

# 領域ベース深層学習を用いた 車載カメラ映像からの危険予測

松田 賢太<sup>†</sup> 村田 祐樹<sup>‡</sup> 後藤 紳一郎<sup>‡</sup> 渥美 雅保<sup>\*</sup>

創価大学工学部情報システム工学科<sup>†</sup> 創価大学大学院工学研究科情報システム工学専攻<sup>‡</sup>

創価大学理工学部情報システム工学科<sup>\*</sup>

## 1. はじめに

ADAS, 及び自動運転の研究では運転者視点の映像から道路・交通状況の危険度を予測する研究が行われている[1][2]. 本研究では, 車載カメラ映像から領域ベース CNN と LSTM により交通状況を符号化し相対比較ロス(Comparative Loss)関数により学習した危険度推定器で危険を予測する手法を提案する. 本手法では, 車載カメラ映像から物体検出器 YOLOv2 を使って移動体領域を切り出すと同時に, 検出器の中間層からそれらの特徴量を取り出す. そして, これらの特徴量系列を LSTM に入力して相対比較ロス関数により危険度推定器を学習して危険度を予測する. 車載カメラのデータセットを用いて学習を行い, 危険度推定の精度を評価する.

## 2. 危険予測の手法

### 2.1. 概要

提案手法は, 図 1 のように, 物体検出器 YOLOv2, 移動体空間パターン符号化 CNN, 移動体時空間パターン符号化 LSTM, 危険度推定ネットワークから構成される. まず, 車載カメラ映像から物体検出器 YOLOv2 を用いて移動体の検出を行い, その中間層から特徴量を取り出す. 次に, これら移動体領域の特徴量系列を CNN, LSTM に入力することによって移動体時空間特徴を抽出し, 危険度推定ネットワークにより危険度予測を行う. 危険度推定ネットワークは, 訓練時に 2 つの映像のペアに与えられた相対的な危険度から相対比較ロス関数を用いて学習される.

### 2.2. 物体特徴検出

車載カメラ映像から危険度予測を行うためには, 危険を伴う物体を検出する必要がある. 車の運転を行う際には様々な物体に注意して運転を行うが, 特

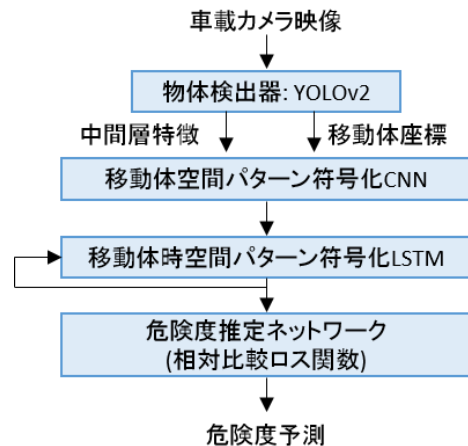


図 1 提案手法の概要

に危険なものは移動体である. 本手法では, COCO データセットで事前学習された YOLOv2 を 2 種類の車載カメラデータセットである KITTI Dataset[3]と Dashcam Accident Dataset[1]を用いて追加学習を行い, 移動体の検出を行った. 検出する対象物体は次の 7 カテゴリ-car, truck, person, tram, bicycle, motorbike, bus-とし, 2 つのデータセットでラベルを統一した.

移動体を検出した後, それらの特徴量を抽出する. 移動体の特徴抽出は, 物体検出器 YOLOv2 の CNN の中間層から, 移動体の座標を用いて該当部分の畳み込み特徴量を切り出すことで行う. ここで, 中間層には第 21 層を用いている.

### 2.3. 移動体時空間特徴の抽出

移動体時空間特徴の抽出は, YOLOv2 の中間層の特徴マップから移動体領域の畳み込み特徴のみを残した特徴マップに対して, 移動体時空間パターン符号化のための CNN と LSTM を適用することによりなされる(図 1). 図 2 にこのネットワークの基本構成を示す. 図中, Max Pooling 層の(2,2)はカーネルサイズとストライド, Convolution 層の(512,3,1,1)は出力チャンネル数, カーネルサイズ, ストライド, パディング幅, Spatial Pyramid Pooling 層の(3)はピラミッドのレベル数である.

### 2.4. 危険度推定と相対比較ロス関数

交通状況の客観的な数値による危険度評価は一般には難しい. 一方, 事故が起こっている状況は起こ

Risk Prediction from On-vehicle Video based on Region-based Deep Learning

<sup>†</sup>Kenta Matsuda, Dept. of Information Systems Sci., Faculty of Eng., Soka University

<sup>‡</sup>Yuki Murata, Graduate School of Engineering Dept. of Information Systems Eng., Soka University

<sup>‡</sup>Shinitiro Goto, Graduate School of Engineering Dept. of Information Systems Eng., Soka University

<sup>\*</sup>Masayasu Atsumi, Dept. of Information Systems Sci., Faculty of Sci., and Eng., Soka University

