

SC-RRT*を用いた自動運転のための経路生成

成瀬柊平† 家崎遥† 平川翼† 山下隆義† 藤吉弘亘†

† 中部大学

E-mail: {iesaki, hirakawa}@mprg.cs.chubu.ac.jp

1 はじめに

自動運転技術とは、人が操作することなく、自動車がシステム制御により自動で走行する技術である。自動運転にはレベル0からレベル5までの段階があり、レベル4までは高速道路などの特定の場所での運転に限られる。一方、レベル5は完全自動運転と呼ばれ、場所の制限がなくなり、市街地を含む一般道路などのすべての道路で自動運転が可能になる。市街地を含む一般道路での自動運転の実現には、認知・判断・操作に有効活用できるデジタル地図が必要である。

デジタル地図とは、走行に必要な地図情報をコンピュータで扱えるように数値として表現したデータである。デジタル地図には、走行する環境や道路標識などの様々な情報が含まれており、自車両の現在地や周辺環境の把握、目的地までの移動ルートの決定などに活用される。また、デジタル地図には、交通規則に従い適切な位置を車両が走行するための経路情報が含まれている。従来のデジタル地図では、経路情報は手作業で作成されているため、人的コストがかかるという問題点がある。また、直線道路では車線の中央に線を引けばよいが、交差点では車線が無いために最適な経路を引くことが困難であるという問題点がある。

そこで、本研究ではデジタル地図における経路情報、とりわけ交差点のような明確な車線が存在しない地点の経路を自動で作成することを目的とする。この目的のために、本論文ではデジタル地図生成のための交差点データセットの作成及び、経路生成の手法の提案を行う。データセットには、Google Maps から得た交差点の航空写真の画像が100枚、その画像のアノテーション画像が100枚、各画像上での経路のサンプルが合計1,417サンプル含まれている。経路生成の手法として自動車のための目的関数を導入したSC-RRT* [1]を提案する。目的関数には、経路を生成する環境を考慮するシーンコンテキストの項、経路の距離に対する正則化項、経路の交差点中心からの距離に対する正則化項の計3項より成り立つ。この交差点中心からの距離に対する正則化項は、デジタル地図の交差点の右折の経路を生成する場合において、交差点内をショートカットする経路が生成されることを抑制する。評価実験では、

各正則化項のパラメータによる精度の違いを比較し、自動車に適した経路を生成できているのかを検証する。

2 関連研究

2.1 自動運転におけるデジタル地図の活用

デジタル地図は安全かつ高精度な自動運転制御を実現するために広く用いられている。具体的には、Light Detection and Ranging (LiDAR) や車載カメラから取得した周囲の環境データとデジタル地図に含まれる情報を活用することで、高精度な車両の自己位置推定が実現されている [2, 3, 4, 5, 6, 7]。Taoら [5] は拡張カルマンフィルタと白線情報を用いた高精度な自己位置推定を実現している。また、Obstら [3] は天候等の影響によるGlobal Positioning System (GPS) の計測誤差を補正するためにデジタル地図を活用している。これらの手法では主にデジタル地図に含まれる車線情報や停止線のようなランドマークを効果的に活用している。また、このような自己位置推定法を活用し、実環境での自動走行実験も行われている [8, 9]。これらの実験では、車両の自己位置を推定した後に適切な走行位置が決定され、車両を制御する。一方、本研究では、車両が走行すべき適切な位置をあらかじめ生成し、デジタル地図に含める。これにより、リアルタイムに経路を求めることなく、効率的に車両を制御することを可能にする。

