

Particle Filter による文脈の動的ベイズ推定

持橋大地 *1,*2 松本裕治 *1

{daiti-m,matsu}@is.naist.jp

¹ NAIST 情報科学研究科 松本研究室

² ATR 音声言語コミュニケーション研究所 音声言語処理研究室

IPSJ 2005-NL-165

2005.1.12 (Wed)

Today's Topic

- 適切な文脈長を自動的に選択することのできるベイズ言語モデル

Today's Topic

- 適切な文脈長を自動的に選択することのできるベイズ言語モデル
 - 文脈の変化に対する, 確率的生成モデル

Today's Topic

- 適切な文脈長を自動的に選択することのできるベイズ言語モデル
 - 文脈の変化に対する, 確率的生成モデル
- 文脈推定問題を, フィルタリング問題と捉える

Today's Topic

- 適切な文脈長を自動的に選択することのできるベイズ言語モデル
 - 文脈の変化に対する, 確率的生成モデル
- 文脈推定問題を, フィルタリング問題と捉える
 - カルマンフィルタ等では解けない

Today's Topic

- 適切な文脈長を自動的に選択することのできるベイズ言語モデル
 - 文脈の変化に対する, 確率的生成モデル
- 文脈推定問題を, フィルタリング問題と捉える
 - カルマンフィルタ等では解けない
 - 自然言語は非ガウシアン・非ベクトル空間

Today's Topic

- 適切な文脈長を自動的に選択することのできるベイズ言語モデル
 - 文脈の変化に対する, 確率的生成モデル
- 文脈推定問題を, フィルタリング問題と捉える
 - カルマンフィルタ等では解けない
 - 自然言語は非ガウシアン・非ベクトル空間
 - Particle Filter (非線型ベイジアンフィルタ) を使うことで, オンラインで解くことができる

Today's Topic

- 適切な文脈長を自動的に選択することのできるベイズ言語モデル
 - 文脈の変化に対する, 確率的生成モデル
- 文脈推定問題を, フィルタリング問題と捉える
 - カルマンフィルタ等では解けない
 - 自然言語は非ガウシアン・非ベクトル空間
 - Particle Filter (非線型ベイジアンフィルタ) を使うことで, オンラインで解くことができる
 - 各粒子の持つ, 複数の文脈からの予測の混合

Today's Topic

- 適切な文脈長を自動的に選択することのできるベイズ言語モデル
 - 文脈の変化に対する, 確率的生成モデル
- 文脈推定問題を, フィルタリング問題と捉える
 - カルマンフィルタ等では解けない
 - 自然言語は非ガウシアン・非ベクトル空間
 - Particle Filter (非線型ベイジアンフィルタ) を使うことで, オンラインで解くことができる
 - 各粒子の持つ, 複数の文脈からの予測の混合
- テキストの「意味」の変化点をオンラインで検出し, TextTiling の確率化とも捉えられる

Background

- さまざまな言語的状况に適應するために, n-gram を超える長距離言語モデルが重要
 - 例: 翻訳モデル $p(J|E) \propto p(J)p(E|J)$ (Brown 1990)
- しかし, これまでの研究はほぼすべて, 単一の文脈への適應しか考えてこなかった
 - 話の流れには, サブトピックが存在する
 - 話題の変化?
応用:
 - 実環境の音声認識, ロボティクス
 - 文脈を意識した翻訳, かな漢字変換, HMI (Human-Machine Interaction)
 - テキスト理解 (理学的目標)

Context models so far

- これまでの長距離言語モデル
 - Cache/trigger models (Old)
 - LSI 言語モデル (Bellegarda 1998)
 - PLSI 言語モデル (Gildea & Hofmann 1999)
 - LDA 言語モデル (三品, 山本 2002)
 - DM 言語モデル (山本 2003)
- テキストモデルの応用 (Bag of Words を仮定)
 - 文脈は, 単語の単純な集合
 - 文脈には, 時間的順序がない
 - Bag of words 「文脈」モデル

Context models so far (2)

