


Iskanje ekstremov funkcij in prilagajanje funkcij meritvam

9. 3. 2022



4. naloga: Iskanje funkcijskih ekstremov in prilagajanje funkcij meritvam

Tako kot pri vseh numeričnih metodah kompleksnost metode iskanja ekstremov narašča z dimenzijo prostora v katerem je funkcija definirana. Najbolj robustne in zanesljive metode so tako razvite za iskanje ekstremov v eni dimenziji. V splošnem pa ne smemo pozabiti na dejstvo, da *ne obstaja* metoda, ki bi avtomatsko našla *globalni* ekstrem (minimum ali maksimum), vsaka metoda se bo slej ko prej ustavila v nekem lokalnem ekstremu. Ali je le-ta globalen in/ali edini pa je potrebno proučiti naknadno (s poskušanjem ipd.).

Iskanje minimumov ali maksimumov funkcije lahko poenotimo z metodami iskanja minimumov, saj za maksimume lahko vedno definiramo $f \rightarrow -f$.

V eni dimenziji je najpreprostejša (in najrobustnejša) metoda *zlatega reza*. Najprej poiščemo tri točke ($A < b < C$), za katere velja $f(b) < f(A)$ in $f(b) < f(C)$; točka b je torej groba ocena minimuma. Novo točko B nato najdemo s uporabo razmerja zlatega reza, tukaj podano kot:

$$\frac{1}{\varphi} = \frac{\sqrt{5} - 1}{2} = 0.61803.$$

Koordinata nove točke B je podana z:

$$B = A + h \cdot \frac{1}{\varphi}, \quad h = |C - A|.$$

Dodatno poskusno točko D pa nato dodamo s faktorjem:

$$\frac{1}{\varphi^2} = \frac{3 - \sqrt{5}}{2} = 0.38197,$$

in sicer s koordinato:

$$D = A + h \cdot \frac{1}{\varphi^2}, \quad h = |C - A|.$$

Očitno je točka D bližje točki A kot točka B . Nato obravnavamo dva scenarija:

- Če je vrednost $f(D) > f(B)$, potem postane novi triplet (D, B, C) , točko A torej nadomesti točka D .
- V nasprotnem primeru, ko je $f(D) < f(B)$, pa postane novi triplet (A, D, B) , točko C torej nadomesti točka B , njeno vlogo pa prevzame točka D .

Pri vsakem koraku se interval zmanjša za faktor $\frac{1}{\varphi}$.

Metodo nato ponavljamo do želene natančnosti, pri čemer moramo paziti, da je dosegljiva natančnost le *koren iz numerične natančnosti računskih operacij!* (npr 10^{-8} za dvojno natančnost (double precision)).

Hitrejša, a nekoliko labilnejša metoda, je iskanje minimumov z prilagajanjem parabole na tri začetne točke in oceno novega minimuma iz minimuma prilagojene parabole:

$$x = b - \frac{1}{2} \frac{(b-a)^2[f(b) - f(c)] - (b-c)^2[f(b) - f(a)]}{(b-a)[f(b) - f(c)] - (b-c)[f(b) - f(a)]},$$

ki pa odpove(duje) ko so izbrane tri točke (skoraj) kolinearne. Smiselna je torej ustrezna kombinacija obeh metod, poznana kot *Brentova metoda*.

V primeru, ko je poznana analitična oblika odvoda iskane funkcije, si seveda lahko pomagamo z numeričnim iskanjem ničle v odvodu (npr z metodo bisekcije).

V več dimenzijah je problem ustrezno težji, najrobustnejša in precej učinkovita je t.i. *Downhill simplex* metoda, ki jo bralec z lahkoto najde v literaturi in na spletu.

Poseben primer uporabe minimizacije funkcij je prilagajanje (angl. *fitting*) modelov (in s tem napovedanih funkcij) s prostimi parametri naboru izmerjenih količin. Najpogostejša načina prilagajanja funkcij s prostimi parametri podatkom sta metodi χ^2 in metoda največje zanesljivosti (angl. *Maximum Likelihood Method*). Označimo nabor merjenih podatkov z $\{x_i, y_i\}$ in njihove nedoločenosti z $\{\sigma_i\}$, modelske funkcije s $y = f(x, \alpha)$, kjer so z α označeni neznani parametri, ter uvedimo cenilko (angl. *estimator*) za χ^2 :

$$\chi^2(\alpha) = \sum_i \frac{(y_i - f(x_i, \alpha))^2}{\sigma_i^2},$$

kjer je nato ocena iskanih parametrov α dobljena z minimizacijo funkcije $\chi^2(\alpha)$.

Metoda največje zanesljivosti se uporablja predvsem v primerih, ko vrednost $y = f(x, \alpha)$ predstavlja verjetnost (ali verjetnostno gostoto) in tako iščemo nabor parametrov α , pri katerih je nabor verjetnosti za dane izmerke največji. Iščemo torej maksimum produkta verjetnosti

$$L(\alpha) = \prod_i f(x_i, \sigma_i, \alpha),$$

oziroma še bolj pogosto minimum naravnega logaritma zgornjega izraza (ki je pohlevnejša funkcija):

$$-\ln L(\alpha) = -\sum_i \ln f(x_i, \sigma_i, \alpha).$$

V primeru, da je verjetnostna porazdelitev Gaussova in da iščemo neznani parameter le-te (μ , srednja vrednost), sta obe metodi enaki (dokaz je prepuščen bralcu).

Naloga:

- Z metodo zlatega reza in parabolično ter saj eno vgrajeno metodo (npr Brentovo metodo v SciPy: `scipy.optimize.brent`) poišči ekstreme nekaj funkcij različnih redov tipa $x^n * \sin(x)$ (recimo do tretjega reda) in primerjaj hitrost (št. korakov) in natančnost s točnimi vrednostmi.
- Z zgornjimi metodami poišči najboljše prilagajanje med podatki:

$$\{x_i\} = [0.1, 0.41052632, 0.72105263, 1.03157895, 1.34210526, 1.65263158, 1.96315789, 2.27368421, 2.58421053, 2.89473684, 3.20526316, 3.51578947, 3.82631579, 4.13684211, 4.44736842, 4.75789474, 5.06842105, 5.37894737, 5.68947368, 6.]$$

$$\{y_i\} = [0.04959185, 0.15562821, 0.22546384, 0.29475305, 0.3564775, 0.40037302, \\ 0.45322831, 0.44861781, 0.47145439, 0.49542899, 0.48391543, 0.50759507, \\ 0.49552151, 0.50198301, 0.44788353, 0.46090299, 0.43101869, 0.44916611, \\ 0.40895603, 0.39695574]$$

$$\{\sigma_i\} = [0.03682367, 0.0014194, 0.01994378, 0.01061233, 0.0100865, 0.00231544, \\ 0.01935984, 0.00635483, 0.02376167, 0.00087145, 0.02262165, 0.00350645, \\ 0.01716223, 0.02109906, 0.02477181, 0.03953272, 0.02218641, 0.01454135, \\ 0.01634465, 0.04684965]$$

in funkcijo dveh neznanih parametrov a in b , oblike $f(x, a, b) = a*x*exp(b*x)$. Uporabi eno od vgrajenih metod (npr. v Pythonovih SciPy knjižnicah.)

- **Dodatno:** Z Downhill simplex metodo poišči maksimum dvo-dimenzionalne Gaussove porazdelitve ter dvojne 2D Gaussove porazdelitve (kamelja grba).

Iskanje ekstremov funkcij (v 1D)

Naloga: Imamo funkcijo $f(\vec{x})$, ki je funkcija n neodvisnih spremenljivih $\vec{x} = (x_1, x_2, x_3, \dots, x_n)$. Določiti želimo vrednosti x_1, x_2, \dots, x_n , kjer funkcija doseže maksimum ali minimum.

Ekstremne funkcije (maksimume, minimume) delimo na:

- GLOBALNE: dejansko najvišja oziroma najnižja vrednost funkcije na njenem definicijskem območju.

- LOKALNE: najvišja oziroma najnižja vrednost funkcije v nekem konkretnem okolju / znatni konkretni intervali, izuzetno robne (robne točke) opazovanega intervala.

Mi se bomo spoznali z metodami za iskanje LOKALNIH EKSTREMOV!

