

離散数理工学 (2025 年度後学期)

第 11 回

高次元 (5) : 点配置と次元削減

岡本 吉央 (電気通信大学)

okamotoy@uec.ac.jp


2026 年 1 月 20 日

最終更新 : 2026 年 1 月 12 日 12:01


データサイエンスを離散幾何・計算幾何でとらえると


次元 \approx 属性の総数

MNIST データベース (手書き文字認識)



↑
28 × 28 ピクセル





今日の目標

- 次元削減の手法として, 主成分分析を使える
- 主成分分析と固有値・固有ベクトルを関連付けられる

1. **主成分分析：1次元の場合**
2. 主成分分析：2次元以上の場合

問題：次元削減

入力： 点 $x_1, x_2, \dots, x_n \in \mathbb{R}^d$, 目標次元 $d' (< d)$

出力： 点 $x'_1, x'_2, \dots, x'_n \in \mathbb{R}^{d'}$

目標： 出力 x'_1, x'_2, \dots, x'_n が入力 x_1, x_2, \dots, x_n を
うまく 説明する

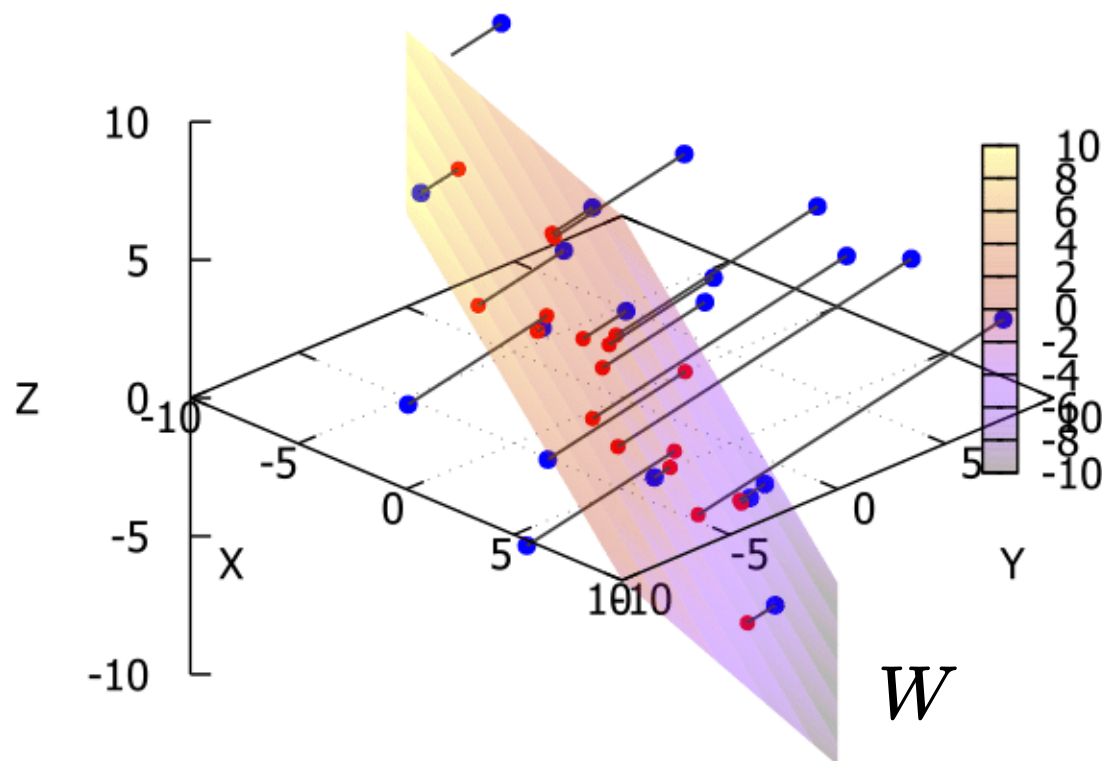


教訓

アルゴリズムを考えるときは, 「入力」と「出力」と
その仕様を明示する


アイディア (1)

\mathbb{R}^d の $\mathbb{R}^{d'}$ 次元アフィン部分空間 W へ直交射影を行う



アイディア (2)

