

愛知県の交通事故データを利用した 地図画像からの事故種別の分類

向直人 *1 内種岳詞 *2 岩田員典 *3 伊藤暢浩 *2
椋山女学園大学 文化情報学部 文化情報学科 *1
愛知工業大学 情報科学部 情報科学科 *2
愛知大学 経営学部 経営学科 *3

愛知県の交通事故死者数は、近年減少傾向にあるが、他県より依然として多く、交通事故対策は重要な課題となっている。この対策の一環として愛知県警察から過去の交通事故データの提供を受けた。この交通事故データには、事故が発生した位置情報に加えて、追突・出合頭などの事故種別の情報が含まれている。そこで、本研究では、事故現場周辺のラスタ形式の道路地図画像を生成し、対応する事故種別を畳み込みニューラルネットワークで学習する。これにより、任意の道路地図画像から生じやすい事故種別を推定することが可能となる。実験の結果、追突・出合頭・右左折の事故種別を 72.5% で正しく分類することが可能であった。また、道路の幅員や交差点の形状が事故種別の分類に寄与していることが確認できた。

Classification of Traffic Accident Categories based on Road Map Images by using Crash Database in Aichi

Naoto MUKAI*1 Uchitane TAKESHI*2 Kazunori IWATA*3 Nobuhiro ITO*2
Dept. of Culture-Information Studies, Sugiyama Jogakuen University*1
Dept. of Information Science, Aichi Institute of Technology*2
Dept. of Business Administration, Aichi University*3

Abstract

The fatalities from traffic accidents in Aichi prefecture is on a declining trend, but it remains stubbornly high. It is an important issue to prevent traffic accidents. In order to solve the issue, we receive a crash database containing traffic accident information (e.g., accident location) from Aichi Prefectural Police. In this work, we generate raster images corresponding to the accident locations and used the images as training data for Convolutional Neural Network to classify categories of accidents (e.g., rear-end collision). The experimental result indicates that 72.0 percent of the accidents can be classified correctly. Moreover, it became clear that the categories of accidents depend on the width of roads and the shape of intersections.

Keyword: 交通事故, 道路地図, 畳み込みニューラルネットワーク

1. はじめに

愛知県警察の交通統計¹には、愛知県における人身事故数・死者数の 2011 年から現在までの推移が示さ

れている。人身事故数・死者数は共に減少傾向であり、2010 年には 256 件であった死者数は、2019 年には 156 件と減少している。この減少の理由には、自動車の安全性能の向上や、交通事故の罰則が強化されたことが

¹<https://www.pref.aichi.jp/police/koutsu/jiko/koutsu-s/toukei.html#>

考えられる。一方で、警察庁の交通事故統計²によると、愛知県の2019年の死亡者数である156件は、都道府県別で2番目に多い件数であった。2020年においては、10月27日までの累計が昨年の同時期よりも6件多い126件であり、高いペースで交通死亡事故が発生している。このように、愛知県の事故数は他県に比べ、依然として多く、交通事故対策は喫緊の課題である。

愛知県警察では、過去に愛知県内で発生した交通事故に関する多面的な情報を記録・保持している。交通事故対策の一環として、これらの交通事故データの提供を受けた。交通事故データには、事故が発生した日時・位置などの情報に加え、追突・出合頭などの事故種別に関する情報が含まれている。

事故現場に存在する交差点や道路の形状が、発生する事故種別に影響を与えると考えられる。例えば、幅員の広い直線的な道路では、車両を加速しやすく、追突などの事故が発生しやすいであろう。そこで、本研究では、事故現場周辺のラスタ形式の道路地図画像を生成する。この道路地図画像を入力、事故種別を出力として、畳み込みニューラルネットワークに学習させることで、任意の道路地図画像から生じやすい事故種別を推定させることを試みる。これにより、道路の特徴に応じて、ドライバに発生しやすい事故を注意喚起することが可能になる。また、より安全な交差点や道路の設計にも応用可能である。本稿では、2018年の交通事故データから、事故種別が追突・出合頭・右左折のレコードを抽出し、畳み込みニューラルネットワーク(Convolutional Neural Network: CNN)の学習用データセットとして用いる。学習した畳み込みニューラルネットワークの精度を明らかにすることに加え、分類に正解したサンプルデータから、事故種別ごとの特徴を考察する。

