

FC-HiFi-GAN: 全結合層型アップサンプリングを導入した高速HiFi-GAN*

☆山下陽生^{1,2}, 岡本拓磨², 高島遼一¹, 滝口哲也¹, 戸田智基³, 河井恒²
 (1 神戸大学, 2 情報通信研究機構, 3 名古屋大学)

1 はじめに

音響特徴量から音声波形を生成する信号処理に基づくソースフィルタ型ボコーダ (e.g. WORLD [1]) と比較して, 近年ではニューラルネットワークを用いた方式 (ニューラルボコーダ) の合成品質の向上が目覚ましい [2]。当初提案された自己回帰モデル (e.g. WaveNet ボコーダ [3], WaveRNN [4]) は合成速度が遅いという問題に対して, 合成品質を保ちつつ1CPUでも音声合成可能な推論速度を持つパラレル生成モデルとしてHiFi-GAN [5] が提案され, 音素系列から直接音声波形を1つのニューラルネットワークで高品質に生成可能なEnd-to-endテキスト音声合成モデルにも採用されている [6, 7]。

HiFi-GANは音声波形を生成するGeneratorおよび優れた2つのDiscriminatorにより構成される。HiFi-GANのGeneratorでは転置畳み込み+ResBlockによるアップサンプリングを計4回行うことでメルスペクトログラムから音声波形を生成するが, さらなる高速化として提案されたMulti-Stream HiFi-GAN [8] やiSTFTNet [9] では最後の2層の転置畳み込み+ResBlockによるアップサンプリングをゼロ挿入型アップサンプリング+畳み込みやiSTFTのような高速処理に置き換えることで, 合成品質を保ちつつ高速化に成功している。これらはHiFi-GANのGeneratorにおいては, 転置畳み込み+ResBlockによるアップサンプリングを4回も行わずとも推論のための十分な学習ができることを示し, 別の処理に置き換える場合においても高速化が可能であることを示している。

これらの結果を踏まえ, 本稿ではMulti-Stream HiFi-GANおよびiSTFTNetにおいて提案されたアイデアを合わせ, 新たにHiFi-GANにおける最後2層の転置畳み込み+ResBlockによるアップサンプリングの代わりに単純な全結合層を導入したFC-HiFi-GANを提案する。FC-HiFi-GANとMulti-Stream HiFi-GAN, iSTFTNetに

ついて, 合成品質, 合成速度について比較実験を行う。

2 HiFi-GANと応用モデル

2.1 HiFi-GAN

HiFi-GANのGeneratorはメルスペクトログラムを入力として受け取り, 転置畳み込み+ResBlockによるアップサンプリングを複数回行うことで音声波形を生成する。HiFi-GANでは優れた2種類のDiscriminatorを導入することによりGeneratorサイズを大きくせず, 音声波形の生成時にはGeneratorのみを使用するため, 高品質かつ高速な音声合成を実現している。HiFi-GANは, Fig. 1(a)に示すように, 転置畳み込み+ResBlockによるアップサンプリングは(8, 8, 2, 2)とし, カーネルサイズは(16, 16, 4, 4)である。以下の改良モデルでは, 隠れチャンネルは512とするHiFi-GAN V1を基本にしたうえで, 最後の2層の転置畳み込み+ResBlockを別の高速処理に置き換えることにより高速化を実現している。

2.2 Multi-Stream HiFi-GAN

HiFi-GANと同様のアップサンプリング型ニューラル波形生成モデルとしてMel-GANが提案されているが, 音質を保ちつつ合成速度をさらに高速化する方式としてMulti-Band MelGAN [10] が提案された。Multi-Band MelGANでは, 最後の4倍アップサンプリングの代わりに4帯域にサブバンド化した波形を出力し, 信号処理に基づくサブバンド合成フィルタを用いてフルバンド波形を得る。しかし, この方式をHiFi-GANにそのまま適用した場合, サブバンドの制約が強すぎるため生成波形に対するDiscriminator損失が下がらず, 学習が進まないという問題がある。

