

Generative Adversarial Networks を用いた半教師あり学習の音響イベント検出への適用

Application of Semi-supervised Learning Using Generative Adversarial Networks to Sound Event Detection

合馬一弥 山田武志 牧野昭二

Kazuya Ouma Takeshi Yamada Shoji Makino

筑波大学情報学群情報科学類

College of Information Science, University of Tsukuba

1. はじめに

音声アシスタントや自動運転車において、音響イベント検出(SED: Sound Event Detection)は重要な役割を担っている。SED とは、与えられた音響データ内で発生している音響イベントの種類、開始時刻、終了時刻を特定することである。

環境音認識の国際コンペティションである DCASE [1] でも見られるように、最近では SED を行う手法として CNN (Convolutional Neural Networks) や CRNN (Convolutional Recurrent Neural Networks) がよく用いられている。このような NN を用いた SED の学習には大量の強ラベル(音響イベントの種類、開始時刻、終了時刻からなるラベル)付きデータが必要である。しかし、強ラベルの作成には音響データの聴取や波形の確認を行う必要があるため、高い検出精度を得るために必要な数百～数千のデータを用意するのは困難である。従来の解決策として、少量の強ラベルを用いた学習の後、大量の弱ラベル(音響イベントの種類のみからなるラベル)を用いて検出精度を向上させる手法[2]が挙げられる。弱ラベルの活用によって、人的・時間的コストを抑えることができる。

弱ラベルの活用のほかに、ラベルなしデータを活用した手法が期待されている。画像認識分野においては、ラベルなし画像を活用するために GAN (Generative Adversarial Networks)[3]を応用した半教師あり学習手法[4]が提案されている。従来の GAN は、よりリアルなデータを出力する Generator と入力データがリアルなものであるかを判別する Discriminator からなるネットワークであり、学習後の Generator が画像生成等に用いられる。一方、[4]ではこの Discriminator にクラス学習も適用し、学習後の Discriminator をクラス分類に用いることで半教師あり学習を実現している。本稿ではこれを SED に適用し、その有効性を評価する。

2. GAN を用いた半教師あり学習

GAN を用いた半教師あり学習手法の概要を図 1 に示す。Generator は従来の GAN と同様の動作をする。すなわち、ノイズからデータを生成し、Discriminator にどの程度リアルなものだと判定されたかで学習を行う。Discriminator は、入力データがリアルなものかを判別するよう学習するほか、入力データが強ラベル付きのリアルデータであった場合は SED についても学習を行う。

3. 実験

上記の手法の有効性を評価するため DCASE 2016 Task 3 [5] を用いて実験を行った。このタスクは、家と住宅街の二つの場所において収録された音響データと強ラベルをもとに SED を行うタスクである。このタスクにおいて、学習データのうち一部の強ラベルを隠し、(i)残った強ラベル付きデータのみで学習する手法、(ii)半教師あり GAN




図 1 半教師あり GAN

表 1 実験結果(評価は Error Rate)

強ラベル付きの割合	1	0.9	0.8	0.7
(i)強ラベルのみ	0.65	0.71	0.86	0.90
(ii)強+ラベルなし	0.49	0.61	0.75	0.77

を用いてラベルなしデータも用いて学習する手法を比較する。本実験では音響特微量としてメルスペクトログラムを用いた。また、(i)の検出器と(ii)の Discriminator には CRNN を、(ii)の Generator には UpSampling + CNN を用了いた。

実験結果は表 1 の通りである。強ラベル付きデータのみを用いた手法(i)に比べてラベルなしデータも用いた手法(ii)は Error Rate が向上していることが分かる。また、画像認識分野において訓練データがすべて正解ラベル付きである場合でも、半教師あり GAN を適用することで精度の向上が得られている[6]が、SED においても同様の向上が見られる。

4. おわりに

GAN を用いた半教師あり学習によって、SED においてもラベルなしデータを用いて検出精度の向上に寄与できることが示された。

謝辞 本研究は JSPS 科研費 19H04131 の助成を受けた。

参考文献

- [1] <http://dcase.community/>.
- [2] T. Matsuyoshi, T. Komatsu, R. Kondo, T. Yamada, S. Makino, "Weakly Labeled Learning Using BLSTM-CTC for Sound Event Detection," Proc. APSIPA 2018, pp. 1918-1923, Nov. 2018.
- [3] I. J. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, Y. Bengio, "Generative Adversarial Networks," arXiv:1406.2661, 2014.
- [4] T. Salimans, I. J. Goodfellow, W. Zaremba, V. Cheung, A. Radford, X. Chen, "Improved Techniques for Training GANs," arXiv:1606.03498, 2016.
- [5] <http://dcase.community/challenge2016/task-sound-event-detection-in-real-life-audio>.
- [6] A. Odena, "Semi-Supervised Learning with Generative Adversarial Networks," arXiv:1606.01583, 2016.