

# 深層学習による気液二相流の流動様式判別に関する研究

## Study on Flow Pattern Discrimination of Gas-Liquid Two-Phase Flow By Deep Learning

権山 昂生<sup>\*1</sup>・箕手 一真<sup>\*2</sup>・吉田 光希<sup>\*1</sup>・坂本 勇樹<sup>\*2</sup>  
 Koki KABAYAMA, Kazuma MINOTE, Koki YOSHIDA, Yuki SAKAMOTO  
 多根 翔平<sup>\*2</sup>・中島 曜<sup>\*2</sup>・小林 弘明<sup>\*3</sup>・佐藤 哲也<sup>\*1</sup>  
 Shohei TANE, Yo NAKAJIMA, Hiroaki KOBAYASHI, Tetsuya SATO

**Key Words:** Multiphase Flows, Flow Pattern, Deep Learning

**Abstract:** Flow pattern discrimination is very important to control gas-liquid two-phase flow because flow patterns affect major parameters on the flow such as heat transfer coefficient and pressure loss coefficient. However, flow patterns have been discriminated by observers qualitatively without clear criteria and so the discrimination is often different by the observers. Therefore, in this paper, automatic determination of flow patterns is the final goal, and as a preliminary step, automatic determination of flow condition from flow image was attempted. We used deep learning as a discrimination method. Since a large amount of images are necessary for the use of deep learning, we conducted experiments first to acquire flow images. We trained deep learning model using the flow images and succeeded in highly accurate discrimination of the flow images. On the other hand, the discrimination accuracy of the flow images obtained by the experiment conducted under the same conditions on the other day was low, indicating the low versatility of the obtained deep learning model. We adjusted the epoch number and expanded the training data by image processing, and the discrimination accuracy increased from 12.3% to 49.0%.


### 記号の説明

$\chi$ :	クオリティ	
$\alpha$ :	ボイド率	
$\rho$ :	密度	kg/m <sup>3</sup>
$\mu$ :	粘度	Pa・s
$\nu$ :	動粘度	m <sup>2</sup> /s
$Q$ :	体積流量	L/min
$g$ :	気相	
$l$ :	液相	

### 1. 序論

近年、航空宇宙分野では液体水素や液体酸素などの極低温流体が燃料として用いられている。新型基幹ロケットであるH3ロケットエンジン<sup>1)</sup>や、極超音速機<sup>2)</sup>、再使用ロケット<sup>3)</sup>などがその代表例である。ところで、極低温流体を燃料として使用するには様々な問題があり、中でも大きなものとして燃料流量の制御が困難であるという問題がある。これは、極低温流体が容易に気化し、制御困難な気液二相流状態になることに起因する。それゆえ、エンジンの高精度制御を実現するために、気液二相流の流動状態を正確に把握する技術が求められている。気液二相流の流動状態を表すパラメータとしては、クオリティ $\chi$ やボイド率 $\alpha$ 、流動様式などが代表的なものであるが、本研究では特に流動様式に注目した。流動様式

は、気液二相流内の気液分布を表し、クオリティやボイド率の値にも大きく影響を及ぼす重要なパラメータである。これまで流動様式は、人間が実際に流れを観察することによって分類されてきたが、異なる流動様式間の区分けが明確ではなく、また観察する人によって判断が異なる場合も多いといった問題があった。そこで本研究では、流動様式の自動判別を最終目標とし、前段階として気液二相流の流動画像から気液流量条件の自動判別を試みた。判別手法としては、近年画像判別分野で大きな成果を挙げているディープラーニング(深層学習)を活用した。具体的には、第1図に示すように、流動画像を深層学習モデルに入力すると、その流動画像がどのような気液流量条件での流動のものであるかが出力される、といったモデルの構築を行った。



