

Title	回帰線導出の方法 ( 続 )
Sub Title	The method of regression (supplement)
Author	佐藤, 保
Publisher	慶應義塾経済学会
Publication year	1969
Jtitle	三田学会雑誌 (Keio journal of economics). Vol.62, No.8 (1969. 8) ,p.942(176)- 949(183)
JaLC DOI	10.14991/001.19690801-0176
Abstract	
Notes	寺尾琢磨教授退任記念特集号 研究ノート
Genre	Journal Article
URL	<a href="https://koara.lib.keio.ac.jp/xoonips/modules/xoonips/detail.php?koara_id=AN00234610-19690801-0176">https://koara.lib.keio.ac.jp/xoonips/modules/xoonips/detail.php?koara_id=AN00234610-19690801-0176</a>

慶應義塾大学学術情報リポジトリ(KOARA)に掲載されているコンテンツの著作権は、それぞれの著作者、学会または出版社/発行者に帰属し、その権利は著作権法によって保護されています。引用にあたっては、著作権法を遵守してご利用ください。

The copyrights of content available on the KeiO Associated Repository of Academic resources (KOARA) belong to the respective authors, academic societies, or publishers/issuers, and these rights are protected by the Japanese Copyright Act. When quoting the content, please follow the Japanese copyright act.

# 回帰線導出の方法 (続)

佐藤 保

(一)

本稿は先に三田学会誌に三回にわたって述べた回帰線導出の方法の続きである。前回までの結果をまとめておく。資料は

	Y <sub>1</sub>	Y <sub>2</sub>	X <sub>1</sub>	X <sub>2</sub>	X <sub>3</sub>
昭和 27	7096	8330	1163.5	100.0	9241
28	8741	8250	1505.1	95.3	10575
29	10640	8000	150.76	90.8	12834
30	10519	7697	1469.0	88.1	16230
31	12969	6497	2044.9	90.8	17514
32	15107	7000	2684.3	97.6	18696
33	14904	6700	2665.3	95.7	21408
34	17169	6300	3263.2	91.4	23148
35	22425	6700	4339.9	88.4	29020
36	24484	6000	5985.2	86.6	31200
37	28662	6350	6534.6	84.9	35568
38	29766	6275	7083.5	82.2	43200

Y<sub>1</sub>=セメントの生産量, Y<sub>2</sub>=セメントの価格, X<sub>1</sub>=総投資量, X<sub>2</sub>=石炭価格指数(原材料価格,あるいは生産コストの代用), X<sub>3</sub>=セメント容量(セメントの生産能力), Y=内生変数, X=外生変数

方程式は

(1)  $Y_1 = a_0 + a_1 Y_2 + a_2 X_1$

(2)  $Y_1 = b_0 + b_1 Y_2 + b_2 X_2 + b_3 X_3$

(1)は需要函数, (2)は供給函数を示すものとする。資料は最初の10年間を使い,あとは2年間を予測するものとする。種々の方法の計算結果は,

(1)式について

古典的最小自乗法

$Y_1 = 15937.915 - 1.3428373 Y_2 + 3.0288719 X_1$   
(0.82297691) (0.4590877)

R=0.9808

二段階最小自乗法

$Y_1 = 31993.518 - 3.26840 Y_2 + 2.16781 X_1$  R=0.9665  
(1.3896165) (0.69306376)

三段階最小自乗法

$Y_1 = 31993.518 - 3.26840 Y_2 + 2.16781 X_1$  R=0.9655  
(1.3896344) (0.6930749)

(二段階でも三段階でも値が変らない)

情報制限最尤法

$Y_1 = 33305.842 - 3.4149039 Y_2 + 2.1023280 X_1$   
(1.74629419) (0.86816577)

R=0.9629

完全情報最尤法

$Y_1 = 27012.646 - 2.662552 Y_2 + 2.4387496 X_1$

R=0.9736

(2)式について

古典的最小自乗法

$Y_1 = -11426.029 + 0.65972410 Y_2 + 53.979740 X_2$   
(0.96216042) (109.87524)

$+ 0.84805669 X_3$  R=0.9867  
(0.12400791)

二段階最小自乗法

$Y_1 = -78983.355 + 6.769584 Y_2 + 174.9051 X_2$   
(7.7681373) (274.95572)

$+ 1.518458 X_3$  R=0.8961  
(0.86173357)

