

走行時動画像を用いた周辺車両の位置推定手法

石崎 雅大¹ 廣森 聡仁¹ 山口 弘純¹ 東野 輝夫¹

概要：都市環境における車や人の流れを表すモビリティデータは、交通渋滞の原因究明、イベントや災害時における効率的な人の誘導、公共施設や商業施設の立地決定招致テナントの最適化、耐災害に向けた避難指示立案など、多方面における利活用が期待されている。現状、車に関するモビリティデータは、多数の協力車両から、車両がある時刻に走行した位置を含む GPS トレースデータを得ることにより把握され、渋滞の検知や曜日時間毎の交通量予測など、道路の混み具合の推定が為されている。しかしながら、このモビリティデータの粒度は必ずしも細かいものではなく、車両間の関係や車両と歩行者の関係など、詳細なモビリティの把握は困難である。本論文では、データ提供に協力する車両の位置や速度だけでなく、車載カメラにより撮影された動画像を用いて、車両の周辺に存在する車両の検知ならびに走行情報を推定することにより、周辺の交通状況を把握する手法を提案する。この手法では、まず、既存の DNN による画像解析を行うことで他車両の存在を検知し、検知した車両に対して、自車との距離、相対速度、走行車線、進行方向といった詳細な情報を推定する。自車と他車の距離を推定する際、大きさが既知である路面表示を基準とし、画像内の距離を推定し、これに基づき、画像内で検知した車両までの距離を画像内の距離と対応づけることで、車両間の相対距離を推定する。実際の車両に搭載された車載カメラにより動画像を撮影し、提案手法により他車両の検出ならびにそれらとの距離を推定した結果、最小誤差 4.72%、最大誤差 18.7%、平均絶対誤差 11.7%の精度で推定できることが確認できた。

1. はじめに

近年、都市環境における車両や人の流れといったモビリティデータの利用法の一つとして、渋滞や事故などの交通情報データを利用した安全運転支援が検討されており、文献 [1] では、収集された混雑状況や事故件数から安全な経路を導出するアルゴリズムを提案されている。また、交通渋滞の解消や、イベント及び災害における効率的な交通流制御、公共施設や商業施設の建設に際しての立地選定の最適化、耐災害に向けた避難指示立案など、様々な方面において、モビリティデータ利活用が期待されている。しかしながら、既存のプロブカーや道路インフラにより得られる交通量データは、必ずしも時間的及び空間的に密なものではなく、また、GPS から得られるおおよその位置や速度の情報を利用するため、レーンレベルでの車両位置を把握することは困難であり、周辺の車両との相対距離や速度といった詳細な交通状況を把握するためにデータとしては十分ではない。一方、クラウドソーシングの枠組みを活用し、協力者のスマートフォンや車内センサを用いて、大量の

GPS トレースデータを収集する取組も実施されているが、センサデータ収集に伴うバッテリー消費やプライバシー保護の問題があり、多数の協力者を確保することは容易でない。一方、我々の研究グループでは、GPS トレースデータだけでなく、各車両レベルで車載カメラで撮影された動画像から、リアルタイムに周辺交通状況を推定し、かつ複数車両で推定されたデータを集約することにより、高精度かつ大規模なモビリティデータを構築する取組を実施している。この枠組においては、可能な限り、個々の車載デバイス側で撮影された動画像に対する意味理解を実施し、残りの解析処理をより資源に余裕のあるクラウドサーバーが実施するエッジ・クラウド協調型の動的ストリーム学習環境を構築することにより、比較的少数の協力者からでもできるだけ多くの情報を収集することを実現している。

本研究では、この枠組において、車載カメラで撮影された動画像に基づき、周辺車両を把握するとともに、それらの位置関係を導出する周辺状況把握手法を提案する。まず、個々の車両に搭載された車載カメラにより撮影された動画像に対し、自車両周辺の車両、人、バイクなど、周辺を移動する物体を検知し、それらの物体と自車両との位置関係ならびに走行車線などの情報を推定する。撮影された二次元画像を一点透視図とみなし、消失点との比を利用すると

¹ 大阪大学 大学院情報科学研究科
Graduate School of Information Science & Technology, Osaka University,
1-5 Yamadaoka, Suita, Osaka 565-0871, Japan

ともに、大きさが既知である路面表示を検出し、その物体までの距離を基準とすることで、画面内での距離と、実空間の距離の対応関係を導出し、それを用いて他車両への距離を推定する。提案手法により、車載カメラ動画像から他車までの距離を推定した結果、推定距離誤差最小 4.72%、最大 18.7%、平均絶対誤差 11.7% で推定できることが示された。また、検出した車線と他車との位置関係を俯瞰図として可視化するプログラムを実装し、周辺車両の把握ができていていることを示している。

