

回帰分析 ～線形代数の視点から～

Ver.2022.09.03

松浦 真也

1 重回帰分析の定式化

ある大学の m 人の学生の n 科目の成績のデータを扱う. i 人目の j 番目の科目の点数を u_{ij} で表す. 例えば, 学生の名前が一郎君, 二郎君, 三郎君, ... で, 科目名が代数 1, 代数 2, 代数 3, ... だとすると, u_{32} は「三郎君の代数 2 の点数」を表す.

さらに, i 人目の学生がこの大学を受験した際の, 入試の点数を t_i とする.

氏名	入試	代数 1	代数 2	代数 3	...	代数 n
一郎君	t_1	u_{11}	u_{12}	u_{13}	...	u_{1n}
二郎君	t_2	u_{21}	u_{22}	u_{23}	...	u_{2n}
三郎君	t_3	u_{31}	u_{32}	u_{33}	...	u_{3n}
⋮	⋮	⋮	⋮	⋮	⋮	⋮
m 郎君	t_m	u_{m1}	u_{m2}	u_{m3}	...	u_{mn}

ここで, 学生の成績をもとに, 入試の点数を推定することを考える. つまり, u_{ij} ($j = 1, 2, \dots, n$) から t_i を推測したい. 例えば, 三郎君の入試の成績 t_3 を, 彼の代数 1 の成績 u_{31} , 代数 2 の成績 u_{32} , ..., 代数 n の成績 u_{3n} から推定する. これを数学的な言葉で言うと, n 変数関数 $g(x_1, x_2, \dots, x_n)$ を上手く選んで,

$$t_i = g(u_{i1}, u_{i2}, \dots, u_{in}) + \varepsilon_i \quad (i = 1, 2, \dots, m) \quad (1)$$

と表現するということである. ただし, ε_i は推定の際の誤差であり, この誤差をなるべく小さくするように, 関数 g を選びたい.

関数 g として, あまり複雑なものを用いると, 理論的な解析が困難になる. そのため, g が 1 次関数の場合を扱う. つまり,

$$g(x_1, x_2, \dots, x_n) = \sum_{j=1}^n a_j x_j + b \quad (a_j, b \in \mathbb{R})$$

のときについて考える. この場合, (1) は

$$t_i = \sum_{j=1}^n a_j u_{ij} + b + \varepsilon_i \quad (i = 1, 2, \dots, m) \quad (2)$$

となる. この式の a_j と b を上手く選んで, 誤差 ε_i を最小に抑えたい.

(2) を行列とベクトルを用いて表しておく、後の計算がスマートに行える。そこで、

$$U = (\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_n, \mathbf{1}) = \begin{pmatrix} u_{11} & u_{12} & \cdots & u_{1n} & 1 \\ u_{21} & u_{22} & \cdots & u_{2n} & 1 \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ u_{m1} & u_{m2} & \cdots & u_{mn} & 1 \end{pmatrix}, \quad (3)$$

$$\mathbf{t} = \begin{pmatrix} t_1 \\ t_2 \\ \vdots \\ t_m \end{pmatrix}, \quad \mathbf{c} = \begin{pmatrix} a_1 \\ a_2 \\ \vdots \\ a_n \\ b \end{pmatrix}, \quad \boldsymbol{\varepsilon} = \begin{pmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_m \end{pmatrix} \quad (4)$$

とおく。すると (2) は

$$\mathbf{t} = U\mathbf{c} + \boldsymbol{\varepsilon} \quad (5)$$

あるいは

$$\boldsymbol{\varepsilon} = \mathbf{t} - U\mathbf{c} \quad (6)$$

と書ける。以上より、我々の考えるべき問題は、次のようになる。

問題 P1 次の量を最小化するように、 $\mathbf{c} \in \mathbb{R}^{n+1}$ を定めよ。

$$\|\boldsymbol{\varepsilon}\|^2 = \|\mathbf{t} - U\mathbf{c}\|^2 = {}^t(\mathbf{t} - U\mathbf{c})(\mathbf{t} - U\mathbf{c}).$$

ただし、一般にベクトル \mathbf{v} や行列 V に対して、 $\|\mathbf{v}\|$ は \mathbf{v} のユークリッドノルムを表し、 tV は V の転置行列を表す。

