

Pix2Pix GAN を用いたサイドミラー周り 流れ場短時間予測ツール

Short-time Prediction Tool for Flow Fields around Side Mirrors Using Pix2Pix GAN

橋 本 拓 郎¹

Takuro HASHIMOTO

山戸田 武 史²

Takeshi YAMATODA

岡 部 浩 司¹

Koji OKABE

城 戸 誉 芳²

Takafusa KIDO

要 旨

開発初期におけるサイドミラーのデザイン方向性を検討するため、深層学習モデルの一つである Pix2Pix GAN を採用して、流れ場を短時間かつ十分な精度で予測し、出力までの操作が容易なツールを構築した。深層学習モデルによる予測時間の短縮に加え、計算負荷の高い形状認識のための符号付距離関数を省略して更なる短時間化を達成した。同時に少量の学習データでも予測精度を維持できるツールを構築した。さらに、ツールの操作画面においては、検証に必要な流体物理量の出力を最小限に絞り、入力から出力までをボタン操作のみでおこなえることで、設計者が使いやすいように工夫した。

ABSTRACT

To examine the design direction of side mirrors in the early stages of development, a Pix2Pix GAN deep learning model was used to develop an easy-to-operate tool that enables prediction of flow fields with sufficient accuracy in a short period of time and output of the results. In addition to a shorter prediction time with a deep learning model, further time reduction was achieved by omitting the signed distance function for shape recognition that has a high computational load. The tool was also developed to maintain prediction accuracy even with a small amount of training data. Furthermore, output of fluid physical quantities required for verification on the tool operation screen was minimized, allowing performance of the process from input to output solely by button operations, making it easy to use for designers.

1. まえがき

自動車用サイドミラーは、後方の状況把握のために使用される部品である。車体外部に取り付けられているため、高速走行時には部品形状が周囲の流れを乱すことによって鏡面が振動し、後方視認性を低下させる場合がある。そのため、我々はこの流れの影響を最小限にするために数値流体解析 (Computational Fluid Dynamics: CFD) による性能予測を実施し形状検討を進めている。近年 CFD は Graphics Processing Unit (GPU) の進化により計算時間が短縮されつつあるが、サイドミラー周りの流速 (速度 3 成分) と表面流線、及び表面の圧力分布を計算するのに約 3 日を要している。

サイドミラーの形状は鏡面の振動に影響を与える一方で、スタイリングにも影響する。機能とスタイリングを両

立させるためには、本来、設計者とスタイリングデザイナーはその場で議論できることが望ましい。しかし、現状 CFD 計算には時間がかかり、持ち帰って性能予測する必要がある。この期間は、設計者が決定した最適形状とスタイリングデザイナーの望むデザインの間ですり合わせをおこなえないことから方向性が合わずに手戻りが発生することが多く、開発期間短縮のボトルネックとなっている。

この課題を解決するために、5 分程度の短時間で予測可能なツールがあれば、設計者とスタイリングデザイナーが予測結果を見ながらトライアンドエラーを繰り返し、会議の最中に両立する形状を決定できるようになると考えられる。

近年、予測を短時間でおこなうための手法として深層学習によるサロゲートモデルの研究が盛んにおこなわれてきており、予測時間の短縮に効果があることが数多く報告さ

¹ 本田技研工業株式会社

E-mail: takuro_hashimoto@jp.honda

² 株式会社 IDAJ

れている⁽¹⁾。

深層学習によるサロゲートモデルは、一般的に Fig. 1 に示すように、Convolutional Neural Networks (CNN) を用いた CNN 符号化器と CNN 復号化器を組み合わせた CNN 自己符号化器 (CNN Autoencoder: CNN-AE) ベースのアーキテクチャが採用されている⁽²⁾。しかし CNN-AE のデメリットとして特徴抽出のための符号化 (圧縮) の過程で細かな情報がノイズとして失われ、形状輪郭がぼやけてしまうことが知られている。このため、形状データを符号付距離関数 (Signed Distance Function: SDF) に換算して CNN 符号化器へ入力し、これを防止している。SDF は形状の幾何学的情報を付与し、ある点からの距離やモデルの内外判定をおこなう符号を含む関数である。精度が向上する一方、訓練時のみならず推論時も毎回全点の距離を算出するため時間がかかるというデメリットがある。

