

SLC Internal tutorial

自然言語処理のための 変分ベイズ法

Daichi Mochihashi

daichi.mochihashi@atr.jp

ATR SLC

2005.6.21 (Tue)

13:15–15:00 @ Meeting Room 1

変分ベイズ法とは?

- 確率モデルのベイズ推定を行うための近似解法
 - 最尤推定 (EM) と違い, 過学習を自動的に防ぐ
 - 最尤推定が不可能な, 複雑な確率モデル
 - 通常の EM アルゴリズムの自然な拡張
- どこで使われているか?
 - 音声認識 (實廣, 中村 2004/渡辺他 2002)
 - 混合 von Mises-Fisher 分布 (田辺他 2004)
 - HMM (MacKay 1997)
 - LDA (Blei et al. 2001)
 - PCFG (栗原他 2004)
 - ...

アウトライン

- ベイズ推定と最尤推定
- 最尤推定と EM アルゴリズム
- 变分ベイズ推定と VB-EM アルゴリズム
- 变分ベイズ推定の性質
- 自然言語処理への応用
 - LDA
 - VB-HMM
- ベイズ推定のためのその他の解法

準備: 不等式

- Jensen の不等式

- 上に凸な関数 $f(x)$ について,

$$f(E[x]) \geq E[f(x)] \quad (1)$$

- $\log(x)$ は上に凸なので, $x = f(x)$ として

$$\log \int p(x) f(x) dx \geq \int p(x) \log f(x) dx. \quad (2)$$

- KL ダイバージェンス

$$D(p||q) = \int p(x) \log \frac{p(x)}{q(x)} dx \geq 0. \quad (3)$$


- $p = q$ のときに等号成立.

準備: 確率モデル

- D をデータとすると,

$$p(D) = \int p(D|\theta)p(\theta)d\theta \quad (4)$$

$$= \int p(D|\theta)p(\theta)d\theta. \quad (5)$$



$p(D|\theta), p(\theta)$: 確率モデル (生成モデル)

θ : 確率モデルのパラメータ

- 目標: データ D が与えられたとき, $p(\theta|D)$ を推定すること.

$$p(\theta|D) \propto p(\theta, D) = p(D|\theta)p(\theta). \quad (6)$$

ベイズ推定と最尤推定

$p(\theta|D)$ がわかれば、新しいデータ d の予測は

- ベイズ推定

$$p(d|D) = \int p(d|\theta)p(\theta|D)d\theta. \quad (7)$$

- $p(d|\theta)$: 確率モデルの適用
- $p(\theta|D)$: パラメータ θ の確率分布で期待値をとる.

- 最尤推定

$$p(d|D) = p(d|\hat{\theta}). \quad (8)$$

- $\theta = \hat{\theta}$ と点推定した確率モデル
- $p(\theta|D) = \delta(\hat{\theta})$ と δ 関数で近似してしまう
- $p(\theta|D)$ が実際はなだらかな時、偏った推定になる

最尤推定

- データ D と隠れ変数 z があるとき,

$$p(D|\theta) = \int p(D, z|\theta) dz \rightarrow \text{最大化.} \quad (9)$$



(6) を最大化する $\theta = \hat{\theta}$ と隠れ変数 z を求める.

- これを解く方法 EM アルゴリズム.

EM アルゴリズム (1)

- Jensen の不等式を用いると,

$$\log p(D|\theta) = \log \int p(D, z|\theta) dz \quad (10)$$

$$= \log \int q(z|D, \hat{\theta}) \frac{p(D, z|\theta)}{q(z|D, \hat{\theta})} dz \quad (11)$$

$$\geq \int q(z|D, \hat{\theta}) \log \frac{p(D, z|\theta)}{q(z|D, \hat{\theta})} dz = F(q(z), \theta) \quad (12)$$

- よって, 下限 $F(q(z), \theta)$ を交互に最大化すればよい.

$$\textbf{E step: } q(z) = \arg \max_{q(z)} F(q(z), \theta), \quad (13)$$

$$\textbf{M step: } \hat{\theta} = \arg \max_{\theta} F(q(z), \theta). \quad (14)$$

