

MCMC チュートリアル

入門から多峰性分布の扱いとその応用まで




Q

「マルコフ連鎖モンテカルロ法」って統計物理とかで昔から使ってるモンテカルロ法とは違う新しい方法なんですか？

A

いいえ同じです。名前が変わっただけ。試行が独立なタイプの「モンテカルロ法」とは違います。



マルコフ連鎖モンテカルロ法とは
呼ばれないモンテカルロ法の例
(各試行が独立)

円の中に入った個数 ÷ 全体の個数

マルコフ連鎖モンテカルロ法 (MCMC)

1950年代前半に誕生

電子計算機の誕生 ⇒

多数の原子や分子の振る舞いの計算

「(動的) モンテカルロ法」

MCMCという名前は他の分野 (統計科学など)
で使われるようになってからのもの

MCMCの応用の展開

@ 1950s~

液体⇒磁性⇒素粒子（経路積分）

@ 1990s~（散発的に1980s）

ベイズ統計を中心とする

統計学・情報処理の諸分野 1990s~

@ Next ?

最後に「他の応用」の話をしてします

Q

MCMCにデータを突っ込むと解析してくれる？

A

だめです。「モデル」(ベイズ)を書く必要がある
MCMCは計算の道具にすぎない

便利なツールはできています
(モデルを入れるとMCMCを実行)

Stan JAGS WinBUGS ..

統計データ解析とMCMC

MCMCだけ勉強するのは水道の蛇口だけ
付けて配管をしないのと同じ



データ

$$Y_t \sim \text{Poisson}(\lambda_t Z)$$

$$\log \lambda_t = \beta_t$$

$$\beta_t = \beta_{t-1} + \epsilon_t$$

ノイズ



```

data {
  int T;
  int Y[T];
  int Z;}

parameters {
  real beta[T];
  real<lower=0>
s_mu;}

transformed parameters {
  real prob[T];
  for(t in 1:T)
    prob[t,1]<-exp(beta[t]); }

model {
  for(t in 3:T)
    beta[t] ~ normal(beta[t-1], s_mu);
  for(t in 1:T)
    Y[t]~poisson(Z*prob[t]); }

```

STANのコード
 (R,Pythonから呼び出す)

Q

要するに最適化の方法でしょう？

A

違います

MCMCの目的

高次元（多変量）の分布からのサンプリング法
（= 乱数の生成法）

@ 最適化手法ではない

（最適化に使うことはできる： simulated annealing）

@ 「高次元積分法」でもない（工夫すれば使えるが）

@ 「普通」のモンテカルロと最適化の中間の性質

今日の話


- MCMCの大雑把な話
(原理からレプリカ交換法まで)
- ベイズ
(ちょっとだけですからね！)
- レアイベントサンプリング

MCMCの要点

サンプリングしたい分布に対して
それを「定常分布」とするマルコフ連鎖
を構成

⇒ 擬似乱数を使ってシミュレート


マルコフ連鎖のエルゴード定理



マルコフ連鎖の定常分布(不変分布)


$P(x)$ 多数の状態(状態空間の代表点)の分布

$$\sum_x P(x) \pi(x \rightarrow x') = P(x')$$




マルコフ連鎖の収束定理(エルゴード性)

「与えられた分布を定常分布に持つ」



与えられた分布 → 与えられた分布 ○




任意の分布 → 正しい分布 ?


簡単な条件のもとで証明できる

条件

まず、複数の部分にわかれていたのではだめ




既約性



(+α)


離れた初期状態から

マルコフ連鎖の仮想時間



多数のサンプルを採る

マルコフ連鎖の仮想時間



記憶を失う




記憶を失う



記憶を失う

平均値の計算では飛ばす必要はない



分散などの不偏推定・・相関の補正が必要(高度)


マルコフ連鎖を設計する

与えられた分布を定常分布にする
マルコフ連鎖は無数に存在する

設計の原理のひとつ ⇒ 詳細釣り合い
(detailed balance)