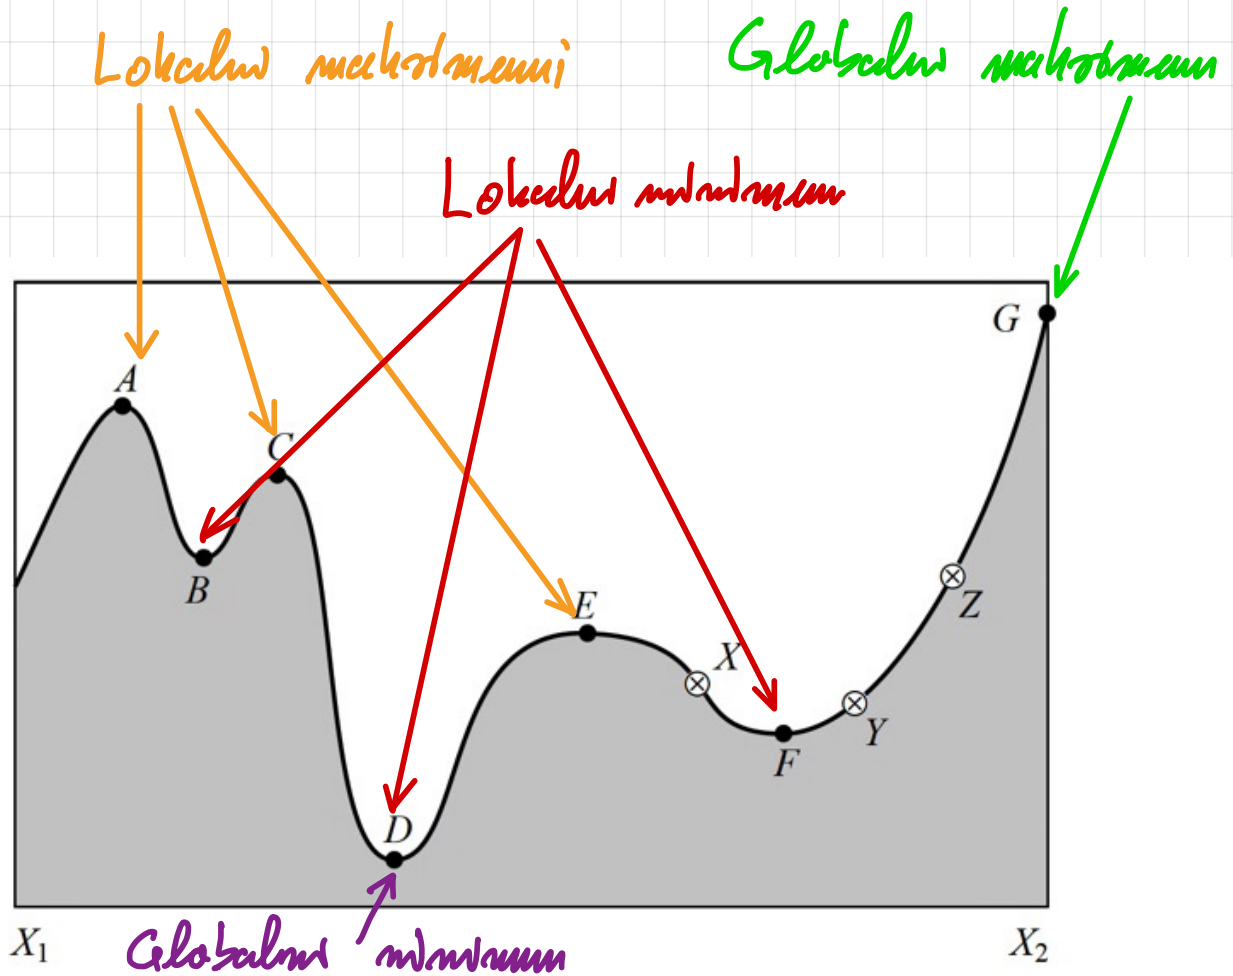


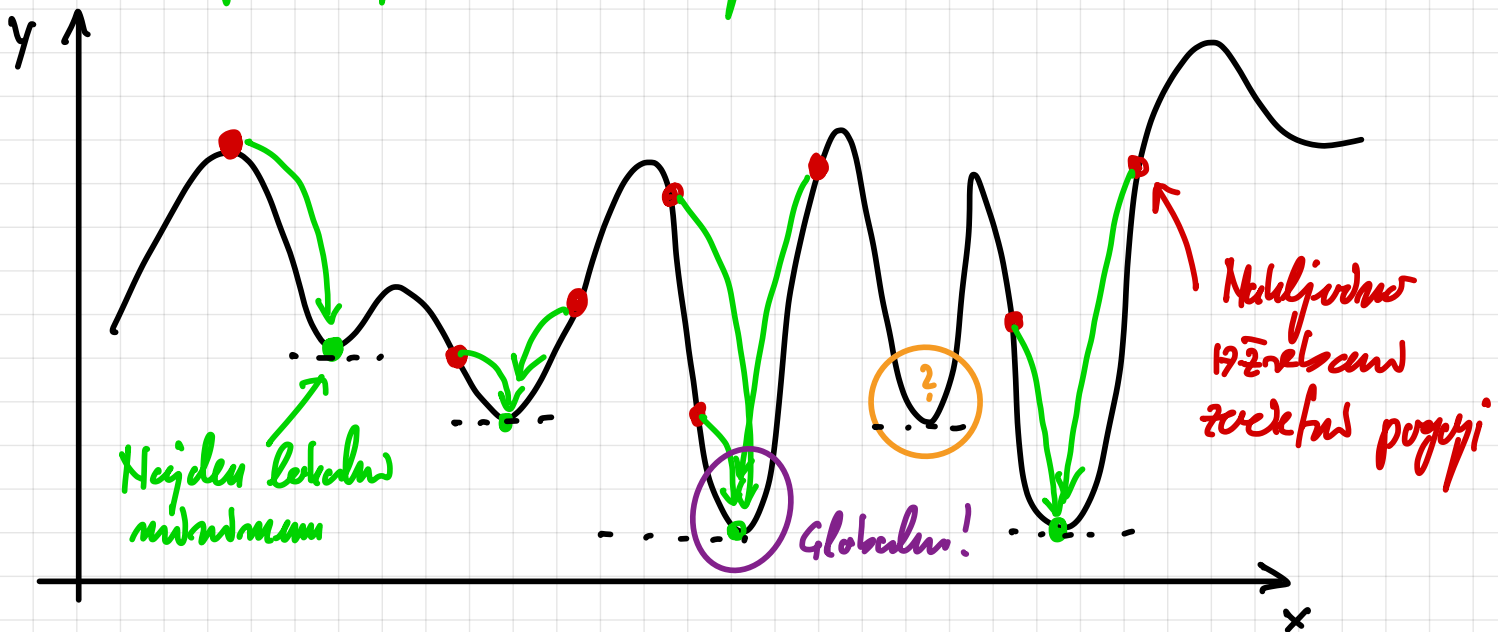
Figure 10.0.1. Extrema of a function in an interval. Points A, C, and E are local, but not global maxima. Points B and F are local, but not global minima. The global maximum occurs at G, which is on the boundary of the interval so that the derivative of the function need not vanish there. The global minimum is at D. At point E, derivatives higher than the first vanish, a situation which can cause difficulty for some algorithms. The points X, Y, and Z are said to “bracket” the minimum F, since Y is less than both X and Z.

Iščanje globalnih ekstremov (predvsem v večih dimenzijah) je zelo zahtevno. Težave so:

- da se zataknejo v lokalnem ekstremu, ne najdemo pa tisto iz njega druga preprosto za globalnega.
- med iskanjem globalnega ekstremu, najdemo vrsto lokalnih, globalnega pa opredelimo.

Predlogovca takтика za iskanje globalnega ekstrema

- 1.) Poiščemo lokalne ekstreme za množico zelo razločnih zveztnih vrednosti neodvisnih spremenljivk in izberemo tistega, v katerem je vrednost funkcije najmanjša! **Zveztne vrednosti lahko znebemo kas nadaljevanje po definicijskem območju!**



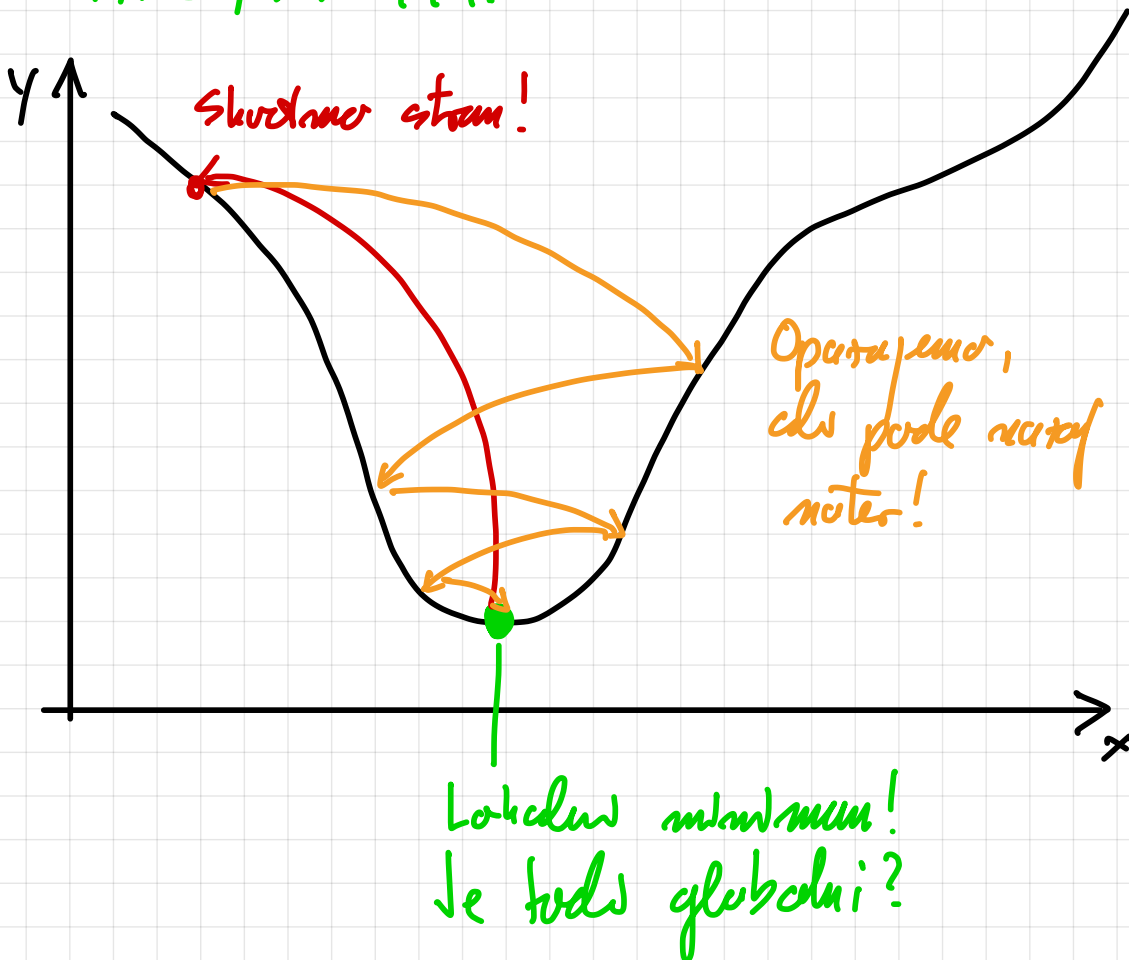
Pregledamo vse lokalne minime in izberemo tistega, ki je najnižji:

- Lahko se zgodijo, da kateri koli minimum spregledamo! Zato moramo analizo izvesti za dovolj razločnih zveztnih pogajev (ali pa za dovolj gosto množico točk)

kar se vedno in zagotovo, da tega ne ignoriramo!

- Lahko se zgodi, da je naš lokalni minimum enak globlji! \Rightarrow Povrnemo vse!

2.) Izvedemo perturbacijo lokalnega ekstrema: Da našo funkcijo amplitude se odmaknemo od ekstrema (npr. minimuma) in pogledamo ali metoda konvergira k boljši točki ali se vrne vme k isti (izbravemo lokalnemu ekstremu) \Rightarrow Po tem principu delujejo metode, ki delujejo po principu "simultaneje obhajanja". Za več glej NRC, str 444.



3.) Ne potrebni preveriti vrednosti funkcije na robu intervala (definičjskega območja)



Globalni ekstrem se lahko skrivata na robu intervala (npr. $[a, b]$ pri $f(a)$).

Opomba: Iščanje minimumov je tako povezano z iskanjem maksimumov: Iščanje minimuma funkcije f je enako iskanju maksimuma funkcije $-f$.

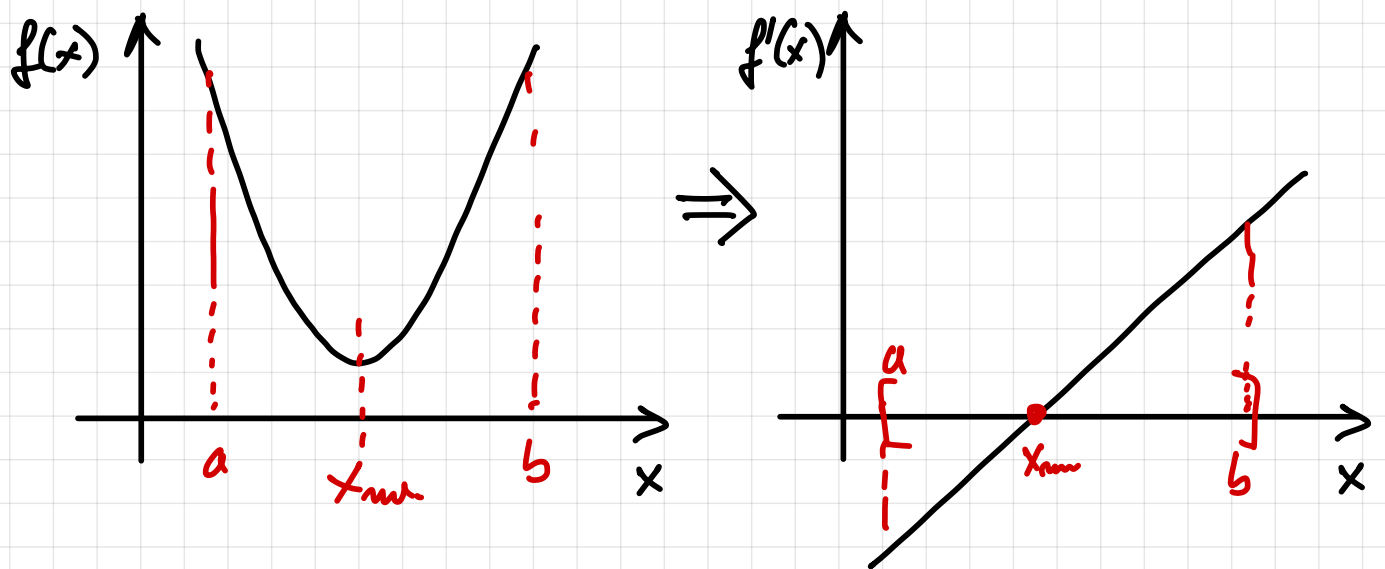
Algoritem za reševanje ekstremov se vedno napreca tako, da iščejo minimume. Maksimume dobimo z iskanjem minimumov ($-f$)!

Algoritmi za iskanje minimumov v 1D:

- Algoritme ločimo na tiste, ki za določanje minimuma potrebujejo le funkcijske vrednosti $f(x_i)$ in $\{x_i\}$ in tiste, ki poleg funkcijskih vrednosti uporabljajo tudi odvode $f'(x_i)$
če jih znamo izračunati!?
- Metode, ki uporabljajo odvode opredelimo med metodami s področja rešenj:
 - Včasih se jih ne sploča uporabljati, saj dodatno računamo odvode, podajajo konvergenco do te mere, da so metode, ki uporabljajo le funkcijske vrednosti hitrejše
 - Odvode se ne uporabljajo za določevanje parametrov nujnih redov (skupaj z vrednostno funkcijo), s katerimi bi red boljše modelirali prave funkcije in so zanesljive hitreje konvergenca. Parameter nujnih redov se lahko določijo običajno, in nas rešijo izven iskalnega območja.

- odvode se upravlja za kutry' se iskuzi naslednjega publikaci minimum v iterativnem procesu. Upravna odvoda je amfena!
(Glej NRC, poglavje 10.3, str. 405)

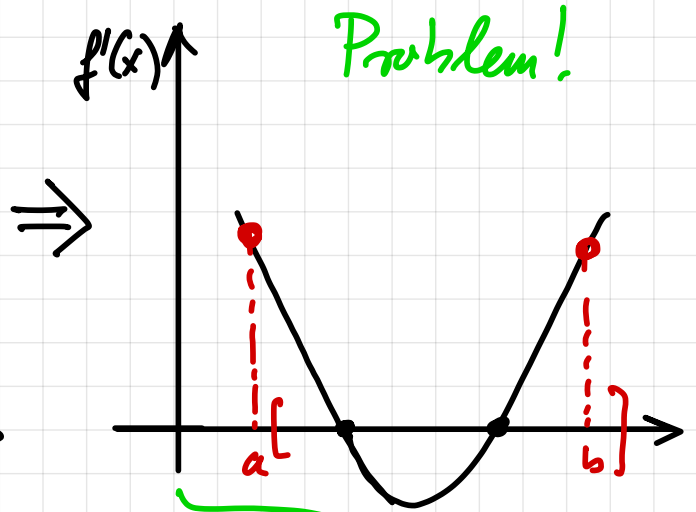
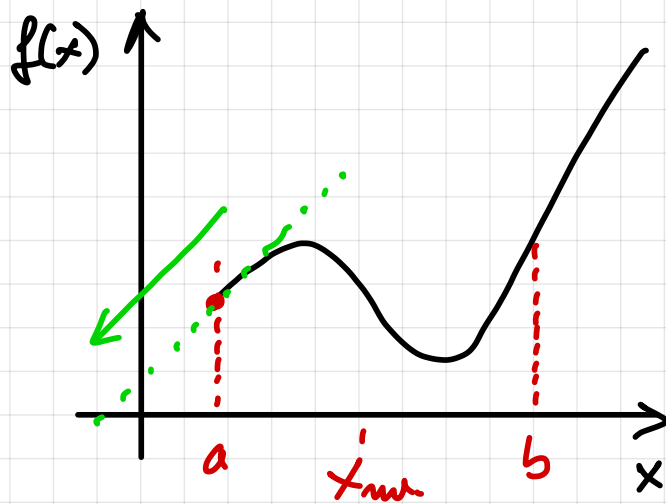
Pozor: Če poznamo odvode, putem bi se dalo minimum iskati tudi z iskuzjem model odvoda z upravno zmogljivi metoda z iskuzjem model.



Por taku metodo nas nekajo pusti:

- Če iščemo $f'(x) = 0$, putem o pricu ne vemo, ali smo uobli minimum, ali minimum?

