

機械学習を用いた危険運転検知システム

2018SE014 早川智紀 2018SE017 本多優斗 2018SE046 水野彌的

指導教員：沢田篤史

1 はじめに

近年では、様々な運転支援システムの導入や研究がされている。その中でも自動ブレーキや自動運転システムなどと組み合わせて事故を防止する危険運転検知システムが注目されている。現在の危険運転検知システムに関する研究では機械学習を用いた設計手法が注目されている。これは危険運転の膨大に存在するパターンに対して手動で危険運転検知のプログラムを組むことは対応できる状況に限界があり、閾値などの設定も難しく現実的ではないという背景がある。そこでデータセットを用意し、CNNなどの機械学習によって危険運転のパターンなどを学習させることで判定をさせる手法 [1][2] が研究されている。

機械学習を用いた危険検知システムの課題として、危険運転を行う車両は相対動作の軌跡の情報が機械学習の学習データに考慮されていないことが挙げられる。危険運転を行う車両は、相対動作の軌跡が安定しないという特徴がある。これを検知する機械学習機を作成するには、画像内の物体の軌跡の変化に柔軟に対応させるための工夫が必要である。

本研究の目的は、車載カメラ映像で捉えることができる前方車両の急な加減速などの危険運転に対して、物体の軌跡も考慮した危険運転検知システムの実装及び考察することである。現在ドライブレコーダーは一般の自動車にも普及しつつあるので、カメラ映像からの検知を行うことは実用的に意味がある。本研究で提案するシステムは天候が安定しており、車両前方の見通しが良い状態での運用を想定している。機械学習器は事前に学習させ、リアルタイムでの学習は行わない。

本研究では、動画像間の物体の動きを変位ベクトルで表現する技術であるオプティカルフローを機械学習と組み合わせて危険運転検知システムを設計することを提案する。オプティカルフローを機械学習器へ入力する前処理として利用することで画像内の物体の軌跡の変化に柔軟に対応できると考えた。また、機械学習で利用するニューラルネットワークにはデータの時系列を考慮して危険の予測ができるLSTMを選択する。これにより、危険運転の前動作パターンからも危険を予測することができるようになると考えた。

本研究では提案した手法に対してPythonを用いて実験を行った。その結果として過学習を引き起こしてしまったのでこのことに対する原因や対策などを考察した。

2 危険運転の自動検知技術とその問題点

2.1 既存研究

北垣ら [1] の研究では、車載カメラ映像からCNNを用いて事故リスクを「安全」、「注意が必要」、「危険」の3段階にレーティングを行っている。最終的な分類精度は50%程度であった。また、この研究では衝突の寸前の画像もデータセットに含まれているので正確に検知できた場合でも事故を防げない可能性がある。

和田ら [2] の研究では、事故の原因となる実際の動画を参考にし、その動画の再現をUnityで作成することでデータセットを作りCNNに入力データとして入力し、「安全」と「注意」の2種類に分類する手法を挙げている。分類精度は70%であった。しかし、データセット作成にUnityを利用しているので実際の車載カメラでの高速で動く背景や歩行者などの情報が無く、現実の危険運転の検知とは精度が異なると考えられる。

飯森ら [3] の研究では、LiDARからのデータを二次元データに変換しCNNへ入力することで前方の物体を歩行者、自動車などにクラス分けをした後に、それぞれの特徴量を得ることで周辺状況を検知するアーキテクチャを提案している。分類精度は70%~80%であった。この研究は自動運転のための危険検知に重きをおいているので、車載カメラでの検知と比較した際に前提となるコストが大きいという課題がある。

車載カメラ映像での既存の研究での課題として前方車両の軌跡の情報を加味しての学習がされていないことが挙げられる。前方車両が危険運転を行った場合には自車とは異なる挙動を取り、車載カメラ内では前方車両が左右に動いたり、拡大縮小されているように見えるので相対動作の軌跡が乱れているといえる。しかし、車載カメラ映像を用いた既存研究では前方車両の検出や追跡などの操作はしていない。本研究では機械学習を行う際に軌跡の情報を含めたデータセットを利用することでこの課題を解決しようと考えた。

3 オプティカルフローを組み合わせた危険運転検知システム

3.1 オプティカルフローについて

オプティカルフローは、動画像から物体の動きを二次元変位ベクトルで表現することができる技術である。オプティカルフローには全画素に対して計算を行い変位ベクトルを求める密なオプティカルフローと、特徴点に対して計算を行い変位ベクトルを求める疎なオプティカルフローがある。

本研究では密なオプティカルフローでは Horn-Schunck 法 [4], 疎なオプティカルフローでは Lucas-Kanade 法 [5] を利用する. また, 特徴点の取得には Shi-Tomasi コーナー検出法 [6] を利用する. Shi-Tomasi コーナー検出法は画像内にあるエッジを検出する方法である.