EM アルゴリズム (2)

- E step

$$F(q(z), \theta) = \int q(z|D, \hat{\theta}) \log \frac{p(D, z|\theta)}{q(z|D, \hat{\theta})} dz \quad (15)$$

$$= \int q(z|D, \hat{\theta}) \log \frac{p(z|D, \theta)p(D|\theta)}{q(z|D, \hat{\theta})} dz \quad (16)$$

$$= - \int q(z|D, \hat{\theta}) \log \frac{q(z|D, \hat{\theta})}{p(z|D, \theta)} dz + \log p(D|\theta) \quad (17)$$

$$= -\underline{D(q(z|D, \hat{\theta})||p(z|D, \theta))} + \log p(D|\theta) \quad (18)$$

は

$$q(z|D, \hat{\theta}) = p(z|D, \theta) \quad (19)$$

で最大 (E ステップ).

EM アルゴリズム (3)

- M step

$$F(q(z), \theta) = \int q(z|D, \hat{\theta}) \log \frac{p(D, z|\theta)}{q(z|D, \hat{\theta})} dz \quad (20)$$

$$= \langle \log p(D, z|\theta) \rangle_{q(z|D, \hat{\theta})} + H(q(z|D, \hat{\theta})) \quad (21)$$

よって, $F(q(z), \theta)$ を θ について最大化するには,

$$Q(\theta) = \langle \log p(D, z|\theta) \rangle_{q(z|D, \hat{\theta})} \quad (\text{Q 関数}) \quad (22)$$

に対して,

$$\frac{\partial Q(\theta)}{\partial \theta} = 0 \quad (23)$$

を解いた θ を新しい $\hat{\theta}$ とすればよい. (M ステップ)

EM アルゴリズム (まとめ)

$$\log p(D|\theta) \geq F(q(z), \theta) = \int q(z|D, \hat{\theta}) \log \frac{p(D, z|\theta)}{q(z|D, \hat{\theta})} dz \quad (24)$$

として、下限 $F(q(z), \theta)$ を $q(z), \theta$ について順に最大化する (EM アルゴリズム)。

ここで左辺と右辺の差は、

$$\log p(D|\theta) - F(q(z), \theta) \quad (25)$$

$$= \int q(z|D, \hat{\theta}) \log p(D|\theta) dz - \int q(z|D, \hat{\theta}) \log \frac{p(D, z|\theta)}{q(z|D, \hat{\theta})} dz \quad (26)$$

$$= \int q(z|D, \hat{\theta}) \log \frac{q(z|D, \hat{\theta})}{p(z|D, \theta)} dz \quad (27)$$

$$= D(q(z|D, \hat{\theta}) || p(z|D, \theta)) \geq 0. \quad (28)$$


この KL ダイバージェンスを最小化していることに相当。

Example: PLSI (1/3)

- ある単語 w が文書 d で生起したとき, 隠れ変数 z があって

$$p(d, w, z) = p(z)p(d|z)p(w|z) \quad (29)$$

と分解できたと仮定する.



- 文書 $\mathbf{w} = w_1 w_2 \cdots w_n$ の集合 $W = \{\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_D\}$, 文書のインデックス集合 $\mathcal{D} = \{1, 2, \dots, D\}$ について,

$$p(\mathcal{D}, W, Z) = \prod p(d, \mathbf{w}_d, \mathbf{z}_d) \quad (30)$$

$$= \prod_d \prod_n p(d, w_{dn}, z_{dn}) \quad (31)$$

$$= \prod_d \prod_n p(z_{dn})p(d|z_{dn})p(w_{dn}|z_{dn}) \quad (32)$$

$$\therefore \log p(\mathcal{D}, W, Z) = \sum_d \sum_n [\log p(z_{dn}) + \log p(d|z_{dn}) + \log p(w_{dn}|z_{dn})]. \quad (33)$$

Example: PLSI (2/3)

