

博士論文

プローブ車両データを用いた冬季道路交通における
異常事象の発生危険性評価

東北大学大学院 情報科学研究科
人間社会情報科学専攻 空間計画科学分野

梅田 祥吾

2020年3月

Copyright © 2020 by 梅田 祥吾

桑原雅夫

桑原 雅夫 教授
(主査)

河野 達仁

河野 達仁 教授

井上 亮

井上 亮 准教授

奥村 誠

奥村 誠 教授

要旨

プローブ車両データを用いた冬季道路交通における 異常事象の発生危険性評価

梅田 祥吾

本研究は、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、広範囲の一般道路ネットワークを対象に、プローブ車両データと気象データを用いて、異常事象の発生危険性を逐次的かつ定量的に評価する手法を提案するものである。

提案手法により、一般道路ネットワークを対象とした冬季道路交通における異常事象の発生危険性を逐次的かつ定量的に評価することが可能となる。そのため、道路管理者は、従来の道路監視エリアを拡大することができ、事象発生前の予防的な対応、事象発生後の早期対応の判断をサポートすることで、冬季道路管理の目標として掲げる「道路ネットワーク全体として大規模な車両滞留の抑制と通行止め時間の最小化(道路ネットワーク機能への影響の最小化)」の達成に貢献することが出来る。

具体的には、道路の走行性能を定義し、プローブ車両データから推定する過去の道路の走行性能と状態空間モデルを用いてリアルタイムに推定する道路の走行性能との乖離程度を評価し、実際に発生した異常事象との関係を分析することで、冬季の道路交通異常事象の発生危険性を評価する手法を提案した。

提案手法を実際に異常事象が発生した際のデータ(61事例:約3,700区間)に適用した結果、多くの場面において、異常事象が発生する前にその危険性が高いことを評価することができ、

異常事象の発生後には、既に異常事象が発生している可能性が高いことを評価できることを明らかにした。また、観測値として評価区間を通過するプローブ車両速度集合の 85 パーセントイル速度に着目し、観測値とモデルの両方に誤差を仮定する状態空間モデルを用いることにより、誤発報を大幅に減らすことが出来ることを明らかにした。提案手法は、監視範囲とコストの観点からも、現状のモニタリング手法よりも制約が少ない手法であるため、有用性が高い。

目次

	頁
第1章 序論.....	1-1
1-1 研究の背景.....	1-1
1-2 研究の目的.....	1-6
1-3 本論文の構成.....	1-7
第2章 本研究の位置付けと既往研究について.....	2-1
2-1 整理の方針.....	2-1
2-2 冬季気象条件が道路交通に与える影響に関する研究.....	2-2
2-3 道路交通における異常事象検知に関する研究.....	2-5
2-4 その他分野における異常事象検知に関する研究.....	2-7
2-5 本研究の位置付け.....	2-10
第3章 冬季道路交通における異常事象発生危険性の評価手法の提案.....	3-1
3-1 研究対象の定義について.....	3-1
3-2 手法に求められる要件.....	3-2
3-3 手法のコンセプト.....	3-3
3-4 技術的な課題と対応.....	3-6
3-5 状態空間モデルについて.....	3-9
3-6 線形ガウス状態空間モデル.....	3-12
3-7 提案手法の全体像.....	3-16
3-8 冬季道路交通における異常事象の発生危険性評価手法の手順.....	3-18
3-9 本研究の状態空間モデル.....	3-24
3-10 モデル選択方法.....	3-30
第4章 実データによる提案手法の適用検証.....	4-1
4-1 検証フロー.....	4-1
4-2 検証対象の整理.....	4-2
4-3 妥当性評価方法の検討.....	4-9
4-4 実データを用いた妥当性評価結果.....	4-18
4-5 モデル選択結果.....	4-26

4-6 手法の有効性の確認.....	4-30
4-7 結果のまとめと考察.....	4-31
第5章 個別事例の詳細分析.....	5-1
5-1 分析対象の選定.....	5-1
5-2 山形県国道47号における立ち往生事例.....	5-1
5-3 福井県国道8号における立ち往生事例.....	5-16
5-4 結果のまとめ.....	5-34
第6章 結論.....	6-1
6-1 本研究の成果.....	6-1
6-2 評価結果に関する考察.....	6-2
6-3 今後の課題.....	6-4
6-4 今後の展望.....	6-7
Appendix1. 状態空間モデルによる状態の逐次推定方法.....	1
Appendix2. カルマンフィルタアルゴリズム.....	3
Appendix3. 時系列の予測.....	5
Appendix4. モデル別・事例別の異常事象発生前のアラート有無.....	6
Appendix5. モデル別・事例別の異常事象発生直後のアラート有無.....	9
Appendix6. モデル選択指標の算出結果.....	12
Appendix7. 山形県国道47号における立ち往生事例の基礎情報.....	15
Appendix8. 福井県国道8号における立ち往生事例の基礎情報.....	25

図目次

	頁
図 1-1 論文の構成	1-8
図 3-1 提案手法のイメージ図	3-3
図 3-2 区間別時間帯別の個別車両の通過速度分布の例	3-5
図 3-3 時間帯別の 85 パーセンタイル速度分布	3-5
図 3-4 通過台数別のデータ数と割合	3-7
図 3-5 時間帯別のプローブ車両 0 台の区間の割合	3-7
図 3-6 提案手法の全体像と計算フロー	3-17
図 4-1 検証フロー	4-1
図 4-2 立ち往生発生箇所的位置図	4-6
図 4-3 提案手法の概念図	4-10
図 4-4 評価視点①のイメージ図	4-12
図 4-5 評価視点②のイメージ図	4-12
図 4-6 評価視点③のイメージ図	4-13
図 4-7 評価視点④のイメージ図	4-13
図 4-8 異常事象発生直前アラート評価のイメージ	4-15
図 4-9 異常事象発生直後アラート評価のイメージ	4-16
図 4-10 除雪前後の異常事象の発生危険性評価のイメージ	4-17
図 4-11 モデル別の特異度の箱ひげ図	4-19
図 4-12 モデル別の異常事象発生直前のアラート事例数	4-20
図 4-13 モデル別の異常事象発生直後のアラート事例数	4-22
図 4-14 モデル別の除雪前後 KL 距離と KL 距離比	4-24
図 4-15 気象条件別のアラート率	4-29
図 4-16 事例別の特異度の比較	4-30
図 4-17 モデル 13 による立ち往生規模別の異常事象発生直前のアラート内訳	4-32
図 4-18 モデル 13 による立ち往生規模別の異常事象発生直後のアラート内訳	4-32
図 5-1 検証対象範囲(山形県国道 47 号)	5-2
図 5-2 異常事象の発生危険性評価結果(アラート)	5-4
図 5-3 異常事象の発生危険性評価結果(KL 距離)	5-5

図 5-4	立ち往生発生箇所における異常事象の危険性評価結果(No.31).....	5-7
図 5-5	予測残差の時間変動(No.31).....	5-7
図 5-6	レベル成分の時間変動(No.31).....	5-9
図 5-7	周期成分の時間変動(No.31).....	5-9
図 5-8	気温(上)と気温回帰成分(下)の時間変動(No.31).....	5-9
図 5-9	6時間前累積降雪量(上)と降雪量回帰成分(下)の時間変動(No.31).....	5-10
図 5-10	プローブ通過台数(上)とプローブ通過台数回帰成分(下)の時間変動(No.31).....	5-10
図 5-11	平常期間における異常事象の発生危険性評価結果(アラート).....	5-12
図 5-12	平常期間における異常事象の発生危険性評価結果(KL 距離).....	5-13
図 5-13	平常期間における異常事象の発生危険性評価結果(観測値：85 パーセントイル速度).....	5-14
図 5-14	気象条件別のアラート率.....	5-15
図 5-15	検証対象範囲(福井県国道 8 号).....	5-17
図 5-16	異常事象の発生危険性評価結果(アラート).....	5-20
図 5-17	異常事象の発生危険性評価結果(KL 距離).....	5-21
図 5-18	立ち往生発生箇所における異常事象の危険性評価結果(No.44).....	5-23
図 5-19	予測残差の時間変動(No.44).....	5-23
図 5-20	レベル成分の時間変動(No.44).....	5-25
図 5-21	周期成分の時間変動(No.44).....	5-25
図 5-22	気温(上)と気温回帰成分(下)の時間変動(No.44).....	5-25
図 5-23	6時間前累積降雪量(上)と降雪量回帰成分(下)の時間変動(No.44).....	5-26
図 5-24	プローブ通過台数(上)とプローブ通過台数回帰成分(下)の時間変動(No.44).....	5-26
図 5-25	異常事象の発生危険性評価結果(アラート).....	5-28
図 5-26	異常事象の発生危険性評価結果(KL 距離).....	5-29
図 5-27	平常期間における異常事象の発生危険性評価結果(観測値：85 パーセントイル速度).....	5-30
図 5-28	平常期間における異常事象の危険性評価結果(No.47).....	5-32
図 5-29	気温と降雪量とアラート率の関係.....	5-33
図 6-1	アラートの概念図.....	6-5

表目次

	頁
表 1-1 大雪時の道路交通確保に向けた新たな取り組み.....	1-3
表 3-1 プローブ車両速度に影響を与える要因(不確実性を生む要因)と対応.....	3-5
表 3-2 構築モデル一覧.....	3-25
表 3-3 周期成分の考え方(4周期の例).....	3-28
表 4-1 適用事例一覧表.....	4-3
表 4-2 異常検知分野の性能評価の混同行列.....	4-9
表 4-3 危険性評価の妥当性評価の視点.....	4-11
表 4-4 本研究における混同行列.....	4-14
表 4-5 モデル別推定パラメータの最尤推定量の中央値一覧.....	4-18
表 4-6 モデル別の特異度の平均値の一覧.....	4-19
表 4-7 モデル別の異常事象発生直前のアラート事例数の一覧.....	4-21
表 4-8 モデル別の異常事象発生直後のアラート事例数の一覧.....	4-23
表 4-9 モデル別の除雪前後の KL 距離の比較結果一覧.....	4-25
表 4-10 モデル別の評価結果.....	4-27
表 5-1 山形県国道 47 号立ち往生発生内容一覧.....	5-2
表 5-2 山形県国道 47 号推定モデルパラメータ(No.31).....	5-6
表 5-3 福井県国道 8 号立ち往生発生内容一覧.....	5-18
表 5-4 福井県国道 8 号推定モデルパラメータ(No.31).....	5-22
表 5-5 福井県国道 8 号推定モデルパラメータ(No.47).....	5-31
表 6-1 評価結果に悪影響を与える要因一覧.....	6-2

第1章 序論

1-1 研究の背景

本研究は、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、一般道路を含む広範囲の道路ネットワークを対象に、プローブ車両データを用いて、異常事象の発見及び発生危険性を逐次的かつ定量的に評価する手法を提案するものである。

本章では、研究の背景として、冬季道路交通に関連する社会の情勢、冬季道路交通管理の現状、本研究で活用するプローブ車両データの特徴と課題について整理し、本研究の社会的な有用性と意義について述べる。

1-1-1 冬季道路交通における社会情勢

近年、我が国では、雪の降り方が変化している。多くの観測地点で、積雪深さが史上最高を更新し、雪の少ない地域でも記録的な降雪が観測されている。その影響により、道路交通ネットワークが大規模かつ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¹⁾。2018年1月には、関東地方を中心に大雪に見舞われ、転倒や車両のスリップ事故が相次いだ。この時、首都高速道路では複数箇所で大規模な立ち往生が発生し、首都高速道路の全延長の約7割にのぼる約230km、20路線で本線通行止めを行い、全ての通行止めが解除されるまでに、97時間を要した²⁾。また、同年2月には北陸地方を中心とした大雪が発生し、福井県の国道8号線では、最大約1,500台の車両の滞留が発生し、滞留の完全解消までに3日間を要した³⁾。さらに、2019年1月には、山形県の国道47号で200台を超える車両が立ち往生し、通行規制の解除まで長時間を要した⁴⁾。これらの事例以外にも冬季気象の影響によって大規模に車両が滞留し、通行再開までに時間を要したケースが多数発生している。

これらの甚大な被害を受けて、国土交通省は2018年2月に、「冬季道路交通確保対策委員会」を設置し⁵⁾、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、チェーン未装着車の通行制限やペナルティ制度、雨量規制のように高速道路や国道を早めに通行規制し、集中的な除雪を行うための「予防的通行止め」の導入等の今後の冬季の道路交通確保対策について、議論している。

1-1-2 冬季道路交通管理の現状とこれからの取り組み

本項では、我が国における従来の冬季道路管理の現状と冬季道路交通確保対策委員会で議論されたこれからの冬季道路管理における取り組みについて整理する。

(1) 冬季道路交通管理におけるモニタリングの現状

我が国の従来の冬季道路管理では、異常事象の発生危険性を逐次的かつ定量的に評価することは行われてこなかった。我が国の道路交通のモニタリングは、管理者による巡回、CCTVで撮影した動画像や車両感知器によって観測された情報(平均速度や交通量)をモニターで監視する方法が中心である。特に、一般道路は高速道路と比較して管理延長が長いため、監視できない区間や時間帯が多く異常事象への対応が遅れやすいという課題がある。車両感知器等の固定センサーでの監視が可能な区間においても、単なる速度の低下であるのか、異常な速度の低下なのかを判別することが出来ない。また、信号や沿道施設、細街路といった、車両の行動パターンを複雑にする要素が多いことが異常事象の発見を難しくしている。冬季道路交通では、大規模な立ち往生を防ぐために、予防的通行止めや除雪の強化といった異常事象の発生する前、発生直後の早期対応がより一層重要となっている。これまでの冬季の通行止めや除雪の判断は、基本的に天気予報を頼りにしており、各自治体が定めている新雪積雪深の基準を超えた場合に除雪車が出動する等の対応を取っている⁹⁾。本来は、気象状況に加えて道路交通の状況をモニタリングし、異常事象の発生危険性を逐次的に評価することが望ましいが、手法や指標が確立されていない。気象情報に加えて、時々刻々と変化する道路交通の状況を逐次的にモニタリング出来れば、より精度の高く冬季の通行止めや除雪の判断をすることや経験値の裏付けに貢献できる。

(2) 冬季道路交通管理のこれからの取り組み

我が国の今後の冬季道路管理のこれからの取り組みについては、冬季道路交通確保対策委員会で議論が重ねられ、大雪時の道路交通確保対策中間とりまとめ(案)が公表されている¹⁰⁾。同資料では、表 1-1のように今後の大雪時の道路交通確保に向けた、ソフト的な対応とハード的な対応といった道路利用者・社会全体が取り組むべき内容が整理されている。これらの対応をより効率的に行うための提言として、「新技術の積極的な活用」があり、車載センサーを活用した迅速な状況把握等が必要とされている。また、同資料では、大雪時の道路交通確保に対する考え方について「自らが管理する道路を出来るだけ通行止めしないこと」から「道路ネットワーク全体として大規模な車両滞留の抑制と通行止め時間の最小化を図る(道路ネットワーク機能への影響の最小化)」への転換が必要とまとめられている。

表 1-1 大雪時の道路交通確保に向けた新たな取り組み

	対応	内容
ソフト 的対応	○タイムライン（段階的な行動計画）の作成	<ul style="list-style-type: none"> ・関係機関との合同訓練 ・気象予測の精度向上
	○除雪体制の強化	<ul style="list-style-type: none"> ・地域状況に応じた除雪体制の強化 ・道路管理者間の協力体制等の構築
	○集中的な大雪時の予防的な通行規制・集中除雪の実施	<ul style="list-style-type: none"> ・道路ネットワーク全体の通行止め時間の最小化 ・リスク箇所の事前把握と監視等の強化 ・集中除雪による早期開放 ・予防的な通行規制に伴う広域迂回等の呼びかけ
	○立ち往生車両が発生した場合の迅速な対応	<ul style="list-style-type: none"> ・リスク箇所の事前把握 ・迂回路として活用できる接続道路の道路管理者との協議 ・沿道物流施設や商業施設に付随する大規模駐車場活用のための協定締結
ハード 的対応	○基幹的な道路ネットワークの強化	<ul style="list-style-type: none"> ・高速道路の暫定2車線区間や主要国道の4車線化，付加車線や登坂車線の設置，バイパス等の迂回路整備等を実施
	○スポット対策，車両待機スペースの確保	<ul style="list-style-type: none"> ・車両待機スペースの確保・リスク箇所に対しては，カメラの増設や，定置式溶液散布装置，ロードヒーティングや消雪パイプ等の消融雪施設の整備，除雪拠点の新設・更新等 ・SA・PAの拡張，待避所等の整備
道路利 用者・ 社会全 体の取 り組み	○集中的な大雪時の利用抑制・迂回	<ul style="list-style-type: none"> ・不要・不急の道路利用を控える(道路の利用抑制) ・除雪作業やUターン等による迂回行動の必要性を理解 ・集中的な大雪時に備えた行動計画（BCP）を策定
	○冬道を走行する際の準備	<ul style="list-style-type: none"> ・チェーン等の装備. ・車内にスコップや飲食料，毛布，砂，軍手，長靴，懐中電灯，スクレーパー等の準備 ・都道府県公安委員会や運送事業者等は，地域の実情に応じ，運転免許の取得・更新時や各種研修，ドライバーへの周知

1-1-3 プローブ車両システムについて

前述したように今後の冬季道路交通管理では、様々な新技術を活用し広範囲の道路ネットワークを逐次的にモニタリングし、異常事象の発生に備える必要がある。そのための有用な技術の一つとして、プローブ車両システムがあり、本研究では、この技術、データを活用する。プローブ車両は、走行位置や速度等の車両挙動をセンサーによって観測し、交通状況をモニタリングすることを目的とした技術である。このプローブ車両は、車両数が増えるほどモニタリング精度が向上し、モニタリング範囲を拡大することが出来るため、広域な交通状況をモニタリングすることにおいて、コストとエリアカバーの観点から有効な手段の一つである¹¹⁾。

1-1-4 研究の背景のまとめ

- 近年、我が国では、雪の降り方の変化が変化している。多くの観測地点で、積雪深さが史上最高を更新し、雪の少ない地域でも記録的な降雪が観測されている。その影響を受けて、大規模な道路交通異常が多発している。
- 大雪時の道路交通確保対策中間とりまとめ(案)によって、今後の大雪時の道路交通確保に向けた取り組むべき内容が整理され、道路管理者は、大雪時の道路交通確保に対する考え方について「道路ネットワーク全体として大規模な車両滞留の抑制と通行止め時間の最小化（道路ネットワーク機能への影響の最小化）」への転換を図っている。
- 従来の冬季道路管理では、異常事象の発生危険性を逐次的かつ定量的に評価することは行われておらず、冬季道路における通行規制や除雪の判断は、天気予報を頼りにしており、経験や技術レベルによって判断にばらつきが生まれたり、モニタリングできない範囲が存在するといった課題がある。
- プローブ車両システムは、広域な交通状況をモニタリングすることにおいて、コストとエリアカバーの観点から有効な手段の一つである。
- 今後の冬季道路管理に求められることは多く、冬季の道路交通ネットワークで発生する異常事象を理解し、その発生危険性を適切に評価することの重要性は年々高まっている。異常事象の早期発見および発生危険性を逐次的に評価することが出来れば、道路交通管理者の迅速な判断、対応を促すことができ、大規模な車両滞留の発生抑制や通行の早期再開のための予防的通行止めや集中的な除雪、異常事象発生後の迅速な救助、復旧に貢献できる。

1-2 研究の目的

前述の背景を踏まえ、本研究では、冬季道路交通における道路管理を支援し、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(道路ネットワーク機能への影響の最小化)を長期的な目的とする。

この目的の達成のためには、以下の2つの方針とその方針に沿った手法の開発が必要である。本研究では、上記の長期的な目標達成のため、冬季道路交通において実際に異常事象が発生した多数の事例のデータを用いて、一般道を含む広範囲の道路ネットワークの性能低下を評価し、異常事象の発生危険性を逐次的かつ定量的に評価する手法の提案を目的とする。提案手法は、実際の道路管理実務への活用を目指している。

方針①：異常事象の発生を未然に防ぎ、異常事象の発生を減少させる(予防的な対応)。

- 逐次的に異常事象の発生危険性が高い状況を推定し、道路管理者が予防的通行止め、集中的な除雪の実施を判断できる手法(予防的な対応をサポートする手法)

方針②：異常事象の発生を早期に発見し、早期に対処することで、異常事象が交通に与える影響を小さくする(事後的な対応)。

- 広範囲の道路ネットワークを対象に従来の道路管理者のモニタリング手法(固定センサーによる監視)よりも一刻も早く、異常事象の発生に気づき、対応を促すことのできる手法(事後的な対応をサポートする手法)

1-3 本論文の構成

本節では、本論文の構成について整理する。本論文は全6章からなり、それぞれの章の概要は以下のとおりである。

まず、第2章では、本研究の関連研究として冬季気象条件が道路交通に与える影響に関する研究として、冬季気象が交通流に与える影響に関する研究、冬季道路交通における異常事象の発生メカニズムに関する研究、道路交通における異常事象検知に関する研究についてレビューする。また、交通以外の分野にもレビュー範囲を拡大するとともに、センシングデータの異常検知に関する研究や時系列データの変化点検知に関する既往研究についてレビューし、本研究の位置づけと貢献について整理する。

第3章では、本研究で提案する冬季道路交通における異常事象発生の危険性評価手法のコンセプトや具体的な計算手順について整理する。その際に、本研究で対象とする異常事象の範囲や異常事象発生のメカニズムの仮説、異常事象の発生危険性の評価手法に求められる要件、制約と技術課題、手法のコンセプトについても併せて整理を行う。

第4章では、第3章で提案した異常事象の発生危険性の評価手法を規模や地域の異なる複数の実災害時のデータ(61事例:3,721区間)に適用し、異常事象の発生危険性評価手法の検証を行い、複数のモデルの中からモデルの評価・選択を行う。

第5章では、山形県国道47号で発生した立ち往生事象及び福井県国道8号線で発生した立ち往生の2事例について、第4章で選択したモデルでの異常事象の危険性評価結果を確認し、モデルの妥当性について確認を行う。

最後に第6章は、本論文の結論であり、得られた結果を整理し、総括するとともに、今後の展望について議論する。

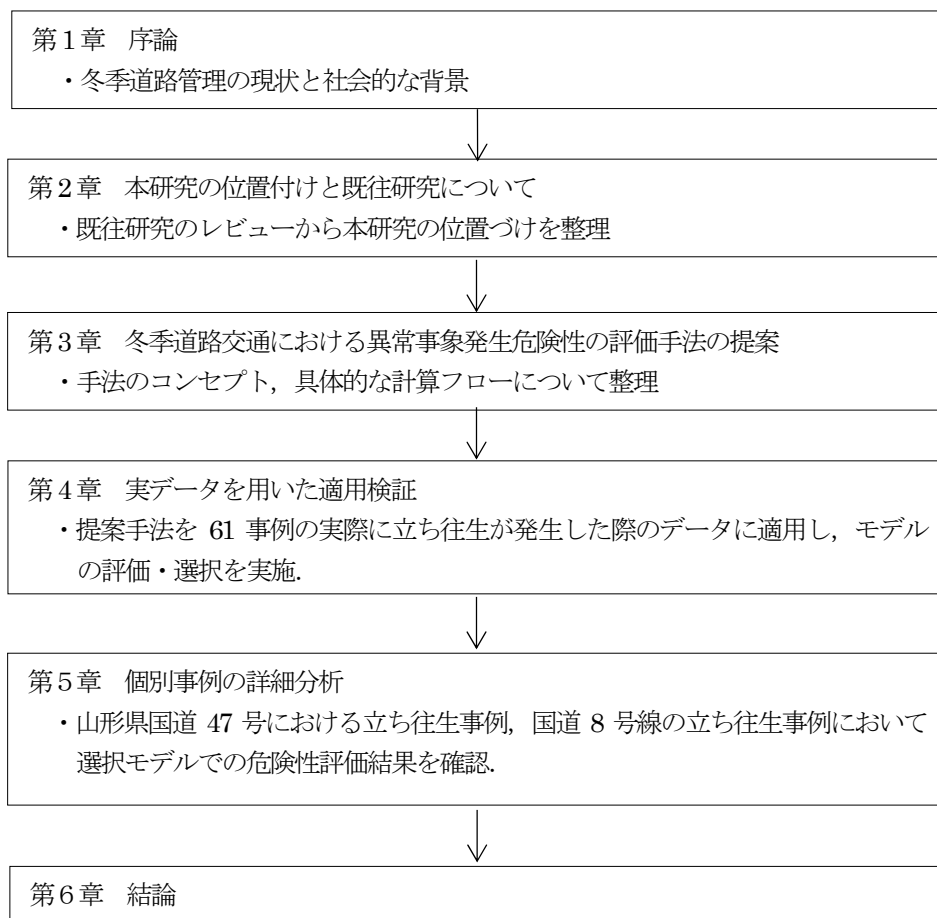


図 1-1 論文の構成

1章の参考文献

- 1) 国土交通省 HP :冬期道路交通確保対策検討委員会資料, <https://www.mlit.go.jp/road/ir/ir-council/oukidourokanri/pdf04/02.pdf>. (最終閲覧日 : 2019年10月19日)
- 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/oukidourokanri/pdf01/05.pdf>. (最終閲覧日 : 2019年10月19日)
- 3) 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/oukidourokanri/pdf01/06.pdf>. (最終閲覧日 : 2019年10月19日)
- 4) 国土交通省山形河川国道事務所 HP :大雪による道路防災情報 (第2報・終報), http://www.thr.mlit.go.jp/Bumon/kisya/saigai/images/73448_1.pdf. (最終閲覧日 : 2019年10月19日)
- 5) 国土交通省北陸地方整備局 HP : 道路の維持管理方針 (案), <http://www.hrr.mlit.go.jp/road/maintenance/policy.pdf>. (最終閲覧日 : 2019年10月19日)
- 6) 新潟県上越市 HP : 平成30年度冬期道路交通確保除雪計画書, <https://www.city.joetsu.niigata.jp/uploaded/attachment/153835.pdf>.
- 7) 札幌市 HP : 札幌市計画除雪, <https://www.city.sapporo.jp/kensetsu/yuki/jigyou/keikakujiyosetsu.html>. (最終閲覧日 : 2019年10月19日)
- 8) 福井市 HP : 福井市道路除雪計画書 (平成29年度), https://www.city.fukui.lg.jp/kurasi/koutu/snow/zyosetunituite_d/fil/josetukeikaku.pdf. (最終閲覧日 : 2019年10月19日)
- 9) 鶴岡市 HP : 平成30年度, 市道等除雪計画書, <https://www.city.tsuruoka.lg.jp/seibi/doro/doroseibi/jyosetukeikaku.files/H30keikakusyozensi.pdf>. (最終閲覧日 : 2019年10月19日)
- 10) 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/oukidourokanri/pdf/t02.pdf>. (最終閲覧日 : 2019年10月19日)
- 11) 国土技術政策総合研究所 HP:, <http://www.nilim.go.jp/lab/qcg/japanese/2reserch/1field/03probecar/p/ro.htm> (最終閲覧日 : 2019年10月19日)

第2章 本研究の位置付けと既往研究について

2-1 整理の方針

本章では、本研究が対象とする冬季道路交通における異常事象の発生危険性評価に関連する既往研究をレビューし、本研究の位置付けを整理する。なお、本研究で提案する冬季道路交通における異常事象の危険性評価手法における評価指標の考え方やデータ処理方法やモデル構築の際の考え方等、個別の技術に関連する既往研究の整理はその都度行う。

まずは、冬季気象が道路交通に与える影響に関する研究、冬季道路交通における異常事象の発生メカニズムに関する研究をレビューし、本研究で対象とする冬季道路交通における異常事象について、既往研究で明らかになっている範囲を整理する。次に、道路交通における異常事象についてセンシングデータを用いて検知を試みている研究、交通以外の分野も含めた異常検知手法、変化点検知手法に関する研究についてレビューする。

2-2 冬季気象条件が道路交通に与える影響に関する研究

2-2-1 冬季気象条件が交通流に与える影響に関する研究

気象条件による路面の状況や視界の良し悪し等が交通流に影響を及ぼすことが知られている。道路構造令¹⁾では、積雪寒冷地における道路の構造について、「冬季通行の安全性・円滑性が低下する積雪寒冷地域では、冬季でも一定の自動車の通行機能が確保できるよう、積雪や凍結を考慮した道路構造とすべきである。」と記載されている。道路の交通容量²⁾では、「積雪寒冷地において、冬季積雪時には路上の雪、路肩を含めた路側の堆雪のため道路の側方余裕の減少、幅員の狭隘化を来し、車頭間隔の増大や走行速度の低下を招くなど、一般に交通容量を減少させると言われている。しかし、これらの影響度合は、積雪状態に応じていろいろな範囲に分布しており、我が国では調査研究の例も少なく、積雪時の影響度合を特定することは現段階では、非常に困難である。積雪の影響は地域により大きく変化するので、各地域に見合った要因補正を今後検討していく必要がある。」と記載されている。

国内外において、現在に至るまで、冬季気象が道路交通にどのような影響をどの程度与えるかについては、様々な研究がなされてきた。寺内ら³⁾⁴⁾は、積雪時の道路交通管理計画立案のための基礎情報を得ることを目的に、福井県大野市郊外のバイパス道路での実測調査により無雪時と積雪時の速度分布、車頭時間分布の変化を分析し、積雪により速度の低下と車頭時間が増大することを報告している。宗広ら⁵⁾は、タクシープローブ調査による札幌市内の交通特性の分析を行い、無雪期と積雪期の交通特性を比較し、降雪時や圧雪路面の発生により、平均旅行速度が著しく低下したことを報告している。Lu et al.⁶⁾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⁷⁾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整理し、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。榎谷ら⁸⁾は、数量化理論I類を用いて、冬期の峠部の天候、路面状態、平面線形が車両走行速度に与える影響を分析し、峠部の下りでは車両速度の低下が顕著に見られ、天候、路面状況の悪化と共にその影響も大きくなることを明らかにしている。武知ら⁹⁾は、走行実験と定点観測の結果を基に郊外道路における走行速度と季節、道路線形、視界、風速及び路面状況の関係について分析を行っている。その結果、積雪期の走行速度は、無雪期に比べ低下しており、道路の曲線半径、視界状況の影響を強く受けると整理している。

Datta et al.¹⁰⁾¹¹⁾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、気象の程度によって異なることを示した。谷村ら¹²⁾は、札幌市において、プローブ車両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。また、ある路線では積雪量以外にも前日最高気温が速度低下に影響を与えていたのに対し、別の路線では前日日照時間が速度低下要因となることを整理している。Heqimi et al.¹³⁾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¹⁴⁾は2014年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、プローブ車両データの空白域が広がることを明らかにした。山田¹⁵⁾は、状態スイッチングモデルを冬季の道路交通データに適用し、路面の凍結状態と走行速度の関係を分析している。Seeherman et al.¹⁶⁾は、降雪の多い地域における降雪量と積雪頻度が交通事故の程度と頻度を与える影響について、回帰分析を行い積雪が事故に大きな影響を与えることを定量的に示した。

上記に示すように、冬季の気象条件が交通流に与える影響度合や程度を分析している研究は多く存在し、車両速度や交通容量に大きな影響を与えることがわかっている。また、気象条件の程度や道路の幾何構造などの特性が交通に与える影響の度合いの大小を変える条件となることについてもわかっているものの、本研究が対象とする立ち往生やスタックといった冬季道路交通における極端な事象を取り扱った研究は見当たらない。

2-2-2 冬季道路交通における異常事象の発生メカニズムに関する研究

本研究で対象とする冬季道路交通における異常事象を対象にその発生メカニズムに関する研究は非常に少ない。平ら¹⁷⁾は、高速道路における実験において、タイヤの通過回数と圧雪形成の関係を分析し、タイヤの発熱とマイナス路面及び凍結防止剤によって路面の凍結、融解の繰り返しにより氷面積が増大し、上り坂で滑り摩擦係数が低下することにより登坂不能が発生すると述べている。藤本¹⁸⁾は、実車両を用いたスタック実験と路面圧雪層のせん断破壊実験によりスタック車両発生予測モデルの開発を試みているが、データ不足や収集データの誤差等の要因により、十分な精度を持つモデル開発には至っていない。

国土交通省による冬季立ち往生の発生傾向の報告¹⁹⁾によると、立ち往生車両は、年間約500台以上発生し、そのうちの約6割は大型車であること、冬タイヤを装着していても、縦断勾配5%を超える区間では立ち往生が多く発生していること、冬タイヤを装着している車両のうち、チェーン未装着車が9割弱を占めており、冬タイヤだけでは不十分であるとされている。また、株式会社富士通交通・道路データサービス社²⁰⁾は、2018年に発生した大雪時の福井県国道8号の物流貨物車両の走行状況を物流貨物車両に搭載された富士通製デジタルタコグラフから収集された走行情報をもとに分析している。大雪時は、通常時と比べて国道8号線区間を通過する際の所要時間が大幅に増加しており、途中で折り返す車両や広域な迂回を行う車両が増えていることを報告している。

2-3 道路交通における異常事象検知に関する研究

道路交通に関するセンシングデータ(車両感知器データやプローブ車両データ等)を用いて、道路交通における異常事象の発生を検知もしくは、推定を目的とした研究は、数多く実施されている。

2-3-1 プローブ車両データを用いた例

本研究と同じようにプローブ車両データに着目し、その集計量を用いた例としては、Horiguchi et al.²¹⁾の研究がある。Horiguchi et al.は、1km四方のエリア内のプローブ車両の存在台数と交通流率との関係を推定し、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知する手法を提案している。また、牛木ら²²⁾は、プローブ車両による観測データを用いた突発事象検知手法を提案し、シミュレータ実験で検証を行っている。プローブ車両の旅行時間の変化を確認することに加え、突発的ボトルネックの交通容量低下を考慮し、プローブ車両の交通流率を取り入れることで、一定の検知精度を得られることを示している。Li and McDonald²³⁾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車両の通過台数の時間的变化により異常事象の検知を行う手法を提案している。

次に、プローブ車両の1台1台の走行軌跡データを用いた例を整理する。Petty et al.²⁴⁾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ている。Asakura et al.²⁵⁾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 et al.²⁶⁾は、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知する手法等を提案している。Takenouchi et al.²⁷⁾は、対向車線のプローブ車両の情報を用いて、事故などの突発事象の発生場所と時間の推定精度が従来の順方向のプローブ車両のみを用いた手法よりも精度向上が期待できる手法を提案している。川崎ら²⁸⁾は、機械学習アルゴリズムの一つであるOne-Class Support Vector Machine (OCSVM)を用いて、平常時のプローブ車両軌跡の学習結果から西日本豪雨時のプローブ車両軌跡を分類し、異常な経路(迂回)の抽出を試みている。また、Yoshida et al.²⁹⁾は、熊本地震発生時のプローブ車両軌跡データを解析し、車両軌跡の観測点情報を文字に置き換え、経路全体の文字列の差異(レーベンシュタイン距離)を評価することによって地震時の通行不能箇所の発見を試みている。Pan et al.³⁰⁾は、交通ネットワーク上の走行経路に着目して交通事故等の異常検知を行っている。この他にも、赤塚ら³¹⁾は、高速道路を対象に時間平均速度と空間平均速度の特徴量、ゆらぎを用いた異常事象の発見手法を提案している。

2-3-2 車両感知器データを用いた例

次に車両感知器データを使用した例を整理する。Salamanis et al.³²⁾は、高速道路の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ている。野村ら³³⁾は、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し、首都高の5路線に適用している。Wang et al.³⁴⁾は、交通ネットワーク上における正常な交通状況が動的に変化するという前提を置いた上での交通異常の検知方法を提案している。Li et al.³⁵⁾は、異常検知を含む交通状況の時系列分析は、トレンドモデリングによって統一的に記述することができると述べている。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 et al.³⁶⁾やKawasaki et al.³⁷⁾がある。

2-3-3 その他

その他の交通に関連した異常検知の例として、井上ら³⁸⁾は、空港流入交通量データに対して独立成分分析を適用することにより、欠航日特有の交通量の時間分布の特性解明を試みている。神谷ら³⁹⁾は、メッシュ人口の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を提案している。

Mahadevan ら⁴⁰⁾は、動画像を用いて人口動態の異常検知を行っている。監視カメラに映る人流をdynamic textureと呼ばれる動画像から抽出した特徴ベクトルを利用した混合モデルでモデル化し、負の対数尤度をから動画内の異常行動を検知する方法を試みている。他にも画像を用いた例として、上条ら⁴¹⁾や原田ら⁴²⁾がある。任意の車線数の無分岐道路を対象に、時空間Markov Random Field(MRF)モデルにより、車両の隠れや照度変化に対しても頑強な異常事象の検知システムを開発している。牧野ら⁴³⁾や拓殖ら⁴⁴⁾も、高速道路を対象にして動画像から事故等の突発事象を検知するシステムを開発している。

以上のように道路交通における異常事象の検知は、多様のデータ、手法によって取り組まれているが、上記の多くの手法が事故や故障車といった突発事象発生後の早期検知を目的としており、本研究のように気象の影響により発生する異常事象を対象とし、その事象が発生する前にその危険性を評価することを目的とした研究ではない。また、車両感知器やCCTVといった固定センサーのデータを用いた手法が多く提案されているが、そもそも固定センサーが設置されていない区間では、事象の評価、検知が出来ない。

2-4 その他分野における異常事象検知に関する研究

本節では、道路交通以外の分野にレビューの範囲を広げ、データ解析における異常事象検知に関する研究についてレビューする。

2-4-1 異常検知について

データ解析の分野では、異常検知と変化検知は、実務上重要な位置をしめており統計学の分野では、1世紀近い歴史を持つ分野である。そのため、関連書籍は多く存在する⁴⁵⁾⁴⁶⁾⁴⁷⁾⁴⁸⁾。関連書籍を参考に、異常検知問題について概説する。異常検知問題は基本的に、データラベルの有無によって、教師あり異常検知、半教師あり異常検知、教師なし異常検知の3つに分類される。ただし、一般的に異常検知の分野では異常のデータが正常のデータに比べて極端に数が少ないことが多い。このようなデータセットは不均衡データ (Imbalanced data) と呼ばれ、評価指標と手法の適切な調整が重要で、取り扱う上で注意が必要となる。そのため、前提として学習データのほとんどは正常データで異常データは全くないか、あったとしてもごく少量と考えることが多い。異常検知の基本的な考え方は、特徴空間上で正常データは密集しており、一方、異常データは高密度部分から外れた位置にあるものとして考える。各データ点に対して、異常度のスコアリングを行い、閾値を決めてスコアに応じて検知する。異常度のスコアリングは学習データを用いて、正常データの範囲をモデル化して正常データから遠い点に対して異常度を高く見積もることで異常を検知する。例えば、ホテリングのT²法、Maharanobis Taguchi System(MTS)、Similarity Based Modeling(SBM)、Gaussian Process Regression(GPR)といった手法がある。しかし、これらの正常モデルとの比較による手法では、観測値と正常モデルとの距離によって、状態変化の発生を判断するため、データの値からは見えてこない状態の変化や観測値にノイズが多い場合には、正しく異常を検知することが難しいという課題がある。

世の中の多くの動的な系から生じる時系列データを考える場合、隣り合う時刻の観測値同士には明らかな相互関係があり、各観測値の時刻を適当に並び替えると異常を検知できなくなる。これは、前の時刻の観測値との関係が、異常の判定に本質的であり、各観測値が独立であるという前提が成り立たないことを示している。したがって、観測値が互いに独立であると仮定する方法は、これらの異常検知では無力である。このように時系列で観測される時系列データを取り扱う場合は、時系列性を明示的に取り入れた異常検知の方法が必要である。簡単な方法として、近傍法による異常部位検知がある。スライド窓という考え方により、時系列に隣接した観測値をひとまとまりにして扱い、外れ値検知問題を部分時系列に対して適用したものである。近傍法による異常部位検知の枠組みは汎用的に使えるが、特別なチューニングを行わずに、手法を適用した場合、見逃しや誤発報が起こる。これは、時系列に含まれるノイズが、近傍の計算に大きな影響を与えるためである。

ノイズを除去し、今の状況が少し前の状況に似ているはずだという仮定を置いて時系列の変化をとらえる手

法として、特異スペクトル変換法や自己回帰モデルを用いた異常検知手法が提案されている。これらは、一般的に正規分布に基づく、正弦波に近い形を持つデータには比較的うまく予測が出来るが、突発的に大きな値をとるデータにはうまくいかないことが知られている。そのようなデータについては、適切な前処理を行い変化をスムージングすることが必要となる。

本研究で対象とする冬季道路交通における異常事象は、発生が稀で同じ時間、場所で発生する事象のデータを収集することは困難であるため、本研究は教師なし学習、もしくは平常データのみラベルがつく、半教師なし学習によるアプローチとなる。また、時間で変化する天候の影響や交通の影響を考慮しない場合、単なる速度の低下や交通量の減少と異常時の状況を区別することが出来ないため、変数間の関係や時系列の関係を加味する必要があり、時系列データを対象にした変化点を検知する問題と設定する。また、本研究で対象とする冬季の異常事象は事故や故障車といった突発的に発生するものではなく、異常が発生する前から気象の影響を徐々に受けていると考えられ、事前にその傾向が表れている可能性があるため、突発的な変化をスムージングし、緩慢な変化を上手く捉える手法の構築が必要である。

2-4-2 変化点検知に関する研究

前節で述べたように、本研究で対象とする目的に対しては、時系列データの変化点を検知する手法が必要となる。そこで、本節では時系列データを対象とした変化点検知に関する既往研究についてレビューする。

変化点検知は時系列データの振る舞いの急激な変わり目を検知する手法である。何らかの変動やノイズを含んでいる時系列データを観察し、顕著な状況の変化が現れたかを検知する。どのような変化を顕著とみなすかは目的と手法によって様々であるが、変化点検知は観測値が事前に決めた閾値を超えた時点で検知すると遅すぎる問題に対して有効な技術である⁴⁸⁾。

時系列の変化点検知における課題として、対象の特徴を適切に表現する予測モデルを構築すること、予測対象とモデルの乖離を迅速に検知することが挙げられる。また、従来の変化点検知法を大別すると、データを蓄積しておいてから過去に生じた変化点を検知する一括的手法と新規データを観測する毎に変化が発生したか否かを判断する逐次的手法に分類できる⁴⁹⁾。一括的手法の代表的手法として、chowテスト⁵⁰⁾がある。この手法は時点で変化が生じたという仮説を設定して、統計的検定を行う手法である。chowテストでは、変化点が未知の場合には、全時刻について、総当たりで検定を行う必要がある。変化点以後の時間経過に伴う、データが十分蓄積されていることが前提になっていること、総当たりによる検定法では、データ数増加に伴い計算量が膨大になるという問題がある。逐次的手法の代表的手法としては、累積和(cumulative sum, CUMSUM)を用いた手法⁵¹⁾やベイズの枠組みを用いた手法⁵²⁾がある。CUSUMは、データを観測する毎に予測式を逐次構築し、残差平方和を求め、残差平方和がゼロであるかどうかの検定を行うものであるが、検知力が低い。ベイズの枠組みを用

いた変化点検知手法であるBayesian Online Change Point Detection⁵³⁾は非定常系列に対するリアルタイムでの変化点検知が可能である。変化点検知は系列データにおける生成パラメータの急激な変化の識別であると考え、変化点の間に位置するデータの生成パラメータは同一であるという仮定に基づいて、各時点を分類する。ただし、ハイパーパラメータに敏感であるため、パラメータの調整は十分に行う必要がある。また、変換点以前と変化点以後のデータ発生確率分布が既知であるという前提を置いている。変化点検知は、問題の対象が異常や変化の早期発見の場合、リアルタイムで変化点を検知することが要求される。つまり、逐次的処理に向けた手法を使う必要がある。

次に、逐次的処理を用いた変化点検知に関する既往研究を整理する。川野ら⁵⁴⁾は、予測対象とモデルの乖離検知に着目し、確率比検定を用いる構造変化点検知手法を提案している。品質管理分野で使われている確率比検定法を適用した手法を定式化し、トレンド変化や予測式精度に対する変化点検知精度の評価実験を行い、chowテストとの比較を行っている。山西⁵⁵⁾は、ARモデルを用いたChangeFinderを提案している。ChangeFinderは、外れ値のスコア平滑化を通じて、本質的なモデルの変動を検知する手法である。ChangeFinderは時系列データを部分的に用いて、ARモデルを構築し、予測値と観測値の差異からスコアを算出するのが基本的な考え方である。ただし、この場合、ノイズに敏感であり、偽陰性となる確率が高い。また、ARモデルを用いたChangeFinderは、定常であることを仮定し、バッチ学習であり計算量が多いという課題がある。そのため、竹内ら⁵⁶⁾は、2段階でARモデルを適用し、平滑化することで、変化点スコアを頑健にし、忘却機能を備えた逐次学習可能なSDARアルゴリズムを開発している。SDARアルゴリズムは、過去に求めたパラメータと新たな時系列データのみでパラメータを計算することで計算量を少なくするという工夫がされている。しかし、時系列モデルを用いているため、データに欠測がある場合に課題がある。

流王ら⁵⁷⁾は、鉄道構造物を監視する状態監視データを用いて、データ間の関係性を用いた状態変化の検知法を提案した。具体的には、異常ないし異常の兆候を示した際のデータを蓄積し、実際に得られたデータが、それと類似するかを判定し、類似している場合は、状態が変化したと判定する手法を提案している。徳永ら⁵⁸⁾は、特異スペクトル分析を応用した変化点検知法を、多次元データを用いたアルゴリズムへと拡張することで、鋭敏に前兆現象の開始時刻を推定できることを示した。ただし、実データへの適用では誤検知が問題になるため、オフラインでの事前スクリーニング処理が必要としている。

その他に、深層学習の枠組みであるRecurrent Neural Network(RNN)を用いて、時系列特徴パターンを抽出し、異常スコアを推定する方法が提案されている。特にRNNの拡張手法であるLong Short-Term Memory(LSTM)を用いれば、単純なRNNでは学習できなかった長期的な依存関係を学習でき、異常データを観測し難い状況といった現実世界での適用がしやすいモデルを構築できる。この手法は、正常系列がはっきりわかっており、異常な状態がよくわからないデータに有効であるとされている⁵⁹⁾。

2-5 本研究の位置付け

既往研究のレビュー結果を踏まえた、本研究の位置付けについて整理する。

本研究は、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、プローブ車両データを活用し、一般道を含む広範囲の道路ネットワークを対象に、異常事象の発生危険性を定量的に評価する手法を提案するものである。

既往の研究において、降積雪や凍結といった冬季気象条件が交通流に与える影響に関しては、多くの分析がなされており、速度や交通量にどの程度の影響を与えるかについては多くの知見が得られている。ただし、本研究で対象とするスタックや立ち往生といった冬季道路交通における極端な事象については、事象の発生自体が稀で異常事象発生時のデータの収集が困難であったことなどから、複数の実事例のデータを用いて、分析を行っている研究はない。

また、既往の道路交通における異常検知に関する研究の多くは、異常事象が発生した後の早期検知を目的としており、本研究のように異常事象が発生する前にその危険性を評価することを目的とした研究は少ない。また、既往研究で提案されている手法の多くは、高速道路上で発生する異常事象を対象にしており、一般道における異常事象の検知を目的とした研究は少ない。一般道はアクセスコントロールされた道路よりも、外乱が多いため車両の挙動が複雑になりやすく、平常と異常の差異が明確でない、ノイズと変化点の境目が曖昧であるといった点から異常事象の検知を困難にしている。また、事故や故障車発生後は、ある地点で交通流に急激な変化が表れ、その影響が伝播するが、本研究で対象とする冬季道路交通における異常事象は、積雪や凍結の影響により、広域かつ緩やかに状況が変化するため、その事象の発生にいたる過程や性質が異なる。

道路交通以外の分野において、異常検知や変化点の検知に関する研究は数多くあるが、その多くが、人口的に生成したデータを用いており、欠損がない前提や等間隔でデータが取得できる前提で手法を提案を行っている。また、検証のケース数も数事例のみであることが多く、その多くが実データへの適用を今後の課題としている。

以上に整理したとおり、本研究で対象とする冬季道路交通における異常事象の発生危険性の評価は、その目的、検知対象とする事象、事象の特性、適用対象が既往研究とは異なる。本論文では、実際に異常事象が発生した際のノイズや欠測が多い実データを用いているため、既往モデルが適用できない場合や、そのまま転用した場合、誤判定や見逃しが多発する。

以上より、本論文は、これまで研究対象とされなかった冬季道路交通における異常事象の発生危険性に着目し、その評価を行う手法を提案している。また、提案手法を、61の実事例、約3,700区間という膨大なデータに適用し、検証を行っている点に新規性と有用性がある。なお、本研究で提案する手法に求められる要件の詳細については、3-2項で整理している。

2章の参考文献

- 1) 日本道路協会：道路構造令の解説と運用，2015.
- 2) 日本道路協会：道路の交通容量，(社)日本道路協会，1984.
- 3) 寺内 義典，川上 洋司，本多 義明：降積雪時における交通流の変化に関する研究．土木計画学研究・講演集，No.21,pp921-924,1998.
- 4) 寺内 義典，宇佐美 誠史，本多 義明：積雪時における道路交通管理のための交通特性に関する調査研究．日本雪工学会誌，Vol.15，No3，pp3-10，1999.
- 5) 宗広 一徳，秋元 清寿，高橋 尚人，浅野 基樹，三谷 光照：冬期道路交通評価へのタクシードロブデータの活用～札幌市における事例～，北海道開発土木研究所月報，No.632，2006.
- 6) 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.
- 7) 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-B_41,2019.
- 8) 榎谷 有三,浦田 康滋,田村 亨,斎藤 和夫：北海道峠部の冬季走行速度に及ぼす影響要因について，第18回交通工学研究発表会論文報告集，Vol.18,pp125-128,1998.
- 9) 武知 洋太，伊藤 靖彦，松澤 勝，加治屋 安彦：冬季道路環境が走行速度に及ぼす影響，北海道開発土木研究所月報，No.658，2008.
- 10) Datla, S., Sharma,S.:Impact of cold and snow on temporal and spatial variations of highway traffic volumes, Journal of Transport Geography,Vol.16, pp.358–372,2008.
- 11) 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.
- 12) 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
- 13) 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.
- 14) 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.
- 15) 山田 晴利：冬季道路交通データの分析-状態スイッチングモデルの適用-,土木学会論文集，No.7 09/IV-56，pp95-104，2002.
- 16) Seeherman,J., Liu,Y.; Effects of extraordinary snowfall on traffic safety, Accident Analysis and Prevention , Vol.81,pp.194–203,2015.

- 17) 平 俊勝,橘 吉宏:高速道路における登坂不能発生メカニズムと対策提案, http://www.thr.mlit.go.jp/yukimirai_morioka/pdf/ronbun_30.pdf, 2016.
- 18) 藤本 明宏,下村 壮太:豪雪時におけるスタック車両発生のメカニズム解明とその対策—考察, 雪氷研究大会,pp.286,2018.
- 19) 国土交通省HP: 第1回冬期道路交通確保対策検討委員会 配付資料資料: <https://www.mlit.go.jp/road/ir-council/toukidourokanni/pdf01/04.pdf>. (最終閲覧日: 2019年10月19日)
- 20) 株式会社富士通交通道路データサービス社HP: 福井大雪(2月5日~9日)時の物流貨物車両の走行状況について(速報), <https://www.fujitsu.com/jp/group/fttd/company/press-releases/2018/0221.html>. (最終閲覧日: 2019年10月19日)
- 21) 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.
- 22) 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.
- 23) 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.
- 24) 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.
- 25) 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.
- 26) 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.
- 27) Takenouchi,A.,Kawai,K.,Kuwahara,M.: Traffic state estimation and its sensitivity utilizing measurements from the opposite lane, Transportation Research Part C: Emerging Technologies, Vol.104, pp 95-109, 2019.
- 28) 川崎洋輔, 梅田祥吾, 桑原雅夫, 飯星明, 機械学習によるプローブデータを用いた西日本豪雨災害時の迂回経路検出手法の構築, 土木学会論文集 (平成30年西日本豪雨災害特別企画) , 2019.
- 29) Yoshida, M., Umeda, S., Kawasaki, Y. and Kuwahara, M., Incident Alert by an Anomaly Indicator of Probe Trajectories, Transportation Research Procedia, Vol 34, pp.179-186, 2018.
- 30) B. Pan, Y. Zheng, D. Wilkie, and C. Shahabi. Crowd sensing of traffic anomalies based on human mobility and social media. In Proceedings of the 21st ACM SIGSPATIAL International Conference on Advances in

- n Geographic Information Systems, pp. 344-353, 2013.
- 31) 赤塚 裕人, 高須 淳宏, 安達 淳: プローブカーデータを用いた高速道路における自動交通異常検出, IEI CE Technical Report, Vol.12, No.17-21.23-28, pp.13-28, 2012.
 - 32) 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.
 - 33) 野村 大智, 西内 裕晶, 轟 朝幸, 川 智也, 割田 博.: ベイ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.
 - 34) J. Wang and I. C. Paschalidis. Statistical traffic anomaly detection in time-varying communication networks. IEEE Transactions on Control of Network Systems, Vol. 2, No. 2, pp. 100-111, 2015.
 - 35) L. Li, X. Su, Y. Zhang, Y. Lin, and Z. Li. Trend modeling for traffic time series analysis: An integrated study. IEEE Transactions on Intelligent Transportation Systems, Vol. 16, No. 6, pp. 3430-3439, 2015.
 - 36) 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.
 - 37) 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.
 - 38) 井上真一, 塚井誠人, 桑野将司, 奥村誠. 独立成分分析による非日常時の地方空港利用交通の分析. 土木計画学研究・論文集, Vol. 28, No. 3, pp. 583-593, 2009.
 - 39) 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.
 - 40) V. Mahadevan, W. Li, V. Bhalodia, and N. Vasconcelos. Anomaly detection in crowded scenes. In IEEE Conference on Computer Vision and Pattern Recognition, pp. 1975-1981, 2010.
 - 41) 上條俊介, 原田将弘, 坂内正夫: 統計モデルと意味階層の結合による交通映像異常事象検出システム, 信学論 (A), vol.J88-A,no.2,pp.152-163,(2005).
 - 42) 原田 将弘, 上条 俊介, 坂内 正夫: リアル交通事故検出システム, 画像センシングシンポジウム講演論文集, Vol.9, pp.233-238, 2003.
 - 43) 牧野正吉, 中村 高宏, 谷口 博康, 山本 貴幸: 突発事象検知システム. 三菱電機技報, Vol.36, No.12, pp.78-83, 1993.
 - 44) 拓植 章英, 相馬 祐明: 阪神高速道路の突発事象検知システム, 高速道路と自動車, Vol.36, No.