広範囲にわたるデジタル地図の作成は非常にコストが高い。そのため、航空画像や衛星画像を活用し、デジタル地図に必要な情報を抽出することで効率的な地図の作成が可能となる [10, 11, 12, 13, 14]。深層学習の発達により、畳み込みニューラルネットワーク (convolutional neural network; CNN) を用いた手法が提案されている。Azimiら [12] はCNNを用いた白線の自動検出手法を提案している。この手法はfully convolutional network (FCN) [15] に基づきネットワークを構築しており、さらに白線検出のデータセットを作成し評価している。Kampffeyerら [13] は道路や車、建物などの領域を自動で推定するための手法を提案している。さらに、推定した結果を解析するために、不確実性を用いたセグメンテーション結果の解析手法を提案している。

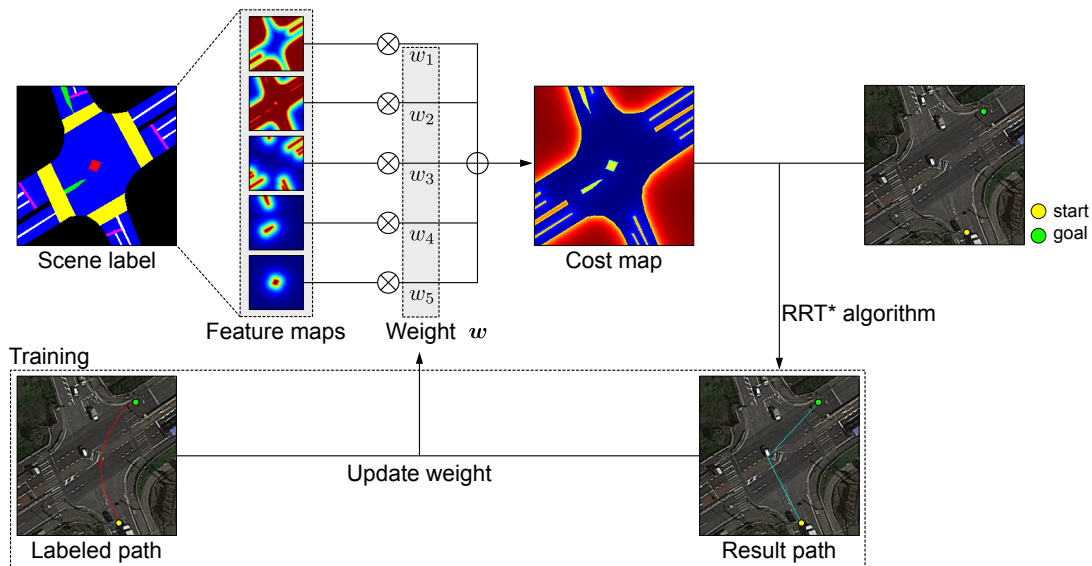


図 1 提案手法の概要

このように、多くの研究では、航空衛星画像から物体のカテゴリや位置を推定している。一方、本研究では画像から推定されたセマンティックなシーンラベルの情報を元に、車両の適切な走行経路を自動で生成することを目的とする。

2.2 経路生成

経路生成はロボティクス分野で古くから扱われている問題である。経路生成には様々な手法が安されているが、代表的な手法として Rapidly-exploring random tree (RRT) [16] がある。この手法では、初期地点からランダムに移動経路を生成し、探索を行うことで、目標地点までも移動経路を高速に生成することを可能としている。また、同様のアルゴリズムでより最適な移動経路を生成する手法として、Optimal RRT (RRT*) [17, 18] が提案されている。この手法では RRT アルゴリズムによる探索に加えて、コストが小さくなるようにノードを繋ぎ直す処理 (rewire) を導入している。これにより、十分なサンプリングを行うことで、経路の最適性を保証しており、目標地点までの最短経路の生成を可能としている。

観測した経路情報にシーンコンテキストを反映した SC-RRT* (Scene Context-aware Rapidly-exploring Random Tree) が提案されている。シーンコンテキストは、車道や歩道、建物などの周囲の環境である。この手法は、シーンコンテキストから生成された特徴マップと人の移動経路データから学習に使用した移動経路データのコストが低くなるような重み w を学習する。その後、学習により獲得した重みを用いて最適なコストマップを作成し、Optimal Rapidly-exploring Random Tree (RRT*) [17, 18] により最適な経路を生成する。この手法では、シーン中の歩行者の移動経路について着