- Kako napredujemo od točnih pogojev
da znači ali ne? nekoli toki kazi,
da je omer naveden v omer nem iz
intervalu?




Nekli omer, da algoritam
 za iskanje ničel delujejo
 za tako stvarno ničel
 na intervalu $[a, b]$,
 kjer je $f(a) \cdot f(b) < 0$!

Ishujja lokalnega minimuma se lahko na podoben način, kot smo se lotili ishujja model.

Korak #1: Minimum moramo najprej lokalizirati, (uokvirati). Za to potrebujemo tvoj točki $a < b < c$, za katere velja, da je

$$f(b) < f(a), f(c)$$



Na takem intervalu je vsaj en minimum!

Nekateri algoritmom to daves že sam naredijo se ves! Kljub temu se vedno prepričajte tudi samo, da je na izbranem intervalu res minimum! \Rightarrow Lahko so novbete funkcija!

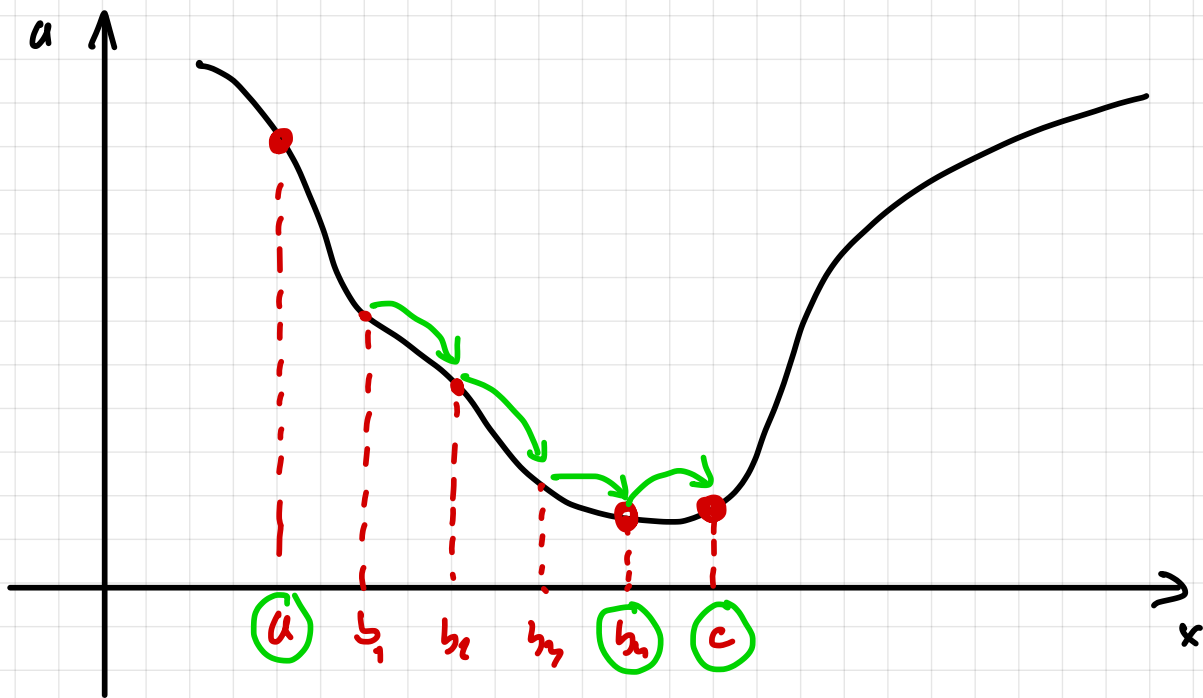
Metoda za nalaženje minimuma

1.) Izaberu dva točka: a, b , tako da je $f(a) > f(b)$.
Da je $f(b) > f(a)$, je završeno.

2.) Izračunamo tačku točka $c = b + f \cdot (b - a)$.
kjer je f faktor koraka. Korak lahko
določimo konstantno ($f=1$), ali pa ga poravnamo
v vsakem koraku.

Izračunamo $f(c)$. Da je $f(c) < f(b)$,
potem: $b = c$ in ponovno korak 2.)
ine sicer $f(c) > f(b)$.

3.) Vrsta (a, b, c)



b.) Če $f(x_i) > f(b_i)$, potem je naslednja
trajka točka:

$$\begin{aligned} a_{i+1} &= a_i \\ b.) \quad b_{i+1} &= b_i \\ c_{i+1} &= x_i \end{aligned}$$

3.) Ponovljamo 2.) vse dokler

$$|c_{i+1} - a_{i+1}| < \underline{\underline{\epsilon}} \approx 10^{-8}!$$

Izbrana
netočnost

Kako izbrati strategijo delovanja naslednjega
približka x_i :

Izbrano:

$$p = b - a$$

$$q = x - b$$

$$r = c - b$$

$$q = \frac{r}{p} ; \text{ Razmerje pare, kje je } b \text{ glede na } a \text{ in } c!$$

Točko x_i želimo gledati na točki (a_i, b_i, c_i) postavit tako, da bo konvergencija v naslednjih korakih postala enakotna, ne glede na to, ali bomo v naslednjem koraku izbrali točko a.) ali b.). To zagotovimo tako, sta naslednji intervali enako široki:

$$\overset{b.)}{p} + \overset{a.)}{q} = r$$

Na enak način, kot v n -tem koraku delovamo levo x_i , smo v prejšnjem koraku delovali levo b_i glede na a_i in c_i . Algoritem slutvi, da so razmerja med točkami (a_i, b_i, c_i) enakih razmerijem naslednjih točk: bodisi (a_i, b_i, x_i) bodisi (b_i, x_i, c_i) . Z obratnim razmerjem algoritem slutvi, da se b_i ne preloži preveč a_i odzrača c_i , kar bi lahko znatno upočasnilo konvergenco:

V primeru a.) zato zadržimo:

$$\frac{p}{r} = \frac{q}{r-q} \left(\equiv \frac{\text{Krajši del}}{\text{Dolgi deli deli}} \right)$$

i -ti korak razmerje intervalov v $i+1$. koraku.

V primeru b.): i+1-korak

i-korak $\frac{p}{r} = \frac{r}{p} \Rightarrow r = \frac{p^2}{r} \quad (*)$

Od tod si sedaj lahko izpeljemo:

$$\frac{r}{p} = \frac{r-r}{r} = \frac{r}{r} - 1 = \frac{r^2}{r^2} - 1$$

"y" "y²"

Dobimo:

$$y^2 - y - 1 = 0$$

Rešitev te enačbe je:

$$y = \frac{1 + \sqrt{5}}{2} = 1.618\dots$$

To imenujemo število zlatega reza.

Še malo razmisli:


$$y^2 = y + 1$$

$$y = 1 + \frac{1}{y}$$

$$\frac{r}{p} = 1 + \frac{p}{r} =$$

$$\frac{r}{p} = \frac{p+r}{r}$$

Zlato
reza!



Ugotovimo še:

$$\begin{aligned} \underline{p+q} &= p + \frac{p^2}{r} = p \cdot \left(1 + \frac{1}{q}\right) = p \frac{1+q}{q} = \\ &= p \cdot \frac{q^2}{q} = p \cdot q = p \cdot \frac{r}{p} = \underline{\underline{r}} \end{aligned}$$

Ugotovimo mo, da je b_i oddaljena od c_i ravno toliko, kot x_i od a_i . Zato dajemo recept:

1) Če vemo, da je na intervalu $[a_i, c_i]$ minimum, izračunamo:

$$b_i = c_i - r = c_i - \frac{(c_i - a_i)}{q}$$

$$x_i = a_i + r = a_i + \frac{(c_i - a_i)}{q}$$

komentar:

$$\begin{aligned} (c-a) &= p+r = \frac{r^2}{p} \\ &= r \cdot \frac{r}{p} = r \cdot q \end{aligned}$$

$$\Downarrow \\ r = \frac{c-a}{q}$$

Primerjamo $f(x_i)$ in $f(b_i)$ ter določimo novo točko (a_i, b_i, c_i) .

Pomembno, določimo dozeženo željeno natančnost! Glej zgled!

Konvergenca: $r = \frac{1}{\varphi} \cdot (c - a) \doteq 0.618.$

Širina intervala v naslednji iteraciji je 0.62 prejšnje, kar je podobno, kot raven nulis pri bisekciji (0.5). Konvergenca je linearna!


- Metoda zlatega reza je robustna metoda, vendar deluje, o nekakšno počasna!
(Analog bisekcije)

- Ali se da iskati minimuma polnosti?
(Da: Metoda z inverzno porabljeno interpolacijo, Brentova metoda, ...)

Metoda z inverzno parabolo interpolacijo

Ideja: Taylorjev razvoj pene, da bi funkcija (če je le dovolj polarna) v neposredno bližnjem minimumu imela praktično obliko parabole. To nas napelje na idejo, da če bi tri točke (a, b, c) v tej okolici interpolirali (povezali) s parabolo, bi v eni iteraciji našli minimum!

