

1 Lösningsförslag till övningarna

1.1 Lösningar till kapitel 1

1: Absoluta felet ≤ 0.0005 (en halv enhet i sista decimalen). Relativa felet $\leq 0.0005/(24.516 - 0.0005) \approx 2 \cdot 10^{-5}$.

2: När vi härledde uppskattningen antog vi att koefficienterna utsattes för små störningar. Det är inte helt uppenbart vad som är litet, utan vi får testa lite. $p(x) = x^2 - 3x + 2$ har nollställena 1 och 2 varför uppskattningarna av konditionstalen blir:

$$\frac{|-3| + |2/1|}{2-1} = 5, \quad \frac{|-3| + |2/2|}{2-1} = 4$$

Tag $\delta_a = 3 \cdot 10^{-4}$, $\delta_b = 2 \cdot 10^{-4}$. Då är $|\delta_a|/|a| = |\delta_b|/|b| = 10^{-4}$.

Vi får då $|\delta_r|/|r| \lesssim 5 \cdot 10^{-4}$ respektive $4 \cdot 10^{-4}$.

```
r = 1.0005e+00 % beräknade rötter
    1.9992e+00
```

```
rel = 5.0040e-04 % relativa fel; stämmer bra!
      4.0020e-04
```

$p(x) = x^2 - 1.99x + 0.99$ har nollställena 0.99 och 1 så att uppskattningarna av konditionstalen blir 298 respektive 299. Med $\delta_a = 2 \cdot 10^{-4}$, $\delta_b = 10^{-4}$ blir $|\delta_r|/|r| \lesssim 0.03$.

```
r = 9.9490e-01+ 1.6553e-02i
    9.9490e-01- 1.6553e-02i
```

```
rel = 1.7321e-02 % relativt fel, jämfört med 1
```

Detta är för stora störningar för att satsen skall fungera bra. Om vi stör mindre och byter tecken på δ_a , stämmer det dock bra. Med $\delta_a = -2 \cdot 10^{-6}$, $\delta_b = 10^{-6}$ blir $|\delta_r|/|r| \lesssim 3 \cdot 10^{-4}$.

```
r = 9.9969e-01
    9.9031e-01
```

```
rel = 3.0739e-04
      -3.0848e-04
```

3: Vi vet att $\hat{x} - \delta \leq x \leq \hat{x} + \delta$. $f(x) = f(\hat{x} + x - \hat{x}) = f(\hat{x}) + (x - \hat{x})f'(\xi)$, $\xi \in (x, \hat{x})$, så $|f(x) - f(\hat{x})| \leq \delta \max_{\xi \in (\hat{x} - \delta, \hat{x} + \delta)} |f'(\xi)|$.

Om f är linjär (första fallet) så är derivatan konstant, 7 i exemplet, varför absoluta felet begränsas av 7δ . I andra fallet får vi begränsningen $2\delta(|\hat{x}| + \delta)$ eftersom derivatan, $2x$, är strängt växande.

4:

$$\sum_{k=1}^n \frac{1}{1.1R_k} \leq \frac{1}{R} \leq \sum_{k=1}^n \frac{1}{0.9R_k} \Rightarrow \frac{0.9}{\sum_{k=1}^n \frac{1}{R_k}} \leq R \leq \frac{1.1}{\sum_{k=1}^n \frac{1}{R_k}}$$

För seriekoppling gäller:

$$\sum_{k=1}^n 0.9R_k \leq R \leq \sum_{k=1}^n 1.1R_k$$

5: Frågan är alltså: hur ändras $f(x)$ när vi ändrar x lite? Taylors formel ger $f(x + \delta_x) = f(x) + \delta_x f'(x) + \dots$. Den absoluta förändringen är: $f(x + \delta_x) - f(x) \approx \delta_x f'(x)$. Om x och $f(x)$ är skilda från noll kan vi studera relativa förändringar:

$$\frac{f(x + \delta_x) - f(x)}{f(x)} \approx \frac{x f'(x) \delta_x}{f(x) x}$$

eller

$$\left| \frac{f(x + \delta_x) - f(x)}{f(x)} \right| \approx \underbrace{\left| \frac{x f'(x)}{f(x)} \right|}_{\kappa} \left| \frac{\delta_x}{x} \right|$$

där κ är en uppskattning av konditionstalet.

Då $f(x) = \cos x$ får vi

$$\kappa = \left| \frac{x f'(x)}{f(x)} \right| = \left| \frac{x \sin x}{\cos x} \right|$$

När $x = \delta > 0$ ($x = 0$ ger division med noll; dessutom är $\sin 0 = 0$, så för att få en uppskattning får man titta på nästa term i Taylorutvecklingen) kan vi gör följande approximation, för att lättare kunna analysera vad som händer:

$$\kappa \approx \delta^2$$

ty $\sin x \approx x$ och $\cos x \approx 1$ för $x \approx 0$. När $x = \pi/2 - \delta$ får vi

$$\kappa = \left| \frac{(\pi/2 - \delta) \sin(\pi/2 - \delta)}{\cos(\pi/2 - \delta)} \right| \approx \left| \frac{\pi/2 \cdot 1}{\delta} \right|$$

Detta κ växer alltså som $1/\delta$ och kan bli mycket stort. Här följer en numerisk kontroll, $x = \delta = 10^{-3}$ och $\delta_x = 10^{-6}$ ger:

```
>> x = 1e-3; delta_x = 1e-6;
>> kappa = abs(((cos(x + delta_x) - cos(x)) / cos(x)) / (delta_x / x))
kappa = 1.0005e-06
```

vilket stämmer bra med x^2 .

```
>> x = pi / 2 - 1e-3; delta_x = 1e-6;
>> kappa = abs(((cos(x + delta_x) - cos(x)) / cos(x)) / (delta_x / x))
kappa = 1.5698e+03
```

vilket stämmer bra med $\pi/(2\delta)$.

