

음성 및 영상합성을 통한 Fake Video생성

Deep Learning Application based on StarGAN-VC and FSGAN
2조: Advance

Team Members

2조 - 김정준, 김용신, 김예현, 박승우, 장우원

Schedule

2020.10.02 데이터수집 및 주제선정
2020.10.09 데이터 전처리, 논문리뷰
2020.10.16 모델 생성 및 훈련, 결과도출
2020.10.23 성능향상을 위한 튜닝
2020.10.30 문서작성 및 프로젝트 발표

Preparation

Data Set : 유명인 음성Data
GAN(Generative Adversarial Network) 기반 기술
StarGANVC / FSGAN 모델 적용

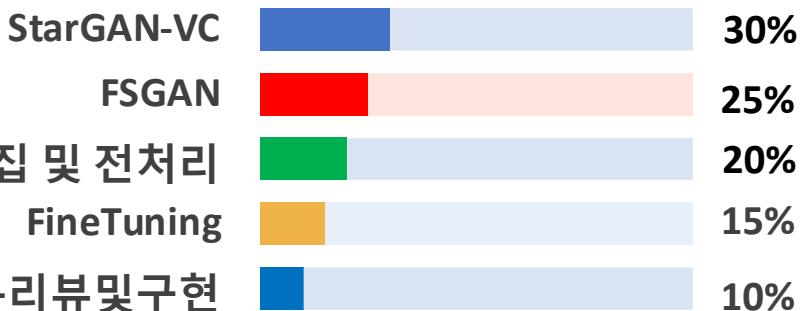
GAN을 활용한 음성&영상 합성



Face Swap과 Voice Conversion에 관한 연구

- FSGAN기반 Face Swap
- StarGAN-VC를 이용한 음성 변조

Works



Motivation

DEEPBRAIN 의 AI Human 기술 간략하게 구현해보기 StarGAN을 이용한 음성 변환과 FSGAN을 이용한 영상 합성을 통해 AI Human 영상 제작

CONTENT STEP UP [A.I.]

문화체육관광부 한국콘텐츠진흥원 KOREA CREATIVE CONTENT AGENCY

교육 장소 한국콘텐츠진흥원 유튜브

10.6(수) 09:20~12:00 STEP 3A. AI 제작 1 이미지/영상

STEP 1 AI BM, 기획 → STEP 2 AI 발전방향 (디지털휴먼)

STEP 3A AI 제작 1 이미지/영상
STEP 3B AI 제작 2 음성/언어

10:15~11:05

김주하 AI앵커

딥브레인AI 장세영 대표
(전) SK C&C, 모바일 솔루션 및 메타버스 모바일 개발
국내 최초 인공지능 앵커 제작
문재인 대통령 및 손석희 아니운서 음성합성

인공인간 (AI Human) 및 버추얼
인플루언서 비즈니스 혁신
음성 및 영상 데이터를 활용한 인공인간 기술 분석

Contents

1. Introduction

2. 프로젝트 주제 및 선정 이유

- 정성평가 설문조사

3. 데이터 수집 (FSGAN선정 개념)

- Face Swap Model 개념

4. 음성 데이터 수집 및 방법

- 데이터 분포 분석
- 음성 추출 방법(VREW)
- FSGAN(얼굴합성)

5. 음성 모델 & 모델 성능 비교

- 성능향상을 위한 Pitch(성별)
- Batch size, Class
- CycleGAN VC
- STARGAN VC
- 정량평가(precision, recall, diverge, converge)

6. FSGAN 얼굴 합성 한계점

- 인물별 움직임에 따른 성능차이
- Metrics -> Cosine similarity, MSE, SSIM
- 유사도의 따른 합성 결과 (Move, Still)

7. 데모영상 시현

8. Contribution

- 영상 & 음성 합성 프로세스
- 음성 모델별 비교 성능차이(성별, Pitch)
- 영상 모델별 비교 성능차이

9. Future work

Introduction

1. Project Goal

- 음성과 영상 합성을 통한 AI Human 구현하기

2. Overall Process (논문리뷰)

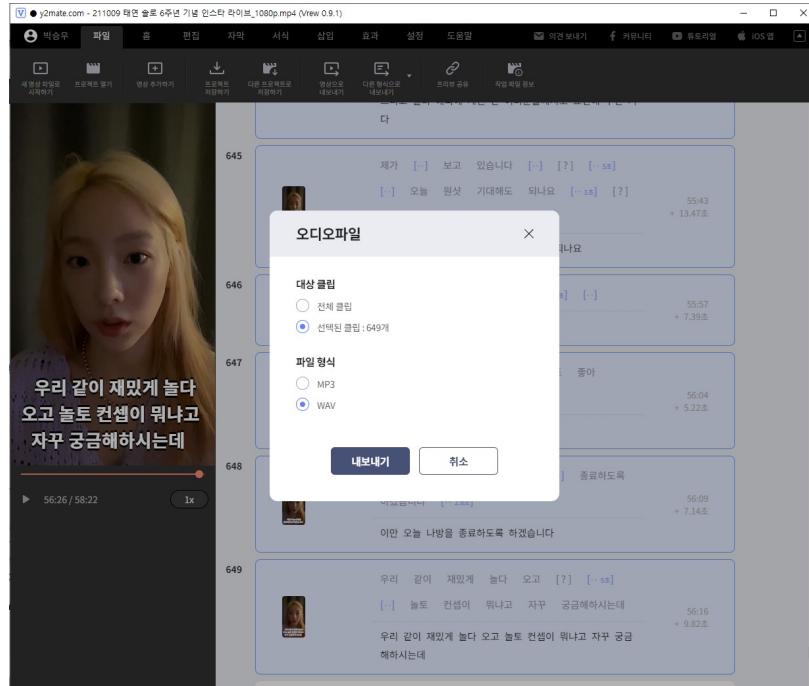
- 논문리뷰
 - 영상: FSGAN
 - 음성: Cyclegan-vc, Stargan-vc, Stargan-vc2
- 코드실습
 - GAN, Cyclegan, Stargan, Fsgan
- 데이터셋 수집
 - 문재인, 김상중, 박근혜, 김주하, 아이유, 유인나
- 모델학습
 - Training: Cyclegan-vc, Stargan-vc, Stargan2-vc
 - Finetuning: Fsgan
- 데모영상
 - 문재인->김상중
 - 박근혜->김주하

3. Dataset

• Description

- 2 class (문재인, 김상중) – 500개씩
- 4 class (문재인 김상중 박근혜 김주하) - 200개씩
- 4 class (김주하, 박근혜, 아이유, 유인나) – 200개씩
- 4 class(김주하, 박근혜, 아이유, 유인나) – 250개씩
- 500개 단위가 (음성의 한문장)

Survey



[YouTube to WAV 변환기](#) - Vrew 브루

- ① 유인나의 볼륨을 높여요(1).wav
- ② 유인나의 볼륨을 높여요(2).wav
- ③ 유인나의 볼륨을 높여요(3).wav
- ④ 유인나의 볼륨을 높여요(4).wav
- ⑤ 유인나의 볼륨을 높여요(5).wav
- ⑥ 유인나의 볼륨을 높여요(6).wav
- ⑦ 유인나의 볼륨을 높여요(7).wav
- ⑧ 유인나의 볼륨을 높여요(8).wav
- ⑨ 유인나의 볼륨을 높여요(9).wav

- ⑩ 태연_인스타 라이브_(1).wav
- ⑪ 태연_인스타 라이브_(2).wav
- ⑫ 태연_인스타 라이브_(3).wav
- ⑬ 태연_인스타 라이브_(4).wav
- ⑭ 태연_인스타 라이브_(5).wav
- ⑮ 태연_인스타 라이브_(6).wav
- ⑯ 태연_인스타 라이브_(7).wav
- ⑰ 태연_인스타 라이브_(8).wav
- ⑱ 태연_인스타 라이브_(9).wav
- ⑲ 태연_인스타 라이브_(10).wav
- ⑳ 태연_인스타 라이브_(11).wav
- ㉑ 태연_인스타 라이브_(12).wav

