



Title	道路空間モニタリングのための骨格動作分析に基づくエッジコンピューティングに関する研究
Author(s)	八木, 雅大
Citation	北海道大学. 博士(工学) 甲第15852号
Issue Date	2024-03-25
DOI	10.14943/doctoral.k15852
Doc URL	<a href="http://hdl.handle.net/2115/91758">http://hdl.handle.net/2115/91758</a>
Type	theses (doctoral)
File Information	Masahiro_Yagi.pdf



[Instructions for use](#)

道路空間モニタリングのための骨格動作分析に基づく  
エッジコンピューティングに関する研究

A Study on Edge Computing for Road Monitoring Based on Human Motion Analysis

八木 雅大

北海道大学大学院工学院

2024年2月

# 道路空間モニタリングのための骨格動作分析に基づく エッジコンピューティングに関する研究

## 目 次

第 1 章 序論	1
1.1 サイバーフィジカルシステム	1
1.2 サイバーフィジカルシステムにおけるデータの集積と分析	1
1.2.1 従来のアーキテクチャとその課題	1
1.2.2 課題解決のための方策	3
1.3 より安全に移動可能な道路空間のためのモニタリング	4
1.3.1 人や車両の移動を妨げる要因の観測とその課題	5
1.3.2 人や車両の通常とは異なる走行のモニタリング	6
1.3.3 複数物体の関係性評価	7
1.3.4 個体同士の主体と従属の評価	7
1.4 本論文の目的	8
1.5 本論文の内容と構成	9
第 2 章 関連研究	12
2.1 はじめに	12
2.2 サイバーフィジカルシステムの起源と定義	12
2.3 サイバーフィジカルシステムの具体的な取り組み	16
2.3.1 道路空間を対象とした CPS	16
2.3.2 建設現場を対象とした CPS	16
2.3.3 農業現場を対象とした CPS	18
2.4 土木に関わる IoT や DX の取り組み	19
2.5 エッジコンピューティングとサイバーフィジカルシステム	21
2.6 画像・映像を用いた実空間モニタリング	26
2.6.1 深層学習に基づく物体認識・追跡および骨格推定の手法	26
2.6.2 機械学習に基づく道路空間を含む実空間の状況認識	28
2.6.3 物体の移動における主体と従属の関係に関する研究	29
2.7 本論文で解決すべき課題とその解決方法	30
2.8 まとめ	31

<b>第3章 映像解析による骨格情報に基づく個人の動作分析</b>	<b>32</b>
3.1 はじめに	32
3.2 特徴量の算出	34
3.2.1 サイクリストの関節位置に基づく特徴量の算出	34
3.2.2 オプティカルフローに基づく特徴量の算出	34
3.3 複数識別器の確信度を用いた識別	36
3.3.1 SVMの構築および確信度の算出	36
3.3.2 ELMの構築および確信度の算出	37
3.3.3 SVMおよびELMから得られる識別結果に対する確信度に基づく識別	37
3.4 実験	38
3.4.1 実験条件	38
3.4.2 実験結果	41
3.5 道路映像における姿勢推定に基づく二輪車識別の検討	47
3.5.1 運転者の姿勢や運動に関する画像・映像特徴	47
3.5.2 実験	48
3.6 一般物体認識と姿勢推定に基づく二輪車の識別手法	51
3.6.1 一般物体認識と姿勢推定に基づく二輪車の識別	51
3.6.2 実験	55
3.7 まとめ	58
<b>第4章 道路空間モニタリングのためのエッジコンピューティング基盤とその応用</b>	<b>59</b>
4.1 はじめに	59
4.2 自転車の走行に関するデータ集積機構	63
4.3 集積されるデータ	65
4.4 実験	66
4.5 冬期の道路状況を観測するエッジコンピューティング基盤	71
4.5.1 路面状態および視界状況を推定する手法	72
4.5.2 エッジコンピューティングによる路面および視界のデータ集積機構	72
4.5.3 都市間バスおよび道路パトロールカーでの実運用	76
4.6 活性化ベクトルの類似度に基づくエッジ選択	86
4.6.1 類似度の計算に基づくエッジ選択	87
4.6.2 実験	91
4.7 まとめ	100

第5章 複数人物の骨格情報に基づく動作の連関の定量評価	101
5.1 はじめに	101
5.2 複数人物の主体および従属の評価	102
5.2.1 関節位置の移動量に基づく動作データの算出	102
5.2.2 DTW によるアラインメント	103
5.2.3 アラインメント結果に基づく動作の主体と従属の評価	104
5.3 実験	108
5.4 複数人物の連動性評価	112
5.4.1 連動性評価	112
5.4.2 実験	113
5.5 まとめ	115
第6章 結論	116
6.1 本論文の総括	116
6.2 本研究の今後の課題	117
謝辞	118
Appendix	118
参考文献	134
著者の研究業績	151

## 図目次

図 1	サイバーフィジカルシステムにおけるデータの集積・分析	2
図 2	本研究における課題とその解決策および章構成の関係	11
図 3	自転車がまっすぐでない走行を強いられる道路状況の例	33
図 4	提案手法の概要.	33
図 5	OpenPose による骨格データの取得：(a) OpenPose による骨格データの取得結果を重畳表示した図, (b) OpenPose により取得する関節	35
図 6	関節位置の近傍の画素からなる部分画像の取得	36
図 7	まっすぐな走行のビデオクリップの例	40
図 8	まっすぐでない走行のビデオクリップの例	40
図 9	提案手法により, まっすぐな走行と正しく識別された例	45
図 10	提案手法により, まっすぐでない走行と正しく識別された例	45
図 11	図 6 に示す方法によって抽出された自転車周辺の領域の例	46
図 12	提案手法により識別された, サイクリスト 3 のまっすぐな走行の例	48
図 13	OpenPose に基づく映像特徴	48
図 14	Gabor wavelet に基づく画像特徴の可視化	49
図 15	自動二輪車における膝と腰を結ぶ線の水平方向からの角	50
図 16	自転車における膝と腰を結ぶ線の水平方向からの角	50
図 17	姿勢推定に基づき二輪車を識別する手法の概要	52
図 18	角 A,B,C	53
図 19	実験に用いた道路映像の例	56
図 20	OCSVM で歩行者と判定された例	56
図 21	自転車の走行に関するデータ集積機構の概要	60
図 22	道路のひび割れを検出し, 地図上で可視化した例. (文献[96]より抜粋.)	62
図 23	自転車の走行に関するデータ集積機構の構成図	64
図 24	データ集積機構の試作機	66
図 25	都市間バスに設置した様子	74
図 26	道路パトロールカーに設置した様子	75
図 27	データ集積機構の操作画面の例 (リモートアクセス)	78
図 28	都市間バスに実装したデータ集積機構が路面状態を推定した結果の例 1	79
図 29	都市間バスに実装したデータ集積機構が路面状態を推定した結果の例 2	80
図 30	都市間バスに実装したデータ集積機構が路面状態を推定した結果の例 3	81
図 31	道路パトロールカーに実装したデータ集積機構が視界状況を推定した結果の例 1	82
図 32	道路パトロールカーに実装したデータ集積機構が視界状況を推定した結果の例 2	83
図 33	集積した視界状況の分析結果を地図上に可視化した例	84

図 34	集積した路面状態の分析結果を地図上に可視化した例	85
図 35	活性化ベクトルの類似度に基づくエッジ選択手法の概要	88
図 36	積雪寒冷地における 3 種類の道路状態の例	92
図 37	データセットを作る 4 つの地域	92
図 38	実験で用いるエッジ AI のアーキテクチャ	93
図 39	OpenPose により位置座標を取得可能な関節	103
図 40	DTW により求まるワーピングパスの例 1 (対応する要素に時間の違いがある場合)	106
図 41	DTW により求まるワーピングパスの例 2 (対応する要素に時間の違いが無い場合)	106
図 42	DTW により求まるワーピングパスの例 3 (対応する要素に時間の違いがある場合)	107
図 43	本実験で分析対象とする作業員	109
図 44	本実験で分析対象とする作業員が作業位置を移動する様子	110
図 45	建設現場映像に対して OpenPose を適用した結果の例	111
図 46	作業員 A を軸とした場合の作業員 B の関係を提案手法により分析した際の ワーピングパスの結果	111
図 47	OpenPose により求める“Neck”の座標を用いて計算した DTW 距離の推移	114

## 表目次

表 1	サイクリストの関節位置に基づく特徴量	35
表 2	実験で用いるデータセットの内訳	39
表 3	各手法におけるラベル”まっすぐな走行”の再現率 (R), 適合率 (P) および F 値 (F)	43
表 4	各手法におけるラベル”まっすぐでない走行”の再現率 (R), 適合率 (P) および F 値 (F)	44
表 5	OCSVM で用いたデータ数	55
表 6	識別器で用いたデータ数	55
表 7	実験結果	57
表 8	SVM で用いるデータ数	57
表 9	Raspberry Pi 4 の主な仕様	65
表 10	各システムにおけるフレームの取得から最終的な認識結果を取得するまでの 計算時間	69
表 11	各機構を用いて集積するデータの内容	69
表 12	各機構における処理毎の計算時間	70
表 13	データ集積機構を構成する各パーツの仕様	72
表 14	実験で用いるデータセットの詳細	92
表 15	提案手法によるエッジ同士の類似度に基づく順序付け	94
表 16	比較手法 1 によるエッジ同士の類似度に基づく順序付け	94
表 17	比較手法 2 によるエッジ同士の類似度に基づく順序付け	94
表 18	エッジ A(深川-留萌自動車道)が各エッジを選択し更新した結果の統計値	96
表 19	エッジ A(深川-留萌自動車道)が各エッジを選択し更新した結果の混合行列	96
表 20	エッジ D(幌延-留萌の街中以外)が各エッジを選択し更新した結果の統計値	97
表 21	エッジ D(幌延-留萌の街中以外)が各エッジを選択し更新した結果の混合行列	97



# 第1章 序論

## 1.1 サイバーフィジカルシステム

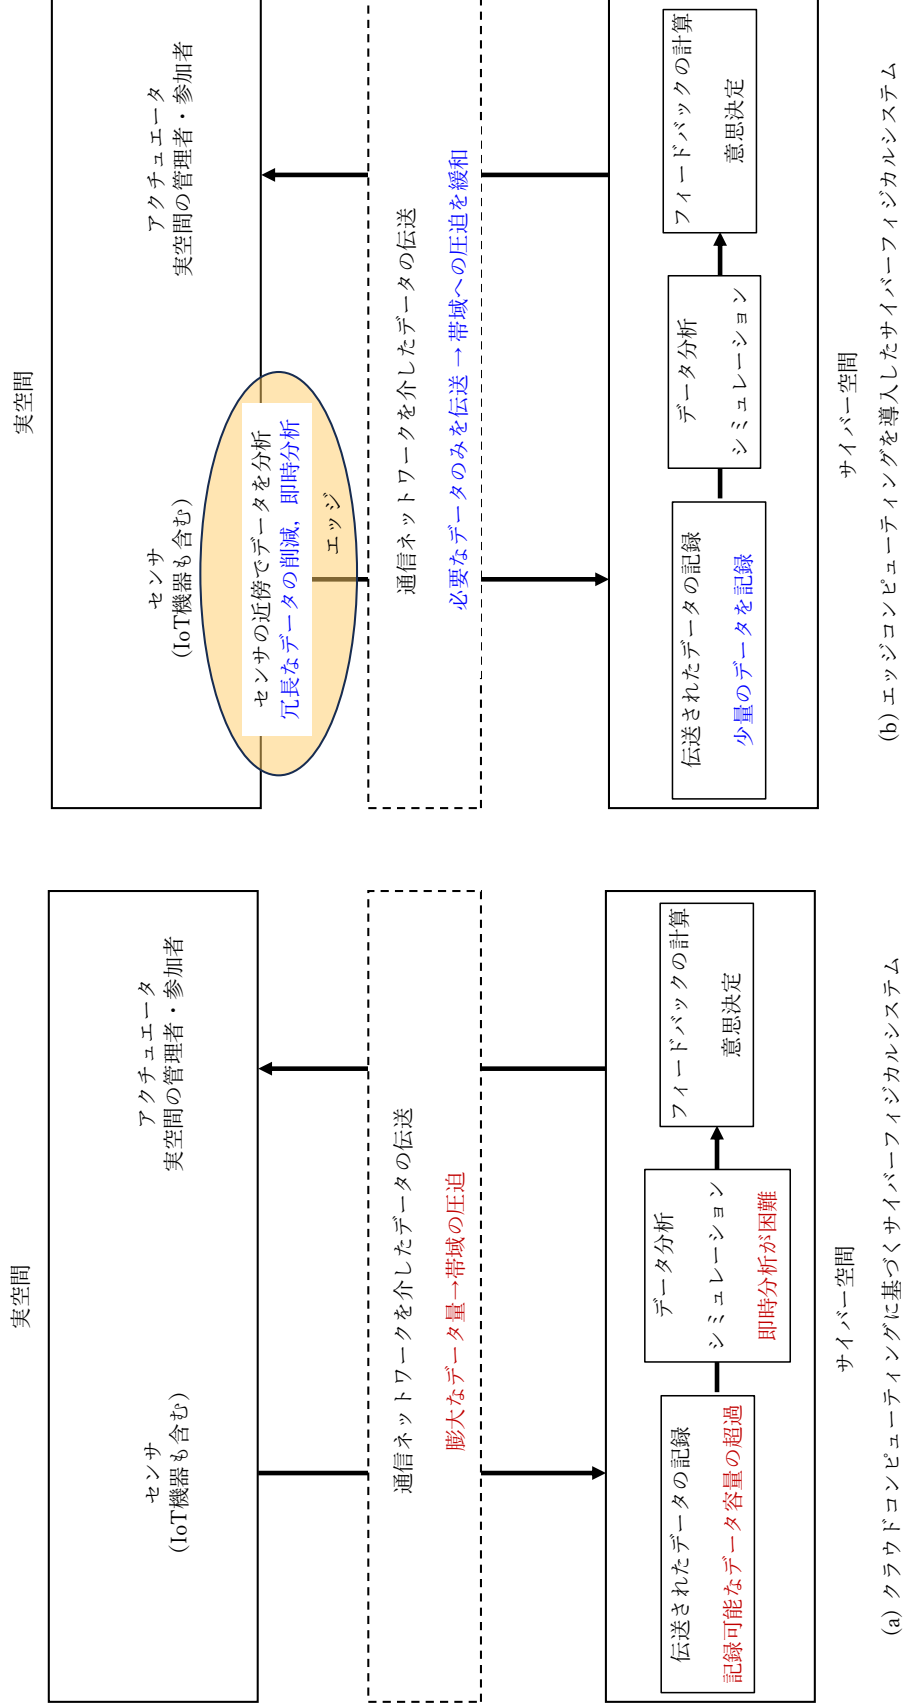
近年、情報通信技術やセンサ技術の発展に伴い、通信ネットワークを介して実空間とサイバー空間を融合する仕組み[1,2]が普及しつつある。このような仕組みの一つとして、サイバーフィジカルシステム[1,32-46]が大きな注目を集めている。サイバーフィジカルシステムでは、実空間をセンシングして取得するデータを、通信ネットワークを介してサイバー空間へ伝送する。サイバー空間では、実空間から伝送されるデータの分析や蓄積された過去データに基づくシミュレーションなどが行われ、それらの結果に基づいて、サイバー空間から実空間へフィードバックが行われる。この一連のプロセスを繰り返し行うことで、実空間を効果的かつ効率的に管理・制御する。サイバーフィジカルシステムは、例えば、道路空間、建設現場、工場、農業現場など、多種多様な空間に対して適用可能な仕組みであり、様々な分野でその取り組みが行われている[9-12,47-49,101]。

## 1.2 サイバーフィジカルシステムにおけるデータの集積と分析

### 1.2.1 従来のアーキテクチャとその課題

サイバーフィジカルシステムを実現するためには、実空間を常にモニタリングする必要がある。実空間をモニタリングするためには、実空間をセンシングして取得するデータを分析する必要がある。従来のシステムは、図1の(a)に示すように、センサにより取得するデータをクラウドで一元的に記録・分析するクラウドコンピューティング[3]の仕組みを採用する場合が多い。

ここで、近年、インターネットや各種センサ技術の発展により、IoT (Internet of Things) が急速に普及している[4]。この傾向は、第五世代無線通信 (5G) の進展により、より一層加速すると考えられる。これはすなわち、画像や動画などの大容量データが、ネットワークを介して多数やりとりされるようになると予想されるものである。International data company Internet Data Center (IDC)は、2025年に全世界で生成されるデジタルデータの総量を163ゼタバイトと予想しており、これは2016年に生成されたデータ量(16.1ゼタバイト)の約10倍の量である[5]。仮に163ゼタバイトのデータ全てを12TBのHDDに記録すると仮定した場合、必要なHDDの個数は約160億個となる。このような状況では、生成されるデータ量が、記録可能なデータ容量を超過する可能性がある。また、通信ネットワークが許容できるデータ量や帯域には限りがあり、IoT機器の増加に伴ってデータ転送



(a) クラウドコンピューティングに基づくサイバー空間システム

(b) エッジコンピューティングを導入したサイバー空間システム

図 1 サイバー空間システムにおけるデータの集積・分析

量が増加した場合には、帯域があふれる可能性がある[6]。これは、5G の環境においても同様であり、各種 IoT 機器の通信障害が発生する恐れがある。また、全てのデータが通信ネットワークを介してクラウドに伝送され、クラウドに記録される膨大な量のデータを順次分析する仕組みでは、データの即時分析が困難である[102]。これは、例えば、実空間の異常を即時に検知して、アラートや作動中の機械に停止命令を送る場合のような、速報性が求められるタスクを実行する上では望ましくない。

土木業界においても、IoT や DX（デジタルトランスフォーメーション）の取り組みが行われ始めている。例えば、CCTV カメラにより取得された道路を撮像した映像（以下、道路映像）の多くが、通信ネットワークを経由して、道路管理者の元へ集積されている。これにより、効果的・効率的な道路状況の把握を実現している。しかしながら、それらの多くは道路映像を取得された画のままに集積されているため、データの転送・保存の容量が膨大である。CCTV カメラだけでなく、道路パトロールカーに搭載されたカメラによって取得される映像を伝送・記録し、道路状況を把握するために活用する取り組みも進められている[25,26]。また、橋梁やトンネルなどのインフラ施設を自動で点検可能とすることを目的として、インフラ施設を撮影した画像を AI によって分析する取り組みが数多く行われている[135-137]。これらのように、土木業界においても、IoT や DX の取り組みが行われ始めており、この傾向は今後より一層加速すると考えられる。これはすなわち、画像や映像などの大容量データが、ネットワークを介して多数やりとりされ、加えて、膨大な量のデータを蓄積することになると予想されるものである。しかしながら、先に述べたとおり、通信ネットワークが許容できるデータ量や帯域には限りがあり、伝送するデータ量が増加した場合には、帯域があふれる可能性がある。また、全てのデータを保存し続けることは現実的ではないため、現状のように膨大な量のデータを蓄積し続けるシステムでは、過去のデータを削除せざる負えない状況に陥る可能性が高い。

以上のように、従来のクラウドコンピューティングに基づくデータ集積・分析の仕組みでは、通信ネットワークを介した伝送や保存のためのデータ量が膨大である。これは、センサや IoT 機器の増加に伴い、その影響はより一層大きくなると予想されるものであり、喫緊の課題である。

## 1.2.2 課題解決のための方策

1.2.1 に示した課題の解決方法としては、データ生成源付近にエッジサーバを設置する仕組みが有効であると考えられる。具体的には、データの生成源に近い場所でそのデータを分析し、冗長なデータを除外することで、データの転送量を削減可能とするコンピューティングの方法である。一般的に、データ生成源の近傍（エッジ）でデータを処理する方法をエッジコンピューティング[7,99-103]と呼び、近年、様々な分野への導入が検討されている。図 1 の(b)に示すように、実空間に設置されるセンサの近傍（エッジ）において、センサによ

り取得されるデータを分析し、データ量を削減しながら必要なデータのみをサイバー空間へ伝送する機構を確立することで、1.2.1 で述べた課題の解決が期待できる。そこで、本論文では、サイバーフィジカルシステムにおける実空間モニタリングのためのエッジコンピューティングについて検討する。具体的には、道路を対象として、道路空間をモニタリング可能とするためのエッジコンピューティングについて検討する。

### 1.3 より安全に移動可能な道路空間のためのモニタリング

本論文では、道路空間をモニタリング可能とするためのエッジコンピューティングについて検討する。道路に求められる機能の一つは、人や車両が安全に移動可能な空間を確保することである。サイバーフィジカルシステムによって、この機能を実現するためには、道路が安全に移動可能な空間となっているかどうかを常にモニタリングする必要がある。ここで、人や車両が移動する様子が通常とは異なる場合、事故などの命に係わる危険な事象が発生する可能性が高い。また、命に係わる事象ではないが、本来想定した通りに移動が為されていない場合には、例えば、遅れ時間が長くなることなどの影響が考えられる。したがって、より安全に移動可能な道路空間を確保するためには、道路空間を常にモニタリングすることで、人や車両が移動する様子が正常ではない状態あるいはその要因を即時に把握して、適切に対応する必要がある。

ここで、近年、各種カメラの小型化・低価格化が進み、多様な分野において映像による記録や撮像された環境の解析・分析が試みられるようになってきている。カメラを用いた実空間の観測は、人や機械などの観測対象の物体にセンサを装着する必要がなく、さらには、広範囲に実空間を観測可能である。サイバーフィジカルシステムにおいても、映像を用いた空間分析を導入する取り組みが行われている[12,13]。このような背景から、人や車両がより安全に移動可能となるサイバーフィジカルシステムの実現に向けて、映像を用いた空間分析に基づき道路空間をモニタリング可能とすることが望ましい。

これを実現するためには、主に二つの要素技術が求められる。一つはエッジで得られる映像を解析する軽量の映像解析理論の導出である。エッジで駆動する計算機は、電力や設置スペースなどが限られた環境で駆動することが想定される。したがって、例えばマイクロコンピュータなどの計算能力が限られたデバイスにおいても実利用可能な時間で計算可能な軽量の映像解析の理論を導出する必要がある。二つ目は、電力や設置スペースが限られた環境で駆動可能なエッジコンピューティング基盤の構築である。エッジで得られる映像を解析しながら冗長なデータを削減し、必要なデータのみをサイバー空間へ伝送可能なエッジコンピューティング基盤を構築することが必要である。

### 1.3.1 人や車両の移動を妨げる要因の観測とその課題

本論文では、サイバーフィジカルシステムを数多くの人や車両が移動する道路空間に適用することを考える。期待される効果の一つとして、人や車両が通常どおりに移動可能な走行空間を常に確保することが挙げられる。これを実現するためには、道路空間を常にモニタリングすることで、人や車両が通常どおりに移動可能な空間になっているかどうかを把握可能とする必要がある。

ここで、映像や画像を用いた実空間モニタリングに関する研究として、近年、深層学習などの機械学習に基づき画像・映像から物体を認識・追跡する手法[14,15,18, 19]や人間の骨格位置を推定する手法[16,17]などが数多く提案されている。さらには、これらの手法を応用することで得られる物体の位置や移動軌跡などの基礎的なデータに基づいて、人や機械の危険な振る舞いを認識する取り組みが行われている[20,21,22]。以上のように、画像や映像から物体とその動きを深層学習などの機械学習に基づき観測する取り組みが数多く行われている。機械学習の中でも特に深層学習に関する研究が活発に行われている。深層学習は多層のニューラルネットワークによる機械学習手法であり、入力データと対応する出力ラベルの組を用いて入力データの特徴を学習することで、隠れ層のパラメータが決定される。深層学習の精度向上には、一般に多数の隠れ層が必要であり、最適に決定すべきパラメータ数が多くなるため、大量の学習データが必要となる。例えば、深層学習に基づき画像から物体を精度よく認識可能とするためには、事前に認識対象の物体が撮像された大量の画像データを準備する必要がある。物体認識のためのオープンデータセットとして広く活用される COCO データセット[23]には、各物体に対して 5000 枚以上の画像が含まれている。このように、深層学習に基づき空間を行き交う物体やその動作を正確に認識可能とするためには、膨大な数の教師有りデータが必要となる。しかしながら、全ての物体や動作に対して大量の教師有りデータを準備することは現実的ではない。深層学習に基づく物体検出モデルとして広く活用される Yolov4[24]であっても、その認識可能な物体は約 80 種類である。したがって、現状の深層学習モデルで認識可能な物体や動作の種類は限られており、将来的にも、全ての物体やその動作を深層学習に基づいて認識可能とすることは困難であると考えられる。

数多くの人や車両が混在する道路空間では、多種多様な物体や状態が人や車両の移動を妨げる要因となる。そのため、移動を妨げる要因全てを事前に想定して、膨大な量の学習データを準備することは難しい。したがって、映像解析の分野で幅広く導入されている深層学習などの機械学習によって、移動を妨げる物体や状態全てを精度良く検出することは極めて困難であり、移動を妨げる要因そのものを観測する仕組みだけでは、人や車両が通常どおりに走行可能な空間となっているかどうかを把握することは不可能である。

### 1.3.2 人や車両の通常とは異なる走行のモニタリング

1.3.1 で述べたように、人や車両の走行を妨げる全ての物体や状態に対して大量のデータを準備することが難しいことから、機械学習に基づいて、移動を妨げる要因全てを精度良く検出することは困難である。この問題の解決策として、人や車両が通常どおりに走行することが困難な様子を分析することを試みる。人や車両の通常とは異なる走行を観測した結果を積み上げることで、走行を妨げる物体や状態が存在する箇所を効率的に把握可能となることが期待できる。具体的には、分散配置されたエッジコンピューティング基盤を用いて、人や車両の通常とは異なる走行を観測した結果をサイバー空間に伝送する。サイバー空間では、各エッジから伝送されるデータを集約して可視化する。最後に、可視化した結果を管理者や利用者にフィードバックする。このプロセスを繰り返すことで、人や車両が通常どおりに走行可能な空間になっているかどうかを常に把握した対応が可能となることが期待できる。また、エッジコンピューティングを導入することで、伝送や保存ためのデータ量が削減可能となるだけでなく、即時分析が可能となり、これはより安全な移動空間の実現に貢献する。

人や車両の走行する様子を観測するためにはまず、その動作を行う物体を認識する必要がある。ここで、道路空間の基本的な参加者の種類には限りがある。道路空間では、歩行者、自動車、自転車および自動二輪車などが基本的な参加者であるが、それらの物体は、一般的な物体認識モデルの認識対象である。したがって、道路を走行する様子をモニタリングする物体については、その種類が限られていることから、将来的には高精度に認識可能となることが期待できる。

そこで、本論文では、人や車両の通常とは異なる走行を映像から観測し、その観測データを積み上げることで、通常どおりに走行することが困難な箇所を把握可能とすることを目指す。これにより、転倒や接触事故のリスクが潜在的に高い危険な箇所を把握した管理が可能となり、これは事故などを未然に防ぐことに繋がる。本論文では、具体的に、① 道路空間の基本的な参加者の一つである自転車の動きを映像から認識する手法の導出、および② 自転車の走行に関するデータ集積を可能とするエッジコンピューティング基盤の構築に取り組む。自転車は、通常時には、まっすぐに走行することが多い物体であることから、通常時と異常箇所を走行する場合との間で、その振る舞いに大きな違いがあると考えられる。したがって、初期検討として、本論文の分析対象とした。

### 1.3.3 複数物体の関係性評価

1.3.2 では、物体個々の通常とは異なる行動を観測した結果を積み上げることで、道路空間が通常どおりに移動可能な空間となっているかどうかを把握可能とする。ここで、数多くの人や車両が混在する道路空間で発生する危険な事象の多くは、例えば、歩行空間における群衆事故や車群現象による多重追突事故など、複数の人や車両が互いに関与している。したがって、人や車両がより安全に移動可能となるサイバーフィジカルシステムを実現するためには、個々の動きを分析するだけでなく、物体同士の関係性を分析可能とする必要がある。

### 1.3.4 個体同士の主体と従属の評価

複数の人や車両から構成される集団の行動には、多くの場合に、個体同士の主体と従属の関係がみられる。例えば、道路空間に形成される車群においては、追従車両は先行車両の動きに大きく影響される。また、文献[29]では、歩行者集団の動きを説明する要素として、各歩行者の間に存在するリーダーとそれに従うフォロアの関係性が重要な役割を持つとしている。また、文献[30,31]では、複数台の協調ロボット群を制御する方法として、リーダーとそれに従うフォロアを設定する手法が多く存在する[30,31]。このように、実空間において、各個体が互いに影響を及ぼし合う集団では、個体同士の主体と従属の関係がみられる。この関係性を乱す個体が存在する状況は、安全性の観点で望ましくない。例えば、歩行者集団は、周囲の人間の動きを予測することで互いに衝突することを回避しているが、集団を乱す個体が現れた場合、通常どおりに振る舞うことが難しく、衝突する可能性が高くなる。

そこで、本論文では、複数の人間が活動する実空間を撮影した映像を対象として、③映像から人の主体と従属の関係を定量化する手法の導出に取り組む。例えば、安全性が高い理想的な状態の空間に対して、本論文で提案する手法を用いて各個体の主体と従属の関係を定量化し、その分析結果をサイバー空間に積み上げる。ここで、理想的な状態とは、人間が通常どおりに動作している状態である。この積み上げたデータを学習する機械学習などの識別器を構築することで、安全性の観点で理想的な空間との乖離度合が把握可能となることが期待できる。ここで、理想的な状態と乖離がある状態とは、人が通常どおりに動作できていない状態である。

また、エッジコンピューティングを導入することは、保存や伝送のためのデータ量の削減に繋がるだけでなく、クラウドの集中処理を避けることにも繋がる。近年、道路管理などにおいて、サイバーフィジカルシステムやデジタルツインなどの取り組みが行われ始めており、今後、そのような取り組みが広がっていくことが予想される。したがって、伝送されるデータ量およびクラウドに求められるタスクの量を可能な限り軽減する必要があると考えられ、本論文におけるエッジコンピューティングの取り組みはその解決策の一つとなることが期待される。

## 1.4 本論文の目的

1.2 で述べたように、サイバーフィジカルシステムにおける実空間のモニタリングにおいて、エッジコンピューティングを導入する必要がある。また、1.3 で述べたように、サイバーフィジカルシステムを人や車両が移動する道路空間に適用する場合、人や車両が通常どおりに移動可能な空間になっているかどうかを常に把握可能とする必要がある。ここで、移動を妨げる物体や状態は多種多様であることから、その全てに対して大量のデータを準備することが困難であり、映像解析の分野で幅広く導入されている機械学習に基づく手法によって、その全てを精度良く検出することは困難である。そこで、本論文では、人や車両の通常とは異なる走行をモニタリングすることで、道路空間の状況を把握可能とする。また、複数の人や車両が混在する空間で発生する危険な事象の多くは、複数の物体が互いに関与している。そのため、個々の動きを分析するだけでなく、物体同士の関係性を分析する必要がある。複数の人や車両が混在する空間では、多くの場合に、個体同士の主体と従属の関係がみられる。この関係性を乱す個体が存在する状況は、安全性の観点で望ましくない。

このような背景から、本論文では、まず、① 道路空間の基本的な参加者の一つである自転車の通常とは異なる走行を映像から認識する手法の導出に取り組む。人や車両が通常どおりに移動可能な安全な道路空間を確保するための研究の多くは、例えば、障害物や路面の劣化などの移動を妨げる物体や状態を把握可能とすることに取り組んでいる。一方で、本論文は、移動を妨げる要因そのものではなく、物体が通常どおりに走行できない様子を観測した結果を積み上げることで、安全に移動可能な空間となっているかを評価する取り組みであり、道路空間を評価する新たなモニタリング手法となることが期待できる。次に、② エッジコンピューティングによって、自転車の走行に関するデータを集積可能とする機構を構築する。本論文では、車両や各種インフラ設備で駆動可能な小型計算機と外部演算装置によって構成されるエッジコンピューティング基盤を構築し、計算に要する時間や削減可能なデータ量を明らかにする。加えて、本論文で構築するエッジコンピューティング基盤が必要とする計算時間や削減可能なデータ容量が、実利用の観点で十分なものであるかを議論する。1.2.1 で述べたとおり、近年、土木業界において、IoT や DX の取り組みが行われ始めており、大容量のデータが通信ネットワークを介して伝送・蓄積されている。しかしながら、通信ネットワークが許容できるデータ量や帯域に限りがある。加えて、保存可能なデータ容量にも限りがある。このような課題の解決に向けて、エッジコンピューティングを導入することが有効な手段の一つである。しかしながら、土木工学の分野では、エッジコンピューティング基盤を構築し、その実現可能性について議論する取り組みはほとんど行われておらず、喫緊の課題である。本論文の取り組みは、道路空間をモニタリング可能とするためのエッジコンピューティング基盤を構築し、その実現可能性について、計算時間やデータ容量の観点で議論するものであり、今後の土木工学におけるエッジコンピューティングの発展に貢献することが期待できる。最後に、複数の人間が活動する実空間の映像を対象として、



③ 映像から複数人物の主体と従属の関係を定量化する手法の導出に取り組む。複数人物の動きや関係性を映像から分析する研究は、スポーツ映像を対象とした空間分析等において、活発に取り組まれているが、道路などの土木に関わる空間を分析対象とした取り組みは少なく、土木工学の分野における映像を用いた空間分析の発展に貢献することが期待される。

## 1.5 本論文の構成と内容

本研究における課題とその解決策および章構成の関係を図 2 に示す。本論文は 6 章から成り、以下に各章の概要を述べる。第 1 章では、本論文の背景と解決すべき課題について述べた。第 2 章では、本論文に関係する既存研究を説明する。第 3 章では、映像から自転車の通常とは異なる走行を認識可能とする手法を提案する。具体的には、深層学習に基づく姿勢推定を適用することで取得するサイクリストの骨格位置に基づいて自転車の走行を分析する。また、自転車の走行を分析するためには、前段階として、映像から自転車を認識する必要がある。そこで、第 3 章では、姿勢推定に基づいて映像から自転車を認識可能とする手法についても検討する。以上のように、第 3 章では、映像解析による骨格情報に基づく個人の動作分析に取り組む。第 4 章では、自転車の通常とは異なる走行に関するデータ集積を可能とするエッジコンピューティング基盤を提案する。具体的には、小型計算機と外部演算装置から構成されるデータ集積機構を構築し、計算時間やデータ容量について、その実現可能性を議論する。特に、深層学習に基づく姿勢推定の計算は比較的成本が大きく、計算に時間を要することから、エッジにおいて実利用可能な時間で計算可能かどうかを確認する。また、第 4 章では、構築する自転車の走行を分析するエッジコンピューティング基盤を発展させ、他の土木工学に応用することに取り組む。本論文は、より安全に移動可能な道路空間の実現に向けたモニタリングのためのエッジコンピューティングに関して検討しているが、積雪寒冷地の冬期道路では、移動を妨げる路面や視界が頻繁に観測される。そこで、冬期道路における路面や視界を映像解析および機械学習に基づき分析し、その分析結果を集積可能とするエッジコンピューティング基盤を構築する。また、第 4 章で構築する二つのエッジコンピューティング基盤は共に、機械学習に基づく AI によって映像を解析する。汎化性に優れた AI を実現するためには、個々のエッジが獲得する知識を共有しながら逐次的に AI を更新する必要がある。そこで、第 4 章の最後には、エッジで活用する AI の更新に有効なデータを有する他のエッジを選択する手法の導出に取り組む。以上のように、第 4 章は、道路空間モニタリングのためのエッジコンピューティング基盤とその応用に関する取り組みである。第 5 章では、複数人物の主体と従属の関係を評価可能とする映像解析の手法を提案する。具体的には、骨格位置に基づく時系列の動作データに対して要素の対応付けを行い、対応付けされた要素の時間差に着目した評価関数を定義する。また、第 5 章で提案する手法は、人物同士が連動している状況を前提としている。そこで、第 5 章の最後には、映像から人物

同士が連動しているかどうかを評価可能とする手法の構築に取り組む。以上のように、第5章では、複数人物の骨格情報に基づく動作の連関の定量評価に取り組む。第6章では、本論文の成果を要約し、論文全体のまとめを行う。

以上のように、第3章から第5章では、一貫して骨格情報に基づいて人の動作を分析する。第3章では、骨格情報に基づく個人の動作分析手法を提案し、第4章では、エッジにおいて骨格推定に必要な計算時間を確認する。第5章では、第4章において骨格推定に必要な計算時間を確認した結果に基づいて、エッジにおいて実利用可能な時間で計算可能な骨格情報に基づく人の動作分析手法として、複数人物の連関を分析する手法を提案する。したがって、第3章から第5章は、骨格情報に基づく映像解析によって人の動作を分析するエッジコンピューティングに関して取り組むものであり、本論文によって、個人の動作に関するデータ集積および複数人物の連関の定量化が可能となる。