- Q 関数 $\langle \log p(D, z|\theta) \rangle_{p(z|D,\theta)}$ を計算すると,

$$Q(z) = \langle \log p(\mathcal{D}, W, Z) \rangle_{p(Z|\mathcal{D}, W)} \quad (34)$$

$$\begin{aligned} &= \sum_d \sum_n \left[\sum_z p(z|d, w_{dn}) \log p(z_{dn}) \right. \\ &\quad + \sum_z p(z|d, w_{dn}) \log p(d|z_{dn}) \\ &\quad \left. + \sum_z p(z|d, w_{dn}) \log p(w_{dn}|z_{dn}) \right]. \end{aligned} \quad (35)$$

- $\delta Q / \delta \theta$ を計算すると,

$$\frac{\delta Q}{\delta p(z)} = \frac{\sum_d \sum_n p(z|d, w_{dn})}{p(z)} + \lambda = 0 \quad (36)$$

$$\therefore p(z) \propto \sum_d \sum_n p(z|d, w_{dn}) \propto \sum_d \sum_w n(d, w) p(z|d, w) \quad (37)$$

Example: PLSI (3/3)

- 同様にして,

$$p(d|z) \propto \sum_n p(z|d, w_{dn}) \propto \sum_w n(d, w) p(z|d, w) \quad (38)$$

$$p(w|z) \propto \sum_d \sum_n p(z|d, w_{dn}) \propto \sum_d n(d, w) p(z|d, w). \quad \square$$

- ここで

$$p(z|d, w) \propto p(z, d, w) = p(z)p(d|z)p(w|z). \quad (40)$$

- この場合, 文書 d ごとにパラメータ

$$\theta(d) = p(z|d) \quad (41)$$

$$\propto p(z)p(d|z) \quad (42)$$


を点推定していることに相当する.

EM アルゴリズムの欠点

- θ は given, 点推定
- 隠れ変数 z が 1 層だけある場合にしか適用不可能
- 過学習してしまう (z はバラバラ).
↓
ベイズ推定.

ベイズ推定

$$p(D) = \iint p(D, z, \theta) dz d\theta \rightarrow \text{最大化.} \quad (43)$$



(26) を最大化する z, θ の確率分布 $p(z|D), p(\theta|D)$ を求めることが目標.

$$\log p(D) = \log \iint q(z, \theta|D) \frac{p(D, z, \theta)}{q(z, \theta|D)} dz d\theta \quad (44)$$

$$\geq \iint q(z, \theta|D) \log \frac{p(D, z, \theta)}{q(z, \theta|D)} dz d\theta \quad (45)$$

この下限はそのままでは z, θ のそれぞれに対して最大化できないので,

$$q(z, \theta|D) = q(z)q(\theta) \quad (46)$$

という因子分解を仮定すると,

変分ベイズ推定

$$\log p(D) \geq \iint q(z, \theta | D) \log \frac{p(D, z, \theta)}{q(z, \theta | D)} dz d\theta \quad (47)$$

$$= \iint q(z) q(\theta) \log \frac{p(D, z\theta)}{q(z)q(\theta)} dz d\theta \quad (48)$$

$$= F(q). \quad (\text{変分自由エネルギー}) \quad (49)$$

この下限 (変分下限, variational lower bound) $F(q)$ は $q(z), q(\theta)$ について逐次最大化できる。

Maximize w.r.t. $q(z)$

$$\begin{aligned} L &= F(q) + \lambda \left(\int q(z) dz - 1 \right) \\ &= \iint q(z) q(\theta) \log \frac{p(D, z, \theta)}{q(z) q(\theta)} dz d\theta + \lambda \left(\int q(z) dz - 1 \right) \quad \text{とおくと}, \end{aligned} \tag{50}$$

$$\begin{aligned} \frac{\delta L}{\delta q(z)} &= \iint q(\theta) [\log p(D, z, \theta) - \log q(\theta) - \log q(z) - 1] dz d\theta + \lambda \\ &= \iint q(\theta) [\log p(D, z|\theta) + \log p(\theta) - \log q(\theta) - \log q(z) - 1] dz d\theta + \lambda \\ &= \langle \log p(D, z|\theta) \rangle_{q(\theta)} - \log q(z) + (\text{const.}) + \lambda = 0 \end{aligned} \tag{51}$$

$$\therefore q(z) \propto \exp \langle \log p(D, z|\theta) \rangle_{q(\theta)}. \tag{52}$$

