

## 分野に依存しない単語極性を考慮した評判分析のための転移学習モデル

吉田 康久<sup>†</sup> 平尾 努<sup>††</sup> 岩田 具治<sup>††</sup> 永田 昌明<sup>††</sup> 松本 裕治<sup>†</sup><sup>†</sup> 奈良先端科学技術大学院大学 情報科学研究科<sup>††</sup> 日本電信電話株式会社 NTT コミュニケーション科学基礎研究所

## 1 はじめに

近年評判分析に関する研究が数多くされている [9]。中でも、文書を肯定、否定、または中立(肯定、否定のどちらでもない)に分類するというタスクが盛んに研究されている。

評判分析で機械学習を使うときの特微量として単語の極性がよく利用されるが、単語によっては分野の情報なしには極性が決定できない。例えば 'long' という単語があったときに、カメラの分野であれば「バッテリーの寿命が長い」という意味になり、PC ソフトの分野であれば「プログラムの処理時間が長い」という意味になりうる。分野数が少数に限定されていれば、分野ごとの単語極性辞書を作ることで対処できるが、実際のデータ(例えば Multi-Domain Sentiment Dataset[2])には、極めて多様な分野が存在しており、事前に辞書を構築しておくことは現実的ではない。本稿では、このような分野により極性が決定される単語の生成過程をモデル化した。

上述したような多様な分野に対応するために「ある分野での学習結果を別の分野で生かせないだろうか?」と考えるのは自然な発想である。このような発想が元になって研究されている分野として転移学習がある。転移学習は新しい分野(転移先)で効果的かつ、効率的に問題を解くために別の関連した分野(転移元)のデータや学習結果を再利用しようというものである [8]。本稿では、転移学習の考え方をを用いて、分野に依存して極性が決まる単語とそうでない単語を区別することで転移がうまくいくように単語の生成過程をモデル化した。

本稿では、転移元には文書極性が分かっている文書が入手可能であり、転移先の文書には極性が分かっていない場合を想定しているが、提案手法を転移元に部分的に文書極性が存在しない場合や転移先にも文書極性が部分的に存在する場合への拡張も容易である。

本稿の貢献は3つある。

1. 極性を持った単語が分野依存、非依存を考慮して生成される過程をモデル化した。分野に依存しない極性を持った単語に着目することで、このモデルは転移元や転移先の分野数が複数になった場合でも対応でき、特に分野が多様である評判分析において非常に重要な特徴である。
2. 事後分布を直接計算するのは困難であるので、Gibbs Sampling による効率的なアルゴリズムを考案した。
3. 提案した手法を実データ [2] に応用し、分野依存性を考えないベースラインモデルと比較して、その有効性を示した。

本稿の構成は以下の通りである。2章ではこれまでの評判分析や転移学習のアプローチ、本稿との差違について述べ、3章では本稿で提案するモデルの詳細について述べる。4章では今回の実験で使用したデータや実験の結果について述べ、5章では、今後の展望などについて述べる。

## 2 関連研究

## 2.1 Joint Sentiment-Topic Model

Lin ら [5] は文書のトピックと極性の両方を考えた生成モデル Joint Sentiment-Topic (JST) Model を提案している。評判分析において、単語の極性判定は重要な要素

であり、例えば Takamura ら [10] はスピンモデルを使い単語の極性をモデル化している。JST でも単語の極性に対応する隠れ変数がモデルに組み込まれている。また、トピックに対応する隠れ変数も同時に考えることで、トピック毎に肯定、否定の軸で文書を見られるのが特徴である。しかし、JST ではトピックを扱ってはいるものの、分野の違い(分野ラベル)を考慮しているわけではない。ここで、「トピック」とはモデルによって決定される単語の意味を扱うような潜在的な変数であり、「分野」とは文書に与えられたカテゴリのような観測済みの変数のことを指す。一方、本稿で提案するモデルは JST と同様に単語極性を生成モデルを使って自然に表現しながらも、文書に付いている分野ラベルを観測済みの変数として取り扱うことで転移学習に向けたモデルとなっている。