第1図 深層学習による流動画像の判別

平成30年1月18日、平成29年度宇宙輸送シンポジウムにて発表

<sup>\*1</sup> 早稲田大学

<sup>\*2</sup> 早稲田大学大学院

<sup>\*3</sup> 宇宙航空研究開発機構

深層学習の利用には大量の画像が必要であるため、まずは気液二相流の流動実験を行って流動画像を取得し、その後、取得画像を用いて深層学習モデルの学習を行った。最後に、学習に用いていない未知データの判別を行うことで、モデルの判別精度評価を行った。

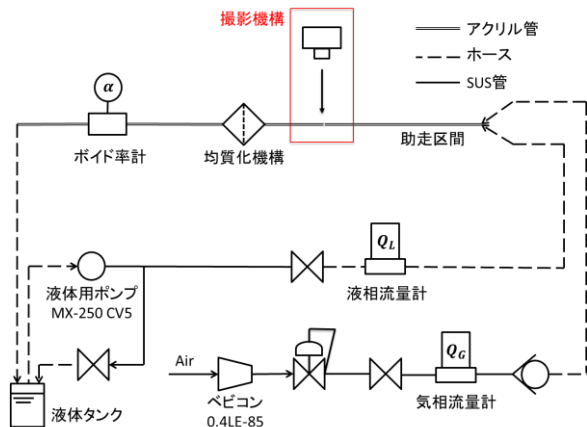
## 2. 研究手法

**2.1 流動画像取得実験** 本節では、流動画像取得実験の概要を述べる。実験目的は、各気液流量条件での気液二相流動画像を撮影することとする。作動流体としては、気相に空気（常温）、液相にシリコンオイル（常温）を用いた。作動流体の 25°C における物性を以下の第 1 表に示す。

第 1 表 作動流体物性<sup>4)</sup>

	空気	シリコンオイル KF-96L-5cs
$\rho$ [kg/m <sup>3</sup> ]	1.205	915
$\mu$ [Pa·s]	$1.85 \times 10^{-5}$	$4.58 \times 10^{-3}$
$\nu$ [mm <sup>2</sup> /s]	1.56	5.0
比誘電率	1	2.60

また、実験装置系統図を第 2 図に示す。



第 2 図 実験装置系統図

本実験では、空気とシリコンオイルはそれぞれベビコンとポンプを用いて独立に供給され、合流して気液二相流状態を作る。その後助走区間を経て流れが安定した段階で流動画像の撮影を行った。撮影においては、CASIO 社の EX-FH20 High Speed カメラを使用し、420fps、224×168px の撮影条件で一つの気液流量条件につき約 25 秒間撮影を行った。つまり、各流量条件につきおよそ 10000 枚の画像を撮影したということである。このようにして、本実験では水平流で 10 条件、上昇流で 8 条件、下降流で 8 条件について撮影を行った。詳細な条件については、以下の第 2 表、第 3 表に示す。以降、この時得られたデータを、データ A とする。ところで、詳しくは後述するが、本研究ではこのデータ A をあらかじめ分割して学習と判別精度評価を行う。そのため、学習時に用いられる画像データと判別精度評価の時に用いられる画像データは別物であるが、あくまで元

は同じデータ A であるため、判別精度が真の精度よりも高くなる可能性がある。本研究で求めたい深層学習モデルは、実験時期が異なっても、同じ条件下の実験で取得した流動画像であれば正しく判別が行えるような汎用性の高いモデルであるため、その評価をする必要がある。そこで、汎用性評価用の流動画像を取得するため、水平流については異なる日に同条件の実験・撮影を追加で行った。この時得られたデータを、データ B とする。データ B については、各流量条件につきおよそ 2000 枚の画像を撮影した。なお、以降簡単のため、撮影画像について、例えば液相流量 8 L/min、気相流量 20 L/min の気液流量条件時の流動画像は「L8G20」といったように表記する。

第 2 表 気液流量条件（水平流）

液相流量 $Q_l$ L/min	気相流量 $Q_g$ L/min			
1.5	5.0	10.0	20.0	40.0
4.0	-	-	20.0	-
8.0	-	-	20.0	-
12.5	5.0	10.0	20.0	40.0

