

# YUIMA におけるモデル選択

江口 翔一

大阪大学 数理・データ科学教育研究センター

YUIMA チュートリアル 確率微分方程式のデータサイエンス入門  
2018. 12. 2.

# 概要

① 情報量規準

② 関数 “IC”

③ シミュレーション・実習

1 情報量規準

2 関数 “IC”

3 シミュレーション・実習

# はじめに

- データ  $x_n = (x_1, x_2, \dots, x_n)$
- 適当な候補モデルを想定し、候補モデルの中からデータ  $x_n$  を生成したモデルを表すために**最も適したモデル**を見つけない

真のモデル:  $g_n(x)$



最適なモデル?

候補モデル:  $\mathcal{M}_1, \dots, \mathcal{M}_K$

$\mathcal{M}_i = \{f_{i,n}(x, \theta_i) | \theta_i \in \Theta_i \subset \mathbb{R}^{p_i}\}$

⇒ モデルの推定:  $f_{i,n}(x, \hat{\theta}_{i,n})$  ( $\hat{\theta}_{i,n}$ : 最尤推定量)

⇒ モデル  $f_{i,n}(x, \hat{\theta}_{i,n})$  のよさを評価する基準が必要: **情報量規準**

# 赤池情報量規準 AIC

$$x_n \xrightarrow{\text{モデルの推定}} f_{i,n}(x, \hat{\theta}_{i,n})$$

- **赤池情報量規準 (AIC):** モデルの評価を予測の観点から捉える  
⇒ 将来真のモデルから獲得したデータ  $z$  の従う真のモデル  $g_n(z)$  を  $f_{i,n}(z, \hat{\theta}_{i,n})$  で予測したときの平均的なよさ (悪さ) を評価
- **Kullback-Leibler 情報量 (K-L 情報量):** 分布の近さを測る尺度

$$\begin{aligned} KL(g_n; f_{i,n}) &= \mathbb{E}_Z \left( \log \frac{g_n(Z)}{f_{i,n}(Z, \hat{\theta}_{i,n})} \right) \\ &= \mathbb{E}_Z \{ \log g_n(Z) \} - \mathbb{E}_Z \{ \log f_{i,n}(Z, \hat{\theta}_{i,n}) \} \end{aligned}$$

▶ 性質: 「 $KL(g_n; f_{i,n}) \geq 0$ 」, 「 $KL(g_n; f_{i,n}) = 0 \Leftrightarrow g_n = f_{i,n}$ 」

⇒  $\mathbb{E}_Z \{ \log f_{i,n}(Z, \hat{\theta}_{i,n}) \}$  の有効な推定量の導出

$$n\mathbb{E}_Z\{\log f_{i,n}(Z, \hat{\theta}_{i,n})\} \xleftrightarrow{\text{推定値}} \mathbb{H}_{i,n}(\hat{\theta}_{i,n}) = \sum_{j=1}^n \log f_{i,n}(x_j, \hat{\theta}_{i,n})$$

⇒ 各候補モデルの  $\mathbb{H}_{i,n}(\hat{\theta}_{i,n})$  の比較で十分? ... NO

↑

$\mathbb{H}_{i,n}(\hat{\theta}_{i,n})$  は  $n\mathbb{E}_Z\{\log f_{i,n}(Z, \hat{\theta}_{i,n})\}$  の推定量として**バイアス**を持つ

⇒ **バイアス**の補正が必要:

$$\mathbb{E}_{\mathbf{X}_n} \left[ \mathbb{H}_{i,n}(\hat{\theta}_{i,n}) - n\mathbb{E}_Z \left\{ \log f_{i,n}(Z, \hat{\theta}_{i,n}) \right\} \right] \approx p_i$$

⇒ **AIC** の導出:

$$\mathbf{AIC}_n^{(i)} = -2\mathbb{H}_{i,n}(\hat{\theta}_{i,n}) + 2p_i, \quad i = 1, \dots, K$$

- ▶ 各候補モデルごとに **AIC** を計算し、最小の値をとるモデルを選択

# Bayes 情報量規準 BIC

- **Bayes 情報量規準 (BIC):** モデルの評価を モデルの事後確率 から捉える
- データ  $x_n$  に対する候補モデル  $\mathcal{M}_i$  の **事後確率**:  $i = 1, \dots, K$

$$\mathbb{P}(\mathcal{M}_i | x_n) = \frac{h_{i,n}(x_n) p_i}{\sum_{i=1}^K h_{i,n}(x_n) p_i}$$

