

TokyoCL 第2回勉強会

論文紹介:

A Log-Linear Model for Unsupervised Text Normalization

(Yang and Eisenstein, EMNLP 2013)

持橋大地

統計数理研究所

daichi@ism.ac.jp

2015-11-20 (金)

論文の概要

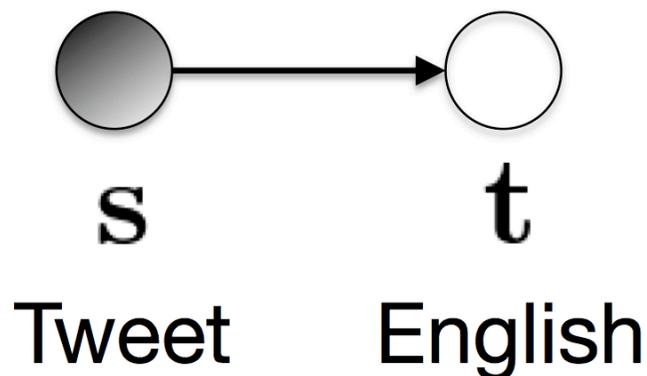
- “gimme suttin 2 beleive inn.” のような文を
教師なしで
“give me something to believe in.”
に変換する
- 隣の単語も間違っている可能性
→ 単語別にやってもダメ、系列全体を探索
- 通常の動的計画法では、 $O(V^2)$ の行列を
計算する必要があって無理 ($V=10000$ 以上)
→ Particle Filterで効率的に微分を計算

教師なし正規化の重要性

- Twitterやチャットのような口語的なメディアは、崩れた表記がごく普通（「不自然言語処理」）
 - “Finna hit a lick on my gramma for that burple slurr”
 - “If dis video doing rounds in watsap on bihar electns is true Mayb d election commisn”
- 日本語ではそもそも異表記が普通
 - 「みる」「なく」「ふむ」
 - 「日弁連」「かにしの」「こなみ」・・・
- 教師データを全部作るのは不可能 (固定ではない)

問題の定式化

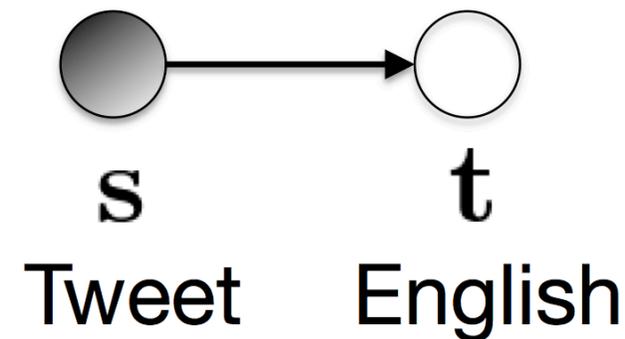
- 以下、Twitterのようなテキストから普通の言葉に変換する問題を考える



- 意味的には s, t が逆だが (t が本当は情報源)、ここでは以下、論文の記法に従う

目的関数

- 観測した文の確率を最大化する



$$\begin{aligned}\text{maximize } \log p(\mathbf{s}) &= \log \sum_{\mathbf{t}} p(\mathbf{s}, \mathbf{t}) \\ &= \log \sum_{\mathbf{t}} p(\mathbf{s}|\mathbf{t})p(\mathbf{t})\end{aligned}$$

- ここで $p(\mathbf{t})$ は正しい文の言語モデル、
 $p(\mathbf{s}|\mathbf{t})$ は対数線形モデルによる誤りモデル

$$p(\mathbf{s}|\mathbf{t}, \theta) = \frac{\exp(\theta^T f(\mathbf{s}, \mathbf{t}))}{Z}$$

誤りモデル＝翻訳モデル

$$p(\mathbf{s}|\mathbf{t}, \theta) = \frac{\exp(\theta^T f(\mathbf{s}, \mathbf{t}))}{Z}$$

- $Z(\theta)$ は正規化項で、

$$Z(\theta) = \sum_{\mathbf{s}} \exp(\theta^T f(\mathbf{s}, \mathbf{t}))$$

- 表記誤りについての素性 $f(\mathbf{s}, \mathbf{t})$ はContractor+(2010)のものを用いる
 - “you”-“u” のような直接の単語ペア
 - 単語 \mathbf{s} が単語 \mathbf{t} に文字列として何番目に近いか

