

# 動的モード分解を用いた音響データの異常検知

## Anomaly Detection on Sound Data Using Dynamic Mode Decomposition

土肥 宏太      武石 直也      矢入 健久      堀 浩一  
Kota Dohi      Naoya Takeishi      Takehisa Yairi      Koichi Hori

東京大学 航空宇宙工学専攻  
Department of Aeronautics and Astronautics, The University of Tokyo

As the evolution of sensors and computers enables collecting abundant data, methods to analyze high-dimensional data are becoming important. Dynamic mode decomposition (DMD) is a data-driven method to extract dynamic structure from data and is attracting attention recently. In this study, we made use of DMD to analyze sound data of rotary machines with normal and abnormal states. We applied DMD to spectral distributions of the data and analyzed the dynamic structure of spectral distributions. We found that on spectral distributions of data from abnormal states, time-decaying structure is more likely to be dominant than those from normal states.

### 1. 背景

近年の計測技術の発達やコンピュータによる計算能力の向上により、大量の観測点を設けて測定データやシミュレーションデータを得ることが可能になった。こうして得られた高次元のデータは現象を精密に再現する一方で、処理の際多くのコストを要するだけでなく、現象の理解を困難にする可能性がある。したがって、高次元データから実現可能なコストで情報を抽出する手法が必要とされるようになった。

高次元データから次元削減により情報を抽出する手法として以前から用いられているものに、主成分分析 (Principal Component Analysis, PCA) や固有直交分解 (Proper Orthogonal Decomposition, POD) 等がある。これらの手法は静的なデータに対して次元削減を行うことができるが、動的な情報抽出には適さない。一方で高速フーリエ変換 (Fast Fourier Transform, FFT) は個々の観測点の動的な情報抽出に適しているが、系全体の挙動を把握し次元削減を行うことはできない。

動的モード分解 (Dynamic Mode Decomposition, DMD) は POD と FFT の特徴を組み合わせた手法であり、高次元時系列データから動的モードと呼ばれる低次元基底を抽出して次元削減を行うことができる。DMD の最大の特徴は、系の時間発展と各観測点の系に対する寄与を同時に表すことが可能な点である。DMD は Schmid らによって 2008 年に提案されて以降、主に流体分野の解析に適用されてきた [Rowley 09, Schmid 10, Tu 14]。近年では衛星の観測データ解析 [Giannakis 15] や感染症の流行解析 [Proctor 15]、脳波解析 [Brunton 16] など様々な分野において有用性が報告されており、今後多くの分野での適用が期待されている。

本研究では DMD を系の状態データに適用し、異なる状態の識別や状態特性の観測を行うことで、DMD の有用性を評価することを目的とした。

### 2. Dynamic Mode Decomposition の概要

#### 2.1 アルゴリズムと特長

時刻  $k \sim k+1$  ( $k \geq 1$ ) においてシステムの状態データ  $x_k$  から  $x_{k+1}$  への時間遷移を考える。各時刻の状態データを時系列に

並べてデータ行列  $X, X'$  を生成し、時間遷移行列  $A$  により系全体の時間遷移を表すことができると仮定する。

$$X = [x_1 \ x_2 \ \cdots \ x_k] \quad (2.1)$$

$$X' = [x_2 \ x_3 \ \cdots \ x_{k+1}] \quad (2.2)$$

$$X' \approx AX \quad (2.3)$$

$X$  の特異値分解の結果から、 $A$  を POD 基底に投影した  $\hat{A}$  の固有値分解の結果を得る。これにより  $A$  の固有値分解の結果を得ることができる。 $A$  の固有値行列  $\Lambda$ 、固有ベクトル行列を  $\Phi$  として係数ベクトルを  $b$  とすると、 $x_k$  は次のように再構成される。