- ... データ  $x_n$  が得られたとき、それがモデル  $\mathcal{M}_i$  から生起するものである確率  
⇒ 確率が最大となるモデルを選択

- ▶  $h_{i,n}(x_n)$ : データ  $x_n$  に対するモデル  $\mathcal{M}_i$  の周辺尤度

$$h_{i,n}(x_n) = \int_{\Theta_i} \exp \{ \mathbb{H}_{i,n}(\theta_i) \} \pi_{i,n}(\theta_i) d\theta_i$$

- ▶  $\pi_{i,n}(\theta_i)$ : パラメータ  $\theta_i$  の事前分布,  $p_i$ : モデル  $\mathcal{M}_i$  の生起確率

事後確率:  $i = 1, \dots, K$

$$\mathbb{P}(\mathcal{M}_i | \mathbf{x}_n) = \frac{h_{i,n}(\mathbf{x}_n) p_i}{\sum_{i=1}^K h_{i,n}(\mathbf{x}_n) p_i}$$

- ▶ 事後確率の最大化  $\Rightarrow$  分子の最大化 (分母は全てのモデルで共通)

$$\Downarrow (p_1 = \dots = p_K)$$

モデルの周辺尤度  $h_{i,n}$  の最大化

$$\Downarrow$$

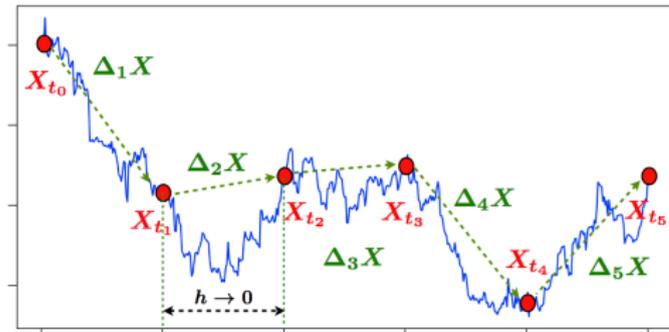
対数周辺尤度  $\log h_{i,n}$  を使いやすい形で表現

$\Rightarrow$  BIC の導出:

$$\text{BIC}_n^{(i)} = -2\mathbb{H}_{i,n}(\hat{\theta}_{i,n}) + p_i \log n, \quad i = 1, \dots, K$$

- ▶ 各候補モデルごとに BIC を計算し、最小の値をとるモデルを選択

# モデル設定: 確率微分方程式モデル



- データ:  $X_n = (X_{t_j})_{j=0}^n$ 
  - $t_j = jh_n$
  - $T_n = nh_n \rightarrow \infty, nh_n^2 \rightarrow 0$

- 候補モデル  $\mathcal{M}_{k,\ell}$  ( $k \leq K, \ell \leq L$ ):

$$dX_t = a_k(X_t, \alpha_k)dt + b_\ell(X_t, \beta_\ell)dw_t, \quad t \in [0, T_n]$$

- ▶ 候補ドリフト項:  $a_1(X_t, \alpha_1), \dots, a_K(X_t, \alpha_K) \dots$  選択の対象
- ▶ 候補拡散項:  $b_1(X_t, \beta_1), \dots, b_L(X_t, \beta_L) \dots$  選択の対象
- ▶ パラメータ:  $\theta_{k,\ell} = (\alpha_k, \beta_\ell) \dots$  推定の対象
- ▶  $w$ : 標準 Wiener 過程

# 確率微分方程式モデルにおける情報量規準: 同時

$$dX_t = a(X_t, \alpha)dt + b(X_t, \beta)dw_t$$

- $\mathcal{L}(X_{t_j} | X_{t_{j-1}}) \approx N(X_{t_j} | X_{t_{j-1}} + h_n a_{j-1}(\alpha), h_n S_{j-1}(\beta))$

$$\mathbb{H}_n(\theta) = \sum_{j=1}^n \log \phi(X_{t_j}; X_{t_{j-1}} + h_n a_{j-1}(\alpha), h_n S_{j-1}(\beta))$$

