

1. はじめに

力覚センサは、装着した部位にかかる力のベクトルを取得することができる。本研究では、力覚センサより取得したデータからロボットが把持した物体を識別することを目的とする。力覚データは系列データであり、一般的なニューラルネットワークでは連続的な変化を捉えることができない。そこで、本研究では系列データから有用な特徴を捉えることが可能な Recurrent Neural Network(RNN) を用いて識別をする。

2. 力覚センサと電流フィードバック

本研究では、入力として力覚センサと電流フィードバック (FB) を用いる。力覚センサは、図 1 に示すようにセンサの上部と下部との力の変位を計測する。静電気容量の変化から変位を計測し、力とモーメントを求める。測定された力覚データは、3次元の力ベクトル (Fx, Fy, Fz) と同軸の回転ベクトル (Mx, My, Mz) を合わせた6軸のデータとなる。




図 1: 力覚データの測定

図 2 に 2 つのアイテム (book, mailer) を把持し、ロボットアームを左右に動作させ停止した後の力覚値 Fy の遷移を示す。形状が似ていてもセンサ値の変動が異なることが分かる。




図 2: アイテムごとの力覚データの比較

電流 FB は、アームが動作する際に関節のモータの電流を測定した値である。測定される電流 FB は ($J_1, J_3, J_3, J_4, J_5, J_6$) の 6 軸からなる関節データである。そのため、電流 FB は動作や姿勢維持するために得られる値であり、ロボットの状態を取得できる。図 3 に 2 つのアイテム (scissors, curtain) を把持し、ロボットアームを左右に動作させ停止した後の電流 FB を示す。停止動作を実現するために、電流 FB の収束が把持物により変化する。




図 3: アイテムごとの電流 FB の比較

3. 提案手法

本研究では、産業用ロボット MELFA に装着された力覚センサと電流 FB より得られたデータを用いて RNN の学習と評価を行う。

3.1. 入力データ

提案手法では、アームが動作停止した後の 100 フレームの力覚データを扱う。取得した力覚データは力ベクトル、回

転ベクトル、電流 FB などの最大値をもとに求める。力ベクトルの最大値を $F_{\max}$ 、回転ベクトルの最大値を $M_{\max}$ 、電流 FB の最大値を $J_{\max}$ としたとき、 i フレーム目の入力データ x_i を求める式 (1) を示す。

$$x_i = \left[\frac{Fx_i}{F_{\max}}, \frac{Fy_i}{F_{\max}}, \frac{Fz_i}{F_{\max}}, \frac{Mx_i}{M_{\max}}, \frac{My_i}{M_{\max}}, \frac{Mz_i}{M_{\max}}, \frac{J_{1i}}{J_{\max}}, \frac{J_{2i}}{J_{\max}}, \frac{J_{3i}}{J_{\max}}, \frac{J_{4i}}{J_{\max}}, \frac{J_{5i}}{J_{\max}}, \frac{J_{6i}}{J_{\max}} \right] \quad (1)$$

3.2. 識別結果の統合

RNN は i フレーム毎にクラス c の確率 $P_i(c|x_i)$ を出力するため、1 つの系列データの結果を統合する。式 (2) により 100 フレームの確率を統合し、最終的な識別結果 $\hat{C}$ を式 (3) より求める。

$$P(c) = \frac{1}{100} \left(\sum_{i=1}^{100} P_i(c|x_i) \right) \quad (2)$$

$$\hat{C} = \arg \max_c P(c) \quad (3)$$

3.3. LSTM を用いたネットワーク構成

本研究では長期記憶を扱うことができる LSTM[1] を用いる。LSTM は、LSTM ユニットと呼ばれる記憶メモリと入力、出力、忘却ゲートを用いることで長期の記憶を可能とする。本手法のネットワークの構成を図 4 に示す。




図 4: ネットワークの構成

4. 評価実験

提案手法の有効性を確認するために評価実験を行う。本実験では、Amazon Picking Challenge 2016 で使用した 25 アイテムを対象とし、ロボット座標系で X, Y, Z の 3 軸方向へ往復させたデータを用いる。学習用データ 3,326 セット、評価用データは 375 セットを使用する。これらの実験により、力覚データ、電流 FB の有用性を比較する。

提案手法による識別結果の Confusion matrix を図 5、識別率を表 1 に示す。電流 FB を力覚データとともに入力することで、識別率を向上させる効果があることがわかる。




図 5: Confusion matrix の比較

表 1: 入力ごとの識別率 [%]

入力	力覚	電流 FB	力覚+電流 FB
識別率	79.7	4.0	85.3

5. おわりに

提案手法では力覚データを用いた物体識別を行った。今後はビジョンセンサを用いた把持を行い、結果の統合を行う。また、強化学習を導入し、識別しやすい動作の獲得方法について検討する。

参考文献

- [1] S.Hochreiter, *et al.*, “Long Short-Term Memory”, Neural Computation, 1997.