



GAN による振動触覚ディスプレイのための信号生成

我妻正太郎¹⁾, 高橋伸²⁾, 嵯峨智³⁾

- 1) 筑波大学大学院 システム情報工学研究科 (〒 305-8577 茨城県つくば市天王台 1 丁目 1-1)
- 2) 筑波大学 システム情報系 (〒 305-8573 茨城県つくば市天王台 1 丁目 1-1)
- 3) 熊本大学 熊本大学 大学院先端科学研究部 (〒 860-8555 熊本県熊本市中央区黒髪 2-39-1)

概要: 触察時の情報を収集する手法はいくつも提案されているが, 触察の条件によっては収集が難しい場合がある. 収集が難しい場合の情報でも, Generative Adversarial Network (GAN) を用いることで既存のデータから生成できる可能性がある. そこで本稿では, 無線型加速度センサを用いた手法により収集した加速度データを用いて, DCGAN による振動情報生成モデルを作成した. このモデルを用いて振動情報の生成を行った. 生成されたデータを実際に無線型加速度センサを用いて収集したデータと比較し, 考察を行った.

キーワード: 振動触覚, 触覚振動データ, DCGAN

1. はじめに

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, 人が何かに触れた場合における振動情報を収集, 記録する必要がある. これに伴い, 触覚情報を収集するシステムの研究が多く行われている.

例えば, Burka et al. [1] は自律型ロボットへの応用を目的とし, 物体表面の視覚情報と触覚情報を収集するデバイスを提案した. 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, 異質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. これらの他にも, 様々な触覚情報収集手法が提案されている. しかし, 先行研究では, なぞり方などの収集の条件を限定しているものがほとんどである. 例えば, Strese et al [3] はテクスチャをペン型機器で左から右になぞることで収集を行ったが, なぞり方の条件を変化させた場合, 収集できるデータに違いがある可能性は高い. ペン型機器でテクスチャをなぞる, という動作の中には機器をテクスチャに押し付ける力やなぞる速度, 機器のなぞる角度, なぞるテクスチャの種類など, 様々な要素が存在している. これらを考慮し, 収集を行うことは可能であるが, 全ての条件を考慮して網羅的に収集を行うのは非現実的である.

しかし, 考慮しきれない条件のデータを収集済みのデータから生成することができれば, この問題に対応できる可能性がある. 収集済みのデータから, それらに類似したデータを適切に生成できれば, 様々な条件のデータを実際に収集実験を行うことなく取得することができる. 例えば, 一定の速さで収集したデータを用いて, また別の速度で収集

したデータと類似したデータを生成できれば, その分収集するコストを削減することができる.

これらの背景から, 本稿では, 触覚情報生成の第一歩として, Generative Adversarial Network (GAN) による信号生成の手法を提案する. GAN に関する手法の中では, 主に畳み込みニューラルネットワーク (CNN) と組み合わせた Deep Convolutional GAN (DCGAN) が高精度な画像生成を実現している. この DCGAN の入力と出力を調整することで, 画像だけでなく, 加速度などの時系列データを高精度に生成できる可能性がある. 本稿では, 3 軸加速度データを訓練データとして学習し, 学習したデータと類似したデータを生成できる DCGAN を構築し, 実際に生成を行った. 訓練データには, 我々が以前から提案している無線型加速度センサを用いた手法 [4] により収集した 3 軸加速度データを用いた. また, 実際に生成されたデータと訓練データを比較し, 考察を行った.

2. 訓練データの収集手法

ここでは, 訓練データの収集手法について概略する. 以前から我々が提案している, 無線型加速度センサを用いた手法 [4] によりデータの収集を行った. 無線型加速度センサには, TWE-Lite-2525A (Mono Wireless Inc. [5]) という既製品のデバイスを用いている. 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 ADXL343 と ZigBee 無線通信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. このデバイスは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, デバイス内のプログラムを容易に書き換えることができる. 我々は, デバイス内のプログラムを改良することで 330 Hz での 3 軸加速度情報収集を可能にした.

