

Basbyten och linjära avbildningar

Innan vi fortsätter med egenvärden så ska vi titta på hur matrisen för en linjär avbildning beror på vilken bas vi använder. Vi vet sedan tidigare att till en linjär avbildning g hör en matris A sådan att

$$g(\mathbf{x}) = A\mathbf{x},$$

där enligt bassatsen matrisen A tex i fallet i 3 dimensioner ges av

$$A = \left(g(\mathbf{e}_1) \quad g(\mathbf{e}_2) \quad g(\mathbf{e}_3) \right)$$

där \mathbf{e}_1 , \mathbf{e}_2 och \mathbf{e}_3 är standardbasvektorerna. Detta är i själva verket inte mer än en del av sanningen. Matrisen beror ju i själva verket på vilken bas vi väljer. Det är just i standardbasen som den ser ut så här. Ska man vara riktigt korrekt så borde man skriva att

$$g(\mathbf{x}) = A\mathbf{x}_E,$$

där \mathbf{x}_E är \mathbf{x} koordinater i basen $E = (\mathbf{e}_1 \ \mathbf{e}_2 \ \mathbf{e}_3)$ och ha i åtanke att A beror på basen.

Antag nu att $F = (\mathbf{f}_1 \ \mathbf{f}_2 \ \mathbf{f}_3)$ är en annan bas. Bassatsen ger nu att

$$g(\mathbf{x}) = A_F\mathbf{x}_F, \text{ där } A_F = \left(g(\mathbf{f}_1) \quad g(\mathbf{f}_2) \quad g(\mathbf{f}_3) \right)$$

Exempel 1 Låt g vara den linjära avbildning som projicerar rummet på xy -planet. Vi har tidigare sett att denna har matrisen

$$A = \begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{pmatrix}$$

i standardbasen.

Låt nu istället F vara ON-basen som består av vektorerna

$$F = \left(\mathbf{f}_1 \quad \mathbf{f}_2 \quad \mathbf{f}_3 \right) = \begin{pmatrix} 1/\sqrt{3} & 1/\sqrt{2} & 1/\sqrt{6} \\ 1/\sqrt{3} & -1/\sqrt{2} & 1/\sqrt{6} \\ 1/\sqrt{3} & 0 & -2/\sqrt{6} \end{pmatrix}$$

och låt h vara den linjära avbildning som projicerar ortogonalt på planet som spänns upp av \mathbf{f}_1 och \mathbf{f}_2 . Matrisen för denna avbildning i basen F kommer då att vara

$$A_F = \left(g(\mathbf{f}_1) \quad g(\mathbf{f}_2) \quad g(\mathbf{f}_3) \right) = \left(\mathbf{f}_1 \quad \mathbf{f}_2 \quad \mathbf{0} \right) = \begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{pmatrix}$$

De två linjära avbildningarna är uppenbarligen olika, ty normalvektorerna \mathbf{e}_3 respektive \mathbf{f}_3 till planen är inte parallella. Däremot har de två linjära avbildningarna samma matris om man jobbar i de två olika baserna.

I exemplet så såg vi att matrisen för den lite krångligare avbildningen h blev lika lätt som för g bara vi valde att jobba med en lämplig bas. Hitta matrisen för h i standardbasen är inte lika lätt, men vi ska se att man kan använda vår kunskap om basbyten för att få fram den. Vad vi söker är alltså en matris B sådan att

$$h(\mathbf{x}) = B\mathbf{x}_E.$$

i standardbasen. Vi såg ovan att

$$h(\mathbf{x}) = A_F\mathbf{x}_F$$

i basen F . Från avsnittet om basbyten så vet vi att koordinaterna i standardbasen och basen F är relaterade genom

$$\mathbf{x}_F = F^{-1}\mathbf{x}_E$$

vilket ger att

$$h(\mathbf{x}) = A_FF^{-1}\mathbf{x}_E$$

fortfarande uttryckt i basen F . För att översätta detta till koordinater i E så utnyttjar vi att $\mathbf{y}_E = F\mathbf{y}_F$ med $\mathbf{y}_F = A_FF^{-1}\mathbf{x}_E$ och får slutligen

$$h(\mathbf{x}) = FA_FF^{-1}\mathbf{x}_E$$

i standardbasen E . Den sökta matrisen är alltså $B = FA_FF^{-1}$. Intuitivt kan man tolka B som så att först översätter F^{-1} från standardbasen till basen F , sedan utför A_F den linjära avbildningen i basen F och slutligen så översätter F tillbaka till standardbasen. Vi sammanfattar i följande sats.

