

Gibbs Sampling による Simulated Annealing 法の画像復元問題への適用について

千代延研究室 土井 博善

論文の目的

写真などの画像データはさまざまな要因により本来の画像とは違った画像としてデータが得られる。この得られたデータから本来の画像を Markov Chain を用いた Gibbs Sampling に対する Simulated Annealing の方法を用いて推定することである。また、この論文は Pierre Bremaud 著、Markov Chains Gibbs Fields, Monte Carlo Simulation, And Queues を参考に書かれている。

画像の配置空間

次のような空間で画像を考える。

画像の配置空間： S^Λ を次のように定義する。

- $\Lambda = Z_m^2 = \{(i, j) \in Z^2, i, j \in [1, m]\}$: ピクセルの空間
- $S = \{+1, -1\}$: 各ピクセルの値

各ピクセルの値について、 $+1$ を黒色、 -1 を白色と表すことで、白黒画像を表現する。



図 0.1: 配置空間の 1 つの配置の例

重要な前提

数学的な枠組みを考えるにあたって、得られるすべての画像の配置は(次に述べる)Gibbs 分布に従う、 S^Λ 上の確率に従う確率変数の一つのサンプルである。

Gibbs Distribution

確率分布

$$\pi_T(x) = \frac{1}{Z_T} e^{-\frac{1}{T}\varepsilon(x)}$$

に従う S^Λ 上の分布を Gibbs 分布と呼ぶ。画像モデルにおけるエネルギー関数

$$\varepsilon(x) = -\frac{J}{k} \sum_{\langle s,t \rangle} x(s)x(t) - \frac{H}{k} \sum_{s \in S} x(s)$$

について、 $H = 0$ と仮定し、簡略化のため $\gamma = \frac{J}{kT}$ とすると

$$\pi(x) = \frac{1}{Z} e^{\gamma \sum_{\langle s,t \rangle} x(s)x(t)} \quad (1)$$

となる。ただし、 $\sum_{\langle s,t \rangle}$ は s に対する近傍の和のことである。

Multiplicative noise

ノイズの基本的なモデルとして、各サイトの値が独立に入れ替わる Multiplicative noise を取り上げる。

$Z = \{Z(s)\}_{s \in \Lambda}$ が i.i.d. かつ、 Z と X が独立で、

$$z(s) = \begin{cases} -1 & \text{確率 } p \\ 1 & \text{確率 } q = 1 - p \end{cases}$$

であるとき、 Y が

$$y(s) = x(s)z(s)$$

により、 Y が与えられるとする。この時、 Z を multiplicative noise という。

復元の方法

得られたデータ Y から

$$\pi(x|y) = P(X = x|Y = y) \quad (2)$$

を計算し、 $\pi(x|y)$ を最大にする x を元画像と推定する。この考え方が Maximum A Posteriori (MAP) likelihood method (事後確率による最尤法) である。ここで次のことがわかっている。

- X は Gibbs 分布に従う。

- 一般的に成り立つ公式として, Bayes の公式

$$P(X = x|Y = y) = \frac{P(Y = y|X = x)P(X = x)}{\sum_x P(Y = y|X = x)P(X = x)}$$

このことを用いることで, 具体的に計算していくと次の結果を得る.

定理 0.1. 画像モデルで表される画像は y : given で

$$P(X = x|Y = y) = \frac{e^{-H(x,y)}}{\sum_x e^{-H(x,y)}}$$

に従う. ここで

$$H(x, y) = \frac{1}{2} \log \frac{p}{q} \sum_{s \in \Lambda} x(s)y(s) - \gamma \sum_{\langle s, t \rangle} x(s)x(t)$$

である.

y が与えられた下で $\pi(x|y)$ を最大にする x を探したい. つまり, $H(x, y)$ を最小にする x を探す. 今回はこの最小の x を探す方法として次の Gibbs Sampling に対する Simulated Annealing を考えていく.

Barker's Algorithm

Barker's Algorithm とは, 一般の target distribution π を定常分布とする, マルコフ連鎖の遷移確率行列 $P = \{p_{ij}\}_{i,j \in E}$ をみつける一つの方法である.

Barker's Algorithm とは

$$p_{ij} = \begin{cases} q_{ij}\alpha_{ij} & (i \neq j) \\ 1 - \sum_{i \neq j} p_{ij} & (i = j) \end{cases}$$

$$\alpha_{ij} = \frac{\pi(i)}{\pi(j) + \pi(i)}$$

として, 遷移確率行列 P を作るアルゴリズムである.

Gibbs Sampling

次のここでの目標は

$$\pi_\beta(x) = \frac{1}{Z_\beta} e^{-\beta H(x,y)} \quad (3)$$

を定常分布とする S^Λ 上のマルコフ連鎖を生成することである .

S^Λ 上のマルコフ連鎖を $\{X_n\}$ として次のように遷移させる .

- 1ステップごとに1つのスピンを変化させる .
- $X_n = x$ から $X_{n+1} = z$ に変化するスピンを s とする .
- 変化する1点を一様な確率 $q_{xz} = \frac{1}{|\Lambda|}$ で選ぶ .
- 点 s の新しい値 $z(s)$ は確率 $P(z(s)|x(S \setminus s)) = q_{xz} \alpha_{xz}$ で変化する .

具体的に α_{xz} を計算すると

$$\alpha_{xz} = \begin{cases} \frac{1}{1 + e^{-\beta(-\log \frac{p}{q} y(s) + 2\gamma \sum_{\langle s,t \rangle} x(t))}} & z(s) = 1 \\ \frac{e^{-\beta(-\log \frac{p}{q} y(s) + 2\gamma \sum_{\langle s,t \rangle} x(t))}}{1 + e^{-\beta(-\log \frac{p}{q} y(s) + 2\gamma \sum_{\langle s,t \rangle} x(t))}} & z(s) = -1 \end{cases}$$

で表される . 最後に Simulated Annealing の方法を用いて $\beta \rightarrow \infty$ とすることで , $H(x,y)$ が最小になる点 x_0 を求めることである . Simulated Annealing について述べる .

Simulated Annealing を用いたシミュレーション

関数の最小値を求める方法として , Simulated Annealing の方法を用いる .

定常分布 $\pi_{\beta(n)}(x)$ について

$$\pi_{\beta(n)}(x) = \frac{1}{Z} e^{-\beta(n)U(x)}$$

について , $\beta(n) \rightarrow \infty$ とすると , $\pi_{\beta(n)}(x)$ は最小になる点 x_0 に収束する .

となることにより , 最小になる点 x_0 を求めることができる . $\beta(n) \rightarrow \infty$ とする早さとしては , $\beta(n) = k + \rho \log(1 + n)$ とするとよい .



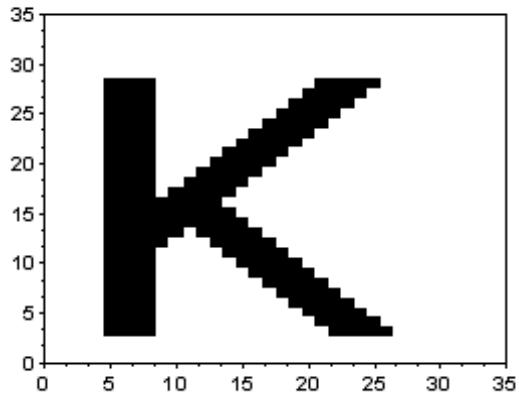


図 0.2: 画像の復元例 (イジングモデル)




図 0.3: 画像の復元例 (Pixel-Edge Model)