また、一般的には深層学習モデル構築で十分な精度を確保するためには 10^3 オーダーのデータが必要となることが知られており、赤坂らの研究⁽¹⁾においても同様の条件でおこなわれている。今回、CFD の結果を用いて、このオーダーの訓練データを準備するには5か月程度かかることが課題であった。

もう一つの課題として、設計者が予測ツールを使用する際の表示方法や操作性を考慮する必要がある。議論の時間が限られているので、事象を多角的に確認するよりも検討に必要な情報だけを迅速かつ簡単に表示できることが求められている。

これらの課題を解決するため、本研究においては、下記三点について検討をおこなった。まず、予測時間を短縮するために深層学習を用いるとともに、SDF を省略する可能性について検討した。二つ目に、少量の学習データで予測精度が確保可能な深層学習モデルを検討した。三つ目に、設計者の操作が煩雑にならないように、検証に必要な出力を最小限に絞り、ボタン操作のみでおこなえる操作画面について検討した。

2. 深層学習モデル選定と予測ツール構築

上記の課題解決に向けて、最適な深層学習モデルの選定と事前確認、設計者が容易に出力できる表示画面について検討をおこなった。




Fig. 1 Basic architecture of previous study

2.1. 予測時間の短縮

予測時間の短縮のため、本研究でも深層学習によるサロゲートモデルを適用した。その深層学習モデルには Pix2Pix Generative Adversarial Networks (Pix2Pix GAN)⁽³⁾を採用し、SDF の省略によるさらなる高速化について検討した。Fig. 2 にそのアルゴリズムのベースとなっている GAN を示す。GAN は、Goodfellow ら⁽⁴⁾によって提唱された生成器の訓練手法であり、生成器 (Generator) に加え、識別器 (Discriminator) という二つのニューラルネットワークから構成される。生成器はランダムノイズを入力としてデータを生成する。識別器はそのデータが本物か偽物かを判別する。学習の中で両者は互いに競い合うように学習を進め、生成されるデータの品質が向上していく (敵対的訓練)。これにより形状輪郭がぼやけてしまう CNN-AE に対して、GAN は鮮明な出力を得ることができるまで学習を続ける特徴がある。

GAN を発展させたものに、Fig. 3 に示す Mirza らによって提唱された条件付き敵対的生成ネットワーク (conditional GAN: cGAN)⁽⁵⁾がある。生成器に条件付き入力を指定することが可能となり、任意の入力に対応した出力を持つ生成器を訓練することで、予測精度を高めることができる。

Pix2Pix GAN は、cGAN をさらに発展させたもので、画像生成アルゴリズムのひとつとして広く使用されている。ペアになった二枚の画像の関係性を学習することで、ある一枚の画像をもとに、その関係を反映したもう一枚の画像




Fig. 2 GAN




Fig. 3 Conditional GAN

を生成することができる。通常条件付き入力として二次元画像を用いるのが一般的であるが、サイドミラー周りの空間流速（速度3成分）と圧力の予測をおこなうため、アーキテクチャを三次元拡張し、条件付き画像の代わりに STL 形式の三次元データを用いた。三次元への拡張は Cirillo ら⁽⁶⁾によって腫瘍セグメンテーションに使用した例があるが、流体予測に適用した例はない。そこで、形状のボクセルデータを入力して、流体物理量を出力する生成器として用いた。さらに Pix2Pix GAN の大きな特徴は生成器に Ronneberger ら⁽⁷⁾によって提唱された U-Net が用いられている点である。Fig. 4 に U-Net の CNN 層を三次元に拡張させた本研究のアーキテクチャを示す。U-Net はエンコーダとデコーダからなるアーキテクチャで、エンコーダで抽出された特徴をデコーダで元のサイズの画像に戻しつつ、エンコーダとデコーダの間のスキップコネクションにより、詳細な情報が失われることなく、同じ解像度のデコーダ層に伝えることができる。これによりエンコーダで失われがちな空間情報や解像度の詳細をデコーダに直接伝えることが可能であり、CNN-AE では符号化の過程で失われてしまう細かい特徴も保持することができる。これら GAN と U-Net の使用によって、SDF を用いずとも予測精度を維持しつつ、時間短縮が可能かどうかを検討する。

