

计算物理 Date

• 蒙特卡洛方法

• 布丰投针实验：一组平行线相距 S ，投掷针长度 $l=S$

相交概率 $\frac{l \cdot |\cos \alpha|}{S} = |\cos \alpha|$ α : 针与平行线垂直方向夹角

$$\frac{1}{\pi} \int_0^{\pi} |\cos \alpha| d\alpha = \frac{2}{\pi}$$

在 N 次投针中，有 M 次与平行线相交

$$\pi \approx \frac{2N}{M}$$

• 线性同余法 (产生伪随机数)

运算 $A=B \pmod{M}$ 表示 A 等于 B 被 M 整除后的余数

$$\begin{cases} X_{n+1} = (aX_n + c) \pmod{m} \\ X_n = X_n / m \end{cases}$$

a, c, X_0, m 为大于 0 的整数

分别叫作乘子, 增量, 初值, 模.

一般 X_0 任选

$$a = 4q + 1, c = 2p + 1 \quad (p, q \text{ 正整数})$$

$\begin{cases} \text{混合同余法 } c \neq 0 \\ \text{乘同余法 } c = 0 \end{cases}$

• 伪随机数统计检验

(a) 均匀性检验: 每个子区间内个数 N_i , 期望 $\frac{N}{k}$, 统计误差 $\sqrt{\frac{N}{k}}$ 服从泊松分布

$$\text{构造卡方统计量 } \chi^2 = \sum_{i=1}^k \frac{(N_i - \frac{N}{k})^2}{\frac{N}{k}} \text{ 检验均匀性}$$

服从 $\chi^2_{(k-1)}$ 分布

(b) 独立性检验: 分为两列 $\{X_1, X_3, \dots, X_{2n-1}\}, \{X_2, X_4, \dots, X_{2n}\}$

分别设为二位散点的 $x-y$ 坐标值, 将二位区域划分成 k^2 小格子

$$\chi^2 = \sum_{i,j=1}^k \frac{(N_{ij} - \frac{N}{k^2})^2}{\frac{N}{k^2}} \text{ 服从 } \chi^2_{(k-1)^2} \text{ 分布}$$

• 随机抽样

• 离散变量的直接抽样 (例: 光子与物质相互作用)

• 连续变量的直接抽样

★ 例: 指数分布

$$F(x) = \int_{-\infty}^x f(x) dx = 1 - e^{-\lambda x}$$

$$f(x) = \begin{cases} \lambda e^{-\lambda x} & x > 0, \lambda > 0 \\ 0 & \text{其他} \end{cases}$$

$$\xi = F(\eta) = 1 - e^{-\lambda \eta}$$

ξ 为 $[0, 1]$ 随机数

$$\Rightarrow \eta = -\frac{1}{\lambda} \ln \xi \quad (-\frac{1}{\lambda} \ln(1-\xi))$$

($1-\xi$ 同上)

同理

• 变换抽样法：对 $f(x,y)$ 的随机变量 η, δ 抽样，如果已掌握 $g(u,v)$ 的随机变量 η', δ' 的抽样方法，则寻找变换：

$$\begin{cases} x = g_1(u,v) \\ y = g_2(u,v) \end{cases} \quad g_1, g_2 \text{ 反函数存在} \Rightarrow \begin{cases} u = h_1(x,y) \\ v = h_2(x,y) \end{cases}$$

则 $f(x,y) = g(h_1(x,y), h_2(x,y)) |J|$ $|J| = \begin{vmatrix} \frac{\partial x}{\partial u} & \frac{\partial x}{\partial v} \\ \frac{\partial y}{\partial u} & \frac{\partial y}{\partial v} \end{vmatrix}$ Jacobi 行列式

★ 例：正态分布 $f(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left\{-\frac{(x-\mu)^2}{2\sigma^2}\right\}$

