

[共同研究成果]

Deep Q-Network と LES を用いた DBD プラズマアクチュエータの 翼周り流れの剥離制御

Tan Kevin : 東京理科大学工学部情報工学科
 浅田 健吾 : 東京理科大学工学部情報工学科
 藤井 孝藏 : 東京理科大学工学部情報工学科
 立川 智章 : 東京理科大学工学部情報工学科

1. はじめに

航空機や風車などの空力機器において、翼面上の流れの剥離は揚力低下や抗力増大を引き起こし、空力性能を大きく低下させる要因となる。そのため、翼周りの流れを制御し剥離を抑制する流体制御技術は重要な研究分野として広く研究が行われている。近年、能動的に翼周り流れの剥離を抑制する手法として、誘電バリア放電 (Dielectric Barrier Discharge, DBD) を利用した DBD プラズマアクチュエータ (以下 PA) [1-3] と呼ばれるマイクロ流体制御デバイスが注目されている。PA は、図 1 に示すように 2 枚の電極とそれに挟まれた誘電体からなる単純かつ軽量の構造であり、放電により生成されるプラズマを利用した空気の流れを制御する空力デバイスである。高い応答性を持つため、Vortex Generator や定常ジェットといった従来デバイスに比べて柔軟な運用が可能なものとして期待されている。




図 1: DBD プラズマアクチュエータの模式図と翼への設置例

先行研究[4-8]より、乱流遷移が生じるレイノルズ数 ($Re \cong 10^4 \sim 10^5$) の条件において、ON と OFF を間欠的に切り替えるバースト波を用いた PA のバースト駆動制御が剥離の抑制に効果的であるということが明らかになっている。図 2 はバースト駆動で用いられる一般的な入力波形であり、バースト時間 T_{on} 、バースト周期 T^+ 、ベース周波数 f_{base} によって表される。さらに、翼周りの剥離制御においては、主流速度 U_∞ と翼コード長 c で無次元化された無次元バースト周波数 $F^+ (= f^+ c / U_\infty)$ とバースト比 (Burst Ratio) $BR = T_{on} / T^+$ が用いられることが多い。特定条件における適切な F^+ に関する理解はこれまでの研究で深まりつつあるが、翼型や流れ条件が変化した場合にも常に有効であるとは限らない。そのため、各条件において適切な F^+ を設定する必要がある。実際には、時々刻々と変化する流れ場において適切な値を決定することが求められる。

流れの状況に応じて適切な駆動パラメータを決定する研究として、小川ら[9]は翼面圧力係数の分散値と閾値に基づく簡易なフィードバック剥離制御アルゴリズムを提案し、流体シミュレーションを用いてその有効性を検証している。近年は特に機械学習を用いた流体制御が大きな注目を浴びている[10]。オープンループ制御では遺伝的アルゴリズムや (Genetic Algorithm, GA) [11] やアントコロニーアルゴリズム (Ant Colony Algorithm, ACA) [12]を用いた最適な制御パラメー




図2 バースト波形




図3 NACA0015 翼周り流れ場

タの組み合わせ探索，クローズドループ制御では，遺伝的プログラミング（Genetic Programming, GP）[13]や深層強化学習（Deep Reinforcement Learning, DRL）[14]などのモデルフリーな機械学習手法の研究が盛んである．下村ら[15]はPAとDeep Q-Network（DQN）を用いた翼周り流れの剥離制御を提案し，風洞実験において固定 F^+ よりも高い制御効果が得られることを示している．数値シミュレーションを用いた研究として，高田ら[16]はRANSとDQNを用いたPAのフィードバック剥離制御手法の提案を行っている．また，小泉ら[17]やRabaultら[18]は，2次元円柱流れにおいて，深層強化学習によるカルマン渦の抑制を行っている．これらの研究は深層強化学習を用いた流れ制御の有効性を示してはいるが，2次元かつ比較的低レイノルズ数条件（ $Re \cong 10^2$ 程度）における Reynolds-Averaged Navier-Stokes（RANS）ベースの数値シミュレーションであり，流れ場の忠実度には限界がある．数値シミュレーションと深層強化学習を組み合わせた研究は，計算コストの制約から2次元計算や低レイノルズ数に留まる場合が多く，乱流遷移を伴うレイノルズ数領域における複雑な流体现象を議論する場合は，Large-Eddy Simulation（LES）のような高忠実なシミュレーションの実施が必要である．しかしながら，翼周りの剥離制御を対象として，深層強化学習と高忠実度数値解析を組み合わせた研究例は限られているのが現状である．

