

2 - 12 - HVA ER EN KATT? - LF

- 1 Dette er litt greit å vite, for det blir lettere å lese statistikkbøker om man er god i lineær algebra.

$$\mathbf{1}^T \mathbf{1} = n$$

$$\mathbf{1}\mathbf{1}^T = \begin{pmatrix} 1 & 1 & \dots & 1 & 1 \\ 1 & 1 & \dots & 1 & 1 \\ \vdots & & \ddots & & \vdots \\ 1 & 1 & \dots & 1 & 1 \\ 1 & 1 & \dots & 1 & 1 \end{pmatrix}$$

$$\mathbf{1}^T \mathbf{x} = n\bar{x}$$

- 2 En projeksjon er en lineær operator som tilfredsstillers $P = P^2$. Vi beregner

$$\begin{aligned} C_n^2 &= \left(I - \frac{1}{n} \mathbf{1}\mathbf{1}^T \right) \left(I - \frac{1}{n} \mathbf{1}\mathbf{1}^T \right) \\ &= I - \frac{2}{n} \mathbf{1}\mathbf{1}^T + \frac{1}{n} \mathbf{1}\mathbf{1}^T \\ &= I - \frac{1}{n} \mathbf{1}\mathbf{1}^T \end{aligned}$$

Gjennomsnittet til den sentrerte variabelen er selvfølgelig null. Det er det som er poenget.

- 3 Med sentrerte variable der $\bar{x} = \bar{y} = 0$, får vi

$$\beta_1 = \frac{\mathbf{x}^T \mathbf{y}}{\mathbf{x}^T \mathbf{x}} \quad \text{og} \quad \beta_0 = 0.$$

Nå kjenner vi igjen β_1 som projeksjonen av \mathbf{y} på \mathbf{x} .

$$\begin{aligned} \mathbf{y} &= \beta_{10} \mathbf{x}_1 + \beta_{01} \mathbf{x}_2 + \beta_0 \mathbf{1} \\ \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix} &= \beta_{10} \begin{pmatrix} x_{11} \\ x_{21} \\ \vdots \\ x_{n1} \end{pmatrix} + \beta_{01} \begin{pmatrix} x_{12} \\ x_{22} \\ \vdots \\ x_{n2} \end{pmatrix} + \beta_0 \begin{pmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{pmatrix} \end{aligned}$$

- 4 og la

$$\begin{pmatrix} x_{11} & x_{12} & 1 \\ x_{21} & x_{22} & 1 \\ \vdots & \vdots & \vdots \\ x_{n1} & x_{n2} & 1 \end{pmatrix}$$

Vi ganger med A^T fra venstre for å få normallikningene:

$$A^T \mathbf{y} = A^T A \beta$$

Skrevet ut på komponentform blir dette

$$\begin{pmatrix} \mathbf{y}^T \mathbf{x}_1 \\ \mathbf{y}^T \mathbf{x}_2 \\ n\bar{y} \end{pmatrix} = \begin{pmatrix} \|\mathbf{x}_1\|^2 & \mathbf{x}_1^T \mathbf{x}_2 & n\bar{x}_1 \\ \mathbf{x}_1^T \mathbf{x}_2 & \|\mathbf{x}_2\|^2 & n\bar{x}_2 \\ n\bar{x}_1 & n\bar{x}_2 & n \end{pmatrix} \begin{pmatrix} \beta_{10} \\ \beta_{01} \\ \beta_0 \end{pmatrix}$$

Dersom $\bar{x}_1 = \bar{x}_2 = \bar{y} = 0$, blir dette mye enklere:

$$\begin{pmatrix} \mathbf{y}^T \mathbf{x}_1 \\ \mathbf{y}^T \mathbf{x}_2 \\ 0 \end{pmatrix} = \begin{pmatrix} \|\mathbf{x}_1\|^2 & \mathbf{x}_1^T \mathbf{x}_2 & 0 \\ \mathbf{x}_1^T \mathbf{x}_2 & \|\mathbf{x}_2\|^2 & 0 \\ 0 & 0 & n \end{pmatrix} \begin{pmatrix} \beta_{10} \\ \beta_{01} \\ \beta_0 \end{pmatrix}$$

og vi ser lett at $\beta_0 = 0$, slik at likningssystemet blir

$$\begin{pmatrix} \mathbf{y}^T \mathbf{x}_1 \\ \mathbf{y}^T \mathbf{x}_2 \end{pmatrix} = \begin{pmatrix} \|\mathbf{x}_1\|^2 & \mathbf{x}_1^T \mathbf{x}_2 \\ \mathbf{x}_1^T \mathbf{x}_2 & \|\mathbf{x}_2\|^2 \end{pmatrix} \begin{pmatrix} \beta_{10} \\ \beta_{01} \end{pmatrix}$$