6: Derivatans av en funktion behöver inte vara begränsad även om funktionen är det. Tag t.ex. $\delta(x) = \epsilon \cos(\omega x)$. Funktionen är tydligen begränsad, men derivatan kan vara godtyckligt stor om vi väljer ett stort ω (hög frekvensen medför stor derivata). En liten störning av f kan alltså ändra derivatan godtyckligt mycket. Detta gäller inte integralen. Vi har ju:

$$\left| \int_a^b f(x) + \delta(x) dx - \int_a^b f(x) dx \right| = \left| \int_a^b \delta(x) dx \right| \leq (b - a)\epsilon$$

7: $h/s = \tan \alpha$ så att $h = s \tan \alpha$. Vi använder nu Taylors formel och får:

$$h(s + \Delta s, \alpha + \Delta \alpha) \approx h(s, \alpha) + h'_s(s, \alpha) \Delta s + h'_\alpha(s, \alpha) \Delta \alpha$$

så att (jag slutar att skriva ut (s, α))

$$\Delta h \approx h'_s \Delta s + h'_\alpha \Delta \alpha \Rightarrow \frac{\Delta h}{h} \approx \frac{h'_s \Delta s}{h} + \frac{h'_\alpha \Delta \alpha}{h} = \underbrace{\frac{h'_s s}{h}}_{\kappa_1} \cdot \frac{\Delta s}{s} + \underbrace{\frac{h'_\alpha \alpha}{h}}_{\kappa_2} \cdot \frac{\Delta \alpha}{\alpha}$$

κ_1 är ett konditionstal (förstoringsfaktor) för s och κ_2 för α .

$$\kappa_1 = \frac{s \tan \alpha}{h} = 1, \quad \kappa_2 = \frac{s \alpha}{h \cos^2 \alpha} = \frac{s \alpha}{s \tan \alpha \cos^2 \alpha} = \frac{2 \alpha}{\sin(2\alpha)}$$

Så

$$\left| \frac{\Delta h}{h} \right| \approx \underbrace{\left(1 + \frac{2 \alpha}{\sin(2\alpha)} \right)}_{\kappa} \max \left(\left| \frac{\Delta s}{s} \right|, \left| \frac{\Delta \alpha}{\alpha} \right| \right)$$

Vi ser att κ går mot oändligheten när α går mot $\pi/2$, vilket verkar rimligt. κ avtar när α går mot 0, vilket inte låter rimligt. Anledningen är att vi har antagit att s mäts med samma relativa fel även för stora s . Detta är nog ett rimligt antagande när s ligger inom rimliga gränser, $\leq 100\text{m}$ säg, men det är orimligt när s blir väldigt stort. Det verkar också kanske rimligare att anta att vi kan mäta α med samma absoluta (och inte relativa) fel oberoende av α . Antar vi en absolut felgräns för α får vi feluppskattningen:

$$\left| \frac{\Delta h}{h} \right| \approx \left| \frac{\Delta s}{s} \right| + \frac{2}{\sin(2\alpha)} |\Delta \alpha|$$

Vi ser att felet ökar när α går mot noll eller går mot $\pi/2$. Optimalt värdet på α är $\pi/4$.

8: Vi kan beräkna \mathbf{x} explicit genom $\mathbf{x} = \mathbf{A}^{-1} \mathbf{b}$ förutsatt att inversen existerar, dvs. då $|\alpha| \neq 1$. Så:

$$\mathbf{x} = \frac{1}{1 - \alpha^2} \begin{bmatrix} 1 & -\alpha \\ -\alpha & 1 \end{bmatrix} \begin{bmatrix} 1 \\ 0 \end{bmatrix} = \frac{1}{1 - \alpha^2} \begin{bmatrix} 1 \\ -\alpha \end{bmatrix}$$

Om $|\alpha| \approx 1$ kommer små variationer i α att ge upphov till stora förändringar i \mathbf{x} . Låt, t.ex. $\alpha = 1 - \epsilon$, då blir \mathbf{x}

$$\mathbf{x} = \frac{1}{1 - (1 - \epsilon)^2} \begin{bmatrix} 1 \\ -(1 - \epsilon) \end{bmatrix} \approx \frac{1}{2\epsilon} \begin{bmatrix} 1 \\ -1 \end{bmatrix}$$

Små variationer i ϵ ger upphov till stora variationer i \mathbf{x} . Beräkningen av \mathbf{x} är således illakonditionerad då $|\alpha| \approx 1$.

En alternativ härledning är att beräkna derivatan av \mathbf{x} som funktion av α . Vi utgår från $\mathbf{A}(\alpha)\mathbf{x}(\alpha) = \mathbf{b}$, där jag skrivit ut (α) för att betona beroendet av denna parameter (\mathbf{b} beror inte av α utan är en konstant vektor). Om prim får beteckna elementvis derivering med avseende på α kan man visa att följande operationer är tillåtna. $[\mathbf{A}(\alpha)\mathbf{x}(\alpha)]' = \mathbf{b}'$ ger

$$\mathbf{A}'(\alpha)\mathbf{x}(\alpha) + \mathbf{A}(\alpha)\mathbf{x}'(\alpha) = \mathbf{0}$$

så att

$$\mathbf{x}'(\alpha) = -\mathbf{A}^{-1}(\alpha)\mathbf{A}'(\alpha)\mathbf{x}(\alpha) = -\mathbf{A}^{-1}(\alpha)\mathbf{A}'(\alpha)\mathbf{A}^{-1}(\alpha)\mathbf{b}$$

Derivatan blir stor när $\mathbf{A}^{-1}(\alpha)$ innehåller stora element, dvs. när $|\alpha| \approx 1$. Det går givetvis att derivera $x_1(\alpha)$ och $x_2(\alpha)$ på vanligt sätt (vi har ju uttryck för $x_1(\alpha)$ och $x_2(\alpha)$).

