

多変量解析

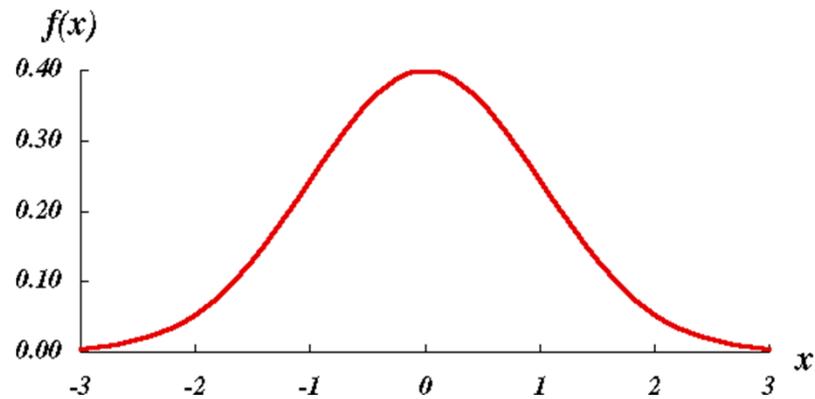
学ぶこと

1. 相関、共分散という考え方
2. 行列の基礎（おさらい）
3. 回帰分析
4. 主成分分析
5. 主成分回帰

データの計測

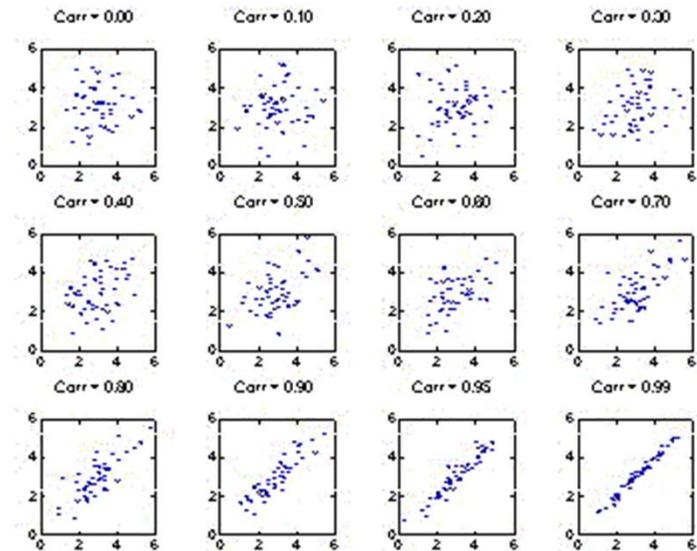
1種類のデータ

複数回計測すると、分布が生じる。



2種類のデータ

複数回計測すると、何らかの
関係が見出される。 = 相関



相関

平均、偏差、分散の関係

- 平均
 $m = \sum x_i / n$
- 偏差
個々のデータと平均の差
 $(x_i - m)$
- 分散
偏差を2乗した平均
 $\sigma^2 = \sum (x_i - m)^2 / n$
- 標準偏差
分散の平方根 σ

共分散 (covariance) と相関

- 共分散
分散を2変量に拡張したものの
 $S = \sum (x_i - m)(y_i - m) / n$
この値は x, y の単位が異なれば変化してしまう
- 相関
共分散を標準化
 $R = \sum (x_i - m)(y_i - m) / (\sigma_x \sigma_y)$

相関 = (標準化した) 共分散

共分散

複数の計測値はベクトル

- 1次元のベクトルは数直線上の点で表せる
- 2次元のベクトルは平面で向きと長さを持つ
- 標準化した共分散とはベクトル間の $\cos\theta$ にあたる

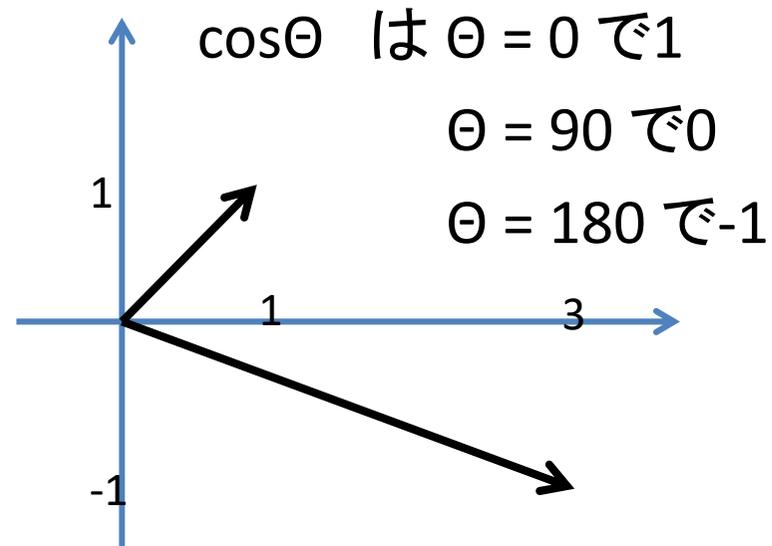
共分散も相関も、多次元データの「角度」をみている

ベクトルの内積

- 内積 = コサイン

$$s_1 = [1, 1] \quad s_2 = [3, -1]$$

$$\begin{aligned} |s_1| |s_2| \cos\theta &= s_1 \cdot s_2 \\ &= 1 \times 3 + (1 \times -1) \end{aligned}$$



データ行列の表現

解析データの記述

2	5	3	サンプル1
8	9	2	サンプル2
3	4	1	サンプル3
9	8	2	:
:			

変量1 変量2 変量3 ...

行方向に
サンプル中の変量 や
ピーク情報(波長)
を記述する。
列方向には
時系列 や
特徴
をとる。つまり列が座標軸。

$n \times p$ 行列で表したとき、たい
てい $n \gg p$ となる。
(例外がゲノム解析)

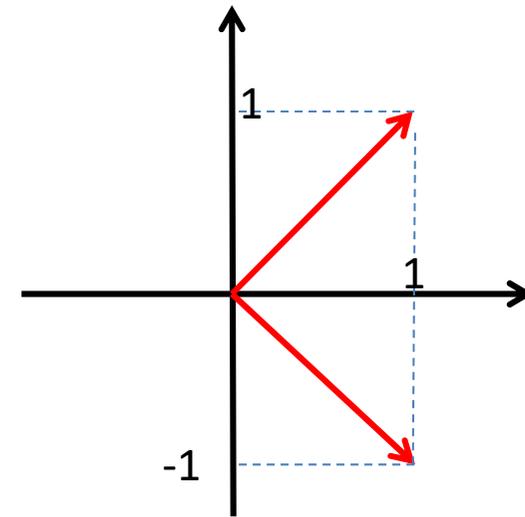
行列 = 射影

行列は、データであると同時に関数でもある。

例 $\begin{pmatrix} 1 & 1 \\ 1 & -1 \end{pmatrix}$

$$\begin{pmatrix} 1 & 1 \\ 1 & -1 \end{pmatrix} \begin{pmatrix} 1 \\ 0 \end{pmatrix} = \begin{pmatrix} 1 \\ 1 \end{pmatrix}$$

$$\begin{pmatrix} 1 & 1 \\ 1 & -1 \end{pmatrix} \begin{pmatrix} 0 \\ 1 \end{pmatrix} = \begin{pmatrix} 1 \\ -1 \end{pmatrix}$$



