

# フラットケーブルのコネクタ挿入のための 深層強化学習を用いたリーチング動作の生成

東京大学 ○山口 勇希, 中島 慎介, 小松 廉  
株式会社不二越 村上 弘樹, 中井 徹志  
東京大学 浅間 一, 安琪, 山下 淳

## 1. 序論

Flexible Flat Cable (FFC) や Flexible Printed Circuit (FPC) などのフラットケーブルは軽量で、電子機器の軽量化・小型化に伴って使用が増加している。フラットケーブルのコネクタへの挿入は訓練を受けた作業員による手作業で行われてきたが、少子高齢化による労働力の減少に対応するため、剛体部品と同様に自動化が必要とされている<sup>1)</sup>。しかし、現状の自動挿入ではケーブルやコネクタなどのワークのモデル登録や挿入動作の経路計画において人による調整が求められ、対象物や作業内容に応じて個別に動作のプログラミングをする必要がある。そのため自動挿入を大量導入する際の妨げとなっている。そこで、ケーブルの種類やロボットとの相対位置に対して汎用性があり、人の介入が少ない自動挿入動作の生成の実現が求められている。

人の手を介さない把持動作の生成手法として、深層学習を用いた手法が挙げられる<sup>2)</sup>。しかし、この手法では把持された物体の操作中の姿勢が考慮されていない。例えば、ケーブルに必要なねじれが生じると、内部で断線する可能性がある。

本研究では、人手を介さず、操作中の姿勢を考慮したフラットケーブルのコネクタ挿入動作の自動生成の実現のために、初期姿勢から把持姿勢までの動作生成手法を提案する。

## 2. 提案手法

### 2.1 問題設定

本研究では Fig. 1 に示したコネクタ挿入動作のうち、赤枠で示した初期姿勢から把持姿勢までの動作生成に取り組む。台の上に基板が設置され、基板の上にケーブルを挿入するコネクタが存在する。今回は簡単のためにケーブルの初期姿勢や相対位置が固定され、手先位置の制御のみを行うものとする。また、マニピュレータの手先にエンドエフェクタと RGB-D カメラが取り付けられている。

### 2.2 概要

深層強化学習による学習をシミュレーション内で行い、動作の自動生成を実現する。深層強化学習では、状態に応じて行動を出力するエージェントを環境から得られる報酬をもとに学習する。シミュレーションで学習したエージェントを実環境に適用するため、実環境でも取得可能な RGB-D 画像とマニピュレータの手先位置を観測として用い、現在の手先位置からの変位を行動とする。しかし、画像は次元数が非常に大きいため、深層強化学習での探索空間がも大きくなる。また、ケーブルやコネクタ以外の物体の写り込みによる不要な情報が含まれることによって、画像をそのまま状態入力に用いることは学習に悪影響を与えうる。そのため、画像から抽出した特徴量を状態入力として用いる。報酬として最終的な手先目標位置との距離や成功・




Fig. 1 問題設定

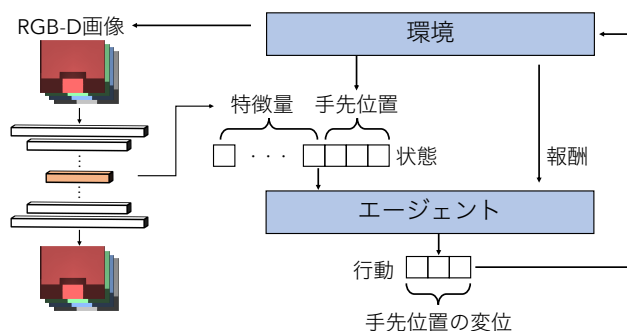


Fig. 2 提案手法の概要

失敗の情報を利用し、把持以降の動作ではひねり角度も用いる。ひねり角度とはケーブルの中心軸に対してケーブルの端部が回転した角度のことであり、ひねり角度が小さい動作はケーブルへの負担が小さい動作となる。Fig. 2 に提案手法の概要を示す。

### 2.3 RGB-D 画像の特徴量抽出

特徴量の抽出には Deep Convolutional Autoencoder (DCAE)<sup>3)</sup> を用いる。DCAE は入力を復元するように学習する Autoencoder と呼ばれる手法に Convolutional Neural Network (CNN) の特性を組み込んだものである。画像を圧縮するエンコーダと元の画像を復元するデコーダから構成され、その間の中間層での出力は次元が削減され、かつ入力画像をよく表現した値となっている。そのため、この中間層での出力を特徴量として用いる。

シミュレーション環境でマニピュレータをランダムに動作させて RGB-D 画像を収集し、DCAE の学習を事前に行う。深層強化学習では学習済みの DCAE で抽出した画像特徴量を用いて学習する。