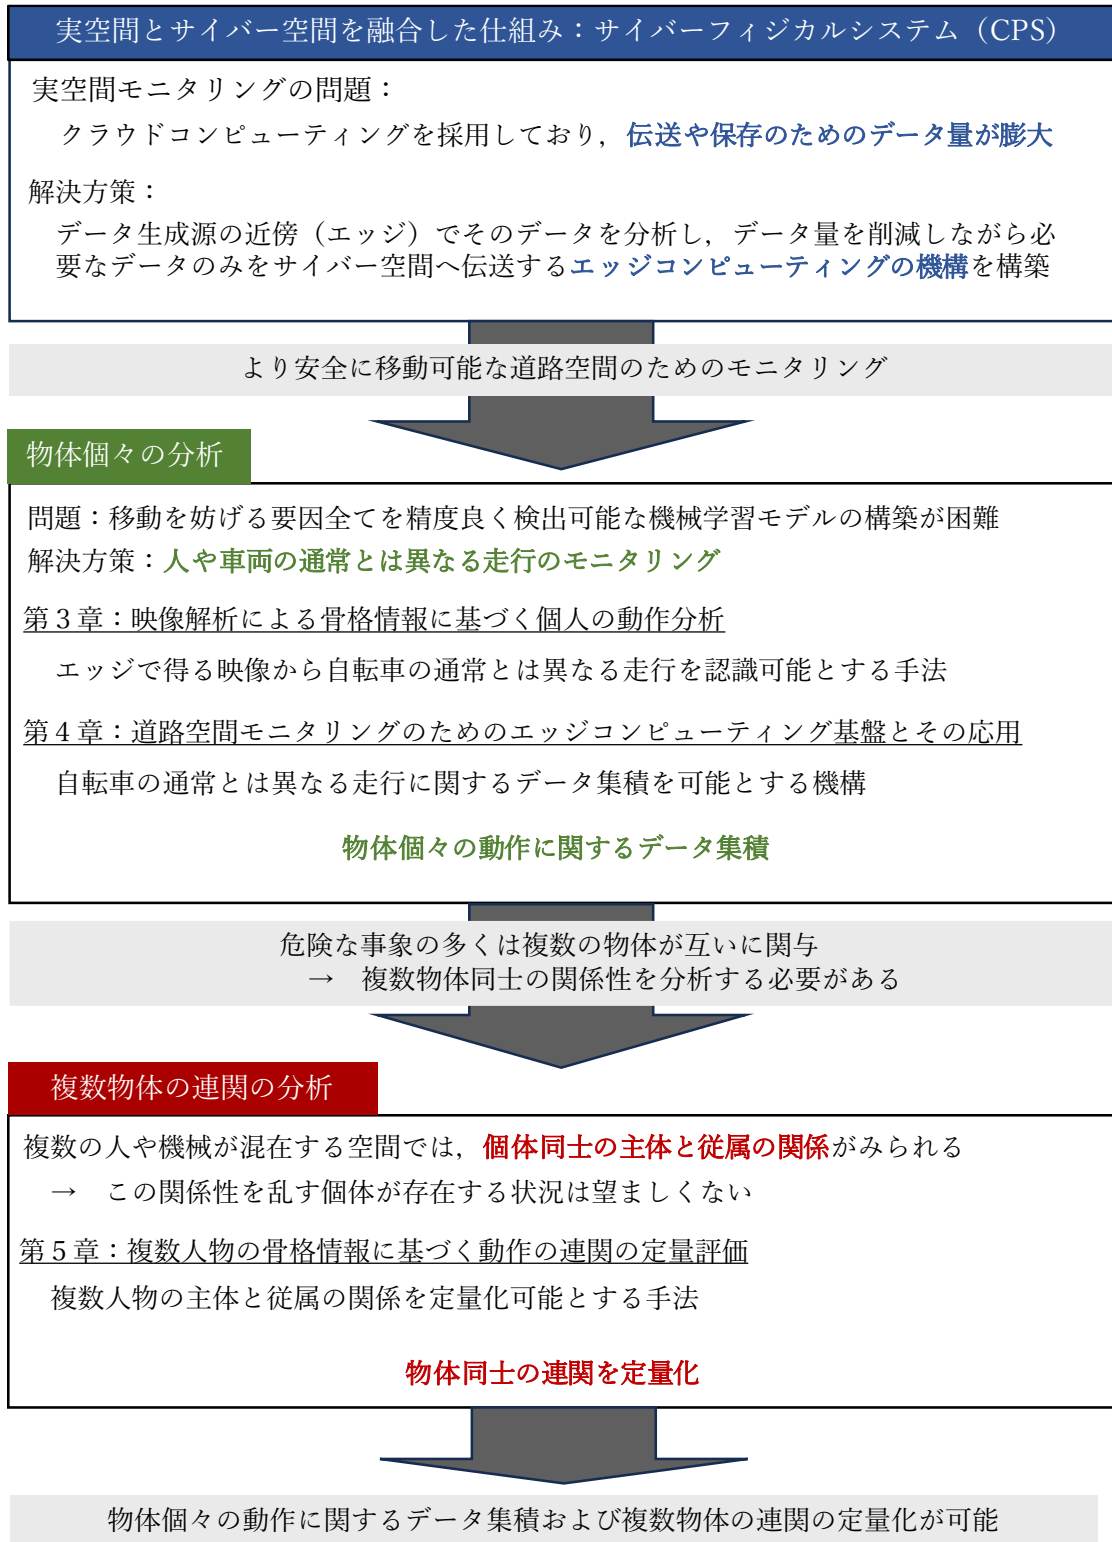


図 2 本研究における課題とその解決策および章構成の関係

## 第2章 関連研究

### 2.1 はじめに

本論文では、サイバーフィジカルシステムにおける道路空間モニタリングのためのエッジコンピューティングについて検討する。以降では、本論文と強く関連している既存研究について説明する。本章の構成を以下に示す。まず、2.2では、サイバーフィジカルシステムの起源や定義に関する既存研究を説明する。次に、2.3では、サイバーフィジカルシステムの具体的な取り組みに関する既存研究を説明する。特に、道路空間を対象としたサイバーフィジカルシステムの取り組みについて説明する。次に、2.4では、土木に関わるIoTやDXの取り組みを説明する。2.5では、画像・映像を用いた実空間モニタリングに関する既存研究を説明する。2.6では、本論文で解決する課題を明確化する。

### 2.2 サイバーフィジカルシステム（CPS）の起源と定義

実空間とサイバー空間を通信ネットワークを介して融合する仕組みの一つとして、サイバーフィジカルシステムが提案されている。サイバーフィジカルシステムは様々な分野に導入されつつある。本章ではサイバーフィジカルシステムについて、その起源や方向性が述べられた既存研究を説明する。

#### 文献[1]：

文献[1]では、「サイバーフィジカルシステム」という用語が初めて定義されている。具体的には、従来のITシステムを超える機能や性能、有効性を持つ複雑なシステムを表現する用語として定義されている。

#### 文献[32]：

文献[32]では、サイバーフィジカルシステムについて、時間の経過に伴う定義の進化について述べている。本文献では、サイバーフィジカルシステムの定義は、基本的には一貫しており、以下に示す6つの共通する特性を有していると述べている。

#### 1. ハイブリッドシステム [33,34]：

「物理的な要素と論理的な要素のハイブリッドなシステム」は、初期の定義および最近の定義において中心となっている。

**文献[33]**：サイバーフィジカルシステムは、コンピューティングと物理プロセスの融合である。

**文献[34]**：サイバーフィジカルシステムは、センシングシステムなどのサイバーコンポーネントと変化する環境やエネルギーシステムなどの物理コンポーネントとの間の緊密な相互作用とフィードバックおよびループを扱う。

## 2. ハイブリッドな手法 [35-37]：

「離散的な手法と連続的な手法を組み合わせたハイブリッドなアプローチを開発することは物理システムと論理システムを統合するための特有の課題」は、多くの定義で強調されている。

**文献[35]**：CPSの知的中心は、物理的プロセス、ソフトウェア、ネットワークの共同ダイナミクスを研究することにある。

**文献[36]**：コンピュータ、ネットワーキング、物理システム間のダイナミクスは、根本的に新しい設計技術を必要とする形で相互作用する。

**文献[37]**：統合されたネットワーキング、情報処理、センシング、アクチュエーション機能により、物理デバイスは変化する環境で動作することができる。これにより、スマートシステムが可能になると同時に、前例のない能力をもたらす新しい「システム科学」の必要性も生まれる。

## 3. 制御 [38,39]：

多くの定義では、計算システムによって、物理プロセスや工学システムを制御することが中心的な特徴として強調されている。

**文献[38]**：サイバーフィジカルシステム(CPS)は、コンピューティングと通信機能を現実世界に存在する物体のモニタリングや制御に統合する。

**文献[39]**：サイバーフィジカルシステム(CPS)は、コンピューティングと通信のコアによって動作が監視、調整、制御、統合される物理的・工学的システムである

#### 4. コンポーネントクラス [40-43] :

サイバーフィジカルシステムの要素である 3 つの包括的なクラスのセットとして定義されている。ここで、3 つのクラスとは、物理的/工学的な要素、変換器（センサとアクチュエータ）及び、ネットワーク/通信システムや計算/分析/制御システムを含む情報技術 (IT) システムを意味する。また、相互作用する構成要素として人間を含む定義もある。

**文献[40]** : CPS は、コンピューティングデバイスと、分散センサやアクチュエータを含む組み込みシステムで構成される異なる複数のシステムから成るシステムであると想定されている。これらのコンポーネントは相互に大規模に接続され、サイバー世界と現実世界をつなぐ自律的なタスクを実行する。

**文献[41]** : コンピューティングとネットワークが他のエンジニアリングシステムに深く統合されたこれらの NIT（ネットワークと情報技術）システムは、センサとアクチュエータを通じて現実世界に接続され、重要なモニタリングと制御機能を安全かつ確実に実行する。

**文献[42]** : 計算コンポーネントと物理コンポーネントは緊密に相互接続され、効果的に連携して動作するように調整されており、時には人間がそのループに加わることもある。

**文献[43]** : アイントホーフェン ICT 研究所 (EIRCT) は、CPS を構成するために時折使用される 6 つのコンポーネントを特定している。6 つのコンポーネントは、具体的に、現実世界、変換器、制御コンポーネント、データ分析要素、計算要素、および通信コンポーネントである。

#### 5. 時間 [33,40] :

現実世界の時間とイベント駆動型計算の統合は、サイバーフィジカルシステムの特有の課題として強調されている。

**文献[33]** : 現実世界では、時間の経過は不可逆であり、同時並行性が本質的に備わっている。これらの特性のどちらも、今日のコンピューティングとネットワークの抽象概念には存在しない。

## 6. 信頼性 [44-46]:

多くのサイバーフィジカルシステムの定義では、重要な物理プロセスや工学的システムが関与する場合に、安全性や信頼性、セキュリティの要件が求められる。

文献[44]:このようなシステムの物理コンポーネントには、汎用コンピューティングとは質的に異なる安全性と信頼性の要件が導入されるため、大きな課題である。

文献[45]:サイバーフィジカルシステム(CPS)は、センサ、プロセッサ、アクチュエータが組み込まれたスマートなネットワークシステムで、現実世界(人間のユーザを含む)を感知し、相互作用するように設計されており、安全性が重要なアプリケーションにおいてリアルタイムの保証されたパフォーマンスをサポートする。

文献[46]:サイバーフィジカルシステム(CPS)は、コンピューティング、通信、ストレージ機能を現実世界の物体のモニタリングや制御と統合するもので、信頼性、安全性、確実性、効率性、リアルタイム性が求められる。

## 2.3 サイバーフィジカルシステムの具体的な取り組み

サイバーフィジカルシステムは、例えば、道路空間、建設現場、農業現場など、多種多様な空間に対して適応可能な仕組みであり、様々な分野でその取り組みが行われている。本章では、サイバーフィジカルシステムの具体的な取り組みに関する既存研究について説明する。

### 2.3.1 道路空間を対象とした CPS

#### 文献[9]：

文献[9]では、スマート交通を実現し、交通制御システム、制御コマンドおよび情報フローを改善するためのサイバーフィジカルシステムの活用について述べている。この文献では、センサ、アクチュエータ、通信ネットワークなど、スマート信号機・交通流システムを実現するためのサイバーフィジカルシステムの特徴を調査している。

#### 文献[47]：

文献[47]では、人間に対する安全で質の高いサービスを改善・提供することを目的として、交通サイバーフィジカルシステム (T-CPS) におけるコンピューティング、通信、制御に関する詳細なアーキテクチャを提示している。提示されたアーキテクチャは、具体的に、以下に示す5つのレイヤーから構成されている。

#### 知覚レイヤー：

このレイヤーは、いくつかのセンサノードとコレクションノードで構成される。主に車両やインフラを含む実世界の物理的な特性を知覚することが役割である。具体的には、赤外線検出器、マイクロ波検出器、超音波検出器、RFID タグ、ビデオセンサー、ETC、VMS、LED などが知覚レイヤーにおけるデバイスである。

#### 通信レイヤー：

通信ステーションとネットワークノードから構成される。知覚レイヤーで得るデータを情報センターに伝送することや V2V、V2R、R2S の通信の信頼性を保証する必要がある。

#### 計算レイヤー：

T-CPS は大量の交通データ情報を扱うため、物理システムとサイバーシステム間の相互



作用やフィードバックがあり、解析やシミュレーションのためのリアルタイム性能が厳しく要求される。

制御レイヤー：

T-CPS の目標の一つは、交通システムの制御能力を強化することである。大量の有効な交通情報に基づいて、T-CPS は科学的な制御アルゴリズムを提供し、制御ノードに指示を送信することや、緊急時にアクチュエータを介して警告信号を送信するなど、交通システムの精密な制御を行うことが可能である。しかし、T-CPS のロバスト性と安定性をいかに確保するかが、満足のいく制御性能を実現するための重要な課題である。

サービスレイヤー：

T-CPS は、対象物、ツール、インフラの膨大な情報を得ることができる。したがって、T-CPS はユーザ端末にリアルタイムの交通情報サービスを提供する。このサービスは実用上重要な意味を持つ。しかし、交通情報の正確性と適時性を向上させるために、知覚と伝送の過程における不確実性と不完全性にどのように効果的に対処するかが課題である。

### 2.3.2 建設現場を対象とした CPS

文献[48]：

文献[48]では、建設作業員や設備オペレータに潜在的に危険な状況を警告するための近接警告アプリケーションを開発した。建設機械に関連した接触衝突、すなわち、建設機械に衝突する危険は、建設現場での負傷や死亡の主な原因となっている。サイバーフィジカルシステムに基づくアプローチは、接近の可能性が高い危険な建設主体（作業員や建設機械のオペレータ）に対して警告を発することで、潜在的な接触衝突を防止することが期待されている。開発されたシステムは、スマートフォンに内蔵された GPS から作業員や建設機器のオペレータの位置情報を取得し、位置情報に基づくアルゴリズムにより、差し迫った衝突が確認された場合、関係する全ての人間に警告する仕組みである。

文献[49]：

文献[49]では、仮設構造物の故障も、作業員の安全に重大なリスクをもたらす可能性があるとして述べ、仮設構造物のモニタリングに CPS を使用することを提案し、仮設構造物のリアルタイムモニタリングとリモートアクセスを容易にする CPS ベースの仮設構造物モニタリ

ングシステム (TSM) を開発している。足場を例に、サイバーフィジカルシステムを活用して足場部材の状態を追跡・評価することで、潜在的な故障や性能上の問題を予測できることを示した。

### 2.3.3 農業現場を対象とした CPS

#### 文献[101]：

文献[101]では、げっ歯類、特に野ネズミなどを検知するための新たなモニタリングシステムを提案している。人間の食料の約 80% は穀物から得られており、食料損失全体の 50% は害虫によるものである。これまで害虫管理には、罠、電気柵、殺鼠剤など、伝統的な最適化措置のみが一般的に用いられてきた。この文献では、従来防除方法をより効率的に適用できるように、ネズミの行動や野外での活動を防除専門家や農家に追跡させるためのスマート防除ソリューション (SPEC) を提案している。本文献では、動物検知のための新しいアプローチを開発している。シミュレーションの結果、本文献で提案する農業モニタリングのアプローチが効率的なシステムであることが示されている。

## 2.4 土木に関わる IoT や DX の取り組み

土木業界においても、IoT や DX（デジタルトランスフォーメーション）の取り組みが行われ始めており、大容量のデータが通信ネットワークを介して伝送・蓄積されている。本節では、土木に関わる IoT や DX について、画像や映像を活用した具体的な取り組みを説明する。

### 文献[25]：

従来の道路巡回は車上からの目視で行われており、損傷や異常などを報告する際は、損傷・異常箇所の画像や位置情報（距離標）を得ることに労力と時間を有している。文献[25]では、道路巡回の効率化・高度化を図るため、巡回用車両にカメラを搭載し、路面等の道路状況等を映像（動画）で確認できる道路巡回システムを試行することで道路巡回を支援し、本格導入にあたっての課題等を検討している。

### 文献[138]：

道路管理者は、道路の整備や管理のために交通量調査を実施している。この調査では、調査員が目視にて車両を計数するが、多地点かつ、長時間に及ぶことから省力化が求められている。その一策として機械式調査が導入されているが、昨今の ICT の発達を踏まえるとさらなる発展が期待される。文献[138]では、CCTV カメラによって撮影された画像を AI によって解析することで、簡易的に交通量を調査する実験を行い、その精度について検証している。

### 文献[139]：

文献[139]では、土工事の現場における進捗管理を効率的に行う「4K 定点カメラ映像による工事進捗管理システム」を開発した。開発したシステムは、主に次の4つの機能を実装しており、ブラウザを介してどこからでも利用できる。①映像に CIM モデル等の 3D データを重畳表示、②映像上から任意地点の距離や面積を瞬時に算出、③ AI により稼働中のダンプ等を識別し進捗レポートを作成、④映像からオルソ画像（俯瞰画像）の作成。本システムを防潮堤の盛土工事で試行し、建設現場の生産性向上につながる結果が確認された。

#### 文献[135]：

社会インフラの維持管理において、目視点検の省力化および効率化を図ることが近年の喫緊の課題の一つとなっている。そこで、文献[135]では、この課題を解決するため、デジタルカメラにより取得した画像に対して深層学習による画像認識を適用し、変状を自動的に検出して損傷程度の区分（ランク）に関するクラス分類を行う手法について検討を行った。また、実構造物での変状画像を用いた検証により、深層学習による画像認識が、目視点検の省力化および効率化に対して有効な手法であることを確認した。

## 2.5 エッジコンピューティングとサイバーフィジカルシステム

サイバーフィジカルシステムを実現するためには、実空間をセンシングして取得するデータの集積および分析が必要不可欠である。従来では、センシングにより得る生のデータをクラウドへ伝送する仕組みを採用するケースが多いが、伝送や保存のためのデータの容量が膨大であることが課題であり、その解決策としてエッジコンピューティングを導入する仕組みが普及しつつある。本節ではまず、エッジコンピューティングに関する既存研究を説明し、次に、サイバーフィジカルシステムとエッジコンピューティングの関連性を示す既存研究を説明する。

### 文献[99]：

文献[99]では、データ生成源の近くで計算することがエッジコンピューティングの核となるアイデアとして、エッジコンピューティングを以下のように定義している。

「エッジコンピューティングはデータを記録・計算する資源をモバイルデバイスやセンサの近傍に配置する新たな計算モデル」

### 文献[7]：

文献[7]では、エッジコンピューティングを以下のように定義している。

「エッジコンピューティングは、ネットワークのエッジで計算を実行する新しいコンピューティングの様式である。エッジコンピューティングにおけるダウンリンクデータはクラウドサービスを表し、アップリンクデータは Internet of Everything を表す。また、エッジコンピューティングのエッジはデータソースとクラウドコンピューティングセンターの経路の間の任意のコンピューティングおよびネットワークのリソースを指す。」

### 文献[100]：

文献[100]では、エッジコンピューティングを以下のように定義している。

「エッジコンピューティングとは、地理的距離やネットワーク距離においてユーザに近いリソースを統合し、アプリケーションサービスにコンピューティング、ストレージ、ネットワークを提供する新しいコンピューティングのモデルである。」

## 文献[102]：

文献[102]では、持続的かつ大幅なデータ量の増加や様々なデータ処理が要求される社会において、ビッグデータをクラウドベースに処理する仕組みには、以下に示す課題があると指摘している。

### 1. リアルタイム性:

クラウドに転送して処理した場合、中間データ転送量が大幅に増加し、データ転送のパフォーマンスが低下する。結果として、通信ネットワークの帯域に大きな負荷がかかり、データ転送の遅延が発生する。モニタリングなどのリアルタイムなフィードバックが必要なアプリケーションでは、クラウドコンピューティングはリアルタイム要件を満たすことができない。

### 2. セキュリティとプライバシー:

例えば、スマートフォンを用いて、様々なアプリケーションを使用する場合、アプリケーションは、私的なデータを含むユーザのデータが要求する。このようなデータをクラウドセンターにアップロードした場合、プライバシーの漏洩や攻撃が発生するリスクが高くなる。

### 3. エネルギー消費:

スマートデバイスの数は増加の一途をたどっている。クラウドコンピューティングのエネルギー消費の利用効率を向上させても、エネルギー消費の需要増に対応することはできない。急速に発展するインテリジェント社会では、クラウドコンピューティングのエネルギー消費に対する要求も高くなると考えられる。

また、エッジコンピューティングには、以下の三つの利点があるとしている。

### 1. 高速なデータ処理と分析およびリアルタイム性：

データ量の急増とネットワーク帯域幅の圧迫は、クラウドコンピューティングの欠点であるが、従来のクラウドコンピューティングと比較すると、エッジコンピューティングは応答速度とリアルタイム性において優位性がある。エッジコンピューティングはデータ生成源に近く、データストレージとコンピューティングタスクをエッジコンピューティングノードで実行できるため、中間的なデータ転送プロセスを削減できる。ユーザとの近接性を重視し、より優れた知的サービスをユーザに提供することで、データ伝送のパフォーマンスを向上させ、リアルタイム処理を保証し、遅延時間を短縮する。特に自動運転、スマートマニファクチャリング、ビデオを用いたモニタリングおよびその他の位置把握などは、迅速なフィードバックが特に重要であるが、エッジコンピューティングは、ユーザに対して様々な高速な応答サービスを提供する。

## 2. セキュリティ：

従来のクラウドコンピューティングでは、全てのデータをクラウドにアップロードして一元的に処理する必要がある。このような仕組みでは、データ損失やデータ漏洩などのリスクが発生し、セキュリティやプライバシーを保証することはできない。例えば、アカウントのパスワードや過去の検索記録、さらには企業秘密までもが流出する可能性がある。エッジコンピューティングは、自身の範囲内のタスクにのみ責任を負うため、データの処理はローカルをベースとし、クラウドにアップロードする必要がなく、ネットワーク伝送プロセスがもたらすリスクを回避できるため、データのセキュリティが保証される。データが攻撃された場合、それはローカルデータにのみ影響し、すべてのデータには影響しない。

## 3. コスト，低エネルギー消費，低帯域幅コスト：

エッジコンピューティングでは、処理するデータをクラウドコンピューティングセンターにアップロードする必要がないため、ネットワーク帯域幅をそこまで使用する必要がなく、ネットワーク帯域幅の負荷が軽減され、ネットワークのエッジにあるインテリジェントデバイスのエネルギー消費が大幅に削減される。エッジコンピューティングは小規模であり、企業はローカル機器のデータ処理コストを削減できる。したがって、エッジコンピューティングは、ネットワーク上で送信されるデータ量を削減し、伝送コストとネットワーク帯域幅の負荷を低減し、ローカル機器のエネルギー消費を削減し、コンピューティング効率を向上させる。

また、エッジコンピューティングの一般的なアーキテクチャは、端末デバイスとクラウドコンピューティングの間にエッジデバイスを導入することで、クラウドサービスをネットワークのエッジまで拡張する連携ネットワーク構造であると述べている。また、クラウドとエッジが連携するこの構造は、一般的には、端末レイヤー、エッジレイヤー、クラウドコンピューティングレイヤーに分けられるとし、それぞれのレイヤーの構成要素と機能を以下のように説明している。

### 端末レイヤー：

モバイル端末や多くの IoT デバイス（センサ、スマートフォン、スマートカー、カメラなど）を含むエッジ・ネットワークに接続されたあらゆる種類のデバイスで構成される。端末レイヤーの何億ものデバイスがあらゆる種類のデータを収集し、上位レイヤーにアップロードし、そこで保存・計算される。

#### エッジレイヤー：

エッジレイヤーは3層アーキテクチャの中核であり、ネットワークのエッジに位置し、端末デバイスとクラウドの間に広く分布するエッジノードで構成される。エッジレイヤーは、端末機器の下方へのアクセスをサポートし、端末機器からアップロードされたデータを保存・計算する。クラウドと接続し、処理したデータをクラウドにアップロードする。エッジ層はユーザに近いので、エッジ層へのデータ伝送はリアルタイムのデータ分析や知的処理に適しており、クラウドコンピューティングよりも効率的で安全である。

#### クラウドレイヤー：

クラウドコンピューティングとエッジコンピューティングが連携したアーキテクチャの中でも、クラウドコンピューティングは依然として最も強力なデータ処理センターである。クラウドコンピューティングレイヤーは、多数の高性能サーバーとストレージデバイスで構成され、強力なコンピューティング能力とストレージ能力を持ち、定期的なメンテナンスやビジネス上の意思決定をサポートするなど、大量のデータ分析を必要とする分野で優れた役割を果たすことができる。クラウドコンピューティングセンターは、エッジレイヤーから伝送されたデータを永続的に保存することができ、エッジレイヤーが処理できない分析タスクや、グローバルな情報を統合する処理タスクもこなすことができる。さらに、クラウドモジュールは、制御ポリシーに従って、エッジレイヤーの展開戦略とアルゴリズムを動的に調整することもできる。

#### 文献[50]：

文献[50]では、センシング、コンピューティング、制御、保存といったサービスを提供することで、サイバーフィジカルシステムは様々な領域における有望なアプリケーションに革命をもたらしたと述べている。しかしながら、データ量の爆発的な増加がサイバーフィジカルシステムを展開していく上で、問題となっていると述べている。具体的には、クラウドコンピューティングは強力な計算能力を有するが、通信ネットワークの帯域幅が限られており、端末デバイスとリモートのクラウドサーバ間の距離が長いので、必然的に許容できない通信遅延が発生すると説明している。その代替として、エッジでデータを処理する仕組みがサービス遅延におけるシステムのQoSを向上させることができると述べている。



## 文献[103]：

文献[103]では、サイバーフィジカルシステムを補助するコンピューティングの仕組みの一つとして、エッジコンピューティングとクラウドコンピューティングを融合した仕組みが説明されている。文献[103]では、エッジコンピューティングは分散コンピューティングであるため、エッジサーバはグローバルな情報ではなく、ローカルな情報しか把握できない。このことから、エッジコンピューティングはグローバルな意思決定には向かないことがわかる。一方、クラウドコンピューティングは、その一元的な機能により、強力な計算能力だけでなく、グローバルな意思決定サービスを提供することができる。上記の事実を考慮し、エッジコンピューティングとクラウドコンピューティングの両方の利点を組み合わせたエッジクラウドコンピューティングの概念が導入された。エッジコンピューティングとクラウドコンピューティングを融合したアーキテクチャでは、端末デバイスは、近接する所定の基地局を経由して、複雑なタスクをエッジサーバにオフロードすることができる。その後、リソースの利用状況やタスクの要件に基づいて、エッジサーバは、タスクの実行を完全に自身で完了させるか、タスクの実行の一部を行い、その後、リモートクラウドサーバにタスク処理の継続を要求するかを選択できる。また、地理的に異なる場所に配置された一連のエッジサーバによって収集されたローカル情報は、最適なグローバルな意思決定を支援する目的で、クラウドサーバに送信することもできる。

## 2.6 画像・映像を用いた実空間モニタリング

映像や画像を用いた実空間モニタリングに関する研究として、近年、深層学習などの機械学習に基づき画像から物体を認識する手法[14,15]や人間の骨格位置を推定する手法[16,17]などが活発に研究されている。また、深層学習に基づき映像から物体を追跡する手法[18,19]なども同様に広く研究されている。さらには、深層学習などの機械学習により、実空間の安全性に関わる事象を認識する取り組みが行われている。本章ではまず、物体の認識・追跡や骨格位置の推定に関して、それぞれの代表的な手法について説明する。次に、画像・映像を用いた空間分析に基づき、実空間における危険な状況を認識する取り組みについて、既存研究を説明する。また、本論文では、集団における各個体同士の主体と従属の関係を定量化する。そこで、集団における主体と従属の関係に関連する既存研究を説明する。

### 2.6.1 深層学習に基づく物体認識・追跡および骨格推定の手法

#### 文献[14]：

文献[14]では、物体認識モデルとして幅広く活用されている Yolo について説明している。具体的には、畳み込みニューラルネットワークに基づく物体認識モデルを提案している。本モデルは、画像を入力として、物体の位置とカテゴリを出力するニューラルネットワークである。本モデルはサイズが小さく計算速度が速いといった特徴がある。物体認識のためのオープンデータである COCO データセットを用いて学習されたモデルが広く活用されており、その認識可能な物体の種類は約 80 である。

#### 文献[16]：

文献[16]では、人の骨格推定モデルとして幅広く活用される OpenPose を提案している。具体的には、畳み込みニューラルネットワークに基づき人間の骨格位置を推定する手法を提案している。本手法では、画像を入力として、複数の人間について、首や腕、足などの最大 25 か所の関節の画像内における 2 次元座標を取得することが可能である。画像から骨格位置を推定可能であり、人間に対してセンサを装着することなく骨格位置を取得することが可能である。

#### 文献[18]：

文献[18]では、物体追跡モデルとして幅広く活用される DeepSORT を提案している。提案されたモデルではまず、カルマンフィルタに基づき追跡対象の物体の位置を予測する。その後、物体の動きに関する情報と見た目に関する情報を統合した評価関数に基づき物体を追跡する。

#### 文献[104]

文献[104]では、深層学習に基づき建設現場の作業員を検出・追跡する手法を提案している。具体的には、深層学習に基づく物体認識モデルの一つである Yolo v4 に基づき作業員を検出し、深層学習に基づく物体追跡モデルの一つである Siamese network に基づいて作業員を追跡する。

#### 文献[105]

文献[105]では、深層学習に基づいて建設現場のロボットの骨格を推定する手法を提案している。具体的には、深層学習に基づく人間の姿勢推定アルゴリズムである stacked hourglass network を応用することで、ロボットの骨格検出を可能としている。

## 2.6.2 機械学習に基づく道路空間を含む実空間の状況認識

### 文献[20]

文献[20]では、CCTV カメラにより取得した映像を用いて、赤信号時における歩行者の横断意思を推定する手法を提案している。具体的には、OpenPoseにより取得する歩行者の姿勢データに基づく特徴量を入力とする機械学習の識別器を構築することで、横断意思を推定している。

### 文献[21]

文献[21]では、映像から交通事故を検出する手法を提案している。具体的には、まず、深層学習に基づき車両を映像から認識し、追跡する。次に、複数車両の軌跡の交錯や速度などの特徴について、異常検知を行うことで、事故の検出を行っている。

### 文献[51]

文献[51]では、建設現場を対象とした画像分析に基づく手法とその応用事例についての文献をレビューしている。文献[51]では、画像を用いて建設現場の安全性を分析する手法について、分析対象とする場面を、ヘルメットの装着の有無[52-56]、事故[57-61]、落下[62,63]、人間工学的リスク[64-69]、その他（セキュリティなど）[72-77]に分類して、文献を要約している。また、画像を用いた建設現場の状況分析に関する取り組みとして、畳み込みニューラルネットワークに基づく手法が幅広く活用されており、膨大な学習データセットの準備が必要であることを課題としている。

以上のように、深層学習などの機械学習に基づく画像や映像を用いた空間分析により、物体の認識や安全性に関わる事象を分析する手法が提案されている。一方で、膨大な学習データセットが必要であることが課題となっている。

### 2.6.3 物体の移動における主体と従属の関係に関する研究

#### 文献[29]

文献[29]では、歩行者集団の振る舞いを、各個体が相互に作用する場合と、そうでない場合とに分類し、相互に作用する場合における歩行者集団の動きを説明する場合においては、leader-follower の関係と衝突回避動作が重要な役割を担うと述べている。文献では、車両の追従と走行レーンの切り替えに関する数理モデルを参考にし、leader-follower の関係と衝突回避動作を考慮した歩行者集団の振る舞いを表現するモデルを用いている。

#### 文献[106]

文献[106]では、ファジィ論理のアプローチに基づき、他の群エージェントと衝突することなく、リーダー・フォロワーのフォーメーションを保つことを目的とした、ロボット群を誘導するアルゴリズムが提案されている。結果として、ロボット群が静止しているときや、ある場所から別の場所に移動しているときに、群エージェントがリーダーを取り囲むなど、生物にヒントを得た行動を示すことがわかった。また、提案したファジィシステムを V-Rep を用いてドローン群に実装した実験では、群体が静止しているときは群体の中心にリーダーを維持し、移動しているときはリーダーを追従して一緒に航行することが示されている。

## 2.7 本論文で解決すべき課題とその解決方法

本節では、サイバーフィジカルシステムにおける道路空間モニタリングを実現するために、本論文で解決すべき課題を明確にする。まず、2.2 および 2.3 において、サイバーフィジカルシステムとエッジコンピューティングに関する既存研究について説明し、従来のクラウドコンピューティングを導入した仕組みでは、伝送や保存のためのデータ量が膨大であることが問題であり、その解決策として、エッジコンピューティングを導入することの有効性を述べた。2.4 では、土木に関わる IoT や DX について、画像や映像を活用した具体的な事例を説明し、画像や映像などの大容量データが通信ネットワークを介して伝送され、蓄積されていることを述べた。また、2.5 において、深層学習などの機械学習に基づく物体の認識手法や安全性に関わる事象を分析する手法が提案されているが、膨大な学習データセットが必要であることが問題となっていることを述べた。また、2.6 では、個体同士が互いに影響を及ぼしあう集団の行動において、個体同士の主体と従属の関係が大切であると述べた。

本論文では、従来から広く採用されるクラウドコンピューティングの枠組みによって生じる伝送や保存のための膨大なデータ容量の問題に対して、エッジコンピューティングを導入することで解決する。具体的には、カメラの近傍において、撮影された映像を分析し、データ量を削減しながら必要なデータのみをサイバー空間へ伝送する機構を提案する。また、本論文では、道路空間を常にモニタリングすることで、人や車両が正常に移動可能な安全な状態にあるかどうかを把握可能とすることを目指す。画像・映像解析の分野では、深層学習などの機械学習に基づく手法が幅広く導入されているが、膨大な学習データを必要であり、それを準備することが困難な状況が多く、問題となっている。人や車両の移動を妨げる物体や状態も膨大なデータセットを準備すること困難な事例の一つである。そこで、本論文では、人や車両の通常とは異なる走行を観測することに取り組む。これにより、膨大なデータセットを準備することなく、道路空間に存在する異常箇所を効率的に把握可能となることが期待できる。具体的には、① 道路空間の基本的な参加者の一つである自転車の通常とは異なる走行を映像から認識する手法の導出、② 自転車の通常とは異なる走行に関するデータ集積を可能とするエッジコンピューティング機構の構築に取り組む。また、複数の人や機械が混在する空間で発生する危険な事象の多くは、複数の物体が互いに関与している。そのため、物体個々の動きを分析するだけでなく、物体同士の関係性を分析する必要がある。ここで、2.5 で説明したとおり、複数の人や機械から構成される集団の行動には、多くの場合に、個体同士の主体と従属の関係がみられる。この関係性を乱す個体が存在する状況は、安全性の観点で望ましくない。このような背景から、③ 映像から物体同士の主体と従属の関係を定量化する手法の導出に取り組む。

## 2.8 まとめ

本章では、本論文と関連した従来研究に関して説明した。具体的には、最初に、サイバーフィジカルシステムの起源や定義に関する文献を説明した。次に、サイバーフィジカルシステムの具体的な取り組みに関する文献を説明した。特に、道路空間を対象としたサイバーフィジカルシステムの取り組みについて説明した。次に、土木に関わる IoT や DX の取り組みについて説明した。次に、エッジコンピューティングの定義やサイバーフィジカルシステムとエッジコンピューティングの関係性を示す既存研究を説明した。次に、映像や画像を用いた実空間のモニタリングに関する既存研究を説明した。最後に、既存研究の課題を明確にした。

## 第 3 章 映像解析による骨格情報に基づく個人の動作分析

### 3.1 はじめに

本章では、道路映像から自転車の通常とは異なる走行を認識する手法を提案する。図 3 に示すように、移動を妨げる物体や状態が存在する道路の異常箇所では、自転車はまっすぐに走行することが出来ない。そこで、提案手法では、自転車の走行がまっすぐか否かを識別する。提案手法の概要を図 4 に示す。具体的に、提案手法は 2 つのステップにより構成される。提案手法で入力とするビデオクリップは、 $n$  フレームからなるものを用いる。具体的には、(1) まず、サイクリストの関節位置およびオプティカルフローに基づく特徴量を算出し、(2) 次に、それぞれの特徴量を入力とする Support Vector Machine (SVM)[78] 及び Extreme Learning Machine (ELM)[79] を構築し、それらの識別結果に対する確信度を用いることで、最終的な識別結果を得る。ここで、提案手法で用いる 2 種類の特徴量は、次元数及び分布が異なる。したがって、2 種類の特徴量を統合し、統合された特徴量を入力とする識別器を構築するアプローチにより、十分な識別精度を実現することは、非常に難しいタスクである。マルチメディアデータ分析の分野では、複数の特徴量それぞれを入力とする識別器を構築し、識別器から得られる結果を統合することの有効性が示されている[80-82]。したがって、提案手法では、サイクリストの関節位置およびオプティカルフローに基づく特徴量それぞれを入力とする識別器を構築し、それらの識別結果を統合することで、自転車の走行を識別する。加えて、サイクリストおよび自転車本体の動きは、サイクリストによって大きく異なる。したがって、同じ種類の特徴量であっても、常に特徴量の分布が同じであるとは限らない。故に、多様なサイクリストのデータに対して頑健な単一の識別器を構築することは難しい。文献[83-85]では、複数の識別器から得られる結果を用いることの有効性が示されている。故に、提案手法では、複数の特徴量を入力とする SVM 及び ELM を構築し、それらの識別結果を統合することで、より精度高い自転車走行の識別を実現する。また、複数の識別器から得られる識別結果の統合に関しては、識別結果に対する確からしさ（以降、確信度）を用いることの有効性が示されている[84-86]。したがって、提案手法では、SVM および ELM から得られる識別結果に対する確信度を用いることで、識別結果を統合する。本章では、3.2 及び 3.3 において提案手法について説明し、3.4 で実験を行う。