目している。そのため、歩行者の移動経路を考慮し、障害物を避けつつ短い移動経路となるようなコストを定義している。一方、本研究ではデジタル地図における移動経路の自動生成を目的としており、自動車に適したコスト関数を定義する。

3 提案手法

従来の SC-RRT* では、人の経路を生成するためのコストが定義されている。すなわち、人の移動経路が最小のコストになりやすい関数を定義していることを見なすことができる。しかし、デジタル地図生成では経路を生成する対象が車であり、交差点の形や右折する場合には膨らんだ経路を生成する必要がある。そこで本研究では、自動車のためのコスト関数を導入した SC-RRT* を提案する。

提案手法の概要を図 1 に示す。まず、経路生成を行うシーンに対するシーンラベルから各ラベルを表現した特徴マップを作成する。また、その特徴マップに対する重みベクトル $w = (w_1, \dots, w_n)^T$ を定義する。ここで n はシーンラベルから作成した特徴マップの数である。その後、上記の特徴マップと重みベクトルのからコストマップを算出する。コストマップを算出したのち、設定した初期地点から目標地点に到達するまでの累積コストが最小となるような移動経路を生成する。移動経路の生成には Rapidly-exploring random tree (RRT*) アルゴリズム [17, 18] を用いる。

3.1 コスト関数

デジタル地図では経路を生成する対象が車であり、右折時や交差点の形状によっては迂回した経路を生成する必要がある。そこで本研究では、自動車が右折時に近づく交差点中心に着目し、第 3 項目に経路と交差点

中心との距離に対する正則化項を追加したコストを次のように定義する。

$$c_p(\mathbf{x}, \mathbf{w}) = \sum_{t=1}^T \mathbf{w}^T \mathbf{f}(x_t) + \theta \sum_{t=1}^{T-1} \|x_t - x_{t+1}\|_2 + c\alpha \sum_{t=1}^T \|x_t - x_{center}\|_2 \quad (1)$$

c は経路が右折時に 1, 直進と左折時に 0 となる変数である。 α は第 3 項の強さを表すスケールパラメータである。提案手法では, 経路上の座標 x_t と交差点中心の座標 x_{center} との距離を求め, コストに加えることで, 右折時に交差点中心に近づく経路生成を実現する。

3.2 経路の生成

このコスト関数を最小化するような経路を求めるために, 提案手法では RRT* アルゴリズム [17, 18] に基づき経路を生成する。アルゴリズム 1 に経路の生成アルゴリズムを示す。

スタート地点 x_{init} を木構造 $T = (V, E)$ 根ノードとする。その後, 任意の点 x_{rand} をサンプリング (Sampling) し, x_{rand} からもっとも近い点 $x_{nearest}$ を選択する (Nearest)。 $x_{nearest}$ から x_{rand} 方向へ枝を伸ばすことで新たなノード x_{new} を生成する (Steer)。その後, x_{new} を中心とした半径 r 内に存在する近傍ノード群 X_{near} を選択する。 X_{near} 内のコストが低くなるノードを x_{parent} とし, x_{new} との間にエッジを作成する。この時の $\text{Cost}(x)$ の計算では式 (1) が使用される。さらに, x_{new} を親ノードとして他のノード $x' \in X_{near} \setminus \{x_{parent}\}$ と接続しコストが低くなる場合, ノードを繋ぎ直す処理を行う。これによりノード間の接続が改善され, コストの低い経路が生成される。これらを繰り返しながら木構造 T を伸ばすことで, 経路の探索を行う。

