

# 動的モード分解を用いた集団運動変化点の検出

猪股能成<sup>1</sup>, 高見利也<sup>2</sup>

<sup>1</sup> 大分大学大学院 工学研究科

<sup>2</sup> 大分大学 理工学部

## 概要

動的モード分解 (DMD) による時系列の再構成誤差に着目した Time-Shifted DMD (TS-DMD) は, 群れの集団運動分析を目的とした新しい手法である. この方法により群れの運動状態の変化を検知できるが, 異なる種類の運動が共存している場合や微小な変化に対する結果が不明だったため, 本研究では, シンプルな集団運動に適用して分析を実施した. その結果, たとえ少数であっても不規則な運動をする粒子の存在を検出できることがわかった. また, 検出は誤差の相対的な比較によることから, 状況によっては, 数値表現の限界まで不連続性を検出可能であることがわかった. これらにより, TS-DMD が集団の運動状態の微妙な変化まで検出できることを確認することができた.

## Detecting Transition of Collective Motion by Dynamic Mode Decomposition

Yoshinari Inomata<sup>1</sup>, Toshiya Takami<sup>2</sup>

<sup>1</sup> Graduate School of Engineering, Oita University

<sup>2</sup> Faculty of Science and Technology, Oita University

## Abstract

Time-Shifted (TS) Dynamic Mode Decomposition (DMD), a new method to analyze collective motion, is introduced by paying attention to reproduction error by DMD. Since it is unknown how this analysis to detect transition of motion behaves for mixed-collective motion or faint change of the motion, analyses for simple collective motion were conducted in this study. As a result, it was shown that TS-DMD recognizes irregular motion by however small number of particles. In addition, it is also shown that it works up to the limit of the number representation. With these analyses, it was confirmed that TS-DMD detects a slight change of collective motion.

## 1 はじめに

人工知能技術の1つである群知能は, 生物などの群れにインスパイアされたアルゴリズムの総称 [1] である. 特徴として, 中心的な役割, いわゆるリーダーがいなくても, 群れとして高度な機能を有することや, 群れを構成する各個体の挙動がシンプルなルールによって決まるなどが挙げられる. 映像作品等で鳥や魚の群れを再現する際も, 個々の挙動はシ

ンプルなルールに従わせることが多く, 群れのシミュレーションモデルとして有名な Boid モデル [2] は, 3つの局所的な相互作用によって群れらしい振る舞いを再現している. また, 各々の相互作用のパラメータを変更することによって異なる群れの振る舞いが発現することが知られている [3].

Boid モデルのような群れのシミュレーションによって発現する運動パターンを分類する研究は既に行わ




図 1: TS-DMD のイメージ ([7] より引用)

れている [4, 5, 6]. 特に藤井氏らによる研究 [4] では、オーダーパラメータのような事前情報を用いず、動的モード分解 (Dynamic Mode Decomposition, DMD) を使うことにより、運動パターンを分類した. しかし、この研究では、ある運動パターンから別の運動パターンに遷移していくことは想定されていないため、DMD を用いて運動の遷移を検知する手法として、我々は Time-Shifted DMD (TS-DMD) を提案した [7]. この手法では、図 1 のように、波形にピークが現れるタイミングと運動パターンが変化するタイミングが一致するようなグラフを得ることができる (図中の (a)~(c) はそれぞれ別の運動パターンが観測された区間を示している). この TS-DMD は、実験を重ねていったことで発見的に提案した手法となっており、どのようなデータを TS-DMD に適用するとどのような出力が得られるのかを完全に理解できていない. そのため、本研究では、比較的シンプルなシミュレーションデータを TS-DMD に適用した結果を確認、比較をすることで、この手法の理解を深め、今後の活用先を検討したい.

## 2 DMD

DMD は、流体力学の分野から提案され [8], 固有直交分解と高速フーリエ変換を組み合わせた手法 [9] である. 解析をしたい時系列データ行列を  $X$  とし、 $X$  の中には各時刻のデータベクトル  $\mathbf{x}_t (t = 1, 2, \dots, T)$  が  $(\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_T)$  のように並べられているとする (各データベクトルは  $N$  次元のベクトルとする). ある時刻  $t$  のデータが、式 (1) のように、前の時刻  $t-1$  における関数  $f$  によって求められると仮定し、この  $f$  を時系列全体に拡張した関数  $F$  を求める.

$$\mathbf{x}_t = f(\mathbf{x}_{t-1}) \quad (1)$$

$F$  を 2 つの行列、 $Y = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_{T-1})$  と  $Y' = (\mathbf{x}_2, \mathbf{x}_3, \dots, \mathbf{x}_T)$  を用いて表すと、 $Y' = FY$  とな




図 2: TS-DMD のイメージ

るが、これは、 $F = Y'Y^\dagger$  と変形できる.  $Y^\dagger$  は  $Y$  の疑似逆行列で、特異値分解を利用すれば、 $Y^\dagger = V\Sigma^{-1}U^*$  と表すことができ、 $F = Y'V\Sigma^{-1}U^*$  となる ( $U \in \mathbb{C}^{N \times M}$ ,  $\Sigma \in \mathbb{C}^{M \times M}$ ,  $V \in \mathbb{C}^{T-1 \times M}$ ,  $M = \min(N, T-1)$ ,  $U^*$  は  $U$  の随伴行列). この行列  $F$  から、固有値  $\Lambda$  と、固有ベクトル  $W$  を求め、動的モード  $\Phi = Y'V\Sigma^{-1}W$  を得る.