つまり、現在の座標系を上の赤い軸方向に射影する内容。

データ行列の意味

植物など対象を観察した際のデータ
= 対象の本質を「射影」したもの

$$\begin{pmatrix} 1 & 1 \\ 1 & -1 \end{pmatrix}$$

- 似た行 = 類似のサンプル
- 似た列 = 類似の形質



似ている要素は、いずれも行列の複雑度を下げる

Rによる実習

アンダーソン、フィッシャー (1936) が用いたアヤメ
50ずつ *Iris setosa*, *Iris versicolor*, *Iris virginica* の3種



➤ `help("iris")` または `?iris`

<http://biostor.org/reference/11559>

<https://onlinelibrary.wiley.com/doi/10.1111/j.1469-1809.1936.tb02137.x>



Fig. 5. Outline drawings of petal and sepal from plants of *Iris setosa* (left), *I. versicolor* (center), and *I. virginica* var. *Shrevei* (right).

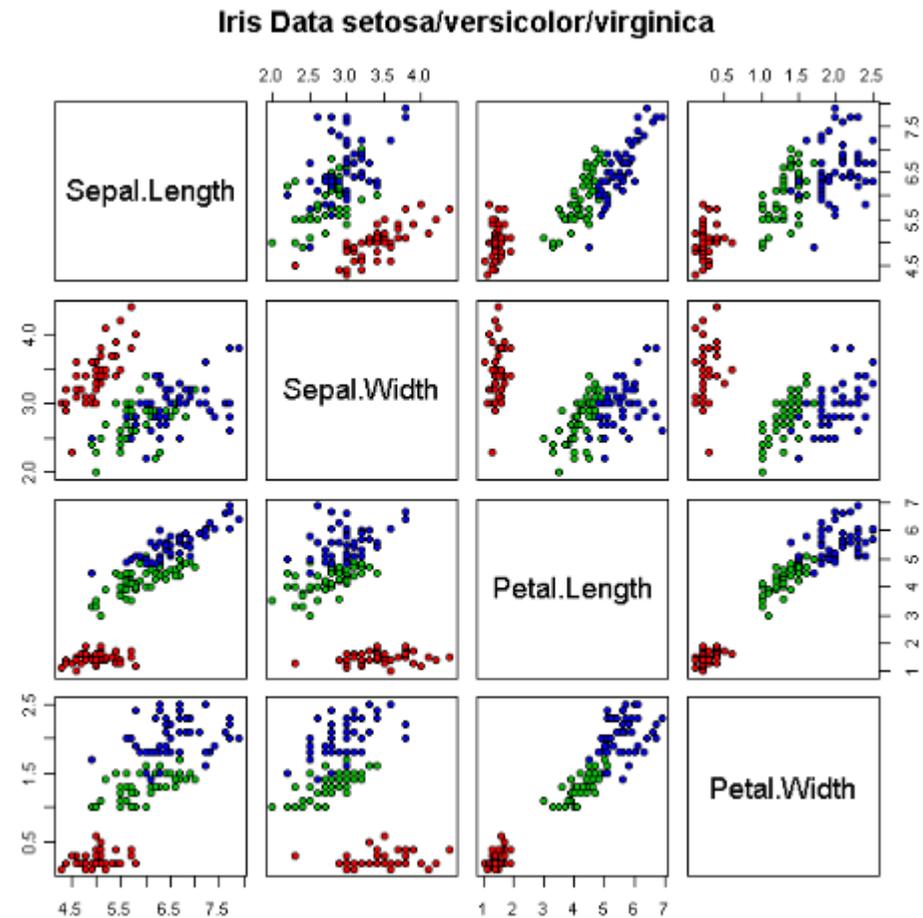
Anderson E. 1936. The Species Problem in Iris. *Annals of the Missouri Botanical Garden* 23:457-509.
<http://biostor.org/reference/11559>

Irisのデータ

福岡大学工学部図学教室 梶山喜一郎さんのサイト
がよくまとまっています。

(「R IRISデータ」で検索)

➤ `plot("iris")`



参考：スピアマンの順位相関

順位が一致しているときと、逆順のときを両端として、-1 から 1 の間に正規化したもの

1 2 3 4 5 6

1 2 3 4 5 6

1 4 9 16 25 36

最大値は $\sum k^2$

1 2 3 4 5 6

6 5 4 3 2 1

6 10 12 12 10 6

最小値は $\sum k(n-k+1)$

最大と最小の中間値は $\sum k(n+1)/2$ 、幅は $\sum (k^2 - nk - 1)$

参考: ケンドールの順位相関

n 要素からランダムに2個選んだペアの順序関係が両者で一致している確率のこと

$$\tau = 2P / {}_n C_2 - 1$$

2をかけて1引くのは $[-1, 1]$ の範囲にするため。

逆行列 = 逆変換

n次元正方行列 A に別の正方行列 A' をかけて単位行列 I になるとき、 A' を A の逆行列と呼ぶ。

$$A A' = I$$

これを A^{-1} と書く。

逆行列が存在するには、 A がn次元の基底を成分に持つ (regular つまり正則である) ことが必要。

これは、変換にロスがないことに相当。

固有値

$$Zx = \lambda x \quad (x \neq 0)$$

スカラー λ を行列 Z の固有値
という。

$$[Z - \lambda I]x = 0$$

つまり $[Z - \lambda I]$ に逆行列は存
在しない。行列を特異にする
(逆行列がない) λ の値が固
有値。

固有値の数はrankに同じ
(重複許す)