第 3 表 気液流量条件（上昇流，下降流）

液相流量 $Q_l$ L/min	気相流量 $Q_g$ L/min			
1.5	1.0	10.0	30.0	50.0
8.0	1.0	10.0	30.0	50.0

**2.2 ニューラルネットワークの学習** 前節のようにして撮影した大量の流動画像を用いて、深層学習を行う。深層学習とは、機械学習の一分野であるニューラルネットワークの発展形である。ニューラルネットワークは、生物の神経回路網を模倣した人工的なモデルのことであり、神経細胞を模したユニットであるニューロンが層状に多数結合した構造を持つ。この層の数が多くなり、深い層構造を持ったニューラルネットワークが深層ニューラルネットワークと呼ばれるものであり、深層学習の代表的な例である。深層ニューラルネットワークは、深い層構造を持つことで、従来のより浅いニューラルネットワークよりも複雑な表現ができるようになっている。深層ニューラルネットワークにもいくつか種類があり、代表的な例の一つが畳み込みニューラルネットワークという画像認識に高い性能を示すモデルである。このモデルの原型は、1998 年に Lecun<sup>5)</sup>らにより提案された LeNet である。本研究では、この畳み込みニューラルネットワークをベースに、Szegedy<sup>6)</sup>らによって開発された GoogLeNet を用いた。

ニューラルネットワークの学習では、まず、用意したデータを訓練データ、検証データ、テストデータの三つに分割する。このうち、訓練データによってニューラルネットワークのパラメータ最適化、すなわち学習を行い、その後テストデータを用いて最終的な性能を評価する。検証データは、学習がうまく進んでいるかどうかの確認や、学習では最適化されず、人間側であらかじめ設定しなくてはならないハイパーパラメータの調整に用いる。今回は、データ A を 80:15:5 の比率で三つに分割し、訓練データ A、検証データ A、テストデー

タ A を作成した。データ B については、モデルの汎用性の検証用であるため、すべてをテストデータ B とした。なお、ハイパーパラメータのほかにも、ネットワーク内パラメータの最適化手法などは人間側で設定する必要がある。今回は、以下の第 4 表に示す条件での学習を行った。

第 4 表 学習条件

エポック数	30
最適化手法	Adam <sup>7)</sup>
学習係数	0.001
データセット比率	80:15:5


エポック数は、学習における単位のこと、1 エポックは全ての訓練データを一回ずつ学習した状態を指す。今回の場合、訓練データの比率は 80% なので、例えば水平流であれば、各気液流量条件での流動画像 10000 枚のうち 8000 枚が訓練データとなり、それが全部で 10 条件分あるので、合計およそ 80000 枚の訓練データがある。そして、この訓練データ全てについて一回ずつパラメータ最適化を行うことが 1 エポックに相当する。つまり、30 エポックの学習では 80000 枚の画像それぞれにつき 30 回ずつパラメータ最適化が行われるということである。また、ニューラルネットワーク内のパラメータ最適化は、主に勾配降下法を改良した手法によって行われ、今回用いた Adam はそういった手法の中でも非常に多くの場合に用いられている手法である。学習係数は、パラメータの更新量にかかる係数のことであり、したがってこの値が大きいかほど一回のパラメータ更新量が大きくなる。学習係数が大きいと、学習が早く進む反面、学習が不安定になってしまうため、適切な値を選ぶ必要がある。なお、第 4 表に示した以外にもハイパーパラメータは存在するが、今回は GoogLeNet のデフォルト値に設定した。

### 3. 流動画像判別結果

本章では、流動画像の判別結果として、流動画像の判別精度を示す。なお、ここでいう判別精度とは、学習済のニューラルネットワークを用いてテストデータの判別を行い、その内正しく流れを判別できた割合のことを指す。また、学習は訓練データ A を用いて行った。


