

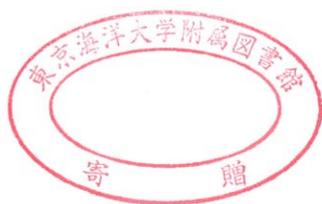
# TUMSAT-OACIS Repository - Tokyo

University of Marine Science and Technology

(東京海洋大学)

ニューラルネットワークを用いた実海域における船舶推進性能の解析に関する基礎研究

メタデータ	言語: jpn 出版者: 公開日: 2021-07-12 キーワード (Ja): キーワード (En): 作成者: 石井, 幹久 メールアドレス: 所属:
URL	<a href="https://oacis.repo.nii.ac.jp/records/2173">https://oacis.repo.nii.ac.jp/records/2173</a>



修士学位論文

ニューラルネットワークを用いた  
実海域における船舶推進性能の  
解析に関する基礎研究

2019 年度

(2020 年 3 月)

東京海洋大学大学院  
海洋科学技術研究科  
海運ロジスティクス専攻

石井幹久



## 目次

第1章 はじめに	1
1.1 研究背景	1
1.1.1 環境問題と海運界	1
1.1.2 船舶のエネルギー効率改善	1
1.2 先行研究	3
1.3 研究目的	4
第2章 解析と推定のための準備	5
2.1 ニューラルネットワークに関して	5
2.1.1 特徴と計算手順	5
2.1.2 誤差逆伝搬による学習	6
2.1.3 過学習の問題と対策	7
2.2 汐路丸に関して	9
2.2.1 主要目とモニタリング項目	9
2.2.2 使用データ項目の選定	10
2.2.3 データクリーニングのための閾値設定	12
2.3 内航貨物船に関して	13
2.4 データの前処理	14
2.4.1 欠損データへの対処	14
2.4.2 データのシャッフルとデータの分割	14
2.4.3 データのスケール変換	15
2.5 アンサンブル学習アルゴリズムの導入	15
第3章 教師なし学習による外れ値除外	17
3.1 外れ値除外の必要性和外れ値検出手法	17
3.2 マハラノビス距離による外れ値検出(汐路丸)	18
3.2.1 計算方法	18
3.2.2 判定に用いる項目	18
3.2.3 外れ値除外結果	20
3.3 次元削減後の再構築誤差を用いた外れ値除外(汐路丸)	23
3.3.1 オートエンコーダに関して	23
3.3.2 再構築誤差計算に用いる項目	23
3.3.3 モデル設計と学習結果	24
3.3.4 外れ値除外結果	26
3.4 次元削減によるデータの可視化(汐路丸)	28

3.4.1	手法	28
3.4.2	特徴平面における正常値と外れ値の分布	29
<b>第4章</b>	<b>教師あり学習による予測</b>	<b>32</b>
4.1	目的変数・説明変数の設定	32
4.2	ニューラルネットワークの表現力	33
4.3	正則化項の導入に関して	34
4.4	バギングアルゴリズム	36
4.5	各推定モデルの予測精度	38
4.5.1	評価指標	38
4.5.2	予測精度の計算結果	39
<b>第5章</b>	<b>推定モデルの評価</b>	<b>42</b>
5.1	推定モデルの解釈	42
5.2	将来データの予測可能性	42
5.3	推定モデルのロバスト性と説明性	43
5.4	感度解析	43
5.4.1	結合荷重法の計算手順	43
5.4.2	汐路丸の解析結果	44
5.4.3	内航貨物船の解析結果	46
5.5	推進性能推定	47
5.5.1	平水中性能	47
5.5.2	経年変化と生物汚損による影響	51
5.5.3	海気象影響	55
<b>第6章</b>	<b>結論</b>	<b>59</b>
	謝辞	60
	参考文献	61
	Appendix.1	64
	Appendix.2	70

# 第1章 序論

## 1.1 研究背景

### 1.1.1 環境問題と海運界

産業革命以降、人間活動による温室効果ガス(GHG)排出量は増加の一途をたどっており、地球の温暖化を招いていることが指摘されている<sup>(1-1)</sup>。最新の研究では、現在のペースでCO<sub>2</sub>が排出され続けた場合、産業革命前と比べて2030年から2050年の間に1.5度、2100年には4度程度まで上昇するシナリオが現実的となっている<sup>(1-2)</sup>。その影響として、海面上昇と地域的な食糧危機の発生、多くの種の絶滅が世界的に予想されている<sup>(1-2)</sup>。日本においても、農林水産業への多大な影響、洪水・高潮被害、水資源の枯渇、熱中症・熱帯性伝染病などが危惧され、現在の自然や文化を維持することは困難と考えられる<sup>(1-3)</sup>。

2015年のCOP21で採択されたパリ協定では、平均気温上昇を産業革命前に比べて2度以下に保ち、今世紀後半に温室効果ガスの排出をゼロにするという目標がたてられた。そこで海運界においても、国際海事機関(IMO)が中心となりGHG削減に向けた取り組みが行われている。2018年の海洋環境保護委員会(Marine Environment Protection Committee : MEPC)において採択された国際海運のGHG削減目標として以下の3つが合意された<sup>(1-4) (1-5)</sup>。

- ① 2030年までに輸送量(トンマイル)当たりのCO<sub>2</sub>排出量を40%以上削減する。
- ② 2050年までに輸送量(トンマイル)当たりのCO<sub>2</sub>排出量を70%以上削減し、CO<sub>2</sub>総排出量も50%以上削減する。
- ③ 今世紀中なるべく早期にCO<sub>2</sub>排出量ゼロを目指す。

GHGの大幅な削減目標に向けて、自然エネルギー(太陽光・風力)の活用や代替燃料(LNG・LPG・メタノール・バイオ燃料・水素)の導入<sup>(1-6)</sup>などが考えられるが、これらの多くは実現まで時間のかかる長期的な対策と言える。一方、船舶のエネルギー効率改善に関しては、単体ではGHG削減目標を達成することは困難であるが、短期～中期的に効果の出る対策であり、燃料消費量を削減できることから運航費のコストダウンも見込めるため、規制側と産業側の思惑が一致する対策でもある<sup>(1-7)</sup>。

### 1.1.2 船舶のエネルギー効率改善

本研究の目的は、実海域における船舶の推進性能を高精度で推定し、エネルギー効率改善に活用することである。エネルギー効率改善にはハード的改善とソフト的改善がある。以下に主な改善方法を列挙する。

#### 1. ハード的改善

- ① 船型の主要目や船速、主機出力の組み合わせから、輸送量あたりのCO<sub>2</sub>排出量を示す、エネルギー効率設計指標(EEDI: Energy Efficient Design Index)の最適解を求め、船型コンセプトを改良する。
- ② 抵抗が少ない推進効率の優れた船型を、貨物や主機の配置を考慮して開発する。
- ③ 効率の優れたプロペラを開発する。
- ④ 電子制御エンジンにより主機効率向上を目指す。

⑤ 主機の排熱を利用して発電を行う。

## 2. ソフト的改善

⑥ 個船や船隊の運航計画を最適化する。

⑦ 喫水及びトリムを最適化する。

⑧ ウェザールーティングを活用して海象によるエネルギーロスを最小化する。

⑨ ジャストインタイム入港を目指し、減速航海を実施する。減速すると、航海時間は速力に比例して増加するが、主機出力は速力の3乗に比例して減少するため、1トンの貨物を1マイル運ぶ際に実際に排出するCO<sub>2</sub>グラム数を示す、エネルギー効率運航指標 (EEOI: Energy Efficiency Operational Index) は速力の2乗に比例して改善される。

⑩ 船体やプロペラの汚損状況を把握して定期的に除去する。

実海域における推進性能を正確に知ることは、ハード的改善とソフト的改善の双方にとって重要なことである。なぜならば、例えば②において、全てのステークホルダーが望むのは、「実海域における抵抗が少ない」ということである。試運転の成績が良いだけでは十分でなく、風波の影響があるときや、貨物を満載まで積んだ時、船齢を重ねた時にも抵抗が少なく、当該船舶の生涯に渡るトータルの燃料消費量を最小にすることが重要である。

また、ソフト的改善においても実海域における推進性能を正確に知ることは重要だ。例えば③のウェザールーティングは、気象海象に合わせて燃料消費量や航海時間を最小にする航路を選択する。その際に、風波がある場合、貨物が半裁の場合、船体汚損による推進性能の劣化が著しい場合においても、回転数-速力-出力の関係を正確に知らなければ的確なルーティングはできない。⑩においても、汚損による推進性能の劣化具合を正確に知ることで、入渠の経済的な最適時期を判断できるだろう。

以上より、実海域における推進性能推定は、船舶のエネルギー効率改善において重要な役割を持つことが分かる。以降、本論文において「実海域性能」とは、特に断りがない限り「船舶の実海域における推進性能」を指すこととする。また、「実海域」を全て一様な環境として議論をするのは無理があるため、実海域を内藤<sup>(1-8)</sup>に従って以下の二種類に大きく分ける。

A: 波浪はあるが比較的穏やかであり、船舶の推進性能が重視され、燃料消費量の少ない船が高く評価される。

B: 稀に遭遇する荒天下であり、推進性能よりも耐航性能がより重視される。転覆しないことは前提として、抵抗増加が小さい、海水打ち込みが少ない、加速度振幅が小さい、プロペラレーシングを起こさない、などの特徴を持つ船が高く評価される。

本研究ではAの状況における実海域性能の推定を行う。

## 1.2 先行研究

実海域性能という言葉が広く使われるようになったのは、平成7年日本造船学会推進性能研究委員会シンポジウム「実海域における船の推進性能」(鈴木敏夫委員長)の時からである<sup>(1-8)</sup>。それ以前は実海域性能に関して十分に議論されていたとは言えず、1マイル間の速力試験のみで推進性能が評価された。実海域での性能に関しては、定時性確保のための余裕馬力を意味する「シーマージン」という概念で漠然と考えられていた。その原因について、内藤<sup>(1-8)</sup>は2003年に以下のように述べている。

『今まで、実海域における船舶性能について十分に目が向けられなかった大きな原因が、「実海域を定量的に捉えられるか?」という疑問を船舶設計者が持ち続けていること、及び実海域性能の評価方法が研究者側から、分かり易く理論的に明確に提示されてこなかったことにあるように思われる。確率統計的に表現されるべき海洋場を航海する船舶性能を考察するのであるから、その性能評価手法も確率的な立場から考えられるのが自然である。』

また、当時は実海域における計測データはアブログデータが主体であり、1日1点のデータしか存在せず、詳細な分析を行うことは難しかった。しかし2002年の西川ら<sup>(1-9)</sup>の研究によれば、アブログデータのみでの利用でも、気象海象や出港後日数、季節変化、就航時からの経年変化を定量的に評価できる可能性が示されている。

そして近年は情報通信の技術向上により、高頻度のデータを取得できるようになったことで、モニタリングデータより実海域性能を詳細に解析するべく研究が盛んに行われている。辻本ら<sup>(1-10)</sup>と櫻田ら<sup>(1-11)</sup>は、物理モデルによる推定値に関してモニタリングデータと比較検討を行い、推定精度を検証している。また、小林ら<sup>(1-11)(1-12)</sup>は内航船の実海域性能推定を行っている。産業界においても、水谷ら<sup>(1-13)</sup>の報告にある自己学習による性能推定システムや、阿南ら<sup>(1-14)</sup>の報告にある機械学習を利用した推定モデルの開発などがある。以上に紹介したケースは一例であり、モニタリングデータを活用した推進性能推定は、国内外問わず広く行われている。

本研究では、モニタリングデータの解析にニューラルネットワークを用いるが、船舶工学へのニューラルネットワークの適用例としては、萩原ら<sup>(1-15)</sup>の航路選定に関する研究や、推進性能推定に関する試みとして、松村ら<sup>(1-16)</sup>、金井ら<sup>(1-17)(1-18)</sup>、石井ら<sup>(1-19)</sup>の研究がある。

### 1.3 研究目的

モニタリングデータから推進性能を推定する際に一般的に取られる手法は、操舵や増減速が行われていない定常運航、且つ、平穏な海気象であるデータを抽出し、それらに適合する対水速力-軸回転数（または翼角）-軸馬力（または主機馬力）の関係を表す近似式を作成することだ。また、物理モデルから得られた推定値に関してモニタリングデータと比較検討を行い、物理モデルに補正が行われることもある。これらの手法により作成される性能推定モデルは、明確な近似式により示されるため、物理的特性と矛盾しない説明性の高いモデルだと言える。しかし一方で、データ抽出における基準の妥当性が不明確なこと、排水量の変動を考慮するためデータの修正等が必要なこと、海気象影響などは別の方法により推定すること、実海域性能の予測精度が高いとは限らないこと、などの課題もある。

そこで本研究は、機械学習を用いて推進性能推定モデルの作成を試みる。機械学習はコンピュータサイエンスの分野から生まれた手法であり、従来の統計的手法が標本データの説明に重点を置いているのに対し、機械学習では未知データの予測に重点が置かれている<sup>(1-20)(1-21)</sup>。従って、船舶の推進性能を学術的に解明する上では統計的手法が有効と言えるが、実海域性能を高精度で予測・推定を行うという実務的な要求に対しては、機械学習による解析が効果的な可能性が高いと考えた。そこで本研究では、機械学習により高い予測精度を持つ推進性能推定モデルを作成できるか試みる。そしてさらに、高い予測精度を持つ推定モデルが、説明力のある推定モデルであるか調査するための解析を行う。

## 第2章 解析と推定のための準備

### 2.1 ニューラルネットワークに関して

#### 2.1.1 特徴と計算方法

ニューラルネットワークは、CNN(Convolutional Neural Network)や RNN(Recurrent Neural Network)など近年様々なモデルが考案されているが、ここでは全結合の階層型ニューラルネットワークに関して述べる。ニューラルネットワークは図 2-1 のような構造の回帰あるいは分類のためのモデルである<sup>(2-1)</sup>。図 2-1 は、入力層、中間層、出力層の 3 層構造であるが、表現力を高めたい場合は中間層を 2 層、3 層と増すこともできる。入力層のユニット数は、入力とする特徴ベクトルの次元数に一致する。中間層のユニット数は任意であり、多いほど表現力が高くなる。回帰に用いる場合の出力層のユニット数は、図 2-1 では 1 つとしているが、2 つ以上とすることも可能である。K クラス分類に用いる場合は、出力層は K 個のノードを持ち、それぞれのノードの出力が、特定のクラスに属する確率を表現する。本研究では、ニューラルネットワークを回帰モデルとして利用するため、以降の説明はニューラルネットワークの回帰モデルに限定して述べる。

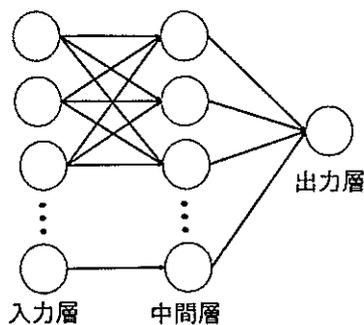


図 2-1 ニューラルネットワークの構造

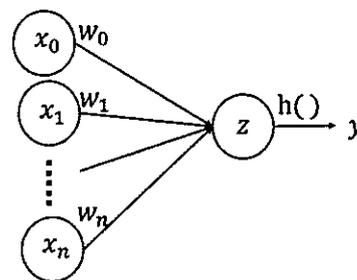


図 2-2 ニューラルネットワークの最小構成単位

入力から出力に至る計算手順 (順伝搬) について、図 2-2 のニューラルネットワークの最小構成単位で説明する<sup>(2-2) (2-3)</sup>。  $x_0, x_1 \dots x_n$  は入力ベクトルであり、  $x_0$  はバイアス項として常に 1 である。  $x_1 \dots x_n$  は任意の入力値である。  $w_0, w_1 \dots w_n$  はニューラルネットワークの持つ、後に述べる学習により得たパラメータであり、「重み」や「結合荷重」と呼ばれる。  $\mathbf{w} = (w_0, w_1 \dots w_n)$ 、  $\mathbf{x} = (x_0, x_1 \dots x_n)$ 、として、(2-1)式より  $z$  を求め、(2-2)式の Sigmoid 関数、または(2-3)式の Hyperbolic Tangent により出力となる  $y$  を求める。(2-2)式や(2-3)式を活性化関数と呼ぶ。ニューラルネットワークが考案された初期は (2-2)式が一般的であったが、中間層の層数が多い深いネットワークを学習する際には「勾配消失」と「勾配爆発」の問題が生じる。そこで深いネットワークでは(2-3)式が使われる。近年の画像分類のタスクに用いる CNN では、正規化線形関数 (ReLU: Rectified Liner Unit) が一般的であるが、本論文の回帰モデルに用いると、ニューラルネットワークの出力が滑らかでなくなるので採用しなかった。本論文においては、特に断りがない限り活性化関数に(2-3)式を使用する。以上の計算をニューラルネットワークの入力層から出力層に向けて順に行うことで、入力に応じた出力を得ることができる。

$$z = \sum_{i=0}^n w_i x_i = \mathbf{w}^T \mathbf{x} \quad (2-1)$$

$$y = h(z) = \frac{1}{1 + e^{-z}} \quad (2-2)$$

$$y = h(z) = \frac{\sinh(z)}{\cosh(z)} = \frac{e^z - e^{-z}}{e^z + e^{-z}} \quad (2-3)$$

### 2.1.2 誤差逆伝搬法による学習

計算機が十分な演算能力を持っていない時代は、人間が手作業によりニューラルネットワークの結合荷重のチューニングを行っていた。しかし現代では、計算機が人の手を介さずに結合荷重のチューニングを自動的に行うことで、大規模なネットワークの訓練が可能となった。

ニューラルネットワークが最適な結合荷重を学習する際に用いる指標の計算は、損失関数により行われる。損失関数には任意の関数を用いることができるが、回帰問題の場合、一般的には二乗平均誤差が用いられる。 $\mathbf{W}$ をニューラルネットワークの全ての結合荷重をまとめたものとする。ニューラルネットワークの出力を $y^{(i)}$ 、真の値を $t^{(i)}$ として、訓練データの総数を $m$ とすれば、二乗平均誤差は(2-4)式で表せる。

$$E(\mathbf{W}) = \frac{1}{m} \sum_{i=1}^m (y^{(i)} - t^{(i)})^2 \quad (2-4)$$

二乗平均誤差の最小化は、誤差の分布に正規分布を仮定した場合の最尤推定と一致する。二乗平均誤差は外れ値に大きな影響を受けるので、データに外れ値が多く含まれている場合や、外れ値の影響をあまり受けたくない場合は、損失関数に(2-5)式の平均絶対誤差を使う。

$$E(\mathbf{W}) = \frac{1}{m} \sum_{i=1}^m |y^{(i)} - t^{(i)}| \quad (2-5)$$

平均絶対誤差の最小化は、誤差の分布にラプラス分布を仮定した場合の最尤推定と一致する。一般に、ラプラス分布は正規分布よりも裾野が広く、多くの外れ値が観測される。本研究では外れ値の存在が想定され、それらに大きな影響を受けるのは好ましくないため、(2-6)式を損失関数として採用した。予測値と真の値の誤差が小さい場合の損失は二乗平均誤差と近いが、予測値と真の値の差が大きい場合は平均絶対誤差と近い特性を持つ。本研究で(2-6)式を採用した詳細な理由を5.1にて述べる。(2-4)式、(2-5)式、(2-6)式の損失関数の差異を図2-3に示す。

$$E(\mathbf{W}) = \frac{1}{m} \sum_{i=1}^m \log(\cosh(y^{(i)} - t^{(i)})) \quad (2-6)$$

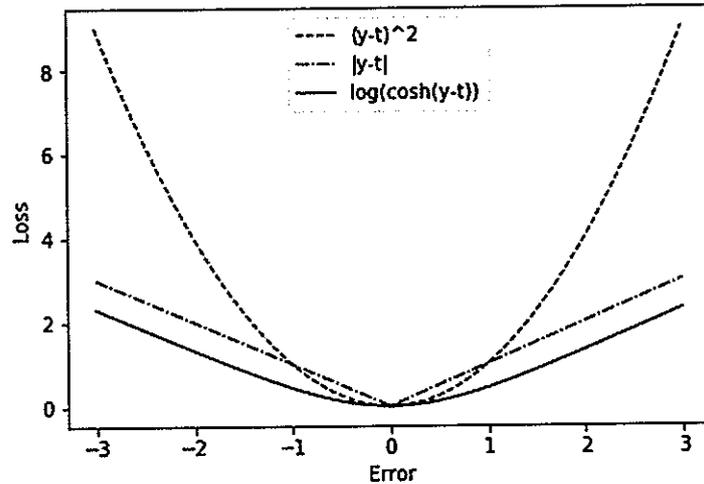


図 2-3 損失関数の比較

誤差逆伝搬法では、任意の結合荷重  $w$  の、損失関数により計算された誤差への寄与を偏微分係数  $\partial E(\mathbf{W})/\partial w$  として計算が可能である。ネットワークの層数を  $N$ 、第  $n$  層の第  $k$  ノードから第  $n+1$  ノードの第  $j$  ノードへの結合重みを  $w_{k,j}^{(n+1)}$ 、学習率を  $\eta$  とするとき、確率的勾配降下法(Stochastic Gradient Descent method : SGD)<sup>(2-2)</sup>による結合荷重の更新は以下のとおりとなる。

$$w_{k,j}^{(n+1)} \leftarrow w_{k,j}^{(n+1)} - \eta \frac{\partial E(\mathbf{W})}{\partial w_{k,j}^{(n+1)}} \quad (2-7)$$

SGD は学習の収束が遅く、大域最小解の周辺で行ったり来たりすることや、局所最小解及び鞍点に陥る問題が発生することもある。そこで本研究では、最適化アルゴリズムに Adam<sup>(2-4)</sup>を採用した。

### 2.1.3 過学習の問題と対策

ニューラルネットワークは非線形な関数を近似可能であり、層数と各層のノード数を増やすことで、高い表現力を与えることができる。しかし、表現力と表裏一体の関係にあるのが過学習の問題である。過学習とは、標本データとはよく適合するが、未知のデータに対する適合が悪い状態を言う。ここで言う適合が良いとは、損失関数により計算される誤差が小さいことである。現実のデータにはノイズが含まれており、訓練データのノイズは学習せずに本質的な傾向のみを学習することを目指す。過学習への対処法として、以下の5つが考えられる。

1. 訓練データを増やす。
2. ネットワークの表現力を削減する。
3. 損失関数に正則化項を導入する。
4. ドロップアウト層を導入する。
5. 正規化層を導入する。

このうち1に関しては、本研究では現実的でない。2は検討に値するので後述する。3は有効

であったので後述する。4のドロップアウト層とは、訓練時に一定の割合のノードを不活性化させる処理であり、分類を目的とした大規模なネットワークでは有効であるが、回帰モデルでは効果が強すぎる事が知られている。本研究においても、実験的に入力層と第一中間層の間にドロップアウト層を加えたが、無効にするノードの割合を1割以下にしなければ推定精度は著しく悪化したので不採用とした。5の正規化層は導入しても大きな効果が見られなかったので採用しなかった。以上より、本研究では次の2つの選択肢から過学習への対処法を選ぶこととなった。

- A. 正則化項は導入せず、ネットワークの表現力を落として対処する。
- B. ネットワークに高い表現力を与えて、正則化項を導入する。

問題を一般化した時にどちらが良いか明確な論拠は存在しないが、機械学習の専門家の間では、経験的にBの方がハイパーパラメータの設定が容易で、良い結果をもたらすことが知られている<sup>(2-5)</sup>。Bの手法を解説すると、学習コストが問題にならない範囲でネットワークの表現力を高くし、次に正則化項を導入して最適な正則化パラメータを探索する。正則化項とは(2-8)式に示す、(2-6)式の損失関数に加えた項であり、ネットワークの全ての結合荷重の二乗和を損失に加算する。但し、ネットワークの層数をNとして、 $s_n$ は第n層のノード数とする。これによりネットワークの結合荷重が過度に大きくなるよう制約をかけており、表現力を削減する。その制約の強さは、ハイパーパラメータである $\lambda$ により設定できる。 $\lambda$ を大きな値にするほど制約は強くなる。

