

無線型加速度センサと畳み込みニューラルネットワークを用いた触対象の分類

Classification of Rubbing Objects

Using Wireless Accelerometers and Convolutional Neural Network

○我妻正太郎 (筑波大学) 中川真史 (筑波大学)
小野智義 (筑波大学) 高橋伸 (筑波大学)
志築文太郎 (筑波大学) 嵯峨智 (熊本大学)

Shotaro AGATSUMA, Masafumi NAKAGAWA, Tomoyoshi ONO,
Shin TAKAHASHI, Buntarou SHIZUKI, University of Tsukuba
Satoshi SAGA, University of Kumamoto

Many methods of collecting haptic information were proposed by many reserchers. In our previous research, we proposed a method of collecting accelerations in haptic behaviors using wireless accelerometers. The method enables to collect haptic information easier than other previous methods. However, classification of the information was not researched enough. Therefore, in this paper, we collected haptic information using the method and classify the information using Convolutional Neural Network. We performed an experiment to classify rubbed objects. Our system classified 90 kinds of haptic information by 88.7%. In addition, we performed an experiment to classify rubbed objects in real-time. Our system classified 15 types of object, 71.0% on average.

Key Words: wireless accelerometer, collecting haptic information, convolutional neural network

1 はじめに

様々な触覚を提示する機器、触覚ディスプレイが一般的に普及し、リアリティの高い触覚情報が提示されるようになりつつある。触覚ディスプレイが使用されている例としては、ゲーム機のコントローラや振動するスマートフォンなどが挙げられる。

触覚ディスプレイの普及に伴い、触覚情報を収集するシステムに関する研究が多く行われている。収集された触覚情報は、主に触覚ディスプレイの出力に応用されている。また、触覚ディスプレイにおいて適切な触覚提示を行うため、収集された触覚情報を分類する試みも多く行われている。先行研究においては、触覚情報の収集と分類を両方行っている場合が多い。

ここで、触覚情報を収集するシステムに関する先行研究を示す。Abdulaliら [1] は、圧力センサと加速度センサを複合した専用の機器を PHANTOMに取り付けて動作させることで、9種類の素材の表面の情報を収集した。また、収集した情報をニューラルネットワークを用いた機械学習手法の一つである RBFNにおいて分類した。Streseら [2] は、6種類のセンサを複合した装置を開発し、108種類の物体表面の触覚情報を収集した。また、収集した情報をユークリッド距離、マハラノビス距離、ガウス混合モデルの3種類の機械学習手法において分類を行った。

これらの先行研究では、様々なセンサを複合した専用の機器を開発して触覚情報の収集を行っている。先行研究の手法では限定的な実験環境下での触覚情報収集は可能であるが、実験環境外、例えば日常的な行動における触覚情報を収集することは難しい。

この問題を解決するため、我々の研究グループでは、複雑な機器を用いずに触覚情報を容易に収集する手法を提案している [3,4]。我々が提案している手法では収集する触覚情報を加速度情報に限定し、無線型加速度センサにより、先行研究の機器より手軽に触覚情報を収集する。これまで、この手法により机上の触覚行動における加速度を収集し、畳み込みニューラルネットワーク (CNN) を用いた機械学習を行うことで、触覚動作の分類が可能であることを示してきた。これまでのところ、CNNを用いた機械学習により、30種類のデータを約90%で分類することに成功している。しかし、30種類より多い種類のデータの分類や、情報収集のやり方による分類精度の変化など、検討するべき事項が多く存在する。

そこで、本研究では、CNNを用いた機械学習により触覚情報の分類を試み、分類に関してのさらなる調査を行った。物体の表面を無線型加速度センサを装着した指またはペンでなぞり、触覚情報収集を行った。3種類の触察速度でそれぞれ30種類の触覚情報を収集した。これらのデータを全てまとめて90種類として分類を行った結果、88.7%であった。また、同一の物体をなぞった速度の異なるデータを1種類のデータにまとめることで30種類分類を行った結果、88.9%であった。これらの結果から、分類する触覚情報の量をさらに増加させても分類が可能であることがわかった。また、触察対象をリアルタイムに分類する実験を行った。15種類の物体を平均71.0%で分類することに成功した。

