

話題と言葉遣いの違いを考慮した潜在トピックモデル

渡邊 研斗[†] 赤間 怜奈[†] 横井 祥^{†,◇} 田 然[†] 乾 健太郎^{†,◇}
 東北大学[†] 理研 AIP[◇]

{kento.w, reina.a, yokoi, tianran, inui}@ecei.tohoku.ac.jp,

1 はじめに

話しことばにおいて、**話題**と**言葉遣い**は会話を円滑に進めるための重要な因子である。例えば、図1の会話の例では、「レポート提出」の話題について登場人物全員が言及している一方で、“わたし”、“～わ”、“です”などの言葉遣いを統一することで登場人物の性格を表現している。仮に、会話における話題と言葉遣いの違いを捉えた確率モデルができれば、応答文の話題や言葉遣いを制御できる対話システムへ応用できる。

このような動機から、会話の話題や言葉遣いをモデル化する研究が行われてきた。例えば、会話の話題や発話行為を潜在状態として表現した生成モデルが提案されている [1,2]。また、言葉遣いを捉えるために、登場人物の埋め込みベクトルを用いた言語モデルが提案されている [3]。しかし、これらの研究は、片方の因子に限定したモデル化に留まっており、話題と言葉遣いの違いを捉えた確率モデルの構築まで踏み込んでいない。

本研究では、会話中のある単語が「話題」に関する単語か「言葉遣い」に関する単語かを区別することで、これら因子を明示的に捉えることができる潜在トピックモデルを提案する。具体的には、話題と言葉遣いを潜在変数で表現し、「ある会話のある登場人物が発言した特定の単語トークンは、話題または言葉遣いの**どちらか一方**から生成される」というプロセスをモデル化した。例えば、図1の「私はそのレポートをもう提出しましたわ」という発言における“レポート”や“提出”などの単語トークンは話題を表す潜在状態から生成され、“私”や“わ”などの単語トークンは言葉遣いを表す潜在状態から生成される。ここで、ある会話の単語トークンについては「話題」と「言葉遣い」のどちらか一方から生成されるという排反的な仮定をおいているが、単語のタイプとしては「話題」と「言葉遣い」のどちらも取りうるということに注意されたい。例えば、“母上”という単語タイプは、ある発話においては「話題」として生成されうるが、別の発話では「言葉遣い」として生成されうる。我々は、各単語タイプが「話題」と「言葉遣い」のどちらから生成されやすいかを確率として表現した提案モデルを、登場人物名が付与された会話コーパスから教師なし学習する。

男子学生	「ヤベー今日までの レポート 、俺やってないし〜」
女子学生	「私はその レポート をもう 提出 しましたわ」
男子学生	「マジかよwww」
女子学生	「今すぐに 取り掛かった ほうがいいですわ」
教授	「 ふむ 、 レポート を 提出 していないのは君だけですよ」
男子学生	「わかりました！すぐに 取り掛かります 」

話題「レポートの提出」 女子学生の言葉遣い「品が高い」
教授の言葉遣い「丁寧」

女子学生に対する男子学生の言葉遣い「粗雑」
教授に対する男子学生の言葉遣い「丁寧」

図1 ある話題に対する複数人での会話の例

表記	説明
M	全会話数
J	話題の数
K	言葉遣いの数
V	語彙数
$A_{(m)}$	会話 m 中の発話者数
$B_{(m)}$	会話 m 中の話し相手数
$N_{(m)}$	会話 m 中の単語数
$w_{(m,n)}$	会話 m の n 番目の単語
$N_{(m,a,b)}$	会話 m の発話者 a が話し相手 b へ発した単語数
$w_{(m,a,b,n)}$	会話 m の発話者 a が話し相手 b へ発した n 番目の単語

表1 記号・変数の説明

本研究では提案モデルが話題と言葉遣いの違いを捉えているか検証するために、話題または言葉遣いだけを考慮したモデルと比較する。分析の結果、比較モデルは話題と言葉遣いを区別できないのに対し、提案モデルは話題と言葉遣いの違いを捉えた結果となった。

