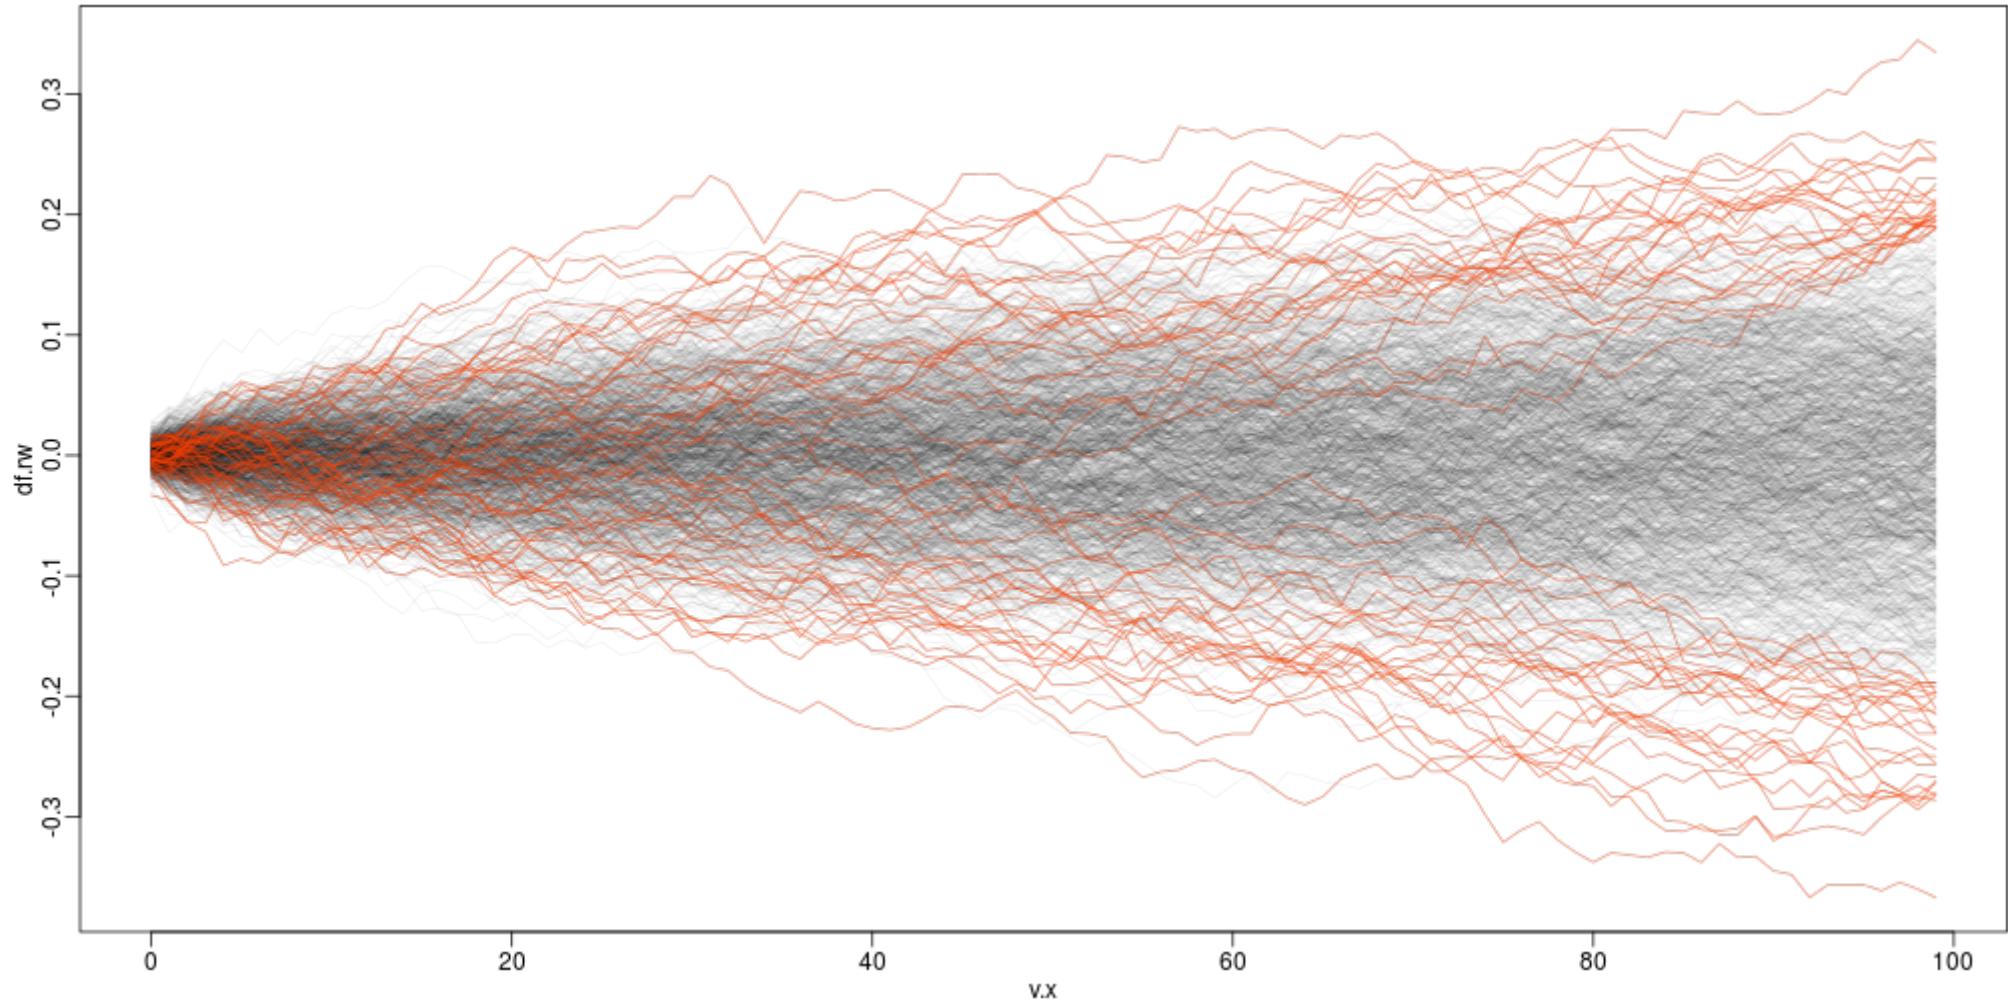


階層ベイズモデル - 時間変化の統計モデリング

久保拓弥

<mailto:kubo@ees.hokudai.ac.jp>



今回・次回の要点

「あぶない」時系列データ解析は

やめましょう！

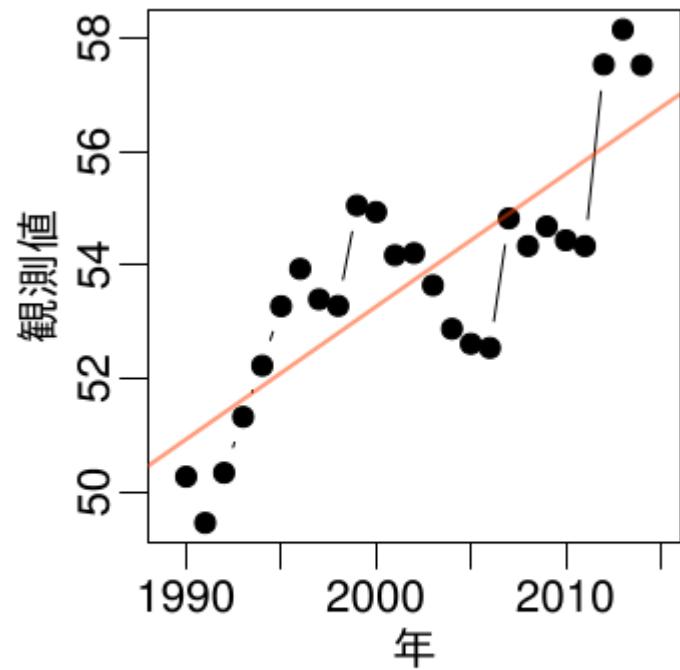
統計モデル
のあてはめ

(危1) 時系列データの GLM あてはめ

(危2) 時系列 $Y_t \sim$ 時系列 X_t

各時刻の個体数 ~ 気温 とか
(これは次回)

(危 1) 時系列データを GLM で



「ゆ一いな傾き」を
ねつぞうする原因

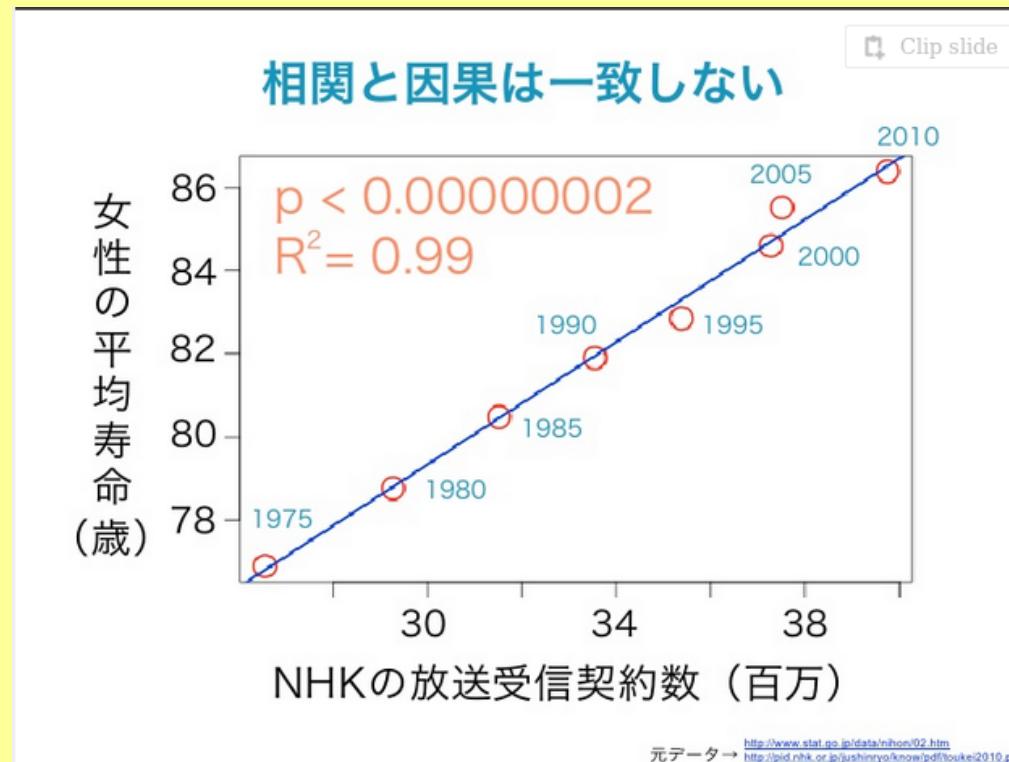
傾きの検定やめて
AIC モデル選択
しても同様になる

検定とかモデル選択とかそういう問題ではない
統計モデルがおかしい?

(危 2) 時系列 Y_t ~ 時系列 X_t

「相関は因果関係ではない」

問題の一部：にせの回帰 (これは次回)

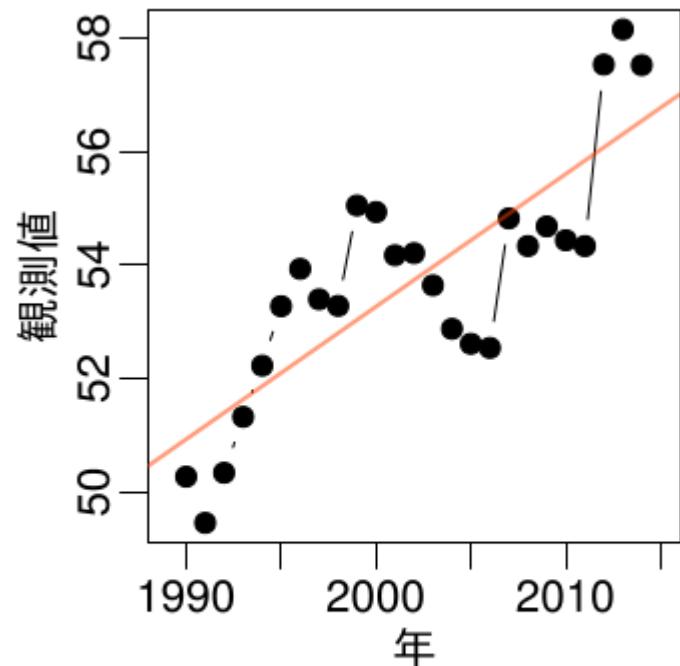


<http://www.slideshare.net/takehikohayashi/ss-13441401>

時系列データの統計モデリング

- ・ 安易に「回帰」してはいけない
- ・ ランダムウォークモデルが基本
- ・ 統計モデルが生成する時系列パターンを意識する
- ・ 階層ベイズモデルで推定
状態空間モデル

(危1) 時系列データを GLM で



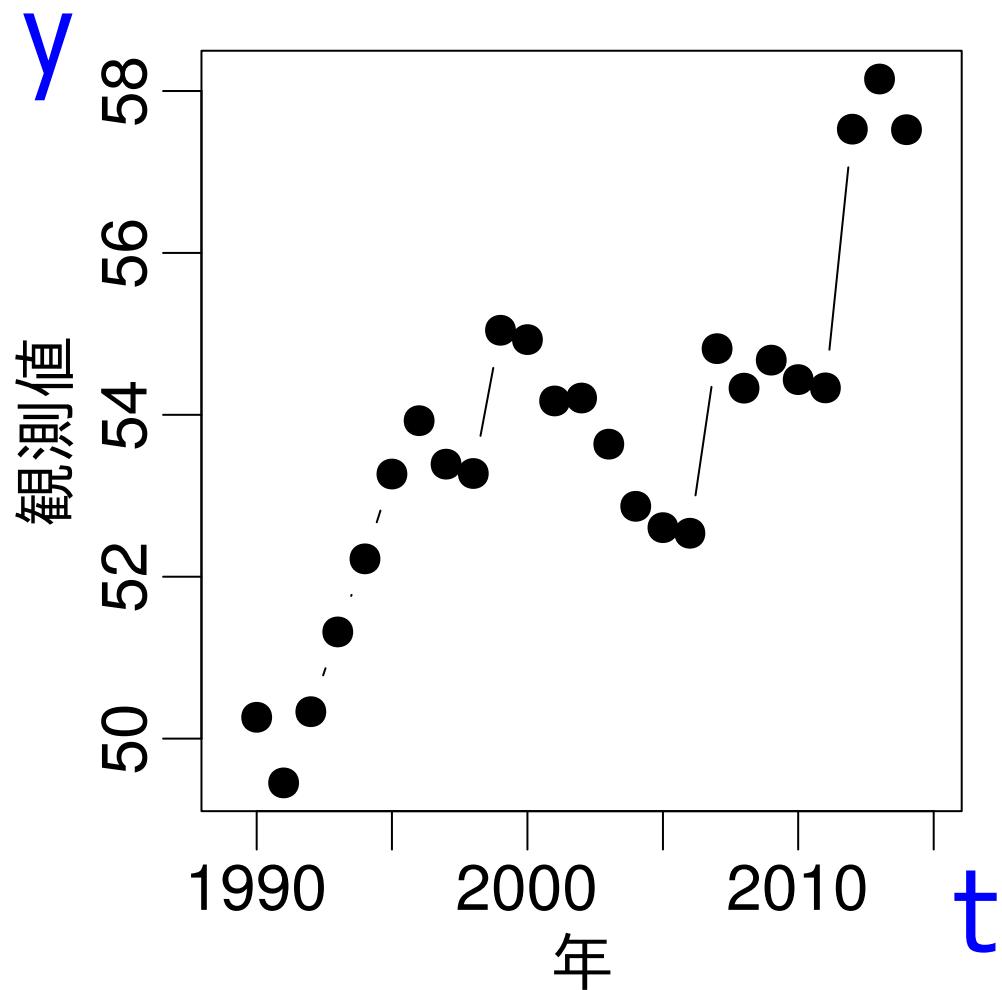
「ゆ一いな傾き」を
ねつぞうする原因

傾きの検定やめて
AIC モデル選択
しても同様になる

検定とかモデル選択とかそういう問題ではない

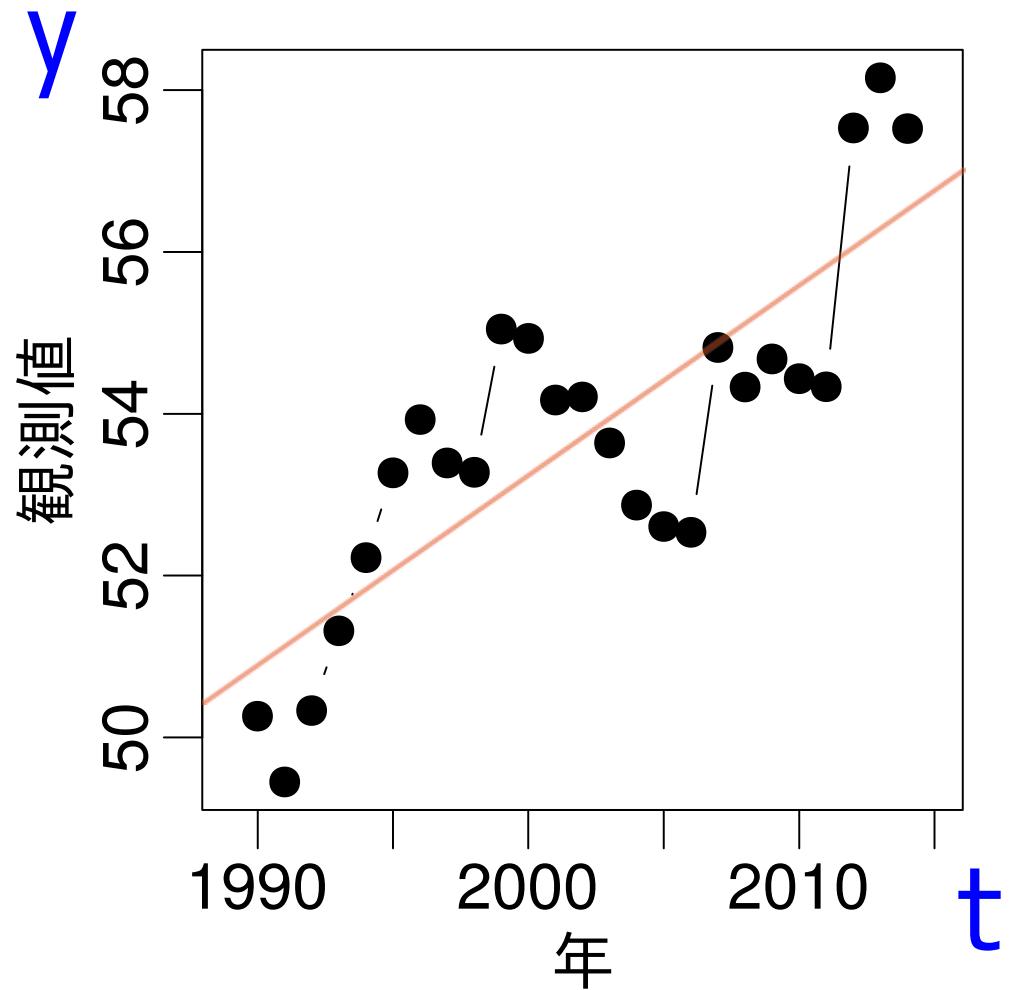
統計モデルがおかしい?

このような時系列データがあったとしましょう



y は何か連續値と
しましよう
(今日でてくる y は
連續値ばかり、と
いうことで)

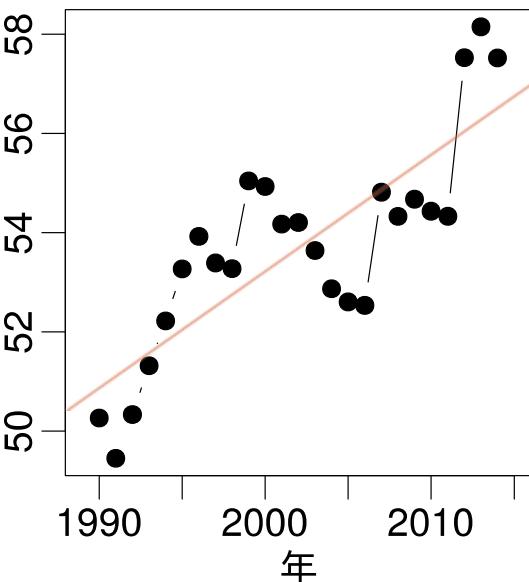
時系列データの統計モデリング入門



`glm(y ~ t)`

…とモデル
をあてはめてみた

「やったーゆーいだ!!」??



```
> summary(glm(formula = y ~ t))
```

Deviance Residuals:

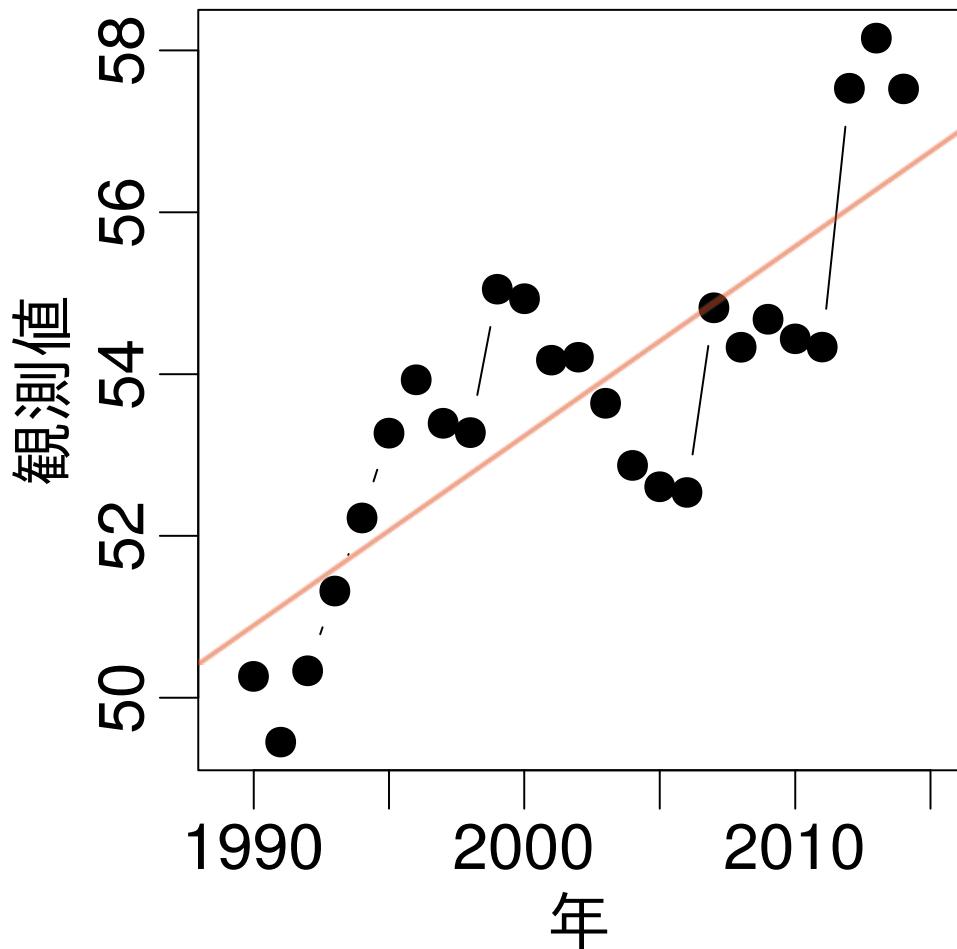
Min	1Q	Median	3Q	Max
-2.1295	-1.0583	-0.0817	0.9860	2.0188

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	-414.5655	71.4761	-5.80	6.6e-06
t	0.2339	0.0357	6.55	1.1e-06

これはまちがい → `glm(時系列Y ~ 時間 t)`

時系列の各点は独立ではない



「ゆ一いな傾き」(偽)

が「ぞろぞろ」でます

傾きの検定やめて

AIC モデル選択

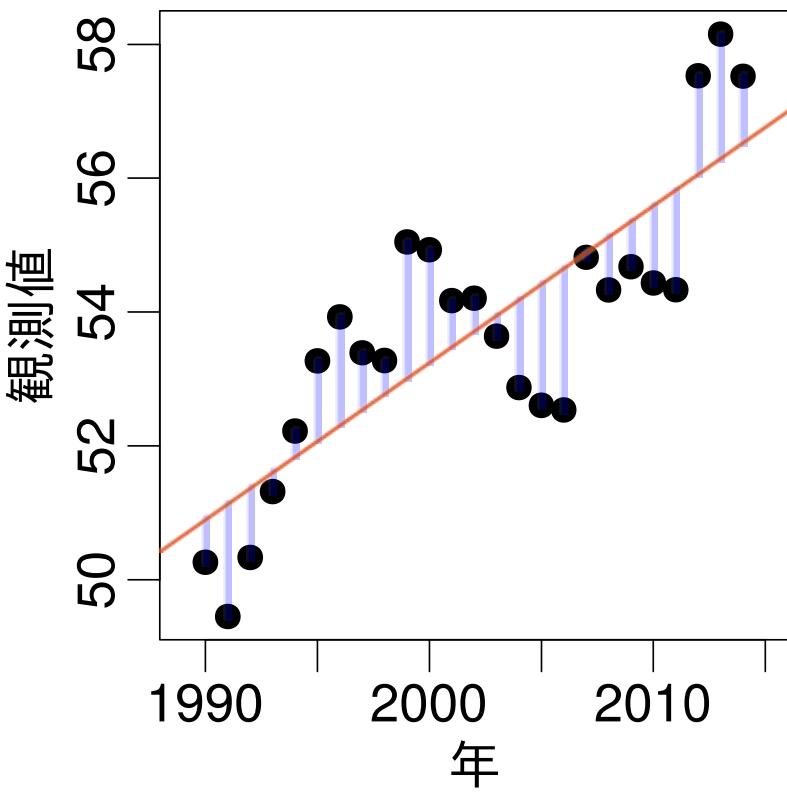
しても同様になる

検定とかモデル選択とかそういう問題ではない

統計モデルがおかしい?

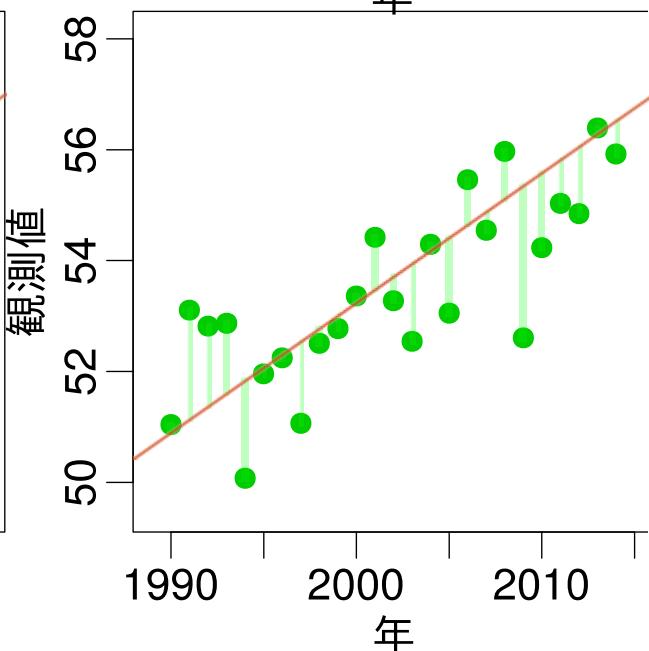
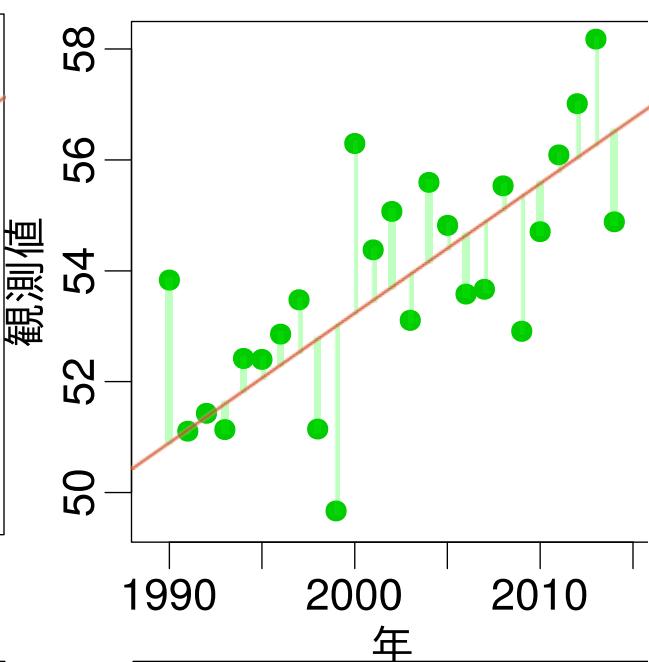
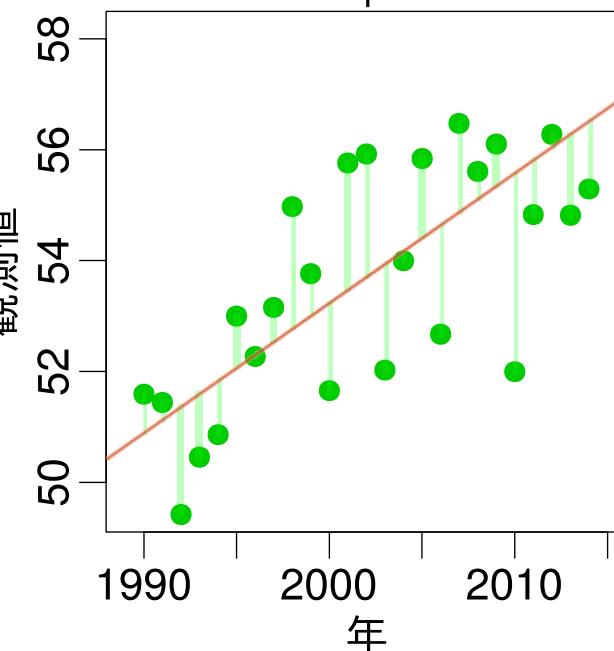
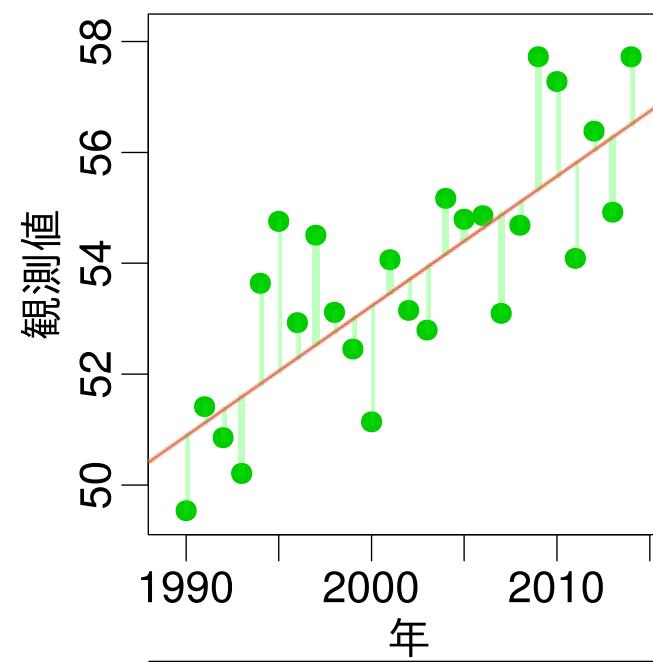
時系列の「ずれ」

GLM のずれ



ずれかたが
ちがってる?

