

パラメタの推定と確率モデルの推定の一般論を「尤度原理」で説明する

子ータ解析  
Rによる多変量解析入門  
最尤法, モデル選択

- 最尤法 (尤度)
  - モデル選択 (修正決定係数, 赤池情報量規準)
- 回帰分析の説明変数選択を例題に取り上げる

最尤法

### 尤度 (likelihood)

- 正規線形回帰モデル

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_p x_{ip} + \epsilon_i; \quad i = 1, \dots, n$$

$$\epsilon_1, \dots, \epsilon_n \sim N(0, \sigma^2) \quad \text{i.i.d.}$$

$$\theta = (\beta_0, \beta_1, \dots, \beta_p, \sigma^2)$$

- 確率密度関数

$$f(y|x; \theta)$$

$$= \frac{1}{\sqrt{(2\pi\sigma^2)^n}} \exp \left[ -\sum_{i=1}^n \frac{(\beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip} - y_i)^2}{2\sigma^2} \right]$$

- 尤度

$$L(\theta; \mathcal{X}) = f(\mathcal{X}; \theta)$$

モデル選択

### 最尤法 (maximum likelihood method)

- 一般にパラメタベクトルを  $\theta$ , データを  $\mathcal{X}$  と書く

$$L(\theta; \mathcal{X}) = f(\mathcal{X}; \theta)$$

- 対数尤度 (log-likelihood)

$$\ell(\theta; \mathcal{X}) = \log L(\theta; \mathcal{X}) = \log f(\mathcal{X}; \theta)$$

- パラメタの最尤推定量 (MLE) を  $\hat{\theta}$  と書く

$$\max_{\theta \in \Theta} \ell(\theta; \mathcal{X}) = \ell(\hat{\theta}; \mathcal{X})$$

$$\left. \frac{\partial \ell(\theta; \mathcal{X})}{\partial \theta} \right|_{\hat{\theta}} = 0$$

### モデルの候補

確率モデルの候補が複数ある場合

$$f_1(\mathcal{X}; \theta_1), \dots, f_m(\mathcal{X}; \theta_m)$$

データ  $\mathcal{X}$  を最もよく説明するモデルを選ぶ

【例】重回帰分析の説明変数の選択

$f_1$  は定数項  $\beta_0$  のみ ( $\beta_1 = \dots = \beta_p = 0$  を仮定)

$f_2$  は  $x_1$  を使う ( $\beta_2 = \dots = \beta_p = 0$ )

$f_3$  は  $x_2$  を使う ( $\beta_1 = \beta_3 = \dots = \beta_p = 0$ )

$f_4$  は  $x_1$  と  $x_2$  を使う ( $\beta_3 = \dots = \beta_p = 0$ )

$f_m$  は  $x_1, \dots, x_p$  を使う

【例】多項式回帰の次数選択

$f_1$  は  $y = \beta_0 + \epsilon$ ,  $f_2$  は  $y = \beta_0 + \beta_1 x + \epsilon$ ,

$f_3$  は  $y = \beta_0 + \beta_1 x + \beta_2 x^2 + \epsilon$ ,

$f_{p+1}$  は  $y = \beta_0 + \beta_1 x + \beta_2 x^2 + \dots + \beta_p x^p + \epsilon$

### 重回帰モデルの最尤推定

$$\ell(\beta, \sigma^2; \mathcal{X}, \mathbf{y}) = -\frac{n}{2} \log(2\pi\sigma^2) - \sum_{i=1}^n \frac{(\beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip} - y_i)^2}{2\sigma^2}$$

$$\frac{\partial \ell}{\partial \beta_k} = \sum_{i=1}^n \frac{\beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip} - y_i}{\sigma^2} x_{ik}$$

$$\frac{\partial \ell}{\partial (\sigma^2)} = -\frac{n}{2\sigma^2} + \sum_{i=1}^n \frac{\beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip} - y_i}{2\sigma^4}$$

$$\text{最尤推定量} \quad \hat{\beta} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{y}, \quad \hat{\sigma}^2 = \frac{\|\mathbf{y} - \mathbf{X}\hat{\beta}\|^2}{n}$$

$$\text{c.f. } \sigma^2 \text{ の不偏推定量} \quad \hat{\sigma}^2 = \frac{\|\mathbf{y} - \mathbf{X}\hat{\beta}\|^2}{n-p-1}, \quad E(\hat{\sigma}^2) = \sigma^2$$

