



|                     |                                                                                                 |
|---------------------|-------------------------------------------------------------------------------------------------|
| Title               | 冬期路面モニタリングのための車載センサを用いた機械学習に関する研究                                                               |
| Author(s)           | 石附, 将武                                                                                          |
| Degree Grantor      | 北海道大学                                                                                           |
| Degree Name         | 博士(工学)                                                                                          |
| Dissertation Number | 甲第16849号                                                                                        |
| Issue Date          | 2026-03-25                                                                                      |
| DOI                 | <a href="https://doi.org/10.14943/doctoral.k16849">https://doi.org/10.14943/doctoral.k16849</a> |
| Doc URL             | <a href="https://hdl.handle.net/2115/99694">https://hdl.handle.net/2115/99694</a>               |
| Type                | doctoral thesis                                                                                 |
| File Information    | Masamu_Ishizuki.pdf, 全文                                                                         |



# 冬期路面モニタリングのための 車載センサを用いた機械学習に関する研究

A Study on Machine Learning based on In-vehicle Sensor  
for Winter Road Surface Monitoring

石附 将武

北海道大学大学院工学院

2026 年 2 月

冬期路面モニタリングのための  
車載センサを用いた機械学習に関する研究

目次

|       |                         |    |
|-------|-------------------------|----|
| 第 1 章 | 序論                      | 1  |
| 1.1   | 研究の背景                   | 1  |
| 1.1.1 | 日本における積雪寒冷地域の現状         | 1  |
| 1.1.2 | 冬期の積雪寒冷地域の交通の課題         | 3  |
| 1.1.3 | 冬期路面モニタリングの必要性と応用       | 3  |
| 1.2   | 冬期路面モニタリングのための方法論       | 4  |
| 1.2.1 | 路面状態の分類                 | 4  |
| 1.2.2 | 路面状態判別の方策               | 7  |
| 1.2.3 | 路面状態判別の応用先              | 7  |
| 1.3   | 車載センサによる路面状態判別          | 8  |
| 1.3.1 | 固定センサと車載センサ             | 8  |
| 1.3.2 | 路面状態判別のための車載センサ         | 8  |
| 1.3.3 | 車載 RGB カメラ              | 9  |
| 1.4   | 本論文の目的                  | 10 |
| 1.5   | 本論文の内容と構成               | 10 |
| 第 2 章 | 関連研究                    | 14 |
| 2.1   | 冬期路面モニタリング研究の現状         | 14 |
| 2.2   | 路面モニタリングの方式（固定センサ）      | 16 |
| 2.3   | 路面モニタリングの方式（車載センサ）      | 18 |
| 2.3.1 | 車載センサによる路面モニタリングの概要     | 18 |
| 2.3.2 | 路面非接触系センサ               | 19 |
| 2.3.3 | 路面接触系センサ                | 21 |
| 2.4   | 路面状態判別のための機械学習関連手法      | 23 |
| 2.4.1 | 特徴量ベースの機械学習による路面状態判別    | 23 |
| 2.4.2 | 深層学習による路面状態判別           | 25 |
| 2.4.3 | マルチモーダル学習による判別ロバスト性の向上  | 26 |
| 2.4.4 | ドメイン適応による環境適応性の向上       | 27 |
| 2.4.5 | オンデバイス推論のためのモデル軽量化      | 29 |
| 2.5   | 本論文で解決すべき課題とその解決方法      | 31 |
| 2.6   | まとめ                     | 32 |
| 第 3 章 | 複数の車載センサデータを統合した路面状態判別機 | 34 |

|       |                                                |    |
|-------|------------------------------------------------|----|
| 3.1   | はじめに                                           | 34 |
| 3.2   | Late Fusion によるマルチモーダル判別手法                     | 35 |
| 3.2.1 | 手法全体のフレームワーク                                   | 35 |
| 3.2.2 | 判別器 1: 画像による路面状態の判別器                           | 38 |
| 3.2.3 | 判別器 2: 路面接触系センサによる路面状態の判別器                     | 40 |
| 3.2.4 | 判別器 3: 路面状態の Late Fusion 判別器                   | 40 |
| 3.3   | 実験                                             | 42 |
| 3.3.1 | 実験データの取得方法                                     | 42 |
| 3.3.2 | データの前処理                                        | 45 |
| 3.3.3 | 評価方法                                           | 45 |
| 3.4   | 実験結果                                           | 46 |
| 3.4.1 | Late Fusion 判別器に適用するアルゴリズムの評価                  | 46 |
| 3.4.2 | Late Fusion 前の判別器と Late Fusion 判別器の比較          | 46 |
| 3.4.3 | 判別器 1・2 の得意データ比率が Late Fusion に与える影響に関する<br>考察 | 51 |
| 3.5   | まとめ                                            | 53 |
| 第 4 章 | 学習と異なる環境での精度低下を抑制するためのラベル訂正                    | 54 |
| 4.1   | はじめに                                           | 54 |
| 4.2   | 学習環境差による精度低下の検証                                | 55 |
| 4.3   | 冬期路面状態の判別結果の訂正手法                               | 57 |
| 4.3.1 | 手法全体の概要                                        | 57 |
| 4.3.2 | 処理 1: 判別結果 $L$ を訂正すべきか                         | 59 |
| 4.3.3 | 処理 2: どの路面状態に訂正するか                             | 68 |
| 4.4   | 実験の設定                                          | 69 |
| 4.5   | 実験結果                                           | 71 |
| 4.5.1 | 提案手法の精度                                        | 71 |
| 4.5.2 | k 近傍法の効果の検証                                    | 80 |
| 4.6   | まとめ                                            | 80 |
| 第 5 章 | 冬期路面の状態判別に特化した深層学習判別器の探索                       | 81 |
| 5.1   | はじめに                                           | 81 |
| 5.2   | 路面状態判別に特化した深層学習判別器の探索方法                        | 82 |
| 5.2.1 | ベースラインとなる判別器                                   | 82 |
| 5.2.2 | 構造的枝刈り                                         | 85 |
| 5.2.3 | 最適な構造の探索方法                                     | 85 |
| 5.3   | 実験の設定                                          | 85 |
| 5.3.1 | データセットの構築                                      | 86 |
| 5.3.2 | 入力データの前処理方法                                    | 86 |

|         |                    |     |
|---------|--------------------|-----|
| 5.3.3   | 学習方法と使用ハードウェア      | 86  |
| 5.3.4   | 評価指標               | 88  |
| 5.4     | 実験結果               | 88  |
| 5.4.1   | 各構造の評価結果           | 89  |
| 5.4.2   | パレート効率な構造の抽出       | 90  |
| 5.4.3   | 判別器の複雑性と過学習についての検証 | 98  |
| 5.5     | まとめ                | 100 |
| 第 6 章   | 結論                 | 101 |
| 6.1     | 本研究の総括             | 101 |
| 6.2     | 本研究の今後の課題          | 102 |
| 謝辞      |                    | 104 |
| 参考文献    |                    | 105 |
| 著者の研究業績 |                    | 118 |

## 図目次

|      |                                                         |    |
|------|---------------------------------------------------------|----|
| 図 1  | 積雪寒冷特別地域略図                                              | 2  |
| 図 2  | 各路面状態の外観例                                               | 6  |
| 図 3  | 本論文の構成                                                  | 11 |
| 図 4  | Late Fusion の冬期路面状態判別器のフレームワーク                          | 37 |
| 図 5  | 画像の切り出し方                                                | 39 |
| 図 6  | 実験車両の外観と車内の計測システム                                       | 43 |
| 図 7  | データセットの例                                                | 44 |
| 図 8  | データの分割方法                                                | 45 |
| 図 9  | Late Fusion 前の判別器の路面状態判別正誤の数                            | 48 |
| 図 10 | 各判別器の混同行列                                               | 50 |
| 図 11 | $X$ と $Y$ の割合変化が推定精度に与える影響                              | 52 |
| 図 12 | 提案手法のフレームワーク                                            | 58 |
| 図 13 | 確信度 $c$ が 0.4 以上 0.5 未満で乾燥と判別された路面の例                    | 60 |
| 図 14 | 確信度 $c$ が 0.9 以上で乾燥と判別された路面の例                           | 61 |
| 図 15 | 高速道路用判別器で一般国道のデータを乾燥路面と判別した際の Precision<br>と確信度 $c$ の関係 | 62 |
| 図 16 | 一般国道の路面を高速道路用判別器で判別した際の間特徴量を二次元に次元削減した散布図               | 64 |
| 図 17 | 図 16 の乾燥路面と判別されたデータのみ、確信度 $c$ に応じてグレースケールで表現しなおした図      | 64 |
| 図 18 | 図 16 の半湿路面と判別されたデータのみ、確信度 $c$ に応じてグレースケールで表現しなおした図      | 65 |
| 図 19 | 図 16 の湿潤路面と判別されたデータのみ、確信度 $c$ に応じてグレースケールで表現しなおした図      | 65 |
| 図 20 | 図 16 のシャーベット路面と判別されたデータのみ、確信度 $c$ に応じてグレースケールで表現しなおした図  | 66 |
| 図 21 | 図 16 の凍結路面と判別されたデータのみ、確信度 $c$ に応じてグレースケールで表現しなおした図      | 66 |
| 図 22 | 図 16 の積雪路面と判別されたデータのみ、確信度 $c$ に応じてグレースケールで表現しなおした図      | 67 |
| 図 23 | 実験走行ルート                                                 | 70 |
| 図 24 | 誤判別されていた路面状態が正しく訂正された例 1                                | 74 |
| 図 25 | 誤判別されていた路面状態が正しく訂正された例 2                                | 75 |
| 図 26 | 誤判別されていた路面状態が正しく訂正された例 3                                | 76 |
| 図 27 | 誤判別されていた路面状態が正しく訂正された例 4                                | 77 |

|      |                                               |    |
|------|-----------------------------------------------|----|
| 図 28 | 誤判別されていた路面状態が正しく訂正された例 5                      | 78 |
| 図 29 | 誤判別されていた路面状態が正しく訂正された例 6                      | 79 |
| 図 30 | Raspberry Pi 4 Model B の外観                    | 88 |
| 図 31 | 各構造の判別時間と精度の関係                                | 89 |
| 図 32 | 使用ブロック数ごとのパレート最適な判別器                          | 91 |
| 図 33 | MobileNetV3 では誤判別だが軽量判別器で正しく乾燥と判別された例         | 92 |
| 図 34 | MobileNetV3 では誤判別だが軽量判別器で正しく半湿と判別された例         | 93 |
| 図 35 | MobileNetV3 では誤判別だが軽量判別器で正しく湿潤と判別された例         | 94 |
| 図 36 | MobileNetV3 では誤判別だが軽量判別器で正しくシャーベットと判別され<br>た例 | 95 |
| 図 37 | MobileNetV3 では誤判別だが軽量判別器で正しく凍結と判別された例         | 96 |
| 図 38 | MobileNetV3 では誤判別だが軽量判別器で正しく積雪と判別された例         | 97 |
| 図 39 | 使用ブロック数と学習損失の関係                               | 99 |
| 図 40 | ブロック数ごとの F-measure の平均と学習損失の平均の関係             | 99 |

## 表目次

|      |                                           |    |
|------|-------------------------------------------|----|
| 表 1  | 各路面状態の判定基準                                | 7  |
| 表 2  | 各モデルの判別精度                                 | 47 |
| 表 3  | Late Fusion 前後での路面状態判別精度                  | 47 |
| 表 4  | Late Fusion 前後での各路面状態判別正誤の数               | 49 |
| 表 5  | 判別器 1・2 の得意データ ( $X, Y$ ) の割合             | 51 |
| 表 6  | 高速道路用の判別器による路面状態判別精度：一般国道画像と高速道路画像<br>の比較 | 56 |
| 表 7  | 提案手法と比較手法の精度                              | 72 |
| 表 8  | 乾燥以外の路面状態を乾燥路面と間違えた数                      | 72 |
| 表 9  | 各手法の危険側路面訂正の禁止をしない場合の精度比較                 | 80 |
| 表 10 | MobileNetV3-Small のネットワーク構造               | 84 |
| 表 11 | データセットの詳細                                 | 87 |
| 表 12 | 学習時のハイパーパラメータ                             | 87 |
| 表 13 | 評価用のハードウェア                                | 87 |
| 表 14 | MobileNetV3 とパレート効率的な構造の判別器の性能比較          | 91 |

# 第 1 章 序論

本章では、冬期道路交通における社会的課題と冬期路面モニタリングの必要性を概観し、本研究の位置づけと目的を明らかにする。まず、日本の積雪寒冷地域における道路交通の現状と課題を整理し、冬期における路面状態の悪化が、個々の交通事故リスクにとどまらず、地域経済や日常生活の持続性にまで影響を及ぼすことを示す。そのうえで、こうした課題に対処する基盤となる方法論として、路面状態をリアルタイムかつ高精度に把握する冬期路面モニタリングの役割と、その情報が道路管理や走行支援、車両制御にどのように活用され得るかを概説する。

続いて、路面状態判別手法に関する既存の取り組みを概観し、固定センサと車載センサの特徴や現状を整理した上で、本研究が焦点を当てる車載センサ、とりわけ車載 RGB カメラの利点と課題を位置づける。これにより、本研究が取り組むべき論点として、深層学習を用いた路面状態推定におけるロバスト性（頑健性）、汎用性（ドメイン適応）、実用性（軽量・高速判別）の 3 つの課題を明確化し、本論文が目指す貢献の方向性を提示する。最後に、本論文全体の構成を示し、以降の各章で展開される議論の流れを記す。

## 1.1 研究の背景

本節では、冬期道路交通における課題の所在を社会的・工学的観点から整理し、本研究が対象とする冬期路面モニタリングの必要性を明確化する。具体的には、1.1.1 節で積雪寒冷地域の分布とその道路交通が担う役割を概観し、冬期の降雪・低温条件が交通の安全性と信頼性に及ぼす影響を示す。続く 1.1.2 節では、冬期に特徴的な交通事故の形態を整理し、路面状態が走行安全に直結することを示した上で、冬期路面モニタリングの必要性を記す。最後に 1.1.3 節で、その必要性を道路管理の高度化および走行安全支援・車両制御の観点から具体化し、応用可能性を述べる。

### 1.1.1 日本における積雪寒冷地域の現状

日本は国土の約 60%が積雪寒冷地域に分類されており、その地域には日本の約 4 分の 1 にあたる人口が暮らしている [1]。このような広大な地域において、冬期の道路交通の安全確保は重要なインフラ維持課題である。

図 1 に示すとおり、日本における積雪寒冷地域は、北海道、東北、北陸、山陰の日本海側、さらには内陸の山間部にまで広く分布し、生活道路から高速道路・幹線道路まで多様な道路網が降雪と低温の影響を受ける。これらの地域の移動・物流は道路交通への依存度が高く、降雪期の通行止めや速度規制は、医療・福祉、通勤・通学、観光・産業活動に直接的な影響を及ぼす。特に豪雪時には、地域間の物資供給の遅延・停滞が発生しやすく、地




図 1: 積雪寒冷特別地域略図

出典：国土交通省ウェブサイト [1]

域経済の継続性の観点からも、安全で信頼性の高い道路交通の確保が不可欠である。

一方で、広域にわたる冬期道路の維持管理は、多大な人員・機材・予算の投入を要する。除雪出動や凍結防止剤・融雪剤の散布は道路の維持に不可欠であるが、コスト管理の観点からも効率化が強く求められている [2, 3]。また、凍結防止剤に広く用いられる塩化ナトリウムなどは、コンクリート構造物や鋼橋に対する腐食・劣化を引き起こす副作用を持ち、長期的なインフラの健全性に影響を与える [4, 5]。このため、気象・交通・路面の状況に応じた適切な運用と、過不足のない維持管理の意思決定が課題となっている。

法制度面では、「積雪寒冷特別地域における道路交通の確保に関する特別措置法」に基づき、厳しい気象条件下でも道路交通の機能を維持するための体制整備が図られている [6]。

交通運用の観点からも、積雪寒冷地域の冬期道路は、ドライバーの行動や交通流に大きな制約を与えている。降雪や視界不良、路面の悪化に伴い、多くのドライバーが出発時間の変更やルートの迂回、運転自体の中止といった選択を迫られ、通勤・通学や物流の遅延・キャンセルが発生しやすい。また、渋滞や車線規制、通行止めなどにより、平常時と比較して所要時間のばらつきが増大し、公共交通機関を含む広域交通網全体の信頼性が低下する。さらに、1.1.2 節で示すとおり、冬期の交通事故は路面凍結などの影響を強く受けており、単なる個別の事故リスクにとどまらず、二次的な渋滞や通行止めによって地域全体の交通の効率性を損なう要因となっている [7]。

このような社会的・制度的背景と交通実態を踏まえると、積雪寒冷地域における冬期道路交通の安全確保は、単なる気象現象への対応に留まらず、広域・長期にわたる社会基盤の安定性を確保する営みであるといえる。次小節では、冬期の積雪寒冷地域に特有の交通の課題を整理し、安全確保に向けて対処すべき論点を示す。

### 1.1.2 冬期の積雪寒冷地域の交通の課題

1.1.1 節で示したとおり、積雪寒冷地域において冬期における安全かつ円滑な道路交通の確保は、人々の生活や経済活動を支える上で極めて重要な社会課題である。「積雪寒冷特別地域における道路交通の確保に関する特別措置法」にも規定されているとおり、これらの地域では降雪、吹雪、路面凍結といった特有の厳しい気象条件に対処し、交通の機能を維持するための適切な措置が求められている [6]。

中でも、路面状態の悪化は交通安全にとって重大な危険要因となる。冬期道路では、雨水や融雪水の凍結、霜凍結、圧雪表面の融解・再凍結などにより、極めて滑りやすい路面が形成され、車両のスリップを誘発する [8]。実際に、路面のスリップは冬期交通事故の主要因であり、北海道の一般道における調査では、冬型事故の原因の 83.9%がスリップ事故であったと報告されている [7]。この数値は、視界不良（12.6%）やわだち（0.9%）といった他の要因を大きく上回っており、スリップ対策の重要性を示している。

特に危険性が高いのは、橋梁の上やトンネルの出入り口などで局所的に発生する路面凍結である。これらは「ブラックアイスバーン」とも呼ばれ、一見すると湿潤路面と見分けが付きにくいいため、ドライバーが危険を認識できずに高速で進入し、重大なスリップ事故を引き起こすリスクが高い [9]。

このような冬期特有の危険を回避し、安全で信頼性の高い道路交通網を維持するためには、路面が「今、どのような状態にあるか」をリアルタイムかつ正確に把握するための方法、すなわち冬期路面モニタリングが不可欠である [10,11]。

### 1.1.3 冬期路面モニタリングの必要性と応用

冬期路面モニタリングによって得られる正確な路面状態の情報は、「道路管理の高度化」と「走行安全支援の実現」という 2 つの主要な観点から、交通の安全性と効率性の包括的な向上に寄与する。

一つ目の観点である道路管理の高度化について、道路管理者は冬期の道路機能を維持するため、路面状態に応じて除雪作業や凍結防止剤・融雪剤の散布といった管理業務を行う [3,12]。しかし、これらの措置は多大な機材・人員コストを要する [2,13]。加えて、凍結防止剤として広く使用される塩化ナトリウムは、コンクリート構造物や鋼橋に対して塩害を引き起こし、道路インフラの老朽化を早めるという深刻な副作用を持つ [4,5]。したがって、路面状態を広域かつ高精度にモニタリングし、「いつ、どこに、どの程度の」措置が必要かを正確に判断することができれば、不要な薬剤散布や除雪作業を削減できる。これは、管理コストの最適化と、塩害抑制によるインフラの長寿命化に直結する。この分

野では、NEXCO 東日本北海道支社が開発・運用する「スマート凍結防止剤散布システム (ISCOS™)」のように、加速度センサをタイヤの内側に貼ったスマートタイヤ (CAIS™) [14] などを用いて路面状態を自動判別し、凍結防止剤の散布を最適化する試みが既に実用化されている [15,16].

二つ目の観点の走行安全支援の実現では、リアルタイムの路面情報は車両のドライバーや制御システムにとって、事故を未然に防ぐための重要な入力情報の一つとなる [17]. 例えば、路面情報を活用することで、ドライバーに対し「この先凍結の可能性あり」といったリアルタイムな警告を発したり、カーナビゲーションシステムや地図アプリケーションが凍結箇所を避けたより安全な走行ルートを事前に提示したりすることが期待できる [18]. さらに、近年発展している ADAS (先進運転支援システム) [19] や自動運転技術に路面状態を活用して安全性を向上することも可能である. また、路面状態を入力として従来の Anti-lock Braking System (ABS) やトラクションコントロール [20] といった車両制御の安全性を向上させる [21, 22] だけでなく、より高度な予防安全制御が実現できる. 具体的には、Adaptive Cruise Control (ACC) [23] が滑りやすい路面を検知して自動的に車間距離を長く調整すること [24] や、衝突被害軽減ブレーキや ESC [25] が路面状態に応じて作動閾値を最適化し、危険な状況に早期から備えるといった制御が想定される [26,27].

このように、冬期路面モニタリングは、道路インフラの維持管理と車両の安全制御の両面において、その基盤的な方法論として高い必要性を有している.

## 1.2 冬期路面モニタリングのための方法論

本節では、冬期路面モニタリングを実現するための基本的な枠組みを整理する. まず 1.2.1 節で監視対象とする路面状態の分類を示し、次に 1.2.2 節で路面状態判別の方策としてセンシング方法と判別アプローチを概観する. 最後に 1.2.3 節で、道路管理、運転支援、車両制御への活用可能性を整理する.

### 1.2.1 路面状態の分類

路面モニタリングにおいて、どのような状態を判別するかが重要である. 冬期路面をいくつかの離散的な状態に区分して取り扱う手法は、多くの研究に共通する基本的な枠組みであるが、その分類数や区分の基準は研究ごとに異なる. 本来、路面状態の分類は、想定する管理目的や利用場面に応じて設計されるべきである. 一方で、本研究は冬期路面モニタリングを基盤として、道路管理、運転支援、車両制御など多様な目的に対応し得る手法の構築を目指しているため、冬期の道路管理や車両制御において一般的に用いられ、先行研究 [15] においても広く採用されている汎用的な分類枠組みを採用する. 具体的には、同研究に基づき 6 種類の路面状態を対象とする.

対象とする路面は、乾燥、半湿、湿潤、シャーベット、凍結、積雪の 6 種類である. これらの分類は、路面の滑りやすさ [12] や、道路管理者が行うべき措置 (薬剤散布の可否など)

と密接に関連 [15] しており，実用的な分類体系である．各路面状態の定義を表 1 に，その代表的な外観を図 2 に示す．



(a) 乾燥



(b) 半湿



(c) 湿潤



(d) シヤーベット



(e) 凍結



(f) 積雪

図 2: 各路面状態の外観例

表 1: 各路面状態の判定基準

| 路面状態   | 判定基準                           |
|--------|--------------------------------|
| 乾燥     | 路面に雪や氷がなく，濡れも見られない状態           |
| 半湿     | 路面の一部に濡れがあり，タイヤの水はねが見られる程度の状態  |
| 湿潤     | 路面全体に水膜が広がっている状態               |
| シャーベット | タイヤ跡が残る程度に雪が多量の水分を含んでいる状態      |
| 凍結     | 路面上に雪氷があり，表面が黒光りしているような凍結状態    |
| 積雪     | 路面に雪が積もっているが，含まれる水分はそれほど多くない状態 |

### 1.2.2 路面状態判別の方策

路面状態を「今，どのような状態にあるか」として継続的に把握するためには，観測された情報に基づいて路面状態を判別する方策を設計する必要がある．路面状態の把握手段は大きく，人によるモニタリングとセンサによるモニタリングに分類できる．人によるモニタリングは，道路パトロールや目視観測などにより状況に応じた柔軟な判断が可能である一方，人的リソースの制約や判断のばらつきといった課題を持つ [28]．センサによるモニタリングは，客観的な計測に基づいて自動化・高頻度化を図れるが，設置や運用に要するコストと，取得できる情報の空間的・時間的な範囲が方式に依存する．

センサによるモニタリングは，センサの設置場所により道路に固定する固定センサと，車両に搭載する車載センサに大別される．固定センサは橋梁部やトンネル出入口など特定地点の継続監視に有効である一方，観測地点が限られるため，広大な道路網全体をカバーするには多大な設置・維持管理コストを要する．これに対して，広域な道路網に対応していくには，走行車両を移動型のセンサプラットフォームとして活用し，走行に伴って広範囲の情報を収集可能な車載センサが重要となる．そのため，本研究では車載センサを中心に扱う．

このようなセンサによる判別のため，これまで多岐にわたるセンシング手法が研究されてきた．センサの種類としては，路面からの反射光の偏光変化を利用するステレオカメラ [29]，レーザー光の反射時間や強度を計測するレーザーレーダ (LiDAR) [30, 31]，路面温度から状態を推定するマイクロ波放射計 [32, 33] や赤外線カメラ・温度計 [17, 34]，タイヤ内に設置した加速度センサで振動レベルを解析する手法 [35–37] などが提案されてきた．

近年，これらの多様なアプローチの中でも，特に著しい進展を見せているのが，機械学習，とりわけ深層学習 (Deep Learning) [38] を用いた判別手法である．膨大なデータから複雑な非線形関係を自動で学習する能力を持つ深層学習モデル，特に画像認識の分野で飛躍的な進歩を遂げた畳み込みニューラルネットワーク (Convolutional Neural Network: CNN) [39–43] は，車載カメラの画像などから路面状態を判別するタスクにおいて，従来の物理モデルや特徴量ベースの機械学習手法 [44] よりも高い判別性能を示しており，本分野の主流の手法となりつつある．

### 1.2.3 路面状態判別の応用先

1.1.3 節で述べたとおり，路面状態判別手法は，冬期交通の安全性と効率性を向上させる多様な応用先を持つ．その実用化は，大きく分けて「道路管理」「運転支援」「車両制御」の3つの領域で期待されている．道路管理の領域では，除雪出動の的確な判断支援や，凍結防止剤の散布ルートおよび散布量を最適化するシステムへの活用が進められている [15]．運転支援の領域では，ドライバーへのリアルタイムな危険警告や，カーナビゲーションシステムなどによる安全なルート提示といった形での貢献が考えられる．さらに車両制御の領域では，Anti-lock Braking System (ABS) [45]，Traction Control System (TCS) [20]，Electronic Stability Control (ESC) [25] といった既存の安全装置の制御パラメータを路面状態に応じて最適化するほか，Adaptive Cruise Control (ACC) [23] や衝突被害軽減ブレーキ [46] をはじめとする先進運転支援システム (ADAS: Advanced Driver Assistance Systems) [19] や自動運転システムにおける高度な予防的安全制御への応用が見込まれている．

## 1.3 車載センサによる路面状態判別

本節では，冬期路面モニタリングで用いられるセンサの中で，本論文で中心的に扱う車載センサの位置づけを整理する．まず 1.3.1 節で固定センサと車載センサの特徴を比較し，次に 1.3.2 節で車載センサの代表的手法を概観する．最後に 1.3.3 節で，本研究が中核として扱う車載 RGB カメラの利点と課題を述べる．

### 1.3.1 固定センサと車載センサ

路面状態を判別するためのセンサ設置場所は，道路脇に固定する「固定センサ」と，車両に搭載する「車載センサ」に大別される．

固定センサは，CCTV カメラや専用の路面内蔵センサ，気象観測装置 (RWIS: Road Weather Information System) [47] などを道路に設置し，定点観測を行う．既存のインフラを活用できる場合は導入コストを抑えられる利点がある一方，観測できるのは設置地点近傍に限られ，広大な道路網全体をカバーするには莫大な設置・維持管理コストを要するという根本的な制約がある．対照的に，車載センサは，車両にセンサを搭載し，走行しながら路面状態を把握する．車両が走行するあらゆる場所の情報を収集できる利点があるが，センサの搭載コストや，車両が走行しない場所の情報は得られないという限界もある．

