

SINGULÆRVERDI-DEKOMPOSISJON (SEC. 7.4)

Vi har lært om spektralteoremet for symmetriske matriser: Hvis en $n \times n$ matrise A er symmetrisk, dvs. hvis $A^T = A$, så finnes der en ortogonal basis $\{\vec{v}_1, \dots, \vec{v}_n\}$ for \mathbb{R}^n som består av egenvektorer til matrisen A . Desuden, kan vi skrive

$$A = UDU^T,$$

for den ortogonale matrise

$$U = (\vec{v}_1, \dots, \vec{v}_n)$$


som har vektorene $\vec{v}_1, \dots, \vec{v}_n$ som søyler, og hvor

$$D = \begin{pmatrix} \lambda_1 & & & \\ & \lambda_2 & & \\ & & \ddots & \\ & & & \lambda_n \end{pmatrix}$$

er denne diagonalmatrise som har egenverdier $\lambda_1, \dots, \lambda_n$ på diagonalen. Spektralteoremet er viktig for mange anvendelser, men det har et problem: Ikke alle matriser er symmetriske! Vi skal nu lære om singularverdi-dekomposisjonen som er en slaks spektralteorem men som gjelder for generelle $m \times n$ matriser.

MATRISER OG ELLIPSER

Vi har set eksempler av $m \times n$ matriser A , hvor enhetssfæren $\{\vec{x} \in \mathbb{R}^n : \|\vec{x}\| = 1\}$ bliver transformert til ellipsoider under transformasjonen $\vec{x} \mapsto A\vec{x}$. Men det var ikke tilfeldig! Vi kommer til at vise at for hvert $m \times n$ matrise A enhetssfæren bliver transformert til en ellipsoid under transformasjonen $\vec{x} \mapsto A\vec{x}$. For at forstå hvordan det virker er det hjelpsom at se på et konkret eksempel:



FIGUR 1. Enhetssfæren transformerer til en ellipse.


Eksempel. For matrisen

$$A = \begin{pmatrix} 4 & 11 & 14 \\ 8 & 7 & -2 \\ & & 1 \end{pmatrix},$$

bliver enhetssfæren

$$\{\vec{x} \in \mathbb{R}^3 : \|\vec{x}\| = 1\}$$

transformert til en ellipse i \mathbb{R}^2 (Se Figur 1). Husk at hvert ellipsoid i \mathbb{R}^n (eller ellipse i \mathbb{R}^2) har n akser som treffes i rette vinkler. De segmenter som går fra sentrum av en ellipsoid langs akserne til randen kælles også for *halvakser* av ellipsoiden. Se Figur 2.



FIGUR 2. Ellipsoider med deres akser (i rød). I blå har vi de så kælte halvaksler av ellipsoiden.

Hvis vi nu kommer tilbake til ellipsoider som er transformasjoner av enhetssfæren under matrisetransformasjoner så kan vi forstå følgende punkter:

- I hvilke retninger peger akser av ellipsoiden for en matrise A ?
- Hvor langt er halvaksler av ellipsoiden for en matrise A ?

Svarene på disse spørsmål henger tèt sammen med singularverdi-dekomposisjon. La oss starte med en delvis svar på den annen spørsmål.

Længden av den længste halvakse. La A være en $m \times n$ matrise. Hvis enhetssfæren i \mathbb{R}^n bliver transformert til en ellipsoid, hvordan kan vi så regne ut hvor langt den længste halvakse er? Længden av den længste halvakse svarer til

$$\max_{\vec{x} : \|\vec{x}\|=1} \|A\vec{x}\|,$$

dvs. det er den største længde av alle vektorer $A\vec{x}$ for vektorer \vec{x} på enhetssfæren. Normen $\|A\vec{x}\|$ og funksjonen $\|A\vec{x}\|^2$ er maksimert for den samme vektor \vec{x} og derfor kan vi like så godt maksimere $\|A\vec{x}\|^2$. Vi regner ut at

$$(1) \quad \|A\vec{x}\|_2^2 = \langle A\vec{x}, A\vec{x} \rangle = \langle \vec{x}, A^T A \vec{x} \rangle.$$