只考虑标准正态分布即可 $f(x) = \frac{1}{\sqrt{2\pi}} \exp\left\{-\frac{x^2}{2}\right\}$ 则 $t = \sigma x + \mu$ 满足任意正态分布

$$\begin{cases} x = \sqrt{-2 \ln u} \cos(2\pi v) \\ y = \sqrt{-2 \ln u} \sin(2\pi v) \end{cases} \quad u, v \text{ 在 } [0,1] \text{ 独立均匀分布}$$

$$\begin{cases} u = \exp\left\{-\frac{1}{2}(x^2+y^2)\right\} = h_1(x,y) \\ v = \frac{1}{2\pi} \tan^{-1}\left(\frac{y}{x}\right) = h_2(x,y) \end{cases} \Rightarrow f(x,y) = |J| = \frac{1}{2\pi} \exp\left\{-\frac{1}{2}(x^2+y^2)\right\} = f(x)f(y)$$


★ 正态分布的 Maraglia 方法

- (a) 产生 $[0,1]$ 上随机数 u 和 v
- (b) 计算 $w = (2u-1)^2 + (2v-1)^2$
- (c) 若 $w > 1$ 则返回 (a)，否则继续
- (d) 计算 $z = \sqrt{-2 \ln w / w}$ 取 $x = uz$ $y = vz$

• 第一类舍选法： η 在 $[a,b]$ 上分布 $f(x)$ ， $L = \max_{x \in [a,b]} f(x) = \frac{1}{\lambda}$

- (a) 产生 $[0,1]$ 上随机数 ξ_1 ，并构造出 $[a,b]$ 区间随机数 $\delta = a + (b-a)\xi_1$
- (b) 产生 $[0,1]$ 上随机数 ξ_2 ，若 $\xi_2 \leq \lambda f(\delta)$ 则继续，否则返回 (a)
- (c) 选取 $\eta = \delta$ 作为一个抽样值

抽样效率 $E = \frac{\int_a^b f(x) dx}{L(b-a)} = \frac{1}{L(b-a)}$



★ 例: $\eta \sim f(x) = 2x \quad (0 \leq x \leq 1) \quad L = \max_{x \in [0,1]} f(x) = 2$

(a) 产生 $[0,1]$ 随机数 ξ_1, ξ_2

(b) 若 $\xi_2 \leq \frac{1}{L} f(\xi_1) = \xi_1$, 则 $\eta = \xi_1$ (效率 50%)

(c) ξ_1, ξ_2 可交换位置, 则 $\eta = \max\{\xi_1, \xi_2\}$ (效率 100%)

同理推广到高次 $f(x) = nx^{n-1} \quad (0 \leq x \leq 1) \quad \eta = \max\{\xi_1, \xi_2, \dots, \xi_n\}$

• 第二类舍选法: 设 $h(x)$ 与 $f(x)$ 同为 $[0,1]$

且 $f(x) = L \frac{f(x)}{L h(x)} h(x) = L g(x) h(x) \quad g(x) < 1, L > 1$

(a) 产生 $[0,1]$ 随机数 ξ 并由 $h(x)$ 抽样得到 η_h

(b) 若 $\xi \leq g(\eta_h)$ 成立, 则 $\eta = \eta_h$ 效率 $\frac{1}{L}$

★ 例: 标准正态分布 $f(x) = \frac{1}{\sqrt{2\pi}} \exp\left\{-\frac{x^2}{2}\right\}$

$L = \sqrt{\frac{2e}{\pi}} \quad h(x) = e^{-x}, \quad g(x) = \exp\left\{-\frac{(x-1)^2}{2}\right\} \quad 0 < x < +\infty$

(a) 对 $h(x)$ 直接抽样 $\eta_h = -\ln \xi_1$

(b) 若 $\xi_2 \leq g(\eta_h)$ 即 $(\eta_h - 1)^2 \leq -2 \ln \xi_2 \Rightarrow \eta = \eta_h$ 效率 $\sqrt{\frac{\pi}{2e}}$

• 第三类舍选法: $f(x) = L \int_{-\infty}^{h(x)} g(x,y) dy$

$L = 1 / \int_{-\infty}^{+\infty} dx \int_{-\infty}^{h(x)} g(x,y) dy > 1$

(a) 由 $g(x,y)$ 抽取随机向量 (η_x, η_y)