この車載センサの限界を克服し，道路網全体の安全性を高めるためには，個々の車両が収集した情報を集約し，他車と共有する協調型のフレームワーク [48–50] が不可欠である．このようなシステムを広く普及させるには，センサ自体が安価であり，多くの車両に容易に搭載可能であることが極めて重要な要件となる．

### 1.3.2 路面状態判別のための車載センサ

車載センサを用いた路面判別には、多様なアプローチが研究されてきたが、大きく路面接触系センサと路面非接触系センサに大別される。路面接触系センサは、タイヤと路面の物理的な相互作用を直接捉えるため、有効な手段の一つである。代表的なものに、タイヤ内に加速度センサを設置して振動を解析する手法 [35–37] や、歪センサでタイヤの変形を分析する手法がある [51]。タイヤ内に加速度センサを設置した手法は高速道路など特定の条件下では実用化されている [15]。しかし、一般道のような低速走行や停止・発進が頻発する環境では、加速度センサの信号レベルが低下し S/N 比（信号対雑音比）が悪化するため、判別が困難になるという課題 [52] や、センサの導入コストの面で普及が進まない側面がある。

路面非接触系センサとしては、ミリ波レーダー [29, 30] やレーザーレーダ [31]、赤外線カメラ [17, 34] などが研究されている。これらは路面の微細な特性を捉える能力を持つが、多くの場合コストが高く、降雪などの悪天候時に性能が低下する脆弱性も指摘されている [17, 52]。

### 1.3.3 車載 RGB カメラ

前節で示した車載センサの中で、本研究では特に車載の RGB カメラに着目する。車載カメラは、ドライブレコーダーやスマートフォンの一部として既に多くの車両に搭載されており、低コストで最も広く普及しているセンサである。この普及性の高さは、1.3.1 節で述べた協調型情報共有システムを構築する上で最も現実的な選択肢であることを意味する。

また、カメラは色調、光の反射、表面のテクスチャといった豊富な視覚情報を取得できる。さらに、他の多くのセンサと異なり、車両の前方の路面状態を認識できるため、危険を予測し、ADAS などが事前に対処（予測的安全制御）することを可能にするという大きな利点を持つ。

近年では、深層学習の発展により、カメラ画像を用いた画像認識技術の性能が飛躍的に向上している。特に、畳み込みニューラルネットワーク（Convolutional Neural Network: CNN） [53] を中心とする深層学習モデルは、大規模な画像データセットから路面の色調やテクスチャ、反射パターンといった微細な違いを自動的に学習し、従来の手設計特徴量に基づく画像処理手法と比較して、はるかに高い判別性能とロバスト性を実現している [39–43]。これにより、昼夜や天候条件が変化する実道路環境においても、車載カメラ画像から冬期路面状態を高精度に推定することが現実的な選択肢となりつつある。また、カメラは従来人間が視覚的に路面状態を判別してきたのと同様の情報を取得できるため、深層学習モデルが人間の視覚認識能力を模倣し、路面状態を効果的に判別できるという点で有力である。

また、車載カメラは、車線認識や前方車両認識、標識認識といった他のカメラベース ADAS 機能と共通のハードウェア基盤（フロントカメラやドライブレコーダー一体型カメラ）を用いることができるため、新たな専用センサを追加することなく、ソフトウェアの更

新やモデルの切り替えのみで路面状態判別機能を付加できるという実装上の利点も有する。

## 1.4 本論文の目的

本研究は、1.1 節および 1.2 節で述べた冬期路面モニタリングの必要性に応えることを目指すものである。特に 1.3 節で論じたように、将来的な広域モニタリング網の構築と ADAS などへの応用を見据えた場合、安価で普及性に優れる車載センサの活用が最も現実的かつ強力なアプローチである。中でも、従来人間が視覚的に路面状態を判別していたものを直接的に代替できることが期待され、またドライブレコーダーなどとして既に広く普及し、前方予測も可能である車載カメラは、その中核をなすセンサとして極めて有望である。

しかし、1.3.3 節で指摘した通り、車載カメラを主要センサとして用いる路面判別手法を実用化し、道路管理や走行支援といった実システムに実装するには、解決すべき複数の課題が存在する。第一に、カメラの光学的な弱点（遮蔽、ハレーション）や、特定路面（湿潤と凍結など）の誤認識といった「ロバスト性（頑健性）」の課題 [17] である。第二に、学習データと異なる環境（例：高速道路で学習し、一般道で使用）では精度が低下するという深層学習特有の「汎用性（ドメイン適応）」の課題 [54, 55] である。第三に、ADAS や車載器への実装に不可欠な、リアルタイム性を担保するための「実用性（軽量・高速なオンデバイス処理）」の課題 [11, 56] である。

本研究の目的は、これら 3 つの実用化に向けた核心的課題を克服し、車載センサ、特にカメラを中核とした冬期路面状態判別の方法論的基盤を確立することにある。具体的には、高精度な判別を実現する「ロバスト性」、多様な環境で機能する「汎用性」、そして車載器で稼働する「実用性」を同時に追求する手法を開発・提案し、その有効性を実証することを目指す。

## 1.5 本論文の内容と構成

本節では、本研究が取り組む 3 つの課題と各章との対応関係を整理し、本論文全体の構成を示す。まず、本論文の全体構成を図 3 に示す。

## 冬期路面モニタリングにおける課題

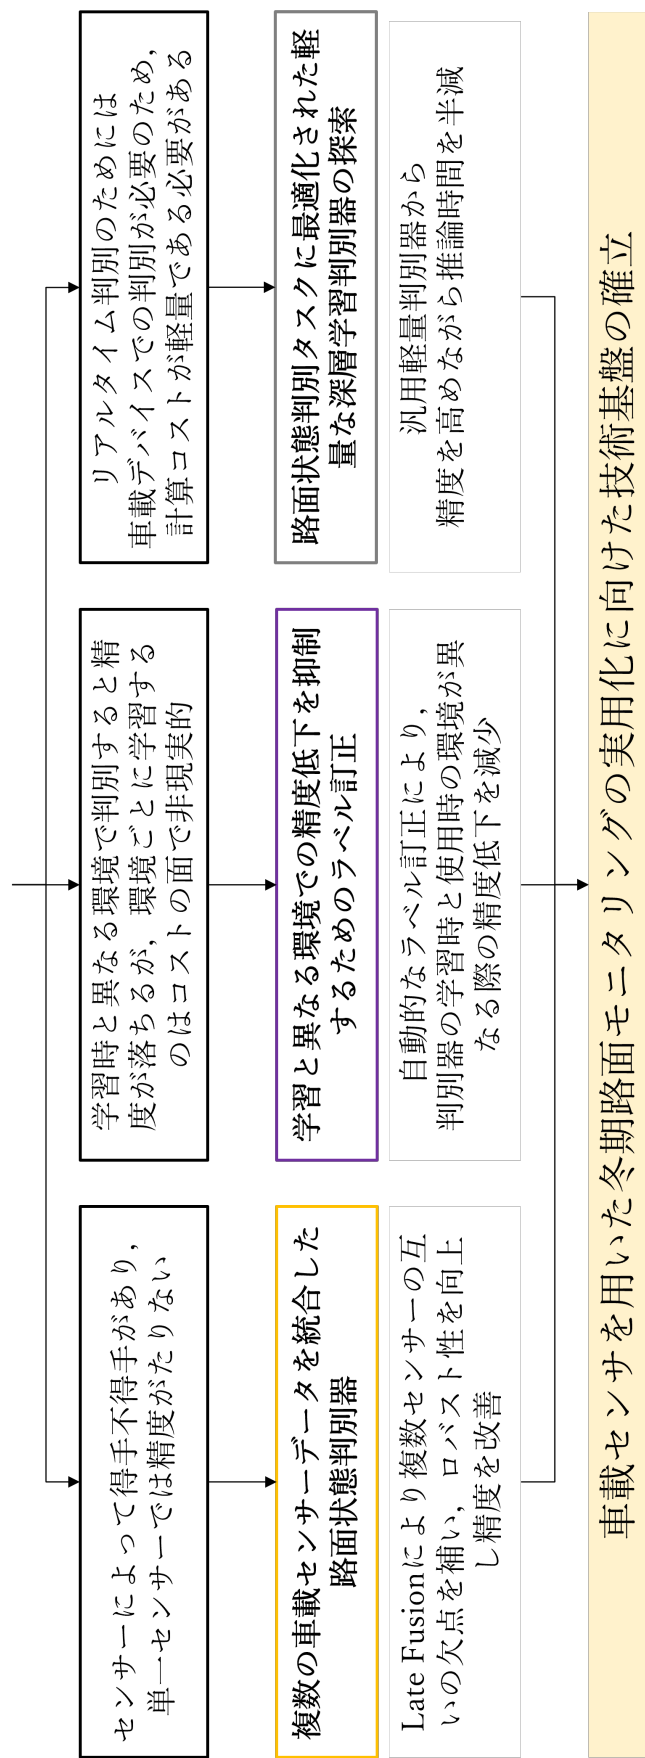


図 3: 本論文の構成

この構成に基づき、本論文は、車載センサを用いた冬期路面状態モニタリング基盤の高度化と実用化に向けた 3 つの課題に対する提案手法をまとめたものであり、以下の章で構成される。

本章である第 1 章では、序論として、研究の背景である冬期交通の課題と路面モニタリングの重要性を述べた。次いで、路面判別技術に関する既存研究の動向、特に車載センサの利点と課題を整理した。そのうえで、本論文が取り組む 3 つの主要な目的 (1) マルチセンサフュージョンによる高精度化、(2) 低コストなドメイン適応手法の開発、(3) 軽量高速モデルの探索を提示し、本論文の全体構成を概説した。

第 2 章では、関連研究として、本研究と密接に関連する分野の既存の知見と技術動向を整理する。冬期路面モニタリングの必要性や協調システム、土木分野における DX の取り組みといった広範な背景から、CCTV、タイヤ内センサ、赤外線カメラ、LiDAR、カメラ画像といった路面状態判別のための具体的なセンシング技術の比較、さらに本研究の核心技術である深層学習モデル、マルチモーダルモデル、ドメインシフト問題、モデル軽量化などの機械学習に関する先行研究を概観し、本研究の位置づけを明らかにする。

第 3 章では、第一の課題であるマルチセンサフュージョンに取り組む。路面非接触系センサである車載カメラと路面接触系センサであるタイヤセンサはそれぞれ異なる環境で弱点を持つ。具体的には、カメラは降雪による視界遮蔽や対向車ヘッドライトなど、光学的な影響を受けやすい。一方、接触系センサは走行ダイナミクス要因により、段差通過時の衝撃ノイズや低速走行時の信号レベル低下に伴う S/N 比の悪化が生じ、判別性能が低下しやすい。これらの弱点を相互補完するため、各センサ情報に対応する個別の判別器と、それらを統合する Late Fusion [57] 判別器を設ける。具体的には、判別器 1 として MobileNet [58]、判別器 2 として LightGBM [59] を用い、それらの出力である路面状態の確率値を、第 3 の判別器として Random Forest [60] で統合する Late Fusion 判別器を提案する。実車から収集したデータを用いた実験により、本手法が単一センサの F-measure をすべての路面クラスで上回り、ロバストな路面判別を実現できることを実証する。

第 4 章では、第二の課題であるドメイン適応に取り組む。深層学習モデルのドメインシフト問題、特に高速道路のデータで学習した路面推定モデルを、一般道などの学習環境外の路面へ適用する際の精度低下の課題を論じる。この課題に対し、新たなラベルのアノテーションや再学習といった高コストなプロセスを回避する手法として、学習済みモデルの出力確信度と k 近傍法 (k-NN) アルゴリズム [61] を組み合わせたラベル訂正手法を提案する。具体的には、学習環境外の路面の判別時にモデルの出力確信度が閾値を下回った場合、そのデータの特徴ベクトル (隠れ層から抽出) を用い、ラベルなしの学習環境外の参照データ群から特徴空間上での近傍データを探索する。そして、近傍データ群において、モデル判別によるラベルが最多のものを、訂正後のラベルとして採用する。実験を通じて、本手法が一般道における精度低下を抑制し、特にシャーベット、凍結、積雪路面を乾燥路面と誤るといった、交通安全上問題となる危険な誤判別の件数を約半数に削減できる有効性を示す。

第 5 章では、第三の課題（軽量高速モデル）に取り組む。車載カメラ画像を用いた路面推定におけるリアルタイム性の確保，すなわち ADAS などでの利用を想定した車載デバイスでの高速判別の必要性を論じる。汎用軽量モデル MobileNetV3-Small をベースとし，その構成要素である 11 個の bneck (bottleneck) ブロックを使用するか否か（枝刈りするか）の組み合わせ ( $2^{11} = 2,048$  通り) を全探索する，タスク特化型の構造探索手法を提案する。さまざまなエッジコンピューティングシステムで使用されている [62–64]Raspberry Pi 4 [65] を用いた評価実験を通じて，ベースラインである元の MobileNetV3-Small [66] と比較し，判別時間を約 58%削減しつつ F-measure を約 7%改善させる，路面状態判別タスクに適した軽量の構造を発見したことを示す。この精度向上は，元の複雑なモデルが本タスクに対して過学習を起こしていたことを示唆しており，タスクの複雑さに応じた適切なモデル選択の重要性を実証する。

第 6 章では，結論として，本論文で得られた成果を総括する。提案した 3 つの手法（マルチモーダル化によるロバスト性向上，ドメイン適応による汎用性向上，軽量化による速度・精度向上）が，車載センサを用いた冬期路面状態推定の実用化と高度化に寄与することを述べる。併せて，本研究に残された課題を明らかにし，今後の展望について述べる。

以上，本章では本研究の背景と目的，そして論文全体の構成について述べた。上記により明確化された 3 つの課題に対し，本論文は，それぞれの課題に対する手法を提示しその有効性を実証することを通じて，車載センサを用いた冬期路面状態モニタリング基盤の高度化と実用化に貢献するものである。

## 第2章 関連研究

第1章で述べたとおり、積雪寒冷地域における冬期路面の安全確保は重要な社会課題であり、道路管理の高度化や先進運転支援システム(ADAS) [19]・自動運転の実現に向けて、路面状態をリアルタイムかつ正確に把握する手法が不可欠である。また、従来の路面状態把握は道路パトロールや目視観測など人手に依存してきたが、人材不足や労働人口の減少、熟練者の引退に伴い、従来と同等の監視水準を人的リソースのみで維持することは難しくなりつつある。さらに、目視に基づく判定には観測者の主観に起因する判断ばらつきが避けられず、情報の客観性・定量性の観点からも課題が残る。このため、自動化・広域化による管理の効率化が求められ、センシングに基づく路面モニタリング手法が多様に提案されている。特に、安価で普及性に優れ、前方予測も可能な車載カメラは、広域かつ高頻度なモニタリング網を構築する上で現実的な選択肢として期待されている。一方で、こうした車載センサを用いた冬期路面モニタリングを多様な環境下で安定的に運用し、実際の道路管理や走行安全支援に組み込むためには、依然として解決すべき課題が残されている。

本章では、本論文の研究テーマである「冬期路面モニタリングのための車載センサを用いた機械学習に関する研究」の位置づけを明確にするため、まず2.1節において冬期路面モニタリングに関する国内外の研究動向を概観し、どのようなセンサ構成と路面モニタリング方法が提案されてきたかを整理する。続いて、路面状態を把握するためのセンシングの観点から、2.2節で固定センサによる路面モニタリング方式を、2.3節で車載センサによる路面モニタリング方式をそれぞれ整理し、車載センサ方式を「路面非接触系」と「路面接触系」に分けてその特徴と課題をまとめる。さらに、2.4節では路面状態判別に適用されている機械学習・深層学習関連手法として、特徴量ベースの機械学習と深層学習の応用、ならびに複数センサ情報を統合するマルチモーダル学習を整理する。加えて、2.4.4節で学習時とは異なる環境下での性能低下に対応するドメイン適応を、2.4.5節で車載器でのリアルタイム処理を可能にするモデル軽量化を取り上げ、先行研究を概観する。

これらの整理を通じて既存の方式や手法の現状を明らかにし、2.5節では、本論文が取り組むべき課題を、多様な条件下における判別の安定性、広範なエリアでの判別を可能とするための学習時とは異なる環境への適応性、そして車載デバイスにおけるリアルタイムな判別のための計算効率の向上という3つの観点から明確化する。

### 2.1 冬期路面モニタリング研究の現状

従来、冬期路面の状態把握は人手によるモニタリングが中心であった[28]。しかし、全国的な労働人口の減少に伴う人材不足や、長年の経験を有する熟練作業員の引退が進むなかで、従来と同等の監視水準を人的リソースのみで維持することは年々困難になりつつある。

さらに、目視観測に基づく路面状態の判定は観測者の主観に依存する側面が大きく、判断基準の違いに起因する評価のばらつきや、情報の客観性・定量性を確保しにくいといった問題もある。このような背景から、限られた人的資源を補完しつつ広域な道路網を継続的に監視できる、自動化・広域化された冬期路面モニタリング手法の構築による管理の効率化が急務となっている。

こうした人的モニタリングの限界や道路管理の高度化に対する社会的要請に加え、AI・ICTの高度化とセンサの低廉化も相まって、冬期路面の状態をより高頻度かつ高精度に把握しようとする研究・実証が国内外で活発に進められている。都市インフラの維持管理や冬期道路管理を対象とした取り組みでは、既存のCCTV（Closed-Circuit Television）カメラや気象観測装置（RWIS: Road Weather Information System）[47]に深層学習を適用する方式に加え、スマートフォンや車載カメラなど車両に搭載されたセンサを活用する方式が提案されている。

国内の代表的な事例としては、国土技術政策総合研究所が高速道路に設置されたCCTVなど既存インフラの映像を活用可能な可視画像路面センサを冬期道路管理へ適用し、路面状態の連続監視に加えて凍結および凍結防止剤散布後の再凍結の兆候を早期に検知する手法を報告している[67]。同研究では、これらの兆候検知により凍結防止剤の散布・再散布判断を支援し、道路が凍結している時間の短縮や、薬剤散布の効率化を通じたコスト・環境負荷低減に資する可能性が述べられている。別の事例として、大都市圏を対象に、道路パトロール車などに設定したスマートフォンのカメラ画像をクラウド上の大規模な深層学習モデルにより路面状態を多クラス（乾燥、濡れ、水たまり、圧雪など）に分類する取り組みが報告されている[68]。また、国立研究開発法人 土木研究所 寒地土木研究所では、路面に照射したマイクロ波や近赤外線の反射特性から乾燥・湿潤・凍結・圧雪といった雪氷状態を高精度に判別し、路面のすべりやすさを推計するアルゴリズムを内蔵した小型軽量の車載型非接触路面センサを開発し、屋外実験により既存路面センサと同等の応答時間で高速かつ実用的な雪氷センシングが可能であることを示している[69]。さらに、NEXCO 東日本 北海道支社においては、加速度センサを内面に貼ったタイヤ[14]を用いて北海道の高速道路における走行路面の路面状態を判別し、その結果に基づいて凍結防止剤の散布量や散布区間を自動制御することで、安全性を維持しつつ薬剤使用量の削減と作業効率化を図るスマート凍結防止剤散布システムが実用化されている[15]。また別の方向性として、照度変化や夕暮れ時の逆光など、視覚条件の悪化に起因する誤判別を抑えるために、画像生成モデルを用いて入力画像を正規化し、その後に深層学習判別器を適用することで、複雑な照明条件下での認識精度を改善する手法など、判別が困難な特定の状況における改善手法も提案されはじめている[70]。

海外においても、カメラ画像に対して深層学習を適用し、冬期路面状態を直接または間接的に推定する研究が多数報告されている[11, 71, 72]。また、RWISやカメラ画像など既存の道路気象観測網を活用し、セマンティックセグメンテーション[73]とGAN[74]を組み合わせて雪氷路面の状態を自動分類する研究[75]や、RWIS画像と気温・降雪量・交通量

といったメタデータを統合するマルチモーダル AI によって分類精度を向上させる研究も報告されている [76]. 後者では、畳み込みニューラルネットワーク (CNN) [53] や Vision Transformer [77] を用いて画像特徴を抽出し、気象・路面情報とクロスアテンションなどで統合することで、画像のみのモデルと比較して高い精度とロバスト性を実現している. 一方で、これらの深層学習ベースの手法の多くは、サーバ環境でのバッチ推論やオフライン評価を主な前提としており、実際の道路管理システムや車載環境にそのまま適用するには、モデルの軽量化やシステム統合など実装面での検討が依然として必要である.

このように、冬期路面モニタリング研究は、固定設置型の CCTV や RWIS などの道路カメラを高度化する方向と、スマートフォン・車載カメラ・タイヤ内蔵センサなど車両に搭載したセンサ群を活用する方向の双方で発展している. 一方で、これらの取り組みは、想定する道路環境や利用可能なセンサ構成に応じた個別最適化として設計されており、観測地点やセンシング手段が限定されることが多い. そのため、広域な道路網を対象として、多様な気象条件・道路環境の下で一貫して高い信頼性を確保しつつ、車載器上でリアルタイム判別を行う汎用的な枠組みは依然として十分に確立されていない.

そこで本章では、これらの研究動向を踏まえつつ、まず冬期路面モニタリングに用いられてきたセンサの設置形態とセンシング方式（固定センサ・車載センサ）を整理し、続いて路面状態判別に適用されている機械学習・深層学習の手法を概観する. これにより、本論文が焦点を当てる「車載センサを用いた機械学習による冬期路面モニタリング」の位置づけと、実用化に向けて残された課題を明確にする.

## 2.2 路面モニタリングの方式（固定センサ）

路面状態をセンシングする方式は、センサの設置形態によって大きく二分される. 一つは、道路インフラ側にセンサを固定設置し、特定の地点を継続的に観測する方式（固定センサ）である. もう一つは、車両側にセンサを搭載し、走行しながら広範囲の路面情報を収集する方式（車載センサ）である. 本節では、まず固定センサによる方式に関する先行研究を整理する.

路面状態を定点で観測する方式として、道路インフラ側にセンサを設置する方式が広く研究・運用されている. 代表的なものに、既存の CCTV カメラの映像を解析する方式、路面にセンサを埋設する方式、あるいは気象観測装置 (RWIS) のデータを使用する方式などがある. これらの固定センサは、橋梁部、トンネル出入口などといった特定の危険箇所を継続的に監視する上で高い信頼性を持つ利点がある. しかし一方で、センサが設置された地点の情報しか得られず、広大な道路網全体をカバーするためには多くの設置費用や維持管理コストが必要となる点が課題である. 以下では、各方式に関する先行研究を概観する.

### 1.CCTV カメラ [78,79] :

#### 文献 [78] :

文献 [78] では、冬期道路の安全性を高めるため、交差点や橋梁部に設置された CCTV カメラの映像を用いて路面状態を自動検出する道路管理システムを提案している。凍結・積雪などの危険箇所をリアルタイムに把握し、道路管理者が効率的に除雪・散布作業を行えるよう支援することを目的とし、画像解析によって滑りやすい路面の早期発見が可能であることを示している。

#### 文献 [79] :

文献 [79] では、道路沿いに設置された CCTV カメラ画像と気象センサ情報を組み合わせ、CNN [53] により路面状態（乾燥・湿潤・積雪など）を自動判別するシステムを提案している。既存の道路観測ステーションを活用し、リアルタイムで滑りやすい路面を検知する仕組みを構築し、多様な路面画像で学習・評価を行い、CCTV 映像だけでも高い判別精度が得られることを示している。

### 2.路面埋め込みセンサ [80] :

#### 文献 [80] :

文献 [80] では、路面と同一高さに設置する埋め込み式の凍結検知センサを用いて冬期道路の状態を直接計測し、その有効性を検証している。センサは舗装面に一体化して配置され、路面温度や凍結の有無を高精度に検知できる点が特徴である。複数地点での実測データに基づき、冬期の滑りやすい路面の早期発見や道路管理判断への活用可能性が示されている。

### 3.気象観測データ [81,82] :

#### 文献 [81] :

文献 [81] では、スウェーデン交通庁が運用する気象観測データである RWIS (Road Weather Information System) と路側カメラ画像を統合し、路面状態を自動分類する手法を提案している。気温・降水量・風速などの RWIS 気象データを画像と併用することで、乾燥・湿潤・積雪・凍結といった路面状態の判別精度が向上することを示している。

#### 文献 [82] :

文献 [82] では、RWIS が高精度な情報を提供する一方、その設置方式に本質的な制約があることが指摘されている。報告書は、RWIS が固定設置ゆえに空間的カバー範囲が限定されること、さらに 1 基あたりの設置費・運用費が高額で、自治体は限られた地点にしか配置できないと述べている。

#### 4.RGB カメラ（可視光カメラ）

文献 [44]：

文献 [44] では、道路管理用に設置された一般的な RGB カメラ映像を用いて、冬期の路面状態を自動判別する手法を提案している。本手法では、道路画像から抽出した色特徴量やテクスチャ情報を基に、乾燥・湿潤・凍結・積雪といった複数の路面状態を分類するアルゴリズムを構築している。

### 2.3 路面モニタリングの方式（車載センサ）

本節では、まず 2.3.1 節で、車載センサを用いた路面モニタリングの基本的な考え方と、固定センサと対比した際の空間的カバレッジの特徴を概説する。車載センサを用いた方式は、センシングの方式によってさらに「路面非接触系」と「路面接触系」に大別されることから、次に 2.3.2 節で路面と非接触で計測を行う方式（カメラ、レーダー、赤外線センサなど）の先行研究を整理し、それぞれの利点と課題を述べる。続いて 2.3.3 節で、タイヤに加わる力や車体挙動・振動などの走行データから路面状態を推定する路面接触系の方式について、同様に研究動向と課題を整理する。特に本論文では、人による視覚的なモニタリングを直接的に代替し得る手段として有用性が高い路面非接触系に着目し、その中でも可視光カメラ画像を用いた画像認識手法を中心的な対象として位置づけと課題を明確化する。

#### 2.3.1 車載センサによる路面モニタリングの概要

固定センサが持つ空間的カバレッジの限界を補うアプローチとして、車両そのものを移動型のセンサプラットフォームとして活用する研究が進んでいる [68, 83]。車両に搭載されたカメラや各種センサから得られる走行データを多数の車両から収集・統合することで、道路網全体の状況を広域かつリアルタイムに把握することが期待されている。このとき車載センサ方式は、車両が通行可能な場所であれば、新たに固定観測装置を設置しなくとも、車両が通行しさえすれば原理的にはどの道路区間でもモニタリングが可能であるという空間的な柔軟性を有する。一方で、データ取得の前提として「実際に車両がその区間を走行すること」が必要であり、交通量が少ない時間帯や道路区間では観測が間欠的になったり、十分なサンプルが得られないといった課題も内在している。

また、高速道路や有料道路のように路線網と管理主体が限定された環境では、専用の観測車両やパトロール車両にセンサを搭載し、計画的に巡回走行させることで、比較的高密度かつ安定したモニタリングを実現できる可能性がある。これに対して、都市内道路や地方部を含む広域な道路網を対象とする場合には、特定の観測車両だけでは空間的カバレッジを確保することが難しく、一般に走行している多数の車両をプローブとして活用する必要が生じる。このときには、民間車両や営業車両へのセンサ搭載、データ収集・共有の仕組み、通信インフラやプライバシー保護に関する制度設計なども含めた社会実装上の検討

が重要となる。

**文献 [83] :**

文献 [83] では、都市部の幹線道路を対象に、車両に搭載された GPS や速度情報などを用いて交通状態をリアルタイムに推定する手法を提案している。固定センサではカバーしきれない区間においても、走行中の車両が移動型センサとして継続的にデータを提供することで、道路網全体の混雑状況を把握できる点が示された。多数の車両から集約された情報を活用することで、交通監視の空間的密度とリアルタイム性を向上させられることを示した事例である。