三段階最小自乗法

$Y_1 = -66134.1285 + 6.5403 Y_2 + 72.450 X_2$   
(7.7585786) (206.85008)

$+ 1.46145 X_3$  R=0.8883  
(0.85580928)

情報制限最尤法

$Y_1 = -78992.356 + 6.7576317 Y_2 + 174.88979 X_2$   
 $+ 1.5140387$

(情報制限最尤法と二段階最小自乗法はこの場合原理的に一致すべきものであり,値の差は計算誤差によるものである。)

完全情報最尤法

# 回帰線導出の方法 (続)

	X <sub>1</sub>	X <sub>2</sub>	X <sub>3</sub>	Y <sub>1</sub>	Y <sub>2</sub>
X <sub>1</sub>	1.0000000	-0.54398195	0.94679313*	0.97339518*	-0.80120823*
X <sub>2</sub>	-0.54398195	1.0000000	-0.62157664	-0.59230707	0.48521478
X <sub>3</sub>	0.94679313*	-0.62157664	1.0000000	0.98568452*	-0.88180014*
Y <sub>1</sub>	0.97339518*	-0.59230707	0.98568452*	1.0000000	-0.85186380*
Y <sub>2</sub>	0.80120823*	0.48521478	-0.88180014*	-0.85186380*	1.0000000

\*印は有意水準1%で有意。

$Y_1 = 29156.153 + 2.246441 Y_2 + 86.456960 X_2$   
 $+ 1.0244547 X_3$  R=0.9801

$(R = \sqrt{1 - \frac{\sum(\text{実際値} - \text{推定値})^2}{\sum y^2}})$  とした。  $y = \sum(Y - \bar{Y})^2$

単純誘導形

$Y_1 = 794.651 + 1.43705 X_1 + 6.68748 X_2 + 0.48275 X_3$   
(0.547681) (77.115504) (0.121721)

$Y_2 = 11792.495 + 0.21265 X_1 - 24.8907 X_2 - 0.15325 X_3$   
(0.319284) (44.956263) (0.070966)

構造方程式より逆算した誘導形

$Y_1 = 1087.165 + 1.4454645 X_1 + 2.4141383 X_2$   
(0.42915284) (59.827504)

$+ 0.48697618 X_3$   
(0.090416840)

$Y_2 = 10070.816 + 0.22100888 X_1 - 7.3862992 X_2$   
(0.25893716) (17.25572)

$- 0.14899526 X_3$   
(0.051897159)

単純な時間回帰

$Y = a + bt$  (t=昭和27年を1とする)

$Y_1 = 4398.13 + 1819.50t$  r=0.969

$Y_2 = 7536.56 - 70.76t$  r=0.482

予測値(部分分析)

(1)式

Y <sub>1</sub> 実際値	古典的 最小自 乗法	二段階 最小自 乗法	三段階 最小自 乗法	完全情 報最尤 法	時間変 数	
37	28662	27203	25405	25405	26041	24413
38	29766	28967	26840	29840	27580	26232

(2)式

37	28662	27510	32861	33529	28887	24413
38	29766	33787	43470	43996	36303	26232

	X <sub>1</sub>	X <sub>2</sub>	X <sub>3</sub>	Y <sub>1</sub>	Y <sub>2</sub>
X <sub>1</sub>	.20941569 E+08	-.33240380 E+05	.95561043 E+08	.76003989 E+08	-.93642286 E+07
X <sub>2</sub>	-.33240380 E+05	.17830100 E+03	-.18305971 E+06	-.13494798 E+06	.16547520 E+05
X <sub>3</sub>	.95561043 E+08	-.18305971 E+06	.48645469 E+09	.37093833 E+06	-.49672198 E+08
Y <sub>1</sub>	.76003989 E+08	-.13494798 E+06	.37093833 E+09	.29112880 E+09	-.37122290 E+08
Y <sub>2</sub>	-.93642286 E+07	.16547520 E+05	-.49672198 E+08	-.37122290 E+08	.65229498 E+07

E+08=10<sup>8</sup>

注(1) Basmann, R. L., Letter to the Editor, Econometrica, 1962. No. 4, p. 824-826.

