

# 深層学習を用いた極低温二相流における計測技術の高度化に向けた実験研究

## Experimental Study on Advancement of Measurement Technology in Cryogenic Two-Phase Flow Using Deep Learning

中尾 圭吾\*1・阿久津 元秀\*2・生沼 瑞基\*1・宮瀬 拓海\*1・坂本 勇樹\*3・佐藤 哲也\*2

**Key Words:** Multiphase Flows, Two-Phase Flow, Deep Learning, Bidirectional LSTM, Flow Meter

**Abstract:** 様々な航空宇宙輸送機では、燃料として液体水素(LH2)などの極低温流体が用いられているが、容易に気化しやすく、気液二相流を形成する。しかし、流量は気体と液体の分布パターンを表す流れの状態に変化するため、その制御は困難である。そこで著者らは、極低温二相流における計測技術の高度化を目指し、ボイド率計の計測値を入力とし、気液の流量条件を出力として、深層学習法の一つである双方向 LSTM ネットワークを用いた分類器を開発した。気相流量条件を各液相流量につき 7 条件から 11 条件へと変化させた結果、誤判別の傾向として、異なる液相流量の条件への判別が抑制された。また、分類器が気相流量を判別する根拠について次元圧縮を用いて調査した結果、各データ波形の平均値との関係が示唆された。

### 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

液体水素や液体酸素などの極低温流体は、航空宇宙分野では推進剤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>などがその代表例である。ところで、極低温流体を推進剤として使用するには様々な問題があり、その中でも流動制御が困難であることが運用上の課題となっている。これは、極低温流体が容易に気化し、気体と液体が混在した気液二相流を形成することに起因する。気液二相流は、気液分布の外見パターンである流動様式に応じて特性が時間的・空間的に大きく変化し、流れが不安定になる。そのため、この性質が原因で、特に航空宇宙分野ではエンジンが着火しない、ロケット燃料を余分に消費してしまうなどの重大な問題が発生している。

前提として、高精度な流動制御手法を確立するには、気液二相流の特性把握が肝要である。流動特性を支配する特徴量としては、流動様式やクオリティ $\chi$ など様々あるが、本研究室では気液比を表すボイド率 $\alpha$ に注目してきた。そし

て、これまでに極低温二相流用の静電容量型ボイド率計の研究を進め、気泡流、スラグ流など様々な流動様式に対応する高精度で小型軽量な計測器を開発した。

そこで、具体的な流動制御手法の確立に向け、著者らは「流動様式や流量」を「ボイド率計計測値」から判別する「深層学習モデル」の構築を行うことを目標としている(第1図)。深層学習手法を用いることで、複雑な流れである気液二相流に対して適切な特徴抽出が可能になる。本研究に先立ち、著者らは CNN (Convolutional Neural Network)<sup>3,4)</sup>を用いた分類器を構築し、高速度カメラで撮影した流動画像から 10 種類の気液条件を約 50%の精度で分類した<sup>5)</sup>。その後、深層学習モデルへの入力をボイド率計で取得した数値データに変更し、14 種類の気液条件(液相 2 条件、気相 7 条件)を判別する多クラス分類器を開発した。深層学習手法もそれに応じて、長時間の時系列情報を考慮する長短期記憶ネットワーク(LSTM)<sup>6,7)</sup>を採用した。その結果、80%以上の精度で分類することに成功した。本技術を適用して気液両相の流量の連続値を推定するには、その前段階として、より間隔の狭い条件への分類を行うことが求められる。そこで本研究では、気相流量の間隔を狭め、条件数を増やして取得したデータについて学習及び検証を行い、その結果から気相流量の特徴量について考察を行った。



第1図 深層学習による流量条件の判別

令和4年1月14日、令和3年度宇宙輸送シンポジウムにて発表

\*1 早稲田大学大学院

\*2 早稲田大学

\*3 宇宙航空研究開発機構

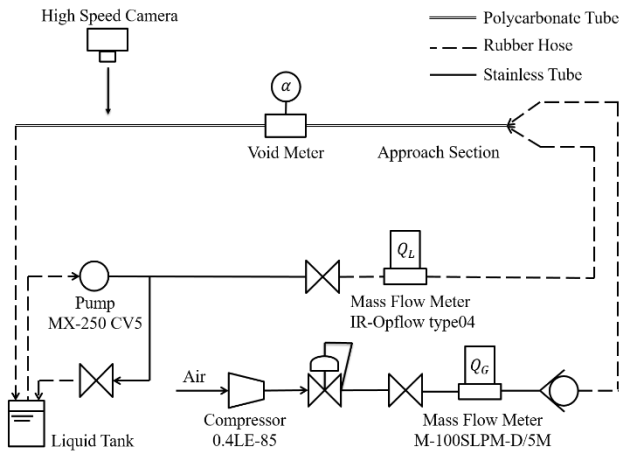
## 2. 研究手法

**2.1 データセット取得実験** 本節では、データセット取得実験の概要を述べる。深層学習を行うには、大量の入力と出力のペアセットを用意する必要がある。そこで、様々な気液流量条件下で気液二相流状態を作り、その時のボイド率計測定値を取得した。作動流体として用いた空気(常温)とシリコンオイル(常温)について、その 25 °C における物性を第 1 表に示す。