以上の背景から，本研究では翼周り流れを対象に，LESによる高忠実シミュレーションと深層強化学習を組み合わせたPAのフィードバック剥離制御手法を構築し，流れ場に応じたPAの駆動方法を探索するとともに得られた流れ場からその制御メカニズムについて議論することを目的とする．

2. 流れ場の設定と計算手法

2.1 流れ場の設定

本研究では先行研究[8]と同様に， $Re = 63,000$ のNACA0015翼周り流れを対象とする．このレイノルズ数は，UAVやMAVといった小型無人航空機などのスケールに相当する．翼はスパン方向に一様な形状を有する3次元形状である．流れ条件はマッハ数 $M_\infty = 0.2$ ，比熱比 $\gamma = 1.4$ ，プラントル数 $Pr = 0.72$ とする．図3に本条件の非制御時における数値シミュレーション結果を示す．図は，主流方向速度で色付けされた速度勾配テンソルの第二不変量の等値面であり，翼周り流れが前縁から剥離している状態を示している．PAは翼前縁5%の位置に設置する．迎角は失速角直後の12度と15度とする．

2.2 プラズマアクチュエータのモデル化

PA の流体計算への導入は支配方程式に PA を模擬した体積力項を導入することで行う． PA の体積力モデルはいくつか提案されているが[19, 20]，ここでは Suzen と Huang ら[21]の定常体積モデル（以下 Suzen モデル）を非定常に拡張した体積モデルを用いる． 図 4 に Suzen モデルの概形を示す． モデルの数値計算への導入方法の詳細，その信頼性，および数値計算の妥当性については既出論文を参照されたい[22, 23]． PA のパラメータは，先行研究[8,15]にあわせて無次元ベース周波数は $f_{base}U_\infty/c = 60$ ，バースト比 $BR = 0.1$ ，体積力項の大きさを決める運動量係数 D_C は 0.04 とした． ベース周波数は，実験における 6[kHz]に相当し，最大誘起速度は 3[m/s]で電圧は 6[kV_{pp}]，消費電力は 100[W/m]となる．




図 4 Suzen モデル

2.3 計算手法

3次元圧縮性 Navier-Stokes 方程式を支配方程式とし，空間の離散化には 6次精度コンパクト差分法[24]を用いた．フィルタリングには 10次精度陰的フィルタを適用し，フィルター係数は $\alpha_f = 0.45$ とした．時間積分には内部反復を 5 回行う ADI-SGS 陰解法[25]を用いた．また，本研究では陽的なサブグリッドスケール (SGS) モデルを用いない Implicit LES を採用した．時間刻み幅は $dt = 2.0 \times 10^{-4}$ とした．

2.4 計算格子

図 5 に本研究で用いる計算格子を示す．翼周り流れを解く Zone1 および Zone2 と，アクチュエータ近傍の擾乱を解像する高解像度格子 Zone3 から構成される重合格子法を用いる．Zone1 には C 型格子を採用し，外部境界は翼弦長の 25 倍とする．Zone2 は翼後方の下流領域を対象とし，同様に外部境界は 25c とする．スパン方向長さは 0.2c とする．Zone3 には翼弦長 5%位置に設置したアクチュエータの体積力分布を内挿する．格子点数は，Zone1 が約 1.7×10^7 ，Zone2 が約 3.4×10^6 ，Zone3 が約 2.2×10^6 で総格子点数は約 2200 万点である．翼面直交方向の最小格子幅は約 0.00012c とし，翼面には固体壁条件，スパン方向には周期境界条件を適用する．