2. 関連研究

2.1 交通流把握

各都市圏の交通量を計測する都市交通実態調査 [2] は概ね 10 年に 1 回行われているが、道路計画や公共交通計画など、総合的な都市交通を検討するための基礎資料として活用されるものであり、限られた都市における長期的な交通量の変動の把握に留まっている。一方、日々の交通流を把握するために、交差点や道路上に通行する車両を検知することが可能なセンサを設置し、交通量の計測や旅行時間の把握や推定する取組が行われている。文献 [3,4] においては、道路上に設置した車両を検知するループ検出器において計測される流量に基づき、旅行時間を推定する取組が実施されている。また、文献 [5] においては、複数の ETC における車両通過履歴に基づき、高速道路上の各セグメント単位の交通量を推定する手法を提案しており、中国における 69 の高速道路路線に対して評価を実施し、高い精度で交通量を推定できることを示している。これらの固定型のセンサを活用することにより、交通状況をリアルタイムに把握することができるが、広範囲の交通流を把握するためには、多数のセンサを設置する必要がある。

一方、GPS や速度計など、様々なセンサと通信可能な車載機を搭載した車両により、走行データを計測及び集約するプローブカーシステムは、広範囲に渡るデータを継続的かつ低コストで収集することができる [6]。この特徴を活かした取り組みとして、道路網が密な都市部を対象とし、広域の交通状況を把握する研究が数多く実施されている。文献 [7] では、毎分送信される都市内のタクシーの位置情報に基づき、都市レベルでの交通量を推定する手法が提案されている。Liu ら [8] は、中国のある都市において収集された約 15,000 台のタクシープローブデータを分析することにより、タクシーの稼働状況や交通渋滞情報などを利用者に提示するシステムを開発している。文献 [9] でも同様の取り組みが行われており、中国の瀋陽市において約 10,000 台のタクシープローブデータから交通状況をリアルタイムに収集し、ウェブサイトを通じて、利用者に現在の交通状況を提示するシステムが開発されている。提案手法(これはどれを指している?...)は、ニューラルネットワークとパターンマッチングのアルゴリズムを応用した

手法で、30 分後の平均速度を 90% の精度で推定できることを示している。Bo ら [10] は、北京市内を走行するタクシープローブカーデータの旅行時間を分析し、空車状態のタクシーのリンク旅行時間と、乗客をのせているタクシーのリンク旅行時間の傾向は異なり、空車状態のタクシーのリンク旅行時間が実際のリンク旅行時間を正確に表していることを明らかにしている。さらに、Yokota ら [11] は、北阪神エリアを走行する約 300 台のトラックから得られたプローブデータを分析することで、自動車の利用頻度に応じて、エリア内の道路網を二種類に分類し、それぞれの道路網における平均速度の違いやサービス水準の違いについて明らかにしている。また、収集された大量のプローブカーデータに基づき、旅行時間やモビリティを予測する研究も実施されている。文献 [12] においては、過去のプローブカーデータから抽出した走行時間及び路面状況などに基づき、確率的なモデルを構築し、個々の車両の行き先を予測する手法を提案している。文献 [13] においては、蓄積された過去のプローブカーデータから、データマイニング手法を活用することで、交通量の変化パターンを発見し、それらに基づき、リアルタイムに旅行時間を予測する手法を提案している。文献 [1] では、収集したプローブカーデータに基づき、景観、安全性、単純性、所要時間の四つの指標に基づき、ユーザの需要に応じた経路選択を実現する手法を提案している。広範囲の道路上の車両状況を収集するために、クラウドソーシングの枠組みを活用し、車両に搭乗している協力者のスマートフォンから GPS データを収集することで、カバレッジを広げる取り組み [14,15] が実施されているが、プライバシーの問題や、スマートフォンにおけるデータ収集及び送信処理に少なからず電力を消費するため、広範囲に渡り、協力者を集めることは容易ではない。

2.2 周辺状況把握

一方、車両に設置したセンサやカメラを用いて、走行中の自車両及び周辺の状況を推定する研究も実施されている。文献 [16] では、GPS が正確に動作しない際、加速度センサを用いることで車速を推定する手法を提案しており、車両の右左折や停止、路面の凹凸などによって生じる誤認識をフィルタリングすることで、高い精度で車速を推定できることを示している。文献 [17] では、屋内の駐車場において車両の位置を推定する手法を提案している。この手法では、スマートフォンセンサを利用して、車両が移動した軌跡を把握し、事前に学習した駐車場の形状を比較することで、GPS が機能しない屋内における位置推定を実現している。文献 [18] では、車両の IMU から得られる加速度データと、車内に設置したスマートフォンのセンサデータおよびカメラ映像を組み合わせることで、ステアリングホイールの角度、運転速度、加速度、道路状況など、様々な情報

