

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

○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), 嵯峨 智 (筑波大学), 高橋 伸 (筑波大学)

ZigBee-Microcomputer-based Tactile Data Collection and A Classification Method by Deep Learning

○Shotaro AGATSUMA (University of Tsukuba), Shinji NAKAGAWA (University of Tsukuba), Tomoyoshi ONO(University of Tsukuba), Satoshi SAGA(University of Tsukuba), and Shin TAKAHASHI(University of Tsukuba)

Abstract : In the research field of tactile display, many researchers are developing systems that employs recorded vibrations as a tactile signal, and these systems present high-quality tactile sensations. To enhance this kind of displaying method, it is necessary to collect and classify recorded vibration in haptic behaviors. Here, we focused on accelerations in haptic behaviors. In previous research, we proposed a method of collecting accelerations in haptic behaviors using ZigBee-based microcomputer. In this paper, to classify 30 classes of haptic information, we applied a deep learning based classification. With the result, we discussed the possibility of combination of collecting vibration in tactile behaviors and deep learning.

1. はじめに

近年, 様々な触覚を提示する機器 (触覚ディスプレイ) において, リアリティの高い触覚情報が提示されるようになってきた。ゲーム機のコントローラ等, 一般的に普及している機器も多い。

研究分野における触覚ディスプレイの多くは, 記録された振動を触覚信号として利用する方式がよりリアリティの高い触覚提示を実現している。この方式による触覚提示の実現には, 触覚行動における振動情報を収集, 記録し, それを分類する必要がある。これに伴い, 触覚情報を収集, 分類するシステムの研究が多く行われている。

例えば, Strese et al. [1] は圧力センサ, 加速度センサ, 赤外線センサ, 金属探知器, マイク, カメラの6つの機器を搭載した専用の触覚情報収集装置を開発し, 108種類の物体表面の触覚情報を収集, 分類した。Abdulali et al. [2] は, 圧力センサ, 加速度センサを用いて触覚情報を収集することにより, 異方性素材における物体表面の触覚のモデリングの手法を提案した。これらの研究の多くは数多くのセンサを複合した専用のデバイスを用いた限定的な実験環境下での触覚情報収集を行っている。そのため, 実験環境外, 例えば日常的な触覚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]。我々が提案する手法では, 収集する触覚情報を加速度情報に限定し, ZigBeeを用いた小型無線マイコンにより, 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での触覚行動に

おけるデータを収集し, Support Vector Machine(SVM)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。さらに, Convolutional Neural Network(CNN)を用いた機械学習によって, SVMを用いた際よりも多くの種類のデータを分類できる可能性があることを示した。これまでのところ, CNNを用いた機械学習による分類により, 18種類のデータを約93%ほどで分類することに成功している。しかし, 18種類より多い種類のデータの分類や, 触覚情報収集のやり方による分類精度の変化など, 我々のCNNを用いた分類手法には検討すべき事項が多く存在する。

そこで, 本稿では, 我々の提案手法であるZigBeeマイコンによる触覚情報収集の枠組みはそのままに, CNNを用いた機械学習により触覚情報の分類を試みた。分類するデータを以前の18種類から30種類にまで増加させ, 分類を行った。また, 触覚行動の速さに着目し, 同じ行動を異なる速さで行って得た触覚情報を分類可能か調査した。これらの実験の結果から, 我々の手法による触覚行動の分類の可能性について検討した。結果, 30種類のデータを精度約90%で分類することに成功した。また, 同じ行動を異なる速さで行って得た触覚情報を分類することにも成功し, 我々の手法による触覚情報分類の可能性が広がった。

2. 触覚情報収集, 分類手法

本節では, 今回用いた触覚情報収集手法について示す。ZigBeeを用いた小型無線マイコンにより加速度情報を収集し, CNNを利用した機械学習により分類する。以降ではこの手法を構成する要素について詳述する。

