

## 道路政策の質の向上に資する技術研究開発

## 【研究状況報告書（２年目の研究対象）】

①研究代表者		氏 名（ふりがな）		所 属		役 職				
		高橋 翔 (たかはし しょう)		北海道大学 大学院工学研究院		准教授				
②研究 テーマ	名 称	デジタルツインによる冬期道路交通マネジメントシステムの技術開発								
	道路行政 技術開発 ニーズ	No.	SDx1,SE6,SDs8		政策 テーマ	インフラ分野のDX				
		項目名	ETC2.0とAIを活用した交通マ ネジメントサービス			経済の好循環を支える 基盤整備				
			道路交通マネジメントの実践・ 高度化を可能とする技術  被災後の交通状況をリアルタ イムに把握し, 情報提供できる 技術			防災・減災が主流となる 社会の実現				
③研究経費(単位:万円)		令和５年度		令和６年度		令和７年度				
		2,999		2,479		2,500				
※R5 は精算額、R6 は受託額、R7 は計画額を記入。端数切捨。						7,978				
④研究者氏名 (研究代表者以外の共同研究者の氏名、所属・役職を記入。なお、記入欄が足りない場合は適宜追加下さい。)										
氏 名			所属・役職							
八木 雅大			北海道大学 工学研究院 博士研究員							
吉井 稔雄			北海道大学 工学研究院 教授							
萩原 亨			北海道大学 名誉教授、(一財)北海道道路管理技術センター 顧問							
有村 幹治			室蘭工業大学 工学研究科 教授							

浅田 拓海	室蘭工業大学 工学研究科 准教授
Tran Vinh Ha	室蘭工業大学大学院 工学研究科 博士研究員
永田 泰浩	(一社)北海道開発技術センター 地域政策研究所 次長
大井 元揮	(一社)北海道開発技術センター 地域政策研究所 室長
芝崎 拓	(一社)北海道開発技術センター 調査研究部 上席研究員
小西 信義	(一社)北海道開発技術センター 調査研究部 主任研究員
丹治 和博	(一財)日本気象協会 北海道支社 統括主幹
小松 麻美	(一財)日本気象協会 北海道支社 主任技師
槌本 陽	(一財)日本気象協会 北海道支社
山本 郁淳	(株)ドーコン交通事業本部 交通部 都心交通企画室 室長
内藤 利幸	(株)ドーコン交通事業本部 防災保全部 グループ長
松田 真宜	(株)ドーコン交通事業本部 交通部 グループ長
平川 貴志	(株)ドーコン交通事業本部 交通部 主任技師
高橋 歩夢	(株)ドーコン交通事業本部 防災保全部 主任技師
坂本 信	(株)ドーコン交通事業本部 防災保全部 技師

## ⑤研究の目的

本研究では、サイバー空間に道路API(Application Programming Interface)を備えたデジタルツインによる冬期道路交通マネジメントシステムの構築による、積雪寒冷地における高度な移動支援の実現を目的とする。これにより年間を通じて安全で快適な道路交通の確保が可能となる。

本研究で開発するデジタルツインは、フィジカル空間とサイバー空間で動的データを交換する道路APIを有する。道路・交通・気象の動的データをエッジコンピュータで加工の上、道路APIを通してサイバー空間に送り、シミュレーションを実行。道路交通状況として今後起きることを再び道路APIを通して道路管理者や道路利用者に提供する。

## ⑥これまでの研究経過、目標の達成状況、研究成果

昨年度から大きく次の4つの研究テーマ（【テーマ1】～【テーマ4】）で研究を進めている。

【テーマ1】 冬期の路面や視界等の情報収集・活用に関する技術開発

【テーマ2】 冬期道路交通マネジメントを可能とするデータ集積プラットフォームに関する技術開発

【テーマ3】 冬期道路交通マネジメントのための交通・気象データを利用したシミュレーション等に関する技術開発

【テーマ4】 冬期における人の移動の負担軽減に資する情報提供に関する技術開発

このうち令和6年度は、(1)に関してはデジタルツインのデータ拡充と先読み情報の構築、(2)に関してはプラットフォーム機能の拡充と道路APIの基幹システムの構築、(3)に関しては雪害時における道路利用者の行動変容による効果検証に向けた交通配分シミュレーションの構築とミクロ交通シミュレーションを活用した交通制御支援モデルの精度検証、(4)に関しては冬期道路情報の提供を他地域に展開するための導入マニュアルの内容の検討などを行う。

これらの達成状況について、以降に報告する。

### 1. 【テーマ1】 冬期の路面や視界等の情報収集・活用に関する技術開発

#### (1) デジタルツインのデータ拡充

令和6年度の研究では、昨年度に引き続き、モニタリング可能な車両台数を拡充することにより、デジタルツインが構築可能な時空間解像度を向上させることを目標とした。この目標の達成に向けて、車両台数を次のとおり拡充した。

- ・「特急わっかない号（札幌－稚内）」で、昨年度までの7台から10台に拡充
- ・「えさし号（札幌－枝幸）」で、昨年度までの2台から5台に拡充

モニタリング可能な車両台数計が昨年度から約1.7倍の15台となった。時間解像度の観点では、「札幌－稚内」で最大1.4倍、「札幌－枝幸」で最大2.5倍に向上した。また、空間解像度の観点では、えさし号が、旭川-鬼志別の路線も一部運行しており、車両の拡充によりモニタリングが可能となったことから、路線の数が昨年度から1.5倍となった。

#### (2) 先読み情報の構築

#### ◆気象に関わる先読み情報

##### 【令和6年度に扱う先読み情報（気象）の選定】

令和6年度に実施するデジタルツインで扱う先読み情報のうち、気象に関する情報は表1-1に示す降水量、降雪量、気温、風向風速、視程の5項目とした。このうち、降水量は気象庁の高解像度降水ナウキャストをそのまま活用するが、これ以外の降雪量、気温、風向風速、視程は日本気象協会が独自に解析した気象情報である。なお、降水量、風向風速、視程は令和5年度にもデジタルツインで提供した気象情報である。

表1-1 今年度のデジタルツインで導入する先読み情報（気象）

気象要素	名称	R05年度実施	予測の有無	備考
降水量	高解像度降水ナウキャスト	○	30分先まで	250mメッシュ、5分毎に更新
降雪量	JWA独自メッシュ		6時間先まで	1kmメッシュ、毎時更新
気温	JWA独自メッシュ		6時間先まで	1kmメッシュ、毎時更新
風向風速	JWA独自予測	○	予測発表から69時間先まで	1kmメッシュ相当、12時間毎に更新
視程	JWA独自メッシュ	○	6時間先まで	1kmメッシュ、毎時更新

上述の表1-1の気象情報のほか、次年度にデジタルツインに導入できる可能性のある気象情報として考えられるのは表1-2の吹雪量、路面状態、路面積雪量である。これらの情報は表1-1に示す一般的な気象情報とは異なり、他の気象要素などによる解析から得られる推定値である。

吹雪量----- 地吹雪によって雪面から剥離されて飛ばされる雪の移動量。風向に直交する単位幅当たりの雪の移動量（体積または質量）で表現される。

路面状態----- 乾燥、湿潤、凍結、積雪で表現される道路面の状態。気温や降水量などの気象データから熱収支法などによって推定される路面状態。

路面積雪量----- 上述の吹雪量（道路外からの飛雪）や降雪量から推定される道路上における積雪量。道路構造や走行車、除雪の影響を受けるので厳密に算定することは困難であるが、車両スタックの発生リスクを表現できる可能性がある。

表1-2 R6年度検討の上、最終年に導入できる可能性がある気象項目

名称	概要
吹雪量	地吹雪による雪の移動量の予測
路面状態	乾燥、湿潤、凍結、積雪などの路面状態予測
路面積雪量	路面上の積雪量（もしくはその指標）

本研究開発のデジタルツインの実証実験に導入することは困難であるが、道路環境を可視化するデジタルツインに、将来的に導入することが期待できる情報として表1-3の2項目を挙げておく。雪害リスク情報は車両スタックや視界不良事故などの発生リスクを各種の気象情報から解析するものである。加えて、気象情報に限らずデジタルツインで収集・分析された他のデータとの融合解析により、冬期道路環境の悪化を総合的な指標として表すことも期待できる。これらの情報はいずれも評価手法が定まってはならず、今後の研究開発に委ねられる。

表1-3 事後解析などにより、デジタルツインの将来的な候補となる気象関連項目

名称	概要
雪害リスク情報	降雪量や気温、風速などの気象要因によるスタック・多重衝突事故リスク
交通など他の気象要素との融合指標	気象要素のほか車両情報など他の要素と融合したリスク指標

#### 【2023年12月18日の大雪事例を想定した先読み情報】

留萌市では2023年12月18日に記録的な大雪となった。この大雪事例に対して想定されるデジタルツインの降雪量を再現した。図1-4は2023年12月18日1時～12時の12時間の降雪量を表した分布である。前12時間降雪量としたのは、道路維持業者へのヒアリングから、12時間程度に降り積もった雪の総量が除雪作業に大きく影響するとの指摘があったことによる。この図1-4から、留萌市周辺で局所的に12時間で90cm前後の大雪が降ったことがわかる。したがって、デジタルツインでは通常の降雪量（1時間

値)に加えて、12時間降雪量の可視化も重要となる

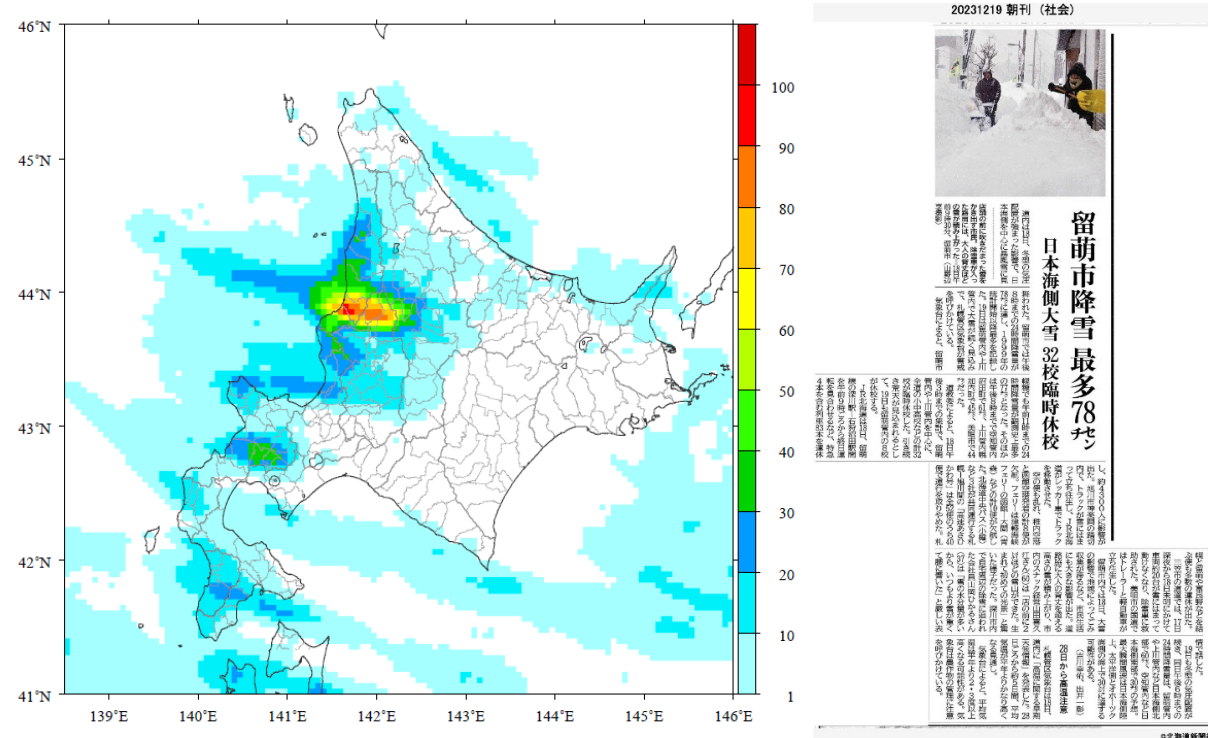


図1-4 前12時間降雪量 (2023年12月18日1時～12時)

表1-5～表1-6は、国道239号の幌延～留萌間の路線沿いにあるCCTVカメラ19箇所を対象に、2023年12月17日12時～18日18時までの前6時間降雪量、吹雪量（毎時）を算定したものである。また、表1-7は吹雪による道路上への吹き込みを考慮した路面上の積雪量を試算したものである。

表1-5の前6時間降雪量では12月18日の1時から7時の時間帯に、歌越（遠別町）～春日（留萌市）にかけて6時間に15cm以上の激しい雪が降った。特に、留萌市の春日では18日未明から明け方にかけての前6時間降雪量が40cmを超える時間帯もある。一方、この大雪事例では風速があまり強くなかったため、表1-6に示す12月18日の吹雪量は $1\text{m}^3/\text{m}$ に満たない値が続き、地吹雪の影響はほとんどなかったと考えられる。したがって、この12月18日の事例の場合、吹雪量のみでは雪害状況を的確に表現できていない。

降雪と地吹雪を加味した路面上の積雪量を試算した結果（表1-7）を見ると、12月18日の2時～3時には道路上には30cmを超える積雪があったと推定され、道路環境が劣悪だったことが表現されていると考えられる。

表1-5 前6時間降雪量（単位：cm）

No.	地点名	12/18																	
		12:00	13:00	14:00	15:00	16:00	17:00	18:00	19:00	20:00	21:00	22:00	23:00	0:00	1:00	2:00	3:00	4:00	5:00
1	下サロベツ	4.6	6.0	9.2	9.2	9.4	8.1	5.7	4.3	1.1	2.6	1.9	1.9	1.9	1.9	2.7	0.8	0.8	0.8
2	天塩町振老	3.9	5.4	9.2	10.5	10.0	8.6	6.6	5.1	1.3	0.2	0.7	1.0	1.3	1.3	1.8	1.9	1.4	1.1
3	天塩町北川口	3.9	5.3	8.9	10.8	10.3	8.9	6.9	5.5	1.9	0.0	0.5	1.2	1.7	1.7	2.2	2.7	2.2	1.5
4	天塩町更岸	5.3	5.9	7.5	9.4	9.6	8.3	5.3	4.7	3.1	0.9	0.7	1.7	2.7	3.7	4.7	5.5	5.0	4.0
5	遠別町啓明	3.9	4.5	4.8	5.1	5.7	4.7	4.0	3.4	3.1	2.2	1.8	2.3	3.1	4.1	8.6	9.4	9.9	8.5
6	富士見	4.0	4.7	4.9	4.2	4.5	4.6	3.8	3.1	2.8	3.0	3.5	4.3	5.1	6.1	10.9	11.4	11.3	9.1
7	金浦	3.7	4.3	4.2	3.5	3.8	4.8	4.3	3.7	3.4	3.7	4.9	5.2	6.2	7.2	12.5	12.9	12.1	9.7
8	歌越	2.9	3.7	4.1	3.3	3.5	5.2	4.7	3.9	3.4	3.7	4.3	5.8	8.0	10.0	16.8	17.2	17.4	13.6
9	共成	2.9	4.0	4.5	3.7	3.9	5.6	5.0	3.9	3.4	3.7	4.4	5.8	8.3	10.6	16.6	17.8	18.7	15.3
10	明里	2.7	4.4	4.9	4.3	4.6	6.4	5.9	4.2	3.7	4.1	5.3	7.4	9.9	12.7	17.7	19.9	19.6	15.9
11	第3米	3.6	4.8	5.1	5.1	5.1	9.1	8.7	7.0	6.2	7.6	8.0	6.9	9.4	14.4	22.7	27.7	28.5	25.1
12	有明	3.5	4.4	4.7	5.9	6.0	9.8	10.0	8.6	8.3	8.4	8.8	7.0	9.8	15.8	23.3	29.6	30.2	28.5
13	鶴別	2.6	3.4	3.9	5.4	6.0	9.7	10.1	8.9	8.7	7.9	9.0	8.5	13.2	20.1	26.7	33.8	33.2	30.5
14	汐見	2.0	2.8	3.1	5.0	5.5	9.1	9.2	8.0	8.1	7.2	10.8	10.8	15.8	22.9	28.8	35.5	32.3	29.2
15	興津	2.5	3.1	3.2	4.5	5.0	8.5	8.2	7.1	7.2	6.8	11.3	11.4	14.8	20.1	26.4	32.9	28.8	25.7
16	古前町上平	2.0	3.8	3.8	5.3	5.8	6.8	6.4	4.4	4.4	4.1	8.9	11.5	15.0	20.5	29.8	36.9	32.8	30.2
17	力屋	2.0	4.5	4.5	5.4	5.8	6.1	5.7	3.0	3.0	3.2	8.1	9.8	14.9	21.8	32.4	38.2	35.6	35.3
18	鬼鹿	1.7	3.2	4.7	5.3	5.3	5.0	4.6	3.0	1.1	1.4	6.2	10.7	13.5	19.6	28.8	34.5	33.3	30.7
19	春日	2.8	1.6	2.4	4.3	6.1	7.0	7.3	7.4	7.5	8.1	16.6	21.6	25.1	30.0	38.2	43.5	39.3	39.3

表1-6 吹雪量(単位：m³/m)