図 5 計算格子

2.5 計算機に関して

計算機として東北大学サイバーサイエンスセンターのスーパーコンピュータ AOBA のサブシステム AOBA-S を利用した。AOBA-S の 1 ノードは 1 ベクトルホスト(VH)と 8 ベクトルエンジン(VE)で構成されており、本計算では格子を 8 分割して 8VE を用いた。具体的には Zone1 を 5 分割, Zone2 を 2 分割した。VE 内はスレッド並列 (自動並列) とし, 各 VE 間は MPI 通信を行うハイブリッド並列を用いた。後述する深層強化学習は VH 側で行う。

3. 深層強化学習フレームワーク

一般的な強化学習は Q テーブルが用いられるが, 本研究では Q テーブルの代わりにニューラルネットワークを用いる DQN を採用する。DQN は行動価値関数をニューラルネットワークで近似し, 状態に対する最適な行動を選択する手法である。DQN アルゴリズムの詳細は[14]などを参照されたい。本研究では, 翼面上の圧力センサから得られる情報を状態として入力し, PA の駆動パラメータ (無次元バースト周波数 F^+) の選択を行動とした。構築した深層強化学習フレームワークを図 6 に示す。

まず, 機械学習を実行する Python プログラム (Agent) と数値シミュレーションを行う Fortran プログラム (Solver) を分離し, 両者が双方向通信を行う構成となっている。Solver は一定周期で環境状態を Agent に送信し, Agent は受信した環境に応じて行動を決定する。各プログラムの通信方式としてはファイルや標準入出力が利用できるようになっている。さらに, 図に示すように処理は大きく制御フェーズと学習フェーズの 2 つに分けられる。制御フェーズでは, Agent が Solver から環境状態を取得し行動選択を一定間隔で繰り返す。その際, DQN アルゴリズムのミニバッチ学習を行うために状態と行動, 行動の結果として得られる状態変化をバッファに蓄積していく。学習フェーズでは, 蓄積されたバッファからミニバッチを生成し, Agent のネットワークパラメータを更新する。制御フェーズと学習フェーズを 1 エピソードとし, 両フェーズを交互に繰り返す。制御フェーズと学習フェーズが終わったら (1 エピソードが終わったら), 環境をリセットする。具体的には初期の剥離状態の流れ場に戻す。Agent はエピソードを重ねていく中で試行錯誤を通じて最適な制御方策を獲得していくことが期待される。

図 6 の Sensor-A, B, C は疑似的な圧力センサであり, それぞれ翼面のスパン方向中央断面におけるコード長 0%, 40%, 100%位置に設置されている。Sensor-A, B の圧力係数を環境状態と

