

# 変分オートエンコーダと注意機構を用いた 発話文のキャラクタ性変換

Transforming the Personality of a Dialogue System  
Using Variational Auto-Encoder and Attention Mechanism

谷川 晃大<sup>\*1</sup> 藤田 寛泰<sup>\*2</sup> 壱岐 太一<sup>\*1</sup>  
Akihiro Tanikawa Hiroyasu Fujita Taichi Iki

<sup>\*1</sup>株式会社 Nextremer  
Nextremer Co., Ltd.

<sup>\*2</sup>高知工科大学大学院 工学研究科  
Graduate School of Engineering, Kochi University of Technology

Dialogue systems such as chatbots and smart speakers are becoming ubiquitous in our daily lives. In order to achieve high user experience, it is important for dialogue agents to have attractive personality which enables friendly and human-like conversations. However, in most present cases, development of such dialogue systems involves hand-crafting of dialogue scenarios, and introducing the characteristics representative of certain personality to system utterances requires large time and human resources. This paper proposes a technique to automatically transform the characteristics of a sentence using variational auto-encoder and attention mechanism.

## 1. はじめに

チャットボットやスマートスピーカなどの実用化が進み、対話システムが日常生活に浸透してきている。対話システムと人間の会話において生じる問題の一つとして、対話システムの無個性な発話に起因した対話体験の質の低下が挙げられる。対話体験をより向上するには、親しみがあり、愛着が湧くようなキャラクタ性を対話エージェントに付与することが重要であると考えられる。

対話システムの構築において、対話シナリオは人手で作成されることが多い。複数のサービスに対話システムを導入する上で、対話シナリオの再利用を考えた場合、特定のキャラクタに対応した発話を人手で書き換えることに対する作業コストの高さが懸念される。これを解決する方法として、発話のキャラクタ性を自動変換する研究が行われている [Walker 12][刀山 17][沈 12][宮崎 16]。ただし、これらの研究では、変換を行うために、文の書き換えルールや辞書、モデルの学習に使用するパラレルコーパスなどをあらかじめ人手で作成する必要がある。

我々は、コストを抑えたキャラクタ性変換の手法として、さまざまなキャラクタの発話をそれぞれ独立に用意することで、キャラクタ性の変換を可能とする変分オートエンコーダ (Variational Auto-Encoder; VAE) を用いる手法に注目している。本稿では、キャラクタ性変換の制御性を高めることを目的に、VAE と注意機構を組み合わせた発話文のキャラクタ性変換手法を提案する。

## 2. 関連モデル

まずは、本稿で用いる VAE と注意機構について説明する。

### 2.1 VAE

VAE は Kingma らによって提案された深層生成モデルである [Kingma 14a]。VAE では、潜在変数  $\mathbf{z}$  の分布  $p(\mathbf{z})$  からデコーダ  $p_\theta(\mathbf{x}|\mathbf{z})$  ( $\theta$  はモデルパラメータ) によって観測変数  $\mathbf{x}$  が生成されるとし、次の周辺尤度の下界が最大になるように学習する。

連絡先: 谷川 晃大, 株式会社 Nextremer 高知 AI ラボ,  
〒 783-0060 高知県南国市螢が丘 1-1-1 南国オフィス  
パーク 3F, akihiro.tanikawa@nextremer.com

$$\begin{aligned}\log p(\mathbf{x}) &\geq \mathbb{E}_{q_\phi(\mathbf{z}|\mathbf{x})} [\log p_\theta(\mathbf{x}|\mathbf{z})] - D_{KL}(q_\phi(\mathbf{z}|\mathbf{x})||p(\mathbf{z})) \\ &= -\mathcal{L}(\mathbf{x})\end{aligned}\quad (1)$$

ここで、 $q_\phi(\mathbf{z}|\mathbf{x})$  は潜在変数の分布を推論するためのエンコーダ ( $\phi$  はモデルパラメータ) である。なお、潜在変数の分布は  $\mathbf{z} \sim \mathcal{N}(\mathbf{0}, \mathbf{I})$  と仮定する。