3.2 システム全体の概要

提案するシステムはオプティカルフローを前処理として機械学習を行い, 自車両前方の危険運転を検知するシステムである. 本研究では, 運転者がハンドル操作やブレーキなどの回避行動をとらなければ事故に発展しうる他車の挙動を危険運転と定義する. データセットにより事前学習をさせシステムの運用時のリアルタイム学習は行わない. また本研究では, 天候が安定しており車両前方の見通しが良い状況での運用を想定している.

3.3 システムのプロセス

図 1 はシステムの構成図であり, 本研究における危険運転検知システムの構成は以下の 3 ステップからなる.

- (1) 画像データの取得
- (2) 軌跡計算サブシステムへの適用
- (3) 危険判定サブシステムへの適用

(1) について, 車載カメラから得た映像をフレームごとに分けて利用する. 学習時にはオープンデータセットや動画投稿サイトから学習用データセットを作成する.

(2) について, 取得した画像データに対しオプティカルフローを利用し変位ベクトルを取得する. オプティカルフローは直接物体の検出や種類の識別などをする技術ではないので, 高速に動く背景が前方に存在する車両の変位ベクトルデータと混在することになる. 最終的な分類精度に影響があると考えた. そこで通常の密なオプティカルフローと疎なオプティカルフローの 2 つの方法で実装を行う.

(3) について, 事前に学習された LSTM に変位ベクトルデータを入力することで危険運転の検知を行う. LSTM のパラメータは損失関数に交差エントロピー誤差, 最適化関数に Adam, 評価関数に accuracy, 活性化関数に tanh 関数を選択した.




図 1 システムの構成図

4 実験の内容と結果

本研究では, Lucas-Kanade 法により計算されたベクトルデータと Horn-Schunck 法により計算されたベクトル

データの 2 つのデータをそれぞれ LSTM と組み合わせて, 自車前方の危険運転を予測する実験を行った.

4.1 データセットの作成

本研究で使用する画像は, KITTI データセット及びドライブレコーダーの映像が投稿されているウェブサイトから得られた映像を 1 秒間あたり 10 フレームに分けた画像を使用した. 以下にデータセットの作成手順を示す.

- (1) 連続画像 50 枚に対して, Lucas-Kanade 法/Horn-Schunck 法を適用し変位ベクトルの計算を行う.
- (2) 得られたベクトルデータを CSV ファイルに書き出す.
- (3) CSV ファイルを安全, 危険の 2 つの CSV ファイルにまとめる.
- (4) 安全, 危険の 2 つの CSV ファイルをそれぞれ読み込む.
- (5) 2 つの CSV ファイルに対して安全なら 0, 危険なら 1 のラベルをそれぞれに付ける.
- (6) ラベル付けしたデータを npy ファイルにまとめる.

本研究では, 上記の手順により安全なデータ 50 件, 危険なデータ 50 件と安全なデータ 75 件, 危険なデータ 50 件の 4 パターンのデータセット作成した.

4.2 Lucas-Kanade 法と LSTM の実験結果

本研究では, Lucas-Kanade 法を用いた軌跡計算サブシステムによるベクトルの計算を行い, 得られたデータを危険判定サブシステムの LSTM に適用することで危険運転の予測を行った. LSTM の学習結果をデータセットのデータ数に分けて図 2 と図 3 示す.




図 2 Lucas-Kanade 法の accuracy の学習結果 1

図 2 は, 安全なデータ 50 件, 危険なデータ 50 件の時の Epoch 回数あたりの accuracy 推移を表している. Epoch1 回目のトレーニングデータの accuracy の数値は, 0.4054 となった. この時のテストデータの accuracy の数値は 1.0000 となっており, 過学習を起こす結果となった. Epoch2 回目以降のトレーニングデータの accuracy の数値は 1 回目よりも 0.0135 上昇した. テストデータの accuracy の数値に変動はなかった. loss は最後まで nan のままだった. 図 3 は, 安全なデータ 75 件, 危険なデータ 50 件の時の Epoch 回数あたりの accuracy の推移を表している. Epoch1 回目のトレーニングデータの accuracy の数値は, 0.4362 となった. この時のテストデー