本稿の構成は以下である。2章で交通事故の分析に関連する既存研究について述べる。3章で愛知県警察から提供を受けた交通事故データを基に構築した学習データセットについて示す。4章で採用した畳み込みニューラルネットワークの構成について示す。5章で学習した畳み込みニューラルネットワークの精度を明らかにし、事故・種別ごとの道路形状の特徴を考察する。最後に6章で本稿をまとめる。

2. 関連研究

本章では、交通事故の分析に関連する既存研究について述べる。分析手法として統計モデルを採用した研究が報告されている。渡部らは、愛知県の事故データと道路交通情報(道路構造、交通量、道路幅員など)を組み合わせたデータベースを構築し、負の2項回帰による事故誘発要因の特定を試みた¹。分析の結果、旅行速度や交差点間の距離が安全性向上に寄与していること示した。また、兵頭らは、愛媛県内の幹線道路で発生した事故データと道路交通情報を基に、ポアソン回帰による事故リスクの評価を試みた²。この結果、右

左折事故では、交通量、沿道状況、道路構造の影響が有意であること、また、出合頭事故では、道路構造のみが強く影響していることを示した。これらの研究は、データに基づくマクロな視点での分析が中心であり、局所的な道路形状は考慮されていない。

そこで、交差点の幾何的な形状に着目した研究が報告されている。塩見らは、交差点の幾何構造と事故リスクの関係性を明らかにするために、Google Earthの航空写真などから、交差点の幾何的な特徴量を抽出し、データベースを構築した³。ポアソン回帰による分析の結果、停止線間距離、横断歩道長など交差点の規模を表す特徴量が、事故リスクを有意に増加させることを示し、交差点のコンパクト化が事故低減に有用である可能性を明らかにした。また、坪田らは、交差点の幾何構造に加え、交通流の観測データを導入した⁴。交通流は自由流状態、渋滞流状態、臨界流状態、混合流状態の4つに分類される。分析の結果、渋滞流状態と混合流状態で、事故リスクが増加し、特に追突事故の可能性が高いことを示した。これらの研究では、交差点の幾何形状から特徴量を抽出し、事故リスクの分析に用いている。一方、本研究では、ラスタ形式の道路地図画像を利用するため、事前に特徴量を抽出する必要はなく、任意の道路地図を対象に事故リスクの推定が可能であることが大きな特徴である。

近年、画像データの分類問題に、畳み込みニューラルネットワークが効果的であることが示され、交通や災害などの社会問題に応用する研究が報告されている。瀧本らは、ドライブレコーダで記録された映像に対し、畳み込みニューラルネットワークを拡張した手法を適用することで、交通事故に繋がるような危険なシーン(ヒヤリ・ハット)を抽出した⁵。また、利根川らは、被災地の航空画像に対し、畳み込みニューラルネットワークを適用し、高い精度で家屋倒壊の判別が可能であることを示した⁶。本研究においては、道路地図から生じやすい事故種別を推定するために、畳み込みニューラルネットワークを用いる。

3. データセットの構築

愛知県警察から提供を受けた交通事故データから、畳み込みニューラルネットワークに学習させるためのデータセットを構築する。交通事故データのレコードには、事故発生現場の緯度・経度、また、追突や出合頭などの事故種別が記録されている。データセットは、入力と正しい出力のペアで構成され、入力には事故現場周辺のラスタ形式の道路地図画像、また、出力には対応する事故種別を用いる。

ラスタ形式の道路地図画像の生成には、カスタム地図が生成可能なMapbox³を採用した。Mapboxのズームレベルを17に設定して、事故発生現場の緯度・経度を中心に、幅と高さが256ピクセルのラスタ形式(PNG)の画像を取得する。ズームレベルが17のとき、日本では1ピクセルが約0.457メートルとなるため、画像の

²<https://www.npa.go.jp/publications/statistics/koutsuu/toukeihyo.html>

³<https://www.mapbox.com/>

1辺は約117メートルに相当する⁴。図1に生成した画像の例を示す。道路領域は白、背景領域は黒の2値画像であり、建物や信号などの地図要素は含めないことにした。この画像を畳み込みニューラルネットワークの入力とする。



Fig.1 ラスタ形式の道路地図画像

ここで、2018年の事故種別ごとの事故件数を図2にまとめる。総数35,258件に対して、追突が13,845件、出合頭が9,790件、右左折時が3,880件となっており、全体の約78%を占めている。一般にデータが少ない場合は、畳み込みニューラルネットワークで正しく学習することが困難となる。そこで、本稿では、分類対象として、追突・出合頭・右左折時の3種類に絞ることにした。




