

# パターン認識特論

担当: 和田 俊和  
部屋 A513  
Email twada@ieee.org

## 主成分分析

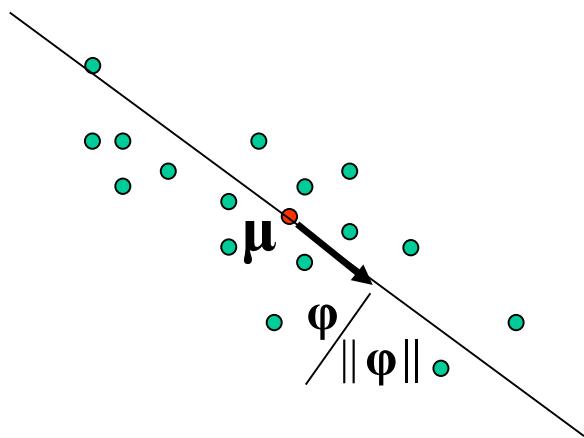
<http://vrl.sys.wakayama-u.ac.jp/PRA/>

# 主成分分析1

(正規直交基底をデータから求める)

- 特徴ベクトルの各要素の分散を最大化する。

$$c_i = (\bar{x}_i - \mu) \cdot \varphi$$



$$\begin{aligned} \bar{c} &= \frac{1}{n} \sum_{i=1}^n (\bar{x}_i - \mu) \cdot \varphi \\ &= (\bar{\bar{x}} - \mu) \cdot \varphi \end{aligned}$$

$$\mu = \bar{\bar{x}} \Rightarrow \bar{c} = 0$$

# 主成分分析2

- 特徴ベクトルの各要素の分散

$$V(\boldsymbol{\varphi}) = \frac{1}{n} \sum_{i=1}^n \left\{ (\mathbf{x}_i - \bar{\mathbf{x}}) \cdot \boldsymbol{\varphi} \right\}^2$$

$$= \frac{1}{n} \sum_{i=1}^n \{(\mathbf{x}_i - \bar{\mathbf{x}})^T \boldsymbol{\varphi}\}^T \{(\mathbf{x}_i - \bar{\mathbf{x}})^T \boldsymbol{\varphi}\}$$

$$= \frac{1}{n} \sum_{i=1}^n \boldsymbol{\varphi}^T (\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_i - \bar{\mathbf{x}})^T \boldsymbol{\varphi}$$

$$\underbrace{\frac{1}{n} \sum_{i=1}^n (\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_i - \bar{\mathbf{x}})^T}_{\hat{\mathbf{a}}} \quad \boxed{\hat{\mathbf{a}}}$$

$$= \boldsymbol{\varphi}^T \Sigma \boldsymbol{\varphi}$$

この値を  
 $\|\boldsymbol{\varphi}\|^2 = 1$   
という条件  
の下で最  
大化する。

# 知識：ベクトルの操作に関する公式

内積

$$\mathbf{a} \cdot \mathbf{b} = \mathbf{a}^T \mathbf{b} = \mathbf{b}^T \mathbf{a} = \mathbf{b} \cdot \mathbf{a}$$

$$(\alpha \mathbf{a} + \beta \mathbf{b}) \cdot \mathbf{x} = \alpha \mathbf{a} \cdot \mathbf{x} + \beta \mathbf{b} \cdot \mathbf{x}$$

転置

$$(\mathbf{A}\mathbf{b})^T = \mathbf{b}^T \mathbf{A}^T \quad (\mathbf{a}^T)^T = \mathbf{a}$$

微分

$$\frac{\partial}{\partial \mathbf{b}} \mathbf{a}^T \mathbf{b} = \mathbf{a}$$

$$\frac{\partial}{\partial \mathbf{a}} \mathbf{a}^T \mathbf{A} \mathbf{a} = 2 \mathbf{A} \mathbf{a}$$

$$\frac{\partial}{\partial \mathbf{a}} \|\mathbf{a}\|^2 = \frac{\partial}{\partial \mathbf{a}} \mathbf{a}^T \mathbf{a} = 2 \mathbf{a}$$

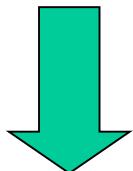
# 主成分分析3 ラグランジエの未定係数法

$$F(\varphi, \lambda) = \varphi^T \Sigma \varphi - \lambda (\|\varphi\|^2 - 1)$$

この式を最大化するのが解.

