

# サンプリング戦略に基づく単語ベクトルの意味成分とスタイル成分の分離

赤間 怜奈<sup>†1</sup> 横井 祥<sup>†‡2</sup> 渡邊 研斗<sup>†‡3</sup> 小林 颯介<sup>\*4</sup> 田然<sup>†5</sup> 乾 健太郎<sup>†‡6</sup>

<sup>†</sup> 東北大学 <sup>‡</sup> 理化学研究所 AIP センター <sup>\*</sup> 株式会社 Preferred Networks

{<sup>1</sup>reina.a, <sup>2</sup> yokoi, <sup>3</sup> kento.w, <sup>5</sup> tianran, <sup>6</sup> inui}@ecei.tohoku.ac.jp, <sup>4</sup> sosk@preferred.jp

## 1 はじめに

近年、対話の応答文生成などの文生成タスクでは、生成する文の**意味 (何を伝えるか)**だけでなく、話者の性別や年齢 [1]、敬意 [2,3]、感情 [4]、性格 [5,6] など、文の**スタイル (どう表現するか)**を制御する研究が増えている。しかし、これらの既存研究は敬意表現などスタイルの一側面を限定的にモデル化しており、スタイルとして考えられる多種多様な特徴をトップダウンに網羅できていない。仮に、スタイルとして考えられる種々の特徴を網羅した語の分散表現を教師なし学習でできれば、スタイルに関する様々な言語学的仮説の検証という学術的貢献や、多種多様なスタイルを自在に制御できる対話システムの実現といった実用的貢献が期待できる。このような動機から、本研究では、多種多様なスタイルを捉えた単語ベクトル空間の教師なし学習を試みる。我々が期待するスタイルの単語ベクトル空間とは、「意味」は近くとも「スタイル」が大きく異なる「俺」と「私」は遠くに配置され、「意味」は異なっているとしても「スタイル」が似ている「俺」と「だぜ」が近くに配置されるような空間である (図1, 右下)。

本研究では、「スタイル」の類似性を捉えるベクトル空間を構築するに当たり、「同一発話内に含まれる単語は同一のスタイルを持つ」という仮定を置く\*1。この仮定の上で、スタイルが似た単語同士は、共通の単語をそれぞれの同一発話内で見つけている可能性が高い。たとえば「俺」と「だぜ」は似たスタイルを持つと考えられるが、これらの語はそれぞれが「お袋」という共通の単語と発話内で出会っていると考えられる。以上の考察から、同一発話内の単語を予測できるようなベクトルを構成することで、スタイルの類似性を捉えた単語ベクトル空間を作ることを試みる (図2の青色, 3.2 節)。

一方で、いわゆる「意味」を捉えるための単語ベクトルの学習では、同一発話内のすべての単語を予測する能力ではなく、ごく近傍の単語を予測する能力を重視する (図2の赤色, 3.1 節)。そのため、図2から分かるように、「近傍の単語を予測する能力」を持つベクトルは、意味性とスタイル性の両方が混ざった状態になっていることが懸念される。

そこで本研究では、図2の色の濃さの比率に応じて、周辺単語を予測するベクトルの「意味」部分と「スタイル」部分を使い分ける工夫を施した。作成した単語ベクトルは、意味を表す次元とスタイルを表す次元に分かれており、それぞれの情報を独立に利用できる。さらに提案手法は、スタイルを捉えるための既存研究 [1,6] のように同一の文体で統一された教師データを必要せず、生コーパスを使った学習が可能である。