Fig. 5 に今回検討したアーキテクチャを示す。推論部分には Pix2Pix GAN を使用した。予測精度の検証をおこなうながら CNN-AE では推論前に必要であった SDF を省略することで、ボクセル表現の形状データを直接生成器に入力する方式を検討した。




Fig. 4 Extension of U-Net to 3D




Fig. 5 Proposed architecture

Table 1 Deep learning conditions

	CNN-AE	Pix2Pix GAN
Number of training data	32,500	2,000
Using SDF	Yes	No

2.2. 少量の学習データによる予測精度の確保

一般的に使用される CNN-AE は、ミニバッチと呼ばれる小さなデータ単位ごとに学習をおこなうが、データ分布全体を考慮できないことから、高い精度を得るには大量の学習データが必要となる。

一方、Pix2Pix GAN は、少量の学習データでも高い予測精度を実現できる有効な深層学習モデルである。その理由として、敵対的訓練によって生成モデルがデータ分布全体を捉えられることに加え⁽⁴⁾、生成器に採用されている U-Net が高精度な予測を可能にする点が挙げられる。これらの要素が組み合わさることで、CNN-AE より少ないデータでも予測精度の高い生成器の訓練が可能となっている。

本研究では、少量学習データによる予測精度を検証するため、予測精度と学習データ数の目標値を設定した。Reynolds-averaged Navier-Stokes (RANS) を使用した CFD の精度が $\pm 10\%$ 程度であることから、予測精度目標は誤差 $\pm 10\%$ 以内と設定した。サイドミラーの圧力係数 C_p は ± 0.3 の範囲であることから ± 0.03 以下、速度は主流速 38.8 m/s に対して ± 3.8 m/s (± 13.6 km/h) となる。学習データ数は 100 個以下を目標とした。

精度検証には式 (1) に示す平均二乗誤差 (Mean Squared Error: MSE) を使用した。

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (1)$$

ここで、 Y_i および $\hat{Y}_i$ は CFD 結果と予測ツールの推定結果を示している。 n はボクセル点数を示している。

この式から精度目標は、圧力は MSE で 750 以下、速度は MSE で 14.4 以下となる。

2.3. 二次元画像による精度検証

本ツールを構築するにあたり、事前に Pix2Pix GAN の予測精度の妥当性について、Guo らによる CNN-AE と Pix2Pix GAN を比較し検証をおこなった。学習データとして、様々な形状において汎用 CFD ソフト Synopsys 社製 ANSYS Fluent によって計算された二次元の速度分布の画像を用いた。Table 1 に学習時の条件を示す。CNN-AE は学習データに 32,500 枚の画像を使用し、さらに SDF への換算をおこなっている。Pix2Pix GAN は学習データに 32,500 枚の画像からランダムに選択した 2,000 枚を使用し、SDF を省略している。Fig. 6 に予測時の入力例としてバイク形状のバイナリデータと、そこから算出された SDF を示す。Fig. 7 はこの条件をもとに予測した流速

U_x 成分 (図水平方向) の結果比較である。CNN-AE および Pix2Pix GAN とともに、バイク形状およびバイク周辺の速度分布は、CFD と同様のボケの少ない画像が得られたとともに、速度の強弱やその領域を定性的に再現することができている。この結果から CNN-AE の代わりに Pix2Pix GAN を採用することで学習データ数が減らせること、SDF が無くても流れ場の車体近傍流速の予測が可能なが示された。

