

## プルーム画像を用いたニューラルネットワークによるホールスラスタの放電電流予測

河津, 誠人  
九州大学大学院総合理工学府先端エネルギー理工学専攻

淵上, 大貴  
九州大学大学院総合理工学府先端エネルギー理工学専攻

Yamamoto, Naoji  
Department of Advanced Energy Engineering Science, Faculty of Engineering Science, Kyushu University

民田, 太一郎  
三菱電機株式会社先端技術総合研究所駆動制御システム技術部放電システムグループ

<https://hdl.handle.net/2324/4377921>

---

出版情報 : AEROSPACE TECHNOLOGY JAPAN, THE JAPAN SOCIETY FOR AERONAUTICAL AND SPACE SCIENCES.  
20, pp.47-51, 2021-03-23. 日本航空宇宙学会  
バージョン :  
権利関係 :



# プルーム画像を用いたニューラルネットワークによる ホールスラスタの放電電流予測

## Neural Network Prediction of Discharge Current using Plume shape and Operational Parameters in Hall Thrusters

河 津 誠 人<sup>\*1</sup>・淵 上 大 貴<sup>\*1</sup>・山 本 直 嗣<sup>\*2</sup>・民 田 太 一 郎<sup>\*3</sup>  
Masato KAWAZU, Naoji YAMAMOTO and Hirotaka FUCHIGAMI, Taichiro TAMIDA

**Key Words:** Propulsion, Hall Thruster, Neural Network, Auto Controlling

**Abstract:** A neural network for prediction of discharge current, which shows nonlinearity and hysteresis dependent on coil current, has been developed to build auto control system of Hall thrusters. The prediction accuracy dependence on training data sets composed of operational parameters (previous work), 250 images of plume shape and both, operational parameters and images, are investigated. The network using only plume images can describe the non-linear mode hop jump and hysteresis that the network using only operational parameters cannot describe. The predicted discharge current, however, is fluctuated up and down, while that observed in experiment shows smooth curve. The prediction using both operating parameters and plume images as the training data, can describe mode hop jump and hysteresis with 0.8 % difference between prediction current and that observed in experiment.

### 記 号 の 説 明

$I_d$ : 放電電圧  
 $I_{in}$ : 内側コイル電流  
 $I_{out}$ : 外側コイル電流  
 $\dot{m}$ : 推進剤流量  
 $t$ : 作動時間  
 $V_d$ : 放電電圧

### 1. 研究背景

近年、宇宙産業の発展に伴い SpaceX 社や Oneweb 社、アクセルスペース社や QPS 研究所などの民間企業が数多くの人工衛星の打ち上げを予定している。<sup>1-4)</sup> これらの衛星には、主推進、軌道維持、軌道変更のために電気推進機が搭載されており、その中でもホールスラスタは高推力電力比と高比推力を実現できることから今後の人工衛星の主推進機として期待されている。<sup>5)</sup> しかし、ホールスラスタはプラズマの非線形特性や推進性能の時間的変化が原因で自動制御することが難しいという問題点を抱えている。今後の宇宙産業において人工衛星の数は増加していくことが見込まれており、それらの衛星を全て手動で制御することはヒューマンコストが膨大にかかるため、ホールスラスタの自動制御システムの構築は重要な課題である。

一般的に自動制御システムを構築する際には PID 制御によるフィードバック制御を行うが、ホールスラスタではプ

ラズマが非線形特性を持つことに加えて、ホールスラスタの出口付近のチャンネルがイオンの衝突によりスパッタリングを起こし、推力や電力のような推進性能が時間的に変化していく<sup>6)</sup>ので作動条件から推進性能を正確に求める式を構築するのが困難で PID 制御によるフィードバック制御を行うことができていない。

そこで本研究ではホールスラスタの非線形性や時間依存性を示す推進性能を、過去のデータから性能を見積もることが出来るニューラルネットワークを用いてフィードバック制御の機構を構築することを目的としている。