$\Rightarrow \varphi$  と  $\lambda$  で微分し, それらを0と置く

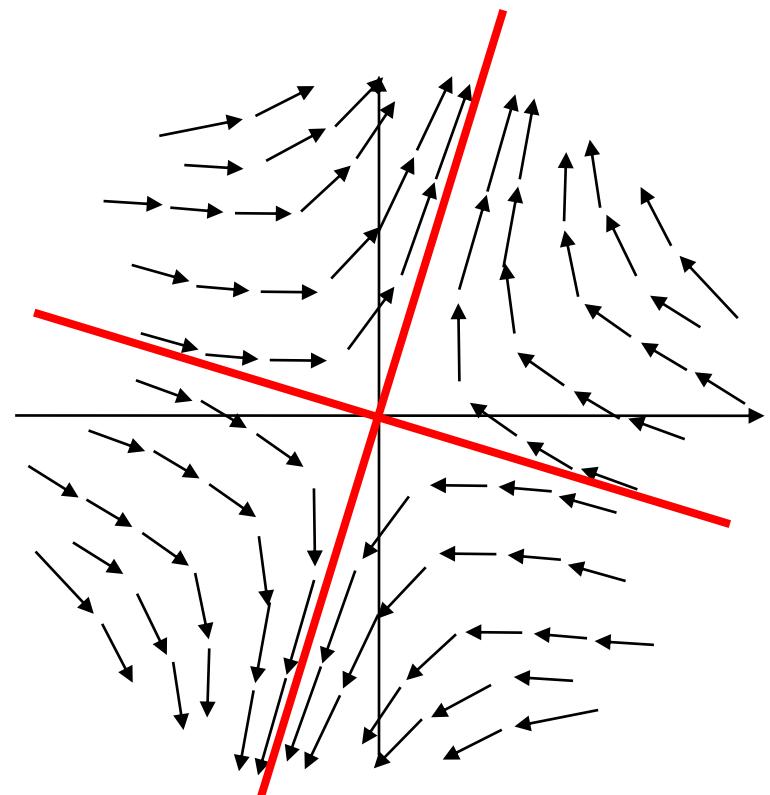
$$\frac{\partial}{\partial \varphi} F(\varphi, \lambda) = 2(\Sigma \varphi - \lambda \varphi) = 0 \quad \frac{\partial}{\partial \lambda} F(\varphi, \lambda) = \underbrace{\|\varphi\|^2 - 1}_{} = 0$$



$$\lambda \varphi = \Sigma \varphi \quad \text{固有値問題になる}$$

# $\lambda\phi = \sum\phi$ 固有値問題の例

- ・ 線形変換  $\sum\phi$
- ・  $\phi$ を起点として終点を  
 $\sum\phi$ とするベクトルを描  
く。
- ・ 右図に固有ベクトル  
の方向を書き加える  
と,



# 知識：固有値問題の解き方

固有方程式

$$\lambda\varphi = \Sigma\varphi$$

特性方程式

$$|S - I| = 0$$

各固有値が求められれば、それに対応する固有ベクトルが求められる。

# 実例

- $x_1 = (2, 4, 3)^T, \quad x_2 = (2, 2, 4)^T, \quad x_3 = (1, 1, 2)^T, \quad x_4 = (3, 1, 3)^T$

$$\bar{x} = (2, 2, 3), \quad S = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})(x_i - \bar{x})^T$$