- 1, pp.51-58, 1998.
- 45) 井出剛:入門機械学習による異常検知-Rによる実践ガイド, コロナ社, 2015.
 - 46) 井出剛, 杉山将:機械学習プロフェッショナルシリーズ異常検知と変化検知, 講談社, 2017.
 - 47) 山西健司:データマイニングによる異常検知, 共立出版, 2009.
 - 48) 島田直希:時系列解析 自己回帰型モデル・状態空間モデル・異常検知, 共立出版, 2019.
 - 49) 川野弘道, 服部哲郎, 西松研:逐次確率比検定による時系列の構造変化点検出法—ChowTestとの早期検出性の比較—, 電学論C, Vol.128,No.4,pp.583-592, 2008.
 - 50) G.C.Chow:Tests of Equality Between Sets of Coefficients in Two Linear Regressions,Econometrica,Vol.28,No.3.1960.
 - 51) C.Han,P.K.Willet,and.D.A.Abraham:Some methods to evaluate the performance of Page’s test as used to detect transient signals”,IEEE Trans.on Signal Processing,Vol.47,No.8,pp.2112-2127,1991.
 - 52) V.V.Veeravalli and A.G.Tartakovsky:Asymptotics of quickest change detection procedures under aBayesian criterion,Proc.of 2002 IEEE Information Theory Workshop (ITW2002),pp.100-103,2002.
 - 53) Adams,R.P. and MacKay,D.J.C.:Bayesian Online Changepoint Detection.preprint arXiv:0710.3742,2007.
 - 54) 山西健司:データマイニングによる異常検知, 共立出版, 2009.
 - 55) 竹内孝, 河原吉伸, 岩田具治:高階結合正則化による時空間変化パターン検出, 人工知能学会研究会資料, SGI-FPAI-B503-10, pp47-52,2016.
 - 56) 川野弘道, 服部哲郎, 西松研:逐次確率比検定による時系列の構造変化点検出法—ChowTestとの早期検出性の比較—, 電学論C, Vol.128,No.4,pp.583-592, 2008.
 - 57) 流王智子, 川村智輝, 羽田明生, 岩澤永照:状態監視データ間の関係性を用いた状態変化検出手法の構築, 電気学会論文誌C, Vol.137No.8, pp.1111-1120, 2016.
 - 58) 徳永旭将, 池田大輔, 中村和幸, 樋口知之, 吉川顕正, 魚住禎司, 藤本晶子, 森岡昭, 湯元清文:変化点検出を応用した時系列データからの突発現象の前兆アルゴリズム, 情報処理学会論文誌, 数理モデル化と応用, Vol.4, No.3, pp14-34,2011.
 - 59) Malhotra, P., Ramakrishnan, A., Anand, G., Vig, L., Agarwal, P., and Shroff,G.:LSTM-based Encoder-Decoder for Multi-sensor Anomaly Detection, In Anomaly Detection Workshop at 33rd International Conference on Machine Learning (ICML 2016).CoRR,<https://arxiv.org/abs/1607.00148>.2016.

第3章 冬季道路交通における異常事象発生危険性の評価手法の 提案

ここでは、本論文における冬季の道路交通における異常事象発生の危険性評価手法について提案する。手法の提案にあたり、本研究で評価対象とする異常事象の定義、手法構築に求められる要件、技術的な課題、手法のコンセプト等の手法の詳細を整理する。

3-1 研究対象の定義について

3-1-1 本研究の異常事象の定義

本研究における異常事象とは降雪・凍結といった冬季の気象条件の影響により、道路の走行性能が大幅に低下し、車両の性能が十分に発揮できないために進行不能となり、道路交通に悪影響を及ぼす事象と定義する。

なお、道路車線外(駐車場や路肩等)で発生するスタックなどといった交通流への影響が軽微である事象については、本研究における異常事象の危険性評価の対象外とする。また、降雪自体が稀な地域では、降雪が即、異常事象の発生に繋がるため本研究の対象外とする。

3-1-2 道路の走行性能の定義

本研究における道路の走行性能とは、ある道路区間・時間帯において、交通条件によらず(車両密度、信号、交差点、沿道出入り、路上駐車の影響を受けない状況下)に一般的なドライバーが安全に走行できる上限速度とする。この道路の走行性能は、道路の状態を運転者が認識することで、自動車の走行速度に表れると考える。

本論文では、この道路の走行性能を観測するセンサーの代替としてプローブ車両の速度に着目する。

3-2 手法に求められる要件

ここでは、本論文で提案する手法の必要要件について整理する。提案手法は、道路管理実務への適用を目指しているため、冬期道路交通確保対策検討委員会資料及び国土交通省東北地方整備局及び近畿地方整備局福井河川国道事務所に対してヒアリング結果を基に、以下のとおり道路管理実務へ適用するための必要要件の整理を行った。

(1) 誤発報が少ない手法

道路管理の人員は限られており、特に地方自治体等は技術者が少ないため、誤発報が多発すると、業務の効率を下げることとなり、不確実な情報でむやみに発報するモデルは望ましくない。特に一般道の場合、道路の路面の状態以外の影響が自動車の走行速度に表れる場面(信号、沿道施設、路上駐車等)が多々存在するため、これまでの道路管理のように道路区間の平均的な速度をモニタリングし、その速度の低下を異常と判定すると、誤発報が多発する。本論文で提案する手法は、誤発報が少なく、適切なタイミングで、正確にアラート出来る手法である必要がある。

(2) 異常事象が発生する前に危険性が評価できる手法

提案手法は、異常事象が発生する前に、道路管理者への対応を促す必要があるため、リアルタイムに異常事象が発生する前にその危険性を評価できる必要がある。国土交通省が公表する降雪時を想定したタイムライン^{1) 2) 3)}によると、大雪に関する気象情報を得て(異常事象の発生発生の1日前)から警戒態勢が布かれ、優先区間への除雪車の配置が行われる。異常事象の発生半日前から数時間前には、通行止めの予想される路線、区間の発表、凍結防止剤の散布が行われる。異常事象が発生する前に、リアルタイムにその発生危険性を評価出来れば、道路管理者の降雪時の道路管理に関する各判断に貢献出来る。

(3) 早期に異常事象を発見できる手法

異常事象の発生後は、被害情報を収集し、関係機関と情報共有を行い、道路利用者に被害情報の提供を行う必要がある。一刻を争う判断が必要となるため、事象発生直後に出来る限り、早期に異常を発見できる手法である必要がある。

(4) 転用性が高い手法

近年の異常気象により、雪の降り方が変わっており、降雪がどこで発生するか、異常事象がどこで発生するか予測することは困難である。そのため、地域や道路種別が異なっても、異常事象の発生危険性を評価できる必要がある。また、急こう配や、交差点で一旦停止した後に再発進できないような立ち往生にも対応するため、道路の特性(単路・交差点、幾何構造)が異なっても、同一手法で、異常事象の発生危険性を評価できる必要がある。

3-3 手法のコンセプト

本節では、1-2節に整理した目的を達成するため、前述した研究対象と道路の走行性能との関係及び必要要件を考慮し、提案手法のコンセプトについて述べる。

まず前提として、冬季の道路交通における異常事象は、気象条件、ドライバーのスキル、車両の性能、道路の性能が複雑に絡み合った事象である。そのため、現時点で、一般的に収集可能なデータでは、その発生を完全に予測することは困難である。ただし、異常事象が発生する前には、多くの場合、積雪や凍結の影響によって道路の走行性能の低下が存在すると考える。

そこで、本論文では、気象の影響により道路の走行性能が一定程度低下した時、異常事象が発生しやすい状態であると考え、道路の走行性能の低下と異常事象の関係を分析することで異常事象の発生危険性の評価手法の構築、評価を行う。具体的には、降雪がある、気温が低いなどの気象条件が悪い状況において、図3-1に示すように、「①リアルタイムの道路の走行性能」が「②過去に発揮された道路の走行性能」よりも大きく低下している場合に、道路の状態が悪い状態であり、異常事象がいつ発生してもおかしくない状態であると考えられる。

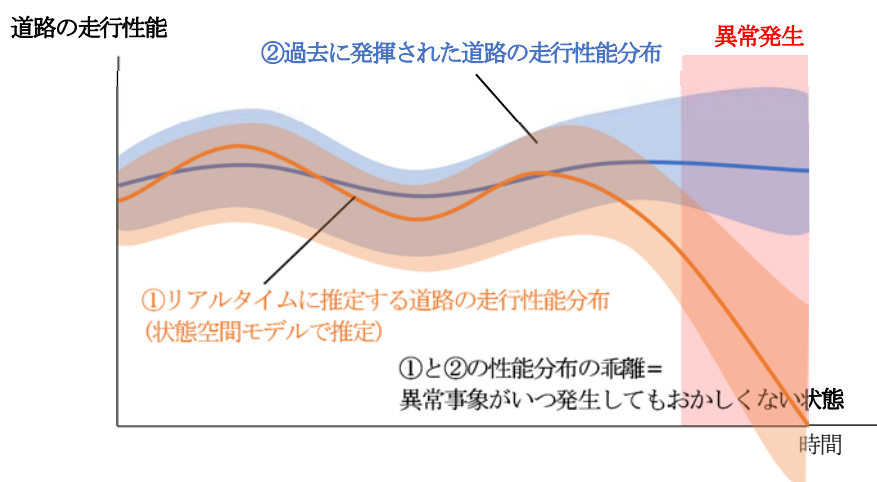


図3-1 提案手法のイメージ図

この時、道路の走行性能の代替として、プローブ車両速度に着目するが、プローブ車両の速度によって道路の走行性能を計測する際には、様々な不確実性が存在する。プローブ車両速度の不確実性を生む要因は、表 3-1のように分類できると考える。精度のよい手法を構築するためには出来るだけ、この不確実性を除外する必要がある。そこで、本研究で提案する手法は、明暗といった時間的な変動、道路特性といった空間的な変動を考慮して、時間帯別、道路区間別に行う。そのほかの要因については、明確に分類・除外することが出来ないため、プローブの車両速度は確率的に分布すると考える。特に一般道の場合、信号や沿道施設、路上駐車等の外乱が多く、道路路面の状況に関係なく速度を落とす車両が存在するために、実データを見ると図 3-2に示すように二山に分布する。

ここで、道路の走行性能は、交通条件によらずに一般的なドライバーが安全に走行できる上限速度と考えているため、道路路面の状況に関係なく人為的制御(信号、前方車両)、道路特性(交差点・単路・沿道状況)速度を落とす車両の影響は出来るだけ除外する必要がある。そのために、本研究では、道路の走行性能の代替として評価区間を通過した車両の速度集合の 85パーセンタイル値(以降は、単に85パーセンタイル速度)に着目する。85パーセンタイル速度に着目することで、信号や沿道施設、路上駐車等の外乱の影響により速度を落とす車両を除外出来るため、85パーセンタイル速度は、単路区間でも交差点区間でも図 3-3に示すように一山に分布する。85パーセンタイル速度は交通の分野では、一般的なドライバーが前に遅い車がない条件で、運転者が自分の判断で走行する際の速度の上限値と考えられている。

ただし、85パーセンタイル速度をリアルタイムに観測する場合は、過去のデータとは異なり、サンプルが少ない中での推定となることが多く、より不確実性が高まるため、モデルと観測値の両方を用いて確率的に推定する。本研究ではこのリアルタイムの道路の走行性能を推定する際に、状態空間モデルの枠組みを用いる。

上記を踏まえると、85パーセンタイル速度を用いて、リアルタイムに推定する道路の走行性能と過去の道路の走行性能は共に不確実性を伴い、確率的に分布するため、確率分布間の乖離を考慮した評価が必要となる。この時、評価対象区間の空間解像度と時間解像度が重要となるが、異常事象の危険性を評価する際の空間解像度と時間解像度の考え方については、3-8で整理する。

表 3-1 プローブ車両速度に影響を与える要因(不確実性を生む要因)と対応

カテゴリ	要因	対応
時間的変動	明暗	時間帯別に評価することで考慮(分類・除外)
	天候	明確に定義, 分類できず除外できない
空間的変動	幾何構造	プローブ速度を一定の道路区間毎に評価することで考慮(分類・除外)
	人為的制御(信号, 前方車両), 道路特性(交差点・単路・沿道状況)	85 パーセントイル速度に着目することで除外
個体差	ドライバー, 車両	明確に定義, 分類できず除外できない(一部は 85 パーセントイル速度に着目することで除外)
その他	観測誤差(GPS 誤差)	明確に定義, 分類できず除外できない




図 3-2 区間別時間帯別の個別車両の通過速度分布の例




図 3-3 時間帯別の 85 パーセントイル速度分布

3-4 技術的な課題と対応

前述した手法の必要要件及び手法のコンセプト、85パーセンタイル速度の特徴を踏まえた技術的な課題とその対応について以下のとおり整理する。

(1) 欠測値の補間

本研究で使用するプローブ車両データは、通行台数が多い地域でも全車両に対して10%程度の取得率であり、場所や時間帯によっては、欠測となることが多い。欠測が数パーセントであったとしても連続して観測できた利用可能なデータが少ないと、目的を十分に達成できない。通常は、欠測値をデータの平均値などで補間したり、線形補間した後、欠測値がないものとみなして統計解析を行うが、このような前処理は一部分の観測データの重複使用となるため、モデルを歪曲したり、解析結果に大きな偏りをもたらす危険性がある。

図3-4は、本論文で使用するプローブ車両データ(詳細は第4章で整理)の1時間毎、区間毎の通過台数別のデータ数のヒストグラムと累加曲線を示したものである。図3-4を見ると、プローブ車両が1台も観測されない時間帯・区間が約24%存在し、プローブ車両台数が10台/h以下の割合が約80%を占めている。図3-5は、時間帯別にプローブ台数が1台も観測されなかった区間の割合を示している。深夜から早朝にかけてプローブ車両が観測されないことが多く、3時台では、約7割の区間でプローブ車両台数が0台となる。このように本論文で使用するプローブ車両データは欠測が多いため、欠測への対応が容易な手法が必要となる。

状態空間モデルは、欠測値を含むデータに対しても厳密な尤度計算が可能で、パラメータの最尤推定値を求めることが出来る。モデルパラメータの同定後は、計算プロセスの中で、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、さらに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。ARIMA⁴⁹⁾等の時系列モデルでは、観測値が欠測する場合、パラメータの同定が困難でモデルを構築することができない。

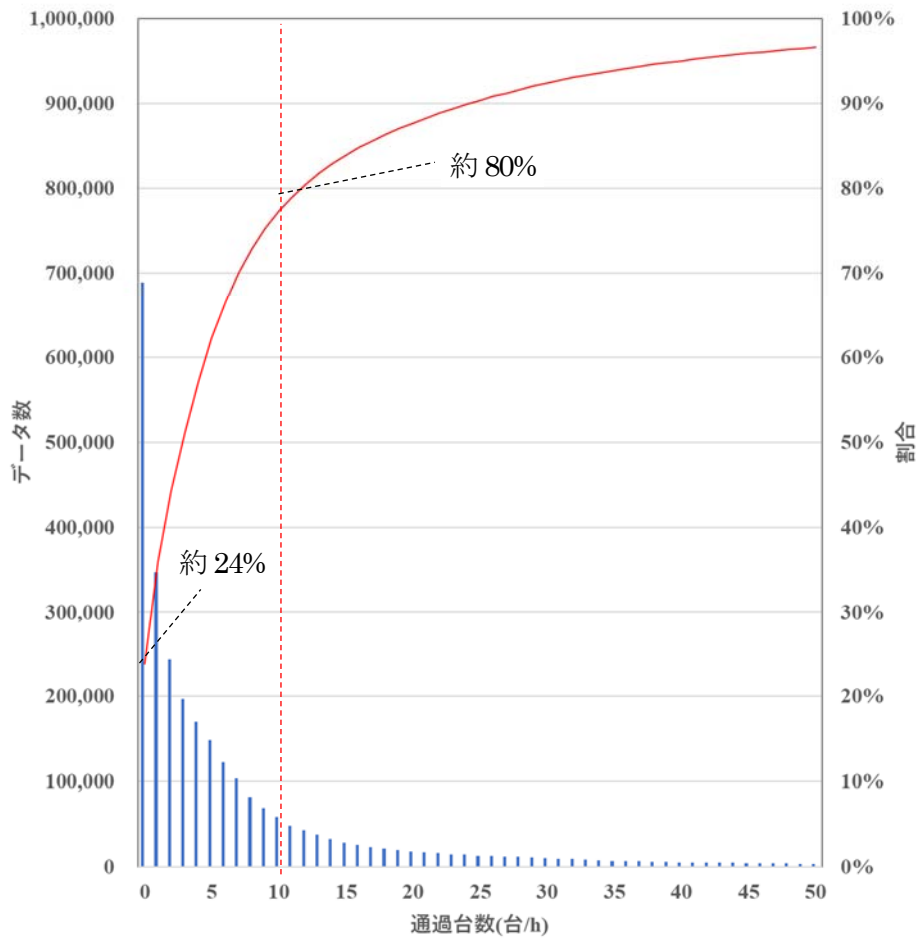


図3-4 通過台数別のデータ数と割合




図3-5 時間帯別のプローブ車両0台の区間の割合

(2) 逐次的計算

冬季道路交通異常事象発生危険性を評価するためには、リアルタイムに変化する状況を考慮して、データを観測する度に、逐次的に計算、評価が可能な枠組みである必要がある。本研究で採用する線形ガウス状態空間モデルは、逐次的かつ効率的なアルゴリズムが適用できる。線形ガウス状態空間モデルについての詳細は後述する。

(3) 入手困難な教師データへの対応

本論文で対象とする冬季道路交通における異常事象の発生は稀で、同じ場所、同じ状況でのデータを大量に入手することは困難である。少ない教師データもしくは、教師データがなくてもその危険性を評価できる手法である必要がある。状態空間モデルは、逐次的に得られるデータを活用しながらモデルを修正する(データ同化)ことができるため、事前に異常事象発生時のデータ(教師データ)を入手しなくてもリアルタイムの状況を推定することが出来る。

(4) ノイズの考慮

プローブ車両の速度は、GPS誤差を持つ。85パーセンタイル値に着目することで、不確実性を低減しているが、本来、道路の走行性能を計測するためのデータではないためノイズを含む。状態空間モデルは観測値やモデルに確率的なノイズがあることを仮定し、ノイズの考慮、評価が可能である。

3-5 状態空間モデルについて

3-5-1 状態空間モデルの概要

ここでは、前述した状態空間モデルの概要について説明する。状態空間モデルは、非常に汎用性が高く、幅広い分野で活用されているモデルである。前述したように状態空間モデルの持つ特徴は、本研究の技術的な課題に対応する。

状態空間モデルは、時系列データに対して見えない状態を仮定し、状態を推定する問題を解く手法である。制御工学や経済の分野で発展したモデルであり、Kalman⁶⁾により理論整備がなされた。状態空間モデルはモデルと観測値の両方が確率的な誤差を持つという仮定を置く確率モデルで、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に従って、状態が時間変化すると共に、各々の状態から観測値が出力されるという仮定に基づいていることで、柔軟なモデリングが可能なモデルである。

状態空間モデルは、観測される時系列データと時間発展するシミュレーションを統合し、モデルを改善するため、データ同化を目的として利用されることが多い。データ同化はKitagawa⁷⁾やGordonら⁸⁾によって提案された理論的枠組みである。データ同化は、気象や海洋分野をはじめ、シミュレーションを活用した研究領域でもよく活用されており、シミュレーションの精度・性能を観測データによって改善する。

本研究では、状態空間モデルの中でも、システムモデルが線形関数で定義され、モデルに含まれるノイズがガウス分布に従うと仮定した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、逐次的かつ効率的に計算可能なカルマンフィルタアルゴリズムが適用できる。非定常過程の時系列データや時系列の様々な変化に柔軟に対応できるだけでなく、過去の増減や将来予測における各要素の寄与を議論することが出来る。ベイズ型統計モデルであり、点推定ではなく分布の推定が出来る。カルマンフィルタでは、状態の分散はモデル内で計算されるため、計算済みの分散を使用することで簡単に信頼区間の計算が出来る。

以降では、状態空間モデルの一般形、状態の逐次推定方法、線形状態空間モデルについて、島田⁹⁾を参照して3-5-2, 3-5-3, 3-6で整理を行う。ただし、状態空間モデルは既往の研究であるため、詳細については野村¹⁰⁾、樋口ら¹¹⁾¹²⁾、沖本¹³⁾、片山¹⁴⁾等に譲る。

3-5-2 状態空間モデルの一般形

状態空間モデルの一般的な表現について整理する。状態空間モデルは、以下のシステムモデルと観測モデルという2つの方程式で表現することが出来る。 \mathbf{x}_t , \mathbf{y}_t は確率変数であり、式(3-1)と式(3-2)をそれぞれシステムモデルと観測モデルと呼ぶ。なお、本節では、列ベクトルは \mathbf{v} 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。転置行列は \mathbf{A}' のように表す。逆行列は、 \mathbf{A}^{-1} で表す。

$$\text{システムモデル： } \mathbf{x}_t = \mathbf{F}_t(\mathbf{x}_{t-1}) + \mathbf{G}_t(\mathbf{v}_t) \quad (3-1)$$

$$\text{観測モデル： } \mathbf{y}_t = \mathbf{H}_t(\mathbf{x}_t) + \mathbf{w}_t \quad (3-2)$$

式中に登場する記号の説明は以下のとおりである。式(3-2)の観測モデルは時系列 \mathbf{y}_t の観測される仕組みを規定するものであり、状態 \mathbf{x}_t を回帰係数とする回帰モデルとみなすことが出来る。この時、式(3-1)のシステムモデルは、その回帰係数の時間的変化を表す。つまり状態空間モデルでは、時間ごとに変化するパラメータを推定するための非定常系列を扱うことが出来る。

\mathbf{x}_t : 状態ベクトル。 (以降, k 次元ベクトル)

\mathbf{v}_t : システムノイズ。 以降, m 次元ベクトル。 状態 \mathbf{x}_{t-1} から \mathbf{x}_t にシフトする過程における攪乱要因を表す。 ノイズがガウス分布に従うことを仮定する場合は、 \mathbf{w}_t とは独立のホワイトノイズを仮定し、 $\mathbf{v}_t \sim N(\mathbf{0}_m, \mathbf{Q}_t)$ とする。 \mathbf{Q}_t はシステムノイズの分散共分散行列である。

\mathbf{y}_t : 直接観測可能な時系列データ。 以降は, l 次元ベクトル。

\mathbf{w}_t : 観測ノイズ。 以降は, l 次元ベクトル。 \mathbf{y}_t と \mathbf{x}_t の関係における攪乱要因を表す。 \mathbf{v}_t とは独立のホワイトノイズを仮定し、 $\mathbf{w}_t \sim N(\mathbf{0}_l, \mathbf{R}_t)$ とする。 \mathbf{R}_t は観測ノイズの分散共分散行列である。

\mathbf{F}_t : 非線形関数または線形関数。 線形関数の場合は行列であり、状態推移行列または、係数行列と呼ぶ。 $k \times k$ 行列。 システムの時間変化、メカニズムを決める関数と考えることが出来る。

\mathbf{G}_t : 非線形関数または線形関数/線形関数の場合は係数行列と呼ぶ。 $k \times m$ 行列。

\mathbf{H}_t : 非線形関数または線形関数/線形関数の場合は観測行列または係数行列と呼ぶ。 $l \times k$ 行列。

\mathbf{Q}_t : システムノイズの分散共分散行列。 $m \times m$ 行列。

\mathbf{R}_t : 観測ノイズの分散共分散行列。 $l \times l$ 行列。

3-5-3 状態の逐次推定

状態空間モデルでは見えない状態ベクトルを推定することが目的となる。状態ベクトルを推定する問題は状態推定と呼ばれ、観測時点を j として推定する状態の時点を t とすると、その大小関係により以下の3つに分けられる。

- ・予測： $j < t$
- ・フィルタ： $j = t$
- ・平滑化： $j > t$

このように問題を3つに分けて考えるのは、後に示すように欠測値補間、パラメータ推定、成分分解などの課題解決に必要な問題のほとんどがこの状態推定を利用することによって統一的に解決できるからである。状態推定の問題は、時点1から j までの観測データ集合 $Y_{1:j} = \{y_1, \dots, y_j\}$ が与えられた時の $Y_{1:j}$ の下で、状態 x_t の条件付き確率分布 $p(x_t | Y_{1:j})$ を求める問題となる。一般的な1期先予測分布、フィルタ分布、固定区間平滑化分布の算出方法については、本文では割愛し、Appendix1に整理する。

3-6 線形ガウス状態空間モデル

本論文では、逐次的かつ高速に計算できる必要があるため、状態空間モデルの中でも、ウィナーフィルタやMCMCを活用したような一括型の状態推定手法は適さない。そこで、本論文では、システムモデル、観測モデルがともに線形関数で、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考える。線形ガウス状態空間モデルは、動的線形モデル(linear dynamical system)とも呼ばれ、一般的な線形回帰分析の回帰係数と切片が時間変化することを許容するモデルである¹⁵⁾。

線形ガウス状態空間モデルは、状態の変化を表す \mathbf{F}_t が線形でノイズが正規分布に従うモデルであり、以下のように表現できる。ただし、初期状態は \mathbf{x}_0 である。初期状態の期待値と分散行列は、ハイパーパラメータである。状態初期値に関する事前情報がある場合はその値を用いればよいが、事前情報がない場合は、期待値は0、分散は十分に大きな値とすることで、どのような値を取っても、同じ結果を得るため、設定は不要となる(この処理を行うカルマンフィルタを散漫カルマンフィルタと呼ぶ)。

$$\mathbf{x}_t = \mathbf{F}_t \mathbf{x}_{t-1} + \mathbf{G}_t \mathbf{v}_t, \quad \mathbf{v}_t \sim N(\mathbf{0}_m, \mathbf{Q}_t) \tag{3-3}$$

$$\mathbf{y}_t = \mathbf{H}_t \mathbf{x}_t + \mathbf{w}_t, \quad \mathbf{w}_t \sim N(\mathbf{0}_l, \mathbf{R}_t) \tag{3-4}$$

$$\mathbf{x}_0 \sim N(\mathbf{0}_m, \mathbf{Q}_0) \tag{3-5}$$

3-6-1 カルマンフィルタ

線形ガウス状態空間モデルの逐次状態推定手法として、カルマンフィルタアルゴリズムがある。本論文では、カルマンフィルタアルゴリズムによりリアルタイムに状態を推定する。カルマンフィルタアルゴリズムでは、各時点 t に対する1期先予測とその予測誤差分散行列及びフィルタリング値とその推定誤差分散行列を交互に求めていくアルゴリズムである。カルマンフィルタでは、下付き添え字 $t|j$ で、縦バー“|”の左側は状態ベクトルの時点に対応し、時点 t の状態ベクトルであることを指す。一方、バーの右側の j は条件となる所与のデータ $Y_{1:j}$ の j である。 $j=t-1$ の場合が1期先予測、 $j=t$ の場合がフィルタと対応する。

線形ガウス状態空間モデルは、システムノイズ \mathbf{v}_t 、観測ノイズ \mathbf{w}_t 及び初期状態のすべてが正規分布に従うと仮定しているため、得られた状態 \mathbf{x}_t の条件付き分布 $p(\mathbf{x}_t | Y_{1:j})$ も正規分布となる。したがって、状態空間モデルの状態推定の問題においては、条件付き分布 $p(\mathbf{x}_t | Y_{1:j})$ の規定する平均と分散共分散行列のみを求めればよい。ここで、状態 \mathbf{x}_t の条件付き分布の平均 $\mathbf{x}_{t|j}$ と分散共分散行列 $\mathbf{V}_{t|j}$ は以下のとおりとなる。

$$\mathbf{x}_{t|j} = E[\mathbf{x}_t | Y_{1:j}] \tag{3-6}$$

$$\mathbf{V}_{t|j} = E[(\mathbf{x}_t - \mathbf{x}_{t|j})(\mathbf{x}_t - \mathbf{x}_{t|j})' | Y_{1:j}] \tag{3-7}$$

カルマンフィルタのアルゴリズムの詳細については、本文では割愛し、Appendix2に整理する。また、カルマンフィルタのアルゴリズムの中で、時系列の予測も可能となる。時系列の予測については、Appendix3に整理する。

3-6-2 パラメータ推定方法

カルマンフィルタを適用するためには各初期状態の分布とシステムノイズと観測ノイズの分散行列がパラメータとなる。これらのパラメータは未知であることが多いため、何らかの推定手法あるいは仮定が必要となる。そこで本節では、最尤法によるパラメータ推定について整理する。

ただし、前述したように初期状態の分布については、初期状態の平均を0、分散を十分に大きい数とすることで、どのような値を取っても、同じ結果に収束するため、設定は不要となる。

パラメータ θ を持つ時系列モデルの尤度 $L(\theta)$ は長さ T の時系列 $Y_{1:T} = \{y_1, \dots, y_T\}$ が与えられるとき、同時確率密度関数 $f_{1:T}(Y_{1:T} | \theta)$ を用いて、次のように表現される。

$$L(\theta) = f_{1:T}(Y_{1:T} | \theta) = f_{1:t-1}(Y_{1:t-1} | \theta) p_t(y_t | Y_{1:t-1}, \theta) \quad (3-8)$$

(3-8)に示した分解を繰り返し適用すると、最終的には、

$$L(\theta) = \prod_{t=1}^T p_t(y_t | Y_{1:t-1}, \theta) \quad (3-9)$$

と表現できる。ただし、 $p_1(y_1 | Y_{1:0}, \theta) = f_1(y_1 | \theta)$ である。したがって、一般に時系列モデルの対数尤度 $l(\theta)$ は、

$$l(\theta) = \log L(\theta) = \sum_{t=1}^T \log p_t(y_t | Y_{1:t-1}, \theta) \quad (3-10)$$

$p_t(y_t | Y_{1:t-1}, \theta)$ は逐次フィルタの予測分布である。したがって、状態空間モデルで表現できる時系列モデルに対しては、対数尤度はフィルタの副産物として、統一かつ自動的に計算できる。状態空間モデルのハイパーパラメータの最尤推定量を求めるためには、数理最適化により式(3-10)の対数尤度を最大とするハイパーパラメータを求めればよい。この対数尤度を使用して、例えば、システムノイズの共分散行列 Q を数理最適化により求める。本研究では、BFGS法¹⁰⁾を用いた最尤推定により、パラメータを推定する。

3-6-3 欠測値の補間推定方法

ここでは、カルマンフィルタによる欠測値の補完推定方法について整理する。

時点 t において、欠測がある時は、 $Y_{1t} = Y_{1t-1}$ が成り立つため、カルマンフィルタにおいて、フィルタの部分を省略し、平滑化処理を施せば良い。したがって、時系列モデルがすでに与えられている場合、そのモデルを利用して、欠測値の補間を行うことが出来る。時点 t において欠測値がある時は、以下のようにカルマンフィルタの計算及び欠測値の補間を行うことできる。

手順1. 1期先予測分布の平均 $\mathbf{x}_{t|t-1}$ と分散共分散行列 $\mathbf{V}_{t|t-1}$ だけを計算する。

手順2. 手順1で求めた1期先予測分布の平均、分散共分散行列でフィルタ分布の平均、分散共分散行列を

$$\mathbf{x}_{t|t} = \mathbf{x}_{t|t-1} \text{ と } \mathbf{V}_{t|t} = \mathbf{V}_{t|t-1} \text{ で置き換える。}$$

手順3. 手順2で求めたものを使用し、平滑化アルゴリズムを適用し状態の平滑化 $\mathbf{x}_{n|t}$ を計算する。

手順4. 時点 t における時系列 \mathbf{y}_t の推定値として $\mathbf{y}_{t|t} = \mathbf{H}_t \mathbf{x}_{t|t}$ を使用し欠測値を補間する。

3-7 提案手法の全体像

本論文で提案する冬季道路交通における異常事象の発生危険性の評価方法の全体像について概説する。

本論文では、3-3で整理したように、過去に発揮された道路の性能とリアルタイムの道路の走行性能の乖離度合いから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。異常事象がいつ起きてもおかしくない状況と既に異常事象が起きている可能性の高い状況といった2つの異なる状況とその程度を一つの枠組みで評価する。

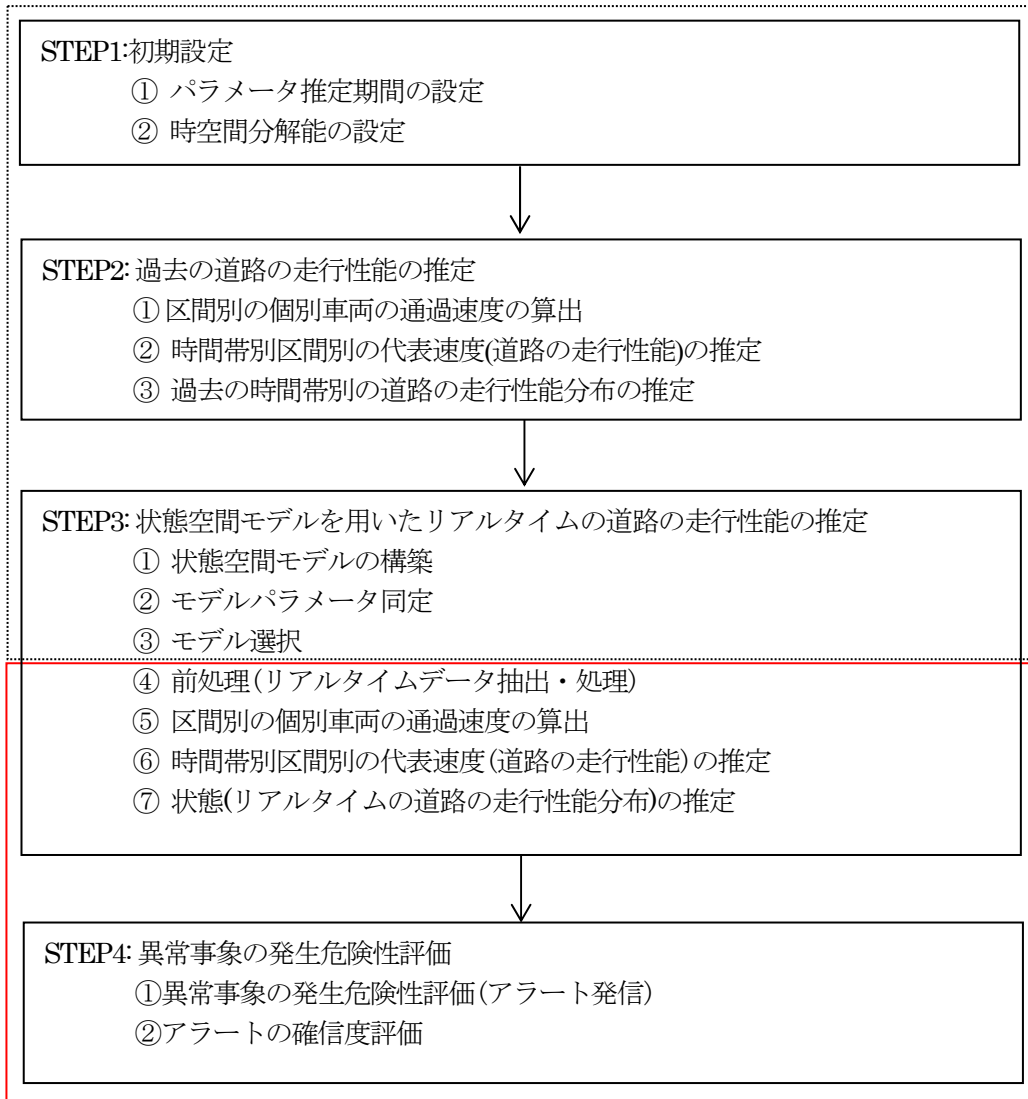
本研究で提案する異常事象の発生危険性評価手法のフローは図 3-6に示すとおりである。本研究の提案手法は、大きく4つのステップに分かれる。

まず、STEP1として、異常事象の発生危険性を評価するための初期設定を行う。具体的には、過去の期間の期間設定や、評価を行うタイムステップ、空間分解能の設定である。次にSTEP2として、過去に発揮された道路の走行性能を推定する。過去のデータは、データ期間を増やすことでサンプル数を増やすことが出来るため、観測値のみで道路の走行性能が推定できるとする。

STEP3として、状態空間モデルを用いてリアルタイムの道路の走行性能を推定する。リアルタイムに道路の走行性能を推定する際は、サンプルが少ない場合が多々存在すると考えられるため、道路の走行性能を説明する状態成分は見えない状態として仮定し、状態空間モデルによって状態推定を行う。

STEP4は、STEP2で推定する過去に発揮された道路の走行性能とSTEP3で推定するリアルタイムの走行性能の乖離程度を比較評価することで、異常事象の発生危険性の評価を行う。乖離程度の判定は、異常事象がいつ起きてもおかしくない状況と既に異常事象が起きている可能性の高い状況といった2つのレベルに分けて評価をおこなう。

各ステップの詳細については、次頁以降に整理する。なお、STEP3で使用する状態空間モデルについては3-5節で詳細を整理する。STEP1からSTEP3の③までは、過去の期間のデータを用いて、事前に実施しておくことが可能であり、STEP3の④以降はリアルタイムにデータを収集し、逐次的に計算を行う。



オフラインで事前に推定 :

リアルタイムに逐次推定 :

図 3-6 提案手法の全体像と計算フロー

3-8 冬季道路交通における異常事象の発生危険性評価手法の手順

本節では、前述した手法のコンセプト、要件、技術課題を踏まえて、冬季道路交通における異常事象の発生危険性の評価手法の具体的な計算手順について整理する。

なお、本節では、観測変数は、 \diamond で表し、過去の期間のデータは \bullet^* で表す。

3-8-1 STEP1:初期設定

① パラメータ推定期間の設定

過去に発揮された道路の走行性能を推定及び状態空間モデルのパラメータ推定のための期間を設定する。この期間は、直近の数年度程度の冬季期間の災害や大きな事故が発生した日、積雪が観測された日も観測されない日も全て含んだ形で設定する。

② 時空間分解能の設定

提案手法により異常事象の発生危険性の評価を実施する時間分解能、空間分解能を設定する。3-2 節で述べたように、本論文で提案する手法は、満たすべき必要要件と技術的な課題があり、異常事象の危険性を評価する時間分解能、空間分解能の設定が重要となる。本論文では、使用するデータの制約と目的を踏まえて以下のとおり設定する。なお、前述したように本研究で提案する手法はリアルタイム性で計算する必要があるため、計算負荷が大きいマップマッチング処理は行わずに地域メッシュ単位で集計を行う。時間分解能、空間分解能が評価結果に与える影響については、6章で考察する。

1)時間分解能

本論文で推定する道路の走行性能は冬季気象の影響を受けるが、降雪や気温といった気象条件は分単位ではなく、時間単位で緩やかに変化すると想定される。また、気象に関するデータ更新は1時間単位であるため、本論文では、異常事象の発生危険性評価の時間分解能は1時間と設定する。異常事象発生後の評価については、出来るだけ早い方が望ましいが、現状のプローブ車両の普及率を考慮すると現時点では1時間間隔での評価となる。将来的に、プローブ車両が普及した場合は、時間分解能を小さくすることも可能である。

2)空間分解能

空間解像度については、道路管理者は、路線、区間単位で対応を行うことから、異常事象の発生危険性は、路線単位、区間単位で評価できることが望ましい。本論文では、気象データの最小解像度(500m 四方メッシュ)を考慮し、地域4次メッシュ(500m 四方メッシュ)単位で評価を行うが、実運用時は、道路管理者と調整の上で、道路管理に必要な区間単位で評価を行う。

3-8-2 STEP2: 過去の道路の走行性能の推定方法

① 前処理(データ抽出)

STEP1 で設定したデータ期間及び時間分解能, 空間分解能でプローブ車両データを抽出する.

プローブ車両データが記録する緯度経度と対象区間とを対応付け, 評価を行う区間のデータを抽出する. この時, 車両の進行方向を加味して, 評価を実施する方向別にデータを抽出すると以降の推定及び評価の精度が向上する. なお, 本論文では, 異常事象が発生した方向の道路のデータのみを抽出して分析を行う.

② 区間別の個別車両の通過速度の算出

ここで, 評価区間を通過するプローブ車両のインデックスを $k = \{1, 2, \dots, J\}$ とおき, 1 日の時間帯を $t = \{0, 1, \dots, 23\}$ で表す. また, 分析対象日数が N 日ある時, $d = \{1, 2, \dots, N\}$ とおく.

式(3-11)より, ある日 d のある時間帯 t に, ある区間を J 台のプローブ車両が通過するとき, 個別プローブ車両 k の区間通過距離幅 $\hat{x}_{k,t,d}^*$ と区間通過時間幅 $\hat{t}_{k,t,d}^*$ から区間通過速度 $\hat{v}_{k,t,d}^*$ を算出する. 時間帯 t にある区間を通過する J 台のプローブ車両通過速度 $\hat{v}_{k,t,d}^*$ の集合を $\hat{V}_{t,d}^*$ とおき, 式(3-12)のとおり定義する.

$$\hat{v}_{k,t,d}^* = \frac{\hat{x}_{k,t,d}^*}{\hat{t}_{k,t,d}^*} \quad (3-11)$$

$$\hat{V}_{t,d}^* \equiv \{ \hat{v}_{1,t,d}^*, \hat{v}_{2,t,d}^*, \dots, \hat{v}_{J,t,d}^* \} \quad (3-12)$$

③ 時間帯別の道路の走行性能の推定

ある日 d のある時間帯 t の個別プローブ車両の通過速度集合 $\hat{V}_{t,d}^*$ の 85 パーセントイル速度を $PT\hat{v}_{t,d}^*$ とおき, この速度 $PT\hat{v}_{t,d}^*$ をある日 d のある時間帯 t に発揮された道路の走行性能と考える.

④ 過去の期間の時間帯別の道路の走行性能分布の推定

過去の期間のデータ日数が N 日ある時、ある日 d の時間帯 t の85パーセンタイル速度 $PT\hat{v}_{t,d}^*$ を算出し、その集合を式(3-13)に示すとおり $PT\hat{V}_t^*$ と定義する。 $PT\hat{V}_t^*$ は、正規分布で近似できると仮定し、 $PT\hat{V}_t^*$ の平均値 μ_t^* と分散 σ_t^{2*} を式(3-14)、式(3-15)のとおり算出すると、過去の各時間帯 t の道路の走行性能の分布 $p(v_t^*)$ を式(3-16)で表すことができる。

$$PT\hat{V}_t^* \equiv \{PT\hat{v}_{t,1}^*, PT\hat{v}_{t,2}^*, \dots, PT\hat{v}_{t,N}^*\} \quad (3-13)$$

$$\mu_t^* = \frac{1}{N} \sum_{d=1}^N PT\hat{v}_{t,d}^* \quad (3-14)$$

$$\sigma_t^{2*} = \frac{1}{N} \sum_{d=1}^N (PT\hat{v}_{t,d}^* - \mu_t^*)^2 \quad (3-15)$$

$$p(v_t^*) \sim N(\mu_t^*, \sigma_t^{2*}) \quad (3-16)$$

3-8-3 STEP3: リアルタイムの道路の走行性能の推定方法

STEP3では、リアルタイムの道路の走行性能を推定するために、状態空間モデルを構築し、カルマンフィルタアルゴリズムにより状態推定を行う。

① 状態空間モデルの構築

過去の期間の $PT\hat{v}_t^*$ の変動を考慮し、状態推定を行うための状態空間モデルを構築する。本論文におけるモデル構築の考え方については、3-9-1 項で詳細を整理する。

線形ガウス状態空間モデルの詳細とカルマンフィルタを用いた状態推定手順については、3-6 節で整理したとおりである。

② モデルパラメータの同定

線形ガウス状態空間モデルのカルマンフィルタによる状態推定では、初期状態の分布とノイズの分散がモデルパラメータとなる。そのため、過去の期間の $PT\hat{v}_t^*$ を用いて、最尤推定により、状態空間モデルのパラメータ(観測ノイズの分散,システムノイズの分散)を推定する。パラメータの推定方法の詳細は、3-6-2で整理したとおりである。

③ モデル選択

モデルの構造が決まっている下では、未知パラメータを最尤推定することによりモデルが特定されるが、構造が異なるモデル構造が複数ある場合には、その中から良いモデルを選択することが必要となる。モデル選択の方法については、3-10 及び次章で整理する。

④ 前処理(リアルタイムデータ抽出)

STEP2 と同様にして、リアルタイムに収集されるプローブ車両データから STEP1 で設定した時空間分解能でプローブ車両データを抽出する。

⑤ 区間別の個別車両の通過速度の算出

STEP2 の②と同様にして、時間 t に区間を通過する個別プローブ車両 k の区間通過速度 $\hat{v}_{k,t}$ を算出する。 $\hat{v}_{k,t,d}$ の集合を $\hat{V}_{t,d}$ とおく。

⑥ 時間帯別区間別の代表速度(道路の走行性能)の推定

$\hat{V}_{t,d}$ から 85 パーセンタイル速度 $PT\hat{v}_{t,d}$ を算出する。

⑦ 状態(リアルタイムの道路の走行性能分布)の推定

ここで、カルマンフィルタのフィルタリングに関する表記を簡潔にするため、時点 t を入力すると時間帯を返す関数を $\tau(t) \equiv (0, 1, \dots, 23)$ と定義する。

新たな観測値 $PT\hat{v}_t$ が得られる度に、カルマンフィルタにより、時間 t におけるリアルタイムの道路の走行性能の分布 $p(v_{it}|PT\hat{v}_{1:t})$ を推定する。

3-8-4 STEP4: 異常事象の発生危険性評価

①異常事象の発生危険性評価(アラート発信)

STEP2 で推定した過去の各時間帯の道路の走行性能 $p(v_{\tau(t)}^*)$ と、STEP3-①で推定した時間 t におけるリアルタイムの道路の走行性能 $p(v_{it}|PT\hat{v}_{1:t})$ との乖離度合いを評価し、異常事象発生の危険性を評価する。

本研究では、式(3-17)のとおり、 μ_{it} が過去の分布の 68%信頼区間の下限値 $(\mu_{\tau(t)}^* - z_{0.16}\sqrt{\sigma_{\tau(t)}^{2*}})$ を下回った場合に異常事象がいつ発生してもおかしくない状況(アラートレベル 1)であるというアラートを発信し、過去の分布の 95%信頼区間の下限値 $(\mu_{\tau(t)}^* - z_{0.025}\sqrt{\sigma_{\tau(t)}^{2*}})$ を下回っている場合は、既に異常事象が発生している可能性の高い状況(アラートレベル 2)をアラートする。ここで、 $z_{0.16}$ は、標準正規分布の上側 16%点であり、 $z_{0.025}$ は、標準正規分布の上側 2.5%点である。

$$Alert_t = \begin{cases} 2(= anomaly), & \text{if } \left(\mu_{it} - \left(\mu_{\tau(t)}^* - z_{0.025}\sqrt{\sigma_{\tau(t)}^{2*}} \right) < 0 \right) \\ 1(= indication), & \text{if } \left(\mu_{it} - \left(\mu_{\tau(t)}^* - z_{0.16}\sqrt{\sigma_{\tau(t)}^{2*}} \right) < 0 \right) \\ 0(= normal), & \text{if } \left(\mu_{it} - \left(\mu_{\tau(t)}^* - z_{0.16}\sqrt{\sigma_{\tau(t)}^{2*}} \right) \geq 0 \right) \end{cases}$$

(3-17)

②アラートの確信度評価

①によってアラート発信を行うが、過去の道路の走行性能及びリアルタイムの道路の走行性能は分布を持つため、2つの確率分布が得られた場合に、その相違の度合いを表す指標 Kullback-Leibler divergence(以降、KL

距離)をアラートの確信度とする^{17) 18)}。本論文では、過去の道路の走行性能及びリアルタイムの道路の走行性能のどちらもガウス分布を仮定しているため、KL距離は式(3-18)で計算できる。

過去の道路の走行性能の分布 $: p(v_{\tau(t)}^*) \sim N(\mu_{\tau(t)}^*, \sigma_{\tau(t)}^{2*})$

リアルタイムの道路の走行性能の分布 $: p(v_{t|t} | PT\hat{v}_{1:t}) \sim N(\mu_{t|t}, \sigma_{t|t}^2)$

$$KL_t = \ln\left(\frac{\sigma_{t|t}}{\sigma_{\tau(t)}^*}\right) + \frac{\sigma_{\tau(t)}^{2*} + (\mu_{\tau(t)}^* - \mu_{t|t})^2}{2\sigma_{t|t}^2} - \frac{1}{2}$$

(3-18)

ただし、KL距離は、式(3-19)に示すように過去の分布の68%信頼区間の下限值 $(\mu_{\tau(t)}^* - z_{0.16}\sqrt{\sigma_{\tau(t)}^{2*}})$ を閾値として、リアルタイムに推定するフィルタリング分布の期待値 $E(v_{t|t} | PT\hat{v}_{1:t})$ がそれぞれの閾値を下回った場合に計算を行う。

$$KL_t = \begin{cases} 0, & \text{if } \left(\mu_{t|t} - (\mu_{\tau(t)}^* - z_{0.16}\sqrt{\sigma_{\tau(t)}^{2*}}) > 0\right), \\ \ln\left(\frac{\sigma_{t|t}}{\sigma_{\tau(t)}^*}\right) + \frac{\sigma_{\tau(t)}^{2*} + (\mu_{\tau(t)}^* - \mu_{t|t})^2}{2\sigma_{t|t}^2} - \frac{1}{2}, & \text{if } \left(\mu_{t|t} - (\mu_{\tau(t)}^* - z_{0.16}\sqrt{\sigma_{\tau(t)}^{2*}}) < 0\right) \end{cases}$$

(3-19)

3-9 本研究の状態空間モデル

3-9-1 モデル構築の考え

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て考えることが一般的であり、これを時系列データの成分分解と呼ぶ^{19) 20)}。基本的な状態成分として「レベル成分、傾き成分、周期成分、回帰成分」が広く認識されている。状態空間モデルでもこの基本的な考え方は同じであり、本研究でもこれらの組み合わせによりリアルタイムの道路の走行性能を推定するためのモデル構築を行う。ただし、モデルは以下の前提で構築する。

- ・道路管理実務での汎用性を踏まえ、各区間毎に1つのモデル構造を選択するが、モデルのパラメータは、区間毎にそれぞれ推定する。
- ・プローブ車両の速度は、プローブ車両の速度が観測された時点で道路幾何構造の影響を受けていると考え、説明変数に幾何構造は考慮しない。

本研究における状態空間モデルのシステムモデルについて整理する。前述したとおり、状態空間モデルでは、基本的な状態成分として「レベル成分、傾き成分、周期成分、回帰成分」の組み合わせによってモデルを構築する。ここでは、モデルの定式化とモデル候補の考え方を示すことに留め、各モデルを用いて、実データを分析した結果を確認して、モデルを選択する。各事例における分析結果、モデル選択の結果については、4章で整理する。

プローブ車両速度の時間変動が右肩上がりや左肩下がりといったトレンド傾向を持たないことは、明らかであるため、本研究において、トレンド成分は考慮しない。また、3-1-2で定義したように、道路の走行性能はその区間を交通条件によらずにスムーズ走行出来た時の速度であり、本研究で分析対象とする地域は、地方の郊外部や山間部等の交通量が少ない区間であるため、下流区間の速度低下の影響は考えない。

路面の走りやすさへ影響を与えると想定できる気象条件(降雪量と気温)については回帰成分として考慮し、明暗については、周期的な変動成分として考慮することにする。ここで降雪量は、時刻 t の6時間前からの累積降雪量とする。6時間の累積降雪量とする理由は、概ね除雪車両の作業のサイクルは4-6時間であることが多いことから²¹⁾、6時間前からの降雪が道路上に残っている可能性が高いという考えからである。また、プローブの通過車両の台数が85パーセンタイル値の精度に影響するため、プローブ車両の通過台数についても回帰成分として考慮する。プローブ車両速度は、標準偏差10km/hに収束する傾向があり、統計的有意性を95%に設定し

た場合の推定誤差±5%を確保するには20サンプルが必要とされている²⁾，そのため，実測されたプローブ台数をそのまま変数として用いる場合と，20台－サンプル数を変数として用いる場合の両方をモデル候補に含めた。

以上を踏まえると，本研究では，以下の5つ成分の組み合わせにより時系列データが説明できると仮定して状態空間モデルを構築する。実際のデータに適用し，モデル選択を行う候補として，各成分の組み合わせを考慮して，表 3-2に示す13種類のモデル候補を設定した。モデルパラメータについては，各区間毎の時系列データを用いて，3-6-2に整理した方法で推定する。

【モデルを構築する状態成分】

- 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(実測値，差分：必要サンプル数－実測値)

表 3-2 構築モデル一覧

No	モデル	観測量 (被説明変数) 入力	観測行列 (説明変数) 入力	状態ベクトル (潜在変数) 出力
①	ローカルレベルモデル	$PT\hat{V}_t$:時間別 85 パーセン タイル速度	—	μ_t :レベル成分
②	周期成分モデル (①+周期成分)	$PT\hat{V}_t$:時間別 85 パーセン タイル速度	—	μ_t :レベル成分, $\gamma_{1,t}$:周期成分
③	回帰成分モデル (①+降雪量回帰成分)	$PT\hat{V}_t$:時間別 85 パーセン タイル速度	\hat{S}_t :6時間降雪量	μ_t :レベル成分, $\beta_{s,t}$:降雪量回帰成分
④	回帰成分モデル (①+気温回帰成分)	$PT\hat{V}_t$:時間別 85 パーセン タイル速度	\hat{k}_t :気温	μ_t :レベル成分, $\beta_{k,t}$:気温回帰成分
⑤	回帰成分モデル (①+プローブ台数回帰成分)	$PT\hat{V}_t$:時間別 85 パーセン タイル速度	\hat{q}_t :プローブ通過台数(差分)	μ_t :レベル成分, $\beta_{q,t}$:プローブ台数回帰成分(差分)
⑥	回帰成分モデル (①+降雪量+気温+プロ ーブ台数回帰成分)	$PT\hat{V}_t$:時間別 85 パーセン タイル速度	\hat{S}_t :6時間降雪量, \hat{k}_t :気温, \hat{q}_t :プローブ通過台数(差分)	μ_t :レベル成分, $\beta_{s,t}$:降雪量回帰成分 $\beta_{k,t}$:気温回帰成分, $\beta_{q,t}$:プローブ台数回帰成分(差分)

No	モデル	観測量 (被説明変数) 入力	観測行列 (説明変数) 入力	状態ベクトル (潜在変数) 出力
⑦	周期成分回帰成分モデル (②+降雪量回帰成分)	$PT\hat{v}_t$:時間別 85 パーセン タイル速度	\hat{S}_t :6時間降雪量	μ_t :レベル成分, $\gamma_{1,t}$:周期成分, $\beta_{s,t}$:降雪量回帰成分
⑧	周期成分回帰成分モデル (②+気温回帰成分)	$PT\hat{v}_t$:時間別 85 パーセン タイル速度	\hat{k}_t :気温	μ_t :レベル成分, $\gamma_{1,t}$:周期成分, $\beta_{k,t}$:気温回帰成分
⑨	周期成分回帰成分モデル (②+プローブ台数回帰成分)	$PT\hat{v}_t$:時間別 85 パーセン タイル速度	\hat{q}_t :プローブ通過台数(差分)	μ_t :レベル成分, $\gamma_{1,t}$:周期成分 $\beta_{q,t}$:プローブ台数回帰成分(差分)
⑩	周期成分回帰成分モデル (②+プローブ台数回帰成分)	$PT\hat{v}_t$:時間別 85 パーセン タイル速度	\hat{q}_t :プローブ通過台数(実測)	μ_t :レベル成分, $\gamma_{1,t}$:周期成分 $\beta_{q,t}$:プローブ台数回帰成分(実測)
⑪	周期成分回帰成分モデル (⑨+降雪量回帰成分)	$PT\hat{v}_t$:時間別 85 パーセン タイル速度	\hat{S}_t :6時間降雪量, \hat{q}_t :プローブ通過台数(差分)	μ_t :レベル成分, $\gamma_{1,t}$:周期成分, $\beta_{s,t}$:降雪量回帰成分, $\beta_{q,t}$:プローブ台数回帰成分(差分)
⑫	周期成分回帰成分モデル (⑨+気温回帰成分)	$PT\hat{v}_t$:時間別 85 パーセン タイル速度	\hat{k}_t :気温, \hat{q}_t :プローブ通過台数(差分)	μ_t :レベル成分, $\gamma_{1,t}$:周期成分, $\beta_{k,t}$:気温回帰成分, $\beta_{q,t}$:プローブ台数回帰成分(差分)
⑬	周期成分回帰成分モデル (②+降雪量+気温+プローブ台数回帰成分)	$PT\hat{v}_t$:時間別 85 パーセン タイル速度	\hat{S}_t :6時間降雪量, \hat{k}_t :気温, \hat{q}_t :プローブ通過台数(差分)	μ_t :レベル成分, $\gamma_{1,t}$:周期成分, $\beta_{s,t}$:降雪量回帰成分 $\beta_{k,t}$:気温回帰成分, $\beta_{q,t}$:プローブ台数回帰成分(差分)