Sats 1 *Låt en linjär avbildning ha matrisen A_F i basen $F = (\mathbf{f}_1 \mathbf{f}_2 \mathbf{f}_3)$. Då har den matrisen*

$$A = FA_FF^{-1}$$

i standardbasen.

Exempel 2 *Vi återknyter till förra exemplet. Enligt satsen så får vi nu att matrisen för den linjära avbildningen h i standardbasen ges av*

$$A = FA_FF^{-1} = FA_FF^t = \frac{1}{6} \begin{pmatrix} 5 & -1 & 2 \\ -1 & 5 & 2 \\ 2 & 2 & 2 \end{pmatrix}.$$

Observera speciellt att $F^{-1} = F^t$ eftersom det är en ON-bas så F är en ON-matris. Man kunde givetvis ha räknat fram A direkt genom att tänka geometriskt, men inte utan en hel del besvär. Det lönar sig att jobba med olika baser (och lära sig användbara satser som den ovan).

En av vinsterna med att beräkna egenvärden om man kan hitta en full uppsättning av linjärt oberoende egenvektorer (och det går tex som vi vet om matrisen är symmetrisk) är att man får en bas där den linjära avbildningen är väldigt enkel. På en bas bestående av egenvektorer så är ju matrisen bara multiplikation med ett tal på respektive basvektor, så att matrisen i egenvektorsbasen blir diagonal. Det är detta som är kärnan i vad som kallas för **diagonalisering** som är nästa ämne då vi ska knyta samman egenvärden med denna diskussion om basbyten och linjära avbildningar.

Diagonalisering

En **diagonal matris** är en matris som bara har nollor utanför diagonalen. Sådana matriser är väldigt enkla att hantera på alla möjliga sätt och vi ska se hur man kan utnyttja detta för bla symmetriska matriser.

Definition 1 Låt A vara en $n \times n$ -matris. Vi säger att A är **diagonaliserbar** om det finns inverterbar matris P och diagonal matris D sådana att

$$A = PDP^{-1}.$$

En direkt tillämpning av diagonaliseringen är att det blir snabbt att beräkna en godtycklig potens av A . Vi får

$$A^2 = (PDP^{-1})(PDP^{-1}) = PD(P^{-1}P)DP^{-1} = PD^2P^{-1},$$

vilket med en uppenbar induktion ger

$$A^n = PD^nP^{-1}.$$

Det är trivialt att beräkna D^n (varför?) och sedan behöver vi bara multiplicera med P och P^{-1} .

Genom att multiplicera med P från höger i båda leden så får vi den ekvivalenta likheten

$$AP = PD.$$

Antag nu att A har n stycken linjärt oberoende egenvektorer $\mathbf{v}_1, \dots, \mathbf{v}_n$ med motsvarande egenvärden $\lambda_1, \dots, \lambda_n$, dvs $A\mathbf{v}_i = \lambda_i\mathbf{v}_i$ för $i = 1, \dots, n$. Låt P vara matrisen som har $\mathbf{v}_1, \dots, \mathbf{v}_n$ som kolonner och låt D vara den diagonalmatris som har $\lambda_1, \dots, \lambda_n$ på diagonalen. Eftersom kolonnerna är linjärt oberoende så kommer P att vara inverterbar. Vi får

$$AP = A(\mathbf{v}_1 \ \dots \ \mathbf{v}_n) = (A\mathbf{v}_1 \ \dots \ A\mathbf{v}_n) = (\lambda_1\mathbf{v}_1 \ \dots \ \lambda_n\mathbf{v}_n) = PD.$$

Vi har alltså visat att om A har n stycken linjärt oberoende egenvektorer så är den diagonaliserbar. Omvänt så antag att $A = PDP^{-1}$ är diagonaliserbar. Då ser man direkt från $AP = PD$ att kolonnerna i P är egenvektorer till A med elementen i D 's diagonal som egenvärden. Vi har alltså visat följande:

Sats 2 En $n \times n$ -matris är diagonaliserbar om och endast om den har n stycken linjärt oberoende egenvektorer.