\*1既存研究 [1,2,7] でも、「発話内でスタイルは一貫している」ことを暗黙的に仮定している。

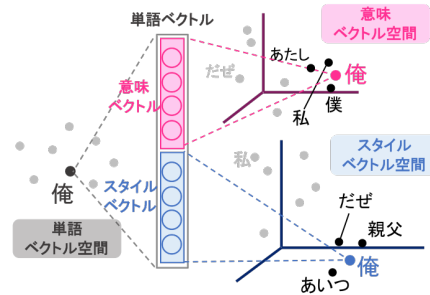


図1 意味とスタイルの類似性を捉えた単語ベクトル空間。




図2 ターゲット単語に対する文脈単語の予測範囲とその性質。ターゲット単語の周辺にある文脈単語の予測を重要視することで「意味」を捉えた単語ベクトルが学習される (赤色)。発話内の全文脈単語を均等に予測するように単語ベクトルを学習することで「スタイル」の類似性を捉えられると考えられる (青色)。

## 2 表記・実験設定

### 本研究で使う記号の定義

発話内の単語の並びにしたがって単語に添え字を付ける。たとえば  $w_i$  は発話内の  $i$  番目の単語を表す。とくに、注目しているターゲット単語を  $w_t$  で表す。すなわち  $w_{t+1}$  はターゲット単語の次の単語を表す。

### データセット

「発話内のスタイルの一貫性」を手がかりにスタイルベクトルを構築したいので、扱うコーパスは発話単位 (たとえばかぎ括弧) が多く出てくるものが望ましい。我々は学習用コーパスとして、ショートストーリー (SS) のデータを用いた。SS は Web 上に投稿された漫画やアニメなどの二次創作の物語であり、それぞれの作品はかぎ括弧で囲まれた登場人物の発話が連なっている。ここから、かぎ括弧で囲まれた文をそれぞれ 1 発話として抽出し、約 30M 発話を用意した。なお、この内 1,000 発話を評価用のデータとして無作為に除外した。集められた発話に対し、品詞情報の付与などの一般的な前処理をおこなった上で、スタイルを学習しやすくするために「わ + よ + ね」のような文末表現の連結 [1] を施した。学習には、コーパス内での出現頻度が 5 以上の単語を用い、結果として語彙数は約 10 万となった。

### 3 予備実験：アプローチの妥当性の検証

予備実験として、「近傍文脈」に基づく意味ベクトルの学習と、「発話内スタイル一貫性」に基づくスタイルベクトルの学習を素朴に行い、図2に示した直観の妥当性を確認する。

#### 3.1 近傍文脈に基づく意味ベクトルの学習

本研究では、分布仮説 [8,9] に基づき「意味」を捉えた単語ベクトルの構築手法として Mikolov らの Skip-gram モデル [10] を用いる。Skip-gram モデルは、ターゲット単語  $w_t$  に対する文脈単語たち  $C_{w_t} = \{w_{t\pm d} \mid 0 < d \leq \delta\}$  ( $d$  は  $w_t$  との距離、 $\delta$  は文脈の窓幅) の予測可能性を手掛かりに、意味情報や統語情報を分散表現として学習している。具体的には、以下の予測確率を最大化することで単語ベクトルを学習する。

$$P(c|w_t) = \frac{\exp(\mathbf{v}_{w_t}^\top \tilde{\mathbf{v}}_c)}{\sum_{w' \in V} \exp(\mathbf{v}_{w'}^\top \tilde{\mathbf{v}}_c)} \quad (1)$$

ここで、 $c$  は各文脈単語  $c \in C_{w_t}$  を表し、 $\mathbf{v}_{w_t}$  は単語  $w_t$  のベクトル、 $\tilde{\mathbf{v}}_c$  は単語  $c$  を予測するベクトルである。  $V$  は語彙の単語集合を表す。学習高速化のため、Mikolov らと同様に負例サンプリングにより近似を行った\*2。

Mikolov らの実装では、学習時に  $0 < \delta \leq \Delta$  ( $\Delta$  は最大窓幅) の範囲で  $\delta$  を一様分布に従ってサンプリングし、 $w_t$  との距離  $d$  が小さい文脈語  $c$  ほど高頻度で学習される。たとえば  $\Delta = 5$  の場合、 $w_{t\pm 1}$  は必ず学習されるが、 $w_{t\pm 5}$  は 0.2 の確率で学習される。このように、一般的な設定の Skip-gram モデルにより学習される単語ベクトルは、ターゲット単語により近い文脈単語の予測を特に重視している (図2の赤色)。

