

3D számítógépes geometria 2

Numerikus analízis alapok

Várady Tamás, Salvi Péter / BME

October 19, 2020

Gyökkereső algoritmusok

- ▶ Feladat: $f(x) = 0$
 - ▶ x skalár vagy n -dimenziós vektor
- ▶ Nemlineáris eset az érdekes
- ▶ Iteratív megoldás
 - ▶ Konvergencia sebessége általában ismert
 - ▶ Jó kezdőérték kell (nagyon fontos!)
- ▶ Egy dimenzióban keretezés
- ▶ Problémát okozhat
 - ▶ Ha nincs gyök
 - ▶ Ha többszörös gyök van
 - ▶ Ha nagyon közeli gyökök vannak

Keretező és nyitott módszerek

- ▶ Keretező módszerek
 - ▶ Megadunk a gyöknél kisebb és nagyobb értékeket
 - ▶ Mindig működnek
 - ▶ Általában lassan konvergálnak
- ▶ Nyitott módszerek
 - ▶ Csak kezdőérték kell
 - ▶ Nem mindig működnek
 - ▶ De ha igen, gyorsabban konvergálnak
- ▶ Kezdőérték gyakran a feladatból adódik
 - ▶ De jöhet inkrementális keresésből:
 - ▶ Egyenletesen felosztjuk az intervallumot
 - ▶ Előjelváltást keresünk: $f(x_k)f(x_{k+1}) < 0$, $x_i \in [x_{\min}, x_{\max}]$
 - ▶ Ha kevés részre osztunk, kihagyhatunk gyököt, ha sokra, lassú

Kettéosztás (bisection) ★

- ▶ Keret: x_{low} és x_{high} , $f(x_{\text{low}}) \cdot f(x_{\text{high}}) < 0$
- ▶ x_{mid} az intervallum közepe: $(x_{\text{low}} + x_{\text{high}})/2$
- ▶ Ha $f(x_{\text{low}}) \cdot f(x_{\text{mid}}) < 0$:
 - ▶ $x_{\text{high}} := x_{\text{mid}}$
- ▶ Ha $f(x_{\text{low}}) \cdot f(x_{\text{mid}}) > 0$:
 - ▶ $x_{\text{low}} := x_{\text{mid}}$
- ▶ Leállási feltételek:
 - ▶ Maximum iterációs szám túllépése ($i_{\text{max}} \approx \log_2 \frac{x_{\text{high}} - x_{\text{low}}}{\epsilon}$)
 - ▶ Relatív hiba kicsi:


$$\left| \frac{x'_{\text{mid}} - x_{\text{mid}}}{x'_{\text{mid}}} \right| < \epsilon$$

(x'_{mid} az újonnan számolt érték)

Hamis pozíció (lineáris interpoláció)

- ▶ Az előző algoritmus módosítása
- ▶ Új értéket lineáris interpolációval
 - ▶ Keretpontokat összekötő egyenes és az x tengely metszete
 - ▶ Hasonló háromszögekkel:

$$x = x_{\text{high}} - \frac{x_{\text{low}} - x_{\text{high}}}{f(x_{\text{low}}) - f(x_{\text{high}})} f(x_{\text{high}})$$



- ▶ Gyakran jobb, mint a kettéosztás
 - ▶ Nem mindig, pl. $x^{10} - 1$
 - ▶ Erős görbületű függvénynél nem hatékony
- ▶ Ridders-módszer:
 - ▶ Nem sokkal bonyolultabb (másodfokú egyenlet van benne)
 - ▶ Exponenciális függvénynel linearizál – nagyon stabil
 - ▶ $\sqrt{2}$ -rendű (2 fv.kiértékeléssel 2x annyi számjegyig pontos)

Fixpont iteráció


- ▶ $f(x) = 0$ helyett $x = g(x)$
 - ▶ Pl. mindkét oldalhoz $+x$
- ▶ Iteráció: $x_{k+1} = g(x_k)$
- ▶ Leállás, ha a változás elég kicsi:

$$\left| \frac{x_{k+1} - x_k}{x_{k+1}} \right| < \varepsilon$$

- ▶ Lineáris konvergencia

- ▶ A hiba arányos a g függvény deriváltjával

- ▶ Ha $|g'(x)| > 1$, akkor nő



Newton–Raphson iteráció ★

- ▶ Taylor sor:

$$f(x + \delta) \approx f(x) + f'(x)\delta + \frac{f''(x)}{2}\delta^2 + \dots$$

- ▶ Kis δ esetén a lineáris utáni tagok elhagyhatóak
- ▶ Ebből $\delta = -f(x_k)/f'(x_k)$, és $x_{k+1} = x_k + \delta$
- ▶ Szokásos leállási feltételek (iteráció, relatív hiba)
- ▶ Használható többdimenziós esetben is
- ▶ Négyzetes (másodrendű) konvergencia
 - ▶ De van ahol lassú: ha $f'(x_k) \approx 0$
 - ▶ Ilyenkor instabil is (0-ra kiértékelhetetlen)
- ▶ Kell deriváltfüggvény
- ▶ Kombinálható a kettéosztással
 - ▶ Csak olyankor osztunk,
ha a Newton–Raphson kimenne a keretből

Metszővonal (secant) módszer

- ▶ A derivált közelítése:

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

- ▶ Behelyettesítve a Newton–Raphson módszerbe:

$$x_{k+1} = x_k - \frac{x_{k-1} - x_k}{f(x_{k-1}) - f(x_k)} f(x_k)$$

- ▶ Ez gyakorlatilag a hamis pozíció képlete
 - ▶ De mindig a legújabb két pontot tartjuk meg (Nem pedig amelyek ellentétes előjelűek.)
- ▶ Alternatív módszer: csak az utolsó pont alapján

$$f'(x_k) = \frac{f(x_k + \delta x_k) - f(x_k)}{\delta x_k}$$

- ▶ Kevésbé jó, mert több kiértékelés kell, és instabil

Brent-módszer ★

- ▶ Kombinálja a keretező és nyitott módszereket
 - ▶ Keretező: kettéosztás (ha a nyitott kivenne a keretből)
 - ▶ Nyitott: metszővonal & inverz négyzetes interpoláció
- ▶ Inverz négyzetes interpoláció
 - ▶ Mint a metszővonal módszer, csak egyenes helyett parabolával
 - ▶ „Elforgatott” $x = g(y)$ parabolát illeszt
 - ▶ Így biztosan lesz metszés az x tengellyel
 - ▶ Innen az „inverz” elnevezés
 - ▶ Illesztés Lagrange polinommal ($y_i = f(x_i)$ jelöléssel):

$$g(y) = \frac{(y - y_{k-1})(y - y_k)}{(y_{k-2} - y_{k-1})(y_{k-2} - y_k)} x_{k-2} + \frac{(y - y_{k-2})(y - y_k)}{(y_{k-1} - y_{k-2})(y_{k-1} - y_k)} x_{k-1} + \frac{(y - y_{k-2})(y - y_{k-1})}{(y_k - y_{k-2})(y_k - y_{k-1})} x_k$$

$$\Rightarrow x_{k+1} = \frac{y_{k-1}y_k}{(y_{k-2} - y_{k-1})(y_{k-2} - y_k)} x_{k-2} + \frac{y_{k-2}y_k}{(y_{k-1} - y_{k-2})(y_{k-1} - y_k)} x_{k-1} + \frac{y_{k-2}y_{k-1}}{(y_k - y_{k-2})(y_k - y_{k-1})} x_k$$

