

Def. 1. Mówimy, że macierz symetryczna S jest *dodatnio półokreślona*, gdy dla dowolnego wektora x zachodzi $x^T S x \geq 0$, a *dodatnio określona*, gdy dla dowolnego niezerowego x zachodzi $x^T S x > 0$.

Uwaga 1. Wyrażenie $x^T S x$ nazywane jest *formą kwadratową* o macierzy S . Pojęcia dodatniej określoności i półokreśloności przenosimy z macierzy S na jej formę kwadratową.

Twierdzenie 1. *Macierz symetryczna jest dodatnio określona wtedy i tylko wtedy, gdy ma dodatnie wartości własne.*

Twierdzenie 2. *(x, y) jest iloczynem skalarnym w \mathbb{R}^n wtedy i tylko wtedy, gdy $(x, y) = x^T S y$ dla pewnej dodatnio określonej symetrycznej macierzy S .*

Kryterium Sylwestera

Twierdzenie 3 (Sylwestera). *Macierz symetryczna S stopnia n jest dodatnio określona wtedy i tylko wtedy, gdy wszystkie jej początkowe minory główne M_1, M_2, \dots, M_n są dodatnie.*

Przykład 1. Sprawdzić, które z macierzy symetrycznych są dodatnio określone:

$$\begin{bmatrix} 3 & 2 \\ 2 & 2 \end{bmatrix}, \begin{bmatrix} 2 & 3 \\ 3 & 3 \end{bmatrix}, \begin{bmatrix} 1 & 2 & 3 \\ 2 & 5 & 4 \\ 3 & 4 & 15 \end{bmatrix}, \begin{bmatrix} 2 & 1 & 0 & 0 \\ 1 & 2 & 1 & 0 \\ 0 & 1 & 2 & 1 \\ 0 & 0 & 1 & 2 \end{bmatrix}.$$

Fakt 4. *W macierzu U rozkładu $A = LU$ symetrycznej macierzy dodatnio określonej A elementy główne $[U]_{ii}$ są dodatnie, $[U]_{11} = M_1$ i $[U]_{ii} = \frac{M_i}{M_{i-1}}$ dla $i > 1$.*

Rozkład Choleskiego $S = A^T A$, gdzie A jest trójkątna górna

1. W rozkładzie $S = LU$ dodatnio określonej macierzy symetrycznej S elementy główne macierzy U są dodatnie.
2. Tworzymy z nich macierz diagonalną D zachowując kolejność.
3. Z symetrii macierzy S wynika $S = LU = LDL^T$.
4. Wyznaczamy taką macierz \sqrt{D} , że $\sqrt{D} \cdot \sqrt{D} = D$ (pierwiastkując wyrazy macierzy D) i stąd $S = L\sqrt{D}\sqrt{D}L^T$.
5. Przyjmując $A = \sqrt{D}L^T$ dostajemy rozkład Choleskiego

$$S = A^T A$$

z pierwiastkami elementów głównych macierzy U na głównej przekątnej macierzy A .

Przykład 2. Wyznaczyć rozkłady Choleskiego macierzy $\begin{bmatrix} 3 & 2 \\ 2 & 2 \end{bmatrix}$ i $\begin{bmatrix} 1 & 1 & 1 \\ 1 & 10 & 7 \\ 1 & 7 & 9 \end{bmatrix}$.

Fakt 5. Dla dowolnej macierzy A (niekoniecznie kwadratowej):

1. macierz $A^T A$ jest dodatnio półokreśloną macierzą symetryczną,
2. $r(A^T A) = r(AA^T) = rA = rA^T$,
3. niezerowe wartości własne macierzy AA^T i $A^T A$ są takie same.

Uwaga 2. Nie zawsze dla macierzy rzędu r rząd ich iloczynu jest równy r tak, jak w przypadku $A^T A$.

Fakt 6. Jeśli A jest $(m \times r)$ macierzą rzędu r i B jest $(r \times n)$ macierzą rzędu r , to AB ma również rząd r .