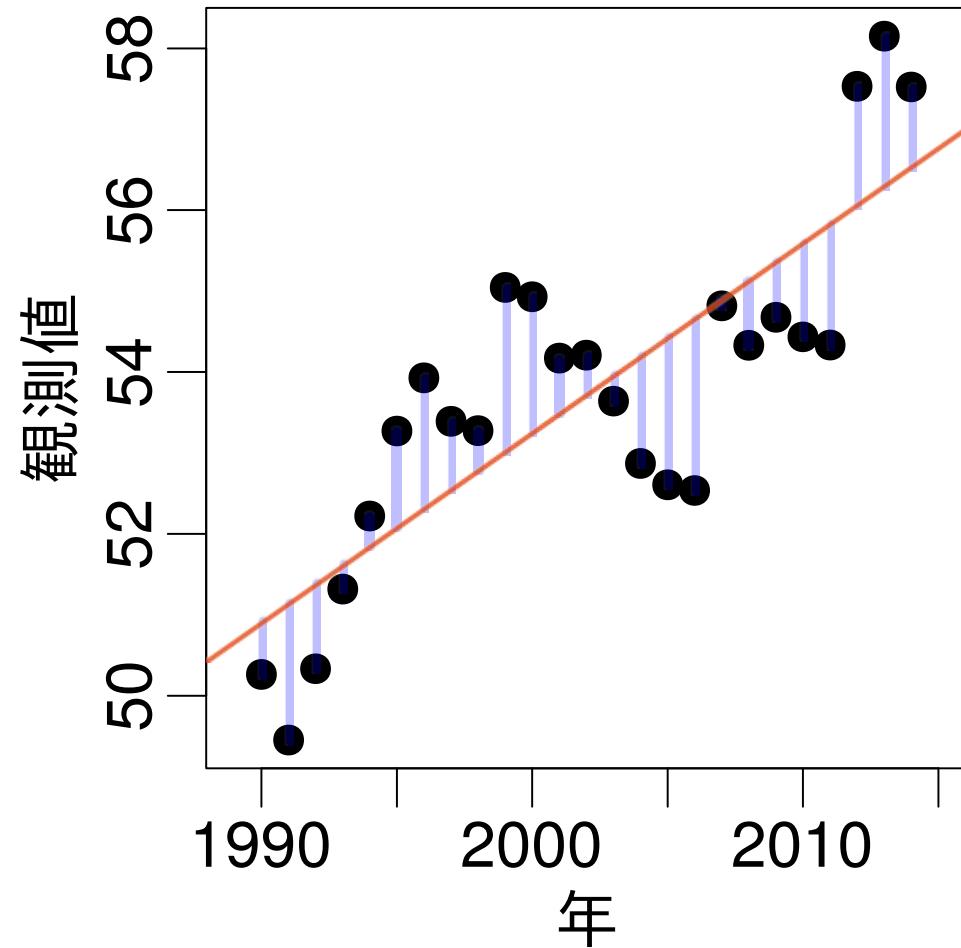
2016-11-17



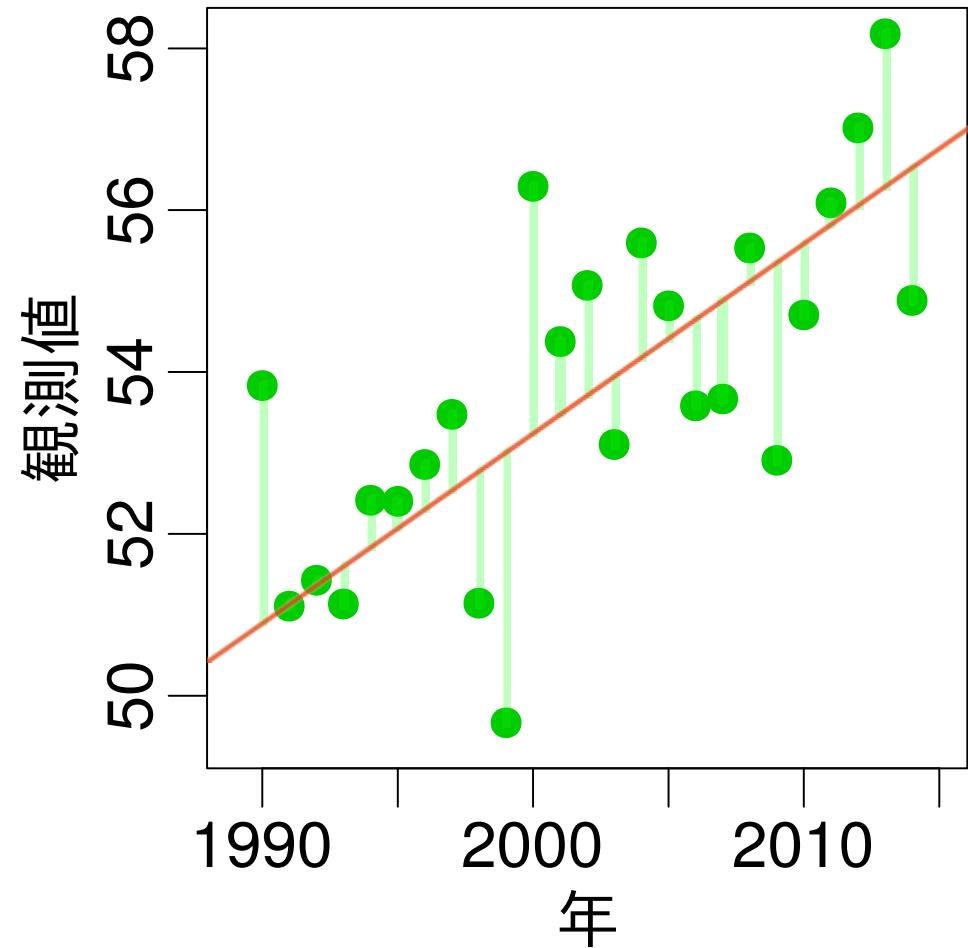
ngt2016f

11/80

時系列の「ずれ」



GLM のずれ



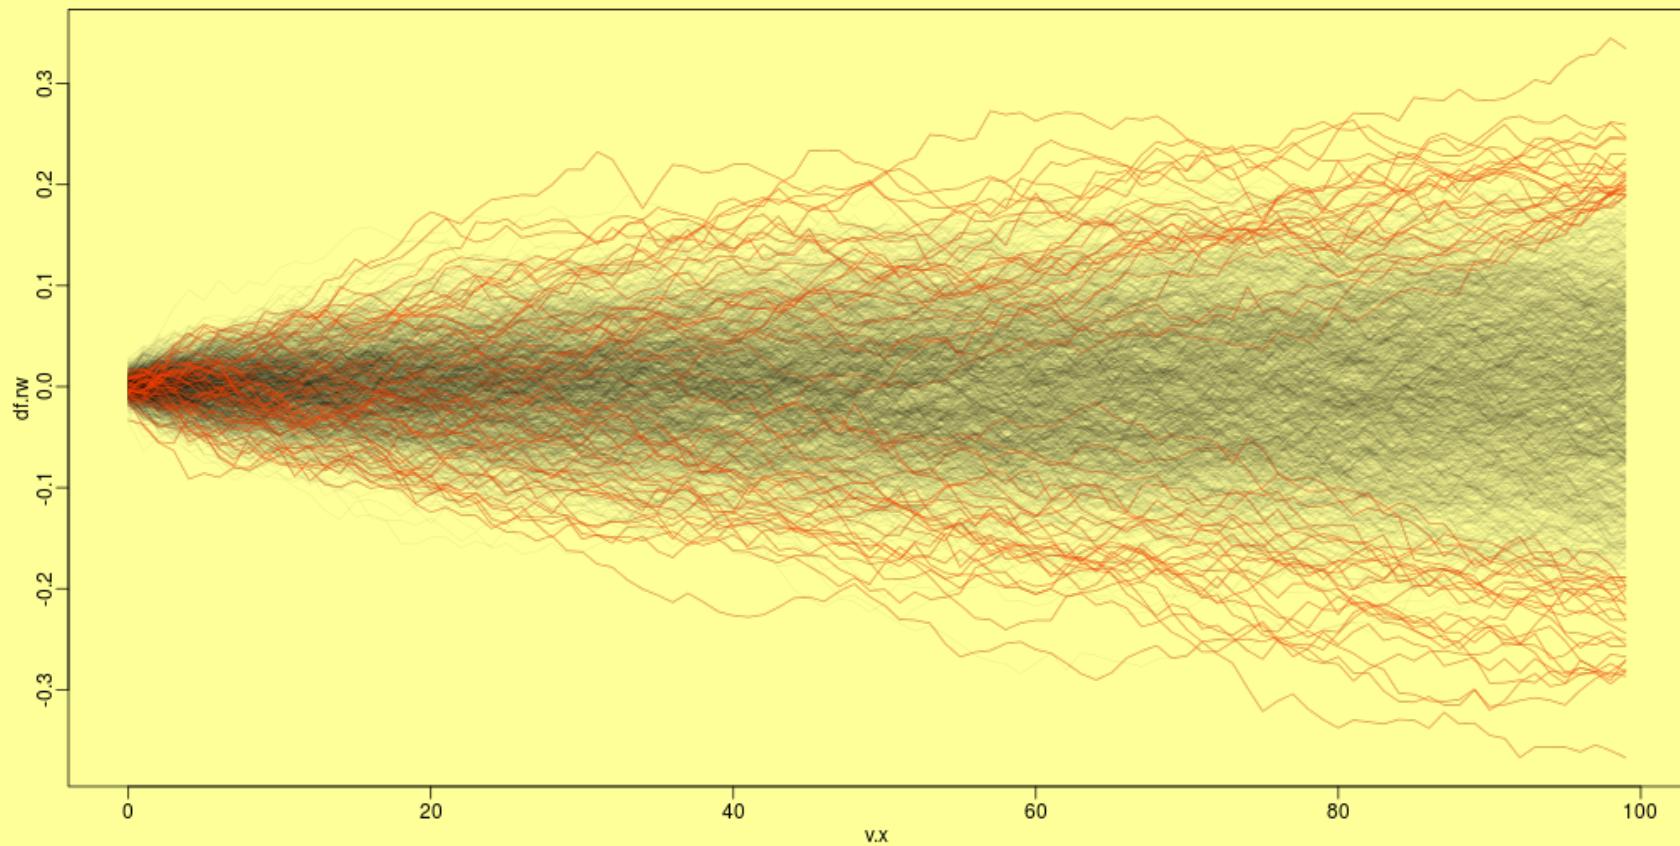
直線からのずれがちがう！

時間的自己相関がある

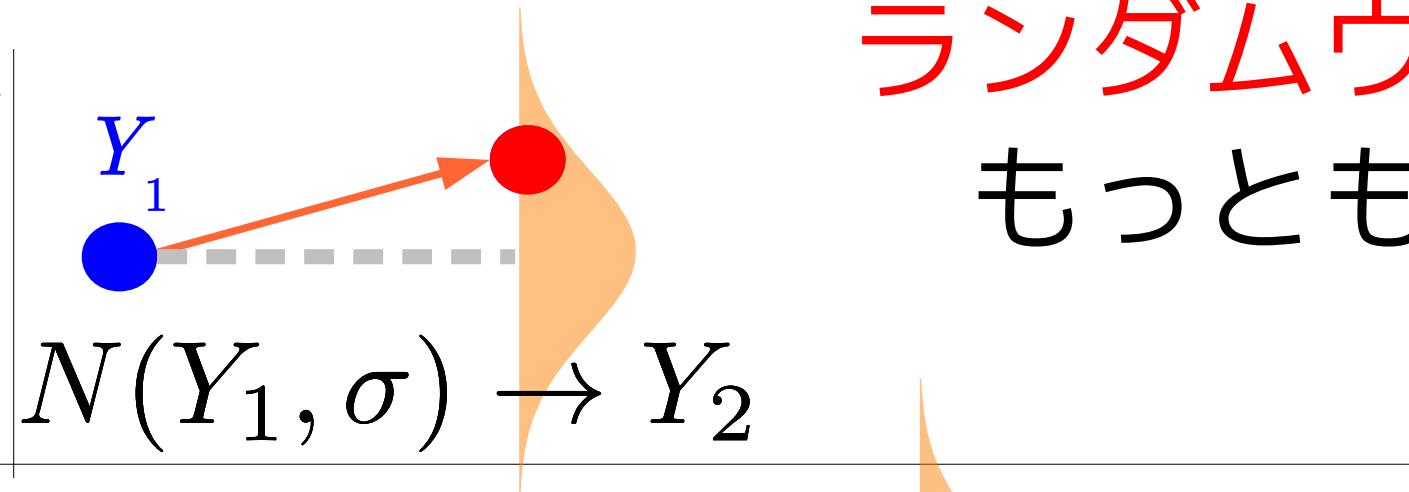
時間的自己相関がない

時系列の基本モデルのひとつ

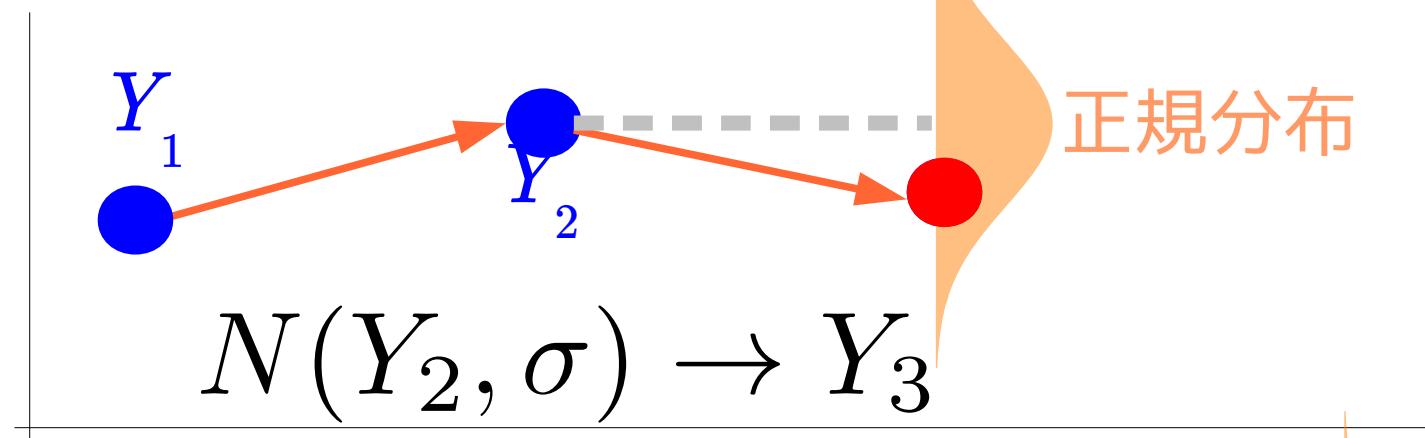
ランダムウォーク（乱歩）



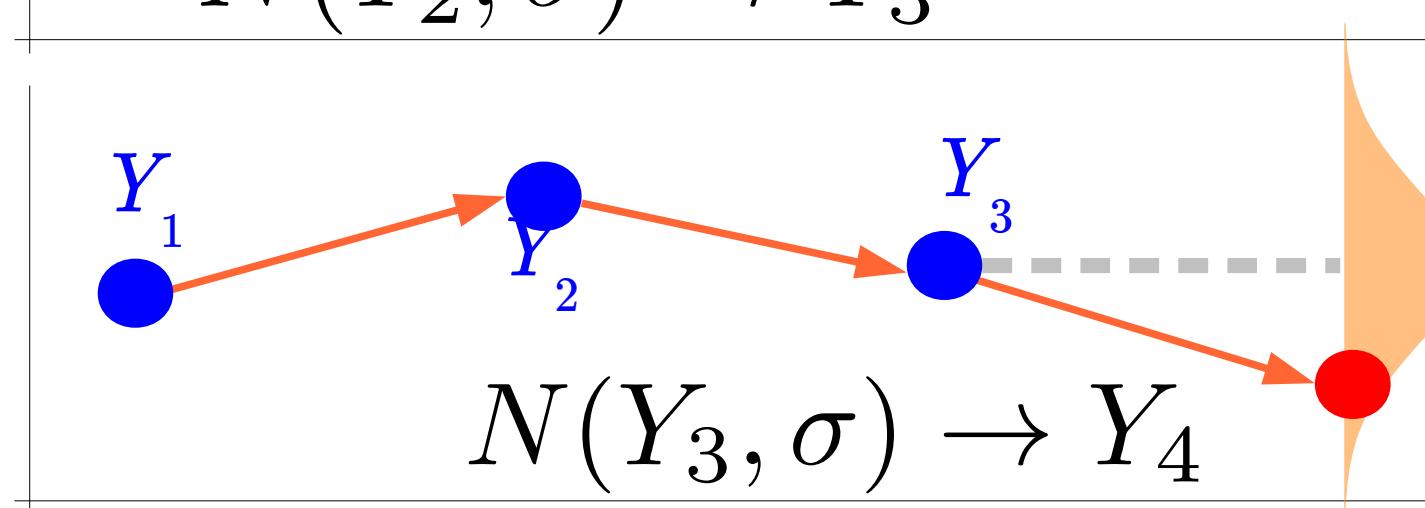
変数
 Y



ランダムウォーク
もっとも単純な
モデル



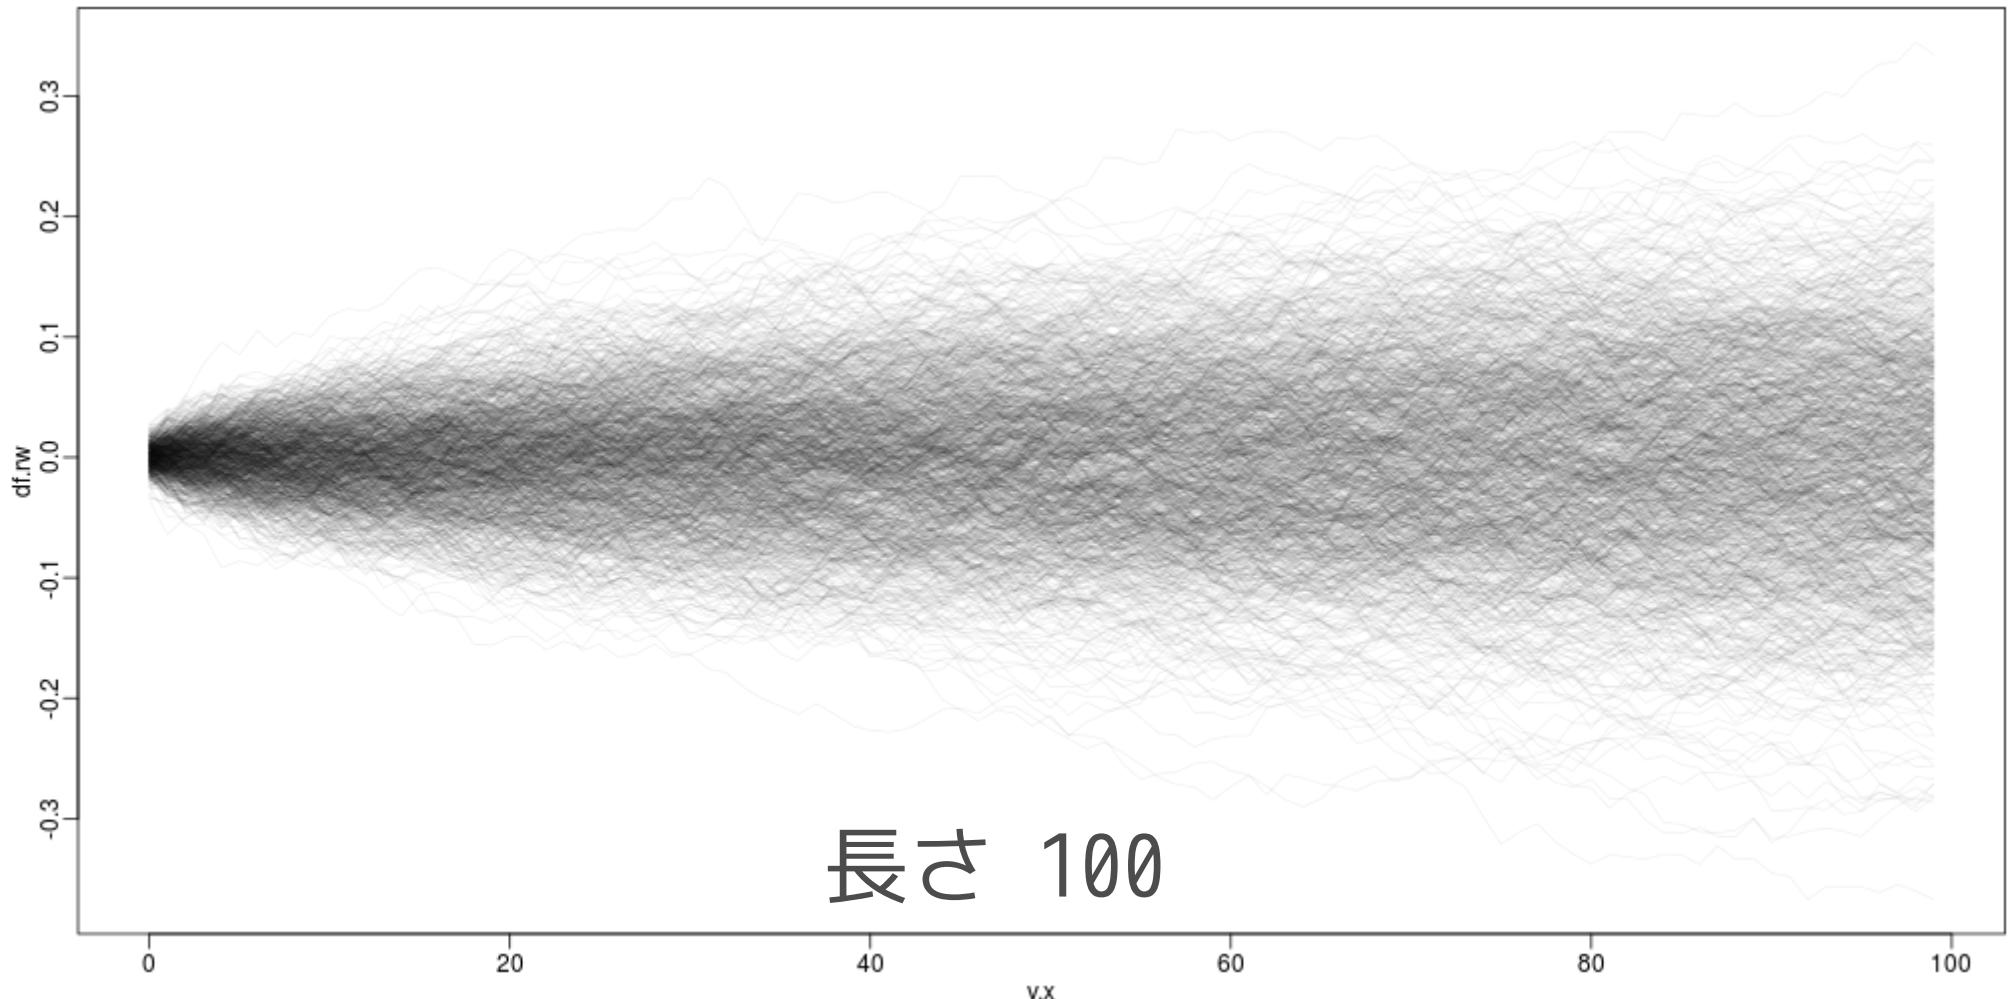
正規分布



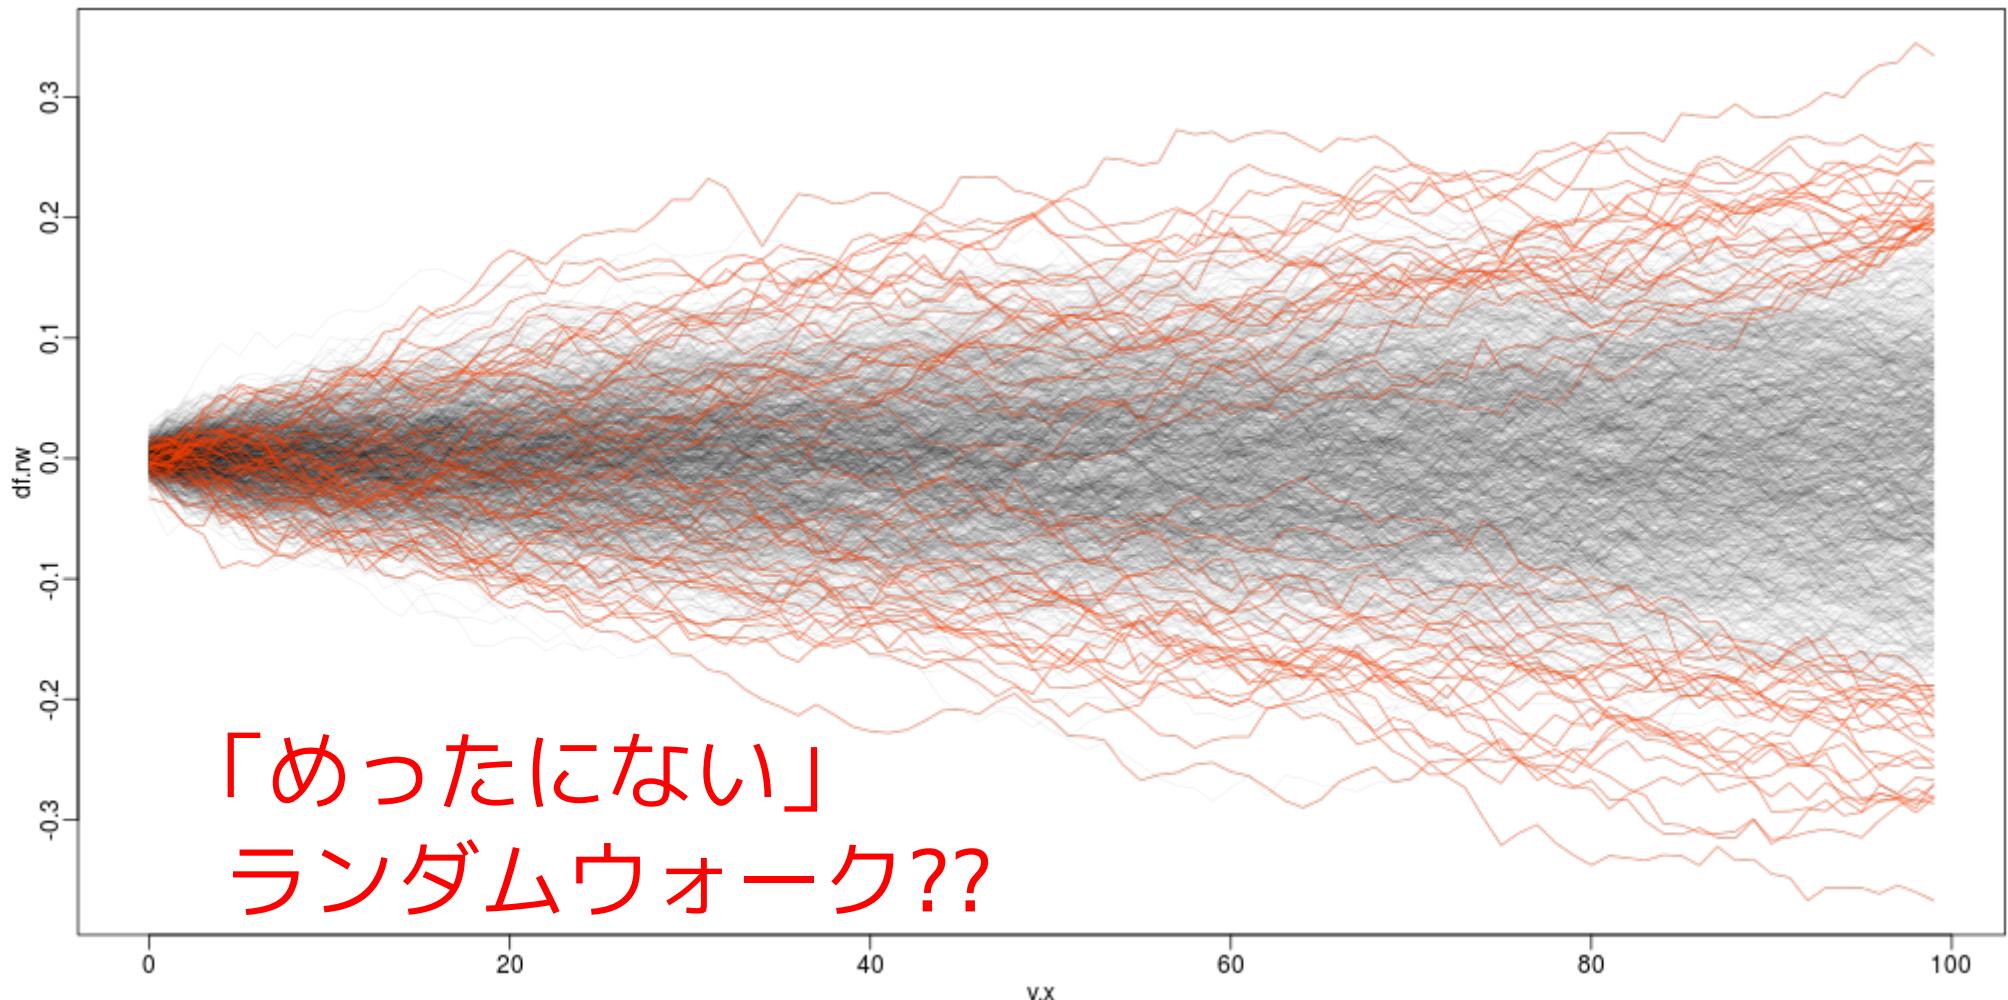
時間 t

ランダムウォークなサンプル時系列

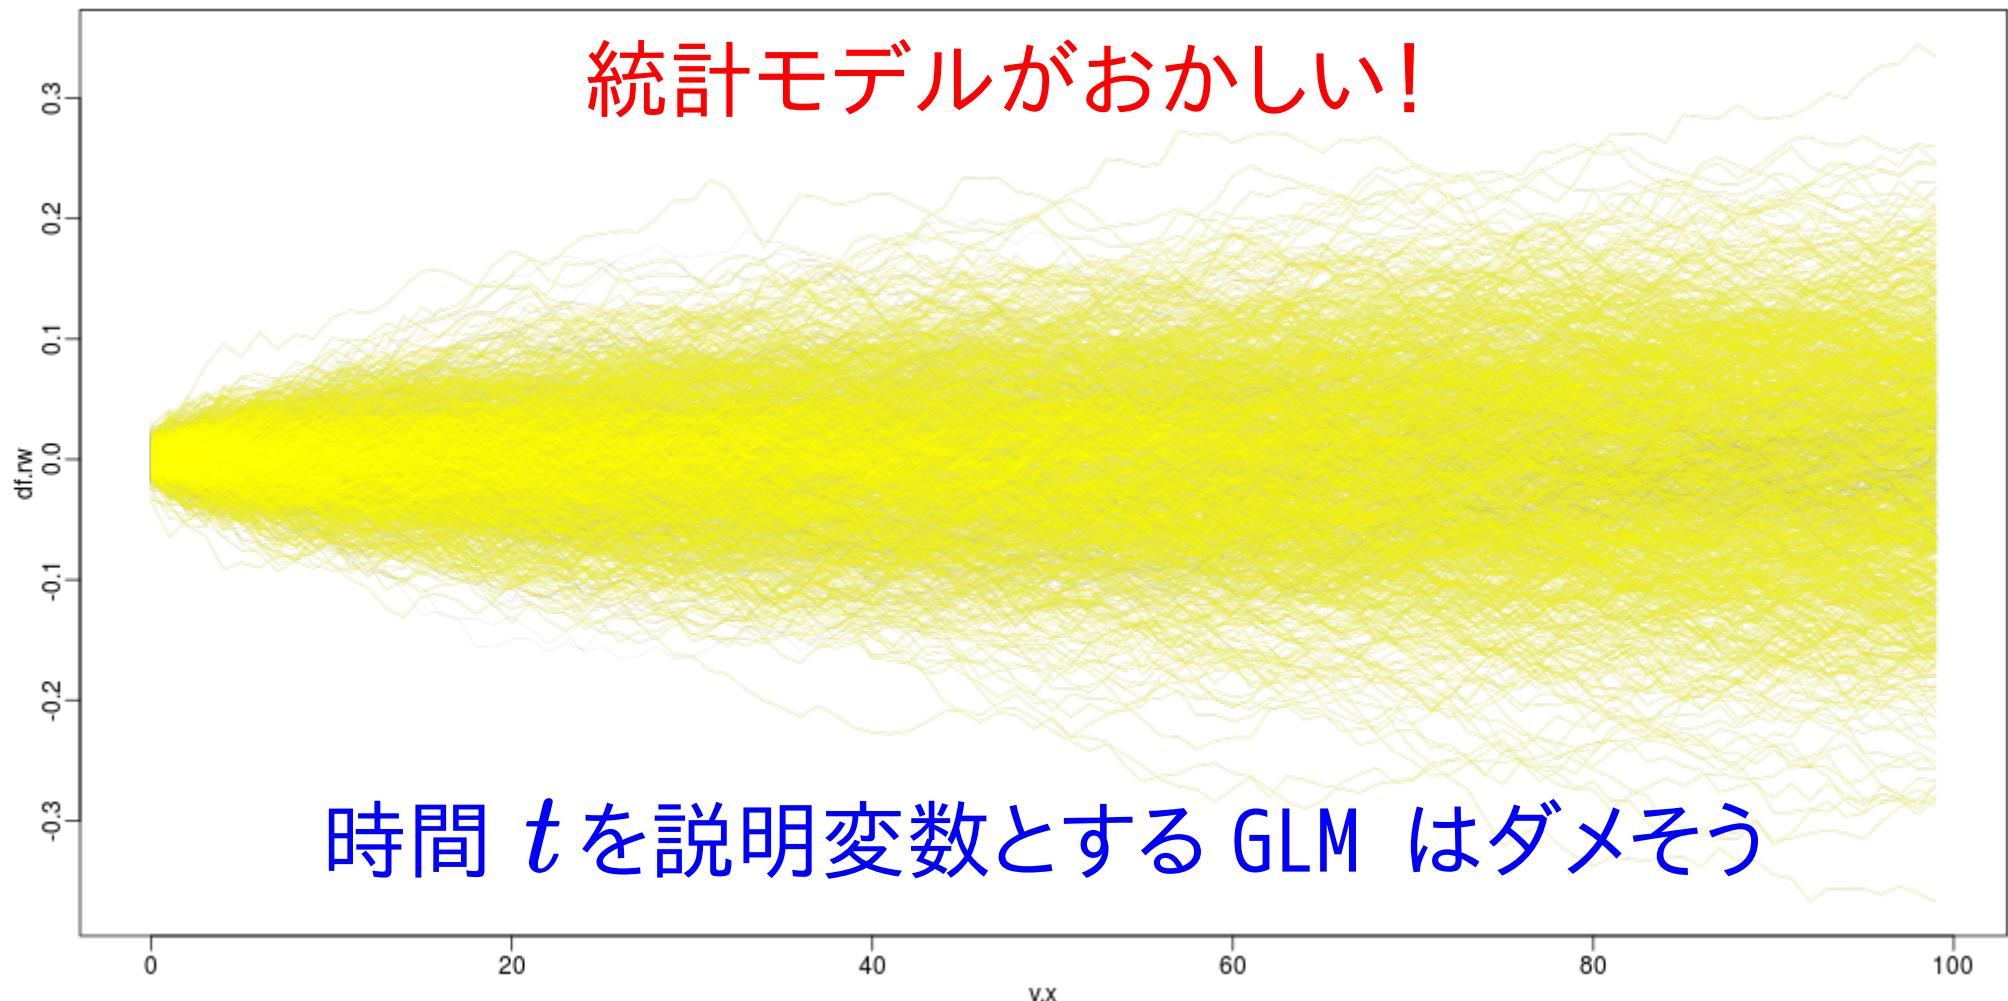
とりあえず 1000 本ほど生成してみました



例外的な時系列というのはある
たとえば $t = 100$ でかなり外れている 50 本



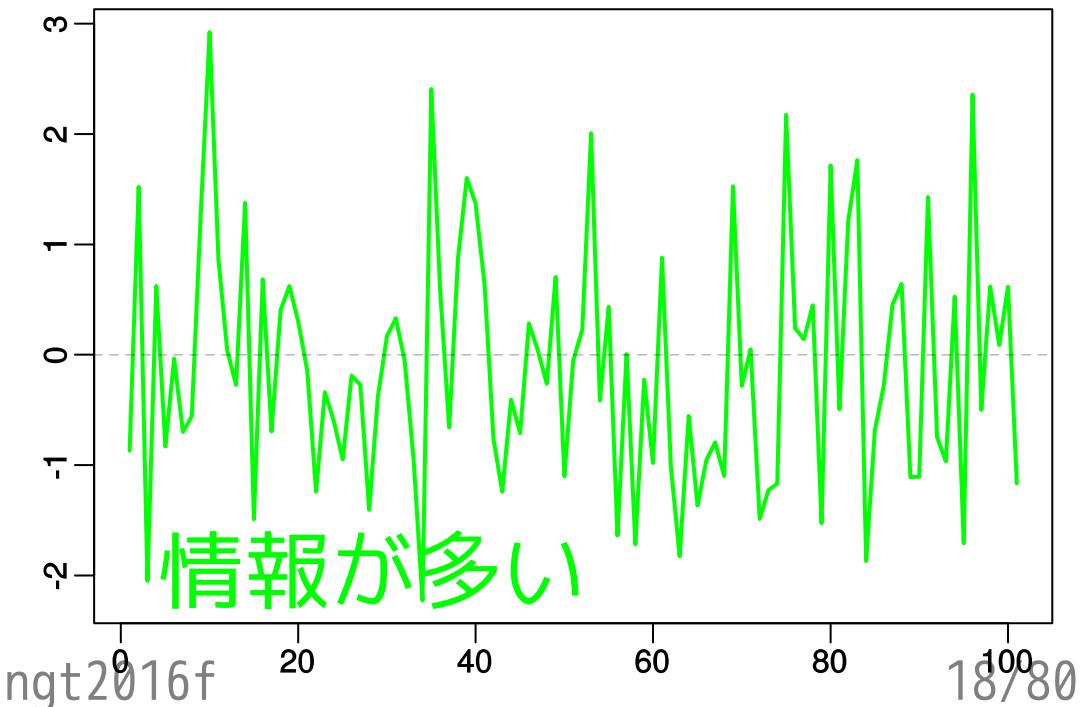
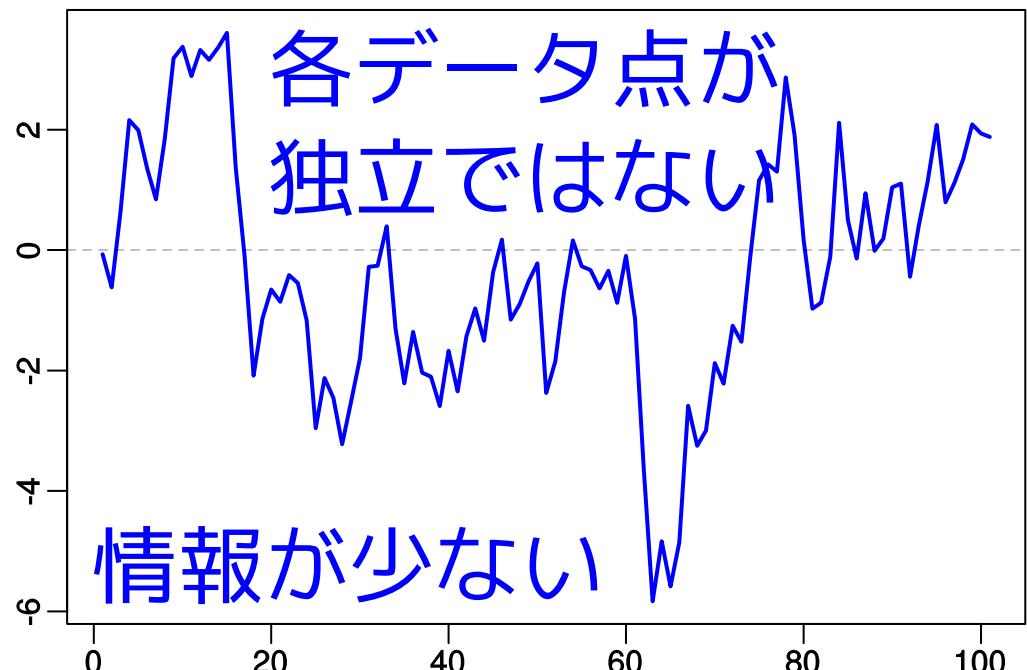
しかし直線回帰 GLM あてはめると… ほとんどすべての場合で「ゆーい」！



ちょっとでも傾いてたら「ゆーい」

実際には
こんなデータ
なのに

R の `glm()` は
こんなデータ
だとみなしている



時間的自己相関

(略称:自己相関, 時間相関)

を調べたらいいの?

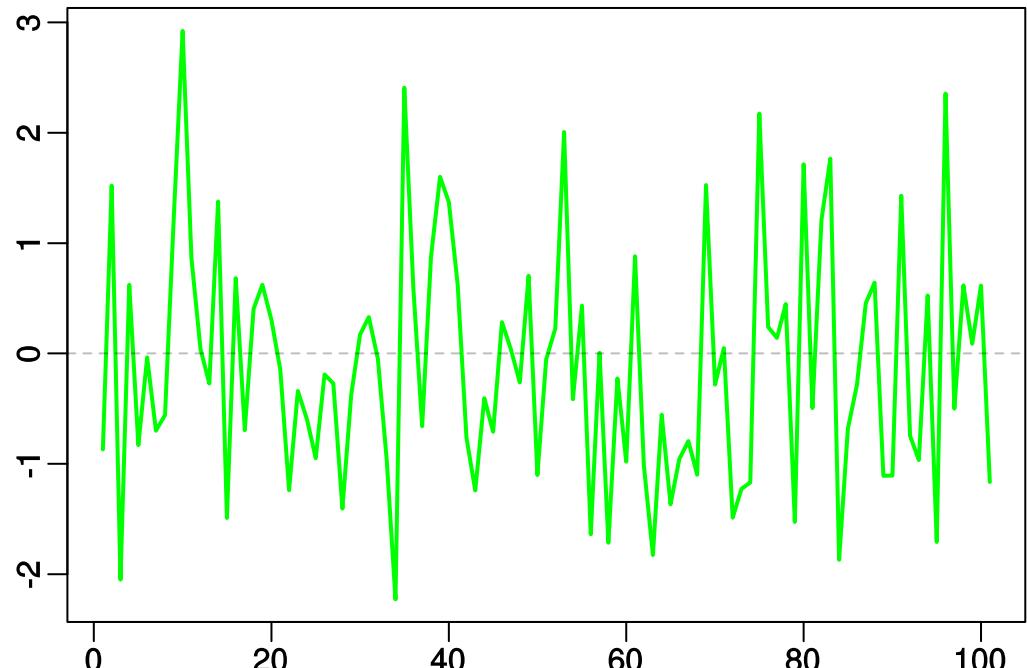
$$\rho_k = \frac{\text{Cov}(y_t, y_{t-k})}{\sqrt{\text{Var}(y_t) \cdot \text{Var}(y_{t-1})}}$$