Če pa smo v nekateri "širši" okolici, po metoda obljublja hitrejšo konvergenco k minimumu. **Metoda ima super linearno konvergenco z ϵ^n ; $n \approx 1.325$.**



Polynomparabel $f(x) = Ax^2 + Bx + C$, in ge. Skat. Form (a, b, c)

$$\underline{f(x) = A(x-b)^2 + B(x-b) + f(b)}$$

$$f(c) = A(c-b)^2 + B(c-b) + f(b)$$

$$\underline{f(a) = A(a-b)^2 + B(a-b) + f(b)}$$

$$f(a) - f(b) = A(a-b)^2 + B(a-b) \quad /: (a-b) \quad /: (a-b)^2$$

$$\underline{f(c) - f(b) = A(c-b)^2 + B(c-b) \quad /: (c-b) \quad /: (c-b)^2}$$

$$\left. \begin{aligned} \frac{f(a) - f(b)}{(a-b)} &= A(a-b) + B \\ \frac{f(c) - f(b)}{(c-b)} &= A(c-b) + B \end{aligned} \right\} -$$

$$\frac{f(a) - f(b)}{(a-b)} - \frac{f(c) - f(b)}{(c-b)} = A(a-b - c+b) = A(a-c) \quad /: (-1)$$

$$A = \frac{f(c) - f(b)}{(c-b)(c-a)} + \frac{f(a) - f(b)}{(b-a)(c-a)}$$

$$\left. \begin{aligned} \frac{f(a) - f(b)}{(a-b)^2} &= A + \frac{B}{a-b} \\ \frac{f(c) - f(b)}{(c-b)^2} &= A + \frac{B}{c-b} \end{aligned} \right\} -$$

$$\begin{aligned} \frac{f(a) - f(b)}{(a-b)^2} - \frac{f(c) - f(b)}{(c-b)^2} &= B \left[\frac{1}{a-b} - \frac{1}{c-b} \right] \\ &= B \frac{c-b - a+b}{(a-b)(c-b)} = B \frac{(c-a)}{(a-b)(c-b)} \end{aligned}$$

$$B = \frac{[f(a) - f(b)](c-b)}{(a-b)(c-a)} - \frac{[f(c) - f(b)](a-b)}{(c-b)(c-a)}$$

Zanimiva nas, kje ima posredna minimum:

$$f(x) = A(x-b)^2 + B(x-b) + f(c)$$

$$f'(x) = 2A(x-b) + B = 0$$

$x = x_{\min}$

$$x_{\min} = b - \frac{B}{2A}$$

Dobimo:

$$x_{\min} = b - \frac{1}{2} \frac{\frac{[f(a) - f(b)](c-b)}{(a-b)(c-a)} - \frac{[f(c) - f(b)](a-b)}{(c-b)(c-a)}}{\frac{f(a) - f(b)}{(c-b)(c-a)} + \frac{f(a) - f(b)}{(b-a)(c-a)}}$$

Zneblava se drojnih ulankov z nuroenjem z
(c-b)(c-a)(b-a):

$$x_{\min} = b - \frac{1}{2} \frac{[f(b) - f(c)](b-a)^2 - [f(b) - f(a)](b-c)^2}{[f(b) - f(c)](b-a) - [f(b) - f(a)](b-c)}$$

Postupci:

1.) Delovanje $a < b < c$, da je $f(b) < f(a), f(b)$

2.) Izračunavanje x_{min} ili $f(x_{min})$

• Če je $f(x_{min}) < f(b)$ ili $x_{min} < b$:
 $c = b$ ili $b = x_{min}$

• Če je $f(x_{min}) < f(b)$ ili $x_{min} > b$:
 $a = b$ ili $b = x_{min}$

• Če je $f(x_{min}) > f(b)$ ili $x_{min} < b$:
 $a = x_{min}$

• Če je $f(x_{min}) > f(b)$ ili $x_{min} > b$:
 $c = x_{min}$.

3.) Ponovljeno, dakle $|a - c| < \underline{\underline{\epsilon}}$. $\sim 10^{-8}$
Izračun




Figure 10.2.1. Convergence to a minimum by inverse parabolic interpolation. A parabola (dashed line) is drawn through the three original points 1,2,3 on the given function (solid line). The function is evaluated at the parabola's minimum, 4, which replaces point 3. A new parabola (dotted line) is drawn through points 1,4,2. The minimum of this parabola is at 5, which is close to the minimum of the function.

Težave:

- Metoda ne deluje med minimumom in maksimumom.
- Metoda hit telesa in nujno da konvergira, lahko ja iznese izven izbranih točk in intervala!
- Težave se pojavijo tedaj, ko se funkcija zelo približuje 0. Tedaj je $A \approx 0$ in poravnane vrednosti ne delajo dobro.

V tej obliki se metoda ne uporablja!

Brentova metoda: (Glej NRC, str. 402)

Metoda na volikant novim zdražuje hitro porabalnoro metodo z robustnejšo metoda zlatega reza v primerih, ko metoda ugotavi, da porabalnoro metoda ne konvergira. To dosega s prewiskjevanu najipredstrem zedajh nekaj vrednosti in 7 npru preverja, da so naslednje iteracije porabalnoro metode omiselne. Lopr. da naslednje xov leži znotraj $[a, b]$.

Dosegljiva natančnost pri iskanju minimuma:

Izkušnje pri iskanju model funkcije, predlagamo, da bomo z algoritmom minimume isali na intervalu:

$$|c - a| < \varepsilon$$


↓
ali

↓ Najboljša približek.

$$(1 - \varepsilon) \cdot b \leq b \leq (1 + \varepsilon) \cdot b$$

kjer je $\varepsilon \sim 10^{-15}$ naša računski natančnost v očitmetih = precej do vejico.

Opomba: Natančnost $\varepsilon \sim 10^{-15}$ ne bomo nikoli dosegle, saj nas bo pri angle natančnosti, skuter znano računsko vrednosti funkcije v okolici minimuma.



Vsej karkoli manjsta šiti točka x in b razlika ($\Delta = x - b$), da bomo še nepelj ločite $f(x)$ in $f(b)$?

Vrednost $f(x)$ v okolici $f(b)$ razvijemo po Taylorjevem razvoju:

$$f(x) \approx f(b) + \underbrace{f'(b)}_{\substack{= 0 \\ \text{(Minimum)}}}(x-b) + \frac{1}{2} f''(b) \cdot (x-b)^2 + \dots$$

Relativno odstopanje:

$$\left| \frac{f(x) - f(b)}{f(b)} \right| \approx \frac{1}{2} \frac{f''(b)}{|f(b)|} (x-b)^2 \geq \varepsilon$$

$$\underbrace{\frac{f(x)}{f(b)} - 1}_{\equiv \text{Dejanska vrednost}}$$

$$|x-b| \geq \sqrt{\varepsilon} \cdot \sqrt{\frac{2|f(b)|}{f''(b)}} \cdot \frac{b^2}{b}$$

\swarrow Pomembno da bode lepše enote
 \swarrow

$$|x-b| \geq \sqrt{\varepsilon} \cdot b \cdot \sqrt{\frac{2|f(b)|}{b^2 f''(b)}} \approx 1$$

Dobitno: $|x - b| \geq \sqrt{\epsilon} \cdot b$

$$\left| \frac{x - b}{b} \right| \geq \sqrt{\epsilon} = \epsilon_{\text{eff}} = \underline{\underline{10^{-8}}}$$

Najveća neizbježna greška u ovom je zradu $f'(b) = b$ približno 10^{-8} .! Če bismo zahtevali 10^{-15} algoritem ne bi nikada konvergirao!

Izled: Izračunaj minimum funkcije $f(x) = x + \frac{1}{x}$,
če $x \in (0, \infty)$.

Kje ima funkcija ekstrem: $f'(x) = 0$?

$$f'(x) = 1 - \frac{1}{x^2} = 0$$

$$x^2 = 1$$

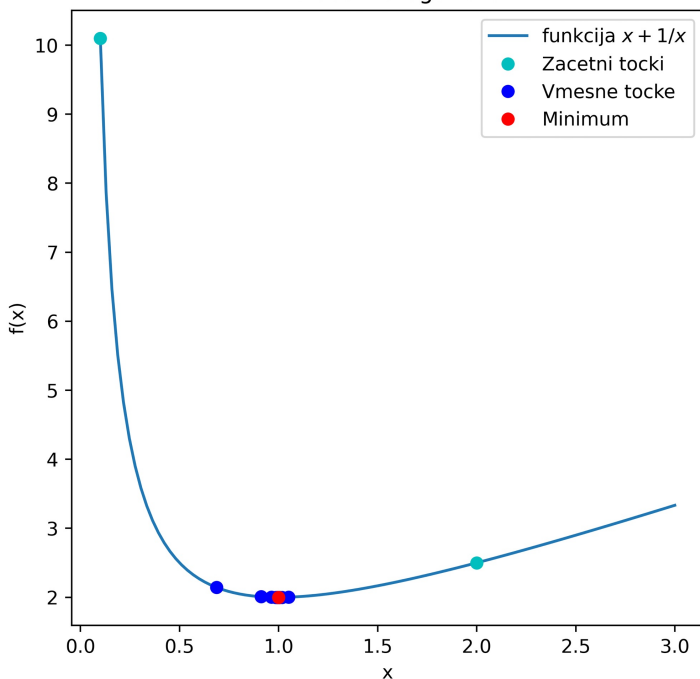
$$x = \pm \sqrt{1} = 1$$

To je minimum
funkcije!