2 触覚情報の収集と分類

本節では、今回用いた触覚情報の収集手法と分類手法について示す。無線型加速度センサを用いて加速度情報を収集し、CNNを用いた機械学習により分類する。

2.1 無線型加速度センサ

TECHTILE toolkit [5]をはじめとする多くの実装例において、200 Hzを中心とした0-1 kHz帯の機械振動を用いて、リアリティの高い触覚提示がなされている。よって我々も200 Hzを中心とした振動情報を収集できる加速度センサを用いて触覚情報収集を行う。

今回我々は、TWE-Lite-2525A [6] (MonoWireless Inc.) という既製品のデバイスを用いた。このデバイスを図1に示す。このデバイスには3軸加速度センサとZigBee無線モジュールが内蔵されている。電源にはボタン電池 (CR2032) が用いられている。大きさは25 mm四方、重さはボタン電池を含めて6.5 gである。ZigBeeによる無線通信が可能であることから、計測した加速度情報を受信するデバイスから離れた場所においても触覚情報収集が可能である。TWE-Lite-2525Aに搭載されている3軸加速度センサはADXL345であり、素子単独では最大800 Hzでの加速度計測が可能である。

また、省電力化のため、デバイスにスリープ機能を追加した。測定した加速度が設定した閾値を超えるまで、通常の測定より低

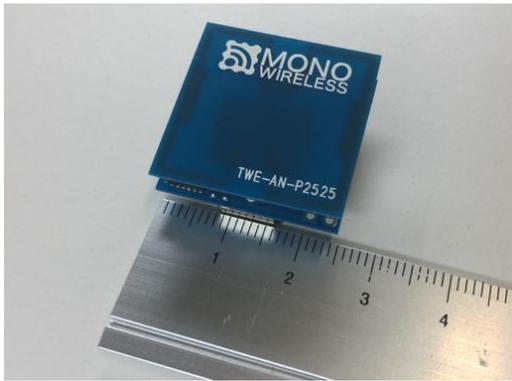


Fig.1: TWE-Lite-2525A [6] (MonoWireless Inc.).

3 分類実験

本節では前節で述べた手法を用いて触覚情報の収集と分類を行う。その結果から、収集した情報をどの程度の精度で分類可能か調査する。今回はデータ収集時の触覚行動の速度に着目し、同じ物体に対して異なる速度で触覚行動した際のデータを分類できるか調査する。また、あらかじめ収集したデータを用いて、触察した対象をリアルタイムに識別できるか調査する。

3.1 触察時の速度が異なるデータの分類

同じ物体に対して異なる速度で触覚行動した際のデータを分類できるか調査する実験を行った。

3.1.1 実験の条件

TWE-Lite-2525A を 3D プリントした専用のケースに入れて指またはペンに装着し、15 種類の物体 (テクスチャ) をなぞることによって著者 1 名が触覚情報を収集した。その様子を図 3 に示す。また、用いたテクスチャを図 4 に示す。

周波で測定し、閾値を超えて初めて通常の測定を開始する。

2.2 データの送信

機械学習による分類を行うため、収集した加速度情報を ZigBee を用いた無線通信により PC に送信する。前述の通り、TWE-Lite-2525A に搭載されている加速度センサ、ADXL345 は通常 800 Hz で計測が可能である。しかし、無線モジュールと PC 間の ZigBee 通信を考慮しなければならず、実際の値は 800 Hz に比べて下がる。TWE-Lite-2525A の加速度計測レートは購入時に書き込まれているプログラムでは 33 Hz となっており、そのままの実装では十分に触覚情報が収集できない可能性がある。そこで、連続する 10 点の加速度計測値をまとめて 1 つのパケットとして送信する方式を採用し、マイコンのプログラムを書き換えた。これにより、3 軸加速度を 330 Hz で計測することが可能になった。

2.3 CNN による分類

CNN を用いた触覚情報の分類について述べる。CNN では入力データに畳み込み演算を行うことでデータの空間的形状を維持したまま学習を行うことができる。この特徴から、データの形状やパターンが重要であるデータの分類に適しており、計測した加速度情報の形状を効率的に学習できると考えられる。本研究では、計 13 層の CNN を用いた。その概略図を図 2 に示す。



Fig.3: Collection of haptic information.



Fig.4: Textures.

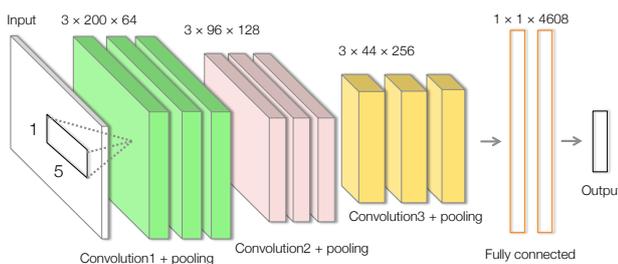


Fig.2: Composition of CNN.

