


Parallel WaveGAN

빠르고 안정적인 WaveNet 음성 합성 모델 만들기

송은우 / HDTS

Introduction

Text-to-speech (TTS)란 기계가 사람처럼 **텍스트를 읽어주는** 기술입니다.



클로바의 HDTS 기술로
생생하게 재현한 셀럽 AI 보이스

뉴스 읽어주는 AI 앵커 오상진,
유인나의 달달한 챗봇 연애상담소

The advertisement features a green background with white text and icons. On the left is a male AI voice actor, and on the right is a female AI voice actor holding a cookie. The text highlights Clova's HDTS technology and its application in creating realistic celebrity AI voices.

Introduction

Text-to-speech (TTS)란 기계가 사람처럼 텍스트를 읽어주는 기술입니다.





DNN TTS = Acoustic model + Vocoder

Introduction

Text-to-speech (TTS)란 기계가 사람처럼 텍스트를 읽어주는 기술입니다.


톤의 높낮이, 음색, 어조, 강세 등
텍스트에서 **Acoustic Parameter** 를 추정



Introduction

Text-to-speech (TTS)란 기계가 사람처럼 **텍스트를 읽어주는** 기술입니다.

Acoustic Parameter 에서 음성 신호를 추정



Introduction

Text-to-speech (TTS)란 기계가 사람처럼 **텍스트를 읽어주는** 기술입니다.

Acoustic Parameter 에서 음성 신호를 추정




본 발표에서는 TTS 엔진의 핵심 요소인 **Vocoder** 기술을 정리하고,
빠르고 안정적인 **Parallel WaveGAN** 모델을 소개하고자 합니다.

Vocoder: Overview


Vocoder: Overview

Vocoder란 Acoustic Parameter 에서 음성 신호를 만들어내는 기술입니다.





Vocoder: Overview

Vocoder란 Acoustic Parameter 에서 음성 신호를 만들어내는 기술입니다.



Acoustic Parameter ..?

톤의 높낮이, 음색, 어조, 강세 등 음성의 특징을 나타내는 파라미터
(ex. F0, Spectrum, v/uv, ...)



Vocoder: Overview

Vocoder란 Acoustic Parameter 에서 음성 신호를 만들어내는 기술입니다.



어떤 모델을 Vocoder 에 사용하냐에 따라 종류가 정해집니다.


Vocoder: Overview

Vocoder란 Acoustic Parameter 에서 음성 신호를 만들어내는 기술입니다.



어떤 모델을 Vocoder 에 사용하냐에 따라 종류가 정해집니다.

RNN 기반의 WaveRNN




Vocoder: Overview

Vocoder란 Acoustic Parameter 에서 음성 신호를 만들어내는 기술입니다.



어떤 모델을 Vocoder 에 사용하냐에 따라 종류가 정해집니다.

Flow 기반의 WaveGlow




Vocoder: Overview

Vocoder란 Acoustic Parameter 에서 음성 신호를 만들어내는 기술입니다.



어떤 모델을 Vocoder 에 사용하냐에 따라 종류가 정해집니다.

CNN 기반의 WaveNet




$$p(\mathbf{x}|\mathbf{h}) = \prod_{t=1}^T p(x_t|x_1, \dots, x_{t-1}, \mathbf{h})$$

$$\mathbf{z} = \tanh(W_{f,k} * \mathbf{x} + \mathbf{V}_{f,k}^T \mathbf{h}) \odot \delta(W_{g,k} * \mathbf{x} + \mathbf{V}_{g,k}^T \mathbf{h})$$

Vocoder: Overview

Vocoder란 Acoustic Parameter 에서 음성 신호를 만들어내는 기술입니다.



어떤 모델을 Vocoder 에 사용하냐에 따라 종류가 정해집니다.

CNN 기반의 WaveNet

현재 음성 신호를 예측할 때 과거 음성 신호를 함께 사용합니다.
이러한 방법을 **Autoregressive Model** 라고 정의합니다.




$$p(\mathbf{x}|\mathbf{h}) = \prod_{t=1}^T p(x_t|x_1, \dots, x_{t-1}, \mathbf{h})$$

$$\mathbf{z} = \tanh(W_{f,k} * \mathbf{x} + \mathbf{V}_{f,k}^T \mathbf{h}) \odot \delta(W_{g,k} * \mathbf{x} + \mathbf{V}_{g,k}^T \mathbf{h})$$

Vocoder: Overview

Vocoder란 Acoustic Parameter 에서 음성 신호를 만들어내는 기술입니다.



