

高精度ダイナミックマップ作成のための点群位置合わせを 応用した動的物体検知・同定システムに関する検討

松尾 和哉^{1,a)} 高木 雅¹ 中田 亮太¹ 森 航哉¹

概要: ICT 端末の機能を有する自動車（コネクテッドカー）の分野において注目されているダイナミックマップでは、車両や歩行者の現在位置といった動的な物体に関する情報を、車載センサや道路インフラのセンサデータから取得する場合がある。このとき、各センサが観測した物体が同一か否かを判断できなければ、現実世界とダイナミックマップ上で動的物体の数が一致せず、動的物体に関する情報の精度が低下するという問題がある。複数のセンサデータから検知された物体が同一か否かを判断（同定）する既存研究は数多くあるが、画像から抽出した 2 次元特徴量を利活用した手法がほとんどであり、同じ物体でも観測した方向で外見が大きく異なる物体は、同定が困難である。一方、深度マップなどの 3 次元情報を用いた同定手法も存在するが、特定の物体しか同定できないため、多種多様な動的物体を登録する必要があるダイナミックマップへの適用は困難である。そこで本稿では、複数の点群データの位置合わせを行う手法と、一つの点群データから複数種類の物体を検知できる手法を組み合わせることで、複数種類の物体を同定するシステムを提案する。本システムでは、入力された各点群データに対して個別に物体検知を行うのではなく、まず観測領域が重複している点群データを、位置合わせを用いて一つの点群データに統合し、その点群データに対して物体検知を行う。これにより、複数のセンサから観測されている物体も、一つの物体として検知されるため、現実世界とダイナミックマップ上で動的物体の数が乖離することを防ぐ。さらに本稿では、実環境で取得した点群データを用いて、本システムの有効性を評価する。

1. はじめに

近年、自動車業界では CASE (Connected, Autonomous/Automated, Shared, Electric) をはじめとする技術革新に伴い、車の概念が大きく変わり始めている。その中でも自動車を他の車両や道路インフラ、クラウド等と接続する「Connected」と、他の車両と情報を共有する「Shared」は、運転手の安全運転支援の実現の観点から非常に注目されており、ダイナミックマップ [9] という形で各所で研究開発が進んでいる [12], [15], [16]。

ダイナミックマップとは、静的な（時間経過による更新頻度が低い）地図上に、動的な（時間変化による更新頻度が高い）情報を重畳し、道路交通に関する情報をリアルタイムに管理する仕組みのことである。ダイナミックマップ活用の一例として、運転手や車載センサの死角になる領域に存在する歩行者や他車両の位置などの動的な情報をダイナミックマップから取得することがあげられる。これにより、運転手や車両が認識できる領域が拡大するため、安全

運転支援の実現が期待できる [12]。

ダイナミックマップの作成に必要な動的な情報は、車載センサや道路インフラのセンサデータ（画像や点群など）を解析して取得することが想定されている [12], [15], [16]。一方、この方法でダイナミックマップを作成するためには、以下の三つの要件を満たすことが重要であると考える。

- (1) 検知した物体の種別と位置がわかること。これにより、検知した動的物体の情報をダイナミックマップ上に反映できる。
- (2) センサからの観測方向に寄らず、各センサが観測した物体が同一か否かを判断（同定）可能であること。これにより、現実世界とダイナミックマップ上で動的物体の情報の乖離を防ぐことができる。
- (3) 複数の種別の物体を同定可能であること。これにより、歩行者・車両・自転車など多種多様な動的物体をダイナミックマップ上に反映できる。

上記要件 2 に関して、複数のセンサデータから検知された物体を同定する既存研究は数多くあるが [6], [13], 1 種類の物体にしか対応しておらず、要件 3 を満足できない。一方、要件 3 に関して、複数種別の物体の同定を行う既存研究も近年進んでいるが [2], [4], [8], これらの手法は画像か

¹ 日本電信電話株式会社 デジタルツインコンピューティング研究センター 〒108-0023 東京都港区芝浦 3-4-1 グランパークタワー 33F.

