

## Felanalys

### Approximationsfel

Datorer representerar nästan alla tal approximativt.

Notation Låt  $x \in \mathbb{R}$ . En APPROXIMATION av  $x$  betecknas  $\hat{x}$ .

Ex.  $x = 3.141592\dots$   $\hat{x} = 3.14$

$$f(x) = e^x \quad \hat{f}(x) = 1 + x + \frac{1}{2}x^2$$

Two sätt att beskriva felet

Absoluta felet:  $\delta x := \hat{x} - x$

Relativa felet:  $\frac{\delta x}{x} = \frac{\hat{x} - x}{x} = \frac{\text{"absoluta felet"}}{\text{"exakta värdet"}}$

Ex.  $x = \pi$ ,  $\hat{x} = 3.14$

$$\delta x \approx -0.15927 \cdot 10^{-2}$$

↑  
OBS tecken

$$\frac{\delta x}{x} \approx -0.508 \cdot 10^{-3} \quad (*)$$

Om man inte känner  $x$  kan relativa felet approximeras  $\frac{\delta x}{x} \approx \frac{\delta \hat{x}}{\hat{x}}$  (om  $\hat{x} \neq 0$ )

### Felgränser

Konstanter  $c_1, c_2$  är FELGRÄNSER för respektive fel om:

$$|\delta x| \leq c_1, \quad \left| \frac{\delta x}{x} \right| \leq c_2$$

(\*) är  $c_1 = 0.2 \cdot 10^{-2} \approx c_2 = 0.6 \cdot 10^{-3}$

Om det absoluta felet uppfyller  
 $|\delta x| \leq 0.5 \cdot 10^{-n}$  sägs att approximationen  
 $\hat{x}$  har (minst)  $n$  KORREKTA DECIMALER  
OBS:  $n$  kan vara negativ!

OBS! Ej som  
i boken

Om det relativa felet uppfyller  
 $|\delta x/x| < 0.5 \cdot 10^{-n}$  säger vi att approximationen  
 $\hat{x}$  har (minst)  $n$  SIGNIFIKANTA SIFFROR.

Ex  $x = \pi$   $\hat{x} = 3.14$

$\Rightarrow$  2 korrekta decimaler, 2 signifikanta siffror

### Fel fortplantning

Antag att vi har en funktion / algoritme  
 $f: I \rightarrow \mathbb{R}$ ,  $I \subset \mathbb{R}$  och att vi vill beräkna  
 $f(x)$  för  $x \in I$ .

Fel fortplantning studerar hur fel i indata  
 $\hat{x} - x$  fortplantar sig till fel i utdata  $f(\hat{x}) - f(x)$ .

Om vi antar att  $f \in C^1(I)$  ger MV-satsen:

$$\begin{aligned} \delta f(x) &= f(\hat{x}) - f(x) = f'(x + \theta(\hat{x} - x))(\hat{x} - x) = \\ &= f'(x + \theta \delta x) \delta x \quad \text{där } \theta \in [0, 1] \end{aligned}$$

OBS: |utdatafel| > |indatafel| om  $|f'| < 1$   
och vice versa.

Om inte  $\theta$  eller  $x$  är bekanta används  
FÖRSTA ORDNINGENS APPROXIMATIVA  
FEL FORTPLANTNINGSFORMEL

$$\delta f(x) \approx f'(\hat{x}) \delta x$$

Med  $\delta f(x) \approx f'(\hat{x}) \delta x$  blir felgränser:

$$|\delta f(x)| \leq |f'(\hat{x})| |\delta x| \quad \Leftrightarrow \quad \left| \frac{\delta f(x)}{f(\hat{x})} \right| \leq \left| \frac{f'(\hat{x})}{f(\hat{x})} \right| |\delta x|$$

Exempel Volymen av ett klot m. radie  $r$ .

Antag att vi mäter  $\hat{r}$  med 1% relativ fel

Ange felgräns för relativfelet för volymbestämningen

$$V(r) = \frac{4}{3} \pi r^3 \Rightarrow V'(r) = 4 \pi r^2$$

Relativfelet ger

$$\Rightarrow |\delta r| \leq 0.01 |r| \leq 0.01 |\hat{r}| \quad (\text{känner ej } r)$$

Approximativa felfortplantningsformeln ger:

$$\left| \frac{\delta V(r)}{V(\hat{r})} \right| \leq \left| \frac{V'(\hat{r})}{V(\hat{r})} \right| |\delta r| \leq \left| \frac{4 \pi \hat{r}^2}{(4/3) \pi \hat{r}^3} \right| \cdot |\hat{r}| = 0.03$$

Svar: 1% relativ fel i indata ger 3% relativ fel i utdata.

### Högre ordnings felapproximation

$$\delta f(x) = f'(\hat{x}) \delta x$$

Om  $f'(\hat{x}) \approx 0$  är approx optimistisk

Om  $f \in C^2(I)$  kan man härleda:

$$\delta f(x) = f'(x) \delta x + f''(x + \theta \delta x) \delta x^2 \cdot \frac{1}{2} \quad \theta \in [0, 1]$$

Na för vi  $\delta f(x) = \frac{1}{2} f''(x + \theta \delta x) \delta x^2$  om  $f'(\hat{x}) \approx 0$

Ex  $f(x) = x^2 + 2x + 1 \quad \hat{x} = -1 \approx x \quad \Leftrightarrow \quad \left| \frac{\hat{x} - x}{x} \right| \leq 0.01$

$$f'(x) = 2x + 2 \Rightarrow f'(\hat{x}) = 0$$

$$\text{Använd } \delta f(x) \approx f''(x) \delta x^2 / 2$$

$$\Rightarrow \left| \frac{\delta f(x)}{f(\hat{x})} \right| \leq \left| \frac{f''(\hat{x})}{f(\hat{x})} \right| \delta x^2 / 2 \leq 0.5 \cdot 10^{-4}$$

## Felfortplantning i flera variabler

Låt  $x \in \mathbb{R}^n$  &  $\hat{x}$  vara en approx av  $x$ .

Generalisering:

Absolut fel:  $\delta x = \hat{x} - x$

Relativ fel:  $\frac{\|\delta x\|}{\|x\|}$

Felgränser:  $\|\delta x\| \leq c_1$ ,  $\frac{\|\delta x\|}{\|x\|} \leq c_2$

Om  $f \in C^1(I)$  där  $I \subset \mathbb{R}^n$  kan felfortplantningen

från indata  $\hat{x} = x + \delta x$  till fel i utdata

$f(\hat{x}) = f(x) + \delta f(x)$  skattas:

$$\delta f(x) = f(\hat{x}) - f(x) = \int_0^1 \frac{d}{ds} f(x + s\delta x) ds =$$

$$= \sum_{k=1}^m \frac{\partial f}{\partial x_k}(x + \theta \delta x) \delta x_k \quad \theta \in [0, 1]$$

Approximation om  $x$  är obekant:

$$\delta f(x) \approx \nabla f(\hat{x}) \cdot \delta x$$

Ex Hörled formel för relativa felet för multiplikation

$$f(x_1, x_2) = x_1 x_2$$

$$|f(\hat{x}) - f(x)| = |(x_1 + \delta x_1)(x_2 + \delta x_2) - x_1 x_2| =$$

$$= |x_1 \delta x_2 + x_2 \delta x_1 + \underbrace{\delta x_1 \delta x_2}_{\text{försunbar}}| \leq |x_1 \delta x_2 + x_2 \delta x_1|$$

$$\Rightarrow \left| \frac{\delta f(x)}{f(x)} \right| \leq \left| \frac{x_1 \delta x_2 + x_2 \delta x_1}{x_1 x_2} \right| \leq \left| \frac{\delta x_1}{x_1} \right| + \left| \frac{\delta x_2}{x_2} \right|$$



## Konditionstal

### Def (Relativa) KONDITIONSTALET

definieras, som:

$$\kappa(x) = \lim_{\delta \rightarrow 0^+} \max_{\|\delta x\| < \delta} \left( \frac{|\delta f(x)|}{|f(x)|} / \frac{\|\delta x\|}{\|x\|} \right) \approx$$
$$\approx \frac{\|\text{Relativ fel utdata}\|}{\|\text{Relativ fel indata}\|} \quad (\text{största felet men för litet steg})$$

### Tolkning

Relativt indatafel  $\kappa$  kan ge relativ utdatafel  $\kappa \alpha$   
Ett problem med litet konditionstal sägs  
vara **STABILT** eller **VÄLKONDITIONERAD**.  
Tvärtom, stort  $\kappa \rightarrow$  **INSTABILT** eller  
**ILLAKONDITIONERAD**.

Litet betyder ungefär  $\kappa \in (0, 10)$ , stort  $\kappa \approx 10^8$

$$|\delta f(x)| \leq \|\nabla f(x)\| \|\delta x\|$$

$$\Rightarrow \kappa(x) \leq \|x\| \frac{\|\nabla f(x)\|}{|f(x)|}$$

Ex  $f(x) = cx$   $c$  konstant

$$\Rightarrow \kappa(x) \leq |x| \frac{|c|}{|cx|} = 1$$

d.v.s, multiplikation  $m$  konstant ger  
relativt indatafel = relativt utdatafel  
(OBS! absolut blir annorlunda)

$$\underline{\text{Ex}} \quad f(x_1, x_2) = x_1 - x_2 \quad x = (1; 1 + 10^{-100})$$

Vi vill beräkna  $f(x)$

$$K(x) \approx \|x\| \frac{\|\nabla f(x)\|}{|f(x)|} = \sqrt{2} \frac{\|(1, -1)\|}{|1 - (1 + 10^{-100})|} \approx 2 \cdot 10^{100}$$

↑  
STORT!

OBS:  $x_1 - x_2$  är en

instabil operation då  $x_1 \approx x_2$

Senare i kursen: fungerar även för metriser!  
(matrisnormer)

### Approximativa algoritmer

Den exakta funktionen  $f$  kan behöva ersättas med en approximativ funktion  $\hat{f}$ .

Def FRAMÅTFELET för  $(f, \hat{f}, x)$  ges av  $\hat{f}(x) - f(x)$ , som beskriver approximativa algoritmens fel i utdata.

Antag att  $f$  är inverterbar nära  $x$ .

Då finns ett indatavärde  $\hat{x} = f^{-1}(\hat{f}(x))$  så att

$$f(\hat{x}) = f(f^{-1}(\hat{f}(x))) = \hat{f}(x)$$

Def BAKÅTFELET för  $(f, \hat{f}, x)$  ges av

$$\hat{x} - x = f^{-1}(\hat{f}(x)) - x$$

och motsvarar det absoluta fel  $\delta x$  som ger fel förplantningen  $f(\hat{x}) - f(x) = \hat{f}(x) - f(x)$

Ex  $f(x) = e^x$   $\hat{f}(x) = 1 + x + \frac{1}{2}x^2 + \frac{1}{6}x^3$   $x=1$

$\hat{f}(1) = 8/3$   $f(1) = e$

Framåttfelet:

$\hat{f}(1) - f(1) = \frac{8}{3} - e = -0,051615\dots$

Bakåttfelet  $f^{-1}(x) = \ln(x)$


$\Rightarrow \hat{x} = f^{-1}(\hat{f}(1)) = \ln(8/3)$

Så bakåttfelet är

$\hat{x} - x = \ln(8/3) - 1 = -0,019171\dots$

Numerisk algoritm & felfortplantning

Problem: Beräkna  $I = \int_0^1 g(x) dx$



Förenklat problem:

$\hat{I} = \int_0^1 \hat{g}(x) dx$

Numerisk algoritm:

$\hat{I} = \sum_{i=0}^n (g(x_i) + g(x_{i+1})) \frac{(x_{i+1} - x_i)}{2}$  ← approx

Vi kan använda konditionstal även för algoritmer.

$$\kappa(x) = \frac{\|\text{rel. utdatafel}\|}{\|\text{rel. indatafel}\|}$$

Def En numerisk algoritm  $\hat{f} \approx f$  sägs vara STABIL för  $x \neq 0$  om relativa bakåttfelets storlek

$$\frac{|f^{-1}(\hat{f}(x)) - x|}{\|x\|}$$

är litet.

Vi använder bakåttfel för att det ofta är enklare än framåttfel.

Betrakta  $f(b) = A^{-1}b$  &  $\hat{f}(b) = (A^{-1} + \varepsilon I)b$

Framåtanalys ger framåtstabiliteten:

$$\frac{\|\hat{f}(b) - f(b)\|}{\|f(b)\|}$$

Svårt om vi ej vet  $A^{-1}$ !

I bakåtanalysen använder vi  $f^{-1}(y) = Ay$  vilket är lättare.

## Datoraritmetik

Olika talformat:

o signed int32 (eller 64)

- Alla heltal  $[-2^{31}, 2^{31}-1]$  kan lagras

o single precision floating point (32 bitar)  
(eller double precis..., 64 bitar)

I matlab är default double 64. Man kan skriva t.ex.  $y = \text{int64}(\pi)$ ;

## Flyttal

ett flyttalssystem definieras av  $F = (\beta, t, L, U)$

o  $\beta \in \mathbb{N} \setminus \{1\}$  är basen till systemet

o  $t$  är antalet siffror

o  $L, U$  är lägsta resp. högsta värdet hos exponenten.

Varje flyttal  $x$  i  $F$  representeras:

$$x = \pm (d_0 + d_1\beta^{-1} + d_2\beta^{-2} + \dots + d_{t-1}\beta^{1-t})\beta^e$$

där  $1 \leq d_0 \leq \beta - 1$ ,  $0 \leq d_i \leq \beta - 1$  för  $1 \leq i \leq t-1$ ,  $L \leq e \leq U$

Den första faktorn kallas MANTISSA

Notation: Med mantissan  $m = d_0.d_1\dots d_{t-1}$  kan talet ovan skrivas  $x = \pm m \cdot \beta^e$


Ex Flyttalssystemet IEEE-754 beskrivs av

$$(\beta = 2, t = 53, L = -1022, U = 1023)$$

t.ex.  $x = 2.75 = (1 + 0 \cdot 2^{-1} + 2^{-2} + 2^{-3}) \cdot 2^1$  skrivs

$$1.0110\dots 0_2 \cdot 2^1$$

Hur det lagras



Underflow, Overflow  $\approx$  Heltalsavrundning

$$\min(F \cap \mathbb{R}_+) = 1.0000 \cdot \beta^t := \text{UFL} \quad \text{underflow level}$$

motsvarande för OFL

För att konvertera/avrunda reella tal till flyttal!

närmsta  
tal i  $F$

$$fl(x) := \begin{cases} \arg \min_{y \in F} (y - x) & \text{Om } \text{UFL} \leq |x| \leq \text{OFL} \\ \text{Inf.} & \text{om } |x| > \text{OFL} \end{cases}$$

(förenklat)

Tal  $|x| < \text{UFL}$  (t.ex. 0) ingår formellt ej i  $F$

I IEEE släpps normaliseringskravet, d.ä. för vara 0.

Vi får tal under UFL genom att gradvis flytta bak 1 i mantissan, och 0 genom att ha 0 överallt.

För alla  $\text{UFL} < |x| < \text{OFL}$ :

$$\left| \frac{fl(x) - x}{x} \right| \leq 0.5 \cdot \beta^{1-t}$$

(För  $|x| < \text{UFL}$  tappar vi denna precision!)

d.v.s.  $fl(x)$  approximerar  $x$  m.  $t-1$  signifikanta siffror.

Flyttalsaritmetik görs i ett utökat register för att bevara precision.

OBS generellt gäller inte att

$$fl(fl(a+b)+c) = fl(a+fl(b+c))$$



Utskiftning innebär att vi tappar noggrannhet  
då tal med olika storlek adderas.

Strategi för att undvika utskiftning:  
börja addera de minsta talen.

Kancellation innebär noggrannhetsförlust vid  
subtraktion av två nästan lika stora tal.

Strategi: skriv om problemet.

Ex:  $\sqrt{x^2+1} - x = \dots = \frac{1}{\sqrt{x^2+1} + x}$

↑ risk för cancellation      bättre! ↓

Framåtanalys av flyttalsystem

$$f(x) = x^2 \quad \hat{f} = fl(fl(x)^2)$$

Låt oss verifiera  $\left| \frac{\hat{f}(x) - f(x)}{f(x)} \right| = \mathcal{O}(\mu)$

$fl(x) = x(1+\delta)$  där  $\delta \in [-\mu, \mu]$ . där  $\mu$  är maskintalet  
 $\Rightarrow \hat{f}(x) = x^2(1+\delta_1)^2(1+\delta_2)$

$$\Rightarrow \left| \frac{\hat{f}(x) - f(x)}{f(x)} \right| = |(1+\delta_1)^2(1+\delta_2) - 1| = \mathcal{O}(\mu)$$

Bakåtanalys

Rep:  $\hat{f}$  &  $f$  är stabil om bakåtfelet är litet.

d.v.s.  $\left| \frac{f^{-1}(\hat{f}(x)) - x}{x} \right| = \mathcal{O}(\mu)$

Låt oss verifiera att  $\hat{f}(x) = fl(fl(x)^2)$  är stabil.

$$f^{-1}(\hat{f}(x)) = x((1+\delta_1)\sqrt{(1+\delta_2)}) = x(1+\delta_1 + \frac{\delta_2}{2} + \mathcal{O}(\delta^2))$$

$$\Rightarrow \left| \frac{f^{-1}(\hat{f}(x)) - x}{x} \right| \leq \left| \frac{x(\delta_1 + \frac{\delta_2}{2})}{x} \right| = \mathcal{O}(\mu)$$

OK!

Numerisk lösning av ekvationer

Idag: Icke-linjära ekvationer / 1 variabel

$$f: \mathbb{R} \rightarrow \mathbb{R}, f(x) = 0$$

Endast i undantagsfall har vi explicita lösningar. Vi behöver numeriska metoder.

$$\text{Ex: } \frac{\pi}{2} - \arcsin x - x\sqrt{1-x^2} - 1.24 = 0$$

Har en lösning  $x^* = 0.16617..$ Def En lösning eller ROT  $x^*$  till  $f(x) = 0$ kallas ENKELROT om  $f'(x) \neq 0$ ,MULTIPELROT med MULTIPLICITET  $m$ om  $f'(x^*) = f''(x^*) = \dots = f^{(m-1)}(x^*) = 0$  men

$$f^{(m)}(x^*) \neq 0$$

$$\text{Ex: } f(x) = x^4 - 6x^3 + 2x^2 - 10x + 3 = (x-1)^3(x-3)$$

har rot  $x^* = 1$  med multiplicitet 3 och en enkelrot  $x^* = 3$ .IterationsmetoderFörsta approximation  $x_0$ Beräkna en talföljd  $\{x_k\}_{k=1}^{\infty}$ Metoden konvergerar om  $\lim_{k \rightarrow \infty} x_k = x^*$  där  $f(x^*) = 0$ Konvergensordning  $q$  är största  $q > 0$  s.a.

$$\lim_{k \rightarrow \infty} \frac{|x_{k+1} - x^*|}{|x_k - x^*|^q} = c < \infty$$

 $c$  kallas asymptotiska felkonstanten

## Olika fall av konvergens:

- $q = 1$ : Linjär konvergens
- $q > 0$ : Superlinjär konvergens
- $q = 2$ : Kvadratisk konvergens

## Newtons metod

Antag  $x_0$  approximativ rot.

Taylorutveckla kring  $x_0$

$$f(x) \approx f(x_0) + f'(x_0)(x - x_0)$$

Har linjäriserat kring  $x_0$

$\Rightarrow$  Lokalt linjär modell:

$$f(x_0) + f'(x_0)(x - x_0) = 0$$

$$\Rightarrow \boxed{x = x_0 - \frac{f(x_0)}{f'(x_0)}} \quad \leftarrow \text{troligtvis en bättre approximation!}$$

Upprepa med  $x_1$  istället för  $x_0$  ...

$$\Rightarrow \boxed{x_{k+1} = x_k - \frac{f(x_k)}{f'(x_k)} \quad k = 0, 1, \dots}$$

Detta kallas Newtons metod.

## Konvergens

Om  $x_0$  är långt från  $x^*$  kan metoden divergera.


Antag att  $f(x^*) = 0$ ,  $f'(x^*) \neq 0$ ,  $x_k \rightarrow x^*$

Taylorutveckla kring  $x_k$ :

$$0 = f(x^*) = f(x_k) + f'(x_k)(x^* - x_k) + \frac{1}{2} f''(\xi_k) (x^* - x_k)^2 \quad (*)$$

Newtoniterationen ger:  $x_{k+1} = x_k - \frac{f(x_k)}{f'(x_k)}$

$$\Leftrightarrow 0 = f'(x_k)(x_{k+1} - x_k) + f(x_k) \quad (**)$$



→ (\*) - (\*\*) ger:

$$0 = f'(x_k)(x^* - x_{k+1}) + \frac{1}{2} f''(\xi_k)(x^* - x_k)^2$$

$$\Rightarrow |x_{k+1} - x^*| = \frac{|f''(\xi_k)|}{2|f'(x_k)|} |x_k - x^*|^2$$

$$\Rightarrow \frac{|x_{k+1} - x^*|}{|x_k - x^*|^2} \xrightarrow{k \rightarrow \infty} c \quad \text{där } c$$

$$c = \lim_{k \rightarrow \infty} \frac{|f''(\xi_k)|}{2|f'(x_k)|} = \frac{|f''(x^*)|}{2|f'(x^*)|} < \infty \quad \text{ent. ant.}$$

Alltså: Om metoden konvergerar mot en enkelrot så konvergerar den kvadratisk.

Detta innebär att den ungefär fördubblar antalet korrekta decimaler per iteration.

Linjär konvergens vid multipelrot.

Alternativ om  $x^*$  har multiplicitet  $m$ :

$$x_{k+1} = x_k - m \frac{f(x_k)}{f'(x_k)} \quad \text{ger kvadratisk konvergens}$$

Nackdel: behöver känna till multiplicitet.



## Sekantmetoden

Newtons metod kräver uttryck för derivatan. Om uttryck saknas, approximeras med differenskvot:

$$f'(x_k) \approx \frac{f(x_k) - f(x_{k-1})}{x_k - x_{k-1}}$$

Detta ger sekantmetoden:

$$x_{k+1} = x_k - f(x_k) \frac{x_k - x_{k-1}}{f(x_k) - f(x_{k-1})} \quad k = 1, 2, \dots$$

Notera att två startpunkter  $x_0 \neq x_1$  krävs.

Konvergens vid enkelrot ger:  $q = 1,618\dots$  (superlinjär)

Sekantmetoden är alltså långsammare än Newton.

## Fixpunktsiterationer

Skriv om  $f(x) = 0$  på formen  $x = g(x)$  (addera t.ex.  $x$  på båda sidor). Vissa sätt är bättre än andra.

Iterera:  $x_{k+1} = g(x_k)$   $k = 0, 1, \dots$  med  $x_0$  startapprox.

Om vi har konvergens  $x_k \rightarrow x^* \Rightarrow x^* = g(x^*)$   
d.v.s.  $x^*$  är fixpunkt till  $g$ .

Lokal konvergens om  $|g'(x^*)| < 1$ . Mindre  $|g'(x^*)|$  ger snabbare konvergens.

Ex:  $g(x) = x - \frac{f(x)}{f'(x)}$  ger Newtons metod.

$$\begin{aligned} g'(x) &= 1 - \frac{f'(x)f'(x) - f(x)f''(x)}{(f'(x))^2} = \\ &= \frac{f(x)f''(x)}{(f'(x))^2} \Rightarrow g'(x^*) = \frac{f(x^*)f''(x^*)}{(f'(x^*))^2} = 0 \end{aligned}$$

Newtons metod "optimal",  $|g'(x^*)| = 0$

Ex  $x^3 + x - 1 = 0$  kan skrivas  $x = \underbrace{1 - x^3}_{g(x)}$

$$\Rightarrow g'(x) = -3x^2$$

Beräkna...

$x^* = 0.6823 \Rightarrow |g'(x^*)| \approx 1,40 > 0$  ingen konvergens!

Men  $x = \sqrt[3]{1-x}$  fungerar,


$$g'(x^*) \approx 0,716 < 1$$

### Intervallhalveringsmetoden

Om  $f(x_1) < 0$ ,  $f(x_2) > 0$

Satsen om mellanliggande värde

$\Rightarrow \exists x^* \in (x_1, x_2)$  s.a.  $f(x^*) = 0$  (om  $f$  kont)



Bilda  $x_3 = \frac{1}{2}(x_1 + x_2)$ .

$f(x_3) < 0 \Rightarrow x^* \in (x_3, x_2)$

$f(x_3) > 0 \Rightarrow x^* \in (x_1, x_3)$

$f(x_3) = 0 \Rightarrow x^* = x_3$

Upprepa!

Ger alltid konvergens men är långsam. Kan kombineras med andra metoder. Ger s.k. hybridmetoder.

### Lösning noggrannhet

Ändligt antal iterationer och avrundningsfel ger att vi måste acceptera  $f(\hat{x}) \neq 0$ .

Felet  $\delta x = \hat{x} - x^*$  kan vi estimerar m.h.a.

Taylorutvecklingen:

$$f(\hat{x}) = f(x^* + \delta x) = \cancel{f(x^*)} + f'(x^*)\delta x + \mathcal{O}(\delta x^2)$$

$$\text{Små } \delta x \Rightarrow f(\hat{x}) = f'(\hat{x})\delta x \Rightarrow \delta x \approx \frac{f(\hat{x})}{f'(\hat{x})}$$

Detta är en metodoberoende feluppskattning:

$$|\hat{x} - x^*| \approx \left| \frac{f(\hat{x})}{f'(\hat{x})} \right|$$






—▷

$$|\tilde{x} - x^*| \approx \left| \frac{f(\tilde{x})}{f'(\tilde{x})} \right|$$

Vi ser att det är illa konditionerat om  $|f'(\tilde{x})|$  är litet.



flack kurva

$\Rightarrow$  liten höjledsförändring  
ger stor sidledsförändring.

Om  $x^*$  rot med multiplicitet  $m$ :

Längre Taylorutveckling:  $\delta x^m = m! \frac{f(\tilde{x})}{f^{(m)}(\tilde{x})}$  istället

Lana 200325

## Linjära rum - C

Kallas även vektorrum

Generalisering av  $\mathbb{R}^n$

Vad elementen är spelar ingen roll, bara hur de samverkar.

### Def

EH LINJÄRT RUM eller VEKTORRUM är en mängd  $V$ , tillsammans med tal (skalärer)  $K$  (oftast  $K = \mathbb{R}$ , ibland  $K = \mathbb{C}$ ) om följande axiom gäller:

$$\textcircled{1} \forall u, v \in V \exists! u \oplus v \in V$$

$$\textcircled{2} \forall u \in V \exists \alpha \in K \exists! \alpha \odot u \in V$$

och följande räknelagar gäller:

$$\textcircled{3} u \oplus v = v \oplus u \quad \forall u, v \in V$$

$$\textcircled{4} (u \oplus v) \oplus w = u \oplus (v \oplus w) \quad \forall u, v, w \in V$$

$$\textcircled{5} \exists 0 \in V: 0 \oplus u = u \oplus 0 = u \quad \forall u \in V$$

$$\textcircled{6} \forall u \in V \exists -u \in V: u \oplus (-u) = (-u) \oplus u = 0$$

$$\textcircled{7} \alpha \odot (\beta \odot u) = (\alpha\beta) \odot u \quad \forall \alpha, \beta \in K \quad \forall u \in V$$

$$\textcircled{8} \alpha \odot (u \oplus v) = \alpha \odot u \oplus \alpha \odot v \quad \forall \alpha \in K \quad \forall u, v \in V$$



$$\textcircled{9} (\alpha + \beta) \odot u = \alpha \odot u \oplus \beta \odot u \quad \forall \alpha, \beta \in K \quad \forall u \in V$$

$$\textcircled{10} \exists 1 \in K: 1 \odot u = u \quad \forall u \in V$$

### Notation/begrepp

Element i  $V$  kallas VEKTORER (även om de är t.ex. funktioner). Om  $K = \mathbb{C}$  kallas  $V$  ett KOMPLEXT LINJÄRT RUM.

## Ex: Geometrisk vektorer



10.

etc.

$$u \oplus v = v \oplus u$$

$$\exists -u$$

$$\exists 0$$

o  $V = \mathbb{R}^n$  (euklidiska rummet)

o  $x \oplus y = (x_1 + y_1, \dots, x_n + y_n)$

o  $\alpha \odot x = (\alpha x_1, \dots, \alpha x_n)$

etc

o  $m \times n$  matriser

o Mängden av alla reellvärda funktioner

$$(f \oplus g)(t) = f(t) + g(t)$$

$$(\alpha \cdot f)(t) = \alpha f(t)$$

$$0(t) \equiv 0$$

$$(-f)(t) = -f(t)$$

etc.

Räkelagarna följer här av de från  $\mathbb{R}$  (se ovan)

o Andra ordningens differentialoperatorer verkande på  $C^2$

o  $V = \mathbb{R}^+$ , men ha "gönger" som  $\oplus$   $\odot$  exponent som  $\odot$   
(mer på storgruppsövningen)

## Def

En delmängd  $M \subseteq V$  kallas ett UNDERRUM av ett linjärt rum  $V$  om  $M$  är ett linjärt rum med avseende på samma operationer.

## Sats

En icke-tom delmängd  $M$  av ett linjärt rum  $V$  är ett underrum av  $V$  om

(\*)  $u, v \in M \Rightarrow u \oplus v \in M$ ,  $u \in M, \alpha \in \mathbb{R} \Rightarrow \alpha \odot u \in M$   
eller ekvivalent:

$$u, v \in M \quad \alpha, \beta \in \mathbb{R} \Rightarrow \alpha \odot u \oplus \beta \odot v \in M$$

## Bevis

$\Rightarrow$  Vill visa:  $M$  underrum till  $V \Rightarrow (*)$  gäller

Det följer direkt av axion ①  $\Leftrightarrow$  ②

$\Leftarrow$  Antag att  $M$  uppfyller (\*).

①  $\Leftrightarrow$  ② uppfylls direkt.

Låt  $u \in M$  ( $M$  icke-tom) och  $\alpha = 0$ .

$V$  är ett linjärt rum, så  $\alpha \odot 0 = 0$

(\*) ger därför:  $0 \in M$

Tag  $\alpha = -1$  och  $u \in M$  godtyckligt.

$V$  är ett linjärt rum, så  $-u = (-1) \odot u \in M$

(\*) ger därför  $-u \in M$

③ - ⑩ gäller för alla element i  $V$ , och således också för alla element i  $M$ .

Alla axiom är verifierade.

□


## Exempel på underrum

Underrum till 3 dim. euklidiska rummet  
( $\mathbb{R}^3$  utan koordinatsystem typ)

Identifiera punkter med Ortsvektorer.


Underrum:

- Origo (dim 0)
- Räta linjer genom origo (dim 1)
- Plan genom origo (dim 2)
- Hela euklidiska rummet (dim 3)



OBS: linjen/planet måste gå genom origo!

En godtycklig linje är en translation av en linje genom origo.



Def

En delmängd  $M \subseteq V$  kallas  
AFFIN om det finns en

vektor  $u_0 \in V$  och ett underrum

$U$  av  $V$  så att  $M = u_0 \oplus U = \{u_0 \oplus u : u \in U\}$

## Fler exempel på underrum

Låt  $V = \mathbb{R}^{n \times n}$  ( $n \times n$  matriser), linjärt rum

Låt  $M$  vara alla anti-symmetriska  $n \times n$  matriser  
(d.v.s.  $A \in M \Rightarrow A^T = -A$ )

$M \subseteq V$  icke-tom ty  $0 \in M$ . (nollmatrisen)

$$A, B \in M \Rightarrow (A \oplus B)^T = A^T \oplus B^T = (-A) \oplus (-B) = -(A \oplus B)$$

Så  $A, B \in M \Rightarrow A \oplus B \in M$ , och uppenbart  $\lambda \oplus A \in M$

$\Rightarrow M$  är ett underrum

Ex  $V = F([a, b])$  reellvärda funktioner på  $[a, b]$

Har många intressanta underrum (funktionsrum)

a)  $C([a, b])$ , kontinuerliga funktioner på  $[a, b]$

b)  $C^k([a, b])$ ,  $k$  ggr kontinuerligt deriverbara funktioner på  $[a, b]$ .

c)  $P_n$ , polynom av grad högst  $n$  Annars ej slutet under + ∞.

d)  $L^2((a, b))$ , f.s.a.  $\exists \int_a^b f^2(t) dt < \infty$

För a) - c) är det enkelt att kontrollera

$$f, g \in M, \alpha \in \mathbb{R} \Rightarrow f + g \in M, \alpha f \in M$$

Bevis för d)

$$0 \leq (a-b)^2 = a^2 - 2ab + b^2 \text{ ger } ab \leq \frac{1}{2}(a^2 + b^2)$$

$$\Rightarrow \underline{(a+b)^2 = a^2 + 2ab + b^2 \leq 2a^2 + 2b^2}$$

Om  $f, g \in L^2((c, d))$

$$\int_c^d (f(t) + g(t))^2 dt \leq 2 \int_c^d f^2(t) dt + 2 \int_c^d g^2(t) dt < \infty$$

$$\Rightarrow f + g \in L^2((c, d))$$

Om  $\alpha \in \mathbb{R}, f \in L^2((c, d))$

$$\int_c^d (\alpha f(t))^2 dt = \alpha^2 \int_c^d f^2(t) dt < \infty$$

$$\Rightarrow \alpha f \in L^2((c, d))$$

Så  $L^2((c, d))$  underrum till  $F((c, d))$





## Ex

Lösningar till homogena differentialekvationer kan också vara underrum.

Låt  $V$  vara funktioner  $f(t, x)$  med kont. andraderivator för  $t \in (0, 1)$ ,  $x \in (0, 1)$ . Då är  $V$  ett linjärt rum.

$$\text{Låt } M = \left\{ f : \frac{\partial^2 f}{\partial t^2} - \frac{\partial^2 f}{\partial x^2} = 0 \right\}$$

$M$  är ett underrum ty:

$f=0$  är en lösning, så  $M$  är icke-tom.

