

ターゲット領域のキーワード含有率を事例の重みとした感情分析の領域適応

白 静 古宮 嘉那子 新納 浩幸
 茨城大学大学院 茨城大学工学部 茨城大学工学部
 理工学研究科情報工学専攻 情報工学科 情報工学科

{17nm719x, kanako.komiya.nlp, hiroyuki.shinnou.0828}@vc.ibaraki.ac.jp

1 はじめに

本論文では感情分析の領域適応に対して、新たな事例ベースの手法を提案する。

感情分析とはレビュー文書（例えば映画のレビュー）が肯定的なものか、否定的なものかを判定するタスクである。これは文書分類の一種であり、教師あり学習を用いて解決できる。しかし判定先の文書が学習データの領域とは異なる領域の文書（例えば書籍のレビュー）であった場合に、教師あり学習で得られた分類器の精度が下がってしまう。これが領域適応の問題である。

領域適応の問題に対する手法は、素性ベースのものと事例ベースのものに大別できる [6]。素性ベースの手法は学習データの素性に重みを付けた学習であり、事例ベースの手法は学習データの事例に重みを付けた学習である。

ここでは新たな事例ベースの手法を提案する。従来、事例ベースの手法としては共変量シフトを仮定し、確率密度比を事例の重みとする手法が一般的である。ただし確率密度比を算出する計算コストは大きい。ここで提案する手法は単純なものであるが、確率密度比以上の効果がある。

提案手法ではターゲット領域の文書集合から、IDF値を用いてターゲット領域における単語 w のキーワードの度合い d_w を設定する。この d_w を用いて、ソース領域における事例 x がどの程度ターゲット領域のキーワードを含むかというキーワード含有率 w_x を設定する。この w_x を x の重みとして重み付け学習を行うことで、領域適応の問題に対処する、

実験では Amazon dataset [1] を用いて、確率密度比を求める2つ手法（uLSIF [10] と論文 [11] の提案手法）と提案手法を比較することで、提案手法の有効性を示す。

2 関連研究

領域適応の手法は、まず、ターゲット領域のラベル付きデータを用いる教師ありの手法と、それを用いない教師なしの手法に大別できる。教師ありの手法の場合、Daumé の手法 [3] が簡易でしかも能力が高いため、標準手法となっている。

本論文で扱うのは教師なしの手法である。教師なしの手法の場合、素性ベースのものと事例ベースのものに大別できる [6]。素性ベースの手法は学習データの素性に重みを付けた学習であり、事例ベースの手法は学習データの事例に重みを付けた学習である。素性ベースの手法としては古典的には SCL [2] が有名である。近年は CORAL [7] が簡易でしかも能力が高いため注目されている。さらに素性ベースの手法は深層学習とも相性がよく [5]、CORAL を拡張した手法 [8] や敵対性ネットワークを利用した手法 [4][9] が state of the art と思われる。

一方、事例ベースの手法の研究は素性ベースのものに比べると数が少ない。事例ベースの手法では共変量シフトを仮定する。共変量シフトとは $P_S(c|\mathbf{x}) = P_T(c|\mathbf{x})$ かつ $P_S(\mathbf{x}) = P_T(\mathbf{x})$ という仮定である。共変量シフト下では、ソース領域のデータ \mathbf{x} に対して確率密度比 $r = P_T(\mathbf{x})/P_S(\mathbf{x})$ を重みとした重み付き学習から、 $P_T(c|\mathbf{x})$ を得ることができる。確率密度比の算出方法としては様々な手法がある。単純には $P_S(\mathbf{x})$ と $P_T(\mathbf{x})$ を求めればよいが、それらのモデルが複雑な場合は問題をより複雑にするために、直接、確率密度比をモデル化する手法が研究されている。それらの中でも uLSIF [10] は比較的計算量が少なく、広く利用されている。ただし、自然言語処理に限れば、bag-of-words の $P(\mathbf{x})$ を Naive Bayes でモデル化できるので、論文 [11] では領域 R でのデータ \mathbf{x} が素性リスト $\{f_1, f_2, \dots, f_n\}$ であるとき $P_R(\mathbf{x}) = \prod_{i=1}^n P_R(f_i)$ としている。また

