

## 主成分分析 Principal Component Analysis (PCA)

pp.35~49

## 回帰分析と主成分分析

- ◎回帰分析は**条件の付かない**最小問題
- ◎主成分分析は**条件付**の最大最小問題  
⇒手順は殆ど同じ
- ◎回帰分析は  
多変量解析の手法の中で最もポピュラーな手法


## 主成分分析(今回のポイント)

◎主成分分析は**条件付**の最大最小問題  
問題:

観測データにおける**分散が最大の軸**を求める

条件:

- 軸同士が直交
- p次元の軸の長さ=1



主成分分析の問題 → 固有値問題

## 主成分分析(PCA)

データ解析の数学的考え方の基本形は**主成分分析**にある

主成分分析が理解できれば  
データ解析は半分以上が理解できたと言える

観測データの**主要な変動**を要約し、特徴を把握する  
ための統計的手法を**主成分分析**と呼ぶ

### 主成分分析の目的

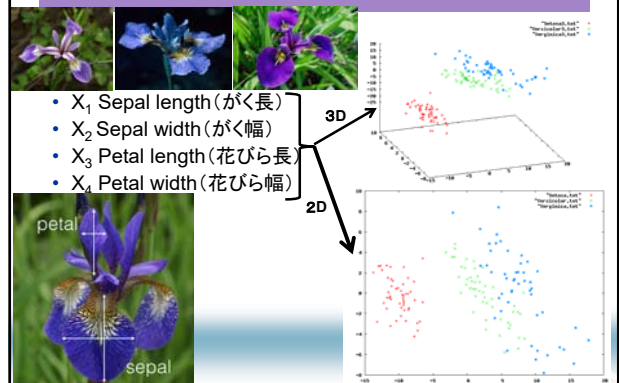
- ・情報の要約(縮約)
- ・新しい尺度の構築
- ・構造の探索



## 次元縮小・情報要約・新変数

- ◆質量÷体積 = 密度
- ◆体重・身長・胸囲・座高 → 体格
  - ・具体的・現象的(計測できる) → 抽象的・概念的
  - ・次元縮小 → 抽象度上昇
- ◆科目テストの成績 → 能力
  - ・観測変数 → 合成変数
  - ・単純化 → 理解・解釈が容易に


## 不可視 → 可視化



## データの要約(縮約)とは

- ◆ 1変量の要約 → 平均・分散・標準偏差
- ◆ 2変量の要約 → 相関係数(分散、共分散)
- ◆ 多変量の要約 → 総和・加重
  - 主成分分析、回帰分析など


$$z = X /$$



- ◆ 多変量  $X$  → 1変量の  $z$  に ⇒ **次元縮小**

## データの要約(縮約)の特例


- ◆ 2変量(●)は**一直線上に並んでいる**場合
  - **新しいz軸**で表現
  - 2次元表現が1次元に圧縮
  - ⇒ **次元縮小**



拡張: N次元の変量は**一直線上に並んでいる**時も  
同様に1次元に圧縮できる


## データの要約(縮約)の一般例

- ◆ N変量は**直線に近い状態**で並んでいる場合
  - N(=2)次元から1次元へ
  - ⇒ **次元縮小**



**問題:** Z軸をどのように定めたらよいか?

## 回帰分析と主成分分析における誤差の考え方



## 主成分分析のイメージ

点  $P_i (i=1..4)$  の平均点  $O$  に対して  $OZ_1 + OZ_2 + OZ_3 + OZ_4$  が最大にする  $z$  軸を探す

