


ディープラーニングを用いた船舶性能要素推定

Hull Performance Estimation Using Deep Learning



技術研究所 流体研究 G

天谷 一朗

AMAYA Ichiro

新井 洋

ARAI Hiroshi

岡本 直也

OKAMOTO Naoya

概要

船型設計は、設計者の専門的知見や経験に依存するところが多い。設計者が作成した船型には、設計者の専門的知見や経験が暗黙的に含まれている。これらの知見を一般化し船型設計に活用することができれば、船舶設計の更なる効率化につながることが期待できる。そのための第一歩として、近年着目されているディープラーニングを用いて船型と性能要素の関係を導き出すことが可能か検討を行った。水槽試験で評価・確認している代表的な性能要素である造波抵抗係数および形状影響係数を対象として、水槽試験の結果を学習し、既存の統計データに基づいた推定ツールと比較し性能要素を精度良く推定できることを確認した。

Summary

Hull form design is strongly dependent on the expertise and experience of the engineer. Since the hull form implicitly includes the expert knowledge and experience of the engineer, if those can be utilized in the hull form design, it can be expected that it will lead to further efficiency of hull form design. As a first step to that goal, possibility of deriving the relationship between hull form and wave-making resistance coefficient and form factor (these are typical hull performance factors) is examined by using deep learning techniques. It is confirmed that typical hull performance factors can be estimated accurately by comparing with statistical estimation model based on the tank test results.

1. 緒言

推進性能における船体形状の設計とは、その三次元的な形状とそこから生み出される流体性能（抵抗や自航要素など）の関係を把握しながら最適な形状を求めることである。この形状と性能の関係は複雑であるため、設計者の経験により設計を進めていくことが多かった。これらの経験は暗黙知であることが多く、経験工学と呼ばれてきた。

近年、最適化手法の確立により、最適化自体の汎用性は高くなったが、これらは形状と結果の関係を解き明かすというよりは、大量の計算結果から良いものを選び出すというものである。

そこで近年、注目されてきているのが Deep Learning（深層学習）に代表される機械学習の活用である。この技術を用いることで、従来暗黙知であった設計者の経験値や判断をモデル化できる可能性が出てきた。Deep Learning とは、ニューラルネットワ

ークを多層に結合して学習能力を高めた機械学習の一手法である。一般的に Deep Learning には大きな計算資源が要求される一方で、これまでは人間が明示的に与える必要のあった判断材料を自動的に抽出・学習し、人間が介入することなく判断や分類を行うことができるという大きな利点がある。そのため、現在では画像認識や音声認識、翻訳等さまざまな分野で活用され成果を生み出している。

Deep Learning を利用した工業分野での研究としては、Zhang ら¹⁾が航空機の二次元翼の空力特性予測を目的に、画像認識に広く用いられる CNN (Convolutional Neural Network: 畳み込みニューラルネットワーク) を用いて翼形状画像から揚力係数の推定を行っている。また、赤坂ら²⁾は自動車の空力特性予測を目的に、CNN を用いて三次元のボクセルデータに変換した自動車の形状データおよび CFD 結果から自動車の空気抵抗係数の推定を行っている。

一方、船舶の分野では、松村ら³⁴⁾、金井⁵⁾のニューラルネットワークを用いた船舶性能要素推定の研究が存在するが、入力する船型データを主要目やプリズマティック曲線、水線の幅の分布等に限定しており、フレームライン形状の違いなどを考慮することができない。そのため、船体の三次元形状自体を考慮するという点において特徴量設計の観点から改善の余地がある。

以上から、Deep Learning を利用し、水槽試験を実施した船型から特徴量を抽出することで、船型に暗に含まれる工学的知見や設計者の経験をモデル化した船型設計支援ツールを構築することが可能ではないかと考える。

ここでは、設計者の専門的知見や経験を反映した最適船型の自動生成を最終目標として、まずはその第一段階として船型と性能要素の関係を Deep Learning により正しく導き出すことが可能か、過去に行われた水槽試験結果を用いて検討を行った。