詳細釣り合い (可逆性)


$$P(x)\pi(x \rightarrow x') = P(x')\pi(x' \rightarrow x)$$



各ペアについてつりあう

$$\sum_x P(x)\pi(x \rightarrow x') = P(x')$$

定常分布になる十分条件



詳細釣り合いを満たさない例

最近は「詳細釣り合いなしMCMC」もある

メトロポリス法

対称な提案分布 $Q(x, x') = Q(x', x)$

x の候補 x^{new} を

提案分布 $Q(x, x^{new})$ に従って生成

一様乱数 $0 \leq r < 1$ を発生

$r < \frac{P(x^{new})}{P(x)}$ なら x を x^{new} で置き換える
さもなければ何もしない

詳細釣り合いを満たすことの証明

2つの状態を α , γ とする

$P(\alpha) \leq P(\gamma)$ として一般性を失わない

$\alpha \rightarrow \gamma$

$$r < 1 \leq \frac{P(\gamma)}{P(\alpha)} \quad Q(\alpha, \gamma)$$

$\gamma \rightarrow \alpha$

$$r < \frac{P(\alpha)}{P(\gamma)} \leq 1 \quad Q(\gamma, \alpha) \frac{P(\alpha)}{P(\gamma)}$$

続き


$$P(\alpha)\pi(\alpha \rightarrow \gamma) = P(\gamma)\pi(\gamma \rightarrow \alpha)$$

$$P(\alpha) \times Q(\alpha, \gamma) = P(\gamma) \times Q(\gamma, \alpha) \frac{P(\alpha)}{P(\gamma)}$$


$$Q(\alpha, \gamma) = Q(\gamma, \alpha)$$

ステップ幅の影響


Metropolis sd= 0.2
b= 0.8



Metropolis sd= 6
b= 0.8



Metropolis sd= 0.8
b= 0.8



マルコフ連鎖の作り方

■ メトロポリス法

■ Gibbs Sampler (熱浴法)

➔ メトロポリス・ヘイスティングス法 (MH法)


(上の2つの両方を含む)

■ ハミルトニアンモンテカルロ法 (Stanに採用)


メトロポリス法の1stepをHamilton力学系で

■ emcee

MCMCが困難に陥る場合



確率密度の大きいところが複数に分かれる



レプリカ交換モンテカルロ法 (パラレル・テンパリング)

たくさんの系を並列にシミュレートする

$$\{P_k(x^k)\}, k = 1, 2, \dots, K$$

「たくさんの系」の作り方

それぞれ温度が少しずつ段階的に違うようにする

$$P_k(x^k) = \frac{\exp(-\beta_k E(x^k))}{Z(\beta_k)}$$

任意のパラメータ (β) についての族でもよい

$$P_k(x^k) = P(x^k | \beta_k)$$

交換操作


一定の規則で隣同士の状態を交換する

$$P_k(x^k) \quad P_{k+1}(x^{k+1})$$

$$x^{k(t+1)} \leftarrow x^{k+1(t)}$$

$$x^{k+1(t+1)} \leftarrow x^k(t)$$

交換の様子 (系4つの場合)



交換の規則

- 以下の比を計算

$$W = \frac{P_{k+1}(x^{k(t)}) P_k(x^{k+1(t)})}{P_{k+1}(x^{k+1(t)}) P_k(x^{k(t)})}$$

- 一様乱数 $0 \leq rnd < 1$ を発生
 $rnd < W$ なら交換する

同時分布についての詳細釣り合い


同時分布が交換操作を含めたマルコフ連鎖の不変分布になっている

$$P(x^1, x^2, \dots, x^K) = P_1(x^1)P_2(x^2) \dots P_K(x^K)$$

「交換」の部分がメトロポリス法の試行に相当

$$W = \frac{P_1(x^1) \dots P_k(x^k) P_{k+1}(x^{k+1}) \dots P_K(x^K)}{P_1(x^1) \dots P_{k+1}(x^{k+1}) P_k(x^k) \dots P_K(x^K)}$$

交換の効果で橋をかける



ベイズ統計 (ちょっとだけ)

岩波データサイエンス 全6巻 各1500円




- 1巻 **ベイズ推論**
- 2巻 **自然言語処理**
- 3巻 **因果推論**
- 4巻 **地理空間情報**
- 5巻 **スパース推定**
- 6巻 **時系列解析(6月刊)**