また、自転車の走行を分析するためには、前段階として映像から自転車を認識する必要がある。道路を撮影した映像から交通参加者を認識する取り組みが数多く行われおり、その精度向上に向けて、深層学習に基づく一般物体認識を応用する手法が期待されている。しかしながら、自転車と自動二輪車は、その形状が類似することから、識別精度に課題がある。こ



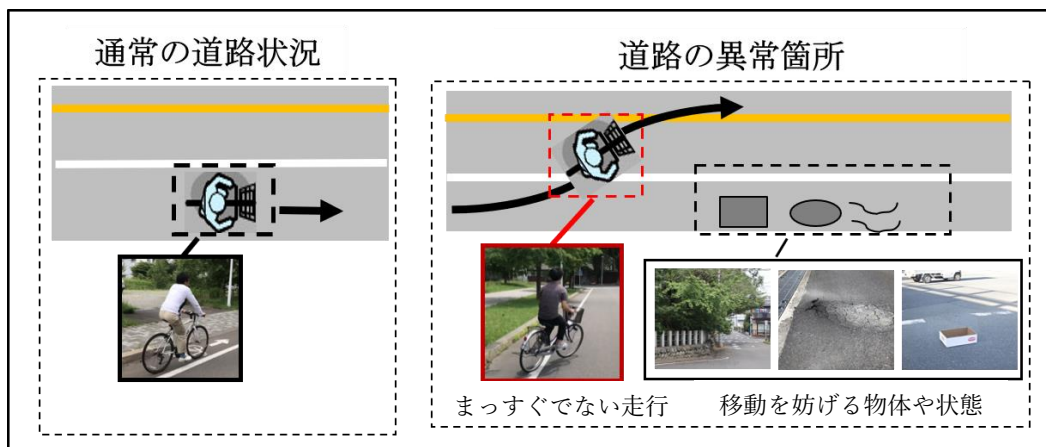


図 3 自転車がまっすぐでない走行を強いられる道路状況の例

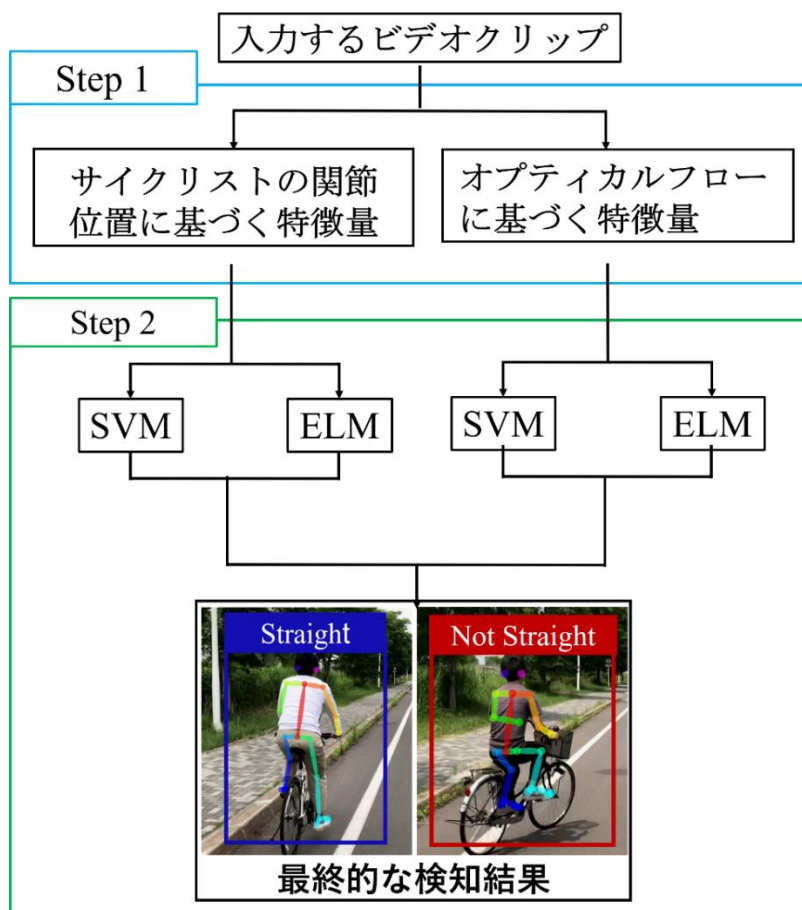


図 4 提案手法の概要

ここで、自転車と自動二輪車では、運転者の姿勢や運動に違いがある。したがって、この特徴に基づいた識別手法により、自転車と自動二輪車をより精度高く識別可能となることが期待できる。そこで、本章の 3.5 及び 3.6 では、運転者の姿勢や運動に関する特徴に基づいた自転車と自動二輪車の識別手法について検討する。

## 3.2 特徴量の算出

### 3.2.1 サイクリストの関節位置に基づく特徴量の算出

提案手法では、サイクリストのハンドル操作などを表現することを目的として、サイクリストの関節位置に基づく特徴量を求める。提案手法では、まず、OpenPose[16]を用いて、画像内におけるサイクリストの関節の位置座標を取得する。OpenPose は、畳み込みニューラルネットワークに基づいて画像内の人体の部位の 2 次元位置を取得する。2 次元位置は、画像内の水平座標と垂直座標を意味する。したがって、図 5 に示すように、提案手法は、各フレームでサイクリストの 25 種類の関節の 2 次元位置を取得する。また、いくつかの身体部位が検出されない場合がある。関節位置の検出に使用したライブラリは、非検出部位の水平座標、垂直座標をとともゼロとして出力するように実装されているため、本論文ではその出力値を非検出部位の座標として使用する。検出されない部位の多くは、他の身体部位によって覆われている。また、撮影角度とサイクリストの姿勢が同じ条件であれば、同じ部位が検出されない。したがって、各部位の検出の有無もサイクリストの動きを表す特徴となることが期待できる。また、2 次元位置は、図 5 において No.9 として示されている「MidHip」を原点とした相対座標で表現する。次に、カメラとサイクリストの距離に対してロバストな特徴量を求めるため、フレーム単位で相対座標を正規化する。最後に、提案手法は相対座標に基づき表 1 に示すサイクリストの動作特徴  $x^{cyc}$  を求める。

### 3.2.2 オプティカルフローに基づく特徴量の算出

提案手法では、自転車本体の動きを表現することを目的として、オプティカルフローに基づく特徴量を求める。提案手法では、各ビデオクリップからオプティカルフローに基づく特徴量を求める。まず、図 6 に示すように、ビデオクリップの最初のフレームから自転車の周囲の領域を抽出し、自転車の動きを表すのに有効な特徴量を取得する。提案手法では、OpenPose を用いて取得したサイクリストの下半身部位の 2 次元位置に基づいて領域を抽出する。具体的に、提案手法ではまず、「MidHip」から「Neck」までの長さ ( $r$  ピクセル) を計算する。次に、計算された「MidHip」から「Neck」までの長さ  $r$  と「MidHip」の 2 次元位置を用いて、図 6 に示すように  $2\alpha r \times \beta r$  ( $\alpha, \beta \in \mathbb{R}$ ) ピクセルで構成される自転車周囲の

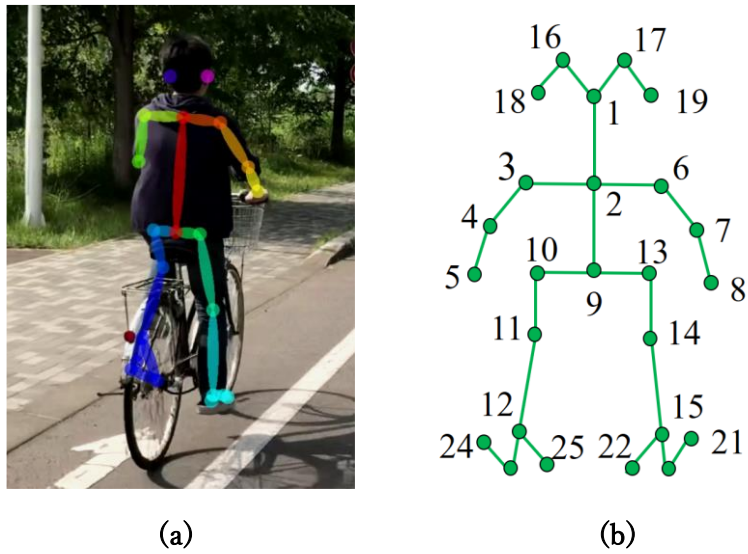


図 5 OpenPose による骨格データの取得 : (a) OpenPose による骨格データの取得結果を重畳表示した図, (b) OpenPose により取得する関節

表 1 サイクリストの関節位置に基づく特徴量

サイクリストの関節位置に基づく特徴の種類	次元数
相対座標の平均値	50
隣接フレーム間での相対座標の差分	100
関節角度の平均値	10
計	160

領域を抽出する。次に、自転車周囲のオプティカルフローを計算する。具体的には、提案手法ではまず Shi-Tomashi のコーナー検出法[87]を用いて、抽出した領域から 10 個の特徴点を取得する。次に、得られた特徴点に対して、Lucas-Canade アルゴリズム[88]をフレーム間隔ごとに適用してオプティカルフローを計算する。最後に、提案手法は計算されたオプティカルフローをフレーム間隔ごとに 6 方向に分類し、ヒストグラムを取得する。その結果、提案手法はオプティカルフローに基づく特徴量  $x^{bic}$  を取得する。ここで、 $x^{bic}$  の次元は  $6(n-1)$  である。

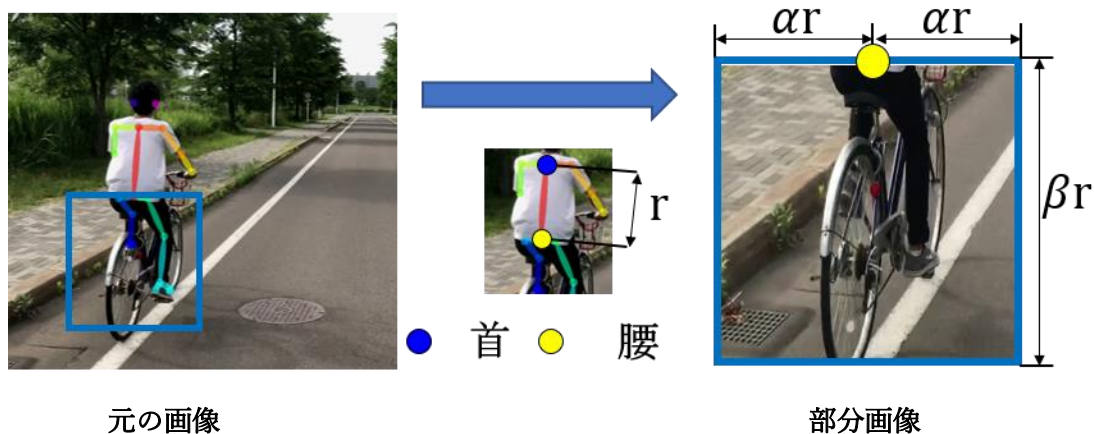


図 6 関節位置の近傍の画素からなる部分画像の取得

### 3.3 複数識別器の確信度を用いた識別

本節では、前節までに求める特徴量それぞれを入力とする SVM 及び ELM を構築し、それらの識別結果に対する確信度を用いて、自転車の走行がまっすぐか否かを識別する。以降の項では、初めに SVM 及び ELM を構築し、識別結果に対する確信度を求める。最後に、識別結果に対する確信度を用いて、自転車の走行を識別する。

#### 3.3.1 SVM の構築および確信度の算出

SVM は画像認識の分野で広く用いられている識別器であり、特徴ベクトルを高次元特徴空間に写像し、識別超平面を構築することで分類を行う。提案手法では、前節までに求める特徴量を入力とする SVM を構築し、識別結果に対する確信度を文献[107]で提案された手法に基づいて取得する。本章では、特徴量 $x^j$ を入力とする SVM のラベル $z$ に対する確信度を $p_{z,j}^{svm}(z \in \{st, nst\}, j \in \{cyc, bic\})$ とする。ただし、 $st$  は“まっすぐな走行”， $n\_st$  は“まっすぐでない走行”を意味する。

### 3.3.2 ELM の構築および確信度の算出

ELM は 3 層のニューラルネットワークからなる識別器である。提案手法では、前節までに求める特徴量を入力とする ELM を構築し、出力値に対してソフトマックス関数を適用することで、識別結果に対する確信度を取得する。本章では、特徴量  $x^j$  を入力とする ELM のラベル  $z$  に対する確信度を  $p_{z,j}^{\text{ELM}} (z \in \{st, nst\}, j \in \{cyc, bic\})$  とする。

### 3.3.3 SVM および ELM から得られる識別結果に対する確信度に基づく識別

提案手法では、前節までに求めた識別結果に対する確信度を用いて、自転車の走行を識別する。具体的には、以下の式によって、最終的な結果 *Label* を得る。

$$label = \arg \max_{(z \in \{st, nst\})} p_{z,j}^c . \quad (1)$$

ただし、 $p_{z,j}^c (z \in \{st, nst\}, j \in \{cyc, bic\}, c \in \{SVM, ELM\})$  は特徴量  $x^j$  を入力とする識別器  $c$  から得られるラベル  $z$  に対する確信度を表す。識別結果に対する確信度の中から、最大の値に対応するラベルを選択する理由は、最も識別結果に対する確からしさが高い識別結果に基づき最終的なラベルを決定するためである。一般的に、複数の識別結果から、確信度が大きいものを選択することは有効であり、文献[89]などでその有効性が示されていることから、提案手法でもこの統合方法を採用する。

## 3.4 実験

提案手法の有効性を確認するための実験結果を行う。まず実験条件を示す。次に実験結果を示して、考察する。

### 3.4.1 実験条件

本実験では、自転車が走行する様子を自転車の後方から撮影した映像を用いる。各フレームの解像度およびフレームレートはそれぞれ、 $1,920 \times 1,080$  および 30fps である。本実験で用いるデータセットには、「Straight」および「Not Straight」のラベルが付いた 2 種類の自転車の走行が含まれている。本実験では、スラロームに似たさまざまな動きを記録し、その映像を「Not Straight」というラベルに設定した。データセットの例を図 7 および 図 8 に示す。具体的には、図 7 は「Straight」とラベル付けされた映像のフレームを示し、図 8 は「Not Straight」とラベル付けされた映像内のフレームを示す。サイクリストの数は 6 名（サイクリスト 1 ～ 6）である。実験では、連続する 3 つのフレームで構成されるビデオクリップが「Straight」あるいは「Not Straight」であるかを識別する。本実験における映像、ビデオクリップ、およびビデオクリップ内のフレームの数を表 2 に示す。また、本実験では、サイクリストを個別に評価する。具体的には、各サイクリストのデータをテストデータとして設定する 6 分割交差検証を行う。SVM のパラメータはグリッドサーチ[90]によって決定した。ELM のパラメータとオプティカルフローに基づく特徴量のパラメータは、各手法の性能が最高となるように決定した。具体的に、ELM の中間層のノード数は、サイクリストの動作特徴  $x^{cyc}$  を入力とする ELM では 320、オプティカルフローに基づく特徴量  $x^{bic}$  を入力とする ELM では 50 とした。また、部分画像を取得する際のパラメータ  $\alpha$  および  $\beta$  の値は、それぞれ 1.3 および 1.8 とした。本実験では、性能評価のために、Recall, Precision, F-measure を計算した。これらは、画像認識における性能評価に使用される代表的な評価関数である。具体的には以下のように定義される。

$$R_z = \frac{\text{ラベル}z\text{に正しく分類されたビデオクリップの総数}}{\text{ラベルが}z\text{であるビデオクリップの総数}}, \quad (2)$$

$$P_z = \frac{\text{ラベル}z\text{に正しく分類されたビデオクリップの総数}}{\text{ラベル}z\text{に分類されたビデオクリップの総数}}, \quad (3)$$

表 2 実験で用いるデータセットの内訳

ラベル	映像数	ビデオクリップの数	1 ビデオクリップ当たり のフレーム数
まっすぐ	57	27,411	3
まっすぐでない	62	32,274	

$$F_z = \frac{2 \times R_z \times P_z}{R_z + P_z}. \quad (4)$$

さらに、提案手法の有効性を評価するために、2つの比較手法を用いる。比較手法 1 (CM1) はサイクリストの特徴量のみを用いた手法であり、比較手法 2 (CM2) はオプティカルフローに基づく特徴量のみを用いた手法である。



図 7 まっすぐな走行のビデオクリップの例



図 8 まっすぐでない走行のビデオクリップの例



### 3.4.2 実験結果

実験結果を表 3 および表 4 に示す。なお、表 3 および表 4 中の PM は提案手法を意味する。全ての手法のラベル「Straight」の再現率、適合率、F-measure を表 3 に示す。また、ラベル「Not Straight」の場合を表 4 に示す。提案手法により得られた結果の例を図 9 および図 10 に示す。図 9 は、ラベル「Straight」として正しく認識されたビデオクリップの例を示す。図 10 は、ラベル「Not Straight」として正しく認識されたビデオクリップの例を示す。表 3 と表 4 より、全ての評価指標の平均において、提案手法が比較手法 1 及び比較手法 2 よりも優れていることがわかる。本研究では、自転車のまっすぐでない走行を認識した結果を積み上げることを想定している。そのため、ラベル「Not Straight」のビデオクリップをどれだけ正確に認識できるかが最も重要であり、ラベル「Not Straight」の Precision が高いことが望ましい。表 4 より、提案手法はその平均値が 0.835 であり、比較手法を上回っていることがわかる。ここで、社会インフラの利用者の異常行動を、映像から検知することを目的とした最新の研究[94]において、その検知精度は 0.7 程度であり、提案手法が実現する 0.835 という精度はそれを上回る数字である。加えて、その他の評価指標に関しても、最新の研究における検知精度を上回る。したがって、提案手法の有効性が確認できた。また、提案手法におけるラベル「Not Straight」の F 値の平均は約 0.85 であり、0.15 の誤差がある。ここで、本章で提案する手法は、自転車が通常どおりに走行可能な空間であるかどうかを評価するための手法であり、最終的には、自転車のまっすぐでない走行に関するデータを積み上げることで、通常どおりに移動することが困難な箇所を効率的に把握可能とすることを想定している。そのため、データを一定量蓄積した場合には、その影響は小さいと考えられる。

表 3 および表 4 に示すように、提案手法は、すべての評価指標の平均において比較手法 1 を上回っている。以上より、オプティカルフローに基づく特徴量を導入することの有効性が確認された。図 11 は、図 6 に示した方法で自転車の周囲の領域を抽出した例を示している。図 11 に示すように、自転車の周囲の領域がうまく抽出されていることが確認できる。

次に、本研究の限界と今後の取り組みについて説明する。表 3 に示すように、提案手法におけるサイクリスト 3 のラベル「Straight」の Recall および F 値は、他のサイクリストに比べて明らかに劣っている。図 12 に、提案手法により認識された「Straight」とラベル付けされたサイクリスト 3 のビデオクリップの例を示す。図 12 に示すように、誤って認識してしまう際の傾向として、映像をサイクリストの横方向から撮影していることが多いことが確認された。また、サイクリスト 3 のビデオクリップは、他のサイクリストに比して横方向から撮影された映像が多い。したがって、サイクリスト 3 の識別器を構築するために使用される学習データには、サイクリスト 3 の走行を撮影した映像の画角と類似している映像があまり含まれていない。これが他のサイクリストに比して識別性能が低い理由であると考えられる。この問題を解決するために、今後の研究ではより多様な学習データを用いる

ことが必要である。また、提案手法は、自転車の通常とは異なる走行を高い性能で識別可能とすることを実現したが、各識別器の信頼性は考慮されていない。そこで、各識別器の信頼性を考慮した統合を導入することで、認識性能の向上が期待できる。したがって、今後の研究では、これらの統合アプローチを導入した方法を検証する予定である。また、本論文では、自転車を分析対象としたが、今後は、自動車などの他の物体および建設現場などの他の空間に対して適用可能となる理論の拡張に取り組む予定である。

表 3 各手法におけるラベル ”まっすぐな走行” の再現率 (R), 適合率 (P) および F 値 (F)

	PM			CMI			CM2		
	R	P	F	R	P	F	R	P	F
Cyclist 1	<b>0.927</b>	<b>0.883</b>	<b>0.905</b>	0.923	0.87	0.898	0.603	0.763	0.673
Cyclist 2	<b>0.911</b>	<b>0.917</b>	<b>0.914</b>	0.885	0.907	0.896	0.642	0.709	0.674
Cyclist 3	0.388	<b>0.934</b>	0.548	0.31	0.893	0.46	<b>0.552</b>	0.803	<b>0.654</b>
Cyclist 4	0.662	<b>0.929</b>	<b>0.773</b>	<b>0.669</b>	0.908	0.77	0.512	0.752	0.609
Cyclist 5	0.77	<b>0.912</b>	<b>0.835</b>	0.654	0.904	0.759	<b>0.866</b>	0.706	0.778
Cyclist 6	0.89	<b>0.642</b>	<b>0.746</b>	<b>0.901</b>	0.627	0.739	0.544	0.593	0.567
Average	<b>0.758</b>	<b>0.87</b>	<b>0.787</b>	0.724	0.852	0.754	0.62	0.721	0.659

表 4 各手法におけるラベル ”まっすぐでない走行” の再現率 (R) , 適合率 (P) および F 値 (F)

	PM			CM1			CM2		
	R	P	F	R	P	F	R	P	F
Cyclist 1	<b>0.882</b>	<b>0.927</b>	<b>0.904</b>	0.868	0.925	0.896	0.82	0.683	0.745
Cyclist 2	<b>0.932</b>	<b>0.927</b>	<b>0.929</b>	0.925	0.907	0.916	0.782	0.725	0.753
Cyclist 3	<b>0.982</b>	0.709	0.823	0.976	0.682	0.803	0.911	<b>0.755</b>	<b>0.826</b>
Cyclist 4	<b>0.96</b>	0.782	<b>0.862</b>	0.946	<b>0.783</b>	0.857	0.867	0.691	0.769
Cyclist 5	0.923	0.795	<b>0.854</b>	<b>0.928</b>	0.721	0.812	0.627	<b>0.819</b>	0.71
Cyclist 6	0.597	0.87	<b>0.708</b>	0.564	<b>0.875</b>	0.686	<b>0.697</b>	0.653	0.674
Average	<b>0.879</b>	<b>0.835</b>	<b>0.847</b>	0.868	0.816	0.828	0.784	0.721	0.746

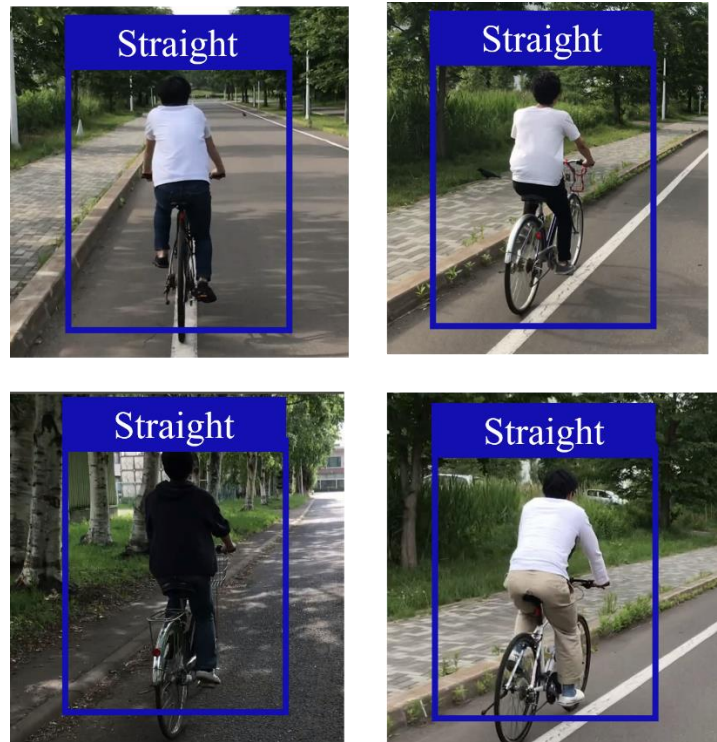


図 9 提案手法により，まっすぐな走行と正しく識別された例

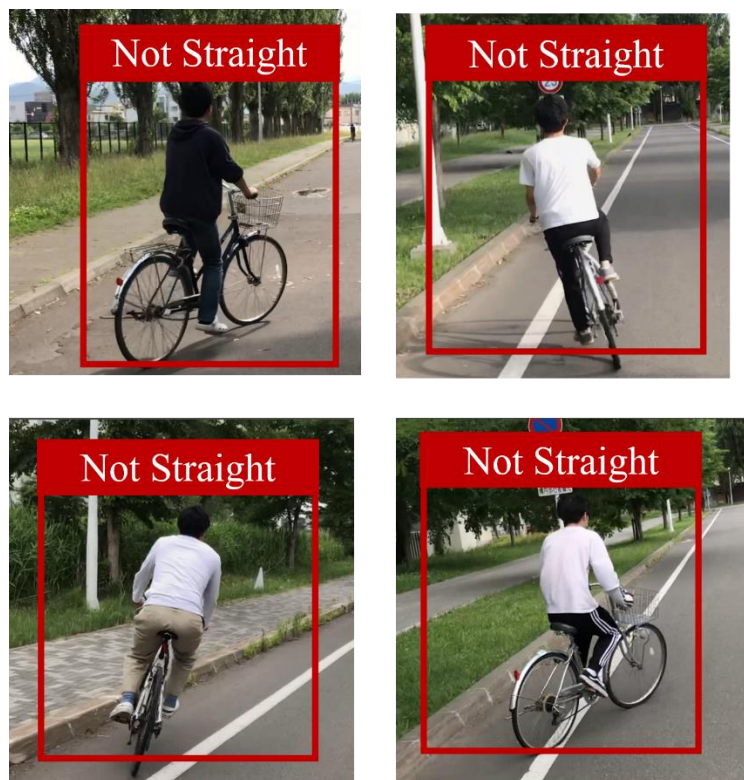


図 10 提案手法により，まっすぐでない走行と正しく識別された例



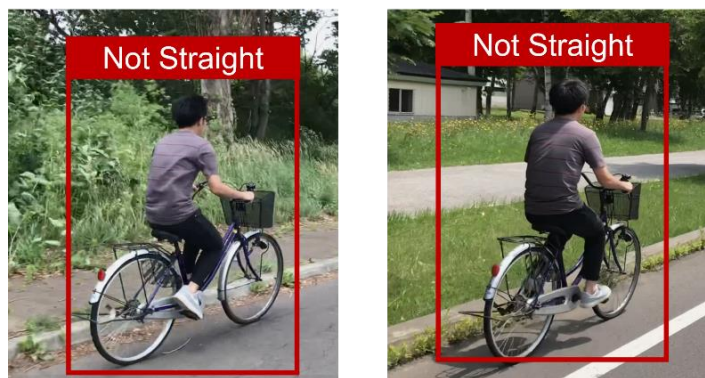


図 11 図 6 に示す方法によって抽出された自転車周辺の領域の例



(a) 正しく識別された例.



(a) 誤って識別された例.

図 12 提案手法により識別された、サイクリスト 3 のまっすぐな走行の例

### 3.5 道路映像における姿勢推定に基づく二輪車識別の検討

本章では、道路映像から自転車の通常とは異なる走行を認識する手法を提案した。具体的には、自転車を運転する人間の姿勢や運動に着目した特徴量を含む複数の映像特徴を入力とする機械学習によって、自転車の走行がまっすぐか否かを識別する手法を提案した。ここで、映像から自転車の走行を識別するためには、前段階として、映像から自転車を認識する必要がある。そこで、本章の以降では、映像から自転車を認識する手法について検討する。

道路を撮影した映像から交通参加者を認識する取り組みが数多く行われおり、その精度向上に向けて、深層学習に基づく一般物体認識を応用する手法が期待されている。しかしながら、自転車と自動二輪車は、その形状が類似することから、識別精度に課題がある。ここで、自転車と自動二輪車では、運転者の姿勢や運動に違いがある。したがって、この特徴に基づいた識別手法により、自転車と自動二輪車をより精度高く識別可能となることが期待できる。

そこで、運転者の姿勢や運動に関する特徴に基づいた自転車と自動二輪車の識別可能性について検討する。具体的には、Gabor wavelet や OpenPose に基づく画像・映像特徴によって実験を行い、その実現可能性を議論する。

#### 3.5.1 運転者の姿勢や運動に関する画像・映像特徴

Gabor wavelet や OpenPose に基づく画像・映像特徴について説明する。まず初めに、Gabor wavelet に基づく画像特徴について説明する。具体的には、画像内の自転車・自動二輪車が撮像された領域に対して、48次元のGabor wavelet に基づく画像特徴[108]を算出する。これにより、運転者の姿勢、すなわち画像中の形状の違いを表現可能な特徴を得る。

次に OpenPose に基づく映像特徴について説明する。自転車の運転者は、自動二輪車とは違い、ペダリング動作を行う。したがって、自転車と自動二輪車では、運転者の下半身の動きに違いがあると考えられる。そこで、図 13 に示すように、OpenPose により得る膝の位置と腰の位置を結ぶ線の水平方向からの角度を求める。自動二輪車の運転者は、膝と腰を結ぶ線の水平方向から角度の変化が少ないが、自転車の運転者はペダリング動作を行うため、角度が周期的に変化すると考えられる。以上により、自転車及び自動二輪車の運転者の運動に関する映像特徴を得る。

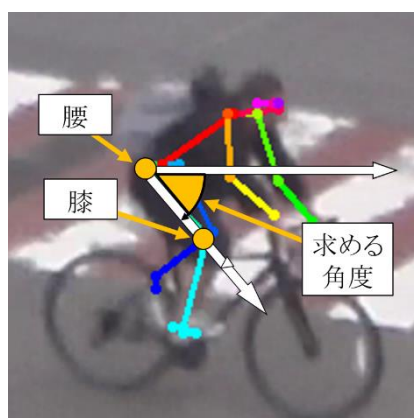


図 13 OpenPose に基づく映像特徴

### 3.5.2 実験

本実験では、定点カメラにより撮影した自転車・自動二輪車が撮像された映像を用いて実験を行う。まず初めに、Gabor wavelet に基づく画像特徴によって実験を行う。データ数は、自転車と自動二輪車それぞれ、14 台および 11 台である。3.5.1 で説明した方法により取得する 48 次元の画像特徴について、多次元尺度構成法[109]により 2 次元に縮退した結果を図 14 に示す。図 14 における緑色の点は自転車、青色の点は自動二輪車を示す。図 14 より、運転者の姿勢に関する Gabor wavelet に基づく画像特徴について、自転車と自動二輪車の識別可能性が示唆された。

次に、OpenPose に基づく映像特徴によって実験を行う。本実験では、OpenPose により、自転車および自動二輪車の運転者の骨格を検出可能な映像を用いる。自転二輪車と自転車について、運転者の右膝と右腰を結ぶ線における水平方向からの角度をフレーム毎に求め、プロットした結果をそれぞれ図 15 および図 16 に示す。図 15 より、自動二輪車の運転者は、膝と腰を結ぶ線の水平方向からの角度の変化が少ない。一方で、図 16 より、自転車の運転者については、角度が周期的に変化している。図 15 および図 16 より、OpenPose に基づく映像特徴について、自転車と自動二輪車の間に違いがあることが確認された。これらの結果より、OpenPose に基づく運転者の運動に関する映像特徴に基づいた自転車と自動二輪車の識別可能性が示唆された。






図 14 Gabor wavelet に基づく画像特徴の可視化

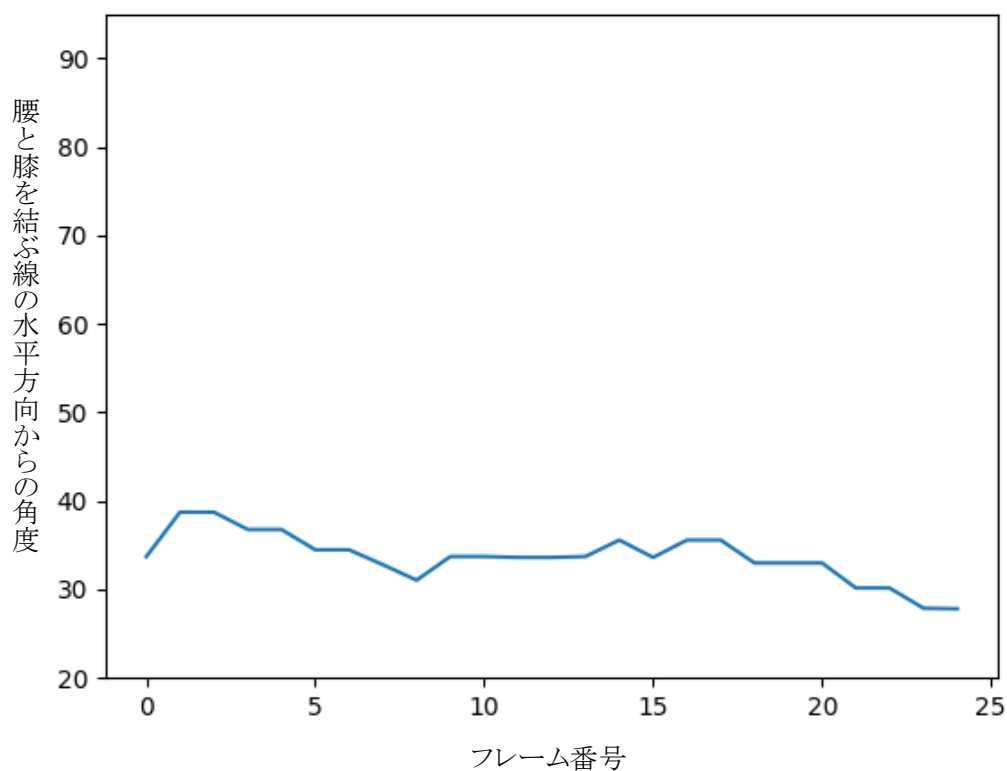


図 15 自動二輪車における膝と腰を結ぶ線の水平方向からの角




図 16 自転車における膝と腰を結ぶ線の水平方向からの角度

## 3.6 一般物体認識と姿勢推定に基づく二輪車の識別手法

3.5では、運転者の姿勢や運動に関する映像特徴に基づいた自転車と自動二輪車の識別可能性を確認した。そこで、本節では、運転者の姿勢推定に基づく二輪車の識別手法を提案する。具体的には、一般物体認識と姿勢推定に基づく二輪車の識別手法を提案する。

### 3.6.1 一般物体認識と姿勢推定に基づく二輪車の識別

提案手法について説明する。図17に提案手法の概要を示す。提案手法では、まず、道路映像に対して姿勢推定および一般物体認識を適用する。次に、同一人物の姿勢データをフレーム間で追跡する。次に、歩行者と人物以外の物体に誤推定される姿勢データを取り除き、二輪車運転者の姿勢データのみを抽出する。以降では、姿勢が誤推定された人物以外の物体をゴーストと呼ぶ。次に、抽出した二輪車運転者の姿勢データを用いて自転車か自動二輪車かを識別する。最後に一般物体認識の識別結果と姿勢推定に基づく識別結果を統合する。

#### (1) 一般物体認識および姿勢推定の適用

提案手法における一般物体認識と姿勢推定の適用について述べる。まず映像の各フレームに対して一般物体認識を適用する。次に姿勢推定を適用する際、信頼度スコアに閾値を設ける。信頼度スコアは、関節部位と推定された点に実際に関節部位が存在する確率を示す。ゴーストの多くは、信頼度スコアが比較的低い傾向が見られたため、閾値を設けることで除去する。

#### (2) 姿勢データの追跡

取得した姿勢データをフレーム間で追跡する方法を説明する。姿勢推定は画像内における人体の関節部位を座標形式で出力する。そこで、提案手法では、フレーム間での人物の移動量に着目する。具体的には、多くの場面で精度よく推定されていた首部の座標を用いて、移動量を計算する。最も移動量の小さい姿勢データが同一人物の姿勢データであると判断する。この計算を繰り返すことで同一人物の姿勢データを追跡する。

またフレーム間の移動量に閾値を設けることで、信頼度スコアの高いゴーストを除去する。これは、そのようなゴーストの姿勢推定値は不安定であり、フレーム間での移動量が大きくなるためである。ここまでの処理によって道路映像に対する姿勢推定の結果から、主に歩行者と二輪車運転者の追跡された姿勢データを取得可能となることが期待される。