9: Denna övning är snarlik den föregående. Vi kan återigen derivera, men nu beror \mathbf{x} både på α och β så vi får använda partiella derivator.

$$\mathbf{x}(\alpha, \beta) = \frac{1}{\alpha^2 - \beta^2} \begin{bmatrix} \alpha \\ -\beta \end{bmatrix}$$

som är känslig för störningar då $|\alpha| \approx |\beta|$.

10: Lösningen är $y(t) = e^{ct}y_0$. Låt $z(t)$ vara lösningen till det störda problemet: $z'(t) = cz(t), z(0) = y_0 + \delta$. Tydligt är $z(t) = e^{ct}(y_0 + \delta)$ så att $z(t) - y(t) = e^{ct}\delta$. Om $c > 0$ kommer $|z(t) - y(t)|$ att växa; större c ger snabbare tillväxt. Om $c < 0$ så kommer skillnaden att avta och om $c = 0$ så är den konstant.

11: Denna uppgift kräver kunskap om hur man löser linjära differensekvationer (jag tar inte upp teorin här). Karakteristiska polynomet är $r^2 = r + 1$ så att rötterna är $r_1 = (1 + \sqrt{5})/2 \approx 1.62$ och $r_2 = (1 - \sqrt{5})/2 \approx -0.62$. Den allmänna lösningen har formen $a_k = c_1 r_1^k + c_2 r_2^k$. Vi bestämmer c_1 och c_2 med begynnelsevärdena, a_0 och a_1 , och får slutligen:

$$a_k = \frac{r_2 a_0 - a_1}{r_2 - r_1} r_1^k + \frac{-r_1 a_0 + a_1}{r_2 - r_1} r_2^k$$

Låt nu b_k vara en störd talföljd definierad genom: $b_{k+2} = b_{k+1} + b_k, b_0 = a_0 + \delta$ och $b_1 = a_1 + \epsilon$. Eftersom a_0 och a_1 ingår linjärt i a_k , så ges skillnaden, $b_k - a_k$, av:

$$b_k - a_k = \frac{1}{r_2 - r_1} [(r_2 \delta - \epsilon) r_1^k + (-r_1 \delta + \epsilon) r_2^k]$$

Den relativa förändringen ges av:

$$\frac{b_k - a_k}{a_k} = \frac{\frac{1}{r_2 - r_1} [(r_2 \delta - \epsilon) r_1^k + (-r_1 \delta + \epsilon) r_2^k]}{\frac{r_2 a_0 - a_1}{r_2 - r_1} r_1^k + \frac{-r_1 a_0 + a_1}{r_2 - r_1} r_2^k}$$

Om $r_2 a_0 - a_1 \neq 0$ så kommer $(b_k - a_k)/a_k$ att konvergera mot $(r_2 \delta - \epsilon)/(r_2 a_0 - a_1)$ då $k \rightarrow \infty$ (eftersom $r_1 > |r_2|$). Det relativa felet stannar alltså på en viss nivå. Om däremot $r_2 a_0 - a_1 = 0$ så avtar $|a_k|$ eftersom $|r_2| < 1$. Är då koefficienten, framför r_1 i uttrycket för b_k , skild från noll så kommer felet att växa. Dvs. om $r_2(a_0 + \delta) - a_1 - \epsilon \neq 0$ så kommer $|b_k| \rightarrow \infty$ men $|a_k| \rightarrow 0$.

12: Låt $p(x) = a_n x^n + \dots + a_1 x + a_0$ med distinkta nollställen r_1, \dots, r_n . Vi vill veta hur känslig ett nollställe, r_k , är för små ändringar i koefficienterna, dvs. vi vill studera $\partial r_k(a_0, a_1, \dots, a_n)/\partial a_j, j = 0, 1, \dots, n, k = 1, \dots, n$. För att få enklare formler låter vi r beteckna ett av nollställena (vi får samma härledning oberoende av vilket nollställe vi arbetar med). $\partial r(a_0, a_1, \dots, a_n)/\partial a_j$ kommer jag att beteckna med r' (vi måste då komma ihåg att vi deriverar med avseende på just a_j). Observera dock att olika nollställen kan vara olika känsliga och att det spelar stor roll vilken koefficient vi stör.

Låt oss först se på specialfallet $n = 3$. Eftersom r är ett nollställe, $p(r) = 0$, så gäller:

$$a_3 r^3 + a_2 r^2 + a_1 r + a_0 = 0$$

Vi deriverar nu detta uttryck med avseende på a_2 och får (med våra beteckningar):

$$3a_3 r^2 r' + r^2 + 2a_2 r r' + a_1 r' = 0$$

Om vi låter $p'(x)$ beteckna derivatan av $p(x)$ med avseende på x , dvs. $p'(x) = 3a_3 x^2 + 2a_2 x + a_1$ så ser vi att

$$3a_3 r^2 r' + r^2 + 2a_2 r r' + a_1 r' = r' p'(r) + r^2$$

Uppgift: övertyga Dig om att när vi deriverar $p(r) = 0$ med avseende på a_j för allmänt n så får vi sambandet: $r' p'(r) + r^j = 0$. Detta ger omedelbart följande uttryck för derivatan, $r' = -r^j/p'(r)$. $p'(r)$ är lite svårtolkat, så vi gör följande omskrivning (åter specialfallet $n = 3$):

$$p(x) = a_3(x - r_1)(x - r_2)(x - r_3) \Rightarrow p'(x) = a_3 [(x - r_2)(x - r_3) + (x - r_1)(x - r_3) + (x - r_2)(x - r_3)]$$

varför (r är ju en av r_1, r_2 eller r_3)

$$p'(r) = a_3 \prod_{s=1, \dots, 3, r_s \neq r} (r - r_s)$$

I det allmänna fallet gäller väsentligen samma formel, dvs.