Fig.2 事故種別ごとの事故件数 (愛知県・2018年)

2018年の交通事故データから、事故種別が追突・出合頭・右左折時である7,716件のレコードを抽出し、畳み込みニューラルネットワークのデータセットとした。データセットに含まれるサンプルの8割(6,172件)を訓練データ、残りの2割(1,544件)を評価データとして用いる。訓練データと評価データの事故種別の内訳を表1にまとめる。事故種別のサンプル数に偏りがある不均衡データであり、サンプル数が特に少ない右左折時が正しく学習できない可能性がある。本稿では損失関数に重みを設定することで、この不均衡データの問題の解決を図る。損失関数の詳細は後述する。

Table 1 訓練データと評価データのサンプル数

	追突	出合頭	右左折時	合計
訓練データ	3,203	2,102	867	6,172
評価データ	784	543	217	1,544

4. 畳み込みニューラルネットワークによる道路地図画像の学習

本章では道路地図画像から事故種別を分類する畳み込みニューラルネットワークの学習方法やパラメータについて述べる。

4.1 訓練データの事前処理

学習の収束性を向上させることを目的として、道路地図画像のサイズを幅と高さが32ピクセルとなるように縮小する。また、Mapboxで生成した画像は北が上方向に固定されているため、道路形状が同じでも向きが異なる画像を正しく学習できない。そこで、ランダムに画像を上下左右に反転させることで、画像の変種を作成し、学習時に用いる(データ拡張)。図3は、図1の画像に対して事前処理を施した結果である。左の画像は左右反転、右の画像は上下反転していることがわかる。




Fig.3 事前処理を施した道路地図画像

4.2 畳み込みニューラルネットワークの設計

採用した畳み込みニューラルネットワークの構成を図4に示す。畳み込み層・プーリング層のセットを2回繰り返す。全結合層を経て、3クラス(追突, 出合頭, 右左折時)の分類確率を出力する。最初の畳み込み層・プーリング層は、6種類の5x5のフィルタで構成され、最大プーリングにより14x14の画像に縮小する。2回目の畳み込み層・プーリング層は、16種類の5x5のフィルタで構成され、最大プーリングにより5x5の画像に縮小する。フィルタを適用する際のストライドは1、活性化関数はReLU(ランプ関数)を共通して用いた。最後の全結合層は、分類確率を出力するため、活性化関数にソフトマックス関数を採用した。




Fig.4 畳み込みニューラルネットワークの構成

⁴<https://docs.mapbox.com/help/glossary/zoom-level/>

4.3 畳み込みニューラルネットワークの学習

学習のための損失関数にはソフトマックス交差エントロピー、最適化関数には Adam⁷⁾ を採用した。ソフトマックス交差エントロピーは多クラス分類問題に適した評価指標であり、不均衡データに起因する学習の偏りを避けるため、各クラスに重みを設定する。ここでは、重みとして各クラスのサンプル数の逆比を用いる。サンプル数の最も多い追突の重みが 1.00 になるように正規化したところ、出合頭の重みは 1.52、右左折時の重みは 3.69 となった。これにより、追突や出合頭よりも右左折時の誤差が重視され、均一な学習が期待できる。また、バッチサイズが 256 のミニバッチ方式を採用し、200 回のパラメータの更新を繰り返す。

本稿では、研究の初期段階として、畳み込みニューラルネットワークを利用して、道路地図画像から事故種別の推定が可能であるかを検証することが目的であり、分類精度の最適化には固執しない。畳み込みニューラルネットワークの構成や、損失関数・最適化関数などのハイパー・パラメータの最適化は今後の課題としたい。

5. 実験結果と考察

本章では、上述の畳み込みニューラルネットワークに道路地図画像を学習させた結果について示し、事故種別の分類に影響する道路形状の特徴を考察する。

5.1 実験結果

学習過程における損失（ソフトマックス交差エントロピー）の推移を図 5、平均正解率の推移を図 6 に示す。実線は訓練データ、破線は評価データに対する結果を表している。訓練データに対する損失は学習の経過と共に、緩やかに減少するが、評価データの損失は 40 エポック付近で収束していることがわかる。同様に、訓練データの平均正解率は学習の経過と共に、緩やかに上昇し 75% を超えるが、評価データの平均正解率は 70% 前後で振動し、最終的に 72.5% で学習を終了した。評価データの平均正解率の低下は確認できないことから、オーバーフィッティングは生じておらず、訓練データに対し十分な学習ができたとみなせる。