**文献 [68] :**

文献 [68] では、札幌市における冬期路面管理の高度化を目的に、車載スマートフォンを活用した路面状態の収集を試みている。市内のパトロール車や収集車に AI 判定機能付きスマートフォンを搭載し、走行中に路面画像と位置情報を自動取得し、固定センサでは難しい広域な情報収集を実現し、除排雪や道路管理に活用できる可能性を示した。特定車両の巡回だけでなく、一般車両への展開を視野に入れることで、交通量に応じた空間的カバレッジの向上を期待できることについて論じている。

## 2.3.2 路面非接触系センサ

路面非接触系センサは、路面と物理的に接触せずに状態を推定する方式である。本論文でも主要な情報源として用いる安価な RGB カメラ（可視光カメラ）の画像認識による手法のほか、レーザー光の反射を利用するレーザーレーダー、路面温度を計測する赤外線サーモグラフィ、あるいはマイクロ波レーダーを用いた手法などが提案されている。

### 1.RGB カメラ（可視光カメラ） [17,41] :

RGB カメラを用いた路面状態推定は、低コストかつ既存の車載カメラを活用できる点で実装性に優れるため、近年広く研究されている。画像認識の手法を応用することで、乾燥・湿潤・凍結・積雪など複数の路面状態を分類可能であり、深層学習モデルの導入により精度向上が期待されている。一方で、光学条件への依存度が高く、照明変化や影、夜間走行などの環境要因による誤認識が課題とされている。

**文献 [41] :**

文献 [41] では、車載カメラで取得した可視光（RGB）画像を用いて冬期高速道路の路面状態を推定する手法を提案している。MobileNet [58] を基盤とした軽量な深層学習モデルを採用し、乾燥・湿潤・凍結・積雪といった複数の状態を効率的に分類した点が特徴である。

文献 [17] :

文献 [17] では、カメラを用いた路面状態判別はコスト面や実装面で魅力的である一方、明暗・光源変化・夜間・影・ハレーションといった光学条件への依存が大きく、暗所・逆光・影が生じる走行環境では誤認識が生じやすいとの指摘がある。さらに、データセットの依存性が強く、照明条件や路面材質の変化に対して頑健性に欠ける点も述べられている。

2. ミリ波レーダー [29,30] :

ミリ波レーダーを用いた路面状態推定は、光学条件に依存しないため、夜間や悪天候下でも安定した計測が可能である点が利点である。路面からの反射特性や偏波比の変化を利用することで、乾燥・湿潤・凍結・積雪など複数の状態を識別できることが報告されている。一方で、センサコストや設置スペースが課題となる場合がある。

文献 [29] :

文献 [29] は、24GHz 帯ミリ波レーダーを用いて路面状態を分類する手法を提案した。乾燥・湿潤・凍結など 12 種類の典型的な路面状態を対象に、レーダー信号から統計量やウェーブレット特徴など複数の特性を抽出し、それらを融合して機械学習モデルで識別する手法である。

文献 [30] :

文献 [30] は、24GHz 帯のミリ波レーダーによる路面状態識別の可能性を実験的に検証した。乾燥、湿潤、凍結、積雪といった路面に対し、ミリ波の反射強度や縦・横偏波比の変化を計測し、状態ごとに特徴的な散乱特性を示すことを明らかにしている。特に濡れ路面や凍結路面では偏波比が大きく変化し、ミリ波レーダーにより低摩擦状態を検知できる可能性を示した。

3. レーザーレーダー (LiDAR) [31,84] :

レーザーレーダー (LiDAR) は、路面の三次元形状や反射強度を高精度に取得できる。点群データを活用することで、乾燥・湿潤・凍結など複数の状態を識別可能であり、深層学習との組み合わせにより精度向上が期待される。一方で、霧・雨・雪などの悪天候下では散乱や遮蔽による計測精度の低下が課題であり、センサ表面の凍結など機械的な不具合も指摘されている。これらの要因から、気象条件への依存性を低減する方法が求められている。

文献 [31] :

文献 [31] では LiDAR を用いて路面状態を分類する深層学習手法を提案した。自動緊急ブレーキへの応用を想定し、LiDAR 点群から得られる高さ情報や反射強度を時

系列的に処理するネットワークを構築し、乾燥・湿潤・凍結などの路面状態を高精度に判別できることを示している。

**文献 [84] :**

文献 [84] では LiDAR が悪天候下でどのように認識性能を損なうかを体系的に整理した。本論文では、霧・雪・雨といった降雪環境では散乱や遮蔽が生じ、点群密度や反射強度が低下すること、さらに低温環境ではセンサ表面の凍結など機械的な不具合も発生し得ることが示されている。これらの要因により、LiDAR の計測精度は気象条件に大きく依存し、悪天候時に性能が劣化するという脆弱性が指摘されている。

**4.赤外線カメラ，赤外線放射計 [17,34] :**

赤外線カメラや赤外線放射計を用いた路面状態推定は、路面表面温度を直接計測できるため、凍結リスクの評価に有効な手法である。センサの設置位置や外気温の影響を受けやすい点が課題として指摘されている。

**文献 [17] :**

文献 [17] では車両に赤外線サーマルカメラを搭載し、走行しながら路面表面温度を連続的に計測して走行路面の路面温度分布を取得し、凍結リスクの高い低温箇所や橋梁部の熱特性を可視化する手法を検証した。

**文献 [34] :**

文献 [34] では車両に搭載した赤外線放射計を用いて走行中に路面表面温度を連続的に計測し、冬期道路の凍結リスクを推定する手法を示した。実走行で取得した温度データと気象条件を組み合わせることで、橋梁部や日陰区間など局所的に温度が低下しやすい箇所を高精度に抽出できることを示している。

**5.路面非接触系センサの課題 [17] :**

**文献 [17] :**

文献 [17] では路面非接触式の路面状態検知手法（カメラ、赤外分光、偏光、レーダーなど）を総括し、実用化に向けた実用上の課題を整理している。特に、これらのセンサは照度変化や雨・雪・水膜などの気象条件に大きく影響され、反射特性の乱れや信号品質の低下によって判別精度が劣化する点が指摘される。また、雪氷路面ではカメラの視認性低下やレーダーの識別困難性が顕著となり、悪天候下でのロバスト性が依然として大きな課題であると述べている。

### 2.3.3 路面接触系センサ

路面接触系センサは、路面と唯一物理的に相互作用するタイヤ周辺の情報から路面状態を判別する方式である。代表的なものとして、タイヤの内周部に加速度センサや歪センサを貼り付ける、いわゆるインテリジェントタイヤ [85]（スマートタイヤ [86]）と呼ばれる方式がある。これらのセンサ方式は、時系列データから抽出された特徴量と 2.4 節で詳述する機械学習モデルを組み合わせる路面状態を判別する方式が主流である。

#### 1. タイヤ内加速度センサ

タイヤ内加速度センサを用いた路面状態推定は、路面と直接接触するタイヤから振動情報を取得できるため、摩擦状態や滑りやすさの検知に優れる手法である。加速度データを解析することで、乾燥・湿潤・凍結・積雪など多様な状態を分類可能であり、機械学習や深層学習を組み合わせることでリアルタイム推定も実現されている。一方で、低速走行や停止・発進が頻繁な環境では信号レベルが低下し、S/N 比の悪化による精度低下が課題とされている。また、センサの耐久性やコスト面も実用化に向けた検討事項である。

#### 文献 [35]：

文献 [35] ではタイヤ内部に加速度センサを備えたインテリジェントタイヤとタイヤ音を収集するマイク、路面温度計を組み合わせた Contact Area Information Sensing (CAIS<sup>TM</sup>) [14] を用い、振動波形・タイヤ音・路面温度など複数の信号特徴量を統合し、統計的特徴抽出と機械学習的な識別手法により、凍結・積雪・圧雪・湿潤・乾燥などといった多様な路面状態を分類する手法を示している。

#### 文献 [15]：

文献 [15] ではタイヤ内加速度センサで得られる振動データを解析し、乾燥・湿潤・凍結・雪氷といった路面状態を自動判別する手法を用いたスマート散布システムを提案している。本手法は冬期高速道路において実際に 3 シーズン運用され、100 m ごとに路面状態を自動推定し、その結果に基づいて凍結防止剤の散布量を自動制御する仕組みを構築した。運用結果として、適正散布と薬剤使用量削減の両立が確認されている。

#### 文献 [36]：

文献 [36] ではタイヤ内部に三軸加速度センサを装着したインテリジェントタイヤを用い、その接地中の振動データを収集した上で、畳み込みニューラルネットワーク (CNN) [53] や全結合ニューラルネットワーク (FCNN) [87] を使用してリアルタイムに路面状態を分類する手法を提案している。

文献 [52] :

文献 [52] ではタイヤ内部に三軸加速度センサを固定しタイヤ進行方向のタイヤ特性を検証している。一般道のように低速走行かつ停止・発進の頻度が高い環境では、加速度センサから得られる信号レベルが低下し、S/N 比（信号対雑音比）が悪化するため、判別精度が著しく低下するという課題を示している。

## 2.歪センサ

歪センサを用いたタイヤ内部計測は、タイヤと路面の接触領域における力学的変化を直接捉えられる点で、摩耗状態や接地特性の評価に有効な手法である。路面状態推定を主目的とする研究はないものの、歪分布からタイヤ・路面間の相互作用を解析することで、低速走行時でも安定したデータ取得が可能であることが示されている。一方で、センサの耐久性や設置コスト、データ処理の複雑さが課題となる。

文献 [51] :

文献 [51] ではタイヤ内部に設置した歪センサを用いて、低速走行車両におけるタイヤ摩耗状態を自己診断する手法を提案している。路面状態を直接推定する研究ではないものの、タイヤ内部の計測データから車両・路面との相互作用を評価する点で、車載センシングの発展形として位置づけられる。特に、低速域でも安定して取得可能な歪分布に着目し、摩耗レベルを推定するアルゴリズムを構築した点が特徴である。

## 2.4 路面状態判別のための機械学習関連手法

センサデータから路面状態を判別するモデルの構築には、機械学習の手法が広く用いられる。その手法は大きく二分され、一つはセンサデータから物理的な特徴量を設計・抽出し、それらを判別器に入力する手法であり、もう一つは、特に画像データを対象として、特徴抽出から分類までを深層学習で一貫して学習する手法である。本節では、これらの手法に関する先行研究をレビューする。そこで、まず 2.4.1 節にて、センサ信号から物理的意味を持つ特徴量を設計・抽出し、SVM や決定木ベースのアンサンブル学習などの判別器で分類する特徴量ベース手法を整理する。次に 2.4.2 節では、主に画像データを対象として、特徴抽出から分類までを深層学習で一貫して学習する手法を扱う。さらに 2.4.3 節では、複数モダリティを統合するマルチモーダル学習によるロバスト性向上を概観し、2.4.4 節では、環境差に起因するドメインシフトへの対処としてのドメイン適応を述べる。最後に 2.4.5 節では、車載器などでのオンデバイス推論を念頭に置いたモデル軽量化手法を整理する。

### 2.4.1 特徴量ベースの機械学習による路面状態判別

タイヤ内加速度センサをはじめとする接触系センサから得られる時系列データは、多くの場合、まず FFT などの周波数解析や統計量の計算によって物理的な意味を持つ特徴量に

変換される。

このように設計された特徴量を入力とし、サポートベクターマシン (SVM) [88], 決定木ベースのアンサンブル学習 (Random Forest [60], LightGBM [59] など) といった、いわゆる古典的な機械学習を用いて路面状態を判別する手法は、本分野において確立された手法の一つである。これらの手法は、比較的少ないデータでも学習が可能であり、判別根拠の解釈性が高いという利点を持つ。以下に各機械学習の手法とそれを用いた路面状態判別の手法を説明する。

## 1. サポートベクターマシン (SVM)

### 文献 [88] :

文献 [88] では、SVM の基礎理論を提示した。本研究では、分類問題におけるマージン最大化の考え方を導入し、線形分離可能・不可能な場合を扱うためのソフトマージン手法を定式化した。また、非線形判別を実現するためにカーネルトリックを用いる枠組みを示し、SVM の計算的特徴や最適化問題として定式化した。

### 文献 [89] :

文献 [89] では、タイヤ振動などの時系列信号から得られる周波数特徴を用いて路面状態进行分类する手法を提案している。特徴量には時系列同士の類似度を捉えるための Global Alignment Kernel (GAK) [90] を導入し、SVM と組み合わせることで、路面状態を高精度に識別可能であることを示した。

## 2. 決定木ベースのアンサンブル学習

### 文献 [60] :

文献 [60] では、複数の決定木を組み合わせる分類・回帰を行う手法を提案した。本文献では、ブートストラップサンプリングによる学習データの生成と、各分岐で特徴量をランダムに選択する仕組みを導入し、決定木モデルの多様性を高める枠組みを示した。また、予測精度の推定に用いる Out-of-Bag 誤差や、特徴量の重要度評価方法についても記述しており、ランダム化とアンサンブルによる学習手法の基礎を体系的に示している。

### 文献 [91] :

文献 [91] では、損失関数の負の勾配に基づき弱学習器を逐次追加する Gradient Boosting Machine (GBM) を提案した。本研究は、決定木を弱学習器として組み合わせる枠組みを定式化している。多数の決定木を独立に構築して多数決を行う Random Forest とは異なり、GBM は逐次的に誤差を補正する学習構造をとる点が特徴である。

**文献 [59] :**

文献 [59] では、GBM を高速・軽量に実装する LightGBM を提案している。本文献では、誤差に敏感なデータ点を優先的に学習する Gradient-based One-Side Sampling(GOSS) や特徴量の分布に基づきヒストグラムを効率化する Exclusive Feature Bundling (EFB) を導入し、計算量とメモリ使用量を削減した。

**文献 [92] :**

文献 [92] では、冬期の路面状態を気象データと交通量データから推定するため、Random Forest を用いた分類モデルを構築している。観測地点における気温、降雪量、積雪深、交通量などの複数指標を特徴量とし、路面状態を推定する手法を提案した。

**文献 [93] :**

文献 [93] では、24GHz 帯などのミリ波レーダーを用い、6 種類の路面状態を測定した。取得信号を FFT 解析により特徴量化し、統計量や画像表現を入力として LightGBM をはじめとした分類モデルを訓練・評価した。

## 2.4.2 深層学習による路面状態判別

近年、画像認識の分野では深層学習 (Deep Learning)、特に畳み込みニューラルネットワーク (CNN) [53] が主流となっている。VGG [94], ResNet [95], DenseNet [96] といった、より深く複雑なアーキテクチャが提案され、ImageNet [97] などの大規模データセットを用いた事前学習モデルが、多様なタスクで高い汎化性能を示すことが知られている。

**文献 [53] :**

文献 [53] では、畳み込みニューラルネットワーク (CNN) の代表的モデルである LeNet-5 を提示し、手書き文字認識を題材にその有効性を体系的に示した。本文献では、畳み込み層とサブサンプリング層を段階的に重ね、誤差逆伝搬で学習する構造を記述している。さらに、大規模データを用いた実験により、CNN が局所受容野や重み共有を通じて画像認識に適した特徴抽出を自動的に行うことを示し、CNN の基盤を確立した。

**文献 [97] :**

文献 [97] では、大規模画像データベース ImageNet を提案した。英語の単語を意味ごとに整理した語彙データベースである WordNet [98] の階層構造に基づいて画像カテゴリを体系化し、1,000 万枚規模の画像を収集・整理した点を特徴とする。本研究では、インターネット画像を大規模に収集し、人手によるラベリングを経て高品質な訓練データとして整備する手法を示した。ImageNet は深層学習を用いた画像認識の

研究の基盤データセットとして位置づけられる。

**文献 [94] :**

文献 [94] では、より深い構造をもつ畳み込みニューラルネットワーク (VGGNet) を提案した。本研究では、 $3 \times 3$  の小さな畳み込みフィルタを多数積層し、層を深くすることで表現能力が向上することを示した。ImageNet の分類タスクで VGG-16 および VGG-19 が高い精度を達成したことを報告し、深層化が CNN 性能向上に有効であることを実証した。

**文献 [95] :**

文献 [95] では、深いネットワークの学習を困難にする勾配消失などの問題に対処するため、残差学習 (Residual Learning) を導入した ResNet を提案した。本研究では、恒等写像を経由するスキップ接続を各ブロックに追加することで、層を深くしても誤差逆伝播が安定する構造を示した。これにより 100 層を超える CNN を効率的に学習できることを確認し、ImageNet で高い精度を達成した。

本研究の対象である路面状態判別の分野においても、これらの CNN アーキテクチャを車載カメラ画像に適用する研究が活発に行われている。先行研究では、路面画像を収集・分類したデータセットを用いて CNN モデルを学習させることで、従来の画像処理ベースの手法を凌駕する高い判別精度が達成されたと報告されている。

**文献 [11] :**

文献 [11] では、固定設置された交通・気象カメラ画像から冬期路面の積雪・凍結状況をリアルタイムに判別する手法として、残差学習を用いた CNN を用いたモデルを提案している。事前学習済みの深層ネットワークを基に、路面の積雪被覆率を分類するよう事後学習し、複数のカメラ画像を用いた実験で精度と汎化性能を比較検証した。

**文献 [79] :**

文献 [79] では、道路脇に設置された CCTV カメラ画像から路面の滑りやすさを判定するシステムを提案している。既設カメラで取得した画像を用い、転移学習を適用した畳み込みニューラルネットワークとして ResNet50/152 [95], VGG19 [94], DenseNet201 [96] を比較しつつ、乾燥・湿潤・積雪路面を分類する手法を構築した。DenseNet201 を用いたモデルが最も高精度であり、運転手に速度制限情報を提供する活用方法も示している。

### 2.4.3 マルチモーダル学習による判別ロバスト性の向上

単一のセンサ（シングルモーダル）情報のみでは捉えきれない複雑な事象に対し、特性の異なる複数のセンサ（モダリティ）情報を統合して判断を行うマルチモーダル学習の手法が広く研究されている。情報統合のタイミングにより、入力に近い層で特徴量を結合する「Early Fusion」や、各モダリティで一度判別を行った後にその結果を統合する「Late Fusion」といった手法が提案されている。

#### 文献 [57] :

文献 [57] では、マルチモーダル機械学習の研究領域を体系化し、表現学習・アライメント・融合・推論などの観点から包括的に整理した。本研究では、異なるモダリティの統合方法として、特徴レベルで統合する Early Fusion と各モダリティの出力を後段で統合する Late Fusion を含む複数の融合手法を分類し、その利点・課題をまとめている。

#### 文献 [99] :

文献 [99] では、定点カメラ画像と気象・交通などの補助時系列データを融合し、冬期路面の乾燥・湿潤・雪・凍結などを判別する Early Fusion によるマルチモーダルな Transformer [100] モデルを提案している。異なるモダリティの特徴をクロスアテンションで相互補完し、さらに複数時刻を入力とする時系列処理を導入し、実際の冬期高速道路データを用いた実験により、高精度な判別性能を実証している。

#### 文献 [101] :

文献 [101] では、定点カメラ画像に加えて気象予測値や路面状況に関するテキスト情報を組み合わせ、冬期路面状態を分類する Early Fusion のマルチモーダル深層学習手法を提案している。画像特徴と数値・テキスト的特徴を統合して入力とし、クラス不均衡による判別性能低下を抑えるために Focal Loss を導入した。実道路データを用いた評価では、湿潤・積雪・凍結といった複数の路面状態に対して精度向上が確認され、マルチモーダル統合の有効性を示した。

### 2.4.4 ドメイン適応による環境適応性の向上

深層学習モデルは、学習データ（ソースドメイン）と推論データ（ターゲットドメイン）の分布が異なる場合に性能が低下する「ドメインシフト問題」を抱えている。この問題を解決するための方法全般を転移学習と呼ぶ。転移学習の中でも、ターゲットドメインのラベルの有無で方法が分かれ、ターゲットドメインのラベルがある場合は、ソースドメインで学習したモデルを少量のターゲットドメインで微調整（Fine-tuning）するのが代表的な方法である。一方で、ソースドメインのラベルなしデータを用いてモデルの適応を図る方

法は教師なしドメイン適応（Unsupervised Domain Adaptation: UDA） [102] と呼ぶ。これには、ドメイン間の特微量分布を近づける手法や、疑似ラベルを活用する手法などがある。

**文献 [103] :**

文献 [103] では、転移学習全般を体系的に整理したサーベイであり、学習データ（ソース）とテストデータ（ターゲット）の分布差によって性能が低下するドメインシフト問題を中心概念として扱っている。論文では、特徴空間・分布・ラベル空間の違いに基づくタスク分類を提示し、ドメイン適応を含む多様な手法を比較・整理している。

**文献 [104] :**

文献 [104] では、深層ニューラルネットワークにおける特微量の転移性と Fine-tuning の効果を体系的に検討した。ImageNet [97] で事前学習した CNN を異なるタスクへ転移し、ネットワークのどの層を固定し、どの層を微調整するかによって性能がどのように変化するかを詳細に分析した。

**文献 [102] :**

文献 [102] では、教師なし深層ドメイン適応（Unsupervised Deep Domain Adaptation: UDA）に関する研究を体系的に整理した。ラベル付きのソースドメインと、ラベルなしのターゲットドメイン間の分布差を低減し、性能劣化を防ぐことを目的とする手法を体系的に整理している。特徴分布の整合、再構成型手法、疑似ラベル生成などの主要アプローチを分類し、代表的アルゴリズムを比較する。また理論的背景、評価指標、ベンチマークデータセットを整理し、今後の課題として負の転移、安定学習、実応用への展開を挙げている。

**文献 [105] :**

文献 [105] では、点群のドメイン適応において、特徴空間内での近傍投票に基づく信頼性の高い疑似ラベルを導入した手法を提案している。まずソースデータで学習した特徴抽出器を用いてソース・ターゲット双方を共通特徴空間に写像し、ターゲットサンプルに対してその近傍に位置するソースサンプルのラベルを多数決で付与する。さらに、一致度の高い疑似ラベルのみを用いて自己学習を進めることで、ドメインギャップを効果的に縮小する枠組みを示した。

冬期路面判別タスクにおいて、このドメインシフトの課題に対して UDA でアプローチした例は少ない。一方で、舗装損傷分類タスクや画像から道路を抽出するセグメンテーションタスクなどで本アプローチが検討されている。

文献 [106] :

文献 [106] では、舗装損傷分類におけるドメインシフト問題を解決するため、自己教師あり学習と敵対的適応を組み合わせた手法を提案している。本研究では、前景特徴抽出モジュールを導入し、ラベルなしターゲットデータを活用して特徴分布を整合させることで、追加のラベル付けコストなしにモデルの汎化性能を向上させている。

文献 [107] :

文献 [107] では、道路検出におけるドメインシフト問題を解決するため、U-Net ベースの CNN に敵対的学習を組み込んだ UDA 手法を提案した。ラベルなしターゲットデータを活用し、特徴分布の整合を図ることで IoU や F-measure を大幅に改善し、追加のラベル付けなしで汎化性能を向上させた。

## 2.4.5 オンデバイス推論のためのモデル軽量化

深層学習モデルをスマートフォンや車載器といったリソースに制約のあるエッジデバイス上でリアルタイムに動作（オンデバイス推論）させるため、モデル軽量化に関する研究が数多く存在する。軽量の構造を探索する手法である Neural Architecture Search (NAS) [108] により、MobileNet [58] をはじめとした計算効率の高いアーキテクチャが提案されている。また、学習された構造を軽量化するための代表的な手法として、モデルの冗長な接続や重みを削除する枝刈り (Pruning)、重みのビット数を削減する量子化 (Quantization)、大規模モデルの知識を小規模モデルに転移させる知識蒸留 (Knowledge Distillation) などが挙げられる。

文献 [108] :

文献 [108] では、Neural Architecture Search (NAS) の基本概念と主要な構成要素を体系的に整理した。特に、探索空間 (Search Space)、探索戦略 (Search Strategy)、性能推定 (Performance Estimation) の 3 つの観点から既存手法を分類し、それぞれの特徴や課題を明確に示した。

文献 [58] :

文献 [58] では、モバイル環境における画像認識の効率化を目的として、MobileNet を提案した。本研究では、従来の畳み込み演算を深さ方向と点方向に分離する Depthwise Separable Convolution を導入し、モデルの計算量とパラメータ数を大幅に削減している。これにより、精度を維持しつつ、低消費電力デバイスでのリアルタイム推論を可能にし、エッジコンピューティングや組み込みシステムへの応用を促進した。

**文献 [66] :**

文献 [66] では、MobileNet およびその後継の MobileNetV2 [109] の設計思想を発展させ、モバイル環境に最適化された高効率モデル MobileNetV3 を提案した。本研究では、Neural Architecture Search (NAS) [108] による構造探索を行い、従来の深さ方向畳み込みとボトルネック構造を継承しつつ、滑らかな非線形性を持つ Swish 関数をハードウェア実装に適した形で近似した h-swish 活性化関数を導入することで精度と計算効率をさらに向上させた。

**文献 [110] :**

文献 [110] では、深層ニューラルネットワークにおける枝刈り手法を包括的に整理した。本文献は、枝刈りの分類を実施タイミング・対象構造・手法に基づき体系化し、既存研究の性能比較と分析を行っている。さらに、大規模モデルやハードウェア最適化への応用、他の圧縮手法との統合、今後の研究課題についても詳細に議論し、効率的なモデル設計に向けた推奨事項を提示している。

**文献 [111] :**

文献 [111] では、深層ニューラルネットワークにおける量子化手法を包括的に整理した。本稿では、ポストトレーニング量子化 (Post-Training Quantization)、量子化対応学習 (Quantization-Aware Training)、および混合精度量子化といった主要な手法を体系的に分類し、計算効率、メモリ削減、精度維持の観点から比較分析を行った。さらに、畳み込みニューラルネットワークや Transformer モデルを含む多様なモデルへの適用事例、ハードウェア実装上の課題、ならびに今後の研究方向についても詳細に示している。

**文献 [112] :**

文献 [112] では、知識蒸留 (Knowledge Distillation) に関する包括的なサーベイであり、大規模な教師モデルから小規模な生徒モデルへ知識を転移する手法を体系的に整理している。出力分布や中間特徴、関係性など蒸留対象の分類、学習フレームワークや損失設計、画像認識・検出などの応用例を整理し、理論的理解の不足やロバスト性といった今後の課題も議論している。

**文献 [113] :**

文献 [113] では、知識蒸留に関する理論と手法を体系的に整理。本文献では、教師モデルから生徒モデルへの知識転移を実現する主要なアプローチを、応答ベース・特徴ベース・関係ベースの観点から分類し、それぞれの特徴と適用領域を論じている。さらに、蒸留の設計要素、性能向上のための工夫、コンピュータビジョンや自然言語処理など多様な応用事例を網羅し、今後の研究課題と展望を提示した。

これらの課題は、路面判別タスクにおいても不可欠である。特に ADAS などでの利用を想定した場合、高精度と低遅延（高速判別）の両立が求められる。先行研究においても、MobileNet のような軽量アーキテクチャを路面判別に応用する試みや、既存モデルを枝刈り・量子化などによって高速化する検討が行われている。

#### 文献 [41] :

文献 [41] では、冬期高速道路における路面状態推定手法を提案した研究である。本稿では、車載カメラ画像を入力とし、軽量の深層学習モデルである MobileNet を用いて路面状態を分類するモデルを構築している。5 種類の路面状態を対象に、実車両から取得したデータを用いて有効性を検証した。

## 2.5 本論文で解決すべき課題とその解決方法

2.2 節から 2.4 節で概観したとおり、車載センサ、特にカメラを用いた冬期路面状態推定は、機械学習の発展と共にその精度を大きく向上させてきた。しかし、これを実世界の多様かつ制約の厳しい環境で安定的に運用し、道路管理や走行安全支援といった実システムに実装するためには、既存の手法だけでは不十分な 3 つの課題が存在する。

第一の課題は、多様な条件下での判別安定性（ロバスト性）である。2.3.2 節で述べたカメラ単体での推定は、光学センサの宿命として、夜間や前方車両による遮蔽、ヘッドライトのハレーションといった外的要因に脆弱である。一方で、2.3.3 節で述べた接触系センサも、段差や路面の凹凸などによるノイズ付加や、低速走行・停止時の S/N 比低下などにより、判別が困難になるという異なる弱点を持つ。したがって、単一のセンサだけでは、あらゆる状況で信頼できる判別を行うことは困難である。

第二の課題は、学習時とは異なる環境への適応性（環境適応性）である。2.4.4 節で触れたとおり、深層学習モデルは、学習時に用いたデータ（ソースドメイン）と実際に適用する環境（ターゲットドメイン）の間に分布の差異があると、判別精度が著しく低下するドメインシフト問題に直面する。例えば、高速道路のように限定的な範囲で収集したデータで学習した判別器を、一般道など異なる環境へそのまま適用すると、撮影条件や路面状態の出現頻度の違いにより精度低下が生じうる。この問題に対して、適用先のデータを網羅的に収集し、人手で正確なラベルを付与して再学習やファインチューニングを行うことは、コストと時間の面で現実的ではない。したがって、追加のラベル付けを最小限に抑えつつ、既存の学習済みモデルを新しい環境へ適応させる枠組みが求められる。

第三の課題は、車載器における計算効率である。2.4.5 節で述べたとおり、ADAS や自動運転における走行安全支援では通信遅延を許容できず、車載でのリアルタイムなオンデバイス判別が必須である。しかし、高精度な深層学習モデルは、その精度と引き換えに膨大な計算コストを要求するものが多く、演算能力やメモリが限られた車載器への実装を阻む大きな障壁となっている。

本論文は、これら 3 つの実用化に向けた核心的な課題である、判別のロバスト性、異なる環境への適応性、および車載器での計算効率を克服し、車載センサを中核とした冬期路面状態推定の基盤を確立することを目的とする。

この目的を達成するため、本論文では以下の具体的な解決方法を提案し、その有効性を実証する。

### 1. マルチモーダル・レイトフュージョン（第 3 章）

第一の課題であるロバスト性の向上に対し、特性の異なるセンサ群（路面非接触系のカメラ画像と路面接触系のタイヤ内加速度センサ情報）を個別の判別器で処理した後、路面状態確率を最終段の判別器で統合する「Late Fusion」を採用する。これにより、一方のセンサが信頼できない状況でも、他方の情報で補完し、ロバストな判別を実現する。

### 2. 低コストなドメイン適応（第 4 章）

第二の課題である環境適応性の確保に対し、再学習やラベル付けを必要としない、低コストなドメイン適応手法を導入する。具体的には、学習済みモデルの出力（確信度）と  $k$  近傍法アルゴリズム [61] を組み合わせ、適用先の環境の「ラベルなし」参照データ群を利用して、判別器の判別結果を自動で訂正する後処理手法を提案する。

### 3. タスク特化型モデル軽量化（第 5 章）

第三の課題である計算効率の向上に対し、汎用的な軽量 CNN 判別器である MobileNetV3 [66] が、路面判別という特定タスクに対しては必ずしも最適な構造とは限らず、冗長な計算を含む可能性に着目する。そこで、構造的枝刈りにより判別器の構成要素を体系的に削除する探索を行い、タスクに必要な表現能力を保ったまま演算量を削減する。これにより、ベースラインの精度を維持しつつ、車載器上での判別速度を大幅に高速化する、タスク特化型の軽量モデル構造を獲得することを目指す。

## 2.6 まとめ

本章では、本論文の研究テーマである「車載センサを用いた冬期路面状態推定」に関連する既存の研究を、センシング方式と機械学習の応用の両面から概観した。

路面状態モニタリングの方式として、固定センサと車載センサ（路面非接触系、路面接触系）の利点と限界を整理した。また、路面状態判別のための機械学習の応用として、特徴量ベースの手法と深層学習の活用、マルチモーダル学習、ドメイン適応、モデル軽量化といった主要な分野における先行研究をレビューした。これらの調査に基づき、既存の手法を実用化する上での核心的な課題として、判別のロバスト性（単一センサの弱点）、異なる環境への適応性（ドメインシフト問題）、および計算効率（オンデバイス判別の計算コス

ト) の 3 点を特定した.