Stratégiák polinomokra

- ▶ Osztogatás
 - ▶ Az összes gyök megtalálásához
 - ▶ Ha találunk egy x_0 gyököt, leosztunk $(x - x_0)$ -val
 - ▶ Vigyázat: egyre több hiba csúszik be
- ▶ Muller-módszer
 - ▶ Hasonló a metszővonal módszerhez
 - ▶ Három ponttal kvadratikus interpoláció
 - ▶ Komplex gyökpárokat is megtalál
- ▶ Sajátérték módszer
 - ▶ A sajátértékek a karakt. polinom gyökei
 - ▶ Hatékony algoritmusok vannak a kiszámításukra

$$\begin{bmatrix} -\frac{a_{n-1}}{a_n} & -\frac{a_{n-2}}{a_n} & \dots & -\frac{a_1}{a_n} & -\frac{a_0}{a_n} \\ 1 & 0 & \dots & 0 & 0 \\ 0 & 1 & \dots & 0 & 0 \\ \vdots & & \ddots & & \vdots \\ 0 & 0 & \dots & 1 & 0 \end{bmatrix}$$

Karakt. polinom: $a_n x^n + \dots + a_1 x + a_0$.

Laguerre-módszer

- ▶ Komplex aritmetikát használ
- ▶ Jól működik többszörös gyökökre is
- ▶ Legyen

$$\begin{aligned}
 P_n(x) &= (x - x_1)(x - x_2) \cdots (x - x_n) \\
 \ln |P_n(x)| &= \ln |x - x_1| + \ln |x - x_2| + \cdots + \ln |x - x_n| \\
 \frac{\partial}{\partial x} \ln |P_n(x)| &= \frac{1}{x - x_1} + \frac{1}{x - x_2} + \cdots + \frac{1}{x - x_n} = \frac{P'_n}{P_n} = G \\
 -\frac{\partial^2}{\partial x^2} \ln |P_n(x)| &= \frac{1}{(x - x_1)^2} + \frac{1}{(x - x_2)^2} + \cdots + \frac{1}{(x - x_n)^2} \\
 &= \left(\frac{P'_n}{P_n} \right)^2 - \frac{P''_n}{P_n} = H
 \end{aligned}$$

- ▶ Tegyük fel, hogy $x_0 - x_1 = a$ és $x_0 - x_i = b$ ($i = 2, \dots, n$)
(ahol x_0 az aktuális tippünk) [furcsa ötlet!]

Laguerre-módszer ★

- ▶ Ekkor

$$\begin{aligned}\frac{1}{a} + \frac{n-1}{b} &= G \\ \frac{1}{a^2} + \frac{n-1}{b^2} &= H\end{aligned}$$

- ▶ ...amiből

$$a = \frac{n}{\sqrt{G \pm (n-1)(nH - G^2)}}$$

- ▶ Az előjelet úgy kell megválasztani, hogy a nevező normája nagyobb legyen
- ▶ A következő tipp $x_0 = a$
- ▶ Szokásos leállási feltételek:
 - ▶ Ha elég kicsi a hiba
 - ▶ Ha elég kicsi a változás
 - ▶ Ha túlléptük a maximális iterációs számot

Általános struktúra

- ▶ Solver objektum allokáció:
 - ▶ `gsl_root_f[df]solver_alloc(típus)`
- ▶ Solver paraméterek megadása:
 - ▶ `gsl_root_fsolver_set(solver, f, lower, upper)`
 - ▶ `gsl_root_fdfsolver_set(solver, f, df, guess)`
 - ▶ Függvények: `double (*f)(double x, void *params)`,
`void (*fdf)(double x, void *params, double *f, double *df)`
- ▶ Iteráció (egy iterációs lépés!):
 - ▶ `gsl_root_f[df]solver_iterate(solver)`
 - ▶ Eredmény: `gsl_root_f[df]solver_root(solver)`
 - ▶ Keret: `gsl_root_fsolver_[lower|upper](solver)`
- ▶ Solver objektum felszabadítása:
 - ▶ `gsl_root_f[df]solver_free(solver)`

Leállási tesztek

- ▶ Siker: `GSL_SUCCESS` visszatérési érték, kül.: `GSL_CONTINUE`
- ▶ `gsl_root_test_interval(x_low, x_high, eps_abs, eps_rel)`
 - ▶ Ellenőrzi, hogy az intervallum elég szűk-e
 - ▶ Ha nincsen benne 0 az intervallumban:

$$|x_{\text{low}} - x_{\text{high}}| < \varepsilon_{\text{abs}} + \varepsilon_{\text{rel}} \min(|x_{\text{low}}|, |x_{\text{high}}|)$$

- ▶ Ha benne van:

$$|x_{\text{low}} - x_{\text{high}}| < \varepsilon_{\text{abs}} \quad (\text{mivel } 0 \text{ a minimum absz. az intervallumon})$$

- ▶ `gsl_root_test_delta(x1, x0, eps_abs, eps_rel)`
 - ▶ Ellenőrzi, hogy a változás elég kicsi-e:

$$|x_1 - x_0| < \varepsilon_{\text{abs}} + \varepsilon_{\text{rel}} |x_1|$$

Algoritmusok

- ▶ Keretező módszerek:
 - ▶ Kettéosztás: `gsl_root_fsolver_bisection`
 - ▶ Hamis pozíció: `gsl_root_fsolver_falsepos`
 - ▶ Brent-módszer: `gsl_root_fsolver_brent`
- ▶ Deriváltas módszerek:
 - ▶ Newton–Raphson: `gsl_root_fdfsolver_newton`
 - ▶ Metszővonal: `gsl_root_fdfsolver_secant`
 - ▶ Steffensen: `gsl_root_fdfsolver_steffenson`
 - ▶ A Newton–Raphson módszer változata
- ▶ Többdimenziós módszerek (nem teljes):
 - ▶ Mindenhol `gsl_root` helyett `gsl_multiroot`
 - ▶ Broyden: `gsl_multiroot_fsolver_broyden`
 - ▶ Discrete Newton: `gsl_multiroot_fsolver_dnewton`
 - ▶ Newton–Raphson: `gsl_multiroot_fdfsolver_newton`
 - ▶ Powell: `gsl_multiroot_fdfsolver_hybridsj`