3.3 クロソイド曲線による補間

車両の移動経路はその車両特性を考慮し, 滑らかに変化するような移動経路を生成する必要がある。提案手法のコスト関数では, 滑らかに変化する経路を生成するために経路の長さに対する正則化項を導入している。しかし, RRT* アルゴリズムを用いてランダムに経路の探索を行うため, 車両の移動特性を考慮した滑らかな移動経路が生成されない可能性がある。そこで, 提案手法により得られた経路に対し, 道路の設計等に用いられるクロソイド曲線を用いて補間することにより, 滑らかな移動経路を最終的な結果として出力する。

具体的には, 得られた移動経路うち, 交差点の中心部分の移動経路に対し, クロソイド曲線を用いた補間手法 [19] を用いることで, 滑らかな移動経路を生成する。

Algorithm 1 Algorithm of proposed approach

```

1:  $V \leftarrow \{x_{init}\}; E \leftarrow \emptyset;$ 
2: for  $n = 0$  to  $N$  do
3:    $T \leftarrow (V, E);$ 
4:    $x_{rand} \leftarrow \text{Sample}(n);$ 
5:    $x_{nearest} \leftarrow \text{Nearest}(T, x_{rand});$ 
6:    $x_{new} \leftarrow \text{Steer}(x_{nearest}, x_{rand}, \eta);$ 
7:   if  $\text{ObstacleFree}(x_{nearest}, x_{new})$  then
8:      $V \leftarrow V \cup x_{new};$ 
9:      $x_{parent} \leftarrow x_{nearest}$ 
10:     $X_{near} \leftarrow \text{Near}(T, x_{new}, |V|)$ 
11:    for all  $x_{near} \in X_{near}$  do
12:      if  $\text{ObstacleFree}(x_{near}, x_{new})$  then
13:         $c' \leftarrow \text{Cost}(x_{near}) + c_p(x_{new}, x_{near})$ 
14:        if  $c' < \text{Cost}(x_{new})$  then
15:           $x_{parent} \leftarrow x_{near}$ 
16:        end if
17:      end if
18:    end for
19:     $E \leftarrow E \cup \{x_{nearest}, x_{new}\};$ 
20:    for all  $x' \in X_{near} \setminus \{x_{parent}\}$  do
21:      if  $\text{ObstacleFree}(x_{new}, x')$  and
22:         $\text{Cost}(x') > \text{Cost}(x') + c_p(x_{new}, x')$  then
23:         $E \leftarrow E \setminus \{(\text{Parent}(x'), x')\}$ 
24:         $E \leftarrow E \cup \{(x_{new}, x')\}$ 
25:      end if
26:    end for
27:  end for
28: return  $T = (V, E);$ 

```

3.4 学習

式 (1) における最適な重みベクトル $\hat{\mathbf{w}}$ を学習により獲得する。具体的には, exponentiated gradient descent により, 学習データの経路で獲得できる特徴ベクトルと提案手法で生成する経路で獲得できる特徴ベクトルが一致するような重み \mathbf{w} を推定する。

ある K 個の経路から得られる特徴ベクトルの平均値は次のように定義される。

$$\bar{\mathbf{f}} = \frac{1}{K} \sum_k^K \mathbf{f}(x_k) \quad (2)$$

また, 式 (1) のコスト関数の \mathbf{w} に対する勾配は次式により定義される。

$$\nabla c_{\mathbf{w}} = \bar{\mathbf{f}} - \bar{\mathbf{f}}_{\mathbf{w}} \quad (3)$$

ここで, $\bar{\mathbf{f}}$ は学習サンプルの経路から得られる特徴ベクトルの平均値であり, $\bar{\mathbf{f}}_{\mathbf{w}}$ は現在の重み \mathbf{w} を用いて

