

2017.09.22 (15:40~17:10)
日本心理学会第81回大会TWS
ベイズアンデータ解析入門

回帰分析を例に ベイズアンデータ解析 を体験してみる

広島大学大学院教育学研究科
平川 真

ベイズ分析のステップ(p.24)

- 1) データの特定
- 2) モデルの定義 **(解釈可能な)モデルの作成**
- 3) パラメタの事前分布の設定
- 4) ベイズ推論を用いて、パラメタの値に確信度を再配分
ベイズ推定
- 5) 事後予測がデータを模倣できているかを確認
記述的妥当性のチェック

データの特定

被予測変数と予測変数を決める

どの変数を記述したいのか（被予測変数; y ）

どの変数で記述したいのか（予測変数; x ）

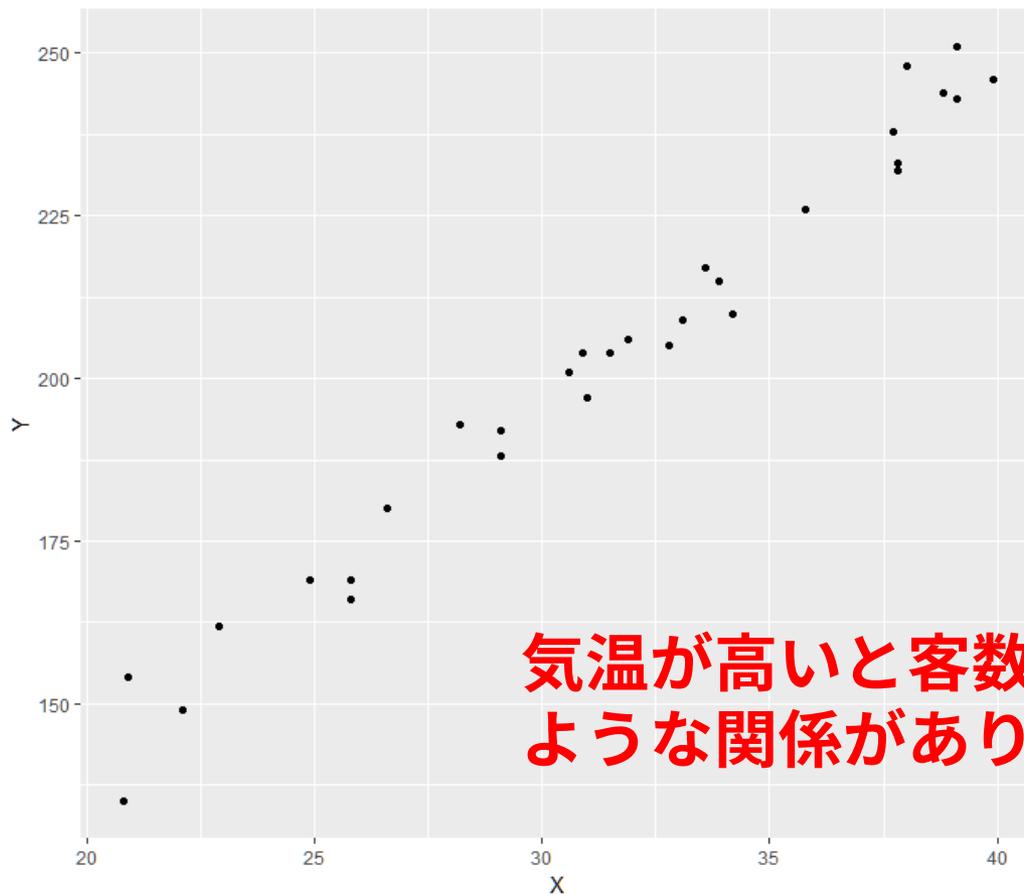
「アイス屋さんの客数を気温で予測する」

ということを考えてみる（架空データ）



データの確認

気温(x)と客数(y)の30ポイントのデータ



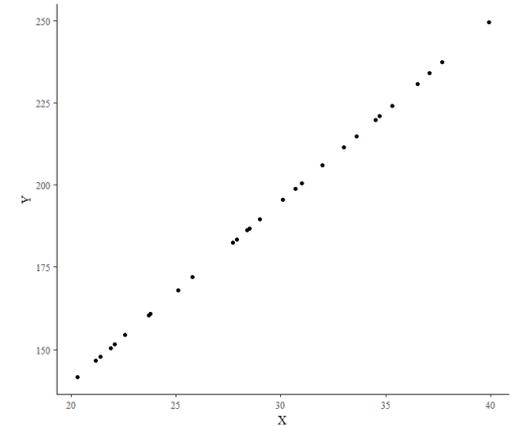
気温が高いと客数が多い
ような関係がありそう

	X	Y
1	25.8	169
2	35.8	226
3	28.2	193
4	37.7	238
5	38.8	244
6	20.9	154
7	30.6	201
8	37.8	232
9	31.0	197
10	29.1	188
11	39.1	251
12	29.1	192
13	33.6	217
14	31.5	204
15	22.1	149
16	30.0	210

モデルの定義

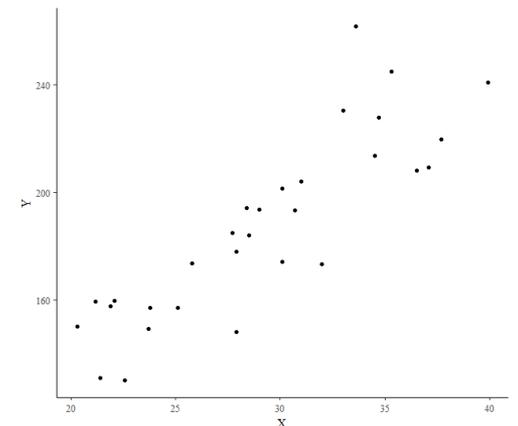
1) x と y の関係について**とりあえず線形関係を考える**

- 現実世界の依存関係の多くは厳密には非線形かもしれないが、
ほぼ線形で考えて問題ないことが多い (p. 434)



2) x と y の関係について**確率的関係を考える**

- x から予測できない y の変動が常にある
- y が予測変数の線形結合に完全に従うのではなく
「**ほぼ従う**」と考える (p. 449)



回帰分析のモデル

- ✓ 中心傾向 (μ) を x の線形結合で表現
- ✓ μ 周辺に y が正規分布に従って発生する

解釈可能なモデル (赤字はパラメタ)

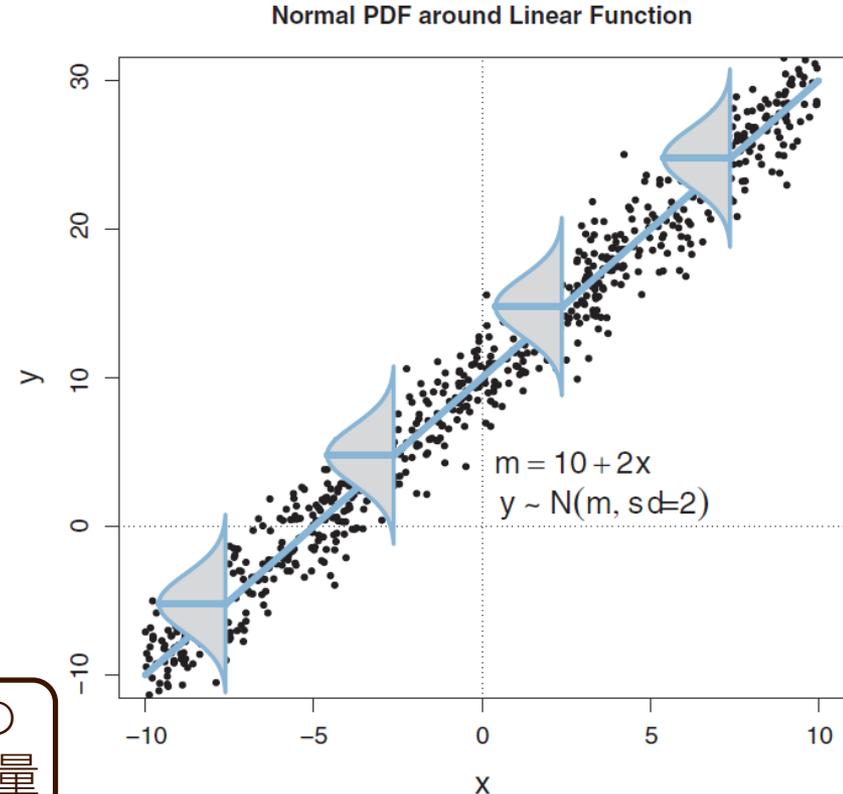
x が0のときの
予想される y の値

$$\mu = \beta_0 + \beta_1 x$$

x が1増加したときの
予想される y の変化量

$$y \sim normal(\mu, \sigma)$$

予想される周辺で
 y が変動する程度



パラメタの事前分布の設定

無情報事前分布をつかう

- ・パラメタについて事前情報がほとんどないことを示す
= **データの情報を重視する**

よく使う無情報事前分布

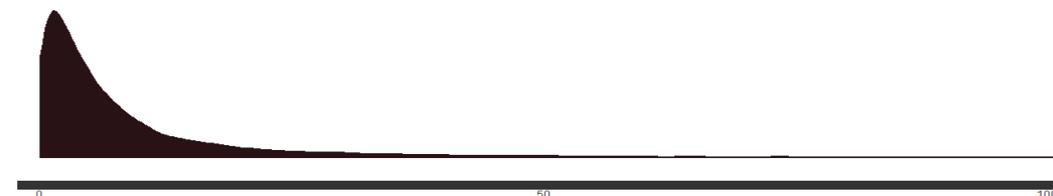
- ・切片や回帰係数 ($-\infty \sim \infty$ の範囲)