^{a)} kazuya.matsuo.yv@hco.ntt.co.jp




図 1 提案システム概要

ら抽出した2次元特徴量を利活用した手法であるため、同じ物体でも観測した方向で外見が大きく異なる物体は、同定が困難である。すなわち要件2を満足することが困難である。また、上記いずれの既存研究も、検知・同定した物体の位置の取得は想定していない。

そこで本稿では、センサデータとして点群データに焦点を当て、複数の点群データの位置合わせを行う手法と、一つの点群データから複数種類の物体を検知できる手法を組み合わせることで、上記要件をすべて満足するシステムを提案する。本システムでは、入力された各点群データに対して個別に物体検知を行うのではなく、まず観測領域が重複している点群データを、位置合わせを用いて一つの点群データに統合し、その点群データに対して物体検知を行う(図1)。このとき、センサの位置から検知された物体に該当する点群までの距離を基の点群から取得することで、要件1を満足する。さらに、統合後の点群に対して物体検知を行うことで、複数のセンサから観測されている物体が一つの物体として検知されるため、要件2を満足できる。最後に、一つの点群データから複数種類の物体を検知できる手法を用いることで、検知モデル構築時に学習できた物体であれば、どんな種類の物体であっても同定できるようになるため、要件3を満足できる。

以下では、まず2章で関連研究について述べる。次に3章で本研究の想定について述べ、4章で提案システムについて述べる。5章で実験結果を示した後、最後に6章で本

稿のまとめと今後の課題について述べる。

2. 関連研究

2.1 人物同定、車両同定

1章で述べた通り、複数のセンサデータから検知された物体が同一か否かを判断(同定)する既存研究は数多く存在する[6], [13]。

文献[5], [7], [14]では、市中の画像データセットを教師データとし、同一人物の画像の2次元特徴量の類似度を学習することで、クエリ画像に写った物体(人あるいは車)と同一の物体である可能性が高い物体の一覧を、その確率と共に出力する。また、車両同定[6]では、画像だけではなく、車両の移動軌跡やナンバープレートも併用して同定を行っている。

文献[1], [3]では、点群データや深度マップを入力として、人物の同定を行っている。具体的には、人物の身体動作から、時間軸も含めた4次元の特徴を抽出し、これを基に人物の同定を行っている。

これらの研究では、物体の同定を実現しているという点で本研究と類似するが、1種類の物体しか同定できない。また、検知物体の位置の取得も想定していないため、要件1・3の点で本研究とは異なる。

2.2 複数種類の物体同定

文献[2], [4], [8]では、同定対象の物体の種類を限定せず、

複数種類の物体の同定が可能な手法を提案している。

文献 [4] では、従来の CNN ベースの手法では取得が困難だった画像内の 2 次元特徴量間の構造的なパターンと、生の画像から抽出できる 2 次元特徴量の情報を Transformer に学習させることで、複数種類の物体の同定を実現している。文献 [8] では、人物同定の手法と人物以外の物体の同定手法と物体追跡手法を組み合わせることで、複数種類の物体の同定を実現している。

これらの研究では、1 章で挙げた要件 3 に関して本研究と類似するが、入力として画像を想定しており、同一物体でも観測方向によって見た目が大きく異なる物体の同定は想定していない。また、検知物体の位置の取得も想定していないため、要件 1・2 の点で本研究とは異なる。

3. 想定

本章では、本研究における想定について説明する。

3.1 環境

本稿では、複数のコネクテッドカーと 1 台のセンタサーバが存在する環境を想定する。各コネクテッドカーは、センタサーバと通信するための通信装置、LiDAR スキャナをはじめとする点群センサ、および GPS をはじめとする位置情報を取得可能なセンサを具備している。またセンタサーバが構築したダイナミックマップを受信し、表示するためのアプリケーションがインストール済みであり、センサデータの取得時刻は各コネクテッドカー間で同期されているものとする。センタサーバは、コネクテッドカーから受信したセンサデータを解析し、ダイナミックマップを作成する機能、およびそれを各コネクテッドカーへ送信する機能を具備する。