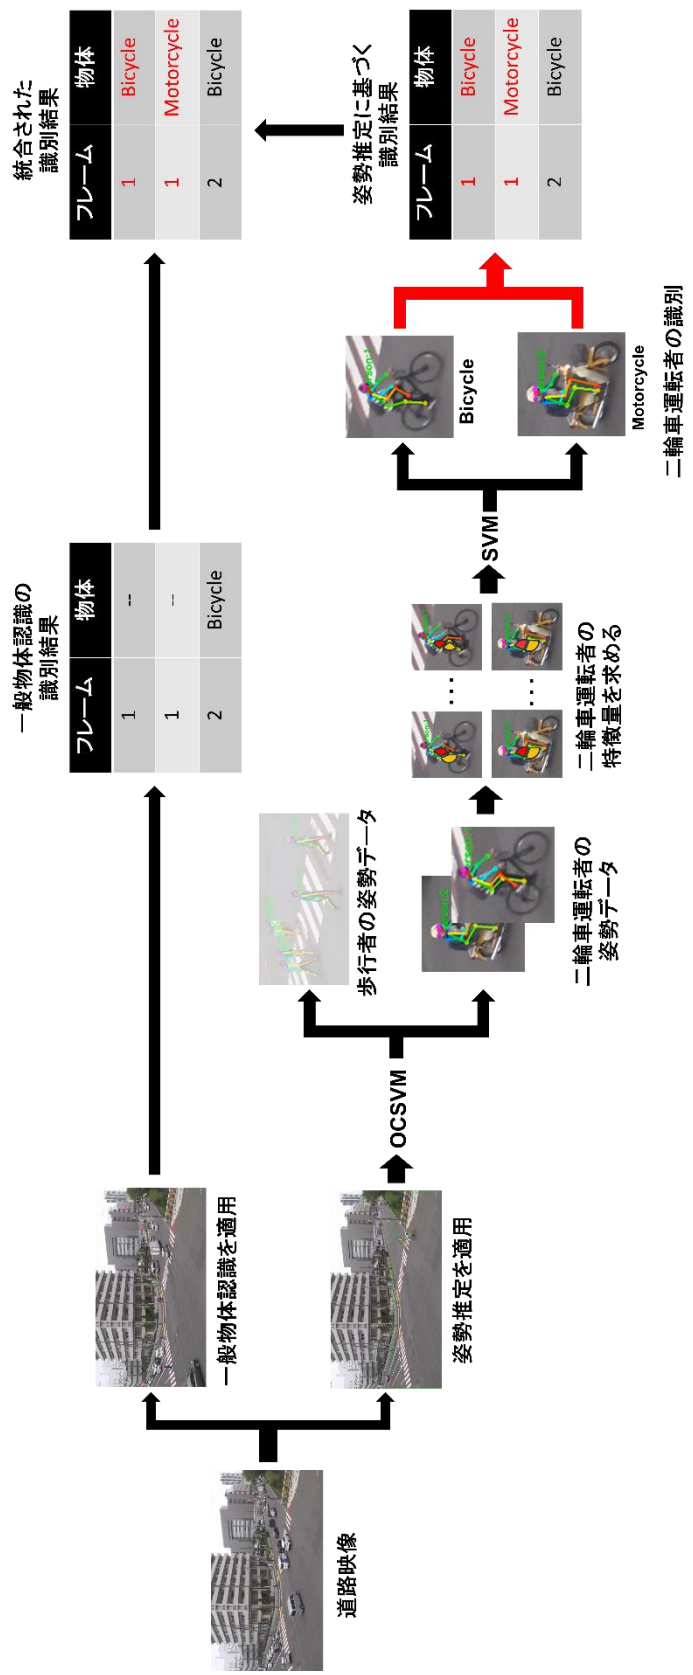


図 17 姿勢推定に基づき二輪車を識別する手法の概要




図 18 角 A, B, C

### (3) 歩行者と二輪車運転者の識別

(2)までに追跡した姿勢データを、歩行者と二輪車の運転者に識別する方法を説明する。提案手法では、図 18 に示す角度に着目し、識別を行う。まず角 A (肘—肩—腰) は腕の上がり具合を表す。二輪車の運転者はハンドルを握る必要があるため、両腕を前方へ伸ばす姿勢となる。歩行者も腕を振る動作をするが、平均的な角度は二輪車運転者がより大きくなることが期待される。次に角 B (肩—腰—膝) および角 C (腰—膝—くるぶし) は脚部の開き具合を表す。走行中、自転車の運転者はペダリング動作を行い、自動二輪車の運転者は足を所定の位置に固定しておく。これらはどちらも膝を折り曲げた状態になる。一方で歩行者は膝を大きく折り曲げることはないため、平均的な角度は歩行者の方が大きくなることが期待される。提案手法では、姿勢データの追跡を行った範囲で、角 A, B, C の平均値を左右の体側でそれぞれ計算する。角度の平均値を  $v_{i,n}^{mean}$  として、以下に示す特徴ベクトル  $v$  を算出する。ここで  $i(\in A, B, C)$  は角の位置を表し、 $n(\in right, left)$  は体側を表す。

$$v = [v_{A,right}^{mean}, v_{A,left}^{mean}, v_{B,right}^{mean}, v_{B,left}^{mean}, v_{C,right}^{mean}, v_{C,left}^{mean}] \quad (4)$$

提案手法ではこの特徴ベクトル  $v$  を入力とする One Class Support Vector Machine(OCSVM)[92]を構築する。OCSVM は一つのクラスのデータを正常データとして学習することで、そのクラスに属さないデータを異常データとして検出できる。提案手法においては、歩行者を正常データとして学習することで二輪車運転者を異常データとして検出可能である。

#### (4) 二輪車運転者の識別

(3)で二輪車運転者と判定された姿勢データを，自転車の運転者と自動二輪車の運転者に識別する方法を説明する．提案手法では自転車の運転者と自動二輪車の運転者の違いを表すために，図 18 に示す角 B と角 C を用いる．自転車の運転者はペダリング動作によって，角 B および角 C に時間的な変化が生じる．一方で，自動二輪車の運転者は基本的に，足を所定の位置に固定しておくため時間的な変化は生じにくい．したがって，角 B および角 C の平均と分散は，いずれも自動二輪車の運転者に比して，自転車の運転者で大きくなることが期待される．そこで，角度の分散に基づく特徴量 $v_{i,n}^{var}$ と角度の平均に基づく特徴量 $v_{i,n}^{mean}$ を用いて次の特徴ベクトル $V$ を算出する．ここで $i(\in B, C)$ は角の位置を表し， $n(\in right, left)$ は体側を表す．

$$V = [V^{var}, V^{mean}] \quad (5)$$

ただし，

$$V^{var} = [v_{B,right}^{var}, v_{B,left}^{var}, v_{C,right}^{var}, v_{C,left}^{var}] \quad (6)$$

$$V^{mean} = [v_{B,right}^{mean}, v_{B,left}^{mean}, v_{C,right}^{mean}, v_{C,left}^{mean}] \quad (7)$$

提案手法では特徴ベクトル $V$ を入力とする Support Vector Machine(SVM)を構築する．SVM は特徴ベクトルを高次元空間に写像し，境界となる超平面を張ることでデータを識別可能である．SVM により自転車の運転者と自動二輪車の運転者の姿勢データを識別することで，結果的に二輪車を識別することが可能となる．

#### (5) 一般物体認識と姿勢推定に基づく識別結果の統合

最後に，(1)で得た一般物体認識の識別結果と，(4)までに得た姿勢推定に基づく識別結果を統合する．具体的には，一般物体認識で二輪車が識別された場合にはその結果を採用する．一般物体認識で二輪車が存在しないと判断された場合には，姿勢推定に基づく識別結果を採用する．

表 5 OCSVM で用いたデータ数

	内訳	データ数
学習	歩行者	10,000
テスト	歩行者+二輪車運転者	20,711

表 6 識別器で用いたパラメータ

パラメータ	パラメータの設定	
	OCSVM	SVM
kernel	linear	rbf
C	-	1.0
gamma	-	scale

### 3.6.2 実験

実際の道路空間を撮影した映像を用いて実験を行い提案手法の有効性を確認する。以降では、実験設定および実験結果を示し、考察を行う。

#### (1) 実験設定

本実験で用いた道路映像の例を図 19 に示す。道路映像のピクセル数は  $3840 \times 2160$ 、フレームレートは 30FPS である。本実験では、姿勢推定の精度を確保するため、映像の下半分を分析対象とする。また、本実験では一般物体認識モデルとして YOLOv7[133]、姿勢推定モデルとして OpenPose を用いる。次に OCSVM の学習、およびテストに用いたデータ数を表 5 に示す。ただしデータとは、同一人物を追跡することで得た連続の姿勢データを指す。本実験では 30 フレームの追跡を行う。識別器構築時には、複数のパラメータの組み合わせを試行し、表 6 に示す、最も精度の高くなった値を用いる。評価指標としては以下に示す、再現率、適合率、F 値を用いる。

$$\text{再現率} : R = \frac{\text{正しく二輪車を識別したデータ数}}{\text{自動二輪車} \cdot \text{自転車のデータ数}} \quad (8)$$



図 19 実験に用いた道路映像の例




図 20 OCSVM で歩行者と判定された例

$$\text{適合率} : P = \frac{\text{正しく二輪車を識別したデータ数}}{\text{自動二輪車・自転車と識別したデータ数}} \quad (9)$$

$$F \text{ 値} = \frac{2 \times R \times P}{R + P} \quad (10)$$

また一般物体認識の結果のみを用いた手法を比較手法とする。

## (2) 実験結果と考察

提案手法および比較手法について再現率、適合率、F 値を表 7 に示す。表 7 より、自転車においては、提案手法が再現率と F 値で比較手法を上回った。自動二輪車においては同程度の識別精度となったことが確認できる。

次に姿勢データの追跡と二輪車運転者の抽出機能の精度を確認する。表 8 に示すように、テストに用いたデータのうち、626 データが OCSVM によって二輪車運転者として検出された。そのうち実際に二輪車運転者であったものは 555 データであり、71 データは歩行者のものであった。一方で、道路映像中のすべての二輪車運転者を抽出できていないことが確認された。具体例としては図 20 に示すように、カメラに面する方向で走行した場合である。この場合、二次元の座標系から求まる角度によって腕の上がり具合や、脚部の開き具合を正しく求めることが困難であり、二輪車運転者であっても、得られる特徴量は歩行者のものに近くなることが考えられる。したがって今後の課題として、三次元での姿勢推定が可能なモデルを用いることが必要である。なお本実験においては一般物体認識では正しく識別されていたために最終的な精度には影響を及ぼさなかった。

次に自転車の識別結果について考察する。表 7 より再現率および F 値において、提案手



表 7 実験結果

	自転車		自動二輪車	
	提案手法	比較手法	提案手法	比較手法
再現率	<b>0.545</b>	0.226	<b>0.973</b>	<b>0.973</b>
適合率	0.904	<b>0.977</b>	<b>0.836</b>	<b>0.836</b>
F 値	<b>0.680</b>	0.367	<b>0.899</b>	<b>0.899</b>

表 8 SVM で用いるデータ数

	自転車運転者	自動二輪車運転者	歩行者
学習	1,374	607	-
テスト	376	179	71

法が比較手法を大きく上回った。一般物体認識を単体で用いた場合に自転車の再現率が低くなった理由としては、自転車が小さく撮像されるということに加えて、細いパーツから成るという点が考えられる。一般物体認識モデルが畳み込み処理によって特徴抽出を行う過程で自転車の特徴は十分に抽出されない可能性がある。一方、提案手法では、姿勢推定によって自転車の運転者に基づいて識別を行うことが効果的に働いたといえる。提案手法で適合率が低くなったのは、OCSVM が二輪車運転者と判定した歩行者の姿勢データがすべて自転車と識別されたためである。このことより、OCSVM の精度を向上させることが課題である。また姿勢推定では正しく識別されるが、一般物体認識では誤って識別される場合が多く確認された。したがって、一般物体認識の結果をそのまま用いるのではなく、姿勢推定に基づく識別結果を踏まえた上で、再度最終的な識別を行う仕組みが必要である。

次に自動二輪車の結果について考察する。本実験では提案手法と比較手法で自動二輪車の識別精度は同程度である。これは自動二輪車が比較的面積の大きいパーツから成ることから一般物体認識が多くのフレームで正しい識別を行うことが可能であり、再現率が高くなる傾向があることによる。提案手法では一般物体認識で二輪車が識別されている場合その結果を採用するため、姿勢推定に基づく識別結果が影響を及ぼさなかったと考えられる。提案手法においては、先述の自転車を自動二輪車と誤って識別してしまう点を解決することでさらなる精度向上が期待される。

### 3.7 まとめ

本章では、道路映像を用いて自転車の通常とは異なる走行を識別するための新しいマルチモーダルな手法を提案した。提案手法はマルチモーダルなアプローチに基づいて自転車の走行がまっすぐか否かを識別する。具体的には、提案手法では、まず、サイクリストの関節位置に基づく特徴量とオプティカルフローに基づく特徴を抽出する。次に、提案手法では暫定的な認識を行う。提案手法は、サイクリストの関節位置に基づく特徴量のみを用いて自転車の走行を識別する。同様に、オプティカルフローに基づく特徴量のみを用いた認識も行う。最後に、提案手法では、各識別器から得る帰属確率に基づいて、最終的な認識結果を取得する。実験により、提案手法の有効性が確認された。また、自転車の走行を分析するためには、前段階として、道路映像から自転車を認識する必要がある。道路映像から交通参加者を認識する手法として、深層学習に基づく一般物体認識を応用する手法が期待されるが、自動二輪車と自転車の識別に課題がある。ここで、自動二輪車と自転車では、運転者する人間の姿勢や運動に違いがある。そこで、本章の最後では、運転者の姿勢推定に基づいて、映像から二輪車を識別する手法について検討した。

## 第4章 道路空間モニタリングのためのエッジコンピューティング基盤とその応用

### 4.1 はじめに

本章では、道路空間モニタリングのためのエッジコンピューティングによるデータ集積機構を構築する。本論文では、自転車が通常どおりに走行可能な空間となっているかを評価可能とすることを目的の一つとしている。上記の目的を達成するための手段として、GPSデータを利用した方法が考えられる。しかしながら、GPSの測位誤差は数メートルに及ぶことから、精度良く回避行動を認識することは難しい。加えて、Real Time Kinematic GPS などの高精度な測位が可能な機構は、その導入に大きなコストを要する。一方で、CCTVや車載カメラは、既に多くの箇所に設置され、道路管理に広く活用されている。加えて、車両及び人間の認識や社会インフラの利用者の動作分析等を可能とする映像解析の手法が広く提案されており、その有効性が示されている[93,94]。したがって、道路映像を活用することで、簡便に自転車の走行に関するデータの集積が可能となることが期待できる。そこで、本研究では、CCTVや車載カメラによって取得された映像を活用することで、自転車が通常どおりに走行することが困難な道路状況を把握可能とすることを目指す。

本研究の目的を実現するためには、次の3つの要素技術：① 観測、② 通信、③ 可視化が必要である。具体的に、①は、映像を解析することで自転車の挙動を観測し、データを取得可能とする技術である。次に、②は、通信ネットワークを経由して、データを伝送する技術である。最後に、③は、集積データを地図上へ可視化する技術である。本章では、3つの要素技術の内、①の構築に取り組む。本稿では、第3章で提案したサイクリストや自転車の動きに関する複数の特徴量に基づいて自転車の走行を識別し、その識別結果に基づくデータ集積を可能とするエッジコンピューティング基盤を構築する。図21に概要を示す。本機構では、認識結果および低容量の映像を集積する機能を有する。また、図21の左側に示すように、本機構は、バッテリーで駆動が可能なマイクロコンピュータ、およびUSB接続型の外部演算装置により構成される。これにより、様々なインフラ設備や車両などへの搭載が可能となる。本機構における自転車の走行の識別は、サイクリストおよび自転車の動きに関する複数の特徴量それぞれを入力とする識別器によって実現する。このデータ集積機構を用いることで、道路状況に関するデータの高効率な集積が可能となる。さらには、この集積されたデータを地図上で可視化し、道路管理者などに提示することで、道路状況を広範囲に効率良く把握可能となることが期待できる。例えば、図22は、車載カメラにより取得した映像から道路のひび割れを検出し、検出結果を地図上で可視化した例であるが[96]、このようなマップを本機構で集積するデータを用いて生成し、道路管理者に提示することで、道路が危険な状

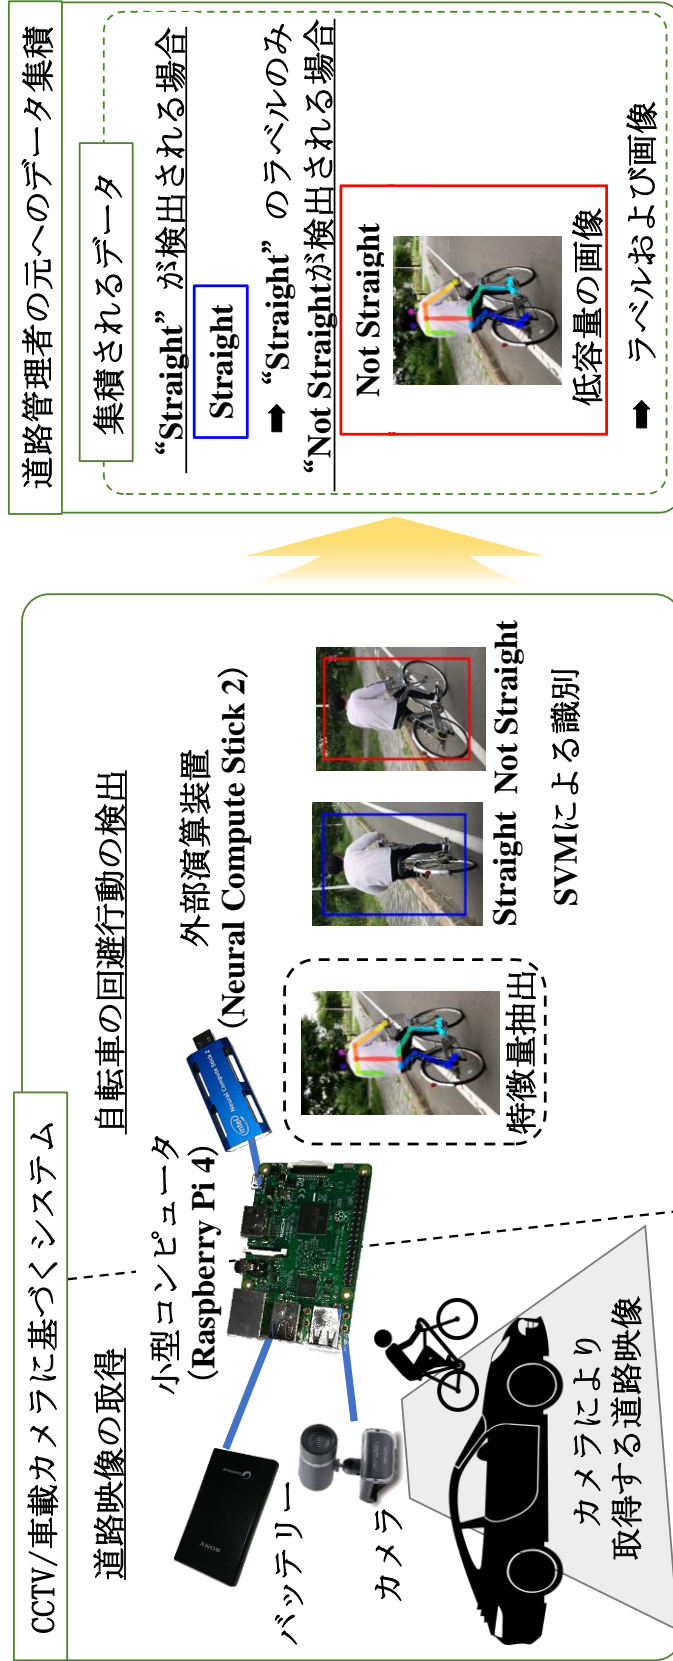


図 21 自転車の走行に関するデータ集積機構の概要

況にあることの把握を支援可能となる。具体的には、例えば、自転車のまっすぐでない走行が路面の損傷に起因している場合、その情報が集積されることで、損傷に関する道路状況を自動的にモニタリングできると考えられる。さらには、集積データの分析や、通常とは異なる走行が多く発生している道路に対するパトロール、画像を介した目視確認等を行うことで、道路の損傷などの移動を阻害する要因を効率的に把握可能となると想定される。これは、道路管理の高度化につながるものであり、自転車がより安全に走行できる道路環境の形成が期待できる。以降、本章では、4.2 でマイクロコンピュータに実装するデータ集積機構について説明し、4.3 で、集積するデータについて説明する。さらに、4.4 では、データ集積機構の実現可能性を実験により確認する。

また、4.5 では、4.4 までに得た知見に基づいて、構築したエッジコンピューティング基盤を発展させ、他の土木工学へ応用することに取り組んでいる。本論文では、より安全に移動可能な道路空間の実現に向けたモニタリングのためのエッジコンピューティングに関して検討しているが、積雪寒冷地の冬期道路では、移動を妨げる路面状態や視界状況が頻繁に観測される。したがって、より安全な実空間を実現するためには、路面や視界を常にモニタリングする必要がある。そこで、4.5 では、積雪寒冷地の冬期道路をモニタリングの対象とした、マイクロコンピュータによるエッジコンピューティング基盤を構築する。構築するエッジコンピューティング基盤は、映像解析や機械学習に基づいて路面や視界の状況を分析し、その分析結果を集積可能とする。

本章の 4.5 までには、2 種類のエッジコンピューティング基盤を構築するが、その二つは共に、機械学習に基づく AI によって映像を解析し、その解析した結果を集積している。ここで、汎化性に優れた AI を実現するためには、大規模な学習データセットが必須である。また、機械学習モデルは過去事例に基づいて分析を行うが、様々な事象に対応できるようなデータセットを事前に用意することは困難である。そのため、エッジコンピューティング基盤を複数台用いて実空間をモニタリングするシステムを運用していく上では、個々のエッジが獲得する知識を共有しながら逐次的に AI を更新していくことが求められる。これを実現するためには、エッジ AI の更新に有効なデータを有する他のエッジを選択する手法が必要であり、4.6 ではその方法論の導出に取り組む。

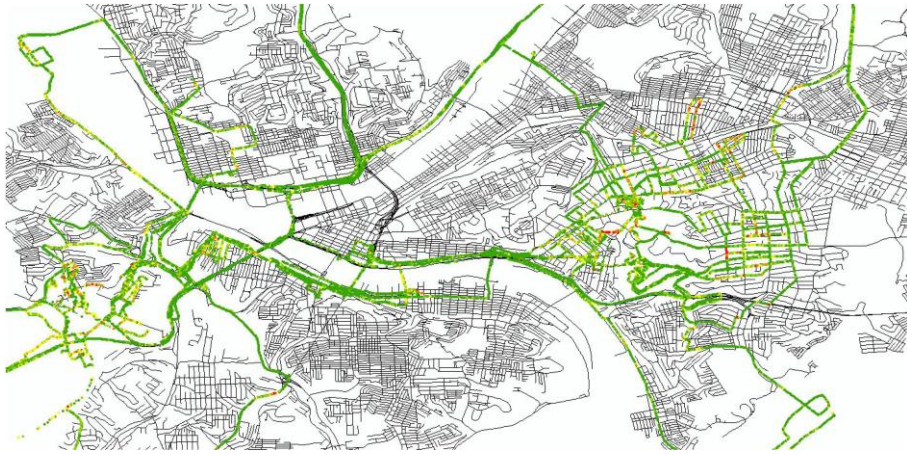


図 22 道路のひび割れを認識し，地図上で可視化した例  
(文献[96]より抜粋)

## 4.2 自転車の走行に関するデータ集積機構

本節では、提案するデータ集積機構について説明する。図 23 に構築するデータ集積機構の構成図を示す。本機構は、バッテリーでの駆動が可能なマイクロコンピュータ、カメラ、および USB 接続型の外部演算装置によって構成する。本機構は、小型かつバッテリー駆動が可能であるため、様々なインフラ設備や車両への搭載が可能となる。また、本機構では、第 3 章で説明した道路映像から自転車の走行を識別する手法を演算可能なプログラムを実装する。本機構では、マイクロコンピュータとして、Raspberry Pi 4<sup>1</sup>を用いる。表 9 に、Raspberry Pi 4 の仕様を示す。また、本機構では、Full HD (1920×1080) での撮影が可能なカメラを搭載する。本機構に実装する手法に含まれる OpenPose は、深層学習による骨格データの取得手法であり、比較的大きな計算コストを必要とする。したがって、本機構では、外部演算装置によってその演算を可能とする。具体的には、USB 接続型の外部演算装置である Intel Neural Compute Stick 2<sup>2</sup>を用いる。Intel Neural Compute Stick 2 は、コンピュータビジョンや深層学習の各種関数を提供する Software Development Kit として、OpenVINO が利用可能である。本機構では、Intel Neural Compute Stick 2 と OpenVINO を用いることで、マイクロコンピュータ上での深層学習の演算を実現する。また、本機構では、ネットワークを介したデータ伝送によるデータ集積を可能としている。具体的には、簡便に構築可能な Apache サーバと WebDAV によってこのデータ転送機能を実現している。

---

<sup>1</sup> <https://www.raspberrypi.org/>

<sup>2</sup> <https://software.intel.com/en-us/neural-compute-stick/>

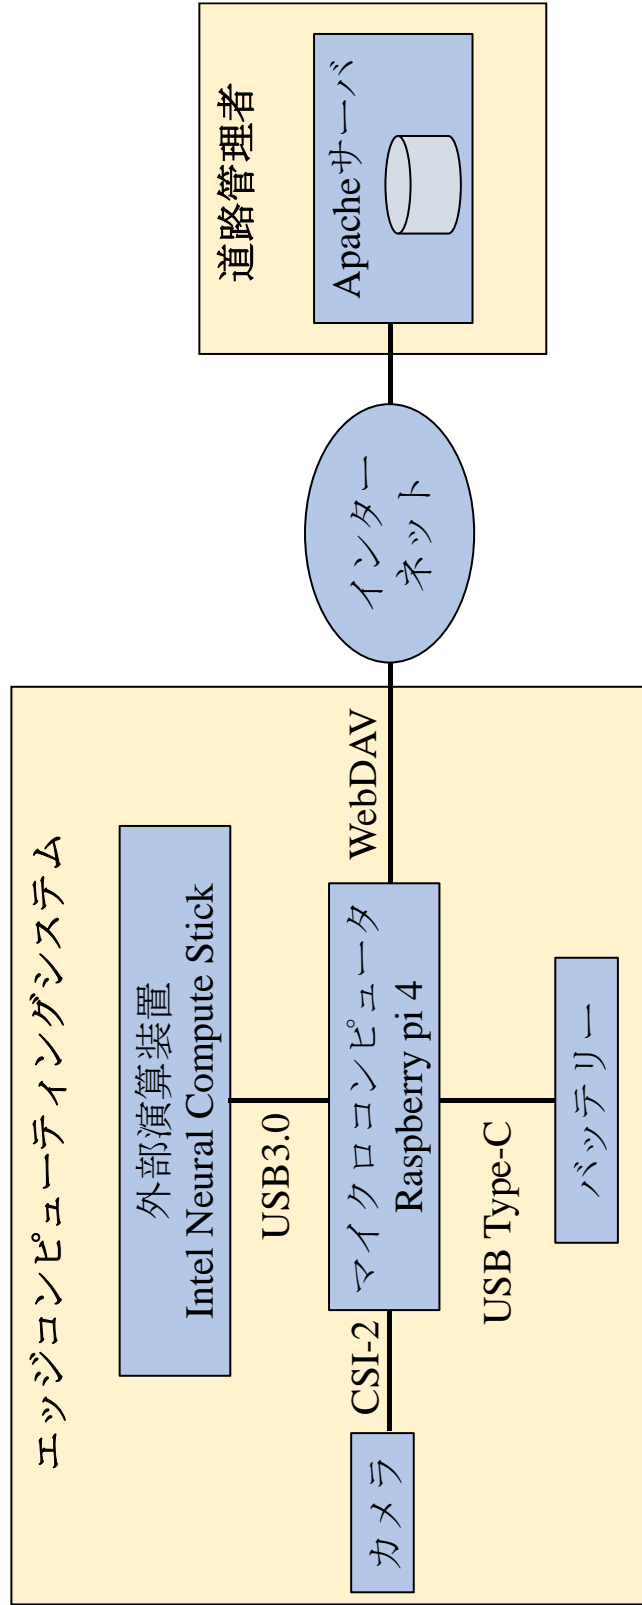


図 23 自転車の走行に関するデータ集積機構の構成図



表9 Raspberry Pi 4 の主な仕様

項目	内容
使用 SoC	Broadcom BCM2711
CPU (型名)	ARM Cortex A72
コア数	4
クロック [Hz]	1.5G
GPU	Broadcom VideoCore IV 500MHz
RAM [Byte]	1/2/4G
最大消費電力	1250mA, 6.25W
本体質量	46g
外形寸法	88 × 58 × 19.5 mm

### 4.3 集積されるデータ

本機構により集積されるデータについて説明する。図 21 の右側に示すように、本機構では、自転車の走行を識別した結果を常に集積するとともに、「まっすぐでない走行」が認識された場合に限り、低容量の画像を集積する。集積する画像の解像度やピクセル数については、適応的に決定することができる。また、SVM や ELM の再学習などの目的に応じて、認識する際に用いた特徴量を集積することも可能である。これらより、本機構を用いることで、道路映像を撮影された画のままに集積する場合に比べ、より小さな容量でのデータ伝送、および道路状況を目視可能な画像データの集積が可能となる。また、本機構によって自転車の通常とは異なる走行に関するデータが自動で集積可能となるため、通常とは異なる走行が発生しやすい道路状況の迅速な把握が可能となる。したがって、より安全な道路交通の実現に向けた道路管理の高度化が期待できる。なお、例えば前方車両の追い抜きなど、道路の障害物などに関係なく、まっすぐでない走行が観測される場合も十分に想定されるが、道路の障害物などのまっすぐでない走行を発生させる要因が存在しない道路状況であれば、その箇所においては、“まっすぐな走行”が常に観測されると考えられるため、データを一定量蓄積した場合には、その影響は小さいと考えられる。




図 24 データ集積機構の試作機

#### 4.4 実験

実験により、提案するデータ集積機構の実現可能性を確認する。提案する機構の実現可能性を確認するために、自転車の走行を識別する手法を実装したデータ集積機構を試作し、実験を行う。具体的には、図24に示すように、小型カメラ、Raspberry Pi 4 (RAM=4GB) および Intel Neural Compute Stick 2を用いる。また、Raspberry Pi 4 に実装するOSとしてはRaspbianを採用する。加えて、映像を用いて自転車の通常とは異なる走行を認識する手法は、Pythonにより実装する。実験では、実際にカメラにより映像を取得し、第3章で提案する手法に基づく自転車の通常とは異なる走行の認識、およびその認識結果に基づくデータ集積を行う。

まず初めに、計算時間について考える。本実験では、本機構の有用性を確認するために、異なる計算機環境で同様の計算を行い、その結果を比較する。比較する機構（以降、比較機構1）の具体的な計算機のスペックはCPUが3.30GHz Intel Core i5-4590、GPUがNvidia GeForce GTX 1070 Ti、メモリが12GBとなっている。また比較機構1では、GPUを用いた演算により、OpenPoseを利用した骨格データの取得を実現し、その他の処理はCPUにより

計算する。また、映像から回避行動を認識する手法の実装に関しては、本機構と同様に、Pythonにより行う。表10に、フレームの取得から最終的な認識結果を取得するまでの計算時間を示す。表10より、本機構の計算時間は $8.10 \times 10^{-1}$ 秒である。これはすなわち、1秒間におよそ1回の頻度で、回避行動の認識が可能であることを意味する。本機構を搭載した車両の速度が40km/hであると仮定すると、10mに1回の計算が可能である。これは、文献[97]で対象とする、舗装路面に対して獲得された膨大な路面性状調査データと同程度の空間解像度である。この内容から、本機構の有用性が確認できる。また、表10より、比較機構1での計算時間は $2.59 \times 10^{-1}$ 秒である。この比較機構は、Nvidia GeForce GTX 1070 Tiを有しており、映像を解析する上で優れた環境であるにも関わらず、 $2.59 \times 10^{-1}$ 秒もの計算時間を必要とする。本機構では、比較機構1に比べて小型かつ安価であるにも関わらず、このような高コストな映像解析を、10mに1度の間隔でリアルタイムに計算可能であることが確認された。

次に集積するデータの容量について考える。本実験では、本機構の有用性を確認するために、文献[98]で利用されているような、CCTVカメラにより取得した映像をその画のままに集積する機構を比較対象として用いる（以降、比較機構2）。本実験では、1レコードの容量を考える。表11に、1レコードの内容を機構別に示す。本機構では、認識結果（ラベル）を集積するとともに、回避行動が認識された場合のみ、低容量の画像を集積する。低容量の画像のピクセル数は適応的に決定することができるが、本実験では $456 \times 256$ とする。これは、OpenPoseにより骨格データを取得する際に、ニューラルネットワークに入力するサイズと同じである。また、比較機構2では、ピクセル数が $720 \times 480$ である画像を集積する。このピクセル数は、実際にCCTVカメラにより集積されているデータを参考に決定した[98]。また、CCTVカメラにより集積されている画像の多くが24ビットのカラー画像であることから、本実験でも同様に採用する。本実験では、1レコードの容量をビット単位で比較する。まず、比較機構2における1レコードの容量を考える。本実験で集積する画像は24ビットのカラー画像であるため、1ピクセル当たりのデータ容量は24ビットである。したがって、ピクセル数が $720 \times 480$ である画像を集積する比較機構2の1レコードの容量は、 $8.29 \times 10^6$ ビットなる。次に、本機構によりまっすぐでない走行が認識された場合のデータ容量を計算する。本機構で想定される認識結果は“nst”および“st”の2種類であるため、認識結果（ラベル）は1ビットのデータ容量で集積可能である。したがって、本機構によりまっすぐでない走行が認識された場合に集積するデータの容量は、認識結果のデータ容量である1ビットと、ピクセル数が $456 \times 256$ である画像のデータ容量を足し合わせることで算出可能であり、その値は $2.80 \times 10^6$ ビットとなる。次に、まっすぐでない走行が認識されない場合のデータ容量を考える。この時、集積されるデータは認識結果のみであるため、そのデータ容量は1ビットである。以上より、本機構を用いることで、まっすぐでない走行が認識された場合には、その画のままに画像を集積する場合のデータ容量を約3分の1に

削減可能であり、認識されない場合には、約829万分の1に削減できることが分かる。また本機構は、通信ネットワークへの負荷軽減やスムーズなデータ転送に貢献する必要がある。具体的には、十分な情報をリアルタイムに伝送するために、データ容量を圧縮する必要がある。例として、本機構を搭載した車両が、回避行動を認識するための計算を毎秒行いながら15分間走行することを考える。ここでは、走行中に遅延なくデータを伝送することが重要である。データの伝送にはLTEを利用するとして、その実質データ転送レート（上り）を5Mbpsと仮定する。この時、15分の映像をその画のままに集積する場合には、データの伝送に25分程度の時間を必要とするため、走行中に遅延なく伝送することは困難である。しかしながら、データの容量を約3分の1または約829万分の1に削減可能な本機構では、少なくとも9分程度の時間でデータを伝送可能であり、走行中に遅延なくデータを伝送することが十分に期待できる。以上の内容から、本機構の有用性が確認できる。ここで、まっすぐな走行が観測された場合の映像については、速報性は必要ないが、将来的に活用する場面も想定される。このような場合には、ローカルに記録することが望ましい。しかしながら、全ての映像をその画のままに記録する仕組みでは、データ量が膨大であることが課題となる。そこで、エッジで映像を解析する場合には、カメラにより取得した画のままの映像を活用し、記録する場合には、高圧縮率の符号化方式を用いて低容量の映像を記録するなどの仕組みを導入することで、蓄積するデータ量を効果的に削減可能となることが期待できる。

最後に、今後の取り組みを示す。実験で確認したように、本機構が自転車の走行を識別するのに必要な計算時間は、実利用が可能な程度に十分小さな値であるが、これを減少させることで、より細かな頻度で通常とは異なる走行に関するデータの集積が可能となる。そこで、今後は計算時間の減少に向けた取り組みを検討する。表 12 に、各処理の計算時間を示す。12 より、両機構共に、a)サイクリストの関節位置に基づく特徴量の抽出に、比較的大きな計算時間を要していることが分かる。これは、OpenPose によるサイクリストの骨格データ取得が大きな計算コストを要するからである。ここで、本機構ではこの計算を Intel Neural Compute Stick 2 により実行しているが、この外部演算装置は、複数を併用可能である。したがって、複数の Intel Neural Compute Stick 2 によって、並列に計算することで計算時間の削減が期待できる。また、本実験で実装したプログラムは、各処理を直列に計算しており、並列に処理することでより短い時間での処理が可能となると考えられる。実験で用いた Raspberry Pi 4 に搭載された CPU のコア数は4つであるため、OS を稼働させるためにコアを一つ利用すると考えると、およそ3つの処理を別々のコアで並列計算できると考えられる。以上のように、本機構は、より高速な処理を実現しうる可能性を大きく有しており、今後はこれらを実験により検証する予定である。加えて、本章で提案した機構を複数台用いて、実道でのデータ集積実験を行うことも同様に検討する。

