

Convolutional-Recurrent Neural Network による自己運動識別

神谷龍司† 川口俊樹† 福井宏† 石井育規‡ 小塚和紀‡ 羽川令子‡
築澤宗太郎‡ 山下隆義† 山内悠嗣† 藤吉弘亘†

†中部大学 ‡パナソニック株式会社

E-mail: {shinryu@vision.cs, yuu@isc, yamashita@cs, hf@cs}.chubu.ac.jp

Abstract

Convolutional-Recurrent Neural Network (C-RNN) は, Deep Convolutional Neural Network (DCNN) による特徴抽出と Recurrent Neural Network (RNN) による時系列対応により, 動画像などの時系列を学習することができる. C-RNN は, 畳み込み層と LSTM 層を End-to-End で学習するため, DCNN と RNN のパラメータを同時に最適化する必要がある. パラメータがうまく学習されない場合がある. 本研究では, 1 人称視点映像からの自己運動識別を対象とし, C-RNN のより良いパラメータを学習する方法及び入力データの形式について検討する. 学習は, DCNN と RNN を End-to-End で学習する方法と, DCNN と RNN を別々に学習する 2 段階学習を導入する. 入力には, カラー画像, オプティカルフローおよびオプティカルフローの方向ベクトルの可視化画像, カラー画像と方向ベクトルの可視化画像の 3 種類の入力データを用いる. 方向ベクトルの可視化画像を用いることで, 各画素の移動方向や強度を 1 枚の画像で表現できる. 評価実験の結果, 方向ベクトルの可視化画像を 2 段階で学習した場合に最も良い自己運動識別精度を得ることができた.

1 はじめに

Deep Convolutional Neural Network(DCNN) [2] は, 一般物体認識の性能を大きく上回ったことで注目されており, シーンセグメンテーションや歩行者検出等の様々な物体認識で高い性能を達成している. しかし, DCNN は 1 枚のカラー画像またはグレースケール画像を入力とした場合に高い性能を発揮できるが, 自己運動識別のような, 時系列情報を必要とする認識問題に対しては十分な性能を発揮できない. ニューラルネットワークにおいて, 時系列情報を入力して認識する RNN [3] があり, 動画像認識や自然言語処理, 音声認識など時系列情報を扱うような問題設定で用いられている. RNN は, 時系列に従ってサンプルを入力する構造となっており, 時刻 t の中間層には時刻 t のサンプルと時刻 $t-1$ の中

間層の応答値が入力される. 学習時には, Back Propagation Through Time(BPTT) や Long Short Term Memory(LSTM) [11] を使用し, 時系列を遡りながらパラメータを更新する. RNN は, BPTT や LSTM を用いることで時系列対応が可能となり, 高精度な時系列パターンの学習が可能となる.

DCNN と RNN をベースとした C-RNN は, DCNN による特徴抽出と RNN による時系列対応により高精度な時系列パターンの学習が可能である [1]. しかし, C-RNN は End-to-End で学習するため, DCNN と RNN のパラメータを同時に最適化する必要がある. 問題設定によって性能が発揮されない場合がある. また, 入力サンプルに動画のフレームを用いた場合, 1 枚のフレームから物体の動きを推定するのは困難である.

本研究では, C-RNN による自己運動識別を対象として, 学習における最適なパラメータ更新方法, 及び入力データの形式について検討する. 学習では, DCNN と RNN を End-to-End で学習する方法と, 別々に学習する 2 段階学習を比較する. 入力データの形式には, カラー画像, オプティカルフロー及びオプティカルフロー方向ベクトルの可視化画像, カラー画像と方向ベクトルの可視化画像で検証する. オプティカルフローの可視化画像は, 1 枚のカラー画像で数フレームの物体の移動量を表現できる. そのため, DCNN のように 1 枚の画像から特徴量を抽出して認識する方法でも, 自己運動識別に有効な特徴量を獲得できる. 本稿では, 自己運動識別に対して学習法や入力データの形式を検討することにより, C-RNN の推定性能を向上させる.

2 DCNN と RNN

本章では, C-RNN のベースとなる CNN と RNN の構造及び関連研究について述べる.

