

山道自動運転に対応する 走行レーン認識 AI システム

武田龍斗 竹内浩太 郭清蓮

概要: 近年自動運転に関する研究が大変重要視されている。将来的には日本全土において自動運転システムが実装された自動車や運送機が確実に実用化される。山地が約 75%である日本の地理的特徴を考えれば山道に関連する道路空間の認識が特に重要である。そこで本研究は、山道を研究の対象として捉えた。自動車の運転席から見える景色(画像)に対してアノテーションを行い、自作したニューラルネットワークに学習させた。アノテーション手法とニューラルネットワークの学習パラメータと階層などの研究を行うことによって、高い正解率で山道の道路と道路ではない空間を区別することができるようになった。最終的には、山道走行レーンの認識システムの構築を目指す。

キーワード: 自動運転, 画像認識, 人工知能, 画像アノテーション

Mountain road recognition AI system supporting automatic driving

RYUTO TAKEDA KOTA TAKEUCHI QINGLIAN GUO

Abstract: In recent years, researches on automatic driving have become rather popular. In the future, automobiles and transport machines equipped with automatic driving systems will surely be put into practical usage throughout Japan. Considering the geographical features of Japan, which has about 75% mountain area of the national land, the recognition of mountain roads changes to be especially important. Therefore, we have aimed at images of mountain roads as the subject our research. We annotated images from a driver's view, trained a deep learning neural network by using these images as teacher data. While studying on annotation method, parameters of neural networks, we have found the most appropriate values. Now our neural network is possible to distinguish between an area of mountain road and that not be mountain road with a high accuracy rate. Ultimately, we are going to build a recognition system for speculating the driving lanes of mountain road.

Keywords: Automatic driving, Image recognition, Artificial intelligence, Image annotation

1. はじめに

近年、自動運転に関連する各方面の技術と研究開発は着実に進んでいる。例えば、中国の検索エンジン大手である Baidu (百度) は、自動運転の研究開発を行い、2021 年から北京で無人ロボタクシーサービス (Apollo Go) を開始した [1]。また、米国企業 Waymo は、2021 年 8 月からカリフォルニア州において、一般住民を対象とした自動運転タクシー

の実証実験を行っている [2]。Waymo の実験は、一般道で進められ、車には周辺環境をリアルタイムに取得するカメラ、レーダー、地域 HD マップなどが搭載されている。

一般道の場合は、道路、歩行者、車、標識、信号などを認識しなければならないため、自動運転の難易度がかなり高い。その上、山道となると難易度がさらに増加する。複雑な走行環境による特殊問題も発生する。様々な走行環境に対応するために、ローカルのな情報を「走行環境オプション」

として提供する必要がある。例えば、「市街地オプション」、「住宅地オプション」、「山道オプション」、「橋オプション」などが考えられる。また、走行環境オプションを作るためには、地図、地理、道路情報の細分化と多く人手が不可欠である。これらは一朝一夕で実現できることではなく、長期的に研究とデータを蓄積していくしかない。

私たちは山道での自動運転の必要性を考慮し、「山道オプション」の構築を研究目標とした。上述した Baidu や Waymo の例のように、市街地での自動運転技術の研究開発は大きく前進しているが、山道などのインフラ整備が十分に行われていない場所に対する研究開発は数が少ない。しかし、人や荷物の自動運送を始めとする自動運転技術の導入は、都市部以上に中山間地域での必要性が大きくなると考えられる。そのためには「山道オプション」の開発が必要不可欠である。

研究手法として、ニューラルネットワーク技術を用いて山道の画像から走行可能エリア自動認識とレーンマーク推測を実現したい。現在、車メーカーの技術開発は、知能化、高い認識性能、ソフトウェアアップデートなど、多分野で同時進行されており、それぞれの分野において、ニューラルネットワークが中心技術となっている。また、一般道の画像認識において、レーンマークとなる白線を認識・抽出することが主な目標となっている。しかし、山道の場合、レーンマークが途切れたところや汚れたところ、薄くなったところ、落ち葉に隠されたところ、そもそも引かれていないところが存在する。また、山や樹木の影も画像認識に大きく影響する。そのため、山道の画像認識はレーンマークの認識・抽出を目標とすると、非実用的な結果になってしまう可能性が高いと考えられる。そこで、我々の目標は、山道の走行可能エリアを認識してから、その領域に基づいてレーンマークとなる白線を推測することとした。