R の ts クラス: 時系列をあつかう

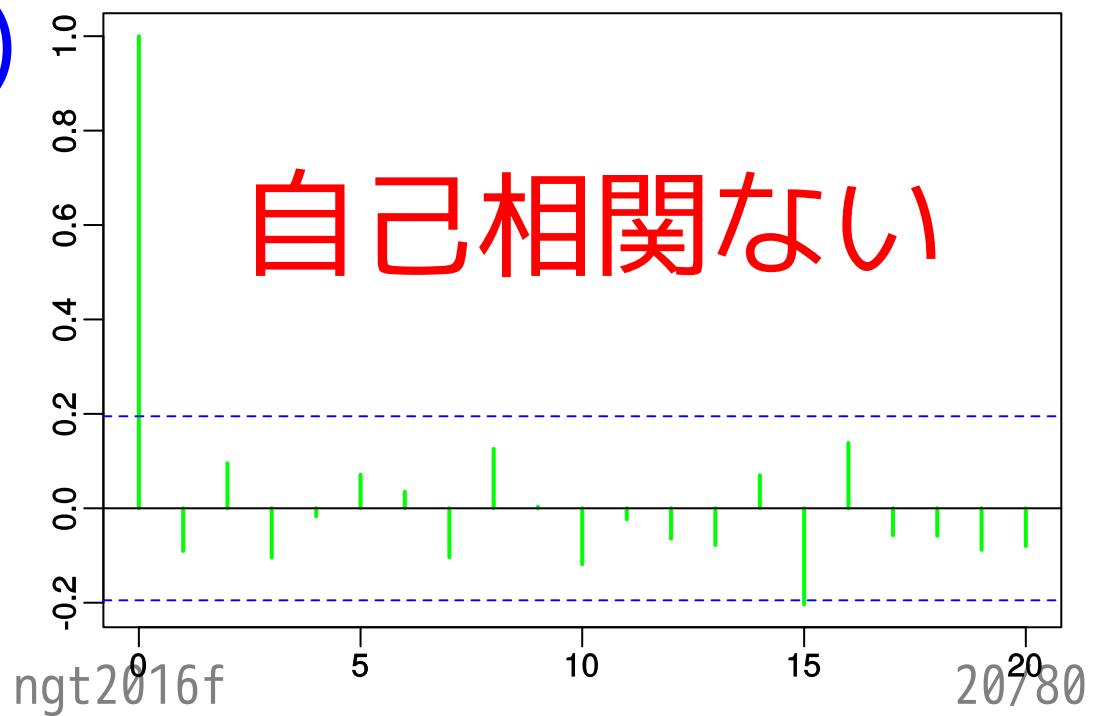
`plot(ts(Y))`

これはたんなる
100 個の正規乱数



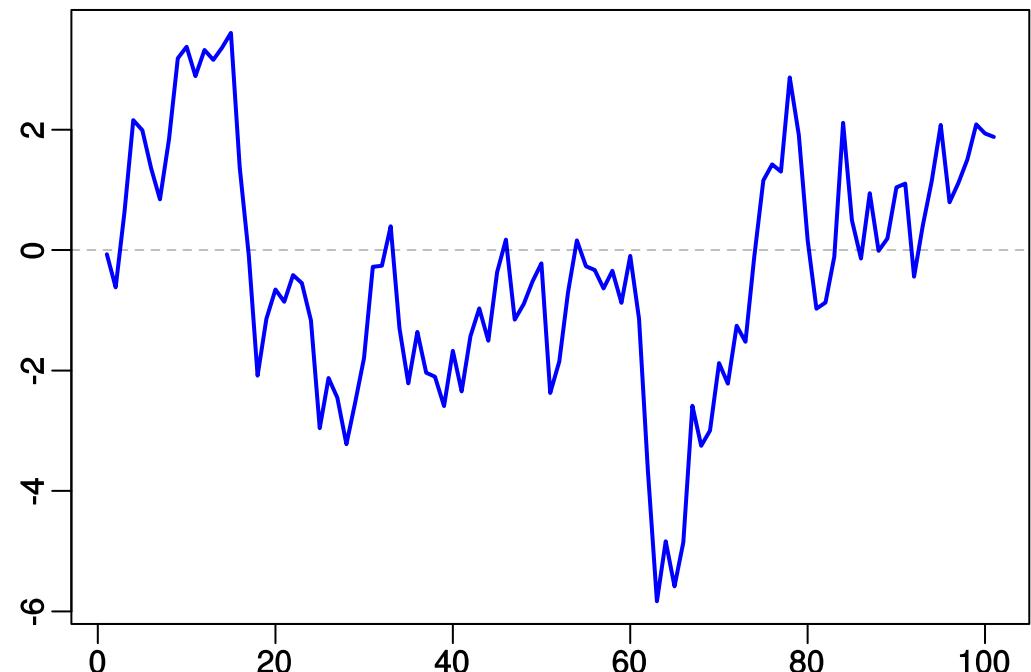
`plot(acf(ts(Y)))`

自己相関ない

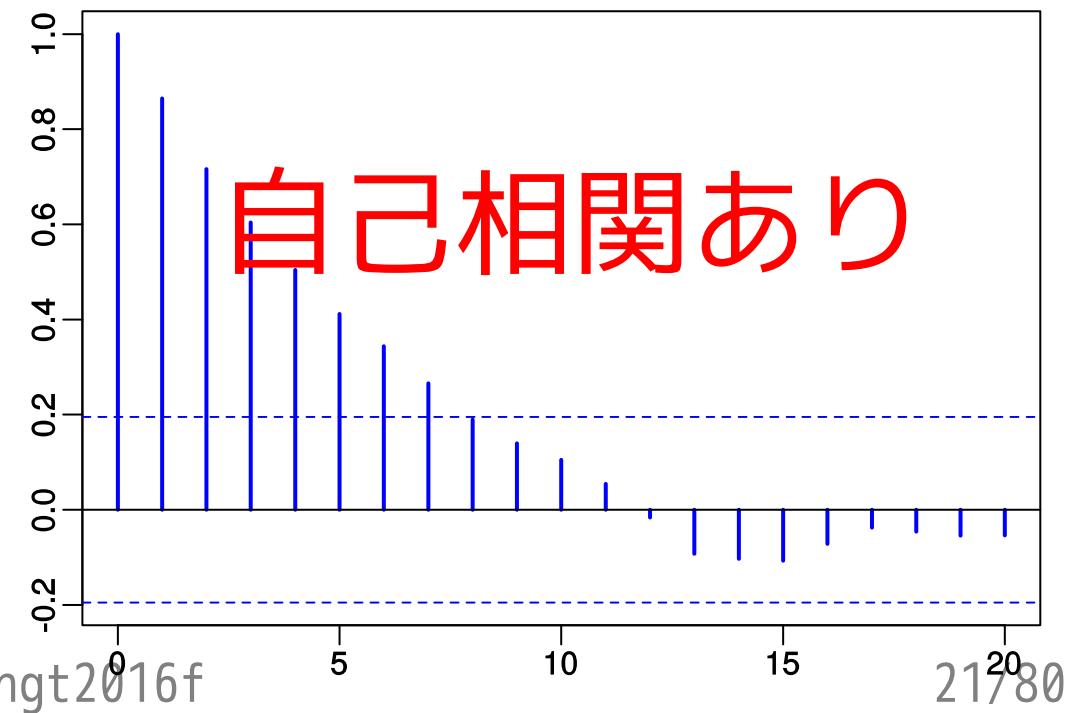


自己相関減衰の様子を図示

`plot(ts(Y))`

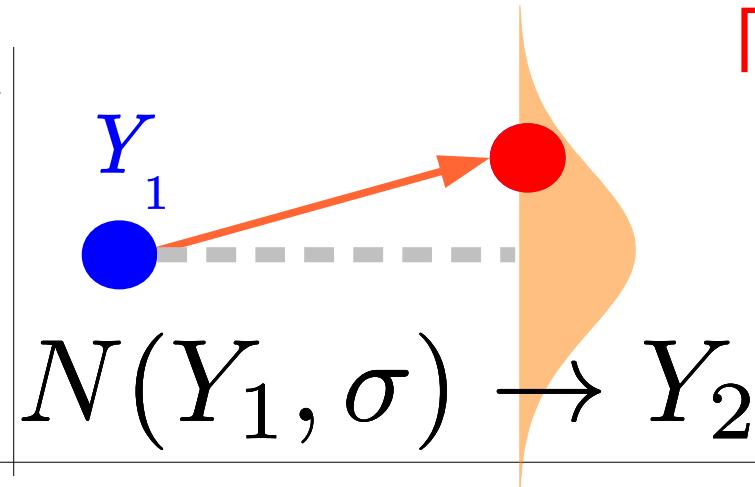


`plot(acf(ts(Y)))`

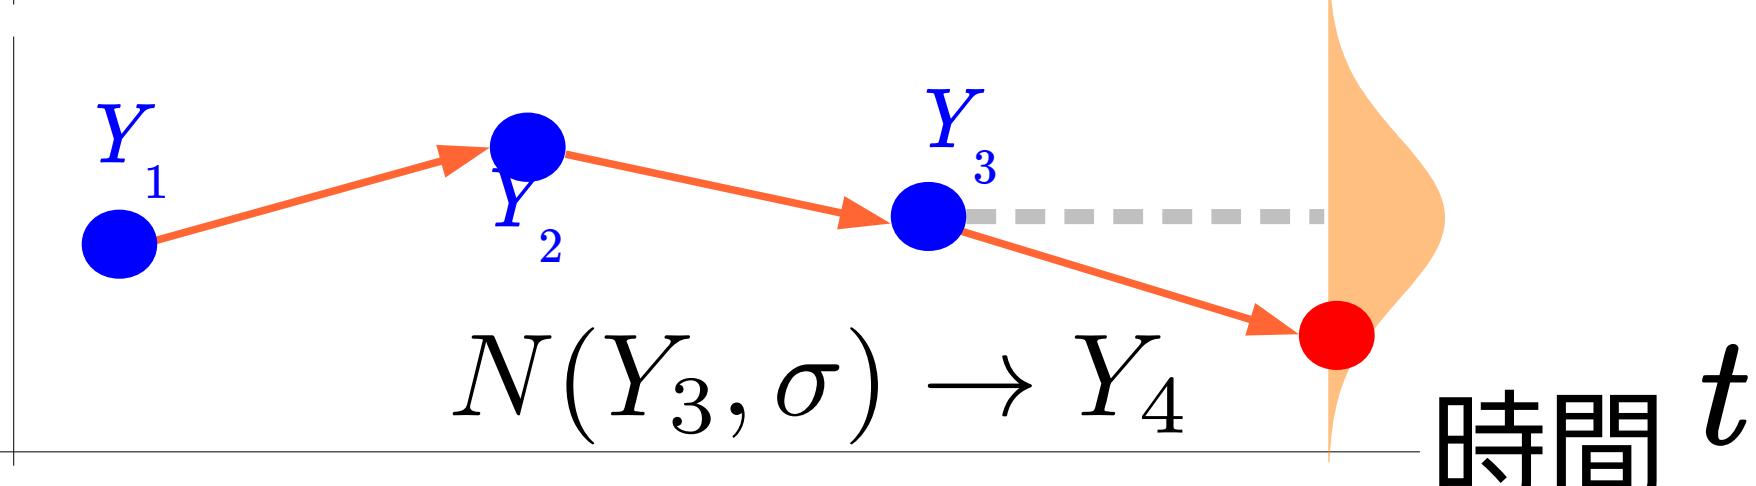
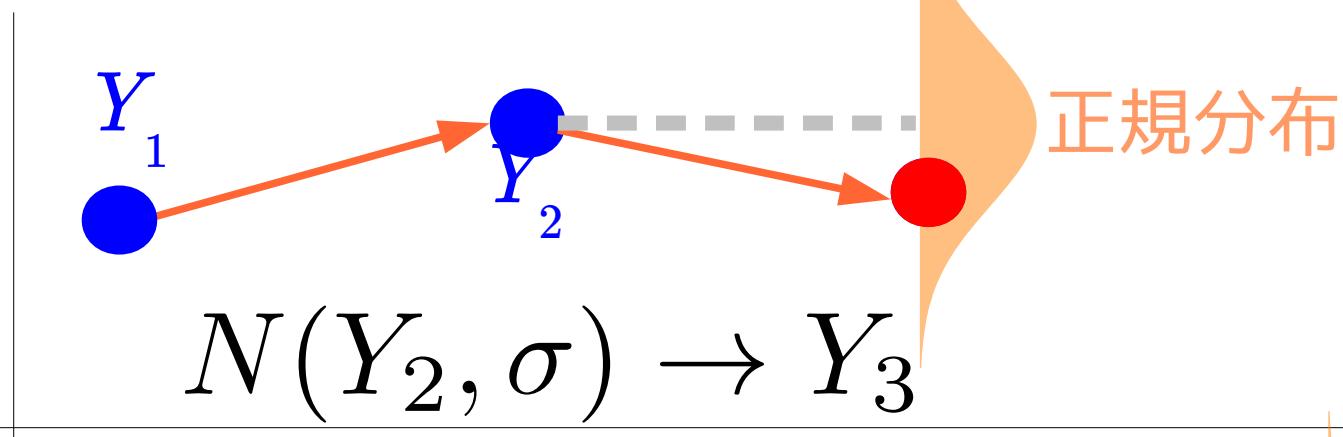


変数
 Y

「時間相関がある」とは?

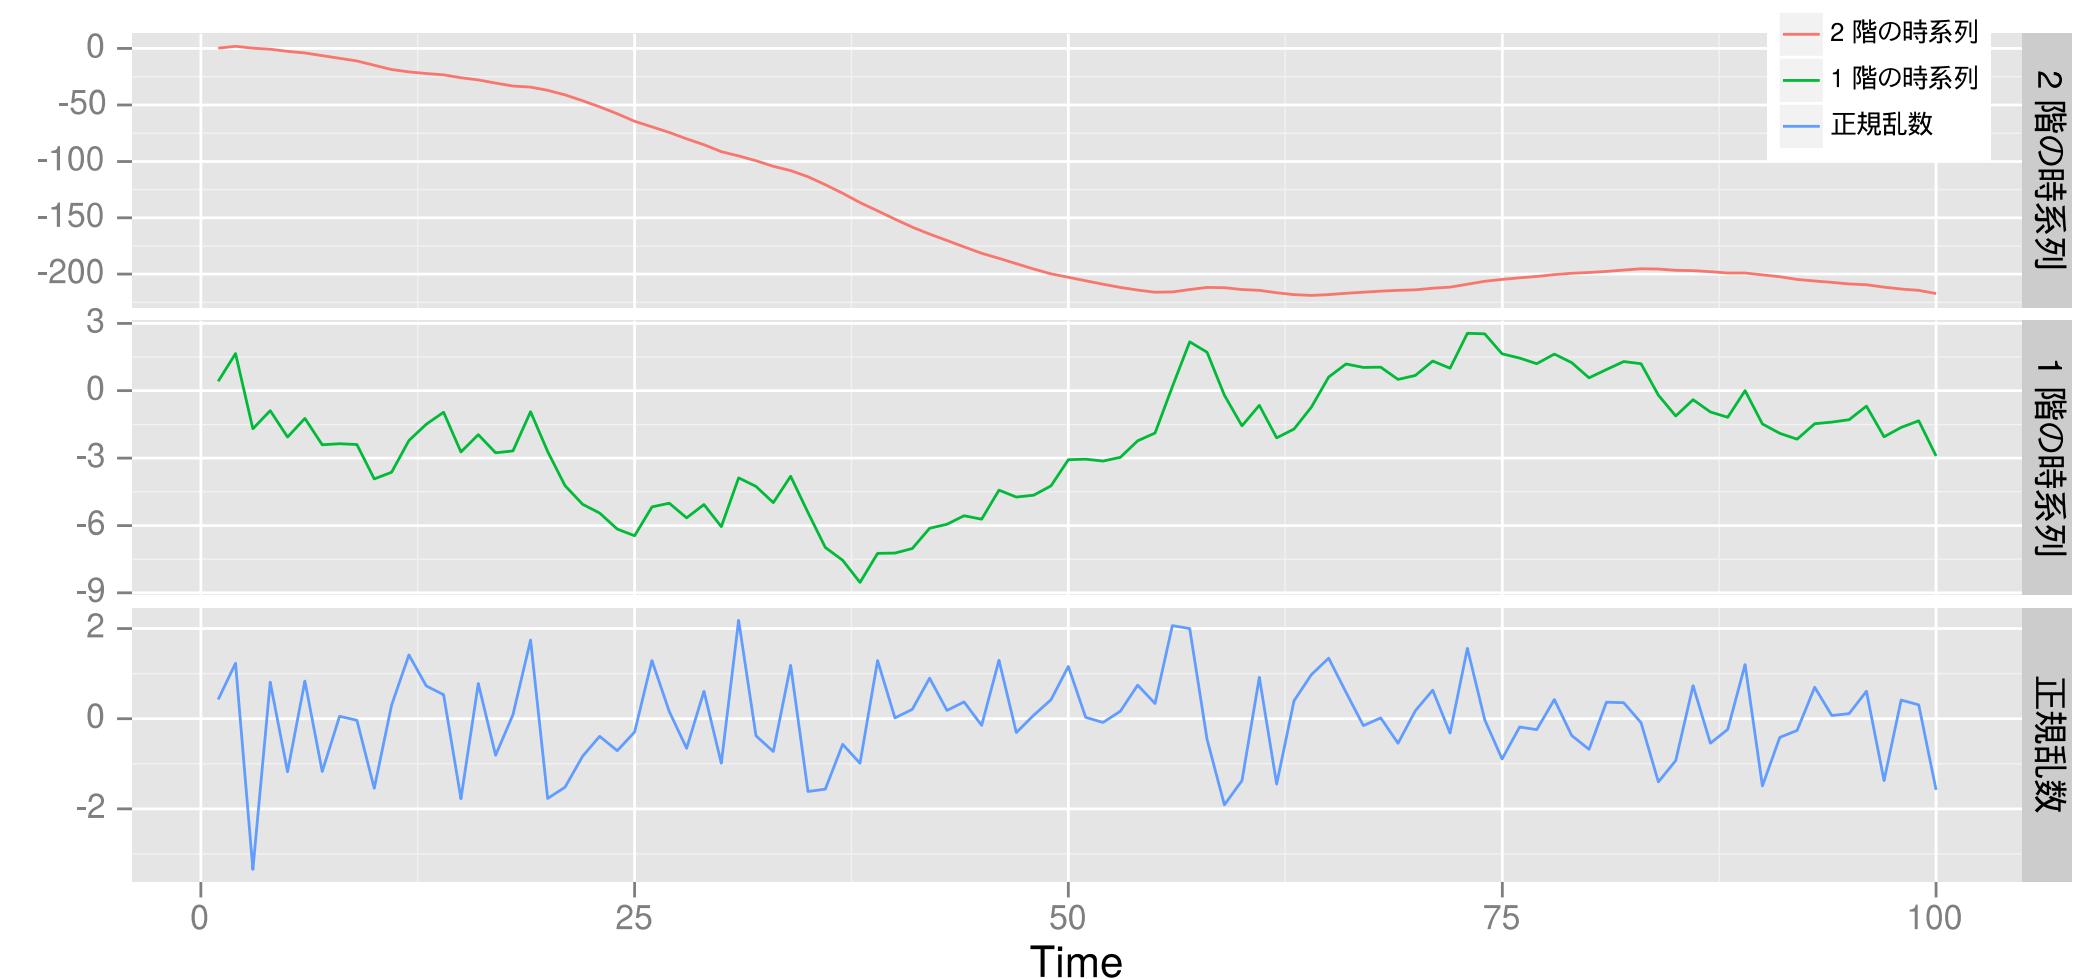


Y_t と Y_{t+1} は似ている!



時系列データの「差分」をみよう

自己相関係数もいいけど差分を調べるのが基本



時間的自己相関

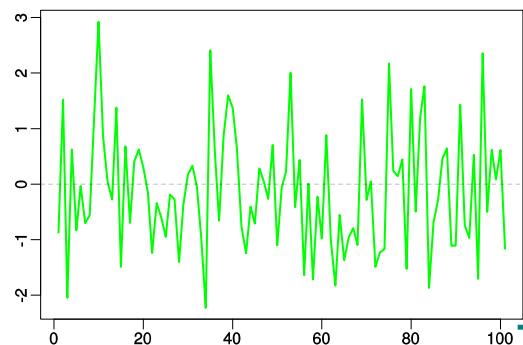
いつも役にたつわけではない?

$$\rho_k = \frac{\text{Cov}(y_t, y_{t-k})}{\sqrt{\text{Var}(y_t) \cdot \text{Var}(y_{t-1})}}$$

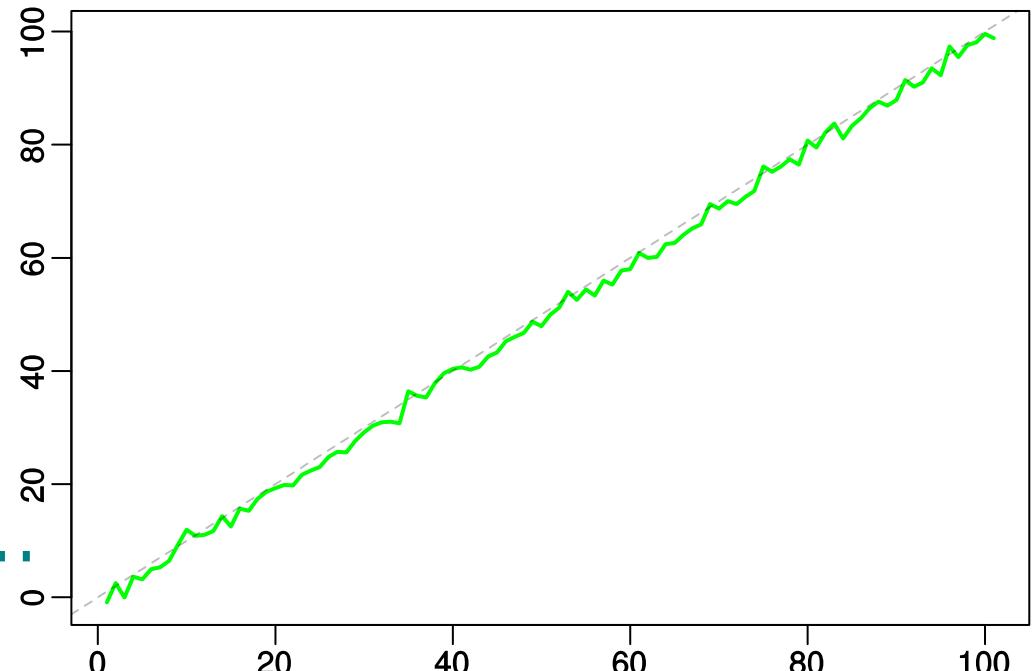


各点独立のデータをナナメにすると?

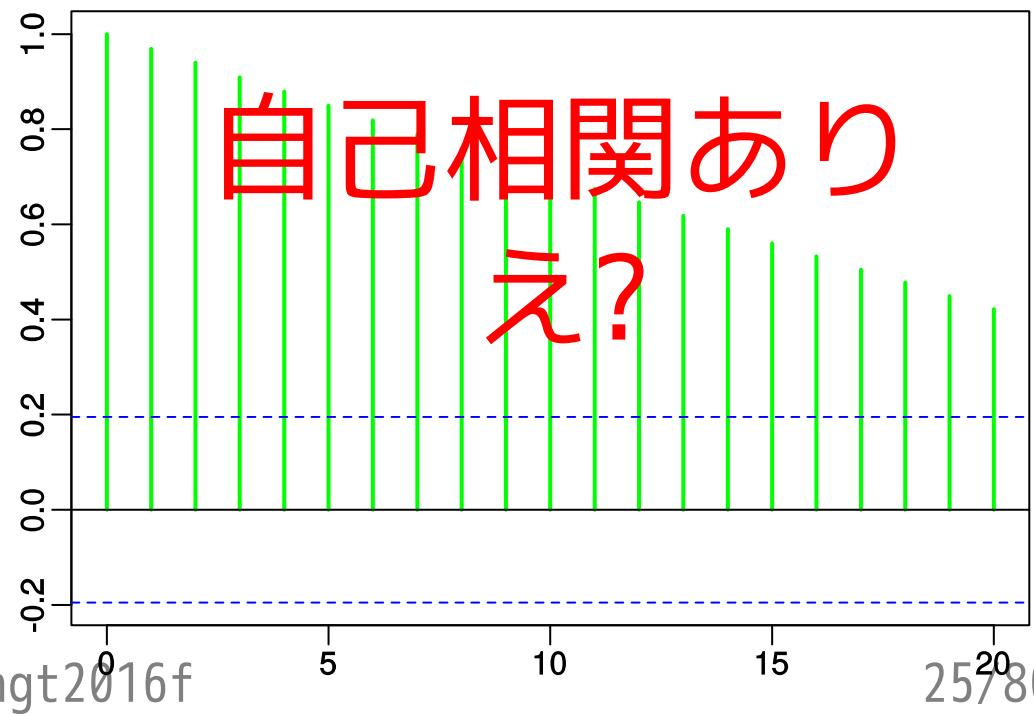
`plot(ts(Y))`



これを
ナナメに
したもの
なんだけど…

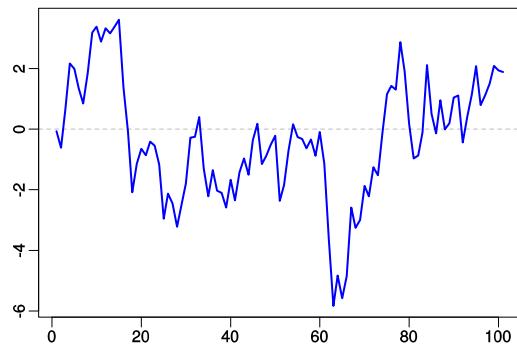


`plot(acf(ts(Y)))`



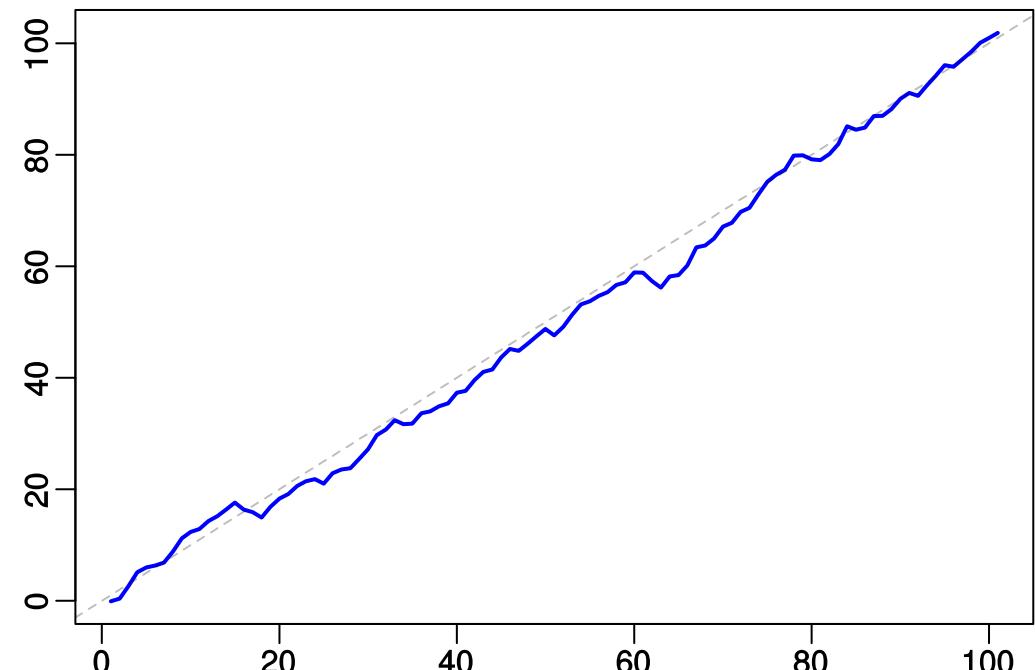
各点独立のデータをナナメにすると?

`plot(ts(Y))`

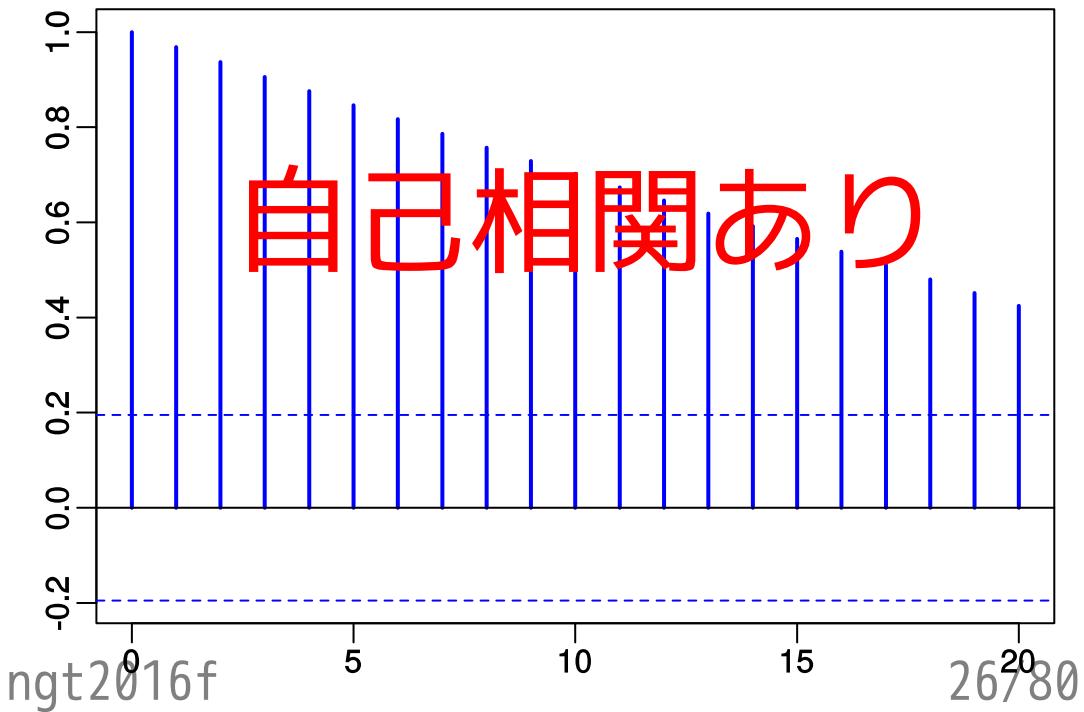


これを
ナナメに
したもの

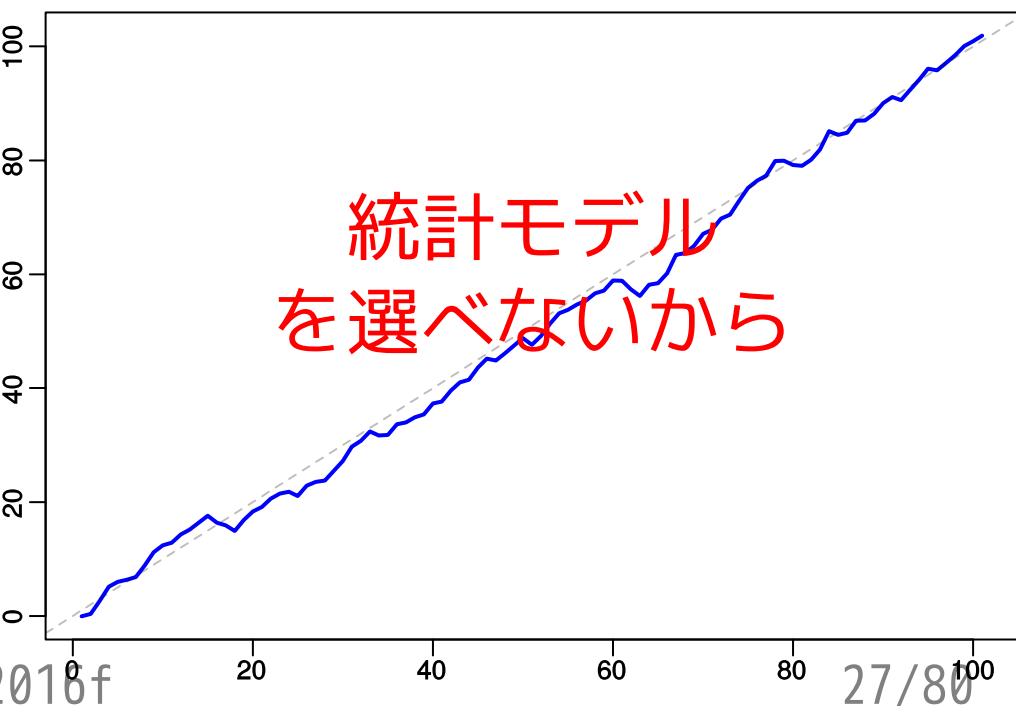
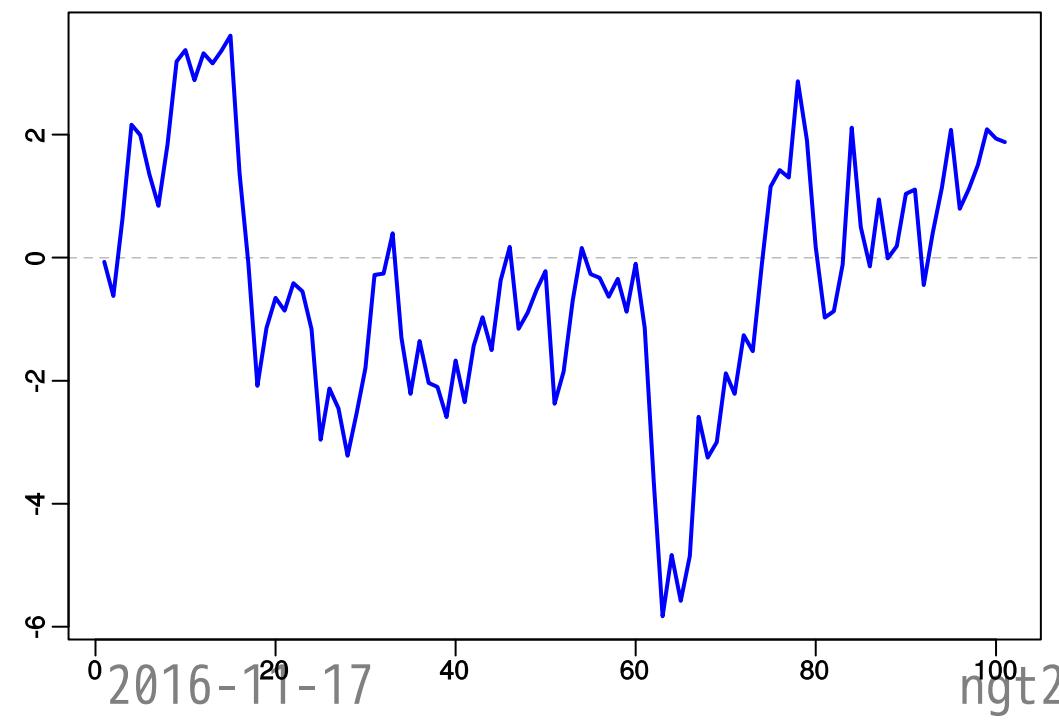
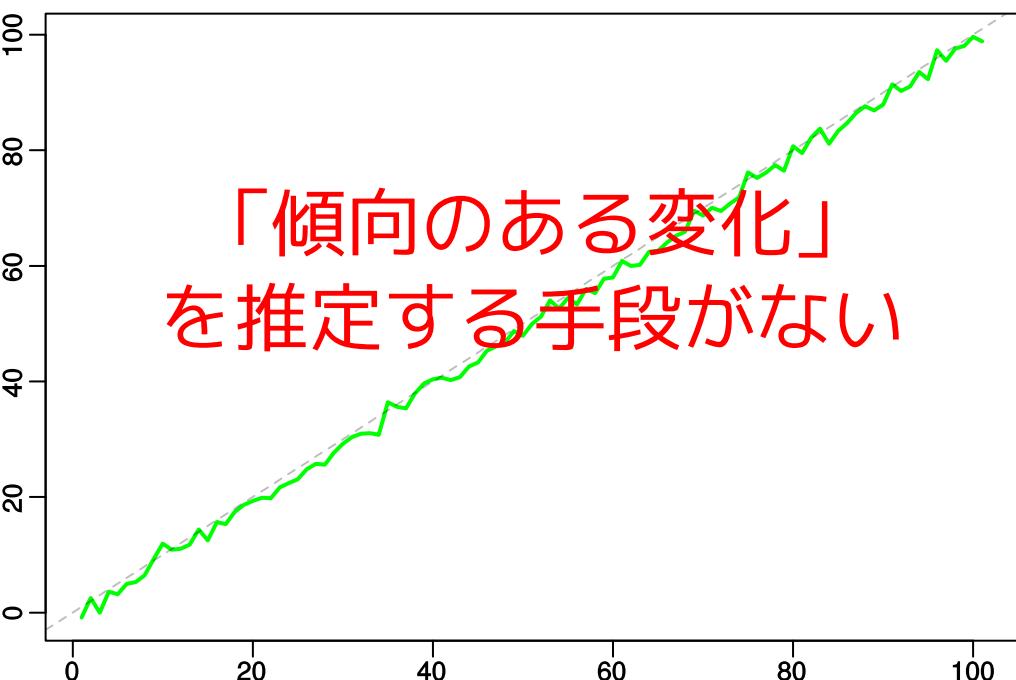
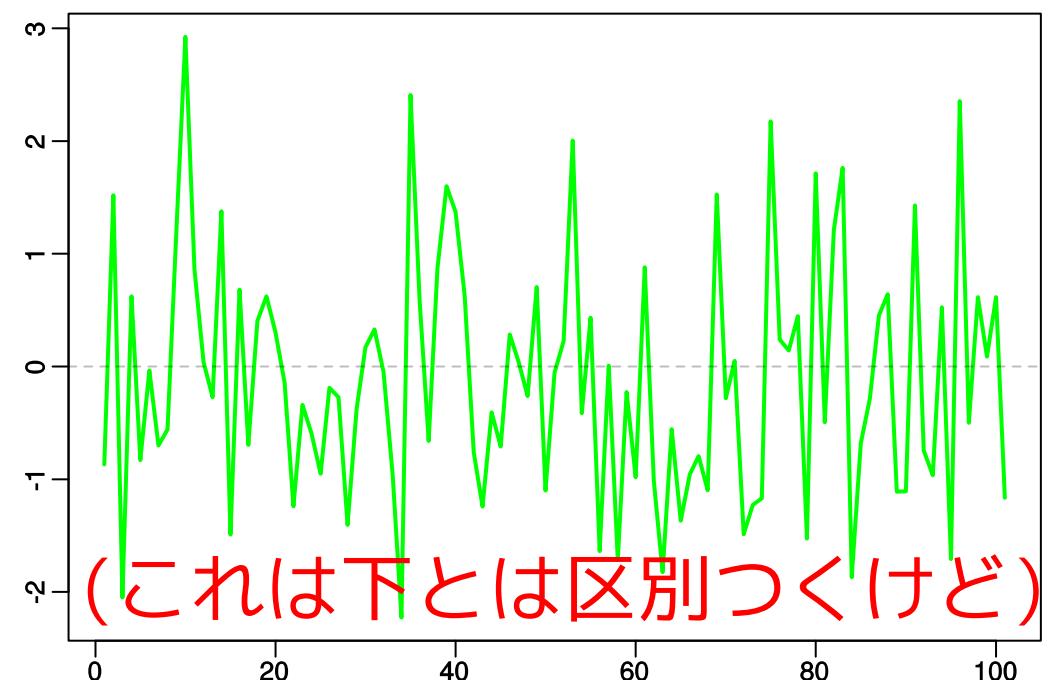
`plot(acf(ts(Y)))`



