

データの分析と知識発見

Introduction to Data Analysis

今回の構成


0101010101010101010101010101010101

主成分分析について理解する

寄与率について学ぶ


Rを用いて主成分分析を行う

아이아이아이아이아이아이아이아이아이아이아이아이아이아이아이아이




- 変数の特徴をなるべく保持したまま、より少ない変数(主成分)で表す
- 直交回転:
ばらつきが大きい方向を探す
- データ間の関係
- データの圧縮

主成分分析とは




主成分分析の導出(1)

$$a_1^2 + a_2^2 = 1$$




主成分分析の導出(1)

$$a_1^2 + a_2^2 = 1$$




主成分分析の導出(1)

$$a_1^2 + a_2^2 = 1$$



主成分分析の導出(2)



$$(d^{(p)})^2 = (a_1 y_1^{(p)} + a_2 y_2^{(p)})^2$$

$$(d^{(1)})^2 = a_1^2 (y_1^{(1)})^2 + a_2^2 (y_2^{(1)})^2 + 2a_1 a_2 (y_1^{(1)} y_2^{(1)})$$

$$(d^{(2)})^2 = a_1^2 (y_1^{(2)})^2 + a_2^2 (y_2^{(2)})^2 + 2a_1 a_2 (y_1^{(2)} y_2^{(2)})$$

+

+

+

$$(d^{(N)})^2 = a_1^2 (y_1^{(N)})^2 + a_2^2 (y_2^{(N)})^2 + 2a_1 a_2 (y_1^{(N)} y_2^{(N)})$$

ラグランジュの未定乗数法

中心化されたデータの場合

$$U(a_1, a_2) = s_{11}a_1^2 + 2s_{12}a_1a_2 + s_{22}a_2^2$$

$a_1^2 + a_2^2 = 1$ という条件のもとで

$U(a_1, a_2)$ が最大となるような

a_1, a_2 を求める

ラグランジュの未定乗数法

$$G(a_1, a_2, \lambda) = U(a_1, a_2) - \lambda(a_1^2 + a_2^2 - 1)$$

$$a_1 \text{ で偏微分 } s_{11}a_1 + s_{12}a_2 + \lambda a_1 = 0$$

$$a_2 \text{ で偏微分 } s_{12}a_1 + s_{22}a_2 + \lambda a_2 = 0$$

$$\lambda \text{ で偏微分 } a_1^2 + a_2^2 = 1$$

これをまとめると

$$\begin{pmatrix} s_{11} & s_{12} \\ s_{12} & s_{22} \end{pmatrix} \begin{pmatrix} a_1 \\ a_2 \end{pmatrix} = \lambda \begin{pmatrix} a_1 \\ a_2 \end{pmatrix}$$

$$a_1^2 + a_2^2 = 1$$

分散共分散行列の
固有値, 固有ベクトルを求める

主成分分析の導出 (寄与率, 累積寄与率)

一般(r次元)

中心化後のデータの場合

$$A = \begin{pmatrix} s_{11} & s_{12} & \cdots & s_{1r} \\ s_{21} & s_{22} & \cdots & s_{2r} \\ \vdots & \vdots & \ddots & \vdots \\ s_{r1} & s_{r2} & \cdots & s_{rr} \end{pmatrix}$$

$$A\mathbf{a}_i = \lambda_i \mathbf{a}_i, \mathbf{a}_i = \begin{pmatrix} a_{i1} \\ a_{i2} \\ \vdots \\ a_{ir} \end{pmatrix}$$

$$\lambda_1 \geq \lambda_2 \geq \cdots \geq \lambda_r \geq 0$$

寄与率

$$\frac{\lambda_i}{\lambda_1 + \lambda_2 + \cdots + \lambda_r} = \frac{\lambda_i}{\sum_{k=1}^r \lambda_k}$$

累積寄与率

$$\frac{\lambda_1 + \cdots + \lambda_i}{\lambda_1 + \lambda_2 + \cdots + \lambda_r} = \frac{\sum_{j=1}^i \lambda_j}{\sum_{k=1}^r \lambda_k}$$

分散共分散行列の固有値・固有ベクトル

主成分分析の導出 (寄与率, 累積寄与率)

一般(r次元)

標準化後のデータの場合

$$A = \begin{pmatrix} 1 & r_{12} & \cdots & r_{1r} \\ r_{21} & 1 & \cdots & r_{2r} \\ \vdots & \vdots & \ddots & \vdots \\ r_{r1} & r_{r2} & \cdots & 1 \end{pmatrix}$$

$$A\mathbf{a}_i = \lambda_i \mathbf{a}_i, \mathbf{a}_i = \begin{pmatrix} a_{i1} \\ a_{i2} \\ \vdots \\ a_{ir} \end{pmatrix}$$

$$\lambda_1 \geq \lambda_2 \geq \cdots \geq \lambda_r \geq 0$$

寄与率

$$\frac{\lambda_i}{\lambda_1 + \lambda_2 + \cdots + \lambda_r} = \frac{\lambda_i}{\sum_{k=1}^r \lambda_k}$$

累積寄与率

$$\frac{\lambda_1 + \cdots + \lambda_i}{\lambda_1 + \lambda_2 + \cdots + \lambda_r} = \frac{\sum_{j=1}^i \lambda_j}{\sum_{k=1}^r \lambda_k}$$

相関行列の固有値・固有ベクトル

主成分分析とは

