

深層学習を用いた要素動作の統合手法の開発

Development of Integration Method of Element Motions using Deep Learning

○ 伊藤 洋 (日立製作所) 山本 健次郎 (日立製作所)
尾形 哲也 (早稲田大学)

Hiroshi Ito, Hitachi, Ltd., hiroshi.ito.ws@hitachi.com
Kenjiro Yamamoto, Hitachi, Ltd.
Tetsuya Ogata, Waseda University

Cooperation of multiple element motions is important for robots to realize various complicated tasks. Most of the researches focus on realizing a single and complicated element-motion using a motion-generating-model made of deep neural network. In this study, we propose an integration method for those models. We introduce a timing determiner to determine the execution timing of motion, as well as an autoencoder and a recurrent neural network in the model as the novel integration method. We have confirmed that a passing-through-door motion, cooperating multiple element-motions is accomplished by the method.

Key Words: Deep Learning, Integration Method, Robot Arm, Mobile Robot

1. はじめに

少子高齢化による労働力不足解消のため、人の作業支援を行うロボットの普及が期待されている。しかし、従来の制御手法では、人が行っている様々な環境での複雑な作業をロボットで実現するには、膨大な数のプログラミングを行う必要がある。その結果、多大な開発費および開発期間が必要になり、ロボットの普及が阻まれる要因となっている。

そこで、ロボットが多様な環境に対し柔軟な動作を自動生成する技術として、深層ニューラルネットワーク (NN) を用いた動作生成モデルが提案されている。例えば Noda ら[1]は、ロボットの視覚情報と関節角度情報を統合学習させる動作生成モデルを提案し、1つのモデルで環境変化に対し柔軟な複数の動作を生成できることを示した。また陽ら[2]は、動作生成モデルに与える学習データを、遠隔操作装置を用いて獲得し、定式化が困難な不定形柔軟物のハンドリング作業の例として、布の折り畳み動作の自動生成を実現した。

筆者らは、人が行う複雑な作業をロボットが実現するためには、要素動作を1つの動作生成モデルで獲得する上記従来研究に加え、さらに、複数の動作生成モデルを連携させ、それぞれ別々に獲得した複数の要素動作を1つの連続動作 (作業) に統合する技術が必要であると考えた。そこで本稿では、複数の動作生成モデルの統合手法を提案する。本提案手法では、各動作生成モデルそれぞれに、学習した動作の実行を開始するタイミングを決定するタイミング決定器を設け、各動作生成モデルの自律的 (ボトムアップ的) な統合を行う。本手法の検証タスクには、移動動作とマニピュレーション動作の連携が必要な動作例として「ドア開け通過動作」を選定し、本手法によって、移動を行う動作生成モデルとドア開けを行う動作生成モデルが、それぞれ別個に学習した要素動作を適切なタイミングで実行し、統合動作である「ドア開け通過動作」が実現できることをロボットの実機を用いて確認した。

2. 動作生成モデル (従来技術)

本研究の基本となる動作生成モデル (Fig.1) は、陽ら[2]のモデルを参考とし、カメラ情報から画像特徴量を抽出する自己符号化 NN (Fig.1(a)) と、ロボットの関節角と画像特徴量の時系列変化を学習する再帰型 NN (Fig.1(b)) から構成される。

自己符号化 NN には、Deep Convolutional Autoencoder (DCAE) を用いた。DCAE は砂時計型の Autoencoder と畳み込み層から

構成されており、入出力データが一致するように各層の重みを学習させることで、中間層で低次元の特徴量を抽出するものであり、ここでは、画像特徴量の抽出に用いる。

再帰型 NN には、入出力層と2つのコンテキスト層 (Cf 層, Cs 層) から構成される Multiple Time-scale Recurrent Neural Network (MTRNN) [3]を用いた。コンテキスト層は、時定数と呼ばれる値を持ち、Cf 層よりも Cs 層の時定数を大きな値にすることで、MTRNN をロボットの動作学習に用いた場合、Cf 層がロボットの短期的な動作を、Cs 層が長期的な動作を学習する。

この動作生成モデルの学習過程では、まず学習させたい要素動作をロボットに実際に実行させたときの画像および関節角データを学習データとして取得する。この学習データは、環境変化に柔軟な動作に対応できるように、条件を変えた複数のパターンを用意する。次に、取得した全画像の特徴量を DCAE に学習させ、さらに DCAE で抽出した画像特徴量とロボットの関節角を用いて、現在の状態から次の状態を予測するように MTRNN を学習させる。この学習により、動作生成モデルの実行過程では、ロボットが取得した現在の画像と関節角から、学習した動作を実現する次のステップの画像と関節角を出力できるため、この関節角を指令値としてロボットに与えることで要素動作の生成を行う。