**3.1 同日実験で得た流動画像の判別** 本節では、訓練データ A と同一の撮影において得られたテストデータ（テストデータ A）を用いた場合の流動画像の判別精度を示す。流動方向別の精度は第 3 図のようになった。

ここで示した精度は、全条件それぞれの精度の平均値となっている。例えば水平流では、第 2 表に示す 10 条件それぞれについての判別精度の平均値が 99.6% であった。本結果から、気液二相流の流動画像を深層学習によって判別することが可能であるということが示された。




第 3 図 流動方向別のテストデータ A 判別結果

**3.2 別日実験で得た流動画像の判別** 本節では、訓練データ A とは異なる日の撮影で得られたテストデータ（テストデータ B）を用いた場合の流動画像の判別精度を示す。前述のように、モデルの汎用性の検証用としては水平流のみ撮影を行っていたので、結果についても水平流のみを示す。第 4 図に前節の結果を気液流量条件ごとにより詳細に示し、第 5 図にテストデータ B の判別結果を同様に示す。



第 4 図 流量条件別のテストデータ判別結果 (テストデータ A: 同日実験で得た流動画像)



第 5 図 流量条件別のテストデータ判別結果 (テストデータ B: 別日実験で得た流動画像)


上図より、平均の判別精度は99.6%から12.3%まで低下し、本深層学習モデルの汎用性が著しく低いことが確認できる。

#### 4. モデルの汎用性の検証と向上

前章から、深層学習モデルの汎用性が著しく低いことが分かった。本章では、その原因を考察し、それに基づいて汎用性向上の工夫を行った結果を示す。

汎用性が低くなった原因として、モデルが今回用意した訓練データにのみ過剰に適合（過学習）してしまったことが考えられる。過学習は、エポック数が大きすぎることや、訓練データの少なさ、偏りによって生じることが多い。そこで、各要因について汎用性向上のための工夫を行った。以下4.1節と4.2節ではこれらの工夫について詳細を述べ、4.3節においてその結果を示す。


**4.1 エポック数の調整** 学習時のエポック数が必要以上に大きいと、モデルが過学習を起こしやすくなる。これに対し、学習中に過学習が始まった段階（検証データの精度が下がり始めた段階）で学習を打ち切る早期終了（early stopping）という手法を用いて過学習を防ぐことが多い。今回は、一般的な早期終了とは少し異なるが、各エポック終了時のモデルに対し、テストデータ B の判別を行い、精度が最も高くなるエポック数を調査した。エポック数は1から20の範囲で調査を行い、第6図に3.2節のモデルでの結果を一例として示す。これより、本モデルの場合ではエポック数が9の時に精度が20%となり、最も高くなることが分かる。また、精度の推移については、エポック数が大きくなるにつれ変動幅が小さくなっていることが確認できる。この傾向は、後述する別の訓練データを用いたモデルについても同様であった。



第6図 エポック数と精度の関係

**4.2 訓練データの量・質の向上** 深層学習においては、訓練データの量と質が学習の成否に大きく影響し、訓練データの拡充を行うことで結果が急激に良好になる場合が多い。訓練データの拡充手法としては、単に全く新しいデータを取得するというのが最良ではあるが、それが難しい場合は、データの変換等によって疑似的に新たなデータを用意すること

もできる。本研究のようにデータが画像である場合には、画像の加工やノイズ処理によって新たな画像データを作成することができる。今回は、第7図に示すように、上下左右の反転、グレースケール化、あるいはそれらの組み合わせによる訓練データ A の画像加工を行い、新たな訓練データを作成した。新たな訓練データについて、その名称と内容を第5表に示す。




第7図 テストデータ画像の加工

第5表 新しい訓練データの詳細

データ名	内容	1条件の枚数
訓練データ A	カラー	10000
訓練データ C	カラー+グレー	20000
訓練データ D	カラー+グレー+左右反転	30000
訓練データ E	カラー+グレー+上下反転	30000
訓練データ F	カラー+グレー+上下反転+左右反転	40000
訓練データ G	カラー+グレー+上下反転+上下反転 (グレー)	40000