$$A\Phi = \Phi\Lambda \quad (2.4)$$

$$x_k \approx \Phi\Lambda^k b \quad (2.5)$$

$$= \Phi\Psi \quad (2.6)$$

ここで  $\Phi$  の各列ベクトル  $\phi_i$  は動的モードと呼ばれ、系全体の各観測点に対する寄与を表す。 $\Lambda$  は複素行列であり、各成分の絶対値が系の減衰、角度成分が系の振動に相当する。このように  $\Phi$  と  $\Psi$  によって、系の時空間構造を捉えることができる点が DMD の特長である。また、固有値行列  $\Lambda$  により系の減衰を捉えることができるため、FFT では捉えることが困難な、減衰振動現象の動的構造を捉えることが可能である。例として、1000Hz、2000Hz、3000Hz の合成波の 3000Hz の項に減衰項を掛け合わせたデータ  $y$

$$y = \sin(1000 \cdot 2\pi t) + \sin(2000 \cdot 2\pi t) + \sin(3000 \cdot 2\pi t) \cdot \exp(-300t) \quad (2.7)$$

に対して DMD および短時間フーリエ変換 (Short Time Fourier Transfer, STFT) を適用した。結果を図 2.1、2.2 に示す。図 2.2 の DMD による結果では、図 2.1 の STFT による結果では捉えられなかった振動数 3000Hz に相当するパワースペクトルを捉えることができている。

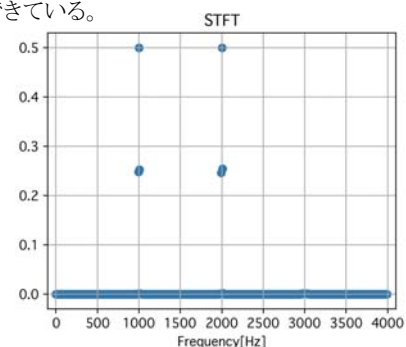


図 2.1 STFT を適用した結果。

連絡先: dohi@g.ecc.u-tokyo.ac.jp




図 2.2 DMD を適用した結果.

## 2.2 応用研究例

動的モードの減衰率に注目した例として、エンジン燃焼室内のバッフル付き燃料注入器の最適な取り付け間隔を求めた Jourdain らの研究がある[Jourdain 13]. Jourdain らは、燃料注射器の間隔を変化させながら燃焼室内に圧力擾乱を加えた数値計算を行い、得られた音圧データに DMD を適用している。各動的モードの減衰率を比較することで、圧力擾乱を最も減衰させる燃焼注射器の間隔を求めることに成功している。

## 3. 実験

### 3.1 実験の概要

この実験では石油会社 A より提供された、製油所内の回転機の模擬音データを用いて、軸受けに傷がある場合の音（異常音と呼ぶ）と傷がない場合の音（正常音と呼ぶ）の DMD による識別、特性推定を行った。音圧データは、異常音の有無、集音地点（2種類）、軸受け回転数（600rpm、1200rpm、1800rpm）による 12 種類のデータを用いた。

まず、各時間帯の音響データに対して STFT を適用し、得られたスペクトル分布を時系列に並べて図 3.1 のようなスペクトログラムを生成した。ここで、各時間帯におけるスペクトル分布は 2.1 節で示したシステムの状態データ  $x$  に相当し、スペクトログラムは  $x$  を時系列に並べたデータ行列  $X$  に相当する。

次にスペクトログラムの時間遷移に対して DMD を適用することで、異常音と正常音のスペクトル分布の動的特性を把握することを試みた。特に DMD が系の減衰特性を捉えることができることを考え、スペクトル分布の減衰特性に注目して異常音と正常音を識別することとした。

このように、STFT によって得られる各周波数成分を一つ一つの観測点とみなして DMD を適用することで、1次元の音響データに対しても高次元のデータと同じように DMD を適用することが可能になる。このような適用方法によりデータの振動的成分を考慮せず、減衰的な成分のみを抽出することを目指した。




図 3.1 スペクトログラムの例.