表 10 各機構におけるフレームの取得から最終的な認識結果を取得するまでの計算時間

	本システム	比較システム 1
フレームの取得から最終的な検知結果を 取得するまでの計算時間 (sec)	$8.10 \times 10^{-1}$	$2.59 \times 10^{-1}$

表 11 各機構を用いて集積するデータの内容

	ラベル	集積する内容
本システム	<i>nst</i>	検知結果, 低容量の画像 (ピクセル数: 456×256)
	<i>st</i>	検知結果
比較システム 2	—	取得された画のままの画像 (ピクセル数: 720×480)

表 12 各機構における処理毎の計算時間

実装するアルゴリズムで行う主な処理の内容	計算時間 [sec]	
	本システム	比較システム
a) サイクリストの関節位置に基づく特徴量の抽出	$6.06 \times 10^{-1}$	$2.34 \times 10^{-1}$
b) オプティカルフローに基づく特徴量の抽出	$3.28 \times 10^{-2}$	$0.44 \times 10^{-2}$
c) サイクリストの関節位置に基づく特徴量を入力とする SVM による識別	$2.73 \times 10^{-3}$	$0.33 \times 10^{-3}$
d) オプティカルフローに基づく特徴量を入力とする SVM による識別	$1.11 \times 10^{-3}$	$0.12 \times 10^{-3}$
e) サイクリストの関節位置に基づく特徴量を入力とする ELM による識別	$4.70 \times 10^{-4}$	$1.12 \times 10^{-4}$
f) オプティカルフローに基づく特徴量を入力とする ELM による識別	$2.28 \times 10^{-4}$	$0.26 \times 10^{-4}$
g) 複数の識別器から得られる識別結果に対する確信度の統合	$9.13 \times 10^{-5}$	$1.25 \times 10^{-5}$

## 4.5 冬期の道路状況を観測するエッジコンピューティング基盤

北海道などの積雪寒冷地では、吹雪を起因とした視界不良による道路の通行止めが多発する。また、路面の凍結による交通事故も発生している。このような厳しい冬期の道路状況では、しばしば、複数車両による衝突事故が発生し、これは、多大な経済的損失をもたらす。このような背景から、道路管理者や各種交通サービスの管理者が、視界状況および路面状態をリアルタイムに把握可能となることが望ましい。

視界不良を自動で検知可能とすることを目的として、北海道では、道路沿いに設置された CCTV（閉回路テレビ）カメラを活用した視界状況評価の取り組みが行われている。文献[110-112]では、CCTV カメラにより取得されたデジタル画像を処理することで、悪天候下での視界不良を識別する手法を提案されている。具体的には、パワースペクトルの重み付け強度（WIPS）を活用することで、視界不良の識別を実現している。しかしながら、CCTV カメラの視野はドライバの視野とは異なるため、ドライバ目線の視界状況を把握することは難しい。また、CCTV カメラは約 5km 間隔で設置されており、道路空間の視界状況を解像度高く把握することは困難である。

一方、事故防止のため、高速道路管理者は凍結防止剤の散布を行っている。凍結防止剤の散布は、濡れた路面の水の凍結温度を下げることで、路面の凍結を効果的かつ効率的に防ぐ方法である。しかしながら、過剰な散布は、道路構造物の劣化を引き起こすため、凍結防止剤の使用量を削減することが重要である[113,114]。この問題を解決するために、Intelligent Salting Control Optimization System が研究されている[115]。具体的には、路面状態を把握して、道路に散布する防止剤の量を最適化するシステムである。この最適化のための方法として、路面状態を判別するセンサシステムに基づく方法が提案されている[116]。しかしながら、このセンサシステムは、タイヤ内部に設置されたセンサによって得られるデータのみを活用するため、タイヤが通過していない路面状態の判別は不可能である。そのため、現在の冬期高速道路管理では、人手による観測と、センサシステムに基づくデータ解析の両方によって路面状態の判別を行っている[116]。

近年、小型化・低コスト化が進み、多くの車両にカメラが搭載されている。そのため、車載カメラによって撮影された画像を蓄積することが可能である。加えて、画像から道路状況を解析する様々な手法が提案されている[96, 117]。したがって、画像処理に基づく手法を活用することで、道路状況の効率的な認識が実現されている。しかしながら、蓄積された画像の解析には膨大な時間と大型の計算機が必要であり、即時解析は困難である。

そこで、本節では、小型計算機を利用し、冬期道路における路面状態および視界状況を観測するためのエッジコンピューティングによるデータ集積機構を構築する。構築するデータ集積機構は、車載カメラによる前方視野の映像を記録し、記録された映像から視界状況と路面状態を同時に推定する。視界状況は、各画像のパワースペクトルを基に算出する。路面状態は、ニューラルネットワークを用いた画像認識により求める。現在、構築したデータ集

積機構を都市間バスおよび道路パトロールカーに実装し、実道でのデータ集積を行っている。以降では、まず、構築したデータ集積機構について詳述し、次に、都市間バスや道路パトロールカーに実装したデータ集積機構の冬期における動作状況について説明する。

#### 4.5.1 路面状態および視界状況を推定する手法

##### (a) 路面状態を推定する手法

車載カメラにより取得した画像を用いて、冬期の路面状態を推定する手法を説明する。提案するデータ集積機構では、車載カメラから取得した画像を dry, semi-wet, wet, slush, ice, flesh, の6つのクラスに分類する。この手法は、軽量な深層畳み込みニューラルネットワーク(CNN)の一つである Mobile Nets[118]に基づいている。Mobile Nets は従来の CNN よりも計算コストが低い。そのため、Mobile Nets を用いることで、限られた計算資源で即時に画像を解析可能となることが期待できる。本アルゴリズムでは、車載カメラから取得した画像を用いて Mobile Nets を構築する。そして、構築した Mobile Nets を用いることで、冬期の路面状態を即座に推定可能となることが期待できる。

##### (b) 視界状況を推定する手法

構築したデータ集積機構では、視界状況を評価するために、路面状態の推定と同時に WIPS(Weighted intensity of power spectra)を算出している。WIPS の大きさは、人間のコントラスト感度関数に基づく画像内の空間周波数の差を表現しており、視界の悪さを識別可能となることが期待できる

#### 4.5.2 エッジコンピューティングによる路面および視界のデータ集積機構

構築したデータ集積機構は、一部の都市間バスおよび道路パトロールカーに搭載されている。本機構は2つのサブシステムから構成される。一つ目のサブシステムでは、画像の記録、路面状態の推定、および視界状況の推定を行う。このサブシステムは、車載カメラで撮影した走行映像を記録し、記録された映像から路面状態や視界状況を推定するものである。二つ目のサブシステムは、データの伝送を行うシステムであり、記録された画像、推定結果、および GNSS に基づく位置情報をインターネットを介してリアルタイムにサーバシステムに伝送する。このシステムは、エッジコンピューティングを実現するために、マイクロコンピュータ上で動作する。

##### (a) ハードウェア

構築したデータ集積機構を構成する機器とそのスペックを表 13 に示す。都市間バスおよび道路パトロールカーにシステムを設置した様子をそれぞれ、図 25 および図 26 に示す。



表 13 データ集積機構を構成する各パーツの仕様

Device	Specifications
Microcomputer (Raspberry Pi 4)	Soc: Broadcom BCM2711 CPU: ARM Cortex A72 (4 cores, 1.5GHz) GPU: Broadcom VideoCore IV 500MHz RAM: 8GB
Camera (Logicool C920s)	1080p/30fps - 720p/30fps
GPS receiver (BU-353S4)	GPS Chipset: SiRF Star IV Routes: 48 Channel All-In-View-Tracking Waterproof: IPX6 Operating temp.: -40C - 80C Humidity: Up to 95%
Data storage (LSDMI512BBNL633A)	Capacity: 512GB Type: microSDXC



(a) データ集積機構を設置したバス



(b) 車両前方に設置したカメラと GNSS 受信機



(c) 運転席後方に設置したマイクロコンピュータ

図 25 都市間バスに設置した様子



(a) データ集積機構を設置した道路パトロールカー



(b) 車両前方に設置したカメラ



(c) ルーフに設置した GNSS 受信機

図 26 道路パトロールカーに設置した様子

車両前方の中央に設置されたカメラは、前方視界を撮影する。カメラはドライバの邪魔にならない位置に設置されている。GNSS 受信機は、都市間バスでは、カメラと同じ装置に設置され、道路パトロールカーでは、ルーフに設置されている。マイコンは、都市間バスでは、運転席後方に設置され、道路パトロールカーでは、後部座席に設置されている。ネットワークとの接続については、都市間バスでは、マイコンが WiFi のゲートウェイ装置に有線で接続されており、道路パトロールカーでは、マイコンに USB 接続の LTE ドングルを用いている。各機器は、インバータを用いた変換により、AC100V の電源を得ている。カメラと GNSS 受信機は USB でマイコンと有線接続されている。

#### (c) ソフトウェア

本機構では、10 秒毎に、8 秒間の前方映像を撮影する。2 秒は GNSS 受信のための時間である。ビデオキャプチャ機能は、WIPS の計算および路面状態の推定と並行して実行される。WIPS と路面状態も並行して計算される。したがって、構築したデータ集積機構では、3 つの関数を並行して計算する。ここで、道路パトロールカーでは、路面の計算は行わず、ビデオキャプチャおよび WIPS を計算する 2 つの関数を並列して行う。また、ロバストな推定を実現するために、映像の先頭から 1.5 秒間に 3 枚の推定用画像を撮影する。3 枚の画像を利用することで、ワイパーブレードを含まない画像を得ることができる。撮影された映像と画像はマイコンに記録される。GNSS 受信機は、車両の位置、時間、速度を 1 秒ごとに受信する。これらのデータは、ビデオや画像と同じストレージに記録される。また、本機構では、各静止画像に対して WIPS と路面状態を推定する。その後、本システムは、静止画像、推定結果、GPS パラメータのみをサーバシステムへ送信する

#### 4.5.3 都市間バスおよび道路パトロールカーでの実運用

構築したデータ集積機構は、都市間バスについては、札幌と稚内および札幌と枝幸を結ぶ都市間バスに搭載されており、札幌—稚内間が 7 台、札幌—枝幸間が 2 台、計 9 台のバスに実装されている。また、道路パトロールカーについては、釧路管内 6 台、留萌 2 台、稚内 1 台の計 9 台が運用されている。

現状では、プローブ車両の電力や LTE ネットワークの構築によるトラブルは観測されておらず、画像抽出システムとデータ送信システムを正常に動作している。操作画面の例を図 27 に示す。図 27 は、取得した画像、WIPS、路面状態の例である。図 28～図 30 に、都市間バスに実装したデータ集積機構が路面の状態を推定した結果の例を示す。図 28～図 30 より、冬期の路面状態を分類できていることがわかる。また、図 31 および図 32 に、道路パトロールカーに実装したデータ集積機構が視界の状況を分析した結果を示す。ここで、WIPS は視界の状況を表現する値であり、WIPS の値が 7.8 より大きい場合が「視界良好」、

7.5より大きく7.8以下の場合には「視界がやや不良」、7.5より小さい場合が「視界不良」となる。図31および図32が示すように、冬期の視界状況を評価できていることがわかる。また、本機構で集積したデータを地図上に可視化する取り組みも行っている。図33に、視界状況を推定した結果を可視化した例を示す。赤色が「視界不良」、朱色が「やや良好」、灰色が「視界良好」を意味している。また、図34に、路面状態を推定した結果を可視化した例を示す。赤色が「冬期路面」、朱色が「湿潤路面」、灰色が「乾燥路面」を表す。図29および図30のような可視化結果を提示することで、利用者や管理者が即時に道路状況を把握可能となることが期待できる。

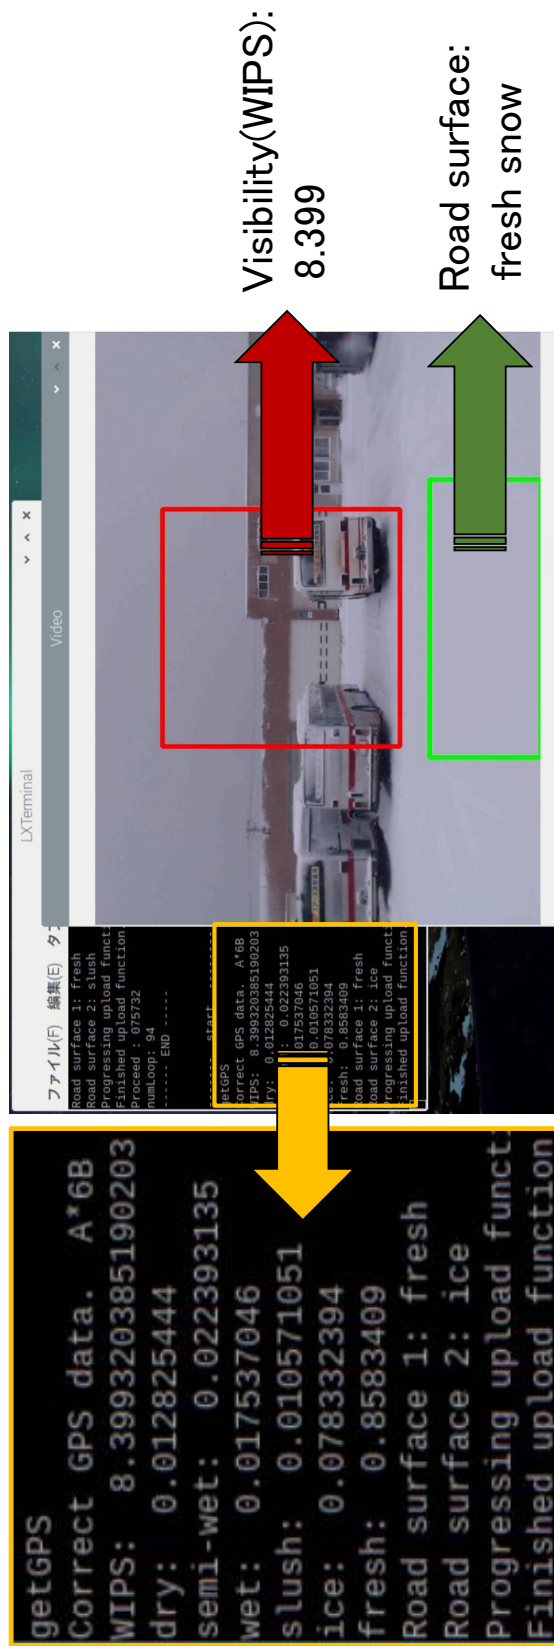


図 27 データ集積機構の操作画面の例 (リモートアクセス)



(a) 路面状態が「dry」と推定された画像の例



(b) 路面状態が「semi-wet」と推定された画像の例

図 28 都市間バスに実装したデータ集積機構が路面状態を推定した結果の例 1



(a) 路面状態が「wet」と推定された画像の例



(b) 路面状態が「slush」と推定された画像の例

図 29 都市間バスに実装したデータ集積機構が路面状態を推定した結果の例 2





(a) 路面状態が「ice」と推定された画像の例



(b) 路面状態が「fresh」と推定された画像の例

図 30 都市間バスに実装したデータ集積機構が路面状態を推定した結果の例 3



(a) 視界良好 (WIPS : 8.59, 日中) と推定された画像の例



(b) 視界良好 (WIPS : 8.46, 夜間) と推定された画像の例

図 31 道路パトロールカーに実装したデータ集積機構が視界状況を推定した結果の例 1



(a) 視界不良（WIPS：6.99，日中）と推定された画像の例



(c) 視界やや不良（WIPS：7.56，夜間）と推定された画像の例

図 32 道路パトロールカーに実装したデータ集積機構が視界状況を推定した結果の例 2



図 33 集積した視界状況の分析結果を地図上に可視化した結果の例



## 4.6 活性化ベクトルの類似度に基づくエッジ選択

分散配置されたエッジに搭載された AI (以下, エッジ AI) を更新する手法の代表例に, 連合学習[134]が挙げられるが, これは, 各エッジから集約された膨大なパラメータを用いて共通の識別器を構築し, 各エッジに再配布する仕組みである. しかし, 将来的にエッジの数が膨大となった場合は, 広域な通信ネットワークを介した膨大なやり取りが必要になる. これは, エッジ AI を更新する際に膨大な時間や通信コストが要求されることを意味する. それゆえ, 連合学習に比較してより効率的に逐次更新が可能な分散学習が必要である. そこで, 本研究では, より効率的なエッジ AI の更新が可能なエッジ同士の連携ネットワーク構築を目指している. 本研究の概要を図 35 に示す. 具体的には, 自身が保持するデータとは性質が異なるデータを保持するエッジから知識を獲得し, エッジ AI の更新に活用する. これにより, 連合学習に比較して, 更新に用いるデータが少量であっても, 汎化性能に優れたエッジ AI の高効率な更新が期待できる.

上記の目的を達成するためには, 次の 2 つの課題: (1) 性質が異なるエッジの選択, (2) 選択したエッジから獲得したデータによるエッジ AI の更新, を解決する必要がある. 我々は以前, ニューラルネットワークから成る識別器において, 他方の識別器の重み行列のみを用いて更新を行う手法を提案した[130]. これにより, 学習データを使わずに知識を共有し, 識別器の精度向上が可能であることを確認した. この手法は 課題 (2) に取り組んだものであり, 本研究の最終的な目的を達成するために, 課題 (1) にも取り組む必要がある.

そこで, 本節では, 高効率なエッジ AI の更新に向け, 学習済みモデルの性質の違いに基づき, エッジ AI の更新に有効なデータを有する他のエッジを選択する手法を提案する. 文献[128,129]では, ニューラルネットワークから成る機械学習モデルにおいて, ニューロンの出力値から得られる活性化ベクトルにより, 機械学習モデルの表現の類似度を定量的に測る手法が提案されている. また, 実験によって, 同じアーキテクチャを持ち, 異なる初期値から同じデータを学習した 2 つの機械学習モデルの表現が類似していることが示されている. このことから, 各エッジが保持するデータの性質の違いは, これらを学習済みモデルの表現の違いとして表れると考えられる. それゆえ, 提案手法では, 学習済みモデルの表現の類似度に着目し, 選択するエッジを決定する. 具体的に, 提案手法ではまず, エッジ AI の学習済みモデルの特徴を表す活性化ベクトルを求める. 次に, 2 つの学習済みモデルにおいて, 類似度を求めるアルゴリズムを用いて類似度を算出する. 最後に, 類似度が最も低いエッジを有効なデータを有するものとして選択する.

#### 4.6.1 類似度の計算に基づくエッジ選択

##### (1) Step1:活性化ベクトルから成るベクトル空間の算出

各エッジ AI から取得する活性化ベクトル[128]とその集合の線形結合によってできるベクトル空間について説明する. 同一のアーキテクチャをした 2 つのニューラルネットワークの同じ層におけるニューロンの集合を  $\mathcal{X}$ ,  $\mathcal{Y}$  とする. これらのネットワークに  $d$  個の入力データ  $a_1, a_2, \dots, a_d$  が与えられたとする. ニューロン  $v$  の出力を  $z_v(a_i)$  と表記すると, ニューロン  $v$  は,  $d$  個の入力データに対するニューロン  $z_v$  の活性化ベクトル

$$\mathbf{z}_v = (z_v(a_1), z_v(a_2), \dots, z_v(a_d)) \quad (11)$$

で評価できる. このときのニューラルネットワークの表現は, ニューロンの部分集合  $X \subseteq \mathcal{X}$  から得られるニューロンの活性化ベクトルの線形結合によってできるベクトル空間

$$\text{span}(\mathbf{z}_X) = \left\{ \sum_{\mathbf{z}_x \in \mathbf{z}_X} \lambda_{\mathbf{z}_x} \mathbf{z}_x : \forall \lambda_{\mathbf{z}_x} \in \mathbb{R} \right\} \quad (12)$$

で評価できる. ただし, 任意の部分集合  $X \subseteq \mathcal{X}$  に対し, ベクトル集合  $\{\mathbf{z}_x : x \in X\}$  を略して  $\mathbf{z}_X$  と表記した.

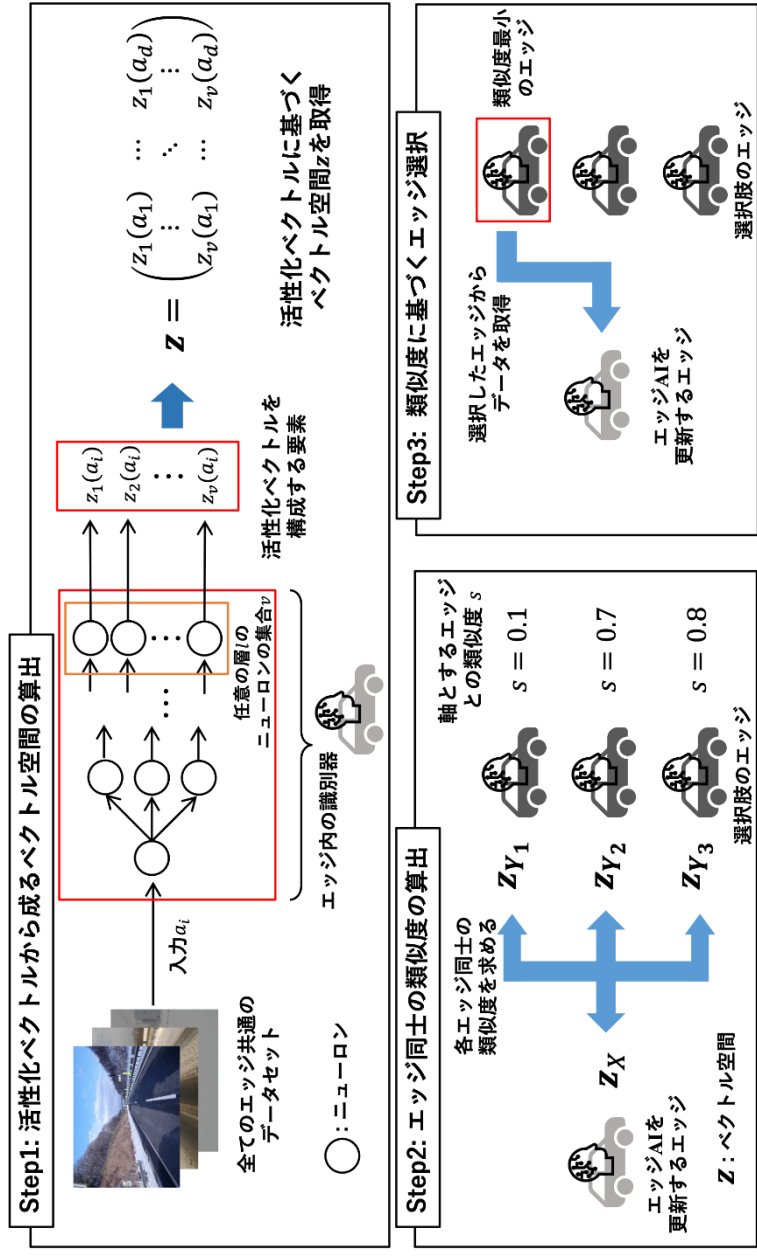


図 35 活性化ベクトルの類似度に基づくエッジ選択手法の概要図



(2) Step2:エッジ同士の類似度の算出

活性化ベクトルを用いた, 学習済みモデル間の類似度の算出方法[129]について説明する. 提案手法では,  $\varepsilon$  近似一致に基づいた計算によって, 類似度を求める.

a)  $\varepsilon$  近似一致

$X \subseteq \mathcal{X}, Y \subseteq \mathcal{Y}$  をニューロンの部分集合とする. このとき, 以下の2条件を満たす場合は,  $X$  と  $Y$  は  $\varepsilon$  近似一致を形成するという.

$$\forall x \in X, \text{dist}(\mathbf{z}_x, \text{span}(\mathbf{z}_Y)) \leq \varepsilon |\mathbf{z}_x| \quad (13)$$

$$\forall y \in Y, \text{dist}(\mathbf{z}_y, \text{span}(\mathbf{z}_X)) \leq \varepsilon |\mathbf{z}_y| \quad (14)$$

ここでは,  $L_2$  距離を用いる.  $\varepsilon$  は  $[0, 1)$  の範囲で定めるパラメータである.  $\text{dist}$  は任意のベクトル  $\mathbf{z}$  と任意のベクトル空間  $S$  に対して,

$$\text{dist}(\mathbf{z}, S) = \min_{\mathbf{z}' \in S} \|\mathbf{z} - \mathbf{z}'\|_2 \quad (15)$$

で計算される.

b)  $\varepsilon$  近似一致を用いた類似度の算出

類似度は,  $X, Y$  全ての  $\varepsilon$  近似一致が,  $X \subseteq X^*$  と  $Y \subseteq Y^*$  の2条件を満たすときの  $X^*$  と  $Y^*$  を用いて計算される. このとき,  $\varepsilon$  に基づく類似度  $s(\varepsilon)$  は,

$$s(\varepsilon) = \frac{|X^*| + |Y^*|}{|\mathcal{X}| + |\mathcal{Y}|} \quad (16)$$

で計算される.

---

**Algorithm** 類似度  $s(\varepsilon)$  を求める

---

```
1:  $(X^*, Y^*) \leftarrow (X, Y)$ 
2:  $changed \leftarrow true$ 
3: while  $changed$  do
4:      $changed \leftarrow false$ 
5:     for  $x \in X^*$  do
6:         if  $dist(\mathbf{z}_x, span(\mathbf{z}_{Y^*})) > \varepsilon|\mathbf{z}_x|$  then
7:              $X^* \leftarrow X^* \setminus \{x\}$ 
8:              $changed \leftarrow true$ 
9:     if  $changed$  then
10:         $changed \leftarrow false$ 
11:        for  $y \in Y^*$  do
12:            if  $dist(\mathbf{z}_y, span(\mathbf{z}_{X^*})) > \varepsilon|\mathbf{z}_y|$  then
13:                 $Y^* \leftarrow Y^* \setminus \{y\}$ 
14:                 $changed \leftarrow true$ 
15:  $s(\varepsilon) \leftarrow (|X^*| + |Y^*|) / (|X| + |Y|)$ 
```

---

**c) 類似度を求めるアルゴリズム**

類似度を計算する際に用いる  $X^*$ ,  $Y^*$  を求めるために、繰り返し  $\varepsilon$  近似一致を形成するかを確認するアルゴリズム[129]を使用する.  $\varepsilon$  に基づく類似度を計算するための具体的なアルゴリズムを **Algorithm** に示す. 最初に,  $X^* = X, Y^* = Y$  とする. 次に,  $dist(\mathbf{z}_x, span(\mathbf{z}_{Y^*})) \leq \varepsilon|\mathbf{z}_x|$  を満たさない  $x \in X^*$  があれば,  $X^*$  から  $x$  を削除する. 同様に, ある  $y \in Y^*$  について,  $\varepsilon$  の範囲内で  $y$  が  $\mathbf{z}_{X^*}$  で線形表現できないような場合,  $Y^*$  から  $y$  を削除する. このように  $X^*$  と  $Y^*$  において  $\varepsilon$  近似一致を満たさない  $x, y$  が検出されなくなるまで繰り返す.

**(3) Step3: 類似度に基づくエッジ選択**

最後に, ニューロンの集合間の類似度を算出した結果に基づき, データを獲得するエッジを選択する. 選択するエッジは, 複数あるエッジの中から類似度が最も低く算出されたエッジで決定される. エッジの選択結果  $Edge$  は, 選択枝のエッジとの類似度  $s^k(\varepsilon)$  ( $k \in \{\text{選択枝のエッジ}\}$ ) に基づいて行われ,

$$Edge = \arg \min_k s^k(\varepsilon) \quad (17)$$

で計算される。提案手法に基づくエッジ選択によって、再学習に使うデータが少量であっても、汎化性に優れたエッジ AI の更新が期待できる。

## 4.6.2 実験

提案手法の有効性を確認するため、性質が異なる 4 つのデータセットを用意し、実験を行う。実験では、道路管理において現在取り組まれている項目の一つである路面推定を行う。本実験の路面推定とは、積雪寒冷地における道路の路面状態を、乾燥、積雪、湿潤のいずれかを判定し分類することを指す。最初に、各データセットを学習済みのエッジ AI を構築する。次に、更新するエッジ AI を一つ定め、その他 3 つのエッジから、提案手法を用いて選択し、エッジ AI を更新する。以降では、まず、実験の詳細について述べる。次に、類似度によるエッジ選択に基づきエッジ AI を更新し、考察する。

### (1) 実験設定


本実験では、道路の路面状態の画像を用いて路面推定を行うエッジ AI を複数構築する。エッジ AI は、車両前方に取り付けたカメラから得られた路面の画像を用い、路面状態から乾燥 (dry)、湿潤 (wet)、積雪 (snow) の 3 種に分類を行う。路面状態の一例を図 36 に示す。本節の以降では、実験で使用するデータセット、エッジ AI のアーキテクチャ、提案手法のパラメータ設定、エッジ AI の更新方法、比較手法について、それぞれ詳述する。

#### (a) データセット

路面推定に用いるデータセットには、図 37 に示す 4 つの地域で撮影された画像を、dry, wet, snow の 3 つに分類したものを使用する。なお、データセットは、一部でも走行路面に湿潤や積雪が確認できれば該当する路面に分類されている。4 つの地域のうち、深川-留萌自動車道と豊富-幌延バイパスの 2 地域は高規格道路であり、幌延町-留萌市の街中の一般道、幌延町-留萌市の街中以外の一般道の 2 地域は一般道である。一般道と高規格道路を混在させることで、データの性質の違いに大小をつけたデータセットとなっている。各地域におけるデータセットの詳細を表 14 に示す。これ以降、4 つの地域 (深川-留萌自動車道、豊富-幌延バイパス、幌延町-留萌市の街中の一般道、幌延町-留萌市の街中以外の一般道) のデータを保持したエッジを、それぞれエッジ A、エッジ B、エッジ C、エッジ D と呼ぶ。なお、データセットは、4.5 で説明した、都市間バスに搭載されたエッジコンピューティング基盤により取得した画像から構成され、全エッジ共通の類似度評価用データセットは、上記の 4 地域全てからランダムに集めたものである。

#### (b) エッジ AI のアーキテクチャ

路面状態の分類には、有効性が確認済みの先行事例[131,132]で用いられている軽量の深層畳み込みニューラルネットワーク (CNN) である MobileNets を使用する。CNN とは二



(a) *dry*                      (b) *wet*                      (c) *snow*

図 36 積雪寒冷地における 3 種の道路状態の例

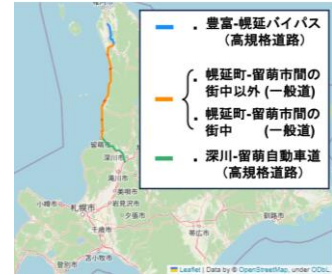


図 37 データセットを作る 4 つの地域

表 14 実験で用いるデータセットの詳細

		深川-留萌 自動車道	豊富-幌延 バイパス	幌延-留萌の 街中の一般道	幌延-留萌の街 中以外の一般 道	類似度評価用 データセット
画像数	訓練用	1200	1200	1200	1200	300
	評価用	300	300	300	300	

ニューラルネットワークに畳み込み層とプーリング層を導入したものであり、画像認識において高い性能を発揮することで知られている。その中でも、MobileNets は、通常の畳み込み層の代わりに Depthwise Separate Convolution を導入することで、従来の CNN と比べ計算量の削減し軽量化を実現している。

本実験では、ImageNet により訓練された MobileNets を転移学習させることで識別器を構築する。エッジ AI のアーキテクチャを図 38 に示す。エッジ AI は ImageNet を学習済みの MobileNets と全結合層 2 層から構成され、画像を入力することで、3 種の路面状態それぞれの確率が出力される。路面推定は、3 種の路面状態それぞれの確率  $p_{image}^k (k \in \{dry, wet, snow\})$  に基づいて行われ、推定結果 Label は、

$$Label = \arg \max_k p_{image}^k \quad (18)$$

で計算される。

(c) 提案手法のパラメータ設定

提案手法の類似度を求める際に必要となる活性化ベクトルを求める対象とする層および  $\varepsilon$  の値は、実験的に定めたものを用いる。具体的には、活性化ベクトルを求める対象とする層を出力層の一つ前の層とし、 $\varepsilon$  の値は 0.8 とした。設定した提案手法のパラメータは、エッジ AI 同士の類似度の算出に対して適用される。

(d) エッジ AI の更新方法

エッジ AI の更新には、以前我々が提案した、ニューラルネットワークの重み行列のみを用

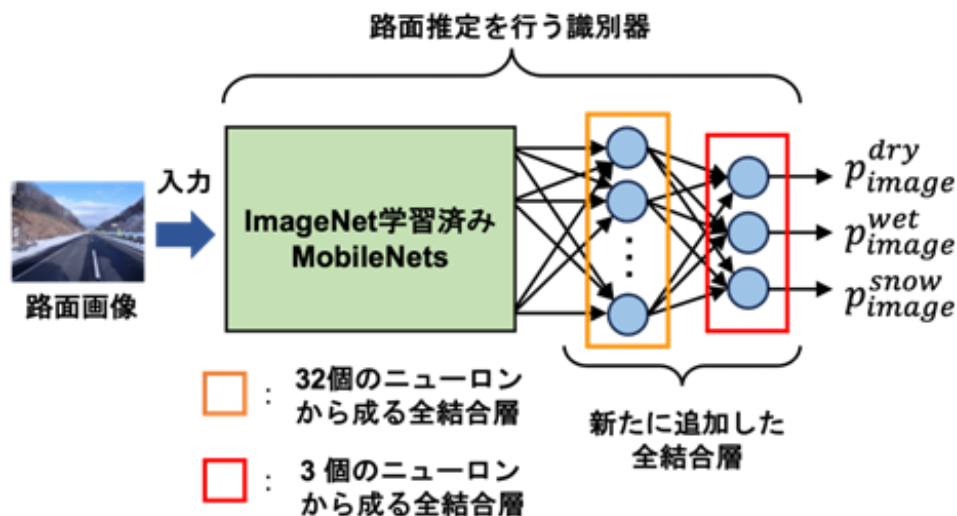


図 38 実験に用いるエッジ AI のアーキテクチャ

いた更新手法に基づいて行われる[130]. 一般的に, ニューラルネットワークは 1 個の入力層,  $K$  個の隠れ層, 1 個の出力層で構成される. 本実験で用いるニューラルネットワークの更新は, 以下の 2 ステップで行われる. 最初に,  $K$  番目の隠れ層と出力層の間の計算に用いられる重み行列を, 選択したエッジの識別器の重み行列に置き換える. 次に, ニューラルネットワークの学習に用いられる逆誤差伝搬法を用いて, 置き換えた重み行列をニューラルネットワークに適応させる.

(e) 比較手法

本実験では, 比較として次の比較手法 1 と比較手法 2 を用いる. 比較手法 1 は, 全エッジ共通の類似度評価用データセットを用いて生成した活性化ベクトルを一次元に平滑化し, コサイン類似度を用いて類似度を算出するものである. この手法との比較により,  $\epsilon$  近似一致を導入して類似度を求めることの有効性を確認する. 比較手法 2 は, 全エッジ共通の類似度評価用データセットを入力とし, 推定結果を 1, それ以外を 0 とする One-Hot ベクトルの集合を一次元に平滑化し, コサイン類似度を用いて類似度を算出するものである. この手法との比較により, エッジ同士の類似度に, 活性化ベクトルを使うことの有効性を確認する.