Om  $f, g \in M$  o  $\alpha, \beta \in \mathbb{R}$  Låt  $\alpha f + \beta g =: h$

$$\frac{\partial^2 h}{\partial t^2} - \frac{\partial^2 h}{\partial x^2} = \alpha \frac{\partial^2 f}{\partial t^2} + \beta \frac{\partial^2 g}{\partial t^2} + \alpha \frac{\partial^2 f}{\partial x^2} - \beta \frac{\partial^2 g}{\partial x^2} = 0$$

$$\Rightarrow h \in M$$

## Ex

Låt  $V \subset C([0, \infty))$  sådana att  $f \in V$  om

$$\int_0^{\infty} f^2(x) e^{-x} dx < \infty \quad (\text{viktat } L^2 \text{ rum})$$

$V$  underrum ty:

Om  $f, g \in V$ ,  $\alpha \in \mathbb{R}$

$$\int_0^{\infty} (f(x) + g(x))^2 e^{-x} dx = \int_0^{\infty} 2(f^2(x) + g^2(x)) e^{-x} dx =$$

$$= 2 \int_0^{\infty} f^2(x) e^{-x} dx + 2 \int_0^{\infty} g^2(x) e^{-x} dx < \infty$$

$$\int_0^{\infty} (\alpha f(x))^2 dx = \alpha^2 \int_0^{\infty} f^2(x) dx < \infty$$

$$\Rightarrow f+g \in V, \alpha f \in V.$$

Linjära avbildningar

Skriver fr.o.m. nu  $u+v \in \alpha u$  istället för  $u \oplus v$   
och  $\alpha \circ u$

Rep: Sats [1.1.]

•  $0 \neq M \subset V$   $V$  linj. rum

$M$  underrum om  $u, v \in M, \alpha, \beta \in \mathbb{R} \Rightarrow \alpha u + \beta v \in M$

Linjära avbildningar

Def: Låt  $U, V$  vara reella linjära rum.

En avbildning (funktion/transformation)  $F: U \rightarrow V$

kallas **LINJÄR** om

$$F(u+v) = F(u) + F(v) \quad \forall u, v \in U \text{ och}$$

$$F(\alpha u) = \alpha F(u) \quad \forall \alpha \in \mathbb{R}, u \in U$$

eller ekvivalent

$$F(\alpha u + \beta v) = \alpha F(u) + \beta F(v) \quad \forall \alpha, \beta \in \mathbb{R}, u, v \in U$$

Om  $U=V$  säger vi att  $F$  är en linjär avbildning på  $V$ .

Om  $u \in V$  är i  $\mathbb{R}^n$  är  $F$  linjär om den är på formen  $F(x) = Ax$  där  $A$  är en  $n \times m$ -matris.

OBS:  $\alpha=0$  ger  $F(0)=0$  (bra kontroll)

Exempel på linjära avbildningar av geo. vek.  
spegling, vridning, skalning, projektion

Ex Låt  $U = \mathbb{R}^n$ ,  $V = \mathbb{R}^m$ ,  $A$   $m \times n$  matris  
 $\Rightarrow F(x) = Ax$  linjär avbildning

Ex Avbildningar på funktionsrum kallas operatorer

Låt  $U = C'([0, 1])$ ,  $V = C([0, 1])$  och  $F(f) = Df = f'$

$F: U \rightarrow V$  är linjär avbildning ty

$$F(\alpha f + \beta g) = D(\alpha f + \beta g) = \alpha Df + \beta Dg = \alpha F(f) + \beta F(g)$$

$$\forall f, g \in U, \alpha, \beta \in \mathbb{R}$$

Om  $p(t)$  är ett polynom av grad  $n$  så är  
 $F(f) = p(D)f = (a_n D^n + \dots + a_0 D^0)f = a_n f^n + \dots + a_0 f$   
en linjär avbildning  $F: C^n(\mathbb{R}) \rightarrow C(\mathbb{R})$ , kallas  
linjär differentialoperator. Koefficienterna  
kan bero på  $x$  men inte  $f$ .

Ex Integraloperator:

$F(f) = \int_a^x f(t) dt$  ger  $F: C([a, b]) \rightarrow C([a, b])$ ,  
en linjär avbildning. - (Kontroll som övning)

Def: Låt  $F: U \rightarrow V$  vara linjär avbildning.

NOLLRUMMET för  $F$  är  $N(F) = \{u \in U \mid F(u) = 0\}$

VÄRDERUMMET för  $F$  är  $V(F) = \{F(u) \mid u \in U\}$

---

$N(F)$  är allt som mappar på  $0$

$V(F)$  är allt  $F$  mappar på.

Kontroll av att  $N(F)$  är linjärt:

$$F(0) = 0 \Rightarrow N(F) \neq \emptyset$$

Låt  $u_1, u_2 \in N(F)$ ,  $\alpha, \beta \in \mathbb{R}$

$$F(\alpha u_1 + \beta u_2) \stackrel{\substack{\uparrow \\ F \text{ linjärt}}}{=} \alpha F(u_1) + \beta F(u_2) \stackrel{\substack{\uparrow \\ u_1, u_2 \in N(F)}}{=} 0$$

$$\Rightarrow \alpha u_1 + \beta u_2 \in N(F) \quad \text{OK!}$$

$N(F)$  är därmed ett underrum till  $U$ .

Kontroll av att  $V(F)$  är linjärt.

$$F(0) = 0 \text{ ty } F \text{ linjär} \Rightarrow V(F) \neq \emptyset$$

Låt  $v_1, v_2 \in V(F)$ ,  $\alpha, \beta \in \mathbb{R}$

$$\Rightarrow \exists u_1, u_2 \in U \text{ s.d. } F(u_1) = v_1, F(u_2) = v_2$$

$$\alpha v_1 + \beta v_2 = \alpha F(u_1) + \beta F(u_2) = F(\alpha u_1 + \beta u_2)$$

$$\text{Så } \alpha v_1 + \beta v_2 \in V(F) \quad \text{OK!} \quad \begin{array}{c} \uparrow \\ F \text{ linj} \\ \underbrace{\alpha u_1 + \beta u_2}_{\in U} \end{array}$$

$V(F)$  är därmed ett underrum till  $V$

Ett linjärt ekvationssystem, en linjär differentialekvation eller system av sådana m. fl. kan uttryckas  $F(u) = v$  <sup>(\*)</sup> där  $F: U \rightarrow V$  är en linjär avbildning,  $u$  är sökt och  $v$  känd.

Sats [1.4.] Antag att  $u_p$  är en känd lösning till (\*) (partikulärlösning). Då är  $u \in U$  en lösning till (\*) om och endast om  $u = u_p + u_h$  där  $u_h \in N(F)$

(Lösningsrummet är ett affint rum)

Bevis Då  $F(u_p) = v$  gäller

$$F(u) = v = F(u_p) \stackrel{\substack{\uparrow \\ F \text{ linj}}}{\Leftrightarrow} F(u - u_p) = 0 \Leftrightarrow \underbrace{u - u_p}_{= u_h} \in N(F) \quad \square$$

Lösningarna till  $F(u)=v$  är det affina rummet  $u_p + N(F)$

### Linjärt (0)beroende bas och dimension

Def Låt  $v_1, v_2, \dots, v_p \in V$ ,  $V$  linjärt rum.

$\alpha_1 v_1 + \alpha_2 v_2 + \dots + \alpha_p v_p$  med  $\alpha_j \in \mathbb{R}$  kallas

en LINJÄRKOMBINATION av  $v_1, \dots, v_p$ .

$\text{Span}\{v_1, \dots, v_p\} = \text{Span}\{v_j\}_{j=1}^p$  är mängden av alla linjärkombinationer av  $v_1, \dots, v_p$ .

Kallas LINJÄRA HÖLJET av  $v_1, \dots, v_p$ .

Övning: Visa att  $\text{span}\{v_j\}_{j=1}^p$  är ett underrum av  $V$ .

Def Låt  $u_1, \dots, u_n \in V$ ,  $V$  linjärt rum.

$u_1, \dots, u_n$  sägs SPÄNNA UPP  $V$  om

$V = \text{Span}\{u_i\}_{i=1}^n$  (varje element i  $V$  är en linjärkombination av  $u_1, \dots, u_n$ .)

Def  $u_1, \dots, u_n \in V$  sägs vara

LINJÄRT BEROENDE om

$$(*) \quad \lambda_1 u_1 + \dots + \lambda_n u_n = 0$$

har en icke-trivial lösning. (Något  $\lambda_i \neq 0$ ).

Om (\*) endast har trivial lösning sägs

$u_1, \dots, u_n$  vara LINJÄRT OBEROENDE.

OBS: Om någon  $u_i = 0$  är  $u_1, \dots, u_n$  alltid

linjärt beroende (sätt  $\lambda_i = 1$  & resterande

$\lambda_j = 0$  så är (\*) uppfyllt).

### Lemma [1.1]

Om ingen av  $u_1, \dots, u_n$  är 0 så är följande påståenden ekvivalenta:

(i) De är linjärt beroende

(ii) Någon vektor  $u_i$  med  $i \geq 2$  är en linjärkombination av de föregående.

(iii) Någon vektor  $u_i$  är lin. komb av de övriga.

Bevisidé: (i)  $\Rightarrow$  (ii)  $\Rightarrow$  (iii)  $\Rightarrow$  (i)

(Bevis finns i boken)

### Lemma [1.2]

Om  $u_1, \dots, u_m \in V$  är linjärt oberoende  $\ominus v \in V$  men  $v \notin \text{Span}\{u_i\}_{i=1}^m$  så är  $u_1, \dots, u_m, v$  linjärt oberoende.

Bevis Låt  $U = \text{Span}\{u_1, \dots, u_m\}$ .

$0 \in U$  och  $u_1, \dots, u_m$  är ober. så ingen av  $u_1, \dots, u_m, v$  är 0. Eftersom  $v \notin U$  gäller Lemma 1.1. inte för något  $i$ . Alltså är  $u_1, \dots, u_m, v$  linjärt oberoende.  $\square$

### Def

En uppsättning vektorer  $u_1, \dots, u_n \in V$  som är linjärt oberoende och spänner upp  $V$  kallas en BAS för  $V$ .



## Def

Det maximala antalet  $n$  av linjärt oberoende vektorer i ett linjärt rum  $V$  kallas **DIMENSIONEN** av  $V$ , skrivs  $\dim V = n$ .

Om det inte finns ett maximalt antal sägs  $V$  vara **OÄNDLIGDIMENSIONELLT**.

Om  $V$  bara innehåller nollelementet är  $\dim V = 0$ . (Enda 0-dim vektorrummet).

## Sats: [1.5] $\neq \infty$

Antag  $\dim V = n > 0$ . Då finns en uppsättning av  $n$  linj. ober. vektorer i  $V$ . Varje sådan uppsättning är en bas för  $V$ .

Bevis Låt  $u_1, \dots, u_n$  vara godt. uppsättning  $n$  linj. ober. vektorer i  $V$ .

Definitionen av  $\dim$  ger existensen av minst en sådan uppsättning.

Låt  $v \in V$  vara en godt. vektor.

Fall 1:  $v \notin \text{span}\{u_1, \dots, u_n\}$

[Lma 1.2]  $\Rightarrow u_1, \dots, u_n, v$  linj. ober  $\leftarrow$   $n+1$  st

Detta motsäger att  $n$  är maximala antalet linj. ober vektorer i  $V$ .

Så Fall 2:  $v \in \text{span}\{u_1, \dots, u_n\}$  måste gälla. Detta för  $\forall v \in V$ , ty  $v$  var godt.

$\Rightarrow V = \text{span}\{u_1, \dots, u_n\} \Rightarrow u_1, \dots, u_n$  bas för  $V$ .  $\square$

### Sats [1.6]

Antag  $V = \text{span}\{u_1, \dots, u_n\}$ . Då är varje uppsättning med fler än  $n$  vektorer linjärt beroende.  
(Se bevis från första linjalgkursen.)

### Sats [1.7]

Antag  $V$  ändlig dimensionellt.  
Alla baser har då  $n = \dim V$  element.

#### Bevisidé:

Antag  $V = \text{span}\{u_1, \dots, u_m\}$ . Om  $u_i$  är linjärkomb av de andra kan vi ta bort den.  $u_1, \dots, u_{i-1}, u_{i+1}, \dots, u_m$  spänner fortfarande upp  $V$ . Fortsätt till man har en linjäroberoende mängd. Vi har nu en bas med  $n = \dim V$  ingående vektorer.

### Sats [1.9]

Antag  $\dim V = n \geq 0$  och  $u_1, \dots, u_m \in V$  med  $m < n$  är linjärt oberoende. Då finns  $n - m$  vektorer  $u_{m+1}, \dots, u_n$  så att  $u_1, \dots, u_n$  är en bas för  $V$ .

Bevis: Låt  $U_m = \text{span}\{u_1, \dots, u_m\}$ .  $\dim U_m < n$ . Så  $U_m$  är inte hela  $V$ . Då finns  $u_{m+1} \in V$  så att  $u_{m+1} \notin U_m$ . Lemma 1.2 ger  $u_1, \dots, u_m, u_{m+1}$  är linj. ober. upprepa tills vi har  $n$  vektorer. De utgör en bas enl. Sats 1.5.  $\square$

Lana 200331

Dimension för underrum, direkt summa, rang

Sats [1.10]

Antag att  $V$  är ändlig dimensionellt och  $U$  är ett underrum till  $V$ . Då är  $\dim U \leq \dim V$ . Om  $\dim U = \dim V$  är  $U = V$ .

Bevis

Låt  $n = \dim V$ .  $U$  kan inte ha fler än  $n$  linjärt oberoende vektorer, ty  $V$  kan inte ha det. Alltså  $\dim U \leq \dim V$ .

Om  $\dim U = n$  så finns en bas med  $n$  vektorer. Detta är även en bas för  $V$ , ty varje uppsättning med  $n$  linj. oberoende vektorer utgör en bas enl. sats 1.5. Så  $U = V = \text{span}\{\text{bas}\}$ .

◻

Direkt summa

Def. Låt  $U_1 \subseteq U_2$  vara två underrum till  $V$ . då är  $U_1 + U_2 := \{u_1 + u_2 \mid u_1 \in U_1, u_2 \in U_2\}$ . Summan är en DIREKT SUMMA om  $u \in U_1 + U_2$  har en entydig uppdelning  $u = u_1 + u_2$  med  $u_1 \in U_1$  och  $u_2 \in U_2$ . Vi skriver  $U_1 \oplus U_2$

### Lemma [1.4]

$U_1 + U_2$  är en direkt summa om

$$U_1 \cap U_2 = \{0\}$$

### Bevisidé

Om  $v \in U_1 \cap U_2$  ger  $u_1 + u_2 = \underbrace{(u_1 + v)}_{\in U_1} + \underbrace{(u_2 - v)}_{\in U_2}$

Två olika uppdelningar

Fullständigt bevis i boken.

### Sats [1.11]

Om  $V$  ändligdim och  $U$  underrum till  $V$  så finns ett underrum  $W$  så att  $V = U \oplus W$ .

$$\dim W = \dim V - \dim U$$

$W$  kallas komplementet till  $U$  i  $V$ .

Bevisidé: Använd sats 1.9 med  $u_1, \dots, u_m$  bas för  $U$  och  $u_{m+1}, \dots, u_n$  bas för  $W$ .

## Dimension i samband med matriser

### Sats [1.14] Dimensionssatsen

Om  $A$  är en  $m \times n$ -matris så gäller

$$\dim N(A) + \dim V(A) = n$$

### Bevis

Antag  $0 < p = \dim N(A) < n$  och  $e_1, \dots, e_p$  är en bas för  $N(A) \subseteq \mathbb{R}^n$ .

Sats 1.9 ger vektorer  $e_{p+1}, \dots, e_n$  så att  $e_1, \dots, e_n$  är en bas för  $\mathbb{R}^n$ .

En godt.  $x \in \mathbb{R}^n$  kan skrivas

$$\begin{aligned} x &= \sum_{j=1}^n \lambda_j e_j \Rightarrow Ax = \sum_{j=1}^n \lambda_j A e_j = \\ &= \sum_{j=1}^p \lambda_j \underbrace{A e_j}_{=0} + \sum_{j=p+1}^n \lambda_j A e_j \end{aligned}$$

Så  $V(A)$  spänns upp av  $A e_{p+1}, \dots, A e_n$

Är dessa linj. ober? Antag

$$(*) \quad \sum_{j=p+1}^n \alpha_j A e_j = 0 \Leftrightarrow \underbrace{A y}_{\Rightarrow y \in N(A)} = 0 \quad \text{med} \quad \underline{y = \sum_{j=p+1}^n \alpha_j e_j}$$

$$\Rightarrow \underline{y} \text{ kan skrivas } \sum_{j=1}^p \beta_j e_j = \underline{\sum_{j=1}^p \alpha_j e_j} \quad (\text{Låt } \beta_j = -\alpha_j)$$

$$\text{Så } 0 = y - y = \sum_{j=p+1}^n \alpha_j e_j - \sum_{j=1}^p -\alpha_j e_j = \sum_{j=1}^n \alpha_j e_j$$

men  $e_1, \dots, e_n$  är linj. ober!  $\Rightarrow \alpha_j = 0 \quad \forall j$

så (\*) har bara trivial lösning.

$\Rightarrow A e_{p+1}, \dots, A e_n$  är linj. ober  $\Rightarrow$  bas för  $V(A)$

d. v. l.

→

$$\dim V(A) = n - p \Rightarrow \dim V(A) + \dim N(A) = n$$

Om  $p = 0$  blir  $N(A) = \{0\}$ , samma argument

$$\text{ger } \dim V(A) = n$$

Om  $p = n$  blir  $N(A) = \mathbb{R}^n$  och  $V(A) = \{0\}$

$$\Rightarrow \dim V(A) = 0$$

□

### Dimensioner och matrisoperationer

$$F: \mathbb{R}^n \rightarrow \mathbb{R}^m \quad F(x) = Ax \quad A \in \mathbb{R}^{m \times n}$$

Kolonrangen är  $\dim$  vörderummet =

= kolonrummet, d.v.s. rummet som spänns upp av kolonnerna

Radrangen är  $\dim$  radrummet

### Sats [1.15] Rangsatsen

För godt.  $m \times n$ -matris  $A$  är

$$\text{kolonrang} = \text{radrang}$$

Vördet kallar  $\text{rang}(A)$ , rangen av  $A$ .

### Bevis

Fullständig Gausselimination transformerar

$A$  m.h.a. elementära radoperationer till

någon matris  $A'$ . Låt  $j_1, \dots, j_r$  vara

pivotkolonnerna (r st) T.ex.

$$A' = \left( \begin{array}{cccc|cc} 0 & 1 & * & 0 & \dots & 0 & * \\ \vdots & \vdots & \vdots & \vdots & & \vdots & \vdots \\ 0 & 0 & 0 & 0 & & 0 & 0 \end{array} \right) \left. \begin{array}{l} \vdots \\ \vdots \\ \vdots \end{array} \right\} \begin{array}{l} r \\ m-r \end{array}$$

$n$

→



→

$$Ax = 0 \Leftrightarrow A'x = 0 \quad \text{s\aa} \quad N(A) = N(A')$$

Radrum oförändrat under elem. radop.

$$\Rightarrow \text{radrang}(A) = \text{radrang}(A') = r$$

dim. satsen r linj. obero rader

$$\begin{aligned} \text{kolonnrang}(A) &\stackrel{\downarrow}{=} \dim V(A) = n - \dim N(A) = \\ &= n - \dim N(A') \stackrel{\uparrow}{=} \dim V(A') = r \end{aligned}$$

dim. sats \uparrow

ty kolonnerna med nr  $j_1, \dots, j_r$  \u00e4r linj. obero

$$\Rightarrow \text{kolonnrang}(A) = r = \text{radrang}(A) \quad \square$$

OBS:  $Ax = 0 \Leftrightarrow A'x = 0$

\u00c4r samma sak som

(\*)

$$x_1 a_1 + \dots + x_n a_n = 0 \Leftrightarrow x_1 a'_1 + \dots + x_n a'_n = 0$$

d\u00e4r  $a_j$  \u00e4r kolonner i  $A$  \u2264  $a'_j$  kolonner i  $A'$

Kolonnerna med nr  $j_1, \dots, j_r$  i  $A'$  \u00e4r uppenbart

linj. obero  $\Rightarrow x_j = 0 \quad \forall j$  - enda l\u00f6sning till (\*)

$\Rightarrow$  kolonnerna med nr  $j_1, \dots, j_r$  i  $A$  \u00e4r

linj. obero  $\Rightarrow$  dessa kolonner utg\u00f6r en bas f\u00f6r  $V(A)$ .

## Sats [1.18]

Låt  $A$  vara en  $n \times n$ -matris. Då är följande påståenden ekvivalenta:

- (i)  $Ax = 0$  har endast lösningen  $x = 0$   
( $N(A) = \{0\}$ ,  $\dim N(A) = 0$ )
- (ii)  $Ax = b$  lösbar för alla  $b \in \mathbb{R}^n$   
( $V(A) = \mathbb{R}^n$ ,  $\dim V(A) = n$ )
- (iii)  $Ax = b$  entydigt lösbar  $\forall b \in \mathbb{R}^n$
- (iv)  $\text{rang } A = n$
- (v) Kolonnerna i  $A$  är linjärt oberoende
- (vi)  $A$  är inverterbar
- (vii)  $\det A \neq 0$

## Koordinater och basbyten

Låt  $\mathcal{B} = \{e_1, \dots, e_n\}$  vara en bas för  $V$ .

(ordningen spelar roll)

Varje vektor  $u \in V$  kan skrivas på formen

$$u = x_1 e_1 + \dots + x_n e_n = \sum_{j=1}^n x_j e_j$$

Talen  $x_1, \dots, x_n$  är entydiga ty om  
också

$$u = x'_1 e_1 + \dots + x'_n e_n$$

$$\Rightarrow 0 = u - u = (x_1 - x'_1) e_1 + \dots + (x_n - x'_n) e_n$$

Eftersom  $\{e_1, \dots, e_n\}$  är linj obero är  $x_i = x'_i \forall i$

Varje vektor  $u \in V$  motsvarar vektorn

$$x = [u]_e = \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix} \in \mathbb{R}^n$$

$x$  kallas koordinatvektor och talen

$x_1, \dots, x_n$  kallas koordinater för  $u$  i basen  $e$

Linjärkombinationer i  $V$  motsvarar linjärkombinationer i  $\mathbb{R}^n$ . ty:

Om  $u, v \in V$ ,  $x = [u]_e$ ,  $y = [v]_e$

$$u + v = \sum_{i=1}^n x_i e_i + \sum_{i=1}^n y_i e_i = \sum_{i=1}^n (x_i + y_i) e_i$$

$$\Rightarrow [u + v]_e = x + y = [u]_e + [v]_e$$

$$\alpha u = \alpha \sum_{i=1}^n x_i e_i = \sum_{i=1}^n (\alpha x_i) e_i$$

$$\Rightarrow [\alpha u]_e = \alpha x = \alpha [u]_e$$

Generellt:

$$(*) \quad [\alpha_1 u_1 + \dots + \alpha_k u_k]_e = \alpha_1 [u_1]_e + \dots + \alpha_k [u_k]_e$$

### Basbyten

Låt  $e = \{e_1, \dots, e_n\}$  och  $e' = \{e'_1, \dots, e'_n\}$

vara två baser för  $V$ .

$$x = [u]_e = \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix}, \quad x' = [u]_{e'} = \begin{pmatrix} x'_1 \\ \vdots \\ x'_n \end{pmatrix}$$

$$\Rightarrow u = \sum_{i=1}^n x_i e_i = \sum_{i=1}^n x'_i e'_i$$

$$(*) \Rightarrow x = [u]_e = \sum_{i=1}^n x'_i [e'_i]_e = \underbrace{\begin{pmatrix} | & & | \\ [e'_1]_e & \dots & [e'_n]_e \\ | & & | \end{pmatrix}}_{T, n \times n \text{ matris}} \begin{pmatrix} x'_1 \\ \vdots \\ x'_n \end{pmatrix}$$

$$\Rightarrow x = T x'$$

$x = T x'$  där kolonnerna i matrisen  $T$  är koordinatvektorerna för  $e'_1, \dots, e'_n$  i basen  $e$ .  $T$  kallas transformationsmatrisen. Om  $T = (t_{ij})$  så är

$$e'_j = \sum_{i=1}^n t_{ij} e_i \quad e'_1, \dots, e'_n \text{ linj. oberoende i } V$$

$\Rightarrow$  kolonner i  $T$  linj. oberoende i  $\mathbb{R}^n$ .

$\Rightarrow T$  är inverterbar.

$$x = T x' \Leftrightarrow x' = T^{-1} x$$

Byt roll på  $e$  &  $e' \Rightarrow T^{-1} = \left( [e'_1]_e \quad \dots \quad [e'_n]_e \right)$

Tydligare skrivsätt:

$$x = T_{e \leftarrow e'} x' \Leftrightarrow x' = T_{e' \leftarrow e} x$$

$$\Rightarrow (T_{e \leftarrow e'})^{-1} = T_{e' \leftarrow e}$$

Lana 200403

Basbyten (Fortsättning)

$$[\alpha_1 u_1 + \dots + \alpha_k u_k]_e = \alpha_1 [u_1]_e + \dots + \alpha_k [u_k]_e \quad (*)$$

$$T = \left( [e'_1]_e \dots [e'_n]_e \right), \quad T = (t_{ij}),$$

$$\Rightarrow e'_j = \sum_{i=1}^n t_{ij} e_i \quad (**)$$

$e \text{ o } e'$  baser för vektorrum  $V$ .

Om  $V$  är ett underrum till  $U$ .

Låt  $f$  vara någon bas för  $U$ , och vi har  $e_i$  uttryckt i  $f$ . Hur uttrycker vi  $e'_i$  i  $f$ ?

$$[e'_i]_f \stackrel{(**), (*)}{=} \sum_{j=1}^n t_{ij} [e_j]_f = \left( [e_1]_f \dots [e_n]_f \right) \begin{matrix} [e'_i]_e \\ \hline t_{1j} \\ \vdots \\ t_{nj} \end{matrix}$$

$$\Rightarrow \boxed{\left( [e'_i]_f \dots [e'_n]_f \right) = \left( [e_1]_f \dots [e_n]_f \right) T} \quad (***)$$

Ex: [1.21] Låt

$$e_1 = \begin{pmatrix} 3 \\ 0 \\ -1 \end{pmatrix} \quad e_2 = \begin{pmatrix} 1 \\ -1 \\ -1 \end{pmatrix} \quad e'_1 = \begin{pmatrix} 2 \\ 1 \\ 0 \end{pmatrix} \quad e'_2 = \begin{pmatrix} 0 \\ 3 \\ 2 \end{pmatrix}$$

vara två baser för planet  $x - 2y + 3z = 0$  i  $\mathbb{R}^3$  (uttryckta i standardbasen för  $\mathbb{R}^3$ ). Vad är  $T$ ?

$$(***) \Rightarrow \begin{matrix} \begin{pmatrix} 2 & 0 \\ 1 & 3 \\ 0 & 2 \end{pmatrix} \\ [e'_i]_f \end{matrix} = \begin{matrix} \begin{pmatrix} 3 & 1 \\ 0 & -1 \\ -1 & -1 \end{pmatrix} \\ [e_i]_f \end{matrix} T \quad \text{Obs: } T \text{ } 2 \times 2$$

Stryk t.ex. första raden ( $2 \cdot (2 \cdot a) - 3 \cdot (3 \cdot e)$ )

$$\Rightarrow \begin{pmatrix} 1 & 3 \\ 0 & 2 \end{pmatrix} = \begin{pmatrix} 0 & -1 \\ -1 & -1 \end{pmatrix} T \Leftrightarrow T = \begin{pmatrix} 1 & 1 \\ -1 & 3 \end{pmatrix}$$

## Skalärprodukt

Def:

En SKALÄRPRODUKT eller INRE PRODUKT i ett reellt linjärt rum  $V$  är en reellvärd funktion  $\langle u, v \rangle$  av  $u, v \in V$  med egenskaperna:

$$(i) \langle u, v \rangle = \langle v, u \rangle \quad \forall u, v \in V$$

$$(ii) \langle \alpha u, v \rangle = \alpha \langle u, v \rangle \quad \forall u, v \in V, \alpha \in \mathbb{R}$$

$$(iii) \langle u_1 + u_2, v \rangle = \langle u_1, v \rangle + \langle u_2, v \rangle \quad \forall u_1, u_2, v \in V$$

$$(iv) \langle u, u \rangle \geq 0 \quad \forall u \in V \text{ och } \langle u, u \rangle = 0 \Leftrightarrow u = 0$$

Ex: Standard skalärprodukten i  $\mathbb{R}^n$

$$\langle x, y \rangle = x \cdot y = x_1 y_1 + \dots + x_n y_n = x^T y$$

$$(iv) : \langle x, x \rangle = x_1^2 + \dots + x_n^2 \geq 0$$

$$\langle x, x \rangle = 0 \Leftrightarrow x_1 = \dots = x_n = 0$$

Ex: Alternativ skalärprodukt i  $\mathbb{R}^2$ ,  $x, y \in \mathbb{R}^2$

$$\langle x, y \rangle = x_1 y_1 + x_1 y_2 + x_2 y_1 + 2x_2 y_2$$

(i), (ii) & (iii) är enkla att kontrollera

$$(iv) : \langle x, x \rangle = x_1^2 + 2x_1 x_2 + 2x_2^2 = (x_1 + x_2)^2 + x_2^2$$

Alltid  $\geq 0$ ; likhet om  $x_1 + x_2 = 0$  &  $x_2 = 0$

$$\Leftrightarrow x_1 = x_2 = 0 \quad \text{OK!}$$



Ex: Låt  $A$  symmetrisk  $n \times n$  matris som är positivt definit, d.v.s.  $x^T A x \geq 0 \quad \forall x \in \mathbb{R}^n$ , med likhet omm  $x=0$ . Låt  $\langle x, y \rangle = x^T A y$ .

Detta är en inre produkt ty!

$$(i) \quad \langle x, y \rangle = x^T A y = (x^T A y)^T = y^T A^T x = \\ = y^T A x = \langle y, x \rangle$$

egenskap (ii) & (iii) som övning

$$(iv) \quad \langle x, x \rangle = x^T A x \geq 0 \text{ med likhet omm } x=0 \\ \Leftrightarrow A \text{ positivt definit.}$$

OBS: förra exemplet är specialfallet  $A = \begin{pmatrix} 1 & 1 \\ 1 & 2 \end{pmatrix}$

Ex: Om  $V = C([a, b])$ . Låt  $\langle f, g \rangle = \int_a^b f(t)g(t) dt$

Detta är en skalärprodukt ty!

(i), (ii), (iii) följer av räkneregler för integraler.

$$(iv) \quad \langle f, f \rangle = \int_a^b \underbrace{f^2(t)}_{\geq 0} dt \geq 0$$

$$\int_a^b f^2(t) dt = 0 \Leftrightarrow f(t) \equiv 0 \text{ på } [a, b] \text{ ty } f \text{ kont.}$$

---

Idé bakom  $\langle f, g \rangle = \int_a^b f(t)g(t) dt$

Låt  $a=0$  &  $b=1$ .

Vi vill ha något som liknar  $\mathbb{R}^n$  skalärprodukt:

$$x_1 y_1 + x_2 y_2 + \dots \approx \sum_{i=1}^n f\left(\frac{i}{n}\right) g\left(\frac{i}{n}\right)$$

Men vi måste normalisera för  $n$  om vi ska ta många värden!

$$\frac{1}{n} \sum_{i=1}^n f\left(\frac{i}{n}\right) g\left(\frac{i}{n}\right) \quad (\text{Riemannsumma!})$$

$$\text{Låt } n \rightarrow \infty \quad \langle f, g \rangle = \int_0^1 f(t)g(t) dt$$

## Def

Om  $V$  har en skalärprodukt  $\langle \cdot, \cdot \rangle$  så definierar vi LÄNGDEN eller NORMEN av en  $u \in V$  som

$$\|u\| = \sqrt{\langle u, u \rangle} \quad (\text{ok p.g.a. (iv)})$$

AVSTÅNDET mellan  $u$  och  $v \in V$  är  $\|u - v\|$ .

OBS: Man kan ha normer som inte kommer från en skalärprodukt, till exempel  $\|x\| = |x_1| + |x_2|$  i  $\mathbb{R}^2$ .

Egenskaper (För normer från skalärprodukt)

$$\begin{aligned} \|u+v\|^2 &= \langle u+v, u+v \rangle = \langle u, u+v \rangle + \langle v, u+v \rangle = \\ &= \langle u, u \rangle + \langle u, v \rangle + \langle v, u \rangle + \langle v, v \rangle = \\ &= \|u\|^2 + 2\langle u, v \rangle + \|v\|^2 \end{aligned}$$

$$\Rightarrow \langle u, v \rangle = \frac{\|u+v\|^2 - \|u\|^2 - \|v\|^2}{2}$$

$$\|\alpha u\| = \sqrt{\langle \alpha u, \alpha u \rangle} = |\alpha| \sqrt{\langle u, u \rangle} = |\alpha| \cdot \|u\|$$

$$\|\alpha u\| = |\alpha| \cdot \|u\|$$

Sats [2.1] Cauchy-Schwarz olikhet  
 $|\langle u, v \rangle| \leq \|u\| \cdot \|v\| \quad \forall u, v \in V$  med likhet  
om  $u = v$  är linjärt beroende.

Bevis

Om  $v = 0$  gäller olikheten och  $u, v$  linj. ber.

Om  $v \neq 0$ : Tag godtygl.  $\alpha \in \mathbb{R}$ .

$$0 \leq \|u - \alpha v\|^2 = \|u\|^2 + 2\langle u, -\alpha v \rangle + \|-\alpha v\|^2 = \\ = \|u\|^2 - 2\alpha \langle u, v \rangle + \alpha^2 \|v\|^2$$

Låt  $\alpha = \frac{\langle u, v \rangle}{\|v\|^2}$  (ok ty  $v \neq 0$ ).

$$0 \leq \|u\|^2 - 2 \frac{\langle u, v \rangle^2}{\|v\|^2} + \frac{\langle u, v \rangle^2}{\|v\|^4} \|v\|^2 = \|u\|^2 - \frac{\langle u, v \rangle^2}{\|v\|^2}$$

Multiplitera med  $\|v\|^2$ :

$$0 \leq \|u\|^2 \|v\|^2 - \langle u, v \rangle^2 \Leftrightarrow \langle u, v \rangle^2 \leq \|u\|^2 \|v\|^2$$

$\Rightarrow |\langle u, v \rangle| \leq \|u\| \cdot \|v\|$  (den sökta olikheten)

Vi har likhet om  $\|u - \alpha v\| = 0$

$\Leftrightarrow u - \alpha v = 0 \Leftrightarrow u = \alpha v$  d.v.s.  $u, v$  linj. ber.  $\square$

Triangelolikheten och vinklar

Def

Om  $u, v \neq 0$  är **VINKELN** mellan  $u$  och  $v$

$$\theta = \arccos \left( \frac{\langle u, v \rangle}{\|u\| \cdot \|v\|} \right)$$

OBS: Cauchy-Schwarz  $\Rightarrow -1 \leq \frac{\langle u, v \rangle}{\|u\| \cdot \|v\|} \leq 1$

Så  $\theta$  är definierad  $\forall u, v$  (i linjärt rum med skalärprodukt).

