



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. 30-2

研究テーマ

交通流理論とAI学習による
非日常の発見とアラート発信

研究代表者:	東北大学未来科学技術共同研究センター 教授	桑原 雅夫
共同研究者:	株式会社オリエンタルコンサルタンツ 技術主査	梅田 祥吾
	九州大学 教授	川崎 洋
	明治大学 准教授	横山 大作
	株式会社オリエンタルコンサルタンツ 執行役員 東北支社長	江藤 和昭
	本田技研工業株式会社 技師	飯星 明
	株式会社アイ・トランスポート・ラボ 代表取締役	堀口 良太
	一般財団法人日本気象協会 統括主幹	丹治 和博
	アジア航測株式会社先端技術研究所	浦山 利博
	株式会社富士通交通・道路データサービス	稲垣 宏
	愛媛大学 教授	吉井 稔雄

令和3年6月
新道路技術会議

目次

研究概要	1
第1章 はじめに	3
1. 1 研究の背景・目的.....	3
1. 2 研究の概要	3
1. 3 研究体制.....	4
1. 4 本報告書の構成	4
第2章 非日常の発見手法の構築	5
2. 1 データ収集・整理.....	5
2. 2 プローブ車両データを用いた非日常の発見手法の構築	5
2. 3 ドラレコ画像を用いた非日常発見手法の構築	13
2. 4 実規模ネットワークにおける交通状態推定手法の構築	25
第3章 非日常の事前アラート発信手法の構築	30
3. 1 降雪による車両スタック発生事前アラート条件の検討	31
3. 2 状態空間モデルを用いたスタック発生危険性のアラート手法の構築	37
3. 3 土砂災害危険性の事前アラート手法構築	45
第4章 リアルタイム可視化システム開発および実証実験.....	47
4. 1 リアルタイム可視化システム開発.....	47
4. 2 道路管理者に対する実証実験.....	49
4. 3 まとめと今後の課題	50
第5章 まとめ.....	52
5. 1 研究の総括	52
5. 2 今後の展望	52

第1章 はじめに

1.1 研究の背景と目的

本研究は、共同研究体DOMINGOを中心に実施している。DOMINGOは、東日本大震災直後に東北大学を中心に立ち上げた産学共同の研究体であり、災害時のモビリティ支援に関する研究開発を実施してきた。これまでにプローブ、気象、Twitter、スマホ画像データをリアルタイムに可視化するシステムを構築し、熊本地震や本年の豪雨時に、情報発信するとともに、東北地方整備局、千葉国道事務所、NEXCO東日本などに試行していただき、実務に使えるシステムの構築に努めてきた。

本研究は、このシステムを交通流理論とAI学習を用いて高度化し、災害時の道路損傷、冠水、積雪、Gridlockといった非日常を早期に発見することを目的としている。通行障害を事前にアラートするシステムは、災害時の安全で迅速な避難支援、通行規制や情報提供、道路復旧や、イベント時の交通マネジメントなどに貢献するものである。

この研究開発では次のような課題があり、本研究では、これら課題を交通流理論とAI学習を援用して解決を図る。

1. 非日常の発見には、利用者の日常の移動行動をAI学習しながら、プローブだけでなくドラレコ（ドライブレコーダー）画像等を自動解析して、質が異なるデータを融合させることが必要である。
2. 非日常の事前アラートには、渋滞、降雨、降雪、浸水、地形などの観測可能な周辺環境（素因・誘因）と非日常発生との関連性を把握することが重要で、過去の災害や観光地、イベントデータを数多く収集した分析が必要である。
3. リアルタイムに可視化するシステムについては、より操作性が高く必要な情報を迅速に届けられる速達性に優れた改善が必要である。

1.2 研究の概要

本研究は、交通流理論とAI学習を用いて、移動体データと気象・地形データ等を融合解析し、リアルタイムに非日常の「発見」と「事前アラート発信」を行う手法を開発するものである。AI学習は、大量のプローブデータ、気象データなどを学習して、現象の規則性や潜在的なパターンを見つけ出す有用な手法であり、これに交通工学の知見を援用することにより、従来は見つけ出せなかった非日常の早期発見や予知を行える可能性を探る。

対象とする非日常は、災害時の道路損傷、豪雪時の車両スタック、冠水等を中心として、その発見と事前アラートについて研究開発を行う。

非日常の発見と事前アラートに関する個別の開発技術はリアルタイム可視化システムに組み込み、インターネット経由で管理者にリアルタイムに情報を提供できる仕組みを構築する。

本研究の概要を以下に示す。本研究は、大きく3つのパートに分けて実施する。

1. 非日常の発見

交通流理論と、プローブやドラレコ画像、気象、地形データをAI学習して、非日常（渋滞、事故、道路損傷、冠水、大雪、落下物など）を発見するとともに、面的に広がる道路網全体の交通状況モニタリングを行う手法を開発する。

2. 非日常の事前アラート発信（大雪による通行障害、土砂災害）

災害発生時のデータを用いてAI学習を行い、非日常発生と素因（地形、道路網等の静的要因）と誘因（津波、降雨、降雪、混雑等の動的要因）の関係から異常事象の発生危険性を事前に予測しアラート発信する方法を分析する。

3. リアルタイム可視化システム開発および実証実験

DOMINGOで開発しているリアルタイム可視化システムに、上記の非日常の発見と事前アラート発信機能、要素を組み込んだシステムを構築する。また、道路管理者への試用実験を実施し、操作性が高く必要な情報を迅速に届けられる速達性に優れた実務に利用できるシステム開発を行う。

1.3 研究体制

研究全体を「①非日常の発見」、「②非日常の事前アラート」、「③リアルタイム可視化システム」という3つのタスクに分け、交通、気象、画像処理、計算技術、地理情報およびプローブデータ収集組織という幅広い専門家を、各タスクに配置した。

1.4 本報告書の構成

本報告書は、5章から構成されている。第1章では、本研究の背景と目的、研究の概要を示す。第2章は、非日常の発見手法として、プローブ車両データを中心とした路面、交通の状況検出に資する車両センサーデータ解析手法について整理し、その有効

性について示す．具体的には、「非日常の発見手法」に関する技術開発として、Uターン、方向変更、速度変化等の特異な車両挙動に基づいて、局所的な非日常を抽出する方法と、エリア内の交通流の変化から広域的な非日常を発見する手法について、その手法と精度検証結果について示す．またドラレコ画像を活用した冠水、落下物、事故等の検出手法とその発見制度について整理する．第3章では、「非日常の事前アラート手法として、降雪による車両スタックについて、全国適用を狙ったアラート手法

と、局所的なスタック危険性をアラートする手法とその検証結果を整理する．また、広範囲の土砂災害危険個所を抽出するアルゴリズムを提案する．第4章では、第2章、3章で構築した個別開発技術を組み込むための「リアルタイム可視化システム」の構築結果、個別要素技術の組み込み結果についてについて整理する．最後に第5章では、研究の成果を総括し、今後の展望について述べる．

第2章 非日常の発見手法の構築

2.1 データ収集・整理

非日常の発見，アラート発信を行うためには，平常時及び災害発生時の交通，気象，地形，通行障害に関するデータをセットで収集する必要がある．そこで，本研究課題の遂行にあたりプローブデータ，気象データ，地形データ，通行障害データ等の多様なデータの収集を行った．具体的には，本研究期間中に発生した災害事例の中から表 2.1-1 に示す災害事例を対象に可能な範囲で平常期間も含めた交通関連のデータ(乗用車プローブ，商用車プローブ，車両感知器，ドラレコ画像等)，気象関連のデータ(降雨量，降雪量，積雪深，気温等)，通行障害・災害・地形関連のデータ(JARTIC 規制情報，VICS データ，DRM，流木発生量 GIS 等)を収集した．

表 2.1-1 データ収集対象とした災害事例

災害事象名	発災期間	被災エリア
平成 29 年 7 月九州北部豪雨	2017/7/5~6	福岡県、大分県
平成 29 年愛知豪雨	2017/7/14	愛知県
平成 29 年秋田豪雨	2017/7/22~23	秋田県
平成 29 年台風 22 号	2017/10/29	千葉県
平成 30 年 7 月豪雨	2018/6/28~7/9	西日本全域
平成 30 年台風 21 号	2018/9/4~5	愛知県，三重県等
平成 30 年台風 24 号	2018/9/30~10/1	滋賀県，京都府等
平成 30 年台風 25 号	2018/10/5~7	宮城県，沖縄県等
令和元年 8 月九州北部豪雨	2019/8/27~8/30	九州北部
平成 30 年 1 月首都高速道路立ち往生	2018/1/22~23	東京都
平成 30 年 2 月福井県国道 8 号立ち往生	2018/2/6~9	福井県
平成 31 年 1 月山形県国道 47 号立ち往生	2019/1/25	山形県
平成 30 年・平成 31 年東北地整管内立ち往生	2018・2019	東北地方
月山道路スタック事象	2019	月山道路
平成 28 年熊本地震	2016/4/14	熊本県
平成 30 年大阪北部地震	2018/6/18	大阪府
平成 30 年北海道胆振東部地震	2018/9/6/	北海道

2.2 プローブ車両データを用いた非日常の発見手法の構築

(1) プローブ車両データを用いた大規模災害時の局所的な異常事象抽出手法

本研究項目は，地震などの大規模災害時に同時多発的に発生する局所的な交通障害発生箇所を，プローブ軌跡データから自動で検出することを目的とする．現状の大規模災害時の交通障害の把握方法は監視範囲・時間が限定されるという課題がある．そこで，24 時間，広範囲のデータの収集が可能なプローブ車両データを用いてリアルタイムに道路ネットワーク上の交通障害発生箇所を検出する手法を提案する．2016 年 4 月に発生した熊本地震時の通行規制箇所を対象に，提案手法の精度および適用範囲について検証する．

a) 既往研究について

災害時の交通実態把握と交通障害検出という 2 つの視点で既往研究を整理する．

・災害時の交通実態把握

Zhu et al.¹⁾は，車両感知器，バス利用者統計及びアンケート調査を用いて I-35W 橋崩壊後の交通パターンの変化を分析している．分析の結果，I-35W 橋付近の高速道路の交通パターンには一時的な変化が生じたが，崩壊後の交通需要はそれほど変化しなかったことを示した．しかし，車両感知器の観測箇所は限定的であり，道路ネットワーク全体の交通実態は把握できない．また，アンケート調査は，被験者の想起に基づいているため必ずしも結果が正しいとは限らず，調査に時間を要するため多くのサンプルを入手することが困難である．

一方，携帯電話やカーナビから収集されるプローブ軌跡データは，道路ネットワーク全体のトリップの経路や速度を詳細に把握することができる．プローブ軌跡データを用いた研究には，Bengtsson et al.²⁾，Lu et al.³⁾，Hara and Kuwahara⁴⁾，Kawasaki et al.⁵⁾等がある．Kawasaki et al.は，2016 年 4 月の熊本地震での都市内交通と避難行動の実態を，プローブ軌跡データを使って分析している．具体的には，九州自動車道の通行止めの影響を受け，福岡方面から熊本中心部への代替経路の日中の旅行時間が平常時に比べて大きく増加したこと，避難所やスーパー，銭湯などが新たな発集点となり，平常時とは違った交通渋滞を引き起こしていたことなどを，プローブ軌跡データを用いて定量的に明らかにしている．

以上の研究のように、災害時の交通実態把握のためにプローブ軌跡データを用いた研究は数多く存在する。これは、プローブ軌跡データによって災害時でも広範囲に渡る車両挙動の把握が可能であるためであり、本研究で災害時の交通障害検出をプローブ軌跡データから行うことは有効な手段と考えられる。

・災害時の交通障害検出

Cullip and Hall⁶⁾、Kawasaki et al.⁷⁾等は、車両感知器による交通量やオキュパンシー、もしくは車線別の速度差等の統計量について、平常時と交通障害発生時での差異を分析し、平常と異常を判別する閾値を設定している。そして、新たに得られた車両感知器データを閾値によって平常か異常か判別することで交通障害検出を試みている。プローブ軌跡データを用いた交通障害検出の研究は関塚ら⁸⁾、Asakura et al.⁹⁾等がある。これらの研究では、交通障害発生時の二次元（時間×走行距離）上の車両軌跡の変曲点間をつないだ衝撃波面に着目し、交通障害発生の時間と場所を推定している。

ここで取り上げてきた研究は全て高速道路を対象に行っており、車両感知器の設置やアクセスコントロールが適用条件となっているため、この手法を一般道を含めた道路ネットワークにそのまま適用することはできない。また、時間×走行距離の二次元プローブ軌跡データを評価しており、災害時の一般道上での道路損傷箇所付近での徐行や停止、もしくは損傷箇所の迂回のような車両挙動は把握できないといった課題も有している。

本研究と同様に、一般道を対象とした研究にはCai et al.¹⁰⁾がある。この研究では、交通障害発生時に一般道交差点の進入区間で生じるふらつきや車線逸脱を“異常挙動”と定義し、プローブ軌跡データのみで異常挙動を検出することを試みている。しかし、得られた軌跡全体を統計処理しているため、道路ネットワーク全体のプローブデータを処理する際には計算負荷が膨大になる。また、仮に異常挙動のクラスタに分類されたとしても、災害時の特殊な車両挙動に沿ったクラスタに分類されているかは判断できない。

既存研究の課題を踏まえ、本研究では、プローブ車両データを用いて一般道を含む道路ネットワーク全体から交通障害を早期に自動検出することを試みる。具体的には、道路ネットワーク上の車両が交通障害を発見した際にとると考えられるUターン、方向転換、減速行動に着目し、それらの行動を表現できるモデルを構築する。また、検出の迅速性を確保するため、プローブ軌跡データのマップマッチングが必要ない手法を提案する。

b)提案手法

提案手法のコンセプト、手法のイメージ計算手順等について整理する。

・災害時の車両の挙動の仮説

地震等の災害によって、道路が損傷することで通行障害が発生した箇所は、平常時に見られない車両挙動(異常な車両挙動)が出現し続ける。もしくは、車

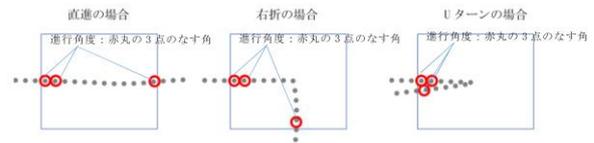


図 2.2-1 メッシュ内のプローブ車両軌跡イメージと進行角度のイメージ

両の通行がなくなると考えられる。ここで、異常な車両挙動とは、通常時に発生確率が低い速度低下、Uターン、経路変更の変更などを想定する。

通行障害箇所が発生していない箇所においても、地震発生直後は、ドライバーが周囲の状況確認や安全確保のために異常な車両挙動が頻発するが、時間の経過と共に通常の車両挙動を取る車両が増加すると考えられる。

前述した災害時の通行障害箇所と非通行障害箇所の車両挙動の特性を踏まえて、災害直後は、異常の可能性が高い箇所が頻出するが、徐々に本当に道路に異常が発生している箇所(通行不能箇所や道路損傷箇所)だけが残っていくような枠組みを構築する。(車両が通過する度に異常度を更新する)。

本手法は、リアルタイムでの計算を想定しているため、計算付加が高いマップマッチング処理やノンパラメトリックな手法は選択せずに、出来るだけ少ない点群データを用いたパラメトリックな手法を構築する。

・計算手順

STEP0：データの準備

・地域メッシュ単位で、プローブ車両データを抽出し、異常が含まれていないか、含まれていたとしてもごく少数と思われるデータセット(平常時)を用意する。

STEP1：特徴量抽出

・メッシュを通過する車両の特徴量は、異常な車両挙動(速度低下、Uターン、経路変更)を判別するためメッシュ内の通過速度と進行角度の2変数とした。通過速度は車両がメッシュ内を通過する空間平均速度とし、進行角度は図 2.2-1 に示すように車両別のメッシュ内の進行角度は、メッシュ内に侵入した最初の点と2点目を結ぶベクトル、2点目とメッシュ内の最後の点を結ぶベクトルのなす角としている。

・以降はあるメッシュに着目して整理する。

STEP2：分布推定

・通過速度 v_j と進行角度 θ_j の確率分布が正規分布で近似できると仮定し、2次元正規分布の未知パラメータである平均値 μ と分散共分散行列 Σ を計算する。

$$x_j = \begin{bmatrix} v_j \\ \theta_j \end{bmatrix} \tag{2.2-1}$$

x_j ：車両 j の特徴量ベクトル
 v_j ：車両 j のメッシュ通過速度
 θ_j ：車両 j の進行角度

STEP3：異常度の計算

- ・あらたな観測データ x_j' がどれだけ標本平均 $\hat{\mu}$ から離れているかを評価するため、マハラノビス距離の2乗を異常度 a と定義する。

$$a(x_j') = (x_j' - \hat{\mu})^T \hat{\Sigma}^{-1} (x_j' - \hat{\mu}) \quad (2.2-2)$$

- ・平常時のメッシュ内の通過速度と進行角度の2次元の分布を推定し、災害後の車両の特徴量の出現確率から異常度を計算する。

STEP4：閾値の設定

- ・異常度の閾値を設定し、異常度 a が閾値を超えた場合に異常を判定する。本研究では、平常時データを対象に算出した異常度の99%タイル値を閾値として設定する。

c)実データによる提案手法の適用検証

提案手法を実災害時のデータに適用し、手法の精度および適用範囲について整理する。地震発生前後のプローブ車両データ、地震発生後の通行障害データを入手することができた熊本地震を対象に提案手法の精度等の検証を行う。

・使用データ

本研究では HONDA 技研工業株式会社が管理するプローブ車両データを用いて分析を行う。分析には、以下の期間の5次メッシュ(250m四方)のプローブデータを用いた。データの期間は災害発生後5日間(4月14日～4月18日)、災害発生前5日間(4月07日0:00～4月11日)の計10日間とする。

・分析対象

分析対象は、九州河川国道および熊本県、熊本市内の通行規制実施状況(204件)のうち、データを保持している期間内に通行規制が行われた箇所かつ平常時にプローブ車両が通行している130箇所とする。

・検証方法

提案手法を分析対象の含むメッシュ(250m四方)のデータに適用し、地震発生後の異常事象検出状況について検証を行う。検証は異常の検知の可否、地震発生後から異常を検知するまでの時間とする。

なお、最初の地震(2016年4月14日21時26分)発生から、通行規制開始時間までに異常度が閾値を超えた場合に、手法により異常を検知できたとして判定する。また、各変数の有効性を確認するため、進行角度と速度の両方を使った場合、速度のみを使った場合、角度のみを使った場合の3ケースで検証を行う。

・検証結果

提案手法による異常事象の検知可否および検知時間の結果を示す。ただし、以降の検証(検知可否・検知時間)はあくまでも最初に発生した地震からの経過時間(分)、最初に発生した地震から規制時間までの検知可否であることに留意が必要である。

表 2.2-1 は、検証対象箇所に対して、提案手法を適用し、変数別にその検知が出来た数と精度を示し

表 2.2-1 提案手法の変数別の検知精度

	使用変数		
	角度	速度	速度・角度
検知数	67	65	66
精度(検知数/検知対象)	52%	50%	51%

表 2.2-2 提案手法の検知時間(分)の一覧

	使用変数		
	角度	速度	速度・角度
検知時間(分)			
最小値	16	1	1
25パーセンタイル値	115	146	135
中央値	621	570	486
平均値	712	715	709
75パーセンタイル値	929	1174	760
最大値	3711	3809	5206

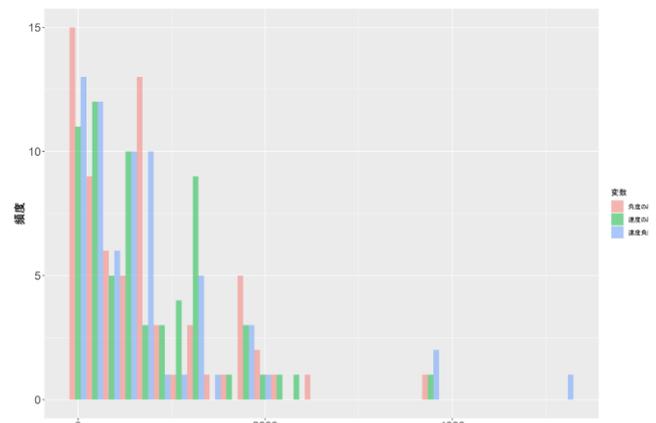


図 2.2-2 使用変数別の異常検知時間(分)の頻度分布

たものである。検知数は角度のみを用いた場合、67箇所、速度のみを用いた場合、65箇所、速度と角度の両方を用いた場合で66箇所となり、いずれも50%程度で同程度の検知精度である。

表 2.2-2 は、使用変数別の検知時間の最小値、25パーセンタイル値、中央値、平均値、75パーセンタイル値、最大値を示したものである。平均値、中央値に着目すると速度と角度の両方の変数を用いた場合が最も検知までの時間が早い結果である。図 2.2-2 は、使用変数別の検知時間の頻度分布を示したものである。いずれの変数においても、地震発生直後の検知頻度が最も高くなっている。

最初の地震発生時から通行規制開始時間の前に異常を検知できた事例および異常を検知できなかった事例の通行障害状況、異常度の時系列変化(使用変数事3ケース)の箇所別の評価を行った結果、規制時間発生前に異常を検知できているケースは、道路陥没や段差等いずれも車両の速度や角度に変化が現れると考えられる異常事象であり、検知できない異常事象は、異常の発生から即座に通行規制がなされた事例や落石や火災等、道路そのもの損傷ではなく、車両が挙動を変えない可能性がある事象であることが分かった。

d)まとめ

本項では、Uターンや速度低下といった異常事象

発生時に行われると想定される車両挙動から局所的な異常事象を抽出する方法を提案し、手法の適用範囲や精度の検証を行った。

具体的には、通行障害発生箇所と非通行障害箇所の車両挙動の特性(速度低下, Uターン, 経路変更)を踏まえて、250m メッシュ単位で、プローブ車両の特徴量(通過速度と進行角度)を学習し、平常時の特徴量との乖離程度から災害発生時の通行車両の異常度を算出する方法で、局所的な異常事象の発生箇所の抽出を試みた。

・手法の精度について

提案手法を熊本地震発生時の通行規制区間(130箇所)に適用した結果、提案手法により約半数の通行障害を検知することが出来た。

また、変数として速度と角度の両方を用いた場合、速度のみを使用した場合、角度のみを使用した場合の3ケースについて比較検証を行った結果、検知精度としては3ケース間で大きな違いはなかったが、検知までの時間は速度と角度の両方を用いた場合が最も早い結果となった。検知の可否は、特徴量の違いよりも対象箇所にプローブ車両が出現するか否かに依存しているため、検知精度に大きな差が表れなかったと考えられる。ただし、速度と角度の両方の変数を使用した場合、少ないプローブ車両であってもその変化、特徴を加味できたことで、検知時間が最も早くなったと考えられる。

・手法適用範囲について

検知できなかった事象は、落石や沿道家屋の火災といった道路そのものの損傷ではないため、車両挙動に大きな影響を与えないような事象は、当該手法では検知しにくいということが分かった。また、異常事象発生から通報などにより即座に情報が伝達し、迅速に規制が行われた事例は、それよりも前に検知できる可能性は低いことを明らかにした。

2.2.1 の参考文献

- 1) Zhu, S., Levinson, D., Liu, H. X. and Harder, K. : The traffic and behavioral effects of the I-35W Mississippi River bridge collapse, *Transportation Research Part A: Policy and Practice*, Vol. 44, Issue 10, pp. 771-784, 2010.
- 2) Bengtsson, L., Lu, X., Thorson, A., Garfield, R. and von Schreeb, J. : Improved response to disasters and outbreaks by tracking population movements with mobile phone network data: a post-earthquake geospatial study in Haiti, *PLoS Med.*, Vol. 8, No. 8, p. e1001083, 2011.
- 3) Lu, X., Bengtsson, L. and Holme, P. : Predictability of population displacement after the 2010 Haiti earthquake, *Proc. Natl. Acad. Sci. USA*, Vol. 109, No. 29, pp. 11576-11581, 2012.
- 4) Hara, Y. and Kuwahara, M. : Traffic monitoring immediately after a major natural disaster as revealed by probe data - A case in Ishinomaki after the Great East Japan Earthquake, *Transportation Research Part A: Policy and Practice*, Vol. 75, pp. 1-15, 2015.
- 5) Kawasaki, Y., Kuwahara, M., Hara, Y., Mitani, T., Takenouchi, A., Iryo, T. and Urata, J. : Investigation of traffic and evacuation aspects at Kumamoto earthquake and the future issues, *Journal of Disaster Research*,

Vol. 12, No. 2, 2017.

- 6) Cullip, M. and Hall, F. : Incident detection on an arterial roadway, *Transportation Research Record: Journal of the Transportation Research Board*, Vol. 1603, pp. 112-118, 1997.
- 7) Kawasaki, Y., Tanaka, A., Goto, H., Takada, J., Warita, H., Hong, S., Tanaka, S. and Kuwahara, M. : Research on mechanisms to provide attention-attracting information effective in preventing rear-end collisions, *18th ITS World Congress*, 2011.
- 8) 関塚貴一, 三谷卓摩, 川崎洋輔, 益田卓朗, 永井慎一, 桑原雅夫: 車両軌跡のみを用いた突発事象発生時の旅行時間予測, 土木計画学研究・講演集, Vol. 53, CD-ROM, 2016.
- 9) Asakura, Y., Kusakabe, T., Nguyen, L. X. and Ushiki, T. : Incident detection methods using probe vehicles with on-board GPS equipment, *Transportation Research Part C: Emerging Technologies*, In press, 2016.
- 10) Cai, Y., Wang, H., Chen, X. and Jiang, H. : Trajectory-based anomalous behaviour detection for intelligent traffic surveillance, *IET Intelligent Transport Systems*, Vol. 9, pp. 810-816, 2015.