(2) 実験結果と考察

実験結果と考察について述べる. 4 つのエッジ AI 同士の類似度を求め, 類似度が高い順に順序付けを行った. 提案手法を用いた結果を表 15, 比較手法 1 を用いた結果を表 16, 比較手法 2 を用いた結果を表 17 に示す. 類似度が低いエッジ, つまり, 順序付けの結果が 3 となるエッジに着目する. 提案手法と 2 つの比較手法では, 選択するエッジ, つまり, 類似度の順序付けを行い 3 となったエッジが異なる結果となった. 特に, エッジ A とエッジ D

表 15 提案手法によるエッジ同士の類似度に基づく順序付け

		選択枝のエッジ			
		エッジ A	エッジ B	エッジ C	エッジ D
更新する エッジ	エッジ A (深川-留萌自動車道)	—	1	<b>3</b>	2
	エッジ B (豊富-幌延バイパス)	2	—	<b>3</b>	1
	エッジ C (幌延-留萌の街中)	<b>3</b>	1	—	2
	エッジ D (幌延-留萌の街中以外)	2	1	<b>3</b>	—

表 16 比較手法 1 によるエッジ同士の類似度に基づく順序付け

		選択枝のエッジ			
		エッジ A	エッジ B	エッジ C	エッジ D
更新する エッジ	エッジ A (深川-留萌自動車道)	—	<b>3</b>	1	2
	エッジ B (豊富-幌延バイパス)	1	—	2	<b>3</b>
	エッジ C (幌延-留萌の街中)	1	<b>3</b>	—	2
	エッジ D (幌延-留萌の街中以外)	2	<b>3</b>	1	—

表 17 比較手法 2 によるエッジ同士の類似度に基づく順序付け

		選択枝のエッジ			
		エッジ A	エッジ B	エッジ C	エッジ D
更新する エッジ	エッジ A (深川-留萌自動車道)	—	1	2	<b>3</b>
	エッジ B (豊富-幌延バイパス)	1	—	<b>3</b>	2
	エッジ C (幌延-留萌の街中)	<b>3</b>	2	—	1
	エッジ D (幌延-留萌の街中以外)	<b>3</b>	2	1	—

においては、提案手法と 2 つの比較手法それぞれの類似度に基づき順序付けを行った結果が 3 となるエッジが、全て異なる結果となった。したがって、エッジ A とエッジ D が選択肢の 3 つのエッジをそれぞれ用いたエッジ AI の更新を行い、その結果を比較することで、提案手法の有効性を確認する。エッジ A, D において、選択したエッジからデータを取得しエッジ AI を更新し、正解率、適合率、再現率、F 値、混合行列をそれぞれ計算する。この結果を、表 18, 表 19, 表 20, 表 21 に示す。なお、正解率、適合率、再現率、F 値は以下の式で計算される。ここで、 $k$  は分類ラベルを指し、 $k \in \{\text{dry, wet, snow}\}$  である。

$$\text{正解率} = \frac{\text{路面状態が正しく推定された画像数}}{\text{路面状態を推定する画像数}} \quad (19)$$

$$\text{適合率} = \frac{\text{路面状態を } k \text{ と正しく推定した画像数}}{\text{路面状態を } k \text{ と分類した画像数}} \quad (20)$$

$$\text{再現率} = \frac{\text{路面状態を } k \text{ と正しく推定した画像数}}{\text{路面状態が } k \text{ の画像数}} \quad (21)$$

$$F\text{値} = \frac{2 \cdot (\text{適合率}) \cdot (\text{再現率})}{(\text{適合率}) + (\text{再現率})} \quad (22)$$

表 18 から、エッジ AI の更新前は、エッジ A が保有しているデータにのみ特化した正解率であり、正解率の平均値は 0.603、F 値の平均値は 0.545 にとどまっていたが、提案手法で選択されるエッジ C または比較手法 2 で選択されるエッジ D を選択し更新した後は、正解率の平均値は 0.795、F 値の平均値は 0.787 となり、学習したことがない地域のデータセットの正解率も向上させられることが確認できる。これは、高規格道路を学習済みのエッジ AI が、性質が異なる一般道のデータを保持するエッジを選択することにより、エッジ AI の広範囲に表現可能な更新ができたことが考えられる。

提案手法と比較手法 1 に着目する。表 18, 表 19 から、比較手法 1 で最も類似度が低いとされるエッジを選択した場合、正解率の平均値は 0.603 から 0.666 に、F 値の平均値は 0.545 から 0.648 に向上するが、正解率および F 値の上げ幅は、提案手法に比べて小さい。表 20, 表 21 も同様である。それゆえ、活性化ベクトルから類似性を見出すために、 $\varepsilon$  近似一致を導入する必要があることを確認できる。

次に、提案手法と比較手法 2 に着目する。表 18, 表 19 より、提案手法と比較手法 2 をそれぞれ用いてエッジ AI を更新したときの正解率の平均値は 0.795、F 値の平均値は 0.787 と同じである。しかし、表 20, 表 21 から、提案手法と比較手法 2 をそれぞれ用いてエッジ AI を更新したときの正解率の平均値はそれぞれ 0.833 と 0.683、F 値の平均値はそれぞれ 0.824 と 0.645 となり、提案手法の方が高い値となることが確認できる。このことから、エ

表 18 エッジ A (深川-留萌自動車道) が各エッジを選択し更新した結果の統計値

		データセット				平均
		深川-留萌 自動車道	豊富-幌延 バイパス	幌延-留萌 の街中の 一般道	幌延-留萌の 街中以外の 一般道	
更新前	正解率	<b>0.967</b>	<b>0.543</b>	<b>0.473</b>	<b>0.430</b>	<b>0.603</b>
	適合率	0.968	0.543	0.649	0.269	0.607
	再現率	0.967	0.543	0.473	0.430	0.603
	F 値	<b>0.967</b>	<b>0.502</b>	<b>0.390</b>	<b>0.321</b>	<b>0.545</b>
エッジ C を選択 (幌延-留萌の街中) (提案手法)	正解率	<b>0.887</b>	<b>0.677</b>	<b>0.803</b>	<b>0.813</b>	<b>0.795</b>
	適合率	0.889	0.666	0.810	0.836	0.800
	再現率	0.887	0.677	0.803	0.813	0.795
	F 値	<b>0.884</b>	<b>0.646</b>	<b>0.805</b>	<b>0.813</b>	<b>0.787</b>
エッジ B を選択 (豊富-幌延バイパ ス) (比較手法 1)	正解率	0.833	0.710	0.603	0.517	0.666
	適合率	0.839	0.793	0.626	0.525	0.696
	再現率	0.833	0.710	0.603	0.517	0.666
	F 値	0.835	0.670	0.579	0.508	0.648
エッジ D を選択 (幌延-留萌の街中 以外) (比較手法 2)	正解率	<b>0.850</b>	<b>0.717</b>	<b>0.773</b>	<b>0.840</b>	<b>0.795</b>
	適合率	0.854	0.732	0.802	0.841	0.807
	再現率	0.850	0.717	0.773	0.840	0.795
	F 値	<b>0.848</b>	<b>0.685</b>	<b>0.776</b>	<b>0.840</b>	<b>0.787</b>

表 19 エッジ A (深川-留萌自動車道) が各エッジを選択し更新した結果の混合行列

		推定ラベル											
		更新前			エッジ C を選択 (幌延-留萌の街中)			エッジ B を選択 (豊富-幌延バイパ ス)			エッジ A を選択 (幌延-留萌の街中 以外)		
		<i>dry</i>	<i>wet</i>	<i>snow</i>	<i>dry</i>	<i>wet</i>	<i>snow</i>	<i>dry</i>	<i>wet</i>	<i>snow</i>	<i>dry</i>	<i>wet</i>	<i>snow</i>
真値	<i>dry</i>	134	127	139	311	82	7	317	53	30	334	61	5
	<i>wet</i>	28	195	177	104	265	31	207	169	33	124	254	22
	<i>snow</i>	0	5	395	0	22	378	71	7	322	3	31	366



表 20 エッジ D (幌延—留萌の街中以外) が各エッジを選択し更新した結果の統計値

		データセット				平均
		深川-留萌 自動車道	豊富-幌延 バイパス	幌延-留萌 の街中の 一般道	幌延-留萌の 街中以外の 一般道	
更新前	正解率	0.690	0.667	0.793	0.933	0.771
	適合率	0.688	0.667	0.800	0.934	0.772
	再現率	0.690	0.667	0.793	0.933	0.771
	F 値	0.686	0.590	0.796	0.933	0.751
エッジ C を選択 (幌延-留萌の街中) (提案手法)	正解率	<b>0.840</b>	<b>0.733</b>	<b>0.873</b>	<b>0.887</b>	<b>0.833</b>
	適合率	0.839	0.751	0.872	0.890	0.838
	再現率	0.840	0.733	0.873	0.887	0.833
	F 値	<b>0.836</b>	<b>0.701</b>	<b>0.872</b>	<b>0.885</b>	<b>0.824</b>
エッジ B を選択 (豊富-幌延バイパ ス) (比較手法 1)	正解率	0.800	0.830	0.650	0.727	0.752
	適合率	0.821	0.848	0.739	0.747	0.789
	再現率	0.800	0.830	0.650	0.727	0.752
	F 値	0.805	0.828	0.648	0.733	0.754
エッジ D を選択 (幌延-留萌の街中 以外) (比較手法 2)	正解率	0.733	0.683	0.693	0.623	0.683
	適合率	0.776	0.709	0.679	0.575	0.685
	再現率	0.733	0.683	0.693	0.623	0.683
	F 値	0.698	0.660	0.660	0.560	0.645

表 21 エッジ D (幌延—留萌の街中以外) が各エッジを選択し更新した結果の混合行列

		推定ラベル											
		更新前			エッジ C を選択 (幌延-留萌の街中)			エッジ B を選択 (豊富-幌延バイパ ス)			エッジ D を選択 (深川-留萌自動車 道)		
		<i>dry</i>	<i>wet</i>	<i>snow</i>	<i>dry</i>	<i>wet</i>	<i>snow</i>	<i>dry</i>	<i>wet</i>	<i>snow</i>	<i>dry</i>	<i>wet</i>	<i>snow</i>
<i>dry</i>		336	57	7	350	41	9	283	117	0	360	34	5
<i>wet</i>		140	226	34	88	259	53	92	301	7	151	83	22
<i>snow</i>		9	28	363	4	5	391	6	76	318	10	13	377

エッジ AI の性質の違いを測る際、推定結果を用いる比較手法より、活性化ベクトルを用いた提案手法の方が、汎化性能が向上するエッジを安定的に選択できる可能性が示された。

本節では、高効率なエッジ AI の更新に向け、学習済みモデルの性質の違いに基づき、エッジ AI の更新に有効なデータを有する他のエッジを選択する手法を提案する。実験結果から、性質が異なるデータを獲得し活用することで汎化性能の向上に貢献することを確認した。加えて、提案手法を用いることで、汎化性能が向上するエッジを安定的に選択できることも確認した。

### (3) 通信コストと計算コスト

エッジ AI を更新するために提案手法を用いた場合と連合学習との通信コストおよび計算コストの比較を行う。パラメータ 1 つの容量を  $4[B]$ 、連合学習に必要なイテレーション数を  $N$  とし、本稿で実施した実験と同様の設定で見積もる。このとき、図 38 で説明した共有対象となるエッジ AI の 2 つの全結合層を求めるために必要なデータ量は、それぞれ 55,296 行 32 列、32 行 3 列で構成される重み行列であるため、

$$\begin{aligned} & \left( 32 \text{ 個のニューロンからなる全結合層のデータ量} \right) \\ & = \frac{4 \times 55,296 \times 32}{1,024} = 6.912 \times 10^3 [KB] \end{aligned} \quad (23)$$

$$\begin{aligned} & \left( 3 \text{ 個のニューロンからなる全結合層のデータ量} \right) \\ & = \frac{4 \times 32 \times 3}{1,024} = 3.750 \times 10^{-1} [KB] \end{aligned} \quad (24)$$

となる。また、エッジ AI 間の類似度の計算に用いる活性化ベクトルは、300 行 32 列で構成される行列のため、

$$\left( \text{活性化ベクトルのデータ量} \right) = \frac{4 \times 300 \times 32}{1,024} = 3.75 \times 10^1 [KB] \quad (25)$$

と計算される。本節の以降では、これらの値を用いて通信コストと計算コストを計算する。

#### a) 通信コストの比較

連合学習では、4 つのエッジにおいて 2 つの全結合層のデータを 1 箇所に集約し、その結果を再配布するため、1 つのエッジ当たり  $2N$ [回]の通信が必要となる。さらに、4 つのエッジを用いるとき、通信コストは 4 倍かかる。そのため、連合学習における通信コストは、以下のように計算できる。

$$4 \times 2N \times (6,912[KB] + 0.375[KB])$$

$$\cong 5.529N \times 10^4[KB] \quad (26)$$

一方で提案手法では、はじめに類似度を計算するために選択枝のエッジ 3 つから活性化ベクトルを取得する。次に決定した 1 つのエッジのみから、最後の全結合層のデータのみを取得する。それゆえ、提案手法における通信コストは、以下のように計算される。

$$37.5[KB] \times 3 + 0.375[KB] \cong 1.129 \times 10^2[KB] \quad (27)$$

したがって、N が最小の値である 1 であっても、提案手法は連合学習に比べ 100 分の 1 以下に抑えることが可能である。

#### b) 計算コストの比較

連合学習の時間計算量はイテレーションの回数に比例するが、提案手法はイテレーションの回数が 1 回で済む。そのため、提案手法の時間計算量は連合学習に比較して N 分の 1 に抑えることが可能である。また、連合学習の空間計算量は 4 つのエッジ分のコストがかかるが、提案手法ではエッジ 1 つ分で済む。それゆえ、提案手法の空間計算量は連合学習に比較して 4 分の 1 に抑えることが可能である。

## 4.7 まとめ

本章では、エッジコンピューティングによる自転車の動きに関するデータ集積機構を構築した。具体的に、本機構は、バッテリーで駆動が可能なマイクロコンピュータ、カメラ、および外部演算装置から構成された。また、複数の特徴量および機械学習の識別器に基づく手法により、自転車の通常とは異なる走行を認識し、その認識結果に基づいたデータ集積を可能とした。さらに、実験により、提案するデータ集積機構の実現可能性を確認した。また、本章で得られた知見に基づく他の土木工学への応用として、エッジコンピューティングによって冬期道路の路面や視界に関するデータを集積可能とする機構を構築した。加えて、映像を解析するAIを再学習するために必要な要素技術として、活性化ベクトルの類似度に基づくエッジの選択手法を提案した。

本章では、エッジコンピューティングを導入することで、映像をその画のままに集積する場合に比して、通信ネットワークを介して伝送するデータの容量を削減可能としている。ここで、本章で提案した自転車の走行に関するデータ集積を可能とするエッジコンピューティング基盤では、まっすぐでない走行が観測された場合に限り、低容量の画像を集積する。しかしながら、まっすぐな走行が観測された場合の映像・画像についても、速報性は必要無いが、将来的に活用する場面も想定される。このような場合には、まっすぐな走行が観測された際の映像・画像をローカルに記録可能とすることが望ましいが、全ての映像・画像をその画のままに記録する仕組みでは、蓄積するデータ量が膨大となる。そこで、例えば、エッジAIによって映像を分析する場合には、高解像度の映像を活用し、記録する場合には、高圧縮率の符号化方式を用いて低容量の映像を記録するなどの仕組みを導入することで、蓄積するデータ量を効果的に削減可能となることが期待できる。

# 第 5 章 複数人物の骨格情報に基づく動作の連関の 定量評価

## 5.1 はじめに

本章では、複数人物の主体および従属の関係性を定量的に評価可能な手法を提案する。提案手法では、主体となる人物がまず先に動作を行い、その後、主体となる人物の影響を受ける人物が類似した動作を行うと仮定する。提案手法では、まず、OpenPose によって求める関節位置に基づいて、時系列の動作データを取得する。次に、分析対象の人物について、動作データの要素の対応付け（アライメント）を行う。DTW[91]は、2 系列間の合計距離、すなわち DTW 距離が最小となる要素のアライメントを探索する手法である。DTW では、複数の時間の要素を特定の一つの時間に対応付けすることが可能であるため、類似するデータではあるが、時間方向にずれがある事象について、尤もらしくアライメントをすることが可能である。提案手法では、この DTW によって求まるアライメントの結果に基づいて、その主体および従属の関係を評価可能とする。例えば、人物 A に関する時系列の動作データ A における時間  $t$  の要素について、人物 B に関する動作データ B の時間  $t+r$  の要素が対応付けられたとする。この時、提案手法では、人物 A の時間  $t$  の動作に影響を受けて、人物 B が時間差  $r$  で類似した動作を行ったと考える。このような考えに基づき、提案手法では、DTW によって求まるアライメントの結果について、対応付けされた要素の時間の差に着目した評価関数を定義することで、主体および従属の関係を評価する。提案手法を用いることで、動作が連動する状況において、その主体および従属の関係性について、基本的な傾向を数値データとして積み上げることが可能となる。近年、深層学習などによって実現される機械学習の高精度化が進み、多様な分野での AI によって各種課題を解決することが期待されているが、本章で提案する手法を用いて映像を解析し、データを積み上げることで、その基本的な傾向を学習する機械学習の実現が期待できる。このような仕組みが構築される場合には、基本的な傾向を示す数値データとの差などによって、理想的な状況との乖離度合などの定量的な評価に繋がるといえる。以降、本章では、5.2 において、提案手法について詳述する。次に、5.3 では、実際に建設現場の様子を撮影した映像を用いて実験を行い、提案手法の有効性を確認する。

また、本章では、連動して動作する人物間の主体と従属の関係を評価可能とすることを目的としている。したがって、5.2 で提案する手法を適用する前に、分析対象の人物同士が連動しているかどうかを分析する必要がある。そこで、5.4 では、映像から連動性を評価する手法について検討する。

## 5.2 複数人物の主体および従属の評価

提案手法ではまず、分析対象の各人物について、映像から OpenPose に基づく時系列の動作データを算出する。次に、DTW により、動作データの各要素について、アライメントを行う。最後に、DTW によって求まるアライメントの結果に基づいて、複数人物の連動する動作について、その主体および従属の関係性を評価する。

本節の以降では、5.2.1 で、動作データの算出方法について説明する。次に、5.2.2 で DTW を用いて動作データ間の要素のアライメントを行う方法を説明する。最後に、5.2.3 で、連動する動作の主体と従属の関係性を評価する方法について述べる。

### 5.2.1 関節位置の移動量に基づく動作データの算出

本項では、映像から動作データを求める。はじめに、OpenPose を用いて、各人物の関節位置を取得する。OpenPose では、人間が撮像された画像に対して、畳み込みニューラルネットワークを用いて、その人間の関節の画像内における位置座標を取得することが可能である。具体的には、図 39 に示すように、首や腰、腕、脚などの 25 種類の関節位置を取得することが可能である。提案手法では、取得した関節の位置座標から、任意の関節について、座標の移動量を求める。例えば、移動軌跡に注目する場合には、首の位置座標など、移動する様子を表現可能な関節位置を選択する必要がある。このように、提案手法では、注目する動作を表現可能な関節の位置座標を用いて動作データを求める。位置座標を求める方法として、深層学習に基づく物体検出の結果を活用する方法も考えられるが、主従関係を評価する場合には、腕や脚などの細かな動きを分析することが妥当である場合も想定されることから、提案手法では、首や腕、脚などの関節位置を取得可能な OpenPose を用いる。

動作データの求め方を具体的に説明する。提案手法では、 $T$ 秒間の映像に対して、OpenPose により人物 $p$ の分析対象とする関節の $x$ 座標および $y$ 座標を $d$ 秒の間隔で取得する。ここで、時間 $t$ での人物 $p$ における分析対象の関節の $x$ 座標および $y$ 座標をそれぞれ $h_t^p$ 、 $v_t^p$ とする。次に、 $d$ 秒間での座標の変化量を求める。時間 $t-d$ から時間 $t$ における座標の変化量 $s_t^p$ は以下のようなになる。

$$s_t^p = \sqrt{(h_t^p - h_{t-d}^p)^2 + (v_t^p - v_{t-d}^p)^2} \quad (28)$$

最後に、 $d$ 秒間での座標の変化量を要素とする時系列データを人物 $p$ の動作データ $F_p$ として求める。動作データ $F_p$ は以下のようなになる。




図 39 OpenPose により位置座標を取得可能な関節

$$F_p = [s_d^p, s_{2d}^p, \dots, s_T^p] \quad (29)$$

### 5.2.2 DTW によるアライメント

5.2.1 までに得られる動作を表現する時系列データについて，異なる人物間で DTW により要素の対応付けを行う．長さがそれぞれ  $N$  および  $M$  である二つの時系列データ， $X := (x_0, x_1, \dots, x_{N-1}), Y := (y_0, y_1, \dots, y_{M-1})$  について，DTW によりアライメントをすると仮定する．DTW では，まず初めに， $N \times M$  の距離行列  $C \in \mathbb{R}^{N \times M}$  を算出する．距離行列  $C$  における  $(n^{th}, m^{th})$  の要素  $c(x_n, y_m)$  は， $x_n$  と  $y_m$  の距離を表し，一般的にユークリッド距離を用いて以下のように算出される．

$$c(x_n, y_m) = (x_n - y_m)^2 \quad (30)$$

DTW では，累積距離が最小となるような，時系列データ  $X$  と  $Y$  の間のワーピングパスを計算する．ワーピングパス  $W$  における  $k$  番目の要素を  $w_k = (i, j)_k$  とする．この時， $w_k \in \mathbb{R}^2$  であり，ワーピングパス  $W$  は以下ようになる．

$$W = (w_1, w_2, \dots, w_K) \quad (31)$$

$$\max(N, M) \leq K \leq N + M - 1$$

DTW に算出されるパスは、以下の3つの条件を満たす。

- ・境界条件： $X$ と $Y$ の最初と最後の要素が互いに対応付けられる。すなわち、 $w_1 = (0,0)$ であり、 $w_K = (N-1, M-1)$ となる。
- ・単調性の条件：ワーピングパスの各要素を時間的に単調に配置する。すなわち、 $i_1 \leq i_2 \ll \dots \leq i_N$ であり、 $j_1 \leq j_2 \ll \dots \leq j_M$ となる。
- ・ステップサイズ条件： $X$ と $Y$ のアライメントにおける要素の省略と重複を回避する。すなわち、 $(w_{k+1} - w_k) \in (1,0), (0,1), (1,1)$ となる。ここで、 $k \in [1:K-1]$ である。

DTW では、動的計画法を用いて累積距離行列 $D$ を求める。累積距離行列の各要素は、以下のように計算される。

$$D(n, m) = \min\{D(n-1, m-1), D(n-1, m), D(n, m-1)\} + c(x_n, y_m) \quad (32)$$

ここで、 $n \in [0:N-1]$ 、 $m \in [0:M-1]$ である。DTW では、累積距離行列 $D$ を用いて、以下に示すアルゴリズムに基づき、 $w_k = (N-1, M-1)$ を始点として、インデックスと逆の順番で、最適なワーピングパスを求める。

$$w_{k-1} = \begin{cases} (1, m-1), & \text{if } n = 0 \\ (n-1, 1), & \text{if } m = 0 \\ \operatorname{argmin}\{D(n-1, m-1), D(n-1, m), D(n, m-1)\}, & \text{otherwise} \end{cases} \quad (33)$$

以上が、DTW による時系列データのアライメントの方法である。

### 5.2.3 アライメント結果に基づく動作の主体と従属の評価

提案手法では、前項までに求める DTW によるアライメントの結果に基づいて、複数人物の連動する動作について、その主体および従属の関係を定量的に評価可能とする。ここで、 $N$ および $M$ が8の場合において、時系列データ $X$ と $Y$ を DTW により対応付けした際のワーピングパスの例を図40に示す。図40におけるx軸及びy軸はそれぞれ時系列データ $X$ と $Y$ を表す。この時、図40に示す赤色の線のような垂直方向のセグメント、すなわち $w_{k+1} - w_k = (0,1)$ として定義されるセグメントは、時系列データ $X$ のインデックスが時系列データ $Y$ の1つ以上の連続するインデックスに関連付けられている場合に発生する。したがって、時系列データ $X$ の一つの要素に対して、時間的に進行している時系列データ $Y$ の要素が対応している。これはすなわち、時系列データ $Y$ が時系列データ $X$ に対して、時間的に遅れていることを示す。そこで、提案手法では、図40に青色で示す領域の面積を算出することで、



連動する動作における主体および従属の関係性を評価可能とする。連動する動作について、対応付けされた要素の時間に差がない場合のワーピングパスは図 41 のようになる。したがって、図 40 や図 41 に青色で示す領域の面積は、類似する二つの時系列データ間について、時間的なずれを表現可能な数値であり、この数値を用いることで、主体および従属の関係を定量的に評価可能となる。

図 40 および図 41 を、人物 X を軸として、人物 Y が主体か従属かを分析した結果とする。この時、図 40 の面積が、図 41 の面積に比して大きいことから、図 40 の結果が得られた場合には、人物 Y が人物 X に対して従属となる関係であることがわかる。また、図 42 として、主従関係が逆の場合のワーピングパスの結果の例を示す。図 42 の面積が、図 41 の面積に比して小さいことから、人物 Y が人物 X に対して主体であることがわかる。このように、提案手法により求める指標の大小関係から主従の関係が把握可能となる。また、指標として、対応付けされた要素の時間に差がない場合との面積の乖離の量を求めることも考えられるが、面積の大小関係が把握できれば良いため、本章で求める面積の値と乖離の量は等価となる。乖離の量を求めるためには、対応付けされた要素の時間に差がない場合の面積の引き算が常に必要であり、計算コストの観点から提案手法では、単純な面積の値を指標として計算している。




図 40 DTW により求まるワーピングパスの例 1  
(対応する要素に時間の違いがある場合)




図 41 DTW により求まるワーピングパスの例 2  
(対応する要素に時間の違いが無い場合)




図 42 DTW により求まるワーピングパスの例 3  
(対応する要素に時間の違いがある場合)

### 5.3 実験

本節では、複数の人物が活動する実空間を撮影した映像を用いて実験を行う。本論文では、道路空間をモニタリングの対象としているが、提案手法の有効性を確認するためには、人物同士の主体と従属の関係が明確な場面を分析対象とすることが望ましい。そこで、本節では、主体と従属の関係が明確な建設現場を撮影した映像を用いる。具体的には、実際にコンクリート打設を行う様子を撮影した映像を用いて実験を行う。本実験では約 35 秒間の映像を用いる。図 43 に本実験で分析対象とする 2 名の作業員を示す。本実験で用いる映像は、コンクリート打設において、複数の作業員が動作位置を移動する場面を撮影した映像である。作業員 A の役割は、ポンプを用いてコンクリートを流し込むことであり、作業員 B の役割は、バイブレータを用いて流し込まれたコンクリートに振動を与えることである。コンクリート打設の現場においては、図 44 に示すように、基本的にはまず、ポンプを持つ作業員が先に移動し、遅れてバイブレータを持つ作業員が移動する。したがって、作業員 A と作業員 B では、作業員 A が主体である。本実験では、提案手法により求める指標が、このような主体と従属の関係性を表現可能か否かを確認する。図 45 に実験で用いる映像に OpenPose を適用した結果の例を示す。本実験では動作位置が移動する様子を分析するため、OpenPose により求める首の座標をおよそ 2 秒の間隔で取得し、その変位を動作データとして算出する。また、本実験では、作業員 A を軸とした場合の作業員 B の関係を分析する。

図 46 に提案手法により求まるワーピングパスの結果を示す。ここで、図 46 の横軸は作業員 A、縦軸が作業員 B である。提案手法により求める指標の値は 192.5 であり、時間に差がなく要素が対応づけされた場合の指標の値は 112.5 である。したがって、時間に差がなく要素が対応づけされた場合に比して、指標の値が大きくなっており、この大小関係から、作業員 B が作業員 A に対して従属となる関係であることが示されている。これは、実際の主体と従属の関係性に一致する。図 46 は、作業員 A に対する作業員 B の関係を表現しており、図 46 における赤色の領域から、作業員 A に対して、作業員 B が遅れて移動する様子が、ワーピングパスにより表現できていることがわかる。また、図 46 より、主体作業員である作業員 A が移動するタイミングの作業員 A の要素と、時間的に先の作業員 B の要素が対応していることがわかる。これより、提案手法により算出される指標が、主体と従属の関係性を正しく表現していることが確認できる。以上により、提案手法により主体と従属の関係を定量化できる可能性が示唆された。

本実験で分析対象とした場面では、作業員 A が作業員 B に対して主体となる関係が望ましく、反対に作業員 B が作業員 A に対して主体となる状況や、二人の作業員が同じタイミングで移動するような状況は、安全性の観点で望ましくない。提案手法により求める指標について、安全性が高い現場を分析して得る結果との類似性を見ることで、主体と従属の関係が望ましい状況か否かの把握が可能となる。このように、提案手法を用いて、安全性が高い



図 43 本実験で分析対象とする作業員

空間の主従関係を数値化し蓄積することで、理想的な状況との類似度合を分析することが可能となる。





図 44 本実験で分析対象とする作業員が作業位置を移動する様子



図 45 建設現場映像に対して OpenPose を適用した結果の例




図 46 作業員 A を軸とした場合の作業員 B の関係を提案手法により分析した際のワーピングパスの結果

## 5.4 複数人物の連動性評価

本章では、複数人物の動作が連動する状況において、主体と従属の関係性を定量的に評価する手法を提案した。具体的には、OpenPoseにより得る関節の位置座標に基づく時系列の動作データに対して、DTWによりアライメントを行い、対応する要素の時間差に着目した評価関数を定義することで、主体と従属の関係を評価可能とした。ここで、本章では、連動する人物の主体と従属の関係を評価可能とすることを目的としている。したがって、本章で提案する手法を適用する前に、分析対象の人物が連動しているかどうかを分析する必要がある。そこで、本章の以降では、映像から人物の連動性を評価する手法について検討する。

### 5.4.1 連動性評価

本論文では、道路空間をエッジコンピューティングによってモニタリングすることを想定している。したがって、エッジで計算可能な程度に軽量な手法を構築する必要がある。ここで、主体と従属の関係を評価する手法では、DTWによってアライメントを行ったが、DTWでは、時系列データの類似度を求めることが可能である。具体的に、DTWでは、要素の全ての組み合わせに対してその距離を計算し、累積距離が小さくなる要素の対応関係を求めているが、この累積距離が小さいほど、二つの時系列データが類似していることを表す。一般的に、DTWによる求める累積距離をDTW距離と呼び、時系列データの類似度合いを求める手法として広く活用されている。主体と従属の関係を評価する手法と同様に、OpenPoseによって求まる関節の位置座標から動作データを取得し、動作データ間のDTW距離を求めることで、連動関係を評価可能となることが期待できる。また、全体の計算の中で、OpenPoseの計算が大きなコストを要するが、この計算がエッジで毎秒計算可能であることを第4章で確認しており、なおかつ、一度計算を行ってしまえば、連動性の評価および主体と従属の関係性評価の両方で活用できる。したがって、連動性および主体と従属の関係性評価の計算を実利用可能な時間で計算可能となることは十分に期待できる。



## 5.4.2 実験

本項では、5.3と同様に、連動する関係性が明確な建設現場の映像を用いて実験することで、提案手法の有効性を確認する。具体的には、コンクリート打設を行う様子を撮影した映像を用いて実験を行う。本実験では約70秒間の映像(30fps)を用いる。撮影したコンクリート打設の現場では、一人の作業員がポンプを使ってコンクリートを施工する場所に流し込む。また、異なる二人の作業員が、ポンプで流し込まれたコンクリートに対して、バイブレータを用いて振動を与える。本実験では、ポンプを用いてコンクリートを流し込む作業員を“ポンプ”、バイブレータで振動を与える二人の作業員をそれぞれ“バイブレータ A”および“バイブレータ B”とする。適切なコンクリート打設を行うためには、“ポンプ”と“バイブレータ A および B”の作業員の間に関連性が必要であり、同時に、“バイブレータ A”と“バイブレータ B”の作業員も連動する必要がある[119]。この様子は、実際に該当する作業員が連動していることが映像に記録されている。また、動作内容の観点から、前述の作業員との関連が低い作業員1名も撮像されており、この作業員を“その他”とする。本実験では、“ポンプ”、“バイブレータ A”、“バイブレータ B”、および“その他”の4人の作業員について、提案手法により DTW 距離を算出し、それらの連動する様子の定量化が可能であることを確認する。

図47に、OpenPoseで求める“Neck”の座標を用いて計算した DTW 距離の推移を示す。図47より、“ポンプ”と“バイブレータ A および B”の作業員、および“バイブレータ A”と“バイブレータ B”の作業員の DTW 距離が、“その他”の作業員との DTW 距離に比して、小さい傾向にあることが定性的に確認できる。これより、提案手法を用いることで、人物同士の動作の連動性が定量化可能となることが確認された。




図 47 OpenPose により求める“Neck”の座標を用いて計算した DTW 距離の推移

## 5.5 まとめ

本章では、人物間で動作が連動する状況において、主体および従属の関係性を定量的に評価する手法を提案した。具体的に、提案手法ではまず、各人物に対して、OpenPoseにより得る関節の位置座標に基づいて時系列の動作データを求める。次に、分析対象とする人物の組み合わせについて、動作データ間の要素をDTWによりアライメントする。提案手法では、DTWによって求まるアライメントの結果について、対応付けされた要素の時間の差に着目した評価関数を定義することで、主体および従属の関係性を評価する。実際のコンサート打設の様子を撮影した映像を用いた実験により、提案手法により主体と従属の関係を定量化できる可能性が確認された。

提案手法を用いることで、人物間で動作が連動する状況において、その主体及び従属の関係性の基本的な傾向を数値データとして積み上げることが可能となる。これにより、その基本的な傾向を学習する機械学習の実現が期待できる。例えば、One-Class Support Vector Machine[92]などを用いた、動作が通常どおりに行われる場合のデータのみを学習し、それと外れる状況を検知する異常検知のアプローチによって、正常な状態であるかの判断が定量的に可能となると期待できる。これは、事故リスクの低減などに繋がることを期待できるものであり、今後の課題として取り組んでいく。また、本章では、映像から主体と従属の関係を定量化可能とすることを課題として設定しているため、実験では、主体と従属の関係が明確な場面を検証データとして採用したが、今後の課題として、道路空間を移動する歩行者の群れなどを分析対象とした検証に取り組む必要がある。

また、本論文では、連動する複数人物の主体と従属の関係を評価可能とすることを目的としている。したがって、本章で提案する手法を適用する前に、分析対象の人物が連動しているかどうかを分析する必要がある。そこで、本章の最後では、映像から人物の連動性を評価する手法について検討した。具体的には、OpenPoseにより得る関節の位置座標に基づく動作データに対してDTW距離を求めることで、連動性を評価した。また、複数人物が活動する実空間を撮影した映像を用いた実験により有効性を確認した。

## 第6章 結論

### 6.1 本研究の総括

本論文では、サイバーフィジカルシステムにおける道路空間モニタリングのための骨格動作分析に基づくエッジコンピューティングについて検討した。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、サイバーフィジカルシステムやエッジコンピューティング、映像解析に基づく実空間モニタリングなど、本研究と関連した既存研究を説明し、本論文で解決すべき課題を明らかにした。第3章では、映像解析による骨格情報に基づく個人の動作分析手法を提案した。具体的には、映像から自転車の通常とは異なる走行を認識する手法を提案した。提案手法では、サイクリストの姿勢およびオプティカルフローに基づく特徴量を入力とする複数の機械学習に基づく識別器を構築し、複数の識別器から得る確信度に基づいて、自転車の走行を識別可能とした。また、自転車の走行を識別するためには、前段階として、映像から自転車を認識する必要がある。そこで、姿勢推定に基づく二輪車の識別手法についても検討した。第4章では、道路空間モニタリングのためのエッジコンピューティング基盤とその応用について取り組んだ。具体的には、エッジコンピューティングによる自動車の走行に関するデータ集積機構を提案した。提案するデータ集積機構は、バッテリー駆動が可能なマイクロコンピュータと USB 接続型の外部演算装置から構成され、第3章で提案した理論に基づき映像を解析し、自転車の走行に関するデータをサイバー空間へ伝送可能とする。また、計算時間やデータ容量について議論した。加えて、構築したエッジコンピューティング基盤を発展させ、他の土木工学に応用する取り組みを行った。具体的には、冬期道路の路面や視界の状況をモニタリング可能とするエッジコンピューティング基盤を構築した。また、第4章で構築する二つのエッジコンピューティング基盤は共に、機械学習に基づく AI によって映像を分析している。汎化性の優れた AI を実現するためには、個々のエッジが獲得する知識を共有しながら逐次的に AI を更新する必要がある。そこで、第4章の最後には、エッジで計算される AI の更新に有効なデータを有する他のエッジを選択する手法を構築した。第5章では、複数人物の骨格情報に基づく動作の連関の定量評価に取り組んだ。具体的には、実空間の映像から複数の人の主体と従属の関係を定量化する手法を提案した。提案手法では、骨格データに基づく時系列の動作データに対して DTW によりアラインメントを行い、アラインメントされた要素の時間の差に着目した評価関数を定義することで、主体と従属の関係を定量化した。また、この手法は、人物同士が連動していることを前提としている。そこで、第5章の最後には、映像から複数人物が連動しているかどうかを評価可能とする手法を構築した。

## 6.2 本研究の今後の課題

本論文の第3章および第4章では、人や車両の通常とは異なる走行を観測することで、通常どおりに移動可能な安全な空間であるかどうかを把握可能とすることを目的とし、その初期検討として、道路空間を対象として、自転車の走行を識別する手法とその識別結果に基づくデータ集積を可能とするエッジコンピューティング基盤を構築した。このアプローチは、自転車のみならず、道路空間であれば歩行者や自動車、さらには、建設現場や農業現場などの他の空間においても適用可能である。したがって、今後は他の物体や空間へ適応可能となる手法の拡張に取り組む必要がある。また、本論文における第5章では、個体間の主体と従属の関係を定量化可能とすることを目的として、複数人物の主体と従属の関係を定量化する手法を提案した。今後は、提案した手法により得られるデータを学習する機械学習の識別器を構築し、安全な状態との乖離度合を求めることで、異常な状態を検知可能とする手法の構築に取り組む必要がある。また、本論文では、主体と従属の関係が明確な建設現場を撮影した映像を用いて実験を行ったが、今後は、道路空間を移動する歩行者の群れなどを分析対象とした検証に取り組む必要がある。また、本論文では、サイバーフィジカルシステムの実現に向けて道路空間モニタリングのためのエッジコンピューティングについて検討した。しかしながら、サイバーフィジカルシステムを実現するためには、サイバー空間における分析やシミュレーション、さらには、サイバー空間から実空間へのフィードバックに関しても取り組む必要があり、今後の課題である。また、本論文では、IoTの普及などに伴い通信ネットワークを介した伝送や記録のためのデータ量が膨大となり、通信ネットワークの帯域が溢れることや、記録可能なデータ容量を超過する可能性が高いことに課題を設定し、エッジコンピューティングによって、データ量を削減することで課題の解決を図っている。ここで、記録するデータ量が増加することで生じる別の問題として、蓄積されるデータの管理や活用が困難になることが挙げられる。例えば、蓄積するデータ量が膨大となった場合には、データの検索に要する時間が長くなってしまふ。このような課題の解決に向けて、蓄積するデータの管理・活用方法についても考える必要があり、今後の課題である。