### 3.2 結果

図 3.2 に示すように、各 160 秒間の音響データから時系列に 6,000 個のスペクトル分布を得た上でそれらを 10 個ずつに区切ってスペクトログラムを生成し、それぞれに対し DMD を適用した。




図 3.2 スペクトログラムの生成.

2.1 節で説明したように、DMD の結果得られる固有値行列  $\Lambda$  と係数ベクトル  $b$  を用いることで、各動的モードの時間発展  $\Psi$  を求めることができる。ここで、特異値分解の結果から、 $\Psi$  の第  $i$  成分は系全体に対する寄与率が  $i$  番目に大きい動的モードの時間発展に相当する。以下、 $\Psi$  の第  $i$  成分に相当する動的モードをモード  $i$  と呼ぶ。したがって、モード 1 は系の動的モードの中で系全体に対する寄与率が最も大きく、支配的なモードとなる。

多くのスペクトログラムにおいて、DMD を適用して得られた動的モードのうち最も寄与率が大きく支配的であったのは、図 3.3 のモード 1 のような振動数 0 の非振動的なモードであった。一方で図 3.4 のモード 1 およびモード 1 と共役なモード 2 のように、振動的なモードが支配的になった場合も存在した。これらの分析を 12 種類の音響データから得られるスペクトログラムに対して行った。その上で、各音響データにおいて支配的なモードが非振動的になる割合を調べた。結果を図 3.5 に示す。図 3.5 からはいずれの回転数、地点においても異常音の支配的なモードが非振動的なモードになる割合が高いことがわかる。この傾向は、特に 1200rpm のデータにおける結果で顕著である。これにより、異常音と正常音を支配的な動的モードの種類によって識別できる可能性が示された。また、異常音の各振幅スペクトルは本実験で用いた時間幅については、単調的に減衰する傾向にあることが示された。




図 3.3 減衰モードが支配的な区間の例.




図 3.4 振動モードが支配的な区間の例.




図 3.5 減衰モードが支配的になる区間の割合.

#### 4. まとめ

DMD には系の時空間構造を同時に分析できる点や、系の減衰特性をとらえることができる点などの特長が存在する。音響データに対して、スペクトル分布の減衰特性に注目しながら DMD を適用することで、異常音と正常音でスペクトル分布の減衰構造が異なる傾向にあることがわかった。今後は、STFT や DMD を適用する時間幅を変更するなどして、異常音と減衰特性の関係性について知見を深めることがあげられる。

#### 参考文献

- [Rowley 09] Rowley, Clarence, *et al.*: Spectral analysis of nonlinear flows, *Journal of Fluid Mechanics*, **641** (2009), 115-127.
- [Schimid 10] Schmid, Peter: Dynamic mode decomposition of numerical and experimental data, *Journal of Fluid Mechanics*, **656** (2010), 5-28.
- [Tu 14] Tu, Jonathan, *et al.*: On dynamic mode decomposition: theory and applications, *Journal of Computational Dynamics*, **1** (2014), 391-421.
- [Giannakis 15] Giannakis, Dimitrios, Joanna Slawinska, Zhizhen Zhao: Spatiotemporal Feature Extraction with Data-Driven Koopman Operators, *JMLR Workshop and Conference Proceedings*, **44** (2015), 103-115.

[Proctor 15] Proctor, Joshua, and Philip Eckhoff: Discovering dynamic patterns from infectious disease data using dynamic mode decomposition, *Int Health*, **7** (2015), 139-145.

[Brunton 16] Brunton, Bingni, *et al.*: Extracting spatial-temporal coherent patterns in large-scale neural recordings using dynamic mode decomposition, *Journal of Neuroscience Methods*, **258** (2016), 1-15

[Jourdain 13] Jourdain, Guillaume, *et al.*: Application of dynamic mode decomposition to acoustic-modes identification and damping in a 3-dimensional chamber with baffled injectors, *Journal of Sound and Vibration*, **332** (2013), 4308-4323.