

カーネル平均を用いた記述子設計

青木 祐太 ものづくりデータ科学研究中心 特任助教

背景 集合データに対するデータ分析

- ✓ 要素数がサンプルによって異なる。

$$S_i = \{s_i^{(1)}, s_i^{(2)}, \dots, s_i^{(p)}\}$$

$$S_j = \{s_j^{(1)}, s_j^{(2)}, \dots, s_j^{(q)}\}$$

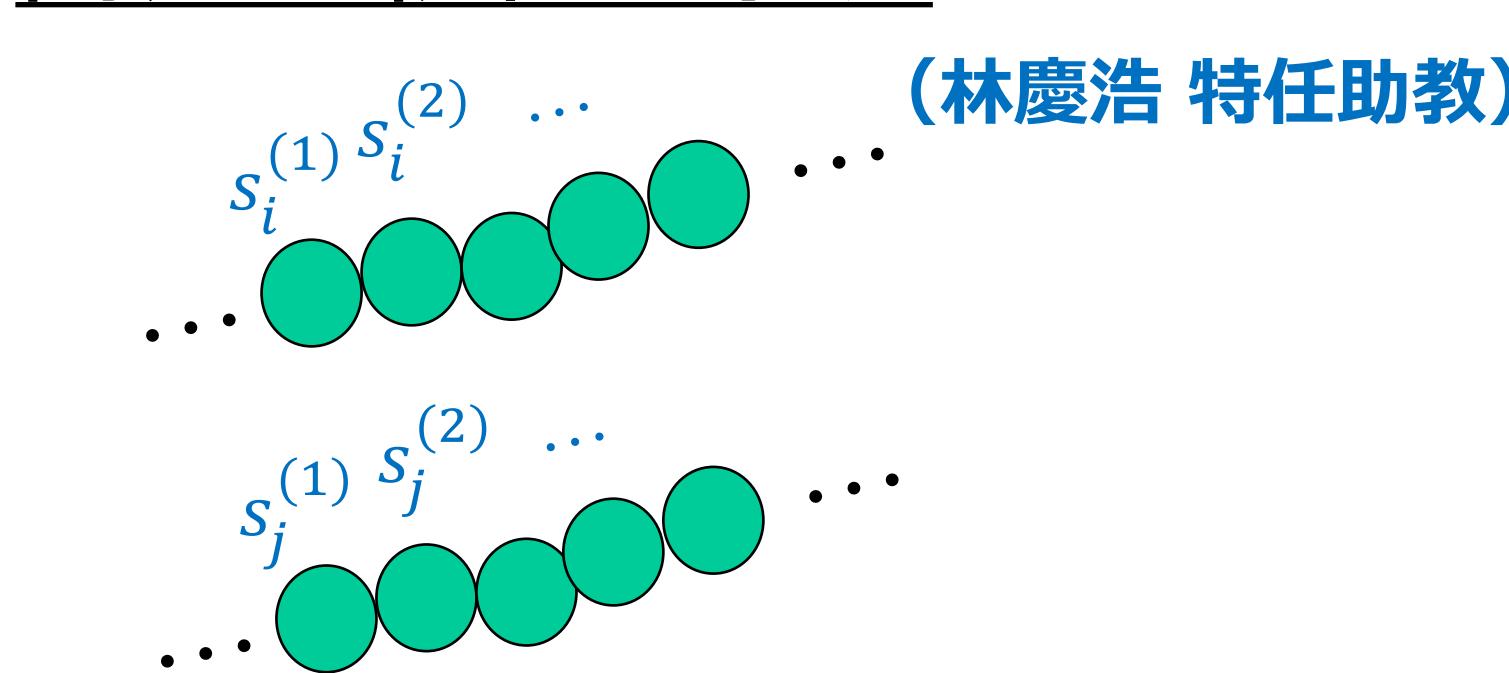
- ✓ 任意の要素間の交換に対する不变性。
(順不同)

$$S_i = \{s_i^{(1)}, s_i^{(2)}, \dots, s_i^{(k)}, \dots, s_i^{(l)}, \dots, s_i^{(p)}\}$$

$$= \{s_i^{(1)}, s_i^{(2)}, \dots, s_i^{(l)}, \dots, s_i^{(k)}, \dots, s_i^{(p)}\}$$