3-9-2 定式化

表 3-2 で整理した提案モデルの中で、最も変数が多いモデル 13 は、式(3-20)~式(3-25) のように定式化できる。その他のモデルについてはモデル 13 から変数を減らした形になるため、省略する。本研究での状態成分は、前述したように、時刻 t のレベル成分 μ_t (一般的な線形回帰モデルの切片に相当) と周期的な変動を表す周期成分 γ_t 、時刻 t までの 6 時間累積降雪量 \hat{s}_t とプローブ通過台数 \hat{q}_t 、気温 \hat{k}_t に対する回帰係数 $\beta_{s,t}, \beta_{q,t}, \beta_{k,t}$ と表す。システムモデルはこれらの各成分が、前時点の値から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として、式(3-20)~式(3-24)のように表す。

周期的な変動成分は周期数を c とした時に、一般に $c-1$ 本の方程式で表す。本研究における速度の変動は、1 日で周期すると考え、周期数 c は 1 日当たりの時間数の 24 となり、式(3-24)に示すとおり、23 本の方程式が必要となる。式(3-24)の 1 本目の式は、周期変動の総和が 0 になるという仮定を利用して、次の期の周期成分を求めている。式(3-24)の 2 本目以降の式は、時刻 t における i 番目の要素を $\gamma_{i,t}$ とおくと、時刻 $t+1$ の周期成分は、 $i+1$ 番目の要素と等しいことを示している。周期成分の考え方については、簡単な例として 4 周期の例を表 3-3 に示す。

システムモデル：

$$\text{レベル成分} \quad \mu_{t+1} = \mu_t + \varepsilon_t, \quad \varepsilon_t \sim N(0, \sigma_\varepsilon^2) \quad (3-20)$$

$$\text{積雪回帰成分} \quad \beta_{s,t+1} = \beta_{s,t} + \xi_t, \quad \xi_t \sim N(0, \sigma_\xi^2) \quad (3-21)$$

プローブ通過台数回帰成分

$$\beta_{q,t+1} = \beta_{q,t} + \zeta_t, \quad \zeta_t \sim N(0, \sigma_\zeta^2) \quad (3-22)$$

気温回帰成分

$$\beta_{k,t+1} = \beta_{k,t} + \tau_t, \quad \tau_t \sim N(0, \sigma_\tau^2) \quad (3-23)$$

周期成分

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

(3-24)

表 3-3 周期成分の例(4周期の例)

3つの状態成分で4つの周期を表現

	t	$t+1$	$t+2$	$t+3$	$t+4$	$t+5$	$t+6$	$t+7$
γ_1	$\gamma_{1,t} = 1$	$\gamma_{1,t+1} = -6$	$\gamma_{1,t+2} = 3$	$\gamma_{1,t+3} = 2$	$\gamma_{1,t+4} = 1$	$\gamma_{1,t+5} = -6$	$\gamma_{1,t+6} = 3$	$\gamma_{1,t+7} = 2$
γ_2	$\gamma_{2,t} = 2$	$\gamma_{2,t+1} = 1$	$\gamma_{2,t+2} = -6$	$\gamma_{2,t+3} = 3$	$\gamma_{2,t+4} = 2$	$\gamma_{2,t+5} = 1$	$\gamma_{2,t+6} = -6$	$\gamma_{2,t+7} = 3$
γ_3	$\gamma_{3,t} = 3$	$\gamma_{3,t+1} = 2$	$\gamma_{3,t+2} = 1$	$\gamma_{3,t+3} = -6$	$\gamma_{3,t+4} = 3$	$\gamma_{3,t+5} = 2$	$\gamma_{3,t+6} = 1$	$\gamma_{3,t+7} = -6$

周期の総和が0になることを利用して、次期の状態を求めている。

本研究では、プローブの観測速度 $PT\hat{v}_t$ は、レベル成分 μ_t 、周期成分 $\gamma_{1,t}$ 、観測変数を用いた回帰成分の線形和に確率的な観測ノイズ η_t が加わって出力されるものと考え、観測モデルを式(3-25)のように表す。

観測モデル：

$$PT\hat{v}_t = \mu_t + \gamma_{1,t} + \beta_{s,t} \hat{s}_t + \beta_{q,t} \hat{q}_t + \beta_{k,t} \hat{k}_t + \eta_t, \quad \eta_t \sim N(0, \sigma_\eta)$$

(3-25)

なお、式(3-20)~式(3-25)は、式(3-3)、式(3-4)に示した線形ガウス状態空間モデルの一般形の各変数を以下のよ
うに定義することで表現することができる。

$$\mathbf{x}_t = (\mu_t \quad \beta_{s,t} \quad \beta_{q,t} \quad \beta_{k,t} \quad \gamma_{1,t} \quad \gamma_{2,t} \quad \cdots \quad \gamma_{23,t})^T,$$

$$\mathbf{F}_t = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 & \cdots & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & & 0 \\ 0 & 0 & 0 & 0 & -1 & -1 & & -1 \\ 0 & 0 & 0 & 0 & 1 & 0 & & 0 \\ \vdots & & & & & & \ddots & \vdots \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \end{bmatrix}, \quad \mathbf{G}_t = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix},$$

$$\mathbf{v}_t = (\varepsilon_t \quad \xi_t \quad \zeta_t \quad \tau_t \quad \omega_t)^T,$$

$$\mathbf{Q}_t = \begin{bmatrix} \sigma_\varepsilon^2 & 0 & 0 & 0 & 0 \\ 0 & \sigma_\xi^2 & 0 & 0 & 0 \\ 0 & 0 & \sigma_\zeta^2 & 0 & 0 \\ 0 & 0 & 0 & \sigma_\tau^2 & 0 \\ 0 & 0 & 0 & 0 & \sigma_\omega^2 \end{bmatrix},$$

$$\mathbf{y}_t = PT\hat{\mathbf{y}}_t, \quad \mathbf{H}_t = (1 \quad \hat{s}_t \quad \hat{q}_t \quad \hat{k}_t \quad 1 \quad 0 \quad \cdots \quad 0)^T,$$

$$\mathbf{w}_t = \eta_t, \quad \mathbf{R}_t = \sigma_\eta$$

(3-26)

3-10 モデル選択方法

モデルの構造が決まっている下では、未知パラメータを最尤推定することによりモデルが特定されるが、構造が異なるモデル構造が複数ある場合には、その中から良いモデルを選択することが必要となる。

モデル選択に関しては、情報量基準AIC²³⁾、平均二乗誤差といった尺度がある。ただし、これらの指標はその選択された最良のモデルが「どれだけ良いのか」については示してくれない。特にデータの量や質が十分かどうかを判断するためには、モデル選択だけではなく、モデルの評価を行うことが重要であるとされている。そのため、モデルの選択、評価方法は個々の問題に対して、検討を行う必要がある。本論文ではAIC、平均二乗誤差といったこれらの値は参考にするものの、目的である道路の異常事象の発生危険性を最も妥当に評価できると考えられるモデルを選択する。提案手法による異常事象の発生危険性の評価結果の検証方法については、次章で詳細を整理する。

3章の参考文献

- 1) 国土交通省HP：降雪時を想定したタイムライン（防災行動計画），<https://www.mlit.go.jp/common/001133425.pdf>.
- 2) 稲沢太志，神田忠士，松本幸司：大雪タイムライン(案)の作成及び課題の整理，http://www.thr.mlit.go.jp/yukimirai_morioka/pdf/ronbun_2.pdf.
- 3) 鈴木正彦，大野敦史：タイムラインを活用した雪寒対応の取り組み，
- 4) 北川 源四郎，時系列解析入門，岩波書店，2005.
- 5) 北川 源四郎，田中 勝人，川崎 能典:時系列分析ハンドブック，新倉書店，2016.
- 6) R. E. Kalman, P. L. Falb, and M. A. Arbib. Topics in mathematical system theory, Vol. 1. McGraw-Hill New York, 1969.
- 7) G. Kitagawa. Monte carlo filter and smoother for non-gaussian nonlinear state space models. Journal of Computational and Graphical Statistics, Vol. 5, No. 1, pp. 1,1996.
- 8) N. J. Gordon, D. J. Salmond, and A. F. M. Smith. Novel approach to nonlinear non-gaussian bayesian state estimation. IEE Proceedings F - Radar and Signal Processing, Vol. 140, No. 2, pp. 107, 1993.
- 9) 島田直希:時系列解析 自己回帰型モデル・状態空間モデル・異常検知，共立出版，2019.
- 10) 野村 俊一:カルマンフィルタ，共立出版，2016.
- 11) 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-，朝倉書店,2013.
- 12) 樋口 知之：予測にいかず統計モデリングの基本 ベイズ統計入門から応用まで，講談社，2011.
- 13) 沖本 竜義:経済・ファイナンスデータの計量経済時系列分析，朝倉書店，2009.
- 14) 片山 徹：非線形カルマンフィルタ，朝倉書店，2011..
- 15) J.J.F.コマンダー，S.J.クープマン，和合 肇，松田 安昌:状態空間時系列分析入門，シーエーピー出版，2008.
- 16) 八巻 直一，矢部 博，安定な準ニュートン法のクラスについて，数理解析研究講究録，915巻，192-202，1995.
- 17) 荻原 淳一郎，瓜生 真也，牧山 幸史，基礎から分かる時系列分析，技術評論社，2018.
- 18) 杉山 将:確率分布間の距離推定：機械学習分野における最新動向，日本応用数理学会論文誌，vol.23, no.3, pp.439-452, 2013.
- 19) 小西 貞則，北川 源四郎,:情報量基準，朝倉書店，2018.
- 20) Jacques J. F. Commandeur, Siem Jan Koopman: An Introduction to State Space Time Series Analysis, Oxf

ord University Press,2007.

- 21) 高木朗義, 杉浦聡志, 岩田裕憲, 目標レベルに基づく除雪機械の配置計画方法に関する研究, 土木学会論文集F4(建設マネジメント), Vol.71, No.4, I_45-I_52, 2015.
- 22) 馬場拓也, 永尾慎一郎, 手塚誠, 川岸孝治, 中村英樹, 民間プローブデータを活用した道路交通性能評価指標の検討, 土木計画学研究・講演集(CD-ROM), Vol.34, pp.294, 2011.
- 23) Akaike, H.: A new look at the statistical model identification, IEEE Trans. AC, 19-6, pp.716-723, 1974.

第4章 実データによる提案手法の適用検証

本章では、実際に冬季道路交通において異常事象が発生した際のデータに、提案手法を適用し、その評価結果の妥当性について検証を行う。また、前章で整理した複数のモデル候補による異常事象の危険性評価結果と、観測値を確定的に扱い異常事象の危険性を評価した結果を比較し、モデルの有効性についても併せて確認する。

4-1 検証フロー

提案手法の検証フローを図4-1に示す。本章ではまず、検証対象として、2018年~2019年に東北地方整備局管内で発生した冬季の立ち往生事象61事例を整理を行い、使用するプローブ車両データ及び気象データについて整理を行う。次に評価結果の妥当性の評価方法について検討を行い、検討した手法に従って妥当性の評価を行う。さらに前章で構築したモデル候補による評価結果を比較し、最も妥当な評価結果を示すモデルを選択する。最後に選択したモデルによる評価結果と観測値を確定的に用いて評価した場合の評価結果を比較し、提案モデルの有用性を確認する。

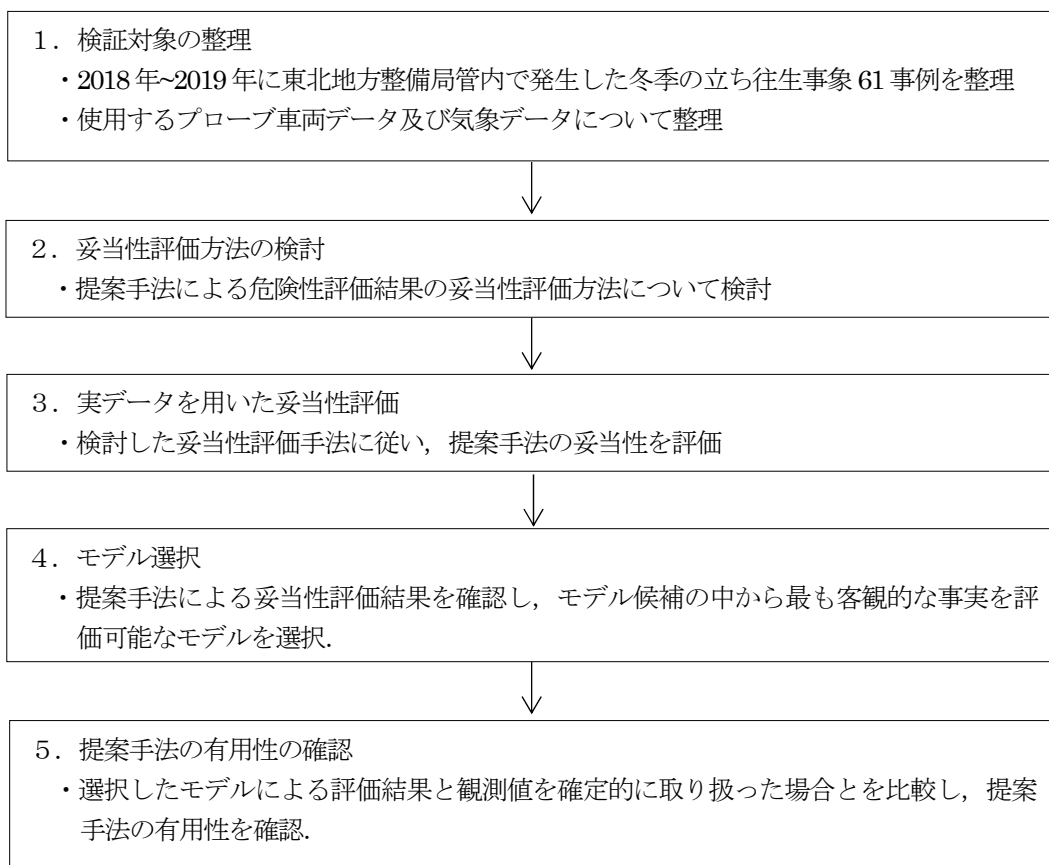


図4-1 検証フロー

4-2 検証対象の整理

4-2-1 概要

提案手法の検証対象は、2018年1月～2月(2ヶ月間)と2019年1月～2月(2ヶ月間)に国土交通省東北地方整備局管内で発生した冬季立ち往生事例60事例と2018年2月6日に発生した福井県国道8号線での立ち往生事例(1事例)の計61事例とする。各事例の検証対象範囲は、立ち往生が発生した区間(メッシュ)とその上下流の30区間(メッシュ)ずつの計61区間を抽出し手法を適用する。そのため、適用対象区間は61事例×61区間で全3,721区間となる。

適用対象とする61事例の詳細は、表 4-1に整理する。整理内容は、国土交通省東北地方整備局が整理する立ち往生車両発生リストを基に、立ち往生発生日時、発生場所、事象の内容、道路管理者の対応内容、天候状況等を整理した。立ち往生が発生した箇所の位置については図 4-2に示す。

表4-1 適用事例一覧表

No	年	月	日	時	分	道府県	路線名	進行方向	距離標	地先名	4次メッシュ番号	予防的 通行 規制 区間	勾配(%)	災害事象の内容	確認	処理	交通状況	滞留長	タイヤ・チェーンに関する備考	天候	気温	積雪	注意報等	路面状況
1	2019	1	24	13	15	山形	48号	上	375	関山トンネル山形坑口 CCTV 付近	574044734	○	5	大型車立ち往生発生	CCTV+現地	グレーダー(牽引)	通行止め	2800	不明	雪	-4	3		圧雪・凍結
2	2019	1	25	14	40	山形	47号	上	145.9	戸沢村大字古口沓喰	584000984	○	0	大型車(セミトレーラー)立ち往生発生	現地	ホイローダ(牽引)	渋滞	2000	スタッドレス・チェーン携行(現地で装着)	雪	0	0	大雪注意報	圧雪
3	2019	1	25	15	3	山形	47号	下	144.02	戸沢村大字古口	584001803	○	3.5	大型車立ち往生発生	CCTV	ホイローダ(牽引)	渋滞	2000	不明	雪	0	0	大雪注意報	圧雪
4	2019	1	21	9	40	青森	104号	下	88	八戸市大字櫛引	604153741	○	5	大型車立ち往生発生	通報(警察)	チェーンを装着し脱出	片側交互通行	1000	チェーン携行	小雪	-4	1	風雪・雷・低温注意報	圧雪・凍結
5	2019	1	18	14	42	山形	48号	上	375	関山トンネル山形坑口 CCTV 付近	574044734	○	5	大型車立ち往生発生	CCTV+現地	グレーダー(牽引)	片側交互通行	800	不明	雪	-4	2		圧雪・凍結
6	2019	1	24	13	10	宮城	48号	下	33.7	仙台市青葉区 作並字岳山	574044462	○	5	大型車立ち往生発生	CCTV	自力脱出	片側交互通行	100	チェーン携行	雪	-4	2		圧雪
7	2019	2	8	11	15	岩手	46号	下	29.3	雫石町橋場坂本山	594046672	○	4.8	大型車立ち往生発生	CCTV	仙岩トンネル坑口通過を確認	支障なし	10	不明	雪	-8	3	大雪・風雪	圧雪・凍結
8	2019	1	22	7	33	岩手	4号	下	442.2	一関市山目字沢内	584130293	○	4.3	大型車立ち往生発生	CCTV	自力脱出	一部車線閉塞	0	不明	雪	-3	1	大雪・なだれ注意報	圧雪・凍結
9	2019	1	24	6	54	岩手	4号	下	452.6	平泉町平泉下徳沢	584140293	○	4.5	大型車立ち往生発生	CCTV	自力脱出	一部車線閉塞	0	不明	雪	-3	1	風雪注意報	圧雪・凍結
10	2019	1	24	11	15	岩手	46号	下	29.2	雫石町橋場坂本山	594046672	○	4.8	大型車立ち往生発生	CCTV	仙岩トンネル内まで牽引	支障なし	0	チェーン未携行(未装着)	雪	-2	3	大雪・風雪・着雪	圧雪・凍結
11	2018	1	24	9	7	山形	112号	上	60.7	鶴岡市田麦俣字六十里山	573967363	○	5	大型車立ち往生発生	CCTV	ロータリ除雪車で牽引(牽引)	通行止め	不明	スタッドレス・チェーン携行	雪	-7	1	暴風雪警報 大雪注意報	圧雪
12	2018	1	26	13	9	山形	112号	上	60.8	鶴岡市田麦俣字六十里山	573967363	○	5	大型車立ち往生発生	CCTV	ロータリ除雪車で牽引(牽引)	通行止め	不明	スタッドレス・チェーン携行	雪	-9	1	風雪注意報	圧雪
13	2018	2	18	0	40	青森	4号	下	639.9	南部町剣吉字上平	604152362	×	5	大型車立ち往生発生	通報(警察)	除雪トラックで牽引(牽引)	通行止め	不明	不明	不明	-3	不明	風雪・大雪	圧雪・凍結
14	2018	2	14	5	15	山形	13号	下	135.6	尾花沢市大字野黒沢	574072692	×	0	大型車立ち往生発生	維持業者	除雪車(牽引)	通行止め	不明	スタッドレス・チェーン未携行	雪	0	0		圧雪
15	2018	2	6	9	45	山形	112号	上	135.6	尾花沢市大字野黒沢	573967831	×	0	大型車立ち往生発生	維持業者	除雪車(牽引)	通行止め	不明	スタッドレス・チェーン未携行	雪	0	0		圧雪
16	2018	2	13	8	41	山形	112号	上	72.5	鶴岡市田麦俣字六十里山	573967823	○	5	大型車立ち往生発生	CCTV	ロータリ除雪車で牽引(牽引)	通行止め	不明	チェーン未携行	雪	-4	1	大雪注意報	圧雪
17	2018	1	30	16	20	青森	4号	下	727.4	青森市久栗坂	614026374	×	0	中型車立ち往生発生	CCTV	チェーン装着	片側交互通行	不明	未装着	雪	-5	0	低温	圧雪
18	2018	1	23	14	30	岩手	4号	上	584.1	一戸町奥中山地内	604111082	○	3	大型車立ち往生発生	維持業者	自力脱出	片側交互通行	不明	スタッドレス・チェーン未携行	雪	-1	1	風雪注意報 大雪注意報	圧雪
19	2018	1	23	16	0	岩手	4号	上	586.8	一戸町中山地内	604112104	○	5	大型車立ち往生発生	維持業者	自力脱出	片側交互通行	不明	スタッドレス・チェーン未携行	雪	-1	1	風雪注意報 大雪注意報	圧雪
20	2018	1	23	16	20	岩手	4号	上	588.7	一戸町小繋地内	604112304	○	5	大型車立ち往生発生	維持業者	自力脱出	片側交互通行	不明	スタッドレス・チェーン未携行	雪	-1	1	風雪注意報 大雪注意報	圧雪
21	2018	1	30	14	28	秋田	46号	下	72.4	仙北市角館町 西長野字古米沢	594033472	○	6	大型車立ち往生発生	CCTV	チェーン装着後自力脱出	片側交互通行	不明	チェーン携行	雪	0	0	大雪注意報	圧雪

No	年	月	日	時	分	道府県	路線名	進行方向	距離標	地先名	4次メッシュ番号	予防的 通行 規制 区間	勾配(%)	災害事象の内容	確認	処理	交通状況	滞留長	タイヤ・チェーンに関する備考	天候	気温	積雪	注意報等	路面状況
22	2018	1	26	14	20	山形	13号	下	61.5	鳥上げ坂	574001732		0	大型車立ち往生発生	CCTV+現地	チェーン装着後自力脱出	片側交互通行	不明	スタッドレス・チェーン未携行	雪	0	1		圧雪
23	2018	1	21	19	54	山形	7号	下	188.5	遊佐町吹浦字大黒坂道東	583947902	×	不明	大型車立ち往生発生	通報(警察)	自力脱出	片側交互通行	不明	不明	雪	-1	1		圧雪
24	2018	1	22	23	5	福島	6号	下	243.7	双葉郡富岡町小浜	564100104	○	4.5	大型車立ち往生発生	現地	チェーン装着後自力脱出	片側交互通行	不明	チェーン携行	雪	-2	0	大雪警報	圧雪
25	2018	2	14	21	44	岩手	4号	上	590	一戸町小繋地区	604112511	○	3	立ち往生発生(車種不明)	警察	自力脱出	片側交互通行	不明	チェーン未携行	雪	0	1	大雪注意報	圧雪
26	2018	2	14	5	40	岩手	46号	下	28.8	雫石町橋場坂本山地内	594046583	○	5.9	大型車立ち往生発生	維持業者	除雪車(牽引)	片側交互通行	不明	スタッドレス・チェーン携行	小雪	-8	1	なし	圧雪
27	2018	2	14	8	27	岩手	46号	下	32.2	雫石町橋場竜川山地内	594046652	○	5	大型車立ち往生発生	CCTV	除雪車(牽引)	片側交互通行	不明	スタッドレス・チェーン携行(装着)	雪	-8	1	風雪注意報	圧雪
28	2018	2	15	3	20	岩手	4号	下	579.8	岩手町御堂地区	604101584	○	5	大型車立ち往生発生	CCTV+維持業者	自力脱出	片側交互通行	不明	チェーン未携行	雪	-3	1	大雪警報	圧雪
29	2018	2	27	12	30	山形	47号	上	151.2	戸沢村大字古口土湯	584010151	○	0	大型車立ち往生発生	維持業者	チェーン装着後自力脱出	片側交互通行	不明	スタッドレス・チェーン携行	曇	0	1		圧雪
30	2018	2	14	20	10	岩手	4号	下	580	岩手町御堂地区	604101682	○	5	大型車立ち往生発生	維持業者	自力脱出	車線規制	不明	チェーン未携行	雪	0	1	大雪注意報	圧雪
31	2018	1	25	21	57	岩手	4号	上	453.7	奥州市前沢区新城	584140393	○	3.5	大型車立ち往生発生	通報(警察)	自力脱出自力脱出	一部車線閉塞	不明	不明	雪	-5	0	低温注意報	凍結
32	2018	1	24	15	0	山形	13号	上	131	南原 CCTV 付近	574073114		0	大型車立ち往生発生	CCTV+現地	除雪車(持込)	一部車線閉塞	不明	スタッドレス・チェーン未携行	雪	0	0		圧雪
33	2018	1	25	18	34	山形	13号	上	29.5	西粟子 TN 付近	564061291		0	大型車立ち往生発生	現地	除雪車(牽引)	一部車線閉塞	不明	スタッドレス・チェーン未携行	雪	0	0		圧雪
34	2018	1	27	9	30	山形	112号	上	44.65	本道寺地内	574050432		0	普通車立ち往生発生	現地	パトロール車(牽引)	一部車線閉塞	不明	スタッドレス・チェーン未携行	雪	0	0		圧雪
35	2018	1	25	22	00	岩手	4号	上	453.7	奥州市前沢区新城	584140393	○	3.5	大型車立ち往生発生	通報(警察)	自力脱出	一部車線閉塞	不明	不明	雪	-5	0	低温注意報	凍結
36	2018	1	24	15	0	山形	13号	上	131	南原 CCTV 付近	574073114		0	大型車立ち往生発生	CCTV+現地	除雪車(持込)	一部車線閉塞	不明	スタッドレス・チェーン未携行	雪	0	0		圧雪
37	2018	1	25	18	34	山形	13号	上	29.5	西粟子 TN 付近	564061291		0	大型車立ち往生発生	現地	除雪車(牽引)	一部車線閉塞	不明	スタッドレス・チェーン未携行	雪	0	0		圧雪
38	2018	1	27	9	00	山形	112号	上	44.6	本道寺地内	574050432		0	普通車立ち往生発生	現地	パトロール車(牽引)	一部車線閉塞	不明	スタッドレス・チェーン未携行	雪	0	0		圧雪
39	2018	1	29	13	0	山形	112号	下	54.38	葦谷地沢橋上	573957891		0	普通車立ち往生発生	現地	パトロール車(牽引)	一部車線閉塞	不明	スタッドレス・チェーン未携行	雪	0	0		圧雪
40	2018	1	27	12	57	山形	112号	上	61.4	鶴岡市田麦俣字六十里山	573967354	○	5	大型車立ち往生発生	CCTV	維持業者により駐車帯へ誘導。 その後、チェーンを装着し自力で走行。	一部車線閉塞	不明	スタッドレス・チェーン携行	雪	-7	1	風雪注意報	圧雪
41	2018	1	30	19	26	福島	13号	下	20.2	福島市飯坂町中野字石小屋	564062044	○	5.8	大型車立ち往生発生	CCTV	自力脱出	一部車線閉塞	不明	不明	雪	-5	2	低温	圧雪
42	2018	1	30	19	44	福島	13号	下	18.7	福島市飯坂町中野字長老沢	564062063	○	5.6	大型車立ち往生発生	CCTV	自力脱出	一部車線閉塞	不明	不明	雪	-5	3	低温	圧雪
43	2018	1	22	18	22	福島	4号	上	214	須賀川市大黒町	554072493	○	3.4	大型車立ち往生発生	現地	除雪車(牽引)	一部車線閉塞	不明	不明	雪	-3	0	大雪警報	圧雪
44	2018	1	22	20	19	福島	4号	下	199	泉崎村踏瀬	554062122	×	3	大型車立ち往生発生	現地	除雪車(牽引)	一部車線閉塞	不明	不明	雪	-3	0	大雪警報	圧雪

No	年	月	日	時	分	道府県	路線名	進行方向	距離標	地先名	4次メッシュ番号	予防的 通行 規制 区間	勾配(%)	災害事象の内容	確認	処理	交通状況	滞留長	タイヤ・チェーンに関する備考	天候	気温	積雪	注意報等	路面状況
45	2018	1	22	20	59	福島	4号	上	214	須賀川市大黒町	554072493	○	34	大型車立ち往生発生	CCTV+現地	除雪車(牽引)	一部車線閉塞	不明	不明	雪	-3	0	大雪警報	圧雪
46	2018	1	22	22	10	福島	4号	下	218.2	須賀川市滑川	554072991	○	35	大型車立ち往生発生	現地	除雪車(牽引)	一部車線閉塞	不明	不明	雪	-3	0	大雪警報	圧雪
47	2018	2	14	21	30	岩手	4号	下	542.8	盛岡市下厨川字四十四田	594151004		46	大型車立ち往生発生	CCTV	除雪車(牽引)	一部車線閉塞	不明	不明	雪	0.1	2	大雪警報	積雪
48	2018	2	14	7	40	岩手	46号	下	296	雫石町橋場坂本山地内	594046672	○	6	大型車立ち往生発生	維持業者+CCTV	除雪車(牽引)	一部車線閉塞	不明	スタッドレス・チェーン携行(装着)	雪	-8	1	風雪注意報	圧雪
49	2018	2	15	0	47	岩手	4号	下	542.8	盛岡市下厨川字四十四田	594151004		46	大型車立ち往生発生	CCTV	凍結防止剤散布後	一部車線閉塞	不明	不明	雪	0.1	3	大雪警報	積雪
50	2018	2	15	2	0	岩手	4号	下	547	滝沢市菓子	594150494		2.25	大型車立ち往生発生	パトロール	チェーン装着後自力脱出	一部車線閉塞	不明	チェーン携行	雪	0.1	3	大雪警報	積雪
51	2018	2	3	19	17	岩手	45号	上	336.2	九戸郡野田村大字玉川	604106683	○	0	立ち往生発生(車種不明)	CCTV	自力脱出	一部車線閉塞	不明	不明	雪	0	0		積雪
52	2018	2	8	11	16	山形	48号	上	38.2	大洞橋 CCTV 付近	574044733		0	大型車立ち往生発生	CCTV	チェーン装着後自力脱出	一部車線閉塞	不明	チェーン携行	雪	0	0		圧雪
53	2018	2	6	10	30	山形	113号	下	98.2	遅越	573907221		0	大型車立ち往生発生	現地	除雪車(牽引)	一部車線閉塞	不明	スタッドレス・チェーン未携行	雪	0	0		圧雪
54	2018	2	12	12	20	山形	113号	上	100	新字津トンネル	573907134		0	大型車立ち往生発生	現地	除雪車(牽引)	一部車線閉塞	不明	スタッドレス・チェーン未携行	雪	0	0		圧雪
55	2018	2	14	5	0	山形	113号	上	91.6	網取	573906574		0	大型車立ち往生発生	現地	除雪車(牽引)	一部車線閉塞	不明	スタッドレス・チェーン未携行	雪	0	0		圧雪
56	2018	2	17	12	30	山形	113号	上	93.1	栗松	573906484		0	小型車立ち往生発生	現地	自力脱出	一部車線閉塞	不明	スタッドレス・チェーン未携行	雪	0	0		圧雪
57	2018	2	7	20	0	山形	112号	下	55.9	上楓登坂	573957972		0	大型車立ち往生発生	現地	除雪車(牽引)	一部車線閉塞	不明	スタッドレス・チェーン未携行	雪	0	0		圧雪
58	2018	2	14	8	10	山形	112号	下	55	頭光滝沢橋付近	573957884		0	大型車立ち往生発生	現地	除雪車(牽引)	一部車線閉塞	不明	ノーマル・チェーン携行	曇	0	0		圧雪
59	2018	2	12	9	55	山形	112号	上	60.5	鶴岡市田麦俣字六十里山	573967361	○	5	大型車立ち往生発生	維持業者	ロータリ除雪車で駐車帯まで牽引. その後自力で走行.	一部車線閉塞	不明	チェーン携行(装着)	雪	-8	1	大雪警報	圧雪
60	2019	1	25	12	0	山形	47号	上	-	戸沢村大字古口	584001901	○	-	大規模大型車立ち往生発生	現地	除雪車(牽引)	通行止め	不明		雪	0	0	大雪注意報	圧雪
61	2018	2	6	6	0	福井	8号	上	-	福井市	543612402		-	大規模大型車立ち往生発生	現地	除雪車(牽引)	通行止め	不明		雪	0	0	大雪警報	積雪



図4-2 立ち往生発生箇所的位置図

4-2-2 使用データ

(1) プローブ車両データ

本研究で使用するプローブ車両データは、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である¹⁾。プローブ車両データは、HONDAインターナビ搭載車両を対象に、それぞれの車両のID(秘匿化処理済)、データ取得日時、GPS位置情報(緯度、経度)、走行速度を記録した情報である。このプローブデータは東北大学桑原研究室を中心とする研究共同体DOMINGO²⁾の活動において、収集を行ったデータである。

HONDAインターナビは、交通情報など多彩なリアルタイム情報が通信を介して受け取れる代わりに、自らも車両の走行情報をサーバーに提供するという双方向通信情報システムである。2011年以降に発売されたHONDA車のすべてにサービスが適用されているため、車種の偏りは小さい。このシステムは、数百万台のデータを常時・リアルタイムに取得することができるが、プローブ車両が稀にしか走行しない時間帯、路線についての情報は少なく、頻繁に走行する時間、路線についての情報は多いといったデータ収集にむらが生じるという課題は残る。

(2) 気象データ

気象データは国土交通省気象庁HP³⁾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、以下の4項目とする。データ期間はプローブ車両データの期間に合わせる。モデルの構築の際には、3-9節で整理したように時間帯別の気温と6時間前からの累積降雪量を用いる。各項目の詳細については国土交通省気象庁HPを参照されたい。なお、積雪深さは基礎情報の整理の際に用いるのみで、モデルの変数としては利用しない。

【気象情報整理項目】

- ① 気温(°C)
- ② 降雪量(cm/h)
- ③ 6時間前累積降雪量(cm/6h)
- ④ 積雪深さ(cm)

(3) データ期間

1) 全データ期間

データ保持期間は、以下の2期間である。本論文では、計65日分(1,560時間)のデータを活用し、異常事象発生時の分析及び異常事象の発生危険性の評価を行う。

期間①：2018年1月20日から2月28日(40日間)

期間②：2019年1月16日から2月9日(25日間)

2) パラメータ推定期間

状態空間モデルのパラメータ推定に使用するデータ期間は、データの保持期間と各事例の異常事象の発生年を考慮し、2018年に発生した異常事象の分析の際には、2019年1月16日から2月9日までの25日間(期間②)をパラメータ推定期間とし、2019年に発生した異常事象の分析の際には、2018年1月20日から2月28日の40日間(期間①)をパラメータ推定期間として設定した。

4-3 妥当性評価方法の検討

4-3-1 妥当性評価方法の考え方

ここでは、提案手法による異常事象の発生危険性の評価結果の妥当性について評価する方法の考え方を整理する。

異常検知の分野では、モデルが正しく評価した場合の数と間違って評価した場合の数を定量化し、に示すような混同行列を用いてモデルの性能評価が行われることが多い⁴⁾。この混同行列は、陽性・陰性のラベルが既知のデータをモデルに評価させ、陽性を正しく陽性と評価した場合の数 (True Positive :TP)、陽性を間違って陰性と評価した場合の数 (第一種の過誤や誤検知, False Positive :FP)、陰性を正しく陰性と評価した場合の数 (True Negative :TN)、陰性を間違って陽性と評価した場合の数 (第二種の過誤や見逃し, False Negative :FN) からなる。この混同行列から、式(4-1)で計算できる実際に陽性であるもののうち、モデルが陽性であると評価したものの割合を示す*Recall*や、式(4-2)で計算できるモデルが陽性と評価したデータのうち、実際に陽性であるものの割合を示す*Precision*、式(4-3)に示すように、*Recall*と*Precision*の調和平均を取った*F-measure*等の指標が知られている。また、偽陽性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*Specificity*(特異度)もある⁶⁾。どの指標を重視するかは取り扱う問題の要請によって異なり、目的に見合った評価が必要である。

表 4-2 異常検知分野の性能評価の混同行列

		実際	
		陽性	陰性
モデル	陽性	TP	FP (第一種の過誤や誤検知)
	陰性	FN (第二種の過誤, 見逃し)	TN

$$Precision(\text{適合率}) = \frac{TP}{TP + FP} \quad (4-1)$$

$$Recall(\text{再現率}) = \frac{TP}{TP + FN} \quad (4-2)$$

$$F - measure = \frac{2Recall \cdot Precision}{Recall + Precision} \quad (4-3)$$

$$Specificity(特異度) = \frac{TN}{FP + TN}$$

(4-4)

本論文では、第3章で述べたように、気象条件が悪い状況下において異常事象がいつ起きてもおかしくない環境及び異常事象が発生している可能性が高い環境をアラートする手法を提案している(図43)。この異常事象がいつ起きてもおかしくない環境及び異常事象が発生している可能性が高い環境を明確に定義づけて観測することは困難であり、仮に立ち往生が発生した事実のみを正解ラベルとして、混同行列を用いた評価を行った場合、モデルのコンセプトと評価方法に矛盾が生じて、モデルの性能を正しく評価することが出来ない。

そこで、本論文では、混同行列の考え方をできるだけ踏襲しながらも、観測可能な客観的な事実(気象条件、除雪、立ち往生の発生)と手法のコンセプトを加味した提案手法の妥当性評価方法を検討し、評価を行う。




図43 提案手法の概念図

4-3-2 妥当性評価の視点

提案手法の結果の妥当性の具体的な評価の視点について整理する。本論文では、手法のコンセプトを加味して表 4-3 に示す 5 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。そこで、積雪がなく気温が高いといった異常事象の発生危険性が低い状況下でアラート発信していないか(誤発報の程度)を確認する。

次に、提案手法は、異常事象が発生してもおかしくない状況をアラート($Alert_t = 1$)するため、アラート時には異常事象が発生する直前の状況が含まれている必要がある。アラート時に見逃しがないかという視点で評価する。同じように異常事象が発生している可能性が高い状況のアラート($Alert_t = 2$)についても、実際の異常事象発生直後の状況が含まれているかという視点で評価する。

更にそのほかの客観的な事実との突き合わせとして、除雪後に異常事象の危険性(KL 距離)が低下し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、13 のモデル構造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、選択したモデルの評価結果と気象条件と異常事象に関する一般的知見との整合についても確認する。図 4-3 に示した手法のコンセプト図に対応させた各評価の視点のイメージ図については、図 4-4~図 4-7 に示す。

表 4-3 危険性評価の妥当性評価の視点

評価の視点		コンセプト	混同行列との対応
(1) 誤発報の程度	・異常事象が起こるはずのない条件で危険性が高いことアラートしていないか。 ※気象条件が良い(eg.積雪がない, 気温が高い)	・気象条件が悪い状況下において異常事象がいつ起きてもおかしくない環境及び異常事象が発生している可能性が高い環境をアラートする	第一種の過誤(誤検知)に対応する視点
(2) アラート発報(レベル 1)と立ち往生発生直前の状況の関係	・危険性が高いことをアラート(レベル 1)した時に異常事象直前の状況が含まれているか(見逃しがないか)		第二種の過誤(見逃し)に対応する視点
(3) アラート発報(レベル 2)と立ち往生発生直後の状況の関係	・危険性が高いことをアラート(レベル 2)した時に異常事象直後の状況が含まれているか(見逃しがないか)		第二種の過誤(見逃し)に対応する視点
(4) 除雪前後の異常事象の発生危険性の変化	・除雪前と比較して、除雪後は異常事象の危険性(KL 距離)が低下しているか。 ※除雪データが収集出来た事例		(その他客観的な事実との突き合わせ)

(5)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)	<ul style="list-style-type: none"> 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)
------------------------------------	---	--------------------

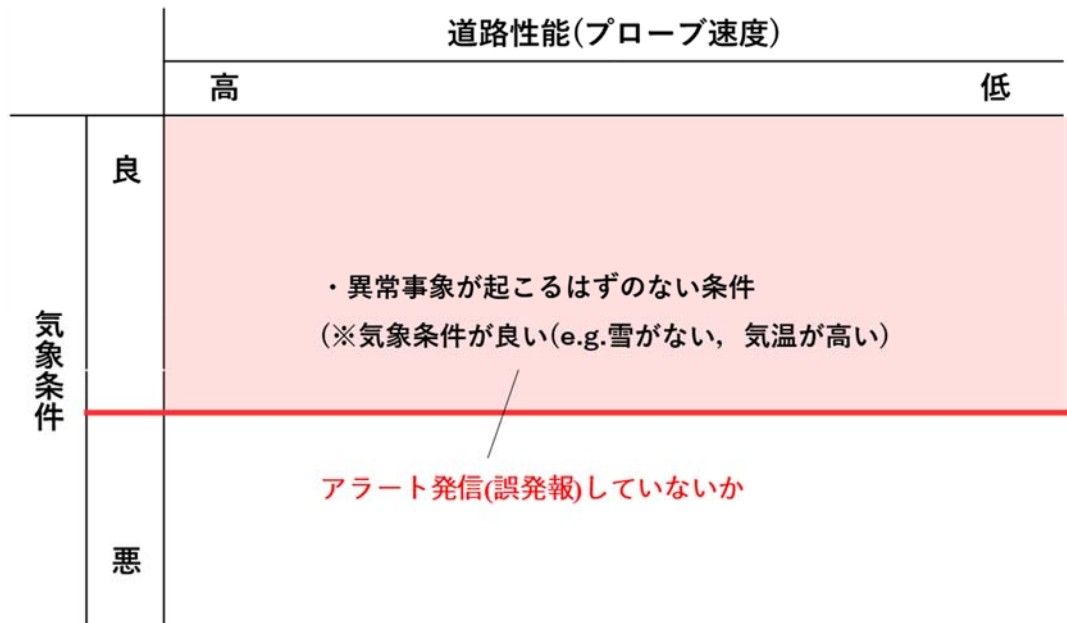


図44 評価視点①のイメージ図

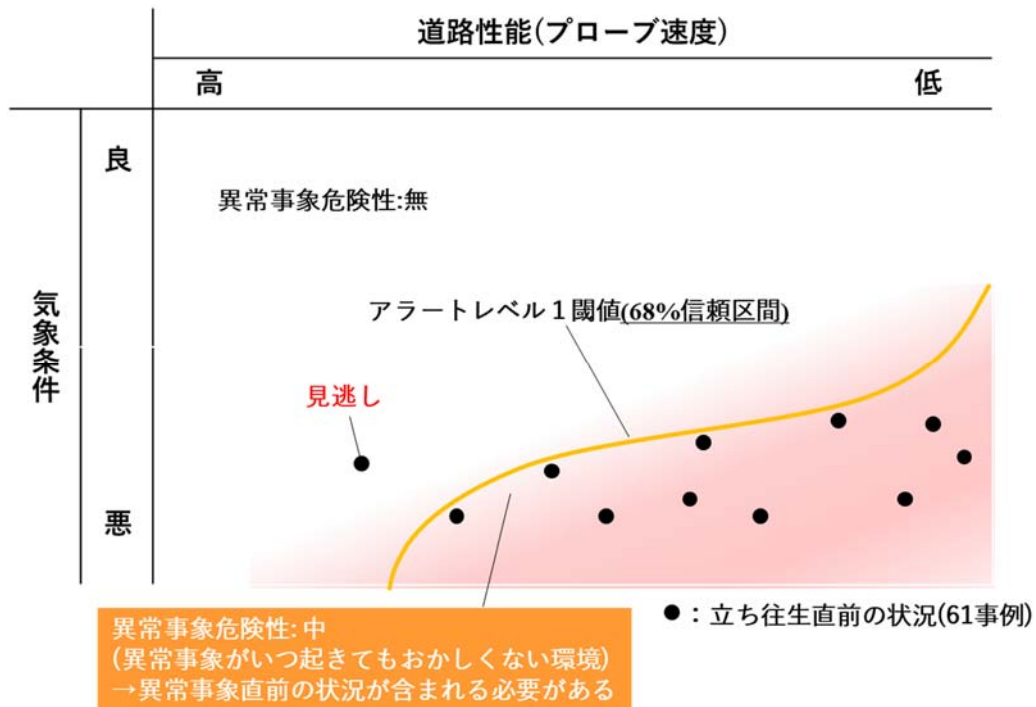


図45 評価視点②のイメージ図




図4-6 評価視点③のイメージ図




図4-7 評価視点④のイメージ図

(1) 誤発報の程度

異常事象の発生危険性が低い状況下において、アラート発信($Alert_t = 1$)がされていないか、すなわち誤発報の少なさを確認する。誤発報の少なさは、式(4-4)で示した特異度により評価が可能である。

本論文では、一般的に路面凍結時もしくは路面積雪時に道路の性能が下がり、異常事象が発生しやすくなると考えられるため、気温が高く(2°C 以上)、積雪が観測されていない(6時間前累積降雪量が 0cm)状況では異常事象の危険性がないものとして特異度を算出する。

表 4-4 本研究における混同行列

		実際		計
		陽性(危険性高)	陰性(危険性無) 気温 2°C 以上, 降雪 観測なし	
モデル	陽性(危険性高)	TP(正検知数)	FP(誤検知数)	TP+FP (モデルの検知総数)
	陰性(危険性無)	FN(見逃し数)	TN(正非検知数)	FN+TN (モデルの非検知総数)
計		TP+FN (総性能低下数)	FP+TN (性能非低下数)	TP+FP+FN+TN (検証対象総数)

(2) アラート発報(レベル1)と立ち往生発生直前の状況の関係

提案手法によるアラートレベル1は、現時点において、異常事象がいつ発生してもおかしくない環境であることを示すものである。異常事象の発生には、様々な要因が関係していると考えられるため、完全に異常事象の発生危険性をアラートすることは困難であるが、異常事象の発生前には異常事象がいつ起きてもおかしくない環境となる可能性が高いはずである。そこで、図48に示すように異常事象前の発報精度については、実際に立ち往生が発生した時間(t)、区間(i)においてその直前($t-1$)にアラート発信が出来ていたかという視点で評価を行う。なお、異常事象の発生位置は、ピンポイントでは分からず、整理の際の誤差があると考えられるため、異常事象発生箇所とその前後の区間($i-1$)、($i+1$)を含めた3区間における異常事象発生直前($t-1$)のアラートの発報有無を確認する。

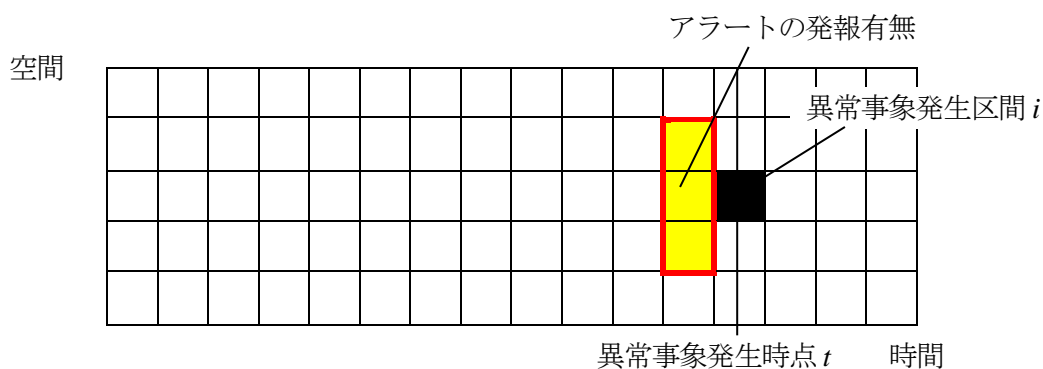


図48 異常事象発生直前アラート評価のイメージ

(3) アラート発報(レベル2)と立ち往生発生直後の状況の関係

提案手法によるアラートレベル2は、現時点において、異常事象が発生している可能性が高い環境であることを示すものである。図4-9に示すように実際に立ち往生が発生した時間(t)、区間(i)において、アラートレベル2の発報状況を確認する。先ほどの指標と同様に、異常事象発生箇所(i)とその前後の区間($i-1$)、($i+1$)を含めた3区間において異常事象発生時(t)と直後 $t+1$ の計2時間のアラートの発報有無を確認する。




図4-9 異常事象発生直後アラート評価のイメージ

(4) 除雪前後の異常事象の発生危険性の変化

多くの場合、道路管理者による道路の除雪を行うことによって、積雪によって低下していた道路の走行性能が回復し、異常事象の発生危険性は低下すると考えられる。そこで、ここでは、除雪によって、異常事象の危険性が下がることを前提として、提案手法がその状況を評価できているかによって、妥当性の検証を行う。

本論文では、除雪前後の異常事象の発生危険性(KL距離)を比較し、除雪前のKL距離と比較して、除雪後のKL距離が小さくなっているかを確認する。具体的には除雪区間を(i)とし、除雪発生時間を t とした時のKL距離を $KL_t^{(i)}$ とした時、式(4-5)で計算できるKL距離の比で評価を行う。ただし、この評価は、除雪データを入手することができた2019年1月25日に発生した山形県国道47号の立ち往生事例(No.60)のみに適用する。図4-10に除雪前後の異常事象の発生危険性評価のイメージを示す。

$$KL\text{距離比} = \frac{\sum_i KL_{t+1}^{(i)}}{\sum_i KL_{t-1}^{(i)}} \quad (4-5)$$

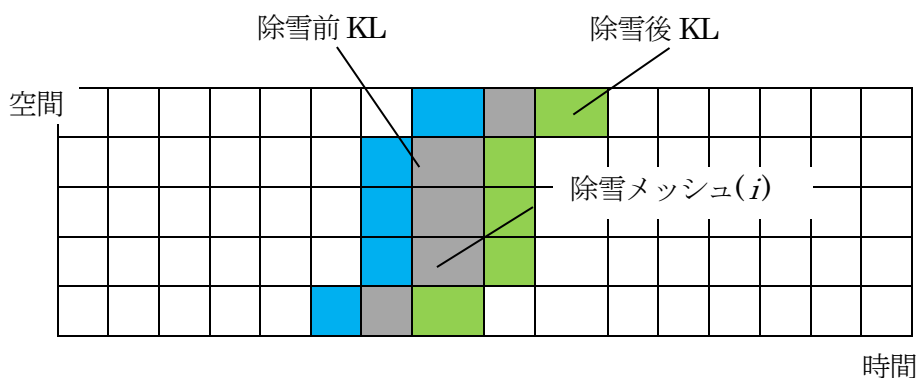


図4-10 除雪前後の異常事象の発生危険性評価のイメージ

4-4 実データを用いた妥当性評価結果

4-4-1 パラメータ推定結果

本論文では、61事例の全区間毎、モデル毎に3-6-2の方法に従い、最尤推定により、モデルパラメータを推定する。推定が必要なパラメータは、3-9節で整理した13種類のモデル候補の観測誤差分散 σ_η とシステム誤差分散行列 Q_t である。ここで、表4-5に、全事例、全区間の推定したモデル別のパラメータを整理する。表4-5を見ると、どのモデルも観測誤差の分散 σ_η は30程度と推定された。システム誤差分散については、どのモデルもレベル成分の誤差分散と周期成分の誤差分散が相対的に大きく、プローブ車両台数回帰係数の誤差分散、降雪量回帰係数の誤差分散、気温回帰係数の誤差の分散は小さな値が推定された。

表4-5 モデル別推定パラメータの最尤推定量の中央値一覧

モデル番号	観測誤差分散 σ_η	レベル成分誤差分散 σ_ε^2	降雪量回帰係数誤差分散 σ_ξ^2	プローブ車両台数回帰係数誤差分散 σ_ζ^2	気温回帰係数誤差分散 σ_τ^2	周期成分誤差分散 σ_ω^2
1	34.35511	1.85882	-	-	-	-
2	32.79128	1.34756	-	-	-	0.00147
3	35.99967	1.25914	0.00005	-	-	-
4	35.72291	1.33330	-	-	0.00055	-
5	32.11232	1.20731	-	0.00769	-	-
6	33.89865	0.44470	0.00002	0.00000	0.00073	-
7	33.17775	0.83705	0.00002	-	-	0.00075
8	32.66234	1.02633	-	-	0.00059	0.00091
9	30.96630	1.05778	-	0.00000	-	0.00076
10	31.72344	0.36414	0.00001	0.00000	0.00046	0.00012
11	31.59276	1.19408	-	0.00001	-	0.00058
12	31.32165	0.67518	0.00001	0.00000	-	0.00024
13	31.16814	0.85956	-	0.00000	0.00041	0.00032

4-4-2 モデル別の妥当性評価結果

(1) 誤発報の程度

図4-11は、4-3-2項(1)に整理した方法に従い、事例別、モデル別にアラート発報($Alert_{t-1} = 1$)の状況を整理し、式(4-4)により、特異度の平均値を示したものである。どのモデルを用いても特異度の平均が97%以上を示しているが、特にモデル7、モデル11とモデル13の特異度の値が高く、誤発報が少ないことを示している。特異度が1%変わると、おおよそ、1事例あたり38(回/日)のアラート回数が増えるため、数パーセント異なるだけで、実際の道路管理への活用を考えると大きな差になると考えられる。




図4-11 モデル別の特異度の箱ひげ図

表4-6 モデル別の特異度の平均値の一覧

モデル番号	1	2	3	4	5	6	7	8	9	10	11	12	13
平均	97.00%	97.64%	97.80%	97.46%	97.04%	97.53%	98.10%	97.61%	97.54%	97.46%	97.93%	97.57%	97.91%

(2) アラート発報(レベル1)と立ち往生発生直前の状況の関係

図4-12及び表4-7は、4-3-2項(2)に整理した方法に従い、事例別、モデル別に、異常事象発生直前のアラート発報($Alert_t = 1$)の有無を確認したものである。尚、61事例の内、プローブ台数が0台である時間帯に立ち往生が発生した事例(No.7, No.10)と、道路管理者が交通に支障がないと判断し、整理を行った事例(No.28, No.40, No.41)の計5事例については、集計対象から除外した。モデルの中で最も事前にアラートを発報することが出来ていたモデルは、モデル6であり、56事例に対して38事例(67.9%)でアラート発信をすることが出来ている。次いでモデル1、モデル13が56事例に対して37事例(66.1%)、モデル11が56事例に対して36事例(64.3%)でアラート発報をすることが出来ている。

なお、モデル別の事例毎の異常事象発生直前のアラートの状況の詳細については、Appendix4に整理する。




図4-12 モデル別の異常事象発生直前のアラート事例数

表4-7 モデル別の異常事象発生直前のアラート事例数の一覧

モデル	事象発生前にアラート出来た事例数	評価事例数	事象発生前にアラート出来た事例数の割合	(参考:全 61 事例)		
				事象発生前にアラート出来た事例数	事例数	事象発生前にアラート出来た事例数の割合
1	37	56	66.1%	39	61	63.9%
2	28	56	50.0%	30	61	49.2%
3	35	56	62.5%	37	61	60.7%
4	35	56	62.5%	38	61	62.3%
5	34	56	60.7%	36	61	59.0%
6	38	56	67.9%	39	61	63.9%
7	35	56	62.5%	36	61	59.0%
8	31	56	55.4%	35	61	57.4%
9	31	56	55.4%	33	61	54.1%
10	27	56	48.2%	29	61	47.5%
11	36	56	64.3%	37	61	60.7%
12	27	56	48.2%	29	61	47.5%
13	37	56	66.7%	37	61	60.7%

