

素性ベース手法と事例ベース手法の組合せ手法による 感情分析の領域適応

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

{17nm719x, hiroyuki.shinnou.0828, kanako.komiya.nlp}@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、素性ベースの手法と事例ベースの手法をニューラルネットワークによって組み合わせて利用する手法を提案する。

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 [7]。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。一般に事例ベースの手法単独では効果が少なく、素性ベースの手法が利用される。

ただし事例ベースの手法と素性ベースの手法は簡単に組み合わせることができる。ここではニューラルネットワークを利用してこの組み合わせを行い、素性ベースの手法のみからの精度の改善を目指す。

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 [4] 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 [7]。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。

素性ベースの手法の基本的な考え方はソース領域とターゲット領域の共通空間にそれぞれのデータをマッピングし、共通空間上で学習と識別を行うというものである。共通空間の求め方としては、単純には、ソース領域とターゲット領域を合わせた空間を特異値分解などで次元縮約を行えばよい。古典的手法である SCL [3] や近年提案されている CORAL [8] なども、この考え方に基づいている。さらに素性ベースの手法は深層学習とも相性がよく [6]、CORAL を拡張した手法 [9] や敵対的生成ネットワークを利用した手法 [5][10] が SOTA である。

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 [11] 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 [12] では領域 R でのデータ \mathbf{x} が素性リスト $\{f_1, f_2, \dots, f_n\}$ で表現できるとき $P_R(\mathbf{x}) = \prod_{i=1}^n P_R(f_i)$ 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。

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

また単語の重要度をターゲット領域での IDF 値により測り、重要単語がどの程度文書に存在するかによって文書事例に重みを付けた事例ベースの手法も提案されている [1]。本論文の事例ベースの手法には、この手法を用いる。

データ x に対して事例ベースの手法からその重み w を求め、また素性ベースの手法から x を x' に変換し、 x' に重み w を付けて学習させることで、事例ベースの手法と素性ベースの手法を容易に組み合わせることができる。論文 [12] では Daumé の手法 [4]¹ と事例ベースの手法を組み合わせて利用している。

3 ニューラルネットワークによる重み付き学習

一般にニューラルネットワークによる学習はデータ x とそのラベル y を用意し、 x に対するその時点でのネットワークの出力 y' を求め、 y と y' の差に対応する損失 $loss$ からネットワークのパラメータを更新することで行われる (図 1 参照)。

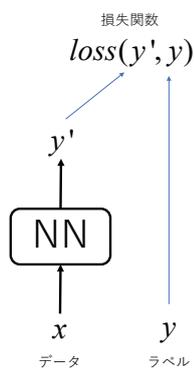


図 1: 一般のニューラルネットワーク

ニューラルネットワークによる重み付き学習の実装は非常に容易である。 x の重みを w としたとき、先の操作でも求まる損失 $loss$ に w を乗じ、それを損失 $loss$ とすれば良いだけある (図 2 参照)。

3.1 利用する事例ベースの手法

ここで利用する事例ベースの手法は論文 [1] で提案されたものである。

¹Daumé の手法は教師ありの素性ベースの手法とみなせる。

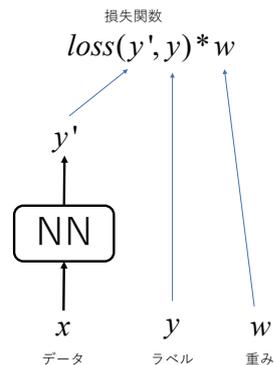


図 2: 重み付きのニューラルネットワーク

ここでは単語 w がターゲット領域においてどの程度重要語とみなせるかという度合い d_w 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。

$$d_w = \log \left(\frac{N}{n_w} \right) + 1$$

ここで N はターゲット領域の文書集合の文書数、 n_w 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。

上記 d_w を利用して、ソース領域の事例 x の重み o_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 o_x を以下の式で定める。

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

3.2 利用する素性ベースの手法

ここで利用する素性ベースの手法は特異値分解である。

ソース領域の文書とターゲット領域の文書をすべて合わせた索引語文書行列を作成する。この行列を特異値分解することで、文書に対応するベクトル x を 200 次元に縮約したベクトル s_x を作成する。この x と s_x とを結合したベクトル $[x; s]$ を、その文書のベクトルとする。

4 実験

実験では Amazon dataset [2] を用いる。具体的には以下のサイトで公開されている

表 1: 実験結果

	IDEAL	NN	NN+SVD	NN+SVD+WT
B → D	0.822	0.810	0.797	0.817
B → E	0.852	0.729	0.738	0.745
B → K	0.878	0.766	0.774	0.776
D → B	0.831	0.773	0.775	0.764
D → E	0.852	0.748	0.749	0.763
D → K	0.878	0.795	0.774	0.789
E → B	0.831	0.735	0.741	0.732
E → D	0.822	0.735	0.745	0.743
E → K	0.878	0.866	0.866	0.864
K → B	0.831	0.720	0.742	0.740
K → D	0.822	0.756	0.756	0.744
K → E	0.852	0.862	0.858	0.861
平均	0.846	0.775	0.776	0.778

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 2 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 2: 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

