

機械学習を用いた危険運転検出システムの設計

2016SE089 和田蓮 2016SE096 横井太一

指導教員：野呂昌満

1 はじめに

近年では、交通事故を減らすために安全運転支援の研究が盛んに行われている。例えば、自動ブレーキ、誤発進抑制制御機能、車線逸脱警報装置、自動切換型前照灯や車間距離制御装置が開発されている。これらにより、事故が発生した時の被害は軽減されている。本研究において危険な状況とは、事故に至る可能性があったが、事故に至る前に発見されて防ぐことができた場合のことである。本研究では、前方車両を車載カメラの動画から事前に危険を予測することにより、事故を未然に防ぐことを目的に研究を進める。

これまでの研究 [2] では、事故が発生する直前に危険事象を判断・分類しており、危険運転を予測することはできない。現在の自動運転に用いられている技術では、重大な事故には至らなかったものの、それに直結してもおかしくない一歩手前の出来事などの危険事象が発生する直前に検知される。直前でしか特定できない危険事象を、システムがより早い段階で事前に予測できれば、乗員の安全性を確保した上で危険を回避することが可能となる。

本研究の目的は、危険察知を学習対象とし、適切な時機での適切な判断を行う判定器を設計、実現することである。この目的を達成することで、危険事象が起こるより前の段階でドライバーに注意を促し、危険を回避できるようになることが期待できる。本研究での危険察知とは、運転中に遭遇する危険状況を察知することである。設計した後、判定器の妥当であるかの検証を行う。危険な状況に至る前の状況を学習する学習及び、判定器を作成し判定を行う。これで得た結果を基に、本研究に対する考察を行う。

本研究での技術課題は以下の三点である。

1. 前方車両の動画の分類の定義
2. ニューラルネットワークの設計
3. 設計した判定器の妥当性の検証

本研究の着想に基づきこれらの技術課題を解決することで、前方車両の危険を予測し、危険事象が起こる前の段階で注意を促すことが可能になる。

2 関連研究

三井 [2] らは、車載カメラの動画を CNN を用いた自動車の事故リスク（危険度）を分類し発見することに重きを置いている。車載カメラの動画において、自動車同士の事故危険度、すなわち事故リスクを三段階でレーティングすることを目的としている。

小平ら [11] は、ドライブレコーダーによって記録される映像データのフレーム画像のクラス分類において、クラスの持つ特性に沿った分類を提案している。ドライブレコーダーデータで記録されたイベントデータに対してヒヤリハットの危険度を推定することを目的にフレーム画像から推定方法を提案している。

ドライブレコーダーの映像データを対象とした研究について、車両の前方映像は、近年、自動車の自動運転に関する研究で幅広く利用されている。これらのシステムは、事故や事故を起こす前兆などの危険事象が発生する直前に検知される。前述したように、前方車両の予期できない突然の危険事象を回避する場合は、急激な制動や操舵が必要となり、乗員を危険にさらす可能性が生じる。したがって、より早い段階で危険を予測することが本研究の課題である。

3 技術課題の解決

前述した三つの技術課題の解決方法について述べる。

3.1 前方車両の動画の分類の定義

本研究では、自車の運転中に前方に車が走行している場面について状況判断を行う。車載カメラの映像において、前方車両の走行状態を安全（通常時）と注意（危険要因が出現）の二種類に分類する。本研究における「安全」と「注意」の分類について、動画サイト YouTube に公開されている自動車事故の際の車載カメラの動画をもとにシミュレーションを用いて作成した動画を「安全」と「注意」にラベリングする。シミュレーションを用いて動画を作成するのは、前述したように、実際に車を運転して危険運転を再現するのは困難であることから、その場面をシミュレーションを用いて再現し、それを判定器のデータとして扱う。本研究における「安全」とは、前方車両から影響を得ることなくドライバーがハンドル操作やブレーキ操作をとっさに行うことなく走行できる状態を表す。「注意」は、前方車両の走行により安全とは違い、ブレーキ操作やハンドル操作を行わなければ事故になりうる可能性がある状況を表す。

本研究では、前方車両の動画を「安全」と「注意」と分類することにより、危険と判断する前の状況をシステムに判断させ、事故を未然に防ぐことができると考えている。

3.2 ニューラルネットワークの設計

前方車両の画像を分類するために、CNN を用いて判定器を設計する。

前方車両の動画の学習について、動画における特徴量を抽出するために、1秒の動画を10フレームにラベル付けたデータを入力して学習させる。本研究では学習データにあらかじめ正解ラベルをつけて学習させるニューラル