本研究では、一般的に良いとされるBの手法によりニューラルネットワークを設計することにした。第4章にて、ネットワークの表現力と最適な正則化パラメータ $\lambda$ の決定を、探索的調査により行う。

$$E(\mathbf{W}) = \frac{1}{m} \sum_{i=1}^m \log(\cosh(y^{(i)} - t^{(i)})) + \frac{\lambda}{m} \sum_{n=1}^{N-1} \sum_{k=1}^{s_n} \sum_{j=1}^{s_{n+1}} (w_{k,j}^{(n)})^2 \quad (2-8)$$

## 2.2 汐路丸に関して

### 2.2.1 主要目とモニタリング項目

本研究の解析対象船は2隻あり，そのうちの1隻が汐路丸である．汐路丸は東京海洋大学の練習船であり，1987年2月に石川島播磨重工業株式会社により建造された．以下に主要目<sup>(2-6)</sup>を掲載する．

表 2-1 汐路丸の主要目

竣工	昭和 62.2.10	排水量	717.52t	
最大搭載人員	62 名	総トン数	425 トン	
船型	全通船楼甲板型	試運転最大速力	14.61kt	
航行区域	近海	航海速力(85%出力)	14.12kt	
資格	JG 第 4 種船	航続距離	3200nm	
船質	鋼	主 機 関	形式	4 サイクル中速ディーゼル
全長	49.93m		連続最大出力	1400PS (1030kW)
垂線間長	46.00m		連続最大回転数	700rpm
型幅	10.00m	プ ロ ペ ラ	形式	4 翼可変ピッチ
型深	3.80m		直径	2200mm
喫水	(計画満載)3.00m		回転数	300rpm

汐路丸のモニタリングデータは 2010 年 1 月 14 日分から，東京海洋大学の先端ナビゲートシステムに保存されている．航海系と機関係のデータに分かれており，本研究では航海系のデータを使用する．航海系のデータは 1 秒間隔であり，1 時間ごとに 1 つの csv ファイルとして保存される．以下に計測されている航海系データの項目を列挙する．但し，世界標準時や船舶 ID，計測のできていない項目など，一部は省略する．

表 2-2 モニタリングデータの項目

日時 Timestamp (船内)	真風向 (北基準)	Roll 角
船首方位	真風速	Pitch 角
回頭角速度	舵角応答	Yaw 角
緯度	CPP 翼角	Roll 角速度
経度	軸回転数	Pitch 角速度
GPS 高度	軸馬力	Yaw 角速度
GPS 移動速度	主機回転数	前後加速度
GPS 移動方向	前後対水速力	左右加速度

汐路丸の計測データは 1 秒間隔であり，Roll, Pitch, Yaw の角度，角速度まで計測されているた

め、船体運動を詳細に知ることが可能である。しかし、波に関するデータは計測されていないため、波による影響は Roll, Pitch, Yaw の値に含まれていると仮定した。しかし、汐路丸の航行海域のほとんどは東京湾内であり、波の影響を受ける状況は少ないことが推測される。

### 2.2.2 使用データ項目の選定

緯度・経度や GPS 高度など、本研究における推進性能解析に必要な計測項目があるため、それらを除去し必要な項目のみを選定する。計測データの間隔は 1 秒であるが、本研究は周期の短い船体運動を調査対象としないため、1 分間隔のデータに加工したうえで解析を行った。1 分間隔のデータへの加工とは、1 分間の平均値や標準偏差をとることを指す。詳細は表 2-3 に示す。

推進性能に影響を与える要素として、出渠後の経過日数が挙げられる。ドライドックにて船底を掃除した後、海洋生物により船底が汚損されることで、航行時の船体抵抗が増す可能性がある。そこで出渠後日数を使用データ項目に追加した。また、建造から年数が経つことで推進性能が変化する可能性がある。そのため船齢を使用データ項目に追加した。

さらに、推進性能を表す指標として、「見かけのスリップ比」と、「 $(SHP)/(V_s)^3$ 」を使用データ項目に追加した。但し、SHP は軸馬力(kW)、 $V_s$  は対水速力(kt)である。これらは、ニューラルネットワークによる推定において使うことはないが、外れ値除外において使用する。プロペラ直径を  $D$ (m)、翼角を  $\varphi$ (deg)、プロペラピッチを  $P$ (m)、対水速力を  $V_s$ (kt)、プロペラ回転数を  $n$ (rpm) とすれば、見かけのスリップ比  $S_A$  の計算式は以下のとおりである。尚、以降の本論文において、スリップ比とは見かけのスリップ比のことを指すとする。全ての使用データ項目を表 2-3 に示す。項目名に\*が付いた項目は、データ整理や、他の項目の計算に追加したものである。

$$P = D * \pi * \tan(\varphi) \quad (2-9)$$

$$S_A = 1 - \frac{30.867 * V_s}{P * n} \quad (2-10)$$

表 2-3 使用データ項目

項目名	概要	単位	統計処理	その他
DateTime*	計測日時	文字列	なし	
SPOG*	対地速力	knot	平均	
SPTW	対水速力	knot	平均	
Heading*	船首方位	deg	平均	0~360°表記 単位ベクトル合算法使用
HeadingSD	船首方位	deg	標準偏差	変針時大きくなる 単位ベクトル合算法使用
REV	軸回転数	rpm	平均	
CPP	翼角	deg	平均	
RudderSD	舵角	deg	標準偏差	変針時大きくなる
SHP	軸馬力	kW	平均	
Rolling	ローリング	deg	標準偏差	
Pitching	ピッチング	deg	標準偏差	
WindSpeed	真風速	m/s	平均	
WindDirection	真風向	deg	平均	船首方位を 0°として、 -180~180°で表記
Variation	対水速力変化量	knot	なし	1 分前との差分 増減速を表現する
Tide*	前後方向潮流	knot	平均	SPOG と SPTW から計算
TotalYear	船齢	年	平均	
AfterDock	出渠後経過日数	日	平均	
Slip	スリップ比	なし	なし	
Performance	$(SHP)/(SPTW)^3$	なし	なし	

### 2.2.3 データクリーニングのための閾値設定

モニタリングデータには物理的に取り得ないエラー値が含まれており、また、解析の際には停船時のデータも必要ない。そのため下限値と上限値を設定して、その範囲外にあるデータを除外する。そこで、汐路丸の使用データ統計処理後の上限値、下限値を表 2-4 のように設定した。ここでのデータクリーニングは、物理的に矛盾のある外れ値を除外することが目的なので、下限値と上限値の設定は、正常値を除外してしまわないように余裕を持たせた。また、データ間の関係により異常と判断されるデータの除外処理は、第 3 章で扱う。

表 2-4 使用データ統計処理後の各項目の上限値と下限値

項目名	下限値	上限値	単位
SPOG	1	17.5	knot
SPTW	1	16	knot
Heading	0	360	deg
HeadingSD	0	30	deg
REV	1	330	rpm
CPP	-1	20	deg
RudderSD	0	5	deg
SHP	1	1100	kW
Rolling	0	10	deg
Pitching	0	10	deg
WindSpeed	0	30	m/s
WindDirection	0	180	deg
Variation	-1	1	knot
Tide	-6	6	knot

### 2.3 内航貨物船に関して

汐路丸とは別に、1隻の内航貨物船も解析対象とした。当該船を、以降はA丸と呼ぶ。A丸の船上計測データは、携帯電話回線を通じて船載機から陸上サーバへ、航海・機関に関するデータの10分平均値が送信される。解析対象期間は2018年4月4日から2020年1月9日である。A丸は1軸の固定ピッチプロペラ(FPP)装備船である。表2-5にA丸の使用データ項目と、設定した上限値及び下限値を示す。

表 2-5 A丸の使用データ項目

項目名	概要	単位	下限値	上限値	その他
SPOG	対地速力	knot	1	17	
SPTW	対水速力	knot	1	16	
REV	軸回転数	rpm	1	140	
SHP	軸馬力	kW	1	3600	
Displacement	排水量	t	なし	なし	喫水から計算
Trim	トリム	m	なし	なし	喫水から計算
WindSpeed	真風速	m/s	0	50	
WindDirection	真風向	deg	-180	180	船首方位を0°として、 -180~180°で表記
WaveHeight	波高	m	0	0	
WaveDirection	波向き	deg	-180	180	船首方位を0°として、 -180~180°で表記
Variation	対水速力変化量	knot	なし	なし	1分前との差分
Tide	海潮流	knot	なし	なし	
AfterDock	出渠後日数	days	なし	なし	
Slip	スリップ比	なし	なし	なし	
Performance	$(SHP)/(SPTW)^3$	なし	なし	なし	

## 2.4 データの前処理

### 2.4.1 欠損データへの対処

計測値に欠損がある場合、そのままでは回帰モデルの学習に利用できないため、何らかの対処を検討する必要がある。しかし、この問題を扱う上での最初の論点は、欠損の仕方と計測値は互いに独立であるか、という点にある。もしも欠損の仕方が計測値に影響を受けているのならば、計測されたデータは真の母集団から外れたものとなる。計測値がランダムに欠損していると仮定すると、対処方法は複数考えられる。

1. 欠損値を1つでも含む計測値は除去する。
2. モデルの訓練時に、学習アルゴリズムにより欠損値を扱う。
3. 学習前に、欠損値を全て補完して埋めてしまう。

本研究で取り扱うモニタリングデータにおける欠損の多くは、停船中に発生していることを確認した。これは、停船中は計測を止めているということである。よって、欠損の仕方は厳密には計測値と独立でないが、そもそも停船中のデータは、解析の対象外であるため問題ないと判断した。航行中においても少なからずデータの欠損は発生しているが、それはデータ全体からすると極めて少数であるため、欠損の仕方により訓練データが真の母集団から大きく外れることはないと仮定し、欠損値を含むデータに関しては削除した。

### 2.4.2 データの並び替えとデータ分割

第4章において、軸馬力の推定と対水速力の推定をニューラルネットワークにより行うが、その際に、データ全体を乱数により並び替えた後、3つに分割している。それは、訓練データ(8割)、評価データ(1割)、テストデータ(1割)である。ニューラルネットワークの訓練に直接利用するデータは訓練データのみであり、残りのデータは訓練の進捗確認や、推定精度のテストに利用する。このようにデータを分割する理由は、過学習の防止、つまりモデルが訓練データへ過度に適合し、真の母集団から乖離することを防ぐためである。

評価データは結合荷重更新に直接使わないが、損失は計算する。これにより、評価データの損失が訓練データの損失よりも高ければ、過学習の発生を示している。従って、訓練データと評価データを用いてニューラルネットワークをチューニングすることで、最適なハイパーパラメータを探索的に求めることが可能だ。

テストデータは、訓練データと評価データを用いたチューニングと訓練を終えたニューラルネットワークの、最終的な性能評価に利用する。ハイパーパラメータ決定に関与した評価データを最終的な性能評価に利用せず、ニューラルネットワークにとって完全に未知であるテストデータを用いることで、信頼性の高い予測精度を得ることができる。

データ分割を行う前にデータの並び替えを行うことは重要である。なぜならば、モニタリングデータは時系列データであり、日によって外乱の状況や喫水、船底汚損の状況が大きく異なる。並び替えずに、古いデータから順に、訓練、評価、テストと分割をすれば、船底汚損や船齢を重ねることによる推進性能の変化が、それぞれのデータで大きく異なりテストデータ予測は外挿域となってしまう。ウェザールーティングなどの実務で活用する場合、予測する状況は未来である

から外挿推定となるが、その際は収集したデータから逐次パラメータを更新する、オンライン学習を導入することで性能変化を逐次学習できるため、外挿推定であっても推定精度の大きな悪化を防ぐことができると考えられる。

### 2.4.3 データのスケール変換

ニューラルネットワークの学習を行う際、訓練データの項目ごとに値のスケールが大きく異なると、パラメータごとに学習時の更新幅が大きく異なり、学習の収束が遅くなる。そのため、データの項目ごとにスケール変換をする必要がある。スケール変換には正規化と標準化がある。正規化はそれぞれの項目で、全てのデータが0から1の範囲に収まるようにする処理であり、標準化はそれぞれの項目の平均が0、標準偏差は1となるようにする処理である。正規化は画像分野で多く採用される手法であるが、外れ値に大きな影響を受けるため、本研究では標準化を採用した。i番目のサンプルデータのj番目の要素を $x_j^{(i)}$ として、(2-10)式により標準化を行う。但し、 $\bar{x}_j$ はj番目の項目の平均値、 $s_j$ はj番目の項目の標準偏差である

$$x_j^{(i)} \rightarrow \frac{x_j^{(i)} - \bar{x}_j}{s_j} \quad (2-11)$$

## 2.5 アンサンブル学習アルゴリズムの導入

アンサンブル学習とは一般に、複数の機械学習モデルを組み合わせることで、結果として優れたモデルを作成する手法のことである。有名なものとしては、決定木アルゴリズムの葉の部分に他のモデルを使用するものや、複数の決定木アルゴリズムにより構成されるランダムフォレストが挙げられる。本研究では複数のニューラルネットワークを訓練することで、バギングアルゴリズムを導入する。バギングアルゴリズム<sup>(2-7)</sup>とは、複数の機械学習モデルの出力を平均して最終的な出力とすることで、確率的に汎化誤差を減少させる手法である。ここで、E を平均を表す記号として、 $\delta$ を複数のモデルの残差を求める関数とすれば、(2-12)式が成り立つ。

$$E_{\delta^2(x)} \geq [E_{\delta(x)}]^2 \quad (2-12)$$

(2-12)に示した不等式は、複数のモデルの実行結果の平均を取るとその2乗平均誤差は、複数の異なる機械学習モデルの実行結果の二乗平均誤差の平均より、下回るか、同程度であることを示している。また、データ全体を訓練・評価・テストの3つに分ける際に、モデルごとに訓練データと評価データの分け方をランダムにすることで、汎化性能向上を目指す。この際、テストデータが訓練データ、評価データに選ばれないよう、十分注意する必要がある。訓練データを機械学習モデルごとにランダムに選ぶ手法を、統計の分野ではブートストラップ法と呼び、訓練データの重複を認めているため、元のデータセットサイズよりも訓練データ数の方が多くなることもある。しかし本研究では重複は認めずに、データ全体からテストデータを除いた残り9割のデータ

から、訓練データ数と評価データ数の比が8:1となるようランダム選択をニューラルネットワークごとに行う。

ところで、ニューラルネットワークの結合荷重の初期値は乱数を用いて与えられる。そのため、同じデータと同じ条件でニューラルネットワークの訓練を行っても、異なる結合荷重を持ち、同じ入力に対しても多少異なる出力を取る。そこで複数のニューラルネットワークを訓練しバギングアルゴリズムを導入することで、出力値のばらつきが抑えられ、汎化性能の高いモデルとなるうえに再現性のある検証が行える。以上2つの理由によりバギングアルゴリズムを導入した。

## 第3章 教師なし学習による外れ値除外

### 3.1 外れ値除外の必要性と外れ値検出手法

第2章において、モニタリングデータの各項目に下限値と上限値を設定することで、外れ値を除外した。しかしそれだけでは十分でなく、項目間の相関関係まで考慮した外れ値除外処理を行う。当然ながら、対水速力と軸回転数、翼角、軸馬力などの間には強い相関があり、例えば、軸馬力が通常運航におけるレンジにも関わらず、対水速力が通常よりも明らかに低い、例えば 3kt 程度というのは異常と言える。この場合、計測機器の故障か、通信などの過程で発生したデータの破損を疑うべきだろう。あるいは特殊な気象海象状況や、特殊な運航状態だった可能性もある。汐路丸の場合は練習船であるので、操縦性能調査のためにジグザグ試験を行っていた可能性や、錨を引っ張ることで錨の把駐力を計測していた可能性もある。本研究は、船舶の実海域性能を明らかにすることが目標であるが、それは統計的な観点から頻度の高い状況、つまり定常運航状態を研究対象とする。船舶が一生涯のうち一度遭遇するような、意識的減速を行うほどの荒天や、港内操船において動静が急激に変化するような状況は研究の対象外である。そのようなデータは外れ値として使用するデータから除外を行う。

外れ値とは一般に、観測された値の中で、推定される真の値からの残差が異常に大きい観測値のことである。正規分布のデータであれば、残差が標準偏差の2倍から3倍以上あるデータや、残差が最も大きい1%のデータを外れ値と判定することが一般に多い。しかしこれは、正規分布となる一定値に張り付くようなデータに有効であり、船舶の速力や軸馬力のように、互いに影響を及ぼし合いながら常時変動する物理量には適用できない。そこで、軸回転数、翼角、対水速力、軸馬力を利用して正規分布となる性能指標を計算し、3.2で述べるマハラノビス距離が大きいデータを外れ値と判定する。この手法を3.2で試みるが、作成する性能指標が船舶工学の側面から適切なもので、且つ、正規分布でなければならないので、常に有効な手法とは言えない。

そこで、性能指標等を作成せずに外れ値検出を行う手法も試みる。定義より外れ値とは、推定される真の値からの残差が異常に大きいデータである。真の値を知ることは不可能だが、データ全体から真の値を確率的に推定することは教師なし学習により可能である。具体的には、次元削減後の再構築誤差を利用するものである。入力ベクトルを次元削減すると、正常データは特徴ベクトル空間の高密度の領域に転写されるのに対し、外れ値は低密度の領域に転写される。そして、低密度の領域に転写されたデータの再構築誤差が大きくなる性質を利用するもので、3.3にて詳細に解説する。次元削減には多くの手法があり、オートエンコーダ、線形PCA、カーネルPCAなどが一般的な手法である。本研究では、後に回帰モデルとしてニューラルネットワークを利用することや、計算コストによる理由、先行研究<sup>(3-1)</sup>などから、次元削減にオートエンコーダを採用することに決めた。はじめに、3.2にてマハラノビス距離による外れ値除外に関して述べて、次に3.3にて再構築誤差を用いた外れ値除外に関して述べる。

### 3.2 マハラノビス距離による外れ値検出(汐路丸)

#### 3.2.1 計算方法

異常度の計算方法<sup>(3-2)</sup>を簡潔に述べる。M次元のN個の観測値からなるデータ $\mathcal{D} = \{x^{(1)}, x^{(2)}, \dots, x^{(N)}\}$ を考える。このデータは、外れ値を全く含んでいないか、含んでいたとしても極僅かであるという前提のもと、各標本が独立に(3-1)式の確率密度関数に従うと仮定する。

$$\mathcal{N}(x|\mu, \Sigma) \equiv \frac{|\Sigma|^{-1/2}}{(2\pi)^{M/2}} \exp\left\{-\frac{1}{2}(x-\mu)^\top \Sigma^{-1}(x-\mu)\right\} \quad (3-1)$$

(3-1)式の確率密度関数を正規分布と呼び、平均 $\mu$ と共分散行列 $\Sigma$ の2つのパラメータを含む。これらのパラメータを最尤推定により求める。最尤解 $\mu = \hat{\mu}$ は(3-2)式の相加平均で求まる。最尤解 $\Sigma = \hat{\Sigma}$ は(3-3)式で求まる。

$$\hat{\mu} = \frac{1}{N} \sum_{n=1}^N x^{(n)} \quad (3-2)$$

$$\hat{\Sigma} \equiv \frac{1}{N} \sum_{n=1}^N (x^{(n)} - \hat{\mu})(x^{(n)} - \hat{\mu})^\top \quad (3-3)$$

最尤推定量を代入することにより、データ $\mathcal{D}$ を表現する確率密度関数が、(3-4)式のように得られたとする。

$$p(x|\mathcal{D}) = \mathcal{N}(x|\hat{\mu}, \hat{\Sigma}) \quad (3-4)$$

多変量正規分布の定義式(3-1)を使い、観測値に関係ない定数を見捨てる、マハラノビス距離は(3-5)式で定義される。これは、観測データ $x'$ がどれだけ標本平均 $\hat{\mu}$ から離れているかを表すもので、マハラノビス距離が大きいほど標本平均 $\hat{\mu}$ から離れており異常度が高い。

$$a(x') = (x' - \hat{\mu})^\top \hat{\Sigma}^{-1}(x' - \hat{\mu}) \quad (3-5)$$

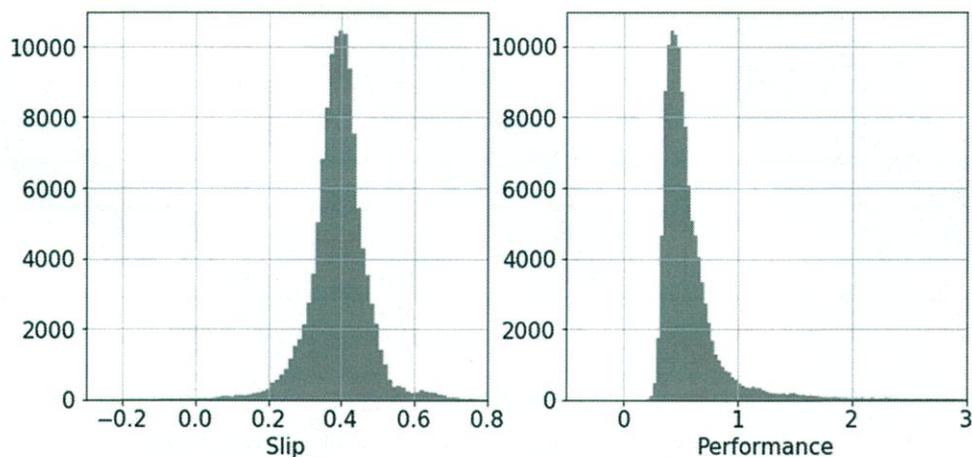
#### 3.2.2 判定に用いる項目

(3-5)式を用いて各標本の異常度を計算し、異常度の高い方から1%を外れ値として、訓練データから除外した。異常度の計算を行う際に用いる変数は正規分布であることが前提であるので、軸馬力や軸回転数、翼角、速力といった値はそのまま利用することはできない。また、それらの値自体は重要でなく、変数間の関係こそ重要である。よって、第2章にて説明した使用データ項目のうちの、「Slip」と「Performance」をマハラノビス距離による外れ値除外に用いることとした。

「Slip」とは見かけのスリップ比であり、「Performance」は、軸馬力をSHP、対水速力をSPTWとして、 $(SHP)/(SPTW)^3$ で定義される軸馬力の性能指標である。従って、見かけのスリップ比と軸馬力の性能指標が、定常運航における値のレンジより大きく外れた場合に異常と判定される。以下に外れ値除外の過程と結果を載せるが、ここでは主に汐路丸に関して述べる。A丸への適用結

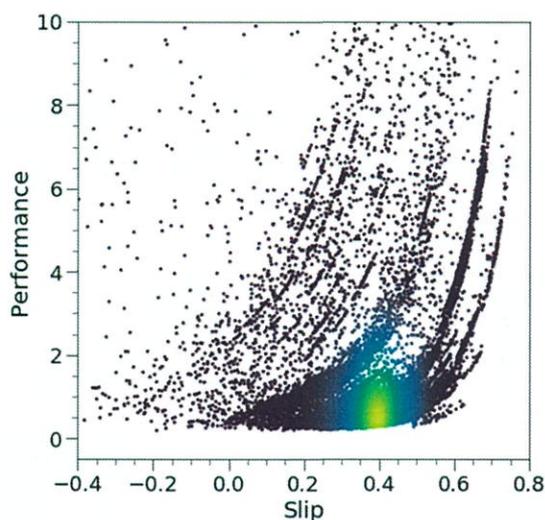
果は Appendix.1 に詳細に記載した。

図 3-1(a), (b)は、汐路丸の「Slip」と「Performance」のヒストグラムである。図 3-1(c)は「Slip」と「Performance」の散布図であるが、データ数が多くデータ点同士が重なるので、カーネル密度推定によりデータ密度を色で表現している。藍色の領域はデータ密度が最も低く、緑色の領域は中程度、黄色の領域は最も高い。カーネル密度の計算には Python の scipy パッケージを利用した。