本論文は, これらの課題に対し, それぞれ第 3 章 (マルチモーダル・レイトフュージョン), 第 4 章 (低コストなドメイン適応), 第 5 章 (タスク特化型モデル軽量化) において具体的な解決手法を提案するものである. 次章以降では, これらの提案手法の詳細と, 実車データを用いた有効性の検証について詳述する.

## 第3章 複数の車載センサデータを統合した路面状態判別機

本章では、冬期の一般道において路面状態をよりロバストに判別することを目的とし、路面非接触系センサである車載カメラとタイヤ内加速度センサをはじめとした路面接触系センサから得られる情報を統合したマルチモーダルな路面状態判別機を扱う。単一の情報源のみに依存した従来手法では、急な段差や車速変動、視界不良など実道路特有の条件下で精度が不安定になるという課題があり、本章ではその克服に向けた一つのアプローチとして Late Fusion 型のフレームワークを検討する。

以降では、まず冬期路面状態モニタリングの背景と既存研究を踏まえて、本章で扱う課題設定と提案手法の位置づけを 3.1 節で整理する。3.2 節では、提案するマルチモーダル判別機の全体像と、各判別器（画像判別器、路面接触系センサ判別器、Late Fusion 判別器）の役割を示す。3.3 節では、冬期の一般道走行実験によるデータ取得方法とデータセット構築・前処理について述べるとともに、提案手法の有効性を検証するための評価指標および実験条件を整理する。3.4 節では、Late Fusion に適用するアルゴリズムの比較や単一モーダルとの精度比較、混同行列に基づく詳細な分析結果を示し、最後の 3.5 節で本章を総括する。

### 3.1 はじめに

第1章では、冬期道路交通における路面状態モニタリングの社会的背景と、乾燥、湿潤、凍結、積雪などの路面状態が車両のスリップリスクや制動距離に直結することを整理した [8]。また、道路管理者にとっても、凍結防止剤の散布タイミングや量を最適化し、塩害などの環境負荷 [4] を最小限に抑えつつ安全性を維持するために、路面状態の正確な把握が不可欠であることを示した [10, 11]。さらに第2章では、固定センサおよび車載センサを用いた冬期路面モニタリングの既存研究を概観し、冬期路面状態モニタリングにおける残された課題を整理した。

一方、車載センサに着目した第1章の1.3節や第2章の2.3節で述べたように、冬期路面状態の判別は、おおまかに路面接触系センサと路面非接触系センサという二つのアプローチに大別される。前者は、路面と唯一接する自動車部品であるタイヤあるいはその周辺にセンサを設置し、振動、音、温度などの路面接触系情報に基づいて判別する手法であり、タイヤ内加速度センサや路面温度計、タイヤ走行音を拾うマイクを用いる CAIST<sup>TM</sup> システム [14] が高速道路を対象に実用化されている [15, 35]。これらの手法は路面からの直接的な情報を利用できる利点があるが、タイヤの振動を主に捉える加速度センサの出力はタイヤの遠心力に比例することから、その信頼性は車速に依存する側面があり、信号機や交差点などで停止・発進・低速走行が頻繁に発生して低速走行が増える一般道においてはセンサ

信号の S/N 比 (Signal-to-noise ratio) が低下し、単独では安定した精度を確保することが困難になるという課題がある [52].

これに対して、車載カメラで撮影した画像情報 (路面非接触系) を用いるアプローチは、深層学習などの画像認識技術を適用することで、低速走行時でも路面の視覚的な特徴を捉えられる利点を持つ [40, 41]. しかし一方で、濡れた路面、凍結路面、シャーベット路面といった視覚的な差異が微妙な状態の判別精度に課題が残る. また、降雪によりカメラの視界が覆われたり、夜間に対向車線のヘッドライトがカメラに入射したりするなど、光学的な要因によって路面が観測できなくなる状況に脆弱であるという根本的な課題も抱えている [17].

このように、路面接触系センサと路面非接触系センサでは、誤判別を引き起こす要因が必ずしも一致しない. 広範な道路網においては多様な走行環境が存在するため、単一の情報源のみでロバストに路面状態を判別し続けることには限界がある. そこで本章では、第 1 章で掲げた課題のうち「マルチセンサフュージョンによる高精度化」に対応する取り組みとして、情報源の異なる複数の車載センサデータ (カメラ画像、タイヤ内加速度センサ、路面温度計、マイク) を統合するマルチモーダル [57] な路面状態判別器を提案する.

提案手法は、まず画像から路面状態確率を判別する判別器と、路面接触系センサデータから路面状態確率を判別する判別器を個別に構築する. その上で、両判別器から出力される確率情報を入力とし、最終的な路面状態を判別する第三の判別器を設ける構成をとる. このような、各モーダルで得られた結果を統合するアプローチは、マルチモーダル機械学習において Late Fusion と呼ばれる手法である [57]. 各モーダルの出力を一度「路面状態確率」という共通の尺度に変換した上で統合することで、センサ特性の違いによる不整合を緩和しつつ、互いの利点を補完的に活用することを目指す.

## 3.2 Late Fusion によるマルチモーダル判別手法

本節では、画像および路面接触系センサから得られる複数の情報源を統合して路面状態を判別する Late Fusion 型マルチモーダル判別手法について述べる. まず提案手法全体のフレームワークを概説したのち、画像を入力とする判別器 1、路面接触系センサを入力とする判別器 2、およびそれらを統合する判別器 3 の構成と学習方法について順に説明する.

### 3.2.1 手法全体のフレームワーク

本章で提案する冬期の路面状態判別モデルは、画像 (路面非接触系) と路面接触系センサという、情報源の異なるデータを統合するマルチモーダルモデルである. 本手法の核心は、情報源の異なるデータを直接統合するのではなく、それぞれを一度「路面状態確率」という共通の尺度に変換した上で統合する点にある. このアプローチにより、特性の異なるデータを効果的に組み合わせることを目指す.

提案手法の全体のフレームワークを図 4 に示す. 本手法は 3 つの機械学習判別器によっ

て構成される．第一の「判別器 1」は，車載カメラの画像を入力とし，路面状態の確率  $p_{image}^k$  を出力する．第二の「判別器 2」は，加速度センサ，路面温度計，マイク，GPS などから得られる路面接触系データを入力とし，路面状態の確率  $p_{road}^k$  を出力する．そして第三の「判別器 3」が，判別器 1 と判別器 2 から出力された 2 組の路面状態確率を入力とし，最終的な路面状態の確率  $p_{fusion}^k$  を出力する Late Fusion 判別器である．最終的な路面状態  $L$  は，この判別器 3 が出力した確率  $p_{fusion}^k$  が最大となるクラス  $k$  として，式 (3.1) に基づいて決定される．

$$L = \operatorname{argmax}_k p_{fusion}^k \quad (3.1)$$

学習時は，まず判別器 1 と判別器 2 を個別に学習させ，これらの判別器を確定させた後，最後に判別器 3 の学習を行う．




図 4: Late Fusion の冬期路面状態判別器のフレームワーク

### 3.2.2 判別器 1：画像による路面状態の判別器

判別器 1 は，車載カメラで撮影された画像から路面状態を判別する．本研究では，車載器のような比較的計算能力の低いコンピュータでのリアルタイム動作を想定している．そのため，深層学習モデルの中で画像を入力とした判別器として適した畳み込みニューラルネットワーク（CNN） [53] において，パラメータ数が少なく計算コストの低い MobileNet [58] を採用した．

入力データとして，先行研究 [41] を参考に，図 5 のとおり車両前方を撮影した画像から固定された位置の路面領域を縦 80 ピクセル，横 200 ピクセルの長方形に切り出したものを使用する．判別器は，入力された各画像に対して，各路面状態  $k$ （乾燥，半湿，湿潤，シャーベット，凍結，積雪）の確率値  $p_{image}^k$  を出力するように学習される．




図 5: 画像の切り出し方

### 3.2.3 判別器 2：路面接触系センサによる路面状態の判別器

判別器 2 は、タイヤと路面の接触に係るセンサ群（路面接触系）のデータから路面状態を判別する。本研究では、タイヤ内加速度センサ、路面温度計、タイヤ走行音を用いる CAIS™ [14] のシステムを活用する。

ただし、既存の CAIS™ システムは最適化された単一の路面状態を出力するため、本手法ではその途中で計算される中間特徴量を入力として利用する。入力特徴量は、加速度センサに基づく各種路面状態の程度、タイヤ接触寸前の路面温度、タイヤ走行音のボリューム、および GPS から算出される車速で構成される 4 種の特徴量で、合計で 8 次元の情報になる。これらの特徴量は、タイヤ 1 回転ごとに出力される。

判別器としては実験的に最良のものを選択し、アンサンブル学習器の一種である LightGBM [59] を採用した。LightGBM は、Random Forest [60] や XGBoost [113] といった同じアンサンブル系の手法と比較して学習が高速であり、軽量のモデル構築が可能である。これにより、判別器 1 の MobileNet が稼働する車載コンピュータ上でも、十分にリアルタイム判別が可能であると判断した。判別器 2 は、判別器 1 と同様に入力された特徴量 1 組に対して、各路面状態の確率  $p_{road}^k$  を出力するように学習される。

### 3.2.4 判別器 3：路面状態の Late Fusion 判別器

判別器 3 は、前段の 2 つの判別器の出力を統合し、最終的な路面状態を判別する Late Fusion の役割を担う。本研究では、画像特徴量と路面接触系センサ特徴量を早い段階で結合して単一のモデルに入力する Early Fusion ではなく、各モジュールで一度独立に判別を行った後に結果を統合する Late Fusion を採用する。これは、冬期一般道の実環境では各モジュールに突発的なエラーが生じ、片方だけが一時的に信頼できなくなる状況を想定する必要があるためである。Late Fusion では、各モジュールで得られる判断（確率）を独立に算出した上で統合できるため、片方の出力が劣化してももう一方の情報で補完しやすく、部分的なエラーに対して頑健な構成になりやすいことが指摘されている [114]。

本手法では、各モジュールの出力を一度「路面状態確率」という共通の尺度に変換し、その確率情報を入力として統合する。判別器 3 への入力は、判別器 1 からの画像に基づく確率  $p_{image}^k$  と、判別器 2 からの接触系センサに基づく確率  $p_{road}^k$  を連結したベクトルである。本研究では路面状態を 6 分類（乾燥、半湿、湿潤、シャーベット、凍結、積雪）とするため、合計 12 次元の特徴量となり、次式で表される。

$$z = [p_{image}^1, \dots, p_{image}^k, p_{road}^1, \dots, p_{road}^k]^T \in [0, 1]^{2k} \quad (3.2)$$

判別器 3 には Random Forest [60] を採用した。Random Forest は、複数の決定木を学習し、それらの予測を平均化して出力するアンサンブル学習器である。Random Forest が出力するクラス  $k$  の確率を  $p_{fusion}^k = \hat{p}(y = k | z)$  とおくと、 $B$  本の木からなる Random Forest は、各木の葉領域  $R_{b,m}$  に属したサンプルに対して定義されるクラス確率  $q_{b,m}(k)$  を

用い、入力  $z$  に対するクラス  $k$  の確率を推定する．その推定式を式 (3.3) に示す．

$$\hat{p}(y = k | z) = \frac{1}{B} \sum_{b=1}^B \sum_{m=1}^{M_b} \mathbf{1}\{z \in R_{b,m}\} q_{b,m}(k) \quad (3.3)$$

ここで、 $\mathbf{1}\{\cdot\}$  は指示関数であり、 $M_b$  は木  $b$  の葉数である．最終的な路面状態  $L$  は、この確率  $p_{fusion}^k$  に基づき、式 (3.1) により決定される．

本研究における判別器 3 の課題は、実環境においてモダルごとの出力信頼度が状況により変動する中で、2 系統の路面状態確率を状況に応じて適切に統合し、最終的な路面状態を安定して判別することである．この課題を解くためには、確率入力の組み合わせに応じて参照すべきモダルを切り替えられるような非線形な条件分岐の表現力と、学習データのばらつきに過度に影響されにくい汎化性能が必要となる．Random Forest は、多数の決定木による領域分割を通じて、2 系統の確率入力間の非線形な相互作用を条件分岐として表現しやすい．例えば、夜間に対向車線のヘッドライトが入射して路面が観測しにくい場合や、降雪によってカメラが雪に覆われた場合には、画像判別器の出力が不安定になりやすく、路面接触系判別器の確率を相対的に重視するような統合規則を領域分割として学習できる．反対に、信号機や交差点などで停止・発進が頻繁に発生する低速域では、接触系センサの S/N 比が低下して出力が不安定になるため、画像判別器の確率をより重視するようなルールを学習できる．さらに、ブートストラップと特徴サブサンプリングにより多様な木の判断を平均化できるため、一時的に不安定な確率出力に過度に引きずられにくく、実環境のばらつきに対して過学習を抑えやすい．このように、モダルごとの推定結果である路面状態確率を統合する Late Fusion は、実環境における観測条件の変動に対して性能の改善が期待できる．一方で、統合効果はデータの性質や前段モデルの出力特性に依存するため、3.4 節では判別器 3 に適用するアルゴリズムを複数比較し、実データに基づいて有効性を検証する．

### 3.3 実験

提案手法の有効性を確認するため、冬期の一般道において実車走行実験を行い、取得したデータを用いて評価を行った。本節では、まず 3.3.1 節で実験環境と計測方法、および正解ラベルの付与手順について述べる。次に 3.3.2 節で、取得データから学習・評価用データセットを構築するための前処理と分割方法を整理する。最後に 3.3.3 節で、提案手法の有効性を定量的に検証するための評価指標と評価手順を示す。

#### 3.3.1 実験データの取得方法

実験データは、2021 年 12 月から 2022 年 4 月までの期間、福島県会津若松市の市街地を週に 3~4 日程度走行した。また、走行時間帯は、路面温度が低下して凍結が発生しやすくなるなど、シビアな路面環境が出現しやすい夜間の時間帯を選択した。

実験車両として乗用車に計測用 PC を搭載し、車両前方の画像データと、CAIS システムからリアルタイムに出力される路面接触系センサの中間特徴量を記録した。なお、画像と接触系データは、タイヤ 1 回転ごとの算出周期と同期して記録するように実装している。路面状態の分類は、先行研究に基づき [15]、道路管理で用いられる指標も参考にして、「乾燥」「半湿」「湿潤」「シャーベット」「凍結」「積雪」の 6 種類とした。正解ラベルの路面状態は、車両の助手席搭乗者が、走行中の車線の路面状態を表 1 に示す判定基準に基づき、専用の自作入力アプリケーションを用いて目視で記録した。計測車両の外観と車内の計測システムを図 6 に示す。さらに、データセットの例を図 7 に示す。



図 6: 実験車両の外観と車内の計測システム




(a) 乾燥



(b) 半湿



(c) 湿潤



(d) シヤーベット



(e) 凍結



(f) 積雪

図 7: データセットの例

|              | 45%                            | 45%                            | 10%       |
|--------------|--------------------------------|--------------------------------|-----------|
| 画像           | 分類器 1 用学習データ<br>(うち20%=検証用)    | 分類器 3 用学習データ<br>(k-分割交差検証 k=5) | 評価<br>データ |
| 路面接触系<br>データ | 分類器 2 用学習データ<br>(k-分割交差検証 k=5) |                                |           |

図 8: データの分割方法

### 3.3.2 データの前処理

データ収集後、まず目視確認により明らかな路面状態のラベル入力ミスが含まれるデータを除外した。次に、一般道での走行を対象とするため、データセットの車速条件を絞り込んだ。一般道の法定速度である 60 km/h を上限とし、また生活道路における規制速度であるゾーン 30 [115] を考慮し、実質的な走行速度の下限として 30 km/h を設定した。この条件で抽出したデータから、6 種類の路面状態ごとに均等に 6,000 件、合計 36,000 件のデータセットを構築した。構築したデータセットの分割方法を図 8 に示す。まず、データ全体を 9:1 の割合で学習データ (32,400 件) と評価データ (3,600 件) に分割した。次に、学習データを「判別器 1・2 の学習用データ (45%)」と「判別器 3 の学習用データ (45%)」に分割した。このように判別器 3 の学習データを独立させた理由は、判別器 3 の学習時に説明変数 (判別器 1・2 の出力) へ正解ラベルの情報が間接的に漏洩することを回避するためである。もし判別器 1・2 の学習に使用したデータとその正解ラベルをそのまま判別器 3 の学習にも用いると、判別器 1・2 の出力に正解ラベルの情報が反映されてしまい、判別器 3 が過学習を起し、適切な汎化性能が評価できなくなる懸念があるためである。また、それぞれの学習データは、さらにそのうち 8 割をモデルの学習に、残りの 2 割をモデルの選択やハイパーパラメータのチューニングに使用した。特に、判別器 2 (LightGBM) と判別器 3 (Random Forest) の学習・検証においては、k-分割交差検証 ( $k = 5$ ) を用いて過学習を回避し、汎化性能を高める工夫を施した。

### 3.3.3 評価方法

提案手法の有効性を評価するため、3.3.2 節で準備した 3,600 件の評価データを用いて、2 つのステップによる検証を行った。評価指標としては、Recall (再現率)、Precision (適合率)、および両者の調和平均である F-measure (F 値) を採用した。各指標の算出式を式 (3.4)-式 (3.6) に示す。

$$\text{Recall} = \frac{\text{Num. of correctly estimated road conditions in the class}}{\text{Num. of road conditions in the class}} \quad (3.4)$$

$$\text{Precision} = \frac{\text{Num. of correctly estimated road surface}}{\text{Num. of estimated road surface in the class}} \quad (3.5)$$

$$\text{F-measure} = \frac{2 \times \text{Recall} \times \text{Precision}}{\text{Recall} + \text{Precision}} \quad (3.6)$$

また、各判別器のハイパーパラメータは、それぞれ k-分割交差検証を用いて最も F-measure が高くなるものを選択した。

## 3.4 実験結果

本節では、前節で構築した Late Fusion 型マルチモーダル判別手法について、冬期一般道走行データを用いた評価結果を示す。まず判別器 3 に適用するアルゴリズムの違いによる性能差を比較し、続いて単一モーダルである判別器 1・2 と Late Fusion 判別器 3 の精度を F-measure などの指標および混同行列に基づいて詳細に分析し、最後に判別器 1・2 の得意データ比率が Late Fusion による精度向上に与える影響について考察する。

### 3.4.1 Late Fusion 判別器に適用するアルゴリズムの評価

提案手法の要である判別器 3 (Late Fusion) において、Random Forest を採用したことの妥当性、および提案するフレームワーク自体のロバスト性 (頑健性) を評価するため、判別器 3 に適用するアルゴリズムを複数比較した。

比較対象として、Random Forest の他に、ロジスティック回帰 (Logistic Regression) [116]、サポートベクターマシン (SVM) [88]、Extreme Learning Machine (ELM) [117]、ニューラルネットワーク (Neural Network) [118]、および判別器 2 でも用いた LightGBM の、合計 6 種類の一般的な機械学習判別器を用いた。各アルゴリズムを判別器 3 に適用した際の各路面および全路面の平均の F-measure を表 2 に示す。表 2 から、F-measure の全路面平均値は、いずれの判別器を用いた場合でも 0.76~0.77 程度と、非常に近い判別精度となった。これは、入力データを「路面状態確率」という共通の粒度に正規化・抽象化したことで、後段の機械学習アルゴリズムの種類によらず、扱いやすい情報になっていることを示唆している。この結果から、提案する Late Fusion のフレームワーク自体が、特定のアルゴリズムに依存しないロバストな構成であることが確認された。その中でも、提案手法として採用した Random Forest が、F-measure の平均値において 0.777 と最も高い精度を示した。

### 3.4.2 Late Fusion 前の判別器と Late Fusion 判別器の比較

次に、Late Fusion 判別器の導入効果を測るため、画像と路面接触系データそれぞれ単体の判別器と Late Fusion 判別器の精度を比較する。より詳細に分析するため、評価指標として F-measure に加えて Recall と Precision を採用した結果を表 3 に示す。表 3 より、全路面において Late Fusion である判別器 3 の F-measure が判別器 1・2 のそれをすべて上回っていることが確認できる。特に、半湿と湿潤、シャーベット、凍結路面の F-measure が判別器 1 に比べても大きく増加していることが分かる。また、Recall, Precision については、大

表 2: 各モデルの判別精度

| モデル                 | 乾燥           | 半湿           | 湿潤           | シャーベット       | 凍結           | 積雪           | 平均           |
|---------------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|
| Random Forest       | 0.834        | 0.708        | 0.765        | <b>0.795</b> | <b>0.742</b> | 0.815        | <b>0.777</b> |
| Logistic Regression | 0.823        | 0.673        | 0.733        | 0.786        | 0.732        | 0.812        | 0.760        |
| SVM                 | 0.829        | 0.688        | 0.738        | 0.781        | 0.728        | 0.806        | 0.762        |
| ELM                 | <b>0.835</b> | 0.700        | 0.747        | 0.786        | 0.732        | 0.804        | 0.767        |
| Neural Network      | 0.833        | 0.687        | 0.747        | 0.779        | 0.728        | 0.802        | 0.763        |
| LightGBM            | 0.834        | <b>0.711</b> | <b>0.767</b> | 0.787        | 0.735        | <b>0.817</b> | 0.775        |

表 3: Late Fusion 前後での路面状態判別精度

| 判別器                     | 指標        | 乾燥           | 半湿           | 湿潤           | シャーベット       | 凍結           | 積雪           | 平均           |
|-------------------------|-----------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|
| 判別器 1<br>画像             | recall    | <b>0.848</b> | 0.545        | 0.645        | 0.682        | 0.788        | 0.788        | 0.716        |
|                         | precision | 0.767        | <b>0.758</b> | 0.727        | 0.726        | 0.580        | 0.815        | 0.725        |
|                         | F-measure | 0.805        | 0.627        | 0.684        | 0.705        | 0.668        | 0.800        | 0.715        |
| 判別器 2<br>路面接触系<br>センサ   | recall    | 0.618        | 0.460        | 0.570        | 0.770        | 0.625        | 0.450        | 0.582        |
|                         | precision | 0.719        | 0.543        | 0.510        | 0.591        | 0.547        | 0.616        | 0.588        |
|                         | F-measure | 0.665        | 0.498        | 0.538        | 0.669        | 0.584        | 0.520        | 0.579        |
| 判別器 3<br>Late<br>Fusion | recall    | 0.835        | <b>0.687</b> | <b>0.755</b> | <b>0.817</b> | 0.772        | <b>0.795</b> | <b>0.777</b> |
|                         | precision | <b>0.834</b> | 0.730        | <b>0.774</b> | <b>0.775</b> | <b>0.715</b> | <b>0.837</b> | <b>0.778</b> |
|                         | F-measure | <b>0.834</b> | <b>0.708</b> | <b>0.765</b> | <b>0.795</b> | <b>0.742</b> | <b>0.815</b> | <b>0.777</b> |

半の路面において判別器 3 の方が高いが、乾燥と凍結路面の Recall と半湿路面の Precision だけは判別器 1 の方が高い。これらは判別器 1 の Precision と Recall がアンバランスなためである。例えば判別器 1 の凍結路面の Recall は 0.788 と高いが Precision は 0.580 と低い。一方で判別器 3 の同路面は Recall が 0.772 で Precision が 0.715 となり共に高い精度を示している。したがって、判別器 3 の導入により一部の Recall または Precision が減少しているものの、全路面の F-measure が上昇していることから、本手法はすべての路面でバランス良く精度が向上したといえる。

次に、この手法が画像と路面接触系センサの互いの利点を活かして精度が向上しているかどうかを評価する。図 9 は、判別器 1・2 の評価データにおける判別正誤の数をグラフで示したものである。グラフは路面毎に、両判別器が正しく判別した数、それぞれ片方の判別器だけが正しく判別した数、どちらも正しく判別できなかった数を集計している。このグラフより、どの路面においてもどちらかの判別器でしか正しく判別できない路面が一定数存在しており、片方の判別器だけでは不十分なことが分かる。また、路面接触系センサ