(3) アラート発報(レベル2)と立ち往生発生直後の状況の関係

図4-13及び表4-8は、4-3-2(3)に整理した方法に従い、事例別、モデル別に、異常事象発生直後(2h)のアラート発報($Alert_t = 2, Alert_{t+1} = 2$)の有無を確認した。尚、先ほどと同様に、61事例の内、プローブ台数が0台である時間帯に立ち往生が発生した事例(No.7, No.10)と、道路管理者が交通に支障がないと判断し整理を行った事例(No.28, No.40, No.41)の計5事例については、集計対象から除外している。モデルの中で最も異常事象発生直後にアラートを発報することが出来ていたモデルは、モデル13であり、56事例に対して29事例(51.8%)でアラート発信をすることが出来ている。

なお、モデル別の事例毎の異常事象発生直後のアラートの状況の詳細については、Appendix5に整理する。




図4-13 モデル別の異常事象発生直後のアラート事例数

表 4-8 モデル別の異常事象発生直後のアラート事例数の一覧

モデル	事象発生直後にアラート出来た事例数	評価事例数	事象発生直後にアラート出来た事例数の割合	(参考:全 61 事例)		
				事象発生直後にアラート出来た事例数	事例数	事象発生直後にアラート出来た事例数の割合
1	25	56	44.6%	25	61	41.0%
2	20	56	35.7%	20	61	32.8%
3	25	56	44.6%	25	61	41.0%
4	24	56	42.9%	24	61	39.3%
5	24	56	42.9%	24	61	39.3%
6	25	56	44.6%	25	61	41.0%
7	27	56	48.2%	27	61	44.3%
8	21	56	37.5%	21	61	34.4%
9	24	56	42.9%	24	61	39.3%
10	20	56	35.7%	20	61	32.8%
11	28	56	50.0%	28	61	45.9%
12	22	56	39.3%	22	61	36.1%
13	29	56	51.8%	29	61	47.5%

(4) 除雪前後の異常事象の発生危険性の変化

ここでは、除雪データを入手することができた2019年1月25日に発生した山形県国道47号の立ち往生事例(事例No.60)を対象に、モデル別に除雪前後の異常事象の危険性の変化評価を行った。図4-14及び表4-9は、モデル別に除雪前後のKL距離とその比を示したものである。除雪前のKL値と比較して、除雪後のKL値の比率が最も小さくなっているモデルはモデル13(除雪前と比較してKL値が29%減)であり、除雪によって道路の走行性能が回復するという変化をとらえることが出来ている。反対にモデル1, 3, 4, 5, 6は除雪後に異常事象の発生危険性が高くなっており、除雪後に異常事象の発生危険性が高くなるという結果となっており、妥当な結果ではないと考えられる。除雪状況とKL距離の時空間の関係は、図5-3で整理している。




図4-14 モデル別の除雪前後KL距離とKL距離比

表 4-9 モデル別の除雪前後の KL 距離の比較結果一覧

モデル番号	除雪前 KL 距離合計	除雪後 KL 距離合計	除雪前後 KL 比
1	2142.1	2721.4	127%
2	2455.1	2022.1	82%
3	2237.7	2325.2	104%
4	1965.8	2324.3	118%
5	1701.9	2172.5	128%
6	1534.1	1729.8	113%
7	2254.9	1760.8	78%
8	2208.6	1757.7	80%
9	1921.1	1504.4	78%
10	2441.5	1831.4	75%
11	1714.4	1321.0	77%
12	1744.2	1368.3	78%
13	1597.3	1140.6	71%

4-5 モデル選択結果

本研究では、リアルタイムの道路の走行性能を推定する状態空間モデル構造の候補として表 3-2 に示す 13 の候補を構築した。本章では、13 のモデル候補全てを用いて、実際に立ち往生が発生した事例のデータで異常事象の発生危険性の評価を行い、4-3-2 で示した方法により結果の妥当性を評価した。

本研究では、提案した 13 のモデルの中で最も客観的な事実を説明できるモデルが良いモデルとして、モデル選択を行う。

表 4-10 は、モデル別の妥当性の評価結果をまとめたものである。表 4-10 を見ると、複数のモデル候補の中でも、モデル 13 が誤発報が少なく(全モデル中、2 位(98.1%))、異常事象の見逃しが少ない(アラートレベル 1 の場合 2 位、アラートレベル 2 の場合 1 位)。また、除雪後に道路の性能が回復するという変化をとらえることが出来ている(1 位(71%))。

以上より、本論文では、モデル 13 が提案モデルの中で、優れていると判断し、以降はモデル 13 による結果を整理する。また、参考として算出した本論文の分析対象のデータを用いた各モデルの AIC、平均二乗誤差については、Appendix 6 に整理する。

表 4-10 モデル別の評価結果

No	システムモデル (状態ベクトル)	特異度	発生前 アラート $Alert_t = 1$	発生後 アラート $Alert_t = 2$	除雪前後
①	ローカルレベルモデル (レベル)	97.0%	66.1% (2位)	44.6%	127%
②	周期成分モデル (レベル+ 周期)	94.6%	50.0%	35.7%	82%
③	回帰成分モデル (レベル+ 降雪量回帰)	97.8%	62.5%	44.6%	104%
④	回帰成分モデル (レベル+ 気温回帰)	97.5%	62.5%	42.9%	118%
⑤	回帰成分モデル (レベル+ プローブ台数回帰)	97.0%	60.7%	42.9%	128%
⑥	回帰成分モデル (レベル+ プローブ台数回帰+降雪量回帰+気温 回帰)	97.5%	67.9% (1位)	44.6%	113%
⑦	周期成分回帰成分モデル (レベル+ 周期+降雪量回帰)	98.1% (1位)	62.5%	48.2% (3位)	78%
⑧	周期成分回帰成分モデル (レベル+ 周期+気温回帰)	97.6%	55.4%	37.5%	80%
⑨	周期成分回帰成分モデル (レベル+ 周期+プローブ台数回帰)	97.5%	55.4%	42.9%	78%
⑩	周期成分回帰成分モデル (レベル+ 周期+プローブ台数回帰：実測)	97.5%	48.2%	35.7%	75% (2位)
⑪	周期成分回帰成分モデル (レベル+ 周期+プローブ台数回帰+降雪量回 帰成分)	97.9% (2位)	64.3% (3位)	50.0% (2位)	77% (3位)
⑫	周期成分回帰成分モデル (レベル+ 周期+プローブ台数回帰+気温回帰 成分)	97.6%	48.2%	39.3%	78%
⑬	周期成分回帰成分モデル (レベル+ 周期+プローブ台数回帰+降雪量回帰 +気温回帰)	97.9% (2位)	66.1% (2位)	151.8% (1位)	71% (1位)

4-5-1 気象条件と異常事象に関する知見との整合

ここでは、選択したモデル13による異常事象の発生危険性の評価結果が、2-2-2で整理したような異常事象に関する既往の知見(以下)と整合が取れているかについて確認を行う。

- ①路面が凍結していると、タイヤの滑り摩擦係数が低くなり、車両の性能が落ちるため異常事象が発生しやすい
- ②路面の積雪が多いと、雪に車両が乗り上げることや、タイヤの滑り摩擦係数が低くなるために、異常事象が発生しやすい
- ③0°C付近は凍結と融解を繰り返すため、氷面積が増大したり、雪がぬかるんだりすることにより、タイヤの滑り摩擦係数が低くなり、異常事象が発生しやすい

図 4-15は、気温と6時間降雪量の2変数を軸にとり、気象条件別にモデル13による異常事象の発生危険性 ($Alert_t = 1$)のアラート割合を示したものである。6時間降雪量が多いほど、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度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、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(道路の走行性能の低下)を認識することで、アラート発信がなされていると考えられる。これらの結果は、2-2-2冬季道路交通における異常事象の発生メカニズムに関する研究で整理した知見と整合が取れる結果となっている。

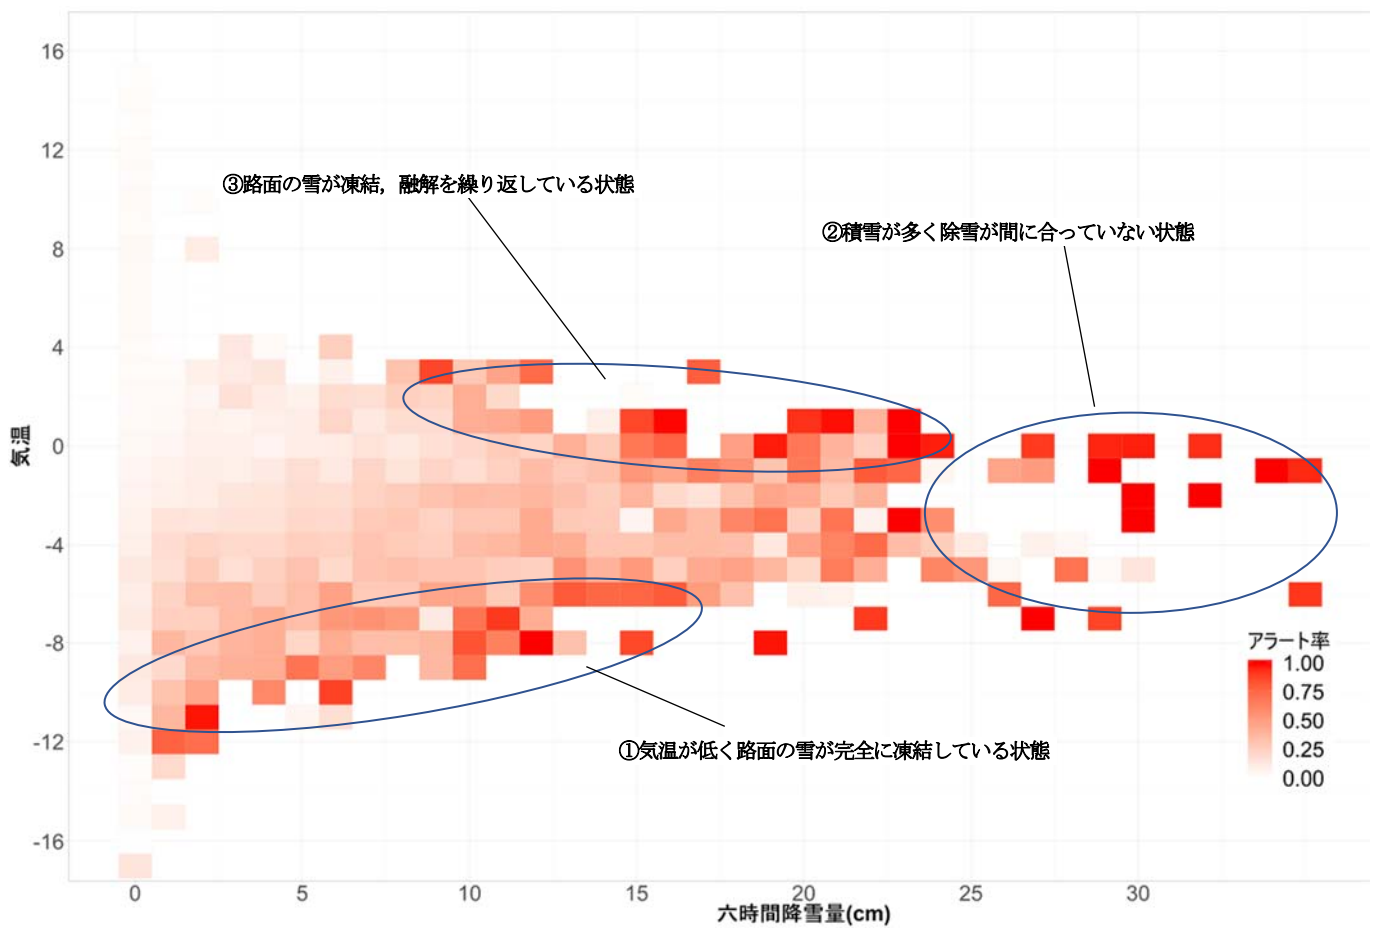


図 4-15 気象条件別のアラート率

4-6 手法の有効性の確認

ここでは、選択したモデルによる異常事象の危険性評価結果と、観測値を確定的に扱い異常事象の危険性を評価した結果を比較することで提案手法の有効性について確認する。

図4-16は、選択したモデル13により算出した特異度と観測値を確定的に取り扱った場合(85パーセンタイル速度と平均速度)の特異度を事例別に比較したものである。なお、特異度は、災害が発生していない平常期間で評価を行っているため、事例の除外条件(立ち往生発生時にプローブが存在しない、立ち往生時に交通流への影響がない)に関わらず算出が可能であるため全事例が対象計算を行っている。

全ての事例で、モデル13は、観測値を確定的に扱った場合よりも特異度は高い値を示している。空間平均速度を用いて、アラートした場合の特異度は、低い値を取ることが多い。この結果から、観測値を確定的に取り扱くと、特に空間平均速度の場合、誤発報が多発する。85パーセンタイル値に着目することにより、誤発報の発生を抑制することが出来ているが、状態空間モデルを用いることによって、さらに誤発報の発生を抑制できている。提案手法は状態空間モデルを用いており、モデルと観測値の両方に確率的な誤差を仮定しているため、状態推定の際に、突発的な観測値の変化(外れ値)がスムージングされたことにより誤発報を減らすことが出来ていると推察できる。




図4-16 事例別の特異度の比較

4-7 結果のまとめと考察

4-7-1 結果のまとめ

本章では、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、提案手法による異常事象の発生危険性の評価結果について5つの視点でその妥当性の評価を行った。

モデル候補別に評価結果を比較し、最も客観的な事実を説明できるモデルとしてモデル13を選択した。

また、選択したモデル13による異常事象の危険性の評価結果が異常事象に関する既往の知見と概ね整合することを確認した。

提案手法の有効性を確認するために、観測値を確定的に取り扱った場合と提案手法による誤発報の程度の比較を行った結果、提案手法は観測値を確定的に取り扱った場合よりも大幅に誤発報を抑制出来ることを確認した。

4-7-2 考察

提案手法の特異度は、98%以上と高い精度が確認できたが、100%とはならなかった。

本研究は85パーセントイル速度に着目すること、状態空間モデルを用いるという2つの工夫によって、出来るだけノイズや外乱を除外することを試みたが、気象条件が良好(2℃以上かつ積雪がない状況)の中に、プローブ車両が速度を大きく落とす場面(eg.事故、故障車、渋滞等)が含まれていた(除外しきれっていない)可能性があることが誤発報を生む原因の一つと考えられる。他の事例と比較して、検証対象範囲が都市部で比較的交通量や外乱が多い、福井の事例でその傾向が強いことがこのことを裏付けている。

次に、アラート発信の中に、異常事象発生前の状況及び異常事象発生後の状況が100%含まれていなかった理由について考察する。

図 4-17は、モデル13による立ち往生規模別の異常事象発生直前のアラートの内訳、図 4-18は、モデル13による立ち往生規模別の異常事象発生直後のアラートの内訳を示したものである。図 4-17を見ると立ち往生の規模規模が小さい(一部車線閉塞や片側交互通行)場合は、アラートの割合が低いことが分かる。図 4-18も同様であるが、通行止めとなった事象でもアラートの割合が低いことが分かる。

この結果から提案手法は、立ち往生の規模が小さく交通流に影響を与えていない事象については見逃しが増加する傾向にあることが分かる。また、立ち往生発生後に通行止めとなり、プローブが観測されない場合もアラート発信がされない傾向にある。ただし、通行止めは既に道路管理者が対応できているということでもあるため、大きな問題にはならないと考えられる。そのほかにも影響を与える要因があるが、まとめて、6-2で考察を行う。




図4-17 モデル13による立ち往生規模別の異常事象発生直前のアラート内訳




図4-18 モデル13による立ち往生規模別の異常事象発生直後のアラート内訳

4章の参考文献

- 1) 本田技研工業株式会社HP : <https://www.honda.co.jp/internavi/>
- 2) データ指向型モビリティ情報生成支援生成グループDOMINGOHP:<http://www.cps-project.sakura.ne.jp/domingo-web/index.html>.
- 3) 気象庁HP : <https://www.data.jma.go.jp/gmd/risk/obsdl/index.php>.
- 4) 井出剛, 杉山将 : 機械学習プロフェッショナルシリーズ異常検知と変化検知, 講談社, 2017.
- 5) ダヌシカ ボレガラ, 岡崎 直観, 前原貴憲 : 機械学習プロフェッショナルシリーズウェブデータの機械学習, 講談社, 2016.
- 6) 日本疫学会 : 疫学辞典第3版, 日本公衆衛生協会, 2000.

第5章 個別事例の詳細分析

5-1 分析対象の選定

本章では、分析対象の61の事例のうち、除雪に関する情報を入手することができ、異常事象の規模が大きかった2019年1月25日に山形県国道47号で発生した立ち往生事例(No.60)と、2018年2月6日に福井県の国道8号線で発生した大規模な立ち往生事例(No.61)といった2つの規模、発生地域の異なる事例に焦点をあて、提案手法による異常事象の危険性評価結果と立ち往生発生の関係について確認する。

5-2 山形県国道 47 号における立ち往生事例

5-2-1 事例概要

2019年1月25日、山形県戸沢村の国道47号線上では、大雪のため、大型トラックなどが相次いで動けなくなり、一時200台以上が立ち往生した。国土交通省山形河川国道事務所が付近を通行止めにして午後4時ごろまでに車両を移動させ、午後5時半に通行止めを解除した。同事務所によると、立ち往生は午前11時半ごろから断続的に発生したとされている。午後2時40分から午後5時半まで、新庄市一庄内町間（約25キロ）を通行止めにして、集中的に除雪を行うなどの対応を取ったが、最長で約2キロの渋滞が発生した事例である¹⁾。

5-2-2 検証対象範囲

検証対象範囲は2019年1月25日(金)に山形県国道47号線上下り酒田市から新庄市間で発生した立ち往生の発生位置を中心に国道47号線沿いに抽出した前後30区間ずつ(約20km区間)とする。検証対象範囲として設定した区間と立ち往生発生位置を地図上に図 5-1に示す。なお、この区間は、国土交通省の除雪優先区間として設定されている区間である²⁾。また、2019年1月25日(金)に山形県国道47号線上下りでは、同時多発的に発生した4件の立ち往生が報告されており、それらの詳細は、表 5-1に整理する。検証期間は、立ち往生が発生する5日前である2019年1月20日(日)から立ち往生発生後の1月27日(日)の1週間を対象とする。

なお、検証対象範囲の基礎情報(メッシュ別標高、傾斜角度、土地利用、規制速度、交差点数)及び検証期間の気象状況(気温、降雪量、6時間前累積降雪量)、交通状況(プローブ車両平均速度、85パーセントイル速度、プローブ車両通過台数)については、Appendix7に整理する。

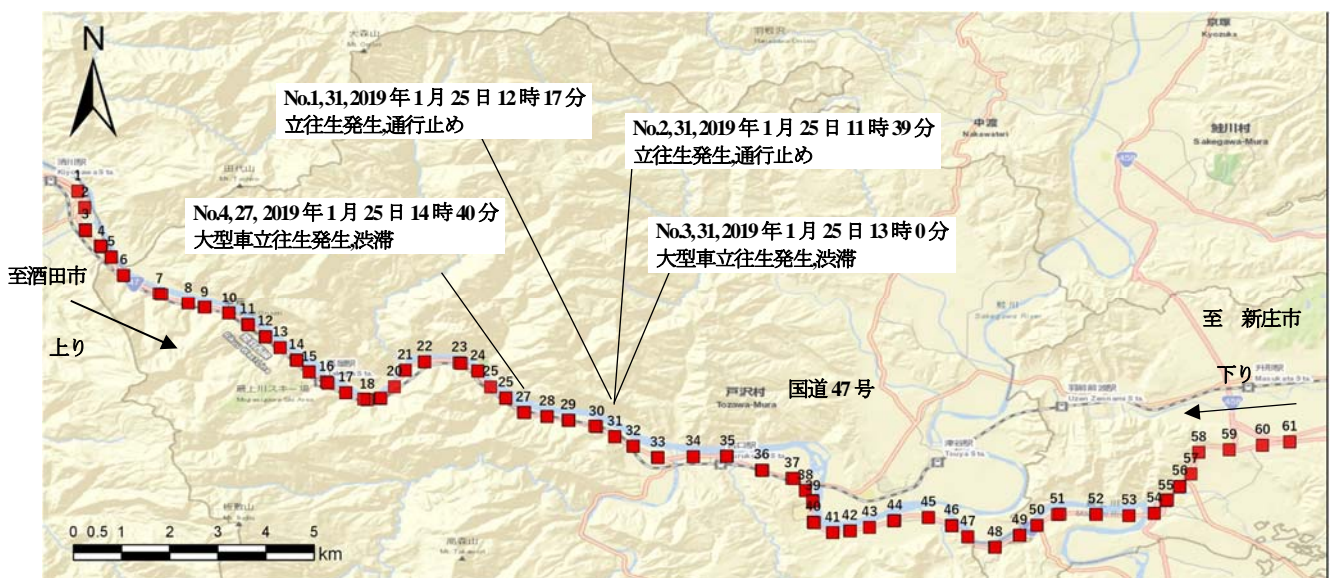


図 5-1 検証対象範囲(山形県国道 47 号)

表 5-1 山形県国道 47 号立ち往生発生内容一覧

No	位置,区間番号	検知日時	処理	災害事象の内容
1	31, 584001901	1/25 11:39	自走	大型車立ち往生発生
2	31, 584001901	1/25 12:17	牽引	大型車立ち往生発生
3	31, 584001901	1/25 13:00	牽引	大型車立ち往生発生
4	27, 584000984	1/25 14:40	牽引	セミトレーラー立ち往生発生

5-2-3 危険性評価結果の確認

(1) 路線全体の危険性評価結果(立ち往生発生時)

ここでは、モデル13による当該事例の検証期間の異常事象の発生危険性の評価結果を図5-2、図5-3に示す。

図5-2は、区間別時間帯別の異常事象の発生危険性評価結果(アラート発信状況)の時空間変化と気象条件と幾何構造の関係を示したものである。図中の黄色は異常事象がいつ発生してもおかしくない状況($Alert_t = 1$)を示しており、赤色は異常事象が発生している可能性が高い状況($Alert_t = 2$)を示している。図中には、立ち往生が発生した場所、時間を示している。また、図中の青枠は除雪車が稼働している時間と区間を示している。

立ち往生発生日の前は、1月21日、23日に異常事象の発生危険性を示すアラート発信がされている。1月21日はまとまった降雪を観測し、1月23日は-7度付近まで気温が低下していたことから、過去と比較すると凍結によって路面の状況が悪化し、道路の走行性能が低下していたと推察できる。立ち往生発生当日である1月25日は、路線の大部分で異常事象がいつ発生してもおかしくない状況($Alert_t = 1$)となっており、路線の大部分で過去よりも道路の走行性能が低下していたと考えられる。立ち往生発生箇所(No.31)に着目すると立ち往生発生直後である1月25日の12:00頃に異常事象が発生している可能性が高い状況($Alert_t = 2$)を示している。異常事象発生後の時間帯においては、上流方向に赤色が拡大していつていることから、異常事象が発生している可能性が高いことを評価出来ている。また、立ち往生発生の数時間前から異常事象がいつ発生してもおかしくない状況($Alert_t = 1$)を評価できている。また、除雪車の稼働状況との関係を見ると、除雪車が稼働している範囲は、異常事象の危険性が低い状況となっていることが定性的だが確認できる。

図5-3は、モデル13による区間別時間帯別のKL距離を示したものである。KL距離の大きさを赤色の濃淡で示している。KL距離は、立ち往生発生後に大きな値を取るようになっており、異常の発生危険性の程度を表現することが出来ている。1月25日の14:40にNo.27で立ち往生が発生しているが、この区間は、1月22日、23日、24日にもKL距離が大きな値を取っている。

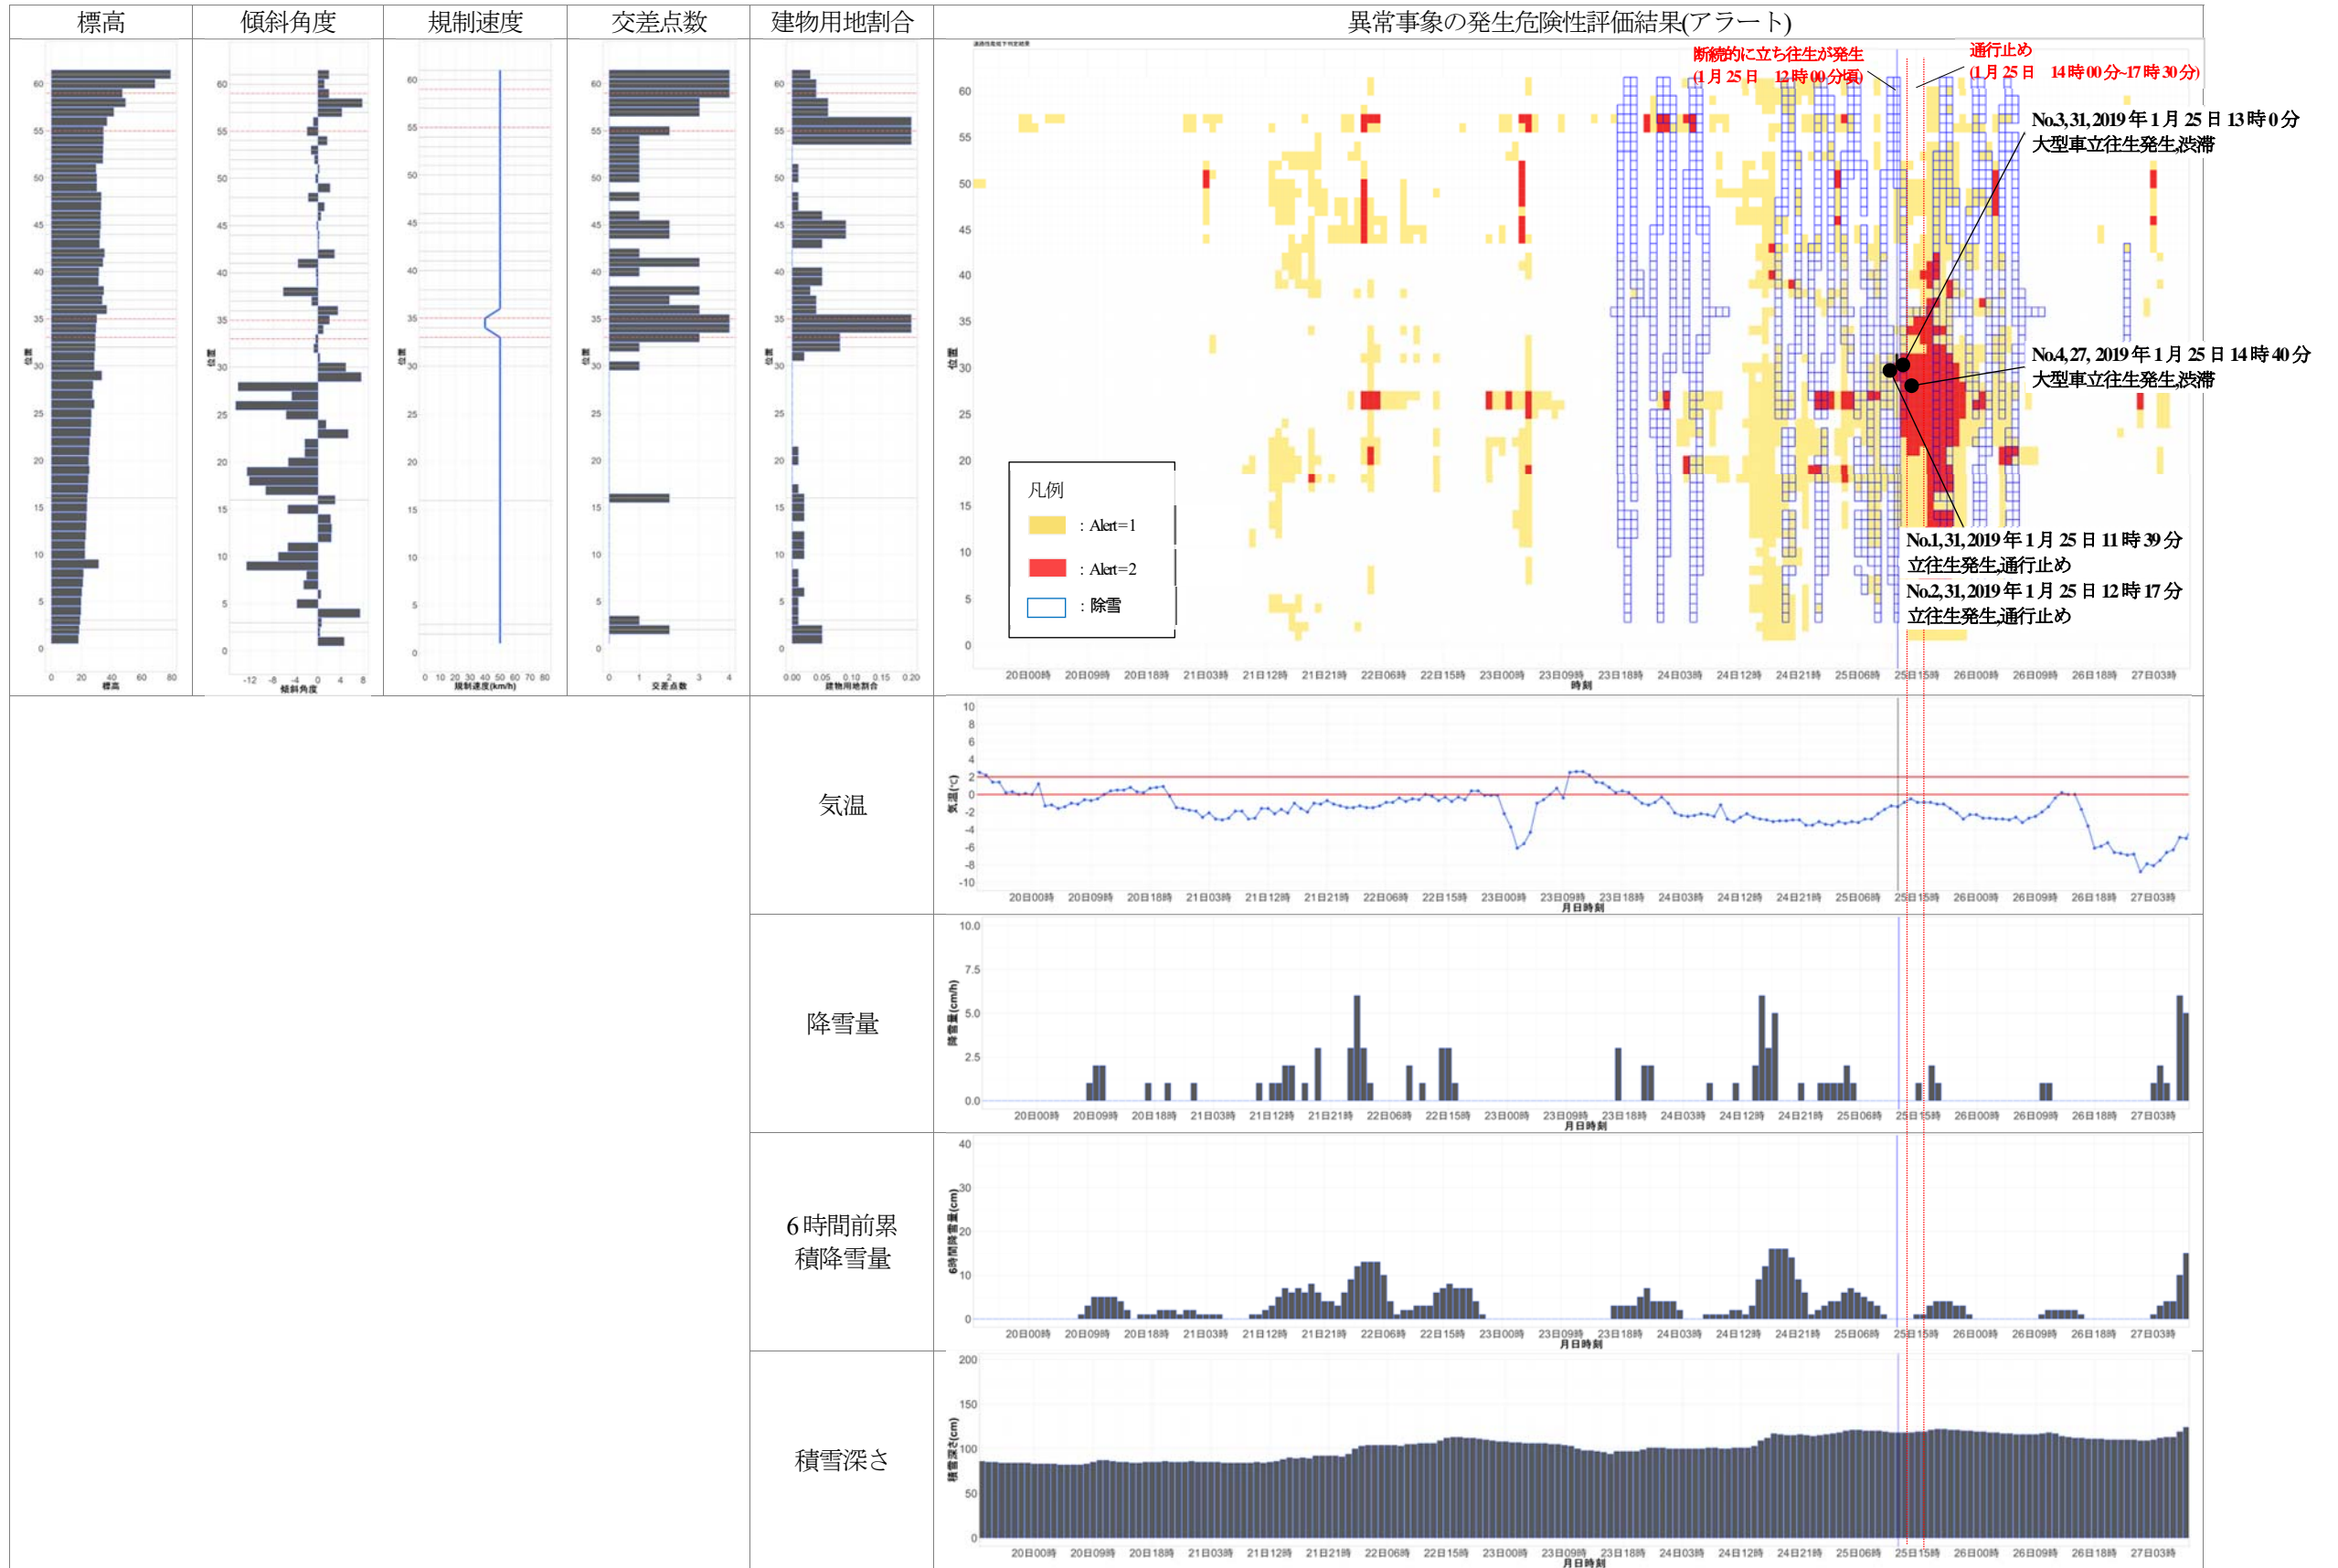


図5-2 異常事象の発生危険性評価結果(アラート)

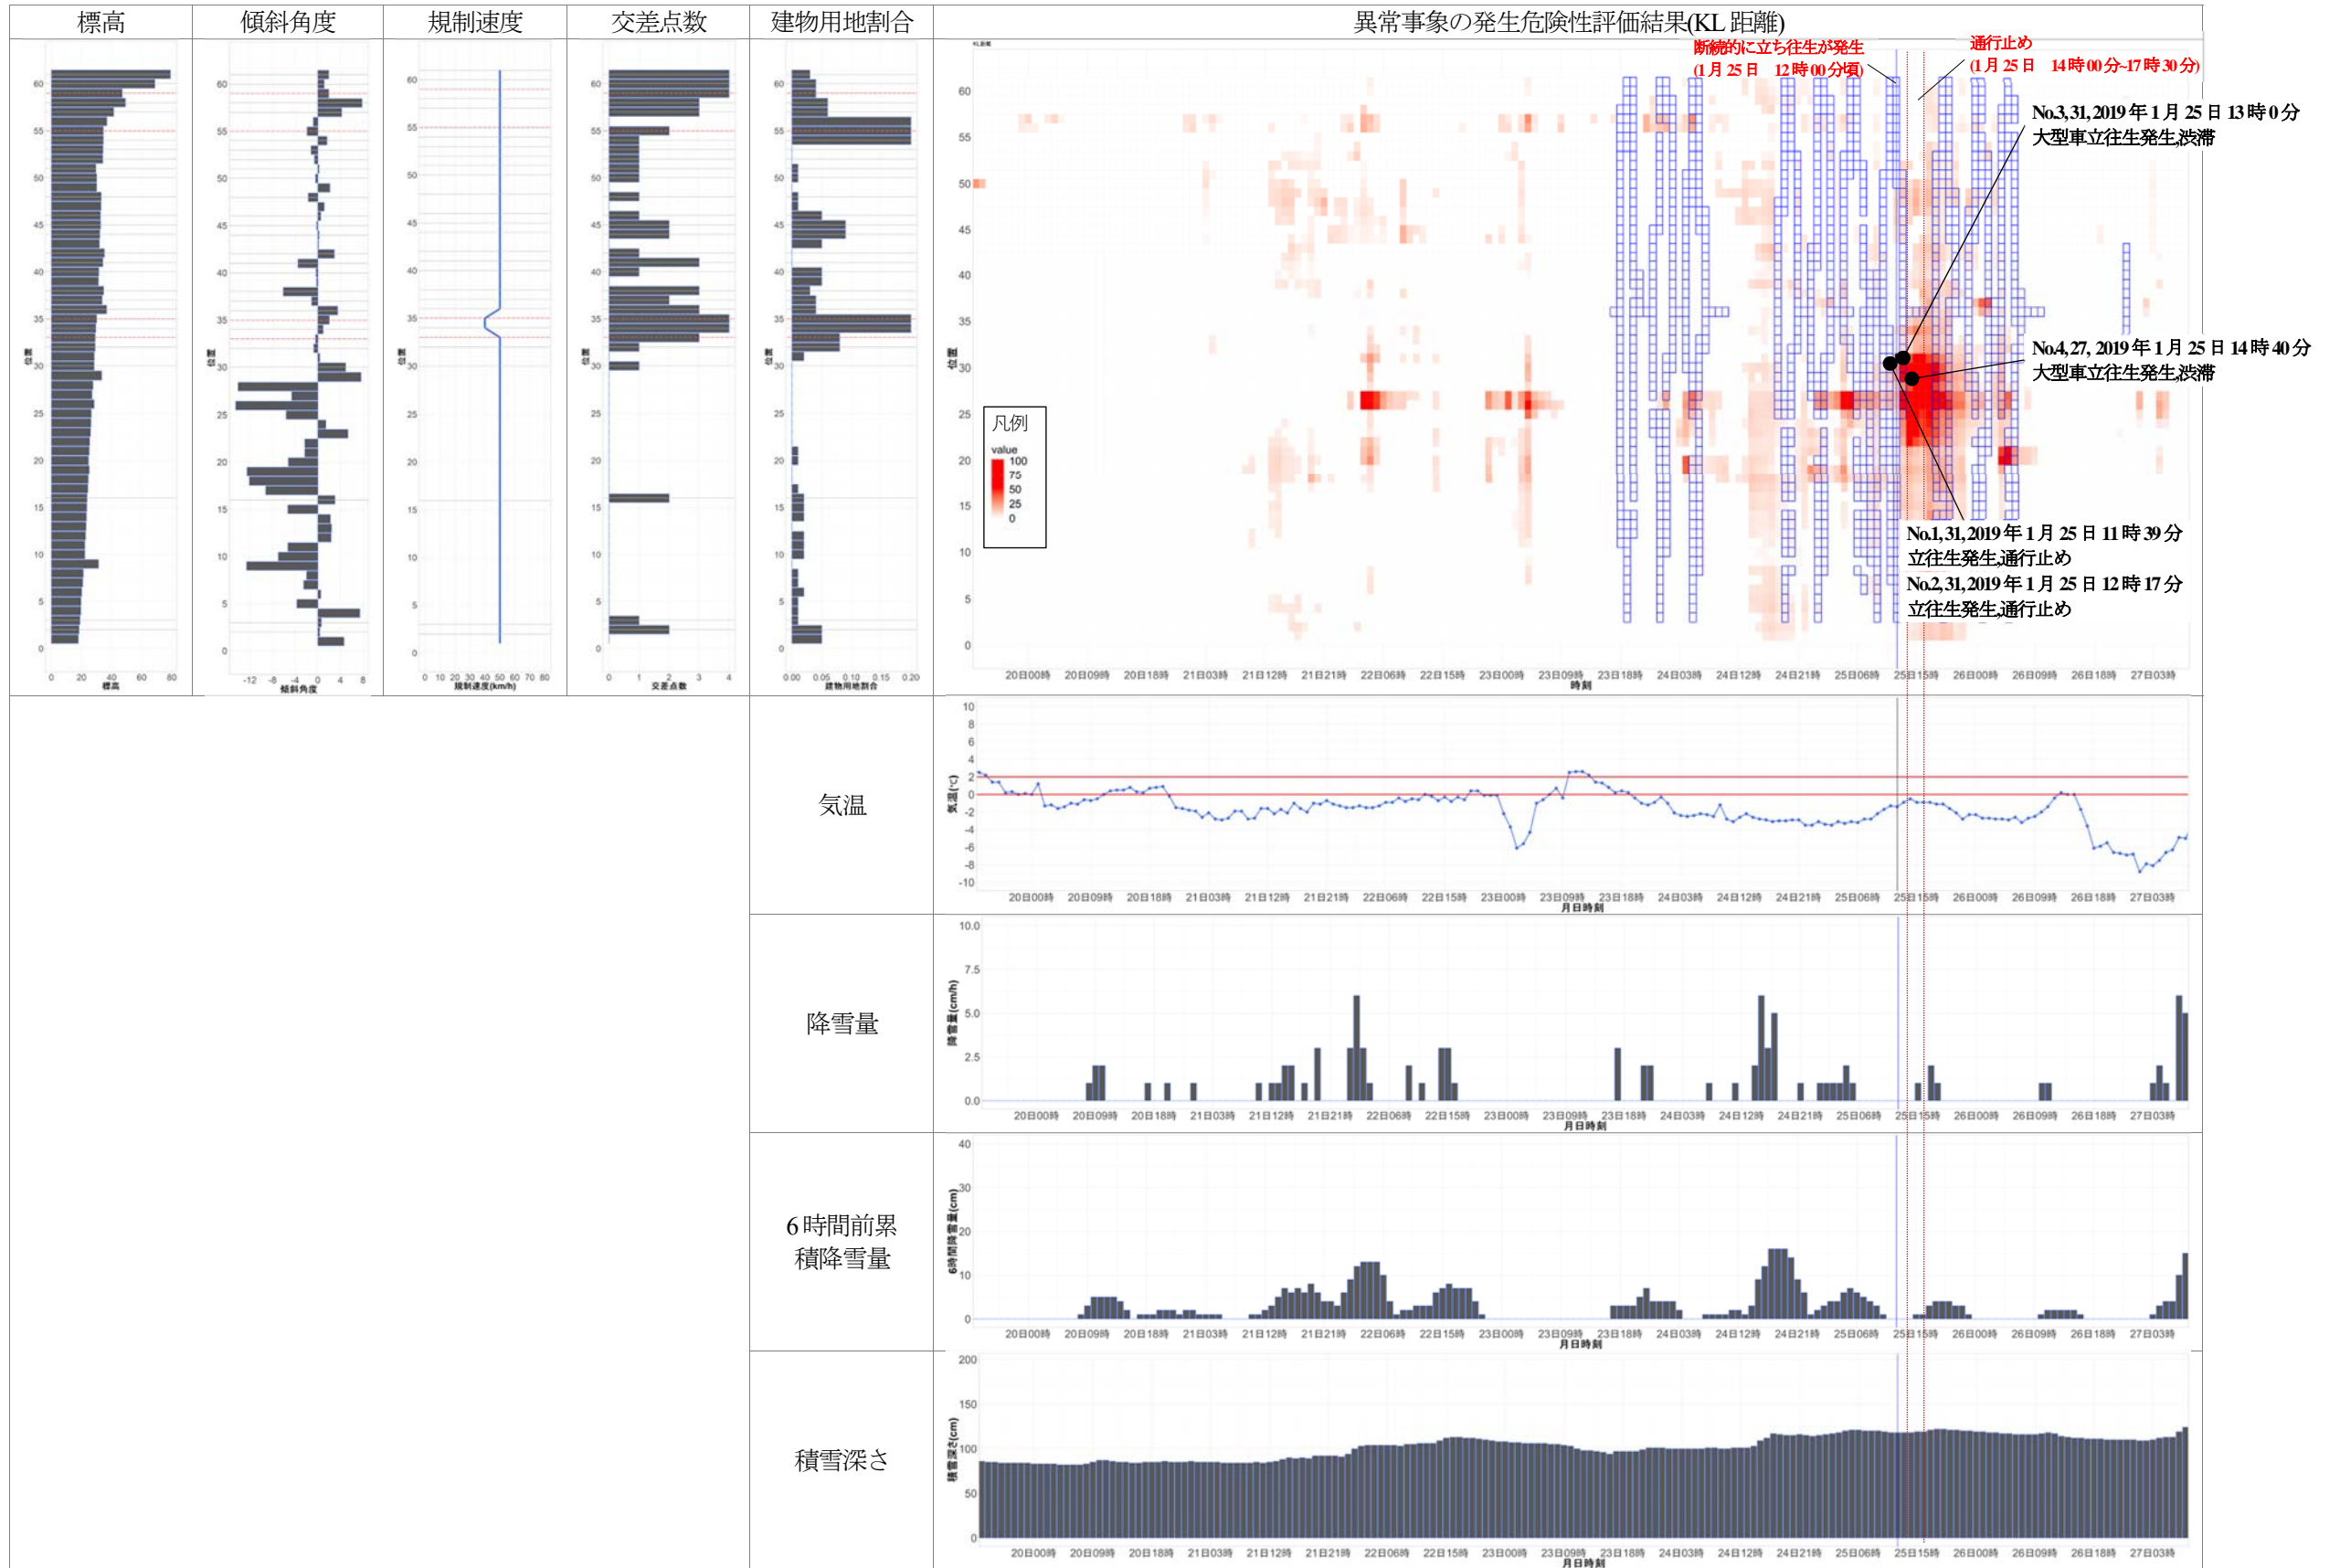


図 5-3 異常事象の発生危険性評価結果(KL距離)

(2) 区間別の危険性評価結果(立ち往生発生時)

ここでは、個別の区間に着目し、異常事象の発生危険性の評価結果と、パラメータ、状態の推定結果を整理する。整理対象は、当該事例において、最初に立ち往生が発生した区間(No.31)とする。

1) パラメータ推定結果

3-6-2項のパラメータ推定方法に従い、最初に立ち往生が発生した区間のパラメータ(システム誤差の分散、観測誤差の分散)の推定結果を整理する。表 5-2はモデルパラメータを整理したものである。観測誤差の分散は、35.51902で、レベル成分の分散が、1.595340、気温回帰係数の誤差分散が、0.00171、降雪量の回帰係数誤差の分散は1.894933e-06、プローブ台数の回帰係数の誤差の分散は、1.014779e-22、周期成分の誤算の分散が9.82207e-06と推定された。

表 5-2 山形県国道 47 号推定モデルパラメータ(No.31)

観測誤差分 散 σ_{η}	レベル成分誤差 分散 σ_{ξ}^2	降雪量回帰係数誤差 分散 σ_{ξ}^2	プローブ台数回帰係数誤 差分散 σ_{ξ}^2	気温回帰係数誤差 分散 σ_{ξ}^2	周期成分誤差 分散 σ_{ω}^2
35.51902	1.5953430	1.894933e-06	1.014779e-22	0.001713102	9.82207e-06

2) 危険性評価結果

図 5-4は、当区間の異常事象の発生危険性の評価結果を示したものである。上段が過去の道路の走行性能の分布とリアルタイムの道路の走行性能と観測値の時間変動を示した図である。灰色の帯が過去の分布を表し、濃い灰色が68%信頼区間を表し、薄い灰色が95%信頼区間を表している。赤色の帯がフィルタリング分布(リアルタイムの走行性能の分布)を表し、黒点が観測値(85パーセントイル速度)を示している。2段目の棒グラフは、KL距離の時間変化を表し、黄色が68%信頼区間を超過、赤色が95%信頼区間を超過した場合の計算結果を示している。3段目はアラートの発生状況の時間変化を示している。立ち往生が発生した1月25日12時台は、異常事象がいつ発生してもおかしくない状況($Alert_t = 1$)を示しており、13時台では、異常事象が発生している可能性が高い状況($Alert_t = 2$)を示していることから、実態にあったアラート発報がなされている。また、提案手法は、1月25日当日の朝方の時点で、異常事象がいつ発生してもおかしくない状況($Alert_t = 1$)を示していることから事前に異常事象がいつ起きてもおかしくない状況を示していたことが分かる。図 5-5は、モデルによる1期先予測と観測値とその差分(予測誤差)を図示したものである。

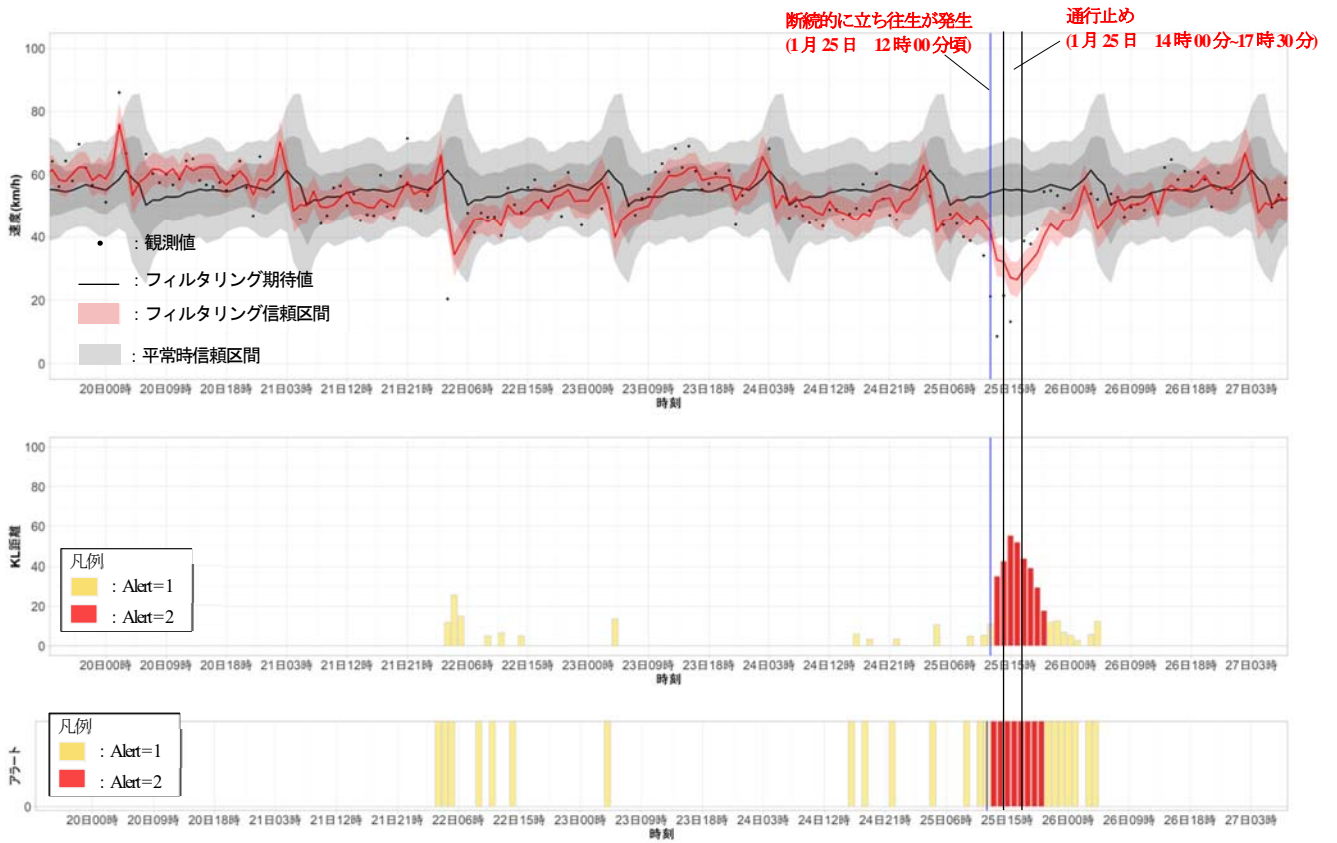


図5-4 立ち往生発生箇所における異常事象の危険性評価結果(No.31)




図5-5 予測残差の時間変動(No.31)

3) 状態推定結果

ここでは、当該区間における各変動成分の推定結果について整理する。図 5-6は、レベル成分の時間変動を示したものである。図 5-7は、周期成分の時間変動を表したものである。図 5-8は、気温と気温の回帰成分の時間変動を示したものである。気温が低いほど、速度が低くなる傾向にあり、1月23日の0時頃に最大で4km/h程度の速度低下が推定されている。図 5-9は、6時間前累積降雪量と降雪量回帰成分の時間変動を示したものである。1月24日の6時間前累積降雪量が最大となる時間帯に、降雪量の回帰成分が最大となり、最大で4km/h程度の速度低下が推定されている。図 5-10はプローブ通過台数とプローブ通過台数回帰成分の時間変動を示したものである。プローブ台数が少ないほど、速度が低く推定され、プローブ台数が多いほど、速度が高く推定される傾向にある。これは、観測量として85パーセントイル速度を用いており、プローブの通過台数が多いほど、区間をスムーズに走行した車両の速度が観測されているためと考えられる。




図 5-6 レベル成分の時間変動(No.31)




図 5-7 周期成分の時間変動(No.31)




図 5-8 気温(上)と気温回帰成分(下)の時間変動(No.31)





図5-9 6時間前累積降雪量(上)と降雪量回帰成分(下)の時間変動(No.31)





図5-10 プローブ通過台数(上)とプローブ通過台数回帰成分(下)の時間変動(No.31)

(3) 路線全体の危険性評価結果(平常時)

図 5-11は、平常期間における検証対象箇所の間別時間帯別の異常事象の発生危険性評価結果(アラート)の時空間変化と気象条件と幾何構造の関係を示したものである。また、平常期間は、データを保持している期間の中で、出来るだけ降雪が少ない2018年2月21日~2月28日の1週間を選定した。

図 5-11をみると、検証期間と比較して、アラートの発報回数は大幅に少ないものの、No.50付近で異常事象が発生している可能性が高い状況($Alert_t = 2$)を等時間間隔で発報している。アラート発報されているのは、夜中の3時頃であり、プローブ台数が平常時から常に少ない時間帯であることから、過去の分布推定精度が低いためにアラート発報をしてしまっている。区間位置5付近も同様の理由で一定間隔でアラート発報がされてしまっている。図 5-12は、平常期間における検証対象箇所の間別時間帯別のKL距離を示したものである。KL距離の大きさを赤色の濃淡で示している。検証期間と比較するとKL距離が極端に大きな値を取ることは少ない。図 5-13は、平常期間における検証対象箇所の間別時間帯別に観測値(85パーセントイル速度)を確定的に扱って、過去の道路の走行性能から乖離した場合に、異常事象の発生危険性評価を行った結果(アラート)を示したものである。図 5-11と比較すると、発報回数が多いことが分かる。