負の値を取ることが避けるため、

$$OZ_1^2 + OZ_2^2 + OZ_3^2 + OZ_4^2 \quad (1)$$


考え方をを用いる

主成分分析の基本は式(1)が


最大となる新しい軸を求める

問題に帰着する

⇒ **新しい軸の分散を最大にする** **新しい軸への垂線**


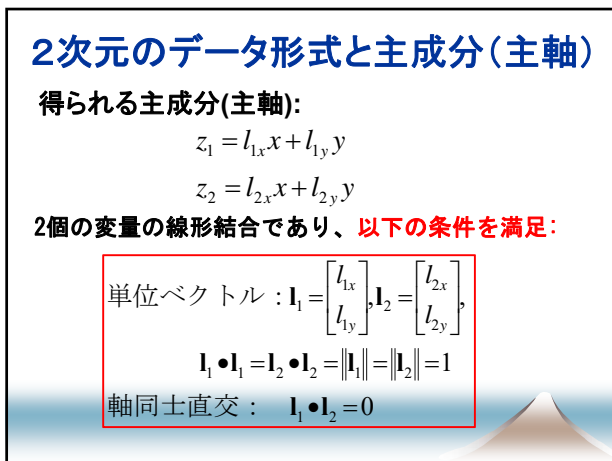
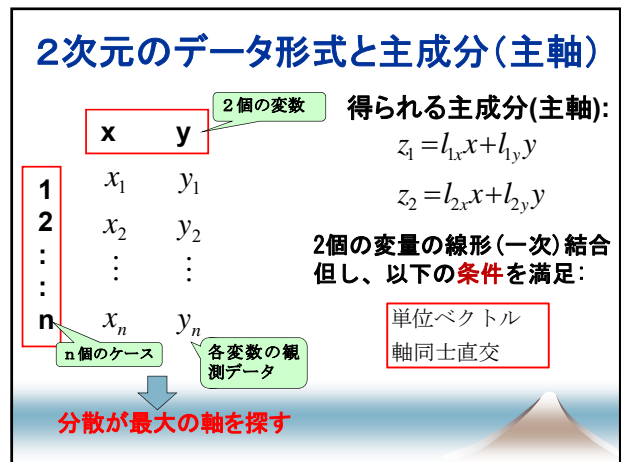
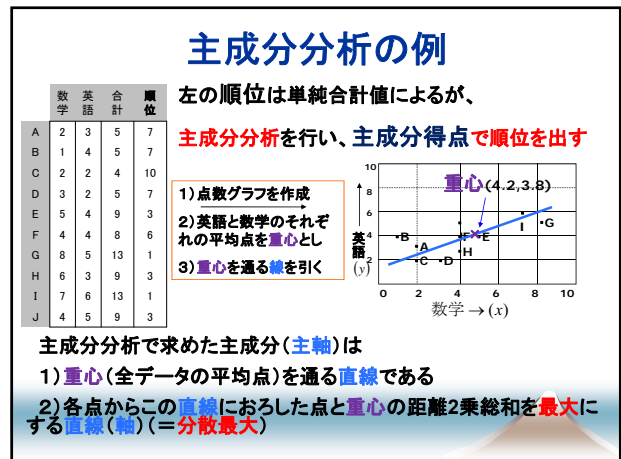



## 直線と点の距離の2乗 (最小)



中心を通る以下の直線(新しい軸Z)を求める問題に帰着:

- (1)各点からこの直線におろした垂線の長さの2乗和の値が最小にする直線  
直角三角形の有名なピタゴラスの定理より || (内容的にはまったく同じことを意味)
- (2)各点からこの直線におろした点と中心の距離2乗総和を最大にする直線



## 主成分分析

(2次元の場合、数式で表す)

$$Z_i = (\cos \theta)x_i + (\sin \theta)y_i \quad (i=1,2,\dots,n)より$$

$$Z_i = l_1x_i + l_2y_i \quad (i=1,2,\dots,n)$$

ここで、 $l_1 = \cos \theta$ ;  $l_2 = \sin \theta$

$$Z_i = x_i l_1 + y_i l_2 \quad (i=1,2,\dots,n)$$

ベクトルZと、行列Xで表現:  $Z = \begin{bmatrix} Z_1 \\ Z_2 \\ \vdots \\ Z_n \end{bmatrix} = \begin{bmatrix} x_1 & y_1 \\ x_2 & y_2 \\ \vdots & \vdots \\ x_n & y_n \end{bmatrix} \begin{bmatrix} l_1 \\ l_2 \end{bmatrix} = \mathbf{X}\mathbf{l}$

ベクトルZの分散  $S_{zz} = \frac{1}{n} \mathbf{Z}'\mathbf{Z}$  を最大にする問題

## 主成分分析

(2次元の場合、数式で表す)

$S_{zz} = \frac{1}{n} \mathbf{Z}'\mathbf{Z}$  の最大となる時のベクトル $\mathbf{l}$ の値を求めれば、新しいZ軸(第1主軸)が求められる

