

Deep neural networkを用いた ヒューマノイドロボットによる物体操作行動の記憶学習と行動生成

Memory learning and behavior generation of object manipulation behaviors by a humanoid robot utilizing a deep neural network

野田 邦昭 有江 浩明 菅 佑樹 尾形 哲也
Kuniaki Noda Hiroaki Arie Yuki Suga Tetsuya Ogata

早稲田大学 理工学術院 基幹理工学研究科
Graduate School of Fundamental Science and Engineering, Waseda University

For robots to perform in real environments, handling of high-dimensional and large-scale raw sensory inputs is a difficult problem. This paper presents a novel computational framework in which a deep learning method is applied for modeling and generating multiple object manipulation behaviors by a humanoid robot. The proposed mechanism succeeds in modeling six different object manipulation behaviors without any dedicated sensory feature extraction mechanism. By retrieving temporal sequences over the learnt different modals, the proposed mechanism enables to generate the object manipulation behaviors from the corresponding images sequence, and vice versa.

1. はじめに

オープンエンドな実環境下においてロボットが活動するためには、多次元で大規模なセンサ入力をいかに効率的に扱うかが重要な課題となる。これまでのロボティクス研究では、想定されるタスクや環境設定などに応じて、例えば視覚入力ならばオプティカルフローや色領域抽出を行うなど、設計者のセンスによって抽出する特徴を選択し、元のセンサ入力に対して前処理を施すことで、学習器や制御器で扱う情報の次元を縮退させることが慣例となってきた。一方、機械学習の分野では、Deep learning [Hinton 2006] が近年注目を集めている。多段階層型のニューラルネットワークを用いてテキスト、画像、音響データなど様々な多次元データを教師なしで学習することにより、高精度に可逆な次元圧縮を行い、特徴量を自己組織化することが可能であることが報告されている。

本研究では、Deep learning の学習フレームワークをロボットの感覚運動統合学習に導入することで、センサ入力に対する恣意的な特徴抽出を行うことなく複数モーダルから得られた多次元時系列を統合化し、ロボットによる複数物体の行動経験を記憶学習する。これにより、複数モーダルを統合した特徴空間に、行動パターンごとのクラスターが自己組織化することを示す。また、学習によって獲得した感覚運動モデルを用いてクロスモーダルな記憶連想を行うことで、運動パターンに対応した画像の想起をしたり、画像系列から運動パターンを生成したりすることが可能となることを示す。

2. マルチモーダル時系列記憶連想システム

2.1 システム全体の構成

本システムでは、画像圧縮および時系列情報の認識生成のために、多段階層型ニューラルネットワークを用いる。ニューラルネットワークの構造は、入出力次元に対し、中央の中間層のニューロン数が最も小さくなるような砂時計型を用いる。さらに、入出力が同一になるような制約の下で学習パラメータを更新することにより、恒等写像（オートエンコーダ）の学習を行う。ネットワークの学習には、Martens によって提案されている学習手法を用いる [Martens 2010]。これにより、最狭部

連絡先: 野田邦昭, 早稲田大学理工学術院, 東京都新宿区大久保 3-4-1, 03-5286-2742, kuniaki.noda@akane.waseda.jp

の中間層を境として、もとの入力情報を失わずに次元圧縮するための変換と、次元圧縮された特徴ベクトルから元の情報を復元するための変換を行う写像変換が、階層型ネットワークに同時に獲得される。

2.2 マルチモーダル時系列の学習と記憶連想

ロボットから得られた画像入力ベクトルは、そのままでは次元が大きいため、圧縮して画像特徴ベクトルに変換してから時系列学習に用いる。教示から得られた画像データを用いて恒等写像学習をし、画像の圧縮と復元を実現する変換を自己組織的にネットワークに獲得する。学習によって得られたネットワークの入力層に画像データを入力し、中間層のアクティベーションを取得することにより、低次元化された画像特徴ベクトルを取得する。

ロボットから得られた関節角度ベクトル時系列と、次元圧縮の結果得られた画像特徴ベクトル時系列を合わせたものを入力ベクトル時系列とし、恒等写像学習を行う。なお、再帰結合を持たない階層型ニューラルネットワークで多次元時系列を学習するために、タイムディレイ型ニューラルネットワークの学習 [Lang 1990] を行う。これは、一定の時間幅を持った時間ウィンドウで、時刻ごとに多次元時系列をサンプルすることで、学習器への入力情報を生成する手法である。

時系列生成の際には、関節角度時系列もしくは画像特徴ベクトル時系列を入力とし、出力層から得られた時系列のうち、入力に与えなかったモーダルの時系列を取得することにより、クロスモーダルな記憶連想を行う。また、時間ウィンドウの一定範囲のみを入力し、出力時系列を取得することにより、時系列予測を行う。なお、外部からデータを与えないモーダルや予測によって生成する範囲の時系列に関しては、ネットワークの出力として得られたベクトルを再帰的に入力にフィードバックすることにより、時系列を内部生成する。

3. 評価実験

3.1 実験設定

提案する学習フレームワークを評価するため、Aldebaran Robotics 社の NAO を用いて直接教示により生成した、6 種類の物体操作タスク (Ball lift, Ball roll, Bell ring L, Bell ring R, Ball roll on a plate, Ropeway) に関する学習実験を行っ