(a) 「Slip」のヒストグラム

(b) 「Performance」のヒストグラム



(c) 「Slip」と「Performance」の散布図

図 3-1 汐路丸の「Slip」と「Performance」のヒストグラム及び散布図

「Slip」は、約 0.4 を最頻値として、ほぼ左右対称に裾野が広がる正規分布となった。しかし「Performance」は、最頻値の右側、つまり最頻値よりも大きい値が多く、裾野も長い。この原因について次に述べる仮説を立てた。一般に、船舶の出力は速力の 3 乗に比例するが、低速域では成り立たないことがある。図 3-2 は汐路丸の対水速力、翼角、軸馬力の関係を散布図で表した図であるが、図 3-2(a)より最低出力が約 150kW を下回ることはほとんどない。これは、CPP 船は翼角 0°、対水速力が 0kt の場合であっても、プロペラは回り続けているため抵抗が発生するためである。よってこのことから、「Performance」の値が最頻値よりも大きいデータというのは、速力に

対して軸馬力が大きいということであるから、低速域におけるデータであると考えられる。尚、「Performance」の分布が正規分布から外れる傾向は、A丸のデータでも確認した。汐路丸と同様に低速域における軸回転数及び軸馬力の分散が大きいことが原因として考えられる。

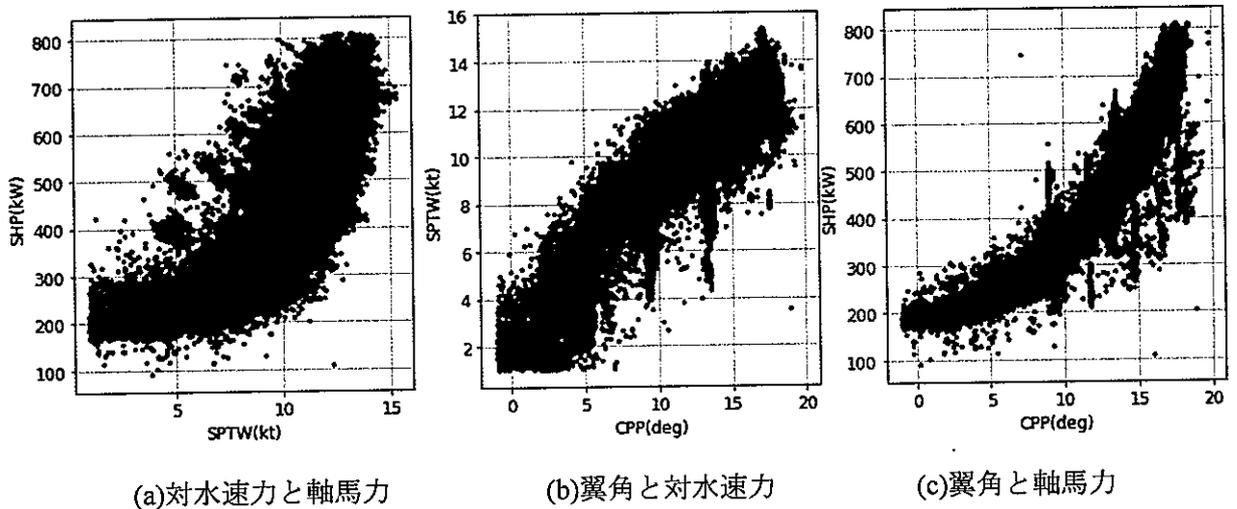


図 3-2 汐路丸の対水速力，翼角，軸馬力の散布図

### 3.2.3 外れ値除外結果

「Performance」の指標が両船とも正規分布から外れており、マハラノビス距離による外れ値除外を行うのは不適切である、しかしこれが正規分布であると仮定した上で、外れ値除外が可能であるか実験的に調査した。(3-5)式により各標本の異常度を計算し、図 3-3 に汐路丸の異常度のヒストグラムを示す。

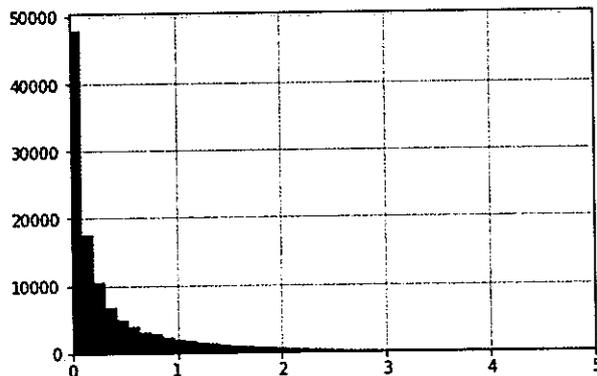
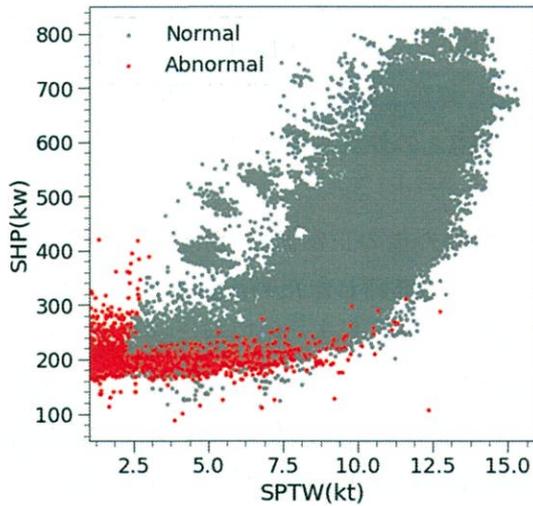


図 3-3 汐路丸の異常度のヒストグラム

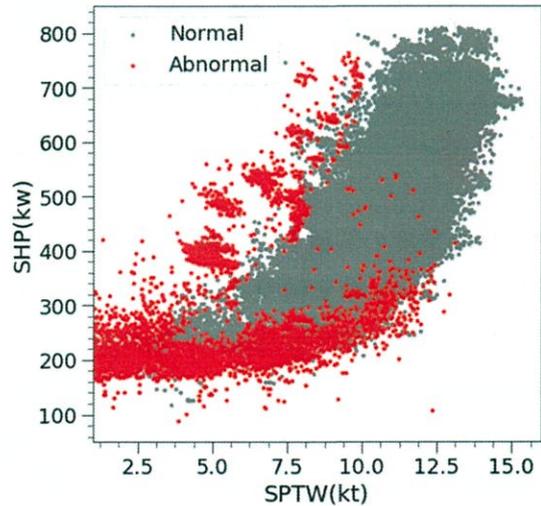
異常度の頻度分布はカイ 2 乗分布となった。全ての標本のうち、異常度の高い方から 1%を外れ値と仮定した場合と、異常度の高い方から 5%を外れ値と仮定した場合の、外れ値と正常値の閾値を探索的に調べた結果、それぞれ 16.466 と 3.329 となった。よって、異常度の閾値が 16.466 と 3.329 の場合について、閾値を下回れば正常値、上回れば外れ値と振り分けた。正常値と外れ値の分布の違いを、対水速力，翼角，軸馬力の散布図を用いて図 3-4 に示す。正常値を灰色点，外れ値

を赤点で示し、左列は異常度の閾値が 16.466 の場合、右列は異常度の閾値が 3.329 の場合である。

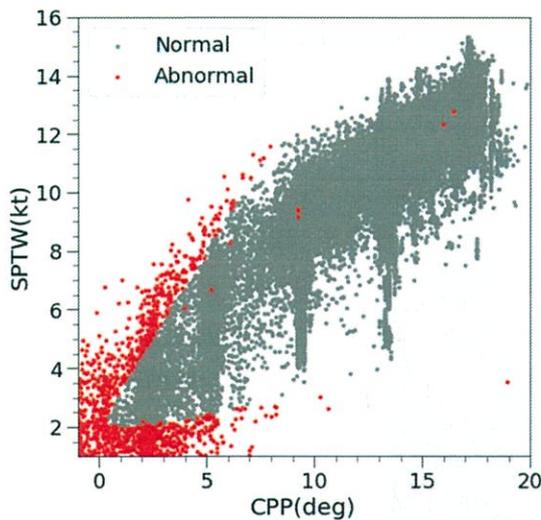
異常度が最も高い1%のデータは、翼角が小さいか、低速である場合がほとんどである。これは前に述べた通り、翼角が小さく低速であっても、CPP船である汐路丸は軸馬力が約150kWを下回ることはない。よって「Performance」の値が異常に大きくなってしまふと考えられる。外れ値の割合を1%にすると、単に翼角が小さく低速であるデータが異常と判定されてしまふ実用的ではない。外れ値の割合を5%とすると、図3-4(b)(d)のとおり、外れ値が正常値を囲むように分布しているが、低速域のデータがさらに多く除外されてしまふ、低速域のデータがなくなるので適切でない。



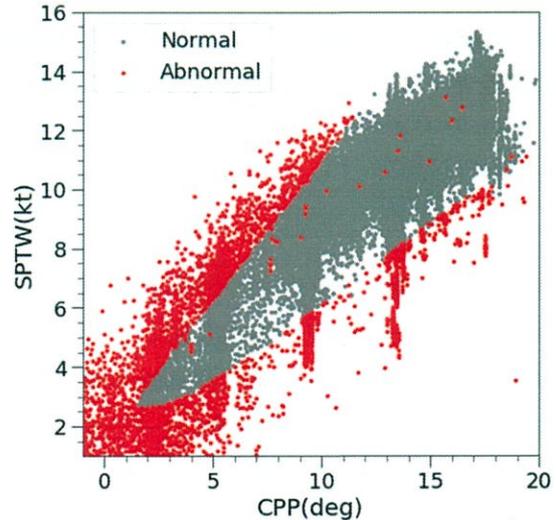
(a) 対水速力と軸馬力-外れ値 1%



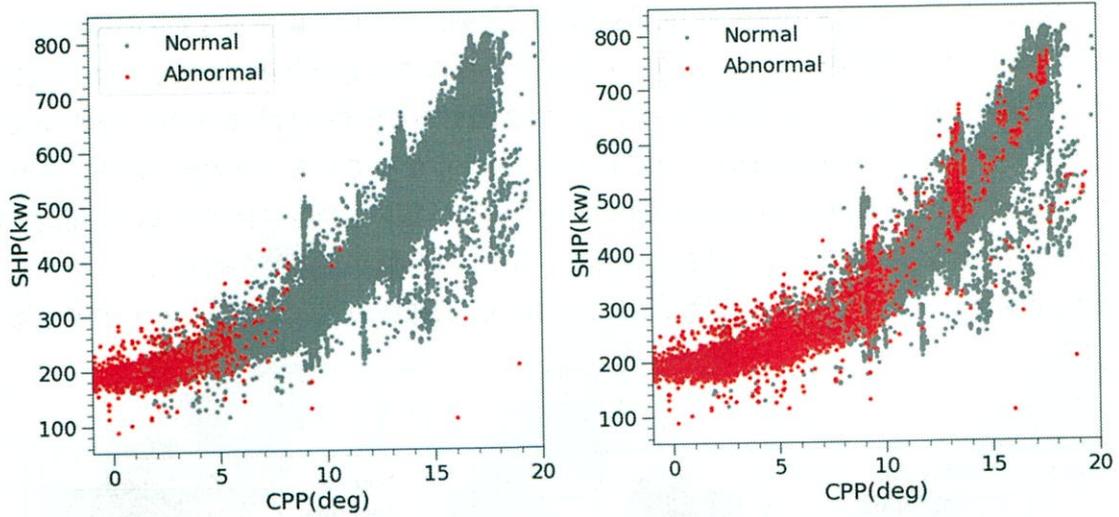
(b) 対水速力と軸馬力-外れ値 5%



(c) 翼角と対水速力-外れ値 1%



(d) 翼角と対水速力-外れ値 5%



(e) 翼角と軸馬力-外れ値 1%      (f) 翼角と軸馬力-外れ値 5%

図 3-4 マハラノビス距離による汐路丸の外れ値除外結果

図 3-5 は異常度の閾値を 16.466 とした場合の、外れ値除外後の正常値の「Slip」と「Performance」の散布図である。x 軸 y 軸のどちらも図 3-1 と同じレンジで描画したため、図 3-1 との比較が可能である。「Slip」の分散が小さく、「Performance」の分散が大きいいため、楕円型に切り取られていることが分かる。また、「Performance」は正規分布でないことから、外れ値は最頻値よりも大きい場合にしか存在せず、マハラノビス距離による外れ値除外は有効と言えない。A 丸への適用結果も決して良くはないが、汐路丸よりは良好であり、CPP 船への適用が特に難しい可能性がある。マハラノビス距離による外れ値除外を行う場合、軸馬力と速力、軸回転数、翼角の関係を示す指標が正規分布となるように工夫する必要があるだろう。

以上の結果より、本研究ではマハラノビス距離による外れ値検出を行わずに、3.3 にて述べる再構築誤差を用いた外れ値検出を利用することにした。

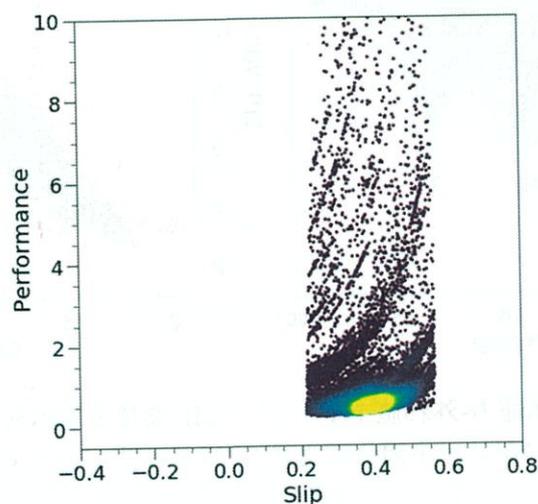


図 3-5 外れ値除外後の汐路丸の「Slip」と「Performance」の散布図

### 3.3 次元削減後の再構築誤差を用いた外れ値除外(汐路丸)

#### 3.3.1 オートエンコーダに関して

第2章で述べたニューラルネットワークの回帰モデルは、教師データの学習を前提としたものであった。本章では、入力データを次元削減した後、入力データを復元する教師なし学習の応用に関して述べる。ニューラルネットワークによる教師なし学習は、オートエンコーダ（自己符号化器）<sup>(3-3)</sup>により行われる。それは、以下の図のような砂時計型ネットワークの構造をしている。

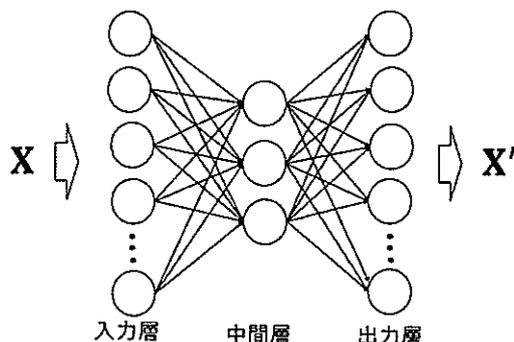


図 3-6 オートエンコーダ

入力層と出力層は同じノード数であり、出力層では入力ベクトル $X$ の復元を試みる。中間層の層数は任意であり、中間層のノード数は、入力層及び出力層よりも少ない。よって、入力ベクトル $X$ が一旦、中間層にて低次元の特徴ベクトルに変換されることになる。この次元削減が行われる部分をエンコーダと言う。中間層から出力層に向けては、低次元の特徴ベクトルから入力ベクトルの復元を行い、 $X'$ が出力される。この部分をデコーダと言う。入力ベクトル $X$ と出力ベクトル $X'$ の差を再構築誤差と言う。一般に、中間層のノード数が少ないほど再構築誤差は大きくなる。本研究では以下の2つの目的でオートエンコーダを利用する。

1. 再構築誤差を用いた外れ値除外
2. 次元削減によるデータの可視化

#### 3.3.2 再構築誤差計算に用いる項目

オートエンコーダを用いて再構築誤差を計算する際には、適切な入力項目を選定しなければならない。軸馬力、軸回転数、翼角、対水速力といった項目は推進性能を直接的に表す重要なデータである。それに対して風・波に関する項目や船首方位の振れ角度などは、推進性能に影響を及ぼすものの、推進性能を直接的に表す4項目ほど重要なデータではない。オートエンコーダを用いて再構築誤差を計算する際に、各項目の重要度を無視して全ての項目を一律に扱い計算を行うと、期待したとおりの外れ値除外ができない可能性がある。その理由を以下で述べる。

再構築誤差は、真の値と復元値の2乗誤差で定義する。そうすると、異常度は各項目の2乗誤差の総和として(3-1)式で定義できる。但し、 $D$ 次元の入力ベクトルとして、 $x_j^{(i)}$ は、 $i$ 番目のサンプル、 $j$ 番目の要素のデータとする。 $x_j^{(i)}$ は、 $i$ 番目のサンプル、 $j$ 番目の要素の復元値とする。

$$\text{Err}^{(i)} = \sum_{j=1}^D (x_j^{(i)} - x'_j{}^{(i)})^2 \quad (3-1)$$

なお、 $x_j^{(i)}$ は標準化されているため、平均0、標準偏差1であり、復元された $x'_j{}^{(i)}$ も平均0、標準偏差1に近い分布である。よって、各項目のスケールは揃っており、スケールの違いによる異常度への影響はない。

(3-1)式より異常度の計算において、各項目の再構築誤差が一律に扱われていることが分かる。各項目の重要度が同じ程度であれば問題はないが、本研究の場合、推進性能を直接的に表す4項目は特に重要であるため、これでは不適切であると考えられる。そこで、各項目が推進性能に影響を及ぼす程度を知るためにランダムフォレストを用いた。具体的には、ランダムフォレストを回帰モデルとして軸馬力と対水速力の推定を行った、その結果、汐路丸の場合は、軸馬力と対水速力推定における重要度の高い項目として、翼角、船齢、出渠後日数の3項目が挙げられた。A丸の場合は、軸回転数と排水量が重要な項目として挙げられた。従って、再構築誤差計算に用いる項目は、汐路丸は「軸馬力、対水速力、翼角、船齢、出渠後日数」の5項目として、A丸は、「軸馬力、対水速力、軸回転数、排水量」の4項目とした。

### 3.3.3 モデル設計と学習結果

汐路丸の再構築誤差計算に用いるオートエンコーダの構造は以下の表のとおりである。正則化パラメータは、0.001とした。5次元ベクトルが、第2中間層にて3次元ベクトルに圧縮されることになる。尚、A丸に関しては Appendix.1.2 で述べる。

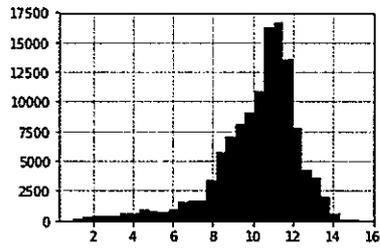
表 3-1 汐路丸の再構築誤差計算に用いるネットワーク

	入力層	第1中間層	第2中間層	第3中間層	出力層
ノード数	5	4	3	4	5

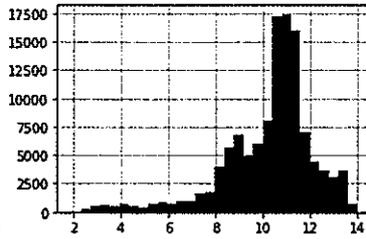
オートエンコーダの学習においては、バッチサイズ256、エポック数80、訓練データ数96266、評価データ数24067とした。学習は、過学習が発生していないか、訓練データと評価データの損失を確認しながら行った。過学習せずに学習が収束したことを確認した後、オートエンコーダにより復元した値の分布の比較、並びに再構築誤差を確認した。図3-7にヒストグラムを示す。3列に並んでおり、左から、真の値の分布、オートエンコーダにより復元した値の分布、再構築誤差の分布を示している。5項目のいずれも、真の値の分布をおおよそ再現できていることが読み取れる。また、再構築誤差の分布は全ての項目で正規分布となった。

図3-7(d)、(g)より、汐路丸の出力は大きく分けると3段階であることが分かる。しかし図3-7(a)より、対水速力の分布は1つの山となっている。平水中において対水速力は翼角に比例するが、外力等により、翼角と対水速力の分布に差が出ると考えられる。これに対して、図3-7(b)より、対水速力の復元値は3つの山に分かれている。これは、オートエンコーダが翼角と対水速力の比例関係を学習したものの、外力が入力項目に存在しないため、対水速力の復元値の分布が比例関係

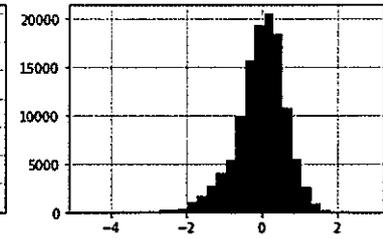
にある翼角の分布に影響を受けた可能性がある。



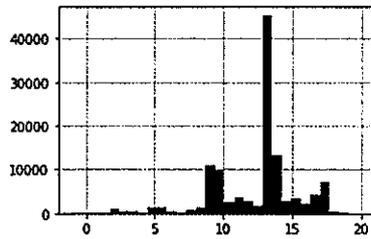
(a) 対水速度真の値



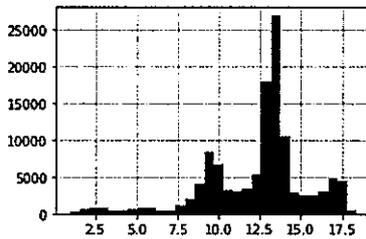
(b) 対水速度復元値



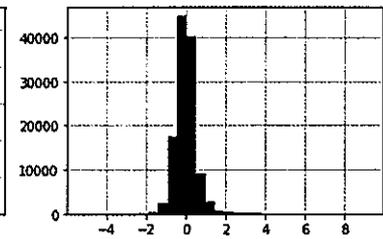
(c) 対水速度再構築誤差



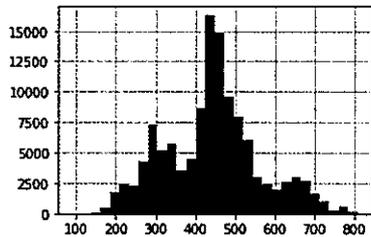
(d) 翼角真の値



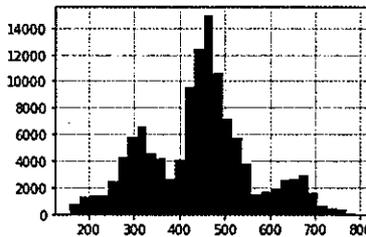
(e) 翼角復元値



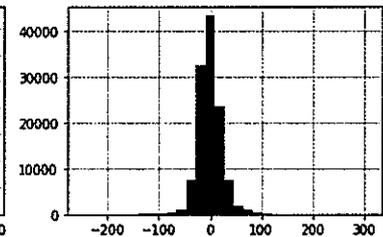
(f) 翼角再構築誤差



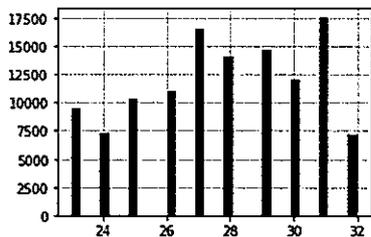
(g) 軸馬力真の値



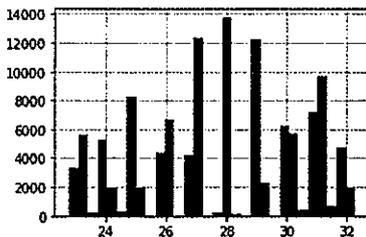
(h) 軸馬力復元値



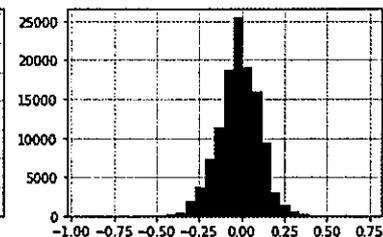
(i) 軸馬力再構築誤差



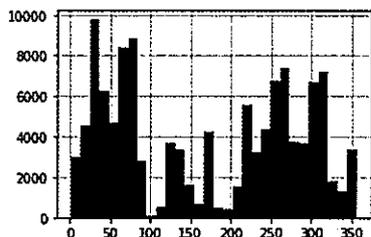
(j) 船齢真の値



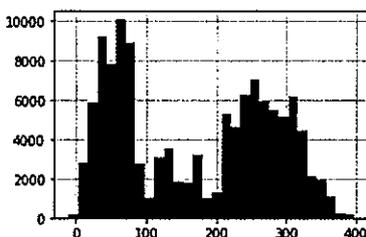
(k) 船齢復元値



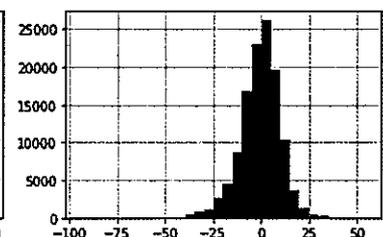
(l) 船齢再構築誤差



(m) 出渠後日数真の値



(n) 出渠後日数復元値



(o) 出渠後日数再構築誤差

図 3-7 項目ごとの再構築誤差

図 3-7 の再構築誤差は、標準化したデータを元のスケールに戻した際に計算したものであるから、項目間の再構築誤差の比較ができない。そこで、標準化した値における再構築誤差を計算し、それぞれの項目の分散を以下の表 3-2 に記載する。小数点以下第 4 桁を四捨五入した。