この CNN において、入力は 3 軸加速度データ連続 200 点分 (3×200) とし、出力は入力したデータがどの触覚情報であるかの確率とする。この CNN の構成は代表的な CNN の構成の一つである VGG [7] の構成を参考に、一回の畳み込みにおいて畳み込む量を減らし、畳み込み層自体を増やすことで精度の向上を図った。この CNN の畳み込みフィルタのサイズは全畳み込み層において 1×5 とした。フィルタの数は畳み込み第 1 層、第 2 層では 64 枚、第 3 層、第 4 層では 128 枚、第 5 層、第 6 層では 256 枚とした。プーリングは、全プーリング層において 1×2 の Max プーリングを用いた。活性化関数には全ての層において ReLU 関数 [8] を用いた。損失関数には交差エントロピー誤差を用いた。重みの最適化アルゴリズムには Adam [9] を用いた。また、過学習を抑制するため、各層の活性化関数を計算後に Batch Normalization [10] を適用した。さらに全結合第 2 層から出力層の間に Dropout [11] を使用し、過学習の抑制を図った。

carpet1, carpet2, carpet3 が素材の異なる絨毯の一部、sponge-g, sponge-y が家庭用スポンジの表と裏、sponge-b が板状のスチレンフォーム、stonetile1, stonetile2, stonetile3 が質感の異なる石のタイル、whitetile1, whitetile2, whitetile3 が質感の異なるフローリングタイル、woodtile1, woodtile2, woodtile3 が質感の異なる木の板である。

これらの物体をほぼ一定の速度で、左右に往復させて 3 分間なぞることにより触覚情報を収集した。この動作を 1 つの物体につき 3 回行うことで、物体 1 つにつき 9 分間の加速度データを収集した。なぞる速度は約 100 mm/s, 約 200 mm/s, 約 400 mm/s の 3 種類とした。図 4 の 15 種類の物体を指またはペンでなぞることで、各速度ごとに 30 種類、計 90 種類の触覚情報を収集した。

収集したデータを CNN を用いた機械学習により分類を行う。まず、収集した 90 種類のデータを分類できるか検証した。次に、触覚行動の速さが分類に与える影響を調査するため、同じテクスチャをなぞった速度が異なるデータ 3 種類を 1 つのクラスにまとめ、30 クラス分類を行った。分類の際、分類に用いるデータの 9 割を訓練データとし、残りの 1 割でテストを行った。CNN の入力については、収集したデータの中からランダムに取り出した 3 軸加速度連続 200 点のデータとした。出力は、入力データがどのテクスチャのデータであるかの確率とし、この確率が一番大きいテクスチャを分類結果とした。結果について、CNN によって

作成されるモデルの汎化性能を確認するため、10分割交差検証を行った。

3.1.2 結果

収集したデータを分類した精度についての結果を表1に示す。

Table 1: Result of classification.

	90 種類分類	30 クラス分類
分類精度	88.7%	88.9%

各速度で収集したデータを全てまとめて90種類の分類を行った結果、88.7%であった。また、同じテクスチャをなぞった速度が異なるデータ3種類を1つのクラスにまとめ、30クラスとして分類を行った結果、88.9%であった。この結果からまず、以前の研究の30種類分類から分類するデータの数を90種類に増加させても高い精度での分類ができることがわかった。また、30クラス分類においても90種類分類と同じく高い精度を維持することができたことから、触察速度に関係なく触察した物体を分類できる可能性があることがわかった。今回用いた速度は3種類のみであるが、これらと異なる速度でなぞった場合の分類への影響を今後調査する必要がある。また、今回はテクスチャを左右になぞることと触覚情報を収集したが、この方法と異なる方法で収集した場合、収集したデータ分類できるか調査する必要がある。

3.2 触察対象のリアルタイム分類

あらかじめ収集したデータを用いてCNNのモデルを作成し、このモデルを用いて触察した対象をリアルタイムに分類する実験を行った。

3.2.1 実験の条件

これまでの実験同様、TWE-Lite-2525Aを指に装着し、著者1名によりテクスチャを左右になぞることにより触覚情報を収集した。この実験で用いたテクスチャは図4の15種類である。テクスチャを約400 mm/sで左右に5秒間なぞることによって触覚情報を収集した。この操作を各物体ごとに90回行い、一つの物体につき90個のデータを収集した。

