

MDLの効率的計算のための事前分布設定

豊橋技術科学大学 情報・知能工学系 渡辺一帆

概要

- 正規化最尤符号 (NML) の計算: 符号長, 予測分布

NML

$$p_{NML}^{(n)}(x^n)$$

計算困難

Bayes

$$\int p(x^n | \theta) \underline{q(\theta)} d\theta$$

効率的に計算可
(近似, 別表現)

- 漸近的ミニマックスにする (精度良く近似する) にはどうしたらいいか? [Watanabe, Roos, Myllymäki, ACML2013]
[Watanabe & Roos, J. Mach. Learn. Res.]
- 別表現を用いて効率的計算が可能か?
[Barron, Roos, Watanabe, ISIT2014]

ユニバーサル符号化

- 系列の予測

$x_1, \dots, x_{i-1}, x_i, \dots, x_n$

$\{p(x^n | \theta); \theta \in \Theta\}$: 学習モデル

$$p(x^n) = \prod_{i=1}^n p(x_i | x^{i-1})$$

予測分布
 $-\log p(x^n)$: 累積誤差 (符号長)

$-\log p(x^n | \hat{\theta}(x^n))$: 理想的な符号長 (x^n だけ符号化するなら)

← 最尤推定量

$$\min_{\bar{p}} \max_{x^n} \log \frac{p(x^n | \hat{\theta}(x^n))}{\bar{p}(x^n)}$$

← どんなデータ系列であっても

最大リグレット最小化



ミニマックス解は

正規化最尤法 (NML)

- 正規化最尤符号 [Shtarkov, 1987]

$$p_{NML}^{(n)}(x^n) = \frac{p(x^n | \hat{\theta}(x^n))}{C_n}$$

$$C_n = \sum_{x^n} p(x^n | \hat{\theta}(x^n))$$

- いくつかのモデルでは計算可
- モデル選択への応用:
 - 多項モデル, マルコフモデル, ベイジアンネット ...
- 非漸近 (少サンプル) での有効性

[Kontkanen & Myllymäki, 2007]

[Silander, Roos, & Myllymäki, 2010]

[本セッションでの他の講演と参考文献]

正規化最尤法(2)

- 確率的コンプレキシティ(NMLの符号長)

$$-\log p_{NML}^{(n)}(x^n) = -\log p(x^n | \hat{\theta}(x^n)) + \log C_n$$

- パラメトリックコンプレキシティ(NMLのリグレット)

$$\log \frac{p(x^n | \hat{\theta}(x^n))}{p_{NML}^{(n)}(x^n)} = \log C_n \quad (\text{すべての } x^n \text{ で})$$

- 予測分布(逐次符号化で必要 例:算術符号)

$$p_{NML}^{(n)}(x_i | x^{i-1}) = \frac{p_{NML}^{(n)}(x^i)}{\sum_{x_i} p_{NML}^{(n)}(x^i)}$$

□ NMLの予測分布の計算はnの指数オーダー

ベイズ符号

$$p_B(x^n) = \int p(x^n | \theta) \underbrace{q(\theta)}_{\text{事前分布}} d\theta \quad \text{: ベイズ混合(エビデンス)}$$

- 予測分布

$$\begin{aligned} p_B(x_{i+1} | x^i) &= \frac{\int p(x_{i+1} | \theta) p(x^i | \theta) q(\theta) d\theta}{\int p(x^i | \theta) q(\theta) d\theta} \\ &= \int p(x_{i+1} | \theta) \underbrace{q(\theta | x^i)}_{\text{事後分布}} d\theta \end{aligned}$$

$$q(\theta | x^i) = \frac{p(x_i | \theta) q(\theta | x^{i-1})}{p_B(x_i | x^{i-1})} \quad \text{事後分布}$$

□ ベイズ符号の予測分布は逐次的に計算可

漸近的ミニマックス性

- NMLとの差が $o(1)$ にできるか？ g : 計算しやすい分布

$$\log \frac{p(x^n | \hat{\theta}(x^n))}{g(x^n)} \leq \log C_n + o(1) \quad (\text{すべての } x^n \text{ で})$$