表 3-2 各項目の再構築誤差の分散

	対水速力	翼角	軸馬力	船齢	出渠後日数
再構築誤差の分散	0.107	0.034	0.040	0.003	0.009

表 3-2 より、船齢と出渠後日数の再構築誤差が小さく、逆に対水速力の再構築誤差は大きいことが分かる。考えられる理由として、3次元に次元削減された際に、そのうち2つのノードは、他の項目と相関の弱い船齢と出渠後日数の特徴表現に大きな役割を果たし、残る1つのノードが、相関の強い対水速力、翼角、軸馬力の3変数の特徴表現を担っている可能性がある。そのため、項目ごとに再構築誤差の分散が大きく異なると考えられる。

### 3.3.4 外れ値除外結果

再構築誤差を利用して外れ値除外を行うには、正常値と外れ値の閾値を設定する必要がある。(3-1)式の異常度を、各サンプルデータに対して求め、異常度の分布を示したヒストグラムが、図 3-8 である。ここで、全データのうち 1% に異常があると仮定した。この仮定において異常度の閾値を探索的に求めたところ、閾値は約 1.351 と求まった。よって、 $Err \geq 1.351$  を満たせば異常とし、 $Err < 1.351$  であれば正常とした。

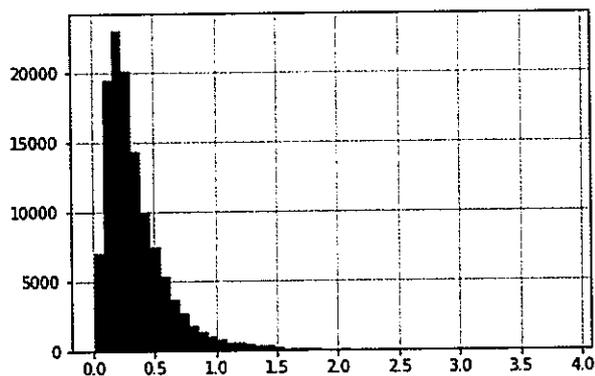
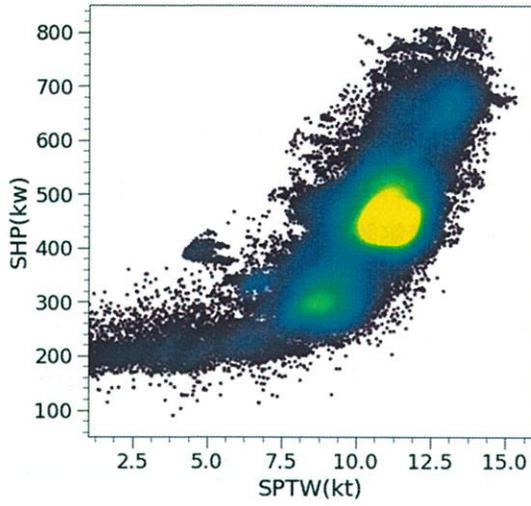
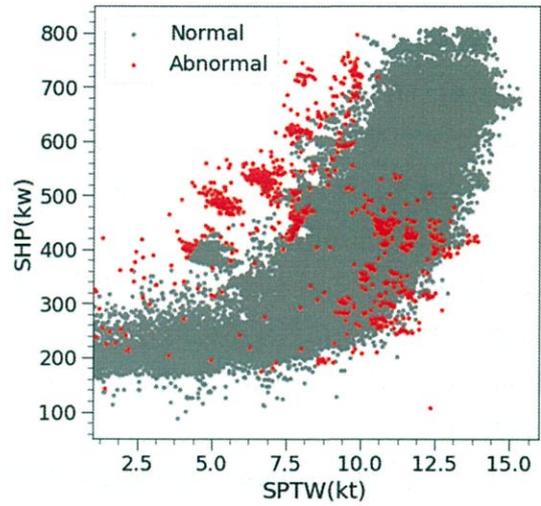


図 3-8 異常度の分布

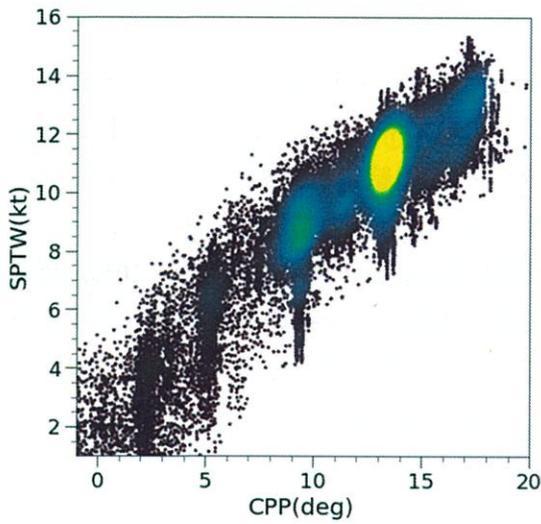
異常と判定されたデータは、正常データと比べてどのような特徴を持つか確認する。データ分布を調べる際に用いる項目は、対水速力、翼角、軸馬力とする。正常データはデータ数が多くデータ点同士が重なるので、カーネル密度推定によりデータ密度を色で表現している。藍色の領域はデータ密度が最も低く、緑色の領域は中程度、黄色の領域は最も高い。カーネル密度の計算には Python の `scipy` パッケージを利用した。図 3-9 の左列は正常値の分布であり、右列は赤点が外れ値を示す。比較のため正常値を灰色でプロットした。



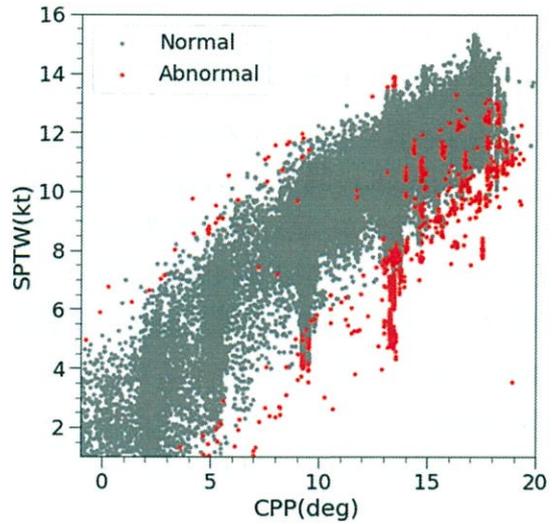
(a) 対水速力と軸馬力-正常値



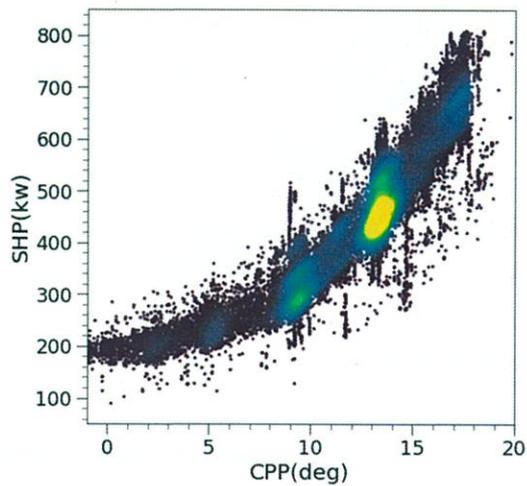
(b) 対水速力と軸馬力-外れ値



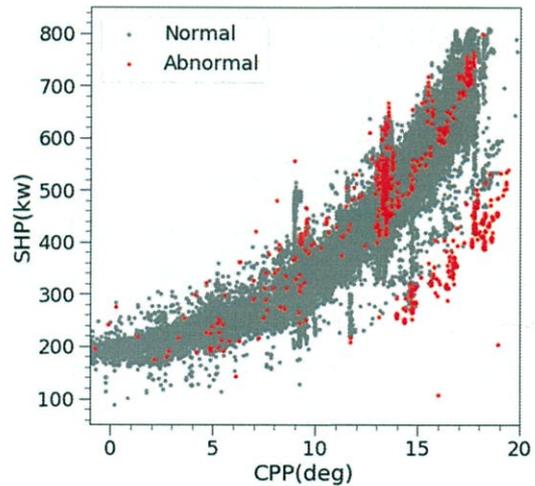
(c) 翼角と対水速力-正常値



(d) 翼角と対水速力-外れ値



(e) 翼角と軸馬力-正常値



(f) 翼角と軸馬力-外れ値

図 3-9 対水速力・翼角・軸馬力の散布図

図 3-9(a)(b)より、軸馬力は低速域 (1~5kt) において 200kW 程度の一定値を保っており、外れ値は、5kt 以上における速力に対する軸馬力が大きいデータに多い。一方で、データ密度の高い領域にも外れ値が存在する。

図 3-9(c)より、使用する翼角が、2.5 deg, 5 deg, 10deg, 13 deg, 17 deg と離散的に分布していることが分かる。また、翼角に対する対水速力の分散が大きいことが特徴的である。図 3-9(d)より、正常値と外れ値の分布が明確に分かれている。これより、再構築誤差を用いて検出した汐路丸の外れ値は、翼角に対する対水速力が異常に低い状態か、高い状態とすることができる。

図 3-9(e)より、翼角に対する軸馬力の分散が、対水速力よりも小さいことが分かる。図 3-9(f)より、翼角に対する軸馬力が異常に低いデータは外れ値と言えるが、データ密度の高い領域にも外れ値は存在する。

以上より、正常値と外れ値の分布が最も明確に分かれるのは翼角と対水速力の関係であり、翼角に対する対水速力が明らかに低いデータが外れ値の主体と言える。また、正常値と外れ値の分布の境界線は、データ分布に沿った非線形な形状をしており、マハラノビス距離を用いた外れ値検出結果よりも好ましいと言える。

以上に述べた外れ値検出の目的は、定常運航から外れたデータを検出することであった。図 3-9(b)(d)(f)より、明らかに定常運航から外れているデータの大半は検出されており、目的を達成したと言える。A 丸に関しても再構築誤差による外れ値検出結果は良好であり、結果の詳細を Appendix.1.2 に載せた。尚、検出を想定する外れ値に関して、5.1 にて詳細に述べる。

本研究では外れ値の割合を 1%と比較的少数に仮定したが、もしもこの割合が 10%を超えるような場合は、正常と判定されたデータのみを用いてオートエンコーダの訓練を繰り返すことで、正常値と外れ値を分離可能であることが報告されている<sup>(3-4)</sup>。この手法を用いれば、多変量、且つ、変数間の相関が存在するモニタリングデータに対しても、作業者の主観が入り込むことなく定常運航のデータ抽出を行える可能性がある。

### 3.4 次元削減によるデータの可視化(汐路丸)

#### 3.4.1 手法

3.3.5 にて推進性能を示す 3 項目の散布図を描いたが、同時に比較できるのは 2 項目間であり、データ全体の分布を一度に把握するのが難しい。そこでオートエンコーダを用いて 3 次元データの特徴を 2 次元に落とし込み、データ構造を一枚の散布図で表現する。

オートエンコーダの次元削減部分をエンコーダと呼び、復元部分をデコーダと呼ぶ。エンコーダのみを利用すれば、入力値を任意の次元数まで次元削減することが可能だ。エンコーダを利用する際は、通常のオートエンコーダを訓練し、デコーダを取り除くことで次元削減された特徴ベクトル  $V$  を持つ中間層を新たな出力層とする。図 3-6 からデコーダを取り除いたネットワークが図 3-10 のエンコーダである。表 3-3 は学習させたオートエンコーダの構造を示す。表 3-3 の第 2 中間層を出力層としたモデルを用いて次元削減を行った。

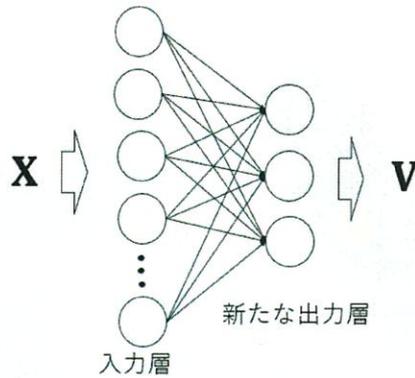


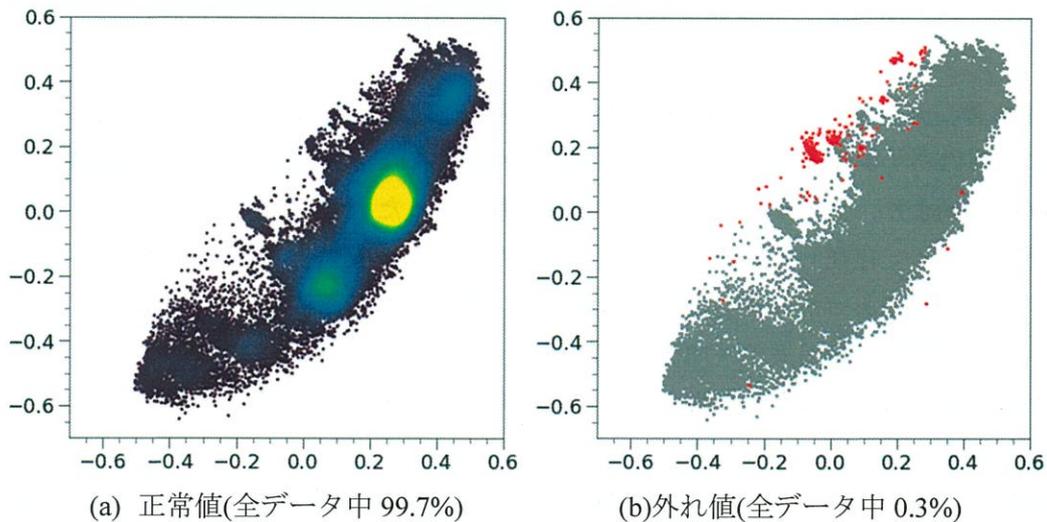
図 3-10 エンコーダによる次元削減

	入力層	第1 中間層	第2 中間層	第3 中間層	出力層
ノード数	3	3	2	3	3

表 3-3 オートエンコーダの構造

### 3.4.2 特徴平面における正常値と外れ値の分布

再構築誤差を用いて外れ値除外したデータの次元削減結果を図 3-11 に示す。(a)から(f)は、条件や対象データを変えた際の分布を示し、x 軸と y 軸の値は、標準化されたデータが持つ特徴量である。図 3-11 の左列が正常値のみの密度分布であり、右列は、赤点が外れ値、灰色点は比較のための正常値である。3.2.4 にて、異常度の閾値を全データのうち 1.0%が異常となるように設定した。しかしここでは、外れ値の分布傾向を調べるために、全データ中の外れ値の割合を、0.3%、1.0%、5.0%と変化させた際のデータ分布を示している。(a)、(b)は外れ値の割合が 0.3%(正常値の割合は 99.7%)、(c)、(d)は外れ値の割合が 1%(正常値の割合は 99.0%)、(e)、(f)は外れ値の割合が 5%(正常値の割合は 95.0%)である。



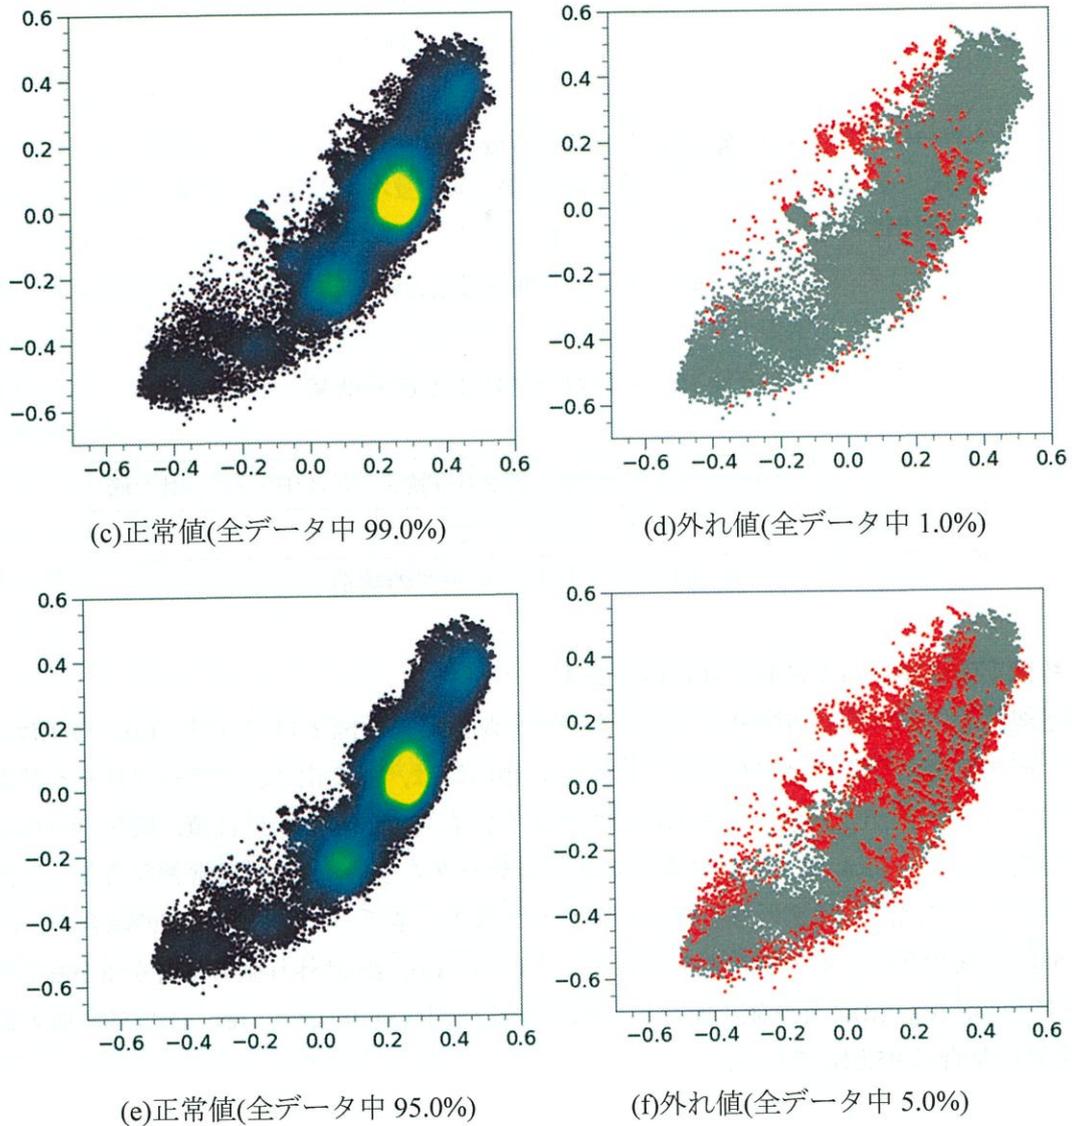
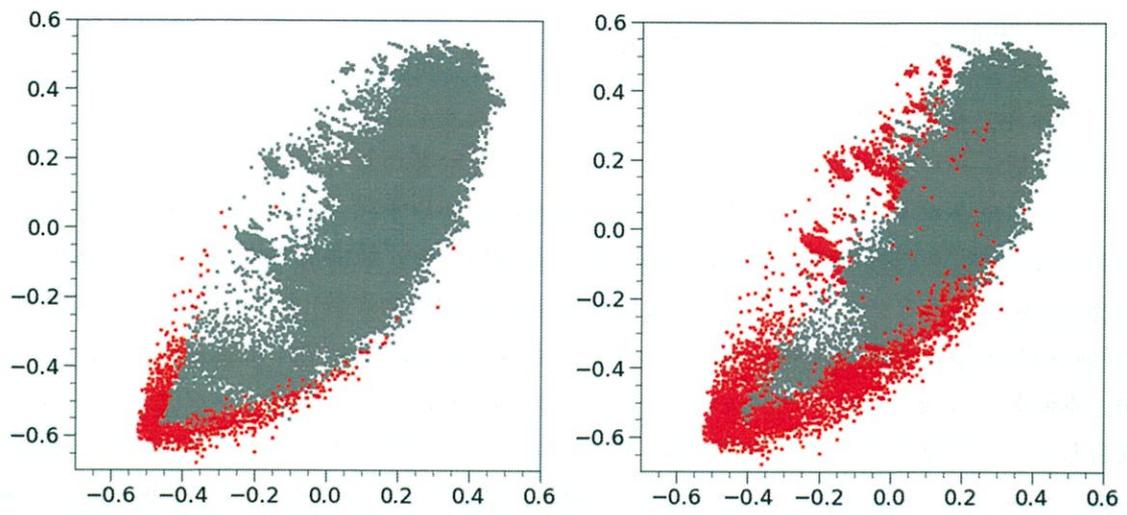


図 3-11 正常値と外れ値の特徴量の分布(再構築誤差使用時)

図 3-11 より、外れ値は正常データを囲むように存在する傾向にあることが分かる。そして正常データの分布はバナナ型であり、これは、軸馬力が速力の 3 乗に比例することを表現している可能性が高い。(b)より、全データのうち異常度が最も高かった上位 0.3%のデータ群は、特徴平面上の 1 か所に固まって存在している。これらを調べたところ、翼角と軸馬力に対して対水速力が極端に低いデータ群であった。翼角に対する軸馬力に関しては若干高い。具体的には、異常データ群の対水速力、翼角、軸馬力の平均値はそれぞれ、7.0kt, 14.3deg, 523.2kW である。外力による影響や、港内操船時であった可能性、あるいは何らかの実験の影響で、対水速力が著しく低下したと考えられる。

参考までに、図 3-12 にマハラノビス距離による外れ値除外結果を示す。次元削減した結果からも、再構築誤差による手法とマハラノビス距離による外れ値除外結果は大きく異なることが分かる。



(a) 外れ値(全データ中 1.0%)

(b) 外れ値(全データ中 5.0%)

図 3-12 正常値と外れ値の特徴量の分布(マハラノビス距離使用時)

## 第4章 教師あり学習による予測

### 4.1 目的変数・説明変数の設定

第3章では、ニューラルネットワークをオートエンコーダとして、外れ値の検出とデータの可視化を行った。本章ではニューラルネットワークを、未知数予測を目的とした回帰モデルとして利用する。本研究では、燃料消費量に直接影響する軸馬力と、航海計画に重要な対水速力の推定を行う。ニューラルネットワークへの入力に利用する項目(説明変数)は表4-1のとおりである。それぞれの項目の選定理由も記載した。それぞれの項目の詳細は第2章に記載してある。

尚、本研究では複数のニューラルネットワークを訓練し、それらをバギングアルゴリズムにより統合して一つの推定モデルを作成する。単一のニューラルネットワークと区別するために、バギングアルゴリズムにより統合したものを、「軸馬力推定モデル」または「対水速力推定モデル」と呼ぶ。

表 4-1 説明変数に選定した汐路丸の項目

項目名	項目の説明	説明変数に選定した理由
HeadingSD	船首方位の振れ	船首方位変化により船体抵抗増加
REV	軸回転数	軸回転数一定だが、多少の変動あり
CPP	翼角	可変ピッチプロペラ装備
RudderSD	舵角の大きさ	操舵により船体抵抗増加
Rolling	ローリング	波浪抵抗を考慮
Pitching	ピッチング	波浪抵抗を考慮
WindSpeed	真風速	風圧抵抗を考慮
WindDirection	真風向	風圧抵抗を考慮
Variation	速力変化量	慣性力を考慮
TotalYear	船齢	経年変化影響を考慮
AfterDock	出渠後日数	生物汚損影響を考慮