この90個のデータからCNNモデルを作成する。CNNの入力と出力、設定については、3.1節の実験と同様である。作成したCNNモデルを用いて、リアルタイムに触察した対象を分類する。CNNモデル作成の際と同じく、5秒間テクスチャをなぞり、なぞり終わった瞬間にCNNモデルによりデータを分類する。分類を行う際、収集した5秒間のデータから連続200点を10個抜き出すことで、1回の収集ごとに10回の収集を行い、実験の効率化を図った。1回データを収集し、分類することを1セットとして、1物体あたり20セット行う。

3.2.2 実験結果

収集した5秒間のデータから10個のデータを抜き出し分類した精度は表2のようになった。

分類の結果、精度は全体平均で46.8%という結果となった。また、この実験では、収集した5秒間のデータから10個のデータを抽出しているが、10個の中で最も分類された頻度が高かったものを全体の分類結果として扱った場合、精度は全体平均で71.0%であった。この結果は表2において、“最頻抽出精度平均”として示されている。

表2を見ると、CNNの出力の精度の全体平均は46.8%と、3.1節の実験のものより低い結果となった。この結果の原因としては、データの収集ごとに指でなぞる速度や指の角度などの触覚情報収集の条件が微小に変化している可能性があるからだと考えられる。人が実際にテクスチャをなぞるため、機械による収集とは異なり、完全になぞる速度や指の角度を固定することは実質不可能であり、この変化をCNNモデルがうまく学習できず、新たに収集したデータを分類することができなかつたと思われる。この問題に対処するため、今後はデータ収集方法を見直す必要があることがわかった。また、CNNモデル作成の際に使用するデータの数を増加させれば、CNNモデルがより多くのデータに対応できるようになる可能性がある。

表2の“最頻抽出精度平均”を見ると、全体平均で71.0%と、全体で見た場合、CNNの出力をそのまま分類結果として利用するより精度の改善が見られた。テクスチャによっては分類精度

Table 2: Result of real-time classification.

	精度平均	最頻抽出精度平均
carpet1	62.5%	95.0%
carpet2	68.5%	100%
carpet3	55.0%	80.0%
sponge-b	43.5%	65.0%
sponge-g	41.0%	70.0%
sponge-y	48.0%	80.0%
stonetile1	31.5%	50.0%
stonetile2	53.0%	80.0%
stonetile3	25.5%	30.0%
whitetile1	50.0%	85.0%
whitetile2	56.5%	85.0%
whitetile3	61.5%	95.0%
woodtile1	32.5%	35.0%
woodtile2	30.0%	40.0%
woodtile3	43.5%	75.0%
全体平均	46.8%	71.0%

が90%を超え、高い精度での分類に成功した。一方でstonetile3の結果など、分類精度が30-40%ほどの低い結果となったテクスチャも存在している。表2から、テクスチャごとの分類精度を見ると、この最頻抽出の手法を用いた場合、CNNの出力の精度が40%を超えているテクスチャに関しては大きな精度の改善が見られたものの、40%を下回っているテクスチャに関しては、精度の改善は見られなかつた。これは、もともとのCNNの出力の精度が30-40%の低い結果である場合、正解の分類結果が最頻にならない場合が多かつたからと考えられる。これらの考察から、今回の実験の条件でリアルタイム分類を行う場合、CNNの出力の精度が40%を越えれば、高い精度での分類ができる可能性があることがわかつた。

4 おわりに

我々は先行研究のものより手軽に触覚情報を収集する手法として、無線型加速度センサを用いた手法を提案しているが、収集した情報の分類に関して、検討すべき事項が多く存在していた。そこで本稿ではCNNを用いた機械学習によって、以前よりも多くの種類の触覚情報を分類できるか実験を行った。さらに、触覚情報を収集する際の触覚行動の速さに着目し、同じ触覚行動を異なる速さで行った場合のデータについて分類を行った。さらに、あらかじめ収集した触覚情報からCNNのモデルを作成し、触察した対象をリアルタイムに分類する実験を行った。