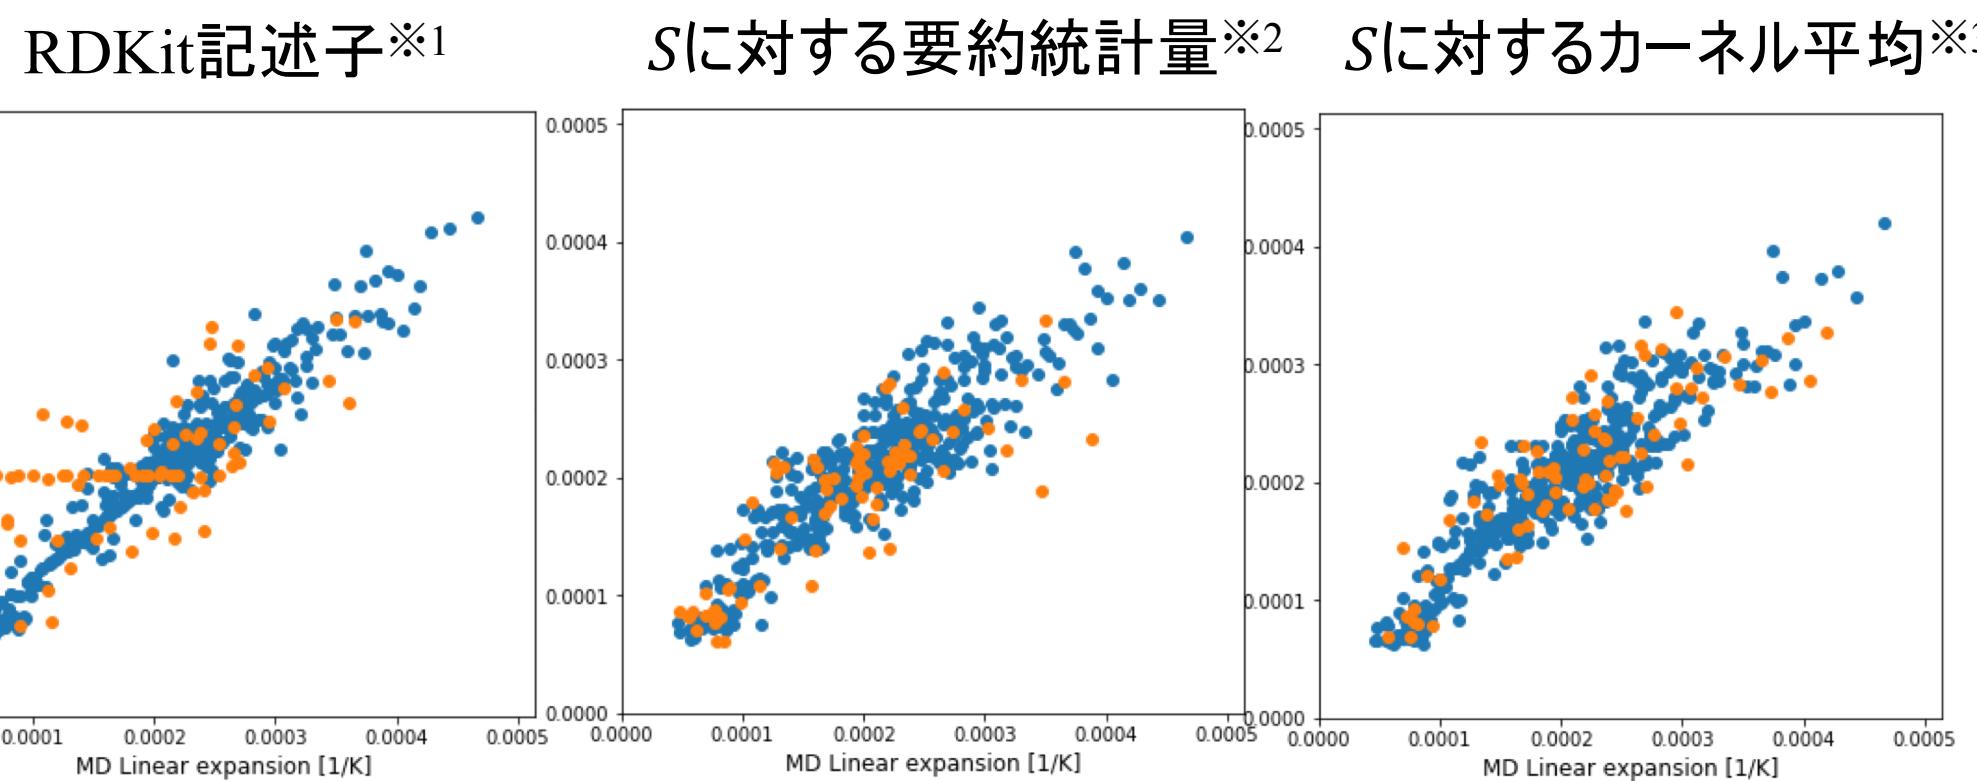
通常の機械学習の枠組みに載せるには、
集合データ S_i を固定長のベクトル記述子 x_i に
変換する必要がある。→ **カーネル平均** の利用