2.1 加速度センサ付き ZigBee マイコン

触覚情報を利用した多くの研究では、0–1 kHz 程度の周波数帯の機械振動が数多く利用されている。TECHTILE toolkit [4] をはじめとした、研究分野における実装例において高いリアリティを示している。よって、我々の手法においても、0–1 kHz 程度の振動情報を触覚情報として収集する。そのために、0–1 kHz 程度の振動情報を収集できる加速度センサを搭載した小型 ZigBee マイコンによる実装を行う。

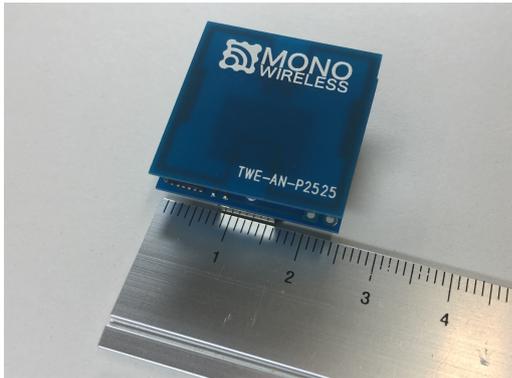


Fig. 1: TWE-Lite-2525A, Mono Wireless Inc [5]. This sensor node includes 3-axis accelerometer, ZigBee transfer module and a battery cell (CR2032).

今回我々は、TWE-Lite-2525A (MonoWireless Inc. [5]) という既製品のデバイスを用いた。このデバイスを Fig. 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おり、電源にはボタン電池が用いられている。大きさ 25 mm 四方、重さ 6.5 g と小型であり、ZigBee を用いた無線通信を行うことができることから、様々な物体に取り付けて動作させることが可能である。さらに、既製品であることから、入手が容易である。また、開発環境も整備されており、簡単なマイコンのプログラム更新により、誰でも容易に使用が可能である。このデバイスには 3 軸加速度センサは ADXL345 が搭載されている。ADXL345 は通常、800 Hz での振動情報の収集が可能である。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、低周波で測定し、閾値を超えて初めて高周波での測定を開始する。

2.2 収集したデータの送信

機械学習による分類を行うため、収集した加速度データを ZigBee を用いた無線通信によって PC に送信する。前述の通り、今回使用するデバイスに搭載されている加速度センサ ADXL345 では、800 Hz での振動計測が可能である。しかし、加速度センサと ZigBee 無線モジュール間の

I2C 通信と、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、800 Hz に比べて実際の値は著しく下がる。今回使用するマイコンの計測レートは購入時に書き込まれているプログラム [5] では 33 Hz となっており、そのままの実装では高周期での計測値の送信に不向きである。

そこで、連続する 10 単位時間分の加速度計測値をまとめて一つの packets として送信する方式を採用し、新たなプログラムとしてマイコンに実装した。これにより、3 軸加速度計測値を約 333 Hz で計測することが可能となった。

2.3 データの補間処理

前述の通り、我々の手法では、10 単位時間分の加速度計測値をまとめて一つの packets として送信している。この送信処理を間に挟むため、前後の packets 間の計測時間間隔に若干不規則なずれが生じる場合がある。そこで、送信されたデータに補間処理を施すことによって計測時間間隔を揃え、解析可能な信号へと変換する。この補間処理のイメージ図を図に示す。

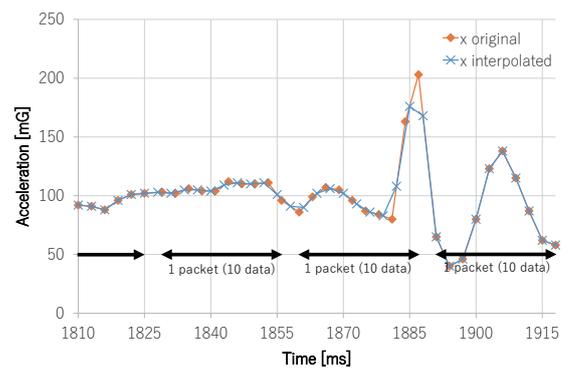


Fig. 2: Interpolation processing. Calculate quadratic equations using measurement data of two points before and after, calculate values at intervals of 1 ms, and linearly interpolate.