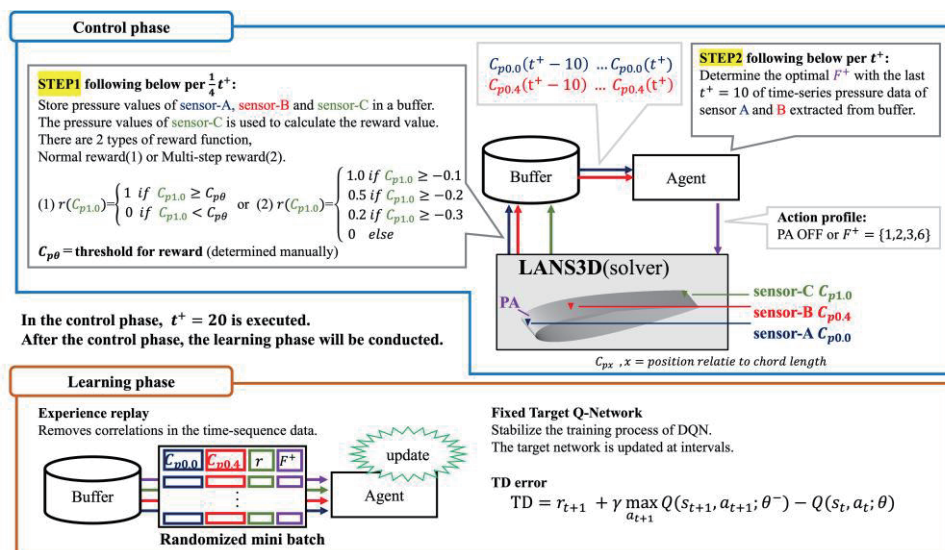


図 6 深層強化学習フレームワーク

して用い、後縁位置の Sensor-C は報酬として活用する。報酬はあらかじめ設定した閾値を越えたかどうかの 2 値で即時報酬を決定することとする。報酬として後縁の圧力係数を用いる理由は、流れの付着状況と後縁圧力には正の相関があるためである。流れが翼に沿って流れる（付着している）とき、翼の後縁に十分な運動量が供給され、翼後縁の圧力係数が上昇することから Sensor-C の圧力係数が閾値を越えた場合は「付着」、下回ったときは「剥離」しているとみなす。

図 7 に Agent のネットワーク構成を示す。ネットワークは 1 次元畳み込み層、バッチ正規化層、最大プーリング層、全結合層からなる。ネットワークへの入力（環境状態）は、Sensor-A, B の直近の 10 無次元時間の圧力履歴からそれぞれ 40 点サンプリングしたベクトル（80 次元）とする。ネットワークの出力（行動）は、 $F^+ = 1, 2, 3, 6$, PA-OFF の 5 種類であり、出力ベクトルは各行動の Q 値となっている。最も Q 値が高い行動（＝報酬期待値が高い行動）が選択され、ソルバに送信される。行動選択後、一定時間は選択された行動が継続される。

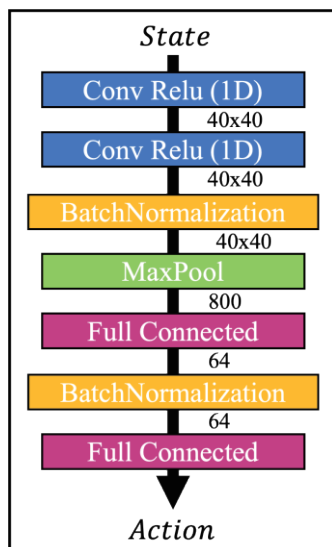


図 7 ネットワーク構成

表 1 DQN の学習パラメータ (Model-A)

Episode number	11
Action number per episode	20
Max memory size	240
Mini-batch size	20
Discount rate	0.99
Optimizer	Adam Optimizer
Target network update interval	3
Epsilon	0.9 to 0.1
Minimum of Epsilon	0.1
Learning rate	0.01
Reward	$C_{p\theta} = -0.09$
$C_{p\theta}$: threshold for reward	$r = \begin{cases} 1 & \text{if } C_{p1.0} \geq C_{p\theta} \\ 0 & \text{if } C_{p1.0} < C_{p\theta} \end{cases}$
$C_{p1.0}$: Pressure of sensor-C	

4. 迎角 12 度環境下でのフィードバック剥離制御

4.1 計算条件

迎角 12 度における DQN の学習パラメータを表 1 に示す。この設定のモデルをここでは Model-A と呼ぶ。1 エピソードあたりの行動変調回数は 20 回とし、各エピソードで一定時間ごとに行動を更新する。1 エピソードあたりの計算時間は AOBA-S で約 32 時間である。経験再生 (Experience Replay) のためのメモリサイズを 240、ミニバッチサイズは 20 とし、学習の安定化のために導入されるターゲットネットワークの更新間隔は 3 とした。割引率は 0.99 とし、将来の報酬も考慮した学習を行う。

行動選択には ϵ -greedy 選択を用い、 ϵ は 0.9 から 0.1 まで線形に減少させることで学習初期は探索を重視し、学習が進むにつれて報酬期待値の高い行動を選択する設定とした。最適化手法には Adam を用いた。学習率は大きすぎると学習が不安定になり、小さすぎると収束までに時間を要する。本研究では 0.01 とした。