Polinomok GSL-ben


- ▶ Polinom kiértékelés: `gsl_poly_eval(coeff[], len, x)`
 - ▶ `coeff[0]` a konstans tag, a fokszám `len-1`
 - ▶ Komplex együtthatókra `gsl_complex_poly_complex_eval`
- ▶ Deriváltakkal: `gsl_poly_eval_derivs(...)`
- ▶ Gyökkeresés (sajátértékes megoldó, QR-felbontás):
 - ▶ `gsl_poly_complex_workspace_alloc(n)`
 - ▶ `gsl_poly_complex_solve(coeff[], len, w, z)`
 - ▶ `z` egy $2n$ elemű tömb
 - ▶ Felváltva valós és képzetes tagok
 - ▶ `gsl_poly_complex_workspace_free(w)`
- ▶ Speciális esetek:
 - ▶ `gsl_poly_[complex_]solve_quadratic(a, b, c, x0, x1)`
 - ▶ `gsl_poly_[complex_]solve_cubic(b, c, d, x0, x1, x2)`
 - ▶ A főegyüttható 1

Áttekintés

- ▶ Feladat: $f(x) \rightarrow \min$
 - ▶ Maximalizálásnál $-f(x) \rightarrow \min$
 - ▶ Egy megoldás: derivált/gradiens gyökei
- ▶ Lehetnek hozzá kényszerek
 - ▶ Egyenlőségi és egyenlőtlenségi
 - ▶ Speciális eset: lineáris programozás
- ▶ Lokális és globális minimumok
 - ▶ Különböző kezdőértékekkel próbálkozás
 - ▶ Heurisztikák
- ▶ Kényszer nélküli feladat:
 - ▶ Egy- és többdimenziós
 - ▶ Derivált használatával vagy anélkül


[1D] Aranymetszéses keresés ★

- ▶ Kettéosztásos gyökkeresés mintájára
 - ▶ Kell egy keret (x_{low} és x_{high})
- ▶ Aranymetszés aránya: $a : b = a + b : a$
 - ▶ $a = \phi b \Rightarrow \phi = (\sqrt{5} + 1)/2$
 - ▶ $\phi - 1 = \frac{1}{\phi}$; $\phi = [1; 1, 1, \dots]$ lánctört
 - ▶ Fibonacci sorozat, spirál, ötszög stb.
 - ▶ Építészet, festészet, zene stb.
- ▶ $x_1 = x_{\text{low}} + d$ és $x_2 = x_{\text{high}} - d$,
ahol $d = (\phi - 1)(x_{\text{high}} - x_{\text{low}})$
- ▶ Ha $f(x_1) < f(x_2)$, akkor $\Rightarrow x_{\text{low}} = x_2$
- ▶ Ha $f(x_2) < f(x_1)$, akkor $\Rightarrow x_{\text{high}} = x_1$
- ▶ Az aranymetszés miatt az egyik belső érték már ki van értékelve!




[1D] Brent-módszer

- ▶ Hasonló a gyökkereső módszerhez
- ▶ Parabolát illeszt és az aljára lép
- ▶ Elfogadjuk, ha:
 - ▶ A kereten belülre esik
 - ▶ Max. feleannyit lép, mint az előző lépésben
- ▶ Ha nem jó, akkor helyette aranymetszéses lépés
- ▶ Változat: parabola helyett deriváltra metszővonal módszer




[nD] Lejtő szimplex (Nelder–Mead)

- ▶ Szimplex: $n + 1$ pontú alakzat (háromszög, tetraéder stb.)
 - ▶ Legnagyobb fv.értékű pont: x_{high} , szemben levő lap: F_{high}
 - ▶ Hasonlóan x_{low} és második legnagyobb x_{nhigh}
 - ▶ Induló szimplexhez $n + 1$ kezdőérték, pl. x_0 és $x_0 + \lambda e_i$
- ▶ Műveletek:
 - ▶ x_{high} pont F_{high} feletti magasságára szorzó
 - ▶ Tükrözés: -1
 - ▶ Az alpművelet, ezzel kezd az iteráció
 - ▶ Kihúzás: 2
 - ▶ Ha $f(x'_{\text{high}}) < f(x_{\text{low}})$, akkor nyújtjuk
 - ▶ Összehúzás: 0.5
 - ▶ Ha $f(x'_{\text{high}}) > f(x_{\text{nhigh}})$, akkor beszűkítjük
 - ▶ Ha nem segít: F_{low} -t az x_{low} felé (felezés)




[nD] Kereszt-entrópia ★

- ▶ Feltételezünk egy valószínűségi eloszlást a minimumra
 - ▶ Minden dimenzióban külön!
- ▶ Pl. normális eloszlás
 m : várható érték, σ : szórás
- ▶ Ez alapján k mintapont
- ▶ Legjobb (elit) k_e minta
- ▶ Erre illesztünk új eloszlást
- ▶ Relaxáció m -re és σ -ra:
 $\lambda(1 - 1/i)^5$ ahol i az iteráció
- ▶ Nem engedi, hogy
rögtön bezsugorodjon



[nD] MADS (Mesh-Adaptive Direct Search) ★

- ▶ Véletlenszerű pozitív feszítőirányok ($d_0 = -\sum_{i=1}^n d_i$)
- ▶ Sorban ellép, ha jobb (és megpróbál 4x akkora lépni)
- ▶ Utána új irányok/lépésköz (javult: nagyobb, kül: kisebb)



[nD] Powell-módszer

- ▶ Irányonkénti 1D minimalizálás (pl. Brent-módszerrel)
 - ▶ $f(x_0 + \lambda u_i)$ minimalizálása λ szerint
- ▶ Probléma: kiolthatják egymás hatását
 - ▶ u irányú minimumban a gradiens merőleges u -ra
 - ▶ v irányú minimalizálásnál ezt meg akarjuk tartani
 - ▶ Feltétel: $u^T A v = 0$, ahol A az f Hesse-mátrixa
 - ▶ Cél: n lineárisan független, kölcsönösen konjugált irány
- ▶ Módszer:
 1. Induljunk ki a bázisvektorokból: $u_i = e_i$
 2. Minimalizáljunk sorban minden irányban ($\Rightarrow x'_0$)
 3. Legyen $u_i = u_{i+1}$ és $u_n = x'_0 - x_0$
 4. Minimalizáljunk x'_0 -ból kiindulva u_n mentén
 5. Vissza a 2-es ponthoz; n iteráció után az 1-eshez
- ▶ Alternatíva:
 - ▶ u_1 helyett azt az irányt dobjuk ki, amiben a legtöbbet változott

