

# データ解析

<http://coconut.sys.eng.shizuoka.ac.jp/data/06/>

静岡大学工学部

安藤和敏

2006.11.02

# 主成分分析のデータ (変数が3個の場合)

No	変数 $x$	変数 $y$	変数 $z$
1	$x_1$	$y_1$	$z_1$
2	$x_2$	$y_2$	$z_2$
$\vdots$	$\vdots$	$\vdots$	$\vdots$
$i$	$x_i$	$y_i$	$z_i$
$\vdots$	$\vdots$	$\vdots$	$\vdots$
$n$	$x_n$	$y_n$	$z_n$

# 合成変数 $u$

$$a^2 + b^2 + c^2 = 1$$

を満たす  $a, b, c$  に対して,

$$u = ax + by + cz$$

という変数変換を考える.

ただし, ここで  $u$  の分散  $s_u^2$  が最大になるように,  $a, b, c$  を選びたい.

# $u$ の分散

$$\begin{aligned} s_u^2 &= \frac{1}{n} \sum_{i=1}^n (u_i - \bar{u})^2 = \frac{1}{n} \sum_{i=1}^n (ax_i + by_i + cz_i - a\bar{x} - b\bar{y} - c\bar{z})^2 \\ &= a^2 \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 + b^2 \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2 + c^2 \frac{1}{n} \sum_{i=1}^n (z_i - \bar{z})^2 \\ &\quad + 2ab \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) + 2bc \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})(z_i - \bar{z}) \\ &\quad + 2ca \frac{1}{n} \sum_{i=1}^n (z_i - \bar{z})(x_i - \bar{x}) \\ &= a^2 s_x^2 + b^2 s_y^2 + c^2 s_z^2 + abs_{xy} + bcs_{yz} + cas_{zx} \end{aligned}$$

# uの分散の最大化

条件  $a^2 + b^2 + c^2 = 1$

を満足する  $[a, b, c]$  のうちで,

$$s_u^2 = a^2 s_x^2 + b^2 s_y^2 + c^2 s_z^2 + abs_{xy} + bcs_{yz} + cas_{zx}$$

を最大にするものを求めたい。

# 主成分の必要条件

$s_u^2$  を最大にする  $[a, b, c]$  は, 以下の方程式の解である必要がある.

$$\begin{bmatrix} s_x^2 & s_{xy} & s_{zx} \\ s_{xy} & s_y^2 & s_{yz} \\ s_{zx} & s_{yz} & s_z^2 \end{bmatrix} \begin{bmatrix} a \\ b \\ c \end{bmatrix} = \lambda \begin{bmatrix} a \\ b \\ c \end{bmatrix},$$

$$a^2 + b^2 + c^2 = 1$$

つまり, そのような  $[a, b, c]$  は, 分散共分散行列の固有ベクトル(で長さが1のもの)である.

# 主成分の十分条件

$$s_u^2 = a^2 s_x^2 + b^2 s_y^2 + c^2 s_z^2 + abs_{xy} + bcs_{yz} + cas_{zx}$$

$$= [a \quad b \quad c] \begin{bmatrix} s_x^2 & s_{xy} & s_{zx} \\ s_{xy} & s_y^2 & s_{yz} \\ s_{zx} & s_{yz} & s_z^2 \end{bmatrix} \begin{bmatrix} a \\ b \\ c \end{bmatrix}$$

$$= [a \quad b \quad c] \lambda \begin{bmatrix} a \\ b \\ c \end{bmatrix} = \lambda (a^2 + b^2 + c^2) = \lambda.$$

# 主成分の必要十分条件

uの分散  $s_u^2$  の極値を与える  $[a,b,c]$  は,

分散共分散行列  $\begin{bmatrix} s_x^2 & s_{xy} & s_{zx} \\ s_{xy} & s_y^2 & s_{yz} \\ s_{zx} & s_{yz} & s_z^2 \end{bmatrix}$  の固有ベクトル

であり, そのとき,  $s_u^2 = \lambda$  (= 固有ベクトル) となる.