W への距離の二乗の和が最小となるようにする



入力 : $x_1, x_2, \dots, x_n \in \mathbb{R}^d$

前処理 : 平均を 0 にする

$$\sum_{i=1}^n x_i = 0$$

入力 : $x_1, x_2, \dots, x_n \in \mathbb{R}^d$

行列に変換

$$X = \begin{bmatrix} \text{---} & x_1^T & \text{---} \\ \text{---} & x_2^T & \text{---} \\ & & \\ \text{---} & x_n^T & \text{---} \end{bmatrix}$$

n


d

前処理 : 平均を 0 にする

$$\sum_{i=1}^n x_i = 0$$

$$\mathbf{1}^T X = \mathbf{0}^T$$

手始めに : $d' = 1$ の場合 (直線への射影) を考える




$x' = \alpha u$ とすると ($\alpha \in \mathbb{R}$)

$$\begin{aligned}\|x - x'\|^2 &= \|x - \alpha u\|^2 = (x - \alpha u)^T (x - \alpha u) \\ &= \|x\|^2 - 2\alpha x^T u + \alpha^2 \|u\|^2\end{aligned}$$

$\therefore \|x - x'\|^2$ は $\alpha = x^T u$ のとき最小値 $\|x\|^2 - (x^T u)^2$ をとる

手始めに : $d' = 1$ の場合 (直線への射影) を考える



$x' = \alpha u$ とすると ($\alpha \in \mathbb{R}$)

$$\begin{aligned}\|x - x'\|^2 &= \|x - \alpha u\|^2 = (x - \alpha u)^T (x - \alpha u) \\ &= \|x\|^2 - 2\alpha x^T u + \alpha^2 \|u\|^2\end{aligned}$$

$\therefore \|x - x'\|^2$ は $\alpha = x^T u$ のとき最小値 $\|x\|^2 - (x^T u)^2$ をとる

x の W への射影 x' は $x' = (x^T u)u$ で与えられる

考える最適化問題

変数 : $u \in \mathbb{R}^d$

目的 : $\sum_{i=1}^n (\|x_i\|^2 - (x_i^T u)^2)$ の最小化

制約 : $\|u\| = 1$

考える最適化問題

変数 : $u \in \mathbb{R}^d$

目的 : $\sum_{i=1}^n (\|x_i\|^2 - (x_i^T u)^2)$ の最小化

制約 : $\|u\| = 1$

↓ $\|x_i\|^2$ は入力だけから決まる

考える最適化問題 (上の問題と等価)

変数 : $u \in \mathbb{R}^d$

目的 : $\sum_{i=1}^n (x_i^T u)^2$ の最大化

制約 : $\|u\| = 1$

考える最適化問題

変数 : $u \in \mathbb{R}^d$

目的 : $\sum_{i=1}^n (\|x_i\|^2 - (x_i^T u)^2)$ の最小化

制約 : $\|u\| = 1$

↓ $\|x_i\|^2$ は入力だけから決まる

考える最適化問題 (上の問題と等価)

変数 : $u \in \mathbb{R}^d$

目的 : $\sum_{i=1}^n (x_i^T u)^2$ の最大化

制約 : $\|u\| = 1$

$$\max_{\substack{u \in \mathbb{R}^d \\ \|u\|=1}} \sum_{i=1}^n (x_i^T u)^2$$

$$\max_{\substack{\mathbf{u} \in \mathbb{R}^d \\ \|\mathbf{u}\|=1}} \sum_{i=1}^n (x_i^T \mathbf{u})^2 = \max_{\substack{\mathbf{u} \in \mathbb{R}^d \\ \|\mathbf{u}\|=1}} (\mathbf{X}\mathbf{u})^T (\mathbf{X}\mathbf{u})$$

$$\because \mathbf{X}\mathbf{u} = \begin{bmatrix} x_1^T \\ x_2^T \\ \vdots \\ x_n^T \end{bmatrix} \mathbf{u} = \begin{bmatrix} x_1^T \mathbf{u} \\ x_2^T \mathbf{u} \\ \vdots \\ x_n^T \mathbf{u} \end{bmatrix}$$