第 1 表 作動流体物性<sup>8)</sup>

	空気	シリコンオイル KF-96L-0.65cs
$\rho$ kg/m <sup>3</sup>	1.205	760
$\mu$ Pa·s	$1.85 \times 10^{-5}$	$4.94 \times 10^{-4}$
$v$ mm <sup>2</sup> /s	1.56	0.65
比誘電率	1.00	2.17

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をそれぞれベビコン、液体用ポンプを用いて独立に供給し、その後合流させることで気液二相流を作った。ここで、シリコンオイルを用いたのは、静電容量型ボイド率計の性能を左右する比誘電率が液体水素に近く、安定した電気特性を示すため、安全・簡便に水素流と条件の近い実験が可能となるからだ。合流後は、十分な助走区間(内径 15 mm, 長さ約 67 cm)を経て流れが安定した地点でボイド率計による測定と、記録用の流動状態の撮影を行った。ボイド率計は、中島ら<sup>9)</sup>の研究を基に開発した静電容量型ボイド率計で、測定は各条件につき 50 Hz で約 60 秒間行った。実験は水平流条件で行い、気液条件は液相流量( $Q_l$ )2 条件と気相流量( $Q_g$ )11 条件を組み合わせ、計 22 条件を設定した。気相流量間隔は、低流量を除き従来の半分とした。具体的な気液流量条件及び観察された流動様式については、第 2 表を参照されたい。第 2 表において、太字で示した条件が本研究で新たに設定した条件である。なお、以降簡単のため、例えば液相流量 3 L/min, 気相流量 5 L/min の流動条件は「L3G5」といったように表記することとする。また、本研究では上記の実験を日を改めて計 4 回行った。本稿では便宜上、最初の実験日に取得したデータセットから順に A, B, C, D とする。

第 2 表 設定した気液条件と観察された流動様式

気相流量 $Q_g$ L/min	流動様式	
	液相流量 $Q_l$ L/min	
	3	6
1	プラグ流	プラグ流/スラグ流
5	スラグ流	プラグ流/スラグ流
10	スラグ流	チャーン流
<b>15</b>	<b>スラグ流</b>	<b>スラグ流/チャーン流</b>
20	スラグ流/チャーン流	スラグ流/チャーン流
<b>25</b>	<b>スラグ流/チャーン流</b>	<b>チャーン流</b>
30	チャーン流	チャーン流/環状流
<b>35</b>	<b>チャーン流/環状流</b>	<b>環状流</b>
40	チャーン流/環状流	環状流
<b>45</b>	<b>環状流</b>	<b>環状流</b>
50	環状流	環状流

## 2.2 BLSTM ネットワークの学習

本節では、双方向性 LSTM ネットワーク (bidirectional LSTM networks, BLSTM)<sup>10)</sup>を用いた分類器の学習について述べる。深層学習の手法としては現在様々なものが提案されている。本研究では、ボイド率計測定値という数値データを用いるため、長期的な時系列情報を含んだデータの学習に優れる LSTM を採用した。また、気液二相流特有の流動の周期性を捉えることを目的として、LSTM の中でも BLSTM ネットワークを採用した。次に具体的なネットワークの内部構造について述べる。本研究では、隠れユニット数 320 個の BLSTM 層を 2 層持つ 22 クラス判別モデルを構築した。入力データは平均 0, 分散 1 に標準化したボイド率計測定値(静電容量値)であり、1 つにつき 300 点(6 秒分)の測定値を含んでいる。続いて、本研究で任意に設定したハイパーパラメータの値を第 3 表にまとめて示す。最適化手法 Adam に関するハイパーパラメータは文献<sup>11)</sup>を参照している。第 3 表以外の学習条件については、全て MATLAB の Deep Learning Toolbox の既定値を用いた。

第 3 表 設定したハイパーパラメータ

	$\alpha$	0.001
最適化手法	Adam <sup>11)</sup>	
	$\beta_1$	0.9
	$\beta_2$	0.999
隠れユニット数		320
BLSTM 層の層数		2
Sequence 長		300
全結合層のユニット数		100

