

# 圧縮機内部流れの圧力波形学習による不安定現象の予兆分析 — 4 段軸流圧縮機への適用事例 —

## Predictive Analysis of Unsteady Phenomena in Compressor with Pressure Waveform Learning - Case Study of 4-Stage Axial Compressor -

丹羽 直之\*<sup>1</sup>  
NIWA Naoyuki

中山 健太郎\*<sup>1</sup>  
NAKAYAMA Kentaro

金澤 直毅\*<sup>1</sup>  
KANAZAWA Naoki

### ABSTRACT

This paper discusses the prediction technology of unsteady phenomena in compressor such as rotating stall and surge, it would be a cause to limit the operation range. In rig test of the 4-stage axial compressor developed in KHI, the pressure waveform is measured during occasion of these unsteady phenomena. In this study, the feature of pressure waveform is extracted by machine learning using the Transformer model and be used for classification and prediction of unsteady phenomena.

キーワード：ガスタービン，圧縮機，旋回失速，サージ，機械学習

Key words : Gas Turbine, Compressor, Rotating Stall, Surge, Machine Learning

### 1. はじめに

ガスタービンの運転範囲を制限する要因の一つは圧縮機のサージや旋回失速といった不安定現象である。運転範囲の制限は燃費の悪化に繋がるため、圧縮機開発において作動限界（サージ限界）の評価技術は重要な要素となっている。しかしながら、サージ限界はCFD等により正確に予測することが難しく、試験による計測に頼らざるを得ないのが現状である。それに加えて、製造上のバラツキや経年劣化、吸気条件の変化等を考慮するとサージ限界の評価はさらに困難になる。

そこで本研究では、圧縮機から取得できるデータを監視し、圧縮機の作動状態やサージ限界を動的に診断する手法の開発を行う。不安定現象を予測し状況に応じたマージン設定が可能になることで、より安全な運転制御や燃費の改善を実現することを目指している。本稿では、近年の発展が目覚ましい機械学習技術を用いて圧縮機の作動状態の変化を学習させ、サージや旋回失速の発生診断を行う。機械学習を用いることで膨大な試験データから様々な作動状態の圧力波形を学習し、不安定現象の発生の兆候などの従来技術では捉えることが困難な特徴を検出することが期待できる。先行研究<sup>(1),(2)</sup>では統計的手法やクラスタリングを用いて不安定現象の分類が可能なが示されている。本研究では大規模データに適合するより深いネットワークモデルを用いて不安定現象の分

析を行う。本稿では当社（川崎重工業株）で開発した4段軸流圧縮機<sup>(3)</sup>を対象にした機械学習と不安定現象発生時の圧力波形分析の結果について述べる。

### 2. 4 段軸流圧縮機試験

#### 2.1 圧縮機概要

4 段軸流圧縮機の概略図と動翼枚数をFig. 1とTable 1に示す。IGVは可変翼であり、その他の静翼は固定翼である。圧縮機の下流にはタービンが設置される。圧縮機は電動機によって駆動され、排気ダクトの下流に設置した弁の開度あるいはタービンの可変ノズルの開度を調整することで圧力比を操作しながら試験を行った。圧縮機の圧力比や効率はIGV上流と4段静翼下流に設置したプローブで計測した全圧・全温によって評価した。1段動翼上流の壁面には圧力トランスデューサーを設置し、圧力波形の計測を行った。その際、サンプリング周波数は50kHzあるいは100kHzで計測した。

#### 2.2 試験結果

Fig. 2に試験で計測した圧縮機の特性格線の例を示す。特性格線の計測は修正回転数が一定になるように電動機の回転数を調整し、低圧力比側の作動点から排気側の弁あるいはタービンの可変ノズルを閉じることで圧力比を上げながら行った。図中の各点は状態を静定させて計測を行った点を示す。試験はサージが発生するか、あるいは旋回失速による振動等により安全上の懸念が発生するまで行った。Fig. 2の例では計測区間Bで旋回失速が発生し、計測区間Cでサージが発生した。旋回失速の発生は監視している圧力波形の高速フーリエ変換（FFT）結果より翼通過周波数（BPF: Blade Passing

原稿受付 2025年7月28日


査読完了 2026年3月17日

\* 1 川崎重工業株

〒673-8666 明石市川崎町 1-1

E-mail: niwa\_naoyuki@global.kawasaki.com

Frequency) 以外の周波数成分が顕在化することや作動音が変化すること、流量・圧力比の大きな変動を伴わないことから判断した。サージの発生は圧力振幅の急激な増大や回転軸の振動の増大、脈動的な大きな作動音の発生から判断した。



