


簡約流体モデルに基づく数値乱流場の構造クラスタリング

奥野彰文^{1,2}, 古田原拓実³, 佐々木真³

¹統計数理研究所 ²理化学研究所 ³日本大学

Overview

- ▶ 数値乱流場 (静電ポテンシャル $\phi(x, y, t)$) のモードのクラスタリング




- ▶ Okuno, Kodahara, and Sasaki, "Hierarchical Clustering of Modes in Numerical Turbulence Fields", PFR: Rapid Communications, accepted.

背景 (1/2)

- ▶ 核融合プラズマの特性は乱流に支配されており、動的現象の理解が喫緊の課題。
 - ▶ 本研究ではKelvin-Helmholtz乱流シミュレーションにより得られた静電ポテンシャル $\phi(x, y, t)$ を考える。
 - ▶ 乱流を直接的に扱うことは難しい。ので分解をしたい。
- ▶ 単純なフーリエ展開では多くの自由度(基底)が生じる。
 - ▶ 分解の粒度が細かすぎて、内部の挙動を理解することは困難。
- ▶ 動的モード分解 (Sasaki et al. PPCF2019) やニューラルネット (Jajima et al. PPCF2023) を利用した解析手法が報告されている。

背景 (2/2)

- ▶ 特異値分解 (SVD) を利用して乱流を分解し, その過程を解析するアプローチが提案されている (Sasaki et al. PPCF2019; Kodahara et al. PFR2023).
- ▶ SVDでも多くの自由度(基底)が残る.



- ▶ 本研究では「乱流の分解」を体系的に扱う方法を考える.

静電ポテンシャルの分解

- ▶ 乱流 (静電ポテンシャル) $\phi(x, y, t)$ をそのまま扱うのは難しいので、独立な要素 ϕ_1, ϕ_2, \dots に分解:

$$\phi(x, y, t) = \sum_{j \geq 0} \phi_j(x, y, t).$$

特異値分解 (a.k.a., 主成分分析)

$$\phi_j(x, y, t) = s_j \Psi_j(x, y) h_j(t).$$

s_j は特異値 (要素 j の重要度), $\Psi_j(x, y)$ は空間構造, $h_j(t)$ は時間発展を表す.

- ▶ 実際にはシミュレーションの観測値から離散的に計算する.

より詳細な構造 $\Psi_j(x, y)$ のリスト





Figure: 背景構造 ($j = 0$), Zonal ($j = 3, 13, \dots$), 乱流 (それ以外)

時間成分 $h_j(t)$ のリスト



構造を分解する手続き


- (1) (とびぬけて寄与率大きい) $j = 0$ を背景構造とする
- (2) $v(r, \theta) = (r \cos \theta, r \sin \theta)$ として, 周方向の Ψ_j の変動の総和

$$c_j := \iint \left\{ \frac{\partial \Psi_j(v(r, \theta))}{\partial \theta} \right\}^2 dr d\theta, (j = 1, 2, \dots)$$

を計算する.

- ▶ c_j が特定の閾値 c_* より小さければ(周方向に変動が小さいので)帯状流,
 - ▶ そうでなければ乱流の成分とする.
- (3) 帯状流, 乱流の要素をそれぞれクラスタリングしてまとめる.


クラスタリングとは？



- ▶ クラスタリング=似た要素をまとめ上げる手続き。


数値乱流場の場合はどうなる？

①



要素に分解
(※特異値分解)


②



クラスタリング



③



▶ 最終的に、「細かすぎない」分解が得られる。

代表的なクラスタリング手法と要望


- ▶ Sasaki et al. (PoP2019) ⇒ 手動でのクラスタリング.
- ▶ 自動化も可能.
 1. k -meansクラスタリング,
 2. mean-shiftクラスタリング,
 3. 混合正規クラスタリング,...

基本的には“いくつのクラスにまとめるか”を指定してクラスタリングする.

- ▶ 自動化しつつ、粒度の設定をフレキシブルにしたい.


階層型クラスタリング

- ▶ 全体を，徐々に要素に分解する手法.




階層型クラスタリング

▶ 細かいまとめ方 (4クラスタ)



階層型クラスタリング: より荒い分類

- ▶ もっと大まかなまとめ方 (3クラス)



どうやって計算するのか?

1. 要素 i, j 間の乖離度(距離) d_{ij} を計算.
2. パッケージに $D = (d_{ij})$ を投げる \Rightarrow デンドログラムが生成される.
3. おわり.

```
linkage_D = linkage(D, method="ward")  
dendrogram(linkage_D)
```

- ▶ 距離 d_{ij} が近いものから徐々に合体させていくクラスタリング.

今回の設定では

モード $\{\phi_j(x, y, t)\}_j$ をまとめたいので、モード ϕ_i, ϕ_j の間の乖離度を定義する必要がある。
いくつかの候補があった。

- ▶ 回転を無視した構造の乖離度: $d_{ij} = \min_{\mathcal{O}: \text{回転行列}} \|\Psi_i - \mathcal{O}\Psi_j\|,$
- ▶ $h_i(t), h_j(t)$ の周波数の乖離度,
- ▶ 特異値の乖離度 $d_{ij} = |s_i - s_j|, \dots$

結論から言うと…

- ▶ 特異値の乖離度で階層型クラスタリング(ward法)するのが一番素朴でよかった。




Figure: 第1特異値-第30特異値のプロット.

各クラスター $\mathcal{J} \subset \{1, 2, \dots\}$ について, $\phi_{\mathcal{J}}(x, y, t) = \sum_{j \in \mathcal{J}} s_j \Psi_j(x, y) h_j(t)$ を計算する.

得られたデンドログラムと、その帰結としての分解

- ▶ 乱流がさらに線形不安定モード・非線形モードに分解された.
 - ▶ 非線形モードは突発性に重要な寄与をする可能性 (Sasaki et al. PPCF2020).
 - ▶ これまでの「背景・帯状流・乱流」の3分割より細かくできる.


今後の課題

- ▶ テンソル型の分解：今回は $\phi_j(x, y, t) = s_j \Psi_j(x, y) h_j(t)$ 型だったが、


$$\phi_j(x, y, t) = \alpha_j(x) \beta_j(y) h_j(t)$$

型などにも分解できる。いろいろ試してみたい。

- ▶ 各クラスタから背景へのエネルギー輸送



まとめ



- ▶ Okuno, Kodahara, and Sasaki, "Hierarchical Clustering of Modes in Numerical Turbulence Fields", PFR: Rapid Communications, accepted.
- ▶ これまで手動でやっていた分解を体系的に自動化できた.
- ▶ 特異値が重複しないケースはより複雑で, 研究中の課題.
- ▶ 連絡先: okuno@ism.ac.jp