報酬設計については、剥離の抑制し翼面上の圧力回復を促す制御方策の獲得を目的として、

Sensor-C の圧力係数 $C_{p1.0}$ が閾値 $C_{p\theta}$ を越えたら報酬 1, 越えない場合は 0 を与えることとした。 $C_{p\theta}$ は予備実験に基づき-0.09 とした。

4.2 制御結果

図 8 に各エピソードにおける翼後縁圧力係数の推移を示す。縦軸は圧力係数(C_p)、横軸は無次元時間 (t^+) である。黒線は閾値であり、閾値を上回っているときは即時報酬が得られている。図より、エピソード初期は閾値を下回る時間が多くみられるが、エピソードが進むにつれて圧力係数が全体的に回復し、閾値を上回る時間が増加していることがわかる。また、 $t^+ = 12$ におけるエピソード 9 とエピソード 11 の瞬間場の図 9 を示す。等値面は速度勾配テンソルの第二不変量で、主流速度成分で色付けしている。図からエピソード 9 ではまだ剥離している流れが、エピソード 11 では大きく改善されていることがわかる。



図 8 翼後縁圧力係数の推移




図 9 瞬間場

さらに翼の空力性能を表す揚抗比に注目する。図 10 に代表的なエピソードにおける揚抗比の推移を、図 11 に対応する行動履歴を示す。横軸はいずれも無次元時間である。図より、揚抗比はバースト周波数の選択と強く対応して変化していることが確認できる。特に、 $F^+ = 6$ が選択された後に揚抗比が急激に上昇しており、その後も $F^+ = 6$ が維持されている間は高い揚抗比が持続していることが分かる。これは、適切なバースト駆動によって流れ場が改善され、空力性能が向上していることを示唆している。一方で、 $F^+ = 6$ の選択頻度が低いエピソードでは揚抗比の向上が限定的であり、高い値に到達しない傾向が見られる。このことから、本モデルは学習の進行に伴い、高い揚抗比をもたらすバースト周波数を選択する方策が獲得できていると考えられる。




図 10 揚抗比の推移




図 11 行動履歴

5. 迎角 15 度環境下でのフィードバック剥離制御

5.1 計算条件


大規模な剥離が生じ剥離の抑制が難しい迎角 15 度における DQN の学習パラメータを表 2 に示す. ここでは, Model-A の設定を基にしつつ, 一部変更を加えたモデル (Model-B と呼ぶ) を検討した. Model-B では, 1 エピソードあたりの行動変調回数は 30 回とし, エピソード数を 26 に増加させより多くの探索を行う. 経験再生のためのメモリサイズは Model-A よりも増加させ 320, ミニバッチサイズも 32 とした.

学習率は 0.01 とした. 報酬設計については, Model-A と同様に剥離の抑制し翼面上の圧力回復を促す制御方策の獲得を目的として, Sensor-C の圧力係数 $C_{p1.0}$ が閾値 $C_{p\theta}$ を越えたら報酬 1, 越えない場合は 0 を与えることとし, $C_{p\theta} = -0.25$ とした.


表 2 DQN の学習パラメータ (Model-B)

Episode number	26
Action number per episode	30
Max memory size	320
Mini-batch size	32
Discount rate	0.99
Optimizer	Adam Optimizer
Target network update interval	3
Epsilon	0.9 to 0.1
Minimum of Epsilon	0.1
Learning rate	0.01
Reward	$C_{p\theta} = -0.25$
$C_{p\theta}$: threshold for reward	$r = \begin{cases} 1 & \text{if } C_{p1.0} \geq C_{p\theta} \\ 0 & \text{if } C_{p1.0} < C_{p\theta} \end{cases}$
$C_{p1.0}$: Pressure of sensor-C	

5.2 制御結果



(a) 後縁圧力係数の推移



(b) 行動履歴

図 12 翼後縁圧力係数の推移と行動履歴 (Model-B)