2 話題と言葉遣いのモデル化

我々の目的は (a) 会話における話題の一貫性と (b) 登場人物の言葉遣いの一貫性を捉えた確率モデルの構築である。まず (a) に対しては、文書の話題を潜在変数 z で表現した生成モデルである Latent Dirichlet Allocation (Topic-LDA) [4] を利用する。次に (b) に対しては、登場人物の言葉遣いを潜在変数 z で表現した Topic-LDA の拡張モデル (Speaker-LDA) を構築する。最後に、これら 2 つのモデルを組み合わせることで、話題と言葉遣いの違いを考慮した Mutex-LDA を提案する。本稿で使う記号と変数の一覧を表1に示した。

2.1 Topic-LDA：会話の話題のモデル化

Topic-LDA [4] は、「会話（文書）ごとに話題の偏りがある」という仮定に基づいたベイジアンモデルである。例えば、「スポーツ選手の選挙出馬」に関する会話では、「スポーツ」を表す潜在状態 $z = j$ と「政

治」を表す潜在状態 $z = j'$ が生成されやすいはずである。具体的には、 m 番目の会話の n 番目の単語トークン $w_{(m,n)}$ に対して、話題を表す潜在変数 z が確率分布 $\phi_m = (\phi_{m,1}, \phi_{m,2}, \dots, \phi_{m,J})$ から生成される。 $\phi_{m,j}$ は話題 $z = j$ の生成確率を意味し、以下の式で計算できる：

$$\phi_{m,j} = \frac{N_{(m,j)} + \alpha}{\sum_{z=1}^J N_{(m,z)} + \alpha J} \quad (1)$$

ここで、 $N_{(m,z)}$ は m 番目の会話で話題 z が割り当てられた単語トークンの数である。なお、 α は分布 ϕ_m を生成するディリクレ分布のハイパーパラメータである。

次に会話内の各単語トークン $w_{(m,n)}$ は話題 z ごとに用意された生成確率分布 $\theta_z = (\theta_{z,1}, \theta_{z,2}, \dots, \theta_{z,V})$ から生成される。例えば、「バット」や「ボール」といった単語は「スポーツ」を表す潜在状態 $z = j$ の単語生成分布 θ_j から生成されやすい。ここで、確率分布 θ_z の各確率値 $\theta_{z,v}$ は以下の式で計算できる：

$$\theta_{z,v} = \frac{N_{(z,v)} + \gamma}{\sum_{w=1}^V N_{(z,w)} + \gamma V} \quad (2)$$

ここで、 $N_{(z,w)}$ は潜在状態 z から生成された単語 w の数である。なお、 γ は分布 θ_z を生成するディリクレ分布のハイパーパラメータである。ここで、各単語トークン $w_{(m,n)}$ はある 1 つの潜在変数 z から生成されているが、単語タイプ $w = v$ は確率分布 θ_z に従って、全ての z から生成されうることに注意されたい。

2.2 Speaker-LDA：登場人物の言葉遣いのモデル化

Speaker-LDA は、「話し相手によって登場人物が使う単語が偏る」という仮定に基づいた Topic-LDA の拡張モデルである。例えば、図1の例では女子学生に対して男子学生は「粗雑」な言葉遣いだが、教授に対しては「丁寧」な言葉遣いである。つまり、女子学生に対する言葉遣い z の分布は「粗雑」を表す潜在状態を生成しやすく、教授に対する言葉遣い z の分布は「丁寧」を表す潜在状態を生成しやすくなる。具体的には、 m 番目の会話における登場人物 a が話し相手に発した単語トークン $w_{(m,a,b,n)}$ に対して、言葉遣いを表す潜在変数 z が確率分布 $\psi_{m,a,b} = (\psi_{m,a,b,1}, \psi_{m,a,b,2}, \dots, \psi_{m,a,b,K})$ によって生成される。 $\psi_{m,a,b,k}$ は言葉遣い $z = k$ の生成確率を意味し、以下の式で計算できる：

$$\psi_{m,a,b,k} = \frac{N_{(m,a,b,k)} + \beta}{\sum_{z=1}^K N_{(m,a,b,z)} + \beta K} \quad (3)$$