したがって,  $s_u^2$  の最大値を与える  $[a,b,c]$  は, 分散共分散行列の最大の固有値に属する固有ベクトル (で, 長さが1のもの) である.



# 主成分分析のデータ (変数が5個の場合)

No	変数 $x$	変数 $y$	変数 $z$	変数 $v$	変数 $w$
1	$x_1$	$y_1$	$z_1$	$v_1$	$w_1$
2	$x_2$	$y_2$	$z_2$	$v_2$	$w_2$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
$i$	$x_i$	$y_i$	$z_i$	$v_i$	$w_i$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
$n$	$x_n$	$y_n$	$z_n$	$v_n$	$w_n$

# 合成変数 $u$

$$a^2 + b^2 + c^2 + d^2 + e^2 = 1$$

を満たす  $[a, b, c, d, e]$  に対して,

$$u = ax + by + cz + dv + ew$$

という変数変換を考える.

ただし, ここで  $u$  の分散  $s_u^2$  が最大になるように,  $[a, b, c, d, e]$  を選びたい.

# 分散共分散行列

$$S = \begin{bmatrix} s_x^2 & s_{xy} & s_{xz} & s_{xv} & s_{xw} \\ s_{xy} & s_y^2 & s_{yz} & s_{yv} & s_{yw} \\ s_{xz} & s_{yz} & s_z^2 & s_{zv} & s_{zw} \\ s_{xv} & s_{yv} & s_{zv} & s_v^2 & s_{vw} \\ s_{xw} & s_{yw} & s_{zw} & s_{vw} & s_w^2 \end{bmatrix},$$

とする。

# $u$ の分散 $s_u^2$

3変数のときと同様にして,

$$s_u^2 = [a \ b \ c \ d \ e]S[a \ b \ c \ d \ e]^T$$

であることが分かる.

さらに,  $u$ の分散を最大化する  $[a, b, c, d, e]$  は,  $S$ の最大の固有値  $\lambda_1$ に属する固有ベクトルである.

# 主成分の必要条件

$s_u^2$  を最大にする  $[a, b, c, d, e]$  は, 以下の方程式の解である必要がある.

$$S \begin{bmatrix} a \\ b \\ c \\ d \\ e \end{bmatrix} = \lambda \begin{bmatrix} a \\ b \\ c \\ d \\ e \end{bmatrix}, a^2 + b^2 + c^2 + d^2 + e^2 = 1$$

つまり, そのような  $[a, b, c, d, e]$  は, 分散共分散行列  $S$  の固有ベクトル (で長さが 1 のもの) である.

# 主成分の必要十分条件

$[a, b, c, d, e]$ が,  $S$ の固有値  $\lambda$  に属する固有ベクトルであるならば,

$$\begin{aligned} s_u^2 &= [a \ b \ c \ d \ e] S [a \ b \ c \ d \ e]^T \\ &= [a \ b \ c \ d \ e] \lambda [a \ b \ c \ d \ e]^T \\ &= \lambda (a^2 + b^2 + c^2 + d^2 + e^2) = \lambda. \end{aligned}$$

したがって,  $s_u^2$  の最大値を与える  $[a, b, c, d, e]$  は, 分散共分散行列の最大の固有値に属する固有ベクトル(で, 長さが1のもの)である.