Det er måske ikke helt åbenlyst hvordan man maksimerer denne funksjon over alle \vec{x} i enhetssfæren men vi kan i første omgang bruke spektralteoremet for at gjør funksjonen lidt nemmer. Husk at der finnes en ortogonale $n \times n$ matrise U og en $n \times n$ diagonalmatrise D slik at

$$A^T A = U D U^T.$$

Vi har også set at D har formen

$$D = \begin{pmatrix} \lambda_1 & & & \\ & \lambda_2 & & \\ & & \ddots & \\ & & & \lambda_n \end{pmatrix},$$

hvor $\lambda_1, \dots, \lambda_n$ er egenverdiene av matrise $A^T A$, og hvor vi kan anta at

$$\lambda_1 \geq \dots \geq \lambda_n.$$

La oss nu simplificere funksjonen fra (1). Vi har

$$\|A\vec{x}\|^2 = \langle \vec{x}, A^T A \vec{x} \rangle = \langle \vec{x}, U D U^T \vec{x} \rangle = \langle U^T \vec{x}, D U^T \vec{x} \rangle.$$

Hvis vi maksimerer denne funksjon kan vi bruke at transformasjonen $\vec{x} \mapsto U^T \vec{x}$ transformerer enhetssfæren til sigselv. Derfor har vi

$$\max_{\vec{x}: \|\vec{x}\|=1} \|A\vec{x}\|^2 = \max_{\vec{x}: \|\vec{x}\|=1} \langle U^T \vec{x}, D U^T \vec{x} \rangle = \max_{\vec{y}: \|\vec{y}\|=1} \langle \vec{y}, D \vec{y} \rangle,$$

hvor vi har skiftet variabler til $\vec{y} = U^T \vec{x}$. Til sist ser vi at

$$\max_{\vec{x}: \|\vec{x}\|=1} \|A\vec{x}\|^2 = \max_{\vec{y}: \|\vec{y}\|=1} \langle \vec{y}, D \vec{y} \rangle = \max_{\vec{y}: \|\vec{y}\|=1} (\lambda_1 y_1^2 + \dots + \lambda_n y_n^2).$$

Bemerk at vi maksimerer over alle indganger y_1, \dots, y_n slik at

$$y_1^2 + \dots + y_n^2 = 1.$$

Derfor har vi

$$\max_{\vec{x}: \|\vec{x}\|=1} \|A\vec{x}\|^2 = \max_{\vec{y}: \|\vec{y}\|=1} (\lambda_1 y_1^2 + \dots + \lambda_n y_n^2) = \lambda_1,$$

og vi konkluderer at lengden av den lengste halvakse er

$$\max_{\vec{x}: \|\vec{x}\|=1} \|A\vec{x}\| = \sqrt{\lambda_1}.$$

Hvilken vektor \vec{x} med $\|\vec{x}\| = 1$ maksimerer funksjonen $\|A\vec{x}\|^2$? Det er nu nemt at regne ut. Vi ser at $\vec{y} = \vec{e}_1$ maksimerer funksjonen etter koordinateskift $\vec{y} = U^T \vec{x}$. Derfor finner vi at $\vec{x} = U\vec{y} = U\vec{e}_1$ maksimerer $\|A\vec{x}\|^2$ over enhetssfæren. Men $\vec{x} = U\vec{e}_1$ er jo den første søyle av U som er egenvektoren av den symmetriske matrise $A^T A$ til egenverdien λ_1 . Med denne argument har vi vist den etterfølgende teorem:

Teorem. La A være en $m \times n$ matrise og la

$$\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n,$$

være egenverdier til matrisen $A^T A$ med ortonormale egenvektorer

$$\{\vec{v}_1, \vec{v}_2, \dots, \vec{v}_n\}.$$

Der er

$$\max_{\vec{x}: \|\vec{x}\|=1} \|A\vec{x}\| = \|A\vec{v}_1\| = \sqrt{\lambda_1}.$$

Teoremet sier at den lengste halvakse i ellipsoiden til matrisen A har lengden $\sqrt{\lambda_1}$ og peger i retningen $A\vec{v}_1$ hvor λ_1 er den største egenverdi av matrisen $A^T A$ og \vec{v}_1 er den tilsvarende egenvektor.