- ▶  $f_{j-1}(\cdot) = f(X_{t_{j-1}}, \cdot)$ ,  $S_{j-1}(\beta) = b_{j-1} b_{j-1}^\top(\beta)$

- ▶  $\theta = (\alpha, \beta) \in \mathbb{R}^{p_\alpha} \times \mathbb{R}^{p_\beta}$ ,  $\hat{\theta}_n \in \operatorname{argmax}_\theta \mathbb{H}_n(\theta)$

CIC (Uchida(2010)) : AIC 型情報量規準

$$\text{CIC}_n = -2\mathbb{H}_n(\hat{\theta}_n) + 2(p_\alpha + p_\beta)$$

quasi-BIC and BIC (E and Masuda(2018)) : BIC 型情報量規準

$$\text{QBIC}_n = -2\mathbb{H}_n(\hat{\theta}_n) + \log \left| -\partial_\alpha^2 \mathbb{H}_n(\hat{\theta}_n) \right| + \log \left| -\partial_\beta^2 \mathbb{H}_n(\hat{\theta}_n) \right|$$

$$\text{BIC}_n = -2\mathbb{H}_n(\hat{\theta}_n) + p_\alpha \log T_n + p_\beta \log n$$

# 確率微分方程式モデルにおける情報量規準: 二段階

候補モデル  $\mathcal{M}_{k,\ell}$  ( $k \leq K, \ell \leq L$ ):

$$dX_t = a_k(X_t, \alpha_k)dt + b_\ell(X_t, \beta_\ell)dw_t$$

(i)  $\alpha$  を含まない (補助) 対数尤度関数  $\mathbb{H}_{1,n}^{(\ell)}(\beta_\ell)$  を用いて拡散項を選択:

$$\begin{aligned} \text{QBIC}_n^{(k)} &= -2\mathbb{H}_{1,n}^{(k)}(\hat{\beta}_{\ell,n}) + \log \left| -\partial_{\beta_\ell}^2 \mathbb{H}_{1,n}^{(\ell)}(\hat{\beta}_{\ell,n}) \right| \\ \{\ell_n^*\} &= \underset{1 \leq \ell \leq L}{\operatorname{argmin}} \text{QBIC}_n^{(\ell)} \end{aligned}$$

(ii) ドリフト項を選択:  $dX_t = a_k(X_t, \alpha_k)dt + b_{\ell_n^*}(X_t, \hat{\beta}_{\ell_n^*,n})dw_t$

$$\begin{aligned} \text{QBIC}_n^{(k|\ell_n^*)} &= -2\mathbb{H}_n^{(k,\ell_n^*)}(\hat{\alpha}_{k,n}, \hat{\beta}_{\ell_n^*,n}) \\ &\quad + \log \left| -\partial_{\beta_\ell}^2 \mathbb{H}_n^{(k_n^*,\ell)}(\hat{\alpha}_{k,n}, \hat{\beta}_{\ell_n^*,n}) \right| \\ \{k_n^*\} &= \underset{1 \leq k \leq K}{\operatorname{argmin}} \text{QBIC}_n^{(k|\ell_n^*)} \end{aligned}$$

※ BIC についても同様の二段階選択が可能

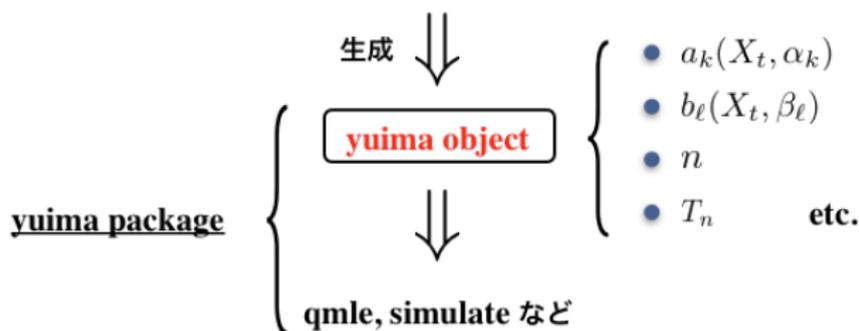
1 情報量規準

2 関数 “IC”

3 シミュレーション・実習

# yuima object

$$\text{候補モデル: } \mathcal{M}_{k,\ell} = \{a_k(\cdot, \cdot), b_\ell(\cdot, \cdot)\}, \quad k = 1, \dots, K, \quad \ell = 1, \dots, L$$
$$dX_t = a_k(X_t, \alpha_k)dt + b_\ell(X_t, \beta_\ell)dw_t, \quad t \in [0, T_n]$$