**4.3 モデルの汎用性向上の結果** 第5表に挙げた各訓練データを用いて改めてニューラルネットワークの学習をし、その後テストデータ B の判別を行った。さらに各モデルについて、エポック数1から20の間で最も精度が高くなるエポック数の調査を行い、その結果を第8図に示す。なお、データ名の横に記した数値はエポック数を表す。



第8図 訓練データによる判別精度の変化

この結果から、テストデータ B の判別精度が、12.3%から 49.0%まで増加したことが確認できる。また、全体として訓練データの枚数が多くなるにつれ、判別精度が向上する傾向が見られた。一方で、訓練データ C, D, E, F を比較すると、枚数が増えても、それが左右反転の画像による増加であるとむしろ精度が下がっていることが確認できる。また逆に、上下反転の画像による増加であると、精度が大きく向上していることも見て取れる。このことから、画像加工の手法によって、精度の変化の仕方が大きく影響を受けることが分かる。

## 5. 結論

本研究では、流動様式の自動判別を最終目標とし、その前段階として気液二相流の流動画像から流動条件の自動判別を試みた。具体的には、深層学習を利用して気液流量条件ごとの流動画像の判別を行った。結果としては、流動方向別でのテストデータの高精度な判別に成功し、気液二相流の流動画像分類に対する深層学習の有用性が示された。一方で、別日に同条件で行った実験で得られた流動画像の判別精度は低く、得られた深層学習モデルの汎用性の低さが示された。これに対し、エポック数の調整と訓練データの加工による拡充を行い、判別精度は 12.3%から 49.0%まで増加した。

今後の展望としては、まずは汎用性の更なる向上を目指す。深層学習はあくまでデータ駆動の手法であるため、この課題に対する有効なアプローチとしては更なるデータ拡充が第一に挙げられる。本稿では、画像加工のみによる拡充を行ったが、今後何回かに分けて同条件での実験を行い、追加の流動画像を取得することで、汎用性が大きく向上するのではないかと期待している。また、もう一つの課題として、本研究の深層学習モデルでは流動の時間変動が考慮されていないということがある。気液二相流現象においては、流動パターンの時間遷移が重要な意味を持つと考えられるので、今後は

時系列を考慮した深層学習モデルの利用も検討したい。

## 謝 辞

本研究は JSPS 科研費 17H03479 の助成を受けたものです。

## 参 考 文 献

- 1) 堀秀輔, 黒須明英, 青木賢司. :H3 ロケット第 1 段エンジンの開発計画, 宇宙科学技術連合講演会講演集, Vol. 59, 2015.
- 2) Tetsuya Sato, Hideyuki Taguchi, Hiroaki Kobayashi, Takayuki Kojima, Katsuyoshi Fukiba, Keiichi Okai Daisaku Masaki, Kazuhisa Fujita, Motoyuki Hongo, and Shujiro Sawai.: Development study of a precooled turbojet engine., Acta Astronautica, Vol. 66, 2010.
- 3) 稲谷芳文. 再使用ロケットの研究開発. 日本機械学会誌, Vol. 108, 2005.
- 4) KF-96L性能試験結果, 信越シリコン, 2014
- 5) Y.Lecun, L.Bottu, Y.Bengio, and P.Hffiner: Gradient-based learning applied to document recognition. Proceedings of the IEEE 86, 11 (November 1998), 2278-2324. DOI: (<http://dx.doi.org/10.1109/5.726791>), 1998.
- 6) Christian Szegedy et al. Going Deeper With Convolutions. IEEE Congerence on Computer Vision and Pattern Recognition (CVPR), 2014.
- 7) Diederik Kingma and Jimmy Ba. Adam: A Method for Stochastic Optimization. arXiv:1412.6980 [cs], 2014.