表 4-2 説明変数に選定したA丸の項目

項目名	項目の説明	説明変数に選定した理由
REV	軸回転数	固定ピッチプロペラ装備
Displacement	排水量	貨物船のため変動が大きい
Trim	トリム	貨物船のため変動が大きい
WindSpeed	真風速	風圧抵抗を考慮
WindDirection	真風向	風圧抵抗を考慮
WaveHeight	波高	波浪抵抗を考慮
WaveDirection	波向き	波浪抵抗を考慮
Variation	速力変化量	慣性力を考慮
AfteDock	出渠後日数	生物汚損影響を考慮

## 4.2 ニューラルネットワークの表現力

2.1.3にて過学習の問題に言及したが、ニューラルネットワークに適切な表現力を与えるためのアプローチとして、高い表現力に設定した後、損失関数に正則化項を加えることで、適切な表現力を選定するとした。従って、高い表現力を持たせるに、どの程度の層数とノード数が必要であるか調べる。Nを任意の整数として、表4-3の構造のニューラルネットワークを考える。入力層のノード数は汐路丸が11、A丸が9であり、in-Nと表記している。中間層の層数は4層で固定して、中間層のノード数をNにより定める。Nを増すほどニューラルネットワークの表現力は高くなる。それぞれの場合の、訓練データと評価データに対する損失を計算する。調査したNの値は以下のとおりである。

・汐路丸

N= 10, 20, 30, 40, 50, 60, 70, 80, 90, 100, 110, 120, 130, 140, 150, 160, 170, 180, 190, 200, 250, 300, 350, 400, 500, 600, 700, 800, 900, 1000

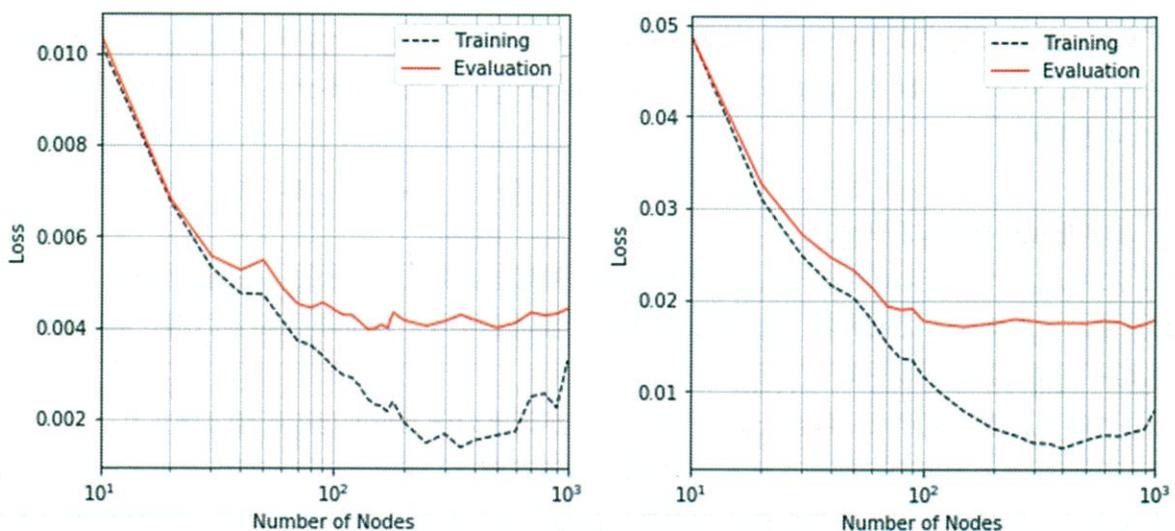
・A丸

N= 10, 20, 30, 40, 50, 60, 70, 80, 90, 100, 110, 120, 130, 140, 150, 160, 170, 180, 190, 200, 250, 300

表 4-3 ニューラルネットワークの構造

	入力層	第1中間層	第2中間層	第3中間層	第4中間層	出力層
ノード数	in-N	N	N	N	N	1

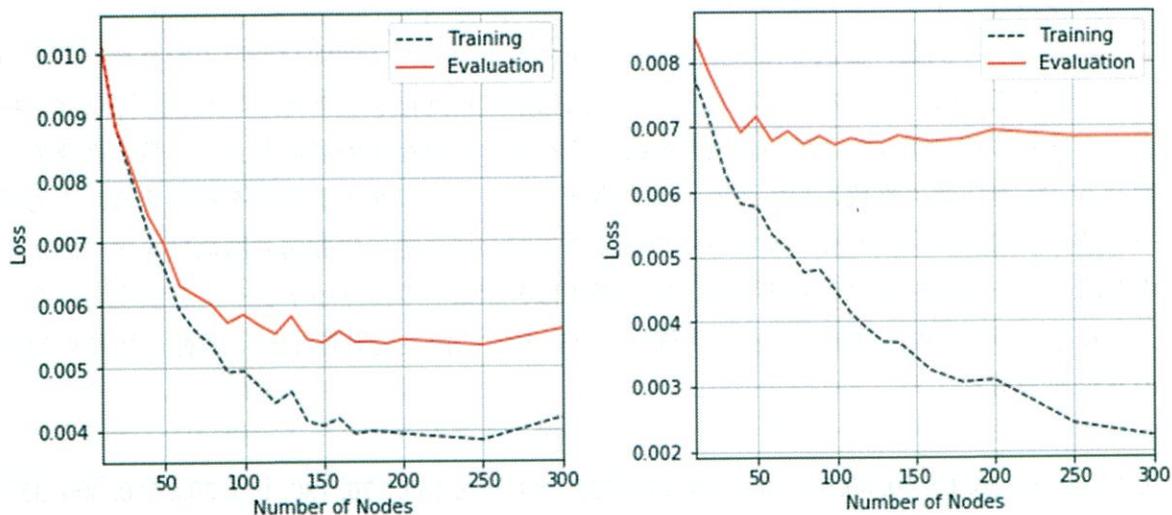
それぞれの学習回数(エポック数)は80回、バッチサイズは256であり、損失を計算する際には(2-6)式を用いた。尚、最終的な推定精度を計算する際に用いるテストデータは、今回の探索において使用していない。図4-1は汐路丸の探索結果、図4-2はA丸の探索結果である。図4-1のx軸は対数スケールとした。



(a)軸馬力推定ニューラルネットワーク

(b)対水速力推定ニューラルネットワーク

図 4-1 汐路丸のニューラルネットワークの表現力と損失



(a) 軸馬力推定ニューラルネットワーク (b) 対水速度推定ニューラルネットワーク

図 4-2 A 丸のニューラルネットワークの表現力と損失

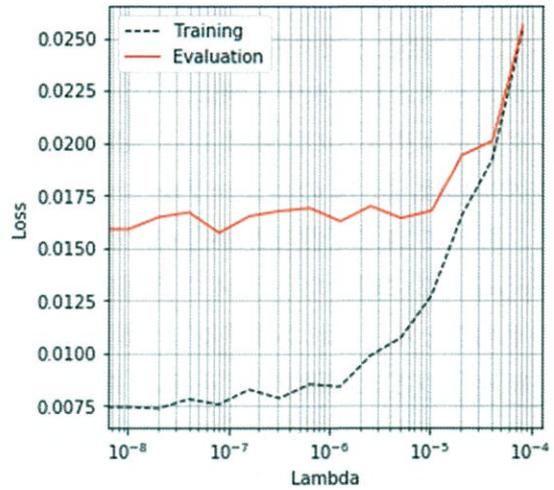
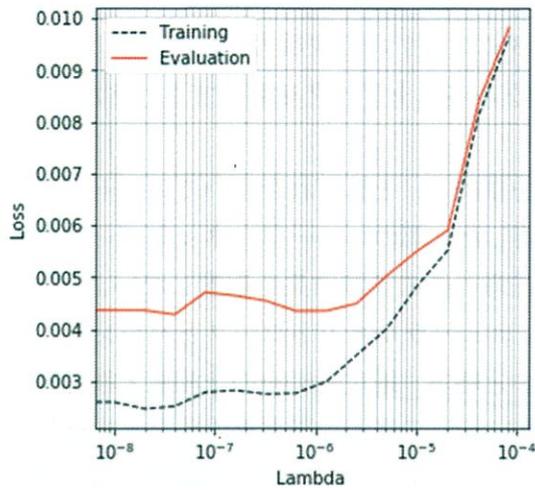
図 4-1 より，汐路丸の場合はノード数 150 程度で評価データの損失が最小になり，ニューラルネットワークの表現力をそれ以上高めても評価データの損失は減少せず，訓練データの損失のみが減少する．これは訓練データに含まれるノイズを学習している状態であり，評価データの損失が若干上昇していることから過学習と言える．よって，汐路丸の軸馬力推定ニューラルネットワークと，対水速度推定ニューラルネットワークの中間層ノード数は，どちらも 150 とした．

図 4-2 より，A 丸の軸馬力推定ニューラルネットワークの場合も，中間層ノード数が 150 程度で評価データの減少が止まっていることが分かる．ところで，A 丸の訓練データと評価データを合わせると 36196 のデータ数となる．もしも A 丸のニューラルネットワークの中間層ノード数を 150 とすると，ニューラルネットワークが持つ総パラメータ数は 69601 となり，訓練データ数よりも多くなる．訓練データ数よりも多いパラメータを持つことは，たとえ評価データの損失が低くても汎化性能に懸念があるため，軸馬力推定ニューラルネットワークの中間層ノード数（総パラメータ数 20321）は 80 とした．そして，対水速度推定ニューラルネットワークの中間層ノード数は 50 とした．

### 4.3 正則化項の導入に関して

4.2 においてニューラルネットワークの中間層の層数を設定した．次に，正則化項のパラメータ  $\lambda$  の最適な値を探索的に求める．図 4-3 に汐路丸の調査結果を，図 4-4 に A 丸の調査結果を示す．どちらも x 軸は対数スケールとした．

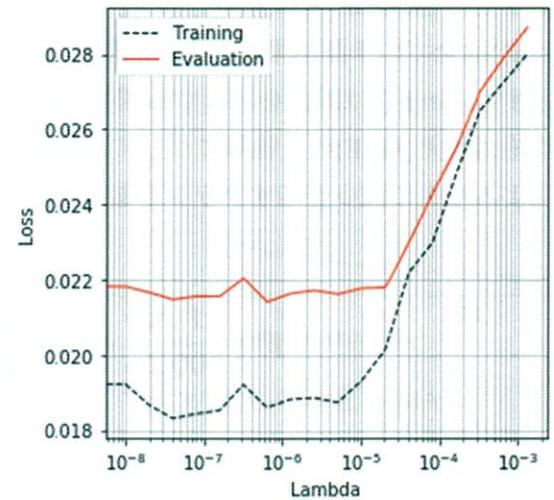
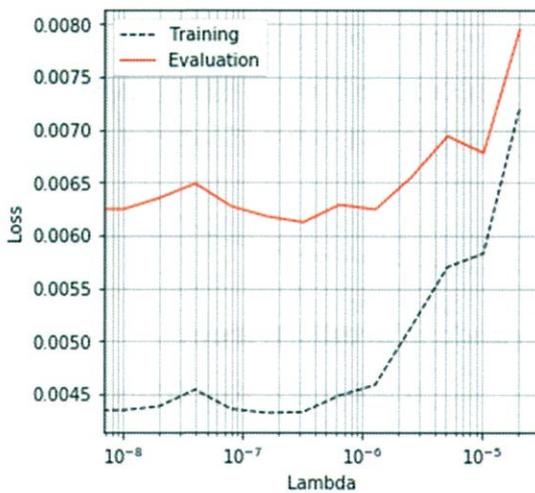
$\lambda=0$  の時は正則化項がない場合と同じであり， $\lambda$  が大きいほど正則化の影響は強まり，ニューラルネットワークの表現力が削減される． $\lambda$  を選定する基準は，訓練データと評価データの損失の乖離が少なく，評価データの損失が最小の水準であることとした．表 4-4 に各ニューラルネットワークのノード数と総パラメータ数，正則化パラメータの値を記載した．



(a)軸馬力推定ニューラルネットワーク

(b)対水速度推定ニューラルネットワーク

図 4-3 汐路丸の正則化項パラメータ探索



(a)軸馬力推定ニューラルネットワーク

(b)対水速度推定ニューラルネットワーク

図 4-4 A 丸の正則化項パラメータ探索

表 4-4 各ニューラルネットワークのハイパーパラメータ

	中間層ノード数	総パラメータ数	正則化パラメータ $\lambda$
汐路丸 軸馬力推定	150	69901	1.0E-6
汐路丸 対水速度推定	150	69901	1.0E-5
A 丸 軸馬力推定	80	20321	1.0E-5
A 丸 対水速度推定	50	8201	4.0E-5

#### 4.4 バギングアルゴリズム

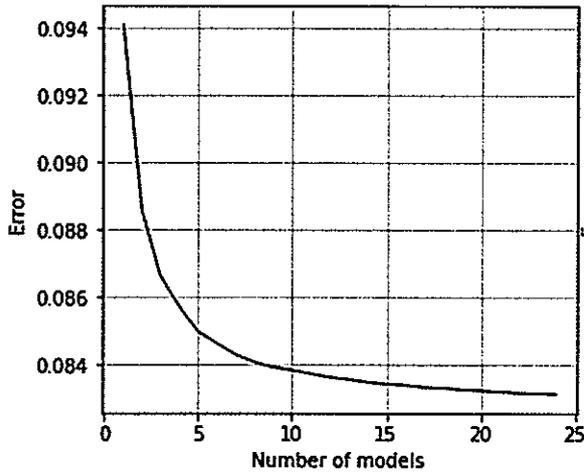
4.1にて目的変数と説明変数を選定し、4.2及び4.3にてモデルの表現力を決定した。次に、バギングアルゴリズムを導入する際に、いくつのニューラルネットワークを訓練すべきか調査する。バギングアルゴリズムの詳細は2.5に記載した。

調査の手順は、計24のニューラルネットワークを訓練し、それぞれを用いてテストデータを予測する。よって24の予測結果が存在する。尚、訓練した一部のニューラルネットワークの学習曲線をAppendix.2に載せた。計24の予測結果から、任意の数の予測結果を重複しないよう選び、それらの平均をとる。それが最終的な予測値であり、ニューラルネットワークとバギングアルゴリズムが組み合わさった回帰モデルを、「推定モデル」と呼ぶ。推定モデルの予測値と教師データを比較することで予測誤差を計算する。予測誤差計算には、二乗平均平方根誤差と平均絶対誤差を用いる。ニューラルネットワークごとにテストデータに対する予測誤差に差異があるため、全てのニューラルネットワークを用いる場合を除いて、選び方により予測誤差は変わる。そこでニューラルネットワークの選択を100回繰り返す、推定モデルの予測誤差の平均をとることで対処した。 $\text{pred}_{(k)}$ をk番目(1~24)の予測値のベクトル、 $\text{true}$ を教師データのベクトル、モデルの選択数をK、データ数をmとすれば、推定モデルの予測誤差の平均を(4-1)式で計算できる。但し、 $\text{random}()$ は全ての予測結果の中から、無作為にK個の予測ベクトルを重複がないよう抽出する関数とする。 $\text{erf}()$ は誤差を計算する関数であり、(4-2)式の二乗平均平方根誤差(RMSE)と(4-3)式の平均絶対誤差(MAE)の2種類について計算した。図4-5に計4つのモデルのバギングアルゴリズムによる損失の減少を示すグラフを載せた。

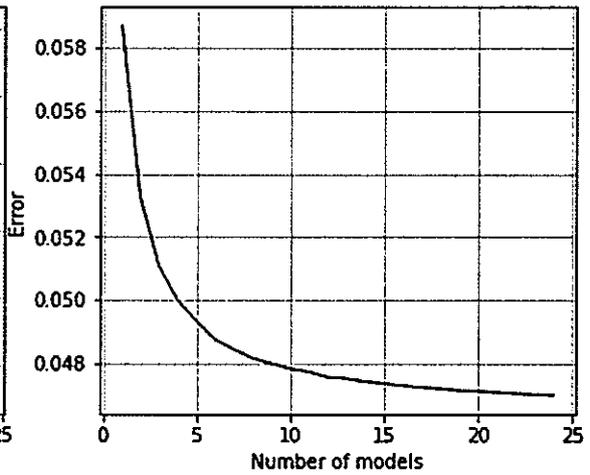
$$E = \frac{1}{100} \sum_{n=1}^{100} \text{erf} \left( \frac{1}{K} \sum_{k=1}^K \text{random}(\text{pred}_{(k)}), \text{true} \right) \quad (4-1)$$

$$\text{erf}_{\text{rmse}}(\text{ave\_pred}, \text{true}) = \sqrt{\frac{1}{m} \sum_{i=1}^m (\text{ave\_pred}^{(i)} - \text{true}^{(i)})^2} \quad (4-2)$$

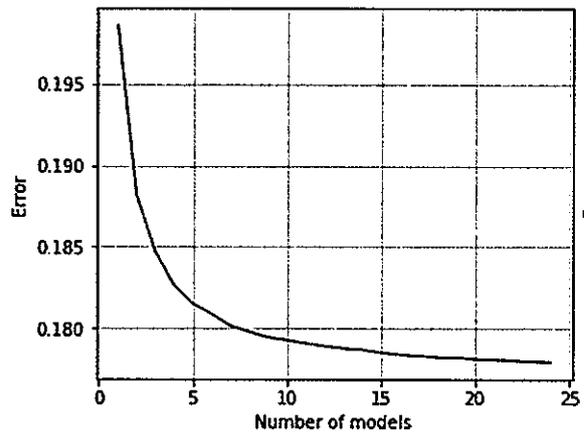
$$\text{erf}_{\text{mae}}(\text{ave\_pred}, \text{true}) = \frac{1}{m} \sum_{i=1}^m |\text{ave\_pred}^{(i)} - \text{true}^{(i)}| \quad (4-3)$$



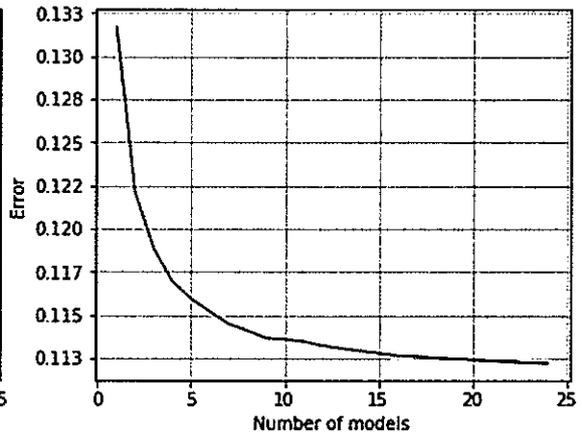
(a) 汐路丸-軸馬力-RMSE



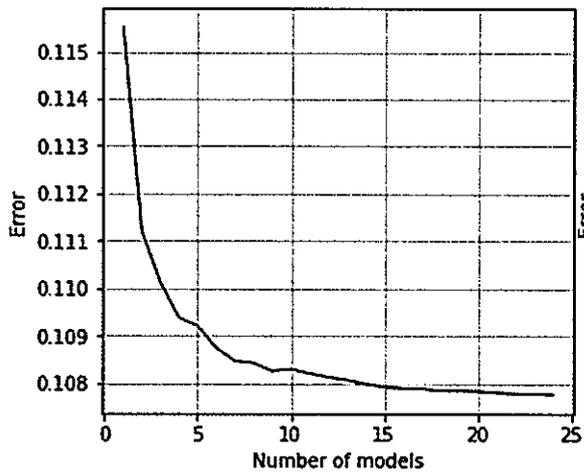
(b) 汐路丸-軸馬力-MAE



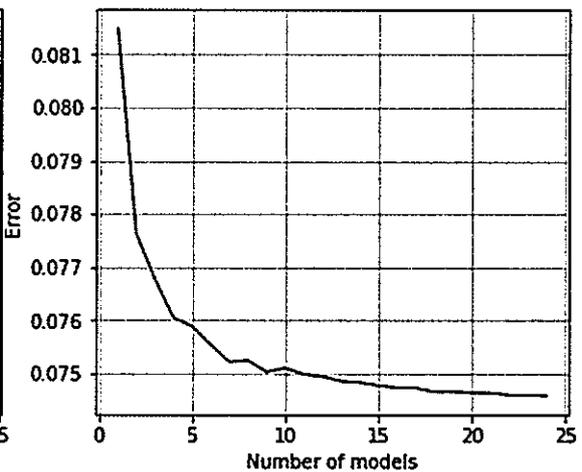
(c) 汐路丸-対水速力-RMSE



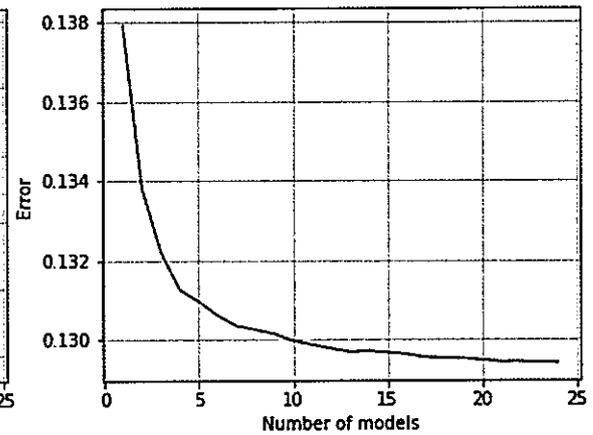
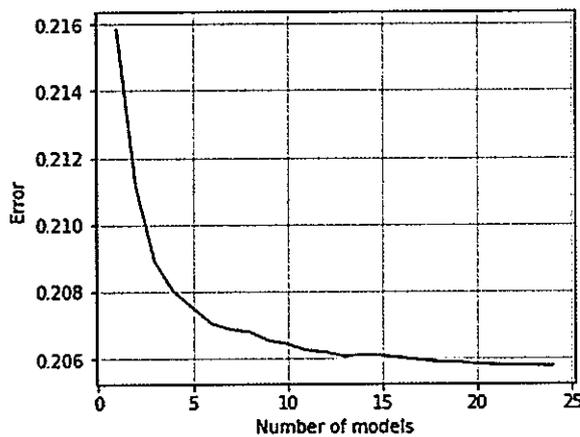
(d) 汐路丸-対水速力-MAE



(e) A丸-軸馬力-RMSE



(f) A丸-軸馬力-MAE



(g)A 丸-対水速力-RMSE

(h)A 丸-対水速力-MAE

図 4-5 バギングアルゴリズムに利用するモデル数と予測誤差

全ての推定モデルにおいて、バギングアルゴリズムに利用するニューラルネットワークの数を増やすほど、テストデータに対する予測誤差が減少しており、汎化性能が向上している。さらに利用するニューラルネットワークを増やすことで、若干の汎化性能向上が期待できると推測される。バギングに利用する適切なニューラルネットワークの数は、計算リソースとの兼ね合いであるが、5~10 のモデルを利用すればバギングアルゴリズムの恩恵を十分に受けられると考えられる。図 4-5 より、ニューラルネットワークの数を 10 より多くしても、必要となる計算リソースに対する精度向上の幅は小さいと言える。しかし本研究では研究結果の質を高めるために、全てのニューラルネットワークを利用して推定モデルを作成した。

#### 4.5 各推定モデルの予測精度

##### 4.5.1 評価指標

4.4 ではバギングアルゴリズムによる予測精度向上に関して述べた。ここでは、テストデータの予測誤差を計算することで、ニューラルネットワークの予測精度が具体的にどの程度であるか述べる。バギングアルゴリズムに利用するモデル数は 24 とする。予測精度の評価指標は次の 5 つとする。平均絶対誤差：(4-3)式，平均絶対誤差率：(4-4)式，二乗平均平方根誤差：(4-2)式，二乗平均平方根誤差率：(4-5)式，決定係数：(4-6)式である。誤差率や決定係数は、推定する値の単位やスケールに依存しない指標であるので、他船のデータを推定した際に比較可能である。なお、 $\overline{true}$  は教師データの平均値である。

$$MAPE(\text{平均絶対誤差率}) = \frac{1}{m} \sum_{i=1}^m \left| \frac{pred^{(i)} - true^{(i)}}{true^{(i)}} \right| \quad (4-4)$$

$$RMSPE(\text{二乗平均平方根誤差率}) = \sqrt{\frac{1}{m} \sum_{i=1}^m \left( \frac{pred^{(i)} - true^{(i)}}{true^{(i)}} \right)^2} \quad (4-5)$$

$$R^2(\text{決定係数}) = 1 - \frac{\sum_{i=1}^m (\text{true}^{(i)} - \text{pred}^{(i)})^2}{\sum_{i=1}^m (\text{true}^{(i)} - \bar{\text{true}})^2} \quad (4-6)$$