$$p'(r) = a_n \prod_{s=1, \dots, n, r_s \neq r} (r - r_s)$$

Vi vill slutligen få en relativ feluppskattning och sammanställer ovanstående. Låt ändringarna i r_k och a_j betecknas med δ_{r_k} respektive δ_{a_j} . Vi utnyttjar (som vanligt) att $r' \approx \delta_{r_k} / \delta_{a_j}$ och får (givet att $r_k \neq 0$):

$$\left| \frac{\delta_{r_k}}{r_k} \right| \approx \left| \frac{a_j r_k^{j-1}}{a_n \prod_{s \neq k} (r_k - r_s)} \right| \left| \frac{\delta_{a_j}}{a_j} \right|$$

κ

När $n = 2$ känner vi igen resultaten från föreläsningen. Produkten består då bara av gapet, $|r_1 - r_2|$. När $n > 2$ spelar gapet också en viktig roll. Låt oss se på två exempel: låt nollställena vara $1, 1 \pm \epsilon, 1 \pm 2\epsilon, \dots, 1 \pm p\epsilon$ (så att $n = 2p + 1$). Tag $r = 1$, produkten kommer då att bli $(\epsilon^p p!)^2$. Genom att hålla p fixt och låta $\epsilon \rightarrow 0$ kan vi göra gapen godtyckligt små. $\kappa \rightarrow \infty$ då $\epsilon \rightarrow 0$. Ett, eller flera, små gap leder till ett stort konditionstal. Om r har långt till alla övriga nollställen, stora gap, så blir κ normalt inte så stort. Låt nollställena vara $1, \lambda + 1 + \epsilon, \lambda + 1 + 2\epsilon, \dots, \lambda + 1 + (n - 1)\epsilon$, där λ är mycket större än ett och $\epsilon > 0$. Produkten blir då $|(\lambda + \epsilon)(\lambda + 2\epsilon) \cdots (\lambda + (n - 1)\epsilon)|$. Produkten står i nämnaren, så ett genom produkten kan begränsas av $1/\lambda^{n-1}$. Detta blir ett litet tal och r är ett välkonditionerat nollställe.

Ibland bjuds man dock på överraskningar. Antag att vi har nollställena $r_k = k, k = 1, \dots, n$ med $n = 20$. Gapen mellan angränsande nollställen är då ett, vilket verkar vara betryggande, alla nollställen borde vara välkonditionerade. Låt oss nu studera hur känsligt nollstället $r_n = n$ är för störningar i $a_n = 1$. Vår uppskattning ger:

$$\left| \frac{\delta_{r_n}}{r_n} \right| \approx \left| \frac{a_n r_n^{n-1}}{a_n \prod_{s \neq n} (r_n - r_s)} \right| \left| \frac{\delta_{a_n}}{a_n} \right| = \frac{n^{n-1}}{(n-1)!} \left| \frac{\delta_{a_n}}{a_n} \right| \approx 4.3 \cdot 10^7 \left| \frac{\delta_{a_n}}{a_n} \right|$$

Några av de andra nollställena är ännu känsligare.

13: Får Du göra själv, se dock diskussionen i slutet av föregående övning.

14: Vi kan klara av alla tre fallen på en gång genom att låta p , nedan, anta värdena $-10, 0$ respektive 10 . Det exakta värdet blir: $6.278 \cdot 10^p + 4.039 \cdot 10^p = 1.0317 \cdot 10^{p+1}$ och det lagras, korrekt avrundat och i normaliserad form, som $1.032 \cdot 10^{p+1}$. Det absoluta felet blir: $1.032 \cdot 10^{p+1} - 1.0317 \cdot 10^{p+1} = 3 \cdot 10^{p-3}$. Det relativa felet blir $3 \cdot 10^{p-3} / 1.0317 \cdot 10^{p+1} \approx 3 \cdot 10^{-4}$. Notera att de tre absoluta felen blir: $3 \cdot 10^{-13}, 3 \cdot 10^{-3}$ respektive $3 \cdot 10^7$. Det relativa felet blir, i alla tre fallen, $\approx 3 \cdot 10^{-4}$.

15: Vi vet att $fl(a + b) = (a + b)(1 + \epsilon)$, $|\epsilon| \leq \epsilon_{mach}$. Alltså gäller att $fl(a + b) = \tilde{a} + \tilde{b}$ där $\tilde{a} = a(1 + \epsilon)$, $|\tilde{a} - a| \leq |a|\epsilon_{mach}$, analogt för b . $fl(a + b)$ är således den exakta summan av två något störda tal.

16: Eftersom matrisaddition utförs elementvis kan vi tillämpa resultatet från föregående övning på varje summa. Således gäller att $fl(\mathbf{A} + \mathbf{B}) = \tilde{\mathbf{A}} + \tilde{\mathbf{B}}$ där $\tilde{\mathbf{A}}$ ligger nära \mathbf{A} och $\tilde{\mathbf{B}}$ ligger nära \mathbf{B} .

17: Låt oss betrakta specialfallet då $n = 4$. För att få mindre oläsliga formler inför vi $\sigma_k = 1 + \delta_k$, $\pi_k = 1 + \epsilon_k$ (σ för summa och π för produkt) där alla $|\epsilon_k|$ och $|\delta_k|$ är mindre än ϵ_{mach} . $fl(x_1 y_1) = x_1 y_1 \pi_1$.

$$fl(x_1 y_1 + x_2 y_2) = [x_1 y_1 \pi_1 + x_2 y_2 \pi_2] \sigma_2, \text{ vi använder inte } \sigma_1$$

$$fl(x_1 y_1 + x_2 y_2 + x_3 y_3) = ([x_1 y_1 \pi_1 + x_2 y_2 \pi_2] \sigma_2 + x_3 y_3 \pi_3) \sigma_3.$$

$$fl(x_1 y_1 + x_2 y_2 + x_3 y_3 + x_4 y_4) = ([([x_1 y_1 \pi_1 + x_2 y_2 \pi_2] \sigma_2 + x_3 y_3 \pi_3) \sigma_3 + x_4 y_4 \pi_4] \sigma_4.$$

