SG7

自然科学における統計サンプリングの プログラミング・シミュレーションの実践

サンプリング

ビッグデータの時代
 – PCの能力の向上…ムーアの法則
 – 大量のデータを解析できるようになった



• 統計データ...サンプリングが必要...どうするか?



- 得られたビックデータの活用
- 社会の様々なところで使われ始めている
 画像認識、自然言語処理、金融工学、etc...



・応用は様々…中身はどうなっているのだろう?

内容

各々の興味に応じたテーマに対してプログラミン グを行い結果を発表することで知識を共有した

- 機械学習
 手書き文字認識
- サンプリング



産総研 手書教育漢字データベースより



- 分子動力学(MD)シミュレーション
- 応用(組み合わせ)
 - MDによって得られたサンプルを用いたデータ同化 解析



「自動反応経路探索を用いる触媒反応の機構解明と機械学習による効率的解析」

✓ k-means法による化学構造の分割と解析



「機械学習を用いた計測とシミュレーションの統合 によるタンパク質動態解析」

✓ MD シミュレーションと機械学習によるタンパク質折り 畳み過程の解析とデータ同化

機械学習

村田 隆 (M1,生物物理)

Deep belief network







学習を重ねるほどエラーが大きくなっている⇔過学習の兆候

ノード数の過多

生物物理への応用



既存MD力場パラメータのリファインメント

$$\begin{split} V_{AICG2}(\mathbf{R}|\mathbf{R}_{0}) &= \sum_{ibd} K_{b,ibd} (b_{ibd} - b_{ibd,0})^{2} + V_{loc}^{flp} \\ &+ \sum_{i+2 \leq j \leq i+3} \varepsilon_{loc,ij} \exp\left(-\frac{(r_{ij} - r_{ij0})^{2}}{2W_{ij}^{2}}\right) \\ &+ \sum_{i< j-3}^{nat \ contact} \varepsilon_{go,ij} \left[5 \left(\frac{r_{ij0}}{r_{ij}}\right)^{12} - 6 \left(\frac{r_{ij0}}{r_{ij}}\right)^{10}\right] \\ &+ \sum_{i< j-3}^{non-native} \varepsilon_{ev} \left(\frac{d}{r_{ij}}\right)^{12}. \end{split}$$

核酸構造予測



分子動力学 シミュレーション

西尾 宗一郎 (B4,化学) 単原子分子のシミュレーション

座標,速度 x,v

67

• Lennard-Jones potential

$$U(r) = 4\epsilon \left[\left(\frac{\sigma}{r} \right)^{12} - \left(\frac{\sigma}{r} \right)^{6} \right]$$
$$F(r) = -\frac{d}{dr} U(r) = 4\epsilon \left(12 \frac{\sigma^{12}}{r^{13}} - 6 \frac{\sigma^{6}}{r^{7}} \right)$$

速度ベルレ法

$$x_{t+\Delta t} = x_t + v_t \cdot \Delta t + \frac{1}{2}F(x_t, t) \cdot \Delta t^2$$
$$v_{t+\Delta t} = v_t + \frac{1}{2}\Delta t \left(F(x_t, t) + F(t + \Delta t, x_{t+\Delta t})\right)$$





x,vの更新

相互作用

F(r)の計算

H,0分子のシミュレーション •O-H, H-H間の結合長の固定と速度 の補正(RATTLE法) -ロン相互(FFH) $U(r) = \frac{1}{2} \sum_{\mathbf{n}} \sum_{i} q_{i} \sum_{j} \frac{q_{j}}{r_{ij\mathbf{n}}}$ フーリエ変換 クーロン相互作用 $U = U_{real} + U_{self} + U_{wave}$ $q = rac{1}{2} \sum_{\mathbf{n}} \sum_{i} q_i \sum_{j} rac{q_j}{r_{ij\mathbf{n}}} \mathrm{erfc}\left(rac{r_{ij\mathbf{n}}}{\eta}
ight) - rac{1}{\pi^{1/2}} \sum_{i} q_i^2$ $+\frac{1}{2}\sum_{\mathbf{K}}\frac{\exp(-\pi^{2}\eta^{2}\mathbf{K}^{2})}{\mathbf{K}^{2}}\left\{\left(\sum_{i}q_{i}\cos 2\pi\mathbf{K}\cdot\mathbf{r}_{i}\right)^{2}+\left(\sum_{i}q_{i}\sin 2\pi\mathbf{K}\cdot\mathbf{r}_{i}\right)^{2}\right\}$

隠れマルコフモデルによる データ同化



水分子クラスターの構造変化

・水3分子の配置を4状態に分類

	状態	配置		
	0	三角形		
Q P	1	直線状(水分子1が中心)		
	2	直線状(水分子2が中心)		
6	3	直線状(水分子3が中心)		



 ・状態を隠れ変数、重み付きダイポールモーメントを 観測値とする隠れマルコフモデルで系を表現

$$\begin{bmatrix} P(s_{k+1} = 0) \\ P(s_{k+1} = 1) \\ P(s_{k+1} = 2) \\ P(s_{k+1} = 3) \end{bmatrix} = \begin{bmatrix} .876 & .127 & .127 & .128 \\ .041 & .0873 & 0 & 0 \\ .041 & 0 & .873 & 0 \\ .041 & 0 & 0 & .873 \end{bmatrix} \begin{bmatrix} P(s_k = 0) \\ P(s_k = 1) \\ P(s_k = 2) \\ P(s_k = 3) \end{bmatrix}$$

$$P(o_k = n) \equiv P(5n \le \mu < 5(n+1)) = h(o_k | s_k) P(s_k)$$
重み付きダイポール $\mu = \sum_i^N q_i r_i \exp(|r_i|^2/30)$



・電荷1.5倍の"変な水分子"1個を含む系を現実系とし 重み付きダイポールモーメントの時系列データから その遷移行列を求める



結果

右式を最大化する

状態	配置
0	三角形
1	直線状(水分子1が中心)
2	直線状(水分子2が中心)
3	直線状(水分子3が中心)

<i>P</i> (<i>o</i> ₁ ,	$,o_N) = s$	$\sum_{S_1S_N} P(S_1$, , S _N , O ₁ ,	, o _N)
$=\sum_{S_1\ldots S_N}h$	〔(o _N s _N)】 <mark>観測量</mark>	P(s _N s _{N-2} 遷移確率	$h(o_1 s_1)\cdots h(o_1 s_1)$)P(s1)
$\begin{array}{c} \bullet 0 \rightarrow \\ \bullet 0 \rightarrow \end{array}$	1, 2→0, 3 2, 0→3遷	→0遷移の 移の確率/	確率が増加 が減少	

		/	n 77 \
〒巾1	. 月川	(\mathbf{N})	()治)

現実系

	0	1	2	3	
0	.876	.127	.127	.128	(
1	.041	.873	.0	.0	-
2	.041	.0	.873	.0	2
3	.041	.0	.0	.873	

	0	1	2	3		0	1	2	3
)	.756	.129	.202	.202	0	.802	.158	.180	.183
1	.171	.867	.016	.016	1	.164	.842	.001	.001
2	.037	.002	.783	.0	2	.018	.0	.819	.0
3	.037	.002	.0	.783	3	.018	.0	.0	.816

現実系の遷移行列の特徴を取り込むことができた

最適化後