

特異値分解：Singular Value Decomposition

定理 \mathbf{A} を、rankがRのMxN行列とする。このとき、以下の式を満たすMxMの直交行列 \mathbf{V} 、NxNの直交行列 \mathbf{U} 、および、MxNの対角行列 \mathbf{S} が存在する。

$$\mathbf{V}^T \mathbf{A} \mathbf{U} = \mathbf{S} \quad \text{または} \quad \mathbf{A} = \mathbf{V} \mathbf{S} \mathbf{U}^T \quad (1)$$

ただし、

$$\mathbf{V} = \begin{bmatrix} v_{11} & \cdots & v_{1M} \\ \vdots & \ddots & \vdots \\ v_{M1} & \cdots & v_{MM} \end{bmatrix}$$

$$\mathbf{U} = \begin{bmatrix} u_{11} & \cdots & u_{1N} \\ \vdots & \ddots & \vdots \\ u_{N1} & \cdots & u_{NN} \end{bmatrix}$$

$$\mathbf{S} = \begin{bmatrix} \lambda_1 & \cdots & 0 & & \\ \vdots & \ddots & \vdots & & \\ 0 & \cdots & \lambda_R & & \\ & & & 0 & \\ & & & & 0 \end{bmatrix}$$

M行

$\mathbf{A} = \mathbf{V} \mathbf{S} \mathbf{U}^T$ を、 \mathbf{A} の特異値分解Singular Value Decompositionとよぶ。

特異値分解の別の表現（個々のベクトルを用いた表現）

$$\mathbf{V} = \begin{bmatrix} \mathbf{v}_{11} & \cdots & \mathbf{v}_{1M} \\ \vdots & \ddots & \vdots \\ \mathbf{v}_{M1} & \cdots & \mathbf{v}_{MM} \end{bmatrix} = [\mathbf{v}_1 \quad \cdots \quad \mathbf{v}_M]$$
$$\mathbf{U} = \begin{bmatrix} \mathbf{u}_{11} & \cdots & \mathbf{u}_{1N} \\ \vdots & \ddots & \vdots \\ \mathbf{u}_{N1} & \cdots & \mathbf{u}_{NN} \end{bmatrix} = [\mathbf{u}_1 \quad \cdots \quad \mathbf{u}_N]$$

として、特異値分解は次のようにも表現できる。

$$\mathbf{A} = \mathbf{V}\mathbf{S}\mathbf{U}^T = \sum_{i=1}^R \lambda_i \mathbf{v}_i \mathbf{u}_i^T \quad (2)$$

V,Sを求める

$$\mathbf{A} = \mathbf{V}\mathbf{S}\mathbf{U}^T = \sum_{i=1}^R \lambda_i \mathbf{v}_i \mathbf{u}_i^T \quad (2)$$

\mathbf{A} を特異値分解で表現するための \mathbf{U} 、 \mathbf{V} 、 \mathbf{S} は固有値問題を解くことにより求まる。すなわち、まず \mathbf{V} については、 $\mathbf{A}\mathbf{A}^T$ を計算すると、

$$\mathbf{A}\mathbf{A}^T = \mathbf{V}\mathbf{S}\mathbf{U}^T (\mathbf{V}\mathbf{S}\mathbf{U}^T)^T = \mathbf{V}\mathbf{S}\mathbf{U}^T \mathbf{U}\mathbf{S}^T \mathbf{V}^T = \mathbf{V}\mathbf{S}_M^2 \mathbf{V}^T \quad (3)$$

両辺に右から \mathbf{V} を掛ければ、

$$\mathbf{A}\mathbf{A}^T \mathbf{V} = \mathbf{V}\mathbf{S}^2 \quad (4)$$

式(1-7)を別の表現で書くと、

$$(\mathbf{A}\mathbf{A}^T) \mathbf{v}_i = \lambda_i^2 \mathbf{v}_i \quad (5)$$

ただし、

$$\mathbf{S}_M^2 \equiv \begin{bmatrix} \lambda_1^2 & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & \lambda_R^2 \\ & & & 0 \\ & & & & 0 \end{bmatrix}$$