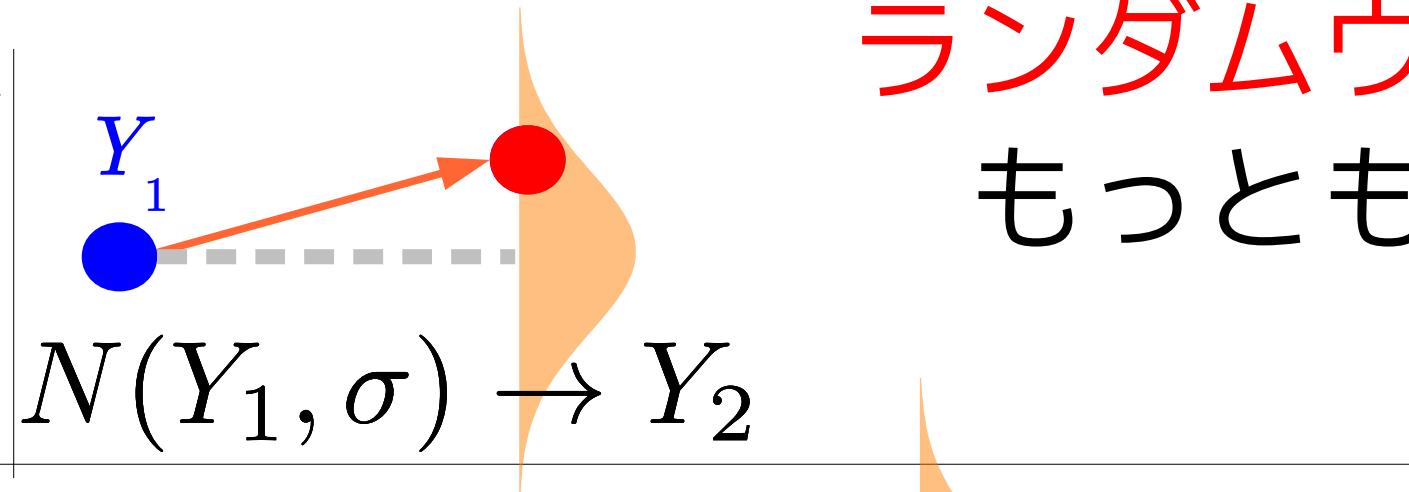
自己相関あり



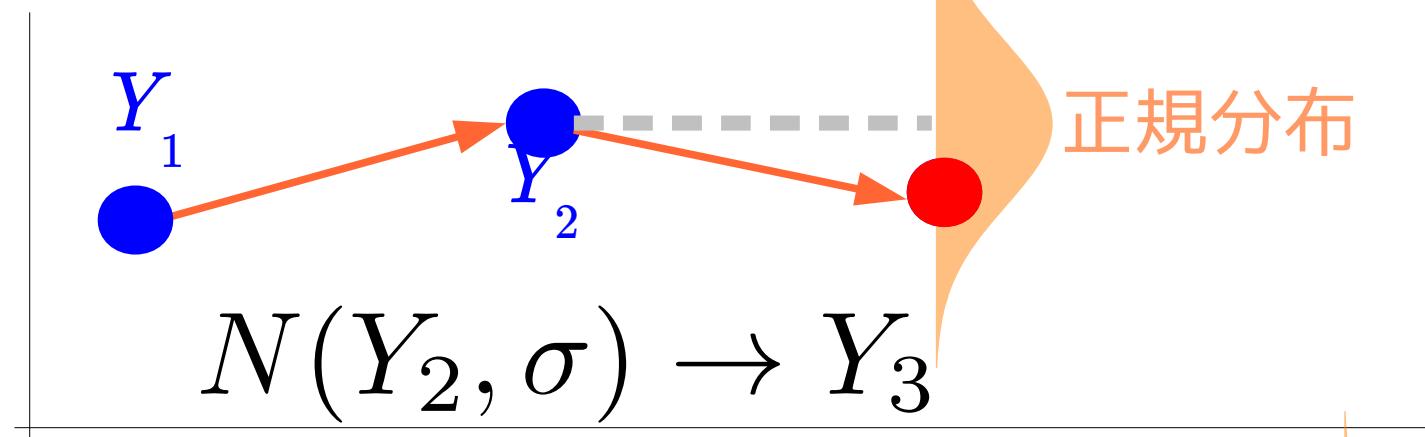
自己相関係数みても区別がつかない



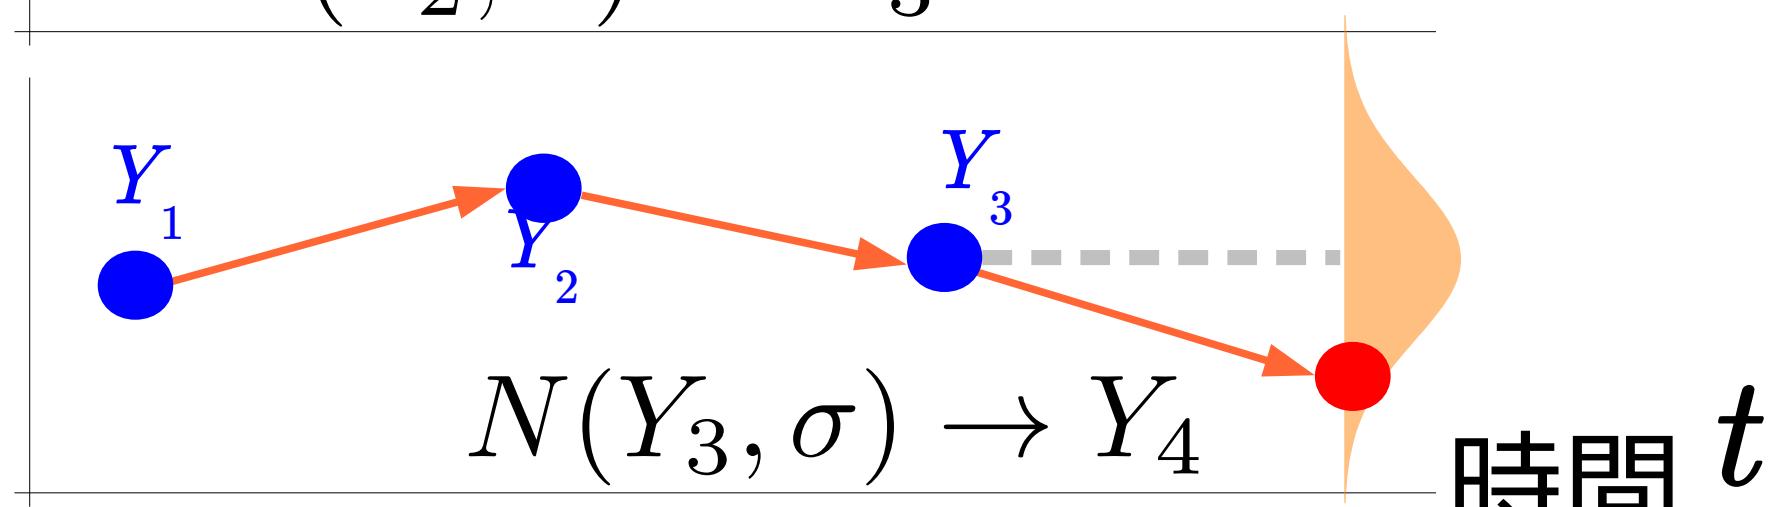
変数
 Y



ランダムウォーク
もっとも単純な
モデル



正規分布

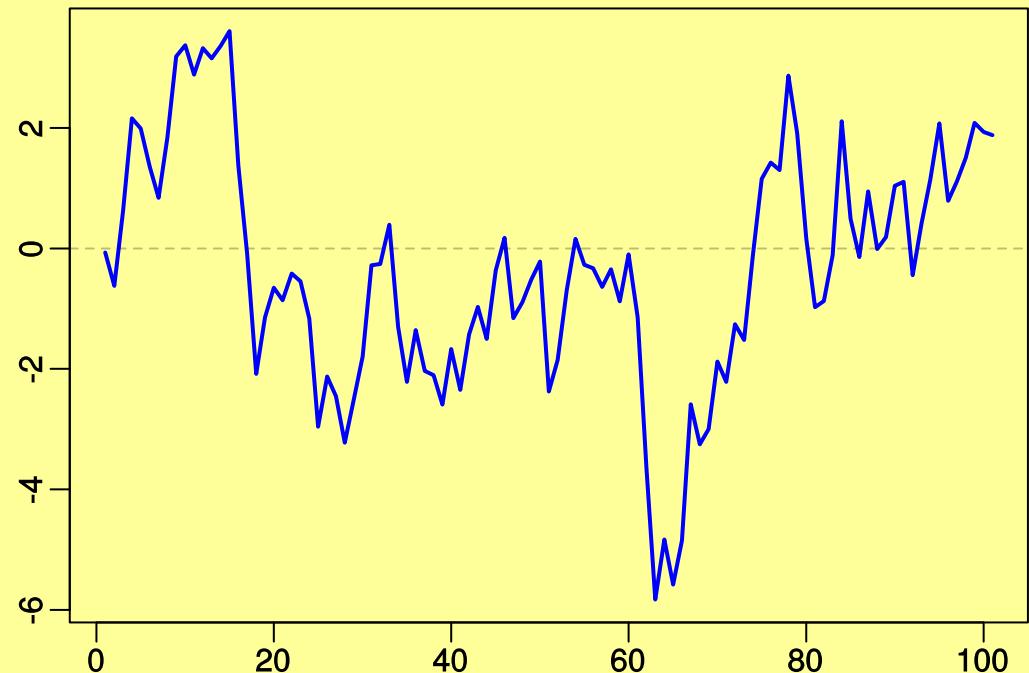
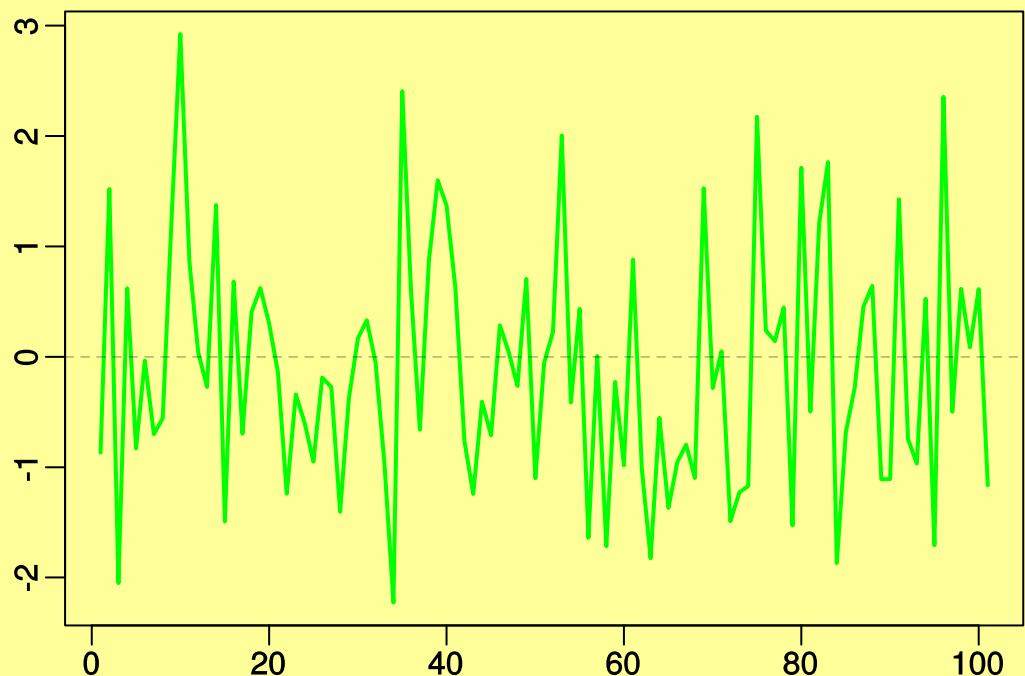


時間 t

状態空間モデルでたちむかう

時系列データ解析

いろいろな時系列データを
統一的につかえないので?



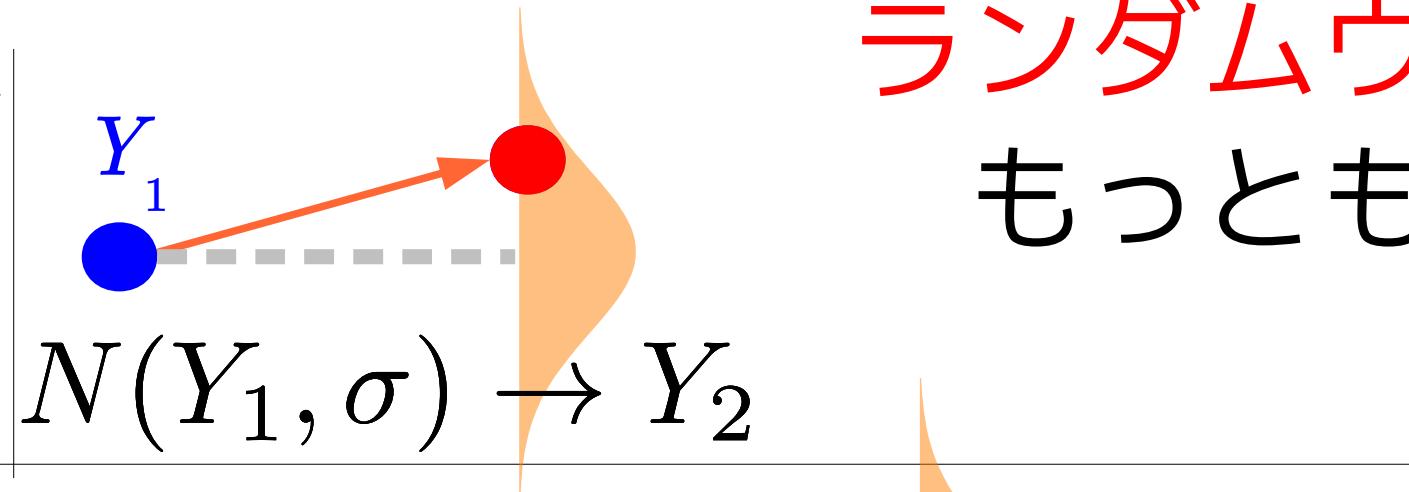
時系列データ解析の教科書、ねえ……

- モデルがあれこれ多すぎる
- 経済学よりのモデルばかり
- なんでも正規分布

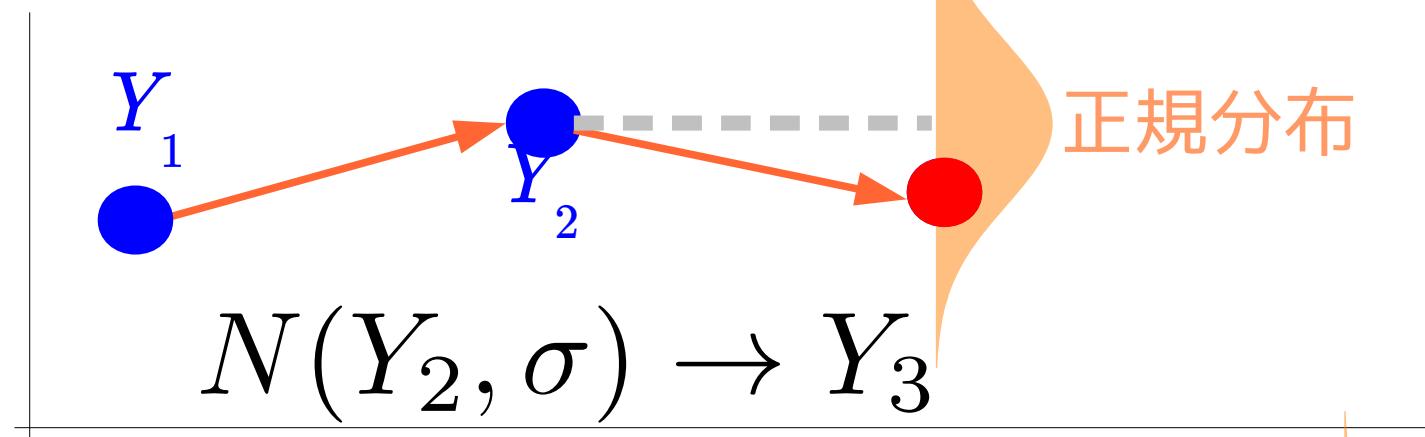
なんとかならないかな?

状態空間モデル、どうでしょう?

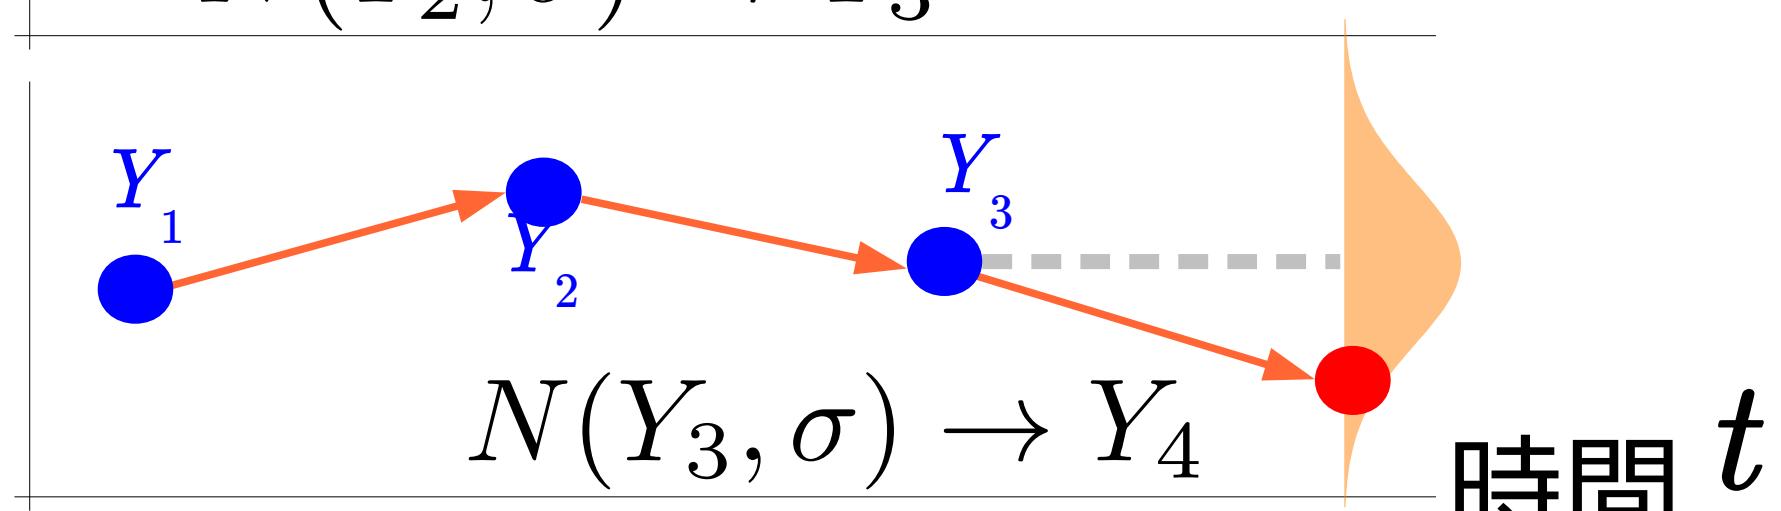
変数
 Y



ランダムウォーク
もっとも単純な
モデル



正規分布



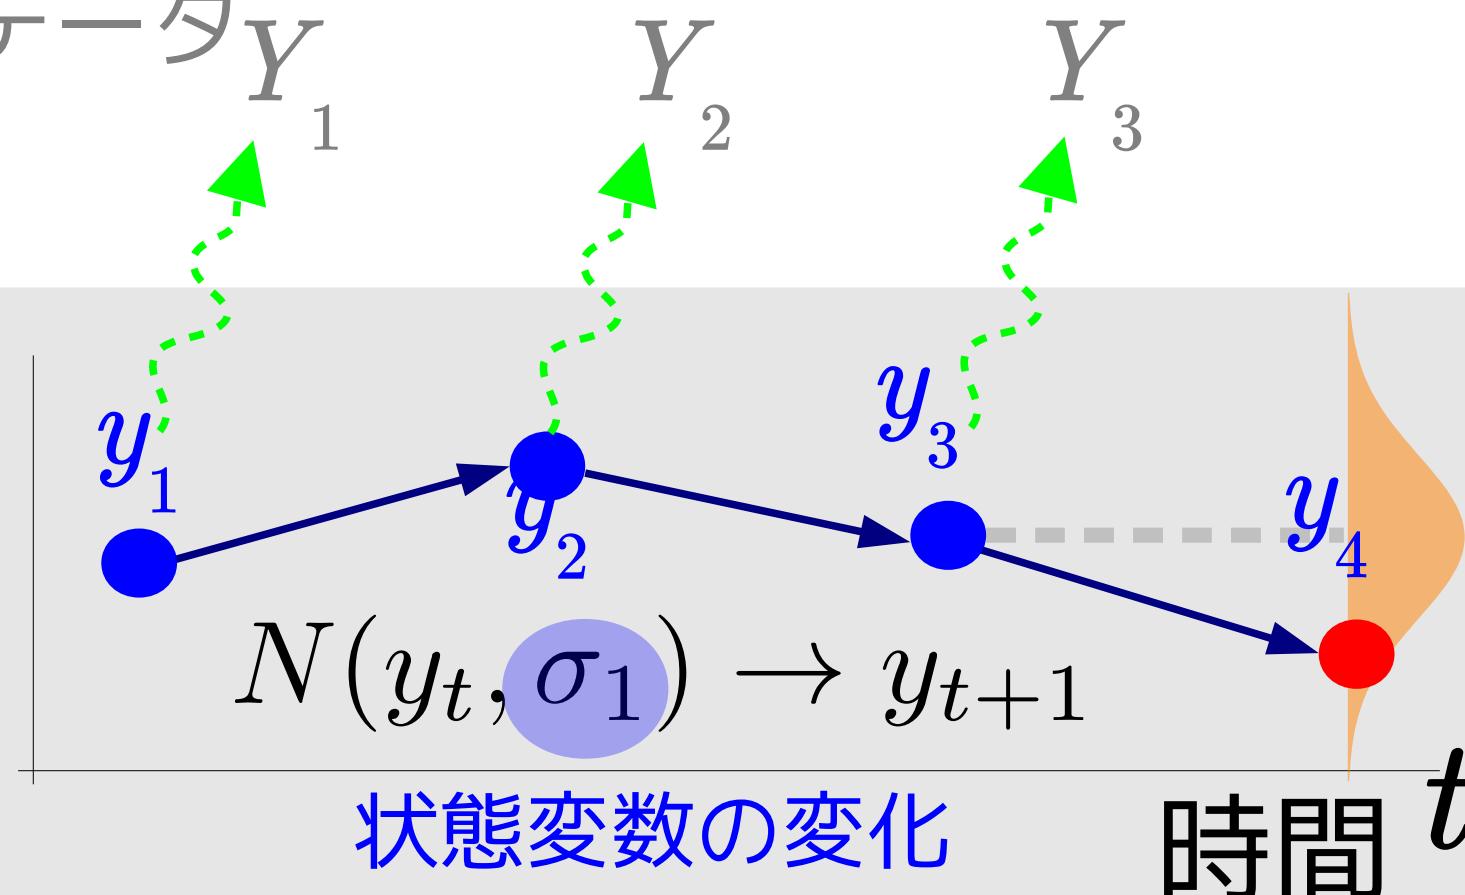
観測の誤差

状態空間モデル

$$N(y_t, \sigma_2) \rightarrow Y_t$$

二種類の σ をもつ

観測データ Y



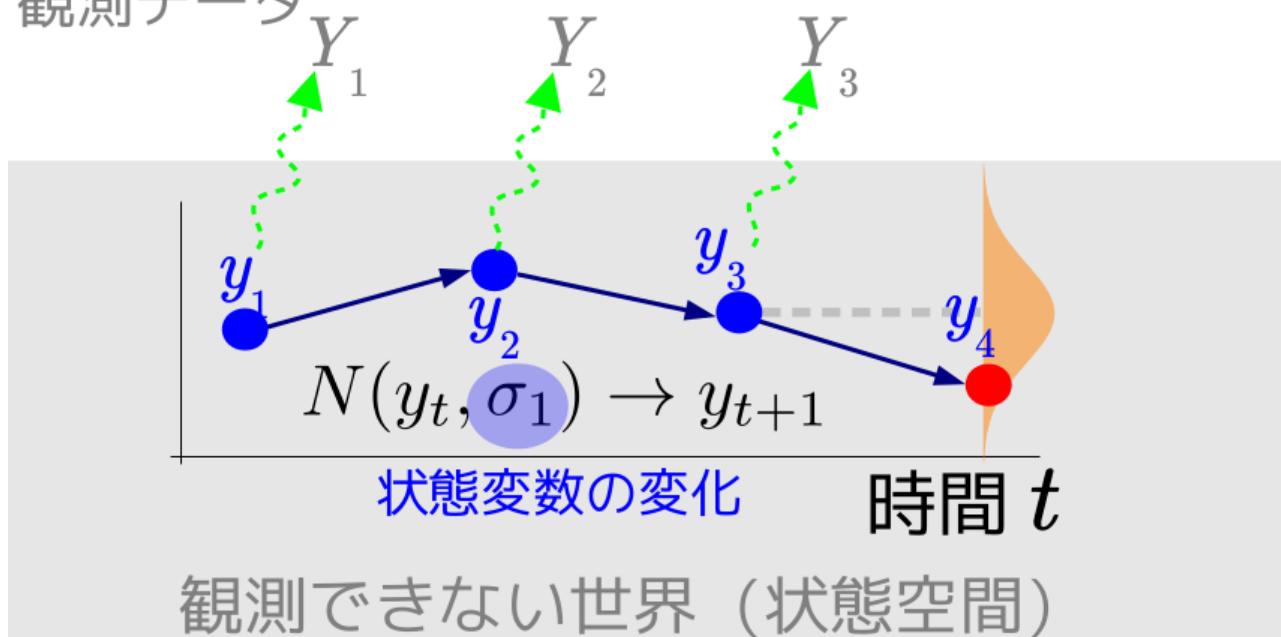
観測できない世界（状態空間）

観測の誤差

状態空間モデル

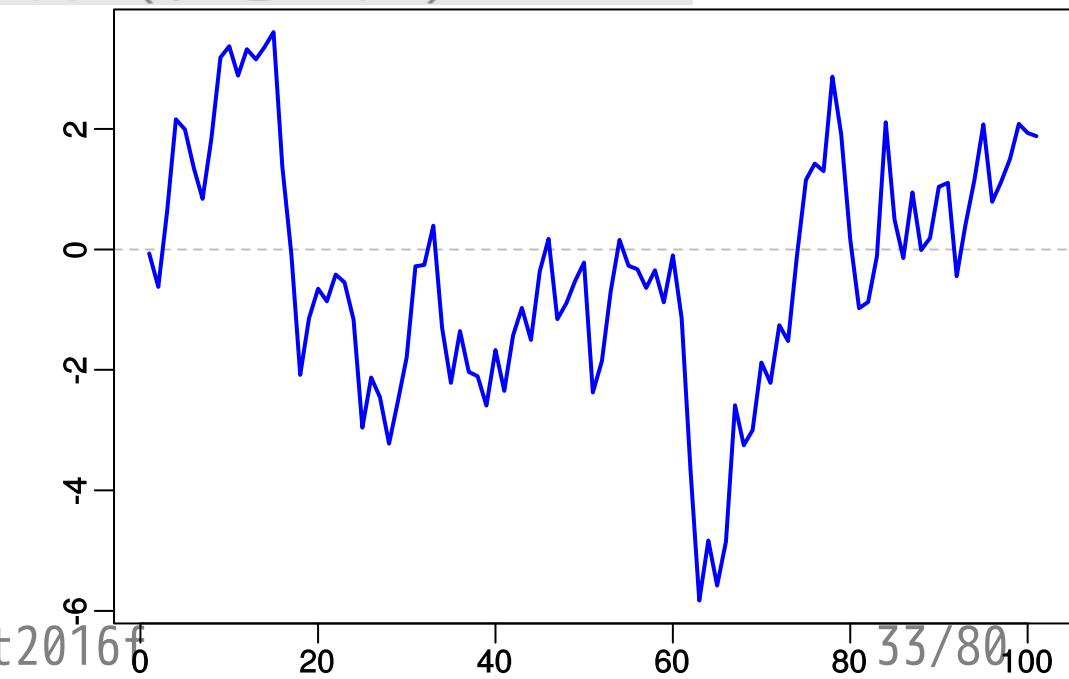
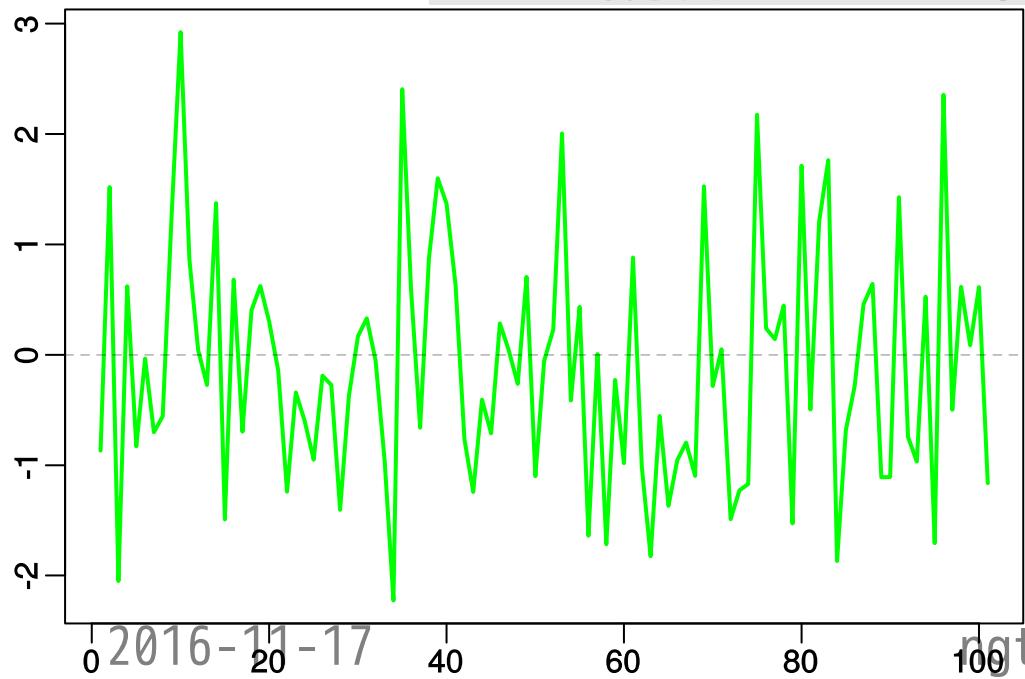
$N(y_t, \sigma_2)$ $\rightarrow Y_t$ 二種類の σ をもつ

観測データ



σ₂ 大
σ₁ 小

σ₂ 小
σ₁ 大

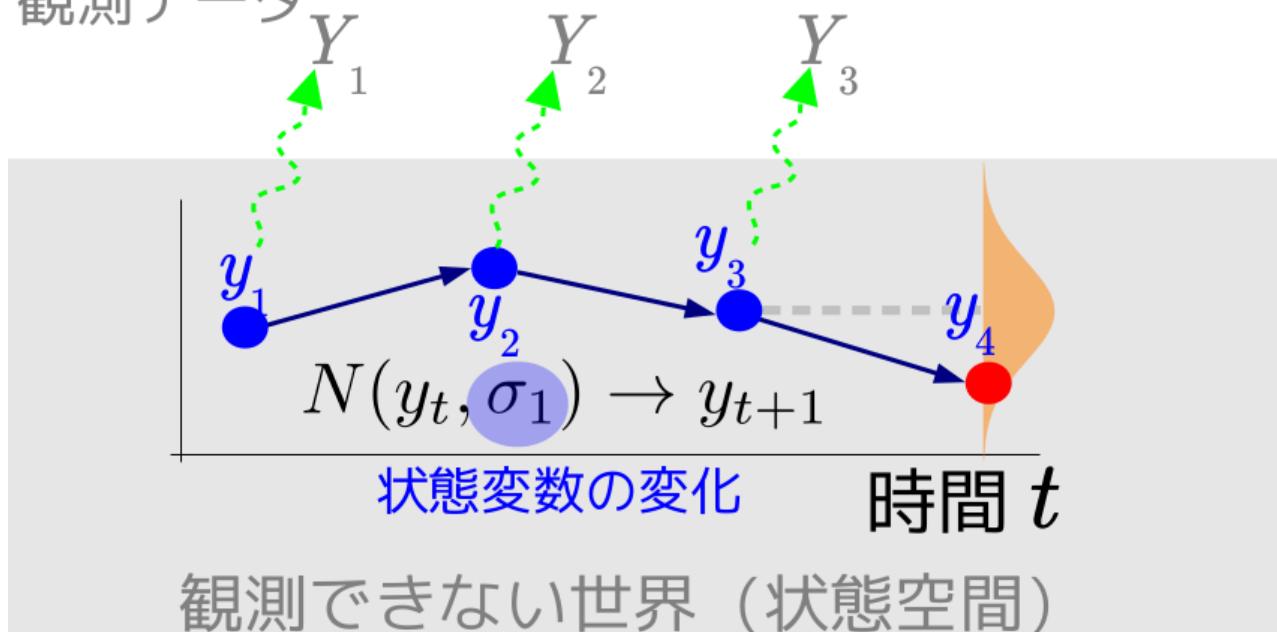


観測の誤差

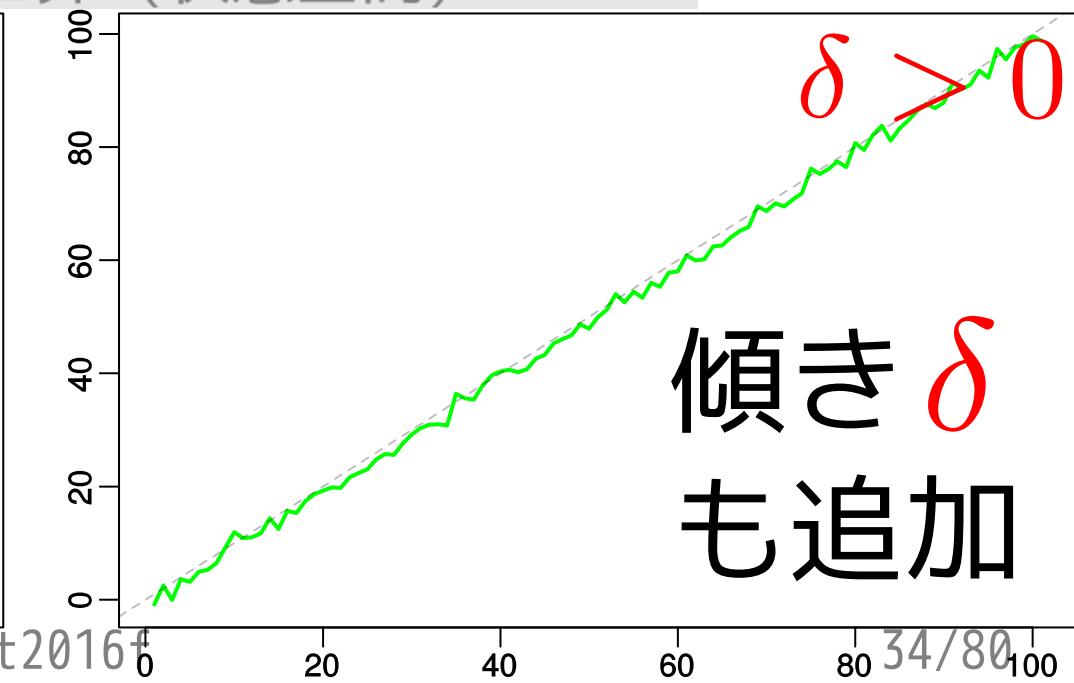
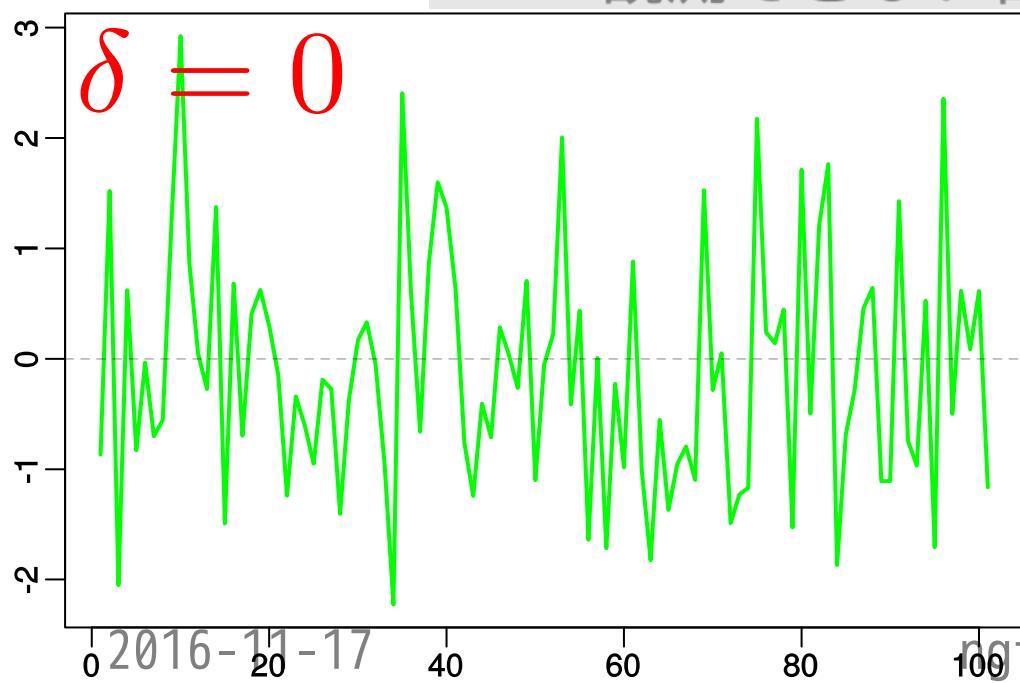
状態空間モデル

$N(y_t, \sigma_2)$ $\rightarrow Y_t$ 二種類の σ をもつ

観測データ



σ_2 大
 σ_1 小

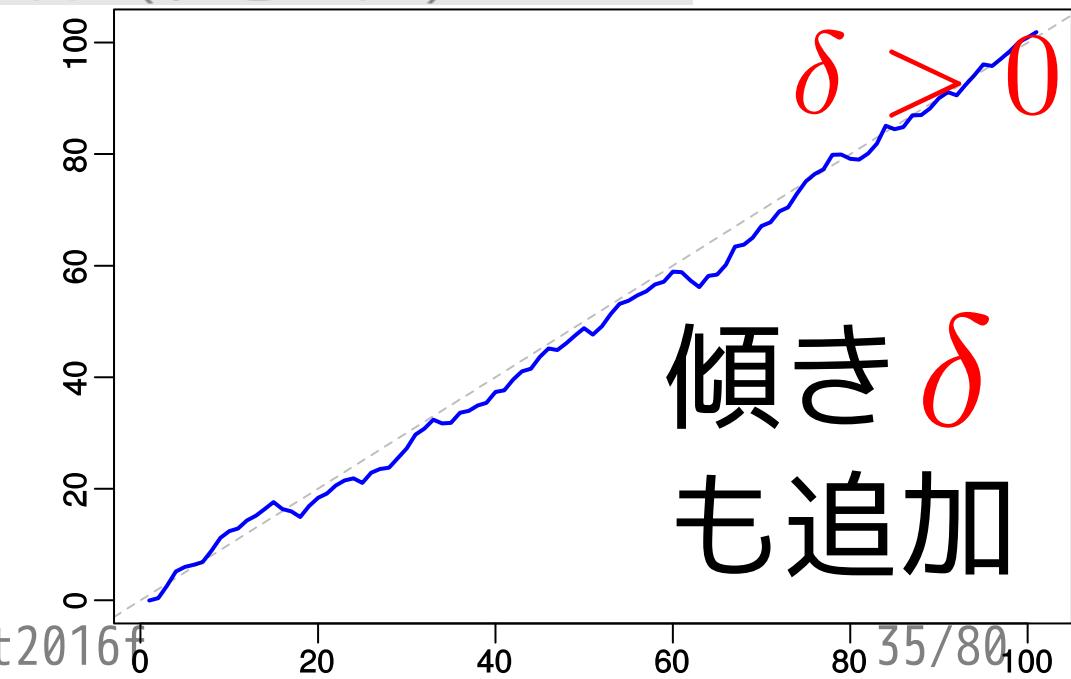
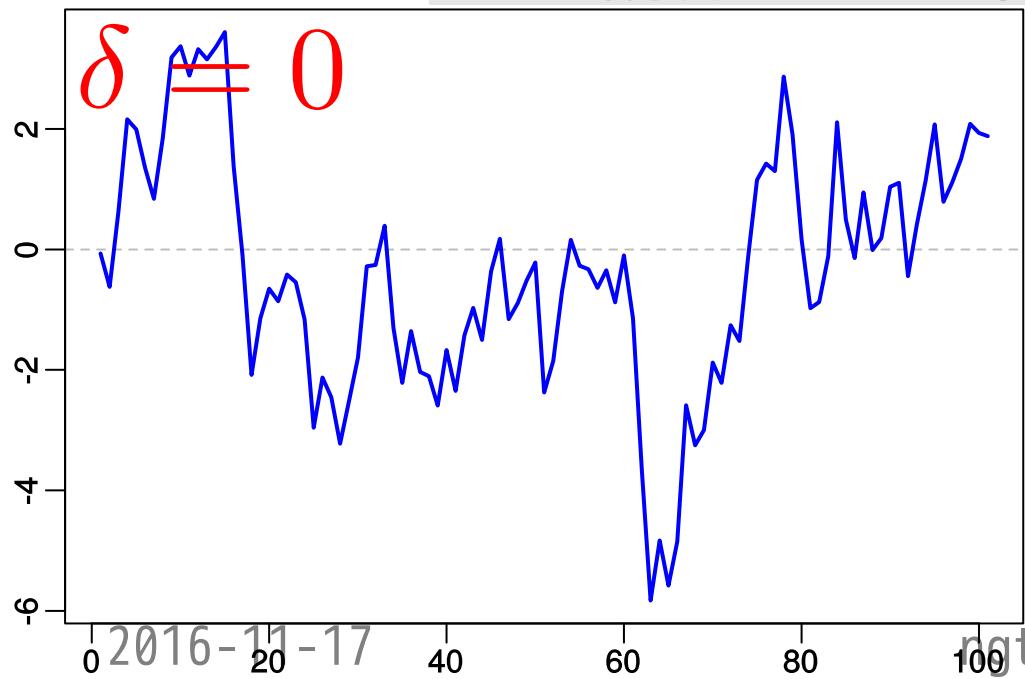
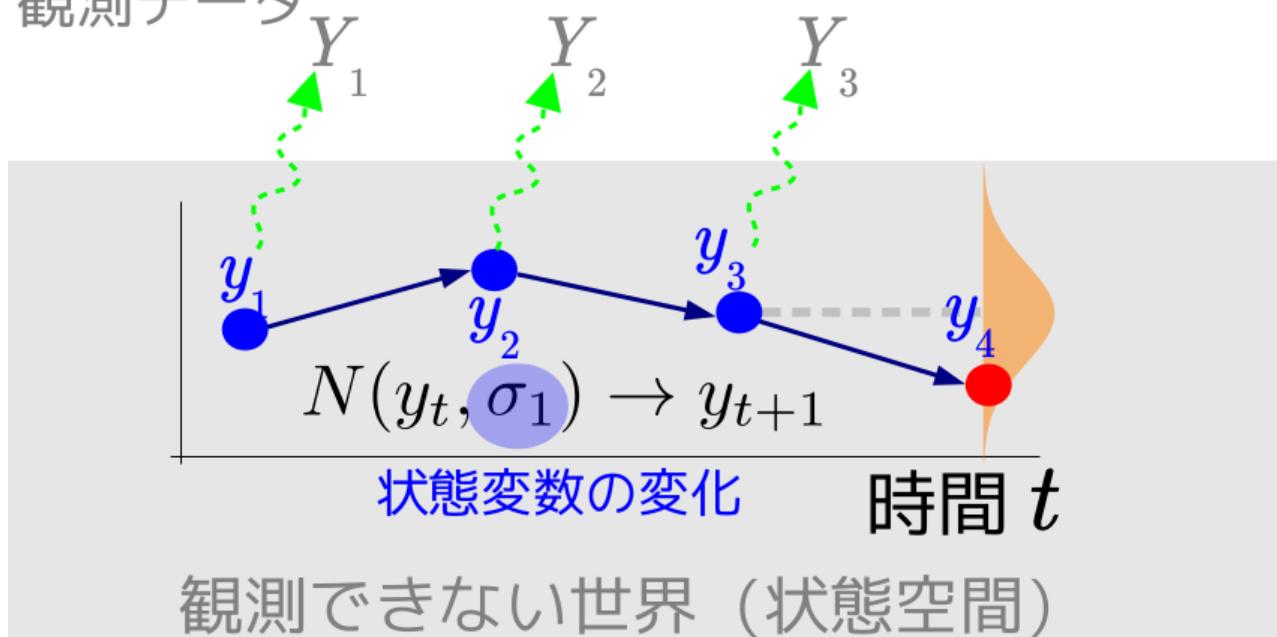