Maximize w.r.t. $q(\theta)$

$$L = F(q) + \lambda \left(\int q(\theta) d\theta - 1 \right) \quad (53)$$

$$= \iint q(z) q(\theta) \log \frac{p(D, z, \theta)}{q(z) q(\theta)} dz d\theta + \lambda \left(\int q(\theta) d\theta - 1 \right) \quad (54)$$

$$\begin{aligned} \frac{\delta L}{\delta q(\theta)} &= \iint q(z) [\log p(D, z, \theta) - \log q(\theta) - \log q(z) - 1] dz d\theta + \lambda \\ &= \iint q(z) [\log p(D, z|\theta) + \log p(\theta) - \log q(\theta) - \log q(z) - 1] dz d\theta + \lambda \\ &= \langle \log p(D, z|\theta) \rangle_{q(z)} + \log p(\theta) - \log q(\theta) + (\text{const.}) + \lambda = 0 \end{aligned} \quad (55)$$

$$\therefore q(\theta) \propto p(\theta) \exp \langle \log p(D, z|\theta) \rangle_{q(z)}. \quad (56)$$

変分ベイズ推定のまとめ

- 観測データ D に対して, 隠れ変数 z , パラメータ θ をすべて確率変数とみて, その確率分布を求める.

$$\log p(D) = \log \iint p(D, z, \theta) dz d\theta \quad (57)$$

$$\geq \iint q(z)q(\theta) \log \frac{p(D, z, \theta)}{q(z)q(\theta)} dz d\theta = F(q). \quad (58)$$

- $F(q)$ を $q(z)$, $q(\theta)$ に関して最大化すると,

$$\begin{cases} q(z) \propto \exp \langle \log p(D, z | \theta) \rangle_{q(\theta)} & \text{(VB-E step)} \quad (59) \\ q(\theta) \propto p(\theta) \exp \langle \log p(D, z | \theta) \rangle_{q(z)} & \text{(VB-M step)} \quad (60) \end{cases}$$

… VB-EM アルゴリズム.

変分ベイズ法について (1)

- VB-EM アルゴリズム:

$$\begin{cases} q(z) \propto \exp \langle \log p(D, z|\theta) \rangle_{q(\theta)} & (\text{VB-E step}) \quad (61) \\ q(\theta) \propto p(\theta) \exp \langle \log p(D, z|\theta) \rangle_{q(z)} & (\text{VB-M step}) \quad (62) \end{cases}$$

$q(\theta) = \delta(\hat{\theta})$ のとき, (44) 式は

$$q(z) \propto p(D, z|\hat{\theta}) \propto p(z|D, \hat{\theta}) \quad (63)$$

… EM アルゴリズムの E-step と同じ.

変分ベイズ法について (2)

$$\log p(D) \geq F(q). \quad (64)$$

ここで、

$$\log p(D) - F(q) \quad (65)$$

$$= \iint q(z, \theta) \log p(D) dz d\theta - \iint q(z, \theta) \log \frac{p(D, z, \theta)}{q(z, \theta)} dz d\theta \quad (66)$$

$$= \iint q(z, \theta) [\log p(D) - \log p(z, \theta | D) - \log p(D) + \log q(z, \theta)] dz d\theta \quad (67)$$

$$= \iint q(z, \theta) \log \frac{q(z, \theta)}{p(z, \theta | D)} dz d\theta \quad (68)$$

$$= D(q(z, \theta) || p(z, \theta | D)) \geq 0. \quad (69)$$

この近似誤差をできるだけ小さくするように, $q(z, \theta) = q(z)q(\theta)$ を最適化している。

変分ベイズ法について (3)

$$F(q) = \iint q(z)q(\theta) \log \frac{p(D, z, \theta)}{q(z)q(\theta)} dz d\theta \quad (70)$$