$$\max_{\substack{\mathbf{u} \in \mathbb{R}^d \\ \|\mathbf{u}\|=1}} \sum_{i=1}^n (x_i^T \mathbf{u})^2 = \max_{\substack{\mathbf{u} \in \mathbb{R}^d \\ \|\mathbf{u}\|=1}} (\mathbf{X}\mathbf{u})^T (\mathbf{X}\mathbf{u})$$

$$\because \mathbf{X}\mathbf{u} = \begin{bmatrix} x_1^T \\ x_2^T \\ \vdots \\ x_n^T \end{bmatrix} \mathbf{u} = \begin{bmatrix} x_1^T \mathbf{u} \\ x_2^T \mathbf{u} \\ \vdots \\ x_n^T \mathbf{u} \end{bmatrix}$$

$$= \max_{\substack{\mathbf{u} \in \mathbb{R}^d \\ \|\mathbf{u}\|=1}} \mathbf{u}^T \mathbf{X}^T \mathbf{X} \mathbf{u}$$

$$\max_{\substack{\mathbf{u} \in \mathbb{R}^d \\ \|\mathbf{u}\|=1}} \sum_{i=1}^n (x_i^T \mathbf{u})^2 = \max_{\substack{\mathbf{u} \in \mathbb{R}^d \\ \|\mathbf{u}\|=1}} (\mathbf{X}\mathbf{u})^T (\mathbf{X}\mathbf{u})$$

$$\because \mathbf{X}\mathbf{u} = \begin{bmatrix} x_1^T \mathbf{u} \\ x_2^T \mathbf{u} \\ \vdots \\ x_n^T \mathbf{u} \end{bmatrix} \quad \mathbf{u} = \begin{bmatrix} x_1^T \mathbf{u} \\ x_2^T \mathbf{u} \\ \vdots \\ x_n^T \mathbf{u} \end{bmatrix}$$

$$= \max_{\substack{\mathbf{u} \in \mathbb{R}^d \\ \|\mathbf{u}\|=1}} \mathbf{u}^T \mathbf{X}^T \mathbf{X} \mathbf{u}$$

$$= \max_{\substack{\mathbf{u} \in \mathbb{R}^d \\ \|\mathbf{u}\|=1}} \mathbf{u}^T \mathbf{A} \mathbf{u}$$

(ただし, $\mathbf{A} = \mathbf{X}^T \mathbf{X}$)

注: \mathbf{A} は対称半正定値

定義：対称正定値行列

正則な対称行列 $M \in \mathbb{R}^{d \times d}$ に対して、次は同値

1. ある正則行列 $C \in \mathbb{R}^{d \times d}$ が存在して, $M = C^T C$
2. M の固有値はすべて正
3. 任意の $x \in \mathbb{R}^d - \{0\}$ に対して, $x^T M x > 0$

この性質を持つ M を **対称正定値行列** と呼ぶ

定義：対称半正定値行列

対称行列 $M \in \mathbb{R}^{d \times d}$ に対して、次は同値

1. ある行列 $C \in \mathbb{R}^{r \times d}$ が存在して, $M = C^T C$
2. M の固有値はすべて非負
3. 任意の $x \in \mathbb{R}^d$ に対して, $x^T M x \geq 0$

この性質を持つ M を **対称半正定値行列** と呼ぶ

注：対称半正定値行列は正則であるとは限らない

考える最適化問題

入力： 実対称半正定値行列 $A \in \mathbb{R}^{d \times d}$

出力： $\max_{\substack{u \in \mathbb{R}^d \\ \|u\|=1}} u^T A u$

考える最適化問題

入力： 実対称半正定値行列 $A \in \mathbb{R}^{d \times d}$

出力： $\max_{\substack{u \in \mathbb{R}^d \\ \|u\|=1}} u^T A u$

性質：最適化と固有値・固有ベクトル


実対称半正定値行列 A の最大固有値を $\lambda_1 \geq 0$ として、
 λ_1 に対応する単位固有ベクトルを v_1 とすると

$$\max_{\substack{u \in \mathbb{R}^d \\ \|u\|=1}} u^T A u = v_1^T A v_1 = \lambda_1$$