2.1 Deep Convolutional Neural Network

DCNN は, 一般物体認識において高い性能を発揮しており, ImageNet Large Scale Visual Recognition Challenge (ILSVRC) 2012 で高い認識性能を実現して以降, 注目されている [7]. ILSVRC2012 以降, 一般物体認識をはじめ家の番号認識 [4], シーン認識 [5], 物体検出 [6]

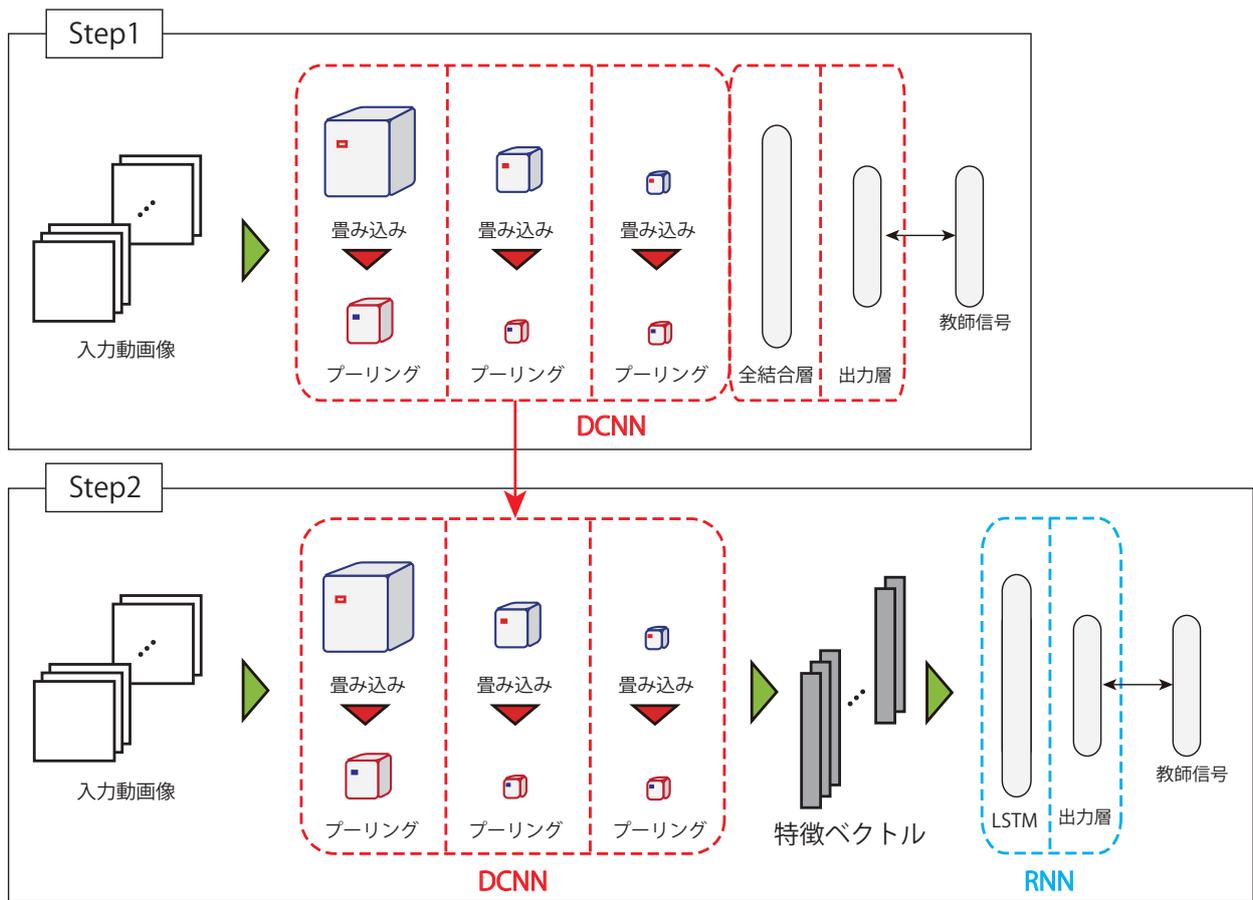


図2 2段階学習の流れ

れる。そして、各時刻の C-RNN の出力を得たとき、各時刻における C-RNN の学習誤差を算出する。算出した各時刻の学習誤差から、BPTT により C-RNN のパラメータを更新する。

End-to-End で C-RNN を学習させた場合、BPTT によりネットワーク全体が時系列を捉えられる特徴量を獲得できるように学習されるため、高精度な識別が可能となる。

3.2 2段階学習

C-RNN の End-to-End による学習は、動画を順伝播させて誤差を算出し、LSTM により DCNN と RNN のパラメータを更新する。しかし、DCNN と RNN のパラメータを同時に更新するため、問題設定によってパラメータがうまく学習されない場合がある。C-RNN の学習方法において、DCNN と RNN を別々に学習する 2 段階学習がある。パラメータの更新を別々に行うことで、1 フレームから自己運動識別に有効な特徴量を DCNN により抽出し、RNN により時系列に対応した学習と識別が可能となる。

