

Generative Topographic Mapping (GTM) でデータの可視化・回帰分析・モデルの逆解析を一緒にやってみた

明治大学 理工学部 応用化学科 専任講師 金子 弘昌

2018年5月22日 (火)

第7回ケモインフォマティクス若手の会@渋谷ヒカリエ

自己紹介

1

✓ 明治大学 応用化学科 応用化学科 専任講師 金子 弘昌

- データ化学工学研究室
- Website: <https://datachemeng.com/>
 - 「明治 金子」で検索
- Twitter: @hirokaneko226
- 部屋: 第二校舎D館D409
- E-mail: hkaneko@meiji.ac.jp
- Tel: 044-934-7197
- オンラインサロンはじめました！
 - <https://datachemeng.com/onlinesalon/>

✓ 生年月日

- 1985年1月9日 (33歳)

自己紹介

2

✓出身地

- 栃木県足利市
 - あしかがフラワーパーク
 - 足利学校
 - 相田みつを
 - ココ・ファーム・ワイナリー

✓経歴


- 足利高校
 - 東京大学
 - 東京大学大学院 修士課程
 - 東京大学大学院 博士課程
 - 東京大学大学院 助教
 - 明治大学へ

✓趣味

- ソフトテニス
- ジョギング
- 読書 (マンガ含む)
- 映画鑑賞

✓家族

- 妻 1 人、娘 1 人の 3 人家族



例) **X**: 2変数
データ数: 3
線形モデル

	x_1	x_2	y
データ1	1	2	5.1
データ2	2	1	3.9
データ3	3	3	9.2

回帰モデル



$$y = x_1 + 2x_2 + \text{誤差}$$

エクセルのファイルだとデータはこんな感じ

4

	logS	MinAbsPa	NumRadic	HeavyAtom	MaxAbsES	MaxAbsPa	MaxEState	MinPartia	ExactMolV	MolWt	NumValer	MinEState	M
CC(N)=O	1.58	0.21379	0	54.028	9.222222	0.369921	9.222222	-0.36992	59.03711	59.068	24	-0.33333	C
CNN	1.34	0.001725	0	40.025	4.597222	0.271722	4.597222	-0.27172	46.0531	46.073	20	1.652778	1
CC(=O)O	1.22	0.299685	0	56.02	9	0.481433	9	-0.48143	60.02113	60.052	24	-0.83333	C
C1CCNC1	1.15	0.004845	0	62.051	3.222222	0.316731	3.222222	-0.31673	71.0735	71.123	30	1.25	
NC(=O)NO	1.12	0.335391	0	72.023	9.229167	0.349891	9.229167	-0.34989	76.02728	76.055	30	-0.93981	C
OCC(O)CO	1.12	0.100047	0	84.03	8.166667	0.393593	8.166667	-0.39359	92.04734	92.094	38	-0.9537	C
CC(=O)N(C)C	1.11	0.218425	0	78.05	10.06944	0.349064	10.06944	-0.34906	87.06841	87.122	36	0.092593	C
c1ccnc1	1.1	0.049569	0	76.058	3.534722	0.159176	3.534722	-0.15918	80.03745	80.09	30	1.638889	1
c1cncnc1	1.1	0.114757	0	76.058	3.673611	0.244832	3.673611	-0.24483	80.03745	80.09	30	1.5	
OCC(O)C(O)C(O)C	1.09	0.110579	0	168.06	8.95662	0.393579	8.95662	-0.39358	182.079	182.172	74	-1.66931	C
CC(N)CC(=O)O	1.08	0.304406	0	94.049	9.729722	0.481188	9.729722	-0.48119	103.0633	103.121	42	-0.83796	C
C1CNCCN1	1.07	0.007723	0	76.058	3.222222	0.314206	3.222222	-0.31421	86.0844	86.138	36	1.138889	1
C1CCNCC1	1.07	0.004891	0	74.062	3.284722	0.316733	3.284722	-0.31673	85.08915	85.15	36	1.25	
Oc1ccncc1	1.02	0.118146	0	90.061	8.592222	0.50785	8.592222	-0.50785	95.03711	95.101	36	0.259259	C
Oc1cccn1	1.02	0.210156	0	90.061	8.521111	0.493268	8.521111	-0.49327	95.03711	95.101	36	0.071759	C
O=C(O)CCCC(=O)O	1	0.302856	0	124.051	9.787862	0.48123	9.787862	-0.48123	132.0423	132.115	52	-0.94792	C
CN1CCOCC1	1	0.05935	0	90.061	5.098194	0.378793	5.098194	-0.37879	101.0841	101.149	42	0.913194	C
CC(N)=O	0.97	0.403708	0	70.027	0.368056	0.453034	0.368056	-0.45303	75.03203	75.067	30	-0.74537	

<https://atachemeng.wp.xdomain.jp/pythonassignment/> からダウンロード可能

データ解析の一般的な流れ

✓データ収集

- データの前処理

✓データの可視化：主成分分析 (PCA) など

✓モデル構築：サポートベクターマシン・回帰 (SVM, SVR) など

- 今回は回帰分析
- モデルの検証

✓モデルの逆解析

- y から X を推定
- 順解析を繰り返す、とか

一気にデータ解析できないか？

✓データの可視化・モデル構築・モデルの逆解析は
別々に行われている


- たとえば、データの可視化の結果とモデル構築の結果との間に
関係があるわけではない
- 別々にやるのは面倒 (?)