No.	地点名	12/18																	
		12:00	13:00	14:00	15:00	16:00	17:00	18:00	19:00	20:00	21:00	22:00	23:00	0:00	1:00	2:00	3:00	4:00	5:00
1	下サロベツ	0.04	0.07	0.10	0.16	0.18	0.14	0.09	0.03	0.05	0.05	0.05	0.04	0.02	0.05	0.07	0.05	0.06	0.07
2	天塩町振老	0.04	0.09	0.12	0.24	0.23	0.14	0.08	0.05	0.06	0.06	0.09	0.10	0.05	0.13	0.12	0.08	0.12	0.10
3	天塩町北川口	0.00	0.09	0.12	0.23	0.23	0.14	0.08	0.05	0.06	0.05	0.08	0.09	0.05	0.13	0.11	0.08	0.12	0.10
4	天塩町更岸	0.04	0.13	0.18	0.44	0.45	0.26	0.15	0.10	0.09	0.08	0.12	0.11	0.07	0.22	0.20	0.15	0.21	0.18
5	遠別町啓明	0.00	0.06	0.13	0.41	0.55	0.31	0.14	0.10	0.07	0.08	0.06	0.03	0.05	0.14	0.17	0.12	0.19	0.19
6	富士見	0.00	0.05	0.15	0.37	0.67	0.41	0.17	0.11	0.09	0.09	0.06	0.02	0.05	0.13	0.19	0.12	0.19	0.19
7	金浦	0.00	0.04	0.13	0.22	0.57	0.37	0.16	0.10	0.09	0.08	0.05	0.00	0.04	0.10	0.15	0.10	0.16	0.16
8	歌越	0.00	0.00	0.15	0.16	0.59	0.41	0.18	0.10	0.11	0.09	0.05	0.00	0.03	0.09	0.16	0.11	0.18	0.17
9	共成	0.00	0.00	0.09	0.06	0.35	0.25	0.11	0.06	0.07	0.06	0.03	0.00	0.00	0.04	0.08	0.05	0.10	0.10
10	明里	0.00	0.00	0.14	0.05	0.52	0.41	0.19	0.10	0.12	0.10	0.05	0.00	0.02	0.07	0.14	0.10	0.16	0.16
11	第3米	0.00	0.04	0.18	0.00	0.61	0.57	0.28	0.16	0.19	0.15	0.06	0.00	0.02	0.06	0.16	0.11	0.13	0.16
12	有明	0.00	0.06	0.16	0.06	0.50	0.54	0.25	0.17	0.17	0.12	0.04	0.00	0.00	0.03	0.14	0.11	0.10	0.13
13	鶴別	0.00	0.13	0.00	0.18	0.81	0.94	0.41	0.34	0.28	0.19	0.06	0.00	0.00	0.06	0.24	0.19	0.16	0.19
14	汐見	0.00	0.21	0.00	0.31	1.02	1.18	0.50	0.47	0.35	0.22	0.06	0.00	0.00	0.10	0.29	0.23	0.18	0.19
15	興津	0.00	0.26	0.00	0.41	1.05	1.18	0.52	0.54	0.38	0.23	0.06	0.00	0.00	0.12	0.27	0.20	0.16	0.18
16	古前町上平	0.04	0.10	0.54	0.45	0.72	0.91	0.50	0.47	0.27	0.13	0.00	0.00	0.00	0.13	0.21	0.14	0.13	0.12
17	力屋	0.44	0.00	0.47	0.35	0.39	0.59	0.38	0.30	0.18	0.08	0.00	0.00	0.00	0.08	0.14	0.08	0.07	0.07
18	鬼鹿	1.45	0.00	0.54	0.34	0.26	0.48	0.37	0.23	0.14	0.05	0.00	0.00	0.00	0.06	0.12	0.05	0.07	0.06
19	春日	2.26	1.49	0.30	0.31	0.25	0.41	0.29	0.12	0.00	0.00	0.00	0.00	0.00	0.02	0.09	0.00	0.00	0.00

表 1-7 吹雪による道路上への吹き込みを考慮した路面上の積雪を試算したもの

No.	地点名	12/18																	
		12:00	13:00	14:00	15:00	16:00	17:00	18:00	19:00	20:00	21:00	22:00	23:00	0:00	1:00	2:00	3:00	4:00	5:00
1	下サロベツ	8.2	8.3	10.5	9.8	10.1	9.8	9.1	8.1	6.7	7.7	6.6	5.8	5.0	4.2	4.6	4.4	4.0	3.8
2	天塩町振老	6.9	7.4	10.6	10.8	11.0	11.0	10.2	8.9	7.5	6.8	6.4	6.3	6.2	5.4	6.1	6.3	5.8	5.6
3	天塩町北川口	6.7	6.7	9.8	10.8	10.9	10.9	10.1	8.8	7.5	6.5	6.2	6.4	6.5	5.6	6.2	6.6	6.0	5.7
4	天塩町更岸	8.2	7.5	8.9	11.2	14.0	15.6	15.0	13.4	11.6	10.3	9.5	9.7	9.7	9.5	10.7	11.5	10.6	10.5
5	遠別町啓明	4.5	4.1	4.2	5.7	9.7	14.2	14.4	12.8	11.2	9.8	9.2	9.3	8.5	8.2	12.5	12.6	12.4	11.7
6	富士見	4.4	4.2	4.1	5.4	8.7	15.0	16.0	14.4	12.5	11.7	11.5	11.9	10.4	9.7	13.8	14.1	13.6	12.8
7	金浦	3.7	3.5	3.5	4.6	6.6	13.1	14.0	12.7	11.0	10.4	11.1	11.7	10.3	9.5	13.8	13.6	13.0	11.9
8	歌越	2.9	3.1	3.0	4.4	5.6	12.7	14.1	13.0	11.3	10.9	10.8	12.8	12.4	12.1	17.3	16.6	15.6	14.2
9	共成	2.7	3.3	3.1	3.8	4.2	9.1	9.7	8.8	7.6	7.5	7.8	10.2	10.6	10.7	14.9	14.6	14.3	12.6
10	明里	2.8	3.9	3.6	4.9	5.1	11.6	13.3	12.5	10.9	10.9	11.6	14.1	13.7	13.9	16.7	17.9	16.8	15.6
11	第3米	3.1	4.1	4.5	6.4	5.7	15.1	17.8	16.9	15.0	16.2	15.4	16.2	15.4	17.4	22.7	27.2	24.5	20.7
12	有明	3.3	4.0	4.5	7.6	7.2	14.9	17.8	16.6	15.4	16.4	15.2	14.9	15.2	18.1	22.7	28.1	25.0	21.5
13	鶴別	3.7	4.1	5.4	6.8	7.8	18.4	24.8	23.7	22.9	22.7	21.6	21.3	22.4	24.7	27.5	33.0	29.3	25.7
14	汐見	4.3	4.6	6.5	7.1	9.3	21.6	29.7	28.6	28.3	27.0	27.7	26.6	26.9	28.5	30.3	34.7	30.7	27.1
15	興津	4.9	5.0	7.4	7.2	10.2	22.6	30.3	29.2	29.4	28.1	29.6	28.1	26.3	26.2	29.2	33.3	29.3	25.8
16	古前町上平	4.3	6.1	6.7	12.2	14.7	20.1	25.1	25.1	25.5	24.1	25.7	24.3	22.8	23.8	30.4	34.5	30.0	26.4
17	力屋	3.9	10.4	9.1	12.8	14.1	15.7	18.4	18.6	18.7	17.7	20.1	18.3	19.6	22.7	30.3	32.4	29.2	26.0
18	鬼鹿	14.6	28.0	24.3	25.2	23.4	21.3	21.7	21.1	19.2	17.6	19.3	19.9	18.6	21.1	26.7	29.0	27.2	24.2
19	春日	18.0	37.6	45.6	41.1	37.7	33.7	31.5	28.7	24.9	22.2	28.0	28.6	26.9	27.0	30.8	33.1	32.5	32.1



## 【令和6年度でのデジタルツインでの気象に関わる先読み情報（仮運用）】

令和6年度のデジタルツインで提供した気象に関わる先読み情報の提供画面を図1-8～図1-9に示す。なお、この図1-8～図1-9は令和6年度の初冬期に仮運用を行った気象情報である。

図1-8は、日本気象協会が独自に解析した降雪量（左）と吹雪視程（右）のメッシュ予測情報の表示例である。このメッシュ予測所法は6時間先まで1kmメッシュでの予測情報である。なお、下絵は国土地理院の地理院地図を用いており拡大表示が可能である。

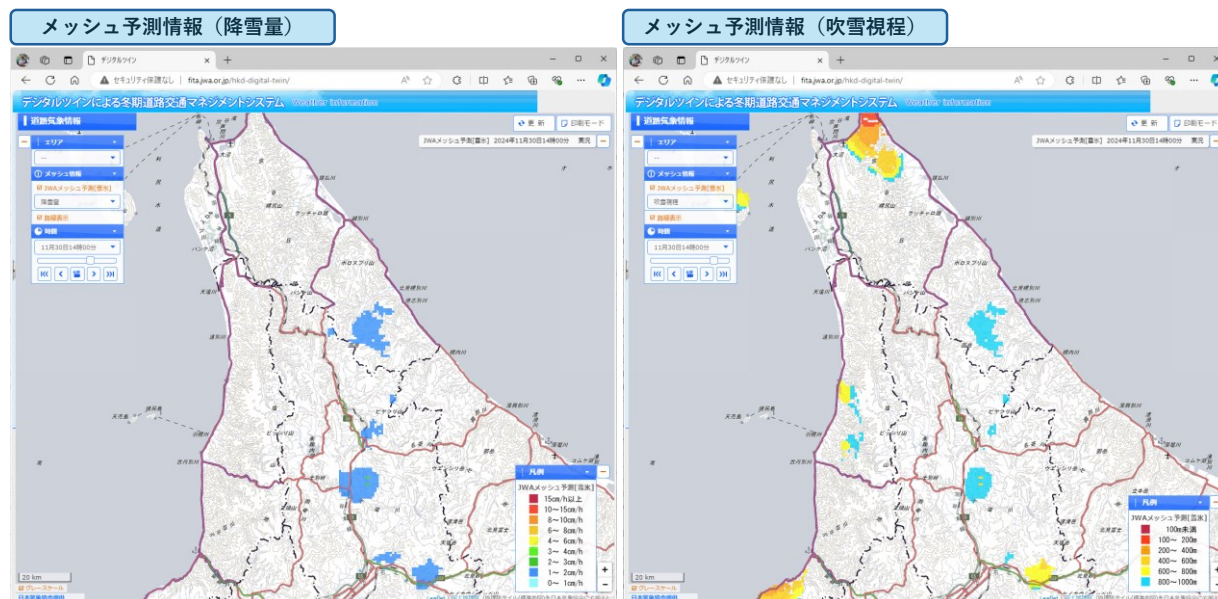


図1-8 メッシュ気象予測情報（JWA独自メッシュ）

図1-9は、気象庁の高解像度降水ナウキャストの表示例である。高解像度降水ナウキャストの更新間隔は5分で、60分先までの予測情報がある。なお、高解像度降水ナウキャストは令和5年度のデジタルツインでも実装している。

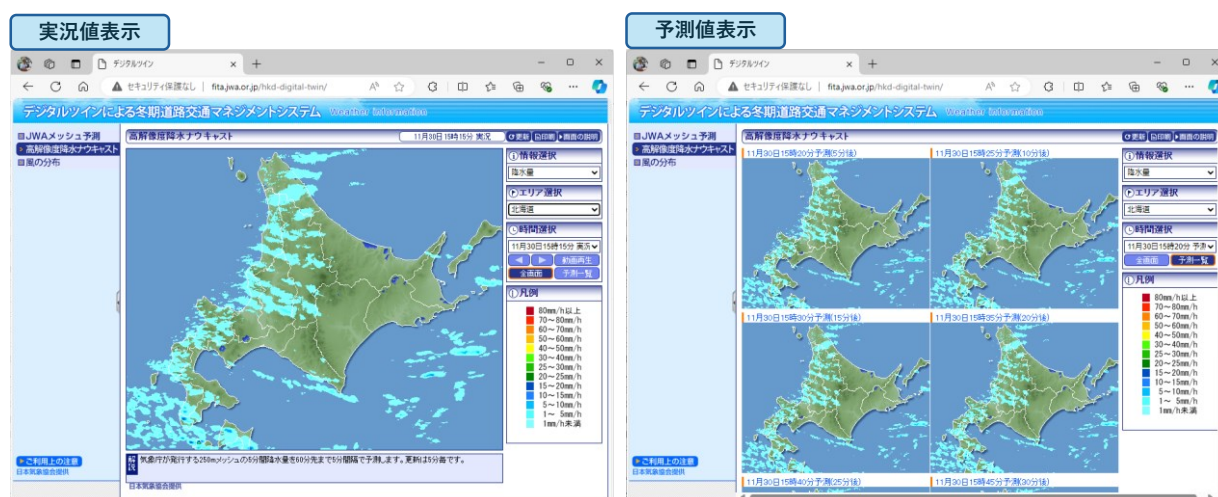


図1-9 高解像度降水ナウキャスト

図1-10は、風向風速を流線で示したデジタルツインでの表示例である。この風向風速の実況および予測情報は、日本気象協会独自の統合予測によるもので、3時間ごとに2日先までの予測情報からなる。さらにデジタルツインでの風向・風速情報は、利用者が風の強弱と向きが視覚的に分かるよう風の流線で表示した。また、前述のメッシュ予測情報と同様に、下絵には国土地理院の地理院地図を用い、拡大表示を可能とした。この風向風速の分布情報も令和5年度のデジタルツインでも実装している。

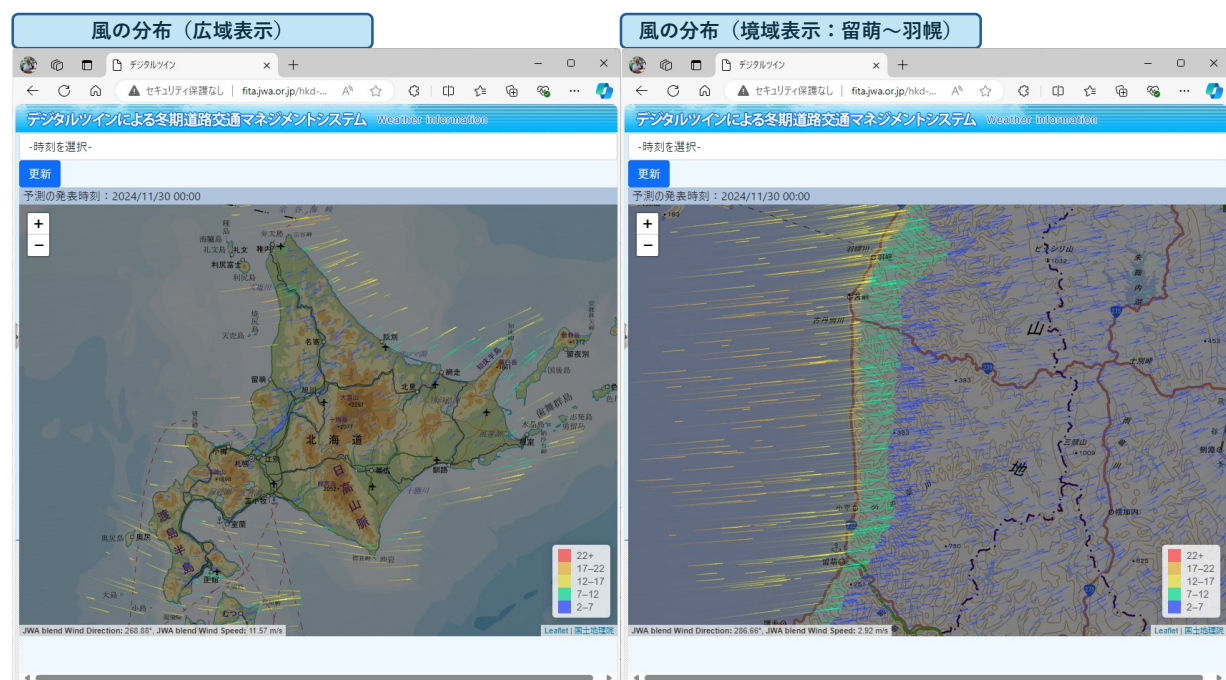
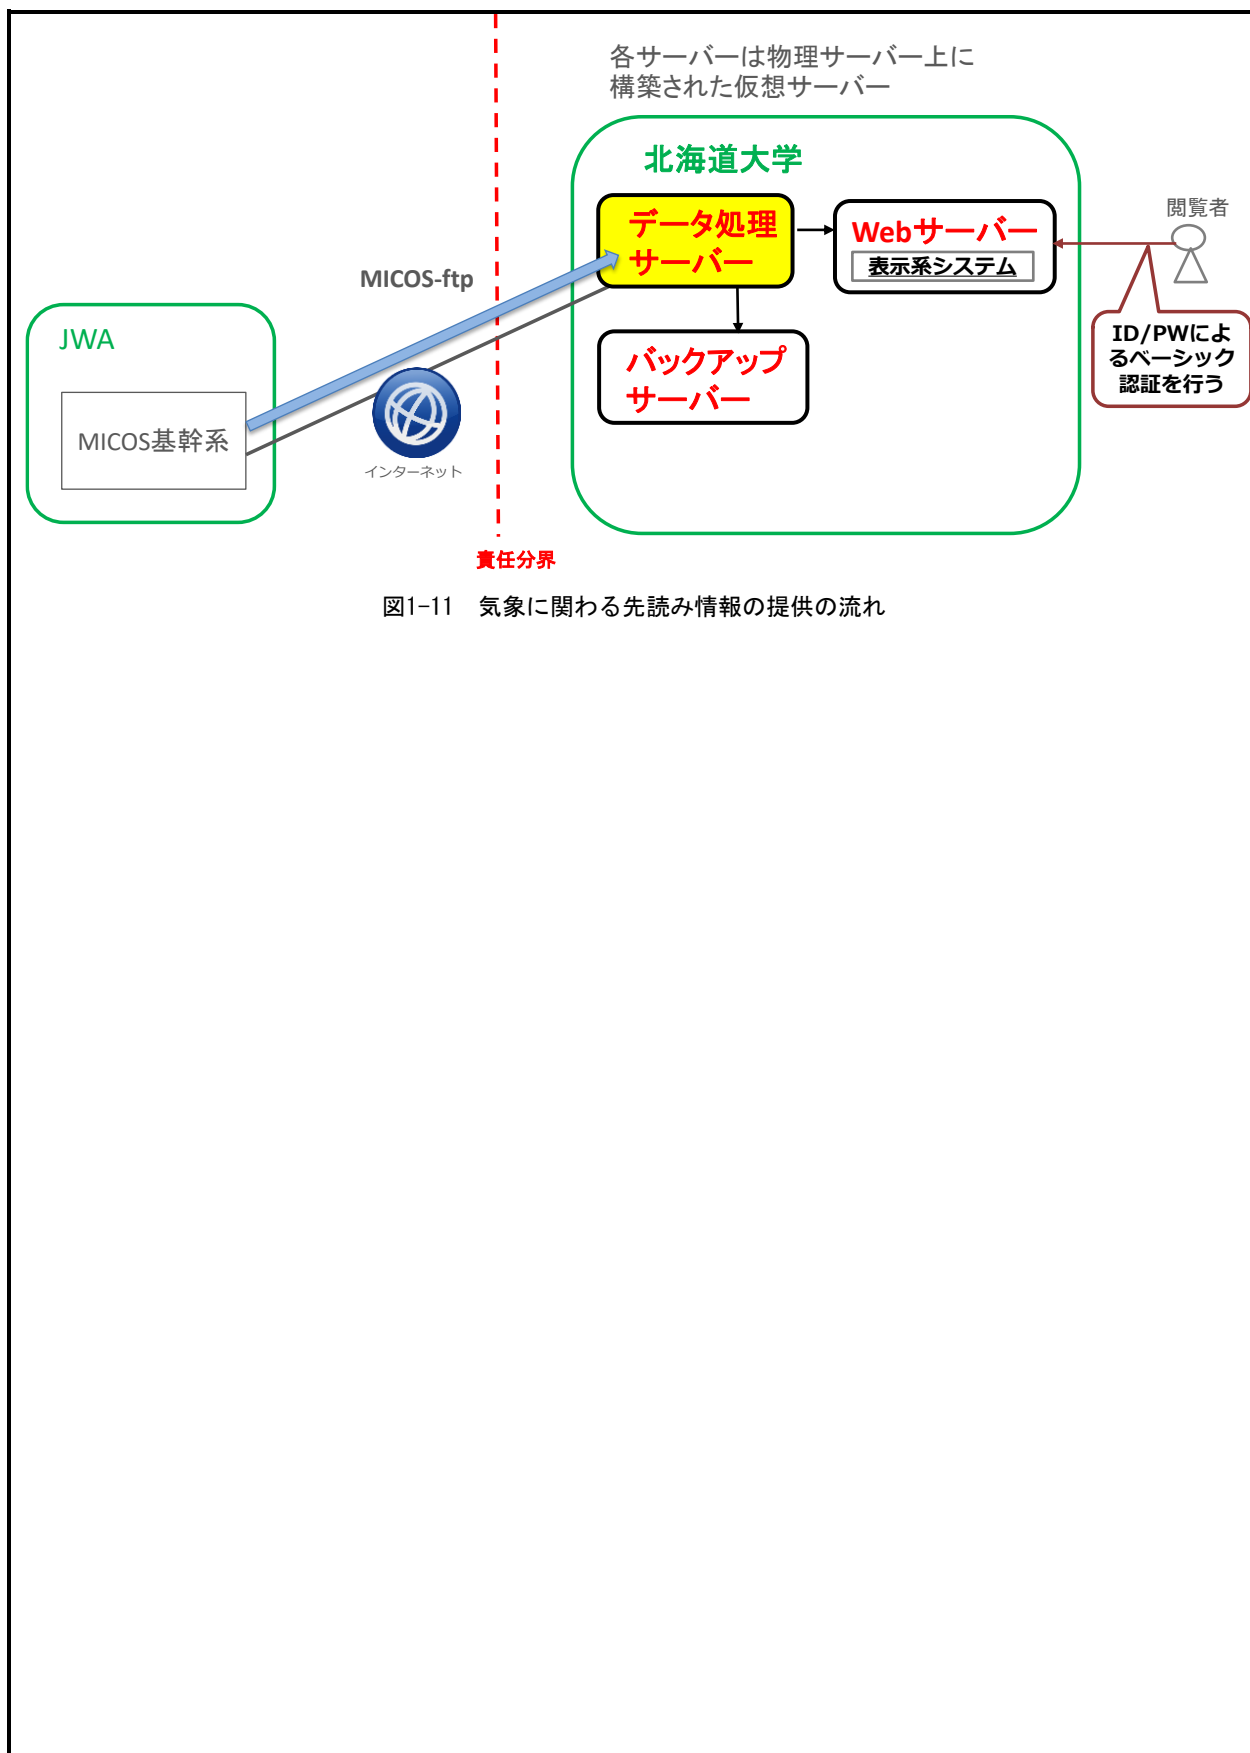


