

Statistične simulacije

- 1 Uvod
- 2 Generatorji naključnih števil
- 3 Primeri simulacij tipa Monte Carlo
 - Računanje števila π
 - Računanje določenega integrala
- 4 Naključni prehodi

- Nekateri problemi so **preveč kompleksni**, da bi jih obravnavali analitično. Uporabimo lahko **simulacije**
 - ▶ Pretok prometa v križišču.
 - ▶ Simulacija pojavov, ki jih v naravi ni mogoče (dobro) spremljati: udar strele, vulkanski izburuh, tornado, poplava, ...
 - ▶ Poenostavljene simulacije ekonomsko dragih projektov (vesoljske raziskave, raziskave v kemiji, ...).
 - ▶ Simulacije iger z velikim številom dejavnikov vpliva.

- Simulacija je umetno generiranje podatkov, ki mu sledi oblikovanje modela in nastavljanje parametrov.
- Kritična presoja rezultatov simulacije potrди (vsaj deloma) model, ali ga ovrže in narekuje njegove spremembe.
- Večinoma je pomembno, da so podatki generirani naključno.
- Zato imajo odločilni pomeni **generatorji naključnih števil**.

Primer

Verjetnost meta šestice na klasični igralni kocki zlahka ocenimo statistično. Generiramo N naključnih metov kocke in preštejemo število metov šestice (n_6). Statistična verjetnost p_6 meta šestice je torej približno

$$p_6 \approx \frac{n_6}{N}.$$

Oceno še izboljšamo, če poskus ponovimo večkrat in za rezultat vzamemo povprečje.

- Očitno pomembno vlogo igra **naključno generiranje podatkov**.

Generatorji naključnih števil

Primer

Ista verzija programa Matlab (od verzije 7.4 naprej), bo na vseh računalnikih kot rezultat ukaza `rand(1)` takoj po zagonu vrnila `0.8147`. To naj bi bilo naključno število med 0 in 1???

- Računalniki so deterministični, zato lahko generirajo le **psevdonaključna števila**.
- To pomeni, da so “naključna” števila določena z nekimi začetnimi parametri.
- Njapogosteje se uporabljajo **multiplikativni kongruenčni algoritmi**.

- **Lehmerjev algoritem:** podani so celoštevilski parametri a, c in m ter začetna vrednost x_0 . Tvorimo zaporedje števil

$$x_{k+1} = a x_k + c \pmod{m}, \quad k = 0, 1, \dots$$

- Števila lahko potem z deljenjem z m še normiramo na $[0, 1)$.
- Pri primerno izbranih parametrih se zdi zaporednje “naključno”.
- Sestavljeno je seveda iz končnega števila možnih vrednost, kvečjemu m .

Primer

Če za parametre izberemo $a = 13$, $c = 0$, $m = 31$ in $x_0 = 1$, dobimo zaporedje,

$$1, 13, 14, 27, 10, 6, 16, 22, \dots,$$

oziroma normirano na $[0, 1)$

$$0.0323, 0.4194, 0.4516, 0.8710, 0.3226, 0.1935, 0.5161, 0.7097, \dots$$

Lahko se prepričamo, da ima zaporedje periodo 30.

Primer

Med prvimi primeri uprabe tega generatroja je bil IBM v šestdesetih letih prejšnjega stoletja (t.i. Scientific Subroutine Package (SPS)). Izbrali so parametre $a = 65539$, $c = 0$ in $m = 2^{31}$. Ostanek se v 32 bitni dolžini preprosto računa, obenem pa je $a = 2^{16} + 3$, kar olajša računanje množenja. V takratni dobi je bil to zelo pomembno zaradi hitrosti računanja. Toda izbira ima tudi nezaželjene posledice. Ker je (vse po modulu 2^{31})

$$\begin{aligned}x_{k+2} &= \left(2^{16} + 3\right) x_{k+1} = \left(2^{16} + 3\right)^2 x_k \\ &= \left(2^{32} + 6 \cdot 2^{16} + 9\right) x_k \\ &= \left[6 \left(2^{16} + 3\right) - 9\right] x_k.\end{aligned}$$

Torej je $x_{k+2} = 6 x_{k+1} - 9 x_k$, kar pomeni, da so tri zaporedna "naključna" števila povezana.

- Matlab je dolgo uporabljal Lehmerjev algoritem s parametri $a = 7$, $c = 0$ in $m = 2^{31} - 1$.
- Generira normirana števila med 0.00000000046566 in 0.99999999953434 s periodo $m - 1$.
- Kljub temu, da dobimo več kot 10^9 psevdonaključnih števil, je to za današnje hitrosti računalnikov premalo.
- Matlab je zato od verzije 5.0 do 7.3 uporabljal algoritem, ki temelji na izsledkih Georgea Marsgalie.
- Od verzije 7.4 naprej pa uporablja Mersenne Twisterjev algoritem. Za podrobnosti si oglejte `help rand` ali stran <http://www.math.sci.hiroshima-u.ac.jp/m-mat/MT/emt.html>

- Očitno je pri izbiri parametrov a , c in m vse določeno z x_0 .
- Številu x_0 rečemo **seme**.
- Matlab dovoljuje določitev semena pri posameznih generatorjih. Izberemo ga denimo iz računalniškega časa (clock).
- Obstajajo pa tudi generatorji, ki temeljijo na popolnoma drugačnih osnovah, recimo na fizikalnih pojavih: žarki sevanja, digitaliziran hrup, ...
- Vsi generatorji naključnih števil se ponavadi testirajo s standardnimi statističnimi testi, ki "ocenijo naključnost" generatorja.