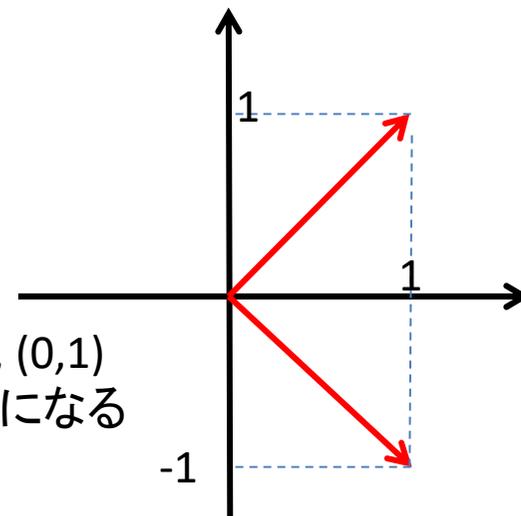
例

$$Z = \begin{pmatrix} 1 & 1 \\ 1 & -1 \end{pmatrix} \quad \text{のとき}$$

$$|Z - \lambda I| = ((1-\lambda) * (-1-\lambda)) - (1 * 1) = \lambda^2 - 2 = 0$$

$$\lambda = \pm\sqrt{2}$$

Z で単位ベクトル $(1,0)$, $(0,1)$
を射影すると長さが $\sqrt{2}$ になる



固有ベクトル

座標変換において方向が変わらないベクトルが固有ベクトル x 。

$$Zx = \lambda x \quad (x \neq 0)$$

普通はノルム(長さ)を1にする。

固有値とは、変換における固有ベクトルの引き伸ばし率。

例

$$Z = \begin{pmatrix} 1 & 1 \\ 1 & -1 \end{pmatrix} \quad \text{のとき}$$

$\lambda = \pm\sqrt{2}$ より

• $+\sqrt{2}$ のとき

$$\alpha \begin{pmatrix} 1 & (\sqrt{2}-1) \end{pmatrix}^t$$

• $-\sqrt{2}$ のとき

$$\beta \begin{pmatrix} 1 & -(\sqrt{2}+1) \end{pmatrix}^t$$

固有ベクトル

固有ベクトル

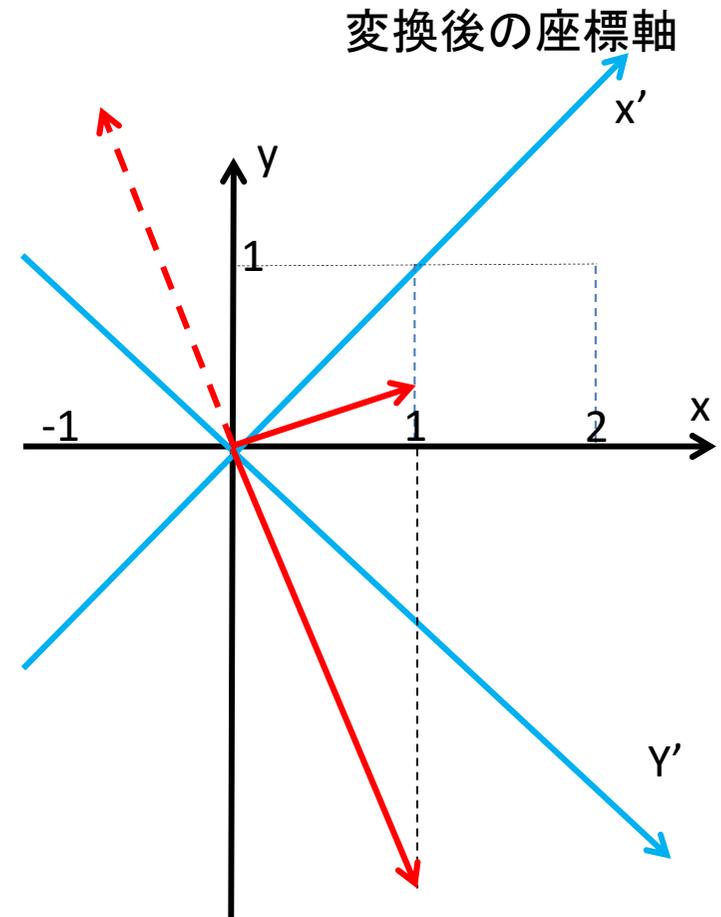
$$(1 \quad \sqrt{2}-1)^t$$

$$(1 \quad -(\sqrt{2}+1))^t$$

は座標変換前と座標変換後の座標が変わらない方向を示す。

固有ベクトルは一次独立。

(基底ベクトルになる。)



注： 2x2の回転行列の場合は向きが変わらないベクトルが存在せず、固有値が虚数になる。3x3の回転行列の場合は、回転軸が固有ベクトル、対応する固有値が1。

行列の固有値分解

Z が異なる n 個の固有値

$$\lambda_1, \dots, \lambda_i, \dots, \lambda_n$$

を持ち、対応する固有ベクトルを

$$P = [x_1, \dots, x_i, \dots, x_n]$$

とすると

$$P^{-1} Z P = \begin{bmatrix} \lambda_1 & \dots & 0 & \dots & 0 \\ \vdots & & \vdots & & \\ 0 & \dots & \lambda_i & \dots & 0 \\ \vdots & & \vdots & & \\ 0 & \dots & 0 & \dots & \lambda_n \end{bmatrix}$$

行列 Z による一次変換

$Zx = y$ における x, y を、 P の座標系で表現する

$$Z P x' = P y'$$

$$P^{-1} Z P x' = y'$$

x が Z の固有ベクトルなら

$$Z P x' = \lambda P x'$$

$$P^{-1} Z P x' = \lambda x'$$

となり、 x' も固有ベクトル。

つまり、 $P^{-1} Z P$ は固有値を成分とする対角行列。

固有値分解の例

例

$$\mathbf{Z} = \begin{pmatrix} 1 & 1 \\ 1 & -1 \end{pmatrix} \text{ のとき}$$

基底ベクトルをなす変換

$$\mathbf{P}^{-1} = (1/2\sqrt{2}) \begin{pmatrix} 1 & 1 \\ \sqrt{2}-1 & -(\sqrt{2}+1) \end{pmatrix}$$

固有値は $\pm\sqrt{2}$

$$\mathbf{Z} \begin{pmatrix} 1 \\ \sqrt{2}-1 \end{pmatrix} = \sqrt{2} \begin{pmatrix} 1 \\ \sqrt{2}-1 \end{pmatrix}$$

$$\mathbf{Z} \begin{pmatrix} 1 \\ -(\sqrt{2}+1) \end{pmatrix} = -\sqrt{2} \begin{pmatrix} 1 \\ -(\sqrt{2}+1) \end{pmatrix}$$

$$\mathbf{P}^{-1} \mathbf{Z} \mathbf{P} = \dots = \begin{pmatrix} \sqrt{2} & 0 \\ 0 & -\sqrt{2} \end{pmatrix}$$

確かに、固有値の対角行列になっている。

$$\mathbf{P} = \begin{pmatrix} 1 & 1 \\ \sqrt{2}-1 & -(\sqrt{2}+1) \end{pmatrix}$$