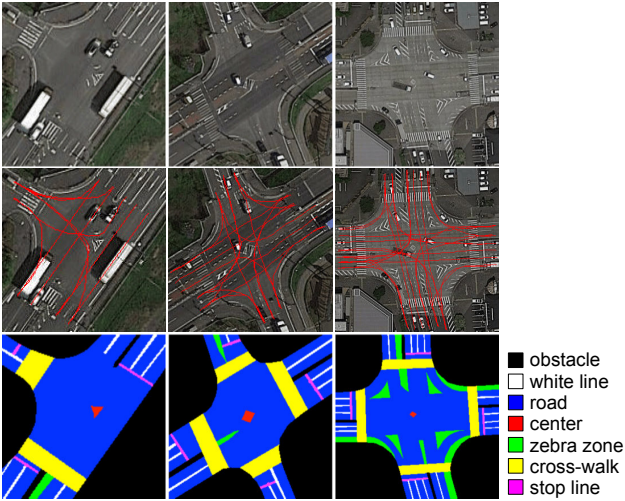


図2 作成した交差点データセットの例。上段：収集した交差点の画像。中段：収集した移動経路。下段：各シーンに付与したシーンラベル。

生成された経路から得られる特徴ベクトルの平均値を示している。 \bar{f}_w は現在の重み w およびアルゴリズム 1 を用いて生成した経路から産出する。その後、勾配を用いて重み w を更新する。

$$w \leftarrow w e^{(-\lambda \nabla c_w)} \quad (4)$$

ここで、 λ は学習率である。上記の処理を w が変化しなくなるまで繰り返すことで、最終的な重み \hat{w} を得る。

4 実験

提案手法の有効性を評価実験により検証する。

4.1 データセット

提案手法の学習および定量的評価を目的として、交差点における自動車の移動経路データセットを作成した。データセットには交差点画像、シーンラベル、経路及び交差点中心座標が含まれる。以下では作成したデータセットの詳細について述べる。

交差点画像は GoogleStaticMapsAPI で取得できる GoogleMaps の航空写真を用いる。画像サイズは 640×640 [pixel] で、100 枚収集した。また、交差点画像中に含まれる領域を交差点に限定するために、それぞれの画像を交差点のすべての停止線が入るほどの大きさに縦横比は変えずに切り取った。そのため、画像サイズはシーンにより異なる。

収集した交差点画像に対してシーンラベルを付与した。付与したシーンラベルは、障害物や車道、白線などの自動車の走行に影響を与えていると考えられる計 7 種類である。また、シーン内の自動車が走行する移動経路の情報を収集した。収集した移動経路は、シーンにおいて考えられる初期地点および目標地点全てに対

し、1 サンプルずつ収集した。収集した移動経路サンプルは、直進が 472 サンプル、左折が 471 サンプル、右折が 474 サンプルの計 1,417 サンプルである。この他にも、交差点の中心座標を収集している。図 2 に作成したデータセットの例を示す。

4.2 実験設定

本実験では、提案するコスト関数に含まれるパラメータ θ および α を変更し、パラメータの違いによる精度の変化を検証する。各パラメータは 0.1 刻みで変化させ、精度を確認するが、組み合わせた膨大になるため、以下の手順で最適なパラメータを求める。

1. 従来の SC-RRT* の精度を検証するためにスケールパラメータ θ を 0.5 から 1.5 まで 0.1 刻みに設定し、11 パターンの実験を行う。
2. 提案手法のスケールパラメータ θ を 0.5 から 1.5 まで 0.1 刻みに設定し、11 パターンの実験を行う。この時のスケールパラメータ α は 1.0 に固定する。
3. 提案手法で最も精度の高いスケールパラメータ θ を固定し、スケールパラメータ α を 0.1 から 0.9 まで 0.1 刻みに設定し、9 パターンの実験を行う。

また、比較手法として、従来の SC-RRT* を用いる。

提案手法および従来手法における RRT* のパラメータとして、探索木の長さを 10 [pixels]、ランダムサンプリング回数を 1,000 回、ゴールをサンプリング確率を 5% と設定する。