## 謝辞

本論文は筆者が北海道大学および北海道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戴きました。ここに深謝の意を表します。また、萩原亨教授には、ゼミや論文執筆などにおいて、大変丁寧なご指導を頂きました。同専攻の内田賢悦教授、高野伸栄教授には副査として貴重なご助言を戴きました。ここに深謝の意を表します。また、秘書の井上さんには、学会参加や論文投稿に伴う手続きなどで大変お世話になりました。そして、あらゆる面で協力していただいた研究室の後輩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。また、本論文で用いた映像データの一部は、阿部建設株式会社よりご提供いただきました。心より謝意を表します。

本研究の遂行にあたってご協力を賜りました皆様に心より感謝致します。誠にありがとうございました。

# Appendix

## A.1 はじめに

本論文では、サイバーフィジカルシステムにおける実空間モニタリングのためのエッジコンピューティングについて検討している。第1章および第2章で説明したとおり、画像・映像解析に基づく実空間モニタリングに関する取り組みとして、物体認識や人の骨格検出などが盛んにおこなわれている。これらの手法を応用することで、実空間における物体の位置や動作を観測可能となることが期待されており、本論文における第3章～第5章では、骨格推定の結果に基づいて、実空間の人の動作を分析している。ここで、サイバーフィジカルシステムを実現するためには、24時間365日をとおして実空間をモニタリングする必要がある。したがって、映像を撮影する時間帯や気象、映像の解像度やフレームレートなどに関わらず、安定して、物体認識や骨格推定の結果を取得可能とする必要がある。

これを実現するためには、ノイズ除去や高解像度化などの画像・映像の前処理が必要となる。例えば、文献[119]では、夜間に撮影した画像に対してコントラスト平坦化などの前処理を行うことで、物体認識の精度向上を実現している。また、文献[120]では、サイズの小さな画像から人間の骨格を検知可能とすることを目的とした超解像の手法を提案している。ここで、積雪寒冷地では、吹雪による視界不良が発生する。視界不良が発生した場合には、既存の物体認識手法によって物体を正確に認識することは難しく、ノイズ除去などの前処理が必要となる。これを実現するためには、まず、視界がどれだけ悪いのか、すなわちノイズの量を事前に把握する必要がある。

道路空間を対象として、画像・映像から視界状況を推定する手法が提案されているが、夜間の精度が課題である。文献[121]で提案された手法は、車載カメラ映像を用いて、機械学習に基づく手法と教師無し数理モデルに基づく手法[111]の協調利用によって夜間の視界を推定している。しかしながら、教師無し数理モデルに基づく手法の精度が、機械学習に基づく手法に比して低いことが課題である。そこで、教師無し数理モデルに基づく手法の高精度化に取り組む。

ここで、従来の教師無し数理モデルに基づく手法は、画像のコントラストを表現する評価値を用いている。視界不良時には、雪粒子により、画像のコントラストが小さくなることから、コントラストの大きさの違いに基づいて視界状況を推定する。しかしながら、雪粒子の密度が疎である場合、すなわち、中程度の視界不良が発生している状況では、画像に雪粒子のエッジが生じるため、画像のコントラストが大きくなり、結果として、視界良好として誤推定してしまう傾向にあることが問題である。

ここで、コントラストの大きさが同程度であっても、コントラスト感度が異なる場合には、見え方が異なる。また、コントラスト感度は背景の輝度によって変化する。具体的には、背

景の輝度が大きくなると、コントラスト感度は低くなる。この現象を一般的に輝度順応効果と呼ぶ。夜間の降雪時では、雪粒子に光が反射することで、背景輝度が大きくなるため、コントラスト感度が低くなる。したがって、輝度順応効果に基づくコントラスト感度の変化を表現可能な評価値を新たに導入することで、中程度の視界不良を識別する精度の向上が見込める。そこで、提案手法では、従来のコントラストに基づく評価値に加えて、新たに輝度順応効果によるコントラスト感度の変化を表す評価値を導入した視界の評価手法を提案する。本論文では、視界状況をエッジコンピューティングにより評価することを想定している。そのため、より低演算で視界を評価可能とすることが望ましい。ここで、画像や映像の圧縮方式の多くが、画像のコントラスト感度に着目している。したがって、画像や映像の圧縮過程で得られるデータを活用することで、輝度順応効果に基づくコントラスト感度の変化を表現可能な評価値の導出が期待できる。画像や映像の圧縮は、画像・映像を扱うエッジコンピューティング基盤において必要な計算であることから、その過程で得られるデータを活用することで、視界評価に必要な計算量の大幅な削減が見込める。



## A.2 車載カメラ映像を用いた夜間の視界評価手法

本節では、夜間の視界を評価するための教師なし数理モデルに基づく手法について説明する。提案手法は、図 a に示すように、2つのステップから構成されており、第1ステップでは2つの評価値を算出する。1つ目の評価値は画像のコントラストを表し、2つ目の評価値は輝度順応効果によるコントラスト感度の変化を表す。提案手法では、第2ステップで2つの評価値を統合し、最終的な視界の評価結果を得る。

### A.2.1 Step 1: 二つの評価値の算出

#### A.2.1.1 画像のコントラストを表現する評価値

まず、車載カメラで撮影した画像から $2^n \times 2^n$ ピクセル(例えば、 $128 \times 128$ ピクセルや $256 \times 256$ ピクセル)の領域を切り出す。この領域は、遠方の道路空間を含むように手動で決定される。分析領域のサイズと位置は、車載カメラの画角によって異なる。次に、グレースケール変換を施し、得られるグレースケール画像に対して2次元高速フーリエ変換(FFT)を適用する。次に、約 $1.5 \sim 18$  cpdの範囲における空間周波数振幅に対応するパワースペクトル値を計算する。最後に、計算されたパワースペクトル値の合計を対数パワースペクトルとしてスケールリングすることにより、画像のコントラストを表す評価値 $Wips$ を得る。晴天時では、パワースペクトルが大きく、 $Wips$ が大きくなる。降雪時のような視界が悪い状況では、パワースペクトルは小さく、 $Wips$ も小さくなる。

#### A.2.1.2 輝度順応効果によるコントラスト感度の変化を表現する評価値

様々な画像圧縮方式において、R, G, B プレーンから Y, Cb, Cr プレーンに変換するための前処理が実行される。前処理の後には、新しい3つのプレーン(Y, Cb, Cr)がそれぞれブロックに分割される。ブロックのサイズは、 $8 \times 8$ ,  $16 \times 16$ ,  $32 \times 32$ ,  $64 \times 64$  などさまざまであり、各ブロックに対してDCT変換を適用する。提案手法では、 $Wips$ の計算に使用される領域内のブロックのYプレーンをDCT変換して得られるDCT係数を利用する。本論文では、 $c_{ijk}$ は、 $k_{th}$  ( $k = 1, 2, \dots, K$ )ブロック内のY平面の $(i, j)_{th}$ 番目のDCT係数を表す。ここで、 $K$ は $Wips$ の計算に使用される領域内のブロックの数である。

背景が明るいほど、コントラスト閾値は高くなる。これは通常「輝度順応効果」と呼ばれる。本章では、 $k$ 番目のブロック内の各周波数 $i, j$ のコントラスト閾値を $t_{ijk}$ と呼ぶ。文献[122]では、輝度適応効果を考慮して決定される閾値は次のように計算される。

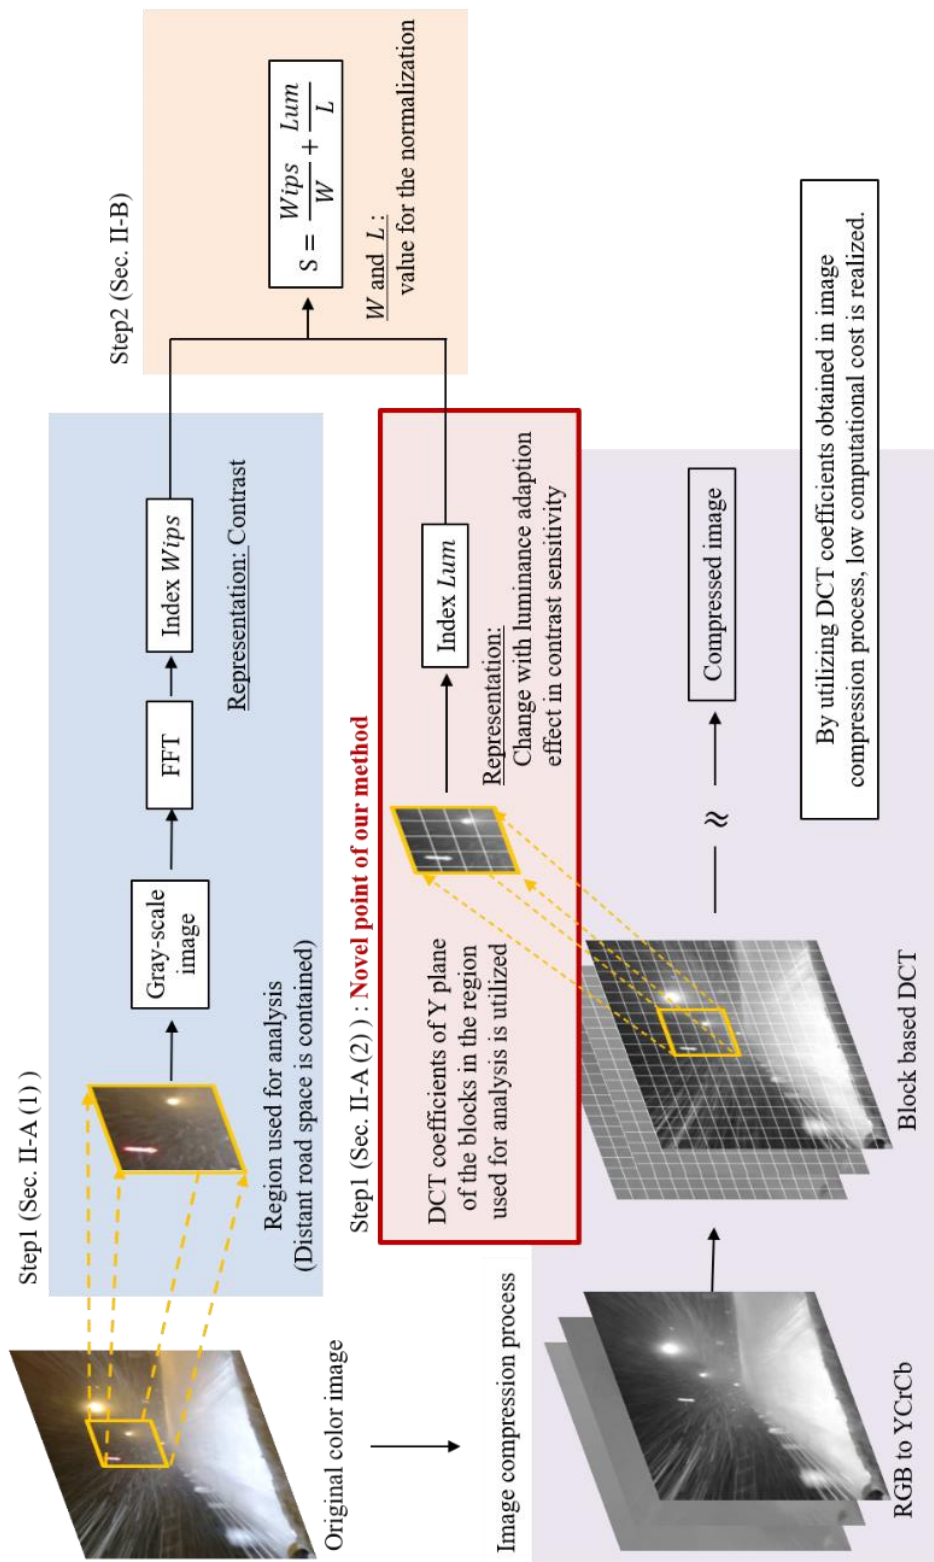


図 a 提案手法の概要

$$t_{ijk} = t_{ij}(c_{00k}/\bar{c}_{00})^a$$

ここで、 $t_{ij}$ は基準となるコントラスト閾値、 $\bar{c}_{00}$ は $t_{ij}$ に対応する DC 係数を表す。また、 $a$ は、輝度順応効果が発生する程度を制御するパラメータである。

提案手法では、まず、解析に使用する領域内のブロックの DC 係数の大きさの中央値を次のように計算する。

$$C_{00} = \text{median}\{c_{001}, c_{002}, \dots, c_{00K}\}$$

ここで、 $\text{median}$ は中央値を計算する関数を意味する。コントラスト感度は、コントラスト閾値の逆数として定義される。そこで、提案手法では、輝度順応効果によるコントラスト感度の変化を表す評価値 $Lum$ を以下のように計算する。

$$Lum = 1/(C_{00}/\bar{c}_{00})^a$$

$Lum$ の値が小さいと、輝度順応効果によりコントラスト感度が低くなる。反対に、指標 $Lum$ の値が大きい場合には、輝度順応効果によりコントラスト感度が高くなることを意味する。

#### A.2.2 Step 2: 二つの評価値の統合

前のステップで取得した 2 つの評価値を統合する方法を示す。提案手法は次のようにして、新たな評価値 $S$ を算出する。

$$S = \frac{Wips}{W} + \frac{Lum}{L}$$

ここで、 $W$ と $L$ は各値を正規化するための値である。 $Wips$ は、画像のコントラストを表す評価値である。降雪時などの視界が悪い状況におけるドライバーの視界は、コントラストが小さく、 $Wips$ も小さくなる。反対に、晴天時には、コントラストが大きく、 $Wips$ も大きくなる。また、 $Lum$ は輝度順応効果によるコントラスト感度の変化を表す。視界が悪い状況では、雪粒子による光の反射によって背景輝度が増加し、これによりドライバーのコントラスト感度が低下するため、 $Lum$ は小さくなる。晴天時はコントラスト感度が高く、 $Lum$ が大きい。 $S$ の値が小さいと、ドライバー目線における視界のコントラストおよびドライバーのコントラスト感度が低くなる。この状況では、ドライバーは道路空間を認識することが困難である。逆に、 $S$ の値が大きい場合には、視界のコントラストおよびドライバーのコントラスト感度がともに高く、ドライバーは道路空間を認識しやすい。このように、評価値 $S$ は、運転者か

ら見た道路空間の見えやすさを表す数値となる。提案手法は $S$ の値が小さい場合には、視界が不良と推定し、反対に、 $S$ が大きい場合には、視界が良好であると推定する。

## A.3 実験

本章では、実際に車載カメラによって取得された画像を用いて提案手法の有効性を確認する。A.3.1では実験の概要を説明し、実験結果をA.3.2で示す。

### A.3.1 実験設定


提案手法の有効性を確認するために、道路の視界状況をレベル 1、レベル 2、レベル 3 の 3 つのカテゴリに分類する。カテゴリの数は文献 [121] に基づいている。レベル 1 は「視界良好」を表し、レベル 3 は「視界不良」を表す。視界レベルは、視認可能な矢羽の数に基づいて定義される。本実験では、提案する評価値を用いて視界レベルを推定する。視界レベル $Level$ は次のように推定する。

$$Level = \begin{cases} Level 1 & (S > Th_1) \\ Level 2 & (Th_2 \leq S \leq Th_1) \\ Level 3 & (S < Th_2) \end{cases}$$

$Th_1$ と $Th_2$ はしきい値を表す。各レベルの識別性能を評価することで、 $S$ の値が視界状況に対応しているかどうかを確認する。本実験では、実際に、夜間に車載カメラによって取得した画像を使用する。各視界レベルの画像の例を図 b に示す。各視界レベルの画像数は 300 枚である。本実験において、提案する視界の評価値の計算に使用した領域の位置は図 c の緑色の矩形で示すとおりであり、そのサイズは  $128 \times 128$  ピクセルである。また、2 つの評価値を正規化するための  $W$  と  $L$  の値は実験的に設定しており、その値はそれぞれ 7.14 および 1.869 である。また、視界レベルを推定するための閾値  $Th_1$  と  $Th_2$  は、提案手法の性能が最も高くなるように決定しており、その値はそれぞれ 1.14 および 0.93 である。また、コントラスト感度に基づく評価値の計算に使用されるパラメータ  $\bar{c}_{00}$  および  $a$  は、文献 [122] に基づいて決定しており、その値はそれぞれ 1.024 および 0.649 である。

提案手法の性能は、次のように定義する Recall, Precision, F 値を使用して評価される。

$$Recall = \frac{Num. of correctly estimated images}{Num. of correct images}$$



Level 1



Level 2



Level 3

図 b 各視界レベルの画像例



図 c 提案手法における分析領域

$$Precision = \frac{Num. of correctly estimated images}{Num. of all estimated images}$$

$$F \text{ 値} = \frac{2 \times Recall \times Precision}{Recall + Precision}$$

また、提案手法の性能を評価するために、4つの比較手法を用いる。

### 比較手法 1

画像のコントラストを表す評価値のみを使用する。この評価値は、道路管理のための新たなツールとして実際に使用されている。

### 比較手法 2

この手法は、文献[122]に基づく機械学習の手法である。この手法では、まず、車載カメラの映像から4種類の特徴量を取得する。4種類の特徴は、具体的に、空間周波数、明度、オプティカルフロー、Inception-v3 [15] である。次に、比較手法 2 は、4種類の特徴ベクトルを用いて ELM と SVM を構築する。最後に、構築した SVM と ELM から得られた推定結果に対して多数決を行うことで視界レベルを推定する。

提案手法により得られた結果と比較手法 1 により得られた結果を比較することで、提案された手法が、[122]で使用された従来の教師なし数学モデルに基づく手法よりも効果的であることを検証する。さらに、提案手法と比較手法 2 により得られた結果を比較する。この

比較により、これら 2 つの手法を組み合わせることで視界の推定性能が向上する可能性を確認する。

提案手法は、エッジで計算することを想定している。画像認識の分野では、軽量の畳み込みニューラルネットワーク (CNN) が提案されている [118,123]。そこで、提案手法を評価するために以下の比較手法を用いた。

### **比較手法 3**

この手法は、MobileNets[118]をファインチューニングした CNN モデルに基づいている。MobileNets は軽量の Deep CNN の 1 つで、モバイルおよびエッジデバイスで、深層学習に基づくアプリケーションを活用することを想定して設計されている。比較手法 3 では、ImageNet データセット [124] で学習済みの Mobilenet をファインチューニングした。MobileNets の入力画像のサイズは 224 × 224 ピクセルであり、提案手法で使用した画像を 224 × 224 ピクセルにリサイズした。トレーニングは最大 100 エポックで実行した。検証データセットの識別精度に基づいて、最適なモデルを選択した。また、検証方法は 5 分割交差検証を用いた。

### **比較手法 4**

この手法は、EfficientNets-B0[123]に基づいている。EfficientNets は、軽量の Deep CNN の 1 つである。比較手法 4 では、ImageNet データセットで学習済みの EfficientNets をファインチューニングしている。EfficientNets-B0 の入力画像サイズは 224 × 224 ピクセルであり、提案手法で用いる画像のサイズを 224 × 224 ピクセルにリサイズしたものを入力画像とした。トレーニングは最大 100 エポックで実行した。検証データセットの識別精度に基づいて、最適なモデルを選択した。また、検証方法は 5 分割交差検証を用いた。

提案手法により得られた結果と比較手法 3 および比較手法 4 により得られた結果の比較により、提案された手法が一般的な軽量の CNN に基づく手法に比して効果的であるかどうかを確認する。これら 4 つの比較方法を選択した理由は次のように要約される。

### **提案手法 vs 比較手法 1**

提案された評価値が、従来の教師無し数理モデルに基づく手法よりも効果的であるかどうかを検証する。

### **提案手法 vs 比較手法 2**

機械学習ベースの手法と教師なし数学モデルに基づく手法の協調利用の可能性を検証する

### **提案手法 vs 比較手法 3 と比較手法 4**

提案された手法が一般的な軽量の CNN に基づく手法よりも効果的であるかどうかを検証する。

また、道路の視界情報を取得するために、視程計を利用した方法も実際に活用されている。ただし、夜間におけるドライバーの視認性は道路照明の影響を受ける。したがって、視程計を使用して推定される視程は、夜間のドライバー目線の視界とは異なる。これに対し、提案手法では車載カメラ画像を利用するため、ドライバー目線の視界に近い視界状況を推定することができる。

### A.3.2 実験結果

提案手法と比較手法1の Recall, Precision, F 値を表 a に示す。全ての視界レベルの Recall, Precision, および F 値の平均値において、提案手法は比較手法1を上回る性能を示している。これより、提案手法の有効性が確認された。比較手法1では、レベル1やレベル3に比して、レベル2の Recall が低いという問題がある。具体的には、雪粒子の密度が疎で、画像に雪粒子のエッジが現れる場合、レベル2の画像を視界が良好であると誤って推定する傾向がある。表 a に示すように、レベル2の Recall において、提案手法は比較手法1を上回っている。提案手法では正しく推定され、比較手法1では誤ってレベル1と推定されたレベル2の画像の例を図 d に示す。図 d に示すように、吹雪粒子の密度が疎で、雪粒子のエッジが画像に現れる場合、比較手法1は誤ってレベル1と推定する。これは、雪粒子のエッジにより画像のコントラストが増加し、評価値が視界良好時と同じくらい高くなるためである。一方で、提案手法では正しくレベル2と推定される。画像のコントラストは大きいですが、コントラスト感度は晴天時よりも低い。これは、雪粒子による光の反射により、背景の輝度が増加するためである。そのため、晴天時よりも視界状況は悪くなる。提案手法はコントラスト感度の変化を考慮しているため、正確に視界状況を推定することができる。したがって、コントラスト感度に基づく評価値を導入することの有効性が確認できる。

将来的には、提案する教師なし数理モデルに基づく手法と機械学習に基づく手法を協調して利用することを想定している。そこで、提案手法と比較手法2による推定結果を比較することで、二つの手法の協調利用により視界の推定精度が向上する可能性を確認する。表 b に示すように、比較手法2は、全ての視界レベルの Recall, Precision, および F 値の平均値において、提案手法を上回っている。しかし、提案手法はレベル3の Recall において比較手法2を上回っている。レベル3は「視界が非常に悪い」ことを示し、運転の危険性が



表 a 提案手法と比較手法 1 における Recall, Precision および F 値

	Level1			Level2			Level3			Average		
	R	P	F	R	P	F	R	P	F	R	P	F
提案手法	0.69	<b>0.93</b>	<b>0.79</b>	<b>0.58</b>	<b>0.57</b>	<b>0.58</b>	0.83	<b>0.67</b>	<b>0.75</b>	<b>0.70</b>	<b>0.73</b>	<b>0.70</b>
比較手法 1	<b>0.75</b>	0.62	0.68	0.11	0.53	0.19	<b>0.89</b>	0.56	0.69	0.59	0.57	0.52




図 d 提案手法では正しく推定され、比較手法 1 では誤ってレベル 1 と推定されたレベル 2 の画像の例

最も高くなる。より安全な道路空間を確保するためには、最も危険な視界状況であるレベル 3 を見逃すことが最も避けるべきことである。したがって、レベル 3 の Recall は、すべての指標の中で最も重要である。次に、提案手法による推定結果と比較手法 2 による推定結果の混同行列を表 c および表 d に示す。表 c および表 d より、提案手法と比較手法 2 による誤推定の傾向が異なることが確認できる。比較手法 2 は、提案手法に比べてレベル 2 をレベル 1 と誤って推定する傾向がある。道路交通の安全を確保する観点からは、視界状況の推定を誤ってしまう場合には、実際の視界状況よりも危険な状況として誤推定することが望ましい。これらのように、提案手法と比較手法 2 では視界状況推定の傾向が異なっている。そして、それぞれの方法には長所と短所がある。したがって、提案手法と比較手法 2 の結果を、各手法の推定傾向を考慮しながら統合することで、より正確な視界推定の実現が期待できる。

表 b 提案手法と比較手法 2 における Recall, Precision および F 値

	Level1			Level2			Level3			Average		
	R	P	F	R	P	F	R	P	F	R	P	F
提案手法	0.69	<b>0.93</b>	0.79	0.58	0.57	0.58	<b>0.83</b>	0.67	<b>0.75</b>	0.70	0.73	0.70
比較手法 2	<b>0.90</b>	0.87	<b>0.89</b>	<b>0.59</b>	<b>0.62</b>	<b>0.60</b>	0.73	<b>0.72</b>	0.73	<b>0.74</b>	<b>0.74</b>	<b>0.74</b>

表 c 提案手法の混合行列

		推定結果		
		Lv. 1	Lv. 2	Lv. 3
GT	Lv. 1	207	83	10
	Lv. 2	14	175	111
	Lv. 3	1	49	250

表 d 比較手法 2 の混合行列

		推定結果		
		Lv. 1	Lv. 2	Lv. 3
GT	Lv. 1	271	28	1
	Lv. 2	39	176	85
	Lv. 3	1	79	220

表 e 提案手法と比較手法 3 および 4 における Recall, Precision および F 値

	Level1			Level2			Level3			Average		
	R	P	F	R	P	F	R	P	F	R	P	F
提案手法	0.69	<b>0.93</b>	<b>0.79</b>	0.58	<b>0.57</b>	0.58	<b>0.83</b>	0.67	<b>0.75</b>	<b>0.70</b>	<b>0.73</b>	<b>0.70</b>
比較手法 3	<b>0.76</b>	0.77	0.77	<b>0.76</b>	0.55	<b>0.64</b>	0.44	<b>0.72</b>	0.55	0.66	0.68	0.65
比較手法 4	0.64	0.73	0.68	0.68	0.41	0.51	0.26	0.58	0.36	0.53	0.57	0.52

次に、提案手法で得られた結果と比較手法3および4で得られた結果を比較する。表 e に示すように、全ての視界レベルの Recall, Precision, および F 値の平均値において、提案手法は比較手法を上回っている。したがって、提案手法は、一般的な軽量の CNN に基づく手法よりも優れていることが確認できる

提案手法は、エッジで活用することを想定している。したがって、エッジコンピューティングを想定した環境での計算時間を確認する必要がある。比較手法1は従来の評価値に基づいた手法であり、提案手法では、従来の手法にコントラスト感度に基づく評価値を新たに導入することで、より正確な視界推定を実現している。提案手法は、計算量を削減するために、画像圧縮処理で得られる DCT 係数を用いてコントラスト感度に基づく評価値を計算する。そこで、本実験では、提案手法と比較手法1の計算時間を比較する。計算時間はマイクロコンピュータを用いて測定する。マイクロコンピュータの仕様を表 f に示す。Raspberry Pi は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 [125-127] ため、本実験では Raspberry Pi を使用した。表 g に示すように、提案手法の計算時間は、コントラスト感度に基づく評価値を算出する計算が必要であるにもかかわらず、比較手法1の計算時間と同等である。したがって、画像圧縮処理で得られる DCT 係数を利用することの有効性が確認された。また、提案手法の計算時間は、表 g に示すように  $2.30 \times 10^{-2}$  秒である。これは1秒間に約43回の頻度で視程を推定できることを意味する。エッジコンピューティングシステムで使用される車載カメラのフレームレートが30fpsであると仮定すると、提案手法はすべてのフレームを遅延なく解析できる。さらに、エッジコンピューティングシステムを搭載した車両の速度が40km/hであると仮定すると、0.26mごとに1回の視界推定が可能である。この解像度は、道路の視界状況を把握するのに十分な大きさである。以上の内容から、提案手法は、視界状況を推定するエッジコンピューティングとして活用することに有効な手法であることがわかる。

実験結果を以下に纏める。コントラストが同等であっても、コントラスト感度が異なる場合には、見え方が異なる。コントラスト感度は背景の輝度によって変化するが、従来の評価値では、それを考慮していない。そこで、提案手法では、輝度順応効果によるコントラスト感度の変化を表す評価値を新たに導入した。実験結果から、夜間の視界推定には、コントラスト感度に基づく指標を導入することが有効であることが判明した。また、提案手法は、新たな評価値を計算する必要があるにもかかわらず、増加する計算コストはわずかであり、これは、視界を推定するエッジコンピューティングとして実際に活用する場合に有益である。また、機械学習に基づく手法と本章で提案する教師なし数理モデルに基づく手法を組み合わせることで、より高精度な視界推定が実現できる可能性が確認された。

表 f 実験で用いるマイクロコンピュータの仕様

Device	Specification
Micro Computer (Raspberry Pi4)	Soc: Broadcom BCM2711 CPU: ARM Cortex A72(4cores, 1.5GHz) GPU: Broadcom VideoCore IV 500MHz RAM : 8GB

表 g 提案手法及び比較手法 1 における計算時間

Method	Computation cost(sec)
提案手法	$2.30 \times 10^{-2}$
比較手法 1	$2.26 \times 10^{-2}$

## A.4 まとめ

車載カメラ画像を用いて夜間の視界状況を推定する教師なし数理モデルに基づく手法を提案した。提案手法は、視界を推定するエッジコンピューティングとしての利用を想定している。提案手法では、車載カメラ画像から2つの評価値を算出する。2つの評価値はそれぞれ、画像のコントラストおよび輝度適応効果によるコントラスト感度の変化を表現する。コントラスト感度に基づく評価値は、計算コストを削減するために、画像圧縮プロセスで得られるDCT係数を活用することで求められる。最後に、これら2つの指標を統合することにより、視界状況の新たな評価値を得る。実際に車載カメラにより取得した画像を用いた実験により、推定精度および計算時間の二つの点において、提案手法の有効性が確認された。

## 参考文献

- [1] Gill H. : NSF perspective and status on cyber–physical systems, In NSF Workshop on Cyber–physical Systems, 2006.
- [2] Grieves M. : Digital twin: manufacturing excellence through virtual factory replication, White paper, vol. 1, pp. 1–7, 2015.
- [3] B. Hayes : Cloud computing, Commun. ACM, vol. 51, no. 7, pp. 9–11, 2008.
- [4] 総務省 : 平成 30 年度版情報通信白書 , <https://www.soumu.go.jp/johotsusintokei/whitepaper/ja/h-30/index.html> (参照 2020-03-04).
- [5] Reinsel, D., Gantz, J., and Rydning : Data age 2025: the evolution of data to life-critical don't focus on big data; focus on the data that's big, International Data Corporation (IDC) White Paper, 2017.
- [6] 千川尚人 : エッジコンピューティング, 映像情報メディア学会誌, vol. 73, no. 4, pp. 707-709, 2019.
- [7] Shi, Weisong and Cao, Jie and Zhang, Quan and Li, Youhuizi and Xu, Lanyu : Edge Computing: Vision and Challenges, IEEE Internet of Things Journal, vol. 3, num. 5, pp. 637-646, 2016.
- [8] Liu, Yang and Peng, Yu and Wang, Bailing and Yao, Sirui and Liu, Ziheng : Review on cyber-physical systems, IEEE/CAA Journal of Automatica Sinica, vol. 4, num. 1, pp. 27-40, 2017.
- [9] Möller, Dietmar P.F. and Vakilzadian, Hamid : Cyber-physical systems in smart transportation, 2016 IEEE International Conference on Electro Information Technology (EIT), vol. 3, num. 5, pp. 637-646, 2016.
- [10] Akanmu, A. A., Anumba, C. J., and Ogunseiju, O. O. : Towards next generation cyber-physical systems and digital twins for construction. Journal of Information Technology in Construction, vol. 26, pp. 505-525, 2021.

- [11] L. Monostori, B. Kádár, T. Bauernhansl, S. Kondoh, S. Kumara, G. Reinhart, O. Sauer, G. Schuh, W. Sihn and K. Ueda : Cyber-physical systems in manufacturing, CIPR Annals, vol. 65, num. 2, pp. 621-641, 2016.
- [12] Ahmad, Irfan and Pothuganti, Karunakar : Smart field monitoring using ToxTrac: A cyber-physical system approach in agriculture, In 2020 International Conference on Smart Electronics and Communication (ICOSEC), pp. 723-727, 2020.
- [13] Shakeri, Reza and Al-Garadi, Mohammed Ali and Badawy, Ahmed and Mohamed, Amr and Khattab, Tamer and Al-Ali, Abdulla Khalid and Harras, Khaled A. and Guizani, Mohsen : Design challenges of multi-UAV systems in cyber-physical applications: A comprehensive survey and future directions, IEEE Communications Surveys & Tutorials, vol. 21, no. 4, pp. 3340-3385, 2019.
- [14] Peiyuan Jiang, Daji Ergu, Fangyao Liu, Ying Cai, Bo Ma : A Review of Yolo algorithm developments. Procedia Computer Science, vol. 199, pp. 1066-1073, 2022.
- [15] Christian Szegedy, Vincent Vanhoucke, Sergey Ioffe, Jon Shlens, Zbigniew Wojna : Rethinking the inception architecture for computer vision. In Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 2818-2826, 2016.
- [16] Cao, Z., Simon, T., Wei, S.-E. and Sheikh, Y. : Realtime Mul-ti-Person 2D Pose Estimation using Part Affinity Fields, in Proc. IEEE Conference on Computer Vision and Pattern Recognition, pp. 7291-7299, 2017.
- [17] Fang, Hao-Shu and Li, Jiefeng and Tang, Hongyang and Xu, Chao and Zhu, Haoyi and Xiu, Yuliang and Li, Yong-Lu and Lu, Cewu : Alphapose: Whole-body regional multi-person pose estimation and tracking in real-time, IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 45, num. 6, pp. 7157-7173, 2023.
- [18] Wojke, Nicolai and Bewley, Alex and Paulus, Dietrich : Simple online and realtime tracking with a deep association metric. In 2017 IEEE international

conference on image processing (ICIP), pp. 3645-3649, 2017.

- [19] Pal, S. K., Pramanik, A., Maiti, J., and Mitra, P. : Deep learning in multi-object detection and tracking: state of the art, *Applied Intelligence*, vol. 51, pp. 6400-6429, 2021.
- [20] Zhang, Shile and Abdel-Aty, Mohamed and Wu, Yina and Zheng, Ou : Pedestrian Crossing Intention Prediction at Red-Light Using Pose Estimation, *IEEE Transactions on Intelligent Transportation Systems*, vol. 23, num. 3, pp. 2331-2339, 2022.
- [21] Ijjina, Earnest Paul and Chand, Dhananjai and Gupta, Savyasachi and Goutham, K. : Computer Vision-based Accident Detection in Traffic Surveillance, 2019 10th International Conference on Computing, Communication and Networking Technologies (ICCCNT), pp. 1-6, 2019.
- [22] Kareem Mostafa and Tarek Hegazy : Review of image-based analysis and applications in construction, *Automation in Construction*, vol. 122, 2021.
- [23] Tsung-Yi Lin, Michael Maire, Serge Belongie, James Hays, Pietro Perona, Deva Ramanan, Piotr Dollár, and C Lawrence Zitnick : Microsoft coco: Common objects in context, In *Proc. Europ. Conf. Computer Vision (ECCV)*. Springer, pp. 740–755, 2014.
- [24] Alexey Bochkovskiy, Chien-Yao Wang, Hong-Yuan Mark Liao : Yolov4: Optimal speed and accuracy of object detection. arXiv preprint arXiv:2004.10934.
- [25] 川嶋智和, 宮内新太郎 : 車載カメラを用いた道路状況等の確認に関する試行導入について, 令和 3 年度近畿地方整備局研究発表会 論文集, 一般部門 (安全・安心) I, no. 2, 2021.
- [26] 国土交通省 : 道路施設の点検データベースの整備と新技術活用, <https://www.mlit.go.jp/road/ir/ir-council/dourogijutsu/pdf03/04.pdf> (2024-02-09 参照)



- [27] 公益財団法人 交通事故総合分析センター：交通統計 令和3年度版.
- [28] 厚生労働省：令和4年 / 令和元年労働災害発生状況の分析等,  
<https://www.mhlw.go.jp/bunya/roudoukijun/anzeneisei11/rousai-hassei/>
- [29] Th. Robin, G. Antonini, M. Bierlaire and J. Cruz : Specification, estimation and validation of a pedestrian walking behavior model. *Transportation Research Part B: Methodological*, vol. 43, num. 1, pp. 36-56, 2009.
- [30] Basilico, N., Gatti, N., and Amigoni, F. : Leader-follower strategies for robotic patrolling in environments with arbitrary topologies. In *Proceedings of the International Joint Conference on Autonomous Agents and Multi Agent Systems (AAMAS)*, pp. 57-64, 2009.
- [31] Xiao, Hanzhen and Li, Zhijun and Philip Chen, C. L. : Formation control of leader-follower mobile robots' systems using model predictive control based on neural-dynamic optimization. *IEEE Transactions on Industrial Electronics*, vol. 63, num. 9, pp. 5752-5762, 2016.
- [32] C. Greer, M. Burns, D. Wollman, and E. Griffor : NIST SP 1900-202: Cyber-physical systems and Internet of Things, NIST, Gaithersburg, MD, USA, document NIST SP 1900-202, 2019.
- [33] Edward A. Lee : *Cyber-Physical Systems - Are Computing Foundations Adequate?*, Position Paper. *NSF Workshop on Cyber-Physical Systems: Research Motivation, Techniques and Roadmap*, vol. 2, 2006.
- [34] IEEE Technical Committee on Cyber-Physical Systems (2018) *Cyber Physical Systems Technical Committee*.
- [35] Edward A. Lee : *CPS Foundations*. *DAC '10 Proceedings of the 47th Design Automation Conference*, (ACM, Anaheim, California), pp 737-742, 2010.
- [36] Shi, Jianhua and Wan, Jiafu and Yan, Hehua and Suo, Hui : *A Survey of Cyber-Physical Systems*. *2011 International Conference on Wireless Communications*

and Signal Processing, pp. 1-6, 2011.