このデバイスを 3D プリントした専用のケースに入れる

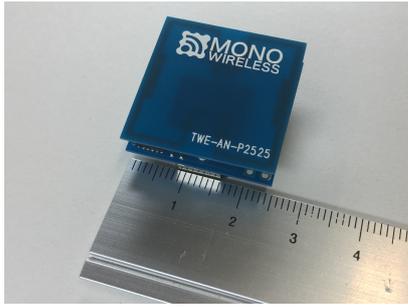


図 1: TWE-Lite-2525A(Mono Wireless Inc. [5]). 3 軸加速度センサと ZigBee 無線モジュールが内蔵されている。電源にはボタン電池 (CR2032) を用いている。

ことで、指などの様々な物体への装着を可能にする。本稿では、デバイスを装着した指でテキストチャをなぞることで、その際の 3 軸加速度情報を収集した。

3. GAN の構成

ここでは、振動データ生成に用いる GAN について説明する。GAN では、実際にデータ生成を行う生成器である Generator と、生成データと本物のデータを分類する Discriminator の 2 種類の機械学習モデルを用いる。Discriminator の分類結果から、本物のデータに生成データが近づくように Generator を学習することで、学習が進むごとに Generator がより高精度なデータを生成できるようになる。本稿では、振動データ生成には GAN の一種である DCGAN を用いる。DCGAN は Discriminator と Generator どちらにも CNN を用いて、精度の向上を図った手法である。本稿では、Generator 側、Discriminator 側どちらも畳み込み 6 層としたネットワークを構築した。構築した DCGAN の概略図を図 2 に示す。本稿では、得られた 3 軸加速度データのなかから、ランダムに抽出した連続 1000 点のデータを学習に利用した。

DCGAN の具体的な構成について説明する。本稿で用いた DCGAN の構成に関しては、DCGAN の提案者である Goodfellow et al. [6] の構成を参考にしている。まず、Generator 側について説明する。Generator 側の CNN において、入力は平均 0、標準偏差 1 の標準正規分布に基づき生成された 100×100 の乱数行列とした。出力は 3×1000 の生成された 3 軸振動データである。Generator 側においては、通常の畳み込みとは異なる転置畳み込み演算を行い、入力データのアップサンプリングを行う。転置畳み込みにおいては、入力データに空白を足してサイズを拡大した後、畳み込み演算を行うことで、アップサンプリングを行う。Generator 側において、畳み込みフィルタのサイズは、畳み込み 1 層目から 5 層目までは 1×10 、6 層目は 1×9 とした。フィルタの数は畳み込み 1 層目から 5 層目までは 64 枚、6 層目は 1 枚とした。6 層目のみ設定が他と異なるのは、出力の次元を訓練データと同じ 3×1000 に調整するためである。これにより、Discriminator 側で、訓練データと生成

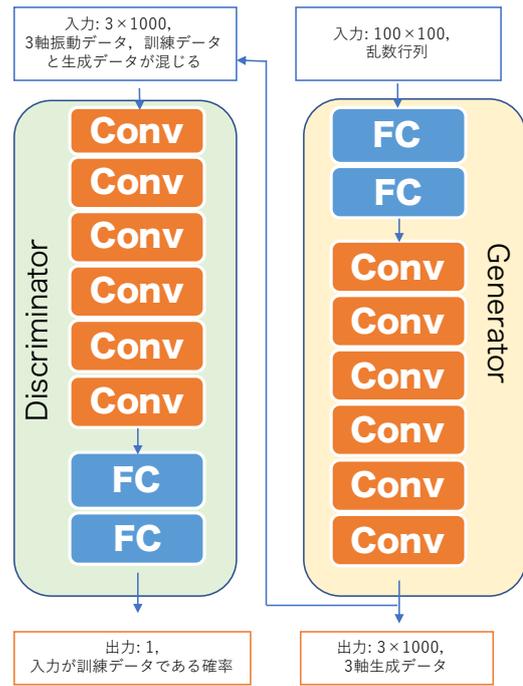


図 2: DCGAN の概略図。FC が全結合層、Conv が畳み込み層を表している。

データの比較と分類が可能になる。活性化関数は全畳み込み層で ReLU 関数、出力層では tanh 関数を用いた。損失関数にはバイナリ交差エントロピー誤差を用いた。重みの最適化には Adam [7] を用いた。また、勾配消失による学習の停止を防ぐため、各層の活性化関数の計算後に Batch Normalization を適用した [8]。