(b) 判别 $\eta_x \leq h(\eta_x)$ 成立, 则 $\eta = \eta_x$ 效率 $\frac{1}{L}$

★ 例: 各项同性方位角余弦的抽样, 即 $x = \cos \theta, \theta \in [0, 2\pi], y = \sin \theta$

$f(x) = \frac{1}{\pi \sqrt{1-x^2}}, |x| < 1$

$$\begin{cases} x = \frac{\xi_1^2 - \xi_2^2}{\xi_1^2 + \xi_2^2} \\ y = \frac{2\xi_1\xi_2}{\xi_1^2 + \xi_2^2} \end{cases} \Rightarrow \begin{cases} \xi_1 = \sqrt{\frac{1}{2}y(1+x)} \\ \xi_2 = \sqrt{\frac{1}{2}y(1-x)} \end{cases} \Rightarrow \begin{cases} g(x,y) = f(\xi_1, \xi_2) |J| \\ = \frac{1}{4\sqrt{1-x^2}} \\ |x| < 1 \quad 0 < y < 1 \end{cases}$$

• 加分布抽样: $f(x) = \sum_n p_n h_n(x)$ $0 < p_n < 1, \sum_n p_n = 1$

(a) 产生 $[0, 1]$ 随机数 ξ , 由 $\sum_{i=1}^m p_i < \xi \leq \sum_{i=1}^n p_i$ 解得 n

(b) 找到对应 $h_n(x)$, 抽样得 $y = y_{h_n}$

• 减分布抽样: $f(x) = A_1 g_1(x) - A_2 g_2(x)$ $x \in [a, b]$ $A_{1,2} \geq 0$

令 m 为 $g_2(x)/g_1(x)$ 的下边界

$$0 < f(x) = g_1(x) \left[A_1 - \frac{A_2 g_2(x)}{g_1(x)} \right] \leq g_1(x) (A_1 - A_2 m)$$

$$\text{令 } h_1(x) = f(x) / [g_1(x) (A_1 - A_2 m)] \quad 0 < h_1(x) \leq 1$$

$$\Rightarrow f(x) = (A_1 - A_2 m) h_1(x) g_1(x) \quad \text{采用第二类舍选法} \quad \text{效率 } \frac{1}{A_1 - A_2 m}$$

• 乘加分布抽样: $f(x) = H_1(x) g_1(x) + H_2(x) g_2(x)$ $x \in [a, b]$ $H_{1,2} \geq 0$

(1) 若 $p_{1,2} = \int_a^b H_{1,2}(x) g_{1,2}(x)$, 直接转为加分布抽样

(2) 若 M_1, M_2 分别为 H_1, H_2 上界, 令 $p_1 = \frac{M_1}{M_1 + M_2}$ $p_2 = \frac{M_2}{M_1 + M_2}$

$$L = M_1 + M_2 \quad H_{1,2}(x) = M_{1,2} h_{1,2}(x)$$

$$f(x) = p_1 [L h_1(x) g_1(x)] + p_2 [L h_2(x) g_2(x)] \quad \begin{array}{l} \text{加分布抽样} \\ + \\ \text{第二类舍选法} \end{array}$$

• 乘减分布抽样

$$f(x) = H_1(x) g_1(x) - H_2(x) g_2(x) \quad x \in [a, b]$$

令 m 为 $\frac{H_2(x) g_2(x)}{H_1(x) g_1(x)}$ 最小值, M_1 为 H_1 最大值

$$0 < f(x) \leq H_1(x) g_1(x) [1 - m] \leq M_1 (1 - m) g_1(x)$$

第二类舍选法

效率

$$\Rightarrow f(x) = M_1 (1 - m) h_1(x) g_1(x) \quad 0 < h_1(x) \leq 1 \quad M_1 (1 - m) > 1$$

$$\frac{1}{M_1 (1 - m)}$$

• 直方图抽样 一共 N 个道址

$$\text{令 } n_j \text{ 为第 } j \text{ 道址的频数, 则 } F(x_j) = \frac{\sum_{i=0}^j n_i}{\sum_{i=0}^N n_i}$$

(1) 产生 $[0, 1]$ 均匀分布随机数 ξ

(2) 若 $F(x_{j-1}) \leq \xi < F(x_j)$, 则 $y = x_j$

$\{y = x_j\}$

每个道址有宽度, 可以通过插值法得到连续抽样值

● 高维随机向量的抽样

(1) 舍选法 抽样 $y = (y_1, y_2, \dots, y_n)^T \sim f(x_1, x_2, \dots, x_n)$

取值范围 $\{a_1 \leq x_1 \leq b_1, a_2 \leq x_2 \leq b_2, \dots, a_n \leq x_n \leq b_n\}$

