

# Twitter 発話文に含まれる固有表現のラベル体系を考慮した ユーザの属性推定

坂本 裕樹 赤石 美奈

法政大学 情報科学部

## 1 はじめに

近年、対話システムの研究開発が活発化している。対話システムにおいて高いユーザ満足度を達成するためには、対話のパーソナライズが重要な課題の1つとして挙げられる。対話のパーソナライズを目指した関連研究として、過去のユーザ発話を用いてシステム応答発話に応用するもの[1]や、ユーザの対話文から、そのユーザの興味を推定したもの[2]がある。一方、本研究ではユーザの属性(年代, 職業, 興味地域等)に基づく対話のパーソナライズを目的とし、Twitter ユーザの発話文から、そのユーザの属性を推定する手法を提案する。

## 2 ユーザ属性推定手法

提案手法の概要を図1に示す。提案手法は、固有表現ラベル分類層と属性推定層の2層で構成され、発話者 $s$ の発話集合 $Us = (u_1, u_2, \dots, u_n)$ が与えられたとき、推定対象の属性集合 $T = (t_1, t_2, \dots, t_m)$ に対する発話者 $s$ のユーザ属性 $Y = (y_{t_1}, y_{t_2}, \dots, y_{t_m})$ を推定する。なお、本論における属性 $t_k$ は、年代, 職業, 興味地域を表し、各ユーザ属性 $y_{t_k}$ は各属性 $t_k$ の要素を表す。固有表現ラベル分類層は、発話集合 $Us$ を入力とし、各発話 $u_i$ に含まれる固有表現のラベル体系に基づいて、各発話 $u_i$ をラベル別発話集合 $X = (x_{h_1}, x_{h_2}, \dots, x_{h_l})$ に分類する。分類に用いるカテゴリ $H = (h_1, h_2, \dots, h_l)$ は固有表現のラベル体系のラベルに対応する。ラベル体系を用いた各発話 $u_i$ の分類は、ユーザ属性の違いによって、発話内容に偏りがあるという仮定に基づき、各ユーザ属性 $y_{t_k}$ の推定に用いる発話集合を、特定のラベル別発話集合 $x_{h_j}$ に限定することで、推定精度が向上すると考えた。属性推定層は、入力されたラベル別発話集合 $X$ から、各ユーザ属性 $y_{t_k}$ の推定に有効なラベル別発話集合 $x_{h_j}$ を用いて、推定ユーザ属性 $D = (d_{t_1}, d_{t_2}, \dots, d_{t_m})$ を出力する。なお、各ユーザ属性 $y_{t_k}$ の推定に有効なラベル別発話集合 $x_{h_j}$ として、推定実験を行い、推定精度の高い $x_{h_j}$ を用いる。以下では固有表

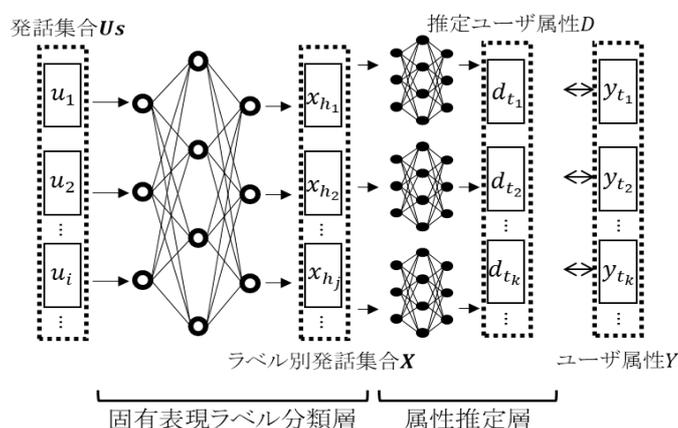


図1 提案手法の概要

現ラベル分類層と属性推定層を詳しく説明する。

### 2.1 固有表現ラベル分類層

固有表現ラベル分類層は、発話集合 $Us$ を入力として、各発話 $u_i$ に含まれる固有表現を抽出し、抽出された固有表現のラベル体系に基づいて、各発話 $u_i$ を各ラベル別発話集合 $x_{h_j}$ に分類する。このとき、 $x_{h_j}$ は、 $h_j$ に属する固有表現を含む発話の集合を表す。本研究のカテゴリラベル $h_j$ は、Person (人名), Organization (組織名), Location (地名), Product (製品名)の4つとする。また、本研究では固有表現及び固有表現のラベル体系の抽出手法として、GiNZA[3]の固有表現抽出モデルを用いた。

### 2.2 属性推定層

属性推定層は、固有表現ラベル分類層より得た各ラベル別発話集合 $x_{h_j}$ のうち、各ユーザ属性 $y_{t_k}$ の推定に有効であると定めた $x_{h_j}$ のみを用いて、各ユーザ属性 $y_{t_k}$ を推定する。また、クラス分類手法にはBERT (Bidirectional Encoder Representations from Transformers) [4]を用いる。本研究では、事前学習されたBERT-baseモデルに対してクラス分類層を追加し、作成した訓練データセットを用いてfine-tuningを行うことで、クラス分類モデルを作成した。

