

経済データ分析における多重比較の問題と knockoff 法

植松 良公

2020 年 7 月 29 日

東北大学大学院経済学研究科

回帰分析と t 検定に関する注意点について、その現代的な解決方法を含め概観する。

1. 線形回帰モデルと最小 2 乗法
2. 各係数の有意性検定と検定の誤り
3. 多重検定（多重比較）の問題
4. Family-Wise Error Rate (FWER) のコントロール
 - Bonferroni 法
5. False Discovery Rate (FDR) のコントロール
 - Benjamini-Hochberg 法
 - Knockoff 法

線形回帰モデルと最小2乗法

線形回帰モデルを考える：

$$y = x_1\beta_1 + \cdots + x_k\beta_k + u.$$

データセット $\{y_i, x_{i1}, \dots, x_{ik}\}_{i=1}^n$ が得られたとき、このモデルの係数の最小2乗推定量は、

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}\mathbf{y}.$$

ただし

$$\mathbf{X} = \begin{pmatrix} x_{11} & \dots & x_{1k} \\ \vdots & & \vdots \\ x_{n1} & \dots & x_{nk} \end{pmatrix}, \quad \mathbf{y} = \begin{pmatrix} y_1 \\ \vdots \\ y_n \end{pmatrix}.$$

係数 β_j の**有意性検定**を考える。仮説は、

$$H_0 : \beta_j = 0 \quad v.s. \quad H_1 : \beta_j \neq 0.$$

係数 β_j の **t 検定統計量**は、

$$T_j = \frac{\hat{\beta}_j}{\hat{s}_j}.$$

ただし \hat{s}_j^2 は $\hat{\mathbf{S}} = \hat{\sigma}^2(\mathbf{X}'\mathbf{X})^{-1}$ の (j, j) 要素で $\hat{\sigma}^2$ は誤差項 u の分散の推定量。

サンプルサイズ n が十分に大きいとき、中心極限定理より、 H_0 の下での t 統計量 T_n は漸近的に標準正規分布に従う：

$$T_j \xrightarrow{a} N(0, 1).$$

漸近正規性に基づいた検定を考える。

有意水準を α とすると、帰無分布 $N(0,1)$ の（両側）棄却域は $C = (-\infty, -\bar{t}_\alpha] \cup [\bar{t}_\alpha, \infty)$ と書ける。データから T_j の実現値 t_j を計算し、以下のいずれかを得る：

- $t_j \in C$ のとき、 H_0 を棄却し H_1 を採択する。このとき、 β_j は有意に 0 とは異なるという。
- $t_j \notin C$ のとき、 H_0 を採択する。このとき、統計学的には $\beta_j = 0$ を否定できない。これを「有意ではない」という。

2通りの t 検定の使われ方：

(A) 事前に検定したい仮説を考慮してモデルを作り、興味ある係数の t 検定を考える。

- 教育年数 x_1 が賃金 y に与える影響を調べたい。教育年数以外の「個人の能力」を x_2, \dots, x_k として回帰モデル
$$y = \alpha + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + u$$
 を立て、 β_1 の t 検定を行う。

(B) 回帰モデルを推定した後、 t 検定により事後的に有意な変数を選ぶ。

- 多くの経済指標 x_1, \dots, x_k の中から、経済成長 y の要因となるものを t 検定で探す。
- 多くの投資戦略 x_1, \dots, x_k の中から、ベンチマーク y を上回るものを t 検定で選ぶ。
- ある財の価格 y の決定要因を、関連のありそうな x_1, \dots, x_k の中から t 検定で探す。

仮説検定には 2 つの誤りがある：

- **第一種の過誤**：正しい H_0 を棄却する誤り。検定の定義より，第一種の過誤の確率 α は有意水準であり，分析者がコントロールできる。
- **第二種の過誤**：正しくない H_0 を棄却できない誤り。第二種の過誤の確率を β としたとき， $1 - \beta$ を**検出力**と呼ぶ：

$$\begin{aligned}1 - \beta &= 1 - \mathbb{P}(H_0 \text{ を採択} | H_1 \text{ は真}) \\&= \mathbb{P}(H_0 \text{ を棄却} | H_1 \text{ は真}).\end{aligned}$$

(B) の場合，第一種の過誤が積み上がる。これを多重検定の問題という。

複数の仮説検定を考える：

$$H_0^j : \beta_j = 0 \quad v.s. \quad H_1^j : \beta_j \neq 0, \quad j = 1, \dots, k.$$

各仮説の t 検定を $j = 1, \dots, k$ と繰り返すとき、以下の表を得る：

	H_0^j は真	H_0^j は偽	合計
H_0^j を棄却	E_1	$s - E_2$	
H_0^j を採択	$p - s - E_1$	E_2	
合計	$p - s$	s	p

- E_1 = 選ばれた「不要な」変数の数 = 第一種の過誤の数.
- E_2 = 選ばれなかった「重要な」変数の数 = 第二種の過誤の数.

