

N:1 Felanalys och datoraritmetik

Thomas Bäckdahl

8 april 2019

(Baserat på slides av Håkon Hoel)

- 1 Approximationsfel och felfortplantning
- 2 Konditionstal och stabilitet för matematiska problem
- 3 Felanalys för approximativa algoritmer
- 4 Flyttalsaritmetik

Av olika skäl behöver vi studera approximationsfel.

- Mätfel och avrundningsfel (datorer representerar nästan alla tal approximativt).
- T.ex. alla tal i intervallet $(1 - \epsilon/4, 1 + \epsilon/2)$ med $\epsilon = 2.2 \cdot 10^{-16}$ sparas som (64-bit flyttalet) 1 i Matlab.
- **Notation:** För en skalär $x \in \mathbb{R}$ låter vi \hat{x} beteckna en approximation av x . T.ex.:

$$\hat{x} = 3.14 \approx 3.14159265 \dots = x.$$

- Ofta måste man använda en approximativ algoritm/funktion för att lösa ett problem (även i fall där det finns en exakt algoritm).
- Exempel: Exakt funktion $f(x) = e^x$ och en approximation

$$\hat{f}(x) := 1 + x + x^2/2 \approx e^x.$$

- Två sätt att beskriva approximationsfelet:

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

- **Relativa felet:**

$$\frac{\delta x}{x} = \frac{\hat{x} - x}{x} = \frac{\text{absoluta felet}}{\text{exakta värdet}}.$$

- Exempel: Approximationen $\hat{x} = 3.14$ av $x = 3.14159265\dots$ ger

$$\delta x := -0.00159265\dots \approx -0.15927 \cdot 10^{-2} \quad \text{och} \quad \frac{\delta x}{x} \approx -0.508 \cdot 10^{-3}. \quad (1)$$

- Om man inte känner exakta värdet av x (och $x, \hat{x} \neq 0$) kan relativäta felet approximeras

$$\frac{\delta x}{x} \approx \frac{\delta x}{\hat{x}}.$$

- Ofta behövs endast uppskattningar av approximationsfelets storlek. Konstanter $c_1, c_2 > 0$ är **felgränser** för respektive fel om

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

- I exemplet ekv. (1) är $c_1 = 0.2 \cdot 10^{-2}$ $c_2 = 0.6 \cdot 10^{-3}$ möjliga felgränser ty

$$|\delta x| \approx 0.15927 \cdot 10^{-2} \leq 0.2 \cdot 10^{-2} \quad \text{och} \quad \left| \frac{\delta x}{x} \right| \approx 0.508 \cdot 10^{-3} \leq 0.6 \cdot 10^{-3}.$$

- Om det absoluta felet uppfyller $|\delta x| \leq 0.5 \cdot 10^{-n}$ säger vi att approximationen \hat{x} har (minst) n **korrekta decimaler** (Obs! n kan vara negativ.)
- (Obs! Inte riktigt samma definition som Numerisk analys boken s. 9)
Om relativt felet uppfyller $|\delta x|/|x| < 0.5 \cdot 10^{-n}$ säger vi att approximationen \hat{x} har (minst) n **signifikanta siffror**.
- Approximationen $\hat{x} = 3.14$ av π har 2 korrekta decimaler och 2 signifikanta siffror.
(3 signifikanta enligt bokens def.)

Felfortplantning

- Antag vi har en funktion/algoritm $f : I \rightarrow \mathbb{R}$, med $I \subset \mathbb{R}$ och att vi önskar att beräkna $f(x)$ för indata $x \in I$.
- Felfortplantning studerar hur fel i indata $\hat{x} - x$ fortplantar sig till fel i utdata $\delta f(x) = f(\hat{x}) - f(x)$.
- Om vi antar $f \in C^1(I)$ ger medelvärdessatsen

$$\delta f(x) = f'(x + \theta\delta x)(\hat{x} - x) = f'(x + \theta\delta x)\delta x, \quad \theta \in [0, 1].$$