한문장별로 나눠
음성 데이터 취합

<https://forms.gle/ke3b8qgeZACYCJSm6>

Voice conversion evaluation

다음 음성 중 문재인 대통령님과 가장 비슷한 목소리 음성을 선택해 주세요. (File responses)

Q1-2 : link *

[Survey_voice](https://drive.google.com/drive/folders/1VjEvxgOHVaVsK9PCW6LlrMj6piUjGEyY?usp=sharing)

	오디오-1	오디오-2	오디오-3	오디오-4
1st	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
2nd	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
3rd	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
4th	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

음성 합성된 음성 정성평가분석을
위한 설문조사 진행

StarGAN VC source analysis

StarGan-VC 소스 분석

The screenshot shows a Jupyter Notebook environment with the following components:

- File Explorer:** Displays a file tree under "drive/MyDrive". Key folders include "converted", "data" (containing "VCTK-Corpus" and "custom"), and "test" (containing "p1_08.npy").
- GPU Check:** A code cell with the output "true" and the text "GPU 확인".
- Run Demo:** A code cell containing the command: `[] !python convert.py --resume_iters 38000 --src_spk p3 --trg_spk p2`. An arrow points from this cell to the "Iteration 확인" section.
- Iteration 확인:** A terminal window showing the conversion process. It lists speakers: "인물3 -> 인물2", "p1, p2, p3, p4 = 발라드, 일엔비, 트로트, 어쿠스", and "p1, p2, p3, p4, p5".
- Generator 학습:** A section with the command: `return torch.FloatTensor(mc), torch.LongTensor([spk_idx]).squeeze_(), torch.FloatTensor(spk_cat)`.
- Transcription Results:** A section labeled "전처리 결과" with the text "Speaker Index화" and "Speaker Category화".

The screenshot shows two code editors side-by-side:

- preprocess.py:** A Python script for processing speaker features. It includes functions for getting speaker world features and normalizing coded speaker vectors. A portion of the code is highlighted with a red box.
- main.py:** A Python script for training the model. It uses a loop to process test paths, encode wav files, and save normalized coded speaker vectors. Another portion of the code is highlighted with a red box.

Face Swap

Face Swap 기술이란?

사진 혹은 비디오에 있는 얼굴을 인식하여, 얼굴의 부분을 우리가 원하는 대상의 얼굴 부분으로 바꿔주는 딥러닝 기반의 기술을 의미한다.



Source



Target



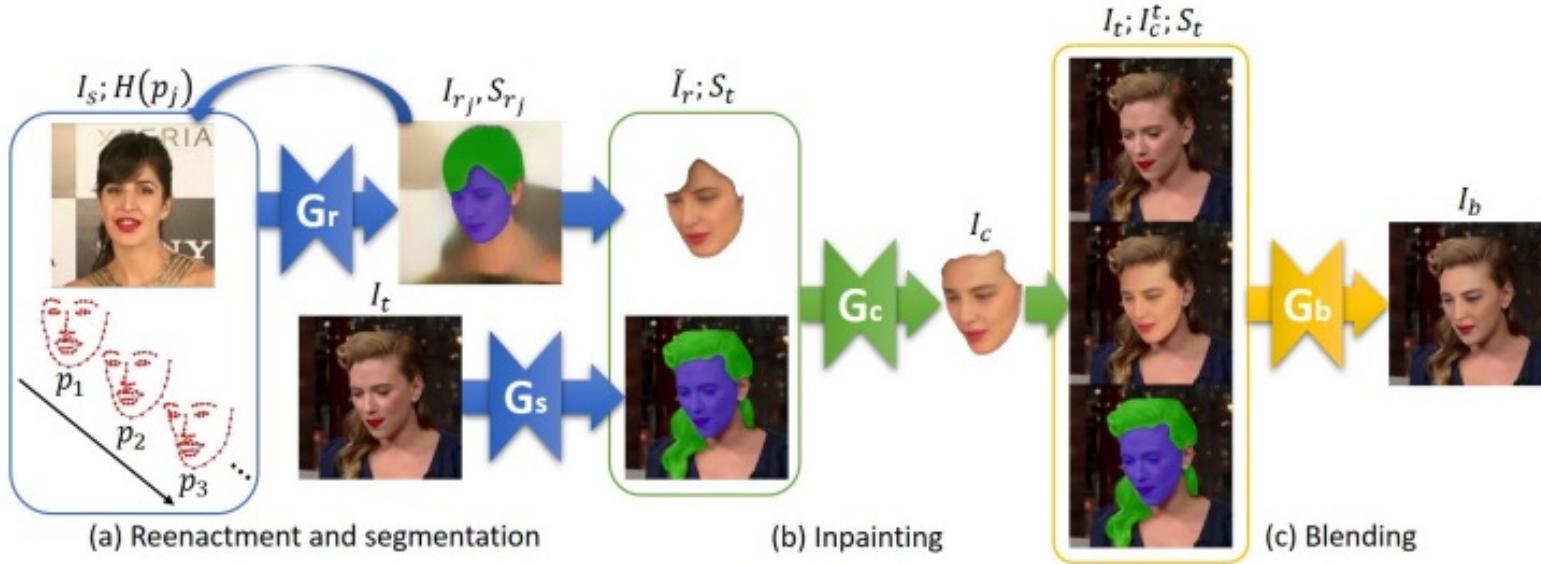
Result

FSGAN (Face-Swapping Generative Adversarial Network)

Goal: Subject-agnostic face swap



FSGAN(Face Swapping Generative Adversarial Network)

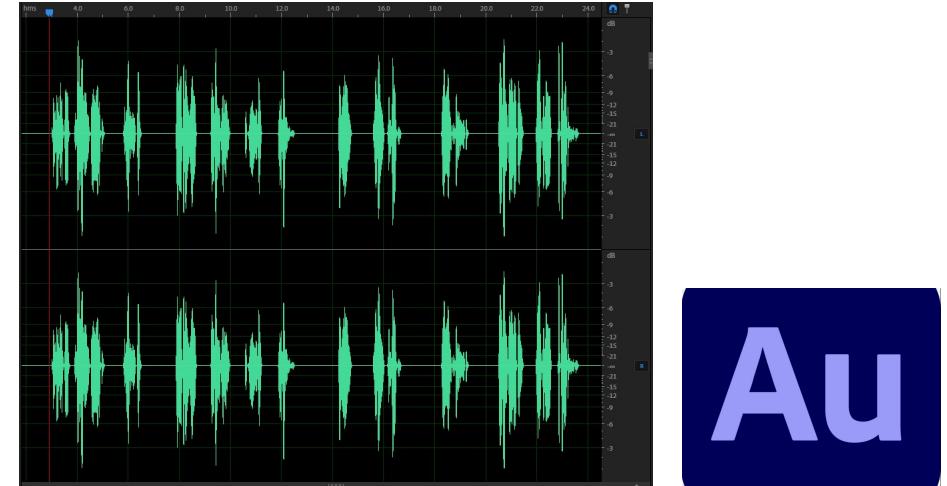


Contribution:

1. RNN기반으로 접근하여 사진 한 장 또는 영상 시퀀스에 적용하여 얼굴 재현을 가능하게 함.
2. Face completion network를 사용하여 얼굴 영역을 생성하고, face blending network를 통해 target의 얼굴색과 조명색을 유지하여 두 얼굴이 매끄럽게 합성되도록 함.
3. 새로운 손실함수인 Poisson blending loss를 사용.