Sats [2.2] Triangelolikheten

$$\|u+v\| \leq \|u\| + \|v\| \quad \forall u, v \in V$$

likhet omm  $v=0$  eller  $u=\alpha v$  med  $\alpha \geq 0$ .

Bevis

$$\begin{aligned} \|u+v\|^2 &= \|u\|^2 + 2\langle u, v \rangle + \|v\|^2 \leq \\ &\leq \|u\|^2 + 2|\langle u, v \rangle| + \|v\|^2 \leq \\ &\leq \|u\|^2 + 2\|u\| \cdot \|v\| + \|v\|^2 = \\ &= (\|u\| + \|v\|)^2 \end{aligned}$$

likhet om  $\langle u, v \rangle \geq 0$

CS, likhet om  $v=0$  eller  $u=\alpha v$  där  $\alpha = \frac{\langle u, v \rangle}{\|v\|^2}$

$$\Leftrightarrow \|u+v\| \leq \|u\| + \|v\|$$

Likhet omm  $v=0$  eller  $u=\alpha v$ ,  $\alpha \geq 0$  ◻

Ex: Vinkel mellan två polynom

Bestäm vinkeln mellan  $f=t$  &  $g=t^3$  i  $C([0,1])$

med skalärprodukt  $\langle f, g \rangle = \int_0^1 f(t)g(t) dt$

$$\|f\|^2 = \int_0^1 t^2 dt = 1/3$$

$$\|g\|^2 = \int_0^1 (t^3)^2 dt = 1/7$$

$$\langle f, g \rangle = \int_0^1 t \cdot t^3 dt = 1/5$$

$$\theta = \arccos \left( \frac{\langle f, g \rangle}{\|f\| \|g\|} \right) = \arccos \left( \frac{1/5}{1/\sqrt{3} \cdot 1/\sqrt{7}} \right) =$$

$$= \arccos \frac{\sqrt{21}}{5} = 0,4115... \text{ rad}$$



Ortogonalitet

Om  $u, v$  har vinkel  $\theta$  mellan sig

$$\cos \theta = \frac{\langle u, v \rangle}{\|u\| \cdot \|v\|}$$

Vinkelräta:  $\theta = \frac{\pi}{2} \Rightarrow \langle u, v \rangle = 0$

Def

$u, v \in V$  är ORTOGONALA om  $\langle u, v \rangle = 0$

En mängd är ORTOGONAL MÄNGD om dess vektorer är parvis ortogonala.

$u \in V$  är NORMERAD om  $\|u\| = 1$

En ortogonal mängd med normerade vektorer kallas ORTONORMERAD eller ON-MÄNGD.

En ORTOGONALBAS är en bas och ortogonal mängd.

En ON-BAS är en bas och ON-mängd.

OBS: Nollvektorn är ortogonal mot alla vektorer.

Ex:  $f=1$  &  $g=2t-1$  är ortogonala i  $C([0,1])$  med  $\langle f, g \rangle = \int_0^1 f(t)g(t)dt$  ty:

$$\langle f, g \rangle = \int_0^1 1 \cdot (2t-1) dt = [t^2 - t]_0^1 = 0$$

$$\|f\|^2 = \int_0^1 1^2 dt = [t]_0^1 = 1 \text{ så } f \text{ är normerad.}$$

$$\|g\|^2 = \int_0^1 (2t-1)^2 dt = \dots = \frac{1}{3} \text{ så } g \text{ ej normerad.}$$

$$\text{men } \frac{g}{\|g\|} = \sqrt{3}g \text{ är normerad}$$

$\Rightarrow \{f, \sqrt{3}g\}$  är en ON-mängd.

Sats [2.3]

a) En ON-mängd är linj. oberoende

b) Om  $e_1, \dots, e_n$  är en ON-bas

$$u = \langle u, e_1 \rangle e_1 + \dots + \langle u, e_n \rangle e_n \quad \forall u \in V$$

OBS:  $\langle u, e_i \rangle$  är koordinat  $i$  för  $u$  i  $e$

Bevis för b)

$$(*) \quad u = \sum_{i=1}^n \lambda_i e_i \Rightarrow \langle u, e_j \rangle = \sum_{i=1}^n \lambda_i \langle e_i, e_j \rangle$$

$$\langle e_i, e_j \rangle = \begin{cases} 0 & \text{om } i \neq j \\ 1 & \text{om } i = j \end{cases} \quad \text{ty } e_1, \dots, e_n \text{ ON-bas}$$

$$\Rightarrow \langle u, e_i \rangle = \lambda_i$$

Sätt in i (\*)

$$u = \langle u, e_1 \rangle e_1 + \dots + \langle u, e_n \rangle e_n \quad \square$$

Om  $e_1, \dots, e_n$  bara är ortogonalbas, ersätt

$$e_i \text{ med } \frac{e_i}{\|e_i\|} \text{ d.v.s. } u = \sum_{i=1}^n \frac{\langle u, e_i \rangle}{\|e_i\|^2} e_i$$



## Gram-Schmidts ortogonaliseringsprocess

ETT systematiskt sätt att konstruera en ON-bas.

Ex: Låt  $v_1 = \begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix}$   $v_2 = \begin{pmatrix} 0 \\ 1 \\ 1 \end{pmatrix}$   $v_3 = \begin{pmatrix} 0 \\ 0 \\ 1 \end{pmatrix}$ ,  $V = \text{span} \{v_i\}_{i=1}^3$   
Bestäm en ON-bas  $\{e_1, e_2, e_3\}$ .

Steg 1: Låt  $e_1' = v_1$

Steg 2: Bilda  $e_2' = v_2 - \alpha e_1'$

Vi vill att  $\langle e_1', e_2' \rangle = 0$

$$\Rightarrow \langle e_1', v_2 - \alpha e_1' \rangle = \langle v_2, e_1' \rangle - \alpha \langle e_1', e_1' \rangle = 0$$

$$\Rightarrow \alpha = \frac{\langle v_2, e_1' \rangle}{\langle e_1', e_1' \rangle} \quad \text{d.v.s.} \quad e_2' = v_2 - \frac{\langle v_2, e_1' \rangle}{\langle e_1', e_1' \rangle} e_1'$$

I vårt exempel:

$$e_2' = \begin{pmatrix} 0 \\ 1 \\ 1 \end{pmatrix} - \frac{3}{4} \begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix} = \frac{1}{4} \begin{pmatrix} -3 \\ 1 \\ 1 \end{pmatrix}$$

$v_2 \in \text{span} \{e_1'\} \Rightarrow e_2' \neq 0 \Rightarrow \text{span} \{e_1', e_2'\} = \text{span} \{v_1, v_2\}$

Steg 3:

$$\text{Låt } e_3' = v_3 - \underbrace{\frac{\langle v_3, e_1' \rangle}{\langle e_1', e_1' \rangle}}_{\text{proj. på } e_1'} e_1' - \underbrace{\frac{\langle v_3, e_2' \rangle}{\langle e_2', e_2' \rangle}}_{\text{proj. på } e_2'}$$

$$\text{Vi får } \langle e_3', e_1' \rangle = \langle v_3, e_1' \rangle \overset{\leftarrow \text{lika}}{\rightarrow} \frac{\langle v_3, e_1' \rangle}{\langle e_1', e_1' \rangle} \langle e_1', e_1' \rangle - \frac{\langle v_3, e_2' \rangle}{\langle e_2', e_2' \rangle} \langle e_2', e_1' \rangle = 0$$

Och p.s.s.  $\langle e_3', e_2' \rangle = 0$



→

Så  $\{e_1', e_2', e_3'\}$  är parvis ortogonala.

$$v_3 \notin \text{span}\{v_1, v_2\} = \text{span}\{e_1', e_2'\}$$

$$\Rightarrow e_3' \neq 0 \text{ och } \text{span}\{e_1', e_2', e_3'\} = \text{span}\{v_1, v_2, v_3\}$$

I vårt exempel:

$$e_3' = \begin{pmatrix} 0 \\ 0 \\ 1 \end{pmatrix} - \frac{2}{4} \begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix} - \frac{2}{12} \begin{pmatrix} -3 \\ 1 \\ 1 \end{pmatrix} = \frac{1}{3} \begin{pmatrix} 0 \\ -2 \\ 1 \end{pmatrix}$$

Så  $e_1', e_2', e_3'$  utgör en ortogonalbas för  $V$ .

Steg 4: Normera!

$$e_i = \frac{e_i'}{\|e_i'\|} \text{ ger } \{e_1, e_2, e_3\} = \left\{ \frac{1}{2} \begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix}, \frac{1}{2\sqrt{3}} \begin{pmatrix} -3 \\ 1 \\ 1 \end{pmatrix}, \frac{1}{\sqrt{6}} \begin{pmatrix} 0 \\ -2 \\ 1 \end{pmatrix} \right\}$$

$e_1, e_2, e_3$  utgör en ON-bas för  $V$ .

Sats [2.4]

Låt  $V$  vara ett ändlig dimensionellt linjärt rum med skalärprodukt definierad och  $\dim V > 0$ . Då har  $V$  en ON-bas.

Bevis Låt  $n = \dim V$  och  $v_1, \dots, v_n$  bas för  $V$ .

Låt  $e_i' = v_i$ . Induktion:

Antag att vi har  $e_1', \dots, e_k'$  parvis ortogonala och  $\text{span}\{e_1', \dots, e_k'\} = \text{span}\{v_1, \dots, v_k\}$ .

$$\text{Låt } e_{k+1}' = v_{k+1} - \sum_{j=1}^k \frac{\langle v_{k+1}, e_j' \rangle}{\langle e_j', e_j' \rangle} e_j' \quad (*)$$

$$\begin{aligned} \langle e_{k+1}', e_i' \rangle &= \langle v_{k+1}, e_i' \rangle - \sum_{j=1}^k \frac{\langle v_{k+1}, e_j' \rangle}{\langle e_j', e_j' \rangle} \underbrace{\langle e_i', e_j' \rangle}_{0 \text{ om } i \neq j} = \\ &= \langle v_{k+1}, e_i' \rangle - \langle v_{k+1}, e_i' \rangle = 0 \end{aligned}$$

→

→

Så  $e_{k+1}$  enl. (\*) ger att även

$\{e_1, \dots, e_{k+1}\}$  parvis ortogonala.

$v_i$  linj.  
ober

$$\rightarrow v_{k+1} \notin \text{span}\{v_1, \dots, v_k\} = \text{span}\{e_1, \dots, e_k\}$$

$$\Rightarrow e_{k+1} \neq 0 \text{ och } \text{span}\{e_1, \dots, e_{k+1}\} = \text{span}\{v_1, \dots, v_{k+1}\}$$

(ty enl. (\*) är  $v_{k+1}$  lincomb. av  $e_1, \dots, e_{k+1}$ )

Induktion ger att vi kan bilda

$\{e_1, \dots, e_n\}$  ortogonala så  $V = \text{span}\{e_1, \dots, e_n\}$

Vi kan normera:

$$e_i = \frac{e_i}{\|e_i\|} \quad \forall i=1, \dots, n$$

$\Rightarrow \{e_1, \dots, e_n\}$  ON-bas för  $V$  □

### Ortogonalprojektioner

Sats [2.5] Pythagoras sats

Om  $\{u_1, \dots, u_n\}$  är en ortogonal mängd i  $V$

$$\left\| \sum_{i=1}^n u_i \right\|^2 = \sum_{i=1}^n \|u_i\|^2$$

Bevis:

$$\begin{aligned} \left\| \sum_{i=1}^n u_i \right\|^2 &= \left\langle \sum_{i=1}^n u_i, \sum_{i=1}^n u_i \right\rangle \stackrel{\substack{\text{skalärprodukt} \\ \text{linj. i } \langle \cdot, \cdot \rangle}}{=} \sum_{i=1}^n \sum_{j=1}^n \underbrace{\langle u_i, u_j \rangle}_{0 \text{ om } i \neq j} = \\ &= \sum_{i=1}^n \langle u_i, u_i \rangle = \sum_{i=1}^n \|u_i\|^2 \quad \square \end{aligned}$$

### Def

Låt  $U$  vara ett underrum av  $V$ .

Det ORTOGONALA KOMPLEMENTET är

$$U^\perp = \{v \in V \mid \langle v, u \rangle = 0 \quad \forall u \in U\}$$



"Alla vektorer i  $V$  som är ortogonala mot alla vektorer i  $U$ "

### Sats [2.6]

$U^\perp$  är ett underrum av  $V$

### Bevis

$$v_1, v_2 \in U^\perp, \alpha, \beta \in \mathbb{R}, u \in U$$

$$\Rightarrow \langle \alpha v_1 + \beta v_2, u \rangle = \alpha \langle v_1, u \rangle + \beta \langle v_2, u \rangle = 0$$

$$\Rightarrow \alpha v_1 + \beta v_2 \in U^\perp \quad \square$$

### Def

Om en vektor  $u \in V$  kan skrivas  $u = u' + u''$

där  $u' \in U$  och  $u'' \in U^\perp$  kallas  $u'$

ORTOGONALPROJEKTIONEN av  $u$  på  $U$ .

OBS: Om  $U$  är oändligdim är det inte säkert att ortogonalprojektionen existerar.

### Sats [2.1]

Om ortogonalprojektionen existerar är den entydig.

### Lemma [2.2]


Om orto.proj. existerar  $\forall u \in V$  så är  $(U^\perp)^\perp = U$ .



Lana 200415

## Ortogonalitet & Tillämpningar

Om  $U$  underrum till  $V$ ;  $u = u' + u''$  med  $u' \in U$ ,  $u'' \in U^\perp$  är  $u'$  ortogonalprojektionen av  $u$  på  $U$ .



### Sats [2.7]

Låt  $u \in V$ . För en vektor  $u' \in U$ :

$$\underbrace{u - u' \in U^\perp}_{(i)} \Leftrightarrow \underbrace{\|u - u'\| \leq \|u - w\|}_{(ii) \quad \forall w \in U}$$

d.v.s. ortogonalprojektionen är närmaste vektorn i  $U$  för  $u$ .

### Bevis

Antag  $u - u' \in U^\perp$ ,  $w \in U$  godt.

$$\begin{aligned} \|u - w\|^2 &= \|\underbrace{(u - u')}_{\in U^\perp} + \underbrace{(u' - w)}_{\in U}\|^2 = \{\text{pythagoras sats}\} = \\ &= \|u - u'\|^2 + \|u' - w\|^2 \geq \|u - u'\|^2 \end{aligned}$$

$$\text{så } \|u - w\| \geq \|u - u'\| \quad \forall w \in U$$

d.v.s. (i)  $\Rightarrow$  (ii)

Antag  $\|u - u'\| \leq \|u - w\|$ . Låt  $u'' = u - u'$ ,  $w$  godt.

Vill visa att  $u'' \in U^\perp$ . För  $t \in \mathbb{R}$ :

$$\|u''\| \stackrel{(ii)}{\leq} \|u - (u' - tw)\| = \|u'' + tw\|$$

$$\text{Bilda } \varphi(t) = \|u'' + tw\|^2 = \|u''\|^2 + 2t\langle u'', w \rangle + t^2\|w\|^2$$

$\varphi(t)$  har min i  $t = 0$  t.g. (x)

$$\Rightarrow 0 = \varphi'(0) = 2\langle u'', w \rangle.$$

$w$  godt så  $u'' \in U^\perp$



### Sats [2.8]

Antag  $\dim U = k$ . För  $u \in V$  existerar entydigt  $u' \in U$  så  $u - u' \in U^\perp$ . Om  $\{e_1, \dots, e_k\}$  är en ON-bas för  $U$   
 $u' = \langle u, e_1 \rangle e_1 + \dots + \langle u, e_k \rangle e_k$  ( $u' = 0$  om  $k = 0$ )

Anm: om  $\|e_i\| \neq 1$ , använd  $\frac{1}{\|e_i\|} e_i$

### Sats [2.9]

Om  $\dim V = n$ ,  $U$  underrum till  $V$ , så  
 $\dim U + \dim U^\perp = n$

### Fundamentala underrum till matriser

Låt  $A$   $m \times n$ -matris

$N(A)$  och  $V(A^T)$  är underrum av  $\mathbb{R}^n$

$V(A)$  och  $N(A^T)$  är underrum av  $\mathbb{R}^m$

### Sats [2.11] De 4 fundamentala underrumen

För en godt.  $m \times n$ -matris  $A$  så gäller

- $N(A) = V(A^T)^\perp$
- $N(A)^\perp = V(A^T)$
- $N(A^T) = V(A)^\perp$
- $N(A^T)^\perp = V(A)$



## Bevis

$$A = \begin{pmatrix} \text{---} & r_1 & \text{---} \\ \vdots & \vdots & \vdots \\ \text{---} & r_m & \text{---} \end{pmatrix} \quad Ax = \begin{pmatrix} r_1^T \cdot x \\ \vdots \\ r_m^T \cdot x \end{pmatrix}$$

$$x \in N(A) \Leftrightarrow Ax = 0 \Leftrightarrow x \perp \text{ mot } \forall r_i^T$$

$$\Leftrightarrow x \perp \forall \text{ kolonner i } A^T$$

$$\Leftrightarrow x \perp V(A^T) = \text{span}\{\text{kolonner i } A^T\}$$

$$\Leftrightarrow x \in V(A^T)^\perp$$

$x$  godt. i  $N(A)$

$$\Rightarrow \underline{N(A) = V(A^T)^\perp}$$

Det följer nu att

$$(N(A))^\perp = (V(A^T)^\perp)^\perp$$

$$\Rightarrow \underline{N(A)^\perp = V(A^T)}$$

$A$  var godt, så byt  $A$  mot  $A^T$

$$\Rightarrow \underline{N(A^T) = V(A)^\perp}$$

$$\Rightarrow \underline{N(A^T)^\perp = V(A)}$$



## Minstakvadratmetoden

Vill lösa  $Ax = b$  med  $A$   $m \times n$ -matris,  $b \in \mathbb{R}^m$

Ibland finns ej lösningar, typiskt om  $m > n$

Vi söker då  $x$  så att  $Ax$  blir så nära

$b$  som möjligt, d.v.s. minimerar  $\|Ax - b\|$ .


$$\|Ax - b\|^2 = ([Ax]_1 - b_1)^2 + \dots + ([Ax]_m - b_m)^2$$

(minsta kvadratsumma)

Obs: Alla vektorer  $Ax$  utgör  $V(A)$ .

Vi söker  $b' = Ax \in V(A)$  som minimerar  $\|b' - b\|$ .

Sats 2.7  $\rightarrow \Leftrightarrow b - b' \in V(A)^\perp$  d.v.s.  $b'$  ortoproj av  $b$  på  $V(A)$ .



### Sats [2.12]

Det finns minst en minstakvadrat lösning till  $Ax = b$ .  $x$  är:

minstakvadrat lösning om

$$A^T Ax = A^T b \quad (\text{Normalekvationerna})$$

### Bevis

Enl. sats 2.7:  $x$  MK-lösn  $\Leftrightarrow Ax = b'$  där  $b - b' \in V(A)^\perp$

Enl. sats 2.8:  $\exists! b' \in V(A) \Rightarrow \exists x: Ax = b'$

$x$  MK-lösn  $\Leftrightarrow$  Sats 2.11  $b - Ax \in V(A)^\perp = N(A^T)$

$$\Leftrightarrow A^T (b - Ax) = 0 \Leftrightarrow A^T Ax = A^T b$$

residual,  
felet

□

"residualen ligger i nollrummet till  $A^T$ "

Obs:  $b'$  behöver inte beräknas, men  $b' = Ax$  för godst MK-lösning  $x$ .

$b'$  är entydig, men  $Ax = b' \Leftrightarrow A^T Ax = A^T b$  kan ha flera lösningar.

Obs: Antag att  $Ax = b$  är lösbar

$$\Rightarrow b \in V(A) \Rightarrow b' = b$$

$$A^T Ax = A^T b \Leftrightarrow Ax = b$$


(Normalekvationen har samma lösningar)

Exempel: Anpassa andragradspolynom

$y = c_1 + c_2 t + c_3 t^2$  till mätdata

$t$  |  $t_1$   $t_2$   $t_3$  ...  $t_n$

$y$  |  $y_1$   $y_2$   $y_3$  ...  $y_n$



d.v.s. Minimera  $\sum_{i=1}^n (c_1 + c_2 t_i + c_3 t_i^2 - y_i)^2 =$

$$= \left\| \begin{pmatrix} 1 & t_1 & t_1^2 \\ \vdots & \vdots & \vdots \\ 1 & t_n & t_n^2 \end{pmatrix} \begin{pmatrix} c_1 \\ c_2 \\ c_3 \end{pmatrix} - \begin{pmatrix} y_1 \\ \vdots \\ y_n \end{pmatrix} \right\|^2 = \|Ax - b\|^2$$

d.v.s. lös normalekv.  $A^T Ax = A^T b$

ger bästa  $x = \begin{pmatrix} c_1 \\ c_2 \\ c_3 \end{pmatrix}$

Anm.

Tag t.ex.  $n=4$   $t_1=0$   $t_2=1$   $t_3=10$   $t_4=100$

ger  $A^T A = \begin{pmatrix} 4 & \dots \\ \vdots & \vdots \\ \vdots & \sim 10^8 \end{pmatrix} \Rightarrow$  stor skillnad mellan elementen.

Vi får lätt numeriska problem.

## Ortogonala matriser

Def En kvadratisk matris kallas

ORTOGONAL om  $A^T A = I$

### Lemma

En kvadratisk matris  $A$  är ortogonal om dess kolonner är parvis ortogonala och har längd 1.

### Bevis

Om  $A = (\underset{|}{a_1} \dots \underset{|}{a_n})$ :

$$A^T A = \begin{pmatrix} -a_1^T - \\ \vdots \\ -a_n^T - \end{pmatrix} \begin{pmatrix} \underset{|}{a_1} \dots \underset{|}{a_n} \end{pmatrix} = \begin{pmatrix} a_1 \cdot a_1 & \dots & a_1 \cdot a_n \\ \vdots & \ddots & \vdots \\ a_n \cdot a_1 & \dots & a_n \cdot a_n \end{pmatrix}$$

$$a_i \cdot a_j = [A^T A]_{ij} = I_{ij} = \begin{cases} 0 & \text{om } i \neq j \\ 1 & \text{om } i = j \end{cases}$$

Så parvis ortogonala  $\Leftrightarrow A^T A = I$

OBS:  $A$  ortogonal om kolonnerna är ortonormala

$$A \text{ ortogonal} \Leftrightarrow A^T A = I \Rightarrow A^{-1} = A^T$$

$$\Rightarrow I = A A^{-1} = A A^T = (A^T)^T A^T$$

$$\Rightarrow A^T \text{ ortogonalmatris}$$

$$\Rightarrow \text{raderna ortonormala}$$

## ON-basbyten

Låt  $\{e_1, \dots, e_n\}$  vara ON-bas för  $V$ .

Låt  $u, v \in V$  och  $[u]_e = x \in \mathbb{R}^n$  o  $[v]_e = y \in \mathbb{R}^n$

Skalarprodukten

$$\begin{aligned}\langle u, v \rangle &= \left\langle \sum_{i=1}^n x_i e_i, \sum_{j=1}^n y_j e_j \right\rangle = \\ &= \sum_{i=1}^n \sum_{j=1}^n x_i y_j \langle e_i, e_j \rangle \stackrel{\text{ON-bas}}{=} \\ &= \sum_{i=1}^n x_i y_i = \\ &= x^T y = x \cdot y\end{aligned}$$

Så  $\boxed{\langle u, v \rangle = [u]_e \cdot [v]_e}$  om  $e$  ON-bas!

Låt  $\{e'_1, \dots, e'_n\}$  vara en annan ON-bas.

Transformationsmatrisen

$$T = T_{e \leftarrow e'} = \begin{pmatrix} [e'_1]_e & \dots & [e'_n]_e \end{pmatrix}$$

$$[e'_i]_e \cdot [e'_j]_e = \langle e'_i, e'_j \rangle \stackrel{e' \text{ ON-bas}}{=} \begin{cases} 0 & \text{om } i \neq j \\ 1 & \text{om } i = j \end{cases}$$

d.v.s. kolonnerna i  $T$  är parvis ortogonala med längd 1  $\Rightarrow T$  ortogonalmatris.

Lana 200416

## Matrisrepresentation av linjära avbildningar

$F(x) = Ax$  är typexempel på linj. avb.

Om  $F: U \rightarrow V$  och  $U, V$  ändligdim så

kan den representeras av matris!

Låt  $n = \dim U$  och  $m = \dim V$ .

$F: U \rightarrow V$  linj. avb.  $e$  bas för  $U$ ,  $f$  bas för  $V$

$u \in U$  godt.,  $v = F(u)$ ,  $x = [u]_e \in \mathbb{R}^n$ ,  $y = [v]_f \in \mathbb{R}^m$

$$v = F(u) = F\left(\sum_{j=1}^n x_j e_j\right) = \sum_{j=1}^n x_j F(e_j)$$

$$\Rightarrow y = [v]_f = \sum_{j=1}^n x_j [F(e_j)]_f =$$

$$= \underbrace{\begin{pmatrix} | & & | \\ [F(e_1)]_f & \dots & [F(e_n)]_f \\ | & & | \end{pmatrix}}_{=: A} x$$

$A$  är en  $m \times n$ -matris som relaterar  $y$  till  $x$ .

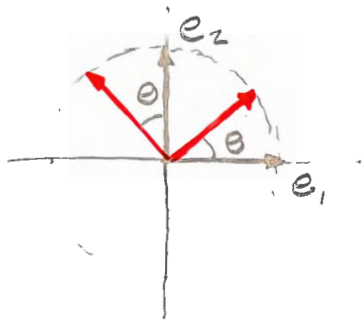
Kolumnerna i  $A$  är koordinatvektorer för  $F(e_1) \dots F(e_n)$  i basen  $f$ .  $A$  kallas "matrisen för avbildningen  $F$  i baserna  $e$  och  $f$ ".  
 $y = Ax$  matrisrepresentation av  $F(u) = v$ . Om  $U = V$  och  $e = f$  är  $A$  matrisen för  $F$  i basen  $e$ .

Samma princip som vanligt, "Var hamnar basvektorer?"



## Exempel 1: Vridning i planet

$e = f = \{e_1, e_2\}$   $U = V = \text{geom. planet}$



$$F(e_1) = \cos \theta e_1 + \sin \theta e_2$$

$$\Rightarrow [F(e_1)]_e = \begin{pmatrix} \cos \theta \\ \sin \theta \end{pmatrix}$$

$$F(e_2) = -\sin \theta e_1 + \cos \theta e_2$$

$$\Rightarrow [F(e_2)]_e = \begin{pmatrix} -\sin \theta \\ \cos \theta \end{pmatrix}$$

$$\Rightarrow A = \begin{pmatrix} \cos \theta & -\sin \theta \\ \sin \theta & \cos \theta \end{pmatrix}$$

## Eigenvärden och egenvektorer

### Exempel

Låt  $A = \begin{pmatrix} -1 & 6 \\ 0 & 2 \end{pmatrix}$ ,  $F(x) = Ax$

Hur avbildar  $F$  vektorer? Finns vektorer som avbildas på ett enkelt sätt?

$$F \begin{pmatrix} 2 \\ 1 \end{pmatrix} = \begin{pmatrix} -1 & 6 \\ 0 & 2 \end{pmatrix} \begin{pmatrix} 2 \\ 1 \end{pmatrix} = \begin{pmatrix} 4 \\ 2 \end{pmatrix} = 2 \begin{pmatrix} 2 \\ 1 \end{pmatrix}$$

$$F \begin{pmatrix} 1 \\ 0 \end{pmatrix} = \begin{pmatrix} -1 & 6 \\ 0 & 2 \end{pmatrix} \begin{pmatrix} 1 \\ 0 \end{pmatrix} = \begin{pmatrix} -1 \\ 0 \end{pmatrix} = -1 \begin{pmatrix} 1 \\ 0 \end{pmatrix}$$

$\begin{pmatrix} 2 \\ 1 \end{pmatrix}$  kallas egenvektor med egenvärde 2.

$\begin{pmatrix} 1 \\ 0 \end{pmatrix}$  kallas egenvektor med egenvärde -1.

Eigenvärden kan användas för att förstå  $F$ .

### Exempel

Låt  $V = C^\infty(\mathbb{R})$  och  $F(f) = f'$  (derivata)

$F(e^{\lambda t}) = \lambda e^{\lambda t}$  så  $f(t) = e^{\lambda t}$  är egenvektor  
för  $F$  med egenvärde  $\lambda$ .


Def En EGENVEKTOR för en  
linjär avbildning  $F: V \rightarrow V$  är en vektor  
 $u \neq 0$  så att  $F(u) = \lambda u$  för något tal  $\lambda$   
som kallas EGENVÄRDE. Alla vektorer  
 $u$  (öven 0) som uppfyller  $F(u) = \lambda u$   
för ett egenvärde  $\lambda$  utgör ett underrum  
 $E(\lambda)$  som kallas EGENRUMMET till  
egenvärdet  $\lambda$ .

Om  $V$  är ändlig dimensionellt,  $A$  är matrisen  
för  $F$  i en bas  $e$  och  $x = [u]_e$  där  $u \in V$ :

$$F(u) = \lambda u \Leftrightarrow \boxed{Ax = \lambda x} \Leftrightarrow (A - \lambda I)x = 0$$

Så  $E(\lambda)$  motsvarar  $N(A - \lambda I)$ .

### Exempel Spegling i plan i rummet



Planet är egenrummet  
till egenvärdet 1

(Vektorerna avbildas

på sig själva).  $E(1) = P$

En normal till planet är egenvektor med  
egenvärde -1.  $E(-1) = P^\perp$

### Exempel

$$F(f) = f'' \quad F(\sin(\alpha t)) = -\alpha^2 \sin(\alpha t)$$

Si  $\sin(\alpha t)$  är egenvektor med egenvärde  $-\alpha^2$

Egenvärden och egenvektorer viktiga för lösning av differentialekvationer.

### Exempel

Schrödinger ekvationen  $H\psi = E\psi$  (där  $E$  är ett tal) är en egenvärdesekvation. Detta är grundläggande för kvantmekanik.

Egenvärden ger spektrallinjer, mängden av egenvärden kallas spektrum.

### Exempel

Rotationen av en stel kropp beskrivs m.h.a. principalaxlar = egenvektorer till tröghetsmatris.

### Exempel

Resonans sker vid frekvenser som är egenvärden till ett egenvärdesproblem.

## Beräkning av egenvektorer och egenvärden

### Idé

$\lambda$  är egenvärde till  $A \Leftrightarrow (A - \lambda I)x = 0$

har icke-trivial lösning  $\Leftrightarrow A - \lambda I$  ej

inverterbar  $\Leftrightarrow \det(A - \lambda I) = 0$

polynom i  $\lambda$  av grad  $n$

### Sats

Låt  $V$  vara ändligdim med bas  $e$ .

Låt  $F: V \rightarrow V$  vara en lin. avb. med matris

$A$  i basen  $e$ . Då är  $\lambda$  egenvärde till

$F$  om  $\det(A - \lambda I) = 0$

Def  $\det(A - \lambda I)$  kallas KARAKTÄRISTISKA  
POLYNOMET till  $A$  eller  $F$ .

$\det(A - \lambda I) = 0$  kallas KARAKTÄRISTISKA  
EKVATIONEN.

### Exempel

Beräkna egenvärden o vektorer till  $A = \begin{pmatrix} 2 & 3 \\ 3 & -6 \end{pmatrix}$

$$\text{kar. poli: } \det(A - \lambda I) = \begin{vmatrix} 2-\lambda & 3 \\ 3 & -6-\lambda \end{vmatrix} = \dots ?$$

$$= (2-\lambda)(-6-\lambda) - 9 = (\lambda-3)(\lambda+7)$$

Så  $A$  har egenvärden  $3$  o  $-7$ ,

ty karakteristiska ekvationen har

rötter  $3$  o  $-7$



- ->

Egenvektorer till  $\lambda_1 = 3$ :

$$Ax = \lambda_1 x \Leftrightarrow (A - \lambda_1 I)x = 0 \Leftrightarrow$$

$$\Leftrightarrow \left( \begin{array}{cc|c} -1 & 3 & 0 \\ 3 & -9 & 0 \end{array} \right) \sim \left( \begin{array}{cc|c} -1 & 3 & 0 \\ 0 & 0 & 0 \end{array} \right) \Leftrightarrow$$

$$-x_1 + 3x_3 = 0 \Leftrightarrow x = \begin{pmatrix} 3 \\ 1 \end{pmatrix} t \quad t \in \mathbb{R}$$

Så  $v_1 = \begin{pmatrix} 3 \\ 1 \end{pmatrix}$  är egenvektor med egenvärde 3.

$$E(3) = \text{span} \{v_1\}$$

Egenvektorer till  $\lambda_2 = -7$ :

$$(A + 7I)x = 0 \Leftrightarrow \left( \begin{array}{cc|c} 9 & 3 & 0 \\ 3 & 1 & 0 \end{array} \right) \sim \left( \begin{array}{cc|c} 3 & 1 & 0 \\ 0 & 0 & 0 \end{array} \right)$$

$$\Leftrightarrow x = \begin{pmatrix} -1/3 \\ 1 \end{pmatrix} t \quad t \in \mathbb{R}$$

Så  $v_2 = \begin{pmatrix} -1 \\ 3 \end{pmatrix}$  egenvektor med egenvärde -7.

$$E(-7) = \text{span} \{v_2\}$$

Anm! Flera parametrar  $\Leftrightarrow$  Högre dim på egenrummet.

Anm! Metoden fungerar för små matriser och handräkning. Fungerar dåligt numeriskt. Determinantberäkningar dyra och numeriskt instabilt att hitta rötter till polynom av hög grad.

Om  $A$   $n \times n$ -matris:

$$\begin{aligned} (*) \det(A - \lambda I) &= \begin{vmatrix} a_{11} - \lambda & \dots & a_{1n} \\ \vdots & \ddots & \vdots \\ a_{n1} & \dots & a_{nn} - \lambda \end{vmatrix} = \\ &= (a_{11} - \lambda) \dots (a_{nn} - \lambda) + \dots = \\ &= (-1)^n \lambda^n + (-1)^{n-1} \underbrace{(a_{11} + a_{22} + \dots + a_{nn})}_{\text{Sp}(A)} \lambda^{n-1} + \\ &\quad + \dots + \det(A) \end{aligned}$$

Vi får ett polynom av grad  $n$ .