図 9: Late Fusion 前の判別器の路面状態判別正誤の数

を用いる判別器 2 のみが正解した割合に焦点を当てると、乾燥と積雪路面の数値が小さく、それに比べてその他の水や氷に起因する路面の数値が大きい。これは、乾燥と積雪路面が画像単体で路面判別がしやすい一方で、それ以外の路面は画像だけの判別が難しく、路面接触系のセンサの情報が有効であることを示している。乾燥路面は路上に堆積物がないこと、積雪路面は雪の白さという視覚情報によって判断できるため画像の情報から判別しやすいが、残りの路面は視覚情報としての差が小さいため、このような傾向を示していると考えられる。


表 4 は図 9 で示した判別器 1・2 の判別正誤の数が判別器 3 を導入することでどれだけ変化したかを路面状態ごとに  $2 \times 2$  の行列で表したものである。各行列の左下の成分が、単一の判別器では不正解だったものが判別器 3 により正解になった数で、右上の成分が逆に正解だったものが不正解になった数である。したがって、左下の成分が大きく右上の成分が小さいほど、その路面の判別精度が大きく向上したことになる。判別器 1 を起点に見た際、乾燥と積雪路面に大きな正解数の変化が無い一方で、半湿と湿潤、シャーベット路面で正解数が大きく増加しており、判別器 2 を起点に見た際はすべての路面で正解数が大きく増加していることから、画像と路面接触系センサの利点を互いに活かした判別器が構成できたことが確認できた。なお、凍結路面の正解数は減少しているが、これは判別器 1 の Recall が高いためであり、表 3 より F-measure は大きく増加しているので問題ないといえる。これは乾燥路面においても同様である。

最後に、各判別器の混同行列を図 10 に示す。冬期の道路管理において、シャーベットや凍結、積雪路面への対応はもちろんのこと、路面に水分があるとそれが後に凍結することから、半湿や湿潤路面も対策を取る必要があり、逆に対策が不要な路面は乾燥路面だけ


表 4: Late Fusion 前後での各路面状態判別正誤の数

|                       |     | 判別器 3 Late Fusion |     |     |     |     |     |        |     |     |     |     |     |
|-----------------------|-----|-------------------|-----|-----|-----|-----|-----|--------|-----|-----|-----|-----|-----|
|                       |     | 乾燥                |     | 半湿  |     | 湿潤  |     | シャーベット |     | 凍結  |     | 積雪  |     |
|                       |     | 正解                | 不正解 | 正解  | 不正解 | 正解  | 不正解 | 正解     | 不正解 | 正解  | 不正解 | 正解  | 不正解 |
| 判別器 1<br>画像           | 正解  | 482               | 27  | 313 | 14  | 371 | 16  | 398    | 11  | 432 | 41  | 453 | 20  |
|                       | 不正解 | 19                | 72  | 99  | 174 | 82  | 131 | 92     | 99  | 31  | 96  | 24  | 10  |
| 判別器 2<br>路面接触系<br>センサ | 正解  | 360               | 11  | 229 | 47  | 319 | 23  | 422    | 40  | 333 | 42  | 250 | 20  |
|                       | 不正解 | 141               | 88  | 183 | 141 | 134 | 124 | 68     | 70  | 130 | 95  | 227 | 10  |


である。したがって、乾燥路面以外を乾燥路面と判別することを避けることが重要である [119]。よって、本手法の道路管理の現場への活用においては、図 10 の赤枠で囲った範囲の合計件数が小さいほど良く、判別器 1 が 155 件、判別器 2 が 145 件であったのに対し、判別器 3 では 100 件となり約 1/3 減少することができた。ただし、この数は乾燥路面をすべて乾燥路面以外と判別することでも減らせるが、それでは道路管理の効率性に悪影響を与えてしまう。そこで、乾燥路面を乾燥路面以外と判別した数（図 10 の黒枠）を確認すると、判別器 1 は 91 件であるのに対し、判別器 3 は 99 件であることから、わずかな増加に留まっている。よって、対策が不要な乾燥路面をその他の対策が必要な路面状態と誤判別することにより道路管理の効率性に悪影響を与えることを防げていることが確認できた。



(a) 判別器 1：画像



(b) 判別器 2：路面接触系センサ



(c) 判別器 3：Late Fusion

図 10: 各判別器の混同行列

表 5: 判別器 1・2 の得意データ ( $X, Y$ ) の割合

| データ    | $X$ (判別器 1 のみ正解) | $Y$ (判別器 2 のみ正解) |
|--------|------------------|------------------|
| 学習データ  | 68%              | 32%              |
| テストデータ | 75%              | 25%              |

### 3.4.3 判別器 1・2 の得意データ比率が Late Fusion に与える影響に関する考察

本章では、情報源の異なる 2 系統のセンサを併用し、誤判別が同時に生じにくい情報を統合することで、路面状態判別の頑健性を向上させ、精度改善を目指した。しかし、Late Fusion による精度向上は常に保証されるものではなく、判別器 1 と判別器 2 のいずれか一方が誤り、他方が正しく判別できるデータの構成比、すなわち片方にとって苦手であり、もう片方にとって得意なデータの比率に応じて、判別精度が変動しうる。

ここで、評価データにおいて  $X$  を判別器 1 (画像) が得意なデータ、すなわち「判別器 1 が正しく判別し、判別器 2 が誤判別するデータ」、 $Y$  を判別器 2 (路面接触系センサ) が得意なデータ、すなわち「判別器 2 が正しく判別し、判別器 1 が誤判別するデータ」と定義する。なお、 $X$  と  $Y$  は、一方が正解で他方が誤判別するデータに限定した集合であり、両判別器がともに正解、または誤判別するデータは  $X + Y$  には含まれない。以降の比率  $X/(X + Y)$  は、前段 2 判別器の誤りが相補的に現れる度合いを表す指標として用いる。Late Fusion 判別器 (判別器 3) は、判別器 1・2 の出力確率を入力として学習するため、学習時に観測した  $X$  と  $Y$  の構成比を前提に、両判別器のどちらを相対的に重視するかを決める規則を獲得する。このため、適用対象における  $X$  と  $Y$  の比率が学習時と大きく異なる場合、獲得した規則が適用対象に合致しにくくなり、精度が低下する可能性がある。

本研究で用いたデータセットにおける  $X$  と  $Y$  の割合を表 5 に示す。ただし、表の数値だけから「学習時とテスト時の比率が十分に近いか」を厳密に判断することは難しい。そこで、テストデータにおける  $X$  と  $Y$  の混合比を意図的に変化させた適用対象を構成し、学習・テスト時の比率が Late Fusion による精度向上が期待できる範囲に含まれているかを、判別結果に基づいて確認する。

具体的には、テストデータから  $X$  と  $Y$  に該当するデータのみを抽出し、混合比  $X/(X + Y)$  を変化させた複数の適用対象を構成して判別を行った。その結果を図 11 に示す。図より、 $X/(X + Y)$  が極端に大きく、または小さくなると Late Fusion によってかえって精度が低下する領域が存在する一方で、中間的な混合比では各判別器の得意領域を補完し合い、頑健性向上に寄与していることが分かる。具体的には、図 11 において判別器 3 が判別器 1 および 2 を上回る混合比の範囲を、実運用においても Late Fusion による精度向上が見込みやすい領域として捉えることができる。表 5 より本研究の学習データでは  $X/(X + Y) = 0.68$ 、テストデータでは  $X/(X + Y) = 0.75$  であり、いずれも当該領域に含まれている。したがって、少なくとも  $X$  と  $Y$  の構成比の観点では、学習時に獲得した統合規則がテスト時に大きくミスマッチする状況ではなく、本章で示した Late Fusion の精度改善が得られる条件の一




図 11:  $X$  と  $Y$  の割合変化が推定精度に与える影響

つを満たしていると考えられる。

以上より、マルチモーダルによる統合は情報量の増加によって一般に精度改善の可能性を持つ一方で、適用環境における得意データ比率の変化が推定精度に影響しうる点に留意が必要である。今後の課題として、運用時に  $X$  と  $Y$  の比率が学習時から乖離していないかを監視・検知する仕組みや、状況に応じて Late Fusion をせずに得意な判別器のみの利用に切り替える手法などを導入することで、さらなる頑健性向上が期待できる。

### 3.5 まとめ

本章では、複数の車載センサのデータを統合して冬期の路面状態を判別するための手法を提案した。提案手法は、路面非接触系センサと路面接触系センサそれぞれから路面状態を判別する2つの判別器に加え、それらの出力を統合するLate Fusion判別器によって構成される。Late Fusion判別器は、一般的な機械学習判別器のいずれを用いても高い精度を示し、提案手法の構成がロバストであることが確認された。その中でもRandom Forestが最も精度の高い判別器となった。また、評価指標であるF-measureが個別の判別器のそれをすべての路面で上回り、その有効性が確認できた。加えて、各路面の判別結果から、Late Fusion判別器が画像と路面接触系センサの利点を互いに活かしていることが確認された。さらに、冬期の道路管理において対策が不要な乾燥路面を、その他の対策が必要な路面状態と誤判別して道路管理の効率性に悪影響を与えることは抑えながら、個別の判別器では見逃してしまうような対策すべき路面状態の約1/3を正しく判別できるようになることが分かった。以上より、本章で提案したマルチモーダル路面状態判別機は、冬期道路管理における凍結防止剤散布や除雪作業の高度化、限られた維持管理資源の効率的配分、および冬期道路交通安全性向上への貢献が期待できるといえる。

## 第4章 学習と異なる環境での精度低下を抑制するためのラベル訂正

本章では、第3章で構築した冬期路面状態モニタリング向けのマルチモーダル判別機のうち、従来の人間の目視による路面モニタリングを直接代替する方法として有力である、車載カメラで動作する高速道路環境で学習された路面状態判別器に着目し、その学習環境外への適用について検討する。高速道路（学習環境）と高速道路以外の道路環境（学習環境外）とでは、路面の舗装の違い [120] による色や排水性能から来るテクスチャや路面に現れる道路標示・カラー舗装・周辺景観、さらには修理方法などが異なるため、学習時に想定していない環境に判別器をそのまま適用すると、深層学習モデル特有のドメインシフトにより判別精度が低下する可能性がある。本章では、このような学習環境差が冬期路面状態モニタリングの精度に与える影響を定量的に評価するとともに、追加の再学習を行うことなく、学習環境外で得られるラベルなしデータを活用して判別結果を自動的に訂正し、精度低下を抑制する枠組みを検討する。

本章ではまず、4.1 節で本章で扱う課題設定と、高速道路環境で学習した判別器を学習環境外へ展開する際の問題意識を整理する。4.2 節では、高速道路環境で学習された車載カメラ判別器を学習環境外へ適用した際に生じる精度劣化の実態を示す。続く 4.3 節では、判別器の出力する確信度と中間特徴量空間内での近傍関係に基づき、危険側路面の見逃しを抑えつつ誤判別を訂正するラベル訂正手法のアルゴリズムを記す。4.4 節では、北海道の一般国道で撮影した路面画像を用いた検証実験の条件および評価指標を示し、4.5 節で提案手法と比較手法との比較結果から、冬期の学習環境外における安全側・危険側の誤判別に与える影響を含めて本手法の有効性と限界を議論する。最後に 4.6 節で、本章で得られた知見を総括する。

### 4.1 はじめに

第3章までにおいて、非接触センサである車載カメラと、接触系センサであるタイヤ内加速度センサの情報を深層学習判別器で統合（Late Fusion）する手法について論じた。しかし、構築した Late Fusion 判別器に含まれるタイヤ内加速度センサは導入コストが高く、高速道路のような範囲が限定されている場合は良いが、高速道路以外の道路網は総延長が圧倒的に長く [121]、広く展開するには現実的ではない。そのため、現在多くの車両にドライブレコーダーやスマートフォン、あるいは ADAS 用のカメラといった形で搭載されているカメラを用いた判別器の適用を検討する必要がある。

そこで本章では、車載カメラを用いた路面状態判別器を異なる道路環境に展開するという課題に取り組む。具体的には、すでにある高速道路データで学習された車載カメラ画像に基づく判別器を、学習時と環境が異なる道路環境へ適用する際に生じる判別精度の低

下 [122], いわゆるドメインシフトの問題 [103] に焦点を当てる. 本章では学習環境外の代表例として, 北海道の一般国道 (R232 (留萌～天塩), R40 (天塩～士別)) で取得したデータを用いる.

一般国道は, 高規格道路である高速道路と舗装が異なるため, 排水性能 [123] や路面の色が異なる. また, 停止線, 横断歩道, 多様な道路標示, カラー舗装 [124] など, カメラ画像に映り込む視覚的ノイズが多い. また, 低速走行による車間距離の短縮による前方車両による路面の隠れなど走行パターンの違いも, 高速道路のデータ分布とは異なる特徴である.

このドメインシフト問題に対する最も直接的な解決策は, 一般国道をはじめとする学習環境外のデータを大量に収集し, 人手で正確な路面状態のラベルを付与したデータセットを構築し, 判別器を再学習または微調整 (Fine-tuning) [104] することである. しかし, 高速道路以外の道路網は高速道路に比べて総延長が圧倒的に長く [121], 前述のとおり環境の多様性も非常に大きい. そのため, 都市部, 郊外, 山道など, 地域や道路特性ごとに判別器を構築する必要が生じる可能性があり, そのための網羅的なデータ収集とラベル付けは, コストと時間の面で現実的ではない.

そこで本章では, 学習済みの高速道路環境用判別器を再学習することなく, その判別結果を後処理によって自動で訂正し, 学習環境外の路面データに対する判別精度の低下を抑制する手法を提案する. 提案手法は, 判別器が自身の出力に対して示す「確信度」に着目する. 確信度が低い, すなわち判別器が迷っていると判断されたデータのみを訂正対象とし, 判別器の中間層から得られる特徴ベクトル空間内での近傍関係を利用して, より確からしいラベルへと修正する.

本手法の最大の利点は, 訂正処理の参照データとして用いる学習環境外のデータ群に, 人手による正解ラベルを必要としない点にある. これは, ラベルなしデータのためのターゲットドメイン (学習環境外の路面) へ, ラベル付きデータが豊富なソースドメイン (学習環境の路面) の判別器を適応させる, ドメイン適応 [103] の一形態と捉えることができる.

## 4.2 学習環境差による精度低下の検証

これまで提案されてきた路面状態判別手法の多くは機械学習が用いられている. 機械学習は, 計算パラメータをデータから自動的に学習するため, その精度は学習データに強く依存する. 特に近年発展した深層学習は複雑な非線形関係を表現できるため高い判別精度を示す一方, 学習時に存在しない範囲のデータでは判別精度が低下することが知られている [122]. これを確認するため, その一例として実際に先行研究 [41] で用いられた高速道路用の路面状態判別器で, 学習環境以外の環境である一般道データの路面状態を判別した. この判別器は路面画像を表 1 に例を示した 6 種の路面状態 (乾燥, 半湿, 湿潤, シャーベット, 凍結, 積雪) に判別する. データは 2022 年 10 月から 2023 年 3 月の間, 北海道の一般国道 R232 (留萌～天塩) と R40 (天塩～士別) を走行した車両の車載カメラで撮影した日中の路面画像を用いた. 判別された路面状態ごとに 1,000 件ずつ抽出したデータに対し,

表 6: 高速道路用の判別器による路面状態判別精度：一般国道画像と高速道路画像の比較

| 対象画像 | 指標        | 乾燥   | 半湿   | 湿潤   | シャーベット | 凍結   | 積雪   | 平均   |
|------|-----------|------|------|------|--------|------|------|------|
| 一般国道 | Recall    | 0.53 | 0.44 | 0.61 | 0.67   | 0.72 | 0.84 | 0.64 |
|      | Precision | 0.55 | 0.58 | 0.79 | 0.82   | 0.57 | 0.30 | 0.60 |
|      | F-measure | 0.54 | 0.50 | 0.69 | 0.74   | 0.64 | 0.45 | 0.59 |
| 高速道路 | Recall    | 0.85 | 0.55 | 0.65 | 0.68   | 0.79 | 0.79 | 0.72 |
|      | Precision | 0.77 | 0.74 | 0.73 | 0.73   | 0.58 | 0.81 | 0.73 |
|      | F-measure | 0.81 | 0.63 | 0.68 | 0.70   | 0.67 | 0.80 | 0.72 |

下式で計算される 3 つの指標を集計した結果と、同じ判別器で高速道路の路面画像を判別した結果を表 6 に示す。

$$\text{Recall} = \frac{\text{Num. of correctly estimated road conditions in the class}}{\text{Num. of road conditions in the class}} \quad (4.1)$$

$$\text{Precision} = \frac{\text{Num. of correctly estimated road surface}}{\text{Num. of estimated road surface in the class}} \quad (4.2)$$

$$\text{F-measure} = \frac{2 \times \text{Recall} \times \text{Precision}}{\text{Recall} + \text{Precision}} \quad (4.3)$$

表 6 より、この判別器が高速道路の路面状態を判別した際の各指標の平均は 0.7 を超えていたのに対し、一般国道データに対する判別精度は各指標とも約 0.6 であり、実際に大幅な精度の低下が確認された。

この精度低下を解決するための最も単純な方法は、一般道データセットを新たに構築し、路面状態判別器を再学習することである。しかし、データセットの構築のためには、データの収集だけでなく正解の路面状態をラベル付けする必要がある、その作業に多くの人件費と時間が必要となる。そして、一般道は多種多様な道路標示や歩行者、自転車用のカラー舗装 [124]、横断歩道などにより多様な路面が存在するため、高速道路よりも多くのデータを収集する必要がある、より多くのラベル付けのコストが要求される。

また、都市部、郊外、山道、峠道など地点による路面の差も高速道路より大きいと考えられるため、ある地域の一般道データセットで学習した判別器が、他の地域の一般道で有効でない可能性が高く、そのため地域ごとに判別器を構築する必要がある。しかし、高速道路以外の道路網は総延長が長く、地域ごとに判別器を構築することは現実的でない。そのため、すでにある判別器を使って、学習環境外での精度低下を抑えた路面状態判別ができる方法が求められる。

そこで本章では、既存の判別器を使って路面状態を判別した後、必要に応じて結果を訂正する方法を提案する。この方法では、参照データとして判別したい路面環境で収集したデータ群を必要とするものの、それらの路面状態のラベル付けを必要としない。その代わ

り、すでにある高速道路環境で学習した判別器の判別結果で擬似ラベル付けを行う。そして、判別したい路面の判別結果を訂正する際に、その路面の近傍データを参照データから複数抽出し、抽出したデータの擬似ラベルで最多のものを訂正先とするものである。

本手法を検証するために、表 6 でも利用した、冬期の高速道路の路面画像を学習対象とした深層学習による路面状態判別器 [41] を使う。路面画像を使った判別器を対象とした理由は、人間による視覚的なモニタリングを直接代替する手段であること、また広域網のモニタリングに対応するにはより安価な方法で判別できるようにする必要があるため、ドライブレコーダーやスマートフォンなど、既に多くの車両に搭載されているセンサを活用できる点が有効と考えたからである。学習環境外の環境として一般国道を用いる中で、一般国道の路面状態を何種類に分類するかは議論が必要であるが、本章では手法の有効性を確認するため、判別する路面状態は先行研究 [41] と揃えており、乾燥、半湿、湿潤、シャーベット、凍結、積雪の 6 路面に判別した。

### 4.3 冬期路面状態の判別結果の訂正手法

本節では、学習済みの路面状態判別器  $f$  を学習環境外の路面へそのまま適用した際に生じる誤判別を、再学習を行わずに後処理として訂正する枠組みを示す。提案手法の基本方針は、(i) 判別器の出力確信度に基づき「訂正が必要なデータのみ」を選別し、(ii) 判別器の中間特徴量空間内での近傍関係を用いて訂正先ラベルを決定する、という 2 段階の処理で構成される。このとき参照用データとして、学習環境外で収集したラベルなしデータ群を用い、擬似ラベルとして判別器  $f$  の判別結果を与える。また、交通安全上の観点から危険側路面を安全側へ訂正することを抑制する制約も併せて導入する。以下では、まず 4.3.1 節で全体像を述べた後、1 つ目の処理を 4.3.2 節で、2 つ目の処理を 4.3.3 節にて説明する。

#### 4.3.1 手法全体の概要

ここでは、学習済みの路面状態判別器を使って学習環境外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。

ある判別したい学習環境外のデータ  $\mathbf{x}$  に対して、学習済みの路面状態判別器  $f$  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 つの判断が必要となる。処理 1 は、判別器  $f$  が出力する路面状態の確信度  $c$  に対する閾値処理によって判別する。処理 2 は、事前に収集した学習環境外の参照用データ群  $\{\mathbf{x}_i^{ref}\}_{i=1}^n$  から、路面状態を判別対象のデータ  $\mathbf{x}$  の近傍データを  $k$  個抽出する。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。提案手法のフレームワークを図 12 に示し、以降で各処理の詳細を記す。




図 12: 提案手法のフレームワーク

#### 4.3.2 処理 1：判別結果 $L$ を訂正すべきか

学習済みの路面状態判別器  $f$  で判別した路面状態  $L$  を訂正すべきか判断するため、ここでは判別器  $f$  の出力として得られる路面状態の出力ベクトル  $\mathbf{p}$  を使う。一般的に、深層学習を使ったクラス判別器は、最終層の活性化関数にソフトマックス関数を使ってラベル数と同じ長さのベクトル  $\mathbf{p}$  を出力する。 $\mathbf{p}$  の各要素は各ラベルの確信度を表し、合計は 1 である。そして、 $\mathbf{p}$  の要素の最大値に対応したラベル  $L$  が判別結果となる。以上の関係を式で表すと下記の通りとなる。

$$L = \arg \max_k p^k \quad (4.4)$$

$$\sum_k p^k = 1 \quad (4.5)$$

$$k \in \{\text{乾燥, 半湿, 湿潤, シャーベット, 凍結, 積雪}\} \quad (4.6)$$

ここで、判別結果であるラベル  $L$  に対応した  $\mathbf{p}$  の要素を確信度  $c$  とおく。つまり、 $c$  は  $\mathbf{p}$  の要素の最大値である。

深層学習のクラス判別器において、このようなソフトマックス関数による出力の最大値は、誤判別しやすい入力や、学習時の分布から外れた入力を検出するための有効な指標として提案されている [125]。したがって本章でも、その知見を踏まえ、確信度  $c$  が低いデータほど誤判別の可能性が高いとみなし、 $c$  に対する閾値処理により、判別結果を訂正すべきか否かを決定する。

図 13、図 14 は一般国道の路面を高速道路で学習した判別器  $f$  で判別した際に、高い確信度  $c$  で乾燥路面と判別された路面と、低い確信度  $c$  で乾燥路面と判別された路面を比較したものである。低い確信度  $c$  で乾燥路面と判別された路面は、凍結路面や濡れた路面が多く混じっており、また乾燥路面も道路標示やカラー路面、横断歩道など高速道路にない要素が映っているものが多い。一方で、高い確信度  $c$  で乾燥路面と判定された路面は、そのような路面の混入が少なく、人間の目でも分かりやすい乾燥路面が多い。




図 13: 確信度  $c$  が 0.4 以上 0.5 未満で乾燥と判別された路面の例




図 14: 確信度  $c$  が 0.9 以上で乾燥と判別された路面の例




図 15: 高速道路用判別器で一般国道のデータを乾燥路面と判別した際の Precision と確信度  $c$  の関係

そこで、確信度  $c$  と精度の関係を定量的に確認するため、乾燥路面と判別されたデータについて、確信度  $c$  を 0.1 ごとに区切って 100 件ずつ抽出して Precision を計算した結果を図 15 に示す。この場合の Precision は、乾燥路面と判別された中で実際に乾燥路面であった割合である。図 15 より、確かに確信度  $c$  が小さくなるほど Precision が小さくなることから、確信度  $c$  は路面状態の判別にどれだけ自信があるかを示す指標といえる。そこで、先行研究 [125] と同様に閾値  $\theta$  を設け、判別された路面状態の確信度  $c$  がその閾値  $\theta$  を下回った場合は、誤判別だった可能性が高いとみなし、路面状態  $L$  を訂正すべきだと判断する。

この判断方法を別の観点で検証する。図 16 は、一般国道の路面を高速道路で学習した路面状態判別器  $f$  で判別した際に、計算途中で得られる中間特徴量  $\mathbf{h}$  を 2 次元に次元削減し、判別された路面状態ごとにプロットした散布図である。この次元削減は提案手法に含まれるものではなく、あくまでデータを可視化して解釈するために行うものである。次元削減の方法には、高次元データを低次元で可視化するための代表的な手法である t-SNE [126] を使用した。t-SNE の計算のために各路面状態ごとに 9,000 件ずつデータを用意しており、そのすべてを図 16 にプロットしている。高速道路用の路面状態判別器  $f$  は先行研究 [41] のものを利用しているが、これは軽量の畳み込みニューラルネットワークとして代表的な MobileNet [58] をベースにしている。判別器  $f$  は、MobileNet の最終層である 1024 次元のベクトルを全結合層と活性化関数である ReLU で 32 次元のベクトルに変換した後、全結合層によって路面状態の数である 6 次元のベクトルに変換し、最後にソフトマックス関数で出力ベクトル  $\mathbf{p}$  を計算している。今回 t-SNE で次元削減した中間特徴量  $\mathbf{h}$  は、上記の 32 次元のベクトルであり、 $\mathbf{h}$  のベクトル空間を  $\mathcal{H}$  とおく。

図 16 では、各路面状態が同じ箇所に集まりクラスターを形成していることが分かる。また、凍結路面と湿潤路面の間にシャーベット路面が位置し、乾燥路面と湿潤路面の間に半湿路面が位置しており、それぞれの路面状態同士の物理的な特徴の関係性が、クラスター同士の位置関係として適切に表現されている。したがって、高速道路用の判別器  $f$  は一般国道のデータに対して判別精度の低下を起こすとはいえ、路面状態の特徴抽出を一定程度できていることが分かる。

図 17 は、図 16 の乾燥路面と判別されたデータのみ、確信度  $c$  に応じてグレースケールで表現しなおした図であり、確信度  $c$  が高い路面ほど濃くなるよう表現している。図 17 から、確信度  $c$  の低いデータは路面状態のクラスターの境界に集中していることが分かる。同様にその他の路面状態についても確信度  $c$  をグレースケールで表現したものを図 18-図 22 に示す。これらの図より、路面状態によらず確信度  $c$  の低いデータがクラスターの境界に多く存在していることが分かる。路面状態判別器  $f$  はこの中間特徴量  $\mathbf{h}$  を使って路面状態を判別している以上、クラスターの境界に位置するデータは、どちらの路面状態かを判断することが判別器  $f$  にとって難しい状態であると解釈でき、この結果は判別結果を訂正するか否かの判断に確信度  $c$  を使う方針を支持するものである。




図 16: 一般国道の路面を高速道路用判別器で判別した際の間特徴量を二次元に次元削減した散布図




図 17: 図 16 の乾燥路面と判別されたデータのみ、確信度  $c$  に応じてグレースケールで表現しなおした図




図 18: 図 16 の半湿路面と判別されたデータのみ，確信度  $c$  に応じてグレースケールで表現しなおした図




図 19: 図 16 の湿潤路面と判別されたデータのみ，確信度  $c$  に応じてグレースケールで表現しなおした図




図 20: 図 16 のシャーベツト路面と判別されたデータのみ，確信度  $c$  に応じてグレースケールで表現しなおした図




図 21: 図 16 の凍結路面と判別されたデータのみ，確信度  $c$  に応じてグレースケールで表現しなおした図




図 22: 図 16 の積雪路面と判別されたデータのみ，確信度  $c$  に応じてグレースケールで表現しなおした図

#### 4.3.3 処理 2：どの路面状態に訂正するか

次に処理 1 で確信度  $c$  が閾値  $\theta$  を下回ったデータを対象として、どの路面状態に訂正するか（訂正先ラベル  $\hat{L}$ ）を決定する方法を記す．深層学習モデルは誤差逆伝播により入力から有用な中間表現を獲得することが知られている [38, 118]．また，ネットワークの途中の特徴量においてユークリッド距離を意味的類似度として扱う定式化は，類似度学習・検索の文脈で広く用いられている [127]．そこで本章では，4.3.2 節で可視化に用いた中間特徴量（t-SNE で次元削減する前の特徴量），すなわち判別器  $f$  の中間層から得られる特徴量  $\mathbf{h}$  を，路面状態を表す表現として用いる．そして，その特徴空間  $\mathcal{H}$  におけるユークリッド距離が小さいほど，路面状態が類似しているとみなす．このとき，確信度が低く判別が不安定なデータであっても， $\mathcal{H}$  内の近傍データを参照することで，近傍で多数を占める路面状態へ訂正できる可能性がある．