Et klassisk triks for å kjapt løse 2×2 -matriser, er å kjenne til formelen

$$\begin{pmatrix} a & b \\ c & d \end{pmatrix}^{-1} = \frac{1}{ad - bc} \begin{pmatrix} d & -b \\ -c & a \end{pmatrix}.$$

slik at

$$\begin{aligned} \beta &= (A^T A)^{-1} A \mathbf{y} \\ &= \frac{1}{\|\mathbf{x}_1\|^2 \|\mathbf{x}_2\|^2 - (\mathbf{x}_1^T \mathbf{x}_2)^2} \begin{pmatrix} \|\mathbf{x}_2\|^2 & -\mathbf{x}_1^T \mathbf{x}_2 \\ -\mathbf{x}_1^T \mathbf{x}_2 & \|\mathbf{x}_1\|^2 \end{pmatrix} \begin{pmatrix} \mathbf{y}^T \mathbf{x}_1 \\ \mathbf{y}^T \mathbf{x}_2 \end{pmatrix} \end{aligned}$$

I dataanalyse er det også vanlig å dele ut standardavvikene. Dette er det samme som å normalisere vektorer i lineær algebra. Gjør vi det, blir det enda penere:

$$\beta = \frac{1}{1 - (\mathbf{x}_1^T \mathbf{x}_2)^2} \begin{pmatrix} 1 & -\mathbf{x}_1^T \mathbf{x}_2 \\ -\mathbf{x}_1^T \mathbf{x}_2 & 1 \end{pmatrix} \begin{pmatrix} \mathbf{y}^T \mathbf{x}_1 \\ \mathbf{y}^T \mathbf{x}_2 \end{pmatrix}$$

5 Empirisk kovarians mellom to datasett \mathbf{x} og \mathbf{y} ser slik ut

$$\frac{1}{n-1} \sum_k (x_k - \bar{x})(y_k - \bar{y})$$

og dersom vi sentrerer, blir dette bare skalarproduktet mellom \mathbf{x} og \mathbf{y} delt på $n-1$. Hvis du ser nøye på $\frac{1}{n-1} X^T X$ vil du se at hvert element er den empiriske kovariansen mellom de forskjellige kolonnene i X siden $X^T X$ bare er skalarprodukter mellom kolonner i X .

6 Alle matriser på formen $A^T A$ er positivt definitte om de har full rang, og positivt semidefinitte om de ikke har det.¹ Dersom A har full rang, er

$$0 < \|A\mathbf{x}\|^2 = \mathbf{x}^T A^T A \mathbf{x}$$

så lenge $\mathbf{x} \neq \mathbf{0}$. Dersom A ikke har full rang, er

$$0 \leq \|A\mathbf{x}\|^2 = \mathbf{x}^T A^T A \mathbf{x}$$

siden det kan finnes $\mathbf{x} \neq \mathbf{0}$ slik at $A\mathbf{x} = \mathbf{0}$.

¹Full rang betyr maksimalt antall lineært uavhengige rader eller kolonner:
[https://en.wikipedia.org/wiki/Rank_\(linear_algebra\)](https://en.wikipedia.org/wiki/Rank_(linear_algebra))

- 9 Dette var kanskje bittelitt i hardeste laget for TMA4106. PCA er en teknikk for å projisere dataskyen inn på en retning i rommet slik at variansen til det resulterende envariable datasettet blir maksimert:

https://en.wikipedia.org/wiki/Principal_component_analysis

Jeg har plaget dere med dette fordi det er sentralt i kunstig intelligens, og skal du skjønne noe av dét er du nødt til å forstå lineær algebra og statistikk.

- 11 Både $A^T A$ og AA^T er symmetriske, og symmetriske matriser er som kjent ortogonalt diagonaliserbare.

- 12 Dersom A har dimensjon $n \times p$, har $A^T A$ og V dimensjon $p \times p$ mens AA^T og U er $n \times n$.