Algebras fundamentalsats ger exakt  $n$  rötter (räknat med multiplicitet).

Dessa är egenvärdena  $\lambda_1, \dots, \lambda_n$ .

$\Rightarrow$  Alla matriser har (komplexa) egenvärden.

$\Rightarrow$  Behöver räkna med komplexa vektorrum

$$\begin{aligned} (**) \det(A - \lambda I) &= (-1)^n (\lambda - \lambda_1) \dots (\lambda - \lambda_n) = \\ &= (-1)^n \lambda^n - (-1)^{n-1} (\lambda_1 + \lambda_2 + \dots + \lambda_n) \lambda^{n-1} + \dots + \\ &\quad + \dots + \lambda_1 \lambda_2 \dots \lambda_n \end{aligned}$$

Jämför (\*) med (\*\*):

$\begin{aligned} \lambda_1 + \lambda_2 + \dots + \lambda_n &= \text{Sp}(A) \\ \lambda_1 \lambda_2 \dots \lambda_n &= \det(A) \end{aligned}$
---

Speciellt:  $\det(A) = 0 \Leftrightarrow$  minst ett egenvärde 0



Om  $A$  är triangulär:

$$\det(A - \lambda I) = \begin{vmatrix} a_{11} - \lambda & & a_{1n} \\ & \ddots & \\ 0 & & a_{nn} - \lambda \end{vmatrix} = \\ = (a_{11} - \lambda)(a_{22} - \lambda) \dots (a_{nn} - \lambda)$$

$\Rightarrow$  egenvärdena är diagonalelementen.

Om  $A$  är blocktriangulär:

$$A = \begin{pmatrix} A_{11} & A_{12} \\ 0 & A_{22} \end{pmatrix}$$

$$\det(A - \lambda I) = \det \begin{pmatrix} A_{11} - \lambda I & A_{12} \\ 0 & A_{22} - \lambda I \end{pmatrix} =$$

$$= \det(A_{11} - \lambda I) \det(A_{22} - \lambda I)$$

Sats [4.2]

$A$  och  $A^T$  har samma egenvärden

Bevis  $\det(A^T - \lambda I) = \det(A^T - \lambda I)^T = \det(A - \lambda I)$

Samma kar. ekv  $\Rightarrow$  samma egenvärden  $\square$

## Komplexa vektorrum

Behöver komplexkonjugat  $\bar{u}$  av  $u$

Def En skalärprodukt  $\langle u, v \rangle$  i ett komplext vektorrum  $V$  är komplexvärd och uppfyller:

$$(i) \langle u, v \rangle = \overline{\langle v, u \rangle} \quad \forall u, v \in V$$

$$(ii) \langle u, \alpha v \rangle = \alpha \langle u, v \rangle \quad \forall u, v \in V, \alpha \in \mathbb{C}$$

$$(iii) \langle u+v, w \rangle = \langle u, w \rangle + \langle v, w \rangle \quad \forall u, v, w \in V$$

$$(iv) \langle u, u \rangle \geq 0 \quad \forall u \in V, \text{ likhet om } u=0$$

OBS! (i) & (ii) ger  $\langle \alpha u, v \rangle = \bar{\alpha} \langle u, v \rangle$

Komplexa matriser:

Konjugattransponat  $A^* := \bar{A}^T$

Se sektion 4.8 för mer komplexa rum med skalärprodukt.

---

$$V = \mathbb{C}^2 \quad x = \begin{pmatrix} a + ci \\ b + di \end{pmatrix}$$

Lana 200420

## Matrisrepresentation av linjära avbildningar

$F: U \rightarrow V$  linjär avbildning,  $e$  bas för  $U$   
 $f$  bas för  $V$ . Matrisen för  $F$  är

$$A = \begin{pmatrix} [F(e_1)]_f & \dots & [F(e_n)]_f \end{pmatrix}$$

Vi får då  $F(u) = v \Leftrightarrow [v]_f = A[u]_e$

$\lambda$  egenvärde och  $u$  egenvektor om  $F(u) = \lambda u$  ( $U=V$ )

### Exempel Komplexa egenvärden

Låt  $V = \text{span}\{\sin t, \cos t\}$ ,  $F: V \rightarrow V$   $F(f) = f'$

$\{e_1, e_2\} = \{\sin t, \cos t\}$  bas för  $V$ .

Vad är matrisen för  $F$ ?

$$F(e_1) = \cos t = e_2 \quad F(e_2) = -\sin t = -e_1$$

$$\Rightarrow A = \begin{pmatrix} [e_2]_e & [-e_1]_e \\ [e_1]_e & [-e_2]_e \end{pmatrix} = \begin{pmatrix} 0 & -1 \\ 1 & 0 \end{pmatrix}$$

Sök egenvärden!

$$[\text{Kar. ekv.}] \quad 0 = \det(A - \lambda I) = \begin{vmatrix} -\lambda & -1 \\ 1 & -\lambda \end{vmatrix} = \lambda^2 + 1$$

Egenvärden:  $\lambda_1 = -i$   $\lambda_2 = i$

Egenvektor till  $\lambda_1$ :  $(A + iI)x = 0$

$$\Leftrightarrow \left[ \begin{array}{cc|c} i & -1 & 0 \\ 1 & i & 0 \end{array} \right] \Leftrightarrow \left[ \begin{array}{cc|c} i & -1 & 0 \\ 0 & 0 & 0 \end{array} \right] \Rightarrow x = \begin{pmatrix} i \\ 1 \end{pmatrix} t \quad t \in \mathbb{C}$$

Egenfunktion  $e_1 + ie_2 = \sin t + i \cos t = \underline{e^{it}}$

Egenvektor till  $\lambda_2$  p.s.s.  $x = \begin{pmatrix} 1 \\ -i \end{pmatrix} t \quad t \in \mathbb{C}$

Egenfunktion  $\sin t - i \cos t = \underline{e^{-it}}$

### Exempel [4.11]

Låt  $V = C^\infty(\mathbb{R})$  och  $F(f) = f'$

Bestäm egenvärde och egenfunktioner!

$$f \text{ egenfunktion} \Leftrightarrow F(f) = \boxed{f' = \lambda f} \Leftrightarrow f(t) = Ce^{\lambda t}$$

ODE

Alla  $\lambda \in \mathbb{C}$  är egenvärden med egenfunktion  $e^{\lambda t}$ .

OBS: Behöver ej bas för egenvektorer/värden

### Sammansättningar av linjära avbildningar

Låt  $F: U \rightarrow V$ ,  $G: U \rightarrow V$  linj. avb.

$$\text{Låt } (F+G)(u) := F(u) + G(u) \quad \forall u \in U$$

$$(\alpha F)(u) := \alpha F(u) \quad \forall u \in U$$

Detta ger ett linjärt rum (se storgruppsövning 3)

Om  $F: U \rightarrow V$ ,  $H: V \rightarrow W$  lin. avb. är

$$HF: U \rightarrow W \text{ avbildningen } (HF)(u) = H(F(u)) \quad \forall u \in U$$

$HF$  är uppenbart linjär (Låt verka på  $\alpha u + \beta v$ ).

Hur ser matrisen ut?

Om  $U, V, W$  ändlig dim och  $e, f, g$  deras baser

$F$  har matris  $A$ ,  $H$  har matris  $B$  m.a.p. baserna.

$$\Rightarrow \underline{HF \text{ har matris } BA} \quad \text{matrisprodukt}$$

(Detta är grunden för matrisproduktens definition)

### Sats [3.1]

Låt  $F: U \rightarrow V$  lin. arb,  $U$  ändligdim. lin. rum,  $V$  lin. rum (som kan vara oändligdimensionellt). Då är  $V(F)$  ändligdimensionellt och

$$\dim N(F) + \dim V(F) = \dim U$$

(Analog till Sats [1.14] för matriser, liknande bevis)

### Bevisidé

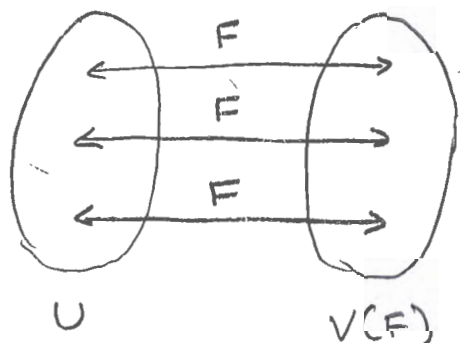
Bitra en bas  $e_1, \dots, e_n$  för  $U$  så att  $\text{span}\{e_1, \dots, e_p\} = N(F)$

Vi får då  $\{F(e_{p+1}), \dots, F(e_n)\}$  bas för  $V(F)$ ,  
(man måste visa att de är linj. obero)

$$\Rightarrow \dim V(F) = n - p = \dim U - \dim N(F) \quad \square$$

Anm. Om  $N(F) = \{0\} \Leftrightarrow \dim N(F) = 0$  får vi att för varje  $v \in V(F)$  finns ett unikt  $u \in U$  så att  $F(u) = v$  och vice versa.

Arbildningen kallas då ISOMORFISM mellan  $U$  och  $V(F)$ .  $U$  och  $V(F)$  kallas ISOMORFA.



Jämför med  
bijektivitet.

"Isomorfa rum har  
i någon mening  
samma form."



Omformulering av sats [1.10]:

$\dim V(F) \leq \dim(U)$ , likhet om  $V(F)$   
och  $U$  är isomorfa.

Om  $e$  är bas för  $U$  är  $F: U \rightarrow \mathbb{R}^{\dim U}$

$F(u) = [u]_e$  en isomorfism. Så

Alla  $n$ -dimensionella rum är isomorfa med  $\mathbb{R}^n$

"Kan vi göra något i  $\mathbb{R}^n$  kan vi göra  
samma sak i alla ändligdimensionella rum."

Exempel Låt

$$f_1(x) = \sin x \quad f_2(x) = x \cos x \quad f_3(x) = x^2 \sin x$$

$$g_1(x) = \cos x \quad g_2(x) = x \sin x \quad g_3(x) = x^2 \cos x$$

$e = \{f_1, f_2, f_3\}$  är lin. ober. i  $C^1(\mathbb{R})$  och

utgör därför en bas för  $U = \text{span}\{f_1, f_2, f_3\}$

$\# = \{g_1, g_2, g_3\}$  p.s.s. bas för  $V = \text{span}\{g_1, g_2, g_3\}$

Låt  $D: U \rightarrow V$  vara deriveringsoperatoren  $D(f) = f'$ .

Derivera  $e$ :

$$f_1'(x) = \cos x = g_1(x)$$

$$f_2'(x) = \cos x - x \sin(x) = g_1(x) - g_2(x)$$

$$f_3'(x) = 2x \sin x + x^2 \cos x = 2g_2(x) + g_3(x)$$

Så  $D$  har i baserna  $e$  och  $\#$  matris:

$$A = \begin{pmatrix} [D e_1]_{\#} & [D e_2]_{\#} & [D e_3]_{\#} \end{pmatrix} = \begin{pmatrix} 1 & 1 & 0 \\ 0 & -1 & 2 \\ 0 & 0 & 1 \end{pmatrix}$$





A är en inverterbar matris

$\Rightarrow \dim(N(D)) = 0 \Rightarrow D$  är en isomorfism  
mellan  $U$  och  $V(D) = V$

T.ex.  $h(x) = (3+x^2)\cos x - 2x\sin x =$

$$= 3g_1(x) - 2g_2(x) + g_3(x) \in V$$

Sök  $k(x) \in U$  s.d.  $Dk = h$ , d.v.s. finn en

primitiv funktion  $k(x) = \int h(x) dx \in U$

$$[h]_{\mathcal{F}} = \begin{pmatrix} 3 \\ -2 \\ 1 \end{pmatrix} \quad \text{Lös } A[k]_{\mathcal{E}} = [h]_{\mathcal{F}} \quad \Leftrightarrow \quad \begin{matrix} \uparrow \\ \text{OBS} \Rightarrow \text{ingen} \\ \text{konstant-} \\ \text{term} \end{matrix}$$

$$\Leftrightarrow \left[ \begin{array}{ccc|c} 1 & 1 & 0 & 3 \\ 0 & -1 & 2 & -2 \\ 0 & 0 & 1 & 1 \end{array} \right] \Rightarrow [k]_{\mathcal{E}} = \begin{pmatrix} -1 \\ 4 \\ 1 \end{pmatrix}$$

$$\text{Alltså } \int h(x) dx = -f_1(x) + 4f_2(x) + f_3(x) = \\ = -\sin x + 4x\cos x + x^2\sin x$$

OBS: Om konstanta funktioner hade ingått i  $U$  hade  $\dim N(D) > 0$  och vi hade inte fått en isomorfism.

## Basbyten vid linjära avbildningar.

### Sats

Låt  $e = \{e_1, \dots, e_n\}$  och  $e' = \{e'_1, \dots, e'_n\}$  vara två baser för det linjära rummet  $V$ .  
Om den linjära avbildningen  $F: V \rightarrow V$  har matris  $A$  m.a.p.  $e$  o matrisen  $A'$  m.a.p.  $e'$  så gäller att  $A' = T_{e' \leftarrow e} A T_{e \leftarrow e'}$ .

### Bevis

Låt  $u \in V$  godt, och  $v = F(u)$ .

Låt  $x = [u]_{e'}$ ,  $x' = [u]_e$ ,  $y = [v]_{e'}$ ,  $y' = [v]_e$

Vi har att  $y = Ax$  o  $y' = A'x'$  per def. av  $A$  och  $A'$ .

$$\underline{A'x'} = y' = T_{e' \leftarrow e} y = T_{e' \leftarrow e} Ax = \underline{T_{e' \leftarrow e} A T_{e \leftarrow e'}} x'$$

Men  $x' = [u]_{e'}$  och  $u$  godt, så

$$A' = T_{e' \leftarrow e} A T_{e \leftarrow e'} \quad \square$$

Def Två matriser  $A, B$  kallas **SIMILÄRA**

om  $B = T^{-1}AT$  för någon matris  $T$ .

(Anm. måste vara kvadratiske matriser)

Determinanten är invariant under  
similaritetstransformationer?

$$\det A' = \cancel{\det T^{-1}} \det A \cancel{\det T} = \det A$$

Determinanten för en linjär avbildning  
är oberoende av val av bas.

## Egenvärden och egenvektorer under basbyten

Om  $A' = T^{-1}AT$  d.v.s.  $A$  och  $A'$

similära (matriser för en avbildning  $F$  i två olika baser)

Karakteristiska polynomet:

$$\begin{aligned}\det(A' - \lambda I) &= \det(T^{-1}AT - \lambda T^{-1}T) = \\ &= \cancel{\det T^{-1}} \det(A - \lambda I) \cancel{\det T} = \\ &= \det(A - \lambda I)\end{aligned}$$

Similära matriser har samma kar. pol  
 $\Rightarrow$  samma egenvärden

Egenvärden för  $F$  är oberoende av bas

Om  $A'y = \lambda y$  d.v.s.  $y$  egenvektor till  $A'$

$$\Rightarrow T^{-1}ATy = \lambda y \Rightarrow ATy = T\lambda y \Rightarrow A(Ty) = \lambda(Ty)$$

Så  $Ty = Te \leftarrow e'y$  är egenvektor till  $A$ .

$y'$ egenvektor till $A'$
$\Updownarrow$
$y = Te \leftarrow e'y$ egenvektor till $A$

Lana, 200421

Ortogonal matriser

Repetition

$A$  ortogonal  $\stackrel{\text{def.}}{\iff} A^T A = I$

Vid basbyte mellan två ON-baser blir transformationsmatrisen ortogonal.

$\langle u, v \rangle = [u]_e \cdot [v]_e$  om  $e$  ON-bas.

Om  $F: V \rightarrow V$  och två baser  $e, e'$  till  $V$  och  $A, A'$  matriserna till  $F$  i resp. bas så

$$\underline{A' = T^{-1} A T}$$

Om  $e$  och  $e'$  är ON-baser:

$$T \text{ ortogonal} \Rightarrow T^T T = I \Rightarrow T^T = T^{-1}$$

$$\Rightarrow \boxed{A' = T^T A T}$$

Detta är mycket enklare att beräkna.

L1



## Linjära avbildningar med ortogonala matris

Ska se:  $A$  ortogonalmatris

$\Rightarrow F$  bevarar avstånd och vinklar

### Sats [3.3]

Antag  $A$  är  $n \times n$ -ortogonalmatris. Då gäller

a)  $\det A = 1$  eller  $-1$

b)  $(Ax) \cdot (Ay) = x \cdot y \quad \forall x, y \in \mathbb{R}^n$

b')  $\|Ax\| = \|x\| \quad \forall x \in \mathbb{R}^n$

b'')  $x$  och  $y$  ortogonala  $\Rightarrow Ax$  och  $Ay$  ortogonala

c)  $A, B$  ortogonala  $n \times n$ -matriser  $\Rightarrow AB$  ortogonal

### Bevis

Per def  $A^T A = I$

a)  $1 = \det I = \det A^T \det A = (\det A)^2$

$\Rightarrow \det A = \pm 1$

b)  $(Ax) \cdot (Ay) = (Ax)^T (Ay) = x^T A^T A y = x^T y = x \cdot y$

b') Låt  $y = x$  i b)  $\Rightarrow \|Ax\|^2 = \|x\|^2$

$\Rightarrow \|Ax\| = \|x\|$

b'')  $x \perp y \Leftrightarrow x \cdot y = 0 \stackrel{b)}{\Rightarrow} (Ax) \cdot (Ay) = 0 \Leftrightarrow Ax \perp Ay$

c)  $(AB)^T (AB) = B^T A^T A B = B^T B = I \quad \square$

### Sats

Om  $A$   $n \times n$ -matris med  $\|Ax\| = \|x\|$  så är  $A$  en ortogonalmatris.

Bevis tag  $x, y \in \mathbb{R}^n$

$$(1) \quad \|Ax + Ay\|^2 = \|Ax\|^2 + 2(Ax) \cdot (Ay) + \|Ay\|^2 = \\ = \|x\|^2 + 2(Ax) \cdot (Ay) + \|y\|^2$$

$$(2) \quad \|Ax + Ay\|^2 = \|A(x+y)\|^2 = \|x+y\|^2 = \\ = \|x\|^2 + 2x \cdot y + \|y\|^2$$

Sätt (1) = (2)

$$\Rightarrow (Ax) \cdot (Ay) = x \cdot y \quad \forall x, y \in \mathbb{R}^n \quad (*)$$

Speciellt för standardbasvektorer  $e_i$ :

$Ae_j = a_j$ , d.v.s. kolonn  $j$  i  $A$

$$a_i \cdot a_j = (Ae_i) \cdot (Ae_j) \stackrel{(*)}{=} e_i \cdot e_j = \begin{cases} 1 & \text{om } i=j \\ 0 & \text{om } i \neq j \end{cases}$$

$$\Rightarrow A^T A = I \quad \square$$

## Geometrisk tolkning av ortogonala matriser

Vinklar och avstånd bevaras.

### 2D-fallet

#### Sats [3.4]



Om  $A$  är en ortogonal  $2 \times 2$  matris är motsvarande avbildning på  $\mathbb{R}^2$  en rotation eller spegling i en linje genom origo.

#### Förklaring

Hur avbildas  $e_1$  och  $e_2$ ?

Sats [3.3]  $\Rightarrow Ae_1$  och  $Ae_2$  ortogonala och längd 1.

#### Två möjligheter:



#### Rotation med

$\theta$  grader kring  $\odot$ :

$$A = \begin{pmatrix} \cos \theta & -\sin \theta \\ \sin \theta & \cos \theta \end{pmatrix}$$

$$\det A = \cos^2 \theta + \sin^2 \theta = 1$$

Spegling i  $l$  genom  $\odot$

$$A = \begin{pmatrix} \cos \theta & \sin \theta \\ \sin \theta & -\cos \theta \end{pmatrix} =$$

$$\det A = -\cos^2 \theta - \sin^2 \theta = -1$$

Ann. Det gäller att

$\det A = 1 \Rightarrow F$  rotation

$\det A = -1 \Rightarrow F$  spegling

## 3D - Fallet

### Sats [3.5]

Antag  $A$  är ortogonal  $3 \times 3$ -matris.

Om  $\det A = 1$  motsvarar  $A$  rotation i  $\mathbb{R}^3$

Om  $\det A = -1$ , motsvarar  $A$  rotation följt av spegling i origo.

### Bevisidé

Om  $\det A = 1$ :

$$\begin{aligned}\det(A - I) &= \det(A - A^T A) = \det((I - A^T)A) = \\ &= \det(I - A^T) \det A = \det(-I(A - I)) = \\ &= \det(-I) \det(A - I) = -\det(A - I)\end{aligned}$$

$\Rightarrow \det(A - I) = 0$  så  $\lambda = 1$  egenvärde

$(A - I)x = 0$  har icke-trivial lös.  $x = Ax$

$x$  bevaras och är rotationsaxeln.

Resterande reduceras till 2D-fallet.

efter ett basbyte med en axel parallell med  $x$ .

### Exempel

$$A = \begin{pmatrix} 0 & 0 & 1 \\ 1 & 0 & 0 \\ 0 & 1 & 0 \end{pmatrix} \text{ ortogonal } 3 \times 3 \text{ m. } \det A = 1$$

Hitta rotationsaxeln.

Lösning: Hitta egenvärdet, d.v.s. lös  $(A - I)x = 0$

$$\Rightarrow \dots \Rightarrow x = \begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix} t \quad t \in \mathbb{R}$$

Bonus:  $y = \begin{pmatrix} 0 \\ 1 \\ -1 \end{pmatrix} \perp x$ . Hur vrider  $y$ ?



$$\cos \theta := \frac{Ay \cdot y}{\|Ay\| \|y\|} = \frac{-1}{\sqrt{2} \sqrt{2}} = -\frac{1}{2} \Rightarrow \theta = \frac{2\pi}{3}$$

## Matrisnormer

### Frobeniusnorm (Mindre vanlig)

$$\|A\|_F := \sqrt{\text{Sp}(ATA)} = \left( \sum_{i=1}^m \sum_{j=1}^n a_{ij}^2 \right)^{1/2}$$

Def Låt  $A$  vara en  $m \times n$ -matris

NORMEN av  $A$  är

$$\|A\| = \sup_{\substack{x \in \mathbb{R}^n \\ x \neq 0}} \frac{\|Ax\|}{\|x\|} \stackrel{(*)}{=} \sup_{\|x\|=1} \|Ax\|$$

(\*) +  $\|A\alpha x\| = \alpha \|Ax\|$  speciellt då  $\alpha = 1/\|x\|$

Anm.  $\|Ax\|$  kontinuerlig funktion av  $x$  och

$\|x\|=1$  är kompakt  $\Rightarrow$  sup antas  $\Rightarrow$  sup = max

$$\text{Så } \|A\| = \max_{\|x\|=1} \|Ax\|$$

Egenskaper  $A, B, C$  matriser

$$\|A+B\| \leq \|A\| + \|B\| \quad (\text{triangelolikheten})$$

$$\|\alpha A\| = |\alpha| \|A\|$$

$$\|A\| \geq 0 \quad \text{likhet omm. } A = \mathbf{0}$$

$$\|Ax\| \leq \|A\| \|x\|$$

$$\|AC\| \leq \|A\| \|C\|$$

$$\|A^T\| = \|A\|$$

$$\|P\| = 1 \quad \text{om } P \text{ ortogonal}$$



## Diagonalisering

### Repetition

A  $n \times n$ -matris,  $x \neq 0$  egenvektor med egenvärde  $\lambda \Leftrightarrow Ax = \lambda x$ . Egenvärdena är rötter till kar. ekv.  $\det(A - \lambda I) = 0$

Egenvektorer är lätta att avbilda. Vi vill därför hitta en bas av egenvektorer.

Antalet linjärt oberoend egenvektorer för en matris är väsentligt.

### Exempel

Låt  $a \in \mathbb{C}$  och  $A = \begin{pmatrix} a+1 & 1 \\ 0 & a \end{pmatrix}$ . Sök egenvärden och egenvektorer. Lösning:

$$\det(A - \lambda I) = \begin{vmatrix} a-\lambda & 1 \\ 0 & a-\lambda \end{vmatrix} = (a-\lambda)^2 \Rightarrow \lambda_1 = \lambda_2 = a$$

$$\text{Egenvektorer: } (A - aI)x = 0 \Leftrightarrow \left[ \begin{array}{cc|c} 0 & 1 & 0 \\ 0 & 0 & 0 \end{array} \right]$$

$$\Rightarrow x = \begin{bmatrix} 1 \\ 0 \end{bmatrix} t \quad t \in \mathbb{C}$$

Endast 1 linj. ober egenvektor.  $\dim E(a) = 1$   
(Men  $\lambda = a$  är en dubbelrot till kar. ekv.)

Slutsats: Bas för  $\mathbb{R}^2$  av egenvektorer till A existerar inte.  $\wedge$

Def För ett egenvärde  $\lambda_k$  är den  
ALGEBRAISKA MULTIPLICITETEN  $m_a$   
multipliciteten av roten  $\lambda_k$  i det kar. pol.  
(d.v.s. kar. pol. har faktor  $(\lambda_k - \lambda)^{m_a}$ .)

Den GEOMETRISKA MULTIPLICITETEN  
är  $m_g = (\dim(E(\lambda_k)))$ .

(d.v.s. max antal lin. ober. egenvektorer till  $\lambda_k$ )

Lemma 4.1

$$m_g \leq m_a$$

Bevis m.h.a. variabelbyte

Anm. Om  $m_g < m_a$  kallas  $\lambda_k$  DEFECT.

Lana 200422

## Diagonalisering

### Repetition

Om  $(\lambda_k - \lambda)^{m_a}$  är faktor i kar. pol.  $\det(A - \lambda I)$   
så är  $m_a$  algebraiska multipliciteten.

$m_g = \dim E(\lambda_k)$  är geometriska multipliciteten.

Def En  $n \times n$ -matris  $A$  är **DIAGONALISERBAR**  
(kan **DIAGONALISERAS**) om  $A$  är similär  
med en diagonal matris  $D$ , d.v.s.  $D = T^{-1}AT$   
för någon inverterbar matris  $T$ .

Diagonalisering kan göras m.h.a. en bas av  
egenvektorer.

### Sats [4.5]

Antag att  $A$  är en  $n \times n$ -matris med  $n$   
linjärt oberoende egenvektorer  $\{e_1, \dots, e_n\}$   
med tillhörande egenvärden  $\{\lambda_1, \dots, \lambda_n\}$ .

Då är  $A$  diagonaliserbar,  $T^{-1}AT = D$  med

$$T = \begin{pmatrix} | & & | \\ e_1 & \dots & e_n \\ | & & | \end{pmatrix} \text{ och } D = \begin{pmatrix} \lambda_1 & \dots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \dots & \lambda_n \end{pmatrix}$$

Varje egenvärde förekommer i  $D$  lika  
många gånger som den algebraiska  
multipliciteten.

## Bevis

Låt  $T$  och  $D$  vara som i satsen.

$T$  har linj. ober. kolonner och är kvadratisk

$\Rightarrow T$  inverterbar.

$$AT = A \begin{pmatrix} | & & | \\ e_1 & \dots & e_n \\ | & & | \end{pmatrix} = \begin{pmatrix} | & & | \\ Ae_1 & \dots & Ae_n \\ | & & | \end{pmatrix} = \begin{pmatrix} | & & | \\ \lambda_1 e_1 & \dots & \lambda_n e_n \\ | & & | \end{pmatrix} \quad \text{eigenvektorer}$$
$$TD = \begin{pmatrix} | & & | \\ e_1 & \dots & e_n \\ | & & | \end{pmatrix} \begin{pmatrix} \lambda_1 & & 0 \\ & \dots & \\ 0 & & \lambda_n \end{pmatrix} = \begin{pmatrix} | & & | \\ \lambda_1 e_1 & & \lambda_n e_n \\ | & & | \end{pmatrix}$$

Så vi har

$$AT = TD \Leftrightarrow T^{-1}AT = D$$

Så  $A$  och  $D$  är similära. Detta ger:

$$\det(A - \lambda I) = \det(D - \lambda I) = (\lambda_1 - \lambda) \dots (\lambda_n - \lambda)$$

$\Rightarrow m_\lambda$  är antal ggr. egenvärdet förekommer i  $D$ .



## Sats [4.6]

Om  $\lambda_1, \dots, \lambda_k$  är olika egenvärden och  $e_1, \dots, e_k$  motsvarande egenvektorer så är  $e_1, \dots, e_k$  linjärt oberoende.

Bevis Antag att  $e_1, \dots, e_k$  är linj. ber.

Låt  $m = \max$  antal linj. ober. vektorer

bland  $e_1, \dots, e_k$ . Efter omnumrering antag

att  $e_1, \dots, e_m$  är linj. ober.

$$\Rightarrow e_k = \alpha_1 e_1 + \dots + \alpha_m e_m \quad (*)$$

$$A(*) : \lambda_k e_k = \alpha_1 \lambda_1 e_1 + \dots + \alpha_m \lambda_m e_m$$

$$\lambda_k (*) : \lambda_k e_k = \alpha_1 \lambda_k e_1 + \dots + \alpha_m \lambda_k e_m$$



→

Sätt de två uttrycken lika:

$$0 = \alpha_1(\lambda_1 - \lambda_k)e_1 + \dots + \alpha_m(\lambda_m - \lambda_k)e_m$$

Men  $e_1, \dots, e_m$  linj. ober,

$$\lambda_i - \lambda_k \neq 0 \quad \forall i = 1, \dots, m \neq k \text{ enl. ant.}$$

$$\text{Så } \alpha_1 = \alpha_2 = \dots = \alpha_m = 0$$

$$\text{Sätt in i (*) } \Rightarrow e_k = 0$$

Motsägelse ty  $e_k$  är egenvektor!

Så  $e_1, \dots, e_k$  måste vara linj. ober.  $\square$

### Sats [4.7]

Om  $n \times n$ -matrisen  $A$  har  $n$  olika egenvärden

(d.v.s. alla egenvärden har  $m_a = 1$ ) så

kan  $A$  diagonaliseras.

### Bevis

Sats [4.6] ger att de  $n$  egenvektorerna

som motsvarar egenvärdena är linj. ober.

$\Rightarrow$  utgör en bas

Sats [4.5] ger diagonaliseringen.  $\square$



Om alg. mult.  $m_a = 1$  för alla egenvärden  
så kan vi diagonalisera. Detta är  
dock inte nödvändigt.

Sats [4.8]

$A$  är diagonaliserbar om och endast om alg. mult  $m_a$   
är lika med geom. mult  $m_g$  för  
varje egenvärde. D.v.s. inga defekta egenvärden.

Exempel  $\begin{pmatrix} a & 1 \\ 0 & a \end{pmatrix}$  ej diagonaliserbar  
ty  $a$  dubbelrot men  $\dim(E(a)) = 1$ .

Def En linj. avb.  $F: V \rightarrow V$  kallas  
SYMMETRISK om  $\langle u, F(v) \rangle = \langle F(u), v \rangle \forall u, v \in V$   
En matris kallas SYMMETRISK om  $A^T = A$ .

Sats [4.9]

Om  $e$  är en ON-bas för  $V$ ,  $F: V \rightarrow V$   
lin. avb. med matris  $A$  i basen  $e$  så  
är  $F$  symmetrisk om och endast om  $A$  är symmetrisk.

Bevis

Med  $x = [u]_e$ ,  $y = [v]_e$   $\langle u, v \rangle = x^T y$ .

$e$  ON-bas

$F$  symmetrisk

$\Leftrightarrow \langle u, F(v) \rangle = \langle F(u), v \rangle$

$\Leftrightarrow x^T A y = (A x)^T y = x^T A^T y \quad \forall x, y$

$\Leftrightarrow A = A^T$



### Sats [4.10]

Om  $A$  är en reell symmetrisk  $n \times n$ -matris så är alla egenvärden till  $A$  reella.

Bevis Låt  $\lambda$  vara egenvärde till  $A$  med egenvektor  $x$  (eventuellt komplexa).

$$Ax = \lambda x \quad \begin{array}{l} \text{komplex-} \\ \text{konjugat} \\ A \text{ reell} \end{array} \Rightarrow A \bar{x} = \overline{\lambda} \bar{x} \quad \begin{array}{l} \text{trans-} \\ \text{ponera} \end{array} \Rightarrow (A \bar{x})^T = \overline{\lambda} \bar{x}^T$$

$$A \text{ sym.} \Rightarrow \bar{x}^T A = \overline{\lambda} \bar{x}^T \quad \begin{array}{l} \text{mult. m.} \\ x \end{array} \Rightarrow \bar{x}^T \underbrace{A x}_{\lambda x} = \overline{\lambda} \bar{x}^T x$$

$$\Rightarrow \lambda \bar{x}^T x = \overline{\lambda} \bar{x}^T x$$

Antingen  $\bar{x}^T x = 0$  eller  $\lambda = \overline{\lambda}$ . Men

$$\bar{x}^T x = \bar{x}_1 x_1 + \dots + \bar{x}_n x_n = |x_1|^2 + \dots + |x_n|^2 > 0$$

$$\Rightarrow \lambda = \overline{\lambda} \quad \text{d.v.s. } \lambda \text{ reell} \quad \square$$

$E(\lambda)$  förs av att lösa  $\overbrace{(A - \lambda I)}^{\text{reell}} x = 0$   
så  $E(\lambda)$  har en bas av reella vektorer.

Reell Gausselimination ger minst en parameter  $\Rightarrow$  minst en lösning  $x \neq 0$ .

### Sats [4.11]

Om  $F$  är symmetrisk och  $u_1, u_2$  är egenvektorer för  $F$  med egenvärden  $\lambda_1 \neq \lambda_2$  så är  $u_1$  och  $u_2$  ortogonala.

$$\text{Bevis } \langle u_1, \overbrace{F(u_2)}^{\lambda_2 u_2} \rangle = \langle \overbrace{F(u_1)}^{\lambda_1 u_1}, u_2 \rangle$$

$$\Leftrightarrow \lambda_2 \langle u_1, u_2 \rangle = \lambda_1 \langle u_1, u_2 \rangle$$

$$\Leftrightarrow \underbrace{(\lambda_2 - \lambda_1)}_{\neq 0} \langle u_1, u_2 \rangle = 0 \Leftrightarrow u_1 \perp u_2 \quad \square$$

## Spektralsatsen

Formulering 1:

Sats [4.12] Spektralsatsen

Om  $F: V \rightarrow V$  symmetrisk och  $V$  ändlig dim.  
så finns en ON-bas för  $V$  bestående  
av egenvektorer till  $F$ .