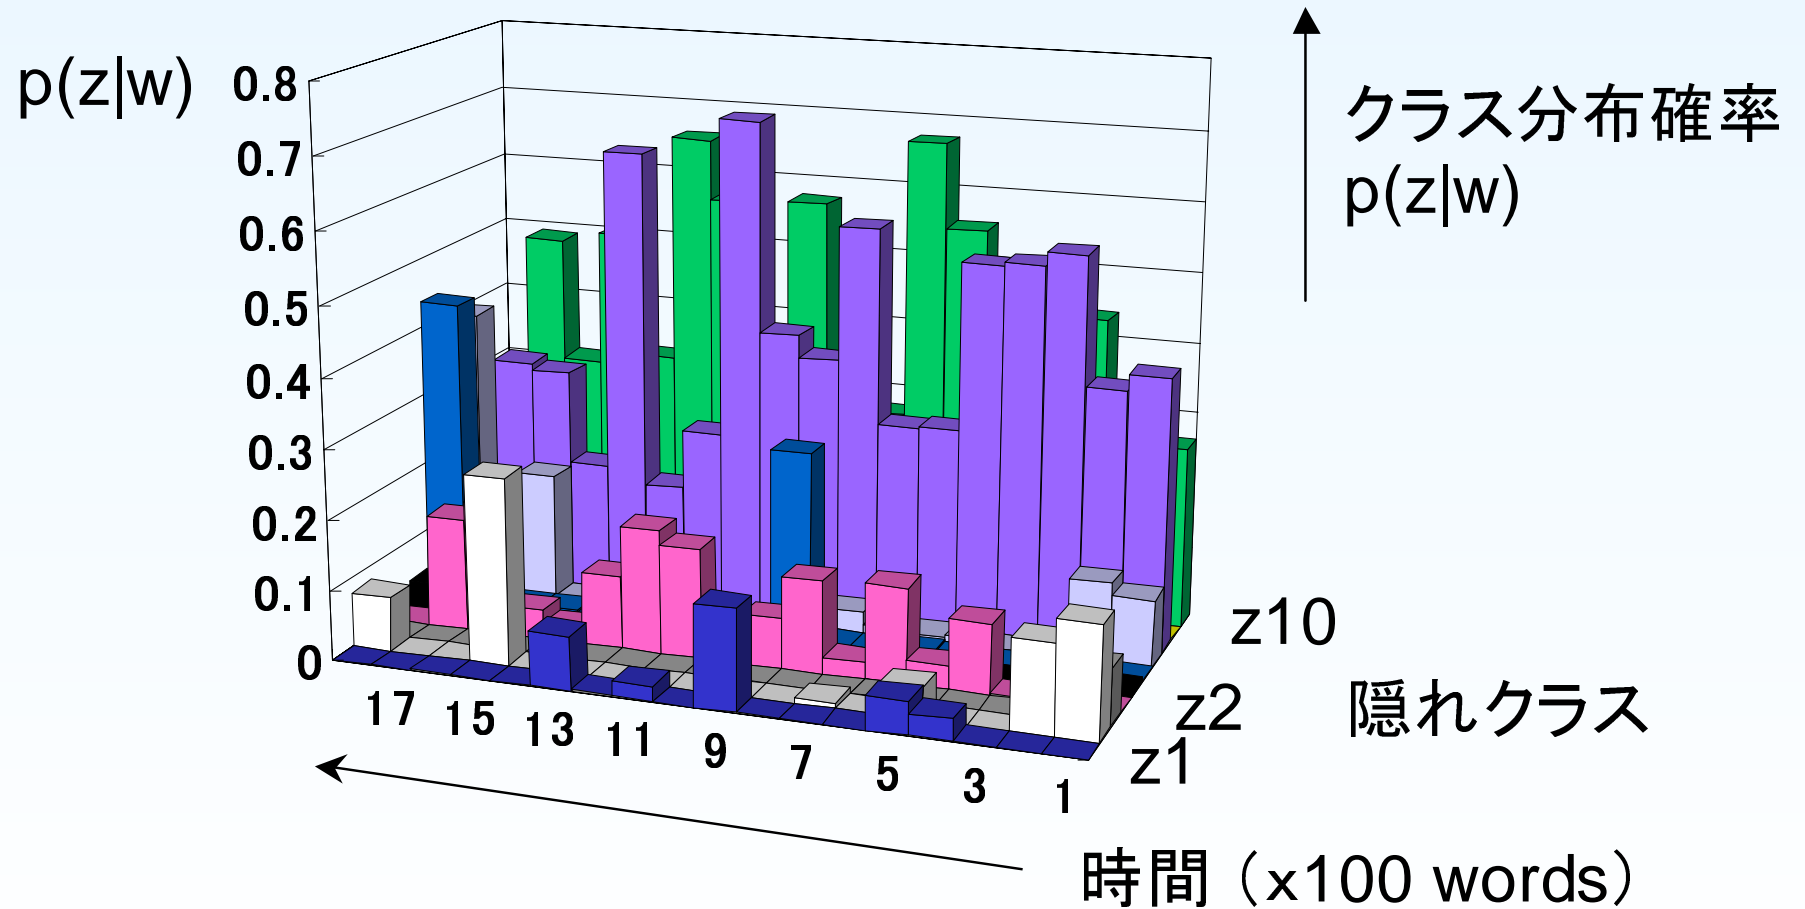
- 文脈として, テキストの先頭から全て用いている
 - or, 1000 語などの単純な閾値 (黒橋, 織 2000)
 - テキストの後ろほど推定値が悪くなる (高橋他 2003)
- テキストが長い場合はどうする?
 - 小説
 - 論説文
- 実環境への適用? (例: ロボティクス)
 - 複数の文脈の切り替え, 長時間の動作
 - 動的な適応
 - eg. かな漢字変換



これまでのモデルは, テキストに対して定常情報源を仮定 (!)

Example of Real Text

- 毎日新聞テキスト, about 1700 words
 - PLSI で 10 クラス (図示のため) に分解



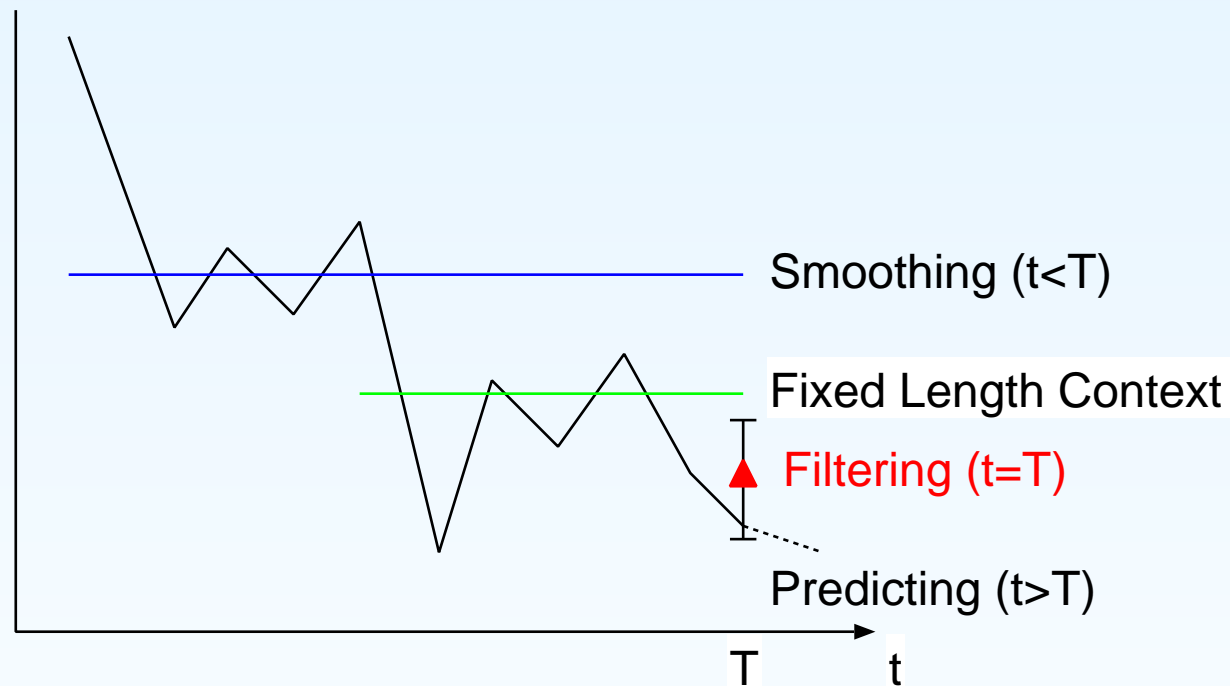
Some Exceptions

- Bellegarda (1998)
 - LSI (Latent Semantic Indexing) による文脈モデル
 - 過去の履歴を, $\lambda = 0.975$ (固定) の比率で忘れると予測が最良. ただし,
 1. 文書によって最適な λ には違いがあるのでは?
 2. 過去を一様に忘れるのでよいか?
 - 文脈の変化点からとるべき
 - 「文脈の変化点」を記述するモデル?
- Beeferman, Berger, Lafferty (1997)
 - 言語の時間的な非定常性に着目
 - テキスト中での語の意味的な関係が, 距離に関して指数的に減少
 - 指数分布としてモデル化・EM で全体のパラメータを推定