観測の誤差

状態空間モデル

$$N(y_t, \sigma_2) \rightarrow Y_t \quad \text{二種類の } \sigma \text{ をもつ}$$

観測データ



状態空間モデル + GLM

この部分にポアソン分布や

二項分布をいれる

誤差

状態空間モデル

$$N(y_t, \sigma_2) \rightarrow Y_t$$

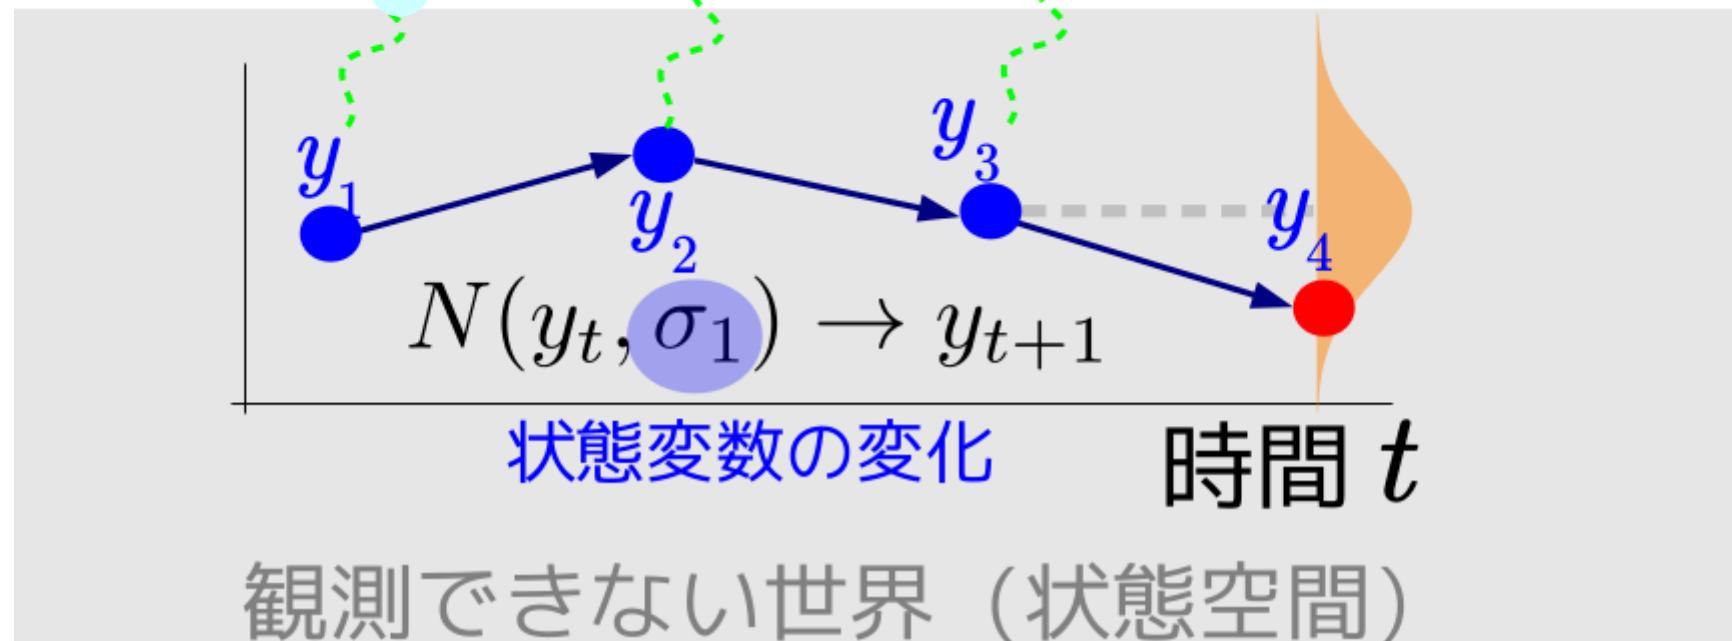
二種類の σ をもつ

観測データ

$$Y_1$$

$$Y_2$$

$$Y_3$$

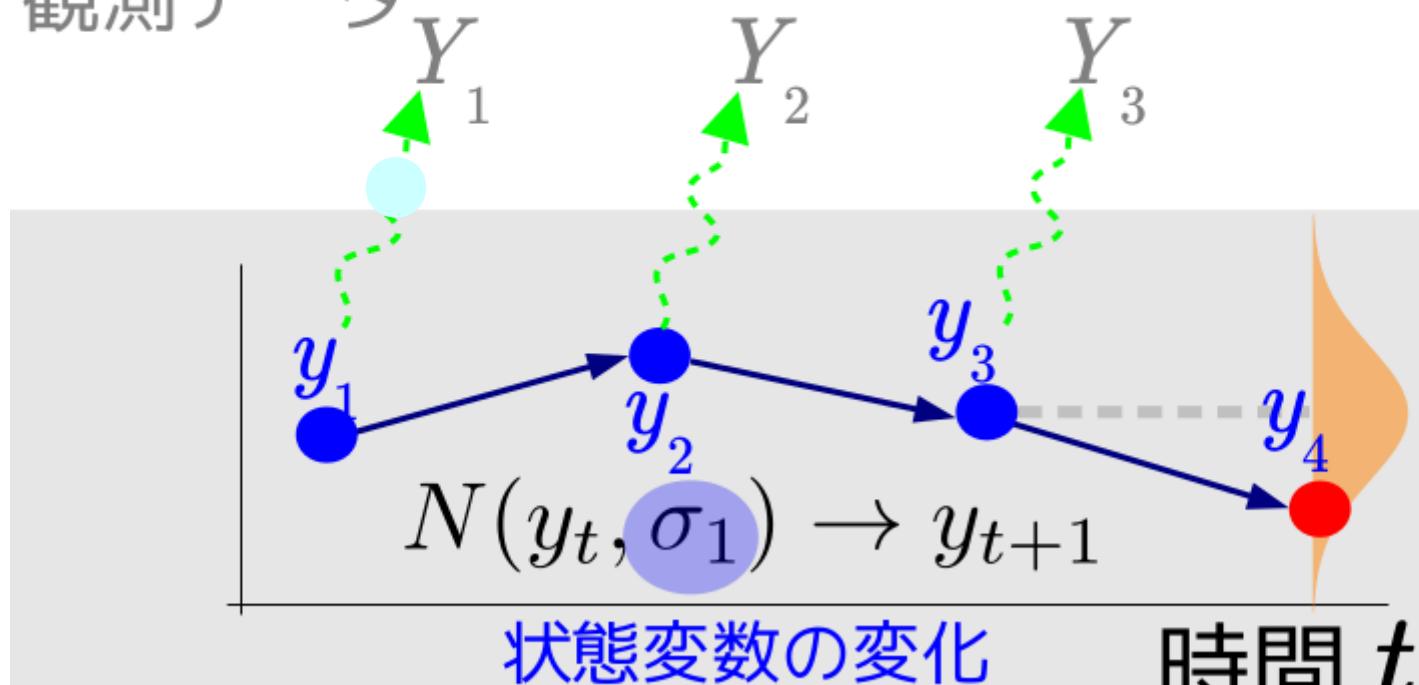


状態空間モデル + GLM

他にも季節変動などを
入れることができます

今日は
省略…
すみません

観測データ



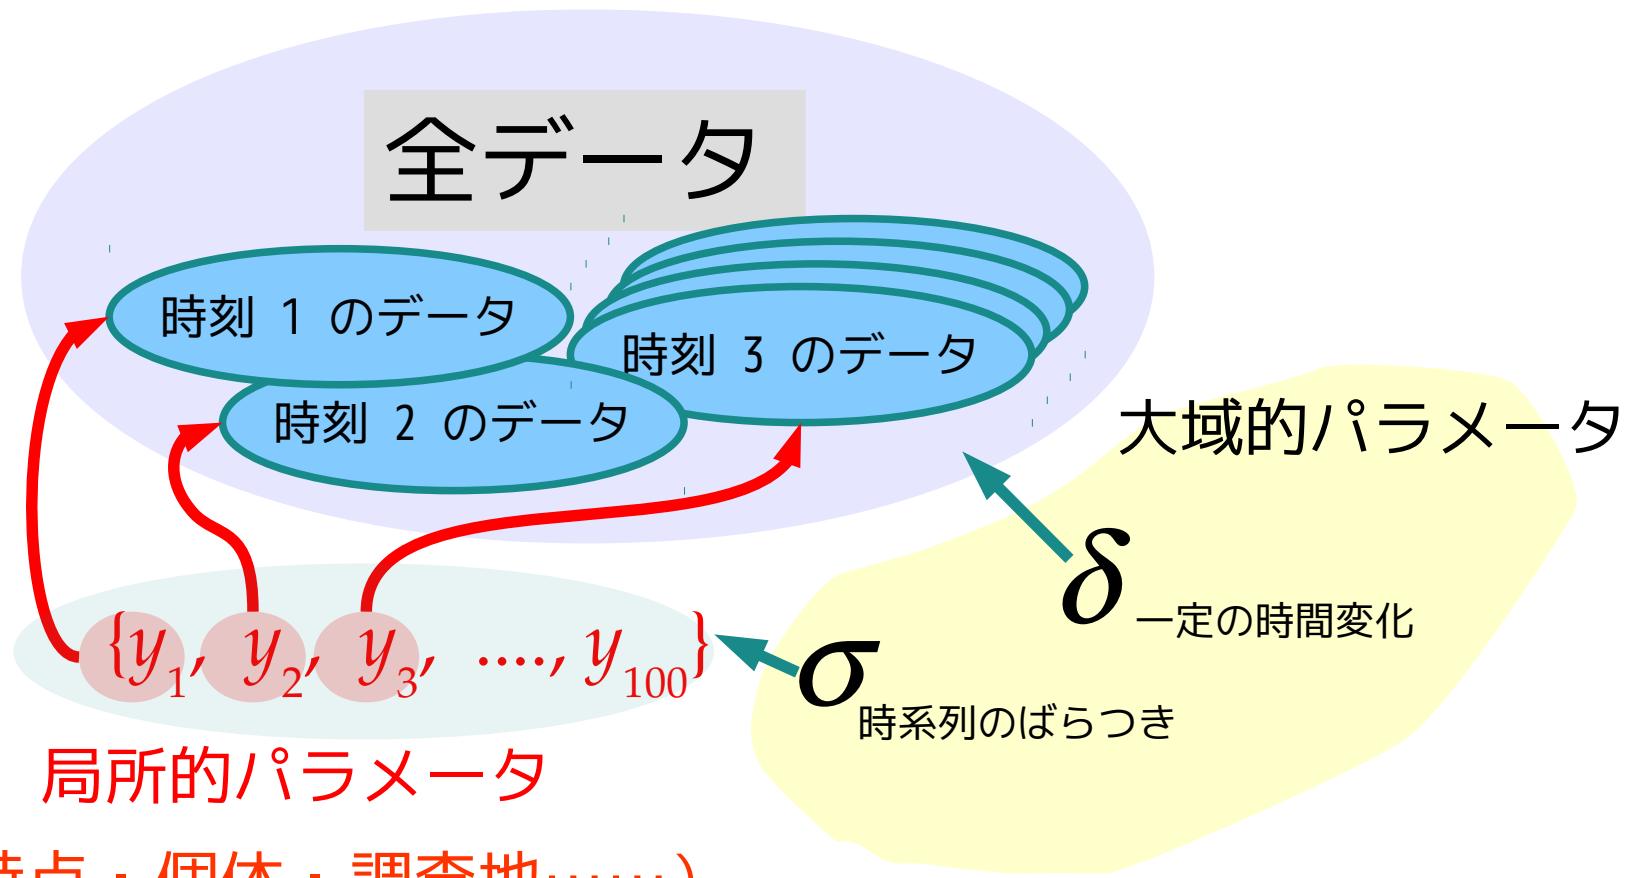
状態変数の変化

時間 t

観測できない世界（状態空間）

階層ベイズモデルとは？

多数の「似たようなパラメーター」たちに
「適切」な制約を加えて推定できる



(たくさんの時点・個体・調査地……)

どうやってモデルをあてはめる？



R の状態空間モデルの

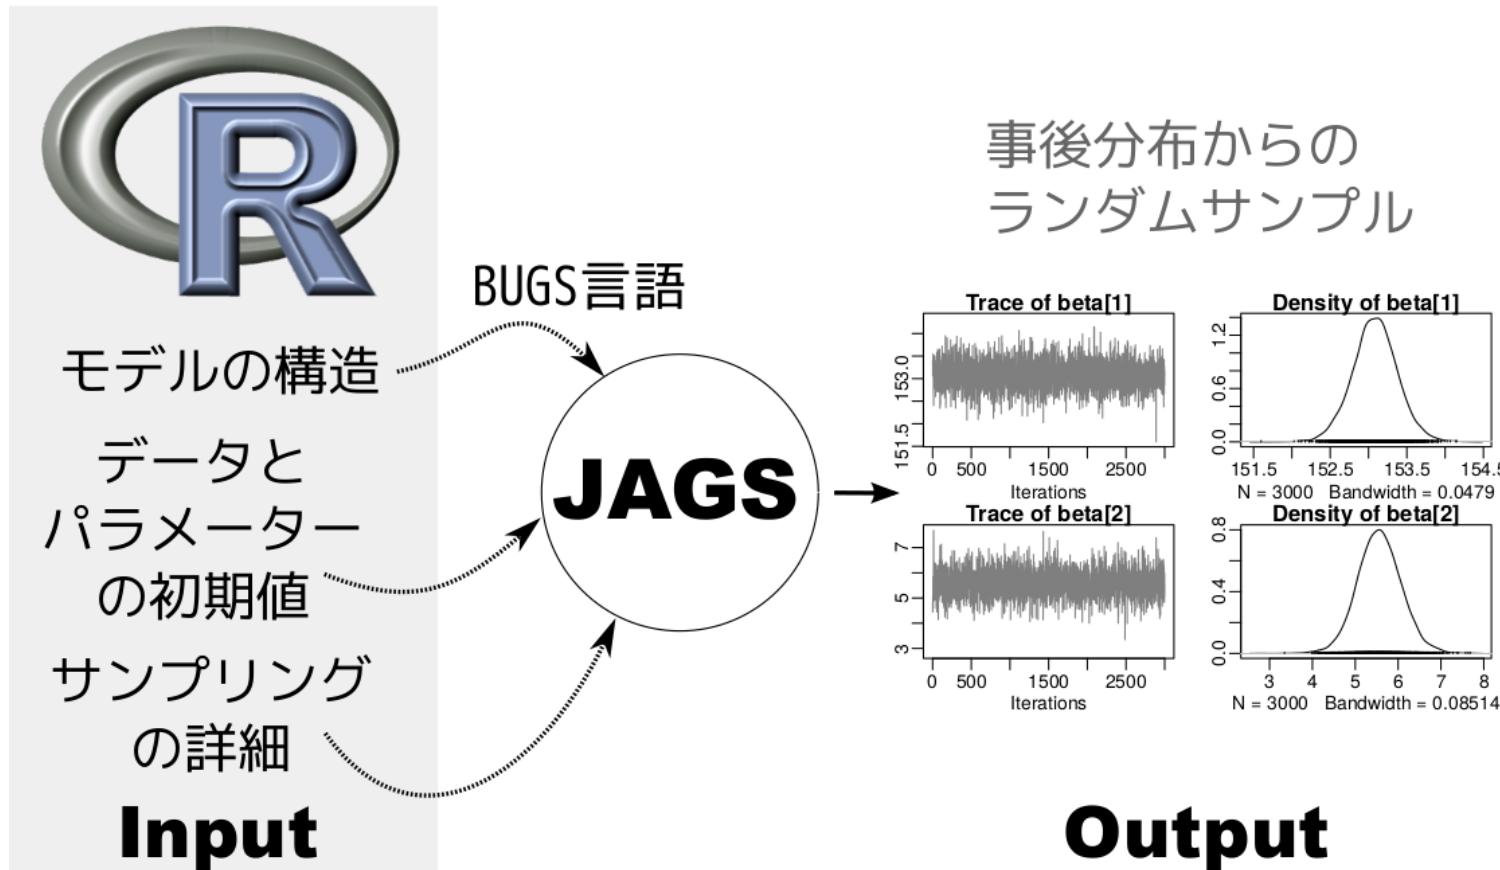
package いろいろある

`library(dlm)`

`library(KFAS)`

(けっこうめんどう?)

こういう問題も JAGS で BUGS 言語でこの単純な 階層ベイズモデルを記述できる



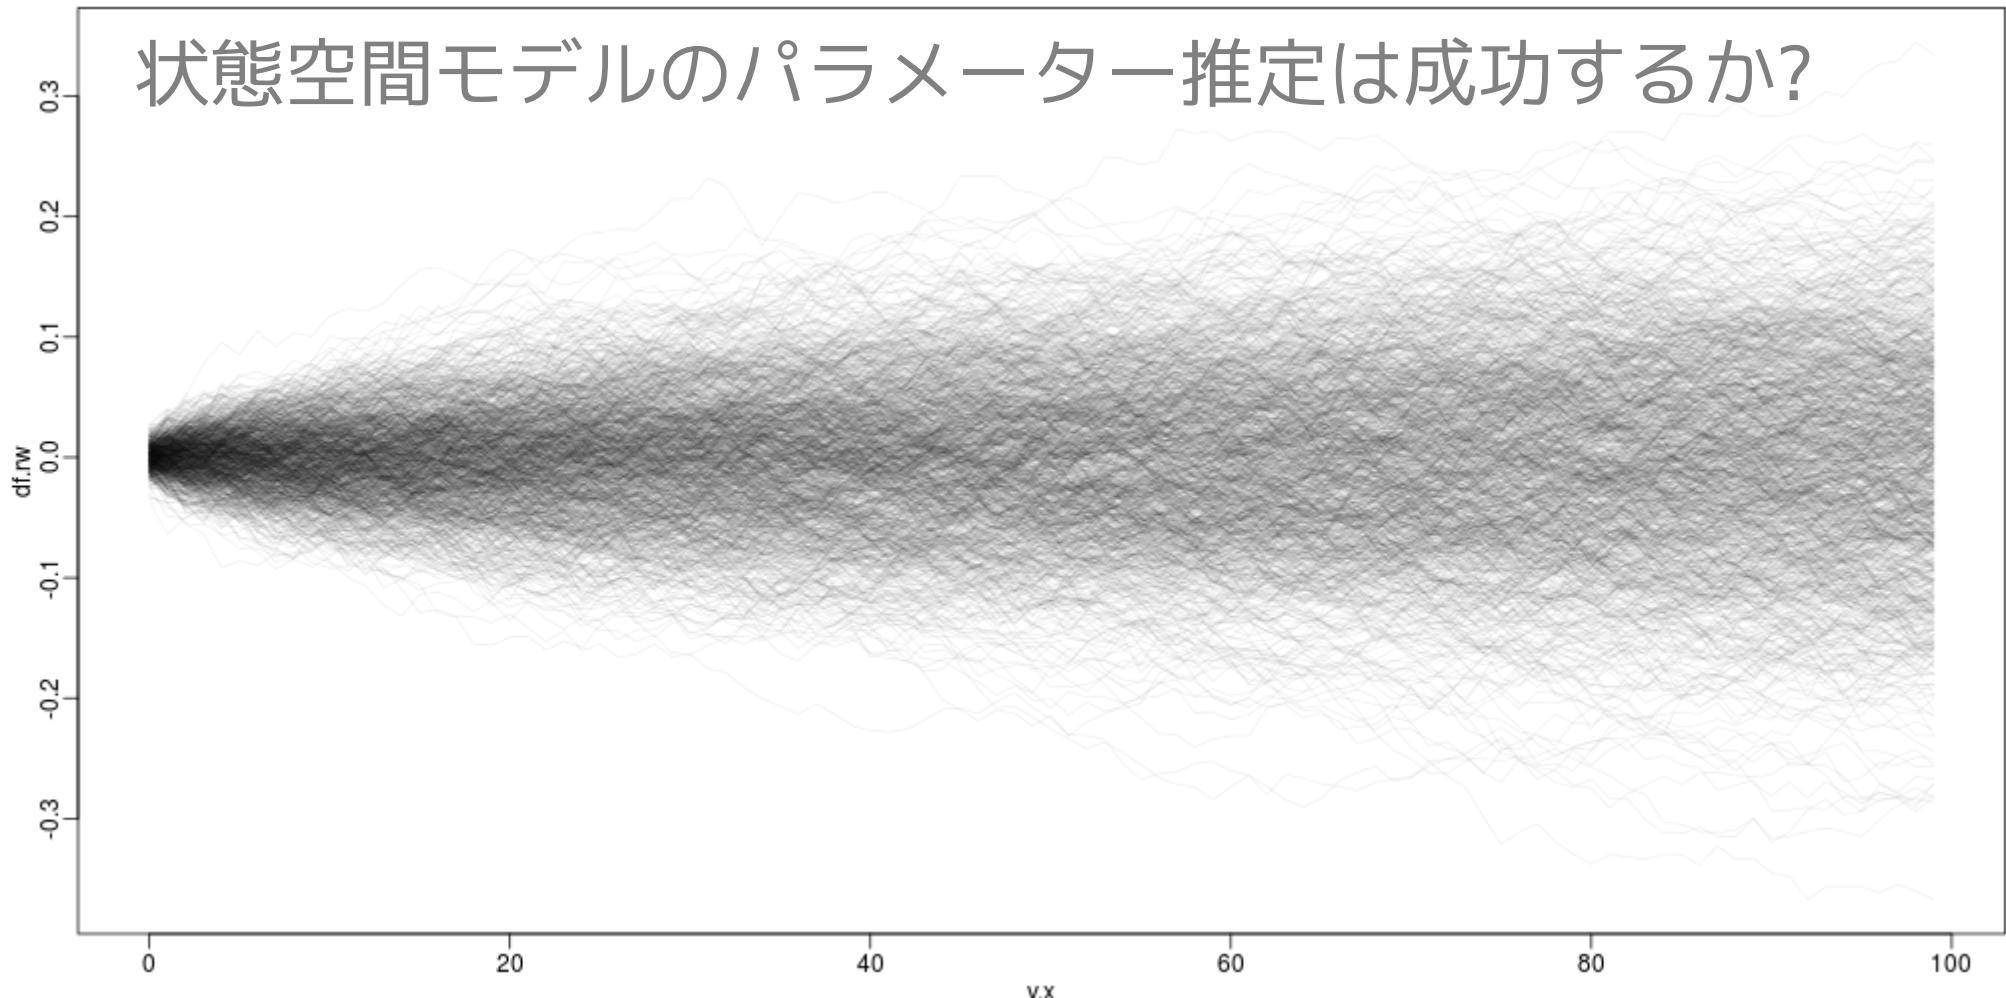
```
model
```

```
{
```

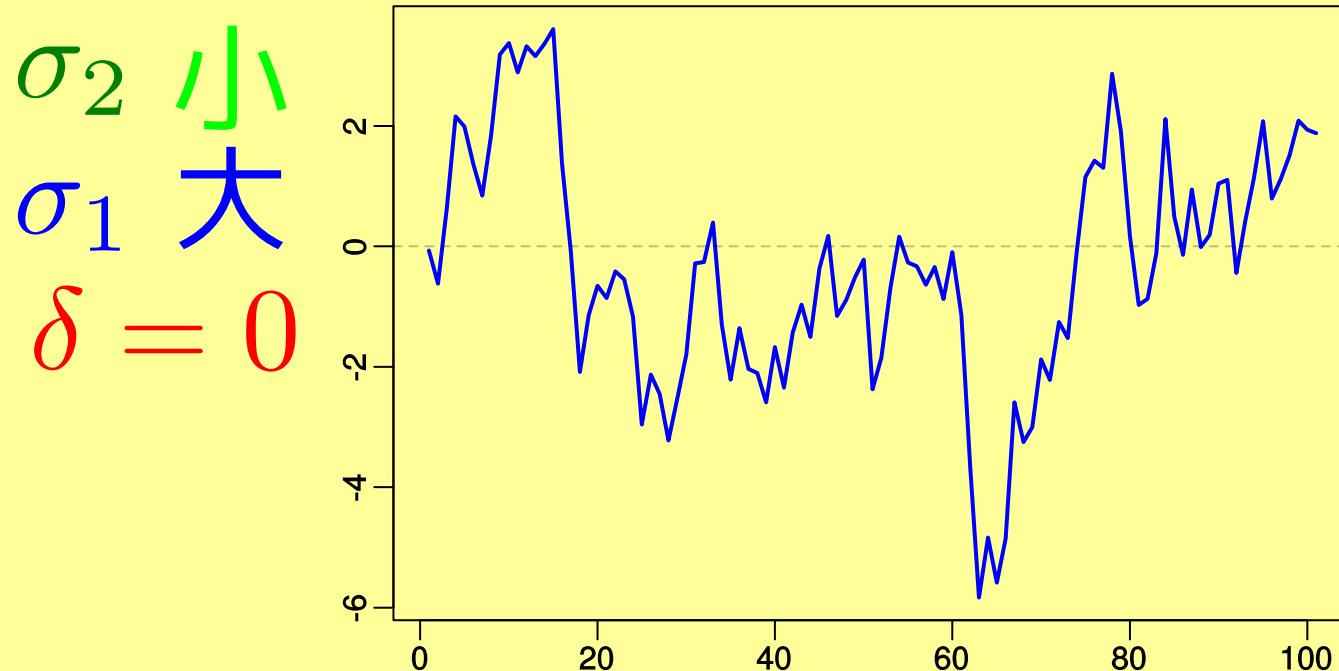
```
  Tau.Noninformative <- 0.0001  
  Y[1] ~ dnorm(y[1], tau[2])  
  y[1] ~ dnorm(0, Tau.Noninformative)  
  for (t in 2:N.Y) {  
    Y[t] ~ dnorm(y[t], tau[2])  
    y[t] ~ dnorm(m[t], tau[1])  
    m[t] <- delta + y[t - 1]  
  }  
  delta ~ dnorm(0, Tau.Noninformative)  
  for (k in 1:2) {  
    tau[k] <- 1 / (s[k] * s[k])  
    s[k] ~ dunif(0, 10000)  
  }
```

1000 個の架空データを推定

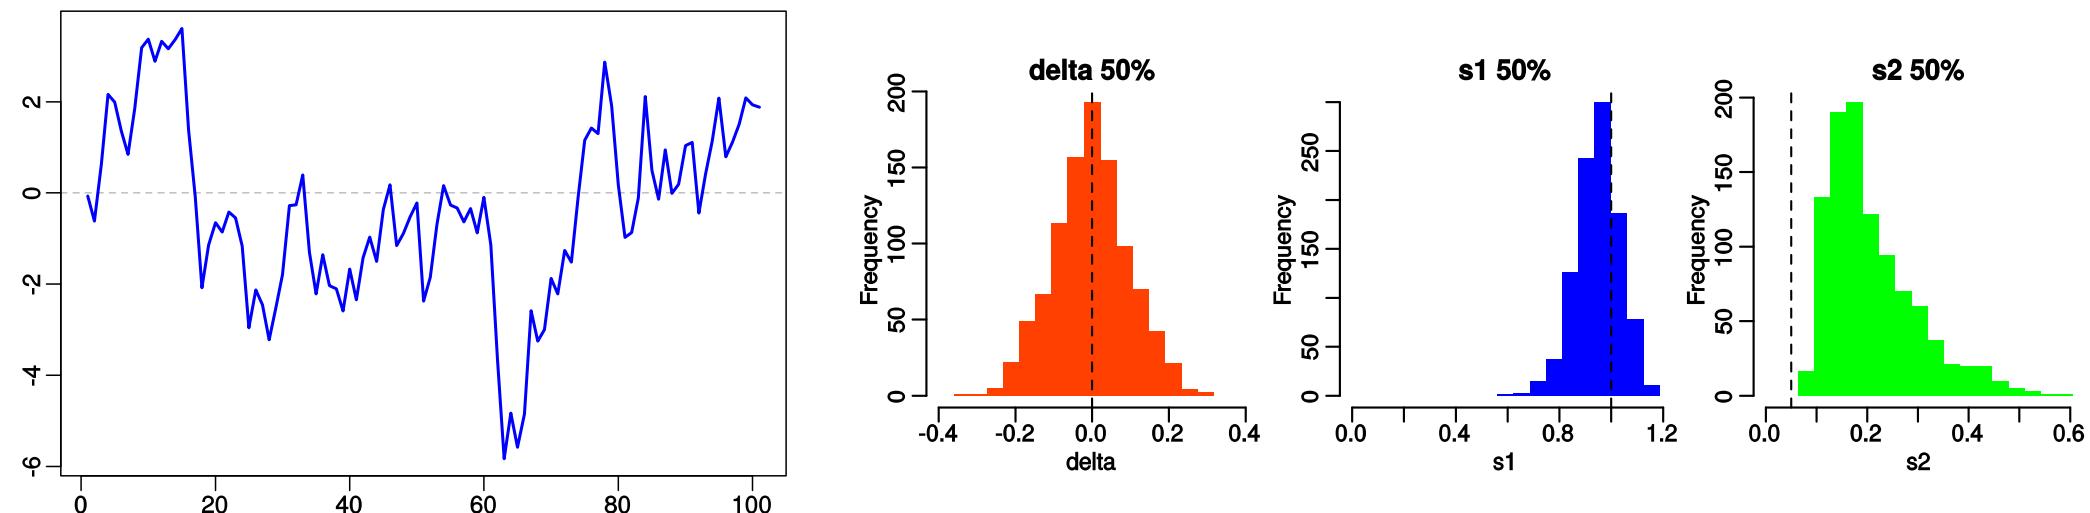
いろいろなランダムウォークが生成される



状態空間モデルを 「かたむきゼロ」ランダムウォーク $\delta = 0$ な架空データにあてはめる

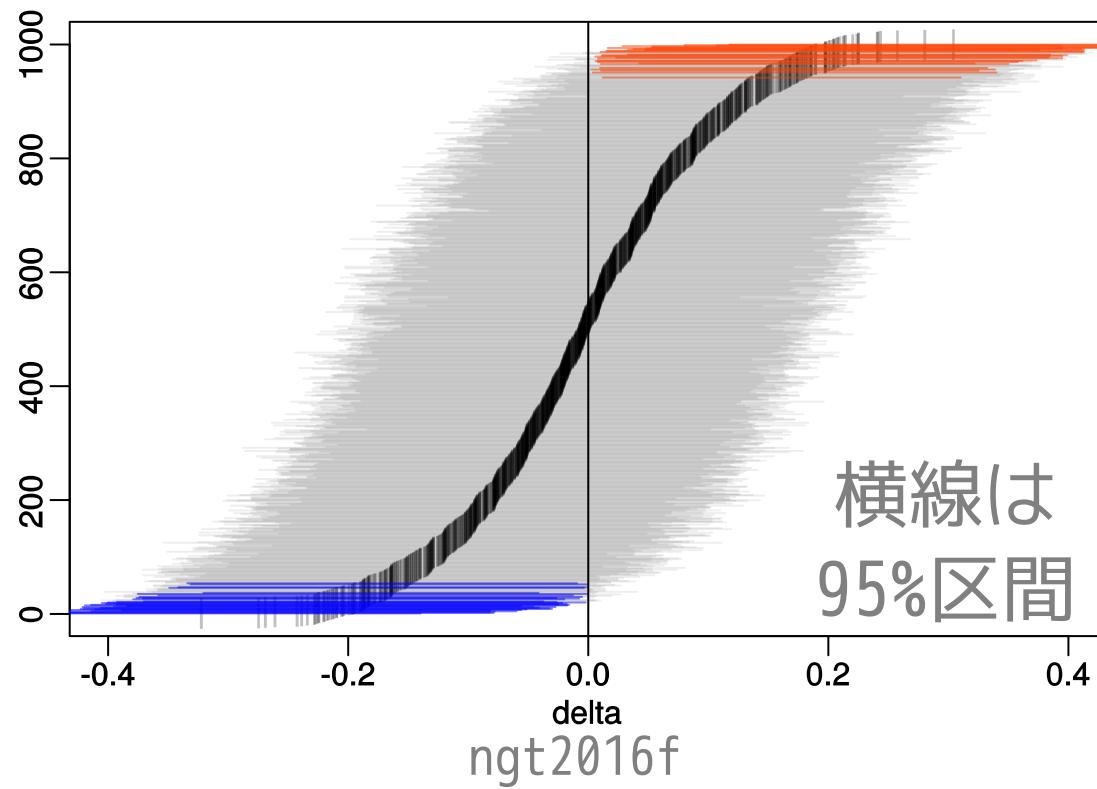


「傾き」 δ の事後分布を見る

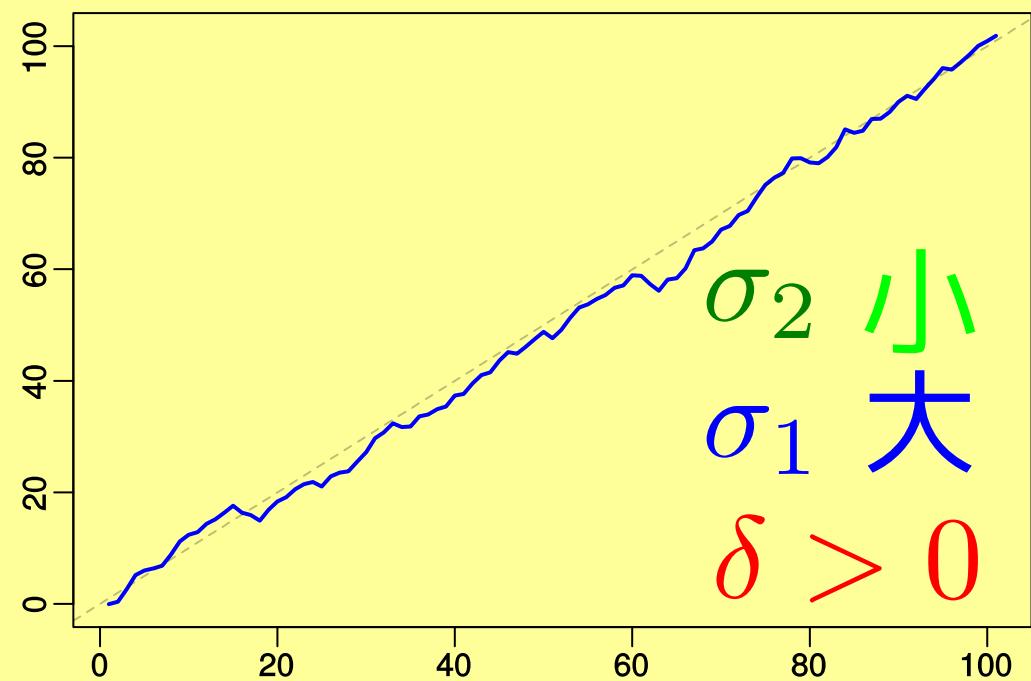
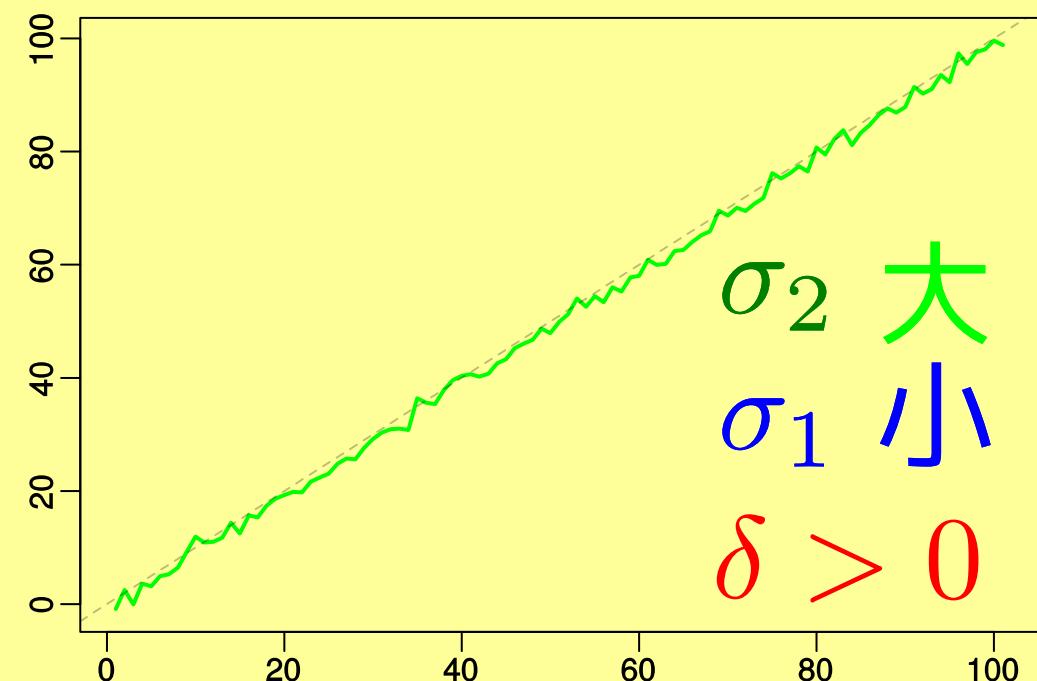