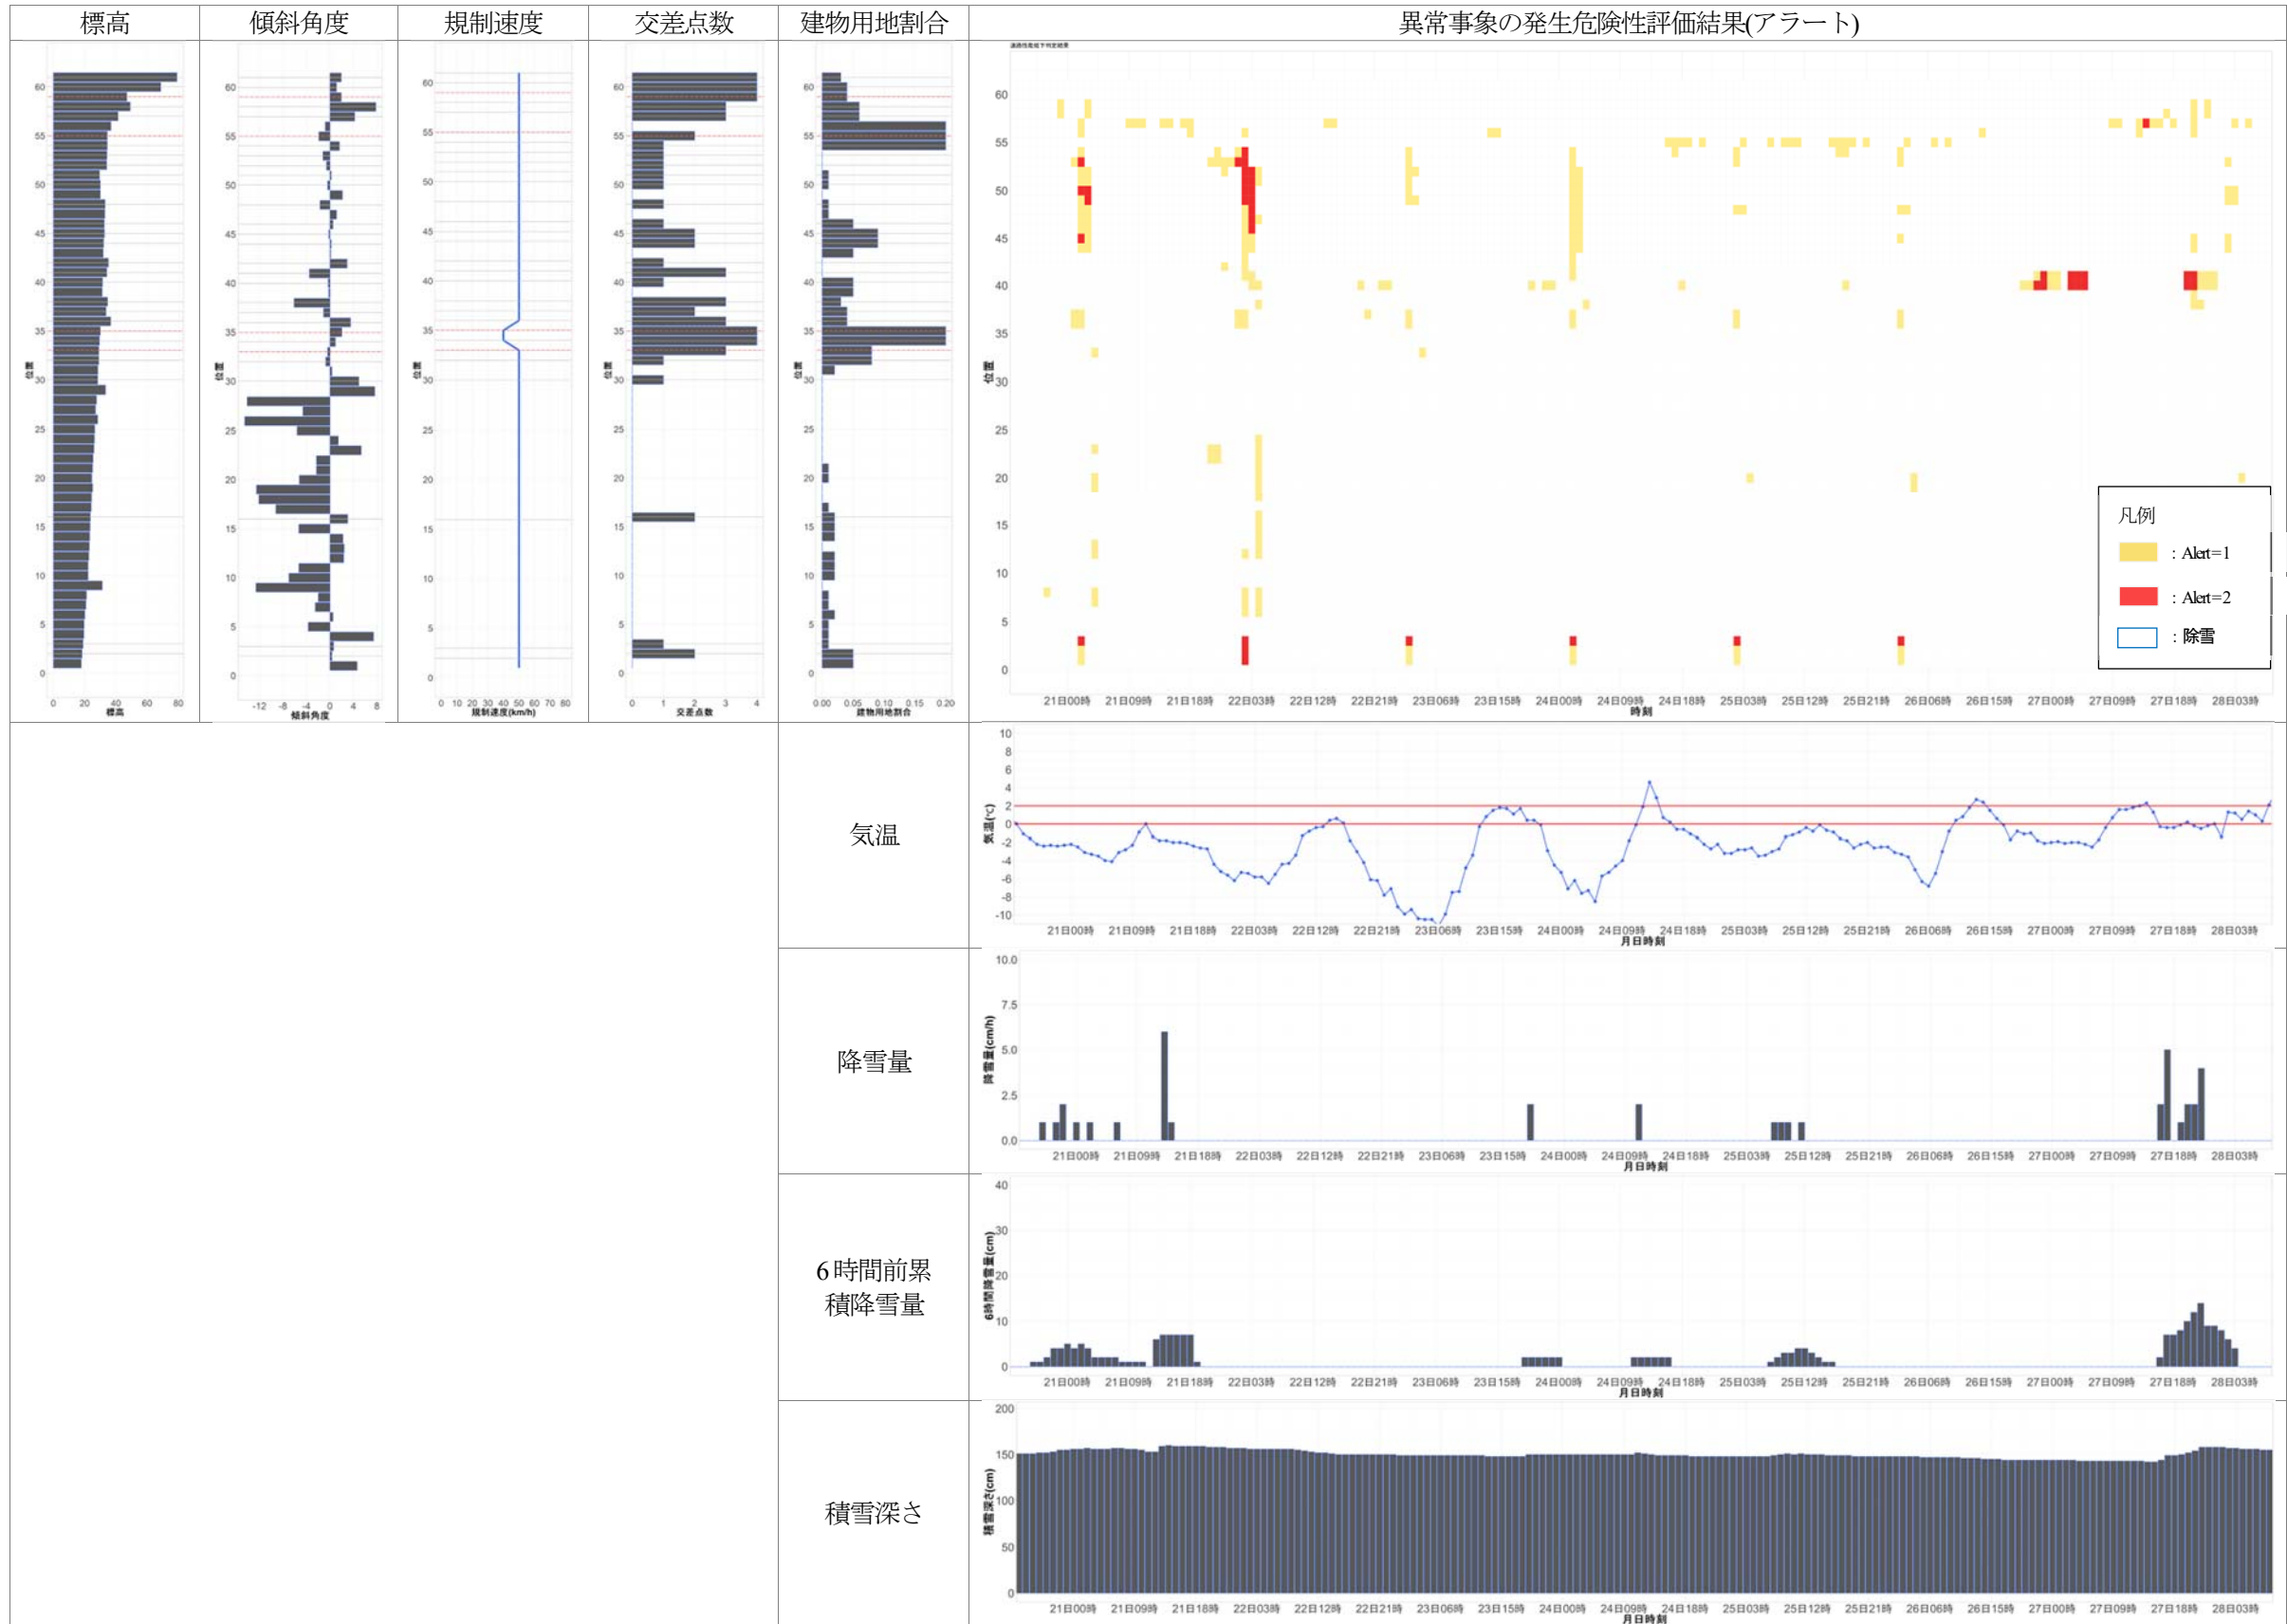


図 5-11 平常期間における異常事象の発生危険性評価結果(アラート)

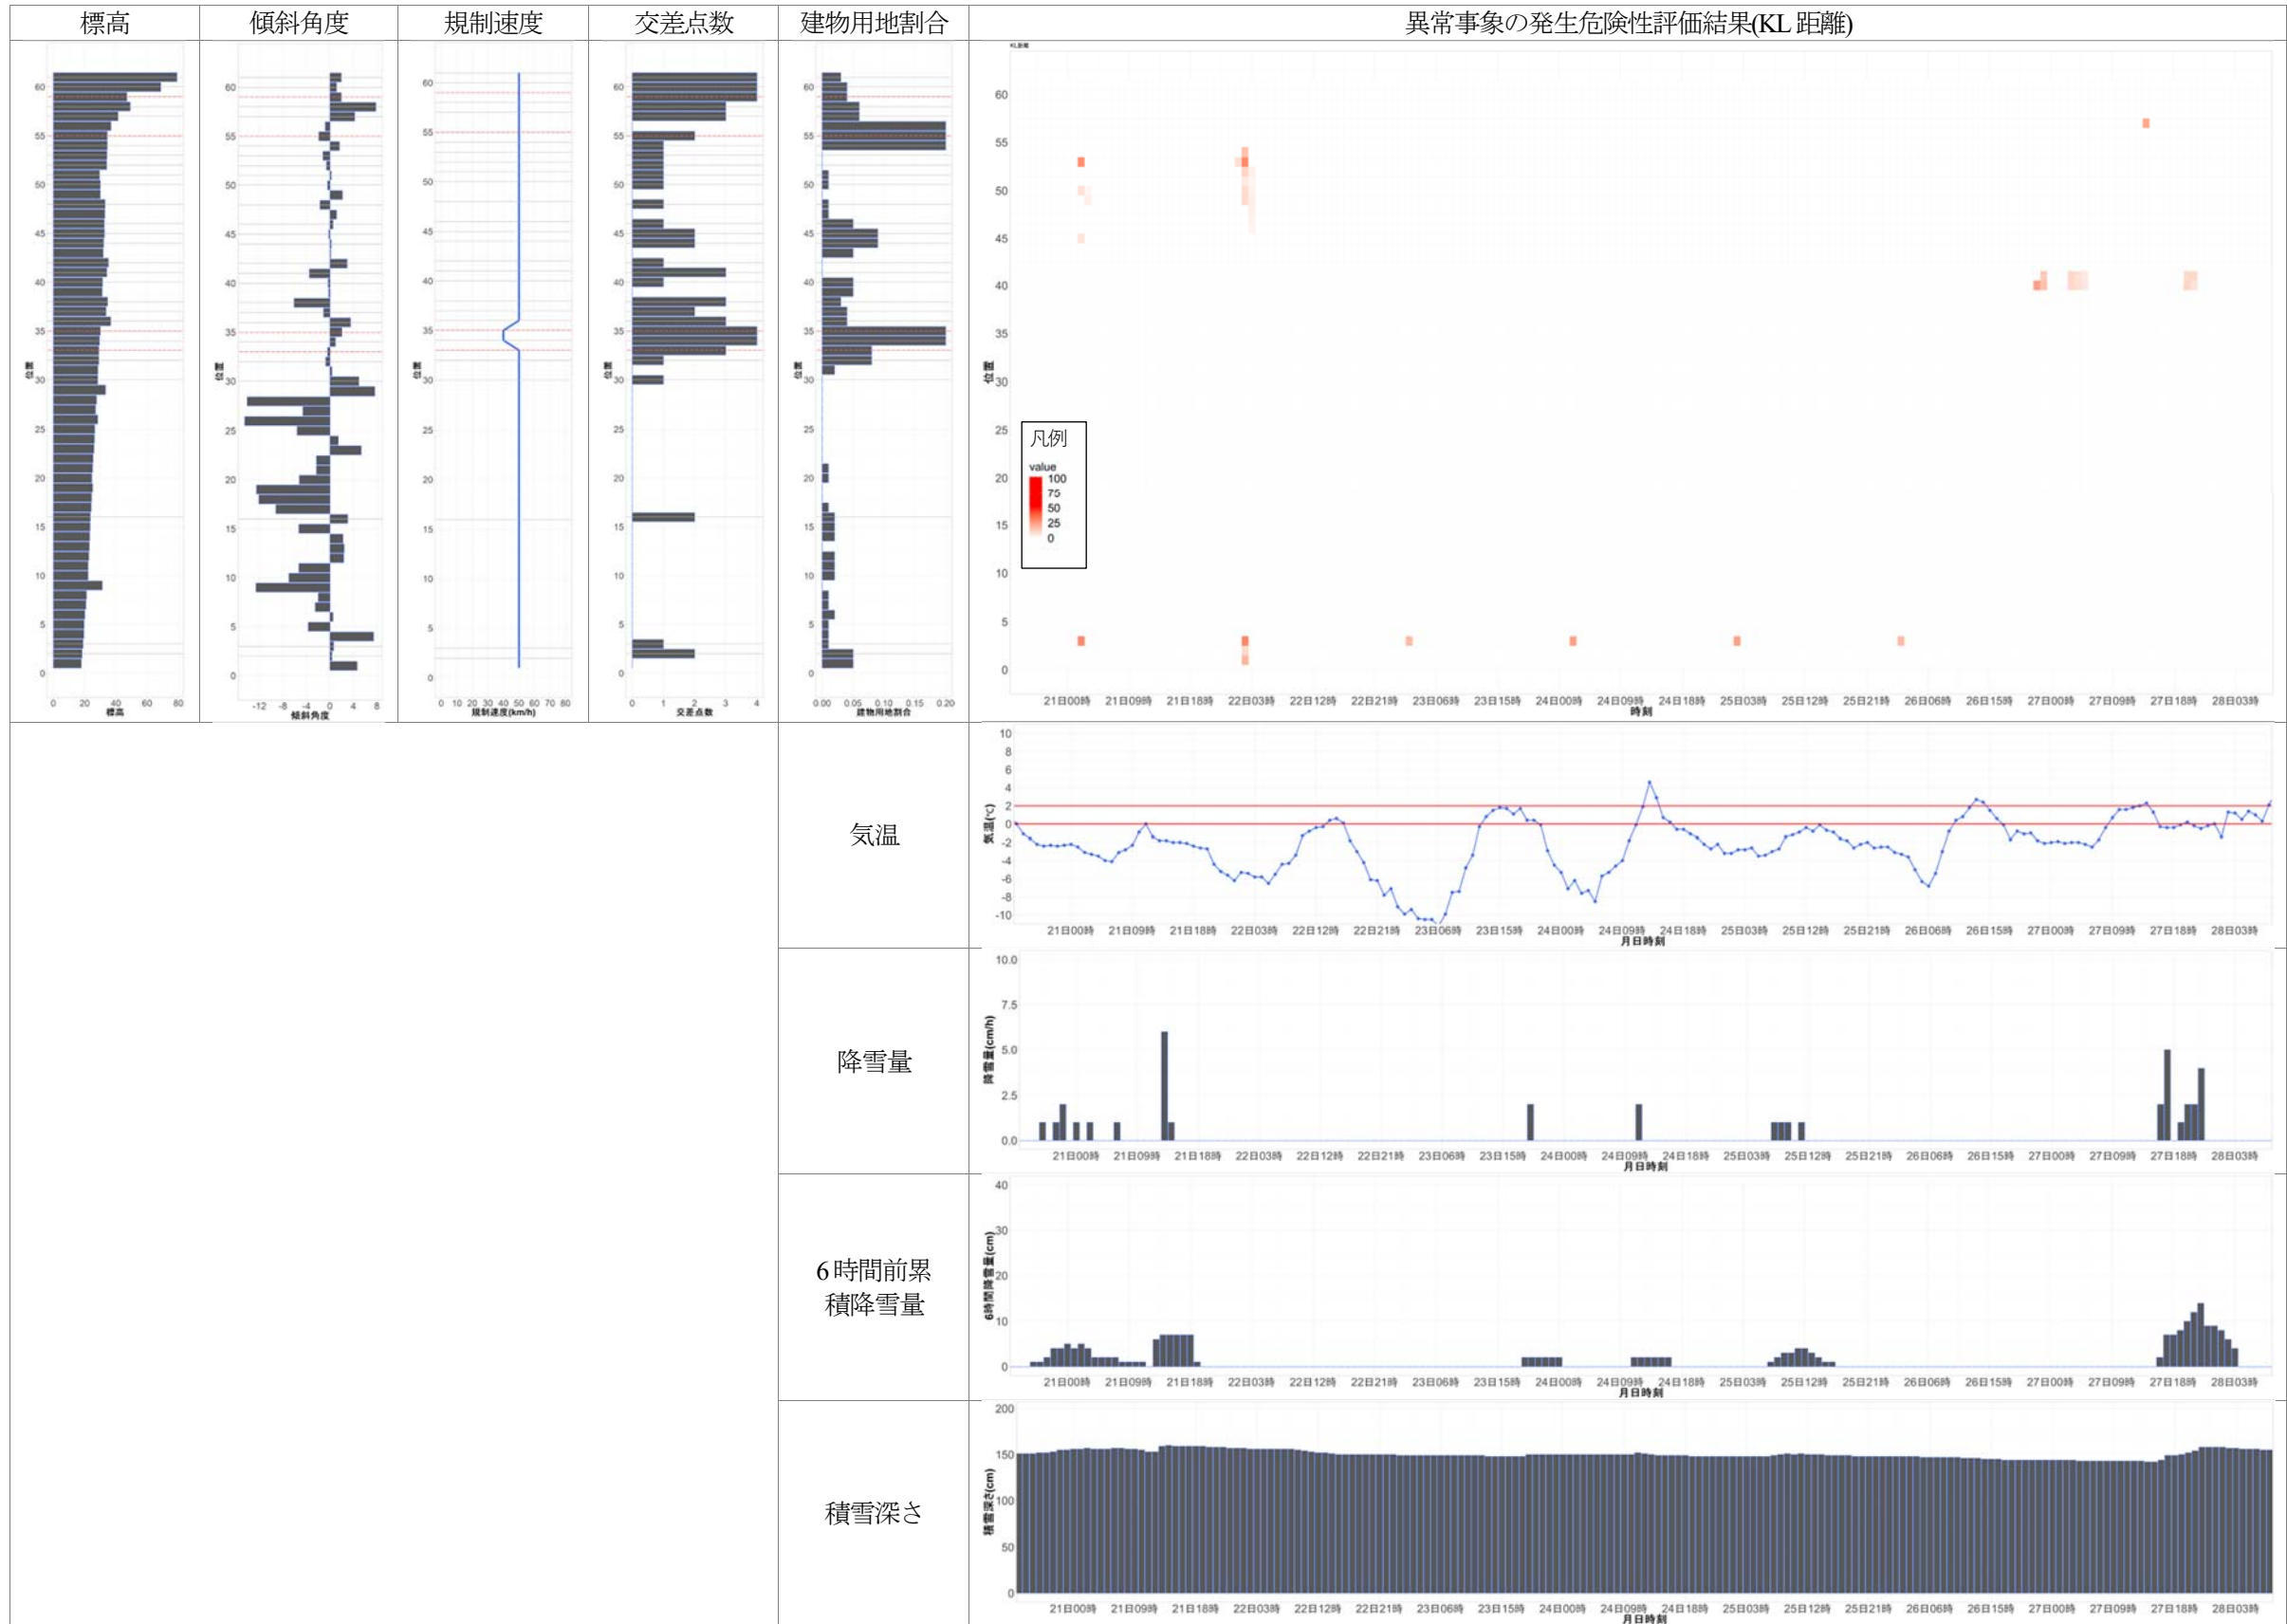


図 5-12 平常期間における異常事象の発生危険性評価結果(KL距離)

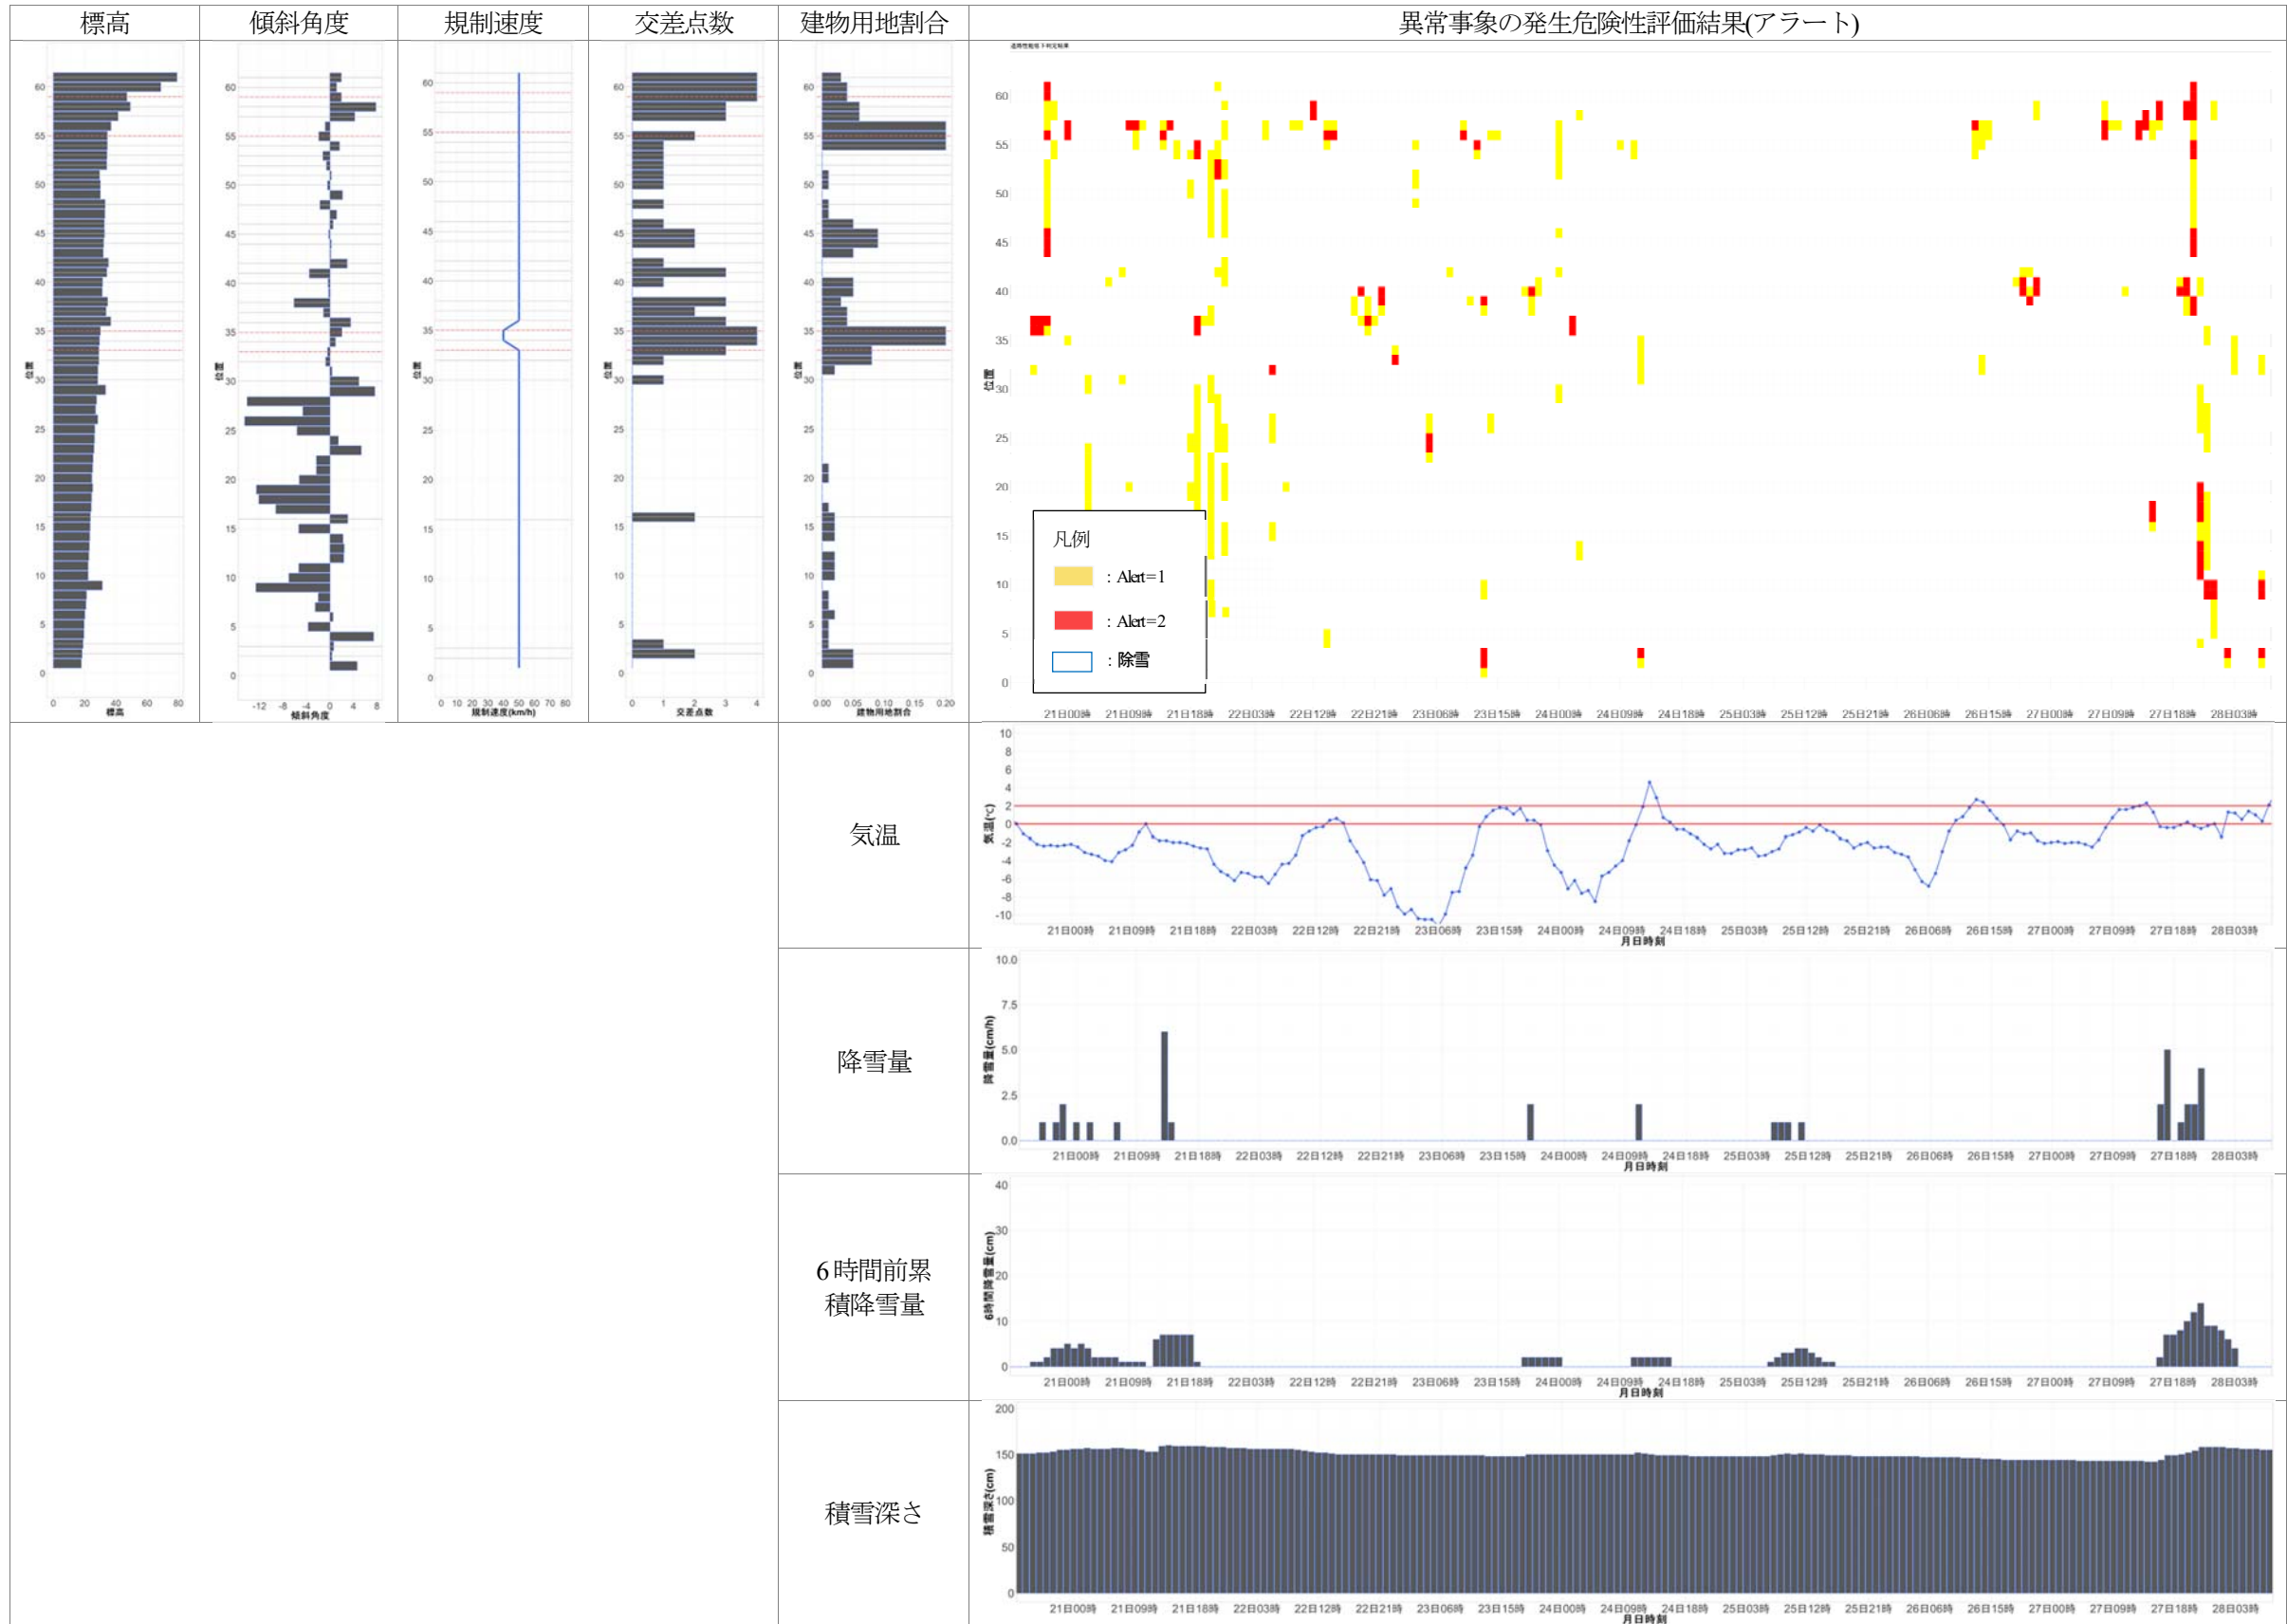


図 5-13 平常期間における異常事象の発生危険性評価結果(観測値：85パーセントイル速度)

(4) 気象と道路状況に関する一般的知見との整合確認

図 5-14は、と同様の集計方法で、当該区間における気温と6時間降雪量という気象条件別のアラート率を示したものである。この区間は、6時間降雪量が多いほど、アラート率が高くなる傾向にあり、61事例をまとめて分析したと同じ傾向を示している。①気温が低く路面の雪が完全に凍結している状態、②積雪が多く除雪が間に合っていない状態により、道路の走行性能が低下していると考えられる。図 4-15と比較すると③路面の雪が凍結、融解を繰り返している状態による道路の走行性能の低下は顕著には見られない。これはこの区間において、分析期間内に0℃以上を観測することが少ないためと考えられる。




図 5-14 気象条件別のアラート率

5-3 福井県国道8号における立ち往生事例

5-3-1 事例概要

2018年2月6日、日本列島は上空の強い寒気の影響により日本海側で大雪となった。日本海側に位置する福井県では、平年の6倍を超える積雪の深さ147cmを記録し、37年ぶりに130cmを超えた。この大雪の影響により、福井県北部の国道8号線では午前6時頃に坂井市丸岡町からあわら市熊坂の10kmの区間に渡って約1,500台の車が立ち往生が発生し、解消までは、3日間を要した。

立ち往生の規模が拡大した理由としては、国道8号線よりも先に北陸自動車道が通行止めとなり、国道8号の交通量が通常より増加したこと、チェーン未装着の大型車の立ち往生が各地で多発し、車両間に継続して積雪があり、除雪機械が入らなかったことが挙げられている³⁾。

5-3-2 検証対象範囲

図 5-15に分析対象とした区間(500m四方メッシュ)を示す。2018年2月6日(火)に国道8号線入り方向で発生した6つの立ち往生事象(表 5-3)を含む同路線上の61の区間を対象に分析, 手法の検証を行う。立ち往生事象の詳細は国土交通省近畿地方整備局の公表資料を基に整理を行った⁴⁾。最初に2月6日の0時18分に大型車が3台立て続けに立ち往生し, その後2月6日の朝まで断続的に立ち往生が発生し, 2月6日の6時頃には滞留が長時間化し, 8時半には常態化, 11時半に通行止めとなった。検証期間は, 立ち往生発生前の2018年2月1日(木)から立ち往生解消後の2018年2月8日(木)の1週間とする。

なお, 検証対象範囲の基礎情報(メッシュ別標高, 傾斜角度, 土地利用, 規制速度, 交差点数)及び検証期間の気象状況(気温, 降雪量, 6時間前累積降雪量), 交通状況(プローブ車両平均速度, 85パーセントイル速度, プローブ車両通過台数)については, Appendix8に整理する。



図 5-15 検証対象範囲(福井県国道 8 号)

表 5-3 福井県国道 8 号立ち往生発生内容一覧

No	位置,区間番号	検知日時	処理	災害事象の内容
1	31,543612402	2018/2/6 2:15	牽引	大型車立ち往生発生
2	36,543612611	2018/2/6 4:04	自走	大型車追い越し車線でチェーン装着
3	44,543622011	2018/2/6 0:18	牽引	大型車 3 台立ち往生発生
4	45,543622112	2018/2/6 0:58	牽引	セミトレーラー立ち往生発生
5	54,543622514	2018/2/6 7:18	自走	立ち往生車両への接触事故
6	54,543622514	2018/2/6 8:30	自走	車道での大型車チェーン装着

5-3-3 危険性評価結果の確認

(1) 路線全体の危険性評価結果(立ち往生発生時)

提案手法を検証対象範囲内の全区間(計 61 区間)に適用した結果を確認する。

図 5-16 は、区間別時間帯別の異常事象の発生危険性評価の時空間変化と気象条件と幾何構造の関係を示したものである。整理の方法は、山形の事例と同様である。図 5-16 を見ると、立ち往生が発生した前日 2 月 5 日時点で、路線全体が赤色を示し、異常事象が発生している可能性が高い状況($Alert_t = 2$)を示していたことがわかる。2 月 5 日はまとまった降雪を観測し、気温が低下していたことから、平常日と比較すると路面の状況が悪化し、プローブ車両の速度が低下していたと推察できる。立ち往生発生当日である 2 月 6 日は、2 月 5 日よりもさらに路線全体で赤色が目立つ。

図 5-17 は、モデル 13 による区間別時間帯別の KL 距離を示したものである。KL 距離の大きさを赤色の濃淡で示している。立ち往生の規模に合わせて赤色が濃くなっていることから、立ち往生の発生、発生後に過去の分布から乖離した値が得られていることを示している。徐々に危険性が低下していく様子も評価することが出来ている。特に最初に立ち往生が発生した No.44 付近から大きな値を取り、徐々に上流側の区間でも大きな値を取るようになっていく。その後の時間帯において、上流方向に赤色が拡大していつていることから、立ち往生の影響が拡大していることも評価できている。

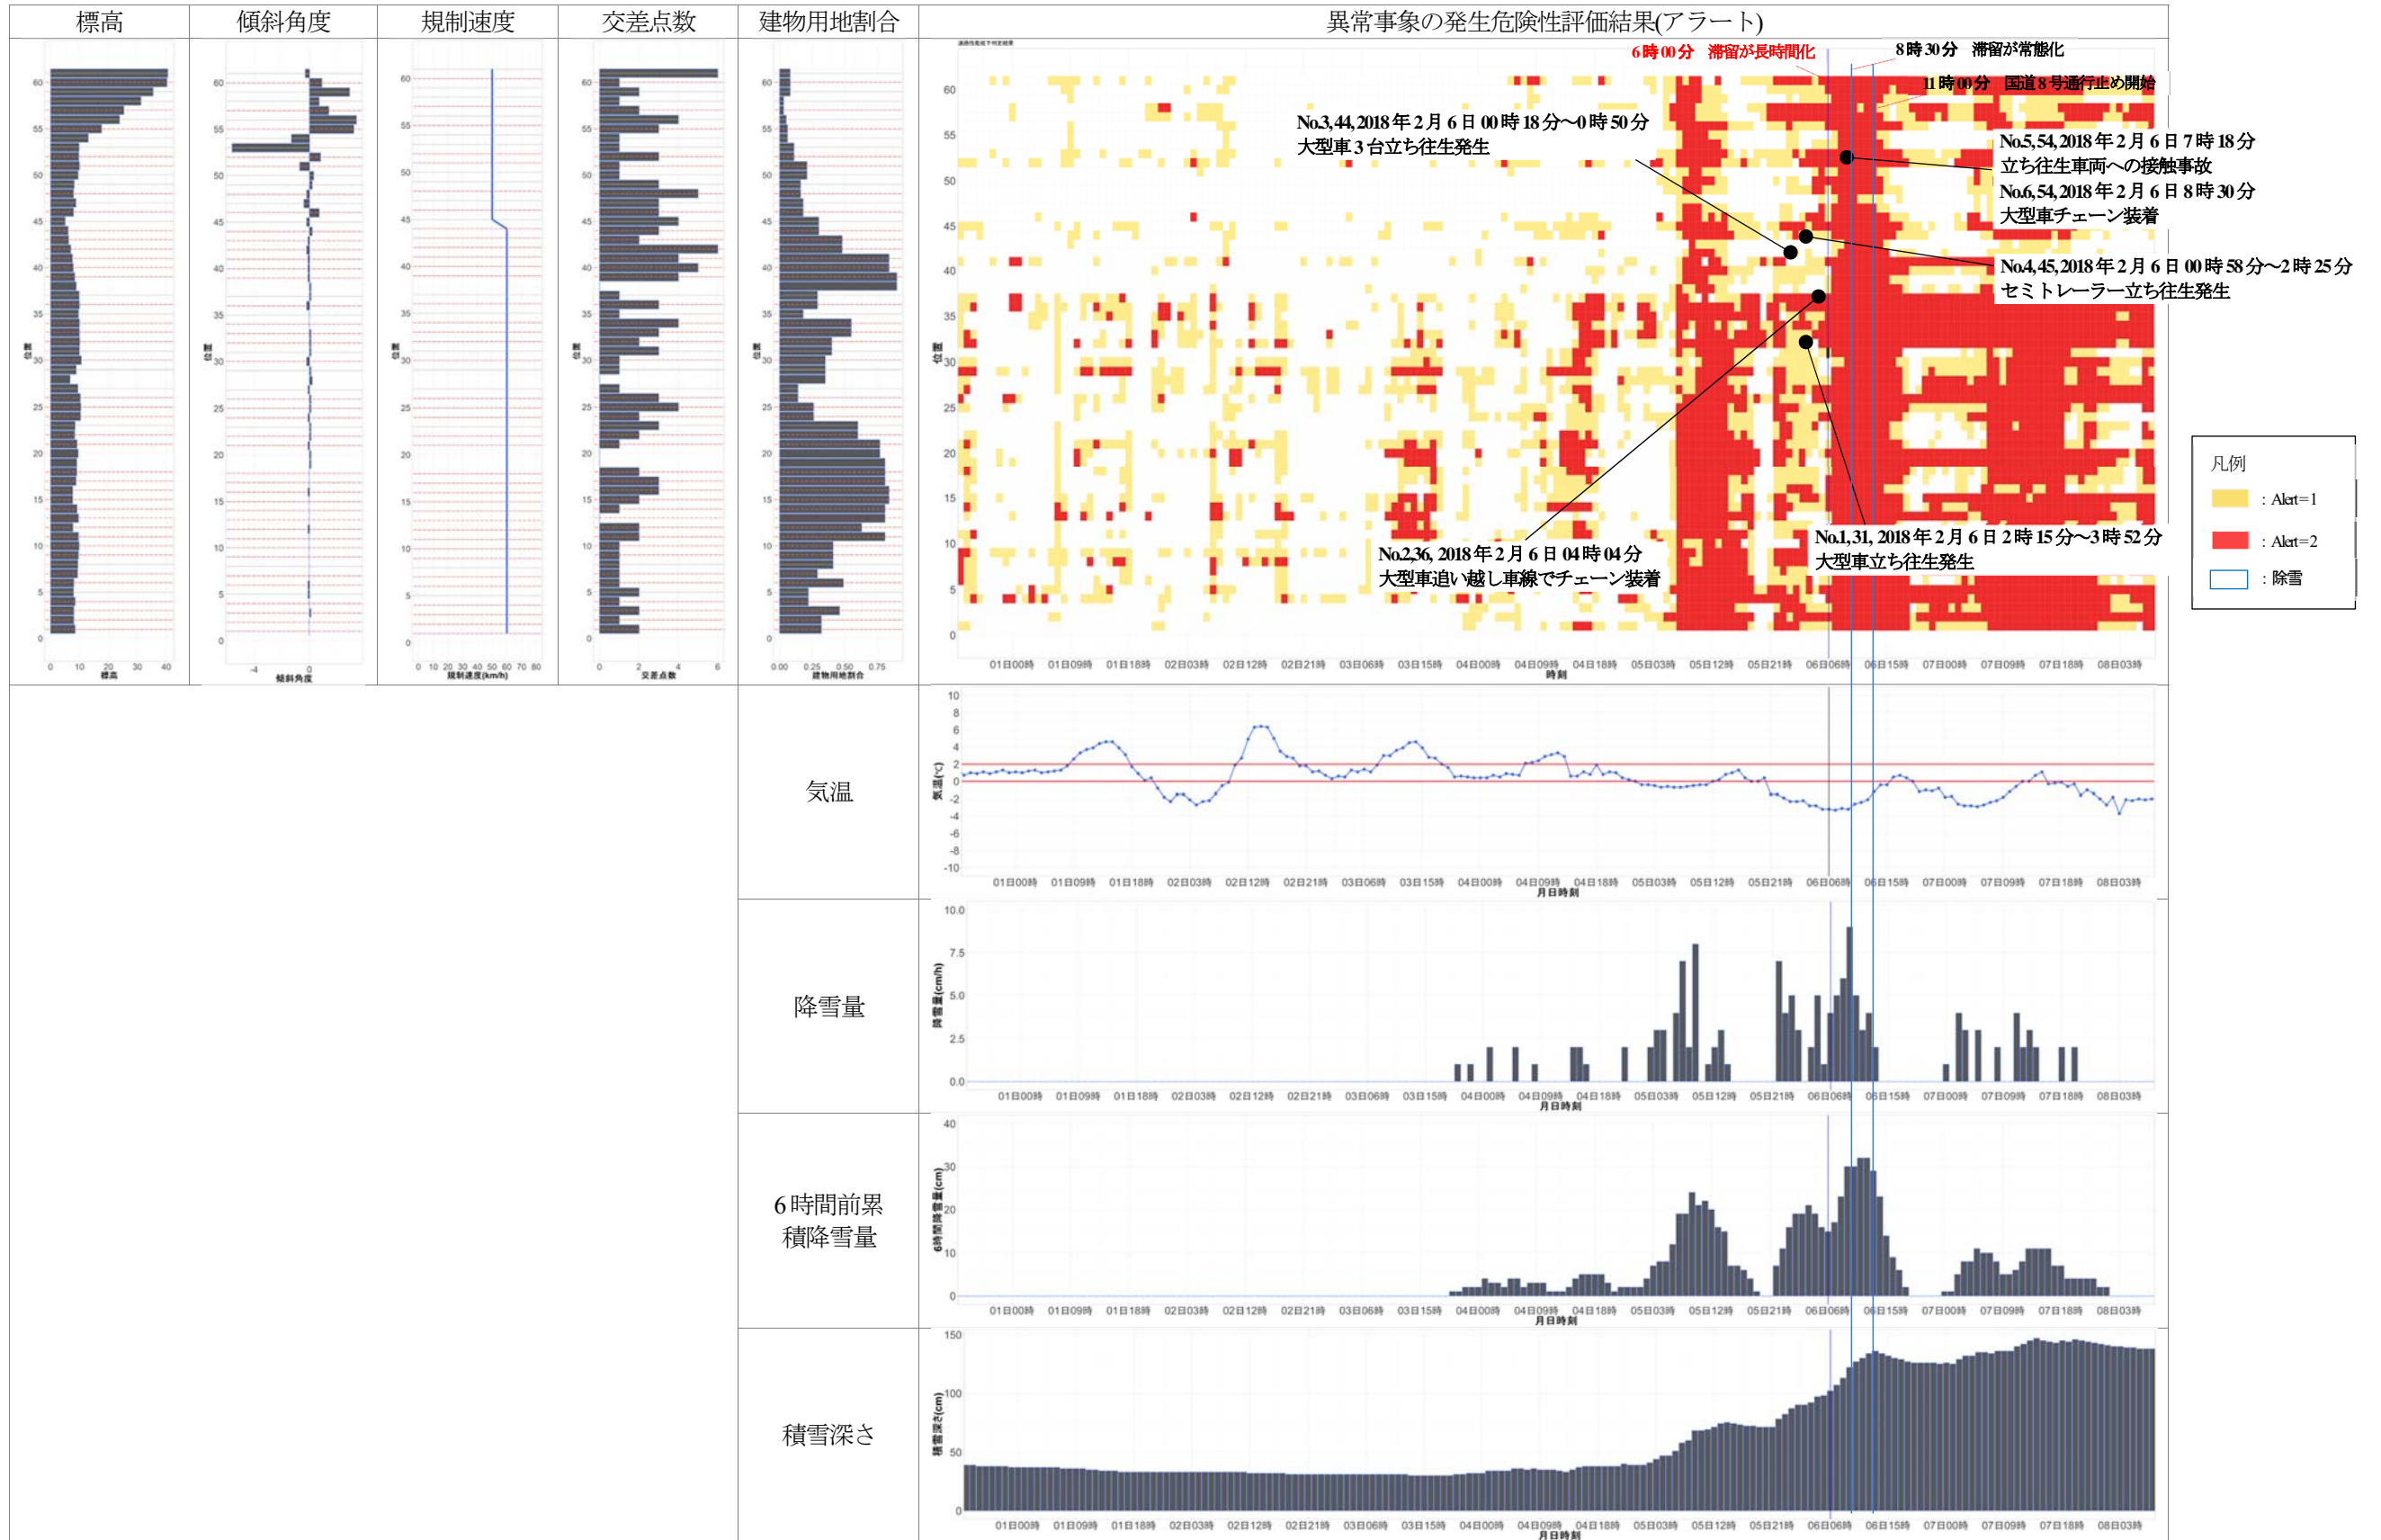


図5-16 異常事象の発生危険性評価結果(アラート)