Allmänt gäller tydligen, om vi inför $\sigma_{j:k} = \sigma_j \sigma_{j+1} \cdots \sigma_k$, att:

$$fl(x_1 y_1 + x_2 y_2 + \dots + x_n y_n) = x_1 y_1 \pi_1 \sigma_{2:n} + x_2 y_2 \pi_2 \sigma_{2:n} + x_3 y_3 \pi_3 \sigma_{3:n} + \dots + x_k y_k \pi_k \sigma_{k:n} + \dots + x_n y_n \pi_n \sigma_n$$

Med våra antaganden om flyttalsaritmetik kan vi skriva detta

$$fl\left(\sum_{k=1}^n x_k y_k\right) = x_1 y_1 (1 + n\epsilon'_1) + \sum_{k=2}^n x_k y_k (1 + (n - k + 2)\epsilon'_k)$$

där alla $|\epsilon'_k| \leq \epsilon_{mach}$. Om vi t.ex. sätter $\tilde{x}_k = x_k \sqrt{1 + (n - k + 2)\epsilon'_k}$ och $\tilde{y}_k = y_k \sqrt{1 + (n - k + 2)\epsilon'_k}$ (analogt för x_1 och y_1) så gäller tydligen att:

$$fl\left(\sum_{k=1}^n x_k y_k\right) = \sum_{k=1}^n \tilde{x}_k \tilde{y}_k$$

Om då $n\epsilon_{mach}$ är **tillräckligt litet** så är den beräknade skalärprodukten en exakt skalärprodukt av näraliggande värden och algoritmen är stabil.

Ovanstående analys är onödigt pessimistisk. Det visar sig nämligen att många FPUer (Floating Point Unit) kan beräkna `sum = sum + x(k) * y(k)` med endast ett avrundningsfel (en s.k. FMA, floating multiply add; även kallad MADD). Det kan också vara så att FPU:n internt har flera bitar (än 64) i flyttalsregistren. Här följer ett experiment. Jag har skrivit ett innerproduktsprogram, i enkel precision, i Fortran90. Vektorerna innehåller 100000 slumpstal valda så att innerprodukten skall bli noll. Koden har kompilerats med olika optimeringsoptioner, allt på en IBM-dator. Först tvingade jag kompilatorn att generera kod som följer IEEE. Det står i manualbladet för kompilatorn att:

```
-qfloat=<suboption1>[:<suboption2>[:...:<suboptionN>]]
  Specifies various floating-point suboptions. Suboptions include:

  hssngl - Rounds single-precision expressions only when the results are
          stored into REAL(4) memory locations.

  rndsngl - Ensures strict adherence to IEEE standard. That is, all operations on
          single-precision values produce results that remain in single precision.
```

Därefter kompilerade jag utan optioner och i det sista fallet slog jag på aggressiv optimering. Jag fick följande resultat i de tre fallen:

```
Innerprodukten = 3.85E-02
Innerprodukten = 1.89E-04
Innerprodukten = -1.07E-14
```

I tredje fallet räknas allt i dubbel precision (minst).

18: Största talet i båda fallen är $9.999 \cdot 10^{10}$. Minsta normaliserade talet är $1.000 \cdot 10^{-10}$ och det minsta denormaliserade talet är $0.001 \cdot 10^{-10}$. Denormaliserade flyttal används bara (i IEEE-standarden) kring nollan och inte kring största/minsta tal. Det är därför det största talet i b)-uppgiften är samma som i a)-uppgiften. De största talet är i båda deluppgifterna normaliserat.

19: $100^{20} + 100^{15}$ pga utskiftning, så $1.000000000100000e+40$.

20: a) 2365.27 normaliserat blir $2.36527 \cdot 10^3$ med $t = 6$ och $U = 3$.
 $0.0000512 = 5.12 \cdot 10^{-5}$ så $L = -5$.
 b) Med $t = 6$ får vi $0.0000512 = 0.00512 \cdot 10^{-2}$ så $L = -2$.

21: Två logaritmbereäkningar torde ta mer tid än en logaritm och en division. Problem med cancellation då $x \approx y$. Sätt $x = (1 + \delta)y$, där $|\delta|$ är litet och antag att $fl(\log z) = (1 + \epsilon_1) \log z$ med $|\epsilon_1| \leq \epsilon_{mach}$ (dvs. logaritmfunktionen returnerar ett korrekt avrundat värde). Via Taylorutveckling kan vi skaffa oss en uppfattning om det exakta värdet:

$$\log x - \log y = \log(1 + \delta)y - \log y = \delta - \delta^2/2 + \dots$$

Nu till felen:

$$fl(\log x - \log y) = ((1 + \epsilon_1) \log x - (1 + \epsilon_2) \log y)(1 + \epsilon_3) =$$

$$\underbrace{\log x - \log y}_{\text{exakt}} + \underbrace{\epsilon_3(\log x - \log y)}_{\approx \delta \epsilon_3} + \epsilon_1 \log x - \epsilon_2 \log y + \underbrace{\epsilon_3(\epsilon_1 \log x - \epsilon_2 \log y)}_{\approx \epsilon_{mach}^2}$$

Så

$$|fl(\log x - \log y) - (\log x - \log y)| \lesssim (|\delta| + 2|\log x|)\epsilon_{mach}$$

$|\log x|$ kan bli stor (men inte väldigt stor).


Motsvarande för $\log x/y$:

$$fl(\log x/y) = (1 + \epsilon_2) \log [(x/y)(1 + \epsilon_1)] = (1 + \epsilon_2)(\log x/y + \log(1 + \epsilon_1)) = \log x/y + \log(1 + \epsilon_1) + \epsilon_2 \log x/y + \epsilon_2 \log(1 + \epsilon_1)$$

så

$$|fl(\log x/y) - (\log x/y)| \lesssim (1 + |\delta| + \epsilon_{mach})\epsilon_{mach}$$

(ty $\log(1 + \epsilon_1) = \epsilon_1 - \epsilon_1^2/2 + \dots \approx \epsilon_1$). Metod två ger, med andra ord, bättre resultat utom då $x \approx 1$ (när $2|\log x| < 1$). Detta faktum illustreras i nedanstående plot (gjort i Fortran och för $\delta = 10^{-5}$).