- サンプル数(ホライゾン)依存性

「 n に依存しない」 $\iff g(x^{\tilde{n}}) = \sum_{x_{\tilde{n}+1}^n} g(x^n) \quad (\tilde{n} < n)$

○ 例えば、 $g(x^n) = \int p(x^n | \theta) \underbrace{q(\theta)}_{\text{事前分布}} d\theta$

$q(\theta)$ を n に応じて設計 \implies 漸近的ミニマックス
[Xie & Barron, 2000]
[Takeuchi & Barron, 1997]

多項モデル

- 有限アルファベット上の定常無記憶情報源

$$p(x^n | \theta) = \prod_{i=1}^n \theta_{x_i} \quad \theta = (\theta_1, \theta_2, \dots, \theta_m) \quad \sum_{j=1}^m \theta_j = 1$$

$x_i \in \{1, 2, \dots, m\}$

- 共役事前分布 (ディリクレ分布)
- ベイズ混合による予測

$$q(\theta) = \frac{\Gamma(m\alpha)}{\Gamma(\alpha)^m} \prod_{j=1}^m \theta_j^{\alpha-1}$$

← ディリクレ分布

$$p(x_{l+1} = j | x^l) = \int p(x_{l+1} = j | \theta) \underline{q(\theta | x^l)} d\theta$$

$$= \frac{l_j + \alpha}{l + m\alpha}$$

l_j : x^l 中の j の数


$\alpha=1$: Laplace

$\alpha=1/2$: Krichevski-Trofimov

漸近的ミニマックス性とサンプル数依存性

- 定理 [Watanabe & Roos, J. Mach. Learn. Res.]:

多項モデルでは

漸近的ミニマックス  サンプル数 n の知識が必要
(ベイズ混合では $q(\theta)$ が n に依存)

証明の概略)

$\alpha=1/2$ のベイズ混合(ジェフリーズ混合)は、 $n \rightarrow \infty$ でNMLに十分に近くなるが漸近的ミニマックスではない。

あるサンプル数と系列におけるジェフリーズ混合との差を考えると、 n に依存しない場合、(少なくとも一つの)その系列の延長では、差が残り続ける。

一般のモデルの場合

- 仮定 ある $x^{\tilde{n}}$ に対し、 例: $\tilde{n} = \sqrt{n}$

$$\log \frac{p_{NML}^{(\tilde{n})}(x^{\tilde{n}})}{\sum_{x_{\tilde{n}+1}^n} p_{NML}^{(n)}(x^n)} \rightarrow M > 0 \quad (n \rightarrow \infty)$$

意味: p_{NML} は n とともに変化する(その度合いが M)

- 定理 [Watanabe, Roos, Myllymäki, ACML2013]

仮定の下, g が n に依存しない

→ (すべての x^n で)

$$\log C_n - \underline{M} + o(1) \leq \log \frac{p(x^n | \hat{\theta}(x^n))}{g(x^n)} \leq \log C_n + o(1)$$


$\underline{M} (< M)$ は任意の定数 とはならない

多項モデルでのNMLの変動(仮定のM)

- $$\log \frac{p_{NML}^{(\tilde{n})}(x^{\tilde{n}})}{\sum_{x_{\tilde{n}+1}^n} p_{NML}^{(n)}(x^n)} = \sum_{j=1}^m \left\{ l_j \log l_j - \log \Gamma(l_j + 1/2) - l_j + \frac{\log 2\pi}{2} \right\} + o(1)$$

l_j : $x^{\tilde{n}}$ 中のjの数

- $$\sum_{n_j \geq l_j} \binom{n - \tilde{n}}{n_j - l_j} \prod_{j=1}^m \left(\frac{n_j}{n} \right)^{n_j}$$
 の評価が必要

$l_1 = \tilde{n}$  $M = \frac{m-1}{2} \log 2$ ととれる。

$l_j = 0 \ (j = 2, \dots, m)$

単純なn依存性と漸近的ミニマックス性

- $\alpha_n^* = \arg \min_{\alpha} \max_{x^n} \log \frac{p(x^n | \hat{\theta}(x^n))}{p_{B,\alpha}(x^n)}$ (数值的に計算)

