

車両の進路情報を条件としたcGANによる走路推定

○右島 琢也 †, 久徳 遙矢 ‡, 出口 大輔 †, 川西 康友 †, 井手 一郎 †, 村瀬 洋 †

○ Takuya MIGISHIMA † Haruya KYUTOKU ‡ Daisuke DEGUCHI †
Yasutomo KAWANISHI † Ichiro IDE † and Hiroshi MURASE †

†: 名古屋大学, migishimat@murase.is.i.nagoya-u.ac.jp

‡: 豊田工業大学

＜要約＞ 近年、自動運転に関する研究開発が活発になされており、限定された環境下ではあるものの公道での走行実験等も進められている。しかし、交差点は事故の危険性が高く、交差点を含む一般道を状況に応じて安全に走行するための課題は多い。このような背景から、車載カメラを用いて詳細に周囲環境を認識し、周囲の状況を考慮して安全に走行できる道路上の領域（走路）を推定する技術が求められている。そこで本発表では、車載カメラ画像と、目的地までの経路から得られる車両の進路情報を条件（Condition）とした、conditional GANの枠組みを利用して走行すべき走路を推定する手法を提案する。実走行データから構築したデータセットを用いた評価実験により、画像のみを入力とする比較手法に比べて、提案手法では走路推定精度が15.0%向上することを確認した。
＜キーワード＞ ITS, GAN, 走路

1 はじめに

交通事故発生件数は年々減少し続けているものの、依然として多くの交通事故が発生しており、多数の死者を出している [1]。道路形状別死亡事故発生件数では全体の過半数が交差点周辺で発生していることから、特に交差点周辺における事故防止技術が求められている。

近年では事故防止のため、各製造者が自動車に様々な先進運転支援技術（ADAS: Advanced Driver-Assistance Systems）を搭載し始めている。ADASとは、車載カメラなど様々な外界センサを自動車に搭載することで自車周囲の環境を認識し、運転者に対する様々な運転支援を行なう技術である。

また、交通弱者対策や交通事故対策の一つとして、自動運転技術が期待されている。しかし、現在実用化が進みつつある自動運転技術の多くは、高速道路上でのみ動作するように設計されており、一般道での安全な自動運転は依然として困難である。これは、一般道の周囲環境には、歩行者、自転車などの様々な交通参加者が含まれ、高速道路に比べて非常に多様性が高いためである。また、交通事故の危険性が高い交差点では、より多くの交通参加者を正確に認識する必要がある。し

たがって車両を安全に自動走行させるためには、車両の周囲環境を詳細に認識し、歩行者や他車両などの交通参加者の状況をつぶさに把握しつつ、安全に走行できる道路上の領域（以下、走路）を正確に把握する必要がある。

現在走路決定のために多く採用されている手法は、事前に作成した高精細な3次元地図上で複数の走路を作成した後、車載カメラ画像やLiDARを用いて検出した歩行者などの移動物体を地図上にマッピングし、走行すべき走路を選択するものである。これらの手法では高精細な3次元地図の事前作成が必要となるが、全国のあらゆる地域での地図作成はコストが大きい。また、検出物体を3次元地図にマッピングするためにLiDARを必要とする手法が多いが、LiDARは一般的に高価で大衆車への搭載は困難なため、車載カメラ画像のみを用いた走路決定手法が必要である。

このような車載カメラ画像のみを用いた走路決定技術として、胡らは車道領域抽出手法を提案している [2]。特に一般道路において、道路中で車両が走行できる車道と、できない歩道は、車載カメラ画像中で同じ明るさや色彩をもつ場合が多い。そこで、車道と歩道を分離する白線などの路面標示に着目し、画像のカラー微分

エッジ抽出法を用いて路面標示を認識することで、車載カメラ画像中の車道領域を抽出している。しかし、一般道では経年劣化などで路面標示が消失する 경우가多く存在するため、それらに大きく依存する本手法は正しく動作しない可能性が高い。そのため、路面標示に依存しない走路決定手法が必要である。

このような問題に対して Barnes ら [3] や Zhou ら [4] は、周囲環境認識技術の一つである Semantic segmentation を拡張し、画像上に直接的な画像特徴として存在しない走路の推定を実現する手法を提案している。これらの研究では、事故なく車両が走行した領域は安全に走行可能であると仮定している。そして、各車載カメラ画像に対し、撮影後に車両が実際に移動した経路を投影して学習することで、画像上の走路を直接推定している。しかし、交差点のように、自車が様々な方向へ進み得る複雑な状況下では、同じ周囲環境でも複数の移動経路が存在し得るため、車載カメラ画像のみから走行すべき走路を高精度に推定することは困難である。