図1-10 風向風速の分布情報

### 【気象に関わる先読み情報の配信構築】

令和6年度のデジタルツインの実装に向けて、図1-11の流れで気象に関わる先読み情報の配信構築を進めている。気象に関わる先読み情報は、日本気象協会（JWA）からインターネット回線を介して北海道大学のデータ処理サーバにFTP-PUTで送信される。送信された先読み情報は北海道大学内のデータ処理サーバで必要な加工や統計処理が行われ、Webサーバ上で構築された表示系システムを通じて閲覧者に情報が届けられる。





#### ◆ 深層学習に基づく路面状態判別におけるラベル訂正

本研究プロジェクトで構築を進める道路モニタリングシステムでは、車載カメラにより撮影した画像を入力とする深層学習に基づく判別器により、路面状態を判別している。この判別器は、人手によって路面の状態をラベル付けした大量の画像データを学習することにより、構築している。このような、画像を用いた路面状態の判別技術は、実際の高規格道路の管理にも活用されている。一方で、一般道での活用例は多くない。本研究で構築するデジタルツインでは、高規格道路のみならず、一般道も含めた多様な道路の環境をモニタリング可能とする技術が必要である。

一般に、深層学習に基づく判別器は、計算パラメータをデータから自動的に学習するため、その判別精度は学習データに強く依存する。そのため、学習データと性質が異なるデータの判別精度は低下する傾向にあり、高規格道路のデータで学習した判別器を、一般道のデータにそのまま適用した場合には、判別精度の低下が懸念される。しかしながら、一般道は高規格道路に比べて総延長が長く、全ての路面データに対して、人手によりラベルを付与することは、コストの観点から現実的でない。

そこで、令和6年度には、既存の判別器を使って路面状態を判別した後、必要に応じて、その判別結果を訂正可能とする手法を構築した。この手法により、学習データセットの構築に必要なコストを抑えながら、多様な道路の路面状態を汎用的に判別可能となることが期待できる。

#### 【学習に用いた路面以外での判別精度の確認】

はじめに、学習に用いた路面以外で、その判別精度が低下することを確認する。具体的には、高規格道路の路面データを用いて深層学習に基づく路面状態の判別器を学習し、一般道の路面データの判別精度を確認する。構築する判別器は、車載カメラにより撮影する画像を入力として、路面状態を“乾燥”、“半湿”、“湿潤”、“シャーベット”、“凍結”、“積雪”のいずれかに判別する。本実験では、一般道のデータとして、北海道の天塩～留萌間の一般道で撮影した路面の画像をラベル毎に1,000枚用意し、下式で計算される3つの評価指標をラベル毎に計算し、その判別精度を検証する。

$$\text{再現率} = \frac{\text{ラベル}N\text{と正しく判別された画像の枚数}}{\text{ラベル}N\text{のテスト画像の総数}} \quad (1)$$

$$\text{適合率} = \frac{\text{ラベル}N\text{と正しく判別された画像の枚数}}{\text{ラベル}N\text{と判別された画像の枚数}} \quad (2)$$

$$F\text{値} = \frac{2 \times \text{Recall} \times \text{Precision}}{\text{Recall} + \text{Precision}} \quad (3)$$

実験結果を表1-12に示す。ここで、先行研究において、この判別器が高規格道路の路面状態を判別した際の各評価指標の平均値は0.85を超えている。一方で、表1-12より、一般道のデータに対する判別精度は各指標とも約0.6であり、精度が低下している。これより、高規格道路のデータで学習した判別器を、一般道のデータにそのまま適用した場合には、判別精度が低下することが確認された。

表1-12 高速道路用の判別器で一般道の路面状態を判別した際の精度

	乾燥	半湿	湿潤	シャーベット	凍結	積雪	平均
再現率	0.53	0.84	0.72	0.44	0.67	0.61	0.64
適合率	0.55	0.30	0.57	0.57	0.82	0.80	0.60
F 値	0.54	0.45	0.64	0.50	0.74	0.69	0.59

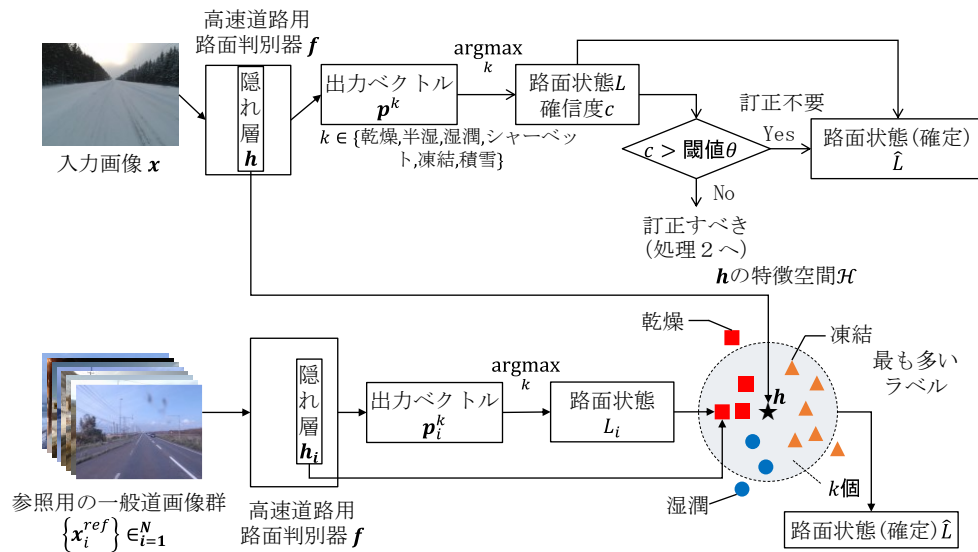


図1-13 提案手法の概要図

### 【路面状態推定におけるラベル訂正】

高規格道路用判別器を使って冬期の一般道の路面状態を判別した際に、判別結果を訂正する手法を説明する。提案手法の概要を図1-13に示す。ある判別したい一般道のデータ $\mathbf{x}$ に対して、高規格道路用の路面状態判別器 $f$ で判別された路面状態 $L = f(\mathbf{x})$ を適切に訂正するには、判別結果 $L$ を訂正すべきか判断（処理1）し、訂正すべき場合にどの路面状態に訂正（処理2）するか、の2つの判断が必要である。処理1は、高規格道路用判別器 $f$ が判別した路面状態の確信度 $c$ に対する閾値処理によって判別する。ここで、確信度とは、判別結果に対する確からしさを表している。処理2は、まず、事前に収集した一般道の参照用データ群 $\{\mathbf{x}_i^{ref}\}_{i=1}^N$ から、判別対象のデータ $\mathbf{x}$ の近傍データを $k$ 個抽出する。そして、抽出した $k$ 個の近傍データを判別器 $f$ で判別して得られる $k$ 個の路面状態 $\{L_j\}_{j=1}^k$ の中から、最多の路面状態を求め、それを訂正後の路面状態 $\hat{L}$ とする。近傍データを抽出する際のデータ間の距離の計算には、路面状態判別器 $f$ の隠れ層から得られる路面特徴量 $\mathbf{h}$ を利用する。以上の手続きにより、深層学習による路面状態の判別が自動で訂正可能となり、学習データセットの構築に必要なコストを抑えながら、多様な道路の路面状態を汎用的に判定可能となることが期待できる。

### 【ラベル訂正手法の性能評価】

ここでは、提案手法の性能を評価する．北海道の高規格道路の画像で学習された路面状態判別器と、2022年10月から2023年3月までの間に、北海道の天塩～留萌間の一般道を走行した車両の車載カメラで日中に撮影した路面画像を用いて検証した．この路面状態判別器は、乾燥、半湿、湿潤、シャーベット、凍結、積雪の6種類の路面状態を判別するものであり、エッジで計算可能な程度に軽量の深層学習モデルであるMobileNet[1]を転移学習することで構築した．

今回検証した路面状態の訂正手法のパラメータとして、訂正基準となる確信度 $c$ の閾値 $\theta$ を0.7にした．また、 $k$ 近傍法アルゴリズムのための参照データセットとして一般道の画像を6,000枚用意した．これらの画像は、高規格道路用の判別器 $f$ で判別された6種の路面状態がそれぞれ1,000枚ずつになるよう構成されている．そして、 $k$ 近傍法アルゴリズムが検索する近傍データ数 $k$ を10とした．さらに、テストデータとして 6,000枚の参照用データとは別日に収集された路面画像を6,000枚用意し、正解となる路面状態を手でラベル付けした．この6,000枚のテストデータも、高規格道路用の路面状態判別器 $f$ で判別した路面状態がそれぞれ1,000枚ずつになるよう構成している．また、比較対象として、次の2つの手法を用いる．

- ・比較手法1：高規格道路用判別器の結果をそのまま使用（訂正なし）
- ・比較手法2：確信度が低い場合、次点（確信度が2番目に高いラベル）の路面状態に訂正

[1] Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., and Adam, H.: MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications, CoRR, 1704.04861, 2017.




図1-14 各手法におけるラベル毎のF値

図1-14に各手法におけるラベル毎のF値を示す。図1-14より、どの路面状態においても提案手法が最も高い判別精度であった。これより、提案手法によりラベルを訂正することで、判別精度が向上することが確認された。また、冬期の交通安全を確保するには、危険側の路面状態を安全側として誤判別してしまう件数を減らすことが重要である。そこで、そのような危険な誤判別の件数を提案手法と比較手法1で集計したものが表1-15である。提案手法は、訂正前である比較手法1に比べて危険な誤判別を大きく減少できていることが分かる。特に冬期特有の路面状態であるシャーベット、凍結、積雪路面を乾燥路面と間違えた件数を約半数に減らせた。以上より、提案手法の有効性が確認された。

表1-15 提案手法と比較手法1における危険な誤判別の件数

真の路面状態	比較手法1	提案手法	誤判定の削減率
半湿	349	216	38%
湿潤	73	56	23%
シャーベット	2	1	50%
凍結	15	9	40%
積雪	13	4	69%

#### ◆ 深層学習に基づく路面状態判別器の再学習に関する検討

前述のとおり、本研究で構築を進める車載システムでは、車載カメラで撮影した画像を入力とする深層学習に基づく判別器により、路面状態を判別している。深層学習に基づく判別器は、その構築に、大量のラベル付きデータが必要である。しかしながら、モニタリング対象の全ての路面データに対して、事前に人手によって路面状態のラベルを付与することは困難である。本研究で構築するデジタルツインでは、多様な道路の環境を正確にモニタリング可能なシステムが必要であるため、前述の項（「深層学習に基づく路面状態判別におけるラベル訂正」）では、少ない学習データで汎用的に多様な道路の路面状態を判別可能な手法を構築した。

将来的には、フィジカル空間に散りばめられた複数かつ大量のエッジコンピュータにより、広範囲に道路環境をモニタリングする状況が想定される。ここで、エッジは、モニタリングシステムが搭載された車両を意味しており、各車載システムには、一つの路面状態判別器が実装されている。広範囲に分散配置された各エッジでは、車載システムにより常時、画像データとその解析結果を記録し続ける。したがって、各エッジで新たに取得するデータを用いて、判別器を逐次的に再学習可能な機能をデジタルツインに搭載することで、多様な道路の環境を正確にモニタリング可能となることが期待できる。

汎用性の高い判別器を構築するためには、広範囲に分散配置された大量のエッジが取得する画像データを、エッジ全体で共有することで、多様な道路の路面に関する知識を逐次的に再学習可能とすることが望ましい。しかしながら、画像はデータ容量が大きいいため、データの伝送による通信ネットワークへの負荷が大きい。そのため、画像データそのものをエッジ全体で共有する仕組みは、現実的ではない。そこで、本研究では、深層学習に基づく判別器を効率的に再学習する手法を構築する。具

体的には、各エッジが自身で取得した画像を用いて判別器を再学習し、他のエッジで駆動する判別器の計算パラメータの一部を、自身の判別器に置換することで、他のエッジが持つ知識を学習可能とする。画像そのものではなく、計算パラメータを共有することで、通信ネットワークへの負荷を低減する。昨年度の研究[2]では、計算パラメータを獲得するエッジを選択する手法を提案している。具体的には、判別器の性質を表現するベクトルの類似度が低いエッジを選択する。自身が既に学習した路面とは異なる性質を持つ路面の知識を獲得可能となることが期待でき、これは効率的な再学習に繋がる。また、昨年度までに、他の判別器の計算パラメータを用いて識別器を更新する手法を提案している[3]（以降、従来手法）。従来手法は、他の判別器のパラメータの一部を自身の判別器に置換し、誤差逆伝搬法により置換したパラメータを自身の判別器に適応させている。これにより、データ容量の大きな画像や映像そのものをデータ通信することなく、判別器を再学習可能としている。

しかしながら、従来手法では、再学習により汎化性能が向上する判別器が存在する一方で、性能が大幅に低下する判別器もあり、多様な判別器に対してより安定して再学習可能な手法へと高度化させる必要がある。そこで、令和6年度には、より安定した再学習のための学習済みモデルの計算パラメータを用いた判別器の再学習手法を構築した。

[2] 植西康太，八木雅大，高橋翔，萩原亨：道路空間を観測するエッジ AI の類似度を用いた再学習のためのエッジ選択手法， AI・データサイエンス論文集，2023.

[3] Uenishi K., Yagi, M., Takahashi, S., and Hagiwara, T.: A Note on Discriminator Updating Method based on Weights of Other Models and its Verification, IEEE International Conference on Consumer Electronics - Tai-wan, pp. 39-40, 2023.