C-RNN の 2 段階学習の流れを図 2 に示す。Step1 では、通常の DCNN に 1 フレーム毎に入力し、誤差逆伝播法により学習する。そして、Step1 で学習した DCNN と RNN を用いて C-RNN を構築する。Step1 で学習し

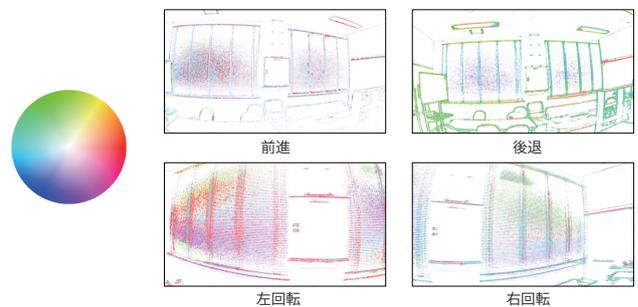


図3 方向ベクトルの可視化例

た DCNN は、畳み込み層及びプーリング層を、RNN の下位層へ結合させる。C-RNN を構築した後に、RNN と同様に時系列に従いながら入力データを C-RNN に入力する。ここで、畳み込み層及びプーリング層により得られる特徴マップは、1 次元の特徴ベクトルに変換され、RNN へ入力する。学習によるパラメータの更新では、LSTM により RNN のパラメータのみ更新される。

3.3 入力データの方式

入力データには、カラー画像を入力する方法とオプティカルフローの方向ベクトルの可視化画像を入力する方法を考える。カラー画像の場合、動画の中から 1 フレームを取り出して、ネットワークに入力する。しか

し、1枚のカラー画像からシーン中の物体の動きを捉えるのは、非常に困難である。そのため、シーン中の物体の動きを捉えるためにオプティカルフローから得られる方向ベクトルを用いる。オプティカルフローの方向ベクトルを用いることで、フレーム間の物体の動きを1枚の画像で表現できる。そのため、学習により特徴量を獲得する際に、物体の動きのみに着目しながら学習できる。また、DCNNのように1枚の画像から自己運動識別する方法に対しても有効である。

オプティカルフローの方向ベクトルを用いる場合、はじめに前後2フレームからオプティカルフローにより方向ベクトルを算出する。そして、算出した方向ベクトルから、方向ベクトルの向きを色、強度を明るさで変換した可視化画像を生成する。ここで、図3に方向ベクトルの可視化画像の例を示す。図3の生成した方向ベクトルの可視化画像は、DCNNやRNN、C-RNNのネットワークに入力される。学習時は、連続する2フレームから方向ベクトルの可視化画像を1人称視点の映像から生成して学習データセットを構築し、ネットワークを学習する。識別時は、連続する2フレームから方向ベクトルの可視化画像を生成してネットワークに入力し、自己運動識別する。

4 評価実験

C-RNNの学習方法及び入力データの方式の有効性を調査するために評価実験を行う。比較手法として、C-RNN(2段階学習)、C-RNN(End-to-End)、DCNN、RNNの4つの手法を用いる。

本実験では、一人称視点で撮影された動画画像から、カメラ装着者の運動を識別し、精度を評価する。推定する運動は前進、後退、右回転、左回転の4パターンとする。自己運動は、屋内で撮影し、動画画像の各フレームには、前進、後退、右回転、左回転の4方向の教師データが付与されている。また、各手法ではData Augmentationは行わずに学習する。学習及び評価に使用するフレーム数を表1に示す。ここで、フレームのサイズは 90×160 のカラー画像を使用する。

表1 使用するカメラ映像のフレーム枚数

サンプル	前進	後退	右回転	左回転	合計
学習	5,200	5,000	5,300	4,900	20,400
評価	500	500	600	500	2,100

また本実験では、カラー画像、方向ベクトルの可視化画像、カラー画像と方向ベクトルの可視化画像の3種類の入力データを用いる。可視化画像を作成する際に使用する方向ベクトルの算出手法には、Gunnar Farneback法[12]を用いる。オプティカルフローは、前後の2フレームから抽出する。本実験に使用するDCNNは、表

表2 DCNNのネットワーク構造

入力層		$3 \times 90 \times 160$
1層目	重みフィルタ	$32 \times 3 \times 3$
	ReLU	-
	MaxPooling	2×2
2層目	重みフィルタ	$64 \times 3 \times 2$
	ReLU	-
	MaxPooling	2×2
3層目	重みフィルタ	$64 \times 2 \times 2$
	ReLU	-
	MaxPooling	2×2
4層目	ユニット数	64
	Dropout	50%
5層目	ユニット数	128
	Dropout	50%
6層目	ユニット数	4
	Softmax	-