VAE を拡張したモデルとして、条件付き変分オートエンコーダ (Conditional VAE; CVAE)[Kingma 14b] がある。CVAE は VAE の入力にラベル情報  $\mathbf{y}$  を追加したモデルである。CVAE では、次の周辺尤度の下界が最大になるように学習を行う。

$$\begin{aligned}\log p(\mathbf{x}, \mathbf{y}) &\geq \mathbb{E}_{q_\phi(\mathbf{z}|\mathbf{x}, \mathbf{y})} [\log p_\theta(\mathbf{x}|\mathbf{y}, \mathbf{z}) + \log p(\mathbf{y})] \\ &\quad - D_{KL}(q_\phi(\mathbf{z}|\mathbf{x}, \mathbf{y})||p(\mathbf{z})) \\ &= -\mathcal{L}(\mathbf{x}, \mathbf{y})\end{aligned}\quad (2)$$

CVAE では、エンコーダとデコーダの入力にラベル情報を加えることにより、潜在変数  $\mathbf{z}$  にラベル以外の情報が抽出されるようになるという特徴をもつ。例えば、手書き数字画像であれば、画像に描かれている数字がいくつであるかをラベル情報とすることで、数字のスタイル情報を潜在変数として抽出できる。潜在変数を固定した状態でラベル情報を替えてデコーダに入力すると、スタイルを維持したまま任意の数字の画像を生成できる。

VAE や CVAE はもともと画像分野で考案されたモデルであるが、これらを自然言語に応用した例として、[Bowman 15] や [Hu 17] の研究がある。[Bowman 15] では、VAE における潜在空間上の 2 点の線形補間により、2 文の中間文を生成可能であることを示している。[Hu 17] は、CVAE をベースとしたモデルを用いて感情や時制を変換する方法を提案している。

### 2.2 注意機構

Seq2Seq [Sutskever 14] や系列 Encoder-Decoder [Cho 14] では、系列情報を RNN で固定長のベクトルに変換するため、長い系列であるほど変換が難しくなる。注意機構 [Bahdanau 14][Luong 15] は、出力時に入力情報を直接的に使用することで、この問題に対処する手法である。本稿では [Luong 15] の提案に従って、注意機構を導入する。

エンコーダの隠れ状態を  $(\mathbf{h}_1^{(a)}, \dots, \mathbf{h}_T^{(a)})$  とし、 $j$  ステップ目のデコーダの隠れ状態を  $\mathbf{h}_j^{(t)}$  としたとき、注意機構はそれぞ

れの隠れ状態に対してアライメントの重みを計算する。

$$a_i = \frac{\exp(\text{score}(\mathbf{h}_i^{(a)}, \mathbf{h}_j^{(t)}))}{\sum_{i=1}^I \exp(\text{score}(\mathbf{h}_i^{(a)}, \mathbf{h}_j^{(t)}))} \quad (3)$$

$\text{score}$  関数にはさまざまなものが存在するが、本稿では、 $\mathbf{h}_i^{(a)}$  と  $\mathbf{h}_j^{(t)}$  の内積をとる。

$$\text{score}(\mathbf{h}_i^{(a)}, \mathbf{h}_j^{(t)}) = \mathbf{h}_i^{(a)} \cdot \mathbf{h}_j^{(t)} \quad (4)$$

式 (3) で計算したアライメントの重みをもとに、次のようにして文脈ベクトル  $\bar{\mathbf{h}}$  が計算される。

$$\bar{\mathbf{h}} = \sum_{i=1}^I a_i \mathbf{h}_i^{(a)} \quad (5)$$

デコーダは  $j$  ステップ目の単語の予測において、次に定義される  $\hat{\mathbf{h}}_j^{(t)}$  を利用する。

$$\hat{\mathbf{h}}_j^{(t)} = \tanh(\text{Linear}([\bar{\mathbf{h}}, \mathbf{h}_j^{(t)}])) \quad (6)$$

### 3. 提案するキャラクタ性変換手法

我々は事前研究として、2.1 節で説明した CVAE をベースに、ラベル情報としてキャラクタの ID を与えることで、文の伝達内容とキャラクタ性を分離するモデルを構築し、チューニングを行った。しかし、文の内容が損なわれた変換が多く見られた。これは、2.2 節で述べたように、文全体を固定長のベクトル（潜在変数  $z$ ）に圧縮することによって、入力文の情報を保持することが難しいためと考えられる。そこで、本稿では CVAE に注意機構を組み合わせることにより文の内容保持の向上を目指す。

具体的には、我々は、キャラクタ性が機能語に多くあらわることを前提とし、内容語（本稿では、名詞、動詞、形容詞とする）は注意機構を用いて、VAE を介さずに直接出力に利用することを試みる。この方法により、文に含まれる情報の劣化を抑えて、目的のキャラクタの発話を得ることを意図する。