げ,

$$C(Y_t) = \beta_1 Y_t + r_1 + u_t \quad (\text{消費})$$

$$0 < \beta_1 < 1 \quad r_1 \geq 0$$

$$I(Y_t) = \beta_2 r_t + \beta_3 Y_t + v_t \quad (\text{投資})$$

$$\beta_2 < 0 \quad \beta_3 > 0$$

$$L(Y_t) = \beta_4 Y_t + \beta_5 r_t + w_t \quad (\text{流動性選好})$$

攪乱項は  $t=1, 2, \dots, n$  で同一の分布をして,

$$f(u_t, v_t, w_t) = \left(\frac{1}{2\pi}\right)^3 \frac{1}{\sigma_1 \sigma_2 \sigma_3} \exp \left\{ -\frac{1}{2} \left[ \frac{u_t^2}{\sigma_1^2} + \frac{v_t^2}{\sigma_2^2} + \frac{w_t^2}{\sigma_3^2} \right] \right\}$$

とする。  $Y_t^*, C_t^*, r_t^*, Q_t^*$  を所得, 消費, 利子率, 貨幣供給量, とする。  $Q_t^*$  のみが外生変数とされる。

$$C(Y_t^*) = C_t^*$$

$$Y_t^* - C(Y_t^*) = I(Y_t^*, r_t^*)$$

$$L(Y_t^*, r_t^*) = Q_t^*$$

誘導形は

$$Y_t^* = \frac{\beta_2}{D} Q_t^* + \frac{\beta_1 r_1}{D} + \left\{ \frac{\beta_1(u_t + v_t) - \beta_2 w_t}{D} \right\}$$

$$r_t^* = \frac{(1 - \beta_1 - \beta_3) Q_t^* - \beta_3 r_1}{D} + \left\{ -\frac{\beta_3(u_t + v_t) + (1 - \beta_1 - \beta_3) w_t}{D} \right\}$$

$$C_t^* = \frac{\beta_1 \beta_2}{D} Q_t^* + \left\{ \frac{\beta_1 \beta_1}{D} + 1 \right\} r_1 + \left\{ \frac{\beta_1 [\beta_1(u_t + v_t) - \beta_2 w_t]}{D} + u_t \right\}$$

$$D = \beta_1(1 - \beta_1 - \beta_3) + \beta_2 \beta_3 \neq 0$$

$\sigma_1^2, \sigma_2^2, \sigma_3^2$  は極端に小さいが 0 でないとする。

$$S^2 Q_t^* = \sum_{t=1}^n (Q_t^* - \bar{Q}^*)^2$$

誘導形に対する重相関係数は

$$\rho_{Y, Q}^* = \frac{\beta^2 E \sum_{t=1}^n (Y_t^* - \bar{Y}^*)(Q_t^* - \bar{Q}^*)}{E \sum_{t=1}^n (Y_t^* - \bar{Y}^*)^2}$$

注(2) Hooper, John, W., Simultaneous Equations and Canonical Correlation Theory. Econometrica 1959. No. 2, p. 245-256.

(3) 読者に便利のためホッパーの正準相関をその論文から引用しておく。正準相関とは正準変数 (canonical variate) 間の相関を言うが、今方程式体系で従属変数  $Y_1, \dots, Y_m$ , 外生変数  $X_1, \dots, X_n$  とする。行列の形で示せば  $Y$  は  $T$  行  $M$  列,  $X$  は  $T$  行  $N$  列の行列で示される。  $Y_1, \dots, Y_n$  と  $X_1, \dots, X_n$  を一次変換して  $h_1, \dots, h_n$  と  $\xi_1, \dots, \xi_n$  にする。

(i) すべての  $\xi$  と  $\eta$  は平均 0, 平方和 1 をもつ。

(ii) すべての  $\xi$  はすべての他の  $\xi$  と無相関であり, すべての  $\eta$  はすべての他の  $\eta$  と無相関である。

(iii)  $\xi$  と  $\eta$  との間の相関は,  $\xi_1$  と  $\eta_1, \xi_2$  と  $\eta_2$  等の相関である  $r_1, r_2, \dots$  で  $n$  個あるいは  $M$  個 (もし  $n \leq M$  なら  $n$ , もし  $n > M$  なら  $M$ ) を除いて 0 である。  $\xi$  と  $\eta$  は正準変数と呼ばれ  $r_1, r_2, \dots$  は正準相関と呼ばれる。そして