つまり、 v_1 が最適解で、 λ_1 が最適値

次元削減の手法：主成分分析 (直線への射影)

1. x_1, \dots, x_n の和が 0 となるように平行移動する
2. x_1^T, \dots, x_n^T を行とする行列 $X \in \mathbb{R}^{n \times d}$ を作る
3. $A = X^T X$ を作る
4. A の最大固有値に対する単位固有ベクトル v_1 を求める
5. 各 i に対して, x_i を $x_i^T v_1 \in \mathbb{R}$ に写す



証明 (1) : 最適値 = 最大固有値

17/35

証明 (最適値 \geq 最大固有値) :

単位固有ベクトル $v_1 \in \mathbb{R}^d$ は $\|v_1\| = 1$ を満たすので

$$\max_{\substack{u \in \mathbb{R}^d \\ \|u\|^2 = 1}} u^T A u \geq v_1^T A v_1 = v_1^T (\lambda_1 v_1) = \lambda_1 (v_1^T v_1) = \lambda_1$$

証明 (最適値 \geq 最大固有値) :

単位固有ベクトル $v_1 \in \mathbb{R}^d$ は $\|v_1\| = 1$ を満たすので

$$\max_{\substack{u \in \mathbb{R}^d \\ \|u\|^2 = 1}} u^T A u \geq v_1^T A v_1 = v_1^T (\lambda_1 v_1) = \lambda_1 (v_1^T v_1) = \lambda_1$$

証明 (最適値 \leq 最大固有値) :

- $\|u\| = 1$ を満たす任意のベクトル $u \in \mathbb{R}^d$ を考える
- A の固有値を $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_d$ とし,
 $\{v_1, v_2, \dots, v_d\}$ が \mathbb{R}^d の正規直交基底となるように
 λ_i に対応する固有ベクトル v_i をとれる
(注 : A が対称であるとき, これが可能)

証明 (最適値 \leq 最大固有値) :

- $u = \sum_{i=1}^d \alpha_i v_i$ とする

- このとき, $1 = \|u\|^2 = \left\| \sum_i \alpha_i v_i \right\|^2 = \sum_i \alpha_i^2$

$$\left\| \sum_i \alpha_i v_i \right\|^2 = \left(\sum_i \alpha_i v_i \right)^T \left(\sum_j \alpha_j v_j \right)$$

$$= \sum_i \sum_j \alpha_i \alpha_j \underline{v_i^T v_j} = \sum_i \alpha_i^2$$

$$= \begin{cases} 1 & (i = j) \\ 0 & (i \neq j) \end{cases}$$

証明 (最適値 \leq 最大固有値) :

- $u = \sum_{i=1}^d \alpha_i v_i$ とする

- このとき, $1 = \|u\|^2 = \left\| \sum_i \alpha_i v_i \right\|^2 = \sum_i \alpha_i^2$

- したがって

$$\begin{aligned} u^T A u &= \left(\sum_{i=1}^d \alpha_i v_i \right)^T A \left(\sum_{j=1}^d \alpha_j v_j \right) \\ &= \sum_{i=1}^d \sum_{j=1}^d \alpha_i \alpha_j v_i^T A v_j = \sum_{i=1}^d \sum_{j=1}^d \alpha_i \alpha_j \lambda_j v_i^T v_j \\ &= \sum_{i=1}^d \alpha_i^2 \lambda_i \leq \sum_{i=1}^d \alpha_i^2 \lambda_1 = \lambda_1 \end{aligned}$$

□

関連する用語だけ導入する

定義：レイリー商

実対称行列 $A \in \mathbb{R}^{d \times d}$ とベクトル $x \in \mathbb{R}^d - \{0\}$ に対する **レイリー商** とは、次の比のこと

$$\frac{x^T A x}{x^T x}$$

注：レイリー商は x のスカラー倍に関して不変
つまり、 x を cx に変えると ($c \in \mathbb{R} - \{0\}$)

$$\frac{(cx)^T A (cx)}{(cx)^T (cx)} = \frac{c^2 (x^T A x)}{c^2 (x^T x)} = \frac{x^T A x}{x^T x}$$