研究プロセスとして、初めに、運転席から見える光景を映像データとして保存する。様々な山道を走りながら撮影を行い、日本の山道の特徴をカバーする十分なデータを手に入れる。手に入れた映像データから 1 フレームごとの画像データを取得し、そこから教師データとなる画像を作成する。次に、独自のアイデアに基づいて、教師データの分類を行い、自動分類のためのニューラルネットワークを構築する。また、自動分類の正解率を高めるための研究を行う。将来的には、独自に開発する山道の走行可能エリア認識システムに自動分類の機能を取り入れ、その結果を用いた路面のレーンマークの可視化を行う予定である。

2. 日本の山道

日本の山は国土の約 75% を占めている^[4]。高齢化の影響もあり、交通インフラが整備されていない場所での自動運転による配達や送迎といったことは、実現が強く望まれている。そのため本研究では、山を横断する高速道路のような

整備された道路ではなく、整備が行き届いていない山道を研究対象としている。表 1 は、山道の状況を、落ち葉や積雪によって走行可能エリアがどれくらい見えなくなっているか（視認できる走行可能エリアの割合）、路上に走行の妨げとなるものや他車（対向車や並行車）がないか（路上の障害物や他車等の有無）、時間帯はいつか（時間帯）などの要因で、走行可能エリア認識難易度を分類したものである。都会の道路に比べ、山道の場合、道が狭く、すぐ横に斜面（崖）があるため、これらが要因の影響が複雑に表れる。研究の初期目標は、晴れた日、午前中、対向車なし、並行車なし、春、という最もシンプルな条件下（表 1 のレベル 1）で、走行中の動画データから走行可能エリアを検出し、レーンマークを推測、可視化することを目指す。

表 1 山道における走行可能エリアの認識難易度の分類
 Table 1 The difficulty of recognition of mountain road affected by three factors

走行可能エリア 認識難易度	視認できる走行可能 エリアの割合	路上の障害物や 他車等の有無	時間帯
レベル1	大	無	昼
レベル2	大	無	夜
レベル3	大	有	昼
レベル4	大	有	夜
レベル5	小	無	昼
レベル6	小	無	夜
レベル7	小	有	昼
レベル8	小	有	夜

3. 山道教師データ作成

3.1 ねらい

この研究の第 1 段階は、画像上の走行可能エリアを抽出である。ここでの「走行可能エリア」とは、車道のことを表す。厳密には、車道であっても、路上駐車、落石、道路の損傷などにより走行できないエリアも存在することが考えられるため、車が実際走行できるエリアを「走行可能エリア」と表現する。図 1 のように画像上には走行可能エリアだけでなく、空や森といった走行できない「走行不可能エリア」が存在する。そこで、本研究では山道の教師データを走行可能エリアと走行不可能エリアの 2 種類に分類することにした。1 枚の画像を細分化して、それら 1 つ 1 つを細かく分類できれば、それは、画像上から走行可能エリアを抽出することができるということである。



図1 走行可能エリアと走行不可能エリアの仮想分類図
 Figure 1 Virtual classification map of drivable areas and un-drivable area

3.2 教師データの分類, 作成

図2は, 教師データの分類のために開発したアノテーションプログラムの実行画面である. 画面左上にはプログラム実行時, または Select Folder で選択したフォルダ内の画像が表示される. 画像は左右の矢印キーで変更可能である. 画像内の四角い枠が教師データとして切り取られる範囲である. マウスクリックで枠を移動させ, A (a) または B (b) を押すことで, プログラム内であらかじめ指定したフォルダに A または B のタグを付けて保存する. 右上には保存した画像とタグが表示される.

図3は, 保存された教師データのフォルダを示す. 保存されたデータは, ファイル名の先頭に A または B のタグが付けられている. ここでの A は走行可能エリア, B は走行不可能エリアを表している.

また, データセットの画像枚数を増やすために, 作成した画像データを 90 度, 180 度, 270 度に回転したもの, 上下反転, 左右反転, 上下左右反転させたものを追加し, 教師データを作成した.




図2 独自開発した画像アノテーションソフト
 Figure 2 Our original annotation software



図3 教師データが保存されたフォルダ
 Figure 3 A folder saving the teacher data

4. 山道認識ニューラルネットワーク

4.1 ニューラルネットワークの構造

図4, 5は, 山道認識のために, 構築したニューラルネットワークを示す. ここには, 入力層と出力層を含め, 5層のネットワークが示されているが, 中間層の数を3層~8層に変化できるようにプログラムされている.

入力層は 56×56 の画像データを利用するため, 入力層のノード数は 3136 である. 出力層は走行可能エリアと走行不可能エリアの2種に分類するため, 出力層のノード数は2である. 中間層は, 図4, 5の場合, 中間層の第1層から順にノード数が 784, 196, 49 である. ニューラルネットワークの層数, ノード数については, 学習を進めながら, 結果の正解率の変化を追跡し, 最適値を探索していきたい.