次に Discriminator 側について説明する。Discriminator 側の CNN において、入力は 3×1000 の振動データとした。出力は、入力データが生成データではなく訓練データである確率とした。Discriminator 側では、畳み込み 6 層、全結合 2 層のネットワークを用いた。Discriminator 側において、畳み込みフィルタのサイズは全ての層で 1×10 とした。畳み込みフィルタの枚数は全ての層で 64 枚とした。活性化関数は出力層のみシグモイド関数を用い、他の層では Leaky ReLU 関数を用いた。損失関数にはバイナリ交差エントロピー誤差を用いた。重みの最適化には Adam [7] を用いた。また、全結合層と出力層の間に Dropout [9] を使用し、ネットワークのノードを半分にすることで過学習の抑制を図った。

4. データ生成実験

ここでは、本稿で構築した DCGAN による 3 軸振動データの生成実験を行う。無線型加速度センサを装着した指でテキストチャをなぞることで 3 軸加速度情報を収集した。収集したデータを訓練データとし、DCGAN によるデータ生成を行った。

まず、データの収集について説明する。データ収集は 1 人の被験者 (22 歳, 男性) にて行われた。被験者の指に前述

の無線型加速度センサを取り付け、約 10 cm 四方の絨毯の一部 (テクスチャ) をなぞることで、その際の 3 軸加速度情報を収集した。テクスチャをなぞる速度は約 400 mm/s で一定とした。テクスチャの右端から左端を往復してなぞることで収集を行った。5 秒間一定の速度でテクスチャをなぞることを 1 試行として、108 試行を行い、合計で 9 分間分の加速度情報を収集した。この収集の様子を図 3 に示す。



図 3: データ収集の様子

収集したデータを訓練データとして、DCGAN による 3 軸振動データの生成を行った。生成されたデータを軸ごとにグラフ化した図を図 4 に示す。なお、Generator 側の出力層において tanh 関数を活性化関数にすることで、-1 から 1 の範囲での出力データの正規化を行っている。これは Goodfellow et al. [6] の論文を参考に、より訓練データに近い波形のデータを生成するためである。また、ある 1 つ訓練データの軸ごとの波形を図 5 に示す。なお、図 5 では、出力データと比較するため、出力データと同じ範囲で正規化を行っている。

これらの図から、まず、3 軸振動データを生成すること自体には成功したことがわかった。X 軸について比較すると、波形自体には類似点があり、生成データの値は訓練データと同じく、全体の最大値付近に点がある場合が多い。Y 軸について比較すると、生成されたデータと訓練データの値自体の分布には類似している点はあまり見受けられないものの、収集の際の左右に折り返したときのものと思われる値の上下が生成データにも表れている。X、Y 軸では訓練データと生成データの類似点があったものの、Z 軸においては、完全に異なると思われるデータが生成されてしまった。Z 軸の生成データの波形は訓練データの Z 軸よりも、生成データの Y 軸に非常によく似ており、学習の際、Y 軸と Z 軸が混同して学習されてしまったものと思われる。

5. おわりに

本稿では、収集しきれない条件における触覚情報を収集済みの触覚情報から生成する手法の第一歩として、DCGAN を用いた 3 軸振動情報の生成を行った。DCGAN の学習に用いた訓練データは、以前より我々が提案している無線型加

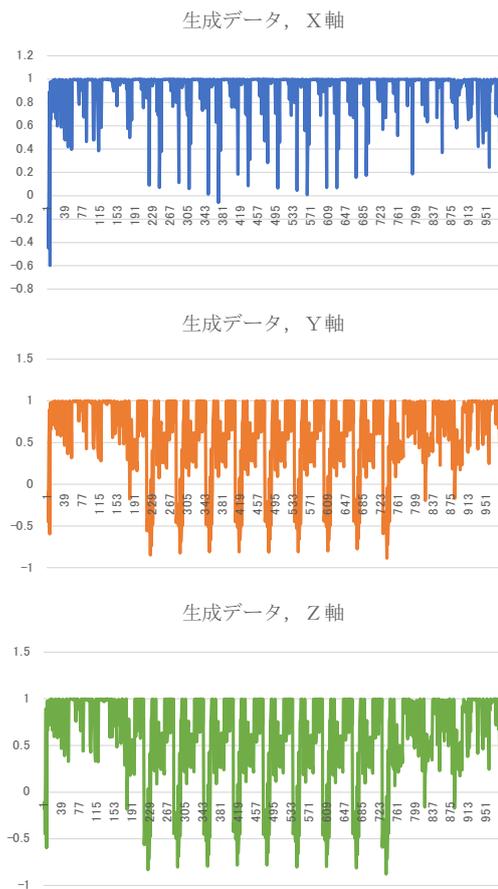


図 4: 生成データの波形

速度センサを用いた手法 [4] を用いた。DCGAN については、主に Goodfellow et al. [6] の論文を参考に機械学習モデルを構築した。収集したデータを訓練データとして 3 軸振動情報の生成を行い、軸ごとに生成データと訓練データの比較を行った。結果、X、Y 軸のデータには類似点が見られたものの、Z 軸のデータに関しては全く異なるデータが生成された。