関連する用語だけ導入する

定義：レイリー商

実対称行列 $A \in \mathbb{R}^{d \times d}$ とベクトル $x \in \mathbb{R}^d - \{0\}$ に対する **レイリー商** とは、次の比のこと

$$\frac{x^T A x}{x^T x}$$

注：レイリー商は x のスカラー倍に関して不変
つまり、 x を cx に変えると ($c \in \mathbb{R} - \{0\}$)

$$\frac{(cx)^T A (cx)}{(cx)^T (cx)} = \frac{c^2 (x^T A x)}{c^2 (x^T x)} = \frac{x^T A x}{x^T x}$$

したがって、 $\max_{x \in \mathbb{R}^d - \{0\}} \frac{x^T A x}{x^T x} = A$ の最大固有値

いままでの議論を模倣すると、次が分かる


性質：レイリー商と最大/最小固有値

実対称行列 $A \in \mathbb{R}^{d \times d}$ の最大固有値 λ_1 , 最小固有値 λ_d は次を満たす

$$\lambda_1 = \max_{x \in \mathbb{R}^d - \{0\}} \frac{x^T A x}{x^T x}$$

$$\lambda_d = \min_{x \in \mathbb{R}^d - \{0\}} \frac{x^T A x}{x^T x}$$

1. 主成分分析：1次元の場合
2. **主成分分析：2次元以上の場合**



d' 次元線形空間 W

正規直交基底 $\{u_1, u_2, \dots, u_{d'}\}$

$$x' = \sum_{j=1}^{d'} \alpha_j u_j \text{ とすると}$$

$$\begin{aligned} \|x - x'\|^2 &= \|x - \sum_j \alpha_j u_j\|^2 \\ &= \|x\|^2 - 2 \sum_j \alpha_j x^T u_j + \sum_j \alpha_j^2 \|u_j\|^2 \\ &= \|x\|^2 - \sum_j (x^T u_j)^2 \quad (\alpha_j = x^T u_j \text{ のとき}) \end{aligned}$$

考える最適化問題

変数 : $u_1, u_2, \dots, u_{d'} \in \mathbb{R}^d$

目的 : $\sum_{i=1}^n \sum_{j=1}^{d'} (\|x_i\|^2 - (x_i^T u_j)^2)$ の最小化

制約 : $\|u_j\| = 1, \quad u_j^T u_k = 0 \ (j \neq k)$

考える最適化問題

変数 : $u_1, u_2, \dots, u_{d'} \in \mathbb{R}^d$

目的 : $\sum_{i=1}^n \sum_{j=1}^{d'} (\|x_i\|^2 - (x_i^T u_j)^2)$ の最小化

制約 : $\|u_j\| = 1, u_j^T u_k = 0 (j \neq k)$

↓ $\|x_i\|^2$ は入力だけから決まる

考える最適化問題 (上の問題と等価)

変数 : $u_1, u_2, \dots, u_{d'} \in \mathbb{R}^d$

目的 : $\sum_{i=1}^n \sum_{j=1}^{d'} (x_i^T u_j)^2$ の最大化

制約 : $\|u_j\| = 1, u_j^T u_k = 0 (j \neq k)$

考える最適化問題

変数 : $u_1, u_2, \dots, u_{d'} \in \mathbb{R}^d$

目的 : $\sum_{i=1}^n \sum_{j=1}^{d'} (\|x_i\|^2 - (x_i^T u_j)^2)$ の最小化

制約 : $\|u_j\| = 1, u_j^T u_k = 0 (j \neq k)$

↓ $\|x_i\|^2$ は入力だけから決まる

考える最適化問題 (上の問題と等価)