定量的な評価指標として、modified Hausdorff distance (MHD) [20] を用いる。移動経路の真値を $A = \{a_1, \dots, a_{N_a}\}$ 、生成された経路を $B = \{b_1, \dots, b_{N_b}\}$ としたとき、MHD $\mathcal{D}(A, B)$ は次式により表される。

$$d(A, B) = \frac{1}{N_a} \sum_{a \in A} d(a, B) \quad (5)$$

$$d(B, A) = \frac{1}{N_b} \sum_{b \in B} d(b, A) \quad (6)$$

$$\mathcal{D}(A, B) = \max(d(A, B), d(B, A)) \quad (7)$$

ここで、 $d(a, B) = \min_{b \in B} \|a - b\|$ である。MHD は物体の形状の類似度として用いられる値である。そのため、移動経路を 2 次元の曲線と見なし、真値との類似度を MHD により求めることで定量的な評価を行う。

4.3 実験結果

表 1 に従来手法および提案手法の MHD を示す。この時、 α の値は 1.0 に固定し実験を行なっている。この結果より、従来手法では $\theta = 0.7$ の時に MHD が最小となっている。一方、 $\theta = 0.7$ の場合の提案手法では従来手法よりも誤差が小さくなっていることが確認できる。この結果より、提案するコスト関数を用いることで、より自動車に適した移動経路の生成が実現できていることがわかる。

表 1 評価結果 (単位 : pixel)

手法	θ	α	MHD
SC-RRT* [1]	0.5	-	6.275
	0.6	-	6.044
	0.7	-	6.100
	0.8	-	5.962
	0.9	-	5.843
	1.0	-	5.695
提案手法	0.5	1.0	4.273
	0.6	1.0	6.930
	0.7	1.0	4.076
	0.8	1.0	3.987
	0.9	1.0	5.887
	1.0	1.0	5.883

表 2 $\theta = 0.8$ に固定し, α を変更した場合の実験結果 (単位 : pixel)

手法	θ	α	MHD
提案手法	0.8	0.1	4.882
	0.8	0.2	4.793
	0.8	0.3	4.499
	0.8	0.4	4.515
	0.8	0.5	4.365
	0.8	0.6	4.328
	0.8	0.7	4.160
	0.8	0.8	4.250
	0.8	0.9	3.967
	0.8	1.0	3.987

また, 提案手法では $\theta = 0.8$ のとき MHD が最小となっている。そのため, これ以降の実験では, $\theta = 0.8$ と固定し, α を変化させた場合の精度を検証し, 最適なパラメータの組み合わせを求める。

表 2 に $\theta = 0.8$ に固定し, α を偏差させた場合の提案手法の MHD を示す。この結果より, $\theta = 0.8$ および $\alpha = 0.9$ を用いた場合が最も誤差が小さく, 最適なパラメータの組み合わせであることがわかる。

本実験で用いたデータセットでは, 1 [pixel] は実空間において約 25 [cm] に相当している。依然として大きな誤差はあるものの, 提案手法を用いることにより, 実空間での誤差が約 50 [cm] ほど低減していることが分かる。

表 3 に直進および右左折ごとの MHD を示す。提案手法は従来手法と比較して, 大きく誤差を低減していることが分かる。特に, 右折時の経路の生成では, 実空間において 1 [m] 以上の誤差を改善している。この結果より提案手法を用いることで, 車両に適切な移動

表 3 $\theta = 0.8$ および $\alpha = 0.9$ を用いた場合の直線および右左折に対する MHD

	直進	左折	右折
SC-RRT* ($\theta = 1.0$) [1]	4.268	3.119	9.744
提案手法 ($\theta = 0.8, \alpha = 0.9$)	1.901	1.074	4.177