表3 RNNのネットワーク構造

入力層		$3 \times 90 \times 160$
1層目	ユニット数	64
	Dropout	50%
	LSTM	-
2層目	ユニット数	128
	Dropout	50%
	LSTM	-
3層目	ユニット数	4
	Softmax	-

2のように畳み込み層が3層、全結合層が2層の構造である。RNNは、表3のように3層のRNNを用いる。C-RNNは、表2の畳み込み層と表3の中間層及び出力層が、結合した構造となる。学習パラメータは、学習率は0.01、ミニバッチのサイズは10、更新回数は10万回である。

4.1 自己運動識別精度の比較

各手法による識別精度を表4に示す。表4より、C-RNNとDCNN及びRNNを比較すると、入力データに方向ベクトルの可視化画像を用いたほうが精度が高いことがわかる。方向ベクトルの可視化画像は1枚のフレームに映っている各物体の動きを捉えることができるため、自己運動識別の精度が向上したと考えられる。

DCNNとRNNの識別精度を比較すると、RGB画像を用いた場合はRNNのほうが精度が良く、可視化画像を用いた場合においてはDCNNのほうが精度が良い。これを踏まえてC-RNNをEnd-to-Endで学習した場合と2段階で学習した場合を比較すると、RGB画像を

表4 各手法による推定精度

手法	RGB 画像	可視化画像	RGB 画像 + 可視化画像
C-RNN(2 段階学習)	30.71	84.52	61.00
C-RNN(End-to-End)	49.66	82.66	73.57
DCNN	28.47	81.52	48.90
RNN	35.71	71.71	67.57

用いた場合は End-to-End の学習のほうが精度が良く、可視化画像を用いた場合は 2 段階学習が良い。これは、RNN が適している問題は End-to-End の学習を用いるほうが良く、DCNN が適した問題であれば 2 段階学習を用いるほうが良い傾向があるといえる。RGB 画像+可視化画像においても同様であり、RNN の識別精度が DCNN よりも高いため End-to-End の学習方法を用いるほうが 2 段階学習より識別精度が高い。また、入力データにおける精度を比較すると、RGB 画像よりも可視化画像を用いた場合のほうが圧倒的に精度が良いことがわかる。これは、DCNN により特徴ベクトルを抽出する際に、RGB 画像を用いた場合は画像中から移動方向や強度といった情報は得られないが、可視化画像を用いることで DCNN の畳み込みに適した入力となったため、識別精度が向上したと考えられる。

4.2 自己運動識別の結果

図 4(a), (b), (c) に、方向ベクトルの可視化画像を入力とし、2 段階学習した C-RNN の自己運動識別結果を示す。図 4(a) は、室内で撮影した動画像に対して自己運動識別した結果である。図 4(a) より、方向ベクトルの可視化画像は物体の動きを 1 枚のフレームで捉えることができるため、高精度に自己運動識別できることが確認できる。

次に、自動車走行環境において自己運動識別を行った際の推定結果を示す。ここで、自己運動識別に使用する C-RNN は、図 4(a) で推定に使用したネットワークを用いる。実験では、昼の時間帯に撮影した走行シーンと夜間に撮影した走行シーンを用いて、自己運動識別を行う。図 4(b) に、昼の時間帯に撮影したシーンで自己運動識別を行った結果を示す。図 4(b) より、学習で使用したデータと異なった場合においても、自己運動識別が可能であることが確認できる。方向ベクトルの可視化画像を用いることで、シーン中の物体の動きに着目して学習により特徴量を獲得できる。そのため、学習サンプルと異なるシーンを評価した場合でも、自己運動識別が可能となる。図 4(c) に、夜間に撮影したシーンで自己運動識別を行った結果を示す。カラー画像では、夜間のシーンにおいて物体が映らなくなるため、自己運動識別が非常に困難となる。方向ベクトルの可視化画像は、夜間でも図 4(c) のように方向ベクトルを抽出できる。そのため、図 4(c) のような夜間のシーン