2.4 機械学習による分類

ここでは収集したデータを機械学習により分類する手法について説明する。我々の以前の研究では、SVM を用いた機械学習による分類と、CNN を用いた機械学習による分類を行った。今回は、CNN を用いた機械学習による以前より多数のデータの分類について検討するため、CNN を用いた機械学習により収集したデータを分類する。今回、データの分類のために計 13 層の CNN を使用する。構成を Fig. 3 に示す。

この CNN への入力データには、収集した加速度データからランダムに抽出した連続 200 点 (x, y, z の 3 軸、

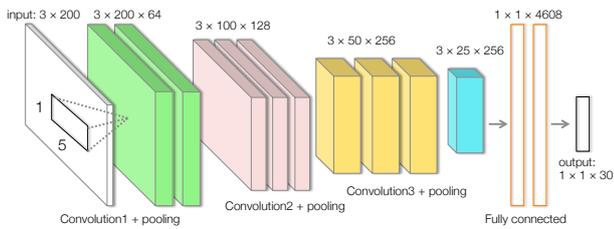


Fig. 3: Composition of CNN.

3×200 のデータ)を用いた。これにより、学習パターンを増加させ、モデルの汎化性能を向上させる。今回は、あらかじめデータの種類ごとにラベル付けを行った。このCNNの出力データは入力したデータがどの触覚情報であるかの確率となるようにした。

CNNの構築にはGoogle社が提供する機械学習ライブラリ、TensorFlow [6]を使用した。今回のCNNを構築する際代表的なCNNの構成の一つであるVGG [7]のモデルを参考に、一つの畳み込み層で畳み込むデータ量を減らし、その分、層自体を増やすことによって精度の向上を図った。活性化関数にはRelu関数を用いた。畳み込みに関しては、1×5のサイズの畳み込みフィルタを用いて畳み込みを行った。フィルタの数はプーリングの度に2倍することで汎化性能の向上を図った。プーリング層では1×2でMaxプーリングを行い、情報を半分に圧縮することで、微小なデータの差異に対して頑健になるようにした。また、各畳み込み層における活性化関数の計算後と全結合層の計算後にIoffe et al. [8]が提案したBatch Normalizationアルゴリズムを使用することで、過学習を抑制した。

本稿では、上記のCNNを用いた機械学習により、触覚情報の高精度な分類を試みた。

3. 分類評価実験

本節では、前節で述べた手法を用いた触覚情報の収集と分類を行う。その上で、収集された情報をどの程度の精度で分類が可能かを検証する実験を行った。今回は分類するデータの種類を以前の18種類から30種類に増やした他、データの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を検証する。

3.1 実験手法

指またはペンに前述の小型ZigBeeマイコンを取り付け、様々な素材の物体の表面をなぞる動作によって実験者自ら触覚情報を収集した。その様子をFig. 4に示す。また、この実験に用いた物体をFig. 5に示す。



Fig. 4: Collection of tactile data. Put the microcomputer in the 3D printed case, attach it to experimenter's finger or pen and operate it to collect the data.

触覚対象はそれぞれ、縦横100 mmほどの板状の物体である。carpet1, carpet2, carpet3が異なる素材のカーペットの一部、sponge-g, sponge-yが家庭用スポンジの裏表、sponge-bが発泡スチロールに似た質感の物体、stonetile1, stonetile2, stonetile3が表面が石のような質感の異なるタイル、whitetile1, whitetile2, whitetile3が異なる質感の白いタイル、woodtile1, woodtile2, woodtile3が異なる質感の木の板である。



Fig. 5: Textures. These are plate-like object with length 70–100 mm and width 100–130 mm.