Fig.5 損失関数の推移

表 2 に評価データにおける追突・出合頭・右左折時の適合率と再現率を示す。追突は適合率、再現率が共に




Fig.6 平均正解率の推移

80% を超えており、高い精度で分類が可能である。一方、右左折時の適合率、再現率は 40% 前後と低く、分類が難しいことがわかる。この原因として、右左折時の事故の要因が道路形状には大きく依存していない、または、右左折時の事故が追突や出合頭と同じような状況でも発生することが考えられる。また、右左折時はサンプル数が少なく、不均衡データであることも影響していると思われる。

Table 2 追突・出合頭・右左折時の適合率と再現率

	追突	出合頭	右左折時
適合率	81.8%	72.4%	39.2%
再現率	83.8%	69.2%	40.1%

表 3 に推定された事故種別に対する正誤表を示す。例えば、追突に分類された 804 件に対し、657 件は実際の追突事故の道路地図画像であり、91 件の出合頭と 55 件の右左折時の道路地図画像が誤って追突に分類されたことを表している。全ての事故種別において、正しく分類したケースが最頻値となっており、特定の事故種別を引き起こしやすい道路形状を学習できたと考えられる。一方、右左折時を出合頭に誤分類するケースが 75 件、逆に、出合頭を右左折時に誤分類するケースが 76 件と比較的多く、出合頭と右左折時の道路形状に類似性があることを示している。

Table 3 分類された事故・種別に対する正誤表

	追突	出合頭	右左折時
追突 (推定)	657 件 (正解)	91 件	55 件
出合頭 (推定)	68 件	376 件 (正解)	75 件
右左折時 (推定)	59 件	76 件	87 件 (正解)

5.2 道路形状に関する考察

ここでは、分類された道路地図画像を目視で確認し、追突・出合頭・右左折時の事故が生じやすい道路形状の特徴を明らかにする。

5.2.1 正しく分類された道路地図画像

最初に正しく分類された道路地図画像を目視で確認する。図7は、追突に正しく分類された道路地図画像の例である。事故発生地点である画像の中央には、直線的で幅員の広い道路が存在していることがわかる。追突の多くは速度超過が原因と考えられ、幹線道路など加速しやすい直線的な道路形状を特徴量として学習したと思われる。




Fig.7 追突に分類された道路地図画像

図8は、出合頭に正しく分類された道路地図画像の例である。追突とは異なり、幅員の狭い道路が占める割合が高い。また、画像の中央には、三叉路や四叉路の交差点が存在していることがわかる。出合頭の多くは見通しの悪い交差点で発生していると考えられ、路地裏などの幅員の狭い交差点の形状を特徴量として学習したと思われる。




Fig.8 出合頭に分類された道路地図画像

図9は、右左折時に正しく分類された道路地図画像の例である。出合頭と同様に、画像の中央には交差点が存在している。一方で、三叉路は少なく、四叉路が殆どであることが確認できる。また、幅員の広い道路と狭い道路が交差しているケースが多い。右左折時の事故の多くは、脇道から幹線道路への流入・流出時に発生していると考えられ、交差する道路の幅員の差を特徴量として学習することで、出合頭と区別していると思われる。




Fig.9 右左折時に分類された道路地図画像

5.2.2 誤分類された道路地図画像

次に誤分類された道路地図画像を目視で確認する。ここでは、特に誤分類が多かった右左折時に着目する。図10は、追突を誤って右左折時に分類した道路地図画像である。追突の特徴である幅員の広い道路が確認出来るが、右左折時の特徴である交差点が画像中央に存在しており、右左折時の特徴に近い。直線道路に比べ交差点内での追突事故は少ないと考えられ、道路地図画像のみでは判断が難しい。




Fig.10 追突が右左折に誤分類された道路地図画像

図11は、出合頭を誤って右左折時に分類した道路地図画像である。出合頭と右左折時の特徴である交差点が画像中央に確認できる。交差している道路の幅員は広く、出合頭に比べ、右左折時の特徴に近い。一般に幅員の広い道路には信号が設置されるケースが多いと考えられるが、これらの事故現場では信号が設置されておらず、出合頭の事故を誘発した可能性がある。