Voice preprocessing

- 고품질의 음성 데이터 수집 및 음성 파일 preprocessing
 - Prototype #1 문재인과 김상중 간 목소리 변환 모델의 데이터 500여개 수집



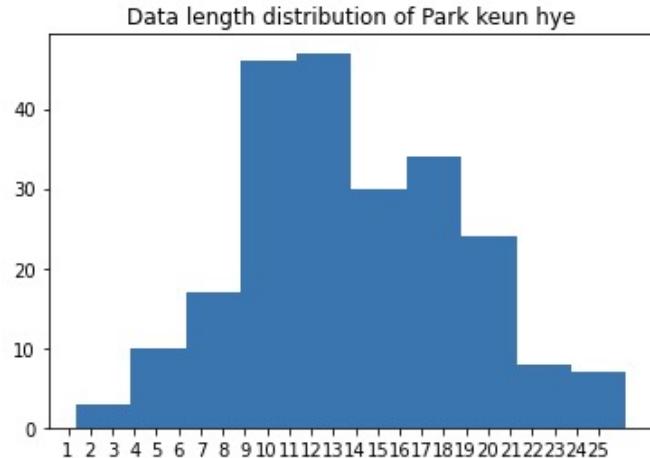
- Prototype #2 여성 화자 기반의 목소리 데이터 200여개 파일 수집

팀 내 역할과 주별 주요 활동

- 음성 데이터 분포 분석

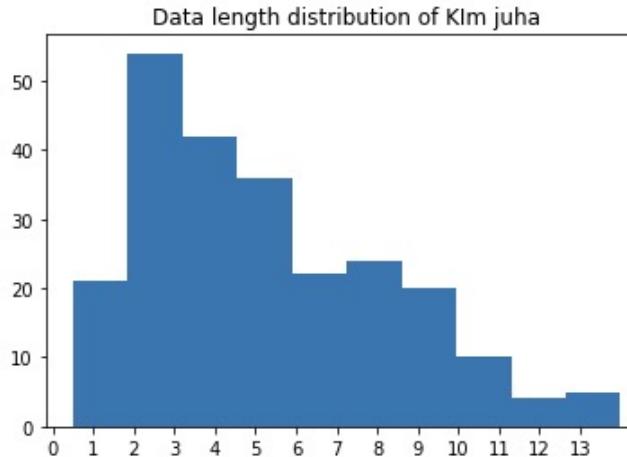
mean value: 13.9025958702065

sample_n: 226



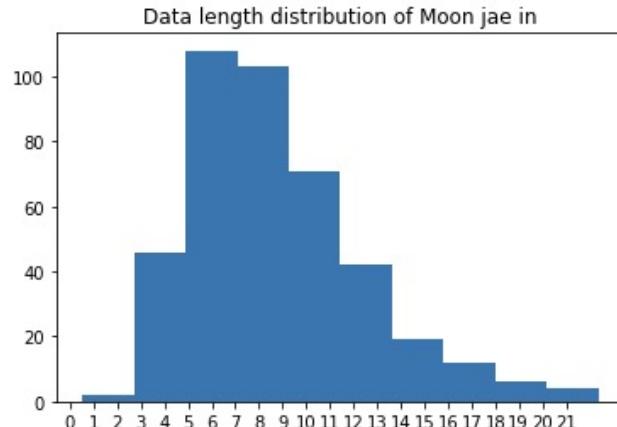
mean value: 5.263165266106442

sample_n: 238



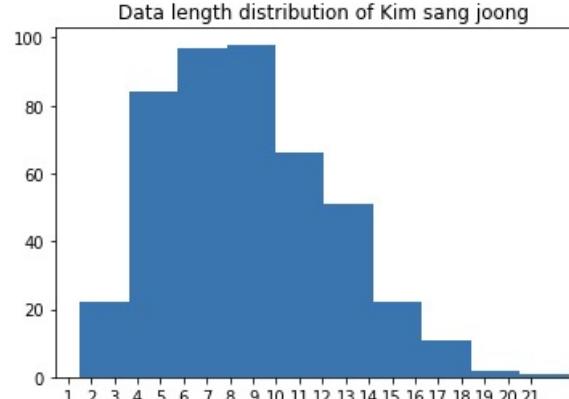
mean value: 8.746853056900717

sample_n: 413



mean value: 8.778942731277533

sample_n: 454



```
import os
```

```
DIR = "/content/drive/MyDrive/StarGAN-Voice-Conversion-master/
```

```
files = os.listdir(DIR)  
files.sort()
```

```
lengDict=dict()  
for target_id in files[0:]:  
    print(target_id)  
    subDir=os.listdir(DIR+str(target_id))  
    subDir.sort()  
    lengDict[target_id]=[]  
    for num,file in enumerate(subDir):  
        if num%20 ==0:  
            print("file : ",file)  
            f = sf.SoundFile(DIR+str(target_id)+"/"+str(file))
```

```
lengDict[target_id].append(f.frames / f.samplerate)
```

```
print("mean value: ",sum(lengDict['p1'])/len(lengDict['p1']))  
plt.hist(lengDict['p1'])  
print("sample_n: ",len(lengDict['p1']))  
x=list(range(int(min(lengDict['p1'])),int(max(lengDict['p1']))))  
plt.xticks(x)  
plt.title("Data length distribution of Kim sang joong")  
plt.show()
```

```
p1  
file : p1_01.wav  
file : p1_11.wav  
file : p1_128.wav
```

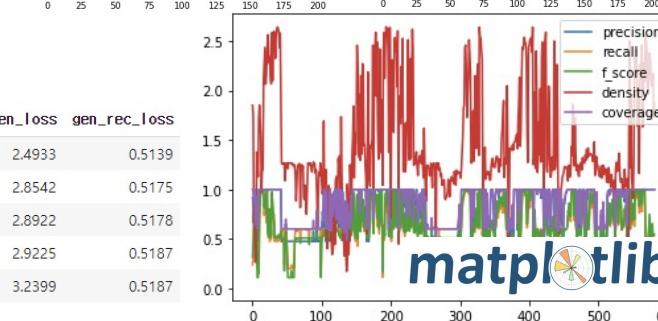
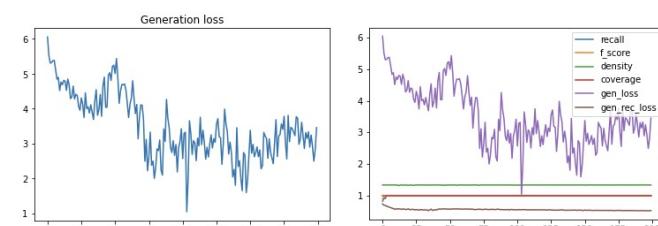
팀 내 역할과 주별 주요 활동

- 학습성능 향상을 위한 영상 편집 및 마스크 처리
- FSGAN
 - 박근혜 김주하 얼굴 합성 및 파라미터 튜닝
- starGAN
 - Model training
 - Loss terms, converge and density 등의 정량 평가 데이터 분석, 가시화 및 최적 모델 탐색
- 데모 시연 영상 편집 및 제작

```
Elapsed [0:07:07], Iteration [1000/145000], D/loss_real: -107.6250, D/loss_f  
Elapsed [0:14:34], Iteration [2000/145000], D/loss_real: -22.3880, D/loss_fa  
Elapsed [0:21:59], Iteration [3000/145000], D/loss_real: -39.7920, D/loss_fa  
Elapsed [0:29:25], Iteration [4000/145000], D/loss_real: -54.0177, D/loss_fa  
Elapsed [0:36:50], Iteration [5000/145000], D/loss_real: -49.2912, D/loss_fa  
Elapsed [0:44:16], Iteration [6000/145000], D/loss_real: -55.7255, D/loss_fa  
Elapsed [0:51:42], Iteration [7000/145000], D/loss_real: -50.4180, D/loss_fa  
Elapsed [0:59:08], Iteration [8000/145000], D/loss_real: -50.4180, D/loss_fa  
Elapsed [1:06:34], Iteration [9000/145000], D/loss_real: -50.4180, D/loss_fa  
Elapsed [1:13:59], Iteration [10000/145000], D/loss_real: -50.4180, D/loss_fa  
...
```

iter	precision	recall	f_score	density	coverage	gen_loss	gen_rec_loss	
197	198000/200000	1.0000	1.0000	1.0000	1.3333	1.0	2.4933	0.5139
190	191000/200000	1.0000	1.0000	1.0000	1.3307	1.0	2.8542	0.5175
194	195000/200000	1.0000	1.0000	1.0000	1.3333	1.0	2.8922	0.5178
196	197000/200000	1.0000	1.0000	1.0000	1.3333	1.0	2.9225	0.5187
189	190000/200000	1.0000	1.0000	1.0000	1.3333	1.0	3.2399	0.5187