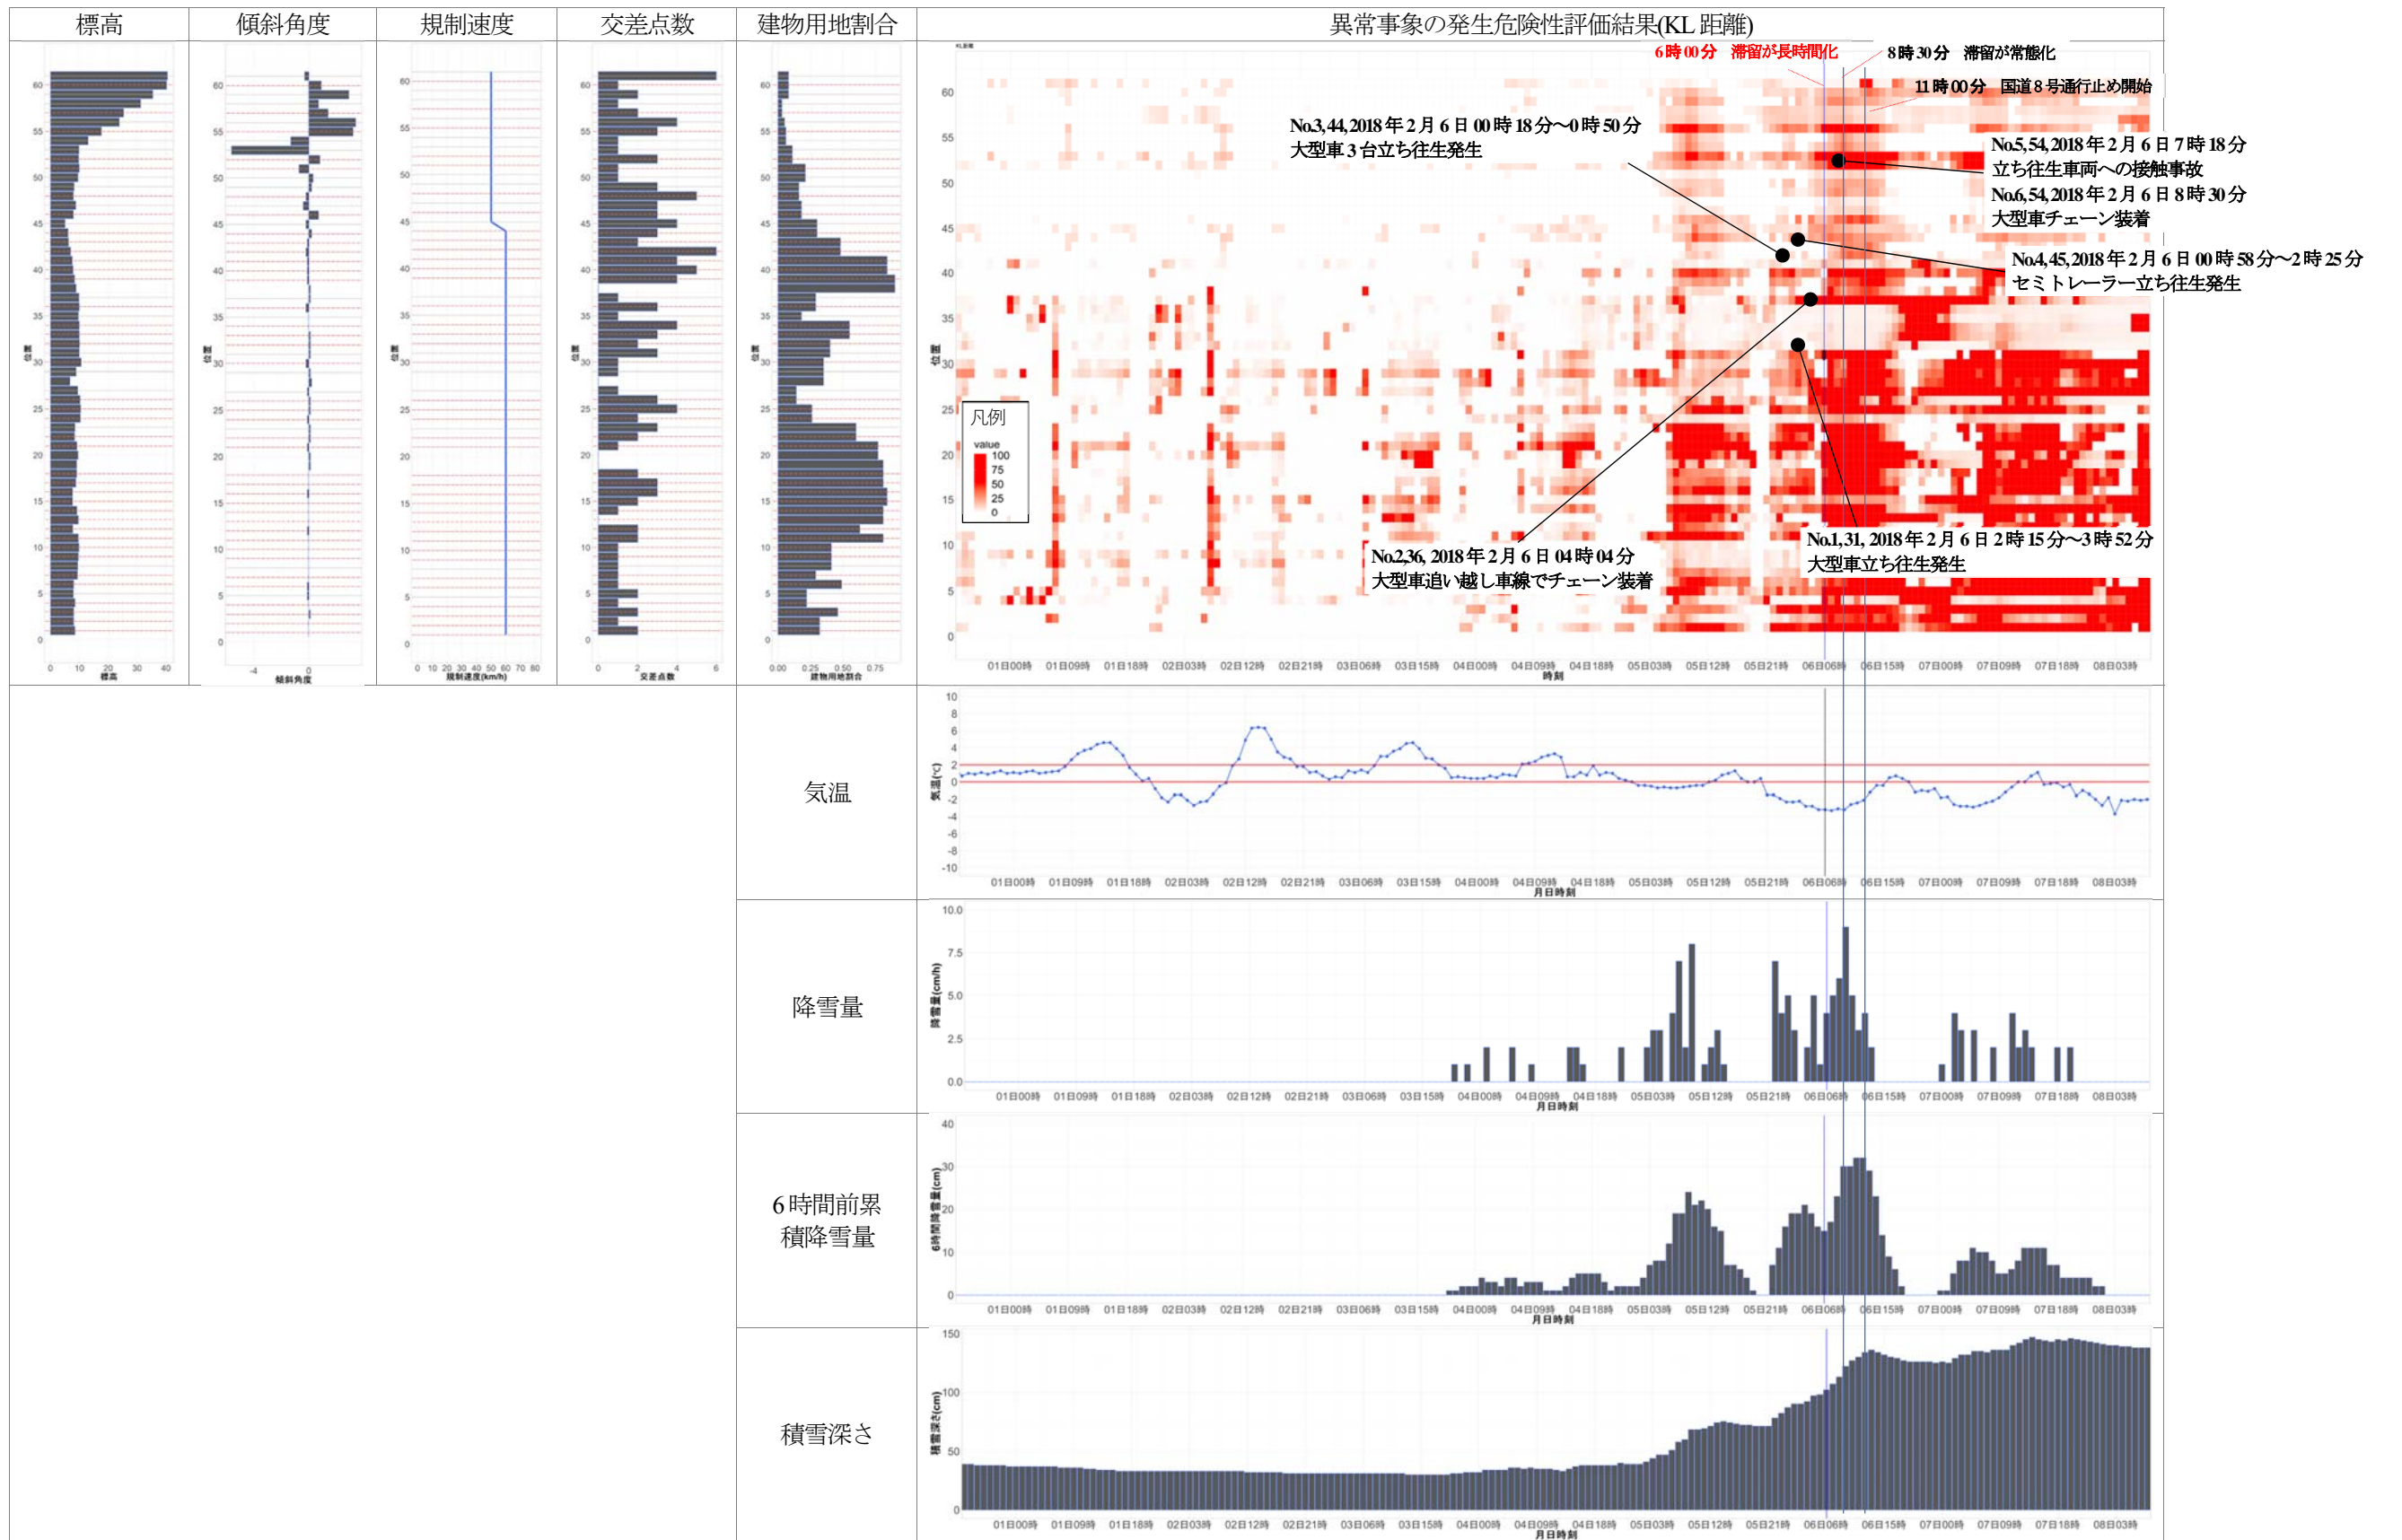


図5-17 異常事象の発生危険性評価結果(KL距離)

(2) 区間別の危険性評価結果(立ち往生発生時)

1) パラメータ推定結果

3-6-2のパラメータ推定方法に従い、当該事例において、最初に立ち往生が発生した区間のパラメータ(システム誤差の分散、観測誤差の分散)の推定結果を整理する。表 5-4はモデルパラメータの整理したものである。観測誤差の分散は、101.6393で、レベル成分の分散が、3.675239e-05、気温回帰係数の誤差分散が、6.175637e-07、降雪量の回帰係数誤差の分散が0.002503177、プローブ台数の回帰係数の誤差の分散が1.779546e-08、周期成分の誤算の分散が4.038978e-05と推定された。観測誤差の分散は、山形の事例と比較すると大きい。

表 5-4 福井県国道 8 号推定モデルパラメータ(No.31)

観測誤差分散 σ_{η}	レベル成分誤差分散 σ_{ε}^2	降雪量回帰係数誤差分散 σ_{ξ}^2	プローブ台数回帰係数誤差分散 σ_{ζ}^2	気温回帰係数誤差分散 σ_{τ}^2	周期成分誤差分散 σ_{ω}^2
101.6393	3.675239e-05	0.002503177	1.779546e-08	6.175637e-07	4.038978e-05

2) 危険性評価結果

図 5-18は、図 5-4と同様にして、当該区間の(No.44)異常事象の発生危険性の評価結果を示したものである。立ち往生が発生した2月6日0時台は、異常事象がいつ発生してもおかしくない状況($Alert_t = 1$)を示しており、1時台では、異常事象が発生している可能性が高い状況($Alert_t = 2$)を示していることから、実態にあったアラート発信がなされている。また、提案手法は、2月4日18時時点、2月5日の午前中の時点で、異常事象が発生している可能性が高い状況($Alert_t = 2$)をアラートしている。図 5-19は、モデルによる1期先予測と観測値とその差分(予測残差)を図示したものである。







図5-18 立ち往生発生箇所における異常事象の危険性評価結果(No.44)



- : 観測値
- : フィルタリング期待値
- : 予測残差

図5-19 予測残差の時間変動(No.44)

3) 状態推定結果

ここでは、当該区間における各変動成分の推定結果について整理する。図 5-20は、レベル成分の時間変動を示したものである。山形の事例では、レベル成分が時間変動したが、当該区間ではほぼ時間変化していない。図 5-21、周期成分の時間変動を表したものである。図 5-22は、気温と気温の回帰成分の時間変動を示したものである。気温が低いほど、速度が低くなる傾向にあり、2月6日の0時頃に最大で4km/h程度の速度低下が推定されている。図 5-23は、6時間前累積降雪量と降雪量回帰成分の時間変動を示したものである。2月6日の6時間前累積降雪量が最大となる時間帯に、降雪量の回帰成分が最大となり、最大で20km/h以上の速度の低下の影響が推定されている。図 5-24はプローブ通過台数とプローブ通過台数回帰成分の時間変動を示したものである。プローブ台数が少ないほど、速度が低く推定され、プローブ台数が多いほど、速度が高く推定される傾向にある。プローブ台数の影響により2km/h~10km/h程度の速度の低下が推定されている。




図 5-20 レベル成分の時間変動(No.44)




図 5-21 周期成分の時間変動(No.44)





図 5-22 気温(上)と気温回帰成分(下)の時間変動(No.44)




図5-23 6時間前累積降雪量(上)と降雪量回帰成分(下)の時間変動(No.44)




図5-24 プローブ通過台数(上)とプローブ通過台数回帰成分(下)の時間変動(No.44)

(3) 路線全体の危険性評価結果(平常時)

図 5-25は、平常期間における検証対象箇所の間別時間帯別の異常事象の発生危険性評価結果(アラート)の時空間変化と気象条件と幾何構造の関係を示したものである。平常期間は、データを保持している期間の中で、出来るだけ降雪が少ない2019年2月1日~2月8日の1週間を選定した。図 5-25をみると、立ち往生発生時と比較して、アラートの状況は大幅に少ないものの、複数回の発報がある。特に、区間位置45~50付近で、複数回赤色 ($Alert_t = 2$)が表示されている。アラート発信されているのは、夜中の3時頃であり、プローブ台数が少ない時間帯である。プローブ台数が少ない時間帯は、過去の道路性能の推定精度が悪いため、発報されやすい傾向にある。図 5-26は、平常期間における検証対象箇所の間別時間帯別のKL距離を示したものである。KL距離の大きさを赤色の濃淡で示しており、赤色が濃いほどKL距離が大きいことを示している。立ち往生発生時と比較するとKL距離が極端に大きな値を取ることは少ない。また、図 5-27は、平常期間における検証対象箇所の間別時間帯別に観測値(85パーセンタイル速度)を確定的に扱って、異常事象の発生危険性評価を行った結果(アラート)を示したものである。図 5-25と比較すると、発報回数が非常に多い傾向がある。




図 5-25 異常事象の発生危険性評価結果(アラート)

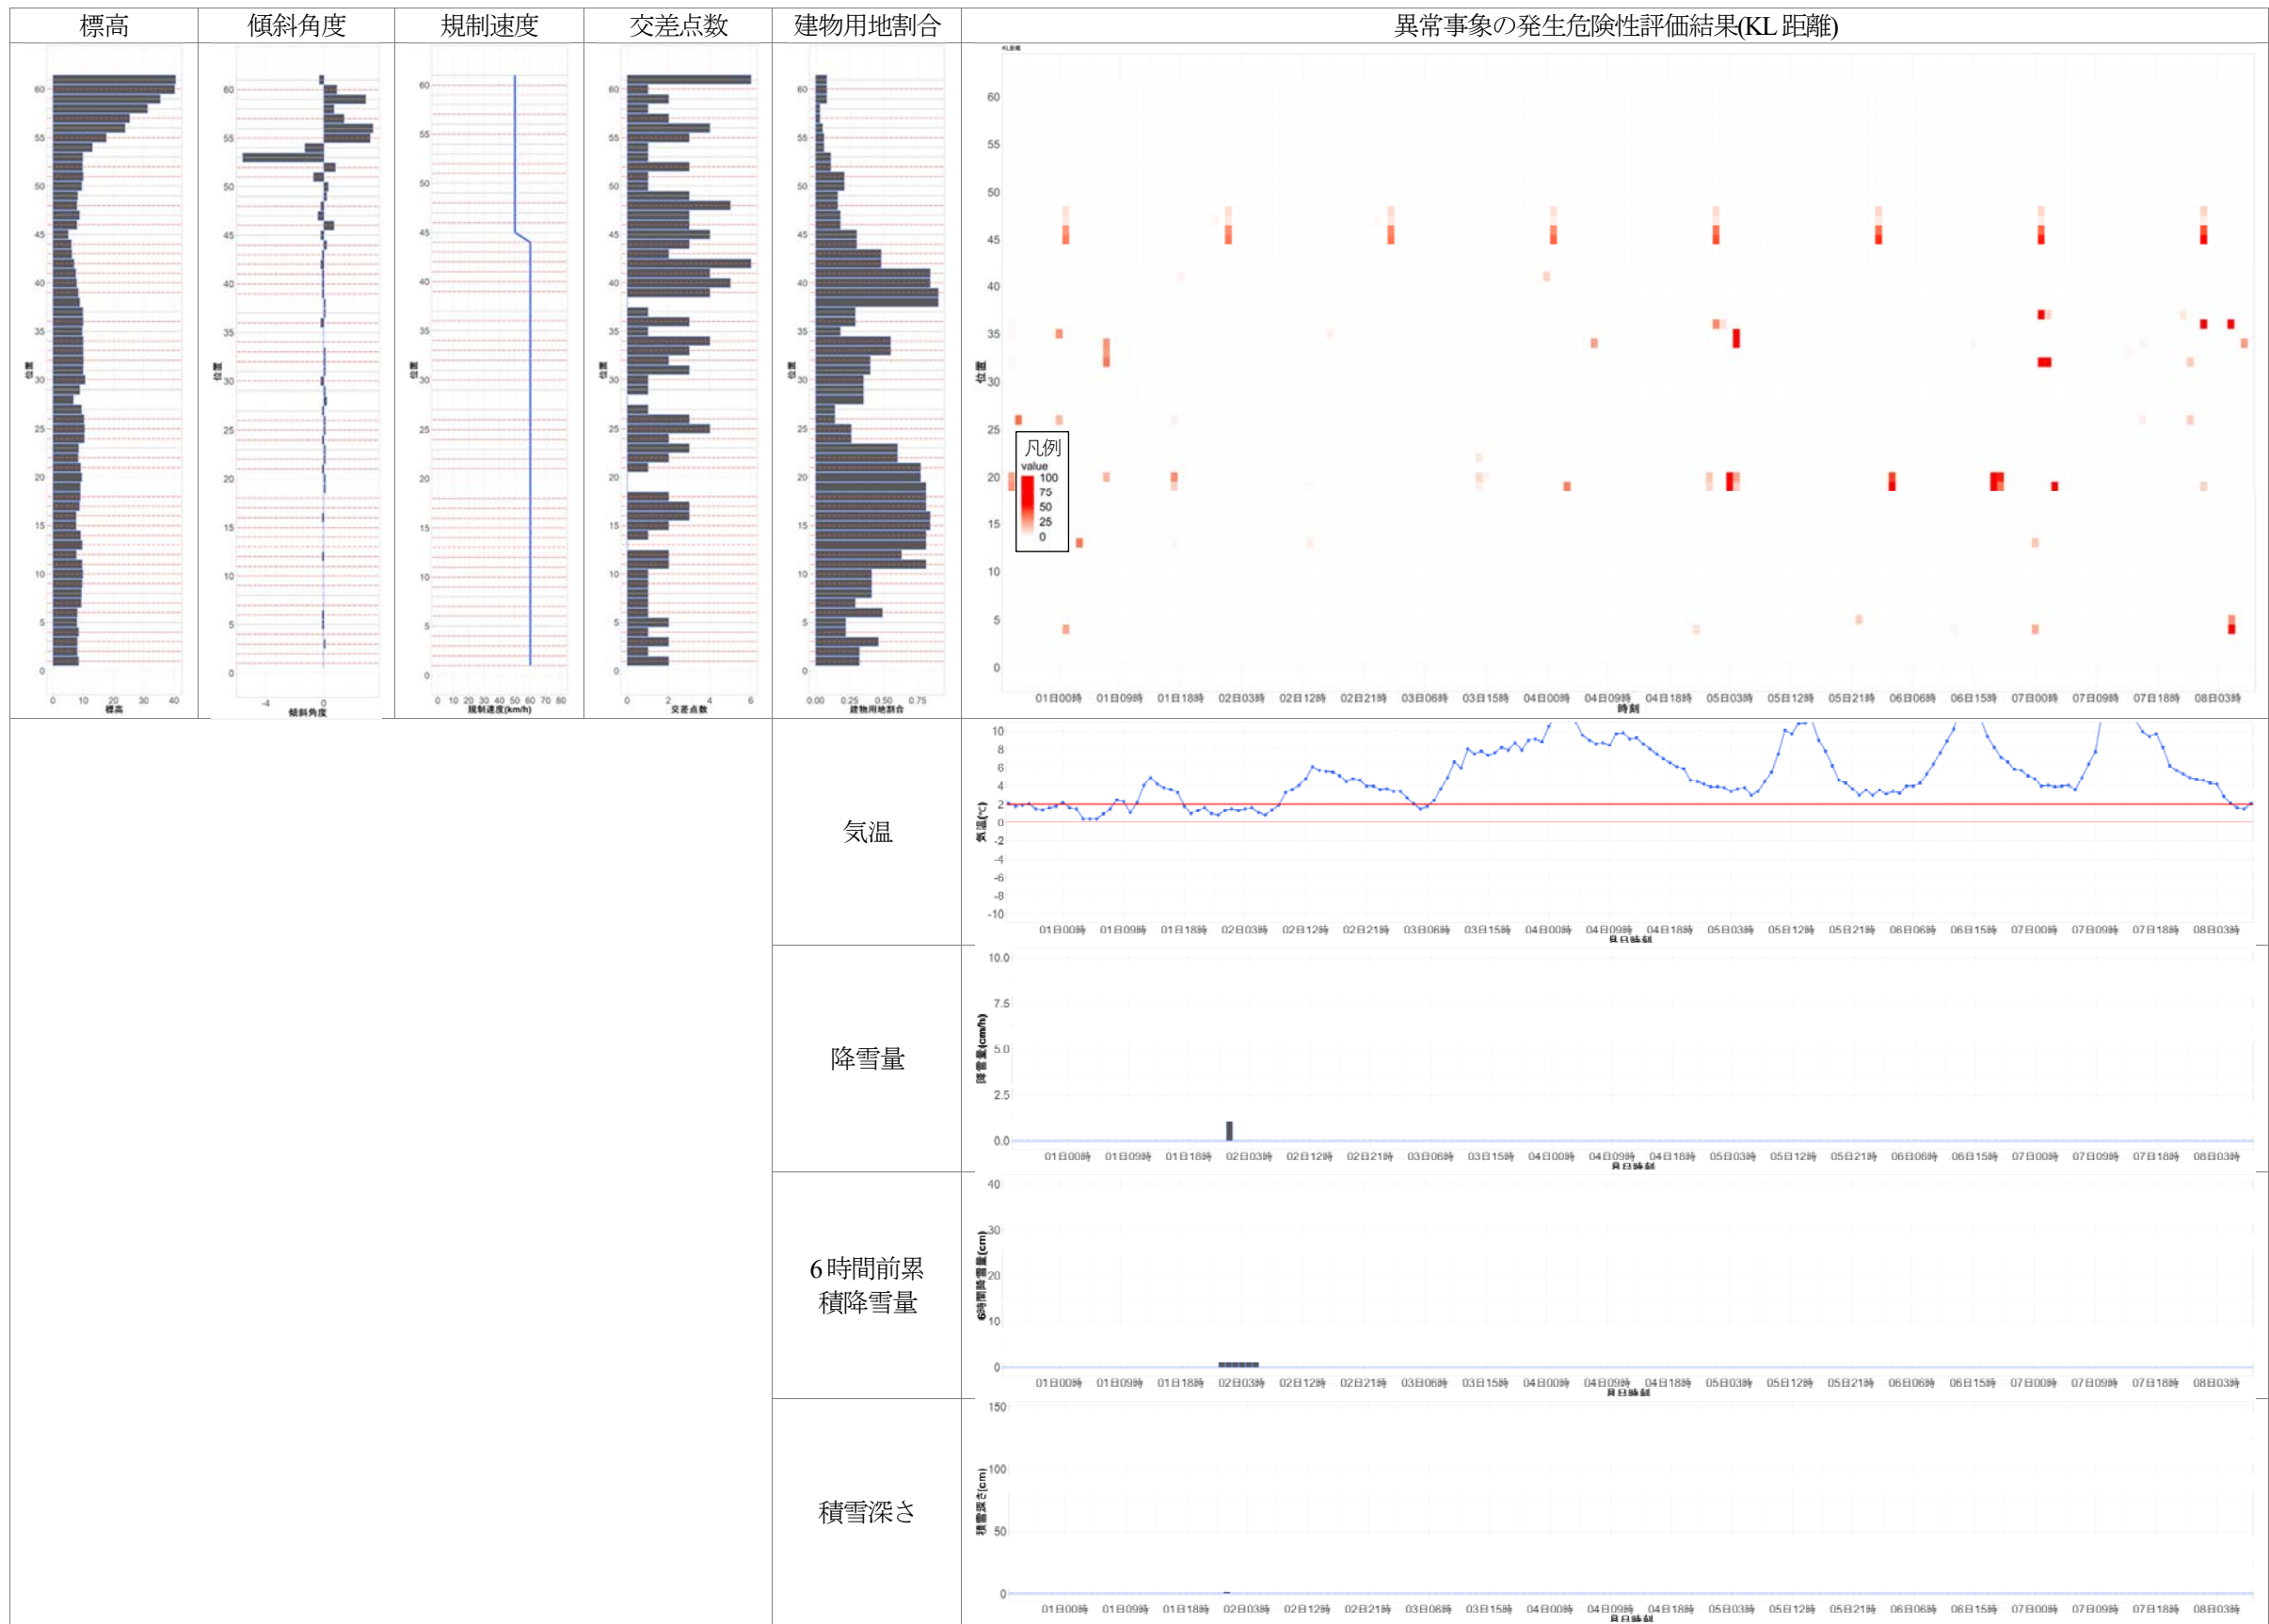


図 5-26 異常事象の発生危険性評価結果(KL距離)

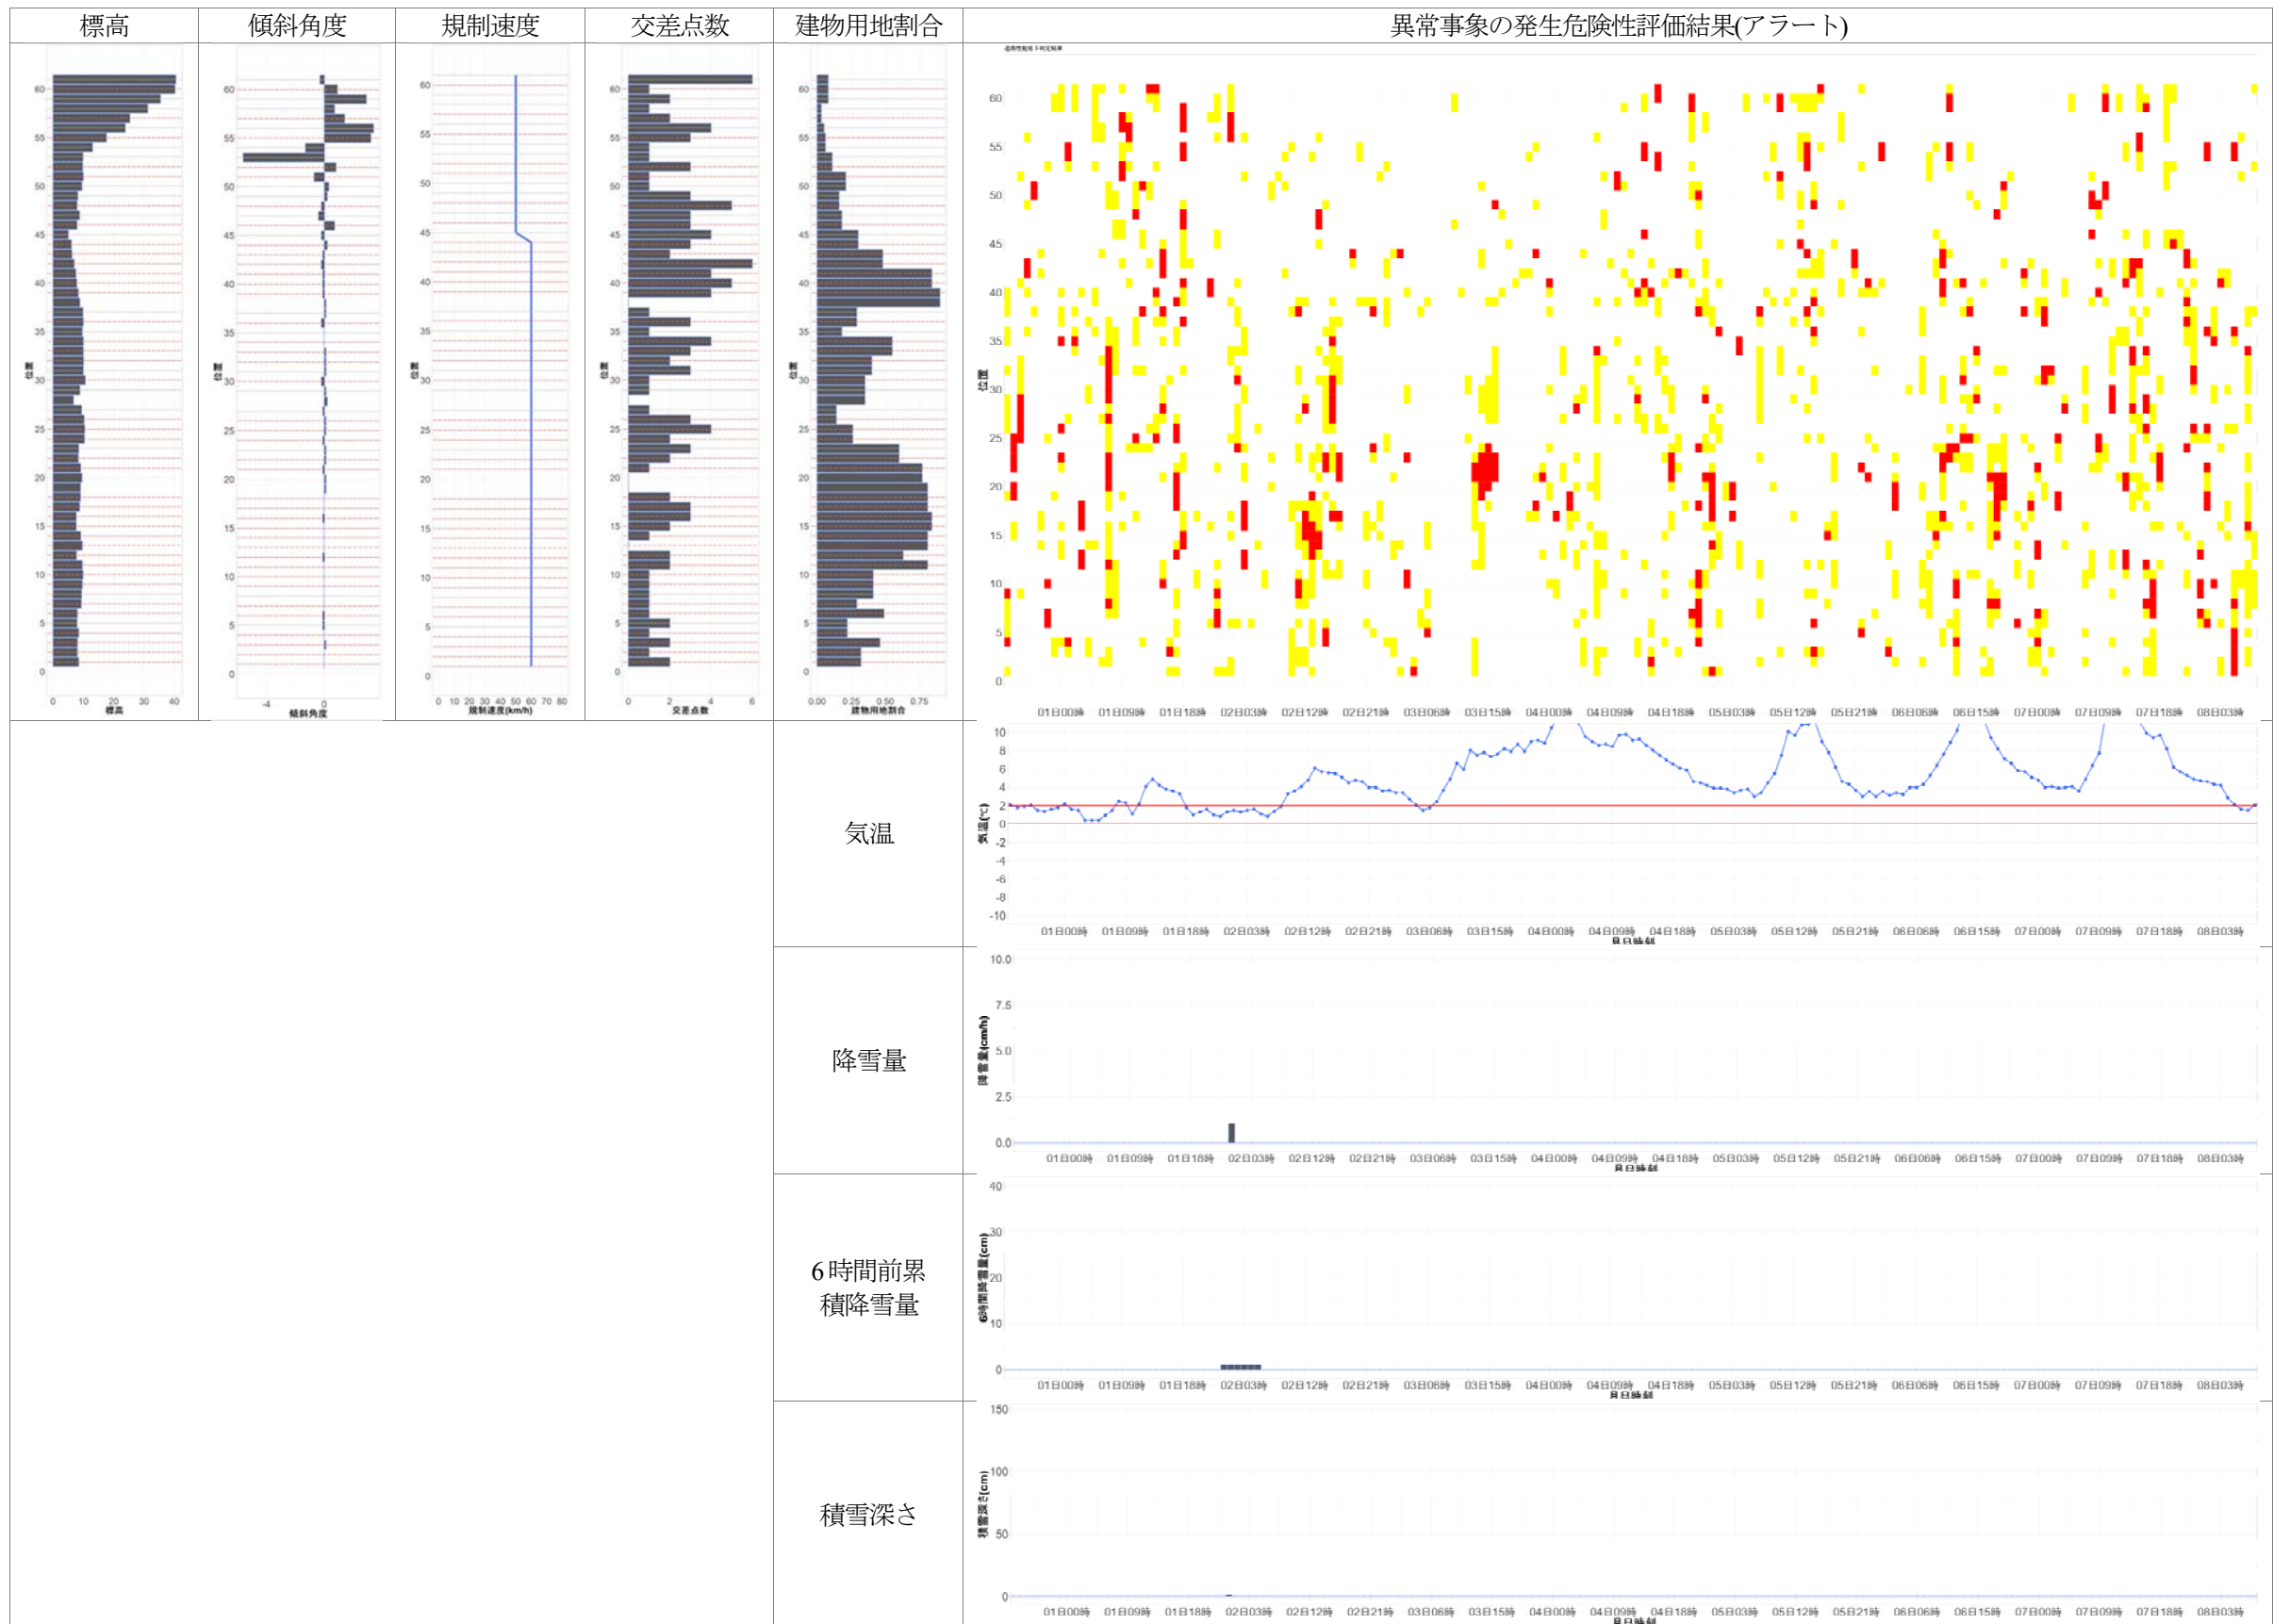


図 5-27 平常期間における異常事象の発生危険性評価結果(観測値：85パーセントイル速度)

(4) 区間別の危険性評価結果(平常時)

1) パラメータ推定結果

ここでは、平常時に異常事象の発生危険性を頻繁にアラート発報している No.47 について、詳細を整理する。3-6-2 節のパラメータ推定方法に従い、当区間のパラメータ(システム誤差の分散、観測誤差の分散)の推定結果を整理する。表 5-5 はモデルパラメータを整理したものである。観測誤差の分散は、154.1995 で、レベル成分の分散が、0.0001482545、気温回帰係数の誤差分散が 0.008174945、0.00171、降雪量回帰係数の誤差分散が 0.0002842075 とプローブ車両台数回帰係数の誤差分散が 0.0003509135、周期成分の誤算分散が 0.0004850677 と推定される。最初に立ち往生が発生した区間(No.31)と比較すると観測誤差分散、システム誤差分散のいずれの値も大きく推定されている。

表 5-5 福井県国道 8 号推定モデルパラメータ(No.47)

	観測誤差 分散 σ_{η}	レベル成分誤差 分散 σ_{ε}^2	降雪量回帰係数誤差 分散 σ_{ξ}^2	プローブ台数回帰係数誤 差分散 σ_{ζ}^2	気温回帰係数誤差 分散 σ_{τ}^2	周期成分誤差 分散 σ_{ω}^2
平均	154.1995	0.0001482545	0.0002842075	0.0003509135	0.008174945	0.0004850677

2) 危険性評価結果

図 5-28 は、図 5-4 と同様にして、当該事例における平常期間に発報が多い区間(No.47)の異常事象の発生危険性の評価結果を示したものである。夜中(0 時~3 時頃)において、プローブ車両の通過を観測できた平常期間の日数が少なすぎるために、過去の分布を推定することが出来ていない。そのため、同じ時間帯でアラート発信がなされてしまっている。フィルタリング分布についても、分散が大きくなっており、推定精度が低い結果となっている。プローブ車両の観測台数や観測日数が少なすぎる場合は、推定精度に大きな悪影響を及ぼすため、このような区間は評価不可とする必要がある。



図5-28 平常期間における異常事象の危険性評価結果(No.47)

(5) 気象と道路状況に関する一般的知見との整合確認

図 5-29は、気温と6時間降雪量別のアラート率のヒートマップである。気温が低く、六時間降雪量が多いほど、アラート率が高い傾向が見て取れる。降雪量がなく、気温だけが低い場合はアラート発報がなく、道路の性能低下には、気温の影響は小さく、降雪量が多く、気温が低いという2つの条件が重なった場合に低下する傾向にある。当該事例では、気温が4℃以下に下がることはなく、山形の事例と比較すると気温の分布の幅が狭い傾向にある。




図 5-29 気温と降雪量とアラート率の関係

5-4 結果のまとめ

2018年に発生した福井県の国道8号線の立ち往生、2019年に発生した山形県の国道47号の立ち往生事例という異なる場所で発生した規模の大きな事象に対しても、異常事象が発生する前日や10時間以上前の段階で異常事象の発生危険性が高い状況であったことを評価出来ることを確認した。ただし、福井の事例のように、37年ぶりという豪雪の場合は、区間というよりも路線全体が異常事象の危険性が高くなる傾向にあり、区間単位で危険性に大きな差が現れるような事象ではなかったことがわかった。また、国道8号線のように都心部を通過する区間では、観測値に85パーセントイル速度を用いても信号による速度低下や車両密度による速度低下の影響を完全に除くことが出来ない時間帯が存在するため、道路の走行性能の時間変動にばらつきが生まれやすく、時間帯によっては、過去の分布が大きく推定され、発報しにくい傾向があることが分かった。反対に、リアルタイムの道路の走行性能は、気象による速度低下以外の状況を多く観測するため、誤発報が発生しやすくなる傾向にあることがわかった。また、過去、夜間にプローブ車両が1台も観測されない日が多い場合では、過去の分布が推定できないため、その時間帯は毎日発報してしまうという状況も確認できた。このような区間、時間帯は、評価不可として取り扱う必要がある。

5章の参考文献

- 1) 国土交通省HP: 冬期道路交通確保対策検討委員会資料,<https://www.mlit.go.jp/road/ir/ir-council/toukidourokannri/pdf01/06.pdf>. (最終閲覧日: 2019年10月19日)
- 2) 国土交通省HP東北地方整備局平成28年11月28日発表資料: http://www.thr.mlit.go.jp/bumon/kisya/kisyah/images/63723_1.pdf.
- 3) 国土交通省国土政策局国土情報課GISホームページ: <http://nlftp.mlit.go.jp/ksj/index.html> (最終閲覧日: 2019年11月20日) .
- 4) 国土交通省近畿地方整備局HP: 今後の大雪に関する対策, http://www.pref.fukui.lg.jp/doc/kikitaisaku/setsugai/h30_taisaku_d/fil/01_01honpen_all.pdf.

第6章 結論

最後に、結論として、本研究の成果について整理し、提案手法での異常事象の発生危険性の評価結果に関する考察を行い、本研究の今後の課題と展望について述べる。

6-1 本研究の成果

本論文では、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、広範囲の一般道路ネットワークを対象に、異常事象の発見、異常事象の発生危険性を逐次的かつ定量的に評価する手法を提案し、その有効性と結果の妥当性を示した。以下に、具体的な成果を示す。

本論文では、まず道路の走行性能を定義し、プローブ車両データと気象データを観測量とした状態空間モデルを構築し、逐次的に推定する道路の走行性能と事前に推定しておく過去に発揮された道路の走行性能の乖離程度から冬季の道路交通異常事象発生危険性を定量的に評価する手法を構築した。

提案手法については、実際に異常事象が発生した事例(61事例：約3,700区間)のデータに適用し、除雪や立ち往生、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。

また、提案手法は、観測量として、時間当たりに区間を通過するプローブ車両の速度の85パーセンタイル値を用いるという点、さらに、状態空間モデルを用いて道路の走行性能を推定するという2つの工夫によって、観測値を確定的に扱うよりも大幅に誤発報を減らすことができることを明らかにした。また、提案手法は、欠測が多い時系列データに対しても、状態空間モデルにより前処理が不要かつ自然な形で補間推定することができることから転用性が高く、有用性が高い手法であると考えられる。

提案手法は、異常事象がいつ発生してもおかしくない状況、異常事象が既に発生している可能性が高い状況という2段階で異常事象の発生危険性をアラートすることができる枠組みであるため、当初の目的である道路管理者が異常事象の発生を未然に防ぐ予防的な対応と異常事象を早期に発見し、その影響を小さくするための事後的な対応の両方に活用することが出来る。

上記のとおり、提案手法は、道路管理実務へ活用する際の必要要件と技術的な課題に対応することが出来ている。この研究成果を用いることで、冬季道路交通における異常事象の発生しやすい道路特性を事前に把握することができ、一般道路の広域ネットワークを対象とした定量的な異常事象の危険性評価が可能となる。そのため、道路管理者は、従来の道路監視エリアを拡大することに加えて、予防的な対応が取れることで、道路管理者が目標として掲げる「道路ネットワーク全体として大規模な車両滞留の抑制と通行止め時間の最小化を図る(道路ネットワーク機能への影響の最小化)」の達成に貢献することが出来る。

6-2 評価結果に関する考察

6-2-1 評価結果に影響を与える要因

提案手法により異常事象の危険性を評価し、一定の成果を得たが、異常事象の発生可能性が低い環境下で異常事象が発生する可能性を誤発報したり、異常事象を見逃すケースが存在した。今後の手法の改良へ生かすため、提案手法の評価結果に悪影響を与え、誤発報や見逃しが増加する要因について考察する。

提案手法は、85パーセンタイル速度から過去の道路の走行性能の分布とリアルタイムの道路の走行性能の分布を状態空間モデルによって推定し、その乖離度合いの評価を行っている。そのため、評価結果に悪影響を与える主な要因として表6-1に示す要因が考えられる。

表 6-1 評価結果に影響を与える要因一覧

影響要因	主な要因	詳細
①85パーセンタイル速度の推定精度	サンプル数	夜間や山間部ではサンプル数が少ないことが多いため、85パーセンタイル速度が道路の走行性能を代替できていない可能性がある。その場合は、過去やリアルタイムの道路の走行性能の推定に影響を及ぼし、評価結果に悪影響を及ぼす。
②妥当性評価方法	対象事象の規模・原因	立ち往生の規模が小さく交通流に影響を与えない場合は、本来評価の対象外とする必要があるが、立ち往生の原因・規模の詳細が不明のため、本論文の評価対象に含まれている可能性がある。
	評価の閾値	気温が2℃以上かつ6時間降雪量が0cmをパラメータとして異常事象の危険性がない(陰性)として評価を行っているが、閾値が適切ではない可能性がある。気象データの誤差や道路特性の影響で陰性の中にも、危険な状況が含まれている可能性がある。反対に気温が低く、積雪があっても、車両の性能が高い場合や除雪・融雪が行われていれば、道路の性能が低下しない場面がある。また、異常事象の危険性に影響を与える要素として、当期の気象条件以外(前日からの気温差、当日の天気等)の影響がある可能性がある。
③過去の分布の推定精度	アラートの閾値	過去の分布の68%信頼区間、95%信頼区間をパラメータとしてアラート発信しているが、閾値が適切ではない可能性がある。
	サンプル数	評価日数が過去分布推定の際のサンプル数となるが、評価日数が少ない場合、過去の分布の推定精度が悪くなる。

影響要因	主な要因	詳細
④リアルタイムの分布の推定精度	・モデル構造	気温、6時間降雪量、プローブ台数を説明変数として、モデルを構築しているが、速度を低下させる要因として当期の気象条件以外(前日からの気温差、当日の天気等)や幾何構造が影響している可能性がある。
⑤その他	・データ(気象、プローブ)の誤差	その他のモデル化できない要素、除外しきれない様々なノイズが影響している可能性がある。

6-2-2 時空間分解能の影響に関する考察

本論文では、空間分解能を500m地域メッシュ単位、時間分解能を1時間単位として、異常事象の発生危険性について評価を行った。評価結果に、時空間の分解能が与える影響が大きいため、時間分解能と空間分解能が評価結果に与える影響について考察を行った。

1) 時間分解能の影響

提案手法の精度は、85パーセンタイル速度を推定するためのサンプル数(プローブ車両の通過台数)に依存する。必要サンプル数を満たすために有効な手段として、時間分解能を大きくする事が考えられるが、時間分解能を大きくするとリアルタイム性は損なわれることになるため、評価精度とリアルタイム性はトレードオフの関係にある。実態として、提案手法で評価したい冬季道路の路面状況の変化のスピード、気象データの時間分解能、現状のプローブ車両の普及状況を考えると、現状は、評価の時間分解能は1時間程度が妥当と考えられる。ただし、異常事象の早期発見を目的とする場合、1時間では、時間分解能が大きすぎることが懸念されるため、今後のプローブ車両の普及状況に応じて、時間分解能を小さくしていくことが望ましいと考える。

2) 空間分解能の影響

前述したように提案手法の精度は、評価区間の85パーセンタイル速度を推定するためのサンプル数(プローブ車両の通過台数)に依存する。空間分解能の大きさは、時間分解能に比べて、サンプル数に与える影響は小さいため、実運用の際には、道路管理者の対応区間や方法に合わせて空間分解能を設定することが重要である。ただし、プローブ車両データは数秒間隔で取得されるため、空間分解能を小さくした場合、区間内で観測されるプローブ点列データ数が少なくなる。結果として、通過速度にばらつきが生じやすくなり、85パーセンタイル速度もばらつきやすくなるため、評価精度が低下する。また、現状の気象データや道路特性に関するデータの空間分解能が500mであるため、同一の道路特性や気象特性を踏まえた評価を行う場合は、道路特性や気象特性の空間分解能に合わせてプローブ車両速度を算出する必要がある。

6-3 今後の課題

本研究の今後の課題は以下のとおりと考える。

1) 提案手法の実証実験

本論文では、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が、実際の道路管理へ適用する際には、未だ考慮できていない要素や、更なる精度の向上が求められると考えられる。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。提案手法を道路管理者に試験的に活用してもらうことで、更なる課題の抽出を図る。

2) 時空間分解能の感度分析

前節で、時空間分解能の影響について考察を行ったが、実際のデータで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。

3) 詳細な気象データの活用

本論文での提案手法は、気象台で観測される気象統計データを活用した。気象データに関して、より小さな空間解像度(500m四方メッシュ)のデータが存在する、このデータを活用することにより提案手法による異常事象の発生危険性の評価精度の向上を図ることが出来るか確認する。

4) 提案手法の更なる改良

6-2-1にて、提案手法による評価結果に影響を与える要因について考察を行った。考察を踏まえて、以下の方針で更なる手法の改良を行う。

①モデルの変数選択

モデルの変数について、危険性に影響を与える可能性がある変数を追加、選択し、評価結果への影響を確認する。具体的には、変数に幾何構造(勾配、幅員、曲線半径)や前日との関係(気温差)、当日の天気、凍結・非凍結等をダミー変数として考慮することが考えられる。

②観測値の信頼度の考慮

提案手法は評価区間を通過するプローブのサンプル数が、85パーセンタイル速度の推定及び危険性の評価結果精度に大きく影響する。プローブのサンプル数が多いほど、推定精度が高くなると考えられるため、観測値には本来信頼度があると考えられるが、本論文では考慮出来ていない。また、プローブ車両の走行位置や、気象観測台からの距離によっても各データの精度が異なると考えられることから、これらも本来は、信頼度をもっていると考えられるため、今後は、観測値の精度や信頼度を考慮した手法を開発する。

③近未来の予測手法の構築・精度検証

冬季道路交通における異常事象の対応では、リアルタイムの評価結果も重要であるが、近未来の予測がより重要となる。状態空間モデルの状態の時間変化を表すシステムモデルを定式化することにより、近未来の予測が可能となるため、モデルによる予測精度の検証が必要である。

5) 最適なアラート閾値の設定

本論文で提案したアラート発信を簡単に整理すると図 6-1、式(6.1)~式(6.3)となる。本論文では、アラート発信の閾値(パラメータ)として、過去の分布の $P_1=68\%$ 信頼区間と $P_2=95\%$ 信頼区間となるような x_1, x_2 を閾値にて評価をおこなったが、より適切なアラートの閾値が存在すると思われる。例えば、誤発報による損失と立ち往生の見逃しによる損失を考慮して、総損失を最も小さくする閾値等が考えられる。具体的には、式(6.4)に示すように、誤発報による損失と見逃しによる損失を最小化するパラメータを推定することが考えられる。ただし、実際には、意思決定者(道路管理者)との価値観に対応した重み(損失)を定める必要があるため、意思決定者との調整を行った上で、最適なアラートの閾値を設定する必要がある。




図 6-1 アラートの概念図

$$P_1 = 1 - \int_{x_1}^{\infty} f(x) dx \quad (6.1)$$

$$P_2 = 1 - \int_{x_2}^{\infty} f(x) dx \quad (6.2)$$

$$Alert = \begin{cases} 2(= anomaly), & \text{if } (\hat{y} - x_2 < 0) \\ 1(= indication), & \text{if } (\hat{y} - x_1 < 0) \\ 0(= normal), & \text{if } (\hat{y} - x_1 \geq 0) \end{cases} \quad (6.3)$$

$$\min .w_1h_1(x_1, x_2, \hat{y}) + w_2h_2(x_1, x_2, \hat{y}) \quad (6.4)$$

$f(x)$: X の確率密度関数

\hat{y} : フィルタリング分布の期待値

x_1 : アラートレベル1の閾値

x_2 : アラートレベル2の閾値

P_1 : アラートレベル1の閾値以上が出現する確率

P_2 : アラートレベル2の閾値以上が出現する確率

$h_1(x_1, x_2, \hat{y})$: 誤発報件数を返す関数

$h_2(x_1, x_2, \hat{y})$: 見逃し件数を返す関数

w_1 : 誤発報の重み(1件当たりの損失額)

w_2 : 見逃しの重み(1件当たりの損失額)

6) 冠水や道路損傷への適用可能性の検証

本論文では、冬季気象による異常事象を対象にその発生危険性の評価を試みた。そのほかの気象や自然現象の影響を受けて、発生する道路交通異常事象として、豪雨による冠水や地震による道路損傷等が考えられる。提案手法を改良することにより、冠水や道路損傷といった自然現象による異常事象や突発的な異常事象の発生危険性評価の可能性について検証を行う。

6-4 今後の展望

最後に、本研究の今後の展望について述べる。

1) 冬季道路管理対策(除雪, 融雪, 凍結防止等)の評価への活用

提案手法は、現時点の道路の走行性能を評価することが出来る。除雪や融雪といった道路管理者がなんらかの対応を行った後に、その対応前後の道路の走行性能を確認することで対応の効果や適切さを評価することが出来る可能性がある。対策の評価を行うことで、追加対策の必要性を議論することが出来る。

2) 潜在的危険箇所の把握への活用

提案手法による異常事象の発生危険性の評価結果と異常事象の発生実績を蓄積していくことで、異常事象の発生しやすい区間とその特性を定量的に把握することが出来る可能性がある。潜在的な危険箇所を把握することで、除雪計画の見直しや、異常事象発生前の対応計画を深度化できる可能性がある。

3) 道路利用者への情報提供

従来の天気予報などの天候情報以外に、本研究で提案する冬季道路交通における異常事象の発生危険性という新たな情報を道路利用者や運送事業者に提供することで、危険性が高い区間を避ける迂回行動や不要な外出を抑制でき、異常事象の影響を小さくすることが出来る可能性がある。

4) モニタリング・パトロール優先順位の検討

将来的には、道路のモニタリング方法が高度化し、CCTVが管理区間全区間を網羅できるように整備される可能性やドライブレコーダを用いたモニタリング方法が確立される可能性がある。しかし、全映像を常にモニタリングする方法や映像を収集する方法は、人手や通信網の強化が必要となる。提案手法はプローブの速度と気象データのみを用いているため、映像を切り替えるタイミングや映像を収集するタイミング等の異常の可能性が高い箇所やタイミングを抽出する(気づきを与える)ことに活用できる可能性がある。

謝 辞

本論文の作成にあたり、様々な方々からお力添えを賜りました。ここに記して感謝の意を表します。

東北大学大学院情報科学研究科 桑原雅夫教授には、指導教官、本論文の主査として、格別なるご指導、ご高配を賜りました。桑原先生には、建設コンサルタントとして働いていた私を社会人博士課程学生として温かく研究室に迎えていただき、優しく、ときに熱くご教授いただきました。私の力不足ゆえにご期待に添えていない部分も多分にあり、研究成果が思うように出ないなかでも辛抱強く見守っていただいたことに深くお礼申し上げます。桑原先生の社会貢献の精神、一つの問題に対して考え抜く姿勢は、私にとって、研究者としての在り方の見本となりました。今後、先生のご指導の下で培ったものを、さらに研鑽を重ね、研究と実社会の橋渡しに貢献できるよう邁進して参ります。

学位論文審査において拙論の副査を務めて頂き、貴重なご指摘とご助言を頂いた東北大学大学院情報科学研究科 河野達仁教授、井上亮准教授、東北大学 災害科学国際研究所 奥村誠教授に心より感謝申し上げます。

東北大学大学院情報科学研究科人間社会情報科学専攻空間計画科学分野桑原研究室スタッフの三谷卓摩元助教、川崎洋輔助教、竹之内篤研究員には、ゼミ等での議論を通じて非常に多くの貴重なご意見を頂き、支えて頂きました。特に川崎洋輔助教は、大学での生活、研究について右も左もわからなかった私に対して、誰よりも身近な先輩として様々な助言、議論をいただきました。また、忙しい中でも、常に私を含む研究室のメンバー全員を気にかけて、研究にひたむきに取り組む姿勢は社会人として、研究者としての見本となりました。厚く御礼申し上げます。佐々木恵秘書には、共同研究プロジェクトの契約手続きや日々の研究生活の中の様々な事務手続き等、常にご支援をしていただき、研究に集中できる環境を作っていただきました。研究室の学生の皆様には、日々の研究生活において、多々ご協力を賜り支えて頂きました。特に、卒業生の熊倉大樹さん、吉田政範さんには、この論文の基礎となる分析や解析を共に行い、学会の度に研究内容について貴重な議論、意見をいただきました。また、増田亮さん、大久保孔明さんには、本論文で用いたプローブ車両データの整理や異常事象発生時の状況データを整理を手伝っていただきました。2年半間、共に楽しい研究生活を過ごさせていただいた研究室スタッフ、学生の皆様への感謝の意をここに記します。

東北大学の桑原研究室を中心とした共同研究体である、データ指向性モビリティ情報生成グループ (Data Oriented Mobility Information Group ; DOMINGO) の皆様にも多くのご協力を賜りました。本論文で使用した数多くのデータは、DOMINGOの研究活動で収集・整理したものであります。データなくしてはこのような研究は不可能であり、皆様に心からお礼申し上げます。株式会社オリエンタルコンサルタンツの皆様には新卒入社して以降、技術者として自立できるよう多くのご指導をいただいたうえ、社会人博士課程進学に際しては大きな後押しをいただきました。進学後も本論文を完成させるに至るまで研究活動に集中できるよう常にご支援いただきました。特に格段のご配慮とご支援を賜りました江藤和昭氏、辻光弘氏、田中淳氏、林祐志氏、後藤秀典氏、

大畑長氏に心より感謝申し上げます。

本研究の一部は、国土交通省「道路施策の質の向上に資する技術研究開発」の委託研究「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」および独立行政法人情報通信研究機構の委託研究「異分野データ連携によるスマートモビリティ基盤の研究開発」の助成を受けて実施されました。

私の研究生活その他日常生活を支え続けてくれた、両親、妻の由起と長男の晃成に感謝の意を表します。最後に、ここに記しきれない多くの方々のご支援によって本研究が遂行されましたこと、心より感謝致します。

Appendix1. 状態空間モデルによる状態の逐次推定方法

ここでは、本文の3-5で割愛した状態空間モデルによる状態の逐次推定方法について整理する。状態空間モデルによる、1期先予測分布、フィルタ分布、固定区間平滑化分布は以下のように表すことができる。また、1期先予測、フィルタ、平滑化とデータとの関連性をグラフィカルモデルに表すと、図A-1のように表すことができる。また、各計算ステップは、図A-2のように表現できる。詳細については参考文献を参照されたい¹⁾²⁾。

○1期先予測分布

$$\begin{aligned} p(\mathbf{x}_t | Y_{1:t-1}) &= \int_{-\infty}^{\infty} p(\mathbf{x}_t, \mathbf{x}_{t-1} | Y_{1:t-1}) d\mathbf{x}_{t-1} &= \int_{-\infty}^{\infty} p(\mathbf{x}_t | \mathbf{x}_{t-1}, Y_{1:t-1}) p(\mathbf{x}_{t-1} | Y_{1:t-1}) d\mathbf{x}_{t-1} \\ &= \int_{-\infty}^{\infty} p(\mathbf{x}_t | \mathbf{x}_{t-1}) p(\mathbf{x}_{t-1} | Y_{1:t-1}) d\mathbf{x}_{t-1} \end{aligned} \tag{A-1}$$

○フィルタ分布


$$\begin{aligned} p(\mathbf{x}_t | Y_{1:t}) &= p(\mathbf{x}_t | \mathbf{y}_t, Y_{1:t-1}) &= \frac{p(\mathbf{x}_t, \mathbf{y}_t | Y_{1:t-1})}{p(\mathbf{y}_t | Y_{1:t-1})} &= \frac{p(\mathbf{y}_t | \mathbf{x}_t, Y_{1:t-1}) p(\mathbf{x}_t | Y_{1:t-1})}{p(\mathbf{y}_t | Y_{1:t-1})} \\ &= \frac{p(\mathbf{y}_t | \mathbf{x}_t) p(\mathbf{x}_t | Y_{1:t-1})}{p(\mathbf{y}_t | Y_{1:t-1})} \end{aligned} \tag{A-2}$$

○固定区間平滑化分布

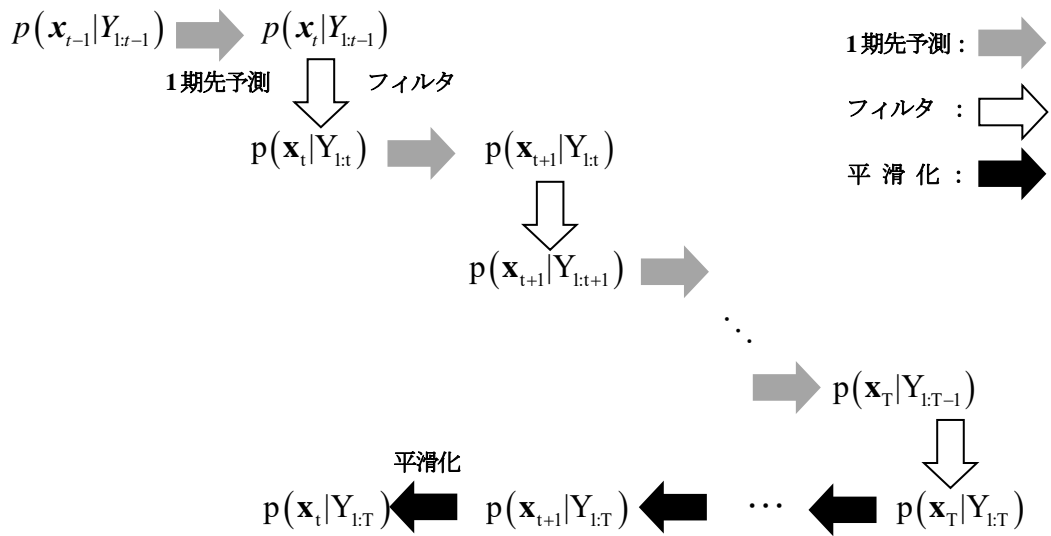
$$p(\mathbf{x}_t | Y_{1:T}) = p(\mathbf{x}_t | Y_{1:t}) \int_{-\infty}^{\infty} \frac{p(\mathbf{x}_{t+1} | Y_{1:T}) p(\mathbf{x}_{t+1} | \mathbf{x}_t)}{p(\mathbf{x}_{t+1} | Y_{1:T})} d\mathbf{x}_{t+1} \tag{A-3}$$

1) 島田直希:時系列解析 自己回帰型モデル・状態空間モデル・異常検知, 共立出版, 2019.