(a) Overall view of test rig<sup>(3)</sup>  
 (b) Schematic view of compressor section  
 Fig. 1 Test rig of 4-stage axial compressor

Table 1 Specifications of compressor

Shaft speed [min <sup>-1</sup> ]	8750				
Stage	IGW	1	2	3	4
Number of rotor blade		33	51	57	63
Number of stator vane	52	68	76	84	90
Tip clearance(%span height)		0.62	0.84	1.06	1.28
Relative Mach number @Tip		1.2	0.9	0.9	0.9

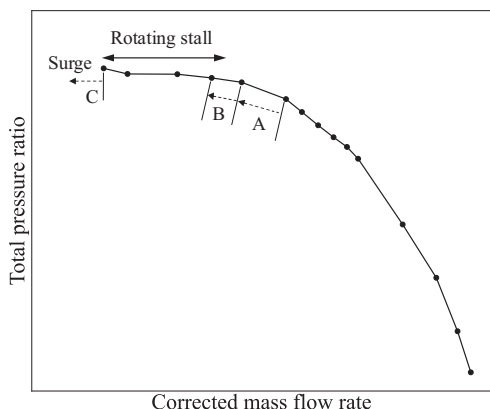
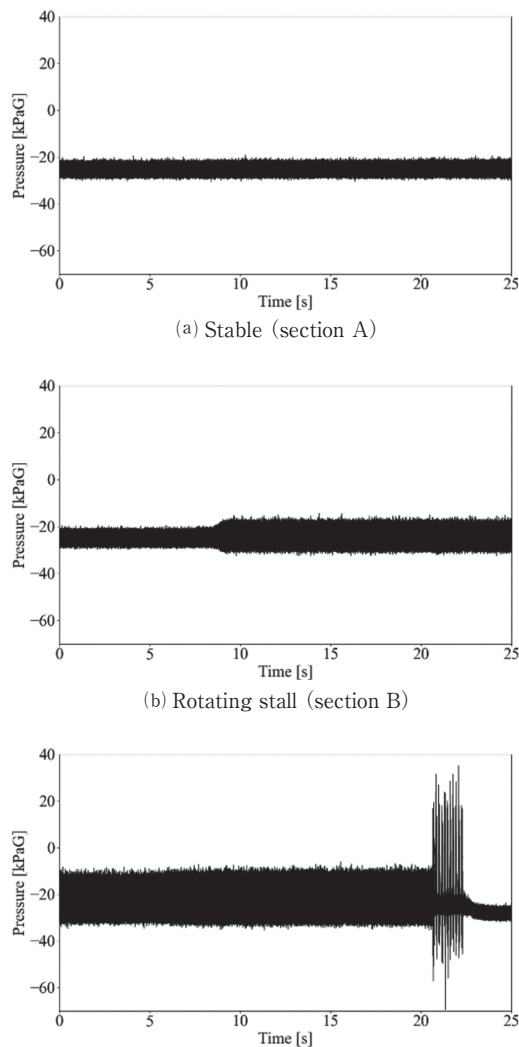


Fig. 2 Characteristic curve of compressor (Test Result)

2.3 フーリエ解析による圧力波形分析


1 段階動翼上流のセンサで計測した圧力波形の分析結果として、Fig. 3およびFig. 4に平常時、旋回失速発生時およびサージ発生時の圧力波形と短時間フーリエ変換 (STFT: Short Time Fourier Transform) 結果を示す。

STFTは1 段階動翼のBPF近傍より低い周波数域を可視化した。各図の(a),(b),(c)はそれぞれFig. 2の計測区間A, B, Cのデータを処理した結果である。平常時(a)は、4 kHz付近のBPF以外に目立った周波数成分はない。旋回失速はFig. 3 (b)の8 sec以降から発生する。STFT結果には0.1kHzと1.5kHz程度に顕著な周波数成分が複数現れる。3 kHzおよび4.5kHz程度の周波数成分は1.5kHzの高調波と推測される。計測区間Bでは流量や圧力比の大きな変動を伴わないことから、これらの周波数成分は旋回失速によるものと考えられる。また、複数の周波数成分が発生していることから失速セルの数が安定していない状態と推測される。サージはFig. 3 (c)の20 ~ 23secの間で発生し、それ以前の区間では旋回失速が発生している。サージの発生後に出口弁を開く操作を行ったためサージおよび旋回失速は終息する。サージの圧力波形の振幅ピークの間隔から周波数を概算すると約6 Hzである。また、STFT結果によるとサージ発生時は全周波数成分が増加することが分かる。