- 漸近的な近似


$$\alpha_n = \frac{1}{2} - \frac{\log 2}{2} \frac{1}{\log n}$$

導出:

○ $n_j = n$ (一つのjで)

○ $n_j = n/m$

➡ リグレットを等しくする。



単純なn依存性と漸近的ミニマックス性(2)

- 定理 [Watanabe, Roos, Myllymäki, ACML2013]

α_n を用いたベイズ混合は漸近的ミニマックス。

しかも,

$$\log C_n - M + o(1) \leq \log \frac{p(x^n | \hat{\theta}(x^n))}{p_{B, \alpha_n}(x^n)} \leq \log C_n + o(1)$$

(すべての x^n で) となる。

$$M = \frac{m-1}{2} \log 2$$

証明の概略: スターリングの公式を適用し, 定数オーダーの項を評価。

- 強い意味での漸近的ミニマックス性をほぼ達成する。

数値実験(ベルヌーイモデル:m=2)

- nに依存(ベイズ混合)

- p_{B,α_n^*} p_{B,α_n}

- 修正ジェフリーズ [Xie & Barron, 2000] ジェフリーズ事前分布

$$q_{MJ}^{(n)}(\theta) = \frac{\varepsilon_n}{2} \{ \delta(\theta - 1/n) + \delta(\theta - 1 + 1/n) \} + (1 - \varepsilon_n) \underline{b_{1/2}}(\theta)$$

$$\varepsilon_n = n^{-1/8} \quad \varepsilon_n : \text{最大リグレット最小化}$$

- nに依存しない

- $p_{B,1/2}$ (ジェフリーズ事前分布)

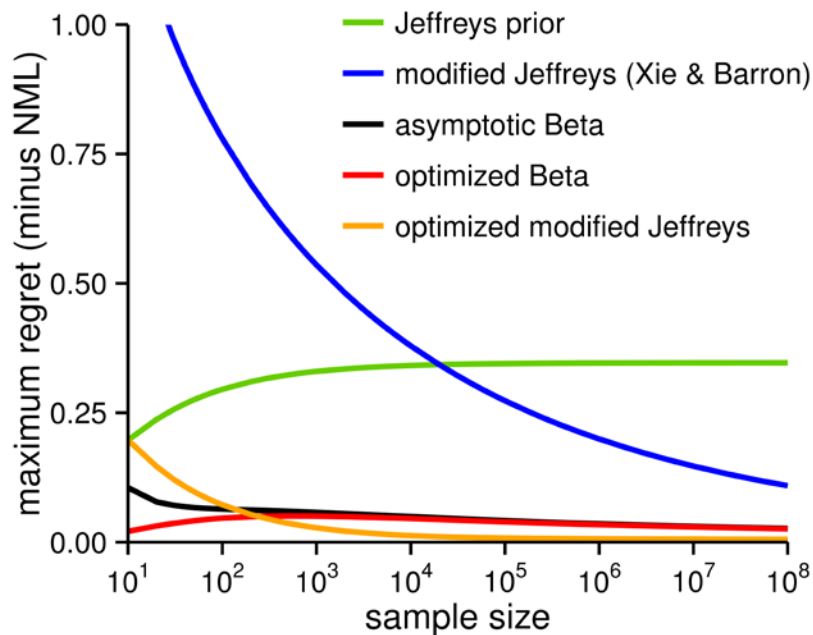
- k-Last-step minimax (Sequential NML)

[Takimoto & Warmuth, 2000] [Rissanen & Roos, 2007]