- Observation: $|utdatafelet| > |indatafelet|$ om $|f'| > 1$, och annars är $|utdatafelet| \leq |indatafelet|$.
- Om inte θ och/eller x är bekanta, används ofta första ordningens approximativa felfortplaningsformel

$$\delta f(x) \approx f'(\hat{x})\delta x \tag{2}$$

med motsvarande absoluta och relativa felgränser

$$|\delta f(x)| \lesssim |f'(\hat{x})||\delta x| \quad \text{och} \quad \left| \frac{\delta f(x)}{f(\hat{x})} \right| \lesssim \left| \frac{f'(\hat{x})}{f(\hat{x})} \right| |\delta x|$$

Exempel 1.2

Vi önskar att bestämma volymen av ett klot med radien r .

Antag att vår mätning av radien \hat{r} är bestämd med 1% relativfel (indatafel).

Ange felgräns för relativfelet till volymbestämningen.

Lösning:

1. Formeln för volymen: $V(r) = (4/3)\pi r^3$ med $V'(r) = 4\pi r^2$.
2. Relativfelet högst 1% implicerar att $|\delta r| \leq 0.01|r| \lesssim 0.01|\hat{r}|$.
(Vi använder approximativa felgränsen då vi inte känner r).
3. Approximativa felfortplantningsformeln ger

$$\left| \frac{\delta V(r)}{V(\hat{r})} \right| \lesssim \left| \frac{V'(\hat{r})}{V(\hat{r})} \right| |\delta r| \lesssim \left| \frac{4\pi \hat{r}^2}{(4/3)\pi \hat{r}^3} \right| \cdot 0.01 \cdot |\hat{r}| = 0.03.$$

Slutsats: 1% relativfel i indata ger att volymen kan bestämmas med 3% relativfel.

Högre ordnings felapproximation

- Medelvärdessatsen (2) leder till första ordningens approximation av felfortplantningen

$$\delta f(x) \approx f'(\hat{x})\delta x \quad (3)$$

- Om $f'(\hat{x}) \approx 0$, så är sannolikt approximationen (3) för optimistisk.
- Om t.ex. $f \in C^2(I)$ kan man i stället härleda en andra ordningens utveckling
1.

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

- 2. och, om $f'(\hat{x}) \approx 0$, approximativa felfortplantningsformeln

$$\delta f(x) \approx f''(\hat{x})\delta x^2/2.$$

Exempel 1.4 (ändrat)

Betrakta $f(x) = x^2 + 2x - 1$ och antag vi är givna mätningen $\hat{x} = -1 \approx x$ och $|\hat{x} - x|/|\hat{x}| \leq 0.01$. Hur noggrant kan $f(x)$ bestämmas?

Lösning:

1. Då $f'(x) = 2x + 2$ är $f'(\hat{x}) = 0$, och vi använder approximationen

$$\delta f(x) \approx f''(\hat{x})\delta x^2/2.$$

2. $f(\hat{x}) = -2$ och $f''(\hat{x}) = 2$ ger

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

Slutsats: $f(x)$ kan bestämmas med fyra signifikanta siffror.

Felfortplantning i flera variabler

- Generalisering av begreppen ovan från endimensionella fall till n -dimensionella fall:
- För en approximation $\hat{x} \approx x$ där $\hat{x}, x \in \mathbb{R}^n$, och $\delta x = \hat{x} - x$ säger vi att $c_1, c_2 > 0$ är felgränser för absoluta resp. relativfelen om

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

- Om $f \in C^1(I)$ där $I \subset \mathbb{R}^n$, dvs $f(x) = f(x_1, x_2, \dots, x_n)$ kan felfortplaningen från fel i indata

$$\hat{x} = x + \delta x = (x_1 + \delta x_1, \dots, x_n + \delta x_n)$$

till fel i utdata $f(\hat{x}) = f(x) + \delta f(x)$ skattas med medelvärdessatsen

$$\delta f(x) = f(\hat{x}) - f(x) = \int_0^1 \frac{d}{ds} f(x + s\delta x) \, ds = \sum_{k=1}^m \frac{\partial f}{\partial x_k}(x + \theta \delta x) \delta x_k, \quad \theta \in [0, 1].$$

- Approximation, om x är obekant: $\delta f(x) \approx \nabla f(\hat{x}) \cdot \delta x$.