3.1.1 触覚情報の収集

これらの物体をほぼ一定の速度でなぞることによって触覚情報を収集する。それぞれの物体の表面において、ほぼ同程度の速度で指またはペンを左右に往復させて3分間なぞることで、その際の加速度情報をした。この動作を物体1つにつき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。

実験に用いた物体は図に示した通り、15種類である。15種類の指とボールペンでなぞったデータの合計30種類を収集した。今回はデータ収集時の触覚行動の速度に着目し、物体をなぞる速度を変化させてデータを収集した。前述の30種類のデータについて、100 mm/s, 200 mm/s, 400 mm/sの3種類の速度でなぞることで収集を行った。

Table. 1: Confusion matrix of 400 mm/s data.

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T	U	V	W	X	Y	Z	AA	AB	AC	AD	
A: carpet1-pen	0.94	0	0	0	0.02	0	0.03	0	0	0.01	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
B: carpet1	0	0.92	0	0	0	0.03	0	0	0	0	0	0.01	0	0	0	0.01	0	0	0	0	0	0.01	0	0	0	0	0	0	0	0	0
C: carpet2-pen	0	0	0.92	0	0.05	0	0	0	0.02	0	0	0	0	0	0	0	0	0	0	0.01	0	0	0	0	0	0	0	0	0	0	
D: carpet2	0	0	0	0.97	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.02	0	0	0	0	0	0	0	0	0.01	
E: carpet3-pen	0.02	0	0.02	0	0.95	0	0	0	0	0	0.01	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
F: carpet3	0	0.04	0	0.03	0	0.9	0	0.01	0	0.01	0	0.02	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
G: sponge-b-pen	0	0	0	0	0	0	0.96	0	0.01	0	0.01	0	0.01	0.01	0.01	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
H: sponge-b	0	0	0	0	0	0	0.92	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.05	0	0	0	0	0.02	0	0.01	
I: sponge-g-pen	0	0	0	0	0	0	0	0	0.98	0	0.02	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
J: sponge-g	0	0	0	0	0	0	0	0	0	0.94	0	0.03	0	0	0	0.01	0	0.03	0	0	0	0	0	0	0	0	0	0	0	0	
K: sponge-y-pen	0	0	0.01	0	0	0	0	0	0.03	0	0.95	0	0	0.01	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
L: sponge-y	0	0.04	0	0.03	0	0	0	0	0	0	0	0.91	0	0.01	0.01	0	0	0	0	0	0	0.01	0	0	0	0	0	0	0	0	
M: stonatile1-pen	0	0	0	0	0	0	0	0	0	0	0	0	0.98	0.01	0	0	0.01	0	0	0	0	0	0	0	0	0	0	0	0	0	
N: stonatile1	0	0	0	0	0	0.01	0	0	0	0.01	0	0.01	0	0.95	0	0	0	0	0	0	0	0	0	0	0	0	0.01	0	0	0.01	
O: stonatile2-pen	0	0	0	0	0	0	0	0	0	0	0	0	0.01	0	0.86	0.01	0.02	0	0	0.02	0	0.01	0	0	0	0	0	0	0	0.08	0
P: stonatile2	0	0	0	0.01	0	0.01	0	0	0	0	0	0	0	0	0	0.92	0	0.03	0	0	0	0	0	0	0.01	0	0	0.02	0	0	
Q: stonatile3-pen	0	0	0	0	0	0	0	0	0	0	0	0	0.01	0	0	0	0.9	0	0.01	0.01	0	0	0	0	0	0	0	0	0	0.07	0
R: stonatile3	0	0	0	0	0	0	0	0	0	0.02	0	0.01	0	0	0	0	0.94	0	0	0	0	0	0	0	0.01	0	0.02	0	0	0	
S: whitetile1-pen	0	0	0	0	0	0	0	0	0	0	0.01	0	0	0	0	0	0	0.02	0	0.87	0.01	0	0.02	0	0	0.03	0.04	0	0	0.01	0
T: whitetile1	0	0	0	0	0	0	0.01	0	0	0	0	0	0.01	0	0	0.03	0	0.01	0	0	0.85	0	0.01	0	0	0	0.03	0	0	0.06	0
U: whitetile2-pen	0	0	0	0.01	0	0	0	0	0	0	0	0	0	0	0	0.01	0	0.01	0	0	0	0.97	0	0	0	0	0	0	0	0	
V: whitetile2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.02	0	0	0.95	0	0	0	0.01	0	0	0.01	0	
W: whitetile3-pen	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.99	0	0	0	0	0	0	0	0.01
X: whitetile3	0	0	0	0	0	0	0	0.01	0	0.02	0	0	0	0.04	0	0	0	0	0	0	0	0	0	0.89	0.01	0.02	0.01	0	0	0.01	0
Y: woodtile1-pen	0	0	0	0	0	0	0	0	0	0	0	0	0.01	0	0	0	0	0	0.01	0	0	0	0	0	0	0.97	0	0	0	0.01	0
Z: woodtile1	0	0	0	0	0	0	0	0	0	0	0	0	0.01	0	0	0.01	0.01	0	0	0.01	0	0	0	0	0	0	0.94	0	0	0.01	0
AA: woodtile2-pen	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.04	0	0.01	0	0	0	0	0	0	0	0	0	0.94	0	0	0
AB: woodtile2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.01	0	0	0	0.99	0	0	0
AC: woodtile3-pen	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.08	0.01	0.02	0	0	0.03	0	0.01	0	0	0	0	0	0	0	0.86	0
AD: woodtile3	0	0	0	0	0	0	0	0.01	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.02	0.03	0	0	0	0	0	0.94

