

Positivně (semi)definitní matice

$A \in \mathbb{R}^{n \times n}$ symetrická

• A je positivně semidefinitní pokud $[PSD]$
 $(\forall x \in \mathbb{R}^n) (x^T A x \geq 0)$

• A je positivně definitní pokud $[PD]$
 $(\forall 0 \neq x \in \mathbb{R}^n) (x^T A x > 0)$

⊗ Dává smysl i pro ^{čvercové} nesymetrické matice, ale podmínka se redukuje na symetrický případ:

$$x^T A x = \frac{1}{2} x^T A x + \left(\frac{1}{2} x^T A x \right)^T = \frac{1}{2} x^T A x + \frac{1}{2} x^T A^T x = x^T \frac{1}{2} (A + A^T) x$$

Matice $\frac{1}{2} (A + A^T)$ je symetrická.

pozorování Pozitivně Semidefinitní

matice má nezápornou diagonálu,
pozitivně definitní matice má kladnou
diagonálu.

Důkaz $e_i = (0 \dots 0 \underset{i}{1} 0 \dots 0)^T$

$$e_i^T A e_i = a_{ii} \geq 0 \quad \square$$

Věta

- (1) A, B jsou PD potom $A+B$ je PD
- (2) A je PD a $d > 0$ potom dA je PD
- (3) A je PD potom A je regulární a A^{-1} je PD.

Důkaz (1), (2) z definice

$$(3) \quad Ax = 0 \text{ pak } x^T Ax = x^T 0 = 0$$

Pak nutně $x = 0$ protože A je PD.

$\Rightarrow A$ regulární tedyž $\det A \neq 0$ a
 A^{-1} existuje a je regulární.

Nechť $x \neq 0$:

$$x^T \tilde{A}^{-1} x = x^T \tilde{A}^{-1} A \tilde{A}^{-1} x = y^T A y \text{ pro}$$

$$y = \tilde{A}^{-1} x \neq 0 \text{ a tudíž } x^T \tilde{A}^{-1} x > 0.$$



Doma: použila se symetrie A ?

-
- Analogie (1), (2) platí i pro PSD matice ale ne (3) protože PSD matice může být singularní (nepř. 0).
-

Věta $A \in \mathbb{R}^{n \times n}$ symetrická. Pak je ekv.

(1) A je PD

(2) vlastní čísla A jsou kladná

(3) existuje matice $U \in \mathbb{R}^{n \times n}$ hodnosti n taková že $A = U^T U$.

[Choleského dekompozice]

Důkaz

$$(1) \Rightarrow (2) \quad Ax = \lambda x, \quad \|x\|_2 = 1 \quad \Rightarrow$$

$$x^T Ax = \lambda x^T x = \lambda \quad \Rightarrow \quad \lambda > 0.$$

[λ vlastní číslo, x vlastní vektor]

(2) \Rightarrow (3) A symetrická a kladná
má **spektrální rozklad** QLQ^T kde
 L je diagonální matice s prvky
 $\lambda_1, \dots, \lambda_n > 0$.

Definujeme matici L' jako diagonální
s prvky $\sqrt{\lambda_1}, \dots, \sqrt{\lambda_n} > 0$. Potom
hledaná matice je $U = L'Q^T$:

$$U^T U = Q L' L' Q^T = Q L'^2 Q^T = Q L Q^T = A.$$

* U je regulární a má sudý hodnost n
neboť je součinem regulárních matic.

(3) \Rightarrow (1) $x \neq 0 \Rightarrow x^T Ax = x^T U^T U x =$
 $(Ux)^T Ux = \|Ux\|_2^2 > 0$ protože sloupce U
jsou lineárně nezávislé. \square

Věta $A \in \mathbb{R}^{m \times m}$ symetrická, je ekv.:

(1) A je PSD

(2) vlastní čísla A jsou nezáporná

(3) existuje matice $U \in \mathbb{R}^{m \times m}$, $A = U^T U$.