[nD] Konjugált gradiens

- ▶ Jobb, mint a(z ismertebb) *steepest descent* algoritmus
 - ▶ Nem „zavarják” egymást a lépések (mint a Powell-módszernél)
- ▶ Láttuk már lineáris egyenletrendszer megoldására
 - ▶ Most négyzetesen közelített függvény minimalizálására
 - ▶ $f(x) \approx \frac{1}{2}x^T A x - b^T x + c$ a Taylor-sor alapján
 - ▶ Nem ismerjük az A mátrixot $\Rightarrow$ kiváltja az 1D minimalizálás
- ▶ Módszer:
 1. Legmeredekebb irány: $\Delta x_k = -\nabla f(x_k)$
 2. Új irány: $u_k = \Delta x_k + \gamma_k u_{k-1}$, ahol γ_k -ra több képlet is van, pl.

$$\gamma_k^{\text{Fletcher-Reeves}} = \frac{\Delta x_k^T \Delta x_k}{\Delta x_{k-1}^T \Delta x_{k-1}}, \quad \gamma_k^{\text{Polak-Ribière}} = \frac{\Delta x_k^T (\Delta x_k - \Delta x_{k-1})}{\Delta x_{k-1}^T \Delta x_{k-1}}$$

3. 1D keresés x_k -ból u_k mentén ($\Rightarrow x_{k+1}$)

[nD] Kvázi-Newton módszerek

- ▶ Newton–Raphson módszer a gradiensre (A : Hesse-mátrix)

$$x_{k+1} = x_k - A^{-1} \cdot \nabla f(x_k)$$

- ▶ David–Fletcher–Powell (DFP) / Broyden–Fletcher–Goldfarb–Shanno (BGFS)
- ▶ Közelítő inverz Hesse-mátrix számítása: $\lim_{k \rightarrow \infty} H_k = A^{-1}$
 - ▶ Gyakran jobb, mint az igazival számolni
 - ▶ Pozitív definit A kell, hogy csökkenő irányba vigyen
 - ▶ A közelítés mindig szimmetrikus pozitív definit ($H_0 = I$)
- ▶ Nem feltétlenül tesszük meg a teljes Newton-lépést
 - ▶ Ha nem javít eleget, részlépéssel próbálkozunk (backtracking)

$$H_{k+1}^{\text{DFP}} = H_k + \frac{(x_{k+1} - x_k)(x_{k+1} - x_k)^T}{(x_{k+1} - x_k)^T (\nabla f_{k+1} - \nabla f_k)} - \frac{[H_k(\nabla f_{k+1} - \nabla f_k)][H_k(\nabla f_{k+1} - \nabla f_k)]^T}{(\nabla f_{k+1} - \nabla f_k)^T H_k (\nabla f_{k+1} - \nabla f_k)}$$

Lagrange szorzó

- ▶ Feladat: $f(x) \rightarrow \min$ és $g(x) = 0$
- ▶ A $g(x) = 0$ kontúrt bejárva keressük, hol nem változik az $f(x)$
 - ▶ Ha f és g kontúrja (és így gradiense) párhuzamos
 - ▶ Ha f lapos (semmilyen irányban nem változik)
 - ▶ Képlettel: $\nabla f = \lambda \nabla g \Rightarrow \mathcal{L}(x, \lambda) = f(x) - \lambda g(x)$
- ▶ Megoldandó: $\nabla \mathcal{L}(x, \lambda) = 0$
- ▶ 2D Példa: $f(x) = x_1 + x_2$, $g(x) = x_1^2 + x_2^2 - 1$

$$\nabla \mathcal{L}(x, \lambda) = \begin{bmatrix} 1 \\ 1 \\ 0 \end{bmatrix} - \begin{bmatrix} 2\lambda x_1 \\ 2\lambda x_2 \\ x_1^2 + x_2^2 - 1 \end{bmatrix} = 0$$

- ▶ Ebből $x_1 = x_2 = 1/(2\lambda)$, az utolsóba beírva $\lambda = \pm 1/\sqrt{2}$
- ▶ Lehet több kényszer (mindegyikhez külön λ_i)
- ▶ Egyenlőtlenségi kényszerek $\Rightarrow$ Karush–Kuhn–Tucker (KKT)

Lineáris programozás

- ▶ $z = a_{01}x_1 + \dots + a_{0n}x_n = A_0x \rightarrow \max; (x_i \geq 0)$
 - ▶ Kényszerek: $A_i x \leq b_i, A_j x \geq b_j, A_k x = b_k; (b_l \geq 0)$
 - ▶ Normálforma: csak $A_i x = b_i$ kényszerek
 - ▶ Korlátozott normálformához ezen felül
 $\forall i \exists j : a_{ij} > 0 \wedge (\forall k > 0 : a_{kj} \neq 0 \rightarrow k = j)$
 - ▶ Minden lin.prog. feladat átírható korlátozott normálformára
- ▶ A korlátozott normálformájú feladat táblázatba írható:

$$A = \begin{bmatrix} 0 & 2 & -4 & 0 \\ 1 & 6 & -1 & 0 \\ 0 & -3 & 4 & 1 \end{bmatrix}, \quad b = \begin{bmatrix} - \\ 2 \\ 8 \end{bmatrix} \equiv \begin{cases} z &= 2x_2 - 4x_3 \\ x_1 &= 2 - 6x_2 + x_3 \\ x_4 &= 8 + 3x_2 - 4x_3 \end{cases}$$

	b	x_2	x_3
z	0	2	-4
x_1	2	-6	1
x_4	8	3	-4

Szimplex módszer

- ▶ Kiválasztunk egy oszlopot, ami a z sorban pozitív (nő a célfv.)
- ▶ A pivot oszlop negatív elemei kényszerek
 - ▶ Max. növelés: a b oszlopban levő érték / $|a$ negatív érték|
 - ▶ Az a pivot sor, ahol ez az érték a legkisebb ($\Rightarrow$ pivot elem)
 - ▶ Ha nincs negatív érték, akkor bármeddig növelhető
- ▶ A pivot sorral/oszloppal csere:
 1. Pivot sor konstansszorosát hozzáadjuk a többi sorhoz úgy, hogy a pivot oszlop nullázódjon (de ahhoz nem nyúlunk)
 2. Pivot sort és oszlopot a pivot elemmel leosztjuk
 3. A pivot sort negáljuk (kivéve a pivot elemet)

	b	x_2	x_3
z	0	2	-4
x_1	2	-6	1
x_4	8	3	-4

 $\Rightarrow$

	b	x_1	x_3
z	$2/3$	$-1/3$	$-11/3$
x_2	$1/3$	$-1/6$	$1/6$
x_4	9	$-1/2$	$-7/2$

 $\Rightarrow$

$$\begin{cases} z_{\max} &= \frac{2}{3} \\ x_1 &= 0 \\ x_2 &= \frac{1}{3} \\ x_3 &= 0 \\ x_4 &= 9 \end{cases}$$

