

機械学習による船体抵抗推定のための画像データセットの構築

Setup of Image Data Set for Ship Resistance Estimation by using Machine Learning

○ 三上 航平, 横国大理工, 〒240-8501 神奈川県横浜市保土ヶ谷区常盤台 79-5, E-mail: mikami-kohei-hp@ynu.jp

高木 洋平, 横国大, 〒240-8501 神奈川県横浜市保土ヶ谷区常盤台 79-5, E-mail: takagi-yohei-hn@ynu.ac.jp

日野 孝則, 横国大, 〒240-8501 神奈川県横浜市保土ヶ谷区常盤台 79-5, E-mail: hino-takanori-nf@ynu.ac.jp

Kohei MIKAMI, Yokohama National University, 79-5 Tokiwadai, Hodogaya-ku, Yokohama

Youhei TAKAGI, Yokohama National University, 79-5 Tokiwadai, Hodogaya-ku, Yokohama

Takanori HINO, Yokohama National University, 79-5 Tokiwadai, Hodogaya-ku, Yokohama

The estimation of resistance is one of critical issue in the design stage of ship designs. The estimations using conventional method like experiment and CFD, however, require large efforts. Machine learning is expected to become new method which be able to estimate the resistance in short time. In the paper, we built image data set to estimate ship resistances by using machine learning and tested the data set whether it have enough and various information. Consequently, it was confirmed that image groups in the data set have high entropy and information different from each other.

1. はじめに

船舶の計画段階において、抵抗を推定することは船型を決定するために不可欠である。抵抗推定の方法としては、大きく分けて模型を用いた抵抗試験と数值的に Navier-Stokes 方程式を近似して解く Computational Fluid Dynamics (CFD) が挙げられるが、実験には数週間から数ヶ月、CFD を用いても数時間から数日の時間を要する。船型決定の際には多大なケース数を検討しなければならないため、抵抗推定は船型開発のボトルネックとなっている。そこで、より短時間での抵抗推定方法として機械学習を用いた手法が提案されている。

我々の研究グループでは船のオフセットデータを入力データとする、ニューラルネットワークを用いて船の造波抵抗を推定する手法を提案している。この手法によって、未学習船型についても造波抵抗曲線の傾向を再現できることを確認している。この手法では、船の形状を有次元の 1 次元配列として扱っているため、船長や喫水の異なる船型間でデータ長を揃えるための処置等が必要となっている。そのため今後の課題として、より直接的に船型形状を学習できる方法の検討を挙げている。

そこで本研究では船体抵抗を機械学習によって画像から推定することを最終目標とし、今回はその準備として学習器の入力となる画像データセットの構築を行う。

2. 解析手法

2.1 画像の選択

画像群から船体抵抗を推定する問題は非線形回帰であると考えられる。画像入力を用いた非線形回帰の手法としては、畳み込みニューラルネットワーク (CNN) が考えられる。CNN への入力としては、船体を表現する画像が必要であるが 1 枚の画像で捉えることのできる範囲には限りがあり、1 枚で船体のすべてを表現することは難しいと推測される。そこで船体を表現する画像は複数枚必要であると考えられる。

また船体抵抗は船型と船速の関数であると考えられるため、船体抵抗を与える画像群の他に、船速を与える説明変数を加える必要がある。説明変数としては船の垂線間長 (Length between perpendiculars: L_{pp}) と、流体の慣性力と重力の比であるフルード数 (Froude number: F_n)、さらに流体の慣性力と粘性力の比であるレイノルズ数 (Reynolds number: Re) を付加する。これは、船の抵抗成分には大きく分けて造波抵抗と粘性抵抗があり、前者はフルード数、後者はレイノルズ数の関数となるためである。

以上からデータセットは、ある船型について固有の画像群と船長 L_{pp} に、船速によって定まるフルード数 F_n とレイノルズ数 Re が付与され、それらに対応する船体抵抗係数 C_t の値を持つ。そしてその行が、(船型の数 \times 1 船型当たりの船速の数) 行だけ続いた形になると考えられる。