## 2.2 Structural Correspondence Learning

Ando らは Structural Correspondence Learning (SCL) を提案しており [1]、Blitzer らがそれを用いた転移学習手法を提案している [3]。SCL の概要を Algorithm 1 にまとめた。このアルゴリズムでは、文書極性と相互情報量が高い単語を pivot feature と呼び、補助問題として、ある pivot feature をそれ以外の素性で説明させる二値分類問題を解く。補助問題を解く際には文書極性は必要ないので、転移元と転移先の文書極性が付いていないデータも利用することができる点に注意されたい。SCL では、pivot feature を転移学習の手掛かりとしてそれぞれの分野特有の極性に関係する単語を結び付けている。例えば、転移元の分野を携帯電話、転移先の分野をコンピューターとした時、“good-quality reception”や“fast dual-core”はそれぞれの分野における肯定的な単語であるが、これらの単語はそれぞれの分野のみ登場する単語と考えられる。これらの単語のみではうまく転移学習ができないが、SCL ではこれらの単語が“excellent”などの単語と共起しやすいことを主要なアイデアとしてアルゴリズムを構成している。SCL を Amazon のレビューデータに適用した結果、転移学習がうまく機能し、高い分類性能を示したとの報告がある [2]。

しかし、SCL において pivot feature は転移元の文書極性との相互情報量が高い単語と定義されているだけであり、これでは教師ラベルと関連の高い転移元特有の単語も pivot feature となりうる。転移学習では分野に依存せずクラス分類に寄与する単語を得ることが重要であるが、SCL ではこれを正確にモデル化しているとは言えない。そこで、本稿では、Lin ら [5] のように生成モデルのアプローチから、分野に依存しない単語極性を極めて自然な形でモデル化した。

また、SCL では転移元と転移先の分野数が1つずつの場合にしか対応できない。上述の通り評判分析ではデータとして多様な分野が存在するので、転移元、転移先の分野数が増加した場合にも分野の違いを考慮しながら自然に扱えるモデル望ましい。本稿で提案するモデルは、転移元、転移先の分野数が複数ある場合にも分野の違いを考慮できる。

## 3 提案手法

本章では提案手法の詳細について述べる。本稿で使う記号、変数の表記一覧を表1にまとめた。

提案手法では、単語  $w_n$  に対して単語極性  $l_n$  と分野依

### Algorithm 1 Structural Correspondence Learning

**入力:** 転移元のラベル付きデータ  $\{(\mathbf{x}_t, y_t)_{t=1}^T\}$  と転移元と転移先のラベルなしデータ  $\{x_j\}$

**出力:** 識別器  $f: X \rightarrow Y$

**Step 1:** 教師ラベルとの相互情報量が高い  $m$  個の素性を選択し、それらを pivot feature とする。補助問題として、ある pivot feature をそれ以外の feature で説明させる  $m$  個の二値分類問題を作る (その問題に対する識別器を  $p_l(\mathbf{x})$  を作る ( $l = 1, \dots, m$ ))。

**Step 2:** 全ての pivot feature に対して以下の重みベクトルを求める ( $L$  は損失関数)。

$$\hat{\mathbf{w}}_l = \arg \min_{\mathbf{w}} \left( \sum_j L((\mathbf{w}^T \mathbf{x}_j, p_l(\mathbf{x}_j)) + \lambda \|\mathbf{w}\|^2) \right)$$

**Step 3:** Step 2 で求めた重みベクトルを連結し、 $W = (\hat{\mathbf{w}}_1, \dots, \hat{\mathbf{w}}_m)$  とする。この  $W$  に対し、SVD を実行する ( $(UDV^T)^T = \text{SVD}(W)$ )。行列分解してできた行列のうち、 $U$  の上位  $h$  個の特異値に対応するベクトルをまとめて  $\theta = U_{[1:h,:]}^T$  とする。