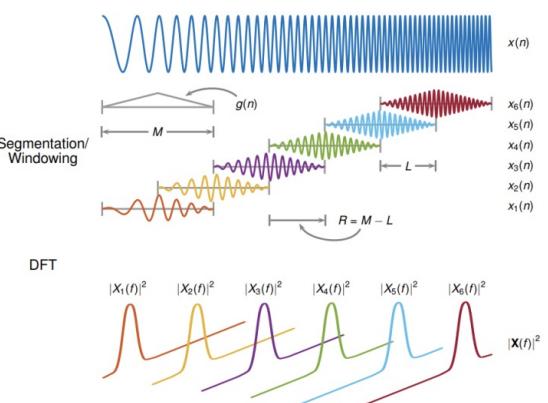
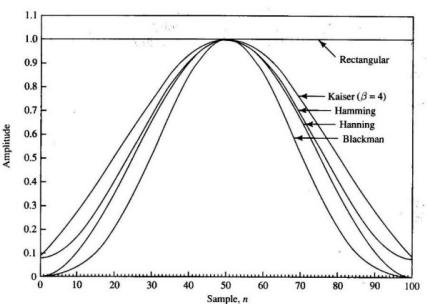
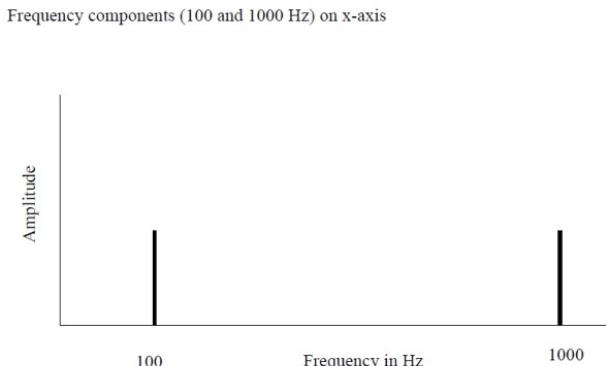
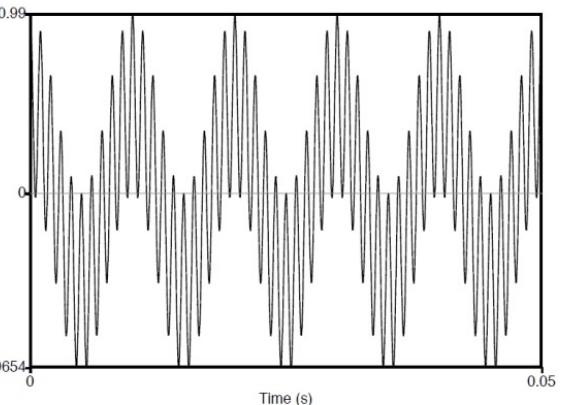
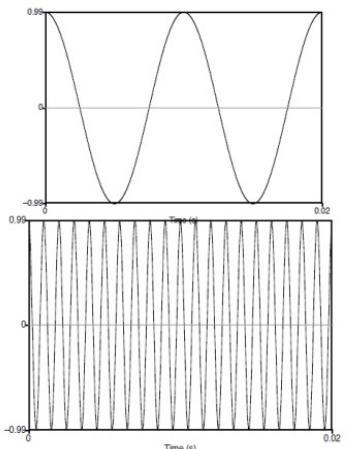


```
# Utility functions  
import ffmpeg  
  
def encode_audio(video_path, audio_path, output_path):  
    ffmpeg.concat(input(video_path), ffmpeg.input(audio_path), ffmpeg.output(output_path, strict='-2')).run()  
  
def display_video(video_path, width=640, clear=False):  
    vid_data = open(video_path, 'rb').read()  
    vid_url = 'data:video/mp4;base64,' + b64encode(vid_data).decode()  
  
    if clear:  
        clear_output()  
  
    return HTML(f'''  
        <video width={width} controls>  
            <source src={vid_url} type="video/mp4">  
        </video>  
    ''')  
  
from google.colab import drive  
drive.mount('/content/drive')  
  
Drive already mounted at /content/drive: to unmount  
!rm -dr /content/data/source*  
!rm -dr /content/data/target*
```