Wonderful *R* 2
StanとRで
ベイズ統計モデリング

石田基広 監修

松浦健太郎 著



共立出版

統計と機械学習

データ解析のための
統計モデリング入門

— 線形モデル・一般化線形モデル・階層ベイズモデル・MCMC —

久保拓修

共立出版

内部状態 x の発展

$$x(t+1) = f(x(t)) + \eta(t)$$

$$p(x) \quad x = (x(1), x(2), \dots)$$

観測してデータ y を得る

$$y(t) = g(x(t)) + \epsilon(t)$$

$$p(y|x) \quad y = (y(1), y(2), \dots)$$

$$p(x, y) = p(y|x)p(x)$$


条件つき確率

$$p(x, y) = p(y|x)p(x)$$

$$p(x|y) = \frac{p(x, y)}{p(y)} = \frac{p(y|x)p(x)}{\int p(y|x)p(x)dx}$$


ベイズの公式

データ




時間→

**ランダムウォーク
システム方程式**




**データに合う
ようなパスを選ぶ**




**これがあてはめの
結果と考える
(誤差・不確実性を含む)**


シミュレーションとデータ同化(一般化)



データに合うものを
条件つき確率の重みで抜き出す



統計的逆問題も同様の枠組みで





データ

$$Y_t \sim \text{Poisson}(\lambda_t Z)$$

$$\log \lambda_t = \beta_t$$

$$\beta_t = \beta_{t-1} + \epsilon_t$$

ノイズ



条件つき確率

$$p(x, y) = p(y|x)p(x)$$

$$p(x|y) = \frac{p(x, y)}{p(y)} = \frac{p(y|x)p(x)}{\int p(y|x)p(x)dx}$$

どうやって扱う？ → MCMC!



データ

$$Y_t \sim \text{Poisson}(\lambda_t Z)$$

$$\log \lambda_t = \beta_t$$

$$\beta_t = \beta_{t-1} + \epsilon_t$$

ノイズ



```

data {
  int T;
  int Y[T];
  int Z;}

parameters {
  real beta[T];
  real<lower=0>
s_mu;}

transformed parameters {
  real prob[T];
  for(t in 1:T)
    prob[t,1]<-exp(beta[t]); }

model {
  for(t in 3:T)
    beta[t] ~ normal(beta[t-1], s_mu);
  for(t in 1:T)
    Y[t]~poisson(Z*prob[t]); }

```

STANのコード
 (R,Pythonから呼び出す)

レアイベントサンプリング

Example 1

Kitajima & Kikuchi (2015)

魔方陣の数を数える

RESEARCH ARTICLE

Numerous but Rare: An Exploration of Magic Squares

Akimasa Kitajima^{1,2*}, Macoto Kikuchi^{3,2}

Citation: Kitajima A, Kikuchi M (2015) Numerous but Rare: An Exploration of Magic Squares. PLoS ONE 10(5): e0125062. doi:10.1371/journal.pone.0125062

Pinn K, Wiecekowski C (1998)

Parallel Tempering (Replica Exchange MCMC)

$N=30$ で 6.56×10^{2056} 個

ハードな制約条件による困難


魔方陣をたくさん作りたいたいが・・・

魔方陣から別の魔方陣を簡単に作る方法
は思い浮かばない

MCMCの言葉でいえば

「マルコフ基底」の選び方がわからない
(たぶん想像もつかないくらい複雑?)

制約条件をゆるめる





$$U(\{x_i\}) = \underbrace{\sum_i |rsum_i - C|}_{\text{row sums}} + \underbrace{\sum_j |csum_j - C|}_{\text{column sums}} + \underbrace{\sum_{k=1,2} |dsum_k - C|}_{\text{diagonal sums}}$$

$rsum_i$ = 行*i*の数字の和, $csum_j$ = 列*j*の数字の和,
 $dsum_k$ = 対角線の数字の和 (対角線2本)

配置*x*が魔方陣になっている $\Leftrightarrow U(x)=0$

配置xが魔方陣になっている $\Leftrightarrow U(x)=0$

$$U(\{x_i\}) = \sum_i |rsum_i - C| + \sum_j |csum_j - C| + \sum_{k=1,2} |dsum_k - C|$$




Complete Magic Square

MCMCを導入


適当な1変数関数 $f(u) \geq 0$ を定めて
重み $f(u)$ でメトロポリス法のMCMCを走らす
(制約をゆるめてあるのでmoveは適当でよい)