この方針は，図 17 に示した可視化結果とも整合する．すなわち，確信度  $c$  が低いデータは  $\mathcal{H}$  におけるクラスター境界付近に多く存在し，そのようなデータの訂正先は，境界を挟んで隣接するクラスターの路面状態になることが自然である．そこで， $\mathcal{H}$  における局所的な多数決により訂正先を決める方法として， $k$  近傍法アルゴリズム [61] を導入する．具体的には，訂正対象データの近傍  $k$  個を  $\mathcal{H}$  内のユークリッド距離で検索し，その  $k$  個のラベルの多数決を訂正先とする．

ただし本研究の設定では，参照用データは学習環境外で収集され，原則として真のラベルを付与しない．このため近傍のラベルとしては，高速道路用判別器  $f$  の推定結果を擬似ラベルとして用いる．擬似ラベルには誤りが含まれ得るが，局所近傍では同一（あるいは隣接）クラスが優勢となることが多いため，多数決によりノイズの影響を低減できる可能性がある．実際，人手で正解ラベルを付与したテストデータを用いた事前分析（4.2 節の精度評価で用いた一般国道データ）では，確信度  $c \leq 0.7$  のデータに対し近傍  $k = 10$  個の擬似ラベルを集計すると，正解ラベルと一致する近傍データ数の平均が 6.04 個となり，過半数（50%）を上回った．この結果は，本章で扱う冬期路面モニタリングのデータ条件において，低確信度データに対しても近傍多数決が訂正に有効に機能し得る可能性を示唆する．一方で，参照データの分布や擬似ラベルの誤り方によっては誤訂正が起こり得るため，常に正しく訂正できることを保証するものではない．

以上をまとめると，提案手法の処理 2 は，(i) 特徴空間  $\mathcal{H}$  で近傍  $k$  個を検索し，(ii) それらの擬似ラベルの多数決により訂正先を決定する，という枠組みである．

上記を数式で表す．まず，真の路面状態が不明な  $n$  件の学習環境外のデータで構成される参照用データ群  $\{\mathbf{x}_i^{\text{ref}}\}_{i=1}^n$  に対し，高速道路用の判別器  $f$  で計算される路面特徴量群を  $\{\mathbf{h}_i^{\text{ref}}\}_{i=1}^n$  とおく．路面状態を判別したい学習環境外のデータ  $\mathbf{x}$  と参照用データ  $\mathbf{x}_i^{\text{ref}}$  の路面特徴空間  $\mathcal{H}$  内のユークリッド距離  $d$  は以下の式で表される．

$$d(\mathbf{x}, \mathbf{x}_i^{\text{ref}}) = \|\mathbf{h} - \mathbf{h}_i^{\text{ref}}\| \quad (4.7)$$

この距離  $d$  を使い、参照用データ群  $\{\mathbf{x}_i^{\text{ref}}\}_{i=1}^n$  から  $\mathbf{x}$  の近傍データを  $k$  個抽出する.

$$\{\mathbf{x}_{i_1}^{\text{ref}}, \mathbf{x}_{i_2}^{\text{ref}}, \dots, \mathbf{x}_{i_k}^{\text{ref}}\} = \underset{\{i_1, i_2, \dots, i_k\}}{\operatorname{argmin}} d(\mathbf{x}, \mathbf{x}_i^{\text{ref}}) \quad (4.8)$$

次に、抽出した  $k$  個のデータの路面状態を高速道路用判別器  $f$  を使って得る.

$$\{L_{i_1}^{\text{ref}}, L_{i_2}^{\text{ref}}, \dots, L_{i_k}^{\text{ref}}\} = \{f(\mathbf{x}_{i_1}^{\text{ref}}), f(\mathbf{x}_{i_2}^{\text{ref}}), \dots, f(\mathbf{x}_{i_k}^{\text{ref}})\} \quad (4.9)$$

そして、各路面状態の個数を数え上げる.

$$\text{count}(L) = \sum_{j=1}^k \mathbf{1}(L_{i_j}^{\text{ref}} = L) \quad (4.10)$$

ただし、 $\mathbf{1}(L_{i_j}^{\text{ref}} = L)$  は指示関数であり、路面状態  $L_{i_j}^{\text{ref}}$  が  $L$  に等しい場合は 1、そうでない場合は 0 を返す.

最後に、訂正に対して 1 つの制約を加える. 通常の  $k$  近傍法アルゴリズムは  $k$  個の路面状態の中で最も多い路面状態を訂正結果として採用する. しかし、路面状態には安全側の路面状態と危険側の路面状態が存在し、ここでは危険側と判別されたものを安全側に訂正することはリスクの向上につながるため禁止したい. 今回の 6 種の路面状態の中で安全側の路面状態は乾燥路面のみで、残りは温度低下によりすべて凍結する可能性があるため危険側の路面状態である. そこで、訂正後の路面状態は危険側の 5 種の路面状態の中から最多のものを選択する. ただし、5 種の路面状態の数がすべて 0 の場合、すなわち  $k$  個の近傍データがすべて乾燥路面の場合は 5 種の中から路面状態を選択できないため、訂正を取りやめる. 以上を数式にすると、下記の通りとなる.

$$\hat{L} = \begin{cases} \underset{L \neq \text{乾燥}}{\operatorname{argmax}} \text{count}(L) & \text{if } \text{count}(\text{乾燥}) \neq k, \\ f(\mathbf{x}) & \text{if } \text{count}(\text{乾燥}) = k \end{cases} \quad (4.11)$$

このように、本手法は用途に応じて柔軟に訂正する対象を絞ることが可能である点が利点である.

## 4.4 実験の設定

本手法を、北海道の高速道路で学習された高速道路用の路面状態判別器 [41] と、2022 年 10 月から 2023 年 3 月までの間に、北海道の一般国道である R232 (留萌～天塩) と R40 (天塩～士別) を走行した車両の車載カメラで日中撮影した路面画像を用いて検証した. 具体的な走行ルートを図 23 に示す. また、この実験で使用した路面状態判別器は、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る.




図 23: 実験走行ルート

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国道の画像を 6,000 枚用意した。これらの画像は、高速道路用の判別器  $f$  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  $k = 10$  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、高速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。なお、閾値  $\theta$  と近傍データ数  $k$  は、実験的に変化させたうえで最も精度が高くなったものを採用している。

本手法に対して、2 つの手法を比較した。1 つ目は、高速道路用判別器  $f$  のみを使った場合、すなわち訂正前の判別結果（比較手法 1）である。2 つ目は、高速道路用判別器  $f$  で判別した結果、確信度  $c$  が低かった場合に、判別器  $f$  の出力ベクトル  $\mathbf{p}$  の要素が次点で大きい路面状態に訂正する手法（比較手法 2）である。なお、比較手法 2 も訂正基準となる確信

度  $c$  の閾値  $\theta$  を設定する必要があるため、提案手法と同じ 0.7 とした。

## 4.5 実験結果

本節では、提案するラベル訂正手法の有効性を実験的に検証する。まず、4.5.1 節で各手法の精度の比較と、危険側路面を安全側へ誤判別する件数への影響を示し、訂正が有効に働く代表例を提示する。続いて、4.5.2 節で、提案手法を構成する  $k$  近傍法による訂正と「危険側路面を安全側へ訂正しない」制約の寄与を切り分け、精度向上の要因を確認する。

### 4.5.1 提案手法の精度

表 7 は、各手法ごとに Precision, Recall, F-measure を集計した表である。路面状態の平均精度は、すべての指標で提案手法が最も高く、比較手法 2 が最も低かった。個別の路面状態の精度も、乾燥路面の Recall と湿潤路面の Precision を除き、提案手法が比較手法に対して同等以上の精度を示した。

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定の件数を提案手法と比較手法 1 で集計したものが表 8 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、本手法の有効性を確認することができた。

表 7: 提案手法と比較手法の精度

| 手法     | 指標        | 乾燥          | 半湿          | 湿潤          | シャーベット      | 凍結          | 積雪          | 平均          |
|--------|-----------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|
| 提案手法   | Recall    | 0.46        | <b>0.52</b> | <b>0.63</b> | <b>0.70</b> | 0.73        | <b>0.86</b> | <b>0.65</b> |
|        | Precision | <b>0.62</b> | 0.57        | 0.79        | <b>0.84</b> | <b>0.58</b> | <b>0.30</b> | <b>0.62</b> |
|        | F-measure | 0.53        | <b>0.54</b> | <b>0.70</b> | <b>0.76</b> | <b>0.65</b> | <b>0.45</b> | <b>0.61</b> |
| 比較手法 1 | Recall    | <b>0.53</b> | 0.44        | 0.61        | 0.67        | 0.72        | 0.84        | 0.64        |
|        | Precision | 0.55        | <b>0.58</b> | 0.79        | 0.82        | 0.57        | <b>0.30</b> | 0.60        |
|        | F-measure | <b>0.54</b> | 0.50        | 0.69        | 0.74        | 0.64        | <b>0.45</b> | 0.59        |
| 比較手法 2 | Recall    | 0.51        | 0.47        | 0.54        | 0.63        | 0.77        | 0.69        | 0.60        |
|        | Precision | 0.55        | 0.52        | <b>0.81</b> | 0.81        | 0.50        | <b>0.30</b> | 0.58        |
|        | F-measure | 0.53        | 0.49        | 0.65        | 0.71        | 0.61        | 0.42        | 0.57        |

表 8: 乾燥以外の路面状態を乾燥路面と間違えた数

| 真の路面状態 | 手法 1 | 提案手法 | 誤判定削減率     |
|--------|------|------|------------|
| 半湿     | 350  | 220  | <b>37%</b> |
| 湿潤     | 73   | 56   | <b>23%</b> |
| シャーベット | 2    | 1    | <b>50%</b> |
| 凍結     | 15   | 9    | <b>40%</b> |
| 積雪     | 13   | 4    | <b>69%</b> |

次に、高速道路用の路面状態判別機では誤判別したものが、本手法により正しく判別できるようになった実例を図 25-図 29 に示す。いずれの例も、人間の目には比較的容易に真のラベルが判別可能なケースのデータが、提案手法によって正しいラベルに訂正されていることが分かる。人間が比較的容易に真の路面状態を判別できるデータということは、それと同じ路面状態のデータ群が路面特徴量空間  $\mathcal{H}$  内の近傍に存在するということである。そのようなデータが高速道路用の路面状態判別機で誤判別されてしまうのは、高速道路データという限られたデータで最適化した判別境界線の限界によるものである。しかしその間違いは僅差であることから、その近傍に多く存在する同じ路面状態のデータは高速道路用の路面状態判別機でも正しく判別される可能性が十分にあり、その結果を参照することで正しい路面状態に訂正できていることが、結果から説明できる。



(a) 乾燥を半湿に訂正した例 1



(b) 乾燥を半湿に訂正した例 2

図 24: 誤判別されていた路面状態が正しく訂正された例 1



(a) 乾燥を湿潤に訂正した例 1



(b) 乾燥を湿潤に訂正した例 2

図 25: 誤判別されていた路面状態が正しく訂正された例 2



(a) 乾燥を積雪に訂正した例 1



(b) 乾燥を積雪に訂正した例 2

図 26: 誤判別されていた路面状態が正しく訂正された例 3



(a) 湿潤をシャーベットに訂正した例 1



(b) 湿潤をシャーベットに訂正した例 2

図 27: 誤判別されていた路面状態が正しく訂正された例 4



(a) 湿潤を半湿に訂正した例 1



(b) 湿潤を半湿に訂正した例 2

図 28: 誤判別されていた路面状態が正しく訂正された例 5



(a) 積雪を凍結に訂正した例 1



(b) 積雪を凍結に訂正した例 2

図 29: 誤判別されていた路面状態が正しく訂正された例 6

表 9: 各手法の危険側路面訂正の禁止をしない場合の精度比較

| 手法                    | Recall       | Precision    | F-measure    |
|-----------------------|--------------|--------------|--------------|
| (A) 高速道路用判別機          | 0.636        | 0.602        | 0.592        |
| (B) (A) + k 近傍法でラベル訂正 | 0.645        | 0.608        | 0.599        |
| (C) (B) + 危険側路面訂正禁止   | <b>0.651</b> | <b>0.619</b> | <b>0.606</b> |

#### 4.5.2 k 近傍法の効果の検証

最後に、提案手法は k 近傍法によるラベル変更の判断と、危険側路面へのラベル訂正を禁止する 2 つの判断の組み合わせで構成されるため、今回の精度向上がそのどちらか 1 つによってのみ達成されたわけではないことを確認した結果が表 9 である。表は、高速道路用判別機による判別と、それを提案手法の k 近傍法の結果のみを使ってラベル訂正したもの、それに加えて危険側路面訂正を禁止した上でラベル訂正したものの 3 つを比較しており、評価指標は各路面の Precision, Recall, F-measure の平均である。表より、k 近傍法のみの結果でも精度が向上し、さらに危険側路面の訂正を禁止することでも精度が向上していることが確認できた。

## 4.6 まとめ

本章では、学習済みの路面状態判別器を学習環境外へ適用する際に起きる判別精度の低下に対し、判別結果を訂正して精度を改善する手法を提案した。提案手法は、学習済みの路面状態判別器による判別結果を訂正してよいか（処理 1）、訂正してよい場合にどの路面状態に訂正するか（処理 2）の 2 つの処理で構成される。路面状態の訂正には、真の路面状態が不明な代わりに学習済みの路面状態判別器で擬似ラベル付けされた学習環境外のデータセットを参照する。この参照用データセットから、訂正したいデータの近傍データを、高速道路用の判別器で算出される路面特徴量の特徴空間内の距離を使って抽出する。抽出された近傍データの中で最も多かった路面状態が訂正後の路面状態となる。

本手法は、高速道路用の判別器でのみ判別した結果や、判別器が出力した出力ベクトル内の要素が次点で高い路面状態に訂正する手法に比べて高い精度を示した。また、危険側の路面状態を安全側に誤判別する件数を減らすことができ、特に冬期特有の危険側の路面状態であるシャーベット、凍結、積雪路面を安全側の乾燥路面に間違える件数を約半分に減らすことができた。

## 第 5 章 冬期路面の状態判別に特化した深層学習判別器の探索

本章では、冬期路面状態を対象とした画像ベースの路面状態判別器を、実際の車載環境でリアルタイムに動作させることを念頭に、判別器の構造そのものを見直すことで判別速度と判別精度の両立を図る。具体的には、汎用的な軽量 CNN である MobileNetV3-Small [66] をベースとし、その主要ブロック構造を網羅的に枝刈り [110] した多数の派生構造を評価することで、冬期路面判別タスクに適応した軽量構造を探索する。

以降では、まず 5.1 節で本章で扱う課題設定と、前章までの結果を踏まえた本章の位置づけを整理する。続く 5.2 節では、MobileNetV3-Small をベースラインとした構造的枝刈りと網羅的探索の手法について詳述する。5.3 節では、一般道路路面画像データセットの構成、入力前処理、学習条件および使用ハードウェアを示し、5.4 節で 2,048 通りの候補構造の評価結果から、パレート効率な構造と過学習・汎化性能の関係を分析する。最後に 5.5 節で、本章で得られた知見と冬期路面状態モニタリングへの示唆を総括する。

### 5.1 はじめに

第 1 章で述べた通り、寒冷地における冬期路面の安全確保は喫緊の課題であり、特に局所的な凍結などはドライバーによる事前検知が困難であるため、先進運転支援システム (ADAS) や自動運転技術による支援が期待される。これらのシステムが効果的に機能するためには、車両が周囲の環境、とりわけ路面状態を正確かつ迅速に認識することが不可欠である。

本研究では、車両センサを用いて路面状態を判別する手法について論じてきた。第 3 章では、複数のセンサ情報を統合する Late Fusion マルチモーダルモデルを提案し、判別精度の向上を図った。続く第 4 章では、異なる環境下においても頑健な判別性能を維持するための手法について検討した。これらのアプローチにより、多様な状況に対応可能な高精度な路面判別モデルを構築することができた。

しかしながら、第 3 章および第 4 章で導入された判別器の構造は、精度向上と引き換えに、判別器の複雑性を増大させ、計算コストの増加を招いた。ADAS などへの応用では、危険な路面状態を低遅延かつ安定して検知することが重要である。判別処理をクラウドなどの車外のサーバーで担う構成では、画像送信に伴う遅延に加え、通信帯域の圧迫や通信品質の変動の影響、さらには圏外・トンネルなどで判別が成立しないという制約が避けられない。したがって、車載デバイス上で判別を完結させることを前提に、限られた計算資源で高速に動作する軽量 CNN 判別器の利用が不可欠となる。この要求に応えるため、近年では MobileNet [58] に代表されるような、速度と精度のバランスに優れた汎用的な軽量 CNN 構造が広く利用されている。しかし、これらの汎用判別器の構造は、必ずしも本研究

の主題である「冬期路面状態の判別」という特定のタスクに対して、判別速度の観点から最適化されているとは限らない。

そこで本章では、既存の高性能な軽量判別器をベースとしつつ、その構造を抜本的に見直すことで、冬期路面判別タスクに特化した、より軽量かつ高精度な深層学習判別器を探索することを目的とする。具体的には、代表的な軽量 CNN である MobileNetV3-Small [66] をベースラインとし、その主要な構成要素 (bneck ブロック) を削除するアプローチを採用する。このような操作は構造的な枝刈り [110] と呼ばれる。この手法により生成されるすべての派生構造 ( $2^{11} = 2,048$  通り) を網羅的に評価し、精度と判別速度のトレードオフにおいてパレート最適となる構造群を特定する。本章の貢献は、この探索を通じて、汎用的なベースラインモデルと比較して、判別速度と判別精度の両方を同時に大幅に改善するタスク特化型の構造を発見することにある。

## 5.2 路面状態判別に特化した深層学習判別器の探索方法

本節では、判別器の軽量化を実現するための具体的な手法について詳述する。まず 5.2.1 節で軽量化のベースラインとなる構造を示し、次に 5.2.2 節で本研究で採用する構造的な枝刈りのアプローチを説明する。最後に 5.2.3 節で、タスクに特化した最適な構造を発見するための網羅的な探索手法について具体的に述べる。

### 5.2.1 ベースラインとなる判別器

本研究では、軽量化するベースラインの判別器として MobileNetV3-Small [66] を採用した。本判別器は、主要な軽量 CNN 構造の中でも特に優れた精度と速度を示すことから、ベースラインとして選定した。MobileNetV3 は、スマートフォンやエッジデバイスのような性能に制約のある機器で効率的に計算できるよう設計された CNN 構造であり、その効率性は以下の 3 つの技術的要素によって成り立っている。第一に、畳み込み計算を空間方向とチャンネル方向に分解する「Depthwise Separable Convolution」により、計算量とパラメータ数を大きく削減している。第二に、低次元表現を一度高次元に拡張してから畳み込み、ショートカット結合を用いる「Inverted Residual Bottleneck」(bneck ブロック) 構造により、表現力を維持しつつ深いネットワークの学習を安定させている。第三に、チャンネル間の重要度を学習し、特徴マップを適応的に調整する「Squeeze-and-Excitation (SE) モジュール」を bneck ブロックに組み込むことで、わずかな計算コストの増加で表現力を高めている。MobileNetV3 の構造自体も、ハードウェアの特性を考慮したニューラル構造探索 (NAS) [108] によって最適化されており、速度と精度のバランスが追求されている。本研究で用いる MobileNetV3-Small の構造を表 10 に示す。処理内容の conv2d は通常の CNN の畳み込み層であり、pool はプーリング層、NBN はバッチ正規化の処理を指す。CH はチャンネルの略であり、中間 CH 数はそのブロックの層の中で最も多いチャンネル数であり、最終 CH 数はそのブロックの最終的な出力チャンネル数である。最後のブロックの最終 CH

数は  $k$  となっており，これは分類したいラベルの数になるため，今回は 6 種類の路面状態に分類するため  $k = 6$  となる．活性化関数の HS は h-swish であり，RE は ReLU を指す．ストライド  $s$  は，各層における畳み込みあるいはプーリング処理の空間方向の移動幅を表し，1 または 2 の値をとる．表の通り，MobileNetV3-Small は 11 個の主要な bneck ブロックで構成されており，これが特徴抽出の中核を担っている．

表 10: MobileNetV3-Small のネットワーク構造

| 入力サイズ             | 処理内容            | 中間 CH 数 | 最終 CH 数 | 活性化関数 | ストライド |
|-------------------|-----------------|---------|---------|-------|-------|
| $224^2 \times 3$  | conv2d, 3x3     | -       | 16      | HS    | 2     |
| $112^2 \times 16$ | bneck, 3x3      | 16      | 16      | RE    | 2     |
| $56^2 \times 16$  | bneck, 3x3      | 72      | 24      | RE    | 2     |
| $28^2 \times 24$  | bneck, 3x3      | 88      | 24      | RE    | 1     |
| $28^2 \times 24$  | bneck, 5x5      | 96      | 40      | HS    | 2     |
| $14^2 \times 40$  | bneck, 5x5      | 240     | 40      | HS    | 1     |
| $14^2 \times 40$  | bneck, 5x5      | 240     | 40      | HS    | 1     |
| $14^2 \times 40$  | bneck, 5x5      | 120     | 48      | HS    | 1     |
| $14^2 \times 48$  | bneck, 5x5      | 144     | 48      | HS    | 1     |
| $14^2 \times 48$  | bneck, 5x5      | 288     | 96      | HS    | 2     |
| $7^2 \times 96$   | bneck, 5x5      | 576     | 96      | HS    | 1     |
| $7^2 \times 96$   | conv2d, 5x5     | 576     | 96      | HS    | 1     |
| $7^2 \times 96$   | conv2d, 1x1     | -       | 576     | HS    | 1     |
| $7^2 \times 576$  | pool, 7x7       | -       | -       | -     | 1     |
| $1^2 \times 576$  | conv2d 1x1, NBN | -       | 1024    | HS    | 1     |
| $1^2 \times 1024$ | conv2d 1x1, NBN | -       | $k$     | -     | 1     |

### 5.2.2 構造的枝刈り

深層学習判別器を特定のタスクに適用する際、最も一般的な手法は、ImageNet [97]などで事前学習された判別器の重みを初期値として、ターゲットとなるデータセットで再学習を行うファインチューニング [104] である。この手法は多くの場合有効だが、事前学習された判別器の構造自体は変更されない。しかし前述の通り、汎用タスク向けに設計された構造は、特定のタスクに対しては必ずしも最適ではない可能性がある。そこで本研究では、より根源的な最適化手法として判別器の枝刈りに着目する。枝刈りは、判別器の性能への寄与が小さいパラメータを削除することで、判別器を圧縮・高速化する技術である [110]。枝刈りには、フィルタや層といった構造単位で削除する「構造化枝刈り」と、フィルタや層の中の一部の重みをゼロにする「非構造化枝刈り」がある。非構造化枝刈りはパラメータ数を削減できるものの、構造のスパース性を生かすための専用ハードウェアやライブラリがない限り、実際の判別速度の向上に繋がりにくいという課題がある。これに対し、構造化枝刈りは判別器の構造自体を単純化するため、ハードウェアに依存せずに判別速度の向上が可能である。本研究で採用する手法は、bneck ブロックという構造単位を丸ごと削除するため、この構造化枝刈りに分類される。

### 5.2.3 最適な構造の探索方法

本研究の手法は、ニューラル構造探索 (NAS) [108] の枠組みで捉えることができる。NAS は通常、強化学習や進化的アルゴリズムといった発見的探索戦略を用いるが、本研究では限定された探索空間内の真の最適解を発見するため、網羅的な探索アプローチを採用する。以下に、その探索空間と探索戦略、および性能の評価方法について示す。

まず、探索空間については MobileNetV3-Small を構成する、それぞれ内部構成の異なる 11 個の bneck ブロックの各々について、「使用する」か「使用しない」かの二者択一を考える。これにより、合計で  $2^{11} = 2,048$  通りの異なる構造からなる探索空間が定義される。

次に、探索戦略については探索空間内のすべての候補構造を網羅的に生成し、それぞれを独立して学習・評価する総当たり戦略を採用する。これにより、探索空間全体の性能分布を完全に把握することが可能となる。

最後に、性能の評価方法については各候補となる構造を、同一の学習データとテストデータを用いてゼロから完全に学習させ、その性能を評価する。これにより、すべての候補構造を公平に比較することが可能となる。

このプロセスにおいて、技術的に重要な点がある。bneck ブロックを削除すると、その前後のブロック間でチャンネル数が一致しなくなり、ネットワークが成立しなくなる。この問題に対処するため、あるブロックが削除された際には、その直前のブロックの最終層である Pointwise Convolution 層が出力するチャンネル数を、次に接続されるブロックが要求する入力チャンネル数に一致するよう動的に調整する処理を実装することで、すべてのパターンで正しく動作する判別器を作成した。

## 5.3 実験の設定

本節では、本章の評価に用いた実験条件として、データセット、入力データの前処理、学習条件および評価環境、評価指標を整理する。まず 5.3.1 節で一般道路路面画像データセットの構築方法を述べ、続いて 5.3.2 節で判別器への入力生成に用いた前処理手順を示す。次に 5.3.3 節で学習設定と使用ハードウェア (Raspberry Pi 4) を記載し、最後に 5.3.4 節で判別時間と F-measure に基づく評価指標を定義する。

### 5.3.1 データセットの構築

本研究で使用するデータセットは、日本の北海道の一般国道 R232 (留萌～天塩) と R40 (天塩～士別) において、2022 年 10 月から 2023 年 3 月までに収集された。データセットは、車載カメラを用いて日中の走行中に撮影された画像により構築した。本研究では、判別対象となる路面状態を表 1 に示す 6 種類に分類した。各画像のラベル付けは、既存の高速道路向けに開発された路面状態判別器 [41] の判別結果を利用することで、大規模なデータセット (合計 30,000 枚) の効率的な構築を実現した。

### 5.3.2 入力データの前処理方法

判別器への入力データを作成するため、収集した画像に対して一連の前処理を適用した。具体的には、まず各画像から車両前方の路面が映るように、あらかじめ定められた固定座標の領域を  $300 \times 120$  ピクセルの解像度で切り出し、その切り出した領域を、 $200 \times 80$  ピクセルの解像度にリサイズし、判別器の入力とした。

### 5.3.3 学習方法と使用ハードウェア

各路面状態につき 4,000 枚の画像を学習用、1,000 枚をテスト用として用意した。路面状態は 6 種類あるため、合計で学習データは 24,000 枚、テストデータは 6,000 枚となる。データセットの詳細は表 11 に示す。本研究では、2,048 通りすべての候補判別器に対して、同一のデータセットを用いて 50 エポックの学習を行った。学習時の損失関数にはクロスエントロピー誤差を採用し、最適化手法には適応的学習率を持つ Adam オプティマイザ [128] を学習率 0.001 で用いた。学習時のハイパーパラメータの詳細は表 12 に示す。

判別時間の評価は、実際の車載環境を想定したリソース制約の厳しいハードウェアで行うことが重要である。本研究では、評価デバイスとして Raspberry Pi 4 (Model B) [65] を使用した。このデバイスは CPU のみで動作し、GPU を搭載していない。この選定により、研究結果が現実の組込みシステムへの応用可能性を直接的に示すことができる。ハードウェアの仕様は表 13 に示す。