SVD - Singular Value Decomposition

Dla dowolnej macierzy $A \in \mathbf{M}_{m \times n}$ rzędu r szukamy takich liczb $\sigma_1, \sigma_2, \dots, \sigma_r$ spełniających warunek $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_r > 0$ oraz takich ortonormalnych baz $\{v_1, v_2, \dots, v_n\}$ przestrzeni \mathbb{R}^n i $\{u_1, u_2, \dots, u_m\}$ przestrzeni \mathbb{R}^m , że

$$Av_1 = \sigma_1 u_1, \dots, Av_r = \sigma_r u_r, \quad Av_{r+1} = 0, \dots, Av_n = 0.$$

Warunek zapisuje się macierzowo:

$$AV = U\Sigma$$

$$A \begin{bmatrix} v_1 & v_2 & \dots & v_n \end{bmatrix} = \begin{bmatrix} u_1 & u_2 & \dots & u_m \end{bmatrix} \left[\begin{array}{ccc|c} \sigma_1 & & & 0 \\ & \ddots & & \\ & & \sigma_r & \\ \hline & & & 0 \end{array} \right]$$

Liczby $\sigma_1, \sigma_2, \dots, \sigma_r$ nazywamy *wartościami osobliwymi (szczególnymi)* (ang. *singular*), u_1, u_2, \dots, u_m - *lewostronnymi*, a v_1, v_2, \dots, v_n - *prawostronnymi wektorami osobliwymi (szczególnymi)*. Macierze V i U są macierzami ortogonalnymi stopnia n i m odpowiednio. Macierz Σ ma ten sam wymiar co A (na ogół nie jest kwadratowa!) i jest uogólnieniem macierzy diagonalnej. Równość $AV = U\Sigma$ jest równoważna równości

$$A = U\Sigma V^T,$$

którą nazywamy SVD *rozkładem według wartości osobliwych (szczególnych)*.

Twierdzenie 7. Dla dowolnej macierzy A istnieje SVD.

Sposób wyznaczania SVD

1. Za prawostronne wektory osobliwe v_i dla $n \leq r$ przyjmujemy unormowane wektory własne macierzy $A^T A$ uporządkowane od największej wartości własnej λ_1 do najmniejszej niezerowej λ_r .
2. Wyznaczamy wartości osobliwe $\sigma_i = \sqrt{\lambda_i}$ dla $i = 1, 2, \dots, r$.
3. Lewostronne wektory u_i są unormowanymi obrazami wektorów v_i w przekształceniu liniowym o macierzy A dla $i = 1, 2, \dots, r$. Zachodzi przy tym $u_i = \frac{Av_i}{\sigma_i}$.
4. Dla $n > r$ i $m > r$ za pozostałe v_i i u_i bierzemy wektory z ortonormalnych baz przestrzeni zerowej macierzy A i odpowiednio A^T .

Przykład 3. Wyznaczyć SVD macierzy $A = \begin{bmatrix} 3 & 2 \\ 2 & 3 \\ 2 & -2 \end{bmatrix}$.

Rozkład na sumę macierzy rzędu 1

Wn. 1. Jeśli $\sigma_1, \sigma_2, \dots, \sigma_r$ są wartościami osobliwymi, u_1, u_2, \dots, u_m lewostronnymi, a v_1, v_2, \dots, v_n prawostronnymi wektorami osobliwymi rozkładu SVD macierzy A to:

$$A = \sum_{i=1}^r \sigma_i u_i v_i^T = \sigma_1 u_1 v_1^T + \sigma_2 u_2 v_2^T + \dots + \sigma_r u_r v_r^T.$$

Przykład 4. Wyznaczyć rozkład macierzy z przykładu 3 na sumę macierzy rzędu 1.