それに対して, Fig. 1(b)に示すMulti-Stream HiFi-GAN [8] は, 信号処理に基づくサブバンド合成フィルタがゼロ挿入型アップサンプリング+固定フィルタによる畳み込み演算であることに着目し, 固定値のサブバンド合成フィルタを学習可

*FC-HiFi-GAN: High-speed HiFi-GAN with fully connected layer-based upsampling. by YAMASHITA, Haruki^{1,2}, OKAMOTO, Takuma¹, TAKASHIMA, Ryoichi¹, TAKIGUCHI, Tetsuya¹, TODA, Tomoki¹, KAWAI, Hisash¹ (1Kobe Univ, 2NICT, 3Nagoya Univ)




Fig. 1 model outline

能な畳み込みに置き換えたモデルである。これにより、高速化を実現しつつ、HiFi-GANと同等の合成品質を実現できる。Multi-Band MelGANのサブバンド合成フィルタ長を合わせるため、カーネルサイズは63としている。

2.3 iSTFTNet

iSTFTNet [9] は Fig. 1(c) に示すように、HiFi-GANにおける最後の4倍アップサンプリングを逆短時間フーリエ変換 (iSTFT) に置き換えたものであり、Multi-Stream HiFi-GANと同様、合成品質を保ちつつ、合成速度を改善させることに成功している。ここで、Fig. 1(c) の iSTFT は fft サイズは16、window サイズは16、hop サイズは4である。入力されたメルスペクトrogramは出力する音声波形の周波数特性を含んでいることに着目し、64倍アップサンプリング後の Conv1d 層にて音声波形の短時間フーリエ変換 (STFT) の振幅成分と位相成分を出力するよう設計することで、iSTFT を通すことにより音声波形を出力する。文献 [9] では様々な条件が検討されたが、Fig. 1(c) に示す構造が HiFi-GAN と同等の最も高音質を実現している。

2.4 提案法：FC-HiFi-GAN

提案手法である FC-HiFi-GAN は、Fig. 1(d) のように、HiFi-GANにおける最後の4倍のアップサンプリングを全結合層に置き換えたものである。提案モデルは Multi-Stream HiFi-GAN および iSTFTNet を基に考えられている。iSTFT-

Net では HiFi-GAN における最終2層の転置畳み込み+ResBlock を iSTFT に置き換えていたが、iSTFT は重みをフーリエ基底とした全結合層+オーバーラップ加算したものである。全結合層は学習可能な線形変換であるため、iSTFT の代わりに学習可能な全結合層を導入したモデルとして FC-HiFi-GAN を考案する。また、Multi-Stream HiFi-GAN において重みが固定のサブバンド合成フィルタの代わりに学習可能な畳み込みを用いることで高精度化に成功したように、iSTFT を学習可能にすることで精度の向上が期待できる。iSTFTNet と同様に、Conv1d の出力は振幅成分と位相成分に相当する18次元とし、学習可能な全結合層により4次元の信号を出力し、最後に並び替えにより1次元とすることにより4倍のアップサンプリングを実現している。

なお、iSTFT の演算と同じように全結合層の出力をオーバーラップ加算させる手段も考えられるが、単純な全結合層だけであっても十分な合成品質と推論速度を保っていることが確認されたため、本稿ではこのモデルを用いて実験を行った。

3 実験

3.1 実験条件

Multi-Stream HiFi-GAN, iSTFTNet, および提案法である FC-HiFi-GAN の合成品質、推論速度の比較を行う。データセットには130文を読み

Table 1 RTF, WARP-Q, MCD

	HiFi-GAN	MS-HiFi-GAN	iSTFTNet	FC-HiFi-GAN
RTF	0.74	0.45	0.35	0.35
WARP-Q	0.88	0.87	0.90	0.84
MCD	4.93	4.94	5.03	4.93