$$= \frac{1}{4} \left\{ \begin{matrix} \begin{bmatrix} 0 \\ 2 \\ 0 \end{bmatrix} [0 \ 2 \ 0] \\ \begin{bmatrix} 2 \\ 0 \end{bmatrix} \end{matrix} + \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix} [0 \ 0 \ 1] + \begin{bmatrix} -1 \\ -1 \\ -1 \end{bmatrix} [-1 \ -1 \ -1] + \begin{bmatrix} 1 \\ -1 \\ 0 \end{bmatrix} [1 \ -1 \ 0] \right\}$$

$$= \frac{1}{4} \left\{ \begin{bmatrix} 0 & 0 & 0 \\ 0 & 4 & 0 \\ 0 & 0 & 0 \end{bmatrix} + \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 1 \end{bmatrix} + \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix} + \begin{bmatrix} 1 & -1 & 0 \\ -1 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix} \right\}$$

$$= \frac{1}{4} \begin{bmatrix} 2 & 0 & 1 \\ 0 & 6 & 1 \\ 1 & 1 & 2 \end{bmatrix} \quad \leftarrow \text{これが、共分散行列}\quad$$

# 計算結果

$$\bar{x} = (2, 2, 3)$$

$$S = \begin{pmatrix} 1 & 2 & 0 & 1 \\ 0 & 6 & 1 & 1 \\ 1 & 1 & 2 & 1 \end{pmatrix}$$

- 特性方程式  $\lambda^3 - 10\lambda^2 + 26\lambda - 16 = 0$
- 固有値  
(本当の固有  
値はこれを4  
で割る)  
 $\lambda_1 = 6.249140538955$   
 $\lambda_2 = 2.853634516909$   
 $\lambda_3 = 0.897224950336$
- 固有ベクトル: 次ページ

# 固有ベクトルの導出

$$\begin{pmatrix} 2 & 0 & 1 \\ 0 & 6 & 1 \\ 1 & 1 & 2 \end{pmatrix} \begin{pmatrix} x \\ y \\ z \end{pmatrix} = \lambda' \begin{pmatrix} x \\ y \\ z \end{pmatrix} \quad \begin{pmatrix} 2x+z \\ 6y+z \\ x+y+2z \end{pmatrix} = \lambda' \begin{pmatrix} x \\ y \\ z \end{pmatrix}$$

$$(2-\lambda')x = (6-\lambda')y \Leftrightarrow \boxed{x:y = 6-\lambda':2-\lambda'}$$

$$(2\lambda'-8)x = (6-\lambda')(2-\lambda')z$$

$$\Leftrightarrow \boxed{x:z = (6-\lambda')(2-\lambda'):2\lambda'-8}$$

$$\boxed{x:y:z = (6-\lambda')(2-\lambda'): (2-\lambda')^2 : 2\lambda'-8}$$

# 固有ベクトル

$$\Phi_1 = \begin{pmatrix} 0.056802 \\ 0.968772 \\ 0.241360 \end{pmatrix} \quad \varphi_2 = \begin{pmatrix} 0.744880 \\ -0.202092 \\ 0.635855 \end{pmatrix} \quad \varphi_3 = \begin{pmatrix} -0.664776 \\ -0.143667 \\ 0.733098 \end{pmatrix}$$

$$\lambda_1 = 6.2491405389554$$

$$\lambda_2 = 2.8536345169094$$

$$\lambda_3 = 0.89722495093364$$

$\Sigma = \lambda_1 \Phi_1 \Phi_1^T + \lambda_2 \varphi_2 \varphi_2^T + \lambda_3 \varphi_3 \varphi_3^T$  を計算すると

$$\Sigma = \frac{1}{4} \begin{bmatrix} 2 & 0 & 1 \\ 0 & 6 & 1 \\ 1 & 1 & 2 \end{bmatrix}$$
 が得られ、上記結果がことが確認できる。