ここで $N_{(m,a,b,z)}$ は登場人物 a が話し相手 b へ発した会話中に言葉遣い z が割り当てられた単語トークンの数である。なお、 β は分布 $\psi_{m,a,b}$ を生成するディリクレ分布のハイパーパラメータである。

次に各単語トークン $w_{(m,a,b)}$ は言葉遣い z ごとに用意された単語生成確率分布 θ_z から生成される。例えば、「俺」や「だぜ」といった単語は「粗雑」を表す潜在状態 $z = k$ の分布 θ_k から生成されやすい。この確率分布は Topic-LDA と同じ式で計算できる。

2.3 Mutex-LDA：提案モデル

Mutex-LDA は、Topic-LDA と Speaker-LDA を組み合わせることで、話題と言葉遣いの違いを捉えたモデルである。本モデルは (i) Topic-LDA の「会話ごとに話題の偏りがある」という仮定と、(ii) Speaker-LDA の「話し相手によって登場人物が使う単語が偏る」という仮定に加えて (iii) 「ある特定の会話内の各単語トークンは話題または言葉遣いのどちらか一方にしか属さない」という仮定に基づいて、潜在変数 z と単語 w を生成する。例えば、図1の例中の単語「レポート」は会話全体において言及されているため、仮定 (i) に基づいて「話題」に関連があるものとして生成される。一方、単語「私」は女子学生が一貫して使用するため、仮定 (ii) に基づいて「言葉遣い」に関連があるものとして生成される。つまり、各単語トークン w と潜在変数 z は話題か言葉遣いか、どちらか一方の生成過程しか選べないことを意味する。この二者択一 (Mutual exclusion) の生成過程を表現するために、Mutex-LDA では話題分布 ϕ_m と言葉遣い分布 $\psi_{m,a,b}$ を生成するディリクレ分布に以下のような制約を加える：

$$\phi_m \sim \text{Dir}(\alpha|\phi_{m,J+1}, \phi_{m,J+2}, \dots, \phi_{m,J+K} = 0) \quad (4)$$

$$\psi_{m,a,b} \sim \text{Dir}(\beta|\psi_{m,a,b,1}, \psi_{m,a,b,2}, \dots, \psi_{m,a,b,J} = 0) \quad (5)$$

これは、 $1 \leq z \leq J$ の時しか値を持たない話題分布 ϕ_m と $J+1 \leq z \leq J+K$ の時しか値を持たない言葉遣い分布 $\psi_{m,a,b}$ が生成されることを意味する。この時、潜在変数 z は ϕ_m と $\psi_{m,a,b}$ を合成した確率分布 π によって生成される：

$$\pi = (\phi_{m,1}, \phi_{m,2}, \dots, \phi_{m,J}, \psi_{m,a,b,J+1}, \psi_{m,a,b,J+2}, \dots, \psi_{m,a,b,J+K}) \quad (6)$$

次に各単語 $w_{(m,a,b)}$ が、潜在変数 $z (1 \leq z \leq J+K)$ ごとに用意された確率分布 θ_z から生成される。この θ_z は Topic-LDA と同じ式 (2) で計算できる。以上をまとめると、Mutex-LDA における潜在変数 z と単語 w の生成過程は以下のように書き表せる。

```

1: for each state  $z = 1, 2, \dots, J+K$  do
2:   draw  $\theta_z \sim \text{Dir}(\gamma)$ 
3: end for
4: for each document  $m = 1, 2, \dots, M$  do
5:   draw  $\phi_m \sim \text{Dir}(\alpha|\phi_{m,J+1}, \dots, \phi_{m,J+K} = 0)$ 
6:   for each speaker  $a = 1, 2, \dots, A_m$  do
7:     for each partner  $b = 1, 2, \dots, B_m$  do
8:       draw  $\psi_{m,a,b} \sim \text{Dir}(\beta|\psi_{m,a,b,1}, \dots, \psi_{m,a,b,J} = 0)$ 
9:       calculate  $\pi$  according to Eq.(6)
10:      for each  $w_{(m,a,b,n)} (1 \leq n \leq N_{(m,a,b)})$  do
11:        draw  $z_{(m,a,b,n)} \sim \text{Multi}(\pi)$ 
12:        draw  $w_{(m,a,b,n)} \sim \text{Multi}(\theta_{z_{(m,a,b,n)}})$ 
13:      end for
14:    end for
15:  end for
16: end for