Zredukowana forma SVD

Jeśli

$$A = \begin{bmatrix} u_1 & u_2 & \dots & u_m \end{bmatrix} \left[\begin{array}{ccc|c} \sigma_1 & & & 0 \\ & \ddots & & \\ & & \sigma_r & \\ \hline & & & 0 \end{array} \right] \begin{bmatrix} v_1 & v_2 & \dots & v_n \end{bmatrix}^T,$$

to również

$$\begin{bmatrix} u_1 & u_2 & \dots & u_r \end{bmatrix} \begin{bmatrix} \sigma_1 & & & \\ & \ddots & & \\ & & \sigma_r & \end{bmatrix} \begin{bmatrix} v_1 & v_2 & \dots & v_r \end{bmatrix}^T = U_r \Sigma_r V_r^T.$$

Ten drugi rozkład macierzy A nazywamy *zredukowaną formą SVD*. Macierze $U_r \in M_{m \times r}$ i $V_r \in M_{n \times r}$ nie są ortogonalne, natomiast macierz Σ_r jest macierzą diagonalną.

Uwagi dotyczące SVD

1. Jeśli $A = U\Sigma V^T$, to $A^T = V\Sigma^T U^T$ i można znaleźć SVD macierzy A^T zamiast A i wynik przetransponować. Warto tak zrobić, gdy A ma więcej kolumn niż wierszy.
2. Rozkład SVD istnieje dla dowolnej macierzy A podczas, gdy rozkład $A = P\Lambda P^{-1}$ tylko dla macierzy kwadratowej, która ma bazę wektorów własnych.
3. SVD dodatnio półokreślonej symetrycznej macierzy A pokrywa się z rozkładem $A = Q\Lambda Q^T$, gdzie $U = V = Q$ i $\Sigma = \Lambda$.
4. Jeśli macierz symetryczna ma ujemną wartość własną λ_i , w rozkładzie $A = Q\Lambda Q^T$, to wystarczy w SVD wziąć $\sigma_i = -\lambda_i$ i jeden z wektorów osobliwych u_i albo v_i zastąpić wektorem przeciwnym.
5. Jeśli $A = xy^T$ jest macierzą rzędu 1, to $u_1 = \frac{x}{\|x\|}$, $v_1 = \frac{y}{\|y\|}$ i $\sigma_1 = \|x\| \cdot \|y\|$.

Norma spektralna macierzy

Def. 2. Normą spektralną macierzy $A \in \mathbf{M}_{m \times n}$ nazywamy

$$\|A\| := \max\left\{\frac{\|Ax\|}{\|x\|} : x \in E^n\right\}.$$

Lemat 8. Niech $\lambda_1 > 0$ będzie największą wartością własną dodatnio półokreślonej macierzy symetrycznej S . Wówczas największą wartością wyrażenia $\frac{x^T S x}{x^T x}$ jest λ_1 .

Wn. 2. Normą spektralną macierzy A jest równa jej największej wartości osobliwej σ_1 .

Twierdzenie 9 (Eckarta-Younga). Niech $A, B \in \mathbf{M}_{m \times n}$,

$$A = \sigma_1 u_1 v_1^T + \sigma_2 u_2 v_2^T + \dots + \sigma_r u_r v_r^T,$$

$$A_k = \sigma_1 u_1 v_1^T + \sigma_2 u_2 v_2^T + \dots + \sigma_k u_k v_k^T$$

dla każdego $k \in \{1, 2, \dots, r\}$ i $rB \leq k$. Wówczas

$$\|A - B\| \geq \|A - A_k\| = \sigma_{k+1}.$$

Zastosowania do redukcji zbioru danych

Twierdzenie Eckarta-Younga określa błąd przybliżenia dowolnej macierzy (wysokiego) rzędu r najlepszą z możliwych macierzy (niskiego) rzędu k . Macierzą tą jest suma pierwszych k składników, które odpowiadają największym wartościom osobliwym, a błąd wynosi σ_{k+1} . Pakiet danych zawartych w r -wymiarowej przestrzeni rzutujemy na najlepszą (minimalizującą błąd) podprzestrzeń k -wymiarową.