一方、カーナビゲーションシステム（以下、カーナビ）は近年急速に普及しており、2011年時点で日常的に利用する運転者の割合が約80%に達している [8]。そのため、実際の走行時にはカーナビによって進路が定められている場合が多い。また、自動運転車両への応用を考えた場合、このような進路は既知である。したがって、交差点における直進、右折、左折などの進路情報が走路推定における有用な情報源となると考えられる。

そこで本発表では、車両の進路情報を活用し、交差点における高精度な走路推定を目的とする。具体的には、conditional Generative Adversarial Network（以下、cGAN）の枠組みを利用し、車載カメラ画像と進路情報を活用した推定器の構築手法を提案する。この手法により、複数の進路が存在し得る交差点でも、進む予定である進路情報に沿った走路（以下、状況適応型走路）を高精度に推定する技術の実現を目指す。

2 関連研究：cGANによる画像生成

Generative Adversarial Network（以下、GAN）は、Generator（生成器）とDiscriminator（識別器）の2つのネットワークから構成される深層学習ベースの生成モ

デルである [5]。まず潜在変数としてランダムノイズからサンプリングされた値を Generator に入力することで画像を生成し、その生成結果を Discriminator で識別する。そして、この識別結果を用いて損失（Adversarial loss）を計算し、各ネットワークに逆伝播させて両者を相補的に学習する技術である。

本技術は近年注目を集めており、GAN を派生させた様々なネットワークが研究されている。その一つとして、GAN の生成結果を制御するため、出力したいクラスの情報を GAN に埋め込む cGAN が提唱されている [6]。cGAN とは、GAN の各ネットワークに対し、それぞれの入力とクラスの情報を結合したものを学習させることで、明示的に指定したクラスの画像を生成する手法である。また、画像を cGAN の条件（Condition）としたうえで、通常の cGAN の Adversarial loss に L1 loss を加えた損失関数を定義し、これを用いて各ネットワークを学習する手法も提案されている [7]。潜在変数を \mathbf{x} 、真値画像を \mathbf{y} 、元画像を \mathbf{z} としたとき、

$$L_G = \mathbb{E} [\log(1 - D(\mathbf{x}, G(\mathbf{x}|\mathbf{z}))) + \lambda_{L1} \mathbb{E} [\|\mathbf{y} - G(\mathbf{x}|\mathbf{z})\|_1] \quad (1)$$

$$L_D = \mathbb{E} [\log D(\mathbf{x}|\mathbf{z}, \mathbf{y})] \quad (2)$$

で表される損失関数を用いて、指定したスタイルの画像への高精度な変換を実現している。

本研究の目的は、車載カメラ画像から進路情報に沿った走路を推定することである。そのため、元画像から指定したクラスに沿った別の画像を生成する cGAN の枠組みは、本研究のベースとして用いることができる。そこで提案手法では、損失関数として式 (1) と式 (2) を持つ cGAN を拡張し、状況適応型走路推定器を構築する。

3 cGAN を用いた走路推定

提案する状況適応型走路推定器は、車載カメラ画像を通常の GAN における潜在変数とし、目的地までの経路から得られる車両の進路情報を Condition として Generator と Discriminator に与えることで、cGAN の枠組みを利用して走行すべき走路を推定する。図 1 に提案する状況適応型走路推定器の構造を示す。この推定器を用いて状況適応型走路を正確に推定するためには、下記の2つの課題を解決する必要がある。