2 ベクトルの近似

この節では、前節の問題 P1 を解くための一般論を述べる (一般論のため、ここで用いる記号は、前節での記号と直接は関係ない)。

ベクトル $\mathbf{w} \in \mathbb{R}^m$ を、 n 個のベクトル $\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_n \in \mathbb{R}^m$ の 1 次結合で近似したい。ここで、「近似の良さ」として、 \mathbf{w} からのズレのユークリッドノルム (の 2 乗) を用いる。つまり、

$$f(\mathbf{x}) = f(x_1, x_2, \dots, x_n) = \left\| \mathbf{w} - \sum_{i=1}^n x_i \mathbf{v}_i \right\|^2$$

を最小にする $\mathbf{x} = {}^t(x_1, x_2, \dots, x_n)$ を求めたい。ここで、 $m \times n$ 行列 V を

$$V = (\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_n)$$

と定義する。このとき、

$$f(\mathbf{x}) = \|\mathbf{w} - V\mathbf{x}\|^2 = {}^t(\mathbf{w} - V\mathbf{x})(\mathbf{w} - V\mathbf{x}) = {}^t\mathbf{x}{}^tV V\mathbf{x} - 2{}^t\mathbf{w}V\mathbf{x} + {}^t\mathbf{w}\mathbf{w} \quad (7)$$

となる (${}^t\mathbf{w}V\mathbf{x}$ はベクトルや行列ではなく、スカラーになるので、 ${}^t\mathbf{w}V\mathbf{x} = {}^t({}^t\mathbf{w}V\mathbf{x})$ 、つまり ${}^t\mathbf{w}V\mathbf{x} = {}^t\mathbf{x}{}^tV\mathbf{w}$ であることを用いた).

ところで、 $f(\mathbf{x})$ を最小とする \mathbf{x} は

$$\frac{\partial f(\mathbf{x})}{\partial x_i} = 0 \quad (i = 1, 2, \dots, n) \quad (8)$$

の解になっていないといけない。ここで、

$$\frac{\partial f(\mathbf{x})}{\partial \mathbf{x}} = \begin{pmatrix} \frac{\partial f(\mathbf{x})}{\partial x_1} \\ \frac{\partial f(\mathbf{x})}{\partial x_2} \\ \vdots \\ \frac{\partial f(\mathbf{x})}{\partial x_n} \end{pmatrix}$$

と書くことにすれば、(8) は、

$$\frac{\partial f(\mathbf{x})}{\partial \mathbf{x}} = 0 \quad (9)$$

とまとめて表現できる。(9) を解くために、補題を1つ用意する。

補題 1 A を n 次対称行列、 \mathbf{b} を n 次元縦ベクトルとし、ともに各成分は定数とする。このとき、次が成り立つ。

$$(i) \quad \frac{\partial}{\partial \mathbf{x}} ({}^t\mathbf{x}A\mathbf{x}) = 2A\mathbf{x},$$

$$(ii) \quad \frac{\partial}{\partial \mathbf{x}} ({}^t\mathbf{b}\mathbf{x}) = \mathbf{b},$$

$$(iii) \quad \frac{\partial}{\partial \mathbf{x}} ({}^t\mathbf{b}\mathbf{b}) = 0.$$

練習問題 1 補題 1 を証明せよ。

補題 1 を用いて (9) の微分を具体的に計算すると、(7) より

$$\frac{\partial f(\mathbf{x})}{\partial \mathbf{x}} = \frac{\partial}{\partial \mathbf{x}} ({}^t\mathbf{x}{}^tV\mathbf{V}\mathbf{x} - 2{}^t\mathbf{w}V\mathbf{x} + {}^t\mathbf{w}\mathbf{w}) = 2{}^tV\mathbf{V}\mathbf{x} - 2{}^tV\mathbf{w} \quad (10)$$

となる。したがって、(9) が満たされるのは

$${}^tV\mathbf{V}\mathbf{x} = {}^tV\mathbf{w}$$

のときである。特に、 ${}^tV\mathbf{V}$ が正則ならば

$$\mathbf{x} = ({}^tV\mathbf{V})^{-1} {}^tV\mathbf{w}$$

を得る.

以上より, 次の定理が示された.

定理 1 tVV が正則のとき,

$$f(\mathbf{x}) = \|\mathbf{w} - V\mathbf{x}\|^2 = \left\| \mathbf{w} - \sum_{i=1}^n x_i \mathbf{v}_i \right\|^2$$

を最小にする \mathbf{x} は

$$\mathbf{x} = ({}^tVV)^{-1} {}^tV\mathbf{w}$$

で与えられる.

練習問題 2 tVV が正則となるための必要十分条件を, ベクトル $\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_n \in \mathbb{R}^m$ を用いて表せ. 結論だけでなく, 導出過程も記すこと. 特に, $n \leq m$ でないといけないことを示せ.