Normal(0, 100)



- ・標準偏差 ($0 \sim \infty$ の範囲)

Cauchy(0, 5)_{I(0, ∞)}



ベイズ分析のステップ(p.24)

- 1) データの特定
- 2) モデルの定義 (解釈可能な)モデルの作成
- 3) パラメタの事前分布の設定
- 4) ベイズ推論を用いて、パラメタの値に確信度を再配分
ベイズ推定
- 5) 事後予測がデータを模倣できているかを確認
記述的妥当性のチェック

モデルをコードに

example3.stan(*モデルブロックのみ)

モデルの記述

$$\mu = \beta_0 + \beta_1 x$$

$$y \sim \text{normal}(\mu, \sigma)$$

事前分布の設定

$$\beta_0 \sim \text{normal}(0, 100)$$

$$\beta_1 \sim \text{normal}(0, 100)$$

$$\sigma \sim \text{cauchy}(0, 5)$$

```
13 model{
14   //モデルの記述
15   real mu[N];
16   for(n in 1:N){
17     mu[n] = beta0+beta1*x[n];
18     y[n] ~ normal(mu[n], sigma);
19   }
20   //事前分布の設定
21   beta0 ~ normal(0, 100);
22   beta1 ~ normal(0, 100);
23   sigma ~ cauchy(0, 5);
24 }
25
```

そのまま

Stanコード解説

```
1 data{
2   int N; //人数(整数)
3   real y[N]; //被予測変数(N個の配列(実数))
4   real x[N]; //予測変数(N個の配列(実数))
5 }
```

渡すデータを宣言

- N人分の y と x を渡すよ

```
6
7 parameters{
8   real beta0; //切片(実数)
9   real beta1; //回帰係数(実数)
10  real <lower=0> sigma; //正規分布の標準偏差(下限0)(実数)
11 }
```

```
12
13 model{
14   //モデルの記述
15   real mu[N];
16   for(n in 1:N){
17     mu[n] = beta0+beta1*x[n];
18     y[n] ~ normal(mu[n], sigma);
19   }
20   //事前分布の設定
21   beta0 ~ normal(0, 100);
22   beta1 ~ normal(0, 100);
23   sigma ~ cauchy(0, 5);
24 }
```

モデルで使うパラメタを宣言

- $beta0, beta1, sigma$ というパラメタを使うよ
- $sigma$ は正の値だよ

実行

```
#実行コード-----
```

```
model<-stan_model("example3.stan") ←先ほどのモデルをコンパイル
```

```
data<-list(N=nrow(dat), y=dat$Y, x=dat$X)
```

↑ 渡すデータをリスト形式で作成

```
fit<-sampling(model,
```

```
  data=data,
```

←MCMCサンプリングの実行

```
  chains = 4,
```

```
  iter = 2000,
```

```
  warmup = 1000,
```

```
  seed=123)
```

chains:

MCMCサンプル列を何本発生させるか

iter:

MCMCサンプルを何個だすか

warmup:

MCMCサンプルの初めのほうを何個除去するか

とりあえずみてる

```
> fit
```

```
Inference for Stan model: reg.
```

```
4 chains, each with iter=2000; warmup=1000; thin=1;
```

```
post-warmup draws per chain=1000, total post-warmup draws=4000.
```

←MCMCの設定

	mean	se_mean	sd	2.5%	25%	50%	75%	97.5%	n_eff	Rhat
beta0	32.21	0.17	5.44	21.63	28.70	32.15	35.67	43.25	1031	1
beta1	5.42	0.01	0.17	5.08	5.31	5.42	5.53	5.76	1042	1
sigma	5.13	0.02	0.70	4.02	4.62	5.06	5.53	6.80	1488	1
lp__	-62.74	0.04	1.34	-66.27	-63.30	-62.37	-61.77	-61.24	1050	1

Samples were drawn using NUTS(diag_e) at Tue Sep 19 14:14:15 2017.

For each parameter, n_eff is a crude measure of effective sample size, and Rhat is the potential scale reduction factor on split chains (at convergence, Rhat=1).

```
> |
```

パラメタの要約

パラメタの事後分布をみる前に

MCMCの**代表性**をチェックする

チェーン内の値は事後分布を代表していなければならない。

チェーンの任意の初期値に過度に影響をうけるべきでなく、

一部に留まることなく事後分布の範囲を十分に探索すべきである (p.181)

みためによるチェック：

トレースプロット、確率密度プロット

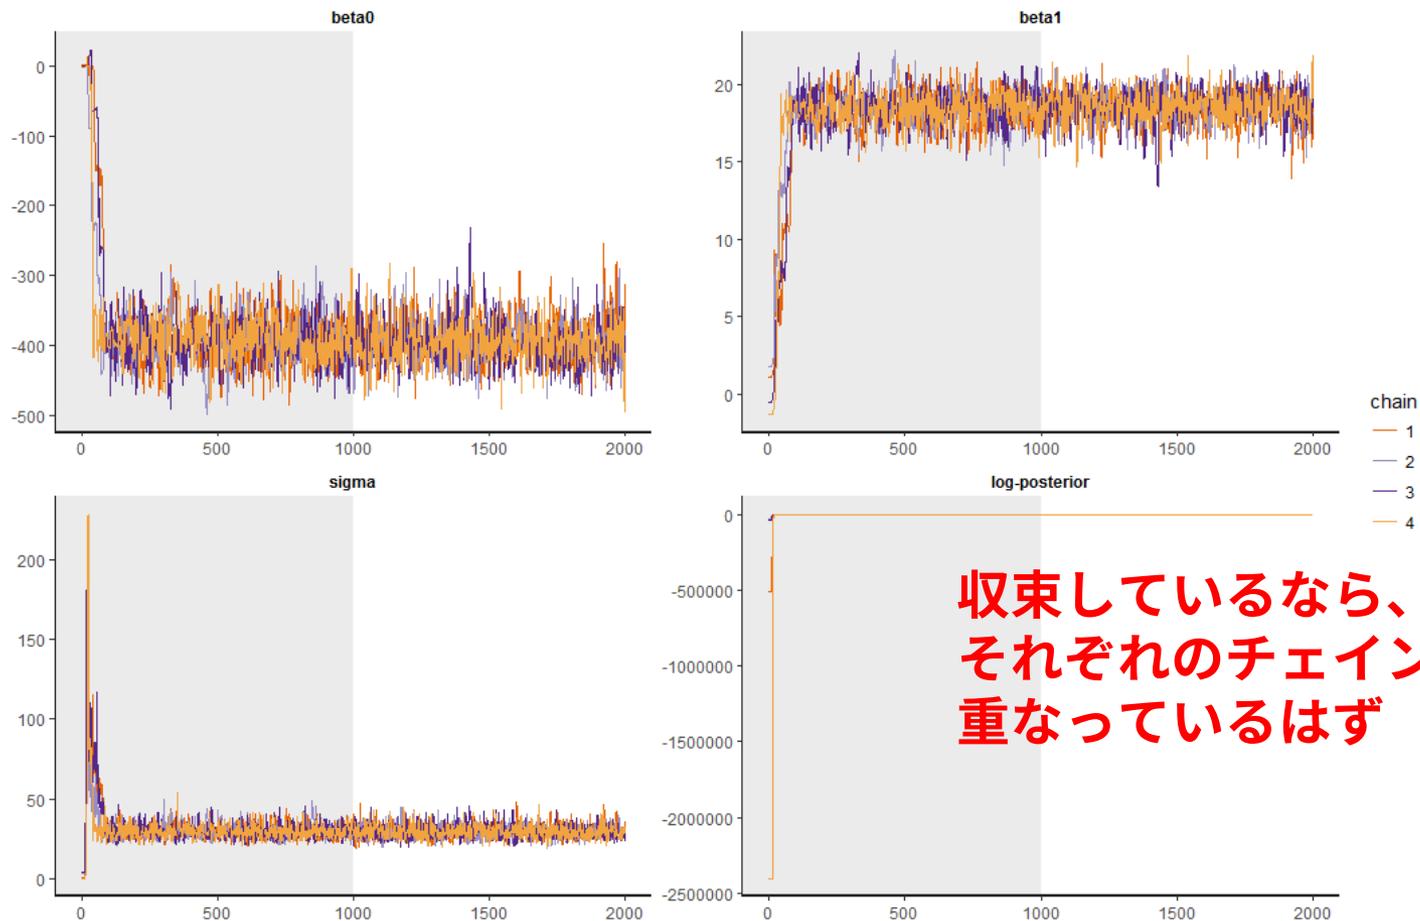
数値によるチェック：

Gelman-Rubin統計量

トレースプロットの確認

```
##トレースプロット
```

```
stan_trace(fit,  
           pars=c("beta0", "beta1", "sigma", "lp__"),  
           inc_warmup = T)
```



