

第11章 サンプルング法

B4 近松京介

原さん(東北大助教授)

ドクターのときの原さんのパワーポイント改良ましまし版

- 基本的なサンプリングアルゴリズム
 - 棄却サンプリング・適応的棄却サンプリング
 - 重点サンプリング
 - SIR
 - サンプリングとEMアルゴリズム
 - データ拡大アルゴリズム
- マルコフ連鎖モンテカルロ
 - Metropolis-Hastingsアルゴリズム
- ギブスサンプリング
- スライスサンプリング
- ハイブリッドモンテカルロアルゴリズム

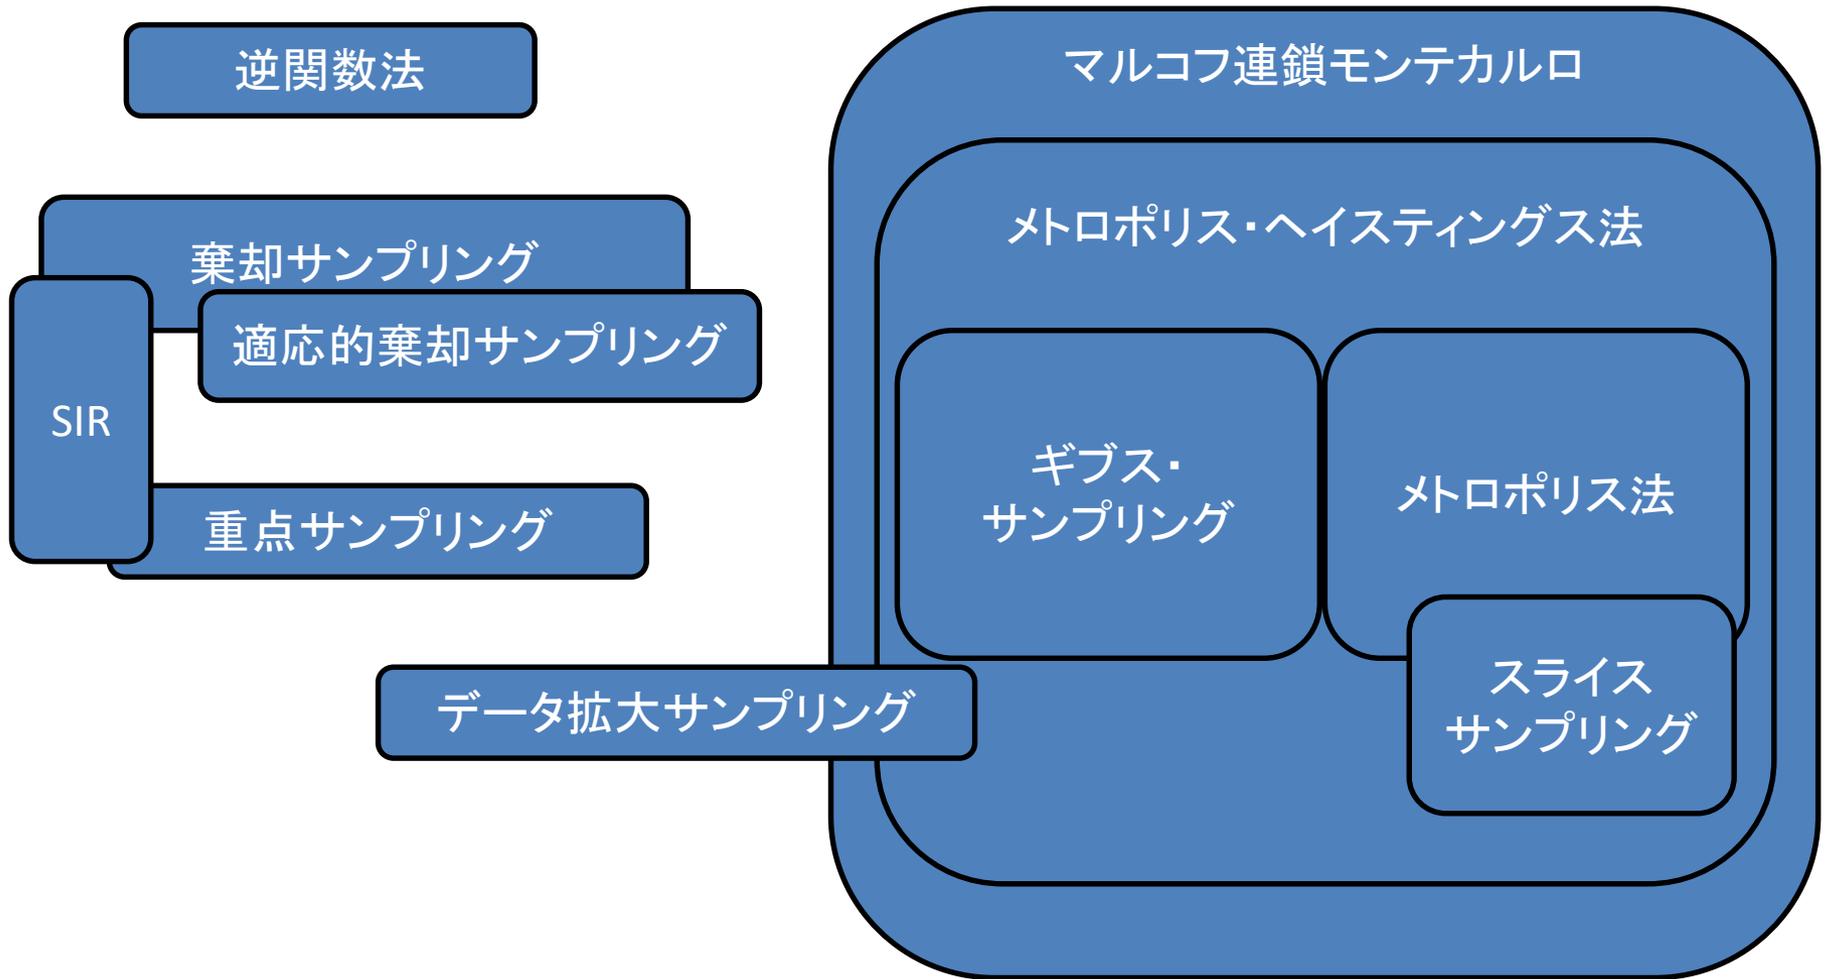
- MCMCを使わないサンプリング
 - 逆関数法
 - 棄却サンプリング
 - 適応的棄却サンプリング
 - 重点サンプリング
 - SIR
- MCMCサンプリング
 - メトロポリス法
 - ギブスサンプラー

- そもそもサンプリングとはなにか理解する
- サンプリング手法を概観・整理

- **メトロポリス法**

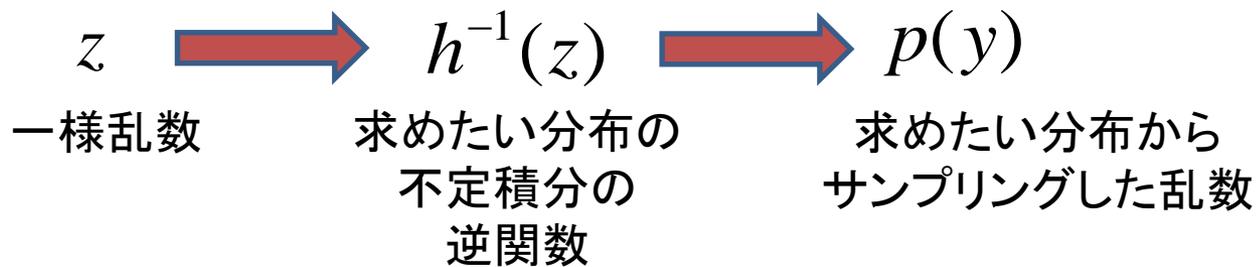
- **ギブスサンプラー**

**実装できそうと思うくらい
理解する**



- 目的は「ある想定した分布」に従う乱数を発生させること(サンプリングすること)
- すなわち分布を再現すること
- たとえばある出発地に1000人いて、目的地として選ばれやすい座標が確率分布として与えられたときにその1000人がどこに行くか
- 正規分布や一様分布ならできるかも？
- より複雑な分布は...？

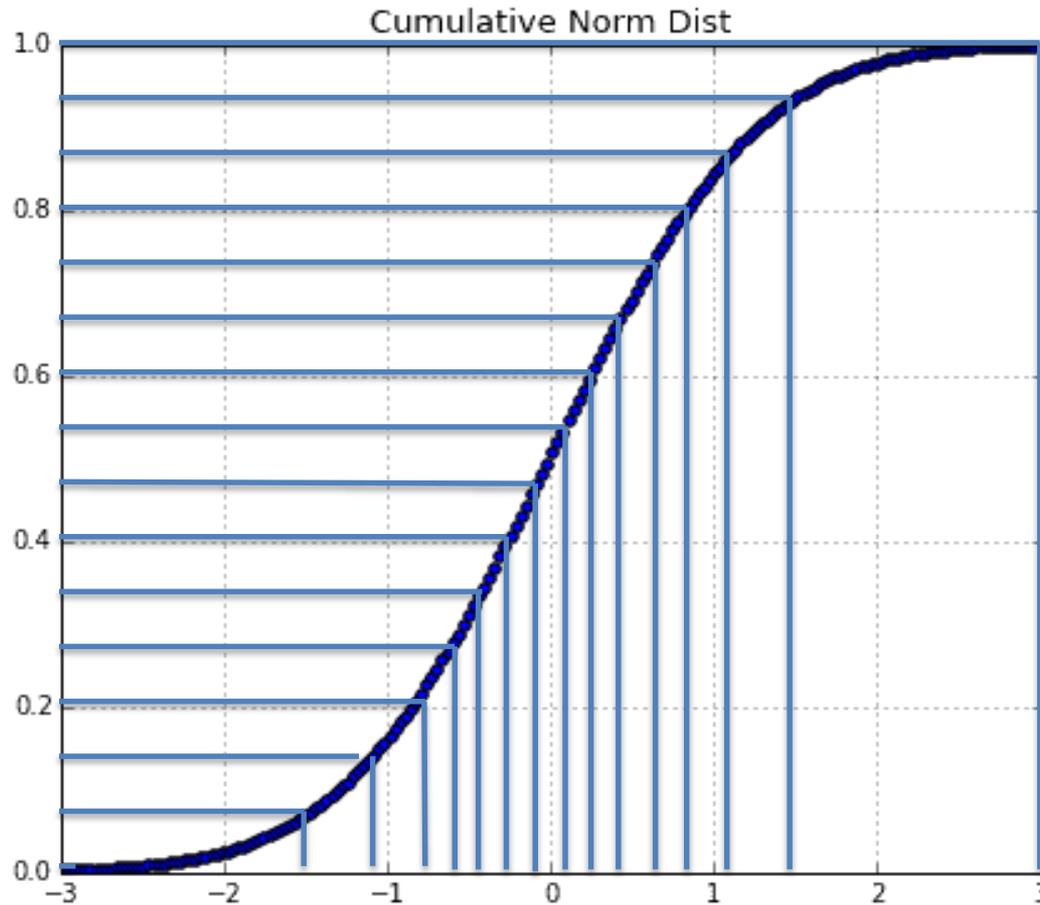
- まずは単純な**逆関数法**から
- 一様分布からサンプリングする(乱数を発生させる)ことができることが前提



こうなるらしいが、イメージがわかりません

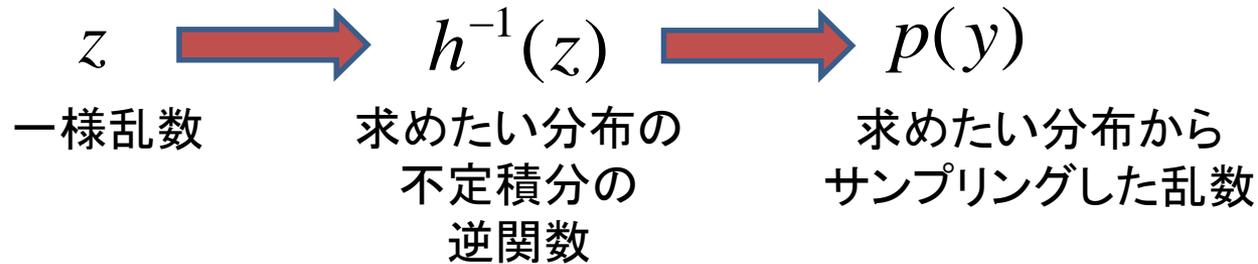
正規分布の累積関数

イメージわきましたか？



一様サンプリング

なんか正規分布っぽい

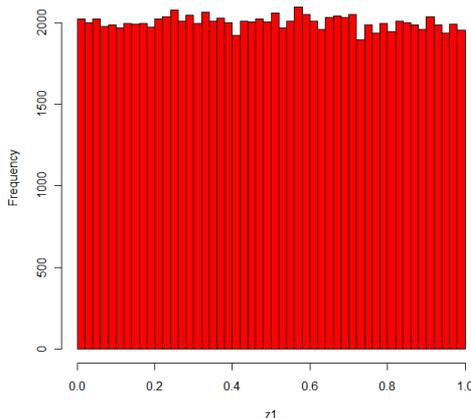


- たとえば指数分布からサンプリングしたいが直接できないとき

$$p(y) = \lambda \exp(-\lambda y) \quad z = h(y) \equiv \int_{-\infty}^y p(\hat{y}) d\hat{y} \quad z = h(y) = 1 - \exp(-\lambda y)$$

よって、次の逆関数を得られる $h^{-1}(z) = -\lambda^{-1} \ln(1 - z)$

乱数発生

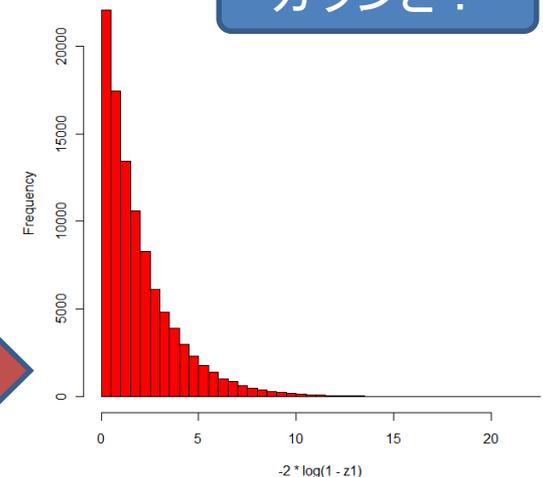


[0,1]の一様乱数 z を
100000個発生

$$y = h^{-1}(z) = -2 \ln(1 - z)$$

にぶち込む

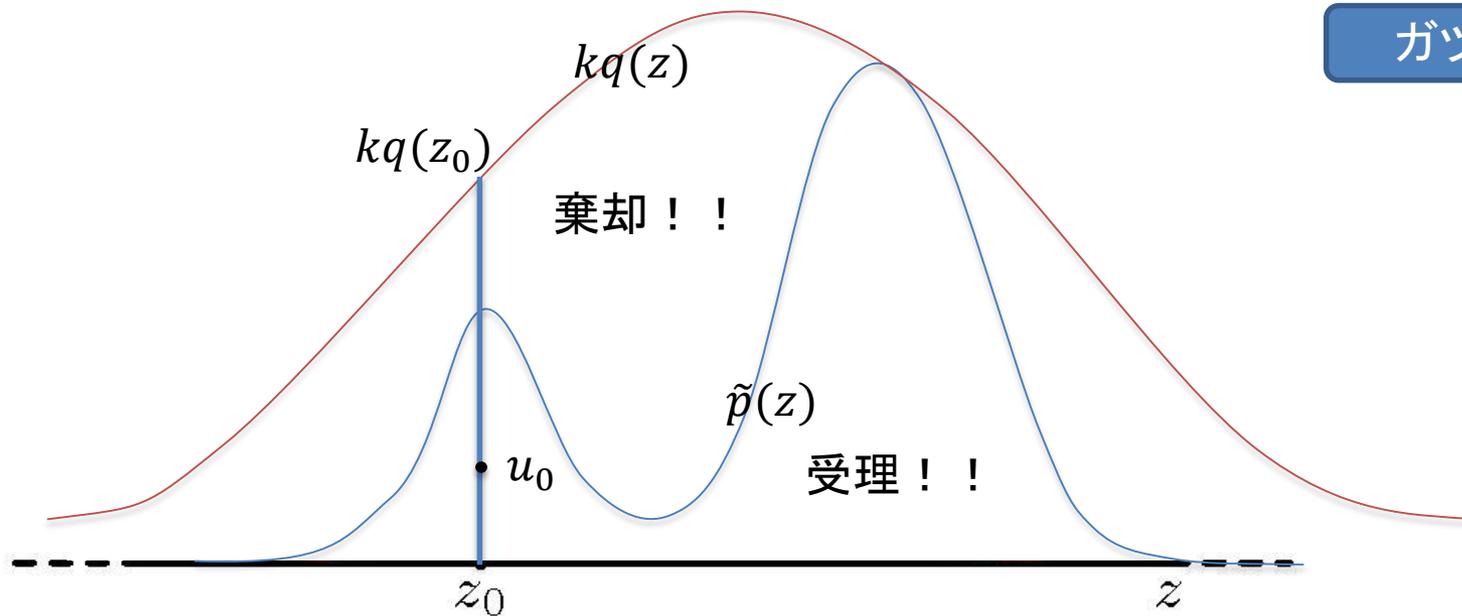
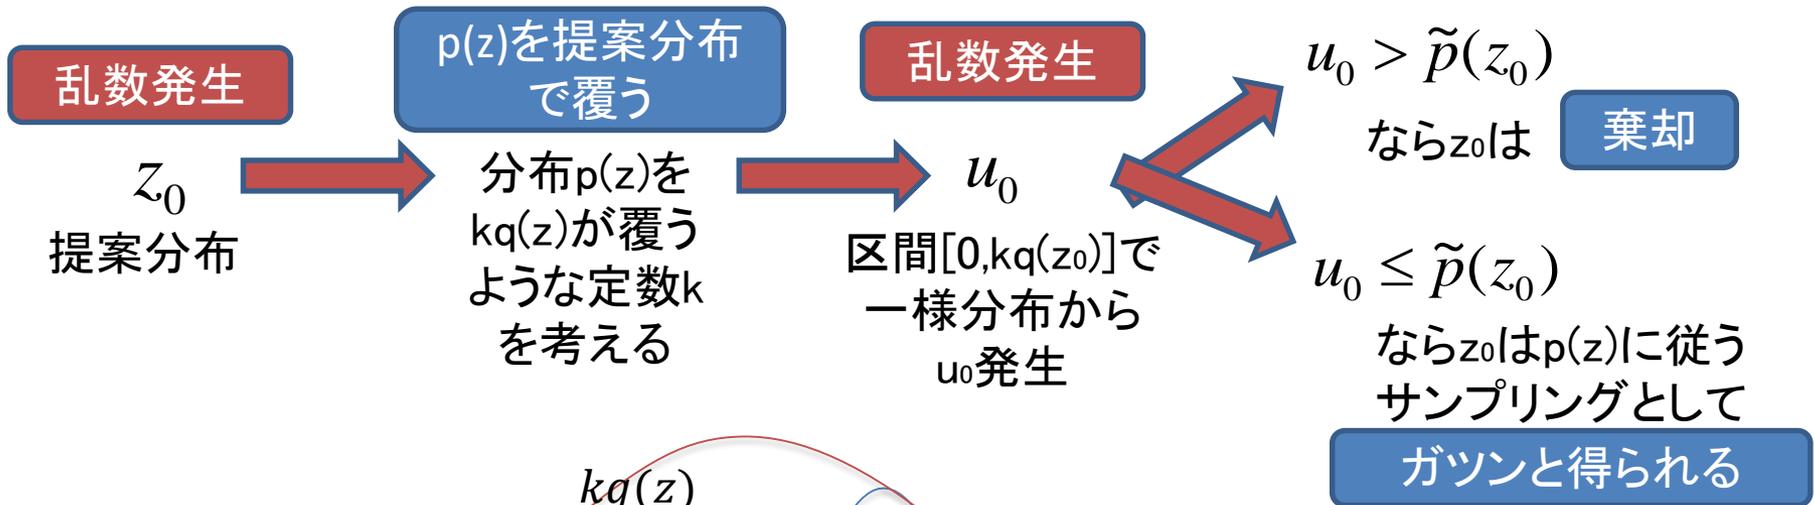
ガツンと!



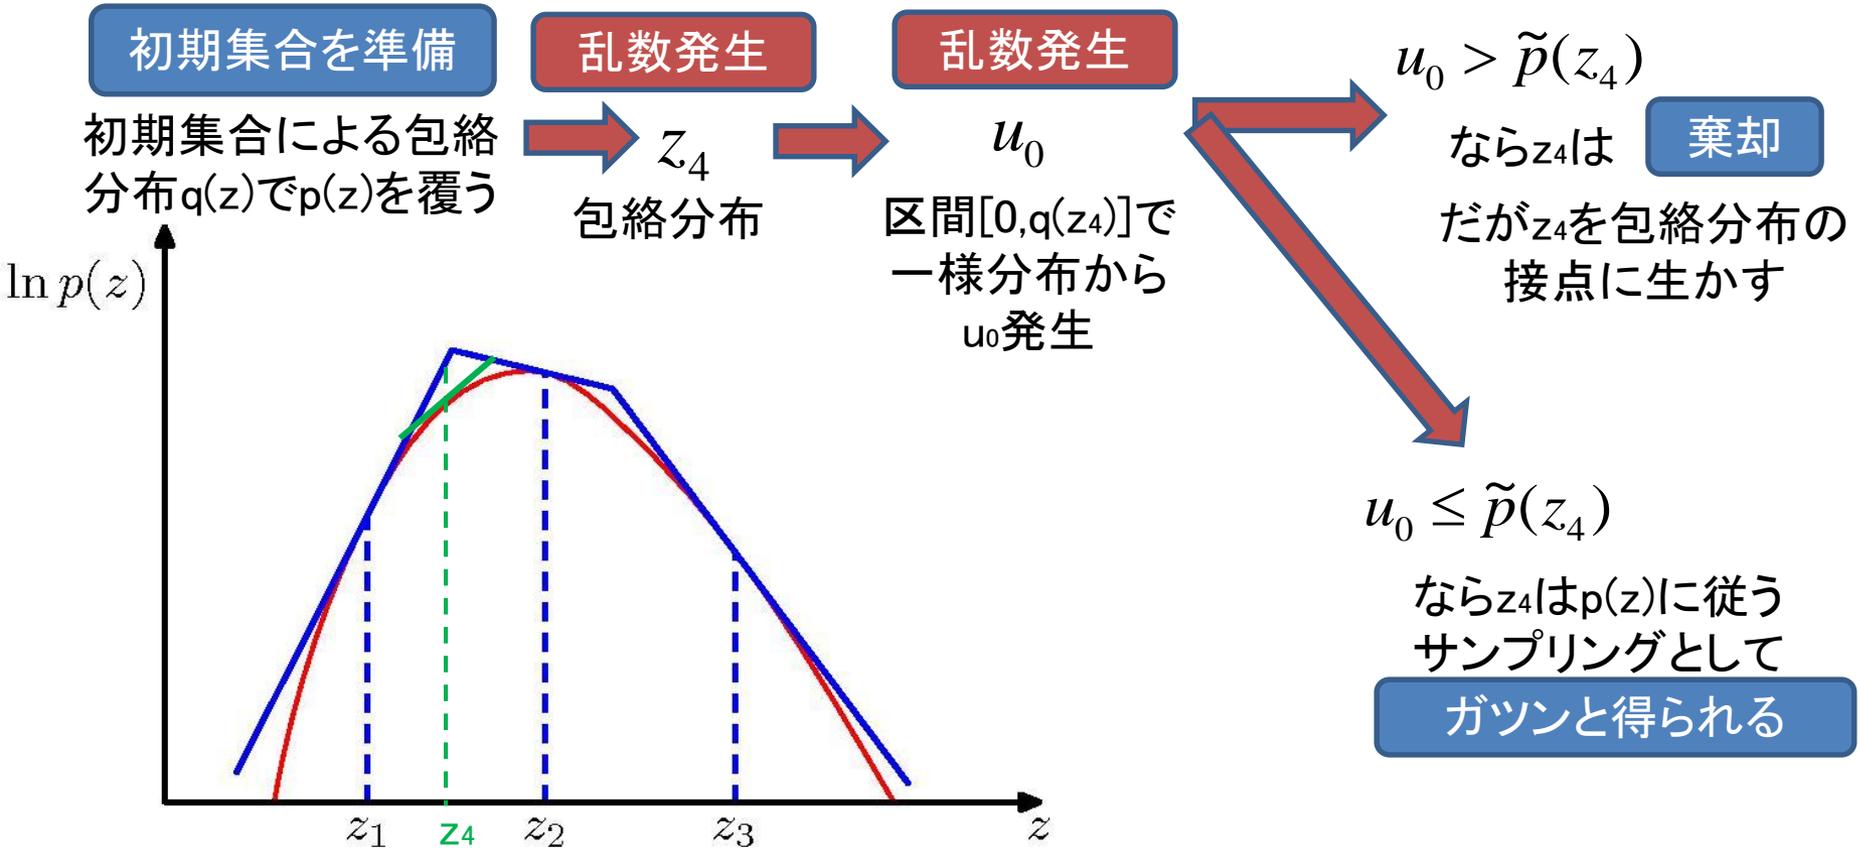
- 逆関数が求められない**比較的複雑な分布**だってある
- やや複雑な分布 $p(z)$ からサンプリングしたいが、**直接** $p(z)$ から**サンプリングするのは困難**であるとする
- 任意の z が与えられたとき、**正規化定数** Z を除いた $p(z)$ を求めることは**容易**であるとしよう(これはよくあること)

$$p(z) = \frac{1}{Z_p} \tilde{p}(z) \quad \tilde{p}(z) \text{はわかるが } Z_p \text{ わからん}$$

- ここで、容易にサンプリングできる**提案分布** $q(z)$ を考える
- これがミソ



- 棄却サンプリングを適用したい多くの場合, 適切な提案分布 $q(z)$ を解析的に決定することは難しい
- 別のアプローチとして, 分布 $p(z)$ の観測値に基づいてその場で **包絡関数** を構築する方法



- 逆関数法
 - 解析的に正しいし, 無駄がないというメリット
 - 複雑な分布だと逆関数を求めるのはまず不可能というデメリット
- 棄却サンプリング
 - 比較的複雑な分布に対してもサンプリングできるメリット
 - 適切な提案分布, 定数 k を選ぶことが難しい
 - 結果としてせっかくサンプリングしても大量に棄却するので無駄
- 適応的棄却サンプリング
 - 包絡関数を提案分布とすることで棄却が少なくなるメリット
 - 棄却した値も新たな包絡線の接点として取り込む再活用
 - 接線の計算負荷. また多次元で多峰性, するどいピークをもつ分布だとまず対応できないデメリット

棄却サンプリングは次元の多い分布だと棄却率が指数的に増加し非現実的

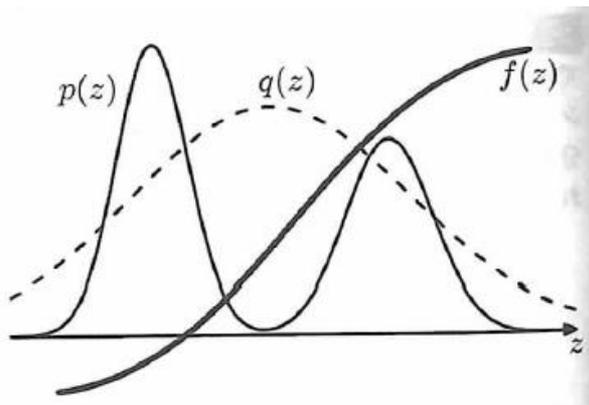
- 分布 $p(z)$ の**期待値を計算したいことが目的**のときもある(重点サンプリングはむしろそれしかできません)
- 一様にサンプリングして期待値もとめるのは非効率的なので提案分布を使います！

$$E[f] = \int f(z)p(z)dz = \int f(z) \frac{p(z)}{q(z)} q(z) dz$$

平均を取っているようなもの

$$\approx \frac{1}{L} \sum_{l=1}^L \frac{p(z^{(l)})}{q(z^{(l)})} f(z^{(l)})$$

重要度重みと呼び、求めたいものとは異なった分布からサンプリングするバイアスを補正する。棄却サンプリングと異なり、すべてのサンプルを保持することに注意！

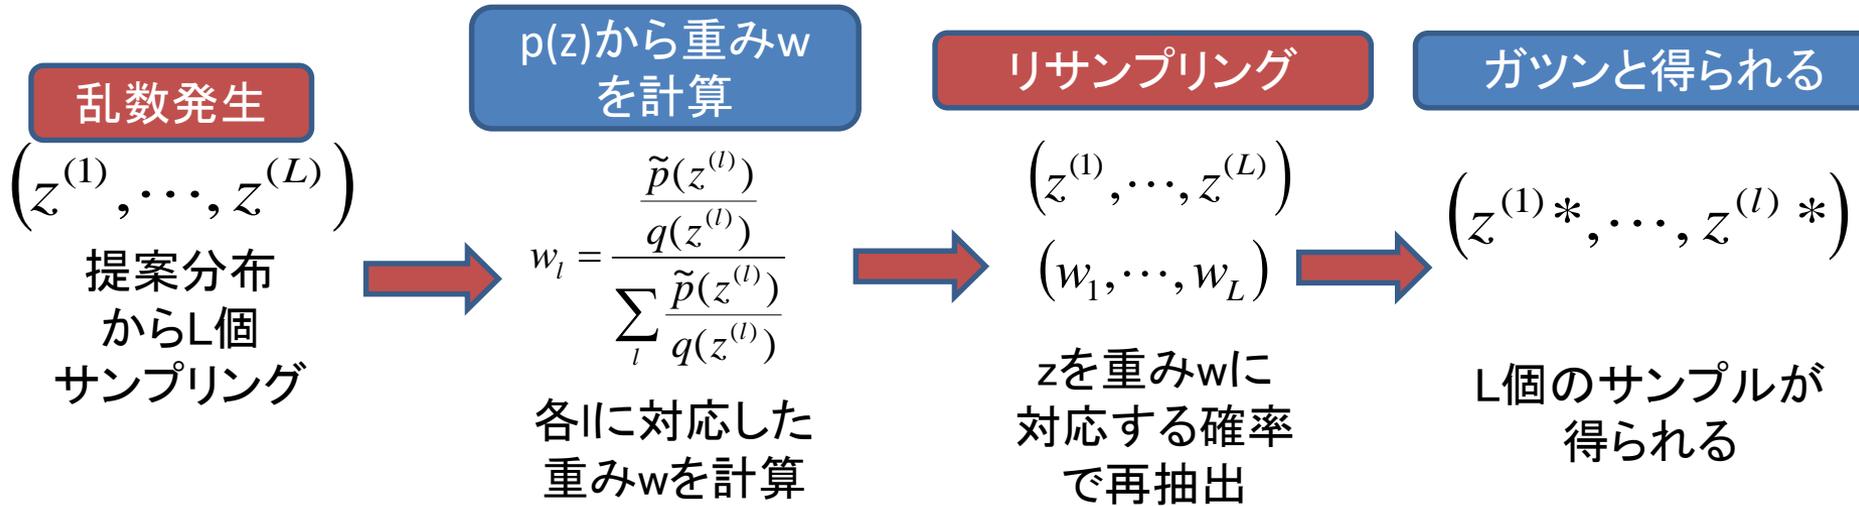


提案分布は $p(z) \cdot f(z)$ が大きくなる場所で分布が大きくなるようなものにとると効率的！！

- 棄却サンプリングのうまい $q(z)$ と k の選び方を発見することは現実的ではない
- そこで、重点サンプリングの重要度重みを有効活用して なんかうまいサンプリング方法はないか？ →SIR
- \tilde{p} と \tilde{q} は容易に計算できるという過程
- 第1段階で提案分布 $q(z)$ から L 個のサンプル z を抽出する
- 第2段階で次式によって重み w を計算する

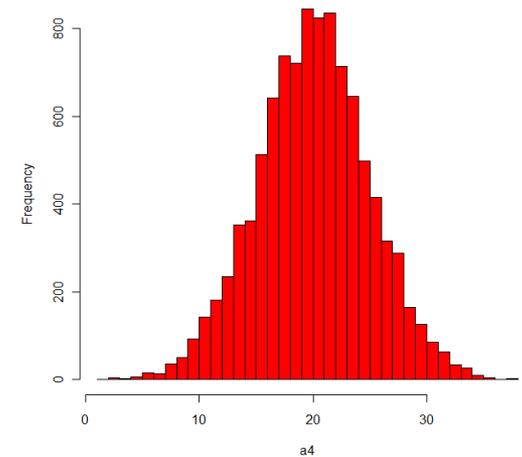
$$w_l = \frac{\tilde{p}(z^{(l)})}{q(z^{(l)})} \quad \text{重要度重み}$$
$$\sum_l \frac{\tilde{p}(z^{(l)})}{q(z^{(l)})}$$

- 最後に z から重い w で与えられる確率に従ってリサンプリングする(このサンプルは $p(z)$ に従う！！)
- これは $L \rightarrow \infty$ では分布は正確に従うことが証明されている



ex) 提案分布:[0,50]の一樣分布で $p(z)$ が $N(20,5)$ とする

17.08	$p(z) =$	$w =$	$z^* =$
2.745	6.730e-02	1.654e-01	17.08
38.93	2.069e-04	5.087e-04	21.15
38.40	6.136e-05	1.508e-04	17.08
$z = 21.34$	9.096e-05	2.235e-04	21.34
41.04	7.694e-02	1.891e-01	21.34
20.52	1.133e-05	2.785e-05	21.15
22.17	7.935e-02	1.950e-01	20.52
21.15	7.259e-02	1.784e-01	22.17
13.30	7.770e-02	1.910e-01	21.15
	3.254e-02	7.999e-02	17.08



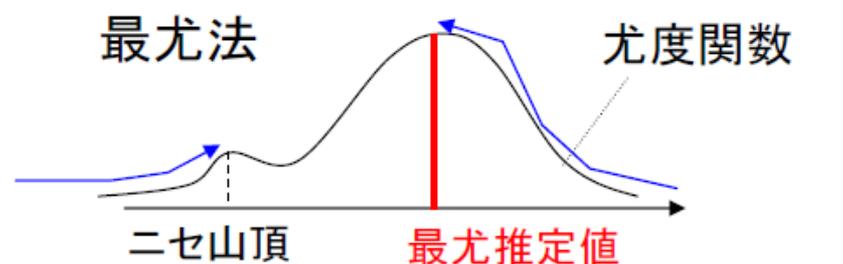
- 重点サンプリング
 - 提案分布との重み付けで期待値を近似的に計算する
 - 分布全体からサンプリングするものではない
- SIR
 - 棄却サンプリングと重点サンプリングの合わせ技
 - あくまで最初のサンプリングからのリサンプリングなので、反復回数が少ないと偏る...が、 ∞ では近似できることは証明されてる

サンプリングしたい確率分布の次元が高いとサンプリングしなければならない数が膨大に...

そんなあなたには！！！！！！

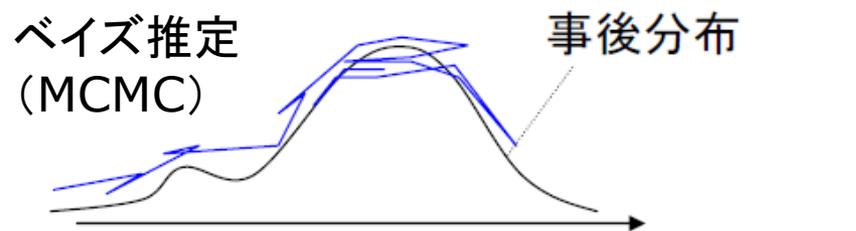
MCMCならびったり！！

• たとえばパラメータ推定の話



ひたすら山頂を目指す
⇒初期値によっては間違った結果

パラメータはひとつの値をとる

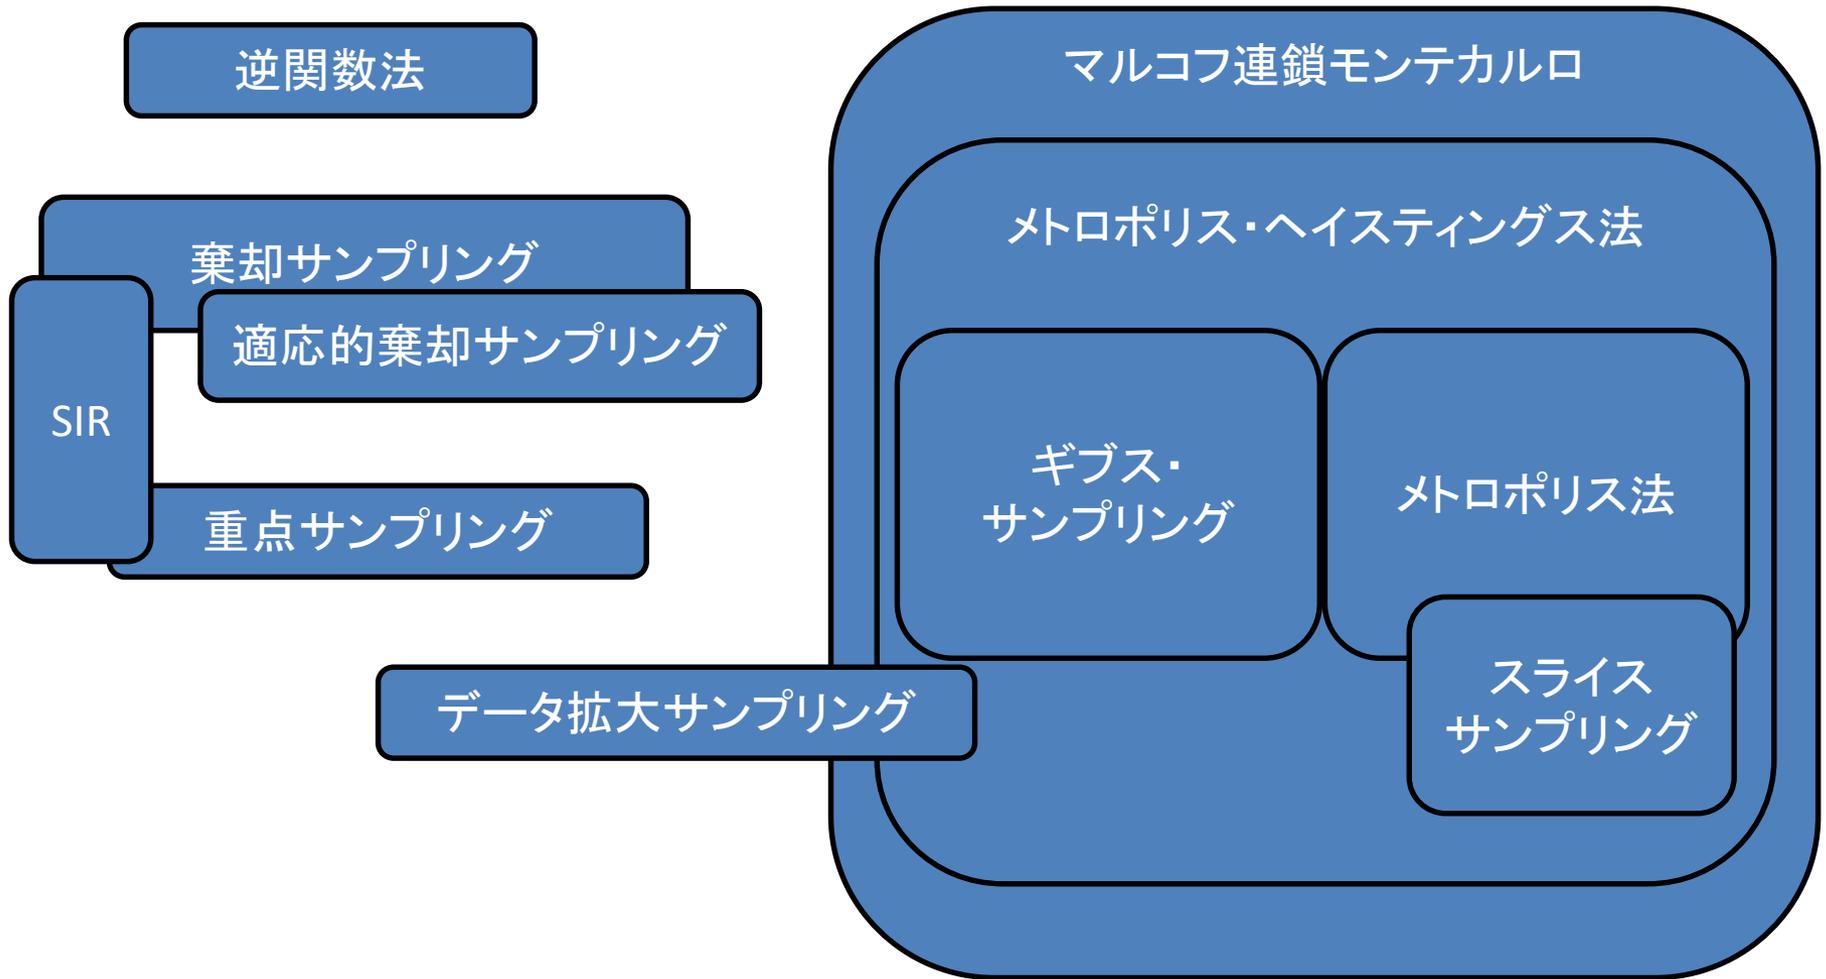


事後分布の形そのものを推定
⇒大域的最適解にたどり着きやすい

パラメータは確率分布をとる

- 最尤法では山頂にのみ関心があるが
- MCMCは山全体の形に興味がある

- 棄却サンプリングやSIR法では効率良いサンプリングのために**サンプラー(提案分布)を上手に選んでやる必要がある**
- 非常に複雑な分布(**非線形モデル**)や大量のパラメータがある(**次元が多い**)とき、適切にサンプラーを選ぶのは難しい。**ときに不可能**
- MCMCなら**定常分布に収束する**という性質を持っており、**初期値に依存せず**、いい感じのサンプリングが**楽**に行える
- モテ系というよりマッチョ系



- 任意の分布 $p(z)$ を不変分布にもつマルコフ連鎖を生成することで、望む分布に従った乱数を生成するモンテカルロ法のこと！！
- 不変分布とは？

- 次の例を考えてみる



$$\begin{pmatrix} F_{t+1} \\ R_{t+1} \end{pmatrix} = \begin{pmatrix} \frac{1}{2} & \frac{2}{3} \\ \frac{1}{2} & \frac{1}{3} \end{pmatrix} \begin{pmatrix} F_t \\ R_t \end{pmatrix} \quad \begin{pmatrix} F_0 \\ R_0 \end{pmatrix} = \begin{pmatrix} 1 \\ 0 \end{pmatrix}$$

この漸化式を解いてやると...