3 重回帰分析の計算

この節では, 再び第 1 節の問題 P1 に戻る. 以下では, tUU は正則であるとする. 第 2 節の定理 1 を用いれば, この問題の答えは, 次のように与えられる.

問題 P1 の解 $\|\boldsymbol{\varepsilon}\|^2 = \|\mathbf{t} - U\mathbf{c}\|^2$ を最小にする $\mathbf{c} \in \mathbb{R}^{n+1}$ は

$$\mathbf{c} = ({}^tUU)^{-1} {}^tU\mathbf{t} \quad (11)$$

である.

これで一応, 問題は解決したが, もう少し整理しなおした方が, 統計学的な意味が分かりやすくなる. まずは, 次の事実に注意する.

定理 2 $\|\boldsymbol{\varepsilon}\|^2$ が (11) により最小化されているとき, $\mathbf{1}$ と $\boldsymbol{\varepsilon}$ は直交する. つまり,

$$(\mathbf{1}, \boldsymbol{\varepsilon}) = (1, 1, \dots, 1) \begin{pmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_m \end{pmatrix} = \sum_{i=1}^m \varepsilon_i = 0 \quad (12)$$

である. 言い換えれば, 誤差の標本平均 $\frac{1}{m} \sum_{i=1}^m \varepsilon_i$ が 0 となる.

証明 (11) より,

$$\boldsymbol{\varepsilon} = \mathbf{t} - U\mathbf{c} = \mathbf{t} - U({}^tUU)^{-1} {}^tU\mathbf{t}$$

となる。したがって、

$${}^tU\varepsilon = {}^tU\mathbf{t} - {}^tUU({}^tUU)^{-1}{}^tU\mathbf{t} = {}^tU\mathbf{t} - {}^tU\mathbf{t} = 0 \quad (13)$$

である。ここで、(3)での定義を思い出すと、 tU の $n+1$ 行目は $(1, 1, \dots, 1)$ である。よって、(13)の両辺の $n+1$ 行目を比較すれば、(12)が得られる。□

ここで、 t_i および u_{ij} (j は固定)の標本平均を、それぞれ \bar{t} , \bar{u}_j と記す。すなわち、

$$\bar{t} = \frac{1}{m} \sum_{i=1}^m t_i, \quad \bar{u}_j = \frac{1}{m} \sum_{i=1}^m u_{ij} \quad (j = 1, 2, \dots, n) \quad (14)$$

とする。さらに、

$$v_{ij} = u_{ij} - \bar{u}_j, \quad w_i = t_i - \bar{t} \quad (i = 1, 2, \dots, m, j = 1, 2, \dots, n) \quad (15)$$

$$V = \begin{pmatrix} v_{11} & v_{12} & \cdots & v_{1n} \\ v_{21} & v_{22} & \cdots & v_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ v_{m1} & v_{m2} & \cdots & v_{mn} \end{pmatrix}, \quad \mathbf{w} = \begin{pmatrix} w_1 \\ w_2 \\ \vdots \\ w_m \end{pmatrix}, \quad \mathbf{a} = \begin{pmatrix} a_1 \\ a_2 \\ \vdots \\ a_n \end{pmatrix} \quad (16)$$

とおく。このとき、以下の関係が成り立つ。

補題 2

- (i) $\frac{(\mathbf{1}, \mathbf{t})}{m} = \bar{t}$, $\frac{1}{m} {}^t\mathbf{1}U = (\bar{u}_1, \bar{u}_2, \dots, \bar{u}_n, 1)$,
- (ii) $\mathbf{t} - \frac{(\mathbf{1}, \mathbf{t})}{m} \mathbf{1} = \mathbf{w}$, $\left(U - \frac{1}{m} \mathbf{1} {}^t\mathbf{1}U\right) \mathbf{c} = V\mathbf{a}$.