#### 4.5.2 予測精度の計算結果

汐路丸の軸馬力の予測精度を表 4-5 に示す。平均絶対誤差及び二乗平均平方根誤差は十分に低いと言えるだろう。決定係数は 0.993 であり、一般的に極めて高い予測精度の回帰モデルである。決定係数が高くなった原因のひとつとして、教師データの分散が大きいことがあげられる。図 3-3(g)の軸馬力のヒストグラムから、最小値が約 150kW、最大値が約 800kW となっており、広いレンジにデータが分布していることが分かる。分散の大きいデータを高精度で推定できていることから、性能の良い回帰モデルであると言える。

汐路丸の対水速力の予測精度を表 4-6 に示す。予測精度は軸馬力ほど高い水準ではないが、決定係数が 0.955 であるから、十分に良い性能の回帰モデルだと言える。この結果の気になる点として、RMSPE の値が他と比べて大きいことである。RMSE/MAE = 1.467 に対して RMSPE/MAPE = 2.221 である。予測誤差を割合で表現すると、低速域における予測誤差が大きな影響をもつ。例えば真の値 3kt に対して 4kt と予測した際に、RMSPE の値は誤差率 33%となる。しかし真の値 10kt に対して 11kt と予測した際は RMSPE の値は誤差率 10%である。また、RMSE、RMSPE ともに予測誤差を 2 乗しているのので、大きい予測誤差を少数でも含むと指標の値は大きく増加する。従って、低速域における予測誤差が大きいのではないかと考えた。そこで、テストデータから対水速力 8kt 未満のデータを除外して予測精度を計算した。その結果、MAPE は 1.99%、RMSPE は 3.08%、決定係数は 0.945 と、RMSPE の大幅な改善が見られた。よって、低速域の予測精度が悪いと言える。考えられる原因として、データ不足と港内操船等による船体運動の急激な変化が挙げられる。

表 4-5 汐路丸の軸馬力の予測精度

	全てのニューラルネットワークの予測誤差平均	バギングアルゴリズム適用時 (推定モデル)
MAE	7.19 (kW)	5.78(kW)
MAPE	1.67%	1.33%
RMSE	11.55(kW)	10.22(kW)
RMSPE	2.66%	2.31%
R <sup>2</sup>	0.991	0.993

表 4-6 汐路丸の対水速力の予測精度

	全てのニューラルネットワークの予測誤差平均	バギングアルゴリズム適用時 (推定モデル)
MAE	0.27(kt)	0.25(kt)
MAPE	3.29%	3.03%
RMSE	0.41(kt)	0.38(kt)
RMSPE	8.2%	7.86%
R <sup>2</sup>	0.961	0.966

A 丸の軸馬力の予測精度を表 4-7 に、対水速力の予測精度を表 4-8 に示す。A 丸の軸馬力推定モデル、対水速力推定モデルのどちらも、予測誤差率は低水準と言える。しかし決定係数に関しては汐路丸の方が良好である。これは、(4-6)式より予測対象の分散が大きいほど決定係数は 1 に近づくこと、また、汐路丸の軸馬力・対水速力の方が分散が大きいことから、データの分散の差が原因である。

表 4-7 A 丸の軸馬力の予測精度

	全てのニューラルネットワークの平均	バギングアルゴリズム適用時 (推定モデル)
MAE	32.18 (kW)	29.54(kW)
MAPE	1.36%	1.24%
RMSE	45.63(kW)	42.69(kW)
RMSPE	2.23%	2.06%
R <sup>2</sup>	0.987	0.988

表 4-8 A 丸の対水速力の予測精度

	全てのニューラルネットワークの予測誤差平均	バギングアルゴリズム適用時 (推定モデル)
MAE	0.14(kt)	0.13(kt)
MAPE	1.15%	1.08%
RMSE	0.22(kt)	0.21(kt)
RMSPE	2.07%	1.98%
R <sup>2</sup>	0.956	0.956

本研究で作成した計 4 つの推定モデルに関して、他の手法や先行研究と比較して、予測精度が高い水準にあるのか調査した。機械学習の中で予測精度が高い手法として一般に、ランダムフォレスト<sup>(4-1)</sup>が知られている。ランダムフォレストは複数の決定木<sup>(4-2)</sup>をバギングアルゴリズムによ

り統合したアルゴリズムである。ランダムフォレストにより同じデータを用いて訓練と予測を行ったところ、全ての予測対象に関して、本研究の推定モデルの方が良好な予測精度 (MAPE, RMSPE, 決定係数) であった。

また、使用するデータや条件等が異なるが、先行研究<sup>(1-11)</sup><sup>(1-12)</sup><sup>(1-14)</sup>が採用する推定モデルによる予測精度と同等か、本研究の推定モデルの方が良好な予測精度であった。以上より、作成した推定モデルのテストデータへの予測精度は十分に高いと言え、未知データに対しても高精度予測が期待できる。

## 第5章 推定モデルの評価

### 5.1 推定モデルの解釈

船舶の推進性能は、物理法則により完全に規定できる確定的な現象である。しかしモニタリングによって得られた計測データには、規則性だけでなく、計測誤差等を原因とする不規則性が含まれている。ここで、実海域における推進性能がデータ  $x$  により記述されるとする。データ  $x$  は他の変数により完全に規定される規則的な部分と、いかなる手段を用いても完全には規定することのできない不規則な部分とに分割できることを仮定する。データ  $x$  の規則的な部分が、 $p$  個の変数  $\theta_1 \theta_2 \dots \theta_p$  によって表現されるとし、また、不規則な部分を  $\varepsilon$  と表す。このとき  $x$  は

$$x = f(\theta_1 \theta_2 \dots \theta_p) + \varepsilon$$

と表される。ここで、 $\varepsilon$  とは主に計測誤差を想定しているが、本研究では波データが GPV の予測値であるので、GPV の予測誤差も含まれる。 $\varepsilon$  は確率変数であり、一般に正規分布が想定される。本研究の推定モデルは、一見、モニタリングデータから関数  $f$  を推定することが目標であるように思えるが、全ての変数  $\theta$  を計測することは不可能であり、 $n$  個の変数  $\theta$  のみ計測可能だとすれば、上式に変更が必要である。このとき  $x$  は

$$x = f(\theta_1 \theta_2 \dots \theta_n) + g(\pi_1 \pi_2 \dots \pi_m) + \varepsilon$$

と記述できるとする。ここで  $\pi$  は、計測不可能だが推進性能に影響を与える何らかの変数 ( $m$  個) であり、具体的には船体表面粗度、船体運動 (rolling, pitching, yawing, 加速度等の時系列データ) などが考えられる。本研究の汐路丸の場合は、波に関するデータも該当する。しかしそれらはモニタリングデータに存在しないため、関数  $g$  を推定することはできない。その分布も不明であるが、定常運航から外れた状態 (港内操船や増減速時、意識的減速を行うような荒天) では、計測誤差等の  $\varepsilon$  よりも相対的に大きな影響を持つと考えられる。これは、損失関数に 2 乗平均平方根誤差 (データのノイズに正規分布を想定する) を使用せず、logcosh と呼ばれる、外れ値 (関数  $g$  の項が大きい場合) に寛容な(2-6)式を使用した理由である。尚、第3章において検出を想定した外れ値の主体とは、まさに関数  $g$  の項が大きいデータである。以上より、本研究で作成した推定モデルとは、推進性能を規定する  $n$  個の計測可能な変数  $\theta$  と軸馬力・対水速力の関係を表す、関数  $f$  と解釈できる。

### 5.2 将来データの予測可能性

第4章にて、作成した推定モデルのテストデータに対する予測精度が高いことを示した。しかしそれは、将来データに対しても同じ予測精度を発揮できる保証とはならない。

統計学では、調査対象全体を母集団と言い、データとして観測される母集団の一部を標本と言う<sup>(5-1)</sup>。本研究で想定する母集団とは定常運航状態にある船舶の航行中のデータであり、これには風圧抵抗・波浪抵抗を受けた状態や、生物汚損影響 (船体表面にスライムと呼ばれる細菌分泌物の被膜や、海洋生物が付着することによる) を受けた状態、経年変化影響 (船体・プロペラ表面粗度の増加や主機の経年変化による) を受けた状態を含む。

このうち経年変化影響に関しては、標本データは観測された時点までのデータであるから、数年後の性能を予測することは困難であり、過去の経年変化影響のみ標本から知ることができる。

しかし実際には、経年変化影響は年単位でその影響を認識できる程度であるから、ある船舶の1月後の性能における経年変化影響は無視できると考えられ、収集したデータから逐次パラメータを更新するオンライン学習により解決可能だと言える。

生物汚損影響は、毎年同じ程度であることを仮定すれば、標本から将来データの予測をすることは可能だと言える。仮に例年と異なる傾向であっても、オンライン学習導入により解決可能と考えられる。

海気象影響は季節により変化するが、十分なモニタリング期間（1年以上）を設けることで、想定する母集団と、標本が大きく異なることはないと考えられる。以上より、将来データの予測精度向上には、オンライン学習が必須と考えられる。

### 5.3 推定モデルのロバスト性と説明性

ニューラルネットワーク等の機械学習によるモデルは、ブラックボックスモデルと呼ばれることがあり、これは入力に対する出力が人間には予測できないことに起因する。それにより発生する問題を以下で述べる。

ニューラルネットワークは、入力における微小なノイズ等により出力が変化することがある。訓練データと異なる入力値に対して十分な性能を発揮できない場合、入力領域の変化に対してロバスト（頑健）でないと見え、推定モデルが安定して性能を発揮する性質をロバスト性と言う<sup>(5-2)</sup>。

また、説明性・解釈性といった概念も重要である<sup>(5-3)</sup>。これらは、システムからの出力を利用する人間が、出力を得る際に用いられた判断基準（推定モデルが習得した規則性）について把握することができる程度を表す<sup>(5-2)</sup>。

推定モデルのロバスト性と説明性を検証するために、5.4において感度解析を行い、入力項目の出力に対する感度を解析した。また、5.5において個々の入力値を変化させた場合の出力の変化を調べた。

## 5.4 感度解析

### 5.4.1 結合荷重法の計算手順

推定モデルのロバスト性を解析するために、また、推定モデルの説明性を高めるために感度解析を行った。これにより、どの入力項目が出力に大きな影響を与えるか把握することができる。感度解析の手法<sup>(5-4)</sup>は結合荷重を用いたものであり、入力の出力に対する影響を比率で把握することができる。任意の数の中間層を持つネットワークに対して計算可能であるが、ここでは単純のため、入力層、中間層1、中間層2、出力層の4層構造のネットワークを考える。各層のユニット数を $n, h_1, h_2, m$ 、各層のユニットを代表する添字を $k, j, i, l$ とする。入力層の各ユニット $i = 1, 2, \dots, n$ について、次の(5-1)から(5-4)の計算を実行する。

$$S_j = \frac{|w_{jk}|}{\sum_{r=1}^n |w_{jr}|}, j = 1, 2, \dots, h_1 \quad (5-1)$$

(5-1) 式の  $w_{jk}(w_{jr})$  は入力層のユニット  $k(r)$  と中間層1のユニット  $j$  を結ぶ結合荷重を示す。そして  $S_j$  は中間層1のユニット  $j$  につながる相対的な結合荷重の強さである。

$$S_i = \sum_{j=1}^{h_1} (S_j \times |w_{ij}|), i = 1, 2, \dots, h_2 \quad (5-2)$$

(5-2) 式の  $w_{ij}$  は、中間層 1 のユニット  $j$  と中間層 2 のユニット  $i$  を結ぶ結合荷重を示す。 $S_i$  は、中間層 2 のユニット  $i$  につながる結合荷重の合計を示す。

$$\tilde{t}_{lk} = \sum_{i=1}^{h_2} (S_i \times |w_{li}|), l = 1, 2, \dots, m \quad (5-3)$$

(5-3) 式の  $w_{li}$  は、中間層 2 のユニット  $i$  と出力層のユニット  $l$  を結ぶ結合荷重を示す。本研究において出力は 1 つであるから、常に  $m = 1$  であるが、(5-3) 式は任意のユニット数を持つ出力層に対応した式とした。 $\tilde{t}_{lk}$  は入力層のユニット  $k$  の出力層のユニット  $l$  に対する感度を示す。

$$T_{m \times n} = \left[ \tilde{t}_{lk} / \sum_{s=1}^m \tilde{t}_{ls} \right] = [t_{lk}] \quad (5-4)$$

(5-4) 式は  $\tilde{t}_{lk}$  を正規化して行列表記したものである。各行の要素は入力出力に対する感度を比率で表している。よって各行の総和は 1 である。(5-4) 式の行列を結合荷重行列と呼ぶ。本研究においては出力層のユニット数は 1 なので、1 行  $n$  列の行列となる。5.4.2 及び 5.4.3 にて、各モデルの項目ごとの感度を箱ひげ図により示す。

#### 5.4.2 汐路丸の解析結果

図 5-1 及び図 5-2 は汐路丸の軸馬力推定モデル 24 個と対水速力推定モデル 24 個の感度解析結果である。横軸は入力項目を、縦軸はそれぞれの入力項目の出力に対する感度を箱ひげ図により示している。翼角(CPP), 船齢(TotalYears), 出渠後日数(AfterDock) の 3 項目が推進性能に与える影響はどちらも大きい。このことから、汐路丸は時間変化に伴う推進性能の変化が著しいと推測できる。モニタリング期間が比較的長期の 9 年に及ぶことから、船齢が推進性能に大きな影響を与えたと考えられる。また、出渠後日数の影響も大きい。これは、汐路丸は一般商船と比較して停泊している時間が長く、海洋生物付着による船体汚損の影響が大きいと考えられる。津金ら<sup>(5-5)</sup>は、長期停泊がある場合には、出渠後日数より累積停泊日数の方が船体汚損度への影響が大きいことを指摘している。汐路丸の船齢と出渠後日数が推進性能に与える影響に関して、5.5 にて詳細に調査する。

図 5-1 より、軸回転数(REV)が軸馬力に比較的大きな影響を与えていることが分かる。汐路丸は CPP 船のため、基本的に軸回転数 300(rpm)一定ではあるが、図 5-3 のヒストグラムに示す通り、若干の変動がある。尚、図 5-3 は縦軸の頻度 2000 から 100000 の部分を省略している。これより、軸回転数の大半が 290 回転後半だと分かる。具体的には、298 回転以上のデータが全体の約 98.2% を占める。残りの約 1.8% のデータは広く分布しており、予測対象である軸馬力に影響を与えていると考えられる。このことから、CPP 船の場合も軸馬力を推定する際には、軸回転数を入力項目に加えることを検討するべきだと言える。

図 5-1 及び図 5-2 より、ピッチングとローリングによる影響は比較的小さいと言える。これは、汐路丸の主な航行海域が東京湾内であり、波浪による影響の大きい状況が少ないことが原因と考えられる。図 5-1 より、風圧による影響は、対水速力に比較的大きな影響を与えていることが分かる。5.5 において汐路丸の風圧影響に関して詳細に解析する。

「HeadingSD」、「RudderSD」はそれぞれ、1 分間における船首方位と舵角の標準偏差を示しており、どちらも大きいほど抵抗が増加すると考えられる。船首方位の振れ角の方が感度が若干大きく、舵を切ることによる抵抗増加よりも、回頭運動による抵抗増加が大きいという船舶工学における知見と一致する可能性がある。

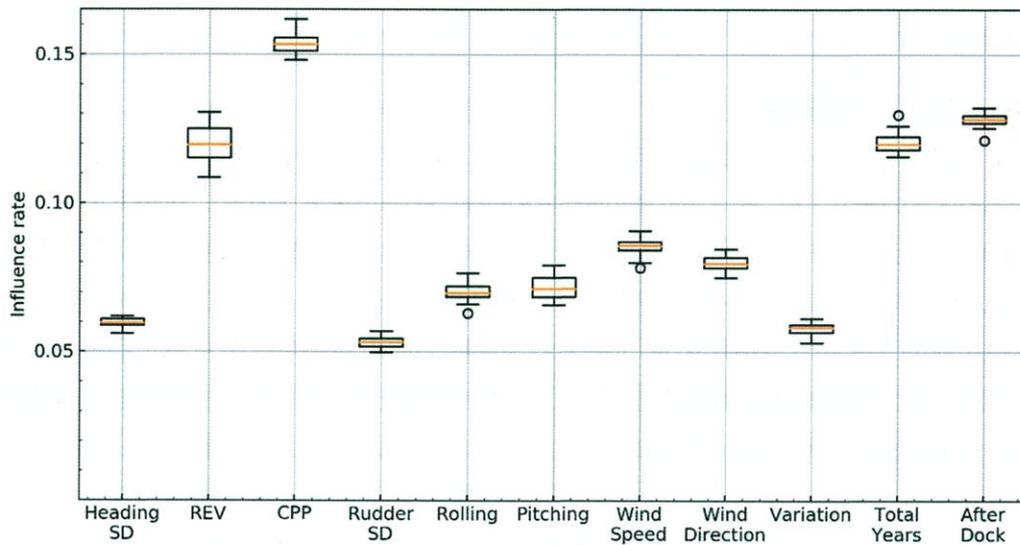


図 5-1 汐路丸の軸馬力推定モデルの感度解析結果

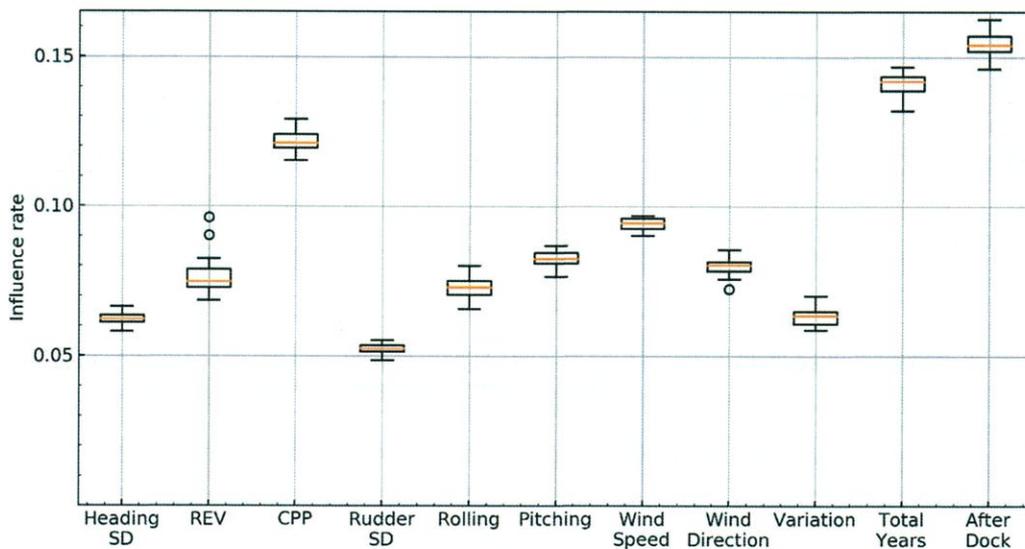


図 5-2 汐路丸の対水速力推定モデルの感度解析結果

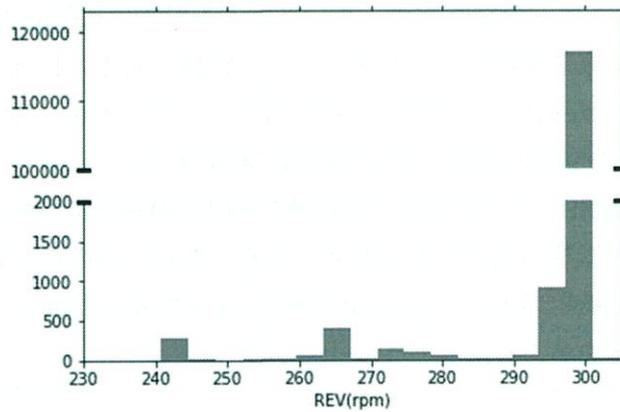


図 5-3 汐路丸の軸回転数ヒストグラム

### 5.4.3 内航貨物船の解析結果

図 5-4 及び図 5-5 に、A 丸の軸馬力推定モデル 24 個と対水速力推定モデル 24 個の感度解析結果を示す。どちらのモデルにおいても軸回転数(REV)の影響が最も大きい。汐路丸の場合は出渠後日数(AfterDock)が大きな感度を持っていたが、A 丸の場合は風・波に関する項目群と同程度である。これは、停泊時間が長く、外乱影響の小さい東京湾内を航行する汐路丸と、停泊時間が短く、外乱影響が比較的大きい日本沿岸を走る A 丸の、運航形態の差から説明可能だろう。A 丸は貨物船であるため、排水量(Displacement)とトリム(Trim)の変動が大きく、どちらの項目も推進性能に比較的大きな影響を持っていることが分かる。

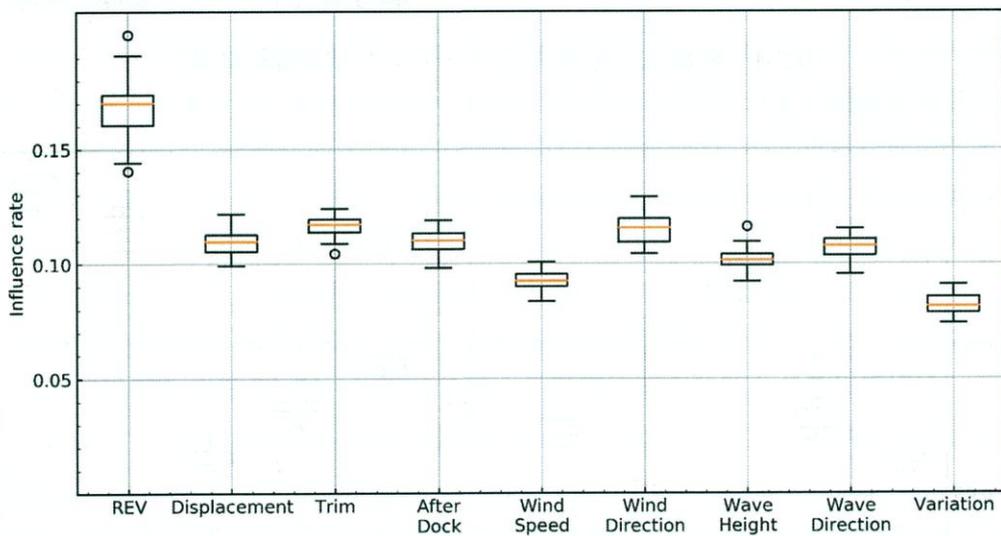


図 5-4 A 丸の軸馬力推定モデルの感度解析結果

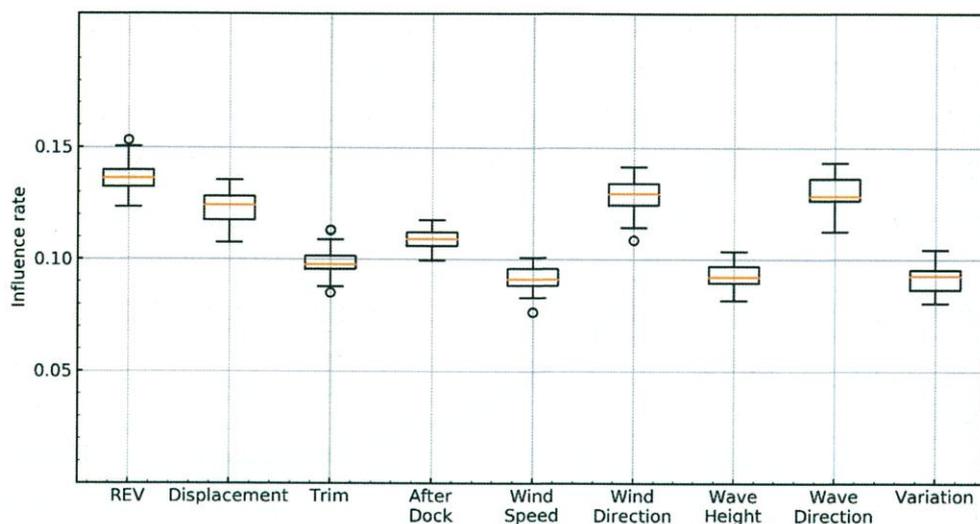


図 5-5 A 丸の対水速力推定モデルの感度解析結果

## 5.5 推進性能推定

### 5.5.1 平水中性能

入力項目のうちのひとつの値を変化させた時に、出力値がどのように変化するか調べる。例えば平水中と仮定して、外乱による影響をないものとし、舵角  $0^\circ$ 、船首方位の変化と対水速力変化もないものとして、船齢と出渠後日数を任意の値に設定する。その条件の下、汐路丸の場合は軸回転数を一定として、翼角と軸馬力、及び翼角と対水速力の関係を調べることで、平水中における推進性能を推定する。A 丸の場合は軸回転数と軸馬力、及び軸回転数と対水速力の関係を調べることで平水中における推進性能を推定することができる。表 5-1 に汐路丸の設定値を、表 5-2 に A 丸の設定値を記載した。汐路丸の設定値において変化させている項目は翼角(CPP)であるが、経年変化の影響を考慮して、船齢(TotalYear)が 24, 27, 30 の 3 ケースの推定値を得た。A 丸の変化させている項目は軸回転数(REV)であるが、排水量とトリムに関して、空船時と満載時の 2 状態について調べた。排水量の具体的な値は本論文に載せないが、空船時の排水量は試運転時と同じ値、満載時の排水量は A 丸の計画満載値である。