2. CNN による性能要素推定法の構築

2.1 モデル概要

三次元物体形状からの学習には、ボクセルを用いた手法⁶⁾や複数視点からの深度マップ(表面の距離に関する情報を含む画像)を用いた手法⁷⁾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低次元で物体の三次元形状を表すことが可能であり、CNN による学習で成果を挙げている形状表現方法である。

図1は画像認識に一般的に用いられる CNN の原型となっている LeNet-5⁸⁾のネットワーク構造である。

CNN は基本的に Convolution 層および Pooling 層 (=Subsampling 層) から成り立ち、最終部分に分類等の処理を行う全結合層が配置される構造となっている。全結合層では空間的な情報が欠落してしまうため、画像の処理には Convolution 層が用いられる。Convolution 層では、カーネル(フィルタ)を用いて、画像の局所的な特徴を抽出し、Pooling 層では Convolution 層から出力された特徴強度を維持しつつ空間次元の削減を行う。上記処理を繰り返し行い、得られたすべての特徴を用いて全結合層で最終的な処理が行われる。Convolution 層ではカーネルのパラメータが自動で学習されることになる。

ここでは、船型オフセットから深度マップを作成し、深度マップを CNN によって学習することで、性能推定に有効な形状特徴量を獲得することを目指した。本研究で用いたニューラルネットワーク構造の概略を図2に示す。

2.2 教師データ

学習に使用する教師データは、水槽試験で得られた各種性能要素および船体形状となる。船体形状は、船型オフセットから作成した船側面の深度マップを教師データとする。船体形状の性能要素への寄与は喫水下




図1 LeNet-5のネットワーク構造⁸⁾

Fig.1 Architecture of CNN (LeNet-5)

が支配的であるため、深度マップへの変換は喫水線下の形状のみとした。また、教師データとして用いる水槽試験結果はイーブンキールの条件のみとした。図3に船体形状および船型オフセットから変換した深度マップの例を示す。

船型オフセットは、船によって船長方向の断面の数や間隔が異なる。そのため、深度マップを作成する際に補間処理を行い、密な深度情報とする必要がある。また、水槽試験模型の大きさに依存しない学習を行う必要があるため、入力データのスケールを統一する処理を行う。




図2 造波抵抗係数推定システムの構成
Fig.2 Configuration of wave-making resistance coefficient estimation system




図3 船体形状および深度マップ
Fig.3 Overview of hull form and depth map

3. 造波抵抗係数推定結果と考察

3.1 学習設定

造波抵抗係数の推定では、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 Fn から、造波抵抗係数 C_w を推定するモデルを構築する。

学習には 582 船型 582 状態の水槽試験結果を用いた。内訳はタンカー166 船型、バルクキャリア 98 船型、コンテナ船 158 船型、RORO 船 48 船型、一般貨物船 8 船型、ガス運搬船 12 船型、研究船型 72 船型、その他 20 船型である。水槽試験では、各船型で船速を変更し計測を行っているため、合計 6908 点の計測点となる。造波抵抗係数は船速ごとに推定されるため RMSE (Root Mean Squared Error : 二乗平均平方根誤差) を評価指標とした。

なお学習の妥当性評価には 5 分割交差検証を用いた。図 4 に 5 分割交差検証の概要を示す。学習は Training データと Validation データにより行われるが、5 分割交差検証は教師データを 5 つのサブセットに分割し、すべてのサブセットが 1 回ずつ Validation データとなるように 5 回学習を行うもので、交差検証はモデルの汎化性能を評価する統計的な手法である。

教師データ					T: Training Data V: Validation Data
ステップ1	V	T	T	T	⇒ モデル1
ステップ2	T	V	T	T	⇒ モデル2
ステップ3	T	T	V	T	⇒ モデル3
ステップ4	T	T	T	V	⇒ モデル4
ステップ5	T	T	T	T	⇒ モデル5

図4 5分割交差検証の概要
Fig.4 Overview of 5-fold cross validation

3.2 推定結果

5 分割交差検証で得られた RMSE を表 1 に示す。ステップ 4, 5 の Validation の RMSE が比較的高く、ステップごとのデータに若干の偏りが存在していると考えられる。各ステップのデータの割り振りを確認した結果、造波抵抗曲線に大きなハンプ・ホローが見られる船型が Training データには少なく、Validation データに多く含まれる場合に RMSE が高くなることが判明している。