Fig.11 出合頭が右左折に誤分類された道路地図画像

以上の結果から、事故種別ごとに事故が発生しやすい道路形状が存在し、畳み込みニューラルネットワークで特徴量を学習することで、任意の道路画像に対しても、追突、出合頭、右左折時の推定が可能であると

言える。しかし、出合頭と右左折時のように道路形状だけでは分類が難しいケースが存在し、分類精度には限界がある。分類精度を向上させるには、信号の有無や道路の勾配などの情報を新たに考慮することが必要になるであろう。

6. まとめ

本稿では、愛知県における交通事故の防止を目的とし、愛知県警察から提供された交通事故データから事故現場周辺の道路地図画像を生成し、追突・出合頭・右左折時の事故が発生しやすい道路形状の特徴を畳み込みニューラルネットワークに学習させた。学習した畳み込みニューラルネットワークを用いることで、任意の道路地図画像に対して、追突・出合頭・右左折時の事故の起こりやすさを推定可能である。追突は高い精度で分類可能であるが、出合頭と右左折時は特徴が似ており、誤って分類するケースも多く確認された。畳み込みニューラルネットワークの構成や、ハイパー・パラメータの最適化により、ある程度の分類精度の向上が可能であると思われる。しかし、2値で表現された道路地図画像だけでは、精度向上には限界がある。そこで、今後は、信号の有無や道路の勾配などの特徴量を新たに訓練データとして整備することが必要だと考えている。信号が設置されている場合、出合頭の事故の多くは防げることが予想され、本稿では分類が難しかった出合頭と右左折時を区別する鍵になる可能性がある。また、一般に車両は上り坂では遅く、下り坂では速くなることが考えられ、道路の勾配を考慮することで、事故の重傷度（死亡、重傷、軽傷）の分類が可能になるかもしれない。将来、本研究の成果を愛知県警察にフィードバックし、愛知県における交通事故の削減に貢献できれば幸いである。

謝辞

本研究は名古屋大学未来社会創造機構 HMI・人間特性研究部門の「エージェントを介した運転支援研究プロジェクト」と、愛知大学経営総合科学研究所の共同研究プロジェクト「人工知能と地理情報システムを用いた愛知県の死亡事故データ分析」の助成を受けている。また、本研究に必要な交通事故データをご提供頂いた愛知県警察に深く感謝する。

参 考 文 献

- 1) 渡部数樹, 中村英樹. 道路交通環境に着目した交通事故発生要因に関する統計モデル分析. 土木学会論文集 D3 (土木計画学), Vol. 71, No. 5, pp. 889–901, 2015.
- 2) 兵頭知, 吉井稔雄. センサス道路における時間帯交通量別交通事故リスク分析. 土木学会論文集 D3(土木計画学), Vol. 72, No. 5, pp. 1283–1291, 2016.
- 3) 塩見康博, 渡部数樹, 中村英樹, 赤羽弘和. 交差点幾何構造を考慮した幹線道路信号交差点における交通事故リスク要因の分析. 土木学会論文集 D3 (土木計画学), Vol. 72, No. 4, pp. 368–379, 2016.
- 4) 坪田隆宏, 吉井稔雄, XING Jian. 交通流状態と幾何構造を考慮した都市間高速道路の事故発生リスク分析. 交通工学論文集, Vol. 5, No. 2, pp. 199–207, 2019.
- 5) 瀧本祥章, 山本修平, 松林達史, 倉島健, 戸田浩之. 敵対的学習に基づくドメイン適応によるドライブレコーダを用いたヒヤリハットの検出および分類. 情報処理学会論文誌データベース (TOD), Vol. 13, No. 3, pp. 1–9, jul 2020.
- 6) 利根川凜, 飯塚博幸, 山本雅人, 古川正志, 大内東. 被災がれき量推定に向けた畳み込みニューラルネットワークを用いた倒壊建造物の自動抽出. 情報処理学会論文誌, Vol. 57, No. 6, pp. 1565–1575, jun 2016.
- 7) Diederik P. Kingma and Jimmy Ba. Adam: A method for stochastic optimization, 2014. cite arxiv:1412.6980Comment: Published as a conference paper at the 3rd International Conference for Learning Representations, San Diego, 2015.