- 候補モデルごとに **yuima object** を生成 (生成例は次のスライド)
  - ▶ モデルの各項 (拡散項  $a$  やドリフト項  $b$ ), データ数  $n$  などの情報を持つ
- **yuima object** はパラメータの推定やデータ生成ための関数に利用可能

## 生成例

$$dX_t = \alpha_1 X_t dt + \sqrt{\beta_1} dw_t, \quad t \in [0, T_n]$$

- $n = 1000$  : データ数,  $T_n = n^{1/3}$

```
> ymodel <- setModel(drift = "alpha1*x", diffusion = "sqrt(beta1)")
```

警告メッセージ:

```
yuima.warn("Solution variable (lhs) not specified. Trying to use state variables.") で:
```

```
YUIMA: Solution variable (lhs) not specified. Trying to use state variables.
```

```
> ysamp <- setSampling(Terminal = 1000^(1/3), n = 1000)
```

警告メッセージ:

```
yuima.warn("'delta' (re)defined.") で:
```

```
YUIMA: 'delta' (re)defined.
```

```
> yuima <- setYuima(model = ymodel, sampling = ysamp)
```

# 関数 “IC”

```
IC <- function(yuima, data, start, lower, upper,  
              joint = FALSE, rcpp = FALSE)
```

- **yuima**: モデルの設定 (yuima object)
- **data**: データセット ( $X_{t_0}, X_{t_1}, \dots, X_{t_n}$ )
- **start, lower, upper**: パラメータの推定のための名前付きリスト

```
> init <- list(alpha1 = -1, beta1 = 0.5)  
> lower <- list(alpha1 = -3, beta1 = 0.001)  
> upper <- list(alpha1 = -0.001, beta1 = 3)
```
- **joint**: パラメータの推定を同時に行うか、または二段階で行うか
- **rcpp**: C++ code を使用するか否か

## 返り値

- パラメータの推定量 (`$par`)
- 情報量規準 QBIC, BIC, CIC の値 (`$QBIC`, `$BIC`, `$CIC`)

```
> ic <- IC(yuima = yuima, data = Xt, start = init, lower = lower,  
+         upper = upper, rcpp = TRUE)
```

```
> ic  
$par  
  beta1  alpha1  
 1.965465 -1.583359
```

```
$BIC  
[1] -1083.488
```

```
$QBIC  
[1] -1086.631
```

```
$CIC  
[1] -1088.698
```

```
> ic$par  
  beta1  alpha1  
 1.965465 -1.583359
```

```
>  
> ic$BIC  
[1] -1083.488
```

```
>  
> ic$QBIC  
[1] -1086.631
```

```
>  
> ic$CIC  
[1] -1088.698
```

# 注意

- 変数 `start`, `lower`, `upper` について:

モデルに含まれているパラメータ全てに関する設定が必須

```
> ymodel <- setModel(drift = "alpha1*x", diffusion = "sqrt(beta1)")
```

✗ ⇐ {  
    > init <- list(alpha1 = -1)  
    > init <- list(gamma1 = -1, beta1 = 0.5)  
    >  
○ ⇐ > init <- list(alpha1 = -1, alpha2 = -1, beta1 = 0.5, beta2 = 0.5)

- QBIC の計算について:

$$\det \left( -\partial_{\alpha}^2 \mathbb{H}_n(\hat{\theta}_n) \right) \leq 0 \text{ または } \det \left( -\partial_{\beta}^2 \mathbb{H}_n(\hat{\theta}_n) \right) \leq 0$$

⇒ QBIC は BIC と同じ値をとる ( $\text{QBIC}_n = \text{BIC}_n$ )

1 情報量規準

2 関数 “IC”

3 シミュレーション・実習

# 実行例: 一次元データ

- 真のモデル:

$$dX_t = -X_t dt + \exp\left\{\frac{1}{2}(-2 \sin X_t + 1)\right\} dw_t, \quad X_0 = 1$$

- ▶  $n = 1000, T_n = n^{1/3}$

- 候補モデル:

$$\text{Model 1 : } dX_t = \alpha_1 X_t dt + \exp\left\{\frac{1}{2}(\beta_1 \sin X_t + \beta_2)\right\} dw_t$$