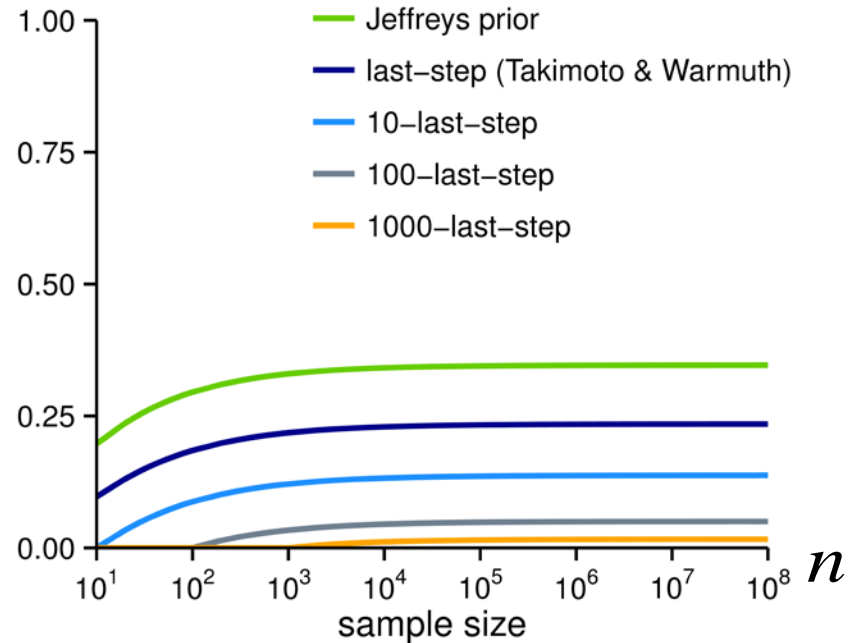
$$p_{kLS}(x_{t-k+1}^t | x^{t-k}) \propto p(x^t | \hat{\theta}(x^t)) \quad (\text{k個分を正規化})$$

数値実験 (m=2)

● nに依存(ベイズ混合)



● nに依存しない



□ 少サンプル数での有効性


□ 漸近的ミニマックス(0に収束) → n依存性が必要

離散混合によるNML

- 事前分布を離散分布とする

$$q(\theta) = \sum_{j=1}^K \pi_j \delta(\theta - \theta_j)$$

$$p_B(x^n) = \sum_{j=1}^K \pi_j p(x^n | \theta_j)$$



- 定理 [Barron, Roos, Watanabe, ISIT2014]

$T(x^n)$: 十分統計量 (K通りの値をとる)