先行研究では、データを学習させることで様々な環境に対応ができるニューラルネットワークが、時々刻々と変化していく推進性能を追従し、自動制御をおこなうのに有効であると考え、ニューラルネットワークによるホールスラスタの推進性能の時間変化予測を行っている。<sup>7,8)</sup> 先行研究では、コイル電流を変化させることで加速チャンネルに印加する磁場の強さを周期的に変化させ、スラスタの温度が時間とともに上昇する状況下でのコイル電流の変化による放電電流の値を予測した。その際に、コイル電流を増加させるときと減少させるときでのヒステリシスが大きく、実験での測定値との誤差が大きくなったため、コイル電流を増加させるときと減少させるときでデータを分けて個別に学習させ、それぞれの範囲において予測することで相対平均誤差 1.3%という結果が出ている。しかし、コイル電流を増加させるときと減少させるときでのデータをそれぞれ個別に学習させる手法では、学習を行う前にデータを仕分けする手間がかかるという問題がある。そのため、本論文では放電電流を予測する際に、ホールスラスタ作動時のプルー

<sup>\*1</sup>九州大学大学院総合理工学府先端エネルギー理工学専攻

<sup>\*2</sup>九州大学大学院総合理工学府先端エネルギー科学部門

<sup>\*3</sup>三菱電機株式会社・先端技術総合研究所駆動制御システム技術部・放電システムグループ

ム画像を用いることで、場合分け学習なしで予測することを目的とした。予測精度目標は放電電流の計測精度である1%とした。現時点では自動制御システムの検討を行っていないため計測精度で目標を設定したが、必要精度が相対平均誤差1%よりも大きくても問題ない場合には、必要精度に達した時点で学習を早めに打ち切り、逆により小さな誤差が求められる場合には、より計測誤差の小さな機器によって計測を行い、学習回数を増やすなどして予測精度を向上させる。プルーム画像の取り込みやオンボード上ニューラルネットワーク処理の実現性に関しては、画像処理 IC チップやニューラルネットワーク用の IC チップの低消費電力化および高性能化が進んでおり、これらを利用することで実現できると考えられる。本論文で行った放電電流の予測では、まず始めにプルーム画像のみでの予測を行い、その後、プルーム画像と作動条件を組み合わせることで予測を行ってプルーム画像のみでの予測と比較した。

## 2. ニューラルネットワーク

**2.1 ネットワーク構造** ニューラルネットワークとは生物の脳の神経回路網を模したモデル<sup>9)</sup>のことであり、画像認識<sup>10)</sup>や天気予報<sup>11)</sup>など様々な分野で応用されている。図1,2に今回用いたニューラルネットワークの概略図を示す。図1にはプルーム画像のみで予測した際に用いたネットワークを示し、図2にはプルーム画像と作動条件を用いて予測したネットワークを示している。今回の予測では、図1では畳み込みニューラルネットワーク(CNN)<sup>12)</sup>、図2では単純なフィードバックニューラルネットワーク(FNN)と CNN の2つのネットワークモデルが組み合わされて構成されている。図2のネットワークでは、CNN において画像の特徴量をフィルタおよび活性化関数によって抽出して信号を変換し、FNNでは変換された信号および作動条件から重みと活性化関数によって信号が変換されていく。重みやフィルタは、次の層に受け渡す信号の強度を調整するものであり、重みやフィルタが大きいくほど受け渡される信号は大きくなる。また、活性化関数は重みやフィルタを通して変換された信号が次の層へと受け渡される前に信号を非線形変換する役割を持っており、活性化関数を用いることで非線形問題に対しても有効な解を見つけることが出来る。ニューラルネットワークでは、重みとフィルタを調整することでネットワークモデルの学習が進み、学習を繰り返すことで出力値が目標値、今回であれば放電電流値に近づいていく。

本研究で用いた CNN では、作動時のプルームの RGB カラー画像が、フィルタを通して画像サイズがだんだんと小さくなっていく。図1のネットワークではそのまま放電電流が出力されるように学習され、図2のネットワークでは CNN からの出力が作動条件と同じ層のユニットに入力され、FNN によって作動条件とともに信号が変換されていき放電電流が出力されるように学習される。今回 CNN で用いたフィルタは畳み込み層で  $5 \times 5$  のサイズでストライドを1にしたものを用い、その後のプーリング層では  $2 \times 2$  のサイズでストライドを2にしたものを使った。また、作動条件より後