Lengde og retning av de andre halvaksler. Med en lignende argument som den fra sidst avsnit kan man vise at lengder av de andre halvaksler er tallene $\sqrt{\lambda_2}, \dots, \sqrt{\lambda_n}$ og at de peger i retninger $A\vec{v}_2, \dots, A\vec{v}_n$ hvor $\lambda_2, \dots, \lambda_n$ er egenverdier av matrisen $A^T A$ slik at $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n$ og $\vec{v}_2, \dots, \vec{v}_n$ er de tilsvarende egenvektorer. Bemerk at hvis det er sant, så er vektorene $A\vec{v}_1, A\vec{v}_2, \dots, A\vec{v}_n$ ortogonal, og egenverdier $\lambda_1, \dots, \lambda_n \geq 0$. La oss se i neste avsnit at det er riktig.

SINGULÆRVERDIER OG SINGULÆRVERDI-DEKOMPOSISJON

For hvert $m \times n$ matrise A finnes der en ortogonal basis $\{\vec{v}_1, \dots, \vec{v}_n\}$ som består av egenvektorer til den symmetriske $n \times n$ matrise $A^T A$. La $\lambda_1, \dots, \lambda_n$ være de tilsvarende egenverdier for $A^T A$. Vi kan regne ut at

$$(2) \quad \|A\vec{v}_i\|^2 = \langle A\vec{v}_i, A\vec{v}_i \rangle = \langle \vec{v}_i, A^T A\vec{v}_i \rangle = \langle \vec{v}_i, \lambda_i \vec{v}_i \rangle = \lambda_i,$$

og vi konkluderer at $\lambda_i \geq 0$ for alle $i \in \{1, \dots, n\}$. Vi kan alltid anta at

$$\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n \geq 0,$$

og vi definerer *singulærverdier* for matrisen A som

$$\sigma_i = \sqrt{\lambda_i}.$$

Bemærk fra (2) at $\sigma_i = \|A\vec{v}_i\|$.

Teorem 9. La A være en $m \times n$ matrise og la

$$\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n,$$

være egenverdier til matrisen $A^T A$ med ortonormale egenvektorer

$$\{\vec{v}_1, \vec{v}_2, \dots, \vec{v}_n\}.$$

Anta at $\lambda_1, \dots, \lambda_r > 0$ og at $\lambda_{r+1} = \dots = \lambda_n = 0$. Da er

- Mængden $\{A\vec{v}_1, \dots, A\vec{v}_r\}$ er en ortogonal basis for $\text{Col}(A)$.
- Vi har $r = \text{rank}(A)$.

Bevis. La oss se først at vektorene i mængden $\{A\vec{v}_1, \dots, A\vec{v}_r\}$ er ortogonale. Hvis $i \neq j$ så har vi $\langle \vec{v}_i, \vec{v}_j \rangle = 0$ (de er jo ortonormale egenvektorer for matrisen $A^T A$). Derfor finner vi at

$$\langle A\vec{v}_i, A\vec{v}_j \rangle = \langle \vec{v}_i, A^T A\vec{v}_j \rangle = \langle \vec{v}_i, \lambda_j \vec{v}_j \rangle = \lambda_j \langle \vec{v}_i, \vec{v}_j \rangle = 0.$$

Det viser at $\{A\vec{v}_1, \dots, A\vec{v}_r\}$ er en mængde av ortogonale vektorer, og selvfølgelig ligger disse vektorer i $\text{Col}(A)$. For at vise at de former en ortogonal basis for $\text{Col}(A)$ er det derfor nok at sjekke at de utspenner hele $\text{Col}(A)$.