最初の予備実験として、 $\delta$  のサンプリングを用いた単語ベクトルの学習、すなわち「近い文脈単語を重視する」学習によって、「意味」を捉えやすくなるかを検証する。単語ベクトルが意味の類似性を捉えているか定量評価するために、日本語単語類似語データセット [11,12] を用いた意味的類似度 (word similarity) タスクで実験を行った。このデータセットは、名詞、動詞、形容詞、副詞それぞれについての単語ペアの集合からなり、各単語ペアに対して作業者が類似度を付与してある。その人手による類似度と、単語ベクトルを用いて計算した類似度を比較し、順位相関係数を計算する。本研究ではスピアマンの順位相関係数  $\rho$  を用いる。  $\rho$  は  $-1$  から  $1$  の値をとり、 $1$  に近いほど相関が強く、すなわちモデルが意味の関連性をよく捉えていることを示唆する。本研究では各品詞のセットについての  $\rho$  のマクロ平均を評価値として用いた。

表1の上2列に、 $\delta$  を一様サンプリングした学習の単語ベクトル (表1, # 1) と、 $\delta$  を5に固定した単語ベクトル (表1, # 2) の順位相関係数  $\rho$  を示した。この表より、 $\delta$  をサンプリングしたモデルの順位相関係数  $\rho$  が大きいことがわかる。これは、ターゲット単語の近傍の文脈単語を重視して予測することが、「意味」を捉えた単語ベクトルを学習する上で重要であることを示唆している。

\*2ターゲット単語  $w_t$  と文脈単語  $c$  のペアに対して負例を5単語サンプリングする。サンプリングにはユニグラム確率を0.75乗した分布を用いる。ベクトルの次元数は300とする。以降、全ての単語ベクトルの学習に、これらのパラメータを用いる。

表1 予備実験の結果

	パラメータ		評価尺度	
	文脈 $C_{w_t}$	$\delta$ のサンプリング	$\rho$	発話内の単語ペアの類似度平均
# 1	$\{w_{t\pm d} \mid 0 < d \leq 5\}$	有	0.419	0.190
# 2	$\{w_{t\pm d} \mid 0 < d \leq 5\}$	無	0.399	0.201
# 3	$\{w_{t\pm d} \mid 0 < d \leq \max\}$	無	0.352	0.274
# 4	$\{w_{t\pm d} \mid 10 < d \leq \max\}$	無	0.205	0.409

#### 3.2 発話内の一貫性に基づくスタイルベクトルの学習

次に、「発話内のスタイルの一貫性」を手がかりに、スタイルの類似性を捉えた単語ベクトルを構築し、その性質を検証する。具体的には、Skip-gram の枠組みにおいて、窓幅  $\delta$  を発話の先頭・末尾まで広げ、発話内の (ターゲット単語を除く) 全単語  $\{w_{t\pm d} \mid 0 < d \leq \max\}$  を文脈  $C_{w_t}$  として、これらを均等に予測するように単語ベクトル  $\mathbf{v}_{w_t}$  を学習する (図2の水色)。この処理により、発話内の単語たちが位置によらず似た予測学習を行うことになり、結果としてベクトル空間上で近くに配置されることを期待している。

ここで、前節での検証から、ターゲット単語の近傍単語を文脈  $c$  として学習を行うと「意味」の類似性が学習されやすくなることが予想される。そこで、意味の類似性を捉えずにスタイルだけを考慮したベクトルを学習する素朴な工夫として、近傍の単語を取り除いた  $\{w_{t\pm d} \mid 10 < d \leq \max\}$  を文脈  $C_{w_t}$  とした手法も用意する。