✓データの可視化・モデル構築・モデルの逆解析をつなげて
一気にできないか？

- データセットは一つなので、この方が効率的

GTMに着目

- ✓ Generative Topographic Mapping (GTM) [1]
 - データを可視化・見える化するための非線形手法
 - 主成分分析などとは異なり、はじめに二次元平面の座標を作り、それを実際の多次元空間のサンプルに合わせ込む
 - ゴム状のシート（二次元平面）を曲げたり伸び縮みさせたりしながら、多次元空間にあるサンプルを通るようにシートを置き、そのシートにサンプルを射影するような手法
 - 自己組織化マップ（Self-Organizing Map, SOM）のいろいろな問題点を解決した、上位互換の手法
 - 2次元平面において近いサンプル同士は、多次元空間においても近いことが補償されている
 - 詳細は <https://datachemeng.com/generativetopographicmapping/>



✓二次元マップ

✓各グリッドに正規分布

✓データセットに
正規分布の重ね合わせ
がフィットするように
マッピング


✓データセットは、
正規分布の重ね合わせ
で表現される


GTMで回帰分析・モデルの逆解析も！

- ✓ Generative Topographic Mapping-Multiple Linear Regression (GTM-MLR)
- ✓ Generative Topographic Mapping Regression (GTMR)

を提案、論文投稿中

- ✓ GitHub: <https://github.com/hkaneko1985/gtm-generativetopographicmapping>
にてPython, MATLABコードを公開





- ✓ GTMで同時確率分布を計算するときには、 X, y は区別していない
- ✓ y が複数あっても、 y の間 の 関係 を 考 慮 し た モ デ ル 構 築 ・
モデルの逆解析ができる

数値シミュレーションデータで検証

✓線形

✓非線形


線形の数値シミュレーションデータ

✓線形


- Swiss roll
 - `sklearn.datasets.make_swiss_roll`

$$y = 0.3x_1 - 0.2x_2 + 0.1x_3$$


- 正規分布に従うノイズを追加
 - トレーニングデータ: 500
 - テストデータ: 500



可視化の結果 (線形)






GTM-MLR



GTMR

回帰分析 テストデータの推定結果 (線形)

	GTM-MLR	GTMR	SVR
r^2	0.991	0.980	0.989
MAE	0.192	0.276	0.209



モデルの逆解析の結果（線形）

	目標のy	Xの推定値			GTMマップ上の X推定値		実際のy
GTM- MLR	4	11.90	4.22	4.28	0.31	-0.03	4.01
	0	4.85	-0.20	-7.28	-0.03	0.45	0.02
	-5	-5.74	17.51	-7.62	-0.66	-0.17	-5.00
GTMR	4	6.91	3.02	11.32	-0.86	-0.10	4.04
	0	9.59	11.8	-8.41	0.72	1.00	0.01
	-5	-3.67	18.21	-10.28	0.86	0.52	-4.98

非線形の数値シミュレーションデータ


17

✓非線形


- S-curve
 - `sklearn.datasets.make_s_curve`

$$y = \arcsin(x_1) + \log(x_2) - 0.5x_3^4 + 5$$


- 正規分布に従うノイズを追加
 - トレーニングデータ: 500
 - テストデータ: 500



可視化の結果 (非線形)






GTM-MLR



GTMR

回帰分析 テストデータの推定結果 (非線形) ¹⁹

	GTM-MLR	GTMR	SVR
r^2	0.127	0.964	0.987
MAE	2.58	0.433	0.281



モデルの逆解析の結果（非線形）

	目標のy	Xの推定値			GTMマップ上の X推定値		実際のy
GTMR	6	0.70	1.32	-0.31	-0.59	-0.17	6.1
	-1	-0.59	1.08	-1.82	0.52	0.52	-1.0
	-5	-0.31	0.07	1.94	0.93	-0.10	-5.1

QSPR、QSARへの応用

- ✓ 化合物データの収集
 - ✓ 記述子の計算
 - ✓ GTM-MLR, GTMRによるモデリング
 - ✓ 物性もしくは活性の目標値を設定
 - ✓ GTM-MLRモデル、GTMRモデルの逆解析により目標値になりうる記述子の値を推定
 - ✓ 記述子の推定値にもとづいて化学構造の探索
-
- ✓ 詳しくは論文が掲載されましたらで、、、
もしくは金子研オンラインサロンで
 - <https://datachemeng.com/onlinesalon/>

まとめ

✓データの可視化、回帰分析、モデルの逆解析をつなげる、GTMに基づく手法を開発した

✓GTM-MLR

- 回帰モデルの性能はMLRモデルに依存
- X と y の間の非線形性に対応できない

✓GTMR

- y が複数のときでも対応可能
- X と y の間の非線形性に対応できる
- ノイズに弱い

補足資料 ハイパーパラメータ候補

✓マップサイズ: 30×30

Hyperparameter	Candidate
Number of RBFs $p^{0.5}$	2, 4, ..., 18, 20
Variance of each RBF σ	2^{-5} , 2^{-4} , ..., 2^2 , 2^3
Regularization coefficient λ	0, 10^{-4} , 10^{-3} , 10^{-2} , 10^{-1}

補足資料 ハイパーパラメータの決め方

✓GTM-MLRにおけるGTM

- k3n-error [1] が最小になるように
 - k3n-error: <https://datachemeng.com/k3nerror/>

✓GTMR

- 2-fold クロスバリデーション後の r^2 が最大になるように

補足資料 クロスバリデーション (CV)

✓例) 3-fold クロスバリデーション (Cross-Validation, CV)