Felfortplantning i flera variabler forts.

- Cauchy-Schwartz, $|x \cdot y| \leq \|x\| \|y\|$, $x, y \in \mathbb{R}^n$, är nyttig vid skattning av felgräns för felfortplantningen:

$$|\delta f(x)| \lesssim |\nabla f(\hat{x}) \cdot \delta x| \leq \|\nabla f(\hat{x})\| \|\delta x\| \quad \& \quad \left| \frac{\delta f(x)}{f(x)} \right| \lesssim \frac{\|\nabla f(\hat{x})\| \|\delta x\|}{|f(x)|}. \quad (4)$$

Exempel 1.3: Härled formel för relativa felet för multiplikation $f(x) = x_1 x_2$

Lösning:

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

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

Då $\nabla f = (x_2, x_1)$ ger (4) en alternativ felgräns

$$\Rightarrow \left| \frac{\delta f(x)}{f(x)} \right| \lesssim \frac{\|x\| \|\delta x\|}{|x_1 x_2|} = \sqrt{x_1^{-2} + x_2^{-2}} \|\delta x\|.$$

- (Relativa) konditionstalet är definierad som

$$\kappa(x) = \lim_{\delta \rightarrow 0^+} \max_{\|\delta x\| \leq \delta} \frac{(|f(x + \delta x) - f(x)| / |f(x)|)}{(\|\delta x\| / \|x\|)} \approx \frac{\|\text{Relativfel utdata}\|}{\|\text{Relativfel indata}\|}$$

- Tolkning: Ett problem med indata relativfel $\alpha\%$ kan ha utdata relativfel $\kappa \cdot \alpha\%$.
- Ett problem med litet konditionstal, t.ex. $\kappa \in (0, 10)$, sägs vara **stabilt** eller **välkonditionerad**.
- Och omvänt, ett problem med stort konditionstal, t.ex. $\kappa = 10^8$, sägs vara **instabilt** eller **illakonditionerad**.
- Tillämpning av approximationen $|f(x + \delta x) - f(x)| \lesssim \|\nabla f(x)\| \|\delta x\|$ ger följande estimat för κ :

$$\kappa(x) \lesssim \frac{(\|\nabla f(x)\| \|\delta x\| / |f(x)|)}{(\|\delta x\| / \|x\|)} = \|x\| \frac{\|\nabla f(x)\|}{|f(x)|}.$$

Exempel

- Den endimensionella funktionen $f(x) = cx$ och $x \neq 0$ ger

$$\kappa(x) \lesssim |x| \frac{|f'(x)|}{|f(x)|} = |x| \frac{|c|}{|cx|} = 1.$$

- Funktionen $f(x_1, x_2) = x_1 - x_2$ och $x = (1, 1 + 10^{-100})$ ger

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

Observation: Subtraktionen $x_1 - x_2$ är en instabil operation när $x_1 \approx x_2$.

- Funktionen $f(x) = Ax$ där A är en inverterbar $n \times n$ matris ger

$$\kappa(x) \lesssim \frac{(\|A\| \|\delta x\| / \|Ax\|)}{(\|\delta x\| / \|x\|)} = \|A\| \frac{\|x\|}{\|Ax\|} \leq \|A\| \|A^{-1}\|$$

(Vi återkommer till matrisnorm $\|A\| := \sup_{x \neq 0} \frac{\|Ax\|}{\|x\|}$ i kapitel 5.)

Approximativa algoritmer, framåt- och bakåtfel

- Förutom indatafel (t.ex. mätfel, eller trunkerad representation) finns en annan potentiell felkälla: exakta metoden/algoritmen f måste i många fall ersättas av en approximativ algoritm \hat{f} .
- **Framåtfel** för en trippel (f, \hat{f}, x) ges av $\hat{f}(x) - f(x)$, som beskriver approximativa algoritmens fel i utdata.
- Antag i fortsättningen att f är inverterbar i en omgivning av x .
- Observera att för varje värde $\hat{f}(x)$ finns då ett indatavärde $\hat{x} = f^{-1}(\hat{f}(x))$ så att

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

- **Bakåtfel** för en trippel (f, \hat{f}, x) är definierad som

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

Bakåtfellet $\hat{x} - x$ motsvarar det absoluta fel δx som ger felfortplantningen $f(\hat{x}) - f(x) = \hat{f}(x) - f(x)$.