### 【学習済みモデルの計算パラメータを用いた判別器の再学習】

提案手法では、まず、他の判別器の計算パラメータの一部を自身の判別器に置換する。次に、出力結果の正誤に応じて計算パラメータの値を補正する誤差逆伝搬法を適用する。この二つの処理を繰り返し行うことで、安定した再学習を可能とする。以降では、計算パラメータの置き換えと誤差逆伝搬について、それぞれ詳述する。

#### 1. 計算パラメータの置換

ニューラルネットワークが $N$ 個の層から構成されているとする。このとき、 $k$ 番目( $1 \leq k \leq N$ )の層にあるニューロンの出力 $y_k$ は、 $k-1$ 番目にあるニューロン全てからの出力ベクトル $x_{k-1}$ と、ニューロン間の計算パラメータ $W_{k-1}$ 、バイアスベクトル $b_{k-1}$ を用いて、(4)式のように計算される。ただし、 $f(\cdot)$ は活性化関数を指す。

$$y_k = f(W_{k-1}x_{k-1} + b_{k-1}) \quad (4)$$

ニューロンの出力値 $y$ に用いられる計算パラメータ $W$ は、学習過程で入力に対して真値が出力されるように調整される。加えて、出力層( $N$ 番目の層)に近づくほど、計算パラメータ $W$ は学習データを表現することが示されている。それゆえ、提案手法では、 $N-1$ 番目と $N$ 番目の計算で用いられる計算パラ



メータ $W_{N-1}$ を操作対象とする．具体的には，再学習を行う判別器と，選択された判別器の $N-1$ 番目と $N$ 番目の計算で用いられる計算パラメータをそれぞれ $W_{update,N-1}$ ， $W_{select,N-1}$ とする．このとき，計算パラメータの置き換え操作は(5)式のように表され，単に代入となる．

$$W_{update,N-1} = W_{select,N-1} \quad (5)$$

## 2. 置き換えた計算パラメータの補正

前項で説明した置き換えた計算パラメータに対して補正を行う．逆誤差伝搬法は，ニューラルネットワークの性能を評価するための誤差関数と，誤差関数から得られた誤差に基づき計算パラメータを更新する逆伝搬で構成される．本手法では，誤差関数として分類問題における交差エントロピー誤差関数を，計算パラメータの更新手法として確率的勾配降下法を用いる．

### (a) 交差エントロピー誤差関数

交差エントロピー誤差関数は，分類において確率分布間の距離を測るための誤差関数として使用される．正解ラベルを $y^{(i)}$ ，ニューラルネットワークの出力を $\hat{y}^{(i)}$ とすると，交差エントロピー誤差関数は(6)式のように表される．

$$J(y, \hat{y}) = -\frac{1}{m} \sum_{i=1}^m \sum_{j=1}^C y_j^{(i)} \log(\hat{y}_j^{(i)}) \quad (6)$$

ただし， $m$ はデータの数， $C$ は分類ラベルの数を指す．

### (b) 確率的勾配降下法

確率的勾配降下法は，バッチごとに勾配を計算しその勾配に基づいてニューラルネットワークの計算パラメータ行列を更新する手法である．学習率 $\alpha$ とすると，計算パラメータ行列の更新結果 $W^{(i)}$ は誤差関数 $J$ を用いて(7)式で表される．バイアス値に対しても同様の計算が適用される．

$$W^{(i)} = W^{(i)} - \alpha \frac{\partial J}{\partial W^{(i)}} \quad (7)$$

提案手法では，式(5)で表す計算パラメータの置き換えと式(7)で表す誤差逆伝搬を繰り返し行うことで，判別器を再学習する．以上により，学習済みモデルの計算パラメータを用いた判別器の再学習が実現する．

## 【再学習手法の性能評価】

ここでは，提案手法の有効性を確認するため，性質が異なる13個のデータセットを用意して実験を行う．本実験では，積雪寒冷地における道路の路面状態を，乾燥，積雪，湿潤のいずれかに分類する判別器を構築し，提案手法により再学習する．はじめに，各データセットを学習済みの判別器を構築する．次に，各判別器に対して，文献[2]で提案した手法を用いて，その他12個の判別器から計算パラ

メータを獲得する判別器を選択し、提案手法により再学習する。

## 1. データセット

本実験で用いるデータセットは、前述の道路モニタリングシステムにより取得した画像データを用いる。このシステムによって、冬期に撮影された画像を用いて13個のデータセット（D1～D13）を作成する。各データセットは、画像を撮影した地域が異なるため、データセットの性質が異なる。各データセットの画像枚数は、各ラベルにおいて学習用300枚、テスト用100枚である。本実験では、この13個のデータセットをそれぞれ学習済みの判別器（M1～M13）を構築する。

## 2. 判別器のアーキテクチャ

本実験では、判別器として深層畳み込みニューラルネットワークであるMobileNetsを使用する。画像を入力することで、3種の路面状態それぞれに対する確率が出力され、確率が最も大きいラベルを判別結果とする。

## 3. エッジの選択手法

本実験では、文献[2]で提案した手法を用いて計算パラメータを獲得するエッジを選択する。具体的には、まず、各判別器に対して、同一のデータセットを入力することで、任意の層のニューロンにおける出力値から成る特徴ベクトルを求める。次に、特徴ベクトルの類似度を計算する。最後に、類似度が最も低いエッジを選択する。

## 4. 実験結果

本実験では、13個のテストデータセットに対する正解率の平均値を判別器ごとに計算する。13個のデータセットは性質が異なることから、正解率の平均値が高いほど、判別器の汎化性能が高いことを表している。実験結果を表1-16に示す。表中のM1～M13は、判別器の番号を表している。表1-16は、判別器ごとに、13個のテストデータセットに対する正解率の平均値を計算した結果を示しており、右端の列は、M1～M13の平均値を示している。表1-16より、提案手法によって、再学習前に比べ正解率の平均値が向上した判別器の数は13個中9個であった。一方で、従来手法では、その数は13個中6個であった。これより、提案手法は、従来手法に比して、多様な判別器に対して汎化性能を向上させる再学習が可能であることが確認できる。

再学習により正解率の平均値が低下した判別器に注目する。M5, M7, M8は、提案手法、従来手法ともに、再学習により精度が低下しているが、提案手法はその低下度合いが比較手法に比して小さいことが確認できる。表1-16の右端の列の値より、M1～M13の平均値は、従来手法は再学習前に比して低い値となっているが、提案手法は再学習前に比して高い値となっている。従来手法については、性能が向上する判別器が存在する一方で、性能が大きく低下する判別器も存在することから、正解率の平均値が再学習前に比べて低い。一方で、提案手法は、半数以上の判別器に対して安定して汎化性能を向上させることができ、性能が低下する場合にも、従来手法に比してその低下する程度は小さいことから、M1～M13の平均値が再学習前に比べて向上している。

以上の内容から、提案手法によって、より多様な判別器に対して汎化性能を向上させる再学習が可能であり、さらには精度が低下する場合においても、その低下度合を抑えることが可能であることが確認できる。これより、提案手法の有効性が確認された。

表1-16 再学習前の各判別器の正解率と提案手法および従来手法により再学習した後の正解率

判別器の番号	再学習前	提案手法	従来手法
M1	0.682	<b>0.750</b>	0.606
M2	0.724	0.767	<b>0.773</b>
M3	0.642	0.619	<b>0.683</b>
M4	0.664	<b>0.683</b>	0.669
M5	<b>0.739</b>	0.644	0.560
M6	0.692	<b>0.737</b>	0.706
M7	<b>0.762</b>	0.739	0.706
M8	<b>0.649</b>	0.617	0.535
M9	0.653	<b>0.685</b>	0.670
M10	0.704	<b>0.710</b>	0.667
M11	0.663	<b>0.716</b>	0.607
M12	0.747	<b>0.771</b>	0.743
M13	0.677	<b>0.772</b>	0.683
平均	0.670	<b>0.705</b>	0.662

#### ◆ 車載カメラ映像を用いた機械学習に基づく夜間の視界レベル推定の軽量化

本研究で構築を進める道路モニタリングシステムでは、車載カメラにより撮影する画像から Weighted Intensity of Power Spectra（以降、WIPS）を計算することで、視界状況を定量化している。WIPSは、日中の視界状況を定量化するために提案されたものであり、夜間は本来の分析対象ではないことから、その精度には課題がある。したがって、一日をととして道路交通をマネジメント可能なデジタルツインを構築するためには、より精度高く夜間の視界状況を定量化可能な手法を構築することが必要である。

先行研究[4]では、前方視野映像から、夜間での視界状況の特徴を表現可能な複数の特徴ベクトルを算出し、それらを入力とする複数の機械学習による識別器に基づいて、視界状況をレベル分けする手法が提案されている（以降、従来手法）。従来手法は、精度高く夜間の視界状況をレベル分け可能である一方で、計算に必要な時間に関して、議論がされていない。ここで、本研究で構築するモニタリングシステムでは、マイクロコンピュータにより、路面や視界を判別する演算を実行している。従来手法についても、マイクロコンピュータのように、演算能力が限られた計算機で計算可能であることが望ましい。そこで、令和6年度にはまず、従来手法の演算に必要な時間をマイクロコンピュータを用いて確認し、その実現可能性について検討した。

[4] R. Sato, S. Takahashi, T. Hagiwara, Y. Nagata, and K. Ohashi : A Visibility Level Estimation Via Late-fusion Based on Probabilities of Multiple Classifiers Using In-vehicle Camera Videos Under Nighttime, *Artificial Intelligence and Data Science*, Vol. 3, No. J2, pp. 534-542, 2022.

#### 【従来手法：車載カメラ映像を用いた夜間の視界レベル推定】

従来手法では、画像の空間周波数、明度、Optical Flow、物体認識モデル、および車速に関する特徴量を算出する。次に、それぞれを入力とする機械学習に基づく識別器として、Support Vector Machine (SVM) [5]およびExtreme Learning Machine (ELM)[6] を計10個構築する。さらに、それらの確信度を入力とするSVMを用いることで視界レベルを推定する。これによって、各識別器から出力された確信度の傾向に基づく推定が可能となる。

本手法で用いる特徴ベクトルそれぞれには、次を期待している。空間周波数は視界が劣悪な場合、降雪が画像全体を覆い平坦な画像となるため、低周波成分が多くなることを期待している。次に、明度は視界が劣悪な場合、前照灯の光が雪粒子に反射して画像全体が白くなる現状の表現を期待している。Optical Flowは物体の動きを定量化するものであり、車載カメラ映像では、視界が良好な場合に車両の進行に伴って映像内の物体が放射状に移動する様子の定量化を期待する。また、物体認識モデルによる特徴量は、深層学習によるモデルであるInception-V3[7]の第3プーリング層から得られる認識の様子を表す数値を用いる。これは、視程障害が認められる場合に物体の識別が困難となる様子を表現することを期待するものである。最後に車速については、車載システムによってGNSSで得る速度を用いる。車速は画像のノイズの影響を受けないデータであることから、夜間の道路空間において、頑健な識別に貢献することを期待するものである。

[5] C. Cortes and V. Vapnik: Support-vector networks, *Machine learning*, Vol. 20, no. 3, pp. 273-297, 1995.

[6]G.-B. Huang, Q.-Y. Zhu and C.-K. Siew: Extreme Learning Machine: a new learning scheme of feedforward neural networks, *Proc. In the IEEE International Joint Conference on Neural Networks*, Vol. 2, pp. 985-990, 2004

[7]C. Szegedy, V. Vanhoucke, S. Loffe, J. Shlens and Z. Wojna: Rethinking the inception architecture for computer vision, in *Proc. of the IEEE Conference on Computer Vision and Recognition*, pp. 2818-2826, 2016.

#### 【要求性能の定義】

現在、冬期高速道路の管理業務においては、凍結防止剤の散布判断を行うことを目的として、100m 単位で路面状態の識別が行われている。このように、多くの道路管理業務が100m単位で行われており、視界状況についても100m単位で把握可能となることが望ましい。また、スタッドレスタイヤを装着した小型車が、視程115～185m程度の視界不良状態で安全に走行可能な運転速度は約40km/hである。以上の内容から、車両速度を40km/hと想定して、100m単位で視界状況を把握可能とするためには、約9秒に1回の頻度で計算する必要がある。

### 【計算時間の確認と課題の明確化】

従来手法の計算時間を確認する．本実験では，バッテリー駆動可能なマイクロコンピュータ，USB 接続型のカメラおよびGNSS受信器で構成されるシステムに，従来手法を直列に搭載して，計算時間を確認する．

表1-17に計算時間を示す．表1-17より，従来手法が必要とする計算時間は約23秒であり，これは実装に要求される計算時間（9秒）を超過している．特に，特徴ベクトルの算出に必要な時間が，他のプロセスに比して大きくなっている．したがって，実装に向けては，特徴ベクトルの算出に掛かる時間を削減することで，計算時間を約14秒削減する必要がある．

表 1-17 従来手法における計算時間

項目	特徴ベクトル	計算時間(秒)
特徴ベクトルの算出	空間周波数	8.59
	明度	2.64
	Optical flow	1.75
	物体認識モデル	7.66
	車速	$4.05 \times 10^{-5}$
SVM による暫定的な識別	空間周波数	$8.80 \times 10^{-2}$
	明度	$1.14 \times 10^{-1}$
	Optical flow	$2.10 \times 10^{-2}$
	物体認識モデル	$3.97 \times 10^{-1}$
	車速	$8.87 \times 10^{-3}$
ELM による暫定的な識別	空間周波数	$3.96 \times 10^{-2}$
	明度	$3.78 \times 10^{-1}$
	Optical flow	$2.96 \times 10^{-3}$
	物体認識モデル	1.35
	車速	$2.67 \times 10^{-3}$
暫定的な識別結果の統合		$2.13 \times 10^{-3}$
合計時間		23.1

### 【視界レベル推定の軽量化】

ここでは，前述の課題解決に向けて，夜間の視界レベル推定を軽量化する手法を検討する．提案手法では，以下の3つのアプローチにより，特徴量算出のプロセスを軽量化し，視界レベルの推定精度を維持しながら，実装に要求される9秒に1回の頻度で視界レベルを判定可能とすることを目標とする．

- 1．特徴量算出に用いるパッチ数およびフレーム数の削減
- 2．軽量の物体認識モデルの導入
- 3．特徴量算出の並列化

## 1. 特徴量算出に用いるパッチ数およびフレーム数の削減

従来手法では、図1-18に示すように、入力画像下部に撮像されるボンネットを含む領域以外の $W \times H$ の領域を用いて特徴量を求める。空間周波数、明度およびOptical Flowの特徴ベクトルにおいては、この領域を横方向に $l$ 分割、縦方向に $m$ 分割して得る合計 $lm$ 個のパッチから特徴ベクトルを求めている。また、従来手法では、約3秒の映像(30fps,  $640 \times 480$ )を入力データとし、全フレームから特徴ベクトルを求めている。

従来手法における空間周波数の特徴ベクトルでは、視界が良好な場合は画像の高周波成分が大きい、視界が劣悪な場合は降雪によって画像全体の色が平坦になり、低周波成分が大きくなるという画像特徴に着目している。これより、視界レベルの判定には、遠方が映る画像中央部分のみの解析で十分である。したがって、提案手法では、図1-18(a)に示すように、分析領域を入力画像の中心部( $W' \times H'$ の領域)に絞る。

次に、従来手法における明度の特徴ベクトルでは、視界が劣悪な場合は車のヘッドライトの光が雪粒子に反射することで光が散乱し、画像全体が白くなるという画像特徴に着目している。これより、画像全体を満遍なく解析する必要がある。したがって、提案手法では、入力画像の特定の領域を解析するようにパッチを削減するのではなく、図1-18 (b) に示すように、画像全体を満遍なく解析する。

夜間における道路空間の映像は、隣り合うフレームが類似しているため、フレーム数を削減することで、冗長性を排することが可能である。また、入力映像全体を捉えるため、入力映像のまとまった一部を解析対象とするのではなく、解析するフレームを交互にサンプリングすることが望ましい。したがって、本稿では、空間周波数、明度およびOptical Flowの特徴量算出において、90枚のフレームから、1枚おきにフレームを削減し、合計45枚のフレームについて解析を行う。




図 1-18 提案手法における分析領域とパッチ分割

## 2. 軽量な物体認識モデルの導入

従来手法では、Inception-v3に基づく特徴量の算出に7.66秒の時間を要しているため、軽量な物体認識モデルを用いることで計算時間を削減することを目指す。提案手法では、物体認識モデルとしてMobileNetV2を用いる。MobileNetV2は、空間方向とチャンネル方向に独立に畳み込み処理を行うため、Inception-v3と比較して、推定時の処理速度が速いネットワークである。提案手法では、計算時間の観点から、特徴ベクトルの次元数が高くなることを避けるため、MobileNetV2の最終層の出力値を特徴ベクトルとして用いる。



### 3. 特徴ベクトル算出の並列化

従来手法では、特徴ベクトルの算出処理を直列に実装しており、並列化により計算時間が削減可能となることが期待できる。提案手法では、特に計算時間を要する物体認識モデルに基づく特徴量の算出処理をパイプ1とし、他の空間周波数、明度、Optical Flow、車速に基づく特徴量の算出処理をパイプ2として、これら二つのプロセスを並列化することで、計算時間を削減する。

#### 【軽量化手法の性能評価】

ここでは、軽量化手法の性能を評価するため、提案手法および従来手法の計算時間および視界レベル判定の精度を比較する。本実験では、視界状況を5つレベルに分類し、各視界レベル500本ずつの合計2500本の映像をデータセットとして用いる。また、視界レベルの推定には5分割交差検証を行う。計算時間を計測するシステムは、前述（【計算時間の確認と課題の明確化】）と同じものを用いる。

計算時間および視界レベルの判定精度をそれぞれ、表1-19と表1-20に示す。表1-19より、提案手法を用いることで、実装に要求される9秒に1回の頻度で視界レベルを判定可能であることが確認できる。また、表1-20より、提案手法の視界レベルの判定精度は、従来手法に比べてわずかに低下しているが、8割以上の精度を維持しており、計算時間の削減率に比して、精度の低下度合はわずかである。以上より、提案手法を用いることで、視界レベルの判定精度を維持しながら、9秒に1回、すなわち100mに1回の頻度で視界レベルを判定可能となり、提案手法の有効性が確認された。

表1-19 提案手法および従来手法における計算時間

項目	特徴ベクトル	計算時間 (秒)	
		従来手法	提案手法
特徴ベクトルの算出	空間周波数	8.59	3.96
	明度	2.64	
	Optical flow	1.75	
	物体認識モデル	7.66	
	車速	$4.05 \times 10^{-5}$	
SVM による暫定的な識別	空間周波数	$8.80 \times 10^{-2}$	$8.80 \times 10^{-2}$
	明度	$1.14 \times 10^{-1}$	$1.14 \times 10^{-1}$
	Optical flow	$2.10 \times 10^{-2}$	$2.10 \times 10^{-2}$
	物体認識モデル	$3.97 \times 10^{-1}$	$5.12 \times 10^{-1}$
	車速	$8.87 \times 10^{-3}$	$8.87 \times 10^{-3}$
ELM による暫定的な識別	空間周波数	$3.96 \times 10^{-2}$	$3.96 \times 10^{-2}$
	明度	$3.78 \times 10^{-1}$	$3.78 \times 10^{-1}$
	Optical flow	$2.96 \times 10^{-3}$	$2.96 \times 10^{-3}$
	物体認識モデル	1.35	1.37
	車速	$2.67 \times 10^{-3}$	$2.67 \times 10^{-3}$
暫定的な識別結果の統合		$2.13 \times 10^{-3}$	$2.13 \times 10^{-3}$
合計時間		23.1	6.08

表1-20 提案手法および従来手法における視界レベルの判定精度

再現率						
	Lv. 1	Lv. 2	Lv. 3	Lv. 4	Lv. 5	Average
提案手法	0.974	0.902	0.776	0.650	0.854	0.831
従来手法	0.972	0.936	0.810	0.738	0.872	0.867
適合率						
	Lv. 1	Lv. 2	Lv. 3	Lv. 4	Lv. 5	Average
提案手法	0.984	0.879	0.732	0.705	0.852	0.831
従来手法	0.992	0.895	0.807	0.762	0.870	0.865
F 値						
	Lv. 1	Lv. 2	Lv. 3	Lv. 4	Lv. 5	Average
提案手法	0.979	0.890	0.753	0.676	0.853	0.830
従来手法	0.982	0.915	0.808	0.750	0.871	0.865