# 第1主成分

$S$ の最大固有値  $\lambda_1$  に属する固有ベクトル  
  $[a_1, b_1, c_1, d_1, e_1]$  を係数として得られる合成変数

$$u = a_1x + b_1y + c_1z + d_1v + e_1w$$

が主成分である。

以降では,  $u$  を **第1主成分** と呼んで  $u_1$  と書くことにしよう。  
 すなわち,

$$u_1 = a_1x + b_1y + c_1z + d_1v + e_1w$$

# 分散共分散行列の固有値

$$S = \begin{bmatrix} s_x^2 & s_{xy} & s_{xz} & s_{xv} & s_{xw} \\ s_{xy} & s_y^2 & s_{yz} & s_{yv} & s_{yw} \\ s_{xz} & s_{yz} & s_z^2 & s_{zv} & s_{zw} \\ s_{xv} & s_{yv} & s_{zv} & s_v^2 & s_{vw} \\ s_{xw} & s_{yw} & s_{zw} & s_{vw} & s_w^2 \end{bmatrix},$$

の固有値を  $\lambda_1 > \lambda_2 > \lambda_3 > \lambda_4 > \lambda_5$  とする。



# 第2主成分

2番目に大きい固有値  $\lambda_2$  に属する固有ベクトル  
(で長さが1のもの)を  $[a_2, b_2, c_2, d_2, e_2]$  とする.

$[a_2, b_2, c_2, d_2, e_2]$  を係数とする合成変数

$$u_2 = a_2x + b_2y + c_2z + d_2v + e_2w$$

は**第2主成分**と呼ばれる.  $u_2$ の分散は, 第1主成分

$$u_1 = a_1x + b_1y + c_1z + d_1v + e_1w$$

に次いで2番目に大きい分散を与える.

なぜならば,

# 第2主成分

$[a_2, b_2, c_2, d_2, e_2]$ が,  $S$ の固有値  $\lambda_2$ に属する固有ベクトルであるので,

$$\begin{aligned} s_{u_2}^2 &= [a_2 \quad b_2 \quad c_2 \quad d_2 \quad e_2] S [a_2 \quad b_2 \quad c_2 \quad d_2 \quad e_2]^T \\ &= [a_2 \quad b_2 \quad c_2 \quad d_2 \quad e_2] \lambda_2 [a_2 \quad b_2 \quad c_2 \quad d_2 \quad e_2]^T \\ &= \lambda_2 (a_2^2 + b_2^2 + c_2^2 + d_2^2 + e_2^2) = \lambda_2. \end{aligned}$$

# 第3, 第4, 第5主成分

3番目に大きい固有値  $\lambda_3$  に属する固有ベクトル (で長さが1のもの) を  $[a_3, b_3, c_3, d_3, e_3]$  とする.

$[a_3, b_3, c_3, d_3, e_3]$  を係数とする合成変数

$$u_3 = a_3x + b_3y + c_3z + d_3v + e_3w$$

は第3主成分呼ばれ,  $u_3$  の分散は  $\lambda_3$  となる.

以下同様に, 第4主成分, 第5主成分も定義される.

# 寄与率

第1主成分 $u_1$ の寄与率 $C_1$ は,

$$C_1 = \frac{s_{u_1}^2}{s_x^2 + s_y^2 + s_z^2 + s_v^2 + s_w^2} = \frac{\lambda_1}{s_x^2 + s_y^2 + s_z^2 + s_v^2 + s_w^2}$$

で定義される。

$u_1$ の寄与率は、与えられた多変量データのもつ情報量のうち、 $u_1$ で表現できる情報量であると解釈できる（p.12を見よ）。

# 寄与率

一般に第*i*主成分 $u_i$ の寄与率 $C_i$ は,

$$C_i = \frac{s_{u_i}^2}{s_x^2 + s_y^2 + s_z^2 + s_v^2 + s_w^2} = \frac{\lambda_i}{s_x^2 + s_y^2 + s_z^2 + s_v^2 + s_w^2}$$

で定義される.

$u_i$ の寄与率は, 与えられた多変量データのもつ情報量のうち,  $u_i$ で表現できる情報量であると解釈できる ( p.12を見よ).