2) 野村 俊一:カルマンフィルタ, 共立出版, 2016.



図A-1 1期先予測, フィルタ, 平滑化とデータとの関連性



図A-2 1期先予測, フィルタ, 平滑化の計算ステップ

Appendix2. カルマンフィルタアルゴリズム

ここでは、本文の3-6で割愛した線形ガウス状態空間モデルの状態推定アルゴリズムであるカルマンフィルタについて説明する。

本研究では、カルマンフィルタアルゴリズムにより算出できる1期先予測値とフィルタ化推定量を用いて、リアルタイムの道路の走行性能の推定を行っている。以下にカルマンフィルタによる1期先予測値とフィルタ化推定量の算出方法を整理する。上述したように、線形ガウス状態空間モデルでは、状態の条件付き分布は正規分布であるため、平均と分散共分散行列を求めることで分布が表現できる。

○1期先予測分布

$$\mathbf{x}_{t|t-1} = \mathbf{F}_t \mathbf{x}_{t-1|t-1} \quad \mathbf{V}_{t|t-1} = \mathbf{F}_t \mathbf{V}_{t-1|t-1} \mathbf{F}_t' + \mathbf{G}_t \mathbf{Q}_t \mathbf{G}_t' \quad (\text{A-4})$$

○フィルタ分布

$$\mathbf{K}_t = \mathbf{V}_{t|t-1} \mathbf{H}_t' (\mathbf{H}_t \mathbf{V}_{t|t-1} \mathbf{H}_t' + \mathbf{R}_t)^{-1} \quad \mathbf{x}_{t|t} = \mathbf{x}_{t|t-1} + \mathbf{K}_t (\mathbf{y}_t - \mathbf{H}_t \mathbf{x}_{t|t-1}) \quad \mathbf{V}_{t|t} = (\mathbf{I}_k - \mathbf{K}_t \mathbf{H}_t) \mathbf{V}_{t|t-1} \quad (\text{A-5})$$

○固定区間平滑化分布

$$\mathbf{A}_t = \mathbf{V}_{t|t} \mathbf{F}_{t+1}' \mathbf{V}_{t+1|t}^{-1} \quad \mathbf{x}_{t|T} = \mathbf{x}_{t|t} + \mathbf{A}_t (\mathbf{x}_{t+1|T} - \mathbf{x}_{t+1|t}) \quad \mathbf{V}_{t|T} = \mathbf{V}_{t|t} + \mathbf{A}_t (\mathbf{V}_{t+1|T} - \mathbf{V}_{t+1|t} \mathbf{A}_t') \quad (\text{A-6})$$

1期先予測における $\mathbf{V}_{t|t-1}$ の第1項は以前の状態から推移してきた確率的変動の影響を表し、第2項は加わったシステムノイズの影響を表す。また、 $t = 1, \dots, T$ について1期先を予測する場合は、初期分布の平均と分散を設定しておく必要があるが、 T が大きければ、初期値の影響は無視できるため適当に与えることができる。ただし、信頼度が低いことを表現するためには、分散は大きくしておく必要がある。フィルタのアルゴリズムについて、 $\mathbf{y}_t - \mathbf{H}_t \mathbf{x}_{t|t-1}$ は \mathbf{y}_t の予測誤差を、 $\mathbf{H}_t \mathbf{V}_{t|t-1} \mathbf{H}_t' + \mathbf{R}_t$ はその分散共分散行列を表す。また、 \mathbf{K}_t はカルマンゲインと呼ばれるもので、 $\mathbf{x}_{t|t} = (\mathbf{I}_k - \mathbf{K}_t \mathbf{H}_t) \mathbf{x}_{t|t-1} + \mathbf{K}_t \mathbf{y}_t$ となることから分かるように、新しいデータによる状態推定値の更新の大きさを決める重み係数行列である。

1期先予測分布及びフィルタ分布の式から分かるように、システムノイズと観測ノイズの両方がない時、統計モデルとして成り立たない。また、逆行列を係数する必要があるため、 $\mathbf{H}_t \mathbf{V}_{t-1|t-1} \mathbf{H}_t' + \mathbf{R}_t$ は正則行列でな

ければならない点に注意が必要である.

平滑化のアルゴリズムには, 1期先予測分布およびフィルタ分布の平均と共分散が利用されているため, 平滑化を行うには, $t = 1, \dots, T$ における, $\mathbf{x}_{t|t-1}$, $\mathbf{x}_{t|t}$, $\mathbf{V}_{t|t}$, $\mathbf{V}_{t|t-1}$ を求め, これらの結果を保存しておかなければならない. そして, 式(A-6)のアルゴリズムに従い, $t = 1, \dots, T$ について時間を遡りながら, $\mathbf{x}_{t|T}$ と $\mathbf{V}_{t|T}$ を求めればよい.

Appendix3. 時系列の予測

本文で割愛した状態空間モデルによる時系列データの予測方法について説明する。状態 \mathbf{x}_t と時系列観測値 \mathbf{y}_t の関係を示す観測モデルを用いて、時点 t 以降の時系列観測値の予測も可能となる。 $Y_{1:t}$ が与えられた時、 $j \geq 1$ について、 \mathbf{y}_{t+j} の予測分布の平均 $\mathbf{y}_{t+j|t}$ と分散共分散行列 $\mathbf{U}_{t+j|t}$ は、次式で表される。

$$\begin{aligned}\mathbf{y}_{t+j|t} &= E\left[\mathbf{y}_{t+j} \mid Y_{1:t}\right] \\ &= E\left[\mathbf{H}_{t+j}\mathbf{x}_{t+j} + \mathbf{w}_{t+j} \mid Y_{1:t}\right] \\ &= \mathbf{H}_{t+j}\mathbf{x}_{t+j|t}\end{aligned}\tag{A-7}$$

$$\begin{aligned}\mathbf{U}_{t+j|t} &= E\left[\left(\mathbf{y}_{t+j} - \mathbf{y}_{t+j|t}\right)\left(\mathbf{y}_{t+j} - \mathbf{y}_{t+j|t}\right)' \mid Y_{1:t}\right] \\ &= E\left[\left(\mathbf{H}_{t+j}\mathbf{x}_{t+j} + \mathbf{w}_{t+j} - \mathbf{H}_{t+j}\mathbf{x}_{t+j|t}\right)\left(\mathbf{H}_{t+j}\mathbf{x}_{t+j} + \mathbf{w}_{t+j} - \mathbf{H}_{t+j}\mathbf{x}_{t+j|t}\right)' \mid Y_{1:t}\right] \\ &= \mathbf{H}_{t+j}E\left[\left(\mathbf{x}_{t+j} - \mathbf{x}_{t+j|t}\right)\left(\mathbf{x}_{t+j} - \mathbf{x}_{t+j|t}\right)' \mid Y_{1:t}\right]\mathbf{H}_{t+j}' + E\left[\mathbf{w}_{t+j}\mathbf{w}_{t+j}' \mid Y_{1:t}\right] \\ &\quad + \mathbf{H}_{t+j}\text{Cov}\left[\mathbf{x}_{t+j}, \mathbf{w}_{t+j} \mid Y_{1:t}\right] + \text{Cov}\left[\mathbf{w}_{t+j}, \mathbf{x}_{t+j} \mid Y_{1:t}\right]\mathbf{H}_{t+j}' \\ &= \mathbf{H}_{t+j}\mathbf{V}_{t+j|t}\mathbf{H}_{t+j}' + \mathbf{R}_{t+j}\end{aligned}\tag{A-8}$$

時系列観測データ $Y_{1:t}$ を用いた \mathbf{y}_{t+j} の予測分布も正規分布に従う。 \mathbf{y}_{t+j} の予測分布の平均 $\mathbf{y}_{t+j|t} = \mathbf{H}_{t+j}\mathbf{x}_{t+j|t}$ を \mathbf{y}_{t+j} の予測値として利用するとすれば、予測誤差は、 $\mathbf{y}_{t+j} - \mathbf{H}_{t+j}\mathbf{x}_{t+j|t}$ となり、その分散共分散行列は、 $\mathbf{U}_{t+j|t}$ で与えられる。

Appendix4. モデル別・事例別の異常事象発生前のアラート有無

表 1 モデル別・事例別の異常事象発生前のアラート有無

事例 NO	1	2	3	4	5	6	7	8	9	10	11	12	13	85 パー セン タイ ル 速 度	平 均 値	備考
1	有	有	有	有	有	有	有	有	有	有	有	有	有	有	有	
2	有	有	有	有	有	有	有	有	有	有	有	有	有	有	有	
3	有	有	有	有	有	有	有	有	有	有	有	有	有	有	有	
4	有	0	0	有	有	有	0	有	有	有	0	0	0	有	有	
5	有	有	有	有	有	有	有	有	有	有	有	有	有	有	有	
6	有	0	有	有	有	有	有	有	有	有	有	有	有	有	有	
7	0	0	0	0	0	0	0	0	0	0	0	0	0	0	有	交通に支障なしのため対象外
8	0	0	0	0	0	0	0	0	0	0	0	0	0	0	有	
9	0	0	0	0	0	有	0	0	0	0	0	0	0	有	有	
10	有	有	有	有	有	有	0	有	有	有	0	有	0	有	有	交通に支障なしのため対象外
11	0	0	0	0	0	0	0	0	0	0	0	0	有	0	有	
12	有	有	有	有	有	有	0	有	0	0	0	0	0	0	有	
13	0	0	0	0	0	0	有	0	有	0	有	0	有	有	有	
14	有	0	0	0	有	有	0	0	0	0	有	0	0	有	有	
15	有	有	有	有	有	有	有	有	有	有	有	有	有	有	有	
16	有	0	有	有	0	有	0	0	0	0	0	0	0	有	有	
17	有	0	有	有	有	有	有	有	有	有	有	有	有	有	有	
18	0	0	有	0	0	有	有	0	0	0	有	0	有	有	有	
19	有	有	有	有	有	有	有	有	有	有	有	有	有	有	有	
20	有	有	有	有	有	有	有	有	有	有	有	有	有	有	有	
21	有	有	有	有	有	有	有	有	有	有	有	有	有	有	有	
22	有	有	有	有	有	有	有	有	有	有	有	有	有	有	有	
23	0	0	0	0	0	0	0	0	0	0	0	0	0	0	有	
24	有	有	有	有	有	有	有	有	有	有	有	有	有	有	有	
25	有	有	有	有	有	有	有	有	有	有	有	有	有	有	有	
26	0	0	0	0	0	0	有	0	0	0	有	0	有	0	0	
27	0	0	0	0	0	0	0	0	0	0	0	0	0	有	有	

事例 NO	1	2	3	4	5	6	7	8	9	10	11	12	13	85 パー セン タイ ル 速 度	平 均 値	備考	
28	有	有	有	有	有	0	有	有	有	有	有	有	0	0	0	プローブ無のために支障なしのため対象外	
29	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0		
30	有	有	有	有	有	有	有	有	有	有	有	有	有	有	有		
31	有	有	有	有	有	有	有	有	有	有	有	有	有	有	有		
32	有	有	有	有	有	有	有	有	有	0	有	有	有	有	有		
33	0	有	有	0	0	有	有	有	有	有	有	0	有	有	有		
34	0	0	0	0	0	0	0	0	0	0	0	0	0	0	有		
35	有	有	有	有	有	有	有	有	有	有	有	有	有	有	有		
36	有	有	有	有	有	有	有	有	有	0	有	有	有	有	有		
37	0	有	有	0	0	有	有	有	有	有	有	0	有	有	有		
38	0	0	0	0	0	0	0	0	0	0	0	0	0	0	有		
39	0	0	0	0	0	0	0	0	0	0	0	0	0	0	有		
40	有	有	有	有	0	有	有	有	0	0	0	0	0	0	有	有	
41	0	0	0	0	0	0	0	有	0	0	0	0	0	0	有	有	プローブ無のために支障なしのため対象外
42	0	0	0	有	0	0	0	有	0	0	0	0	有	0	有	有	プローブ無のために支障なしのため対象外
43	有	0	有	有	0	有	有	0	0	0	有	0	有	有	有		
44	有	0	有	有	有	有	有	0	0	0	有	0	有	有	有		
45	有	0	有	有	0	有	有	0	0	0	有	0	有	有	有		
46	有	有	有	有	有	有	有	有	有	有	有	有	有	有	有		
47	有	有	有	有	有	有	有	有	有	有	有	有	有	有	有		
48	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0		
49	有	有	有	有	有	有	有	有	有	有	有	有	有	有	有		
50	有	有	0	有	有	0	有	有	有	有	有	有	有	有	有		
51	有	有	有	有	有	有	有	有	有	有	有	有	有	有	有		
52	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0		
53	有	有	有	有	有	有	有	有	有	有	有	有	有	有	有		
54	有	0	0	有	有	0	0	0	0	0	0	0	0	0	有	有	
55	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0		
56	0	0	0	0	有	0	0	0	0	0	0	0	0	0	有	有	
57	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0		

事例 NO	1	2	3	4	5	6	7	8	9	10	11	12	13	85 パー セン タイ ル 速 度	平 均 値	備 考
58	有	0	0	0	有	0	0	0	0	0	0	0	0	有	有	
59	有	有	有	有	有	有	0	有	有	有	有	有	有	有	有	
60	有	有	有	有	有	有	有	有	有	有	有	有	有	有	有	
61	有	0	有	有	有	有	有	0	有	0	有	有	有	有	有	

Appendix5. モデル別・事例別の異常事象発生直後のアラート有無

表 2 モデル別・事例別の異常事象発生直後のアラート有無

事例 NO	1	2	3	4	5	6	7	8	9	10	11	12	13	85 パー セン タイ ル 速 度	平 均 値	備考
1	有	有	有	有	有	有	有	有	有	有	有	有	有	有	有	
2	有	有	有	有	有	有	有	有	有	有	有	有	有	有	有	
3	有	有	有	有	有	有	有	有	有	有	有	有	有	有	有	
4	有	0	有	有	有	有	有	有	有	有	有	有	有	有	有	
5	0	0	0	0	0	0	0	0	0	0	0	0	0	0	有	
6	0	0	0	0	0	0	0	0	0	0	0	0	0	0	有	
7	0	0	0	0	0	0	0	0	0	0	0	0	0	有	有	交通に支障なしのため対象外
8	0	0	0	0	0	0	0	0	0	0	0	0	0	0	有	
9	0	0	0	0	0	0	0	0	0	0	0	0	0	0	有	
10	0	0	0	0	0	0	0	0	0	0	0	0	0	有	有	交通に支障なしのため対象外
11	0	0	0	0	0	0	0	0	0	0	0	0	0	0	有	
12	0	0	0	0	0	0	0	0	0	0	0	0	0	0	有	
13	0	0	0	0	0	0	有	0	有	0	0	0	有	有	有	
14	0	0	0	0	0	0	0	0	0	0	0	0	0	0	有	
15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	有	
16	0	0	0	0	0	0	0	0	0	0	0	0	0	0	有	
17	有	0	有	有	有	0	有	有	有	有	有	有	有	有	有	
18	有	有	有	有	有	有	有	有	有	有	有	有	有	有	有	
19	有	有	有	有	有	有	有	有	有	有	有	有	有	有	有	
20	有	有	有	有	有	有	有	有	有	有	有	有	有	有	有	
21	0	0	0	0	0	0	0	0	0	0	0	0	0	0	有	
22	有	有	有	有	有	有	有	有	有	有	有	有	有	有	有	
23	0	0	0	0	有	有	0	0	0	0	0	0	0	0	有	
24	0	0	0	0	0	0	0	0	有	0	有	有	有	0	0	
25	有	有	有	有	有	有	有	有	有	有	有	有	有	有	有	
26	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
27	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	

事例 NO	1	2	3	4	5	6	7	8	9	10	11	12	13	85 パー セン タイ ル 速 度	平 均 値	備考
28	0	有	0	0	0	0	0	0	有	有	0	0	0	0	0	ブロープ無のために支障なしのため対象外
29	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
30	有	有	有	有	有	有	有	有	有	有	有	有	有	有	有	
31	有	有	有	有	有	有	有	有	有	有	有	有	有	有	有	
32	有	有	有	有	有	有	有	有	有	0	有	有	有	有	有	
33	0	0	0	0	0	0	0	0	0	0	有	0	有	0	有	
34	0	0	0	0	0	0	0	0	0	0	0	0	0	有	有	
35	有	有	有	有	有	有	有	有	有	有	有	有	有	有	有	
36	有	有	有	有	有	有	有	有	有	0	有	有	有	有	有	
37	0	0	0	0	0	0	0	0	0	0	有	0	有	0	有	
38	0	0	0	0	0	0	0	0	0	0	0	0	0	有	有	
39	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
40	0	0	0	0	0	0	有	0	0	0	0	0	0	0	有	
41	0	0	0	0	0	0	0	0	0	0	0	0	0	有	有	ブロープ無のために支障なしのため対象外
42	0	0	0	0	0	0	0	0	0	0	0	0	0	0	有	ブロープ無のために支障なしのため対象外
43	有	0	有	有	0	有	有	0	0	0	有	0	有	有	有	
44	有	0	有	有	有	有	有	0	0	0	有	0	有	有	有	
45	有	0	有	有	0	有	有	0	0	0	有	0	有	有	有	
46	有	有	有	有	有	有	有	有	有	有	有	有	有	有	有	
47	有	有	有	有	有	有	有	有	有	有	有	有	有	有	有	
48	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
49	有	有	有	有	有	有	有	有	有	有	有	有	有	有	有	
50	0	0	0	0	0	0	0	0	0	0	0	0	0	有	有	
51	有	0	有	有	有	有	有	0	0	0	有	0	有	有	有	
52	0	0	0	0	0	0	0	0	0	0	0	0	0	有	有	
53	有	有	有	有	有	有	有	有	有	有	有	有	有	有	有	
54	0	0	0	0	0	0	0	0	0	0	0	0	0	有	有	
55	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
56	0	0	0	0	0	0	0	0	0	0	0	0	0	有	有	
57	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
58	0	0	0	0	0	0	0	0	0	0	0	0	0	0	有	

事例 NO	1	2	3	4	5	6	7	8	9	10	11	12	13	85 パー セン タイ ル 速 度	平 均 値	備 考
59	0	0	0	0	0	0	0	0	0	0	0	0	0	0	有	
60	有	有	有	有	有	有	有	有	有	有	有	有	有	有	有	
61	有	有	有	0	有	有	有	有	有	有	有	有	有	有	有	

Appendix6. モデル選択指標の算出結果

本文では割愛したが、本研究では、モデル選択の際の参考としてAIC、予測二乗誤差を各モデル、区間別に算出した。ここでは、AIC、予測二乗誤差の定義と算出結果について整理する。

(1) AIC

AICを用いて異なるモデルを比較するとき次のルールが成立する。AICは小さな値は大きな値よりも良く当てはまっているモデルを示す。この基準の非常に役立つ性質は、モデル内の推定パラメータ数で補正しているため、異なるパラメータ数を持つモデル間での公平な比較が出来ることである。AICは、最大対数尤度に対してパラメータの数だけ、ペナルティを課したものとなっている。一般論として、パラメータを増やしてモデルを複雑にするほど、推定に用いたデータに対する当てはまりはよくなるが、複雑にしすぎると、ホワイトノイズのような不規則変動の実現値にも無理に適合されたモデルが推定され、将来の未観測データに対する予測精度が逆に悪くなるということが起こりうる。パラメータの次元を小さく抑えたシンプルなモデルは、計算時間を短縮するというメリット以外にも、このようなモデルの過適合を回避するという意味合いを持っている。時系列データに対する本論文のように食事帯が散漫な状態である場合のAICは下式で定義される。

$$AIC = -\frac{1}{n} \left[-2n \log L_d + 2(r+q) \right]$$

ここで、 n は、時系列データの観測値数で、 $\log L_d$ は状態空間モデリングで最大化される散漫尤度関数の値である。 q は状態初期値の数、そして、 r は分析で推定される攪乱項分散の総数である。一般には n で割る習慣はないが、時系列解析では観測時点数で割ることが多い。上式に従い、本論文の研究対象(61事例, 3721区間)のAICの統計量について、表3に整理する。

表 3 モデル別の AIC 算出結果 (61 事例)

モデル番号	平均	最小	25 パーセン イル値	50 パーセン イル値	75 パーセン イル値	最大
1	5.509	0.009	5.027	5.372	6.210	8.290
2	5.376	0.081	4.987	5.335	6.092	8.264
3	5.591	0.015	5.051	5.404	6.255	8.559
4	5.589	0.017	5.048	5.403	6.243	8.422
5	5.568	0.017	5.037	5.393	6.199	8.560
6	5.564	0.062	5.041	5.398	6.183	8.433
7	5.435	0.083	5.001	5.355	6.093	8.261
8	5.425	0.085	5.003	5.341	6.097	8.082
9	5.492	0.092	5.006	5.352	6.088	8.268
10	5.425	0.086	4.990	5.333	6.090	8.268
11	5.487	0.094	5.004	5.345	6.086	8.266
12	5.496	0.095	5.014	5.356	6.089	8.273
13	5.489	0.096	5.011	5.349	6.087	8.271

(2) 平均二乗誤差

データにより適合したモデルを構築するために、モデルの残差を調べることは有用である。そのため、モデルによって得られる1期先予測値と実際の観測値との誤差(1期先予測誤差 ε_t)についても確認している。ただし、誤差が非常に大きくなる散漫な初期状態を除いた時点 $t = 48, \dots, n$ について平均を取っている。下式に従い、本論文の研究対象(61事例, 3721区間)の予測誤差の平均二乗誤差の統計量について、表4に整理する。

$$\text{予測誤差の平均二乗誤差} = \sum_{t=48}^n \frac{\varepsilon_t^2}{n}$$

表4 モデル別の平均二乗誤差(61事例)

モデル番号	平均	最小	25パーセント イル値	50パーセント イル値	75パーセント イル値	最大
1	50.154	2.962	27.001	36.906	54.763	1874.332
2	49.689	3.671	32.320	42.060	58.905	388.925
3	49.823	3.682	27.047	37.131	54.735	6862.140
4	46.539	3.275	27.060	37.323	54.847	918.231
5	156.149	2.962	25.977	35.583	54.099	242135.300
6	44.804	3.794	25.875	35.060	53.115	417.219
7	49.928	4.293	32.229	41.937	59.053	970.430
8	51.535	5.755	32.350	42.315	60.104	839.046
9	50.902	2.924	32.528	42.587	60.713	389.149
10	63.211	3.161	31.300	40.679	58.045	18394.842
11	50.946	3.025	32.699	42.495	60.318	390.642
12	51.206	3.613	32.792	42.982	60.858	392.496
13	51.246	3.371	32.881	43.208	60.315	395.936


Appendix7. 山形県国道47号における立ち往生事例の基礎情報

5章で詳細に分析を行った山形県国道47号における立ち往生事例について、検証対象範囲の基礎情報(区間別標高、傾斜角度、土地利用、規制速度、交差点数)及び検証期間の気象状況(気温、降雪量、6時間前累積降雪量)、交通状況(プローブ車両平均速度、85パーセンタイル速度、プローブ車両通過台数)を整理する。


(1) 基礎情報

図A-3は、検証対象範囲の区間別の最低標高を示したものである。当該区間は上り方向から見ると緩やかに標高が高くなっており、No.55付近から急に標高が高くなっている。図A-4は、検証対象範囲の区間別の最低勾配を示したものである。道路勾配データが入手出来ない場合、おおむね道路の勾配を示す情報として、区間別の最低勾配を用いている。No1~30間は、山道であるため、急な勾配が連続している。


図A-5は、検証対象範囲の区間別の土地利用区分を示したものである。No1~30間は、山道であるため、森林が大きな割合を示しているが、No.35付近に古口駅があるため、道路、田、建物用地の割合が大きくなっている。図A-6は、検証対象範囲の区間別の規制速度を示したものである。ほとんどの区間で規制速度は50km/hであるが、No34とNo35のみ40km/hである。図A-7は、検証対象範囲の区間別の交差点数を示したものである。図中の青線は信号がある区間、灰色の線は交差点がある区間を示している。対象区間は、No1~30が山道区間で、以降の区間が古口駅付近の生活圏である。なお、区間別の最低標高、最低勾配、土地利用区分については、国土交通省国土地理院HPよりダウンロードできる国土数値情報を用いた。規制速度と交差点数、信号有無については、Google mapのストリートビュー機能を用いて、目視で整理した。




図A-3 検証対象範囲の区間別の最低標高(山形県国道47号)




図A-4 検証対象範囲の区間別の最小傾斜角度(山形県国道47号)



図A-5 検証対象範囲の区間別の土地利用区分(山形県国道47号)



図A-6 検証対象範囲の区間別の規制速度(山形県国道47号)



図A-7 検証対象範囲の区間別の交差点数(山形県国道47号)

(2) 状況分析

1) 気象状況

検証対象期間の気象状況の変化とプローブ車両データを用いた交通状況の変化について整理する。具体的には、気温、降雪量、6時間前累積降雪量、積雪深さの時間変化及び、区間別時間帯別のプローブ車両の通過台数、空間平均速度、85パーセンタイル速度について整理する。

図A-8は、検証対象期間の気温の時間変動を示したものである。図中には、凍結の恐れがある摂氏0°C、強風、橋梁の場合等、道路特性によっては凍結の恐れがある摂氏2°Cに赤線を引いている。立ち往生発生当日である1月25日(金)は、前日から0°Cを下回っていた。徐々に気温が上がっていく時間帯に立ち往生が発生した。

図A-9は、検証対象期間の降雪量の時間変動を示したものである。対象区間では、検証期間内に時々降雪を観測し、最大で5cm/h以上の降雪を観測している。立ち往生発生当日である1月25日(金)の早朝に1cm程度の降雪を観測したが、その後15時頃までは降雪を観測しなかった。立ち往生が発生したとされる12時頃には降雪は観測されていない。


図A-10は、検証対象期間における6時間前からの累積降雪量の時間変動を示したものである。図A-10を見ると6時間前からの累積降雪量は、立ち往生発生前日である1月24日(木)の昼頃にピークを観測し、10cm/6h以上を観測した。立ち往生が発生したとされる12時頃には6時間前からの累積降雪量は0cm/6hであった。

図A-11は、検証対象期間は積雪深さの時間変動を示したものである。1月20日(日)時点で100cm近くの積雪深さが観測されている。1月22日(火)や1月24日(木)にもまとまった積雪があり、立ち往生発生当日である1月25日(金)には、100cmを超えている。


図A-8~図A-11中には、縦線で断続的に立ち往生が発生した時間(1月25日 12:00頃)と当該区間が通行止めとなった時間帯(1月25日 14:00~17:30)を示している。




図A-8 検証期間の気温の時間変化(山形県国道47号)



図A-9 検証期間の降雪量の時間変化(山形県国道47号)



図A-10 検証期間の6時間前累積降雪量の時間変化(山形県国道47号)



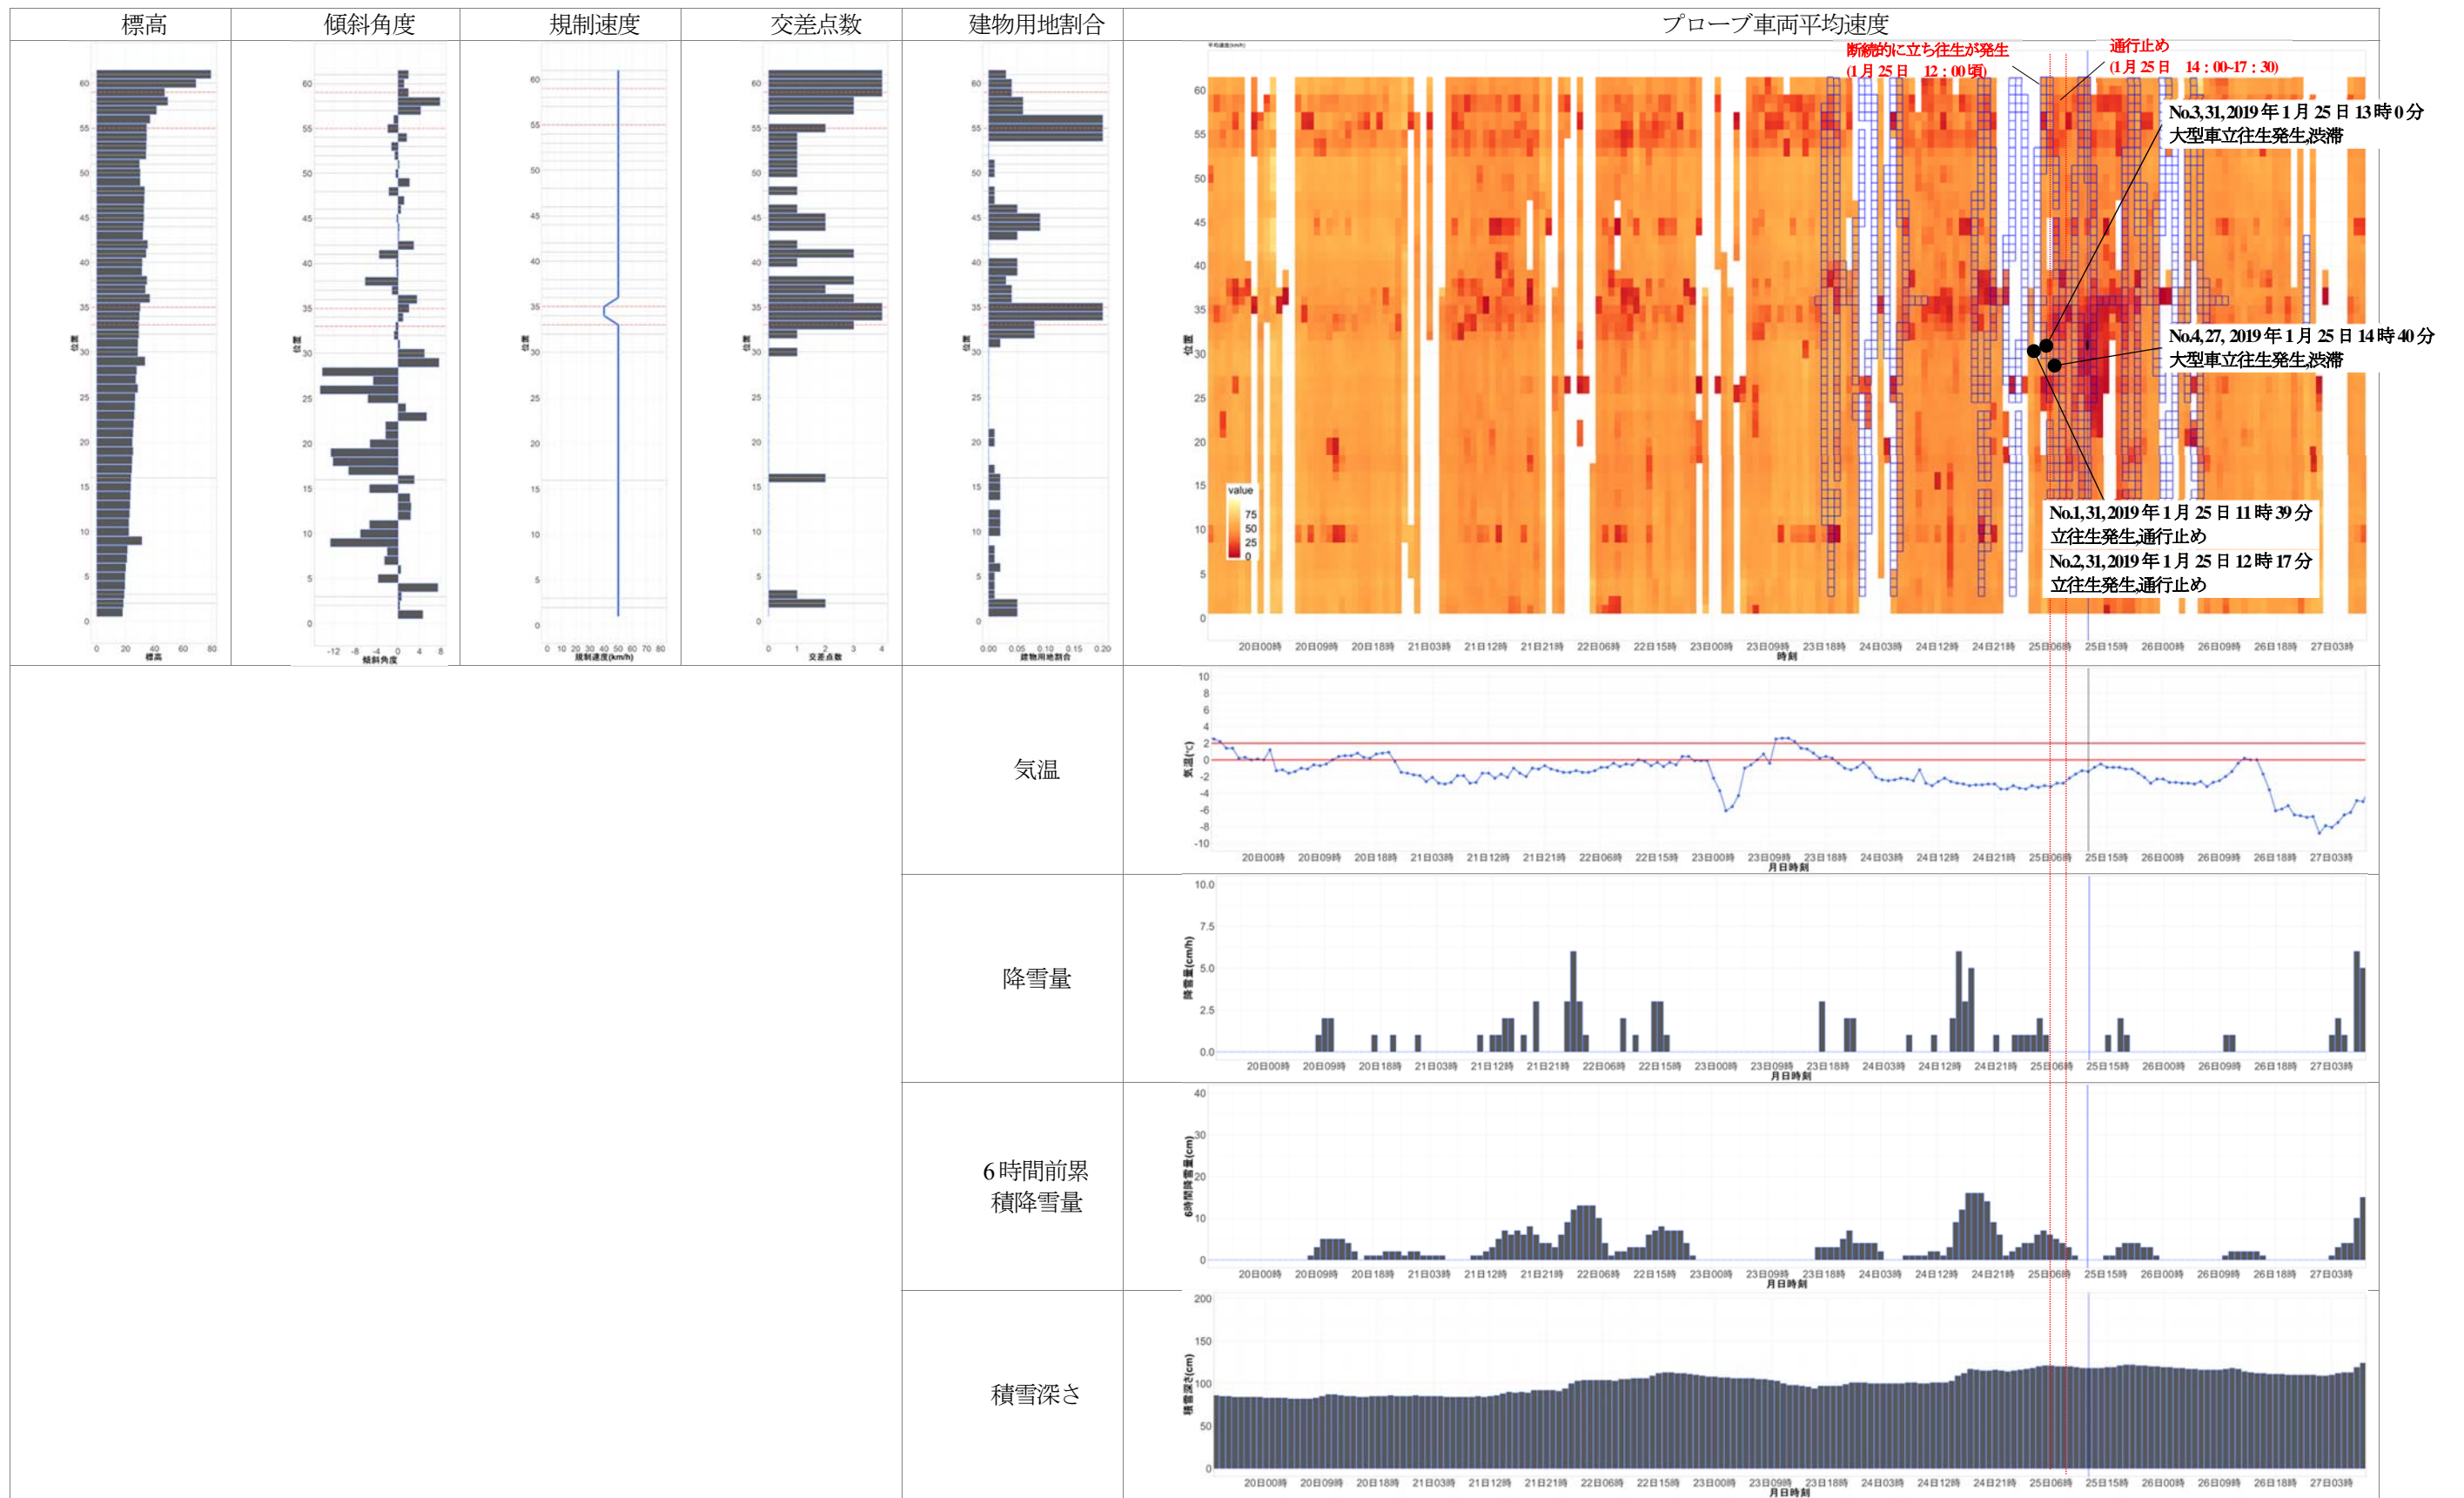
図A-11 検証期間の積雪深さの時間変化(山形県国道47号)

2) 交通状況

(a) 区間別プローブ車両空間平均速度

図A-12は、分析対象における区間別の時間帯別プローブ車両の空間平均速度の時空間変化と気象条件と幾何構造の関係を示した図である。縦軸は、区間の位置を表し、道路の上り方向(西から東)に向かって順に1-61の番号を振っている。空間方向の軸に合わせて区間別の標高、傾斜角度、規制速度、交差点数、建物用地割合を整理し、時間軸に合わせて気温、降雪量、6時間前累積降雪量、積雪深さとの関係を見比べることが出来るように整理を行っている。図中には、立ち往生が発生した時間と場所を示している。図中の白色はプローブ車両が未観測(0台/h)であったことを示している。また、図中の青枠は除雪車が稼働している時間、区間を表している。縦線で断続的に立ち往生が発生した時間(1月25日 12:00頃)と当該区間が通行止めとなった時間帯(1月25日 14:00-17:30)を示している。

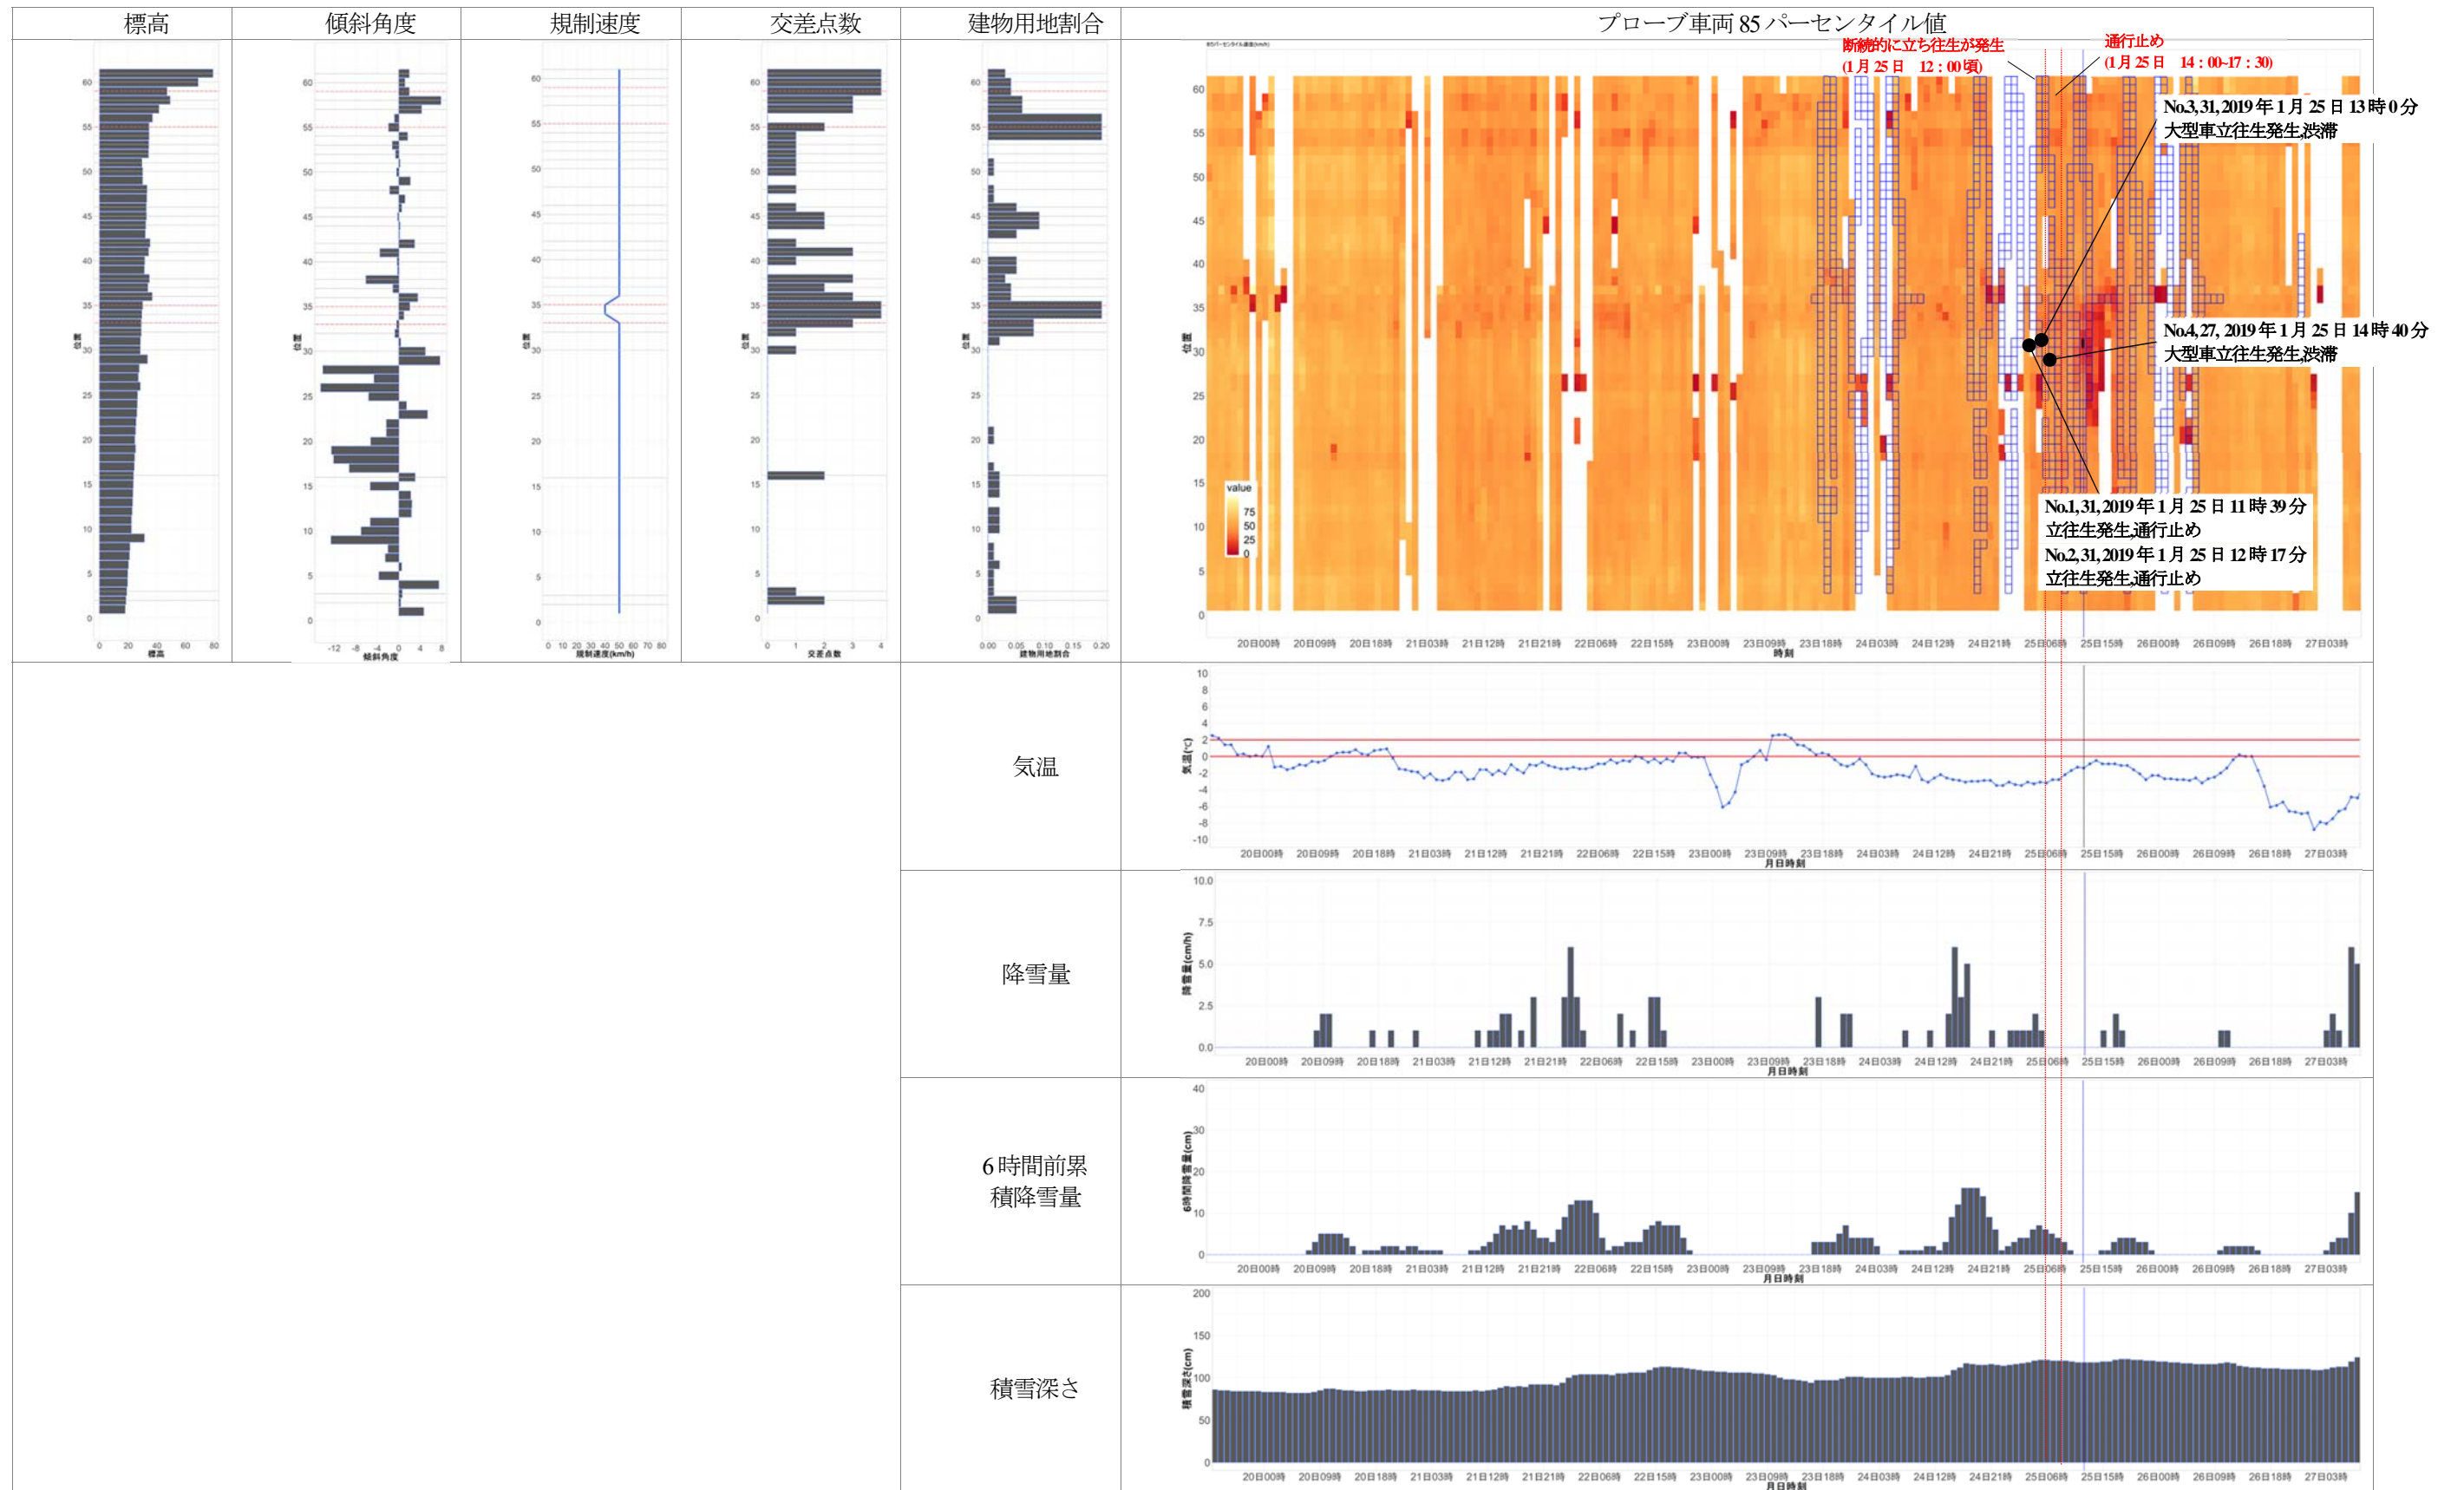
図A-12中のNo.10付近、35付近、55付近が比較的低い速度が観測される傾向にある。No.10付近は傾斜角度が急で、No.35付近は、交差点数が多く、建物用地割合が高い区間であり、規制速度も他の区間と比べて10km/h低く設定されている。No.55付近は、傾斜角度が急で、交差点数が多く、建物用地割合が高い区間が高い区間である。プローブ車両の平均速度が低い傾向にある区間は、一般的に車両が速度を落として走行する可能性が高い区間の特徴を有している区間である。立ち往生が発生した当日である1月25日は、立ち往生発生箇所において、立ち往生発生後に平均速度が大きく低下している。立ち往生発生後は、立ち往生発生箇所を中心に速度が低い区間が拡大している。立ち往生や通行止めの影響が徐々に路線全体が波及していった様子が見て取れる。立ち往生発生翌日には、平均速度は立ち往生発生前と同程度に回復している。