3.2 ダイナミックマップ

ダイナミックマップは一般的に 3 次元の地図をベースとしたものを指すことがあるが、本研究では Google マップをはじめとする 2 次元地図上に動的情報を重畳したものを想定する。センタサーバは、コネクテッドカーから受信したセンサデータを解析し、動的物体の種類と位置情報を取得する。これらの情報を 2 次元地図上に重畳したものをダイナミックマップとし、各コネクテッドカーへ配信する。

4. 提案システム

本章では、提案システムの動作概要について説明し、その、後提案システムの詳細について説明する。

4.1 動作概要

提案システムは、まず受信した点群データを 4.2 項で述べる方法で位置合わせし、その誤差を 4.3 項で述べる方法で丸める。その後、4.4 項で述べる方法で鳥瞰画像化した




図 2 位置情報に基づく共通座標系変換における問題

データに対して、物体検知を行う。

4.2 点群データ位置合わせ

4.2.1 共通座標系への変換

各センサが取得した点群データにおける点群の座標は、それぞれのセンサ位置を原点とした互いに独立した座標系で表現されている。これらの点群データを統合するために、本システムでは各点群データの座標系を、平面直角座標系^{*1}へ変換する。

具体的には、当該センサの 2 次元位置座標 (x, y) から、平面直角座標系における座標 (X_g, Y_g) を算出する。その後、 z 軸を中心に方位角 θ の回転と、 XY 平面上で (X_g, Y_g) 方向への平行移動を行う剛体変換行列 M を作成し、当該センサが取得した点群データ内の各点群座標に掛ける。これによって、すべてのセンサが取得した点群データ内の全点群を行うことによって、すべての点群データを同一座標系で表現することができ、一つのデータとして統合できる。



しかし、このデータをそのまま物体検知に入力すると、現実の物体数と検知した物体数との間に乖離が発生する可能性がある。これは、位置情報センサの取得誤差により、各点群の位置が本来の位置からずれ、同一物体の点群が異なる位置に生じるためである (図 2)。

本稿では、共通座標系に存在する二つの点群 A, B において、点群 A におけるある物体の点群を含む最小の直方体の中心と、点群 B における当該物体の点群を含む最小の直方体の中心との間の距離を「異なる点群間の誤差」と表現する。この点群間の誤差を 0 にすることによって上述の問題は解決できるが、それは非現実的である。一方で、異なる点群間の誤差が推定できるものであれば、その誤差を丸めることでこの問題を解決できる。提案システムでは、これを実現するために、4.2.2 項と 4.3 項で述べる処理を行う。

4.2.2 レジストレーション

位置情報センサの取得誤差による異なる点群間の誤差は、センサの計測誤差に加え、センサと衛星間との通信状況や

^{*1} <https://www.gsi.go.jp/LAW/heimencho.html>



(c) 当該空間内の点群 A に属する点を削除

図 3 点群間の誤差丸め

センサが配置されている環境 (周囲に高い建物があるなど) の影響を強く受けるため, その大きさを事前に推定することは非常に困難である. そこでまず提案システムでは, 位置情報センサの取得誤差による影響を排除するために, 前述の処理を施した各点群に対してレジストレーション処理を行う. 本システムでは, 粗密の激しい点群データに対するレジストレーションの処理速度および精度の観点*2から, レジストレーションに Normal Distributions Transform Distribution-to-Distribution (NDT-D2D) 法 [11] を採用する.

NDT-D2D 法におけるレジストレーション手順の概要は以下のとおりである.