を推定する手法を提案している。

また、無線通信技術やレーザ測域センサ (LiDAR) を利用し、周辺車両を把握する手法も多数提案されている。文献 [19] では、GPS と慣性センサの他に、LiDAR やカメラを用いることで、走行している車線の位置を正確に把握する手法を提案している。文献 [20] では、車載に搭載した LiDAR により取得された三次元点群から、自動車、歩行者、自転車、背景をリアルタイムに分類する車両周辺認識手法を提案している。この手法では、Real AdaBoost アルゴリズムに基づくオブジェクト分類器を生成することによって、車両の周囲 50m 以内に存在する物体に対して、90% 以上の精度での分類を実現している。また、文献 [21] では、三次元点群から生成した密度深度マップを利用し、周辺に存在する車両を検出する手法を提案している。文献 [22] は、ミリ波レーダとドライブレコーダーによるデータを統合した車両の周辺状況検出手法を提案している。文献 [23] では、一般に車々間通信に用いられる狭域通信方式 Dedicated Short Range Communication (DSRC) [24] を携帯端末に搭載することで、人と車両の間での大容量高速通信を可能にし、お互いの相対位置を把握することで、事故を防ぐ手法を提案している。

同様に、車両の周辺の状況を把握するために、走行時に撮影した動画を解析する研究も実施されている。文献 [25] では、人特有の動きのパターンを特徴として、歩行者の動きを検出する手法を提案している。一方、文献 [26] では、人の形状の特徴量をウェブレット解析により抽出し、Support Vector Machine (SVM) を用いて歩行者を検出する手法を提案している。さらに、近年では、Convolutional Neural Network (CNN) などの深層学習を用い、画像からの物体抽出について盛んに研究が行われている。物体が存在する領域を抽出し、CNN による分類を行うことで、高速に物体検出を行う R-CNN [27]、その領域抽出手法を改善することで、検出精度を向上させている Faster R-CNN [28]、さらに、Faster R-CNN をもとに、物体抽出後、ピクセル単位でセグメンテーションを行う Mask R-CNN [29] など、画像処理により、高精度に物体検出及び認識を実現する手法が提案されている。Yolo [30] らは、撮影した画像に対し、物体抽出と分類を同時に行うことで検出速度の向上を実現する手法を提案している。これらの深層学習を用いた画像認識技術を車両周辺の把握に活用する研究も行われており、R-CNN を基にした走行時動画像に基づき、人物検出 [31]、車両検出 [32]、車線検出 [33] を実現する手法が提案されている。また、文献 [34] では、自動運転車への活用を想定し、電力消費量と検出速度を考慮した CNN ベースの物体検出手法が提案されている。このように、深層学習技術を活用することにより、撮影した動画像から高い精度で、人や車の存在など、車両周辺の情報を把握できると期待されるが、それらの認識のために、大容量の動画像の取

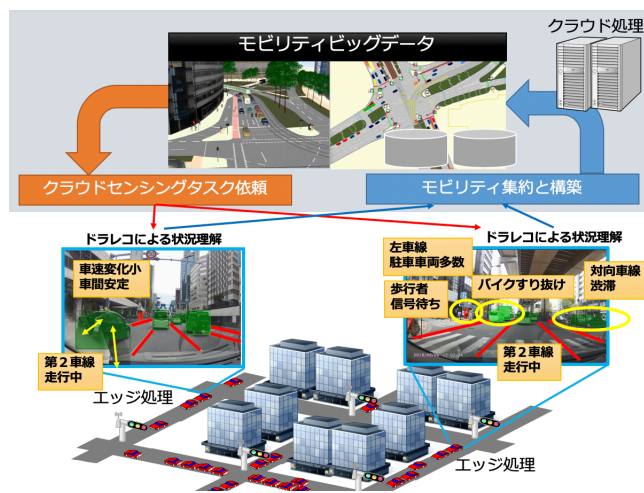


図 1 システム概要

得だけでなく、それらをクラウドに送信することは、ネットワークトラフィックやプライバシーの観点から望ましくない。

本取組においては、車載カメラにより撮影された動画像に対し、同様に車両に搭載されたエッジデバイス上において、ある程度の状況認識処理を実施し、より複雑な状況認識処理をより資源に余裕のあるクラウドサーバーが実施する、エッジ・クラウド協調型の動的ストリーム学習環境の構築を目的とする。また、既存の走行時動画像を用いた画像処理に基づく物体抽出手法では、カメラの仰角や俯角、カメラ位置から動画像の下端までの距離を予め測定する必要があり、車両の違いやカメラの設置方法に対し、柔軟に対応できる方法ではない。クラウドセンシングの枠組みにおいては、協力するユーザの負担はなるべく抑えることが望まれるため、上記に挙げているような、カメラの設置状況を自動的に取得できることが望ましい。

3. モビリティ構築システムに向けた取り組み

本取組は、各車両に搭載された車載カメラによって記録された連続的な動画像を、同じく車両に搭載されたエッジデバイスによって解析することで、その車両の周辺のモビリティを把握するとともに、クラウドソーシングの枠組みを活用し、それぞれの車両において解析されたデータを集約するシステムの構築を目的としている (図 1)。各車両において、車載カメラによって撮影された動画像を解析することにより、自車の周辺に存在する車両やバイク、歩行者などを検出し、自車との相対距離や相対速度、また車両に関して走行車線や駐車位置の把握を行うことで、自車周辺の交通状況を把握する。車両などの物体検出には Mask R-CNN [29,35] といった最新の深層学習ベースの物体認識技術を利用し、動画像上で検出された車両や人といった物体を把握し、また、三次元空間上における移動方向、車両間相対距離、角度を計算し、物体との位置関係を把握する。