令 $L = \max f(x_1, x_2, \dots, x_n)$ 产生 $n+1$ 的 $[0, 1]$ 上独立分布随机数 $\xi_1, \xi_2, \dots, \xi_{n+1}$

若 $\xi_{n+1} < \frac{1}{L} f(a_1 + (b_1 - a_1)\xi_1, a_2 + (b_2 - a_2)\xi_2, \dots, a_n + (b_n - a_n)\xi_n)$

则 $y_i = a_i + (b_i - a_i)\xi_i \quad i = 1, 2, \dots, n$

效率 $\frac{1}{L \prod_{i=1}^n (b_i - a_i)}$

(2) 条件密度法.

$$f(x_1, x_2, \dots, x_n) = f_1(x_1) f_2(x_2 | x_1) f_3(x_3 | x_1, x_2) \dots f_n(x_n | x_1, \dots, x_{n-1})$$

$$\text{且 } f_1(x_1) = \int_{-\infty}^{+\infty} \dots \int_{-\infty}^{+\infty} f(x_1, \dots, x_n) dx_2 \dots dx_n$$

$$f_2(x_2 | x_1) = \int_{-\infty}^{+\infty} \dots \int_{-\infty}^{+\infty} f(x_1, \dots, x_n) dx_3 \dots dx_n / f_1(x_1)$$

\Rightarrow 由 $f_1(x_1)$ 抽样得 $y_1 = x_1$ 在 $y_1 = x_1$ 下由 $f_2(x_2 | x_1)$ 抽 $y_2 = x_2$

依次抽得 y_3 直至 y_n

● 几维正态分布随机抽样

1° 每个分量独立分布 $f(x_1, x_2, \dots, x_n) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi}} \exp\{-\frac{x_i^2}{2}\}$

利用一维方法分别抽样

2° 各分量一般不独立

$$f = (2\pi)^{-\frac{n}{2}} |M|^{-\frac{1}{2}} \exp\{-\frac{1}{2}(\bar{x} - \bar{\mu})^T M (\bar{x} - \bar{\mu})\}$$

M 为协方差矩阵, 矩阵元 σ_{ij}

$$\sigma_{ij} = E\{(y_i - \mu_i)(y_j - \mu_j)\} = \sigma_{ji}$$

M 为正定对称矩阵, 存在非奇异下三角阵使 $M = AA^T$

则 $\vec{y}_x = \bar{\mu} + A\vec{y}_y$ \vec{y}_y 为独立 n 维正态分布

★ 二维正态分布抽样

$$A = \begin{bmatrix} \sqrt{\sigma_{11}} & 0 \\ \frac{\sigma_{12}}{\sqrt{\sigma_{11}}} & \sqrt{\frac{\sigma_{11}\sigma_{22} - \sigma_{12}^2}{\sigma_{11}}} \end{bmatrix} \vec{y}_y = \begin{pmatrix} y_{y1} \\ y_{y2} \end{pmatrix}$$

$$M = \begin{bmatrix} \sigma_{11} & \sigma_{12} \\ \sigma_{21} & \sigma_{22} \end{bmatrix} \bar{\mu} = \begin{pmatrix} \mu_1 \\ \mu_2 \end{pmatrix}$$

• 蒙特卡罗方法计算中减少方差的技巧

• 分层抽样法

如 $\frac{P_i}{N} = \frac{1}{N}$ 即按比例的分层抽样

又如, 采用均匀分层抽样, 分成了 J 个子区间, 每个子区间抽 $n_j = \frac{N}{J}$ 并且点也是均匀的, $P_i = \frac{1}{J}$

• 重要抽样法

$I = \int_0^1 f(x) dx = \int_0^1 \frac{f(x)}{g(x)} g(x) dx$ $\frac{f(x)}{g(x)}$ 相对平坦, $g(x)$ 越接近 $f(x)$ 越好