経路を生成していることが分かる。

4.4 定性的評価

図 3 に移動経路の生成結果を示す。直進および左折に対する移動経路ではどの手法においても同様の移動経路が生成されている。しかし, 従来手法では右折に対する移動経路において, 初期地点から目標地点まで直進するような移動経路を生成していることがわかる。一方, 提案手法では右折時に直進するような経路の生成を抑制し, 交差点の中心付近を通過したのちに目標地点へと移動するような経路の生成を実現している。これらの結果より, 提案手法では交差点における自動車の適切な移動経路を生成していることがわかる。

提案手法ではコストが最小となる経路の生成に RRT* アルゴリズムを用いている。RRT* アルゴリズムではランダムに移動経路の探索を行いつつ, ノードの再接続処理 (rewire) により, 経路の最適性を保証している。しかし, 最適な経路の生成には十分なサンプリング回数が必要であり, 膨大な計算時間を要する。また, 一定間隔でノードを伸ばすため, 生成される経路が滑らかでないという特徴を持つ。実際の自動車の走行時はその移動特性に応じて, 滑らかな移動経路であることが望ましい。そのため, 滑らかな移動経路の生成を行う必要があると考えられる。

図 4 に適切な経路の生成が失敗した例を示す。図 4 の上段の結果では, 直線の移動経路を生成する例を示している。これらの結果では, 直線の移動経路を生成するべきであるにも関わらず, 大きく逸脱した経路を生成している。これは提案手法によって生成された移動経路が直線的ではなく, その結果を用いてクロソイド曲線を用いて補間を行ったため, 大きく滑らかに曲がるような経路が生成されたと考えられる。また, 図 4 の下段は右折時の経路生成の結果を示している。右折時の移動経路は, 一度交差点の中心付近まで進入したのちに滑らかに曲がるような移動経路を生成する必要がある。しかし, 提案手法では交差点進入直後から右折を始めており, 提案手法に導入した第 3 項が寄与していないと考えられる。この問題を解決するためには, より適切なパラメータの設定やスケールパラメータを学習により獲得する必要があると考えられる。



$(\theta = 1.0)$

$(\theta = 0.8, \alpha = 1.0)$

$(\theta = 0.8, \alpha = 0.9)$

図3 生成された移動経路

5 おわりに

本稿では、自動運転時に活用されるデジタル地図における経路情報を自動で作成するための手法を提案した。提案手法では、シーンラベルから作成される特徴マップおよび重みベクトルからコストマップを作成し、与えられた初期地点から目標地点までのコストが最小となる経路を生成する。この時の最適なコストマップを求めるために、学習データから最適な重みベクトルを学習により推定する。また、交差点における自動車の移動に適したコスト関数を定義した。我々が作成したデータセットを用いた評価実験により、提案手法を用いることで交差点における最適な移動経路の生成を実現した。今後の予定としては、交差点における車両間の相互関係を考慮したシーン全体での経路の最適化、車両の移動特性を考慮した滑らかな経路生成などがあげられる。

謝辞

本研究は JSPS 科研費 JP16H06540 の助成を受けたものです。

参考文献

- [1] T. Hirakawa, T. Yamashita, and H. Fujiyoshi, "Scene Context-aware Rapidly-exploring Random Tree for Global Path Planning," in *PerCom Workshops*, 2019.
- [2] P. Fischer, S. M. Azimi, R. Roschlaub, and T. Krauß, "Towards hd maps from aerial imagery: Robust lane marking segmentation using country-scale imagery," *ISPRS International Journal of Geo-Information*, vol. 7, no. 12, p. 458, 2018.
- [3] M. Obst, S. Bauer, P. Reisdorf, and G. Wanielik, "Multipath detection with 3d digital maps for robust multi-constellation gnss/ins vehicle localization in urban areas," in *IV*, pp. 184–190, 2012.
- [4] Z. Tao and P. Bonnifait, "Tightly coupling gps with lane markings for autonomous vehicle navigation," in *ITSC*, pp. 439–444, 2014.
- [5] Z. Tao and P. Bonnifait, "Road invariant extended kalman filter for an enhanced estimation




図 4 適切な経路の生成が失敗した例。 $\theta = 0.8$ および $\alpha = 0.9$ を用いた場合の結果を示している。

of gps errors using lane markings,” in *IROS*, pp. 3119–3124, 2015.