$\Theta_K = \{\theta_1, \dots, \theta_K\}$ に対し、 $T(x^n)$ の分布が線形独立

⇒ $p_{NML}^{(n)}(x^n) = \sum_{j=1}^K \pi_j p(x^n | \theta_j)$ と表現可

□ π_j は負でもよい

負の重みが必要な例

- $X \in \{1, 2, 3\}$

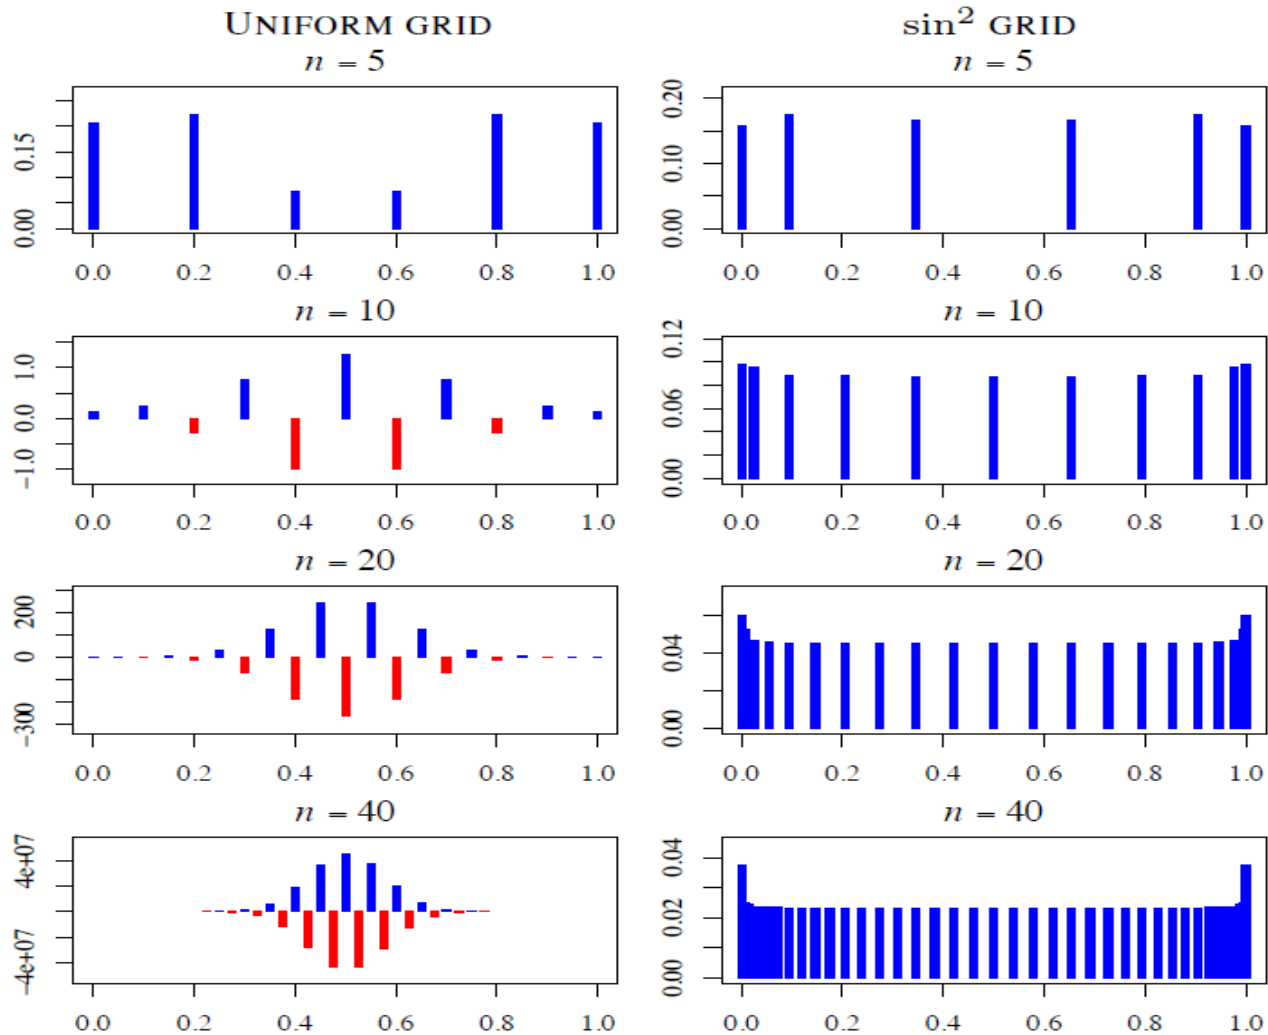
モデル:

$$p_1 = \left(\frac{1}{2}, \frac{1}{2}, 0 \right) \quad p_2 = \left(0, \frac{1}{2}, \frac{1}{2} \right) \quad p_3 = \left(\frac{2}{7}, \frac{3}{7}, \frac{2}{7} \right)$$