Důkaz podobný jako pro PD. choleského
dekompozice

Příklad Gramova matice $G \in \mathbb{R}^{m \times m}$

$\{w_1, \dots, w_m\}$ je generátor podprostoru U

pak $G_{ij} \stackrel{\text{def}}{=} \langle w_i, w_j \rangle$ [skalární součin]

$$x \in \mathbb{R}^m \Rightarrow x^T G x = \sum_{i=1}^m \sum_{j=1}^m x_i x_j \langle w_i, w_j \rangle =$$

$$\left\langle \sum_{i=1}^m x_i w_i, \sum_{j=1}^m x_j w_j \right\rangle \geq 0.$$

$\{w_1, \dots, w_m\}$ je báze $U \Rightarrow G$ je PD. (Poví?)

Nechť $A \in \mathbb{R}^{n \times n}$ je symetrická.


Řekneme že A' je hlavní podmatice, jestliže A' vznikne z A odstraněním podmnožiny řádků a sloupců s stejnými indexy. \rightarrow i prázdno

Lemma • A je PD právě když každá hlavní podmatice je PD.

• A je PSD právě když každá hlavní podmatice je PSD.


Důkaz \Leftarrow jasné pro oba případy

\Rightarrow (pro PSD, pro PD stejně)



$$x^T A' x = z^T A z \text{ kde}$$

$$z = \begin{pmatrix} 0 \\ \vdots \\ 0 \\ x \\ 0 \\ \vdots \\ 0 \end{pmatrix}$$



TESTOVÁNÍ PD

Věta A symmetrická $A = \begin{pmatrix} d & a^T \\ a & \tilde{A} \end{pmatrix}$
 $d \in \mathbb{R}$, $a \in \mathbb{R}^{n-1}$, $\tilde{A} \in \mathbb{R}^{(n-1) \times (n-1)}$. A je PD

\Leftrightarrow

$d > 0$, $\tilde{A} - \frac{1}{d} a a^T$ je PD

Důkaz

\Rightarrow : $d = e_1^T A e_1 > 0$. Necht $\tilde{x} \in \mathbb{R}^{n-1}$, $\tilde{x} \neq 0$:

$$\tilde{x}^T \left(\tilde{A} - \frac{1}{d} a a^T \right) \tilde{x} =$$

$$\tilde{x}^T \tilde{A} \tilde{x} - \frac{1}{d} (a^T \tilde{x})^2 =$$

$$\begin{pmatrix} -\frac{1}{d} a^T \tilde{x} & \tilde{x}^T \end{pmatrix} \begin{pmatrix} d & a^T \\ a & \tilde{A} \end{pmatrix} \begin{pmatrix} -\frac{1}{d} a^T \tilde{x} \\ \tilde{x} \end{pmatrix} > 0.$$

\Leftarrow : $x = \begin{pmatrix} \beta \\ \tilde{x} \end{pmatrix} \in \mathbb{R}^n$. Pakom

$$x^T A x = \begin{pmatrix} \beta & \tilde{x}^T \end{pmatrix} \begin{pmatrix} d & a^T \\ a & \tilde{A} \end{pmatrix} \begin{pmatrix} \beta \\ \tilde{x} \end{pmatrix} = d\beta^2 + 2\beta \overbrace{a^T \tilde{x}}^{\tilde{x}^T \tilde{A} \tilde{x}} +$$

$$= \tilde{x}^T \left(\tilde{A} - \frac{1}{d} a a^T \right) \tilde{x} + \left(\sqrt{d} \beta + \frac{1}{\sqrt{d}} a^T \tilde{x} \right)^2 \geq 0$$

a rovnost jen pro $\tilde{x} = 0$ a $\beta = 0$.



TESTOVÁNÍ PSD

Věta A symetrická $A = \begin{pmatrix} \lambda & a^T \\ a & \tilde{A} \end{pmatrix}$
 $\lambda \in \mathbb{R}$, $a \in \mathbb{R}^{n-1}$, $\tilde{A} \in \mathbb{R}^{(n-1) \times (n-1)}$. A je PSD

\Leftrightarrow

(1) $\lambda > 0$, $\tilde{A} - \frac{1}{\lambda} a a^T$ je PSD nebo

(2) $\lambda = 0$, $a = 0$ a \tilde{A} je PSD.