어떤 모델을 Vocoder 에 사용하냐에 따라 종류가 정해집니다.


CNN 기반의 WaveNet

현재 음성 신호를 예측할 때 과거 음성 신호를 함께 사용합니다.
이러한 방법을 **Autoregressive Model** 라고 정의합니다.

Autoregressive Model 은 고품질의 음성을 생성할 수 있으나,
1초 음성을 만들 때 약 5분 정도의 시간이 소요된다는 치명적인 문제가 있습니다.

Vocoder: Overview

Vocoder란 Acoustic Parameter 에서 음성 신호를 만들어내는 기술입니다.




WaveNet 의 속도 문제를 해결하기 위해 제안된 방법이 Non-autoregressive 구조의 **Parallel WaveNet** 입니다.



Vocoder: Overview


Vocoder란 Acoustic Parameter 에서 음성 신호를 만들어내는 기술입니다.



Autoregressive WaveNet (=Teacher) 모델의 확률 분포를
Non-autoregressive Parallel WaveNet (=Student) 모델이 배우도록 훈련합니다.

Vocoder: Overview


Vocoder란 Acoustic Parameter 에서 음성 신호를 만들어내는 기술입니다.



Non-autoregressive Parallel WaveNet 모델은
과거 음성을 사용하지 않으므로, 생성 속도에 제한이 없습니다.
(1초 음성을 약 0.02초 만에 생성 가능)

Vocoder: Overview

Vocoder란 Acoustic Parameter 에서 음성 신호를 만들어내는 기술입니다.



하지만 그만큼 합성음의 품질이 저하된다는 문제가 남아있습니다.



Vocoder: Overview

Vocoder란 Acoustic Parameter 에서 음성 신호를 만들어내는 기술입니다.



어떤 모델을 Vocoder 에 사용하냐에 따라 종류가 정해집니다.

CNN 기반의 WaveNet

Autoregressive

합성음 품질이 좋지만
생성 속도가 느리다


vs

Non-autoregressive

생성 속도가 빠르지만
학습이 어렵고
합성음 품질이 나쁘다

Vocoder: Overview

Vocoder란 Acoustic Parameter 에서 음성 신호를 만들어내는 기술입니다.



어떤 모델을 Vocoder 에 사용하냐에 따라 종류가 정해집니다.

CNN 기반의 WaveNet

Autoregressive

합성음 품질이 좋지만
생성 속도가 느리다

vs

Non-autoregressive


생성 속도가 빠르지만
학습이 어렵고
합성음 품질이 나쁘다

합성음 품질도 좋고, 생성 속도도 빠른 Vocoder 는 없을까



Vocoder: Overview

Vocoder란 Acoustic Parameter 에서 음성 신호를 만들어내는 기술입니다.



어떤 모델을 Vocoder 에 사용하냐에 따라 종류가 정해집니다.

CNN 기반의 WaveNet

Autoregressive

합성음 품질이 좋지만
생성 속도가 느리다

vs

Non-autoregressive

생성 속도가 빠르지만
학습이 어렵고
합성음 품질이 나쁘다

Non-autoregressive 의 품질을 높여보자


Vocoder: Parallel WaveNet

Vocoder: Parallel WaveNet

Vocoder: Parallel WaveGAN


Vocoder: Parallel WaveGAN

1. Teacher-student 기반의 Probability Distillation 과정을 없애고,



Vocoder: Parallel WaveGAN


1. Teacher-student 기반의 Probability Distillation 과정을 없애고,
 학습이 너무 어려우니까



Vocoder: Parallel WaveGAN

1. Teacher-student 기반의 Probability Distillation 과정을 없애고,
2. Adversarial Training 으로 합성음 품질을 높이고,

$$L_D(G, D) = \mathbb{E}_{x \sim p_{\text{data}}} [(1 - D(x))^2] + \mathbb{E}_{z \sim p_z} [D(G(z, h))^2]$$




출처: X.Mao, et al., "Least squares generative adversarial networks," in *Proc. ICCV*, 2017, pp. 2794-2802.

출처: R. Yamamoto, et al., "Parallel WaveGAN: A fast waveform generation model based on generative adversarial networks with multi-resolution spectrogram," in *Proc. ICASSP*, 2020, pp. 6194-6198.