Genom att utnyttja vad vi vet om symmetriska matriser så får vi följande följsats:

Sats 3 Till varje symmetrisk matris A så finns det diagonal matris D och ON-matris P sådana att

$$A = PDP^t.$$

Exempel 3 Vi såg senast att

$$A = \begin{pmatrix} 3/4 & 1/4 \\ 1/4 & 3/4 \end{pmatrix},$$

hade egenvärdena 1 respektive $1/2$ med motsvarande (normerade) egenvektorer $(1/\sqrt{2})(1 \ 1)^t$ och $(1/\sqrt{2})(1 \ -1)^t$. Vi sätter då enligt receptet ovan

$$P = \frac{1}{\sqrt{2}} \begin{pmatrix} 1 & 1 \\ 1 & -1 \end{pmatrix} \text{ och } D = \begin{pmatrix} 1 & 0 \\ 0 & 1/2 \end{pmatrix},$$

vilket ger

$$PDP^t = \frac{1}{2} \begin{pmatrix} 1 & 1 \\ 1 & -1 \end{pmatrix} \begin{pmatrix} 1 & 0 \\ 0 & 1/2 \end{pmatrix} \begin{pmatrix} 1 & 1 \\ 1 & -1 \end{pmatrix} = \frac{1}{2} \begin{pmatrix} 1 & 1/2 \\ 1 & -1/2 \end{pmatrix} \begin{pmatrix} 1 & 1 \\ 1 & -1 \end{pmatrix} = A$$

som satsen lovade oss.

Vi ska nu relatera diagonaliseringen av en matris till basbyten för linjära avbildningar. Antag att vi har en linjär avbildning som har matrisen A i standardbasen. Vi såg tidigare att om $F = (\mathbf{f}_1 \ \mathbf{f}_2 \ \dots \ \mathbf{f}_n)$ är en annan bas så ges matrisen för den linjära avbildningen i basen F av matrisen A_F där

$$A = F A_F F^{-1}.$$

(Vi formulerade och visade bara satsen för $n = 3$, men samma argument fungerar för godtyckligt n .) Om vi jämför detta med diagonaliseringen

$$A = PDP^{-1}$$

så får vi att D helt enkelt är matrisen A_P för den linjära avbildningen i basen P , dvs basen som består av egenvektorerna. Men om vi tänker efter lite så kan vi inse att detta bara är en omformulering av villkoret att vara egenvektorer.

Antag tex att \mathbf{v}_1 är den första egenvektorn i P . Då kommer den att ha koordinaterna $(1 \ 0 \ 0 \ \dots \ 0)^t$ i basen P . Men $A\mathbf{v}_1 = \lambda_1\mathbf{v}_1$ och $\lambda_1\mathbf{v}_1$ har koordinaterna $(\lambda_1 \ 0 \ 0 \ \dots \ 0)^t$ i basen P , så första kolumnen i A_P kommer att vara $(\lambda_1 \ 0 \ 0 \ \dots \ 0)^t$ vilket är samma som för D . På samma sätt motiverar man att de andra kolumnerna också stämmer överens.

Summerar vi så får vi alltså att den linjära avbildningen som har A som matris (i standardbasen) har en väldigt enkel matris i basen av egenvektorer: Den är diagonal.

Singulärvärdesuppdelning

Nu ska vi titta på vad man kan göra om man har en matris som inte är diagonaliserbar. Om man släpper på villkoret $P = Q$ i faktoriseringen $A = PDQ^t$ av en symmetrisk matris så visar det sig att man alltid kan finna en sådan faktorisering av en godtycklig (inte nödvändigtvis kvadratisk) matris. Beviset av följande sats ligger utanför den här kursen.

Sats 4 Låt A vara en $m \times n$ -matris. Då finns det matriser U , V och Σ sådana att:

1. $A = U\Sigma V^t$.
2. U är en ON-matris av storlek $m \times m$.
3. V är en ON-matris av storlek $n \times n$.
4. Σ är en 'diagonal' matris av formen

$$\Sigma = \begin{pmatrix} \sigma_1 & 0 & 0 & \cdots & \cdots & \cdots & 0 \\ 0 & \sigma_2 & 0 & \cdots & \cdots & \cdots & 0 \\ 0 & 0 & \ddots & \cdots & \cdots & \cdots & \vdots \\ \vdots & \vdots & \cdots & \sigma_r & \cdots & \cdots & \vdots \\ 0 & 0 & \cdots & \cdots & 0 & \cdots & 0 \end{pmatrix}$$

där $\sigma_1 \geq \sigma_2 \geq \cdots \geq \sigma_r > 0$.