(a) Stable (section A)  
 (b) Rotating stall (section B)  
 (c) Surge (section C)  
 Fig. 3 Pressure trend


フーリエ解析による圧力波形分析では、回転失速やサージの発生などの大きく変化する周波数成分の判別は容易であることが分かる。一方で、微細な周波数成分の変化を判別することは難しい。不安定現象の発生に予兆があるとなれば、はじめは微細な変化であると推測されるため、より適した分析手法が必要である。



(a) Stable (section A)



(b) Rotating stall (section B)



(c) Surge (section C)

Fig. 4 STFT results

### 3. 機械学習モデル

#### 3.1 学習モデル概要

圧力波形を学習するモデルとして、自然言語処理分野を中心として多くの分野で高い性能を発揮しているTransformer<sup>(4)</sup>を用いたモデルを使用する。また、膨大な試験データに対するラベル付けの作業（アノテーション）が煩雑であることと、従来の手法では見逃していた領域を識別するため、教師なし学習で波形の分類を行う。

Fig. 5に採用したモデル構造を示す。Table 2に主要なパラメータを示す。学習モデルの前半はTransformerのEncoderモデルの構造である。モデルの後半はDeep Clusterモデル<sup>(5)</sup>を参考にした擬似ラベルによる多クラス分類モデルの構造（以下、分類器モデル）である。

学習においては、後述するように圧力波形をメルスペクトログラムに変換してモデルに入力する。Transformerモデルは入力された圧力波形の特徴抽出を担う。分類器モデルでは、学習時にまず擬似ラベルの生成が行われる。Transformerモデルで抽出された特徴量をMLP（Multi-Layer Perceptron）層で次元削減し、主成分分析（PCA: Principal Component Analysis）によりさらに次元削減した後、k-means法によりクラスタリングを行い、擬似ラベルを生成する。分類器としての出力はMLP層と接続した線形層から出力し、擬似ラベルを正解ラベルとして学習を行う。この際、各擬似ラベルのサンプル数に偏りがあると分類精度が低下する可能性があるため、損失関数の計算時に各擬似ラベルのサンプル数の逆数で重み付けを行った。なお、推論時は擬似ラベルの生成層は使用しない。

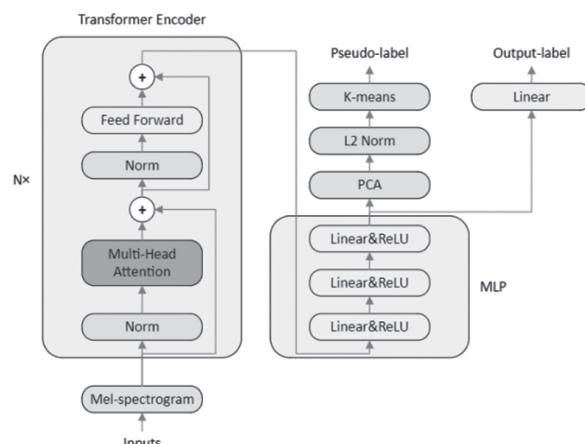


Fig. 5 Model architecture

Table 2 Parameter of model

Mel spectrogram	Mel filterbanks	128
	Max frequency	BPF × 1.05
Transformer	Dimension of input	128
	Number of heads in multi-head attention	16
	Dimension of feed forward model	512
	Number of layer	12
	Activation function	ReLU
	Dropout	0.1
	Layer normalization	pre-norm
Classification	Number of MLP layer	3
	Dimension of MLP output	16
	Number of Class	8

### 3.2 データ前処理

前処理として圧力波形のメルスペクトログラムへの変換を行った。Fig. 6にメルスペクトログラムに変換した波形の例を示す。メルスペクトログラムは音声処理の分野で主に用いられる手法であり、低周波数ほど周波数解像度が高くなる特性を持つ。圧力波形を構成する周波数成分の内、旋回失速の周波数は失速セルの数が1つの場合は回転周波数より低く、サージの周波数も配管系にも依るが数Hz程度である。一方で、失速セルが複数ある旋回失速の周波数はこれらの周波数より高くなると想定されるが、一般に旋回失速の周波数はBPFよりも十分に低い。したがって、圧縮機の圧力波形の構成周波数成分の内、解像すべき周波数は低周波数側に偏っているため、メルスペクトログラムの特性は圧力波形を処理する上でも有用である。また、メルスペクトログラムは出力する周波数範囲を設定してデータを成形できるため次元削減の点でも優れている。