また、車載デバイス上で可能な限りこれらに関わる解析処理を実施し、解析されたデータのみをクラウド上のシステムに送信することで、動画像を直接送信する場合と比較し送信されるデータ量を削減する。このように、複数の車両から様々な地点や交通状況でのモビリティデータを収集することにより、クラウド上のシステムで現実世界を再現するモビリティビッグデータの構築を行い、都市レベルでのモビリティを構築する。

4. 周辺車両位置推定手法

3章において示したエッジ・クラウド協調型のモビリティビッグデータ構築システムを構成する要素のうち、車載カメラで撮影された動画像に基づき、周辺の交通状況を把握する手法について説明する。まず、入力として与えられた車載カメラの動画像に対する画像処理により、周辺の車両を検出し、これらの車両に対して、相対距離と走行車線を推定することで、自車周辺の交通状況を把握する。動画像に基づき、自車と周辺の車両間の距離を推定するために、大きさが規定されている路面標示を検出し、この大きさに基づき、画像内の距離と実空間での距離の対応を算出し、検出した車両との相対距離を推定する。

4.1 画像解析による物体検出

まず、車載カメラで撮影された動画像から車両と路面標示を検出する手続きについて説明する。この検出において利用する Mask R-CNN では、物体が存在している可能性の高い領域を推定する領域分割 (Region Proposal) を実施し、この領域分割を行った部分のみに対して物体を検出することにより、検出速度を向上させている。Convolutional Neural Network (CNN) を用いて特徴量抽出を行い、検出された物体を分類した結果、認識した物体が画像上で占める領域は、図 2 に示すような、矩形のバウンディングボックスとして得られる。また、Mask R-CNN による車両検出においては、Microsoft が提供している学習済みモデル [36] を利用し、路面標示の検出には、Google ストリートビューから取得した路面標示を含む画像で学習したモデルを利用している。その後、OpenCV [37] に実装されている Hough 変換を利用し、画像内における線分を検出することで、消失点を検出する。この処理においては、まず、得られた画像に対し二値化処理及びグレースケール処理を実施し、確率的 Hough 変換にかけることで画像内の直線を検出する。さらに、直線毎の交点を求め、交点の最も集中しかつ中心に近い領域を消失点が存在する領域の候補とする。同様に、同様の線分検出に基づき、自車両の走行車線を検出している。具体的には、推定した消失点よりも下部の線分について、消失点を通りかつ角度が比較的垂直に近いものを車線境界線の候補として選出し、それらの直線のうち、最も画像の中心に近く、かつ線分が集中している




図 2 Mask R-CNN による車両検出の例




図 3 消失点及び自車線の推定

部分を生線の境界として推定する。また、自車両の走行車線以外の車線は、画面下部の車線幅が等しいと仮定し車線境界線の下部と消失点を結ぶことで描画する (図 3)。

4.2 周辺車両の位置推定

4.2.1 カメラが水平である場合の位置推定

4.1 節で述べた Mask R-CNN による車両検出と、消失点検出が実施された動画像に対し、自車両と他車両の相対距離を推定する手法について説明する (図 4)。検出した車両のバウンディングボックスの下端を、路面上におけるその物体の後部の座標とし、一点透視図となる画面内における消失点と検出物体のバウンディングボックスの下端との間の長さ、画面の下端と検出した車両のバウンディングボックスの下端の間の長さをそれぞれ y_1 , y_2 とする。このとき、図 4 の側面図に示すように、仮想的に画面の下端を路面上の位置を合わせて配置すると、相似比 $y_1 : y_2$ の三角形を描くことができる。これにより、路面上での車両の下端から画面までの距離 x_1 と画面から自車両のカメラまでの距離 x_2 の比は $y_1 : y_2$ となる。そのため、画面の最下端に写る路面と自車両との距離 $x_{base}(=x_1)$ から、式 1 により、車両との距離 d を求めることができる。

$$d = \left(1 + \frac{y_2}{y_1}\right)x_{base} \quad (1)$$

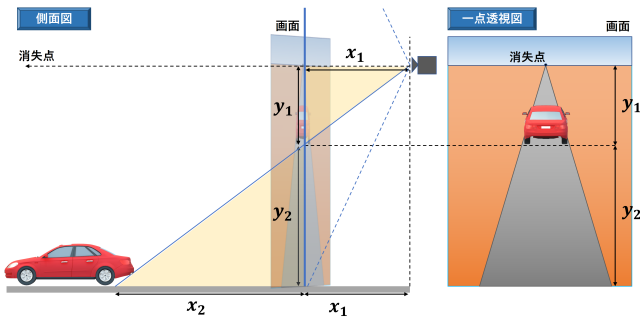


図 4 他車両との距離推定




図 5 寸法に規定されている路面標示の例 [38, 39]