ただし、下の制約条件が常に付いている:

$$l_1 = \cos \theta; \quad l_2 = \sin \theta \quad \text{から} \quad l_1^2 + l_2^2 = 1$$

ベクトル $\mathbf{l} = \begin{bmatrix} l_1 \\ l_2 \end{bmatrix}$  で表現すると  $\mathbf{l}'\mathbf{l} = 1$  となる

ラグランジュの未定乗数法を使って新しい関数を定義  
その問題を解く式は? (各自で書いてみてください)

タイトル「演習レポート」、日付、学生番号、氏名を書く

## 主成分分析(数式で表す)

$$v = \frac{1}{n} \mathbf{Z}'\mathbf{Z} - \lambda(\mathbf{l}'\mathbf{l} - 1) \quad \text{に} \mathbf{Z} = \mathbf{X}\mathbf{l} \text{ を代入して}$$

$$v = \frac{1}{n} (\mathbf{X}\mathbf{l})'(\mathbf{X}\mathbf{l}) - \lambda(\mathbf{l}'\mathbf{l} - 1) = \frac{1}{n} \mathbf{l}'\mathbf{X}'\mathbf{X}\mathbf{l} - \lambda(\mathbf{l}'\mathbf{l} - 1) = \mathbf{l}'\Sigma\mathbf{l} - \lambda\mathbf{l}'\mathbf{l} + \lambda$$

ここで、 $\Sigma = \frac{1}{n} \mathbf{X}'\mathbf{X}$  (分散共分散行列) → 対称行列

ベクトル $\mathbf{l}$ について偏微分して、0とおくと


どんな式が得られるか?

タイトル「演習レポート」、日付、学生番号、氏名を書く

## 「数式で表す」のまとめ

- 主成分分析はとても簡単な計算で求めることができる
- 今まで復習した内容を綺麗にかつ簡潔に使った
- データから分散共分散行列 $\Sigma$ さえ計算されれば、  
 $(\Sigma - \lambda E)\mathbf{l} = 0$   
簡単にヤコビ法で解くことができる

## 主成分分析の計算を行ってみよう



## ベクトルで分散・共分散を書く(復習)

変数が2個、個体がn個の場合

$$\mathbf{Z} = \mathbf{X}\mathbf{l} = \begin{bmatrix} x & y \end{bmatrix} \begin{bmatrix} l_1 \\ l_2 \end{bmatrix} \quad \mathbf{x} = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix}, \mathbf{y} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix}$$

- 変数xとyの平均をそれぞれ求めてから
- 以下の式で分散、共分散をそれぞれ計算できる

分散( $S_{xx}$ )は:  $S_{xx} = \frac{1}{n} (x - \bar{x})'(x - \bar{x})$

分散( $S_{yy}$ )は:  $S_{yy} = \frac{1}{n} (y - \bar{y})'(y - \bar{y})$

共分散( $S_{xy}$ )は:  $S_{xy} = \frac{1}{n} (x - \bar{x})'(y - \bar{y})$

$$\Sigma = \begin{bmatrix} S_{xx} & S_{xy} \\ S_{xy} & S_{yy} \end{bmatrix}$$

### 主成分分析の計算

2次分散共分散行列 $\Sigma$ を求める

$$Z = \mathbf{X}\mathbf{I} = \begin{bmatrix} 50 & 85 \\ 70 & 75 \\ 65 & 80 \\ 60 & 70 \\ 75 & 90 \end{bmatrix} \begin{bmatrix} l_1 \\ l_2 \end{bmatrix} \Rightarrow \begin{bmatrix} x \\ y \end{bmatrix} = \begin{bmatrix} 50 \\ 70 \\ 65 \\ 60 \\ 75 \end{bmatrix} \begin{bmatrix} 85 \\ 75 \\ 80 \\ 70 \\ 90 \end{bmatrix}$$

平均値は: **64, 80**  
ベクトル $\mathbf{x}, \mathbf{y}$ の分散共分散行列

$$\Sigma = \begin{bmatrix} S_{xx} & S_{xy} \\ S_{xy} & S_{yy} \end{bmatrix} = \begin{bmatrix} 74 & 10 \\ 10 & 50 \end{bmatrix}$$

### 主成分分析(数式で表す)

$$\Sigma \mathbf{l} = \lambda \mathbf{l} \Rightarrow (\Sigma - \lambda \mathbf{E}) \mathbf{l} = \mathbf{0}$$