(i)  $Y_k = \eta, X_h = \xi$

誘導形として

$$Y = X\Pi + V$$

$$\hat{Y} = X\hat{P} \quad P = (X'X)^{-1}X'Y$$

$$\hat{Y}'\hat{Y} = Y'X(X'X)^{-1}X'Y = Y'SY$$

$$S = X(X'X)^{-1}X'$$

$M$  個の内生変数とすれば,  $M \times M$  の行列を  $D$  とすると,

$$I - D \equiv (Y'Y)^{-1}Y'SY$$

とする。もし  $M=1$  とすれば通常重相関係数と一致する。

の対を考える。

$$(2) \eta'\eta = k'Y'Yk = 1 \quad \xi'\xi = h'X'Xh = 1$$

$\eta$  と  $\xi$  との相関は

$$(3) r = \xi'\eta = h'X'Yk$$

これは  $h$  と  $k$  の変化に対して安定的でなければならない。そこで条件のつかない安定的値を考えるため

$$(4) h'X'Yk - \frac{1}{2}\lambda_1(h'X'Xh - 1) - \frac{1}{2}\lambda_2(k'Y'Yk - 1)$$

をつくる。ここで  $\lambda$  はスカラーでラグランジュ乗数である。(4) を  $h$  と  $k$  で微分すると

$$(5) X'Yk - \lambda_1 X'Xh = 0$$

$$Y'Xh - \lambda_2 Y'Yk = 0$$

最初の方程式に  $h'$  を前から乗じ, 二番目に  $k'$  を乗じ, (2) と (3) の値によって

$$(6) \lambda_1 = \lambda_2 = r$$

(5) の最初の式と (6) を結びつけて

$$h = \frac{1}{r}(X'X)^{-1}X'Yk$$

これを二番目の式と結合して

$$(7) [(Y'Y)^{-1}Y'X(X'X)^{-1}X'Y - r^2 I]k = 0$$

をうる。そしてこの式から正準相関の自乗は行列  $(Y'Y)^{-1}Y'X(X'X)^{-1}X'Y$  の固有根であることがわかる。母集団では,

$$(8) |E(Y'Y)^{-1}E(Y'X)(E(X'X))^{-1}E(X'Y) - \rho^2 I| = 0$$

さて同時方程式の体系に應用すると,

$$(9) YB + X\Gamma = U$$

$B$  と  $\Gamma$  はパラメーター行列, ( $B$  は正方で非特異),  $U$  は  $T$  行  $M$  列の攪乱行列。体系の誘導形は

$$(10) Y = -X\Gamma B^{-1} + UB^{-1} = X\Pi + \bar{V}$$

$\Pi$  は母集団の誘導形の係数行列,  $\bar{V}$  は攪乱行列である。最小自乗法による誘導形の推定は

$$(11) Y = X\hat{P} + \bar{V}$$

ここで  $P = (X'X)^{-1}X'Y$  これから

$$(12) (Y'Y)^{-1}P'X'XP = (Y'Y)^{-1}Y'X(X'X)^{-1}X'Y = I - D$$

$I$  は  $M$  次の単位行列,  $D$  は (12) 式で示される。この行列の固有根は (7) で示されたものである。

$$(13) |(Y'Y)^{-1}P'X'XP - r^2 I| = 0 \quad \text{あるいは} \quad |(I - D) - r^2 I| = 0$$

$X'V = 0$  であるから

$$Y'Y = P'X'XP + \bar{V}'\bar{V}$$

$$(14) (Y'Y)^{-1}V'V = D$$

$$(15) |(Y'Y)^{-1}V'V - (1 - r^2)I| = 0 \quad \text{あるいは} \quad |D - (1 - r^2)I| = 0$$

そしてこの  $r$  は  $Y$  と  $X$  との間の正準相関であり, 普通の重相関の一般化であると考えられる。そして  $M$  個の  $r^2$  の和の平均をもってそれは  $(I - D)$  の跡を  $M$  で割ったものに等しいので, その値をもって跡相関とする。そして前述のように従属変数の総分散がどれだけ説明されているかの尺度としようとする。