- (1) 入力された点群 A, B をそれぞれ $d[m]$ の格子状に分割
- (2) 各格子内の点群の位置の正規分布を計算

- (3) 点群 B を座標変換
- (4) 点群 A, B 間の各格子内の点群の正規分布同士の距離 (L^2 距離) を計算
- (5) 上記距離が減少する座標変換用の剛体変換行列を, ニュートン法を用いて推定
- (6) 指定回数に達する, あるいは前回からの上記距離の変化量が閾値以下になるまで手順 3, 4, 5 を繰り返す.

上記処理の結果によって発生する点群間の誤差は, 位置情報センサの取得誤差由来のものとは異なり, レジストレーションの精度によるもののみであるため, 統計的に推定可能であるものと考えられる.

4.3 点群間の誤差丸め

レジストレーションの結果によって発生する点群間の誤差の最大値を $e[m]$ とし, この閾値を用いて異なる点群間

*2 準備実験にて比較検証を実施

の誤差を丸める。本システムでは、この閾値以上ずれた点群を検出するために、PCLのOctreeを用いた異なる点群間の差分検出^{*3}を応用する。

Octreeによる差分検出を用いた点群間の誤差丸め処理の手順の概要は以下のとおりである。

- (1) 入力された点群 A, B の両方が存在する空間を八等分する。
- (2) 点が存在する八分空間のみをさらに八等分する。
- (3) 1辺が $e[m]$ 以下の八分空間が現れるまで手順2を繰り返す(図3(a))。
- (4) 点群 A, B の両方の点が存在する八分空間を探索する(図3(b))。
- (5) 当該八分空間内に存在する点群 A に属する点を削除する(図3(c))。

4.4 鳥瞰画像化および物体検知

前項までの処理が施された点群を統合し、その中から物体を検知することで、物体の種別の特定とその同定を同時に行う。点群から物体を検知する方式として、教師データ作成の容易さの観点から、本システムではComplex-yolo[10]をベースとした方式を用いた。この方式は、鳥瞰画像化した点群を既存の物体検知方式であるYOLO^{*4}に入力して物体検知を行うものである。そのため、教師データを作成する際に、3次元点群の中から対象の物体を探してアノテーションする必要はなく、画像認識の場合と同じ方法で教師データを作成できる。

前項までの処理が施された点群から物体を検知するまでの手順は以下のとおりである。

- (1) 点群 A, B 内の各点をその XY 座標を基に、1辺を $0.1[m]$ とみなした画素にプロットして、鳥瞰画像を作成する。
 - (2) 作成した鳥瞰画像を、同様の方法で作成した教師データで訓練した物体検知モデルに入力し、検知された物体の種別と画像内での位置を取得する。
 - (3) コネクテッドカーの位置情報と、検知した物体の画像内の位置から、検知した物体の位置情報を推定する。
- 以上の処理により、下記すべての要件を満たすことができる。
- (1) 検知した物体の種別と位置がわかること。
 - (2) センサからの観測方向に寄らず、各センサが観測した物体が同一か否かを判断(同定)可能であること。
 - (3) 複数の種別の物体を同定可能であること。

5. 性能評価

本章では、提案システムの有効性を確認するために行っ

た実験の設定、および結果を示す。本実験では、センサデータから人物と車両および検知して静的地図上に重畳するシナリオを想定した。また、本システムは、メモリ: 32GB, CPU: Intel(R) Xeon(R) Silver 4110 2.10GHz(8コア 16スレッド), GPU: NVIDIA Quadro P6000, OS: Ubuntu 16.04.6 LTS の性能を持つ計算機上で動作させた。

5.1 実験設定

GPS^{*5}とLiDAR^{*6}を搭載した車両を用いて、図4に示す5通りの車両と人物の配置パターン点群データと位置情報を各パターン f 個取得し、これらのデータを入力として提案システムの有効性を確認した。