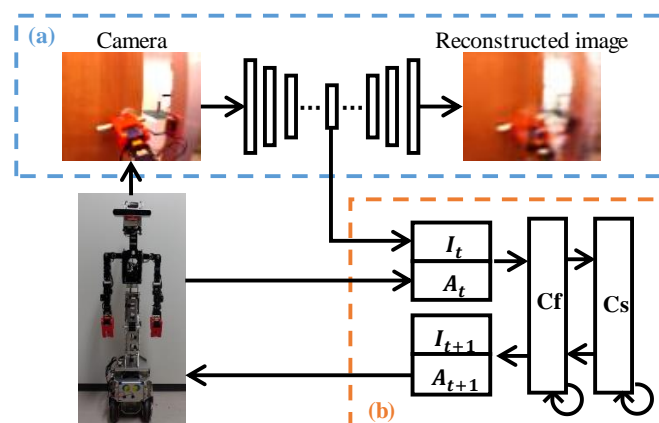


Fig.1 Outline of motion generation model

3. 統合手法 (提案技術)

ここでは筆者らが提案する動作生成モデルの統合方法について述べる。2つの動作モジュール(手, 足)の要素動作を獲得した複数の動作生成モデルを統合する構成例を Fig.2 に示す。ここでは複数の動作生成モデルを統合し連携動作を生成するために, 新たにタイミング決定器を提案する。タイミング決定器とは, 各動作生成モデルが学習経験の有無を判断し, 経験があると判断した時に動作生成モデルを始動させるものである。具体的には, DACE が過去に学習したことのある経験画像であれば, 入力画像の再構成が可能であることに着目し, ロボットの現在のカメラ画像と DCAE の再構成画像の誤差値とその変化量を計算し, ある閾値を越えた場合に MTRNN を始動させることで, 学習した要素動作の動作タイミングを決定する。タイミング決定器の閾値は, DCAE を学習させた際の入力画像と再構成画像の平均誤差値とし, ロボットのオンライン動作時の結果に基づいて調整することで動作タイミングの最適化を行う。このように, 従来の動作生成モデルに筆者らが提案するタイミング決定器を組み込むことで, 複数の動作モジュールの連携動作を実現する。

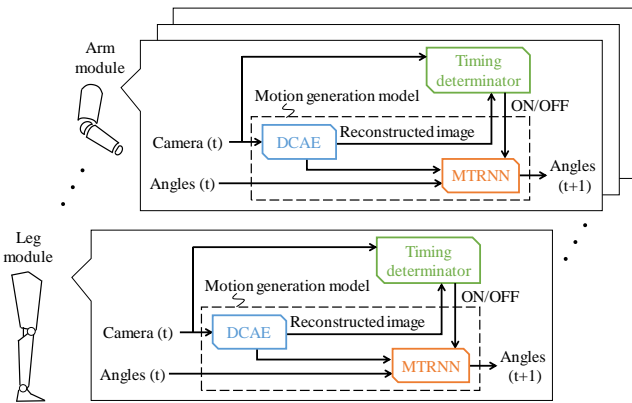


Fig.2 Outline of integration method

4. 実験設定

本手法の有効性を検証するために, Fig.1 に示す 6 自由度のアームと 1 自由度のグリッパ, そして移動台車から構成されるロボットを用いて, ドア開け通過動作の実験を行った。ドア開け通過動作のうち, ドア接近動作 Fig.3(a)とドア通過動作 Fig.3(c)を移動台車の動作生成モデルに, ドア開け動作 Fig.3(b)をアームの動作生成モデルに, それぞれ別個に学習させた後, それらを本提案手法にて統合することで各要素動作を連携させて一つの連続する動作を生成する。なおアームは, ドアへの接触およびドアの拘束のある動きに依う必要があるため, 電流制御による柔らかい動きと, 位置決め制御による目標軌道追従を両立する, 電流ベース位置制御を採用した。

5. 実験結果と考察

5.1 ドア接近及び通過動作の獲得

これまでに筆者らは, End to End Learning による自律移動システムの開発として, 移動台車を用いてドア接近及び通過動作の検証を行った[4]。この研究は, ドア接近動作とドア通過動作の 2 つの要素動作を 1 つの動作生成モデルに学習させ, 複数条件での移動動作の自動生成性能の評価を行ったものである。その結果, スタート位置が異なる未教示位置でも適切に目標位置へ自律移動することを確認した。