Korlátozott normálformára váltás

- ▶ Egyenlőtlenségek kiválthatóak plusz változókkal
 - ▶ Pl. $x_1 + 3x_2 \leq 5 \equiv x_1 + 3x_2 + y_1 = 5$ (hiszen $y_1 \geq 0$)
 - ▶ Hasonlóan $x_1 + 3x_2 \geq 5 \equiv x_1 + 3x_2 - y_2 = 5$
- ▶ A „baloldali változó” feltétel is plusz változókkal
 - ▶ Minden egyenletbe beteszünk egy új z_i változót
 - ▶ Ez megváltoztatja a célfüggvényt, kivéve ha $\forall z_i = 0$
 - ▶ Segéd-célfüggvény: $z' = -\sum_i z_i$
- ▶ Első körben a segéd-célfüggvényt maximalizáljuk
 - ▶ z_i -k nullázódnak, kidobjuk $\Rightarrow$ eredeti célfüggvény

	b	x_1	x_2	y_1	y_2
z	0	2	3	0	0
z_1	10	-5	2	-1	0
z_2	3	1	-2	0	-1
z'	-13	2	-3	1	1

$$\Leftrightarrow \begin{cases} 2x_1 + 3x_2 & \rightarrow \max \\ 5x_1 - 2x_2 & \leq 10 \\ -x_1 + 2x_2 & \leq 3 \end{cases}$$

Szimulált hűtés

- ▶ Amikor nem ismerjük igazán a problémateret
- ▶ Cél: kiszabadulás a lokális minimumokból
- ▶ A hőmérséklet (T) szabályozza, mennyire vagyunk bátrak
 - ▶ Kezdetben nagy valószínűséggel lépünk kedvezőtlen irányba
 - ▶ Későbbi iterációkban egyre „konzervatívabbak” leszünk
 - ▶ Elfogadunk egy lépést, ha $e^{-\Delta/(kT)} > R(0,1)$
 - ▶ Δ a függvényérték változása (negatív a jó)
 - ▶ k a Boltzmann-állandónak felel meg
 - ▶ $R(0,1)$ egy véletlenszám 0 és 1 között
- ▶ Számon tartjuk a mindenkori minimumot
- ▶ Problémák:
 - ▶ Honnan jönnek a „rossz” lépések?
 - ▶ Pl. lejtős szimplexnél amikor nem csökken a célfüggvény
 - ▶ Hogyan csökkentjük a hőmérsékletet?
 - ▶ Nagyon problémafüggő...

Optimalizáló algoritmusok

- ▶ Kezelés nagyon hasonló a gyökkereső alrendszerhez
 - ▶ `gsl_[multi]min_f[df]minimizer_*`
- ▶ Szükséges lépések:
 1. Memóriafoglalás (`alloc`)
 2. Függvények és paraméterek beállítása (`set`)
1D: keret, nD: lépéshossz, tolerancia
 3. Ciklusban iterációs lépés (`iterate`) és teszt hívása (`test_*`)
 4. Eredmény lekérdezése (`minimum`), felszabadítás (`free`)
- ▶ 1D:
 - ▶ Aranymetszés: `gsl_min_fminimizer_goldensection`
 - ▶ Brent: `gsl_min_fminimizer_brent`
 - ▶ Brent variáns: `gsl_min_fminimizer_quad_golden`

Optimalizáló algoritmusok

- ▶ nD (derivált nélkül):
 - ▶ Lejtő szimplex:
`gsl_multimin_fminimizer_nmsimplex[2[rand]]`
 - ▶ A 2-es verzió az újabb $O(n)$ implementáció (a régi $O(n^2)$)
 - ▶ A rand variáns a tengelyek helyett random bázissal indul (adott lépéshosszal)
- ▶ nD (deriválttal):
 - ▶ Konjugált gradiens:
`gsl_multimin_fdfminimizer_conjugate_[fr|pr]`
 - ▶ γ a Fletches–Reeves (fr) illetve Polak–Ribière (pr) szerint
 - ▶ Kvázi-Newton:
`gsl_multimin_fdfminimizer_vector_bfgs[2]`
 - ▶ BFGS algoritmus, a 2-es verzió lényegesen hatékonyabb
 - ▶ Steepest descent:
`gsl_multimin_fdfminimizer_steepest_descent`

Lineáris programozás

- ▶ Külön könyvtár: GNU Linear Programming Kit,
<https://www.gnu.org/software/glpk/>
 - ▶ Kézikönyv >150 oldal – itt csak a minimum
- ▶ (De)init: `glp_create_prob()` / `glp_delete_prob(lp)`
- ▶ Optimalizációs irány: `glp_set_obj_dir(lp, GLP_MAX)`
- ▶ Sorok/oszlopok hozzáadása: `glp_add_[rows|cols](lp, n)`
- ▶ Típus: `glp_set_[row|col]_bnds(lp, i, típus, min, max)`
 - ▶ Lehet GLP_FR, GLP_LO, GLP_UP, GLP_DB, GLP_FX
- ▶ Célfüggvény együtthatói: `glp_set_obj_coef(lp, i, x)`
- ▶ Kényszmátrix: `glp_load_matrix(lp, n, i, j, v)`
 - ▶ Ritka mátrixos tárolás: `a[i[k],j[k]]=v[k]`
- ▶ Megoldás: `glp_simplex(lp, NULL)`
- ▶ Eredmény: `glp_get_obj_val(lp)` / `glp_get_col_prim(lp, i)`

Szimulált hűtés

- ▶ Egy függvényhívás: `gsl_siman_solve` – sok paraméter:
- ▶ `const gsl_rng *r` – [random generátor]
- ▶ `void *x0_p` – [kezdő konfiguráció]
- ▶ `double (* Ef) (void *xp)` – [energiafüggvény]
- ▶ `void (* take_step) (gsl_rng *r, void *xp, double step_size)`
– [random lépés az xp állapotból, maximum step_size távolságra]
- ▶ `double (* distance) (void *xp, void *yp)` – [két állapot távolsága]
- ▶ `void (* print_position) (void *xp)` – [kiírja az adott állapotot]
- ▶ `void (* copyfunc) (void *source, void *dest)` – [állapotmásolás]
- ▶ `void (* copy_constructor) (void *xp)` – [másolással új állapot]
- ▶ `void (* destructor) (void *xp)` – [állapot törlése]
- ▶ `size_t element_size` – [állapot mérete]
- ▶ `gsl_siman_params_t params` – [beállítások]
- ▶ Eredmény az `x0_p` paraméterben