Formulering 2:

Sats [4.13]

Om  $A$  är en reell symmetrisk matris  
så finns en ortogonal matris  $T$  och  
en diagonal matris  $D$  så att  $T^{-1}AT = D$ .  
Egenvärdena utgör diagonalelementen i  $D$   
och kolonnerna i  $T$  är egenvektorerna.

Bevisidé (Bevis i boken) (Formulering 1)

Karakteristiska polynom har minst en rot  $\lambda$ ,

$\lambda_1$  är reell enligt sats 4.10

Reell Gausselimination ger motsvarande reell

egenvektor:  $u_1$ :

Bilda första baselementet  $e_1 = \frac{u_1}{\|u_1\|}$ .

Låt  $U = \text{span}\{e_1\}^\perp$

Om  $u \in U$  för vilka  $\langle F(u), e_1 \rangle = \langle u, F(e_1) \rangle$

$$= \lambda_1 \langle u, e_1 \rangle = 0$$

$0 + \forall u \in U$

Så  $F(u) \in U$ .  $F$  ger lin. aut.  $F: U \rightarrow U$

$\dim U = \dim V - 1$ . Upprepa argument m.  $U$  ist. för  $V$ .

Vi får till slut ON bas till  $V$ .  $\square$

## Exempel

Ortogonalt diagonalisera  $A = \begin{pmatrix} 2 & 1 & 1 \\ 1 & 2 & 1 \\ 1 & 1 & 2 \end{pmatrix}$

Sök egenvärden:

$$\det(A - \lambda I) = \begin{vmatrix} 2-\lambda & 1 & 1 \\ 1 & 2-\lambda & 1 \\ 1 & 1 & 2-\lambda \end{vmatrix} = \dots$$

$$\dots = (4-\lambda)(1-\lambda)^2 = 0$$

Egenvärden  $\lambda_1 = 4$ ,  $\lambda_2 = 1$  med mult. 2.

Sök egenvektorer:

$$(A - 4I)x = 0 \Leftrightarrow \left[ \begin{array}{ccc|c} -2 & 1 & 1 & 0 \\ 1 & -2 & 1 & 0 \\ 1 & 1 & -2 & 0 \end{array} \right] \sim$$

$$\sim \left[ \begin{array}{ccc|c} 1 & 0 & -1 & 0 \\ 0 & 1 & -1 & 0 \\ 0 & 0 & 0 & 0 \end{array} \right] \Leftrightarrow \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} = \underbrace{\begin{bmatrix} 1 \\ 1 \\ 1 \end{bmatrix}}_{v_1} x_3$$

$$(A - I)x = 0 \Leftrightarrow \left[ \begin{array}{ccc|c} 1 & 1 & 1 & 0 \\ 1 & 1 & 1 & 0 \\ 1 & 1 & 1 & 0 \end{array} \right] \sim$$

$$\sim \left[ \begin{array}{ccc|c} 1 & 1 & 1 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{array} \right] \Leftrightarrow \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} = \underbrace{\begin{bmatrix} -1 \\ 1 \\ 0 \end{bmatrix}}_{v_2} x_1 + \underbrace{\begin{bmatrix} -1 \\ 0 \\ 1 \end{bmatrix}}_{v_3} x_3$$

$v_1$  egenvektor med egenvärde 4:

$v_2$  &  $v_3$  egenvektorer med egenvärde 1.

Sats [4.11] ger  $v_1 \cdot v_2 = 0$  &  $v_1 \cdot v_3 = 0$

ty olika egenvärden.  $v_2 \cdot v_3 = 1 \neq 0$

så vi använder Gram-Schmidt för ON-bas.

$$\Rightarrow e_1 = \frac{1}{\sqrt{3}} \begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix} \quad e_2 = \frac{1}{\sqrt{2}} \begin{pmatrix} -1 \\ 1 \\ 0 \end{pmatrix} \quad e_3 = \frac{1}{\sqrt{6}} \begin{pmatrix} -1 \\ 0 \\ 1 \end{pmatrix}$$

$$\Rightarrow T = \begin{pmatrix} | & | & | \\ e_1 & e_2 & e_3 \\ | & | & | \end{pmatrix} \quad D = \begin{pmatrix} 4 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix} \quad D = T^T A T //$$



Lana 200427

## Tillämpningar av diagonalisering

Rep: A diagonaliserbar

$$\Leftrightarrow \exists T, D: D = T^{-1}AT \text{ eller } A = TDT^{-1}$$

där D diagonal m. egenvärden på diagonalen och T har motsvarande egenvektorer som kolonner.

Om  $A^T = A \exists$  diagonalisering och T ortogonal  
 $\Rightarrow A = TDT^T$

Diagonalisering i många sammanhang.

Ex: geometriska tolkning av lin. avb.

$$A = \begin{bmatrix} 2 & 1 & 1 \\ 1 & 2 & 1 \\ 1 & 1 & 2 \end{bmatrix} = TDT^{-1} \quad D = \begin{bmatrix} 4 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad T = \begin{bmatrix} \frac{1}{\sqrt{3}} & -\frac{1}{\sqrt{2}} & -\frac{1}{\sqrt{6}} \\ \frac{1}{\sqrt{3}} & \frac{1}{\sqrt{2}} & -\frac{1}{\sqrt{6}} \\ \frac{1}{\sqrt{3}} & 0 & \frac{2}{\sqrt{6}} \end{bmatrix}$$

A ger skalning med faktor 4 i riktning  $\frac{1}{\sqrt{3}} \begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix}$ .  
(oförändrat i ortogonala riktningar.)

Ex: matrispotenser, beräkna  $A^k$

$$T^{-1}AT = D \Leftrightarrow A = TDT^{-1}$$

$$A^k = \underbrace{(TDT^{-1})(TDT^{-1}) \dots (TDT^{-1})}_I = TDD \dots DT^{-1} \\ = TD^kT^{-1}$$

$$D^k = \begin{pmatrix} \lambda_1^k & & 0 \\ & \dots & \\ 0 & & \lambda_n^k \end{pmatrix} \text{ eftersom } D \text{ diagonal.}$$



Ex: System av linjära differentialekvationer av ordning 1 med konstanta koeff.

$$\begin{cases} \dot{x}_1(t) = a_{11}x_1(t) + \dots + a_{1n}x_n(t) \\ \vdots \\ \dot{x}_n(t) = a_{n1}x_1(t) + \dots + a_{nn}x_n(t) \end{cases} \Leftrightarrow \dot{x}(t) = Ax(t)$$

vektorvärda funktioner

Begynnelsevärden  $x(0) = x_0 \in \mathbb{R}^n$

Systemet är kopplat och kan vara svårlost, men om  $A$  är diagonaliserbar,  $A = TDT^{-1}$ :

Gör variabelbytet  $y(t) = T^{-1}x(t) \Leftrightarrow x(t) = Ty(t)$   
 $\dot{x}(t) = Ax(t) \Leftrightarrow$

$$\underline{\underline{y'(t) = T^{-1}x'(t) = T^{-1}Ax(t) = T^{-1}ATy(t) = Dy(t)}}$$

$$\Leftrightarrow \begin{cases} \dot{y}_1(t) = \lambda_1 y_1(t) \\ \vdots \\ \dot{y}_n(t) = \lambda_n y_n(t) \end{cases} \xrightarrow{\text{Lätt!}} \begin{cases} y_1(t) = c_1 e^{\lambda_1 t} \\ \vdots \\ y_n(t) = c_n e^{\lambda_n t} \end{cases}$$

där  $\begin{pmatrix} c_1 \\ \vdots \\ c_n \end{pmatrix} = y(0) = T^{-1}x(0) = T^{-1}x_0$  Löst!

Så  $c_1, \dots, c_n$  ges av  $T \begin{pmatrix} c_1 \\ \vdots \\ c_n \end{pmatrix} = x_0$

Lösningen till systemet:  $x(t) = Ty(t)$ .

Om  $T = (u_1, \dots, u_n)$  (egenvektorer) blir

$$x(t) = Ty(t) = (u_1, \dots, u_n)y(t) \\ = c_1 e^{\lambda_1 t} u_1 + \dots + c_n e^{\lambda_n t} u_n$$

Utan begynnelsevillkor blir  $\{e^{\lambda_1 t}, \dots, e^{\lambda_n t}\}$  en bas för systemets lösningsrum.

OBS: Behöver ej  $T^{-1}$ , bara lösn. till  $T \begin{pmatrix} c_1 \\ \vdots \\ c_n \end{pmatrix} = x_0$

OBS:  $A$  behöver bara vara diagonaliserbar, inte symmetrisk. Dock kan vi få komplexa egenvärden  $\Rightarrow$  komplexa exp. funktioner.

## Lite mer om vektor- och matrisnormer

Def För  $x \in \mathbb{R}^n$  definierar vi normerna:

• Summanormen / 1-normen:

$$\|x\|_1 = \sum_{i=1}^n |x_i|$$

• Euklidiska normen / 2-normen:

$$\|x\|_2 = \left( \sum_{i=1}^n |x_i|^2 \right)^{1/2} = \sqrt{x^T x}$$

• Maximumnormen,  $\infty$ -normen:

$$\|x\|_\infty = \max_{1 \leq i \leq n} |x_i|$$

Hittills har vi använt  $\|x\| = \|x\|_2$

I matlab: `norm(x, 1)`, `norm(x, 2)`, `norm(x, Inf)`

Varje vektornorm ger en matrisnorm:

$$\|A\|_\star = \max_{x \neq 0} \frac{\|Ax\|_\star}{\|x\|_\star} \quad \text{där } \star = 1, 2, \infty$$

Summanorm:

$$\|A\|_1 = \max_{1 \leq j \leq n} \sum_{i=1}^n |a_{ij}| \quad (\text{maximala kolonnsumman till belopp})$$

Euklidisk norm:

$$\|A\|_2 = \sqrt{\lambda_1} \quad \text{där } \lambda_1 \text{ största egenvärde till } A^T A.$$

Maximumnormen:

$$\|A\|_\infty = \max_{1 \leq i \leq n} \sum_{j=1}^n |a_{ij}| \quad (\text{maximala radsumman till belopp})$$

2-norm "bäst",  $1$  &  $\infty$  kan vara snabbast, mer behändliga vid beräkning

## Kvadratiska former

Def En KVADRATISK FORM på  $\mathbb{R}^n$  är en funktion  $Q: \mathbb{R}^n \rightarrow \mathbb{R}$  som kan skrivas på formen  $Q(x) = x^T A x$  där  $A$  är en symmetrisk  $n \times n$ -matris. d.v.s.  $Q(x_1, \dots, x_n)$  är ett andragrads-polynom i  $x_1, \dots, x_n$  med bara andra-gradstermer.

Ex:  $x = \begin{pmatrix} x_1 \\ x_2 \end{pmatrix}$   $A = \begin{pmatrix} 2 & 0 \\ 0 & 3 \end{pmatrix}$  diagonalelement

$$Q(x) = (x_1 \ x_2) \begin{pmatrix} 2 & 0 \\ 0 & 3 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = 2x_1^2 + 3x_2^2$$

summa av 2 (-1)or

$$A = \begin{pmatrix} 3 & -1 \\ -1 & 5 \end{pmatrix} \Rightarrow Q(x) = 3x_1^2 - 2x_1x_2 + 5x_2^2$$

Ex: Söker  $A$  givet  $Q$ :

$$Q(x) = 2x_1^2 + 2x_2^2 + 2x_3^2 + 2x_1x_2 + 2x_2x_3 + 2x_3x_1$$

$$A = \begin{pmatrix} 2 & 1 & 1 \\ 1 & 2 & 1 \\ 1 & 1 & 2 \end{pmatrix} \quad \text{OBS: finns fler } A \text{ s\u00e5 } x^T A x = Q \text{ men bara en symmetrisk.}$$

Vi v\u00f6ljer att alltid ha  $A$  symmetrisk f\u00f6r enkelhetens skull. Kan d\u00f6 diagonalisera.

Vi vill skriva  $Q$  som en summa av kvadrater f\u00f6r att avg\u00f6ra dess form.  $Q$  \u00e4r en summa av kvadrater om  $A$  \u00e4r diagonal.

Vi vet sedan tidigare  $A = T D T^T$  med

$$D = \begin{pmatrix} 4 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix} \quad T = \begin{pmatrix} 1/\sqrt{3} & -1/\sqrt{2} & -1/\sqrt{6} \\ 1/\sqrt{3} & 1/\sqrt{2} & -1/\sqrt{6} \\ 1/\sqrt{3} & 0 & 2/\sqrt{6} \end{pmatrix}$$



→

In för variabelbytet  $y = T^T x \Leftrightarrow x = Ty$

$$Q = \underbrace{x^T A x}_{\text{Blandade termer}} = (Ty)^T A Ty = y^T T^T A T y = \underbrace{y^T D y}_{\text{bara kvadrater!}}$$

OBS:  $Q$  är en summa av kvadrater så

$Q \geq 0$  med likhet omm  $y = 0 \Leftrightarrow x = 0$

Kallas POSITIVT DEFINIT.

Def En kvadratisk form  $Q(x)$  är

- POSITIVT DEFINIT om  $Q(x) > 0 \quad \forall x \neq 0$   
(positivt semidefinit om  $Q(x) \geq 0$ )
- NEGATIVT DEFINIT om  $Q(x) < 0 \quad \forall x \neq 0$   
(negativt semidefinit om  $Q(x) \leq 0$ )
- INDEFINIT om  $Q$  antar både positiva och negativa värden.

Sats [4.14]

$Q(x) = x^T A x$  är

- a) pos. def. omm alla egenvärden är positiva
  - b) neg. def. omm alla egenvärden är negativa
  - c) indefinit omm  $A$  har både positiva och negativa egenvärden.
- semidefinit tillåter egenvärde 0.

Bevisidé:  $A$  symmetrisk  $\Rightarrow$  diagonaliserbar

$$Q = x^T A x = y^T D y = \lambda_1 y_1^2 + \dots + \lambda_n y_n^2$$

$T$  inverterbar ger  $x = 0$  omm  $y = 0$

Tecken på  $Q$  avgörs av tecken på  $\lambda_i$ .

### Sats [4.15]

A reell symmetrisk med  $\lambda_{\min}$ ,  $\lambda_{\max}$  största resp. minsta egenvärde. Då är

$$\lambda_{\min} \|x\|^2 \leq x^T A x \leq \lambda_{\max} \|x\|^2$$

Likhet för motsvarande egenvektoren.

### Bevisidé:

$$\begin{aligned} x^T A x &= y^T D y = \lambda_1 y_1^2 + \dots + \lambda_n y_n^2 \leq \\ &\leq \lambda_{\max} (y_1^2 + \dots + y_n^2) = \lambda_{\max} \|y\|^2 \end{aligned}$$

Men  $\|y\|^2 = \|T x\|^2 = \|x\|^2$  ty  $T$  ortogonal

Så  $x^T A x \leq \lambda_{\max} \|x\|^2$  och p.s.s. för min.

### Tillämpning för matrisnormer:

$$\|A\| = \max_{x \neq 0} \frac{\|Ax\|}{\|x\|} = \max_{\|x\|=1} \|Ax\|$$

$$\|Ax\|^2 = (Ax)^T Ax = x^T \overset{\text{Satsen}}{A^T A} x \leq \lambda_1 \|x\|^2$$

där  $\lambda_1$  är största egenvärdet av den symmetriska matrisen  $A^T A$ .

Låt  $\|x\|=1$  och  $x$  egenvektor till största egenvärdet.

$$\|A\| = \sqrt{\lambda_1} \quad \text{där } \lambda_1 = \lambda_{\max} \text{ för } A^T A.$$

( $\|A\|$  betecknar euklidiska normen av  $A$ )



Lana 200504

Numerisk lösning av icke-linjära ekv. sys.

Repetition

Söker rot  $x^*$  till ekvationen  $f(x) = 0$ .

Någon metod ger talföljd  $\{x_k\}_{k=0}^{\infty}$  som

konvergerar om  $x_k \rightarrow x^*$  med

konvergensordning  $q > 0$  om

$$\lim_{k \rightarrow \infty} \frac{|x_{k+1} - x^*|}{|x_k - x^*|^q} = C < \infty$$

Newtons metod  $x_{k+1} = x_k - \frac{f(x_k)}{f'(x_k)}$   $k=0, 1, \dots$

konvergerar lokalt kvadratisk ( $q=2$ )

mot enkelrötter.

System av icke-linjära ekvationer

Studera system  $f(x) = 0$ ,  $f: \mathbb{R}^n \rightarrow \mathbb{R}^n$

(lika många ekvationer som variabler)

Istället för  $f'(x)$  får vi Jacobianmatrisen  $J(x)$ .

$$(J(x))_{ij} := \frac{\partial f_i}{\partial x_j}(x)$$


En rot  $x^* \in \mathbb{R}^n$  kallas SINGULÄR om

$J(x^*)$  är singulär (ej inverterbar matris).

Annars kallas  $x^*$  REGULJÄR.

Exempel  $f: \mathbb{R}^2 \rightarrow \mathbb{R}^2$   $x \in \mathbb{R}^2$

$$f(x) = \begin{pmatrix} x_1^2 + x_2^2 - 1 \\ x_1^2 - x_2 - 1 \end{pmatrix} = \begin{pmatrix} f_1(x) \\ f_2(x) \end{pmatrix}$$



Vi får grafiskt tre rötter till  $f(x)=0$ :

$$x^* = \begin{pmatrix} -1 \\ 0 \end{pmatrix}, x^2 = \begin{pmatrix} 0 \\ -1 \end{pmatrix}, x^3 = \begin{pmatrix} 1 \\ 0 \end{pmatrix}$$

$$J(x) = \begin{pmatrix} 2x_1 & 2x_2 \\ 2x_1 & -1 \end{pmatrix}$$

$$J(x^1) = \begin{pmatrix} -2 & 0 \\ -2 & -1 \end{pmatrix} \text{ inverterbar} \Rightarrow x^1 \text{ reguljär rot}$$

$$\left[ \begin{array}{l} J(x^2) = \begin{pmatrix} 0 & -2 \\ 0 & -1 \end{pmatrix} \text{ ej inverterbar} \\ \Rightarrow x^2 \text{ singular rot} \end{array} \right]$$

Grafiskt ser vi detta på att  $f_1(x)=0$  och  $f_2(x)=0$  tangeras varandra i  $x^2$ .

$$J(x^3) = \begin{pmatrix} 2 & 0 \\ 2 & -1 \end{pmatrix} \text{ inverterbar} \Rightarrow x^3 \text{ reguljär rot.}$$

## Newton's metod för system

Idé: Flervariabel Taylorutveckling kring  
approximativ rot  $x_k$ . ( $k$  iterationsindex)

$$f_i(x) \approx f_i(x_k) + \nabla f_i(x_k)^T (x - x_k)$$

$$\Rightarrow f(x) \approx f(x_k) + J(x_k)(x - x_k)$$

En linjär modell:  $0 = f(x_k) + J(x_k)(x - x_k)$   
med lösning  $x_{k+1}$  ger, med  $s_k = x_{k+1} - x_k$

$$\boxed{J(x_k)s_k = -f(x_k)}$$

Detta är vår nya Newtons metod.


Lös ekvationssystemet

$$\Rightarrow \text{för "sökriktning" } s_k = x_{k+1} - x_k$$

Likheter med envariabel fallet:


- Endast lokal konvergens
- Kvadratisk konvergens mot reguljär rot,  
annars linjär konvergens.

För vårt exempel:  $x_0 = \frac{1}{2} \begin{pmatrix} 1 \\ 1 \end{pmatrix}$  ger kvadratisk  
konvergens mot  $x^*$  men  $x_0 = \frac{1}{2} \begin{pmatrix} 1 \\ -2 \end{pmatrix}$  ger  
linjär konvergens mot  $x^*$



$$x_0 = \frac{1}{2} \begin{pmatrix} 1 \\ 1 \end{pmatrix}$$

$$x^* = \begin{pmatrix} 1 \\ 0 \end{pmatrix}$$



$$x_0 = \frac{1}{2} \begin{pmatrix} 1 \\ -2 \end{pmatrix}$$

$$x^* = \begin{pmatrix} 0 \\ -1 \end{pmatrix}$$


## Alternativ till Newtons metod:

Newton's metod har problem:

- o Endast lokal konvergens

Divergens beror ofta på att

$\|s_k\|$  ej avtar  $\Rightarrow$  "går förbi lösningen"



Lösning: Modifiera steglängden

## Dämpad Newtons metod

$$J(x) s_k = -f(x_k), \quad x_{k+1} = x_k + \alpha_k s_k$$

där  $\alpha_k \leq 1$  (dämpar steglängd)

Välj varje  $\alpha_k$  s.a.  $\|f(x_{k+1})\| < \|f(x_k)\|$  (\*)

(d.v.s. ny punkt alltid bättre än gammal)

Kan t.ex. halvera  $\alpha_k$  tills (\*) uppfylls

OBS:  $\alpha_k < 1$  ger långsammare konvergens

$\Rightarrow$  Övergå till  $\alpha_k = 1$  nära roten för

att bibehålla Newtons konvergenshastighet.

- o Newtons metod kräver lösning av ett nytt ekvationssystem för varje iteration.

Långsamt för stora matriser.

Det är bättre om bara HL uppdateras

Kan använda LU-faktorisering (14 maj)

Faktorisering kräver  $O(n^3)$  operationer

Varje nytt högerled kräver  $O(n^2)$  operationer.

Använd  $J(x_0)$  istället för  $J(x_k)$

(samma matris varje iteration)





$$\rightarrow \boxed{J(x_k) s_k = -f(x_k) \quad x_{k+1} = x_k + s_k}$$

Ej kvadratisk konvergens

=> fler iterationer (men varje iter. snabb)

Newtons metod kräver känd Jacobian

Broydens metod

Om  $B_k$  approximerar  $J(x_k)$  för vi

kvasi-Newtonmetoder:

$$\boxed{B_k s_k = -f(x_k) \quad x_{k+1} = x_k + s_k}$$

Bra om  $J(x_k)$  är svår/omöjlig att beräkna

Börja med  $B_0 = J(x_0)$  eller en approximation

Broydens: Uppdatera bara  $B_{k+1}$  i riktning  $s_k$

$$B_{k+1} s_k \approx J(x_{k+1}) s_k$$

Taylorutv. kring  $x_{k+1}$ :

$$f(x_k) \approx f(x_{k+1}) + J(x_{k+1})(x_k - x_{k+1})$$

$$\Leftrightarrow f(x_{k+1}) - f(x_k) \approx J(x_{k+1}) s_k$$

Vill alltså ha  $B_{k+1} s_k = f(x_{k+1}) - f(x_k)$

men oförändrad i ortogonala riktningar:

$$B_{k+1} z = B_k z \quad \forall z: s_k \cdot z = 0$$

Detta ger Broydens metod:

$$\boxed{B_{k+1} = B_k + \frac{1}{\|s_k\|^2} (f(x_{k+1}) - f(x_k) - B_k s_k) s_k^T}$$

Vi slipper beräkna derivator!

(Jämför med sekantmetoden)



## Fixpunktsiterationer

Som i envariabel fallet:

$f(x) = 0$  skrivs om som  $x = g(x)$

$f, g: \mathbb{R}^n \rightarrow \mathbb{R}^n$   $x \in \mathbb{R}^n$

ger metoden  $x_{k+1} = g(x_k)$

När konvergerar metoden?

Om  $G(x)$  är Jacobianen för  $g(x)$  för

vi lokal konvergens om

matris-norm  $\rightarrow \|G(x)\| \leq \mu < 1$  nära  $x^*$

Feluppskattning:

$$\|x_{k+1} - x^*\| \leq \frac{\mu}{1-\mu} \|x_{k+1} - x_k\|$$

för  $x_k$  nära  $x^*$

## Metodoberoende feluppskattning

Som i envariabel fallet (nästan)

$$\delta x = \hat{x} - x^* \quad \hat{x} \in \mathbb{R}^n \text{ approximation}$$

Taylorutveckling kring  $x^*$ :

$$\begin{aligned} f(\hat{x}) &= f(x^* + \delta x) = \\ &= f(x^*) + J(x^*) \delta x + \mathcal{O}(\|\delta x\|^2) \approx \\ &\approx J(x^*) \delta x \end{aligned}$$

Vid reguljör rot existerar  $J(x^*)^{-1}$

$$\Rightarrow \delta x \approx J(x^*)^{-1} f(\hat{x}) \approx J(\hat{x})^{-1} f(\hat{x})$$

Metodoberoende  
feluppskattning



## MATLAB

fzero söker rot till  $f(x) = 0$  i  
envariabel fallet

fsolve motsvarande för flervariabel fallet.

Lana 200505

## Funktionsapproximation, interpolation & splines

Approximera funktioner med polynom av en viss grad, alt. styckvisa polynom (inkl. styckvis linjära funktioner)


- Ger en ändlig representation
- Snabba att evaluera
- Enkla att derivera och integrera

### Polynominterpolation

En funktion  $f$  approximeras med  $\hat{f}$  så att de stämmer överens i vissa punkter.

Def Om  $f: \mathbb{R} \rightarrow \mathbb{R}$  och  $x_0, \dots, x_n$  är  $n+1$  st punkter och  $\hat{f}(x_i) = f(x_i) \quad i = 0, \dots, n$  sägs  $\hat{f}$  INTERPOLERA  $f$  i punkterna  $x_0, \dots, x_n$ .

Med  $f_i = f(x_i)$  och  $\hat{f}_i = \hat{f}(x_i)$  har vi interpolationsvillkoren  $\hat{f}_i = f_i \quad i = 0, \dots, n$



OBS: för de flesta punkter är  $\hat{f}(x) \neq f(x)$   
kan dock gälla att  $f(x) \equiv \hat{f}(x)$

## "Sats"

Det finns entydigt polynom  $p_n$  med grad  $p_n \leq n$  som går genom de  $n+1$  punkterna  $(x_i, f_i) \quad i = 0, \dots, n$ .

OBS:  $x_0, \dots, x_n$  måste vara olika

$p_n$  kallas INTERPOLATIONSPOLYNOMET till  $f$  i punkterna.

## Förklaring

$p_n$  entydigt, ty om  $\tilde{p}_n$  uppfyller samma villkor har  $p_n - \tilde{p}_n$  nollställen  $x_0, \dots, x_n$  ( $n+1$ st) men det är ett polynom med grad  $\leq n$ .

$$\Rightarrow p_n - \tilde{p}_n \equiv 0 \Rightarrow p_n \equiv \tilde{p}_n$$

## Olika konstruktioner

o Lagranges form (ej praktisk)

o Newtons form

Ansats:

$$p_n(x) = c_0 + c_1(x-x_0) + c_2(x-x_0)(x-x_1) + \dots + \dots + c_n(x-x_0)(x-x_1)\dots(x-x_{n-1})$$

OBS:  $p_n(x)$  har grad  $\leq n$

Interpolationsvillkoren ger  $p_n(x_i) = f_i$

$$\begin{cases} f_0 = p_n(x_0) = c_0 \\ f_1 = p_n(x_1) = c_0 + c_1(x_1 - x_0) \\ f_2 = p_n(x_2) = c_0 + c_1(x_2 - x_0) + c_2(x_2 - x_0)(x_2 - x_1) \\ \vdots \\ f_n = p_n(x_n) = c_0 + \dots + c_n(x_n - x_0)(x_n - x_1)\dots(x_n - x_{n-1}) \end{cases}$$

Lös med framåt substitution!

Egenskaper för Newtons interpolationsmetod:

◦ Enkelt att lägga till en punkt.

(tidigare  $c_i$  kan återanvändas)

◦ För evaluering krävs  $0+1+2+\dots+n = \frac{n(n+1)}{2}$  multiplikationer. Men!

Skriv om:

$$p_n(x) = (x-x_0)(c_1 + (x-x_1)(c_2 + (x-x_2)\dots))\dots$$

Nu har vi bara  $n$  multiplikationer!

→ Snabb evaluering

### Exempel

Interpolera  $f(x) = \frac{3x+1}{1+x^2}$  i  $(x_0, x_1, x_2, x_3) = (-1, 0, 1, 3)$

Vi får  $f_0 = -1$ ,  $f_1 = 1$ ,  $f_2 = 2$ ,  $f_3 = 1$

$$\begin{pmatrix} 1 & 0 & 0 & 0 \\ 1 & 1 & 0 & 0 \\ 1 & 2 & 2 & 0 \\ 1 & 4 & 12 & 24 \end{pmatrix} \begin{pmatrix} c_0 \\ c_1 \\ c_2 \\ c_3 \end{pmatrix} = \begin{pmatrix} -1 \\ 1 \\ 2 \\ 1 \end{pmatrix} \Rightarrow \begin{pmatrix} c_0 \\ c_1 \\ c_2 \\ c_3 \end{pmatrix} = \begin{pmatrix} -1 \\ 2 \\ -1/2 \\ 0 \end{pmatrix}$$

$$\begin{aligned} \Rightarrow \hat{f}(x) &= c_0 + (x-x_0)(c_1 + (x-x_1)(c_2 + (x-x_2)c_3)) = \\ &= \dots = -1 + (x-1)(2 - \frac{1}{2}x) = \\ &= -1 + 2x - \frac{1}{2}x^2 - 2 + \frac{1}{2}x = \\ &= -\frac{1}{2}x^2 + \frac{5}{2}x - 3 \end{aligned}$$



## Interpolationsfel

Fel: p.g.a. ändlig representation kallas ofta trunkeringsfel. I vårt fall: interpolationsfel

### Sats

Om  $f \in C^{n+1}$  ( $n+1$  kont. derivator) och  $p_n$  interpolerar  $f$  i  $x_0, \dots, x_n$  är interpolationsfelet

$$p_n(x) - f(x) = - \frac{f^{(n+1)}(\xi)}{(n+1)!} (x-x_0)(x-x_1)\dots(x-x_n)$$

där  $\xi$  ligger mellan  $x_0, x_1, \dots, x_n$ , och  $x$  d.v.s.  $\xi$  större än minsta och mindre än största.

OBS: Interpolationsfelet är 0 i  $x_0, \dots, x_n$

Om  $f$  är polynom av grad  $\leq n \Rightarrow p_n \equiv f$

(eftersom  $f^{(n+1)}(\xi) = 0$ )

Bevisidé: Låt  $x$  vara godtycklig fix punkt.

Konstruera interpolationspolynom  $p_{n+1}(t)$

som även interpolerar  $f$  i punkten  $x$ .

$$p_{n+1}(t) = p_n(t) + c_{n+1}(x) (t-x_0)(t-x_1)\dots(t-x_n)$$

beror av  $x$

Argument med medelvärdesatsen eller

Rolles sats ger


$$c_{n+1}(x) = \frac{f^{(n+1)}(\xi)}{(n+1)!}$$

$f(x) = p_{n+1}(x)$  ty  $p_{n+1}$  interpolerar  $f$  i  $x$

$\Rightarrow$  ger satsen.

## Runges fenomen

Interpolationspolynom med högt gradtal ger dåligt resultat. Mellan punkterna kan felet bli stora. Utanför "punkternas intervall" blir det ännu värre.




Jämt utspridda punkter är dåligt.

Chebyshev: Om interpolationspolynom på  $[-1, 1]$  är  $x_i = \cos\left(\frac{(2i-1)\pi}{2n}\right)$   $i = 1, \dots, n$  bästa valet för  $n$  punkter. (tätare i kanter).

Andra lösningar:

- o Lägre gradtal
- o Styckvisa funktioner
  - Linjär styckvis
  - Kubisk spline

Chebyshevspridningen:





Jämt utspridda på halvcirkel  
projicerade  
på x-axeln

## Interpolation med splines

Def En SPLINE  $s(x)$  av grad  $k$  är ett styckvis polynom av grad  $k$  med kontinuerliga derivator av ordning  $k-1$ , över integrationspunkterna.

- o  $k=1$ : linjär spline, styckvis linjär funktion
- o  $k=2$ : svört (parabel lämpar sig dåligt)
- o  $k=3$ : kubisk spline, vanligast.



$s(x)$  spline av grad 3.

$$s(x) = \begin{cases} s_1(x) & x \in [x_0, x_1] \\ s_2(x) & x \in [x_1, x_2] \\ s_3(x) & x \in [x_2, x_3] \end{cases}$$

Splinevillkor:

$$s_1(x_0) = f(x_0)$$

$$s_1(x_1) = s_2(x_1) = f(x_1), \quad s_1'(x_1) = s_2'(x_1), \quad s_1''(x_1) = s_2''(x_1)$$

$$s_2(x_2) = s_3(x_2) = f(x_2), \quad s_2'(x_2) = s_3'(x_2), \quad s_2''(x_2) = s_3''(x_2)$$

$$s_3(x_3) = f(x_3)$$

Splines är ej entydigt bestämda

Behöver ändpunktsvillkor eller randvillkor.

Olika alternativ:

1) Rätta randvillkor

$$s'(x_0) = f'(x_0) \quad s'(x_n) = f'(x_n)$$

2) Naturliga randvillkor

$$s''(x_0) = 0 \quad s''(x_n) = 0$$

3) Periodiska randvillkor

$$s'(x_0) = s'(x_n), \quad s''(x_0) = s''(x_n)$$

4) "Not a knot" / Ingen nod

$$s_1'''(x_1) = s_2''(x_1), \quad s_{n-1}'''(x_{n-1}) = s_n''(x_{n-1})$$

$$\text{ger } s_1(x) = s_2(x), \quad s_{n-1}(x) = s_n(x)$$

Man tar bort noderna  $x_1$  och  $x_{n-1}$

Kubiska splines ger ofta bra approximationer.

MATLAB:

polyfit för polynominterpolation

spline för kubisk spline (spline toolbox)

Lana 200507

## Numerisk integration

### Repetition

$$p_n(x) = c_0 + c_1(x-x_0) + c_2(x-x_0)(x-x_1) \dots (x-x_{i-1})$$

Interpolationsvillkoren  $p_n(x_i) = f_i$  ger  $c_0, \dots, c_n$

Interpolationsfelet ges om  $f \in C^{n+1}$  av

$$p_n(x) - f(x) = - \frac{f^{(n+1)}(\xi)}{(n+1)!} (x-x_0) \dots (x-x_n)$$

där  $\xi$  mellan största och minsta av  $x_0, \dots, x_n, x$

Vi vill beräkna  $\int_a^b f(x) dx$  numeriskt.