真の δ は 0

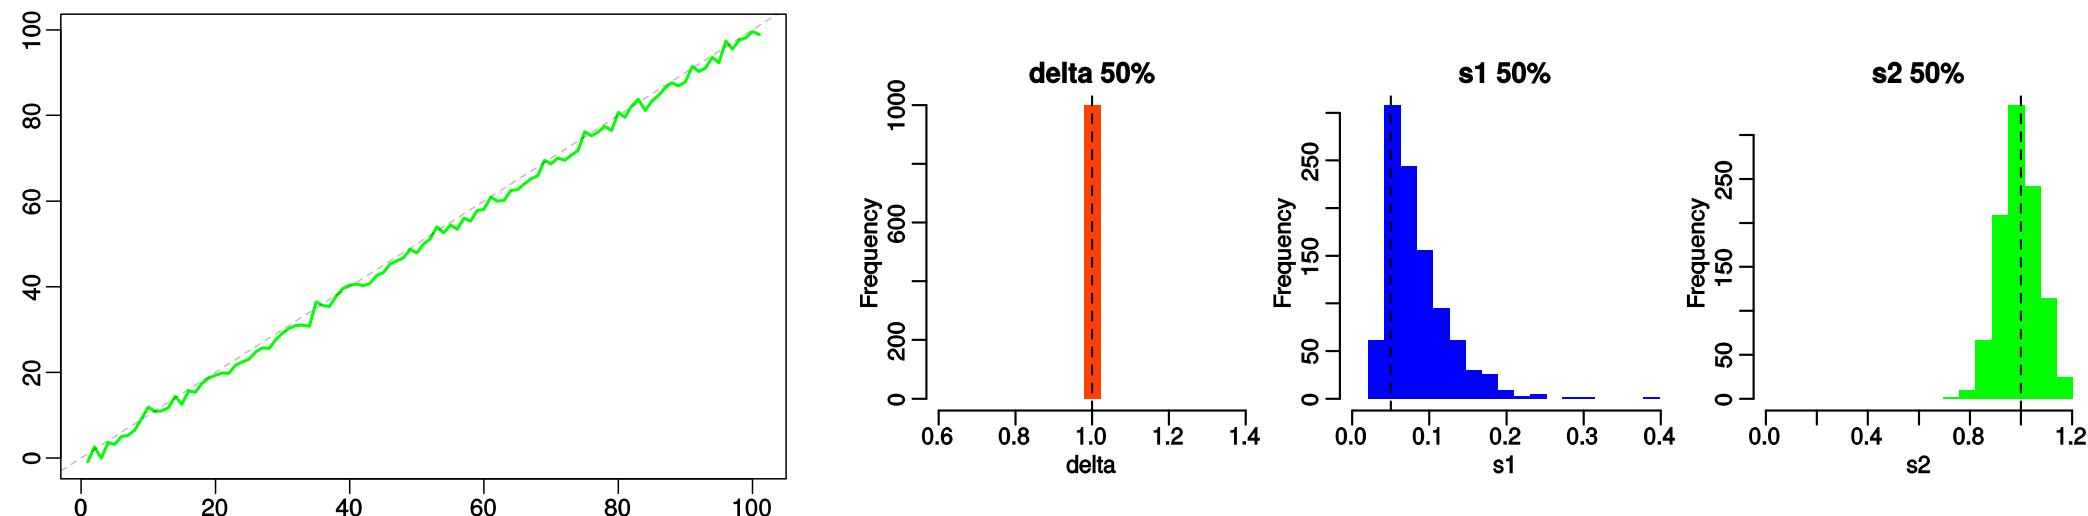
1000回中
63回ずれた



状態空間モデルを
「かたむきあり」ランダムウォーク
 $\delta > 0$
な架空データにあてはめる

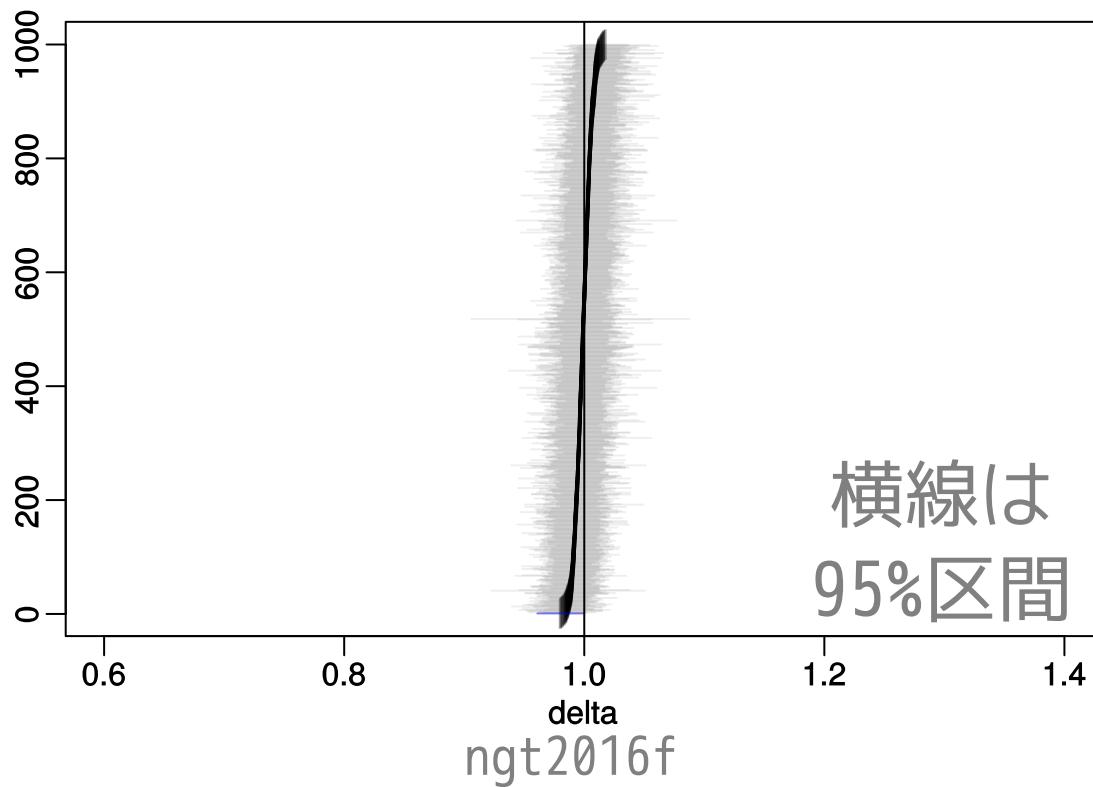


「傾き」 δ の事後分布を見る

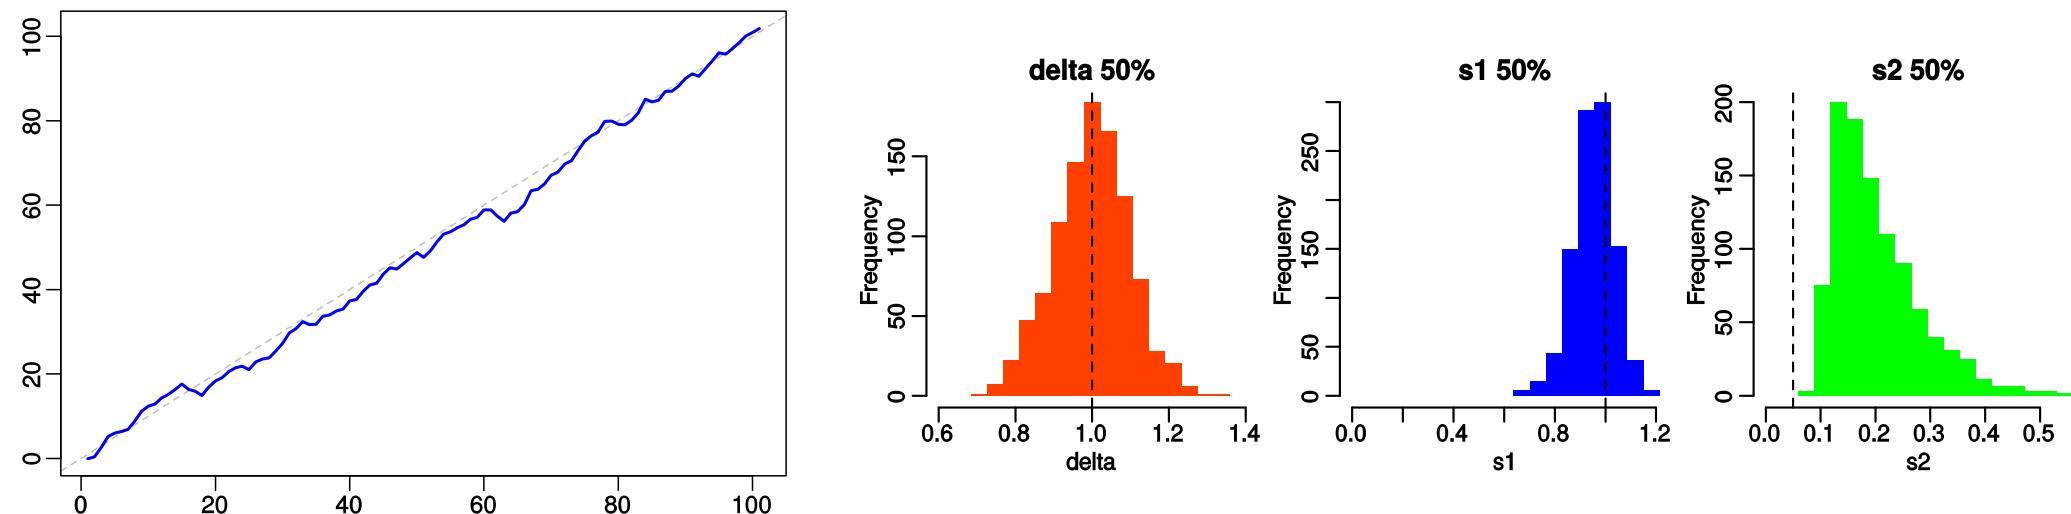


真の δ は 1

1000回中
1回ずれた

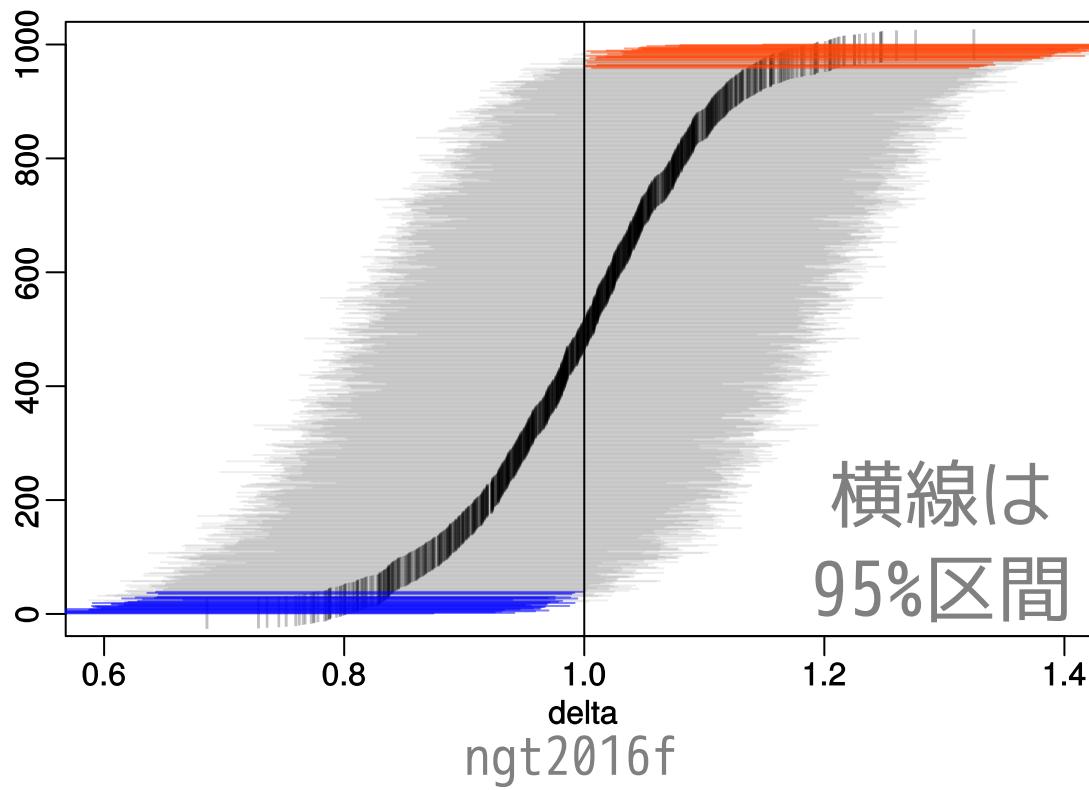


「傾き」 δ の事後分布を見る



真の δ は 1

1000回中
62回ずれた



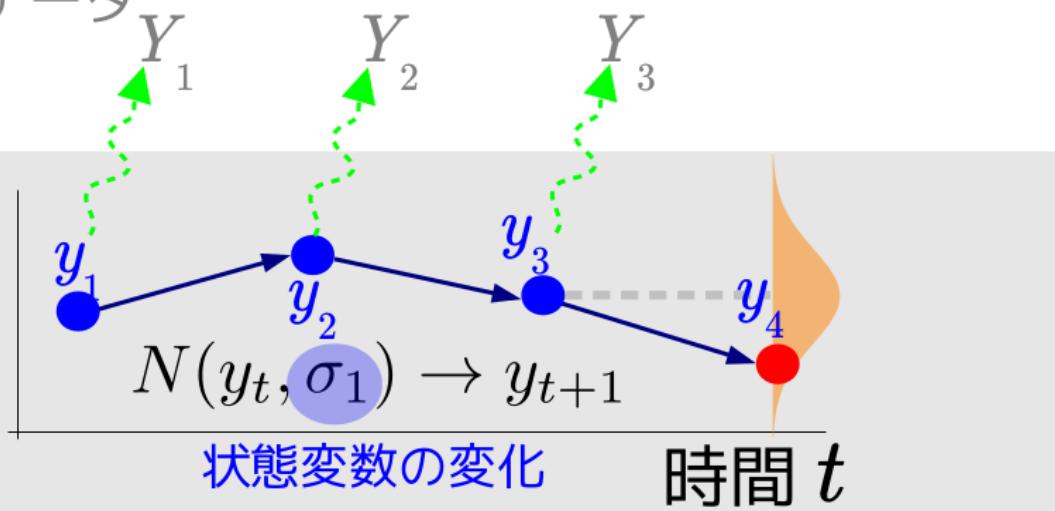
とりあえずの結論

観測の誤差

状態空間モデル

$$N(y_t, \sigma_2) \rightarrow Y_t \quad \text{二種類の } \sigma \text{ をもつ}$$

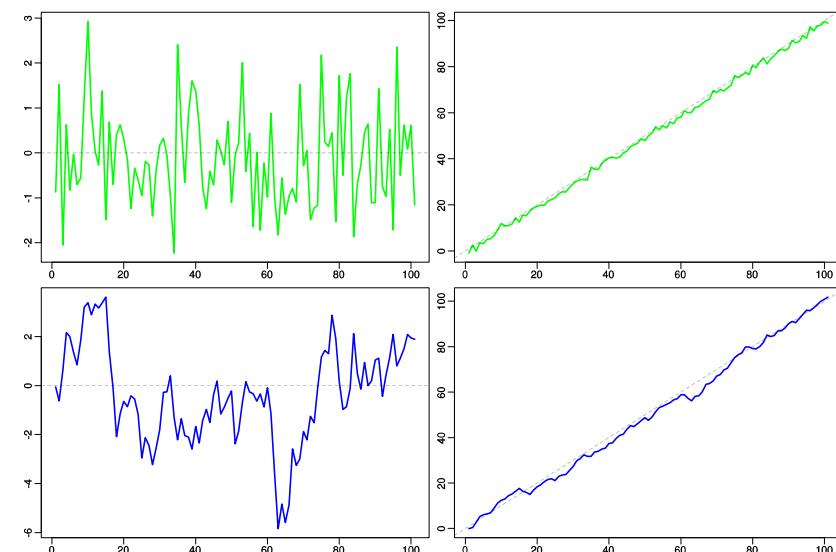
観測データ



ひとつの状態空間
モデルを使って

観測できない世界 (状態空間)

右の4状態は
区別可能でしょう



今回、説明してみたいこと

- ・時系列データ：単純な回帰はダメ（続）
- ・状態空間モデル：乱歩と雑音の分離
- ・欠測と不等間隔
- ・時系列「ばらばら解析」やめよう
- ・「うたがわしい回帰」への対策

階層ベイズモデル!

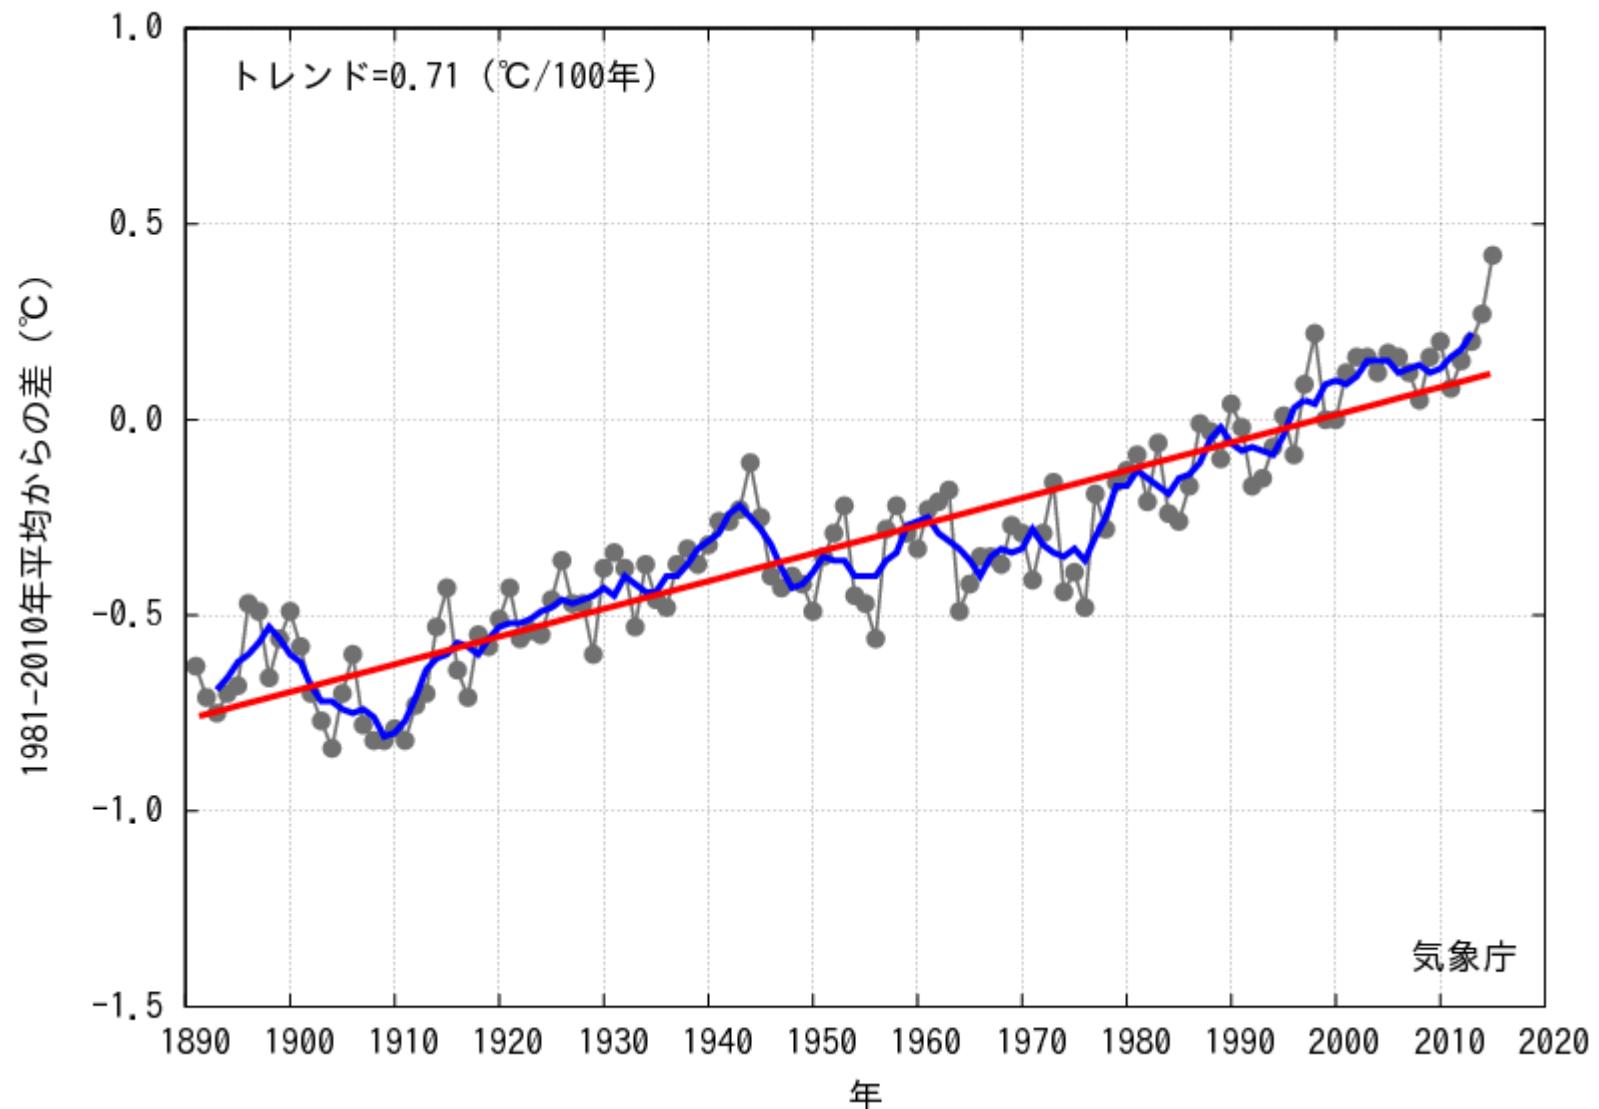
状態空間モデルを使う利点

「ばらばら解析」の回避

気象庁のデータ解析？

気象庁の長期変化傾向（トレンド）の解説

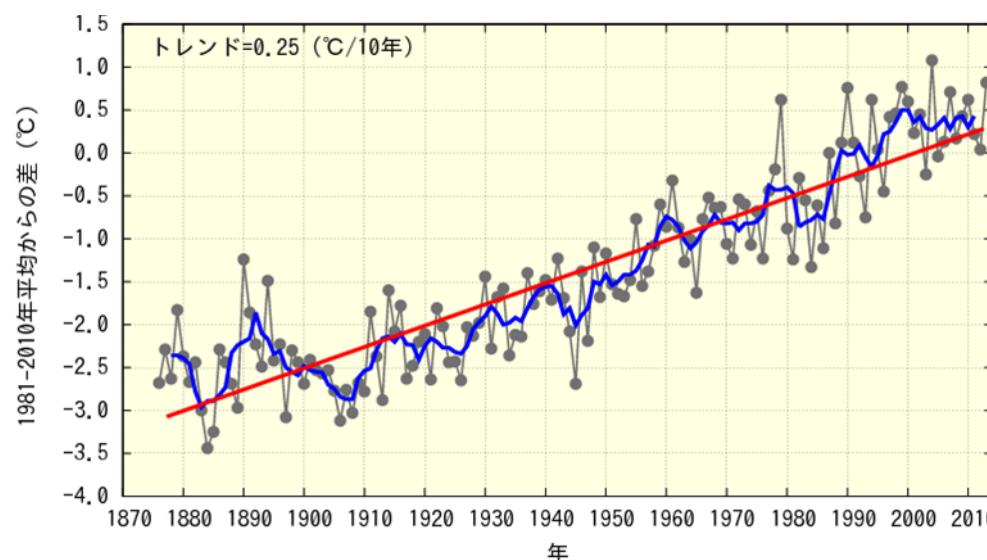
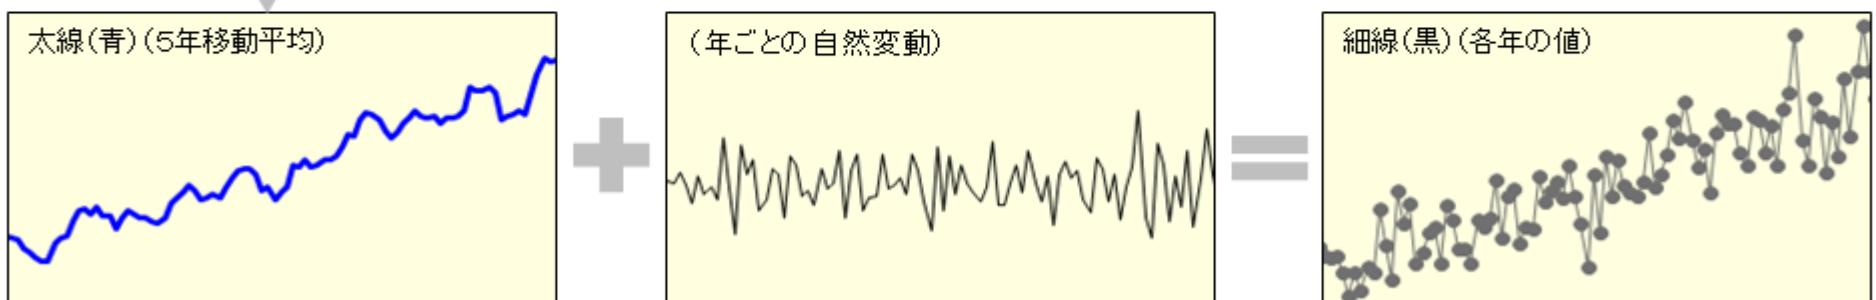
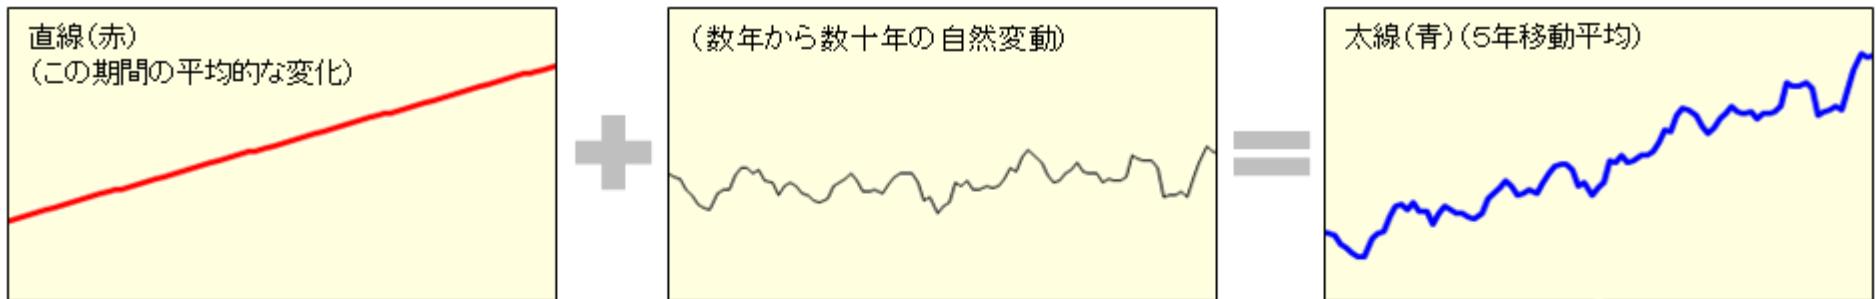
世界の年平均気温偏差



http://www.data.jma.go.jp/cpdinfo/temp/an_wld.html

気象庁の長期変化傾向（トレンド）の解説

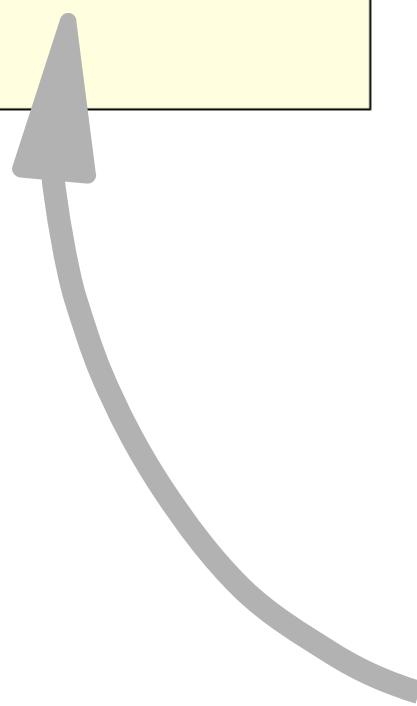
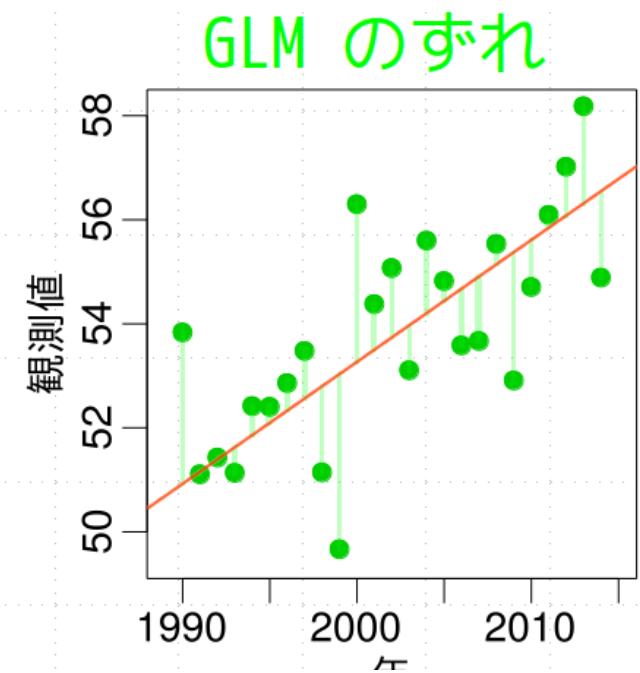
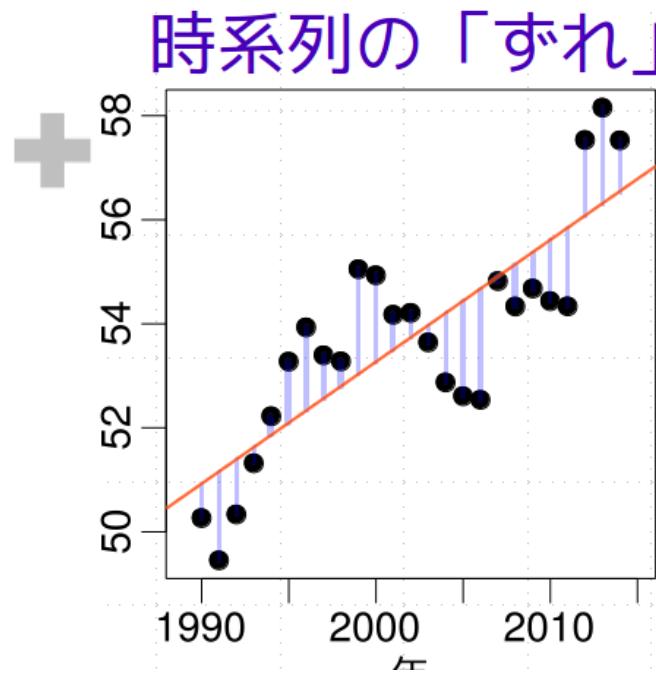
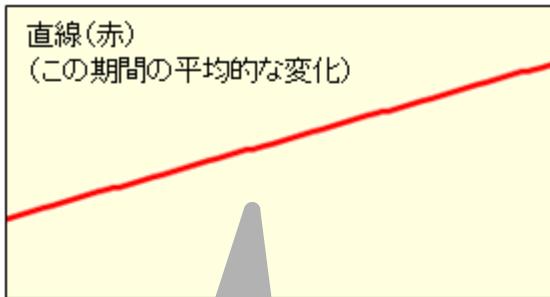
<http://www.data.jma.go.jp/cpdinfo/temp/trend.html>



気象庁
ばらばら
メソッド?

気象庁ばらばらメソッド何がまずいか?

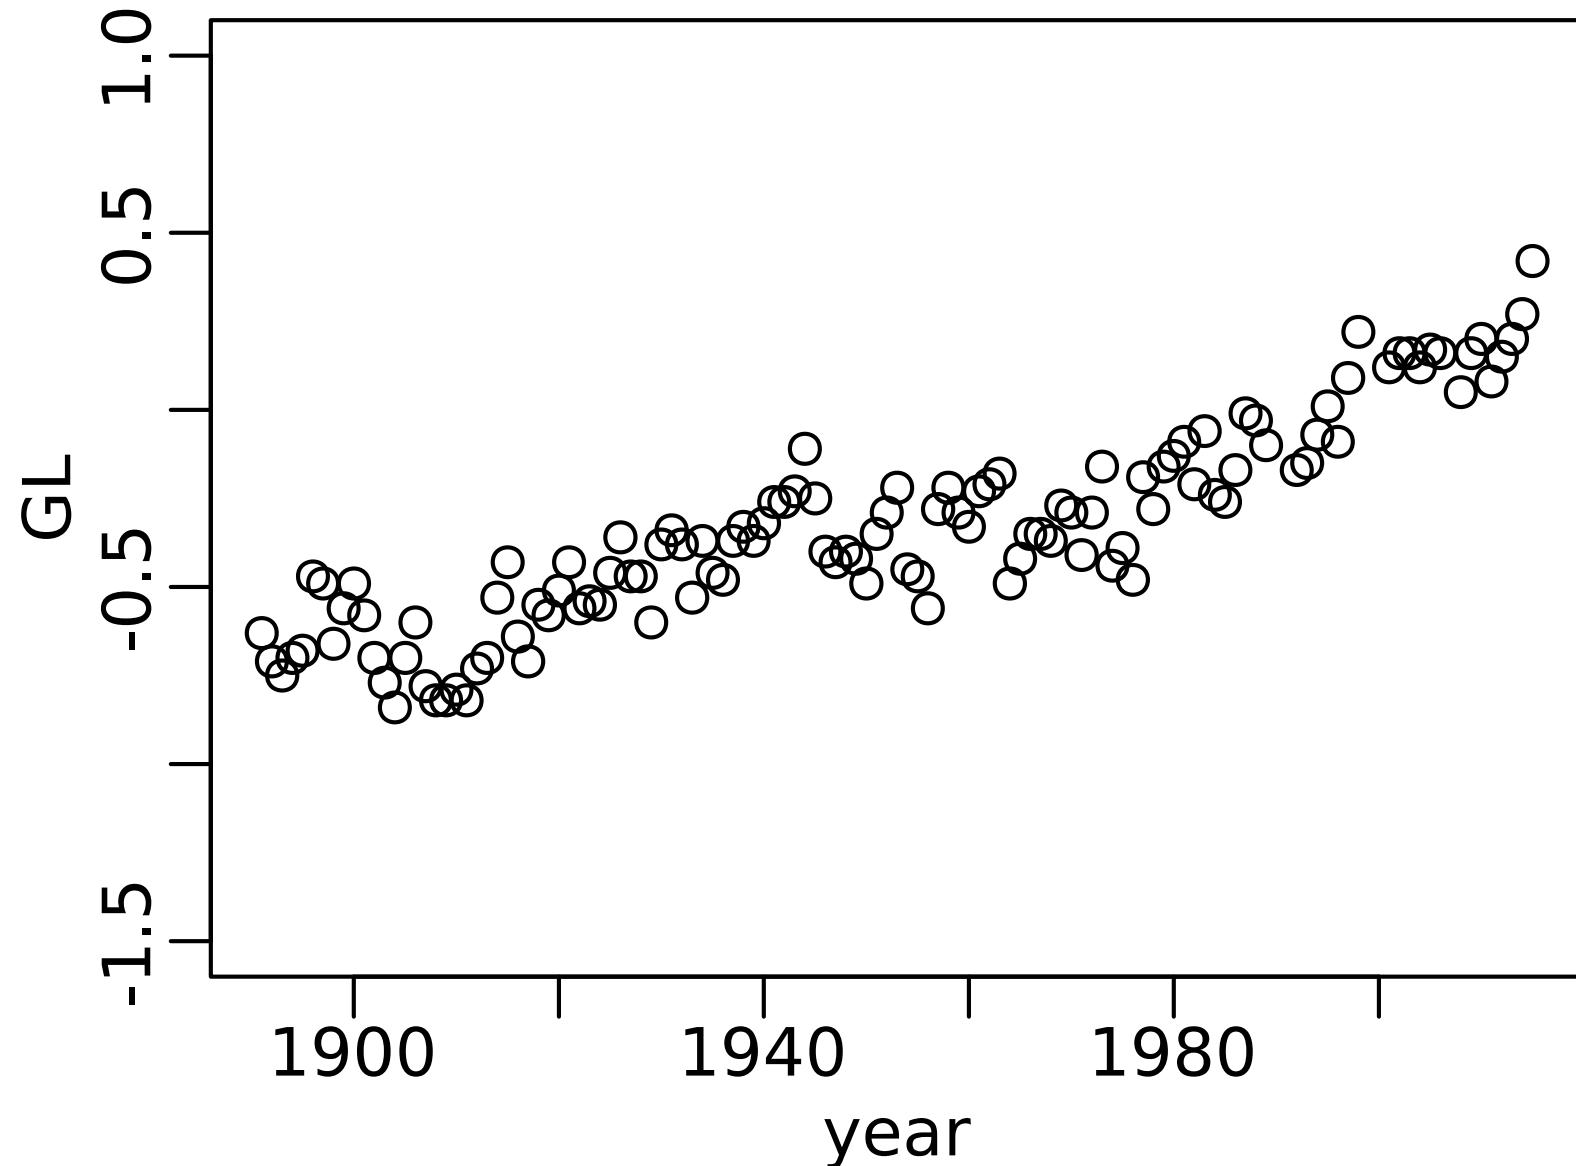
<http://www.data.jma.go.jp/cpdinfo/temp/trend.html>



いきなり直線回帰!

(時系列データなんだから…)

公開データをダウンロード

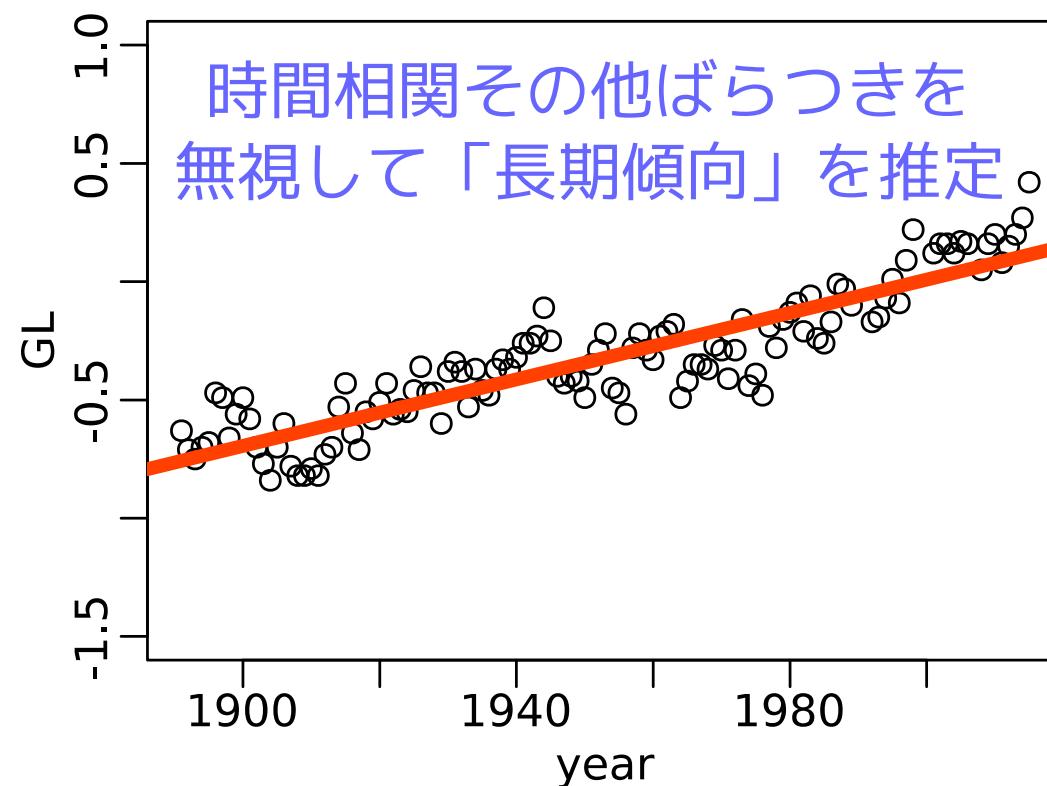


「とりあえず、直線回帰」の危険性

```
> summary(glm(GL ~ year, data = d))
```

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	-1.41e+01	6.21e-01	-22.6	<2e-16
year	7.03e-03	3.18e-04	22.1	<2e-16



確率 1京ぶんの 2?