$P_R(f_i)$ は以下で求めている。

$$P_R(f) = \frac{n(R, f) + 1}{N(R) + 2}$$

ここで $n(R, f)$ は領域 R 内での素性 f の頻度、 $n(R)$ は領域 R のデータ数である。以上より確率密度比は以下となる。

$$r = \frac{P_T(\mathbf{x})}{P_S(\mathbf{x})} = \frac{n(T, f) + 1}{N(T) + 2} \cdot \frac{N(S) + 2}{n(S, f) + 1} \quad (1)$$

3 提案手法

3.1 ターゲット領域におけるキーワードの度合い

ここでは単語 w がターゲット領域においてどの程度キーワードとみなせるかという度合い d_x を w のターゲット領域の文書集合における IDF 値に設定する。

$$d_x = \log \left(\frac{N}{d_i} \right) + 1$$

ここで N はターゲット領域の文書集合の文書数、 d_i はターゲット領域の文書集合の中で単語 w を含む文書数である。

3.2 ソース事例中のキーワードの含有率

ソース領域の事例 x の重み w_x を定める。まず事例 (文書) x の単語の集合を $\{w_i\}_{i=1}^K$ とする。また単語 w_i の x 内での頻度を f_i とする。これらを用いて、 w_x を以下の式で定める。

$$w_x = \frac{1}{\sum_{i=1}^K f_i} \sum_{i=1}^K f_i \cdot d_{w_i}$$

4 実験

実験では Amazon dataset [1] を用いる。具体的には以下のサイトで公開されている `processed_acl.tar.gz` を展開したデータを用いる。

<https://www.cs.jhu.edu/~mdredze/datasets/sentiment/>

このデータは books (B), dvd (D), electronics (E) および kitchen (K) の 4 つの領域をもち、それぞれの領域に含まれる文書数は表 1 の通りである。どの領域でも positive データと negative データはそれぞれ

1,000 個あり、これらを合わせた 2,000 データをその領域の訓練データとする。

表 1: 領域毎の文書数

	positive	negative	test data
books	1,000	1,000	4,465
dvd	1,000	1,000	3,586
electronics	1,000	1,000	5,681
kitchen	1,000	1,000	5,945

学習アルゴリズムには scikit-learn の SVM を用いる。カーネルは linear、C パラメータの値は 0.1 で固定とする。scikit-learn の SVM には重み付き学習もサポートされているので¹、ここでの重み付き学習も scikit-learn の SVM を用いる。

領域適応としては、 $B \rightarrow D$ 、 $B \rightarrow E$ 、 $B \rightarrow K$ 、 $D \rightarrow B$ 、 $D \rightarrow E$ 、 $D \rightarrow K$ 、 $E \rightarrow B$ 、 $E \rightarrow D$ 、 $E \rightarrow K$ 、 $K \rightarrow B$ 、 $K \rightarrow D$ 、 $K \rightarrow E$ の 12 通りが存在する。それぞれの領域適応に対して、確率密度比を求める 2 つ手法 (uLSIF [10] と Naive Bayes を用いた式 (1)) 及び提案手法を用いた結果 (テストデータに対する正解率) を表 2 に示す。表 2 中の NONE は領域適応の手法を用いず、単にソース領域の訓練データから構築した分類器をそのままターゲット領域のテストデータに適用した結果である。また IDEAL はターゲット領域の訓練データを用いて分類器を学習し、それをターゲット領域のテストデータに適用した結果である。

事例への重み付き手法である uLSIF、NB および提案手法を比較すると、12 個の領域適応の中で 6 個について提案手法が最も高い正解率を出し、残りの 6 個は NB が最も高い正解率を出している。12 個の平均を取ると提案手法がわずかに NB を上回っており、提案手法は事例への重み付き手法としては、優秀であると言える。

5 考察

表 2 の NONE と事例への重み付き手法 (uLSIF、NB および提案手法) を比較すると、明らかに NONE の方が正解率が高い。本実験データに限れば、事例ベースの手法は領域適応には効果がないと言える。