練習問題 3 補題 2 を証明せよ。

定理 3 (5) の式

$$\mathbf{t} = U\mathbf{c} + \varepsilon$$

において、 $(\mathbf{1}, \varepsilon) = 0$ となるための必要十分条件は

$$\mathbf{w} = V\mathbf{a} + \varepsilon \quad (17)$$

が成り立つことである。

証明 (5)の両辺と $\mathbf{1}$ との内積をとると、

$$(\mathbf{1}, \mathbf{t}) = {}^t\mathbf{1}U\mathbf{c} + (\mathbf{1}, \varepsilon).$$

よって,

$$\frac{(\mathbf{1}, \mathbf{t})}{m} \mathbf{1} = \frac{1}{m} \mathbf{1} {}^t \mathbf{1} U \mathbf{c} + \frac{(\mathbf{1}, \boldsymbol{\varepsilon})}{m} \mathbf{1} \quad (18)$$

となる. (5) の各辺から, (18) の各辺を引き, 補題 2 (ii) を用いると,

$$\mathbf{w} = V \mathbf{a} + \boldsymbol{\varepsilon} - \frac{(\mathbf{1}, \boldsymbol{\varepsilon})}{m} \mathbf{1}$$

であることがわかる. したがって, (17) が成り立つことと, $(\mathbf{1}, \boldsymbol{\varepsilon}) = 0$ であることは, 同値である. \square

定理 2 と定理 3 により, 第 1 節の問題 P1 は, 次の問題で置き換え可能である.

問題 P2 $\|\mathbf{w} - V \mathbf{a}\|^2$ を最小化するように, $\mathbf{a} \in \mathbb{R}^n$ を定めよ.

なぜなら, 定理 2 より, 問題 P1 において, $\|\boldsymbol{\varepsilon}\|$ を最小化したら, $(\mathbf{1}, \boldsymbol{\varepsilon}) = 0$ が成り立つので, 最初から $(\mathbf{1}, \boldsymbol{\varepsilon}) = 0$ の成り立つ範囲で, $\|\boldsymbol{\varepsilon}\|$ を最小化すれば良い. さらに, 定理 3 より, $(\mathbf{1}, \boldsymbol{\varepsilon}) = 0$ は (17) 式を意味するので, (17) 式の成り立つ範囲で $\|\boldsymbol{\varepsilon}\|$ を最小化すれば良い. さらに, (17) 式が成り立つということは, $\boldsymbol{\varepsilon} = \mathbf{w} - V \mathbf{a}$ なので, 結局, $\|\mathbf{w} - V \mathbf{a}\|^2$ を最小化することになる.

ところで, 問題 P2 の解は定理 1 より,

$$\mathbf{a} = ({}^t V V)^{-1} {}^t V \mathbf{w} \quad (19)$$

と求まる.

練習問題 4 問題 P1 の解に対して

$$b = \bar{t} - \sum_{j=1}^m a_j \bar{u}_j \quad (20)$$

となることを示せ (つまり, \mathbf{a} を決めれば, b は自動的に決まる).

4 回帰分析の統計学的な解釈

この節では, (19) を統計学的な観点から見てみる. まず, $\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_n$ の分散共分散行列 S , それに $\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_n$ と t の共分散ベクトル \mathbf{s} を次のように定義する.

$$S = \begin{pmatrix} s_{11} & s_{12} & \cdots & s_{1n} \\ s_{21} & s_{22} & \cdots & s_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ s_{n1} & s_{n2} & \cdots & s_{nn} \end{pmatrix}, \quad \mathbf{s} = \begin{pmatrix} s_{1t} \\ s_{2t} \\ \vdots \\ s_{nt} \end{pmatrix}. \quad (21)$$

ただし, s_{ij} は \mathbf{u}_i と \mathbf{u}_j の標本共分散, s_{jt} は \mathbf{u}_j と t の標本共分散である. つまり,

$$s_{ij} = \frac{1}{m-1} \sum_{k=1}^m (u_{ki} - \bar{u}_i)(u_{kj} - \bar{u}_j) = \frac{1}{m-1} \sum_{k=1}^m v_{ki}v_{kj} \quad (22)$$

$$s_{jt} = \frac{1}{m-1} \sum_{k=1}^m (u_{kj} - \bar{u}_j)(t_k - \bar{t}) = \frac{1}{m-1} \sum_{k=1}^m v_{kj}w_k \quad (23)$$

である. ここで, 定義 (16) を思い出すと,

$$\frac{1}{m-1} {}^tV V = S, \quad \frac{1}{m-1} {}^tV \mathbf{w} = \mathbf{s} \quad (24)$$

であることがわかる. これを (19) に代入すると,

$$\mathbf{a} = S^{-1} \mathbf{s} \quad (25)$$

を得る. つまり, 重回帰分析の係数ベクトル \mathbf{a} は, 分散共分散行列 S の逆行列を共分散ベクトル \mathbf{s} にかけて求まる.

練習問題 5 分散共分散行列 S が非正則となるのは, データ u_{ij} がどのような性質をもつときか調べよ. また, そのとき, 重回帰分析はどのように実行すれば良いか考察せよ.