ここでは最尤推定は  $\hat{\sigma}^2$ , 不偏推定は  $\hat{\sigma}^2$  と書いて区別する

### モデル選択

- モデルの良さを表す規準を  $C(f_i; \mathcal{X})$  と書く

$$C(f_1, \mathcal{X}), \dots, C(f_m, \mathcal{X})$$

を最大 (または最小) にするモデル  $f_i$  を選択する

- 様々な規準  $C(f_i; \mathcal{X})$  が提案されている

【例】修正決定係数, 赤池情報規準

### 修正決定係数

- 回帰分析の決定係数  $R^2$   
「観測データへのモデルの当てはまりの良さ」を測る
- 決定係数の問題点  
モデルが大きくなるほど大きな値を取る（多項式回帰では最大次数のモデルが  $R^2$  を最大にする）

- 説明変数の数  $p$  が増えるに従い推定誤差が増える影響を考慮して決定係数を修正する

- 修正決定係数  $\bar{R}^2$  を最大にするモデルを選ぶ  
$$\bar{R}^2 = 1 - \frac{n-1}{n-k-1}(1-R^2)$$

$n$  = サンプルサイズ,  $k$  = 変数の数

10

### 重回帰分析のモデル選択

#### セッションファイル

```
edu:~/shimo/class/gakubu200209/note20031010.R#t
> ## 重回帰分析の説明変数選択
> source("myfunc20031010.R")
> ax <- c("E09504", "A0410302", "C01301", "B02101"); x <- X20000$x[,ax]
> ay <- "A05203"; y <- X20000$y[,ay]
> X20000$jname[c(ax,ay)]
      E09504      A0410302
"最終学歴が大学・大学院卒の者の割合" "未婚者割合[20~24歳・女]"
      C01301      B02101
"県民1人当たり県民所得" "年平均気温"
      A05203
"合計特殊出生率"
> fit <- mylsfitv(x,y) # すべての変数のくみあわせ(16通り)
> fit$v # 使った変数のリスト
      1      2      3      4
() FALSE FALSE FALSE FALSE
      13
```

### 修正決定係数の導出

- モデル ( $k$ ) の決定係数

$$R^2 = 1 - \frac{\sigma_k^2}{\sigma_0^2} = 1 - \frac{RSS(k)/n}{RSS(0)/n}$$

ただしモデル ( $k$ ) における  $\sigma^2$  の最尤推定を  $\sigma_k^2$  と書いた。

$$RSS(k) = \sum_{i=1}^n (y_i - \hat{y}_i)^2, \quad RSS(0) = \sum_{i=1}^n (y_i - \bar{y})^2$$

- 最尤推定を不偏推定で置き換えて決定係数を修正する。

$$\bar{R}^2 = 1 - \frac{\sigma_k^2}{\sigma_0^2} = 1 - \frac{RSS(k)/(n-k-1)}{RSS(0)/(n-1)}$$

ただしモデル ( $k$ ) における  $\sigma^2$  の不偏推定を  $\sigma_k^2$  と書いた。

- $\bar{R}^2$  最大化は  $\sigma_k^2$  最小化と同じこと。

11

### 赤池情報規準 (Akaike Information Criterion)

- モデル選択の「最尤法」  
(回帰分析に限らずさまざまなモデルに適用可能)
- モデル候補  $1, \dots, m$  の最大対数尤度

$$\hat{\ell}_i = \log f_i(\mathcal{Y}; \hat{\theta}_i), \quad i = 1, \dots, m$$

- パラメータ数  $\dim \theta_i$  の大きいモデルが  $\hat{\ell}_i$  を大きくする

- パラメータ数の増加に伴い推定誤差が増える影響を考慮して  $\hat{\ell}$  を修正する

$$AIC = -2 \times (\hat{\ell} - \dim \theta)$$

- AIC を最小にするモデルを選ぶ

- 回帰分析の場合、最大対数尤度とパラメータ数は

$$\hat{\ell} = -\frac{n}{2} \{1 + \log(2\pi\sigma^2)\}, \quad \dim \theta = k + 2$$