3.1.1 収集した触覚情報の分類

収集したデータに対して補間処理を施した上で、前述の CNN を用いた機械学習により分類評価を行う。CNN の入力は 3×200 の加速度データ、出力は 1×30 の、入力データがどの物体をなぞったデータであるかの確率とする。分類の際、この 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、全データを 10 分割し、10 分割交差検証を実施する。

具体的な分類の内容について述べる。30 種類の触覚データを分類できるか検証するため、100 mm/s, 200 mm/s, 400 mm/s で収集した 30 種類それぞれに対し、分類を行った。次に、触覚行動の速さが分類に与える影響を見るため、carpet1, carpet2, carpet3, sponge-g, sponge-y, sponge-b, stonatile1, stonatile2, stonatile3, whitetile1 の 10 種の物体を約 100 mm/s, 約 200 mm/s, 約 400 mm/s でなぞった場合の合計 30 種類 (10 種の物体 \times 3 種類の速度) の分類を行った。

3.2 実験結果

収集したデータを分類した精度についての結果を示す。Table. 1 に得られたデータの例として、400 mm/s の速度で収集した 30 種類のデータを分類することによって得られた混同行列を示す。Table. 2 に 100 mm/s, 200 mm/s, 400 mm/s の速度で収集した 30 種類のデータをそれぞれ分類した精度、前述の 10 種の物体について 3 種類の速度で収集した計 30 種類のデータを分類した精度を示す。

結果について考察する。100 mm/s, 200 mm/s, 400

Table. 2: Result of experiment. “3speeds” is the result of classifying ten kinds of objects at three kinds of speeds.

Speed(mm/s)	100	200	400	(3speeds)
Accuracy(%)	89	88	93	90

mm/s の速度で収集した 30 種類のデータをそれぞれ分類した結果、精度は 100 mm/s と 200 mm/s が平均約 88–89%, 400mm/s が平均約 93%という結果となった。さらに、10 種類の物体について 3 種類の速度で収集した 30 種類のデータを分類した結果、精度は平均約 90%ほどという結果となった。この結果から以前よりも多数のデータを分類することに成功したことが分かった。

精度に関して、以前の 18 種類の分類の場合は平均約 93%であったが、今回の 30 種類の分類では 100 mm/s と 200 mm/s の場合が以前の精度を下回っている。このことから、分類する情報の種類を増加させると精度は低下すると思われる。しかし、今回用いた物体には、3 種類の素材の違う絨毯など、物体同士において、触った際の質感が似ている物体が含まれていたため、質感の全く違う物体を多数用意し、実験を行った場合、精度が低下しない可能性がある。