基底ベクトルをなす変換

つまり縮退していない線形変換は、固有ベクトルの座標系に移動して、基底の長さを固有値倍し、逆変換することに相当する。

固有値の解法

べき乗法

$$\begin{aligned} \mathbf{Z}^k &= \lambda_1^k \mathbf{x}_1 \mathbf{x}_1^t + \dots + \lambda_i^k \mathbf{x}_i \mathbf{x}_i^t + \dots + \lambda_n^k \mathbf{x}_n \mathbf{x}_n^t \\ &= \lambda_1^k \{ \mathbf{x}_1 \mathbf{x}_1^t + \dots + (\lambda_i/\lambda_1)^k \mathbf{x}_i \mathbf{x}_i^t + \dots + (\lambda_n/\lambda_1)^k \mathbf{x}_n \mathbf{x}_n^t \} \end{aligned}$$

ここで2項目以降を無視すると

$$\mathbf{Z}^k \doteq \lambda_1^k \{ \mathbf{x}_1 \mathbf{x}_1^t \}$$

転置行列

行列の行方向と列方向を入れ替えたものを転置行列という。
 Z を転置したら tZ と書く。

行列を自身の転置行列と掛け合わせると、正方の対称行列になる。

いずれの対称行列も、ランクは等しい。

例

$$\begin{matrix} & p \\ \text{---} & \\ & \\ & \\ n & \end{matrix} = \begin{matrix} & n \\ p & \text{---} \\ & \\ & \\ & \end{matrix} = \begin{matrix} & n \\ & \\ & \\ & \\ n & \end{matrix}$$

$$\begin{matrix} & n \\ p & \text{---} \\ & \\ & \\ & \end{matrix} = \begin{matrix} & p \\ & \\ & \\ & \\ n & \end{matrix} = \begin{matrix} & p \\ & \\ & \\ & \\ p & \end{matrix}$$

転置行列と逆行列

正規直交基底を列ベクトルとする直交行列と、
その転置行列は逆行列の関係

行列の掛け算を考える。

A = [基底を列方向に持つ行列]

tA = [基底を行方向に持つ行列]

${}^tA A$ = [各要素は基底の内積]

= [同じ基底(軸)なら内積が1, 残りは0]

= [単位行列]

対称行列

Z を転置しても等しい、つまり $Z = Z^t$ となるのが対称行列

実対称行列の固有値は全て実数。

対称行列の固有ベクトルは必ず直交する。(一次独立だけではない。)

$Z^t Z = Z^2 = Z Z^t$ となるので、正規行列 (normal) でもある。

なぜ固有ベクトルが直交?

内積を考える。 Z は固有ベクトルの方向を変えないので

$Z x_1 = \lambda_1 x_1$ 、 $Z x_2 = \lambda_2 x_2$ が成立。

対称行列なので

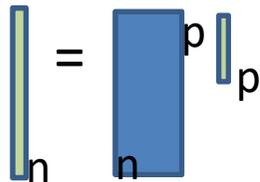
$$\begin{aligned} \lambda_1 (x_1, x_2) &= (\lambda_1 x_1)^t x_2 = (Z x_1)^t x_2 = x_1^t (Z^t x_2) \\ &= x_1^t Z x_2 = x_1^t (\lambda_2 x_2) = (x_1, (\lambda_2 x_2)) = \lambda_2 (x_1, x_2) \end{aligned}$$

固有値が等しくない限り、内積は0。

一般逆行列

正方で正則の行列なら逆行列が存在する。

$$y = X b \text{ なら } b = X^{-1}y$$

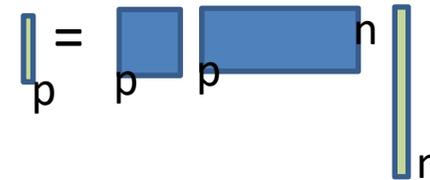


しかし普通のデータ行列は正方でない。そこで X の転置をかけて正方にする。

$$X^T X \quad \begin{matrix} \text{---} & n \\ p & \end{matrix} \begin{matrix} p \\ \text{---} \\ n \end{matrix} = \begin{matrix} p \\ p \end{matrix}$$

$$X^T y = (X^T X) b$$

$$b = (X^T X)^{-1} X^T y$$



この値を $y = X b$ に代入すると

$$\hat{y} = X (X^T X)^{-1} X^T y$$

つまり y の推定値をだすことができる(回帰分析)。

回帰分析 (regression)

$$y = b_0 + x b_1$$

y : 従属(目的)変数 x : 独立(説明)変数

説明変数が1つ: 単回帰分析 (univariate linear regression)

説明変数が2つ以上: 重回帰分析 (multivariate LR)

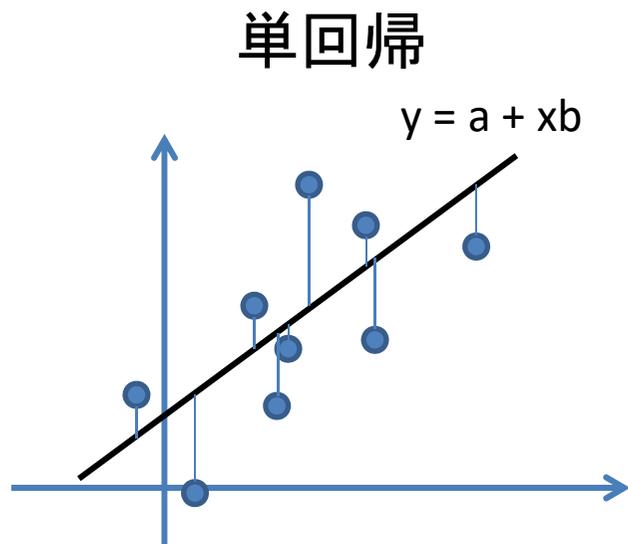
y からのズレ(残差)の二乗和を最小化するように係数 \mathbf{b} を定めたい(最小二乗法)。

$$\text{残差の和 } S = \sum (y - b_0 - x b_1)^2$$

この値を b_0, b_1 で偏微分して0とおけば良い。

$$\partial S / \partial b_0 = \sum -2(y - b_0 - x b_1) = 0$$

$$\partial S / \partial b_1 = \sum -2(y - b_0 - x b_1)x = 0$$



$$\mathbf{y} = \begin{bmatrix} 1 & x \end{bmatrix} \begin{bmatrix} b_0 \\ b_1 \end{bmatrix}$$

$y = \mathbf{X}\mathbf{b}$ なので

$\mathbf{b} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y}$ と計算

重回帰分析 (MLR)

基本は単回帰に全く同じ

$$\begin{array}{c} \mathbf{y} \\ y \end{array} = \begin{array}{c} [1, x_1, x_2 \\ \dots] \\ \mathbf{X} \end{array} \begin{array}{c} \mathbf{b} \\ b \end{array} + \begin{array}{c} \mathbf{f} \\ f \text{ (残差)} \end{array}$$

fを最小化するため、
 $b = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y}$ で係数を推定。
でも、大体はうまくいかない。