### Varför numeriskt?

- $f$  explicit men saknar elementär primitiv  
Ex:  $f(x) = e^{-x^2}$
- $f$  inte explicit men beräkningsbar  $\forall x \in [a, b]$
- $f$  given endast i vissa punkter.
- Analytisk lösning finns men ger numeriska problem.

$$\text{Ex, } \int_{1000}^{1001} \frac{1}{x^2-1} dx = \frac{\arctan(1001)}{1,5697973\dots} - \frac{\arctan(1000)}{1,5697963\dots}$$

Risk för stort cancellationsproblem.



## Kvadraturformler

Vill bara använda funktionsvärden.

Approximera integral som viktad summa:

$$\int_a^b f(x) dx = \sum_{i=1}^n w_i f(x_i) - R_T \quad \leftarrow \text{trunkeringsfel}$$

Kallas kvadraturformler ( $w_i$  för  $c_j$  bero på  $f$ ).

Approximation av  $f(x)$  med interpolationspolynom

$p_n(x)$  följt av integration av  $p_n(x)$  ger


## Newton-Cotes kvadraturformler

Euklaste fallet: Förstgradspolynom ( $n=1$ )

Interpolationspunkter  $a \leq b$

$$p_1(x) = c_0 + c_1(x-a) \quad c_0 = f(a) \quad c_1 = \frac{f(b) - f(a)}{b-a}$$

$$\int_a^b p_1(x) dx = \left[ c_0(x-a) + \frac{c_1}{2}(x-a)^2 \right]_a^b = \dots \quad \begin{array}{l} \swarrow \text{medelvärde} \\ \searrow \text{bredd} \end{array}$$
$$= c_0(b-a) + \frac{c_1}{2}(b-a)^2 = \frac{f(a) - f(b)}{2}(b-a)$$



Kallas trapezmetoden

## Trunkeringsfelet:

$$R_T := \int_a^b (p_1(x) - f(x)) dx =$$

$$= - \int_a^b \frac{f''(\xi)}{2!} (x-a)(x-b) dx =$$

$$\eta \in [a, b] \quad \rightarrow \quad = - \frac{f''(\eta)}{2} \int_a^b (x-a)(x-b) dx = \dots =$$

$$= \frac{f''(\eta)}{12} (b-a)^3$$

formel för fel vid interpolation

integralkalkylens generaliserade MV-sats



### Trapetsregeln

$$\int_a^b f(x) dx = \frac{(b-a)}{2} (f(a) + f(b)) - \underbrace{\frac{f''(\eta)}{12} (b-a)^3}_{R_T}$$

för något  $\eta \in [a, b]$

OBS:  $R_T = 0$  om  $f$  är förstegradspolynom.  
 $R_T = O(\text{intervalllängd}^3)$

### Simpsons regel

Interpolera med ett andragsgradspolynom  $p_2(x)$

i punkterna  $a$  och  $b$  men även  $\frac{a+b}{2}$

$$p_2(x) = p_1(x) + c_2(x-a)(x-b)$$

$$p_2\left(\frac{a+b}{2}\right) = f\left(\frac{a+b}{2}\right) \Rightarrow c_2 = \frac{2f(a) + 2f(b) - 4f\left(\frac{a+b}{2}\right)}{(b-a)^2}$$

$$\begin{aligned} \int_a^b p_2(x) dx &= \int_a^b p_1(x) dx + c_2 \int_a^b (x-a)(x-b) dx = \\ &= \frac{f(a) + f(b)}{2} (b-a) - \frac{c_2}{6} (b-a)^3 = \\ &= \frac{f(a) + 4f\left(\frac{a+b}{2}\right) + f(b)}{6} (b-a) \end{aligned}$$

Kan bestämma  $R_T$  som för trapetsregeln.

### Simpsons regel

$$\int_a^b f(x) dx = \frac{b-a}{6} (f(a) + 4f\left(\frac{a+b}{2}\right) + f(b)) + R_T$$

$$R_T = \frac{f^{(4)}(\eta)}{2880} (b-a)^5 \text{ för något } \eta \in [a, b]$$

OBS:  $R_T = 0$  för kubiska polynom (oväntat!)  
Bli r ej bättre med  $p_3(x)$  approximation.

## Trapetsformeln

Dela upp  $[a, b]$  i delintervall med längd

$h = (b-a)/n$  och använd trapetsregeln på varje.

$$T(h) = h \left( \underbrace{\frac{f(x_0)}{2} + \frac{f(x_1)}{2}}_{[x_0, x_1]} + \underbrace{\frac{f(x_1)}{2} + \frac{f(x_2)}{2}}_{[x_1, x_2]} + \dots + \underbrace{\frac{f(x_{n-1})}{2} + \frac{f(x_n)}{2}}_{[x_{n-1}, x_n]} \right)$$
$$= h \left( \frac{f(x_0)}{2} + \frac{f(x_n)}{2} + \sum_{i=1}^{n-1} f(x_i) \right)$$

$$\int_a^b f(x) dx = T(h) + R_T$$

$$\text{där } R_T = \frac{b-a}{12} h^2 f''(\xi) \text{ där } \xi \in [a, b]$$

Som Riemannintegral men medelvärde på varje intervall!

## Förklaring till $R_T$ :

Summa  
av fel

$$R_T = \sum_{i=0}^{n-1} \frac{h^3}{12} f''(\eta_i) \text{ där } \eta_i \in [x_i, x_{i+1}] \subset [a, b]$$

$$\Rightarrow R_T = \frac{(b-a)h^2}{12} \cdot \underbrace{\frac{1}{n} \sum_{i=0}^{n-1} f''(\eta_i)}_{\text{medelvärde av } f''(\eta_i)}$$

Satsen om mellanliggande värde ger

$$\frac{1}{n} \sum_{i=0}^{n-1} f''(\eta_i) = f''(\xi) \text{ för något } \xi \in [a, b]$$

$$\Rightarrow \boxed{R_T = \frac{b-a}{12} h^2 f''(\xi)}$$

$$\text{bra grej: } h \xrightarrow{n \rightarrow \infty} 0 \quad \circ \quad R_T \xrightarrow{h \rightarrow 0} 0$$

## Simpsons formel

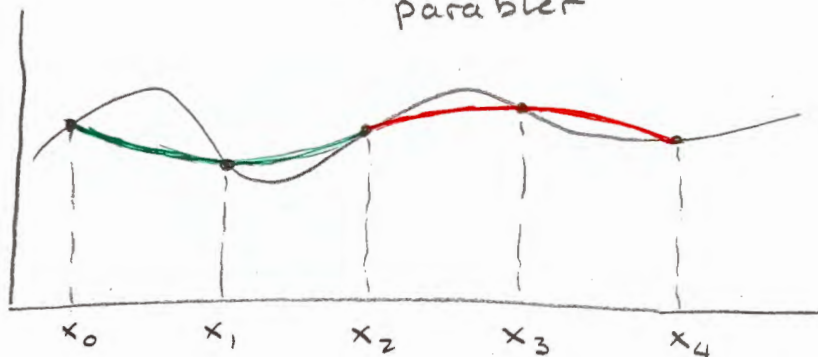
Delar upp  $[a, b]$  i ett jämnt antal  $n$  delintervall med längd  $h = (b-a)/n$ .

$$S(h) = \frac{h}{3} \left( \sum_{i=0}^{\frac{n}{2}-1} f(x_{2i}) + 4f(x_{2i+1}) + f(x_{2i+2}) \right) = \\ = \frac{h}{3} \left( f(x_0) + f(x_n) + 4 \sum_{i=1}^{n/2} f(x_{2i-1}) + 2 \sum_{i=1}^{\frac{n}{2}-1} f(x_{2i}) \right)$$

$$\int_a^b f(x) dx = S(h) + R_T$$

$$R_T = \frac{b-a}{180} h^4 f^{(4)}(\xi) \text{ för något } \xi \in [a, b]$$

$n=4 \Rightarrow$  approximera med två parabler



## Richardsonextrapolation

Smart val av viktning för varannanpunkt ökar exponenten för ordningen av felet  $\Rightarrow$  bättre precision

$$S^{(2)}(h) = S(h) + \frac{S(h) - S(2h)}{15}$$

Ger  $R_T = O(h^6)$  istället för  $O(h^4)$

Fungerar bra för reguljära funktioner.



Lana 200508

Numerisk beräkning av derivator och

lösning av ODE:er

Approximation av derivator

Vill beräkna derivata från funktionsvärden.

Tre enkla differenskvoter:

medel-värde

$$\left\{ \begin{array}{l} \circ \text{Framåt differens } f'(x) \approx \frac{f(x+h) - f(x)}{h} \\ \circ \text{Bakåt differens } f'(x) \approx \frac{f(x) - f(x-h)}{h} \\ \circ \text{Central differens } f'(x) \approx \frac{f(x+h) - f(x-h)}{2h} \end{array} \right.$$

Om steglängden  $h \rightarrow 0$  går approximationerna mot  $f'(x)$ . Trunkeringsfelet  $R_T$  kan analyseras:

Ex: Central differens

$$\begin{aligned} R_T &= \frac{f(x+h) - f(x-h)}{2h} - f'(x) \approx \\ &\approx \frac{1}{2h} \left( \sum_{i=0}^4 \frac{1}{i!} f^{(i)}(x) h^i - \sum_{i=0}^4 \frac{(-1)^i}{i!} f^{(i)}(x) h^i \right) - f'(x) \\ &\approx \{ \text{Termer med jämn } i \text{ stryks} \} \approx \\ &\approx \frac{1}{2h} \left( 2 \cancel{f'(x)h} + 2 \frac{1}{3!} f'''(x) h^3 \right) - \cancel{f'(x)} \end{aligned}$$

$$R_T = \frac{1}{3!} f'''(x) h^2 + O(h^4)$$

För central differens:  $R_T = O(h^2)$

För framåt- / bakåt differens:  $R_T = O(h)$



Kan man välja  $h$  litet för att få litet fel?

Nej!  $f(x+h) \neq f(x)$

$\Rightarrow$  Cancellationsfel vid cancellation

Om  $\delta$  är relativa felet i funktionsberäkningarna

d.v.s.  $\frac{|\delta f|}{|f|} \leq \delta$  så blir felet vid framötdiff:

$$|R_f| \leq \frac{|f(x+h) + f(x)|}{|h|} \delta \quad (\text{av triangelolikhet})$$

Motsvarande formler för bakötdiff./centraldiff.

### Problem

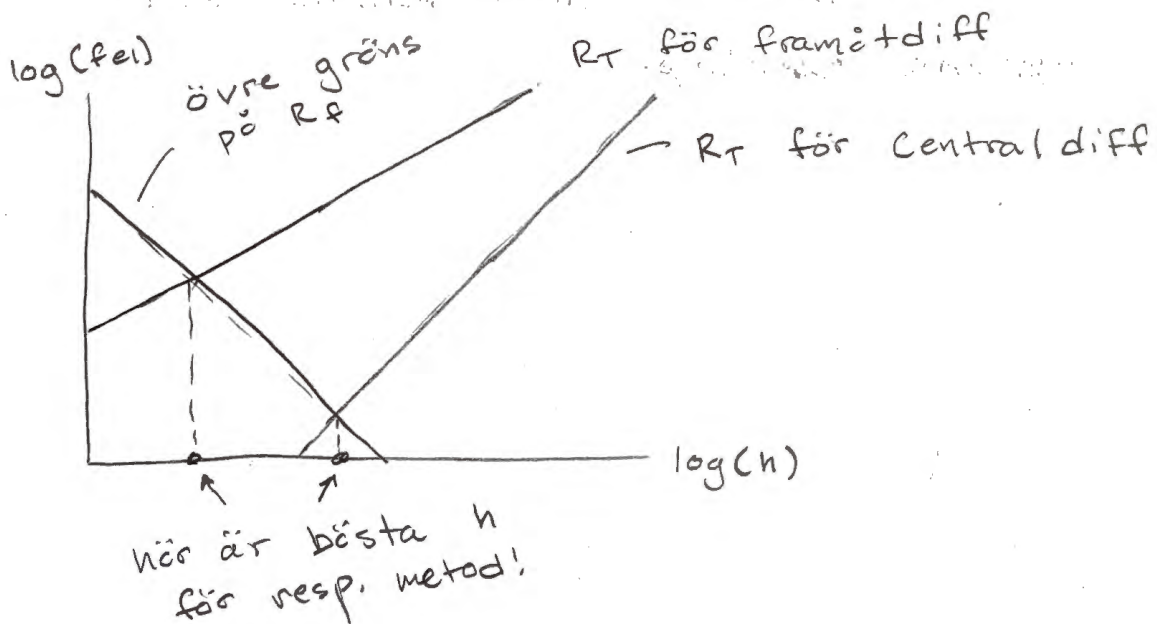
o  $h$  litet  $\Rightarrow |R_f|$  stort

o  $h$  stort  $\Rightarrow |R_T|$  stort

### Exempel

$f(x) = \frac{1}{1+x}$ . Beräkna  $f'(1)$  numeriskt

Sök  $h$  som minimerar  $|R_f| + |R_T|$



Man kan använda Richardson extrapolation för att reducera  $|R_T|$  utan att använda för kort steglängd  $h$ . ( $R_T$ -linje brantare).

Ex. Central differens med steglängd  $h$

$$F(h) \text{ har } R_T = a_1 h^2 + a_2 h^4 + \mathcal{O}(h^6)$$

$$F(2h) \text{ har } R_T = 2^2 a_1 h^2 + 2^4 a_2 h^4 + \mathcal{O}(h^6)$$

$$\frac{F(h) - F(2h)}{3} =$$

$$= \frac{\cancel{f'(x)} + a_1 h^2 + a_2 h^4 - \cancel{f'(x)} - 4a_1 h^2 - 16a_2 h^4}{3} + \mathcal{O}(h^6)$$

$$= -a_1 h^2 - \frac{15}{3} a_2 h^4 + \mathcal{O}(h^6)$$

$$\Rightarrow F(h) + \frac{F(h) - F(2h)}{3} = f'(x) + \underbrace{\mathcal{O}(h^4)}_{R_T}$$

Vi har minskat  $R_T$  (men behöver fler funktionsberäkningar)

## Begynnelsevärdesproblem för ODE:er

Studera ett: begynnelsevärdesproblem

för en: första ordnings differentialekvation:

$$(BVP) \begin{cases} y'(t) = f(t, y(t)), & a \leq t \leq b \\ y(a) = c & \text{(begynnelsevillkor)} \end{cases}$$

$f$  är en given funktion,  $c$  konstant

Vi tillåter  $y(t) \in \mathbb{R}^n$ ,  $c \in \mathbb{R}^n$ ,  $t \in \mathbb{R}$

d.v.s. system av differentialekvationer.

Generellt kan  $f$  vara icke-linjär. Om

$f$  är linjär m.a.p.  $y$  kan (BVP) skrivas.

$$\begin{cases} y'(t) = Ay(t) + b(t) & A \in \mathbb{R}^{n \times n}, y, y', b \in \mathbb{R}^n \\ y(a) = c \end{cases}$$

### Stabilitet

Om närliggande lösningar närmar sig varandra  
då  $t$  växer så är systemet stabilt.

Små fel i indata och beräkningsfel avtar  
med  $t$  om systemet är stabilt.

Om systemet är instabilt kan vi inte

lita på lösningen eftersom felet ökar  
med  $t$ .

## Högre ordnings ekvationsystem

Högre ordnings ekvationer kan skrivas om som första ordnings system.

### Exempel

$$(*) \begin{cases} y''' - yy'' - 2y' - 3y = 0, & 0 \leq t \leq 1 \\ y(0) = a, y'(0) = b, y''(0) = c \end{cases}$$

Inför  $y_1 = y, y_2 = y', y_3 = y''$

Nu är (\*) ekvivalent med

$$\begin{cases} y_1' = y_2 \\ y_2' = y_3 \\ y_3' = y_1 y_3 + 2y_2 + 3y_1 \\ y_1(0) = a, y_2(0) = b, y_3(0) = c \end{cases}$$

Första ordningens system!

## Differensmetoder för ODE:er

Vill beräkna approximativ lösning till (BVP)

Vi stegar oss fram från en tidpunkt till nästa.

$$a = t_0 < t_1 < t_2 < \dots < t_N = b$$

Beräkna succesivt approximationer  $y_k \approx y(t_k)$

Generellt OK om steglängd  $t_{k+1} - t_k$  beror av  $k$ .

Vi använder dock konstant steglängd  $h$ .

$$\Rightarrow t_{k+1} = t_k + h = t_0 + h(k+1)$$

Approximation med framötdiff. ger:


$$\frac{y(t_k + h) - y(t_k)}{h} \approx y'(t_k) = f(t, y_k(t))$$

$$\Rightarrow \boxed{y_{k+1} = y_k + h f(t_k, y_k)}$$

Eulers  
Framötmotod

## Geometrisk tolkning

$$\text{Följ fältet } F(t, y) = \begin{bmatrix} h \\ hf(t, y) \end{bmatrix}$$



$F$  kallas riktningssält  
(skalat med  $h$ )

$$\begin{bmatrix} t_{k+1} \\ y_{k+1} \end{bmatrix} = \begin{bmatrix} t_k \\ y_k \end{bmatrix} + F(t_k, y_k)$$

Anm:  $y_{k+1}$  explicit i VL (smidigt)

Approximation med bakåt differens:

$$\frac{y(t_k) - y(t_k - h)}{h} \approx f(t_k, y(t_k))$$

Skifta  
 $k$ -index

$$\Rightarrow \boxed{y_{k+1} = y_k + h f(t_k, y_{k+1})}$$

Eulers bakåtmetod

Anm.  $y_{k+1}$  ej explicit, behöver lösa ekvation.  
för varje iteration: kallas implicit metod.

Approximation med central differens:

$$\frac{y(t_k + h) - y(t_k - h)}{2h} \approx f(t_k, y(t_k))$$

$$\Rightarrow \boxed{y_{k+1} = y_{k-1} + 2h f(t_k, y_k)}$$

Mittpunktsmetoden

Explicit metod (

Behöver två begynnelsevärden.



Integrera  $y'(t) = f(t, y(t))$  från  $t_k$  till  $t_{k+1}$

$$\Rightarrow y(t_{k+1}) = y(t_k) + \int_{t_k}^{t_{k+1}} f(t, y(t)) dt$$

Ger flera metoder, t.ex. via trapetsregeln:

$$\approx y(t_k) + \frac{h}{2} (f(t_k, y(t_k)) + f(t_{k+1}, y(t_{k+1})))$$

$$\Rightarrow \boxed{y_{k+1} = y_k + \frac{h}{2} (f(t_k, y_k) + f(t_{k+1}, y_{k+1}))}$$

Trapetsmetoden

Implicit metod,  $y_{k+1}$  i HL & VL

Vad krövs för olika metoder?

Euler framåt, Euler bakåt & trapetsmetoden behöver bara  $y_k$  för att beräkna  $y_{k+1}$ .

Kallas enstegsmetoder

Mittpunktsmetoden kräver  $y_{k-1}$  och  $y_k$

Avancerade approximationer av derivator

ger också metoder som kräver flera värden.

Kallas flerstegsmetoder

Explicita metoder  $\Rightarrow$  Enkla beräkningar

Implicita metoder kräver ekv. lösn. för

varje iteration men kan ha större

steglängd. Om det är bättre beror

på problemet. Särskilt bra för

Styva problem.

Lana 200511

Lösningsnoggrannhet och stabilitet  
för differensmetoder

Repetition

Studera BVP:

$$\begin{cases} y'(t) = f(t, y(t)), & a \leq t \leq b \\ y(a) = c & \text{begynnelsevillkor} \end{cases}$$

$y_k$  approximerar exakt lösning  $y(t_k)$  i  $t = t_k$

$$t_{k+1} = t_k + h \Leftrightarrow t_k = t_0 + kh, \quad t_0 = a$$

Euler framåt

$$y_{k+1} = y_k + h f(t_k, y_k)$$

Euler bakåt

$$y_{k+1} = y_k + h f(t_{k+1}, y_{k+1})$$

Mittpunktsmetoden

$$y_{k+1} = y_{k-1} + 2h f(t_k, y_k)$$

Trapetsmetoden

$$y_{k+1} = y_k + \frac{1}{2} h (f(t_k, y_k) + f(t_{k+1}, y_{k+1}))$$

## Problem stabilitet


Def Problemet (BVP) är STABILT om ...  
när liggande lösningskurvor inte divergerar.

Det är ASYMPTOTISKT STABILT om  
lösningskurvorna asymptotiskt konvergerar.


Om  $z(t)$  lösning till (BVP) med andra  
begynnelsevärden sådana att  $|c - z(t_0)|$  är  
litet, så är (BVP) stabilt om

$$|y(t_{k+1}) - z(t_{k+1})| \leq |y(t_k) - z(t_k)|$$


Asymptotiskt stabilt om  $|y(t) - z(t)| \xrightarrow{t \rightarrow \infty} 0$



stabil  
(asymptotisk)



Instabil



Stabil  
(ej asymptotisk)

Exempel  $y' = \lambda y$ ,  $y(t) \in \mathbb{C}$   $y(0) = C_1$

Har exakt lösning  $y(t) = C_1 e^{\lambda t}$

Annars lösning:  $z(t) = C_2 e^{\lambda t}$   $z(0) = C_2$

$$|y(t_{k+1}) - z(t_{k+1})| = |C_1 - C_2| |e^{\lambda t_{k+1}}| =$$

$$= |C_1 - C_2| |e^{\lambda t_k}| |e^{\lambda h}| = |y(t_k) - z(t_k)| |e^{\lambda h}|$$

$$|e^{\lambda h}| = e^{\operatorname{Re}(\lambda)h} \quad (\text{komplexdelen ger bara rotation})$$

Så problemet är stabilt om  $e^{\operatorname{Re}(\lambda)h} \leq 1$

vilket är ekvivalent med  $\operatorname{Re}(\lambda)h \leq 0$

## Lösningssnoggrannhet

Def: Löt.  $u_k(t)$  vara lösningsskurvan som går genom  $(t_k, y_k)$  d.v.s. exakt lösning till BVP med  $a=t_k, c=y_k$ .

Det LOKALA TRUNKERINGSFELET i  $t_k$  är


$$L_k = y_k - u_{k-1}(t_k)$$

d.v.s. skillnaden mellan att använda differensmetoden eller exakt lösning från föregående steg  $(t_{k-1})$ .

Det GLOBALA TRUNKERINGSFELET i  $t_k$  är

$$G_k = y_k - u_0(t_k) = y_k - y(t_k)$$

d.v.s. skillnaden mellan approximationen och exakt lösning från startpunkten.



Def En metod som har lokalt trunkeringsfel  $L_k = O(h^{p+1})$  har APPROXIMATIONSORDNING  $p$ .



Om approximationsordningen är  $p$  och problemet stabilt så är  $G_k = \mathcal{O}(h^p)$ .

$$|G_1| = |y_1 - u_0(t_1)| = |L_1|$$

$$\begin{aligned} |G_k| &= |y_k - u_0(t_k)| \stackrel{\text{Stabilitet}}{\leq} \\ &\leq |y_k - u_{k+1}(t_k)| + |u_{k+1}(t_k) - u_0(t_k)| \leq \\ &\leq |L_k| + |u_{k-1}(t_{k-1}) - u_0(t_{k-1})| = \\ &= |L_k| + |G_{k-1}| \end{aligned}$$

Antal delintervall  $N \propto h^{-1}$ . Summera

$$N \text{ delintervall ger } G_N = h^{-1} \mathcal{O}(h^{p+1}) = \mathcal{O}(h^p).$$

### Approximationsordning för differensmetoder

$$\text{Studera } y'(t) = \lambda y(t) \quad y(t_0) = c$$

### Approximationsordning för Euler framåt

$$y' = \lambda y \text{ ger metod}$$

$$\begin{aligned} y_{k+1} &= y_k + \lambda h y_k = (1 + h\lambda) y_k \\ \Rightarrow y_k &= (1 + h\lambda)^k y_0 = (1 + h\lambda)^k c \end{aligned}$$

Faktorn  $(1 + h\lambda)$  kallas tillväxtfaktor.

Den exakta lösningen är  $u_k(t) = y_k e^{\lambda(t-t_k)}$

### Lokala trunkeringsfelet:

$$\begin{aligned} L_{k+1} &= y_{k+1} - u_k(t_{k+1}) = (1 + h\lambda) y_k - y_k e^{\lambda h} = \\ &= (1 + h\lambda - e^{\lambda h}) y_k = \{ \text{Taylorutveckla } e^{\lambda h} \} \\ &= \left( \frac{(h\lambda)^2}{2} + \mathcal{O}(h^3) \right) y_k = \mathcal{O}(h^2) \end{aligned}$$

Alltså är lokalt trunkeringsfel  $\mathcal{O}(h^2)$

$\Rightarrow$  approximationsordning 1.

"Halvera  $h \Rightarrow$  Halvera globalt fel"



### Approx. ordn. för Euler bakåt

$$y' = \lambda y \Rightarrow y_{k+1} = y_k + h\lambda y_{k+1}$$

$$\Rightarrow y_{k+1} = \frac{1}{1-h\lambda} y_k$$

Tillväxtfaktor:  $\frac{1}{1-h\lambda}$  som förut Taylorutveckla båda

$$\begin{aligned} L_{k+1} &= \left( \frac{1}{1-h\lambda} - e^{h\lambda} \right) y_k = \\ &= \left( \cancel{1+h\lambda} + (h\lambda)^2 - \cancel{1+h\lambda} - \frac{1}{2}(h\lambda)^2 + \mathcal{O}(h^3) \right) y_k = \\ &= \mathcal{O}(h^2) \end{aligned}$$

Lokalt trunkeringsfel  $\mathcal{O}(h^2)$ ,

approximationsordning 1.

### Approx. ordn. för Trapetsmetoden

$$y' = \lambda y \Rightarrow y_{k+1} = y_k + \frac{h}{2} (\lambda y_k + \lambda y_{k+1})$$

$$\Rightarrow \left( 1 - \frac{h\lambda}{2} \right) y_{k+1} = \left( 1 + \frac{h\lambda}{2} \right) y_k \Rightarrow y_{k+1} = \frac{1 + \frac{h\lambda}{2}}{1 - \frac{h\lambda}{2}} y_k$$

Tillväxtfaktor:  $\frac{2+h\lambda}{2-h\lambda} = 1 +$

$$L_{k+1} = \left( \frac{2+h\lambda}{2-h\lambda} - e^{h\lambda} \right) y_k = \left( \frac{11}{12}(h\lambda)^3 + \mathcal{O}(h^4) \right) y_k$$

Lokalt trunkeringsfel  $\mathcal{O}(h^3)$

approximationsordning 2.

Behöver inte lika korta steg!

## Stabilitet av differensmetoder

Testa med exemplet  $y' = \lambda y$ ,  $y(t_0) = c$

Problemet bara stabilt om  $\operatorname{Re}(\lambda) \leq 0$

Krävs för att fel i indata inte ska växa exponentiellt. Vill alltid ha detta.

Def: En metod är STABIL för steglängd  $h$  om den ger en icke-växande approximation för  $y' = \lambda y$  med  $\operatorname{Re}(\lambda) \leq 0$ , d.v.s.  $|\text{tillväxtfaktor}| \leq 1$ .


Eulers framåtmetod på  $y' = \lambda y$  har tillväxtfaktor  $1 + h\lambda$  så vi får stabilitet av metoden om  $|1 + h\lambda| \leq 1$ .

Om  $\lambda$  reellt:  $-1 \leq 1 + h\lambda \leq 1 \Leftrightarrow h \leq -\frac{2}{\lambda}$   
↑  
upperbar

→ Om  $\lambda$  är stort (negativt) måste  $h$  vara liten.

För komplexa  $\lambda$ :

Låt  $z = h\lambda$ . Vi får stabilitetsområdet  $|1 + z| \leq 1$



Om  $h$  väljs för stort kan vi hamna utanför stabilitetsområdet och få en instabil metod.

Detta är ett litet område jämfört med för de andra metoderna.

Lana 200512

Stabilitet av differensmetoden (forts.)

Repetition

Studera (BVP)  $y'(t) = f(t, y(t))$   $a \leq t \leq b$ .

$y_k$  approximation vid  $t_k = t_0 + kh$ ;  $t_0 = a$

Lokalt trunkeringsfel:  $L_k = O(h^{p+1})$  ger approximationsordning  $p$ .

Stabilitet av metoder studeras mha  $y' = \lambda y$   
 $y(t_0) = c$ . Euler framåt har approx. ordn. 1  
och stabilitetsområdet  $\{z = h\lambda \in \mathbb{C} \mid |z+1| \leq 1\}$


Bösta stabilitetsområdet är hela  
vänstra halvplanet  $\operatorname{Re}(z) \leq 0 \Leftrightarrow \operatorname{Re}(h\lambda) \leq 0$   
 $\Leftrightarrow \operatorname{Re}(\lambda) \leq 0$ . Vi har i sådana fall  
metodstabilitet för alla stabila problem.

Def En metod med stabilitetsområde  
som innehåller hela vänstra halvplanet  
kallas A-STABIL.

Euler framåt ej A stabil

$\Rightarrow$  Krävs korta steg för stabilitet.

Eulers bakåtmetod på  $y' = \lambda y$ ,  $y(t_0) = c$   
 har tillväxtfaktor  $\frac{1}{1-h\lambda}$  så värt  
 stabilitetsområde ges av



$$\left| \frac{1}{1-z} \right| \leq 1 \Leftrightarrow 1 \leq |1-z|$$

Innehåller hela vänstra  
 halvplanet!

$\Rightarrow$  Euler bakåt är A-stabil.

Tropetsmetoden på  $y' = \lambda y$  har  
 tillväxtfaktor  $\frac{z+h\lambda}{z-h\lambda}$  så stabilitetsområdet  
 ges av

$$\left| \frac{z+z}{z-z} \right| \leq 1$$

Ansätt  $a+bi = z$  och kvadrera!

$$\Rightarrow 1 \geq \frac{|z+a+bi|^2}{|z-a-bi|^2} = \frac{(z+a)^2 + b^2}{(z-a)^2 + b^2}$$

$$\Leftrightarrow (z-a)^2 + b^2 \geq (z+a)^2 + b^2$$

$$\Leftrightarrow -4a \geq 0 \Leftrightarrow a < 0 \Leftrightarrow \operatorname{Re}(z) \leq 0$$

Så stabilitetsområdet är hela vänstra  
 halvplanet

$\Rightarrow$  Tropetsmetoden är A stabil.



## Sammanfattning

Metod	Approx. Ordn.	Stabilitets-område	A stabil
Euler framåt	1	$ 1+z  \leq 1$	Nej
Euler bakåt	1	$ 1-z  \geq 1$	Ja
Trapetsmetoden	2	$\text{Re}(z) \leq 0$	Ja

Euler framåt är explicit  $\Rightarrow$  enkla beräkningar

Ej A stabil  $\Rightarrow$  kort steglängd för stabilitet.

Låg approx. ordn  $\Rightarrow$  kort steglängd för noggrannhet.

Euler bakåt och trapetsmetoden är

implicita  $\Rightarrow$  ekvationslösning för varje iteration. (Långsammare)

A-stabila  $\Rightarrow$  Lång steglängd OK för stabilitet.

Trapetsmetoden har bättre approximationsordning men kräver två funktionsberäkningar av  $f$ .



## Systemlösning med differensmetoder

Problemet  $y' = \lambda y$  stabilt om  $\operatorname{Re}(\lambda) \leq 0$ .

Linjära system enklare jämfört med icke-linjära.

Problemet  $y' = Ay$ ,  $y(0) = c$ ,  $A$   $n \times n$  diag. matris  $y(t) \in \mathbb{R}^n$ ,  $c \in \mathbb{R}^n$  har lösning

$$y(t) = \sum_{i=1}^n d_i e^{\lambda_i t} u_i$$

där  $u_i$  egenvektorer med egenvärde  $\lambda_i$ .  
 $d_i$  bestäms av begynnelsevärdena.

Asymptotiskt stabilt d.v.s.  $y(t) \xrightarrow{t \rightarrow \infty} 0$  om  $\operatorname{Re}(\lambda_i) < 0 \quad \forall i$

$\operatorname{Re}(\lambda_i) = 0$  ger oscillerande lösningar.

Gäller även om  $A$  inte är diagonaliserbar, men fallet  $\operatorname{Re}(\lambda_i) = 0$  mer konstigt

(vi kommer inte visa det i denna kurs)

För icke-linjära system kan vi få en uppfattning om stabiliteten genom linjärisering (d.v.s. Taylorutv. av  $f$ )

$$y' = f(y) \approx Jy + b$$

där  $J$  är jacobian för  $f$  med avseende på  $y$ .

Egenvärdena av  $J$  analyseras som ovan,

d.v.s. om egenvärdena  $\lambda_i$  till  $J$  uppfyller

$\operatorname{Re}(\lambda_i) < 0$  har vi stabilitet.

OBS: Ger "lokal" stabilitet, välj punkter väl.

Tillbaka till linjära fallet.

Olika storleksordning på  $\lambda_i$  kallas styva problem. Gör överlagring av snabba och långsamma förlopp.

Euler framåt kräver  $|1 - h\lambda_i| \leq 1 \quad \forall \lambda_i$

Om t.ex.  $|\lambda_1|$  stort och  $|\lambda_2|$  litet krävs kort steglängd p.g.a.  $\lambda_1$ , kan ge instabilitet men lång tid för att se effekterna av  $\lambda_2$ . (långsamma förlopp)

Exempel  $y'(t) = Ay(t) \quad y(0) = \begin{pmatrix} 1 \\ 0 \end{pmatrix}$

där  $A = \begin{pmatrix} 0 & 1 \\ -100 & -101 \end{pmatrix}$

$$\det(A - \lambda I) = \dots = (100 + \lambda)(1 + \lambda) = 0$$

$\Rightarrow$  Egenvärden  $\lambda_1 = -100$ ,  $\lambda_2 = -1$  (styvt!)

Euler framåt kräver

$$|1 + h\lambda_i| \leq 1 \quad \forall i \Rightarrow -1 \leq 1 - 100h \Rightarrow \underline{\underline{h \leq 2 \cdot 10^{-2}}}$$

för stabilitet.

Euler bakåt alltid stabil om problemet är stabilt, d.v.s.  $\operatorname{Re}(\lambda_i) < 0$

$$y_{k+1} = y_k + hAy_{k+1} \Rightarrow \underline{\underline{(I - hA)y_{k+1} = y_k}}$$

lös för varje iteration med  $\backslash$  i matlab.

## Prediktor - Korrektor metoder

Finns inga A stabila explicita metoder.

=> Behöver använda implicita metoder.

Om  $f$  icke-linjär kan Newton's metod eller annan iterationsmetod användas, men en bra startgissning behövs.