Szimulált hűtés

- ▶ Random generátor interface: `gsl_rng_env_setup()`, utána `gsl_rng_alloc(gsl_rng_default)` / `gsl_rng_free()`
- ▶ Ha a `print_position` nem NULL, akkor debug információt ír
 - ▶ `#iter`, `#eval`, `T`, `position`, `energy`, `best energy`
- ▶ Az állapotok tárolása lehet fix méretű vagy dinamikus
- ▶ Fixnél a `copyfunc`, `copy_constructor`, `destructor` = NULL
- ▶ Dinamikusnál az `element_size` értéke 0
- ▶ A `gsl_siman_params_t` struktúra:
 - ▶ `int n_tries` – [hány pontot nézzen lépésenként]
 - ▶ `int iters_fixed_T` – [egy-egy hőmérséklet hány iteráció]
 - ▶ `double step_size` – [maximum lépéshossz]
 - ▶ `double k`, `t_initial`, `mu_t`, `t_min` – [hűtési paraméterek]
 - ▶ $T \rightarrow T/\mu_T$, ahol μ_T kicsit nagyobb 1-nél

Áttekintés

- ▶ Feladat:

$$I = \int_a^b f(x) dx$$

- ▶ Differenciálegyenletként:


$$I = y(b), \quad \frac{dy}{dx} = f(x), \quad y(a) = 0$$

- ▶ Ha a függvény nagyon egyenetlen, jó ilyen módszert használni
 - ▶ $\Rightarrow$ Majd a differenciálegyenleteknél
- ▶ Cél: minél pontosabban, minél kevesebb kiértékeléssel
- ▶ Választható rendű megoldások, pl. Romberg-integrálás
 - ▶ Magasabb rend $\rightarrow$ (általában) pontosabb
- ▶ Többdimenziós integrálok, pl. Monte-Carlo integrálás
- ▶ Függvényapprox. módszerek, pl. Clenshaw–Curtis kvadratúra

Newton–Cotes formulák

- ▶ Adott $x_0, x_1, \dots, x_n, x_{n+1}$ egyenletes osztás ($x_i = x_0 + ih$)
- ▶ Ezekben ismert a függvényérték $f_i = f(x_i)$
- ▶ Zárt formula: használja a szélső értékeket
- ▶ Trapéz-szabály:

$$\int_{x_1}^{x_2} f(x) dx = h \left[\frac{1}{2} f_1 + \frac{1}{2} f_2 \right] + O(h^3 f''(\hat{x}))$$




Newton–Cotes formulák

- ▶ Simpson-szabály:

$$\int_{x_1}^{x_3} f(x) dx = h \left[\frac{1}{3}f_1 + \frac{4}{3}f_2 + \frac{1}{3}f_3 \right] + O(h^5 f^{(4)}(\hat{x}))$$

- ▶ Simpson $\frac{3}{8}$ -szabály:

$$\int_{x_1}^{x_4} f(x) dx = h \left[\frac{3}{8}f_1 + \frac{9}{8}f_2 + \frac{9}{8}f_3 + \frac{3}{8}f_4 \right] + O(h^5 f^{(4)}(\hat{x}))$$



Trapéz-módszer ★

- ▶ Kiterjesztett trapéz-szabály:

$$\int_{x_1}^{x_n} f(x) dx = h \left[\frac{1}{2} f_1 + f_2 + f_3 + \cdots + f_{n-1} + \frac{1}{2} f_n \right] + O \left(\frac{(b-a)^3 f''(\hat{x})}{n^2} \right)$$

- ▶ Kiterjesztett Simpson-szabály:

$$\int_{x_1}^{x_n} f(x) dx = h \left[\frac{1}{3} f_1 + \frac{4}{3} f_2 + \frac{2}{3} f_3 + \frac{4}{3} f_4 + \cdots + \frac{2}{3} f_{n-2} + \frac{4}{3} f_{n-1} + \frac{1}{3} f_n \right] + O \left(\frac{f^{(4)}(\hat{x})}{n^4} \right)$$

- ▶ Ötlet: dinamikus sűrítés
- ▶ Ha S_k a kiterjesztett trapéz-szabály $2^k + 1$ pontra
 $\Rightarrow \frac{4}{3} S_{k+1} - \frac{1}{3} S_k$ a kiterjesztett Simpson-szabály!



Romberg-integrálás

- ▶ A trapéz-módszer kiterjesztése tetszőleges rendre
- ▶ k trapéz-módszert kombinálva eltünteti a hibatagokat
 - ▶ Csak $O(1/n^{2^k})$ marad
 - ▶ Az előző algoritmus a $k = 2$ eset
- ▶ Ugyanúgy tovább sűríthető
 - ▶ Tárolni kell az előző $k - 1$ trapéz-módszeres eredményt
- ▶ Richardson-elv:
 - ▶ Polinomiális interpoláció (h_i, S_i) párokra
 - ▶ Mivel $\lim_{i \rightarrow \infty} h_i = 0$, ezért 0-ban értékeljük ki
 - ▶ Itt (h_i^2, S_i) párok, mert a trapéz-módszer hibatagjában csak páros hatványokon szerepel a h
 - ▶ Pl. $k = 2$ esetén $(1, S_i)$ és $(\frac{1}{4}, S_{i+1})$
 - ▶ Lineáris interpoláció $\Rightarrow \frac{4}{3}S_{i+1} - \frac{1}{3}S_i$

Nyílt módszerek

- ▶ Hasznos, amikor nem tudjuk kiértékelni a végpontokat
 - ▶ Szingularitás miatt, vagy mert végtelen
 - ▶ Végtelennél a változót a reciprokára cseréljük:

$$\int_a^b f(x) dx = \int_{1/b}^{1/a} f\left(\frac{1}{t}\right) \frac{1}{t^2} dt$$

- ▶ Kiterjesztett középpont-módszer:

$$\int_{x_1}^{x_n} f(x) dx = h [f_{3/2} + f_{5/2} + f_{7/2} + \cdots + f_{n-3/2} + f_{n-1/2}] + O\left(\frac{f'(\hat{x})}{n^2}\right)$$

- ▶ Ez is inkrementálisan számítható $\Rightarrow$ triplázni kell
 - ▶ Minden iterációban 3^{k-1} új pontot adunk hozzá
- ▶ A Romberg-interpoláció is ugyanúgy használható

