

CNN を用いた類似した三次元船型形状からの造波抵抗推定 Wave making resistance estimation from similar 3D hull shape using CNN

登内 雅人[†]
Masato Tonouchi

新井 洋[‡]
Hiroshi Arai

濱上 知樹[†]
Tomoki Hamagami

1 はじめに

日本の貨物輸送において、その総重量における船舶の占める割合は非常に高い。したがって、船舶の推進性能の向上は膨大なコスト削減に繋がり、造船業界では造波抵抗削減のための船型開発が盛んに行われている。特に、造波抵抗推定は造波抵抗削減を達成するための重要な要素である。

船型の検討段階においては、数値流体力学 (CFD: Computational Fluid Dynamics) などの数値解析を用いて船型の推進性能を評価することが一般的であるが、造波抵抗の推定を対象にした CFD では、現状では精度や計算時間の観点で課題がある。これに対し、船型開発ではその開発フローの中で模型船を使った水槽試験の結果が得られるため、実データを活用した機械学習や深層学習による造波抵抗推定も可能である。既存研究では、ニューラルネットワークを用いた手法 [1][2][3] が提案されている。一方で、これらの手法は特徴量設計の観点で改善の余地がある。

本研究では学習モデルに与えるデータ表現及び特徴量設計を見直し、船側面の深度マップから Convolutional Neural Network (CNN) により形状特徴量を獲得することで、造波抵抗推定の精度改善を目指す。また、船型という類似した形状データから有効な特徴抽出を行うための機構を提案する。

2 船型開発について

造船業界における現状の船型開発の流れは図 1 に示す。

図 1 に示すように、何らかの船型を検討する際には、船型形状の設計と推進性能推定を繰り返し行い、水槽試験の供試模型を決定する手順が一般的である。

2.1 水槽試験

水槽試験は、船舶や海洋構造物の流体力学的な性能を調査するために、各種の流体の状態を試験水槽内に再現し、模型を使って行う試験である。造波抵抗の評価についても水槽試験が使われる。水槽試験から得られるデータとしては、船の形状を記した船型オフセッ

ト、船の速度を表すフルード数 F_n 、造波抵抗係数 C_w がある。

船型オフセットは、図 2 に示す船舶を x 軸方向に特定の間隔で切り取った断面上の測量点で、船の幅長を記録した船体寸法表である。測量点数や間隔は船によって異なる。

また、造波抵抗係数は船のスケールに依存しない値であるため、模型船による水槽試験の結果はそのまま実物大の船にも適用できる。

2.2 船型と造波抵抗の関係

造波抵抗は船舶形状と推進速度によって決まる抵抗値である。船型が決まったとき、造波抵抗係数 C_w はフルード数 F_n に対し、単調増加の傾向になるが、船型によってはハンプと呼ばれる複雑な関係式となる場合もある。また、最適な船型は喫水線位置や目標船速によって変わる。

3 CNN による造波抵抗推定

本研究では、水槽試験結果の実データを活用し、CNN で船型から造波抵抗の推定を行う。3 次元物体形状からの学習は、ボクセルを用いた手法 [4] や、複数視点からの深度マップを用いた手法 [5] などが提案されているが、ボクセルによる学習では、解像度を下げる必要があるため、精度面に課題がある。一方で、深度マップは比較的次元で物体の三次元形状を表すことが可能である上に、CNN による学習で成果をあげている形状表現方法である。よって、船型オフセットから深度マップを作成し、その深度マップから有効な形状特徴量を CNN による学習によって獲得することを目指す。

ここで、本研究では対象船種としてタンカーに限定しているが、タンカーは船首・船尾以外の形状は非常に類似しており、深度マップ上では類似した領域が大部分を占めるため、抽出された特徴量も類似したものが多数を占める可能性がある。そこで、畳み込み層の最終層で Global Max Pooling (GMP) を適用し、必要な特徴量のみを獲得できるようにする。

3.1 データの作成

本研究では、船型オフセットから船側面の深度マップを作成し、学習データとする。本研究の対象船型は、図 2 での $x-z$ 面を基準に左右対称であるため、船型




図 1: 船型開発のフロー




図 2: 模型船体

[†]横浜国立大学大学院理工学部

[‡]ジャパンマリユニテッド (株)




図 3: 船型の深度マップ (喫水線以下)