Kaj pa drugi odvod?

$$f''(x) = \frac{2}{x^3}. \quad f''(x=1) = 2 > 0$$

Metoda zlatega reza



Metoda z inverzno parabolicno interpolacijo



Minimalizacija v več dimenzijah

Za izvedbo minimalizacije obstaja vrsta različnih algoritmov: Ameba, Powellova metoda konjugiranih smeri, metoda konjugiranih gradientov, metode s spremenljivo metodo, metoda simultanege ohlajanja.

Ameba (ali metoda Nelder-Mead ali "Downhill simplex" metoda)

- To je najbolj splošno uporabljena metoda
- Velika prednost metode je, da zahteva le vrednosti funkcije. Za delovanje ne potrebuje vrednosti odvodov.

Osnovni objekt metode je simpleks, geometrijski objekt, ki ima v N dimenzionalnem prostoru $N+1$ oglišč, ki jih povezujejo stranice, mnogokotniki itd.

V dvodimenzionalnem prostoru ($N=2$) je simpleks trikotnik.

Opcija:

Delovanje metode ni bomo pogledali na primeru $N=2$, saj si tu reči najlažje predstavljamo, hitro pa se izgubljamo splošnosti.

Ouha:

Prvi evolucionarni minimum zvezi smo minimum uokviru / lokalni in si s tem zagotovimo, da bomo minimum našli! Tega pa večdimensionalnih minimumov ni! Vse kar lahko naredimo je, da algoritmu damo začetno približek, nato pa pustimo, da gre algoritem svojo pot po prostoru dokler ne zredne lokalnega minimuma.

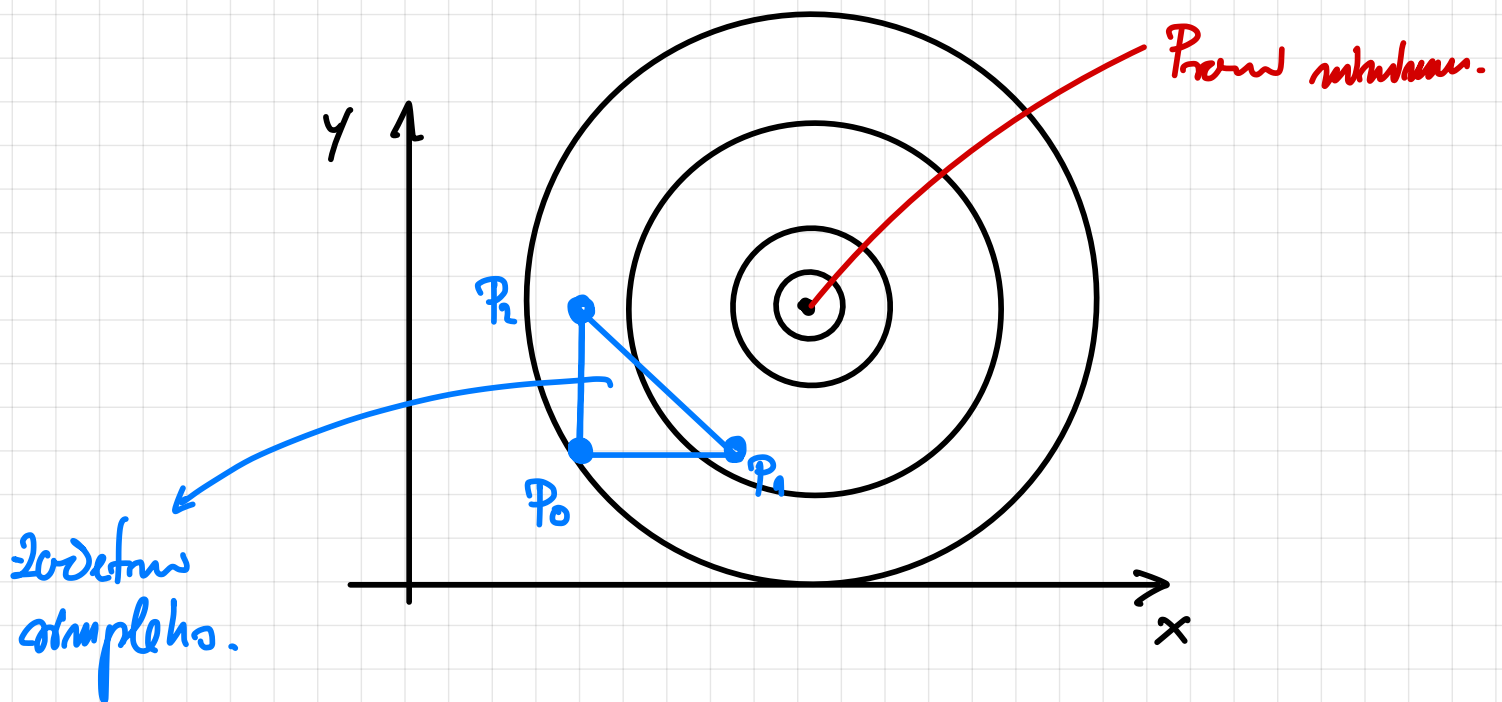
Začetna približek: Algoritem zahteva $N+1$ začetnih točk, ki definirajo začetni simpleks. Tega lahko konstruiramo na naslednji način:

- Izberemo eno točko $\vec{P}_0 = (x_0, y_0)$

- Oskula oglašiti kompleksa daljotina tako, da se premaknemo vzdolž evklidskih vektorjev prostora:

$$\vec{P}_i = \vec{P}_0 + \Delta_i \cdot \hat{e}_i; \quad i = 1, \dots, k.$$

Pri tem so Δ_i hipotne delitimske skale, ki hitenli se spleva iskati minimumu. Vrednosti Δ_i so odvisne od primera, zato moramo meti neli unid v problem! Ne uporabljaj algoritma ni slepo!




Isticanje minimuma je mož zaporednih transformacij
s katerimi zvedemo simpleks najde pot do
lokalnega minimuma da se "se sede najj."

1. korak: Oglivda simpleksa vredno po velikosti:
 $f(x_1) \leq f(x_2) \leq f(x_3)$

2. korak: Transformiramo simpleks. Možne
so naslednje transformacije:

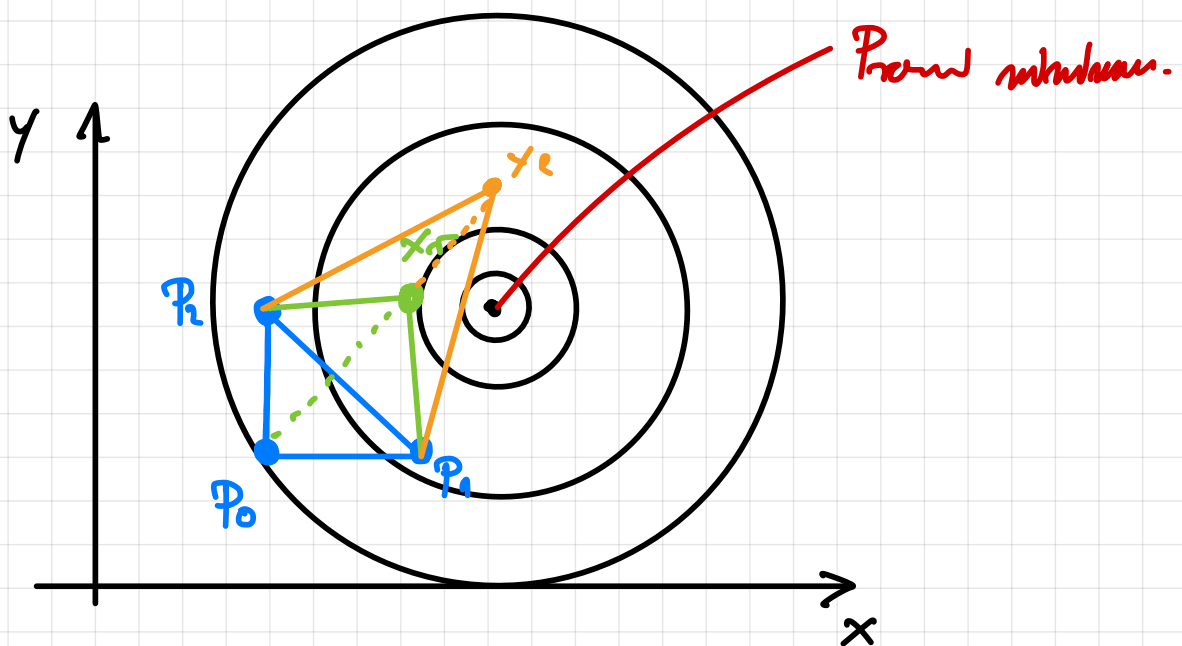
Zrcaljenje: To transformacija naredimo najprej
zrcalimo najslabši točko: $f(x_3)$
preko nasprotne ležne stranice. Dobimo
 x_4 in $f(x_4)$



- Će je $f(x_1) < f(x_r) < f(x_2) < f(x_3)$ putem sprijam točku ($x_3 = x_r$) du se vratit na 1.)
- Će je $f(x_r) < f(x_1) < f(x_2) < f(x_3)$, putem izvedu se razteg.
- Će je $f(x_r) > f(x_2)$, putem izvedu se kontrakcija.