学習モデルはメルスペクトログラムから振幅と周波数の対応関係および各成分の相対関係、それらの時間変化を学習し分類を行う。




Fig. 6 Mel spectrogram during rotating stall

## 4. 学習結果

### 4.1 学習データ

学習に用いたデータはFig. 2の特性曲線を含む複数の回転数の圧縮機特性の取得時に計測した約1.5時間分の圧力波形データを用いた。全データの内、約85%が平常時、約15%が旋回失速時のデータである。サージ時のデータは数秒程度で全体の約0.1%しかないため、学習データとして十分ではない。学習データは9割を訓練用、残りを検証用として分割した。Table 3に学習時の主要な設定を示す。Fig. 7に学習時の誤差の推移を示す。過学習を防ぐために検証データに対する損失が一定回数以上低下しなくなった場合に学習を打ち切った。

Table 3 Parameter of learning

Loss function	Cross Entropy
Optimizer	RAAdam
Initial leaning rate	0.001
Schduler type	StepLR
Schduler step size	10
Schduler gamma	0.8
Batch size	200




Fig. 7 Loss trend in training

### 4.2 分類結果

機械学習により全学習データをClass 0～7の8つのクラスへの分類を行った。Fig. 8に圧力波形の分類結果を示す。この圧力波形はFig. 2の特性曲線を計測した際の全ての波形を時系列で結合し、分類した結果である。縦の破線は計測区間の区切りを示す。計測は圧力比を上げる操作の前後を通して行った。計測区間の区切りごとに数分間の静定時間を設けており、その間は計測を行っていない。波形の分類結果より、圧力比を上げていくと分類されるクラスが変化しており、機械学習により圧力波形の特徴変化を捉えていることが分かる。なお、Class 3～Class 5は本稿で例示するFig. 2の特性曲線における波形ではほぼ出現せず、他の回転数における波形において出現する。




Fig. 8 Whole pressure with classification label

計測区間A～Cにおける圧力波形の分類結果をFig. 9に示す。

Fig. 9 (a)は、旋回失速が発生する直前の計測区間Aの圧力波形であり、全てClass 2に分類される。Fig. 8より、計測区間Aよりも前の計測区間ではClass 0やClass 1に

分類されており、これらはより圧力比の低い条件であることから、機械学習が圧力比上昇に伴う特徴の変化を捉えて異なる分類をしていることが分かる。

Fig. 9 (b)は、旋回失速が発生した計測区間Bの圧力波形であり、主にClass 2とClass 6に分類される。旋回失速が発生する8sec以前はClass 2に分類され、発生以降はClass 6に分類される。Fig. 8より計測区間B以降はClass 6が支配的であることから、Class 6の出現は旋回失速の発生に対応していると推測できる。また、旋回失速の発生に伴ってClass 2からClass 6に遷移する過程でわずかな間Class 3の分類が出現する。これは他のより高い回転数の波形分類で主に出現する平常時のクラスである。旋回失速の発生初期における振幅の増加を平常時の圧力比上昇による振幅増加と混同して分類している可能性がある。

Fig. 9 (c)は、サージが発生した計測区間Cの圧力波形である。サージ発生前の波形は概ねClass 7に分類される。サージ発生中はClass 6とClass 7に分類されているが、サージのデータは全学習データの内のごく僅かであることから十分に学習できているとは判断しがたい。しかしながら、Fig. 8より計測区間Cとその直前の計測区間を比べると、Class 6からClass 7へ分類結果が変化することから、サージ直前にその予兆に類する圧力波形の特徴の変化を捉えた可能性がある。

Fig. 10に計測区間Cとその直前の計測区間の周波数分析結果を示す。機械学習への入力と同等のスケールで比較するため周波数はメル尺度で示す。サージが発生する前の両計測区間を比較すると、Class7に分類された計測区間Cの圧力波形は、Class6に分類された直前の計測区間の圧力波形よりも旋回失速による周波数成分である150melsや1300mels近傍の周波数成分が増加している。特に150mels付近は回転周期よりもやや低い周波数であり失速セル1つ分に相当すると推測すると、複数の失速セルが結合しより大きな失速セルが形成されつつあると解釈できる。また、1300mels近傍の3つの振幅ピークの内、直前の計測区間では中央の振幅ピークが卓越しているのに対し、計測区間Cでは両隣の振幅が増加していることも失速セルの数が不安定化していることを示している。機械学習はこのような特徴の変化に注目し分類を行っていると考えられる。