La oss se på en vektor $\vec{y} \in \text{Col}(A)$ som kan skrives som $\vec{y} = A\vec{x}$ for en vektor $\vec{x} \in \mathbb{R}^n$. Matrisen $A^T A$ er symmetrisk og vi har set før at mængden $\{\vec{v}_1, \vec{v}_2, \dots, \vec{v}_n\}$ av egenvektorer er en ortonormal basis for \mathbb{R}^n . Derfor finnes der tal c_1, \dots, c_n slik at

$$\vec{x} = c_1 \vec{v}_1 + \dots + c_n \vec{v}_n,$$

og vi ser at

$$(3) \quad \vec{y} = A\vec{x} = c_1 A\vec{v}_1 + \dots + c_n A\vec{v}_n.$$

Det ser ut som at der er lidt for mange vektorer i denne lineærkombinasjon. Vi har også brukt vektorer $A\vec{v}_{r+1}, \dots, A\vec{v}_n$. Kan vi si noget om disse vektorer? Vi kan regne ut deres norm! For hvert $i \geq r+1$ har vi

$$\|A\vec{v}_i\|_2^2 = \langle A\vec{v}_i, A\vec{v}_i \rangle = \langle \vec{v}_i, A^T A\vec{v}_i \rangle = \lambda_i \langle \vec{v}_i, \vec{v}_i \rangle = \lambda_i \|\vec{v}_i\|_2^2 = 0,$$

fordi $\lambda_i = 0$ hvis $i \geq r+1$. Vi konkluderer at $A\vec{v}_{r+1} = \dots = A\vec{v}_n = \vec{0}$, og fra (3) finner vi at

$$\vec{y} = A\vec{x} = c_1 A\vec{v}_1 + \dots + c_n A\vec{v}_r.$$

Det viser at $\vec{y} \in \text{Span}\{A\vec{v}_1, \dots, A\vec{v}_r\}$ og vi konkluderer at mængden

$$\{A\vec{v}_1, \dots, A\vec{v}_r\}$$

utspenner $\text{Col}(A)$. Mængden $\{A\vec{v}_1, \dots, A\vec{v}_r\}$ er en basis for $\text{Col}(A)$ og fordi den inneholder r vektorer har vi $\text{Rank}(A) = r$. □

La oss nu komme til singularverdi-dekomposisjonen.

Teorem 10 (Singularverdi-dekomposisjon). *La A være en $m \times n$ matrise med rang r . Da finnes det en $m \times m$ ortogonale matrise U og en $n \times n$ ortogonale matrise V slik at*

$$(4) \quad A = U\Sigma V^T,$$

med matrisen

$$\Sigma = \begin{pmatrix} D & \mathbf{0}_{r \times (n-r)} \\ \mathbf{0}_{(m-r) \times r} & \mathbf{0}_{(m-r) \times (n-r)} \end{pmatrix},$$

hvor

$$D = \begin{pmatrix} \sigma_1 & & & \\ & \sigma_2 & & \\ & & \ddots & \\ & & & \sigma_r \end{pmatrix}.$$

Dekomposisjonen i (4) hedder *singularverdi-dekomposisjon* av matrisen A . Ortogonale matriser U og V i denne dekomposisjon er *ikke* unik for matrisen A men singularverdier (og dermed matrisen Σ) er unike. Søylene i matrisen U kalles *venstre singularvektorer* av A og søylene i matrisen V kalles for *høyre singularvektorer* av A .

Bevis. Like som i Teorem 9, la $\vec{v}_1, \dots, \vec{v}_n$ være egenvektorer til matrisen $A^T A$ for egenverdier $\lambda_1, \dots, \lambda_n$ hvor vi anta at

$$\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_r \geq \lambda_{r+1} = \dots = \lambda_n = 0.$$

Vi definerer singularverdier $\sigma_i = \sqrt{\lambda_i}$ og husker at

$$\|A\vec{v}_i\|_2 = \sigma_i,$$

for hvert $i \in \{1, \dots, n\}$. For hvert $i \in \{1, \dots, r\}$ kan vi definere \vec{u}_i den normaliserte vektor $A\vec{v}_i$, dvs.