の中間層は、層数が5でニューロンの数が各層12個としており、入力した作動条件は推進剤流量、作動時間、放電電圧、内側コイル電流、外側コイル電流である。

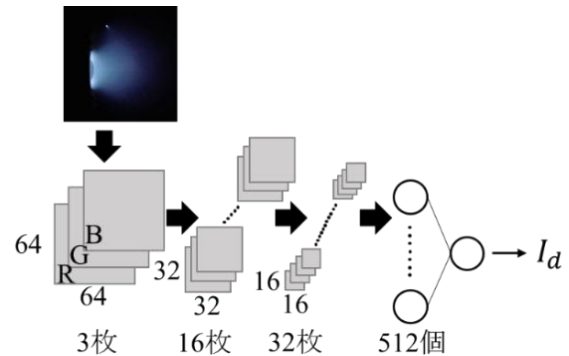


図1 CNNの概略図<sup>12)</sup>

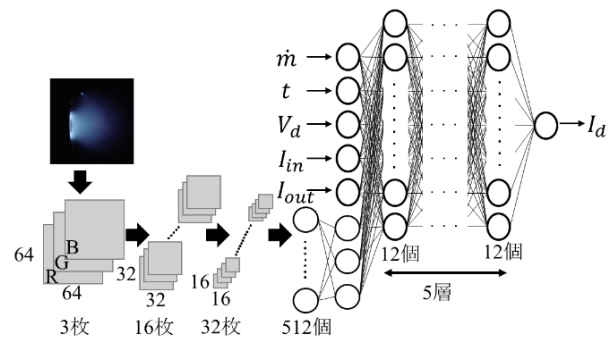


図2 CNN+FNNの概略図<sup>12)</sup>

**2.2 学習手法** 今回用いた学習手法としては目標値と出力値の誤差関数として二乗誤差を用い、重みおよびフィルタの更新手法として確率的勾配降下法の応用である AdaGrad<sup>13)</sup>を用いた。活性化関数に関しては、CNN, FNN ともに傾き 0.01 の Leaky ReLU<sup>14)</sup>を用い、重みの初期値は CNN では平均0、標準偏差0.1の正規分布を、FNN では He の初期値<sup>15)</sup>を用いた。

## 3. 実験条件

今回の学習・検証で用いた実験データは、九州大学所有の 200W ホールスラストおよび真空試験装置( $\phi 1.0$  m, 長さ 1.2 m)を用い、電子源としてはホローカソード (Veeco, HC252)を用いて取得した。詳細は参考文献 16)に譲る。作動条件としては、作動時間が 0~180 s、推進剤であるキセノンの流量を 0.68 mg/s、電場の制御を行っている放電電圧を 150 V、磁場の制御を行っている内側コイル電流と外側コイル電流の比を 1:2 で固定しており、コイル電流の変化に対する放電電流の変化を測定している。図2にコイル電流の変化に対する放電電流の変化を示す。図2の放電電流値の変化を見ると、コイル電流が線形的にしか変化していないにもかかわらず、放電電流の値は急下降したり、急上昇したりするなどの変化が見られる。この変化は、プルームの形状や発光強度が変化した時に現れた。図3にプルーム画像の例を示す。図2中の(a), (b), (c)の各点は、プルーム画像(a), (b), (c)の作動点

にそれぞれ対応している。図3のブルーム画像を見ると、(b)のブルームの発散角が(a)および(c)のブルームと比べて小さくなっていることや(c)のブルームの発光強度が(a)および(b)に比べて大きいことが分かる。今回の検証ではまず、このブルームの違いから、放電電流の急激な変化をニューラルネットワークによって予測することが出来るかどうかを確かめた。その後、作動条件とブルーム画像による予測を行い、ブルーム画像のみの予測と比較した。また、今回の予測では用意したデータのうち、0~150 s を学習のために用い、150~180 s を検証のために用いた。画像は 0.6 秒おきに撮像しているため、学習は250枚の画像で行っている。カメラは、Logicool HD PRO WEBCAM C920 を用いた。

開発環境としては、HP EliteDesk 800 Desktop (Processor: Intel® Core™ i5-4590 CPU @ 3.30GHz, RAM: 4.00GHz, OS: Windows 10) を使用し、計算には Python 3.7.3 および Tensorflow 1.15.0 を用いた。