```

ここで $\text{Dir}(\cdot)$ と $\text{Multi}(\cdot)$ はそれぞれディリクレ分布と多項分布を意味する。

2.3.1 モデルの推定

本研究ではパラメータ Φ, Ψ, Θ を積分消去することで、潜在変数 z を効率的に推定できる崩壊型ギブスサンプリングを用いる [5]. ここで、サンプリングのための式を導出するために、「話題」の生成過程を表す潜在状態 τ_t と「話し言葉」を表す潜在状態 τ_s を導入する。 Φ, Ψ, Θ を積分消去した単語集合 \mathbf{w} と潜在状態集合 \mathbf{z} と $\boldsymbol{\tau}$ の同時確率は以下の式で表現することができる：

$$P(\mathbf{w}, \mathbf{z}, \boldsymbol{\tau} | \alpha, \beta, \gamma) =$$

$$P(\mathbf{z}, \boldsymbol{\tau}_t | \alpha) P(\mathbf{w} | \mathbf{z}, \boldsymbol{\tau}_t, \gamma) + P(\mathbf{z}, \boldsymbol{\tau}_s | \beta) P(\mathbf{w} | \mathbf{z}, \boldsymbol{\tau}_s, \gamma) \quad (7)$$

ここで、一つ目の因子 $P(\mathbf{z}, \boldsymbol{\tau}_t | \alpha) P(\mathbf{w} | \mathbf{z}, \boldsymbol{\tau}_t, \gamma)$ だけに注目すると Topic-LDA と見なせ、二つ目の因子 $P(\mathbf{z}, \boldsymbol{\tau}_s | \beta) P(\mathbf{w} | \mathbf{z}, \boldsymbol{\tau}_s, \gamma)$ は Speaker-LDA と見なせる。ただし、本モデルでは話題分布 ϕ_m と言葉遣い分布 $\psi_{m,a,b}$ を生成するディリクレ分布に制約をいれたため、潜在変数 z のサンプリング式は以下のように計算できる：

$$\begin{aligned} P(z_{(m,a,b,n)} = k | \mathbf{w}, \mathbf{z}_{-n}, \alpha, \beta, \gamma) &\propto \\ P(z_{(m,a,b,n)} = k | \mathbf{z}_{-n}, \alpha, \beta) &\times \\ &\times P(w_{(m,a,b,n)} | z_{(m,a,b,n)} = k, \mathbf{z}_{-n}, \gamma) \end{aligned} \quad (8)$$

ここで、 $-n$ はサンプル n を除いたことを意味する。また、それぞれの項は以下の式で計算される：

$$\begin{aligned} P(z_{(m,a,b,n)} = k | \mathbf{z}_{-n}, \alpha, \beta) &\propto \\ \begin{cases} \frac{N_{(m,k)-n} + \alpha}{\sum_{z=1}^{J+K} N_{(m,z)-n} + \alpha(J+K)} & (1 \leq z \leq J) \\ \frac{N_{(m,a,b,k)-n} + \beta}{\sum_{z=1}^{J+K} N_{(m,a,b,z)-n} + \beta(J+K)} & (J+1 \leq z \leq J+K) \end{cases} & \quad (9) \\ P(w_{(m,a,b,n)} | z_{(m,a,b,n)} = k, \mathbf{z}_{-n}, \gamma) &\propto \\ \frac{N_{(z,v)-n} + \gamma}{\sum_{w=1}^V N_{(z,w)-n} + \gamma V} & \quad (10) \end{aligned}$$