12

```
(1) TRUE FALSE FALSE FALSE
(2) FALSE TRUE FALSE FALSE
(12) TRUE TRUE FALSE FALSE
(3) FALSE FALSE TRUE FALSE
(13) TRUE FALSE TRUE FALSE
(23) FALSE TRUE TRUE FALSE
(123) TRUE TRUE TRUE FALSE
(4) FALSE FALSE FALSE TRUE
(14) TRUE FALSE FALSE TRUE
(24) FALSE TRUE FALSE TRUE
(24) TRUE TRUE FALSE TRUE
(124) TRUE TRUE FALSE TRUE
(34) FALSE TRUE TRUE TRUE
(134) TRUE FALSE TRUE TRUE
(234) FALSE TRUE TRUE TRUE
(1234) TRUE TRUE TRUE TRUE
> fit$v # 変数の数
() (1) (2) (3) (4)
0 1 1 1 2 2 2 2 3 3 1 2
(124) (134) (234) (1234)
(124) (1234) (24) (234) (14) (134) (23) (12) (123) (2) (13)
0.72 0.72 0.68 0.68 0.65 0.64 0.62 0.62 0.62 0.60 0.54
(1) (3) (34) () (4)
0.52 0.41 0.26 15 0.004
> a <- mylsfitv.table(fit) # 上記の結果をまとめた表
> round(a,3)
      aic      rsq      rsqadj
(124) 1 0.000 2 0.743 1 0.725
(1234) 2 1.921 1 0.743 2 0.719
(24) 3 6.357 4 0.693 4 0.679
(234) 4 6.539 3 0.704 3 0.684
(14) 5 10.983 6 0.661 5 0.645
(134) 6 12.974 5 0.661 6 0.637
(23) 7 13.625 8 0.641 7 0.625
(12) 8 14.423 9 0.635 9 0.618
(123) 9 14.753 7 0.648 8 0.623
(2) 10 15.361 10 0.612 10 0.603
(13) 11 23.629 11 0.556 11 0.536
(1) 12 24.073 12 0.532 12 0.522
```

```
3 2 3 3 4
> round(fit$coef,3) # 推定した回帰係数
Intercept 1 2 3 4
() 1.473 0.000 0.000 0 0.000
(1) 1.742 -0.028 0.000 0 0.000
(2) 5.099 0.000 -0.042 0 0.000
(12) 4.175 -0.010 -0.030 0 0.000
(3) 2.132 0.000 0.000 0 0.000
(13) 1.914 -0.022 0.000 0 0.000
(23) 4.624 0.000 -0.034 0 0.000
(123) 4.189 -0.006 -0.029 0 0.000
(14) 1.329 0.000 0.000 0 0.009
(134) 1.447 -0.032 0.000 0 0.021
(24) 5.047 0.000 -0.044 0 0.017
(124) 3.653 -0.016 -0.027 0 0.020
(34) 2.021 0.000 0.000 0 0.007
(134) 1.459 -0.031 0.000 0 0.021
(234) 4.745 0.000 -0.039 0 0.015
(1234) 3.696 -0.017 -0.027 0 0.020
```

```
> round(fit$aic,2) # 情報量規準 AIC
() (1) (2) (12) (3) (13) (23) (123) (4)
-53.17 -86.90 -95.61 -96.55 -76.78 -87.34 -97.35 -96.22 -52.41 -99
(24) (124) (1234) (34) (134) (234) (1234)
-104.61 -110.97 -75.86 -98.00 -104.43 -109.05
> o <- order(fit$aic) # AICの小さい順序
> o
[1] 12 16 11 15 10 14 7 4 8 3 6 2 5 13 1 9
> round(fit$aic[o] - min(fit$aic),2) # AIC最小モデルからの差
(124) (1234) (24) (234) (14) (134) (23) (12) (123) (2) (13)
0.00 1.92 6.36 6.54 10.98 12.97 13.62 14.42 14.75 15.36 23.63
(1) (3) (34) () (4)
24.07 34.19 35.11 57.80 58.56
> round(fit$rsq[o],2) # 決定係数
(124) (1234) (24) (234) (14) (134) (23) (12) (123) (2) (13)
0.74 0.74 0.69 0.70 0.66 0.66 0.64 0.64 0.65 0.61 0.56
(1) (3) (34) () (4)
0.53 0.42 0.43 0.00 0.03
> round(fit$rsqadj[o],2) # 修正決定係数
```

```
(124) (1234) (24) (234) (14) (134) (23) (12) (123) (2) (13)
0.72 0.72 0.68 0.68 0.65 0.64 0.62 0.62 0.62 0.60 0.54
(1) (3) (34) () (4)
0.52 0.41 0.26 15 0.004
> a <- mylsfitv.table(fit) # 上記の結果をまとめた表
> round(a,3)
      aic      rsq      rsqadj
(124) 1 0.000 2 0.743 1 0.725
(1234) 2 1.921 1 0.743 2 0.719
(24) 3 6.357 4 0.693 4 0.679
(234) 4 6.539 3 0.704 3 0.684
(14) 5 10.983 6 0.661 5 0.645
(134) 6 12.974 5 0.661 6 0.637
(23) 7 13.625 8 0.641 7 0.625
(12) 8 14.423 9 0.635 9 0.618
(123) 9 14.753 7 0.648 8 0.623
(2) 10 15.361 10 0.612 10 0.603
(13) 11 23.629 11 0.556 11 0.536
(1) 12 24.073 12 0.532 12 0.522
```