2.4. 容易に出力可能な操作画面の実現

操作画面は設計者が使用できるように、容易に操作できる必要がある。そこで、すべての操作をボタンのみでおこなえるようにした。入力となる STL データの読み込みから、予測結果の出力までの必要なボタンが順番に並び、一つの画面ですべて操作できる画面とした。出力は Fig. 8 に示す断面速度分布とサイドミラー表面の流体情報 (表面圧力分布および流速分布, 表面流線) に絞り込み、ボタン操作のみで容易に選択表示できるようにした。




Fig. 6 2D input image




Fig. 7 Comparison between CNN-AE and Pix2Pix GAN




Fig. 8 Mapping from spatial distributions to surfaces

3. サイドミラー予測に向けた学習

2章で説明したツールを用いて、サイドミラー周辺の圧力分布と流速分布を予測するための学習をおこなった。

3.1. 学習過程

Fig. 9 に本研究で用いた Pix2Pix GAN の提案モデルにおける空間圧力分布の学習過程を示す。まず、ボクセル表現のサイドミラー形状を条件付き入力データとして生成器に加えた。その生成器によって予測された空間圧力分布とサイドミラー形状のペア、同様に CFD 結果 (真値) とミラー形状のペアをそれぞれ作成した。続いて識別器はそのふたつのペアを入力として、真偽判定をおこなった。その後この判定をもとに敵対的訓練をおこなった。三次元の空間速度分布 (X, Y, Z 方向) に対しても同様に訓練をおこなった。参考までに、このモデルは未知のサイドミラー形状の STL データを与えると生成器のみで空間圧力および空間速度を予測することができる。

3.2. CFD による学習データ生成

学習データは、サイドミラーを取り付けた車両における CFD 結果を用いた。種々のミラーサイズに適用することを想定し、最大のミラーサイズをもつ車体を選定して、すべてのミラーサイズを包括できるようにした。サイドミラーを、Fig. 10 に示すように形状や位置、大きさの特徴を表す 11 個の形状パラメータを設定した。形状パラメータはそれぞれ 3 水準とし、乱数実験計画に基づいた 101 ケースの組み合わせを生成した。パラメトリックなデータ生成には市販のモーフィングツール DEP 社製の DEP MeshWorks を使い、CFD には ANSYS Fluent を用いた。

CFD のメッシュ条件を Table 2 に、メッシュの配置状況を Fig. 11 に示す。全体にヘキサメッシュをベースに用い、表面のみ形状再現のため 1 層の境界層メッシュを配置した。CFD の解析条件を Table 3 に示す。乱流モデルには RANS を使用した。また CFD 結果の一例を Fig. 12 に示す。




Fig. 9 Deep learning model for pressure distribution

Table 2 Mesh conditions

Number of mesh	50 million
Vehicle surface mesh size	4 mm
Circumference	8-16 mm
Boundary layer mesh	2 mm x 1 layer

Table 3 Analysis conditions

Turbulence model	Realizable k-ε
Speed	140 km/h (38.8 m/s)
Density	1.205 kg/m ³
Viscosity coefficient	1.8075e-5 Pa-s

No.	Parameters
1	Peak position (Horizontal direction)
2	Peak position (Vertical direction)
3	Inner plane angle
4	Outer plane angle
5	Leading edge angle
6	Mirror size
7	Length in mainstream direction
8	Mounting position (Rotation)
9	Mounting position (Mainstream direction)
10	Mounting position (Vertical direction)
11	Mounting position (Horizontal direction)