“Context as a Filtering”

- なぜ、文脈の遷移がモデル化されてこなかったのか？
 - 長距離文脈の問題は、統計的には状態を逐次推定するフィルタリング問題と考えられる
 - カルマンフィルタ (KF), 拡張カルマンフィルタ (EKF)
 - 制御, 信号処理, ロボティクスでこれまでよく使われている
 - ベクトル空間, Gaussian Noise を仮定
- ↓
- しかし、自然言語は非ベクトル空間, かつ非 Gaussian
… 多項分布, 多項単体 (Multinomial Simplex)
- 多項分布のフィルタリング問題
 - 難しい!

Filtering, Smoothing, Predicting ..



- 従来の文脈モデルは, Smoothing をしているものと考えられる
- 正確な Filtering のためには, 状態空間モデルが必要
 - 信号処理, 計量経済学 (Econometrics) などによく使われている


Multinomial and Dirichlet distribution

- 多項分布 $\text{Mult}(\boldsymbol{\theta})$... 離散シンボルの生起確率

- $\boldsymbol{\theta} = (\theta_1 \theta_2 \dots \theta_K)$

- $\theta_1 + \theta_2 + \dots + \theta_K = 1.$

- 例: n-gram 確率, 混合モデルの混合比




- ディリクレ分布 $\text{Dir}(\boldsymbol{\alpha})$... 多項分布の分布

- $\text{Dir}(\boldsymbol{\theta}|\boldsymbol{\alpha}) = \frac{\Gamma(\sum_k \alpha_k)}{\prod_{k=1}^K \Gamma(\alpha_k)} \prod_{k=1}^K \theta_k^{\alpha_k - 1}$

- Simplex (単体) 上の確率分布


- 多項分布を推定するには,
多項分布の分布であるディリクレ分布が必要.



State Space Models

- 状態空間モデル (State space models) = 一般化 HMM

$$\begin{cases} \mathbf{x}_t \sim p(\mathbf{x}_t | \mathbf{x}_{t-1}) & (\text{状態遷移方程式}) \\ \mathbf{y}_t \sim p(\mathbf{y}_t | \mathbf{x}_t) & (\text{観測方程式}) \end{cases}$$



- 状態空間がベクトル空間&正規分布の場合
 - 最小二乗の厳密解が存在 (Kalman Filter) (Kalman 1960)
- 状態空間が離散変数のどれか一つである場合
 - 離散隠れマルコフモデル
 - Baum-Welch 法 (転送行列法) が厳密解
- それ以外...解が簡単には求められない
 - 言語モデル, 混合モデル...真の状態が一つでなく, 多項分布
 - データが少ない場合 (ex. 言語の文脈)

Multinomial State Space Model

- 文脈に、隠れた多項分布 θ_t が存在するとする。 θ_t とは、
 - 単語の出現確率 (ユニグラム)
 - 隠れたトピックの混合比
 - 例. “スポーツ” = 0.2, “政治” = 0.4, ... etc.
 - 「トピック」はコーパスから (VB)-EM で求まる
- このとき, θ に次の状態空間モデルを仮定する (Mean shift model: MSM)

$$\begin{cases} \theta_t \sim \begin{cases} \text{Dir}(\alpha) & \text{with probability } \rho \\ \theta_{t-1} & \text{with probability } (1 - \rho) \end{cases} \\ y_t \sim \text{Mult}(\theta_t) \end{cases} \quad (1)$$

- 確率 ρ で隠れた多項分布 θ_t が変化
- θ_t は未知, いつ変化したのかも未知
- 観測されるのは, 出力 $y = (y_1 y_2 \dots y_T)$ のみ.


Multinomial Mean Shift Model (1)

次のようなアルファベット a,b,c の系列が観測されたとする.

```
aaaaaabaacbaabaaaaabbbbbbababababababbab\  
bbbabcaccccbcaccccccccccccccccccccccccc\  
cccccccccaaaaacbbbbbb
```

- 次のアルファベットは何?
 - b の可能性が高い (しかし, オーバーフィットの危険)
 - 全部平均してしまう (今までの文脈モデル!)
- 最近変化した場所に依存
 - 変化点検出問題 (Change-point problem) として知られた問題
 - もし最近の変化点がわかれば, 推定値は正確に求まる. (次スライド)

Multinomial Mean Shift Model (2)



最近の変化点の位置によって, 推定値は

(a) の場合:

$$p(y_t | y_c \cdots y_{t-1}) = \int p(y_t | \theta_t) p(\theta_t | \alpha) d\theta_t = \alpha_y / \sum_y \alpha_y \quad (2)$$

(b) の場合:

$$p(y_t | y_c \cdots y_{t-1}) = \int p(y_t | \theta_t) p(\theta_t | y_c \cdots y_{t-1}) d\theta_t \quad (3)$$

$$= \frac{\alpha_y + \sum_{t=c}^{t-1} \delta(y)}{\alpha + \sum_{t=c}^{t-1} \delta(y_t)} \quad (4)$$

のように求まる.

How to detect a change point?

- ベイズの公式により, 変化確率は計算できる (Chen and Lai, 2003; Yao, 1984)

$$p(\textit{change}|\textit{observed}) \tag{5}$$

$$\propto p(\textit{observed}|\textit{change}) p(\textit{change}) \tag{6}$$

$$= \begin{cases} p(\textit{observed}|\textit{change} = 1)p(\textit{change} = 1) \\ p(\textit{observed}|\textit{change} = 0)p(\textit{change} = 0) \end{cases} \tag{7}$$

- $p(\textit{observed}|\textit{change})$ は, 今求めたばかり
- $p(\textit{change}) = \rho$ ととりあえずおく [文脈変化の事前確率]
 - 後で動的に推定
- $p(\textit{change}|\textit{observed})$ が計算できる!