4.2.2 カメラが水平である場合の路面標示に基づく距離推定

前節で提案した自車と他車の相対距離を推定する手法では、車載カメラの動画像における下端に写る路面とカメラ設置場所の水平距離 x_1 に基づき、距離を推定している。この距離は、車載カメラの垂直画角のうち、レンズ向以下の角度を α 、車載カメラの設置高を h とするとき、式 (2) によって算出できる。

$$x_1 = \frac{h}{\tan \alpha} \quad (2)$$

走行時動画像から寸法に規定がある路面標示 (図 5) を検出し、動画像上での実距離を推定する手法について述べる。動画像内からの路面標示検出には、前述の通り Mask R-CNN を利用する。図 7 に、検出した路面標示から画像内の実距離を推定する手法の模式図を示す。一点透視図となる画面内における消失点と図 6 のように検出された路面標示のバウンディングボックスの上端との間の長さ、バウンディングボックスの上端と下端の間の長さをそれぞれ y_1 、 y_2 とする。このとき前章と同様に側面図において仮想的に画面を配置すると、相似比 $y_1 : y_2$ の三角形を描くことができる。これにより、路面上での路面標示の下端から画面までの距離 x'_1 と路面標示の上端と下端の距離 x'_2 の比は $y_1 : y_2$ となる。よって、路面標示の上端と下端の距離 x'_2 とすると式 3 により、路面標示と自車両との距離 x'_1 を求めることができる。

4.2.3 カメラが水平である場合の位置推定

また、式 1 により、画面の最下端に移る路面と自車両との距離 x_1 を逆算することもできる。

$$x'_1 = \frac{y_1}{y_2} x'_2 \quad (3)$$

また、カメラの取り付け角度 (以下、俯角) が水平とならない場合の距離推定について、図 8 に基づいて説明する。図 4 と同様に一点透視図となる画面内における消失点と画面の中央部分 (レンズ高) との間の長さ、消失点と検出物体のバウンディングボックスの下端との間の長さをそれぞれ y_1 、 y_2 とする。このとき、前章と同様に側面図において仮想的に画面を配置し考える。図の赤色と黄色の三角形



図 6 路面標示検出例




図 7 距離の指標からの実距離推定

に注目すると先ほどの y_1 、 y_2 と俯角 θ 、検出物体の下端に対する角度 α との間に式 4 のような関係が成り立つ。

$$\tan \theta : \tan \alpha = y_1 : y_2 \quad (4)$$

これにより、角度 α は式 5 によって求められる。

$$\alpha = \arctan \left(\frac{y_2}{y_1} \tan \theta \right) \quad (5)$$

また、図の青色の三角形に注目すると、求めたい物体との距離 X は式 6 によって表される。

$$X = \frac{h}{\tan(\alpha + \theta)} \quad (6)$$

4.2.4 カメラが水平でない場合の路面標示によるカメラ設置高推定

前節で提案した自車と他車の相対距離を推定する手法では、カメラの傾いた角度 (俯角) θ 、車載カメラの設置高を h を既知のパラメータとして与えていた。しかし、この手




図 8 カメラが水平でない場合の距離推定

法を利用する場合、車両ごとにカメラの取り付け角度や設置高の測定を行う必要があるという課題が存在する。そこで、節 4.2.2 同様に走行時動画像から寸法に規定がある路面標示 (図 5) を検出し、動画像上での設置高を推定する手法について述べる。

図 9 に、検出した路面標示からカメラ設置高を推定する手法の模式図を示す。一点透視図となる画面内における消失点と画面の中央部分 (レンズ向) との間の長さ、消失点と図 6 のように検出された路面標示のバウンディングボックスの上端との間の長さをそれぞれ y_1 、 y_2 とする。この時式 5 と同様にカメラから検出物体の上端に対する角度 α を求められる。また、カメラから検出物体の下端に対する角度 β も同様に求められる。また、式 6 を用いることでバウンディングボックスの上端、下端までの距離を求めることができることから、その差に対して次の関係が成り立つ。ここで x_0 は検出した路面表示の寸法とする。

$$x_0 = \frac{h}{\tan(\alpha + \theta)} - \frac{h}{\tan(\beta + \theta)} \quad (7)$$

よって、カメラ設置高 h は式 8 のように求めることができる。

$$h = \frac{x_0}{\frac{1}{\tan(\alpha + \theta)} - \frac{1}{\tan(\beta + \theta)}} \quad (8)$$




図 9 距離の指標からのカメラ設置高推定

4.3 俯瞰図による可視化

提案手法によって推定された周辺車両の状況は、実際の画像上にマッピングした例を図 10 に示す。出力として俯瞰図を作成し、この段階で車両ごとの走行車線の特定を行った。車両ごとにそれぞれ後方部分の画像上の横幅の座標を取得しその横幅がある車線内に収まるものであればその車線上に車両があるものとしてマッピングした。また車線外の車両や複数車線をまたぐ車両が検出された場合は、Mask R-CNN による誤検出とみなしそれらを除外している。




