当該ネットワークで交通量配分を実施した結果が示されている。この配分結果をもとに、sin関数を用いて時系列化した。このようなデータを用いる場合、精度面で問題があるが、本研究では計算時間の確認を主眼とするため、問題ないと判断した。

Sioux Falls Networkにおける交通量のデータを1400時間×76リンク分用意し、最初の1050時間×76リンク分でモデルの学習を行い、残りの350時間分でモデルの検証を行う。

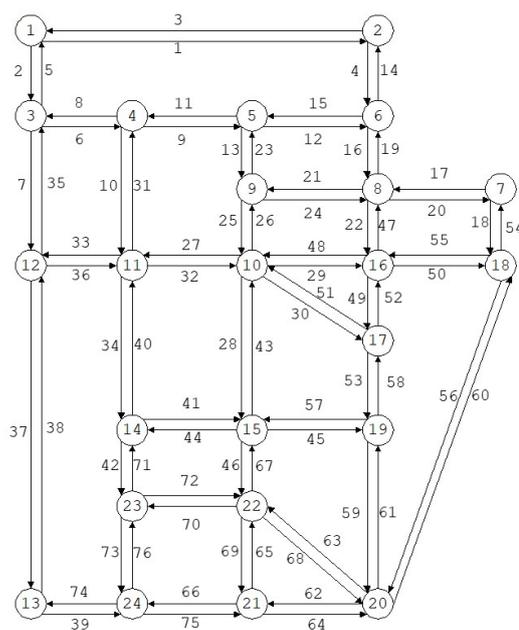


図 4.7-3 Sioux Falls Network

3) ハイパーパラメータの設定

畳み込み層・ESN層における各種パラメータは表4.7-1、表4.7-2のように設定した。

表 4.7-1 畳み込み層のハイパーパラメータ

パラメータ	値
畳み込み回数	2[回]
出力する特徴量の次元	1[リンク]

表 4.7-2 ESN層のハイパーパラメータ

パラメータ	値
最適マイザ	線形回帰
隠れ層内のノード数	300
隠れ層のノード結合密度	0.05
隠れ層の内部スペクトル半径	0.8
各ノードの活性化関数	tanh

なお、畳み込み層における畳み込み回数については、畳み込み回数が多いほど、ネットワーク上で離れた地点の情報も考慮できる反面、算出される特徴量がネットワーク全体の特徴に近づいてしまい、地点間の差がなくなっていく問題が存在するため、本研究では2回とした。また、ESN層における隠れ層内のノード数については、一回の入力データの次元(今回のデータでは76)より十分大きいことが求められるが、ノード数を増やすと、当然ながら計算時間も増加するため、本研究では300とした。

(4) 精度検証と考察

1) 性能評価指標

本研究では、モデルの精度評価に以下の2つの指標を用いる。なお、本節では推定値(出力データ)を $y_k(k=1,2,\dots,n)$ 、実測値(正解データ)を $\hat{y}_k(k=1,2,\dots,n)$ と表す。

二乗平均平方根誤差 (RMSE)

二乗平均平方根誤差 (Root Mean Squared Error, RMSE) は回帰モデルの評価に用いられる精度指標の1つで以下の式で表される。

$$RMS = \sqrt{\frac{1}{n} \sum_{k=1}^n (y_k - \hat{y}_k)^2}$$

推定値と実測値の誤差を二乗して平均した値の平方根をとった値であり、単位は推定値と同じになる(今回のケースでは台/h)。誤差を二乗するため、誤差の大きさを厳しく評価する指標だといえる。外れ値が存在すると値が大きくなる傾向があるため、他指標も併用して確認する必要がある。

平均絶対誤差 MAE

平均絶対誤差 (Mean Absolute Error, MAE) は、RMSEと同様に回帰モデルの評価に用いられる評価指標であり、以下の式で表される。

$$MAE = \frac{1}{n} \sum_{k=1}^n |y_k - \hat{y}_k|$$

推定値と実測値の誤差の絶対値を平均した値であり、単位は推定値と同じになる(今回のケースでは台/h)。誤差をそのまま平均するため、RMSEと比べて外れ値に強い指標だといえる。

その他の評価指標

他の指標として、実測値と誤差との比を%で表して平均をとる。平均絶対パーセント誤差

(Mean Absolute Percentage Error, MAPE) もよく使用される指標だが、今回のケースでは実測値に0を含む(ゼロ除算が発生する)ため、MAPEは使用しないこととした。

2) 精度検証結果

推定結果および精度評価指標を表4.7-3、図4.7-4に示す。図はobserved-predicted plotグラフであり、横軸に実測値、縦軸に推定値をとって図示したものである。プロットが図内点線($y=x$)上にあれば、推定値と実測値が等しくなる。したがって、点線近くにプロットされている点が多いほど良い予測が行えていると言える。ところで、時系列データに対してobserved-predicted plotは使わないことが通例だが、本研究では時系列推定したデータが76次元と膨大になるため、observed-predicted plotで示した。

表 4.7-3 推定結果の評価指標

評価指標	値
RMSE[台/h]	216.2
MAE[台/h]	173.6

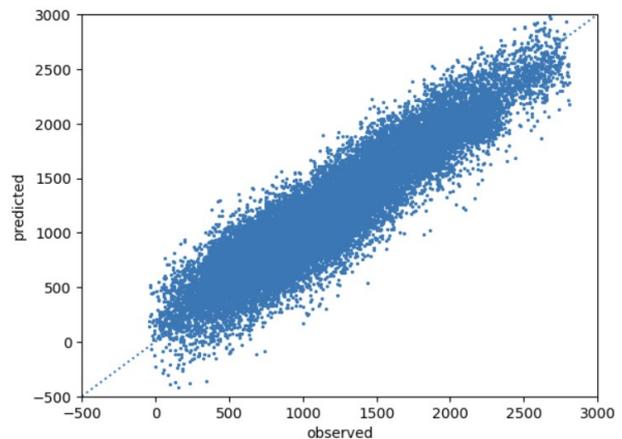


図 4.7-4 Observed-Predicted Plot
(横軸：実測値，縦軸：推定値)

3) 精度検証結果

まず、評価指標について見ると、RMSEが216.2、MAEが173.6とどちらも大きい値をとっていることがわかる。データのスケールを見ると、0~3000台という範囲であり、このスケールのデータで誤差が200台近いというのはかなり大きいといえる。ただし、図からはプロットが対角線上に集まっており、おおよその予測の正確性はあると言える。また、実測値の大小によらずプロットが散らばっており、過大評価・過小評価が同様に発生していることから、誤差がデータの性質によるものではないと考えられ、

モデルの改善が必要だと言える。特に、推定値が負の値をとっている部分があるのは、交通量推定においては問題があるため、改善が必要である。

計算速度については、1500×76リンクの処理に対して、市販の家庭用Note PCを用いて15.6秒で処理が完了しており、非常に高速だといえる。この点については、ESNの学習するパラメータを削減することによる高速性が良く表れており、リアルタイム予測に対して有効なモデルであると考えられる。

(5) 本検討の成果と課題

本研究では、グラフ畳み込み演算とESNを用いたリンク交通量の時系列推定モデルを構築した。構築したモデルについて、ベンチマークデータを用いて検証した結果、精度については課題の残る結果となったが、計算速度については非常に高速であり、リアルタイムの推定に有用であることが示唆された。

大きな課題として、全体的な精度の向上が挙げられる。現状のモデルでは、予測の精度が低く、実用に耐えうるモデルではない。そのため、モデルの構造を変えていくなどして精度を上げていくことが求められる。精度向上のためのモデルの改善案としては、主に次の3つが考えられる

- ① 畳み込み層で出力する特徴量を増やす
- ② 畳み込み層の畳み込み回数を変える
- ③ ESNを別のモデルに変える

①については、特徴量を増やすことでネットワークの空間構造の特徴を正確に捉えられるようになり、精度向上に寄与すると考えられる。

②については、畳み込む回数を増やすことで、考慮できる空間構造をより広げ、精度向上につながる一方、前項4-5-3で述べたように、増やしすぎると逆に空間構造の情報が消失しやすくなるため注意が必要で、畳み込み回数を変えて比較する必要がある。

特に③について、ESNはリザーバーコンピューティング手法のうち、最も基本的なモデルであるため、Deep-ESNやMulti-step ESNなどの様々な発展形が存在する。これらをESNの代わりに使用することで精度向上が期待できる。