変数 : $u_1, u_2, \dots, u_{d'} \in \mathbb{R}^d$

目的 : $\sum_{i=1}^n \sum_{j=1}^{d'} (x_i^T u_j)^2$ の最大化

制約 : $\|u_j\| = 1, u_j^T u_k = 0 (j \neq k)$

$$\max_{\substack{u_1, \dots, u_{d'} \in \mathbb{R}^d \\ \|u_j\|=1 \\ u_j^T u_k = 0 (j \neq k)}} \sum_{i=1}^n \sum_{j=1}^{d'} (x_i^T u_j)^2$$

以下, $d' = 2$ として, アイディアを説明する

$$\max_{\substack{\mathbf{u}_1, \mathbf{u}_2 \in \mathbb{R}^d \\ \|\mathbf{u}_j\|=1 \\ \mathbf{u}_1^T \mathbf{u}_2=0}} \sum_{i=1}^n ((\mathbf{x}_i^T \mathbf{u}_1)^2 + (\mathbf{x}_i^T \mathbf{u}_2)^2)$$

$$= \max_{\substack{\mathbf{u}_1, \mathbf{u}_2 \in \mathbb{R}^d \\ \|\mathbf{u}_j\|=1 \\ \mathbf{u}_1^T \mathbf{u}_2=0}} (\mathbf{u}_1^T X^T X \mathbf{u}_1) + (\mathbf{u}_2^T X^T X \mathbf{u}_2)$$

$$= \max_{\substack{\mathbf{u}_1, \mathbf{u}_2 \in \mathbb{R}^d \\ \|\mathbf{u}_j\|=1 \\ \mathbf{u}_1^T \mathbf{u}_2=0}} (\mathbf{u}_1^T A \mathbf{u}_1) + (\mathbf{u}_2^T A \mathbf{u}_2)$$

(ただし, $A = X^T X$)

注: A は対称半正定値

考える最適化問題

入力： 実対称半正定値行列 $A \in \mathbb{R}^{d \times d}$

出力： $\max_{\substack{u_1, u_2 \in \mathbb{R}^d \\ \|u_j\|=1 \\ u_1^T u_2 = 0}} (u_1^T A u_1) + (u_2^T A u_2)$

考える最適化問題

入力： 実対称半正定値行列 $A \in \mathbb{R}^{d \times d}$

出力： $\max_{\substack{u_1, u_2 \in \mathbb{R}^d \\ \|u_j\|=1 \\ u_1^T u_2 = 0}} (u_1^T A u_1) + (u_2^T A u_2)$

性質：最適化と固有値・固有ベクトル


A の最大・第2最大固有値を $\lambda_1, \lambda_2 \geq 0$ として,
 λ_1, λ_2 に対応する単位固有ベクトルを v_1, v_2 とすると
(ただし, $v_1^T v_2 = 0$)

$$\begin{aligned} \max_{\substack{u_1, u_2 \in \mathbb{R}^d \\ \|u_j\|=1 \\ u_1^T u_2 = 0}} (u_1^T A u_1) + (u_2^T A u_2) &= v_1^T A v_1 + v_2^T A v_2 \\ &= \lambda_1 + \lambda_2 \end{aligned}$$

次元削減の手法：主成分分析 (平面への射影)

1. x_1, \dots, x_n の和が 0 となるように平行移動する
2. x_1^T, \dots, x_n^T を行とする行列 $X \in \mathbb{R}^{n \times d}$ を作る
3. $A = X^T X$ を作る
4. A の最大固有値, 第 2 最大固有値に対する単位固有ベクトル v_1, v_2 を求める (ただし, $v_1^T v_2 = 0$ とする)
5. 各 i に対して, x_i を $(x_i^T v_1, x_i^T v_2) \in \mathbb{R}^2$ に写す

$d' > 2$ の場合も同様
(第 d' 最大固有値まで考える)



以下, 証明は 発展的内容

証明 (最適値 $\geq \lambda_1 + \lambda_2$) :

単位固有ベクトル $v_1, v_2 \in \mathbb{R}^d$ を

$\|v_1\|, \|v_2\| = 1$ と $v_1^T v_2 = 0$ を満たすようにとると,

$$\max_{\substack{u_1, u_2 \in \mathbb{R}^d \\ \|u_j\|=1 \\ u_1^T u_2=0}} (u_1^T A u_1) + (u_2^T A u_2) \geq v_1^T A v_1 + v_2^T A v_2 = \lambda_1 + \lambda_2$$