図 10 俯瞰図の例

5. 評価実験

まず、提案手法により推定された距離について評価実験を実施した。提案する手法では、Mask R-CNN を用いて車載カメラ動画像から車両を検出し、その画像上の座標より相対距離を推定している。大学構内の道路において、車載カメラ (Yupiteru Corporation 製 DRY-WiFiV5d [40]) を搭載した車両と、その前方に別の車両を配置し、車両間の距離を 5m から 25m まで、5m ずつ変化させ、車載カメラにより、5つの画像を撮影した。このとき、距離推定には画面の最下端に移る路面と自車両との距離 x_{base} を導出する必要がある。提案手法ではこれを推定する方法を 4.2 節で述べているが、まず x_{base} を実験環境で実際に測定した値 (すなわち真値) とした場合の距離誤差を、対象車両との距離ごとに導出し、その精度を確かめる。なお、 x_{base} の真値は 3.3m であった。

図 11 に x_{base} の真値を用いた場合の、対象車両までの実際の距離に対する距離誤差を示す。 ($\pm 0m$ のもの) まず、実距離が 25m の場合には Mask R-CNN により車両が検出できなかった。車両の車高や画像に映り込む角度などで画像上における車両の大きさは変化するが、本手法において検出可能な距離は 25m 未満であるとして測定した。同図に示すように、推定誤差は距離 10m の場合が最小となった。距離 5m では、正の誤差、すなわち自車両から遠い方向への誤差が発生している。これは車載カメラの歪みが影響しているものと考えられる。今回用いた車載カメラには




図 11 推定距離誤差

広角レンズが使われているため、画像中央から遠い部分ほど歪みが強くなる。本来の正しい位置に映るべき車両がより小さく映っていることから、中央付近では収縮し、画面端付近では拡大されるような歪みが生じていると想定される。

一方、10m を超えると推定誤差は負に転じる。これらの距離においては、1ピクセルがより長い距離に対応するようになるため、Mask R-CNN のマスクサイズが実際の車両よりも大きくなりがちであることによる影響が、上述の歪みの影響を上回っていると想定される。あわせて、 x_{base} の誤差が推定に与える影響を同じ図において示す。図では、 x_{base} の誤差を $-0.6m$ から $+0.6m$ まで $0.3m$ 刻みで測定した値も示している。これらの結果から、 x_{base} が $+0.6m$ の場合が平均絶対誤差が最小となった。これは、距離が長い場合に負の距離誤差が出やすいため、 x_{base} に正の誤差がある場合、誤差を相殺する効果があるためと考えられる。

最後に提案手法において推定した x_{base} の誤差を図 12 に示す。横軸は x_{base} を推定する際に用いた路面標示までの実距離を示している。 x_{base} の誤差は距離推定における誤差と同じ傾向を示しており、路面標示までの距離が大きくなるほど、負の誤差が発生する。この結果および、図 11 における誤差の傾向を加味すれば、 x_{base} の推定はなるべく路面標示に近い状況で行うことで正の誤差が強くなり、結果として大きい距離の推定時に発生する強い負の誤差を打ち消す効果が期待できる。これは x_{base} を推定する際の有効な指標になると考えられる。

6. おわりに

本論文では、車載カメラで撮影された走行時動画像から、他の車両を検出し、それらの走行情報を推定する手法を提案した。提案手法では、動画像に対して Mask R-CNN を適用することにより他の物体を検出し、その後、Hough 変換より検出された線分の交点から消失点を推定することにより、検出した物体と消失点との画像上の位置関係から、自車両と各物体の相対距離を推定する。また、大きさが基地である路面標示を検出し、画像上での距離を把握することにより、相対位置の推定を行うために事前知識として必




図 12 路面表示による x_{base} 推定結果 (m 表示)

要となる情報の削減を達成した。評価実験においては、提案手法により、車載カメラ動画像から他車までの距離を推定した結果、推定距離誤差最小 4.72%、最大 18.7%、平均絶対誤差 11.7% で推定できることを示した。

今後の課題として、性能が限られている車載 GPU により、リアルタイムに周辺状況を把握できるように、推定処理全体の効率化が挙げられる。また、車両から収集したモビリティデータをクラウド上統合し、リアルタイムアクセス可能なシミュレーション環境を構築したいと考えている。

謝辞

本研究成果は国立研究開発法人情報通信研究機構 (NICT) の平成 30 年度日米共同公募委託研究「スマートコミュニティを支える高信頼ネットワーク構成技術の研究開発」により得られたものです。