Fig. 11に全学習データのMLP層の出力（特徴ベクトル）を主成分分析し、第1主成分と第2主成分を投影した図を示す。これまでの考察やSTFTによる分析と照らし合わせると、概ね次のように分類される。Class 0~5は平常時に分類され、Classの番号が大きくなるほど旋回失速やサージに近い状態になる。Class 6およびClass 7は旋回失速およびサージに分類される。計測区間A～Cの平常時や旋回失速時などの代表的な点の特徴量をプロットすると、各状態によって特徴空間上の位置が明確に異なることが分かる。このことから、例えば図中の破

線で示すような境界を設けて旋回失速等の発生を判断するなど、特徴空間上で適切な閾値を設けることにより不安定現象の発生検知や発生までのマージンの設定が可能と考えられる。一方で、各クラスの境界はk-means法による重心ベースのクラスタリングに基づいており、一部の分類クラスの境界は、例えばClass 0とClass 1の境界など、物理的な意味を解釈することが困難である。

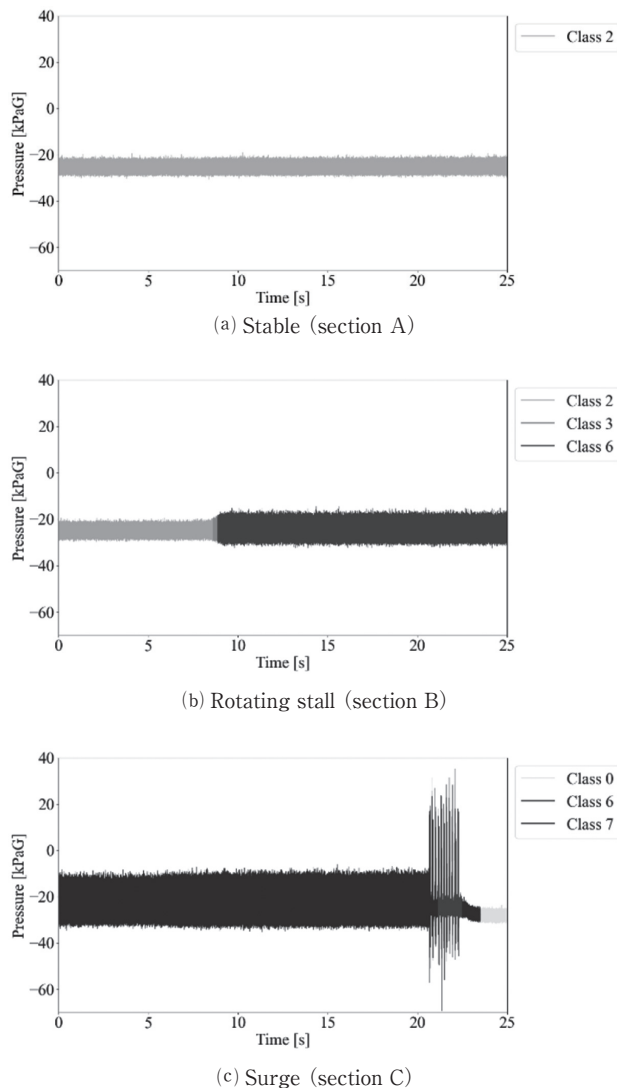


Fig. 9 Classified pressure trend

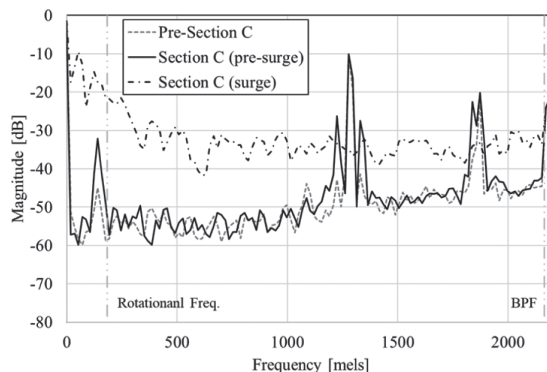


Fig. 10 Frequency analysis results in Section C

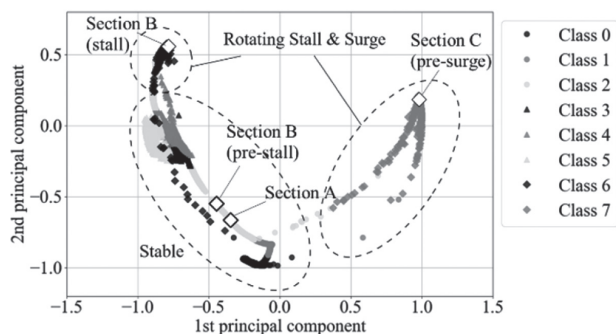


Fig. 11 Latent distribution of reference points

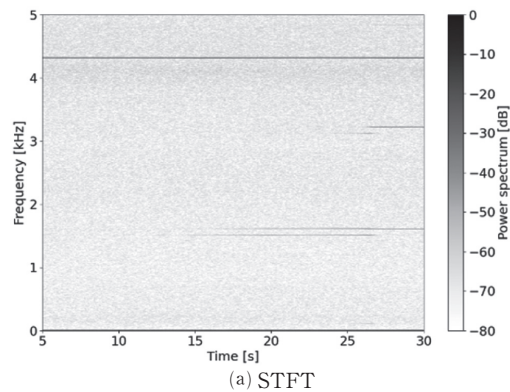
Fig. 12にFig. 2に示した特性曲線よりも高い回転数条件における旋回失速発生時の圧力波形のSTFTと分類結果を示す。Fig. 12 (a)のSTFT結果において、4.2kHzのBPF以外の周波数成分は15sec以降の1.6kHz付近に現れ、26sec以降の3.2kHz付近にその高調波と思われる成分が現れる。これらの周波数成分は旋回失速によるものであると推測される。Fig. 12 (b)の圧力波形と比較すると振幅が明確に増大するのは26sec以降であり、それ以前の周波数成分は比較的弱い波形であることが分かる。Fig. 12 (b)の分類結果を見ると、26sec付近を境にして分類結果がClass 4からClass 5を経てClass 6に変化している。Class 6が旋回失速の波形に割り当てられる点はFig. 9の結果と共通している。一方で、15sec以降に現れる周波数成分には分類結果が変化せずClass 4のままである。前述の通り、今回採用した分類手法はデータの重心に基づくクラスタリングに依存しており、特徴空間上で近い距離にあるクラス分類境界の物理的な意味は曖昧である。今後、このような特徴変化も正確に分類できるよう手法の改善が必要である。