$y \sim g(x)$ 随机抽样

y 带入 $f(x)/g(x)$ 求均值得 I 的蒙特卡罗估计

$$\bar{I} = \frac{1}{N} \sum_{i=1}^N \frac{f(y_i)}{g(y_i)}$$

• 控制变量法 $I = \int_0^1 f(x) dx = \int_0^1 [f(x) - g(x)] dx + \int_0^1 g(x) dx$

• 对偶变量法 $I = \int_0^1 f(x) dx \quad I \approx \frac{1}{N} \sum_{i=1}^N [f(x_i) + f(1-x_i)] / 2$

• 随机游走

★ 例: 求解泊松型微分方程

$\begin{cases} \frac{\partial^2 \phi}{\partial x^2} + \frac{\partial^2 \phi}{\partial y^2} = q(x, y) \\ \phi|_{\Gamma} = F(s) \end{cases}$ Γ 为考察区域 D 的边界
 s 为边界上的点

格点阵中, O 点上下左右四点为 1, 2, 3, 4

差分公式 $\frac{(\phi_1 - \phi_0) - (\phi_0 - \phi_2)}{h^2} + \frac{(\phi_3 - \phi_0) - (\phi_0 - \phi_4)}{h^2} = q_0$

$\Rightarrow \phi_0 = \frac{1}{4}(\phi_1 + \phi_2 + \phi_3 + \phi_4 - h^2 q_0)$

产生 $[0, 1]$ 上随机数 ξ , 判断走哪个点, 记为 m , 则 $\phi_0 \sim \phi_m - \frac{h^2}{4} q_0$

ϕ_m 亦未知, 同理进行二维游走到 n 点

$\phi_m \sim \phi_n - \frac{h^2}{4} q_m \Rightarrow \phi_0 \sim \phi_n - \frac{h^2}{4} (q_0 + q_m)$

直至走到边界 Γ 上某点 S , 得到估计值 $\eta_0 = F(S) - \frac{h^2}{4} \sum_{j=0}^J q_j$
 J 为游走到边界前总步数 反复游走得 ϕ_0 估计序列 $\{\eta_0^{(1)}, \eta_0^{(2)}, \dots, \eta_0^{(N)}\}$
 ϕ_0 期望 $\bar{\phi}_0 = \frac{\sum_{n=1}^N \eta_0^{(n)}}{N} = \frac{\sum_{n=1}^N [F(S^{(n)}) - \frac{h^2}{4} \sum_{j=0}^{J^{(n)}} q_j^{(n)}]}{N}$

$$\phi_0 \text{ 方差 } \sigma^2 = \frac{1}{N} \sigma_{\eta}^2 = \frac{1}{N} [\bar{\eta}^2 - \bar{\eta}_0^2]$$

• 考虑 $\nabla^2 \psi = 0$ $\psi(x, 0) = \psi(x, 1) = 0$ $\psi(0, y) = \psi(1, y) = 1$
 $0 \leq x \leq 1$ $0 \leq y \leq 1$

对正方形中任意一点, 则 $\eta_0^{(n)} = F(S^{(n)}) - \frac{h^2}{4} \sum_{j=0}^{J^{(n)}} q_j^{(n)} = F(S^{(n)})$
 $\bar{\phi}_0 \sim \frac{\sum_{n=1}^N \eta_0^{(n)}}{N} = \frac{\sum_{n=1}^N F(S^{(n)})}{N}$ 为区域内数值解

• Metropolis 方法 从 X 取值区间内选择一个初始点 X_0 , 如下递走

(1) 选取试探位置 $X_{try} = X_n + \eta_n$, η_n 为 $[-\delta, \delta]$ 随机数

(2) 计算 $r = f(X_{try}) / f(X_n)$

(3) 若 $r \geq 1$, 步进成功, $X_{n+1} = X_{try}$

(4) 若 $r < 1$, 产生 $[0, 1]$ 随机数 ξ , 若 $\xi \leq r$, 步进成功, $X_{n+1} = X_{try}$

若 $\xi > r$ 则拒绝 X_{try} , 重新试探 X_{n+1}

讨论: (a) 只有游走足够多步才能收敛到 $f(x)$ 的分布

(b) 参数 δ 的选择: δ 太小, 可能使绝大多数步子被接受, 难达平衡

δ 太大, 大多步子被拒绝, 出现效率问题

(c) 初始位置 X_0 : 尽快到达平衡, 一般取 $f(x)$ 最大区域

伊辛模型——简单，忽略与格点相关的原子的能^动，
只包括了最相邻原子的作用能

$$S_i = \begin{cases} 1 & \text{自旋}\uparrow \\ -1 & \text{自旋}\downarrow \end{cases}$$