22: Kancellation om $x \approx y$.

$$fl(x^2 - y^2) = (x^2(1 + \epsilon_1) - y^2(1 + \epsilon_2))(1 + \epsilon_3) = x^2(1 + \epsilon_1 + \epsilon_3 + \epsilon_1\epsilon_3) - y^2(1 + \epsilon_2 + \epsilon_3 + \epsilon_2\epsilon_3)$$

Så

$$|fl(x^2 - y^2) - (x^2 - y^2)| \leq (|x^2 + y^2|(1 + \epsilon_{mach}) + |x^2 - y^2|)\epsilon_{mach}$$

vilket ger ett stort relativt fel om $x \approx y$, ty

$$\frac{|fl(x^2 - y^2) - (x^2 - y^2)|}{|x^2 - y^2|} \leq \left[\frac{x^2 + y^2}{|x^2 - y^2|} (1 + \epsilon_{mach}) + 1 \right] \epsilon_{mach}$$

Alternativ formel:

$$fl((x - y)(x + y)) = (x - y)(1 + \epsilon_1)(x + y)(1 + \epsilon_2)(1 + \epsilon_3) = (x^2 - y^2)(1 + \epsilon_1)(1 + \epsilon_2)(1 + \epsilon_3)$$

så

$$|fl((x - y)(x + y)) - (x^2 - y^2)| \lesssim 3\epsilon_{mach}|x^2 - y^2|$$

vilket alltid ger ett litet relativt fel, ty

$$\frac{|fl((x - y)(x + y)) - (x^2 - y^2)|}{|x^2 - y^2|} \lesssim 3\epsilon_{mach}$$

23: Låt oss kalla den stora (negativa) roten R och den lilla, nära noll, r . Standardformeln och Taylorutveckling ger:

$$R = -\frac{a}{2} - \sqrt{\frac{a^2}{4} - b} = -\frac{a}{2} \left[1 + \sqrt{1 - \frac{4b}{a^2}} \right] = -\frac{a}{2} \left[2 - \frac{2b}{a^2} - \frac{2b^2}{a^4} - \dots \right] \approx -a$$

$$r = -\frac{a}{2} + \sqrt{\frac{a^2}{4} - b} = \frac{a}{2} \left[-1 + \sqrt{1 - \frac{4b}{a^2}} \right] = \frac{a}{2} \left[-\frac{2b}{a^2} - \frac{2b^2}{a^4} - \dots \right] \approx -\frac{b}{a}$$

Här följer ett litet Matlabexempel:

```
>> format long e
>> a = 1e4;    b = 1;
>> roots([1 a b])
ans =
    -9.999999899999999e+03
    -1.000000010000000e-04
```

Vi kan uppskatta konditionstalen enligt:

$$\kappa_R \approx \frac{|a| + |b/R|}{|R - r|} \approx \frac{a + b/a}{a} \approx 1$$

och

$$\kappa_r \approx \frac{|a| + |b/r|}{|R - r|} \approx \frac{a + b/(b/a)}{a} \approx 2$$

När vi beräknar $r = -\frac{a}{2} + \sqrt{\frac{a^2}{4} - b}$ kommer att få utskiftning av b . I det mest extrema fallet kommer inte b alls med och approximationen blir noll. I vårt exempel får vi approximationen $-1.000000011117663e-04$. Hur skall vi beräkna r ? Ett sätt är att använda utvecklingen ovan:

$$r = -\frac{b}{a} - \frac{b^2}{a^3} - 2\frac{b^3}{a^5} \dots$$

Hur många termer skall vi ta med? Det är enklare att analysera om vi skriver om utvecklingen som:

$$r = -\frac{b}{a} \left[1 + \frac{b}{a^2} + 2\frac{b^2}{a^4} \dots \right]$$

Det är ingen vits att ta med termer, inom hakparenteserna, som är mindre än ϵ_{mach} eftersom de skiftas ut. I exemplet ovan får vi approximationen:

```
>> r = -(b / a) * (1 + b / a^2)
r = -1.000000010000000e-04
```


Den exakta roten är $-0.0001000000010000000200000005000000\dots$

Ett standardtrick är att förlänga med konjugatet, sålunda:

$$r = \frac{\left[-\frac{a}{2} + \sqrt{\left(\frac{a}{2}\right)^2 - b}\right] \left[-\frac{a}{2} - \sqrt{\left(\frac{a}{2}\right)^2 - b}\right]}{-\frac{a}{2} - \sqrt{\left(\frac{a}{2}\right)^2 - b}} = \frac{b}{-\frac{a}{2} - \sqrt{\left(\frac{a}{2}\right)^2 - b}}$$

Vi får utskiftning av b i nämnaren, men b kommer med i täljaren. Ytterligare ett sätt, är att göra en transformation så att r blir en dominant rot i det transformerade problemet. Sätt $y = 1/x$ (så att $r \rightarrow 1/r$). Ekvationen $x^2 + ax + b = 0$ övergår då till $y^2 + (a/b)y + 1/b = 0$. Om vi använder standardformeln får vi för den sökta roten:

$$\frac{1}{r} = -\frac{a}{2b} - \sqrt{\frac{a^2}{4b^2} - \frac{1}{b}}$$

24: Problemet är att normen kan vara representerbar men att delresultat ger under- eller overflow. I dubbel precision är det minsta normaliserade positiva talet $\approx 2.2 \cdot 10^{-308}$ och det största $\approx 1.8 \cdot 10^{308}$. Den naiva implementationen `nrm = sqrt(sum(x.^2))` fungerar inte bra, t.ex.:

```
>> x = [1e300 2e300]; sqrt(sum(x.^2))
ans =
    Inf
>> norm(x)      % Matlabs normkommando
ans =
    2.2361e+300

>> x = [1e-300 2e-300]; sqrt(sum(x.^2)), norm(x)
ans =
    0
ans =
    2.2361e-300
```