表 1: コサイン類似度

	船型 No.0327	全船型
平均値	0.73	0.631
標準偏差	0.332	0.093

オフセットに記録されている各断面での半幅をそのまま深度情報として用いることで、船舶の 3 次元的な形状の表現が満たされる。

船型オフセットデータは、船によって計測断面の数や間隔も異なる。そのため、深度マップを作成する際に、事前に補間処理を行って密な深度情報を得る必要がある。また、水槽試験で使用された模型船のスケールに対して不変な学習器を作成するために、入力データのスケールを揃える処理も行う。さらに、造波抵抗の発生に大きく寄与するのは喫水線以下の形状であるため、喫水線以下の領域だけで切り取り、最終的な深度マップを作成する。

形状データ作成手順を示す。

1. 船型オフセットを読み込み
2. 全船舶の船長を 5.0[m] に揃えるスケール変換
3. 0.01[m] 間隔で船長・船高方向にスプライン補間
4. 喫水線以下だけでクロッピング
5. 深度マップとしてマッピング

上記の手順により作成された船型 No.0327 の深度マップの例を図 3 に示す。なお、図 3 左が船首側である。

3.2 入力データの形状類似性

本研究で対象とする形状データは、図 2 や図 3 に示すように、船首・船尾以外の部分の形状が非常に類似している。これは、CNN で特徴抽出を行う際に、船の中間領域でほとんど同じ特徴量が抽出されることを意味する。

表 1 に、本提案手法の畳み込み層で抽出された特徴マップ ($7 \times 31 \times 164$ 次元) を船長方向の軸で分割し、コサイン類似度を求めた結果を示す。特徴マップの断面間では $7 \times 164 = 1148$ 次元ベクトルの比較となる。このような高次元数のベクトル間で、コサイン類似度が表 1 のような結果になるのは、対象データの類似度の高さを示している。

3.3 提案手法

本研究では、CNN によって深度マップから獲得した形状特徴量とフルード数 F_n から、造波抵抗係数 C_w を

推定するモデルを提案する。ここで、3.2 節で述べた入力データの形状類似性から、CNN により抽出される特徴量も類似したものになり、学習を行う上で悪影響を及ぼす可能性がある。そこで、畳み込み層の最終層で GMP による特徴量選択を行い、続く全結合層に必要な特徴量のみを与える手法をとる。

Global Pooling は、CNN において有効なダウンサンプリング手法であり、特に Global Average Pooling (GAP) [6] は、一般物体認識など、様々な研究でその有用性が報告されている [7]。一方で、GMP については、活用された報告例は多くない。

それぞれの Global Pooling は、チャンネル k の特徴マップの i, j 座標の値を $A_{i,j}^k$ 、各特徴マップのサイズを Z 、チャンネル k での出力を y_k とした時、式 (1) と式 (2) のように算出される。

- Global Average Pooling:

$$y_k = \frac{1}{Z} \sum_{i,j} A_{i,j}^k \quad (1)$$

- Global Max Pooling:

$$y_k = \max(A_{i,j}^k) \quad (2)$$

ここで、GAP を本研究において活用する場合、その平均化処理は 3.2 節で述べたような特徴マップ中の多数派の類似特徴量によって影響を受ける。これにより、形状に差がある領域の特徴量の寄与度が小さい値が出力されてしまう。このように、類似した形状から学習を行う場合、GAP の使用は適切とはいえない。一方、GMP は特徴マップの各チャンネルの最大値を選択する操作であるため、特徴マップ上の特徴量の類似性によって影響を受けることはなく、重要な特徴量のみを残す効果的なダウンサンプリングが行える。本研究においては、船首尾などの船型開発における重要領域から特徴を獲得できるようになることが期待できる。

このように、GMP は、類似した形状から CNN で学習を行う上で有効に働く手法であると考えられる。以降の実験により、実際に GMP の有効性を示す。

4 実験

4.1 実験設定

全 582 隻の試験船型による水槽試験結果を用いて実験を行う。各船について船型オフセットと水槽試験の異なる船速による試験点が 10 点程度含まれるため、合計 6908 点の試験点がある。船種はタンカーに限定し、対象船型の要目を表 2 に示す。ここで、 L_{pp} , B , z , d はそれぞれ船の長さ、幅、高さ、喫水線位置を表す。

その他、提案モデルを学習する際の各種実験パラメータは表 3 に示す。表 3 の設定で、582 隻の船型形状を 5 つのグループに分けた交差検証により、提案手法のモデルを評価する。