本節の予備実験では、 $\delta$  の値を広げた発話内で均等な予測学習を行うことで、発話内単語のスタイルの類似性を捉えやすくなるかを検証する。また、前節で検証された、近い文脈単語での学習では意味を捉えやすくなる、という結果を考慮し、逆に、近い文脈単語を除くことによるスタイル情報の学習への影響も観察する。そこで、この実験では、テストデータ中の各発話内の全単語ペアのコサイン類似度の平均を計算することで、各学習方法における単語ベクトルがスタイルの類似性をより良く捉えているか定量的に計測する。

表1の下2列に、文脈  $C_{w_t}$  を  $\{w_{t\pm d} \mid 0 < d \leq \max\}$  にした時と、 $\{w_{t\pm d} \mid 10 < d \leq \max\}$  にした時に学習された単語ベクトルの評価結果を示した。まず、周辺単語  $\{w_{t\pm d} \mid 0 < d \leq 5\}$  を文脈単語  $C_{w_t}$  にして学習したベクトル (表1, # 2) と比較すると、文脈単語を発話の先頭、末尾まで広げる (表1, # 3) ことで、平均類似度が大きくなっていることがわかる。更に、 $\{w_{t\pm d} \mid 10 < d \leq \max\}$  を文脈単語  $C_{w_t}$  にして単語ベクトル (表1, # 4) を学習すると、平均類似度はより大きくなった。これらの結果は、意味的類似性に深く関わる学習要素である近傍の周辺単語を除外し、発話全体の文脈単語を予測するように単語ベクトルを学習することで、意味情報の代わりにスタイル情報を重視して学習できる可能性を示唆している。

実際に、発話内の単語  $\{w_{t\pm d} \mid 0 < d \leq \max\}$  を文脈とした時は、単語「俺」のベクトル空間における類似単語として「だぜ」のようなスタイルが類似した単語が上位になる傾向が見られたが、同時に「私」のような意味としても類似した単語も上位類似単語となる傾向が見られた。一方で、 $\{w_{t\pm d} \mid 10 < d \leq \max\}$  を文脈とした学習結果についても類似単語を確認すると、意味的に類似した単語は減少し、スタイル的に類似した単語がより

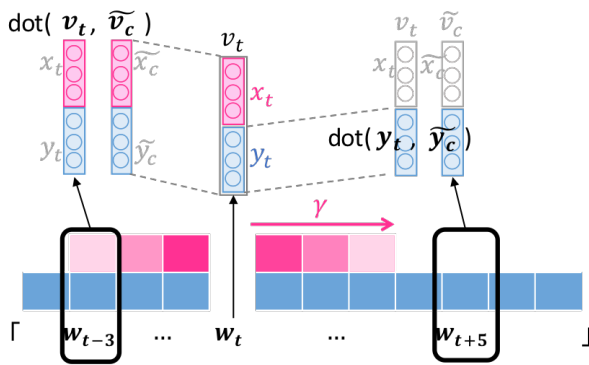


図3 提案する単語ベクトルの概念図

多く観察できた。

#### 4 提案手法

予備実験より、(1)「意味」の類似性を捉えるには特に近傍に位置する単語を重要視した周辺単語の予測が有効であり、(2)「スタイル」の類似性を捉えるには発話内の(ターゲット単語を除く)全単語を均一に予測することが有効であるという、図2の直観が妥当であることを確かめた。予備実験では意味の類似性を除外してスタイルの類似性のみを学習するために、周辺単語を文脈単語から除外するという素朴な手法を用いた。しかし、「発話内のスタイルは一貫している」と本研究では仮定しているため、周辺単語もスタイルの類似性を捉えるための情報になりうるはずである。とは言い、単純に近傍の単語も文脈語に追加するだけでは、分離したいはずの意味情報までもが混じって学習されてしまう。そこで本研究では Skip-gram を拡張し、ターゲット単語  $w_t$  から文脈単語  $c$  までの距離  $d$  によって学習する単語ベクトルの位置を変えることで、意味とスタイルの類似性を上手に分離しながら同時に学習する。