Gauss-kvadratúra

- ▶ A kiértékelés helyét a módszerre bízunk
 - ▶ Több szabadságfok $\rightarrow$ magasabb rend
- ▶ Általános képlet:

$$\int_a^b W(x)f(x) dx \approx \sum_{i=1}^n w_i f(x_i)$$

- ▶ Adott W -re és n -re található w_i és x_i
- ▶ Gauss–Legendre kvadratúra: $W(x) = 1$, $a = -1$, $b = 1$
 - ▶ Különböző n -ekre táblázatok w_i -re és x_i -re
- ▶ Sok más változat is létezik:
 - ▶ Pl. Gauss–Csebisev: $W(x) = 1/\sqrt{1-x^2}$, $a = -1$, $b = 1$
 - ▶ Pl. Gauss–Hermite: $W(x) = e^{-x^2}$, $a = -\infty$, $b = \infty$

Clenshaw–Curtis kvadratúra ★

- ▶ Csebisev-approximáció ($x \in [-1, 1]$):

$$f(x) \approx \sum_{k=0}^{n-1} c_k T_k(x) - \frac{1}{2}c_0, \quad c_k = \frac{2}{n} \sum_{i=1}^n f(x_i) T_k(x_i)$$

- ▶ $T_n(x) = \cos(n \arccos x)$ az n -edfokú Csebisev-polinom
- ▶ $T_0(x) = 1$, $T_1(x) = x$, és $T_{n+1}(x) = 2xT_n(x) - T_{n-1}(x)$
- ▶ $x_i = \cos((2i-1)\pi/2n)$ a $T_n(x)$ polinom gyökei
- ▶ A c_i együtthatók gyorsan csökkennek, ha sima a függvény


- ▶ Az integrál képlete:

$$\int_a^b f(x) dx \approx (b-a) \left[\frac{1}{2}c_0 - \frac{1}{3}c_2 - \frac{1}{15}c_4 - \cdots - \frac{1}{(2k+1)(2k-1)}c_{2k} - \cdots \right]$$

- ▶ Elég addig kiértékelni, amíg c_{2k} nem lesz elhanyagolható

Stratégiák n dimenzióban

- ▶ A dimenzióval exponenciálisan nő a kiértékelések száma
- ▶ Az $n - 1$ dimenziós határ nagyon bonyolult lehet
 - ▶ Nem feltétlenül konvex, vagy akár összefüggő
- ▶ Ha sima a függvény, és egyszerű a határ:
 - ▶ Egymásba ágyazott 1D integrálások
 - ▶ Többdimenziós Gauss-kvadratura
- ▶ Egyébként:
 - ▶ Monte-Carlo integrálás
 - ▶ Statisztikai alapú
 - ▶ Lassan konvergál




Monte-Carlo integrálás

- ▶ Kiértékeljük a függvényt N random pontban (x_i)
- ▶ Tétel:

$$\int f dV \approx V \langle f \rangle \pm V \sqrt{\frac{\langle f^2 \rangle - \langle f \rangle^2}{N}}, \quad \langle f \rangle = \frac{1}{N} \sum_{i=1}^N f(x_i)$$

ahol V a térfogat, amin integrálunk

- ▶ A $\pm$ tag csak szórás (de a hiba nem feltétlenül normáeloszlású)
- ▶ Bonyolult határfelülelnél berakjuk egy nagyobb dobozba
 - ▶ A kiegészített részeken a függvényérték legyen 0



Mintavételezés

- ▶ Kvázi-random mintavételezés:
 - ▶ Alacsony diszkrepanciájú sorozattal (pl. Halton-/Sobol-sorozat)
- ▶ Fontosság szerinti mintavételezés:
 - ▶ Több mintapont ott, ahol a függvényérték nagy
 - ▶ Ha p a sűrűség (random esetben $p = 1/V$):

$$\int f dV \approx \left\langle \frac{f}{p} \right\rangle \pm \sqrt{\frac{\langle f^2/p^2 \rangle - \langle f/p \rangle^2}{N}}$$

- ▶ Réteges mintavételezés:
 - ▶ Részekre osztjuk a teret, mindegyikben külön integrálunk
 - ▶ Az összeg szórása csak kisebb lehet
 - ▶ Csak 2-3 dimenzióban hasznos
 - ▶ Keverhető a fontosság szerinti mintavételezéssel

QuadPack

- ▶ A kvadratúra alrendszer a QuadPack könyvtárat használja
- ▶ Elnevezés: $Q(N|A)(G|W)(S|P|I|O|F|C)$
 - ▶ N: nem adaptív, A: adaptív
 - ▶ G: általános függvény, W: súlyozott függvény
 - ▶ P: szinguláris pontok megadhatóak; I: végtelen határok stb
- ▶ Megadható ε_{abs} és ε_{rel}
- ▶ Nem adaptív:
 - ▶ `gsl_integration_qng`: Gauss–Kronrod
 - ▶ 10 / 21 / 43 / 87-ponttal (automatikusan)
- ▶ Adaptívakhoz workspace:
 - ▶ `gsl_integration_workspace_alloc()` /
`gsl_integration_workspace_free(w)`

QuadPack

- ▶ Adaptív módszerek (nem teljes lista):
 - ▶ `gsl_integration_qag`: Gauss–Kronrod
 - ▶ 15 / 21 / 31 / 41 / 51 / 61 ponttal, választható
 - ▶ `gsl_integration_qagp`: Gauss–Kronrod 21 módosítása
 - ▶ `gsl_integration_qaws`: Clenshaw–Curtis 25 módosítása
 - ▶ Csebisev-táblázatot kell hozzá foglalni:
`gsl_integration_qaws_table_alloc` stb.
- ▶ Gauss–Legendre kvadratúra:
 - ▶ `gsl_integration_glfixed_table_alloc(n)`
 - ▶ `gsl_integration_glfixed(f, a, b, table)`
 - ▶ `gsl_integration_glfixed_point(f, a, b, i, xi, wi, table)`
[lekérdezi az i-edik abszcisszát és súlyt]
 - ▶ `gsl_integration_glfixed_free(table)`

Áttekintés

- ▶ Feladat:

$$\frac{dy_i}{dx} = f_i(x, y_1, \dots, y_n)$$

- ▶ f_i ismert, y_i -t akarjuk meghatározni valahol
- ▶ Magasabb rendű feladatok visszavezethetők elsőrendűre
 - ▶ Új változókat kell bevezetni (ált. az eredetiek deriváltjai)
- ▶ Kezdeti érték probléma:
 - ▶ Minden y_i ismert egy x_s pontban
 - ▶ Keressük az értéket egy x_f pontban
 - ▶ Pl. Euler, Runge–Kutta stb.
- ▶ Peremérték-probléma (2 pontra):
 - ▶ A feltételek egy része az x_s -re, másik az x_f -re van megadva
 - ▶ Pl. lövő módszer stb.