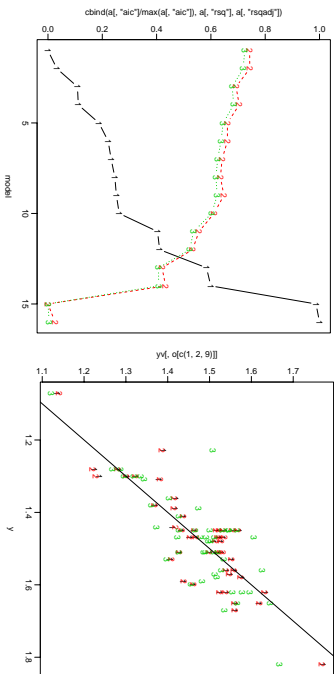
```
(3) 13 34.188 14 0.420 14 0.407
(34) 14 35.110 13 0.433 13 0.408
() 15 57.801 16 0.000 16 0.000
(4) 16 58.557 15 0.026 15 0.004
> a["aic"]/max(a["aic"]) # ちょうど 0 ~ 1 の範囲に収まるようにする。
(124) (1234) (24) (234) (14) (134) (23)
0.00000000 0.03281278 0.10856896 0.11166437 0.18755748 0.22156638 0.23267936
(12) (123) (2) (13) (1) (3) (34)
0.24630189 0.25193588 0.26232587 0.40353000 0.41111183 0.58383451 0.59959282
() (4)
0.98708914 1.00000000
> matplot(cbind(a["aic"]/max(a["aic"]),a["rsq"],a["rsqadj"]),type="b",x1=
> yv <- apply(fit$coef,1,function(beta) cbind(1,x) %>% beta) # 予期値
> matplot(y.yv[,o[c(1,2,9)]]
> abline(0,1)
```

## 多項式回帰の次数選択

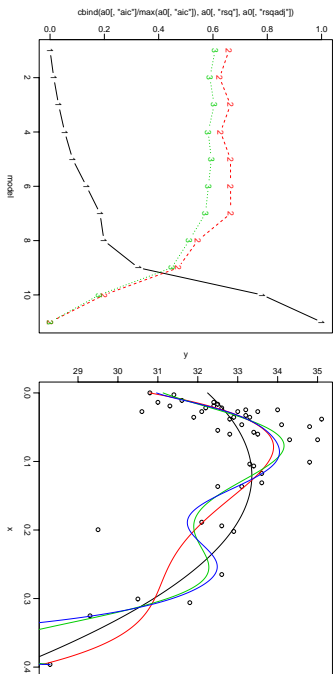
```

> ## 次数1,...,10で回帰分析
> ax <- "B02304"; ay <- "B02102"
> X2000$item[c(ax,ay)]
      B02304
      B02102
"雪 日 数(年間)"
"最高気温(日最高気温の月平均の最高値)"
> x <- X2000$x[,ax]/366 # 雪が降る頻度にしておく
> y <- X2000$y[,ay]
> m0 <- 10 # 10次回帰までしらべる
> xx0 <- apply(as.matrix(1:m0),1,function(i) x~i) # データ行列
> dimnames(xx0)[2] <- paste("X",1:m0,sep="")
> v0 <- matrix(F,m0+1,m0) # 変数の組み合わせを指定する場所
> for(i in 1:m0) { v0[i+1,1:i] <- T }
> dimnames(v0) <- list(paste("deg",0:m0,sep=""),dimnames(xx0)[2])
> v0
      X1  X2  X3  X4  X5  X6  X7  X8  X9  X10  X14
deg0  0.0  0.0  0.0  0.0  0.0  0.0  0.0  0.0  0.0  0.0  0.0
deg1  0.0  0.0  0.0  0.0  0.0  0.0  0.0  0.0  0.0  0.0  0.0
deg2  0.0  0.0  0.0  0.0  0.0  0.0  0.0  0.0  0.0  0.0  0.0
deg3  0.0  0.0  0.0  0.0  0.0  0.0  0.0  0.0  0.0  0.0  0.0
deg4  0.0  0.0  0.0  0.0  0.0  0.0  0.0  0.0  0.0  0.0  0.0
deg5  0.0  0.0  0.0  0.0  0.0  0.0  0.0  0.0  0.0  0.0  0.0
deg6  0.0  0.0  0.0  0.0  0.0  0.0  0.0  0.0  0.0  0.0  0.0
deg7  0.0  0.0  0.0  0.0  0.0  0.0  0.0  0.0  0.0  0.0  0.0
deg8  0.0  0.0  0.0  0.0  0.0  0.0  0.0  0.0  0.0  0.0  0.0
deg9  0.0  0.0  0.0  0.0  0.0  0.0  0.0  0.0  0.0  0.0  0.0
deg10 0.0  0.0  0.0  0.0  0.0  0.0  0.0  0.0  0.0  0.0  0.0