Exempel 1.8

Låt $f(x) = e^x$ och

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

vara exakta resp. approximativa algoritmen. Beräkna framåt- och bakåtfelet för (f, \hat{f}, x) med $x = 1$.

Lösning:

1. Då

$$\hat{f}(1) = (1 + 1 + 1/2 + 1/6) = 8/3$$

blir framåtfelet

$$\hat{f}(1) - f(1) = 8/3 - e^1 = -0.051615\dots$$

2. För bakåtfelet, observera att $f^{-1}(x) = \ln(x)$. Det ger

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

och

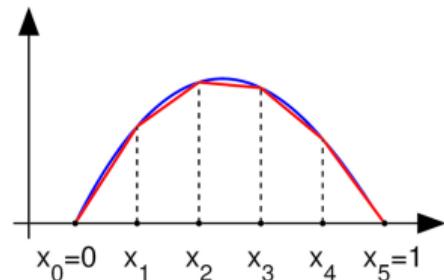
$$\hat{x} - x = \ln(8/3) - 1 = -0.019171\dots$$

Numerisk algoritm

Exempel, matematisk problem: Beräkna integralen

$$I = \int_0^1 g(x) dx.$$

Om vi inte kan lösa problemet exakt, kan vi försöka lösa det numeriskt. Typiska steg från matematiskt problem till numerisk algoritm:



1. Reduktion av informationsmängd: approximera funktionen $g : [0, 1] \rightarrow \mathbb{R}$ med styckvis-linjär funktion \bar{g} sådan att $\bar{g}(x_i) = g(x_i)$ för $0 = x_0 < x_1 < \dots < x_n = 1$.
2. Förenklat (numeriskt) problem: Beräkna integralen

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

3. Numerisk algoritm

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

- Kom ihåg att ett problem sägs vara stabilt/välkonditionerad om konditionstalet är litet

$$\kappa(x) = \frac{\|\text{relativfel utdata}\|}{\|\text{relativfel indata}\|}.$$

- Med andra ord, ett problem är stabilt om relativt små förändringar i indata ger relativt små förändringar i utdata.
- Definitionen: En numerisk algoritm $\hat{f} \approx f$ sägs vara stabil för $x \neq 0$ om relativa bakåtfellets storlek

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

är litet.

- Med andra ord, \hat{f} är stabil om $\hat{f}(x)$ är exakta lösningen till nästan rätt problem ($f(\hat{x})$).
- Exempel 1.8: $|f^{-1}(\hat{f}(1)) - 1|/1 \approx 0.02$. Algoritmen är stabil för $x = 1$.

Framåt- och bakåtanalys

- Vi använder bakåtanalys i definitionen av stabilitet bland annat för att det i många fall är lättare att studera än framåtanalys.
- Exempel: Betrakta problemet $Ax = b$, A stor men inverterbar matris, och låt

$$f(b) = A^{-1}b, \quad \text{och} \quad \hat{f}(b) = (A^{-1} + \varepsilon I)b.$$

- Framåtanalys estimerar (framåtstabiliteten)

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

vilket är svårt att komma åt i fall där A är stor och vi inte kan lösa problemet exakt.