Fig. 10 CFD model creation for training data




Fig. 11 Mesh placement




Fig. 12 Example of pressure distribution results using CFD

3.3. 学習データ抽出

車両全体の CFD 結果に対して、深層学習による予測空間をサイドミラー周辺に絞ることで、サイドミラーモデルの形状解像度を引き上げつつ、データ容量を削減して高速度化を図った。具体的な深層学習による予測空間は、Fig. 13 に示すように長さが 400 mm のサイドミラーを包含する立方体とし、その内部に 2 mm 間隔のボクセルを配置した。Fig. 14 に示すミラー形状のボクセルデータへの変換には、オープンソース The Visualization Toolkit (VTK) ライブラリの vtkSelectEnclosedPoints アルゴリズムを使用した。

学習データとして使用する空間圧力場の例を Fig. 15 に示す。CFD メッシュからボクセルへの変換は、各ボクセルの中心に、その近傍上位 10 個の CFD メッシュ点の平均値を代入しておこなった。




Fig. 13 Training data space for deep learning




Fig. 14 Side mirror voxel model as noise and condition label




Fig. 15 Example of pressure distribution as training data

Table 4 Machine learning conditions

	Velocity	Pressure
Optimizer	Adams	Adams
Epoch	1000	1000
Batch size	1	1
Learning rate	2×10^{-4}	2×10^{-5}

3.4. 学習条件と学習時間

Table 4 に学習条件を示す。用意した 101 ケースのうち、80 ケースを学習データとして使用した。訓練には NVIDIA 社製 RTX A6000 GPU を 1 台使用した。学習には約 190 時間かった。

4. 予測ツールの精度検証と効果

本ツールによって得られた空間圧力分布と空間速度分布の予測結果それぞれについて検証をおこなうとともに、製作した操作画面において実行した場合の時間短縮効果について確認した。

4.1. 空間圧力分布予測結果

Fig. 16 に空間圧力分布の推論結果を表面投影した表面圧力分布と CFD 結果との比較を示す。ボクセル化による影響で解像度が下がり、圧力分布にムラが生じるものの、




Fig. 16 Comparison of predicted and CFD pressure distribution

圧力の上昇や下降箇所は定性的に CFD 結果と一致した。

Fig. 17 に空間圧力分布を予測した際の MSE を示す。横軸にミラー形状毎に割振った識別番号をとり、縦軸に MSE をプロットしている。白丸は構築した深層学習ツールにおける訓練データ 80 ケースの MSE、黒丸は検証データ 21 ケースの MSE である。訓練データ全体の MSE は 160 程度、検証データ全体の MSE は 330 程度であり、精度目標 10% 以内に収まっていた。ただし、最も悪いケースで MSE は 841 となりわずかに 10% を超えていた。

4.2. 空間流速分布予測結果

Fig. 18 に、空間流速分布の推論結果を表面投影した表面流速分布と流線と CFD 結果との比較を示す。ミラー振




Fig. 17 MSE of inference of pressure distribution




Fig. 18 Comparison of predicted and CFD velocity distribution

動に起因するのは、はく離などに影響される表面速度の分布状況や、流線の方向である。この観点において、予測結果はCFD結果とおおむね一致している。

以上の結果より学習データが80個でも十分な精度を確保した予測ツールを構築できた。

各ミラー形状の空間流速分布予測におけるMSEをFig. 19に示す。訓練データ80ケース全体のMSEは0.1程度、検証データ21ケース全体のMSEは1.0程度であった。検証データ全体のMSEを速度に換算すると±1 m/s程度であり、目標値である10%以内に収まっていた。最も悪いケースでもMSEは4.9(速度±1.1 m/s)となり、10%以内に収まっていた。これらの結果から少量の学習データにおいても、本ツールを活用するうえで十分な精度を確保できていることがわかった。

4.3. 操作画面

本研究において製作した操作画面をFig. 20に示す。入力となるSTLの読み込みから出力結果までの手順のボタンが順番に並び、同一画面上で操作することができる。必




Fig. 19 MSE of inference of velocity distribution

Table 5 Computer specifications

	CFD	Deep learning
CPU	AMS EPYC7702	Intel Xeon w9-3475X 2.21GHz
Number of CPUs	128 core/node	1
GPU	-	NVIDIA RTX6000 Ada
Memory	512 GB/node	1 TB
OS	Red Hat Enterprise Linux release 8.3	Windows Server 2022