$$= \iint q(z)q(\theta) \log \frac{p(D, z|\theta)}{q(z)} \underbrace{\frac{p(\theta)}{q(\theta)}}_{\text{p(\theta)}} dz d\theta \quad (71)$$

$$= \left\langle \log \frac{p(D, z|\theta)}{q(z)} \right\rangle_{q(z)q(\theta)} - \int q(\theta) \log \frac{q(\theta)}{p(\theta)} d\theta \quad (72)$$

$$= \left\langle \log \frac{p(D, z|\theta)}{q(z)} \right\rangle_{q(z)q(\theta)} \underbrace{- D(q(\theta|D)||p(\theta))}_{\text{過学習を防ぐ (正則化項)}} \quad (73)$$

$$\left(\rightarrow \left\langle \log \frac{p(D, z|\theta)}{q(z)} \right\rangle_{q(z)q(\theta)} \underbrace{- \frac{|\hat{\theta}|}{2} \log N + \log p(\hat{\theta})}_{\substack{\text{MDL, BIC} \\ (\text{const.})}} \right) \quad (74)$$

- パラメータ事前分布と事後分布の KL ダイバージェンスで、自動的に正則化が行われる。

変分ベイズ法のまとめ (2)

- 学習データの尤度の下限を、変分近似して最大化する

$$\log p(D) \geq F(q) \rightarrow \text{最大化.} \quad (75)$$

- 左辺と右辺の差は KL ダイバージェンス (\rightarrow 最小化).
- $\delta F/\delta q(z), \delta F/\delta q(\theta) \rightarrow$ VB-EM アルゴリズム.
 - パラメータの確率分布 $q(z), q(\theta)$ が求まる (\neq 点推定)
 - $q(\theta)$ が δ 関数のとき、通常の EM アルゴリズムと一致
- パラメータの過学習を防ぐ… パラメータの事前分布 $p(\theta)$ と事後分布 $q(\theta|D)$ との KL-ダイバージェンスで自動的に正則化
- データ数 $N \rightarrow \infty$ の極限で MDL/BIC と一致

応用: LDA

- PLSI では文書 d について対応する パラメータ $\theta = p(z|d)$ を点推定 したが、これは過学習する恐れがある
- θ 自体に確率を与える (ディリクレ分布) :

$$p(\theta) \sim \text{Dir}(\theta|\alpha) \quad (76)$$

- $\beta = p(w|z)$ とおくと、

$$p(\mathbf{w}|\alpha, \beta) = \int p(\theta|\alpha) \prod_n p(w_n|\theta, \beta) d\theta \quad (77)$$

$$= \frac{\Gamma(\sum_k \alpha_k)}{\prod_k \Gamma(\alpha_k)} \int \prod_k \theta_k^{\alpha_k - 1} \prod_n \sum_z \prod_v (\theta_z \beta_{zv})^{w_n^v} d\theta$$

→ 最大化. (78)

応用: LDA (2)

$$\log p(\mathbf{w}|\alpha, \beta) = \log \int \sum_z p(\mathbf{w}, z, \theta|\alpha, \beta) d\theta \quad (79)$$

$$= \log \int \sum_z q(z, \theta|\gamma, \psi) \frac{p(\mathbf{w}, z, \theta|\alpha, \beta)}{q(z, \theta|\gamma, \psi)} d\theta \quad (80)$$

$$\geq \int \sum_z q(z, \theta|\gamma, \psi) \log \frac{p(\mathbf{w}, z, \theta|\alpha, \beta)}{q(z, \theta|\gamma, \psi)} d\theta \quad (81)$$

- $q(z, \theta|\mathbf{w}, \gamma, \psi) = q(\theta|\gamma) \prod_n q(z_n|w_n, \psi)$ と近似すると,

$$\begin{aligned} \log p(\mathbf{w}|\alpha, \beta) &\geq \langle \log p(\theta|\alpha) \rangle_{q(\theta|\gamma)} + \sum_n \langle \log p(z_n|\theta) \rangle_{q(\theta|\gamma), q(z_n|w_n, \psi)} \\ &\quad + \sum_n \langle \log p(w_n|z_n, \beta) \rangle_{q(z_n|w_n, \psi)} \\ &\quad - \langle \log q(\theta|\gamma) \rangle_{q(\theta|\gamma)} - \sum_n \langle \log q(z_n|w_n, \psi) \rangle_{q(z_n|w_n, \psi)}. \end{aligned} \quad (82)$$