図 12 に代表的なエピソードにおける翼後縁圧力係数の推移と行動履歴を示す. まず, 圧力係数が閾値を大きく下回る箇所が確認でき, このとき翼後縁において大きな剥離が生じていると考えられる. その後, PA が駆動することで圧力係数が一時的に回復し, 閾値付近まで戻る挙動が繰り返し確認できる. ここで注目すべき点として, 圧力係数が回復する前において一時的に PA を OFF にする挙動 (ここでは Nested Burst 駆動と呼ぶ) が複数のエピソードで確認できる. このことは, PA の連続的な駆動ではなく, 適度に間欠的な駆動を行うことで剥離抑制に有効な擾乱を与えている可能性を示唆している.

また, Model-B は 1 エピソード内の行動変調回数を増加させたことでより細かな駆動パラメータの変更が可能となり, 圧力係数が回復する機会が増加していると考えられる. しかし, 圧力係数の急激な低下を抑えることはできておらず, 大規模な剥離が生じる迎角 15 度環境下では継続的な剥離抑制には至っていない.

図 13 に揚抗比の推移を示す. 図より, $t^+ = 5 \sim 7$ にかけて揚抗比が大きく向上した後, 揚抗比が低下していき, その後再び回復に向かっていくことが確認できる. 揚抗比は時間的に大きく変動しており, 安定的に剥離を抑制した状態を維持できていないことがわかる. 図 14 に示す瞬間場に着目すると, 揚抗比が高い $t^+ = 6$ では翼面上において剥離が抑制された流れ場となっているの




図 13 揚抗比の推移




図 14 瞬間場 (episode20)

に対し、揚抗比が低下する $t^+ = 12$ では翼後縁に大規模な剥離構造が発達している状況が確認できる。一方、 $t^+ = 15$ では再び剥離領域が縮小傾向にあり、それに伴い揚抗比が再び増加していることがわかる。図 12 の行動履歴と対応づけると、Nested Burst 駆動により PA を一時的に OFF とすることで、翼面近傍に形成された剥離せん断層が一旦翼面から離脱し、再度 PA を ON とした際に大規模な巻き込み渦が生成されることで、流れ場に強い擾乱が付与されると考えられる。この擾乱が剥離流れの再構成を促進し、結果として揚抗比の回復につながっていると考えられる。

6. まとめ

本研究では、NACA0015 翼周り流れを対象に、LES による高忠実数値シミュレーションと深層強化学習 (DQN) を組み合わせた PA のフィードバック剥離制御フレームワークを構築した。本手法を迎角 12 度および迎角 15 度の条件に適用し、その有効性の検証を行った。

迎角 12 度においては、エピソードの進展に伴い、揚抗比を向上させる最適な無次元バースト周波数 ($F^+ = 6$) を選択する制御方策が獲得された。翼後縁圧力が回復し、揚抗比が継続的な向上が確認され、先行研究と概ね一致する結果となった。

一方、迎角 15 度は大規模な剥離が生じる流れ場であることから、揚抗比は一時的に向上するものの変動が大きく、高い揚抗比を安定的に維持するには至らなかった。流れ場の解析から、剥離の付着と再剥離を繰り返す挙動が確認されたものの、PA の駆動において、連続的なバースト駆動ではなく、バースト駆動の ON と OFF を切り替える間欠的な制御 (Nested Burst 駆動) が見られた。PA を一時的に OFF とすることで、剥離せん断層を翼面から離し、再起動時に大規模な渦構造を誘起することで揚抗比の回復につながっていると考えられる。このことは、単一の周波数制御に加えて ON と OFF を切り替える間欠的な制御戦略の重要性を示している。

しかしながら、現状の試行回数および学習設定では、このような制御を安定して維持する方策の獲得には至っておらず、安定的な剥離抑制の実現にはさらなる学習手法の改良が必要である。