無線型加速度センサを指やボールペンに装着し、約100 mm/s、約200 mm/s、約400 mm/sの3種類の速度で15種類のテクスチャをなぞることにより、各速度ごとに30種類の触覚情報を収集した。これらを全てまとめて90種類分類を行った結果、88.7%の精度を得ることに成功し、以前より多い種類の触覚情報を高い精度で分類することに成功した。さらに、同一のテクスチャをなぞった速度の異なるデータ3種類を1つのクラスにまとめて30クラス分類を行ったところ、88.9%の精度を得ることに成功し、触察速度に関わらず、触察した物体を分類できる可能性があることがわかつた。また、触察した対象をリアルタイムに分類する実験を行った結果、平均46.8%、最頻値抽出を行った場合平均71.0%という結果になった。これらの結果から、現在のCNNでは、人がテクスチャをなぞる際の速度や指の角度などの微小な変化をうま

く学習できていない可能性があることがわかった。

本稿ではテクスチャを3種類の速度でなぞることにより収集した触覚情報を分類する実験を行った。今後は、今回の3種類以外の速度での収集を行い、分類実験を行うことで、触察速度が分類に与える影響について、さらなる調査を行う。また、リアルタイムでの触察物体の分類を行った。今後、リアルタイム分類については、CNNの設定を見直すことにより、触察時の微小な条件の変化を効率的に学習できるようにする。また、今回の実験の条件を変化させず、CNNモデル作成の際のデータの数を増加させることでモデルの汎化性能を上昇させる。さらに、CNN以外の機械学習手法を用いた場合の検証も行う。特に、時系列データを扱うことに優れているとされる、再帰型ニューラルネットワーク (RNN) ベースの機械学習手法を用いることで精度の向上が期待できる。

また、我々の一連の手法を応用した具体的なアプリケーションの開発についても検討していく予定である。

参考文献

- [1] Arsen Abdulali and Seokhee Jeon. Data-Driven Modeling of Anisotropic Haptic Textures: Data Segmentation and Interpolation. In *Haptics: Perception, Devices, Control, and Applications: 10th International Conference, EuroHaptics 2016, London, UK*, pp. 228–239. Springer International Publishing, 2016.
- [2] Matti Strese, Yannik Boeck, and Eckehard Steinbach. Content-based Surface Material Retrieval. In *2017 IEEE World Haptics Conference (WHC), Fürstenfeldbruck (Munich), Germany*, pp. 352–357. IEEE, 2017.
- [3] 嵯峨智, 中川真史, 小野智義, 潘振雷, 張嘉袁. Zigbee を利用した日常の触覚情報収集. 電気学会研究会資料 (知覚情報研究会・力触覚提示デバイス), Vol. 2017, No. 52, pp. 11–14, 2017.
- [4] 我妻正太郎, 中川真史, 小野智義, 嵯峨智, 高橋伸. Zigbee マイコンによる触覚情報収集と深層学習による分類手法. 第18回計測自動制御学会システムインテグレーション部門講演会予稿集, pp. 467–471. 計測自動制御学会, 2017.
- [5] Kouta Minamizawa, Yasuaki Kakehi, Masashi Nakatani, Soichiro Mihara, and Susumu Tachi. TECHTILE toolkit: A prototyping tool for designing haptic media. In *ACM SIGGRAPH 2012 Emerging Technologies*. ACM, 2012.
- [6] Mono Wireless Inc. TWE-Lite-2525A. (<https://mono-wireless.com/jp/products/TWE-Lite-2525A>).
- [7] Karen Simonyan and Andrew Zisserman. Very Deep Convolutional Networks for Large-Scale Image Recognition. In *International Conference on Learning Representations*, arXiv:1409.1556, 2015.
- [8] Xavier Glorot, Antoine Bordes, and Yoshua Bengio. Deep sparse rectifier neural networks. In *Fourteenth International Conference on Artificial Intelligence and Statistics*, Vol. 15 of *Proceedings of Machine Learning Research*, pp. 315–323. PMLR, 2011.
- [9] Diederik Kingma and Jimmy Ba. Adam: A method for stochastic optimization. In *The International Conference on Learning Representations*, arXiv:1412.6980, 2015.
- [10] Sergey Ioffe and Christian Szegedy. Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift. In *International Conference on Machine Learning*, pp. 448–456, 2015.
- [11] Nitish Srivastava, Geoffrey E Hinton, Alex Krizhevsky, Ilya Sutskever, and Ruslan Salakhutdinov. Dropout: a simple way to prevent neural networks from overfitting. *Journal of machine learning research*, Vol. 15, No. 1, pp. 1929–1958, 2014.