体系

$$H = -J \sum_{i=1}^N S_i \sum_{\langle i,j \rangle} S_j - \mu B \sum_{i=1}^N S_i$$

μ 单个自旋的磁矩。

$J > 0$ 铁磁体模型，自旋倾向同方向排列
 $J < 0$ 反铁体模型 反方向。

配分函数 $Z = \sum_{\vec{s}} e^{-\beta H(\vec{s})}$

$\beta = \frac{1}{k_B T}$ $\vec{s} = \{S_i\}$ 自旋态位形

磁化强度 $M = \frac{1}{\beta} \frac{\partial \ln Z}{\partial B} = \sum_{\vec{s}} M(\vec{s}) e^{-\beta H(\vec{s})}$

$$M(\vec{s}) = \sum_{i=1}^N S_i$$

怎么抽样？

玻尔兹曼分布

$$\begin{aligned} P(\vec{x}, T) d\vec{x} &= (Z)^{-1} f(H(\vec{s})) d\vec{x} \\ &= (Z)^{-1} e^{-\beta H(\vec{s})} d\vec{x} \end{aligned}$$

• 有限差分法 与计算方法中相似

$$\text{考虑 } \begin{cases} \nabla^2 \phi = q(x, y) & \text{在 } D \text{ 内} \\ \phi|_G = g(\phi) & \text{在 } D \text{ 的边界 } G \text{ 上} \end{cases}$$

$$\text{直接迭代式: } \phi_{ij}^{(k+1)} = \frac{1}{4} [\phi_{i+1,j}^{(k)} + \phi_{i-1,j}^{(k)} + \phi_{i,j+1}^{(k)} + \phi_{i,j-1}^{(k)} - h^2 q_{ij}]$$

$$\text{高斯-赛德尔迭代: } \phi_{ij}^{(k+1)} = \frac{1}{4} [\phi_{i+1,j}^{(k)} + \phi_{i,j+1}^{(k+1)} + \phi_{i-1,j}^{(k)} + \phi_{i,j-1}^{(k+1)} - h^2 q_{ij}]$$

超松弛迭代: 将上式作为一个中间结果 $\bar{\phi}_{ij}^{(k+1)}$

$$\Rightarrow \phi_{ij}^{(k+1)} = \omega \bar{\phi}_{ij}^{(k+1)} + (1-\omega) \phi_{ij}^{(k)}$$

$$= (1-\omega) \phi_{ij}^{(k)} + \frac{\omega}{4} (\phi_{i+1,j}^{(k)} + \phi_{i,j+1}^{(k+1)} + \phi_{i-1,j}^{(k)} + \phi_{i,j-1}^{(k+1)} - h^2 q_{ij})$$

$1 \leq \omega \leq 2$ 时收敛速度快好

$\omega=1$ 时就是高斯赛德尔迭代

第一类边值问题

$$\text{最佳 } \omega_0 = \frac{2}{1 + \sin(\frac{\pi}{4})} \text{ (正方形) or } \omega_0 = 2 - \pi \sqrt{2} (\frac{1}{l^2} + \frac{1}{m^2}) \text{ (矩形)}$$

• 有限元素法 (详见讲义)

• 有限差分法和有限元素法的比较

(1) 处理问题的数学方法上:

有限差分法: 从物理模型出发, 列出偏微分方程及定解条件, 通过网络划分将问题离散化对差分方程组的数值求解

有限元素法: 将物理问题化为对泛函求极值的变分方程, 利用差分法的区域划分的离散化方法, 并通过元素划分所构造的插值函数, 把求解连续的变分方程问题离散化为求解线性方程组 (问题在离散化的整个过程中始终具有明确物理意义)

(2) 对区域的高散化方法:

有限差分法: 矩形网络区域划分, 很难实现网络节点在区域中的配置与边界的良好逼近.