図3に提案手法の概略を示した。提案手法では、意味とスタイルの情報を独立に表現するために、単語ベクトル  $v_{w_t}$  を、意味を表す次元成分  $x_{w_t}$  とスタイルを表す次元成分  $y_{w_t}$  に切り離す(文脈単語  $c$  のベクトル  $\tilde{v}_c$  も同様に  $\tilde{x}_c$  と  $\tilde{y}_c$  に切り離す)。

$$v_{w_t} = x_{w_t} \oplus y_{w_t} \quad (2)$$

$$\tilde{v}_c = \tilde{x}_c \oplus \tilde{y}_c \quad (3)$$

ここで、 $\oplus$  はベクトルの連結を表す。本研究では、 $x_{w_t}$  と  $y_{w_t}$  の次元数をそれぞれ 50 次元と 250 次元にした。

ターゲット単語の周辺単語を文脈とした時は、意味ベクトル  $x_{w_t}$  とスタイルベクトル  $y_{w_t}$  の両方を学習し、ターゲットから一定以上の距離にある単語を文脈としたときはスタイルベクトル  $y_{w_t}$  だけを学習すればよい。つまり、提案手法における予測確率  $P(c|w_t)$  は整数のハイパーパラメータ  $\gamma$  を定義することで以下のように定式化できる。

$$P(c|w_t) = \begin{cases} \frac{\exp(\mathbf{v}_{w_t} \top \tilde{\mathbf{v}}_c)}{\sum_{w' \in V} \exp(\mathbf{v}_{w'} \top \tilde{\mathbf{v}}_c)} & (d \leq \gamma) \\ \frac{\exp(\mathbf{y}_{w_t} \top \tilde{\mathbf{y}}_c)}{\sum_{w' \in V} \exp(\mathbf{y}_{w'} \top \tilde{\mathbf{y}}_c)} & (\gamma < d) \end{cases} \quad (4)$$

なお、予測確率の計算コスト上の問題から3.1節と同様に、負例サンプリングによる近似を行った。

また、3.1節の予備実験の結果より、意味ベクトルを学習する上で、ターゲット単語の近傍の文脈単語を重視して予測するこ

とが重要であることが示唆されている(図2の赤色)。そこで本研究では、意味情報をスタイル成分  $y_{w_t}$  から上手く分離するために、ハイパーパラメータ  $\gamma$  を固定せず一様分布に従い  $[1:5]$  の範囲で  $\gamma$  をサンプリングすることで、 $w_t$  との距離に近い文脈単語ほど ( $v_{w_t}$  の学習に使われるようにする。この工夫により、意味ベクトル成分  $x_{w_t}$  は近傍の文脈単語を重視して学習することになる。

#### 5 意味とスタイルベクトルの定性的分析

本研究では、学習された意味ベクトル  $x_{w_t}$  とスタイルベクトル  $y_{w_t}$  がそれぞれ意味の類似性とスタイルの類似性を捉えているかを定性的に分析<sup>\*3</sup>する。具体的には、5つの単語“俺”、“ぜ”、“くださる”、“ほな”、“サンタ”を分析対象に、ベクトル空間におけるコサイン類似度が大きい単語を見ることで、空間内で近くに位置する単語を観察する。

表2に3.1節で学習した2種類の意味ベクトルと、提案手法により得られた意味ベクトル  $x_{w_t}$  の3種類のベクトル空間上における分析対象の単語とのコサイン類似度が大きい上位8件の単語を示す。この表より、予備実験で得られた意味ベクトルは、意味とスタイルの類似性を同時に捉えているのに対し、提案手法で得られた意味ベクトル  $x_{w_t}$  では、期待通りスタイルの類似性が薄れている。たとえば、 $x_{w_t}$  では“俺”と似た単語から“オメー”のような粗雑なスタイルの単語が類似しなくなった。