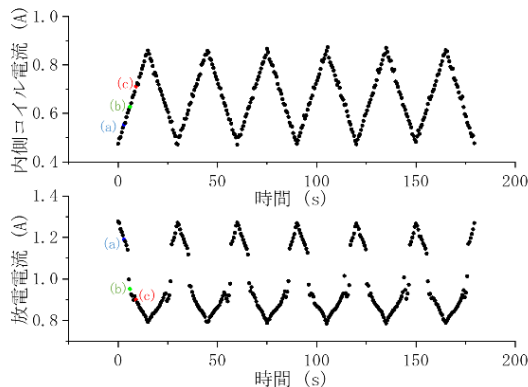
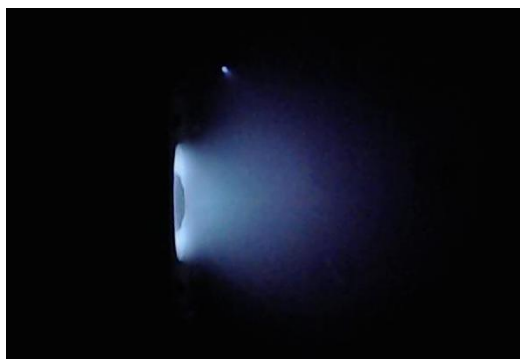
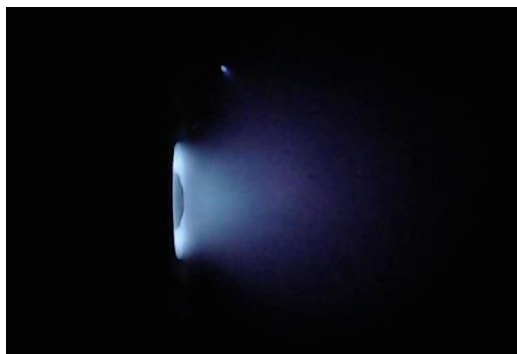