ただし事例ベースの手法は素性ベースの手法と容易に組み合わせられるという長所がある。ここでは論文 [7] で行っている 4 つの領域適応 $B \rightarrow E$ 、 $D \rightarrow B$ 、 $E \rightarrow K$ 、 $K \rightarrow D$ に対して、最初に SCL を用いて訓練デー

¹http://scikit-learn.org/stable/auto_examples/svm/plot_weighted_samples.html

表 2: 実験結果

	IDEAL	NONE	uLSIF	NB	提案手法
B → D	0.822	0.806	0.806	0.811	0.809
B → E	0.852	0.761	0.756	0.755	0.765
B → K	0.878	0.845	0.778	0.779	0.785
D → B	0.831	0.762	0.733	0.745	0.741
D → E	0.852	0.761	0.748	0.753	0.758
D → K	0.878	0.795	0.773	0.782	0.789
E → B	0.831	0.712	0.714	0.723	0.719
E → D	0.822	0.722	0.708	0.723	0.714
E → K	0.878	0.849	0.854	0.857	0.855
K → B	0.831	0.713	0.707	0.714	0.715
K → D	0.822	0.740	0.733	0.723	0.736
K → E	0.852	0.842	0.847	0.852	0.845
平均	0.846	0.776	0.763	0.768	0.769

表 3: 素性ベース手法+事例ベース手法

	IDEAL	NONE	CORAL	提案手法	SCL	SCL + 提案手法
B → E	0.852	0.761	0.763	0.760	0.757	0.756
D → B	0.831	0.762	0.783	0.756	0.732	0.733
E → K	0.878	0.849	0.836	0.849	0.852	0.853
K → D	0.822	0.740	0.739	0.743	0.732	0.733
平均	0.846	0.778	0.780	0.777	0.768	0.769

タの素性ベクトルを変換し、次にその変換されたベクトルに提案手法の重みを付けて学習を行う実験を行った。その結果を表 3 に示す。表 3 の CORAL は [7] の表から取り出した。

表 3 を見ると SCL はあまり効果がなく、SCL に提案手法を組み合わせた手法の精度は良くない。しかし SCL に提案手法を組み合わせた場合、SCL 単独の精度を改善できており、素性ベースの手法に事例ベースの手法を組み合わせた効果が確認できる。素性ベースの手法には SCL 以外にも多くの手法があるので、それらの手法と提案手法を組み合わせて改良できると考えている。

また本論文では重み付き学習には重み付き SVM を利用したが、ニューラルネットでは損失関数の損失値に重みを乗じて、それを損失値とすることで容易に重み付き学習が実現できる。深層学習を利用した領域適応の手法は数多く提案されており、それらと事例ベースの手法を組み合わせることも容易である。

簡単な例として、ソース領域のデータとターゲット領域のデータから AutoEncoder により次元縮約を行

い、次元縮約したデータによりニューラルネットワークで学習を行うことを試してみる。学習では前述したように損失関数の損失値に本論文の提案手法から得られた重みを乗じて、それを損失値とした (図 1 参照)。B → E のみの実験であるが、表 4 と図 2 の結果が得られた。なお、この実験でのニューラルネットワークの学習は 25 epoch で終了させており、正解率は 25 epoch 後の学習によって得られたモデルをテストデータで評価した結果である。また次元縮約では 400 次元に縮約している。

表 4: ニューラルネットワークによる重み付き学習

IDEAL	NONE	NN	AE+NN	AE+NN+ 重み付け
0.852	0.761	0.743	0.690	0.695

チューニングが十分でなく、良い値は得られてはいないが、素性ベースの手法と事例ベースの手法を組み合わせることが、ニューラルネットワークで容易に実現できることがわかる。今後はこの枠組みでの領域適応の手法を考案したい。