- [37] National Institute of Standards and Technology (2013) Foundations for Innovation in Cyber-Physical Systems Workshop Summary Report. (Prepared by Energetics Incorporated Columbia, Maryland).
- [38] Rajkumar, Raguathan and Lee, Insup and Sha, Lui and Stankovic, John : Cyber-Physical Systems: The Next Computing Revolution. Proceedings of the 47th Design Automation Conference, pp 731–736, 2010.
- [39] Cardenas, Alvaro A. and Amin, Saurabh and Sastry, Shankar : Secure Control: Towards Survivable Cyber-Physical Systems. The 28th International Conference on Distributed Computing Systems Workshops, pp. 495-500, 2008.
- [40] Tan, Ying and Vuran, Mehmet C. and Goddard, Steve : Spatio-Temporal Event Model for Cyber-Physical Systems, 29th IEEE International Conference on Distributed Computing Systems Workshops, pp. 44-50, 2009.
- [41] President’s Council of Advisors on Science and Technology : Leadership Under Challenge: Information Technology R&D in a Competitive World (Executive Office of The President, Washington, DC), 2007.
- [42] Executive Roundtable on Cyber-Physical Systems : Strategic Vision and Business Drivers for 21st Century Cyber-Physical Systems. (National Institute of Standards and Technology, Gaithersburg, MD), 2013.
- [43] Bordel B, Alcarria R, Robles T, Martin D : Cyber-Physical Systems: Extending Pervasive Sensing from Control Theory to the Internet of Things, Pervasive and Mobile Computing, vol. 40, pp. 156–184, 2017.
- [44] Lee, Edward A. : Cyber Physical Systems: Design Challenges, 2008 11th IEEE International Symposium on Object and Component-Oriented Real-Time Distributed Computing, pp. 363-369, 2008.
- [45] Networking and Information Technology Research and Development, Cyber-

Physical System Interagency Working Group, CPS Vision Statement, working document, p. 2, 2015.

- [46] Teodora Sanislav, Liviu Miclea : Cyber-Physical Systems -Concept, Challenges and Research Areas. *Journal of Control Engineering and Applied Informatics*, vol. 14, no. 2, pp. 28–33, 2012.
- [47] Yongfu, Li and Dihua, Sun and Weining, Liu and Xuebo, Zhang : A service-oriented architecture for the transportation Cyber-Physical Systems, *Proceedings of the 31st Chinese Control Conference*, pp. 7674-7678, 2012.
- [48] Wade Genders, Jun Wang, Saiedeh Razavi : Smartphone construction safety awareness system: A cyber-physical system approach, In *The 16th International Conference on Computing in Civil and Building Engineering (ICCCBE2016)*, pp. 1697-1704, 2016.
- [49] Yuan, X., Anumba, C. J. and Parfitt, M. K. : Real-time Cyber-Physical Systems (CPS)-based monitoring of temporary structures: A scaffolding system example, *Proceedings of the 32nd CIB W78 Conference 2015*, pp. 780-789, 2015..
- [50] Cao, Kun and Hu, Shiyan and Shi, Yang and Colombo, Armando Walter and Karnouskos, Stamatis and Li, Xin : A survey on edge and edge-cloud computing assisted cyber-physical systems. *IEEE Transactions on Industrial Informatics*, vol. 17, num. 11, pp, 7806-7819, 2021.
- [51] Kareem Mostafa and Tarek Hegazy : Review of image-based analysis and applications in construction, *Automation in Construction*, vol. 122, 2021.
- [52] M.W. Park, N. Elsafty, Z. Zhu : Hardhat-wearing detection for enhancing on-site safety of construction workers, *J. Constr. Eng. Manag.*, vol. 141, num. 9, 2015.
- [53] B.E. Mneymneh, M. Abbas, H. Khoury, Automated hardhat detection for construction safety applications, *Procedia Engineering*, vol. 196, pp. 895–902, 2017.
- [54] Q. Fang, H. Li, X. Luo, L. Ding, H. Luo, T.M. Rose, W. An : Detecting non

hardhat use by a deep learning method from far-field surveillance videos, *Autom. Constr.*, vol. 85, pp. 1-9, 2018.

- [55] J. Wu, N. Cai, W. Chen, H. Wang, G. Wang : Automatic detection of hardhats worn by construction personnel: a deep learning approach and benchmark dataset, *Autom. Constr.*, vol. 106, 2019.
- [56] B.E. Mneymneh, M. Abbas, H. Khoury : Vision-based framework for intelligent monitoring of hardhat wearing on construction sites, *J. Comput. Civ. Eng.*, vol. 33, num. 2, 2019.
- [57] D. Kim, M. Liu, S.H. Lee, V.R. Kamat : Remote proximity monitoring between mobile construction resources using camera-mounted UAVs, *Automation in Construction*, vol. 99, pp. 168–182, 2019.
- [58] H. Son, H. Seong, H. Choi, C. Kim : Real-time vision-based warning system for prevention of collisions between workers and heavy equipment, *J. Comput. Civ. Eng.*, vol. 33, num. 5, 2019.
- [59] J. Chen, Y. Fang, Y.K. Cho : Real-time 3D crane workspace update using a hybrid visualization approach, *J. Comput. Civ. Eng.*, vol. 31, num. 5, 2017.
- [60] H. Kim, K. Kim, H. Kim : Vision-based object-centric safety assessment using fuzzy inference: monitoring struck-by accidents with moving objects, *J. Comput. Civ. Eng.*, vol. 30, num. 4, 2016.
- [61] Z. Rong-hui, Z. Jia-Li, X. Zhou : A pedestrian detection method based on hierarchical tree Cascade classification at nighttime, *J. Highway Transp. Res. Dev.*, vol. 9, num. 2, pp. 77–83, 2015.
- [62] W. Fang, B. Zhong, N. Zhao, P.E.D. Love, H. Luo, J. Xue, S. Xu : A deep learning based approach for mitigating falls from height with computer vision: convolutional neural network, *Adv. Eng. Inform.*, vol. 39, pp. 170–177, 2019.

- [63] Q. Fang, H. Li, X. Luo, L. Ding, T.M. Rose, W. An, Y. Yu : A deep learning-based method for detecting non-certified work on construction sites, *Adv. Eng. Inform.*, vol. 35, pp. 56-68, 2018.
- [64] Y. Yu, H. Li, X. Yang, L. Kong, X. Luo, A.Y.L. Wong : An automatic and noninvasive physical fatigue assessment method for construction workers, *Autom. Constr.*, vol. 103, pp. 1–12, 2019.
- [65] H. Son, H. Choi, H. Seong, C. Kim : Detection of construction workers under varying poses and changing background in image sequences via very deep residual networks, *Autom. Constr.*, vol. 99, pp. 27–38, 2019.
- [66] Y. Yu, X. Yang, H. Li, X. Luo, H. Guo, Q. Fang : Joint-level vision-based ergonomic assessment tool for construction workers, *J. Constr. Eng. Manag.*, vol. 145, num. 5, 2019.
- [67] L. Ding, W. Fang, H. Luo, P.E.D. Love, B. Zhong, X. Ouyang : A deep hybrid learning model to detect unsafe behavior: integrating convolution neural networks and long short-term memory, *Autom. Constr.*, vol. 86, pp. 118–124, 2018.
- [68] H. Zhang, X. Yan, H. Li : Ergonomic posture recognition using 3D view-invariant features from single ordinary camera, *Autom. Constr.*, vol. 94, pp. 1–10, 2018.
- [69] J. Chen, J. Qiu, C. Ahn : Construction worker’s awkward posture recognition through supervised motion tensor decomposition, *Autom. Constr.*, vol. 77, pp. 67–81, 2017.
- [70] R. Wei, P.E.D. Love, W. Fang, H. Luo, S. Xu : Recognizing people’s identity in construction sites with computer vision: a spatial and temporal attention pooling network, *Adv. Eng. Inform.*, vol. 42, 2019.
- [71] X. Yan, H. Zhang, H. Li, Estimating worker-centric 3D spatial crowdedness for construction safety management using a single 2D camera, *J. Comput. Civ. Eng.* 33 (5) (2019), 04019030.
- [72] Z. Kolar, H. Chen, X. Luo : Transfer learning and deep convolutional neural

networks for safety guardrail detection in 2D images, *Autom. Constr.*, vol. 89, pp. 58–70, 2018.

- [73] J. Chen, J. Qiu, C. Ahn, Construction worker’s awkward posture recognition through supervised motion tensor decomposition, *Autom. Constr.*, vol. 77, pp. 67–81, 2017.
- [74] W. Fang, L. Ding, H. Luo, P.E.D. Love : Falls from heights: a computer vision-based approach for safety harness detection, *Autom. Constr.*, vol. 91, pp. 53–61, 2018.
- [75] Z. Zhu, M.-W. Park, C. Koch, M. Soltani, A. Hammad, K. Davari : Predicting movements of onsite workers and mobile equipment for enhancing construction site safety, *Autom. Constr.*, vol. 68 pp. 95–101, 2016.
- [76] Zhang, S., Abdel-Aty, M., Wu, Y., and Zheng, O. : Pedestrian crossing intention prediction at red-light using pose estimation. *IEEE transactions on intelligent transportation systems*, vol. 23, num. 3, pp. 2331-2339, 2021.
- [77] Ijjina, E. P., Chand, D., Gupta, S., and Goutham, K. : Computer vision-based accident detection in traffic surveillance. In 2019 10th International conference on computing, communication and networking technologies (ICCCNT), pp. 1-6, 2019.
- [78] C. Cortes and V. Vapnik : Support-Vector Networks, *Ma-chine learning*, vol. 20, no. 3, pp. 273-297, 1995.
- [79] G.-B. Huang, Q.-Y. Zhu and C.-K. Siew : Extreme Learning Machine: a new learning scheme of feedforward neural net-works, in *Proc. IEEE International Joint Con-ference on Neural Networks*, vol. 2, pp. 985-990, 2004.
- [80] D. T. Meva and C. K. Kumbharana : Comparative Study of Different Fusion Techniques in Multimodal Biometric Authentication, *International Journal of Computer Appli-cations*, vol. 66, no. 19, pp. 16-19, 2013.

- [81] C. G.M. Snoek, M. Worring and A. W.M. Smeulders : Early Versus Late Fusion in Semantic Video Analysis, in Proc. the 13th annual ACM International Conference on Multimedia, pp. 399–402, 2005.
- [82] P. K. Atrey, M. A. Hossain, A. El Saddik, and M. S. Kankanhalli : Multimodal fusion for multimedia analysis: a survey, *Multimedia systems*, vol. 16, no. 6, pp. 345–379, 2010.
- [83] T. Ogawa, K. Sugata, R. Togo and M. Haseyama : Multi-classifier Decision: Integration of Multiple Brain Activity-based Classifications, *ITE Transactions on Media Technology and Applications*, vol. 7, no. 1, pp. 36-44, 2019.
- [84] K. Maeda, T. Ogawa, and M. Haseyama : Automatic Martian Dust Storm Detection from Multiple Wavelength Data Based on Decision Level Fusion, *IPSJ Transactions on Computer Vision and Applications*, Information Processing Society of Japan, vol. 7, pp. 79-83, 2015.
- [85] N. Saito, T. Ogawa, S. Asamizu and M. Haseyama, “Tourism Category Classification on Image Sharing Services Through Estimation of Existence of Reliable Results, in Proc. ACM International Conference on Multimedia Retrieval (ICMR '18), pp. 493-496, 2018.
- [86] V. C. Raykar, S. Yu, L. H. Zhao, A. Jerebko, C. Florin, G. H. Valadez, L. Bogoni, and L. Moy : Supervised Learning from Multiple Experts: Whom to Trust When Everyone Lies A Bit, in Proc. 26th Annual International Conference on Machine Learning, pp. 889–896, 2009.
- [87] B. D. Lucas and T. Kanade : An Iterative Image Registration Technique with an Application to Stereo Vision, Proc. In the International Joint Conference on Artificial Intelligence, pp. 674-679, 1981.

- [88] J. Shi and C. Tomasi : Good Features to Track, in Proc. the IEEE Conference on Computer Vision and Pattern Recognition, pp. 593-600, 1994.
- [89] Yamasaki and T. Chen : Confidence-assisted Classification Result Refinement for Object Recognition Featuring TopN-Exemplar-SVM, in Proc. 21st International Conference on Pattern Recognition, pp. 1783-1786. 2012.
- [90] C.-W. Hsu, C.-C. Chang and C.-J. Lin : A Practical Guide to Support Vector Classification, Technical Report, Department of Computer Science, pp. 1-16, 2003.
- [91] Sakoe, H. and Chiba, S. : Dynamic programming algorithm optimization for spoken word recognition, IEEE transactions on acoustics, speech, and signal processing , Vol. 26, No. 1 , pp. 43-49, 1978.
- [92] Schölkopf, B., Platt, J. C., Shawe-Taylor, J., Smola, A. J. and Williamson, R. C. : Estimating the support of a highdimensional distribution, Technical Report MSR-TR99-87, Microsoft Research, 1999.
- [93] J. Redmon and A. Farhadi : YOLOv3: An Incremental Improvement, arXiv preprint arXiv:1804.02767, 2018.
- [94] 渡邊 はるな, 藤後 廉, 小川 貴弘, 長谷山 美紀 : 弱異常検知アルゴリズムに基づく CCTV 映像を用いた河川利用者の異常行動の検出に関する検討, 映像情報メディア学会技術報告, vol. 44, no. 6, pp, 367-370, 2020.
- [95] 八木雅大, 高橋翔, 萩原亨 : 異なる複数の特徴量を用いた自転車の回避行動の検出に関する検討, 令和元年度 電気・情報関係学会北海道支部連合大会, pp. 165-166, 2019.
- [96] S. Varadharajan, S. Jose, K. Sharma, L. Wander and C. Mertz : Vision for road inspection, in Proc. IEEE Winter Conference on Applications of Computer vision, pp. 115-122, 2014.



- [97] 宮崎文平, 加藤寛之, 小濱健吾, 貝戸清之, 風戸崇之, 田中克則 : 膨大な路面性状調査データに基づく舗装補修施策の評価法の提案, 土木学会論文集 F4 (建設マネジメント), vol. 71, no. 3, pp. 142-161, 2015.
- [98] 森田 健司, 今野 新, 関谷 浩孝, 蘆屋 秀幸 : CCTV 画像を点群データに重畳し画像内の対象物を計測する精度の理論と分析, 土木情報学シンポジウム講演集, Vol, 43, pp. 121-124, 2018.
- [99] M. Satyanarayanan : The emergence of edge computing, Computer, vol. 50, no. 1, pp. 30-39, 2017.
- [100] Z. M. Zha, F. Liu, and Z. P. Cai : Edge computing: Platforms; Applications and challenges, J. Comput. Res. Develop., vol. 55, no. 2, pp. 327-337, 2018.
- [101] Ahmad, Irfan and Pothuganti, Karunakar : Smart Field Monitoring using ToxTrac: A Cyber-Physical System Approach in Agriculture, 2020 International Conference on Smart Electronics and Communication (ICOSEC), pp. 723-727, 2020.
- [102] K. Cao, Y. Liu, G. Meng and Q. Sun : An Overview on Edge Computing Research, in IEEE Access, vol. 8, pp. 85714-85728, 2020.
- [103] K. Cao, S. Hu, Y. Shi, A. W. Colombo, S. Karnouskos and X. Li : A Survey on Edge and Edge-Cloud Computing Assisted Cyber-Physical Systems, in IEEE Transactions on Industrial Informatics, vol. 17, no. 11, pp. 7806-7819, 2021.
- [104] Son Hyojoo and Changwan Kim : Integrated worker detection and tracking for the safe operation of construction machinery, Automation in Construction, vol. 126, 2021.
- [105] Ci-Jyun Liang, Kurt M. Lundeen, Wes McGee, Carol C. Menassa, SangHyun Lee and Vineet R. Kamat : A vision-based marker-less pose estimation system

for articulated construction robots, *Automation in Construction*, vol. 104, pp. 80-94, 2019.

- [106] Wilson O. Quesada, Jonathan I. Rodriguez, Juan C. Murillo, Gustavo A. Cardona, David Yanguas-Rojas, Luis G. Jaimes and Juan M. Calderón : Leader-Follower Formation for UAV Robot Swarm Based on Fuzzy Logic Theory, *International Conference on Artificial Intelligence and Soft Computing*, pp. 740–751, 2018.
- [107] C.-C. Chang and C.-J. Lin. : LIBSVM : A Library for Support Vector Machines, *ACM Transactions on Intelligent Systems and Technology*, vol. 2, no. 3, article 27, pp. 1-27, 2011.
- [108] Judson P. Jones and Larry A. Palmer : An evaluation of the two-dimensional Gabor filter model of simple receptive fields in cat striate cortex, *Journal of Neurophysiology*, vol. 58, no. 6, 1987.
- [109] Michael A. A. Cox, and Trevor F. Cox : Multidimensional scaling, *Handbook of data visualization*, pp. 315-347, 2008.
- [110] Y. Nagata, T. Hagiwara, Y. Kaneda, K. Araki and K. Murakami : Simple Way to Use Closed-Circuit Television Road Images for Poor-Visibility Information, *Journal of the Transportation Research Board*, No.1980, pp.105-116, 2006.
- [111] T. Hagiwara, Y. Ota, Y. Kaneda, Y. Nagata and K. Araki : Method of Processing Closed-Circuit Television Digital Images for Poor Visibility Identification, *Journal of the Transportation Research Board*, No.1973, pp.95–104, 2006.
- [112] Y. Nagata, T. Hagiwara, Y. Kaneda, K. Araki, and H. Sasaki : Application of Road Visibility Information System (RVIS) to Winter Maintenance, *Journal of the Transportation Research Board*, No.2055, pp.128-138, 2008.

- [113] X. Shi, L. Fay, Z. Yang, T. Nguyen, and Y. Liu : Corrosion of deicers to metals in transportation infrastructure: Introduction and recent developments, Corrosion Review, vol. 27, no. 1-2, pp. 23–52, 2009.
- [114] N. Takahashi, K. Sato, R. Tokunaga, N. Nakajima, and S. Yamanaka : Evaluation of disodium succinate hexahydrate as an alternative deicer, Transportation Research Board, 2018.
- [115] Tomonori Ohiro, Kiyoshi Takakura, Takuya Sakuraba, Yasushi Hanatsuka, Toru Hagiwara : Development of Advanced Anti-icing Spray System using Automated Road Surface Condition Judgement System, Transportation Research Record, TRB 98th Annual Meeting, pp.1-15, 2019.
- [116] Yasushi Hanatsuka, Hiroshi Morinaga, Yasumichi Wakao : Discrimination of Road-Surface Condition by Intelligent Tire, JSSI & JSSE Joint Conference, No. B1-11, pp.24, 2010.
- [117] Shih-Chia Huang, Bo-Hao Chen, and Yi-Jui Cheng : An Efficient Visibility Enhancement Algorithm for Road Scenes Captured by Intelligent Transportation Systems, IEEE Transactions on Intelligent Transportation Systems, vol. 15, no. 5, pp. 2321–2332, 2014.
- [118] Andrew G. Howard, Menglong Zhu, Bo Chen, Dmitry Kalenichenko, Weijun Wang, Tobias Weyand, Marco Andreetto, Hartwig Adam : MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications, arXiv:1704.04861, 2017.
- [119] 齊藤 康司, 高橋 翔, 萩原 亨 : 低照度環境下における車両検出のための入力画像の明瞭化, AI・データサイエンス論文集, 4 巻 2 号 p. 163 169, 2023.
- [120] Zhang, Zhizhuo , et al : Estimating a 2D pose from a tiny person image with super resolution reconstruction, Computers & Electrical Engineering, 93, 2021.

- [121] R. Sato, M. Yagi, S. Takahashi, T. Hagiwara, Y. Nagata and K. Ohashi : An Estimation Method of Visibility Level Based on Multiple Models Using In-vehicle Camera Videos under Nighttime, 2021 IEEE 10th Global Conference on Consumer Electronics (GCCE), pp. 530-531, 2021.
- [122] A. B. Watson, DCTune: A technique for visual optimization of DCT quantization matrices for individual images, Sid International Symposium Digest of Technical Papers. Vol. 24. Society for information display, pp. 946–949, 1993.
- [123] M. Tan, and Q. Le : Efficientnet: Rethinking model scaling for convolutional neural networks, In International conference on machine learning. PMLR, 2019.
- [124] A. Krizhevsky, I. Sutskever, and G. E. Hinton : Imagenet classification with deep convolutional neural networks, in Proceeding Adv. Neural Inf. Process. Syst., 2012, pp. 1097–1105.
- [125] C. Hegde, P. B. Suresha, J. Zelko, Z. Jiang, R. Kamaleswaran, M. A. Reyna, and G. D. Clifford : Autotriage-an open source edge computing raspberry pi-based clinical screening system, medrxiv, 2020.
- [126] Z. Zhao, Z. Jiang, N. Ling, X. Shuai, and G. Xing : ECRT: An edge computing system for real-time image-based object tracking, in Proc. 16th ACM Conf. Embedded Netw. Sensor Syst., pp. 394–395, 2018.
- [127] D. S. Breland, S. B. Skriubakken, A. Dayal, A. Jha, P. K. Yalavarthy and L. R. Cenkeramaddi : Deep Learning-Based Sign Language Digits Recognition From Thermal Images With Edge Computing System, in IEEE Sensors Journal, vol. 21, no. 9, pp. 10445-10453, 2021.
- [128] Raghu, M., Gilmer, J., Yosinski, J., and Sohl-Dickstein, J.: SVCCA: Singular Vector Canonical Correlation Analysis for Deep Learning Dynamics and

- Interpretability, Conference on Neural Information Processing Systems, 2017
- [129] Wang, L., Hu, L., Gu, J., Wu, Y., Hu, Z., He, K., and Hopcroft, J.: Towards Understanding Learning Representation: To What Extent Do Different Neural Networks Learn the Same Representation, Conference on Neural Information Processing Systems, 2018.
- [130] Uenishi K., Yagi, M., Takahashi, S., and Hagiwara, T.: A Note on Discriminator Updating Method based on Weights of Other Models and its Verification, IEEE International Conference on Consumer Electronics – Taiwan, 2023. (Accepted for Publication)
- [131] Yagi, M., Takase, T., Takahashi, S., Hagiwara, T., Ohi-ro, T., Iwasaki, Y., Mori, T., and Hanatsuka, Y.: An Edge Computing System for Estimating Road Surface Condition on Winter Expressway, IEEE Global Conference on Consumer Electronics, 2021.
- [132] Takase, T., Takahashi, S., Hagiwara, T., Ohi-ro, T., Iwa-saki, Y., Mori, T., and Hanatsuka, Y.: An Estimation Method of Road Surface Condition on Winter Express-way via Mobile Nets using In-vehicle Camera Images, IEEE Global Conference on Consumer Electronics, 2021.
- [133] Chien-Yao Wang, Alexey Bochkovskiy, and Hong-Yuan Mark Liao: YOLOv7 Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors, IEEE/CVF Conference on Computer Vision and Pattern Recognition, pp.7464-7475, 2023.
- [134] McMahan, H. B., Moore, E., Ramage, D., Hampson, S., and Arcas, B. A. y.: Communication-Efficient Learning of Deep Networks from Decentralized Data, International Conference on Artificial Intelligence and Statistics, 2017.
- [135] 青島亘佐, 河村伸哉, 中野聡, 中村秀明: 深層学習による画像認識を用いた

コンクリート構造物の変状検出に関する研究. 土木学会論文集 E2 (材料・コンクリート構造), 74 巻, 4 号, pp. 293-305, 2018.

- [136] Calton, L. Wei, Z.: Using artificial neural network models to assess hurricane damage through transfer learning, Applied sciences, vol.12, no.3, pp.1466\_1–1466\_20, 2022.
- [137] 大関誠, 堀田修平, 與那覇誠, 山口浩平, 中村聖三: マルチタスク深層学習による橋梁の損傷程度評価モデルの検討, AI・データサイエンス論文集, vol.1, no.J1, pp.86–91, 2020.
- [138] 国土交通省 道路局 企画課 道路経済調査室, 国土交通省 国土技術政策総合研究所 道路研究室: CCTV カメラ(AI 解析)の精度に関する報告, 2021, <https://www.mlit.go.jp/road/ir/ir-council/ict/pdf05/02.pdf> (参照: 2024-02-17)
- [139] 木付拓磨, 早川健太郎: 4K 定点カメラ映像による工事進捗管理システムの開発および試行, 建設機械施工, vol.73, no. 7, pp. 38-42, 2021.

## 著者の研究業績

### 1. 論文(学位論文関係)

- 1) 八木雅大, 高橋翔, 萩原亨: 作業動作データのアライメントに基づく建設現場作業の主体および従属の関係性評価, 土木学会 AI・データサイエンス論文集, 4 巻, 3 号, pp. 611-618, 2023.
- 2) 植西康太, 八木雅大, 高橋翔, 萩原亨: 道路空間を観測するエッジ AI の類似度を用いた再学習のためのエッジ選択手法, 土木学会 AI・データサイエンス論文集, 4 巻, 3 号, pp. 619-628, 2023.
- 3) M. Yagi, S. Takahashi, T. Hagiwara: CYCLISTS' AVOIDANCE BEHAVIOR ON BICYCLE TRIPS DETECTION BASED ON MULTIMODAL APPROACH FOR ROAD MANAGEMENT, Journal of JSCE D3 (Infrastructure Planning and Management), vol. 76, no. 5, pp. I\_899-I\_907, 2021.
- 4) 八木雅大, 高橋翔, 萩原亨, 自転車の回避行動に関するデータ集積のためのエッジコンピューティングシステムの構築, 土木学会論文誌 D3(土木計画学), 査読あり, 76 巻, 5 号, pp. I\_859-I\_867, 2021.

### 2. 論文(その他)

- 1) 木下洋輝, 八木雅大, 高橋翔, 萩原亨: 車載カメラを用いた道路空間の画像解析に基づく堆雪による狭窄状況の識別に関する研究, 土木学会論文集 D3(土木計画学), 78 巻, 5 号, I\_119-I\_127, 2023.

### 3. 講演(学位論文関係)

- 1) Y. Nagata, T. Hagiwara, S. Takahashi, M. Yagi, G. Ooi : Developing Prototype of Digital Twin for Winter Road Maintenance, TRB Annual Meeting, Washington DC, January 2024. (Accepted for presentation)

- 2) 繁澤朗, 八木雅大, 高橋翔, 萩原亨: OpenPose を用いた道路映像における二輪車の識別に関する一考察, 第 68 回土木計画学研究発表会・秋大会, 東京都, 2023 年 11 月.
- 3) 高橋翔, 八木雅大, 萩原亨, 佐藤諒: 複数識別器の Late-fusion による夜間の視界レベル推定の Edge-computing に関する検討, 第35回日本道路会議, 東京都, 2023 年 11 月.
- 4) 繁澤朗, 八木雅大, 高橋翔, 萩原亨: OpenPose を用いた道路映像における二輪車の識別に関する検討, 令和 5 年度 電気・情報関係学会北海道支部連合大会, 北海道, 2023 年 10 月.
- 5) M. Yagi, R. Sato, S. Takahashi, T. Hagiwara: An In-vehicle Edge Computing System for Monitoring Nighttime Winter Road Visibility, Proc in the 2023 IEEE 10th Global Conference on Consumer Electronics (GCCE), Nara pref. October 2023.
- 6) 八木雅大, 高橋翔, 萩原亨: 運転者の姿勢や運動に関する特徴量に基づく自転車と自動二輪車の識別に関する検討, 映像情報メディア学会 2023 年年次大会, 東京都, 2023 年 8 月.
- 7) K. Uenishi, M. Yagi, S. Takahashi, T. Hagiwara: A Note on Discriminator updating Method based on Weights of Other Models and its Verification, Proc. In the IEEE 2023 International Conference on Consumer Electronics - Taiwan, Pingtung, July 2023.
- 8) S. Takahashi, M. Yagi, T. Hagiwara : An Edge-computing System for Observing Road Surface Condition and Visibility in Winter Road, Presentation at International Conference on Road Weather and Winter Maintenance, Washington DC, May 2023.
- 9) M. Yagi, S. Takahashi, T. Hagiwara: Improvement of Nighttime Visibility Estimation Based on Spatio-Temporal Correlation in Videos, International Workshop on Advanced Image Technology 2023 (IWAIT 2023), Jeju, January 2023.



- 10) 八木雅大, 高橋翔, 萩原亨, Jevica, 柳瀬ひろし, 須田清隆: OpenPose を用いた建設現場映像における作業員の運動性評価に関する検討, 映像情報メディア学会 2022 年冬季大会, 東京都, 2022 年 12 月.
- 11) 植西康太, 八木雅大, 高橋翔, 萩原亨: パラメータ置換による識別器更新とその効果に関する検討, 令和 4 年度 電気・情報関係学会北海道支部連合大会, オンライン開催, 2022 年 11 月.
- 12) 高橋翔, 八木雅大, 向井智洋, 萩原亨, 須田清隆, Jevica, 柳瀬ひろし: 中小建設業における映像解析 AI の導入に向けた検討と試行, 令和4年度土木学会全国大会第77回年次学術講演会, 京都府, 2022 年 9 月.
- 13) R. Sato, M. Yagi, S. Takahashi, T. Hagiwara, Y. Nagata and K. Ohashi: An Estimation Method of Visibility Level Based on Multiple Models Using In-vehicle Camera Videos under Nighttime, Proc. in the 2021 IEEE 10th Global Conference on Consumer Electronics (GCCE), Kyoto pref., October 2021.
- 14) M. Yagi, Tomoyuki Takase, S. Takahashi, T. Hagiwara, T. Ohiro, Y. Iwasaki, T. Mori, Y. Hanatsuka: An Edge Computing System for Estimating Road Surface Condition on Winter Expressway, Proc. In 2021 IEEE 10th Global Conference on Consumer Electronics (GCCE), Kyoto pref., October 2021.
- 15) 八木雅大, 高橋翔, 萩原亨: 道路管理を支援するデータ集積のための自転車の動きに基づくエッジコンピューティングシステムに関する研究, 映像情報メディア学会技術報告, vol. 44, no. 34, pp. 5-8, オンライン開催, 2020 年 12 月.
- 16) M. Yagi, S. Takahashi and T. Hagiwara: A Study on Avoidance Behavior on Bicycle Trips Detection Using Multiple Features for Improvement Road Management, Proc. In the IEEE 2020 International Conference on Consumer Electronics – Taiwan, Taoyuan, September 2020.
- 17) 八木雅大, 高橋翔, 萩原亨: 自転車の回避行動に関するデータ集積のためのエッジコンピューティングシステムの構築, 第 61 回土木計画学研究発表会・春大会, オンライン開催, 2020 年 6 月.

- 18) 八木雅大, 高橋翔, 萩原亨: OpenPose および複数識別器を用いた自転車の回避行動の検出に関する検討, 第 60 回土木計画学研究発表会・秋大会, 富山県, 2019 年 11 月.
- 19) 八木雅大, 高橋翔, 萩原亨: 異なる複数の特徴量を用いた自転車の回避行動の検出に関する検討, 令和元年度 電気・情報関係学会北海道支部連合大会, 北海道, 2019 年 11 月.
- 20) M. Yagi, S. Takahashi and T. Hagiwara: An Evaluation Method of Obstacle Avoidance Behavior on Bicycle Trip Using Rider's Gesture, Proc. In the IEEE 8th Global Conference on Consumer Electronics, Osaka pref., October 2019.
- 21) S. Takahashi, M. Yagi and T. Hagiwara: Data Accumulation System of Obstacle Avoidance Behavior on Bicycle Trip for Transportation Engineering, Proc. In the IEEE 8th Global Conference on Consumer Electronics, Osaka pref., October 2019.

#### 4. 講演(その他)

- 1) 福田英輝, 八木雅大, 高橋翔, 萩原亨: 低ランク近似に基づく離散データの更新を導入したテンソル補完による視界レベル推定に関する一考察, 第 68 回土木計画学研究発表会・秋大会, 東京都立, 2023 年 11 月.
- 2) 林亮佑, 八木雅大, 高橋翔, 萩原亨: GNSS データを用いた冬期道路環境における走行位置の観測, 第 68 回土木計画学研究発表会・秋大会, 東京都, 2023 年 11 月.
- 3) 笹枝悠人, 八木雅大, 高橋翔, 萩原亨: 車載システムによる視界評価の実装に向けた課題の検討, 令和 5 年度 電気・情報関係学会北海道支部連合大会, 北海道, 2023 年 10 月.
- 4) E. Fukuda, M. Yagi, S. Takahashi, T. Hagiwara: A Note on Visibility Level Estimation Based on Third-Order Tensor Completion Using CCTV Images and GPV Data, Proc. in the 2023 IEEE 10th Global Conference on Consumer Electronics (GCCE), Nara pref., October 2023.

- 5) R. Hayashi, M. Yagi, S. Takahashi, T. Hagiwara: An Observation Method of Vehicle Lateral Position Based on Map Matching in Winter Road Condition, Proc. in the 2023 IEEE 10th Global Conference on Consumer Electronics (GCCE), Nara pref., October 2023.
- 6) 福田英輝, 八木雅大, 高橋翔, 萩原亨: 低ランク近似を用いた既知データの更新と行列補完による視界推定手法の高度化に向けた検討, 令和 4 年度土木学会北海道支部年次技術研究発表会, 北海道, 2023 年 1 月.
- 7) 向井智洋, 八木雅大, 高橋翔, 萩原亨: AI による協調観測のためのカメラパラメータ探索における一考察, 第 66 回土木計画学研究発表会・秋大会, 沖縄県, 2022 年 11 月.
- 8) 林亮佑, 八木雅大, 高橋翔, 萩原亨: GNSS データのマッピングによる車両走行位置の変位の定量化, 令和 4 年度 電気・情報関係学会北海道支部連合大会, オンライン開催, 2022 年 11 月.
- 9) T. Mukai, T. Abe, M. Yagi, S. Takahashi and T. Hagiwara: An Estimation Method for Deploying Condition of Sensors in Cooperative Observation of Road Traffic, Proc. in the 2022 IEEE International Conference on Consumer Electronics - Taiwan, Taipei, July 2022.
- 10) H. Kinoshita, M. Yagi, S. Takahashi and T. Hagiwara: A Method for Classifying Road Narrowing Conditions Based on Features of Surrounding Vehicles and Piled Snow in In-vehicle Camera Videos, Proc. in the 2022 IEEE International Conference on Consumer Electronics - Taiwan, Taipei, July 2022.
- 11) 木下洋輝, 八木雅大, 高橋翔, 萩原亨: 車載カメラ映像を用いた道路空間の画像解析に基づく堆雪による狭窄状況の識別に関する研究, 第 65 回土木計画学研究発表会・春大会, 広島県, 2022 年 6 月.
- 12) 木下洋輝, 八木雅大, 高橋翔, 萩原亨: 車載カメラ映像における周辺車両および道路空間の特徴を用いた堆雪による道路の狭窄状況の分類に関する研究, 令和 3 年度 土木学会北海道支部年次技術研究発表会, オンライン開催, 2022 年 2 月.

- 13) 八木雅大, 高橋翔, 萩原亨: CCTV カメラ映像における夜間の吹雪による視界不良検知のための分析領域の決定手法, 第 63 回土木計画学研究発表会・春大会, オンライン開催, 2021 年6月.

## 5. 受賞

- 1) 2023 年 10 月, IEEE 12th Global Conference on Consumer Electronics, IEEE GCCE 2023 Excellent Student Demo! Award, Bronze Prize, 題目「An In-Vehicle Edge Computing System for Monitoring Nighttime Winter Road Visibility」
- 2) 2023 年 10 月, IEEE 12th Global Conference on Consumer Electronics, IEEE GCCE 2023 Excellent Student Paper Award, Gold Prize, 題目「An Observation Method of Vehicle Lateral Position Based on Map Matching in Winter Road Condition」
- 3) 2023 年 8 月, 一般社団法人映像情報メディア学会, 学生優秀発表賞, 題目「OpenPose を用いた建設現場映像における作業員の連動性評価に関する検討」
- 4) 2023 年 1 月, International Workshop on Advanced Image Technology 2023, Best Paper Award, 題目「Improvement of Nighttime Visibility Estimation Based on Spatio-Temporal Correlation in Videos」
- 5) 2019 年 11 月, 令和元年度電気・情報関係学会北海道支部連合大会, 若手優秀論文発表賞, 題目「異なる複数の特徴量を用いた自転車の回避行動の検出に関する検討」
- 6) 2019 年 10 月, 2019 IEEE 8th Global Conference on Consumer Electronics, IEEE GCCE 2019 Excellent Demo! Award, Gold Prize, 題目「Data Accumulation System of Obstacle Avoidance Behavior on Bicycle Trip for Transportation Engineering」
- 7) 2019 年 10 月, 2019 IEEE 8th Global Conference on Consumer Electronics, IEEE GCCE 2019 Excellent Poster Award, Bronze Prize, 題目「An Evaluation Method of Obstacle Avoidance Behavior on Bicycle Trip Using Rider's Gesture」