次に、表3に3.2節で学習した2種類のスタイルベクトルと提案手法により得られたスタイルベクトル  $y_{w_t}$  の3種類のベクトル空間上における分析対象の単語とのコサイン類似度が大きい上位8件の単語を示す。この表と表2を比較する。例えば、分析対象の単語“俺”について着目すると、意味ベクトル  $x_{w_t}$  の空間では一人称を表す“僕”や“あたし”など意味的に似た語との類似度が高いが、スタイルベクトル  $y_{w_t}$  の空間では“あいつ”や“テメエ”など粗野な印象を受ける単語との類似度が高いことが確認できる。

以上より、提案手法により意味ベクトル  $x_{w_t}$  からはスタイルの類似性が薄れ、スタイルベクトル  $y_{w_t}$  からは意味の類似性が薄れたことが定性的に観察できた。しかし、提案手法でえられたスタイルベクトル空間  $y_{w_t}$  において、“サンタ”のようなスタイルとは関係なさそうな単語と類似した単語を列挙したところ、“トナカイ”や“プレゼント”のように「トピック」が似た単語の類似度が高くなる様子が見られた。本研究で「スタイルは発話内で一貫している」と仮定してスタイルベクトルを学習したが、「発話内で一貫している」のはトピックも同様であるため、トピックもスタイル情報として学習されたと考えられる。これは「発話内の一貫性」に基づくモデリングでは当然起こりうる結果であり、文書情報(文書全体でトピックは一貫しているが、スタイルの一貫性はない)などを利用することで解決できる可能性がある。

#### 6 おわりに

本研究では、「分布仮説」と「発話内のスタイルの一貫性」に基づき、単語の意味成分とスタイル成分を捉えたベクトル空間

<sup>\*3</sup>なお、予備実験で採用した二種類の評価尺度(語の意味的類似度タスクの性能、および、発話内の単語ペアの類似度の平均)については省略する。

表2 意味ベクトル空間における分析対象の単語とコサイン類似度が大きい上位8単語

手法	単語				
	俺/名詞	ぜ/文末	くださる/動詞	ほんな/接続詞	サンタ/名詞
予備実験#1: $C \in \{w_{\pm d}   0 < d \leq 5\}$ δのサンプリング有	おまえ/名詞 僕/名詞 おいら/名詞 あたし/名詞 あたい/名詞 オメー/名詞 私/名詞 オメエ/名詞	ぞ/文末 かな/文末 たぜ/文末 けどな/文末 だぜ/文末 がな/文末 よな/文末 ぜ/助詞	下さる/動詞 まし/文末 なさる/動詞 頂戴/名詞 ちようだい/名詞 くだす/動詞 くだ/名詞 ませ/文末	ほんなら/接続詞 ええ/形容詞 ほんま/名詞 へん/助動詞 ホンマ/名詞 や/助動詞 やろ/助動詞 ホンマに/副詞	サンタクロス/名詞 トナカイ/名詞 プレゼント/名詞 クリスマス/名詞 クロース/名詞 メリークリスマス/名詞 サンタコス/名詞 クリスマスカード/名詞
予備実験#2: $C \in \{w_{\pm d}   0 < d \leq 5\}$ δのサンプリング無	おまえ/名詞 おいら/名詞 僕/名詞 あたし/名詞 あたい/名詞 私/名詞 オメエ/名詞 オメー/名詞	ぞ/文末 かな/文末 けどな/文末 たぜ/文末 がな/文末 ベ/名詞 わ/文末 よな/文末	下さる/名詞 まし/文末 頂戴/名詞 ちようだい/名詞 なさる/名詞 クダサイ/名詞 くだ/名詞 くだく/動詞	ほんなら/接続詞 ほんじゃ/接続詞 ええ/形容詞 ほんで/接続詞 ほんま/名詞 ホンマ/名詞 や/助動詞 よろしゅう/形容詞	サンタクロス/名詞 トナカイ/名詞 明石家/名詞 プレゼント/名詞 クリスマス/名詞 メリークリスマス/名詞 コウノトリ/名詞 クロース/名詞
提案手法: $\alpha w_t$ 意味ベクトル	きみ/名詞 おまえ/名詞 おいら/名詞 僕/名詞 あたし/名詞 おら/名詞 父さん/名詞 彼女/名詞	ぞ/文末 たぜ/文末 けどな/文末 の/文末 わ/文末 わよ/文末 からさ/文末 けどね/文末	下さる/動詞 ほしい/形容詞 欲しい/形容詞 形式/名詞 法/名詞 くれる/動詞 調査/名詞 ね/文末	引き続き/副詞 とりあえず/副詞 各自/名詞 ひとまず/副詞 よしつ/感動詞 さてと/感動詞 取り敢えず/副詞 次第/名詞	パン/名詞 会長/名詞 クリスマス/名詞 各自/名詞 プロデューサー/名詞 うどん/名詞 幽霊/名詞 グッズ/名詞 部長/名詞