Fig.1 Shape of data set

次に、画像から船体抵抗を推定するための入力データとなる画像群を選択することを考える。画像数は少なすぎれば学習することができないが、多すぎると学習に時間がかかるだけでなく過学習の原因となるため、ある程度画像の枚数を絞る必要がある。そのために入力データとしては、船型の特徴をよく表した画像群かつ、できるだけ少ない枚数であることが望ましい。そこでどのような画像が船の特徴をよく表しているのかを明らかにするために、いくつかの検証を行った。まず船長 L_{pp} で長さを無次元化した空間において半径 0.6, 1.2, 1.8, 2.4 の 4 分球面上に 5 度毎に視点を配置した。この結果、計 2812 個の視点が得られた。さらに左舷船殻のみの船体 3DCAD データを、視点群が構成する球の中心と船体中央が一致するように配置した。




Fig.2 Viewpoints

2.2 可視化における情報量

船舶の抵抗は、摩擦抵抗と粘性圧力抵抗と造波抵抗に大別できる。ここでは船体形状に強く依存する粘性圧力抵抗に注目すれば、抵抗を表す画像としては船体表面の圧力と船型が確認できる船体表面圧力分布の可視化画像が望ましいと考えられる。しかし船体圧力分布を計算するには CFD による解析が必要となり時間がかかる。そこで 3DCAD 形状の画像で代用できないかを探った。まず KRISO Container Ship(KCS)船型を用いて、 $F_n = 0.182, 0.207, 0.233, 0.259$ の 4 船速における、11 段階の色分けを行った船体圧力分布の可視化画像と、3DCAD モデルの画像を先述の視点群から取得した。その結果、次の例に示すような画像が得られた。




Fig.3 Image examples (around midship)

得られた画像の情報エントロピー $H(P)$ を次式(1)によって求めた^[1]。

$$H(P) = -\sum P(A)\log P(A). \quad (1)$$

(1)式において $P(A)$ はある色 A の専有面積の割合を表しており、ある色のピクセル数 A_i を用いて(2)式で定義される。

$$P(A) = A_i / \sum_{(i \in I)} A_i. \quad (2)$$

次に、得られた情報エントロピーについて 4 つの船速における船体圧力分布の画像と 3DCAD のキャプチャ画像がそれぞれ持つ情報エントロピーの相関係数を求めた。その結果を Table1 に示す。

Table1 Correlation coefficients

Fn:	0.182	0.207	0.233	0.259
Coef:	0.971	0.973	0.975	0.961

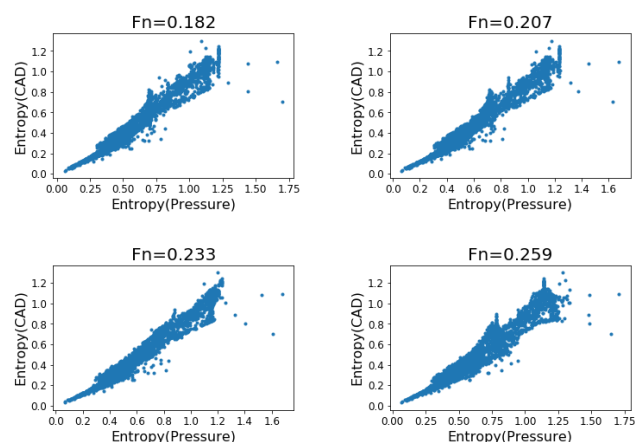


Fig.4 Correlation diagrams

いずれの F_n 数においても高い正の相関が見られる。また Fig.4 から、情報エントロピーの減少率も大きくないことが読み取れる。この結果から 3 DCAD のキャプチャ画像が、船体圧力分布画像と同様に十分な情報を持つと考えられる。