3 モデルの分析

本研究では、Topic-LDA と Speaker-LDA と比べ、提案した Mutex-LDA が人間が見てもわかりやすく、「話題」と「言葉遣い」の違いを表現できるかを分析する。

3.1 データとパラメータ

本研究では、図1のような登場人物の情報が付与された会話データとして、ショートストーリー (SS) を用いる。SS は Web の掲示板に投稿された漫画やアニメの2次創作の物語であり、カギ括弧で囲まれた発話の系列で表現されている。また、カギ括弧の直前には登場人物の名前が記載されている。本研究では、Web 上から無作為に 1 万件の SS を収集した。なお、登場人物 a の直前に発言した人物を話し相手 b と仮定した。

前処理として、発話に形態素解析を行い、発話中に出てくる登場人物の名前を OWNNAME (発話者の名前)、YOURNAME (話し相手の名前)、HUMANNAME (それ以外の登場人物の名前) に置き換えた。使用する語彙はデータ中の出現頻度が大きい上位 2 万単語である。

z	単語生成確率 $P(w \phi_z)$ 上位 15 単語
2	ふ、ふ、ねー、へ、にや、よー、なー、ー、ちよ、ご、ほ、可愛い、あー、よっ
4	戦車、住、西、隊長、こと、会長、試合、学園、姉ちゃん、流、チーム、生徒、みぼりん、こちら、副
6	司令、官、艦、娘、鎮守、府、姉、達、つばい、駆逐、敵、艦隊、出撃、二、作戦
9	先輩、あたし、兄ちゃん、おう、言っ、じゃん、あんた、先生、ゆき、別に、学校、君、わたし、由比ヶ浜、なんで
16	〜、料理、なあ、美味しい、作っ、食べる、今日、き、ご飯、食べ、まあ、買っ、ほら、風呂、飲ん
19	です、ます、か、プロデューサー、アイドル、仕事、でし、ので、事務所、レッスン、お願い、プロ、おはよう、わかり、ライブ

表2 Topic-LDA での生成確率 $P(w|\phi_{(z)})$ 上位 15 単語

z	単語生成確率 $P(w \phi_z)$ 上位 15 単語
3	わ、でしよ、あんた、なに、なんて、そうね、ない、早く、まだ、別に、仕方、こっち、まったく、知ら、うるさい
7	この、する、ば、司令、官、ここ、娘、敵、艦、貴様、鎮守、攻撃、府、相手、第
8	俺、お前、まあ、ああ、悪い、わかっ、少し、すまん、頼む、しよ、だ、そろそろ、さて、なあ、とりあえず
11	ねー、よー、なー、姉ちゃん、ー、兄ちゃん、じゃん、ほら、ほ、あー、はい、へー、ありがと、しま、わたし
14	です、さん、ます、ん、プロデューサー、先輩、ありがとう、お願い、わかり、すみません、はい、おはよう、仕事、そうですね、すみません

表3 Speaker-LDA での生成確率 $P(w|\phi_{(z)})$ 上位 15 単語

各モデルの教師なし学習には崩壊型ギブスサンプリングを用い、イテレーション回数を 100 に設定した。なお、潜在変数の数は Topic-LDA は $J=20$ 、Speaker-LDA は $K=20$ 、Mutex-LDA は $J=10$ 、 $K=10$ とした。また、ディリクレ分布のハイパーパラメータ α, β, γ は Fixed Point Iteration [6] により最適化した。

3.2 潜在変数ごとの単語生成確率の分析

モデルが話題や言葉遣いを捉えているか確認するために、どんな単語タイプが分布 θ_z から生成されやすいかを観察する。表2と3はそれぞれ、Topic-LDA と Speaker-LDA における潜在変数 z と各単語生成確率が大きい単語を示した。なお紙面の都合上、話題や言葉遣いとして観察できなかった z の学習結果は除外した。

表2より、Topic-LDA については $z = 4, 6, 9, 16, 19$ で、それぞれ「戦車」「艦隊」「学校」「料理」「アイドル」など、アニメや漫画に関連する話題が学習されたことがわかる。しかし、 $z = 2$ は話題ではなく、「ファイラー」などの言葉遣いが学習された。これは、「ファイラー」が多く使われた会話があり、「ファイラー」をある種の話題であるとモデルが学習したと考えられる。