# 直交展開

$$\begin{pmatrix} 2 \\ 4 \\ 3 \end{pmatrix} = 1.9375\boldsymbol{\varphi}_1 - 0.4042\boldsymbol{\varphi}_2 - 0.2873\boldsymbol{\varphi}_3 + \bar{\mathbf{x}}$$

$$\begin{pmatrix} 2 \\ 2 \\ 2 \\ 4 \end{pmatrix} = 0.2414\boldsymbol{\varphi}_1 + 0.6359\boldsymbol{\varphi}_2 + 0.7331\boldsymbol{\varphi}_3 + \bar{\mathbf{x}}$$

$$\begin{pmatrix} 1 \\ 1 \\ 2 \end{pmatrix} = -1.2669\boldsymbol{\varphi}_1 - 1.1786\boldsymbol{\varphi}_2 + 0.0753\boldsymbol{\varphi}_3 + \bar{\mathbf{x}}$$

$$\begin{pmatrix} 3 \\ 1 \\ 3 \end{pmatrix} = -0.9120\boldsymbol{\varphi}_1 + 0.9470\boldsymbol{\varphi}_2 - 0.5211\boldsymbol{\varphi}_3 + \bar{\mathbf{x}}$$

# Octaveを使えば、簡単に計算できる。

<http://www.octave.org/>

```
octave:1> sigma=[2,0,1;0,6,1;1,1,2]
```

```
sigma =
```

```
2 0 1  
0 6 1  
1 1 2
```

```
octave:2> [v,lambda]=eig(sigma)
```

```
v =
```

```
-0.664776 0.744880 0.056802  
-0.143667 -0.202092 0.968772  
0.733098 0.635855 0.241360
```

```
lambda =
```

```
0.89722 0.00000 0.00000  
0.00000 2.85363 0.00000  
0.00000 0.00000 6.24914
```

```
octave:3> v*lambda*v'
```

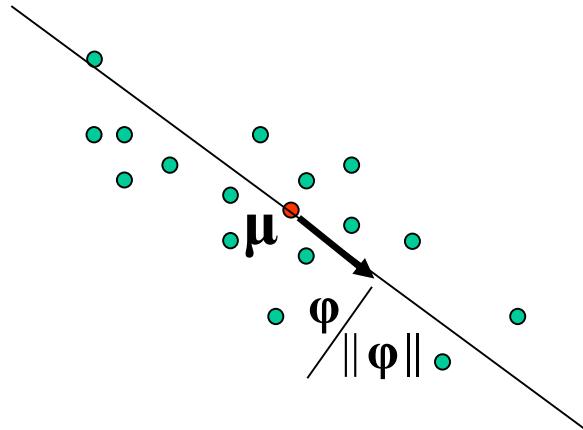
```
ans =
```

```
2.0000e+00 -4.1975e-16 1.0000e+00  
-4.8881e-16 6.0000e+00 1.0000e+00  
1.0000e+00 1.0000e+00 2.0000e+00
```

```
octave:4>
```

# 主成分分析

- 共分散行列 $\Sigma$ の性質  $S_i^2$ 分散,  $S_{ij}$ 共分散



$$\Sigma = \begin{bmatrix} S_1^2 & S_{12} & \cdots & S_{1n} \\ S_{21} & S_2^2 & \cdots & S_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ S_{n1} & S_{n2} & \cdots & S_n^2 \end{bmatrix}$$

対称行列なので次式による  
対角化が 可能

$$\Sigma = V \Lambda V^T$$

$$V = [\Phi_1 \quad \Phi_2 \quad \cdots \quad \Phi_N]$$

$$\Lambda = \begin{bmatrix} \lambda_1 & 0 & \cdots & 0 \\ 0 & \lambda_2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \lambda_n \end{bmatrix}$$

# 主成分分析

- 共分散行列 $\Sigma$ の分解

$$\Sigma = V \Lambda V^T$$

$$V = \begin{bmatrix} \varphi_1 & \varphi_2 & \cdots & \varphi_N \end{bmatrix} V^T = \begin{bmatrix} \varphi_1^T \\ \varphi_2^T \\ \vdots \\ \varphi_N^T \end{bmatrix} \Lambda = \begin{bmatrix} \lambda_1 & 0 & \cdots & 0 \\ 0 & \lambda_2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \lambda_n \end{bmatrix}$$