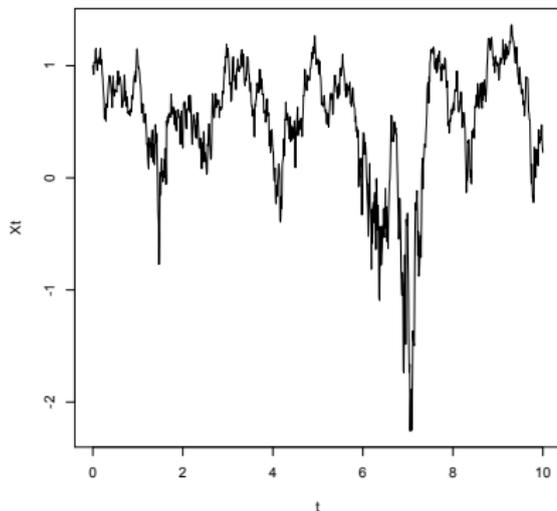
$$\text{Model 2 : } dX_t = \alpha_1 X_t dt + \exp\left\{\frac{1}{2}(\beta_1 \sin X_t)\right\} dw_t$$

- 真のパラメータ:  $(\alpha_{1,0}, \beta_{1,0}, \beta_{2,0}) = (-1, -2, 1)$

```
> set.seed(123)
> model <- setModel(drift = "alpha1*x", diffusion = "exp((beta1*sin(x)+beta2)/2)")
警告メッセージ:
yuima.warn("Solution variable (lhs) not specified. Trying to use state variables.") で:
YUIMA: Solution variable (lhs) not specified. Trying to use state variables.

> sample <- setSampling(Terminal = 1000^(1/3), n = 1000)
警告メッセージ:
yuima.warn("'delta' (re)defined.") で:
YUIMA: 'delta' (re)defined.

> yuima <- setYuima(model = model, sampling = sample)
> simu <- simulate(yuima, xinit = 1,
+                 true.parameter = list(beta1 = -2, beta2 = 1, alpha1 = -1))
> Xt <- simu@data@original.data
```



## ● yuima object 生成:

### Model 1:

```
> model1 <- setModel(drift = "alpha1*x", diffusion = "exp((beta1*sin(x)+beta2)/2)")
警告メッセージ:
yuima.warn("Solution variable (lhs) not specified. Trying to use state variables.") で:
YUIMA: Solution variable (lhs) not specified. Trying to use state variables.

> sample1 <- setSampling(Terminal = 1000^(1/3), n = 1000)
警告メッセージ:
yuima.warn("'delta' (re)defined.") で:
YUIMA: 'delta' (re)defined.

> yuima1 <- setYuima(model = model1, sampling = sample1)
```

### Model 2:

```
> model2 <- setModel(drift = "alpha1*x", diffusion = "exp(beta1*sin(x)/2)")
警告メッセージ:
yuima.warn("Solution variable (lhs) not specified. Trying to use state variables.") で:
YUIMA: Solution variable (lhs) not specified. Trying to use state variables.

> sample2 <- setSampling(Terminal = 1000^(1/3), n = 1000)
警告メッセージ:
yuima.warn("'delta' (re)defined.") で:
YUIMA: 'delta' (re)defined.

> yuima2 <- setYuima(model = model2, sampling = sample2)
```

```
> Xt <- yuima.simu@data@original.data
```

- パラメータ設定 ( $\alpha_1, \beta_1, \beta_2$ ):

```
> init <- list(alpha1 = -0.5, beta1 = 0.5, beta2 = 0.5)
> low <- list(alpha1 = -5, beta1 = -5, beta2 = -5)
> upp <- list(alpha1 = -0.001, beta1 = 5, beta2 = 5)
```

- “IC” の使用:

### Model 1:

```
> ic1 <- IC(yuima = yuima1, data = Xt, start = init, lower = low, upper = upp)
```

### Model 2:

```
> ic2 <- IC(yuima = yuima2, data = Xt, start = init, lower = low, upper = upp)
```

- 計算結果比較

### Model 1:

```
> ic1
$par
      beta1      beta2      alpha1
-2.082683  1.022628 -1.085644

$BIC
[1] -1684.132

$QBIC
[1] -1687.361

$CIC
[1] -1694.25
```