表3より、Speaker-LDA については $z = 3, 8, 11, 14$ で、それぞれ「ツンデレ」「粗雑」「稚拙」「丁寧」など、典型的な言葉遣いが学習されたことがわかる。一方で $z = 7$ のように言葉遣いとは異なる「艦隊」に関する話題が学習された。Speaker-LDA は「話し相手によって登場人物の言葉遣いが異なる」ことを仮定したモデルであるが、ある登場人物が常に「艦隊」について言及していれば、それはある種の言葉遣いとみなすことができるため、話題が学習されたと考えられる。以上の結果をまとめると、Topic-LDA と Speaker-LDA はそれぞれ話題と言葉遣いを上手く学習しているが、話題と言葉遣いが混在しており、両モデルは言葉遣いと話題の

z	単語生成確率 $P(w \phi_z)$ 上位 40 単語
1	司令,官,艦,娘,達,鎮守,府,敵,姉,駆逐,艦隊,つばい,出撃,作戦,第,了解,提督,戦艦,空母,秘書,戦闘,任務,姉さん,訓練,演習,執務,夜戦,部隊,艦装,デ,他,巡,報告,海域,遠征,任せ,装備,艦載,全,妖精
2	みんな,2,たち,3,ライブ,まで,練習,麻雀,プロ,二,須賀,三,京,頑張つ,勝負,最後,選手,スクール,,さすが,4,すごい,さあ,5,部長,-,やり,目,凄い,野球,優勝,メンバー,勝つ,宮永,応援,絶対,年生,誕生
3	!!,...!!!,.....!!!,(ア,..,ねエ,!!?!!!!,こんな,?!??.,..,早く,パンツ,さあ),...?,...,..!!!!!!!,おっばい,緩,マスター,御坂,変態,..,痛い,こう,ちんちん,.....,尻,使徒,なア
4	HUMANNAME,た,く,ここ,犯人,誰,少女,事件,死ん,部屋,【,】,どこ,魔女,ベ,眺美,はず,名前,まさか,室,どういう,コイン,美樹,涼,警察,絶望,ノート,鹿目,殺さ,捜査,嘘,クン,間違い,無事,鍵,探偵,今回,探し,夜
5	戦車,住,西,隊長,会長,由比ヶ浜,雪ノ下,谷,生徒,先輩,殿,試合,学校,先生,学園,比企,流,奉仕,チーム,部活,みぼりん,副,高校,女子,わたし,ボコ,大学,友達,依頼,クラス,告白,アンツイオ,優美子,逸見,秋山,祭,峰,転校,ヒキオ,大会
6	の,この,様,魔法,あの,人間,攻撃,魔,世界,相手,能力,カード,剣,0,効果,ターン,..,貴様,まだ,発動,仲間,召喚,モンスター,魔物,倒し,魔術,力,魔力,戦う,魔王,破壊,ポケモン,勇者,旅,戦つ,生き,武器,族,主人,騎士
7	,.?,も,どう,なつ,言つ,たい,そういう,言わ,聞い,それで,気持ち,いつ,昨日,忘れ,初めて,なく,それなら,いい,良い,大事,幸せ,約束,迷惑,今,家族,どうしても,もうすく,突然,はつきり,誤解,返事,また,入ら,体調,嬉しく,てつきり,ちよつとした,解つ
8	プロデューサー,アイドル,『,』,とか,仕事,事務所,レッスン,的,,ゲーム,ファン,普通,いう,番組,キャラ,765,可愛い,アニメ,っていう,なるほど,最近,大人,意味,ラジオ,どんな,一番,映画,ユニット,イメージ,ロック,最初,お疲れ様,ちなみに,書い,衣装,猫,質問,ネタ,プロデューサー
9	一,..,進撃,添い寝,隣,ほか,クエスト,..,..,華,ブルマ,/////////,喫茶店,/////////,配,ZZZ,オプション,vs,桃,夜空,中国,潤つ,苦し,恐竜,かぜ,一覽,フランス語,ほかほか,すつきり,墓参り,昨夜,下ろす,止まれ,さんざん,汚し,辛く,ひみ,金魚,ゆり,?),抱き着い