また、内容保持の向上とキャラクタ性の発現はトレードオフの関係にあると考えられる。本稿では、キャラクタ性を維持するための対策として、出力文がどのキャラクタによる発話であるかを分類する分類器を導入する。CVAE と分類器を併せて最適化することで、分類しやすい — すなわちキャラクタ性が強くあらわれた — 出力文が学習されると期待できる。

#### 3.1 モデルの構成

モデルの模式図を図 1 に示す。本モデルは次の 4 つのコンポーネントから構成される。以下に各コンポーネントの詳細を説明する。

#### Global encoder

発話文の単語列  $\mathbf{x} = (\mathbf{x}_1, \dots, \mathbf{x}_L)$  および、キャラクタラベル  $\mathbf{y}$  から潜在変数  $z$  を推論する。なお、 $(\mathbf{x}_1, \dots, \mathbf{x}_L)$  と  $\mathbf{y}$  はそれぞれ、単語 ID、キャラクタ ID に対応する one-hot ベクトルとする。

$$\mathbf{a}_l = \text{Embed}(\mathbf{x}_l) \quad (7)$$

$$\mathbf{b} = \text{Embed}(\mathbf{y}) \quad (8)$$

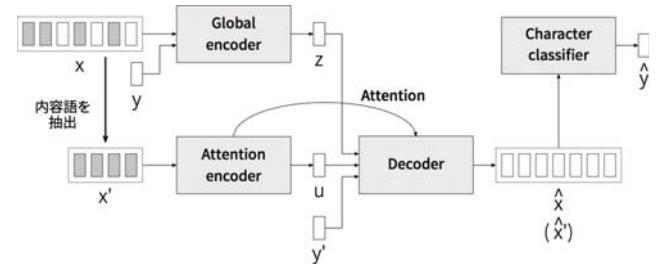


図 1: 提案モデルの模式図

$$\vec{\mathbf{h}}_l^{(s)} = \text{LSTM}(\vec{\mathbf{h}}_{l-1}^{(s)}, [\mathbf{a}_l, \mathbf{b}]) \quad (9)$$

$$\overleftarrow{\mathbf{h}}_l^{(s)} = \text{LSTM}(\overleftarrow{\mathbf{h}}_{l+1}^{(s)}, [\mathbf{a}_l, \mathbf{b}]) \quad (10)$$

$$\boldsymbol{\mu} = \text{Linear}([\vec{\mathbf{h}}_L^{(s)}, \overleftarrow{\mathbf{h}}_1^{(s)}]) \quad (11)$$

$$\boldsymbol{\sigma} = \text{Linear}([\vec{\mathbf{h}}_L^{(s)}, \overleftarrow{\mathbf{h}}_1^{(s)}]) \quad (12)$$

$$\mathbf{z} = \boldsymbol{\mu} + \boldsymbol{\sigma} \odot \boldsymbol{\epsilon}, \quad \boldsymbol{\epsilon} \sim \mathcal{N}(\mathbf{0}, \mathbf{I}) \quad (13)$$

ここで、Embed 関数は埋め込みベクトルへの変換を表し、Linear 関数はバイアス項を含む線形変換を表す。また、 $(\vec{\mathbf{h}}_1^{(s)}, \dots, \vec{\mathbf{h}}_L^{(s)})$  は順方向 LSTM の隠れ状態、 $(\overleftarrow{\mathbf{h}}_1^{(s)}, \dots, \overleftarrow{\mathbf{h}}_L^{(s)})$  は逆方向 LSTM の隠れ状態を表す。

#### Attention encoder

キャラクタの発話文に含まれる内容語  $(\mathbf{x}'_1, \dots, \mathbf{x}'_I)$  をエンコードする。なお、活用形のある単語は原形に変換して入力する。

$$\mathbf{c}_i = \text{Embed}(\mathbf{x}'_i) \quad (14)$$

$$\vec{\mathbf{h}}_i^{(a)} = \text{LSTM}(\vec{\mathbf{h}}_{i-1}^{(a)}, \mathbf{c}_i) \quad (15)$$

$$\overleftarrow{\mathbf{h}}_i^{(a)} = \text{LSTM}(\overleftarrow{\mathbf{h}}_{i+1}^{(a)}, \mathbf{c}_i) \quad (16)$$

$$\mathbf{h}_i^{(a)} = [\vec{\mathbf{h}}_i^{(a)}, \overleftarrow{\mathbf{h}}_i^{(a)}] \quad (17)$$

$$\mathbf{u} = \text{Linear}([\vec{\mathbf{h}}_I^{(a)}, \overleftarrow{\mathbf{h}}_1^{(a)}]) \quad (18)$$