## 5. まとめ


4段軸流圧縮機を対象に圧力波形の機械学習と波形分類を行った。その結果、機械学習により旋回失速やサージの分類が可能なが示された。圧力波形の微細な特徴変化を捉えることが可能であり、不安定現象の予兆検出への利用の可能性が示された。

一方で、次の課題があることが示された。1つ目の課題はデータに著しい偏りがあることである。今回使用した計測データは8割以上が平常時のデータであり、不安定現象発生中のデータが相対的に少ない。特にサージについては安全上の問題から長時間の計測データを得ることは困難である。このため、8つの分類クラスの内、6つのクラスが平常時の波形に割り当てられており、学習が偏った方向に集中していることが分かる。この対策として、全データに対してアノテーションを行い、各状態で学習データ数が均一になるように調整を行う方法やCFDを用いて不足するデータを補う方法などが考えられる。

2つ目の課題は、各分類クラスの境界がクラスタリングに依存しており、境界の位置に物理的な解釈を見出すことが難しい点である。これについても、アノテーションによって各状態をどのクラスに割り当てるか方向付けを行う必要があると考えられる。



(a) STFT



(b) Classified pressure trend

Fig. 12 Classification of higher speed condition

## 参考文献

- (1) Fangyuan, L., Nicole, L., Compressor Stall Warning Using Nonlinear Feature Extraction Algorithms, *Journal of Engineering for Gas Turbines and Power*, Vol. 142 (2020).
- (2) 宮澤弘法, 萩田泰晴, 早川陸駆, 古澤卓, 山本悟, 産業用ガスタービン圧縮機翼列流動の全周計算に基づく不安定稼働条件の分類, 第51回日本ガスタービン学会定期講演会, (2023).
- (3) Toshimasa, M., Shuichiro, H., Hikaru, O., Naoki, K., Prediction and Suppression of Low-Engine-Order Excitation of Axial Compressor Blisk Due to Measurement Probes, IGTC-2023-036 (2023).
- (4) Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A., Kaiser, L., Polosukhin, I., Attention Is All You Need, NIPS (2017).
- (5) Mathilde C., Piotr B., Armand J., Matthijs D., Deep Clustering for Unsupervised Learning of Visual Features, ECCV (2018).