음성 feature 추출 방법

Voice data 분석 및 특징 추출법 연구

■ 음성 파일 추출과 푸리에 변환 코드화



출처: SK t아카데미/ 스마트 ICT 전문가 양성/ 딥러닝 기반 음성학습 강의 자료

```
def get_spk_world_feats(spk_fold_path, mc_dir_train, mc_paths = glob.glob(join(spk_fold_path, '*.wav'))
spk_name = basename(spk_fold_path)
train_paths, test_paths = split_data(paths)
f0s = []
coded_sps = []
for wav_file in train_paths:
    f0, _, _, _, coded_sp = world_encode_wav(wav_file)
    f0s.append(f0)
    coded_sps.append(coded_sp)
log_f0s_mean, log_f0s_std = logf0_statistics(f0s)
coded_sps_mean, coded_sps_std = coded_sp_statistics(coded_sps)
np.savez(join(mc_dir_train, spk_name+'_stats.npz'),
        log_f0s_mean=log_f0s_mean,
        log_f0s_std=log_f0s_std,
        coded_sps_mean=coded_sps_mean,
        coded_sps_std=coded_sps_std)

for wav_file in tqdm(test_paths):
    wav_name = basename(wav_file)
    f0, timeaxis, sp, ap, coded_sp = world_encode_wav(wav_file)
    normed_coded_sp = normalize_coded_sp(coded_sp, ap)
    np.save(join(mc_dir_train, wav_name.replace('.wav',
                                                '_normed_coded_sp.npz')))

def world_decompose(wav, fs, frame_period = 5.0):
    # Decompose speech signal into f0, spectral envelope and ap
    wav = wav.astype(np.float64)
    f0, timeaxis = pyworld.harvest(wav, fs, frame_period)
    sp = pyworld.cheaptrick(wav, f0, timeaxis, fs)
    ap = pyworld.d4c(wav, f0, timeaxis, fs)
    return f0, timeaxis, sp, ap

def world_encode_spectral_envelop(sp, fs, dim=36):
    # Get Mel-cepstral coefficients (MCEPs)
    # sp = sp.astype(np.float64)
    coded_sp = pyworld.code_spectral_envelope(sp, fs, dim)
    return coded_sp

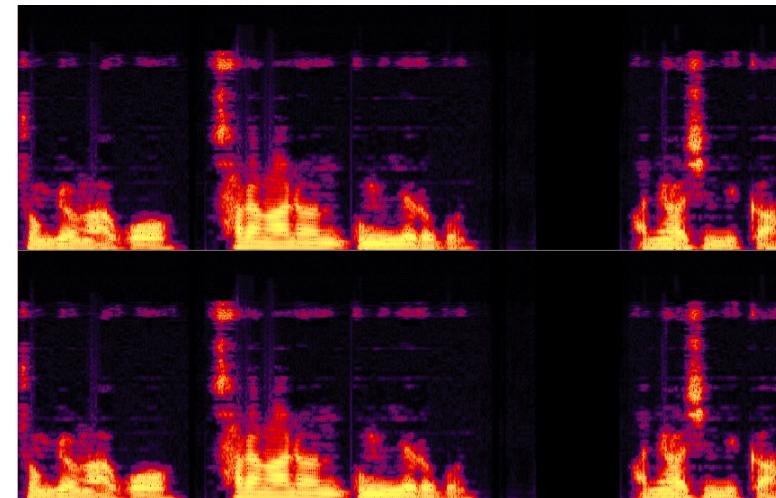
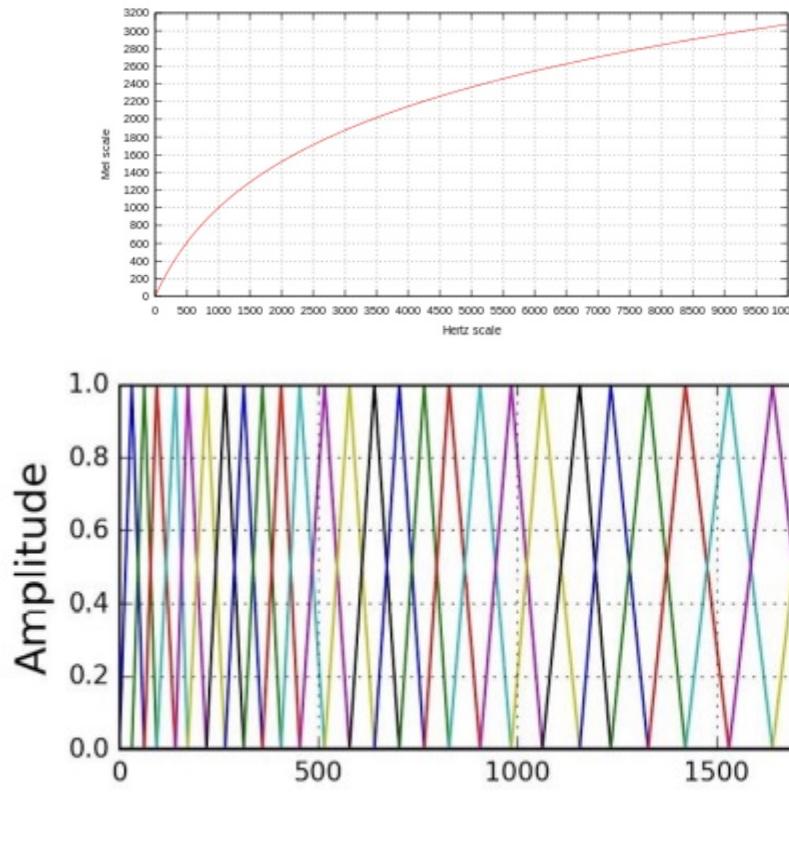
def world_decode_spectral_envelop(coded_sp, fs):
    # Decode Mel-cepstral to sp
    fftlen = pyworld.get_cheaptrick_fft_size(fs)
    decoded_sp = pyworld.decode_spectral_envelope(coded_sp, fftlen, fs)
    return decoded_sp

def world_encode_wav(wav_file, fs, frame_period=5.0):
    wav = load_wav(wav_file, sr=fs)
    f0, timeaxis, sp, ap = world_decompose(wav=wav, fs=fs)
    coded_sp = world_encode_spectral_envelop(sp=sp, fs=fs, dim=36)
    return f0, timeaxis, sp, ap, coded_sp
```

음성 feature 추출 방법

Voice data 분석 및 특징 추출법 연구

- MCEP 채택



```
return wav_padded

def logf0_statistics(f0s):
    log_f0s_concatenated = np.concatenate(f0s)
    log_f0s_mean = log_f0s_concatenated.mean()
    log_f0s_std = log_f0s_concatenated.std()

    return log_f0s_mean, log_f0s_std

def pitch_conversion(f0, mean_log_f0, std_log_f0):
    # Logarithmic Gaussian normalization
    f0_converted = np.exp((np.log(f0) - mean_log_f0) / std_log_f0)

    return f0_converted

def wavs_to_specs(wavs, n_fft=2048, hop_length=512):
    stfts = []
    for wav in wavs:
        stft = librosa.stft(wav, n_fft=n_fft, hop_length=hop_length)
        stfts.append(stft)

    return stfts
```

FSGAN

얼굴 합성 데모 영상 생성 (박근혜 < - > 김주하)

-> 결과가 좋지 않아 fsGAN으로 모델 변경

▪ fsGAN 코드 실행 및 데모 생성

-> 결과 확인을 반복하여 가용 resource내에서

파라미터 튜닝

Iteration 800 > 1000, batch size 8 > 30



```
import os
from fsgan.inference.swap import FaceSwapping
from fsgan.criterions.vgg_loss import VGGLoss

#@markdown This step should only be done once unless one of the
#@markdown following parameters is changed:

#@markdown ---
#@markdown Path to the weights directory (make sure it is correct)
weights_dir = '/content/drive/My Drive/fsgan/weights' #@param {type:"dir"}
#@markdown Number of finetune iterations on the source subject
finetune_iterations = 1000 #@param {type:"slider", min:100, max:1000}
#@markdown If True, the inner part of the mouth will be removed
seg_remove_mouth = True #@param {type:"boolean"}
#@markdown Segmentation batch size
seg_batch_size = 30 #@param {type:"slider", min:1, max:64, step:1}
#@markdown Inference batch size
batch_size = 30 #@param {type:"slider", min:1, max:64, step:1}
#@markdown ---
```

```
detection_model = os.path.join(weights_dir, 'v2/WIDERFace_DSFD')
pose_model = os.path.join(weights_dir, 'shared/hopenet_robust_alpha1')
lms_model = os.path.join(weights_dir, 'v2/hr18_wflw_1_landmarks')
seg_model = os.path.join(weights_dir, 'v2/celeba_unet_256_1_2')
reenactment_model = os.path.join(weights_dir, 'v2/infv_msrunet')
completion_model = os.path.join(weights_dir, 'v2/iibc_msrunet')
blending_model = os.path.join(weights_dir, 'v2/iibc_msrunet_256')
criterion_id_path = os.path.join(weights_dir, 'v2/vggface2_vgg')
criterion_id = VGGLoss(criterion_id_path)
```

Voice Conversion

: 화자가 전달하려는 내용 (linguistic content)은 유지하고 우리가 원하는 대상화자의 말하기 특징 (acoustic feature)을 합성하여 목소리 스타일을 변환하는 기술을 의미한다.