How to detect a change point? (2)

- しかし..
 - 変化点は, 計算上確定されなければならない
 - 「履歴を 0.214 だけ用いる」ようなことはできない.
 - ベルヌーイ試行でサンプル ... 推定が不安定 (一種の弱学習器)
- ↓
- Particle Filter (逐次モンテカルロ法) を使う
 - 複数の Particle (粒子, モンテカルロサンプル) による予測を同時に動かす
 - 混合分布として予測
 - 文脈変化の事前確率も動的に推定できる.
 - 話題の移り変わりの速さ, 遅さ

Particle Filter (1)

- a.k.a. 逐次 (時系列) モンテカルロ法
 - (Kitagawa 1987; Doucet, de Freitas, Gordon 2001)
- 複数のモンテカルロサンプル (Particle) による重み付き推定
 - 信号処理, ロボティクスなどの分野で最近使われ始めている
 - 計算資源の急速な増大
- 任意の非線型ダイナミクスを追跡できる (!)
 - 非ガウシアンダイナミクス, 外れ値推定
 - 自然言語のような離散データにも, 原理的に適用可能
- 複数の変化点履歴を持つ予測を, 同時に動かす

Particle Filter (2)



- 時間 t での N 個の particle $p_t^{(1)} \dots p_t^{(N)}$ 重み $w_t^{(1)} \dots w_t^{(N)}$
- 各 particle は, 異なった変化点履歴を確率的にサンプル
- 重み付き期待値: $E[f(\mathbf{x}_t)] \simeq \sum_{i=1}^N w_t^{(i)} f(p_t^{(i)}(\mathbf{x}_t))$

Particle Filter (3)

- 粒子 i の重み $w_t^{(i)}$ のアップデート (和が 1 になるように正規化)

$$w_t^{(i)} \propto w_{t-1}^{(i)} \cdot \frac{p(y_t | \mathbf{x}_t) p(\mathbf{x}_t | \mathbf{x}_{t-1})}{q(\mathbf{x}_t | X_{t-1}, Y_t)} \quad (8)$$

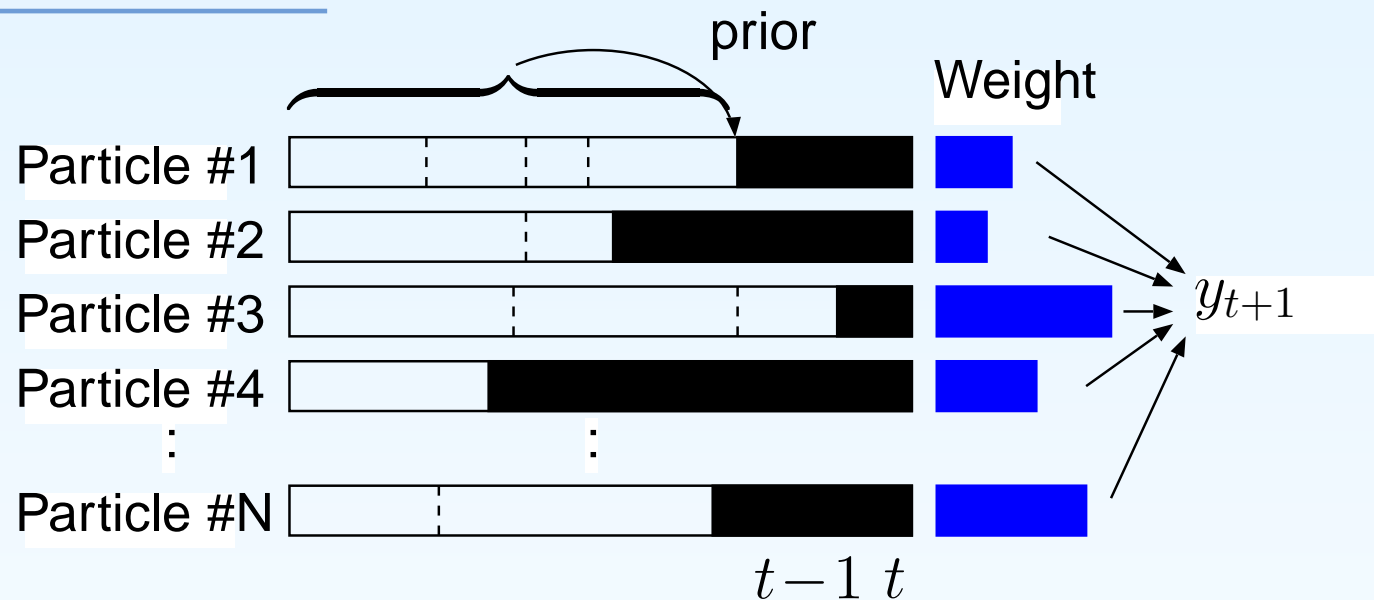
- われわれの問題の場合, 実際には

$$w_t^{(i)} \propto w_{t-1}^{(i)} \cdot (p(y_t | \text{change} = 0) p(\text{change} = 0) + p(y_t | \text{change} = 1) p(\text{change} = 1)) \quad (9)$$

で更新できる [予稿集参照]

- ただし, 時間がたつと, 重み $w_t^{(1)} \dots w_t^{(N)}$ に大きな偏りが生じる (「Particle がすり減る」) リサンプリング
 - 重みの大きい粒子の「子供」を作る
 - 重みの少ない粒子を殺す.