ネットワークの教師あり学習である。入力に著者らが「安全」「注意」とラベル付けしたデータを入力し学習させる。CNNは自身でデータから対象の特徴を抽出することができるので、本研究での画像解析に適していると判断した。

設計するニューラルネットワークの出力について、本研究では「安全」と「注意」の二ラベルを分類し出力する。

3.3 設計した判定器の妥当性の検証

シミュレーションで実際に走行している形の動画データをもとに学習を行なった判別器が適切な時期での適切な判断を行なっているかを確認する。学習に必要なデータだが、YouTubeでは動画の数に限界があるがシミュレーションを用いることで、大量に必要な前方車両の動画を作成することができる。作成したデータは、「安全」、「注意」と判断されるような動画データを作成した。

学習を行っていくうえで、本研究では、安全114個、注意113個の合計227個の動画からそれぞれを1秒につき10フレームの画像に分けて学習を行った。検証を行う際、判定器を作成し、学習では用いてない動画のフレーム画像から安全、もしくは注意に正しく判別できるか確認する。

4 判定器の構成

図1に本研究で設計するニューラルネットワークの判定器の構成を示す。




図1 判定器の構成

入力データの分類を行うために構成した要素について以下で述べる。

4.1 CNNの構成

画像データの学習を行うために動画をフレームに分け画像認識を行い、畳み込みを行うことで特徴を抽出し、「安全」や「注意」に判別することができるCNNを用いる。今回研究を行っていくうえで、畳み込みのフィルタサイズだがいずれの層も 3×3 、 5×5 の2パターンで試行する。サイズが大きいときと小さい時でより精度の高いものを探す。

Pooling層のフィルタサイズについて、サイズを大きくすると粗い特徴になるだけでなく、画像サイズからはみ出る可能性があるため、本研究では 2×2 のみで構成する。またMaxPoolingを行うことで特徴の小さな変化も見逃すことなく特徴を抽出することができる。ここで畳み込み

層とPooling層の間の活性化関数はReLU関数を用いる。ReLU関数は勾配消失問題を解消し処理が速く、出力が0以下は常に0となるので精度が向上しやすい。

全結合層1では一次元配列に変換し、全結合層2ではクラス数である二クラスに分類する。全結合層2の出力にSoftMax関数を用い、そのクラスに分類される確率を出力する。SoftMax関数を出力層の活性化関数に用いることで、ニューラルネットワークの出力があるクラスに属する確率を表しているとして学習させることができる。

4.2 パラメータの推定

本研究におけるCNNの設計にあたり、パラメータを推定する。

損失関数には、機械学習における分類問題において計算効率が良い交差エントロピーを用いる。最適化アルゴリズムはAdamを用いる。Adamは、小さな極小値に陥ることなく最小値を目指す計算手法である。さらにパラメータ毎に最近の勾配の値に比べて、大きかったのか、小さかったのかを考慮したパラメータ更新をおこなうことでパラメータ毎に適切な更新ができる。評価関数にはAccuracyを用いる。Accuracyは正解率で、予測結果全体に対して、予測が正しい割合を表す。

5 実装

実験に必要なデータの収集方法と判定器の実装方法について以下に述べる。

5.1 データの収集方法

学習を行うのに必要な前方車両の動画データをシミュレーションを用いて集める。実際に運転して前方車両の危険動画を集めることは困難であることから、本研究で分類を行う「安全」と「注意」の二種類の運転を再現したシミュレーションを作成する。

シミュレータの実装は、総合開発環境Unityを用いた。シミュレータ内の車両の実装にあたり、Unityが作成し、提供するStandard Assets Packageに実装されているStandardAssets/Vehicles/Carを利用した。再現動画の作成にあたり、動画サイトYOUTUBEに公開されている自動車事故の車載カメラの動画を参考に作成した。

本研究では、前述したように、シミュレーションを用いてデータを用意した。本研究で使用した動画数は、「安全」114件、「注意」113件の計227件、動画のフレーム画像のデータ数は、「安全」を1140個、「注意」を1130個の計2270個である。データセットの約1/4をテストデータ、残りを訓練データとして実験を行う。

5.2 判定器の実装

学習モデルの実装を行なうためにPythonを選択した。Pythonには多くのライブラリが用意されており、高度な数値計算やデータ分析、機械学習などが用意にできるようになっている。

前述した判定器の実装にあたり、深層学習のライブラリである Keras を用いた。Keras には、ニューラルネットワークの構築、学習アルゴリズムの決定、学習、予測など様々なメソッドが定義されており、これらを用いることで容易に実装が可能となった。