7. 今後の研究計画

本研究では、失速直後の迎角 12 度においては本手法の有効性が確認できたが、大規模な剥離が生じる迎角 15 度ではその効果が限られている。DQN のような価値ベース手法では、状態に対して単一の行動が選択される枠組みのため、柔軟な制御方策を獲得することが難しく、十分な制御効果が得られない可能性がある。今後は、用いる環境情報や行動、学習方法などの改良を進めるとともに、学習コストの増加が伴うものの、価値関数と方策を同時に学習する Actor-Critic や過去の状態や行動履歴の時系列を扱える Transformer などのアーキテクチャを導入し、間欠的な ON/OFF 切り替えを含む制御戦略の性能向上を図る予定である。

謝辞

ここに記載させて頂いた成果は、東北大学サイバーサイエンスセンターのスーパーコンピュータを利用することで実現することができたものである。また、研究にあたっては同センター関係各位に有益なご指導とご協力を頂いた。センターの皆様はこの場を借りて謝意を示したい。

参考文献

- [1] J. R. Roth, D. M. Sherman, and S. P. Wilkinson, “Electrohydrodynamic Flow Control with a Glow-Discharge Surface Plasma,” *AIAA Journal*, Vol. 38, No. 7, pp. 1166–1172, 2000.
- [2] T. C. Corke, M. L. Post, and D. M. Orlov, “Single Dielectric Barrier Discharge Plasma Enhanced Aerodynamics: Physics, Modeling and Applications,” *Experiments in Fluids*, Vol. 46, No. 1, pp. 1–26, 2009.
- [3] T. C. Corke, C. L. Enloe, and S. P. Wilkinson, “Dielectric Barrier Discharge Plasma Actuators for Flow Control,” *Annual Review of Fluid Mechanics*, Vol. 42, pp. 505–529, 2010.
- [4] K. Asada, Y. Ninomiya, A. Oyama, and K. Fujii, “Airfoil Flow Experiment on the Duty Cycle of DBD Plasma Actuator,” *AIAA Aerospace Sciences Meeting*, 2009.
- [5] K. Fujii, “High-Performance Computing Based Exploration of Flow Control with Micro Devices,” *Philos Trans A Math Phys Eng Sci*, Vol. 372, No. 2022, p. 20130326, 2014.
- [6] M. Sato, H. Aono, A. Yakeno, T. Nonomura, K. Fujii, K. Okada, and K. Asada, “Multifactorial Effects of Operating Conditions of Dielectric-Barrier-Discharge Plasma Actuator on Laminar-Separated-Flow Control,” *AIAA Journal*, Vol. 53, No. 9, pp. 2544–2559, 2015.
- [7] H. Aono, S. Sekimoto, M. Sato, A. Yakeno, T. Nonomura, and K. Fujii, “Computational and Experimental Analysis of Flow Structures Induced by a Plasma Actuator with Burst Modulations in Quiescent Air,” *Mechanical Engineering Journal*, Vol. 2, Issue 4, p. 15-00233, 2015.
- [8] Makoto Sato, Koichi Okada, Kengo Asada, Hikaru Aono, Taku Nonomura, and Kozo Fujii. Unified Mechanisms for Separation Control Around Airfoil Using Plasma Actuator with Burst Actuation over Reynolds Number Range of 10^3 - 10^6 ,” *Physics of Fluids*, Vol. 32, No. 2, p. 025102, 2020.
- [9] T. Ogawa, K. Asada, S. Sekimoto, T. Tatsukawa, and K. Fujii, “Dynamic Burst Actuation to Enhance the Flow Control Authority of Plasma Actuators,” *Aerospace*, Vol. 8, No. 12, Dec. 2021.
- [10] S. L. Brunton, B. R. Noack, and P. Koumoutsakos, “Machine Learning for Fluid Mechanics,” *Annual Review of Fluid Mechanics*, Vol. 52, No. 1, pp. 477–508, 2020.
- [11] N. Benard, P. Sujar-Garrido, J.-P. Bonnet, and E. Moreau, “Control of the Coherent Structure Dynamics Downstream of a Backward Facing Step by DBD Plasma Actuator,” *International Journal of Heat and Fluid Flow*, Vol. 61, pp. 158–173, 2016.
- [12] B. F. Zhang, D. W. Fan, and Y. Zhou, “Artificial Intelligence Control of a Low-Drag Ahmed Body Using Distributed Jet Arrays,” *Journal of Fluid Mechanics*, Vol. 963, p. A3, 2023.
- [13] J. Chen, H. Zong, H. Song, Y. Wu, H. Liang, and Z. Su, “Closed-Loop Plasma Flow Control of a Turbulent Cylinder Wake Flow Using Machine Learning at Reynolds Number of 28000,” *Physics of Fluids*, Vol. 36, No. 1, 2024.
- [14] V. Mnih, K. Kavukcuoglu, D. Silver, A. A. Rusu, J. Veness, M. G. Bellemare, A. Graves, M. A. Riedmiller, A. K. Fidjeland, G. Ostrovski, S. Petersen, C. Beattie, A. Sadik, I. Antonoglou, H. King, D. Kumaran, D. Wierstra, S. Legg, and D. Hassabis, “Human-Level Control Through Deep Reinforcement Learning,” *Nature*, Vol. 518, pp. 529–533, 2015.
- [15] S. Shimomura, S. Sekimoto, A. Oyama, K. Fujii, and H. Nishida, “Closed-Loop Flow Separation Control Using the Deep Q Network over Airfoil,” *AIAA Journal*, Vol. 58, No. 10, pp. 4260–4270, 2020.
- [16] N. Takada, A. Watanabe, S. Shimomura, and H. Nishida, “Study on High-frequency Control aiming for Improving Deep Reinforcement Learning-based Flow Separation Control over an Airfoil,” *AIAA Aviation Forum*, 2023.