발화 내용

- 동일한 발화 데이터를 사용하는지 여부 – Parallel vs Non-Parallel
- 발화된 언어가 동일한지 여부 – Mono-lingual vs Cross-lingual

발화자 구성

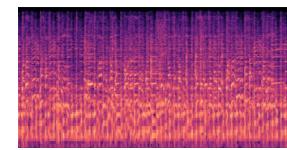
- 여러 명의 화자를 사용하는지 여부 – (one-to-one) vs (many-to-many)
- 동일한 성별의 화자를 사용하는지 여부 – (same gender) vs (different gender)



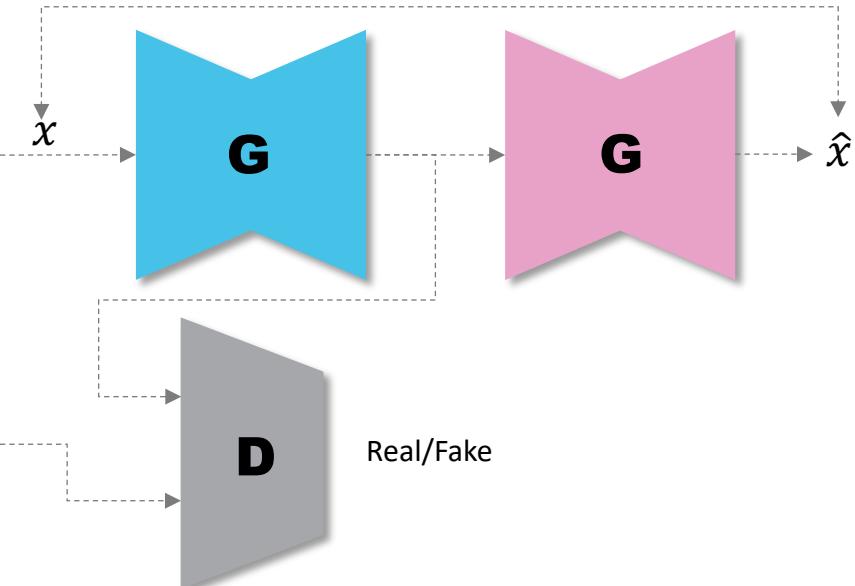
source speaker



waveform audio



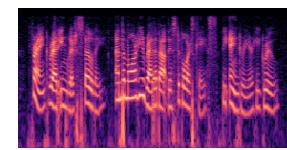
mel-spectrogram



target speaker



waveform audio



mel-spectrogram

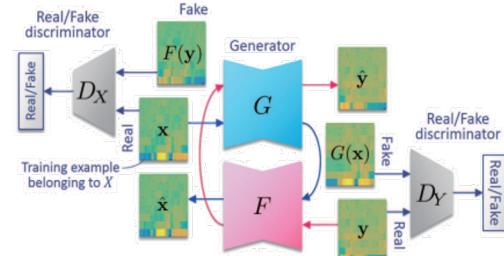
Voice Conversion Models

모델 선택

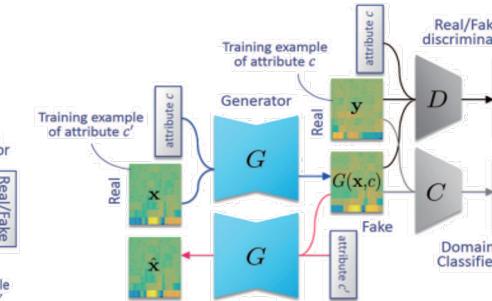
: CycleGAN-VC, StarGAN-VC

목적

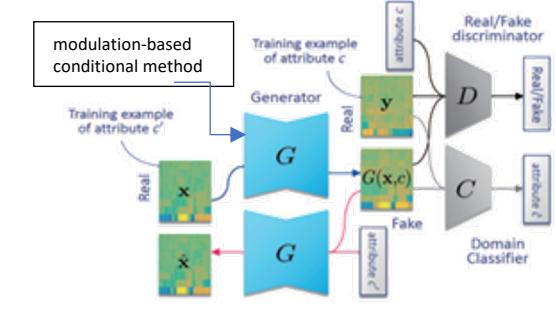
: 각 모델이 갖는 특성에 따라 합성된 음성의 퀄리티가 어떻게 달라지는지 살펴보고 음성 합성 도메인에서 개선의 여지가 있는 기능들을 살펴보자 한다.



CycleGAN-VC



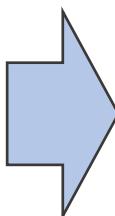
StarGAN-VC



StarGAN-VC2

선행 분석

- 다양한 sampling rate 설정 : 16K, 22K, 32K
- 배치사이즈 변경 : 16, 128, 256
- 학습 iteration : 50K, 100K, 200K
- 다양한 목소리 특징을 갖는 화자를 구성하여 학습
: 박근혜, 유인나, 아이유, 김주하



분석 결과

- 기존 연구에서 사용되는 16K로 resampling하는 결과가 제일 좋음
- 배치사이즈가 적을 수록 미세하게 좋은 합성 결과를 얻음
- 배치사이즈를 작게 설정하고 iteration을 많게 설정하면 비교적 안정적인 음성 합성 결과를 얻음
- 목소리의 높낮이나 말의 빠르기가 많이 차이나는 화자 간의 음성 합성은 잘 되지 않는 결과를 얻음

Model Comparison (1)

	CycleGAN-VC	StarGAN-VC	StarGAN-VC	StarGAN-VC2
Classification Loss (discriminator)	×	0	0	0
Domain code modulation (Generator)	×	Depth-wise modulation	Depth-wise modulation	Conditional instance normalization
Reconstruction Loss	0	0	0	0
Domain A-Domain B	One-to-One	One-to-One	Many-to-Many	Many-to-Many

CycleGAN-VC (one-to-one)

vs

StarGAN-VC (one-to-one)



```

# installed_packages_list = sorted([(ts==is)% (i.key, i.version) for i in installed_packages])
# print(installed_packages_list)

Move to repository in my GoogleDrive
[ ] %cd drive/MyDrive/StarGAN-Voice-Conversion-master
/content/drive/MyDrive/StarGAN-Voice-Conversion-master

Preprocess data using Mel-cepstral coefficients(MCEPs) (already done)

[ ] # python preprocess.py --sample_rate 16000 \
--origin_wavpath data/custom/wav4 \
--target_wavpath data/custom/wav16 \
--mc_dir_train data/custom_mc/train \
--mc_dir_test data/custom_mc/test

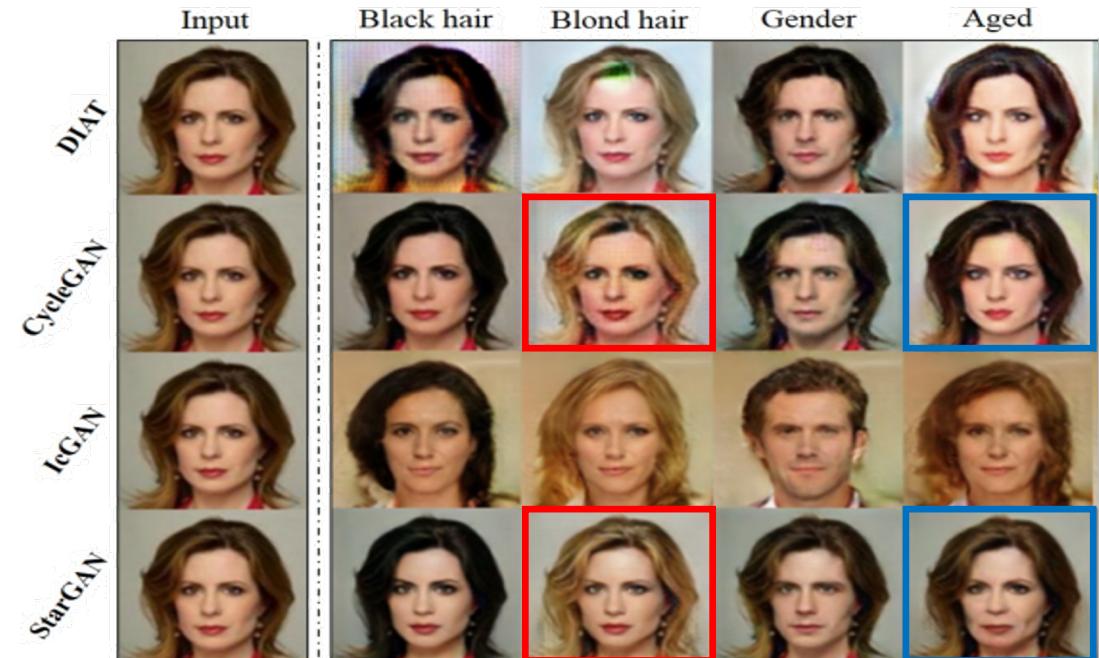
GPU check
[ ] import torch
torch.cuda.is_available()