Particle Filter (4)



- 各粒子は, 異なった変化点履歴 $I_t^{(i)}$ をもつ
- 複数の粒子のもつ, 様々な文脈長からの予測の重みつき推定 (混合分布)
- 文脈の変化速度を「正しく」推定したサンプルが生き残る
 - 間違っってサンプルした粒子は, リサンプリングで消える
 - 文脈の変化速度を, 時間に従って正しく推定する

Multinomial Particle Filtering

aaaaabaacbaabaaaaabbbbbababababababbab\
bbbabcccccbcacccccccccccccccccccccccccc\
cccccccacaaaacbbbbb..



a = blue
b = green
c = red

- 水平線 = 隠れた正解 (多項分布)
- # of Particles = 50, $(\alpha, \beta) = (1, 10)$

Mean shift model of Natural Language

- しかし...
 - 自然言語では, アルファベット (単語) の数が膨大
 - 「病院」 「看護婦」では, 隠れた多項分布は不変
 - 「病院」 「大学」では, 文脈が変化している

↓

単語の間の意味的な相関を捉える必要.
- Dirichlet Mixture (DM) (山本他 2003),
Latent Dirichlet Allocation (LDA) (Blei et al. 2001) を用いて,
MSM を自然言語に拡張した.

MSM-DM (1)

- Dirichlet Mixture (DM) (山本他 2003, 2004) @SLP-48,53
 - 文脈推定のための確率的テキストモデル
 - これまで, 文脈モデルとして性能が最高
 - 単語の意味的な相関を, ハイパーパラメータのレベルで捉える

$$p(\mathbf{w}|\boldsymbol{\lambda}, \boldsymbol{\alpha}) = \int_{\Delta} p(\mathbf{w}|\mathbf{p})p(\mathbf{p}|\boldsymbol{\lambda}, \boldsymbol{\alpha})d\mathbf{p} \quad (10)$$

$$= \sum_{m=1}^M \lambda_m \frac{\Gamma(\sum_v \alpha_{mv})}{\Gamma(\sum_v \alpha_{mv} + n)} \prod_{v \in \mathbf{w}} \frac{\Gamma(\alpha_{mv} + n(v))}{\Gamma(\alpha_{mv})} \quad (11)$$

(p : ユニグラム確率; λ, α : DM パラメータ)

- パラメータ λ, α は EM 法と Newton 法を組み合わせでコーパスから求める
 - <http://cl.naist.jp/~daiti-m/dist/dm/> でパッケージを公開中
 - 56,000 文書, 100 クラスへの分解で 10 時間程度 (Xeon 2.8GHz)

MSM-DM (2)

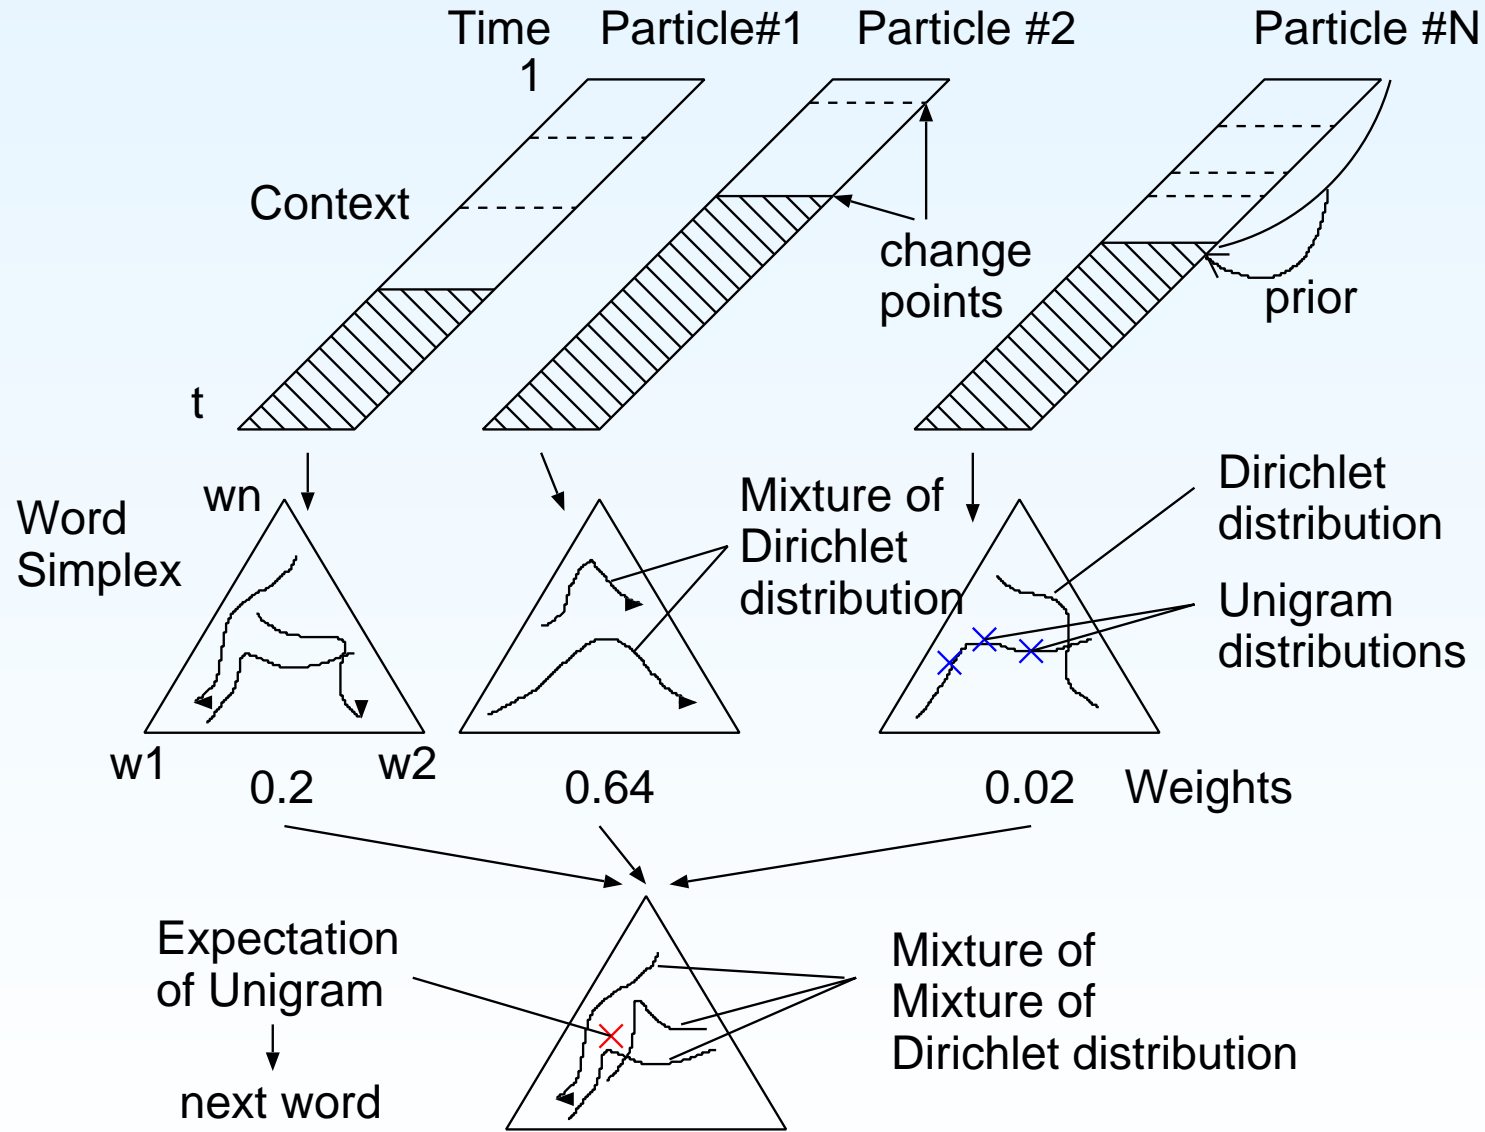
- 文脈 $h = w_1 w_2 \dots w_h$ のもとでの予測確率:

$$p(y|h, \alpha, \lambda) \propto \sum_{m=1}^M C_m(h) \frac{\alpha_{my} + n(y)}{\alpha_m + h} \quad (12)$$

($n(y)$: h 中の y の生起回数)

- 複数のハイパーパラメータ $\alpha_1 \dots \alpha_M$ からの予測の混合
- ハイパーパラメータ自体を適応的に選択
 - MacKay (1994) の Dirichlet smoothing の拡張
- h を最近の変化点からの履歴とし, この予測確率を多項分布 MSM で用いる
 - もともとの MSM は, 事前分布にディリクレ分布を仮定
 - DM では, 混合ディリクレ分布を仮定
 - 多項分布 MSM の自然な拡張になっている.

Graphical image of MSM-DM



MSM-LDA (1)

- Latent Dirichlet Allocation (LDA) (Blei et al. 2001, 2003)
 - 確率的トピックのテキストモデル
 - 単語の間の相関を, 隠れた確率的トピックのレベルで捉える
 - PLSI (Hofmann 1999) のベイズ拡張

$$p(\mathbf{w}|\boldsymbol{\alpha}, \boldsymbol{\beta}) = \frac{\Gamma(\sum_{k=1}^K \alpha_k)}{\prod_{k=1}^K \Gamma(\alpha_k)} \int \left(\prod_{k=1}^K \theta_k^{\alpha_k - 1} \right) \left(\prod_{n=1}^N \sum_{k=1}^K \prod_{v=1}^V (\theta_k \beta_{kv})^{w_n^v} \right) d\boldsymbol{\theta} \quad (13)$$

- パラメータ:
 - $\boldsymbol{\alpha} = \text{Dir}(\boldsymbol{\lambda}|\boldsymbol{\alpha})$ 隠れトピックへの事前分布パラメータ
 - $\boldsymbol{\beta} = \{p(v|m)\}$ ($v = 1..V, m = 1..M$) トピック別ユニグラム確率行列
 - <http://cl.naist.jp/~daiti-m/dist/lda/> でパラメータ推定を行うパッケージを公開している

MSM-LDA (2)

- 文脈 $\mathbf{h} = w_1 w_2 \dots w_h$ の持つ, 潜在的な M 次元のトピック分布 $q(\boldsymbol{\lambda}|\mathbf{h})$ は, 次の変分ベイズ EM 法で求まる

$$\begin{cases} q(z_i^t = 1|\mathbf{h}) \propto p(w_i|t) \exp(\Psi(\alpha + n_t)) & \text{(VB-E step)} \\ q(\boldsymbol{\lambda}|\mathbf{h}) \propto \prod_{t=1}^M \lambda_t^{\alpha+n_t-1} & \text{(VB-M step)} \end{cases} \quad (14)$$

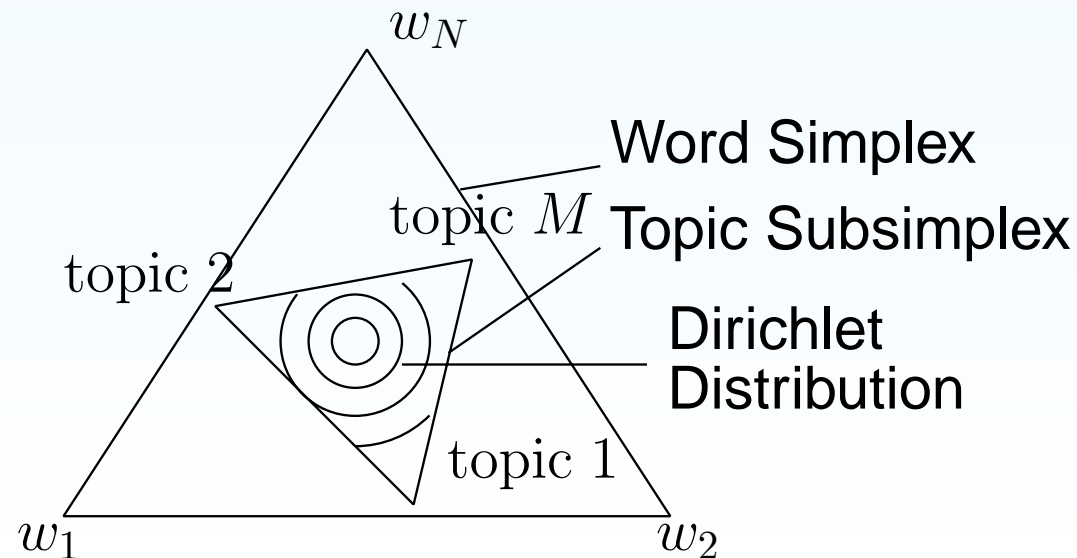
$$\text{where } n_t = \sum_{i=1}^h q(z_i^t = 1|\mathbf{h})$$