#### Decoder

エンコード表現およびキャラクタのラベル  $\mathbf{y}'$  にもとづき文を出力する。

まずは、次式により LSTM の隠れ状態  $\hat{\mathbf{h}}_j^{(t)}$  を求める。

$$\mathbf{d}_j = \text{Embed}(\hat{\mathbf{x}}_{j-1}) \quad (19)$$

$$\mathbf{e} = \text{Embed}(\mathbf{y}') \quad (20)$$

$$\mathbf{h}_j^{(t)} = \text{LSTM}(\mathbf{h}_{j-1}^{(t)}, [\mathbf{d}_j, \mathbf{e}, \mathbf{z}, \mathbf{u}]) \quad (21)$$

ここで、 $\hat{\mathbf{x}}_{j-1}$  は Decoder が前ステップで出力した単語である。次に注意機構を利用して、 $\mathbf{h}_j^{(t)}$  と Attention encoder の隠れ状態  $(\mathbf{h}_1^{(a)}, \dots, \mathbf{h}_I^{(a)})$  から  $\hat{\mathbf{h}}_j^{(t)}$  を求めるが、式 (3)-(6) と同様であるため省略する。

最後に、 $\hat{\mathbf{h}}_j^{(t)}$  から単語を出力する。

$$\mathbf{o}_j = \text{Linear}(\hat{\mathbf{h}}_j^{(t)}) \quad (22)$$

$$\mathbf{p}_j = \text{Softmax}(\mathbf{o}_j) \quad (23)$$

上記の  $\mathbf{p}_j$  より、確率が最大となる単語を  $j$  ステップ目の出力  $\hat{\mathbf{x}}_j$  とする。

### Character classifier

Decoder によって出力された文がどのキャラクタによる発話であるかを分類する。

Character classifier への入力  $\hat{x}'_j$  は、次式により one-hot ベクトルである  $\hat{x}_j$  を近似する。

$$\begin{aligned}\hat{x}_j &\approx \text{Softmax}(\mathbf{o}_j/\tau) \\ &= \hat{x}'_j\end{aligned}\quad (24)$$

$\tau$  はハイパーパラメータである。 $\tau \rightarrow 0$  のとき、 $\hat{x}'_j$  は  $\hat{x}_j$  に収束する。この入力を用いて、キャラクタのラベルを予測する。

$$\mathbf{f}_j = \text{Embed}(\hat{x}'_j) \quad (25)$$

$$\overrightarrow{\mathbf{h}}_j^{(c)} = \text{LSTM}(\overrightarrow{\mathbf{h}}_{j-1}^{(c)}, \mathbf{f}_j) \quad (26)$$

$$\overleftarrow{\mathbf{h}}_j^{(c)} = \text{LSTM}(\overleftarrow{\mathbf{h}}_{j+1}^{(c)}, \mathbf{f}_j) \quad (27)$$

$$\hat{\mathbf{y}} = \text{Softmax}(\text{Linear}([\overrightarrow{\mathbf{h}}_J^{(c)}, \overleftarrow{\mathbf{h}}_1^{(c)}])) \quad (28)$$

### 3.2 重みパラメータの最適化

本モデルでは、VAE 損失の最適化とキャラクタ分類のクロスエントロピー損失の最適化の 2 つを行う。VAE 損失の最適化では、Global encoder, Attention encoder, Decoder の重みパラメータを更新する。キャラクタ分類のクロスエントロピー損失は、正解のキャラクタラベルデータと Character classifier が出力する確率分布のクロスエントロピーを指し、この最適化では、Decoder と Character classifier の重みパラメータを更新する。また、キャラクタ分類のクロスエントロピー損失の最適化は、VAE 損失の最適化を  $k$  回行うごとに 1 回行う。ここでは、 $k = 10$  とした。

### 3.3 キャラクタラベルとキャラクタ性変換

モデルの学習時は、通常のオートエンコーダと同様に、入力をそのまま復元するため、Global encoder と Decoder のキャラクタラベルの関係は  $\mathbf{y} = \mathbf{y}'$  である。