加えてMで割ればよいことにする。

現在の場合

$$Y'X = \begin{pmatrix} .76003989E+08 & -.13494789E+06 \\ -.93642286E+07 & .16547520E+05 \\ & .37093833E+09 \\ & -.49672198E+08 \end{pmatrix}$$

$$P = \begin{pmatrix} .143705E+01 & .21265449E+00 \\ .668748E+01 & -.248907E+02 \\ .48275082E+00 & -.15325198E+00 \end{pmatrix}$$

$$Y'XP = \begin{pmatrix} .28738985E+09 & -.37325495E+08 \\ -.37325495E+08 & .5269138E+07 \end{pmatrix}$$

$$(Y'Y)^{-1} = \begin{pmatrix} .29112880E+09 & -.37122290E+08 \\ -.37122290E+08 & .65229498E+07 \end{pmatrix}^{-1}$$

$$= \begin{pmatrix} .1252115E-07 & .712582E-07 \\ .712582E-07 & .558837E-06 \end{pmatrix}$$

$$I-D \equiv (Y'Y)^{-1}Y'SY = \begin{pmatrix} .287389853E+09 & -.37325495E+08 \\ -.37325495E+08 & .5209138E+07 \end{pmatrix}$$

$$= \begin{pmatrix} .1252115E-07 & .712582E-07 \\ .712582E-07 & .558837E-06 \end{pmatrix}$$

$$= \begin{pmatrix} 0.93870387 & -0.3802383 \\ -0.096164324 & 0.25131147 \end{pmatrix}$$

$$r^2 = \frac{0.93870387 + 0.25131147}{2} = \frac{1.190}{2} = 0.595$$

$$r = 0.771367$$

と計算される。この計算の途中で誘導形に対する通常の重相関を計算できる。すなわち

$$R_1^2 = \frac{.287389853E+09}{.29112880E+09} = 0.987 \quad R_1 = 0.994$$

$$R_2^2 = \frac{.5209138E+07}{.65229498E+07} = 0.799 \quad R_2 = 0.894$$

$r^2$  は約 0.6 であり、全体の外生変数で全体の内生変数の説明力は 6 割となりかなりひくくなる。これは第 2 方程式の説明力がかなり低いためである。これに対して個々の重相関の値はかなり高い。 $r^2$  の値が非常にひくくなるときは、個々の誘導形の重相関が高く、その結果予測式としてかなり役立つと考えられても、構造推定式としては若干問題を残すことになる。なおお附言すれば

I-D より特性根を求めれば

$$r_1 = 0.988317$$

$$r_1 + r_2 = 1.19$$

$$r_2 = 0.201698$$

注(4) Christ Econometric Theory and Models, p. 539-542.

となり先の計算結果と一致する。 $r_2$  はやはり低い。 $r$  の分散を求めると、 $X$  が random variable と考えるとき、

$$\sigma^2_{\bar{r}} = \frac{1}{TM^2 \rho^2} \sum_{u=1}^M \rho_u^2 (1 - \rho_u^2)^2 \quad \sigma^2_{r_1} = 4\rho^2 \sigma^2_{\bar{r}}$$

$$\sigma^2_{r_2} = \frac{4}{TM^2} \sum_{u=1}^M \rho_u^2 (1 - \rho_u^2)^2$$

$X$  が fixed variable と考えるとき

$$\sigma^2_{\bar{r}} = \frac{1}{2TM^2 \rho^2} \sum_{u=1}^M \rho_u^2 (1 - \rho_u^2)^2 (2 - \rho_u^2)$$

$$\sigma^2_{r_2} = \frac{2}{TM^2} \sum_{u=1}^M \rho_u^2 (1 - \rho_u^2)^2 (2 - \rho_u^2)$$

の式に値を代入すれば、 $X$  が random variable のとき

$$\sigma^2_{r_2} = \frac{4}{10 \times 4} [0.988317(1 - 0.988317)^2 + 0.201698(1 - 0.201698)^2] = 0.013$$

$$\sigma^2_{\bar{r}} = \frac{0.013}{4 \times 0.6} = 0.0054$$

同様に  $X$  が fixed variable のときは、

$$\sigma^2_{r_2} = \frac{2}{10 \times 4} [0.000134892(2 - 0.988317) + 0.128539(2 - 0.201698)] = 0.001156$$

$$\sigma^2_{\bar{r}} = 0.00048$$

となり有意となっている。

次に情報制限最尤法に対する overidentify の先験的制約の検定を行ってみる。この方法は次の統計量を計算しきめられた水準より大きければ overidentify についての仮説が正しいということを棄却することになる。<sup>(4)</sup>