- 文脈 \mathbf{h} のもとでの予測確率
= 各トピックからの予測の混合:

$$p(y|\mathbf{h}) = \sum_{m=1}^M p(y|m) E_q[\lambda_m|\mathbf{h}] \quad (15)$$

MSM-LDA (3)

- ユニグラム分布を直接ではなく, M 次元トピックの混合比の変化を追跡する
 - 直感的な解釈が容易
 - トピック空間へ圧縮して追跡するため, やや柔軟性に欠ける
 - Topic simplex は, Word simplex の subsimplex
 - 一般の混合モデルの混合比追跡に応用可能.
 - eg. Gaussian Mixtures



Experiments on BNC

- British National Corpus (BNC)
 - 約 1 億語のバランスドコーパス
 - そのうち 56,939 文書, 11,032,233 語を LDA/DM のパラメータ推定に使用
 - 仮想的にファイルを分割して文書とした
 - LDA などのテキストモデルは, 長い文書には無力 (!)
 - 本研究の手法の, 文書集合への拡張 (Future work)
- サンプルングにより, 4 種類の文脈変化速度の評価セットを作成した
 - 1 セット ≡ 100 文書
 - 1 文書はサンプルングされた 100 文からなる (約 2,000 語)
 - Raw : 連続した 100 文
 - Slow : RAW より速い変化
 - Fast : SLOW より速い変化
 - VeryFast : FAST より速い変化

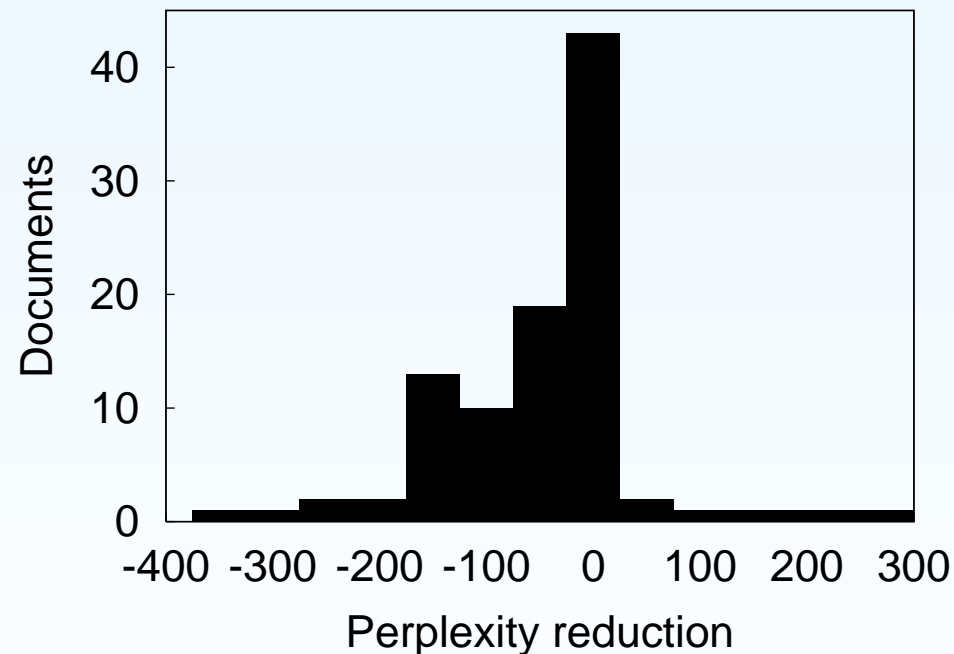
Experiments on BNC (2)

Text	MSM-DM	DM	MSM-LDA	LDA
Raw	870.06 (−6.02%)	925.83	1028.04	1037.42
Slow	893.06 (−8.31%)	974.04	1047.08	1060.56
Fast	898.34 (−9.10%)	988.26	1044.56	1061.01
VFast	960.26 (−7.57%)	1038.89	1065.15	1050.83

- MSM-DMの方が直接 Word Simplex 上で動くため、追跡が柔軟
- MSM-LDA も文脈を自動選択する効果はあるが、トピック空間に圧縮するため、やや柔軟性に欠ける

Experiments on BNC (3)

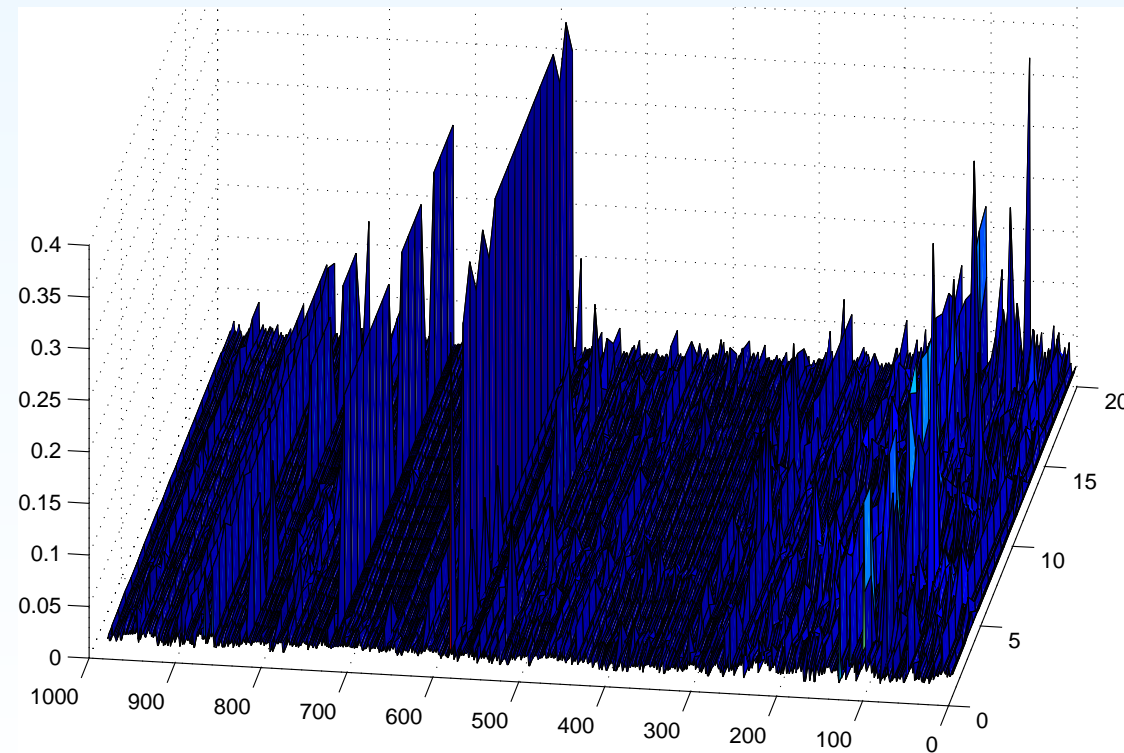
- Dirichlet Mixture に対する, 各文書のパープレキシティ減少
 - “Raw” データの場合 (= 生テキスト)
 - $PPL_{MSM} - PPL_{DM}$