(2) プローブ車両データを用いた広域的な異常事象の発見手法

広域的に道路ネットワークが機能不全となった例として、2011年に発生した東日本大震災による首都圏道路ネットワークの機能不全が記憶に新しいが、これはグリッドロック現象の発生に起因するものであると考えられている。すなわち、グリッドロック現象によって発生した局所的な道路機能不全が周辺の道路ネットワークに影響を及ぼし、やがて広域道路ネットワーク全体の道路機能が麻痺するブレイクダウン現象の発生へと繋がったと考えられる。ここで、ひとたびネットワークブレイクダウン現象が発生すると、交差点信号制御といった通常の交通制御ではその機能を回復することが難しく、機能回復には相当の時間を要することとなる。道路ネットワークの機能を回復するためには、あるいは未然にブレイクダウン現象の発生を回避するためには、局所的な道路ネットワークに着目した交通観測を行って制御するのではなく、広域道路ネットワークエリアを対象として交通流状態を観測し、マクロにエリア交通流状態を捉えた上で、マクロな視点から適切な交通制御を行う必要である。例えば、一定の拡がりを持つ道路ネットワークエリアを対象とし、マクロな交通流動量(以下、“エリア流率”)とマクロな交通密度(以下、“エリア密度”)の2つを状態量として道路ネットワーク全体の交通流状態(以下、“エリア交通流状態”)を捉えることにより、単なる局所的な渋滞とブレイクダウン現象との違いを把握することが可能になる。

本項では、広域道路ネットワークにおけるネットワークブレイクダウン現象に着目し、プローブデータを用いてエリア交通流状態を観測し、道路交通の広域的な非日常、すなわちネットワークブレイクダウンの発生を発見する手法を考案し、具体的に仙台都市圏における道路ネットワークを対象として高精

度にブレイクダウンの発生を検知するネットワークブレイクダウン判定アルゴリズムの開発を試みる。

a) エリア交通流状態の推定方法

本研究では、以下の方法により、プローブ車両走行軌跡を用いて、エリア交通流状態を推定する。

・プローブエリア流率とプローブエリア密度

対象道路ネットワークエリア内を走行したプローブ車両軌跡データを用いて、5分単位で総走行台キロと総走行台時を集計し、下式のとおりそれぞれ、プローブエリア流率、プローブエリア密度として定義する。

$$q_t = \sum_{i \in A_t} d_{it} \quad (2.2-3)$$

$$k_t = \sum_{i \in A_t} o_{it} \quad (2.2-4)$$

ここで、

q_t : 時間帯 t におけるプローブエリア流率

k_t : 時間帯 t におけるプローブエリア密度

d_{it} : 時間帯 t におけるプローブ車両 i の走行距離

o_{it} : 時間帯 t におけるプローブ車両 i の走行時間

A_t : 時間帯 t に対象エリア内を走行したプローブ車両の集合

・エリア交通流状態

本項における分析では、前項で定義したプローブエリア流率とプローブエリア密度を用いた2次元のベクトルを用いて、式(2.2-5)にてエリア交通流状態 \vec{S}_t を定義する。

$$\vec{S}_t = (k_t, q_t) \quad (2.2-5)$$

b) 使用データ

本研究では、仙台都市圏における10km×10kmの道路ネットワークエリアを対象とする。また、令和2年1月15日から令和2年3月16日の2ヶ月間のHondaプローブデータを使用する。ただし、高速道路や自動車専用道路は対象外とする。Hondaプローブデータは、500m×500mメッシュ単位で5分単位に総走行台キロ、総走行台時として集計されたデータを用いる。メッシュ単位5分単位のデータサンプルは計3,518,019である。

c) ブレイクダウンの判定方法

道路ネットワーク交通流状態の広域的な非日常、ここではブレイクダウン現象の発生を発見するために、図2.2-3に示す手順によるブレイクダウン判定方法を考案する。集計単位を5分単位、1.5km×1.5kmのメッシュ単位としてプローブエリア密度とプローブエリア流率をエリア内の交通流状態とし、図2.2-4に示すエリア交通流状態の時間推移に基づきブレイクダウン発生の有無を判定する。なお図中の各丸印はエリア交通流状態を示す。具体的には、最初にエリア交通流状態の5分間推移を示す状態遷移ベクトルが設定した条件を満たしていることを判定する。ここで、状態遷移後の5分間平均速度、続く

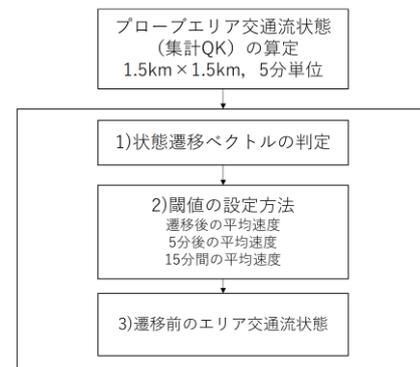


図 2.2-3 ブレイクダウン判定の流れ

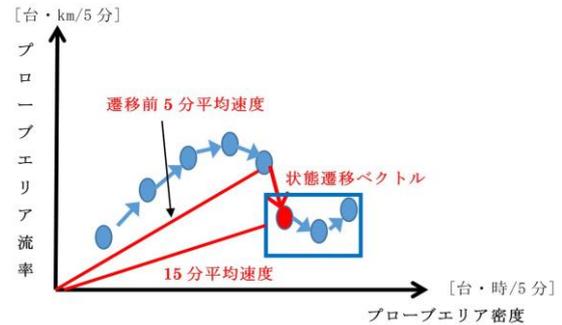


図 2.2-4 ブレイクダウンの判定指標

5分間の平均速度、状態遷移後の15分平均速度を用いて、その閾値を設定する。状態遷移ベクトルの判定に続いて、状態遷移後の15分平均速度、ならびにブレイクダウン発現と単なる渋滞時間帯における交通流状態の変化を区別するために、状態遷移前のエリア交通流状態として遷移前5分間平均速度の3つが条件を満たすときにブレイクダウン発生と判定する。

・状態遷移ベクトルの判定

ブレイクダウン現象が発現する際には、グリッドロック現象が発生すると考えられる。グリッドロック現象とは、ネットワーク上に存在する複数ボトルネックの相互干渉、あるいは自己干渉によりボトルネックにおける交通容量が大きく減少する現象である。個別交差点の交通処理能力の低下を検知するだけでは、例えば、交差点流出側近くで発生した事故などの影響による交差点単独での交通処理能力低下や路線上ネットワークにおける渋滞延伸による先詰まりによる交通処理能力低下とネットワーク規模での交通処理能力低下を区別することが難しい。このため、本研究ではネットワーク規模での交通流状態観測に基づいて、グリッドロック現象等に起因するネットワーク規模でのブレイクダウン発生の判定手法構築を試みる。

図2.2-5を用いて、エリア交通流状態に着目してネットワーク規模での交通流状態の推移を見てみると、渋滞が発生していない状況、すなわち図中の“自由流”では、車両台数の増加、言い換えればエリア交通密度の増加に比例してエリア交通流率が増加する。やがて、ネットワークの一部に渋滞が発生すると、ボトルネックが処理する交通量は変化しないこ

とから、ネットワークの流率は大きな変化がないにもかかわらず、エリア交通密度が上昇する。(図中“混雑流”) さらに、グリッドロック等によるネットワークブレイクダウンが発生すると、図中“渋滞流”に示されるように、エリア交通密度が増加するにもかかわらずエリア交通流率が低下するため状態遷移ベクトルが第4象限に向かう、すなわち右下がりのベクトルが出現する。そこで、同右下がりの状態遷移ベクトルの検出を行う。

・状態遷移ベクトル判定閾値の設定

前項にて、ブレイクダウン発現時には、状態遷移ベクトルが右下がりとなることを示したが、プローブによるデータ収集では、サンプルのバラツキによって右下がりの状態遷移ベクトルが出現する可能性が考えられる。この場合、図 2.2-6 中の破線矢印に示すように、交通流率が回復することから、右下に遷移した後、しばらくの間エリア交通流率が回復しないことがブレイクアウト発現と判定するための一要件となる。さらに、自由流状態でエリア交通密度の高い状況の範囲内でサンプルのバラツキによる右下がりの状態遷移が観測された場合には、エリア交通流率が回復しない場合でもブレイクダウン発現したとは考えられない。このため、遷移後のエリア交通流状態に基づき、遷移後の5分平均速度(図 2.2-6 中 V1)、遷移後5分後における5分平均速度(図 2.2-6 中 V2)、ならびに遷移後の15分平均速度(図 2.2-6 中 V15)を参考にして、状態遷移ベクトルのブレイクダウン判定に用いる閾値を設定する。

・遷移後の5分平均速度

図 2.2-7 は、第4象限に向かう状態遷移ベクトルについて、遷移後の平均速度(V1)の分布を示したものである。多くの状況で平均速度が高い値を示しており、これらはブレイクダウン現象ではないと考えられる。一方、12km/h以下の速度が出現する頻度が小さくなっていることから、遷移後の平均速度が12km/h以下である場合に、ブレイクダウン現象発現の可能性が高いと考えられる。

・遷移後5分後の5分平均速度

次に、前述した状況、すなわち右下への状態遷移ベクトルにおいて遷移後の平均速度が12km/h以下となった状況下において、さらに続く5分後における速度回復の有無を調べた。図 2.2-8 には同条件における遷移後5分後の5分平均速度の分布を示す。同図に示されるように、半数以上の割合で速度が15km/h以上に回復している。このことから、遷移後の平均速度が12km/h以下というだけでは、必ずしもブレイクダウン現象発現ではない可能性が高い。

表 2.2-3 には、右下への状態遷移ベクトルが出現した5分後において、状態遷移ベクトルのプローブ交通流率成分(ΔQ)とプローブ交通密度成分(ΔK)によって、 ΔQ は0.5[台 km/5分]、 ΔK は0.1[台時/5分]刻みの領域を定め、各領域に於いて5分平均速度が15km/h以下に留まっている割合を示す。 ΔK が増加するに従って、同割合が大きくなっており、 $\Delta Q=0.3$ を境にその割合に一定の差が認められること

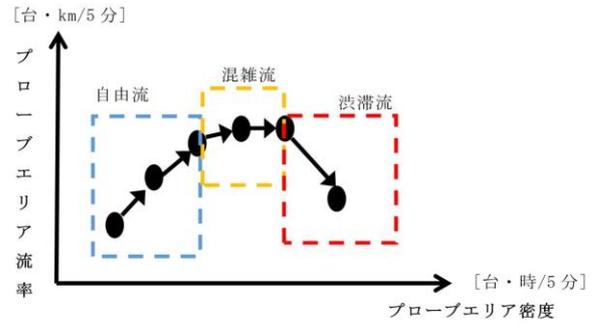


図 2.2-5 エリア交通流状態の推移

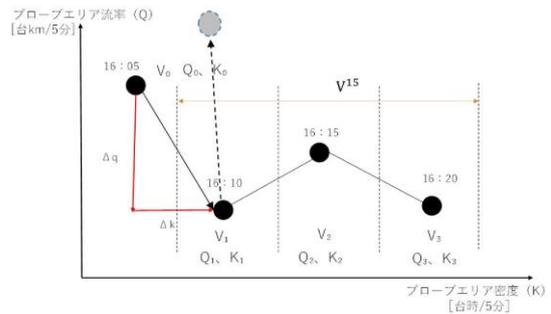


図 2.2-6 ブレイクダウンの判定

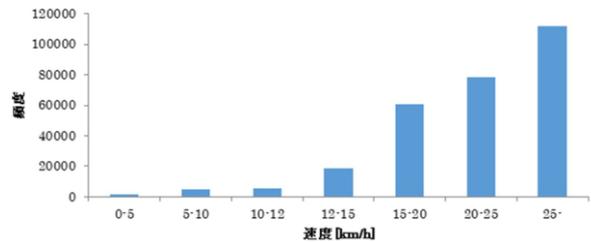


図 2.2-7 遷移後の5分平均速度 (V1) 分布

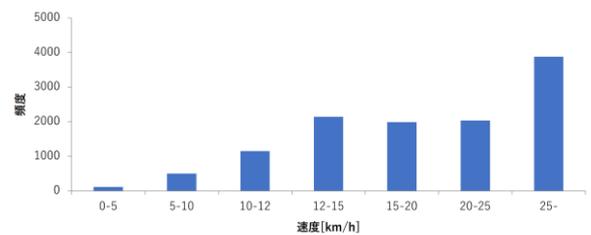


図 2.2-8 遷移後5分後における5分平均速度 (V2) 分布

表 2.2-3 遷移後5分後に低速度が継続する割合

$\Delta Q \setminus \Delta K$	0~0.1	0.1~0.2	0.2~0.3	0.3~0.4	0.4~0.5	0.5~0.6	0.6~	計
0~-0.5	912 1.1%	149 1.6%	64 2.2%	56 5.0%	23 4.7%	18 7.0%	21 5.8%	1243 1.3%
-0.5~-1.0	412 0.9%	129 1.8%	56 2.4%	30 3.2%	25 6.5%	14 7.3%	25 7.0%	691 1.2%
-1.0~-1.5	234 0.9%	85 1.5%	69 3.8%	42 5.6%	20 6.1%	10 6.3%	16 5.1%	476 1.3%
-1.5~-2.0	164 0.9%	82 2.0%	51 3.6%	17 3.2%	12 4.4%	10 7.2%	17 6.9%	353 1.4%
-2.0~-2.5	108 0.9%	56 1.7%	45 4.0%	16 3.8%	6 2.4%	10 8.1%	18 8.3%	259 1.4%
-2.5~-3.0	90 1.0%	48 2.0%	22 2.7%	10 2.7%	8 4.4%	8 7.6%	8 5.4%	194 1.5%
-3.0~	322 1.3%	167 2.2%	97 3.2%	73 5.2%	43 5.9%	21 4.6%	29 3.9%	752 1.9%
計	2242 1.0%	716 1.8%	404 3.0%	244 4.4%	137 5.2%	91 6.4%	134 5.6%	3968 1.4%

から、 ΔK の閾値として0.3を採用する式(2.2-6)。一方の ΔQ に関してはその割合の変動が小さいことか

ら、 $\Delta Q < 0$ とする式(2.2-7). ただし、この閾値判別だけでは、速度回復する割合が大きいことから、15分平均速度をあわせ用いてブレイクダウンの判定を行う。

$$\Delta K > 0.3 \text{ [台時/5分]} \quad (2.2-6)$$

$$\Delta Q < 0.0 \text{ [台 km/5分]} \quad (2.2-7)$$

・遷移後の15分平均速度

ブレイクダウン発現後は長時間にわたって速度回復が期待できないことから、ここでは、遷移後15分間の平均速度を以てブレイクダウンの判定を行う。図 2.2-9 には、15分集計によるエリア交通流状態の散布図を示す。図中に赤線で示した速度 12km/h 以下のエリア交通流状態の出現頻度が低いことが読み取れる。また、図 2.2-10 に、上記の条件を満たした状況下における、遷移後15分平均速度 (V_{15}) の分布を示す。12km/h 以下の出現頻度は六百回程度であった。右下がりの状態遷移ベクトルが出現し、遷移後の15分平均速度が 12km/h 以下となる場合にブレイクアウトが発生した可能性が高いと判断し、遷移後15分平均速度の閾値を 12km/h とする式(2.2-8).

$$V^{15} < 12 \text{ [km/h]} \quad (2.2-8)$$

・遷移前のエリア交通流状態

図 2.2-6 に示したようにエリア交通流状態が推移した場合でも状態遷移前の交通流状態の速度が低い場合には、必ずしもブレイクダウンの発現を示すも

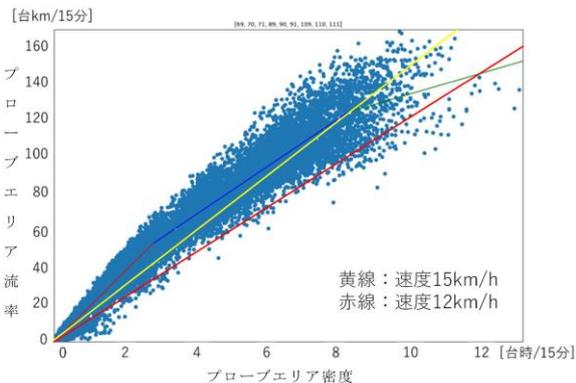


図 2.2-9 5分平均のエリア交通流状態

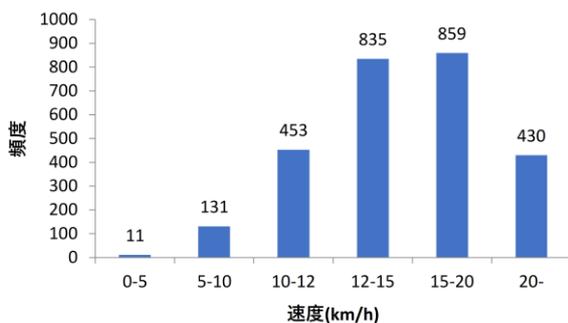


図 2.2-10 遷移後における15分平均速度 (V_{15}) 分布

のではなく、すでに渋滞している中でサンプルのバラツキによる流率低下が発生した可能性が高い。そこで、状態遷移前の交通流状態における平均速度が一定速度以上ある場合にブレイクダウン発現と判定する。図 2.2-9 に示したように、平均速度 15km/h 以上では渋滞流が含まれていない可能性が高い。

また、図 2.2-12 には、状態遷移ベクトルの遷移前平均速度 (V_0) の分布を示す。平均速度 12~15km/h の頻度が高く、15km/h を超えると急激にその頻度が小さくなることから、下式に示すように遷移前のエリア交通流状態として、5分平均速度が 15km/h 以上であることをもってブレイクダウンと判定する。

$$V_0 > 15 \text{ [km/h]} \quad (2.2-9)$$

・ブレイクダウン判定の検証

図 2.2-13 には、前項で考案したブレイクダウン判定方法を適用し、ブレイクダウン現象が発現したと判定された時間帯の分布を示す。図に示すように、22 (21:00~21:59) ~4 (3:00~3:59) 深夜時間帯, 8, 9 の朝ピーク時間帯に多数のブレイクダウン発現が検出された。

図 2.2-11 (a1), (a2) には、深夜においてブレイクダウン発現と判定された例について、出現エリアとエリア交通流状態の推移を示す。図 2.2-11 (a2) 中の破線は平均速度 12km/h の状態を示し、丸印 23:15 はブレイクダウン発現と判定された際のエリア交通流状態を示している。同時時間帯にはプローブエリア密度が大きく上昇し、速度の低下が見られるものの、他の時間帯においては 12km/h 以上の速度を示している、このように、深夜時間帯に出現したブレイクダウンは、突発事象の発生等により一時的にプローブエリア密度が上昇した可能性が考えられる。さらに、図 2.2-11 (b1), (b2) には、朝ピークにおけるブレイクダウン発現の例を示す。図 2.2-11 (a2) と同様に、破線が平均速度 12km/h、丸印がブレイクダウン発現と判定された 7:50 のエリア交通流状態を示している。こちらの例については、平均速度の低い状態が継続しており、ブレイクダウン現象が発現した可能性が高いと考えられる。

d)まとめ

道路交通の広域的な非日常を発見する手法として、本研究では、エリア交通流状態の状態遷移ベクトルを用いて、ブレイクダウン発生の有無を判定する方法を考案し、仙台都市圏における 10km×10km の道路ネットワークエリアを対象に検証を行った。その結果、ブレイクダウン検出の精度については、突発事象の発生等により一時的にプローブエリア密度が上昇し速度低下が発生している状況、すなわちブレイクダウンではない状況をブレイクダウンとして検出する可能性があることが示された。

MFD を把握した後は、非日常の検知に留まらず、Gridlock 等の発生によるブレイクダウン現象発現を

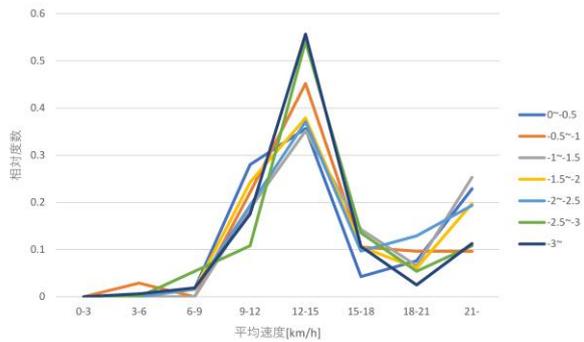


図 2.2-12 条件を満たす状態遷移ベクトルの遷移前平均速度 (V0) の分布

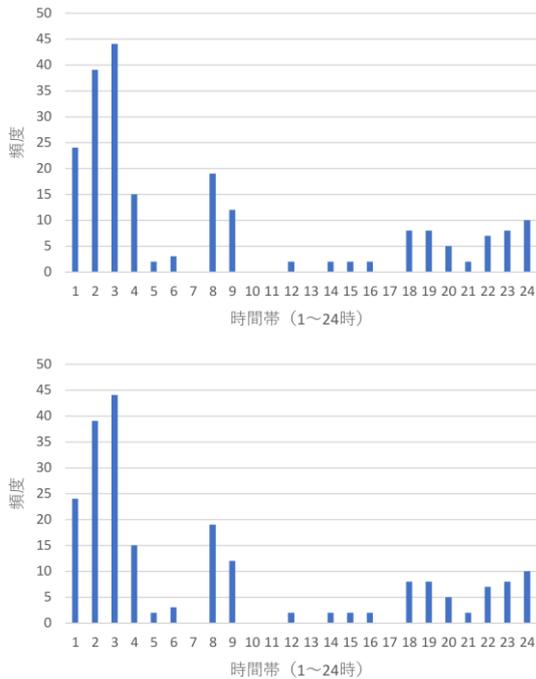


図 2.2-13 ブレイクダウンの判定が出現した時間帯

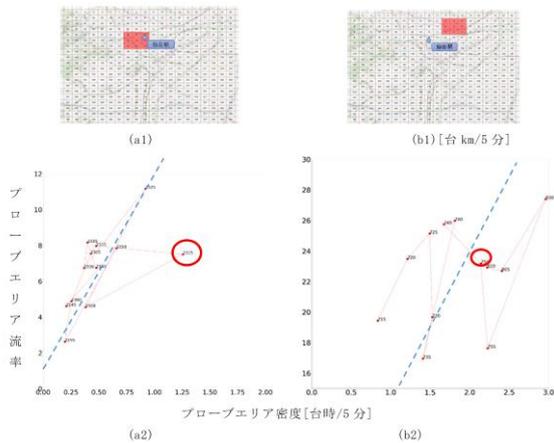


図 2.2-11 ブレイクダウンと判定された例

予測し、円滑なネットワーク交通流状態を維持するための適切な交通管制・制御手法の開発を行う。ここで、MFDはOD交通量の変化や交通事故発生によるネットワーク性能の変化によって、動的に変化すると考えられる。このうち、OD交通量については、リアルタイムにその変化を観測することは不可能で

あるが日常的には大きな変化が生ずることは少ないと考えられる。一方で、交通事故の発生等によりネットワーク性能は大きく変化すると考えられることから、交通事故発生などによるネットワーク性能の変化、すなわちMFDの動的変化をリアルタイムに捉える手法の開発が今後の課題である。

2.3 ドラレコ画像を用いた非日常発見手法の構築

(1) ドラレコ画像による道路冠水および事故等の検出手法

道路空間における非日常シーンの理解が進めば、危険の回避や早期発見といったインフラ整備への対応も可能になる。本項では、非日常シーンのうち、冠水・積雪、交通事故、急ブレーキ、渋滞を対象にしたドライブレコーダ画像を用いた深層学習による非日常の発見手法を提案する。また、その前段として、動画画像における事象認識（特に、以降の交通事故や渋滞の認識）において必要となる半自動ラベル付けに手法についても整理する。

a) ドラレコ画像の半自動ラベル付け手法の開発

一般に深層学習を行うためには、学習器を訓練するため、データに対して事前に教師情報（正解ラベル）を与える必要がある。この作業はアノテーションとも呼ばれる。例えば、画像から物体を認識する場合は、その位置（典型的には矩形）や種別（車両、歩行者等）等の情報を与える必要がある。アノテーションは現状では手作業に頼るところが大きく、典型的には図 2.3-1 のような画面により作業する。特に動画画像の各フレームにラベルを付与するためには膨大な労力が必要となる。

これらを効率化するため、既存の物体検出器を2つのステップにより更に訓練し、検出結果そのものが正解ラベルと見なせるようにすることを考える。この仕組みの全体像を図 2.3-2 に示す。詳細は以降に説明する。

・自己アノテーションによる検出器の強化

自己アノテーションは、以下の繰り返し処理により検出器を強化する仕組み（図 2.3-3）である。

- ①既存の検出器により、映像の各フレームから物体位置（矩形）を検出する
- ②時間的・空間的な連続性に基づいて検出結果を選

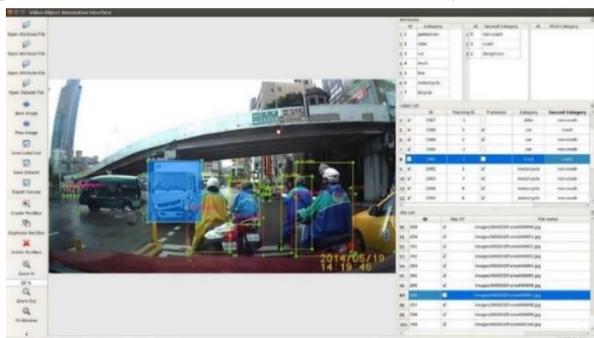


図 2.3-1 動画画像に対するアノテーション作業のイメージ

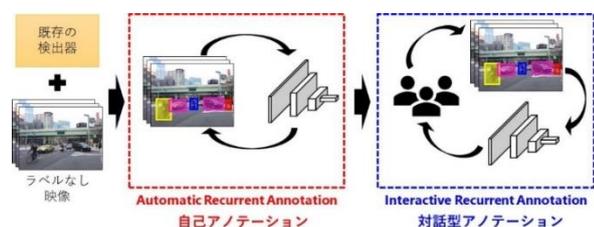


図 2.3-2 提案するアノテーション手法

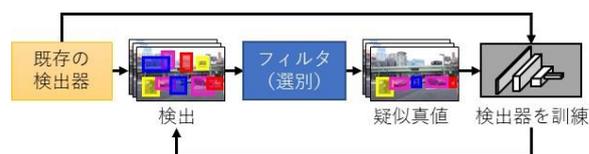


図 2.3-3 自己アノテーションの仕組み

- 別する（矩形サイズ、持続時間、検出信頼度などの条件を満たす物体のみ残す）
 - ③その結果を用いて、改めて検出器を訓練する（自己教師あり学習）
 - ④強化された検出器により物体位置を検出する。②へ進む
- この処理を時間的な順方向だけでなく逆方向に対しても行う。

・対話型アノテーションによる検出器の強化

対話型アノテーションは、初期検出器（既存の検出器、または自己アノテーションにより強化した検出器）の結果に対して人手によるフィードバックを導入して、検出器を更に訓練する仕組みである。誤検出・未検出、矩形領域のずれ、種別判定の誤りが発生すれば、人手により修正する。

・結果および効率化の効果

車載カメラ映像のデータセットである CityScapes⁵⁾ に半自動ラベル付けを行った結果を図 2.3-4 に示す。本手法によれば、完全手作業の場合と比べて、ラベル付けに要した時間は約 11%、人手により修整した物体の割合は約 36%である。

b) ドラレコ画像による冠水・積雪の認識手法の開発および精度向上

深層学習による認識を行うためには、事前の事例として学習データが必要である。日常シーンのデータは豊富に存在するが、非日常シーンのデータは少ないため、このままの状態では学習を行うと非常に偏った学習が行われる問題がある。

そこで、以降に示すアプローチ¹⁾、非日常シーンのデータ量を増加させることで分類性能の向上を試みた。具体的には、CG による描画や、GAN (Generative Adversarial Networks) により既存の画像を変換することで、非日常シーンの画像を人為的に生成し学習データを拡張している。GAN による画像

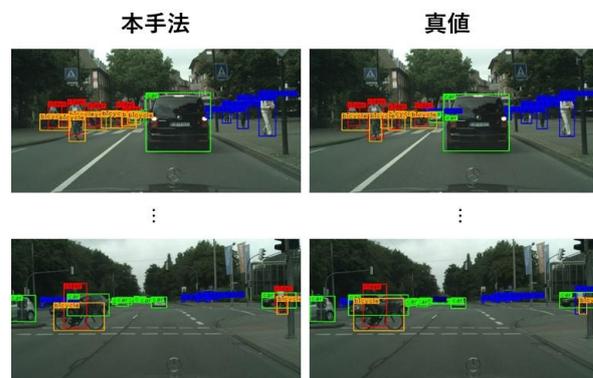


図 2.3-4 半自動アノテーションの結果

変換においては、変換の前後で画像中の意味的な領域（道路、建物、空など）が一致するように制約をかけている。

また、学習データを拡張する際にはパラメータの調整が必要であり、手動によるところが大きい。この問題に対し、PBA (Population Based Augmentation) ⁷⁾ と呼ばれる手法を導入することにより、調整の自動化を試み、認識精度を向上させる可能性を検討する。

・分類クラスの定義

ドラレコで撮影されたシーンを、「日常シーン」と「非日常シーン」に分類する。冠水の場合は (“Dry”, “Wet”) と “Flooded” である。日常シーンを細分化する理由は、冠水と雨のシーンが類似しており、明示的に分離することでより学習が簡単になるほか、誤分類の分析がしやすくなることを意図したためである。

・学習用画像の生成手法

追加する学習用画像としては、CG や、ドラレコの視点でない(例えば路側視点の)画像が考えられる。

ドラレコの視点で新たな画像を生成する手法として、GAN を利用する (図 2.3-5)。GAN では、ある画像 (生成源) を変換して新たな画像を生成するネットワーク (Generator) と、その生成画像が相応しいものであるかを識別するネットワーク (Discriminator) で構成される。ここで「相応しい」とは、後に日常・非日常シーン判定に用いられる学習画像に分類されることを意味する。最終的に Generator が生成する画像は、生成された画像かどうか Discriminator でも見分けがつかなくなる。

GAN では 1 対 1 の画像変換だけでなく、多対多の変換を扱う手法もある。複数クラスを同時に扱うことで、生成画像の質の向上や学習ネットワークの簡易化など様々な利点がある。ドラレコ映像でも天候や時間帯、風景などの要素により複数クラスとして扱う。

・領域情報の考慮

画像変換の前後では、意味的な領域 (道路、建物、空など) が一致していることが望ましく、それが変化すると学習に悪影響があるとされる。そこで、領域分割の結果の違いを定量化し、学習時の損失に反映させるようにネットワークを設計する。

・積雪の認識

上記手法により、積雪状態を以下の 3 クラスに分類する実験を行った。

- ・ Dry (日常)

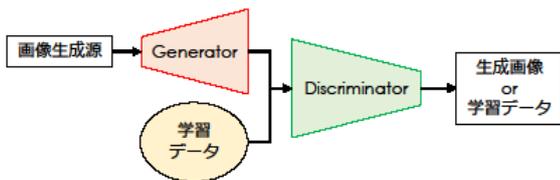


図 2.3-5 GAN の説明図



図 2.3-6 GAN による積雪画像の生成結果 (左: 変換前, 右: 変換後)

- ・ Wet (日常)
- ・ Heavy Snow (非日常, 道路が雪で覆われた状態)

学習および検証に用いる画像データの枚数は表 2.3-1 の通りである。初期状態においては非日常シーンである "Heavy Snow" の枚数が少ない。ここに、本手法に基づくデータ拡張により積雪画像を生成し、追加することで各クラスの学習データを同数とし、分類性能が向上するかどうかを確認する。

学習用のデータは公開データセットである BDD100K ³⁾ および Google 画像検索の検索結果より、検証用のデータは実際のドラレコ映像より取得した。

積雪画像の生成結果を図 2.3-6 に、分類の結果 (40 ~ 50 エポックにおける値) を図 2.3-7 に示す。エポックとは、Deep learning における学習時における一単位である。

本手法により "Dry" クラスの検出性能は向上したことが分かる。一方, "Wet", "Heavy Snow" クラスでは適合率が向上し再現率が低下した (誤報が減り欠報が増えた)。"Heavy Snow" クラスの再現率は特に低く、データ拡張が十分に機能していないことが原因と考えられる。また, "Dry", "Wet" クラスでの性能も大きく低下している。これは、学習データと実際のドラレコ映像の差異 (カメラの違いなど) が大きいことが原因と考えられる。このような場合は、ドメイン適応やドラレコ映像を使用した fine-tuning が有効と考えられ、今後の課題である。

・データ拡張におけるパラメータの自動最適化の検討

画像変換により学習データを拡張するためには、その変換手法や適用の重みづけ、順序づけなど、様々な調整が必要となる。これらのパラメータ調整を自動最適化しながら学習データを拡張する手法として、AutoAugment ⁶⁾ や PBA (Population Based Augmentation) ⁷⁾ と呼ばれる手法が提唱されている。パラメータが最適に調整されれば、認識精度が向上

表 2.3-1 積雪検出のデータセットの枚数

	Dry	Wet	Heavy Snow
学習データ (追加前)	2522	2522	129
学習データ (追加後)	2522	2522	2522
検証データ	4311	3305	2332