- [17] H. Koizumi, S. Tsutsumi, and E. Shima, "Feedback Control of Karman Vortex Shedding from a Cylinder using Deep Reinforcement Learning," AIAA Flow Control Conference, 2018.
- [18] J. Rabault, M. Kuchta, A. Jensen, U. Réglade, and N. Cerardi, "Artificial neural networks trained through deep reinforcement learning discover control strategies for active flow control," *Journal of Fluid Mechanics*, Vol. 865, pp. 281-302, 2019.
- [19] W. Shyy, B. Jayaraman, and A. Andersson, "Modeling of Glow Discharge-Induced Fluid Dynamics," *Journal of Applied Physics*, Vol. 92, No. 11, pp. 6434-6443, 2002.
- [20] C. L. Enloe, Thomas E. McLaughlin, Robert D. VanDyken, K. D. Kachner, Eric J. Jumper, and Thomas C. Corke, "Mechanisms and responses of a Single Dielectric Barrier Plasma Actuator: Geometric Effect," *AIAA Journal*, Vol. 42, No. 3, pp. 595-604, 2004.
- [21] Y. B. Suzen and P. G. Huang, "Simulations of Flow Separation Control using Plasma Actuators," 44th AIAA Aerospace Sciences Meeting and Exhibit, Aerospace Sciences Meetings, Reno, Nevada, January 2006.
- [22] K. Asada, T. Nonomura, H. Aono, M. Sato, K. Okada, and K. Fujii, "LES of Transient Flows Controlled by DBD Plasma Actuator over a Stalled Airfoil," *International Journal of Computational Fluid Dynamics*, Vol. 29, 2015.
- [23] H. Aono, S. Sekimoto, M. Sato, A. Yakeno, T. Nonomura, and K. Fujii, "Computational and Experimental Analysis of Flow Structures Induced by a Plasma Actuator with Burst Modulations in Quiescent Air," *Bulletin of the JSME Mechanical Engineering Journal* Vol. 2, No. 4, 2015.
- [24] Sanjiva K. Lele, "Compact Finite Difference Schemes with Spectral-like Resolution," *Journal of Computational Physics*, Vol. 103, No. 1, pp. 16-42, 1992.
- [25] K. Fujii, "Simple Ideas for the Accuracy and Efficiency Improvement of the Compressible Flow Simulation Methods," *International CFD Workshop for Super-Sonic Transport Design*, Tokyo, 1998.