学習は Keras の models クラスで定義されている fit メソッドを用い、学習に用いるデータとバッチサイズ、エポック数を引数として与えることで学習を行なった。今回は、学習に用いられるデータが少ないことから、バッチサイズを小さい数で二パターンに分けて設定し実装した。

5.3 実装の概要

本研究では、ニューラルネットワークの設計にあたり中間層のユニット、バッチサイズ、エポック数、フィルタサイズを実験にて決定した。一般に、中間層のユニット数を増やすことでニューラルネットワークは複雑になり、分類精度は上がる。しかし、ニューラルネットワークを複雑にしすぎると、過学習が発生し分類精度は下がる。したがって、中間層のユニット数を変更しながら、分類精度の高い値を見つける必要がある。中間層のユニット数とハイパーパラメータを以下の値で実験を行った。

表 1 に中間層のユニット数とハイパーパラメータの組み合わせを示す。

表 1 ハイパーパラメータの組み合わせ

ユニット数	50	80	100
バッチサイズ	32	64	
エポック数	100		
フィルタサイズ	3 × 3	5 × 5	

実験では上記に指定したユニット数、バッチサイズ、エポック数、フィルタサイズを組み合わせで行う。

5.4 実験結果

表 2 に実験の結果である最適な組み合わせの結果を示し、図 2 と表 3 に精度と損失の結果を示す。図 3 から、損失関数は 0 に近づき、精度は 1 に近づいていることから学習は失敗していないことが分かる。学習が 20 回を超えるあたりには、損失関数と精度はともによくなり、それ以降直線に近く減少はほぼない。全ての組み合わせを行った結果から、中間層のユニット数を増やすことでニューラルネットワークの分類精度は上がった。しかし、中間層のユニット数を増やしすぎるとニューラルネットワークが複雑になり過学習が発生し分類精度は下がった。

判定器の妥当性を確かめるために、学習に用いた画像データとは別の画像を「安全」50 枚と「注意」50 枚の合わせて 100 枚を、各組み合わせのニューラルネットに入力した。分類の結果、最も精度の良い組み合わせの時に、「安全」が 39 枚、「注意」が 61 枚という最も良い分類結果になった。「安全」に分類されるべき画像のうち、35 枚が正しく分類された。残りの 4 枚は「注意」に分類されるべき

画像から「安全」に誤って分類された。「注意」に分類されるべき画像のうち、46 枚が正しく分類されたが、15 枚が「安全」に分類されるべき画像から誤って分類された。

表 2 最適な組み合わせの結果

ユニット	バッチ	エポック	フィルタサイズ
80	64	100	3 × 3




図 2 学習の精度と損失

表 3 テストデータの損失値と精度

損失値	0.020137
精度	0.986207

6 考察

これまでの成果から本研究の評価をする。以下 6.1 節では実験に対する考察を、6.2 節では本研究の目的を達成しているか研究の総括として述べる。

本研究では、前方車両の危険運転に対して、適切な時機での適切な判断を行うことを目的とした。この目的を達成することで、危険事象が起こる前の段階でドライバーに注意を促し、危険を回避できることを期待し、前述した三つを技術課題とした。

以下本章では、実験結果と本研究の目的に対する考察を述べる。

6.1 実験結果に対する考察

実験結果の図 2、表 3 について考察を述べる。本研究の実験結果から、分類するにあたり十分に学習できていると考える。実験を通して、損失関数と評価関数の推移を確認した結果、表 2 の組み合わせで最も学習が収束し、98 % の精度を得ることができた。このことから、本研究における危険な状況に至る前の状況で「安全」と「注意」の状況の学習は成功したと言える。

表 4 は、実際に学習用データとは別の「安全」に分類されるべき 50 枚と「注意」に分類されるべき 50 枚合わせて 100 枚を判別器に入力した結果である。判定の結果から、中間層のユニット数とハイパーパラメータの組み合わせによる学習の精度がより高いほうが、より正しい判定を行うことができた。「安全」に分類されるはずの画像データが「注意」に分類されたが、二種類の画像データをさらに増やすことにより精度が増すと考える。「安全」から「注意」、