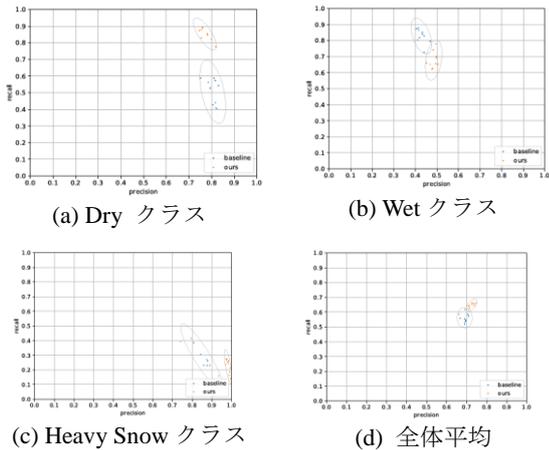


図 2.3-7 積雪検出における分類性能の比較 (適合率 vs 再現率)

することが考えられる。本項では、PBAにより冠水の認識精度を向上させる可能性について検討する。

図 2.3-8 に PBA の仕組みの概要を示す。拡張前の入力データから、どのように拡張処理を行えば良いかのポリシー(Deep learningにおける Augmentation 方法: 例えば、画像の平行移動や回転、反転など)とスケジュール(エポック毎の Augmentation の仕様頻度)を探索する流れが付加されており、これに基づいてデータが拡張される。拡張されたデータを用いて分類器を学習し、それを検証に用いる流れは従来と同様である。

検討のため、以下の3つのケースに対して、画像分類の正解率を比較評価した。

- ・ データ拡張を行わなかった場合
- ・ PBA によるデータ拡張を行った場合
- ・ PBA および mixup⁸⁾ によるデータ拡張を行った場合

ここで mixup とは、データ拡張の一手法であり、既存の複数のデータ(およびラベル)を線形補間することにより新たなデータを生成するものである。初期検討のため、冠水画像ではなく一般的な公開データセットにより傾向を分析した。具体的には、大規模なセットとして CIFAR-10⁹⁾ を、小規模なセットとして Tiny ImageNet を用いた。

評価結果を表 2.3-2 に示す。元々のデータ規模に関わらず、性能の向上効果はほとんど見られなかった。従って、本手法を冠水画像の認識に適用しても効果は薄いと考えられる。

c) ドラレコ画像による交通事故シーンの認識手法の開発

交通事故シーンを認識する方法としては、事故シーンそのものの外観に基づいて深層学習により認識することが考えられる。しかし、より詳細に考えると、シーン中にはもともと個々の路上物体が映り込んでおり、それらの位置関係性などにより、当該の物体が事故状態にあるかどうかが判別されると考えられる。すなわち、従来からの物体認識のような個々の物体の位置・種別と、状況特性(安全、危険、事

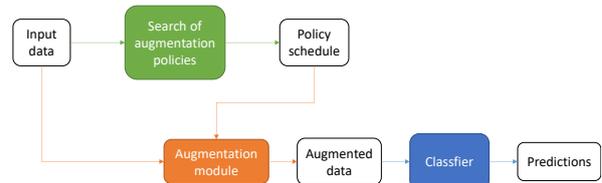


図 2.3-8 Population based Augmentation の仕組み

故)を切り分けた上で複合的に推定することが考えられる。

本項では、そのための新しい深層学習ネットワークとして開発した Attention R-CNN、およびそれに基づいた交通事故シーンの認識について報告する。

・ Attention R-CNN の概要

Attention R-CNN は、入力画像から、物体の外観(位置/種別)と状況特性(安全、危険、事故)を同時に推定し出力する深層学習ネットワークである。

外観(位置/種別)の推定

入力画像に対し、既存の検出器(Faster R-CNN)を改良した検出器により外観特徴を抽出し、プーリング層、全結合層を経て物体の位置/種別を算出する。物体種別ごとの出現頻度が不均衡であることによる悪影響に対応するため、「バランス損失関数」を設計し導入している。

・ 状況特性(安全、危険、事故)の推定

シーン全体の大域的なコンテキストを考慮するため、前述の外観特徴から Global Attention Map(着眼領域マップ)を計算する。Attention Map とは、シーン全体の単なる特徴量マップではなく、その中でどの領域に注目すれば良いかを学習により求めたものである。本研究で用いた車載カメラ映像では、路上物体の存在する領域において Attention が高いと判定される傾向にある。

Attention Map は、形式的には言わば重み付きマス

表 2.3-2 データ拡張手法ごとの画像分類の正解率

(a) データセットとして CIFAR-10 を用いた場合

	Epoch 50	Epoch 200	Epoch 300
No augmentation	96.37%	N/A	N/A
PBA augmentation	N/A	97.39%	N/A
PBA augmentation + mixup	95.73%	97.36%	97.56%

(b) データセットとして Tiny ImageNet を用いた場合

	Epoch 50	Epoch 100	Epoch 200
No augmentation	63.15%	63.06%	62.55%
PBA augmentation	61.97%	63.07%	60.65%
PBA augmentation + mixup	61.14%	N/A	N/A



図 2.3-9 Attention R-CNN による事故の認識結果の例



図 2.3-10 Attention R-CNN による物体の位置・状況の認識精度

ク画像の一種であるので、これを外観特徴に掛け合わせることで状況特性特徴に変換する。その後、先に推定した物体位置とともにプーリング層、全結合層を経て状況特性を算出する。

・結果

先述のデータセットに対して位置・種別および状況を認識した結果を図 2.3-9 に、評価結果を図 2.3-10 に示す。

矩形重なり率 (IoU) 50%以上を正解とした場合、位置・状況の認識精度 (Mean Average Precision, mAP) は、それぞれ $mAP_{50} = 57.7\%$ 、 31.1% であった。比較対象とする参考手法(位置の学習・認識を Faster R-CNN, 状況の学習・認識を Faster R-CNN + 単純な全結合 2 層で行った場合。)では $mAP_{50} = 35.9\%$ 、 19.7% であった。絶対的な性能としては十分ではないものの、Attention R-CNN におけるバランス損失関数やネットワーク構造の効果は現れていると言える。

物体種別および状況別では、「車」「トラック」「バイク」「安全」は 70~80%の認識精度であるのに対し、「バス」「ライダー」「危険」は 10%未満と低かった。これは、データセット中の出現頻度が極端に少ないことが影響している可能性がある。

mAP: 正解の矩形と、推定した矩形との重なり精度を表す指標

mAP50: 矩形重なりが 50%以上の時を正解とした場合の mAP

・ドラレコ画像による急ブレーキの発生予測手法の開発

本項では、ドラレコ画像を分析することにより、非日常事象である急ブレーキが発生しやすい状況であるかどうかを予測する手法について報告する。

先行研究¹²⁾では、急ブレーキの発生は走行箇所だけでなく日時や曜日など時間的要因も影響していることが指摘されている。佐藤らの研究¹³⁾では、ドラレコから得られる車両の粗い位置情報(緯度・経度、時刻 1 秒毎)のみからでも急ブレーキの発生を

機械学習により判別できる(すなわち急ブレーキを予測できる)ほか、天気の情報も合わせて学習に利用することで有意に高い精度で予測できることが示されている。

佐藤らの研究¹³⁾では、最寄りの气象台が 60 分毎に発表する情報をそのまま走行箇所の天気と見なししているが、走行箇所からは離れていることもあり、即時性にも欠けるため、走行箇所の天気とは異なることも多いと考えられる。本項ではドラレコ画像から走行箇所の天気を推定し、それを用いて急ブレーキの発生を予測する。

・データ

本研究で用いるドラレコデータは 2017 年 12 月~2018 年 1 月に九州地方と山口県を中心に 45 台の車両で記録され、総録画時間数は約 1493 時間、総容量は 172GB である。

急ブレーキ発生の判別に用いるデータ項目は表 2.3-3 の 10 種類である。天気を除く 9 項目は、ドラレコの 1 秒毎のログから直接的に得られるプローブデータである。天気は、气象台の記録、またはドラレコ画像から推定したものを用いる。天気の属性値は表 2.3-4 の通りである。

d)ドラレコ画像からの天気推定

ドラレコ画像から深層学習により天気を推定する。深層学習モデルには ResNet50¹⁴⁾を用いる。

ドラレコ画像には天気のラベルが付与されていないため、訓練用データとして用いることができない。代わりに、ドラレコ画像の公開データセットである BDD100K³⁾のうち、日中に撮影された画像を訓練に用いる。BDD100K では表 2.3-4 の 6 分類に

表 2.3-3 急ブレーキ発生の判別に用いるデータ項目と取得方法

データ項目	取得方法
時刻(秒), 月, 年, 曜日, 運転継続時間, 加速度, 速度, 位置(緯度経度), 進行方向	ドラレコのログから直接に取得(プローブデータ)
天気	气象台の記録またはドラレコ画像から推定

表 2.3-4 天気の属性値

	分類数	属性値
气象台の記録に基づく天気	13 分類	快晴, 晴, 曇, 薄曇, 雨, 雪, みぞれ, 雹あられ, 降水現象, 霧, 霧雨, 煙霧, 雷
ドラレコ画像から推定する天気	6 分類	晴, 雨, 雪, 一部曇, 全面曇, 霧
	3 分類	晴, 雨, 雪

従って天気ラベルが付与されている。天気を6分類で推定する場合はこれら全てのデータを、3分類で推定する場合は「晴」「雨」「雪」のみのデータを用いて、それぞれ独立に学習ネットワークを訓練する。

検証には、上記の BDD100K のうち訓練に使用していない画像、ドラレコ画像を用いる。

BDD100K 画像の天気推定結果を表 2.3-5 に示す。3分類よりも6分類の方が困難な問題であり、正解率において15ポイントの差があることが分かる。

e) ドラレコ画像より推定した天気情報を用いた急ブレーキの発生予測

これまでの手法によりドラレコ画像より推定した天気情報を用いて、データマイニングの手法により急ブレーキ発生の有無を判別し、その性能を従来手法と比較する。ここで急ブレーキとは、加速の大きさが0.25G以上とする。

データマイニングの手法には、勾配ブースティング決定木 (GBDT)¹⁵⁾ の CatBoost を用いる。用いるデータの違いにより以下の4つの判別モデルを定める。

- モデル A: ドラレコのログのみ (天気情報なし) を用いる
- モデル B₃: ドラレコのログ + ドラレコ画像から推定した天気 (3分類) を用いる
- モデル B₆: ドラレコのログ + ドラレコ画像から推定した天気 (6分類) を用いる
- モデル C: ドラレコのログ + 気象台の記録による天気を用いる

ドラレコに記録された17581件の事象のうち、急ブレーキの正例および負例はそれぞれ469件、17112件であった。両者の偏りを平準化するため、正例は全てを、負例は1/10を抽出して CatBoost に入力した。

急ブレーキ発生の判別結果を図 2.3-11 に示す。グラフの値は判別結果の F 値 (適合率と再現率の調和平均) であり、10分割の交差検証毎に示している。図より、総合的な性能としてはモデル C が最も優れているが、交差検証における分割毎に比較するとモデル B₆ において性能が向上するケースも認められた。

表 2.3-6 は各判別モデルで用いられるデータ項目の重要度 (CatBoost における Importance 値) を示し

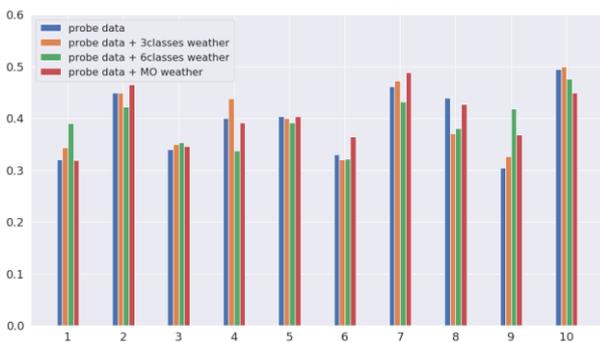


図 2.3-11 急ブレーキ発生の判別性能 (縦軸: F 値, 横軸: 交差検証におけるフォールド)

表 2.3-5 BDD100K 画像の天気の推定結果 (a) 3分類の場合 (b) 6分類の場合

	clear	rainy	snowy	pcloudy	overcast	foggy	sum
clear	1674	34	56	0	0	0	1764
rainy	92	244	60	0	0	0	396
snowy	152	46	224	0	0	0	422
pcloudy	0	0	0	0	0	0	0
overcast	0	0	0	0	0	0	0
foggy	0	0	0	0	0	0	0
sum	1918	324	340	0	0	0	2582

Predictions daytime (Accuracy: 0.8296)

	clear	rainy	snowy	pcloudy	overcast	foggy	sum
clear	1498	28	45	88	105	0	1764
rainy	36	203	22	3	132	0	396
snowy	152	40	131	21	78	0	422
pcloudy	167	5	15	311	140	0	638
overcast	113	93	24	78	729	2	1039
foggy	1	2	0	0	2	0	5
sum	1967	371	237	501	1186	2	2582

Predictions daytime (Accuracy: 0.6735)

たものである。モデル B₆ および C における天気の重要度は比較的高く、急ブレーキの判別に有効利用されていることが分かる。また、各モデルの間の統計的差異をマン・ホイットニーの U 検定により評価した結果を表 2.3-7 に示す。各モデルに有意差は見られなかったが、モデル B₆ はモデル C よりも P 値が低く、有意水準に近いことが分かる。

結論として、ドラレコのプローブ情報に加えてドラレコ画像から推定した天気を用いることにより、急ブレーキの発生を判別する性能は僅かに向上することが確認された。今後は、対象のドラレコ画像に天気の正解ラベルを付与して天気推定の訓練を行うことで天気推定の精度を高めることや、先行車両や障害物の存在などドラレコ画像から得られる新たな情報を加えて急ブレーキの判別を試行することが今後の課題である。

f) ドラレコ画像による渋滞状況の認識のための対向車線車両検出

表 2.3-6 各データ項目の重要度

データ項目	モデル A	モデル B ₃	モデル B ₆	モデル C
速度	40.17	40.28	29.89	37.35
位置	16.55	15.66	13.26	14.81
時刻	15.24	14.21	15.37	13.36
曜日	13.26	12.24	15.30	10.08
運転継続時間	9.96	9.67	9.96	9.82
月	2.44	2.15	2.44	1.86
年	2.39	2.07	2.39	1.99
天気 (ドラレコ画像から推定 3分類)	-	3.74	-	-
天気 (ドラレコ画像から推定 6分類)	-	-	13.26	-
天気 (気象台記録)	-	-	-	10.74

表 2.3-7 U 検定による各判別モデル間の統計的差異の評価

比較するモデル	P 値	帰無仮説	有意差
B ₃ vs A	0.572	採択	なし
B ₆ vs A	0.142	採択	なし
C vs A	0.336	採択	なし

渋滞などの交通状態を把握する手法としては、路側の車両感知器データを用いる手法や、車上のセンサ情報（プローブ）を利用する手法が研究されている。特に後者の手法については、対向車線から交通流を観測したデータ（バックワードプローブ）を用いて交通状態を推定する手法が本受託研究の代表者である桑原らにより提唱されており¹⁶⁾、車両感知器のデータが十分に利用できない場合でも有効とされている。そこで本項では、バックワードプローブ情報を取得するため、前述の手法を用いて前方および側方のドラレコ画像から対向車線の車両を検出することを試み、定性的な分析を行った。

結果を図 2.3-12 に示す。概ね検出できているが、以下の点が傾向および課題として挙げられる。

- ・ 瞬間的な検出漏れは散見される。特に、照明柱と車両が重なった場合等において顕著である。前後数フレームの画像においては検出されていることが多いため、動きの連続性に基づいた補間を考慮したり、検出器の訓練を進めることで改善できる可能性がある。
- ・ 照明柱の湾曲等からも分かるように、ドラレコ画像は全体として樽形に歪んでおり、これが画像中央部以外の領域における検出漏れに影響している可能性がある。歪みは後処理の画像処理により容易に補正できるため、補正後の画像で実験することが望まれる。
- ・ ガードレールの高さがある場合は、対向車両が連続的に隠蔽され、検出できないことが多い。この点は最大の課題である。
- ・ 既存の検出器である Faster R-CNN [Ren 2017]¹⁷⁾ による検出結果と比較すると、誤検出は大きく抑えられている。

2.3.1 の参考文献

- 1) Sho Nakamura, Shintaro Ono, Hiroshi Kawasaki: "Flooded Road Detection from Driving Recorder: Training Deep Net for rare Event using GANs Semantic Information", International Journal of ITS Research, DOI:10.1007/s13177-019-00219-9, 2020.1
- 2) BDD100K Blog Update, <https://bair.berkeley.edu/blog/2018/05/30/bdd/>
- 3) Fisher Yu, Haofeng Chen, Xin Wang, Wenqi Xian, Yingying Chen, Fangchen Liu, Vashisht Madhavan, Trevor Darrell, "BDD100K: A Diverse Driving Dataset for Heterogeneous Multitask Learning," IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2020.
- 4) Cityscapes Dataset - Semantic Understanding of Urban Street Scenes, <https://www.cityscapes-dataset.com>
- 5) M. Cordts, M. Omran, S. Ramos, T. Rehfeld, M. Enzweiler, R. Benenson, U. Franke, S. Roth, and B. Schiele, "The Cityscapes Dataset for Semantic Urban Scene Understanding," IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016.
- 6) Ekin D. Cubuk, Barret Zoph, Dandelion Mane, Vijay Vasudevan, Quoc V. Le, "AutoAugment: Learning Augmentation Policies from Data", IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2019.



図 2.3-12 対向車両の検出結果

- 7) Daniel Ho, Eric Liang, Ion Stoica, Pieter Abbeel, Xi Chen, "Population Based Augmentation: Efficient Learning of Augmentation Policy Schedules", International Conference on Machine Learning (ICML), 2019.
- 8) Zhang, H., Cisse, M., Dauphin, Y.N., Lopez-Paz, D.: "Mixup: Beyond empirical risk minimization", International Conference on Learning Representations (ICLR), 2018.
- 9) Alex Krizhevsky, Vinod Nair, and Geoffrey Hinton. 'Learning multiple layers of features from tiny images', Alex Krizhevsky, 2009.
- 10) CIFAR-10 and CIFAR-100 datasets, <https://www.cs.toronto.edu/~kriz/cifar.html>
- 11) Tiny ImageNet: This is a miniature of ImageNet classification Challenge, <https://www.kaggle.com/c/tiny-imagenet/>
- 12) T. Kawatani, E. Itoh, S. Hirokawa, and T. Mine, "Machine learning and visualization of sudden braking using probe data," 8th International Congress on Advanced Applied Informatics (IIAI-AAI), pp. 67–72, 2019.
- 13) 佐藤祐大, 峯恒憲, 「ドライブレコーダのプローブデータに基づく危険箇所の推定」, 第 17 回 ITS シンポジウム 2019, 2019.12
- 14) Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun, "Deep residual learning for image recognition," IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016.
- 15) Jerome H. Friedman, "Greedy function approximation: A gradient boosting machine," Ann. Statist., 29(5):1189–1232, 10 2001.
- 16) 河合克哉, 竹之内篤, 伊川雅彦, 桑原雅夫, 「対向車線の車両観測データを用いた交通流モニタリング - Variational Theory の適用」, 第 14 回 ITS シンポジウム 2016, 2016.12
- 17) Shaoqing Ren, Kaiming He, Ross Girshick, Jian Sun, "Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks," IEEE Transactions on Pattern Analysis and Machine Intelligence (PAMI), vol. 39, issue 6, pp. 1137 – 1149, 2017.6.

(2) ドラレコ画像による落下物の検出手法

本項では、画像解析と AI 学習により、ドライブレコーダ映像（以下、ドラレコ映像）から路面上の落

下物を検出する手法を構築し、落下物の検知に適用・検証する。

既往手法として、道路上の落下物を定点監視カメラ映像から自動検知する手法の研究（NEXCO 中日本が 2021 年より実証実験開始予定）や、ドライブレコーダと AI を活用し、道路の老朽化の状況を診断するシステム（NEC のサービス「くるみえ for Cities」）が存在する。しかしながら、ドライブレコーダから道路上の落下物を検出する手法として確立された手法は存在しない。

今回開発を進めている手法は、ドラレコ映像を通じて、色の濃淡などを見る画像解析により路面領域を認識（定義）する。その後、路面（アスファルト等）や路面標示など通常の施設以外の色領域を検出した場合、その領域を異常領域として検出するものである。自動車や自転車、路面標示などの通常の道路上のオブジェクトは、深層学習フレームワークを通じて事前に学習しておく。このような画像解析と AI 学習を組み合わせ、道路上の異常物体を検知する。当該手法のフローを図 2.3-13 に示す。

a) 落下物の検出方法について

・画像解析による領域識別（STEP①）

STEP①では画像解析により路面領域の認識を行う。ここで述べる路面領域の認識とは自転車走行位置と区画線との位置関係から自転車が走行する車線領域および対向車線の領域を抽出するものである。このような路面領域の境界探索は、通常、道路は均一な表面であるため、道路境界はそれを左右に囲む 1 つ目の連続的なエッジと考えることができる。この一つ目のエッジが縁石や区画線となる。このエッジの抽出は、画像処理の空間フィルタリング処理の一つであるソーベルフィルタ（特徴抽出）により画像内の白線（直線）を検出する。

ここで、ソーベルフィルタとは、画像の濃淡値を一次微分した上でエッジ（同程度の濃度値領域の境界線）を検出するフィルタリング処理となる。言い換えると、これらの方法は全てグレースケールの画像を生成し、エッジをグレーのレベルで表すものである。

例えば区画線であれば、その向きは進行方向に平行に配置されると仮定し、走行画像の中心から X 軸方向にソーベルフィルタを適用することで車線のエッジを抽出する。このような手続きを Y 軸方向に繰り返し、異なる Y 値でピークを検出した点を結ぶことで区画線として判定するものである（図 2.3-14、図 2.3-15）。

続いて、このように検出した両面領域の境界を用いて、画像解析の対象領域を設定する必要がある。解析領域の検出方法の原理は、閉じた境界から道路中心までの領域とした（図 2.3-16）。

・オブジェクト領域の検出（STEP②）

続いて、道路内領域に存在する全ての特徴を探し、オブジェクトが存在する領域を検出する。基本的にエッジ情報からオブジェクトの輪郭を見つけることで検出するものである。その際、この STEP①

では、解析対象とする道路領域内に存在する区画線などの境界線以外の特徴を持つオブジェクトを異常領域候補として抽出する。

ここで、オブジェクトの一部だけが道路上にあるケースがある。例えば、歩道などの道路外から道路上かけて横たわる木の枝やパイプ、長い障害物等が考えられる。これらのオブジェクト形状を解析領域の境界線で単純に切り取ると、この後に行うオブジェクト分別が正確に行えない可能性がある。よって、そのオブジェクト全体を取得するか、少なくとも小さすぎない範囲の一部を取得することが望ましい。このため、まず各オブジェクトの境界線が解析領域と少しでも交差していれば、そのオブジェクト全体を残すようにした。しかし、エッジ検出により非常に大きなオブジェクト境界線、今回の目的の対象外のオブジェクトまで検出し、障害物の誤認識に

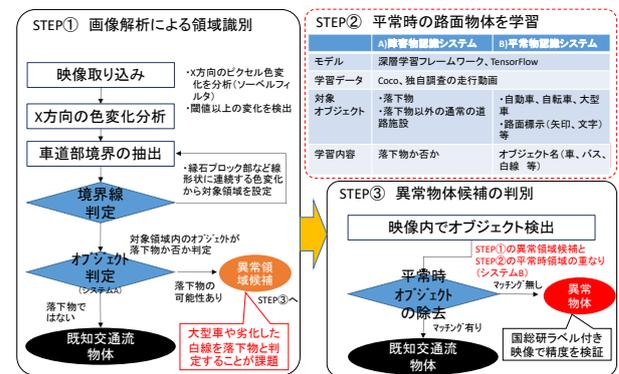


図 2.3-13 ドラレコ映像からの落下物検出手法フロー

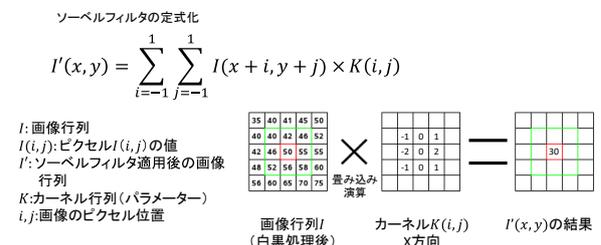


図 2.3-14 ソーベルフィルタによるエッジ検出の計算例



図 2.3-15 ソーベルフィルタによるエッジ検出例

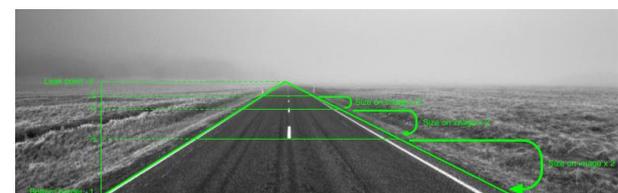


図 2.3-16 解析領域の設定の概念によるエッジ検出例

なる可能性もある。このため、前節で設定した解析領域の境界線で最終的にオブジェクトを切り取るものとした。

分類においては、境界線自体を分析するのではなく、輪郭に対応する RGB 画像を分析する。このような画像を得るために、輪郭の最上部、下部、左端、右端のピクセル座標を取得し、それらを画像の境界として使用した。

・障害物認識システムの学習 (STEP②)

STEP①で抽出した車道部境界については、事前に用意する通常の路面物体 (オブジェクト) 及び障害物リストと比較し、落下物などの異常物として判定する処理を行うこととなる (STEP③)。そこで以下に示す通常の路面物体及び障害物の学習用映像データをリスト化するため、深層学習フレームワークである Tensor Flow 上で、1 枚の画像からオブジェクト認識を行う Single Shot MultiBox Detector (SSD : 物体検出ニューラルネットワーク) を実装した MobileNet V2 を使用して、オブジェクトの事前学習を行った。

通常の路面物体 (オブジェクト) リストの作成にあたって、オブジェクトについては、障害物 (obstacle) を有するか否かという、2 つのクラス (バイナリクラス) に分類するものとしたこの分類は障害物の有無を検出するという目的に合致し、簡易にデータセットを生成できるものである。オブジェクトの事前学習に必要な学習データは、国総研より貸与された、車載カメラ画像による事象検知技術の性能評価試験で用いたラベル付き走行動画 2545 本を用いて作成した。

学習にあたり、障害物と障害物でない物体の学習画像の割合が重要となる。仮に、障害物の画像のみを学習させると、検出した物体は全て障害物であると判定するモデルとなる。逆に障害物でない物体の画像のみを学習させると、障害物を検出した際にも障害物でないとして判定するモデルとなる。そこで、障害物と障害物でない物体の学習画像の割合を変更しながら感度分析を行った結果、障害物の割合が約 43% の時が最も良い結果となった (表 2.3-8)。

よって本研究では最も良い結果となった時のモデルを障害物認識システムとして採用した。

・平常時認識システムの学習 (STEP②)

更なる精度向上に向け、「平常時認識システム」によるダブルチェックを実施できるようにする。

「平常時認識システム」は「ssd_mobilenet_v2_coco」(既に膨大なデータを学習し、様々な物体 (車、猫、本など 90 種類) の検出が可能なモデル (作成者 : Yiming Shi, Vivek Rathod) を使用し、検出した以下の物体について、障害物認識システムにて障害物であると判定されていた場合に、障害物ではないと再判定する仕組みとした。

・異常領域候補の判定 (STEP③)

STEP①で抽出した異常領域候補 (オブジェクト) と STEP②で学習した通常時の路面物体リスト (オブジェクト) と比較し、通常時の路面物体とマッチングしない領域 (オブジェクト) については、異常

領域 (オブジェクト) と判定する。

・誤検知への対応①トラッキング

開発した障害物検出では映像フレームの画像処理によって道路上に物体が存在する場所を検出し、ニューラルネットワークによって検出した物体の分別を行っている。

しかし道路上の物体として検出されるのは物体に限らず、路面の劣化と破損箇所、細かなゴミ、草、強い反射、白線及び路面標示等も含まれる。これらの一部は障害物として誤検知されている。

障害物として誤検知される一部の物体は、障害物と違って動画の中で連続的に検出されないことが多くある。そこで、この特性とトラッキング技術を組み合わせ、誤検出率を下げるのが可能かどうか検討を行った。

・トラッキング技術の種類

トラッキング処理は大きく以下の 2 つの種類に分類される。

- ① 動画のあるフレームで検出されたオブジェクトを次のフレームで再検出せず、トラッキング処理のみで検索する。オブジェクトの移動先の候補を生成し、移動前のオブジェクトとの比較で追従する。
- ② 動画のあるフレームで検出されたオブジェクトを次のフレームで検出されたオブジェクトと比較を行い、対応するオブジェクトを検索する。

上記 2 種類はいずれもオブジェクトの比較を行い、比較方法も複数存在する。

- ・画像 : 平均色、ヒストグラム比較、画像の明るさなど
 - ・位置比較 : 移動量、オブジェクトサイズの変化、フレーム間のオーバーラップ率
 - ・画像の特徴を抽出し、特徴の比較を含めた高度アルゴリズム : SURF, SIFT, ORB, MIL, BOOST, MF, TLD など
- #### ・トラッキングによる誤検出除去結果

検証映像でオーバーラップ率とトラッキング継続フレーム数について率=50%及びフレーム数=2 枚 (前回のフレームと現在のフレーム) の調整結果となった。

上記設定で障害物が残されることを確認し、一部の誤検出を除去することができた。

しかし誤検出がある映像の狭い範囲で連続的に発生する場合は本方法の効果がほとんど見られなかつ

表 2.3-8 学習データ (落下物割合) の感度分析結果

落下物割合	正解率	再現率	適合率	F 値	スレドスコア
41%	0.83	0.75	0.86	0.80	0.67
43%	0.87	0.82	0.87	0.84	0.73
45%	0.84	0.75	0.90	0.82	0.69