表 5-1 及び表 5-2 の設定値を、それぞれの船の軸馬力推定モデルと対水速力推定モデルに入力することで、その状況における軸馬力と対水速力の推定値を得た。図 5-6 に汐路丸の平水中性能推定結果を示す。(a)は対水速力推定モデルを利用して求めた翼角と対水速力の性能曲線であり、(b)は軸馬力推定モデルを利用して求めた翼角と軸馬力の性能曲線である。(c)は、2 つの推定モデルを用いて、任意の翼角における対水速力と軸馬力を求めることで得られた、対水速力と軸馬力の性能曲線である。船齢 24 年時(2011/9)、船齢 27 年時(2014/9)、船齢 30 年時(2017/9)の 3 ケースを、それぞれ緑色、青色、赤色に色分けして描画した。さらに 1987 年の試運転にて行われた速力試験の結果も黒色でプロットした。3 ケースの推定値と速力試験結果は非常に良く一致していることが図 5-6 より分かる。速力試験においては翼角  $21.5^\circ$ (出力 110%)まで行われたが、実際の運航では翼角  $17.5^\circ$ 以上をほとんど使用していないため、翼角  $17.5^\circ$ までをニューラルネットワークに

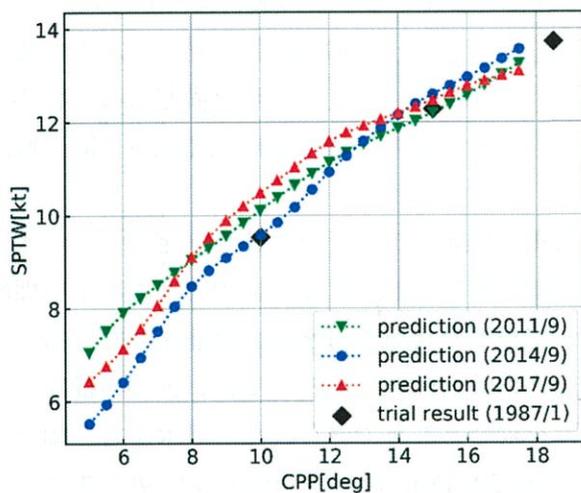
よる推定対象とした。(a)より、翼角に対する対水速力は、3 ケースとも試運転結果より全体的に若干高いことが分かる。(b)より、翼角に対する軸馬力は、翼角 10°では推定値の方が試運転結果より高く、翼角 15°では同程度である。(c)に注目すると、2011 年と 2014 年の性能曲線はほぼ一致しているが、2017 年における性能曲線は全体的に上側にずれており、経年変化影響の可能性がある。経年変化影響に関しては 5.3.3 で詳しく論じる。

表 5-1 汐路丸平水中性能推定の設定値

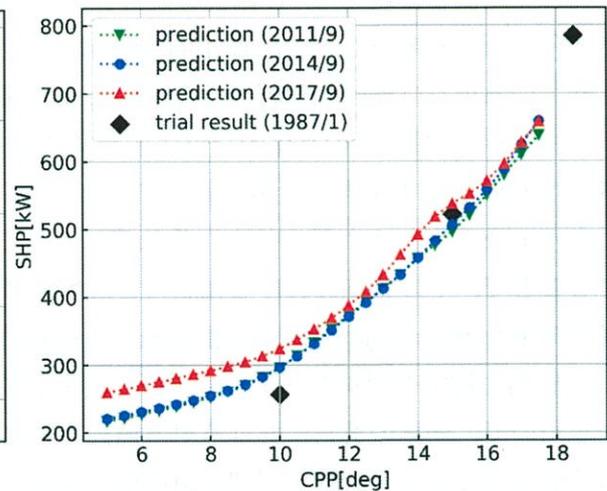
項目名	設定値
HeadingSD	0
REV	300
CPP	5~17.5
RudderSD	0
Rolling	0
Pitching	0
WindSpeed	0
WindDirection	0
Variation	0
TotalYear	24,28,31
AfterDock	0

表 5-2 A 丸平水中性能推定の設定値

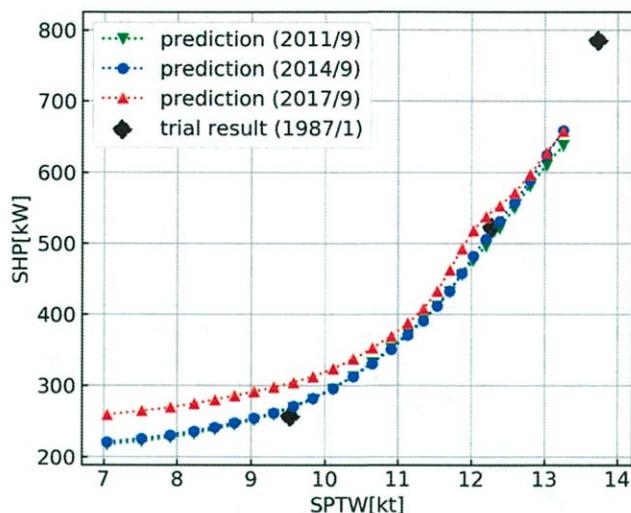
項目名	設定値
REV	100~140
Displacement	Ballast, Full
Trim	2, 0
WindSpeed	0
WindDirection	0
WaveHeight	0
WaveDirection	0
Variation	0
AfterDock	0



(a)翼角-対水速力



(b)翼角-軸馬力



(c)対水速力-軸馬力

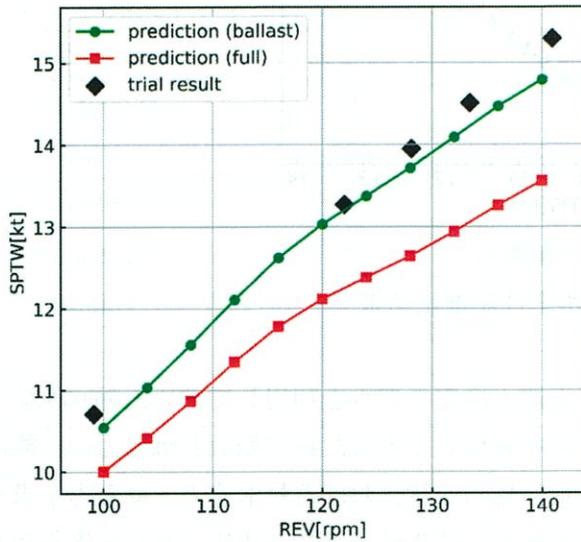
図 5-6 汐路丸の平水中性能推定結果

図 5-7 に A 丸の平水中性能曲線を示す。(a)は対水速力推定モデルを利用して求めた軸回転数と対水速力の性能曲線である。(b)は軸馬力推定モデルを利用して求めた軸回転数と軸馬力の性能曲線である。(c)は、2 つの推定モデルを用いて、任意の軸回転数における対水速力と軸馬力を求めることで得られた、対水速力と軸馬力の性能曲線である。緑色がバラスト状態、赤色が満載状態における推定値を表している。黒色は試運転結果「trial result」と、(c)においてはテイラーチャート等を用いる従来の手法により計算した満載時の性能曲線「existing method」を示している。(c)の「nominal value」とは、計画満載時公称値である。尚、「trial result」及び「existing method」、「nominal value」は、機関馬力に伝達効率 0.96 を乗じて軸馬力とした。

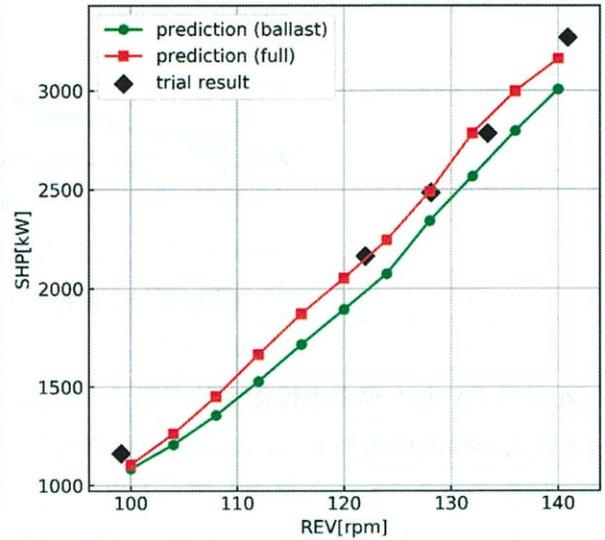
(a)より、バラスト時の軸回転数 120 以上において、対水速力の推定値が試運転結果よりも低いことが分かる。また(b)より、軸回転数に対する軸馬力の推定値が、試運転結果よりも全体的に低いことが分かる。以上より軸回転数を固定した場合、試運転時に比べて対水速力、軸馬力ともに低い推定値となった。

(c)の対水速力と軸馬力の性能曲線に注目すると、バラスト時の推定値と試運転結果とは大方一致しているものの、性能曲線が蛇行しており、満載時の推定値と公称値は乖離していると言える。ニューラルネットワークによる推定性能曲線が蛇行した原因は、サンプルデータへの過学習である。図 5-8 は A 丸モニタリングデータの排水量ヒストグラムであり、満載時の排水量を 100、排水量 0(ton)を 0 として無次元化を行った。満載時の推定を行ったが、モニタリングデータには排水量約 97 までのデータがほとんどであり、排水量 100 のデータは極めて少ない。バラスト時も同様であり、試運転における排水量は 50.2 であるが、ほとんどのモニタリングデータは排水量 52 以上である。従って、A 丸のバラスト時と満載時の性能推定結果は、入力ベクトル空間における、教師データが極めて疎な領域からニューラルネットワークが学習した結果である。第 4 章においてニューラルネットワークの適切な表現力を探索的に求めたが、それはデータ全体に対して適切な表現力という意味であり、このように入力ベクトル空間において教師データが疎な領域では過学習となり得る。教師データが疎な領域でも汎化性能を獲得するにはネットワークの表現力を落

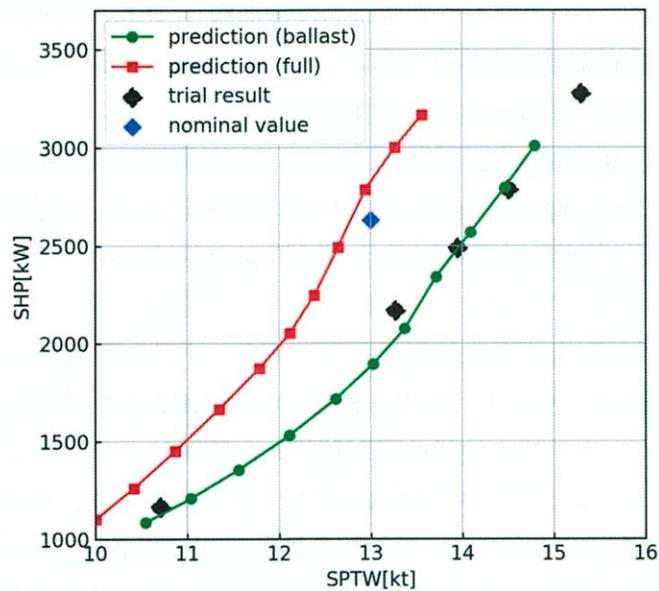
とす必要があるが、それはデータ全体に対してアンダーフィット（未学習）なモデルとなり推定精度は低下する。従って、データ全体に対する推定精度と、教師データが疎な領域における汎化性能はトレードオフの関係にある。どちらを重視してモデルを設計するか、推定モデルの使用目的に応じて検討すべきだろう。



(a)軸回転数-対水速度



(b)軸回転数-軸馬力



(c)対水速度-軸馬力

図 5-7 A 丸の平水中性能推定結果

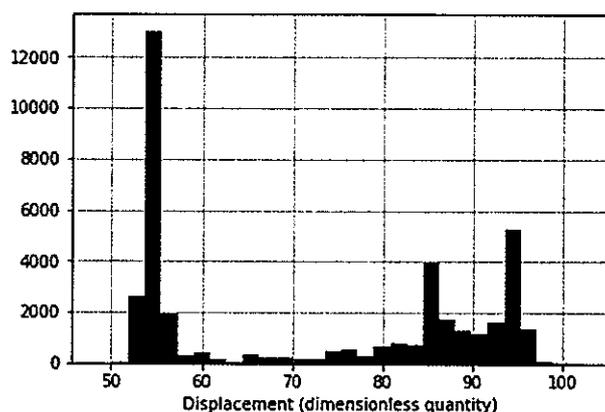


図 5-8 A 丸の排水量ヒストグラム(無次元量へ変換済み)

### 5.5.2 経年変化と生物汚損による影響

汐路丸と A 丸の経年変化及び生物汚損による推進性能への影響を調査する。表 5-3 は、汐路丸の推定における設定値である。翼角が 9°, 13°, 17°の 3 状態に関して、船齢を 24~31 年、出渠後日数を 30 日ごとに 0~330 日の範囲で変化させて軸馬力と対水速力の推定を行った。翼角の設定値を 9°, 13°, 17°の 3 状態に絞った理由は、汐路丸がこれらの翼角を頻繁に利用するためである。図 5-8 と図 5-9 が、表 5-3 の設定値における軸馬力と対水速力の推定結果である。図 5-8 の軸馬力推定結果より、毎年入渠するたびに推進性能が改善していることが明確に分かる。対水速力は推定値の分散が大きく、軸馬力ほど明確な傾向はないが、出渠から日数が経つにつれ船速が低下する傾向にあると言える。次に、具体的に年間何%の割合で性能が変化しているか調査する。

表 5-3 汐路丸の経年変化と生物汚損影響推定における設定値

項目名	設定値
HeadingSD	0
REV	300
CPP	9, 13, 17
RudderSD	0
Rolling	0
Pitching	0
WindSpeed	0
WindDirection	0
Variation	0
TotalYear	24~31
AfterDock	0~350

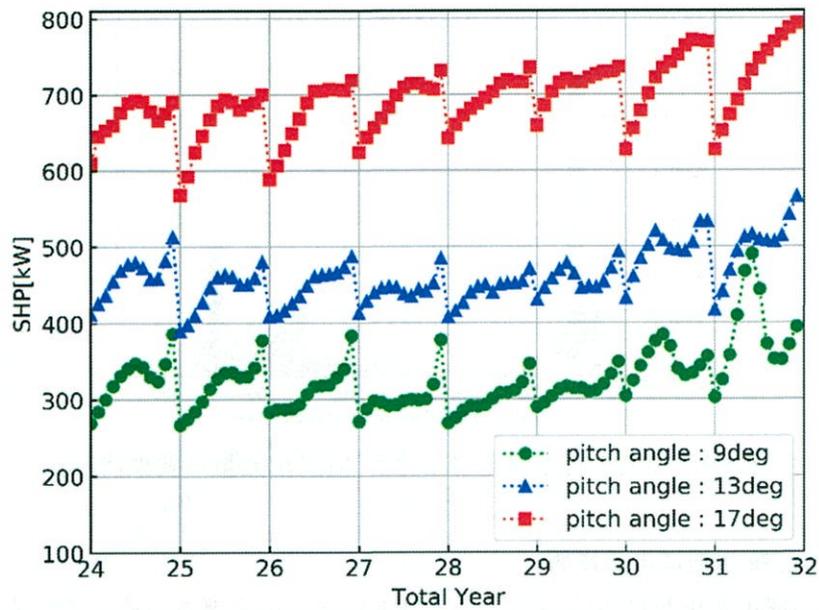


図 5-9 経年変化影響と生物汚損影響による汐路丸の軸馬力変化

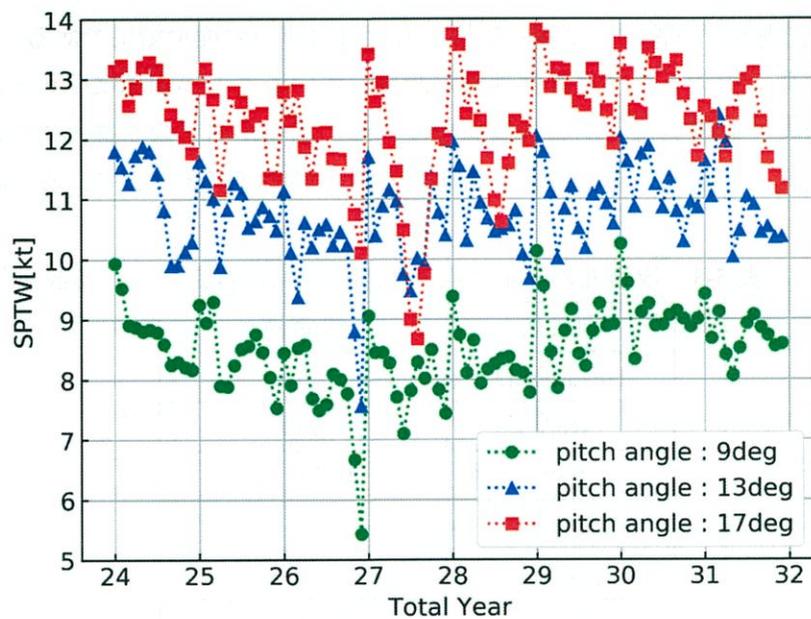


図 5-10 経年変化影響と生物汚損影響による汐路丸の対水速力変化

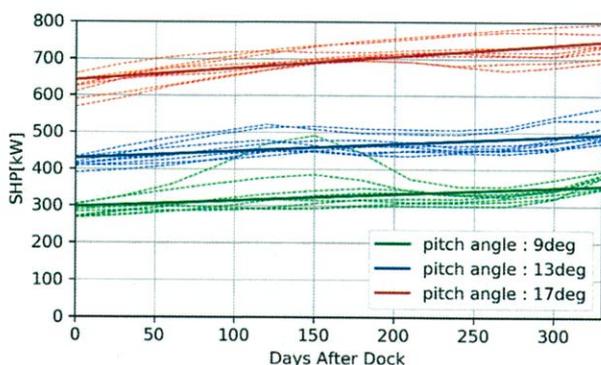
出渠後日数が経過するにつれ推進性能が悪化する傾向にあることを、図 5-8 及び図 5-9 で確認した。次に、具体的に年間何%の割合で、推進性能が生物汚損影響により悪化しているか調査する。調査には出渠後日数を変数とする一次回帰を利用して、全ての年の推定結果から平均的な生物汚損による性能悪化の割合を求める。図 5-11 は出渠後日数と軸馬力・対水速力の変動を示しており、点線が各年のニューラルネットワークの推定値、実線は最小二乗法により求めたニューラルネットワークの推定値 8 年分の回帰直線である。出渠後日数の増加とともに、軸馬力は増加、対水速力は減少する傾向にあることが分かる。表 5-4 に調査結果として、回帰直線の傾きと切片、

360日経過時の性能変化割合を示す。性能変化割合はプラスならば当該値の上昇を、マイナスならば当該値の減少を意味する。軸馬力の生物汚損影響に関しては、翼角による差が大きく、翼角9°では年間で21%程度軸馬力が上昇する結果となった。翼角13°、17°においても、軸馬力が年間で17%程度上昇するため、比較的大きな生物汚損影響を受けていることが分かる。対水速力に関しては、いずれの翼角においても12%程度の低下を示しており、軸馬力ほど大きくはないが、一般商船よりも大きく性能悪化していることを確認した。これは、汐路丸の停泊時間が長いことが原因と考えられる。

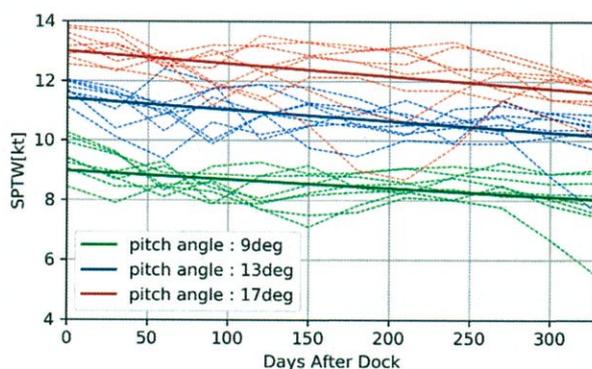
ところで、図5-11(a)より生物汚損影響による軸馬力上昇は、出渠後日数と単純に比例するとは限らないことが読み取れる。津金らは、出渠後日数よりも積停泊日数が生物汚損影響の実態を正確に表すと報告している<sup>(5-5)</sup>。ニューラルネットワークの説明変数に累積停泊日数等を加えることで推定精度が向上するか、今後の検討課題である。

表 5-4 汐路丸の出渠後日数経過に伴う性能変化

	回帰直線の傾き	回帰直線の切片	360日経過時の性能変化割合
軸馬力(翼角 9°)	0.174	297.6	21.1%
軸馬力(翼角 13°)	0.196	428.7	16.5%
軸馬力(翼角 17°)	0.315	642.0	17.7%
対水速力(翼角 9°)	-0.003	9.0	-11.5%
対水速力(翼角 13°)	-0.004	11.4	-11.9%
対水速力(翼角 17°)	-0.004	13.0	-11.7%



(a)軸馬力



(b)対水速力

図 5-11 汐路丸の生物汚損影響

次に、汐路丸の経年変化影響に関して分析する。図5-9及び図5-10は、生物汚損影響による推定値の分散が大きく、推進性能の経年変化を確認することが難しい。そこで各年の推定値の平均をとることで、生物汚損影響が毎年同じ程度であるという前提のもと、経年変化影響の有無を調査した。図5-12が調査結果である。(a)の軸馬力の推定値平均に関しては増加傾向にあるが、(b)の対水速力の推定値平均に関しては単調減少ではなく、船齢26,27年あたりを境に減少傾向から増加傾向に転じている。原因については不明だが、生物汚損影響が年によって異なった可能性や、

防汚塗料の変更の可能性等が考えられる。以上より本研究の分析だけでは、汐路丸の対水速力に関して、経年変化影響の有無を判断することはできない。尚、軸馬力に関しては増加傾向にあると言え、経年変化影響は年間1~2%程度と推定できる。