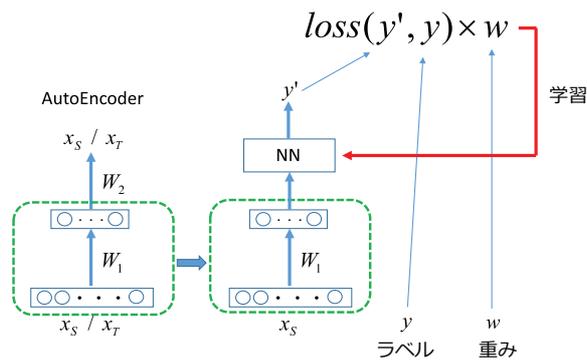


図 1: AE+NN+重み付き学習

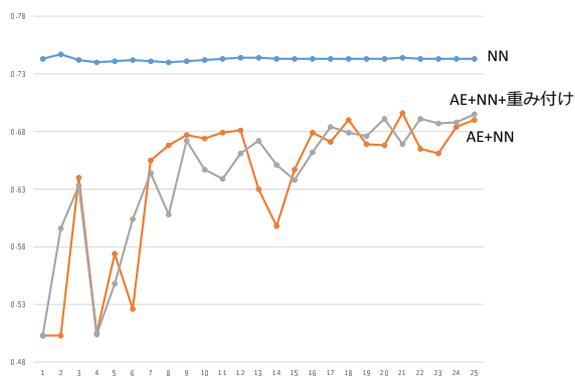


図 2: ニューラルネットワークによる重み付き学習

6 おわりに

本論文では感情分析の領域適応に対して、新たな事例ベースの手法を提案した。ターゲット領域からの IDF 値を利用してキーワードの度合いを定め、ソース領域におけるデータがどの程度ターゲット領域のキーワードを含むかというキーワード含有率を求め、そのキーワード含有率をデータの重みとする。実験では確率密度比を求める 2 つ手法と比較することで、提案手法の優位性を示した。ただし事例ベースの手法単独では領域適応に対して効果は少なく、今後素性ベースの手法を組み合わせたことが有効だと考える。その際にニューラルネットワークでの組み合わせが容易に実現できるため、今後はこの方向で研究を進めたい。

謝辞

本研究の一部は国立国語研究所の共同研究プロジェクト「all-words WSD システムの構築及び分類語彙表と岩波国語辞典の対応表作成への利用」の研究成果を

報告したものである。

参考文献

- [1] John Blitzer, Mark Dredze, and Fernando Pereira. Biographies, Bollywood, Boom-boxes and Blenders: Domain adaptation for Sentiment Classification. In *ACL-2007*, pp. 440–447, 2007.
- [2] John Blitzer, Ryan McDonald, and Fernando Pereira. Domain adaptation with structural correspondence learning. In *EMNLP-2006*, pp. 120–128, 2006.
- [3] Daumé III, Hal. Frustratingly Easy Domain Adaptation. In *ACL-2007*, pp. 256–263, 2007.
- [4] Yaroslav Ganin and Victor S. Lempitsky. Unsupervised domain adaptation by backpropagation. In *ICML*, pp. 1180–1189, 2015.
- [5] Xavier Glorot, Antoine Bordes, and Yoshua Bengio. Domain Adaptation for Large-Scale Sentiment Classification: A Deep Learning Approach. In *ICML-11*, pp. 513–520, 2011.
- [6] Sinno Jialin Pan and Qiang Yang. A survey on transfer learning. *Knowledge and Data Engineering, IEEE Transactions on*, Vol. 22, No. 10, pp. 1345–1359, 2010.
- [7] Baochen Sun, Jiashi Feng, and Kate Saenko. Return of Frustratingly Easy Domain Adaptation. *AAAI*, 2016.
- [8] Baochen Sun and Kate Saenko. Deep coral: Correlation alignment for deep domain adaptation. In *Computer Vision–ECCV 2016 Workshops*, pp. 443–450, 2016.
- [9] Eric Tzeng, Judy Hoffman, Kate Saenko, and Trevor Darrell. Adversarial discriminative domain adaptation. *arXiv preprint arXiv:1702.05464*, 2017.
- [10] Makoto Yamada, Taiji Suzuki, Takafumi Kanamori, Hirotaka Hachiya, and Masashi Sugiyama. Relative density-ratio estimation for robust distribution comparison. *Neural Computation*, Vol. 25, No. 5, pp. 1370–1370, 2011.
- [11] 新納浩幸, 佐々木稔. 共変量シフトの問題としての語義曖昧性解消の領域適応. *自然言語処理*, Vol. 21, No. 1, pp. 61–79, 2014.