表1 5分割交差検証の RMSE 比較
Table 1 RMSE comparison of 5-fold cross-validation

RMSE	Training Data	Validation Data
step1	0.032	0.067
step2	0.030	0.058
step3	0.032	0.057
step4	0.030	0.098
step5	0.032	0.081
average	0.031	0.072

Validation データの誤差が最も低いステップ 3 のモデルにおける Validation データに対する推定結果の例を図 5 に示す。図 5 には推定結果が水槽試験結果とよく一致しているものを示しているが、一方で図 6 に示すように比較的誤差が大きいものも存在している。造波抵抗曲線の立ち上がりが正しく捉えられていない船型で推定誤差が大きくなることが確認された。これは、上述したように波抵抗曲線に大きなハンプ・




図5 造波抵抗係数推定結果の例
Fig.5 Examples of wave-making resistance coefficient estimation




図6 推定誤差の大きい例
Fig.6 Examples with large estimation error

ホローが表れる船型がステップ 3 の Validation データにほとんど含まれておらず、推定誤差が極端に大きくなる船型がなかったためと考えられる。このことから学習には船型形状の特徴を網羅した十分なデータが必要と考えられる。

3.3 既存ツールとの比較

Deep Learning を用いた性能要素推定ツールの精度評価のため、船型設計に利用している水槽試験結果と主要目などの船体形状を含まない統計データに基づいた推定ツールとの比較を行った。

比較には、両ツールともに未使用の 41 船型 63 状態の水槽試験結果を用いた。これらは、教師データ群と比べ新しい船型である。内訳は、タンカー9 船型 15 状態、バルクキャリア 10 船型 16 状態、コンテナ船 13 船型 22 状態、RORO 船 4 船型 5 状態、その他 5 船型 5 状態である。

Deep Learning を用いた推定ツールおよび簡易推定ツールの両者で造波抵抗係数を推定し、RMSE を比較した結果を表 2 に示す。教師データの大半を占めるタンカー、バルクキャリアでは Deep Learning を用いることで推定精度が大きく改善しており、本提案手法の優位性が確認できた。一方で、コンテナ船、その他船型では大きな改善は見られず、RORO 船では推定精度が悪化する結果となった。精度が大きく改善しない原因としては、改善が見られない船種の教師データの隻数が少ない点、比較対象とした船型と教師データの年代が異なるため、設計思想が大きく異なっている可能性がある点が考えられる。

表 2 造波抵抗係数推定結果の比較
Table 2 Comparison of wave-making resistance coefficient estimation

RMSE of Wave-making resistance coefficient			
Ship type	statistical estimation model	Deep Learning model	Improvement ratio
All	0.108	0.076	29%
Tanker	0.123	0.037	70%
Bulk carrier	0.086	0.047	45%
Container carrier	0.102	0.093	8%
RORO	0.146	0.187	-29%
Others	0.140	0.131	7%

できる点が大きく寄与していると考えられる。

4. 形状影響係数推定結果と考察

4.1 学習設定

基本的には造波抵抗係数推定と同一であるが、教師データから形状影響係数 K に影響を及ぼす付加物（省エネデバイス等）が含まれる船型を除外した 531 船型 531 状態を学習に用いた。形状影響係数は 1 状態に対して 1 パラメータであるため、教師データは 531 点となる。形状影響係数では計測値と推定値の差が重要であるため、評価指標には MAE（Mean Absolute Error：絶対平均誤差）を用いた。

4.2 推定結果

形状影響係数の Validation データに対する MAE は 0.0156 となった。形状影響係数は通常 $1+K$ の形で用いられるため、仮に $1+K$ が 1.3 である場合、上記誤差は $1+K$ で 1.2% に相当することになる。

図 7 に Validation データに対する $1+K$ の実測値と推定値の比較を示す。おおむね $\pm 5\%$ の範囲に収まっているが、両端で誤差が大きな船型が存在していることがわかる。これは、両端付近の船型のデータが不足していることによるものと推測される。