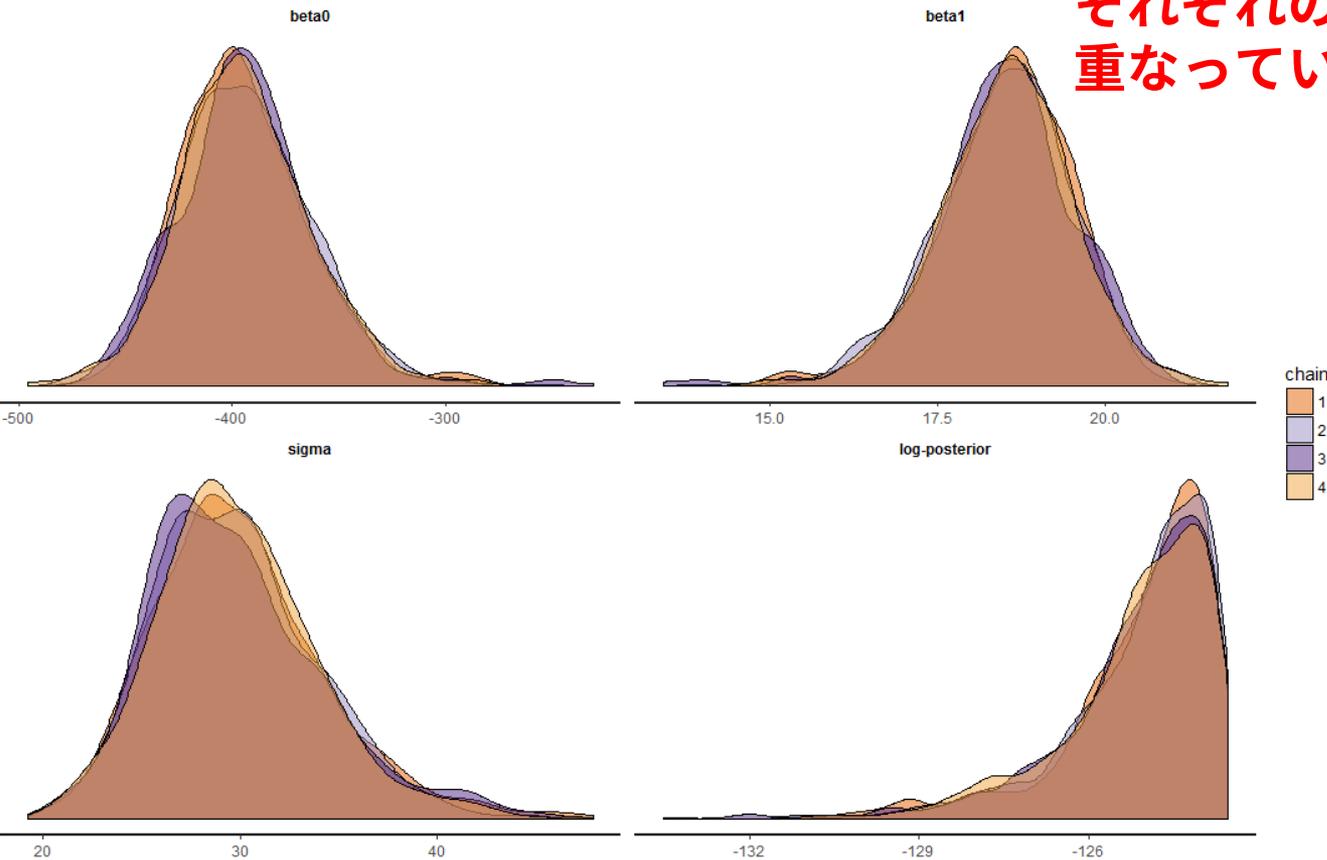
収束しているなら、
それぞれのチェーンのサンプルが
重なっているはず

確率密度プロットの確認

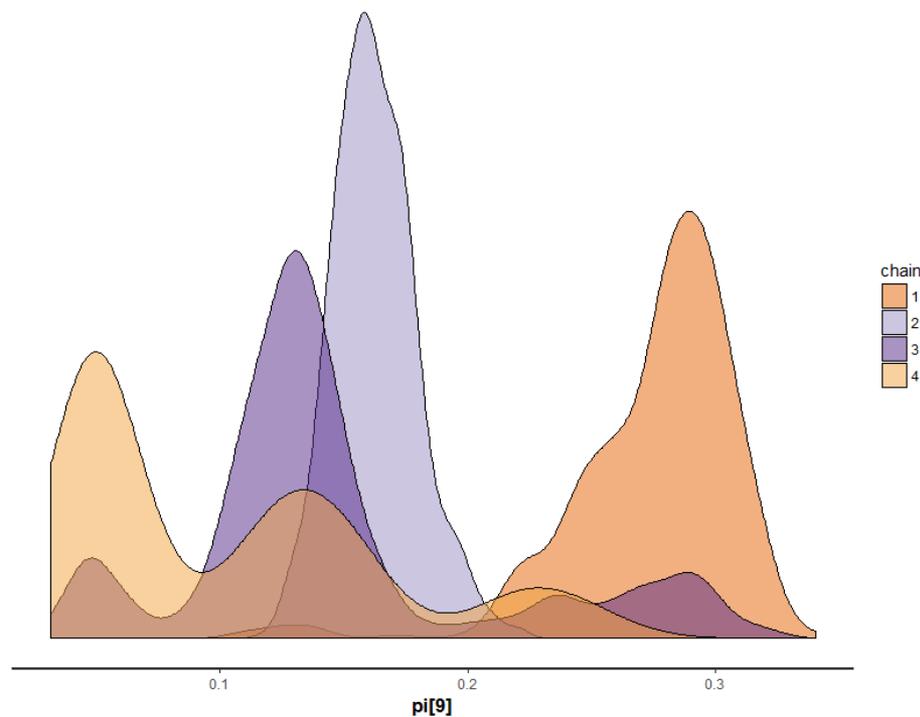
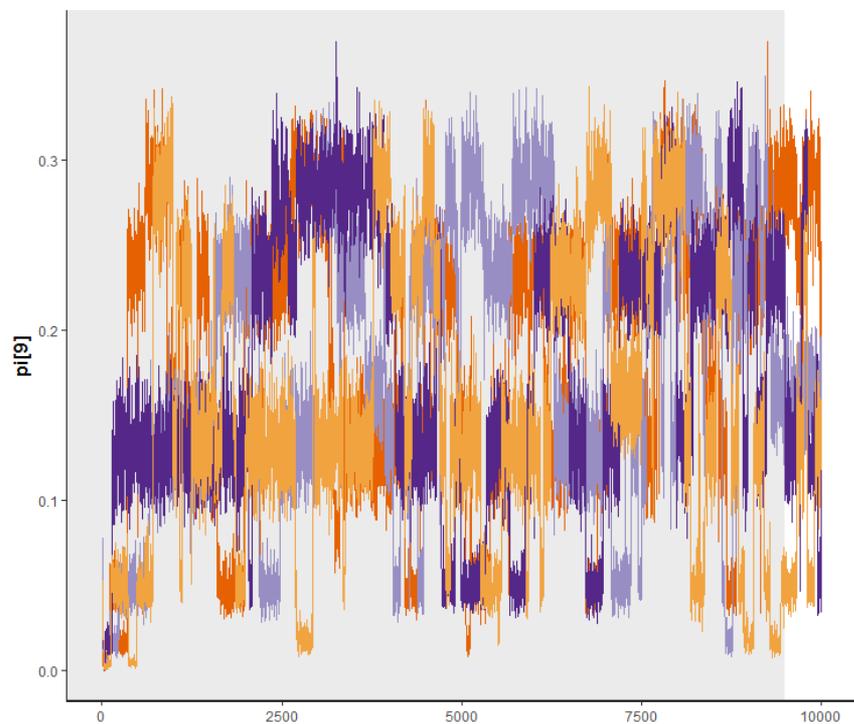
```
## 確率密度プロット
```

```
stan_dens(fit,  
  pars=c("beta0", "beta1", "sigma", "lp__"),  
  inc_warmup = F,  
  separate_chains = T)
```

収束しているなら、
それぞれのチェーンのサンプルが
重なっているはず



だめなMCMC



それぞれのチェーンのサンプルが重なっていない

Gelman-Rubin統計量の確認

チェーン内の分散に対してチェーン間の分散がどれくらい大きいのか、の指標
完全に収束した場合に1.0となり、乖離したチェーンがあれば1.0以上の値になる

```
> fit
```

```
Inference for Stan model: reg.
```

```
4 chains, each with iter=2000; warmup=1000; thin=1;
```

```
post-warmup draws per chain=1000, total post-warmup draws=4000.
```

1.1以上=NG

	mean	se_mean	sd	2.5%	25%	50%	75%	97.5%	n_eff	Rhat
beta0	32.21	0.17	5.44	21.63	28.70	32.15	35.67	43.25	1031	1
beta1	5.42	0.01	0.17	5.08	5.31	5.42	5.53	5.76	1042	1
sigma	5.13	0.02	0.70	4.02	4.62	5.06	5.53	6.80	1488	1
lp__	-62.74	0.04	1.34	-66.27	-63.30	-62.37	-61.77	-61.24	1050	1

Samples were drawn using NUTS(diag_e) at Tue Sep 19 14:14:15 2017.