今後は、Z 軸のデータが全く異なっていることに対応するため、DCGAN の構成の見直しを行う。また、生成されたデータを出力するディスプレイの開発についても検討していく予定である [10]。

参考文献

- [1] Alex Burka, Siyao Hu, Stuart Helgeson, Shweta Krishnan, Yang Gao, Lisa Anne Hendricks, Trevor Darrell, and Katherine J. Kuchenbecker. Design and implementation of a visuo-haptic data acquisition system for robotic learning of surface properties. In *Proc. IEEE Haptics Symposium*, pp. 350–352, April 2016.
- [2] Arsen Abdulali and Seokhee Jeon. Data-Driven Modeling of Anisotropic Haptic Textures: Data Segmentation and Interpolation. In *Haptics: Percep-*

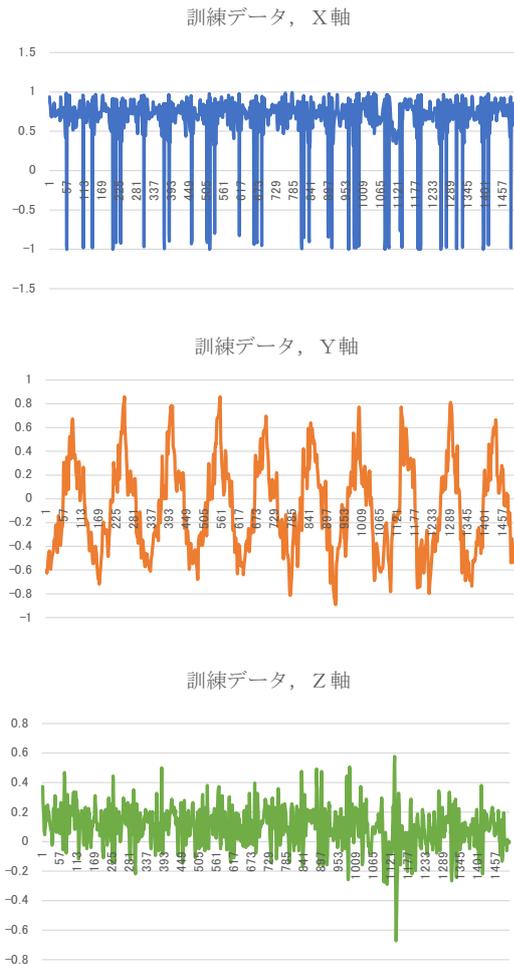


図 5: 訓練データの波形

tion, Devices, Control, and Applications: 10th International Conference, EuroHaptics 2016, London, UK, pp. 228–239. Springer International Publishing, 2016.

- [3] Matti Strese, Yannik Boeck, and Ekehard Steinbach. Content-based Surface Material Retrieval. In *2017 IEEE World Haptics Conference (WHC), Fürstenfeldbruck (Munich), Germany*, pp. 352–357. IEEE, 2017.
- [4] 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.
- [5] Mono Wireless Inc. TWE-Lite-2525A. (<https://mono-wireless.com/jp/products/TWE-Lite-2525A>).
- [6] Ian Goodfellow, Jean Pouget-Abadie, Mehdi Mirza, Bing Xu, David Warde-Farley, Sherjil Ozair, Aaron Courville, and Yoshua Bengio. Generative adversarial nets. In *Advances in neural information processing systems*, pp. 2672–2680, 2014.

- [7] Diederik Kingma and Jimmy Ba. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*, 2014.
- [8] Sergey Ioffe and Christian Szegedy. Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift. *abs/1502.03167*, 2015.
- [9] 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.
- [10] Alec Radford, Luke Metz, and Soumith Chintala. Unsupervised representation learning with deep convolutional generative adversarial networks. *CoRR*, Vol. abs/1511.06434, , 2015.