共線性(colinearity)の問題

\mathbf{X} に相関が高い列成分があると、 b の計算ができない。

行列式 $|\mathbf{X}^T \mathbf{X}|$ が0に近いことが原因 (ランク落ち)。

対策:

固有値が小さい、行列式が0に近い、特大な値がある等。

線形モデルの例

植物の成長を、種のスコア、土のスコア、気温のスコアで近似

$$\text{Plant} = F1 * \text{seed} + F2 * \text{soil} + F3 * \text{temp} + \text{error}$$

Find best parameters F1~F3. (= minimize error)

$$\begin{bmatrix} \text{plant1} \\ \text{plant2} \\ \text{plant3} \\ \vdots \\ \vdots \end{bmatrix} = \begin{bmatrix} \text{seed1} & \text{soil1} & \text{temp1} \\ \text{seed2} & \text{soil2} & \text{temp2} \\ \text{seed3} & \text{soil3} & \text{temp3} \\ & \vdots & \\ & \vdots & \end{bmatrix} \begin{bmatrix} \text{factor1} \\ \text{factor2} \\ \text{factor3} \\ \vdots \\ \vdots \end{bmatrix} + \begin{bmatrix} \text{error1} \\ \text{error2} \\ \text{error3} \\ \vdots \\ \vdots \end{bmatrix}$$

$$\mathbf{Y} = \mathbf{X} \mathbf{b} + \mathbf{f}$$

$$\text{Plant} = 10 * \text{seed} + 5 * \text{soil} + 0.2 * \text{temp} \pm 3$$

Rによる実習（共線性）

ふたたび iris データ

- `s <- lm (Sepal.Length ~ Sepal.width + Petal.Length + Petal.Width, data=iris)`
- `summary(s)`

目的変量が Sepal.Length 。 説明変量として Sepal.Width, Petal.Length, Petal.Width を使う。

2部 主成分分析

スペクトル分解

対称行列 Z が異なる k 個の固有値

$$\lambda_1, \dots, \lambda_i, \dots, \lambda_k$$

を持ち、対応する固有(正規直交)ベクトルを

$$P = [x_1, \dots, x_i, \dots, x_k]$$

とすると

$$P^t Z P = \begin{bmatrix} \lambda_1 & \dots & 0 & \dots & 0 \\ \vdots & & \vdots & & \\ 0 & \dots & \lambda_i & \dots & 0 \\ \vdots & & \vdots & & \\ 0 & \dots & 0 & \dots & \lambda_k \end{bmatrix}$$