For each parameter, n_eff is a crude measure of effective sample size, and Rhat is the potential scale reduction factor on split chains (at convergence, Rhat=1).

```
> |
```

パラメタの事後分布をみる前に

MCMCの**正確性**をチェックする

推定を正確で安定したものとするために、チェーンは十分なサイズであるべきである。特に、(中央値や最頻値などの) 中心傾向の推定や95% HDIの限界は、分析を繰り返した際に大きく異なるべきではない (p. 181)

チェックする指標：

有効サンプルサイズ(ESS)、自己相関

有効サンプルサイズの確認

チェーンの中に独立した情報がどれくらいあるかの指標

```
> fit
```

```
Inference for Stan model: reg.
```

```
4 chains, each with iter=2000; warmup=1000; thin=1;
```

```
post-warmup draws per chain=1000, total post-warmup draws=4000.
```

	mean	se_mean	sd	2.5%	25%	50%	75%	97.5%	n_eff	Rhat
beta0	32.21	0.17	5.44	21.63	28.70	32.15	35.67	43.25	1031	1
beta1	5.42	0.01	0.17	5.08	5.31	5.42	5.53	5.76	1042	1
sigma	5.13	0.02	0.70	4.02	4.62	5.06	5.53	6.80	1488	1
lp__	-62.74	0.04	1.34	-66.27	-63.30	-62.37	-61.77	-61.24	1050	1

Samples were drawn using NUTS(diag_e) at Tue Sep 19 14:14:15 2017.

For each parameter, n_eff is a crude measure of effective sample size, and Rhat is the potential scale reduction factor on split chains (at convergence, Rhat=1).

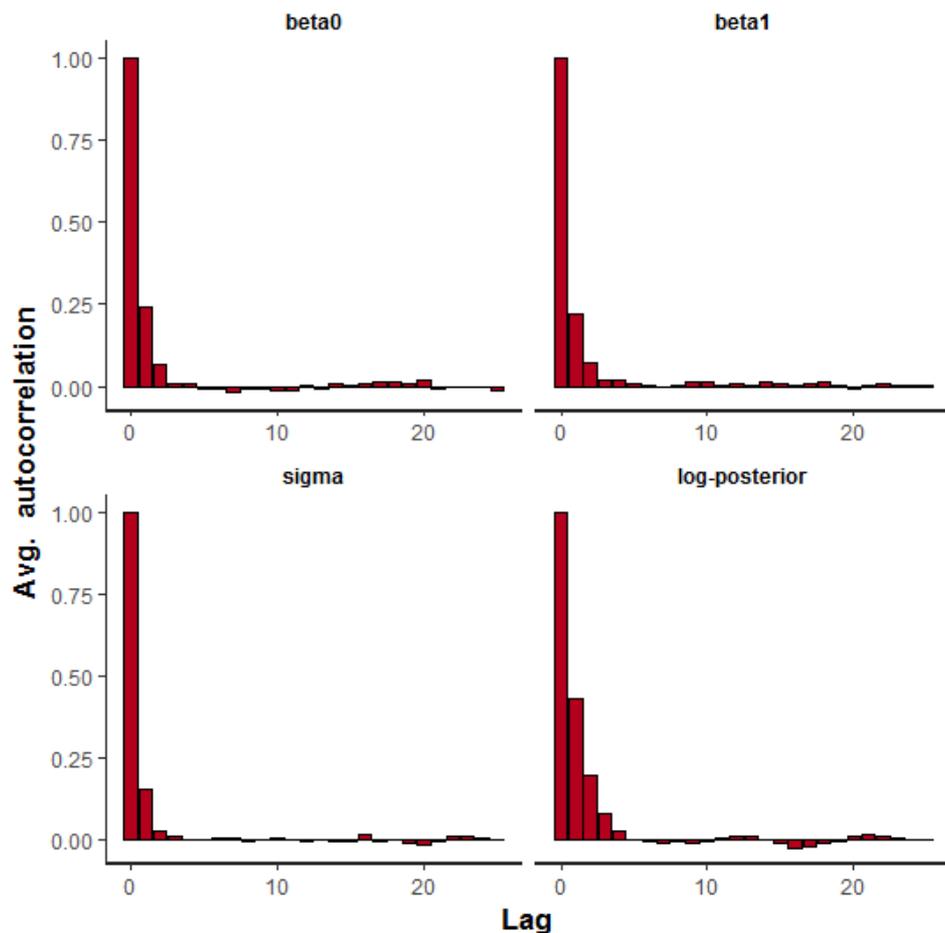
```
> |
```

$$ESS = N / \left(1 + 2 \sum_{k=1}^{\infty} ACF(k) \right)$$

自己相関の確認

自己相関

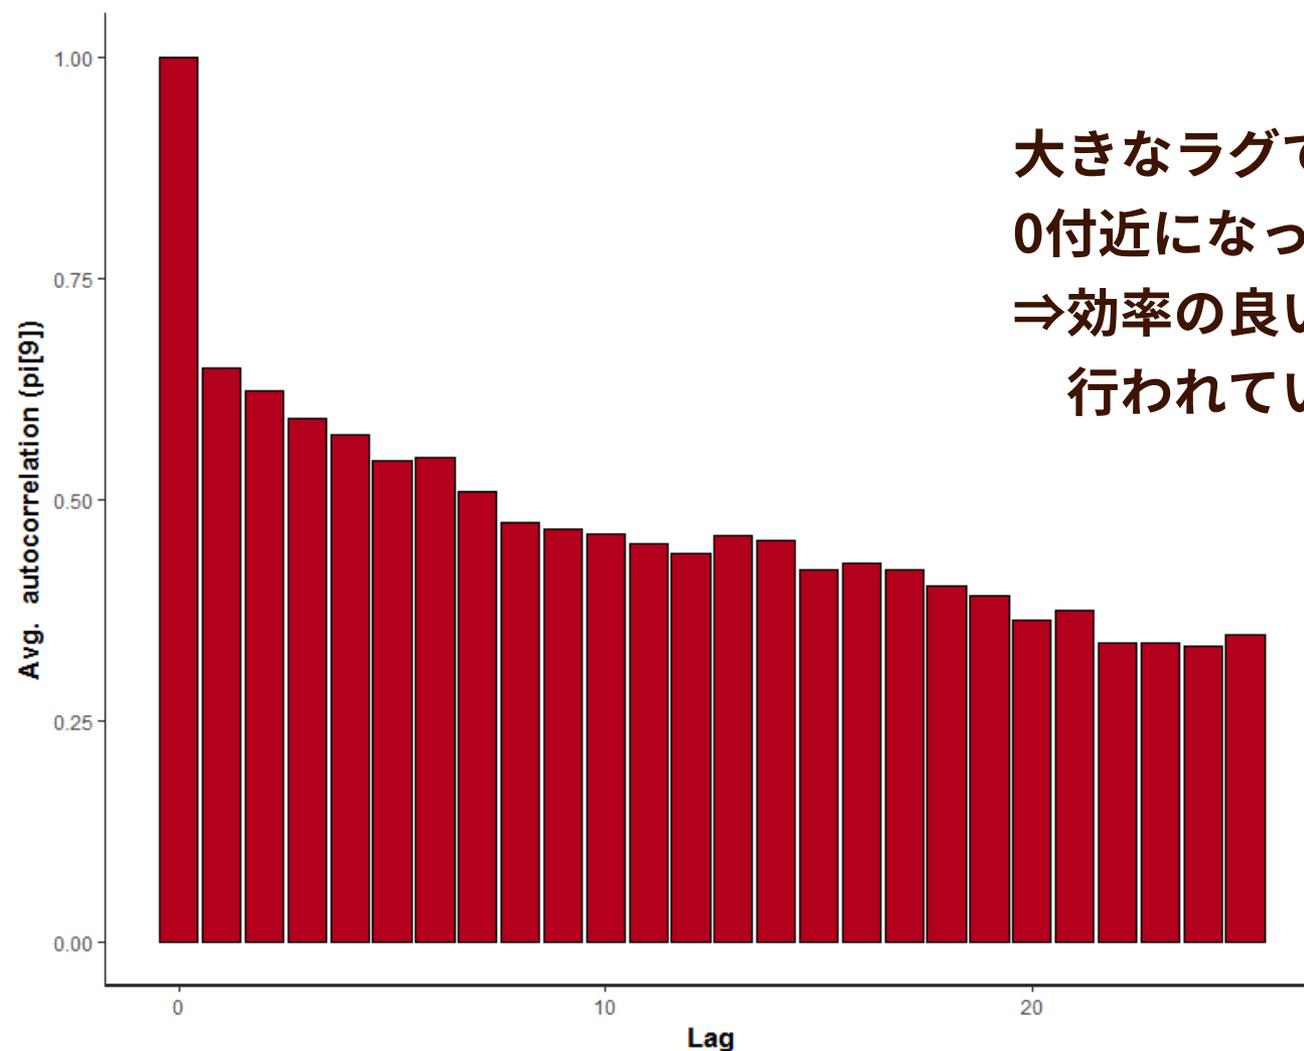
```
stan_ac(fit,  
  pars=c("beta0", "beta1", "sigma", "lp__"),  
  inc_warmup = F)
```



kステップ前の値との相関

離れているステップの値とは
相関しないはず

自己相関が高い場合



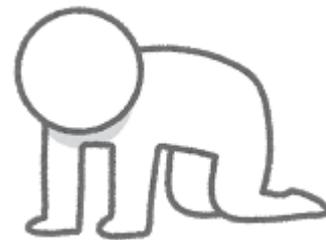
大きなラグでも相関が
0付近になっていない
⇒効率の良いサンプリングが
行われていない可能性あり

どれくらいESSがあると良いのか

扱いたい事後分布による。(中略)

1つの簡単なガイドラインとしては、95%HDIの限界を正確で安定した妥当な推定の為に推奨されるESSの値は10,000である。これは、単に慣習上の経験に基づくヒューリスティックであり、必須のものではない。HDIの限界の正確性が実用上重要でなければ、ESSが小さくても十分である場合もある。 p. 187

	mean	se_mean	sd	2.5%	25%	50%	75%	97.5%	n_eff	Rhat
beta0	32.21	0.17	5.44	21.63	28.70	32.15	35.67	43.25	1031	1
beta1	5.42	0.01	0.17	5.08	5.31	5.42	5.53	5.76	1042	1
sigma	5.13	0.02	0.70	4.02	4.62	5.06	5.53	6.80	1488	1
lp__	-62.74	0.04	1.34	-66.27	-63.30	-62.37	-61.77	-61.24	1050	1



十分な数を得る

iter = 2000 の結果

```
> fit
```

Inference for Stan model: reg.