実験時の提案システムの各パラメータ d, e について、レジストレーションに用いるNDT-D2Dの格子の1辺 $d[m]$ は、GPS座標を基に算出できるコネクテッドカー間の距離が $5[m]$ 以下の場合 $d = 2, 5[m]$ を超える場合は $d = 3$ となるように設定した。この値は、本実験で使用しなかった点群データをNDT-D2Dに入力する準備実験を行い、最も点群間の誤差が小さくなった値を採用している。また、この d の値は、コネクテッドカー間の距離から動的に設定できるように実装している。点群間の誤差の想定最大値は、 $e = 0.4[m]$ と設定した。この値は、上記パラメータが設定されたNDT-D2Dに対して、本実験で使用しなかった点群データをレジストレーションした後の点群間の誤差を計測する準備実験を行い、この実験結果から統計的に設定したものである。

実験時の評価指標は、下記の3つである。

- 同定率: 「現実の対象物体数と検知した物体数が等しくなったデータ数」を「現実の対象物体数以上の物体が検知された※データ数」で割った値。※対象物体として誤検知された物体はカウントしない。例えば、取得した15個のデータにおいて“人”が2人存在しており、本システムによって2人以上の人が検知されたデータが10個、2人のみが検知されたデータがそのうちの6個だった場合、同定率は0.6となる。
- 検知率: 「現実の対象物体数以上の物体が検知された※データ数」を「取得した全データ数」で割った値。上記例では、検知率は約0.67となる。
- 処理時間: 点群が本システムに入力されてから、物体検知が終了するまでに要した時間。

5.1.1 物体検知モデルの構築

4.4節で述べた物体検知モデルを構築するために、5.1節で述べたLiDARを搭載した車両を用いて、吉祥寺駅周辺で点群データを取得した。このデータの中から、人と車が多く観測されている点群データを313個選出し、人と車に対

^{*3} https://pointclouds.org/documentation/octree_-_pointcloud_-_changedetector_8h_source.html

^{*4} <https://pjreddie.com/darknet/yolo/>

^{*5} <https://www.furuno.com/jp/products/gnss-module/PT-G1>

^{*6} <https://velodynelidar.com/products/ultra-puck/>



図 4 実験時のコネクテッドカーと同定対象の配置パターン

	教師データ	validation データ
人	1079	336
車	784	268

表 1 教師データ数および Validation データ数

してアノテーションを行って教師データを作成した(表 1)。また、モデルによる推論結果として出力された bounding box のうち、信頼度が 0.1 以上のものを検知物体とした。

5.2 評価結果

5.2.1 対面：人 × 2

図 5 の結果より、同定率が 1 になっていることがわかる。これは提案システムによって、4.2.2 項と 4.3 項で述べた処理によって、位置情報に誤差がある環境下でも、対象の物体が検知さえできていれば、現実の物体数と検知した物体数との間に発生する乖離が抑制できたためである。一方、検知率が 0.8 未満程度にとどまっていることがわかる。

また、図 5(b) の結果より、すべての処理が約 1.2[s] 要していることがわかる。つまり、本システムを用いてダイナミックマップを構築・更新する場合、1 秒に 1 回未満の更新しかできないことを示している。一方で、鳥瞰画像化に要する時間が、処理時間の支配項になっていることがわかる。本処理は並列処理化が可能な処理である一方で、今回の実装ではシングルスレッドで実装しているため、この処理を並列処理化するだけで、処理時間は改善される可能性が高い。また、点群に対して物体検知できる手法を適用することによってでも、全体の処理時間が短くなる可能性もある。

以降、他の配置パターンにおける処理時間の結果は、本結果と同様であるため、本稿からは省略する。

5.2.2 直角：人 × 2

図 6 の結果より、同定率が 1 になっていることがわかる。これは前項と同じ理由である。一方で、検知率が 0.2 程度となっており、ほぼ物体の検知ができていないことがわかる。これは、4.2.2 項で述べた処理の失敗によって、人の点群が周囲の建物の点群に飲み込まれてしまい、鳥瞰画像から当該点群が識別できなかったためである。