応用例1 高分子物性の予測



$s_i^{(n)}$... 高分子 i を構成する原子 n を表現するパラメータ
分子動力学の力場パラメータ9種類※3

熱膨張係数に対する予測結果 (ガウス過程回帰)



※1 RDKit記述子はchemoinformatics分野で使われる代表的な分子記述子の一つ。

<https://rdkit.org/>

※2 要約統計量として平均, 標準偏差, 歪度, 尖度, 最大値, 最小値の6種類を採用。

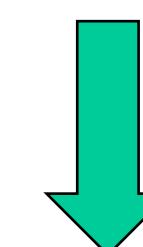
※3 力場パラメータ9種類に対して個別にカーネル平均記述子を作成し, それら全てを使用。

手法 カーネル平均

$$m_X(\cdot) := E_{X \sim P}[k(\cdot, X)]$$

- ✓ カーネル平均の性質:

- X の分布 P に関する高次モーメントの情報を持つ。
- カーネル k が「特性的」であるとき, P を一意に定める。



カーネル平均記述子

$$x_i(\cdot) := \hat{m}_{S_i}(\cdot) = \frac{1}{p} \sum_{n=1}^p k(\cdot, s_i^{(n)})$$

$x_i(\cdot)$ は関数なので, 離散化して固定長ベクトルとする。

ハイパーパラメータ: 離散化の範囲, メッシュ間隔, カーネルのパラメータ

採用したカーネル: ガウスカーネル $k(x, y) = \exp\left[-\frac{\|x - y\|^2}{2\sigma}\right]$

応用例2 準結晶となる化学組成の予測

組成 i

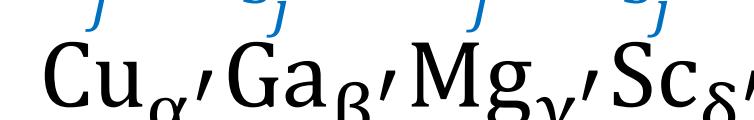
$$s_i^{(1)} \ s_i^{(2)} \ s_i^{(3)}$$

(劉暢 特任助教)



組成 j

$$s_j^{(1)} \ s_j^{(2)} \ s_j^{(3)} \ s_j^{(4)}$$



$s_i^{(n)}$... 組成 i を構成する元素 n を表現するパラメータ

元素に対して定義, 測定, 算出できる元素物性値58種類



組成比 $\alpha, \beta, \gamma, \dots$ で加重平均をとってカーネル平均記述子を算出

準結晶/近似結晶/その他(結晶等)の分類予測精度 (ランダムフォレスト)

XenonPy組成記述子※4 (要約統計量: 加重平均, 加重分散, 最大値, 最小値)

クラス	Recall	Precision	F ₁ score
準結晶	0.602	0.722	0.650
近似結晶	0.608	0.731	0.658
その他(結晶等)	0.999	0.997	0.998

カーネル平均記述子 (58種類の元素物性値に対して個別にカーネル平均記述子を作成し, それら全てを使用)

クラス	Recall	Precision	F ₁ score
準結晶	0.657	0.766	0.703
近似結晶	0.637	0.744	0.681
その他(結晶等)	0.999	0.997	0.998

※4 <https://xenonpy.readthedocs.io/en/latest/>