↓ 新しい軸の分散 = 固有値  
分散共分散行列 $\Sigma$ の固有値を求めればOK

$$\Sigma = \begin{bmatrix} S_{xx} & S_{xy} \\ S_{xy} & S_{yy} \end{bmatrix} \text{ の固有値を求める } |\Sigma - \lambda \mathbf{E}| = 0$$

$$\rightarrow \begin{vmatrix} S_{xx} - \lambda & S_{xy} \\ S_{xy} & S_{yy} - \lambda \end{vmatrix} = 0$$

### 2次分散共分散行列 $\Sigma$ の固有値と固有ベクトルを求めよう

$$\Sigma = \begin{bmatrix} S_{xx} & S_{xy} \\ S_{xy} & S_{yy} \end{bmatrix} \quad \Sigma \mathbf{l} = \lambda \mathbf{l} \text{ より } (\Sigma - \lambda \mathbf{E}) \mathbf{l} = \mathbf{0}$$

$$\Sigma \text{ の固有値を求める } |\Sigma - \lambda \mathbf{E}| = 0 \rightarrow \begin{vmatrix} S_{xx} - \lambda & S_{xy} \\ S_{xy} & S_{yy} - \lambda \end{vmatrix} = 0$$


---

$\lambda_k$ の固有ベクトルを求める $(\Sigma - \lambda_k \mathbf{E}) \mathbf{l}_k = \mathbf{0}$

$$\rightarrow \begin{cases} (S_{xx} - \lambda_k) l_{kx} + S_{xy} l_{ky} = 0 \\ S_{xy} l_{kx} + (S_{yy} - \lambda_k) l_{ky} = 0 \end{cases}$$

$$\sum_{i=x,y} l_{ki}^2 = 1 \quad \leftarrow \text{制約条件}$$

### 主成分分析の計算問題

データの分散共分散行列

$$\Sigma = \begin{bmatrix} S_{xx} & S_{xy} \\ S_{xy} & S_{yy} \end{bmatrix} = \begin{bmatrix} 74 & 10 \\ 10 & 50 \end{bmatrix}$$

$\Sigma$ の固有値と固有ベクトルを求めて下さい

タイトル「**演習レポート**」、日付、学生番号、氏名を書く

### 主成分分析の計算問題(固有ベクトルを求める)

データの分散共分散行列 $\Sigma = \begin{bmatrix} S_{xx} & S_{xy} \\ S_{xy} & S_{yy} \end{bmatrix} = \begin{bmatrix} 74 & 10 \\ 10 & 50 \end{bmatrix}$

$(\Sigma - \lambda \mathbf{E}) \mathbf{l} = \mathbf{0}$ より、 $\Sigma$ の固有ベクトルを求める

$$\begin{pmatrix} S_{xx} - \lambda_i & S_{xy} \\ S_{xy} & S_{yy} - \lambda_i \end{pmatrix} \begin{pmatrix} l_{i1} \\ l_{i2} \end{pmatrix} = \begin{pmatrix} 74 - \lambda_i & 10 \\ 10 & 50 - \lambda_i \end{pmatrix} \begin{pmatrix} l_{i1} \\ l_{i2} \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \end{pmatrix}$$

求めた固有値:  $\lambda_1 = 77.62, \lambda_2 = 46.38$ より

固有ベクトル:  $\mathbf{l}_1 = \begin{bmatrix} ? \\ ? \end{bmatrix}$

タイトル「**演習レポート**」、日付、学生番号、氏名を書く

### 主成分分析の宿題:

下記の表に基づいて、以下の問題を答えなさい。

No	標本	英語(x1)	数学(x2)
1	A	5	8
2	B	5	5
3	C	7	4
4	D	8	5

- (1)  $x_1$ と $x_2$ の平均値を求めなさい。
- (2)  $x_1$ と $x_2$ の分散と共分散を求める定義式を書き、分散共分散行列 $S$ を求めなさい。
- (3) 分散共分散行列 $S$ の固有値を求める定義式を書き、固有値を求めなさい。
- (4) 分散共分散行列 $S$ のランクを答え、その理由を述べなさい。
- (5) 分散共分散行列 $S$ の固有ベクトルを求める定義式を書き、固有ベクトルを求めなさい。