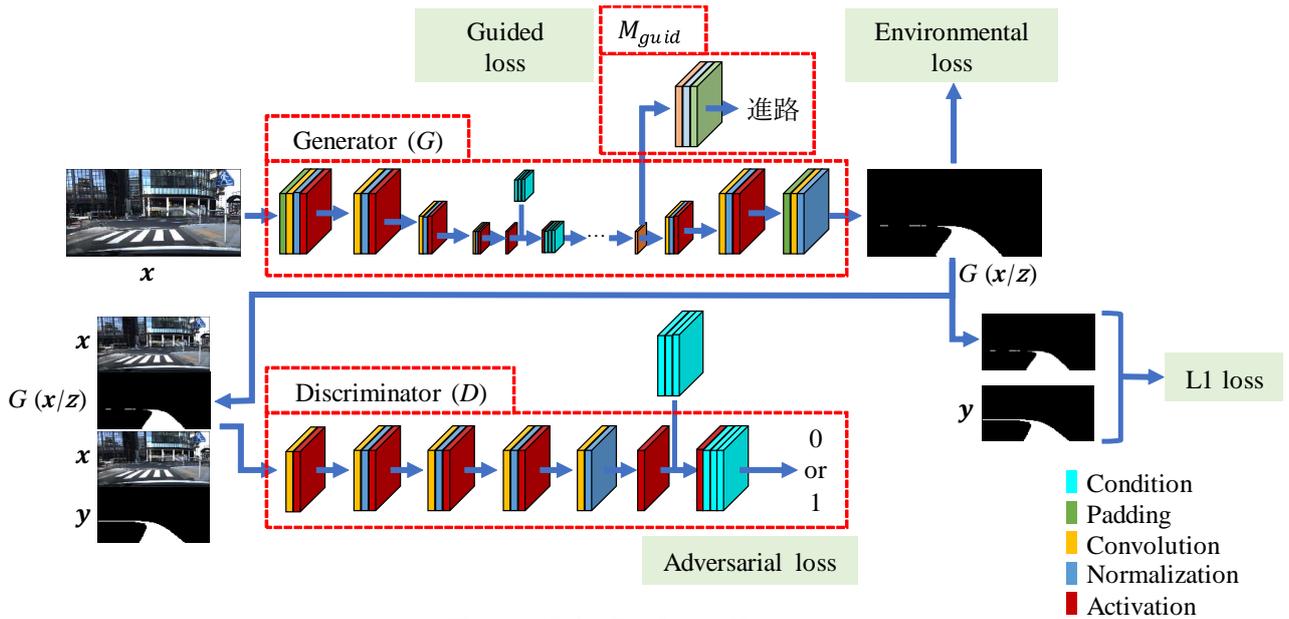


図 1 状況適応型走路推定器の構造.

(A) 進路情報の効率的な学習 :

ある与えられた周囲環境に対して、異なる進路情報を入力することで複数種類の走路を推定できるよう、柔軟に進路情報を学習する必要がある。

(B) 周囲環境情報の有効活用 :

車載カメラ画像のみを用いた単純な走路推定では、周囲環境中の接触が危険な領域が不明であり、そのような領域に走路を推定する可能性がある。安全に走行できる状況適応型走路を推定するためには、歩行者や他車両など、人身事故に直結する領域を回避しつつ走路を推定する必要がある。

提案手法では課題 (A) を解決するため、進路情報を走路推定器に付与するとともに損失関数 Guided loss を追加し、さらに課題 (B) の解決のため損失関数 Environmental loss を追加する。

具体的には、交差点における進路情報を走路推定に利用するため、進路情報を Generator, Discriminator 内の Convolutional 層に挿入する。ここでの進路情報は一般的な交差点における進行方向である直進、右折、左折とする。そして、それぞれに対応する合計 3 チャンネルを Condition 層として走路推定モデルに挿入する。この Condition 層の値を変化させることで、同じ周囲環境における複数走路の推定を実現する。

また、以下の 2 つの損失関数を定義し、式 (1)、式 (2) に追加する。

• Guided loss (L_{guid})

マルチタスク学習による、進路情報学習の効率化を図る。

• Environmental loss (L_{env})

走路推定に重要な周囲環境情報を Generator の学習に用いることで推定精度の向上を図る。

これらの関数を用いて損失を算出し、Discriminator および Generator に逆伝播させることで、識別モデルと走路推定モデルを同時に学習する。提案するモデルの損失関数はそれぞれ各損失関数の係数 λ を用いて次式で表される。

$$L_{G'} = L_{\text{adv}} + \lambda_{L1} L_{L1} + \lambda_{\text{guid}} L_{\text{guid}} + \lambda_{\text{env}} L_{\text{env}} \quad (3)$$

$$L_{D'} = L_{\text{adv}} \quad (4)$$

以降、各損失関数について詳細を述べる。

3.1 Guided loss (L_{guid})

走路推定において進路情報を効率的に活用するため、マルチタスク学習を導入する。マルチタスク学習とは、主とするタスクの他に関連する副タスクを同時に解くことで、複数のドメインの情報を相補的に学習する手法である [9]。この手法は推定器の汎化性能と推定精度に好影響を与えることが知られている。提案手法では主タスクとして走路推定を行ない、補タスクとして進路推定を行なう。この実現のため、図 1 に示したよ