10,.....,もう,これ,オカリン,.....!,.....?,氏,凶,.....,ラボ,..,牧瀬,ああ,助手,倫太郎,.....,.....,www,ルカ,ダメ,ニャン,んで,.....?,メール,メン,橋田,.....,もつと,.....?,院,鳳凰,ござる,.....,ww,.....,ニヤ,笑つ
11	わ,私,でしよ,あなた,あなた,もの,そうね,なに,ない,子,ごめんさい,本当に,貴方,どうして,ミキ,貴女,あらあら,仕方,ふふふ,うるさい,まったく,うふふ,いいえ,当然,あんな,当たり前,分かれ,決まっ,全ク,しょうが,バカ,何かしら,どうせ,アナタ,はね,悪く,ずら,呼ん,黙つ,もらえる
12	。、僕,君,だつ,ボク,少し,しよ,すま,だい,頼む,分かつ,しれ,うむ,だ,さて,くれる,彼女,これから,心配,ふむ,おく,構わ,だが,キミ,わから,そろそろ,もちろん,と,ころで,ほしい,連絡,おや,君たち,頼ん,実は,みよ,安心,おこ,久しぶり,予定,そう
13	は,を,こと,する,という,その,ば,として,れる,しかし,ため,など,そして,自分,す,必要,わけ,できる,可能,存在,ほど,問題,べき,しか,全て,しまう,何故,せる,一つ,以上,彼,言葉,やはり,我々,すれ,為,理由,情報,について,つり
14	です,ます,さん,まじよ,でし,ので,ありがどう,お願い,わかり,では,すみません,分かれ,ご,それでは,そうですね,こちら,わたくし,はい,皆さん,違い,すいません,申し訳,言い,とても,おはよう,いえいえ,頑張り,お話,聞き,みなさん,構い,どうか,よろしい,ですが,戻り,いえ,知り,素敵,こんには
15	たら,から,つす,1,一,だけ,くらい,ほら,入つ,買つ,今日,持つ,作つ,料理,とりあえず,食べる,美味しい,回,寝,風呂,ご飯,朝,そこ,家,食べ,使つ,明日,こっち,ながら,作る,らしい,肉,用意,お金,お腹,10,飲ん,全部,置い,時間
16	!?!?,つ,ああ,う,///,—,はあ,ちよ,おお,うう,,うう,うわ,ひつ,うつ,待つ,/,,—,!///,やっ,だめ,はあ,////,!..,!!?///,てえ,げ,恥ずかしい,ぐす,ほつ,きやあ,!!.....,いつ,くつ,いきなり,えと,くう
17	俺,お前,ぜ,なあ,ら,おう,まあ,あいつ,悪い,なんで,マジ,なあ,しろ,やつ,こいつ,オレ,わかっ,すまん,やめろ,つ,ちまっ,んじや,がっ,何で,知ら,やる,おいおい,馬鹿,何だ,奴,だろ,悪かつ,別に,さつさと,やつば,すげ,飯,アイツ,ってな,おまえ
18	~OWNNAME,♪,にや,ねー,よー,ち,ふ,な一,兄ちゃん,一,姉ちゃん,~,~?,~,~,じ,ほ,~♪,ちん,はい,わあ,かあ,スリ,~,~,かよ,へー,しま,あ一,ど一,つと,ねつ,ぶ,..,ゆ,ちゃん,すう,いや一,よ一
19,.....,親友,フビ,離れる,?.....,だるい,.....,.....,花言葉,眩しい,居心地,フビツ,モグモグ,気遣つ,成り行き,読も,シヤ,無性に,けじめ,——!,繋ご,近付く,むや,訊か,羨ましかつ,悲しかつ,め,思い付か,眩しく,くれよ,運勢,寄せる,働き出す,憎く,首尾,夕陽,してかし,ぼちぼち,お早う
20	YOURNAME,つて,みたい,あたし,思う,大丈夫,じゃん,ちゃんと,一緒,やっぱり,思っ,うーん,ううん,のに,だから,違う,ありがと,さつき,きつと,つけ,全然,嫌,ホント,なんか,知っ,ずつと,ふーん,あんまり,怖い,変,もしかして,へえ,すごく,そんなに,わかる,でる,話し,なんだか,嬉しい,なかつ