Så här ser, en förenklad och förkortad version av, Fortran77-rutinen `dnrm2` från BLAS ut (jag har skrivit rutinen i ett pseudo-språk). BLAS = Basic Linear Algebra Subprograms, en uppsättning standardrutiner för enkla vektor- och matrisoperationer. (I ett riktigt program räknar man inte om $|x_k|$ utan man lagrar absolutbeloppet i en variabel.)

```
if n == 1 then
    norm = |x1|
else
    σ = 0
    s = 1
    for k = 1 to n do
        if xk ≠ 0 then
            if σ < |xk| then
                s = 1 + s(σ/xk)2
                σ = |xk|
            else
                s = s + (xk/σ)2
            end if
        end if
    end for
end for
```



```
1.0000500016671410e+00  5.0e-05  5.0e-05
1.0000050000069649e+00  5.0e-06  5.0e-06
1.0000004999621837e+00  5.0e-07  5.0e-07
1.0000000494336803e+00  4.9e-08  5.2e-08
9.9999999392252903e-01 -6.1e-09  2.7e-08
1.0000000827403710e+00  8.3e-08  2.2e-07
1.0000000827403710e+00  8.3e-08  2.2e-06
1.0000000827403710e+00  8.3e-08  2.2e-05
1.0000889005823410e+00  8.9e-05  2.2e-04
9.9920072216264089e-01 -8.0e-04  2.2e-03
9.9920072216264089e-01 -8.0e-04  2.2e-02
1.1102230246251565e+00  1.1e-01  2.2e-01
0.0000000000000000e+00 -1.0e+00  2.2e+00
```

Om man vill beräkna $e^x - 1$ på ett bra sätt kan man utnyttja C-rutinen `expm1` t.ex. Här är ett förkortat utdrag ur manualsidan:

Mathematical Library

`expm1(3M)`

NAME: `expm1` - computes exponential functions

SYNOPSIS

```
cc [ flag ... ] file ... -lm [ library ... ]
#include <math.h>
double expm1(double x);
```

DESCRIPTION: The `expm1()` function computes $e^{**x}-1.0$.

USAGE: The value of `expm1(x)` may be more accurate than `exp(x)-1.0` for small values of x . The `expm1()` and `log1p(3M)` functions are useful for financial calculations of $((1+x)**n)-1/x$ namely:

```
expm1(n * log1p(x))/x
```

when x is very small (for example, when performing calculations with a small daily interest rate). These functions also simplify writing accurate inverse hyperbolic functions.

26: Diskretiseringsfelet erhålles via Taylorutveckling:

$$\frac{f(x+h) - f(x)}{h} = \frac{f(x) + hf'(x) + \frac{h^2 f''(x)}{2} + \dots - f(x)}{h} = f'(x) + \frac{h}{2} f''(x) + \dots$$

När vi uppskattar avrundningsfelet antar vi (för att förenkla) att $x+h$ beräknas exakt (se dock nedan). Dessutom antar vi att $fl(f(x)) = f(x)(1 + \epsilon_k)$, $|\epsilon_k| \leq \epsilon_{mach}$ (vilket kan vara orealistiskt om f är en komplicerad funktion).

$$\begin{aligned} fl \left[\frac{f(x+h) - f(x)}{h} \right] &= \frac{f(x+h)(1 + \epsilon_1) - f(x)(1 + \epsilon_2)}{h} (1 + \epsilon_3)(1 + \epsilon_4) = \\ &= \frac{f(x+h)(1 + \epsilon_1)(1 + \epsilon_3)(1 + \epsilon_4) - f(x)(1 + \epsilon_2)(1 + \epsilon_3)(1 + \epsilon_4)}{h} = \\ &= \frac{f(x+h)(1 + 3\epsilon_5) - f(x)(1 + 3\epsilon_6)}{h} = \frac{f(x+h) - f(x)}{h} + 3 \frac{f(x+h)\epsilon_5 - f(x)\epsilon_6}{h} \end{aligned}$$

Antar vi dessutom att $f(x) \approx f(x+h)$ får vi uppskattningen:

$$\left| fl \left[\frac{f(x+h) - f(x)}{h} \right] - \frac{f(x+h) - f(x)}{h} \right| \lesssim \left| \frac{f(x)}{h} \right| 6\epsilon_{mach}$$

Det totala felet får vi om vi adderar de två feLEN:

$$\begin{aligned} \left| fl \left[\frac{f(x+h) - f(x)}{h} \right] - f'(x) \right| &= \left| fl \left[\frac{f(x+h) - f(x)}{h} \right] - \frac{f(x+h) - f(x)}{h} + \left[\frac{f(x+h) - f(x)}{h} - f'(x) \right] \right| \leq \\ &\left| fl \left[\frac{f(x+h) - f(x)}{h} \right] - \frac{f(x+h) - f(x)}{h} \right| + \left| \frac{f(x+h) - f(x)}{h} - f'(x) \right| \lesssim \left| \frac{f(x)}{h} \right| 6\epsilon_{mach} + \left| \frac{h}{2} f''(x) \right| \end{aligned}$$


Tar vi $|h|$ för litet dominerar avrundningsfelet och om vi tar ett för stort $|h|$ dominerar diskretiseringsfelet. Genom att derivera begränsningen av felet med avseende på h får vi det optimala värdet:

$$h_{opt} = \sqrt{12\epsilon_{mach} \left| \frac{f(x)}{f''(x)} \right|}$$

Hur stort blir det totala felet, e_T , med h_{opt} ?

$$e_T = \left| \frac{f(x)}{h_{opt}} \right| 6\epsilon_{mach} + \left| \frac{h_{opt}}{2} f''(x) \right| = \dots = \sqrt{12 |f(x)f''(x)|} \sqrt{\epsilon_{mach}}$$

Här följer ett exempel ($f(x) = \sin x, x = 1, h_{opt} \approx 5 \cdot 10^{-8}$ vilket stämmer mycket bra).