FWER と Bonferroni 法

FWER (Family-Wise Error Rate) とは、「少なくとも 1 回は正しい H_0 を棄却してしまう」確率のこと。つまり

$$\begin{aligned} \text{FWER} &= \mathbb{P}(E_1 \geq 1) \\ &= 1 - \mathbb{P}(E_1 = 0) \\ &= 1 - \mathbb{P}\left(\text{正しい } H_0^j \text{ がすべて採択される}\right) \\ &= 1 - (1 - \alpha)^{k-s} \quad (\text{独立ならば}) \\ &\leq 1 - (1 - \alpha)^k. \end{aligned}$$

これは $\alpha = 0.05, k = 20$ のとき, $1 - (1 - \alpha)^k \approx 0.64$.

FWER を α 以下にコントロールするためには、個々の仮説検定における有意水準を α/k とすればよいことが知られている。これを Bonferroni の方法 (Dunn, 1961) という。

Bonferroni 法の問題点：

- 第一種の過誤の指標として FWER は非常に保守的.
- 特に k が大きいとき, 個々の H_0^j は棄却されにくくなる.
- その結果, 検出力が上がらない.

多重検定における検出力：

$$\text{Power} = \mathbb{E} \left[\frac{s - E_2}{s} \right] = \mathbb{E} \left[\frac{\text{選ばれた「重要な」変数の数}}{\text{「重要な」変数の数}} \right].$$

(一般に, 第一種の過誤を低くコントロールしつつ, 検出力が高くなる手法が望ましい.)

Benjamini & Hochberg (1995) の提案：

第一種の過誤の指標として, FWER の代わりに以下の**FDR**
(False Discovery Rate, 偽発見率) をコントロール目標とする：

$$\text{FDR} = \mathbb{E}[\text{FDP}].$$

ただし**FDP** (False Discovery Proportion) とは,

$$\text{FDP} = \frac{E_1}{s + E_1 - E_2} = \frac{\text{選ばれた「不要な」変数の数}}{\text{選ばれた変数の数}}.$$

Benjamini & Hochberg (1995) では, FDR を q 以下にコントロールする変数選択法 (**BH 法**) を提案している.

BH 法 :

1. k 個の帰無仮説 H_0^1, \dots, H_0^k に対応する p 値を p_1, \dots, p_k とする. これらを小さい順に並べたものを $p_{(1)} \leq \dots \leq p_{(k)}$ とする.
2. $p_{(j)} \leq q \times j/k$ を満たす全ての $j = 1, \dots, k$ について, 対応する $H_0^{(j)}$ を棄却 ($x_{(j)}$ を選択) する.

いくつかの仮定のもと, BH 法で選ばれた変数たちの FDR は q 以下にコントロールされる.

一方で k が大きいとき (特に $k > n$ のとき), BH 法はうまく機能しないことが知られている.

最近では、変数の数 k がサンプルサイズ n よりも大きい場合（高次元）でも回帰分析を求められる場合が多々ある。

- そもそも $k > n$ のとき最小 2 乗法は機能しない。（代わりに Lasso や Ridge 回帰が用いられるが、その場合の p 値の計算は安定しない。よって BH 法を用いるのは難しい。）

Barber & Candès (2015), Candes, Janson, Fan and Lv (2018) では、Knockoff 法という新しい FDR コントロール手法を提案した。これは p 値によらない手法で、高次元でも適用できる。

Knockoff 法 :

1. データセット $\{y_i, x_{i1}, \dots, x_{ik}\}_{i=1}^n$ を用いて、「 \mathbf{X} に似ているが \mathbf{y} とは独立な変数行列 $\tilde{\mathbf{X}}$ 」を作る (Knockoff 行列).
2. \mathbf{y} を $(\mathbf{X}, \tilde{\mathbf{X}})$ に回帰する. ($k > n$ のときは Lasso を用いる.)
3. 得られた係数の推定値 $\hat{\beta}' = (\hat{\beta}'_1, \hat{\beta}'_2)'$ を用いて,
 $W_j = |\hat{\beta}_j| - |\hat{\beta}_{p+j}|$ を計算する.
4. ある方法で閾値 $\tau > 0$ を決め, $W_j > \tau$ を満たす j について
 H_0^j を棄却 (x_j を選択) する.