対称行列で、固有値が全て正のとき(0も含まない) 正定値行列と呼ぶ。

対称行列 Z が正定値になる必要十分条件は

$$Z = X^t X$$

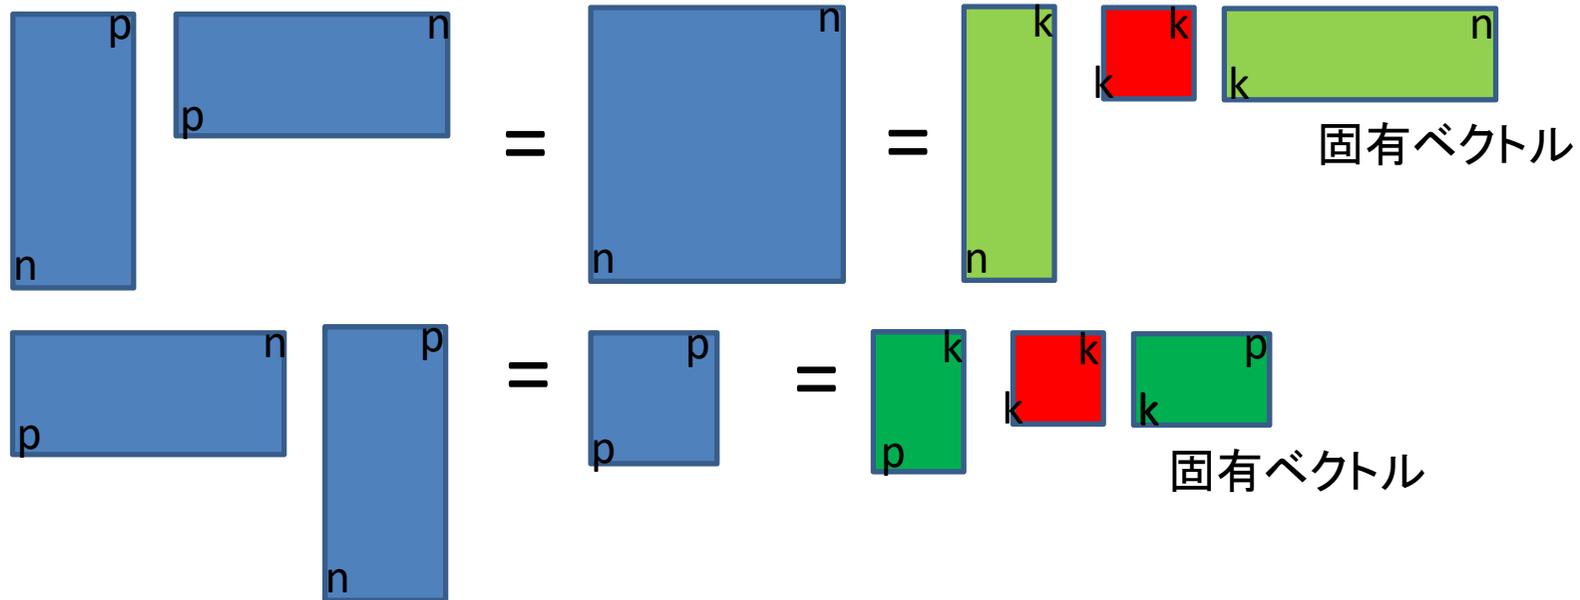
となる正則な正方行列 X が存在すること。

スペクトル分解の図示

データは $n \times p$ 行列で表す



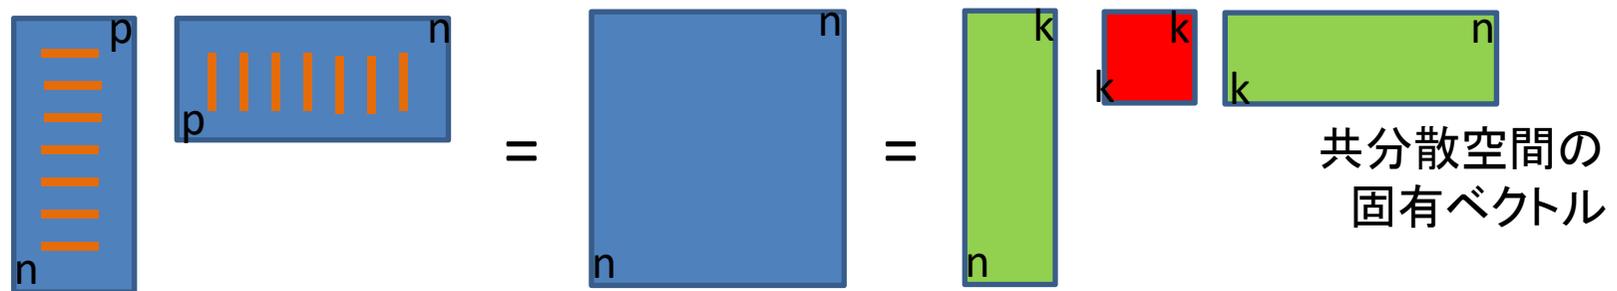
データを転置行列とかけて対称行列にすれば、
スペクトル分解できる。



共分散行列

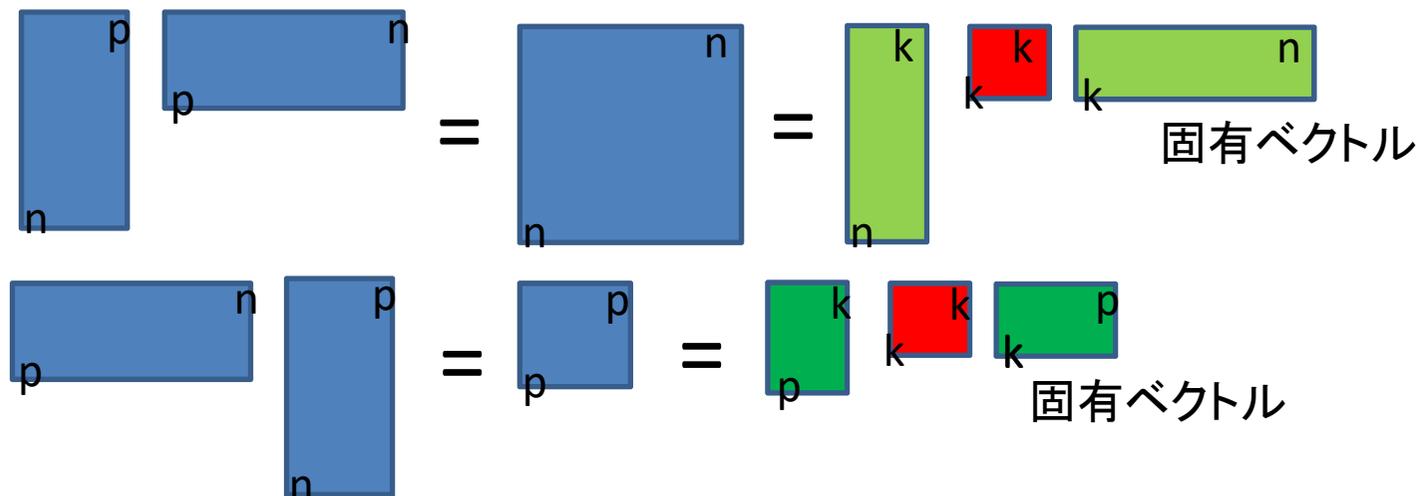
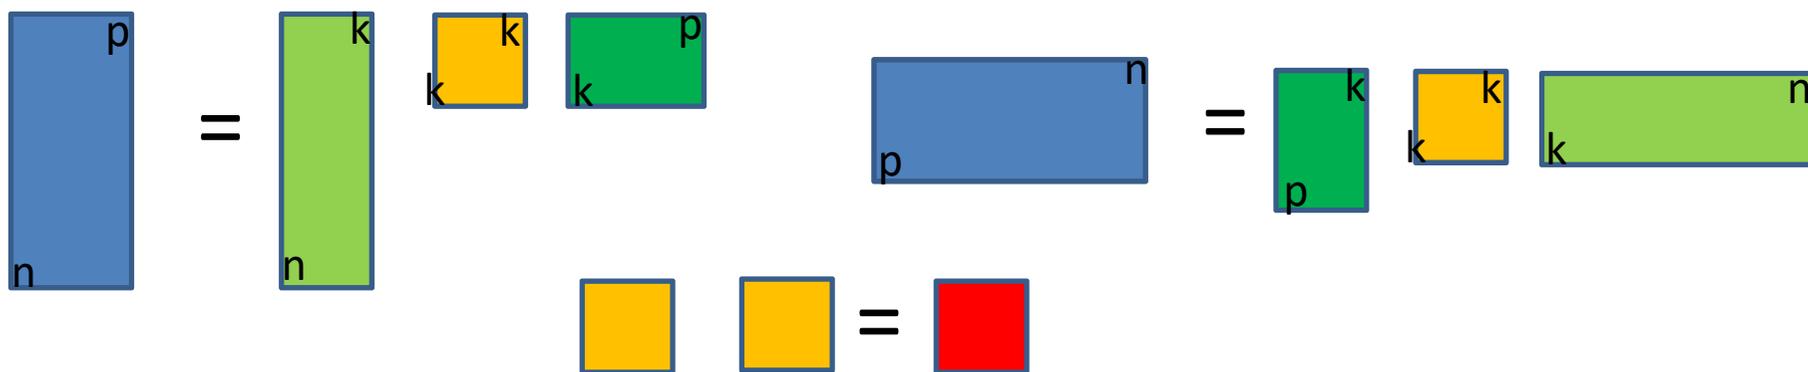
転置してかけ合わせた行列は、共分散行列
(自分自身との相関)になっている。

スペクトル分解



行列の特異値分解 (SVD)

スペクトル分解をよく覗くと



行列の特異値分解(2)

SVD ... singular value
decomposition (特異値分解)

任意の行列 A は

$$A = U D V^T$$

に分解できる。ここで U, V は
正規直交行列

$$U^T U = I, V^T V = I$$

D は A のランク分だけ要素を
持つ対角行列。

これを特異値という。

特異値と固有値の関係

$$\begin{aligned} AA^T &= (U D V^T) (U D V^T)^T \\ &= (U D V^T) (V D^T U^T) = U D^2 U^T \end{aligned}$$