Razteg: Simpleks raztegujemo u smeru zoculjenja za $\gamma > 1$ du dabi točku $x_e, f(x_e)$

- Će je $f(x_e) < f(x_r)$ putem $x_3 = x_e$
- Će je $f(x_e) > f(x_r)$ putem $x_3 = x_r$



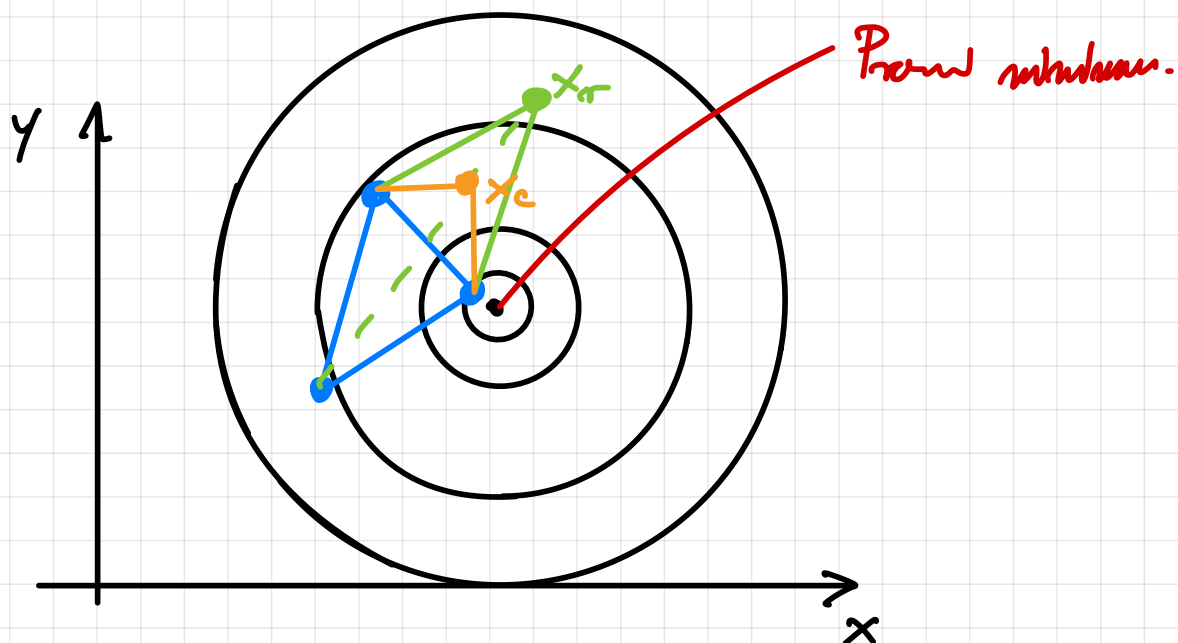
Oznanje:

Tu je $f(x_1) \geq f(x_2)$


Druga najslabša točka

- Če je $f(x_1) < f(x_2)$ potem preizkusimo točkastih zračno (mestec s faktorjem $0 < \gamma < \frac{1}{2}$) v smeri zračneja. Določimo točko x_c in $f(x_c)$. Če je $f(x_c) < f(x_1)$ potem sprejemo točko $x_3 = x_c$ in se vrnemo na 1.) Če ostanje na pomočnika ($f(x_c) > f(x_1)$), potem izvede še leženje

- Če je $f(x_1) > f(x_2)$ potem preizkusimo točkastih zračno z faktorjem $0 < \gamma < \frac{1}{2}$. Določimo točko x_c , $f(x_c)$. Če je $f(x_c) < f(x_1)$, potem sprejemo točko $x_3 = x_c$ in pojdemo na 2.) Če ostanje na pomočnika potem pojdemo na leženje.



Krojenje: Simpleks sluzi tako, da vse točke razen najboljše premaknemo bližje tej točki z faktorom $\sigma \sim \frac{1}{2}$ vzdalje deljic, ki povečujejo oglišča z najboljšim.



3. korak:

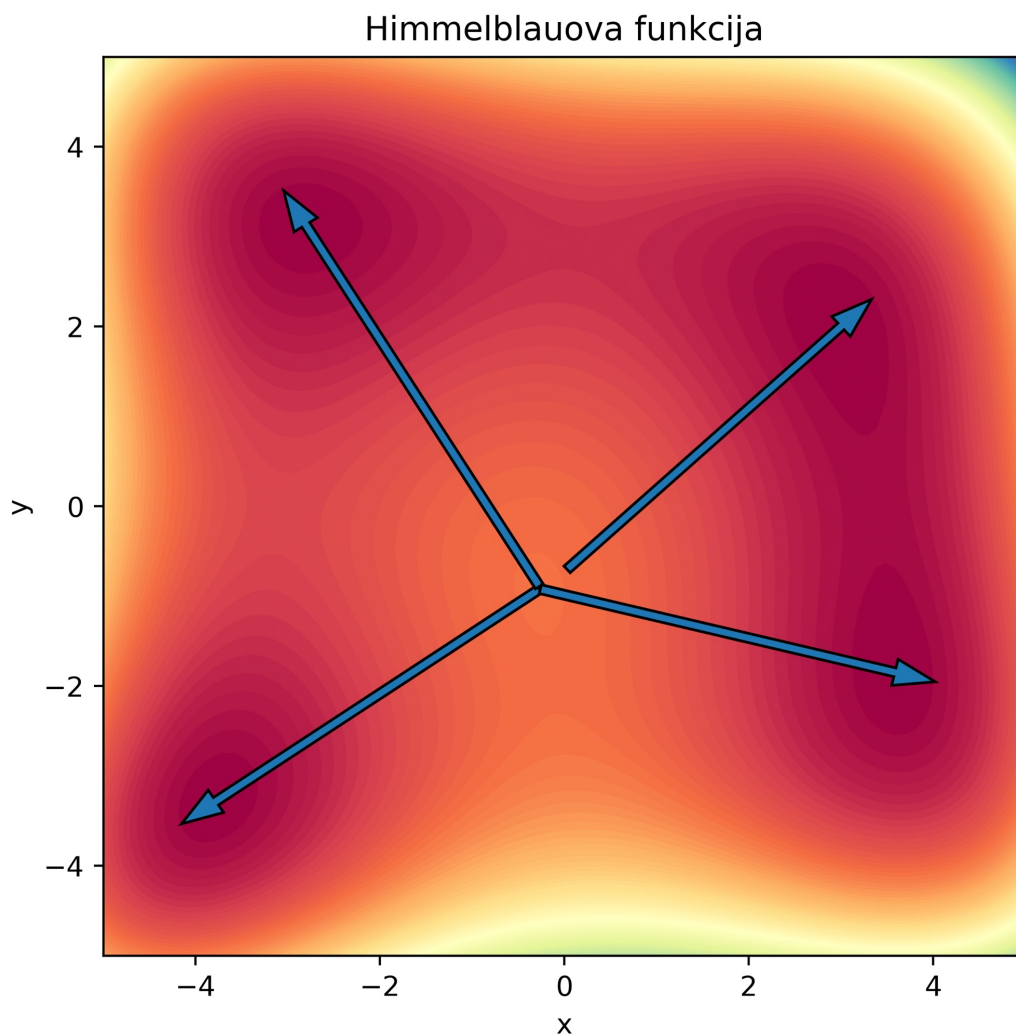
Minimalna vredja zafgodimo, ka je razlika med najbedjio in najslabio toiko manjio od izbrane natančnosti:

$$|f(x_1) - f(x_3)| < \epsilon \sim \underline{10^{-8}}$$

Za minimum izberemo najbedjio toiko x_1 .

Izled: Povšot minimum(e) Himmelblauove funkcije:

$$f(x,y) = (x^2 + y - 11)^2 + (x + y^2 - 7)^2$$



Funkcija ima 4 različne minime. Metoda konvergira v enega izmed njih, odvisno od izbrane začetnih pogojev. Če zelo majhne spremembe lahko vodijo do zelo različnih rezultatov.

Podlagajanje funkcij podatkom

- Podlagajanje funkcij podatkom je poseban primer upotrebe minimizacionih algoritama - predvsem Hstn i minimizacione i neodređenosti.