4 chains, each with iter=2000; warmup=1000; thin=1;

post-warmup draws per chain=1000, total post-warmup draws=4000.

	mean	se_mean	sd	2.5%	25%	50%	75%	97.5%	n_eff	Rhat
beta0	32.21	0.17	5.44	21.63	28.70	32.15	35.67	43.25	1031	1
beta1	5.42	0.01	0.17	5.08	5.31	5.42	5.53	5.76	1042	1
sigma	5.13	0.02	0.70	4.02	4.62	5.06	5.53	6.80	1488	1
lp__	-62.74	0.04	1.34	-66.27	-63.30	-62.37	-61.77	-61.24	1050	1

$$MCSE = SD / \sqrt{ESS}$$

iter = 10000 の結果

```
> fit2
```

Inference for Stan model: reg.

4 chains, each with iter=10000; warmup=1000; thin=1;

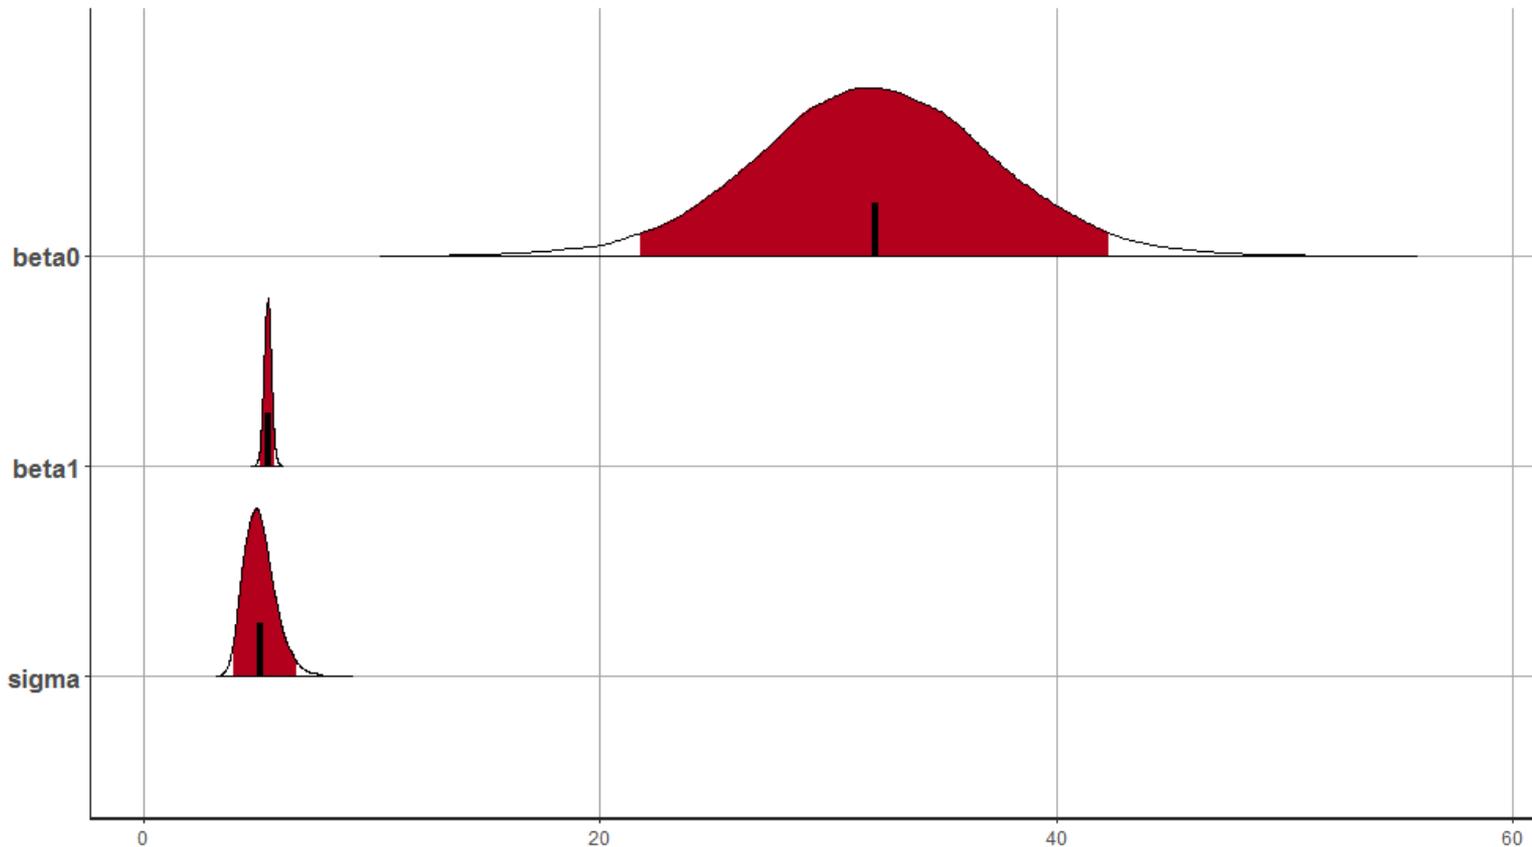
post-warmup draws per chain=9000, total post-warmup draws=36000.

	mean	se_mean	sd	2.5%	25%	50%	75%	97.5%	n_eff	Rhat
beta0	32.06	0.05	5.21	21.76	28.65	32.03	35.50	42.30	11169	1
beta1	5.43	0.00	0.16	5.11	5.32	5.43	5.53	5.75	11210	1
sigma	5.09	0.01	0.70	3.95	4.59	5.02	5.50	6.68	13906	1
lp__	-62.69	0.01	1.29	-66.04	-63.26	-62.35	-61.76	-61.24	10168	1

事後分布を代表するサンプルを十分な数、得ることができた

パラメタの事後分布をみる

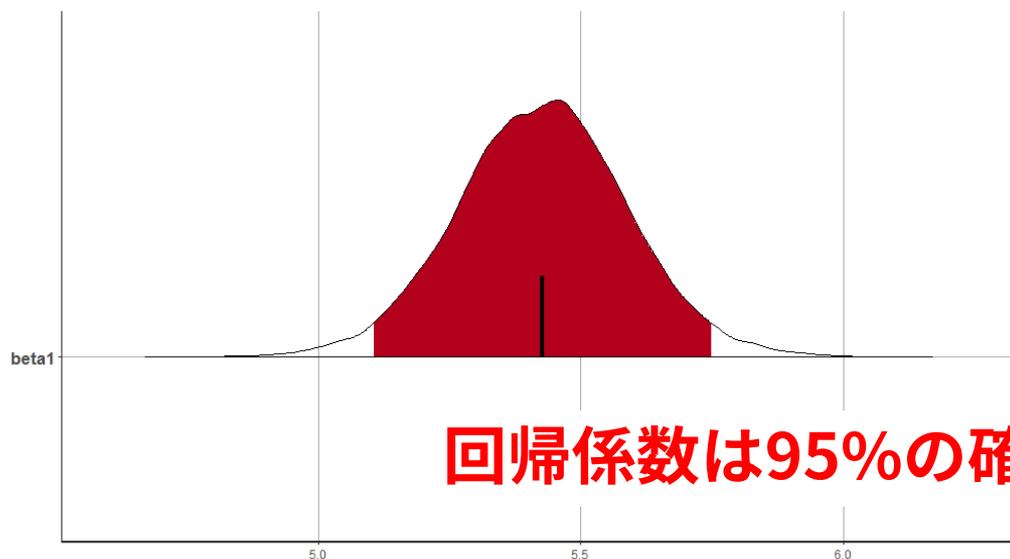
```
stan_plot(fit2,  
          point_est = "mean",  
          ci_level = 0.95,  
          outer_level = 1.00,  
          show_density = T)
```



パラメタの事後分布をみる

```
print(fit2,  
      pars=c("beta0", "beta1", "sigma"),  
      probs = c(0.025, 0.975),  
      digit=2)
```

	mean	se_mean	sd	2.5%	97.5%	n_eff	Rhat
beta0	32.06	0.05	5.21	21.76	42.30	11169	1
beta1	5.43	0.00	0.16	5.11	5.75	11210	1
sigma	5.09	0.01	0.70	3.95	6.68	13906	1



回帰係数は95%の確率で5.11~5.75の範囲！！

MCMCサンプルをとりだしてみる

```
##MCMCサンプルを取り出してみる-----
```

```
MCMC_sample <- rstan::extract(fit2)
```

```
MCMC_sample$beta1
```

```
[9526] 5.327744 5.391297 5.586168 5.228040 5.471859 5.396478 5.394000 5.298967 5.294479 5.407322 5.313322 5.690541 5.242444 5.492485 5.442045  
[9541] 5.523062 5.682807 5.403977 5.711528 5.238148 5.021745 5.267758 5.368967 5.606367 5.442238 5.484823 5.457237 5.406047 5.181691 5.221145  
[9556] 5.583856 5.418137 5.346719 5.403742 5.694464 5.406850 5.197044 5.503226 5.574650 5.647990 5.588874 5.374763 5.257702 5.696040 5.684942  
[9571] 5.292002 5.497614 5.287017 5.407800 5.450511 5.591223 5.341848 5.308522 5.349519 5.429579 5.488189 5.331035 5.423699 5.459995 5.270441  
[9586] 5.443112 5.551823 5.357891 5.393292 5.719813 5.737147 5.423611 5.582843 5.359094 5.195234 5.448931 5.540705 5.467804 5.511697 5.569983  
[9601] 5.216079 5.545751 5.253380 5.227147 5.248379 5.649595 5.310313 5.421093 5.489024 5.485219 5.685252 5.710785 5.270703 5.509406 5.260835  
[9616] 5.541055 5.682500 5.472370 5.539820 5.485763 5.549721 5.216008 5.196411 5.535062 5.506433 5.378822 5.367976 5.205392 5.232530 5.193947  
[9631] 5.339119 5.381403 5.340438 5.462128 5.303274 5.323616 5.630579 5.448144 5.440452 5.419324 5.491012 5.549345 5.396453 5.606915 5.090921  
[9646] 5.148990 5.402892 5.372041 5.395216 5.639929 5.445213 5.583051 5.123423 5.570712 5.346336 5.525440 5.289096 5.124714 5.498917 5.326757  
[9661] 5.537477 5.463039 5.158288 5.623456 5.533672 5.516235 5.459725 5.509476 5.336971 5.176089 5.364578 5.616866 5.317989 5.415214 5.211840  
[9676] 5.329596 5.740530 5.086448 5.248351 5.623909 5.439858 5.323970 5.401471 5.440994 5.471716 5.466710 5.478588 5.445794 5.333914 5.545963  
[9691] 5.394366 5.362815 5.275089 5.504674 5.347213 5.384583 5.382437 5.359517 5.575699 5.424004 5.631942 4.971791 5.614748 5.327558 5.488903  
[9706] 5.636495 5.411853 5.023058 5.427178 5.522153 5.115228 5.256378 5.594736 5.457374 5.379871 5.329675 5.569590 5.409419 5.320595 5.414298  
[9721] 5.624036 5.473210 5.284501 5.448425 5.604199 5.380861 5.336508 5.404221 5.392213 5.689517 5.158517 5.612915 5.261411 5.623937 5.571804  
[9736] 5.415824 5.586629 5.250031 5.475339 5.350601 5.355794 5.497493 5.402543 5.412105 5.165743 5.586504 5.296861 5.425583 5.464363 5.634242  
[9751] 5.457049 5.218538 5.347443 5.444074 5.571790 5.259725 5.321866 5.541890 5.166652 5.535494 5.342726 5.540269 5.659826 5.423026 5.380296  
[9766] 5.327957 5.500350 5.564712 5.535970 5.332730 5.330612 5.372054 5.470599 5.415579 5.311598 5.800682 5.295659 5.395054 5.450714 5.433114  
[9781] 5.305030 5.426745 5.371906 5.427851 5.488430 5.158702 5.351487 5.220493 5.598603 5.041680 5.501504 5.451044 5.264861 5.418514 5.681993  
[9796] 5.322028 5.576613 5.659707 5.391264 5.304711 5.195193 5.396485 5.355377 5.334470 5.506894 5.400300 5.391822 5.531689 5.466296 5.477733  
[9811] 5.524075 5.592017 5.495238 5.273194 5.541097 5.487424 5.432141 5.634036 5.827715 5.419672 5.464317 5.254784 5.374201 5.299846 5.628546  
[9826] 5.197037 5.519877 5.481440 5.311706 5.789387 4.884573 5.271566 5.322643 5.427137 5.191031 5.561998 5.410702 5.612071 5.364951 5.361724 5.556714  
[9841] 5.427705 5.366086 5.485043 5.468828 5.048683 5.327874 5.198257 5.300303 5.203722 5.604651 5.232679 5.270381 5.843844 5.376533 5.586029  
[9856] 5.252775 5.521540 5.410832 5.518144 5.355337 5.500081 5.489055 5.263331 5.372635 5.483577 5.387697 5.474512 5.789923 5.508983 5.547019  
[9871] 5.532555 5.504337 5.323353 5.714781 5.427752 5.374196 5.429243 5.521466 5.320753 5.516128 5.462477 5.226265 5.346915 5.403695 5.655206  
[9886] 5.744851 5.515232 5.417890 5.457810 5.277921 5.407784 5.322643 5.427137 5.191031 5.561998 5.410702 5.612071 5.364951 5.361724 5.556714  
[9901] 5.405357 5.214694 5.215783 5.276046 5.122227 5.609517 5.339299 5.505984 5.051742 5.309609 5.577188 5.100382 5.210931 5.338170 5.242857  
[9916] 5.494320 5.279839 5.420686 5.467431 5.226570 5.342503 5.173700 5.474954 5.120192 5.388047 5.071685 5.558050 5.497036 5.433397 5.807631  
[9931] 5.542141 5.468080 5.644989 5.640255 5.700194 5.470304 5.632964 5.448672 5.296340 5.495016 5.428788 5.423055 5.428169 5.288128 5.549563  
[9946] 5.617458 5.291532 5.362761 5.408573 5.496875 5.338166 5.409951 5.492119 5.373749 5.303897 5.581111 5.321083 5.247136 5.557733 5.434447  
[9961] 5.255783 5.318330 5.405285 5.288522 5.246765 5.430772 5.535952 5.485694 5.048507 5.220742 5.716676 5.308802 5.403158 5.511092 5.421033  
[9976] 5.279330 5.619901 5.209563 5.625805 5.387189 5.577692 5.610974 5.028120 5.279072 5.451122 5.422522 5.550244 5.156675 5.456278 5.514262  
[9991] 5.383406 5.442135 5.792463 5.508121 5.384278 5.265811 5.295682 5.450120 5.279072 5.451122 5.422522 5.550244 5.156675 5.456278 5.514262  
[reached getoption("max.print") -- omitted 26000 entries ]
```

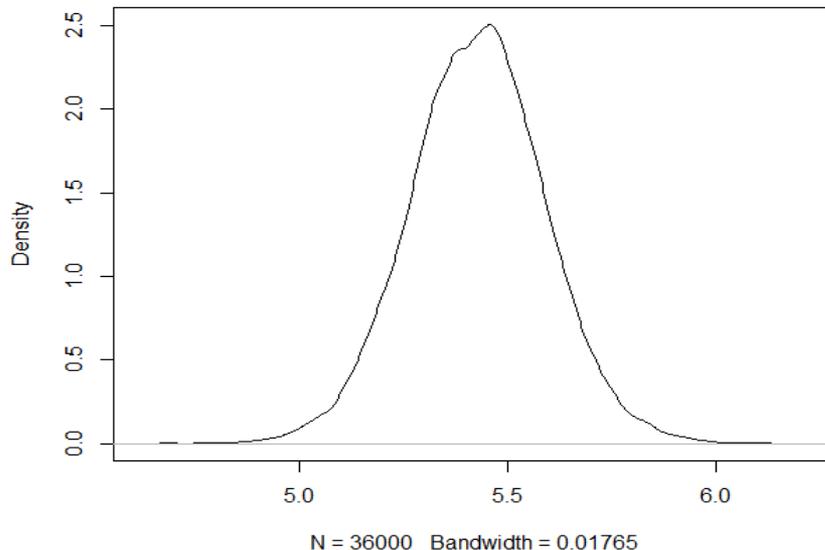
36000個のMCMCサンプル

MCMCサンプルをとりだしてみる

```
> beta1 <- MCMC_sample$beta1
> print(
+   quantile(beta1, probs = c(0.025, 0.975)),
+   digit = 3
+ )
2.5% 97.5%
5.11  5.75
```

とりだした36000個のMCMCサンプルの
2.5%タイル点と97.5%タイル点を求める
= 回帰係数の95%確信区間を求める

density.default(x = beta1)



とりだした36000個のMCMCサンプルの
密度をプロット
= 回帰係数の事後分布を描く

MCMCサンプルを自由につかう

回帰係数が5を超える確率が知りたい！

```
> a <- 5
> sum(ifelse(beta1 > a, 1, 0))/length(beta1)
[1] 0.9942222
```

とりだした36000個のMCMCサンプルのうち
5を超えた個数を数えて、36000でわる

99.4% !!

```
> a <- 6
> sum(ifelse(beta1 > a, 1, 0))/length(beta1)
[1] 0.000416667
```

```
> a <- 5.5
> sum(ifelse(beta1 > a, 1, 0))/length(beta1)
[1] 0.3228889
```

MCMCサンプルを自由につかう

気温が30度のときの客数の95%範囲が知りたい！

```
> beta0<-MCMC_sample$beta0  
> beta1<-MCMC_sample$beta1  
> sigma<-MCMC_sample$sigma
```

各パラメタのMCMCサンプルをとりだして格納

```
>  
> x<-30  
> y<-rnorm(n = 36000,  
+         mean = beta0 + beta1*x,  
+         sd = sigma)  
>  
> round(quantile(y, probs=c(0.025, 0.975)))
```

回帰モデルに従った y (乱数) を36000個発生

```
 2.5% 97.5%  
  185   205
```

発生させた y の2.5%, 97.5%

```
> |  
    タイル点をもとめる
```

↓発生させた y (36000個の一部)

```
[9796] 197.1240 188.6008 186.0957 198.9072 194.2556 197.3051  
[9811] 195.6576 194.9754 202.9250 196.9239 188.3343 192.4133  
[9826] 192.1186 196.4582 200.4046 200.3447 197.9343 192.3935  
[9841] 197.2240 189.7236 189.3067 200.1799 184.5545 199.9318  
[9856] 191.0731 197.8907 185.9613 200.5236 198.9759 194.7952  
[9871] 196.0838 203.1068 200.9442 199.6343 207.9483 191.8382  
[9886] 199.6671 197.0766 193.4163 186.5562 195.1757 189.1155  
[9901] 202.8738 188.2106 197.6509 198.8228 183.9102 191.8424  
[9916] 199.9673 195.6112 192.8284 194.2560 195.5894 194.5207  
[9931] 194.7325 196.0280 198.8894 185.8372 200.1046 191.5518  
[9946] 197.0613 197.3704 187.1656 195.1825 192.5136 196.9820  
[9961] 192.7017 190.0687 195.9860 208.9759 203.0380 192.5204  
[9976] 193.3814 195.4453 190.2607 196.1808 195.8417 188.0084  
[9991] 195.7850 189.6549 190.3989 199.9954 193.1358 205.6664  
[ reached getoption("max.print") -- omitted 26000 entries ]
```

185人~205人！！

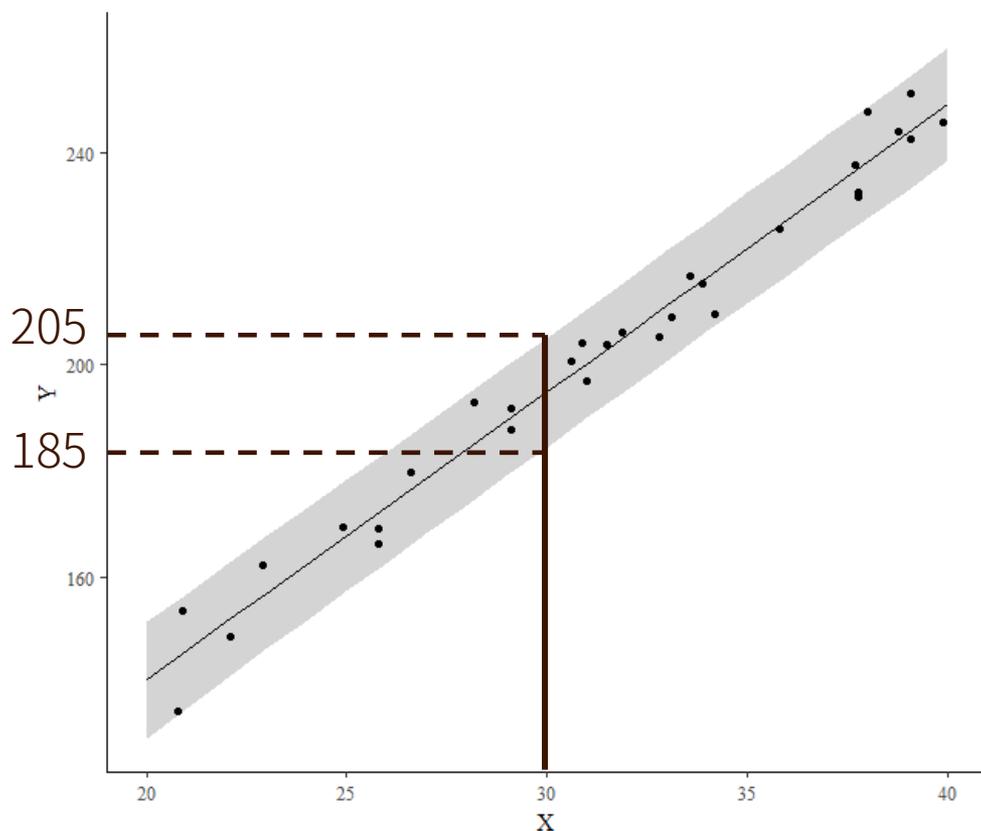
ベイジアン分析のステップ(p.24)

- 1) データの特定
- 2) モデルの定義 **(解釈可能な)モデルの作成**
- 3) パラメタの事前分布の設定
- 4) ベイズ推論を用いて、パラメタの値に確信度を再配分
ベイズ推定
- 5) 事後予測がデータを模倣できているかを確認
記述的妥当性のチェック

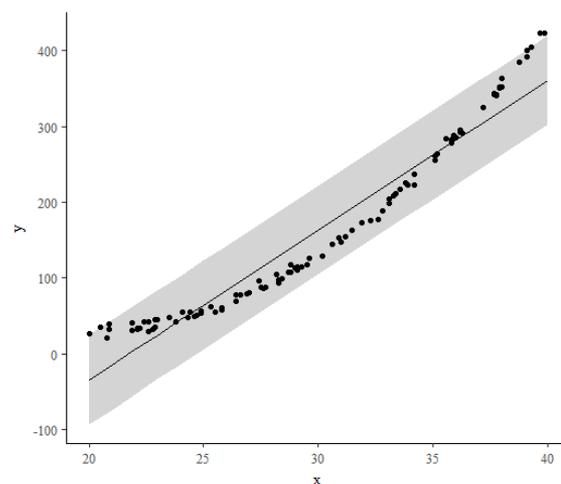
事後予測チェック

事後予測がデータを模倣できているかを確認

モデルから発生させたデータの95%範囲（グレー部分）とデータをプロット



事後予測分布とデータに
一貫したずれがある場合
⇒モデルを修正する必要あり



一般化線形モデル

一般化線形モデル (GLM) の枠組み

- ✓ 中心傾向 (μ) を x の線形結合で表現
- ✓ μ 周辺に y が「ある分布」に従って発生

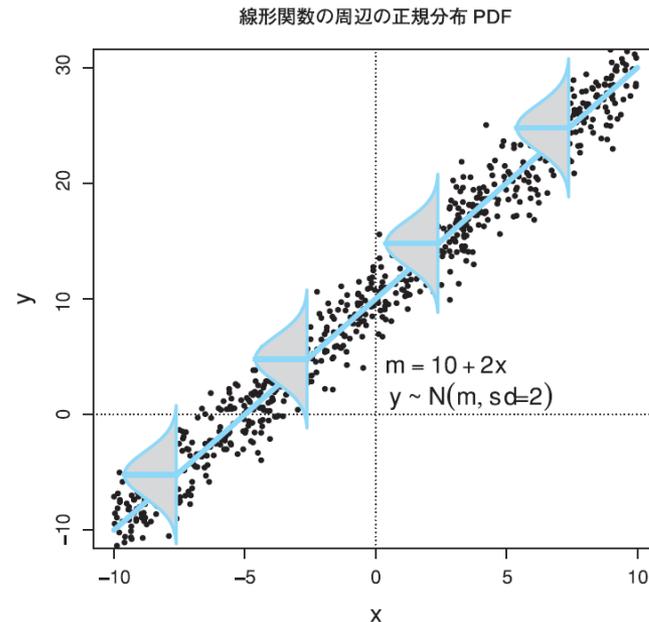
e.g., 回帰分析の表現

$$\mu = \beta_0 + \beta_1 x$$

$$y \sim \text{normal}(\mu, \sigma)$$

↑

y が正規分布に従って発生すると考える



GLMの形式的表現 (p. 452)

$$\mu = f(\text{lin}(x), [\text{パラメタ}])$$

✓ 中心傾向 (μ) を x の線形結合で表現

$$y \sim \text{pdf}(\mu, [\text{パラメタ}])$$

✓ μ 周辺に y が「ある分布」に従って発生

表15.2

被予測変数 y スケールタイプ	典型的なノイズ分布 $y \sim \text{pdf}(\mu, [\text{パラメータ}])$	典型的逆リンク関数 $\mu = f(\text{lin}(x), [\text{パラメータ}])$
量的	$y \sim \text{normal}(\mu, \sigma)$	$\mu = \text{lin}(x)$
2値	$y \sim \text{bernoulli}(\mu)$	$\mu = \text{logistic}(\text{lin}(x))$
名義	$y \sim \text{categorical}(\dots, \mu_k, \dots)$	$\mu_k = \frac{\exp(\text{lin}_k(x))}{\sum_c \exp(\text{lin}_c(x))}$
順序	$y \sim \text{categorical}(\dots, \mu_k, \dots)$	$\mu_k = \Phi((\theta_k - \text{lin}(x)) / \sigma) - \Phi((\theta_{k-1} - \text{lin}(x)) / \sigma)$
カウント	$y \sim \text{poisson}(\mu)$	$\mu = \exp(\text{lin}(x))$

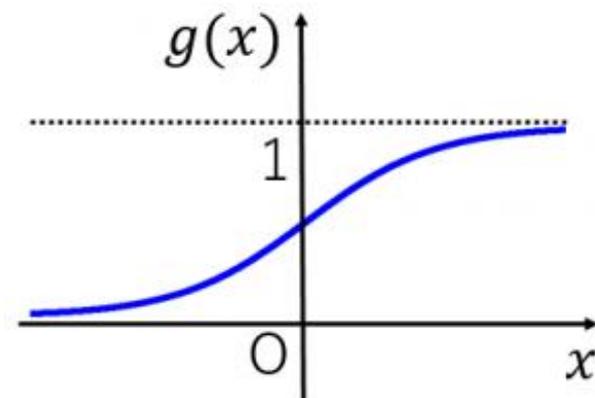
値 μ は予測されたデータの中心傾向（平均である必要はない）。予測変数は x ， $\text{lin}(x)$ は表 15.1 で示されているような x の線形関数。

* pdf: 確率密度関数(*probability density function*)

(例) ロジスティック回帰の場合

被予測変数 y スケールタイプ	典型的なノイズ分布 $y \sim \text{pdf}(\mu, [\text{パラメータ}])$	典型的逆リンク関数 $\mu = f(\text{lin}(x), [\text{パラメータ}])$
2 値	$y \sim \text{bernoulli}(\mu)$	$\mu = \text{logistic}(\text{lin}(x))$

$$\text{logistic}(x) = \frac{1}{1 + \exp(-x)}$$



<https://mathwords.net/logitkansu>

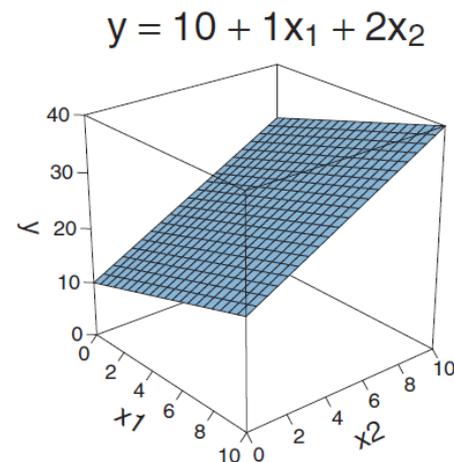
```
model{
  //モデルの記述
  real mu[N];
  for(n in 1:N){
    mu[n] = inv_logit(beta0+beta1*x[n]);
    y[n] ~ bernoulli(mu[n]);
  }
  //事前分布の設定
  beta0 ~ normal(0, 100);
  beta1 ~ normal(0, 100);
}
```

線形関数の作り方

複数の x を考えたい場合：とりあえず加法結合

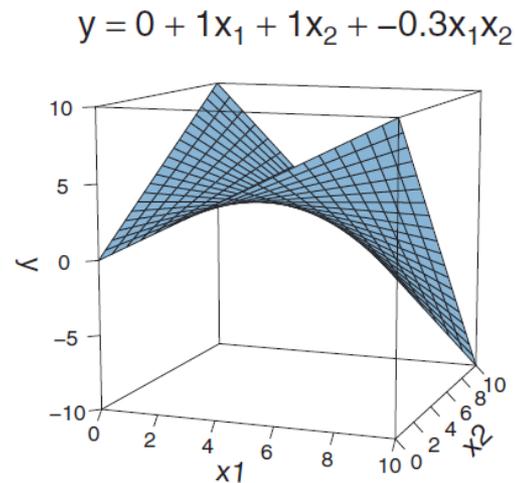
$$y = \beta_0 + \beta_1 x_1 + \cdots + \beta_k x_k$$

$$= \beta_0 + \sum_k \beta_k x_k$$



交互作用を考えたい場合：掛け算の項をたす

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_{12} x_1 x_2$$



線形関数の作り方

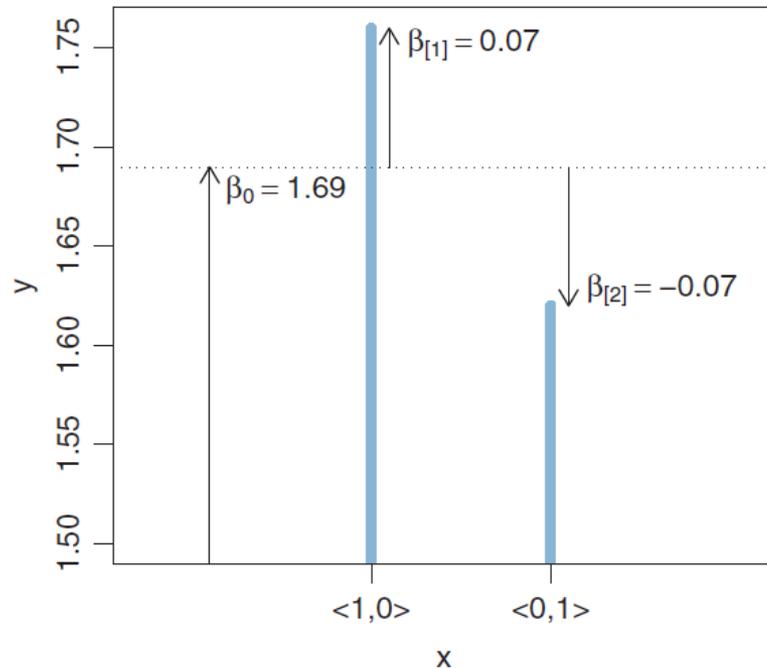
予測変数が名義変数の場合: 各水準の効果を考えてよい

x が水準1の場合の
 y の変化量
↓

$$y = \beta_0 + \beta_{[1]}x_{[1]} + \cdots + \beta_{[J]}x_{[J]}$$
$$= \beta_0 + \vec{\beta} \cdot \vec{x}$$

制約→ $\sum_{j=1}^J \beta_{[j]} = 0$

$$y = 1.69 + \langle 0.07, -0.07 \rangle \cdot \vec{x}$$



予測変数の種類に応じた線形関数

表15.1

予測変数 x のスケールタイプ					
		量的		名義的	
単一の 群	2つの 群	単一の 予測変数	複数の 予測変数	単一の 因子	複数の 因子
β_0	$\beta_{x=1}$ $\beta_{x=2}$	β_0 $+\beta_1x$	β_0 $+\sum_k \beta_k x_k$ $+\sum_{j,k} \beta_{j \times k} x_j x_k$ $+\left[\begin{array}{l} \text{より高次の} \\ \text{交互作用} \end{array} \right]$	β_0 $+\vec{\beta} \cdot \vec{x}$	β_0 $+\sum_k \vec{\beta}_k \cdot \vec{x}_k$ $+\sum_{j,k} \vec{\beta}_{j \times k} \cdot \vec{x}_{j \times k}$ $+\left[\begin{array}{l} \text{より高次の} \\ \text{交互作用} \end{array} \right]$

本書で対応している章

予測変数 x のスケールタイプ

被予測変数 y の スケールタイプ	量的		名義		
	単一の 群	2つの 群	単一の 予測変数	複数の 予測変数	単一の 因子
量的 2値 名義 順序 カウント	第16章 第6章～第9章	第17章	第18章 第21章	第19章 第22章 第23章 第24章	第20章

**ベイズ統計
モデリング**
R, JAGS, Stanによるチュートリアル
原著第2版

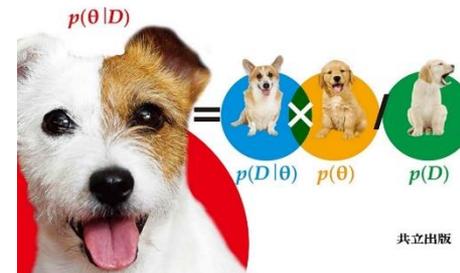
著
John K. Kruschke

訳
前田和寛 小杉孝司

Doing Bayesian Data Analysis
A Tutorial with R, JAGS, and Stan
2nd ed.

訳
前田和寛 小杉孝司 井筒隆太
許上智博 菊田健作 久々原
藤里俊彦 坂本文部 船取雄太
高田真美 竹林由武 徳岡 大
藤原裕史 西田啓貴 守川 眞
有馬いずみ 武藤百里 山根寛史
横山仁史

今すぐ欲しい！



Enjoy!

ベイズ統計モデリング

R, JAGS, Stanによるチュートリアル

原著第2版

著
John K. Kruschke

監訳
前田和寛 小杉考司

訳
前田和寛 小杉考司 井岡龍太
井上和哉 鬼田崇作 紀ノ定保礼
国屋慶彦 坂本次郎 袖取康太
高田菜美 竹林由武 徳岡 大
難波修史 西田若葉 平川 真
福屋いずみ 武藤杏里 山根嵩史
横山仁史

Doing Bayesian Data Analysis

A Tutorial with R, JAGS, and Stan
2nd ed.