◆ 視界状況の空間的先読み方法の検証

2023年度は、「特急わっかない号」の車両前方画像より求めた視界情報と、走行路線上の道路管理用CCTVカメラの道路画像より求めた視界情報の関係性を分析することで、車両の走行していない時間帯の時系列データを推定する方法を検討、確立した。具体的には、2021年度冬期に走行した全ての車両前方画像の視界情報を100m間隔に整理し、同時刻の19箇所のCCTVカメラの視界情報の相関係数を式(1)のように求め、最も相関係数の高い地点のCCTVカメラの視界情報から、全区間の100m間隔の視界情報を求める方法である。

$$WIPS_{Bki} = b_{1kj} \times WIPS_{Ckji} + b_{0kj} \quad (1)$$

$WIPS_B$ : value of the WIPS by the intercity bus

$WIPS_C$ : value of the WIPS by the CCTV

i: intercity bus number (i=1 to m, m: total number of intercity buses (Maximum number:114))

j: CCTV number (c=1 to 19)

k: 0.1km-section number (k=1 to 1280 or 1281)

今年度は、2021年度冬期のデータを用いて構築したこの空間的先読み方法を用い、2023年度冬期の100m間隔の視界情報を推定した結果（吹雪による視界不良の発生した2023年12月17日の例を図1-21に示す）と、同時刻に「特急わっかない号」の車両前方画像より求めた視界情報を比較することで検証を行った。検証結果を図1-22に示した。図のように、平均的には、推定手法を構築した2021年度冬期のデータでの相関係数に比べるとやや相関係数が低くなるものの、2021年度冬期のデータよりも相関係数が高くなる区間もみられた。車両前方画像より求めた視界情報と、走行路線上の道路管理用CCTVカメラの道路画像より求めた視界情報をより多く蓄積し、これに気象情報などを組み合わせることで、より正確な先読みができる可能性が考えられる。




図1-21 CCTVカメラの視界情報と推定結果の経過（2023年12月17日の例）




図1-22 視界情報の推定結果と車両前方画像より求めた視界情報の相関係数

#### ◆視界の時間的先読み方法の検討

上記に示したように、CCTVカメラの視界情報から、全区間の100m間隔の視界情報を求める方法が確立できると、CCTVカメラの視界情報を時間的に先読み（予測）することで、全区間の視界情報の時間的な先読み（予測）に展開が可能になる。そこで、2023年度冬期のCCTVカメラの視界情報と、日本気象協会より提供いただいた気象メッシュの気象データを比較し、気象データから、吹雪や降雪による視界情報の低下を把握できるかどうかを分析した。ここでは、吹雪について既存研究より、地吹雪による視界不良の発生条件（図1-23の青色のエリア）と、降雪を伴う吹雪による視界不良の発生条件（図1-23の紫色のエリア）の場合に、吹雪による視界不良が発生すると仮定し、CCTVカメラの視界情報の低下量（低下量が大きいほど視界は悪化する）を比較した。

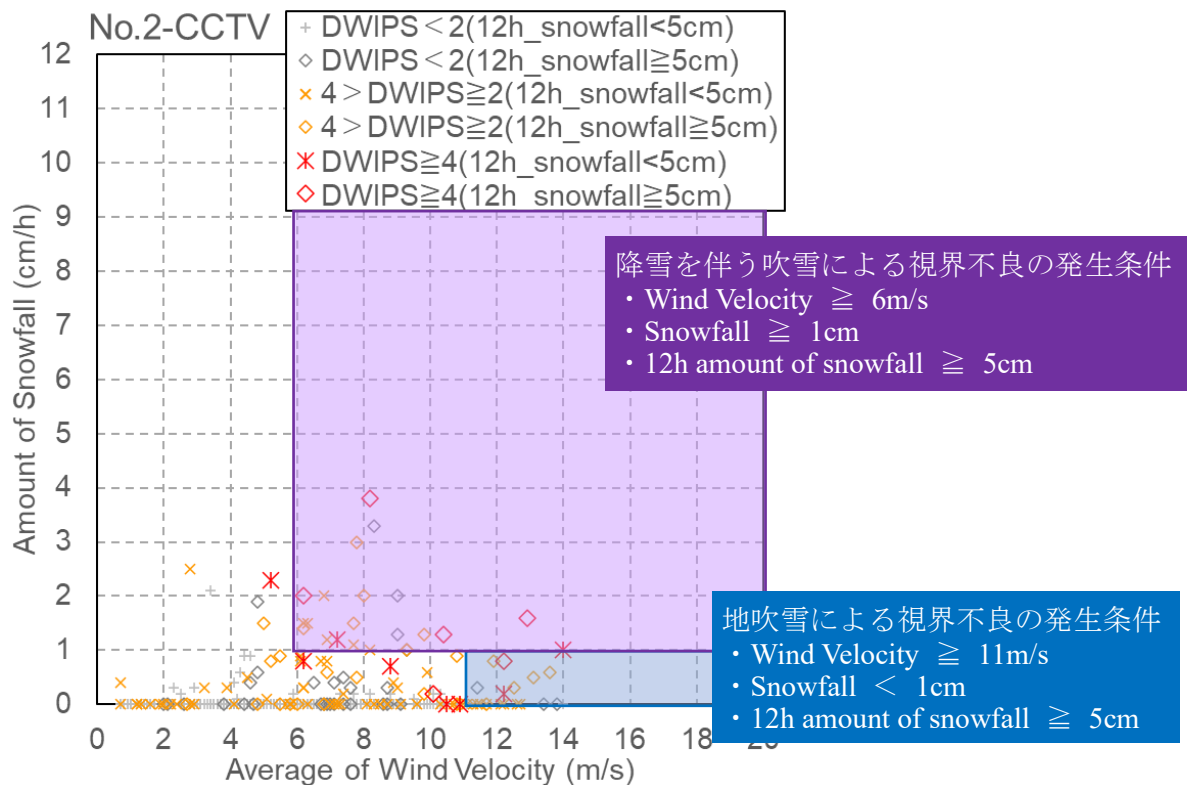


図1-23 吹雪の発生条件とCCTVカメラの視界情報の低下量（DWIPS）の比較

図1-24には、2023年度冬期にCCTVカメラが不調であったNo.8のカメラを除いた18箇所のカメラを対象として、視界不良の発生時のうち、図1-23に示した吹雪の発生条件によって抽出された事例数を示した。全体では220件の視界不良事例のうち、91件が降雪を伴う吹雪による視界不良の発生条件で、16件が地吹雪による視界不良の発生条件で抽出されていた。降雪だけで視界不良になる事例なども含めて、より詳細な分析を進める予定である。






図1-24 視界不良の発生時のうち吹雪の発生条件によって抽出された事例数

## ◆ 冬期道路で観測されるデータと車両速度に基づく到着遅れ推定に関する一検討

北海道などの積雪寒冷地では吹雪による視界不良や路面凍結の影響を受けて、旅行速度が低下することにより、到着遅れが生じる。このような到着遅れは、すなわち損失である。冬期道路の環境を表すデータから到着遅れ時間を推定可能とする機能をデジタルツインに搭載することは、積雪寒冷地における冬期道路の移動支援に繋がる。冬期の到着遅れの原因となる速度低下の要因としては、視界状況や路面状態の悪化などが考えられるが、その要因は定量的には明らかになっていない。そこで令和6年度には、冬期道路の環境を表す路面状態、視界状況および風速のデータと車両速度の関係を分析した。

### 【対象の道路と分析に用いるデータ】

分析対象の地域は、信号遅れやサグなど、冬期特有の条件以外の影響を受けず、さらには、降雪量が多く、風が強い地域であることが望ましい。以上より、本研究では、図1-25に示す遠別町から天塩町を結ぶ国道232号の直線区間を分析対象とした。本研究プロジェクトで実装を進める道路モニタリングシステムでは、前方の視界状況の定量化と路面状態の判定に加えて、GNSSによる速度データを保存する機能を有している。本分析では、車両速度のデータとして、GNSS受信機より得られた速度を日付ごとに平均した値（平均速度）および最低値（最低速度）を用いる。また、路面状態を表すデータとしては、車載カメラにより得る画像を用いて、dry, semi-wet, wet, slush, fresh, iceの6種類に分類した結果を用いる。また、視界状況を表すデータとしては、車載カメラの画像から、視界レベルを数値化する指標であるWIPSを計算した結果を用いる。WIPSは数値が高いほど視界が良好であることを示しており、日付ごとの平均値を平均WIPS、最低値を最低WIPSとする。風速については、(財) 気象業務支援センターが公開する数値予報データを用いる。このデータは、1時間ごと、5kmメッシュであり、東西風速、南北風速はそれぞれ西風、南風を正としている。本研究では、車両位置から最も近いメッシュのデータを用いる。車両が通過した時刻と最も近い時刻の東西風速、南北風速を合成したデータを風速として扱う。




図1-25 分析対象の道路

### 【分析結果とその考察】

#### 1. 視界状況、風速および車速の関係

車両速度と視界状況および風速の相関係数を表1-26に示す。表1-26より、平均速度及び最低速度ともに、視界状況を表す数値である平均WIPSと最低WIPSとやや強い相関が見られる。これより、視界の悪化が速度低下に起因している可能性が高い。また、最低WIPSは、風速および東西風速と比較的高い負の相関が見られる。風速、東西風速および最低WIPSの関係を図4に示す。ここでは、風速を青色、東西風速を橙色でプロットしている。WIPSは数値が低いほど視界が悪化であることを示しており、東西風速は、西風を正としている。図1-27より、特に西風が強い日に、最低WIPSの数値も低い傾向にあることがわかる。これは西から強い海風が吹く日に視界が悪化することを示している。

表1-26 視界状況，風速および車速の相関関係

	平均速度	最低速度	平均 WIPS	最低 WIPS	風速	東西風速	南北風速
平均速度	1	0.77	<b>0.42</b>	<b>0.66</b>	-0.27	-0.12	0.42
最低速度	0.77	1	<b>0.59</b>	<b>0.69</b>	-0.06	-0.13	0.32
平均 WIPS	0.42	0.59	1	0.93	-0.30	-0.33	0.42
最低 WIPS	0.66	0.69	0.93	1	<b>-0.45</b>	<b>-0.41</b>	0.49
風速	-0.27	-0.06	-0.30	-0.45	1	0.90	-0.60
東西風速	-0.12	-0.13	-0.33	-0.41	-0.90	1	-0.39
南北風速	0.41	0.32	0.42	0.49	-0.60	-0.39	1




図1-27 風速および東西風速と最低WIPSの関係

## 2. 路面状態，視界状況，風速，および車速の関係

表1-28に，路面状態ごとの車両速度および視界状況を示す．表1-28より，路面に雪がない状態である dry, semi-wet, wetでは，路面に雪がある状態である slush, fresh, iceと比べて，いずれも平均速度が大きな値となっている．これより，路面に雪があることが，速度低下に起因している可能性が高い．また，路面状態が fresh のとき，平均WIPS，最低WIPSともに最も低く，最も視界レベルが悪い．これは新雪が比較的軽く，風により舞いあがりやすいことが原因として考えられる．

表1-28 路面状態、視界状況および車速の関係

路面状況		平均速度	平均 WIPS	最低 WIPS
雪なし	dry	65.87	7.91	6.62
	semi-wet	66.62	8.22	7.42
	wet	66.17	8.30	7.17
雪あり	slush	62.85	8.23	7.33
	fresh	60.33	<b>7.57</b>	<b>3.94</b>
	ice	64.35	7.89	5.04

本研究項目では、冬期道路で観測されるデータから車両速度の低下に起因する要素の分析を行った。新雪が積もった直後は雪が舞いやすく、その中でも強い海風が吹く日は、地吹雪により視界が悪くなり、車両速度が低下することが確認された。この車両速度の低下が到着遅れに作用すると考えられることから、道路の積雪量や風速のデータから到着遅れを推定できる可能性が示唆され、今後は、到着遅れを推定可能なアルゴリズムの構築に取り組む予定である。

#### ◆ 視界状況・路面状態・気象データの統合指標に関する検討

令和6年度には、視界状況、路面状態、および気象データを個別に分析するだけでなく、視界状況や路面状態などの実際の道路の状況が分かるデータと、降水強度分布や風のような気象データの融合解析により、冬期道路環境の悪化度合いを総合的に表す統合指標を生成可能とする手法を検討した。このような指標は、【テーマ4】「冬期における人の移動の負担軽減に資する情報提供に関する技術開発」において、道路利用者が行動を選択する上で参考になる情報であることが示されている。今後、統合指標を生成するアルゴリズムの具体化を進める予定である。

## 2. 【テーマ2】 冬期道路交通マネジメントを可能とするデータ集積プラットフォームに関する

### 技術開発

#### (1) プラットフォーム機能の拡充

#### ◆ 画像解析による走行ガイダンス機能付きセンチメートル級測位システムの構築


本項目では、道路の位置を正確に計測可能なシステムを構築する。本システムでは、非積雪期において、区画線の緯度経度を計測可能とする。これを基準データとしてデジタルツインに搭載することで、道路の位置をサイバー空間に再現可能となる。積雪寒冷地の冬期道路では、運転行動の結果として車両の走行位置は、道路環境に応じて変化する。本研究プロジェクトで構築する車載のエッジコンピュータは、1年をとおして稼働しており、車両の位置情報を記録して、サイバー空間に伝送する機能を有している。したがって、区画線の緯度経度情報が基準データとしてデジタルツインに搭載可能となれば、「夏期の走行履歴と区画線の距離」と「冬期の走行履歴と区画線の距離」が得られ、これらと比較することで、冬期に特異な走行が生じる様子を観測することが可能となる。

具体的には、比較的安価に入手可能な機器によって道路位置を正確に記録可能なシステムを構築した。提案するシステムでは、近年安価に入手可能となりつつあるCentimeter-Level Augmentation Service（以降、CLAS）に対応した受信機を用いて、高精度な計測を可能とする。CLAS対応受信機の他にも、カメラ、マイクロコンピュータ、ドライバに情報提示するためのモニタ、システムを固定するための治具で構成される。本システムのCLAS対応受信機のアンテナとカメラは、治具によってサイドミラーに装着される。カメラはアンテナ直下に配置され、路面を映したカメラの映像から、ドライバが区画線に沿って走行することを支援するアルゴリズムが組み込まれている。本システムを用いることで、車両を運転しながら高精度に道路位置を計測することが可能となる。

#### 【計測支援アルゴリズム】

本システムには、ドライバが区画線上を走行することを支援するガイダンス機能を実装する。具体的には、車両のサイドミラーに設置したカメラの映像より、車両の区画線からのずれと方向を判定し、図2-1に示すように、走行位置のずれの修正を促す情報を提示する。

車両の区画線からのずれと方向を判定するアルゴリズムを説明する。本システムは映像の縦軸下向きと車両の進行方向が一致することを想定しているが、設置の際にこれらの方向を合わせることは難しく、方向の不一致を補正するアルゴリズムが必要となる。また、システムを使用する時間帯や周辺的环境に応じて、明るさが時々刻々と変動する。さらには、区画線が経年劣化などにより掠れていることが想定される。以上のことから、本システムでは、映像の各フレームについて前処理として、アフィン変換、ヒストグラム平坦化、ガウスぼかしを行う。前処理を行った後は、区画線からのずれの検出を行う。具体的には、図2-2の緑線で囲まれた二つの領域に対して、ヒストグラムインタセクションと閾値処理を行うことにより、車両が区画線からずれた位置を走行しているかを判定する。区画線からのずれが検出された場合には、画像を二値化し、緑線で囲まれた二つの領域間で白色となったピクセル数を比較することにより、左右どちらにずれているかを判定する。



(a) 左にずれた場合



(b) 右にずれた場合

図2-1ガイダンスの例




図2-2 区画線からのずれを判定する計算に用いる領域

### 【システムのハードウェア構成】

システムのハードウェア構成について説明する．図2-3に構築したシステムの構成図を示す．本システムは、バッテリーでの駆動が可能なマイクロコンピュータ、カメラ、ドライバに情報提示するためのモニター、CLAS対応GNSS受信機、GNSSアンテナ及びカメラを固定する治具で構成される．本システムはバッテリー駆動が可能かつ、車両のサイドミラーにGNSSアンテナ及びカメラを取り付けるだけで使用可能なため、車種にとらわれず搭載が可能である．また、マイクロコンピュータには、区画線からのずれとその方向を判定し、ドライバの区画線上の走行を補助するアルゴリズムを演算するプログラムを実装する．本システムではマイクロコンピュータとして、Raspberry Pi 4を用いる．また、本システムでは、高精度な道路の位置を記録するため、みちびきのCLAS（センチメートル級測位補強サービス）に対応した受信機を用いる．CLAS対応受信機は、国土地理院が全国に整備している電子基準点を用いて計算されたセンチメートル級測位補強情報をみちびきから受信することで、単独でセンチメートル級の測位が可能である．本システムでは、GNSSアンテナを路面を撮影するカメラの直上に配置することで、ドライバがモニターからの情報提示を受けながら、区画線の正確な位置を記録可能とする．




図2-3 提案するシステムの構成図



### 【システムの性能評価】

提案するシステムの性能を評価する。具体的には実際の道路で、提案したシステムを用いて区画線の一種である車道外側線の位置を測位し、実際の車道外側線の位置からどの程度ずれずに計測できたかを計算する。

実験で用いる道路として、直線と曲線の2種の道路線形からそれぞれ3コースを選定した。システムを評価するためには、各コースの外側線位置の正解データが必要であるが、本実験では、CLAS対応GNSS受信機のアンテナが外側線上を通るようにアンテナとGNSS受信機を保持して歩行し、2Hzで外側線の緯度・経度座標を3回計測した。離散的な緯度・経度の情報から実際の車道外側線のように連続的なデータとするため、隣接する緯度・経度座標に直線補完を行った。評価する際には、提案システムにより計測した緯度・経度座標と3回計測を行った正解データそれぞれの距離をVincenty法で算出し、それらの算術平均を正解データからのずれの代表値として用いる。なお、距離は、中央線側を正、路側側を負として算出される。

本実験では、被験者2名に各コース、表2-4に示す3つの条件をそれぞれ3回、計9回走行してもらう。また、緯度・経度座標は10Hzで記録する。前処理及び区画線からのずれを検出する閾値のパラメータは、周辺環境に応じて設定した。条件ごとの走行する順序は、「情報提示+モニタからの映像」、「モニタからの映像のみ」、「情報なし」の順とする。これは、コースを複数回走行することによる慣れを考慮し、より被験者に対する補助が強い条件が先となるように設定した順番である。被験者が各コースを走行する際には、車両の速度を揃え、ステアリング操作に専念してもらう目的で、アダプティブクルーズコントロールを30km/hに設定して使用する。

