

SMA センサを用いた深層学習による触覚パターンの分類

大矢隆晟[†]澤田秀之[‡]早稲田大学先進理工学研究科[†]早稲田大学理工学術院[‡]

1. はじめに

我々はこれまでに、形状記憶合金 (Shape Memory Alloy: SMA) を微小変位センサとして応用することで、触覚情報を計測できることを報告してきた。本研究では、物体の表面を SMA センサでなぞることで触覚情報を収集し、深層学習により分類を行った。また高い精度で分類可能なことから、SMA を触覚センサとして活用できる可能性を示した。

2. SMA の特性

SMA に電流を流して温度を上げると、オーステナイト相と呼ばれる結晶構造に変態する。またオーステナイト相において物理的負荷を加えると応力誘起マルテンサイト相に変態し、外力を取り除くと直ちに元のオーステナイト相に戻る。これを超弾性現象という。超弾性現象において、SMA は電気抵抗変化を伴いながらオーステナイト相と応力誘起マルテンサイト相を可逆変化するが、この過程で R 相と呼ばれる結晶構造を経る。R 相は高い時間応答特性を有しており、外力を電気抵抗値の変化として高い時間分解能で取り出せる。この特性を利用することで触覚情報を計測できる。

3. SMA ワイヤを用いた触覚情報の計測

SMA ワイヤに金属ピンを取り付けることで、図 1 に示す触覚センサを作製した。金属ピンの先端部で触対象の表面をなぞることで、SMA ワイヤに負荷が加わり、これを抵抗値の変化として計測することが可能である。また、触覚情報の計測の際に押付け圧が変化して計測値に影響が出ないようにするため、ストッパーを取付けている。これにより、ストッパーの位置で金属ピンが物体に接触し、なぞる際の押し付け圧を一定に保つことができる。SMA ワイヤの抵抗値変化を計測するために、図 2 に示す分圧回路を設計した。これにより電源電圧 $V_{cc} = 3.3(V)$ が 10Ω 抵




図 1 SMA 触覚センサ




図 2 分圧回路




図 3 実験装置の構成

抗と SMA の抵抗 R_{sma} によって分圧され、 V_{out} として得られる。

$$V_{out} = 3.3 \cdot \frac{10}{10 + R_{sma}} \quad (1)$$

分圧回路への電力供給及び分圧計には、電圧の入力と出力が同時に可能な Arduino uno を用いた。

図 3 に実験装置の構成を示す。また実験の手続きを以下の(1)～(4)に示す。なお、実験で使用した 10 種類の触対象を図 4 に示した。

- (1) Arduino uno から分圧回路を通して SMA ワイヤに定電圧($V_{cc} = 3.3(V)$)を印可し、オーステナイト相に変態させる
- (2) SMA 触覚センサの金属ピンで触対象の表面をなぞる
- (3) SMA ワイヤの電気抵抗値変化を分圧回路の電圧変化として取り出す。サンプリング周波数は 11.1Hz とした
- (4) 電圧変化の計測値をシリアル通信で PC に送信する




図4 触対象




図5 分圧回路の電圧変化

取得した電圧値を、Pythonのグラフ描画ライブラリである matplotlib を用いてリアルタイムに描画した。例として、スポンジをなぞった際の出力波形を図5に示す。10種類の触対象に対して、それぞれ450秒分のデータを収集した。

4. 触覚パターンの分類実験

4.1. LSTMの構成

計測値が時系列データであることを考慮して、パターン分類器には深層学習のアルゴリズムの一つである LSTM(Long short-term memory)を用いた。今回使用した LSTMは、単層で128次元の隠れ層を持ち、最適化手法には RMSprop を使用した。また、過学習防止の為、LSTM層と出力層の間に Dropout(=0.2)を挿入した。

4.2. 入力データの前処理

収集したデータに対して階差系列への変換及び、移動平均処理からトレンドの除去を行い、生データと合わせて特徴量を3つとした。それぞれの波形に対して平均を0で分散を1にする標準化処理をした後、1.8秒分の波形を0.27秒ずつ分割して LSTMの入力データとした。

4.3. 分類結果と考察

図6に、LSTMによる触覚パターンの弁別精度を混同行列としてまとめた。全体の弁別精度は81.1%となった。テーブルと指は90%以上の精度で弁別できることがわかる。テーブルについては、他の9種類の触対象に比べて表面の凹凸が少ないため、有効に弁別できたと考えられる。指は表面が丸みを帯びているため、SMA触覚センサの金属ピンが大きく上下運動した可能性が考

Truth										
	table	chair	denim	cardboard	PET bottle	finger	magic tape	sponge	packing tape	towel
table	93.08	0.00	0.00	2.31	4.62	0.00	0.00	0.00	0.00	0.00
chair	0.00	74.62	1.54	0.00	0.00	10.00	2.31	3.08	0.77	7.69
denim	0.00	3.85	76.15	0.00	0.77	0.00	8.46	2.31	6.15	2.31
cardboard	10.00	0.00	0.00	88.46	1.54	0.00	0.00	0.00	0.00	0.00
PET bottle	14.62	0.00	0.00	0.00	85.38	0.00	0.00	0.00	0.00	0.00
finger	0.00	1.54	0.00	0.00	0.00	96.92	0.00	0.00	0.00	1.54
magic tape	0.00	5.38	1.54	0.00	0.00	0.00	89.23	2.31	0.00	1.54
sponge	0.00	2.31	0.00	0.00	0.00	0.77	3.85	60.77	0.00	32.31
packing tape	0.00	0.00	6.92	6.92	0.00	0.00	0.00	0.00	86.15	0.00
towel	3.08	0.00	0.77	0.00	9.23	0.00	6.92	20.00	0.00	60.00
Prediction										
	table	chair	denim	cardboard	PET bottle	finger	magic tape	sponge	packing tape	towel

図6 パターン弁別率[%]の混同行列

えられる。一方、スポンジとタオルは弁別精度が60%弱にとどまり、また相互に誤分類していることがわかる。これはいずれも柔らかくふわふわとした素材であり、凹凸の差異が少ないことが原因と考えられる。このように分類精度は触対象によって差はあるものの、良好な認識ができた。

5. おわりに

本研究では SMA 触覚センサによって物体の表面をなぞり、LSTMによって触覚パターンの分類を行った。その結果、10種類の触対象に対して81.1%の分類精度が得られた。

今回の実験では10種類の触対象に対して触覚パターンの分類を行ったが、実生活で SMA 触覚センサを活用するには、より多様な触覚パターンを分類する必要がある。そのために、サンプリング周波数を上げる、回路を工夫して電圧変化の感度を上げるなど、更に検討を進める。また、今回はシンプルな LSTM を用いたが、CNNなど他の機械学習モデルを検討し、アンサンブル学習を行うなど、精度向上を試みる。

参考文献

- [1] 宮戸田顕音, 重宗宏毅, 三輪貴信, 澤田秀之: 微小振動する形状記憶合金ワイヤを用いた触覚センサ, 電子情報通信学会論文誌 C, J102-C(9), pp.241-248, 2019
- [2] Wonmin Byeon, Marcus Liwicki, Thomas M.Bruehl: Texture Classification using 2D LSTM networks, ICPR, pp.1144-1149, 2014