Przykład 5. Typowe czarno-białe zdjęcie w zapisie cyfrowym to macierz 2064×3088 . Oryginalny obraz wymaga zapamiętania $2064 \times 3088 = 6373632$ liczb. Jeśli ograniczymy się np. do sześciu pierwszych składowych, to wystarczy zapamiętać sześć wartości osobliwych oraz odpowiadających im lewych i prawych wektorów osobliwych. Daje to w sumie $6 \times (1 + 2064 + 3088) = 30918$ liczb do zapamiętania, czyli mniej niż 0,5% oryginalnego rozmiaru zdjęcia.

Wprowadzenie do PCA

Przykład 6. 1. Na płaszczyźnie dane są punkty $(-4, -1)$, $(-1, -2)$, $(2, 0)$, $(3, 3)$. Znaleźć taką prostą $y = ax$, dla której suma kwadratów odległości od tych punktów będzie najmniejsza.

2. Dla danych wektorów $\begin{bmatrix} -4 \\ -1 \end{bmatrix}$, $\begin{bmatrix} -1 \\ -2 \end{bmatrix}$, $\begin{bmatrix} 2 \\ 0 \end{bmatrix}$, $\begin{bmatrix} 3 \\ 3 \end{bmatrix}$ znaleźć najbliższą im podprzestrzeń jednowymiarową.

3. Znaleźć najlepsze przybliżenie macierzy $A = \begin{bmatrix} -4 & -1 & 2 & 3 \\ -1 & -2 & 0 & 3 \end{bmatrix}$ macierzą rzędu 1.

Odp. Otrzymana metodą SVD podprzestrzeń $\text{lin} \begin{bmatrix} 5 \\ 3 \end{bmatrix}$ generowana przez pierwszy wektor osobliwy u_1 rozkładu SVD macierzy A (czyli prosta $y = 0,6x$) spełnia rządzany warunek.

Uwaga 3. Znaleziona metodą SVD prosta nie pokrywa się z prostą regresji znalezionej metodą najmniejszych kwadratów, która w tym samym przykładzie ma równanie $y = 0,5x$. Zastosowanie SVD w tym problemie nazywane bywa *ortogonalną metodą najmniejszych kwadratów* (ang. *perpendicular least squares*).

Uwaga 4. Dane w przykładzie są uśrednione (tzn. średnie każdego wiersza macierzy A są równe 0). Przy tym założeniu symetryczna macierz $S = \frac{1}{n}AA^T$ jest tzw. *macierzą kowariancji*. Jej wyrazy głównej przekątnej $[S]_{11}$ i $[S]_{22}$ są miarami rozrzutu (wariancjami) danych poszczególnych wierszy, a wyraz drugiej przekątnej $[S]_{12} = [S]_{21}$ to tzw. *kowariancja*, która jest miarą zależności liniowej pomiędzy danymi z pierwszego i drugiego wiersza.

- Jeśli każdy wektor a_i danych (kolumnę macierzy A) przedstawimy w postaci kombinacji wektorów bazy ortonormalnej $\{u_1, u_2\}$, $a_i = \alpha_i u_1 + \beta_i u_2$, to

$$\sum_{i=1}^4 \|a_i\|^2 = \sum_{i=1}^4 \alpha_i^2 + \sum_{i=1}^4 \beta_i^2.$$

Ponieważ lewa strona jest ustalona (przez macierz danych), więc maksymalizując pierwszą sumę po prawej stronie jednocześnie minimalizujemy drugą.

- Metoda SVD daje maksymalną wariancję danych na prostej i minimalną sumę kwadratów odchyleń od prostej.
- Metoda SVD wykorzystywana jest w *analizie głównych składowych* (ang. *Principal Component Analysis*) (skrót PCA). PCA wykorzystuje metody algebry liniowej, statystyki i analizy matematycznej do redukcji wymiaru przestrzeni danych.