実験結果を図2-5に示す。図2-5より、直線とカーブ両方の道路線形についてガイダンスを行った条件が最もずれが小さいことがわかる。これより、ガイダンス機能の有効性が確認できる。また、正解データからのずれが15cm程度で計測可能であることが確認できる。これより、道路の正確な位置情報の計測に寄与可能であることが確認できる。

表2-4 実験条件

実験条件
情報提示+モニタからのカメラ映像
モニタからのカメラ映像のみ
情報なし




図2-5 実験結果

## (2) 基幹システムの構築

本研究プロジェクトで構築するデジタルツインは、フィジカル空間に散りばめられた複数のエッジからのデータを大量に集積する。令和5年度には、初年度として、まずは複数の車載システムから常時送信される道路空間を撮影した画像およびエッジコンピューティングによって取得する解析結果のデータを受け入れるサーバのプロトタイプを構築した。具体的には、一般的なWebDAVシステムによって構築したデータを受信する仕組みを構築した。まずは、この一般的な仕組みにおいて、不定期に起動およびデータ送信する9台のエッジから、データをもれなく収受できることを確認した。

将来的には複数かつ大量のエッジからのデータ受信が想定される。そこで、認証プロセスやデータ受け入れの機能が常に速やかに実施されることが望ましい。現状のサーバはデータ受け入れ以外のタスク、例えば、デジタルツインとしてフィジカル空間にフィードバックする可視化インタフェースの演算を行う場合には、ストレージへのアクセスなどのレスポンスに課題があることを確認している。

そこで、令和6年度には上記の課題解決を目標として、今冬の稼働に向けてシステムの拡張に取り組んでいる。新システムでは、サーバの基本スペックを向上させると共に、物理サーバの上に3つの仮想サーバを配置する新たな仕組みを検討している。各仮想サーバの機能は、それぞれ、「フィジカル空間からのデータの受け入れとストレージ」、「シミュレーション」、および「情報提示」である。物理サーバが外部とのインターフェイスとなり、ポートフォワーディングによって、各仮想サーバと外部をやり取り可能とする。構築する新サーバは、昨年度と同様に、車載のエッジコンピューティングから、道路空間を撮影した画像と解析結果を受信すると共に、気象データやCCTVカメラの画像を分析した結果を集積する機能を実装する。加えて、各サーバ間でデータをやり取り可能な機能も実装する。

### 3. 【テーマ3】冬期道路交通マネジメントのための交通・気象データを利用したシミュレーション等に関する技術開発

#### (1) 雪害時における道路利用者の行動変容による効果検証（1年目）

##### ◆ 運搬排雪・拡幅除雪が冬期の幹線道路における交通流に与える影響

積雪寒冷地における冬期道路では、大雪により交通渋滞が発生する。冬期に発生する交通渋滞への対策として、道路の除排雪が行われている。例えば、札幌市内の主要幹線道路では、新雪除雪、拡幅除雪、および運搬排雪が行われている。このうち、拡幅除雪と運搬排雪は幅員を拡大することが可能なため、交通容量を増加させる効果がある。

北海道における道路の除排雪を取り巻く現状として、従事者の高齢化・減少や除雪費用の増加が課題であり、将来的には、現状の運用方法を維持することが困難となる可能性がある。そのため、より効率的に渋滞の影響を軽減可能な除排雪を考える必要がある。効率的に渋滞の影響を軽減可能な除排雪を計画するシミュレーション機能をデジタルツインに搭載可能とすることは、積雪寒冷地における移動の支援に繋がる。

除排雪の計画をシミュレートするためには、運搬排雪・拡幅除雪により変化する交通流の状態を定量的に表現可能とする必要がある。ここで、集計QK図上に発現するヒステリシスループの面積（以降、ループ面積）が拡大することは、平均速度と交通容量の低下を意味する。そこで、本項目では、札幌の冬期道路ネットワークを対象として、集計QK図上に発現するループ面積が、運搬排雪・拡幅除雪により変化する交通流状態を定量的に表現可能であるかを検証した。

分析対象とした道路区間は、図3-1に示す国道36号の札幌市豊平区豊平3-1～清田区里塚2-6の上り車線（片側2車線、区間総延長は11.8km）とした（以降、分析対象区間）。分析対象区間の24時間交通量は37,147台（札幌市清田区、道路交通量調査・2022年）であり、札幌市内において最も交通量が多い主要路線の一つである。



図3-1 分析対象の道路

本分析では、ETC2.0プローブデータを用いてループ面積を計算する．15分毎に分割した時間帯 $t$ （総時間帯 $T=24 \times 4=96$ /日）におけるリンク $i$ の車両存在台数 $k_t^i$ （台/km）・平均速度 $v_t^i$ （km/15min）・交通流率 $q_t^i$ （台/15min）を以下の式(8)～(10)によって求めた．ETC2.0 プローブデータのうち、時間帯  $t$  における情報件数を  $A_t^i$ ，平均速度  $u_t^i$  として用いた．

$$q_t^i = A_t^i \quad (8)$$

$$v_t^i = \frac{u_t^i}{4} \quad (9)$$

$$k_t^i = \frac{q_t^i}{v_t^i} \quad (10)$$

式(11), (12)により対象区間の走行台キロ $P_t$ （台・km/15min）と車両存在台数 $N_t$ （台/15min）を求めた．

$$P_t = \sum_{i=1}^{I_t} q_t^i l^i \quad (11)$$

$$N_t = \sum_{i=1}^{I_t} k_t^i l^i \quad (12)$$

$A_t^i$  :  $t$  におけるリンク $i$  を走行したプローブ車両の台数（台）

$u_t^i$  :  $t$  におけるリンク $i$  の平均速度(km/h)

$l^i$  :  $t$  におけるリンク $i$  のリンク長(m)

$I_t$  :  $t$  においてプローブ車両が走行したリンクの総数

$q_t^i$  :  $t$  におけるリンク $i$  の交通流率(台/15min)

$v_t^i$  :  $t$  におけるリンク $i$  の平均速度(km/15min)

$k_t^i$  :  $t$  におけるリンク $i$  の交通密度(台/km)

上記の式により得る数値から集計QK図を作成し、6:00-8:59の全プロット（計12プロット）の凸包面積をループ面積と定義した．

図3-2に、2022年2月9日から2022年2月17日にかけて実施された拡幅除雪と運搬排雪に伴うループ面積の変化を示す．2月9日は、2月5日から6日にかけて合計61cmの降雪があったため、路肩の堆雪が増加し、道路有効幅員が減少した．その結果、交通容量が減少したため、朝のラッシュ時にネットワークブレイクダウンが発生し、ループ面積が大きくなったと考えられる．2月10日は拡幅除雪、14日、16日、17日、18日は運搬排雪が前日の夜に行われた．そのため、道路有効幅員が増加し、交通容量が増加した．結果として、ネットワークブレイクダウンが軽減され、ループ面積が徐々に減少したと考えられる．2月15日も前日の夜に運搬排雪が行われた．そのため、道路有効幅員が増加し、交通容量が増加した．しかし、ループ面積が増加した．周辺道路から国道36号への車両の流入が増え交通需要が大きくなり、集計交通流率が増加したため、面積が大きくなったと考えられる．以上の内容より、ループ面積が、運搬排雪・拡幅除雪に伴い変化する交通流の状態を定量的に表現可能な指標となる可能性が示唆された．

本項目では、札幌の冬期道路ネットワークを対象に、ETC2.0プローブデータから集計QK図を作成し、6時から8時59分の全プロットの凸包の面積（ループ面積）を求め、運搬排雪・拡幅除雪に伴う面積の変化を分析した。分析の結果、運搬排雪・拡幅除雪に伴いループ面積が減少することを確認した。これより、ループ面積により、運搬排雪・拡幅除雪により変化する交通流状態を定量的に表現可能となることが示唆された。




図3-2 ループ面積と運搬排雪・拡幅除雪の作業タイミング

## (2) ミクロ交通シミュレーションを活用した交通制御支援モデルの精度検証（1年目）

現地においてリアルタイムに通過車両台数をカウントし、シミュレーション上で予測される高速道路上の渋滞長を道路管理者に提供することが可能となれば、信号等のインフラ協調等、より高度な道路交通管理が可能になるものと考えられる。しかし、これらの要素技術を統合的に利用するためには、シミュレーションに必要となる入力値をリアルタイムに把握することが必要となる。また渋滞を予測するシミュレーションの実行時間が長く、予測に時間を要することが課題となる。

上記の課題解決のためにカメラとカメラ動画から車両台数をリアルタイムに解析するシステムを小型PCに登載したデバイスを作成した。本研究ではこれをエッジAIと呼ぶ。エッジAIは車種別の通過交通量を観測現場でカウントする機能を有する。一方、シミュレーションの実行時間を短縮するためには、シミュレーションの入力値（交通量）と出力値（滞留長）の関係性を適切に再現するモデルを開発し、シミュレーションと代替することで、エッジAIからリアルタイムに得られる入力値（交通量）データから短時間で出力値（滞留長）を得ることが考えられる。このモデルをクラウドサーバーに登載し、エッジAIとインターネットを介して接続することで、リアルタイムな渋滞予測が可能になる。本研究では、クラウドサーバー上の短期渋滞予測モデルをクラウドAIと呼ぶ。

筆者らは、このように実際の道路空間上にあるエッジAIからリアルタイムに得られる入力値データをクラウド上の渋滞短期予測モデル（クラウドAI）で処理し、その予測結果をクラウドAIからAPIを介して車両や道路附属インフラを協調させるシステムの概念実証（Proof of Concept）を試みている。

本研究は上記中、リアルタイムに交通観測を行えるエッジAIと、短期渋滞予測を行うクラウドAIをオンラインで動的に連携させるための方法論として、交通シミュレーションを近似した機械学習モデ

ルを構築することを目的とする。これによりマイクロ交通シミュレーションを用いた渋滞予測に要する計算時間を大幅に減らすことが可能となる。本研究では、交通流理論に基づいたシミュレーションから渋滞状況の短期予測を行う機械学習モデルを構築し、エッジAIの車両判別精度を考慮した精度分析を行った。

### （３）気象データと車両前方画像を用いて冬期の路面状態をシミュレートする手法

デジタルツインでの道路の路面や視界の先読み情報を生成するため、過去の路面データと気象データに基づく空間方向および時間方向の系列データを用いて、積雪寒冷地における将来の路面状態をシミュレーションする手法を検討した。提案手法により得られる結果を活用することで、従来の道路管理から拡張し、道路環境を先読みした新たな取り組みが可能となると考えられる。本研究で構築を進める道路モニタリングのエッジコンピュータでは、前方の視界状況の定量化と路面状態の判定に加えて、車両走行時に得られた映像、それに紐づく位置情報、および日時などのデータを保存する機能も有している。

本項目では、この蓄積されたデータを活用し、従来では路面状態の推定にとどまっていた取り組みを路面状態のシミュレーションに拡張する。令和５年度は、路面データと気象データに基づく空間方向の系列データを用いて、積雪寒冷地における路面状態をシミュレーションする手法のプロトタイプを検討した。

令和６年度では、前年度までの空間方向に加えて、時間方向の系列データを新たに導入することで、より高精度に路面状態をシミュレーション可能とすることを目標とした。令和６年度に構築した手法では、空間方向および時間方向の系列データそれぞれを入力として路面状態予測を行うモデルを構築し、各モデルの暫定的な予測結果に対する確からしさ（以降、確信度）を用いることで、時空間の周期性を考慮した路面状態のシミュレーションを行う。各モデルには、系列データを効率的に学習できるように設計されているLSTM[8]を用いる。これにより、年単位の長期で周期性をもつ路面状態に対しても、高精度なシミュレーションの実現が期待できる。

[8]S. Hochreiter and J. Schmidhuber, "Long Short-Term Memory," in Neural Computation, vol. 9, no. 8, pp. 1735-1780, 15 Nov. 1997.

## 【時空間方向の系列データを用いた路面状態のシミュレーション】

### 1. 空間方向の系列データを用いた暫定的な予測】

予測モデルでは、 $i$  日の区間  $j$  における路面状態と、 $i$  日と  $i+1$  日の気象データから構成されるデータ  $\vec{D}_{i+1,j}^{spatial}$  を入力として、 $i+1$  日の区間  $j$  における6種の路面状態それぞれの確率  $p_{i+1,j}^{l,spatial}$  ( $l \in \{dry, semi\ wet, wet, slush, ice, fresh\}$ ) が(13)式のように計算され出力される。

$$p_{i+1,j}^{l,spatial} = LSTM(\vec{D}_{i+1,j}^{spatial}) \quad (13)$$

## 2. 時間方向の系列データを用いた暫定的な予測

空間方向の系列データを入力とする予測モデルと同様に、 $i$  日の区間  $j$  における路面状態と、 $i$  日と  $i+1$  日の気象データから構成されるデータ  $\vec{D}_{i+1,j}^{temporal}$  を入力として、 $i+1$  日の区間  $j$  における6種の路面状態それぞれの確率  $p_{i+1,j}^{l,temporal}$  ( $l \in \{dry, semi\ wet, wet, slush, ice, fresh\}$ ) が(14)式のように計算され出力される。

$$p_{i+1,j}^{l,temporal} = LSTM(\vec{D}_{i+1,j}^{temporal}) \quad (14)$$

## 3. 暫定的な予測結果に対する確信度を用いた路面状態の予測

空間方向および時間方向の系列データそれぞれを用いた暫定的な予測の結果に基づいて、最終的な路面状態の予測を行う。具体的には、(15)式のように、各ラベルに対する確信度が最大となるラベルを最終的な予測結果とする。

$$\ell_{i+1,j} = \arg \max_k p_{i+1,j}^{k,z} \quad (15)$$

ここで、 $p_{i+1,j}^{k,z}$  ( $z \in \{spatial, temporal\}, l \in \{dry, semi\ wet, wet, slush, ice, fresh\}$ )は、式(14)および式(15)で得る暫定的な予測結果に対する確信度を表している。

### 【シミュレーション手法の性能確認】

ここでは、北海道で実際に観測された道路データと気象データから構築する空間方向と時間方向の系列データのデータセットを用いてモデルを構築し、ある日における道路全区間の路面状態をシミュレーションする。具体的には、図3-3に示す、北海道の宗谷地方にある高規格道路の「幌富バイパス」における20kmの道路から獲得した道路データを用いる。

本実験では、 $i$ 日の道路データと、 $i$ 日と $i+1$ 日の気象データを入力として、 $i+1$ 日の路面状態をシミュレーションする。学習に用いる350日分のデータセットのうち、230日分を学習データセットに、120日分をテストデータセットとした。また、比較手法としては次の2つを用いる。



図3-3 分析対象の道路

#### (A) 空間方向の系列データのみを用いた手法(比較手法1)

比較手法1では、空間方向の系列データを入力とするLSTMにより路面状態をシミュレーションする。提案手法と比較手法1を比較することによって、空間方向および時間方向の系列データを併用することの有効性を確認する。

(B) 時間方向の系列データのみを用いた手法（比較手法2）

比較手法2では、時間方向の系列データを入力とするLSTMにより路面状態をシミュレーションする。提案手法と比較手法2を比較することによって、空間方向および時間方向の系列データを併用することの有効性を確認する。

実験結果を表3-4に示す。表より、提案手法と他の手法と比べると、F値において提案手法の方が同等の値または高い値となることが確認できる。特に、ラベル“Snow”の再現率が他の手法に比して高い値となっている。“Snow”は、路面が凍結した状態を含むラベルであり、道路を安全に移動可能とするため先読み情報として、最も重要な情報であることから、提案手法の有効性が確認できる。

以上のことから、空間方向および時間方向の系列データを併用したシミュレーションの有効性が確認できる。しかしながら、さらなる精度向上は必要であり、「デジタルツインにおける路面と視界の先読み情報」を提供可能な仕組みの構築に向けては、アルゴリズムの高度化、さらにはCCTVから得るデータなどとの連携も引き続き検討が必要である。

表3-4 各手法の再現率、適合率、F値

	比較手法 1			比較手法 2			提案手法		
	dry	wet	snow	dry	wet	snow	dry	wet	snow
適合率	0.66	0.68	0.75	0.73	0.56	0.75	0.71	0.67	0.75
再現率	0.79	0.48	0.83	0.71	0.48	0.86	0.74	0.46	0.92
F値	0.72	0.56	0.79	0.72	0.52	0.80	0.72	0.55	0.83



#### 4. 【テーマ4】冬期における人の移動の負担軽減に資する情報提供に関する技術開発

本テーマでは、リアルタイム性の高い多様な情報（視程・路面・遅延情報等）や注意喚起のアラート等の有用性の高い情報を想定し、利用者の行動選択に訴求する情報提供内容について検討する。

##### ◆情報提供内容・手段の検討

令和5年度の研究では、ドライバー自身に安全な交通行動を促すようなソフト面での対策として、利用者の行動選択に訴求する情報提供内容について検討するため、Webシステムで情報提供されることを想定したアンケート調査を行い、情報提示方法の違いがドライバーの行動意図に与える影響と効果的な情報の提示方法について考察した。情報提示方法により、冬期における日常的な行動と、具体的な情報提示後の行動意図は異なるという結果が得られている。さらに、視界状況を文字情報だけでなく道路画像を用いて提示することが危険を回避する行動意図を促すことにおいて有効であることも明らかとした。

令和6年度の研究では、前年度と同様にドライバーに対してアンケート調査を行った。具体的には、2023年の冬期に試験的に提供した情報の提示を含んだアンケート調査を行い、道路状況や情報の理解度が行動選択に与える影響について考察した。令和5年度のアンケートと異なる点は、架空の情報ではなく実際に提供した情報を評価できる点、道路状況と情報の理解度による行動選択の変化を分析できる点である。

本調査では、ドライバーに対して架空の状況を想定してもらい、提示された冬期の道路情報を閲覧したうえでどのように行動するか、また、行動を選択する際にどの情報を参考にしたかなどを尋ねた。ここで、架空の状況とは、「現在は冬期の9:00であり、今から稚内を出発して図4-1に示したオロロンラインルートを選択し、乗用車を運転して札幌へ向かおうとしている」というものである。同時に、事前情報として稚内・旭川・留萌・札幌の4地域における当日の9:00から24:00までの3時間ごとの天気予報をドライバーに示した。




図4-1 わっかない号の経路



## (2) 行動を選択する上で参考にした情報

回答者が行動を選択するうえで参考になったと評価した順位が高い情報ほど、高得点となるように配点し、それぞれの情報の合計点数を算出した。この点数を各情報ごとに合計した結果を表4-3に示す。合計点数が高い程、高い順位で選ばれた回数が多い、すなわち行動を選択するうえで参考になったことを意味する。表4-3より、「道路の通行困難区間の状況」と「道路定点カメラによる視界状況」は現況・予測ともに、合計点数が高く、全問正解者も一部不正解者も高く評価していることが分かった。