いくつかの仮定のもと, Knockoff 法で選ばれた変数たちの FDR
は q 以下にコントロールされる.

Knockoff 法

一般的に Knockoff $\tilde{\mathbf{X}}$ を作るのが難しい.

Fan, Lv, Sharifvaghefi and Uematsu (2020) では, データが **ファクターモデル** $\mathbf{X} = \mathbf{F}\mathbf{B}' + \mathbf{E}$ に従うという仮定の下で, Knockoff $\tilde{\mathbf{X}}$ を生成する方法を提案した.

Knockoff 法

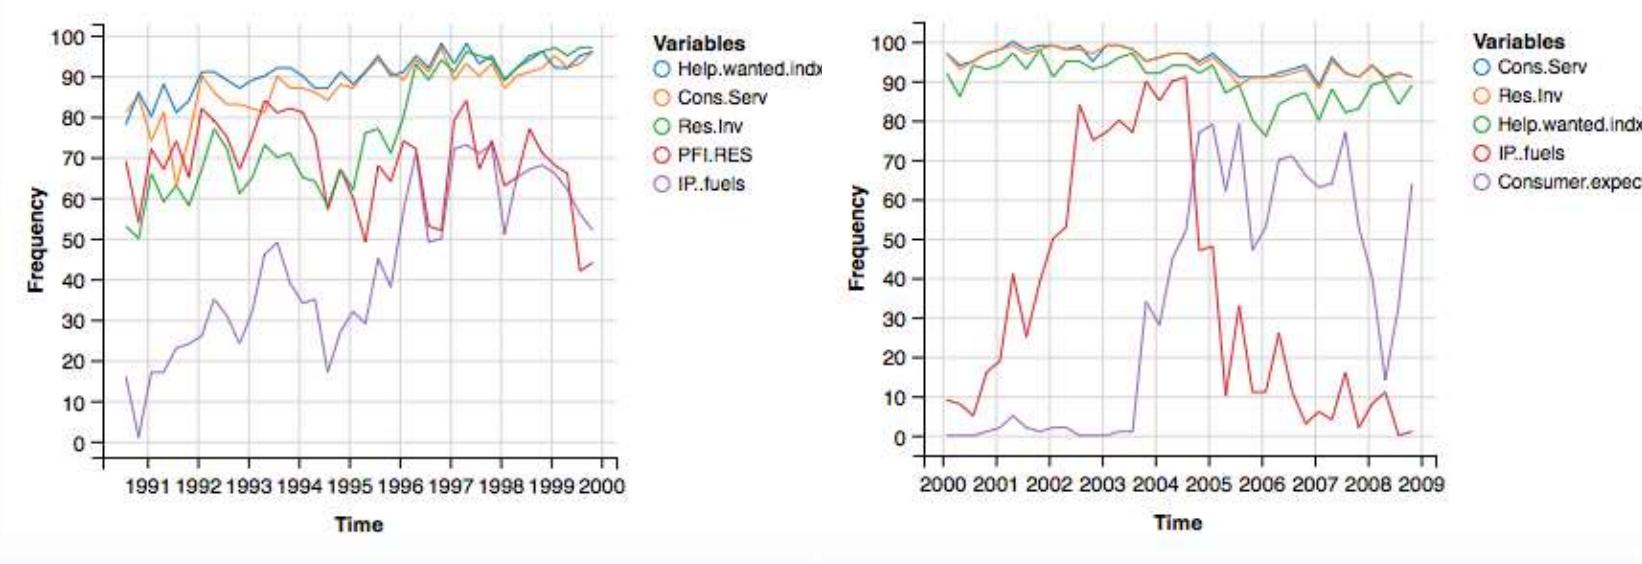


Figure 1. 1990–1999

Figure 2. 2000–2008

参考文献

- Dunn, O. J. (1961). “Multiple comparisons among means.” *Journal of the American Statistical Association*, **56**, 52–64.
- Benjamini, Y. and Y. Hochberg. (1995). “Controlling the false discovery rate: a practical and powerful approach to multiple testing.” *Journal of the Royal Statistical Society Series B*, **57**, 289–300.
- Barber, R. F. and E. Candès (2015). “Controlling the false discovery rate via knockoffs.” *Annals of Statistics*, **43**, 2055–2085.
- Candès, E., L. Janson, Y. Fan and J. Lv (2018). “Panning for gold: model-X knockoffs for high-dimensional controlled variable selection.” *Journal of the Royal Statistical Society Series B*, **80**, 551–577.
- Fan, Y., J. Lv, M. Sharifvaghefi and Y. Uematsu (2020). “IPAD: stable interpretable forecasting with knockoffs inference” *Journal of the American Statistical Association*, forthcoming.