Imamo nabor merenih podataka:

$$\{(x_i, y_i, \sigma_i)\}_{i=1}^N$$

— zbirka merenih
točki.

neodređeni
s promenljivima

neodređena
funkcija

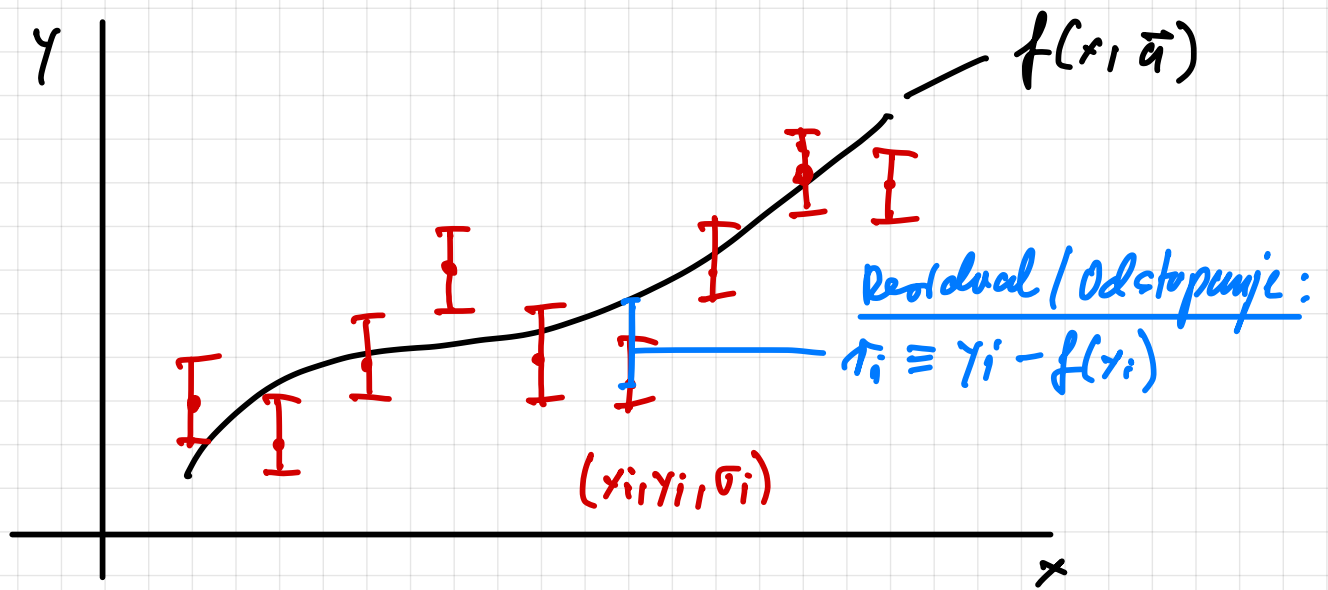
neodređenost
merne.

Kada bi uzglatnulo, kako je y odvisan od $x \Rightarrow$
izvesti zbirnu reprezentaciju odvisne promenljive
 y po neodređenim promenljivima \equiv podatkom
proizvodimo reprezentaciju funkcije

$$f(x, \vec{a}), \quad \vec{a} = (a_1, \dots, a_m)$$

Parametri funkcije.

Funkcija $f(x, \vec{a})$ je model za podatke. Podlagajanje
(ot. "fitovanje") je poseban izbor funkcije i
parametara, da se model kor najbolje prilagodi
podatcima.



Obstaja več kriterijev za to, kaj je "dobro-
rijemanje". Najpogostejše uporabljeno metodo
načrta minimalni kvadratov:

V tej metodi odstopanje modelne krivulje
od posameznih ocenjenih s centralno funkcija χ^2 :

$$\chi^2(\vec{a}) = \sum_{i=1}^N \left(\frac{y_i - f(x_i)}{\sigma_i} \right)^2 = \sum_{i=1}^N \left(\frac{r_i}{\sigma_i} \right)^2$$

Kako dobro se krivulja prilega
posameznim merilom & resiti
kvadratov relativnih odstopanj točk.

Cenilka $\chi^2(\vec{a})$ je funkcija parametrov \vec{a} modela $f(x, \vec{a})$. Model se bo v okviru izbrane metode najboljše prilagal podatkom pri tistem nizu parametrov \vec{a}' , kjer je

$$\chi^2(\vec{a}') = \min.$$

Iščanje parametrov $\vec{a}' = (a_1', a_2', a_3', \dots, a_n')$ kjer je χ^2 minimalna izvedemo z optimizacijskim algoritmom, npr. Amalga!



Če uspešno najde globalno minimum za χ^2 , potem vedemo, da se izbran model pri teh parametrih v smislu najmanjših kvadratov najboljše prilaga izbranim podatkom.

(Pri tem seveda še vedno obstaja možnost, da obstaja neka druga funkcija $g(x, \vec{b})$ z drugimi parametri, ki bi dala še manjšo vrednost χ^2 !)

Past:

Ker je minimizacija kamčena, nam nikoli ne garantira, da smo kamčeni v lokalnem minimumu!

Linearna regresija: (komentor)

O linearni regresiji govorimo, kadar je modelska funkcija linearno odvisna od parametrov a_i .

Npr:

$$f(x, \vec{a}) = \underline{a_1} + \underline{a_2}x + \underline{a_3}x + \dots + \underline{a_m}x^{m-1}$$

$$f(x, \vec{a}) = \underline{a_1}x + \underline{a_2}e^x + \underline{a_3}\sin x + \underline{a_4}\log x$$

⋮

$$f(x, \vec{a}) = \sum_{j=1}^m \underbrace{a_j}_{\text{parameter}} \cdot \underbrace{\theta(x)}_{\text{linearna funkcija } x}.$$

Tudi tu poskušamo najti rešitev $A^?$:

$$\frac{\partial A^?}{\partial a_j} = 0 \quad ; \quad j = 1, \dots, m$$

Od tod dobimo linearen sistem enačb za parametre a_j , ki ga znamo rešiti (Npr. SVD). Dobimo rešitev, ki pa je v smislu najmanjših kvadratov gotovo najboljša!

Glej: Šincar, VF, str. 197.

Nasvet:

Vas problem vedno postavajte
linearno strukt. Npr: Prilogejamo

$$f(x; a, b) = a e^{-bx}$$

Vredimo: $g(x; a, b) = \ln(f(x))$

$$g(x; a, b) = \ln a - bx = \underline{a'} - bx$$

Problem smo linearno strukt!

Prologičnyj amp) pravice:

Prologičnyj amp) pravice je primer linearnne regrezijske
za $m = 2$.

$$f(x; \underline{a, b}) = ax + b$$

Dva parametra.

Minimaln Hramo:

$$X^2(a, b) = \sum_{i=1}^m \frac{(y_i - ax_i - b)^2}{\sigma_i^2} = \min.$$

Rodunimo:

$$\frac{\partial X^2}{\partial a} = -2 \sum_{i=1}^m \frac{(y_i - ax_i - b)x_i}{\sigma_i^2} = 0$$

$$\frac{\partial X^2}{\partial b} = -2 \sum_{i=1}^m \frac{(y_i - ax_i - b)}{\sigma_i^2} = 0$$

Če upeljemo:

$$A = \sum_{i=1}^m \frac{x_i}{\sigma_i^2}, \quad B = \sum_{i=1}^m \frac{1}{\sigma_i^2}$$
$$C = \sum_{i=1}^m \frac{y_i}{\sigma_i^2}, \quad D = \sum_{i=1}^m \frac{x_i^2}{\sigma_i^2}$$
$$E = \sum_{i=1}^m \frac{x_i y_i}{\sigma_i^2}, \quad F = \sum_{i=1}^m \frac{y_i^2}{\sigma_i^2}$$

To znamo izračunati
iz podatkov!

dobimo sistem enob:

$$aA + bB = C$$

$$aD + bA = E$$


in rešitw:

$$a = \frac{EB - CA}{DB - A^2}, \quad b = \frac{DC - EA}{DB - A^2}$$

Izračunati se da tudi neposredni parametri in varcovjski koeficient (Glej, Štira, VF, 206)

$$\sigma_a^2 = \frac{B}{BD - A^2}, \quad \sigma_b^2 = \frac{D}{BD - A^2}$$

$$\text{cov}(a, b) = \frac{-A}{BD - A^2}, \quad \rho(a, b) = \frac{\text{cov}(a, b)}{\sigma_a \cdot \sigma_b}$$



Slika 9.3 — Prilaganje linearne funkcije izmerkom $y_i = 1.4, 1.0, 1.5, 2.7, 3.7, 3.0, 4.1$ z napakami $\sigma_i = 0.5, 0.3, 0.2, 0.6, 1.0, 0.8, 0.5$ v točkah $x_i = 0, 0.5, 1, 1.5, 2, 2.5, 3$ po metodi najmanjših kvadratov. [LEVO] Premica, ki minimizira mero odstopanja X^2 ($\hat{\theta}_1 = 0.578$, $\hat{\theta}_2 = 1.100$). [SREDINA] Kovariančna elipsa s središčem v točki $(\hat{\theta}_1, \hat{\theta}_2)$ in napakama $\pm\sigma(\hat{\theta}_1) = \pm 0.247$ in $\pm\sigma(\hat{\theta}_2) = \pm 0.190$. Parametrom iz notranjosti elipse ustrezajo premice, ki vse potekajo po senčenem območju na sliki [DESNO]. Premica, ki ustreza pravima vrednostma θ_1 in θ_2 , z verjetnostjo $1 - e^{-1/2}$ leži znotraj te pahljače.

Izjed :

(Leo, str 99)

x	0	1	2	3	4	5
y	0.92	4.15	9.78	14.46	17.26	21.90
σ	0.5	1.0	0.75	1.25	1.0	1.5

Podatkom iz tabele prilažemo
premler $f(x) = ax + b$.

Izračunane vrednosti:

$$a = 4.227 \pm 0.044$$

$$b = 0.878 \pm 0.203$$

$$A^2 = 2.078$$

$$\text{cov}(0,5) = -0.0629$$

$$f = 7.04$$

Rezultat minimizacije z Amelom v Pythonu:

