

物質科学におけるデータ同化手法開発と応用

奈良先端科学技術大学院大学

原嶋 庸介

物質科学：実験と理論

実験

理論

- 学理の追求
- 物質の発見

個々に実施して比較検証するだけでなく、**相乗効果**を狙いたい

材料開発における実験と第一原理計算の関係

- 実験と第一原理計算では長所と短所が相補的
 - 実験: データ数が少なく、偶然誤差の影響が大きくなる
 - 第一原理計算: データ数が多く、偶然誤差(不純物の配置など)の影響を小さくできる一方で、理論誤差がある
- 実験と第一原理計算のデータを統合して、物性値の予測精度を向上させたい


➤ データ同化

データ同化とは?

- 実験と数値計算を統合(同化)させて、予測精度を上げる
- “*Data assimilation* is a mathematical discipline that seeks to optimally combine theory (usually in the form of a numerical model) with observations.”
(https://en.wikipedia.org/wiki/Data_assimilation)
- 現在では主に気象予報などで時系列データを扱う手法として使われている

➤ 物質科学の事情を考慮した新しいアルゴリズムが必要

実験とシミュレーションのデータにあるギャップ



- 計算値が実験をよく再現するのが理想

$$y_{\text{expt}}(x) = y_{\text{comp}}(x)$$

実際には系統誤差が生じている
例)平均場近似の過大評価など

$$y_{\text{expt}}(x) = C y_{\text{comp}}(x) + \mathcal{R}(x)$$

- サンプル抽出点(記述子)が
実験とシミュレーションで一致しない
 - 差が直接計算できない

これらの問題を回避したデータ同化手法を開発した

Multivariate Gaussian modelで表現する

確率変数が正規分布によって分布していると仮定する

$$p(z; \Lambda) = \sqrt{\frac{|\Lambda|}{(2\pi)^d}} \exp\left(-\frac{1}{2} z^T \Lambda z\right)$$

記述子と目的変数の両方を確率変数と考える

$$z^T = \underbrace{(1, x_1, x_1^2, x_1 x_2, \dots)}_{\text{記述子}}, \underbrace{(y_{\text{comp}}, y_{\text{expt}})}_{\text{目的変数}})^T$$

記述子の値が与えられた場合の目的変数の条件付き確率を考える

$$p(y|x; \Lambda) = \sqrt{\frac{|\Lambda_{yy}|}{(2\pi)^2}} \exp\left(-\frac{1}{2} (y - \mu)^T \Lambda_{yy} (y - \mu)\right)$$

$$\mu = -(\Lambda_{yy})^{-1} \Lambda_{yx} x \quad \leftarrow \text{これが予測関数}$$

Gaussian modelと線形回帰モデルの関係

- 線系回帰モデル:

$$y = Wx$$

- Gaussian model:

$$y = -(\Lambda_{yy})^{-1}\Lambda_{yx}x$$

- 係数行列:

$$W = -(\Lambda_{yy})^{-1}\Lambda_{yx}$$

- Λ が与えられれば予測モデルが得られる

尤度と推定法

- 目的変数に関する尤度:

$$L(\Lambda) = \sum_{n=1}^N \ln p(y_n | x_n; \Lambda)$$

$$p(y|x; \Lambda) = \sqrt{\frac{|\Lambda_{yy}|}{(2\pi)^2}} \exp\left(-\frac{1}{2}(y - \mu)^T \Lambda_{yy}(y - \mu)\right)$$

$$\mu = -(\Lambda_{yy})^{-1} \Lambda_{yx} x$$

- $\Lambda_{yy}, \Lambda_{yx}$ を $L(\Lambda)$ について最適化することで予測モデルを立てる

欠測データの取り扱い

- 欠測データの変数は積分消去する

$$\begin{aligned} p(y_1) &= \int dy_2 p(y_1, y_2) \\ &= \sqrt{\frac{|\bar{\Lambda}_{11}|}{2\pi}} \exp\left(-\frac{1}{2}(y_1 - \mu_1)\bar{\Lambda}_{11}(y_1 - \mu_1)\right) \\ \bar{\Lambda}_{11} &= \Lambda_{11} - \Lambda_{12}(\Lambda_{22})^{-1}\Lambda_{21} \end{aligned}$$

- 積分消去後の確率で定義した尤度を完全尤度という
- 完全尤度の最適化から Λ を決定する


K.Takai and Y. Kano, Comm. Stat. **42**, 3174 (2013).

高井啓二 et al. 欠測データの統計科学 医学と社会科学への応用, 岩波書店 (2016).

欠測データは回帰への寄与を軽減

記述子	シミュレーション	実験
1.0	933.718	1000
0.9	945.811	994
0.8	962.004	nan
0.7	981.454	965
0.6	1002.318	nan
⋮	⋮	⋮

目的変数(y_{comp} , y_{exp})の分布の模式図




- 欠測によりデータの分布幅が広がる
- データの重みが軽くなる

デモンストレーション

真のモデルを用意

$$f_1(x) = 2 - x + 5(x - 0.7)^2 + 20(x - 0.5)^3$$

$$f_2(x) = f_1(x) - 1.5 \leftarrow \text{定数だけ異なる}$$



- model(i): 10サンプル; error小 (0.03), $x=[0.0,1.0]$
- model(ii): 5サンプル; error大 (0.1), $x=[0.0,0.5]$
- model(ii)とmodel(i)で独立にサンプリング