復習

実対称行列 $X \in \mathbb{R}^{d \times d}$ の異なる固有値に対応する
固有ベクトルは直交する

証明 (最適値 $\leq \lambda_1 + \lambda_2$) :

- A は次のように対角化できる

$$A = \underbrace{\begin{bmatrix} v_1 & \cdots & v_d \end{bmatrix}}_V \underbrace{\begin{bmatrix} \lambda_1 & & \\ & \ddots & \\ & & \lambda_d \end{bmatrix}}_D \underbrace{\begin{bmatrix} v_1^T \\ \vdots \\ v_d^T \end{bmatrix}}_{V^T}$$

ただし, v_1, \dots, v_d は A の固有ベクトルで
 $VV^T = V^TV = E_d$

証明 (最適値 $\leq \lambda_1 + \lambda_2$) :

- A は次のように対角化できる

$$A = \underbrace{\begin{bmatrix} v_1 & \cdots & v_d \end{bmatrix}}_V \underbrace{\begin{bmatrix} \lambda_1 & & \\ & \ddots & \\ & & \lambda_d \end{bmatrix}}_D \underbrace{\begin{bmatrix} v_1^T \\ \vdots \\ v_d^T \end{bmatrix}}_{V^T}$$

ただし, v_1, \dots, v_d は A の固有ベクトルで
 $VV^T = V^TV = E_d$

- 行列 $U \in \mathbb{R}^{d \times 2}$ を次のように定義する

$$U = \begin{bmatrix} u_1 & u_2 \end{bmatrix}$$

$\|u_j\| = 1, u_1^T u_2 = 0$ のとき, $U^T U = E_2$

- このとき,

$$\begin{aligned} U^T A U &= \begin{bmatrix} u_1^T \\ u_2^T \end{bmatrix} A \begin{bmatrix} u_1 & u_2 \end{bmatrix} = \begin{bmatrix} u_1^T \\ u_2^T \end{bmatrix} \begin{bmatrix} A u_1 & A u_2 \end{bmatrix} \\ &= \begin{bmatrix} u_1^T A u_1 & u_1^T A u_2 \\ u_2^T A u_1 & u_2^T A u_2 \end{bmatrix} \end{aligned}$$

- したがって, $u_1^T A u_1 + u_2^T A u_2 = \text{tr}(U^T A U)$

定義：トレース, 跡

実対称行列 $X \in \mathbb{R}^{d \times d}$ の **トレース** とは,

$$\text{tr}(X) = \sum_{i=1}^d x_{ii}$$

- すでに導入した記法と性質を使うと

$$\begin{aligned}\mathrm{tr}(U^T A U) &= \mathrm{tr}(U^T V D V^T U) \\ &= \mathrm{tr}(Z^T D Z) \quad (\text{ただし, } Z = V^T U \in \mathbb{R}^{d \times 2}) \\ &= \sum_{i=1}^d \lambda_i (z_{i1}^2 + z_{i2}^2)\end{aligned}$$

- すでに導入した記法と性質を使うと

$$\begin{aligned}\text{tr}(U^T A U) &= \text{tr}(U^T V D V^T U) \\ &= \text{tr}(Z^T D Z) \quad (\text{ただし, } Z = V^T U \in \mathbb{R}^{d \times 2}) \\ &= \sum_{i=1}^d \lambda_i (z_{i1}^2 + z_{i2}^2)\end{aligned}$$

- ここで, $Z^T Z = U^T V V^T U = U^T U = E_2$
特に, $\text{tr}(Z^T Z) = \text{tr}(I_2) = 2$ なので, $\sum_{i=1}^d (z_{i1}^2 + z_{i2}^2) = 2$

