

# 音声対話システムのテキスト音声合成における 声質変換とx-vector埋め込みを用いた感情制御方式の検討

小原 俊一 岡山大学 阿部研究室

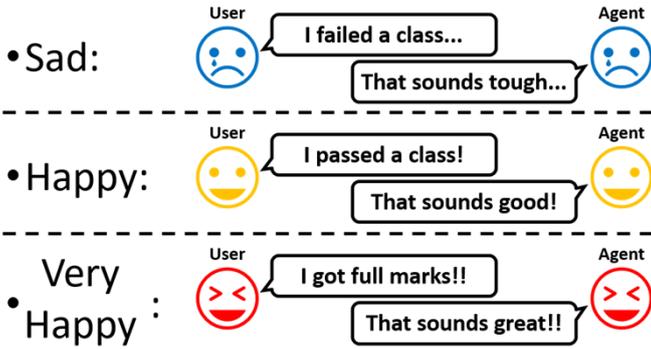
## 1. 研究背景・目的

### 音声対話システム(SDS)

- 音声を用いて機械と対話するシステム
- ✓ 音声の**非言語情報**(感情・韻律など)が重要
- ✓ **これを欠くとシステムの応答合成音声は無味乾燥に**

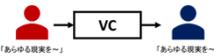
### 目的

□ **感情とその強さをユーザに合わせた音声合成**



### x-vector

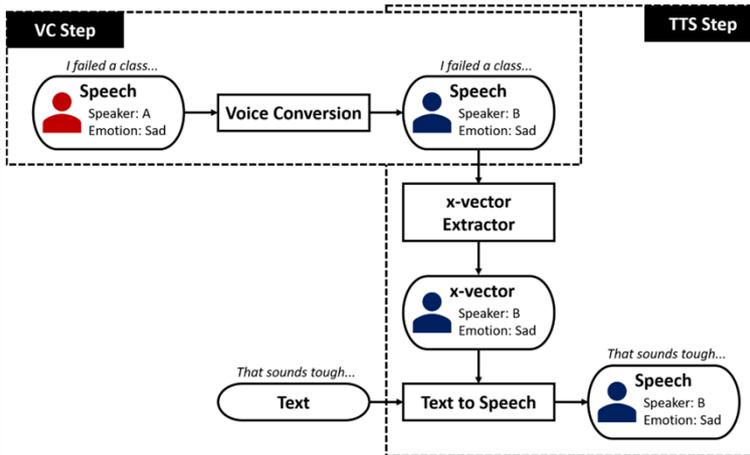
- 話者認識モデルから抽出される話者埋め込みベクトル
- **話者性**に加えて、**感情情報**も内包
- **SDSでは、入力音声と合成音声で話者が異なる**

声質変換 (Voice Conversion: VC) 

### 提案方式

□ **VCで話者性を変更し、x-vectorで感情を付与するTTS**

## 2. 提案方式



### VC Step

- 感情を保持したまま話者性をTTSモデルの話者へ変換

### TTS Step

- 変換音声のx-vectorで感情表現を付与

## 3. データセット

### 使用データセット: STUDIES

- 講師(女性)と(男子, 女子)生徒の模擬対話音声
- 発話ごとに感情ラベルが振られており、  
平静(Neutral)と喜び(Happy), 悲しみ(Sad)を評価

## 4. 評価実験

### VCアーキテクチャ: VITS

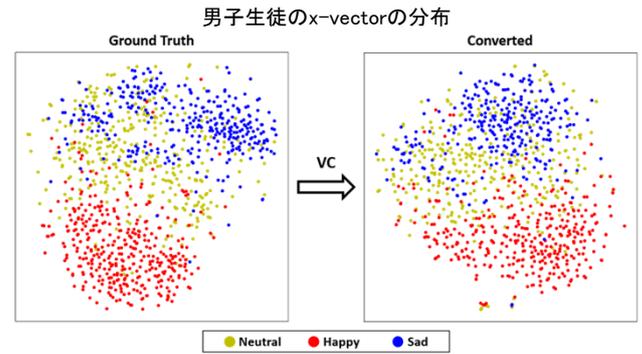
- 男子生徒と女子生徒, 講師で学習, VCとして使用

### TTSアーキテクチャ: X-VITS (ESPnet2)

- 講師の感情音声で学習

### VC Stepに関する分析

- VC後も概ね感情が保持されている



### 感情の制御に関する感情認識テスト

- 変換音声のx-vectorで感情を制御可能

① OneHot-EmoID

② Teacher-GT

Correct emotions	Subject-perceived emotions			Subject-perceived emotions		
	Neutral	Happy	Sad	Neutral	Happy	Sad
Neutral	<b>0.940</b>	0.000	0.060	<b>0.970</b>	0.020	0.010
Happy	0.120	<b>0.880</b>	0.000	0.000	<b>1.000</b>	0.000
Sad	0.110	0.000	<b>0.890</b>	0.080	0.000	<b>0.920</b>

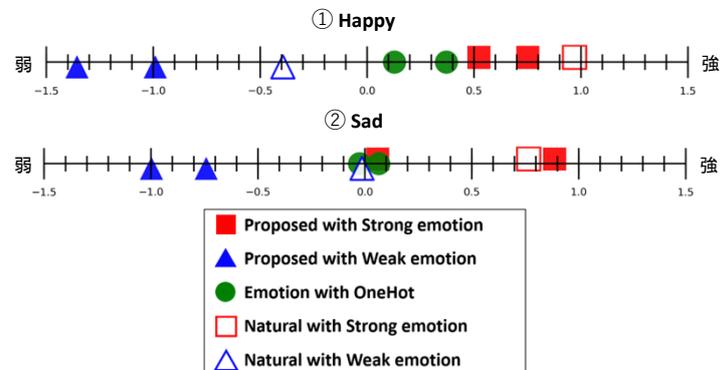
③ M-student-Converted (proposed)

④ F-student-Converted (proposed)

Correct emotions	Subject-perceived emotions			Subject-perceived emotions		
	Neutral	Happy	Sad	Neutral	Happy	Sad
Neutral	<b>0.860</b>	0.030	0.110	<b>0.870</b>	0.040	0.090
Happy	0.000	<b>1.000</b>	0.000	0.040	<b>0.960</b>	0.000
Sad	0.370	0.000	<b>0.630</b>	0.730	0.030	<b>0.240</b>

### 感情の強さに関する一対比較実験

- 喜びも悲しみも強さを表現可能



## 5. まとめと今後の課題

### まとめ

- 声質変換とx-vector埋め込みで感情とその強さを合成音声に反映させる方式の検討
- 変換音声のx-vectorで感情とその強さを制御可能

### 今後の課題

- 提案方式を音声対話システムに用いた場合の評価
- ant-to-one VCやSERの事後確率で条件付ける方式の検討