Faktoriseringen $A = U\Sigma V^t$ kallas för en **singulärvärdesuppdelning (SVD)** av A och $(\sigma_1, \dots, \sigma_r)$ kallas för A 's **singulärvärden**.

Anmärkning 1 Matrisen Σ är unikt bestämd (och därmed är singulärvärdena unikt bestämda), men däremot är matriserna U och V inte unikt bestämda.

Det finns ingen enkel algoritm att beräkna SVD av en matris för hand, däremot finns det bra numeriska metoder som lämpar sig för datorberäkningar. Vi ska dock se att faktoriseringen hänger ihop med de symmetriska matriserna AA^t och A^tA . Antag att $A = U\Sigma V^t$ är en SVD av A . Vi får då

$$AA^t = (U\Sigma V^t)(U\Sigma V^t)^t = U\Sigma V^t V \Sigma^t U^t = U(\Sigma \Sigma^t)U^t.$$

Observera att $\Sigma \Sigma^t$ är diagonal med σ_i^2 på diagonalen så vi ser att vi har en diagonalisering av AA^t . Detta ger att kolonnerna i U är egenvektorer till AA^t med motsvarande egenvärden σ_i^2 . På motsvarande sätt får vi att

$$A^tA = V(\Sigma^t \Sigma)V^t.$$

Detta ger att kolonnerna i V (det är därför man envisas med att ha V^t istället för V) är egenvektorer till A^tA .

En viktig tillämpning på SVD är att man kan utnyttja den till att ta ut det viktiga ur en matris som innehåller någon typ av information. Exempel finns inom signalbehandling, om A är en term/dokument-matris för informations-sökning (så kallad LSI som ni hörde om på temaföreläsningen) och om A innehåller pixlarna till en bild. Vi ska nu antyda hur det här fungerar.

Om vi låter kolonn i i U vara \mathbf{u}_i och kolonn i i V vara \mathbf{v}_i så får vi

$$A = U\Sigma V^t = (\mathbf{u}_1 \quad \mathbf{u}_2 \quad \cdots \quad \mathbf{u}_m) \begin{pmatrix} \sigma_1 & 0 & 0 & \cdots & \cdots & \cdots & 0 \\ 0 & \sigma_2 & 0 & \cdots & \cdots & \cdots & 0 \\ 0 & 0 & \ddots & \cdots & \cdots & \cdots & \vdots \\ \vdots & \vdots & \cdots & \sigma_r & \cdots & \cdots & \vdots \\ 0 & 0 & \cdots & \cdots & 0 & \cdots & 0 \end{pmatrix} \begin{pmatrix} \mathbf{v}_1^t \\ \mathbf{v}_2^t \\ \vdots \\ \mathbf{v}_n^t \end{pmatrix} = \sum_{i=1}^r \sigma_i \mathbf{u}_i \mathbf{v}_i^t.$$

Observera först att $\mathbf{u}_i \mathbf{v}_i^t$ är $m \times n$ -matriser, så att summan i högerledet är en uppdelning av A som summan av r stycken matriser. Eftersom kolonnerna i U och V är normerade så kommer alla element i $\mathbf{u}_i \mathbf{v}_i^t$ att vara små (≤ 1). Därmed kommer det att vara singularvärdena som avgör hur stora matriserna i summan är. Om vi nu tar en del av summan

$$\sum_{i=1}^s \sigma_i \mathbf{u}_i \mathbf{v}_i^t$$

med $s < r$ så kommer denna att vara nästan lika med A om σ_i för $i > s$ är mycket mindre än det största singularvärdet σ_1 .

För signalbehandling och för LSI fungerar det så att man genom att bara ta med de största singularvärdena filtrerar bort skräp i informationen. När det gäller bilder så kan man på det här sättet komprimera lagringen av dem genom att försumma termerna då $i > s$. (Det finns idag bättre metoder för komprimering, men detta exempel är en bra illustration hur SVD fungerar.)