学習済みのモデルを使って、発話の変換を行う場合は次の通りである。まず、キャラクタ A の発話文  $\mathbf{x}_A$  とキャラクタラベル  $\mathbf{y}_A$  を Global encoder および Attention encoder に与え、 $\mathbf{z}, \mathbf{u}$  を得る。そして、Decoder に  $\mathbf{z}, \mathbf{u}$  と、キャラクタ B のラベル  $\mathbf{y}_B$  を与えることで、文の内容を保持したままキャラクタ B の発話文を生成する。

## 4. 評価実験

本稿では、提案モデルが発話のキャラクタ性変換にどの程度貢献するかを検証するために、CVAE 単体モデルとの比較による評価実験を行った。

### 4.1 モデルの学習

キャラクタの発話文データは、SNS や小説投稿サイト、対話システムのシナリオ<sup>\*1</sup> などから計 107 キャラクタ、225,116 件を収集した。このうち 204,800 件を学習事例集合、20,316 件を検証事例集合とした。

文の形態素解析には MeCab (IPA 辞書) を用いた。ミニバッチサイズは 64 とし、最適化手法は Adam ( $\alpha = 0.001$ ) を使用した。VAE 損失の最適化には KL コストアーリング [Bowman 15] の手法を用いた。また、Decoder には単語ドロップアウト (rate 0.2)[Bowman 15] を用いた。その他の設定については、表 1 の通りである。

\*1 筆者が所属する会社にて作成された既存の対話シナリオを使用

表 1: モデルの設定

	CVAE 単体	提案
単語埋め込みの次元	128	128
キャラクタ埋め込みの次元	64	64
$z$ の次元	240	128
$u$ の次元	-	128
LSTM レイヤー	2	2
LSTM セル	240	128

表 2: キャラクタ発話のサンプル (収集データ)

Takeshi	Samurai
最近人気の観光地やな	実際にかわいかったぞ
殺菌作用あるから、食いすぎに注意やで!	左様な時は自然に触れ、感めてもらうのだ
まず東京駅に行ったらえんちゃんやう?	ネットで検索することも可能だ
俺も、自分の言葉が全くわからん	拙者にも教えてくれ

表 3: アノテータによる評価の平均値

	Takeshi		Samurai	
	CVAE	提案	CVAE	提案
(1) 文法性	3.44	3.14	3.22	3.23
(2) キャラクタ性	2.50	2.45	2.47	2.34
(3) 内容保持	2.61	2.68	2.34	3.04

### 4.2 評価内容

本実験では、次の 2 種類のキャラクタ性変換を評価対象とした。

- Neutral → Samurai
- Neutral → Takeshi

Neutral は特定のキャラクタ像をイメージさせないものとした。Samurai は侍をモチーフにしたキャラクタである。Takeshi は関西弁を話す男性キャラクタである。Takeshi と Samurai の発話文のサンプル (収集データ) を表 2 に示す。

上記のキャラクタごとに、CVAE 単体モデルと提案モデルそれぞれ 50 文ずつを生成したものをランダムにシャッフルした上で、アノテータ 5 名に依頼し、各文を次の 3 つの観点で 4 段階評価してもらった。

- 文法性：文法や単語の用法に違和感がないか  
(4: 全く違和感はない ~ 1: 非常に違和感がある)
- キャラクタ性：文にキャラクタの特徴が現れているか  
(4: 現れている ~ 1: 現れていない)
- 内容保持：変換前の文の内容を保持できているか  
(4: ほぼ保持できている ~ 1: 全く保持できていない)

### 4.3 評価結果

評価の結果を表 3 に示す。また、表 4 に提案モデルによる発話文の変換結果を示す。

表 4: 提案モデルによる変換結果と評価の平均値（下線は変換により置き換わった単語を表す。右 3 列は評価の観点に対応する。）

Neutral	Takeshi	(1)	(2)	(3)
沢山いて選べないです	→ いっぱいいいて選べないよね	4.0	2.8	3.4
それは出来ません	→ それは出来ないし	3.8	2.4	3.8
そう思ってくれるのであればいいですけど	→ そう思ってくれるのやけど、いいし…	2.8	3.4	2.0
あまり景気はよくないと思います	→ どう景気は…よからうと思う	2.2	2.0	1.4
Neutral	Samurai	(1)	(2)	(3)
冷えた足先には欠かせません	→ 冷えた足先には欠かせないぞ	4.0	4.0	4.0
それはよい考えです	→ それはよき考え方だ	3.8	3.8	4.0
むしろ大変だと思います	→ まあ大変だと思うな	3.6	2.6	2.8
不作のおそれがあります	→ ガムが、何があるわ	2.4	1.6	1.0