- 13 Dersom \mathbf{v} er en egenvektor til $A^T A$ med egenvektor $\lambda \neq 0$, kan vi gange likningen

$$A^T A \mathbf{v} = \lambda \mathbf{v}$$

med A og få

$$AA^T A \mathbf{v} = \lambda A \mathbf{v}$$

som sier at $A \mathbf{v}$ er en egenvektor til AA^T med den samme egenverdien. Dersom $\lambda = 0$ bryter dette sammen siden $A \mathbf{v} = 0$ og nullvektoren ikke klassifiserer som egenvektor. Resonnementet den andre veien er likt, og egenvektorene til AA^T kaller vi \mathbf{u} . Egenverdiene må være større enn null, siden

$$0 \leq \|A \mathbf{v}\|^2 = \mathbf{v}^T A^T A \mathbf{v} = \lambda \|\mathbf{v}\|^2.$$

- 14 Beregningen i oppgaven over viser at dersom $\|\mathbf{v}\| = 1$ er

$$\|A \mathbf{v}\| = \sqrt{\lambda}.$$

- 15 I de foregående oppgavene har vi vist at

$$A \mathbf{v} = \sqrt{\lambda} \mathbf{u}$$

der \mathbf{v} er en egenvektor til $A^T A$ og \mathbf{u} er en egenvektor til AA^T , begge normaliserte og med egenverdi $\lambda \neq 0$. Setter vi opp alt dette i en matriselikning, får vi

$$AV = U \Sigma$$

der Σ er en diagonal og kvadratisk matrise med singularverdiene på diagonalen. Dette kalles den **reduerte svd-faktoriseringen** til A . Dersom $A^T A$ eller AA^T har egenverdier som er null kan vi utvide faktoriseringen til å inkludere de korresponderende egenvektorene, men disse er sjelden nyttige i praktiske anvendelser. Svd-faktoriseringen til

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

finner vi ved å beregne egenverdier og egenvektorer til

$$A^T A = \begin{pmatrix} 2 & 1 \\ 1 & 2 \end{pmatrix}$$

som er

$$\lambda_1 = 3 \quad \mathbf{v}_1 = \begin{pmatrix} 1/\sqrt{2} \\ 1/\sqrt{2} \end{pmatrix} \quad \text{og} \quad \lambda_2 = 1 \quad \mathbf{v}_2 = \begin{pmatrix} 1/\sqrt{2} \\ -1/\sqrt{2} \end{pmatrix}$$

og for

$$AA^T = \begin{pmatrix} 1 & 0 & 1 \\ 0 & 1 & 1 \\ 1 & 1 & 2 \end{pmatrix}$$

som er

$$\lambda_1 = 3 \quad \mathbf{u}_1 = \begin{pmatrix} 1/\sqrt{6} \\ 1/\sqrt{6} \\ 2/\sqrt{6} \end{pmatrix} \quad \text{og} \quad \lambda_2 = 1 \quad \mathbf{u}_2 = \begin{pmatrix} 1/\sqrt{2} \\ -1/\sqrt{2} \\ 0 \end{pmatrix} \quad \text{og} \quad \lambda_3 = 0 \quad \mathbf{u}_3 = \begin{pmatrix} 1/\sqrt{3} \\ 1/\sqrt{3} \\ -1/\sqrt{3} \end{pmatrix}$$

Du kan nå selv sjekke at

$$A = U\Sigma V^T = \begin{pmatrix} 1/\sqrt{6} & 1/\sqrt{2} \\ 1/\sqrt{6} & -1/\sqrt{2} \\ 2/\sqrt{6} & 0 \end{pmatrix} \begin{pmatrix} \sqrt{3} & 0 \\ 0 & 1 \end{pmatrix} \begin{pmatrix} 1/\sqrt{2} & 1/\sqrt{2} \\ 1/\sqrt{2} & -1/\sqrt{2} \end{pmatrix}$$

Dette kalles egentlig **reduisert svd**. Vi kan inkludere den siste egenvektoren til AA^T , og skrive

$$A = \begin{pmatrix} 1/\sqrt{6} & 1/\sqrt{2} & 1/\sqrt{3} \\ 1/\sqrt{6} & -1/\sqrt{2} & 1/\sqrt{3} \\ 2/\sqrt{6} & 0 & -1/\sqrt{3} \end{pmatrix} \begin{pmatrix} \sqrt{3} & 0 \\ 0 & 1 \\ 0 & 0 \end{pmatrix} \begin{pmatrix} 1/\sqrt{2} & 1/\sqrt{2} \\ 1/\sqrt{2} & -1/\sqrt{2} \end{pmatrix}$$

som kalles **full svd**.