Använd en explicit metod för startgissningen (Predikator) som sedan används i implicita metoden (Korrektor).

Vi får samma stabilitet och noggrannhet som korrektorn.

### Exempel:

Predikator = Euler framåt

Korrektor = Trapets med Newtons metod för ekvationslösning, med startgissning från prediktorn.

## Runge - Kuttametoder

Explicita enstegsmetoder smidiga, men

Euler framåt har dålig approxordn. 1.

Finns bättre?

Def: En metod på formen

$$y_{k+1} = y_k + h \sum_{i=1}^s b_i k_i$$

med  $k_i = f(t_k + c_i h, y_k + h \sum_{j=1}^s a_{ij} k_j)$

som definieras av ett antal NIVÅER  $s \in \mathbb{N}$ ,

en  $s \times s$  matris  $A = (a_{ij})$  och två vektorer

$b \in \mathbb{R}^s$  och  $c \in \mathbb{R}^s$  kallas en

RUNGE - KUTTAMETOD.

Exempel  $s=1$ ,  $a_{11}=0$ ,  $b_1=1$ ,  $c_1=0$  ger

$$y_{k+1} = y_k + h k_1 \text{ med } k_1 = f(t_k, y_k)$$

Alltså är Eulers metod en RK-metod.

Exempel [Heuns metod]

$s=2$ ,  $A = \begin{pmatrix} 0 & 0 \\ 1 & 0 \end{pmatrix}$ ,  $b = \begin{pmatrix} 1/2 \\ 1/2 \end{pmatrix}$ ,  $c = \begin{pmatrix} 0 \\ 1 \end{pmatrix}$  ger

$$y_{k+1} = y_k + \frac{h}{2} (k_1 + k_2) \text{ med}$$

$$k_1 = f(t_k, y_k)$$

$$k_2 = f(t_k + h, y_k + h k_1)$$

Test med  $y' = \lambda y$  ger  $k_1 = \lambda y_k$ ,  $k_2 = \lambda y_k + h \lambda^2 y_k$

$$\Rightarrow y_{k+1} = \dots = \left(1 + h\lambda + \frac{1}{2}(h\lambda)^2\right) y_k$$

$$L_k = \left(1 + h\lambda + \frac{1}{2}(h\lambda)^2 - e^{h\lambda}\right) y_k = \mathcal{O}(h^3)$$

$\Rightarrow$  approx. ordn. 2. Bättre!



## Exempel [Klassisk Runge-Kutta]

$$s = 4, \quad A = \begin{pmatrix} 0 & 0 & 0 & 0 \\ 1/2 & 0 & 0 & 0 \\ 0 & 1/2 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{pmatrix}, \quad b = \frac{1}{6} \begin{pmatrix} 1 \\ 2 \\ 2 \\ 1 \end{pmatrix}, \quad c = \begin{pmatrix} 0 \\ 1/2 \\ 1/2 \\ 1 \end{pmatrix}$$

ger  $y_{k+1} = \frac{h}{6} (k_1 + 2k_2 + 2k_3 + k_4)$  med

$$k_1 = f(t_k, y_k)$$

$$k_2 = f\left(t_k + \frac{h}{2}, y_k + \frac{h}{2} k_1\right)$$

$$k_3 = f\left(t_k + \frac{h}{2}, y_k + \frac{h}{2} k_2\right)$$

$$k_4 = f(t_k + h, y_k + h k_3)$$

bara funktions-  
beräkningar!

Inga ekvationer  
behöver lösas  
(eftersom A  
valts smart)

Har approximationsordning 4, kräver 4  
beräkningar av  $f$ . Euler framåt kräver bara 1.

Matlabfunktionen `ode45` använder den här  
Runge-Kutta metoden och en med 5 nivåer  
för feluppskattning.

Har tillväxtfaktor  $1 + z + \frac{z^2}{2!} + \frac{z^3}{3!} + \frac{z^4}{4!}$

$\Rightarrow$  stabilitetsområde  $\left| 1 + z + \frac{z^2}{2!} + \frac{z^3}{3!} + \frac{z^4}{4!} \right| \leq 1$

För styva problem fungerar `ode15s` bättre.



Lana 200514

## Numerisk linjär algebra

Tre huvudproblem:

- Linjära ekvationssystem
- Linjära minstakvadratproblem
- Egenvärdesproblem

### Linjära ekvationssystem

Vill lösa  $Ax = b$

Två numeriska aspekter:

- Antal operationer (flyttalsaddition & multiplikation)
- Numerisk stabilitet

Om man vill lösa  $Ax = b$  med många olika  
högerled används LU-faktorisering för  
att minska antal operationer.

### LU-faktorisering

$A = LU$  där  $A$   $m \times n$ -matris,  $L$  nedö-  
triangulär  $m \times m$ -matris med ettor på diagonalen  
(Lower) och  $U$   $m \times n$ -matris med  
trappstegsform (som vi får av Gausselimination)  
(Upper)

### Exempel

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

$L$                        $U$   
 $4 \times 4$                        $4 \times 5$

Om  $A = LU$  kan vi lösa  $Ax = b$  effektivt

$$\left[ \begin{array}{l} \text{Låt } y = Ux \text{ så } b = Ax = LUx \end{array} \right.$$

1) Lös  $Ly = b$  med framåtsubstitution

2) Lös  $Ux = y$  med bakåtsubstitution

I steg 2 är det möjligt att få parameterlösning

För varje nytt högerled ca  $2n^2$  operationer om  $A$   $n \times n$ -matris. ( $n^2$  från fram/bak-subs.)

Gausselimination kräver ca  $\frac{2}{3}n^3$  operationer

LU faktorisering billigare om man har många högerled  $b$  ty man behöver bara göra

LU faktorisering (Gausselimination) en gång.

### Beräkning av LU-faktorisering

Som vanlig Gausselimination men sparar information om vad man gjort. Skillnad:

- Inga omskalningar av rader. (behövs ej)  
pivotelement i  $U$  behöver inte vara 1.
- Antag att radbyten inte behövs  
(öterkommer till detta)

Radreducera  $A$  till trappstegsmatris  $U$ .

Kan skrivas  $E_p \dots E_1 A = U$  där  $E_k$

motsvarar radoperation, d.v.s. samma op. på  $I$ .

Alla  $E_k$  nedåt triangulära med 1:or på diagonalen ty använder multiplar av

rader ovanför. Ger  $E_p \dots E_1$  nedåt triangulär med 1:or på diagonalen.

Radoperationer inverterbara

$\Rightarrow E_k$  inverterbara

$\Rightarrow E_p \dots E_1$  inverterbar

$$A = \underbrace{(E_p \dots E_1)^{-1}}_L \underbrace{(E_p \dots E_1) A}_U = LU$$

Bilda  $L$  stegvis så att  $E_p \dots E_1 L = I$

Exempel LU-faktorisera  $A$

$$\underbrace{\begin{pmatrix} 2 & 4 & -1 \\ -4 & -5 & 3 \\ 2 & 10 & 4 \end{pmatrix}}_A \xrightarrow{E_1} \underbrace{\begin{pmatrix} 2 & 4 & -1 \\ 0 & 3 & 1 \\ 0 & 6 & 5 \end{pmatrix}}_{E_1 A} \xrightarrow{E_2} \underbrace{\begin{pmatrix} 2 & 4 & -1 \\ 0 & 3 & 1 \\ 0 & 0 & 3 \end{pmatrix}}_{E_2 E_1 A = U}$$

$$E_1 = \begin{pmatrix} 1 & 0 & 0 \\ 2 & 1 & 0 \\ -1 & 0 & 1 \end{pmatrix}, \quad E_2 = \begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & -2 & 1 \end{pmatrix}$$

Om  $L = \begin{pmatrix} 1 & & \\ v_1 & v_2 & \\ & & 1 \end{pmatrix}$  vill vi ha  $E_2 E_1 L = I$

Men  $E_2$  påverkar inte första kolonnen.

$$\Rightarrow E_1 v_1 = \begin{pmatrix} 1 \\ 0 \\ 0 \end{pmatrix} \Rightarrow v_1 = \begin{pmatrix} 1 \\ -2 \\ 1 \end{pmatrix}$$

det vill säga byt tecken på radoperationerna.

$$\text{P.S.S. } E_2 v_2 = \begin{pmatrix} 0 \\ 1 \\ 0 \end{pmatrix} \Rightarrow v_2 = \begin{pmatrix} 0 \\ 1 \\ 2 \end{pmatrix}, \quad v_3 = \begin{pmatrix} 0 \\ 0 \\ 1 \end{pmatrix}$$

$$\text{Alltså } A = LU \text{ med } L = \begin{pmatrix} 1 & 0 & 0 \\ -2 & 1 & 0 \\ 1 & 2 & 1 \end{pmatrix}, \quad U = \begin{pmatrix} 2 & 4 & -1 \\ 0 & 3 & 1 \\ 0 & 0 & 3 \end{pmatrix}$$

Kolumnerna i  $L$  ges av omvänt tecken på radoperationerna.

## Pivoting

Radbyten kan behövas, kallas här pivoting.

För numerisk stabilitet byter vi rader så att det till beloppet största värdet blir pivotelement innan vi gör radoperationer.

Gör att alla element i  $L$  blir  $|l| \leq 1$

Radbytena håller man reda på m.h.a. en permutationsmatris  $P$ , som beskriver alla radbyten i alla eliminationssteg.

Man får då:  $PA = LU$

I MATLAB:  $[L,U,P] = \text{lufact}(A)$

Så lösning av  $Ax = b$  med många högerled:

1) Faktorisera  $PA = LU$

$\approx \frac{2}{3}n^3$  operationer om  $A$   $n \times n$

2) Framötsubstitution  $Ly = Pb$

$\approx n^2$  operationer

3) Bakötsubstitution  $Ux = y$

$\approx n^2$  operationer

Steg 2) & 3) utförs för varje högerled.

Fungerar för att:

$$Ax = b \Leftrightarrow PAx = Pb \Leftrightarrow LUx = Pb$$

$$\Leftrightarrow \begin{cases} Ly = Pb \\ Ux = y \end{cases}$$



## Varför pivotering?

### Exempel utan pivotering

$$\left[ \begin{array}{cc|cc} 10^{-20} & 1 & 1 & 1 \\ 1 & 2 & 4 & 4 \end{array} \right] \xrightarrow{-10^{20}} \left[ \begin{array}{cc|cc} 10^{-20} & 1 & 1 & 1 \\ 0 & 2-10^{20} & 4-10^{20} & 4-10^{20} \end{array} \right]$$

Flyttalsberäkningar ger utskiftning

Tappar info om 2:a raden

$$\left[ \begin{array}{cc|cc} 10^{-20} & 1 & 1 & 1 \\ 0 & -10^{-20} & -10^{20} & -10^{20} \end{array} \right] \Rightarrow x = \begin{pmatrix} 0 \\ 1 \end{pmatrix}$$

Sätt in i ursprunglig ekvation  $\Rightarrow$  stort fel

### Exempel med pivotering

Kasta om raderna

$$\left[ \begin{array}{cc|cc} 1 & 2 & 4 & 4 \\ 10^{-20} & 1 & 1 & 1 \end{array} \right] \xrightarrow{-10^{20}} \left[ \begin{array}{cc|cc} 1 & 2 & 4 & 4 \\ 0 & 1-10^{-20} & 1-4 \cdot 10^{-20} & 1-4 \cdot 10^{-20} \end{array} \right] \approx$$
$$\approx \left[ \begin{array}{cc|cc} 1 & 2 & 4 & 4 \\ 0 & 1 & 1 & 1 \end{array} \right] \Rightarrow x = \begin{pmatrix} 2 \\ 1 \end{pmatrix}$$

Ger exakt lösning till stort problem

$$(A+E)x = b \quad \text{med} \quad E = \begin{pmatrix} 0 & 0 \\ -10^{-20} & 0 \end{pmatrix}$$

$$\text{och} \quad A = \begin{pmatrix} 1 & 2 \\ 10^{-20} & 1 \end{pmatrix}$$

Generellt är elementen i  $E$  lika stora som avrundningselementen. (maskintalet)

Gausselimination (eller LU-faktorisering) med pivotering är en stabil algoritm



## Lösningsnoggrannhet och konditionstal

Osäkerhet i  $A$  och  $b$  från mätningar, avrundning, algoritmen ger approximationer  $\hat{A}$  och  $\hat{b}$ . Vi löser alltså  $\hat{A}\hat{x} = \hat{b}$  istället för  $Ax = b$ . Hur stort blir felet i  $\hat{x}$ ?

$$\text{Låt } \delta A = \hat{A} - A, \quad \delta b = \hat{b} - b, \quad \delta x = \hat{x} - x$$

Felfortplantning  $\delta b \rightarrow \delta x$

Antag  $\delta A = 0$  och  $A^{-1}$  existerar

$$\begin{cases} A(x + \delta x) = b + \delta b & \text{(I)} \\ Ax = b & \text{(II)} \end{cases}$$

(I) - (II) ger  $A\delta x = \delta b$

$$\Rightarrow \delta x = A^{-1}\delta b \Rightarrow \|\delta x\| = \|A^{-1}\delta b\| \leq \|A^{-1}\| \|\delta b\|$$

$$\text{Vi har även } \|b\| = \|Ax\| \leq \|A\| \|x\| \Rightarrow \frac{1}{\|x\|} \leq \frac{\|A\|}{\|b\|}$$

Tillsammans får vi:  $\text{cond}(A) \text{ ; ML}$

$$\frac{\|\delta x\|}{\|x\|} \leq \|A^{-1}\| \|A\| \frac{\|\delta b\|}{\|b\|} = \kappa(A) \frac{\|\delta b\|}{\|b\|}$$

där  $\kappa(A) := \|A\| \|A^{-1}\|$ , kallas konditionstalet

Relativa felet i lösningen  $\leq$  kondtal  $\cdot$  Relativa felet i högerledet

Problemet är vilkonditionerat om

$\kappa(A)$  är "litet" (alltid  $\geq 1$ ). Hur litet beror på situationen.

Problemet är illakonditionerat om

$\kappa(A)$  är "stort"

Felfortplantning -  $\delta A \rightarrow \delta x$

Antag  $\delta b = 0$

$$\begin{cases} (A + \delta A)(x + \delta x) = b & \text{(I)} \\ Ax = b & \text{(II)} \end{cases}$$

$$(I) - (II) \Rightarrow A\delta x + \delta A(x + \delta x) = 0$$

$$\Leftrightarrow \delta x = -A^{-1}\delta A(x + \delta x)$$

$$\Rightarrow \|\delta x\| = \|A^{-1}\delta A(x + \delta x)\| \leq \|A^{-1}\| \|\delta A\| \|x + \delta x\|$$

$$\Rightarrow \frac{\|\delta x\|}{\|x\|} \approx \frac{\|\delta x\|}{\|x + \delta x\|} \leq \|A^{-1}\| \|A\| \frac{\|\delta A\|}{\|A\|}$$

$$\Rightarrow \boxed{\frac{\|\delta x\|}{\|x\|} \leq \kappa(A) \frac{\|\delta A\|}{\|A\|}}$$

Nästan som  $\delta b - \delta x$  fallet.

Lana 200515

## Minstakvadratproblem

Om  $A \in \mathbb{R}^{m \times n}$  med  $m > n$  är  $Ax = b$  i regel ej lösbart. Minimera 2-normen av residualen  $r = Ax - b$ . Kan lösas med normalekvationerna  $ATAx = A^Tb$ , men  $\kappa(ATA) = (\kappa(A))^2$  kan bli mycket stort, så normalekvationerna blir numeriskt instabila. Alternativa metoder:

- QR-faktorisering
- Singulärvärdesfaktorisering (SVD)

## QR-faktorisering

Låt  $A$  vara  $m \times n$ -matris med  $\text{rang } A = n$ ,  $m \geq n$ . Sök faktorisering  $A = QR$  med  $Q$  ortogonal  $m \times m$ -matris ( $Q^T = Q^{-1}$ ) och  $R = \begin{pmatrix} R \\ 0 \end{pmatrix}$   $m \times n$ -matris där  $R$  uppåt triangulär matris. Kallas full QR-faktorisering. I Matlab `qr(A)`.

Dela upp  $Q = (Q_1, Q_2)$  där  $Q_1$  har  $n$  kolonner och  $Q_2$  har  $m - n$  kolonner, ger

$$A = (Q_1, Q_2) \begin{pmatrix} R \\ 0 \end{pmatrix} = \underset{m \times n}{Q_1} \underset{n \times n}{R}$$

$A = Q_1 R$  kallas kompakt QR-faktorisering.  
I Matlab `qr(A, 0)`.

$\text{rang } A = n$  ger  $R$  inverterbar.

Kan lösa MK-problemet, d.v.s. minimera  $\|r\|_2$  där  $r = Ax - b$ .

$$\begin{aligned}\|r\|^2 &= \|Ax - b\|^2 = \|Q\hat{R}x - b\|^2 = \leftarrow Q^T = Q^{-1} \\ &= \|Q(\hat{R}x - Q^T b)\|^2 = \leftarrow \text{ortogonal matris} \\ &\quad \text{bevarar längd} \\ &= \|\hat{R}x - Q^T b\|^2 = \leftarrow \text{2-norm}^2 \\ &\quad = \text{kvadrat av komponenter} \\ &= \underbrace{\|R_1 x - Q_1^T b\|^2}_{= 0 \text{ om } R_1 x = Q_1^T b} + \underbrace{\|Q_2^T b\|^2}_{\text{beror ej på } x, \text{ alltid } \geq 0}\end{aligned}$$

Alltså: Lösning av det uppåt triangulära systemet  $\boxed{R_1 x = Q_1^T b}$  ger minstakvadrat-lösningen.  $R^{-1}$  existerar om rang  $A = n$

Konditionstalet  $\kappa(R) = \kappa(A)$  är betydligt bättre än för normalekvationerna.

Minsta residualens storlek ges av  $\|Q_2^T b\|$

För att beräkna minstakvadrat-lösningen behövs bara  $Q_1$  och  $R$ , d.v.s. kompakt QR-faktorisering

## Hur beräknar man en QR-faktorisering?

Kan ses som basbyte för  $V(A)$  till ON-bas.

### Alternativ 1: Gram-Schmidt

Om  $A = (a_1 \dots a_n)$   $a_i \in \mathbb{R}^m$

Vill få ON-bas  $\{q_1, \dots, q_n\}$  för

$V(A) = \text{span}\{a_1, \dots, a_n\}$ . Använd Gram-Schmidt!

$$u_1 = a_1, \quad q_1 = \frac{u_1}{\|u_1\|}$$

$$u_2 = a_2 - q_1 q_1^T a_2, \quad q_2 = \frac{u_2}{\|u_2\|}$$

$$u_3 = a_3 - q_1 q_1^T a_3 - q_2 q_2^T a_3, \quad q_3 = \frac{u_3}{\|u_3\|}$$

Återskapa:

$$a_1 = \|u_1\| q_1$$

$$a_2 = \|u_2\| q_2 + q_1 q_1^T a_2$$

$$a_3 = \|u_3\| q_3 + q_1 q_1^T a_3 + q_2 q_2^T a_3$$

linjör komb  
av  $q_1, \dots, q_n$

Låt  $r_{jj} = \|u_j\|$  och  $r_{ij} = q_i^T a_j$

Då för vi:

$$A = \underbrace{(q_1 \dots q_n)}_{Q} \underbrace{\begin{pmatrix} r_{11} & r_{12} & \dots & r_{1n} \\ & r_{22} & \dots & r_{2n} \\ & & \ddots & \vdots \\ & & & r_{nn} \end{pmatrix}}_R$$

ger kompakt QR-faktorisering.

I praktiken: gör GS-metod och spara vissa värden



Addera  $m-n$  extra vektorer så att Gram-Schmidt ger ON-bas för hela  $\mathbb{R}^m$ . Vi får då full QR-faktorisering

$$A = (q_1 \dots q_n \dots q_m) \begin{pmatrix} R \\ 0 \end{pmatrix}$$

En bas för  $N(A^T)$  ger  $m-n$  lin. ober. vektorer som är ortogonala mot  $V(A) = \text{span}\{q_1, \dots, q_n\}$  d.v.s. ortogonala mot  $q_1, \dots, q_n$ . Bra val för att generera  $q_{n+1} \dots q_m$  med.

### Householderspeglingar

Tyvärr ger Gram-Schmidt numeriska problem vid QR-faktorisering om kolonnerna i  $A$  är nästan parallella. Modern programvara använder istället Householderspeglingar.

Konstruerar en sekvens av matriser  $H_i$  så att

$$\underbrace{H_n \dots H_1}_{Q^T} A = \begin{pmatrix} R \\ 0 \end{pmatrix}, \quad Q \text{ ortogonal}$$

$H_i$  ger önskad form på kolonn  $i$

Def En matris på formen  $H = I - 2vv^T$

$v \in \mathbb{R}^n$  ( $\Rightarrow H \in \mathbb{R}^{n \times n}$ ), där  $\|v\| = 1$

kallas HOUSEHOLDERMATRIS.

Egenskaper för  $H = I - 2vv^T$  ( $\|v\|=1$ ):

◦  $H$  symmetrisk ty

$$H^T = (I - 2vv^T)^T = I - 2vv^T = H$$

◦  $H$  ortogonal ty

$$\begin{aligned} H^T H &= H^2 = (I - 2vv^T)(I - 2vv^T) = \\ &= I - 4vv^T + 4\underbrace{vv^T vv^T}_{v^T v = I} = I \end{aligned}$$

◦ Motsvarar spegling ty

$$Hv = v - 2vv^T v = v - 2v = -v \quad \leftarrow \text{egenvärde } -1$$

$$\text{Om } y \perp v \quad Hy = y - 2\underbrace{vv^T y}_0 = y \quad \leftarrow \text{egenvärde } 1$$

Så  $H$  ger spegling i planet ortogonalt mot  $v$

Givet två vektorer  $y, z \in \mathbb{R}^n$  vill man välja  $v$  så att  $Hy = z$ .

$$z = Hy = (I - 2vv^T)y = y - 2(v^T y)v = y - \alpha v \quad \begin{array}{l} \text{skalär} \\ \downarrow \\ \alpha \end{array}$$

$$\Rightarrow v = \frac{y-z}{\alpha} \quad \|v\|=1 \text{ ger } \alpha = \|y-z\|$$

$$\text{Alltså } \boxed{v = \frac{y-z}{\|y-z\|} \text{ ger } Hy = z}$$

För QR-faktoriseringen

Om  $A = (a_1 \dots a_n)$ , välj  $H_1$  så att  $H_1 a_1 =$

$$H_1 a_1 = \begin{pmatrix} r_{11} \\ 0 \\ \vdots \\ 0 \end{pmatrix} = r_{11} e_1 \quad (\text{första kolonnen i } \hat{R}) \\ (r_{11} > 0)$$

$$\text{Då blir } H_1 A = \begin{pmatrix} r_{11} & r_{12} & \dots & r_{1n} \\ 0 & \tilde{a}_2 & & \tilde{a}_n \\ \vdots & \vdots & & \vdots \\ 0 & & & \end{pmatrix}$$

ortogonal

$$\|a_1\| = \|H_1 a_1\| = \|r_{11} e_1\| = r_{11}$$



→

d.v.s. välj  $r_{11} = \|a_1\|$  och  $v_1 = \frac{a_1 - r_{11}e_1}{\|a_1 - r_{11}e_1\|}$

$H_1 = I - 2v_1v_1^T$ . fixar första kolonnen i  $\hat{R}$

Låt  $\hat{a}_2 = \begin{pmatrix} 0 \\ \hat{a}_2 \\ \vdots \\ 0 \end{pmatrix}$  d.v.s. (kolonn 2 i  $H_1 A$ ) =  $\begin{pmatrix} r_{12} \\ 0 \\ \vdots \\ 0 \end{pmatrix}$

Välj  $r_{22} = \|\hat{a}_2\|$  och  $v_2 = \frac{\hat{a}_2 - r_{22}e_2}{\|\hat{a}_2 - r_{22}e_2\|}$

ger  $H_2$  så att  $H_2 \hat{a}_2 = r_{22}e_2$ .

$H_2$  påverkar inte första raden eftersom komponent 1 i  $v_2$  är 0.

$$H_2 H_1 = \begin{pmatrix} r_{11} & r_{12} & r_{13} & \dots & r_{1n} \\ & r_{22} & r_{23} & \dots & r_{2n} \\ 0 & & \hat{a}_3 & \dots & \hat{a}_n \\ & & & \ddots & \\ & & & & \hat{a}_n \end{pmatrix} \leftarrow \begin{array}{l} \text{Tre första} \\ \text{rader OK!} \end{array}$$

Fortsätt med  $\hat{a}_3 = \begin{pmatrix} 0 \\ 0 \\ \hat{a}_3 \\ \vdots \\ 0 \end{pmatrix}$  p.s.s.  $\Rightarrow H_3 \hat{a}_3 = r_{33}e_3$

till slut för vi  $H_n \dots H_1 A = \begin{pmatrix} R \\ 0 \end{pmatrix} \begin{matrix} n \\ m-n \end{matrix}$

Kalla  $Q^T = H_n \dots H_1$


$\Rightarrow Q^T A = \hat{R} \Leftrightarrow A = Q \hat{R}$  ty  $Q$  ortogonal.

Hela processen är multiplikation med

ortogonala matriser.  $H_i$ .  $\det(H_i) = 1$

(gäller alla ortogonala matriser).

Bästa möjliga numeriska egenskaper.



Lana 200518

## Singulärvärdesfaktorisering (SVD)

Liknar diagonalisering, fast för  $m \times n$ -matriser

Låt  $A$  vara godt. reell  $m \times n$ -matris, sök faktorisering

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

- $U$  ortogonal  $m \times m$
- $V$  ortogonal  $n \times n$
- $\Sigma$  "diagonal"  $m \times n$

Antag  $m \geq n$ . Då är  $\Sigma$  på formen

$$\Sigma = \begin{pmatrix} \sigma_1 & 0 & \dots & 0 \\ 0 & \sigma_2 & & \vdots \\ \vdots & & \ddots & 0 \\ 0 & \dots & 0 & \sigma_n \\ 0 & \dots & \dots & 0 \end{pmatrix} \quad \text{där } \sigma_i \geq 0 \quad \forall i$$

$\sigma_i$  kallas singulära värden. Omordning av kolonnerna i  $U$  och  $V$  och elementen i  $\Sigma$  ger

$$\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_n$$
 Antar detta generellt.

$A = U \Sigma V^T$  kallas full SVD faktorisering.

Kan alltid göras.

Exempel Om  $A$  är symmetrisk och positivt semidefinit är diagonaliseringen  $A = TDT^T$  ett specialfall  $U = V = T$ ,  $\Sigma = D$ . Om negativa egenvärden gör teckenbyte i  $\Sigma$  och  $V$  (eller  $U$ )

Om  $\text{rang } A = r$  blir  $\sigma_i = 0$  för  $i = r+1, \dots, n$

$$\Rightarrow \Sigma = \begin{pmatrix} \underbrace{\Sigma_1}_{r} & \underbrace{0}_{n-r} \\ \underbrace{0}_{r} & \underbrace{0}_{n-r} \end{pmatrix} \quad \Sigma_1 = \begin{pmatrix} \sigma_1 & & 0 \\ & \dots & \\ 0 & & \sigma_n \end{pmatrix}$$

Delat upp  $U = \begin{pmatrix} \underbrace{U_1}_r & \underbrace{U_2}_{n-r} \end{pmatrix}$   $V = \begin{pmatrix} \underbrace{V_1}_r & \underbrace{V_2}_{n-r} \end{pmatrix}$

$$A = U \Sigma V^T = \begin{pmatrix} U_1 & U_2 \end{pmatrix} \begin{pmatrix} \Sigma_1 & 0 \\ 0 & 0 \end{pmatrix} \begin{pmatrix} V_1^T \\ V_2^T \end{pmatrix} = \underline{U_1 \Sigma_1 V_1^T}$$

Kallas kompat SVD faktorisering

I Matlab:  $\text{svd}(A)$  för full,  $\text{svd}(A, 0)$  för kompakt SVD.



## Minstakvadratproblem med SVD

Minimera  $\|r\|$  där  $r = Ax - b$ ,

$$\begin{aligned}\|r\|^2 &= \|Ax - b\|^2 = \|U\Sigma V^T x - b\|^2 = \leftarrow U^{-1} = U^T \\ &= \|U(\Sigma V^T x - U^T b)\|^2 = \leftarrow U \text{ ortogonal} \\ &= \|\Sigma V^T x - U^T b\|^2 =\end{aligned}$$

$$= \left\| \begin{pmatrix} \Sigma_1 & 0 \\ 0 & 0 \end{pmatrix} \begin{pmatrix} V_1^T \\ V_2^T \end{pmatrix} x - \begin{pmatrix} U_1^T \\ U_2^T \end{pmatrix} b \right\|^2 =$$

$$= \left\| \begin{pmatrix} \Sigma_1 & V_1^T \\ 0 & 0 \end{pmatrix} x - \begin{pmatrix} U_1^T \\ U_2^T \end{pmatrix} b \right\|^2 = \leftarrow \text{Pythagoras}$$

$$= \underbrace{\|\Sigma_1 V_1^T x - U_1^T b\|^2}_{=0 \text{ om } \Sigma_1 V_1^T x = U_1^T b} + \underbrace{\|U_2^T b\|^2}_{\text{oberoende av } x}$$

$$= 0 \text{ om } \Sigma_1 V_1^T x = U_1^T b \quad \text{Oberoende av } x$$

Så  $x$  minimerar  $\|r\|$  om  $\Sigma_1 V_1^T x = U_1^T b$

$$\Leftrightarrow \boxed{V_1^T x = \Sigma_1^{-1} U_1^T b \quad (*)}$$

OBS:  $\Sigma_1$  alltid inverterbar men  $V_1^T$  ej inverterbar om  $\text{rang } A = r < n$ . För icke entydiga lösningar.

$$I = \begin{pmatrix} I & 0 \\ 0 & I \end{pmatrix} = \underbrace{V^T}_{\substack{r \\ n-r}} \underbrace{V}_{\substack{r \\ n-r}} = \underbrace{V_1^T}_{\text{ortogonal}} \underbrace{V_2^T}_{\text{ortogonal}} (V_1 \ V_2) = \begin{pmatrix} \underbrace{V_1^T V_1}_r & \underbrace{V_1^T V_2}_{n-r} \\ \underbrace{V_2^T V_1}_r & \underbrace{V_2^T V_2}_{n-r} \end{pmatrix}$$

$$\Rightarrow V_1^T V_1 = V_2^T V_2 = I$$

Men detta betyder inte att  $V_1$  är ortogonal.

Behöver inte vara kvadratisk. Dock

löser

$$\boxed{x = V_1 \Sigma_1^{-1} U_1^T b}$$

alltid (\*). Entydigt om  $\text{rang } A = n$

Om  $\text{rang } A = r < n$  är lösningen till  $V_1^T x = \Sigma_1^{-1} U_1^T b$  entydig.

$$x = V_1 \Sigma_1^{-1} U_1^T b$$

ger dock alltid den lösning med minst  $\|x\|$ .

Residualens norm är  $\|r\| = \|U_2^T b\|$

Kompakt SVD räcker för att beräkna  $x$ .

Def. Matrisen  $A^+ = V_1 \Sigma_1^{-1} U_1^T$  kallas

MOORE-PENROSE PSEUDOINVERS

"Närmaste invers man kan få för icke-kvadratiska matriser"

Om  $A^{-1}$  existerar är  $A^+ = A^{-1}$ .

$x = A^+ b$  är minsta kvadratlösning till  $Ax = b$ .

I Matlab ges  $A^+$  av `pinv(A)`.

Konditionstal för icke-inverterbara

matriser kan definieras  $\kappa(A) = \|A\| \|A^+\|$

## Eigenvärden och singulara värden

$$\text{Om } A = U \Sigma V^T$$

$$\Rightarrow A^T A = V \underbrace{\Sigma^T U^T U}_{I} \Sigma V^T = V \Sigma^T \Sigma V^T =$$

$$\Sigma^T \Sigma = \begin{pmatrix} \sigma_1 & 0 & 0 \\ 0 & \sigma_n & 0 \end{pmatrix} \begin{pmatrix} \sigma_1 & 0 \\ 0 & \sigma_n \end{pmatrix} = \begin{pmatrix} \sigma_1^2 & 0 \\ 0 & \sigma_n^2 \end{pmatrix}$$

$V$  ortogonal

$$\Rightarrow A^T A \text{ similär med } \Sigma^T \Sigma$$

$$\Rightarrow A^T A \text{ och } \Sigma^T \Sigma \text{ har samma eigenvärden.}$$

$A^T A$  är positivt semidefinit så  $\lambda_i \geq 0$

$$(+y \quad x^T A^T A x = (Ax)^T (Ax) = \|Ax\|^2 \geq 0)$$

$$\Rightarrow \text{de singulara värdena ges av } \sigma_i = \sqrt{\lambda_i}$$

där  $\lambda_i$  är eigenvärdena till  $A^T A$ .

(Ger ett sätt att konstruera  $\Sigma$ )

Hur konstruerar vi  $U$  och  $V$ ?

Om  $V = (v_1 \dots v_n)$  och  $U = (u_1 \dots u_m)$  så

$$A^T A = V \Sigma^T \Sigma V^T = \sum_{i=1}^n v_i \sigma_i^2 v_i^T \quad \leftarrow v \text{ ortogonal}$$

$$\Rightarrow A^T A v_j = \sum_{i=1}^n v_i \sigma_i^2 v_i^T v_j = \sigma_j^2 v_j$$

Så  $v_j$  egenvektor med eigenvärde  $\sigma_j^2$  till  $A^T A$ .

(Ger ett sätt att bilda  $V$ )

$$\text{P.s.s. } A A^T = \sum_{i=1}^n u_i \sigma_i^2 u_i^T \Rightarrow A A^T u_j = \sigma_j^2 u_j$$

Så  $u_j$  egenvektor till  $A A^T$  för  $1 \leq j \leq n$

Vi kan välja resterande  $u_j$  så  $U$  ortogonal.

—  $\square$

→  
OBS:  $A^T A$  och  $A A^T$  för samma  
nollskilda egenvärden men  $A A^T$  har  
 $m-n$  extra egenvärden som är 0. (om  $m > n$ )

### Trunkerad SVD

$A = U_1 \Sigma_1 V_1^T$  (kompakt SVD) kan skrivas

$$A = \sum_{i=1}^r \sigma_i u_i v_i^T \quad \text{där } r = \text{rang}(A)$$

Innehåller all information om  $A$ . Ibland vill  
vi approximera  $A$  med mindre information.