- 3次の多項式によるfitting
- model(ii)のfitは1,2,3次の項は制限する
- OLS fit (model毎のfitting)と比較

➤ 本手法では他方のサンプルを使って擬似的に外挿が可能になる

例) 永久磁石化合物の探索

- 現在の永久磁石化合物の代表例:



- 実際は、




希土類元素

遷移金属元素

典型元素


- 化学組成はfractionalに与えられる
- 物性値の化学組成依存性の理解は重要課題
- 多次元空間での理解は困難

事例: 永久磁石化合物の有限温度磁化予測




- $\alpha, \beta, \gamma, \delta, \zeta$ の自由度に対して任意の温度の磁化の値を予測する

多次元化学組成空間における任意の温度での磁化



- いろいろな組成で予測可能


非線形な振る舞いの検出: Co濃度依存性



- 低温ではCo濃度によって磁化が単調減少する
- 高温(>320K)では有限のCo濃度で磁化が最大になる

物質探索

- 従来の探索では合成、測定を繰り返す
- シミュレーションデータと同化し、物性値予測モデルを高精度化する
- Bayes最適化により、次の合成条件を提案する



尤度と推定法

- 目的変数に関する尤度:

$$L(\Lambda) = \sum_{n=1}^N \ln p(y_n | x_n; \Lambda)$$

$$p(y|x; \Lambda) = \sqrt{\frac{|\Lambda_{yy}|}{(2\pi)^2}} \exp\left(-\frac{1}{2}(y - \mu)^T \Lambda_{yy}(y - \mu)\right)$$

$$\mu = -(\Lambda_{yy})^{-1} \Lambda_{yx} x$$

- $\Lambda_{yy}, \Lambda_{yx}$ を $L(\Lambda)$ について最適化(先行研究では最尤推定で決めていた)

➤ 本研究：Bayes推定の導入

- ✓ 逐次更新可能：過去の全データが不要
- ✓ 事後分布(Λ の分布)：Bayes最適化

Bayesの定理とBayes推定

Bayesの定理:

$$p(\Lambda|y) = \frac{p(y|\Lambda) \cdot p(\Lambda)}{p(y)}$$

尤度(yの分布) → $p(y|\Lambda)$

事前分布(Λ の分布) → $p(\Lambda)$

$p(\Lambda|y)$ ← 事後分布(Λ の分布)

$p(y)$ ← Λ については無関係

最尤推定：尤度を Λ について最大化する

Bayes推定：事後分布を Λ について最大化する

Bayes推定

- 事後分布の漸化式

$$p(\Lambda|\{y_i\}_1^N, \{x_i\}_1^N) = \frac{p(\{y_i\}_1^N|\Lambda, \{x_i\}_1^N) \cdot p(\Lambda|\{x_i\}_1^N)}{p(\{y_i\}_1^N|\{x_i\}_1^N)} = p(y_N|x_N; \Lambda) \cdot p(\Lambda|\{y_i\}_1^{N-1}, \{x_i\}_1^{N-1})$$


- 事後分布を C^N で表現可能

$$p(\Lambda|\{y_i\}_1^N, \{x_i\}_1^N) = \sqrt{\frac{|\Lambda_{yy}^0|}{(2\pi)^d}} \exp\left(-\frac{1}{2}\text{Tr}(C^N \Lambda^0)\right)$$

$$C_{\gamma_1, \gamma_2}^N \equiv \sum_{i=1}^N z_{i, \gamma_1} z_{i, \gamma_2} \quad \Lambda^0 \equiv \begin{pmatrix} \Lambda_{xy}(\Lambda_{yy})^{-1}\Lambda_{yx} & \Lambda_{xy} \\ \Lambda_{yx} & \Lambda_{yy} \end{pmatrix}$$

- 事後分布を最大化をする Λ_{yy} と Λ_{yx} を使って μ を構築

多項式以外の基底関数による展開



- sin関数による展開


$$y_1 = 2\phi_0(x) + 0.2\phi_1(x) + 0.3\phi_2(x) \\ - 0.2\phi_3(x) + 0.1\phi_4(x) - 0.3\phi_5(x) + 0.2\phi_6(x)$$

$$y_2 = y_1 - 2\phi_0(x) - 0.6\phi_1(x)$$

$$\phi_n(x) \equiv \sin(2\pi nx)$$

Bayes最適化：データ同化 VS 通常の実二乗法

- 2次元空間, (x_1, x_2)
- 7基底/次元, $(\phi_n(x) = \sin(2\pi nx), n = 0, 1, \dots, 6)$
- 交差項, $(\phi_n(x)\phi_{n'}(x))$
- $7 \times 7 = 49$ 個の fitting parameters に対応




iteration

1. 2つのモデルを使用 (model AとB)
2. それぞれのモデルで5データを取得
3. データから予測モデルを導出
4. 候補点 (x_1, x_2) を model Bの最大値を与えるように選択
5. m 個の候補点 (x_1, x_2) を model Aの不確実性が最大になる点で選択

- { データ同化：3.+4.+5.
- { 最小二乗法：3.+4. only 33

Bayes最適化：データ同化 VS 通常の最小二乗法

y の最大値の探索



色付きの幅は揺らぎ

$$\epsilon_u = \sum_i \theta(y_i - \bar{y}) \max(y_i - \bar{y}, 0)$$
$$\epsilon_l = \sum_i \theta(\bar{y} - y_i) \min(\bar{y} - y_i, 0)$$

i の和はサンプルデータに関してとる

- モデルA(calc)が確立されたとき (~49iteration)、モデルB(exp)の最大値が突然発見される
- シミュレーションによる探索は最大値を目標にするのではなく、モデルの確立を目指すのが効率的