Euler- & Runge–Kutta módszer

► Nézzük a $\frac{dy}{dx} = f(x, y)$ feladatot

► Euler-módszer:

$$y_{n+1} = y_n + hf(x_n, y_n) + O(h^2)$$



ahol $x_{n+1} = x_n + h$, és y_n ismert

► Runge–Kutta midpoint módszer:

$$k_1 = hf(x_n, y_n)$$

$$k_2 = hf\left(x_n + \frac{1}{2}h, y_n + \frac{1}{2}k_1\right)$$


$$y_{n+1} = y_n + k_2 + O(h^3)$$



Negyedrendű Runge–Kutta módszer ★

$$\begin{aligned}k_1 &= hf(x_n, y_n) \\k_2 &= hf\left(x_n + \frac{1}{2}h, y_n + \frac{1}{2}k_1\right) \\k_3 &= hf\left(x_n + \frac{1}{2}h, y_n + \frac{1}{2}k_2\right) \\k_4 &= hf(x_n + h, y_n + k_3) \\y_{n+1} &= y_n + \frac{1}{6}k_1 + \frac{2}{6}k_2 + \frac{2}{6}k_3 + \frac{1}{6}k_4 + O(h^5)\end{aligned}$$


- ▶ A leggyakrabban használt KDE megoldó
- ▶ Ha f nem használja y -t, akkor ez a Simpson-szabály



Adaptív lépésközű Runge–Kutta módszer

- ▶ A sima (polinommal jól közelíthető) részen nagyobb lépések
 - ▶ Ehhez ismerni kéne a tényleges hibát
- ▶ Negyedrendű RK-val lépésduplázás:
 - ▶ Minden lépést 2x: egy darabban ill. két feleakkora lépésben
 - ▶ Egy lépés 4 kiértékelés, de a kezdő ugyanaz $\Rightarrow$ összesen 11
 - ▶ Ez $11/8=1.375$ plusz munka
 - ▶ Az egyik hibája $(2h)^5$, a másiké $2h^5$
 - ▶ A két eredmény különbsége (Δ) jó hibabecslés
 - ▶ Δ -t akarjuk szinten tartani (pl. $\lambda = 0.9$, $\mu = 0.2$, $\sigma = 4$):

$$h \rightarrow h \cdot \lambda \cdot \min(\max((\varepsilon/\Delta)^\mu, 1/\sigma), \sigma)$$



Gragg–Bulirsch–Stoer módszer

- ▶ A módosított midpoint módszer Richardson-extrapolációja
 - ▶ Kiértékelés egyre kisebb h értékekkel
 - ▶ Polinomillesztés h^2 felett, és kiértékelés $h^2 = 0$ -ban
 - ▶ Adaptív lépésköz itt is alkalmazható
- ▶ Módosított midpoint módszer:

$$z_0 = y(x)$$

$$z_1 = z_0 + hf(x, z_0)$$

$$z_{i+1} = z_{i-1} + 2hf(x + ih, z_i)$$

$$y(x + nh) = \frac{1}{2} [z_n + z_{n-1} + hf(x + nh, z_n)] + O(nh^3)$$


- ▶ Csak ≈ 1 kiértékelés lépésenként (másodrendű RK-val 2)

Predikciós–korrekciós módszerek

- ▶ Heun-módszer: Euler-módszer alapján
- ▶ Sima Euler-módszer: $y_{n+1}^0 = y_n + hf'_n = y_n + hf(x_n, y_n)$
- ▶ Ez alapján végderivált: $y'_{n+1} = f(x_{n+1}, y_{n+1}^0)$
- ▶ A két derivált átlagával extrapolálunk:

$$y_{n+1} = y_n + h \cdot \frac{y'_n + y'_{n+1}}{2}$$

- ▶ Az utolsó két lépés iterálható (új végderivált, új átlag, ...)



Lövő módszer

- ▶ Probléma: nincs elég információnk a kezdőpontról
- ▶ Megoldásra iterációs módszerek
- ▶ Célbalövés: a nem ismert paramétereket randomizáljuk, és így extrapolálunk a túloldalra
 - ▶ Sokszor tudunk jobbat, mint a random
 - ▶ Pl. magasabb deriváltak törlésére bevezetett deriváltak helyettesítő változó értékére differenciahányados
- ▶ A végponti határfeltétel hibáját akarjuk nullázni
 - ▶ n dimenziós gyökkeresési probléma: Newton–Raphson
 - ▶ az ismeretlen kezdeti paraméterek a változók
- ▶ Alternatíva:
 - ▶ Kétoldalról indítjuk, és középen sima találkozást akarunk

Differenciálegyenlet alrendszer

- ▶ Négy fajta függvényt szolgáltat:
 - ▶ Lépő függvény (`gsl_odeiv2_step_*`)
 - ▶ Egy lépést hajt végre
 - ▶ Adaptív lépésköz kontrolláló (`gsl_odeiv2_control_*`)
 - ▶ Több típus (az adaptív algoritmustól függően)
 - ▶ Különbféle beállítások (pl. ϵ_{abs} , ϵ_{rel} stb.)
 - ▶ Evolúciós függvény (`gsl_odeiv2_evolve_*`)
 - ▶ A lépő és kontrolláló függvényt hívja
 - ▶ Megfelelően változtatja a lépésközt
 - ▶ Meghajtó függvény (`gsl_odeiv2_driver_*`)
 - ▶ Ez kezel mindent, ez a fő felhasználói interfész
 - ▶ `..._alloc_KONTROLLER_new` / `..._free`
 - ▶ `..._apply(driver, x0, xn, y0[])`

Algoritmusok

- ▶ Mindegyik típus neve `gsl_odeiv2_step_*` alakú
- ▶ `_rk2`: Runge–Kutta (másodrendű)
- ▶ `_rk4`: Runge–Kutta (negyedrendű, adaptív)
- ▶ `_rk45`: Runge–Kutta–Fehlberg (adaptív RK verzió)
- ▶ `_rkck`: Runge–Kutta Cash–Karp (adaptív RK verzió)
- ▶ `_rk8pd`: Runge–Kutta Prince–Dormand (adaptív RK verzió)
- ▶ `_rk[124]imp`: Implicit Gauss Runge–Kutta (1,2 és 4-edrendű)
- ▶ `_bsimp`: [Gragg–]Bulirsch–Stoer
- ▶ `_msadams`: multistep Adams (predikciós-korrekción módszer)
- ▶ `_msbdf`: multistep BDF (predikciós-korrekción módszer)
 - ▶ BDF = Backward Differentiation Formula