表4-3 各情報提示の点数（点数が高いほど、行動を選択する上で参考になったことを意味する）



次に、道路状況に適した行動を選択した人がよく参考にした情報について考察した。まず、道路状況に適した行動を選択した人とは、道路状況が非常に悪いAでは何かしらの予定を変更すること、降雪がなく道路状況が良いCでは予定の変更が必要ないため、予定通りを道路状況に適した行動とした。また、少し降雪があるBについては適切な行動を決めることができないため、今回はAとCの回答者に絞って考察した。具体的には、各情報ごとに、先ほど説明した順位付けから算出された点数を現況と予測で合計し、情報の種類ごとの評価点数を算出した。この点数が最も大きい情報を最もよく参考にした情報とした。

各情報の評価点数を表4-4に示す。表4-4より、道路状況に適した行動を選択した回答者を含む多くの回答者が高く評価した情報は、「道路定点カメラによる視界状況」と「道路の通行困難区間の状況」であった。「道路定点カメラによる視界状況」は、提示した5つの情報の中で唯一実際の道路状況の画像を見ることができる情報であり、ドライバーにとって画像を用いた道路状況の提供が有用であると考えられる。また、「道路の通行困難区間の状況」が高く評価されていたことから、道路状況や気象情報から統合的に判断する通行困難状況を示した情報の提供が有用であると考えられる。

回答者が行動を選択するうえで参考にした情報として、「道路定点カメラによる視界状況」と「道路の通行困難区間の状況」が高く評価されていることが明らかとなった。このことから、実際の道路状況を画像を用いて提供することや、道路状況や気象情報から統合的に判断する通行困難状況を示した

情報の提供が求められていると考えられる。さらに、これらの情報は道路状況に適した行動を選択した回答者からも高く評価されており、危険を回避する行動選択を促すうえでも有効な情報であることが示唆された。今後の展望としては、まず、「道路の通行困難区間の状況」の提供の実現に向けて、通行困難区間の情報を生成可能な手法の構築に取り組む必要がある。また、車載カメラによる「視界状況・路面状況・バスの走行速度」に加えて、車載カメラの映像を提示可能な機能を実現させたいと考えている。さらには、情報を正しく読み取ることができなかった原因を分析し、あらゆる人に対して正しく道路状況を読み取ってもらえる情報の提示方法を検討していきたい。

表4-4 順位付けから算出された点数を現況と予測で合計した結果

	全て				全問正解				一部不正解			
	道路状況 非常に悪い		道路状況 良い		道路状況 非常に悪い		道路状況 良い		道路状況 非常に悪い		道路状況 良い	
	予定 変更	予定 通り	予定 変更	予定 通り	予定 変更	予定 通り	予定 変更	予定 通り	予定 変更	予定 通り	予定 変更	予定 通り
道路定点カメラによる 視界状況	9	0	4	11	5	0	1	4	4	0	3	7
車載カメラによる「視界状況・ 路面状況・バスの走行速度」	4	0	2	3	2	0	0	3	2	0	2	0
ナウキャストによる 降水強度分布の状況	3	1	0	5	3	1	0	2	0	0	0	3
風速・風向の状況	1	1	2	1	1	1	1	1	0	0	1	0
道路の通行困難区間の状況	14	4	0	13	10	1	0	5	4	3	0	8
合計	31	6	8	33	21	3	2	15	10	3	6	18

#### ◆実証実験の実施

令和6年12月から令和6年3月の期間で実証実験を行う。1次情報提供として、SNSであるX（旧Twitter）を用いてリアルタイム性の高い情報提供を行う（図4-5）。また、以下の3つの情報提供システムを試行する。

- 1）車載システムで得られた視界状況などを提供（図4-6）
- 2）（一般社団法人）北海道開発技術センターによる、国道に設置されたCCTV画像を用いた道北エリア、道央エリアの視界状況の提供（図4-7）
- 3）（一般財団法人）日本気象協会北海道支社によるレーダー（函岳，美深町）による高解像度降水ナウキャスト（Xバンドレーダーも合成された降水量・雨雲情報・風の分布図・吹雪視程・降雪量メッシュ）の提供（図4-8）



図4-5 Xによるポータル兼リアルタイム性の高い情報提供Xでの提供の例

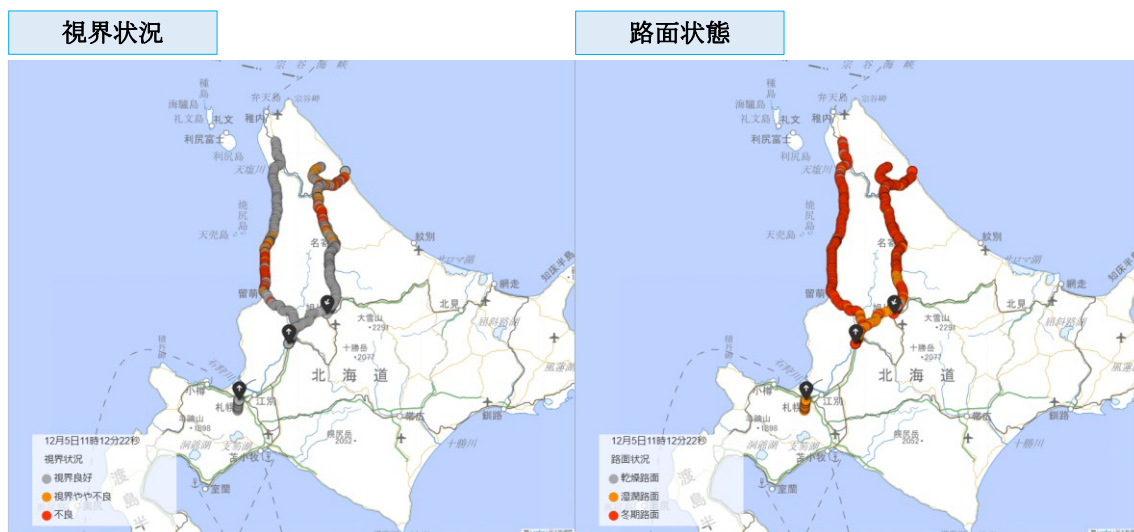


図4-6 車載システムが判別した視界（左）と路面（右）の情報提供の例



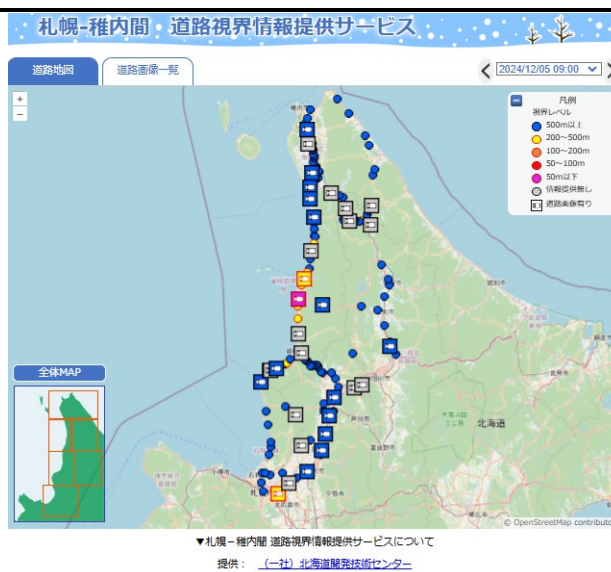


図4-7 CCTV画像を用いた視界状況提供システムの例

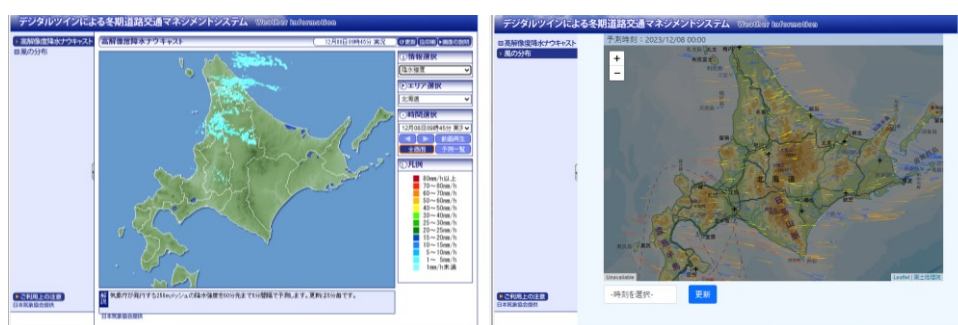


図4-8 降水強度（左）と風向風速（右）の情報提供の例（再掲）

図4-9は、2024年12月5日12時の各情報を示している．この日の北海道は、北部を中止に大雪となり、留萌市周辺で視界不良が発生した．図4-9に示すとおり、各視界情報（車載システム、CCTV画像、気象データによる吹雪視程）ともに、視界が悪化している様子を情報提供できていることがわかる．

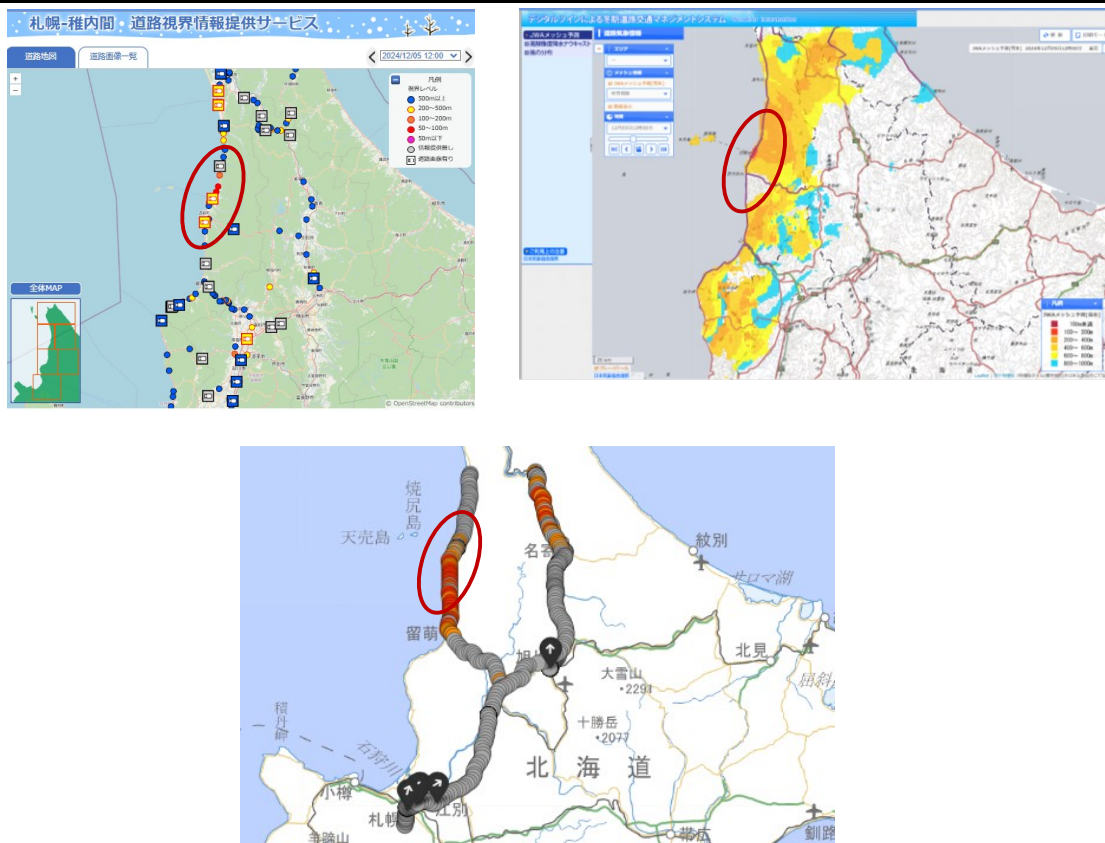


図4-9 2024年12月5日の情報提示（視界情報）の例

利用実態のログやシステムの試験稼働の様子に基づいてデジタルツイン技術の有効性を高める検討を行うことを目的として、本実証実験を行う予定である。

#### ◆コミュニティラジオ放送局による視界情報の情報提供について

令和6年度の研究では、ドライバー自身に安全な交通行動を促すようなソフト面での対策として、コミュニティラジオ放送局（エフエムもえる、エフエムわっかない）を活用した情報発信を予定している。具体的には、図4-6に示された車載システムが判別した視界情報を基に、ラジオ放送を通じて吹雪や地吹雪などにより視界が特に悪化している道路区間の情報を提供を予定している。

下記に実際にラジオ内で放送する際の手稿（案）を示す（図4-10）。

#### ◆ 留萌、宗谷地方の道路視界放送原稿（案）

【放送タイミング：道路交通情報（高速道路、高規格道路の道路規制情報）終了後】

♪（ジングル）SE チャイム♪

♪ BGM スタート

現在時刻は、〇〇 時 〇〇 分

ここからは、北海道大学 先端モビリティ工学研究室、冬期道路交通マネジメントシステムから最新の深川留萌自動車道、国道232号で、吹雪や地吹雪の発生などにより特に視界が悪くなっている道路区間をご紹介します。

まずは深川留萌自動車道！

- ・ 〇〇市から〇〇町までの区間（赤丸が並んでいる場合）
- ・ 〇〇市から〇〇町までの一部区間（赤丸が途切れている場合）

以上の区間では、視界がかなり悪くなっている模様です。

※オレンジしかない場合

以上の区間では、視界が悪くなっている模様です。

※灰色しかない場合

現在のところ視界が悪くなっている区間があるという情報は入っていません。

つづいて、国道232号！

- ・ 〇〇市（町、村）から〇〇町（村）までの区間（赤丸が並んでいる場合）
- ・ 〇〇市（町、村）から〇〇町（村）までの一部区間（赤丸が途切れている場合）

以上の区間では、視界がかなり悪くなっている模様です。

※オレンジしかない場合

以上の区間では、視界が悪くなっている模様です。

※灰色しかない場合

現在のところ視界が悪くなっている区間があるという情報は入っていません。



北海道大学 先端モビリティ工学研究室、冬期道路交通マネジメントシステムは、宗谷バスに搭載されたカメラから送信される視界の情報を分析し、提供しています。実際に通行する際の視界の状況とは異なる場合がありますのでご注意ください。

ここまでは、深川留萌自動車道、国道232号で特に視界が悪くなっている道路区間をご紹介します。

♪ BGM フェードアウト

### ※補足

- ・アナウンスは留萌を起点に行う。  
(留萌から羽幌が全部赤丸の場合 → 留萌市から羽幌町までの区間)  
(留萌から羽幌の間に赤丸がある場合→留萌市から羽幌町までの一部区間)  
※深川留萌自動車道に関してはリスナーに馴染みがある IC 毎のアナウンスにしました。

- ・開始当初の段階では、視界の情報部分のみを使用する。(左下の画面)

- ・CCTV の情報、北海道大学さんが道路交通情報センターと契約してからとなります。当面は、バスの情報のみをアナウンスします。

- ・ソースの出所に関しては前後2回アナウンスするのが定石ですが、システムの説明が直前に入るので少し短縮してみました。

- ・放送時間は宗谷バスの運行ダイヤに合わせて検討が必要！ → 放送のタイミングについて (案)

朝 (10:05) 国道232号のみ

昼 (12:05) 国道232号、深川留萌自動車道

夕 (16:05) 国道232号、深川留萌自動車道

### 【画面イメージ】



図4-10 留萌、宗谷地方の道路視界放送原稿 (案)

## ⑦中間評価で指摘を受けた事項への対応状況

### ◆ 中間評価結果（意見）

冬期道路交通に関する情報の収集・シミュレーション・提供及びデータ集積プラットフォームの構築において、多岐にわたるテーマが設定され、それぞれ堅実に進捗している。一方、個別テーマを統合して得られる成果が未だ不明瞭であり、将来的に目指しているシステムの全体像、その中での各テーマの位置付け、本研究での到達目標を明確にして、取り組む必要がある。よって、指摘事項に留意しながら現行のとおり推進することが妥当であると評価する。

### ◆ 今後の研究計画・方法への指摘事項等と対応状況

・ 個別テーマ間の関係性を明らかにするとともに、研究開発全体のターゲットを明確にして研究開発を進めていただきたい。システムを適用する地域（都市・地方）や場面（平常時・異常時）等、現場での活用をイメージし、新たに何が実現するかを具体化して取り組んでいただきたい。

→ 冬期の北海道は、郊外部の視界不良等、都市内の幅員減少等の道路状況変化があり、都市間移動においては両者に対応したデジタルツインの構築が必要と考えている（図1）。

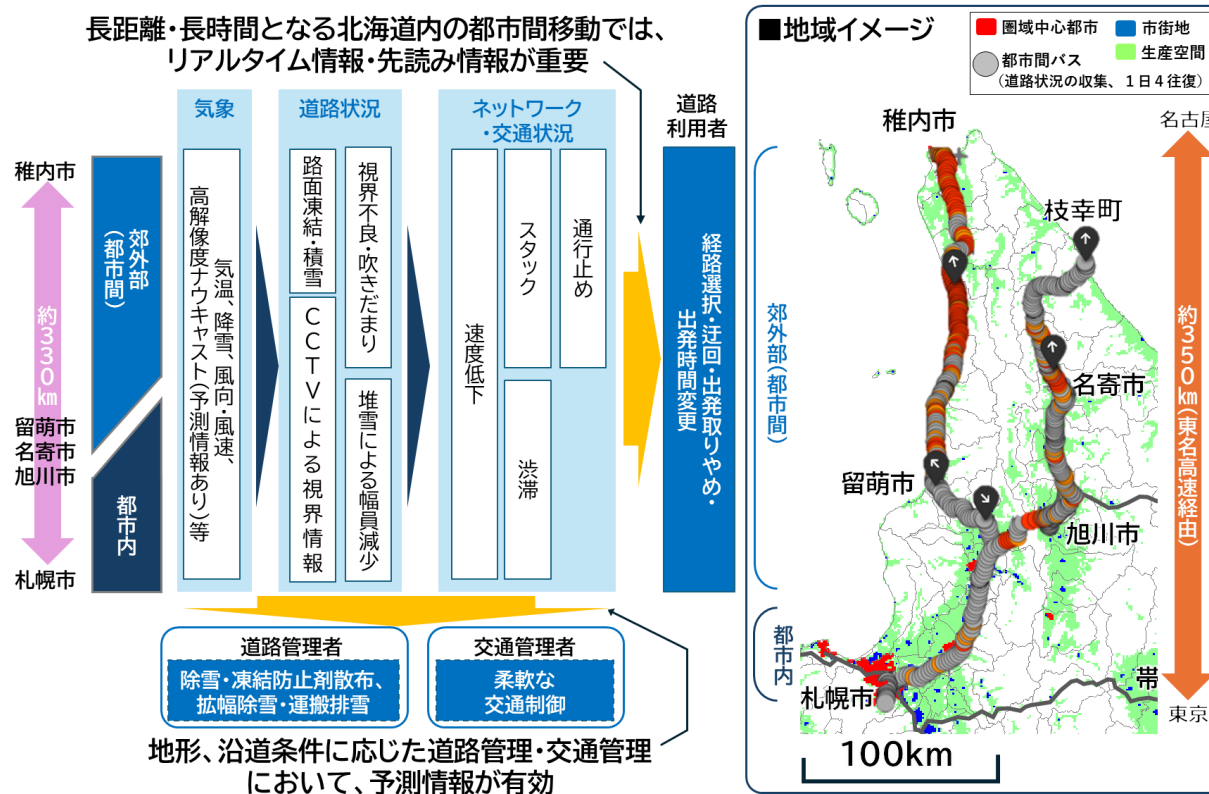


図1 デジタルツイン全体像イメージ

・テーマ1の「リアルタイムモニタリング車両・対象路線」やテーマ2などのシステム開発・実装系においては、仕様や要求水準をある程度明確にし、妥当性を判断して取り組んでいただきたい。テーマ2のデータ集積プラットフォームは、初期段階では安定的な稼働を目指し、拡張性を持たせつつも機能を絞り込むと良いのではないかな。