- 行列式

- トレース(行列の対角要素の和)

$$|\Sigma| = \det \Sigma = \prod_{i=1}^N \lambda_i$$

$$\text{trace} \Sigma = \sum_{i=1}^N \lambda_i$$

# 直交行列

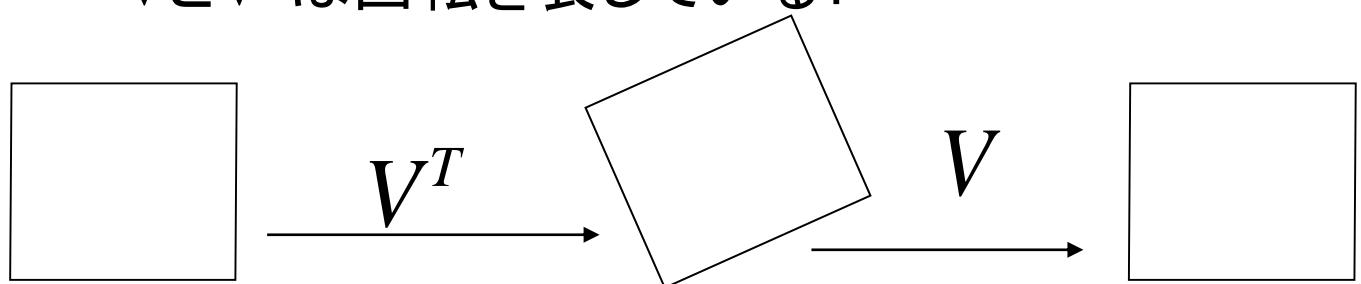
正規直交基底を並べてできる行列は直交行列

$$V = \begin{bmatrix} \varphi_1 & \varphi_2 & \cdots & \varphi_N \end{bmatrix}$$

$$V^T = \begin{bmatrix} j_1^T \\ j_2^T \\ \vdots \\ j_N^T \end{bmatrix} \quad V^T V = I \quad \Rightarrow \quad V^T = V^{-1}$$