要な出力表示は絞り込まれ、すべてボタン操作のみで容易におこなうことができる。

4.4. 計算時間

予測ツールの時間評価をおこなうにあたり、各計算に使用した機材のスペックをTable 5に示す。またFig. 21に本予測ツール全体のワークフローを示す。CFDによる予測では52時間かかっていた作業が、約100秒でできるようになった。




Fig. 20 Graphics of user interface




Fig. 21 Workflow of proposed system and total time

4.5. まとめ

以上のことから、構築した予測ツールを活用することで、設計者はスタイリングデザイナーとリアルタイムで意見を交わしながら、デザインの意思決定をおこなうことが可能となる。

加えて、議論を継続することで、アイデアの深掘りや洗練が進んだり、異なる視点を持つ両者が刺激されることで、様々なアイデアが創出されることも期待できる。

5. 結言

本研究では、Pix2Pix GAN を使用して、以下の特徴を有する、サイドミラー周りの流れ場予測ツールを開発した。

- (1) 深層学習モデルによる予測時間の短縮に加え、Pix2Pix GAN の特徴である GAN や U-Net といったアーキテクチャの寄与により、計算負荷の高い SDF を省略することで更なる短時間化を実現した。これにより STL データの投入から結果表示までを約 100 秒でおこなうことができた。
- (2) 敵対的訓練による生成モデルはデータ分布全体を捉えることができるため、小さな塊ごとに学習させる従来手法より少量データで予測することができる。これにより 80 個の少量学習データでも、圧力及び流速が CFD 結果の±10% 以内で予測できた。
- (3) 検証に必要な流体物理量の表示を最小限に絞り、ボタン上に機能を表現することで、設計者がすべての操作をマウス操作だけで迷わずに選択できる表示画面を製作した。

本手法は、学習データの収集が容易ではないユーザや、これから導入や開発を始めようとするユーザにとって有用な手法であり、今後は他の予測ツールにも広く活用されることを期待する。

参考文献

- (1) 赤坂啓, 陳放歌, 寺口剛仁: 機械学習を用いた自動車空力性能を予測するためのサロゲートモデル開発, 自動車技術会論文集 Vol. 52, No. 3, p. 621-626, (2021), doi: 10.11351/jsaeronbun.52.621
- (2) Guo, X., Li, W., Iorio, F.: Convolutional Neural Networks for Steady Flow Approximation, KDD '16: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, p. 481-490, (2016), doi: 10.1145/2939672.2939738
- (3) Isola, P., Zhu, J-Y., Zhou, T., Efros, A. A.: Image-to-Image Translation with Conditional Adversarial Networks, 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), p. 5967-

5976, (2017), doi: 10.1109/CVPR.2017.632

- (4) Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., Bengio, Y.: Generative adversarial networks, Communications of the ACM, Vol. 63, Issue 11, p. 139-144, (2020), doi: 10.1145/3422622
- (5) Mirza, M., Osindero, S.: Conditional Generative Adversarial Nets, arXiv, (2014), doi: 10.48550/arXiv.1411.1784
- (6) Cirillo, M. D., Abramian, D., Eklund, A.: Vox2Vox: 3D-GAN for Brain Tumour Segmentation, Lecture Notes in Computer Science, Springer, Cham, Vol. 12658, p. 274-284, (2021), doi: 10.1007/978-3-030-72084-1_25
- (7) Ronneberger, O., Fischer, P., Brox, T.: U-Net: Convolutional Networks for Biomedical Image Segmentation, Lecture Notes in Computer Science, Vol. 9351, p. 234-241, (2015), doi: 10.1007/978-3-319-24574-4_28

■ 著 者 ■



橋本 拓郎



岡部 浩司



山戸田 武史



城戸 誉芳