図 7 形状影響係数推定結果
Fig.7 Estimation of form factor

4.3 既存ツールとの比較

Deep Learning を用いた推定ツールおよび前述の水槽試験結果と主要目などの船体形状を含まない統計データに基づいた推定ツールで形状影響係数を推定し、MAE を比較した結果を表 3 に示す。

形状影響係数の推定では、すべての船種で Deep Learning を用いることで推定精度が大きく改善しており、本提案手法の優位性が確認できた。これは既存の方法では考慮できなかった船型の三次元形状を考慮

表 3 形状影響係数推定結果の比較

Table 3 Comparison of form factor estimation

MAE of Form factor			
Ship type	statistical estimation model	Deep Learning model	Improvement ratio
All	0.092	0.047	49%
Tanker	0.050	0.018	63%
Bulk carrier	0.089	0.046	49%
Container carrier	0.100	0.062	37%
RORO	0.183	0.045	76%
Others	0.042	0.027	35%

5. 船型設計への活用

本研究で構築した、Deep Learning を用いた性能要素推定ツールを船型設計に有効に活用するため、汎用 CAD ソフトウェア Rhinoceros への組み込みを行った。実装には Rhinoceros 上で動作するプラグインツールである Grasshopper を利用している。

船型変更に追従して性能要素の推定を行うことで、推定結果をリアルタイムに確認することが可能となり、これにより船型設計の方向性がわかるという利点が得られる。以上により、迅速かつ効率的な船型開発の実現が期待される。





図 8 CAD ソフト Rhinoceros 上での性能要素推定の例
Fig.8 Example of hull performance estimation with CAD software

6. 結 言

本研究では、設計者の専門的知見や経験を取り込んだ船型生成ツールの構築を最終目標として、CNN を用いて造波抵抗係数および形状影響係数の推定を行う手法を提案した。本手法は、水槽試験結果に基づいた既存の簡易推定ツールと比較し、造波抵抗係数・形状影響係数ともに推定精度が優れていることを確認した。この結果から、Deep Learning により性能要素と関連のある船型の特徴を正しく学習することができたとと言える。また、構築した Deep Learning を用いた推定ツールを CAD 上で実行できるようにしたことで、本ツールを船型設計に有効に活用するための基盤を構築できた。

本稿は、横浜国立大学大学院理工学府濱上教授との共同研究の成果⁹⁾¹⁰⁾を基に作成されたものである。

参考文献

- 1) Yao Zhang, WoongJe Sung, Dimitri Mavris : Application of Convolutional Neural Network to Predict Airfoil Lift Coefficient, In Proceedings of AIAA/ASCE/AHS/ASC Structures, Structural Dynamics, and Materials Conference, 2018.
- 2) 赤坂啓, 陳放歌, 寺口剛仁 : 機械学習を用いた自動車空気抵抗係数のインタラクティブ予測ツール開発, 人工知能学会, 第 34 回全国大会, 2020.
- 3) 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, pp.91-100, 1998.
- 4) 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, pp.551-560, 1998.
- 5) 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, pp.1-11, 2000.
- 6) Zhirong Wu, Shuran Song, Aditya Khosla, Fisher Yu, Linguang Zhang, Xiaoou Tang, Jianxiong Xiao : 3D ShapeNets: A Deep Representation for Volumetric Shapes, In Proceedings of CVPR, pp.1912-1920, 2015.
- 7) Hang Su, Subhransu Maji, Evangelos Kalogerakis, Erik Learned-Miller : Multi-view Convolutional Neural Networks for 3D Shape Recognition, In Proceedings of ICCV, 2015.
- 8) Yann LeCun, Léon Bottou, Yoshua Bengio, Patrick Haffner : Gradient-Based Learning

Applied to Document Recognition, In Proceedings of the IEEE, Vol. 86, No.11, pp.2278-2324, 1998.

- 9) 李欣, 新井洋, 濱上知樹 : 船型データの分布を考慮した深層学習による造波抵抗推定, 電気学会論文誌 C, 第 140 巻 3 号, pp.391-397, 2020.
- 10) 登内雅人, 新井洋, 濱上知樹 : 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, 情報科学技術フォーラム講演論文集, 第 18 回, 2019.



天谷 一朗

新井 洋

岡本 直也