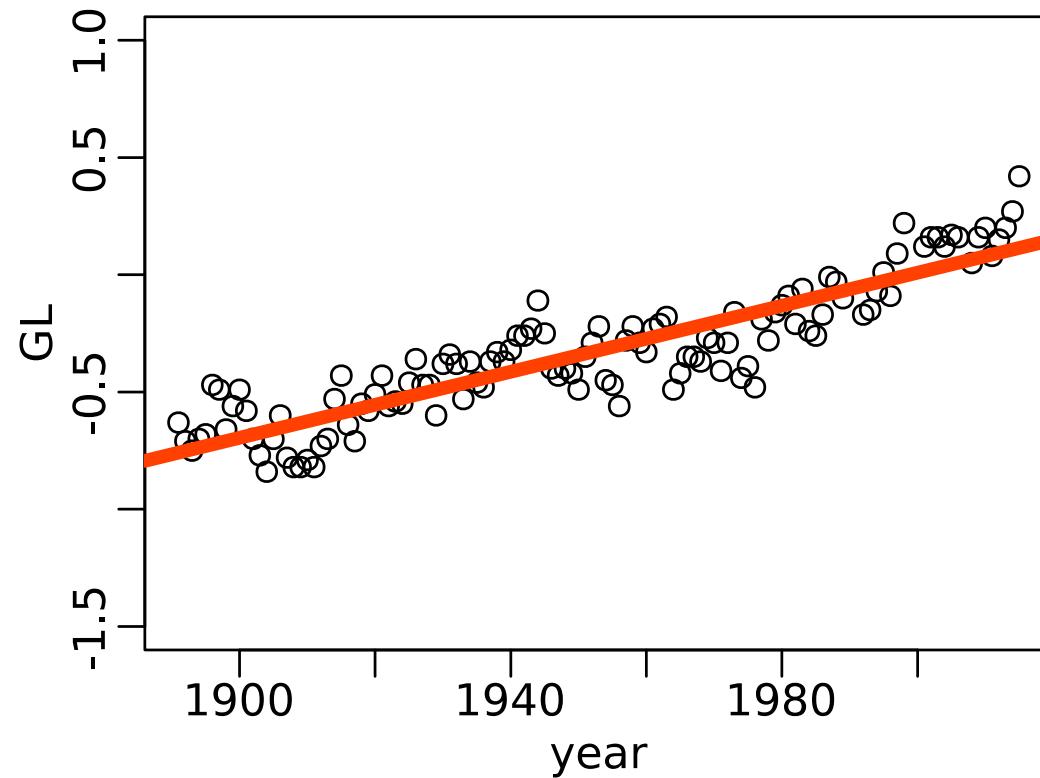
直線あてはめ (GLM) が予測した「温暖化」

```
> summary(glm(GL ~ year, data = d))
```

Coefficients:

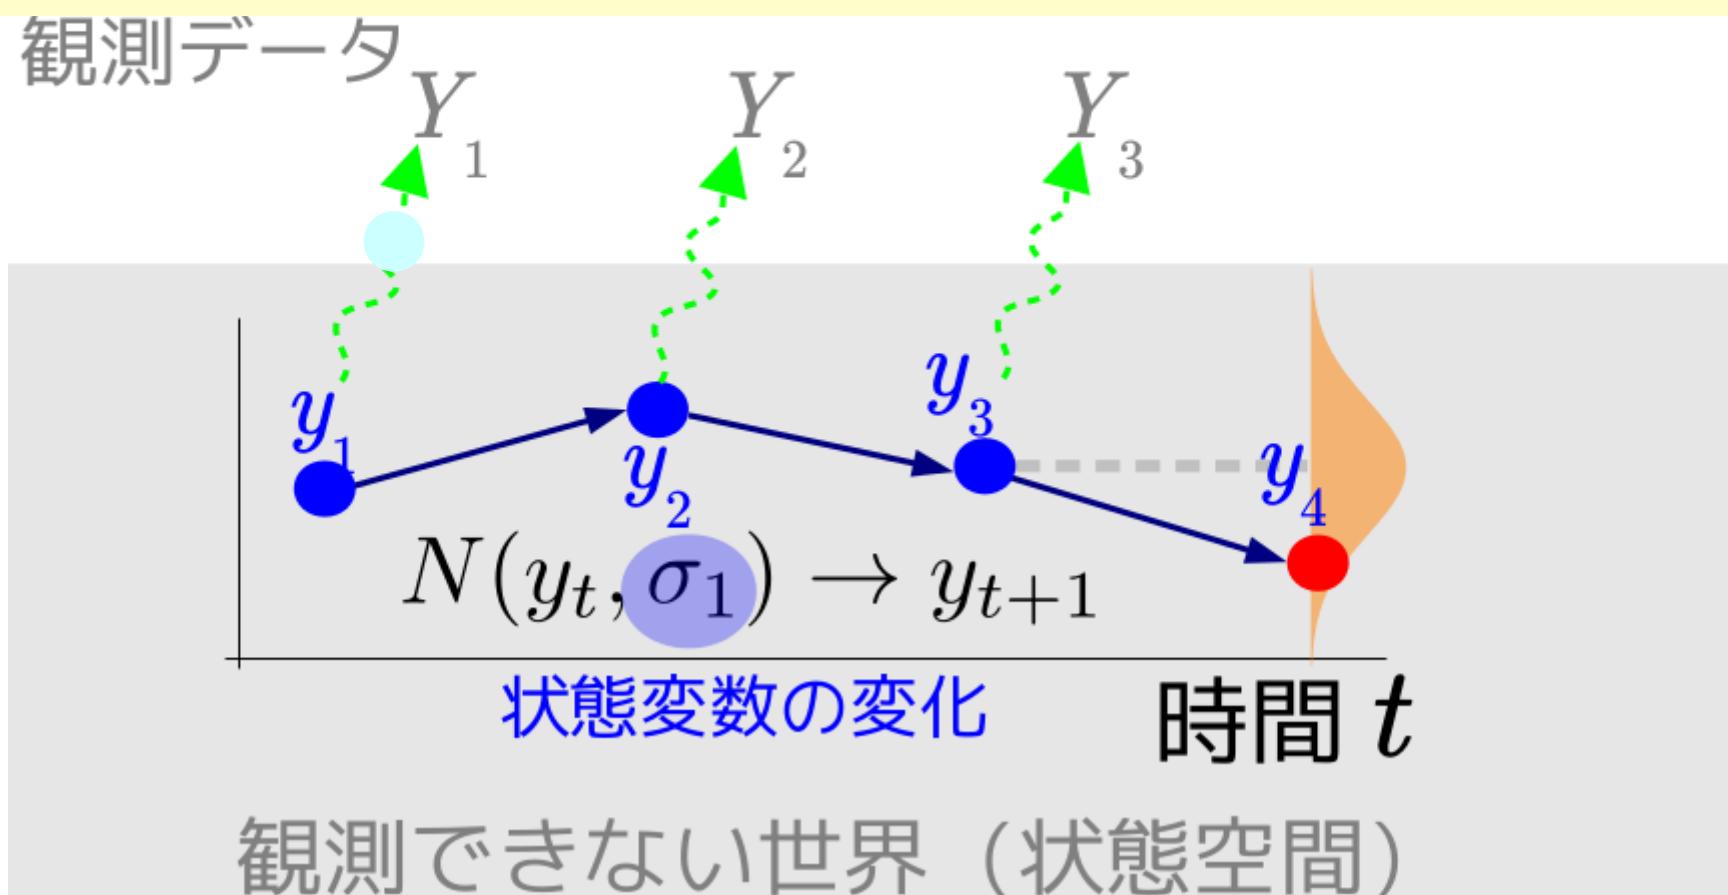
	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	-1.41e+01	6.21e-01	-22.6	<2e-16
year	7.03e-03	3.18e-04	22.1	<2e-16

100年
あたり
0.70°C



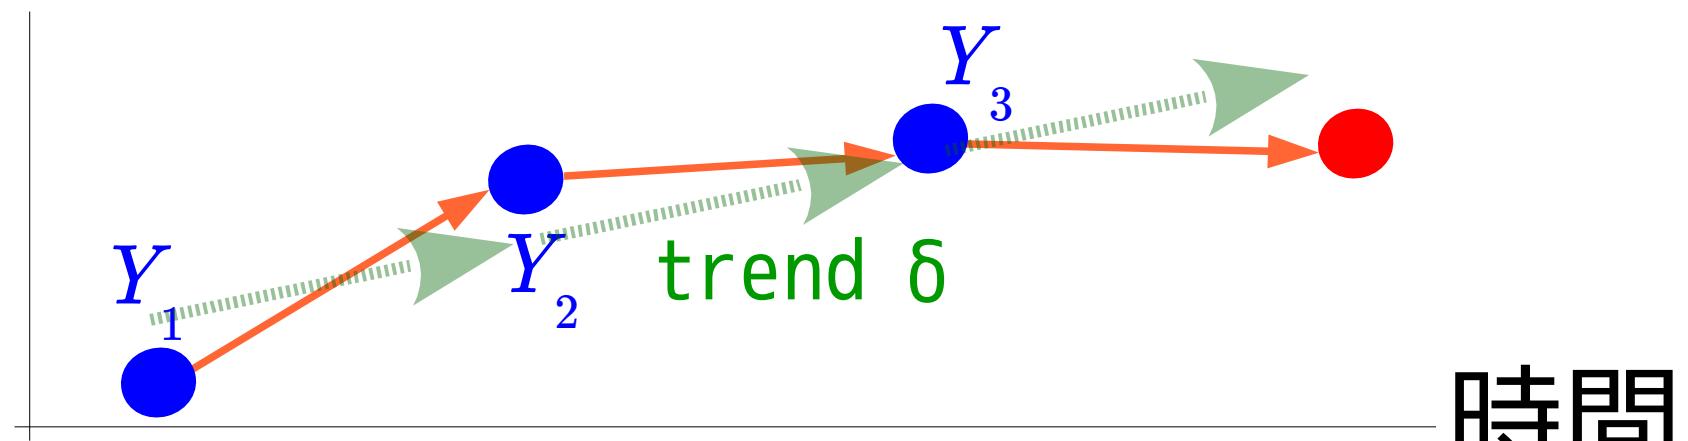
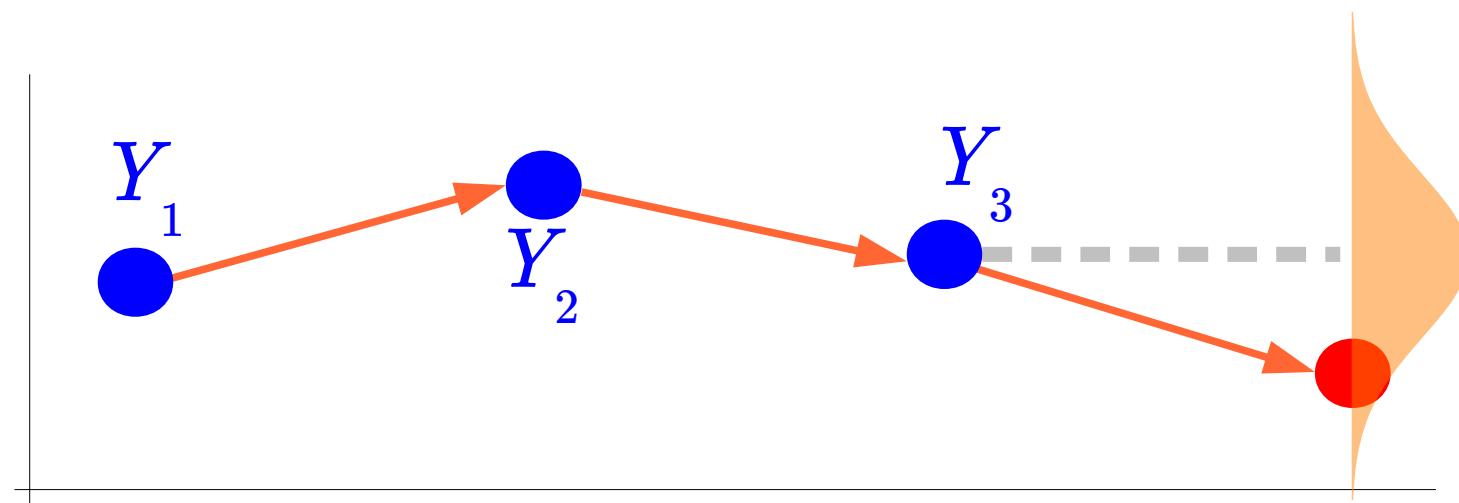
状態空間モデル：すべてを同時に推定

ランダムウォーク+各年独立なノイズ



状態空間モデル：すべてを同時に推定

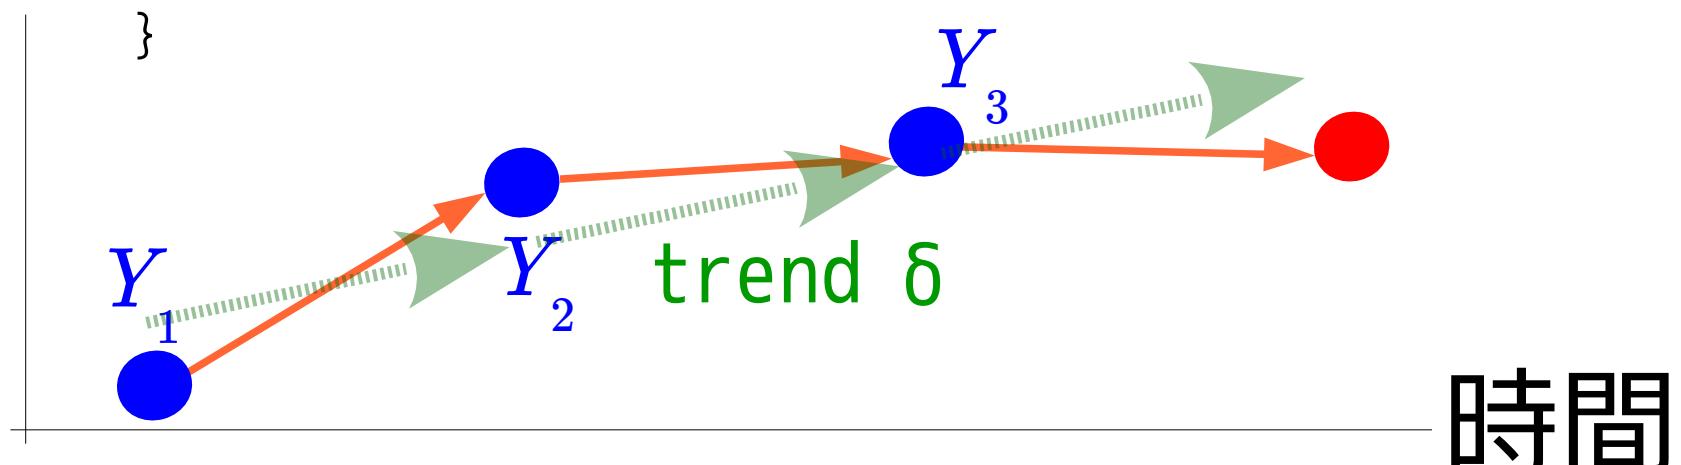
ランダムウォーク+各年独立なノイズ



時間

状態空間モデル：すべてを同時に推定

```
Y[1] ~ dnorm(y[1], tau[2])
y[1] ~ dnorm(0.0, Tau.Noninformative)
for (t in 2:N.Y) {
  Y[t] ~ dnorm(y[t], tau[2])
  y[t] ~ dnorm(m[t], tau[1])
  m[t] <- delta + y[t - 1]
}
delta ~ dnorm(0, Tau.Noninformative)
for (k in 1:2) {
  tau[k] <- 1.0 / (s[k] * s[k])
  s[k] ~ dunif(0, 1.0E+4)
}
```



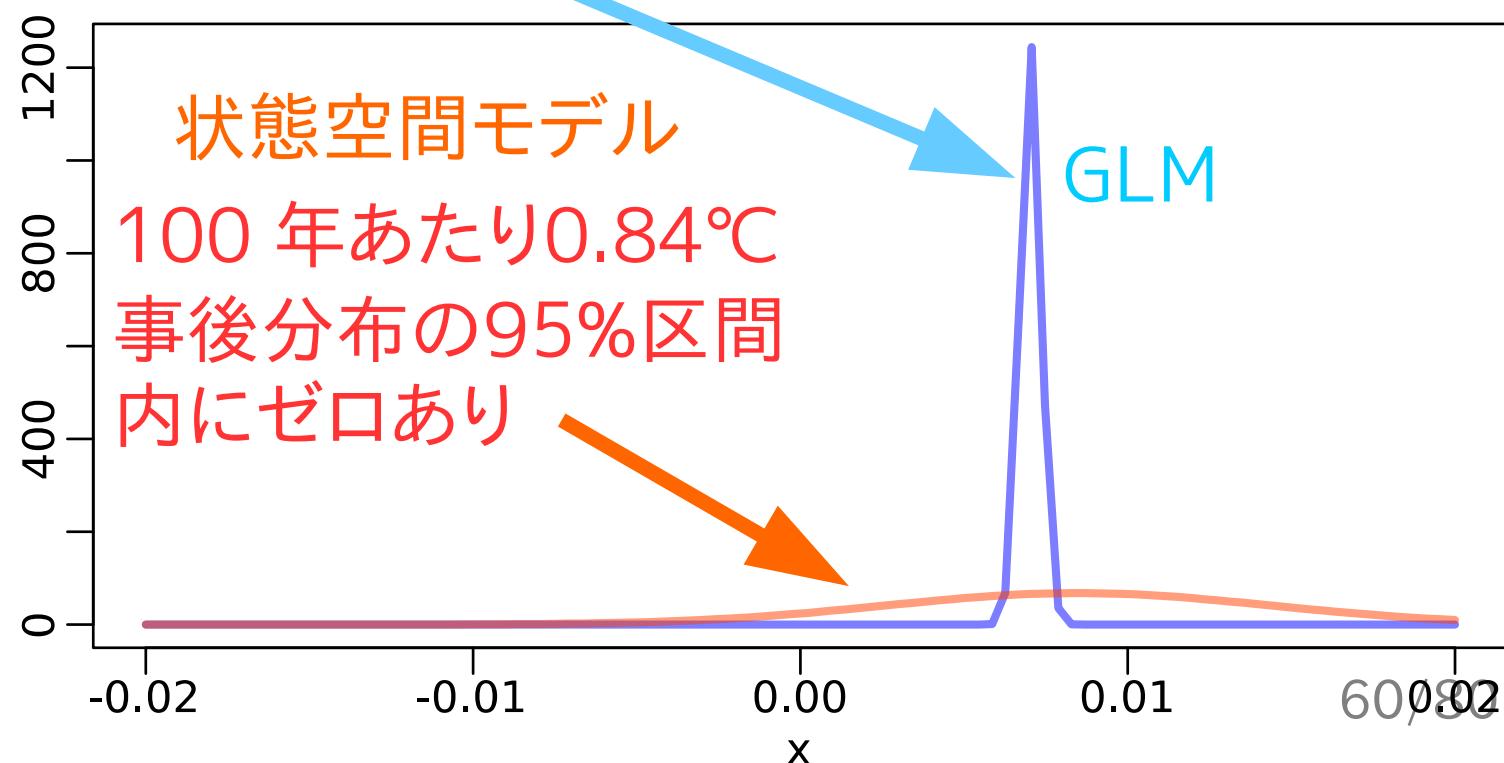
状態空間モデルが予測した「温暖化」

```
> summary(glm(GL ~ year, data = d))
```

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	-1.41e+01	6.21e-01	-22.6	<2e-16
year	7.03e-03	3.18e-04	22.1	<2e-16

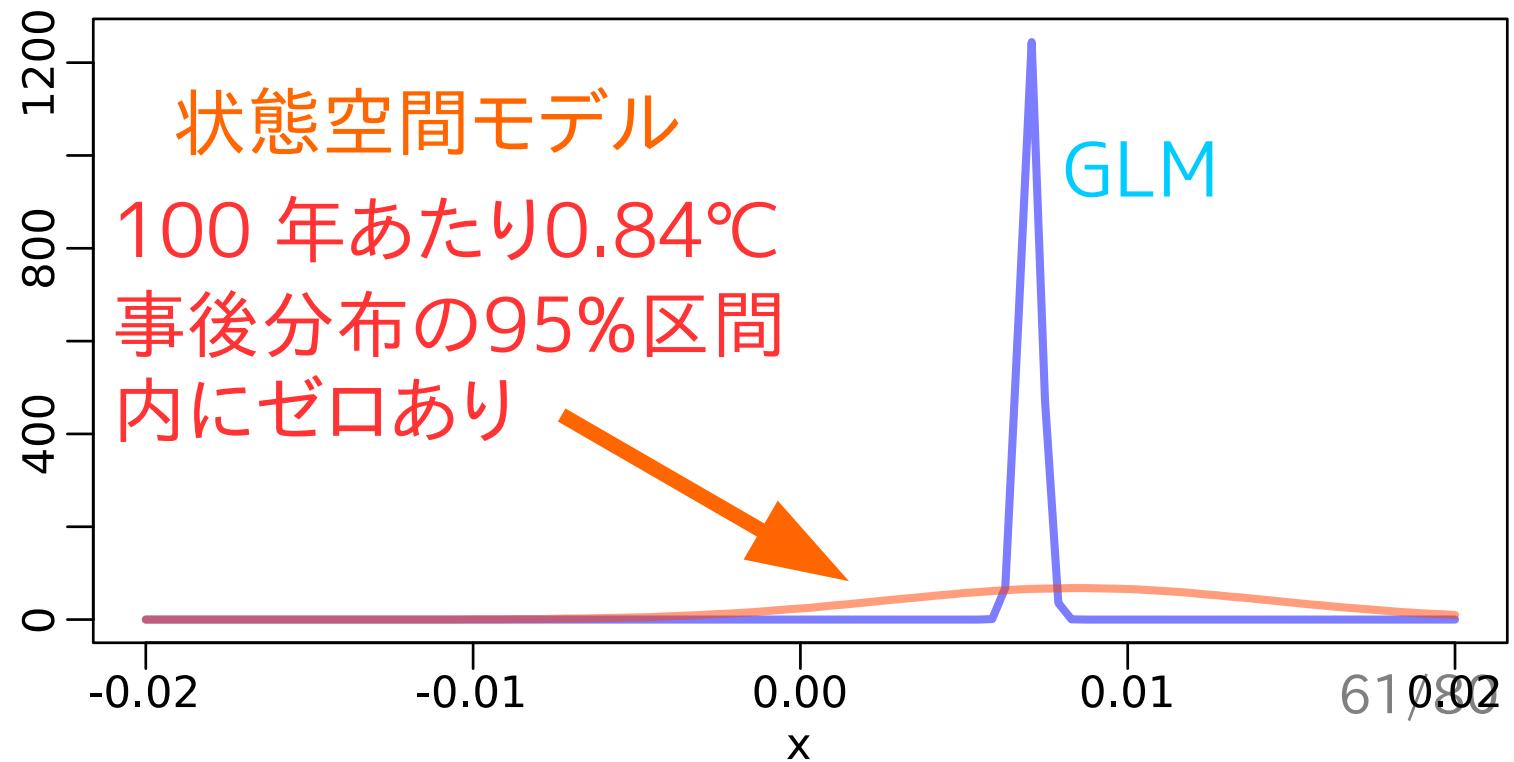
100年
あたり
0.70°C



観測値間に相関あり →

実質的な
サンプルサイズが小さくなる

100年
あたり
 0.70°C



疑わしい回帰

spurious regression

時系列どうしの回帰

time series $Y \sim$ time series X

時系列データの統計モデリング

でやめたほうがいいこと

- GLM: $Y(t) \sim t$ とか $Y(t) \sim X(t)$
- 段階的解析: 観測値の四則演算
- 「残差」の再解析
- 「対応」の無視 – 再測は時系列

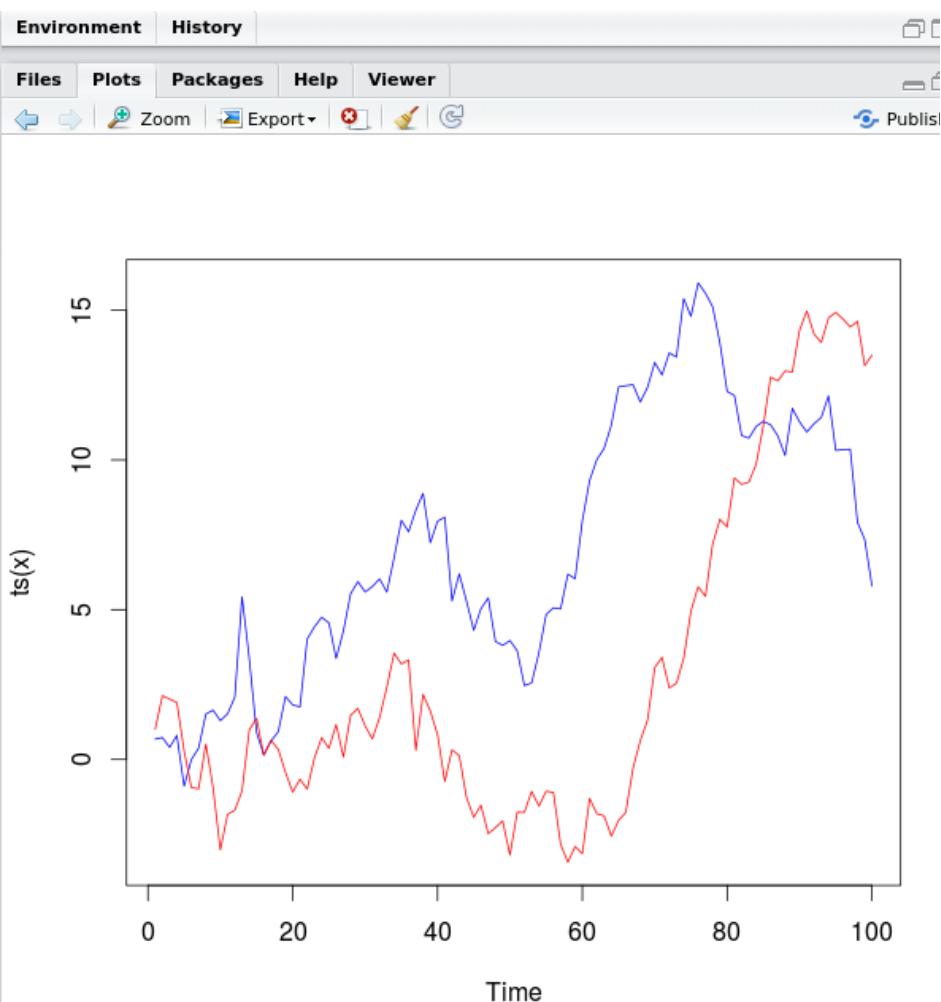
「見せかけの回帰」 spurious regression

The screenshot shows the RStudio interface. In the top-left pane, there is an R script named "spurious_regression.R" with the following content:

```
1 x <- cumsum(rnorm(100))
2 y <- cumsum(rnorm(100))
3 plot(ts(x), col = "blue", ylim = range(x, y))
4 lines(ts(y), col = "red")
5 print(summary(glm(y ~ x))$coefficients)
```

In the bottom-left pane, the "Console" tab shows the execution of the script:

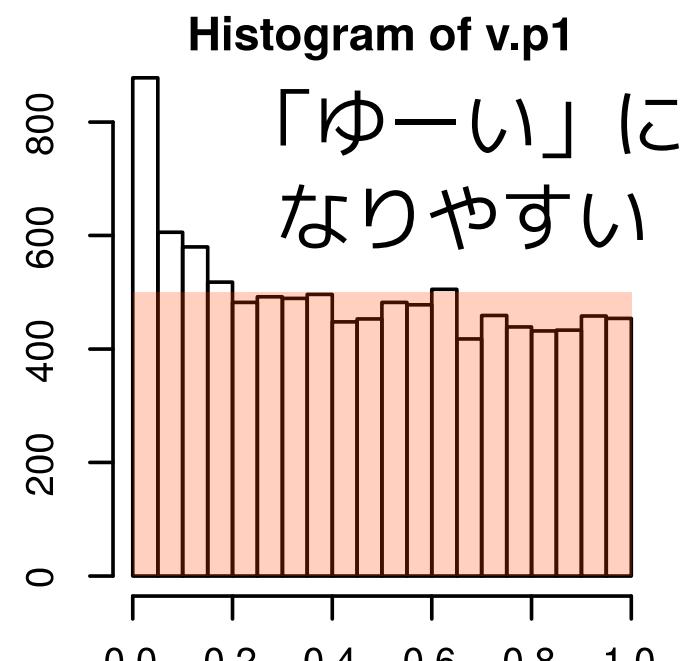
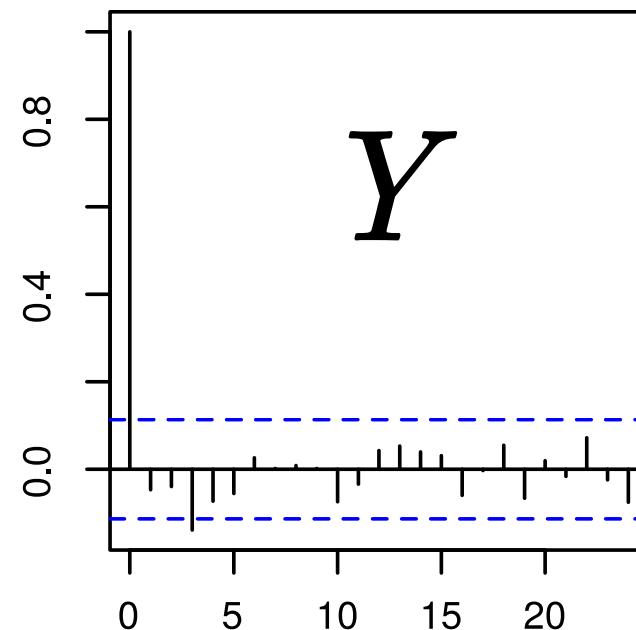
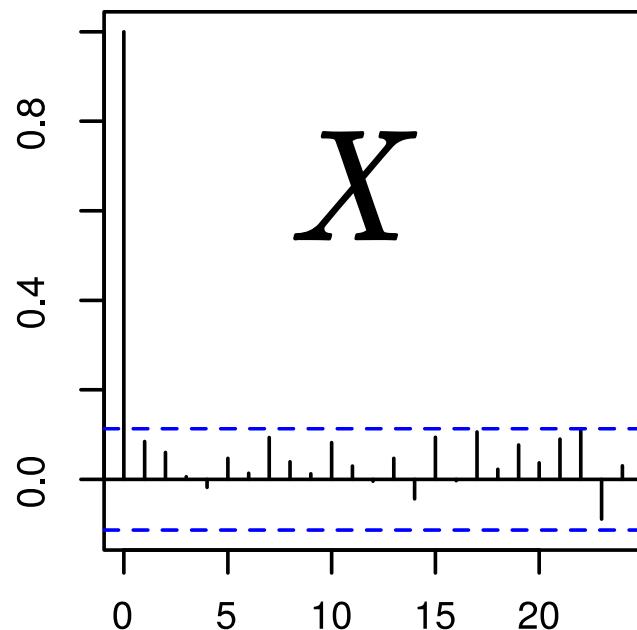
```
> plot(ts(x), col = "blue", ylim = range(x, y))
> lines(ts(y), col = "red")
> print(summary(glm(y ~ x))$coefficients)
   Estimate Std. Error t value Pr(>|t|)
(Intercept) -1.67120    0.90288 -1.8510 6.7186e-02
x             0.64551    0.10803  5.9753 3.7127e-08
```



ちょっとだけ実演してみます

ノイズの大きな時系列にうもれたワナ？

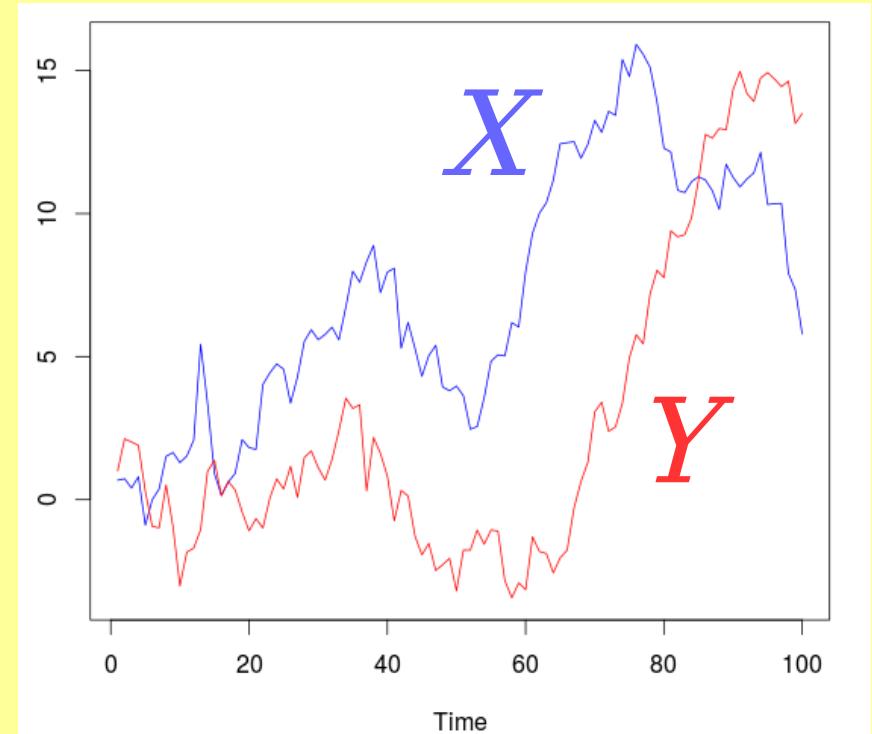
時間的自己相関のない時系列？



しかし $\text{glm}(Y \sim X)$ とすると…

$Y \sim X$

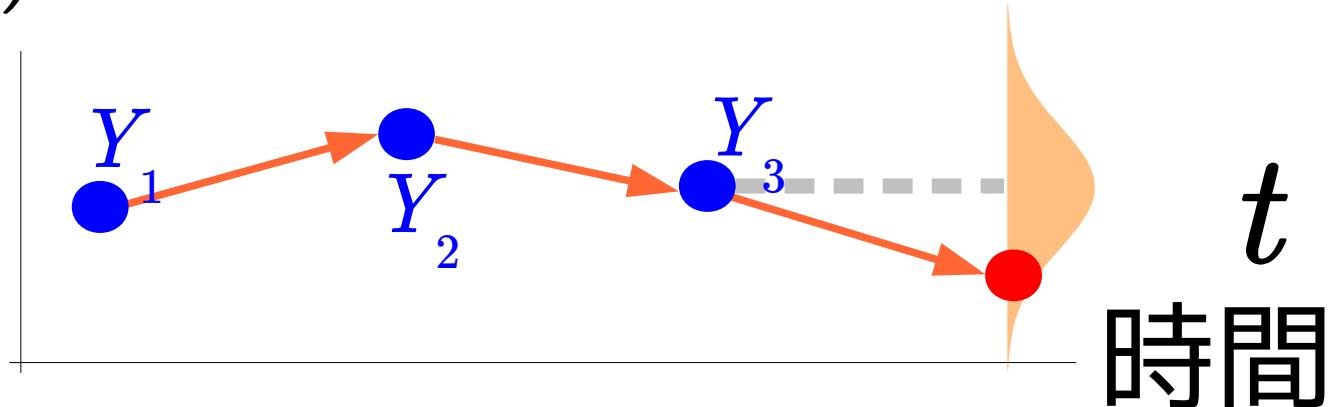
疑わしい回帰
spurious
regression



この問題も
状態空間モデル (SSM) で
解決できないだろうか?

二変量のランダムウォーク モデルを作れないか?

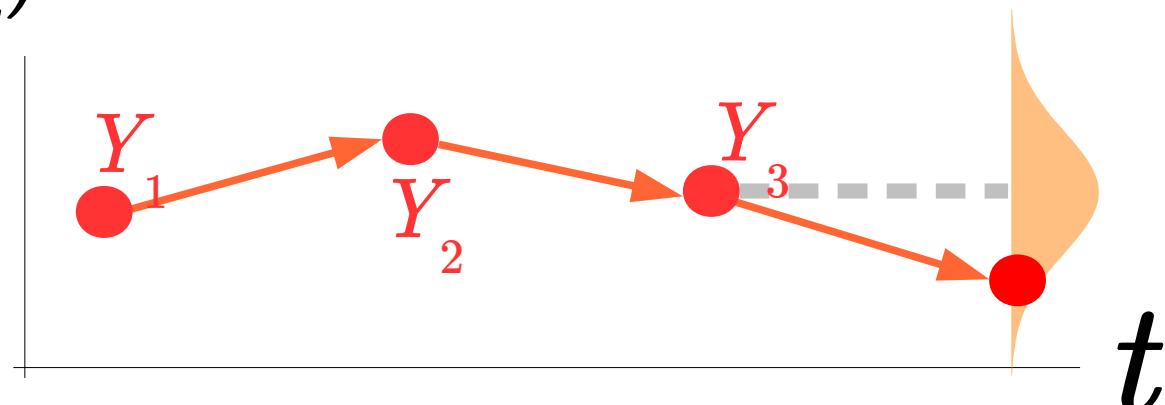
$$Y_{t+1} \sim N(Y_t, s_y)$$



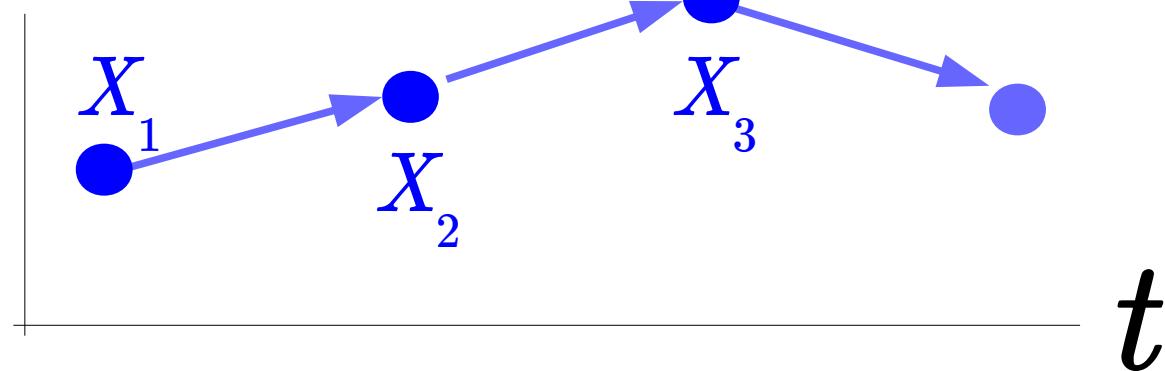
二変量のランダムウォーク

Y_t と X_t は独立

$$Y_{t+1} \sim N(Y_t, s_y)$$



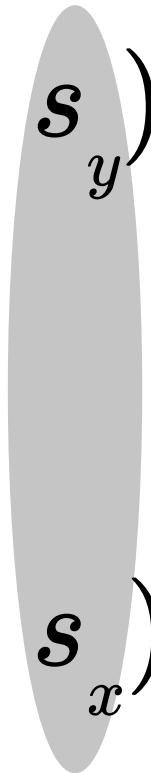
$$X_{t+1} \sim N(X_t, s_x)$$



二変量のランダムウォーク

Y_t と X_t は独立

$$Y_{t+1} \sim N(Y_t, s_y)$$

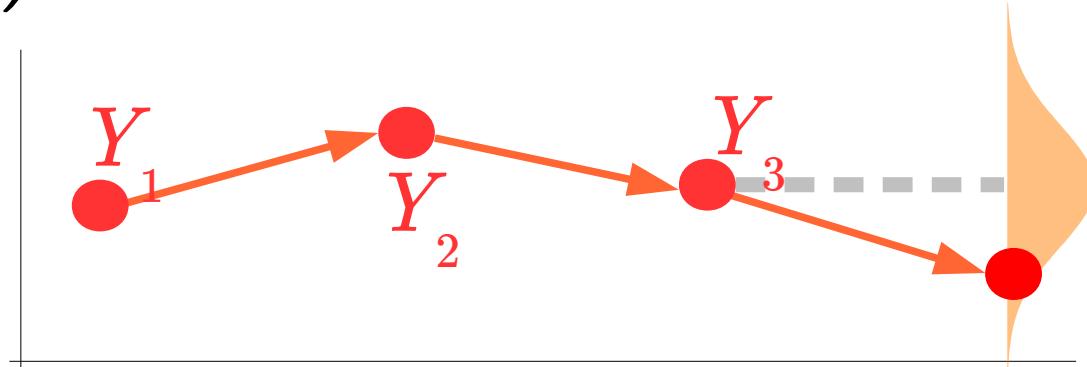


$$X_{t+1} \sim N(X_t, s_x)$$

このあたりで

何とかならないか?