今回の実験において、400 mm/s の場合の精度は以前の 18 種類の分類と同程度であり、分類する触覚情報が増加したのにも関わらず精度が減少しないという結果になった。この要因として、400 mm/s の場合、他の 2 つの速度の場合より、情報収集の際の加速度の変化が大きいと思われる。

ることから、CNNの入力として用いた連続200点中の加速度の変化が他の場合より激しく、その分様々なパターンを学習できたからと考えられる。また、今回のCNNの設定が、100 mm/s、200 mm/sのデータより400 mm/sのデータの分類に適していたとも考えられる。CNNを用いる際、データの量や中身によって設定を変化させる必要がある。今回の設定では他の2種類のデータより400 mm/sのデータに上手く適合した可能性がある。これらの考察を踏まえ、今後はCNNの設定の調整と、CNNに入力するデータの量を調整することで、さらに厳密な調査を行う。

他に、10種類の物体について3種類の速度で収集した30種類のデータを分類した結果から、我々の手法においては、少なくとも今回の実験の動作に関して、触覚行動の速さの違いは分類に影響をあまり与えていないことが分かった。これの要因としては、学習のために抽出した連続200点のデータの中に左右に往復する際の方向転換時の加速度が含まれている場合があるからだと考えられる。なぞる速さによって方向転換する頻度は変化するため、その差異から分類できてしまっている可能性がある。また、単にデータの細かい変化を見逃さず学習を行うことができるCNNの性質が影響しているとも考えることもできる。これらのことから、今後、さらに厳密な結果を得るため現在のデータの収集方法を変更する必要があることがわかった。

4. おわりに

我々は日常の触覚情報を収集する手法を提案しているが、収集した情報を分類する手法には検討の余地があった。そこで本稿では、CNNを用いた機械学習によって、以前よりも多い種類のデータについて高い精度での分類を試みた。また、触覚データ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。

加速度センサ付き小型無線マイコンを指やボールペンに装着し、100 mm/s、200 mm/s、400 mm/sの3種類の速度で様々な物体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。速度を一定にしてなぞった3種類の速度の分類においては、それぞれ平均約89%、88%、93%の精度を得ることができた。さらに触覚行動の速度が分類に与える影響を調査するため、3種類の速度のデータからそれぞれ10種類ずつ、計30種類のデータを分類した。結果、平均約90%の精度が得られた。

以前、我々は18種類の触覚情報を分類したが、今回の結果から、さらに多い30種類の分類を実現できたことがわかった。さらに、我々の手法において触覚行動の速度は分類の精度に影響を与えない可能性があることが分かった。しかし、速度が分類に影響しないことに関しては、データ

収集の方法や、CNNの性質などが要因が考えられ、なぜ影響しないのか今後詳しい調査を行う必要がある。

本稿では、物体を数種類の速度でなぞることで触覚情報を収集、分類する実験を行った。今後は実験におけるデータ収集手法やCNNの構成を見直した上で、触覚行動の速さが分類に影響しないのか厳密な調査を行う。触覚行動の速さだけでなく、物体の質感にも着目し、似た質感の物体の触覚情報を分類できるかどうか検証する。加えて、物体をなぞる行動以外の触覚行動のデータを収集し、分類可能か調査する。また、我々の手法を応用したアプリケーション、またはデバイスの開発についても検討していく予定である。

参考文献

- [1] Matti Strese, Yannik Boeck, and Eckehard Steinbach. Content-based Surface Material Retrieval. In *2017 IEEE World Haptics Conference (WHC), Fürstfeldbruck (Munich), Germany*, pp. 352–357, 2017.
- [2] 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.
- [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] 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.
- [5] Mono Wireless Inc. TWE-Lite-2525A. (<https://mono-wireless.com/jp/products/TWE-Lite-2525A>).
- [6] Google Inc. Tensorflow. (<https://www.tensorflow.org/>).
- [7] Karen Simonyan and Andrew Zisserman. Very Deep Convolutional Networks for Large-Scale Image Recognition. *arXiv:1409.1556*, 2014.
- [8] 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.