4.2 実験結果

実験結果を図 4 に示す。比較として GAP を使用した場合の結果も示している。図 4 の結果から、GMP の

表 2: 対象船型の平均値・標準偏差

	平均値	標準偏差
$Lpp[m]$	6.47	0.521
$B[m]$	1.067	0.199
$z[m]$	0.544	0.079
$d[m]$	0.353	0.073

表 3: 実験パラメータ

項目	設定値
Epoch 数	100
バッチサイズ	64
入力データ	shape = [63, 500]
学習率	adam(r=0.01) + 減衰率 0.98
学習パラメータ数	100,000

使用によって精度が向上していることが分かる。よって、類似形状から学習を行う場合に、GMP は有効であることが分かる。

また、検証データに対する推定結果の例を図 5 に示す。図 5 から我々が提案したモデルにより、高精度な造波抵抗推定が可能であるといえる。

一方、図 6 に示すように、推定が大きく外れるケースもある。これは 2.2 節で述べたハンブが極端に生じるケースであり、これに関しては図 6 に見られるような曲線を描くものが学習データ中にあまりないことが原因だと考えている。これらのように、ハンブと呼ばれる現象がここまで大きく生じているケースは特殊であるが、これら少数派の船型データの対応については今後の課題として検討する。

5 学習モデルの分析

提案手法の学習済みモデルの分析を行う。学習済みモデルの分析を行う手法としては、Grad-CAM などの

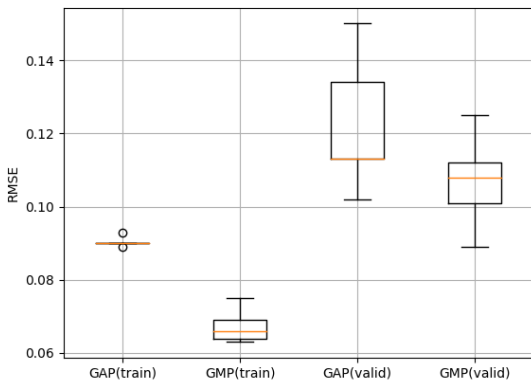


図 4: 5 分割交差検証の RMSE

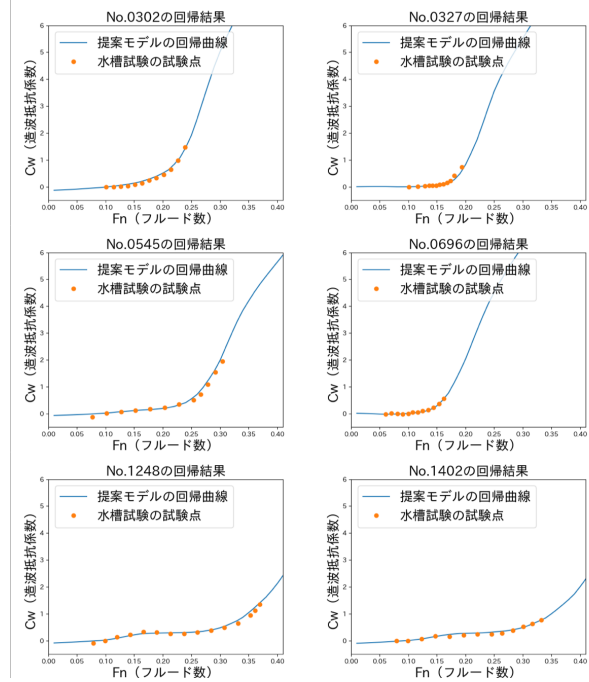


図 5: 造波抵抗推定の一例




図 6: 推定誤差の大きい例

解釈性を与える研究が報告されており、これはモデルが出力を決定する際に注目した領域を抽出できる。本研究においては、学習済みモデルを分析することで、船型形状検討の段階への有益な情報の提示が期待できる。

5.1 Grad-CAM

Grad-CAM は、Ramprasaath R. Selvaraju らの研究 [8] で報告された深層学習に解釈性を与える研究の一つである。以下に Grad-CAM で注目領域を抽出する手順を示す。なお、 c はクラス、 k はチャンネル、 Z は特徴マップのサイズ、 y^c はクラス c の出力、 $A_{i,j}^k$ はチャンネル k の特徴マップの座標 (i, j) の値を表す。

1. 特徴マップ A の各チャンネル k の重み a_k^c を計算

$$a_k^c = \frac{1}{Z} \sum_{i,j} \frac{\partial y^c}{\partial A_{i,j}^k} \quad (3)$$