領域適応としては、B → D、B → E、B → K、D → B、D → E、D → K、E → B、E → D、E → K、K → B、K → D、K → E の 12 通りが存在する。それぞれの領域適応に対して、前章で述べた事例ベースの手法を利用して重みを求め、素性ベースの手法を利用して事例を変換した。

利用したネットワークは 4 層の全結合型のものである。入力層のノード数は領域適応ごとに異なるが、第 2 層で 400 次元に変換し、第 3 層で 200 次元に変換し、出力層で 2 次元 (positive と negative) に変換する。30 epoch まで学習し、各 epoch 毎にモデルを保

存し、各モデルでテストデータに対する正解率を測定した。それらの正解率の最大のものでその手法での正解率とした。

手法としては単にソース領域の訓練データだけを使ったもの (NN)、それに素性ベースの手法を利用したもの (NN+SVD) および事例ベースの手法と素性ベースの手法を組み合わせたもの (NN+SVD+WT) を試した。

実験の結果を表 1 に示す。なお IDEAL はターゲット領域の訓練データから SVM で識別器を学習し、その識別器でターゲット領域のテストデータを識別した結果である。各領域適応における正解率の平均で見ると、

$$\text{NN} < \text{NN+SVD} < \text{NN+SVD+WT}$$

となっており、素性ベースの手法が領域適応として機能し、さらに事例ベースの手法と組み合わせた効果も見られた。

5 考察

表 1 の結果を見ると利用した素性ベースの手法や事例ベースの手法が必ずしも良い結果を出すとは言えないことがわかる。概略、B → * や D → * のタイプでは素性ベースの手法と事例ベースの手法を組み合わせる効果が出ているが、逆に E → * や K → * のタイプ

では事例ベースの手法を組み合わせることが逆効果になっている。

これらの原因の調査は今後の課題である。

また本論文での組み合わせ手法では事例ベースの手法や素性ベースの手法を問わない。ここでは論文 [1] で示された事例の重み付けを行ったが、それに代えて論文 [12] で示された事例の重み付けを行ってみる。具体的には式 1 により事例の重みを算出する。この結果をこの結果を 3 に示す。NN+SVD+WT2 が式 1 による重みを使った場合を意味する。NN+SVD+WT2 の評価値 0.763 は NN の評価値 0.775 よりも大きく下がっている。つまり素性ベースの手法と事例ベースの手法を組み合わせる場合、組み合わせることはどのような手法でも可能だが、組み合わせることで効果が出るかどうかは手法にも依存していると言える。

表 3: 別種の事例ベースの手法の利用

	NN+SVD+WT	NN+SVD+WT2
B → D	0.817	0.803
B → E	0.745	0.712
B → K	0.776	0.754
D → B	0.764	0.747
D → E	0.763	0.732
D → K	0.789	0.779
E → B	0.732	0.744
E → D	0.743	0.740
E → K	0.864	0.862
K → B	0.740	0.716
K → D	0.744	0.722
K → E	0.861	0.840
平均	0.778	0.763

また本論文で示した手法ではニューラルネットワークの部分も変更可能である。単純なフィードフォワード型への変更だけでなく、出力値とラベルから損失を測る仕組みを持ったネットワークであればよい。近年、敵対的生成ネットワークを利用した領域適応の手法 [5][10] が高い精度を示しており、今後はこれらの手法と事例ベースの手法を組み合わせることを試していきたい。

6 おわりに

本論文では感情分析の領域適応に対して、素性ベースの手法と事例ベースの手法をニューラルネットワークによって組み合わせて利用する手法を提案した。素性ベースの手法として特異値分解、事例ベースの手法としてターゲット領域の重要語をどの程度含むかで事

例の重みを定義した論文 [1] の手法、そしてデータセットとして Amazon Dataset を用いて、提案手法の効果を確認した。

今後はネットワークとして敵対的生成ネットワークを利用して、そこに事例ベースの手法を組み合わせることを試みたい。

参考文献

- [1] Jing Bai, Hiroyuki Shinnou, and Kanako Komiya. Domain Adaptation for Sentiment Analysis using Keywords in the Target Domain as the Learning Weight. In *PACLIC-32*, 2018.
- [2] 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.
- [3] John Blitzer, Ryan McDonald, and Fernando Pereira. Domain adaptation with structural correspondence learning. In *EMNLP-2006*, pp. 120–128, 2006.
- [4] Daumé III, Hal. Frustratingly Easy Domain Adaptation. In *ACL-2007*, pp. 256–263, 2007.
- [5] Yaroslav Ganin and Victor S. Lempitsky. Unsupervised domain adaptation by backpropagation. In *ICML*, pp. 1180–1189, 2015.
- [6] 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.
- [7] 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.
- [8] Baochen Sun, Jiashi Feng, and Kate Saenko. Return of Frustratingly Easy Domain Adaptation. *AAAI*, 2016.
- [9] Baochen Sun and Kate Saenko. Deep coral: Correlation alignment for deep domain adaptation. In *Computer Vision–ECCV 2016 Workshops*, pp. 443–450, 2016.
- [10] Eric Tzeng, Judy Hoffman, Kate Saenko, and Trevor Darrell. Adversarial discriminative domain adaptation. *arXiv preprint arXiv:1702.05464*, 2017.
- [11] 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.
- [12] 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.