参考文献

- [1] Johnson, I., Henderson, J., Schöning, J. and Hecht, B.: Beautiful...but at What Cost?: An Examination of Externalities in Geographic Vehicle Routing *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, Vol. 1,2, No. 15, pp. 2474–9567 (2017).
- [2] 国土交通省 都市交通調査・都市計画調査 http://www.mlit.go.jp/toshi/tosiko/toshi_tosiko_tk_000027.html (2008-). [Online; accessed 16-February-2019].
- [3] Petty, K., Bickel, P., Ostland, M., Rice, J., Schoenberg, F., Jiang, J. and Ritov, Y.: Accurate estimation of travel times from single-loop detectors, *Transportation Research Part A: Policy and Practice*, Vol. 32, pp. 1–17 (1998).
- [4] Kwon, J., Coifman, B. and Bickel, P.: Day-to-Day Travel Time Trends and Travel Time Prediction from Loop Detector Data, *Transportation Research Record*, Vol. 1717, pp. 120–129 (2001).
- [5] Yang, Y., Zhang, F. and Zhang, D.: SharedEdge: GPS-Free Fine-Grained Travel Time Estimation in State-Level Highway Systems, *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, Vol. 2,1, No. 48, pp. 1–26 (2018).

- [6] de Fabritiis, C., Ragona, R. and Valenti, G.: Traffic Estimation And Prediction Based On Real Time Floating Car Data, *Proceedings of the 11th International IEEE Conference on Intelligent Transportation Systems (ITSC 2008)*, pp. 197–203 (2008).
- [7] Aslam, J., Lim, S., Pan, X. and Rus, D.: City-Scale Traffic Estimation from a Roving Sensor Network, *Proceedings of the 10th ACM Conference on Embedded Network Sensor Systems (SenSys 2012)* (2012).
- [8] Liu, S., Pu, J., Luo, Q., Qu, H., Ni, L. M. and Krishnan, R.: VAIT: A Visual Analytics System for Metropolitan Transportation, *IEEE Transactions on Intelligent Transportation Systems*, Vol. 14, No. 4, pp. 1586–1596 (2013).
- [9] Wang, W. and Mizuta, H.: Probe car based traffic information system experiment in shenyang, *Proceedings of 8th International Conference on ITS Telecommunications*, pp. 334–336 (2008).
- [10] Liu, B., Liu, K. and Mizuta, H.: Study on impact of taxi status to probe car system performance, *Proceedings of 9th International Conference on ITS Telecommunications*, pp. 136–137 (2009).
- [11] Yokota, T. and Tamagawa, D.: Constructing Two-Layered Freight Traffic Network Model from Truck Probe Data, *International Journal of Intelligent Transportation Systems Research*, Vol. 9, No. 1, pp. 1–11 (2011).
- [12] Li, M., Ahmed, A. and Smola, A. J.: Inferring Movement Trajectories from GPS Snippets, *Proceedings of the 8th ACM International Conference on Web Search and Data Mining (WSDM 2015)*, pp. 325–334 (2015).
- [13] Lee, W.-H., Tseng, S.-S. and Tsai, S.-H.: A Knowledge Based Real-time Travel Time Prediction System for Urban Network, *Expert Systems with Applications*, Vol. 36, No. 3, pp. 4239–4247 (2009).
- [14] Hu, H., Li, G., Bao, Z., Cui, Y. and Feng, J.: Crowdsourcing-Based Real-Time Urban Traffic Speed Estimation: From Trends to Speeds, *Proceeding of the 32nd IEEE International Conference on Data Engineering (ICDE 2016)*, pp. 883–894 (2016).
- [15] Zhou, P., Jiang, S. and Li, M.: Urban Traffic Monitoring with the Help of Bus Riders, *Proceedings of the 35th IEEE International Conference on Distributed Computing Systems (ICDCS 2015)*, pp. 21–30 (2015).
- [16] Yu, J., Zhu, H., Han, H., Chen, Y. J., Yang, J., Zhu, Y., Chen, Z., Xue, G. and Li, M.: SenSpeed: Sensing Driving Conditions to Estimate Vehicle Speed in Urban Environments, *IEEE Transactions on Mobile Computing*, Vol. 15, No. 1, pp. 202–216 (2016).
- [17] Cherian, J., Luo, J. and Ho, S.-S.: ParkLoc: Lightweight Graph-based Vehicular Localization in Parking Garages, *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, Vol. 2,33, No. 99, pp. 1–23 (2018).
- [18] Liu, L., Li, H., Liu, J., Karatas, C., Wang, Y., Gruteser, M., Chen, Y. and Martin, R. P.: BigRoad: Scaling Road Data Acquisition for Dependable Self-Driving, *Proceedings of the 15th ACM Annual International Conference on Mobile Systems, Applications, and Services (MobiSys 2017)*, pp. 371–384 (2017).
- [19] Rose, C., Britt, J., Allen, J. and Bevly, D.: An Integrated Vehicle Navigation System Utilizing Lane-Detection and Lateral Position Estimation Systems in Difficult Environments for GPS, *IEEE Transactions on Intelligent Transportation Systems*, Vol. 15, No. 6, pp. 2615–2629 (2014).