### Model 2:

```
> ic2
$par
      beta1      alpha1
-1.132763 -1.158624

$BIC
[1] -1292.77

$QBIC
[1] -1293.673

$CIC
[1] -1297.981
```

$$\left\{ \begin{array}{l} (\text{Model 1 の BIC}) < (\text{Model 2 の BIC}) \\ (\text{Model 1 の QBIC}) < (\text{Model 2 の QBIC}) \\ (\text{Model 1 の CIC}) < (\text{Model 2 の CIC}) \end{array} \right.$$

## 実行例: 多次元データ

$$d \begin{pmatrix} X_{1,t} \\ X_{2,t} \end{pmatrix} = \begin{pmatrix} -2X_{1,t} \\ -X_{2,t} \end{pmatrix} dt + \begin{pmatrix} -X_{1,t} + 2 & -1 \\ 1 & -X_{1,t} + 2 \end{pmatrix} d \begin{pmatrix} w_{1,t} \\ w_{2,t} \end{pmatrix}$$

- $X_0 = (1, 1)'$
- $n = 2000, T_n = n^{1/3}$
- 真のパラメータ:  $(\alpha_{1,0}, \alpha_{2,0}, \beta_{1,0}, \beta_{2,0}, \beta_{3,0}) = (-2, -1, -1, 0, 2)$
- 候補モデル:

$$d \begin{pmatrix} X_{1,t} \\ X_{2,t} \end{pmatrix} = \begin{pmatrix} \alpha_1 X_{1,t} \\ \alpha_2 X_{2,t} \end{pmatrix} dt + \begin{pmatrix} b(X_t, \beta) & -1 \\ 1 & b(X_t, \beta) \end{pmatrix} d \begin{pmatrix} w_{1,t} \\ w_{2,t} \end{pmatrix}$$

Model 1 :  $b(X_t, \beta) = \beta_1 X_{t,1} + \beta_2 X_{t,2} + \beta_3$ ;

Model 2 :  $b(X_t, \beta) = \beta_1 X_{t,1} + \beta_2 X_{t,2}$ ;

Model 3 :  $b(X_t, \beta) = \beta_1 X_{t,1} + \beta_3$ ; Model 4 :  $b(X_t, \beta) = \beta_2 X_{t,2} + \beta_3$ ;

Model 5 :  $b(X_t, \beta) = \beta_1 X_{t,1}$ ; Model 6 :  $b(X_t, \beta) = \beta_2 X_{t,2}$ ;

Model 7 :  $b(X_t, \beta) = \beta_3$ ;

- 拡散項 (行列)  $\begin{pmatrix} -X_{1,t} + 2 & -1 \\ 1 & -X_{1,t} + 2 \end{pmatrix}$ :

```
> diff.coef.matrix <- matrix(c("beta1*x1+beta3", "1", "-1", "beta1*x1+beta3"), 2, 2)
```

- ドリフト項 (ベクトル)  $\begin{pmatrix} -2X_{1,t} \\ -X_{2,t} \end{pmatrix}$ :

```
> drif.coef.vec <- c("alpha1*x1", "alpha2*x2")
```

- **yuima object:**

```
> model <- setModel(drift = drif.coef.vec, diffusion = diff.coef.matrix,  
+ state.variable = c("x1", "x2"), solve.variable = c("x1", "x2"))  
> sample <- setSampling(Terminal = 2000^(1/3), n = 2000)
```