Vocoder: Parallel WaveGAN

1. Teacher-student 기반의 Probability Distillation 과정을 없애고,
2. Adversarial Training 으로 합성음 품질을 높이고,
3. Multi-resolution STFT Loss 로 합성음 품질을 더 높이고,



Vocoder: Parallel WaveGAN

1. Teacher-student 기반의 Probability Distillation 과정을 없애고,
2. Adversarial Training 으로 합성음 품질을 높이고,
3. Multi-resolution STFT Loss 로 합성음 품질을 더 높이고,



Vocoder: Parallel WaveGAN


1. Teacher-student 기반의 Probability Distillation 과정을 없애고,
2. Adversarial Training 으로 합성음 품질을 높이고,
3. Multi-resolution STFT Loss 로 합성음 품질을 더 높이고,



STFT (short-time Fourier transform)?


짧은 구간의 음성 신호를 주파수 축에서 표현 한 것.

시간 축으로 붙여서 2D 신호로 만든 것이 다음과 같은 Spectrogram



Vocoder: Parallel WaveGAN

1. Teacher-student 기반의 Probability Distillation 과정을 없애고,
 2. Adversarial Training 으로 합성음 품질을 높이고,
 3. Multi-resolution STFT Loss 로 합성음 품질을 더 높이고,
- 시간-주파수 축에서 해상도가 다른 여러 개의 Loss 들의 평균이다.




Vocoder: Parallel WaveGAN

1. Teacher-student 기반의 Probability Distillation 과정을 없애고,
2. Adversarial Training 으로 합성음 품질을 높이고,
3. Multi-resolution STFT Loss 로 합성음 품질을 더 높이고,

시간-주파수 축에서 해상도가 다른 여러 개의 Loss 들의 평균이다.

이때, Loss 는 두가지로 구성되는데




Vocoder: Parallel WaveGAN

1. Teacher-student 기반의 Probability Distillation 과정을 없애고,
2. Adversarial Training 으로 합성음 품질을 높이고,
3. Multi-resolution STFT Loss 로 합성음 품질을 더 높이고,

시간-주파수 축에서 해상도가 다른 여러 개의 Loss 들의 평균이다.

이때, Loss 는 두가지로 구성되는데

하나는 **에너지가 큰 구간**을 잡아내고



$$L_{sc}(x, \hat{x}) = \frac{\sqrt{\sum_{t,f} (|\mathbf{X}_{t,f}| - |\hat{\mathbf{X}}_{t,f}|)^2}}{\sqrt{\sum_{t,f} |\mathbf{X}_{t,f}|^2}}$$

Vocoder: Parallel WaveGAN


1. Teacher-student 기반의 Probability Distillation 과정을 없애고,
2. Adversarial Training 으로 합성음 품질을 높이고,
3. Multi-resolution STFT Loss 로 합성음 품질을 더 높이고,

시간-주파수 축에서 해상도가 다른 여러 개의 Loss 들의 평균이다.

이때, Loss 는 두가지로 구성되는데

하나는 에너지가 큰 구간을 잡아내고


다른 하나는 **에너지가 작은 구간**을 잡아낸다.



$$L_{\text{mag}}(x, \hat{x}) = \frac{\sum_{t,f} |\log |X_{t,f}| - \log |\hat{X}_{t,f}| |}{T \cdot N}$$

Vocoder: Parallel WaveGAN

1. Teacher-student 기반의 Probability Distillation 과정을 없애고,
2. Adversarial Training 으로 합성음 품질을 높이고,
3. Multi-resolution STFT Loss 로 합성음 품질을 더 높이고,
4. STFT Loss 에 Perceptual Weighting Filter 를 적용해서 한번 더 품질을 높인다.



$$L_{sc}^w(\mathbf{x}, \hat{\mathbf{x}}) = \frac{\sqrt{\sum_{t,f} (\mathbf{W}_{t,f} (|\mathbf{X}_{t,f}| - |\hat{\mathbf{X}}_{t,f}|))^2}}{\sqrt{\sum_{t,f} |\mathbf{X}_{t,f}|^2}}$$


$$L_{mag}^w(\mathbf{x}, \hat{\mathbf{x}}) = \frac{\sum_{t,f} |\log \mathbf{W}_{t,f} (\log |\mathbf{X}_{t,f}| - \log |\hat{\mathbf{X}}_{t,f}|)|}{T \cdot N}$$

$$W(z) = 1 - \sum_{k=1}^p \tilde{\alpha}_k z^{-k}$$

Vocoder: Parallel WaveGAN

1. Teacher-student 기반의 Probability Distillation 과정을 없애고
2. Adversarial Training 으로 합성음 품질을 높이고,
3. Multi-resolution STFT Loss 로 합성음 품질을 더 높이고,
4. STFT Loss 에 Perceptual Weighting Filter 를 적용해서 한번 더 품질을 높인다.