## 3. 分類結果と考察

### 3.1 気相流量の間隔を細かく刻んだ場合の応答

本節では、本研究で構築した分類器の判別精度を示す。なお、ここで判別精度とは、学習済みネットワークを用いてテストデータセットを判別した際の正答率のことを指す。本研究では、A から D のデータセットのうち 3 種類を訓練データセットに、残りのデータセットをテストデータセットと


した計4通りの組み合わせを作成し、学習とテストを行った。

第4表に、各データセットの組み合わせによる判別精度をまとめて示す。図中の括弧内の数値は、分類する気液条件を従来の14種類とした場合の判別精度を示している。この結果から、総合的に見た各データセットの判別精度は条件数を増やす前と比較して、減少したことが確認された。


第4表 判別精度の比較

訓練データ セット	判別精度			
	テストデータセット			
	A	B	C	D
B+C+D	57.40 (85.30)	-	-	-
A+C+D	-	59.42 (87.66)	-	-
A+B+D	-	-	62.94 (83.29)	-
A+B+C	-	-	-	41.40 (58.97)

次に、気液条件数の違いによるデータの分類の挙動を考察するため、データセットAをテストデータセットとした場合における判別結果の例を第3図及び第4図にそれぞれ示す。第4図は比較を行いやすくするため、22条件の判別結果から、従来の14条件における判別精度のみを抽出したものである。従来の研究から、誤判別される条件の特徴



第3図 判別結果 (14種類)



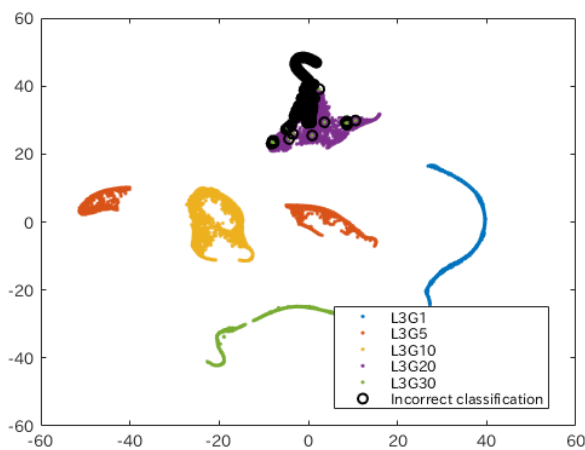
第4図 判別結果 (22種類)

として「液相流量は同じで、気相流量が近接する条件」と「液相流量は異なり、平均ボイド率が近い条件」の2種類が存在することが確認されていた。これらの図を比較すると、第3図で気相流量が近接する条件への誤判別が生じていた条件(L3G30やL6G40など)を中心に誤判別の割合が増加していること、液相流量の異なる条件への判別は抑制されていることが確認された。具体的には、液相流量の異なる条件へ判別されたデータの全体に占める割合が約4.35%から0.85%へと約80%減少した。この傾向は、どのデータセットをテストデータセットに使用した場合でも同様であった。気液二相流は間欠的な流れであり、流動様式も時々刻々と変化することから、ボイド率計測部では流量が変化している可能性がある。そのため、気相流量の判別条件を増やしたことで、実際の流れの様子を顕著に示すようになったと考えられる。これは、より流量を様々に変化させた過渡的な流れにおいても、本分類器がその変化に追従できる可能性を示唆するものである。

### 3.2 次元圧縮による気相流量特徴量の検討

本節では、更なる分類器の汎用性の向上を目指し、気相流量を分類する根拠となる特徴量について、次元圧縮を用いた調査を行った。次元圧縮とは、高次元で表された情報をその意味を保ちつつ、それより少ない次元の情報に落とし込むことである。この手法を用いて、ネットワークの出力を可視化し、誤判別されたデータの特徴を分析した。次元圧縮手法はこれまでに数多く提案されているが、「高次元上の非線形データを扱える」、「局所的・大局的双方の構造を捉えられる」といった観点から、t-SNE<sup>12)</sup>を採用した。

ネットワークの出力層であるソフトマックス層の出力を可視化したのが第5図である。計算に当たり、液相流量を1種類(L3)に固定し、気相流量を低流量側の5条件のみ抽出して解析を実行した。また、縦軸と横軸はt-SNEによる2次元への次元圧縮が行われた後の潜在変数の値を表しており、色はそれぞれの流量条件を示している。それぞれの点の集合体をクラスターと呼び、形に関係なくクラスターが形成されているものは、ネットワーク自身が共通する特徴を学習できていることを示している。そして、黒丸は