**Step 4:** データ  $\left\{ \left\{ (\mathbf{x}_t, \theta \mathbf{x}_t)^T, y_t \right\}_{t=1}^T \right\}$  に対して識別器  $f$  を構築。

表 1: 本稿で使う変数の説明

表記	説明
$D, D_s, D_t$	全文書数、転移元の文書数、転移先の文書数 ( $D = D_s + D_t$ )
$F$	分野の数
$S$	極性の数 (今回は 3 に固定)
$V$	総単語数
$N_d$	文書 $d$ 中の単語の数
$w_{d,n}$	文書 $d$ の $n$ 番目の単語
$y_d, y_d^{(s)}, y_d^{(t)}$	文書 $d$ の極性、転移元の文書 $d$ の極性、転移先の文書 $d$ の極性 (0 なら否定、1 なら肯定を表わす)
$z_{d,n}$	文書 $d$ の $n$ 番目の単語が分野に特有な単語かを表わす indicator 変数
$l_{d,n}$	文書 $d$ の $n$ 番目の単語の極性 (0 なら否定、1 なら肯定、2 なら中立を表わす)
$f_d$	文書 $d$ の分野

存性  $z_n$  を隠れ変数としてモデル化する。単語極性  $l_n$  は、単語  $w_n$  が肯定的な意味の単語である ( $l_n = 1$ ) か、否定的な意味の語である ( $l_n = 0$ ) か、中立的な単語である ( $l_n = 2$ ) かを表わす。分野依存性  $z_n$  は、単語  $w_n$  が分野に依存した単語である ( $z_n = 1$ ) か、そうでないか ( $z_n = 0$ ) を表わす。隠れ変数  $l_n, z_n$  とを用いることにより、単語  $w_n$  に関して分野に依存 { する, しなない } { 肯定, 否定, 中立 } の組み合わせがある。これを分野の数だけ考えることから、単語  $w_n$  は  $S \times Z \times F$  の状態のいずれかを取る。しかし、分野に依存しない単語は肯定、否定、中立ごとにまとめることができるので、最終的な全体の状態数としては  $S \times (F+1)$  となる。ここで、 $z_n = 0$  かつ  $l_n = 0, 1$  の時に  $w_n$  は分野に依存しない極性を持った単語となることに注意されたい。また、分野の情報  $f_d$  を観測済み変数として扱うことができ、分野間の違いを扱えることから転移元、転移先の分野が多対多のものも扱うことができる。

次に文書  $d$  の極性  $y_d$  がどのように決定されるかだが、 $P(y_d = m)$  はその文書に含まれている単語極性  $\{l_1, \dots, l_{N_d}\}$  が  $m$  である個数に比例して決定する。

以上をまとめると極性のついた文書の生成過程は以下のように書き表わせる。

1. For each sentiment  $l = 1, \dots, S$ :
  - (a) Draw word probability  $\phi_{0,l} \sim \text{Dirichlet}(\beta)$
  - (b) For each domain  $f = 1, \dots, F$ :
    - i. Draw word probability  $\phi_{1,l,f} \sim \text{Dirichlet}(\beta)$

2. For each document  $d = 1, \dots, D$ :
  - (a) Draw domain dependent probability  $\theta_d \sim \text{Dirichlet}(\alpha)$
  - (b) Draw word sentiment probability  $\psi_d \sim \text{Dirichlet}(\gamma)$
  - (c) For each word  $w_{d,n}$  in document  $d$ 
    - i. Draw  $z_{d,n} \sim \text{Multinomial}(\theta_d)$
    - ii. Draw  $l_{d,n} \sim \text{Multinomial}(\psi_d)$
  - (d) Draw  $w_{d,n} \sim \begin{cases} \text{Multinomial}(\phi_{0,l_{d,n}}) & (\text{if } z_{d,n} = 0) \\ \text{Multinomial}(\phi_{1,l_{d,n},f_d}) & (\text{if } z_{d,n} = 1) \end{cases}$
  - (e) Draw  $y_d \sim \text{Multinomial} \left( \frac{N_{d,0} + \eta}{N_{d,0} + N_{d,1} + 2\eta}, \frac{N_{d,1} + \eta}{N_{d,0} + N_{d,1} + 2\eta} \right)$