M行

これは、 $\mathbf{A}\mathbf{A}^T$ の固有値 ($\{\lambda_i\}$)、固有ベクトル $\{\mathbf{v}_i\}$ を解くことに他ならない。

U, Sを求める

同様にして、**U**については、 $\mathbf{A}^T\mathbf{A}$ を計算すると、

$$\mathbf{A}^T \mathbf{A} = (\mathbf{V}\mathbf{S}\mathbf{U}^T)^T \mathbf{V}\mathbf{S}\mathbf{U}^T = \mathbf{U}\mathbf{S}_N^2 \mathbf{U}^T \quad (6)$$

両辺に右から**U**を掛ければ、

$$(\mathbf{A}^T \mathbf{A})\mathbf{U} = \mathbf{U}\mathbf{S}_N^2 \quad (7)$$

別の表現で書くと、

$$(\mathbf{A}\mathbf{A}^T)\mathbf{u}_i = \lambda_i^2 \mathbf{u}_i \quad (8)$$

これは、 $\mathbf{A}^T\mathbf{A}$ の固有値 $\{\lambda\}$ 、固有ベクトル $\{\mathbf{u}_i\}$ を解くことに他ならない。

$\mathbf{u}_i, \mathbf{v}_i, \lambda_i$ 間の関係

$$\mathbf{A} = \sum_{i=1}^R \lambda_i \mathbf{v}_i \mathbf{u}_i^T \quad (2)$$

両辺に右から $\mathbf{u}_k, k=1, \dots, R$ を掛ければ、 $\mathbf{u}_k, k=1, \dots, R$ の正規直交性より、

$$\mathbf{A} \mathbf{u}_k = \sum_{i=1}^R \lambda_i \mathbf{v}_i \mathbf{u}_i^T \mathbf{u}_k = \lambda_k \mathbf{v}_k \mathbf{u}_k^T \mathbf{u}_k = \lambda_k \mathbf{v}_k$$

すなわち

$$\mathbf{A} \mathbf{u}_k = \lambda_k \mathbf{v}_k \quad \text{または} \quad \mathbf{v}_k = \frac{1}{\lambda_k} \mathbf{A} \mathbf{u}_k \quad (9)$$

上式により、 $\mathbf{u}_k, \mathbf{v}_k, \lambda_k, k=1, \dots, R$ が関係づけられる。

同様に、式(2)の両辺を転置した後に右から、 \mathbf{v}_k を掛ければ

$$\mathbf{A}^T \mathbf{v}_k = \lambda_k \mathbf{u}_k \quad \text{または} \quad \mathbf{u}_k = \frac{1}{\lambda_k} \mathbf{A} \mathbf{v}_k \quad (10)$$

SVDの利用法1：主成分分析を効率よく計算

いま、画素数 $M=10,000$ の画像データを列ベクトルで表し、これが $N=100$ 枚分、100列のデータとして A に入っているとす。すなわち、 A は $10,000 \times 100$ の行列。

100枚の画像データの固有ベクトル（固有パターン）を算出する問題を考える。

この問題は、以下の式により固有ベクトルを求めることに相当する（実際には平均ベクトルを差し引く前処理は必要）

$$(\mathbf{A}\mathbf{A}^T)\mathbf{v}_i = \lambda_i^2 \mathbf{v}_i \quad (5)$$

しかし $\mathbf{A}\mathbf{A}^T$ は $10,000 \times 10,000$ の行列であり、その固有値問題を解くことは困難。一方、

$$(\mathbf{A}^T \mathbf{A})\mathbf{u}_i = \lambda_i^2 \mathbf{u}_i \quad (8)$$

は 100×100 の行列であり、その固有値問題を解くことは可能。それができれば、前ページ式(9)に、得られた $\mathbf{u}_k, \lambda_k, k=1, \dots, R$ を代入することで $\mathbf{v}_k, k=1, \dots, R$ が求まる。