Důkaz

Jestli $\lambda > 0$ postupujeme stejně jako v předchozím důkazu.

Necht' $\lambda = 0$.

\Rightarrow : z lemma dostaneme že $a = 0$
protože matice 2×2 $\begin{pmatrix} \lambda & a^T \\ a & \tilde{A} \end{pmatrix}$ v

$\begin{pmatrix} 0 & a \\ a & \tilde{A} \end{pmatrix}$ pro $0 \neq a \in \mathbb{R}$ není PSD.

Indice: \tilde{A} je PSD.

\Leftarrow : z definice protože předp. že

$$A = \begin{pmatrix} 0 & \dots & 0 \\ \vdots & \tilde{A} & \\ 0 & & \end{pmatrix}.$$



Tyto věty dávají

Polynomiální rekursivní
algoritmus na testování

PD, PSD.

Příklad

$$A = \begin{pmatrix} 4 & -2 & 4 \\ -2 & 10 & 1 \\ 4 & 1 & 6 \end{pmatrix}$$

$$\alpha = 4$$

$$a^T = (-2 \ 4)$$

$$\tilde{A} = \begin{pmatrix} 10 & 1 \\ 1 & 6 \end{pmatrix}$$

$$\tilde{A} - \frac{1}{\alpha} a a^T = \begin{pmatrix} 10 & 1 \\ 1 & 6 \end{pmatrix} - \frac{1}{4} \begin{pmatrix} -2 \\ 4 \end{pmatrix} \begin{pmatrix} -2 & 4 \end{pmatrix} = \begin{pmatrix} 9 & 3 \\ 3 & 2 \end{pmatrix}$$

V další iteraci dostaneme matici 1×1 .

Stejně rekursivně se dostane i

Choleského dekompozice pro PD a PSD.

POZOR! lze najít jen **APROXIMACI**

už pro $n = 1$: $\sqrt{2}$ "nerozumně" přesně.

Explicitní Choleského Dekompozice

Věta $A \in \mathbb{R}^{n \times n}$ PD. Pakom $A = LL^T$ kde

L je dolní trojúhelníková s kladnou diagonálou a pro $A = \begin{pmatrix} d & a^T \\ a & \tilde{A} \end{pmatrix}$ je

$$L = \begin{pmatrix} \sqrt{d} & 0^T \\ 1/\sqrt{d} a & \tilde{L} \end{pmatrix} \text{ kde nekorrivně } \tilde{L}$$

je rozkladová matice pro PD matici

$$\tilde{A} - 1/d a a^T.$$

Věta $A \in \mathbb{R}^{n \times n}$ PSD. Pakom $A = LL^T$ kde

L je dolní trojúhelníková s nezápornou diagonálou.

Pro $A = \begin{pmatrix} d & a^T \\ a & \tilde{A} \end{pmatrix}$ je

$$L = \begin{pmatrix} \sqrt{d} & 0^T \\ 1/\sqrt{d} a & \tilde{L} \end{pmatrix} \text{ kde nekorrivně } \tilde{L}$$

je rozkladová matice pro PSD matici

$$\tilde{A} - 1/d a a^T.$$

• Pro $A = \begin{pmatrix} d & a^T \\ a & \tilde{A} \end{pmatrix}$ je $L = \begin{pmatrix} 1 & 0 \\ 0 & \tilde{L} \end{pmatrix}$ kde \tilde{L} je rozkladová matice pro PSD matici \tilde{A} .

FAKT Choleského rozklad PD matic je jednoznačný; to nutně neplatí pro PSD matice.

Pozorování (předchozí věta a Gaussova Elim.)

$$A = \begin{pmatrix} d & a^T \\ a & \tilde{A} \end{pmatrix}, \quad d > 0 \text{ a provedeme jeden krok GA}$$

Dostaneme matici

$$\begin{pmatrix} d & a^T \\ 0 & \tilde{A} - \frac{1}{d} a a^T \end{pmatrix} \quad \text{To vede k:}$$

Věta* A symetrická je PD právě tehdy když ji Gaussova Eliminace (GE) převede do odstupňovaného tvaru s kladnou diagonálou za použití jediného typu el. úprav:
přičtení ^{násobku} řádku s pivotem k jinému řádku pod ním.