(till exempel bildkompression eller signalbehandling)

Eftersom  $\sigma_i$  är avtagande (och positiva) är  
de sista  $\sigma_i$  mindre betydelsefulla.

För  $k < r$  kan vi bilda trunkerade SVD-  
approximationen:

$$A_k = \sum_{i=1}^k \sigma_i u_i v_i^T \quad k = \text{rang}(A_k) < r = \text{rang}(A)$$

detta är bästa möjliga rank  $k$  approx. av  $A$ .

$$A - A_k = U_1 \begin{pmatrix} 0 & \dots & 0 \\ & \sigma_{k+1} & \\ 0 & & -\sigma_r \end{pmatrix} V_1^T$$

Normen av  $B$  är  $\|B\| = \sqrt{\lambda_{\max}}$  där  $\lambda_{\max}$   
är största egenvärdet till  $B^T B$ , d.v.s.

$$\|B\| = \sigma_{\max}.$$

$$\Rightarrow \|A - A_k\| = \sigma_{k+1}$$

Si  $\sigma_{k+1}$  litet  $\Rightarrow$  bra approx.



## Konditionstal och singulära värden

$$\kappa(A) = \|A\| \|A^+\|$$

$\|A\| = \sigma_{\max}$  där  $\sigma_{\max}$  största  $\sigma_i$  för  $A$ .

$\|A^+\| = \sqrt{\lambda_{\max}}$  där  $\lambda_{\max}$  största egenvärde till  $(A^+)^T(A^+)$ .

$$\begin{aligned}(A^+)^T(A^+) &= (V_1 \Sigma^{-1} U_1^T)^T V_1 \Sigma^{-1} U_1^T = \\ &= U_1 \Sigma^{-1} V_1^T V_1 \Sigma^{-1} U_1^T = \\ &= U_1 \begin{pmatrix} \sigma_1^{-2} & & 0 \\ & \ddots & \\ 0 & & \sigma_r^{-2} \end{pmatrix} U_1^T\end{aligned}$$

$$\Rightarrow \lambda_{\max} = \sigma_r^{-2} \Rightarrow \|A^+\| = \sigma_{\min}^{-1}$$

Slutsats:  $\boxed{\kappa(A) = \frac{\sigma_1}{\sigma_r} = \frac{\sigma_{\max}}{\sigma_{\min}}}$

Trunkering ger alltså bättre konditionering.

Om  $r < n$  kan små störningar av  $A$  göra

att  $\sigma_{r+1} = 0$  blir  $\sigma_{r+1} > 0$  (litet)

$\Rightarrow \kappa(A)$  stort (delar med litet men nollskilt)

Trunkera små singulära värden

$\Rightarrow$  bättre stabilitet.

Minstakvadratlösningen

$$x = V_1 \Sigma_1^{-1} U_1^T b = \sum_{i=1}^r (u_i^T b) \sigma_i^{-1} v_i$$

kan trunkeras

$$x = \sum_{i=1}^k (u_i^T b) \sigma_i^{-1} v_i = A_k^+ b$$

Blir mindre exakt men också mindre

känsligt för störningar.



Lana 200519

## Numerisk beräkning av egenvärden och

### egenvektorer

Vill numeriskt beräkna egenpar  $(\lambda, v)$  d.v.s.

egenvektor  $v$  med egenvärde  $\lambda$ .

Karaktäristiska ekvationen inte bra för större system.

- För  $A$   $n \times n$ -matris får determinanten  $n!$  termer.
- Numeriskt instabilt att hitta rötter till polynom av hög grad.

### Alternativa metoder

• Iterativa metoder (stegvis förbättrar approx)

- Potensmetoden ger till beloppet största  $\lambda$

- Inversiteration ger till beloppet minsta  $\lambda$

- Inversiteration med skift ger egenvärde närmast ett givet värde

• Transformationsmetoder

$B = T^{-1}AT$  har samma egenvärden som  $A$ .

Bra om  $B$  har t.ex. triangulär form

(egenvärden kan läsas av enkelt)

## Potensmetoden (Power iteration)

### Exempel

$$A = \begin{pmatrix} 1 & 3 \\ 2 & 2 \end{pmatrix}. \quad \text{Låt } x_{k+1} = Ax_k, \quad x_0 = \begin{pmatrix} -5 \\ 5 \end{pmatrix}$$

$$\Rightarrow x_1 = \begin{pmatrix} 10 \\ 0 \end{pmatrix} \quad x_2 = \begin{pmatrix} 10 \\ 20 \end{pmatrix} \quad x_3 = \begin{pmatrix} 70 \\ 60 \end{pmatrix} \quad x_4 = \begin{pmatrix} 250 \\ 260 \end{pmatrix}$$

$x_n$  verkar gå mot  $\alpha \begin{pmatrix} 1 \\ 1 \end{pmatrix}$ . Är  $\begin{pmatrix} 1 \\ 1 \end{pmatrix}$  egenvektor?

$$\text{Facit: } \lambda_1 = 4 \quad v_1 = \begin{pmatrix} 1 \\ 1 \end{pmatrix}, \quad \lambda_2 = -1 \quad v_2 = \begin{pmatrix} -3 \\ 2 \end{pmatrix}$$

Idé:

$$x_0 = \begin{pmatrix} -5 \\ 5 \end{pmatrix} = 1v_1 + 2v_2$$

$$\Rightarrow x_n = \underbrace{1(4)^n}_{\text{Dominerar!}} \begin{pmatrix} 1 \\ 1 \end{pmatrix} - 2(-1)^n \begin{pmatrix} -3 \\ 2 \end{pmatrix}$$

Så  $x_n = A^n x_0 \rightarrow \alpha v_1$ , om  $\lambda_1$  största egenvärde.

### Generellt:

Antag  $A$  diagonaliserbar  $n \times n$ -matris med egenvärden  $|\lambda_1| > |\lambda_2| \geq \dots \geq |\lambda_n|$ .

$(\lambda_1, v_1)$  kallas dominerande egenpar.

Låt  $x_{k+1} = Ax_k$ ,  $x_0$  givet.  $\Rightarrow x_k = A^k x_0$ .

$\{v_1, \dots, v_n\}$  bas för  $\mathbb{R}^n$  ( $A$  diagonaliserbar)

$$\Rightarrow x_0 = \sum_{j=1}^n c_j v_j \quad \text{för } c_j \in \mathbb{R}, \quad \text{Antag } c_1 \neq 0$$

$$\Rightarrow x_k = A^k x_0 = \sum_{j=1}^n c_j A^k v_j = \sum_{j=1}^n c_j \lambda_j^k v_j =$$

$$= \lambda_1^k \left( c_1 v_1 + \sum_{j=2}^n c_j \left( \frac{\lambda_j}{\lambda_1} \right)^k v_j \right) \rightarrow c_1 \lambda_1^k v_1$$

$$+ y \left( \frac{\lambda_j}{\lambda_1} \right)^k < 1 \quad \forall j = 2, \dots, n$$



$x_k$  för riktning  $v_1$  då  $k \rightarrow \infty$  men  $\lambda_1^k$   
problematisks (blir för stor eller liten)  
Normering löser problemet.

### Potensmetoden

Välj startvektor  $x_0$

Iterera:

$$y_{k+1} = Ax_k$$

$$x_{k+1} = \|y_{k+1}\|^{-1} y_{k+1}$$

Aubryt när  $\|x_{k+1} - x_k\| < \text{önskad tolerans}$

### OBS!

Om  $c_1 \neq 0$  konvergerar  $x_k$  mot egenvektorn

$u_1 = \frac{v_1}{\|v_1\|}$  (upp till tecken), annars ej. Om

$|\lambda_1| = |\lambda_2|$  konvergerar metoden inte.

### Beräkning av motsvarande egenvärde

$$Ax = \lambda x \Rightarrow x^T Ax = \lambda x^T x = \lambda \|x\|^2$$

$$\Rightarrow \boxed{\lambda = \frac{x^T Ax}{\|x\|^2}} \text{ Rayleighkvot}$$

Om  $u_1$  egenvektorn från potensmetoden  
är motsvarande egenvärde

$$\lambda = \frac{u_1^T A u_1}{\|u_1\|^2} = u_1^T A u_1$$

## Näst största egenvärdet (Deflation)

Antag  $A$  symmetrisk och  $A = TDT^T$   
med  $T = (u_1 \dots u_n)$ ,

$$\Rightarrow A = \sum_{i=1}^n \lambda_i u_i u_i^T$$

Om vi bestämt  $\lambda_1$  och  $u_1$  kan vi bilda

$$A_2 = A - \lambda_1 u_1 u_1^T = \sum_{i=2}^n \lambda_i u_i u_i^T$$

Om  $|\lambda_2| > |\lambda_3|$  kan vi bestämma  $(\lambda_2, u_2)$   
med potensmetoden ty  $\lambda_2$  största egenvärde  
till  $A_2$ . Kan upprepas.

Tekniken kallas Deflation

## Invers iteration

Om  $|\lambda_n| > 0 \Rightarrow \lambda_i \neq 0 \forall i$

$\Rightarrow A^{-1}$  existerar och har egenvärden  $\lambda_i^{-1}$

$$A v_i = \lambda_i v_i \Leftrightarrow v_i = A^{-1} v_i \Rightarrow A^{-1} v_i = \lambda_i^{-1} v_i$$

Så  $(\lambda_i^{-1}, v_i)$  egenpar till  $A^{-1}$ .

Dominerande egenparet är  $(\lambda_n^{-1}, v_n)$

Förslag: finn  $\lambda_n$  med potensmetoden för  $A^{-1}$

Vill dock undvika  $A^{-1}$ . Använd

$$A y_{k+1} = x_{k+1} \quad \text{ist. för } y_{k+1} = A^{-1} x_{k+1}$$

Många lika högerled  $\rightarrow$  LU-faktorisering

## Inversiteration

Välj startvektor  $x_0$

LU-faktorisera med pivotering:  $PA = LU$

Iterera:

$$\text{Lös } LZ_k = Px_k$$

$$\text{Lös } Uy_{k+1} = z_k$$

$$\text{Bilda } x_{k+1} = \|y_{k+1}\|^{-1} y_{k+1}$$

Tillsammans med Rayleighkvot får man  $(\lambda_n, u_n)$

Anm: Kan ej använda deflation ty alla egenvärden måste vara nollskilda.

## Invers iteration med skift

OBS: Om  $\{\lambda_i\}_{i=1}^n$  egenvärden till  $A$

$$\det(A - \sigma I - \lambda I) = (\lambda_1 - \sigma - \lambda)(\lambda_n - \sigma - \lambda) \dots$$

$\Rightarrow \{\lambda_i - \sigma\}_{i=1}^n$  är egenvärden till  $A - \sigma I$

Inversiteration på  $A - \sigma I$  ger egenparet med minst  $|\lambda_i - \sigma|$  d.v.s. egenvärdet närmast  $\sigma$  är det vi hittar.

Flera egenvärden lika nära  $\Rightarrow$  metod fungerar ej.

Konvergensen blir snabbare om  $\sigma$  ligger närmare egenvärdet.

Modifikation: Uppdatera  $\sigma$  med approx.

av egenvärdet (t.ex. med Rayleighkvot)

$\Rightarrow$  snabbare upp processen.



## Rayleigh kvot - iteration

Välj startskift  $\sigma_0$

Välj startvektor  $x_0$

Iterera:

$$\text{LU-faktorisera } P(A - \sigma_k I) = LU$$

$$\text{Lös } LZ_k = Px_k$$

$$\text{Lös } Uy_{k+1} = z_k$$

$$\text{Bilda } x_{k+1} = \|y_{k+1}\|^{-1} y_{k+1}$$

$$\text{Bilda } \sigma_{k+1} = x_{k+1}^T A x_{k+1}$$

OBS: Om  $\sigma = \lambda_i$  blir  $A - \sigma I$  singular  
 $\Rightarrow$  Numeriska problem om  $\sigma_k$  blir för  
nära  $\lambda_i$ . Behöver eventuellt lägga på  
en liten konstant på  $\sigma_k$

Snabb men kan få stabilitetsproblem

## QR-iteration

Transformationsmetoder är stabilare och kan ge alla egenpar samtidigt.

## QR-iteration

$$\text{Låt } A_0 = A$$

Iterera:

$$\text{QR-faktorisera } Q_k R_k = A_{k-1}$$

$$A_k = R_k Q_k$$

Vi får  $Q_k$  ortogonal och

$$Q_k A_k \underbrace{Q_k^T}_{Q_k^{-1}} = Q_k R_k Q_k Q_k^T = A_{k-1}$$

Så  $A_k$  och  $A_{k-1}$  similära  $\Rightarrow$  samma egenvärden

Om alla egenvärden har olika storlek konvergerar  $A_k$  mot en uppåt triangulär matris  $\Rightarrow$  egenvärden på diagonalen.

A symmetrisk ger  $A_k \rightarrow D$  diagonal

$$\Rightarrow A = Q D Q^T$$

där  $Q = Q_1 Q_2 \dots Q_n$

(Teori visas ej i denna kurs)

Konvergens snabbas upp med skift

### QR-iteration med skift

Låt  $A_0 = A$

Iterera:

$$QR\text{-faktorisera } Q_k R_k = A_{k-1} - \sigma_k I$$

$$A_k = R_k Q_k + \sigma_k I$$

Knepigt att välja  $\sigma_k$  men ger snabb konvergens.  
Deflation kan också användas.

### Ortogonal iteration.

Om man vill beräkna de  $p$  största egenparen kan man använda detta "mellanling".

### Ortogonal iteration

Välj  $\Sigma_0$   $n \times p$ -matrix med rang  $p$  (startgissning)

Iterera:

$$QR\text{-faktorisera } \underline{\text{kompakt}} \quad Q_k R_k = \Sigma_{k-1}$$

$$\Sigma_k = A Q_k$$

OBS: om  $v$  första kolonn i  $\Sigma_{k-1}$  så är  $\frac{v}{\|v\|}$  första kolonn i  $Q_k$ . Metoden ger växelvis normering och multiplikation med  $A$  på första kolonnen d.v.s. potensmetoden.

Valet  $p=n$  och  $\Sigma_0 = I$  ger QR-metoden

$A$  verkar på ortogonala vektorer för att förhindra att alla kolonner i  $\Sigma_k$  konvergerar mot största egenparet.

Lana 200525

## Optimering

Matematiskt formulerade problem:

Maximera eller minimera en funktion  
under givna bivillkor (kallas matematisk  
programmering)

### Generellt optimeringsproblem

minimera $f(x)$		$x \in \mathbb{R}^n$ , $n$ variabler att optimera
då $\begin{cases} g(x) = 0 \\ h(x) \leq 0 \end{cases}$		$f: \mathbb{R}^n \rightarrow \mathbb{R}$ OBJEKTFUNCTION
		$g: \mathbb{R}^n \rightarrow \mathbb{R}^m$ LIKHETSBIVILLKOR
		$h: \mathbb{R}^n \rightarrow \mathbb{R}^k$ OLIKHETSBIVILLKOR

Om  $m=0$  och  $k=0$ : optimering utan bivillkor  
 $h(x) \leq 0$  avser elementvis olikhet

För maxproblem:  $\max f \Leftrightarrow \min(-f)$

$$h \geq 0 \Leftrightarrow -h \leq 0$$

Relationer av typen  $\leq, \geq, =$  kan hanteras,  
strikt olikhet ej praktiska.

Olikhetsbivillkor beskriver ofta resurs begrän-  
ningar, icke-negativitetsvillkor etc.

Kräver speciella metoder, ej i denna kurs.

## Generella begrepp

Mängden  $\mathcal{X} = \{x \in \mathbb{R}^n \mid g(x) = 0, h(x) \leq 0\}$

kallas TILLÅTNA OMRÅDET. Problemet


kan formuleras  $\min_{x \in \mathcal{X}} f(x)$ .

- o  $x^* \in \mathcal{X}$  är ett GLOBALT MINIMUM om  $f(x^*) \leq f(x) \quad \forall x \in \mathcal{X}$
- o  $x^* \in \mathcal{X}$  är ett LOKALT MINIMUM om  $f(x^*) \leq f(x) \quad \forall x \in \mathcal{X}$  i en omgivning av  $x^*$

Om  $f(x^*) < f(x)$  för  $x \neq x^*$  har vi STRIKT eller UNIKT globalt/lokalt min.

(Brakar ej säga unikt lokalt minimum)

## Riktningar



En riktning  $s \in \mathbb{R}^n$  i  $x$  kallas TILLÅTEN om

$$\exists \delta_1 > 0 : x + \alpha s \in \mathcal{X} \quad \forall \alpha \in (0, \delta_1)$$

annars OTILLÅTEN

En riktning  $s \in \mathbb{R}^n$  kallas DESCENTRIKTNING eller AVTAGANDERIKTNING i  $x$  om

$$\exists \delta_2 > 0 : f(x + \alpha s) < f(x) \quad \forall \alpha \in (0, \delta_2)$$



## Vanliga metoder för optimering

- 1) Börja i  $x = x_0 \in \mathbb{X}$
- 2) Hitta en tillåten descentriktning  $s$  i  $x$
- 3) Ta ett steg i riktning  $s$ , d.v.s

$$x \rightarrow x + hs$$

För vissa metoder:  $h$  väljs så att  $f(x+hs)$  minimeras m.a.p.  $h$ . kallas  
LINJESÖKNING (endimensionell optimering)

- 4) Upprepa tills det inte finns någon tillåten descentriktning, då är man i lokalt minimum.

## Matematiska verktyg

Antag  $f \in C^2$ , Inga bivillkor

Gradienten:  $\nabla f(x) = \left( \frac{\partial f}{\partial x_1}, \dots, \frac{\partial f}{\partial x_n} \right)^T$

Hessianen:  $H(x) = \begin{pmatrix} \frac{\partial^2 f}{\partial x_1^2} & \frac{\partial^2 f}{\partial x_1 \partial x_2} & \dots \\ \frac{\partial^2 f}{\partial x_2 \partial x_1} & \frac{\partial^2 f}{\partial x_2^2} & \dots \\ \vdots & \vdots & \ddots \end{pmatrix} = J(\nabla f(x))$

Jacobian av gradient

Andra derivator kommuterar ty  $f \in C^2$

$$\Rightarrow H^T = H \quad \text{d.v.s. } H \text{ symmetrisk}$$

$\Rightarrow H$  har reella egenvärden

Taglorutveckla  $f$  i  $x \in \mathbb{R}^n$  kring  $a \in \mathbb{R}^n$  (ordn. 2)

$$T_2(x) = f(a) + \underbrace{(\nabla f(a))^T (x-a)}_{\text{skalärprod.}} + \frac{1}{2} \underbrace{(x-a)^T H(a) (x-a)}_{\text{kvadratisk form}}$$

$$T_2(x) = f(a) + (\nabla f(a))^T(x-a) + \frac{1}{2}(x-a)^T H(a)(x-a)$$

Om  $\nabla f(a) = 0$  är  $a$  en kritisk punkt.

Om  $\nabla f(a) = 0$  och  $H(a)$  positivt definit,

d.v.s. positiva egenvärden har  $T_2(x)$  globalt minimum i  $a \Rightarrow f$  har lokalt minimum

(ty restterm försumbar nära  $a$ )

P.S.S

•  $\nabla f(a) = 0$  &  $H(a)$  neg. def

$\Rightarrow$  lokal maxpunkt

•  $\nabla f(a) = 0$  &  $H(a)$  indefinit

$\Rightarrow$  sadelpunkt

•  $\nabla f(a) = 0$  &  $H(a)$  semidefinit

$\Rightarrow$  måste utveckla längre.

Exempel  $f(x) = f(x_1, x_2) = x_1^4 + x_1^2 + 2x_2^2 - 2x_1x_2$

Taylorutveckla i  $x = a = \begin{pmatrix} 1 \\ 1 \end{pmatrix}$

$$\nabla f(x) = \begin{pmatrix} 4x_1^3 + 2x_1 - 2x_2 \\ 4x_2 - 2x_1 \end{pmatrix} \Big|_{x=a} = \begin{pmatrix} 4 \\ 2 \end{pmatrix}$$

$$H(x) = \begin{pmatrix} 12x_1^2 + 2 & -2 \\ -2 & 4 \end{pmatrix} \Big|_{x=a} = \begin{pmatrix} 14 & -2 \\ -2 & 4 \end{pmatrix}$$

kring  $a$   $\rightarrow$

$$T_2(x) = 2 + \begin{pmatrix} 4 & 2 \end{pmatrix} \begin{pmatrix} x_1 - 1 \\ x_2 - 1 \end{pmatrix} + \frac{1}{2} \begin{pmatrix} x_1 - 1 & x_2 - 1 \end{pmatrix} \begin{pmatrix} 14 & -2 \\ -2 & 4 \end{pmatrix} \begin{pmatrix} x_1 - 1 \\ x_2 - 1 \end{pmatrix}$$

$$= 7x_1^2 + 2x_2^2 - 2x_1x_2 - 8x_1 + 3$$

## Optimering utan bivillkor

$\Rightarrow$  Lös  $\nabla f(x) = 0$

Kontrollera minimalitet

## Optimering med likhetsbivillkor

Ett alternativ: Lagranges multiplikator metod

Inför Lagrangefunktionen

$$L(x, \lambda) = f(x) + \underbrace{\lambda^T g(x)}_{\text{"sträffterm"}}, \quad \lambda \in \mathbb{R}^m \leftarrow \begin{array}{l} \text{Lagrange-} \\ \text{multiplikatorer} \end{array}$$

Sök min m.a.p.  $x$  och max m.a.p.  $\lambda$

$\Rightarrow$  sök extrempunkt (sadelpunkt)

till  $L(x, \lambda)$

$$\nabla L(x, \lambda) = 0 \Leftrightarrow \begin{cases} \nabla f(x) + \sum_{i=1}^m \lambda_i \nabla g_i(x) = 0 \\ g(x) = 0 \end{cases}$$

Lös med metoder för icke-linjära

ekvationssystem (t.ex. Newtons metod)

## Generella resultat

1)  $s \in \mathbb{R}^n$  är en descentriktning om  $\nabla f(x)^T s < 0$

2) Om  $x^*$  lokalt min. så finns ingen

tillåten descentriktning i  $x^*$

3) Om  $x^*$  lokalt min. i det inre av

tillåtna området är  $\nabla f(x^*) = 0$ .

## Endim. optimering-

Viktigt då  $n=1$  eller vid linjesökning

Utan bivillkor:  $\min_{x \in \mathbb{R}} f(x)$  där  $f: \mathbb{R} \rightarrow \mathbb{R}$

Ibland  $\min_{x \in [a,b]} f(x)$ , typiskt  $[a,b] = [0,1]$

## Newtons metod

Kom ihåg: Newton för  $g(x) = 0$ :

$$x_{k+1} = x_k - \frac{g(x_k)}{g'(x_k)}$$

Vill minimera  $f(x) \Rightarrow$  sätt  $g(x) = f'(x)$ .

Ger Newtons metod för minimering-

$$x_{k+1} = x_k - \frac{f'(x_k)}{f''(x_k)}$$

Konvergensegenskaper som för rotlösning

Nackdelar:

- o hittar extrempunkter, d.v.s. kan hitta max istället för min. Måste kontrollera resultatet.
- o kräver  $f'(x)$  och  $f''(x)$  i alla iterationer.

## Modifierad Newton

Approximera  $f''(x_k)$  med  $f''(x_0)$  eller approximation av  $f''(x_0)$ .

$$x_{k+1} = x_k - \frac{f'(x_k)}{f''(x_0)}$$

Sämr konvergens men behöver ej  $f''(x_k) \forall k$

## Sekantmetoden

Som Newton men approximera

$$f''(x_k) \approx \frac{f'(x_k) - f'(x_{k-1})}{x_k - x_{k-1}}$$

d.v.s. sekanten av  $f'(x)$  i  $x_{k-1}$  och  $x_k$

Som sekantmetod för rotlösning men med  $f'(x)$

$$x_{k+1} = x_k - \frac{f'(x_k)(x_k - x_{k-1})}{f'(x_k) - f'(x_{k-1})}$$

Slipper  $f''(x_k)$  men behöver två startvärden.



Lana 200526

## Optimering forts.

### Repetition

Endim optimering utan bivillkor, d.v.s. sök  $\min_x f(x)$  där  $x \in [a, b]$ .

Newton, Modifierad Newton, sekantmetoden kräver  $f'(x)$ . Diffkvot ej alltid bra. Idag: Gyllene snitt-metoden och polynomapproximation kräver bara  $f(x)$  och inte  $f'(x)$ .

### Gyllenesnitt-metoden

Fungerar unimodala funktioner

Def  $f: [a, b] \rightarrow \mathbb{R}$  är UNIMODAL om det finns en minpunkt  $x^*$  och  $f$  är strängt avtagande för  $x \in [a, x^*]$  och strängt växande för  $x \in [x^*, b]$ .



Unimodal



Unimodal



Ej unimodal

## Gyllensnitt metoden

Börja med två inre punkter  $a < x_1 < x_2 < b$

$$f(x_1) < f(x_2) \Rightarrow x^* \in [a, x_2]$$

ty om  $x^* \in (x_2, b]$  ger unimodalitet att  $f$  är strängt avtagande på  $[a, x_2]$ . Motsäger att  $f(x_1) < f(x_2)$ . P.S.S.

$$f(x_2) < f(x_1) \Rightarrow x^* \in [x_1, b]$$

Vi får nytt intervall att undersöka.

Kan behålla inre punkten för att spara funktionsberäkningar.

Exempel: Ett steg



$f(x_1) < f(x_2)$  ger



$f(x_2) < f(x_1)$  ger



Vi vill helst ha samma proportioner, d.v.s. skalfaktor  $g$  i båda fall.

Hur får vi samma skalfaktor

$$\begin{cases} g(b-a) = (b'-a') = x_2 - a \\ g(x_2 - a) = (x_2'' - a'') = x_1 - a \end{cases}$$

$$\Rightarrow \begin{cases} x_1 - a = g(x_2 - a) = g^2(b-a) \\ g(b-a) = b'' - a'' = b - x_1 \Rightarrow x_1 = b - g(b-a) \end{cases}$$

$$\Rightarrow g^2(b-a) = b - a - g(b-a)$$

$$\Rightarrow g^2 = 1 - g$$

$$\Rightarrow g = \frac{\sqrt{5}-1}{2} \quad \text{d.v.s. gyllene snittet}$$

Så för varje iteration:

$$x_1 = b - g(b-a)$$

$$x_2 = a + g(b-a)$$

Ger att vi kan återanvända funktionsberäkningar och behålla proportioner.

Upprepa  $k$  gånger ger intervall med längd

$$g^k(b-a) \text{ som innehåller } x^*.$$

Liknar intervallhalvering för rotsökning.

## Polynomapproximation

Fungerar om  $f$  är konvex och har min i  $[a, b]$  (med för unimodalitet på  $[a, b]$ ).

- o Börja med tre punkter, t.ex

$$x_1 = a \quad x_2 = \frac{1}{2}(a+b) \quad x_3 = b$$

Låt  $p_2(x)$  vara interpolationspolynomet i  $x_1, x_2, x_3$  av grad 2. Låt  $x_4$  vara minpunkt till  $p_2(x)$  (enkel att beräkna)

- o Sortera  $\{x_1, x_2, x_3, x_4\}$  ger punkter  $y_1 < y_2 < y_3 < y_4$ . Används som i gyllenesnittmetoden men  $a = y_1, x_1 = y_2, x_2 = y_3, b = y_4$ .

OBS! Får ej samma proportioner

- o Jämför  $f(x_1)$  med  $f(x_2) \Rightarrow$  nytt intervall med tre punkter, upprepa metoden.

Avbryt om intervallet är kort eller om  $x_4$  hamnar nära  $x_1, x_2$  eller  $x_3$ .

Ger snabbare konvergens än gyllenesnittmetoden utan att kräva fler funktionsberäkningar (en per iteration)


## Flerdimensionell optimering utan bivillkor

Problem:  $\min_{x \in \mathbb{R}^n} f(x)$   $f: \mathbb{R}^n \rightarrow \mathbb{R}$

Sökmeter: Iterera  $x_{k+1} = x_k + \alpha_k s_k$

där  $s_k$  sökdiriktning och  $\alpha_k$  steglängd

Ex



Val av sökdiriktning

Steepest descent / Brantaste lutning - metoden

$$(SD) \quad \boxed{s_k = -\nabla f(x_k)}$$

$f$  avtar snabbast i riktning  $-\nabla f(x_k)$ ,  
ortogonalt mot nivåkurvorna.

$s_k = -\nabla f(x_k)$  descentriktning om  $x_k$  ej minpunkt

$$\text{ty } \nabla f(x_k)^T s_k = -\nabla f(x_k)^T \nabla f(x_k) = -\|\nabla f(x_k)\|^2 \leq 0$$

Likhet om  $\nabla f(x_k) = \mathbf{0}$ , d.v.s. minpunkt.

Avbryt när  $\|\nabla f(x_k)\|$  är liten.



## Newton's metod

Lös  $\nabla f(x) = 0$  med Newtons metod för att finna rötter till ekvationssystem.

d.v.s. lös  $J(\nabla f(x_k))s_k = -(\nabla f(x_k))$

$$\Rightarrow \boxed{H(x_k)s_k = -\nabla f(x_k)}$$

$x_{k+1} = x_k + s_k$  från Newton antyder  $\alpha_k = 1$  bra.

Kräver  $H(x)$  men kan konvergera snabbt.

Kan konvergera mot lokal maxpunkt istället,

men om  $H(x)$  positivt definit  $\forall x \in \mathbb{R}^n$

( $\Leftrightarrow f(x)$  konvex) så är  $H^{-1}(x)$  positivt definit

(egenvärden  $\lambda_i^{-1} > 0$ )

$$\Rightarrow \nabla f(x_k)^T s_k = -\underbrace{\nabla f(x_k)^T H^{-1}(x_k) \nabla f(x_k)}_{\text{pos. def. kvadratisk form}} \leq 0$$

d.v.s. ger descentriktning för konvexa  $f$ .

Andragsgradspolynom löses på en iteration.

## Kvasi-Newton metoder

Approximera  $H(x_k)$  med  $B_k$ , t.ex.  $B_0 = H(x_0)$

och uppdatera med Broydens metod.

$$\left| \begin{array}{l} B_k s_k = -\nabla f(x_k) \\ x_{k+1} = x_k + s_k \\ B_{k+1} = B_k + \frac{1}{\|s_k\|_2^2} (\nabla f(x_{k+1}) - \nabla f(x_k) - B_k s_k) s_k^T \end{array} \right.$$

Andra val av  $B_k$  finns.

Som Newton: descentriktning om

$B_k$  är positivt definit

## Konjugerande gradientmetoden

Steepest descent. Kan ge många korta "sicksack"-steg. Kan bli bättre om man tar med lite av föregående sökriktning.

$$(KG) \quad s_k = -\nabla f(x_k) + \beta_k s_{k-1}, \quad \beta_k = \frac{\|\nabla f(x_k)\|_2^2}{\|\nabla f(x_{k-1})\|_2^2}$$

Första steget som SD (d.v.s.  $\beta_0 = 0$ )

Om  $f$  andragradspolynom blir  $s_k^T H s_j = 0$  då  $k \neq j$  om  $H$  pos. def.

$\Rightarrow$  ortogonala sökriktningar

$\Rightarrow$  max  $n$  iterationer

Mycket bättre än SD för andragradspolynom!

Då vi valt sökriktning kan vi välja steglängd. Vill ha  $\min_{\alpha_k} g(\alpha_k)$ ,  $g(\alpha_k) = f(x_k + \alpha_k s_k)$   
 $\Rightarrow$  Endim. linjesökning

Specialfall om  $f$  andragradspolynom:

$$g(\alpha_k) = f(x_k + \alpha_k s_k) = f(x_k) + \alpha_k \nabla f(x_k)^T s_k + \frac{1}{2} \alpha_k^2 s_k^T H s_k$$

konstant  
 $\downarrow$

$g'(\alpha_k) = 0$  ger

$$0 = g'(\alpha_k) = \nabla f(x_k)^T s_k + \alpha_k s_k^T H s_k$$

$$\Rightarrow \quad \alpha_k = - \frac{\nabla f(x_k)^T s_k}{s_k^T H s_k}$$

För Newtons metod är  $\alpha_k = 1$  OK.

Vid konvergensproblem kan  $\alpha_k$  väljas mindre i början (Dämpad Newton)

## Exempel

minimera  $f(x) = x_1^2 + 2x_1x_2^2 + x_2^3 - 4x_1 - 6x_2$   
utan bivillkor med Newtons metod och  
exakt linjesökning (En iteration)

$$\nabla f(x) = \begin{pmatrix} 2x_1 + 2x_2^2 - 4 \\ 3x_2^2 + 4x_1x_2 - 6 \end{pmatrix} \quad H(x) = \begin{pmatrix} 2 & 4x_2 \\ 4x_2 & 4x_1 + 6x_2 \end{pmatrix}$$

$$\text{Givet: } x^{(0)} = \begin{pmatrix} 1 \\ 1 \end{pmatrix}$$

pos def!  
Newton konvergerar  
i omgivningen.

$$\nabla f(x^{(0)}) = \begin{pmatrix} 0 \\ 1 \end{pmatrix} \quad H(x^{(0)}) = \begin{pmatrix} 2 & 4 \\ 4 & 10 \end{pmatrix}$$

$$\text{Newtons metod: } H(x^{(k)}) s_{k+1} = -\nabla f(x^{(k)})$$

$$\Rightarrow \left[ \begin{array}{cc|c} 2 & 4 & 0 \\ 4 & 10 & -1 \end{array} \right] \Rightarrow s_1 = \begin{pmatrix} 1 \\ -1/2 \end{pmatrix}$$

Linjesökning:

$$g(\alpha) = f(x^{(0)} + \alpha s_1) = \dots = \frac{3}{8}\alpha^3 + \frac{1}{4}\alpha^2 - \frac{1}{2}\alpha - 6$$

$$g'(\alpha) = 0 \Rightarrow \alpha_1 = \frac{2}{9}(\sqrt{10} - 1) \approx 0.4805$$

positiv rot, men  $\alpha$  måste vara  
positiv för descentriktion

$$x^{(1)} = x^{(0)} + \alpha s_1 = \begin{pmatrix} 1 + \frac{2}{9}(\sqrt{10} - 1) \\ 1 - \frac{1}{9}(\sqrt{10} - 1) \end{pmatrix} \approx \begin{pmatrix} 1.4805 \\ 0.7597 \end{pmatrix}$$

$$f(x^{(1)}) \approx -6.1409 //$$

ska egentligen fortsätta tills  $\|\nabla f(x^{(k)})\|$  litet.