2.3 視点の選択

画像データセットは、出来るだけ少ない枚数で船の特徴を表現するものであることが望ましい。より多くの情報を得られる視点は情報エントロピーの高い視点であるが、情報エントロピーの高い順に画像を選択すると、その中には似た情報を含む画像も多く含まれてしまう。そこで、似た情報を持つ視点を分類するために、視点に対して得られる情報を基にクラスタリングを行った。各視点から得られる画像の持つ情報が似ているかどうかについては、局所特徴量のマッチングをすべての画像の組み合わせについて計算することで判断している。このマッチングでは、2 つの画像の持つ特徴点の重複が多いほど、つまり似ている画像同士ほど小さいスコアが、似ていない画像同士ほど大きいスコアが算出される。この計算において特徴点の検出にはスケールおよび回転不変性を持つ ORB を用いている。クラスタリング手法には非階層型クラスタリング手法である k-means++法を用い、入力データとしては、画像の持つ情報エントロピー、画像同士の局所情報量のマッチングスコア、視点の三次元座標の(2812, 2816)の配列を用いた。クラスタ数を 22 としてクラスタリングを実行すると、全 2812 個の視点が 22 個のクラスタに分類される。さらに、各クラスタ内で情報エントロピーの高い順に 10 番目までの視点を選択した。

ここまでの手順を、Napatanker, だいおう, 龍光丸, KVLCC1, KVLCC2, KVLCC2m の 6 隻の VLCC(Very Large

Crude Carrier)船型について実行した. その結果, 1 船型について 220 視点の, のべ 1320 視点を選ばれた. これを視点毎に選ばれた回数で可視化すると Fig.5 のようになる.

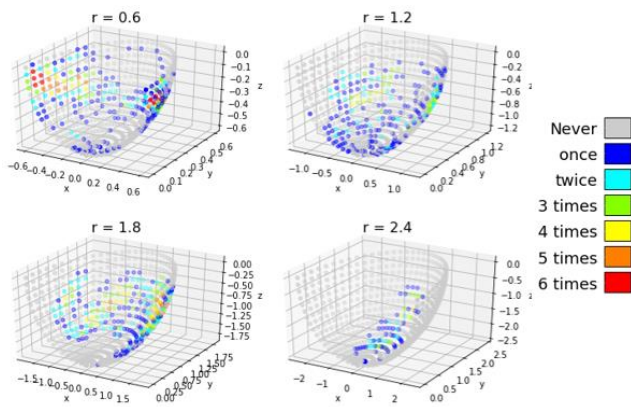


Fig.5 Selected viewpoints

また, この視点群を各船型の局所特徴量のマッチングスコアを視点毎に足し合わせた配列を基にクラスタリングし, Fig.6 に示すように 30 個のクラスタに分類した. 各クラスタには, 似た情報を持つ画像が得られる視点 が分類されていると考えられる.




Fig.6 Clustering result

さらにクラスタ内で, 視点毎に各船型の情報エントロピーを足し合わせた数値が最も大きい視点を抽出し, それをクラスタの代表的な視点とした. 全 30 個の代表視点を可視化すると Fig.7 のようになった.

以上の手順によって, 全 2812 視点から 30 視点を選ばれた. これらを, VLCC 船型を表す代表的な視点とみなし, 画像データセットを構成する視点群とした.

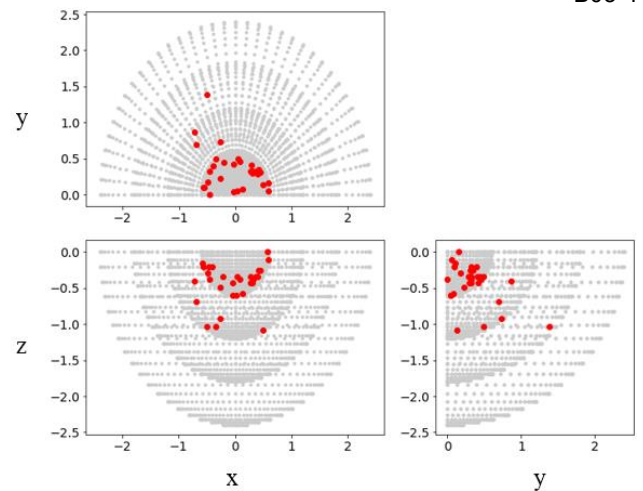


Fig.7 30 representative viewpoints(three views)