表 11: データセットの詳細

| 項目       | 内容                         |
|----------|----------------------------|
| 学習データ    | 24,000 枚 (6 クラス × 4,000 枚) |
| 評価データ    | 6,000 枚 (6 クラス × 1,000 枚)  |
| 入力画像の解像度 | 300 × 120 ピクセル             |
| 路面状態     | 乾燥, 半湿, 湿潤, シャーベット, 凍結, 積雪 |

表 12: 学習時のハイパーパラメータ

| パラメータ  | 値     |
|--------|-------|
| エポック数  | 50    |
| バッチサイズ | 32    |
| 最適化手法  | Adam  |
| 学習率    | 0.001 |

表 13: 評価用のハードウェア

| 項目      | 仕様                       |
|---------|--------------------------|
| デバイス    | Raspberry Pi 4 (Model B) |
| CPU     | ARM Cortex-A72           |
| コア数     | 4                        |
| メモリ     | 4 GB                     |
| クロック周波数 | 1.5 GHz                  |
| GPU     | 無し                       |
| 最大消費電力  | 1250mA, 6.25W            |
| 本体重量    | 46g                      |
| 外形寸法    | 88mm × 58mm × 19.5mm     |



図 30: Raspberry Pi 4 Model B の外観

#### 5.3.4 評価指標

判別器の性能を評価するため、判別時間 (ms) と F-measure の 2 つの指標を用いた。判別時間は Raspberry Pi 4 上で、単一画像の判別にかかる時間を測定した。測定値の安定性を確保するため、100 回の判別を実行し、その平均値を採用した。これは判別器の計算効率とリアルタイム性能を直接的に示す指標である。F-measure は判別精度を評価するための指標として用いた。F-measure は、適合率 (Precision) と再現率 (Recall) の調和平均であり、特にクラス間のデータ数に不均衡がある場合に、精度 (Accuracy) よりも頑健な評価が可能となり、以下の式によって計算される。

$$\text{Recall} = \frac{\text{Num. of correctly estimated road conditions in the class}}{\text{Num. of road conditions in the class}} \quad (5.1)$$

$$\text{Precision} = \frac{\text{Num. of correctly estimated road surface}}{\text{Num. of estimated road surface in the class}} \quad (5.2)$$

$$\text{F-measure} = \frac{2 \times \text{Recall} \times \text{Precision}}{\text{Recall} + \text{Precision}} \quad (5.3)$$

#### 5.4 実験結果

本節では、MobileNetV3-Small の網羅的な枝刈りによって生成された 2,048 通りの判別器の評価結果を示し、その傾向を分析する。まず 5.4.1 節で、全候補構造の性能分布を




図 31: 各構造の判別時間と精度の関係

F-measure と判別時間の 2 軸で可視化し、全体像を整理する．続いて 5.4.2 節で，パレート効率性の観点から有望な構造を抽出し，速度と精度のトレードオフを検討する．最後に 5.4.3 節で，判別器の複雑性と過学習の関係を分析し，軽量化によって精度が向上した要因を考察する．

#### 5.4.1 各構造の評価結果

網羅的な枝刈りによって生成された 2,048 通りの判別器すべてについて学習と評価を行い，その結果を F-measure と判別時間の 2 軸でプロットした結果を図 31 に示す．この散布図は，横軸に判別時間，縦軸に F-measure をとり，各点が個々の判別器の性能を示している．点の色は，その判別器が使用する bneck ブロックの数を表しており，色が明るいほどブロック数が多いことを意味する．図の全体を見ると，多くの枝刈りされた判別器が，図中に赤丸で示されたベースラインである MobileNetV3-Small と比較して高い性能を示していることがわかる．一方で，ベースラインを下回る性能を示す判別器も多数存在し，これは，重要な特徴抽出を担う bneck ブロックを不適切に削除した結果，判別器の表現能力がタスクを解く上で不十分になったためと考えられる．また，削除したブロックの前後を繋げるためのチャンネル数変更の影響により，ブロック数が少ないにもかかわらずベースラインより判別時間が長くなる判別器も散見され，ブロック数と判別速度が必ずしも単純な比例関係にないことを示している．そして，F-measure と判別時間の両方でベースラインよりも改善が見られる構造も多く見つかった．

#### 5.4.2 パレート効率的な構造の抽出

2,048 通りの候補の中から最も優れた構造を特定するため、使用するブロック数ごとにパレート効率的な判別器を分析した。パレート効率的な判別器とは、「他のどの判別器と比較しても、F-measure と判別時間の両方で同時に劣ることがない」判別器の集合を指す。この分析により、まずブロック数ごとのパレート効率的な構造を抽出し、それらを比較することで、全体の探索空間における最適な構造を特定した。図 32 は、この分析によって得られたパレート曲線に位置する判別器のみをプロットしたものである。この図では、同じブロック数を持つパレート効率的な判別器群を線で結び、線の終端にブロック数を示している。例えば、数字の「2」と示された線の上の点は、すべて 2 つの bneck ブロックで構成されるパレート効率的な判別器を表している。この図から、bneck ブロックを 2 つだけ使用した判別器のグループが、グラフの左上に位置する最も優れた、すなわち高速かつ高精度な領域を形成していることが分かる。具体的に、パレート曲線上に位置し、bneck ブロックを 2 つ使用した判別器の性能を、ベースライン判別器と比較するため表 14 に示す。この表の「使用ブロックの構成」列は、11 個の bneck ブロックの有無を左から順に示しており、1 は使用、0 は不使用（枝刈り）を意味する。

また、2,048 通りの候補の中で最も判別時間が短かった判別器は、使用ブロックの構成が 110000000000 であり、F-measure が 0.676、判別時間が 22.5 ms であった。これを、ベースラインである MobileNetV3-Small (11111111111) と比較すると、判別時間は 53.4 ms から 22.5 ms へと 57.9%短縮され、これは約 2.37 倍の高速化に相当する。また、F-measure は 0.632 から 0.676 へと 0.044 向上し、約 7.0%の改善に相当した。ここで、MobileNetV3-Small では誤判別していた路面を、軽量化された判別器である 110000000000 が正しく判別できている例を図 33 から図 38 に示す。いずれの例も特殊な状態ではないため、一般的な路面をより精度よく判別するという、純粋な精度向上が達成されていることが分かる。

なお、パレート曲線が描けるということは、F-measure（精度）と判別時間の間にトレードオフ関係が成立することを意味する。したがって実運用では、用途によって要求される許容遅延時間に応じて、パレート曲線上の判別器を選択することで、判別時間をある程度許容して精度を優先するような設計が可能となる。例えば表 14 に示す構造 100100000000 のように、ベースラインの判別時間に対して 50.0%短縮（53.4 ms から 26.7 ms）しつつ、F-measure が約 10.4%と大幅に改善されたものを選択することも可能である。




図 32: 使用ブロック数ごとのパレート最適な判別器

表 14: MobileNetV3 とパレート効率な構造の判別器の性能比較

| 構造<br>(1: 使用/0: 不使用) | ブロック数    | 判別時間        |              | F-measure    |             |
|----------------------|----------|-------------|--------------|--------------|-------------|
|                      |          | 結果 [ms]     | 削減率          | 結果           | 改善率         |
| 11111111111 (ベースライン) | 11       | 53.4        | -            | 0.632        | -           |
| <b>11000000000</b>   | <b>2</b> | <b>22.5</b> | <b>57.9%</b> | <b>0.676</b> | <b>7.0%</b> |
| 10010000000          | 2        | 26.7        | 50.0%        | 0.698        | 10.4%       |
| 10100000000          | 2        | 38.8        | 27.3%        | 0.710        | 12.3%       |
| 10000010000          | 2        | 46.5        | 12.9%        | 0.711        | 12.5%       |
| 10001000000          | 2        | 51.7        | 3.2%         | 0.713        | 12.8%       |
| 00100001000          | 2        | 203.2       | -280.5%      | 0.723        | 14.4%       |
| 00000101000          | 2        | 236.7       | -343.3%      | 0.730        | 15.5%       |



(a) MobileNetV3 では誤判別だが軽量判別器で正しく乾燥と判別された例 1



(b) MobileNetV3 では誤判別だが軽量判別器で正しく乾燥と判別された例 2

図 33: MobileNetV3 では誤判別だが軽量判別器で正しく乾燥と判別された例



(a) MobileNetV3 では誤判別だが軽量判別器で正しく半湿と判別された例 1



(b) MobileNetV3 では誤判別だが軽量判別器で正しく半湿と判別された例 2

図 34: MobileNetV3 では誤判別だが軽量判別器で正しく半湿と判別された例



(a) MobileNetV3 では誤判別だが軽量判別器で正しく湿潤と判別された例 1



(b) MobileNetV3 では誤判別だが軽量判別器で正しく湿潤と判別された例 2

図 35: MobileNetV3 では誤判別だが軽量判別器で正しく湿潤と判別された例



(a) MobileNetV3 では誤判別だが軽量判別器で正しくシャーベットと判別された例 1



(b) MobileNetV3 では誤判別だが軽量判別器で正しくシャーベットと判別された例 2

図 36: MobileNetV3 では誤判別だが軽量判別器で正しくシャーベットと判別された例



(a) MobileNetV3 では誤判別だが軽量判別器で正しく凍結と判別された例 1



(b) MobileNetV3 では誤判別だが軽量判別器で正しく凍結と判別された例 2

図 37: MobileNetV3 では誤判別だが軽量判別器で正しく凍結と判別された例



(a) MobileNetV3 では誤判別だが軽量判別器で正しく積雪と判別された例 1



(b) MobileNetV3 では誤判別だが軽量判別器で正しく積雪と判別された例 2

図 38: MobileNetV3 では誤判別だが軽量判別器で正しく積雪と判別された例

### 5.4.3 判別器の複雑性と過学習についての検証

前節では、より少ないブロック数を持つ判別器が、複雑なベースライン判別器よりも高い精度を示すという、直感に反する結果が得られた。一般的に、より複雑なモデルが未知のデータであるテストデータに対して性能が劣る現象は、そのモデルが学習データに過剰適合し、汎化性能を失う過学習が原因として考えられる。そこで本節では、この過学習の観点から、判別器の複雑性（使用ブロック数）と学習データに対する損失の関係を分析し、軽量化によって精度が向上した原因を明らかにする。

そこでまず、使用ブロック数と学習データに対する損失（train loss）の関係を調査した。図 39 は、使用する bneck ブロックの数（横軸）ごとに、最終的な学習損失（縦軸）の分布を箱ひげ図で示したものであり、この図から各ブロック数における損失のばらつきと全体的な傾向を読み取ることができる。図 39 を見ると、使用する bneck ブロックの数が増えるほど、学習損失の中央値が一貫して低下する傾向が見られた。これは、より複雑な判別器ほど学習データをより良く暗記する能力が高いことを示しており、過学習の兆候と一致する。

次に、判別器の汎化性能（テストデータに対する性能）を評価するため、ブロック数ごとの平均 F-measure と平均学習損失を図 40 に散布図としてプロットした。この図では、横軸が平均学習損失、縦軸が平均 F-measure を示しており、プロットされた各点が、特定のブロック数を持つ判別器群の平均的な性能位置を表している。学習損失が最も低くなるのはブロック数が多い判別器であるにもかかわらず、F-measure がピークに達するのはブロック数が 2 の時点である。ブロック数が 2 から 1 に減少すると、判別器の表現能力が不足し（過小適合）、F-measure は低下する。逆に、ブロック数が 2 から増加するにつれて、判別器は学習データに過剰適合し始め、汎化性能である F-measure は再び低下していく。この結果は、路面状態判別タスクにおける判別器の複雑性と性能の間に最適なバランスが存在することを実証しており、ベースライン判別器が過学習状態にあったという仮説を裏付けるものである。

以上の分析より、本章で用いた MobileNetV3-Small をベースとした網羅的な構造的枝刈りにより、冬期路面状態判別タスクに特化した軽量な判別器構造を獲得できることが示された。特に、bneck ブロック数を適切に削減した構造では、判別時間を短縮しつつ、テストデータに対する F-measure も同時に向上するという結果が得られた。

また、図 39 および図 40 が示す通り、ブロック数が多い判別器ほど学習損失が低下する一方で、汎化性能である F-measure は必ずしも増加せず、むしろ低下する領域が存在した。これは、ベースライン判別器が本タスクに対して過剰な表現力を有し、過学習を生じていた可能性を示唆する。したがって、枝刈りによってモデル容量をタスクの複雑性に見合う水準へ調整し、過学習を緩和したことが、本章で観測された精度向上の主要因であると解釈できる。




図 39: 使用ブロック数と学習損失の関係




図 40: ブロック数ごとの F-measure の平均と学習損失の平均の関係

## 5.5 まとめ

本章では、冬期路面状態をリアルタイムで判別するためのタスク特化型軽量 CNN 構造を提案した。汎用判別器である MobileNetV3-Small の構成ブロックを網羅的に枝刈りするアプローチにより、2,048 通りの派生構造を評価した。その結果、ベースライン判別器よりも判別時間を約 58%削減し、F-measure を約 7%改善する軽量の構造を発見した。この性能向上は、タスクの複雑性に対してベースライン判別器が過学習に陥っていたのに対し、枝刈りされた判別器がより適切な表現能力を持っていたためであることが示唆された。

本章の最も重要な貢献は、冬期路面状態判別という実用的なタスクにおいて、ベースラインの汎用判別器よりも高速かつ高精度な、タスク特化型の CNN 構造を特定したことである。この結果は、自動車の安全性向上に直接的に貢献する。判別時間が短縮されたことは、車両のシステムが危険を認識して対応するまでの時間が短くなることを意味する。これにより、ADAS が介入するまでの反応距離が実質的に短縮され、わずかな時間の差が事故を回避する上で重要な要因となりうる。また、F-measure が 7%向上したことは、凍結や積雪といった危険な路面状態の誤検知や見逃しが減少することを意味する。これにより、不要な警告によるドライバーの混乱を防ぎつつ、真に危険な状況でのシステムの信頼性を高めることができる。このように、本章で達成された性能向上は、その数値が示す学術的な貢献に加え、現実の道路交通の安全性向上に繋げることが可能となる。

加えて、本章の結果は、判別器の性能が、その構造とタスクの複雑性の適合度によって大きく左右されることを示している。ベースラインとして採用した MobileNetV3 は、ImageNet [97] のような 1,000 種類以上の汎用的な物体を認識するために設計された高効率な判別器である。しかし、本研究が対象とする冬期路面判別タスクのクラス数はわずか 6 種類であり、MobileNetV3 が持つ表現力は本タスクに対して過剰であった。このモデルの複雑性とタスクの要求との不均衡が、5.4 節で示された過学習の根本的な原因であると考えられる。このことから、特定タスクで最高の性能を達成するためには、既製の汎用判別器をそのまま利用するのではなく、タスクの複雑性に見合った最適な構造を探索する「タスク特化」のプロセスが重要となる。本研究で採用した網羅的な枝刈りのアプローチは、このタスクと判別器の適合性を追求し、最適な構造を発見するための具体的な一手法である。冬期路面モニタリングの課題に限らず、リソース制約のあるエッジデバイスにおける判別器設計においては、このようなタスク特化のアプローチは、精度を維持、あるいは向上させつつ、計算効率を最大化するための有効な指針となる。

## 第 6 章 結論

本章では、本論文で検討した各手法の成果を結論として取りまとめ、研究全体の意義と今後の課題を整理する。まず、6.1 節で本研究の成果を総括し、本研究が示した技術的意義を簡潔に述べる。次に、6.2 節で残された課題と今後の展開可能性を述べる。

### 6.1 本研究の総括

本論文では、車載センサ、特にカメラを中核として用いた冬期路面状態推定の技術基盤確立を目的とし、実用化に向けた 3 つの核心的課題である、高精度な推定を実現するためのロバスト性、多様な環境で機能する汎用性、そして車載器で稼働する実用性（軽量・高速なオンデバイス処理）を克服する手法について検討した。以降では、本論文における各章の概要および成果を示す。第 2 章では、冬期路面モニタリングの必要性、関連するセンシング技術（固定・車載）、および機械学習の応用（深層学習、マルチモーダル、ドメイン適応、モデル軽量化）に関する既存研究を詳細に整理し、本論文が取り組むべき課題を明確にした。第 3 章では、判別の「ロバスト性」向上を目的とし、異なる特性を持つ車載センサ（非接触系のカメラと接触系のタイヤ内加速度センサ）の情報を統合するマルチモーダル判別手法を提案した。具体的には、各センサ情報に対応する個別の判別器の出力を、第 3 の判別器で確率レベルで統合する Late Fusion モデルを構築した。これにより、一方のセンサが弱点を持つ状況でも、他方の情報で相互補完し、ロバストな路面推定を実現できることを実証した。第 4 章では、判別の「汎用性」向上として、学習済みの判別器を学習していない路面環境で使用したときに起こる精度低下の課題に取り組んだ。新たなラベル付けや再学習といった高コストなプロセスを回避する手法として、学習済みモデルの出力確信度と  $k$  近傍法 ( $k$ -NN) アルゴリズムを組み合わせたラベル訂正手法を提案した。これにより、適用先の「ラベルなし」参照データ群を利用して判別結果を自動で訂正し、精度低下、特に安全上問題となる危険な誤判別を抑制できることを示した。第 5 章では、判別の「実用性」向上、すなわち ADAS（先進運転支援システム）など車載デバイスでのリアルタイム処理を目的としたモデルの軽量化・高速化に取り組んだ。汎用的な軽量 CNN モデル (MobileNetV3-Small) が、路面判別という特定タスクに対しては過度に複雑である可能性に着目し、その構成要素を構造的枝刈りにより体系的に削除する網羅的な構造探索手法を提案した。この探索により、ベースラインモデルと比較し、判別時間を大幅に削減しつつ F-measure を向上させる、タスクに最適化された軽量構造を発見した。

以上の技術的成果は、冬期路面モニタリングという個別課題に対する貢献にとどまらず、土木工学分野におけるインフラ点検・維持管理技術の高度化にも繋げられると考えられる。近年、深層学習をはじめとするデータ駆動型手法の活用により、点検作業の高度化・効率

化を目指した取り組みが進められている。本論文で検討したマルチモーダル判別の枠組みは、これらと同様に深層学習を基盤としつつ、これまで個別に扱われることの多かった複数の計測情報を統合的に利用する考え方の具体例であり、画像や各種センサ情報など多様な観測情報を組み合わせたモニタリングシステムの設計指針の参考になる。また、ドメインシフトに対応したラベル訂正手法は、一地点で構築した学習モデルを別の地点へ展開する際のラベリング負荷を低減し得る可能性を示しており、多様なインフラ・現場を対象とする実運用への橋渡しとなる。さらに、軽量 CNN によるオンデバイス処理の実現は、高性能なサーバーや常時接続型のネットワークへの依存を抑えつつ、現場での迅速な判断や継続的な状態監視を可能とする基盤技術として位置づけられる。

## 6.2 本研究の今後の課題

本論文で提案した各手法は、車載センサを用いた冬期路面推定の高度化に寄与するものであるが、さらなる性能向上や多様な実環境への適用拡大に向けて、以下のような課題が残されている。

第 3 章のマルチモーダル判別手法に関しては、まず、昼間のデータでの検証が必要である。昼間は路面特徴が鮮明になる利点が期待される一方、濡れた路面と建物の影の混同といった新たな課題も想定される。また、本手法はタイヤ内加速度センサを利用するため、超低速走行時には機能が制限され、画像の判別器のみに依存せざるを得ない。さらに、その導入コストが高いため、そもそもセンサを使えないシステムを利用する状況も見据える必要がある。このように、片方の判別器が完全に使用できない場合に、他方のセンサデータを使って補完する方法の検討も必要である。第 4 章のドメイン適応手法に関しては、適用範囲の拡大とアルゴリズムの高度化が課題である。本手法の有効性については、夜間データや雪によるホワイトアウト、濃霧といった極端な悪天候下に加え、通年を通じた条件変動の下でも検証を進める必要がある。さらに、高速道路以外の道路には海沿いの道や山道、都市部や郊外、さらには他の都府県など多様な環境が存在するため、環境差に起因するドメインシフトの影響を要因別に切り分け、個別に評価していくことが重要である。一方で、 $k$  近傍法の追加に伴う計算コストの増加は、車載システムでの実用化に向けた課題であり、参照データ数の最適化や高速な近傍探索アルゴリズムの導入など、計算コストを削減する方策の検討が求められる。加えて、実験的に決定した閾値  $\theta$  や近傍データ数  $k$  といったパラメータを適応的に決定する方法、ならびに近傍探索に用いる特徴ベクトルとして最適な隠れ層の選定も今後の検討課題である。最後に、道路管理や走行支援の多様なニーズを踏まえ、判別する路面状態を 6 種類のまま維持することが最適かどうかを含め、より実用的な分類体系についても検討を進める必要がある。第 5 章のモデル軽量化手法に関しては、その汎用性とさらなる性能向上の可能性について、今後の検証課題が残されている。構築したデータセットの範囲を超え、夜間、悪天候、多様な地域（都市部、山間部など）を含む、より包括的なデータセットで頑健性を検証し、判別器を改善していく必要が

ある．また，本研究で用いた系統的枝刈り手法を，EfficientNet [129] など他の軽量 CNN 構造に適用し，その有効性を比較検討することも重要である．さらに，本手法で得られた最適構造に対し，学習後量子化（Post-Training Quantization） [111] のような他の圧縮技術を組み合わせることで，判別器サイズと遅延を極限まで削減する可能性を探求したい．探索戦略についても，本研究では網羅的探索を採用したが，より大規模な探索空間を効率的に探索するため，進化的アルゴリズムやベイズ最適化といった，より洗練された NAS アルゴリズムの導入も検討していく．

## 謝辞

本論文は筆者が北海道大学大学院工学院に在学中の研究成果をまとめたものである。はじめに、先端モビリティ工学研究室准教授の高橋翔先生には指導教員として、本研究の遂行にあたって終始多大なるご指導をいただきました。ここに深謝の意を表します。また、萩原亨教授、吉井稔雄教授にはゼミや発表の際などにおいて、大変丁寧なご指導をいただきました。心より感謝申し上げます。そして、著者が遠方に住んでいたため直接会う機会が少なかったにもかかわらず、あらゆる面で協力していただいた研究室の皆様にも心から感謝申し上げます。本当にありがとうございました。

さらに、社会人博士として勤務先である株式会社ブリヂストンに在籍しながら研究を進めるにあたり、多大なるご理解とご支援を賜りました花塚泰史部門長、森徹平部長および同僚の皆様にも厚く御礼申し上げます。

本研究を進めるにあたり、妻と子供たちには多くの負担と心配をかけました。それにもかかわらず、日々変わらぬ支えと励ましを与えてくれたことに、心より深く感謝申し上げます。

## 参考文献

- [1]国土交通省. 道路雪防災の目的. <https://www.mlit.go.jp/road/bosai/fuyumichi/project.html>. (参照 2026-01-18).
- [2]Shigeyuki Nakame, Takahiro Okawado, Fumihiro Hara, Junichi Oshima, and Shinei Takano. Development of a cost management method for road snow removal in cold, snowy regions. *Journal of the Eastern Asia Society for Transportation Studies*, Vol. 8, pp. 311–324, 2010.
- [3]国土交通省. 道の相談室（道路保守・管理）. [https://www.mlit.go.jp/road/soudan/soudan\\_08b\\_12.html](https://www.mlit.go.jp/road/soudan/soudan_08b_12.html). (参照 2026-01-18).
- [4]Xianming Shi, Laura Fay, Zhengxian Yang, Tuan Anh Nguyen, and Yajun Liu. Corrosion of deicers to metals in transportation infrastructure: Introduction and recent developments. *Corrosion reviews*, Vol. 27, No. 1-2, pp. 23–52, 2009.
- [5]David Darwin, JoAnn Browning, Lien Gong, and Sean R Hughes. Effects of deicers on concrete deterioration. American Concrete Institute, 2008.
- [6]積雪寒冷特別地域における道路交通の確保に関する特別措置法. <https://laws.e-gov.go.jp/law/331AC1000000072>. (参照 2026-01-18).
- [7]高田哲哉, 徳永ロベルト, 高橋尚人. 冬期気象条件下における交通事故発生形態について. 日本雪氷学会北海道支部 研究発表会, 2010.
- [8]藤本明宏, 中島知幸, 佐藤賢治, 徳永ロベルト, 高橋尚人, 石田樹. 路面すべり摩擦係数の推定による冬期道路管理の適正化に関する研究. 平成 28 年度国土交通省 国土技術研究会, 2016.
- [9]北海道警察本部交通企画課. スリップが要因となる交通事故実態. <https://www.police.pref.hokkaido.lg.jp/statis/jiko/jiko-surippu/jiko-surippu.pdf>. (参照 2026-01-18).
- [10]Lian Gu, Mingjian Wu, and Tae J. Kwon. An enhanced spatial statistical method for continuous monitoring of winter road surface conditions. *Canadian Journal of Civil*

*Engineering*, Vol. 47, No. 10, pp. 1154–1165, 2020.

- [11]Guangyuan Pan, Matthew Muresan, Ruifan Yu, and Liping Fu. Real-time winter road surface condition monitoring using an improved residual cnn. *Canadian Journal of Civil Engineering*, Vol. 48, No. 9, pp. 1215–1222, 2021.
- [12]藤本明宏, 佐藤賢治, 徳永ロベルト, 高橋尚人, 石田樹. 凍結防止剤散布後の路面すべり摩擦係数の推定による冬期道路管理の効率化に関する研究. ゆきみらい研究発表会論文集, 2016.
- [13]Torbjørn Lorentzen. Climate change and winter road maintenance. *Climatic Change*, Vol. 161, No. 2, pp. 225–242, 2020.
- [14]ブリヂストン. タイヤと路面を感知する技術. [https://www.bridgestone.co.jp/technology\\_innovation/cais/](https://www.bridgestone.co.jp/technology_innovation/cais/). (参照 2026-01-18).
- [15]大廣智則, 高倉清, 桜庭拓也, 花塚泰史, 萩原亨. 自動路面状態判別システムを活用したスマート凍結防止剤散布システムの開発. 交通工学論文集, Vol. 5, No. 4, pp. B\_7–B\_15, 2019.
- [16]Tomonori Ohiro, Kiyoshi Takakura, Takuya Sakuraba, Yasushi Hanatsuka, and Toru Hagiwara. Development of advanced anti-icing spray system using automated road surface condition judgement system. No. 19-04400, 2019.
- [17]Yao Ma, Meizhu Wang, Qi Feng, Zhiping He, and Mi Tian. Current non-contact road surface condition detection schemes and technical challenges. *Sensors*, Vol. 22, No. 24, p. 9583, 2022.
- [18]Sinem Bozkurt, Ahmet Yazici, and Kemal Keskin. A multicriteria route planning approach considering driver preferences. In *2012 IEEE International Conference on Vehicular Electronics and Safety (ICVES 2012)*, pp. 324–328. IEEE, 2012.
- [19]S Ayyasamy. A comprehensive review on advanced driver assistance system. *Journal of Soft Computing Paradigm*, Vol. 4, No. 2, pp. 69–81, 2022.
- [20]Arvind Kumar. Review on traction control system. In *Integrated Emerging Methods of Artificial Intelligence and Cloud Computing*, pp. 184–189. Springer, 2021.