図A-12 区間別時間別プローブ車両平均速度と気象条件と幾何構造の関係

(b) 区間別プローブ車両 85 パーセンタイル速度

図A-13は、分析対象における区間別の時間帯別プローブ車両の85パーセンタイル速度の時空間変化と気象条件と幾何構造の関係を示した図である。図A-12と図A-13を比較すると、図A-13に示したプローブ車両の85パーセンタイル速度の方が、時空間の変化が小さくなっている傾向にある。これは、コンセプトで示したとおり、85パーセンタイル速度に着目することは、その区間をスムーズに走行している車両に着目していることを意味しているため、交差点や沿道施設等の影響をある程度除外出来ていると考えられる。立ち往生発生後は、平均速度と同様に立ち往生発生箇所を中心に速度が低い区間が拡大している。立ち往生や通行止めの影響が徐々に路線全体が波及していった様子が見て取れる。立ち往生発生翌日には、85パーセンタイル速度は回復しており、この傾向も平均速度と同様である。この整理結果からも、85パーセンタイル速度に着目することで、研究の目的に合った速度低下のみを検知できる可能性が高くなっていることを示している。



図A-13 区間別時間別プローブ車両 85 パーセンタイル速度と気象条件と幾何構造の関係

(c) 区間別プローブ車両通過台数

図A-14は分析対象における区間別の時間帯別のプローブ車両通過台数の時空間変化と気象条件と幾何構造の関係を示したものである。図A-14を見ると、夜間は路線全体で、通行台数が少なく、0台であることが多い。交通量は速度とは違い、区間による差は大きくなく、時間帯による差の方が大きい。除雪の稼働状況を見ると、この時間帯に除雪車両が除雪作業を行っていることが多い。立ち往生発生当日は、通常時よりも通行台数が若干少ない傾向にあり、翌日は若干通行台数が多い傾向にあることがわかる。立ち往生当日の移動を避けた交通が翌日にタイムシフトしていると推察される。

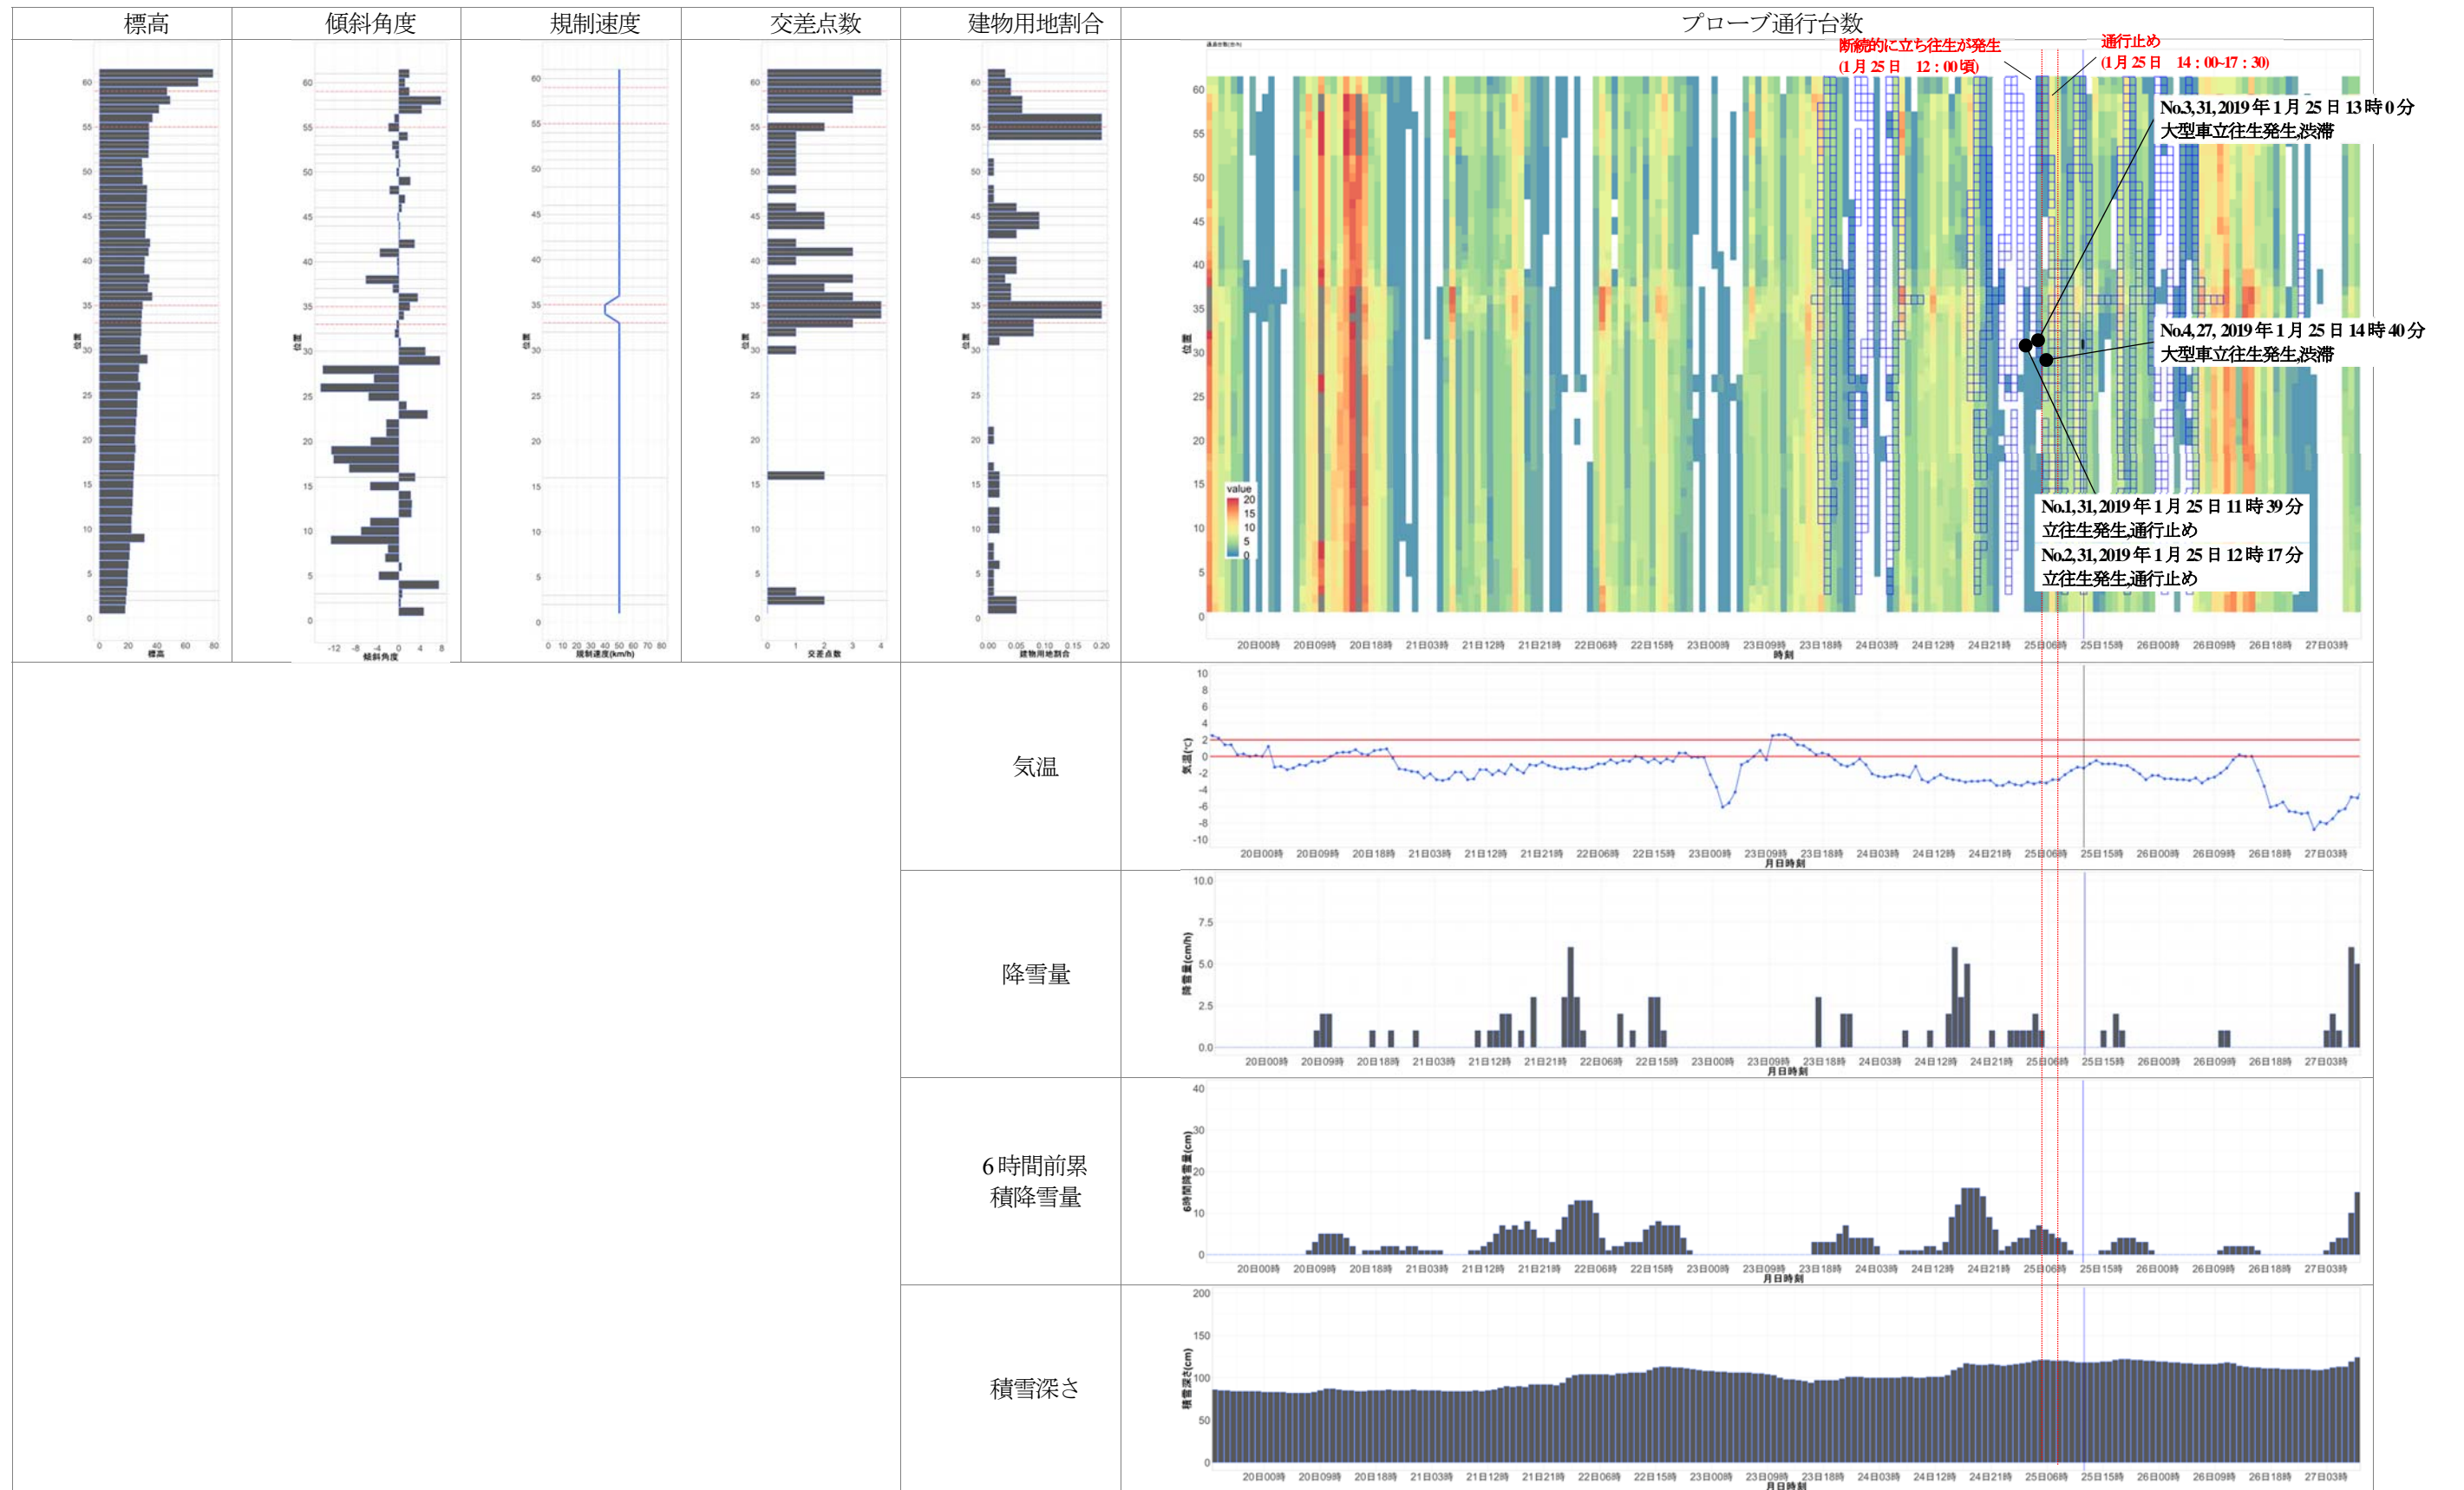


図 A-14 区間別時間別プローブ車両通過台数と気象条件と幾何構造の関係

Appendix8. 福井県国道8号における立ち往生事例の基礎情報

5章で詳細に分析を行った福井県国道8号における立ち往生事例について、検証対象範囲の基礎情報(メッシュ別標高、傾斜角度、土地利用、規制速度、交差点数)及び検証期間の気象状況(気温、降雪量、6時間前累積降雪量)、交通状況(プローブ車両平均速度、85パーセンタイル速度、プローブ車両通過台数)を整理する。

(1) 基礎情報

図A-15は、検証対象範囲の区間別の最低標高を示したものである。No.1~55付近は標高10m程度であるが、No.55付近から山間部となるため、標高が高くなっている。


図A-16は、検証対象範囲の区間別の最低勾配を示したものである。道路勾配データが入手出来ない場合、おおむね道路の勾配を示す情報として、区間別の最低勾配を用いている。当該区間はNo.1~55付近は平坦であるが、No.53付近で下り勾配があり、No.55付近から最大4%程度の上り勾配が続いている。

図A-17は、検証対象範囲の区間別の土地利用区分を示したものである。No.1~45間は市街地であるため、建物用地の割合が大きいが、No.45以降は、徐々に郊外部となるため、田や森林の割合が増加し、建物用地の割合が小さくなっている。


図A-18は、検証対象範囲の区間別の規制速度を示したものである。No.1~45の規制速度は60km/hであるが、No.45以降は50km/hである。また、この地点から車線数が4車線から2車線に減少している。

図A-19は、検証対象範囲の区間別の交差点数を示したものである。山形の事例と比較すると交差点が多く、交差点を含んでいる区間が多い。図A-15~図A-19の図中の縦の青線は信号がある区間、灰色線は交差点がある区間位置を示している。また、赤線は立ち往生が発生した区間を示す。


当該区間は、大きく分けるとNo.1~45が中心地、No.55以降が山間部、No.45~55郊外部のような特性を持っている。山形の事例は対象区間全体が郊外部や山間部であったが、当該事例は、中心市街地を含んでいるため道路特性が大きく異なる。




図A-15 検証対象範囲の区間別の最低標高(福井県国道8号)




図A-16 検証対象範囲の区間別の最小傾斜角度(福井県国道8号)



図A-17 検証対象範囲の区間別の土地利用区分(福井県国道8号)



図A-18 検証対象範囲の区間別の規制速度(福井県国道8号)



図A-19 検証対象範囲の区間別の交差点数(福井県国道8号)

(2) 状況分析

1) 気象状況


先の事例と同様に、検証対象期間の気象条件の変化とプローブ車両データによる交通状況の変化について整理する。図中の凡例、整理方法は同様である。

図A-20は、検証対象期間の気温の時間変動を示したものである。当該区間では、立ち往生が長時間化した2月6日の6:00頃が最も気温が低く、 -4°C を観測している。


図A-21は、検証対象期間の降雪量の時間変動を示したものである。2月1日から2月3日午前中の間は降雪が観測されなかったが、2月3日午後から2月5日午前まで複数回まとまった降雪を観測している。2月5日日中には降雪が観測されていないが、2月5日夜から連続してまとまった量の降雪を観測し、立ち往生が発生した2月6日の午後まで雪が降り続き、最大で 7.5cm/h 以上の降雪が観測されている。

図A-22は、検証対象期間における6時間前からの累積降雪量の時間変動を示したものである。を見ると6時間前からの累積降雪量は、2月5日と2月6日にまとまった量の降雪を観測し、立ち往生が発生した2月6日に最大 $30\text{cm}/6\text{時間}$ を観測した。


図A-23は、検証対象期間は積雪深さの時間変動を示したものである。2月1日~2月3日までは、変動幅は少なく、 50cm 以下となっている。2月5日から急激に積雪深さの値が大きくなり、立ち往生が発生した2月6日がピークとなり、福井市内で、37年ぶりに 130cm を超過した。




図A-20 検証期間の気温の時間変化(福井県国道8号)



図A-21 検証期間の降雪量の時間変化(福井県国道8号)



図A-22 検証期間の6時間前累積降雪量の時間変化(福井県国道8号)



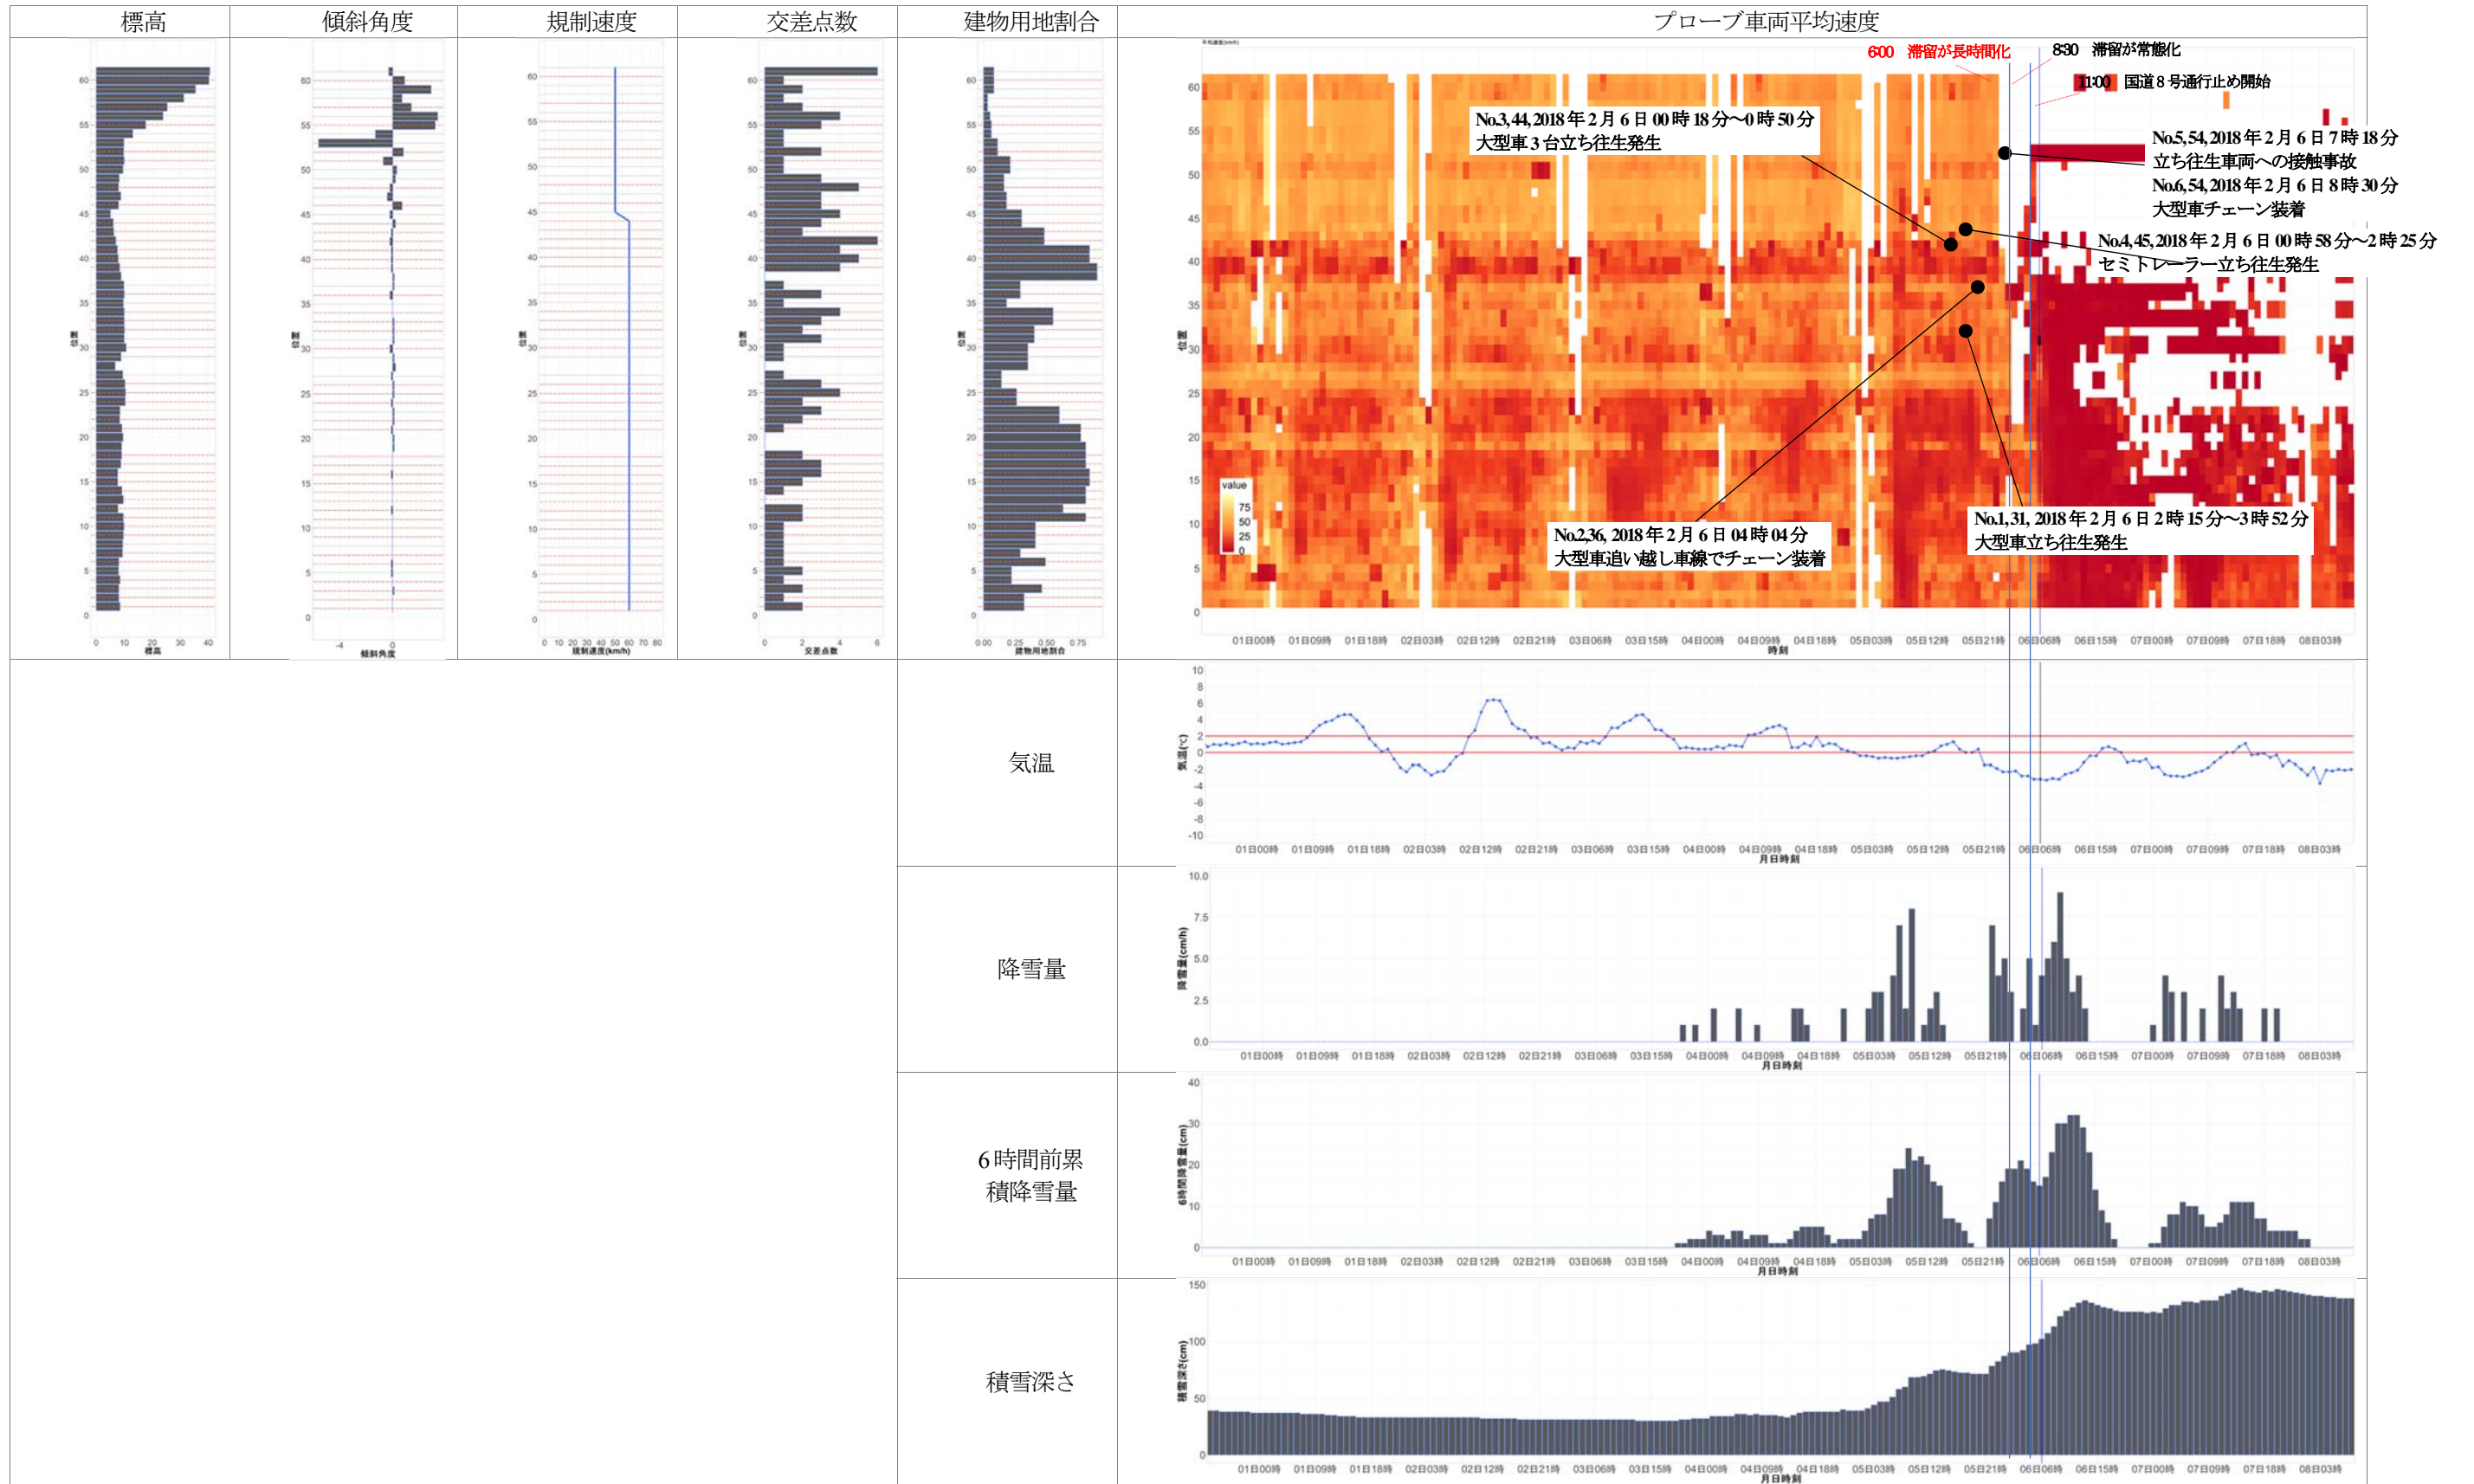
図A-23 検証期間の積雪深さの時間変化(福井県国道8号)

2) 交通状況

(a) 区間別プローブ車両空間平均速度

図A-24は、分析対象における区間別の時間帯別プローブ車両の空間平均速度の時空間変化と気象条件と幾何構造の関係を示した図である。道路の上り方向(南から北)に向かって順に1~61の番号を振っている。図中の縦線は、滞留が長時間化した時間(2月6日6:00頃)と常態化した時間(2月6日8:30頃)、国道8号線が通行止めとなった時間帯(2月6日12:00頃)を示している。

立ち往生発生前である2月1日~4日の速度は中心地に位置する区間(No.1~45)で、郊外部に位置する区間(位置45~61)よりも低い速度が観測される傾向にある。特に交差点が多い、No.10~20付近、No.40付近で低い速度を観測することが多い。立ち往生が発生した当日である2月6日は、全区間において、平常期間と比較して濃い赤色が目立ち、平均速度が大きく低下しており、路線全体で平常時とは異なる状況であったことがわかる。立ち往生発生後は、立ち往生発生箇所を中心に速度が低い区間が拡大している。立ち往生や通行止めの影響が徐々に路線全体が波及していったこと様子が見て取れる。立ち往生発生後から2月9日まで、平均速度が回復することではなく、異常な状態が長時間継続したことが分かる。



図A-24 区間別時間別プローブ車両平均速度と気象条件と幾何構造の関係

(b) 区間別プローブ車両 85 パーセントイル速度

図 A-25 は、図 A-26 と同様にして、分析対象における区間別の時間帯別プローブ車両の 85 パーセントイル速度の時空間変化と気象条件と幾何構造の関係を示した図である。

図 A-25 と図 A-26 を比較すると、に示したプローブ車両の 85 パーセントイル速度の方が、時空間の変化が小さくなっている傾向にある。これは、コンセプトで示したとおり、85 パーセントイル速度に着目することは、その区間をスムーズに走行している車両に着目していることが多いため、交差点や沿道施設等の影響をある程度除外出来ていると考えられる。ただし、山形の事例と比較して、区間内に交差点が多いため、No.10~20 付近、No.40 付近では日中低い速度を観測することがある。また、当該路線が県内の中心部を通過しているため、時間帯によっては交通密度が高く、交通条件の影響を完全に除外することが出来ていないため、区間全体の 85 パーセントイル速度が低下する時間帯も存在する。立ち往生発生後は、平均速度と同様に立ち往生発生箇所を中心に速度が低い区間が拡大している。立ち往生や通行止めの影響が徐々に路線全体が波及していったこと様子が見て取れる。

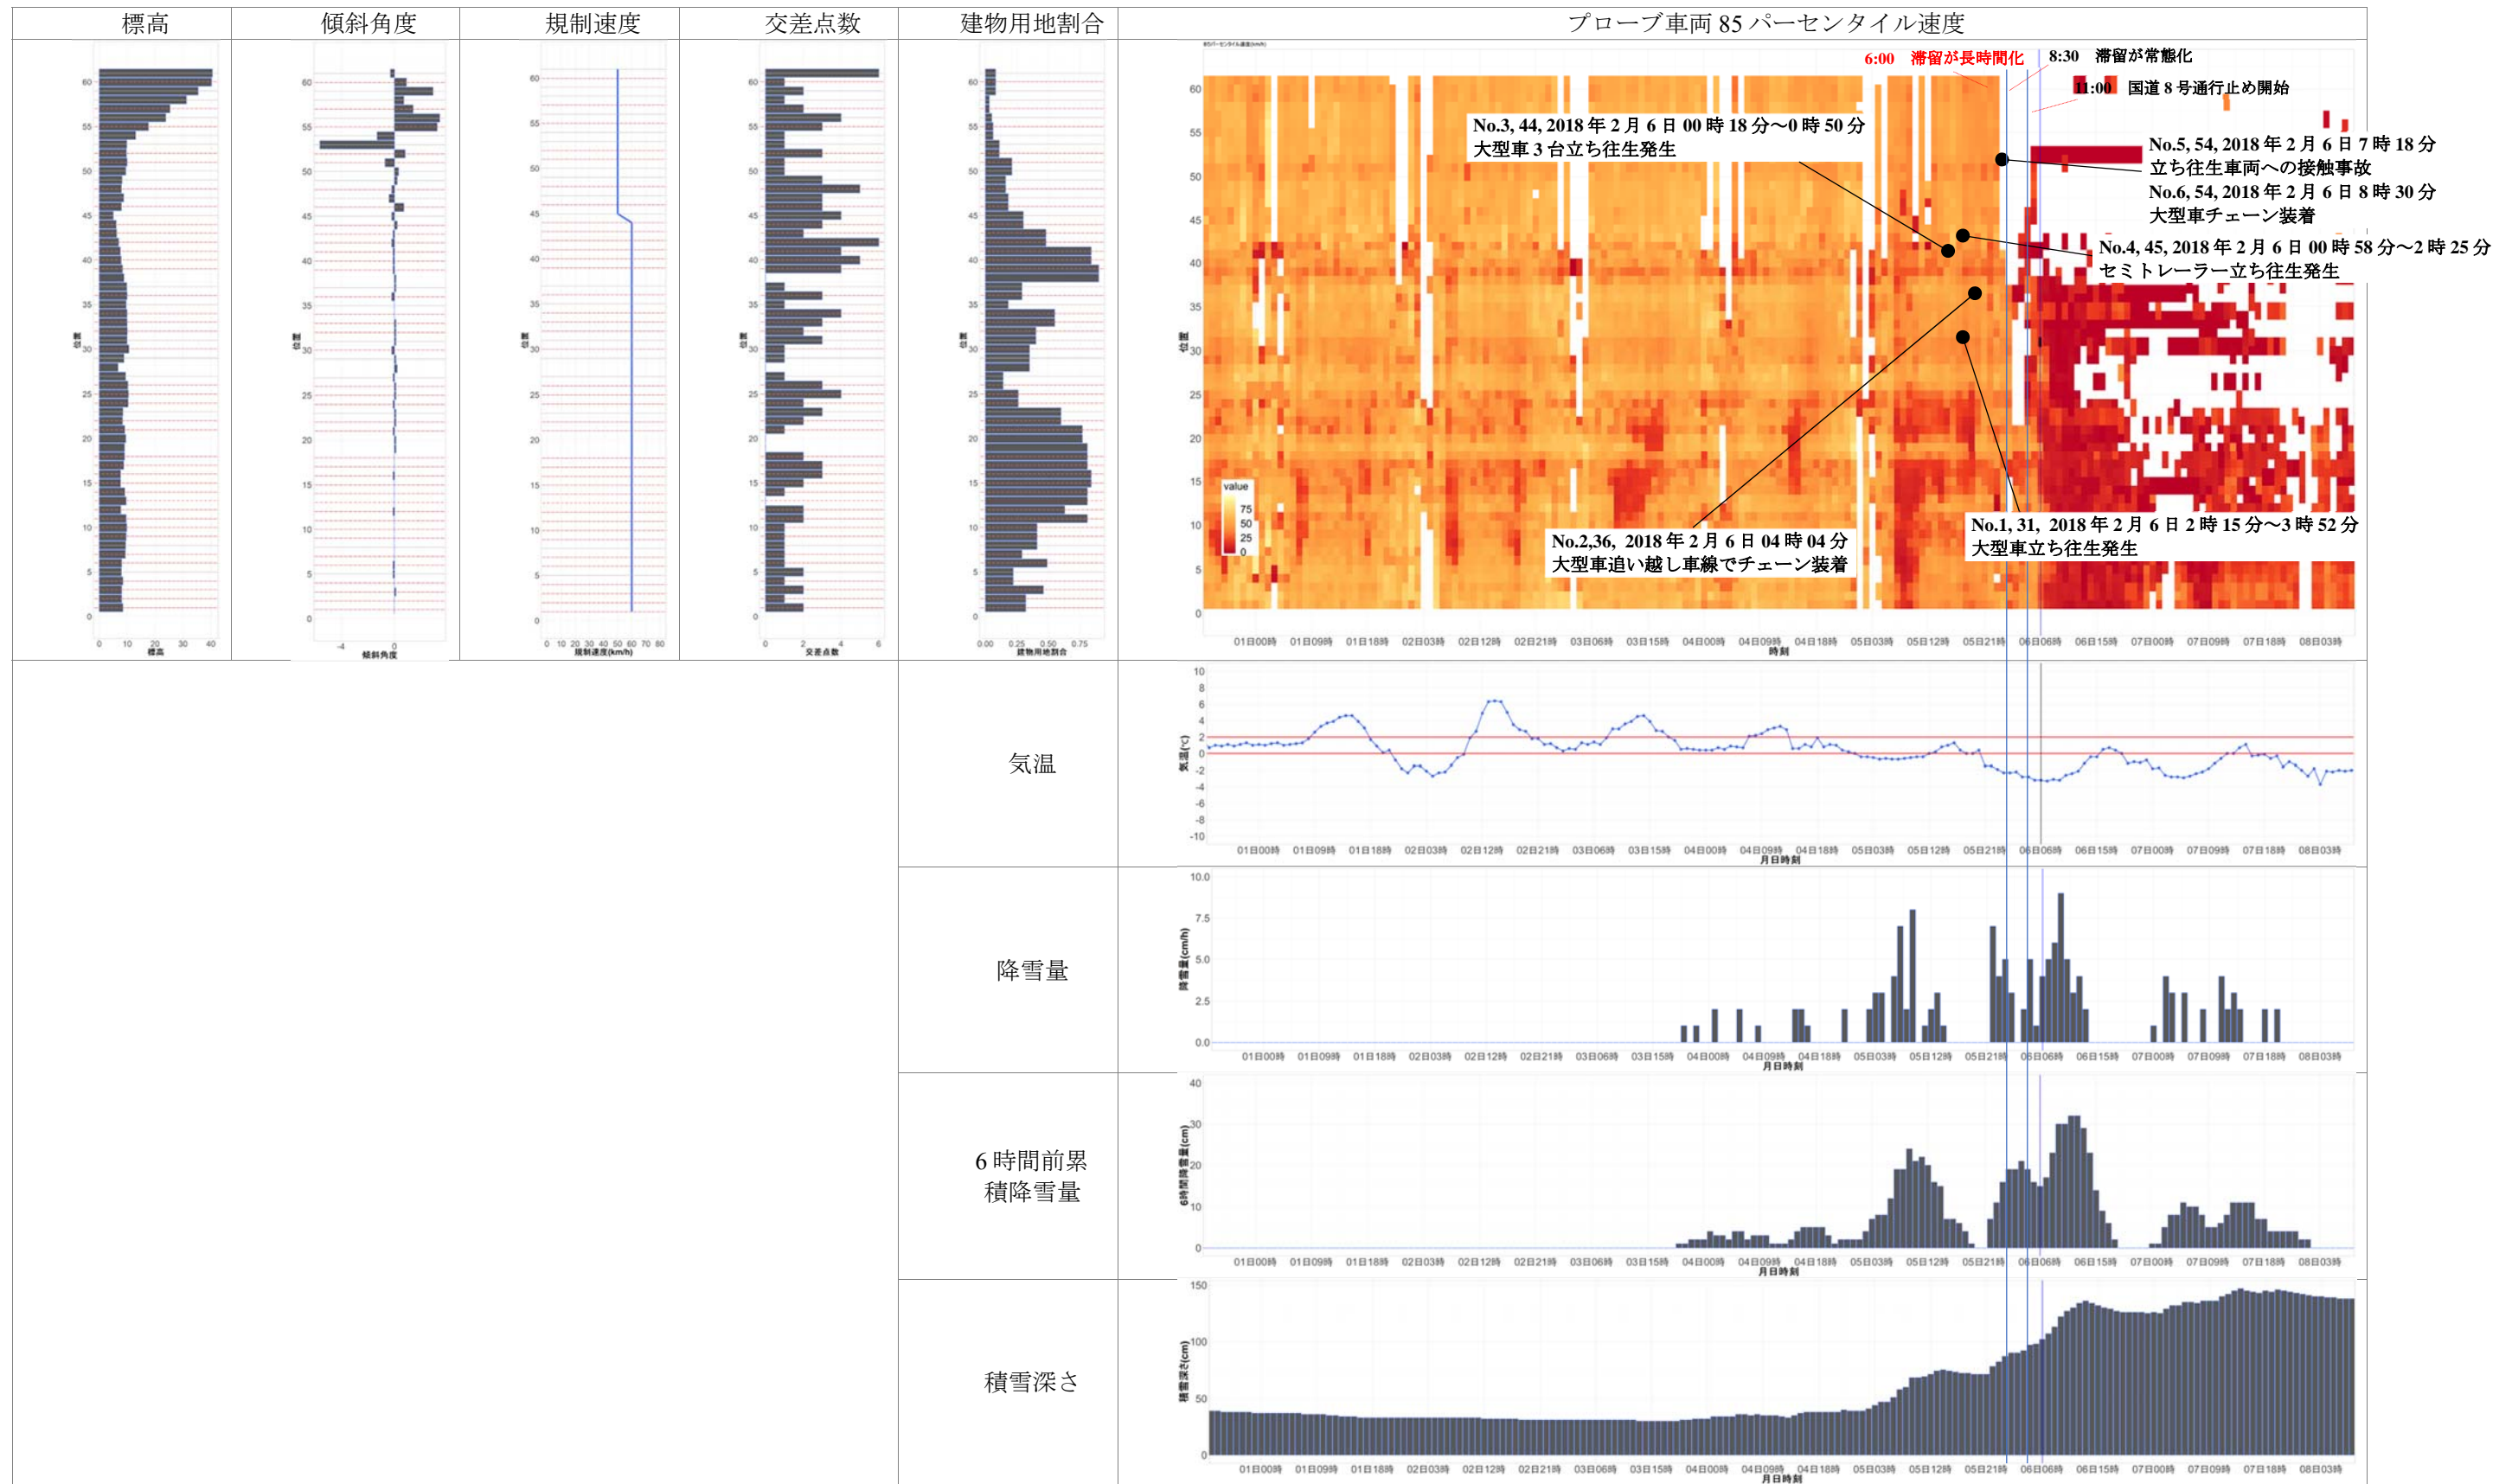
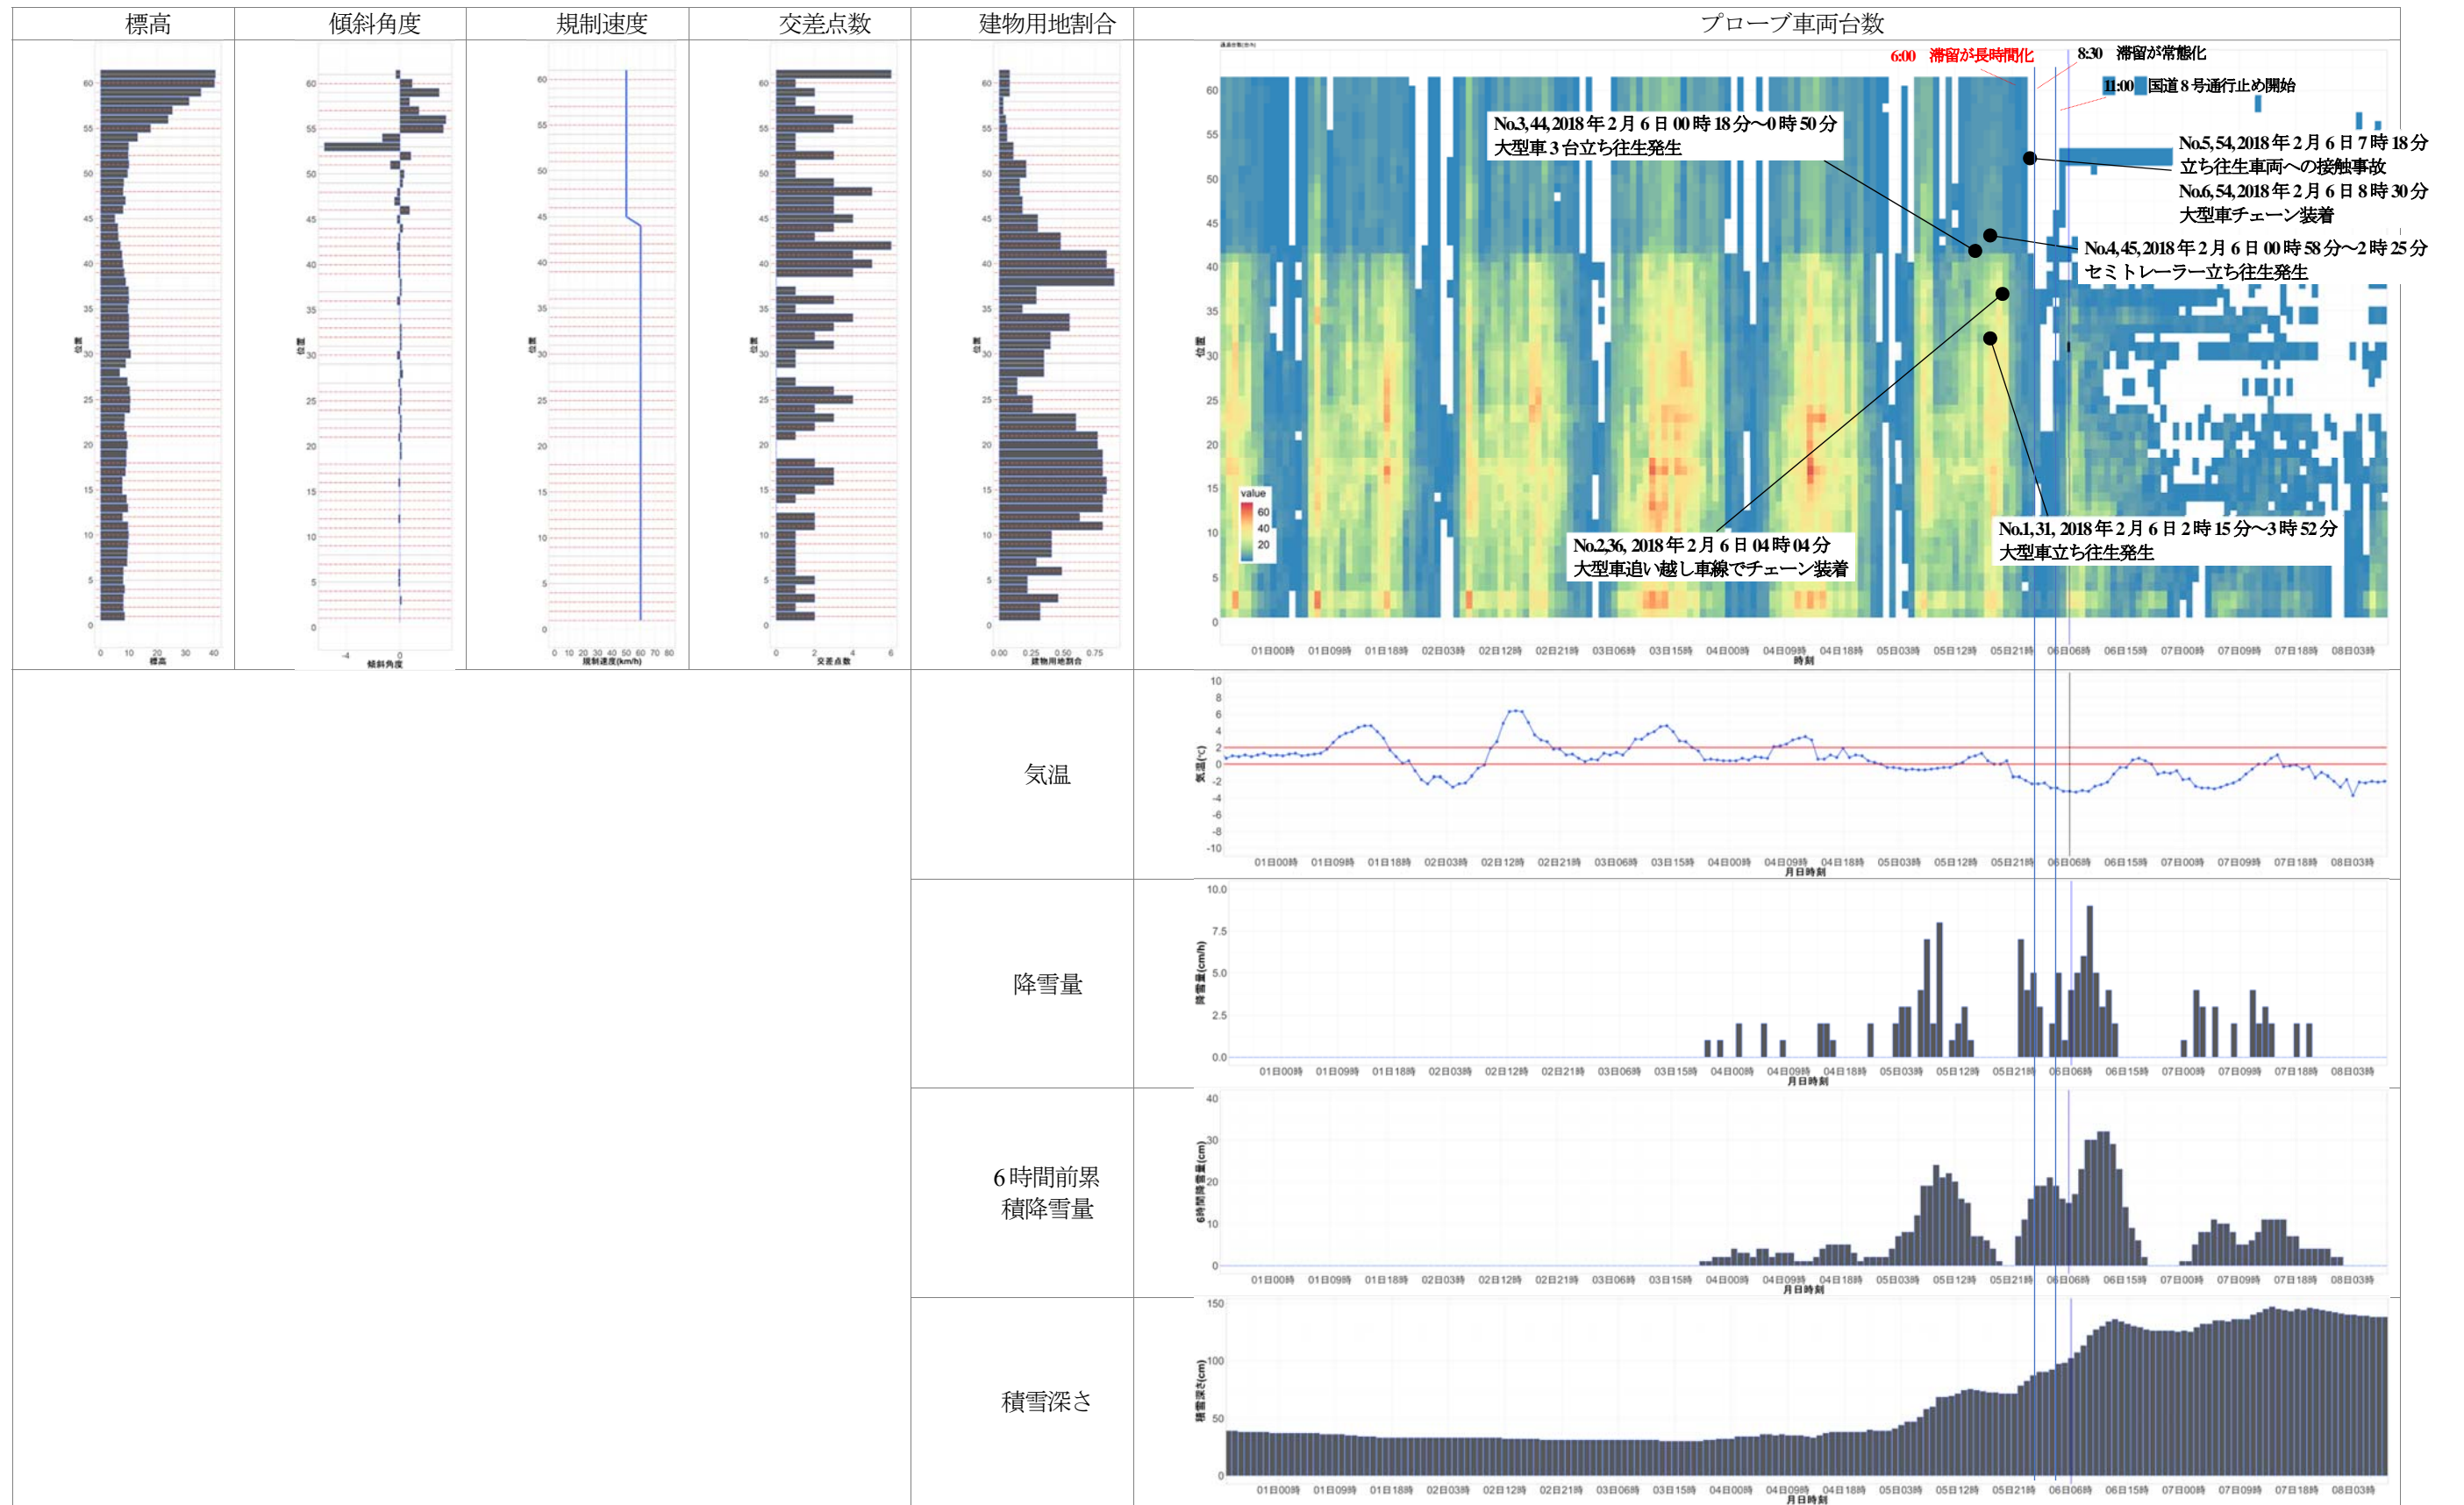


図 A-25 区間別時間別プローブ車両 85 パーセントイル速度と気象条件と幾何構造の関係

(c) 区間別プローブ車両通過台数

図 A-26 は、図 A-25 と同様にして、分析対象における区間別の時間帯別のプローブ車両通過台数の時空間変化と気象条件と幾何構造の関係を示したものである。図中に青色はプローブ車両通過台数が少なく、赤色はプローブ車両通過台数が多い区間と時間を表している。

図 A-26 を見ると、No.45 手前でプローブ車両通過台数が少なくなっている。これは、この区間内に分岐部が存在しており、一部の車両が分岐方向を選択しているためである。夜間は白色が目立ち、プローブ車両通過台数が観測できていないことが多い。立ち往生発生当日は、プローブ車両通過台数が観測できない区間が徐々に拡大し、立ち往生と通行止めの影響による 8 号線が通行できなくなっていく様子と、No.54 の区間のように立ち往生に巻き込まれて長時間、区間の状況が変わっていない状況も見て取ることが出来る。



図A-26 区間別時間別プローブ車両通過台数と気象条件と幾何構造の関係