사람에게 청각적으로 더 잘 들리는 **잡음을 제거**하는 역할



$$L_{sc}^w(\mathbf{x}, \hat{\mathbf{x}}) = \frac{\sqrt{\sum_{t,f} \mathbf{W}_{t,f} (|\mathbf{X}_{t,f}| - |\hat{\mathbf{X}}_{t,f}|)^2}}{\sqrt{\sum_{t,f} |\mathbf{X}_{t,f}|^2}}$$

$$L_{mag}^w(\mathbf{x}, \hat{\mathbf{x}}) = \frac{\sum_{t,f} |\log \mathbf{W}_{t,f} (\log |\mathbf{X}_{t,f}| - \log |\hat{\mathbf{X}}_{t,f}|)|}{T \cdot N}$$

$$W(z) = 1 - \sum_{k=1}^p \tilde{\alpha}_k z^{-k}$$

Vocoder: Parallel WaveGAN

1. Teacher-student 기반의 Probability Distillation 과정을 없애고,
2. Adversarial Training 으로 합성음 품질을 높이고,
3. Multi-resolution STFT Loss 로 합성음 품질을 더 높이고,
4. STFT Loss 에 Perceptual Weighting Filter 를 적용해서 한번 더 품질을 높인다.



Autoregressive

합성음 품질이 좋지만
생성 속도가 느리다

VS

Non-autoregressive

학습도 쉽고
생성 속도도 빠르고
합성음 품질도 좋다

Performance Evaluations

Evaluation: Database


한국 여성 화자 (문장 수) 

Training / Validation / Test
5,085 360 180


한국 남성 화자 (문장 수) 

Training / Validation / Test
5,382 290 140


Evaluation: Model Architecture



Evaluation: Training Method



Evaluation: Inference Speed



Autoregressive WaveNet

294.11 RT

VS

Parallel WaveGAN

0.02 RT

약 14,000 배 빠른 생성 속도

RT: 1초 음성을 생성할 때 걸리는 시간 (180+140=320문장)

Evaluation: Perceptual Quality



Autoregressive WaveNet

여성 화자: 3.6 MOS
남성 화자: 3.6 MOS

VS

Parallel WaveGAN

여성 화자: 4.3 MOS
남성 화자: 4.2 MOS

약 14,000 배 빠른 생성 속도
약 18 % 높은 합성음 품질

Evaluation: TTS Demo



Autoregressive WaveNet

여성 화자:
남성 화자:

VS

Parallel WaveGAN

여성 화자: 
남성 화자:

약 14,000 배 빠른 생성 속도
약 18 % 높은 합성음 품질

Evaluation: TTS Demo



Autoregressive WaveNet

여성 화자:
남성 화자:

VS

Parallel WaveGAN

여성 화자:
남성 화자: 

약 14,000 배 빠른 생성 속도
약 18 % 높은 합성음 품질

Summary

본 발표에서는 TTS 엔진의 핵심 요소인 **Vocoder** 기술을 정리하고,
빠르고 안정적인 **Parallel WaveGAN** 모델을 소개하였습니다.

Goal

빠르고 안정적인 NON-autoregressive Vocoder 만들기

How to ?

Teacher-student 기반의 Probability Distillation 과정을 없애고,
Adversarial Training 으로 합성음 품질을 높이고,
Multi-resolution STFT Loss 로 합성음 품질을 더 높이고,
STFT Loss 에 Perceptual Weighting Filter 를 적용해서 한번 더 품질을 높인다.

Parallel WaveGAN's performance

14,000 배 빠른 생성 속도 + 18 % 높은 합성음 품질

본 발표에서는 TTS 엔진의 핵심 요소인 **Vocoder** 기술을 정리하고,
빠르고 안정적인 **Parallel WaveGAN** 모델을 소개하였습니다.

Next ?

서비스 적용을 위한 안정성 높이기

TTS samples



한국어



일본어

기술 개발 기여자 (가나다순)

HDTS/권오성

HDTS/김진섭

HDTS/송은우

HDTS/송찬호

HDTS/황민제

HDTS/山本龍一

Voice&Avatar/김재민



Q / A