第5図 t-SNEによるソフトマックス層の可視化

誤判別されたデータの値を表したものである。この結果から、他のクラスターに重なってしまっているデータが誤判別されていることが確認できる。

続いて、このデータの判別の性能を定量的に評価するため「Ambiguity」という指標を導入する。Ambiguityはソフトマックス層の出力の中で、最も高い値と二番目の値の比をとったもので、1に近づく程そのデータの判別根拠が十分でないことを表す指標である。今回の条件の中で最も多くの誤判別のあった条件(L3G30)における Ambiguity の値を青線で、分類器の入力に用いた300点分のボイド率の平均値を赤線で時系列にプロットしたものが第6図である。ここで、横軸は時間を表しており、第5図と同様に誤判別された際の値を黒丸で表している。第2軸として平均値を示したのは、各波形の大きさや傾向を表現する適切な指標だと考えたからである。

第6図から、Ambiguityがスパイク上に高い値となる部分で誤判別が生じていることが分かる。また、平均値との関係に注目すると、平均値が高い部分（特に急激な上昇が見られる部分）で Ambiguity の値が増加し、誤判別されることが確認された。そして、その後データが安定すると、Ambiguity は小さくなるが、誤判別は継続することも確認された。これは、BLSTM ネットワークが順方向だけでなく、逆方向の時系列情報も考慮することのできる性質があるからだと考えられる。以上の結果から、平均値やその時間的な変動が気相流量の判別に大きな影響を与えており、特徴量の一つであることが確認された。



第6図 誤判別の合った条件における Ambiguity と平均値の関係(L3G30)

#### 4. 結論

本研究では、静電容量型ボイド率計を用いた高精度な流動制御手法を確立するため、計測したボイド率の数値波形を入力、気液流量を出力とする分類器を構築した。深層学習手法としてはBLSTM ネットワークを用いた。また、気相流量の間隔を狭め、条件数を増やして取得したデータについて学習及び検証を行った。その結果、以下の知見を得た。

1. 気相流量条件を増やした分類器を構築すると、異なる

液相流量に判別されるデータの割合が約80%減少した。

2. 気相流量の特徴量の一つは各データ波形の平均値であり、同条件内で高い値となっている箇所や変動が大きい箇所では Ambiguity の値が増加し、判別根拠が不十分となる。

今後は流量分類の特徴量として考えられ得る他のパラメータと Ambiguity の関係についての考察や、前処理手法の変更により更なる高精度化を図る。また、実用化に向けて、液相流量の条件数を増やした場合や気液二相流の全体的な流量への判別に適用した場合の効果の検証を進めていく予定である。

#### 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) Lecun, Y., Bottou, L., Bengio, Y. and Hffiner, P.: Gradient-based learning applied to document recognition, Proceedings of the IEEE, 86(1998), No. 11, pp. 2278-2324.
- 4) Krizhevsky, A., Sutskever, I. and Hinton, G. E.: ImageNet Classification with Deep Convolutional Neural Networks, Advances in Neural Information Processing Systems, 25(2012).
- 5) 樺山昂生, 箕手一真, 吉田光希, 坂本勇樹, 多根翔平, 中島曜, 小林弘明, 佐藤哲也: 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, 平成29年度宇宙輸送シンポジウム講演集録, STCP-2017-029(2018).
- 6) Hochreiter, S. and Schmidhuber, J.: Long Short-Term Memory, Neural Computation, 9(1997), No. 8, pp. 1735-1780.
- 7) Gers, F. A., Schmidhuber, J. and Cummins, F.: Learning to forget: Continual prediction with LSTM, Neural Computation, 12(2000), No. 10, pp. 2451-2471.
- 8) KF-96L性能試験結果, 信越シリコーン, 2014
- 9) Nakajima, Y., Sakamoto, Y., Tane, S., Minote, K., Furuichi, A., Kabayama, K., Tsujimura, H., Yoshida, K., Kobayashi, H. and Sato, T.: Optimization Design of the Capacitance Void Fraction Sensor adopting Multi Asymmetric Electrodes for Two Phase Flow, Proceedings of Asian Joint Conference on Propulsion and Power, 2018.
- 10) Graves, A. and Schmidhuber, J.: Framewise phoneme classification with bidirectional LSTM networks, Proceedings of the International Joint Conference on Neural Networks, 4(2005), pp.2047-2052.
- 11) Kingma, D. and Ba, J.: Adam: A Method for Stochastic Optimization, arXiv:1412.6980 [cs], 2014.
- 12) Hinton, G. and Maaten, L.: Visualizing Data using t-SNE, Journal of Machine Learning Research, 9(2008), pp.2579-2605.