有限元素法: 三角形划分, 对节点在区域中的配置方式比较随意, 可以根据边界条件来选择.

(3) 有限差分法: 孤立地对微分方程及定解条件分别列差分方程, 因而各节点精度总体上不够一致. 适用范围十分广泛 (特别是当边界形状比较规则时)

有限元素法: 用统一的观点对区域内的节点和边界列出计算格式, 使各节点的计算精度总体上比较协调. 要求的计算机内存量大, 需要准备输入的数据量也比较大. 很多物理还不能求解

● 分子动力学方法

周期性边界条件: 消除引入元胞后的表面效应, 构建一个在无穷大的体积来更精确地代表宏观效应.

$$A(\vec{x}) = A(\vec{x} + \vec{n}L) \quad \vec{n} = (n_1, n_2, n_3)$$

最小像力约定: 在由无穷重复的分子动力学元胞中, 每一个粒子只同它所在的基本元胞内的另外 $N-1$ 个中每个粒子或其最邻近的影像粒子发生相互作用

$$r_{ij} = \min(|\vec{r}_i - \vec{r}_j + nL|) \quad \text{对一切 } n$$

Lennard-Jones 位势: $V(r) = 4\epsilon \left[\left(\frac{\sigma}{r}\right)^{12} - \left(\frac{\sigma}{r}\right)^6 \right]$

$-\epsilon$ 是位势最小值 (ϵ 可确定能量的单位)

这个最小值出现在 $r = 2^{1/6}\sigma$ 的地方 [σ 可确定长度的单位]

[时间标度单位用 $\sqrt{\frac{m\sigma^2}{48\epsilon}}$] $r = \sigma$ 时位势为零

在L-J势下, 第*i*个粒子与元胞内其他*N*-1个粒子或其最邻近的影像粒子的相互作用力在*x*方向的分量为

$$F_{i,x} = 48 \left(\frac{\epsilon}{\sigma^2} \right) \sum_{j=1, j \neq i}^N (x_i - x_j) \left[\left(\frac{\sigma}{r_{ij}} \right)^{14} - \frac{1}{2} \left(\frac{\sigma}{r_{ij}} \right)^8 \right]$$

• 微正则系综的分子动力学模拟

(1) 给定初始空间位置 $\{\vec{r}_i^{(0)}\}$ 初始速度 $\{\vec{v}_i^{(0)}\}$ $i=1, 2, \dots, N$

(2) 利用公式 $\vec{r}_i^{(n+1)} = \vec{r}_i^{(n)} + h\vec{v}_i^{(n)} + \vec{F}_i^{(n)} h^2/2m$ 计算所有粒子在第*n*+1步的空间位置, *h*为时间步长

(3) 计算第*n*+1步所有粒子的速度 $\vec{v}_i^{(n+1)} = \vec{v}_i^{(n)} + h(\vec{F}_i^{(n+1)} + \vec{F}_i^{(n)})/2m$

(4) 返回(2)开始第*n*+2步模拟

★假如总能量不等于给定恒定值, 则通过对速度的调整来实现能量守恒, 即将速度乘以一个标度因子 $\beta = \left[\frac{T^*(N-1)}{16 \sum_i v_i^2} \right]^{\frac{1}{2}}$

• 正则系综的分子动力学模拟

(1) 给定初始空间位置 $\{\vec{r}_i^{(0)}\}$ 初始速度 $\{\vec{v}_i^{(0)}\}$ $i=1, 2, \dots, N$

(2) 计算所有粒子在第*n*+1步的空间位置 $\vec{r}_i^{(n+1)} = \vec{r}_i^{(n)} + h\vec{v}_i^{(n)} + \vec{F}_i^{(n)} h^2/2m$

(3) 计算所有粒子在第*n*+1步的速度 $\vec{v}_i^{(n+1)} = \vec{v}_i^{(n)} + h(\vec{F}_i^{(n+1)} + \vec{F}_i^{(n)})/2m$

$$\text{动能 } E_k = \frac{1}{2} \sum_i m (v_i^{(n+1)})^2$$

$$\text{速度标度因子 } \beta = \left[\frac{(3N-4)kT}{\sum_i m (v_i^{(n+1)})^2} \right]^{\frac{1}{2}}$$

(4) 将速度 $\{\vec{v}_i^{(n+1)}\}$ 乘以标度因子 β , 并令 $\{\vec{v}_i^{(n+1)} \beta\} \rightarrow \{\vec{v}_i^{(n+1)}\}$

返回(2)开始第*n*+2步模拟.