参考文献

- [1] 小川 晃平, 福田 大輔: 多変量 LSTM による短期交通量予測: 鎌倉市の観光交通を対象として, 土木学会論文集 D3, 第 76 巻, p. I_1389-I_1398,
- [2] 吉田 幸司, 井上 亮: 道路リンクの接続関係を考慮した畳み込みニューラルネットワークによる自動車交通量の短期予測の検討, 土木学会論文集 D3, 第 75 巻, p. I_1059-I_1067,
- [3] 田中剛平, 中根了昌, 廣瀬明: リザーバーコンピューティング 時系列パターン認識のための高速機械学習の理論とハードウェア, 森北出版, 2021
- [4] H. Jaeger: The “echo state” approach to analyzing and training recurrent neural networks – with an Erratum note, German National Research Center for Information Technology GMD Technical Report, 148(34):13,2001.
- [5] Schlichtkrull, M., Kipf, N. T., Bloem, P. van den Berg, R. Titov, I. and Welling, M.: Modeling relational data with graph convolutional networks, arXiv preprint arXiv: 1703.06103, 2017.
- [6] Zhiqiang Tong, Gouhei Tanaka: Reservoir Computing with Untrained Convolutional Neural Networks for Image Recognition, IEEE Xplore, 2018
- [7] Transportation Networks for Research Core Team.: Transportation Networks for Research. <https://github.com/bstabler/TransportationNetworks>. 02, 28, 2023.

4.8 ガウス過程回帰を活用した時間帯別OD交通量データ生成モデルの構築と検証

(1) はじめに

複数のデータを活用してネットワーク上の交通データを生成する手法を検討する。ここでは、OD交通量に着目して、先述のLSTMを活用した時系列OD交通量データの出力値、センサデータなどを融合した時系列でのOD交通量を生成するモデルを構築する。具体的には、ガウス過程回帰を活用してリンク交通量を入力、OD交通量を出力するサロゲート型生成モデルを検討する。

(2) 既往研究の整理

1) OD交通量推定に関する既往研究

藤田ら¹⁾は、時間変動係数の観測リンク交通量からOD交通量逆推定手法を検討した。特に、観測リンク交通量からの時間変動係数の逆推定モデルを日単位のOD交通量を与件として、時間均衡配分を併用することで残差最小化モデルとして構築し、その最適性条件と解法を示した。また、阿倉ら²⁾はリンク交通量とそれに対応するOD表のデータセットを予め作成し、与えられたリンク交通量に対し、それがどのクラスのOD表により生成されたものか否かを判定する分類器を深層学習により構築した。推定性能評価を行った結果、対象領域全体の50%のリンク交通量が測定可能であれば、80%程度の精度を達成できることを確認した。大谷ら³⁾はガウス過程を用いてモデルを構築し、ETC2.0プローブデータから得られたサンプルデータのリンク交通量から日別OD交通量を従来の配分計算を行わずに逆推定した。誤差評価では二乗平均平方根誤差（以下、RMSE）は406（台/day）となり、比較的少ない計算量で高精度の日別OD交通量推定に成功した。OD交通量推定の分野はリンク交通量推定の分野より比較的緩やかな発展速度である。

2) ガウス過程回帰の概要

大谷らがOD交通量の推定に活用したガウス過程回帰（Gaussian Process Regression）とは、ガウス過程により入力変数 x から出力変数 y に対応する関数 $y = f(x)$ の推定を意味する。関数の推定にはベイズ推定を用いており、関数の分布として推定されるため、推定値の信頼度を表現することが可能である。

ここからは、データに含まれない新たな観測点 x^* に対応する未知の y^* を予測する方法について解説する。パラメータ w を用いる場合であ

れば、パラメータ w を既知のデータで学習し、新たな観測点の値 x^* を代入すればよいが、ガウス過程回帰ではパラメータ w が積分消去されているため、この方法が使えない。そこで、ガウス過程回帰では x^* を用いて共分散行列を更新することで予測計算を行う。以下に更新された共分散行列を示す。

$$\begin{pmatrix} \mathbf{y} \\ \mathbf{y}^* \end{pmatrix} \sim \mathcal{N} \left(\begin{pmatrix} 0 \\ 0 \end{pmatrix}, \begin{pmatrix} \mathbf{K} & \mathbf{k}_* \\ \mathbf{k}_*^T & k_{**} \end{pmatrix} \right)$$

ここで、 \mathbf{K} は学習データ、すなわちすでに観測された x との共分散行列、 \mathbf{k}_* は学習データ x と新たな観測点 x^* との共分散行列、 k_{**} は新たな観測点 x^* 同士の共分散行列を表している。これにより更新された共分散行列を用いて予測計算を行う。

データ $D = \{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$ がわかっているとき x^* における y^* の予測は、 D と x^* が与えられたときの y^* の条件付き確率を求めると同義である。この条件付き確率はガウス分布の要素間の条件付き確率から求めることができる。ガウス分布に従うベクトルが以下の式で与えられたとする。

$$\begin{pmatrix} y_1 \\ y_2 \end{pmatrix} \sim \mathcal{N} \left(\begin{pmatrix} \mu_1 \\ \mu_2 \end{pmatrix}, \begin{pmatrix} \Sigma_{11} & \Sigma_{12} \\ \Sigma_{21} & \Sigma_{22} \end{pmatrix} \right)$$

このとき、観測点 x^* における y^* の予測分布は以下の式となる。

$$p(y^* | x^*, D) = \mathcal{N}(k_*^T \mathbf{K}^{-1} \mathbf{y}, k_{**} - k_*^T \mathbf{K}^{-1} k_*)$$

これは、 y^* の予測分布が期待値と分散がガウス分布に従うことを意味している。

以上より、ガウス過程回帰の予測分布を求めることができた。予測値としてある1つの値を知りたい場合、期待値を計算すればよいが、カーネル行列の逆行列を解く必要があり、かつ新しい予測点が発生するたびに訓練データ全体とのカーネル関数の計算の上で逆行列を解く必要があるため、計算コストは高くなり、中規模～大規模のデータセットの場合は比較的大容量のメモリが必要となる。ガウス過程回帰によって得られる予測分布の例を図4.8-1に示す。なお、入力1次元・出力1次元の場合の予測分布図である。図中の信頼区間とは、ガウス過程回帰で求めた分散のことである。観測点が多い部分では信頼区間が狭く、観測点が少ない場所

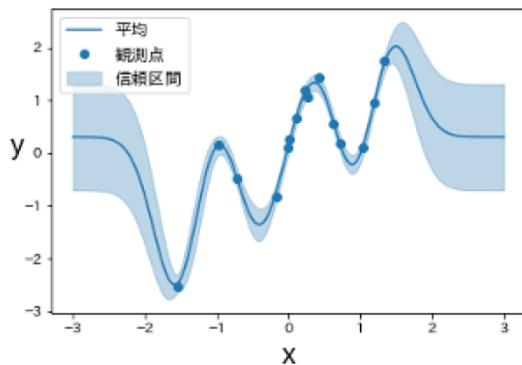


図 4.8-1 ガウス過程回帰による予測分布

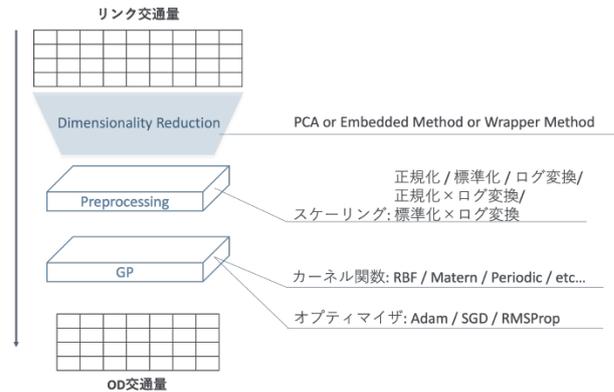


図 4.8-2 提案モデルの構造

では信頼区間が広がっていることが読み取れる。ここまでをまとめると、ガウス過程回帰の特徴は以下となる。

- ノンパラメトリック性
- カーネル法
- 信頼度の表現可能
- 入力 x が似ていれば y も似る
- 高い計算コスト

ノンパラメトリック法とは母集団に一切の分布を仮定しない場合の統計解析手法を指す。ちなみに、パラメトリック法とはノンパラメトリック法の逆で母集団の分布が何らかのある分布に従っていると仮定し、その母数に対して統計的推測を行う手法である。

(3) 時系列OD交通量生成モデルの構築

1) モデルの全体構造

本節よりガウス過程回帰を GPR と記す。本研究における GPR モデルの構造は図 4.8-2 に示すとおりである。

入力データはリンク交通量、出力データは OD 交通量である。それぞれ、列方向にリンク id や OD ペア、行方向に時刻を設定した。つまり、それぞれのデータの一つの要素は「とある時刻のリンク交通量」もしくは「とある時刻の OD 交通量」となる。リンク交通量を入力値として受け取った後、PCA（主成分分析）や特徴量選択手法の Embedded Method や Wrapper Method などを用いて次元削減を行う。その後特徴量スケールリング（変換）として、正規化や標準化、ログ変換などを施す。そのスケールリングされた特徴量を用いて GPR を行う。GPR 内では RBF や Matern, Periodic などのカーネル関数を経て、OD 交通量を出力する。なお、エポック数は全てのモデルで 300 に設定した。入力データには以下の 2 種類を用意した。

- ETC2.0 プローブリンク交通量
- ETC2.0 プローブ×JARTIC リンク交通量

後者は ETC2.0 プローブデータで学習したモデルに対して、JARTIC リンク交通量を入力データに用いて再度学習させ、モデル全体の推定精度を目的としている。いわゆる転移学習的なアプローチでモデルをアップデートする。本研究では、OD 交通量の出力を最適化するために、カーネル関数選択や特徴量エンジニアリングなどの組み合わせを複数個作成し、それらの出力精度や推論時間で比較する。具体的な組み合わせは以下の図 4.8-3 の通りである。モデルとハイパーパラメータの組み合わせは計 360 通りである。よってこの 360 通りの中から最も高精度で推定可能な GPR モデルを探索していく。



図 4.8-3 モデル探索における組み合わせ要素

2) モデルアーキテクチャの概要

Multi-task GPR

Multi-task GPR とは、Simple GPR モデルの特徴に加えて、出力の類似性を同時に学習する。これは同じ入力を共有する複数の関数に対して回帰を実行する場合、特に関数に類似点がある場合に有効である。本研究においては次元削減後の入力データを一括で入力し、一括で出力を行う。

具体的な流れを図 4.8-4 に従って説明する。Simple GPR と同様にデータを準備する。次に入力データに PCA を用いて次元削減を行い、スケールリングを施す。ここで前処理が完了済みの入力データおよび出力データを 4 分割し、学習

データと検証データに分割する。分割された入力データと出力データを用いて、学習および検証（テスト）を行う。本研究ではクロスバリデーションを採用するためここまでの手順を分割数分、すなわち4回繰り返すことで、OD交通量が生成される。

その上で、この手順をスケールリング、モデル内のカーネル関数やオプティマイザごとに全計90通りのモデルの学習および検証(テスト)を繰り返し行う。Simple GPR との大きな違いはOD交通量を一括でモデルに代入できる点である。さらに出力の類似性を同時に学習することで、Simple GPR より高精度の結果になることが期待される。JARTIC データを用いて転移学習的アプローチをする際は、PCA でETC2.0プロンプを用いる時とデータの形状を揃えるように次元削減を行う。

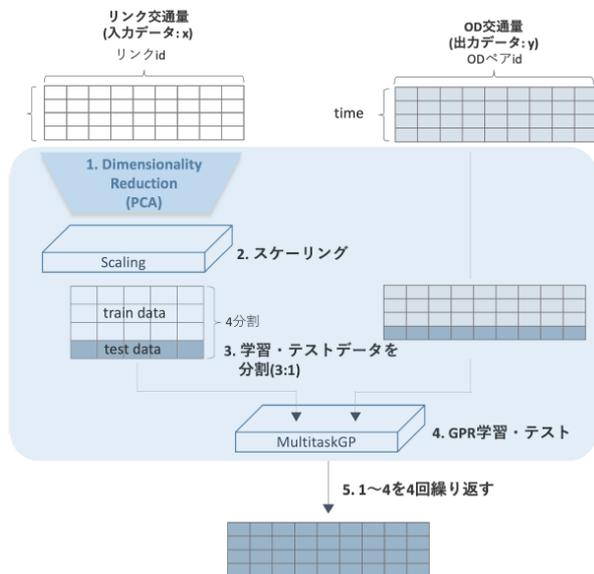


図4. 8-4 Multi-task GPRの構造

Deep Multi-task GPR

Deep Multi-task GPR とは、Multi-task GPR の構造において、Multi-task GP 層を複数層重ねたモデルである。ニューラルネットワークにおいて中間層を複数個持つディープラーニングのガウス過程版と捉えて差し支えない。複数層のモデルを構築することで表現力向上が期待される。具体的な流れは図4. 8-5 より、Multi-task GPR モデルと構造・流れ的に大差なく、Multi-task 層を4層に増大させただけである。

Deep Kernel Learning

Deep Kernel Learning (DKL) はディープラーニングとガウス過程を組み合わせた回帰手法で、ベイズディープラーニングの一つである。

具体的にはガウス過程のカーネル関数の入力にディープニューラルネットワークから出力された特徴量を用いて Deep Kernel を作成する。ガウス過程は無限ユニットを持つニューラルネットワークと等価で、ディープニューラルネットワークの出力層の一つ前の層に無限ユニットを持つ隠れ層が追加されたような構造をDKLは持つ。この構造より、DKLはディープニューラルネットワークのハイパーパラメータとカーネル関数のハイパーパラメータを同時に最適化して学習する特徴を持つ。体的な流れは図4. 8-6のとおりである。

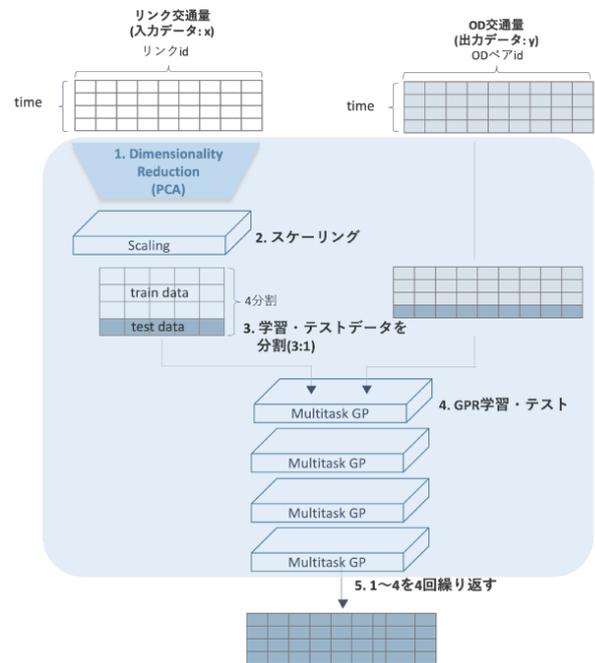


図4. 8-5 Deep Multi-task GPRの構造

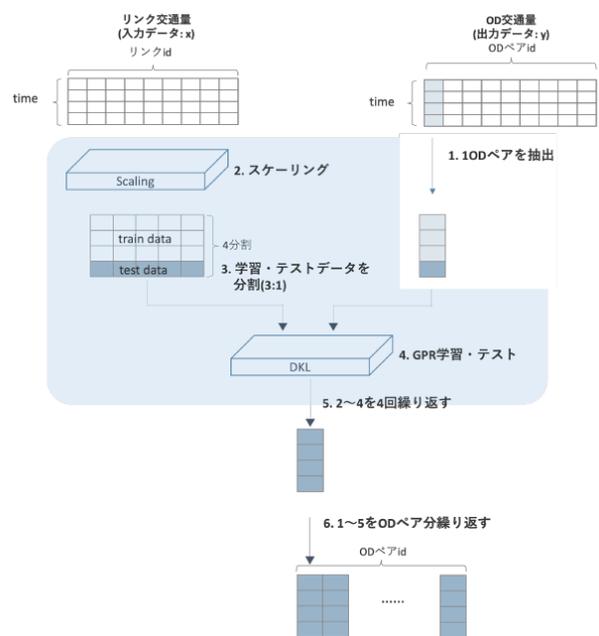


図4. 8-6 Deep Kernel Learningの構造

(4) 提案モデルの性能検証と考察

1) データ概要

本節での入力データには改めて以下の2種類のデータを用いる。

- ETC2.0 プロブリンク交通量
 - ETC2.0 プロブ+JARTIC リンク交通量
- 後者について、ETC2.0 プロブデータを用いてモデル学習させた後、その学習済みモデルを用いて JARTIC リンク交通量を更に学習させる。いわゆる転移学習的なアプローチで、モデルのアップデートを行うことを目的としている。それぞれ、2019年9月4日と9月6日の7:00~22:00 台の間での観測リンク交通量を用いる。

出力データ、すなわち教師データには道路交通センサスの2015年版10月8日と11月18日の7:00~22:00 台の間で推計された OD 交通量を用いる。さらにこのデータの中から0台交通量が32の時間帯の名から22未満の列を削除、すなわち、交通量が0台の時間帯を10以上持つ列(OD ペア)は削除している。

ETC2.0 プロブデータは2016年から2019年の9月までのデータしか手元になく、道路交通センサスデータは2020年のデータは手元にはない状況である。さらに ETC2.0 プロブデータは2016年でのデータ量が少ないという側面がある。そこで、データ期間を無理に合わせることはせず、ETC2.0 プロブデータはデータ量の多い2019年のデータを抽出した。これに合わせて JARTIC のデータも抽出した。各々のデータセットの列方向はリンク id や OD ペア、行方向は時刻としている。よって、レコード数は32レコードである。

提案モデルを用いて実際に OD 交通量を推定し、ハイパーパラメータの最適化を行う。試行するモデルとハイパーパラメータの組み合わせは前節に記載している。加えて、入力データも2種類用意しているので、 $4 \times 5 \times 3 \times 6 \times 2 = 720$ 通りのモデルを学習・検証(テスト)する。また、本研究では図4.8-7のようにクロスバリデーションを用い、分割比は3:1に設定した。

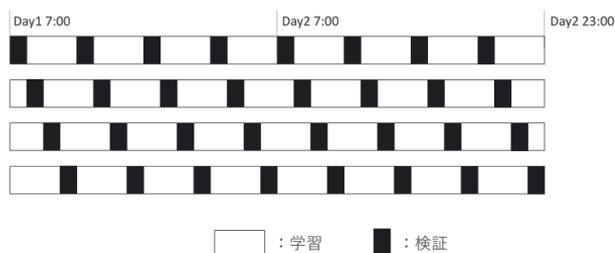


図 4.8-7 クロスバリデーション

2) 性能検証結果

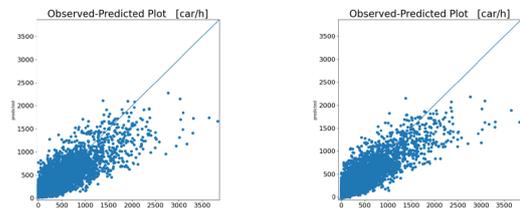
ここでは、紙面の都合上、Deep Multi-task GPR の検証結果を考察する。

ETC2.0 および JARTIC の各データで学習した360モデルのうち、性能が高い上位3つの結果を表4.8-1に示す。また、観測値と予測値をプロットした結果を図4.8-7に示す。

表 4.8-1 Deep Multi-task GPR の検証結果
(上段: ETC2.0 学習結果, 下段: JARTIC 学習結果)

(スケーリング)_(オプティマイザ)_(カーネル)	RMSE[car/h]	MAE[car/h]	R ²	Test time[s]
Norm.Adam_Matern5/2+Periodic	181.1	108.3	0.61	24.13
log.Adam_Matern3/2+Periodic	182.6	106.5	0.60	8.826
std × log.Adam_RBF	182.8	106.8	0.60	4.057

(スケーリング)_(オプティマイザ)_(カーネル)	RMSE[car/h]	MAE[car/h]	R ²	Test time[s]
Norm.RMSProp_Matern5/2	145.7	88.02	0.75	5.068
log.RMSProp_Matern5/2	146.4	89.50	0.75	5.749
Norm × log.RMSProp_Matern3/2	146.5	88.70	0.75	5.136



(a) Norm.RMSProp_Matern5/2 (b) log.RMSProp_Matern5/2
図 4.8-7 上位モデルの観測値と予測値のプロット

結果を見ると、僅かながら過小評価している様子が確認できる。これは GPR 内でのモデルの振る舞いによるものだと考えられる。一般的に、交通量はデータ分布として考えた時比較的ポアソン分布のような分布になりやすく、交通量が多い時間帯よりも、交通量が少ない時間帯の方が多く存在する。また、GPR の特徴の一つとして、「入力が似ていれば出力も似るはず」という特徴より、入力データのリンク交通量がポアソン分布に近い場合、出力値 y すなわち本研究における OD 交通量もデータの小さい値、すなわち OD 交通量が少ないデータを多く出力されることになる。このように出力するモデルを学習を進めていくと小さい値の出力頻度が高くなり、結果として過小評価に繋がると考えられる。本研究ではできる限り交通量データの分布をガウス分布に近づけるために交通量データの使用時間帯も深夜時間帯の除去、ログ変換を行なったが、まだガウス分布とは言い難いかもしれない。ここで本モデルの JARTIC データを使用した場合における検証結果において、もう少し詳しく見てみる。表 4.8-2 より、検証精度上位 10 位までの全ての組み合わせのオプティマイザーが RMS Prop である。全ての

組み合わせで決定係数 R^2 の値は 0.70 以上をマークしている。これは検証精度にはオプティマイザの関連性の大きさを示している。

表 4.8-2 Deep Multi-task GPR の TOP10 モデル

(スケーリング)_(オプティマイザ)_(カーネル)	RMSE[car/h]	R^2
Norm_RMSProp_Matern5/2	145.7	0.75
log_RMSProp_Matern5/2	146.4	0.75
Norm × log_RMSProp_Matern3/2	146.5	0.75
Norm × log_RMSProp_Matern5/2	146.5	0.75
Norm_RMSProp_Matern3/2	147.6	0.74
log_RMSProp_Matern3/2	147.6	0.74
Norm_RMSProp_RBF	148.1	0.74
log_RMSProp_Matern3/2+Periodic	155.3	0.71
Norm_RMSProp_Matern3/2+Periodic	156.0	0.71
Norm × log_RMSProp_Matern5/2+Periodic	157.0	0.71

(5) 本検討の成果と課題

LSTM による時間帯別リンク交通量予測モデルは RMSE[car/h]29.58, 決定係 R^2 は 0.678 という評価精度となり, 改良の余地がありそうだ。特に本研究の流れにおいて, LSTM から出力された値をガウス過程回帰モデルに代入することで時間帯別 OD 交通量を生成するため, ガウス過程回帰の入力値, すなわち LSTM の出力精度が全体の生成精度に対して多かれ少なかれ影響を与えることが考えられる。

ガウス過程回帰モデルによる時間帯別 OD 交通量予測モデルについては, 様々な考察が得られたが今後の生成精度向上に関して, 転移学習的アプローチは有効である場合が多く, 特に Multitask の際に効果を発揮する点が最重要であると考えられる。本研究では ETC2.0 プローブデータと JARTIC データをモデル学習に適用したが, これらのデータの他日時や GAN などの生成系 AI によってデータオーギュメンテーションを行なった上で学習データに適用することで, モデルの精度向上かつ汎用性の向上も期待される。

参考文献

- [1] 藤田素弘, 渡邊健, 山田真士. 観測交通量からの時間変動係数に基づく時間帯別 OD 交通量の逆推定手法の開発. 交通工学論文集, Vol. 2, No. 1, pp. 11-20, 2016.
- [2] 阿倉佑樹, Choochotkaew Sunyanan, 天野辰哉, 山口弘純, 廣森聡仁, 東野輝夫, 西村友佑, 諏訪晃, 長村吉富, 竹嶋進, 峰生. 深層学習によるリンク交通量から OD 交通量の推定手法. 研究報告高度交通システムとスマートコミュニティ (ITS), No. 5, pp. 1-7, 2020.
- [3] 大谷貴俊, 柳沼秀樹, 寺部慎太郎, 田中皓介. 大規模プローブデータとエミュレーション技術を活用した OD 交通量逆推定. 土木計画学研究発表会・講演集, Vol. 64, 12 2021.

4.9 敵対的生成学習を活用したアクティビティデータ生成モデルの構築と検証

(1) はじめに

道路交通分野における最近の施策評価では、多様な施策展開を念頭に高分解能かつ高品質の交通データが求められている。さらに、サービスレベルの質を評価する上で、個人属性を加味したきめの細かい評価分析が重要となる。すなわち、従前のリンク交通量やOD交通量を個人属性別に分析するような実務ニーズが高まっている。しかしながら、このような個人属性を有するデータは、道路交通センサスやパーソントリップ調査のような統計的な代表性を担保した大規模な調査データに限られる。

本研究では、個人属性を有するデータをAIモデルから生成する方法を構築する。具体的には、GAN (Generative Adversarial Network) およびVAE (Variational Autoencoder) を用いて、個人の終日の生活行動 (アクティビティ) を先生する手法を提案し、東京都市圏パーソントリップ調査 (東京PT) への適用をケーススタディとした分析を試みる。これにより、データ収集の効率化と小サンプルでの安定学習を目指す。

(2) 既往研究の整理

1) AIモデルを活用したデータ生成

AI技術を活用したデータ生成に関する研究を整理して、本研究で活用可能な方法を整理する。平湯ら¹⁾は、学習データが不十分とされる医療データに対して、GANを活用したデータ拡張を行なっている。伊藤ら²⁾は、画像の分野においてConditional GAN³⁾ (CGAN) を活用したデータ拡張を行っている。CGANは、カテゴリ固有の特徴を持った画像を生成することができる生成モデルであり、学習時にノイズベクトルだけでなく条件ベクトルも与えることで、条件ベクトルに相当する条件データを生成できるように改良されたモデルである。このように特定のデータを抽出できる技術は東京PTデータの生成においても有用な手法であり、年齢や性別を制約したサンプリングが可能になる。Lei Xuら⁴⁾は、テーブルデータ生成モデルとしてTGANを提案した。生成器にLSTM、識別器にMLPを用いることで従来モデルよりも高精度な生成モデルを開発した。さらに、学習時にGMM (Gaussian Mixture Model) を用いることで、複雑な分布形状を持つカラムに対しても正規化する処理を行っている。しかし、条件付きサンプリングやカテゴリーデータの不均衡

性、GMMのクラスターを5つに固定している点などが問題として挙げられている。同じく、Lei Xuら⁵⁾は、TGANを改良したCTGANを提案した。このモデルは、TVAEで問題とされていた複数の問題を解消したモデルである。生成器の学習時に条件ラベルを加えることで条件付きサンプリングに可能にした点、離散値に対しては各カテゴリーに均等に学習するなどして不均衡性による学習のバイアスを軽減した。さらにVAE (Variational Autoencoder) を用いた生成モデルも提案している。

本研究では、CTGANおよびTVAEを用いて東京PTデータの学習と生成を試みる。以下では、CTGANとTVAEの概要を整理する。

2) GANの概要

画像生成の分野において、膨大な学習データを用いることによって実画像と見分けがつかないような偽画像を生成する敵対的生成ネットワーク (GAN) が注目されている。

図4.9-1に示すようにGANのネットワーク構造は、Generator (生成器) とDiscriminator (識別器) の2つで構成されており、この2つのネットワークを競い合わせることで精度を高めるモデル構造である。生成器は識別器が本物と誤判定するような偽データを生成するようにパラメータを更新し、反対に識別器は本物データか偽物データかを正確に判断できるようにパラメータを更新することによって、生成器が実際に存在しない偽のデータを生成することが可能になる。生成器がデータセットと同様の確率分布を上手く再現し、その分布に従ってサンプリングすることでデータを生成している。

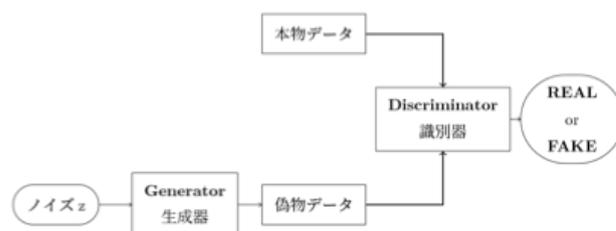


図4.9-1 GANのネットワーク構造

また、GANは教師なし学習であるため、従来の深層学習のようにデータラベルを必要としない学習が特徴であるが、ラベリングがないことによって学習が不安定になるため学習を安定させるような工夫が必要である。

3) CTGANの概要

本研究では、GANを用いたテーブルデータ生成手法であるCTGANによって東京PTデータの拡張を行う。そもそもGANは画像データを生

成するために開発された手法であったが、非画像データに対する研究も進んできている。特に医療分野においては、個人情報保護の観点や投与データを十分に確保できないなどの問題点が挙げられており、これらの問題を解決するためにGANによるテーブルデータ生成手法の開発が進んできた^{1),6)-10)}。また、テーブルデータには連続値、離散値、日時、カテゴリ変数など様々なデータが内包されており、どのデータタイプに対しても適応することが求められている。そしてCTGANはそれらの課題を考慮してデータ生成を行うことが可能である。

今回の分析では、データ生成ツールSDV^{11),12)}を用いてCTGANの学習を行った。生成器と識別器のネットワークは両者とも(256, 256)であり、バッチサイズは500、epochs数は300回で学習を行った。

4) TVAEの概要

VAEはKingma¹³⁾らによって提案された生成モデルであり、入力データを低次元の潜在変数に圧縮するEncoderと潜在変数から入力データを復元して出力するDecoderによってモデルが構成される(図4.9-2)。

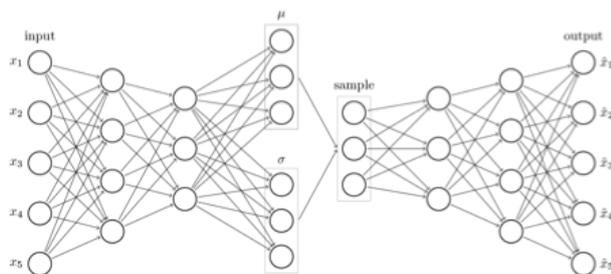


図4.9-2 VAEのネットワーク構造

VAEでは、Encoderにより平均 μ と分散 σ を任意のベクトルに圧縮し、その分布からサンプリングして、Decoderにより拡張することでデータ生成を行う。入力データと生成データの誤差が小さくなるようにVAEを学習させることで、教師データを用いずにデータ生成が可能になる。またVAEは、再パラメータ化トリックを導入することにより、SGDのみで潜在変数付きEncoder-Decoderを実現できている点がVAEの工夫点である。従って、学習時の計算効率性もよく、他のニューラルネットワークと同様の仕組みのSGDのみで学習が可能である。

ここで、VAEのアルゴリズムを説明する。VAEでは確率変数 x と潜在変数 z のデータ生成過程を、確率密度分布のモデルパラメータを用いて $z \sim p(z), x \sim p\theta(x|z)$ のように定める。そして真の事後分布 $p\theta(x|z)$ を近似した分布 $q\phi(z|x)$

を用いて、周辺尤度の下界 $L(\theta, \phi; x)$ が以下のよう

$$\begin{aligned} \log p\theta(x) &= D_{KL}(q\phi(z|x)||p\theta(z|x)) + L(\theta, \phi; x) \\ &\geq L(\theta, \phi; x) \\ &= -D_{KL}(q\phi(z|x)||p\theta(z)) \\ &\quad + E_{q\phi(z|x)}[\log p\theta(x|z)] \end{aligned}$$

訓練では下界 $L(\theta, \phi; x)$ が最大となるようにパラメータを最適化する。ここで、 $q\phi(z|x)$ がエンコーダー、 $p\theta(x|z)$ がデコーダーとなる。

以上を踏まえて、本研究で用いるTVAEの入力データは、CTGANと同様にVGMで正規化された連続量とone-hot化した離散値がモデルのインプットとなる。TVAEの学習もCTGANと同様に、SDVを用いて分析を行った。エンコーダーとデコーダーのネットワークは両者ともに(512, 512)とし、潜在変数の次元は128、バッチサイズは500、epochs数は300回に固定し学習を行った。

(3) AIモデルによる交通行動データ生成

1) 分析データの概要

本研究では、H30東京パーソントリップ調査データ(以下、東京PTデータ)を用いた。東京PTデータは個人の平日1日のトリップデータを収集しており、平成30年の9月から11月に行われた。本研究ではこのデータを用いてデータ生成による精度検証を行う。

データ生成の有効性を検証するために、東京PTデータから交通手段選択モデル用と活動パターン選択モデル用の2つのデータセットを用意した。データセットに使用した特徴量と目的変数は表4.9-1、表4.9-2に示す。

表4.9-1 活動パターンの特徴量と目的変数

特徴量	年齢, 性別, 移動目的, 収入, 職業, 移動時間, 滞在時間, 出発施設, 到着施設, 出発ゾーン, 到着ゾーン, 出発時刻, 到着時刻, 代表交通手段
目的変数	活動パターン (全27選択肢)

表4.9-2 交通手段の特徴量と目的変数

特徴量	年齢, 性別, 移動目的, 収入, 職業, 移動時間, 滞在時間, 出発施設, 到着施設, 出発ゾーン, 到着ゾーン, 出発時刻, 到着時刻, トリップ回数, 各交通手段の移動時間, 各交通手段の費用, 選択肢集合
目的変数	代表交通手段 (全5選択肢)

この2つのデータセットに対してCTGANとTVAEを適用する事でデータを生成し、新たなデータセットを確保することが目的である。また、データ生成をする際にはいくつかの条件が必要であるが、これらはSDV内のモデルを使用すれば様々な制約条件を与えることで表現が可能である。例えば、到着時刻は出発時刻よりも大きいこと、到着時刻と出発時刻の差が移動時間になること、ある閾値よりも小さな値を生成しなければいけないなどデータセット内では複数の条件が考えられる。これらはSDV内で自由に設定することが可能で、本データでは上記のように出発時刻、到着時刻、移動時間の整合が取れるような制約と、移動時間に関しては外れ値を生成させないようにするため、120分以下のトリップを生成するように条件を与えて生成した。

2) 生成データの評価方法

KLダイバージェンスと最尤推定量

生成データの評価は2つの観点から行う。まず1つ目は統計的指標による評価である。具体的には、KLダイバージェンスと最尤推定量を用いる。KLダイバージェンスは2つの確率分布の類似度を測定する尺度であり、0に近いほど2つの分布が類似していると定義される。そして、生成モデルは連続量の分布を複数の正規分布が混合していると仮定しているため、正規分布ではなくGMMによるKLダイバージェンスを計算する必要がある。計算式は以下のように表現される。

$$f(x) = \sum_a \pi_a N(x; \mu_a, \sigma_a)$$

$$g(x) = \sum_b \pi_b N(x; \mu_b, \sigma_b)$$

$$D_{MC}(f||g) = \frac{1}{n} \sum_i \log \left(\frac{f(x_i)}{g(x_i)} \right)$$

2つの正規分布 $f(x)$ 、 $g(x)$ の距離を計算したものが $D_{MC}(f||g)$ となる。まず、混合比 π_a に従って正規分布を1つ選び、選ばれた k 番目の正規分布 $N(\mu_k, \sigma_k)$ から乱数 x_i を1つサンプリングする。そして $f(x_i)$ 、 $g(x_i)$ を計算し、これを N 回繰り返して平均を取ることで求められる。本研究では、連続値のみの評価に用いた。

また、尤度推定量にも同様にGMMを用いて、以下に示す対数尤度関数を計算する。

$$\begin{aligned} \log L(X|\pi, \mu, \Sigma) &= \log \left\{ \prod_{j=1}^N \sum_{k=1}^n \pi_k N(x_j | \mu_k, \Sigma_k) \right\} \\ &= \sum_{j=1}^N \log \left\{ \sum_{k=1}^n \pi_k N(x_j | \mu_k, \Sigma_k) \right\} \end{aligned}$$

ここで μ_k は k 番目の正規分布における平均ベクトル、 Σ_k は k 番目の正規分布における分散共分散行列、 π_k は混合係数である。

KLダイバージェンスと最尤推定量の計算結果を表4.9-4に示す。元のデータセットのうち10000サンプルを抽出し、それらに対して各指標を計算した。また、どちらの指標に関しても各カラムの結果を平均したものが最終的な値となっている。まず、KLダイバージェンスに関しては、どちらのデータセットに関してもCTGANの方が小さくなっており、TVAEよりも各連続量の分布の当てはまりが優れていることが確認された。また尤度に関しては、両データセットでTVAEの方が優れている結果となった。しかし、どちらも僅かな差であるため大きな影響はないと考えられる。

表 4.9-4 KL ダイバージェンスと尤度

	生成モデル	KL	対数尤度
活動パターン	CTGAN	0.879	-49.8
	TVAE	0.909	-47.6
交通手段	CTGAN	0.812	-87.3
	TVAE	0.907	-83.5

ニューラルネットワークによる精度検証

2つ目の評価は、ニューラルネットワークによる精度検証である。具体的な方法は図4.9-3に示す。ニューラルネットワークによる精度検証は3つの方法で行う。以降で述べる精度は全て全く異なるテストデータに対しての精度であり、本物データの中にもテストデータは含まれていない。

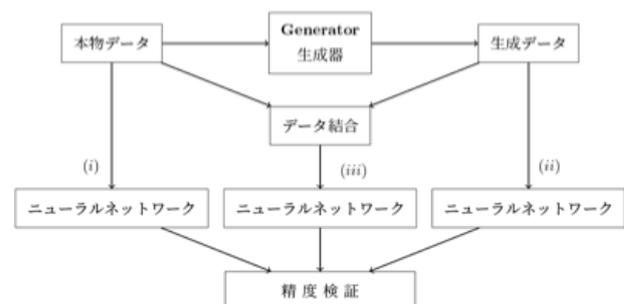


図 4.9-3 ニューラルネットワークによる精度検証

1つ目は、本物データでの検証である。この精度は分析者が確保できているデータ量での精度を示しており、元データでの精度がどれくらいであるのか基準的な指標となる。今回は本物データ数を1000, 5000, 7500, 10000として分析を行った。

2つ目は、生成データでの検証である。この精度は全く異なるデータでどれくらいの精度を示すのかを確認するためのものである。実際に生成されたデータが機械学習に活用できるのかを検証するために計算する。今回は、生成データ数を100, 1000, 10000, 100000として分析を行った。

3つ目は、本物データと生成データの両方を使用した場合の精度である。この精度は実際の分析に近く、本物データに加え、生成データにより学習データを増やした場合にどれだけ精度が向上するのかを検証するための精度になる。検証するデータ数は生成データと同様であり、本物データと生成データを結合し、生成データが増えるにつれ、ランダムサンプリングによる抽出数を100, 1000, 10000, 100000に変更し精度計算を実施した。

(4) 提案手法の精度検証

1) CTGANを活用した生成手法の検証

CTGANで生成したデータの検証結果を図4.9-4と図4.9-5に示す。ベースサンプルは分析者が確保できているデータ数を想定しており、これらの数を変更することでどれくらいのデータ数がデータ生成に有効であるかを検証した。またベースラインはベースサンプルでの精度を示しており、ベースサンプルが増えるほど精度が高くなっている。

活動パターンと交通手段において生成データのみで推定を行った結果である。どのサンプル数においてもベースラインの精度を超えておらず、生成データの質は低い結果となった。

また、生成データと本物データを結合して推定した結果では、少数サンプルでは精度向上が見込めるものの、それ以上のサンプルにおいては同等もしくはそれ以下の精度となっている。上手くデータを生成できていないため、本物データと結合しても精度向上が見込めない結果となった。

2) TVAEを活用した生成手法の検証

TVAEで生成したデータの検証結果を図4.9-6と図4.9-7に示す。CTGANと同様に生成データのみで推定を行った結果である。どのベースサンプルでも生成するデータ数が多くなれば

精度も向上しており、特にベースサンプルが1000個の時には的中率が大幅に向上し、データ生成の有効性が確認された。また、それ以上のデータ数に関しては、1000サンプルほどの精度向上は確認されなかったが、ベースラインの精度を僅かに上回る、もしくは元のデータセットと同等の精度を得ることが確認された。よって、5000サンプル以上では、予測モデルの学習に必要なデータ数は確保できており、データ生成による拡張は精度や汎化性能向上に大きく影響しないことが示唆された。

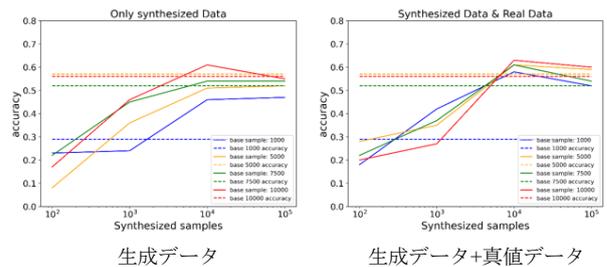


図 4.9-4 CTGAN による活動パターンの生成結果

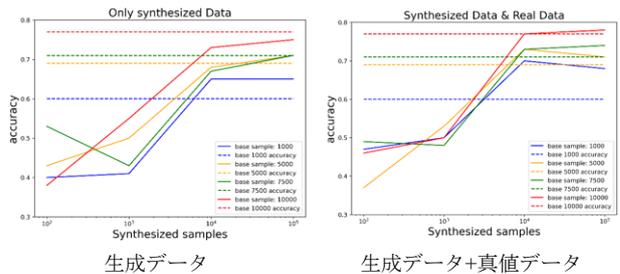


図 4.9-5 CTGAN による交通手段の生成結果

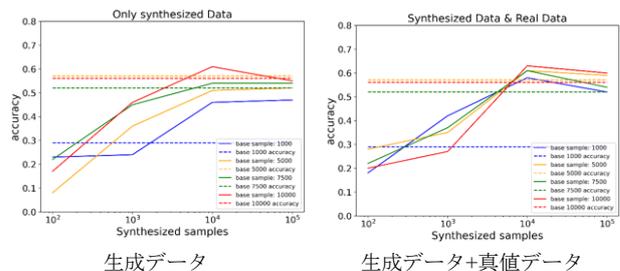


図 4.9-6 TVAE による活動パターンの生成結果

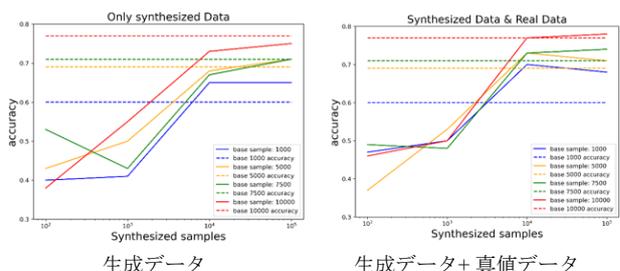


図 4.9-7 TVAE による交通手段の生成結果

生成データと実データを結合して推定した結果では、生成データのみの場合と同様に、1000 サンプルでは精度の大幅な向上が確認され、それ以外のサンプル数に関しては、僅かではあるがベースラインの精度を上回っており、汎化性能向上が確認された。CTGAN に比べ生成データの学習がうまく行っているため、実データと合わせることでより汎用性の高い学習ができていると考えられる。

以上の結果から、PTデータに関してはTVAEの方が優れていることが確認された。本研究において、生成データの評価としては尤度とKLダイバージェンスを適用したが、これらの指標はあくまで元データと生成データの各カラムに対して計算し、それらを平均したものであるため、カラム単体の尤度や分布の類似度しか計算できていない。そのため、テーブルデータ全体の評価はできておらず、今回の指標だけでは生成データセットと本物のデータセットの類似度を判断することは困難であった。生成データ全体の有用性を考慮するためにも、生成されたデータを用いて元データとの精度比較を行った検証方法が有効であり、今回の分析で生成データ全体の有効性を示すことができた。

精度向上を図る際には少数データに対してデータ拡張を行うことは有効であり、それ以上のサンプルになると大きな精度向上は見込めず僅かな汎用性向上にとどまることが確認された。これらを踏まえると、データ生成の使い道は主に2つあると考えられる。まず一つ目は、精度向上のためのデータ拡張である。少数データに対して行ったように、元データが少ない際にはデータを拡張することによって学習データを増やし、汎用性向上に繋げることが可能である。2つ目は、本物と同等のデータを作り出すことで、データの転用が可能であるという点だ。分析の結果、5000サンプル以上のデータに関しては、本物データと遜色のないデータを生成することが確認された。つまり、精度が変わらないほどリアルなデータを生成できるため、プライバシーを考慮したデータ分析や効率的なデータ収集が可能になると考えられる。例えば、本物データではなく生成されたデータを用いることで個人情報の保護、一部のデータを用いてデータ拡張することで、全てのデータを集計する必要がなくなり効率的な集計が期待される。生成されたデータを用いることでモデルの汎用性向上やプライバシー保護に活用できるだろう。

3) 実データと生成データの分布比較

実データとサンプリングしたデータの分布比較を行う。今回は、移動目的、移動時間、滞在時間、出発時刻の4分布の比較を行った。出発時刻は0時からの経過時間(分)に変換しているため連続値となり、4つのうち移動目的だけが離散値となる。結果を図4.9-8に示す。また、実データも生成データもランダムに10000サンプルを抽出している。

移動目的に関しては、分布形状はよく再現されていると確認できる。真の分布とは異なる部分があるものの全体としては当てはまりが良かったため、学習ができていると考えられる。

移動時間に関しては、CTGANとTVAEで大きく異なる結果となった。移動時間はアンケートでの回答上、10分や15分などキリの良い数字を書きやすいため、全体として離散値のような分布となった。しかし、生成データのサンプリング結果を見てみると、前半部分の離散分布は再現できているものの、後半部分に関しては両モデルで連続分布になってしまっている。

滞在時間と出発時刻に関しては、両モデルでわずかな分布のズレは確認できるが、全体としては分布形状を再現できていることがわかる。しかし、モデルごとに比較してみると、滞在時間においては分布の裾部分の再現性でTVAEの方が優れているが、出発時刻では中間部分の分布でCTGANが優れているなど、モデルごとに分布の再現性が異なっていることが確認された。このような差異が生じる原因はブラックボックスであるため正確にはわからないものの、LSTMを用いてテーブルデータのカラムを時系列に捉えることができるCTGANの方が分布形状を再現する上では優位であり、使用しているモデルの影響が大きいと考えられる。

(5) 本検討の成果と課題

本検討では、CTGAN、TVAEを用いてアクティビティデータ生成を行い、生成データの活用可能性を検討した。まず、生成されたデータの質に関してはTVAEの方が優れていることが確認された。KLダイバージェンスと尤度の指標を比較した際、尤度に関してはCTGANの方が優れていたものの、KLダイバージェンスに関してはTVAEの方が優れている結果となった。しかし、これらの指標のみではテーブルデータ全体の良し悪しは確認できないため、生成されたデータを使用し予測モデルを学習させることで生成データが元デー

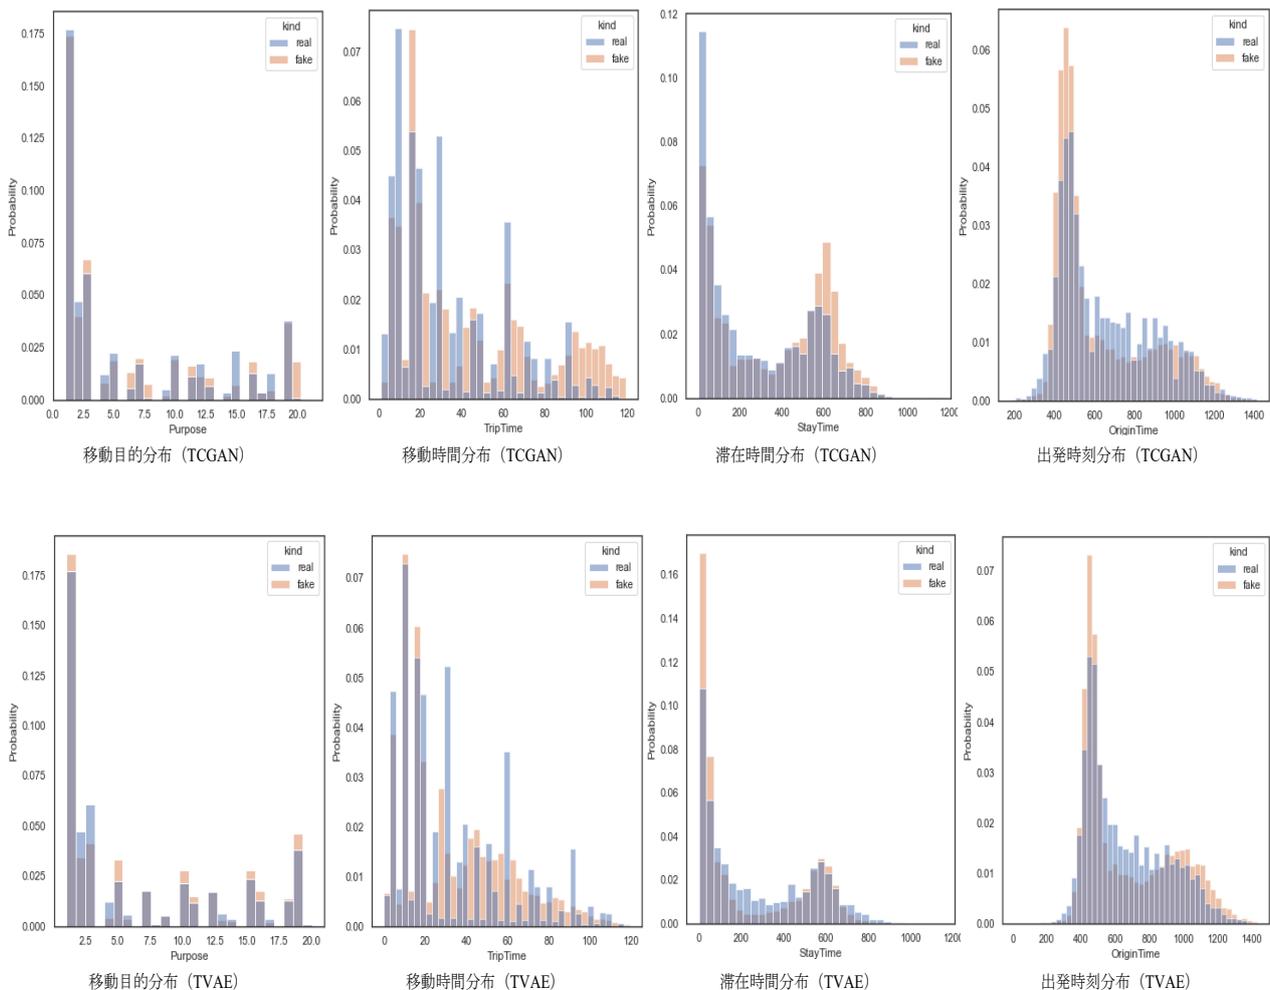


図 4.9-8 生成データの分布

タと同様に機能するかどうかを確認した。その結果、PT データにおいては TVAE によるデータセット拡張の方が有効であるという結果となった。しかし、CTGAN によるデータ生成も TVAE には劣るものの生成サンプルを増やしていけば本物データと同等のデータセットを作成することが可能であり、行動データに対しても生成モデルの適用可能性が示唆された。

課題として、PT データに対してのみ検証を行っている点が問題であると考えられる。本研究では活動パターンと交通手段の 2 つのデータセットを用意し、生成データの機械学習における精度を検証した。しかし、あくまで PT データのみの検証であり、異なるデータセットでの検証は行っていない。そのため、本研究の CTGAN や TVAE はあくまで PT データでの学習になっており、他のデータセットを使用したときには学習結果が異なると予想される。今回の分析では、データセットは 2 種類あるもののあくまで PT データであるため今回のような結果になった可能性も考えられる。今後は異なるデータセットでの生成も行う必要があると考えられる。

参考文献

- [4] 平湯和也, 河野英昭, 折居英章, 辻康弘: GAN を用いた擬似データ生成による血中薬物濃度推定, バイオメディカル・ファジィ・システム学会大会講演論文集 31, pp. 49-52, 2018.
- [5] 伊藤祥文, 丹野良介, 柳井啓司: Conditional GAN を用いた大規模食事画像データからの画像生成, 電子情報通信学会技術研究報告 信学技報, Vol. 117, No. 485, pp. 137-142, 2018.
- [6] Mehdi Mirza and Simon Osindero: Conditional generative adversarial nets, arXiv:1411.1784, 2014.
- [7] Lei Xu and Kalyan Veeramachaneni: Synthesizing tabular data using generative adversarial networks, arXiv:1811.11264, 2018.
- [8] Lei Xu, Maria Skoularidou, Alfredo Cuesta-Infante, Kalyan Veeramachaneni: Modeling tabular data using conditional GAN, Advances in Neural Information Processing Systems, Vol. 32, 2019.
- [9] Gautier Marti. Corrgan: Sampling realistic financial correlation matrices using generative adversarial networks, In ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), pp. 8459-8463, 2020.
- [10] Noseong Park, Mahmoud Mohammadi, Kshitij Gorde,

- Sushil Jajodia, Hongkyu Park, Youngmin Kim: Data synthesis based on generative adversarial networks, arXiv:1806.03384, 2018.
- [11] Edward Choi, Siddharth Biswal, Bradley Malin, Jon Duke, Walter F Stewart, and Jimeng Sun: Generating multi-label discrete patient records using generative adversarial networks, In Machine learning for healthcare conference, pp. 286–305, 2017.
- [12] Akash Srivastava, Lazar Valkov, Chris Russell, Michael U Gutmann, and Charles Sutton. Veegan: Reducing mode collapse in gans using implicit variational learning, Advances in neural information processing systems, Vol. 30, 2017.
- [13] Maayan Frid-Adar, Eyal Klang, Michal Amitai, Jacob Goldberger, and Hayit Greenspan: Synthetic data augmentation using gan for improved liver lesion classification, In 2018 IEEE 15th international symposium on biomedical imaging (ISBI 2018), pp. 289–293, 2018.
- [14] Shaojie Bai, J Zico Kolter, and Vladlen Koltun: An empirical evaluation of generic convolutional and recurrent networks for sequence modeling, arXiv:1803.01271, 2018.
- [15] Neha Patki, Roy Wedge, Kalyan Veeramachaneni: The synthetic data vault. In 2016 IEEE International Conference on Data Science and Advanced Analytics (DSAA), pp. 399-410. IEEE, 2016.
- [16] Diederik P Kingma and Max Welling. Auto-encoding variational bayes, arXiv:1312.6114, 2013.

第5章 まとめと課題

5.1 本研究課題の成果

本年度の成果を下記のとおり取りまとめた。

- テーマ1 (2章) : 研究期間3年間を通じて、国土交通省をはじめとする多くの機関に対して継続的なヒアリング調査を実施することで体系的な実務ニーズの把握を試みた。この結果に基づき、データ取得における課題やシステムに求める要件を明らかにして、本研究が実装するシステムの設計と実装を行った。本研究が実装した次世代交通システムは、クラウド型のWEBシステムとなり、分析対象画像をアップロードするだけで交通計測を実現した。また、プローブデータとの連携を行うことで、固定観測と移動観測を統合した可視化を可能とした。
- テーマ2 (3章) : 実務的な課題となっている環境条件・設置条件・交通条件および歩行者や自転車などの多様な交通モード、詳細な車種、車線別計測に対応した交通計測特化型AIモデルのリリース版を構築した。AIモデルの学習手法として、XAIを活用した戦略的転移学習、アノテーション作業を必要としない地点別自己学習を提案し、汎用性の高いベースモデルと地点特化の地点モデルを可能とした。これにより、モデルのチューニングを地点ごとに学習および精度向上させる仕組みを確立した。本提案により、従前よりも高精度かつ実務ニーズに対応したモデルをリリースすること出来た。さらに、提案手法を活用することで全国での観測体制の確立やAI開発における工数の大幅な圧縮が期待される。
- テーマ3 (4章) : 複数の観測データを融合したマイクロ交通およびマクロ交通データの生成

について、実務ニーズを踏まえた改善を実施した。マイクロ交通データ生成では、カメラ画角の変化に対してロバストなカウントライン自動設定手法、移動体軌跡と航空画像による実空間座標への変換を可能として、移動軌跡や交通量、速度データを精度よくデータ生成を可能となった。マクロ交通データでは、LSTMを活用したリンク交通量とガウス過程回帰を活用したOD交通量の生成モデルを構築した。精度面で課題があるものの、データ観測と生成を一体的に行うフレームワークを確立した。

5.2 実務適用に向けた課題

今後の実務適用や成果活用について、下記の点を留意しながら、引き続きの研究開発を行うことが求められる。

- 開発したシステムを速やかに国土交通省内で活用できるように関係各所との連絡・調整を図る。将来的には、本システムを道路交通センサスでの活用や道路状況の常時モニタリング体制の構築に展開したい。また、道路局のデータプラットフォームであるxROADとの連携が求められる。
- 新たな交通量データに関する品質管理・保証は実務的に重要な課題であり、産官学で議論する場が必要である。現在、交通データV&V研究会の立ち上げを進めており、継続した実務ニーズの把握と研究開発、V&Vの確立を推進したいと考えている。

道路政策の質の向上に資する技術研究開発 成果報告レポート No.2021-2
カメラ画像および複数の観測データを融合した次世代交通計測手法に関する研究開発

2024.5