- [21]Rajesh Rajamani, Neng Piyabongkarn, Jae Lew, Kyongsu Yi, and Gridsada Phanomchoeng. Tire-road friction-coefficient estimation. *IEEE Control Systems Magazine*, Vol. 30, No. 4, pp. 54–69, 2010.
- [22]Nenggen Ding, Guizhen Yu, and Weida Wang. Estimation of brake pressure and tyre–road friction during abs activation. *International journal of vehicle design*, Vol. 58, No. 1, pp. 33–45, 2012.
- [23]Farah M. Ali and Nizar H. Abbas. Adaptive cruise control system: A literature survey. *Journal of Engineering*, Vol. 30, No. 9, 2024.
- [24]M Andersson, F Bruzelius, J Casselgren, M Hjort, S Löfving, G Olsson, J Rönnerberg, M Sjödaahl, S Solyom, J Svendenius, et al. Road friction estimation part ii. *Intelligent Vehicle Safety Systems (IVSS) Project Report, Sweden*, 2010.
- [25]L Anand and A Srinivaas. A review paper of electric vehicle stability control. In *2023 3rd International Conference on Electrical, Computer, Communications and Mechatronics Engineering (ICECCME)*, pp. 1–10. IEEE, 2023.
- [26]Changsun Ahn, Huei Peng, and Hongtei Eric Tseng. Robust estimation of road frictional coefficient. *IEEE Transactions on Control Systems Technology*, Vol. 21, No. 1, pp. 1–13, 2011.
- [27]Seunghoon Woo, Seunguk Jeon, Eunhyek Joa, and Donghoon Shin. Enhanced vehicle dynamics and safety through tire–road friction estimation for predictive elsd control under various conditions of general racing tracks. *Applied Sciences*, Vol. 14, No. 5, p. 1903, 2024.
- [28]舟橋誠, 徳永ロベルト, 高橋尚人. 冬期路面管理における路面状態の定量的計測技術について. 第 52 回北海道開発技術研究発表会, 2009.
- [29]Zhimin Qiu, Jinju Shao, Dong Guo, Xuehao Yin, Zhipeng Zhai, Zhibing Duan, and Yi Xu. A multi-feature fusion approach for road surface recognition leveraging millimeter-wave radar. *Sensors*, Vol. 25, No. 12, p. 3802, 2025.
- [30]Ville V Viikari, Timo Varpula, and Mikko Kantanen. Road-condition recognition using 24-ghz automotive radar. *IEEE transactions on intelligent transportation systems*, Vol. 10, No. 4, pp. 639–648, 2009.

- [31] Ju Won Seo, Jin Sung Kim, Jin Ho Yang, and Chung Choo Chung. A spatiotemporal deep learning architecture for road surface classification using lidar in autonomous emergency braking systems. *IEEE Access*, Vol. 11, pp. 114550–114561, 2023.
- [32] 渡邊直樹, 榎本浩之, 舘山一孝, 山本朗人, 田中聖隆, 高橋修平, 岩本明子, 佐々木亮介. マイクロ波放射計を用いた路面状態 自動判別システムの開発. *雪氷*, Vol. 73, No. 4, pp. 213–224, 2011.
- [33] Yasuhiro Tanaka and Kazutaka Tateyama. Analysis of microwave radiometry of snow and ice on an outdoor experimental asphalt surface. *IEEE Sensors Letters*, 2024.
- [34] M Marchetti, M Moutton, S Ludwig, L Ibos, V Feuillet, and J Dumoulin. Road networks winter risk estimation using on-board uncooled infrared camera for surface temperature measurements over two lanes. *International Journal of Geophysics*, Vol. 2011, No. 1, p. 514970, 2011.
- [35] 花塚泰史, 森永啓詩, 若尾泰通. インテリジェントタイヤによる路面状態判別 冬季道路管理への活用. 雪氷研究大会講演要旨集 雪氷研究大会 (2010・仙台), pp. 24–24. 公益社団法人 日本雪氷学会/日本雪工学会, 2010.
- [36] Dongwook Lee, Ji-Chul Kim, Mingeuk Kim, and Hanmin Lee. Intelligent tire sensor-based real-time road surface classification using an artificial neural network. *Sensors*, Vol. 21, No. 9, p. 3233, 2021.
- [37] Zongzhi Han, Weidong Liu, Zhenhai Gao, and Dayu Liu. A method for real-time road surface identification of intelligent tire systems based on random convolutional kernel neural network. *IEEE Transactions on Intelligent Vehicles*, 2024.
- [38] Yann LeCun, Yoshua Bengio, and Geoffrey Hinton. Deep learning. *nature*, Vol. 521, No. 7553, pp. 436–444, 2015.
- [39] Karen Simonyan and Andrew Zisserman. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*, 2014.
- [40] Guangyuan Pan, Liping Fu, Ruifan Yu, and Matthew Muresan. Winter road surface condition recognition using a pretrained deep convolutional network. *arXiv preprint arXiv:1812.06858*, 2018.

- [41]Tomoyuki Takase, Sho Takahashi, Toru Hagiwara, Tomonori Ohiro, Yuji Iwasaki, Teppei Mori, and Yasushi Hanatsuka. An estimation method of road surface condition on winter expressway via mobile nets using in-vehicle camera images. In *2021 IEEE 10th Global Conference on Consumer Electronics (GCCE)*, pp. 109–110. IEEE, 2021.
- [42]Hongyi Zhang, Rabia Sehab, Sheherazade Azouigui, and Moussa Boukhni. Application and comparison of deep learning methods to detect night-time road surface conditions for autonomous vehicles. *Electronics*, Vol. 11, No. 5, p. 786, 2022.
- [43]李瑾, 阿部雅人, 杉崎光一, 中村一樹, 上石勲. Ai 技術を活用した冬季道路路面判別の効率化. *AI・データサイエンス論文集*, Vol. 1, No. J1, pp. 210–216, 2020.
- [44]竹内和也, 柴田啓司, 堀田裕弘. 道路管理用カメラを用いた冬季の路面状態判別. *電気学会論文誌 C (電子・情報・システム部門誌)*, Vol. 135, No. 7, pp. 901–907, 2015.
- [45]David Burton, Amanda Delaney, Stuart Newstead, David Logan, and Brian Fildes. Effectiveness of abs and vehicle stability control systems. Technical report, Royal Automobile Club of Victoria (RACV) Ltd, 2004.
- [46]Lan Yang, Yipeng Yang, Guoyuan Wu, Xiangmo Zhao, Shan Fang, Xishun Liao, Runmin Wang, and Mengxiao Zhang. A systematic review of autonomous emergency braking system: impact factor, technology, and performance evaluation. *Journal of advanced transportation*, Vol. 2022, No. 1, p. 1188089, 2022.
- [47]Castle Rock Consultants. *REVIEW OF THE INSTITUTIONAL ISSUES RELATING TO ROAD WEATHER INFORMATION SYSTEMS (RWIS)*. Castle Rock Consultants, 1998.
- [48]Sumbal Malik, Muhammad Jalal Khan, Manzoor Ahmed Khan, and Hesham El-Sayed. Collaborative perception—the missing piece in realizing fully autonomous driving. *Sensors*, Vol. 23, No. 18, p. 7854, 2023.
- [49]Florian A Schiegg, Ignacio Llatser, Daniel Bischoff, and Georg Volk. Collective perception: A safety perspective. *Sensors*, Vol. 21, No. 1, p. 159, 2020.
- [50]Jinzhu Chen, Donald K Grimm, Fan Bai, John Grace, Sangeeta Relan, and William Vavrik. Crowd-sensing road surface quality using connected vehicle data. *Transportation*

*Research Record*, Vol. 2675, No. 11, pp. 729–739, 2021.

- [51] Kenta Nishiyama, Masamu Ishizuki, and Teppei Mori. Strain measurement-based self-diagnosis of tire wear conditions in slow driving vehicles. In *2022 IEEE Intelligent Vehicles Symposium (IV)*, pp. 159–166, 2022.
- [52] Fabian Degenhart, Johannes Edelmann, and Manfred Plöchl. Application of tire sensors for an integrated approach to evaluate longitudinal tire characteristics for braking performance. *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering*, Vol. 235, No. 2-3, pp. 627–638, 2021.
- [53] Yann LeCun, Léon Bottou, Yoshua Bengio, and Patrick Haffner. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, Vol. 86, No. 11, pp. 2278–2324, 2002.
- [54] Francesco Barbato, Umberto Michieli, Marco Toldo, and Pietro Zanuttigh. Road scenes segmentation across different domains by disentangling latent representations. *The Visual Computer*, Vol. 40, No. 2, pp. 811–830, 2024.
- [55] Shai Ben-David, John Blitzer, Koby Crammer, Alex Kulesza, Fernando Pereira, and Jennifer Wortman Vaughan. A theory of learning from different domains. *Machine learning*, Vol. 79, No. 1, pp. 151–175, 2010.
- [56] Eldar Šabanovič, Vidas Žuraulis, Olegas Prentkovskis, and Viktor Skrickij. Identification of road-surface type using deep neural networks for friction coefficient estimation. *Sensors*, Vol. 20, No. 3, p. 612, 2020.
- [57] Tadas Baltrušaitis, Chaitanya Ahuja, and Louis-Philippe Morency. Multimodal machine learning: A survey and taxonomy. *IEEE transactions on pattern analysis and machine intelligence*, Vol. 41, No. 2, pp. 423–443, 2018.
- [58] Andrew G Howard, Menglong Zhu, Bo Chen, Dmitry Kalenichenko, Weijun Wang, Tobias Weyand, Marco Andreetto, and Hartwig Adam. Mobilenets: Efficient convolutional neural networks for mobile vision applications. *arXiv preprint arXiv:1704.04861*, 2017.
- [59] Guolin Ke, Qi Meng, Thomas Finley, Taifeng Wang, Wei Chen, Weidong Ma, Qiwei Ye, and Tie-Yan Liu. Lightgbm: A highly efficient gradient boosting decision tree. *Advances*

*in neural information processing systems*, Vol. 30, , 2017.

- [60]Leo Breiman. Random forests. *Machine learning*, Vol. 45, No. 1, pp. 5–32, 2001.
- [61]Thomas Cover and Peter Hart. Nearest neighbor pattern classification. *IEEE transactions on information theory*, Vol. 13, No. 1, pp. 21–27, 1967.
- [62]Chaitra Hegde, Zifan Jiang, Pradyumna Byappanahalli Suresha, Jacob Zelko, Salman Seyedi, Monique A Smith, David W Wright, Rishikesan Kamaleswaran, Matt A Reyna, and Gari D Clifford. Autotriage-an open source edge computing raspberry pi-based clinical screening system. *medrxiv*, pp. 2020–04, 2020.
- [63]Zhihe Zhao, Zhehao Jiang, Neiwen Ling, Xian Shuai, and Guoliang Xing. Ecrt: An edge computing system for real-time image-based object tracking. In *Proceedings of the 16th ACM Conference on Embedded Networked Sensor Systems*, pp. 394–395, 2018.
- [64]Daniel S Breland, Simen B Skriubakken, Aveen Dayal, Ajit Jha, Phaneendra K Yalavarthy, and Linga Reddy Cenkeramaddi. Deep learning-based sign language digits recognition from thermal images with edge computing system. *IEEE Sensors Journal*, Vol. 21, No. 9, pp. 10445–10453, 2021.
- [65]Raspberry Pi Foundation. Raspberry pi 4. <https://www.raspberrypi.org/products/raspberry-pi-4-model-b/>. (参照 2026-01-18).
- [66]Andrew Howard, Mark Sandler, Grace Chu, Liang-Chieh Chen, Bo Chen, Mingxing Tan, Weijun Wang, Yukun Zhu, Ruoming Pang, Vijay Vasudevan, et al. Searching for mobilenetv3. In *Proceedings of the IEEE/CVF international conference on computer vision*, pp. 1314–1324, 2019.
- [67]Isao Yamamoto, Masuo Kawana, Isao Yamazaki, Hisashi Tamura, and Yasuo Ookubo. The application of visible image road surface sensors to winter road management. In *Proceedings of the 12th World Congress and Exhibition on Intelligent Transport Systems and Services*, 2005.
- [68]中村一樹, 上石勲, 佐々木将仁, 仲条仁. 札幌市における冬期路面状況の情報収集と道路管理への適応に関する研究. 寒地技術シンポジウム 寒地技術論文・報告集, Vol. 41, p. 005, 2025.

- [69]土木研究所, 土木研究所寒地土木研究所, 北見工業大学. 路面雪氷センシング技術の高度化に関する研究 : 共同研究報告書. 共同研究報告書, 第 605 号. 土木研究所, 2025.
- [70]Aki Shigesawa, Masahiro Yagi, Sho Takahashi, Toshio Yoshii, Keita Ishii, Xiaoran Hu, Shogo Takedomi, and Teppei Mori. Winter road surface condition recognition in snowy regions based on image-to-image translation. *Sensors*, Vol. 26(1), No. 241, 2026.
- [71]Risto Ojala and Alvari Seppänen. Enhanced winter road surface condition monitoring with computer vision. *ArXiv*, Vol. abs/2310.00923, , 2023.
- [72]Nathir A Rawashdeh, Jeremy P Bos, and Nader J Abu-Alrub. Camera–lidar sensor fusion for drivable area detection in winter weather using convolutional neural networks. *Optical Engineering*, Vol. 62, No. 3, pp. 031202–031202, 2023.
- [73]Yanming Guo, Yu Liu, Theodoros Georgiou, and Michael S Lew. A review of semantic segmentation using deep neural networks. *International journal of multimedia information retrieval*, Vol. 7, No. 2, pp. 87–93, 2018.
- [74]Ian J Goodfellow, Jean Pouget-Abadie, Mehdi Mirza, Bing Xu, David Warde-Farley, Sherjil Ozair, Aaron Courville, and Yoshua Bengio. Generative adversarial nets. *Advances in neural information processing systems*, Vol. 27, , 2014.
- [75]Mingjian Wu, Tae J Kwon, and Nancy Huynh. Winter road surface condition recognition using semantic segmentation and the generative adversarial network: a case study of iowa, usa. *Transportation research record*, Vol. 2678, No. 5, pp. 184–195, 2024.
- [76]Yong Lee, presenter Wu, Mingjian, and Tae J. Kwon. Evaluating multimodal ai for winter road surface conditions monitoring: Does metadata improve classification accuracy? In *International Symposium on Transportation Data & Modelling*, 2024.
- [77]Alexey Dosovitskiy. An image is worth 16x16 words: Transformers for image recognition at scale. *arXiv preprint arXiv:2010.11929*, 2020.
- [78]Hisashi Kido, Hisaaki Masaoka, Yuji Ota, and Lu Bianli. Management of roads in winter using cctv camera. In *New Challenges for Winter Road Service. XIth International Winter Road Congress*, 2001.

- [79]Dariusz Grabowski and Andrzej Czyżewski. System for monitoring road slippery based on cctv cameras and convolutional neural networks. *Journal of Intelligent Information Systems*, Vol. 55, No. 3, pp. 521–534, 2020.
- [80]Taryn DiLorenzo and Xinbao Yu. Use of ice detection sensors for improving winter road safety. *Accident Analysis and Prevention*, Vol. 191, p. 107197, 2023.
- [81]Patrik Jonsson. Classification of road conditions: From camera images and weather data. In *2011 IEEE International Conference on Computational Intelligence for Measurement Systems and Applications (CIMS) Proceedings*, pp. 1–6. IEEE, 2011.
- [82]Mingjian Wu, Tae J Kwon, Michael Urbiztondo, Yong Lee, et al. Optimal rwis sensor density and location–phase iv. Technical report, Iowa. Department of Transportation. Aurora Program, 2024.
- [83]Yiheng Feng, John Hourdos, and Gary A Davis. Probe vehicle based real-time traffic monitoring on urban roadways. *Transportation Research Part C: Emerging Technologies*, Vol. 40, pp. 160–178, 2014.
- [84]Mariella Dreissig, Dominik Scheuble, Florian Piewak, and Joschka Boedecker. Survey on lidar perception in adverse weather conditions. In *2023 IEEE Intelligent Vehicles Symposium (IV)*, pp. 1–8. IEEE, 2023.
- [85]Hojong Lee and Saied Taheri. Intelligent tires? a review of tire characterization literature. *IEEE Intelligent Transportation Systems Magazine*, Vol. 9, No. 2, pp. 114–135, 2017.
- [86]Maria Pomoni. Exploring smart tires as a tool to assist safe driving and monitor tire–road friction. *Vehicles*, Vol. 4, No. 3, pp. 744–765, 2022.
- [87]David E Rumelhart, Geoffrey E Hinton, and Ronald J Williams. Learning representations by back-propagating errors. *nature*, Vol. 323, No. 6088, pp. 533–536, 1986.
- [88]Corinna Cortes and Vladimir Vapnik. Support-vector networks. *Machine learning*, Vol. 20, No. 3, pp. 273–297, 1995.
- [89]Takato Goto, Yasushi Hanatsuka, Tomoyuki Higuchi, and Tomoko Matsui. Road condition classification using a new global alignment kernel. In *2015 IEEE 25th International*

- Workshop on Machine Learning for Signal Processing (MLSP)*, pp. 1–6. IEEE, 2015.
- [90]Marco Cuturi, Jean-Philippe Vert, Oystein Birkenes, and Tomoko Matsui. A kernel for time series based on global alignments. In *2007 IEEE International Conference on Acoustics, Speech and Signal Processing-ICASSP'07*, Vol. 2, pp. II–413. IEEE, 2007.
- [91]Jerome H Friedman. Greedy function approximation: a gradient boosting machine. *Annals of statistics*, pp. 1189–1232, 2001.
- [92]Yoshiaki Takasaki, Miguel Saldana, Jun Ito, and Kazushi Sano. Development of a method for estimating road surface condition in winter using random forest. *Asian Transport Studies*, Vol. 8, p. 100077, 2022.
- [93]Hyunji Lee, Jiyun Kim, Kwangin Ko, Hak Han, and Minkyoo Youm. Radar-based road surface classification using range-fast fourier transform learning models. *Sensors*, Vol. 25, No. 18, p. 5697, 2025.
- [94]Karen Simonyan and Andrew Zisserman. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*, 2014.
- [95]Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 770–778, 2016.
- [96]Gao Huang, Zhuang Liu, Laurens Van Der Maaten, and Kilian Q Weinberger. Densely connected convolutional networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 4700–4708, 2017.
- [97]Jia Deng, Wei Dong, Richard Socher, Li-Jia Li, Kai Li, and Li Fei-Fei. Imagenet: A large-scale hierarchical image database. In *2009 IEEE conference on computer vision and pattern recognition*, pp. 248–255. Ieee, 2009.
- [98]George A Miller. Wordnet: a lexical database for english. *Communications of the ACM*, Vol. 38, No. 11, pp. 39–41, 1995.
- [99]Yuya Moroto, Keisuke Maeda, Ren Togo, Takahiro Ogawa, and Miki Haseyama. Multi-modal transformer model using time-series data to classify winter road surface conditions.

*Sensors*, Vol. 24, No. 11, p. 3440, 2024.

- [100] Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N Gomez, Łukasz Kaiser, and Illia Polosukhin. Attention is all you need. *Advances in neural information processing systems*, Vol. 30, , 2017.
- [101] 諸戸祐哉, 前田圭介, 藤後廉, 小川貴弘, 長谷山美紀. テキストおよび画像情報に基づく focal loss を導入した深層学習による冬期路面状態の分類. *AI・データサイエンス論文集*, Vol. 3, No. J2, pp. 293–306, 2022.
- [102] Garrett Wilson and Diane J Cook. A survey of unsupervised deep domain adaptation. *ACM Transactions on Intelligent Systems and Technology (TIST)*, Vol. 11, No. 5, pp. 1–46, 2020.
- [103] Sinno Jialin Pan and Qiang Yang. A survey on transfer learning. *IEEE Transactions on knowledge and data engineering*, Vol. 22, No. 10, pp. 1345–1359, 2009.
- [104] Jason Yosinski, Jeff Clune, Yoshua Bengio, and Hod Lipson. How transferable are features in deep neural networks? *Advances in neural information processing systems*, Vol. 27, , 2014.
- [105] Hehe Fan, Xiaojun Chang, Wanyue Zhang, Yi Cheng, Ying Sun, and Mohan Kankanhalli. Self-supervised global-local structure modeling for point cloud domain adaptation with reliable voted pseudo labels. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp. 6377–6386, 2022.
- [106] Yanwen Wu, Mingjian Hong, Ao Li, Sheng Huang, Huijun Liu, and Yongxin Ge. Self-supervised adversarial learning for domain adaptation of pavement distress classification. *IEEE Transactions on Intelligent Transportation Systems*, Vol. 25, No. 2, pp. 1966–1977, 2023.
- [107] Gustavo Rota Collegio, Aluir Porfírio Dal Poz, Antonio Gaudencio Guimaraes Filho, and Ayman Habib. Convolutional neural networks for road detection: An unsupervised domain adaptation approach. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Vol. 48, pp. 65–71, 2024.
- [108] Thomas Elsken, Jan Hendrik Metzen, and Frank Hutter. Neural architecture search: A

- survey. *Journal of Machine Learning Research*, Vol. 20, No. 55, pp. 1–21, 2019.
- [109]Mark Sandler, Andrew Howard, Menglong Zhu, Andrey Zhmoginov, and Liang-Chieh Chen. Mobilenetv2: Inverted residuals and linear bottlenecks. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 4510–4520, 2018.
- [110]Hongrong Cheng, Miao Zhang, and Javen Qinfeng Shi. A survey on deep neural network pruning: Taxonomy, comparison, analysis, and recommendations. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2024.
- [111]Amir Gholami, Sehoon Kim, Zhen Dong, Zhewei Yao, Michael W Mahoney, and Kurt Keutzer. A survey of quantization methods for efficient neural network inference. In *Low-power computer vision*, pp. 291–326. Chapman and Hall/CRC, 2022.
- [112]Jianping Gou, Baosheng Yu, Stephen J Maybank, and Dacheng Tao. Knowledge distillation: A survey. *International journal of computer vision*, Vol. 129, No. 6, pp. 1789–1819, 2021.
- [113]Tianqi Chen. Xgboost: A scalable tree boosting system. *Cornell University*, 2016.
- [114]Cees GM Snoek, Marcel Worring, and Arnold WM Smeulders. Early versus late fusion in semantic video analysis. In *Proceedings of the 13th annual ACM international conference on Multimedia*, pp. 399–402, 2005.
- [115]警視庁. ゾーン 30 とは. [https://www.keishicho.metro.tokyo.lg.jp/kotsu/doro/zone30/about\\_zone30.html](https://www.keishicho.metro.tokyo.lg.jp/kotsu/doro/zone30/about_zone30.html). (参照 2026-01-18).
- [116]David R Cox. The regression analysis of binary sequences. *Journal of the Royal Statistical Society Series B: Statistical Methodology*, Vol. 20, No. 2, pp. 215–232, 1958.
- [117]Guang-Bin Huang, Qin-Yu Zhu, and Chee-Kheong Siew. Extreme learning machine: theory and applications. *Neurocomputing*, Vol. 70, No. 1-3, pp. 489–501, 2006.
- [118]David E Rumelhart, Geoffrey E Hinton, and Ronald J Williams. Learning representations by back-propagating errors. *nature*, Vol. 323, No. 6088, pp. 533–536, 1986.
- [119]国土技術政策総合研究所. 凍結防止剤散布について（冬期道路管理）. Technical Report

国土技術政策総合研究所 研究資料, 国土技術政策総合研究所, 2006.

- [120] Jian-Shiuh Chen and Chin Hung Yang. Porous asphalt concrete: A review of design, construction, performance and maintenance. *International Journal of Pavement Research and Technology*, Vol. 13, No. 6, pp. 601–612, 2020.
- [121] 国土交通省. 道路統計年報 2024 道路の現況. <https://www.mlit.go.jp/road/ir/ir-data/tokei-nen/2024/nenpo02.html>. (参照 2026-01-18).
- [122] Anh Nguyen, Jason Yosinski, and Jeff Clune. Deep neural networks are easily fooled: High confidence predictions for unrecognizable images. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 427–436, 2015.
- [123] 竹本恒行. 高速道路における排水性舗装の現況と課題. 土木学会論文集, No. 484, pp. 1–9, 1994.
- [124] 国土交通省. 景観に配慮した道路附属物等ガイドライン. [https://www.mlit.go.jp/road/ir/ir-council/road\\_design/pdf/guidelines.pdf](https://www.mlit.go.jp/road/ir/ir-council/road_design/pdf/guidelines.pdf). (参照 2026-01-18).
- [125] Dan Hendrycks and Kevin Gimpel. A baseline for detecting misclassified and out-of-distribution examples in neural networks. *arXiv preprint arXiv:1610.02136*, 2016.
- [126] Laurens van der Maaten and Geoffrey Hinton. Visualizing data using t-sne. *Journal of machine learning research*, Vol. 9, No. Nov, pp. 2579–2605, 2008.
- [127] Chen Huang, Chen Change Loy, and Xiaoou Tang. Local similarity-aware deep feature embedding. *Advances in neural information processing systems*, Vol. 29, , 2016.
- [128] Diederik P Kingma and Jimmy Ba. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*, 2014.
- [129] Mingxing Tan and Quoc Le. Efficientnet: Rethinking model scaling for convolutional neural networks. In *International conference on machine learning*, pp. 6105–6114. PMLR, 2019.

## 著者の研究業績

### 論文（学位論文関連）

1. 石附 将武, 高橋 翔, 萩原 亨, 吉井 稔雄, 深層学習を用いた高速道路用冬期路面推定の一般道適応におけるラベル訂正, 土木学会 AI・データサイエンス論文集, 2025, 6 巻, 1 号, p. 198-207
2. 石附 将武, 高橋 翔, 萩原 亨, 石井 啓太, 岩崎 悠志, 森 徹平, 花塚 泰史, 複数の車載センサーデータを統合した冬期の路面状態の Late Fusion による推定モデル, 土木学会 AI・データサイエンス論文集, 2022, 3 巻, J2 号, p. 642-649

### 学会発表（国際会議（査読付）・学位論文関連）

1. Masamu Ishizuki, Sho Takahashi, Toru Hagiwara, Keita Ishii, Yuji Iwasaki, Teppei Mori, Yasushi Hanatsuka, "Image and CAIS Features-Based Estimation of Road Surface Condition on Winter Local Road," 2022 IEEE 11th Global Conference on Consumer Electronics (GCCE), Osaka, Japan, 2022, pp. 79-80

### 学会発表（国内会議・学位論文関連）

1. 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 年 11 月

### 表彰

1. 土木学会構造工学研究会 AI・データサイエンス論文集編集小委員会 AI・データサイエンス論文賞

### 論文（その他）

1. Hiroki Kinoshita, Sho Takahashi, Toru Hagiwara, Shinobu Azuma, Yuji Iwasaki, Teppei Mori, Yasushi Hanatsuka, Masamu Ishizuki, Road surface condition estimation

throughout the day and night by late-fusion using the confidence levels of multiple classifiers, *Intelligence, Informatics and Infrastructure*, 2024, Volume 5, Issue 1, Pages 72–79.

2. Keita Ishii, Shunsuke Ono, Takeshi Masago, Masamu Ishizuki, Teppei Mori and Yasushi Hanatsuka, "Fine-Scaled Predictive Modeling of Road Surface Conditions and Temperature in Urban Areas," in *IEEE Transactions on Intelligent Transportation Systems*, vol. 25, no. 11, pp. 17122-17133, Nov. 2024
3. Masamu Ishizuki, Hannyo Takemiya, Takuma Okunishi and Kyozaaburo Takeda Shape of polygonal quantum dots and ground state-instability in the spin polarization, *Physical Review B*. 85,155316 (2012).
4. Tomoki Tagawa, Atsushi Tsubaki, Masamu Ishizuki, and Kyozaaburo Takeda; Self-induced oscillation for electron-hole pair confined in quantum dot, *AIP Conference Proceedings*, **1399**, 365 (2011).
5. Yhuki Negishi, Masamu Ishizuki, Atsushi Tsubaki, Kyozaaburo Takeda, Yusuke Asari, Takahisa Ohno; Singlet-triplet ground-state instability in square quantum dot, *AIP Conference Proceedings*, **1399**, 497 (2011).
6. Yhuki Negishi, Masamu Ishizuki, Takuma Okunishi and Kyozaaburo Takeda; Ground state instability in spin polarization for electrons confined in 2D square quantum dots, *Japanese Journal of Applied Physics*, **50**, 085001 (2011).

## 学会発表（その他）

1. K. Nishiyama, M. Ishizuki and T. Mori, "Strain Measurement-based Self-Diagnosis of Tire Wear Conditions in Slow Driving Vehicles," 2022 IEEE Intelligent Vehicles Symposium (IV), Aachen, Germany, 2022, pp. 159-166