さらに、求めた動的モードから元のデータを再構成することができ、ある時刻  $t$  のデータベクトル  $\mathbf{x}_t$  は、以下の式で求められる.

$$\mathbf{x}_t = \Phi \Lambda^t \Phi^\dagger \mathbf{x}_1 \quad (2)$$

## 3 Time-Shifted DMD

DMD は本来、時系列データ内の線形な時間発展をモードとして分解するため、データ内に非線形な変化が含まれるデータでは、上手くモードを求められず、再構成した時系列データと元データとの誤差が大きくなる. 我々が提案している TS-DMD は、この誤差に着目した手法になっており、具体的な処理の流れを図 2 を基に説明する.

DMD の説明と同様に  $1 \sim T$  までの時間を含む時系列データ  $\mathbf{X} = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_T)$  を入力とする. まず、1 回目の計算として、 $\mathbf{X}$  のうち、 $\mathbf{x}_1 \sim \mathbf{x}_d$  の部分のみを切り取り、DMD を実行する. そして、求めたモードから再構成した時系列データ  $\mathbf{X}' = (\mathbf{x}'_1, \mathbf{x}'_2, \dots, \mathbf{x}'_d)$  との誤差  $E_1$  を計算する.  $\mathbf{x}$  が  $N$  次元のベクトルで、 $\mathbf{x}_d = (x_{(1,d)}, x_{(2,d)}, \dots, x_{(N,d)})^T$ ,  $\mathbf{x}'_d = (x'_{(1,d)}, x'_{(2,d)}, \dots, x'_{(N,d)})^T$  と表した場合、 $E_1$  は以下のように求める.

$$E_1 = \max\{\|\mathbf{x}_{(n,d)} - \mathbf{x}'_{(n,d)}\|, n = 1, 2, \dots, N\} \quad (3)$$

次に時刻を 1 つスライドさせ、 $\mathbf{x}_2 \sim \mathbf{x}_{d+1}$  を切り取り、同様にして誤差  $E_2$  を計算、その次が  $\mathbf{x}_3 \sim \mathbf{x}_{d+2}$  のデータで  $E_3$  を計算. このように誤差の計算をデータの切り取りが最後に到達するまで行う.

TS-DMD は本来の DMD と比べ、時間方向に対して局所的に計算するため、時系列データ内で特に




図 3: シミュレーションのキャプチャ (上部の数字はシミュレーション内の時刻)

変化が大きい時間帯でのみ誤差が大きくなる。これをグラフとして可視化すると、その部分がピークのように強調されるため、データが不連続に変化する時刻を視認しやすくなる。

## 4 実験

### 4.1 実験データ

今実験では、群れのシミュレーションデータを数パターン用意し、それぞれを TS-DMD に適用した結果を比較する。

用意するシミュレーションデータとしては、定期的かつ周期的な集団運動としてパターン (1) を作成した。また、ほとんどの個体が集団運動をしている中、集団に属さない形で自由に動いている個体が存在している例としてパターン (2)、集団の概形はそのままではあるが個々の速度が突然変化する例としてパターン (3) を作成した。

パターン (1) は、図 3(A) のように粒子を環状に配置し、全ての粒子を同じ角速度で反時計回りに移動させる。粒子数は 64 体、各々の粒子はおよそ 100 ステップで 1 周し、元の位置へ戻る。パターン (2) では、パターン (1) のシミュレーションにランダムな動きをする粒子 (図 3(A) の赤点) を 1 体追加した。パターン (3) は、粒子の初期位置と初期速度はパターン (1) と同じだが、300 ステップごとに粒子の角速度をランダムに変更する。したがって、シミュレーションの始めは図 3(A) と同じような粒子の配置をしているが、角速度が変更されると、図 3(B) のように前後の粒子との間隔が一定でなくなる。いずれのパターンもシミュレーションの実行時間は 2000 ステップであるため、パターン (3) では角速度の変更が計 6 回行われる。




図 4: TS-DMD の結果




図 5: TS-DMD の結果 (2)

### 4.2 実験結果

パターン (1)~(3) のデータに対し、前節で述べたデータの切り取り幅  $d$  を 100 として、TS-DMD を実行する。図 4~6 は、その結果である。

