

入門ベイズ統計
§ 11.3 ジーマン-ジーマンによる
画像処理モデル

12月5日

田中洸一

内容

- 1. 概略
- 2. ギブスサンプリングの利用の意義
- 3. マルコフ確率場とギブス分布
- 4. ベイズの定理の適用

1. 概略

- 「画像」は「濃度」を持つ多くの点の集合

$x(i, j)$: 真のピクセル 値の濃度 $e(i, j)$: 誤差 $Y(i, j)$: 観測値

$$Y(i, j) = x(i, j) + e(i, j)$$

- 目的は $Y(i, j)$ から $x(i, j)$ を推定する
↓ 方法の1つ
- 「ギブスサンプリング」による「ジーマンジーマン」の手法
- 次は、なぜギブスサンプリングなのかを説明する。

2. ギブスサンプリングの利用の意義

- 1. ギブス分布を使う
 - 2. 確率分布の扱い方が、ベイズ統計学の考え方(式展開)で用いられている
 - 3. 事後分布の一部の計算が大変であるが、「MCMC法」により、実現可能となった。
 - 4. 3. によって実際にソフトウェアも開発され、ベイズ統計学に用いられている
- 次からギブスサンプリングが利用できることを説明する。

3. マルコフ確率場とギブス分布

- ものの'かたち'は似た性質の集合からできている
- (i, j) と (i', j') が近ければ、 $X(i, j)$ と $X(i', j')$ は関係がある
- $\{X(i, j)\}$ は、確率場であって、異なった (i, j) は相関があると仮定
- マルコフ性を仮定し、「マルコフ確率場」を定義
 (i, j) の近傍を V とするとき

$$P(x(i, j) | x(i, k), (i, k) \neq (i, j)) = P(x(i, j) | x(i, k), (i, k) \in V)$$

※ここでの近傍は近い位置に位置しているということ

3. マルコフ確率場とギブス分布

- マルコフ確率場はその点の局所的周囲のみ確率が影響を受ける



- 「画像」はマルコフ確率場であると考えられる
- 次に、あるたとえ話で説明していく

3. マルコフ確率場とギブス分布

社会

=人 (i,j)

=クリーク (仲間)



=トモダチ

ある人のトモダチである \Leftrightarrow その人の近傍 V に入っている。

3. マルコフ確率場とギブス分布

- $x(i, j)$ = 人 (i, j) の能力
- U_c : クリーク c としての '業績指標'
- 社会全体が成し遂げる業績指標

$$E(x) = \sum_{c \in C} U_c(x) \quad \text{※ } x: \{x(i, j)\} \text{ を略記}$$

- 高い E の値は難しく、低い E の値が起こりやすい。
- その確率は、パラメータ β を用いて以下に与えられる

$$\frac{1}{z} \cdot e^{-\beta E(x)} \quad (z = \sum e^{-\beta U(x)}) \quad (11.3.1)$$

3. マルコフ確率場とギブス分布

- つまり、高いEは確率が小さく、低いEは大きい。
↓ β を変動
- $\beta \rightarrow 0$ のときは高いEが増え低いEが減る。
 $\beta \rightarrow \infty$ のときは低いEへの集中が起こる。
- つまり、 β はその社会の周囲の外的環境の因子と考えられる。
- この確率にしたがって $\{x(i,j)\}$ が生起するならその確率変数はマルコフ確率場になる。
- この関数形の確率分布自体が「ギブス分布」である。
- ギブス分布をうまく画像処理の $\{x(i,j)\}$ に適用するのがジーマン-ジーマンの方法である。次に示す。

4. ベイズの定理の適用

- 画像劣化の式

$$Y(i,j) = x(i,j) + e(i,j) \quad \rightarrow \quad Y_s = x_s + e_s (s \in S)$$

- 誤差のノイズ e_s は加法的で作用し正規分布 $\mathcal{N}(0, \sigma^2)$ に従い、
 $s \in S$ ごとに独立
- 劣化した $\{Y_s\}$ の尤度は、 $|S|$ 次元正規分布

$$\pi(y|x) = \left(\frac{1}{2\pi\sigma^2}\right)^{|S|/2} \exp\left\{-\frac{1}{2\sigma^2} \sum_{s \in S} (y_s - x_s)^2\right\} \quad (|S| = S \text{ の個数})$$

4. ベイズの定理の適用

- x_s に、事前分布をギブス分布とする

$$\pi(x) = \frac{1}{Z} \exp\{\beta \sum_{[s,t]} x_s x_t\}$$

- よって、事後確率は以下となる。

$$\pi(x|y) = \frac{1}{Z_p} \exp\{\beta \sum_{[s,t]} x_s x_t - \frac{1}{2\sigma^2} \sum_{s \in S} (y_s - x_s)^2\}$$

※ Z_p は規格化定数で $\exp\{\quad\}$ の積分

- $\pi(x|y)$ を最大にする $x = \hat{x}$ を選べばよい
- しかし、 Z_p の計算が大変
↓
- 「MCMC法」によって実現可能となった。