SVDの利用法2：システムの伝達関数を評価

線形システムの行列による表現：たとえばCT再構成問題

$$\mathbf{g} = \mathbf{A}\mathbf{f} + \mathbf{n} \quad (12)$$

得られる画像 \mathbf{g} ← 撮像システム \mathbf{A} ← 物体空間 \mathbf{f} ← ノイズ \mathbf{n}

$$\mathbf{g} = \mathbf{A}\mathbf{f} + \mathbf{n}$$

$$\begin{bmatrix} g_1 \\ g_2 \\ \vdots \\ g_M \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1N} \\ a_{21} & a_{22} & \cdots & a_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ a_{M1} & a_{M2} & \cdots & a_{MN} \end{bmatrix} \begin{bmatrix} f_1 \\ f_2 \\ \vdots \\ f_N \end{bmatrix} + \begin{bmatrix} n_1 \\ n_2 \\ \vdots \\ n_N \end{bmatrix}$$

物体空間と像空間、それぞれを張る基底

ここでは $M < N$ の場合を考える


$$\mathbf{g} = \mathbf{A}\mathbf{f} + \mathbf{n} \quad (12)$$

像空間
物体空間

$$\text{式(9)は } \lambda_k \mathbf{v}_k = \mathbf{A}\mathbf{u}_k$$

$\mathbf{v}_k, k=1, \dots, R$ は像空間を張る基底ベクトルと考えられる。

$\mathbf{u}_k, k=1, \dots, R$ は物体空間を張る基底ベクトルと考えられる。



λはシステムの伝達関数

ここでは $M < N$ の場合を考える

$$\underbrace{\mathbf{g}}_{\text{像空間}} = \mathbf{A} \underbrace{\mathbf{f}}_{\text{物体空間}} + \mathbf{n} \quad (12)$$

式(9)は $\lambda_k \mathbf{v}_k = \mathbf{A} \mathbf{u}_k$

$$\mathbf{f} = \sum_{i=1}^N \alpha_i \mathbf{u}_i, \mathbf{g} = \sum_{i=1}^M \beta_i \mathbf{v}_i, \mathbf{n} = \sum_{i=1}^M \gamma_i \mathbf{v}_i \quad \text{と展開すると、式(12)は}$$

$$\sum_{i=1}^M \beta_i \mathbf{v}_i = \mathbf{A} \sum_{i=1}^N \alpha_i \mathbf{u}_i + \sum_{i=1}^M \gamma_i \mathbf{v}_i = \sum_{i=1}^N \lambda_i \alpha_i \mathbf{v}_i + \sum_{i=1}^M \gamma_i \mathbf{v}_i \quad (13)$$

同じベクトルの項どうしを比較すると、式(13)は以下のようなになる。

$$\underbrace{\beta_i}_{\text{像側の成分}} = \underbrace{\lambda_i}_{\text{伝達特性}} \underbrace{\alpha_i}_{\text{物体側の成分}} + \underbrace{\gamma_i}_{\text{ノイズ成分}}$$

こう考えればλはシステムの伝達関数を表していることがわかる、

物体空間（吸収係数分布）と投影データとの関係を線形方程式で記述する。

$$\mathbf{g} = \mathbf{H}\mathbf{f} \iff \begin{bmatrix} g_1 \\ g_2 \\ \vdots \\ g_m \end{bmatrix} = \begin{bmatrix} h_{11} & h_{12} & \cdots & h_{1n} \\ h_{21} & h_{22} & \cdots & h_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ h_{m1} & h_{m2} & \cdots & h_{mn} \end{bmatrix} \begin{bmatrix} f_1 \\ f_2 \\ \vdots \\ f_n \end{bmatrix} \quad (11)$$

1方向だけでなく、
全方向の投影
データを1列にし
たもの。

システム行列

吸収係数分布を
1列にしたもの