- I bakåtanalysen använder vi att $f^{-1}(y) = Ay$, och estimerar enkelt (bakåt) stabiliteten

$$\frac{\|f^{-1}(\hat{f}(b)) - b\|}{\|b\|} = \frac{\|A(A^{-1} + \varepsilon I)b - b\|}{\|b\|} = \frac{\|\varepsilon Ab\|}{\|b\|} \leq |\varepsilon| \|A\|.$$

- I programmeringsspråk kan tal sparas i en del olika format (datatyper):
 - signed int32 eller 64 (32 eller 64-bits heltal), dvs alla heltal i $[-2^{31}, 2^{31} - 1]$ resp. $[-2^{63}, 2^{63} - 1]$
 - single precision floating point (32-bit flyttal) $\hat{\pi} = 3.14159274101257$
 - double precision floating point (64-bit flyttal) $\hat{\pi} = 3.14159265358979$
 - ...
- I Matlab sparas alla tal som flyttal i datatypen **double 64** per default. Om du önskar att spara i annan datatyp måste du ange det när du tilldelar en variabel ett värde.

```
>> x = pi  
x = 3.14159265358979  
>> y = int64(pi)  
y = 3
```

- Ett flyttalssystem definieras av kvadrupeln $\mathcal{F} = (\beta, t, L, U)$.
 - $\beta \in \mathbb{N} \setminus \{1\}$ är basen till systemet. $\beta = 2, 10$ ger det binära respektive decimala systemet.
 - t är antalet siffror i systemet (relaterad till antal signifikanta siffror).
 - L och U är lägsta resp. högsta värde på exponenten (se nedan).
- Varje flyttal x i \mathcal{F} representeras på formen

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

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

- Med mantissan $m = d_0.d_1\dots d_{t-1}$ kan talet ovan skrivas $x = \pm m \cdot \beta^e$.
- Exempel: Flyttalssystemet $(10, 3, -1, 1)$ består av tal på formen

$$x = \pm d_0.d_1d_2 \times 10^e, \quad 1 \leq d_0 \leq 9, \quad 0 \leq d_1, d_2 \leq 9, \quad -1 \leq e \leq 1.$$

- T.ex. flyttalet $x = -0.94 = -9.40 \cdot 10^{-1}$ fås med $d_0 = 9, d_1 = 4, d_2 = 0$ och $e = -1$.

Binära flyttalssystemet double

- Exempel: Flyttalsstemet (IEEE-754) double beskrivs av kvadrupeln $(\beta = 2, t = 53, L = -1022, U = 1023)$ och består av alla tal

$$x = \pm \underbrace{d_0.d_1 \dots d_{52}}_{\text{mantissa}} \times 2^e, \text{ där } d_0 = 1, \quad 0 \leq d_i \leq 1, \quad i \geq 1,$$

och $-1022 < e < 1023$.

- Tex. tablet

$$x = 2.75 = (1 + 0 \cdot 2^{-1} + 2^{-2} + 2^{-3}) \cdot 2^1 \text{ skrivs } 1.0110\ldots 0_2 \cdot 2^1.$$

Diagram illustrating the structure of a floating-point number:

- The first 11 bits represent the exponent + 1023 (11bitar).
- The remaining 52 bits represent the mantissa without d_0 (52bitar).

Underflow, overflow och flyttalsavrundning

- Då vi har normaliseringen $1 \leq d_0 \leq \beta - 1$ för systemet $\mathcal{F} = (\beta, t, L, U)$, får vi

$$\min(\mathcal{F} \cap \mathbb{R}_+) = 1.0\ldots0 \cdot \beta^L = \beta^L =: \text{UFL (underflow level)}$$

och

$$\max(\mathcal{F} \cap \mathbb{R}_+) = (\beta - 1) \cdot \underbrace{(\beta - 1)\ldots(\beta - 1)}_{t-1} \cdot \beta^U = \beta^{U+1}(1 - \beta^{-t}) =: \text{OFL},$$

där OFL står för overflow level.

- För att konvertera/avrunda reella tal till flyttal kan vi tänka oss, något förenklat, att följande avbildning $f_l : \mathbb{R} \rightarrow \mathcal{F}$ används:

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

- Tal $|x| < \text{UFL}$ (t.ex. 0) ingår formellt inte i \mathcal{F} .
 - För tal $|x| < \text{UFL}$ tillåter IEEE-standarden gradvis underspill genom att släppa på normaliseringsskravet. Detta ger större relativt fel.
 - T.ex. talet 2^{-1023} skrivs $0.100\dots0_2 \cdot 2^{-1022}$ (52 bitar kvar)

The diagram illustrates a 64-bit floating-point number. It is divided into two main parts: the exponent and the mantissa. The exponent, labeled as 'exponent + 1022 (11bitar)', is represented by the first 11 bits from the left. The remaining 53 bits, labeled as 'mantissa med d_0 (52bitar)', represent the mantissa, which includes the implicit leading 1 bit.