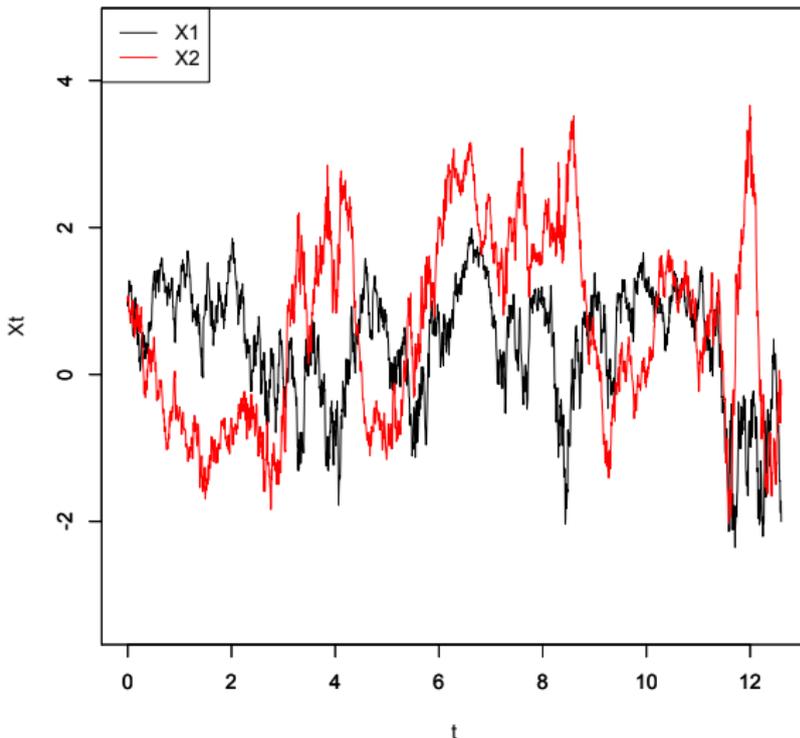
警告メッセージ:

```
yuima.warn("'delta' (re)defined.") で:  
YUIMA: 'delta' (re)defined.
```

```
> yuima <- setYuima(model = model, sampling = sample)
```

## ● データ生成:

```
> set.seed(200)
> simu <- simulate(yuima, xinit = c(1,1),
+                 true.parameter = list(beta1 = -1, beta3 = 2, alpha1 = -2, alpha2 = -1))
> Xt <- simu@data@original.data
```



## ● 候補モデルの yuima object:

```
> cand.diff <- list(matrix(c("beta1*x1+beta2*x2+beta3", "1", "-1", "beta1*x1+beta2*x2+beta3"), 2, 2),  
+                   matrix(c("beta1*x1+beta2*x2", "1", "-1", "beta1*x1+beta2*x2"), 2, 2),  
+                   matrix(c("beta1*x1+beta3", "1", "-1", "beta1*x1+beta3"), 2, 2),  
+                   matrix(c("beta2*x2+beta3", "1", "-1", "beta2*x2+beta3"), 2, 2),  
+                   matrix(c("beta1*x1", "1", "-1", "beta1*x1"), 2, 2),  
+                   matrix(c("beta2*x2", "1", "-1", "beta2*x2"), 2, 2),  
+                   matrix(c("beta3", "1", "-1", "beta3"), 2, 2))
```

候補拡散項

```
> cand.drif <- c("alpha1*x1", "alpha2*x2")
```

候補ドリフト項

```
> cand.model <- NULL  
> for(i in 1:length(cand.diff)){  
+   cand <- setModel(drift = cand.drif, diffusion = cand.diff[[i]],  
+                   state.variable = c("x1", "x2"), solve.variable = c("x1", "x2"))  
+   cand.samp <- setSampling(Terminal = 2000^(1/3), n = 2000)  
+   cand.yuima <- setYuima(model = cand, sampling = cand.samp)  
+   cand.model <- c(cand.model, list(cand.yuima))  
+ }
```

全候補モデルのyuima object

## ● パラメータの設定:

最もパラメータが多い候補モデルに合わせて設定する

```
> init <- list(alpha1 = -1, alpha2 = -1, beta1 = 0.5, beta2 = 0.5, beta3 = 0.5)  
> low <- list(alpha1 = -3, alpha2 = -3, beta1 = -5, beta2 = -5, beta3 = -5)  
> upp <- list(alpha1 = -0.001, alpha2 = -0.001, beta1 = 5, beta2 = 5, beta3 = 5)
```

- “IC” の使用:

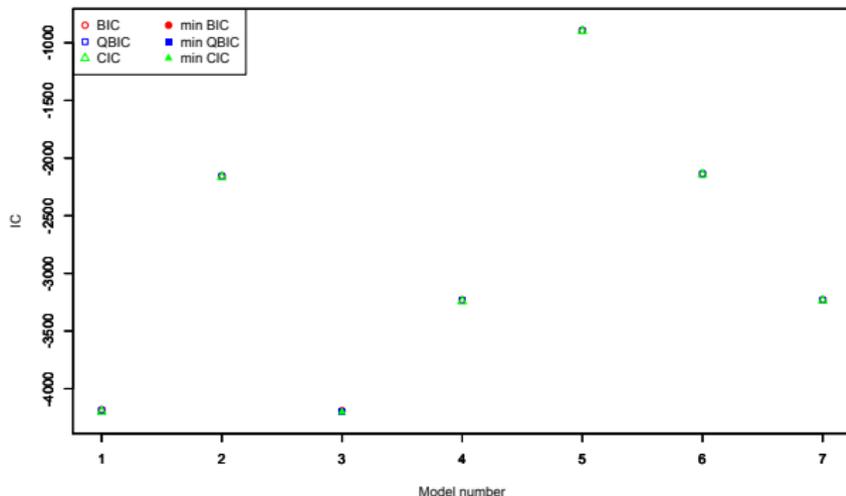
```
> for(i in 1:7){  
+   ic <- IC(yuima = cand.model[[i]], data = Xt, start = init, lower = low, upper = upp)  
+ }
```

- “IC” の使用 & 結果をまとめる (例):

```
> paranum <- list(1:5, c(1,2,4,5), c(1,3,4,5), c(2,3,4,5), c(1,4,5), c(2,4,5), c(3,4,5))  
> results <- matrix(0, 7, 8)  
> for(i in 1:7){  
+   ic <- IC(yuima = cand.model[[i]], data = Xt, start = init, lower = low, upper = upp)  
+   results[i,paranum[[i]]] <- ic$par  
+   results[i,6:8] <- c(ic$BIC, ic$QBIC, ic$CIC)  
+ }
```

```
> results
```

	beta1	beta2	beta3	alpha1	alpha2	BIC	QBIC	CIC
Model 1	-1.0583542	0.001811267	2.018310	-1.770173	-0.8747962	-4182.2607	-4184.882	-4200.1307
Model 2	-0.8069696	1.362905768	0.0000000	-1.974062	-0.5502677	-2153.1532	-2158.122	-2165.4223
Model 3	-1.0586496	0.000000000	2.019548	-1.769961	-0.8739008	-4189.8550	-4192.581	-4202.1241
Model 4	0.0000000	0.059506439	1.732918	-2.336065	-1.0604995	-3230.4508	-3232.794	-3242.7199
Model 5	-2.1998290	0.000000000	0.0000000	-1.851133	-1.4337826	-892.1917	-896.013	-898.8598
Model 6	0.0000000	-1.458342919	0.0000000	-1.555513	-0.3980473	-2134.7236	-2137.536	-2141.3918
Model 7	0.0000000	0.000000000	-1.771589	-2.362494	-1.0457829	-3228.2303	-3230.866	-3234.8985



真のパラメータ:  $(\alpha_{1,0}, \alpha_{2,0}, \beta_{1,0}, \beta_{2,0}, \beta_{3,0}) = (-2, -1, -1, 0, 2)$

	$\beta_1$	$\beta_2$	$\beta_3$	$\alpha_1$	$\alpha_2$	BIC	QBIC	CIC
Model 1	-1.058	0.002	2.018	-1.770	-0.875	-4182.261	-4184.882	-4200.131
Model 2	-0.807	1.363	-	-1.974	-0.550	-2153.153	-2158.122	-2165.422
<b>Model 3</b>	<b>-1.059</b>	-	<b>2.020</b>	<b>-1.770</b>	<b>-0.874</b>	<b>-4189.855</b>	<b>-4192.581</b>	<b>-4202.124</b>
Model 4	-	0.060	1.733	-2.336	-1.060	-3230.451	-3232.794	-3242.720
Model 5	-2.200	-	-	-1.851	-1.434	-892.192	-896.013	-898.860
Model 6	-	-1.458	-	-1.556	-0.398	-2134.724	-2137.536	-2141.392
Model 7	-	-	-1.772	-2.362	-1.046	-3228.230	-3230.866	-3234.898

## 参考文献

- Specification of the function IC in YUIMA package  
(<https://sites.google.com/site/shoichieguchi821/shi-yang-shu>)
- [1] Eguchi, S. and Masuda, H. (2018). Schwarz type model comparison for LAQ models. *Bernoulli*, 24(3), 2278–2327.
  - [2] Uchida, M. (2010). Contrast-based information criterion for ergodic diffusion processes from discrete observations. *Ann. Inst. Statist. Math.*, 62, 161–187.