### 2.4 深層強化学習

今回の条件では状態や行動に用いる手先位置、画像特徴量が連続値である。そのため、行動や将来得られる報酬の割引和の

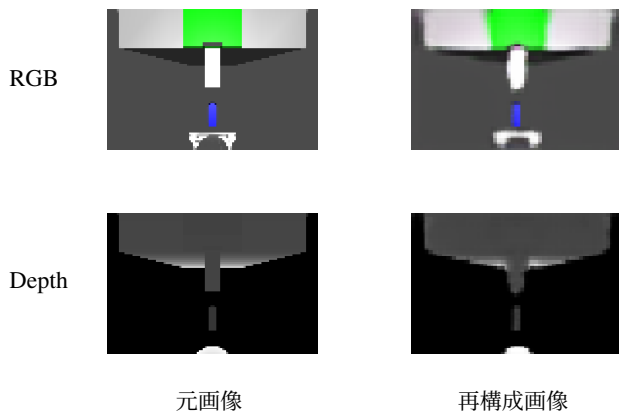


Fig. 3 DCAE の学習結果




Fig. 4 エピソードの累計報酬

期待値である Q 値の算出を Neural Network で行い、連続的な状態入力や連続値制御に対応している、Soft Actor-Critic (SAC)<sup>4)</sup>を用いる。深層強化学習に用いる報酬は次式で計算される。

$$r = \begin{cases} 10 & \text{if success} \\ -10 & \text{if fail} \\ -d & \text{else} \end{cases} \quad (1)$$

ここで、 $d$  は各ステップでの手先位置の目標との距離を表す。

### 3. シミュレーション実験

#### 3.1 実験環境

実験には MuJoCo<sup>5)</sup> を用いたシミュレーション環境を利用した。成功・失敗は各ステップで判断され、成功か失敗となった時点でそのエピソードを終了する。 $d < 0.01$  m を満たすときに成功、 $d > 0.2$  m を満たすか、環境中の物体とマニピュレータや RGB-D カメラ、エンドエフェクタが衝突したときに失敗とした。また、1 エピソードでの最大ステップ数は 100 とした。

#### 3.2 結果

10,000 枚の RGB-D 画像を用いて DCAE を学習した。2 割の画像を検証に利用し、Structural Similarity (SSIM) の更新が 30 回行われなくなる時点で学習を打ち切った。Fig. 3 は学習後の DCAE で初期姿勢での RGB-D 画像を再構成したものである。上段が RGB 画像、下段が Depth 画像、左列が元画像、右列が DCAE で再構成した画像である。再構成画像にはケーブルや基板があり、抽出した特徴量にもその情報が含まれていることが推測できる。




Fig. 5 学習後の動作

2,000 エピソードの学習を SAC に対して行った。学習時のエピソードの累計報酬のグラフを Fig. 4 に示す。1,000 エピソードを越えたあたりから学習が収束していることが確認できる。また、Fig. 5 は学習後の SAC で動作させたときの様子を示している。初期姿勢である上段から順に 1 ステップごとの動作を表し、下段の時点で終了条件を満たしている。つまり、初期姿勢から把持姿勢までの動作を 2 ステップで実現できている。

### 4. 結論

本研究の目的である、人が介入しない、操作中の姿勢を考慮したフラットケーブルのコネクタ挿入動作の自動生成するための手法として、DCAE による画像特徴量の抽出と SAC による深層強化学習を用いる手法を提案した。本報では、初期姿勢から把持姿勢までの動作生成についてシミュレーション環境で実験し、固定環境でのリーチング動作の生成に提案手法を適用可能であることが確認された。

今後は、ケーブルや基板の相対位置やケーブルの姿勢に対する汎用性を確認し、把持から挿入までの動作生成へ提案手法を拡張したい。最終的にはコネクタへの挿入までの一連の動作の生成をシミュレーションで達成し、実環境への適用を目指す。

### 参考文献

- 1) 木村 優太, 高氏 秀則, 金子 俊一: “ケーブルモデルによる多品種ケーブルの形状記述と最適把持への応用,” 電気学会論文誌 C, Vol. 132, No. 5, pp. 766–773, 2012.
- 2) S. Levine, P. Pastor, A. Krizhevsky, J. Ibarz and D. Quillen: “Learning Hand-Eye Coordination for Robotic Grasping with Deep Learning and Large-Scale Data Collection,” *The International Journal of Robotics Research*, Vol. 37, No. 4-5, pp. 421–436, 2018.
- 3) A. Alqahtani, X. Xie, J. Deng and M. Jones: “A Deep Convolutional Auto-Encoder with Embedded Clustering,” *Proceedings of the 2018 IEEE International Conference on Image Processing*, pp. 4058–4062, 2018.
- 4) T. Haarnoja, A. Zhou, P. Abbeel and S. Levine: “Soft Actor-Critic: Off-Policy Maximum Entropy Deep Reinforcement Learning with a Stochastic Actor,” *Proceedings of the 2018 International Conference on Machine Learning*, 2018.
- 5) E. Todorov, T. Erez and Y. Tassa: “MuJoCo: A Physics Engine for Model-Based Control,” *Proceedings of the 2012 IEEE/RSSJ International Conference on Intelligent Robots and Systems*, pp. 5026–5033, 2012.