→令和5年度にはプロトタイプサーバをまず構築し、その挙動を観察したところであるが、令和6年度までには、デジタルツインの時空間解像度の向上が必須であるために、データ集積プラットフォームを拡張しつつ、安定的な稼働となる仕組みとした。令和6年度の残り令和7年度にかけて、デジタルツインの機能などはヒアリングを重ねることで必要とされるものに今後限定しつつ、将来の機能拡張性を想定した仕組みとしていく。令和7年度には他地域への展開などを見据え、仕様や要求水準についてこれまでに得た試行結果に基づいて明確にしていく。

・「エッジコンピュータ」「アンサンブルデータ」等の道路管理者に不慣れな用語を、分かりやすく説明していただくようお願いしたい。

→【テーマ3：冬期道路交通マネジメントのための交通・気象データを利用したシミュレーション等に関する技術開発】(2)報告部分において各用語の概念を記載した。また発表論文においても、同様の説明を記載した。また本年度最終報告書において改めて用語について整理する予定である。

## ⑧研究成果の発表状況

### 【学会発表】

- 1) Sho Takahashi, Masahiro Yagi, Toru Hagiwara, "An Edge-computing System for Observing Road Surface Condition and Visibility in Winter Road," Presentation at International Conference on Road Weather and Winter Maintenance, (2023)
- 2) Toru Hagiwara, Masanori Matsuda, Sho Takahashi, "Evaluation of Traffic Congestion due to Heavy Snowfall in Sapporo Metropolitan Area Using Macroscopic Fundamental Diagrams (MFD)," Presentation at International Conference on Road Weather and Winter Maintenance, (2023)
- 3) Kotaro Yamashiro, Sho Takahashi, Toru Hagiwara, "A Study on Relationship Between Precipitation Intensity of XRAIN and Snow-depth on the Ground," Presentation at International Conference on Road Weather and Winter Maintenance, (2023)
- 4) 山城皓太郎, 萩原亨, 高橋翔, "Macroscopic Fundamental Diagram 理論に基づく冬期の降雪強度が札幌市中心部の交通流に与える影響に関する研究," 第43回交通工学研究発表会, (2023)
- 5) Ryosuke Hayashi, Masahiro Yagi, Sho Takahashi, Toru Hagiwara, "An Observation Method of Vehicle Lateral Position Based on Map Matching in Winter Road Condition," IEEE 12th Global Conference of Consumer Electronics (GCCE2023), (2023)
- 6) Fukuda Eiki, Masahiro Yagi, Sho Takahashi, Toru Hagiwara, "A Note on Visibility Level Estimation Based on Third-order Tensor Completion Using CCTV Images and GPV Data," IEEE 12th Global Conference of Consumer Electronics (GCCE2023), (2023)
- 7) Masahiro Yagi, Ryo Sato, Sho Takahashi, Toru Hagiwara, "An In-Vehicle Edge Computing System for Monitoring Nighttime Winter Road Visibility," IEEE 12th Global Conference of Consumer Electronics (GCCE2023), (2023)
- 8) 繁澤朗, 八木雅大, 高橋翔, 萩原亨, "運転者の姿勢や運動に基づく二輪車の識別に関する検討," 令和5年度 電気・情報関係学会北海道支部連合大会, 101, (2023)
- 9) 笹枝悠人, 八木雅大, 高橋翔, 萩原亨, "車載システムによる視界評価の実装に向けた課題の検討," 令和5年度 電気・情報関係学会北海道支部連合大会, 140, (2023)
- 10) 高橋翔, 八木雅大, 萩原亨, 佐藤諒, "複数識別器の Late-fusion による夜間の視界レベル推定のEdge-computing に関する検討," 日本道路会議, (2023)
- 11) 植西康太, 八木雅大, 高橋翔, 萩原亨, "道路空間を観測するエッジAIの類似度を用いた再学習のためのエッジ選択手法," AI・データサイエンスシンポジウム, (2023)

- 12) 繁澤朗, 八木雅大, 高橋翔, 萩原亨, “OpenPoseを用いた道路映像における二輪車の識別に関する一考察,” 第68回土木計画学研究発表会・秋大会, 7506 (2023)
- 13) 林亮佑, 八木雅大, 高橋翔, 萩原亨, 松本一城, “GNSSデータを用いた冬期道路環境における走行位置の観測,” 第68回土木計画学研究発表会・秋大会, 7144 (2023)
- 14) 福田英輝, 八木雅大, 高橋翔, 萩原亨, “低ランク近似に基づく離散データの更新を導入したテンソル補完による視界レベル推定に関する一考察,” 第68回土木計画学研究発表会・秋大会, 7144 (2023)
- 15) 佐藤陽介, 蛭名将平, 佐々木悠貴, Tran Vinh Ha, 有村幹治, “携帯電話の位置情報集計データを用いた2022年札幌市大規模雪害時の交通行動変容,” 第68回土木計画学研究発表会・秋大会, (2023)
- 16) 金家侑希, 瀧本康太, 江戸元希, 有村幹治, “エッジAIの車両判別精度を考慮した高速道路の短期渋滞予測,” 第68回土木計画学研究発表会・秋大会, (2023)
- 17) Yasuhiro Nagata, Toru Hagiwara, Sho Takahashi, Masahiro Yagi, Genki Ooi, “Developing Prototype of Digital Twin for Winter Road Maintenance,” TRB Annual Meeting, (2024)
- 18) 本坂健太, 植西康太, 八木雅大, 高橋翔, 萩原亨, “冬期道路における時系列データを用いたLSTMによる路面状況予測に関する検討,” 電子情報通信学会技術報告(安全・安心な生活とICT研究会), (2024)
- 19) 木下洋輝, 八木雅大, 高橋翔, 萩原亨, “車載カメラ映像を用いたLate-fusionに基づく複数識別器の確信度統合による道路の狭窄状況の識別に関する検討,” 令和4年度土木学会北海道支部年次学術研究発表会, D-13, (2024)
- 20) 植西康太, 八木雅大, 高橋翔, 萩原亨, “過去の路面データと気象データに基づく LSTM を用いた空間方向の系列データでの冬期路面の状態予測の検討,” 令和4年度土木学会北海道支部年次学術研究発表会, F-10, (2024)
- 21) 笹枝悠人, 八木雅大, 高橋翔, 萩原亨, “夜間の視界レベルを推定するエッジコンピューティングの車載カメラ映像の特徴に注目した高速化に関する検討,” 令和4年度土木学会北海道支部年次学術研究発表会, F-09, (2024)
- 22) 山城皓太郎, 萩原亨, 高橋翔, 松田真宜, “XRAIN降水強度を用いた冬期の交通状態分析,” 交通工学論文集(特集号), vol. 10, no. 1, pp. A\_198-A\_207, 2024.
- 23) 繁澤朗, 八木雅大, 高橋翔, 萩原亨, “道路空間における一般物体認識とヒトの姿勢推定に基づく自転車とバイクの識別,” AI・データサイエンス論文集, (2024) (掲載決定)
- 24) 林亮佑, 八木雅大, 高橋翔, 萩原亨, 松本一城, “GNSS データを用いた冬期道路環境における走行位置の可視化,” AI・データサイエンス論文集, (2024) (掲載決定)

- 25) Hiroki KINOSHITA, Masahiro YAGI, Sho TAKAHASHI, Toru HAGIWARA, “A Road Narrowing Condition Estimation from In-vehicle Camera Videos via Late-Fusion based on Confidence Level Integration of Multiple Classifiers,” Intelligence, Informatics and Infrastructure, (2024) (掲載決定)
- 26) 土井康正, 萩原亨, 吉井 稔雄, 高橋 翔, “運搬排雪・拡幅除雪が冬期の幹線道路における交通流に与える影響,” 第44回交通工学研究発表会, (2024)
- 27) Masahiro Yagi, Yuto Sasaeda, Sho Takahashi, Toru Hagiwara, Toshio Yoshii, “A Note on Issues for Implementation of Visibility Level Recognition Using In-vehicle Camera Videos, IEEE 13th Global Conference of Consumer Electronics (GCCE2024), (2024)
- 28) ShoTakahashi, Kota Uenishi, Masahiro Yagi, Toru Hagiwara, Toshio Yoshii, “A Note on LSTM-based Prediction of Road Surface Condition Using Spatial Direction Series Data, IEEE 13th Global Conference of Consumer Electronics (GCCE2024), (2024)
- 29) 笹枝悠人, 八木雅大, 高橋翔, 萩原亨, “車載カメラ映像を用いたLate-fusionに基づく複数識別器の確信度統合による道路の狭窄状況の識別に関する検討,” 映像情報メディア学会技術報告 (スポーツ情報処理研究会), (2024)
- 30) 林 亮佑, 八木 雅大, 高橋 翔, 萩原 亨, “画像解析による走行ガイダンス機能付きセンチメートル級測位システムの構築,” 第70回土木計画学研究発表会・秋大会, (2024)
- 31) 八木雅大, 植西康太, 高橋翔, 萩原亨, “学習済みモデルの重みを用いた識別器の再学習に関する検討,” 第70回土木計画学研究発表会・秋大会, (2024)
- 32) 石附 将武, 高橋 翔, 萩原 亨, 吉井 稔雄, “深層学習による冬期路面状態推定におけるラベル訂正の一考察,” 第70回土木計画学研究発表会・秋大会, (2024)
- 33) 丹 悠紀, 福井 千菜美, 高橋 翔, 吉井 稔雄, 萩原 亨, “積雪寒冷地におけるドライバーの行動選択に有用な冬期道路環境の情報に関する一考察,” 第70回土木計画学研究発表会・秋大会, (2024)
- 34) 蛭名 将平, 有村 幹治, “高粒度人流データを用いた2022年札幌雪害時の移動需要推定,” 第70回土木計画学研究発表会・秋大会, (2024)
- 35) Tran Vinh Ha, Mikiharu Arimura, “The Application of ETC2.0 Probe Data and Network Clustering in Investigating Urban Mobility Patterns During an Extreme Snow Event”, 第22回ITSシンポジウム2024 (2024)
- 36) 前田周星, 福井 千菜美, 八木雅大, 高橋 翔, 吉井 稔雄, “冬期道路で観測されるデータと車両速度に基づく到着遅れ推定に関する一検討,” 映像情報メディア学会 2024年冬季大会, (2024)
- 37) Yasuhiro Nagata, Toru Hagiwara, Sho Takahashi, Masahiro Yagi, Genki Ooi, Yasuhiro Kaneda, “Developing Digital Twin for Disaster Management under Snowstorm in Winter, TRB Annual Meeting, (2025)

【依頼講演】

- 1) 高橋翔，“デジタルツインが導く未来社会の冬期道路交通－Edge-AIによる現実世界の定量化と可視化－”，日本気象協会シンポジウム，（2023）
- 2) 有村幹治，“ポストコロナと北海道のモビリティ”，令和6年度 第1回 北海道ITS推進フォーラム講演会，（2024）
- 3) 有村幹治，“自動運転を活用した『みらい』”，千歳市次世代モビリティを考えるシンポジウム，（2024）
- 4) 高橋翔，“GNSSを活用した冬期道路のデジタルツイン”，令和6年度 地理空間情報に関する情報共有会合，（2024）
- 5) 高橋翔，“農業土木に活用できるAI・ICTによる実空間モニタリングとデジタルツイン”，北海道農業建設協会 経営者研修会，（2024）

【学会でのセッション運営：研究成果の発信および専門家との議論】

R5年度は，第68回土木計画学研究発表会・秋大会（2023年11月24日～26日）にて，本研究プロジェクトに関するスペシャルセッションを立ち上げた。

セッション名「デジタルツイン・情報技術による道路交通マネジメント 高橋翔（北海道大学大学院）」（11月26日（日） 10:45～12:15）

セッション内で本プロジェクト関係者からの発表は以下のとおり。

- 1) OpenPoseを用いた道路映像における二輪車の識別に関する一考察，繁澤朗（北海道大学工学部）八木雅大・高橋翔・萩原亨
- 2) エッジAIの車両判別精度を考慮した高速道路の短期渋滞予測，金家侑希（室蘭工業大学大学院）瀧本康太・江戸元希・有村幹治
- 3) GNSSデータを用いた冬期道路環境における走行位置の観測，林亮佑（北海道大学大学院工学院）八木雅大・高橋翔・萩原亨・松本一城
- 4) 低ランク近似に基づく離散データの更新を導入したテンソル補完による視界レベル推定に関する一考察，福田英輝（北海道大学大学院）八木雅大・高橋翔・萩原亨
- 5) 携帯電話の位置情報集計データを用いた2022年札幌市大規模雪害時の交通行動変容，佐藤陽介（室蘭工業大学大学院）蛭名将平・佐々木悠貴・Tran Vinh Ha・有村幹治
- 6) 道路維持管理のDXとEBPMにむけた舗装点検・道路巡回のAI支援技術の構築と導入効果検証，日原弘貴（室蘭工業大学大学院）浅田拓海・亀山修一

R6年度は、第70回土木計画学研究発表会・秋大会（2024年11月15日～17日）にて、本研究プロジェクトに関するスペシャルセッションを立ち上げた。

セッション名「デジタルツイン・情報技術による道路交通マネジメント 高橋翔（北海道大学大学院）」（11月16日（土） 09:00～10:30, 10:45～12:15）

セッション内で本プロジェクト関係者からの発表は以下のとおり。

- 1) 深層学習による冬期路面状態推定におけるラベル訂正の一考察，石附将武（北海道大学 大学院工学院 北方圏環境政策工学専攻）・高橋翔・萩原亨・吉井稔雄
- 2) 画像解析による走行ガイダンス機能付きセンチメートル級測位システムの構築，林亮佑（北海道大学大学院工学院）・八木雅大・高橋翔・萩原亨
- 3) 学習済みモデルの重みを用いた識別器の再学習に関する検討，八木雅大（北海道大学 大学院工学研究院）・植西康太・高橋翔・萩原亨，高粒度人流データを用いた2022年札幌雪害時の移動需要推定，蛭名将平（室蘭工業大学大学院）・有村幹治
- 4) 高粒度人流データを用いた2022年札幌雪害時の移動需要推定，蛭名将平（室蘭工業大学大学院）・有村幹治

また、R6年度は、2024 IEEE 13th Global Conference on Consumer Electronics (GCCE 2024)（2024年10月29日～11月1日）にて、本研究プロジェクトに関するオーガナイズセッションを立ち上げた。

セッション名「Actual Data Science-based Digital-twin & Engineering for Enhancement of Human Abilities & Social Infrastructure 高橋翔（北海道大学大学院）」（10月30日（水） 10:00～12:00, 13:00～15:00）

セッション内で本プロジェクト関係者からの発表は以下のとおり。

- 1) A Note on LSTM-based Prediction of Road Surface Condition Using Spatial Direction Series Data, Sho Takahashi (Faculty of Engineering, Hokkaido University) ・ Kota Uenishi ・ Masahiro Yagi ・ Toru Hagiwara ・ Toshio Yoshii
- 2) A Note on Issues for Implementation of Visibility Level Recognition Using In-vehicle Camera Videos, Masahiro Yagi (Faculty of Engineering, Hokkaido University) ・ Yuto Sasaeda ・ Sho Takahashi ・ Toru Hagiwara ・ Toshio Yoshii



## ⑨研究成果の活用方策

本研究では、冬期道路交通マネジメントに貢献するデジタルツインに基づくシステムを構築し、道路行政に貢献したいと考えている。本研究で構築するデジタルツインは、道路・交通・気象の動的データをエッジコンピュータで加工の上、道路APIを通してサイバー空間に送り、シミュレーションを実行。道路交通の現在および将来の状況に関する情報を提供する。プラットフォームによる直接的な情報発信に加え、マスメディア、地域関係者、行政関係者の協力のもと情報発信を強化することで、道路利用者や道路管理者へ情報提供可能な仕組みを構築したいと考える。

このため、本研究プロジェクトでは、道路行政の現場への落とし込みを見据え、北海道開発局と連携し、道路維持管理に関連する工事に従事する方々や都市間バスを運行するバス会社などへのヒアリングなどを重ねている。また、マスメディアによる情報発信の実現に向けて、稚内および留萌のラジオ放送局と情報の読み取りと放送内容について議論を進めている。さらには、NHKのニュース放送にて、新たな防災対策として、本研究プロジェクトで構築するデジタルツインが取り上げられる予定であり、社会実装に向けて積極的に情報発信に取り組んでいる。

#### ⑩特記事項

今後、我が国における道路インフラと人やモノとのスマートな協調といった新たな付加価値の創造を顧みると、道路の走行環境や交通状況をリアルタイムにモニタリングし、人やモノが必要とする情報を提供するインタフェース（Infra to Humans and Things）の開発が必要であり、本研究はその先駆けとなる。

また、本研究プロジェクトは、冬期道路のデジタルツインをテーマにしていることから、12月の報告書類作成時に完了していない項目があるが、特に問題となる部分は無く、令和6年度以降に向けて順調に実施している。先読み（予測）やフィジカル空間へのフィードバックとしての情報提供の機能については、予定よりも進捗が見られる。

加えて、⑧に記載のとおり本件プロジェクトでの成果は大きく、査読付き論文の採択も含め、複数の学会発表にいたっている。また、依頼講演もあり、市民に研究成果を広く発信している。