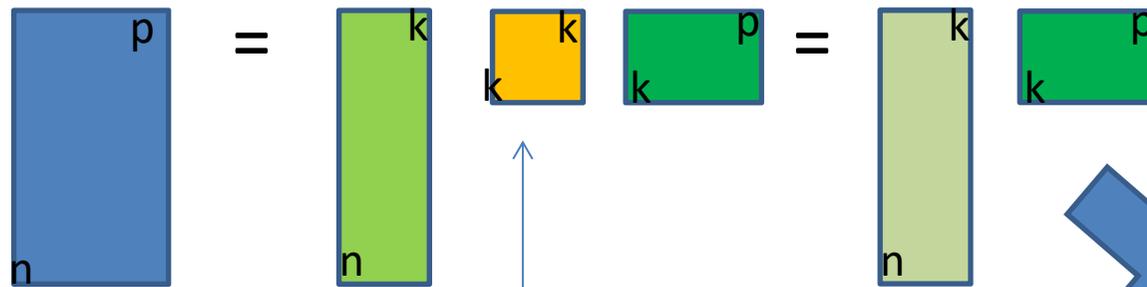
$$\therefore AA^T x_i = d_i^2 x_i$$

特異値の2乗が AA^T の固有値に
対応している。

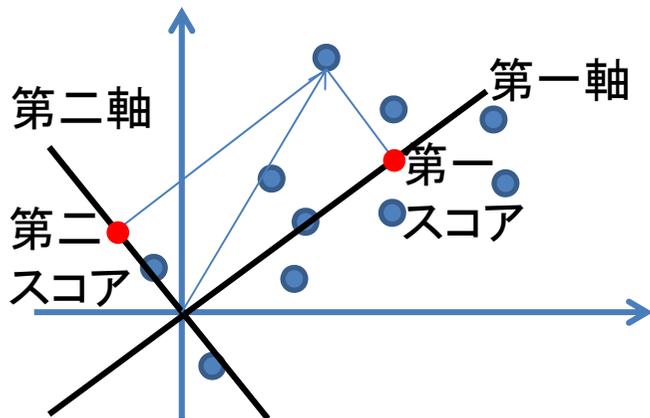


主成分分析 (PCA)

SVD 分解 $A = U D V^T$ を $U D$ 部分 (スコア) と、 V^T 部分 (ローディング = 共分散行列の軸) に分ける

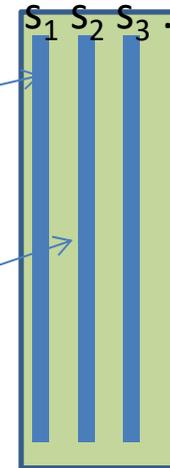


ここで、固有値は大きい順に並べる




第1スコア

第2スコア

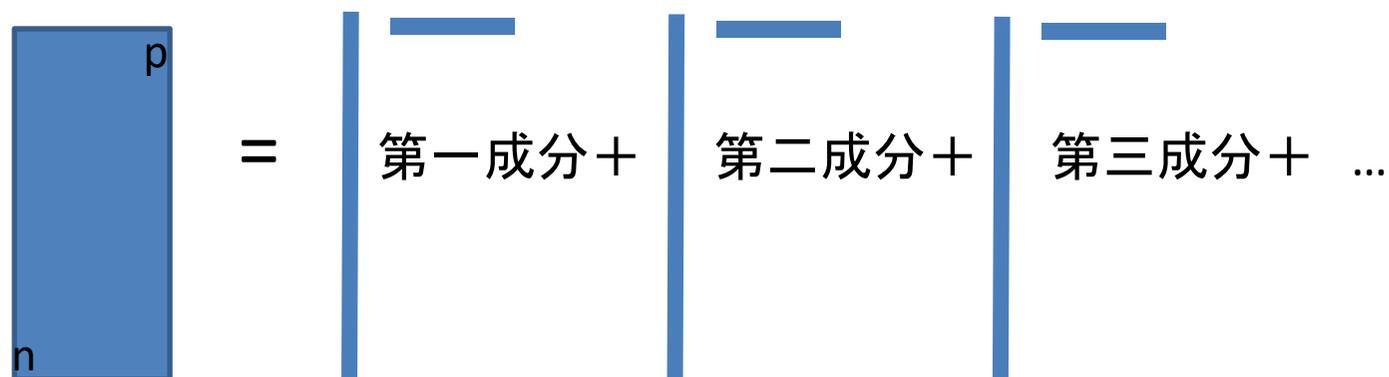


第1軸
(サンプルの分散最大方向)

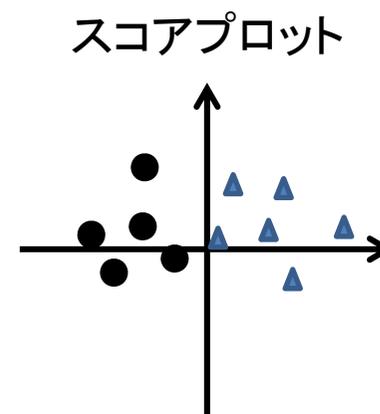
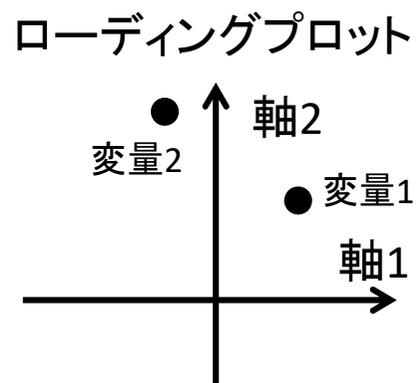
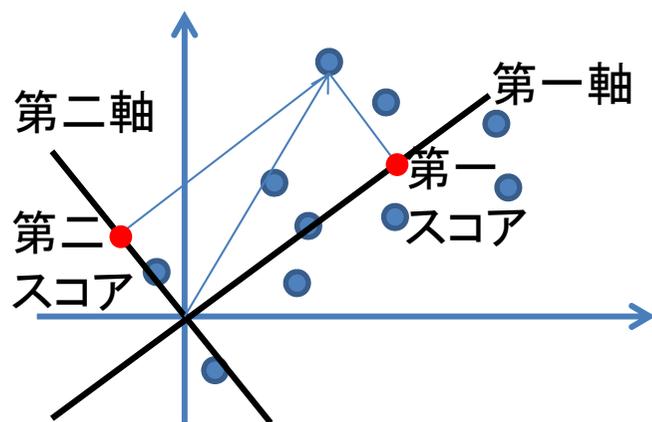


第2軸
(1軸と直交し、分散最大)

主成分分析 (2)