Vi hade antagit att $x+h$ beräknas exakt. Om detta inte är fallet är det risk att vår feluppskattning stämmer dåligt. Man kan lätt skapa ett problem där vi får utskiftning i $x+h$. Rimligtvis borde h_{opt} skalas med x . Det borde göra stor skillnad om $x = 10^{-10}$, 1 resp. 10^{10} . Här följer en rimligare härledning där vi tar hänsyn till beräkningsfelet i $x+h$. För att kunna återanvända det vi redan gjort inför vi ϵ_5 och antar att $fl(x+h) = (x+h)(1+\epsilon_5)$. Taylorutveckling ger $f((x+h)(1+\epsilon_5)) = f((x+h) + \epsilon_5(x+h)) \approx f(x+h) + \epsilon_5(x+h)f'(x+h) \approx f(x+h) + \epsilon_5(x+h)f'(x)$. Vi kan även approximera $x+h \approx x$ eftersom h -termen ändå försvinner när vi deriverar. Vi får

$$fl \left[\frac{f(x+h) - f(x)}{h} \right] = \frac{(f(x) + \epsilon_5 x f'(x))(1 + \epsilon_1) - f(x)(1 + \epsilon_2)}{h} (1 + \epsilon_3)(1 + \epsilon_4)$$

$$\left| fl \left[\frac{f(x+h) - f(x)}{h} \right] - \frac{f(x+h) - f(x)}{h} \right| \lesssim \left| \frac{f(x)}{h} \right| 6\epsilon_{mach} + \left| \frac{xf'(x)}{h} \right| \epsilon_{mach}$$

Detta ger följande uppskattning av h_{opt}

$$h_{opt} = \sqrt{2\epsilon_{mach} \frac{6|f(x)| + |xf'(x)|}{|f''(x)|}}$$

Denna uppskattning verkar rimligare eftersom h_{opt} skalas med x . I vårt exempel ger detta dock en liten förändring av h_{opt} . Det totala felet blir


$$e_T = \sqrt{(6|f(x)| + |xf'(x)|) |f''(x)|/2} \sqrt{\epsilon_{mach}}$$

b) Trunkeringsfelet blir $h^2 f'''(x)/6 + \dots$ och avrundningsfelet som i a-uppgiften (om vi antar att multiplikation med 2 görs exakt). Så det totala felet och h_{opt} blir ungefär

$$\frac{h^2}{6} |f'''(x)| + \left| \frac{f(x)}{h} \right| 6\epsilon_{mach}, \quad h_{opt} = \left[18\epsilon_{mach} \left| \frac{f(x)}{f'''(x)} \right| \right]^{1/3}$$

Här följer ett exempel ($f(x) = \sin x, x = 1, h_{opt} \approx 1.4 \cdot 10^{-5}$ vilket stämmer mycket bra). Totala felet bör mindre i detta fall:

$$e_T = \frac{h_{opt}^2}{6} |f'''(x)| + \left| \frac{f(x)}{h_{opt}} \right| 6\epsilon_{mach} \approx 2.7 |f^2(x) f'''(x)|^{1/3} \epsilon_{mach}^{2/3}$$



Vi kan även i denna uppgift ta hänsyn till felet i beräkningen av $x + h$.

27: Den harmoniska serien är divergent, men om vi räknar med ändligt många siffror får vi utskiftning och för något N kommer det att gälla att:

$$fl \left[\sum_{n=1}^N \frac{1}{n} \right] = fl \left[\sum_{n=1}^{N+1} \frac{1}{n} \right]$$

Låt oss **uppskatta** N . Vi vet att

$$\sum_{n=1}^N \frac{1}{n} \approx \log N + \gamma$$

där $\gamma = 0.57721566490153286060651 \dots$ (Eulers konstant) Vi får utskiftning då

$$(1/N)/(\log N + \gamma) \approx \epsilon_{mach}$$

Dvs. i enkel precision då $N \approx 2.1 \cdot 10^6$ och i dubbel då $N \approx 1.2 \cdot 10^{14}$. Division är ett mycket långsam operation (22 klockcykler på en Sun), så att testa detta tar enormt mycket tid i dubbel precision (tusentals timmar) men i enkel är det möjligt (tar mindre än en sekund). Här följer ett Fortran90-program:

```
program harmonisk
  real    :: summa, gammal_summa = 0.0
  integer :: n = 1

  do
    summa = gammal_summa + 1.0 / n
    if ( gammal_summa == summa ) exit
    gammal_summa = summa
    n = n + 1
  end do

  print*, n, summa
end program harmonisk
```

```
Körning:
% a.out
2097152 15.4036827
```

Det stämmer rätt bra med andra ord.

28: Den andra formeln kräver att vi går igenom x -vektorn en gång, men den första formeln kräver två pass, vilken ur prestandasynpunkt är en nackdel. Ur felsynpunkt är den första formeln dock bättre, eftersom subtraktionen av medelvärdet har en utjämnande verkan. Vi kan få stor skillnad mellan värdena genom att sett till att det blir under- eller overflow i $\sum_{i=1}^n x_i^2$ -beräkningen. T.ex.

```
>> x = [2e154 2e153];
>> n = length(x);
>> mx = sum(x) / n;
>> [sum((x - mx).^2) sum(x.^2) - n * mx^2]
ans =
    1.6200e+308          NaN

>> x = [0.1 ones(1, 50)] * 1e-161; % ger
ans =
    7.9051e-323 -9.8813e-323    % OBS: -9.8813e-323 < 0
```