```

StarGAN-VC (one-to-one)

vs

StarGAN-VC (Many-to-Many)

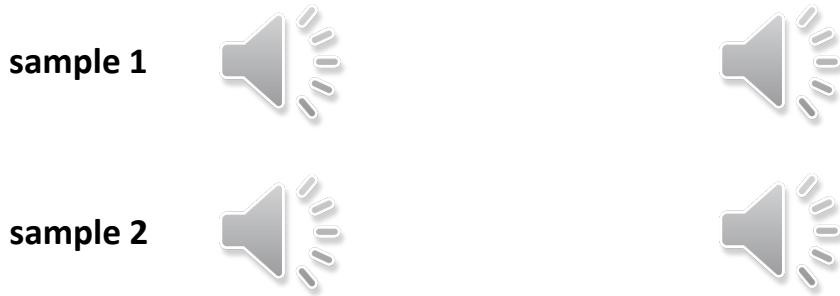


Facial attribute transfer results on StarGAN

Model Comparison (2)

	CycleGAN-VC	StarGAN-VC	StarGAN-VC	StarGAN-VC2
Classification Loss (discriminator)	✗	0	0	0
Domain code modulation (Generator)	✗	Depth-wise modulation	Depth-wise modulation	Conditional instance normalization
Reconstruction Loss	0	0	0	0
Domain A-Domain B	One-to-One	One-to-One	Many-to-Many	Many-to-Many

StarGAN-VC (Many-to-Many) vs StarGAN-VC2 (Many-to-Many)



Limitation on previous methods

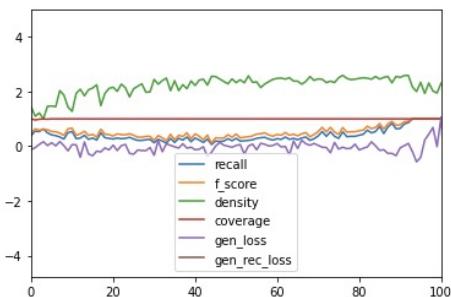
: Source speaker의 음성 길이에 맞춰 target 스피커의 말하기 특징 (acoustic feature)을 합성하다 보니 여전히 source speaker의 음성 특징 정보가 남아 음성합성 결과에 안 좋은 영향을 미침

```
Run Demo
python convert.py --resume_iters 100000 --src_spk p1 --trg_spk p2
Namespace(convert_dir='./converted', log_dir='./logs', model_save_dir='./models', numConvertedWav=100000)
Loading the trained models from step 100000...
131120
Before being fed into G: (1640, 36)
After being fed into G: (1640, 36)
112560
Before being fed into G: (1408, 36)
After being fed into G: (1408, 36)
67760
Before being fed into G: (848, 36)
After being fed into G: (848, 36)
65840
Before being fed into G: (824, 36)
After being fed into G: (824, 36)
177200
Before being fed into G: (2216, 36)
After being fed into G: (2216, 36)
159920
Before being fed into G: (2000, 36)
After being fed into G: (2000, 36)
193200
Before being fed into G: (2416, 36)
After being fed into G: (2416, 36)
140720
Before being fed into G: (1760, 36)
```

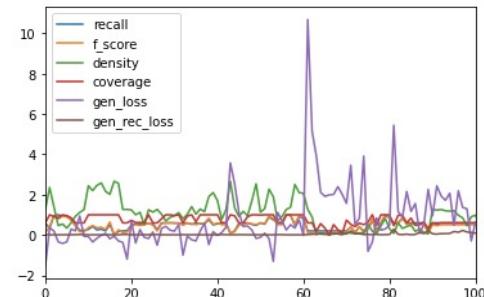
Experimental Results (1)

정량적 결과 (Quantitative Results)

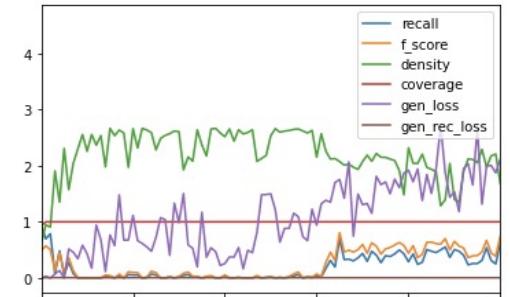
Evaluation metrics: precision, recall, density, coverage



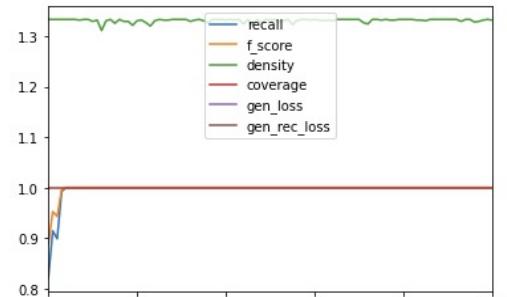
CycleGAN-VC



StarGAN-VC (2p)



StarGAN-VC (4p)



StarGAN-VC 2 (4p)

정성적 결과 (Qualitative Results)

평가 방법: 구글 설문조사를 통해 음성파일을 듣고 좀 더 문재인 (target speaker)의 목소리와 비슷한 샘플에 순위를 매기도록 함

음성 합성 샘플 : 김상중 → 문재인

설문조사자 수: 25명

질문 목록

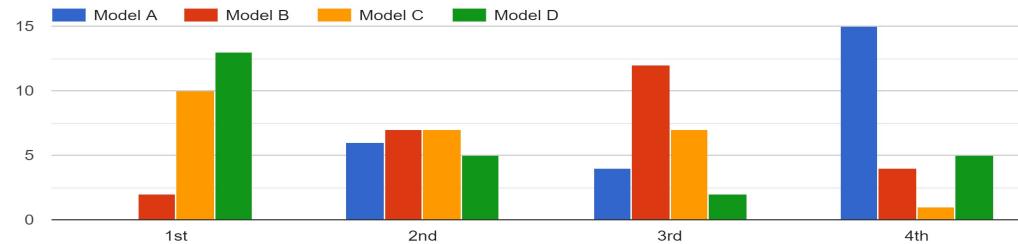
- 각 모델이 합성한 음성 샘플을 비교하여 어떤 모델이 정성적으로 좋은 결과 가지는가?
- 정량지표 (Density, Reconstruction Loss, Generation Loss) 의 min, max, median 값을 시점 (iteration)의 모델의 정성평가 (StarGAN-VC 2 모델로 고정)

Experimental Results (2)

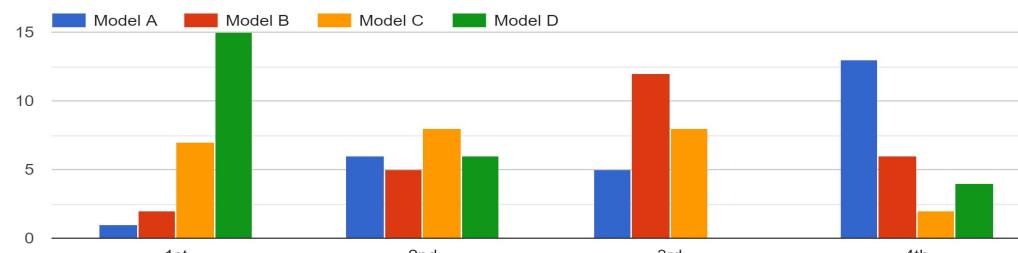
Model A : CycleGAN-VC
Model B : StarGAN-VC (2p)
Model C : StargAN-VC (4p)
Model D : StarGAN-VC 2 (4p)