上げた100人の話者の音声が入っているJVSコーパス [11](サンプリング周波数 24kHz) を用いた。そのうち jvs011 から jvs100 までの 90 名の平行 100 文およびノン平行 30 文の合計 11,697 文を学習に用いた。推論速度の測定と客観評価実験においては学習に使用していない jvs001 から jvs010 の 10 名のノン平行 30 文の合計 300 文を用いた。これにより、学習に含まれていない話者および発話の未知話者合成の評価となる。音響特徴量は 8 kHz までに帯域制限した 80 次元のメルスペクトログラムとした。それぞれのモデル学習におけるパラメータ更新 250 万回行った。モデルの実装及び学習、推論には PyTorch ベースのオープンソース¹を用いた。

モデルの客観評価は、HiFi-GAN, Multi-Stream HiFi-GAN, iSTFTNet, FC-HiFi-GAN の 4 つのモデルについて、WARP-Q [12] とメルケプストラム歪み (MCD) を用いた品質評価と推論速度の測定を行った。WARP-Q はニューラル波形生成モデルの評価手法の 1 つであり、音質評価における平均オピニオン評点 (MOS) [13] との関係が確認されており、WARP-Q 値が小さければ小さいほど MOS 値が良くなる傾向にある [12]。推論速度の測定には Intel Xeon Gold 6152 CPU 2.1GHz を 1 コア用いて生成を行い、その時の実時間係数 (RTF:Real Time Factor) を計測した。モデルの主観評価には、11 名の正常な聴力を有する日本人成人を実験参加者とする聴取実験による MOS 評価を行った。学習に用いていない話者のうち、jvs001, jvs003, jvs004, jvs008(男女 2 名ずつ) からそれぞれ 10 文ずつ抜き出した合計 40 文について、Multi-Stream SHiFi-GAN, iSTFTNet, FC-HiFi-GAN から推論された音声と、原音声を合わせた 160 文を用いた。実験参加者は静かな環境でヘッドホンにより音声を聴取した。

¹<https://github.com/kan-bayashi/ParallelWaveGAN>

3.2 実験結果

3.2.1 客観評価実験

RTF, WARP-Q, MCD の値を Table 1 に示す。RTF の結果から、HiFi-GAN が最も合成速度が遅く、Multi-Stream HiFi-GAN, iSTFTNet, FC-HiFi-GAN のそのモデルも高速化されていることが確認できた。高速化されたモデルの中では、Multi-Stream HiFi-GAN が最も合成速度が遅く、FC-HiFi-GAN と iSTFTNet が同等の合成速度であることが分かった。FC-HiFi-GAN と iSTFTNet はどちらも処理が線形変換となっているため同じ速度であり、すべてのモデルの中で最も速くなっていると考えられる。Multi-Stream HiFi-GAN では合成フィルターのカーネルサイズを 63 と大きくしているため Multi-Stream HiFi-GAN が iSTFTNet, FC-HiFi-GAN よりも遅くなっていると考えられる。

次に、合成品質についての結果を確認する。WARP-Q の結果を見ると、iSTFTNet の値が最も高くなり、高速化されたモデルの中で唯一 HiFi-GAN よりも悪い結果を示している。FC-HiFi-GAN は 4 つの中で最も良い結果を示した。MCD の結果を見ると、WARP-Q と同様に iSTFTNet が最も悪い結果となり、HiFi-GAN, Multi-Stream HiFi-GAN, FC-HiFi-GAN の 3 つのモデルは差がないという結果となった。

FC-HiFi-GAN と iSTFTNet の比較から、iSTFT を学習可能な全結合層に変更するだけで、合成速度を維持したままより合成品質を上げることが可能であると考えられる。これは、iSTFT が単純な線形変換の重ね合わせであるのに対して、全結合層は学習可能な線形変換であり、複数話者に適応するように学習した結果、iSTFT よりも柔軟に未知話者予測が可能となったためであると考えられる。

3.2.2 主観評価実験

Fig. 2 に MOS 評価の結果を示す。結果より、WARP-Q での結果と違い、Multi-Stream HiFi-GAN が最も合成品質が良く、FC-HiFi-GAN が




Fig. 2 Mean Opinion Score(MOS), Confidence level of the error base was 95%.