一見, $U=0$ のところに U の値が集中
するような重み $f(u)$ を考えれば
ベストな気がする



しかしこれでは, うまくいかない
いろいろな魔方陣の間をつなぐことができない
(制約をゆるめないのと同じになってしまう)

重みの選び方が難しい




ではもっと広がった $f(u)$ を考えれば
よいかというと、あっという間に分布が
広がってしまい、正しい魔方陣($U=0$)
が出る数がゼロになってしまう
(次元の呪い; 「軒を貸して母屋を取られる」)

マルチカノニカル法の $f(u)$ の選び方

マルチカノニカル法では
Uの値が大體一様に
分布するように $f(u)$ を選ぶ
(5割やそこらの誤差は許容)

■「xがランダム」とは全く違う
(大数の法則！)

■「コイン100回振って
表100回と裏表半々が
等確率」みたいな感じにしたい





マルチカノニカル法の $f(u)$ の選び方 (続き)

- この選び方ができたとして, なぜうまくいくか
- どうやって $f(u)$ を見つけるか



マルチカノニカル法の $f(u)$ の選び方 (続き)

- この選び方ができたとして, なぜうまくいくか
- どうやって $f(u)$ を見つけるか

Uの値が広い範囲を動く利点(1)




直接繋がってなくても正しい比率



水槽と同じ理屈

Uの値が広い範囲を動く利点(2)

個数の見積もりがすぐにできる



$$\frac{f(0)}{f(\text{ランダム})} \times \text{総数}$$

× 完全に平らなとき

$$\frac{\text{実際の計算で}U=0\text{となった数}}{\text{完全に平らなとき}U=0\text{となる数}}$$


完全に平らでない分の補正

マルチカノニカル法の $f(u)$ の選び方 (続き)

- この選び方ができたとして, なぜうまくいくか
- どうやって $f(u)$ を見つけるか

最も簡単な学習法 (Entropic Sampling)

[シミュレーション→ヒストグラム] を繰り返す
沢山出たら重みを下げる




Histogram $H_k(U)$

$$M_k = \frac{\sum_{\xi} H_k(U)}{\text{(number of bins)}}$$


$$f_{k+1}(U) = f_k(U) \div \frac{H_k(U) + \epsilon}{M_k}$$

ϵ a constant, say 1.0


1




2




3




4




5




6











7



8



An Example of Bad Convergence



- (1) Request of a broad “flat” region
 - (2) Insufficient Sampling in each iteration
- instability

Wang-Landau algorithm

1. Initialize Weights $w(E)$ Set $C \leftarrow 1/e$
2. Set/Reset Histogram $H(E) \leftarrow 0$
3. Metropolis-Hastings update with the weight $w(E(x))$
4. If the current state is x and $E = E(x)$

discount: $w(E) \leftarrow w(E) * C$

increment: $H(E) \leftarrow H(E) + 1$
5. If $H(E)$ becomes “sufficiently flat”
 $C \leftarrow \sqrt{C}$ and Goto 2 else Goto 3.
6. If C become sufficiently small then quit.

Example 2 $\xi = \text{"chaoticity"}$

Chaotic Dynamical Systems

**Search for rare initial conditions
that gives rare trajectories**

e.g., Coupled Standard Map

$$u_{n+1} = u_n - \frac{K}{2\pi} \sin(2\pi v_n) + \frac{k}{2\pi} \sin(2\pi(v_n + y_n))$$

$$v_{n+1} = v_n + u_{n+1}$$

$$x_{n+1} = x_n - \frac{K}{2\pi} \sin(2\pi y_n) + \frac{k}{2\pi} \sin(2\pi(v_n + y_n))$$

$$y_{n+1} = y_n + x_{n+1}$$

**Probability of regular trajectory (fragments)
embedded in chaotic sea**

Our method

■ Initial Condition Sampling (deterministic systems)

initial condition x_0


Define “Mixing Time” $T_\epsilon(x_0)$

Calculate the distribution $P(T_\epsilon)$

■ Muticanonical (or Parallel Tempering)

→ efficient sampling with correct prob.

Multicanonical Sampling



Results(Figures)

See **arXiv:1003.2013**

**Multicanonical Sampling of Rare Trajectories in
Chaotic Dynamical Systems**

Akimasa Kitajima, Yukito Iba

Computer Physics Communications

Volume 182, Issue 1, Pages 1-280 (January 2011)