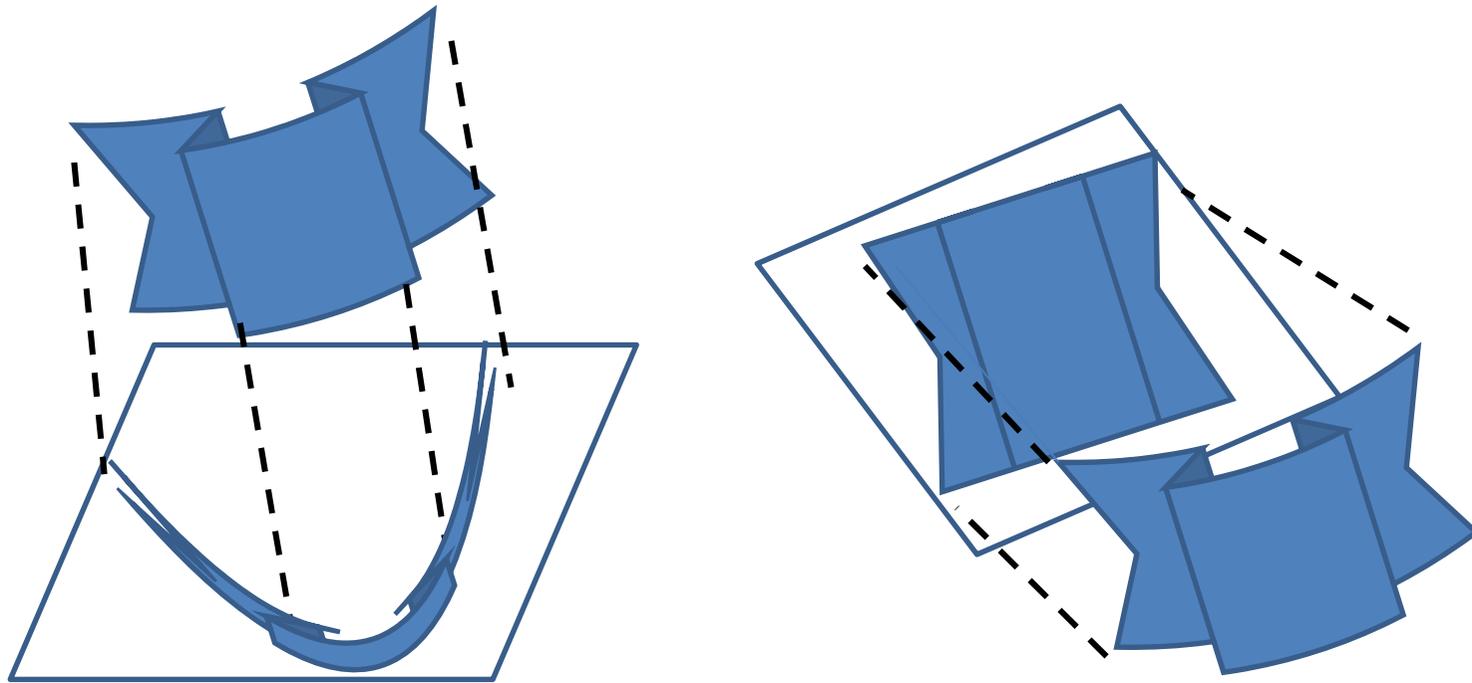


行列を2~3成分でモデルする
各軸において変量の寄与を考慮



主成分分析の幾何的解釈

PCAは、多次元空間を2次元の平面に射影



一番適した射影とは何か？

PCAは「面積」を最大化しているだけ

PCAの利点

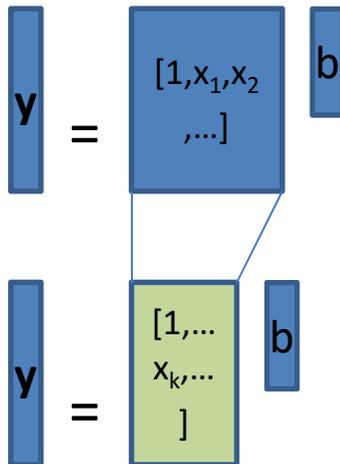
- SVD分解なので逆行列計算より楽
(このへんは数値計算の教科書を参照。
Numerical Recipe in C など。)
- 共線性の問題が生じない

つまり、どんな行列でも安心して処理できる。

主成分回帰 (PCR)

主成分のみで回帰分析

決まった数の主成分を選んで
回帰分析

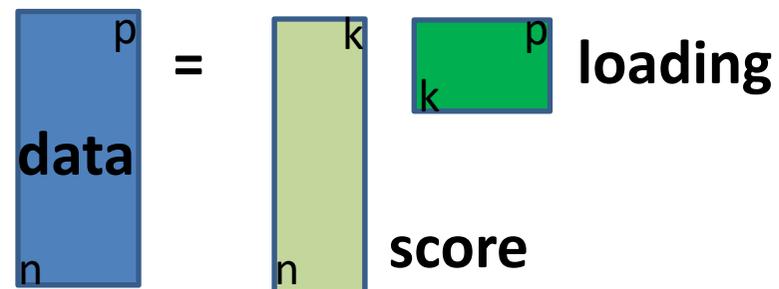


「主成分」として、軸を変換して
いる点に注意

なぜ主成分にするのか

相関が高いものだけを除くと、
本来関心のある説明変数を
省いてしまうリスク

→ 回帰係数は、変数そのもの
の効果ではなくなる。

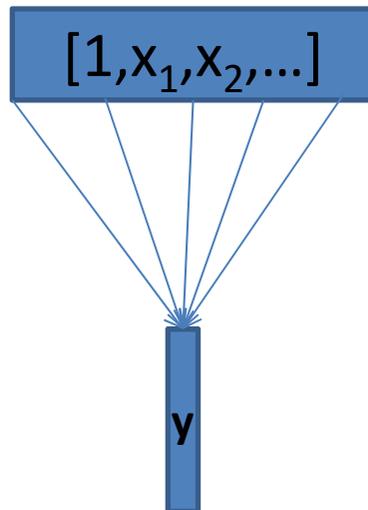


線形回帰分析のまとめ

単、重回帰分析

データの軸をそのまま使う

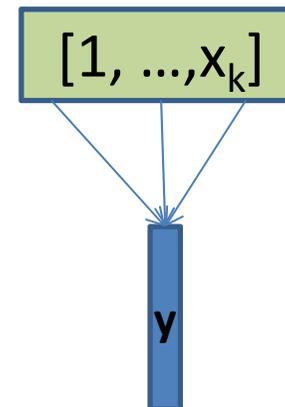
- ノイズが入りやすい
- 変数の選択が必要



主成分回帰

データの分散を最大化する軸を使う

$$\begin{matrix} p \\ \text{data} \\ n \end{matrix} = \begin{matrix} k \\ \text{score} \\ n \end{matrix} \begin{matrix} p \\ \text{loading} \\ k \end{matrix}$$



Rによる実習

-
- `s <- prcomp(iris[1:4], scale=FALSE)`
- `label <- iris[,5]`
- `biplot(s, xlabs = label)`
- `s`
- `summary(s)`

Biplot はローディングを表示

Prcomp に関するウェブページは多数