図2 内側コイル電流と放電電流の時間変化



(a) 3.0 s



(b) 6.0 s

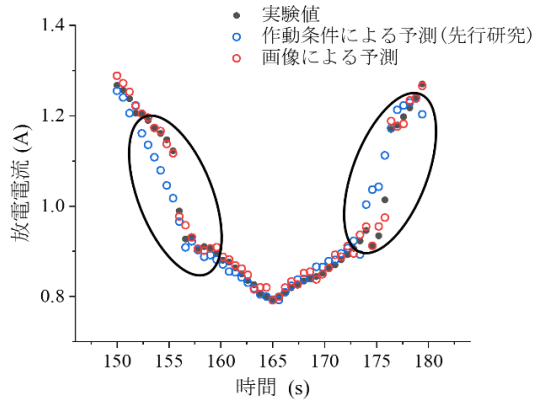


(c) 9.0 s

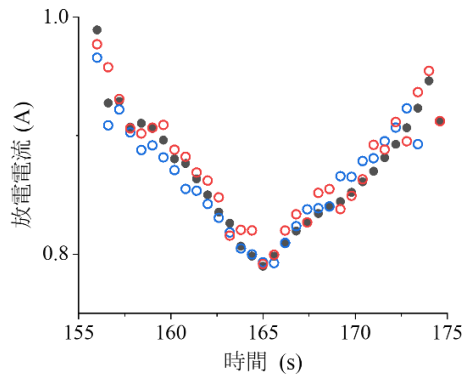
図3 各作動時間におけるブルーム画像

#### 4. 予測結果および考察

**4.1 ブルーム画像による予測** 図4にブルーム画像を用いた場合の予測結果を示す。図4では、放電電流の実験値の検証データとともに、作動条件のみを入力して予測した結果と、推進機のブルーム画像を入力して予測した結果を載せている。図4(a)の黒い楕円で囲った場所に注目すると、作動条件による予測では、磁場の変化に応じて個別に学習させる手法を用いていないため放電電流の急激な変化を捉えることが出来ず、急変化している場所での予測精度が大幅に落ちていることが分かる。一方で、画像による予測では、磁場の変化に応じて個別に学習させなくても放電電流を上手く予測しており、急変化する領域においても予測精度をほとんど落とすことなく予測することが出来ている。この理由としては以下の理由が考えられる。放電電流の急激な変化に伴い、ブルームの形状や発光強度が変化する。この変化を捉えることができるブルーム画像を用いることで、作動条件だけでは捉えることができなかった放電電流の非線形性を捉えることが出来るようになったため、予測精度が向上した。また、検証データにおける相対平均誤差においては、作動条件による予測では2.8%だったのに対し、画像による予測では1.1%という結果になった。このことから、推進性能の予測には作動時の推進機のブルーム画像を入力することが有効な手段であることが分かる。しかし、図4(b)に示している155~175sの各線をつないだ画像による予測結果の拡大図を見てみると、概形は捉えているものの、実験値に対して放電電流の値が上下に揺れていることが分かる。この原因としては、放電電流振動によってブルーム発光に揺らぎが生じていることが考えられる。



(a) 150~180 s の予測結果

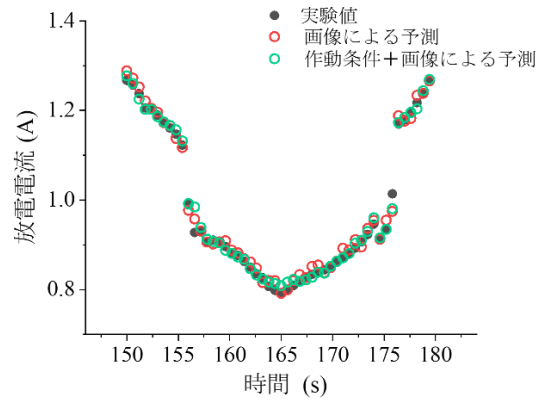


(b) 155~175 s の拡大図

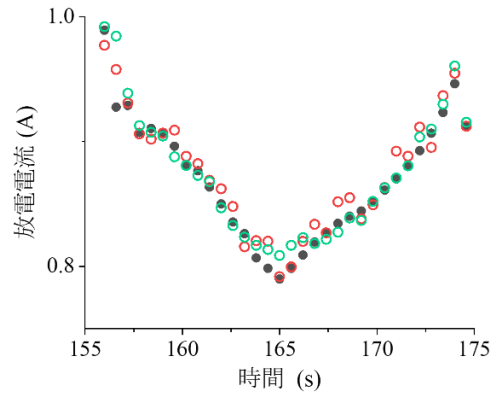
図4 画像入力による予測結果の比較

**4.2 作動条件とブルーム画像による予測** 次に、作動条件とブルーム画像による予測を行い、ブルーム画像による予測と比較した。図 5(a)にその結果を示している。図 5(a)を見てみると、作動条件を加えたことによって全体的に予測精度が上がっており、作動条件と画像による予測の相対平均誤差は0.8%という結果になった。また、図 5(b)に示している 155~175s の各線をつないだ画像による予測と作動条件およびブルーム画像による予測の拡大図を見てみると、作動条件およびブルーム画像による予測では、放電電流の下限値の予測精度がブルーム画像による予測と比べて多少落ちているものの、ブルーム画像による予測の時に見られた予測値の揺らぎがなくなっていることが分かる。これは入力情報としてブルーム画像以外に作動条件も用いることで、ブルームの発光量の揺らぎが与える予測結果への影響が小さくなったからだと考えられる。しかし図 5(b)の左から2番目のそれぞれの値に注目すると、画像だけを用いた場合も画像と作動条件を用いた場合も予測精度が他の予測点に比べて悪いことが分かる。この原因としては、この点は丁度ブルームの形状や発光強度が遷移している途中であるが、ブルームの画像と放電電流の値の計測タイミングがわずかにずれており、このずれが遷移途中の放電電流予測に影響を与えたと考えられる。計測タイミングがわずかにずれた理由は、今回の計測はLabViewによって0.6秒おきに画像の撮影および作動条件、放電電流の計測が行われるように制御していたが、今回の制御では作動条件、放電電流の計測が行

われると同時に撮影の指令が流れるようになっており、実際に撮影されるまでに時間差が生じたからである。



(a) 150~180 s の予測結果



(b) 155~175 s の拡大図

図5 画像による予測と作動条件および画像による予測

## 5. 結論

本論文では、ホールスラストのフィードバック制御システムを構築するために、ホールスラストのブルーム画像を用いて、放電電流の時間変化を予測した。得られた結果は以下のとおりである。