ここで、 $\phi_{0,l}, \phi_{1,l,f}, \theta_d, \psi_d$  はパラメータベクトルで、それぞれのベクトルの各要素は  $\phi_{0,l,w} = P(w|z = 0, l), \phi_{1,l,f,w} = P(w|z = 1, l, f)$  表わしており、 $\theta_{d,z}$  と  $\psi_{d,l}$  はそれぞれ文書  $d$  における  $P(z)$  と  $P(l)$  を表わしている。また、 $N_{d,0}$  は文書  $d$  中の否定の単語の数、 $N_{d,1}$  は文書  $d$  中の肯定の単語の数を表わしている。

ディリクレ分布のパラメータとして  $\alpha, \beta, \gamma$  があるが、これらは簡単化のため symmetric なものを使用した。またこの生成過程を図 1 のグラフィカルモデルで示す。このモデルの同時分布は以下のように条件付き確率




図 1: 提案手法のグラフィカルモデル

の積で書き表わすことができる。

$$P(\mathbf{w}, \mathbf{y}, \mathbf{z}, \mathbf{l} | \mathbf{f}, \alpha, \beta, \gamma, \eta)$$

$$= P(\mathbf{z} | \alpha) P(\mathbf{w} | \mathbf{z}, \mathbf{f}, \mathbf{l}, \beta) P(\mathbf{l} | \gamma) P(\mathbf{y} | \mathbf{l}, \eta) \quad (1)$$

ただし、 $\mathbf{w} = \{\{w_{d,n}\}_{n=1}^{N_d}\}_{d=1}^D, \mathbf{z} = \{\{z_{d,n}\}_{n=1}^{N_d}\}_{d=1}^D, \mathbf{l} = \{\{l_{d,n}\}_{n=1}^{N_d}\}_{d=1}^D, \mathbf{f} = \{f_d\}_{d=1}^D, \mathbf{y} = \{y_d\}_{d=1}^D$  である。(1) 式の第一項は  $P(\mathbf{z} | \alpha) = \prod_{d=1}^D \int P(\mathbf{z}_d | \theta_d) P(\theta_d | \alpha) d\theta_d$  であり、 $\{\theta_d\}_{d=1}^D$  を積分消去することにより、以下を得る。

$$P(\mathbf{z} | \alpha) = \left( \frac{\Gamma(Z\alpha)}{\Gamma(\alpha)^Z} \right)^D \prod_{d=1}^D \frac{\prod_{z=1}^Z \Gamma(N_{z,d} + \alpha)}{\Gamma(\sum_{z=1}^Z N_{z,d} + \alpha)} \quad (2)$$

ここで、 $N_{z,d}$  は  $z = 1$  のとき文書  $d$  中の分野に依存した単語の個数である。(1) 式の第二項、第三項も同様に  $\phi_{0,l}, \phi_{1,l,f}, \psi_d$  を積分消去することにより以下のように書き表わすことができる。

$$P(\mathbf{w} | \mathbf{z}, \mathbf{f}, \mathbf{l}, \beta) = \left( \frac{\Gamma(\beta V)}{\Gamma(\beta)^V} \right)^{(F+1)S}$$

$$\prod_{f=1}^F \prod_{s=1}^S \frac{\prod_{v=1}^V \Gamma(N_{v,1,s,f} + \beta)}{\Gamma(\sum_{v=1}^V N_{v,1,s,f} + \beta)} \prod_{s=1}^S \frac{\prod_{v=1}^V \Gamma(N_{v,0,s} + \beta)}{\Gamma(\sum_{v=1}^V (N_{v,0,s} + \beta))}$$

$$P(\mathbf{l} | \gamma) = \left( \frac{\Gamma(S\gamma)}{\Gamma(\gamma)^S} \right)^D \prod_{d=1}^D \frac{\prod_{s=1}^S \Gamma(N_{s,d} + \gamma)}{\Gamma(\sum_{s=1}^S N_{s,d} + \gamma)}$$

ここで、 $N_{v,1,s,f}$  は分野  $f$  に単語  $v$  が極性  $s$  かつ分野特有のものとして登場した回数、 $N_{v,0,s}$  は単語  $v$  が極性  $s$  かつ分野に依存しないものとして登場した回数、 $z = 0$  のとき文書  $d$  中の分野に依存した単語の個数、 $N_{s,d}$  は文書

$d$  中の極性が  $s$  の単語の個数である。(1) 式の第四項は多項分布であるから以下のように書ける。

$$P(\mathbf{y}|\mathbf{l}, \eta) = \prod_{d=1}^D \prod_{y=1}^Y \left( \frac{N_{d,y} + \eta}{N_{d,0} + N_{d,1} + 2\eta} \right)^{I(y_d=y)} \quad (3)$$

ただし、 $N_{d,y}$  は文書  $d$  中の極性が  $y$  の単語の個数、 $N_{d,0}$  は文書  $d$  中の極性が否定の単語の個数、 $N_{d,1}$  は文書  $d$  中の極性が肯定の単語の個数を表わしている。また、 $I(\cdot)$  は indicator 関数である。

### 3.1 サンプリングのための式の導出

隠れ変数  $\mathbf{z}$  と  $\mathbf{l}$  と  $\mathbf{y}^{(t)}$  の推論は collapsed Gibbs sampling によって効率的に行なうことができる [4]。ここで、 $\mathbf{y}^{(t)} = \{y_d^{(t)}\}_{d=1}^{D_t}$  である。転移元での隠れ変数は  $\mathbf{z}$  と  $\mathbf{l}$  の 2 種類、転移先での隠れ変数は  $\mathbf{z}$  と  $\mathbf{l}$  と  $\mathbf{y}^{(t)}$  の 3 種類あり、転移元でのサンプリングの式は以下となる。

$$P(z_n = j, l_n = k | \mathbf{w}, \mathbf{f}, \mathbf{y}^{(s)}, \mathbf{z}_{-n}, \mathbf{l}_{-n}, \alpha, \beta, \gamma, \eta) \\ \propto P(w_n | z_n = j, l_n = k, f_d, \mathbf{z}_{-n}, \mathbf{l}_{-n}, \beta) P(z_n = j | \mathbf{z}_{-n}, \alpha) \\ P(y_d^{(s)} | l_n = k, \mathbf{l}_{-n}, \eta) P(l_n = k | \mathbf{l}_{-n}, \gamma) \quad (4)$$

ただし、 $\mathbf{y}^{(s)} = \{y_d^{(s)}\}_{d=1}^{D_s}$  である。それぞれの要素は

$$P(w_n | z_n = 1, l_n = k, f_d, \mathbf{z}_{-n}, \mathbf{l}_{-n}, \beta) \\ = \frac{\{N_{w_n,1,k,f_d}\}_{-n} + \beta}{\sum_{w_n=1}^V \{N_{w_n,1,k,f_d}\}_{-n} + \beta} \\ P(w_n | z_n = 0, l_n = k, f_d, \mathbf{z}_{-n}, \mathbf{l}_{-n}, \beta) \\ = \frac{\{N_{w_n,0,k}\}_{-n} + \beta}{\sum_{w_n=1}^V \{N_{w_n,0,k}\}_{-n} + \beta}$$

$$P(z_n = j | \mathbf{z}_{-n}, \alpha) = \frac{\{N_{j,d}\}_{-n} + \alpha}{\sum_{j=1}^Z \{N_{j,d}\}_{-n} + \alpha}$$

$$P(y_d^{(s)} | l_n = k, \mathbf{l}_{-n}, \eta) \\ \propto \frac{(\{N_{d,k}\}_{-n} + \eta + 1)^{I(y_d^{(s)}=k)} (\{N_{d,1-k}\}_{-n} + \eta)^{I(y_d^{(s)}=1-k)}}{\{N_{d,0}\}_{-n} + \{N_{d,1}\}_{-n} + 2\eta + 1}$$

$$P(y_d^{(s)} | l_n = 2, \mathbf{l}_{-n}, \eta) \\ \propto \prod_{y=1}^Y \left( \frac{\{N_{d,y}\}_{-n} + \eta}{\{N_{d,0}\}_{-n} + \{N_{d,1}\}_{-n} + 2\eta} \right)^{I(y_d^{(s)}=y)}$$

$$P(l_n = k | \mathbf{l}_{-n}, \gamma) = \frac{\{N_{k,d}\}_{-n} + \gamma}{\sum_{k=1}^S \{N_{k,d}\}_{-n} + \gamma}$$

と書き表わせる。ここで、 $\{\cdot\}_{-n}$  はサンプル  $n$  を除いたときの回数を表わす。

次に転移先でのサンプリングの式について考えるが、 $\mathbf{z}$  と  $\mathbf{l}$  のサンプリングの式 ((4) 式) については転移元も転移先も変わらない。転移先での文書の極性  $\mathbf{y}^{(n)}$  のサンプリング式は以下となる。

$$P(y_d^{(n)} = m | \mathbf{l}, \eta) = \frac{N_{d,m} + \eta}{N_{d,0} + N_{d,1} + 2\eta} \quad (5)$$

ここで、 $N_{d,m}$  は文書  $d$  中の極性が  $m$  である単語の数である。

## 4 評価実験

### 4.1 データセットと実験設定

まず、実験に用いたデータセットと前処理について述べる。今回の実験には Blitzer らが公開している

Multi-Domain Sentiment Dataset[2] を使用した。データは Amazon のレビューデータであり、17 分野、10000 文書を使用した。レビューデータには 5 段階の rating が付いており、今回は rating が 4 と 5 のレビューを肯定の文書として、rating が 1 と 2 のレビューを否定の文書として扱っている。また、品詞フィルタリングを適用し、形容詞と副詞のみを使用した。'not' などの否定語がある場合、極性が反転することが考えられるが、ここでは 'not 形容詞' のような単純なパターンに従うものに対してはそれを一語と見なすことにした。

次に、実験の設定について述べる。Gibbs Sampling の Iteration は 300 回に設定し、最終的な文書の極性は (5) 式を元にサンプリングした最後の 50 回を元に決定した。ハイパーパラメータ  $\alpha, \beta, \gamma$  は Fixed Point Iteration[6] によって最適化した。ここでは、更新式の詳細は紙面の都合上省略する。また、予備実験の結果より、ハイパーパラメータ  $\eta$  は 1.5 に固定して実験した。文書極性の性能は  $\eta$  の値にそれほど敏感ではなかったことを報告しておく。

最後に評価方法について述べる。極性判定の性能は F 値によって評価した。本稿で提案するモデルはいわゆる Transductive Learning であり、学習時にテストデータも含む形で F 値を計測していることに注意されたい。

### 4.2 比較した手法

今回の実験は極性判定の精度向上が直接の目的ではなく、図 1 の分野依存の変数  $\mathbf{z}$  をモデルに取り込むことで、文書極性の構造をよりよく表現できるかを見るのが目的である。そこで、提案手法から分野依存変数  $\mathbf{z}$  と分野を表わす変数  $\mathbf{f}$  を取り除いたモデルをベースラインとした。

### 4.3 転移先のデータを固定し、転移元の分野数を増加させた場合の評価結果

転移学習を考える場合、どの分野を適用元の分野とし、どの分野を適用先の分野とするかは重要な問題である。なぜならば、分野間に高い類似性がある場合は転移は成功しやすく、低ければ成功するとは限らないからである [2]。今回の実験ではこのような影響をなるべく緩和するために、以下の設定で 10 回実験を行なった。

- Step 1 17 分野から転移先をランダムに 3 分野を選択
- Step 2 残り 14 分野から転移元をランダムに  $N$  分野を選択
- Step 3 転移先の 3 分野にて F 値で評価

ここでは、Step 2 でランダムに選んでくる転移元の分野数  $N$  を 1 から 14 まで増加させた場合について見ていく。評価結果を図 2(a) に示す。転移元のドメイン数を増やしていくと、転移元のドメインでのサンプル数も増加するため、提案手法、ベースラインともに F 値がほぼ単調に増加していくことが確認できる。また、提案手法は転移元の分野の数に係らずベースラインと比較して一貫して高い F 値を示していることが分かる。これはベースラインでは単語極性が分野特有なものかどうかを考えていないモデルであるのに対して、提案手法では単語毎に分野特有なものかを考えており、それが文書極性を考えることに有効であることからこのような結果になったと考える。

また、Blitzer らの提案する SCL[3] でも、転移元と転移先の分野の違いを考慮することはできるが、転移元が一つの分野の場合にしか対応することができない。しかし、提案手法では転移元の分野数が複数の場合においても自然に対応することが可能であり、これは SCL にはない大きな特徴であると言える。

#### 4.4 転移元のデータを固定し、転移先の分野数を増加させた場合の評価結果

本節では、転移元のデータを固定、転移先の分野数を増加させた場合の極性判定の性能を見ていくが、前節と同様にこの問題設定の場合も転移元と転移先の分野がどれだけ類似しているかが極性判定の性能に大きく影響を及ぼす。そのため、本節でも前節の Step 1 から Step 3 において転移元と転移先を入れ替えた設定で実験を 10 回行った。ここでは転移元の分野数を 3 に固定した元で、転移先の分野数  $N$  を 1 から 14 まで増加させた場合の評価結果を図 2(b) に示す。転移先の分野数を増やしていくとベースライン、提案手法ともに F 値が低下してしまっていることが確認できる。これはラベルありデータに対してラベルなしデータの数が多くなりすぎたことが原因と考えられ、同様の現象は半教師あり学習などでも見られる。Nigam ら [7] はラベルなしデータに対する重み入を導入し、この問題を解決しようとしたが、この方法は入に対して非常に敏感であり、調整が非常に難しい。本稿では、このラベルなしデータに対する重みをどうするかという問題に対しては取り扱わない。しかしながら、分野依存変数  $z$  と分野を表わす変数  $f$  を考えることにより提案手法ではベースラインと比較して F 値の低下を抑えられていることが図 2(b) より分かる。

#### 4.5 分野依存、非依存の単語

ここでは、各分野において特徴的な単語がどのようなものだったかについて述べる。ここでは、 $P(w|l, z, f) = \phi_{z,l,f}$  の確率上位であった単語を挙げる。実験の設定としては、転置元の分野として 'Books', 'DVD', 'Electronics' を、転移先の分野として 'Kitchen' を使用した。その結果を表 2、表 3 に示す。

表 2 では 'great', 'bad' などの分野に依存しないで肯定か否定かが決定できるような単語が取れており、表 3 では 'comfortable', 'responsive', 'useless', 'functionally' などの分野依存な肯定な単語や否定な単語が確率上位の単語にきており、提案手法がうまく機能していることが分かる。

### 5 おわりに

本稿では、分野の違いを考慮に入れた文書の極性を判定するための生成モデルを提案した。モデルのパラメータの推論は Gibbs Sampling で効率的に行なうことができる。転移元ドメイン数と共に転移元のサンプル数を増加させると文書極性分類についての F 値が向上していき、ベースラインと比較して最大 5 ポイント程度の F 値の向上があった。また、転移先ドメイン数と共に転移先のサンプル数を増加させると F 値が減少してしまっていることが分かった。モデルにより抽出された分野に依存した肯定、否定な単語は分野特有の単語が抽出されており、これを生かした分野毎の単語極性辞書の作成などが可能となっている。今度の課題としては、転移先の分野数を増やしたときに F 値を下げないようにラベルなしデータの影響を相対的に下げようモデルの工夫をすることなどが挙げられる。