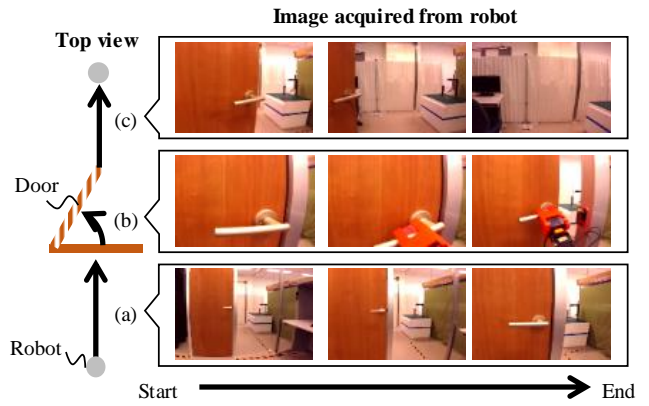


Fig.3 Snapshot of passing-through-door motion

5.2 ドア開け動作の獲得

移動台車のドア接近時の位置ずれに対し, 柔軟なドア開け動作を実現するために, Fig.4 に示すように左端点から 8cm 間隔でずらした位置 (青色丸) でのドア開け動作を学習させた。ドア開け動作生成の汎化性能を検証するために, 教示位置と未教示位置 (赤色丸) の各位置でドア開け動作を 10 回試行した結果, いずれの位置でも 80%以上の成功率で動作を生成することを確認した。

また, この時の NN の内部状態を可視化するため, MTRNN の Cf 層と Cs 層の主成分分析 (PCA) を行った。Fig.5(a)は, 教示位置においてドア開け動作を生成した際の Cf 層の主成分分析結果であり, 教示位置に応じてドア開け動作が要素動作として記憶されていることが分かる。また Fig.5(b)は, 教示位置および未教示位置においてのドア開け動作時の Cs 層の主成分分析結果である。黄色破線は未教示位置でドア開け動作を生成した際の Cs 層の特徴量を示しており, 教示点である 0cm と 8cm の間に生成されている。また, 赤色破線の未教示位置も同様に教示位置である 8cm と 16cm の間に生成されていることから, 未教示位置の破線は, Cf 層で獲得した要素動作を組み合わせることで, 未教示位置での動作を生成していることが確認できた。




Fig.4 Teaching position

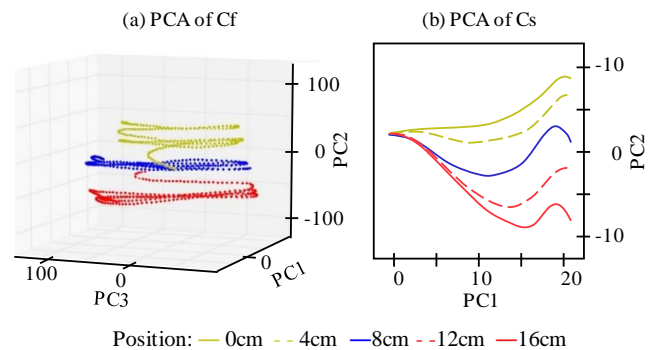


Fig.5 PCA of context neurons

5.3 複数動作統合

提案した複数動作生成モデルの統合手法を検証するため、ドア接近とドア通過動作を学習した動作生成モデルと、ドア開け動作を学習した動作生成モデルを用いて、ドア開け通過動作の評価を行った。

まず、ドア開け動作生成モデルの状況を可視化した結果を Fig.6 に示す。図には、ロボットの実際のカメラ画像 (上段)、ドア開け動作生成モデルの DCAE が再構成した画像 (中段)、そしてその時の DCAE の誤差値 (下段) を示している。図中の着色部分はロボットの各要素動作の動作区間を表しており、青色はドア接近動作、黄色はドア開け動作、そして緑色はドア通過動作を示している。ドア接近及びドア通過時のカメラ画像はドア開け動作生成モデルの DCAE には学習されていないため、カメラ画像を再構成できず、誤差値が大きくなっている。一方で、ドア開け動作中の 12 秒付近の画像では入力画像と類似した再構成画像が生成でき、誤差値が小さいことが確認できる。また、ドアに接近するにつれて誤差値は徐々に減少し、極小値付近の変化が止った地点が、ドア開け動作が開始する適切なタイミングであることが分かる。よって、カメラ画像と DCAE の再構成画像の誤差値とその傾きを計算することで、経験の有無の判別が可能であることが確認できた。