Důkaz. \Rightarrow : úvaha nad větou

\Leftarrow : necht' GA funguje jak popsáno. Nejprve dostaneme (po 1. kroku GE) tvar

$$\begin{pmatrix} d & a^T \\ 0 & \tilde{A} - \frac{1}{d} a a^T \end{pmatrix}, \quad d > 0.$$

Indukcí můžeme předpokládat, že matice $\tilde{A} - \frac{1}{d} a a^T$ je PD. A tudíž A je PD. \square

Příklad $A =$

$$\begin{pmatrix} 4 & -2 & 4 \\ -2 & 10 & 1 \\ 4 & 1 & 6 \end{pmatrix} \xrightarrow{GE} \begin{pmatrix} 4 & -2 & 4 \\ 0 & 9 & 3 \\ 0 & 3 & 2 \end{pmatrix} \xrightarrow{GE} \begin{pmatrix} 4 & -2 & 4 \\ 0 & 9 & 3 \\ 0 & 0 & 1 \end{pmatrix}$$

Prvky na diagonále kladné a také A je PD.

Věta (Sylvestrovo kritérium PD)

Symetrická $A \in \mathbb{R}^{n \times n}$ je PD právě tehdy když $(\forall i = 1, \dots, n)$ $(\det A_i > 0)$ kde A_i vznikne vynecháním posledních $(n-i)$ řádků a sloupců.

Důkaz.

\Rightarrow : každá A_i je PD podle lema.

Tudíž každá A_i má kladná vlastní čísla
a tudíž součin vlastních čísel = det je
kladný.

\Leftarrow : Během Gaussovy eliminace matice A
jsou všechny pivoty kladné, neboť
pokud je i -tý pivot nekladný, je
 $\det(A_i) \leq 0$. Tudíž podle věty *
je A PD.

Věta (Sylvestrovo kritérium PSD)

Symetrická $A \in \mathbb{R}^{n \times n}$ je PSD právě když
determinanty všech hlavních podmatic
jsou nezáporné.

Důkaz \Rightarrow z lemmu a faktu
že det je součin vlastních čísel.

← indukci dle n ; $n=1$ jasné.

$(n-1) \rightarrow n$ (sporem)

Nechť $\lambda < 0$ je vlastní číslo A a x je vlastní vektor λ splňující $\|x\|_2 = 1$.
pokudli ostatní vlastní čísla kladná,
je $\det A < 0$... spor

Tudíž necht' $\lambda \leq 0$ je dalším vlastním číslem A a necht' y , $\|y\|_2 = 1$ je jeho vlastní vektor.

Nyní nalezneme $\Delta \in \mathbb{R}$ tak že

$z := x + \Delta y$ má aspoň 1 složku 0,
necht' je to složka i .

Protože $x \perp y$

máme:

$$z^T A z = (x + \Delta y)^T A (x + \Delta y) =$$

$$(x + \Delta y)^T (Ax + \Delta Ay) =$$

$$(x + \Delta y)^T (\lambda x + \Delta d y) =$$

$$\lambda x^T x + \Delta^2 d y^T y = \lambda + \Delta^2 d < 0.$$

Nechť A' vznikne z A odstraněním i -tého řádku a sloupce, a

z' vznikne ze z odstraněním i -té složky. Potom


$z'^T A' z' = z^T A z < 0$, tudíž hlavní podmatice A nemá PSD.

Tudíž dle indukčního předpokladu má nějaká její hlavní podmatice

káporný determinant a tudíž

i -tá hlavní podmatice A má

káporný determinant. To je spor.



APLIKACE

Věta (Skalární součin a PD)

Operace $\langle x, y \rangle$ je skalárním součinem v \mathbb{R}^n právě když má tvar $\langle x, y \rangle = x^T A y$ pro nějakou pozitivně definitní matici $A \in \mathbb{R}^{n \times n}$.