- Minsta positiva talet $2^{-1022}2^{-52} = 2^{-1074}$ (1 bit kvar)

The diagram illustrates the IEEE 754 floating-point format. It consists of three main fields: a 1-bit sign, a 11-bit exponent, and a 52-bit mantissa. The sign bit is at the far left. The exponent is followed by a hidden bit (implied 1) and the mantissa. Brackets above the exponent and mantissa indicate their widths: 11bitar for the exponent and 52bitar for the mantissa.

- Följande egenskap gäller för alla $\text{UFL} \leq |x| \leq \text{OFL}$, (övning 1.5)

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

- Dvs $fl(x)$ approximerar x med $t - 1$ signifikanta siffror (i basen β) och talet $\mu = 0.5 \cdot \beta^{1-t}$ kallas **maskintalet** eller **avrundningsenheten**.
- Alternativt skriver man

$$fl(x) = x(1 + \delta), \quad \text{för något } |\delta| \leq \mu.$$

- Flyttalssystem är implementerad så att flyttalsaritmetik görs i ett utvidgat register och

$$fl(x \diamond y) \leq x \diamond y(1 + \delta) \quad \text{för något } |\delta| \leq \mu,$$

om $\diamond = +, *, -$ eller $/$, $x, y \in \mathcal{F}$ (och $x \diamond y \neq Inf$).

Illustration av flyttalsaddition i systemet $\mathcal{F} = (10, 4, -9, 9)$.

Summan av $x = 1.234 \cdot 10^0$ och $y = 4.567 \cdot 10^{-2}$.

1. Bestäm vilken av x och y som har störst exponent. Representera båda talen med mantissor anpassad största exponenten:

$$x = 1.234 \cdot 10^0 \quad \& \quad y = 0.04567 \cdot 10^0.$$

2. Addera talen:

$$x + y = 1.27967 \cdot 10^0$$

3. Avrunda till närmaste flyttal:

$$fl(x + y) = fl(1.27967 \cdot 10^0) = 1.280 \cdot 10^0.$$

Flyttalsaddition är inte associativ

- **Exempel 1.12** Låt $\mathcal{F} = (10, 4, -9, 9)$ och addera flyttalen

$$a = 9.876 \cdot 10^4, \quad b = -9.880 \cdot 10^4, \quad c = 3.456 \cdot 10^1.$$

- Å ena sidan får man

$$fl(fl(a + b) + c) = fl(-4.000 \cdot 10^1 + 3.456 \cdot 10^1) = -5.440 \cdot 10^0,$$

men å andra sidan

$$\begin{aligned} fl(a + fl(b + c)) &= fl(a + fl((-9.880 + 0.003456) \cdot 10^4)) \\ &= fl((9.876 - 9.877) \cdot 10^4) \\ &= -1.000 \cdot 10^1. \end{aligned}$$

- Slutsats: Generellt har vi **inte**

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

- **Utskifning** innebär att noggrannhet går förlorad när flyttal med olika storleksordningar adderas/subtraheras.
- Exempel **fullständig utskiftning**: Addition av flyttalen $a = 1.234 \cdot 10^7$ och $b = 1.678 \cdot 10^3$ i $\mathcal{F} = (10, 4, -9, 9)$ ger

$$\begin{aligned}fl(a + b) &= fl((1.234 + 0.0001678) \cdot 10^7) \\&= fl((1.2341678) \cdot 10^7) \\&= 1.234 \cdot 10^7 \\&= a.\end{aligned}$$

- **Partiell utskiftning**: Om en följd av flyttal x_1, x_2, \dots av olika storleksordning adderas.
- Strategi för att undvika utskiftning: Summera följen i (till beloppet) växande storleksordning.