3. 選ばれた視点の評価

選ばれた視点群が, 高い情報エントロピーを持ちながら互いに異なる情報を持つかどうかを検証する. まず選ばれた 30 視点から得られる画像の情報エントロピー (H) と局所特徴量のマッチングスコア (S) を求め, その平均値を算出した. この 2 つの値を基に視点群の評価をするために, 式(3)を定義した.

$$V_{score} = H_{ave} S_{ave}. \quad (3)$$

両者の値は, 共に大きい方が高い情報量かつ多様な情報を持つ視点群であると言えることができるため, V_{score} は大きいほど良いと考えられる. さらに先に取得した 2812 視点から無作為に 30 視点を選択し, V_{score} を求める手順を船型毎に 10 回繰り返した. これらを可視化したものが Fig.8 である.

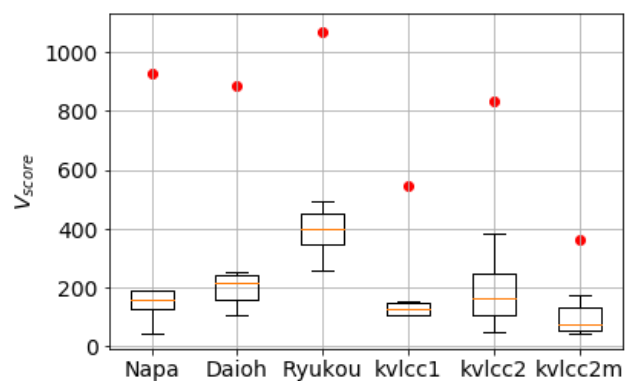


Fig.8 V_{score} for each ships

Fig.8 において, 無作為に選ばれた視点群のスコアを箱ひげ図で, データセットを構成する視点群のスコアを赤い丸でプロットしている. さらに, 視点の選択に用いていない VLCC 船型である 3 船種についても同様に V_{score} を求めた. これを Fig.9 に示す.




Fig.9 V_{score} for new ships

この結果から，選ばれた視点群から得られる画像群は VLCC 船型について高い情報エントロピーを持ち，かつ互いに異なる情報を持っていると考えられる。

4. 結論と今後の展望

機械学習による船体抵抗の推定のための第一段階として，学習器の入力データとなる画像データセットを構築した。構築したデータセットは，1 船型の 1 つの速度につき 30 個の視点から撮影された船体 CAD 画像と垂線間長(Lpp)，フルード数(Fn)，レイノルズ数(Re)を持ち，それに対応するラベルとして船体抵抗(Ct)の値を持つ形状となった。また画像群の持つ情報エントロピー量の平均と局所特徴量のマッチングスコアの平均の積によって視点群の評価値を定義し，今回選んだ視点群と無作為に選ばれた視点群について 9 隻の VLCC 船型で比較したところ，いずれの船型についても今回選んだ視点群の方が高い評価値を持つことが明らかになった。

今後の課題として，今回構築したデータセットを用いた抵抗推定のための学習器の構築が挙げられる。機械学習によって画像から抵抗をより短時間で推定できるようになることで，設計点のスクリーニング等に活用でき，船舶の性能向上に繋がると考えている。

参考文献

- [1] P.P. Vazquez, M. Feixas, M. Sbert, W. Heidrich, "Viewpoint Selection using Viewpoint Entropy", in *Proc. VMV2001*, pp.273-280, 2001.