つまり...

$$\begin{pmatrix} F_t \\ R_t \end{pmatrix} = \begin{pmatrix} \frac{3}{7} \left(-\frac{1}{6}\right)^t + \frac{4}{7} \\ -\frac{3}{7} \left(-\frac{1}{6}\right)^t + \frac{3}{7} \end{pmatrix} \quad \begin{pmatrix} F_\infty \\ R_\infty \end{pmatrix} = \begin{pmatrix} \frac{4}{7} \\ \frac{3}{7} \end{pmatrix}$$

これが
不変分布

- マルコフ連鎖では最終的にある一定の確率分布へと収束し、これが**不変分布**である
- 初期値には依存しない
- **この性質はかなり大事**

- 任意の分布 $p(z)$ を不変分布にもつ**マルコフ連鎖を生成**することで、望む分布に従った**乱数を生成**するモンテカルロ法のこと！！
- マルコフ連鎖の生成による乱数生成は遷移確率が与えられているならばただのすごろく！

```
#晴⇒晴:1/2,雨⇒雨:1/3な推移確率
transition <- c(Fine=1/2,Rain=1/3)
size <- 10000 #サンプリング回数
result <- c() #結果格納
weather.now <- "晴" #現在のお天気
```

#マルコフ連鎖の生成 & 不変分布からのサンプリング.

```
for(i in 1:size){
  result <- c(result,weather.now)
  #現在の状態に応じて次の状態を決める⇒マルコフ連鎖の生成
  if(weather.now=="晴"){
    weather.now <- ifelse(runif(1) > transition["Fine"],"晴","雨")
  }else if(weather.now=="雨"){
    weather.now <- ifelse(runif(1) > transition["Rain"],"晴","雨")
  }
}
```

```
#結果表示、標本から確率を計算
#初めの10個は不変分布に達してないと思って捨てる
print(sum(result[-(10:1)]=="晴")/(size-10))
print(sum(result[-(10:1)]=="雨")/(size-10))
```

```
> print(sum(result[-(10:1)]=="晴")/(size-10))
[1] 0.5705706
> print(sum(result[-(10:1)]=="雨")/(size-10))
[1] 0.4294294
```

- 推移確率が与えられていたら簡単
- 例とは違って不変分布が与えられていて推移確率が与えられていない場合は??
- 不変分布に到達するような推移確率を与え、マルコフ連鎖を生成することで、不変分布を再現(近似)することが可能
- 推移確率を与える手段は??
 - メトロポリス法, ギブスサンプリング!

- **詳細釣り合いの条件**を満たすように推移確率を決めれば、望む不変分布を得る！
- 詳細釣り合いの条件
 - お天気の例で行くと

$$\frac{4}{7} \times \Pi_{Fine \rightarrow Rain} = \frac{3}{7} \times \Pi_{Rain \rightarrow Fine}$$

不変分布
晴の確率

晴⇒雨の
推移確率

不変分布
雨の確率

雨⇒晴の
推移確率

- 先ほどの式を満たす推移確率ならば不変分布を得ることが本当にできるのか
- 推移確率 * 不変分布 = 不変分布になるはず

$$\begin{pmatrix} 1 - \Pi_{Fine \rightarrow Rain} & \Pi_{Rain \rightarrow Fine} \\ \Pi_{Fine \rightarrow Rain} & 1 - \Pi_{Rain \rightarrow Fine} \end{pmatrix} \begin{pmatrix} \frac{4}{7} \\ \frac{3}{7} \end{pmatrix} =$$
$$\begin{pmatrix} \frac{4}{7} - \frac{4}{7}\Pi_{Fine \rightarrow Rain} + \frac{3}{7}\Pi_{Rain \rightarrow Fine} \\ \frac{4}{7}\Pi_{Fine \rightarrow Rain} + \frac{3}{7} - \frac{3}{7}\Pi_{Rain \rightarrow Fine} \end{pmatrix} = \begin{pmatrix} \frac{4}{7} \\ \frac{3}{7} \end{pmatrix}$$

↑詳細釣り合いの条件で消える

詳細釣り合いの条件は

$$Pr\{x\} \times \Pi_{x \rightarrow x'} = Pr\{x'\} \times \Pi_{x' \rightarrow x}$$

証明: 不変確率 = 推移確率 * 不変分布

$$Pr\{x\} = \sum_{x'} \Pi_{x' \rightarrow x} \times Pr\{x'\}$$

↑ お天気推移モデルの一般化式 ↑ 詳細釣り合いの条件

$$= \sum_{x'} \Pi_{x \rightarrow x'} \times Pr\{x\}$$

↓ 推移確率の和は1

$$= Pr\{x\} \sum_{x'} \Pi_{x \rightarrow x'} = Pr\{x\}$$

Q.E.D

- 推移確率を以下の式で与える

$$\Pi_{x \rightarrow x'} = \min\left(1, \frac{Pr\{x'\}}{Pr\{x\}}\right)$$

- このとき詳細釣り合いの条件式が満たされる
- 不変分布の比をとるので不変分布は規格化の必要がない！！
- 比は状態 x と状態 x' 間で取るので、推移先 x' を決めてあげなければならない
- 比が1より大きければ必ず推移し、比が1より小さければその確率で推移する
- つまり推移しないときも当然ある なんとなく分布になりそうなイメージ！

- step0:初期位置を設定
- step1:推移候補先を選定
- step2:メトロポリス法で決まる推移確率で推移
- step3:気が済んだ→end 済まない→step1

※推移候補先の選定に使う確率分布は詳細釣り合いの条件を満たすように！！(一様分布が一般的)

二次元正規分布のサンプリング

http://visualize-mcmc.appspot.com/2_metropolis.html

- メトロポリス法は推移位置を自分で設定して与える必要がある
- ギブスサンプリングはそんなことないです
- 推移確率は以下の通り

$$x = (x_0, x_1)$$

x_0, x_1 がそれぞれの次元での状態(位置)を表す

$$x' = (x_0, x'_1)$$

分母は規格化定数!

$$\begin{aligned} \Pi_{x \rightarrow x'} &= \frac{\Pr\{x'\}}{\sum_{x'_1} \Pr\{x'\}} = \frac{\Pr\{x'\}}{\Pr\{x_0\}} \\ &= \Pr\{x'_1 | x_0\} \end{aligned}$$

$\Pr\{x\}$ は確率(密度)

周辺化してる

- 詳細釣り合いの条件を満たすことの証明

$$\begin{aligned}Pr\{x\}\Pi_{x \rightarrow x'} &= Pr\{x\} \frac{Pr\{x'\}}{Pr\{x_0\}} \\ &= Pr\{x'\} \frac{Pr\{x\}}{Pr\{x_0\}} = Pr\{x'\}\Pi_{x' \rightarrow x}\end{aligned}$$

- 条件付分布が求まらなければ使えない

- たとえば二変量正規分布の場合
(本当はもっと高次元がMCMCの腕の見せ所であるが...)

$$p(x_1, x_2) = \frac{1}{Z} \exp\left(-\frac{x_1^2 - 2bx_1x_2 + x_2^2}{2}\right)$$

ここで、一方を固定したときの条件付き密度は

$$p(x_1 | x_2) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{(x_1 - bx_2)^2}{2}\right) \quad p(x_2 | x_1) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{(x_2 - bx_1)^2}{2}\right)$$

単なる正規分布からのサンプリングになったぞー！ → 余裕

- 条件付き分布からのサンプリングが簡単な場合, **魅力的**
- 条件付き分布が適切に書き下せる場合がギブスサンプラーの使いどころ
- 条件付き分布からのサンプリングが簡単でない場合 → MH