レジストレーションが失敗する原因として、LiDAR で

取得した点群データと NDT の相性が考えられる。LiDAR で取得した点群データは疎密が激しいため、点群の取得位置によっては、近い位置で取得された点群であっても NDT で計算する点群の分布特性が大きく変わってしまい、点群分布間のマッチングに失敗してしまう可能性がある。

5.2.3 直角・並列：車 × 1

図 7, 8 の結果より、検知率・同定率ともに 1 になっていることがわかる。これは 5.2.1 項で述べた理由と同じである。


5.2.4 直角：人 × 1 ・ 車 × 1

図 9 の結果より、同定率が 1 になっていないことがわかる。これは、4.2.2 項の処理結果が、システムの想定最大誤差以内に収まらず、4.3 項で述べた処理で点群間の誤差を丸めきれなかったためである。つまり、4.2.1 項で述べた問題が発生したためである。

6. おわりに

本稿では、高精度ダイナミックマップ作成のための点群位置合わせを応用した動的物体検知・同定システムを提案した。

提案システムでは、センサデータとして点群データに焦点を当て、複数の点群データの位置合わせを行う手法と、一つの点群データから複数種類の物体を検知できる手法を組み合わせて、上記要件をすべて満足するシステムを提案する。本システムでは、入力された各点群データに対して個別に物体検知を行うのではなく、まず観測領域が重複している点群データを、位置合わせを用いて一つの点群データに統合し、その点群データに対して物体検知を行う。このとき、センサの位置から検知された物体に該当する点群までの距離を基の点群から取得することで、検知した物体の位置を推定できる。さらに、統合後の点群に対して物体検知を行うことで、複数のセンサから観測されている物体が一つの物体として検知されるため、物体を同定できる。最後に、一つの点群データから複数種類の物体を検知できる手法を用いることで、検知モデル構築時に学習できた物体であれば、どんな種類の物体であっても同定できるようになるため、複数の物体種別に対応できる。



(a) 検知率・同定率 (対面：人×2)

(b) 処理時間内訳 (対面：人×2)

図 5 評価結果 (対面：人×2)




図 6 検知率・同定率 (直角：人×2)




図 8 検知率・同定率 (並列：車×1)




図 7 検知率・同定率 (直角：車×1)




図 9 検知率・同定率 (直角：人×1・車×1)

提案システムを、実環境で取得した点群データを用いて評価し、点群の位置合わせが精度高くできた場合、かつ鳥瞰画像化した点群に対して物体が検知できた場合、複数種

別の動的物体に対して同定ができることを確認した。

6.1 今後の課題

5.2 節で示した通り、提案システムにおいて、常に物体が正しく同定できたわけではない。その原因は以下の通りである。

- 5.1.1 項で述べた物体検知モデルによって、対象の物体が検知できていない。
- 4.2.2 項で述べたレジストレーションに失敗し、対象の物体に該当する点群が複数発生している、あるいは対象の物体の点群が他の物体の点群に飲み込まれてしまい、そもそも検知ができていない。

本システムにおいて同定率をさらに向上させるためには、物体検知精度の向上と、レジストレーション精度の向上が必要である。前者は、教師データのさらなる拡充により対応可能である。後者への対応方法は二通り考えられる。まず一つ目は、点の疎密が激しい点群データに対応したレジストレーションアルゴリズムの考案である。二つ目は、今回用いた LiDAR より密な点群データが取得可能な点群センサ*7の使用である。今後は、検知モデルの再学習を進めつつ、密な点群データが取得可能な点群センサを用いた検証を行う予定である。