VB-HMM

- 観測系列 $\mathbf{y} = y_1 y_2 \cdots y_T$ に対して、隠れた真の状態系列 $\mathbf{s} = s_1 s_2 \cdots s_T$ がって、
- HMM のパラメータ
 - 初期状態確率 π ($1 \times K$)
 - 状態遷移行列 C ($K \times K$)
 - 出力確率行列 A ($K \times W$) について

$$\log p(\mathbf{y}) = \log \int d\pi \int dA \int dC \sum_{\mathbf{s}} p(\pi, A, C) p(\mathbf{y}, \mathbf{s} | \pi, A, C) \quad (83)$$

$$\geq \int d\pi \int dA \int dC \sum_{\mathbf{s}} q(\pi, A, C, \mathbf{s}) \log \frac{p(\pi, A, C) p(\mathbf{y}, \mathbf{s} | \pi, A, C)}{q(\pi, A, C, \mathbf{s})}. \quad (84)$$

VB-HMM (2)

- π, C の各列, A の各列にそれぞれディリクレ事前分布 $\text{Dir}(\alpha), \text{Dir}(\beta), \text{Dir}(\gamma)$ を考えると,
- VB-Estep:

$$\langle \pi_k \rangle \propto \exp\left(\Psi(\alpha_k^*) - \Psi\left(\sum_k \alpha_k^*\right)\right) \quad (85)$$

$$\langle A_{ij} \rangle \propto \exp\left(\Psi(\beta_{ij}^*) - \Psi\left(\sum_j \beta_{ij}^*\right)\right) \quad (86)$$

$$\langle C_{ij} \rangle \propto \exp\left(\Psi(\gamma_{ij}^*) - \Psi\left(\sum_j \gamma_{ij}^*\right)\right) \quad (87)$$

- VB-Mstep:
 - パラメータ α, β, γ の事後分布 $\alpha^*, \beta^*, \gamma^*$ を Forward-Backward から更新.
- 詳細は Beal, M.J. (2003) Variational Algorithms for Approximate Bayesian Inference. PhD thesis, Gatsby UCL. <http://www.cse.buffalo.edu/faculty/mbeal/thesis/> Chapter.3.

ベイズ推定のための解法

- 変分ベイズ法は、グラフィカルモデル (or, ベイジアンネットワーク) を解くための方法の一つ
- Gibbs sampling, MCMC
 - モデルから実際にサンプリングして、平均を取る
 - 近似のない、正確な推定が可能
 - 複雑なモデルでも、多くの場合適用できる
 - 計算時間が長い (LDA の場合、3倍くらい (らしい))
- EP (Expectation Propagation) (Minka 2001),
Power EP (Minka 2004)
 - VB とは別の解析的近似
 - EP ... KL-ダイバージェンス最小
 - Power EP ... α -ダイバージェンス最小

Readings

- Hagai Attias. A Variational Bayesian Framework for Graphical Models. In *NIPS 1999*, 1999.
- Thomas Minka. Expectation-Maximization as lower bound maximization, 1998.
<http://research.microsoft.com/~minka/papers/em.html>.
- Radford M. Neal and Geoffrey E. Hinton. *A View of the EM Algorithm that Justifies Incremental, Sparse, and other Variants*. in *Learning in Graphical Models*, pages 355–368. Dordrecht: Kluwer Academic Publishers, 1998.
- Zoubin Ghahramani. *Unsupervised Learning*. in *Advanced Lectures on Machine Learning LNAI 3176*. Springer-Verlag, Berlin, 2004.
<http://www.gatsby.ucl.ac.uk/~zoubin/course04/ul.pdf>.