1. $\{z_i : i=1, \dots, M\}$ の初期値 $\{z_1^{(1)}, z_2^{(1)}, \dots, z_M^{(1)}\}$ を与える
2. $\tau = 1, \dots, T$ に対して以下を行う
 - $z_1^{(\tau+1)} \sim p(z_1 | z_2^{(\tau)}, \dots, z_M^{(\tau)})$ をサンプリングする
 - $z_2^{(\tau+1)} \sim p(z_2 | z_1^{(\tau+1)}, \dots, z_M^{(\tau)})$ をサンプリングする
 - $z_j^{(\tau+1)} \sim p(z_j | z_1^{(\tau+1)}, \dots, z_M^{(\tau)})$ をサンプリングする
 - ...
 - $z_M^{(\tau+1)} \sim p(z_M | z_1^{(\tau+1)}, \dots, z_{M-1}^{(\tau+1)})$ をサンプリングする
3. 収束したと判定されるまでステップ2を繰り返す

一つ前の期の自分以外に依存しているのでマルコフ連鎖の一種である

ギブス・サンプリング

- たとえば二変量正規分布の場合

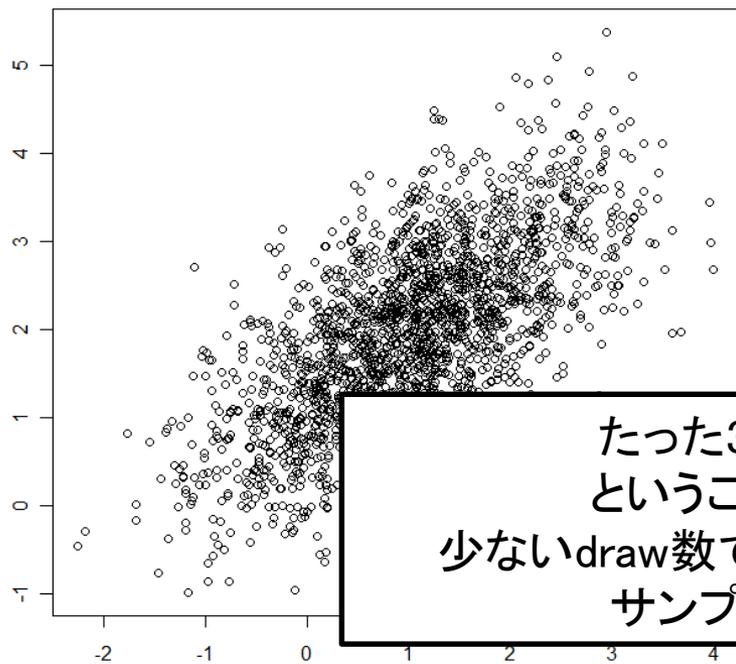
$$\begin{pmatrix} x_1 \\ x_2 \end{pmatrix} \sim N\left(\begin{pmatrix} 1 \\ 2 \end{pmatrix}, \begin{pmatrix} 1 & 0.7 \\ 0.7 & 1 \end{pmatrix}\right)$$

Rの多変量正規分布の乱数発生関数から2000個

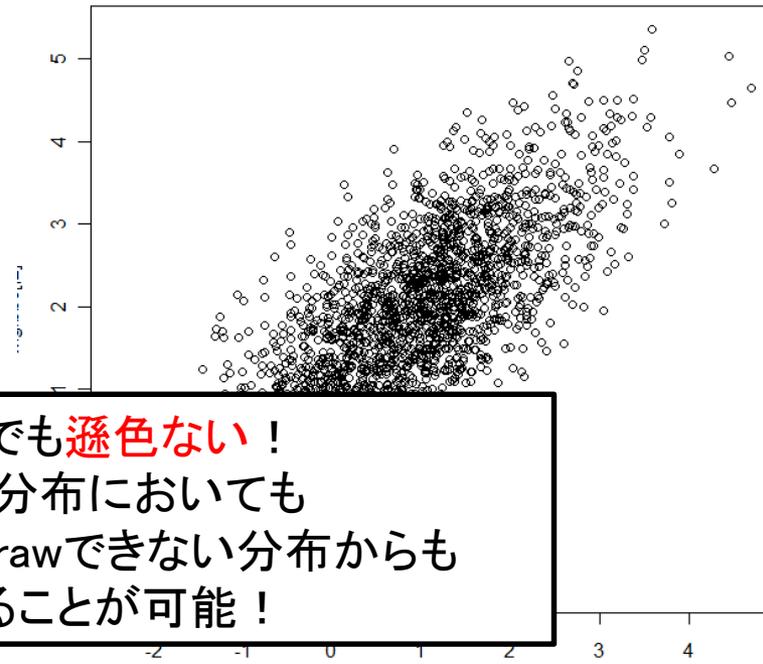
$$x_1 \sim N(1 + 0.7(x_2 - 2), 1 - 0.7^2)$$

$$x_2 \sim N(2 + 0.7(x_1 - 1), 1 - 0.7^2)$$

ギブスサンプラー(3000draw 1000はburn-in)



x.positive2[,1]



x.gibbs[,1]

たった3000drawでも遜色ない！
 ということは他の分布においても
 少ないdraw数で簡単にdrawできない分布からも
 サンプルングすることが可能！

二次元正規分布のサンプリング

http://visualize-mcmc.appspot.com/3_gibbs.html

- 今までのなかで一番一般的な形
- メトロポリス法, ギブスサンプリング \in MH法
- MH法では推移確率を以下のように与える

$$\Pi_{x \rightarrow x'} = Q(x, x') \min\left(1, \frac{Pr\{x'\} Q(x', x)}{Pr\{x\} Q(x, x')}\right)$$

と決定する。ここで $Q(x, x')$ は x という状態にいるときに x' という状態が選択される確率です。

$Q(x, x')$ を適切に選ぶことでメトロポリス法・熱浴法が再現される

- $Q(x, x') = Q(x', x)$ とすると、約分されて...

$$\Pi_{x \rightarrow x'} = Q(x, x') \min\left(1, \frac{Pr\{x'\}}{Pr\{x\}}\right)$$

となってメトロポリス法が再現される。

- $Q(x, x') = Pr\{x' | x\}$ とすると

$$\begin{aligned} \Pi_{x \rightarrow x'} &= Q(x, x') \min\left(1, \frac{Pr\{x'\}Q(x', x)}{Pr\{x\}Q(x, x')}\right) = Pr\{x'|x\} \min\left(1, \frac{Pr\{x'\}Pr\{x|x'\}}{Pr\{x\}Pr\{x'|x\}}\right) \\ &= Pr\{x'|x\} \min\left(1, \frac{Pr\{x, x'\}}{Pr\{x', x\}}\right) = Pr\{x'|x\} \min(1, 1) \\ &= Pr\{x'|x\} \end{aligned}$$

となってギブサンプリングが再現される。

- メトロポリス法
 - 条件付確率が書き下せないときはこれ
 - ステップ幅の設定が難しい(大きすぎたら棄却されやすく, 小さすぎたらランダムウォークしてしまう)
- ギブスサンプリング
 - 条件付き確率が書き下せればかなり効率良い
 - 1つ1つ固定していったうえでのサンプリング
- メトロポリスヘイスティングス法
 - 一般化
- スライスサンプリング
 - ステップ幅を適切に設定することができる
 - 今回は割愛