と iSTFTNet の合成品質では FC-HiFi-GAN は同じ値で、有意な差はないという結果となった。

客観評価実験の結果と合わせて、Multi-Stream HiFi-GAN が最も合成品質が良いものの合成速度は遅く、FC-HiFi-GAN と iSTFTNet は合成速度、合成品質ともに差がないが、Multi-Stream HiFi-GAN よりも合成速度が速いという結果になった。

合成品質は Multi-Stream HiFi-GAN が最も良かったが、本来の HiFi-GAN の高速化という面を考えると、FC-HiFi-GAN が合成速度と合成品質のバランスにおいて最も良いことが分かった。

FC-HiFi-GAN と iSTFTNet においては合成速度、合成品質ともに同じであったが、単純な信号処理である iSTFT よりも全結合層の方が改良の余地があるため、FC-HiFi-GAN の方が今後の発展に期待できる。

また、本稿で用いた Multi-Stream HiFi-GAN はカーネルサイズが 63 となっており、このサイズが大きいため合成速度が遅くなっている。そのため、カーネルサイズを減らし、iSTFTNet、FC-HiFi-GAN と同程度の合成速度に合わせたのちに合成品質を比較する必要もあると考え、これは今後の検証課題である。

4 おわりに

iSTFTNet の iSTFT によるアップサンプリングを学習可能な全結合層に置き換えた FC-HiFi-GAN を提案した。HiFi-GAN、Multi-Stream HiFi-GAN および iSTFTNet との比較実験を行い、提案法の有効性を確認した。

参考文献

[1] M. Morise *et al.*, “WORLD: A vocoder-based high-quality speech synthesis system for real-time applications,” *IEICE trans.*

Inf. Syst., vol. E99-D, no. 7, pp. 1877–1884, July 2016.

[2] 岡本, “ニューラルネットワークに基づく音声波形生成モデル”, 音響誌, vol. 78, no. 6, pp. 328–337, June 2022.

[3] A. Tamamori *et al.*, “Speaker-dependent WaveNet vocoder,” in *Proc. Interspeech*, Aug. 2017, pp. 1118–1122.

[4] N. Kalchbrenner *et al.*, “Efficient neural Audio Synthesis,” in *Proc. ICML*, June 2018, pp. 2410–2419.

[5] J. Kong *et al.*, “HiFi-GAN: Generative adversarial networks for efficient and high fidelity speech synthesis,” in *Proc. NeurIPS*, Dec. 2020, pp. 17022–17033.

[6] J. Kim *et al.*, “Conditional variational autoencoder with adversarial learning for end-to-end text-to-speech,” in *Proc. ICML*, July 2021, pp. 5530–5540.

[7] D. Lim *et al.*, “JETS: Jointly training Fast-Speech2 and HiFi-GAN for end to end text to speech,” in *Proc. Interspeech*, Sept. 2022.

[8] T. Okamoto *et al.*, “Multi-stream HiFi-GAN with data-driven waveform decomposition,” in *Proc. ASRU*, Dec. 2021, pp. 610–617.

[9] T. Kaneko *et al.*, “iSTFTNet: Fast and lightweight mel-spectrogram vocoder incorporating inverse short-time Fourier transform,” in *Proc. ICASSP*, May 2022, pp. 6207–6211.

[10] G. Yang *et al.*, “Multi-band MelGAN: Faster waveform generation for highquality text-to-speech,” in *Proc. SLT*, Jan. 2021, pp. 492–498.

[11] S. Takamichi *et al.*, “JSUT and JVS: Free Japanese voice corpora for accelerating speech synthesis research,” *Acoust. Sci. Tech.*, vol. 41, no. 5, pp. 761–768, Sept. 2020.

[12] W. A. Jassim *et al.*, “WARP-Q: Quality prediction for generative neural speech codecs,” in *Proc. ICASSP*, June 2021, pp. 401–405.

[13] ITU-T Recommendation P. 800, *Methods for subjective determination of transmission quality*, 1996.