まず情報制限最尤法の計算で求められた、最大根を  $\lambda_1$  とすると、

$$1 + \frac{1}{\lambda_1} = l_1$$

$l_1$  は最小根である。 $T \log_e l_1$  を計算する。帰無仮説が正しいとき、 $T$  (観測期間)が増大するとき、 $T \log_e l_1$  は漸近的に自由度  $K - J - H + 1$  の  $\chi^2$  分布をする。このことはアンダーソンとルービンによって発見された。ここで  $K$  はモデル全体の外生変数 (先決変数を含む) の数、 $J$  は推定される方程式に入っている外生変数の数、 $H$  は推定される方程式に入っている内生変数の数である。just identify の方程式では  $K - J - H + 1$  は 0 になり検定は行えない。overidentify の検定を行ってこれが否定されたときでも直ちに just であるという理由にはならないのである。

パースマンは

$$(l_1 - 1)(T - K) / K - J - H + 1$$

が自由度  $K - J - H + 1$  と  $T - K$  の  $F$  分布を示してこの検定方法による方がよいことを示している。大標本による方法であることから、小標本に用いることは近似的意味しかないが多くの場合やむを得ない。クリストは自己のアメリカ経済のモデルで 10 個の方程式に対して検定を行ったところ、95% 水準において、アンダーソン、ルービンの方法では 2 個、パースマンの方法では 3 個を除いてすべて棄却されてしまった。

現在の場合では、

$$l_1 = 1 + \frac{1}{\lambda_1} \quad l_1 = 1 + \frac{1}{31.28778} = 1.032$$

$$T \log_e l_1 = 10 \log_e 1.032 = 0.31464$$

$$K - J - H + 1 = 3 - 1 - 2 + 1 = 1$$

自由度 1 の  $\chi^2$  分布の 5% 点は 3.84 であるから勿論有意ではない。

$$\frac{(T - K)(l_1 - 1)}{K - J - H + 2} = \frac{(10 - 3)(1.032 - 1)}{10 - 1 - 2 + 1} = 0.224$$

$$F(K - J - H + 1, T - K) = F(1, 7)$$

自由度 1, 7 の  $F$  分布の 5% 点は 5.59 であるから勿論有意ではない。

これで一応 overidentify の仮定の正しさが立証されたことになる。

(三)

次に統計的予測あるいは統計的回帰式という意味から逐次重回帰の計算を行ってみる。

ドレーパーとスミスはその著書の中で回帰式選定の方法として五つのものをあげている。

- (1) すべての可能な回帰式の検討
- (2) 後退消去手順 (backward elimination procedure)
- (3) 前進選定手順 (forward selection procedure)
- (4) 段階的 (あるいは逐次) 回帰手順 (stepwise regression procedure)
- (5) 段階的回帰手順 (stagewise regression procedure)

それぞれについて簡単に説明すると、(1) 従属変数を  $Y$  とし、独立変数を  $X_1, \dots, X_k$  とすれば、文字通り  $k$  個の独立変数のすべての組合せについて回帰式をつくり、それぞれの  $R^2$  を求めてそれから適当な組合せをみつける。しかし  $k$  が大きいときはすべてを計算することは非常にはんざつである。通常

次の方法がとられる。例えば  $X_1, X_2, X_3, X_4$  と 4 個の独立変数があるとき、まず 1 個選ぼうとすれば当然  $Y$  と最も相関の高い変数か選ばれるであろう。これが  $X_1$  であったとする。次に 2 個の変数の組合せをつくり、最も相関の高い組を選ぶ。これが  $X_1, X_2$  の組であったとする。次いで三変数の組では、 $X_1, X_3, X_4$  であり、最後に  $Y$  変数  $X_1, X_2, X_3, X_4$  が計算される。それぞれの相関をみて、一変数から二変数にしたときは相関が非常に高まったが、三変数にしてもあまり変わらないときは二変数の組とする。二変数で同じくらい高い相関のものが何組かあるときは、他の情報、経済的知識等によって選ぶことにする。

また 1 変数、2 変数、3 変数、4 変数の時の残差の不偏分散をそれぞれもつて、その平均を計算して、その平均が急に小さくなる点で何個の変数を選んだらよいかをきめる方法もある。しかし前の相関からみた場合と異った結果を生ずることもある。