図4 ニューラルネットワークの実行画面1
 Figure 4 Our original neural network - execution screen1



図5 ニューラルネットワークの実行画面2
 Figure 5 Our original neural network - execution screen2

4.2 各種係数の設定

本研究では、中間層の層数以外に、重みの学習率、画素値の縮小範囲、局所解を回避するためのモーメント、バイアスの重みをそれぞれ変化させ、より精度の高い結果が得られる係数を模索する。各種係数の初期値と値を変化させる範囲を表2に示す。

表 2. 各種係数の初期値と変化範囲

Table 2 Initial value and change range of various coefficients.

	初期値	変化範囲
学習率	0.01	0.01~0.10
画素値	0.0~1.0	(0.0~1.0) or (-1.0~1.0)
モーメント	0.8	0.5~0.8
バイアスの重み	-1.0~1.0	(0.0~1.0) or (-1.0~1.0)

4.3 順伝播と逆伝播のプロセス

順伝播では、入力層から出力層への順方向に計算を行う。ノードごとに前層の重み付け和を計算し、その結果を活性化関数 (sigmoid 関数) に通す。この出力を次の層へ順に伝播していく。各層の各ノードで同様の処理を行っていくことで、最終的な出力 (出力層の出力) を行う。本プログラムでは局所解を回避するためにモーメント値を設定している。モーメントを採用することで、前層すべてのノードの重み付け和を計算するのではなく、一定割合 (モーメント値) のノードのみの重み付け和を計算している。

逆伝播では、順伝播の結果 (出力層の出力) と教師データの誤差を求め、それをを用いて逆方向 (出力層から入力層) に各ノード間の重みの更新を行う。

5. 結果と検証

独自のニューラルネットワークにより、90%を超える精度で、画像データを走行可能エリアと走行不可能エリアに分類することができた。これにより、細分化された画像であれば高い精度で分類できることが分かった。

今後は、このニューラルネットワークを応用し、図1のように画像内を走行可能エリアと走行不可能エリアの領域に分類できるようにする。具体的なプロセスとしては、図6のように画像を細分化し、それらを1つ1つ分類していく。それをもとに、画像全体の領域分類を行う。最終的には、図7のように領域分類の結果を利用し、領域の境界線を利用することで、レーンマークを推測できるシステムを研究する。

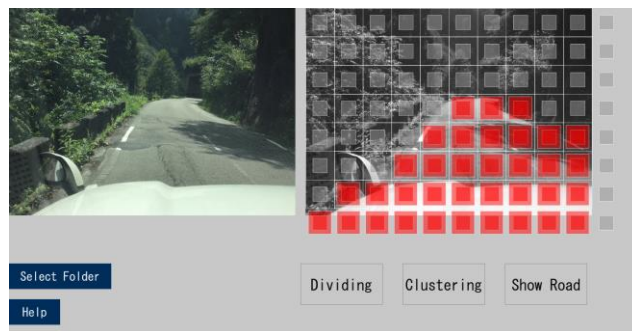


図6 ニューラルネットワークによる領域認識結果
 Figure 6 Area recognition result using our neural network



図7 エリア認識に基づくレーンマーク推測図

Figure 7 Expecting diagram of lane marks based on the result of neural network area recognition

6. まとめ

本研究では、第1段階として、独自の教師データとニューラルネットワークによって、走行可能エリアを高い精度で検出することが可能となった。今後は、今回の結果を用いて、山道のレーンマーク推測を行うためのシステムを研究したい。同時に、様々な地域や状況の山道を撮影し、より多様な環境に対応できるように教師データを増やし、ニューラルネットワークの改良を行う予定である。

参考文献

- [1] 日経クロステック “ウェイモが自動運転商用に王手、サンフランシスコ住民に試験提供” .
<https://xtech.nikkei.com/atcl/nxt/column/18/01537/00180/>, (参照 2021-10-05).
- [2] TechCrunch Japan “中国の検索エンジン大手 Baidu が上海で Apollo Go ロボタクシーのテストを開始” .
<https://jp.techcrunch.com/2021/09/15/2021-09-13-chinese-tech-giant-baidu-begins-publicly-testing-apollo-go-robotaxis-in-shanghai/>, (参照 2021-10-05).
- [3] 国土地理院 “新版 日本国勢地図帳” .
<https://www.gsi.go.jp/atlas/atlas-etsuran.html>, (参照 2021-10-05).
- [4] 国土地理院 “新版 日本国勢地図帳 2.自然 1.地形分類” .
https://www.gsi.go.jp/atlas/archive/j-atlas-d_2j_02.pdf, (参照 2021-10-05).