Računanje števila π

Primer

Naključno izbiramo pare števil (x, y) v kvadratu $[0, 1] \times [0, 1]$. Označimo z N število vseh izbir, s K pa število tistih izbir, za katere je $x^2 + y^2 \leq 1$. Pri predpostavki, da so števila "naključna", očitno velja

$$\frac{K}{N} \approx \frac{\pi/4}{1},$$

Torej je

$$\pi \approx \frac{4K}{N}.$$

Primer

Prejšnji primer lahko posplošimo v d dimenzij. Izbirajmo sedaj d -terice naključnih števil med -1 in 1 , torej $(x_1, x_2, \dots, x_d) \in [-1, 1]^d$. Spet naj bo N število vseh izbir, K pa število tistih, za katere je $x_1^2 + x_2^2 + \dots + x_d^2 \leq 1$ (točka (x_1, x_2, \dots, x_d) leži v enotski d -dimenzionalni krogli v \mathbb{R}^d). Volumen d -dimenzionalne krogle je

$$V_d = \frac{\pi^{\frac{d}{2}}}{\Gamma\left(\frac{d}{2} + 1\right)},$$

kjer je Γ Eulerjeva gama funkcija. Za sode dimenzije $d = 2k$ se formula poenostavi v $V_d = \pi^k / k!$. Ker je volumen kocke $[-1, 1]^d$ enak 2^d , je ocena za π torej

$$\pi \approx \left(2^d \Gamma\left(\frac{d}{2} + 1\right) \frac{K}{N} \right)^{\frac{2}{d}}.$$

Primer

Oglejmo si še nekoliko bolj zapleteno simulacijo, *Buffonovo iglo*. Problem je bil prvič zastavljen leta 1777.

Na "neskončnem" papirju so zarisane vzporedne vodoravne črte na razdalji 1. Iglo dolžine 1 vržemo na papir. Kolikšna je verjetnost p , da bo igla presekala kakšno od črt?

Če verjetnost p izračunamo in naredimo simulacijo z N meti, od katerih jih K preseka kakšno od črt, potem velja

$$p \approx \frac{K}{N}.$$

Izkaže se, da je $p = 2/\pi$, za to je

$$\pi \approx 2 \frac{N}{K}.$$

Kaj pa dva preostala primera, ko je dolžina igle manjša kot razdalja med črtami, ali ko je dolžina igle večja od razdalje med črtami?

Računanje določenega integrala

- Numerično želimo izračunati integral

$$\int_a^b f(x)dx.$$

- Uporabimo lahko kakšnega izmed množice kvadraturenih pravil:
 - ▶ trapezno pravilo,
 - ▶ Simpsonovo pravilo,
 - ▶ Gauss-Legendreovo pravilo,
 - ▶ ...
- Lahko pa integral približno določimo s simulacijo.

Metoda "zadeni ali zgreši"

- Predpostavimo, da je $0 \leq f(x) \leq M$, $x \in [a, b]$. (Kaj če ni?)
- Izberemo N naključnih točk $(x, y) \in [a, b] \times [0, M]$.
- Denimo, da je K točk takih, za katere je $y \leq f(x)$.
- Potem je

$$\frac{K}{N} \approx \frac{\int_a^b f(x) dx}{(b-a)M}.$$

Torej je

$$\int_a^b f(x) dx \approx (b-a)M \frac{K}{N}.$$

Metoda “povprečne vrednosti”

- Izkoristimo dejstvo o povprečni vrednosti

$$f(\xi) = \frac{1}{b-a} \int_a^b f(x) dx, \quad \xi \in [a, b].$$

- Če interval $[a, b]$ razdelimo na N enakih podintervalov širine $h := (b - a)/N$, je na primer

$$\int_a^b f(x) dx \approx h \sum_{i=1}^N f(x_i), \quad x_i = a + (2i - 1)h/2, \quad i = 1, 2, \dots, N.$$

- Namesto, da bi točke izbirali enakomerno, jih izbiramo **naključno** na $[a, b]$.
- Tako za vsak nabor N naključnih točk x_i dobimo oceno

$$\int_a^b f(x) dx \approx h \sum_{i=1}^N f(x_i).$$

- Metodo zlahka posplošimo na večkratne integrale:

$$\int_{a_1}^{b_1} \int_{a_2}^{b_2} \cdots \int_{a_d}^{b_d} f(x_1, x_2, \dots, x_d) dx_d dx_{d-1} \cdots dx_1.$$

- Pri klasični intergaciji izberemo N_i naključnih točk $\xi_{i,j}$, $j = 1, 2, \dots, N_i$ na $[a_i, b_i]$, $i = 1, 2, \dots, d$ in izračunamo približek za integral

$$\frac{(b_1 - a_1) \cdots (b_d - a_d)}{N_1 \cdots N_d} \sum_{i_1=1}^{N_1} \sum_{i_2=1}^{N_2} \cdots \sum_{i_d=1}^{N_d} f(\xi_{1,i_1}, \dots, \xi_{d,i_d}).$$

- V smislu metode Monte Carlo pa bi večkratni integral lahko izračunali tudi z izborom N naključnih točk v domeni $[a_1, b_1] \times \cdots \times [a_d, b_d]$, namreč

$$\frac{(b_1 - a_1) \cdots (b_d - a_d)}{N} \sum_{i=1}^N f(x_{1,i}, x_{2,i}, \dots, x_{d,i}).$$

- Pri klasični numerični integraciji moramo v vsaki koordinatni smeri izbrati vsaj nekaj točk. Njihovo število raste kot $N_1 N_2 \cdots N_d$.
- Pri metodi Monte Carlo pa N raste neodvisno od d .
- Pokazati se da, da v tem primeru napaka (verjetnostno) pada z \sqrt{N} neodvisno od d .