目的関数の微分

- パラメータは θ なので、 θ に関して目的関数を微分

$$L = \log \sum_{\mathbf{t}} p(\mathbf{s}|\mathbf{t}, \theta) p(\mathbf{t})$$

$$\frac{\partial L}{\partial \theta} = \frac{1}{p(\mathbf{s})} \sum_{\mathbf{t}} p(\mathbf{t}) \frac{\partial}{\partial \theta} p(\mathbf{s}|\mathbf{t}, \theta)$$

- $\frac{\partial}{\partial \theta} p(\mathbf{s}|\mathbf{t}, \theta)$ が問題だが..

目的関数の微分 (2)

$$p(\mathbf{s}|\mathbf{t}, \theta) = \frac{\exp(\theta^T f(\mathbf{s}, \mathbf{t}))}{Z(\theta)}$$

なので、

$$\begin{aligned} & \frac{\partial}{\partial \theta} p(\mathbf{s}|\mathbf{t}, \theta) \\ &= \frac{(\exp(\theta^T f(\mathbf{s}, \mathbf{t})))' Z(\theta) - \exp(\theta^T f(\mathbf{s}, \mathbf{t})) Z(\theta)'}{Z(\theta)^2} \\ &= \frac{f(\mathbf{s}, \mathbf{t}) \exp() \cdot Z(\theta) - \exp() \cdot Z(\theta)'}{Z(\theta)^2} \end{aligned}$$

目的関数の微分 (3)

- ここで

$$Z(\theta) = \sum_{\mathbf{s}} \exp(\theta^T f(\mathbf{s}, \mathbf{t}))$$

$$\frac{\partial}{\partial \theta} Z(\theta) = \sum_{\mathbf{s}} f(\mathbf{s}, \mathbf{t}) \exp(\theta^T f(\mathbf{s}, \mathbf{t}))$$

なので、

目的関数の微分 (4)

$$\begin{aligned} & \frac{\partial}{\partial \theta} p(\mathbf{s}|\mathbf{t}, \theta) \\ &= \frac{f(\mathbf{s}, \mathbf{t}) \exp() \cdot Z(\theta) - \exp() \cdot Z(\theta)'}{Z(\theta)^2} \\ &= \frac{f(\mathbf{s}, \mathbf{t}) \exp()}{Z(\theta)} - \frac{\exp() \cdot \sum_{\mathbf{s}'} f(\mathbf{s}', \mathbf{t}) \exp()}{Z(\theta)^2} \\ &= p(\mathbf{s}|\mathbf{t}, \theta) \left[f(\mathbf{s}, \mathbf{t}) - \sum_{\mathbf{s}'} f(\mathbf{s}, \mathbf{t}) p(\mathbf{s}'|\mathbf{t}, \theta) \right] \end{aligned}$$

- よって、

目的関数の微分 (5)

$$\begin{aligned}\frac{\partial L}{\partial \theta} &= \frac{1}{p(\mathbf{s})} \sum_{\mathbf{t}} p(\mathbf{t}) \frac{\partial}{\partial \theta} p(\mathbf{s}|\mathbf{t}, \theta) \\ &= \frac{1}{p(\mathbf{s})} \sum_{\mathbf{t}} p(\mathbf{t}) p(\mathbf{s}|\mathbf{t}, \theta) \left[f(\mathbf{s}, \mathbf{t}) - \sum_{\mathbf{s}'} f(\mathbf{s}', \mathbf{t}) p(\mathbf{s}'|\mathbf{t}, \theta) \right] \\ &= \sum_{\mathbf{t}} p(\mathbf{t}|\mathbf{s}) \left[f(\mathbf{s}, \mathbf{t}) - \sum_{\mathbf{s}'} p(\mathbf{s}'|\mathbf{t}, \theta) f(\mathbf{s}', \mathbf{t}) \right] \\ &= E_{\mathbf{t}|\mathbf{s}} \left[f(\mathbf{s}, \mathbf{t}) - E_{\mathbf{s}'|\mathbf{t}} [f(\mathbf{s}', \mathbf{t})] \right]\end{aligned}$$

何が問題か？

$$\frac{\partial L}{\partial \theta} = E_{\mathbf{t}|\mathbf{s}} \left[f(\mathbf{s}, \mathbf{t}) - E_{\mathbf{s}'|\mathbf{t}} [f(\mathbf{s}', \mathbf{t})] \right]$$

1. 単語列 \mathbf{t} , \mathbf{s}' に関する期待値が二重になっている
2. \mathbf{t} や \mathbf{s}' だけ取っても、動的計画法 (通常のForward-Backward) は $O(V^2)$ の計算量がかかるため不可能 (V : 語彙数、10000~100000程度)

ノート

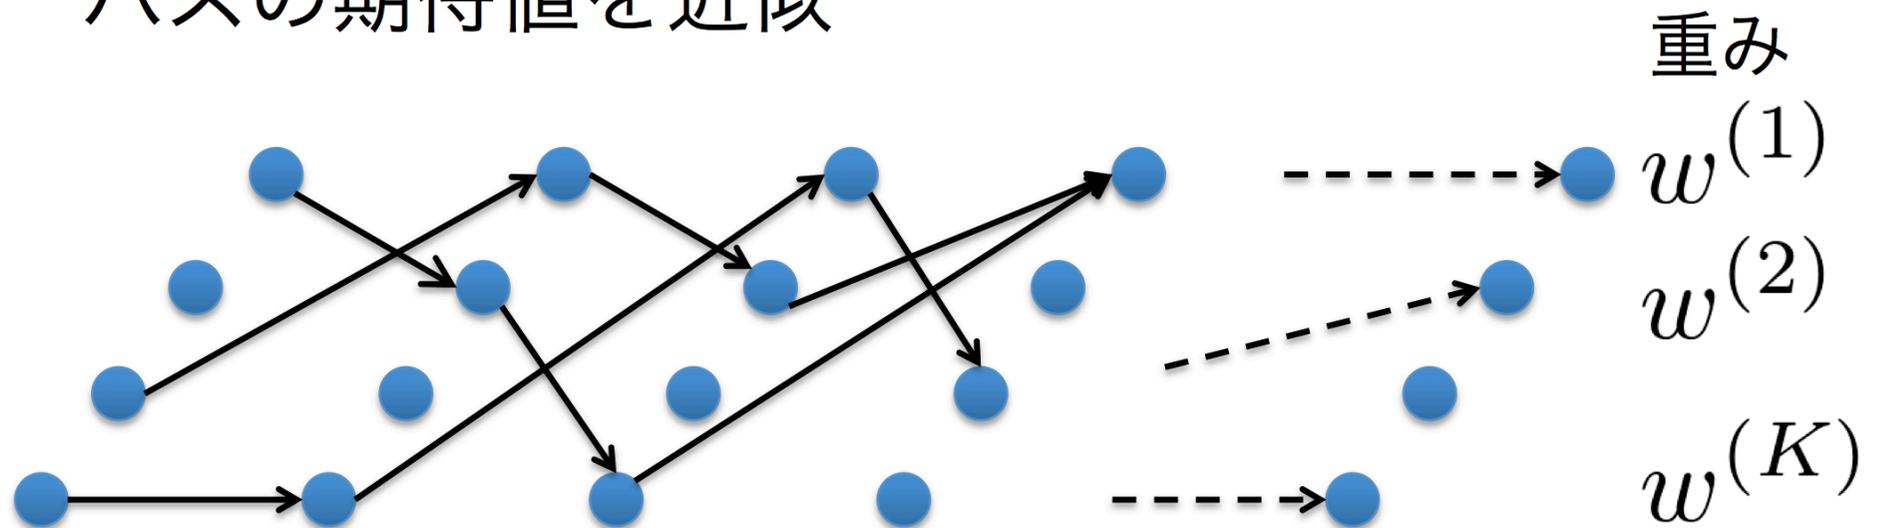
- 実際には、以下誤り確率は単語ごとに分解して考える

$$p(\mathbf{s}|\mathbf{t}, \theta) = \prod_n \frac{\exp(\theta^T f(s_n, t_n))}{Z(t_n)}$$

$$Z(t_n) = \sum_s \exp(\theta^T f(s_n, t_n))$$

Sequential Monte Carlo

- 逐次モンテカルロ法 aka. Particle Filter
 - 言語モデルの話に適用したのは、多分私が最初 (Mochihashi and Matsumoto (2005))
 - 実際のモンテカルロサンプルで、Lattice上のパスの期待値を近似



SMCによる期待値

- いまの場合、 K 個のサンプルを用いて期待値を近似

$$E_{\mathbf{t}|\mathbf{s}}[f(\mathbf{s}, \mathbf{t})] = \sum_{k=1}^K w_N^{(k)} \sum_{n=1}^N f(s_n, t_n^{(k)})$$

- \mathbf{s} : 観測された単語列 (Tweet)
- \mathbf{t} : 真の単語列
- $\mathbf{t}^{(k)}$: 真の単語列のサンプル
- $w_N^{(k)}$ はサンプル $\mathbf{t}^{(k)}$ の確率に比例

サンプル重みの更新

- $w_n^{(k)}$: サンプルkの時刻nでの重み
- 初期値は $w_0^{(k)} = 1$
- SMCの理論から、重みを以下の式で更新

表記誤りモデル

バイグラム言語モデル

$$w_n^{(k)} = w_{n-1}^{(k)} \cdot \frac{p(s_n | t_n^{(k)}) p(t_n^{(k)} | t_{n-1}^{(k)})}{q(t_n^{(k)} | t_{n-1}^{(k)}, s_n)}$$

$t_n^{(k)}$: 提案分布 q からの
正しいと思われる単語のサンプル

提案分布での t_n の確率密度

提案分布

- 正しい分布

$$\begin{aligned} p(t_n^{(k)} | s_n, t_{n-1}^{(k)}) &= \frac{p(s_n | t_n^{(k)}) p(t_n^{(k)} | t_{n-1}^{(k)})}{\sum_{t'} p(s_n | t') p(t' | t_{n-1}^{(k)})} \\ &= \frac{\exp(\theta^T f(s_n, t_n^{(k)}))}{Z(t_n^{(k)})} p(t_n^{(k)} | t_{n-1}^{(k)}) \\ &= \frac{\quad}{Z} \end{aligned}$$

は $O(V^2)$ の計算量

– 分母と分子でそれぞれ正規化項の計算が必要

提案分布 (2)

- 正規化が一つの確率を提案分布に

$$q(t_n^{(k)} | s_n, t_{n-1}^{(k)}) = \frac{\exp(\theta^T f(s_n, t_n^{(k)})) p(t_n^{(k)} | t_{n-1}^{(k)})}{\sum_{t'} \exp(\theta^T f(s_n, t')) p(t' | t_{n-1}^{(k)})}$$

これによるバイアスは、サンプルの重みで補正される

内側の期待値

$$\frac{\partial L}{\partial \theta} = E_{\mathbf{t}|\mathbf{s}} \left[f(\mathbf{s}, \mathbf{t}) - E_{\mathbf{s}'|\mathbf{t}} [f(\mathbf{s}', \mathbf{t})] \right]$$

- 内側の期待値 $E_{\mathbf{s}'|\mathbf{t}}[\cdot]$ には、誤りモデル $p(\mathbf{s}|\mathbf{t}, \theta)$ をそのまま使ってモンテカルロ近似

$$E_{\mathbf{s}'|\mathbf{t}} [f(\mathbf{s}, \mathbf{t}^{(k)})] = \frac{1}{L} \sum_{n=1}^N \sum_{\ell=1}^L f(s_n^{k,\ell}, t_n^{(k)})$$

$$s_n^{k,\ell} \sim p(s|t_n^{(k)}, \theta) \quad \text{i.i.d.}$$

最終的なgradient

$$\begin{aligned} & E_{\mathbf{t}|\mathbf{s}} \left[f(\mathbf{s}, \mathbf{t}) - E_{\mathbf{s}'|\mathbf{t}}[f(\mathbf{s}', \mathbf{t})] \right] \\ &= \frac{1}{\sum_{k=1}^K w_N^{(k)}} \sum_{k=1}^K w_N^{(k)} \times \\ & \quad \sum_{n=1}^N \left(f(s_n, t_n^{(k)}) - \frac{1}{L} \sum_{\ell=1}^L f(s_n^{k,\ell}, t_n^{(k)}) \right) . \end{aligned}$$

- SMC+MCによる期待値で、計算量の爆発する Forward-Backward (のネスト)を回避
- 論文では、 $K=10$, $L=1$ で充分だったとのこと(!)

実験

- 評価用データセット
 - LWWL11 (Liu+ 2011) : 単語とその正規形のリスト, 3802個
 - LexNorm1.1 (Han&Baldwin 2011) : Tweetとその正規形、549 tweets, 558 nonstandard word types
 - LexNorm1.2 : 著者らが上のものの誤りを訂正
- 辞書にある語については、 $p(s_n|t_n)=0$ に設定
 - 書き換えられることはない
 - iiiを i'ii に書き換えることは現状できない

実験結果

Method	Dataset	Precision	Recall	F-measure
(Liu et al. 2011)		68.88	68.88	68.88
(Liu et al. 2012)	LMML11	69.81	69.81	69.81
UNLOL		73.04	73.04	73.04
(Han and Baldwin, 2011)		75.30	75.30	75.30
(Liu et al. 2012)	LexNorm 1.1	84.13	78.38	81.15
(Hassan et al. 2013)		85.37	56.4	69.93
UNLOL		82.09	82.09	82.09
UNLOL	LexNorm 1.2	82.06	82.06	82.06

- 既存研究の精度を大きく上回る

書き換えタイプの分析

- 英語の400000ツイートをUnLOLで正規化して、傾向を分析
 - 単語の書き換えアライメントが得られる
 - Levenstein距離で使われた規則がわかる
- 誰がどんな規則を使ったかの頻度を行列化
 - ↓
 - NMFで圧縮して、“orthographic style”を求める
- どんなスタイルがあったのか？

書き換えタイプの分析結果

style	rules	examples
1. you; o-dropping	$yl_ oul_u \ *yl*_ ol_$	u, yu, 2day, knw, gud, yur, wud, yuh, u' ve, toda, everthing, everwhere, ourself
2. e-dropping, u/o	$belb_ el_ olu \ e*/_*$	b, r, luv, cum, hav, mayb, bn, remembr, btween, gunna, gud
3. a-dropping	$al_ \ *al*_ relr_ arl_r$	r, tht, wht, yrs, bck, strt, gurantee, elementry, wr, rlly, wher, rdy, preciate, neway
4. g-dropping	$g*/_*$	goin, talkin, watchin, feelin, makin
5. t-dropping	$t*/_*$	jus, bc, shh, wha, gota, wea, mus, firts, jes, subsistutes
6. th-stopping	$hl_ \ *t/*d \ th/d_ t/d$	dat, de, skool, fone, dese, dha, shid, dhat, dat' s
7. (kd)-lengthening	$i_/id \ /k \ /d \ \ */*k*$	idk, fuckk, okk, backk, workk, badd, andd, goodd, bedd, elidgible, pidgeon
8. o-lengthening	$o_/oo \ \ */*o*$	soo, noo, doo, oohh, loove, thoo, helloo
9. e-lengthening	$/i \ e_/ee \ /e \ \ */*e*$	mee, ive, retweet, bestie, lovee, nicee, heey, likee, iphone, homie, ii, damnit
10. a-adding	$/a \ \ /ma \ /m \ \ */*a*$	ima, outta, needa, shoulda, woulda, mm, comming, tomm, boutt, ppreciate

Table 3: Orthographic styles induced from automatically normalized Twitter text

まとめ

- 教師なしでも、表記の正規化は可能
 - 面倒な教師データを人手で作る必要はない
- 文→文の可能な書き換えの探索は動的計画法では不可能
 - Sequential Monte Carlo法を用いて、gradientを効率的に計算
 - 他のNLPタスクにも役立つ手法
- 書き換えは、人によってスタイルがある
 - どんなスタイルがあるかの教師なし学習