Důkaz

\Rightarrow : Definujme $A = (a_{ij})$ předpisem

$$a_{ij} = \langle e_i, e_j \rangle. \quad A \text{ je symetrická.}$$

$$\langle x, y \rangle = \left\langle \sum_{i=1}^n x_i e_i, \sum_{j=1}^n y_j e_j \right\rangle =$$

$$\sum_{i=1}^n \sum_{j=1}^n x_i y_j \langle e_i, e_j \rangle = \sum_{i,j=1}^n x_i y_j a_{ij} = x^T A y.$$

Tudíž A musí být PD z definice skalárního součinu.

\Leftarrow : z definic.



Příklad Je $f: \mathbb{R}^3 \times \mathbb{R}^3 \rightarrow \mathbb{R}$

$$f(x, y) = x_1 y_1 - x_1 y_2 - x_2 y_1 + 7 x_2 y_2 + 3 x_2 y_3 + 3 x_3 y_2 + 2 x_3 y_3 \quad \text{skalární součin?}$$

Pišme:

$$f(x, y) = x^T \begin{pmatrix} 1 & -1 & 0 \\ -1 & 4 & 3 \\ 0 & 3 & 2 \end{pmatrix} y = x^T A y.$$

Tedy ključná přesvědčit se že matice je PD.

Věta (odmocnina matice)

A PSD \Rightarrow existuje B PSD tak že $A = B^2$.

Důkaz Necht' A má spektrální rozklad

$A = Q L Q^T$ kde $L = \text{diag}(\lambda_1, \dots, \lambda_m)$. Definujme diagonální matici $L' = \text{diag}(\sqrt{\lambda_1}, \dots, \sqrt{\lambda_m})$

a necht' $B \stackrel{\text{def}}{=} Q L' Q^T$.

Potom $B^2 = Q L' Q^T Q L' Q^T = Q L'^2 Q^T = Q L Q^T = A. \square$

PSD a optimalizace

PSD matice jsou proměnné ve velmi úspěšném zobecnění lineárního programování: **Semidefiniční Programování**

častý základ aprotimačnických algoritmů.

Semidefiniční Programování učíme s Milanem Hladíkem v navazujících přednáškách (např. Úvod do nelineární optimalizace). Zde uvedu jen příklad (nezkouší se)

SDP formulace problému MAX CUT

$G = (V, E)$ graf, $E' \subseteq E$ je MEX jestli existuje $V' \subseteq V$ tak že

$$E' = \{e \in E; |e \cap V'| = 1\}.$$



MAX-CUT Najdi maximální velikost E' .

Základní NP-úplný problém.

Nechť $V = \{1, \dots, m\}$. MAX-CUT lze zapsat:

$$\text{OPT}(G) = \max \sum_{\{i,j\} \in E} \frac{1 - x_i x_j}{2}, \quad x_i \in \{1, -1\}$$

(1) Relaxace pomocí vektorového programování

$$V(G) = \max \sum_{\{i,j\} \in E} \frac{1 - w_i^+ w_j}{2}, \quad w_i \in S = \{x \in \mathbb{R}^n; \|x\| = 1\}.$$

$$\bullet V(G) \geq \text{OPT}(G) \quad [x \in \{1, -1\} \rightarrow (0 \dots 0 x)]$$

$$\textcircled{2} \quad \text{let } x_{ij} := w_i^T w_j$$

SDP formulace ekvivalentní ke $V(G)$

$$\max \sum_{\{i,j\} \in E} \frac{1 - x_{ij}}{2} \quad ; \quad \begin{matrix} i=1, \dots, m \\ x_{ii} = 1 \end{matrix} \text{ a } X \text{ je PSD.}$$

$[X \succeq 0]$

Z teorie SDP plyne že můžeme najít (polynomiálně) PSD matici X^* :

$$\sum_{\{i,j\} \in E} \frac{1 - x_{ij}^*}{2} \geq V(G) - \epsilon \text{ pro každé } \epsilon.$$

Pro X^* můžeme aproximovat Choleského faktorizaci $X^* \doteq U^T U$.

Stoupce matice U aproximují optimální řešení $V(G)$.

Nakonec musíme sloupce U **zakroubit** na 1 nebo -1 abychom dostali aproximační řešení MAX CUT problému.