「注意」から「安全」に誤って分類された画像の多くは、「安全」である範囲と「注意」である範囲のどちらとも言えない曖昧なものが確認できた。「安全」を「注意」に分類されることは事故につながりにくい、「注意」を「安全」に分類されることは、事故につながりうる可能性が上がってしまう。誤って分類された画像は、画像だけでは「安全」か「注意」か断言できるものではなかった。動画の1フレーム画像だけでは正しく判断できない状況は、画像の前後関係、つまり「安全」と「注意」のそれぞれの時系列データを考慮することにより、この問題が解決できると考える。「安全」に分類される条件と「注意」に分類される条件を増やすことで、動画データだけでは判断が困難なタイミングをより正しく分類し判断することが可能であると考えられる。本研究では、動画のフレーム画像を入力として画像認識を行ったが、時系列を考慮したRNN(LSTM)を用いることで動画の前後関係からも分類を行っていけると考えている。

表4 評価指標

	真値が安全	真値が注意
予測が安全	35	4
予測が注意	15	46

6.2 総括

本研究の成果について、本研究の目的である前方車両の動画の適切な判断は精度が十分でない。判定器を用いて判定を行ったが「安全」50枚と「注意」50枚のすべてが正しく分類されなかった。その原因として、学習するにあたってデータ数が少ない点が主な原因である。

実際に運用するにあたり、自動車が走行中にいち早く正確な判断をする必要があるために、処理要求があったときにどの程度の時間で処理に取り掛かることができるか、要求された処理を済ませるのに必要な処理時間はどれくらいかを考慮したリアルタイム性が必要となってくる。

本研究では、時系列を考慮したRNNモデルを使用する前の段階であるCNNを用いて、動画をフレーム画像に分割しそれぞれについて学習し分類を行うところまでしかできていないが、前方車両のフレーム画像を「安全」と「注意」に分類されるところまで行った。

学習の精度が高まり、プログラムの判別結果をドライバーの判断に近づけていくことが出来れば、完全自動運転車におけるシステムが行う危険予測の実現にも応用することが可能になる。

7 おわりに

本研究では、前方車両を車載カメラの動画から事前に危険を予測することにより、事故を未然に防ぐことを課題とした。

本研究では、危険察知を学習対象とし、適切な時期での適切な判断を行う判定機を設計し実現することを通して、

危険察知技術について考察することを目的とした。

本研究の課題を解決するにあたって、前方車両の動画を「安全」と「注意」の二種類に分類するモデルを実現した。分類、学習するにあたってCNNを用いたニューラルネットワークを設計した。

作成した判定器を用いて判定の結果に基づいて妥当性の検証を行った結果、7割が正しく判定され精度は十分ではない。

今後の課題として、RNN(LSTM)等を用いて時系列を考慮したモデルを使用することや、本研究では入力データに画像だけを用いたが、より多くの情報を考慮することができればより精度の高いモデルの実現が可能であると考えられる。

参考文献

- [1] Karen Simonyan, Andrew Zisserman: “Two-Stream Convolutional Networks for Action Recognition in Videos”, Visual Geometry Group, University of Oxford, 2014.
- [2] 三井弘希, 王, 加藤ジェーン, 間瀬健二: “車載カメラ映像における危険の検知”, 情報処理学会第79回全国大会 [名古屋大学], 2017.
- [3] 内閣府, 令和2年版交通安全白書, 2020.
- [4] Driver JOB, “国内メーカー運転支援システム徹底比較! 各社システムの特徴をご紹介!”, 2020.
- [5] 国土交通省自動車局, “自動運転の実現に向けた国土交通省の取り組みについて”, 2019.
- [6] 豊田正史, 横山大作, 伊藤正彦: “運転状況を考慮したドライブレコーダデータからの潜在リスク交差点検知手法”, DEIMForum 2017.
- [7] Lam, H.T.: “A Concise Summary of Spatial Anomalies and Its Application in Efficient Real-time Driving Be-haviour Monitoring”, SIGSPATIAL, pp. 30: 1-30.9, 2016.
- [8] Yokoyama, D., Toyoda, M. and Kitsuregawa, M.: “Understanding Driver”: Safety by Fusing Large Scale Vehicle Recodesr Dataset and Heterogeneous Circumstantial Data, PKDD, pp. 734-746 2017.
- [9] 菊池理人, 日景由華, 御室哲志: “ドライブレコーダデータからの自動分布の試み”, 計測自動制御学会東北支部第290回研究集会, 2014.
- [10] 森村哲郎, 谷澤悠輔, 山崎慎也, 井手剛: “統計的機械学習を用いたプローブカーデータからのヒヤリハット発生形態の推定”, 自動車技術会秋季学術講演会, 2011.
- [11] 小平美沙季, 山本修平, 倉島健, 戸田浩之, 加藤ジェーン: “ドライブレコーダデータに対するヒヤリハット危険度推定”, DEIM Forum 2019.