- (1) 放電電流の予測に作動時のブルーム画像を用いることで、データを仕分けしなくても、相対平均誤差 1.1%で予測することが出来た。しかしながら、放電電流の予測にブルーム画像だけを用いた場合では、放電電流の予測値は実験値と比べると磁場の変化に対して揺らいでいる値になった。
- (2) 画像と作動条件を用いた場合には、放電電流の予測値の揺れも無くなった。結果として、相対平均誤差が 0.8%まで小さくなった。

本論文では、非線形性を示したり、時間変化したりするために、PID 制御が難しく自動制御にいたっていない放電電流を、非線形性を含めて誤差 1%以内で予測できることを示した。今後の予定として推力予測やフィードバック制御の機構を検討し、自動制御の実現を目指していく。

## 参 考 文 献

- 1) Space News, <https://spacenews.com/first-six-oneweb-satellites-launch-on-soyuz-rocket/> (accessed March 12, 2020).
- 2) Space News, <https://spacenews.com/former-spacex-starlink-exec-joins-german-lasercomm-startup/> (accessed March 12, 2020).
- 3) AXELSPACE, [https://www.axelspace.com/info/news/20181227/press\\_20181227/](https://www.axelspace.com/info/news/20181227/press_20181227/) (accessed March 12, 2020)
- 4) QPS 研究所, <https://i-qps.net/news/169> (accessed March 12, 2020)
- 5) Hamada, Y., Bak, J., Kawashima, R., Koizumi, H., Komurasaki, K., Yamamoto, N., et al.: Hall Thruster Development for Japanese Space Propulsion Programs, *Trans JSASS*, **60** (2017), pp. 320–326.
- 6) D. Valentian and N. Maslennikov: THE PPS 1350 PROGRAM, In *Proc. 25th IEPC*, October 1997, 134, pp. 855-861
- 7) Fuchigami, H., Chono, M. and Yamamoto, N.: Prediction of Discharge Current using Neural Network in Hall Thruster, *Trans JSASS*, **66** (2018), pp. 143-145.
- 8) Kawazu, M., Yamamoto, N., Fuchigami, H. and Morita, T.: Prediction of Thruster Performance in Hall Thruster Using Neural Network with Auto Encoder, *ISTS Proceedings*, 2019-b-014, 32<sup>nd</sup> ISTS and 9<sup>th</sup> NSAT, Fukui, Japan, June, 2019.
- 9) 岡谷貴之: 深層学習, 講談社, 東京, 2015
- 10) Okatani, T.: Deep Learning for Image Recognition, *J. Jpn. Soc. Artificial Intelligence*, **28**, 6 (2013), pp. 962-974
- 11) Berrocal, V. J., Raftery, A. E., Gneiting, T. and Steed, R. C.: Probabilistic Weather Forecasting for Winter Road Maintenance, *Am. Stat. Assoc.*, **105**, 490 (2010), pp. 522-537
- 12) LeCun, Y., Boser, B., Denker, S. J., Henderson, D., Howard, E. R., Hubbard, W. and Jackel, L. D.: Backpropagation applied to handwritten zip code recognition, *Neural Computation*, **1**, 4(1989), pp. 541-551
- 13) Dauchi, J., Hazan, E. and Singer, Y.: Adaptive Subgradient Methods for Online Learning and Stochastic Optimization, *J. Machine Learning Research*, **12** (2011), pp. 2121-2159.
- 14) Mass, A. L., Hannun, A. Y. and Ng, A. Y.: Rectifier Nonlinearities Improve Neural Network Acoustic Models, *International Conference on Machine Learning*, 2013.
- 15) He, K., Zhang, X., Ren, Shaoqing. and Sun, J.: Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification, *Proceedings of IEEE International Conference on Computer Vision*, Santiago, Chile, 2015, pp. 1026-1034.
- 16) Kawazu, M., Yamamoto, N., Chono, M., Fuchigami, H., Morita, T.: Prediction of Thruster Performance in Hall Thrusters Using Neural Network with Auto Encoder, *Trans. JSASS Aerospace Tech. Japan*, accrpted