表3 スタイルベクトル空間における分析対象の単語とコサイン類似度が大きい上位8単語

手法	単語				
	俺/名詞	ぜ/文末	くださる/動詞	ほんな/接続詞	サンタ/名詞
予備実験#3: $C \in \{w_{\pm d}   0 < d\}$	おまえ/名詞 ぜ/助詞 ねえ/助動詞 オメー/名詞 ねえ/助動詞 ぜ/文末 ちまう/動詞 ねえよ/文末	だぜ/文末 たぜ/文末 ぜ/助詞 ぞ/文末 かな/文末 じゃねえか/文末 けどな/文末 ないぜ/文末	下さる/動詞 まし/文末 なさる/動詞 ますから/文末 くだす/動詞 ちようだい/名詞 頂戴/名詞 くだ/名詞	ほんなら/接続詞 ええ/形容詞 ホンマ/名詞 やろ/助動詞 ほんま/名詞 へん/助動詞 や/助動詞 やな/文末	サンタクロス/名詞 トナカイ/名詞 プレゼント/名詞 クリスマス/名詞 ソリ/名詞 クロース/名詞 クリスマスカード/名詞 メリークリスマス/名詞
予備実験#4: $C \in \{w_{\pm d}   10 < d\}$	おまえ/名詞 オフクロ/名詞 でねえよ/文末 やねえよ/名詞 ねえからよ/文末 ちまう/動詞 あいつ/名詞 ビービー/名詞	だぜ/文末 ぜ/助詞 ちまう/動詞 ねえぜ/文末 ねえ/助動詞 たぜ/文末 ねえ/助動詞 ねえからよ/文末	下さる/動詞 ます/助動詞 です/助動詞 ます/文末 ますから/文末 ましたら/文末 まし/助動詞 カンパーイ/名詞	ええ/形容詞 や/助動詞 おおきに/副詞 さかい/文末 しゃあない/形容詞 や/文末 たるか/文末 オモロ/名詞	プレゼント/名詞 ナイトキャップ/名詞 メルシー/名詞 サンタクロス/名詞 クリスマス/名詞 プリッツェン/名詞 トナカイ/名詞 トナ/名詞
提案手法: $y_w$ スタイルベクトル	おまえ/名詞 あいつ/名詞 オメー/名詞 そいつ/名詞 親父/名詞 テメエ/名詞 アイツ/名詞 ねえ/助動詞	だぜ/文末 たぜ/文末 ぜ/助詞 じゃねえか/文末 ぞ/文末 じゃねえか/文末 ちまう/動詞 かな/文末	下さる/動詞 ので/助詞 です/助動詞 どうぞ/副詞 まし/助動詞 ませ/助動詞 くだす/動詞	ほんなら/接続詞 ええ/形容詞 しゃあない/形容詞 ほんじゃ/接続詞 ほんなら/接続詞 へん/助動詞 ほんま/名詞 さかい/助詞	サンタクロス/名詞 トナカイ/名詞 プレゼント/名詞 クリスマス/名詞 枕元/名詞 プリッツェン/名詞 妄想/名詞 イヴ/名詞