$Y_{t+1} \sim N(Y_t, s_y)$ 一変量の正規分布(密度関数)



二変量の正規分布(密度関数)

Bivariate case

In the 2-dimensional nonsingular case ($k = \text{rank}(\Sigma) = 2$), the probability density function of a vector $[X \ Y]'$ is:

$$f(x, y) = \frac{1}{2\pi\sigma_X\sigma_Y\sqrt{1-\rho^2}} \exp\left(-\frac{1}{2(1-\rho^2)} \left[\frac{(x - \mu_X)^2}{\sigma_X^2} + \frac{(y - \mu_Y)^2}{\sigma_Y^2} - \frac{2\rho(x - \mu_X)(y - \mu_Y)}{\sigma_X\sigma_Y} \right]\right)$$

where ρ is the correlation between X and Y and where $\sigma_X > 0$ and $\sigma_Y > 0$. In this case,

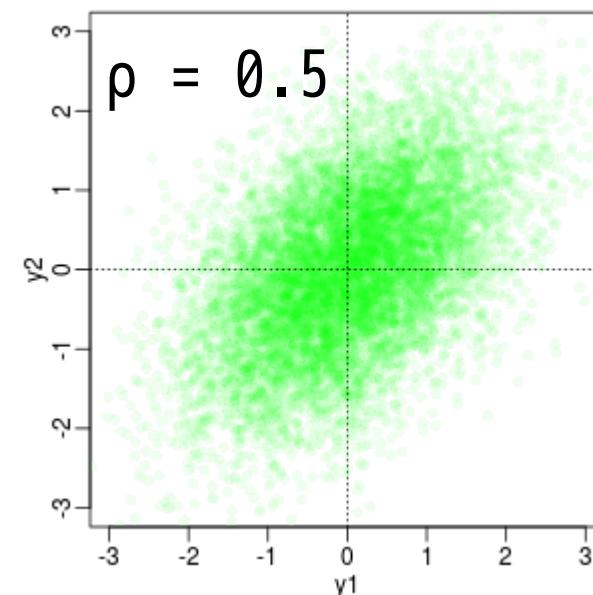
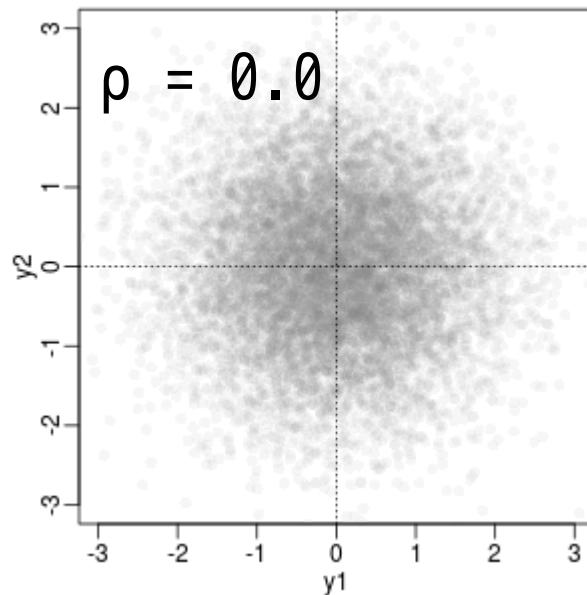
$$\boldsymbol{\mu} = \begin{pmatrix} \mu_X \\ \mu_Y \end{pmatrix}, \quad \boldsymbol{\Sigma} = \begin{pmatrix} \sigma_X^2 & \rho\sigma_X\sigma_Y \\ \rho\sigma_X\sigma_Y & \sigma_Y^2 \end{pmatrix}.$$

相関係数 ρ

分散共分散行列

https://en.wikipedia.org/wiki/Multivariate_normal_distribution

無相関



正の相関

二変量の正規分布(密度関数)

Bivariate case

In the 2-dimensional nonsingular case ($k = \text{rank}(\Sigma) = 2$), the probability density function of a vector $[X \ Y]'$ is:

$$f(x, y) = \frac{1}{2\pi\sigma_X\sigma_Y\sqrt{1-\rho^2}} \exp\left(-\frac{1}{2(1-\rho^2)} \left[\frac{(x-\mu_X)^2}{\sigma_X^2} + \frac{(y-\mu_Y)^2}{\sigma_Y^2} - \frac{2\rho(x-\mu_X)(y-\mu_Y)}{\sigma_X\sigma_Y} \right]\right)$$

where ρ is the correlation between X and Y and where $\sigma_X > 0$ and $\sigma_Y > 0$. In this case,

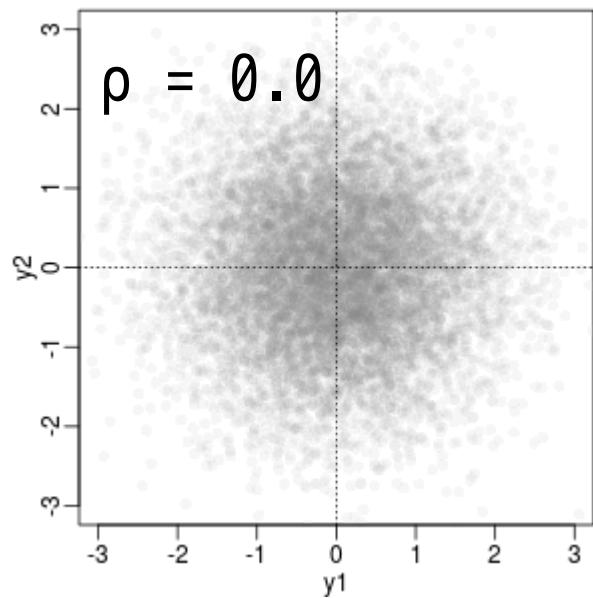
$$\boldsymbol{\mu} = \begin{pmatrix} \mu_X \\ \mu_Y \end{pmatrix}, \quad \boldsymbol{\Sigma} = \begin{pmatrix} \sigma_X^2 & \rho\sigma_X\sigma_Y \\ \rho\sigma_X\sigma_Y & \sigma_Y^2 \end{pmatrix}.$$

相関係数 ρ

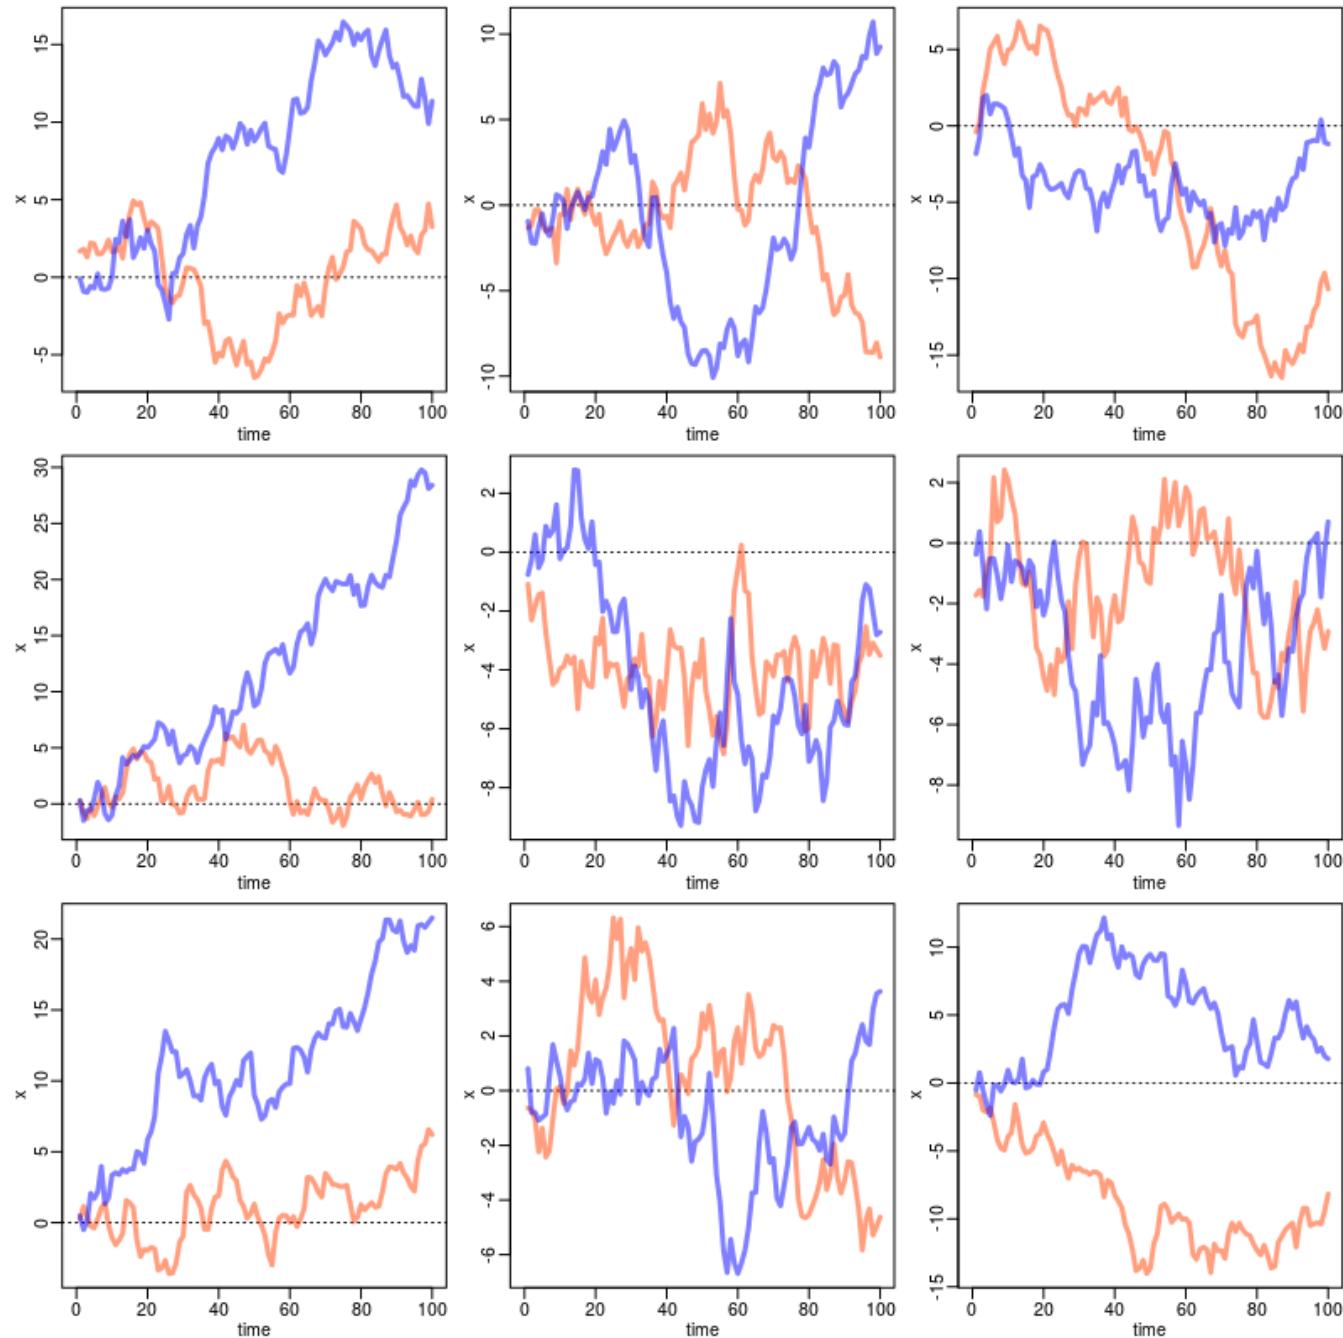
分散共分散行列

https://en.wikipedia.org/wiki/Multivariate_normal_distribution

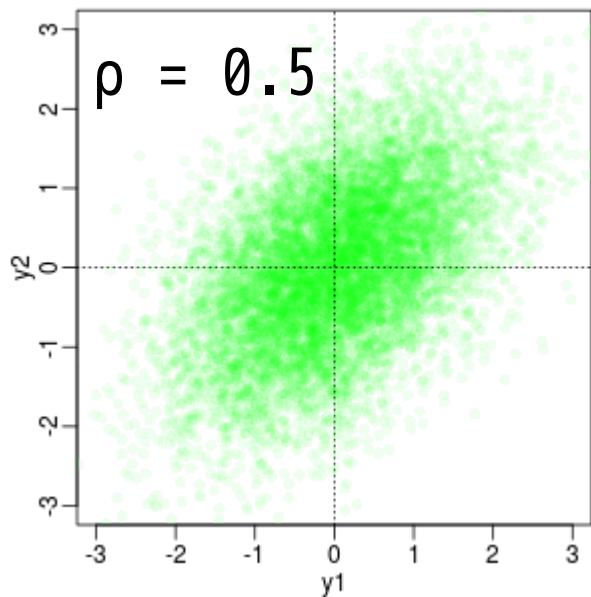
二変量正規分布とランダムウォーク 例1



無相関



二変量正規分布とランダムウォーク 例2

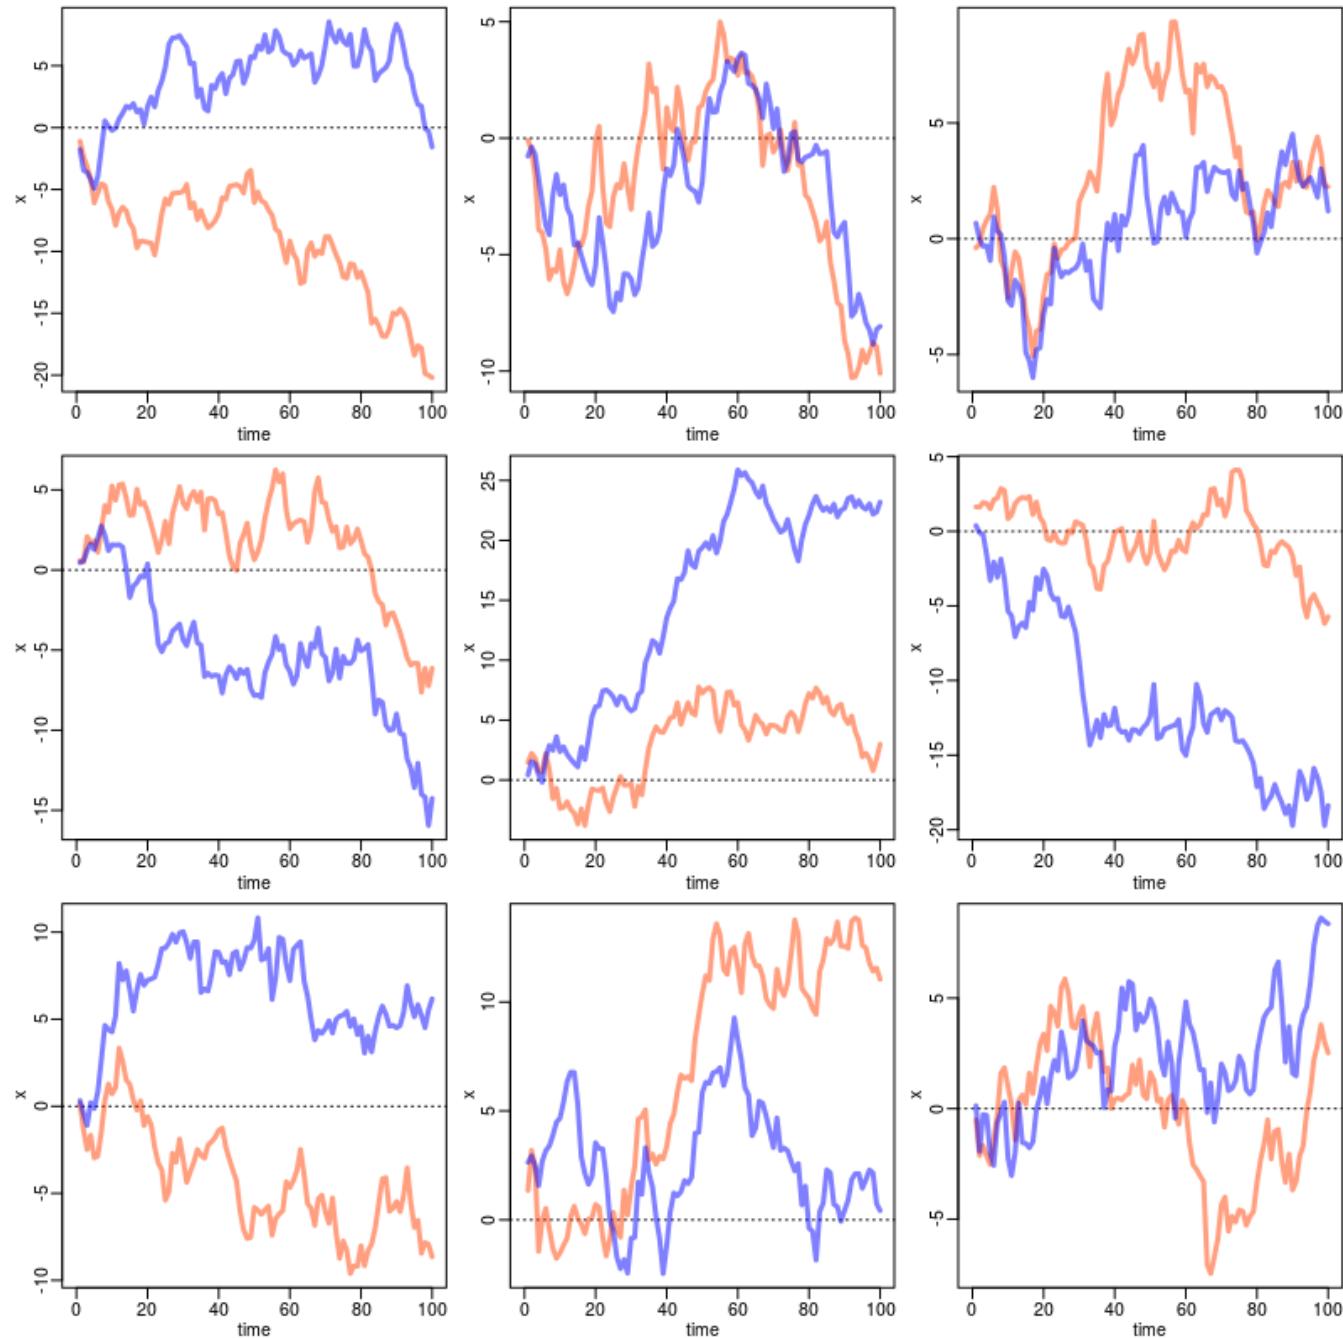


正の相関

時間があれば

demo

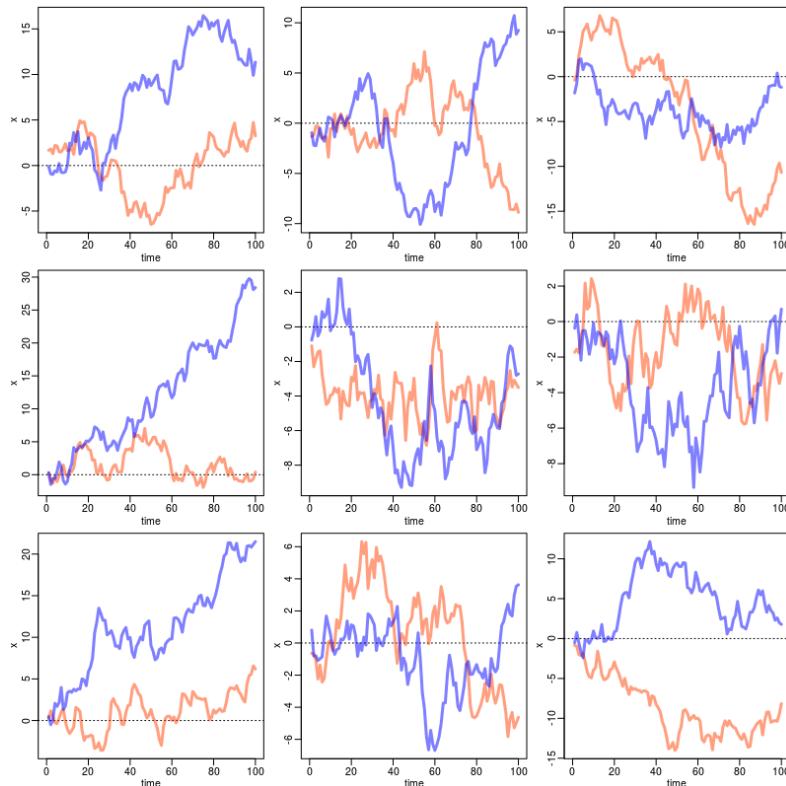
sample_rvar.R



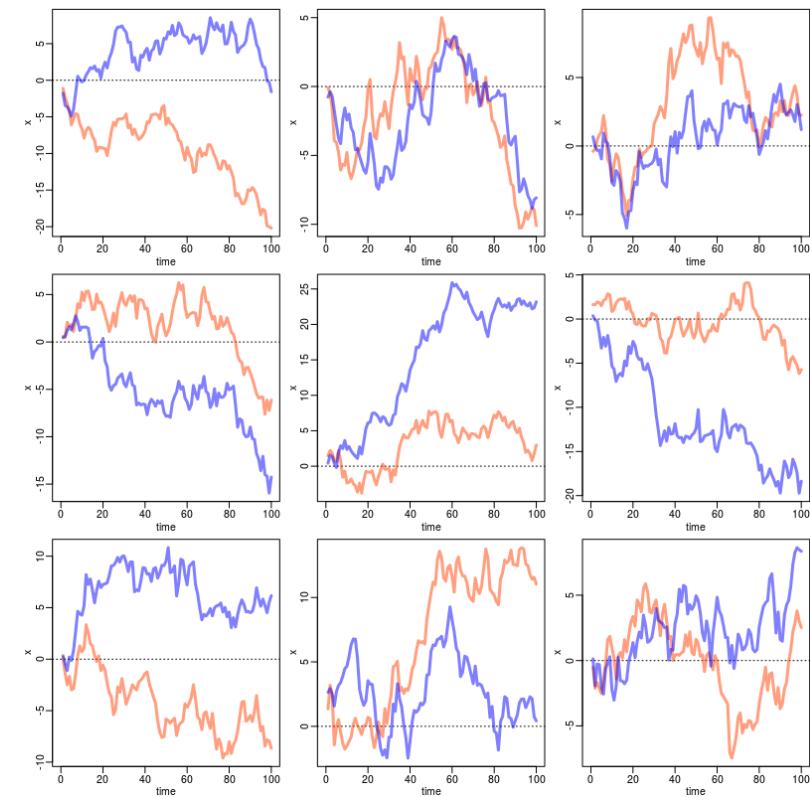
追加スライド

二変量正規分布とランダムウォーク

X と Y の相関係数 ρ を推定できるのか?



$$\rho = 0.0$$



$$\rho = 0.5$$

二変量正規分布を部品とする状態空間モデル

```
for (i in 1:N.Y) {  
    Y[i, 1:2] ~ dmnorm(mu[1:2], Omega[1:2, 1:2])  
}  
mu[1] ~ dunif(-1.0E+4, 1.0E+4)  
mu[2] ~ dunif(-1.0E+4, 1.0E+4)  
Omega[1:2, 1:2] <- inverse(VarCov[1:2, 1:2])  
VarCov[1, 1] <- sigma[1] * sigma[1]  
VarCov[1, 2] <- sigma[1] * sigma[2] * rho  
VarCov[2, 1] <- sigma[2] * sigma[1] * rho  
VarCov[2, 2] <- sigma[2] * sigma[2]  
sigma[1] ~ dunif(0.0, 1.0E+4)  
sigma[2] ~ dunif(0.0, 1.0E+4)  
rho ~ dunif(-1.0, 1.0)
```

(R で実演)

階層ベイズモデルである

状態空間モデル

から得られた事後分布

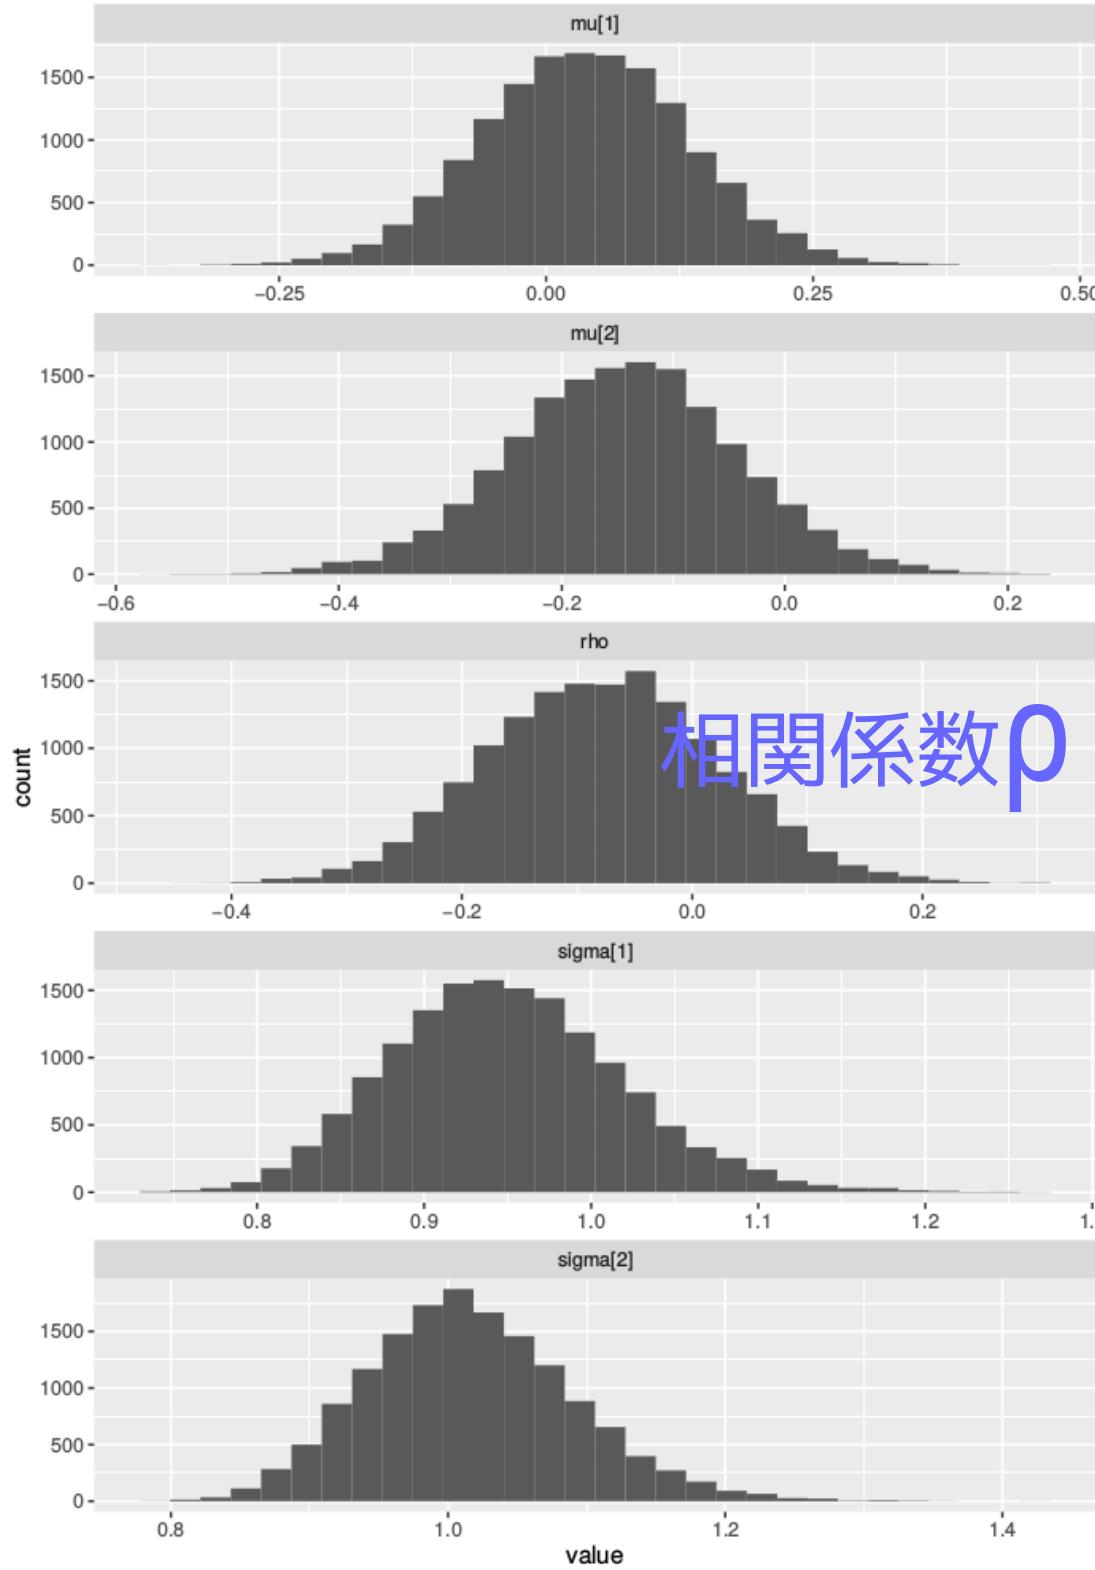
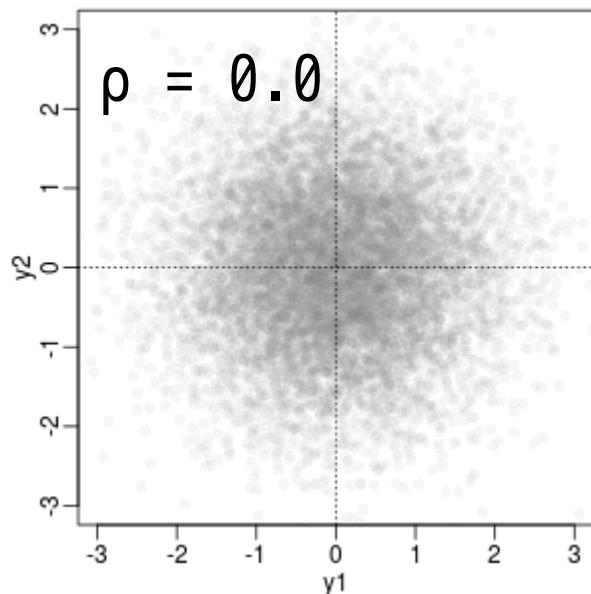
```
3 chains, each with 5200 iterations (first 200 discarded)
n.sims = 15000 iterations saved
      mean     sd   2.5%   25%   50%   75% 97.5% Rhat n.eff
mu[1] -0.122 0.110 -0.342 -0.195 -0.120 -0.048 0.090 1.001  6000
mu[2] -0.157 0.100 -0.355 -0.224 -0.157 -0.091 0.041 1.002  1500
sigma[1] 1.091 0.079  0.949  1.036  1.086  1.142 1.261 1.001  6100
sigma[2] 0.993 0.074  0.864  0.941  0.987  1.039 1.151 1.001  4100
rho     0.568 0.070  0.420  0.523  0.573  0.617 0.693 1.001 11000
```

ふたつの時系列データの変動が
相関しているかどうかを特定できる

図示すると……

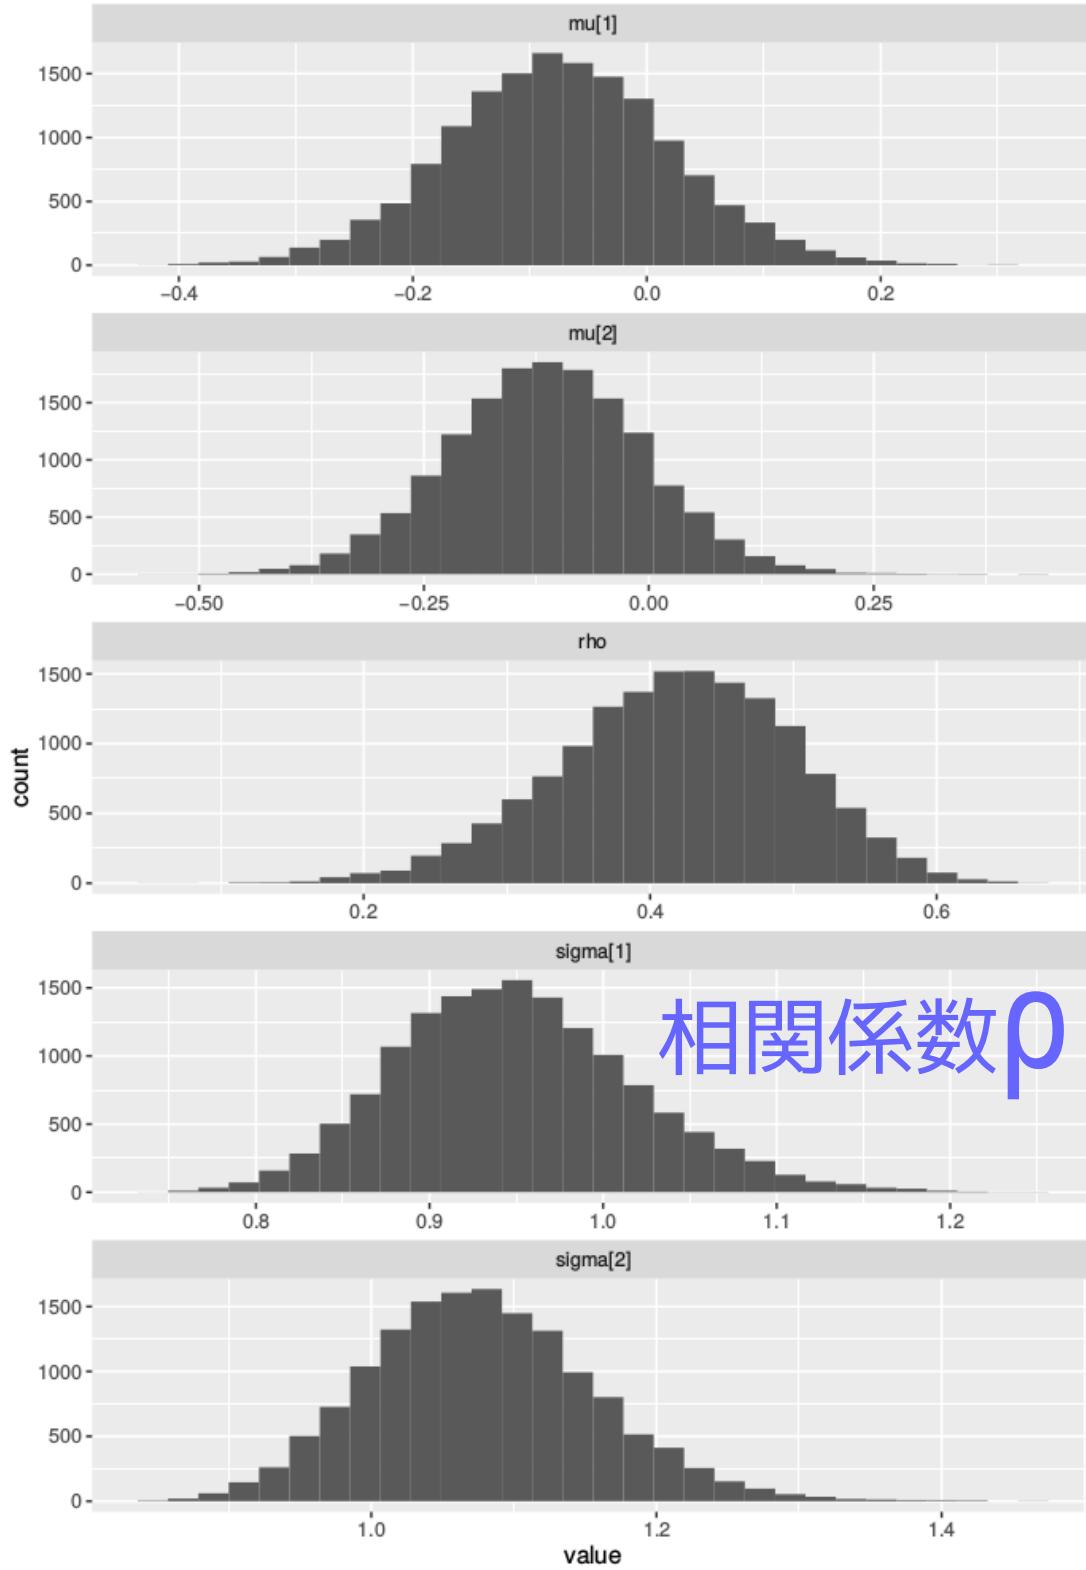
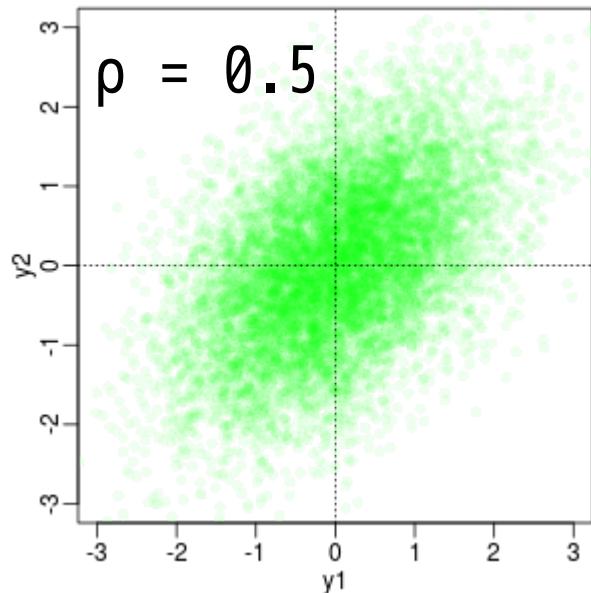
追加スライド

状態空間モデルの パラメーターの 事後分布 ($\rho = 0.0$)



追加スライド

状態空間モデルの パラメーターの 事後分布 ($\rho = 0.5$)



時系列データの統計モデリング

- ・ 安易に「回帰」してはいけない
- ・ ランダムウォークモデルが基本
- ・ 統計モデルが生成する時系列パターンを意識する
- ・ 階層ベイズモデルで推定
状態空間モデル

統計モデリング入門, ここまで…

データの性質・構造をよくみて統計モデルを作る

時系列データ状態空間モデル 線形モデルの発展

階層ベイズモデル

local/global
parameter
を使って

もっと自由な
統計モデリン
グを!

一般化線形混合モデル

個体差・場所差
といった変量効果
をつかいたい

一般化線形モデル

正規分布以外の
確率分布をつか
いたい

推定計算方法
MCMC

最尤推定法

最小二乗法
線形モデル