補題

いまの設定で, $0 \leq z_{i1}^2 + z_{i2}^2 \leq 1$

補題

いまの設定で, $0 \leq z_{i1}^2 + z_{i2}^2 \leq 1$

補題の証明 : $z_{i1}^2 + z_{i2}^2$ は ZZ^T の第 i, i 成分

- $ZZ^T = V^T U U^T V$
- $P = U U^T$ は次を満たす
 - $P^T = P$
 - $P^2 = P$ $(\because P^2 = (U U^T)(U U^T) = U(U^T U)U^T = U U^T = P)$
- したがって, P の固有値は 0 か 1
 $(\because P$ の固有値 α に対応する固有ベクトルを z とすると,
 $\alpha z = P z = P^2 z = P(\alpha z) = \alpha^2 z$ で, $\alpha = \alpha^2)$

- $ZZ^T = V^T U U^T V = V^T P V$
- $\therefore ZZ^T$ の固有値も 0 か 1
($\because \det(ZZ^T - \lambda E) = \det(V^T P V - \lambda V^T V)$
 $= \det(V^T) \det(P - \lambda E) \det(V)$
 $= \det(P - \lambda E)$)
- \therefore 任意のベクトル $x \in \mathbb{R}^d$ (ただし, $\|x\| = 1$) に対して

$$0 \leq x^T (ZZ^T) x \leq 1$$

- $x = e_i$ (第 i 基本ベクトル) とすると,

$$0 \leq ZZ^T \text{ の第 } i, i \text{ 成分} \leq 1$$

- したがって,

$$0 \leq z_{i1}^2 + z_{i2}^2 \leq 1$$

□

- いままでの議論から次が成り立つ

$$\begin{aligned} & \max_{\substack{\mathbf{u}_1, \mathbf{u}_2 \in \mathbb{R}^d \\ \|\mathbf{u}_j\|=1 \\ \mathbf{u}_1^\top \mathbf{u}_2=0}} (\mathbf{u}_1^\top A \mathbf{u}_1) + (\mathbf{u}_2^\top A \mathbf{u}_2) \end{aligned}$$

$$\leq \max_{Z \in \mathbb{R}^{d \times 2}} \left\{ \sum_i \lambda_i (z_{i1}^2 + z_{i2}^2) \mid \begin{array}{l} 0 \leq z_{i1}^2 + z_{i2}^2 \leq 1 \quad \forall i, \\ \sum_i (z_{i1}^2 + z_{i2}^2) = 2 \end{array} \right\}$$

- いままでの議論から次が成り立つ

$$\begin{aligned} & \max_{\substack{\mathbf{u}_1, \mathbf{u}_2 \in \mathbb{R}^d \\ \|\mathbf{u}_j\|=1 \\ \mathbf{u}_1^T \mathbf{u}_2 = 0}} (u_1^T A u_1) + (u_2^T A u_2) \end{aligned}$$

$$\leq \max_{Z \in \mathbb{R}^{d \times 2}} \left\{ \sum_i \lambda_i (z_{i1}^2 + z_{i2}^2) \mid \begin{array}{l} 0 \leq z_{i1}^2 + z_{i2}^2 \leq 1 \quad \forall i, \\ \sum_i (z_{i1}^2 + z_{i2}^2) = 2 \end{array} \right\}$$

$$z_{11}^2 + z_{12}^2 = 1, z_{21}^2 + z_{22}^2 = 1$$

$$z_{i1}^2 + z_{i2}^2 = 0 \quad (i \neq 1, 2)$$

$$= \lambda_1 + \lambda_2$$



性質：レイリー商と第2最大固有値

実対称行列 $A \in \mathbb{R}^{d \times d}$ の第2最大固有値 λ_2 は次を満たす

$$\lambda_2 = \max_{\substack{x \in \mathbb{R}^d - \{0\} \\ v_1^T x = 0}} \frac{x^T A x}{x^T x}$$

ただし, v_1 は最大固有値に対応する固有ベクトル

証明：演習問題

今日の目標

- 次元削減の手法として, 主成分分析を使える
- 主成分分析と固有値・固有ベクトルを関連付けられる

主成分分析のまとめ

1. データを行列 $X \in \mathbb{R}^{n \times d}$ で表す (平均は 0 にする)
2. $X^T X$ の固有値・固有ベクトルを求める
3. 大きい方から順に固有値・固有ベクトルを持ってくる