Recon_loss: reconstruction loss
Gen_loss : generation loss

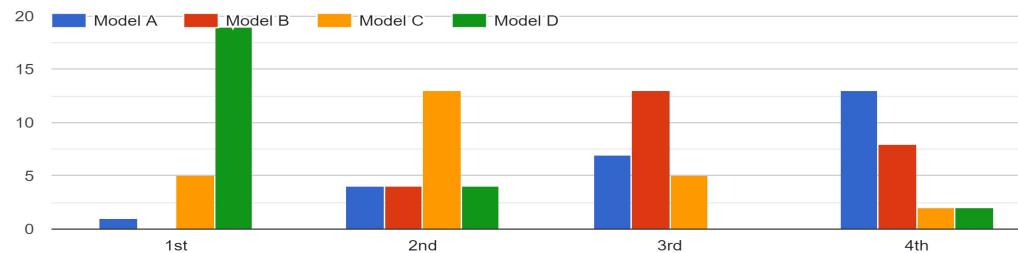
Q1-1



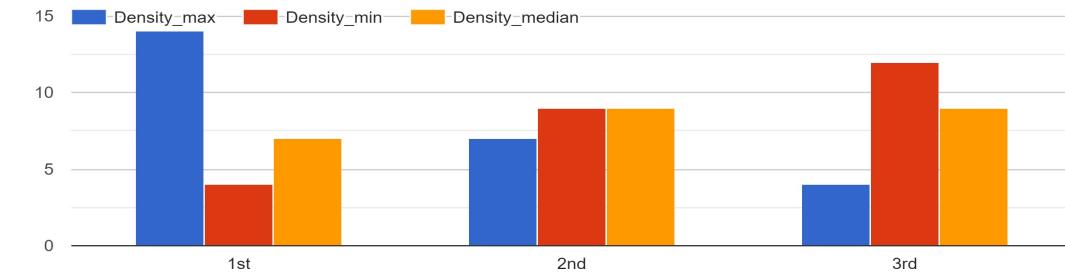
Q1-2 : link



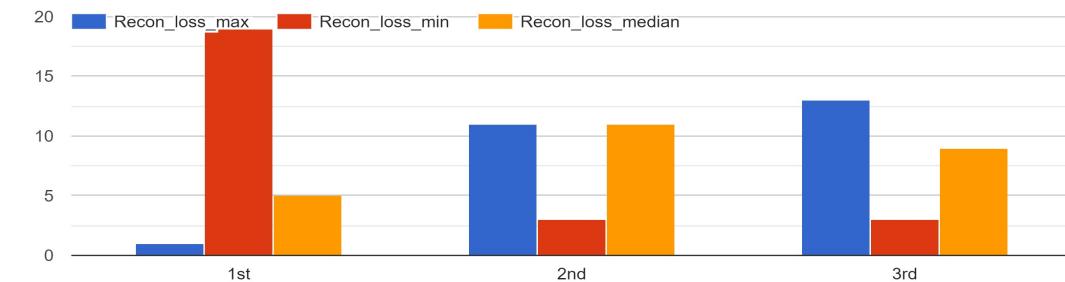
Q1-3 : link



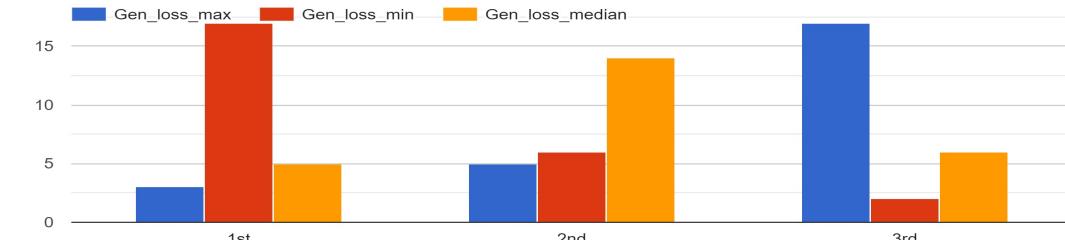
Q2-1 : link



Q2-2 : link

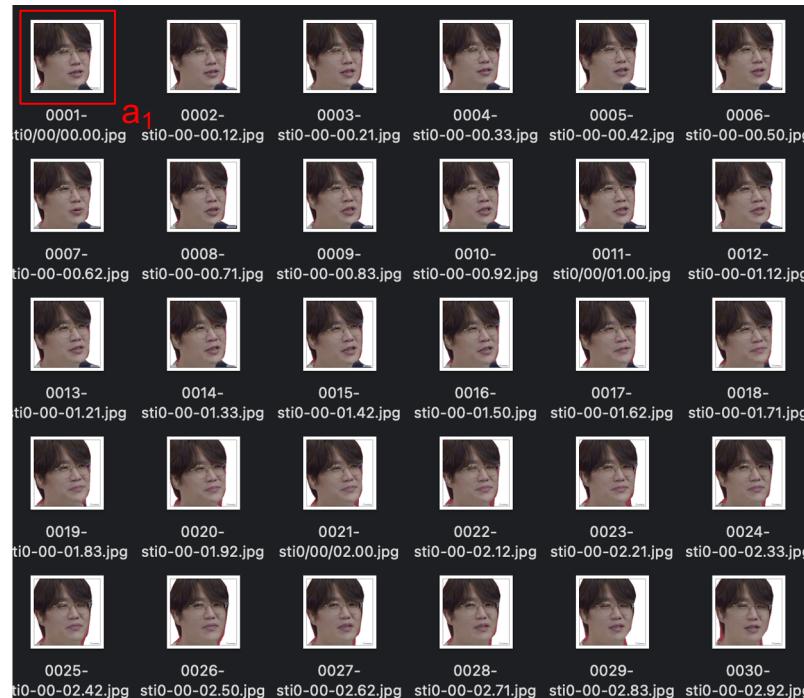


Q2-3 : link



Average similarity

- Problem
 - The more movement on the face, the lower the performance
 - It takes about an hour to synthesize the two videos.
- Average similarity between the two videos
 - Feature types: Pixel vs. Face embedding(FaceNet) vs. PCA
 - Metrics: Cosine similarity, MSE, SSIM(Structural Similarity Index Measure)
 - $\frac{\sum[\text{Cosine sim, MSE, SSIM}](a_n, b_n)}{n}$



Average similarity



Cosine sim: 0.7563 | 비 → 김종국



Cosine sim: 0.8391 | 성시경 → 비



Cosine sim: 0.9358 | 김종국 → 성시경



Cosine sim: 0.9437 | 규현 → 성시경

Demo video

그날PICK.



김상중 → 문재인



박근혜 → 김주하

Conclusion

- Experience in synthesizing videos from data collection to demo video
 - 논문리뷰 → 코드실습 → 데이터셋 수집 → 모델학습 → 데모영상
- Voice
 - Sampling rate, batch size, iteration, ...
 - 정량 및 정성평가
- Video
 - Average similarity between the two videos
- Future work
 - 음성) Source speaker의 음성내용에 Target speaker 목소리 톤을 입히는 경우 Source speaker의 음성 길이에 맞춰 Target speaker의 목소리 톤을 합성하다 보니 자연스러운 음성 변환이 힘든 경우가 있다.
 - Target speaker의 corpus당 음성 길이를 유지하기 위한 loss term을 학습과정에 추가하여 Target speaker의 자연스러운 음성 변환
 - 클래스당 데이터의 개수를 늘리고 좀 더 다양한 클래스를 구성하여 모델을 학습하도록 한다
 - Voice conversion에서 feature를 추출한 방법 상 고주파수 영역의 소리, phase 정보 손실
 - MFCC로 feature 추출 방법을 변경
 - wav 파일 자체를 feature로 사용(학습 시간이 오래 걸리기 때문에 추후 예정)

Q & A