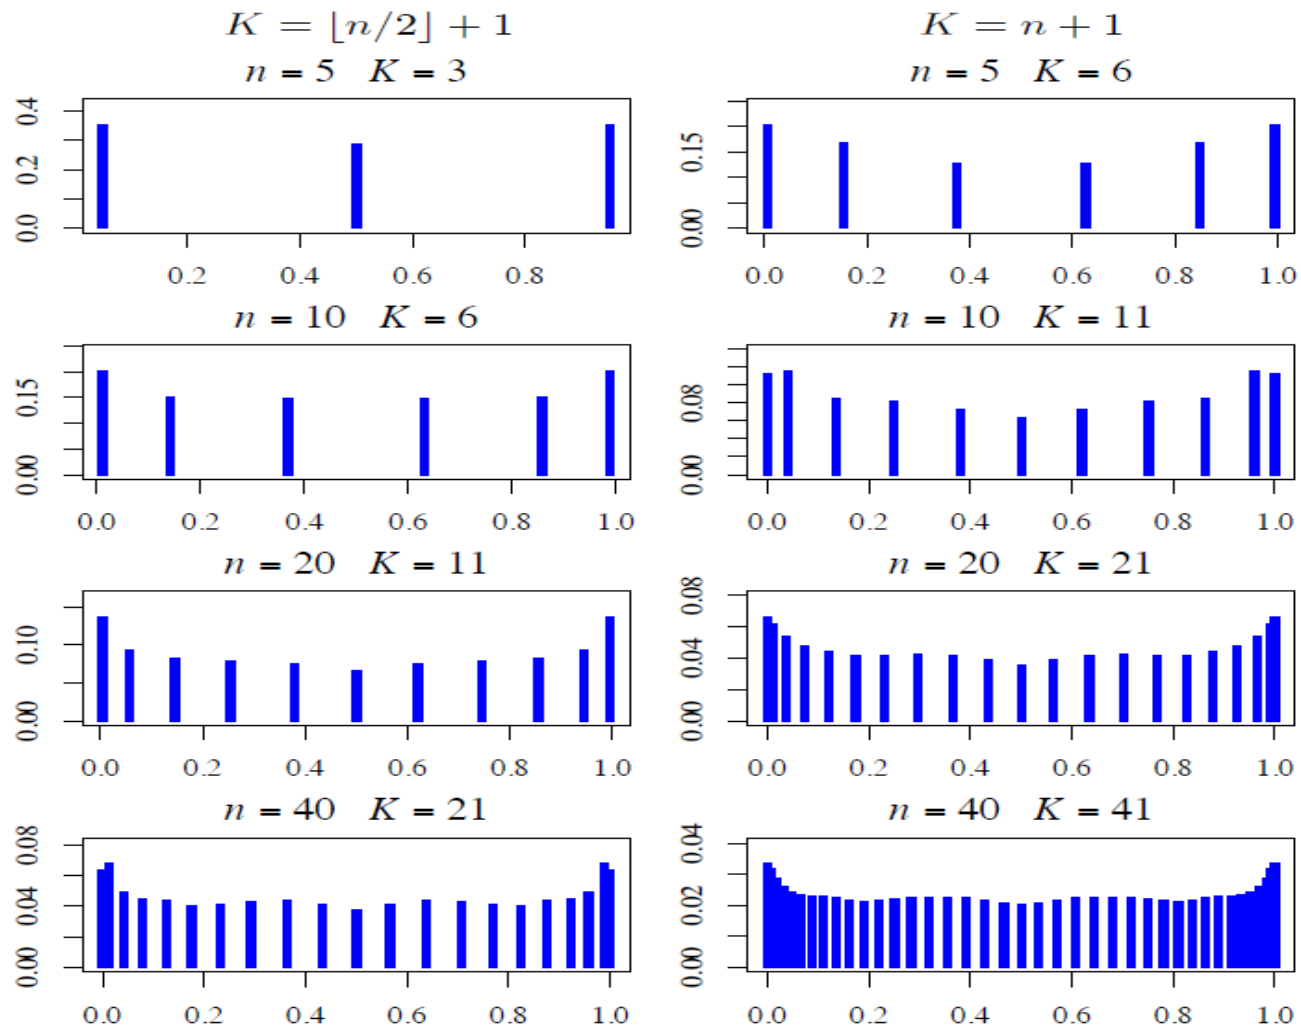
$$\max_{\theta} p(x | \theta) = \frac{1}{2} \quad (x = 1, 2, 3)$$

$$\begin{aligned} p_{NML} &= \left(\frac{1}{3}, \frac{1}{3}, \frac{1}{3} \right) \\ &= -\frac{2}{3} p_1 - \frac{2}{3} p_2 + \frac{7}{3} p_3 \quad (\text{一意}) \end{aligned}$$

ベルヌーイモデル: サポートを固定



ベルヌーイモデル: サポートを最適化



まとめ

- 正規化最尤法の効率的な計算について
 - 漸近的ミニマックス性とサンプル数依存性の関係
 - 離散混合を用いた正確計算法を紹介した。