- [20] Yoshioka, M., Suganuma, N., Yoneda, K. and Aldibaja, M.: Real-time object classification for autonomous vehicle using LIDAR, *Proceedings of the 2017 International Conference on Intelligent Informatics and Biomedical Sciences (ICIIBMS 2017)*, pp. 210–211 (2017).
- [21] Asvadi, A., Garrote, L., Premebida, C., Peixoto, P. and Nunes, U. J.: DepthCN: Vehicle detection using 3D-LIDAR and ConvNet, *Proceedings of the 20th International Conference on Intelligent Transportation Systems (ITSC 2017)*, pp. 1–6 (2017).
- [22] Burtle, J. and Dalla Fontana, M.: Robust and efficient multi-object detection and tracking for vehicle perception systems using radar and camera sensor fusion, *Proceedings of the IET and ITS Conference on Road Transport Information and Control (RTIC 2012)*, pp. 1–6 (2012).
- [23] Xinzhou Wu, Radovan Miucic, Sichao Yang, Samir Al-Stouhi, James Misener, Sue Bai and Wai-hoi Chan: Cars Talk to Phones: A DSRC Based Vehicle-Pedestrian Safety System, *Proceedings of 2014 IEEE 80th Vehicular Technology Conference (VTC2014-Fall)*, pp. 1–7 (2014).
- [24] Kenney, J. B.: Dedicated Short-Range Communications (DSRC) Standards in the United States, *Proceedings of the IEEE*, Vol. 99, No. 7, pp. 1162–1182 (2011).
- [25] Whler, C., Anlauf, J. K., Prtner, T. and Franke, U.: A Time Delay Neural Network Algorithm for Real-Time Pedestrian Recognition, *Proceeding of the International Conference on Intelligent Vehicle*, pp. 247–251 (1998).
- [26] Papageorgiou, C., Evgeniou, T. and Poggio, T.: A Trainable Pedestrian Detection System, *Proceedings of Intelligent Vehicles*, pp. 241–246 (1998).
- [27] Girshick, R. B., Donahue, J., Darrell, T. and Malik, J.: Rich feature hierarchies for accurate object detection and semantic segmentation (2013).
- [28] Ren, S., He, K., Girshick, R. and Sun, J.: Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks, *Advances in Neural Information Processing Systems 28* (Cortes, C., Lawrence, N. D., Lee, D. D., Sugiyama, M. and Garnett, R., eds.), Curran Associates, Inc., pp. 91–99 (2015).
- [29] He, K., Gkioxari, G., Dollr, P. and Girshick, R.: Mask R-CNN, *2017 IEEE International Conference on Computer Vision (ICCV)*, pp. 2980–2988 (2017).
- [30] Redmon, J. and Farhadi, A.: YOLOv3: An Incremental Improvement, *arXiv* (2018).
- [31] Li, J., Liang, X., Shen, S., Xu, T., Feng, J. and Yan, S.: Scale-Aware Fast R-CNN for Pedestrian Detection, *IEEE Transactions on Multimedia*, Vol. 20, No. 4, pp. 985–996 (2018).
- [32] Fan, Q., Brown, L. and Smith, J.: A closer look at Faster R-CNN for vehicle detection, *proceedings of 2016 IEEE Intelligent Vehicles Symposium (IV)*, pp. 124–129 (2016).
- [33] Nugraha, B. T. and and, S. S.: Towards self-driving car using convolutional neural network and road lane detector, *2017 2nd International Conference on Automation, Cognitive Science, Optics, Micro Electro-Mechanical System, and Information Technology (ICA-COMIT)*, pp. 65–69 (2017).
- [34] Wu, B., Iandola, F., Jin, P. H. and Keutzer, K.: SqueezeDet: Unified, Small, Low Power Fully Convolutional Neural Networks for Real-Time Object Detection for Autonomous Driving, *Proceeding of The IEEE Conference on Computer Vision and Pattern Recognition*

- (CVPR) Workshops, pp. 446–454 (2017).
- [35] Abdulla, W.: Mask R-CNN for object detection and instance segmentation on Keras and TensorFlow, https://github.com/matterport/Mask_RCNN (2017).
 - [36] Lin, T.-Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., Dollár, P. and Zitnick, C. L.: Microsoft coco: Common objects in context, *European conference on computer vision*, Springer, pp. 740–755 (2014).
 - [37] Bradski, G.: The OpenCV Library, *Dr. Dobb's Journal of Software Tools* (2000).
 - [38] 国土交通省 国土技術政策総合研究所§附属書 1(参考) 道路標識, 区画線及び道路標示一覧 <http://www.nilim.go.jp/lab/bcg/siryou/tnn/tnn0848pdf/ks084812.pdf> (2013-). [Online; accessed 12-February-2019].
 - [39] 株式会社キクテック§規制標示路面標示のいろいろ .
 - [40] Yupiteru Corporation: ドライブレコーダー DRY-WiFiV5d”https://www.yupiteru.co.jp/products/drive_recorder/dry-wifiv5d/” (2013-). [Online; accessed 12-February-2019].