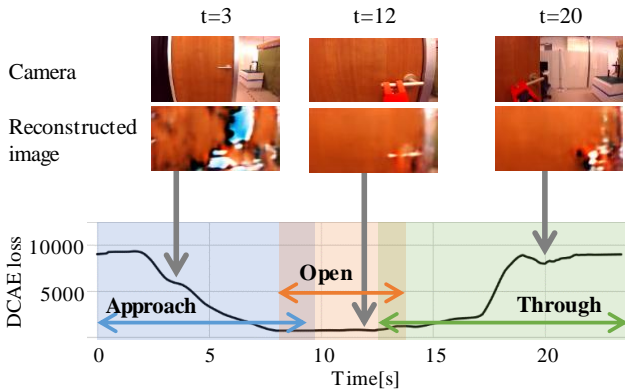


Fig.6 Reconstructed image and loss curve of DCAE

Fig7 は、実際に提案手法を用いてドア開け通過動作を実施したときの各動作生成モデルの DCAE の誤差値、アームの関節角度、移動台車の速度を示している。Fig.7(a)(c)より、動作開始直後では、ドア接近動作生成モデルの誤差値が低いことから、ドア接近動作生成モデルが動作していることがわかる。また Fig.7(a)(b)より、ロボットがドアに接近するにつれドア開け動作生成モデルの誤差値が徐々に減少し、8 秒付近でドア開け動作が生成されていることがわかる。この際、台車の速度は減少しながらアームはドア開け動作を生成していることから、ロボットは移動しながらドア開け動作を生成していることが分かる。また Fig.7(a)(c)より、ドアが開き始めるとドア通過動作生成モデルの誤差値の傾きがマイナス方向に急変し、移動台車はドア通過動作を生成していることがわかる。

以上より、DCAE の誤差値とその傾きをもとに、各動作生成モデルの動作タイミングを決定することで、複数の動作生成モデルが連携したドア開け通過動作が実現できることを確認した (Fig.8)。

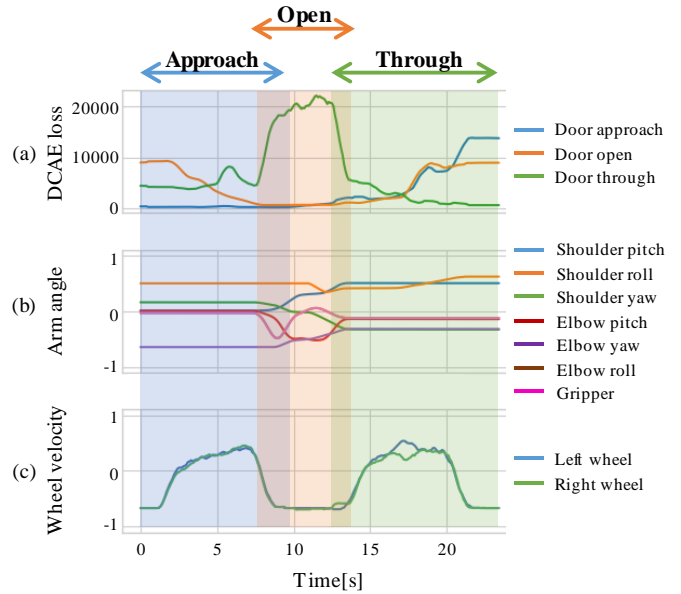


Fig.7 Robot state of passing-through-door motion




Fig.8 Snapshot of generated motion

6. まとめ

人が行う複雑な作業を実現するために、複数の動作生成モデルの統合手法を提案した。移動動作とドア開け動作を別個に学習した動作生成モデルに、学習経験の有無に基づいて動作生成モデルの動作タイミングを決定するタイミング決定器を組み込むことで、複数の動作生成モデルの統合によるドア開け通過動作を獲得した。

参考文献

- [1] Kuniaki Noda, Hiroaki Arie, Yuki Suga, and Tetsuya Ogata: Multimodal Integration Learning of Robot Behavior using Deep Neural Networks, Robotics and Autonomous Systems, Vol. 62, No. 6, pp. 721-736, 2014.
- [2] 陽品駒, 佐々木一磨, 鈴木彼方, 加瀬敬唯, 高橋城志, 菅野重樹, 尾形哲也: Wizard of Oz と深層学習によるロボットの柔軟物折り畳み作業, 日本ロボット学会第 34 回学術講演会, 2G2-05, 2016.
- [3] Y. Yamashita and J. Tani: "Emergence of Functional Hierarchy in a Multiple Timescale Neural Network Model: a Humanoid Robot Experiment," PLoS Comput. Biol., vol.4, no.11, 2008.
- [4] 日永田佑介, 伊藤洋, 山本健次郎, 尾形哲也: MTRNN を用いた End to End Learning による移動行動学習システムの開発, ロボティクス・メカトロニクス講演会講演概要集 2017, 2A2-D11, 2017.