## 3 実験

提案手法を用いて、Twitter アカウントを持つ発話者 85 名を対象として、各発話者の年代が若年, 中年, 高年のどこに属するかを推定した。

### 3.1 実験設定

属性推定層における年代推定モデルとして、若年、中年、高年の3クラス分類モデルを作成した。年代推定モデル学習に用いる訓練データセットは、Twitter から収集したユーザの発話文と、発話元ユーザの年代を組とした 67,363 文から作成した。また、BERT の事前学習済みモデルとして、黒橋ら [5] が公開しているモデルを用いた。この事前学習モデルに対し、バッチ数 32、学習率  $2 \times 10^{-5}$ 、エポック数 3 とし、Adam による最適化手法を用いて fine-tuning を行った。また、損失関数には交差エントロピーを用いた。

### 3.2 評価方法

本実験では、実験対象 85 名のうち何名が、各発話者の各  $x_{h_j}$  を用いて推定された年代と、各発話者の本来の年代が一致しているかの正解率を推定精度として評価した。さらに、推定に用いる各  $x_{h_j}$  の発話文数の変化に対して、年代推定の正解率がどのように推移するかを確認した。また、発話者  $s$  の各  $x_{h_j}$  のうち、推定に必要な発話文数が存在しない  $x_{h_j}$  がある場合、その  $x_{h_j}$  からの発話者  $s$  の年代推定は行わないこととした。

### 3.3 比較手法

年代推定に有効であるラベルを確認するため、固有表現ラベル分類層から得た Person, Organization, Location, Product のいずれかを含むラベル別発話集合と、ベースラインとして Original (全ての発話文) を用いて年代推定精度を比較した。

### 3.4 実験結果

実験結果を図 2 に示す。図 2 では、各発話者の発話集合に存在する各ラベル別発話集合から、発話者の年代を推定したときの正解率と、発話数を段階的に増やしたときの正解率の推移を示した。また、各ラベル別発話集合からの推定人数が被験者全体の 70% 以上である正解率のみを示した。図 2 から、Person による推定正解率は、推定に用いる発話数が 37 文になるまで、全ての発話数に対して最も高い値を示した。このことから、年代推定には、人名を含む発話文を用いた推定が有効であると考えられる。一方、Organization による推定正解率は、Original よりも低く推移した。また、Location による推定正解率も、Original より低く推移し、3 文を用いた推定では最も低い値を示した。このことから、組織名や地名を含む発話文は年代推定に適さないと考える。Product は、Original と比べて推定正解率の推移に大きな差は確認できない。そのため、製品名を含む発話文からの年

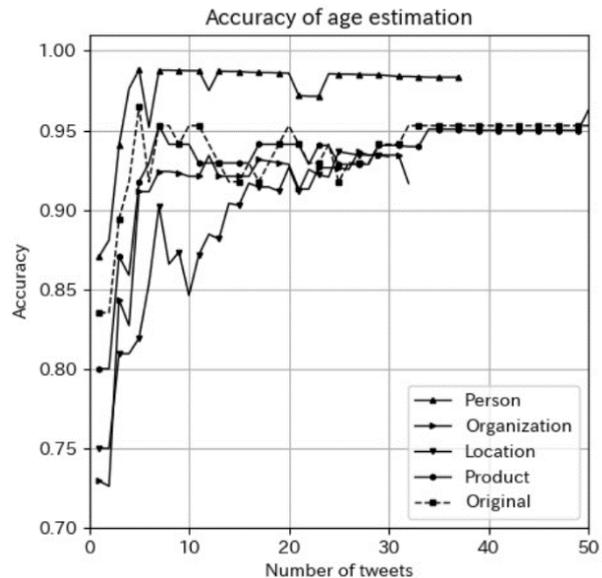


図 2 発話数の変化によるラベル別年代推定の正解率の推移

代推定は有効ではないと考える。

### 4 おわりに

本研究では、発話者の発話集合を入力とし、発話者のユーザ属性を推定する手法を提案している。今回は、提案手法の一部であるユーザの年代推定システムの実装に向けて、各ラベル別発話集合から年代推定実験を行った。実験の結果、年代推定において、人名を含む発話集合からの推定精度が最も高いことを確認した。このことから、ユーザの年代推定には、人名を含む発話文からの推定が有効であると考えられる。今後は、他の属性における推定において、どのラベルを含む発話文が有効か確認する。そして、対話のパーソナライズを目指したユーザ属性推定システムの構築を目指す。

### ◇参考文献◇

- [1] 奥井 颯平, 中辻 真: PLSTM によるチャットボット対話の精度検証, 2019 年度人工知能学会全国大会 (第 33 回)
- [2] 稲葉 通将, 高橋 健一: ニューラルネットワークを用いた雑談対話からのユーザの興味推定, 人工知能学会論文誌, Vol. 34 No. 2 p. E-I94\_1-9, 2019
- [3] GiNZA, 閲覧日: 2021-01-05, <https://megagonlabs.github.io/ginza/>
- [4] Jacob Devlin, Ming-Wei Chang, Kenton Lee, and Kristina Toutanova. BERT: Pre-training of deep bidirectional transformers for language understanding. arXiv: 1810.04805, 2018.
- [5] 黒橋・褚・村脇研究室, 閲覧日: 2021-01-05, <http://nlp.ist.i.kyoto-u.ac.jp/>