```



deg	1	2	3	4	5	6	7	8	9	10
deg0	32.2	18.4	-76.3	0.0	0.0	0.0	0.0	0.0	0.0	0.0
deg1	31.6	44.9	-274.9	365.3	0.0	0.0	0.0	0.0	0.0	0.0
deg2	30.8	94.3	-918.4	3092.5	-3579.6	0.0	0.0	0.0	0.0	0.0
deg3	30.6	110.8	-1274.6	5837.6	-12078.9	9046.4	0.0	0.0	0.0	0.0
deg4	31.1	43.6	910.1	-20998.8	135541.7	-358887.2	337864.1	0.0	0.0	0.0
deg5	30.9	84.0	-808.9	7724.7	-94117.8	579773.2	-1551290.9	0.0	0.0	0.0
deg6	30.9	90.1	-1175.9	16609.0	-198963.7	1240524.4	-3819285.7	0.0	0.0	0.0
deg7	30.9	76.7	-190.0	-12454.7	230323.8	-2302948.9	13266130.5	0.0	0.0	0.0
deg8	31.0	44.3	2848.9	-177348.3	2457603.9	-27018280.4	178824766.5	0.0	0.0	0.0
deg9										
deg10										



deg	1	2	3	4	5	6	7	8	9	10
deg0	32.2	18.4	-76.3	0.0	0.0	0.0	0.0	0.0	0.0	0.0
deg1	31.6	44.9	-274.9	365.3	0.0	0.0	0.0	0.0	0.0	0.0
deg2	30.8	94.3	-918.4	3092.5	-3579.6	0.0	0.0	0.0	0.0	0.0
deg3	30.6	110.8	-1274.6	5837.6	-12078.9	9046.4	0.0	0.0	0.0	0.0
deg4	31.1	43.6	910.1	-20998.8	135541.7	-358887.2	337864.1	0.0	0.0	0.0
deg5	30.9	84.0	-808.9	7724.7	-94117.8	579773.2	-1551290.9	0.0	0.0	0.0
deg6	30.9	90.1	-1175.9	16609.0	-198963.7	1240524.4	-3819285.7	0.0	0.0	0.0
deg7	30.9	76.7	-190.0	-12454.7	230323.8	-2302948.9	13266130.5	0.0	0.0	0.0
deg8	31.0	44.3	2848.9	-177348.3	2457603.9	-27018280.4	178824766.5	0.0	0.0	0.0
deg9										
deg10										

4-1. myLsfitivは残差平方和とRSS =  $\sum_{i=1}^n e_i^2$ を各モデル毎に計算したベクトルをrssとして返す. これを利用して, 各モデルの不偏分散 $\sigma^2$ とAICを計算する関数modelcritを作る.

