

Title	属性に対する極性判定を対象とした教師なし領域 適応
Author(s)	陸, 兵漢
Citation	
Issue Date	2023-03
Type	Thesis or Dissertation
Text version	author
URL	http://hdl.handle.net/10119/18340
Rights	
Description	Supervisor: 白井 清昭, 先端科学技術研究科, 修 士(情報科学)

概要

近年、ユーザによって書かれたレビューの極性を分類する研究が盛んに行われている。レビューの極性を分類するタスク(極性判定)とは、文書分類の一種であり、テキストに含まれる感情の極性を予測する多クラス分類問題である。一般に、極性判定には教師あり機械学習の手法が用いられることが多いが、訓練データとテストデータでドメインが異なると極性判定の性能が低下する問題が知られている。

上記の問題に対する取り込みとして、異なるドメインにおけるデータの差異をなるべく小さくする「領域適応」と呼ばれる技術が研究されている。レビューの極性を分類するタスクに対する現在までの領域適応の手法では、一般にテキストのジャンルや媒体をドメインとするのが主流であるが、属性を対象とする研究は少ない。属性を対象とした極性判定とは、製品やサービスといった評価対象の属性に対してユーザが表明した意見が肯定的か否定的かを判定することを指す。しかし、属性毎にラベル付きデータを用意する必要があるため、属性に対する極性判定では異なる属性に対して訓練データとテストデータの違いが正解率の低下を招くという同様の問題が起こりうる。

本研究は、属性をドメインとみなし、ある属性に関するラベル付きデータから別の属性の極性判定のモデルを学習する領域適応の手法を提案することを目的とする。具体的には、ターゲットドメインのラベル付きデータを自動構築するために、ソースドメインのデータから学習した Bidirectional Encoder Representations from Transformers(BERT) を用いて自動ラベル付けを行う手法と、ソースドメインの文に出現する感情語や特徴語をターゲットドメインのそれに置換することで、ターゲットドメインのラベル付きデータを自動的に生成する手法を組み合わせる。ここで、ソースドメインは訓練データのドメイン、ターゲットドメインはテストデータのドメインを指す。最後に、自動構築したラベル付きデータを用いて、ターゲットドメインの属性の極性を判定する分類器を学習する。

ターゲットドメインのラベル付きデータは、以下の2つの手法で構築する。1つ目は、ソースドメインのラベル付きデータを用いて BERT モデルをファインチューニングし、ターゲットドメインのラベルなしデータに対してラベル付けを行う。この際、極性ラベルの予測確率が閾値より小さいレビュー文は、付与された極性ラベルが誤りである可能性があるため、除外する。これにより、高い品質を持つターゲットドメインのラベル付きデータを作成する。

2つ目の手法は、感情語・特徴語の抽出、レビュー文の生成、生成文のフィルタリングの3つのステップによってターゲットドメインのラベル付きデータを構築する。本研究ではこれを Cross Aspect Review Generation(CARG) と呼ぶ。まず、ソースドメインとターゲットドメインのそれぞれについて、そのドメイン(属性)のレビューで使用される感情語を抽出する。あるドメインのレビュー文を単語に分割し、品詞タガーと感情語辞書 SentiWordNet を用いてそれぞれの単語の極性スコアを計算し、それが閾値以上の単語をドメインに固有の感情語として抽出する。また、特定のドメインだけによく使われる単語を「特徴語」と定義し、こ

れを抽出する。各属性のレビュー集合を仮想的にひとつの文書とみなし、単語の TF-IDF を計算し、この値が高い単語をドメインに固有の特徴語として抽出する。次に、ソースドメインのラベル付きデータにおける感情語もしくは特徴語をターゲットドメインの感情語もしくは特徴語に置き換えることにより、ターゲットドメインのラベル付き文を新たに生成する。単語の置き換えには BERT の Masked Language Model (MLM) を利用する。最後に、各生成文に対して、文の自然さを評価する擬似対数尤度スコアを測定し、スコアの低い文をフィルタリングする。

以上の2つの手法によって構築されたデータセットを用いて BERT モデルをファインチューニングし、ターゲットドメインの極性判定モデルを得る。ファインチューニングの際、Focal Loss を損失関数として使用し、極性ラベルの分布の偏りの問題に対処する。

提案手法の評価のため、レストラン・データセットとラップトップ・データセットを用いて極性判定の領域適応の実験を行った。前者は5つの属性、後者は4つの属性に関するレビューから構成される。ある属性をソースドメイン、別の属性をターゲットドメインとして、全ての属性の組について極性判定を行う実験を行った (クロスドメイン)。比較のため、ソースドメインとターゲットドメインが同じ場合の極性判定の実験も行った (インドメイン)。クロスドメインの実験では正解率を、インドメインの実験では5分割交差検証における5回の試行の正解率のマイクロ平均を評価指標とした。これらの評価指標について、提案手法とベースライン手法ならびに先行研究の手法と比較した。

実験の結果、レストラン・データセットでは、全20組の属性の組み合わせのうち17組については、ベースライン手法に比べて提案手法の正解率が上回った。先行研究との比較では、全20組のうち14組で提案手法の正解率が高かった。不自然な文をフィルタリングするシステムとしないシステムと比べて、全20組のうち12組については前者の正解率が高いことから、不自然な文をフィルタリングする手法は有効であった。Focal Loss を損失関数とするシステムと通常のカロスエントロピーを損失関数とするシステムを比較すると、全20組のうちの15組は前者の正解率と同じもしくは高かった。今回の実験では Focal Loss の導入が効果的であった。フィルタリングと Focal Loss を同時に導入した提案手法の平均正解率は0.658であり、2つのベースライン手法と比べてそれぞれ0.025, 0.013ポイント正解率を向上させ、比較した手法の中で最も高い平均正解率を示した。ラップトップ・データセットの実験では、レストラン・データセットの結果と同様に、ベースラインよりも提案手法の方が優れていることが確認された。比較した手法の中で最も結果が良かったのは、Focal Loss を損失関数としない提案手法であり、全てのドメインの組に対する平均正解率は0.801であった。これは2つのベースライン手法をそれぞれ0.011, 0.007ポイント上回った。ただし、レストラン・データセットと比べて、ベースラインと提案手法の正解率の差は小さかった。インドメインの実験結果と比較すると、属性の組によっては提案手法によるクロスドメインでの正解率がインドメインの正解率のマイクロ平均より高いこともあった。2つ

の異なるデータセットでおおよそ同様の結果が得られたことから、提案手法がどのようなジャンルのレビューにも適用できるという意味での汎用性を有することがわかった。