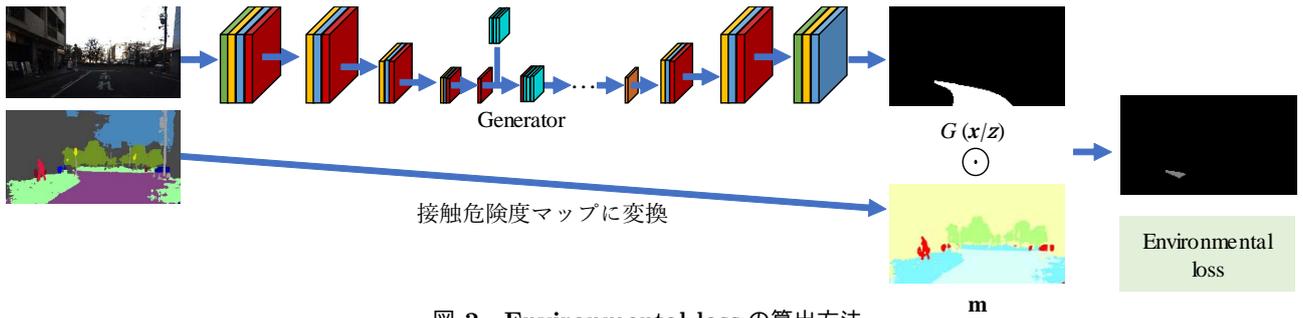


図 2 Environmental loss の算出方法.

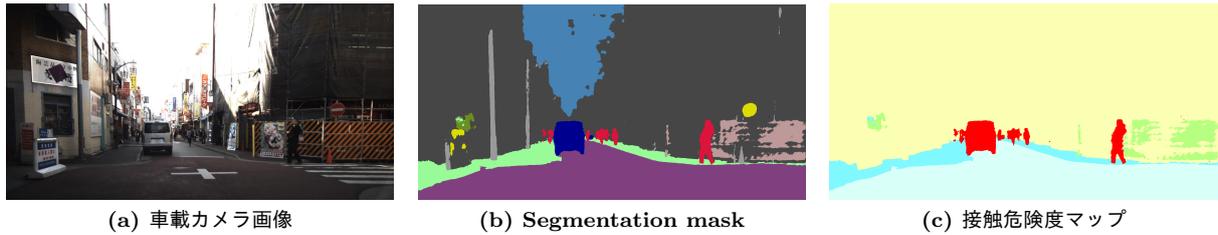


図 3 接触危険度マップの例.

うに, Generator に進路情報を学習させた後に出力を分岐させる. そして分岐させた情報を進路推定モデル M_{guid} に入力することで進路を推定する. 進路推定モデル M_{guid} は Average Pooling 層, Dropout 層, Fully connected 層の 3 層から構成される. この進路推定結果 $M_{\text{guid}}(\mathbf{x}|\mathbf{z})$ と式 (5) から算出される損失を導入することで走路推定に必要な進路情報を効果的に学習する.

$$L_{\text{guid}} = \mathbb{E} [\log(M_{\text{guid}}(\mathbf{x}|\mathbf{z}))] \quad (5)$$

3.2 Environmental loss (L_{env})

1 節で示したように, 状況適応型走路の推定には周囲環境情報が重要である. そこで, この情報を学習に利用するため, Environmental loss を提案する. 図 2 に Environmental loss の算出方法の概要を示す. まず, 周囲環境情報として道路や歩道, 歩行者, 他車両などの情報を含む Segmentation mask を利用する. この Segmentation mask の各画素に対し, 歩行者や他車両などの接触時に人身事故に直結するものは高く, 信号機や電柱などの物損事故の危険があるものは中程度に, 道路や歩道などの安全なものは低くなるように分類し, 接触危険度マップとする. 図 3 に車載カメラ画像と, それに対応する Segmentation mask および接触危険度マップの例を示す.