表4 Hybrid-LDAにおける単語生成確率 $P(w|\phi_z)$ 上位 40 単語. $1 \leq z \leq 10$ は話題を表し, $11 \leq z \leq 20$ は言葉遣いを表す.

違いを捉えられない結果となった.

表4に Mutex-LDA における潜在変数 z と生成確率 $\theta_{z,v}$ が大きい単語タイプの集合を示した. まず, 話題分布の成分 $\phi_{m,1}, \phi_{m,2}, \dots, \phi_{m,J}$ から生成された $1 \leq z \leq 10$ では, Topic-LDA に比べて, 言葉遣いに関する z は学習されずに, 話題に関する単語の生成確率が大きい結果となった. 例えば, $z = 1$ では「艦隊」, $z = 6$ では「勝負」に関する単語の確率値が大きい. 言葉遣い分布の成分 $\psi_{m,J+1}, \psi_{m,J+2}, \dots, \psi_{m,J+K}$ から生成された $11 \leq z \leq 20$ では, $z = 15$ を除いて, 話題は学習されずに言葉遣いに関する単語の生成確率が大きい結果となった. 例えば $z = 12$ では, “僕” や “ふむ”, “さて” などの目上の人を使う言葉遣いが学習されている. しかし $z = 15$ では, 言葉遣いには見えない生活的な単語の生成確率が大きい結果となった. これは, ある登場人物だけが「生活」について言及しているため学習された結果であり, これは「世話焼き」な人の言葉遣いとして見る事ができる. 一方で, $z = 7$ や $z = 9$, $z = 19$ のような話題でも言葉遣いでもない潜在状態も学習される. これらは, 助詞などの「基本的な機能語」や, 形容詞・副詞などの「感情」などの別の因子をモデル化することで改善されると考えられる.

4 おわりに

本研究では, 会話における「話題」の一貫性と, 登場人物の「言葉遣い」の一貫性を捉えた潜在トピックモデル Mutex-LDA を提案した. 提案手法は「特定の会話内の各単語トークンは話題または言葉遣いのどちらか一方にしか属さない」という仮定をモデル化することにより, 「話題」と「言葉遣い」を明示的に区別することが可能となった. 今後は, 学習された話題と言葉遣いの妥当性を主観評価する予定である [7]. また, 提案モデルの応用として, 指定した話題や言葉遣いを満たす応答を生成する対話システムの構築を目指す.

参考文献

- [1] Alan Ritter, Colin Cherry, and Bill Dolan. Unsupervised modeling of twitter conversations. In *NAACL 2010*, pages 172–180, 2010.
- [2] Ke Zhai and Jason D. Williams. Discovering latent structure in task-oriented dialogues. In *ACL 2014*, pages 36–46, 2014.
- [3] Jiwei Li, Michel Galley, Chris Brockett, et al. A persona-based neural conversation model. In *ACL 2016*, pages 994–1003, 2016.
- [4] David M. Blei, Andrew Y. Ng, and Michael I. Jordan. Latent dirichlet allocation. *Journal of Machine Learning Research*, 3:993–1022, 2003.
- [5] Thomas L Griffiths and Mark Steyvers. Finding scientific topics. *Proceedings of the National academy of Sciences*, 101:5228–5235, 2004.
- [6] Thomas P. Minka. Estimating a dirichlet distribution. Technical report, 2000.
- [7] Jonathan Chang, Sean Gerrish, Chong Wang, Jordan L Boyd-Graber, and David M Blei. Reading tea leaves: How humans interpret topic models. In *NIPS 2009*, pages 288–296, 2009.