2. クラス c における注目領域 L_{CAM}^c を計算

$$L_{CAM}^c = ReLU \left(\sum_k a_k^c A^k \right) \quad (4)$$

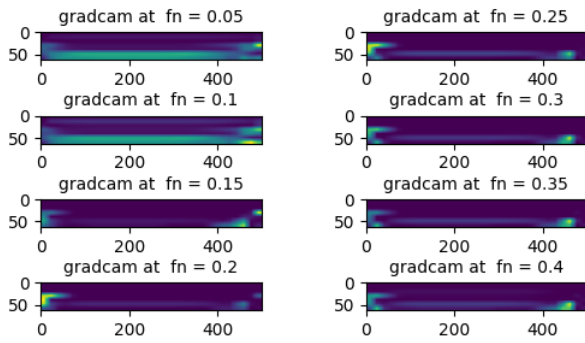


図 7: Grad-CAM による可視化の一例

以上の手順により、学習器の注目領域が得られる。なお、本研究で扱う問題は回帰問題であるため、 c は変数でなく一意に定まる。また、ステップ 1 の重み a_k の算出部分は、本研究では GMP を用いているため、以下の式での算出になる。これによって、Grad-CAM の可視化においても形状の類似による影響をなくすることができる。次節で、 L_{CAM} を可視化することで、注目領域の分析を行う。

$$a_k^c = \max \left(\frac{\partial y^c}{\partial A_{i,j}^k} \right) \quad (5)$$

5.2 分析結果

Grad-CAM で図 3 の船型データの注目領域を可視化した結果を図 7 に示す。

図 7 は、0.05 から 0.4 までの 8 通りのフルード数 F_n で算出した Grad-CAM の可視化結果を示している。図 7 から、船首・船尾を注視していることがわかる。一般的に、船首尾端部の形状の変化が造波抵抗に大きな影響を及ぼすと言われているため、これは妥当な結果であるといえる。また、 F_n によって注目領域に差があることも確認できる。これは目標の船速に合わせた船型を検討する上で、どの部分を改良すればいいかなどの有益な知見となる可能性が期待できる。

これらの考察から、造波抵抗推定の判断の妥当性が示されており、提案したモデルを用いることによる船型の最適化は効果的に機能することが期待される。

6 おわりに

本研究では、船型オフセットを深度マップに変換し、CNN により造波抵抗推定を行う手法を提案した。GMP を活用した提案モデルは、類似した船型形状からも有効な特徴を抽出できており、ハンプの大きい船型以外で精度の高い造波抵抗推定を実現していることを示した。また、5 章で示した通り、学習済みモデルの解釈結果から、船型形状の設計時に有益な情報を提供できることを示した。

今後の展望としては、4.2 節で述べた少数派の船型についても、造波抵抗の推定精度を向上させていくことを目指す。

参考文献

- [1] 松村竹実, 浦環, “ニューラルネットワークを利用した船型初期計画 (第 1 報)”, 日本造船学会論文集, 第 183 号 (1998), p.91-100.
- [2] 松村竹実, 浦環, “ニューラルネットワークを利用した船型初期計画 (第 2 報)”, 日本造船学会論文集, 第 184 号 (1998), p.551-560.
- [3] 金井健, “ニューラルネットワークによる船舶の推進性能推定とその船型最適化への応用”, 西部造船会会報, 第 99 号 (2000).
- [4] Z. Wu, S. Song, A. Khosla, F. Yu, L. Zhang, X. Tang and J. Xiao. 3D ShapeNets: A Deep Representation for Volumetric Shape Modeling. In Proc. of CVPR, 2015.
- [5] Hang Su, Subhransu Maji, Evangelos Kalogerakis, Erik Learned-Miller, Multi-view Convolutional Neural Networks for 3D Shape Recognition. In Proc. of ICCV, 2015.
- [6] M. Lin, Q. Chen, and S. Yan. Network in network. In Proc. of ICLR, 2014.
- [7] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, and A. Rabinovich. Going deeper with convolutions. In Proc. of CVPR, 2015.
- [8] Ramprasaath R. Selvaraju, Michael Cogswell, Abhishek Das, Ramakrishna Vedantam, Devi Parikh Dhruv Batram. Grad-CAM: Visual Explanations from Deep Networks via Gradient-based Localization. In Proc. of ICCV, 2017.