図3 Lucas-Kanade 法の accuracy の学習結果 2

タの accuracy の数値は 1.0000 となっており、過学習を起こす結果となった。Epoch2 回目以降のトレーニングデータの accuracy の数値は 1 回目よりも 0.1064 上昇した。テストデータの accuracy の数値に変動はなかった。loss は最後まで nan のままだった。

4.3 Horn-Schunk 法と LSTM の実験結果

本研究では、Horn-Schunk 法を用いた軌跡計算サブシステムによるベクトルの計算を行い、得られたデータを危険判定サブシステムの LSTM に適用することで危険運転の予測を行った。LSTM の学習結果をデータセットのデータ数に分けて図 4 と図 5 示す。




図4 Horn-Schunk 法の accuracy の学習結果 1

図 4 は、安全なデータ 50 件、危険なデータ 50 件の時の Epoch 回数あたりの accuracy の推移を表している。Epoch1 回目のトレーニングデータの accuracy の数値は、0.4498 となった。この時のテストデータの accuracy の数値は 1.0000 となっており、過学習を起こす結果となった。Epoch2 回目以降のトレーニングデータの accuracy の数値は 1 回目よりも 0.0007 下降した。テストデータの accuracy の数値に変動はなかった。loss は最後まで nan のままだった。図 5 は、安全なデータ 75 件、危険なデー




図5 Horn-Schunk 法の accuracy の学習結果 2

タ 50 件の時の Epoch 回数あたりの accuracy の推移を表している。Epoch1 回目のトレーニングデータの accuracy

の数値は、0.5590 となっている。この時のテストデータの accuracy の数値は 1.0000 となっており、過学習を起こす結果となった。Epoch2 回目以降は両方とも accuracy の数値に変動はなかった。loss は最後まで nan のままだった。

5 考察

5.1 実験結果の考察

実験の結果から今回の学習用データ、機械学習器の設計では過学習を起こしていると考えられる。過学習が起きると学習データ全体のパターンや規則性を学習することができず、新しいデータに対して十分な予測ができない。対策としては学習用データ数を増やす、ニューラルネットワークのモデルを簡易的なものを利用することのどちらかが必要であると考えられる。

5.2 オプティカルフローから LSTM への入力について

本研究でのオプティカルフローの扱いについて考察をする。実験では全画素について計算する方法とエッジ周りの特徴点を取得して特徴点に対して計算する方法を実装したが、背景処理はせずに機械学習器へ入力した。全画素についてのオプティカルフローだけではどこに前方車両が存在しているのかが分からなく、このことが危険運転検知に影響する可能性を考慮して、特徴点を取得し疎なオプティカルフローを用いての検知も目指した。しかし、特徴点は前方車両も検出しているが、背景となるものも多数検出しているので変位ベクトルデータに変換した際には背景と前方車両の区別ができなくなっている。

密なオプティカルフローについて、密なオプティカルフローを用いて全画素に対して変位ベクトルを求め、変位ベクトルの結果のみをもとに前方車両以外の背景などを消すのは難しい。オプティカルフローを利用した背景差分を取得する研究としては笠原ら [7]、熊野ら [8] などがあるが、精度、使用機器などの前提条件、計算コスト、前方車両と歩行者など複数の移動物体が存在する場面に対応できるかなど課題が多くある。

疎なオプティカルフローについて、Lucas-Kanade 法により変位ベクトルデータを取得するために Shi-Tomasi 法でコーナー検出を行うことで最大で 100 個の特徴点を取得して特徴点を追跡する形で変位ベクトルを計算したが、全画像データに対して特徴点を 100 個取得するとは限らなかった。本研究の実装では LSTM に入力するにあたり、データ毎に取得できた特徴点の数がデータ毎に異なり、サイズが異なっていると上手く入力することが出来なかった。そこで検出した特徴点が 100 個に満たない数だけ変位ベクトルデータに null を加えてサイズを揃えて機械学習器へ入力した。本研究では過学習が起きてしまい動くものを実装することはできなかったが、ベクトルデータに null を加えて学習することで現実の危険運転を検知する際に影響の出る可能性がある。

5.3 より良い危険運転検知システムのために

本研究の実験方法や実験結果から考察をして機械学習器を実装する際の過学習の問題やオプティカルフローを推定する際の背景処理に課題があることが分かった。また、課題の対策なども考察したのでその課題を解決して評価実験まですることのできる危険運転検知システムを実装し、オプティカルフローの有用性を検証する必要がある。

本研究の手順とは別で CNN を用いた手法も考えられる。オプティカルフローで推定した変位ベクトルをカラーコード化し画像にすることができる。その画像にラベル付けをして CNN へ入力することで危険運転の検知を行い、評価実験などを行うことでオプティカルフローの有用性を検証することができる。