- [6] S. Bauer, Y. Alkhorshid, and G. Wanielik, “Using high-definition maps for precise urban vehicle localization,” in *ITSC*, pp. 492–497, 2016.
- [7] M. Schreiber, C. Knöppel, and U. Franke, “Laneloc: Lane marking based localization using highly accurate maps,” in *IV*, pp. 449–454, 2013.
- [8] J. Ziegler, P. Bender, M. Schreiber, H. Lategahn, T. Strauss, C. Stiller, T. Dang, U. Franke, N. Appenrodt, C. G. Keller, E. Kaus, R. G. Herrtwich, C. Rabe, D. Pfeiffer, F. Lindner, F. Stein, F. Erbs, M. Enzweiler, C. Knopfel, J. Hipp, M. Haueis, M. Trepte, C. Brenk, A. Tamke, M. Ghanaat, M. Braun, A. Joos, H. Fritz, H. Mock, M. Hein, and E. Zeeb, “Making bertha drive—an autonomous journey on a historic route,” *IEEE Intelligent Transportation Systems Magazine*, vol. 6, no. 2, pp. 8–20, 2014.
- [9] M. Aeberhard, S. Rauch, M. Bahram, G. Tanzmeister, J. Thomas, Y. Pilat, F. Himm, W. Huber, and N. Kaempchen, “Experience, results and lessons learned from automated driving on germany’s highways,” *IEEE Intelligent Transportation Systems Magazine*, vol. 7, no. 1, pp. 42–57, 2015.
- [10] O. Tournaire, N. Paparoditis, and F. Lafarge, “Rectangular road marking detection with marked point processes,” in *Conference on Photogrammetric Image Analysis*, vol. 3, pp. 149–154, 2007.
- [11] “Learning to detect roads in high-resolution aerial images,” in *ECCV*, pp. 210–223, 2010.
- [12] S. M. Azimi, P. Fischer, M. Körner, and P. Reinartz, “Aerial lanenet: Lane-marking semantic segmentation in aerial imagery using wavelet-enhanced cost-sensitive symmetric fully convolutional neural networks,” *IEEE Transactions on Geoscience and Remote Sensing*, pp. 1–19, 2018.
- [13] M. Kampffmeyer, A. Salberg, and R. Jenssen, “Semantic segmentation of small objects and modeling of uncertainty in urban remote sensing images using deep convolutional neural networks,” in *CVPR Workshops*, pp. 680–688, 2016.
- [14] E. Maggiori, Y. Tarabalka, G. Charpiat, and P. Alliez, “High-resolution aerial image labeling with convolutional neural networks,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 55, no. 12, pp. 7092–7103, 2017.
- [15] J. Long, E. Shelhamer, and T. Darrell, “Fully convolutional networks for semantic segmentation,” in *CVPR*, pp. 3431–3440, 2015.
- [16] S. M. LaValle and J. James J. Kuffner, “Randomized Kinodynamic Planning,” *IJRR*, vol. 20, no. 5, pp. 378–400, 2001.
- [17] S. Karaman and E. Frazzoli, “Incremental sampling-based algorithms for optimal motion planning,” in *RSS*, vol. 104, 2010.
- [18] S. Karaman and E. Frazzoli, “Sampling-based algorithms for optimal motion planning,” *IJRR*, vol. 30, no. 7, pp. 846–894, 2011.
- [19] E. Bertolazzi and M. Frego, “G1 fitting with clothoids,” *Mathematical Methods in the Applied Sciences*, vol. 38, no. 5, pp. 881–897, 2015.
- [20] M. P. Dubuisson and A. K. Jain, “A modified Hausdorff distance for object matching,” in *ICPR*, vol. 1, pp. 566–568, 1994.