内容保持に関しては、提案モデルの評価点が CVAE を上回った。一部の事例を除き、Neutral に存在する内容語がそのまま出力文に使用されていたことからも、注意機構の導入による一定の効果が示唆される。

一方で、文法性とキャラクタ性に関しては、CVAE と比較して良好な結果は得られなかった。生成された文を観察すると、機能語の用法が不適切であるために、評価が低く付けられているものが見られた。これは、注意機構が内容語に対して有効に働く反面、機能語に対しては悪影響を与えてしまったのではないかと推測する。したがって、Attention encoder の構造や活用方法に改良の余地があると考える。

## 5. おわりに

本稿では、CVAE と注意機構によるキャラクタ性の変換手法を提案した。注意機構を導入することで、CVAE において、文に存在する一部の単語を制御しつつ、文の変換が行える可能性があることを示した。今後、対話シナリオ作成の補助として実用性を高めるには、まずは非文が出力される割合を減らすことが求められる。

提案モデルによる変換の多くは、文末表現に集中していました。本来であれば、特定の内容語に関しても柔軟に変換を行える方が、キャラクタ性はより強調できると考える。したがって、これを実現する方法についても検討する必要がある。

また、本稿の実験では Neutral からの変換のみを取り扱ったが、Takeshi → Samurai のように、特徴が強く反映されたキャラクタ同士の変換や、Takeshi → Neutral のような、キャラクタ性を除去する変換についても検証していきたい。

## 参考文献

- [Bahdanau 14] Bahdanau, D., Cho, K. and Bengio, Y.: Neural machine translation by jointly learning to align and translate, In Proceedings of ICLR (2014)
- [Bowman 15] Bowman, S. R., Vilnis, L., Vinyals, O., Dai, A. M., Jozefowicz, R. and Bengio S.: Generating Sentences from a Continuous Space, Proceedings of CoNLL (2016)
- [Cho 14] Cho, K., Merrienboer, B. V., Gulcehre, C., Bougares, F., Schwenk, H and Bengio, Y.: Learning Phrase Representations using RNN Encoder-Decoder

for Statistical Machine Translation, In Proceedings of Conference on Empirical Methods in Natural Language Processing, pp.1724-1734 (2014)

[Hu 17] Hu, Z., Yang, Z., Liang, X., Salakhutdinov, R., Xing, E. P.: Toward Controlled Generation of Text, International Conference on Machine Learning, pp.1587-1596 (2017)

[Kingma 14a] Kingma, D. P. and Welling, M.: Auto-Encoding Variational Bayes, In Proceedings of the 2nd International Conference on Learning Representations (2014)

[Kingma 14b] Kingma, D. P., Mohamed, S., Rezende, D. J. and Welling, M.: Semi-supervised Learning with Deep Generative Models, Advances in Neural Information Processing Systems, pp.3581-3589 (2014)

[Luong 15] Luong, M., Pham, H. and Manning, C. D.: Effective approaches to attention-based neural machine translation, In Proceedings of Conference on Empirical Methods in Natural Language Processing, pp.1412-1421 (2015)

[Sutskever 14] Sutskever, I., Vinyals, O. and Le, Q. V.: Sequence to sequence learning with neural networks, Advances in Neural Information Processing Systems, pp. 3104-3112 (2014)

[Walker 12] Walker, M.A., Lin, G.I. and Sawyer, J.E.: An Annotated Corpus of Film Dialogue for Learning and Characterizing Character Style, In Proceedings of the Eight International Conference on Language Resources and Evaluation, pp. 1373-1378 (2012)

[刀山 17] 刀山 将大, 夏目 和子, 佐藤 理史, 松崎 拓也: 話者の特徴を反映した発話文生成器の作成, 言語処理学会 第 23 回年次大会 発表論文集, pp. 28-31 (2017)

[沈 12] 沈 睿, 菊池 英明, 太田 克己, 三田村 健: 音声生成を前提としたテキストレベルでのキャラクタ付与, 情報処理学会論文誌, Vol. 53, No. 4, pp. 1269-1276 (2012)

[宮崎 16] 宮崎 千明, 平野 徹, 東中 竜一郎, 牧野 俊朗, 松尾 義博, 佐藤 理史: 文節機能部の確率的書き換えによる言語表現のキャラクタ性変換, 人工知能学会論文誌, vol. 31, No. 1, pp. 1-9 (2016)