$$(5) \quad \vec{u}_i = \frac{A\vec{v}_i}{\|A\vec{v}_i\|} = \frac{A\vec{v}_i}{\sigma_i}.$$

Efter Teorem 9 har vi en ortonormal basis $\{\vec{u}_1, \dots, \vec{u}_r\}$ for $\text{Col}(A)$ som vi kan forlenge til en ortonormalbasis $\{\vec{u}_1, \dots, \vec{u}_r, \vec{u}_{r+1}, \dots, \vec{u}_m\}$ for hele \mathbb{R}^m . Vi kan definere to ortogonale matriser

$$U = (\vec{u}_1, \dots, \vec{u}_m),$$

og

$$V = (\vec{v}_1, \dots, \vec{v}_n).$$

Fra (5) ser vi at $A\vec{v}_i = \sigma_i \vec{u}_i$ for alle $i \in \{1, \dots, r\}$ og vi ved også at $A\vec{v}_i = \mathbf{0} = \sigma_i \vec{u}_i$ for alle $i \geq r+1$. Derfor finner vi

$$AV = (A\vec{v}_1, \dots, A\vec{v}_n) = (\sigma_1 \vec{u}_1, \dots, \sigma_r \vec{u}_r, \vec{0}, \dots, \vec{0}).$$

Vi finner også at

$$\begin{aligned} U\Sigma &= (\vec{u}_1, \dots, \vec{u}_m) \begin{pmatrix} \sigma_1 & & & & \\ & \sigma_2 & & & \\ & & \ddots & & \\ & & & \sigma_r & \\ & & & & \mathbf{0} \end{pmatrix} \\ &= (\sigma_1 \vec{u}_1, \dots, \sigma_r \vec{u}_r, \vec{0}, \dots, \vec{0}) \\ &= AV. \end{aligned}$$

Fordi V er ortogonal kan vi regne ut at

$$U\Sigma V^T = AVV^T = A.$$

□

Prøv selv at regne ut singularverdi-dekomposisjonen for 2×3 matrisen fra den eksempel i starten.

ANVENDELSER AV SINGULÆRVERDI-DEKOMPOSISJON

Singularverdi-dekomposisjonen har mange anvendelser. Her, vi kan se to av dem:

Basiser av underrom assosiert med en matrise. La oss anta at A er en $m \times n$ matrise med rang r singularverdi-dekomposisjon

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

med en ortogonal $n \times n$ matrise U , en ortogonal $m \times m$ matrise V . La $\vec{u}_1, \dots, \vec{u}_m$ være de venstre singularvektorer, dvs. søylerne i U , og $\vec{v}_1, \dots, \vec{v}_n$ være de høyre singularvektorer, dvs. søylerne i V . Vi har set i Teorem 9 at

$$\{\vec{u}_1, \dots, \vec{u}_r\}$$

er en ortonormalbasis for $\text{Col}(A)$. Fordi de venstre singularvektorer er en ortonormal basis til \mathbb{R}^m konkluderer vi at

$$\{\vec{u}_{r+1}, \dots, \vec{u}_m\}$$

er en ortonormal basis for $\text{Col}(A)^\perp = \text{Nul}(A^T)$. Vi har også set at $\|A\vec{v}_i\| = \sigma_i$ som er like 0 hvis og kun hvis $i \geq r + 1$. Derfor er $\vec{v}_{r+1}, \dots, \vec{v}_n \in \text{Nul}(A)$. Fordi $\dim(\text{Nul}(A)) = n - r$ (etter rangteoremet) ser vi at

$$\{\vec{v}_{r+1}, \dots, \vec{v}_n\}$$

er en ortonormal basis for $\text{Nul}(A)$. Fordi de høyre singularvektorer former en ortonormalbasis for \mathbb{R}^n ser vi at

$$\{\vec{v}_1, \dots, \vec{v}_r\}$$

er en ortonormal basis for $\text{Nul}(A)^\perp = \text{Col}(A^T) = \text{Row}(A)$.