$$\|V\mathbf{x}\| = \|\mathbf{x}\|$$

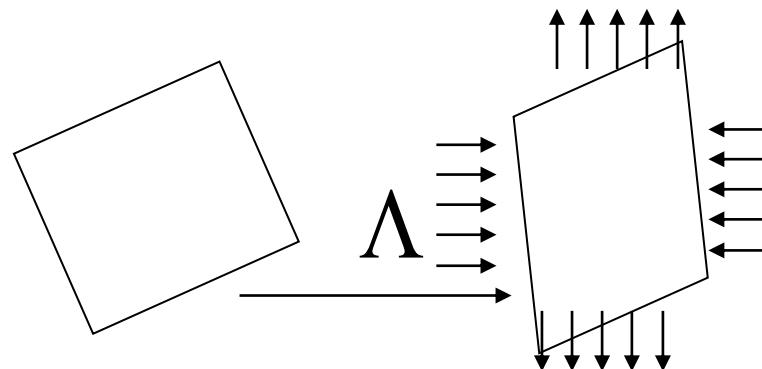
$V$ と $V^T$ は回転を表している：



# 対角行列

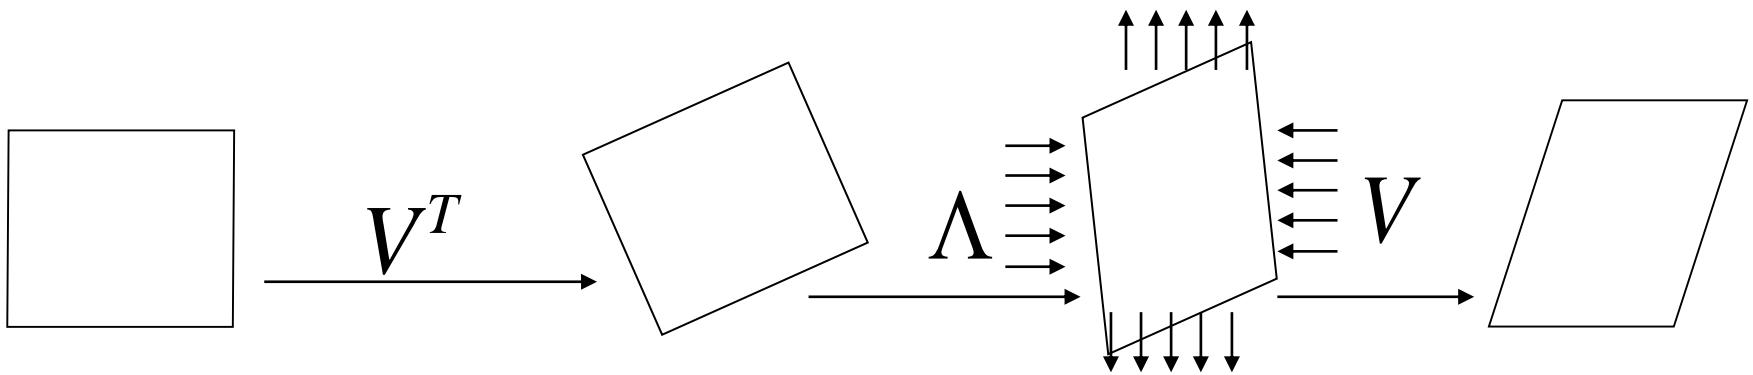
対角行列は各軸ごとの伸縮を表している

$$\Lambda = \begin{bmatrix} \lambda_1 & 0 & \cdots & 0 \\ 0 & \lambda_2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \lambda_n \end{bmatrix}$$



# 共分散行列が表す幾何学的変換

$$\Sigma = V \Lambda V^T$$



# 主成分分析によって何が分かるか

- 分散の大きくなる軸の向き  $\phi_i$
- その軸方向の偏差  $\sqrt{\lambda_i}$  分散  $\lambda_i$
- 共分散行列のランクが  $r$  である場合、次式が成り立つ

$$\mathbf{x} = \sum_{i=1}^r (\phi_i \cdot (\mathbf{x} - \bar{\mathbf{x}})) \phi_i + \bar{\mathbf{x}}$$

$$V(j_i) = j_i^T S j_i = j_i^T V \cup V^T j_i$$

「固有値=軸上  
の分散」の確認

$$= j_i^T \begin{pmatrix} I_1 & 0 & \cdots & \cdots & 0 \\ 0 & \ddots & \ddots & \ddots & \vdots \\ \vdots & \vdots & I_i & \ddots & \vdots \\ \vdots & \vdots & \ddots & \ddots & 0 \\ 0 & \cdots & \cdots & 0 & I_N \end{pmatrix} \begin{pmatrix} j_1^T & \cdots & j_i^T & \cdots & j_N^T \end{pmatrix}$$

$$= \begin{pmatrix} 0 & 0 & \cdots & \cdots & 0 \\ 0 & \ddots & \ddots & \ddots & \vdots \\ \vdots & \vdots & I_i & \ddots & \vdots \\ 1 & \vdots & \vdots & \ddots & 0 \\ \vdots & \vdots & \vdots & \ddots & 0 \\ 0 & 0 & \cdots & \cdots & 0 \end{pmatrix} \begin{pmatrix} j_1^T & \cdots & j_i^T & \cdots & j_N^T \end{pmatrix} = I_i$$

# Karhunen-Loeve 展開

- $r$ 未満の数  $q$  に対する直交展開

$$\mathbf{x}' = \sum_{i=1}^q (\varphi_i \cdot \mathbf{x}) \varphi_i$$

を計算する際に誤差  $\|\mathbf{x} - \mathbf{x}'\|$  を最小化する基底

- 自己相関行列  $R = \frac{1}{N} \sum_{i=1}^N \mathbf{x}_i \mathbf{x}_i^T$  に対する固有値問題になる.

# 次回以降の講義

- 識別(統計的手法、判別分析、線形識別関数とニューラルネットワーク、最近傍識別)
- クラスタリング(K-means、EMアルゴリズム)
- より進んだ識別手法:SVM、BOOSTINGなど