# 累積寄与率

第1主成分 $u_1$ の寄与率 $C_1$ はと第2主成分 $u_2$ の寄与率 $C_2$ の和

$$C_2' = \frac{s_{u_1}^2 + s_{u_2}^2}{s_x^2 + s_y^2 + s_z^2 + s_v^2 + s_w^2} = \frac{\lambda_1 + \lambda_2}{s_x^2 + s_y^2 + s_z^2 + s_v^2 + s_w^2}$$

は第2主成分までの**累積寄与率**と呼ばれる。

これは、第1主成分 $u_1$ と第2主成分 $u_2$ の2つの合成変数によって、与えられた多変量データの情報をどの程度表現しているかを示す指標である。

# 累積寄与率

以下同様に、第3主成分までの累積寄与率、

$$C_3' = \frac{s_{u_1}^2 + s_{u_2}^2 + s_{u_3}^2}{s_x^2 + s_y^2 + s_z^2 + s_v^2 + s_w^2} = \frac{\lambda_1 + \lambda_2 + \lambda_3}{s_x^2 + s_y^2 + s_z^2 + s_v^2 + s_w^2}$$

第4主成分までの累積寄与率も同様に定義される。

$$C_4' = \frac{s_{u_1}^2 + s_{u_2}^2 + s_{u_3}^2 + s_{u_4}^2}{s_x^2 + s_y^2 + s_z^2 + s_v^2 + s_w^2} = \frac{\lambda_1 + \lambda_2 + \lambda_3 + \lambda_4}{s_x^2 + s_y^2 + s_z^2 + s_v^2 + s_w^2}$$

これらの量の意味するところはもはや明らかであろう。

# とりあげる主成分の数

第1主成分 $u_1$ の寄与率 $C_1$ が十分大きいものであれば、もうこれ以上の主成分を調べる必要はないが、寄与率 $C_1$ の大きさが満足いくものでなければ、第2主成分まで調べる必要がある。そこで、第2主成分までの累積寄与率もまだ満足いくものでなければ、累積寄与率が満足がいく数字になるまで、以降の主成分を調べていく。

ただし、とりあげる主成分の数を増やすことは、与えられたデータを少ない変数で表現するという、主成分分析本来の目的に反するので、望ましいことではない。



# 主成分の解釈

主成分の意味を考えるための手助けになるものとして、**変量プロット**と**主成分得点プロット**がある。両方とも、視覚的に主成分を捕らえるためのものである。

# 変量プロット

第1, 第2主成分 $u_1, u_2$ が, それぞれ以下の式で表されているとする.

$$u_1 = a_1x + b_1y + c_1z + d_1v + e_1w$$

$$u_2 = a_2x + b_2y + c_2z + d_2v + e_2w$$

以下の5つの点を二次元平面にプロットしたものが, 変量プロットである.

$$(a_1, a_2), (b_1, b_2), (c_1, c_2), (d_1, d_2), (e_1, e_2)$$

# 主成分得点プロット

2つの主成分, 例えば $u_1$  と $u_2$  を考えて, 以下の式によって, 各データ $[x_i, y_i, z_i, v_i, w_i]$ の第1, 第2主成分得点を計算する.

$$\begin{cases} u_{1i} = a_1x_i + b_1y_i + c_1z_i + d_1v_i + e_1w_i \\ u_{2i} = a_2x_i + b_2y_i + c_2z_i + d_2v_i + e_2w_i \end{cases}$$

こうして得られる $n$ 個の点  $(u_{1i}, u_{2i})$  ( $i = 1, \dots, n$ )

を2次元平面上にプロットしたものが主成分得点プロットである.

# Excelで学ぼう

ファイル: 第3章/3\_3

# 本日のまとめ

- 第 $i$ 主成分 $u_i$ がどのようにして得られるかを理解した。  
(データの分散共分散行列の $i$ 番目に大きい固有値 $\lambda_i$ に属する固有ベクトルから得られる。)
- 寄与率, 累積寄与率の定義とその意味を理解した。
- Excelを用いて, 第 $i$ 主成分 $u_i$ 主成分を計算する方法, 第 $i$ 主成分得点を計算する方法を理解した。
- 変量プロット, 主成分得点プロットの概念, 及び, Excelを用いてこれらのプロットの求め方を理解した。