においても物体の動きを捉えることができ、自己運動識別が可能である。

5 おわりに

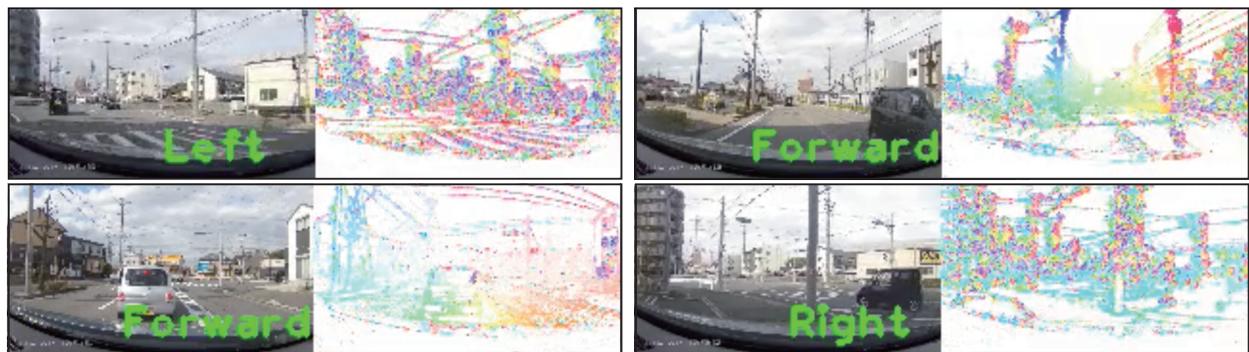
本稿では、自己運動識別を対象として、C-RNN における最良な学習方法と、入力データの形式について検討を行った。1 人称視点の動画像を用いた自己運動識別では、C-RNN を用いることで DCNN と RNN を単体で用いるよりも高精度な識別が可能となった。また、C-RNN の学習において、RNN による時系列対応が効果的であれば End-to-End の学習が適しており、DCNN による特徴量設計のほうが効果的であれば 2 段階学習が適していることが分かった。入力データの形式は、RGB 画像よりもオプティカルフローにより算出した方向ベクトルの可視化画像を用いることで推定精度が向上した。方向ベクトルの可視化画像を用いて学習した C-RNN を用いることで、学習サンプルと大きく異なるシーンにおいても自己運動識別が可能であり、夜間のシーンにおいても自己運動識別が可能になる。

参考文献

- [1] Z. Zuo, B. Shuai, G. Wang, X. Liu, X. Wang, B. Wang, and Y. Chen, "Convolutional Recurrent Neural Networks: Learning Spatial Dependencies for Image Representation", *Computer Vision and Pattern Recognition*, 2015.
- [2] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-Based Learning Applied to Document Recognition", *Proceedings of the IEEE*, pp. 2278-2324, 1998.
- [3] J. Elman, "Finding Structure in Time", *Cognitive Science*, Vol. 2, No.14, pp.179-211, 1990.
- [4] I. J. Goodfellow, Y. Bulatov, J. Ibarz, S. Arnold, and V. Shet, "Multi-digit Number Recognition from Street View Imagery using Deep Convolutional Neural Networks", *CoRR*, Vol. abs/1312.6082, 2013.
- [5] C. Farabet, C. Couprie, L. Najman, and Y. LeCun, "Learning Hierarchical Features for Scene



(a) 室内の認識結果



(b) 自動車走行環境の認識結果 (昼)



RGB 画像

可視化画像

RGB 画像

可視化画像

(c) 自動車走行環境の認識結果 (夜)

図 4 自己運動識別結果の例

Labeling”, IEEE Transactions on Pattern Analysis and Machine Intelligence, 2012.

- [6] R. Girshick, J. Donahue, T. Darrell, and J. Malik, ”Rich Feature Hierarchies for Accurate Object Detection and Semantic Segmentation” , Computer Vision and Pattern Recognition, 2014.
- [7] A. Krizhevsky, I. Sutskever, and G. Hinton, ”ImageNet classification with deep convolutional neural networks”, Neural Information Processing Systems, 2012.
- [8] I. Goodfellow, D. W. Farley, M. Mirza, A. Courville, and Y. Bengio, ”Maxout networks”, arXiv preprint arXiv:1302.4389, 2013.
- [9] I. Sutskever, O. Vinyals, and Q. V. Le, ”Sequence

to Sequence Learning with Neural Networks”, Neural Information Processing Systems, 2014.

- [10] P. Werbos, ”Generalization of backpropagation with application to a recurrent gasmarket model”, Neural Networks 1 (4): 339-356, 1988.
- [11] S. Hochreiter, ”LONG SHORT-TERM MEMORY”, Neural Computation 9(8) 1735-1780, 1997.
- [12] G. Farneback, ”Two-Frame Motion Estimation Based on Polynomial Expansion”, IN SCIA2003, pp.363-370, 2003.