### 演習問題

```

myLsfitiv(x,y) # 例題を参考にして適当にx,y,vを決める.
f$fit # サンプルサイズ
f$fp # 説明変数の数のベクトル
f$RSS # RSSのベクトル
modelcrit <- function(f) {
  # f$RSS, f$fn, f$RSSをつかって不偏分散とAICを計算
  sqe <- ... # 不偏分散の計算
  aic <- ... # AICの計算
  return(sqe,aic)
}

```

4-2. note20031010.Rtの「重回帰分析の説明変数選択」とおなじ数値列にmodelcritを適用し, 各モデルの $\sigma^2$ とAICを計算せよ. note20031010.Rt

```

deg0 FALSE FALSE FALSE FALSE FALSE FALSE FALSE FALSE
deg1 TRUE FALSE FALSE FALSE FALSE FALSE FALSE FALSE
deg2 TRUE TRUE FALSE FALSE FALSE FALSE FALSE FALSE
deg3 TRUE TRUE TRUE FALSE FALSE FALSE FALSE FALSE
deg4 TRUE TRUE TRUE TRUE FALSE FALSE FALSE FALSE
deg5 TRUE TRUE TRUE TRUE TRUE FALSE FALSE FALSE
deg6 TRUE TRUE TRUE TRUE TRUE TRUE FALSE FALSE
deg7 TRUE TRUE TRUE TRUE TRUE TRUE TRUE FALSE
deg8 TRUE TRUE TRUE TRUE TRUE TRUE TRUE TRUE
deg9 TRUE TRUE TRUE TRUE TRUE TRUE TRUE TRUE
deg10 TRUE TRUE TRUE TRUE TRUE TRUE TRUE TRUE
deg0 FALSE FALSE FALSE FALSE FALSE FALSE FALSE FALSE
deg1 TRUE FALSE FALSE FALSE FALSE FALSE FALSE FALSE
deg2 TRUE TRUE FALSE FALSE FALSE FALSE FALSE FALSE
deg3 TRUE TRUE TRUE FALSE FALSE FALSE FALSE FALSE
deg4 TRUE TRUE TRUE TRUE FALSE FALSE FALSE FALSE
deg5 TRUE TRUE TRUE TRUE TRUE FALSE FALSE FALSE
deg6 TRUE TRUE TRUE TRUE TRUE TRUE FALSE FALSE
deg7 TRUE TRUE TRUE TRUE TRUE TRUE TRUE FALSE
deg8 TRUE TRUE TRUE TRUE TRUE TRUE TRUE TRUE
deg9 TRUE TRUE TRUE TRUE TRUE TRUE TRUE TRUE
deg10 TRUE TRUE TRUE TRUE TRUE TRUE TRUE TRUE

```

```

> dev.off()
X11
2
> ##
> xs <- seq(min(x),max(x),length=300) # グラフを書くためにxの範囲を300等分
> xx1 <- apply(as.matrix(1:m0),1,function(i) xs~i) # データ行列
> xx1 <- cbind(1,xx1) # 定数項の列を加える
> a <- c(2,4,6,10) # この次数の曲線だけ描く
> plot(x,y) # 散布図
> for(i in seq(along=a)) lines(xs,xx1 %*% ffit$coef[a[i]+1,],col=i)
> psnit("20031010p2.eps",pty="s")
> plot(x,y) # 散布図
> for(i in seq(along=a)) lines(xs,xx1 %*% ffit$coef[a[i]+1,],col=i)
> dev.off()
X11
2

```

で計算したAICとmodelcritで計算したAICが等しいことを確認せよ. また,  $\sigma^2$ の小さい順が $R^2$ の大きい順と等しいことを確認せよ.

4-3. 情報量規準BICは次式で定義される.

$$BIC = -2 \times \ell + (\log n) \times \dim \theta$$

これはAICの定義とは第2項が異なっている. modelcritを修正して, BICも計算するようにせよ.

```

modelcrit <- function(f) {
  sqe <- ... # 不偏分散の計算
  aic <- ... # AICの計算
  bic <- ... # BICの計算
  return(sqe,aic,bic)
}

```

4-4. note20031010.Rtの「重回帰分析」と「多項式回帰」の二つの例について, modelcritを用いて $R^2$ , AIC, BICのそれぞれを規準でモデル選択を行い, 選択されたモデルとそのときの規準値を示せ.

4-5.  $X_{2000}$ から適当な項目を選んで重回帰分析をする．ただし説明変数は4個以上とする．4-4と同様に3つの規準でモデル選択を行い，それらの結果を比較せよ．