そして, 推定した走路画像 $G(\mathbf{x}|\mathbf{z})$ と接触危険度マップ \mathbf{m} の Hadamard 積を損失関数とする. この損失関

数は, 安全に走行可能な領域を走路と推定するほど小さな値を出力し, 重大な事故を起こす可能性が高い領域を走路と推定するほど大きな値を出力する. この値を Generator に逆伝播させることで, 走行不可領域への走路推定を制限する.

$$L_{\text{env}} = \mathbb{E} [\log(G(\mathbf{x}|\mathbf{z})) \otimes \mathbf{m}] \quad (6)$$

ここで, \otimes は Hadamard 積を表す.

4 評価実験

本節では, 提案する状況適応型走路推定器の精度を評価するために行なった評価実験について述べる.

4.1 実験条件

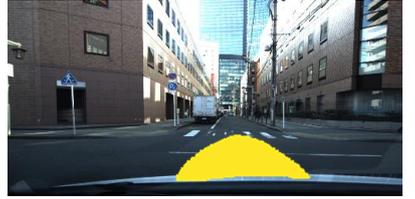
本実験では, 名古屋駅周辺を走行して獲得したデータセットから交差点周辺のデータを手作業で選別し, 進路情報のアノテーションを付与した. この作業を通し, 直進 523 枚, 右折 656 枚, 左折 553 枚の車載カメラ画像にアノテーションを付与した. そして, これらのデータのうち 2/3 を学習用, 残りの 1/3 を評価用に利用した.

提案する Condition 層や各損失関数の導入による推定精度の向上を確認するため, Condition 層, Environmental loss, Guided loss を順次導入して状況適応型走路推定器を構築した. また, 比較手法として, 状況適応型走路のみを推定する推定器と, Zhou ら [4] の手法のように歩行者, 他車両などの周囲環境情報と状況適

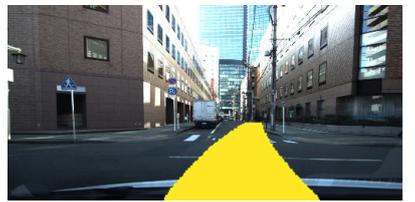
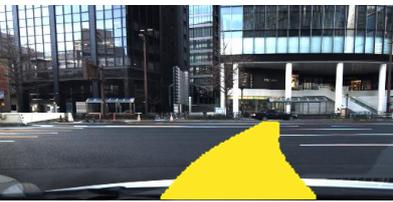
真値



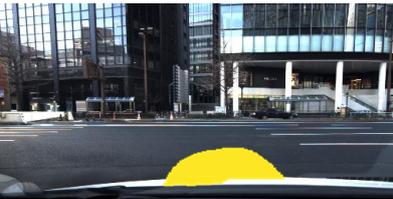
比較1



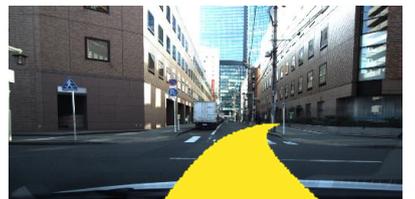
比較2



提案1



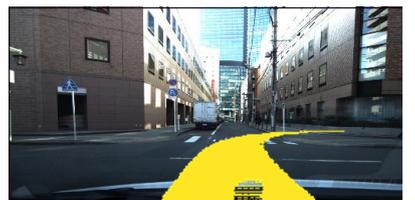
提案2



提案3



提案4



左折時

右折時

直進時

図4 各手法による進路別の状況適応型走路推定結果.

表 1 各推定器による推定結果.

推定器	出力形式	Condition 層	L_{env}	L_{guid}	適合率 [%]	再現率 [%]	F 値 [%]	IoU [%]
比較 1	走路+周囲環境	-	-	-	69.2	67.1	68.1	51.7
比較 2	走路のみ	-	-	-	75.0	72.8	73.9	58.6
提案 1	走路+周囲環境	✓	-	-	74.1	71.3	72.7	57.0
提案 2	走路のみ	✓	-	-	82.2	82.9	82.6	70.3
提案 3	走路のみ	✓	✓	-	86.1	82.7	84.4	73.0
提案 4	走路のみ	✓	✓	✓	86.2	83.5	84.8	73.6

応型走路を同時に推定する推定器を構築した。そして、比較手法と提案手法の合計 6 手法を用いた状況適応型走路推定器をそれぞれ構築し、精度を比較した。推定精度の評価には走路領域の適合率、再現率、F 値、IoU を用いた。