参考文献

- [1] Cheng, Y. and Liu, Y.: Person Reidentification Based on Automotive Radar Point Clouds, *IEEE Transactions on Geoscience and Remote Sensing* (2021).
- [2] Ge, Y., Zhu, F., Chen, D., Zhao, R. and Li, H.: Self-paced contrastive learning with hybrid memory for domain adaptive object re-id, *arXiv preprint arXiv:2006.02713* (2020).
- [3] Haque, A., Alahi, A. and Fei-Fei, L.: Recurrent attention models for depth-based person identification, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 1229–1238 (2016).
- [4] He, S., Luo, H., Wang, P., Wang, F., Li, H. and Jiang, W.: Transreid: Transformer-based object re-identification, *arXiv preprint arXiv:2102.04378* (2021).
- [5] Hsu, H.-M., Huang, T.-W., Wang, G., Cai, J., Lei, Z. and Hwang, J.-N.: Multi-Camera Tracking of Vehicles based on Deep Features Re-ID and Trajectory-Based Camera Link Models., *CVPR Workshops*, pp. 416–424 (2019).
- [6] Khan, S. D. and Ullah, H.: A survey of advances in vision-based vehicle re-identification, *Computer Vision and Image Understanding*, Vol. 182, pp. 50–63 (2019).
- [7] Li, J., Wang, J., Tian, Q., Gao, W. and Zhang, S.: Global-local temporal representations for video person re-identification, *Proceedings of the IEEE/CVF International Conference on Computer Vision*, pp. 3958–3967 (2019).
- [8] Qiu, T., Chen, G., Qi, Z., Li, B., Shan, Y. and Xue, X.: A Generic Object Re-identification System for Short Videos, *arXiv preprint arXiv:2102.05275* (2021).
- [9] Reznik, A., Arora, R., Cannon, M., Cominardi, L., Featherstone, W., Frazao, R., Giust, F., Kekki, S., Li, A., Sabella, D., Turyagyenda, C. and Zheng, Z.: Developing Software for Multi-Access Edge Computing, *ETSI EN 302 895*, pp. 1–15 (2017).
- [10] Simony, M., Milzy, S., Amendey, K. and Gross, H.-M.: Complex-yolo: An euler-region-proposal for real-time 3d object detection on point clouds, *Proceedings of the European Conference on Computer Vision (ECCV) Workshops*, pp. 1–11 (2018).
- [11] Stoyanov, T., Magnusson, M., Andreasson, H. and Lilienthal, A. J.: Fast and accurate scan registration through minimization of the distance between compact 3D NDT representations, *The International Journal of Robotics Research*, Vol. 31, No. 12, pp. 1377–1393 (2012).
- [12] Watanabe, Y., Sato, K. and Takada, H.: DynamicMap 2.0: A Traffic Data Management Platform Leveraging Clouds, Edges and Embedded Systems, *International Journal of Intelligent Transportation Systems Research*, Vol. 18, No. 1, pp. 77–89 (2020).
- [13] Ye, M., Shen, J., Lin, G., Xiang, T., Shao, L. and Hoi, S. C.: Deep learning for person re-identification: A survey and outlook, *IEEE Transactions on Pattern Analysis and Machine Intelligence* (2021).
- [14] Zhu, Z., Jiang, X., Zheng, F., Guo, X., Huang, F., Sun, X. and Zheng, W.: Aware Loss with Angular Regularization for Person Re-Identification, *Proceedings of the AAAI Conference on Artificial Intelligence*, Vol. 34, No. 07, pp. 13114–13121 (2020).
- [15] 佐藤健哉: 次世代ダイナミックマップ DM2.0 (協調型自動運転に向けた情報通信プラットフォーム)(_i 特集_i MaaSにより目指す社会とそれを支える次世代モビリティ技術_i 電子情報通信学会合同企画_i), 日本機械学会誌, Vol. 124, No. 1228, pp. 24–26 (2021).
- [16] 渡辺陽介, 高田広章: 運転支援・自動運転のための高精度デジタルマップ, 日本ロボット学会誌, Vol. 33, No. 10, pp. 754–759 (2015).

*7 <https://www.robosense.ai/en/RS-LiDAR-M1>