図 1: 自己組織化された感覚運動統合特徴空間

た．学習には，各物体を操作した際の左右の腕の関節角 10 自由度および頭部のカメラから取得した RGB 画像を 20×15 の解像度にリサンプルしたものをセンサ入力として用いた．なお，各時刻の関節角度およびカメラ画像を同期したデータは，約 10 [fps] で取得した．

1 回の教示につき 10～20 秒間 (100～200 ステップ相当) の教示を行い，各行動パターンにつき 6～10 回教示を繰り返してデータを取得した．このうち，各行動パターンについて 1 回分の教示データをテストデータとし，残りのデータを学習データとした．結果，画像圧縮に関しては，全部で 8444 ステップの学習データと 948 ステップのテストデータが得られた．一方，時系列学習に関しては，得られた時系列データのうち，30 ステップの時間ウィンドウで切り出したものを学習器への 1 回の入力とし，1 ステップずつウィンドウをスライドさせながら学習データを作成した．結果，6848 ステップの学習データと 776 ステップのテストデータが得られた．

学習に用いたネットワークは，画像圧縮，時系列学習，共に 12 階層 (結合重みの層数) とし，入出力を除いた各層のニューロン数は 1000, 500, 250, 150, 80, 30, 80, 150, 250, 500, 1000 とした．なお，これらの数値は経験的に設定した．各学習器の入出力次元は，画像圧縮については， $20 \times 15 \times 3$ で 900 次元となり，時系列学習については，関節角 10 次元と画像特徴ベクトル 30 次元の時系列に関し，30 ステップ分の時間ウィンドウで取得したデータを学習器に対する 1 回の入力としたため，1200 次元となった．

3.2 実験結果

視覚特徴ベクトル時系列と関節角時系列を統合学習した際にネットワークの中間層から得られた 30 次元の特徴ベクトルに対して主成分分析を行い，3 次元空間に射影して視覚化した感覚運動特徴空間を図 1 に示す．複数のモデルから得られた情報が統合化され，行動パターンごとにクラスターを形成していることがわかる．

次に，テストデータの画像系列を入力し，対応する関節角度時系列を生成した結果の例を図 2 に示す．時系列生成の際，記憶連想によって生成するモデルに対する入力バッファはランダムに初期化されているため，最初の 30 ステップ分の出力は生成波形の精度が低いが，予測データの内部フィードバックが徐々に安定した値に収束して，正解に近い波形を生成できたことを示している．

最後に，テストデータの関節角度時系列を入力し，対応する画像を生成した結果の例を図 3 に示す．実験結果からは運動パターンに対応した操作対象物体が正しく画像中に生成され，行

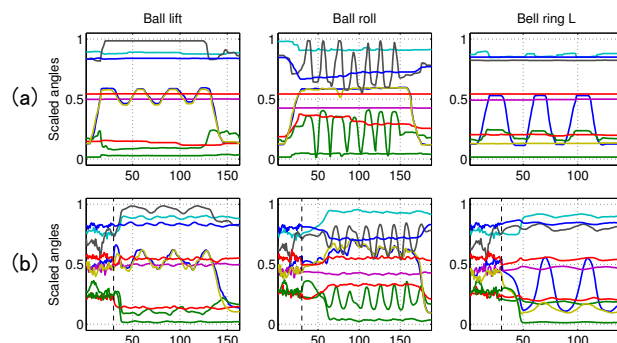


図 2: 画像シーケンスから生成した関節角度系列の例．(a) 正解の関節角度時系列，(b) 生成した関節角度時系列．




図 3: 関節角度時系列から生成した画像の例．(a) 正解画像，(b) 生成した画像．

動のフェーズに合わせた画像が生成されることが確認できた．

4. まとめ

本研究では，ロボットの感覚運動情報を統合化して環境の認知を行うための学習フレームワークとして，多段階階層ニューラルネットワークを用いた時系列記憶学習メカニズムを提案した．提案メカニズムを用いることにより，高次元の画像入力を効率的に次元圧縮して特徴ベクトルを生成することが可能になり，視覚特徴量を自己組織的に生成し，ロボットの行動学習と，獲得した記憶構造を用いたクロスモーダルな記憶連想が実現できることを示した．今後は，視覚入力だけでなく，聴覚入力など，より多様なモーダルの情報を用い，感覚運動統合学習を行う予定である．

謝辞

本研究は，さきがけ領域研究「情報環境と人」及び科研費新学術領域研究「構成論的発達科学」(24119003) の助成を受けた．

参考文献

- [Hinton 2006] G. E. Hinton and R. R. Salakhutdinov: Reducing the dimensionality of data with neural networks, Science, vol. 313, no. 5786, pp. 504-7, July 2006.
- [Lang 1990] K. Lang, A. Waibel, and G. Hinton: A Time-Delay Neural Network Architecture for Isolated Word Recognition, Neural networks, vol. 3, pp. 23-43, 1990.
- [Martens 2010] J. Martens: Deep Learning via Hessian-free Optimization, In Proceedings of the 27th International Conference on Machine Learning (ICML), 2010.