4.2 実験結果および考察

表 1 に各推定器の推定精度を、図 4 に走路の真値および進路別の状況適応型走路の推定結果例を示す。表 1 から、進路情報を条件として用いることに加えて、全ての損失関数を追加した提案手法 4 が、IoU において最も高精度であることを確認した。特に、状況適応型走路のみを推定する比較手法 2 と比較した場合、提案手法 4 は 15.0% の IoU の向上を実現した。

また、図 4 の右折時の車載カメラ画像に対し、比較手法 2 では直進する走路を推定したが、右折の進路情報を付与した提案手法 2~4 では右折する走路を推定できた。これらの結果から、交差点における状況適応型走路推定において、進路情報の付与が有効であることを確認した。

さらに、図 4 の直進時の車載カメラ画像に対し、提案手法 2 は歩道に乗り上げる走路を推定したが、提案手法 3 では周囲環境情報を用いて推定精度向上を図る Environmental loss の導入により正しい走路を推定できた。これは、Environmental loss が歩道領域への走路の推定を制御できたためであると考えられる。したがって、歩道や他車両などの周囲環境情報が状況適応型走路推定において有効であることを確認した。

一方、Guided loss を導入しなかった提案手法 3 と比べて、導入した提案手法 4 での IoU の向上は僅かであった。これは進路情報の学習において、Condition 層の導入が十分機能していたことを示している。

また比較手法、提案手法ともに、状況適応型走路のみを推定した方が、状況適応型走路以外の情報を同時に推定した場合に比べ、より高精度に推定可能であった。図 4 のように、交差点は通常の直進路に比べ道路構造が複雑であるため、歩行者や他車両、構造物などの領域推定の失敗が生じやすい。このような失敗は、状況適応型走路推定そのものに悪影響を与えるため、状況適応型走路のみの推定の方が有効であったと考えられる。

5 むすび

本発表では、交差点における進路情報の付与による高精度な状況適応型走路推定手法を提案した。また、評価のため進路別のデータセットを作成し、状況適応型走路推定器を構築した。この推定器による状況適応型走路推定精度を評価した結果、比較手法より 15.0% 高精度に推定可能であることを確認した。今後の課題として、周囲環境情報の有効利用によるさらなる推定精度向上が挙げられる。

謝辞 本研究の一部は JST 未来社会創造事業 (JP-MJMI17C6)、科学研究費補助金 (17H00745) による。

参考文献

- [1] 交通事故総合分析センター, “交通統計 平成 29 年版,” <https://www.itarda.or.jp/materials/traffic/free/>, July 2019. (2019/1/12 参照)
- [2] 胡振程, 宮平聡, 内村圭一, “道路領域自動抽出法の提案,” 情報処理学会第 54 回全国大会講演論文集, vol.2, pp.415–416, Mar. 1997.
- [3] D. Barnes, W. Maddern, and I. Posner, “Find your own way: Weakly-supervised segmentation of

- path proposals for urban autonomy,” Proc. 2018 IEEE Int. Conf. on Robotics and Automation, pp.203–210, Oct. 2018.
- [4] W. Zhou, S. Worrall, A. Zyner, and E. Nebot, “Automated process for incorporating drivable path into real-time semantic segmentation,” Proc. 2018 IEEE Int. Conf. on Robotics and Automation, pp.6039–6044, May 2018.
- [5] I. J. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, and Y. Bengio, “Generative adversarial nets,” Proc. 2014 IEEE Int. Conf. on Neural Information Processing Systems, pp.2672–2680, Dec. 2014.
- [6] M. Mirza and S. Osindero, “Conditional generative adversarial nets,” Computing Research Repository, arXiv:1411.1784, 2014.
- [7] P. Isola, J. Zhu, T. Zhou, and A. A. Efros, “Image-to-image translation with conditional adversarial networks,” Proc. 2018 IEEE Conf. on Computer Vision and Pattern Recognition, pp.5967–5976, July 2017.
- [8] 外井哲志, 大塚康司, “道路案内標識とカーナビゲーションに関する運転者の利用実態の変化,” 土木計画学研究発表会講演集, vol.45, no.380, June 2012.
- [9] R. Caruana, “Multitask learning,” Machine Learning, vol.28, no.1, pp.41–75, Sep. 1997.