Utskiftning i Matlab

```
>> eps
ans = 2.22044604925031e-16

>> 2^(1-53)
ans = 2.22044604925031e-16
%Slutsats: Matlabs variabel eps=2^(-52) = 2*mu

>> x=x+eps
x = 1.000000000000000 % = 1+eps

>> x=1+2*eps/3
x = 1.000000000000000 % = 1+ eps

>> x=1+eps/3
x = 1
```

- **Kancellation** innebär noggrannhetsförlusten som uppstår vid subtraktion av två nästan lika stora tal (efter tidigare operationer med avrundningsfel).
- **Exempel 1.15** Betrakta följande beräkning

$$37654 + 25.874 - 37679 = 0.874$$

i flyttalssystemet $\mathcal{F} = (10, 5, -9, 9)$.

- Dvs

$$\begin{aligned} & fl(fl(3.7654 \cdot 10^4 + 2.5874 \cdot 10^1) - 3.7679 \cdot 10^4) \\ &= fl(fl((3.7654 + 0.0025874) \cdot 10^4) - 3.7679 \cdot 10^4) \\ &= fl(fl(3.76\textcolor{red}{79874} \cdot 10^4) - 3.7679 \cdot 10^4) \\ &= fl(3.76\textcolor{red}{80} \cdot 10^4 - 3.7679 \cdot 10^4) \\ &= 1.0000 \cdot 10^0 \end{aligned}$$

- Kancellation kan ibland undvikas genom att göra en matematisk omskrivning av problemet.
- **Exempel** För stora x får man kancellation vid beräkning av $\sqrt{x^2 + 1} - x$. Gör istället omskrivningen

$$\sqrt{x^2 + 1} - x = \frac{(\sqrt{x^2 + 1} - x)(\sqrt{x^2 + 1} + x)}{(\sqrt{x^2 + 1} + x)} = \frac{x^2 + 1 - x^2}{(\sqrt{x^2 + 1} + x)} = \frac{1}{\sqrt{x^2 + 1} + x}.$$

vid beräkning av $\frac{1}{\sqrt{x^2 + 1} + x}$ undviks kancellation.

- **Exempel 1.17:** Kvadrering: $f(x) = x^2$ för $x \in \mathbb{R} \setminus \{0\}$ approximeras i flyttalssystemet $\hat{f}(x) = fl(fl(x)^2)$. Låt oss verifiera att

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

vid framåtanalys:

1. Då $fl(x) = x(1 + \delta)$ för något $\delta \in [-\mu, \mu]$ där μ är maskintalet, följer det att

$$\hat{f}(x) = x^2(1 + \delta_1)^2(1 + \delta_2), \quad \text{för några } \delta_1, \delta_2 \in [-\mu, \mu].$$

2. Det ger relativ felgränsen

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

Repetition: Den approximativa algoritmen $\hat{f} \approx f$ är stabil för $x \neq 0$ om relativa bakåtfelet är litet.

För flyttalsalgoritmer kopplar vi "litet" till flyttalssystemets maskintal $\mu = 0.5 \cdot \beta^{1-t}$. Dvs flyttalsalgoritmen är stabil om

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

Exempel 1.17: Låt oss verifiera att $\hat{f} = f \circ (f(x)^2) \approx x^2 = f(x)$ är stabil.

1. Vi har

$$\hat{f}(x) = x^2(1 + \delta_1)^2(1 + \delta_2), \quad \text{för några } \delta_1, \delta_2 \in [-\mu, \mu].$$

2. Inversen $f^{-1}(y) = \sqrt{y}$ och $\sqrt{1 + \delta} = 1 + \delta/2 + \mathcal{O}(\delta^2)$ ger

$$f^{-1}(\hat{f}(x)) = x \left((1 + \delta_1) \sqrt{(1 + \delta_2)} \right) = x \left(1 + \delta_1 + \delta_2/2 + \mathcal{O}(\delta_1^2 + \delta_2^2) \right),$$

3. Flyttalskvadrering är stabil:

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