

応用統計学 2017 第10回 正規線形モデル

2017年12月13日(水)

清智也 sei@mist.i.u-tokyo.ac.jp

<http://ur0.pw/yTzt>

- 正規線形(回帰)モデル, F検定, 両側検定, 片側検定, t検定, 分散分析¹.
- 次回は一般化線形モデル, 最終回は情報量規準を扱う予定。

演習問題

問題 10-1. データ $\mathbf{Y} = (Y_1, \dots, Y_n)'$ が正規線形モデルに従うと仮定する:

$$\mathbf{Y} \sim N(\boldsymbol{\mu}, \sigma^2 \mathbf{I}_n), \quad \boldsymbol{\mu} \in M, \quad \sigma^2 > 0, \quad (1)$$

ただし M は \mathbb{R}^n の線形部分空間である。いま M_0 を M の線形部分空間とし, 帰無仮説 $H_0: \boldsymbol{\mu} \in M_0$ を考える。この場合の対数尤度比検定統計量 $T(\mathbf{y})$ を求めよ。また, $T(\mathbf{y})$ は次の統計量と単調増加の関係にあることを示せ:

$$F(\mathbf{y}) = \frac{\|\mathbf{P}\mathbf{y} - \mathbf{P}_0\mathbf{y}\|^2 / (p - p_0)}{\|\mathbf{y} - \mathbf{P}\mathbf{y}\|^2 / (n - p)}.$$

ただし $\|\cdot\|$ はユークリッドノルムを表す。また \mathbf{P} と \mathbf{P}_0 はそれぞれ M と M_0 への直交射影行列を表し, p と p_0 はそれぞれ M と M_0 の次元である。

補足: 先週出題したレポート課題2と同様の手順により, 帰無仮説のもとで $F(\mathbf{Y})$ がF分布に従うことが示される。この分布に基づく検定方式がF検定である。

問題 10-2. 単回帰モデル

$$Y_i = a + bx_i + \varepsilon_i, \quad \varepsilon_i \sim N(0, \sigma^2), \quad i = 1, \dots, n,$$

を正規線形モデル(1)の形で表せ。また帰無仮説 $b = 0$ に対応する部分空間 M_0 も求めよ。

問題 10-3. 次の2つの検定の違いを説明せよ。統計モデルや帰無仮説は適宜設定せよ。

- 対応のある二群の平均値の差の検定。
- 対応のない二群の平均値の差の検定。

¹normal linear (regression) model, F-test, two-sided test, one-sided test, t-test, analysis of variance.

問題 10-4. 重回帰モデル $\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}$, $\boldsymbol{\varepsilon} \sim N(\mathbf{0}, \sigma^2 \mathbf{I})$, を考える。回帰係数 β_1 の検定について以下の問いに答えよ²。ただし, $\mathbf{X} = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_p)$, $\mathbf{X}_0 = (\mathbf{x}_2, \dots, \mathbf{x}_p)$ とおき, \mathbf{X} の列空間, \mathbf{X}_0 の列空間への直交射影行列をそれぞれ \mathbf{P} , \mathbf{P}_0 とおく。

(i) 最小二乗推定量 $\hat{\boldsymbol{\beta}} = (\hat{\beta}_1, \dots, \hat{\beta}_p)'$ の共分散行列は $\sigma^2(\mathbf{X}'\mathbf{X})^{-1}$ で与えられることを示せ。このことから回帰係数 $\hat{\beta}_1$ の標準誤差は $\text{se}(\hat{\beta}_1) = \hat{\sigma} \sqrt{((\mathbf{X}'\mathbf{X})^{-1})_{11}}$ と見積もられる。ここで $\hat{\sigma}^2 = \|\mathbf{y} - \mathbf{P}\mathbf{y}\|^2 / (n - p)$ は σ^2 の不偏推定量である (問題 6-2 参照)。

(ii) $\mathbf{r} = \mathbf{x}_1 - \mathbf{P}_0\mathbf{x}_1$, $\mathbf{e} = \mathbf{r} / \|\mathbf{r}\|$ とおくととき, 次の等式を示せ:

$$t(\mathbf{y}) := \frac{\hat{\beta}_1 - \beta_1}{\text{se}(\hat{\beta}_1)} = \frac{\mathbf{e}'(\mathbf{y} - \beta_1\mathbf{x}_1)}{\hat{\sigma}}.$$

補足: レポート課題 2 と同様の手順により, $t(\mathbf{Y})$ は t 分布に従うことが示される。この結果に基づく検定方式が t 検定であり, 普通は帰無仮説を $\beta_1 = 0$ として $t(\mathbf{y})$ の値を検討する。同時に, 母回帰係数 β_1 の厳密な信頼区間を求めることもできる。

宿題 10

問題 10-5 (1 元配置分散分析). 下のデータは, ミニ四駆の走行タイムを測定したものである。モーターを A_i としたときの走行タイムが平均 a_i , 分散 σ^2 の正規分布に従うと仮定して, 帰無仮説を $a_1 = a_2 = a_3$ とする F 検定を行いたい。

モーター	走行タイム [秒]			
トルクチューン (A_1)	16.66	15.28	14.19	15.95
レブチューン (A_2)	15.60	15.99	15.73	15.55
プラズマダッシュ (A_3)	13.53	13.47	14.96	13.47

統計ソフトウェア R で実行したところ, 以下の結果を得た。この結果を解説せよ。

```
> y1 = c(16.66, 15.28, 14.19, 15.95)
> y2 = c(15.60, 15.99, 15.73, 15.55)
> y3 = c(13.53, 13.47, 14.96, 13.47)
> y = c(y1, y2, y3)
> A = factor(c(1,1,1,1,2,2,2,2,3,3,3,3))
> lm.1 = lm(y ~ A)
> anova(lm.1)
```

Analysis of Variance Table

```
Response: y
      Df Sum Sq Mean Sq F value Pr(>F)
A       2  8.3500  4.1750  7.4401 0.01239 *
Residuals  9  5.0504  0.5612
```

```
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

²もちろん β_1 以外の回帰係数についても同様である。