6 おわりに

近年では交通事故を防止するための様々な運転支援システムの導入や研究がされている。事故の原因には運転者の操作ミスや他車の危険行為や事故に巻き込まれたりなどがあり、それに対してシステムがブレーキなどに介入したり、運転者に警告をすることで事故を未然に防ぐものがある。そして、これらを上手く利用するには事故の原因となりうる危険を検知しなければならない。そこで本研究では前方車両の危険運転検知システムについての研究を行った。

現在の危険運転検知システムの設計に関しては機械学習を用いた手法が注目されている。これは事故の原因となる要因は様々であるが、前方車両の危険運転に限ってもそのパターンは膨大であるので、手動で1つ1つ対応させるプログラムを組むのは現実的ではない。そこでデータセットを用意して機械学習器に膨大に存在するパターンを学習させて危険を検知する手法が研究されている。

機械学習を用いた危険運転検知システムにおいて、機械学習用のデータセットに前方車両の軌跡の情報が含まれていないことが課題としてある。これは危険運転を行う車両には相対動作の軌跡が安定しないという特徴があると考えられる。前方車両の軌跡の情報を加味して機械学習を利用しなければ現実の危険運転には対応できない可能性もある。

本研究の目的は、物体の軌跡も考慮した機械学習器により車載カメラ映像で捉えることができる前方車両に対する危険運転検知システムを実装、考察することであった。すでに多くの車両に導入されているドライブレコーダーを利用して危険運転を検知することに実用性があると考えた。車載カメラ映像から前方の状況が把握できるよう、天候が安定しており見通しが良い状況の運用を想定した。機械学習器は事前に学習させリアルタイム学習は行わなかった。

本研究では、機械学習の前処理として動画像間の物体の動きを変位ベクトルで表現するオプティカルフローを利用する危険運転検知システムを提案した。オプティカルフローを利用するにあたり、高速に動く背景が危険運転の分

類精度に影響する可能性を考慮して画像中の全面素を計算する方法とエッジ周りを抽出して計算する方法の2つで比較することを提案した。また、機械学習のモデルはLSTMを選択し、オプティカルフローで計算された変位ベクトルをもとに危険運転の前パターン動作からも検知できるよう考えた。

提案したシステムに対して Python で機械学習器を作り、実験を行ったが過学習を起こしてしまった。過学習になってしまった原因にはデータの不足などが挙げられる。本研究の実験で正答率を表す評価関数の accuracy は 1.0 を示しているが現実の危険運転に対応することができないということになる。

今後の課題として、過学習を起こさないように機械学習器を実装し、危険運転検知システムにおいてオプティカルフローが有用であるかを改めて確かめる必要がある。方法としては学習用のデータセットを増やし本研究で起きてしまった過学習の対策をする、オプティカルフローの計算結果を画像として描画することで CNN でも扱えるようにして CNN により危険運転の検知を行うことが挙げられる。

参考文献

- [1] 北垣 修, ワン ユ, 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, 5P-08, pp. 455-456, 2017.
- [2] 和田 蓮, 横井 太一, “機械学習を用いた危険運転検出システムの設計”, 南山大学理工学部 卒業論文 要旨集, 2020.
- [3] 飯盛 天翔, 加地 智也, 大鷹 弘史, 吉本 凌也, “2 段階機械学習を用いた危険予測システムアーキテクチャ設計方法の提案と評価”, 南山大学理工学部 卒業論文集, 2021.
- [4] Berthold.K.P.Horn, Brian.G.Schunck, “Determining Optical Flow”, Artificial Intelligence, Volume 17, Issues 1-3, pp.185-203, 1980.
- [5] Bruce.D.Lucas, Takeo Kanade, “An Iterative Image Registration Technique with an Application to Stereo Vision”, Proceedings DARPA Imaging Understanding Workshop , pp.121-130, 1981.
- [6] Jianbo Shi, Carlo Tomasi, “Good Features to Track”, IEEE Conference on Computer Vision and Pattern Recognition, 1994.
- [7] 笠原 正樹, 花泉 弘, “車載ステレオカメラによる動的背景差分の精度向上”, FIT2013 (第 12 回情報科学技術フォーラム), I-009, pp.237-238,2013
- [8] 熊野 雄太, 増田 寛之, 本吉 達郎, 澤井 圭, 高木 昇, “車両旋回時における天球カメラを用いた オプティカルフロー算出手法の提案”, 第 36 回ファジィシステムシンポジウム 講演論文集 (FSS2020 オンライン), TA3-1, pp.182-186,2020