を、大規模発話コーパスを用いた教師なし学習により獲得することを試みた。具体的には、Skip-gram モデルを拡張し、単語の意味の類似性を捉えた次元と、スタイルの類似性を捉えた次元に分けることで、二つの情報を独立に表現した。また、学習時に使用する文脈単語のサンプリングを調整することで、意味とスタイルの違いを学習する仕組みを提案した。定性分析の結果、得られた意味ベクトルは“俺”と“僕”などの意味が類似した単語群が近づく空間となり、反対にスタイルベクトルでは“俺”と“だぜ”のようなスタイルが類似した単語群が近づく空間となっていることが観察できた。ただし、得られたスタイルベクトル空間では“サンタ”と“クリスマス”のような同じトピックの単語群も近づく空間であるということも、確認できた。

今後は、単語ベクトルの定量評価や、トピックも考慮できるように提案ベクトル表現を拡張したい。更には、それらのベクトル表現を対話システムに組み込む予定である。

**謝辞** 本研究の一部は、豊田中央研究所および文部科学省科研費 15H01702 の支援を受けた。

## 参考文献

- [1] Chiaki Miyazaki, Toru Hirano, Ryuichiro Higashinaka, Toshiro Makino, and Yoshihiro Matsuo. Automatic conversion of sentence-end expressions for utterance characterization of dialogue systems. In *PACLIC2015*, pages 307–314, 2015.
- [2] Rico Sennrich, Barry Haddow, and Alexandra Birch. Controlling politeness in neural machine translation via side constraints. In *NAACL-HLT2016*, pages 35–40, 2016.
- [3] Xing Niu, Marianna Martindale, and Marine Carpuat. A study of style in machine translation: Controlling the formality of machine translation output. In *EMNLP2017*, pages 2804–2809, 2017.
- [4] Zhitong Hu, Zichao Yang, Xiaodan Liang, Ruslan Salakhutdinov, and Eric P. Xing. Toward controlled generation of text. In *ICML2017*, pages 1587–1596, 2017.
- [5] Francois Mairesse and Marilyn Walker. Personage: Personality generation for dialogue. In *ACL2007*, pages 496–503, 2007.
- [6] Marilyn A Walker, Grace I Lin, and Jennifer Sawyer. An annotated corpus of film dialogue for learning and characterizing character style. In *LREC2012*, pages 1373–1378, 2012.
- [7] Di Wang, Nebojsa Jojic, Chris Brockett, and Eric Nyberg. Steering output style and topic in neural response generation. In *EMNLP2017*, pages 2130–2140, 2017.
- [8] Zellig S Harris. Distributional structure. *Word*, 10(2–3):146–162, 1954.
- [9] John Rupert Firth. *Papers in Linguistics 1934–1951*. Oxford University Press, 1957.
- [10] Tomas Mikolov, Ilya Sutskever, Kai Chen, Greg Corrado, and Jeffrey Dean. Distributed representations of words and phrases and their compositionality. In *NIPS2013*, pages 3111–3119, 2013.
- [11] 塚澤勇也 and 小町守. 日本語動詞・形容詞類似度データセットの構築. In 言語処理学会第 22 回年次大会, pages 258–261, 2016.
- [12] Yuya Sakaizawa and Mamoru Komachi. Construction of a Japanese word similarity dataset. *arXiv preprint arXiv:1703.05916*, 2017.