• Mathematica的应用

● 机器学习

● 机器学习类型

(1) 监督学习: 通过学习确定操作 FUN, 用作预言

$OUT = FUN(IN)$ 分类/回归算法

(2) 非监督学习: 通过学习确定数据集的(隐裁)结构.

仅 IN 归类和聚合算法.

(3) 强化学习: 通过在仔细选择的反馈下学习如何达到目标

仅 IN 和环境反馈 游戏算法.

$p \gg n$ 稀疏情形 结果不可靠

测试和训练的统计误差 $\text{Var.} \sim \frac{\sum p}{n}$

引入 Ridge 正则化 $w_{\text{Ridge}}(x) = \arg \min_{w \in \mathbb{R}^p} \|\vec{x}w - \vec{y}\|_2^2$
s.t. $\|w\|_2 \leq t$

Lasso 正则化 $w_{\text{Lasso}}(x) = \arg \min_{w \in \mathbb{R}^p} \|\vec{x}w - \vec{y}\|_2^2$
s.t. $\|w\|_1 \leq t$

使模型参数受约束 (取值范围) \rightarrow 减小统计方差 但增大偏差

交叉熵 $l(w) = \sum_{i=1}^n y_i \log \sigma(x_i^T w) + (1 - y_i) \log [1 - \sigma(x_i^T w)]$

逻辑回归代价函数的一般形式

$$S = -k_B \sum_i p_i \ln p_i$$

Softmax 交叉熵代价函数

$$C(w) = - \sum_{i=1}^n \sum_{m=0}^{M-1} y_{im} \log P(y_{im}=1 | x_i, w_n) + (1 - y_{im}) \log (1 - P(y_{im}=1 | x_i, w_n))$$

集成学习 $g_c^A(x; \{ \theta_j \}) = \frac{1}{n} \sum_{m=1}^M \hat{g}_c(x; \theta_m)$
集成模型 单个模型

合并多个较弱统计模型提高子模型效用, 增强预言力.

尽可能在偏差可控下减小统计方差.

- ① 手段: 袋装算法 (等权平均每个模型)
 - 优: 统计弱关联, 减小方差 (经验重抽样法)
 - 缺: 产生随机集都来自观测数据, 可导致偏差变大.
- ② 但可以给 good 模型更高权重, 提高效率 (增强算法)

③ 决策树 (根据点叶子(决策)的映射 $y=f(x)$)

PPT! 用特征划分数据集“分叉”
 最末端叶子对应类别
 越高(复杂)越好, 但容易出现过拟合(统计公差过大)
 分类效果

“二叉树” Gini Impurity = $1 - \sum_{i=1}^n P_i^2$ 越低越好, 分类效果越好

④ 随机森林 ↑ 阵列生成基于经验集抽样法

↓ 采用随机生成的特征子集

效果依赖: 装袋、增强算法, 树木多少及每棵树的深度等超参的设置与优化

梯度增强树 (增强算法, 梯度下降法)

神经网络 基本结构 (映射关系 + 网络结构)

深度神经网络 DNN 深度学习
 卷积 CNN 图像学习
 循环 自然语言处理

输入层 隐藏层 输出层

$$a^{(k)} = \sigma \left[\sum (w_i a_i^{(k-1)} + b_i) \right]$$

权重因子 \rightarrow 阈值

反向传播算法 (BP)

1. 正向传播 得到当前网络下各神经元取值
2. 从最末端输出层 计算代价函数误差 Δ
3. 利用式子反向推导, 得到代价函数关于所有参数的偏微分
4. 进行步进 \rightarrow 梯度下降

线性回归

决定系数

$$R^2 = 1 - \frac{\sum_{i=1}^n |y_i^{true} - y_i^{pred}|^2}{\sum_{i=1}^n |y_i^{true} - \frac{1}{n} \sum_{i=1}^n y_i^{true}|^2}$$