た。トラッキング機能を実装し、国総研より貸与された以下の2つの動画で落下物検知の精度検証を行った。

- ・動画①路面標示（矢印，文字，ドットライン等）が多い動画
- ・動画②道路付属施設（ガードレールや雑草等）が多い動画

結果は表 2.3-9 に示すとおりである。動画①についてはトラッキング機能が有効に働き、トラッキング無しでは誤検出されていた路面標示が検出されなくなり、落下物はトラッキングにより除去されることなく正しく検知できている。動画②についてはトラッキングが有効に働き、誤検出した道路上の白線をトラッキングにより除去することができた。一方で、落下物が白線上の白く薄い物体であったため、トラッキング無しでは落下物として検出されていたが、トラッキング有りでは見逃しも一部見られた。また、トラッキングでは除去できない大型車の誤検出も確認された。

b) 誤検知への対応

・平常時物体の学習データの拡充

上述までのシステムで、特に大型車の誤検知が発生していた。そこで、車の検出精度を向上させるため、平常時認識システムについて学習データを拡充した。

ここでは、ベースモデルに

「ssd_mobilenet_v2_coco」（既に膨大なデータを学習し、様々な物体（車，猫，本など90種類）の検出が可能なモデル）を使用し、まず普通車と大型車の合計5万枚の学習データ（背景の合成で作成）でファインチューンしたモデルを作成した

更に上記のモデルをベースとし、走行動画より作成した学習データをファインチューンさせた場合と、転移学習させた場合、ファインチューンについては学習回数を変更した場合で精度が向上するか検証を行った（表 2.3-10）。

なお、ファインチューンの方はベースモデルに新たなラベルを追加できず、転移学習は新たにラベルを設定できることから、それぞれ以下のラベル（物体）を検出させる設定とした。

- ・ファインチューン：車，トラック，バス，二輪車，自転車，人，信号機
- ・転移学習：車，トラック，バス，二輪車，自転車，人，信号機，白線，路面標示，看板，柱，その他（ポストコーン，クッションドラム等，通常道路上に存在する物体）

・結果

「動画①路面標示（矢印，文字，ドットライン等）が多い動画」を検証用動画として用いて、表 2.3-10 に示したケースについて落下物検知の精度検証を行った。結果としては、表 2.3-11 に示すとおりファインチューン1000回が全ての指標において最も高い数値となった。詳細に検証結果を確認すると、誤検出が発生していた大型車について、AIモデルの改善を行うことにより前方のトラックが検

表 2.3-9 結果まとめ

	動画①路面標示（矢印，文字）多い		動画②ガードレール，雑草等多い	
	トラッキング ⁺ 無し	トラッキング ⁺ 有り	トラッキング ⁺ 無し	トラッキング ⁺ 有り
正解率	0.35	0.65	0.37	0.63
再現率	0.43	0.58	0.73	0.38
適合率	0.63	0.57	0.24	0.27
F値	0.51	0.58	0.36	0.31
スレトスコア	0.35	0.40	0.22	0.19

出され、誤検出を除去することに成功した。ファインチューン5000回については、過学習により逆に精度が落ちたと考えられる。転移学習は、他のモデルよりも誤検出は減ったが見逃し数が増加し、スレッドスコアは最も低い結果となった。

c) まとめと今後の課題

本研究では、落下物の検出にあたり、障害物検出システムと平常時認識システムの2つのシステムを用いて、更にトラッキング技術を取り入れたシステムを構築した。障害物検出システムについては、障害物と障害物以外の学習データのバランスに留意し、最も精度良く検出できるモデルを検討した。平常時認識システムについては、実走行データより作成した学習データを用いることにより、ベースモデルの改良を図った。

本システムは、ドラレコ映像から落下物を検出するシステムであり、以下に示す点が既往手法と異なる。

- ・道路上の障害物・落下物を検出することが可能
道路上の障害物・落下物は、空き缶やペットボトル等のゴミや街路樹の折れた枝，破損した車のパー

表 2.3-10 学習実行ケース

No.	学習方法	学習回数
1	ファインチューン	1000回
2	ファインチューン	3000回
3	ファインチューン	5000回
4	転移学習	12400回

表 2.3-11 結果まとめ

	ベースモデル（トラッキング ⁺ 有り）	ファインチューン			転移学習（12400回）
		1000回	3000回	5000回	
正解率	0.65	0.66	0.65	0.64	0.64
再現率	0.58	0.58	0.58	0.41	0.48
適合率	0.57	0.58	0.57	0.58	0.58
F値	0.58	0.58	0.58	0.48	0.52
スレトスコア	0.40	0.41	0.40	0.32	0.35

ツなど千差万別である。既往手法の物体検出では特定のものを検出することは可能だが、このような一意に特定できないものに対する検出精度は低い。本システムは複数の技術を組み合わせることにより、道路上の様々な障害物・落下物を検出することが可能である。

・1つ1つの技術が独立しているため、改善、改良を個別に行うことが可能

本システムでは大きく分けて3つの機能が独立して存在している。

- 1) 道路上に存在する物体と思われるものの検出(画像処理)
- 2) 物体が障害物・落下物かどうか検出(クラシフィケーションAI)
- 3) 道路上に存在しても問題ないもの(車や人など)の検出(物体検出AI)

それぞれの機能が独立していることにより、システム全体の調整が必要なく、精度向上に必要なコストを最小限に抑え、継続的な改善、改良を個別に行うことが可能である。

本システムにより、落下物の検出はされたが、一方で落下物以外の通常路面上に存在する物体の誤検出も確認された。

今後の課題として、システム自体の落下物検出精度の向上と、落下物が存在したときのアラートの出し方の双方から利用しやすいシステムへ改善する方法が考えられる。

システム自体の精度向上に関しては、障害物認識システムと平常時認識システムの2つのシステムを用いていることから、それぞれについて学習画像の拡充を図り、AIモデルをより精度の高いものへ更新することにより、誤検出や見逃し数を改善できると考えられる。本システムは落下物検出のための3つの機能が独立して存在しているという特徴を有しているため、それぞれの機能で更なる改善、改良を行うことが可能である。

もう一方のアラートの出し方については、現在誤検出している白線などの路面標示は、次のフレームでは通常物として検出されることも多々ある。落下物は数フレームにわたって障害物であると検出される。これらの検出の特性を考慮し、複数フレーム連続して落下物と認識された場合にアラートを発し、少ないフレームだけで落下物と認識された場合はアラートを出さないような仕組みを構築することも考えられる。また、路面の劣化等により普段から必ず障害物があると誤検出される箇所についてはアラートを出さないといった方法も考えられる。

(3) インターバル静止画像を用いた車両の検出手法

ドライブレコーダによって撮影される動画は高解像度化しており、その解析によってさまざまな非日常事象を検出することが可能になると考えられる。しかしながら、このような高解像度動画データは容量が増大化しており、車載されたドライブレコーダ

から現実的な労力で取り出すことが困難である。現時点では、典型的にはこのような動画データはドライブレコーダに挿入したSDカード等に格納し、そのメディアをそれぞれの車から手で回収して、解析用のコンピュータにコピーする、という手順によって収集する。この手順では、大量の車を対象にした広範囲のデータ収集を、事象発生からの時間遅延を小さくして収集することが困難である。

一方、データ量を大幅に削減した低解像度、低頻度のインターバル撮影静止画像であれば、携帯電話回線を通じて容易に収集することが技術的に可能である。ドライブレコーダの種類によっては、デジタルタコメータの記録データ等、業務に必要な記録を回収するために携帯電話回線を利用できる場合がある。このような機種では、インターバル撮影静止画像を大量広範囲に収集できる可能性がある。本研究では、携帯電話回線を用いて試験的に収集されたインターバル静止画像を利用して、画像からの車両の認識と車両台数の推定が可能であるかの検証を試みた。また、その検証の結果、大量画像に対するアノテーションが必要であることが判明したことを踏まえ、画像のアノテーション支援技術の基礎検討を行った。

a) インターバル静止画像に対する車両の検出技術の検証

携帯電話回線を用いて試験的に収集されたインターバル静止画像を利用して、画像からの車両の認識と車両台数の推定が可能であるかの検証を行った。実験には株式会社富士通交通・道路データサービスによって取得されたデジタルタコメータからのインターバル撮影静止画像を用いた。この静止画像は、解像度を160×120に縮小し、5分に1回の間隔で取得されている。図2.3-17に画像の例を示す。データを取得するデジタルタコメータは動画を撮影することができ、SDカード等のメディアを用いれば、本体内に記録された1280x720等の高解像度の動画データを取得できるが、携帯電話回線を通して無理なく収集できる程度のデータ量とするためには、160×120程度の低解像度の画像である必要がある。

画像から車両を認識するために、広範なカテゴリに対する物体画像認識アルゴリズムとして現時点で最高程度の精度と速度を実現しているYOLO v3アルゴリズム¹⁾を用いる。実装に際しては、高速なディープラーニングフレームワークであるdarknet²⁾を用いた。物体認識タスクにはピクセル単位の判別タスクであるsemantic segmentationなどの形式もあるが、車両の台数を求めることを目標としているため、ここでは物体を囲む矩形を見つけるタスクであ



図 2.3-17 インターバル撮影静止画像例

る bounding box 検出を採用する。学習のためには、画像に対し「ここに車が写っている」という正解を付加した、アノテーション済み画像データを大量に用いる必要があるが、ここでは Microsoft が整備した大規模画像データセットである COCO (Common Objects in Context)³⁾を用い、あらかじめ学習を済ませて公開されているモデルを利用した。COCO は一般的な画像を集めたデータセットであるため、今回適用しようとしている道路上の画像を十分に含んでいない点には注意が必要である。また、正解としてラベル付けされた物体の種類は 80 種類であり、今回の研究ではその中で car や person というカテゴリを判別することを試みることになる。ここでは car カテゴリに属すると判定された bounding box を数えることで、画像中の車の台数の推定を行うことにする。

100 枚のインターバル静止画像をランダムに取り出し、それぞれの画像に存在する車の台数を目視で数え、正解データとした。画像を取得した車両の走行状況が偏っていたためか、車両が写っていた画像が少ないデータセットとなった。ただし、画像の解像度が低いため、人間の目視でも確実に車であると言い切れないような小さな領域については、車が写っているとカウントしてはいない。

この正解データセットに対し、YOLO による物体認識を行った結果の例を図 2.3-18 に示す。低解像度であっても、車が正しく認識されていることがわかる。本実験では検出の確信度が 70%以上で車両カテゴリと認識された領域の数を数えることにする。

この正解付きデータセットを用いて、認識精度を見積もった。車が写っている画像が少ないため、1 台以上車が写っているか否かを判別する問題とし、認識の正解率などを求めた。結果を表 2.3-12 に示す。適合率が高く、車両があると認識された画像は確かに車両が写っていたことがわかるが、再現率はそれほど高くはない。この時の混同行列を表 2.3-13 に示す。車両が目視では確認できるにもかかわらず、アルゴリズムで検出できていない画像が無視できない割合で存在していることが見て取れる。また、認識した車両台数と正解台数の分布の様子を図 2.3-19 に示す。相関係数を求めると、 $R=0.62$ となり、台数の推定もある程度できていると言える。ただし、回帰係数は 0.24 であり、図中の回帰直線に示すよう

表 2.3-12 正解データセットの画像認識性能

正解率	0.93
適合率	1.0
再現率	0.61
F 値	0.76

表 2.3-13 正解データセット100枚中の画像認識結果の内訳 (枚数)

	認識：車なし	認識：車あり
正解：車なし	82	0
正解：車あり	7	11



図 2.3-18 インターバル静止画像に対する物体認識結果の例

に、台数がかかなり少なく見積もられる傾向が見て取れた。

予備評価実験の結果、低い解像度のインターバル撮影静止画像に対しても、YOLO を用いた画像認識によって車の存在の認識が可能であることが示された。インターバル静止画像は、大量・広範囲の車両から得られる道路画像を収集できる、強力なデータ収集経路と成り得ると考えられる。一方、評価では再現率の低さが課題として明らかになった。この実験では一般的な物体カテゴリに対して学習を行ったモデルを利用して車両判別を行っているが、道路上の物体に限定したカテゴリで、低解像度の教師データによって学習を行ったモデルを利用すれば、性能改善が図られる可能性がある。このためには、教師画像データのアノテーションを効率化する技術が必要となる。車両台数の分布の検証によって明らかになったように、大部分の画像には 1 台も車が写っていないため、車が存在しそうでない画像を前もって排除し、人間がアノテーションすべき画像のみを処理対象にするような工夫が考えられる。

b)大量画像へのアノテーション支援技術に関する技術的基礎検討

利用したい画像の割合が少ない、大量の低解像度静止画像に対し、学習用のアノテーションを施すためには、何らかの機械的サポートを利用した作業効率化が必須となると考えられる。そこで、アノテーションの過程を効率化できるような技術確立のための基礎的な検討を行った。ここでは、以下の 2 つのサポート機能について技術検証を行った。

- 軽量な画像処理アルゴリズムによって、利用しにくい画像をフィルタリングする機能
- 類似している画像を集約し、利用しにくい画像をまとめて判断できるようにする機能

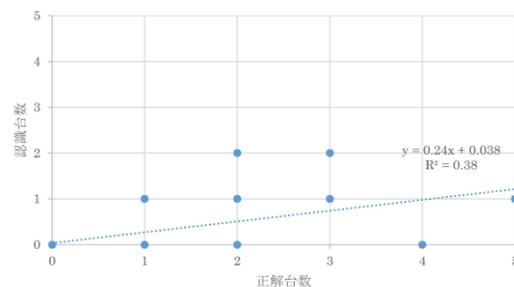


図 2.3-19 正解台数と認識台数の分布と回帰直線

以下、順に検証結果を示す。

・利用しにくい画像をフィルタリングする機能

大量の画像に対する軽量のフィルタリングとして、以下の2つの方法を試験的に実装し、その有効性を検証した。

- ヒストグラムの偏りに着目したフィルタリング
画素ごとの R, G, B の値を画像全体で集約し、出現頻度のヒストグラムを作成する。要素が少数のビンにのみ偏って出現している場合は、画像が全体的に暗いなど、情報量が少ない画像であることが示唆されるため、このような偏りを持つ画像を検出することを目指す。ビンの数を N としたとき、出現頻度が $1/2N$ 未満のビンを数え、このようなビンが 70% を越えた時にヒストグラムが偏っていると判断し、その画像を排除することにする。
- エッジ領域の面積に着目したフィルタリング
何が写っているかわかりにくい画像は、隣接した画素が大きく異なるエッジと判断される領域が少ないと考えられる。これを検出するため、画像のエッジ検出を行い、エッジと判断される画素が 1% 未満の時にその画像を排除することにする。エッジ検出には Canny アルゴリズム⁴⁾を用いた。

多数の乗用車に設置されたドライブレコーダから収集された運転中前方画像アーカイブに対し、この2種類の方法でフィルタリングを行った。元々のドライブレコーダ画像は動画であるが、ここでは5秒毎に1枚の画像を取り出した静止画を実験対象とした。12時台と18時台に記録された画像からランダムに1000枚ずつを抽出し、実験対象とする。12時台の画像はほぼ全て鮮明な画像であるが、18時台には全体的に暗すぎて情報が少ない画像が多く存在するデータセットとなっている。それぞれの手法を用いて判定を行い、情報不足として排除された画像の枚数を表2.3-14に示す。いずれの方法も、18時台の暗い画像については半分程度の画像を情報不足と

表 2.3-14 フィルタリングされた画像枚数(1000枚中)

	12時台	18時台
ヒストグラム	4	604
エッジ検出	32	517



図 2.3-20 エッジ領域抽出で情報なしとしてフィルタされた画像例(18時台)



図 2.3-21 エッジ領域抽出で情報ありとして残された画像例(18時台)



図 2.3-22 エッジ領域抽出で情報なしとして排除された画像のうち、車両が検出された画像の例

して取り除き、12時台ではごく少数の画像を取り除いている。

ここで、取り除かれた画像を目視して調べたところ、ヒストグラムを利用する方法では写っているものが鮮明に判定できる画像も多く取り除かれており、エッジ検出によるフィルタリングの方が人間の感覚と比較的一致する結果を出していることがわかった。図2.3-21は同じ手法で排除されなかった画像の例である。夜間に撮影された画像であっても、比較的情報が読み取りやすい記録画像が存在し、それらを抽出出来ていることがわかった。

また、取り除かれた画像に対し、インターバル静止画像に対する検出と同じ手法で車両の検出を試みた。図2.3-22は、エッジ領域抽出で情報なしとして排除された画像に対し、車両検出を行い、1台以上の車両が検出された画像の例である。夜間の画像であり、輝度が高い部分が多く、輪郭がつぶれているために排除されたと考えられるが、YOLOを用いると車両が認識され、肉眼でも車両が写っていることが確認できる。試験的に、エッジ領域抽出で排除された画像のうち、夜間に撮影された20枚をランダムに取り出して車両検出を行ったところ、2枚から車両が検出された。このような画像を排除してしまうことは有用な情報を捨てることにつながるため、何らかの回避策を講じることが必要になると考えられる。

・類似画像集約機能

軽量のフィルタリングにより、夜間に撮影された情報から得にくい画像を排除することはある程度可能であることが確認された。しかし、昼間に撮影された画像にも、カメラの設置方法が不適切な場合など排除したい画像が存在している。このような画像を排除することを助けるため、画像のクラスタリングを行い、類似画像をまとめる機能の有効性を検証することにした。クラスタリングを行うことで、人間が目視して判断する際、一度に大量の不要な画像を排除することができると考えられる。

それぞれの画像を 50×50 ピクセルに縮小し、画素の R, G, B 値を並べたものを画像を表すベクトルとする。画像間の距離は正規化したベクトル間の Jensen-Shannon divergence を用いて定義することとした。クラスタリングアルゴリズムには DBSCAN⁵⁾ を使い、パラメータは予備実験結果を目視して $\epsilon = 0.015$, $\text{minPts} = 3$ と定めた。2つの時間帯で1000枚ずつの画像に対し、クラスタリングを行った。

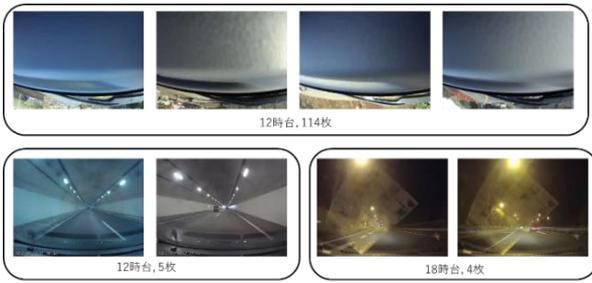


図 2.3-23 DBSCAN を用いたクラスタリングにより発見されたクラスタの例

この手法で発見されたクラスタの例を図 2.3-23 に示す。12 時台の画像には、カメラの設置方法が不適切だったためほとんど路面が写っていない画像が多く存在していたが、これが 114 枚のクラスタ(同図上)としてほぼ完全に発見されていることがわかる。また、得られる情報量が比較的少ない画像群(同図左下)、ガラス面への映り込みによりノイズが多い画像群(同図右下)、などのクラスタが発見されている。

しかしながら、サイズの大きなクラスタについては、見た目の傾向が異なる画像を多く含むものが出力されており、画像類似度の設計を改善する必要があることが判明した。また、今回の実験は画像の情報のみでクラスタリングすることを試みているが、画像の撮影時刻、画像を撮影した機器の ID などの付加情報を利用すれば、撮影状況が大きく異なる画像を分離することは比較的容易であると考えられる。

以上のように、大量画像へのアノテーションを効率化する 2 つの技術、「軽量なアルゴリズムによるフィルタリング」「クラスタリングによる類似画像の集約」について技術的な基礎検証を行い、それぞれの手法がドライブレコーダ画像に対して利用可能であることが示された。低解像度の大量インターバル静止画像に対しても、これらの技術を用いてアノテーションを行い、学習用のデータセットを整備することで、より高い性能での車両判別やイベント判別が可能になると期待できる。

2.3 の参考文献

- 1) Joseph Redmon and Ali Farhadi. YOLOv3: An Incremental Improvement, arXiv, <https://pjreddie.com/darknet/yolo/>, 2018
- 2) Joseph Redmon. Darknet: Open Source Neural Networks in C, <https://pjreddie.com/darknet/>
- 3) Tsung-Yi Lin, et. al. Microsoft COCO: Common objects in context. In European Conference on Computer Vision, pp. 740-755, 2014.
- 4) John Canny. A computational approach to dge detection. IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. PAMI-8, No. 6, pp. 679-698, 1986.
- 5) Martin Ester et. al. A density-based algorithm for discovering clusters in large spatial databases with noise. In Proceedings of the Second International Conference on Knowledge Discovery and Data Mining, KDD'96, pp. 226-231, 1996.

2.4 実規模ネットワークにおける交通状態推

定手法の構築

(1) 概要

非日常を発見するために、特に一般道では、限られたデータから交通状態を推定することが重要である。そこで、本研究では、プローブ車両データを活用した 2 次元状態空間モデルを構築する。構築した 2 次元状態空間モデルを実際の交通ネットワークを対象とした交通シミュレーションに適用し、モデルの有効性を検証した。

a) 状態空間モデルの概要

まず、ネットワークの仮定を述べる。ネットワークは有方向リンク $a=1, 2, \dots, L$ とリンクの結節点であるノード $n=1, 2, \dots, N$ で構成される。それぞれのリンクは、長さ Δx のセルに分割される。セルのインデックスを $i=1, 2, \dots, C$ とする。それぞれのセルの交通状態は、区分線形 FD(fundamental diagram)で表現される。セル i の区分線形 FD を ϕ_i と表記する。 ϕ_i は以下の 3 つのパラメータを持つ。

$$\begin{aligned} v_i &= \text{forward wave speed of } \phi_i, \\ w_i &= \text{backward wave speed of } \phi_i, \\ q_i^{\max} &= \text{maximum flow of } \phi_i. \end{aligned}$$

次に、状態ベクトルを定義する。タイムステップを $t=1, 2, \dots, T$ と表記する。車両の目的地のインデックスを $d=1, 2, \dots, D$ と定義する。状態変数は、

$$k_i^d(t) = \text{セルの目的地別の車両密度}$$

と定義する。状態ベクトルは、全てのセルの目的地別の車両密度 $k_i^d(t)$ の集合ベクトルとして、 $K^D(t)$ と定義する。

次にモデルに用いる観測値を定義する。観測値は、

$$\begin{aligned} \hat{k}_i(t) &= \text{セル } i \text{ の車両密度} \\ \hat{\pi}_{ij}(t) &= \text{セル } i \text{ から } j \text{ への分岐率} \end{aligned}$$

の 2 種類を定義する。上記、状態ベクトルと観測値を用いて、状態空間モデルを下式で定義する。

$$k_i^d(t+1) = f(K^D(t) + e(t)) \text{ for } \forall i, d, t. \quad (2.4-1)$$

$$\hat{k}_i(t) = \sum_d k_i^d(t) + \omega(t), \quad (2.4-2)$$

$$\hat{\pi}_{ij}(t) = g(K^D(t)) + \gamma(t). \quad (2.4-3)$$

(式 2.4-1) はシステムモデル、(式 2.4-3) は観測モデルである。式中の $f(\cdot)$ はシステムモデルの関数、 $g(\cdot)$ は観測モデルの関数である。 $e(t)$ 、 $\omega(t)$ 、 $\gamma(t)$ はシステムノイズと観測ノイズである。状態空間モデルの詳細は、参考文献 1) を参照されたい。

提案手法では、状態ベクトルに加えて、モデルパラメータも同時に推定する。この状態とパラメータ

を推定するモデルは、自己組織化状態空間モデル²⁾とよばれる。以下に本研究の自己組織化状態空間モデルを定義する。まず、モデルパラメータベクトルを

$$\Theta(t) = (\theta, \Phi, Q(t))^T. \quad (2.4-4)$$

と定義する。ここに、 θ は経路選択モデルのパラメータ、 Φ はセルのFDのパラメータおよび $Q(t)$ は時刻 t のOD需要マトリクスである。状態 $X(t) = K^D(t)$ と表記する。状態ベクトルとパラメータベクトルをあわせた拡張状態ベクトルを

$$\tilde{X}(t) = (X(t), \Theta(t))^T. \quad (2.4-5)$$

と定義する。観測ベクトルを時刻 t の観測車両密度および分岐率の集合ベクトルとして、

$$Y(t) = (\hat{k}_1(t), \hat{k}_2(t), \dots, \hat{k}_c(t), \hat{\pi}_{12}(t), \hat{\pi}_{13}(t), \dots, \hat{\pi}_{c-1,c}(t))^T. \quad (2.4-6)$$

と定義する。時刻 t において観測ベクトル $Y(t)$ が得られた下で拡張状態ベクトル $\tilde{X}(t)$ の事後分布 $p(\tilde{X}(t) | Y(t))$ を算定すれば、状態ベクトル $X(t)$ とパラメータベクトル $\Theta(t)$ を推定できる。この事後分布を推定する手法はフィルタリングとよばれる。本研究では、粒子フィルタ³⁾により事後分布の推定を行った。

b)実規模ネットワーク適用のためのフィルタリング手法

本節では、実規模ネットワークへのモデル適用のためのフィルタリング手法を述べる。前述のように提案した状態空間モデルは、粒子フィルタを用いている。粒子フィルタは、モンテカルロ近似により複雑な形状の確率分布を推定可能といった特徴を持つ。また、本研究では、逐次データを収集・処理し、リアルタイムにネットワークの交通状態推定を行う。粒子フィルタは、粒子ごとにシミュレーションを実行し、尤度を求める。そのため、マルチコアやGPU等の発展したコンピュータにより粒子フィルタを並列処理すれば、高速な処理が期待できる。しかし、粒子フィルタは、以下に述べる縮退の問題が指摘されている。粒子フィルタは、時間進展に伴い、少数の粒子の重みだけ大きくなり、その他の多数の粒子の重みはほとんどゼロになってしまう。こうなると、少数の粒子だけで確率分布(予測分布・フィルタ分布)を近似することとなり、分布の近似精度が極端に悪化する。この問題を縮退という。粒子フィルタにおいて、縮退を抑制するためには、大量の粒子を生成することが考えられる。しかし、そうすると、粒子の数を相当量用意する必要があるため、計算量が増加となる。特に、本研究で取り扱うモデルパラメータの一つであるOD需要は、組み合わせパター

ンが[起点(発生ゾーン)数]×[終点(集中ゾーン)数]×[交通量]の数だけ存在するため、パターン数が膨大となってしまう。よって、本研究では、多様な粒子パターンを逐次、生成することで、縮退を抑制する特徴を持つ融合粒子フィルタ⁴⁾を用いる。

以下に融合粒子フィルタによる事後分布の推定法を述べる。まず、粒子フィルタのアルゴリズムを述べる。

前節で定義した変数を用いて、粒子フィルタの計算ステップを以下に示す。生成する粒子のインデックスを $i=1,2,\dots,N$ とする。粒子フィルタの計算ステップは下記の通り：

- 1) 初期分布の生成： $t=0$ とし、 N 個の初期パーティクル $\{X^{(i)}(0)\}_{i=1}^N, i=1,2,\dots,N$ を生成する。
- 2) 予測： $t=t+1$ とし、ノイズ分布 $e(t)$ に従って、 N 個のシステムノイズ $\{e^{(i)}(t)\}_{i=1}^N$ を生成する。システムノイズとシステムモデルにより一期先の状態 $\{X^{(i)}(t|t-1)\}_{i=1}^N$ を予測する。
- 3) 尤度：観測ベクトルと観測ノイズにより、尤度 $\lambda^{(i)}(t) = p(Y(t)|X^{(i)}(t))$ を算定する。次に、正規化した尤度 $\beta^{(i)}(t) = \lambda^{(i)}(t) / \sum_{k=1}^N \lambda^{(k)}(t)$ を算定する。
- 4) リサンプリング： $\beta^{(i)}(t)$ の確率で、 N 個のパーティクルを復元抽出し、 $\{X^{(i)}(t|t)\}_{i=1}^N$ を生成する。
- 5) 時間更新： $t = t + 1$ とし、計算終了まで2)~4)を繰り返す。

融合粒子フィルタは、粒子フィルタの“3)尤度”のステップまでは、同様である。異なるのは、“4)リサンプリング”に代わり、Mergingと呼ばれる処理を行う点である。Mergingの処理内容を以下に示す。

$\{X^{(1)}(t|t-1), \dots, X^{(N)}(t|t-1)\}$ から各粒子 $X^{(i)}(t|t-1)$ が $\beta^{(i)}(t)$ の確率で抽出されるように $n \times N$ の粒子を復元抽出し、 $\{\tilde{X}^{(1,1)}(t|t), \dots, \tilde{X}^{(n,1)}(t|t), \dots, \tilde{X}^{(n,N)}(t|t)\}$ を生成する。次に、 $n \times N$ の粒子 $\{\tilde{X}^{(j,i)}(t|t)\}$ から n 個の粒子 $\{\tilde{X}^{(1,i)}(t|t), \dots, \tilde{X}^{(n,i)}(t|t)\}$ を取り出したうえで、各粒子の重み付き和

$$X^{(i)}(t|t) = \sum_{j=1}^n \alpha_j \tilde{X}^{(j,i)}(t|t). \quad (2.4-7)$$

を計算し、新たな粒子 $X^{(i)}(t|t)$ を生成する。これを全ての粒子 $i=1,2,\dots,N$ で実行し、 $\{X^{(i)}(t|t)\}_{i=1}^N$ を生成する。ここで、重み付き和をとる際の重み α_j は、

$$\sum_{j=1}^n \alpha_j = 1, \quad (2.4-8)$$

$$\sum_{j=1}^n \alpha_j^2 = 1. \quad (2.4-9)$$

を満たす必要がある。重み付き和をとるサンプル数 $n \geq 3$ であれば、(式2.4-11)で生成したフィルタアンサンプル $\{X^{(i)}(t|t)\}_{i=1}^N$ がフィルタ分布 $p(X(t)|Y(t))$

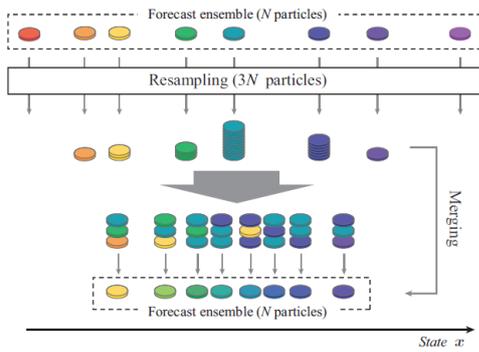


Fig. 2. Scheme of the MFF, in which the number of merging particles is set to be 3. The value of a state x is on the horizontal axis assuming that the state x is scalar.

図 2.4-1 融合粒子フィルタ

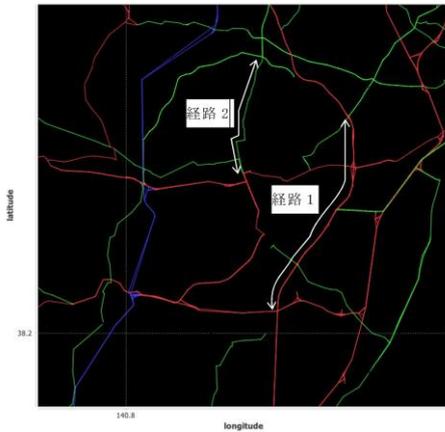


図 2.4-2 テストネットワーク

と近似的に等しい平均値と分散共分散(1次モーメント, 2次モーメント)を得ることができる. 以上の粒子の操作イメージを図 2.4-1 に示す. 同図は, N 個の粒子に対して, $n=3$ としてフィルタリングした場合の例を示している. なお, $n=1$ の場合は, 通常の粒子フィルタと同じである. $n=2$ の場合は, (式 2.4-11) の制約により, 重み α_j のいずれかを 0 にする必要があるため, 通常の粒子フィルタと同じとなる.

本稿の検証では, 既往文献^{4),5),6)}より $n=3$ とし, 重み α_j は $\alpha_1 = 3/4$, $\alpha_2 = (\sqrt{13} + 1)/8$, $\alpha_3 = (\sqrt{13} - 1)/8$ を設定した.

・検証条件

本節では, 提案モデルを検証する方法を述べる.

表 2.4-1 FD パラメータ

	maximum flow rate q_{max} [veh/h]	forward wave speed v [km/h]	backward wave speed w [km/h]
一般道	2100	70	-15
高速道路	1500	40	-10

表 2.4-2 信号現示

サイクル(sec)	青現示時(sec)	赤現示時(sec)
120	70	50

本検証では, 実規模ネットワークでの動作検証を行い, 提案モデルの有効性を検証する. ネットワークデータは, DRM3103 を用いた実ネットワークを使用した. その他の FD(Fundamental diagram), OD 交通量, 信号現示は, データが入手困難なものもあること, 及び簡単なため, 仮想データを用いた.

まず, ネットワーク条件を整理する. ネットワークを図 2.4-2 に示す. このネットワークは, DRM3103 のデータより仙台市中心部の主要地方道以上の規格の道路を抽出したものである. 道路の規格によりリンクを色分けしている. DRM のリンク数は, 2,002 である. そのリンクを元に単路部のリンクを結合し, リンク数 248 のネットワークを生成し, 検証に用いた. 状態空間モデルでは, $\Delta x = 50m$ の微小区間でリンクを分割したセルを用いた.

FD のパラメータは, 表 2.4-1 のように一般道と高速道路の 2 種類設定した. 一般道の交差点には, 信号機を設置した. 信号現示は, 全ての信号機で一律と仮定し, 表 2.4-2 のように設定した. なお, 表で示した現示は, 南北方向に対するものである. 東西方向は, 表とは青赤現示が逆となっている. OD 交通量の設定を述べる. OD 交通量の起点/終点は, 一般道の交差点をランダム選定して 50 個の OD ペアを設定した. OD 交通量は, 1) 真値と, 2) 状態空間モデルに入力するノイズの発生させた擬似 OD の 2 種類を設定した. 真の OD 交通量は, 各 OD ペアで一律とし, $q_{id} = 1200[\text{veh/h}]$, $\forall i, d$ と設定した. i, d は OD ペアの起終点ノードのインデックスである. よって, OD ペアの数 50 であるが, 交通量としては, 1 つの値 (全 OD ペア共通の値) を推定する設定としている. タイムステップごとの OD 交通量は一様分布と仮定して発生させた. 擬似 OD は, 真の OD に正規分布に従った乱数 $\varepsilon \sim N(0, \sigma_\varepsilon)$ を加えたものを 3 種類設定した. プローブデータは, OD ごとに, OD 交通量の 10% にあたる 120veh/hr をランダム抽出して設定した.

本研究では, 上記で設定したデータを用いて双子実験⁷⁾と呼ばれる手法を用いてモデル検証を行う. 双子実験の概要を述べる. まず始めに, 初期条件, 境界条件, モデルパラメータなどを設定してモデル計算を行い, その結果を“真値”と仮定する. 次に, 初期条件, 境界条件, モデルパラメータなどを全てまたは一部を真値から変更してモデル計算を行い, その結果を“シミュレーション値”とする. 観測値は“真値”の一部から観測に相当する物理量を抽出し, 作成する. そして, この観測値を“シミュレーション値”に同化して, 結果を“真値”と比較して精度検証を行う. 本研究では, 上記の双子実験の手法を踏襲してモデル検証を行う. 具体的には, 交通シミュレーションにより生成したベンチマークデータを真値として用いて擬似 OD を入力した状態空間モデルの推定値と比較検証を行う. なお, FD, 信号現示及び経路選択モデルのパラメータは, 交通シミュレーション及び状態空間モデルともに同じ値とし, OD 交通量のみ異なる状況とした.

最後に、評価方法を述べる。ネットワーク全体の推定精度の評価は、Precision(適合率)と Recall(再現率)および F 値を用いる。Precision と Recall は情報検索の有効性を示す評価指標として使われており、Precision は検索結果に適合データ(正解)がどれだけ含まれるかを示す適合率である。Recall は、適合データ全体のどれだけが検索結果に含まれているかを示すものである。そして Precision と Recall の調和平均が、F 値である。一般に、Precision と Recall は、トレードオフの関係にある。そして F 値が高ければ、モデルの性能が良いことを意味する。

本研究における Precision, Recall, F 値を以下に定義する。まず、実際の渋滞状況とモデルで推定された渋滞の関係を表 2.4-4 のように定義する。同表に示す渋滞とは、状態空間モデルのセルの平均速度が 20km/h 以下と定義する。表中の TP, FP, FN, TN は、各々に該当する場合の数(セルの総数)である。例えば、時刻 t におけるセル i の平均速度の真値 $v_i(t)$ と推定値 $\hat{v}_i(t)$ を考えよう。 $v_i(t) < 20\text{km/h}$ かつ $\hat{v}_i(t) < 20\text{km/h}$ であれば、時刻 t のセル i は TP としてカウントする。以上より、Precision と Recall および F 値を

$$\text{Precision} = \frac{TP}{TP + FP} \quad (2.4-10)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (2.4-11)$$

$$F - \text{measure} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (2.4-12)$$

と定義する。その他、擬似 OD のフィルタリング値の時系列変化を分析することで、どの程度、擬似 OD が真の OD に近づくか状態空間モデルの追従性を検証する。

c) モデル検証

本節では、モデル検証結果を述べる。

図 2.4-2 に示したネットワークに提案モデルを計算した結果、メモリーオーバー等なく、計算できた。なお、計算マシンのスペックおよび開発言語は、表 2.4-3 のとおりである。

図 2.4-3 に状態空間モデルの Precision, Recall, F

表 2.4-3 計算マシンのスペックおよび開発言語

マシン名称	MacBook Air 2020
チップ	M1 チップ
メモリ	16GB
モデル開発言語	Java

表 2.4-4 実際の渋滞状況とモデルの推定結果の関係

		真値(実際の渋滞状況)	
		渋滞	非渋滞
推定値 (モデル)	渋滞	TP (True Positive)	FP (False Positive)
	非渋滞	FN (False Negative)	TN (True Negative)

値を示す。提案モデルでは、比較的、Recall の方が大きく、0.91 となっている。これは、提案モデルが真の渋滞を 9 割程度推定していることを意味する。F 値は、0.79 となっており、提案モデルは 8 割程度の精度を担保している。

次に、状態空間モデルのフィルタリングにより、擬似 OD がどの程度、真の OD に近づくか分析する。図 2.4-4 に擬似 OD の統計量の推移を示す。このグラフでは、50 個の OD ペアの全ての粒子の 75 パーセンタイル値、中央値、25 パーセンタイル値の時系列変化を可視化している。同図を見ると、中央値は、シミュレーション開始より真値に近いものの、75 パーセンタイル値と 25 パーセンタイル値は真値から大きく乖離している。この乖離は、時間進展に伴い、減少していることがわかる。これは、フィルタリングにより、擬似 OD が、真値に近づいているためと推察される。

次に渋滞発生状況の再現性を検証する。対象は、図 2.4-2 に示す経路 1、経路 2 とした。図 2.4-5、図 2.4-6 に経路 1 及び経路 2 のタイムスペース図を示す。色の濃さは、速度を示しており、色味が濃い場所は、速度低下している状況を表す。まず、経路 1 (図 2.4-5) に着目する。当該経路は、信号機が 7 基設置された一般道である。シミュレーションと状態空間モデルのタイムスペース図を比較すると、ボトルネック交差点の位置は一致しており、また、概ね渋滞長も再現できていると思われる。経路 2 (図 2.4-6) に着目する。当該経路は、信号機が 5 基設置されている。シミュレーションと状態空間モデルのタイムスペース図を比較すると、ボトルネック交差点の位置は一致している。しかしながら、下流側の交差点の渋滞長が、若干、状態空間モデルの方が長く、上流の交差点まで延伸している。この誤差は、図 2.4-4 で示した OD 交通量の真値と推定値の乖離

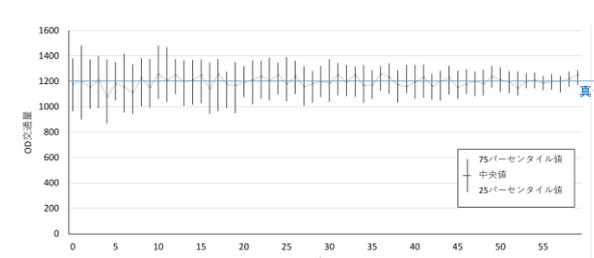
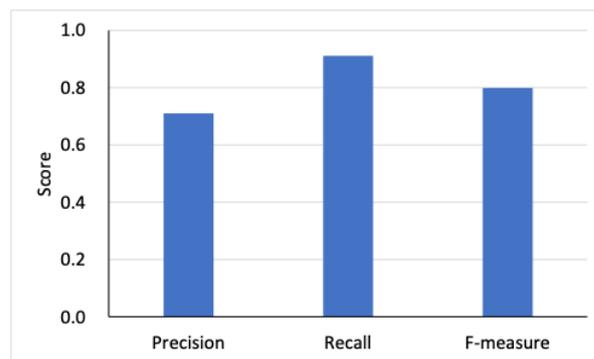


図 2.4-4 擬似 OD の統計量の推移

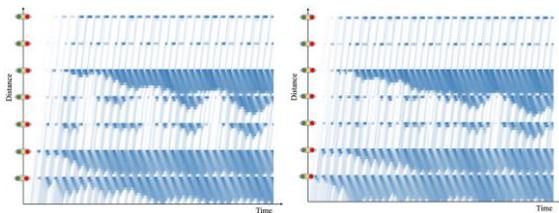


図 2.4-5 経路 1 のタイムスペース図(左：真値、右：シミュレーション値)

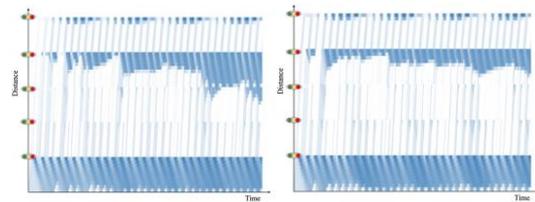


図 2.4-6 経路 2 のタイムスペース図(左：真値、右：シミュレーション値)

の影響と推察される。このように 2 次元ネットワークの場合、FD や経路選択モデルが真値と同じであっても OD 交通量の誤差により、真値と推定値に乖離が生じる。今後は、検証事例を拡充し、モデルの性質を明らかにするとともに、精度向上を図るためのモデル改良が必要と考える。

d) まとめと今後の課題

本研究では、過去に提案した 2 次元状態空間モデルのフィルタリング手法を改良し、仙台市の DRM 用いた大規模ネットワークに適用した。その結果、大規模ネットワークにおいても提案モデルは、メモリーオーバーなく、実行できた。また、OD 交通量の推定値の追従性に注目すると、フィルタリングにより、状態空間モデルに入力した擬似 OD は、真の OD に近づいていることが確認された。また、特定経路の渋滞状況の再現性を検証した結果、ボトルネック交差点の位置がシミュレーションと推定値で一致したことを確認した。しかし、経路途中の渋滞に若干の乖離があるといった新たな課題も確認された。

今後の課題を以下に整理する。本稿では、1 ケースのみモデル検証を実施した。今回のモデル検証結果に一般性を持たせるには、ネットワーク形状や OD 交通量の発生パターン、観測プローブデータの取得パターン等を変更させたケースを追加することが望ましい。そして、検証事例の分析結果を踏まえ、モデルの性質を明らかにするとともに、精度向上を図るために更なるモデル改良が必要と考えられる。また、今回は、FD や経路選択モデルがシミュレーションと状態空間モデルで完全に一致するという強い仮定をおいた。実際は、経路選択行動や FD パラメータは不明な場合が多いと考えられる。よって、FD や経路選択モデルのパラメータと推定精度の感度分析を行う必要があると考える。

2.4.1 の参考文献

- 1) Kawasaki, Y., Hara, Y. and Kuwahara, M. : Real-Time Traffic State Estimation on a Two-dimensional Network

- by State Space Model, Transportation Research Part C: Emerging Technologies, Vol.113, pp.176-192, 2020
- 2) Kitagawa, G. : A self-organizing state-space model, Journal of the American Statistical Association, Vol. 93, pp. 1203–1215, 1998
- 3) Kitagawa, G.: Monte Carlo filter and smoother for non-Gaussian nonlinear state space models, Journal of Computational and Graphical Statistics, Vol. 5, No. 1, pp. 1-25,1996.
- 4) Nakano, S., Ueno, G. and Higuchi, T. : Merging particle filter for sequential data assimilation, Nonlinear Processes in Geophysics, 14, pp.395–408, 2007.
- 5) 中野慎也, 上野玄太, 中村和幸, 樋口知之 : Merging Particle Filter とその特性, 統計数理, Vol.56, No.2, pp.225-234, 2008.
- 6) 樋口知之, 上野玄太, 中野慎也, 中村和幸, 吉田 亮 : データ同化入門—次世代のシミュレーション技術—, pp.47-77, 朝倉書店, 2011.
- 7) 淡路敏之, 蒲地政文, 池田元美, 石川洋一 編著 : データ同化 観測・実験とモデルを融合するイノベーション, 京都大学学術出版会, 2009.

第3章 非日常の事前アラート発信手法の構築

3.1 降雪による車両スタック発生事前アラート条件の検討

(1) スタック事象判別のための機械学習手法

冬季のスタックや立ち往生に関わる事前アラートの判別手法を確立するため、スタック事象を判別するための説明変数を抽出し、機械学習などにより事前アラートに用いるための交通状態、気象、地形の条件設定を行う。また、状態空間モデルによる異常事象の発生危険性評価手法に関しては、アラート精度の向上を検証するとともに、モデルを改良し近未来の異常事象の発生危険性を予測可否について検討を行う。

・分析の対象としたスタック事例

気象災害時の交通障害に関わる事前アラートは、道路上でのスタックの発生を想定し検討を行う。道路上で発生するスタックは、主に降積雪による車両の立ち往生や長時間の滞留によることが多いので、大雪に伴う冬期のスタックを対象として扱う。そこで、平成30年度に収集した以下のスタック・立ち往生事例を機械学習の対象とする。

災害概要：東北地方整備局管内の直轄国道上で発生した大雪や吹雪によるスタック

収集期間：2018年1月1日～2月28日、2019年1月1日～2月28日

事例数：189件

(2) スタック・立ち往生の発生時の機械学習に用いたデータ

a) 気象データ

降積雪時のスタック・立ち往生の発生に大きく関係する説明要因は降雪量であるが、降雪量の観測データは積雪寒冷地の気象庁アメダスや気象官署に限られる。そこで、スタック発生時の気象データとして、平成30年度に解析した1kmメッシュの降雪量データを用いる。以降に降雪量データの解析方法を示す。

使用データ：降水量—気象庁解析雨量（約1kmメッシュ）

気温—気象庁局地数値予報モデル（LFM, 約2kmメッシュ）

降雪量変換：

①対象メッシュ（1km）に対し、気温データから雨雪判別を実施

②降雪と判断された場合、雪水量換算式により雪水比を決定

③対象メッシュの降水量から雪水比により降雪量に換算

こうして得た降雪量データに加えて、気象庁局地数値予報モデルから得た気温をスタック発生事例の解析に用いた。

b) 交通状態データ

降積雪時のスタック・立ち往生の発生の有無にかかわる交通状態データとして、車の位置情報と速度情報からなるプローブデータから、1kmメッシュ単位で5分毎に解析した次のデータを解析に用いた。

①メッシュ平均速度（km/h）

②メッシュ平均台数（台/km）

③特異指数

このうち、特異指数は1kmメッシュ内のプローブデータの走行距離と走行時間を交通状態量として集計し、過去の一定期間の状態量分布に対して、統計的にどの程度稀な状態なのかを情報量として指標化した値である。この特異指数はその1kmメッシュ内の走行速度と走行台数を複合的に表した指標として考えることができ、スタック・立ち往生の発生に大きくかかわる指標として扱った。

c) 地形データ

降積雪時のスタック・立ち往生の発生に大きく関わる地形データとして道路勾配を考慮する。スタック・立ち往生発生箇所の平均的な道路勾配を扱うため、発生箇所を含む1km区間の前後の標高差から勾配を算定する。具体的には発生箇所を含む1km区間に対し、前後のKPの緯経度情報を基に10mDEM地形データから標高を抽出することで、道路勾配を算定した。

d) スタック・立ち往生の非発生データ

降積雪時のスタックや立ち往生の発生要因を解明するためには、スタックや立ち往生の発生時だけでなく、これと対比するための非発生データも必要となる。そこで、スタック・立ち往生の非発生事例として次の事例の気象条件、交通状態データ、地形データを用いた。

・スタック発生箇所の同路線かつ同日時で、前後5kmのキロポストでのデータ

- ・スタック発生箇所におけるスタック発生 1 週間前の同時刻のデータ

スタック発生箇所の緯経度が同定できなかつたり、説明変数に欠損があつたりする場合があります。これらを除いて機械学習を行った。その結果、機械学習を行ったスタック発生データは 95 事例、非発生データは 238 事例である（全 333 事例）。

(2) スタック・立ち往生発生有無の機械学習

a) 気象・交通・地形データによる機械学習

スタック・立ち往生に関わる降雪量は当該時刻 1 時間の値(1 時間降雪量)だけでなく、それまでに降った雪の量も関係すると考えられる。そこで、1 時間降雪量のほか、3 時間降雪量、6 時間降雪量、12 時間降雪量、24 時間降雪量も算定した。また、平均勾配は車両の進行方向を加味した値と、進行方向を加味しない勾配として符号を除いた絶対値の 2 つを用いる。したがって、気象・交通・地形データに用いた説明変数は表 3.1-1 の通りである。

・決定木による機械学習

機械学習では全 333 事例のうち、ランダムに抽出した 80% のデータを学習データに使い、残りの 20% のデータを検証用に用いた。この機械学習による決定木を図 3.1-1 に示す。この決定木の予測精度は、検証用の未学習データに対しては 74.63%、学習データに対しては 78.20% であつた。

この決定木では、まず特異指数で判別される。特異指数が 20.651 を超え、3 時間降雪量が 1.4cm 以上

表 3.1-1 気象・交通・地形データによる機械学習に用いた説明変数

種別	説明変数	略称 (決定木での略称)
気象データ	1 時間降雪量 (cm)	snowfall.1H
	3 時間降雪量 (cm)	snowfall.3H
	6 時間降雪量 (cm)	snowfall.6H
	12 時間降雪量 (cm)	snowfall.12H
	24 時間降雪量 (cm)	snowfall.24H
	気温 (°C)	temp
交通状況データ	メッシュ平均速度 (km/h)	speed
	メッシュ平均台数 (台)	N
	特異指数	SI
地形データ	平均勾配 (標高差 m/1000m)	slope.1
	平均勾配 (標高差 m/1000m, 絶対値)	slope-abs

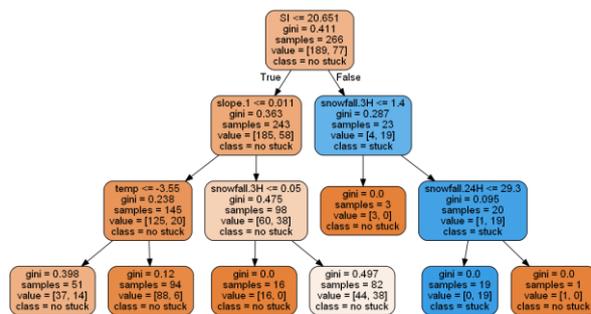


図 3.1-1 気象・交通・地形データによる機械学習結果 (決定木)

かつ 24 時間降雪量が 29.3cm 以下の場合のみスタック発生と判定される。3 時間降雪量 1.4cm 以上は日常的にありうる降雪量である。また、決定木の右端の 24 時間降雪量 29.3cm 超は 1 事例(スタックなし)であり、24 時間で約 30cm を超える降雪があるとスタックが発生しにくいとは考えにくいので、偶発的な事例による分岐と考えられる。そのため、この決定木に従うと、降雪時のスタックの発生は特異指数のみによって判定されてしまうという意味合いを持つ。

また、この決定木では特異指数が 20.651 以下であれば、どの条件であってもスタックの発生はなしと判定される。2 つめの分岐で、平均勾配 0.011 (勾配約 1%) を超える上り坂の場合には、3 時間降雪量が 0.05cm 以上でスタックの発生割合が多くなるものの、平均勾配はスタックの発生判別に影響しない。

上記の点から、この決定木を事前アラートの判別条件に用いるには課題が多い。

b) 気象・交通データによる機械学習

前述の気象・交通・地形データによる機械学習の結果をリアルタイムモニタリング・アラートシステムに実装する場合、地形データとして全ての道路の 1km 区間に対して、平均勾配データを整備する必要があり、現実的には難しい。また、前述したように、平均勾配はスタックの発生有無の判別の大きな影響を与えなかった。そこで、気象データと交通データのみを説明変数 (表 3.1-2) としてスタック・立ち往生発生有無の条件を検討した。

・決定木による機械学習

決定木による機械学習では全 333 事例 (発生 : 95 事例, 非発生 : 235 事例) を学習に用いた。その結果

表 3.1-2 気象・交通・地形データによる機械学習に用いた説明変数

種別	説明変数	略称 (決定木での略称)
気象データ	1 時間降雪量 (cm)	snowfall.1H
	3 時間降雪量 (cm)	snowfall.3H
	6 時間降雪量 (cm)	snowfall.6H
	12 時間降雪量 (cm)	snowfall.12H
	24 時間降雪量 (cm)	snowfall.24H
	気温 (°C)	temp
交通状況データ	メッシュ平均速度 (km/h)	speed
	メッシュ平均台数 (台)	N
	特異指数	SI

を図 3.1-2 に示す。学習データによるこの決定木の精度は 82.08% で、スタックの発生に対するスレッドスコアは 42.9% であった。

図 3.1-2 の決定木ではスタック事例 45 事例は発生に判定されるが、残り 50 事例は非発生と判定され分離されない。また、第 1 分岐にメッシュ平均速度が選択されることから、都市部のように普段から交通が混雑している区間では、容易にスタック発生と判定される恐れがある。そこで、その区間のメッシュ平均速度に依存しないよう、表 3.1-2 の説明変数からメッシュ平均速度を省いて機械学習を試したのが図 3.1-3 である。学習データによる決定木の精度は 91.98% で、スタック発生に対するスレッドスコアは 37.9% であった。

その結果、最初に特異指数で判別され、特異指数が 32.121 を超える場合に 3 時間降雪量または気温で判別される。図 3.1-3 の上下の決定木は同じ学習データから得たものであり、スタックの発生有無の判定は 3 時間降雪量でも気温でも同じ判別となっている。これは、特異指数 32.121 を超える 18 事例のうちスタックが発生した 15 事例は、いずれも 3 時間降雪量が 1.4cm を超えかつ気温が 0.25℃ 以下であったと解釈できる。また、特異指数が 32.121 以下の場合には、気温が -5.65℃ 以下で 24 時間降雪量が 18.3cm 以上の時にスタック発生と判別される。

・ランダムフォレストの検討

ここで表 3.1-2 の説明変数を用いて、多数の決定木によるアンサンブル手法であるランダムフォレストを試してみる。ランダムフォレストでは、決定木の数 (5, 10, 20) と枝である木の深さ (3, 5, 10) を組み合わせて、妥当な決定木と枝の数を検討した。また、全データからランダムに抽出した 50% のデータを学習データ (訓練データ) とし、残りの 50% を検証データ (テストデータ) として、それぞれの精度と各説明変数の特徴量の重要度を分析した。その結果を図 3.1-4 に示す。

訓練データの精度は決定木に数が多く木が深いほど精度は向上するが、テストデータの精度は決定木の数を多くしても精度はあまり向上しない。一方、木が深いほどテストデータの精度は向上するものの、木の深さが 5 以上では精度は頭打ちのようにも見える。

また、特異指数はいずれの機械学習でも特徴量の重

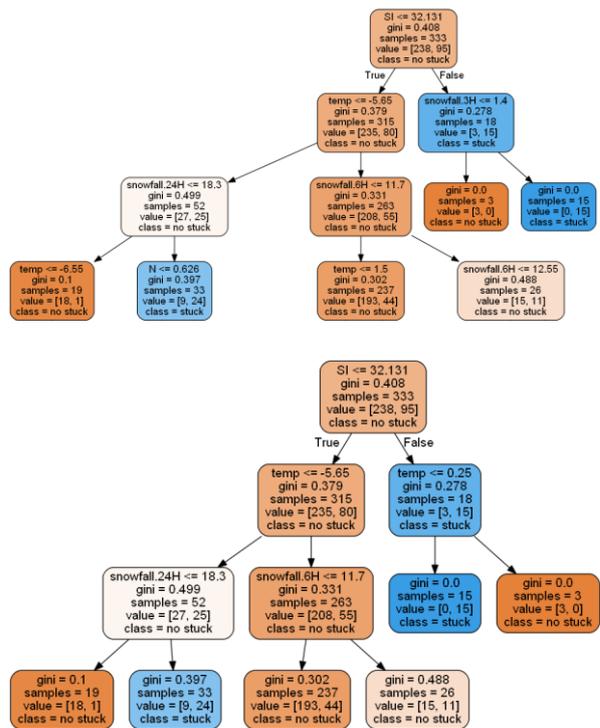


図 3.1-3 メッシュ平均速度を省いた気象・交通データによる機械学習結果 (決定木)

要度が大きく、これに次いでメッシュ平均速度や気温の特徴量の重要度が大きい。各降雪量の特徴量では、決定木の数が少ないと 12 時間降雪量の重要度が大きく、決定木の数を多くすると 6 時間降雪量の重要度が大きくなる。1 時間降雪量や 3 時間降雪量より 6 時間以上の降雪量の方が、特徴量の重要度が大きい傾向にあり、スタックの発生の有無には長時間に降った雪の量も関係していることを示唆していると考えられる。

c)降雪量の地域特性を加味した機械学習地域による降雪量の違いの扱い

前節まで検討した機械学習の結果をリアルタイムモニタリング・アラートシステムに実装し、全国的に展開した場合、地域性は加味されず全国一律の条件となる。特に、降雪量に関しては同じ基準値での判断となるため、基準値の設定によっては積雪寒冷地域でアラートが多発したり、あまり雪の降らない少雪地域ではアラートが発出されることがなかつ

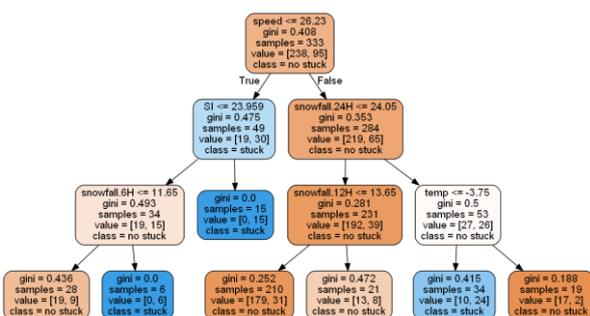


図 3.1-2 気象・交通データによる機械学習結果 (決定木)

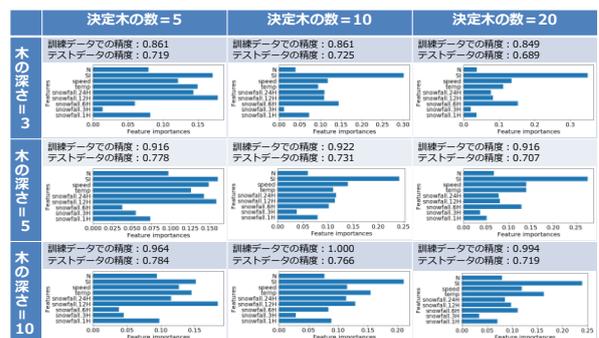


図 3.1-4 気象・交通データによるランダムフォレストの検討結果、特徴量

たり、実態に合わなくなる恐れがある。積雪寒冷地域と少雪地域では、同じ降雪状況であっても道路交通への影響度合いが異なることが予想される。そのため、地域による降雪量の違いを加味する必要があり、年間の平均降雪量を説明変数に加味した。

年間の平均降雪量は、日本気象協会が独自に保有する2010年度～2019年度の10冬期（各年は11月～翌4月）の降雪量1kmメッシュデータ（3次メッシュ）から、年間の平均降雪量を1kmメッシュで統計した値を用いた。東北管内の直轄国道で発生した降積雪時のスタック事例を機械学習に用いている。そのスタック事例の発生箇所および非発生箇所の年間平均降雪量は図3.1-5に示すように、100cm以下～1000cm以下を中心に幅広く分布し、地域による降雪量の違いをある程度加味できると考えられる。

・機械学習に用いた説明変数

地域による降雪量の多少を考慮する目的で、これで説明変数に用いてきた3時間降雪量、6時間降雪量、12時間降雪量、24時間降雪量に対して、年平均降雪量に対する割合を説明変数に加えた。これによって、学習データに用いた事例それぞれに対して、説明変数である降雪量とその区間にとってどのくらい多量なのかの地域性を表現できると考えられる。その結果、機械学習に用いた説明変数は表3.1-3の通りとした。

・決定木による機械学習

機械学習による決定木を図3.1-6に示す。この機械学習では全333事例（発生：95事例、非発生：235事例）を学習に用いた。学習データによるこの決定木の精度は81.68%で、スタック発生に対するスレドスコアは47.0%であった。学習データによる精度は、前述までの機械学習結果と大差ないがスレドスコアは向上しており、空振りや見逃しが少なくなったことを意味している。

図3.1-6の決定木では、図3.1-4と同様にまずメッシュ平均速度26.23km/hで判別され、メッシュ平均速度が26.23km/hを超える場合の判別条件は、地域性は考慮されず図3.1-3と同じ判別である。メッシュ平均速度が26.23km/h以下の場合、24時間降雪量が年平均降雪量の2.715%を超えるとスタックと判別される。また、24時間降雪量が年平均降雪量の2.715%以下であれば、特異指数が28.402を超えた場合にスタック発生と判別され、これ以外はスタックの発生はなしとなる。

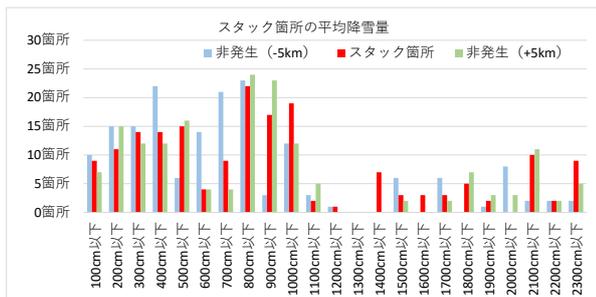


図 3.1-5 機械学習に用いたスタック発生・非発生箇所の年平均降雪量

表 3.1-3 気象・交通・地形データによる機械学習に用いた説明変数

種別	説明変数	略称（決定木での略称）
気象データ	1時間降雪量 (cm)	snowfall.1H
	3時間降雪量 (cm)	snowfall.3H
	6時間降雪量 (cm)	snowfall.6H
	12時間降雪量 (cm)	snowfall.12H
	24時間降雪量 (cm)	snowfall.24H
	3時間降雪量÷年平均降雪量 (%)	snowfall.3H/year
	6時間降雪量÷年平均降雪量 (%)	snowfall.6H/year
	12時間降雪量÷年平均降雪量 (%)	snowfall.12H/year
	24時間降雪量÷年平均降雪量 (%)	snowfall.24H/year
気温 (°C)	temp	
交通状況データ	メッシュ平均速度 (km/h)	speed
	メッシュ平均台数 (台)	N
	特異指数	SI

一見、地域性が反映された学習結果に見えるが、気象庁資料による年降雪量の平年値を基に、その2.7%に相当する降雪量を計算すると次のようになる。

札幌：年降雪量の平年値 597cm×2.7% = 16cm

仙台：年降雪量の平年値 71cm×2.7% = 2cm

東京：年降雪量の平年値 11cm×2.7% = 0.3cm

これらの都市で24時間降雪量がこの値を超えることは珍しくはなく、これとメッシュ平均速度26.23km/hのみでの判定はアラートの発出が極めて多くなる恐れがある。特に、東京のように普段はあまり雪の降らない地域を想定すると、わずかな降雪によって混雑した都市でアラートが頻発してしまうことが容易に想像できる。

ここで、機械学習に用いたスタック事例を確認すると、大雪によるスタックだけではなく路面凍結に起因したスタック事例も含まれている可能性がある。滑りやすい凍結路面でも前日までの降雪などに起因しているが、当日の降雪に伴う大雪に着眼した機械学習の方が、豪雪時のスタック検知として相応しいと考えられる。そこで、機械学習に用いるスタックデータを24時間降雪量5cm以上の事例にのみ絞ることにした。

表3.1-3の説明変数を用いて、24時間降雪量5cm以上のスタック事例（発生：71事例、非発生：213事

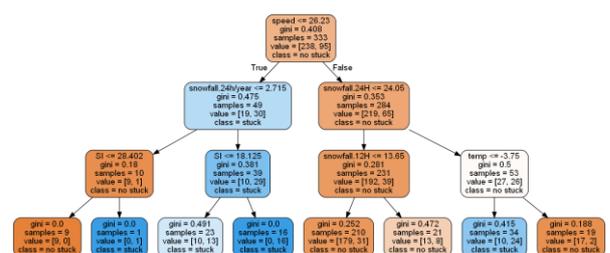


図 3.1-6 地域による降雪量を加味した気象・交通データによる機械学習結果(決定木)

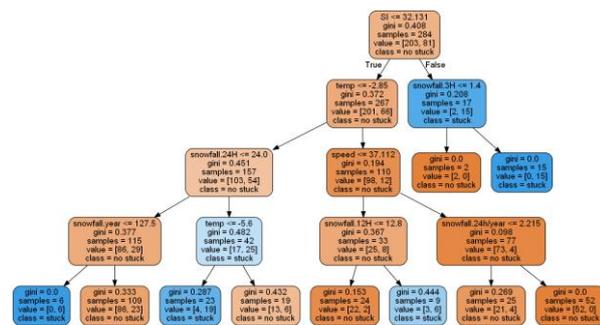


図 3.1-7 地域による降雪量を加味し、気象・交通データによる機械学習結果（決定木）（24 時間降雪量 5cm 以上のスタック事例）

例）で機械学習を行った結果が図 3.1-7 である。学習済みデータによるこの決定木の精度は 85.27%で、スタック事例に対するスレッドスコアは 52.3%であった。この結果は、これまでの機械学習の結果よりも優れている。

この決定木でスタックと判定される条件は以下の 4 つである。

- (1) 特異指数が 32.131 を超え、3 時間降雪量が 1.4cm 以上の場合
- (2) 特異指数が 32.131 以下で、気温が -2.85°C を超え、メッシュ平均速度が 37.112km/h 以下、12 時間降雪量が 12.8cm 以上の場合
- (3) 特異指数が 32.131 以下で、24 時間降雪量が 24cm を超え、気温が -5.6°C 以下の場合
- (4) 特異指数が 32.131 以下で、24 時間降雪量が 24cm 以下で、年平均降雪量が 127.5cm 以下の地域の場合

(1)の条件はある程度の降雪がある中で交通の流れが特異状態にあるとき、(2)の条件は交通の流れは特異的ではないがまとまった降雪があり低速状態になったときを意味しており、交通と降雪の両者を加味した条件と捉えることができる。(3)の条件は厳しい低温下の中での大雪時を意味し、(4)の条件は少雪地域での低温化での降雪時を意味していると解釈できる。このように、降雪に伴うスタックの発生条件として合理的な条件として理解しやすいと考えられる。

図 3.1-8 にこの機械学習に用いた各説明変数の特徴量の重要度を示す。交通データではメッシュ平均速度 (speed) より特異指数 (SI) の特徴量の重要度が大きい。気象データでは気温 (temp) は 24 時間降雪量 (snowfall.24H) の特徴量の重要度が大きい傾向にある。また、地域性を考慮して設けた年平均降雪量の特徴量の重要度も大きく、地域性がある程度考慮された機械学習結果といえる。

・ランダムフォレストの検討

次に、ランダムフォレストを試し、決定木の数 (5, 10, 20) と枝である木の深さ (3, 5, 10) を組み合わせて、妥当な決定木と枝の数を検討した。ここでは全データのうち、70%を学習データ (訓練データ)、残り 30%を検証データ (テストデータ) としてランダムフォレストを検討した。図 3.1-9 は降雪の有無にかかわらず全 333 件のデータに対して検討したも

のであり、図 3.1-10 は 24 時間降雪量 5cm 以上のデータ 284 件に絞って検討した結果である。いずれも、図中に訓練データとテストデータによる精度と各説明変数の特徴量の重要度を決定木の数、木の深さとともに示している。

全データを扱った場合と 24 時間降雪量 5cm 以上に絞った場合の両者とも決定木を増やし、木を深くした方が精度は向上している。全データを基にランダムフォレストを試した結果では、特異指数 (SI) の特徴量の重要度が際立って大きく、次いで気温 (temp) や年平均降雪量 (snowfall.year) の特徴量の重要度が高く、降雪量の重要度は全般に大きくない。

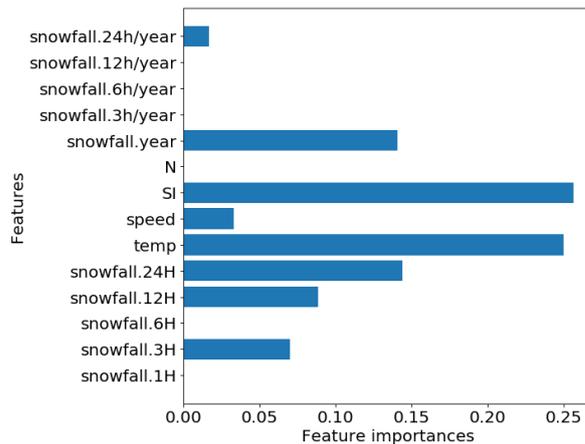


図 3.1-8 機械学習に用いた気象・交通データの特徴量の重要度 (24 時間降雪量 5cm 以上のスタック事例)

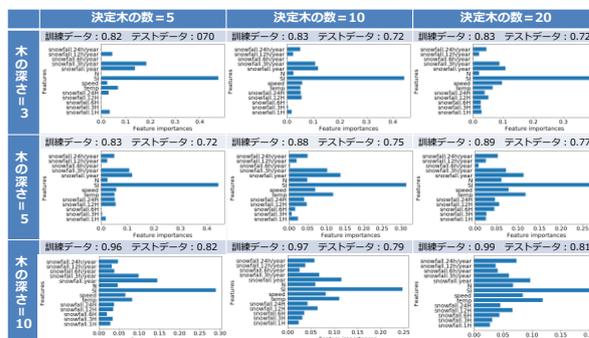


図 3.1-9 地域による降雪量を加味したランダムフォレストの検討結果、特徴量

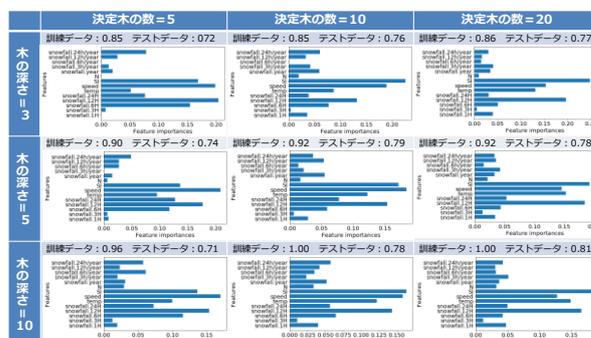


図 3.1-10 地域による降雪量を加味したランダムフォレストの検討結果、特徴量 (24 時間降雪量 5cm 以上のスタック事例)

一方、24 時間降雪量 5cm 以上の降雪時に絞ったランダムフォレストでは、特異指数 (SI) やメッシュ平均速度 (speed)、気温 (temp)、12 時間降雪量 (snowfall.24) の特徴量の重要度が大きく、この 4 つの説明変数に依存した学習結果といえる。また、年平均降雪量を考慮した各降雪量の特徴量の重要性も小さくない。

これらの結果から、学習データを 24 時間降雪量 5cm 以上の降雪時に絞ることで、合理的に説明しやすいスタック発生条件として扱えるものと考えられる。

d)スタック事象判別のためのアラート発信条件の検討

前述した機械学習によって得た決定木からスタック事象判別のためのアラート発信条件を検討する。まず、気象・交通データから得た図 3.1-2 の決定木からアラート発信条件を考えると、図 3.1-11 の図 3.1-12 の条件に整理できる。ここで、各条件の判別値は決定木のラウンド値として整理した。

このとき、アラート条件は 6 時間降雪量が 12cm 以上でメッシュ平均速度が 26km/h 以下であり、まとまった降雪を伴う低速条件を意味している。多雪地では 6 時間降雪量 12cm 以上の降雪は珍しくはなく、普段から交通が混雑する多雪地の市街地では容易にアラート条件に達することが予想される。アラート条件は 24 時間降雪量が 24cm 以上、気温が-4℃以下でメッシュ平均速度 26km/h 以上であり、郊外部で低温・大雪であればアラート条件に達してしまう。気象の厳しさに比重がおかれている一方、東北や北海道のような寒冷地域の郊外部で容易にアラート条件に達する可能性がある。アラート条件③はメッシュ平均速度 26km/h かつ特異指数 24 以上であり気象条件を一切加味しないという課題がある。

図 3.1-12 はメッシュ平均速度を除いた気象・交通データによる機械学習で得た決定木(図 3.1-3)を基に整理したアラート発信条件である。前述の条件と同様に、条件値は決定木の判別値を基にラウンド値として整理したものである。

このときのアラート条件は 2 つに整理される。アラート条件は特異指数 32 以下で 24 時間降雪量 18cm 以上かつ気温-5℃以下であり、低温下での大雪に比重がおかれている。低温下での大雪であれば容易にアラート条件に達する恐れがある。また、アラート条件②は特異指数 32 以上で、3 時間降雪量 1cm 以上かつ気温が氷点下であり、交通流の特異性に比重がおかれている。気象条件はかなり緩めであり、わずかな降雪でアラート条件に達する点が大きな課題である。

以上のように図 3.1-2 および図 3.1-3 の決定木を基にスタック事象の判別条件を検討したが、いずれもリアルタイムモニタリング・アラートシステムに実装するには課題があるといえる。一方、地域による降雪量の違いを考慮し、降雪を伴うスタック事例のみに絞って機械学習を行った図 3.1-7 の決定木は各枝の分岐条件が理解しやすく、この方が実装に適

アラート条件	降雪量	気温	メッシュ平均速度	特異指数	課題
①	6時間降雪量 12cm以上		26km/h 以下		低速かつ降雪量の条件としてはあまり厳しくない。 アラートが出やすい
②	24時間降雪量 24cm以上	-4℃ 以下	26km/h 以上		気象の厳しさに比重がある条件(交通は流れているが気象が厳しい)となる。 低温下での大雪でアラートが出やすい
③			26km/h 以下	24以上	気象に関係しない。低速で特異な交通状態を検知する。 冬期でなくてもアラートが出る

図 3.1-11 機械学習結果を基にしたアラート発信条件と課題 (気象と交通状況によるアラート発信条件)

アラート条件	降雪量	気温	特異指数	課題
①	24時間降雪量 18cm以上	-5℃ 以下	32以下	低温下での大雪に比重がおかれた条件になっている。 気象が厳しければアラート
②	3時間降雪量1cm 以上	0℃ 以下	32以上	特異指数が高ければ、わずかな降雪でアラートが出る。 アラートが出やすい

図 3.1-12 機械学習結果を基にしたアラート発信条件と課題 (メッシュ平均速度を除いた交通状況と気象条件によるアラート発信条件)

しているように見える。

この決定木(図 3.1-7)を基にアラート条件を整理したのが表 3.1-4 である。ここで各条件は決定木の判別値を参考に設定した。なお、一部の設定値は減少の意味合いや出現性から値を多少調整した。

ここで、実証実験中の 2020 年 12 月 17 日に東北地方整備局が管理する国道 48 号で大雪時に登坂不能車によるスタックが発生し、以下の通行止めが生じた(図 3.1-13)。

- ・路線：国道 48 号
- ・区間：山形県東根市観音寺交差点～宮城県仙台市青葉区作並チェーン着脱場
- ・期間：2020 年 12 月 17 日 14:30～19:00

この交通障害を対象に表 3.1-4 のアラート発信条件の適用性を検証した。通行止めはスタックの発生後に道路管理者がとった措置であるから、登坂不能車によるスタックの発生は通行止めの開始時刻より早い時間である。そこで、登坂不能車の発生から通行止め開始に至るまでの時間を仮に 3～4 時間程度とすると、11 時～15 時の間でアラート条件に達しているのが望ましいと考えることができる。



図 3.1-13 国道 48 号でのスタックによる通行止め区間 (2020 年 12 月 17 日)

表 3.1-4 機械学習結果を基にしたアラート発信条件
(降雪量の地域特性を加味)

条件	メッシュ 平均速度	特異指数	年平均 降雪量	3時間 降雪量	12時間 降雪量	24時間 降雪量	気温	備考
①	-	32以上	-	2cm以上	-	5cm以上	-	決定木より
②	37km/h未満	32未満	-	-	15cm以上	-	-3°C以上	決定木より
③	-	32未満	-	-	20cm以上	-	-6°C以上 -3°C未満	決定木に関わらず新設
④	-	32未満	-	-	-	25cm以上	-6°C未満	決定木より
⑤	-	32未満	130cm未満	-	-	5cm以上	+3°C未満	決定木より

表 3.1-5 国道 48 号でのスタック発生時の検証結果か
ら改良したアラート発信条件

条件	メッシュ 平均速度	特異指数	年平均 降雪量	3時間 降雪量	12時間 降雪量	24時間 降雪量	気温
①	-	35以上	-	8cm以上	-	-	-
②	20km/h未満	35未満	-	-	15cm以上	-	-3°C以上
③	-	35未満	-	-	25cm以上	-	-5°C以上 -3°C未満
④	-	35未満	-	-	-	25cm以上	-5°C未満
⑤	-	35未満	130cm未満	-	-	5cm以上	-3°C未満

図 3.1-14 は実証実験時にリアルタイムモニタリング・アラートシステムが使用または解析した気象・交通データを表 3.1-4 の条件で判別させて、1km 毎に毎時のアラート判別結果を表示したものである。図中の赤枠は通行止めが実施された区間と時刻を示し、青字はアラートが判別されるべき区間と時刻の範囲を示している。また、図中の丸数字は達した表 3.1-4 のアラート条件を示し、空欄はどのアラート条件にも該当しない（非発生）ことを意味する。

その結果、スタックの発生リスクが高まっていたと考えられる青枠の範囲でアラート条件①、③に達していた区間・時間帯は多くみられているが、それ以前の時間帯や前後の区間でもアラート条件①、③に達していることが多い。実際に他の時間帯や前後の区間でスタックの発生リスクが高かった可能性は否定できないが、アラートの発信としては過多といえる。また、通行止め区間の起点側（仙台側）ではアラート条件に達した区間がいくつも見られる。そこで表 3.1-4 の各アラート条件を表 3.1-5 のように見直した。表中の赤字が修正したアラート条件である。アラート条件の見直しは次の観点で検討した。

- アラート条件①：特異指数はラウンド値として 35 とし、短時間での強い降雪を意識し 3 時間降雪量 8cm とした（1 時間に約 3cm の降雪が連続する条件）
- アラート条件②：普段から交通が混雑しやすい都市部を意識し速度条件を引き下げた
- アラート条件③：本来、決定木にはない条件であり、スタックの発生リスクは少ないと考え、12 時間降雪量の条件を引き上げた
- アラート条件④：アラート条件③の降雪量条件を引き上げた代わりに、気温条件を少し引き上げアラート条件④に含めた
- アラート条件⑤：特異指数のほかは修正なし



図 3.1-14 国道 48 号でのスタック発生事例に対する条件の検証結果



図 3.1-15 国道 48 号でのスタック発生事例に対する表 3.1.1-5 の条件の検証結果

図 3.1-15 は表 3.1-5 のアラート条件を 12 月 17 日の通行止め事例に適用した場合のアラート発信状況である（図の見方は図 3.1-14 に同じ）。この結果、通行止め区間外でアラート条件に達する区間は多少見られるが、図 3.1-14 よりその区間は激減している。通行止めとなった区間に着目すれば、8 時以降にアラート条件に達した区間が多くなり、11 時～12 時は通行止め区間の大部分でアラート条件に達し、スタックの発生リスクの高まりを表現できているように見える。

実際のスタック事例での検証はこの 1 例に限られるが、機械学習結果を用いたスタック事象の判別条件としては、表 3.1-5 の条件が適当と考える。

3.2 状態空間モデルを用いたスタック発生危険性のアラート手法の構築

(1) 研究概要

我が国では、近年非常に強い降雪が、集中的かつ継続的に発生している。その降雪の影響によって道路ネットワークが長期間に渡って麻痺し、社会的に大きな影響を与えている。国土交通省によると、2015年に国道で発生した立ち往生車両数は547台以上であり、その影響による通行止め区間の長さは1,670km、通行止め時間は1,100時間以上と報告されている¹⁾。これらの被害を受けて、国土交通省は、大雪時に交通渋滞や立ち往生を起こさないようにするために、高速道路や国道を早めに通行規制する「予防的通行止め」²⁾の導入を進めている。

以上に示したとおり、冬季道路における異常事象の発生リスクを評価することの重要性は高まっている。異常事象のリスクを適切に評価できれば、道路管理者の迅速な判断、対応をサポートでき、予防的通行止めや集中的な除雪、融雪剤の散布、異常事象発生後の迅速な救助、復旧に貢献できると考えた。

これまでの冬季道路の交通管理における除雪や通行止めの判断は、天気予報や過去の立ち往生実績、CCTV等の固定センサーを基にした道路管理者の経験に頼っており、動的に変化する交通状況を踏まえた定量的な指標は持ってこなかった。また、これら従来の方法は、監視範囲や監視時間に制約がある。特に一般道は高速道路と比較して、監視延長が長く、不可視区間が存在すること、車両の行動が複雑であること、固定センサーの維持コストが膨大になることなど課題が多い。

そこで、近年データ数が増加し、広範かつ常時データの収集が可能なプローブ車両に着目し、冬季一般道における異常事象の発生危険性を動的かつ定量的に評価できる手法の検討を行った。ここで、本研究の目的は、立往生の発生を予測することではなく、現時点の立ち往生のリスクを評価しようとしていること、現在の監視体制(気象データ中心)を、提案手法で置き換えることではなく、現体制を(交通データを加味して)サポートする手法の提案を目的としていることを強調したい。

以上のように、本研究で提案する手法は、道路管理実務をサポートすることを目指しているため、以下の要件を満たす必要がある。

① 欠測値への対応：プローブ車両は、近年データが増加しているものの、山間部や夜間などではデータが少なく、1台も観測されない場合がある。ARIMAモデル等の古典的な時系列モデルでは、データに欠測がある場合の対応が課題(欠測値の補間方法やパラメータ推定)となる。本研究で提案する手法は、様々な場所への適用を目指しているため、欠測値への対応が容易である必要がある。

② ノイズの考慮：センシング情報は、不確実なノイズを伴う。本研究で使用するプローブ速度データも様々なノイズ(e.g.運転者や車両特性、GPS誤差等)を

伴って観測されていると考えられる。このノイズを考慮しない場合、実際の状態と観測値との乖離が大きくなり、評価精度が低下する可能性がある。

③リアルタイム処理：道路管理者が立ち往生に対応(除雪や通行止め)するためには、立ち往生の発生リスクが高い状況を早期に通知する必要がある。ある程度のデータが蓄積されてから処理を行う一括処理よりも、新たなデータが得られる度に逐次的に処理が可能な方法である必要がある。

④モデル構造・結果の解釈の容易性：道路管理に活用するためには、単に立往生リスクの評価を行うだけでなく、モデルのメカニズムを理解し、立往生を未然に防ぐための方策を検討することが必要のため、モデル構造、結果の解釈が容易であるモデルが望ましい。

(2) 既往研究のレビュー

本研究の関連研究として、冬季の天候が道路交通に与える影響に関する研究、道路交通異常事象の発生をデータから検知、推定する既往研究をレビューし、本研究の位置付けについて整理する。

a)冬季の天候が道路交通に与える影響に関する研究

冬季の天候が道路交通に与える影響を評価に関する研究は数多く実施されている。Luら³⁾は、積雪時においては、飽和交通流率が20%程度低下し、自由流速度が17%程度低くなることを調査し、交通シミュレーション(VISSIM)を使用して積雪時等の悪天候下における信号制御方法を検討している。伊藤ら⁴⁾は積雪時の信号交差点の交通容量の変化について分析し、冬季積雪時の信号の交通容量は、乾燥路面に対して、概ね2割以上の低下が生じることを明らかにしている。また、同様の路面状態であれば、道路種別による差異は軽微であると述べている。

Datlaら⁵⁾は、高速道路の交通量変動に対する気象(冬季の気温と積雪量)影響の定量化を行い、冬季期間の交通量データから年間平均日別交通量を推定するモデルを提案している。また、冬季の気温と積雪量が交通量に与える影響は、曜日、時間帯、気象の厳しさによって異なることを示した。谷村ら⁶⁾は、札幌市において、プローブカーデータから得られる道路交通情報及び降雪量や積雪量などの気象データを収集し、これらのデータを重回帰分析することで、気象条件の変化に伴う道路交通速度の変動を推定するモデル式を作成し、札幌市内の実道路上において、雪道の速度低下を推定できることを示した。Heqimiら⁷⁾は高速道路ネットワークを対象にクリギング法を用いて、積雪時などの悪天候下において、事故が発生しやすい区間の特定を試みている。また、丹治らは⁸⁾2014年2月に発生した山梨豪雪時の降雪経過と交通障害状況をメッシュ別に分析している。豪雪災害時は、平均速度が20km/hを下回るメッシュが急激に増し、プローブデータの空白域が広がることを明らかにした。しかし、それらの原因が単なる交通量低下なのか、大雪による通行不能状態なのかの区別がつかないことを課題として挙げている。

b) 道路交通異常事象発生の検知・推定に関する研究

センシングデータを用いて、道路交通異常事象の発生を検知もしくは、その状況の推定を目的とする研究は、数多く実施されている。本研究と同じようにプローブデータに着目し、その集計量を用いた例としては、Horiguchi ら⁹⁾の研究がある。Horiguchi らは、1km 四方のエリア内のプローブ車両の存在台数とフローとの関係を推定し、観測値との乖離により非日常的な混雑状況を持つメッシュを検出する手法を提案している。または牛木ら¹⁰⁾や Li and McDonald¹¹⁾は、旅行時間の空間的变化と突発的なボトルネックの直下流のプローブ通過台数の時間的变化により異常事象の検出を行う手法を提案している。

プローブ車両の1台1台のデータを用いた例としては、Petty ら¹²⁾Asakura ら¹³⁾の研究がある。Petty らは異常事象発生箇所を低速走行した車両はボトルネック通過後、自由流速度まで加速する特性を利用して、事故の発生箇所を検知する手法を提案し、Asakura らは、高速道路上において、車両軌跡の変曲点間をつないだ衝撃波面に着目し、交通障害発生の時間と場所を推定する手法を提案している。Cai ら¹⁴⁾の一般道の交通障害発生時に交差点の進入区間で生じるふらつきや車線逸脱を異常と定義し、プローブの異常挙動を検出する手法等を提案している。

車両感知器データを使用した例としては、Salamanis ら¹⁵⁾の高速道路車両感知器データを活用し、機械学習(k-近傍法およびサポートベクトル回帰アルゴリズム)と時系列モデルの両方を用いて交通予測モデルを構築した例や野村ら¹⁶⁾によってベイジアンネットワークを用いた突発事象検知モデルを構築、首都高の5路線に適用した例がある。交通量やオキュパンシー、車線別の速度差等の統計量について、平常時と交通障害発生時の差異を分析した例としては Cullip ら¹⁷⁾や Kawasaki ら¹⁸⁾がある。

その他道路交通異常事象以外を対象にしたエリア単位の異常検知の例としては、神谷ら¹⁹⁾によるメッシュ人口時系列データの潜在状態数を推定可能な隠れマルコフモデルを援用した異常検知手法が提案されている。

本研究は、冬季の一般道路ネットワークにおける立ち往生が発生する前にそのリスクをリアルタイムかつ逐次評価することを試みる研究である。雪や凍結が交通に与える影響程度を分析する研究は多くあるものの、立ち往生はめったに発生せず、データの収集が困難であるため、立ち往生を対象とした研究はほとんどない。また、過去の研究の多くは、高速道路上での事故発生後の早期発見を目的としており、立ち往生の事前のリスク評価を目的とする本研究とは異なる。一般道の立ち往生は、広範囲かつ緩やかに徐々に変化する気象の影響を受けて同時多発的に発生事象であり、突発的に、局所地点で発生する交通事故とはそもそも性質が異なる。また、一般道は信号の存在や車両挙動が複雑であることから、高速道路よりも問題を難しくしていることも研究が少ない要因と考えられる。

c) 本研究の位置付け

本研究は、プローブ車両の速度が間接的に路面の状況を表しているという仮説の基に冬季道路交通における異常事象の発生危険性を評価する手法を構築している。速度の低下を異常事象の発生と関連付ける際に、一般道では信号等の人為的な制御の影響で速度低下が発生することが問題となる。そこで本研究では、その影響を除外するために区間を走行する車両の上位側の速度(85 パーセントイル速度)に着目し、実際の立ち往生事象との関係を確認することで、その仮説の妥当性を確認した。

なお、既往研究のレビュー結果を踏まえた、本研究の新規性と有用性は以下の点にあると考える。

- ・プローブデータと気象データを活用して、冬季道路交通における異常事象発生前後の状況を定量的に分析している点に新規性がある。
- ・本研究は、発生頻度が稀な一般道路の冬季立ち往生に着目し、その危険性の評価を試みている点に新規性がある。
- ・提案手法を、実データ(一般道で発生した冬季道路交通異常事象 56 事例)に適用し、客観的な事実との突き合わせによって手法の妥当性を評価している点に新規性と有用性がある。
- ・提案手法は、欠測が多い時間、区間においても適用可能であり、観測値とモデルの両方に確率的な誤差を仮定することで、誤発報と見逃しを減らすことができることから有用性が高い。

(3) 提案手法の全体像

a) 異常事象の定義

本研究における異常事象とは降雪・凍結といった気象の影響により、道路の性能が大幅に低下することで車両が進行不能となり、道路交通に悪影響を及ぼす事象と定義する。道路車線外で発生する立ち往生など交通流への影響が軽微な事象は、本研究の対象外とする。

b) 道路性能とプローブ車両速度に関する仮説

本研究における道路性能とは、評価区間における路面の走りやすさを表すものとし、信号や路上駐車などといった人為的な制御による速度低下の影響を除いた一般的なドライバーが走行できる上限速度で観測できると仮定する(信号等で止まらずに区間走行する車両が路面の状況をよく反映するという仮説)。本研究では、この上限速度について、交通工学の分野で極端な外れ値を除いた上限速度として扱われることが多い 85 パーセントイル速度を採用する。ここで 85 パーセントイル速度とは、評価対象を通過する車両の走行速度分布の累積百分率をみたときに、85%にあたる速度であり、平均値に1標準偏差を加えた速度にほぼ等しく、一般的なドライバーが安全に走行できる速度の最大値として考えられている。また、本研究で 85 パーセントイル速度を採用する大きな理由は、一般的に用いられる平均速度では、路面の状況に関係なく信号等により速度を落とす車両に影響を受けるのに対し、85 パーセントイル速度は

その影響を軽減できると考えたためである。85パーセンタイルよりも高いパーセンタイル速度(95パーセンタイルなど)の採用も考えられたが、特異に高い速度の影響を受けるため、一般的なドライバーの速度として適切ではないと考えた。

図 3.2-1 の左図は、信号区間におけるプローブ車両の速度プロファイル図である。1点1点は、数秒ごとに観測される速度を表しており、同一車両のデータは、同一色でプロットし、経過時間毎に線で結んでいる。この図から区間をスムーズに走行する車両と信号で減速、発信する車両の状況が分かる。また、右図は、速度プロファイルを基に車両別に区間通過速度を算出し、その分布を箱ひげ図で示したものである。85パーセンタイル速度(上位15%の速さで区間を走行)にあたる車両は、区間をスムーズに通過した車両であり、85パーセンタイルに着目することで、信号等の影響を除外できる。

c)手法のコンセプト

本研究では、前述したようにプローブ速度(85パーセンタイル速度)によって観測される道路性能の低下に着目する。85パーセンタイル速度はサンプル数や運転者の違い、個々の車両性能の違いなどによって不確実性が高いと考えられるため、確率的に分布すると仮定して評価を行う。

具体的には、過去に観測されたプローブ車両の速度分布と後述する状態空間モデルによって推定する現時点の速度分布という2つの速度分布に基づいて立ち往生の危険性を評価する。図 3.2-2 は、提案手法の概念図である。図中の灰色の帯は、過去のデータから推定する速度分布を表す。これは、過去の同一時間帯の85パーセンタイル速度の分布である。一方、赤線は、状態空間モデルによって推定したリアルタイムの速度分布の平均値を示す。赤線が灰色の帯から十分に外れている場合、冬季気象の影響により道路の性能が下がっている、すなわち立ち往生が発生する危険性が高いと状況と判断し、道路管理者にアラート発信する。

本研究で構築する状態空間モデルは、プローブ車両速度、プローブ台数、降雪量、気温といった変数を用いる。状態空間モデルは、モデルによる推定値と観測値を融合し、直接観測できない状態を推定するデータ同化手法の一つである。

本研究で構築する状態空間モデルは以下のような特徴を持つ。これらの特徴は、前述した手法の要件を満たす。

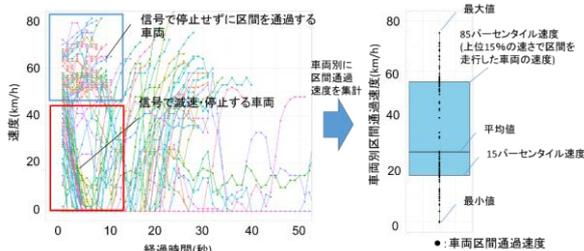


図 3.2-1 信号区間速度プロファイルと車両別通過速度の箱ひげ図

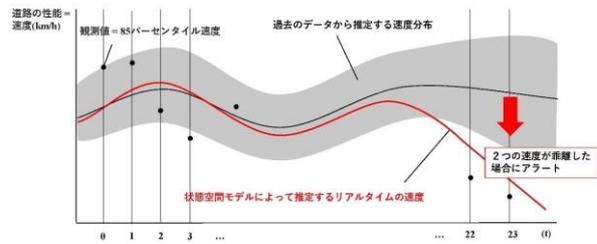


図 3.2-2 危険性評価のコンセプトイメージ

- ・状態空間モデルは時系列データの欠測を容易に処理することが出来る。欠測値を未観測の確率変数として、自然に扱うことができ、欠測値に対する予測及び予測区間を与えて補間することが出来る。欠測値を含むデータに対しても尤度計算が可能で、最尤法によってパラメータを決定することが出来る。
- ・状態空間モデルは確率モデルであり、モデルと観測値の両方に誤差があると仮定し、誤差を考慮して状態変数を推定できる。本研究では、状態空間モデルを用いて、リアルタイムの速度分布を推定する。
- ・本研究では、線形関数でノイズがガウス分布を仮定する線形ガウス状態空間モデルを用いる。線形ガウス状態空間モデルは、計算負荷が小さく逐次処理が可能な状態推定アルゴリズム(カルマンフィルタ)の適用が可能である。
- ・線形ガウス状態空間モデルは、モデル構造がシンプルで、結果の解釈も容易である。一方で、深層学習や機械学習手法等が盛んに活用されているが、これらの学習モデルは予測力はあるものの、構造が複雑なために、予測メカニズムが分かりにくい、頻繁に発生しない事象は学習データがないという課題がある。

(4) 提案手法の定式化

ここでは、前述した過去の速度分布とリアルタイムに推定する速度分布という2つの速度の推定方法及びそれらの乖離を表す指標について定式化する。速度分布は通常、時間と区間に依存するため、本研究では空間 s と時間 t を離散化し、離散化した空間区間を Δs 、離散化した時間区間を Δt とおき、空間を $s \equiv [s, s + \Delta s)$ 、時間を $t \equiv [t, t + \Delta t)$ と定義する。2つの速度分布はそれぞれの空間 s と時間 t に対して定義されるが、以降の定式化では、簡単にするため、ある特定の空間 s のみに焦点を当てて、添え字 s を削除する。また、離散時間 t には対応する1日の中の時間帯が存在するため時間帯 $h = \{0, 1, \dots, 23\}$ を定義する。時間帯 h は時間 t の関数である。なお、本章では、ベクトルは \mathbf{x} などのように太字の小文字、行列は \mathbf{A} などのように太字の大文字で表す。転置は \mathbf{A}^T 、逆行列は \mathbf{A}^{-1} のように表す。

a)過去の速度分布の推定

過去の速度分布の推定方法について述べる。まず、過去のデータが N 日分ある場合、そのデータ期間を $d = \{1, 2, \dots, N\}$ とおく。この期間は、直近の数年程度の積雪が観測された日も観測されない日も全て含んでよい。

次に、評価対象空間 s を通過するプローブ車両のデータを抽出する。この時、評価を行う方向(上り線, 下り線)に走行する車両のデータを抽出する。抽出したデータから、ある日 d のある時間帯 h に区間を通過する車両速度を算出し、その速度分布から 85 パーセンタイル速度 $v_{85}(h, d)$ を算出する。本研究では、 $v_{85}(h, d)$ は正規分布すると仮定し、その平均値 $\mu_{v85}(h)$ と分散 $\sigma_{v85}^2(h)$ はそれぞれ式(3.2-1)、式(3.2-2)で算出できる。過去のデータについてはサンプル数を増やすことが出来るため、観測値のみで分布の推定ができるとする。

$$\mu_{v85}(h) = \frac{1}{N} \sum_{d=1}^N v_{85}(h, d) \quad (3.2-1)$$

$$\sigma_{v85}^2(h) = \frac{1}{N} \sum_{d=1}^N (v_{85}(h, d) - \mu_{v85}(h))^2 \quad (3.2-2)$$

b)リアルタイムの速度分布の推定

前述したとおり、本研究では状態空間モデルの枠組みを用いて、リアルタイムの速度分布を推定する。状態空間モデルは、観測できない状態の時系列遷移を規定するシステムモデルと状態から観測値が出力される過程を記述する観測モデルという 2 つの方程式で表現される確率モデルである。過去のデータと比較して、リアルタイムに得られるデータは少ないためモデルを用いて補完推定を行う必要がある。

本研究では、システムモデル、観測モデルがともに線形でノイズがガウス分布を仮定する線形ガウス状態空間モデルを用いる。線形ガウス状態空間モデルによる状態推定手法として、逐次的かつ効率的に計算可能なカルマンフィルタが適用できるため、本研究においてもカルマンフィルタを用いて状態推定を行う。

c)モデル構築の考え方

時系列データを説明するモデル構造を定める際には、より単純な構造を組み合わせることで一般的であり、これを時系列データの成分分解と呼ぶ。本研究では、レベル成分、周期成分、降雪量回帰成分、気温回帰成分、プローブ台数回帰成分の 5 つの成分の組み合わせにより 85 パーセンタイル速度の時間変動が説明できると仮定して状態空間モデルを

構築する。各成分の組み合わせから、表 3.2-1 に示す 10 種類のモデル構造の候補を構築した。以降は表 3.2-1 で整理したモデル構造の候補の中で、最も変数が多いモデル 10 を代表として定式化する。その他のモデルについてはモデル 10 から変数を減らした形になるため、省略する。

d)観測モデル

本研究における状態空間モデルの観測モデルを式(3.2-3)に示す。式(3.2-3)は、観測値 $v_{85}(t)$ がレベル成分 $\mu(t)$ (一般的な回帰モデルの切片に相当)と周期的な変動成分 $\gamma_1(t)$ 、降雪量、気温、プローブ台数の回帰成分の線形結合にホワイトノイズ $w(t)$ が加わって出力されることを表している。

$$v_{85}(t) = \beta_{snow}(t) \cdot snow(t) + \beta_{temp}(t) \cdot temp(t) + \beta_n(t) \cdot n(t) + \mu(t) + \gamma_1(t) + w(t) \quad (3.2-3)$$

- $v_{85}(t)$: 時間 t における 85 パーセンタイル速度
- $snow(t)$: 時間 t における降雪量(cm/6h)
- $temp(t)$: 時間 t における気温(°C)
- $n(t)$: 時間 t に通過するプローブの台数(台/h)
- $\beta_{snow}(t)$: 時間 t における $snow(t)$ の回帰成分
- $\beta_{temp}(t)$: 時間 t における $temp(t)$ の回帰成分
- $\beta_n(t)$: 時間 t における $n(t)$ の回帰成分
- $\mu(t)$: 時間 t におけるレベル成分

表 3.2-1 モデル構造一覧

No	モデル名	説明変数: 入力	潜在変数: 出力
①	ローカルレベルモデル	—	レベル
②	周期モデル (①+周期)	—	レベル, 周期
③	回帰モデル (①+降雪量)	降雪量	レベル, 降雪量
④	回帰モデル (①+気温)	気温	レベル, 気温
⑤	回帰モデル (①+プローブ台数)	プローブ台数	レベル, プローブ台数
⑥	回帰モデル (①+降雪量+気温+プローブ台数)	降雪量, 気温, プローブ通過台数	レベル, 降雪量, 気温, プローブ台数
⑦	周期成分回帰モデル (②+降雪量)	降雪量	レベル, 周期, 降雪量
⑧	周期成分回帰モデル (②+気温)	気温	レベル, 周期, 気温
⑨	周期成分回帰モデル (②+プローブ台数)	プローブ通過台数	レベル, 周期, プローブ台数
⑩	周期成分回帰モデル (②+降雪量+気温+プローブ台数回帰)	降雪量, 気温, プローブ通過台数	レベル, 周期, 降雪量, 気温, プローブ台数

$\gamma_1(t)$: 時間 t における周期成分

$w(t)$: 観測ノイズ $\sim N(0, \sigma_w^2)$

e) システムモデル

本研究における状態空間モデルのシステムモデルを式(3.2-4)～式(3.2-8)で示す。

レベル成分：

$$\mu(t) = \mu(t-1) + \varepsilon(t), \quad \varepsilon(t) \sim N(0, \sigma_\varepsilon^2) \quad (3.2-4)$$

回帰成分：

$$\begin{aligned} & \beta_{snow}(t) \\ &= \beta_{snow}(t-1) \\ &+ \xi(t), \quad \xi(t) \sim N(0, \sigma_\xi^2) \end{aligned} \quad (3.2-5)$$

$$\beta_{temp}(t) = \beta_{temp}(t-1) + \psi(t) \quad \psi(t) \sim N(0, \sigma_\psi^2) \quad (3.2-6)$$

$$\begin{aligned} & \beta_n(t) \\ &= \beta_n(t-1) \\ &+ \zeta(t), \quad \zeta(t) \sim N(0, \sigma_\zeta^2) \end{aligned} \quad (3.2-7)$$

周期成分：

$$\begin{aligned} \gamma_1(t) &= - \sum_{i=1}^{23} \gamma_i(t-1) + \omega(t), \quad \omega(t) \sim N(0, \sigma_\omega^2) \\ \gamma_2(t) &= \gamma_1(t-1), \\ & \vdots \\ \gamma_{22}(t) &= \gamma_{21}(t-1), \\ \gamma_{23}(t) &= \gamma_{22}(t-1), \end{aligned} \quad (3.2-8)$$

本研究では、雪や気温が道路の性能に与える影響は一定ではないとして、推定する状態を重回帰モデルのパラメータとして考え、パラメータが時間変化するモデルとしてシステム方程式を定式化している。状態は回帰分析の切片に相当するレベル成分 $\mu(t)$ と道路性能に影響を与えると想定できる観測変数(降雪量 $snow(t)$, 気温 $temp(t)$, プローブ車両の通過台数 $n(t)$)の回帰成分 $\beta_{snow}(t), \beta_{temp}(t), \beta_n(t)$ と周期的な変動成分 $\gamma(t)$ の 5 つの成分からなっており、式(3.2-4)～式(3.2-8)に示すとおり、それぞれの状態成分が前時点の値から独立した期待値 0 のガウス分布に従う確率的なノイズを伴って時間変化することを表している。

最後に、リアルタイムの速度分布の平均値 $\mu_{v85}(t|t)$ は、フィルタリング後の状態ベクトル $\mathbf{x}(t|t)$ と観測行列を観測モデルに代入することで算

出できる。

f) 異常事象の危険性評価

前述した過去の速度分布とリアルタイムの速度分布の乖離度合いから立ち往生の発生の危険性を評価する。本研究では、式(3.2-9)に示す値を立ち往生の発生危険性を表す指標(Standstill risk index: SRI)と定義し、アラート発信の基準とする。SRI は、過去の速度分布の標準偏差 $\sigma_{v85}(h)$ で正規化された 2 つの平均値の差を表す指標であり、過去の速度分布の平均値 $\mu_{v85}(h)$ と比較して、リアルタイムの速度分布の平均値 $\mu_{v85}(t|t)$ が低下すると、明らかに大きな値をとる。SRI が 1 を取る時、過去の速度分布の 1σ 区間以下に速度が低下していることと同義である。本研究では、式(3.2-10)に示すとおり、SRI が事前に設定する閾値 α を超えた場合にアラートする。閾値については、様々な考え方が存在すると考えられるが、本研究では、「立ち往生がいつ発生してもおかしくない状況」と「既に立ち往生が発生している可能性の高い状況」の 2 段階でアラート発信する。SRI が閾値 $\alpha=1$ を超えた場合を「立ち往生がいつ発生してもおかしくない状況(レベル 1)」と仮定し、SRI が閾値 $\alpha=2$ を超えた場合を「既に立ち往生が発生している可能性の高い状況(レベル 2)」と仮定する。アラートと立ち往生の関係について妥当性を検証する。

$$SRI = \frac{\mu_{v85}(h) - \mu_{v85}(t|t)}{\sigma_{v85}(h)} \quad (3.2-9)$$

$$\text{Alert} \quad SRI(t) > \alpha \quad (3.2-10)$$

(5) 実データによる提案手法の適用検証

提案手法を実際に立ち往生が発生した際のデータに適用し、その結果の妥当性について検証を行う。

a) 妥当性評価の視点

本研究では、表 3.2-2 に示す 4 つの視点で、妥当性の評価を行う。提案手法は、気象条件が悪い状況下で異常事象が発生してもおかしくない状況をアラートする手法であるため、まずは、積雪量が 0cm かつ気温が 2°C 以上の条件においてアラート発信しないか(誤発報)を確認した。

次に、立ち往生発生直前に「立ち往生がいつ発生してもおかしくない状況」を示すアラート(レベル 1)が出来ているか、立ち往生発生後に「既に立ち往生が発生している可能性の高い状況」を示すアラートが出来ているかについて確認する。また、上記の視点による評価結果を考慮して、表 3.2-1 で示した 10

表 3.2-2 評価結果の妥当性の視点

評価の視点	混同行列との関係
a) 誤発報の程度(特異度)	・立ち往生が起こる可能性が低い条件(積雪がなく気温が高い)でアラートしていないか 誤検知に対応する視点
b) アラート(レベル1)と立ち往生発生直前の状況の関係	・立ち往生発生前に危険性が高いことをアラート(レベル1)出来ているか(見逃しがないか) 見逃しに対応する視点
c) アラート(レベル2)と立ち往生発生直後の状況の関係	・危険性発生後に危険性が高いことをアラート(レベル2)出来ているか(見逃しがないか) 見逃しに対応する視点
d) 気象条件と異常事象に関する知見との整合(モデル選択後)	・一般的危険性が高いと知られている積雪時や凍結時に異常事象の発生危険性が高いことを評価できているか(e.g.凍結, 圧雪, アイスバーン, 緩い雪等) その他客観的な事実との突き合わせ

のモデル構造の候補の中から最も客観的な事実を説明するモデルを選択した。

さらに選択したモデルに関して、一般的に立ち往生の危険性が高いとされている降雪時や低気温時といった気象データとアラート状況を確認した。

b)検証対象

検証対象とする事象は、2018年と2019年1月～2月に国土交通省東北地方整備局管内で発生した立ち往生事例(56事例)とする。本研究では、本田技研工業株式会社によって収集、管理されているプローブ車両データを使用する。気象データは国土交通省気象庁HPからダウンロードできる気象統計データを使用する。気象情報として整理する内容は、時間帯別の平均気温(°C)、6時間前からの累積降雪量(cm/6h)である。

(6) モデル別の危険性評価の妥当性検証結果

表 3.2-3 は、モデル別の特異度、立ち往生発生時間の1時間前時点でアラート(レベル1)状況、立ち往生の1時間以内のアラート(レベル2)状況の評価結果の一覧で整理したものである。特異度は、値が大きいほど、誤発報が少ないことを意味し、発生確率が低い事象を対象とした場合、重要な指標である。

表 3.2-3 を見ると、10のモデル候補の中でも、モデル10が誤発報が少なく、異常事象の見逃しが少ないことが分かる。以上より、本研究では、モデル10が提案モデルの中では、最も優れていると判断し、以降はモデル10による評価結果を整理する。

図 3.2-3 は、気温と6時間降雪量の2変数を軸にとり、気象条件別に選択したモデルによるアラート

表 3.2-3 モデル別の評価結果の一覧

No	システムモデル(状態ベクトル)	特異度	発生前アラート(レベル1)	発後にアラート(レベル2)
①	ローカルレベルモデル(レベル)	97.0%	66.1% (2位)	44.6% (3位)
②	周期成分モデル(レベル+周期)	94.6%	50.0%	35.7%
③	回帰成分モデル(レベル+降雪量)	97.8%	62.5%	44.6% (3位)
④	回帰成分モデル(レベル+気温)	97.5%	62.5%	42.9%
⑤	回帰成分モデル(レベル+プローブ台数)	97.0%	60.7%	42.9%
⑥	回帰成分モデル(レベル+プローブ台数+降雪量+気温)	97.5%	67.9% (1位)	44.6% (3位)
⑦	周期成分回帰成分モデル(レベル+周期+降雪量)	98.1% (1位)	62.5%	48.2% (2位)
⑧	周期成分回帰成分モデル(レベル+周期+気温)	97.6%	55.4%	37.5%
⑨	周期成分回帰成分モデル(レベル+周期+プローブ台数)	97.5%	55.4%	42.9%
⑩	周期成分回帰成分モデル(レベル+周期+プローブ台数+降雪量+気温)	97.9% (2位)	66.1% (2位)	51.8% (1位)

の発報割合を示したものである。赤色が濃いほどその条件下において、アラート発信する割合が多いことを表している。図 3.2-3 を見ると降雪量が多いほど、アラートを発信する割合が高くなる傾向にあり、気温が極端に低い場合、もしくはまとまった降雪があり、気温が0°C付近の場合にアラートを発信する割合が高い傾向になっている。これは、①気温が低く路面の雪が完全に凍結している状態(アイスバーン)、②積雪が多く除雪が間に合っていない状態、③路面の雪が凍結、融解を繰り返している状態(雪が緩い状況)という3つの状況において、ドライバーが道路の状況の悪化を認識することで、速度が低下し、アラートされていると考えられる。これらの結果は、一般的に知られている道路路面の状況が悪い状況と合致する。

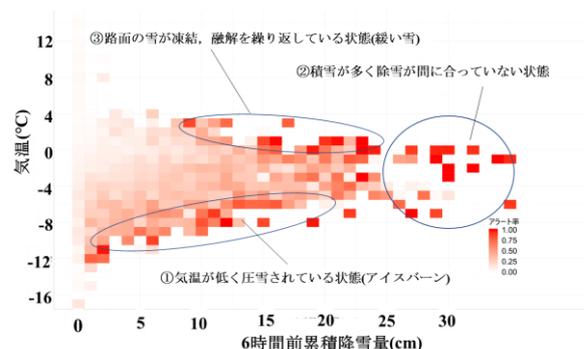


図 3.2-3 気象条件別のアラート発報率

表 3.2-4 比較ケース

Case	リアルタイムの走行性能の分布の推定方法
1	状態空間モデルによるフィルタリング分布
2	状態空間モデルによる1期先予測分布

(7) 提案手法の予測可能性の検討

本項では提案手法の予測可能性について検討を行った。

提案手法において、状態空間モデルのシステムモデル構築した(状態の時間変化を記述した)ことにより、カルマンフィルタアルゴリズムの1期先予測アルゴリズムを用いて、先の予測を行うことが出来る。

表 3.2-4に示すように当期の状態を予測するフィルタリング分布によるアラート性能と1期先予測分布におけるアラート性能を比較することで、提案手法の予測可能性について検討を行った。

・立ち往生発生前後のアラート状況の比較

表 3.2-5は、立ち往生発生事例(56事例)を対象に、立ち往生発生直前(1時点前)と立ち往生発生直後(1時点后)のアラート発報状況についてフィルタリング分布によるアラート状況と1期先予測によるアラート状況について比較行ったものである。1期先予測においてもアラート出来た割合はほぼ変わらないことが分かった。

表 3.2-6は立ち往生発生事例別に特異度を算出し、その平均値、最低値、25%タイル値、50%タイル値、75%タイル値、最大値の整理を行ったものである。いずれの値も予測の方が値が低い傾向にあり、予測の方が誤発報が多い傾向にあることが分かる。

以上より、1期先予測による異常事象の危険性評価は、フィルタリング分布による危険性評価結果と比較して若干のアラート精度(立ち往生時の発報及び誤発報)の低下が確認されたものの、アラートができた事例数には、大きな差はなかったため、異常事象の危険性に関する予測の可能性が確認できたと

表 3.2-5 立ち往生発生直前のアラート割合の比較

Case	立ち往生発生直前にアラート出来た事例数の割合	立ち往生発生直後にアラート出来た事例数の割合
1	66.1%	51.8%
2	64.3%	48.2%

表 3.2-6 特異度(誤発報の少なさ)の比較

case	平均値	最低値	25%タイル値	50%タイル値	75%タイル値	最大値
1	97.9%	84.4%	97.4%	98.7%	99.5%	99.8%
2	97.3%	82.4%	96.8%	98.0%	99.0%	99.8%

考える。ただし、提案手法については、以降に示すとおり、いくつかの課題が残されているため、今後も改良を行い、予測精度についても検証を行う必要がある。

(8) まとめ

本項では、降雪や路面凍結の影響による車両立ち往生やスタックといった冬季道路交通における異常事象が社会に与える影響を小さくすることを目的として、一般道における立ち往生の発生危険性を評価する手法を提案し、その有効性と一定の妥当性を示した。

提案手法については、実際に異常事象が発生した事例のデータに適用し、立ち往生、気象条件といった客観的な事実と突き合わせた検証により、評価結果が一定の妥当性を持つことを確認した。検証の結果、提案手法は、欠測が多い時間、区間においても適用可能であり、観測値とモデルの両方に確率的な誤差を仮定することで、誤発報と見逃しを減らすことができることを確認した。提案手法による評価結果を道路管理者に提供することで、現在の監視体制をより強化することができ、監視員の負荷を低減することに寄与できると考えられる。また、提案手法の予測可能性についても検討を行い、1時点先の予測ではあるものの、アラートの精度が大幅に低下するようなことはなく、予測の可能性を確認できた。

最後に、実務への適用性の観点から本研究の今後の課題は以下のとおりと考える。

・提案手法の実証実験

本研究では、実際に異常事象が発生した際のデータを用いて提案手法の検証を行った。発生した立ち往生が、実際にどの程度交通流に影響を与えたのか明確にわからないことや立ち往生以外の事故や故障車といった異常事象に関するデータを完全に揃えることはできなかつたため、モデルの妥当性に関する検証は完璧ではないと考えられ、モデルの妥当性については引き続き検証が必要である。また、アラートの閾値についても、道路種別や管理体制によって、調整が必要となると考えられる。

・時空間分解能の感度分析

本研究では、500m区間毎、1時間毎に評価を行ったが、時空間分解能の感度分析を行い、その影響について検証を行う必要がある。例えば、空間分解能を小さくすると、小さな区間単位での評価ができるが、得られるプローブ点列データが少なくなり、精度が低下する可能性がある。また、時間分解能を長くすることで、単位時間あたりのサンプル数を増やすことが出来るが、評価できるまでの時間間隔が長くなるといったトレードオフが生じる。時空間分解能を変えることで、リスク評価に様々な影響が表れると想定される。

3.1.2の参考文献

1) 国土交通省 HP：冬期道路交通確保対策検討委員会資料, <http://www.mlit.go.jp/road/ir/ir-council/toukidouroskanri/pdf01/07.pdf>.

- 2) 国土交通省 HP : 冬期道路交通確保対策検討委員会資料, <https://www.mlit.go.jp/road/ir/ir-council/toukidourokanri/pdf01/04.pdf>.
- 3) Lu ,Z , Kwon, J. Tae. ,Fu ,L. : Effects of winter weather on traffic operations and optimization of signalized intersections, *Journal of Traffic and Transportation Engineering*, Vol.6, Issue 2, pp.196-208, 2019.
- 4) 伊藤 潤,大島 亮,佐野 可寸志,鳩山 紀一郎. :冬季路面状況による信号交差点の交通容量低下率に関する研究 , *交通工学論文集*, 第 5 巻, 第 2 号(特集号 B), pp.B_34-B41,2019.
- 5) Datla, S, Sahu, P , Roh .J.H, Sharma, S.: A Comprehensive Analysis of the Association of Highway Traffic with Winter Weather Conditions, *Procedia - Social and Behavioral Sciences* , pp.104 497 – 506, 2013.
- 6) 谷村 亮介, 廣森 聡仁, 梅津 高郎, 山口 弘純, 東野 輝夫 : 気象および交通データ解析に基づく積雪期における交通速度低下の推定手法 , *情報処理学会研究報告*, Vol.2015-MBL-75 No.32, 2015
- 7) Heqimi,G, Gates , J. T, Kay, J. J . : Using spatial interpolation to determine impacts of annual snowfall on traffic crashes for limited access freeway segments, *Accident Analysis & Prevention*,Vol. 121, pp.202-212 , 2018.
- 8) 丹治 和博,須藤 哲寛,今井 武,永井 慎一,菅原 愛子,益田 卓朗:2014 年 2 月山梨県大雪災害における降雪経過と交通障害状況,第 30 回寒地技術シンポジウム,2014.
- 9) Horiguchi, R., Iijima, M., Kobayashi, M. and Hanabusa, H.: Traffic anomaly detection for surface street networks with the mesh-wised traffic indices on macroscopic fundamental diagram, *OPTIMUM 2013 International Symposium on Recent Advances in Transport Modelling*, pp. 1-7, 2013.
- 10) 牛木 隆匡,日下部 貴彦,NGUYEN Xuan Long,朝倉康夫. :交通容量低下を考慮したプローブカーデータによる突発事象検出手法,土木計画学論文集D 3(土木計画学), Vol.70.No5,2014.
- 11) Li, Y. and McDonald, M. : Motorway incident detection using probe vehicles, *Proceedings of the Institution of Civil Engineers-Transport*, Vol. 158, pp. 11-15, February 2005.
- 12) Petty, K. F., Skabardonis, A. and Varaiya, P. P. : Incident detection with probe vehicles: performance, infrastructure requirements and feasibility, *Transportation Systems 1997,A Proceedings Volume from the 8th IFAC/IFIP/ IFORS Symposium*, Chania, Greece, June 16-18, 1997, Vol. 1, pp.125-130, 1997.
- 13) Asakura, Y., Kusakabe, T., Nguyen, L., X., and Ushiki, T. : Incident Detection Methods using Probe Vehicles with on-board GPS Equipment, *Transportation Research Part C: Emerging Technologies*, 2016.
- 14) Cai, Y., Wang,H., Chen, X., Jiang, H. : Trajectory-based anomalous behaviour detection for intelligent traffic surveillance , *IET Intelligent Transport Systems* , Vol.9, pp. 810–816, 2015.
- 15) Athanasios Salamanis, Giorgos Margaritis, Dionysios D. Kehagias, Georgios Matzoulas, Dimitrios Tzovaras, Identifying patterns under both normal and abnormal traffic conditions for short-term traffic prediction, *Transportation Research Procedia*, Volume 22, , pp.665-674, 2017.
- 16) 野村 大智,西内 裕晶,轟 朝幸,川 智也,割田 博. :ベジアンネットワークを用いた都市内高速道路における突発事象検知モデルの構築,土木学会論文集 F3 (土木情報学) 70(2), pp.I_303-I_309, 2014.
- 17) Cullip, M. and Hall, F. : Incident Detection on an Arterial Roadway, *Transportation Research Record: Journal of the Transportation Research Board*, Vol.1603, pp. 112-118, 1997.
- 18) Kawasaki, Y., Tanaka, A., Goto, H., Takada, J., Warita, H., Hong, S., Tanaka, S. and Kuwahara, M. : Research on Mechanisms to Provide Attention-attracting Information Effective in Preventing Rear-end Collisions, *18th ITS World Congress*, 2011.
- 19) 神谷 啓太,布施 孝志,メッシュ人口データに対するノンパラメトリックベイズに基づく統計的異常検知手法の適用可能性の検証,土木学会論文集 D3 (土木計画学), Vol.72, No.5 (土木計画学研究・論文集第 33 巻), I_759-I_769, 2016.

3.3 土砂災害危険性の事前アラート手法構築

(1) 概要

土砂災害が発生する前に事前にその危険性をアラートすることを目的とした手法の構築を試み、精度検証を実施した。

具体的には、土砂災害の事前アラートのための説明要因を整理し、地形の持つ土砂災害リスク（危険箇所の存在、傾斜、地質、道路の有無）を素因として設定した。また、流木発生域の判読結果を教師データとし、赤色立体地図および土壌雨量指数を入力として、通称 **pix2pix** と呼ばれるこのニューラルネットワークを用いて、土砂災害の危険性をアラート出来る手法を検討した。

研究初年度は、2017年7月の九州北部豪雨災害を事例として、九州地方整備局から提供された流木発生判読域を教師データとし、10mDEM（デジタル標高モデル）から作成した赤色立体地図画像を用いて、ディープラーニングにより土砂災害危険箇所を抽出した。その結果、ディープラーニングは、土砂災害危険箇所を過少評価する傾向が大きいことが分かったため、次年度以降は土壌雨量指数を用いてモデルの改良を行い、実際に土砂災害が発生した箇所を対象に手法の検証を行った。

図 3.3-1は、2017九州北部豪雨災害における九州地方整備局提供の流木発生域判読図教師データとし、赤色立体地図画像から地形の持つ土砂災害危険箇所の抽出を試みた結果である。地形データのみを入力とした場合、危険箇所を過少に評価することが分かった。

図 3.3-2は、入力データとして、国土地理院公開の10mDEM（標高地形モデル）データおよび土壌雨量指数を用いて地形の持つ土砂災害の素因リスク分布を抽出した結果である。図 3.3-2を見ると流木発生域をほぼ網羅し、かつ、より広く素因リスクを抽出することができていることが分かる。

提案手法を令和2年7月豪雨時に九州南部で発生した土砂崩れ箇所(5箇所)に適用して汎用性を確認した。検証対象である土砂災害の発生位置、図 3.3-3、発生時の写真を図 3.3-4に示す。

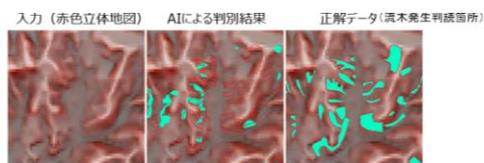


図 3.3-1 地形データのみによる土砂災害危険箇所の抽出結果



図 3.3-2 土壌雨量指数を考慮した土砂災害危険箇所の抽出結果

提案手法を検証対象箇所に適用し、それらの土砂災害リスク（素因リスク）を算定した(図 3.3-5)。その結果、土砂崩れの5箇所の内4箇所において、素因リスクの高い箇所であることを確認した。確認できなかった1箇所は、土砂崩れが主因ではなく河川氾濫によるものであることが分かった。



図 3.3-3 令和2年7月豪雨による土砂崩れ5箇所写真の位置図



図 3.3-4 令和2年7月豪雨における土砂崩れ5箇所の写真



図 3.3-5 令和2年7月豪雨における土砂崩れ5箇所の地形と素因リスク分布

(2) まとめ

本項では、土砂災害が発生する前に事前にその危険性をアラートすることを目的とした手法の構築を試み、精度検証を行った。

検証の結果、令和2年7月豪雨で発生した5箇所の土砂崩れの内、4箇所が土砂災害の危険性が高い状況であったことを評価出来た。ただし、検証数が少ないため、今後も継続して、今後の土砂崩れ災害時のモデルによる評価結果の妥当性の検証が必要である。

第4章 リアルタイム可視化システム開発および実証実験

4.1 リアルタイム可視化システム開発

(1) 概要

本研究で構築したリアルタイムモニタリング・アラートシステムについて報告する。本システムは、プローブデータや気象データ等の多種多様なデータを融合解析し、被災と交通状況をリアルタイムモニタリングするとともに、本研究で開発した交通障害発生のアラート技術を組み込み、ユーザへのアラート発信を目指したものである。

(2) リアルタイム可視化システムの概要

本節では、リアルタイムモニタリングシステムの概要について述べる。

表 4.1-1 にデータ一覧を示す。本システムでは、4 カテゴリ 7 種類のデータを扱っている。このうち、GIS 以外はリアルタイムセンシングデータであり、5 分周期で収集・処理・可視化を行っている。

リアルタイムモニタリングシステムの画面例を図 4.1-1 に示す。同図に示すように、システムでは、日本全国の各種データをリアルタイムに処理し、地図上にレイヤーとして表示する。システムの機能は、大きく“モニタリング機能”と“アラート機能”に分類される。表 4.1-2 に表示項目一覧を示す。同表に示すように、モニタリング機能では、旅行速度や Twitter、気象情報等、5 種類・14 項目の情報を可視化可能としている。

表 4.1-1 取得データ一覧

カテゴリ	ソースデータ	取得頻度
交通	・プローブデータ (普通車)	5 分
気象	・降水量	5 分
	・降雪量	60 分
	・洪水リスク情報	30 分
SNS	・Twitter	10 分 (ユーザ PUSH)
	・ユーザ撮影画像	
GIS	・地形情報, 道路形状	-

表 4.1-2 表示データ

表示項目	可視化データ
交通	・プローブ交通状況 ・メッシュ平均速度 ・メッシュ特異指数
気象ナウキャスト	・降水ナウキャスト ・降雪ナウキャスト
リスク	・洪水リスク情報 ・土砂災害リスク (静的解析データ)
旅行時間	・区間旅行時間 ・到達圏
アラート	・降水×交通状況 ・降雪×交通状況 ・降雪スタックアラート ・土砂災害リスクアラート ・交通ブレイクダウンアラート

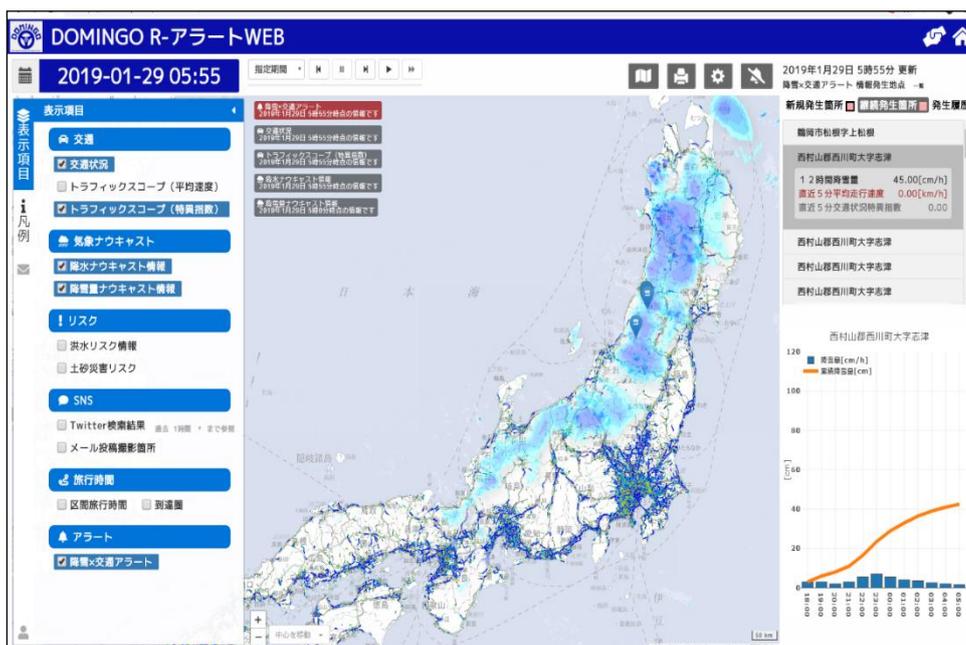


図 4.1-1 可視化システム画面例

(3) 表示データ

以下に本システムで生成している表示データの代表としてメッシュ平均速度・メッシュ得意指数、土砂災害リスク、区間旅行時間、到達圏の内容を述べる。

a)メッシュ平均速度・メッシュ特異指数

プローブデータをリアルタイムに入力し、解析対象メッシュの MFD の統計情報とリアルタイム情報を組み合わせ、方向別平均速度および特異指数（いつもと異なる状況）をメッシュ単位で算定・可視化している。ここで、特異指数とは、過去の集計 MFD とリアルタイムに生成した MFD とのかい離から、通常の交通状況との違いを指標化したものである

本システムでは、1km メッシュ単位で生成し、交通状況は 5 段階×特異指数による通常の交通状況からの乖離度の高低 2 段階の 10 レベルで可視化を、特異指数は通常の交通状況からの乖離度 3 段階×エリア走行密度 2 段階の 6 レベルで可視化している。

b)土砂災害リスク

国土地理院数値地図に公開されている土砂災害に関する危険箇所の有無と傾斜度から評価した土砂災害のリスクを表示している。メッシュごとに、危険箇所の有無と道路の有無、斜面の傾斜の組み合わせによりリスクの高さを色分けしている。なお、本情報は、静的なデータであり、逐次、データ更新はしない。図 4.1-2 に本システムでの土砂災害リスクの分類を示す。

c)区間旅行時間

道路形状から通過メッシュ ID を参照し、各メッシュの方向別メッシュ平均速度とメッシュ内道路区間長を用いて、区間旅行時間としている。画面右に履歴情報グラフとして可視化する。図 4.1-3 に指定区間の所要時間履歴の可視化例を示す。

d)到達圏

ユーザが指定した地図上の任意の地点からの到達圏をサーバ上で検索し、旅行時間のコンター図として地図上に可視化する。各メッシュまでの旅行時間は、ユーザ指定地点から隣接するメッシュまでの積算で、各メッシュ間経路の内の最短時間によって可視化している。各メッシュ間経路を流出方向とすることで、指定地点からの到達圏、進入方向とすることで、指定地点への到達圏とした。図 4.1-4 に到達圏の可視化例を示す。



図 4.1-2 土砂災害リスクの分類

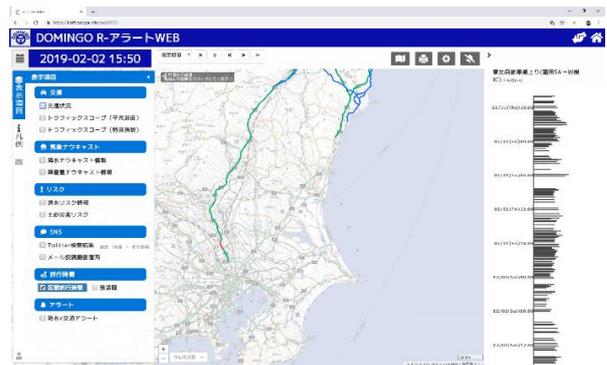


図 4.1-3 区間旅行時間表示例

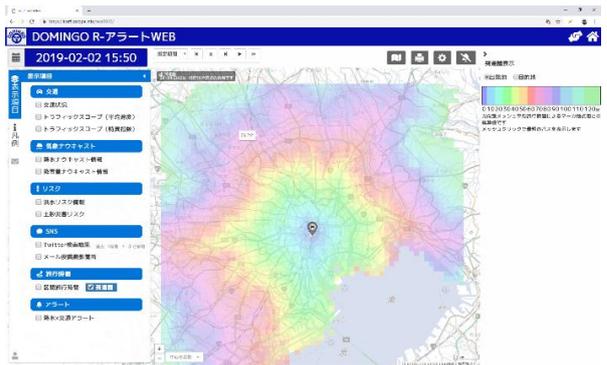


図 4.1-4 到達圏表示例

(4) アラート生成・発出フレームワーク

リアルタイム可視化システムでは、表 4.1-2 に示したように5種類の非日常事象に関するアラート機能を実装している。図 4.1-5 にアラート生成・発出フレームワークの概要をブロック図として示す。各メッシュのプローブデータと気象データを用いて、各機能別に設定した閾値を超えた場合にアラート発信する枠組みである。

閾値判定部に各アラート生成ロジックが適用され、アラートが発出される場合はアラートファイルが生成される。

リアルタイム可視化システムに実装した各アラート生成ロジックの種別、判定方法、本研究テーマと

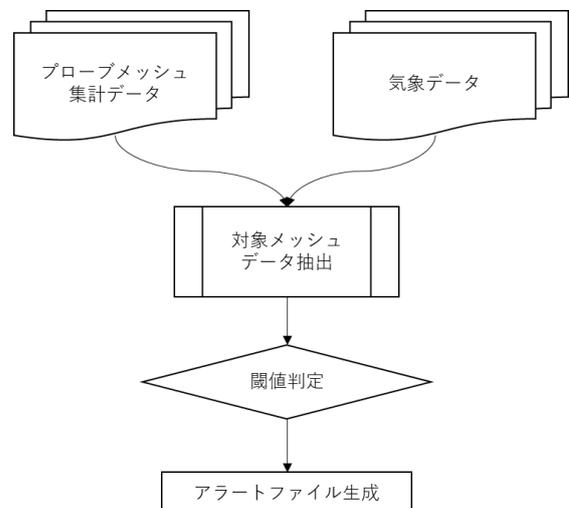


図 4.1-5 アラート生成ブロック

表 4.1-1 リアルタイム可視化システムに実装した各アラート生成ロジック

アラート種別	アラート判定	本研究テーマとの関連
降水×交通アラート	「1時間累積雨量30mm/h以上」かつ「メッシュ平均速度20km/h以下またはメッシュ特異指数15以上」	-
降雪×交通アラート	「1時間降雪量5cm以上」かつ「メッシュ平均速度20km/h以下またはメッシュ特異指数15以上」（仮設定値）	「3.1 降雪による車両スタック発生事前アラート条件の検討」で検討した閾値を設定
降雪スタックアラート	状態空間モデルを用いたスタック発生危険性のアラート手法による	「3.2 状態空間モデルを用いたスタック発生危険性のアラート手法の構築」で構築した手法を実装
土砂災害リスクアラート	土砂災害危険性の事前アラート手法による	「3.3 土砂災害危険性の事前アラート手法構築」で構築した手法を実装
交通ブレイクダウンアラート	プローブ車両データを用いた広域的な異常事象の発見手法による	「2.2 プロブ車両データを用いた非日常の発見手法の構築」で構築した手法を実装

の関連を表 4.1-1にまとめる。以下の機能については、前述した本研究で検討した手法をリアルタイム可視化システムに実装している。

- ・降雪×交通アラート
- ・降雪スタックアラート
- ・土砂災害リスクアラート
- ・交通ブレイクダウンアラート

降雪スタックアラートの可視化画面を図 4.1-6に、土砂災害リスクアラートの可視化画面を図 4.1-7に、交通ブレイクダウンアラートの可視化画面を図 4.1-8に示す。

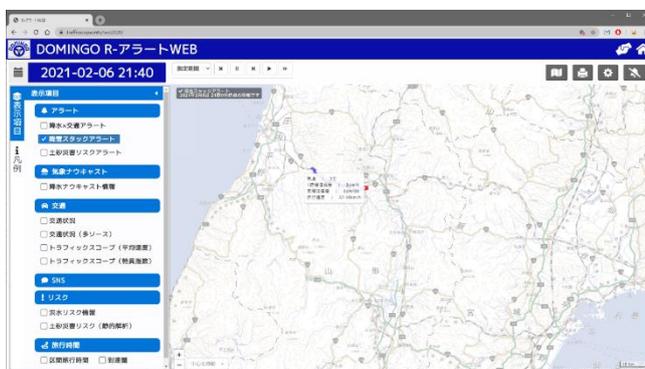


図 4.1-6 降雪スタックアラート

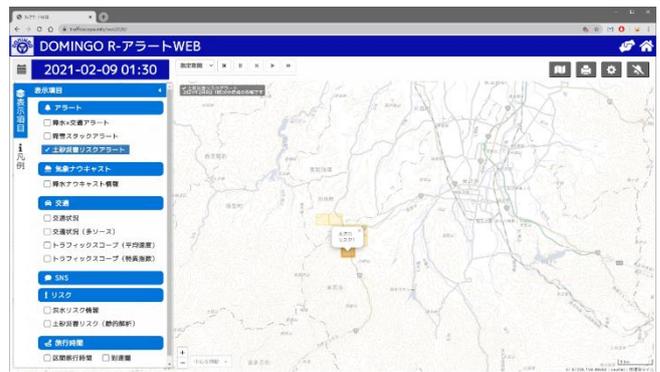


図 4.1-7 土砂災害リスクアラート

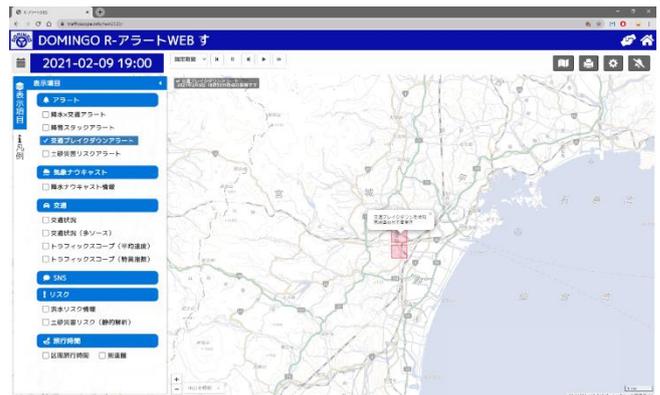


図 4.1-8 交通ブレイクダウンアラート

4.2 道路管理者に対する実証実験

(1) 道路管理者への試行

2020年10月～2021年に行った可視化システムの試行に際して、以下の道路管理者に試用を依頼した。可視化システムを使用させていただいての感想や意見をもとに、道路管理者への情報提供する上での課題を整理する。

- ・東北地方整備局（本局および各事務所）
- ・北陸地方整備局（本局および各事務所）
- ・近畿地方整備局福井河川国道事務所
- ・中国地方整備局（本局および各事務所）
- ・四国地方整備局（本局、松山河川国道事務所）
- ・九州地方整備局（本局および各事務所）

a)課題

・道路管理への活用性について

本システムの道路管理への活用性については、道路管理者は好意的な評価であるが、本システムをより活用しやすくするために、以下のような機能・情報の追加が望ましいという意見があった。これらはいずれも自然災害時の通行可否に関する情報である。

- ・通れるマップの自動作成機能（大地震時）
- ・通行不能道路箇所自動抽出・マップ作成（台風等大雨・大雪時）

また、本システムにおける降雪×交通アラートは、大雪に伴うスタックや立ち往生を想定したアラート条件であったが、少雪地域である西日本方面の道路

管理者からは、大雪に限らず以下の情報によるアラートが必要という意見があった。

- ・路面凍結に伴うスタックや立ち往生の検知
- ・土壌雨量指数を加味した土砂災害に関するアラート（2020年2月に土砂災害アラートは実装済み）

上記の課題は、道路管理者の受け持つ路線の地域特性や気象特性に応じて、道路管理に求められる機能が異なることに起因していると考えられる。本システムを幅広く全国の道路管理者に活用できるようにするためには、実装する情報項目やアラート機能に対して地域性をどのように反映させていくかが大きな課題である。

このほか、道路管理者が設置した CCTV に対して、AI 技術でスタック車両を自動で検知するシステムを導入している事務所があり、そうした事務所では本システムの有用性を感じないため、こうした特定の事象に特化した個別システムとの機能の差別化や複合情報の有用性をさらに活かすことが課題といえる。

・道路管理に有用な機能について

実際の道路管理の現場では担当者が常時本システムのような情報画面を見ているとは考えられない。本システムはブラウザでの WEB 表示のみの機能であり、アラート機能を実装していたとしても、WEB 画面を監視していなければ見逃してしまう。実証実験で本システムを試行した道路管理者からは、アラートに対するメール通知のニーズがあった。本システムを道路管理者に展開する際には、アラートに対するメール通知機能は大きな課題といえる。その際、道路管理者が管理する路線の地域性や気象特性によって、アラートを必要とする情報やアラートの基準が異なるため、その選択や設定機能を設けることが必要となる。

・情報やアラートの精度について

公的機関としての道路管理者が本システムの情報を用いて判断・作業を実施する場合には、その根拠となる情報の信ぴょう性が重要となる。実際、実証実験で本システムを試行した道路管理者からの意見としては、アラート等に対する情報の精度を気にする意見がいくつかあった。本システムに検討したアラートの設定条件は過去事例からの解析結果や AI 学習の結果によって定めたものであり、非日常性の発生を必ずしも保証するものでない。そのため、アラート検知の際の対象とする障害（非日常性）の発生度合いなどを分析して明確にすることも必要と考えられる。また、その発生度合いを用いてアラートのレベル表示などの工夫を検討することもできる。

b)道路管理者以外の運送事業者、個人ユーザへの情報提供する上での課題

・運送事業者

運送事業者における日々の車両運行は、運行管理者が事前に運行計画を作成し、ドライバーはその運行計画に従って運転するのが一般的である。そのため、運送事業者への情報提供は運行管理者向けの情報提供が主体となる。

予定していた運行ルート上で交通異常が発生していることを運行管理者が認識できて、運行計画を変更すべきかどうかを判断することができる情報を提供できているかどうか重要な点である。運行管理者が情報を的確に判断できれば、必要に応じてドライバーに連絡して対応することも可能となる。

・個人ユーザ

個人ユーザへの情報提供方法としては、「カーナビ」、「Web サービス」、「携帯電話」、「PC・スマートフォン向けアプリ」などがあり、また情報を参照する時点も、「旅行計画時」、「出発直前」、「ドライブ中」など色々なタイミングが考えられる。それぞれに合わせて求められる情報や情報の提供形式も異なってくるので、これらのサービスを提供している事業者と提携して情報提供していくことが考えられる。

どちらの場合でも、どのような情報をどのようにしてどう提供するのか、道路管理者とは異なる視点で、ニーズヒアリングなども含めてしっかりした検討を行う必要がある。

また、交通情報を提供する時には「交通情報の提供に関する指針」の遵守が必要となり、更に予測まで行う場合には「特定交通情報提供事業」としての届出も必要となるので、この点についても注意が必要である。

4.3 まとめと今後の展開

ここでは、リアルタイムモニタリング・アラートシステムの概要と実証実験により得られた課題について述べた。本研究で検討したいいくつかの個別開発技術を、「リアルタイム可視化システム」に組み込み、リアルタイムで交通状況、気象状況を提供するとともに、1km メッシュ単位の特異な交通状況、車両スタックや土砂災害のリスクを、インターネット経由で事前アラートするシステムを構築した。リアルタイム可視化システムは、道路管理者に複数回の試用を依頼し、実務ニーズを把握しながら実用可能なシステムとなるように心がけた。今後は実際の交通事象発生履歴と照合し、本システムでのアラートの精度検証と、生成閾値の精緻化を行う。

さらに本システムが、道路管理者の中でもより道路現場に接近しシチュエーションの確認が必要である維持出張所等への「発生事象の早期発見」と「事実確認および検証」の判断精度を向上させる業務支援システムとなり、道路管理者における「メンテナンスサイクル（診断⇒措置⇒記録⇒点検）予防保全と異常時対応」業務に現場のリアルタイムデータを俯瞰することで判断効果の向上に寄与し、アラートによる事実検証と「その次の業務」で情報共有ができる仕組み／仕掛けの実装を検討する。また、マルチデバイス環境下で道路現場からの様々なデータを集約・収集することで、道路管理者の管理・監督業務の意思決定と結果の記録をカバーすることでマネジ

メントデータとリアルタイムデータを融合したプラットフォームの提供を目指す。

第5章 まとめ

5.1 研究の総括

以上のように本研究は、「多様な交通関連データの融合」、「リアルタイム性」という特徴を持つシステム開発を行ったものであり、以下の社会的なインパクトがあると考えられる。

1. 近年頻発する地震による道路損傷，豪雪による車両スタック，豪雨による土砂災害といった災害に対して，非日常を早期に発見するとともに，そのリスクを事前にアラートすることは，安全で迅速な避難支援，予防通行規制，情報提供，道路復旧，救命救急，支援物資輸送に貢献する。
2. 道路管理者との緊密な連携をとりながら研究開発を進めてきており，地域特有のニーズに合致するようにカスタマイズすることで，管理業務や運送事業者の業務に比較的短時間で利用できるシステムが構築できた。
3. 移動体データ，気象データ等を融合活用した技術を開発しており，大きなインフラ投資を伴わないので，我が国地方都市やアジア諸都市への展開が可能である。
4. 本研究で収集した多くの被災状況データ，交通・気象・地理データ，および研究開発の成果は，今後の災害時を中心とした非日常の発見と予知に関する研究の端緒になると思われる。

5.2 今後の展望

1. 継続的な開発技術の検証

本研究で開発した技術は，研究期間内にも検証を行ってきたが，災害の種類，日時，場所を網羅したより多くの検証が必要と考える。継続的な検証の蓄積は，本研究で開発した技術の改善のためだけでなく，これから行われるであろう災害関連の研究開発にも大いに役立つと思われる。

2. 継続的なデータ蓄積

災害などの非日常事象は，災害の種類，日時，場所によって状況が変化するので多くのバリエーシ

ョンがある。一方，平常時の事象に比べればきわめて稀な事象であり，関連データの継続的かつシステムティックな蓄積が必要と考える。一般に，この分野の研究開発のためには，被災状況と計測データ（プローブ，気象データなど）をセットで収集する必要があり，本研究でも，日時と場所を合わせたデータをセットで収集するのに多くの労力を割いた。今後の研究開発のためには，これまでの関連研究で収集したデータと今後収集するデータを，整理して蓄積しておく仕組みが必要である。

3. 研究開発フェーズから実用化への移行

新道路技術開発の性格上，本研究では学術研究だけではなく，実務に利用できる技術開発を心がけてきた。しかしながら，開発技術を実務利用してもらうためには，適用地域・災害に対するカスタマイズ，利用者との調整，技術検証の蓄積，信頼性あるデータサーバの確保，システム故障対応，資金調達など，多くの課題が残されている。実用化への移行のためには，このようにいわれる「死の谷」を渡らなければならず，そのためには行政の支援が必要である。