- ほとんどの文書で効果がある
 - 75% の文書でパープレキシティ減少 (最大の減少 = -365)

Change probabilities of real text

- 本研究は, 単語ごとに**文脈変化確率** $p(I_t = 1)$ を計算できるため, TEXTTILING (Hearst 1994) の確率化ともとらえられる
- 実際のテキストの変化確率:



Conclusion

- 文脈の変化確率を計算し, 適切な文脈長を自動的に選択する
ベイズ長距離言語モデル

Conclusion

- 文脈の変化確率を計算し, 適切な文脈長を自動的に選択する
ベイズ長距離言語モデル
 - 複数の文脈長からの予測の重みつき混合

Conclusion

- 文脈の変化確率を計算し, 適切な文脈長を自動的に選択する
ベイズ長距離言語モデル
 - 複数の文脈長からの予測の重みつき混合
 - 文脈の変化に対する, 確率的生成モデル

Conclusion

- 文脈の変化確率を計算し, 適切な文脈長を自動的に選択する
ベイズ長距離言語モデル
 - 複数の文脈長からの予測の重みつき混合
 - 文脈の変化に対する, 確率的生成モデル
- Mean shift model の DM, LDA による自然言語への拡張

Conclusion

- 文脈の変化確率を計算し, 適切な文脈長を自動的に選択する
ベイズ長距離言語モデル
 - 複数の文脈長からの予測の重みつき混合
 - 文脈の変化に対する, 確率的生成モデル
- Mean shift model の DM, LDA による自然言語への拡張
- 非線型な HMM ... 非線型モンテカルロフィルタである
Particle Filter を用いた

Conclusion

- 文脈の変化確率を計算し, 適切な文脈長を自動的に選択する
ベイズ長距離言語モデル
 - 複数の文脈長からの予測の重みつき混合
 - 文脈の変化に対する, 確率的生成モデル
- Mean shift model の DM, LDA による自然言語への拡張
- 非線型な HMM ... 非線型モンテカルロフィルタである
Particle Filter を用いた
 - 文脈の変化速度もオンラインで推定できる

Conclusion

- 文脈の変化確率を計算し, 適切な文脈長を自動的に選択する
ベイズ長距離言語モデル
 - 複数の文脈長からの予測の重みつき混合
 - 文脈の変化に対する, 確率的生成モデル
- Mean shift model の DM, LDA による自然言語への拡張
- 非線型な HMM ... 非線型モンテカルロフィルタである
Particle Filter を用いた
 - 文脈の変化速度もオンラインで推定できる
 - 補助的に, TEXTTILING の確率化

Conclusion

- 文脈の変化確率を計算し, 適切な文脈長を自動的に選択する
ベイズ長距離言語モデル
 - 複数の文脈長からの予測の重みつき混合
 - 文脈の変化に対する, 確率的生成モデル
- Mean shift model の DM, LDA による自然言語への拡張
- 非線型な HMM ... 非線型モンテカルロフィルタである
Particle Filter を用いた
 - 文脈の変化速度もオンラインで推定できる
 - 補助的に, TEXTTILING の確率化
 - 現在, 最もパープレキシティの低い長距離言語モデル

Future Work

- 本研究は言語モデルのため, Forward モデル (予測モデル)

Future Work

- 本研究は言語モデルのため, Forward モデル (予測モデル)
 - Forward-Backward への拡張

Future Work

- 本研究は言語モデルのため, Forward モデル (予測モデル)
 - Forward-Backward への拡張
 - “Forward Filtering, Backward Sampling”
 - Expectation-Propagation (Minka 2001)?

Future Work

- 本研究は言語モデルのため, Forward モデル (予測モデル)
 - Forward-Backward への拡張
 - “Forward Filtering, Backward Sampling”
 - Expectation-Propagation (Minka 2001)?
- 文・パラグラフ単位の変化点

Future Work

- 本研究は言語モデルのため, Forward モデル (予測モデル)
 - Forward-Backward への拡張
 - “Forward Filtering, Backward Sampling”
 - Expectation-Propagation (Minka 2001)?
- 文・パラグラフ単位の変化点
- 文書集合への拡張

Future Work

- 本研究は言語モデルのため, Forward モデル (予測モデル)
 - Forward-Backward への拡張
 - “Forward Filtering, Backward Sampling”
 - Expectation-Propagation (Minka 2001)?
- 文・パラグラフ単位の変化点
- 文書集合への拡張
 - “Document” という新しい単位の克服

Future Work

- 本研究は言語モデルのため, Forward モデル (予測モデル)
 - Forward-Backward への拡張
 - “Forward Filtering, Backward Sampling”
 - Expectation-Propagation (Minka 2001)?
- 文・パラグラフ単位の変化点
- 文書集合への拡張
 - “Document” という新しい単位の克服
 - HM-DM (Hidden Markov DM)
 - HM-LDA (Hidden Markov LDA)

Thank you

Thank you very much for listening.

Roadmap to MSM-DM

- Unigram
↓
- Dirichlet Mixture of Unigrams
 - ベイズ推定 (MacKay 1994)
 - ディリクレ分布に従った, 無数の Unigram の混合↓
- Mixture of “Dirichlet Mixture of Unigrams”
 - Dirichlet Mixture (山本他 2003)
 - 複数のディリクレ分布を用いた, 上の Unigram 混合の混合↓
- Mixture of “Mixture of Dirichlet Mixture of Unigrams”
 - MSM-DM (本発表)
 - 複数の文脈長を自動的に用いた, Dirichlet Mixture の混合