### 参考文献

[1] Rie Kubota Ando and Tong Zhang. A framework for learning predictive structures from multiple tasks and unlabeled data. *J. Mach. Learn. Res.*, Vol. 6, , December 2005.  
 [2] John Blitzer, Mark Dredze, and Fernando Pereira. Biographies, bollywood, boom-boxes and blenders: Domain adaptation for sentiment classification. In *ACL*, Prague, Czech Republic, 2007.

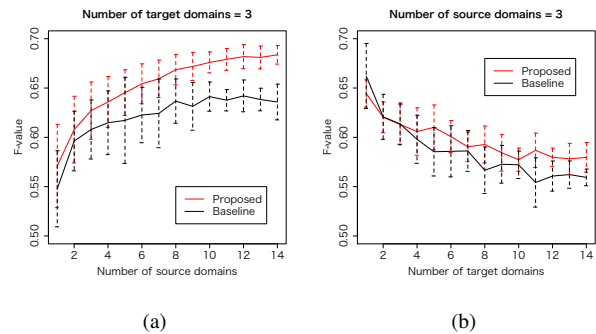


図 2: 10 回の実験の F 値の平均 (実線) と標準偏差 (破線) (a) 転移先分野数を 3 に固定、転移元分野の数を変化させた場合の F 値 (b) 転移元分野数を 3 に固定、転移先分野の数を変化させた場合の F 値

表 2: 分野非依存な単語

極性	確率の高い単語
肯定	great good best excellent worth certainly easily happy particularly quickly deep quick not_really professional fantastic incredible solid effective beautifully potential
否定	bad instead actually wrong unfortunately completely poor worst second short nearly extremely possible worse not_good actual fairly just_not disappointed entirely
中立	quite long right away old probably pretty simply big large amazing white free apparently huge exactly forward open normal older

表 3: 分野依存な単語 (Electronics 分野での例)

極性	確率の高い単語
肯定	easy sound small remote fast comfortable perfectly cool external cheaper decent light pleased green crisp compatible higher optical comfortably responsive
否定	new cheap useless slow defective directly newer static blank quiet flat uncomfortable convenient currently daily glad flimsy verbatim soft tiny lighter
中立	little nice digitallonger low loud inexpensive video audio not_sure properly multiple faulty bulky stylishjust_fine protective manually bright double prior outer

[3] John Blitzer, Ryan McDonald, and Fernando Pereira. Domain adaptation with structural correspondence learning. In *EMNLP*. Association for Computational Linguistics, 2006.  
 [4] Thomas L. Griffiths and Mark Steyvers. Finding scientific topics. *PNAS*, Vol. 101, No. suppl. 1, 2004.  
 [5] Chenghua Lin, Yulan He, and Richard Everson. A comparative study of bayesian models for unsupervised sentiment detection. In *CoNLL*, CoNLL '10. Association for Computational Linguistics, 2010.  
 [6] Thomas P. Minka. Estimating a Dirichlet distribution. 2003.  
 [7] Kamal Nigam, Andrew K. McCallum, Sebastian Thrun, and Tom Mitchell. Text Classification from Labeled and Unlabeled Documents using EM. *Machine Learning*, Vol. 39, No. 2, May 2000.  
 [8] Sinno J. Pan and Qiang Yang. A Survey on Transfer Learning. Technical report, 2008.  
 [9] Bo Pang, Lillian Lee, and Shivakumar Vaithyanathan. Thumbs up? Sentiment Classification using Machine Learning Techniques, 2002.  
 [10] Hiroya Takamura, Takashi Inui, and Manabu Okumura. Extracting semantic orientations of words using spin model. In *ACL*, 2005.