(2) はまず最初に全部の独立変数を入れた回帰をつくり、4 変数なら  $X_1, X_2, X_3, X_4$  を全部入れて回帰をつくる。そしてそれぞれの変数について、あたかもそれが一番最後に入れられたかのように考えて有意性の検定を行う。そして例えば  $X_3$  が有意でなければ  $X_3$  を除外して  $X_1, X_2, X_4$  のみの回帰をつくり、更に  $X_4$  が有意でなければ、 $X_1, X_2$  とする。この方法は (1) よりも簡単であるが、最初にすべての回帰を計算するのでこのとき独立変数の分散行列が特異な形に近いとき、それ以後の手順が丸めの誤差の影響を受けるという欠点がある。

(3) この方法は (2) と反対に一つずつ加えてゆくという方法である。 $X_1, X_2, X_3, X_4$  があるとき最初は  $Y$  と最も高い相関のものを選ぶ、これが  $X_1$  であるとすればそれを入れる。次に残りの  $X_2, X_3, X_4$  のうち、 $X_2$  を導入した後の  $Y$  と最も高い偏相関のあるものを選ぶ。これが  $X_2$  であるとすればそれを導入する。次に  $X_3$  ならばそれを導入する。そして有意でない変数に達すればそこで止めるということになる。この方法は簡単なものから順次進んでゆくという点で計算上からも便利であるが、新しく変数を導入したときそれがすでに導入された変数に対してどのような影響を与えたかを考察していない。この欠点をとり除こうというのが段階的 (あるいは逐次) 回帰の手順となる。

(4) は (3) を改良しようとするもので新しい変数を導入したとき、その前に導入された変数についても再検討

注(5) N. R. Draper and H. Smith, Applied Regression Analysis. 中村慶一訳 (応用回帰分析), p. 163-172.



を行う、として前の段階で導入された最良の変数であっても、後の段階では他の変数との関連で落ちてしまうこともある。これをチェックするため各計算段階において回帰式に存在する各変数に対するFの値あるいはtの値を有意水準の値と比較して、有意でないものはとり除かれる。例えば  $X_1, X_2, X_3, X_4$  があるとき最初は最も相関の高い変数が導入される。これが  $X_1$  であればそれを入れる。つぎに  $X_1$  が導入された後でYと最も高い偏相関のある変数が導入される。 $X_1$  であればそれを導入する。その際先に入れた  $X_1$  の有意性を再検討し有意であればそのまま残す。次に高い偏相関をもつものを入れる。これが  $X_2$  であればそれを入れる。そしてこの際の  $X_1, X_2$  について検定を行い、 $X_1$  が有意でなくなればこれを落してしまう。残りの  $X_3$  についてみてこれが有意でなければ、結局  $X_1$  と  $X_2$  で回帰が形成されることになる。変数が多いときにはまずこの方法で入れるべき変数の数をきめて、そのうえですべての可能な組合せを検討することも考えられる。又有意水準を変えることによって当然入ってくる変数の数も異ってくる。

(5)の方法はまずYと最も相関の高い変数Xを用いた回帰方程式が当てはめられた後に、残差 ( $Y_i - \hat{Y}_i$ ) を計算し、これらの残差を従属変数と考えてこの値を最も高い相関をもつ X (残っているものなかで) に対する回帰を考える。この手順はどの段階に対しても続けられる。この方法によって与えられた回帰式は最小自乗法によるものとは異なる。 $X_1, X_2, X_3, X_4$  があるときまず最高の相関の  $X_1$  が選ばれる。 $X_1$  へのYの回帰を考える。 $\hat{Y} = a + bX_1$ 。残差  $z_i = Y_i - \hat{Y}_i$  を各  $X_1$  の値に対して計算する。この残差  $z_i$  を従属変数として残ったXの中からこの残差に最も高い相関のものを選定する。 $X_1$  が最も高い相関であるとする、 $z = a' + b'X_1$  を計算する。 $Y_i = \hat{Y}_i + (Y_i - \hat{Y}_i) = \hat{Y}_i + z_i = a + bX_1 + a' + b'X_1 = (a + a') + bX_1 + b'X_1$  でこれは普通の最小自乗法とは異った結果をあたえる。更に変数を加えていって残差と新変数の回帰が有意でなくなったら計算をやめる。この方法は通常の最小自乗法より精度が悪くなるが、Yとの相関度以外の理由によって変数を選択することが可能になるという利点もある。