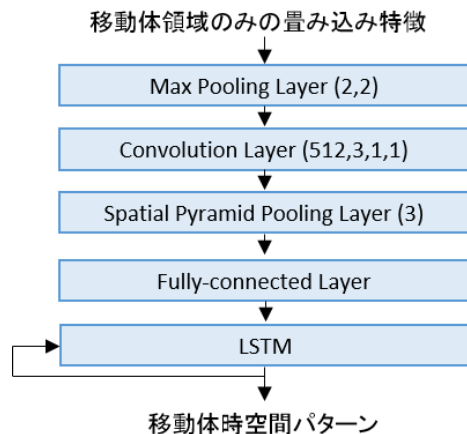


図 2 移動体の時空間パターン特徴抽出ネットワーク

っていない状況より危険、混雑している状況は空いている状況より危険といった評価は比較的容易である。そこで、2つの時空間パターンのペアに対して、どちらが危険かの教師信号とそれらの危険度推定値から正しい相対比較になるように危険度推定関数を学習する相対比較ロス (Comparative Loss) 関数を導入する。まず、2つのカメラ映像を  $v_1, v_2$ 、それらの相対危険度を  $R(v_1, v_2)$  とし、それらカメラ映像から計算された移動体時空間パターンに対してシグモイド活性化関数を持つパーセプトロン(危険度推定ネットワーク)により推定した危険度をそれぞれ  $r_1, r_2$  とする。ここで、 $R(v_1, v_2)$  は、 $v_1$  が  $v_2$  より危険なとき 1、安全なとき -1、同程度のとき 0 の値を取る教師信号である。このとき、相対比較ロス関数を次式で定める。

$$L(r_1, r_2, R(v_1, v_2)) = \begin{cases} \max(r_2 - r_1 + m, 0) & \dots R(v_1, v_2) = 1 \\ |r_2 - r_1| & \dots R(v_1, v_2) = 0 \\ \max(r_1 - r_2 + m, 0) & \dots R(v_1, v_2) = -1 \end{cases} \quad (1)$$

ここで、 $m$  は相対比較のマージンを与えるパラメータである。

危険度予測では、映像のフレーム区間に対する移動体時空間パターンから危険度推定ネットワークにより危険度を予測する。

### 3. データセット

実験では、物体検出器の学習に KITTI Dataset と Dashcam Accident Dataset を、危険度予測の実験に Dashcam Accident Dataset を用いた。Dashcam Accident Dataset には事故あり動画と事故なし動画があり、実験では事故あり動画を用いた。このデータセットは全動画 100 フレームで、最後 10 フレームで事故が起こっている。危険度予測の実験では、この 100 フレームの動画を分割し、前半 50 フレームを事故なし、後半 50 フレームを事故ありの動画として用いた。従って、危険度予測に用いたデータセットは表 1 のような構成になる。

表 1 事故あり (positive) と事故なし (negative) の動画の構成 (ビデオ数/フレーム数)

	Train	Test
positive	455/22750	164/8200
negative	455/22750	164/8200

## 4. 実験

### 4.1. 実験概要

危険度推定の学習の評価を、事故なし動画と事故あり動画、事故なし動画同士の 2 つのケースについて行う。前者では、事故がない状況より事故がある状況のほうが危険という相対比較を相対ロス関数で表現させる。この場合の相対比較マージン  $m$  は 0.5 とした。後者では、動画中の移動体の数により移動体の数が多いほうが危険という相対比較を相対ロス関数で表現させる。この場合の相対比較マージン  $m$  は 0.1 とした。

### 4.2. 実験結果

表 2 に事故なし/あり動画で学習した結果を示す。

表 2 事故なし/あり動画での危険度推定の精度

	Train(%)		Test(%)	
	DOあり	DOなし	DOあり	DOなし
BG_ZERO	99.771	97.706	69.565	62.733
BG_GN	97.706	94.839	70.807	72.050

表において、BG\_ZERO, BG\_GN は、移動体領域の畳み込み特徴抽出において移動体領域以外の領域の特徴をゼロとする (BG\_ZERO) かガウシアンノイズを与えるか (BG\_GN) を表す。また、DO は図 2 の全結合の出力へのドロップアウトの適用を表す。

表 3 に事故なし動画同士で学習した結果を示す。

表 3 事故なし動画同士での危険度推定の精度

	TrainDOなし(%)	TestDOなし(%)
BG_ZERO	93.349	86.957

## 5. むすび

本論では、領域ベース CNN と LSTM により交通状況を符号化し、相対比較ロス関数により学習した危険度推定器で危険を予測する手法を提案した。そして、実験により、相対比較ロス関数により危険な状況を推定できることを示した。今後の課題として、危険度推定器による危険の事前予測の精度向上などがあげられる。

## 参考文献

- [1] Chan, F-H., et al.: Anticipating Accidents in Dashcam Videos, ACCV 2016.
- [2] 鈴木智之, 他: 危険予測のための大規模ニアミス DB 構築と疑似再帰ニューラルネット, ViEW 2017.
- [3] Geiger, A., et al.: Are we ready for Autonomous Driving? The KITTI Vision Benchmark Suite, CVPR 2012.