図 4 は、パターン (1) のデータに対する TS-DMD の結果で、横軸がステップ数  $t$ 、縦軸が誤差  $E_t$  である。図 5 はパターン (1) の結果に加え、パターン (2) のデータでの TS-DMD の結果を示している。赤線がパターン (2) の結果で、黒線がパターン (1) の結果である。また、図 6 はパターン (3) の結果 (緑線) を示したものである。さらに、パターン (1) と (2) については、最も TS-DMD の誤差が大きかった時刻での元データと再構成データの重ね合わせた図を図 7 に示す。赤点が元データ、緑点が再構成データを表しているが、赤点の上に緑点をプロットしたため、点が重なると再構成データの方しか確認出来ない。




図 6: TS-DMD の結果 (3)




図7: 元データと再構成データの重ね合わせ (上部の数字は TS-DMD のステップ数  $t$ )

### 4.3 考察

パターン (1) の結果は、縦軸のスケールが  $1e-13$  で、データの重ね合わせ (図7・左) を見ても、一致しているように見えるが、 $t = 250 \sim 500$  のところで誤差がピークのように大きくなった。これは元のシミュレーションデータを作成するときに桁落ちが生じ、粒子の位置がわずかにずれてしまったことを検知したものである。

パターン (2) に関しては、パターン (1) と比べ、誤差が非常に大きくなっていることが分かる。しかし、全ての粒子で大きな誤差が生じているのではなく、図7・右のように、ランダムに動いていた粒子に限定して大きな誤差が生じた。これは、式 (3) で各々の要素での誤差の最大値を採用したことにより、ランダムに動いていた粒子の誤差が全体の誤差として採用されていたためと考えられる。

また、パターン (3) では、ピークのように誤差が大きくなっている部分が6か所見られ、1つ目のピークは  $E_{250}$  付近で、その後は概ね300ステップごとに現れている。パターン (3) は300ステップごとに角速度を変更したため、1度目の速度変更がTS-DMDで切り取られるのは  $E_{201} \sim E_{300}$  となる。1つ目のピークが現れる  $E_{250}$  付近は、 $E_{201}$  と  $E_{300}$  の中間であるため、粒子の速度が変わるタイミングとピークの現れるタイミングが一致したと言える。

## 5 まとめ

本研究では、魚の群れのような集団運動の状態が変化していることを検知できる手法として提案したTS-DMDに対し、よりシンプルな集団運動データを適用した場合に得られる結果の確認、および比較を行った。実験では、環状に配置した粒子群が周期的に動いているようなシミュレーションのデータに対し、TS-DMDの誤差が限りなくゼロに近づくこと

が確認できた。また、粒子の速度を変更し、全体の運動に変化を与えた場合、その変化が与えられるタイミングを確認できた。一方で、誤差を計算する際、各々の要素における誤差のうち最大のものを採用していたことによって、ランダムな動きをする粒子を1体加えただけで結果のグラフが大きく変動してしまった。そのため、最大値だけでなく、平均値や中間値など、誤差の散らばり度合いを確認できるようにする必要があると考える。

今後の展望としては、誤差の散らばり度合いの確認に加え、TS-DMDでの誤差が大きくなる、または小さくなる要因がシミュレーション結果と比較しなくても分かるようにすることが考えられる。これは、本手法を群知能へ適用する場合、粒子の移動する空間が4次元以上になる可能性があり、粒子のデータを直接可視化できないためである。現在は、TS-DMDの計算過程で求められる動的モードを効果的に可視化する手法などを検討している。

**謝辞** 本研究はJSPS 科研費 JP18K11338 の助成を受けたものです。

## 参考文献

- [1] D. Martens, B. Baesens, T. Fawcett, Machine Learning, Vol. 82, pp.1-42 (2011).
- [2] Craig W. Reynolds, Computer Graphics, Vol.21, No.4, pp.25-34 (1987).
- [3] I. D. Couzin *et al.*, Journal of Theoretical Biology, Vol.218, pp.1-11 (2002).
- [4] K. Fujii, T. Kawasaki, Y. Inaba, Y. Kawahara, PLOS Computational Biology 14(11): e1006545 (2018).
- [5] Matthew Berger, Lee M. Seversky, Daniel S. Brown, 2016 IEEE International Conference on Robotics and Automation (ICRA), pp.5328-5335 (2016).
- [6] Tunström K, *et al.*, PLOS Computational Biology 9(2): e1002915 (2013).
- [7] Y. Inomata, T. Takami, Traffic and Granular Flow 2019, pp.373-379 (2020).
- [8] Peter Schimid, Journal of Fluid Mechanics, 656, pp.5-28 (2010).
- [9] 土肥宏太, 武石直也, 矢入健久, 堀 浩一, 人工知能学会全国大会 (第 32 回) 論文集, 1P2-02 (2018).