以上の5つの方法を述べた後スミスとドレーパーは(4)の方法が最もすぐれているであろうと述べている。

このうち(1)と(4)の方法を用いてみよう。まず変数の数をきめるため残差平方分散をみると、

変数	平均	決定係数
一変数		
1382.2508 ( $X_1$ )	平均	94.75
4860.4621 ( $X_2$ )	2419.9296	35.08
1017.0760 ( $X_3$ )		97.16
二変数		
1396.6505 ( $X_1, X_2$ )	平均	95.31
731.2963 ( $X_1, X_3$ )	1067.4113	98.71
1074.2871 ( $X_2, X_3$ )		97.23
三変数		
789.3890 ( $X_1, X_2, X_3$ )		98.72

これから考えると二変数 ( $X_1, X_2$ ) の組であるとも考えられる。この回帰は

$$Y_1 = 1469.7360 + 1.4454246X_1 + 0.47858956X_2$$

とする。これより予測を試みれば

昭和 37	27937
38	32384

となる。

$X_3$  のみを使うときは、

$$Y_1 = -72.533 + 0.76253431X_3$$

昭和 37	27049
38	32868

となる。

次に逐次回帰を用いてみよう。

$X_1$  が最も高い相関をもっているから

step 1.

$$Y_1 = -72.533 + 0.76253427X_1, R^2 = 0.9716$$

(0.046113910)

step 2.

$$Y_1 = 1469.7350 + 1.4454222X_1 + 0.47858995X_2$$

(0.49652885) (0.10302150)

$R^2 = 0.9871$

この段階で計算は終る。従ってこの場合(1)も(4)も同じ結果を与えることになり、統計的予測という面からは  $X_1$  と  $X_2$  を独立変数とすることがよいと言えよう。なお独立変数として  $Y_2$  を加えた場合も逐次回帰の結果は全く変わらず  $X_1$  と  $X_2$  が選ばれた。

次にこれまでは標本の大きさ 10 ですべての計算が行われたが、これを 12 にする。昭和 37, 38 年まで計算期間としたときどの程度の変化が起きるかをみてみよう。逐次回帰を計算してみると、(独立変数  $X_1, X_2, X_3$  のとき)

step 1

$$Y_1 = 4829.3180 + 3.5911599X_1, R^2 = 0.9761$$

(0.17766876)

step 1 をもってはやくも終わってしまう。そして前とは異った  $X_1$  という変数が入ってくる。 $Y_2$  を独立変数

に加えたときは、標本 12 のとき

step 1

$$Y_1 = 4829.3180 + 3.5911599X_1, R^2 = 0.9761$$

(0.17766876)

step 2

$$Y_1 = 13584.780 - 1.0903475Y_2 + 3.2589932X_1$$

(0.66034577) (0.25959234)

$R^2 = 0.9817$

この結果も標本 10 の場合と大きく異っている。独立変数  $X_1, X_2, X_3$  全部を考えたときについて標本 10 と 12 を比較してみると、

標本 10

$$Y_1 = 794 + 1.437X_1 + 6.69X_2 + 0.4828X_3$$

(0.54) (77) (0.121)

標本 12

$$Y_1 = 3114 + 1.980X_1 - 3.998X_2 + 0.3342X_3$$

(0.64) (98) (0.14)

$X_2$  の値は有意ではないが (5% で) プラスからマイナスに変わっている。 $Y_2$  を加えたときは

標本 10

$$Y_1 = -1030 + 0.1547Y_2 + 1.4041X_1 + 10.5412X_2$$

(0.75) (0.62) (86)

注(6) 標本が 12 の場合の相関行列は次の如くなり、5% 水準ですべて有意となっている。これから標本の大きさが小さいときは、かなりの変動のあることがわかる。

	$X_1$	$X_2$	$X_3$	$Y_1$	$Y_2$
$X_1$	1.00000000	-0.76442904*	0.97297765*	0.98798193*	-0.77494435*
$X_2$	-0.76442904*	1.00000000	-0.80528125*	-0.78426861*	0.59097228**
$X_3$	0.97297765*	-0.80528125*	1.00000000	0.98561912*	-0.81261437*
$Y_1$	0.98798193*	-0.78426861*	0.98561912*	1.00000000	-0.81273610*
$Y_2$	-0.77494435*	0.59097228**	-0.81261437*	-0.81273610*	1.00000000

\*印は 1% で有意。 \*\*印は 5% で有意。