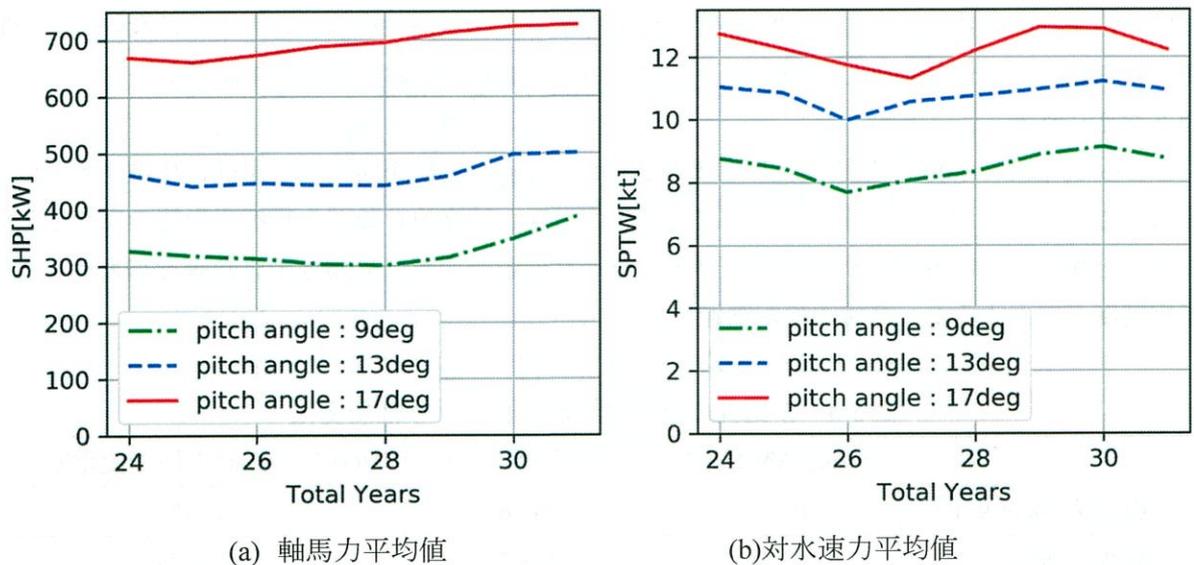


図 5-12 汐路丸の各年の推定値平均

表 5-5 は A 丸の生物汚損影響推定における設定値である。A 丸はモニタリングデータの期間が 2 年弱と、経年変化影響を調べるには短いため、生物汚損影響の推定のみを行った。出渠後 0 日、150 日、300 日について推定を行った。表 5-5 の排水量は無次元量に換算した値である。5.3.2 の図 5-8 の排水量ヒストグラムより、データ数が十分に多い、排水量 54.5(バラスト時に相当)と排水量 93.4(満載時に相当)の 2 状態に関して調査した。表 5-5 の設定値を、軸馬力推定モデルと対水速力推定モデルに入力することで、軸回転数を固定した場合の軸馬力と対水速力の変動を求めた。それらの結果から、A 丸の対水速力と軸馬力の性能曲線の変化を求め、図 5-13 に示した。

出渠後日数の経過により、性能曲線が全体的に左上にずれる傾向にある。しかしその割合は軸回転数によって異なり、ほとんど変化しない場合もあれば、大きく変化する場合もある。図 5-13 の性能曲線は、軸回転数が 100~140rpm の範囲を 5rpm 刻みで推定した結果であるから、各性能曲線に関して、対水速力の小さい方から 5 番目が 125rpm における推定結果である。125rpm では生物汚損影響が比較的大きく、300 日間で対水速力は 1%程度、軸馬力は 3~4%程度悪化すると推定された。これは軸回転数を 125rpm で固定した場合であるから、線形補完により対水速力を固定した場合、軸馬力はバラスト時で約 7.3%の増加、満載時で約 5.6%増加した。軸回転数が 125rpm よりも大きい場合、性能悪化の割合は 125rpm 時よりも小さいことが図 5-13 より読み取れる。

表 5-5 A 丸の生物汚損影響推定における設定値

項目名	設定値
REV	100~140 (5rpm 刻み)
Displacement	54.5, 93.4
Trim	0
WindSpeed	0
WindDirection	0
WaveHeight	0
WaveDirection	0
Variation	0
AfterDock	0, 150, 300

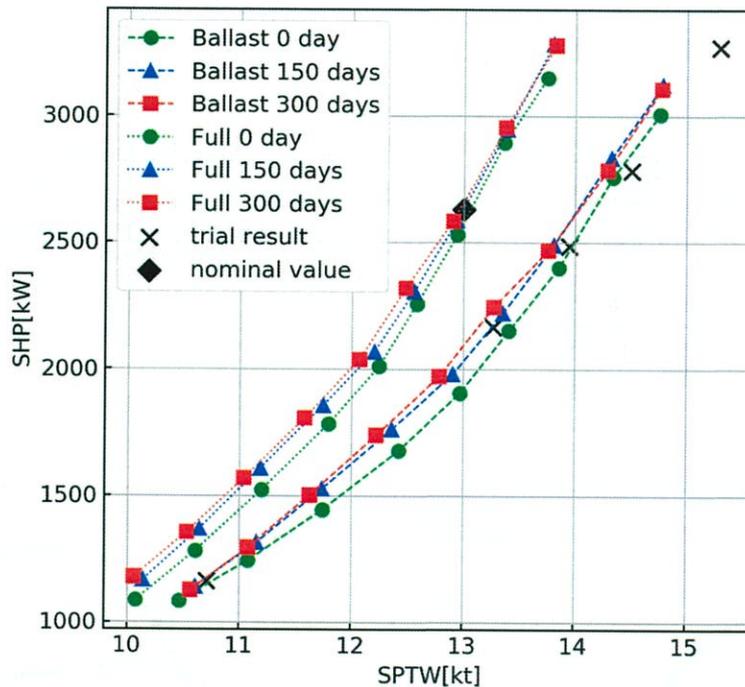


図 5-13 生物汚損影響による A 丸の性能曲線の変化

### 5.5.3 海気象影響

翼角または軸回転数を一定としたうえで、風速・風向及び波高・波向きを変化させることで外乱による軸馬力・対水速力の変化を調べる。汐路丸の波浪に関するデータはないので、汐路丸に関しては風圧抵抗による影響のみを調べる。表 5-6 及び表 5-7 はそれぞれ汐路丸と A 丸の軸馬力推定モデル、対水速力推定モデルへの入力とする設定値である。風速に関しては 3, 6, 9, 12m/s に関して、風向は正船首を 0°として 0~180°の範囲を調べた。風向が左舷側の場合と右舷側の場合で結果が若干異なるので、両舷の推定値を平均した。図 5-14 が汐路丸の、図 5-15 が A 丸の風圧抵抗による影響の推定結果である。

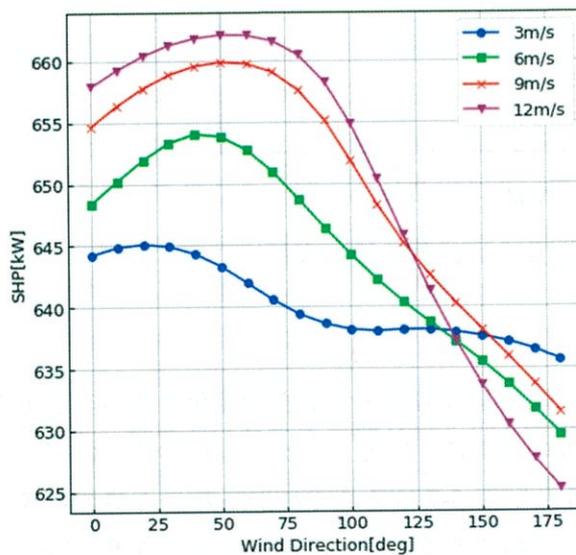
汐路丸は真風向 20~50°の時に軸馬力が最も上昇し、対水速力はいずれの風速においても真風向 0°の時に最も低下する。A 丸の場合はいずれの風速においても、真風向 0°で軸馬力が最も上昇し、対水速力は最も低下することを確認した。以上の結果の妥当性について、ランダムフォレストによる推定値と比較することで検証を試みたところおおよそ一致した。また、物理的特性とも矛盾がないと言える。汐路丸とA丸ではグラフの形状が異なるが、これは両船の水面上の形状差と、ニューラルネットワークの表現力の差が主な原因と考えられる。

表 5-6 汐路丸の風圧抵抗推定における設定値

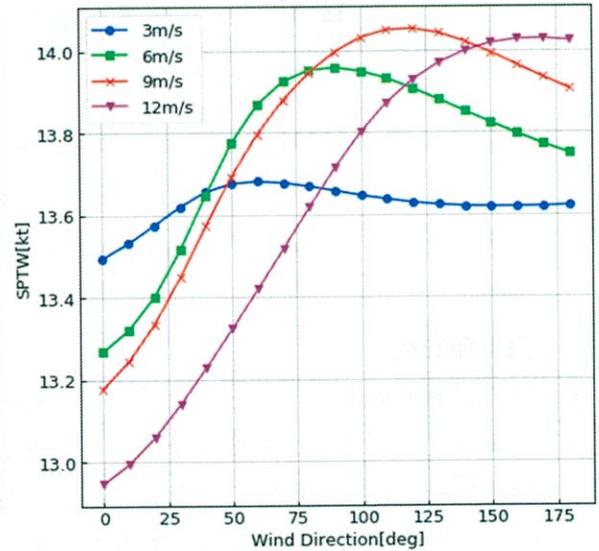
項目名	設定値
HeadingSD	0
REV	300
CPP	17
RudderSD	0
Rolling	0
Pitching	0
WindSpeed	3, 6, 9, 12
WindDirection	0~180
Variation	0
TotalYear	28
AfterDock	0

表 5-7 A 丸の風圧抵抗推定における設定値

項目名	設定値
REV	127
Displacement	93.4
Trim	0
WindSpeed	3, 6, 9, 12
WindDirection	0~180
WaveHeight	0
WaveDirection	0
Variation	0
AfterDock	0

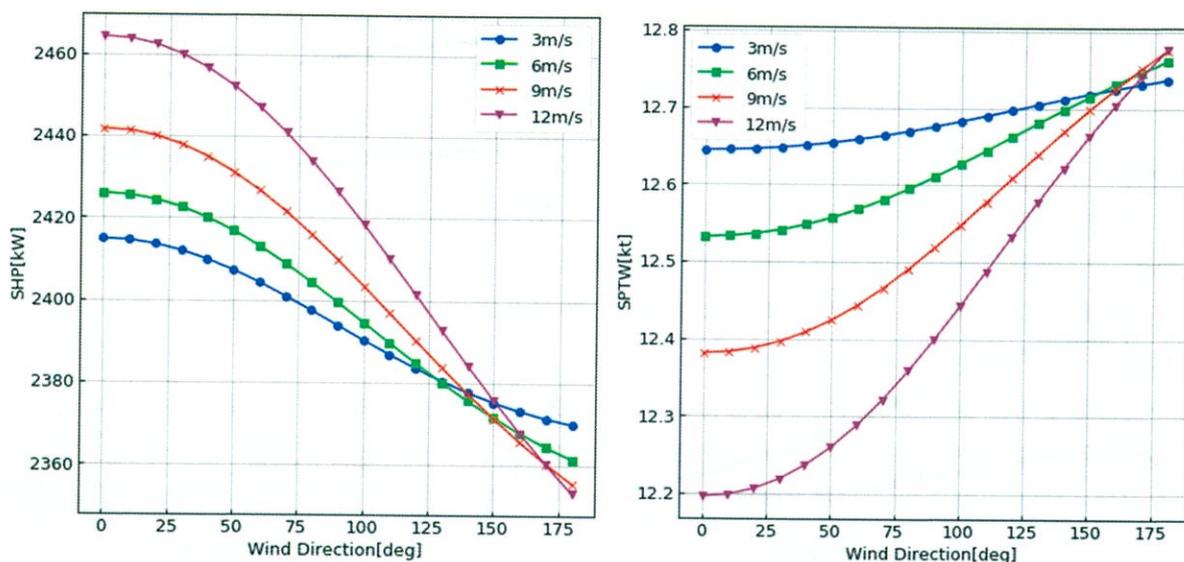


(a)軸馬力



(b)対水速力

図 5-14 風圧抵抗による汐路丸の推進性能への影響



(a)軸馬力

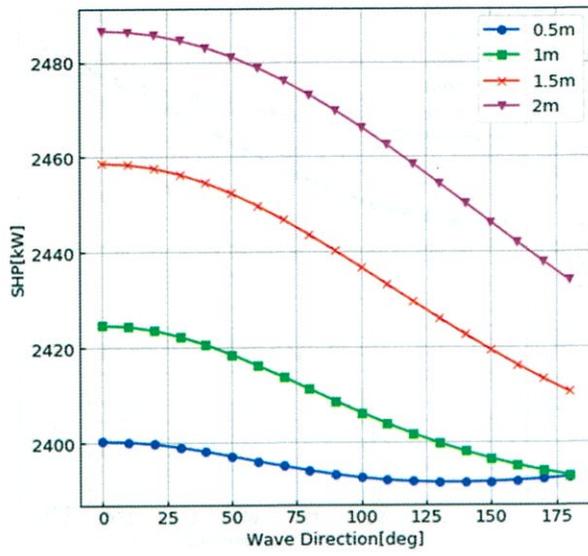
(b)対水速力

図 5-15 風圧抵抗による A 丸の推進性能への影響

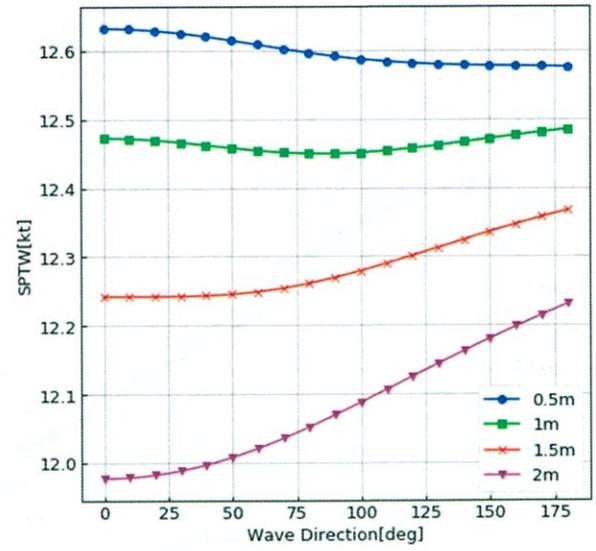
表 5-8 は A 丸の波浪抵抗推定における設定値である。軸馬力推定モデルと対水速力推定モデルに設定値を入力することで、それぞれの推定値を得た。図 5-16 が推定結果である。波高が高いほど、また、波向きが船首方位に近いほど軸馬力は上昇し、対水速力は低下する傾向にあることが分かる。以上の結果の妥当性について、ランダムフォレストによる推定値と比較することで検証を試みたところおおよそ一致した。また、物理的特性とも矛盾がないと言える。但し、波高・波向きは計測値でなく GPV の予測値を使用しているため、推定値は GPV の予測誤差を含むことに留意する必要がある。

表 5-8 A 丸の波浪抵抗推定における設定値

項目名	設定値
REV	127
Displacement	93.4
Trim	0
WindSpeed	0
WindDirection	0
WaveHeight	0.5, 1.0, 1.5, 2.0
WaveDirection	0~180
Variation	0
AfterDock	0



(a)軸馬力



(b)対水速力

図 5-16 波浪抵抗による A 丸の推進性能への影響

## 第6章 結論

本論文では初めに、再構築誤差を利用することで、マハラノビス距離を用いた手法よりも有効に、定常運航から外れたデータを検出できることを示した。

そして次に、訓練データと評価データを用いて、適切な表現力を持つニューラルネットワークを、チューニング作業を経て作成した。複数の訓練済みニューラルネットワークを用いてバギングアルゴリズムを適用することで、テストデータの軸馬力と対水速力を、高精度で回帰予測できることを示した。

また、ロバスト性と説明性を調査するために、感度解析と個々の入力値を変化させた場合の出力の変化を調べた。感度解析結果より、出力に対する影響の大きい入力項目や、影響が小さく除外可能な入力項目を推定することができた。また、軸馬力推定モデルと対水速力推定モデルを用いて、汐路丸と内航貨物船の平水中性能を推定したところ、速力試験結果と一致した。また、実海域性能に関して、経年変化影響、生物汚損影響、海気象影響を推定したところ、船舶工学の知見や物理的特性と一致する結果となった。以上より、本研究において作成した推定モデルは、未知データに対する高い予測精度を持ち、且つ、ロバスト性と説明性も併せ持つと言える。

今後の課題は、減速航海やウェザールーティングでの応用に向けてオンライン学習を導入し、時々刻々と変化する推進性能の予測精度を高めることである。また、本研究において作成した推定モデルは、24の比較的規模の大きいニューラルネットワークから構成されているため、計算コストと外挿性能、説明性に課題が残る。そこで本研究の推定モデルを教師モデルとして、より小規模なモデルを作成する「知識の蒸留」を行うか、推定モデルの出力値から近似式を作成することが検討される。

## 謝辞

本論文は、東京海洋大学大学院海洋科学技術研究科海運ロジスティクス専攻在学中に、庄司るり先生のご指導のもと執筆した論文です。研究を進めるにあたり、多くの方々からご指導・ご協力頂きましたこと、心より感謝申し上げます。

庄司先生には、学部4年時の卒業研究から、修士1年時の16th IAIN (International Association of Navigation) World Congress 2018 発表、修士2年時の日本航海学会秋季講演会発表と、長きにわたり大変お世話になりました。庄司先生の適切な指摘と、日々の親身なご指導に、心より感謝申し上げます。

本研究は、マリンテクノロジストの武隈克義様の示唆により始まりました。武隈氏には、終始、貴重なアイデアと適切な助言を頂き、私が進むべき方向を教えてくださいました。ここに深く感謝致します。また、マリンテクノロジストの山崎英津子様、佐久間昌様を初めとする皆様にも、研究に対してご理解頂くとともに大変お世話になりました。

汐路丸の鹿島船長を初めとする乗組員の皆様には、汐路丸の詳細な情報を教えてくださいました。ご協力ありがとうございました。

研究室の先輩である北澤氏、大家氏、周氏、白井氏、加藤氏、清水氏、鱸居氏には、研究室のことから研究内容まで多くの助言を頂きました。また、同期の島田君、門脇君や、後輩達とは一緒に切磋琢磨できて良い刺激となりました。そして、博士後期課程のキム・ヒョンギ氏とは短い間でしたが、楽しい時間を過ごすことができました。皆様ありがとうございました。

最後になりますが、東京海洋大学越中島キャンパスでの6年間にご指導頂いた多くの先生方に、心より感謝申し上げます。

## 参考文献

### 第1章

- (1-1) 気象庁「IPCC 第5次評価報告書」  
<https://www.data.jma.go.jp/cpdinfo/ipcc/ar5/index.html>, 2019/11/23
- (1-2) 環境省「気候変動適応計画について」  
[http://www.env.go.jp/earth/gaiyou\\_r.pdf](http://www.env.go.jp/earth/gaiyou_r.pdf), 2019/11/23.
- (1-3) IPCC, Global Warming of 1.5°C Special Report Summary for Policymakers, 2018  
[https://www.ipcc.ch/site/assets/uploads/sites/2/2019/05/SR15\\_SPM\\_version\\_report\\_LR.pdf](https://www.ipcc.ch/site/assets/uploads/sites/2/2019/05/SR15_SPM_version_report_LR.pdf),  
2019/11/23.
- (1-4) IMO HP  
<http://www.imo.org/en/MediaCentre/PressBriefings/Pages/06GHGinitialstrategy.aspx>, 2019/11/22.
- (1-5) 国土交通省海事局 国際海運からの温室効果ガス削減対策 (IMO による審議の動向)  
<http://www.mlit.go.jp/common/001250110.pdf>, 2019/11/23.
- (1-6) 日本海事新聞 GHG 削減に向けた船用代替燃料の検討動向 -欧州での分析事例を参考に-  
<http://www.jpmac.or.jp/img/research/pdf/E201810.pdf>, 2019/11/22.
- (1-7) 斎藤英明・保坂達也：環境保全の観点からの必要性—国際海運からの O2 排出削減にかかわる IMO 審議動向について—, 実海域における実船性能モニタリング, 日本船舶海洋工学会・運動性能研究会シンポジウム, 2015.2.
- (1-8) 内藤林：実海域船舶性能評価の現状について, 実海域における船舶性能に関するシンポジウム, 日本造船学会・試験水槽委員会シンポジウム, 2003.12.
- (1-9) 西川栄一・Biyu Wan・佐藤睦・内田誠：アログデータを利用した就航中船舶の推進性能の分析について, 日本マリンエンジニアリング学会誌, 第37巻, 第11号, 2002.11.
- (1-10) Masaru Tsujimoto・Hideo Orihara: Performance prediction of full-scale ship and analysis by means of onboard monitoring, Journal of Marine Science and Technology (2019)24, pp.16-33, 2018.1.
- (1-11) 櫻田顕子・黒田麻利子・辻本勝・杉本義彦・長谷川健：実運航性能における船速—回転数—主機出力関係のモデル化, 日本船舶海洋工学会論文集, vol.25, pp.39-46, 2017.3.
- (1-11) 小林充・加納敏幸：船舶運航時の燃料消費量簡易推定法について, 日本船舶海洋工学会論文集, vol.6, pp.411-412, 2008.4.
- (1-12) 小林充・加納敏幸・松浦邦明・佐藤淑子：環境調和型航海支援システムのための船舶性能推定と実証実験の検証, 日本船舶海洋工学会講演論文集, 2011.5.
- (1-13) 水谷直樹・木戸川充彦：本船性能の見える化と最適運航支援システムについて, 日本マリンエンジニアリング学会誌, 第49巻, 第5号, pp.48-53, 2014.
- (1-14) 阿南泰三・樋口博之・濱田直希：運航ビッグデータと人工知能を活用した船舶の燃費改善と CO2 排出量の削減, FUJITSU.68, 2, pp.22-27, 2017.3.
- (1-15) 萩原秀樹・鈴木るり・杉崎昭生：高層気象パターンに基づくウェザールーティング-ニューラルネットワークによる航路選定-, 日本航海学会論文集, 第93巻, pp.191-199, 1995.
- (1-16) 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) —中高速船

の増派抵抗推定ツールの構築一, 日本造船学会論文集, 第 183 号, pp.91-100, 1998.

- (1-17) 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, 西部造船学会会報, 第 99 号, pp.1-11, 2000
- (1-18) 金井健: ニューラルネットワークを利用した船舶の推進性能推定, 博士学位論文, 2010.6.
- (1-19) 石井幹久・庄司るり・武隈克義: ニューラルネットワークを用いた実海域における船舶推進性能の推定, 日本航海学会講演予稿集, vol.7(2019)No.2, 2019.10.
- (1-20) Road Map for Choosing Between Statistical Modeling and Machine Learning, Statistical Thinking <https://www.fharrell.com/post/stat-ml/>, 2020/1/30.
- (1-21) Galit Shmueli: To Explain or to Predict?, Statistical Science, vol.25, No.3, pp.289-310, 2010, (DOI: 10.1214/10-STS330)

## 第 2 章

- (2-1) 志水清孝: ニューラルネットと制御, コロナ社, 2002.
- (2-2) 麻生英樹・安田宗樹・前田新一・岡野原大輔・岡谷貴之・久保陽太郎・ボレガラダヌシカ: 深層学習, pp.91,127,142, 近代科学社, 2015.
- (2-3) Trevor Hastie・Robert Tibshirani・Jerome Friedman: 統計的学習の基礎 データマイニング・推論・予測, 共立出版, 2014.
- (2-4) Diederik P. Kingma and Jimmy Lei Ba: ADAM: A Method for Stochastic Optimization, conference paper at the 3rd ICLR, 2015.5.
- (2-5) Andrew Ng: Machine Learning, coursera, Advice for Applying Machine Learning, <https://www.coursera.org/learn/machine-learning#about>, 2020/1/30.
- (2-6) IHI 船舶設計部: 汐路丸完成図書, 1987.2
- (2-7) Leo Breiman: Bagging Predictors, Machine Learning, vol.24, issue 2, pp.123-140, 1996.8.

## 第 3 章

- (3-1) 櫻田麻由・矢入健久: オートエンコーダを用いた次元削減による宇宙機の異常検知, 第 28 回人工知能学会全国大会, 2014.5.
- (3-2) 井出剛・杉山将: 異常検知と変化検知, pp.15-21, 講談社, 2015.
- (3-3) G. E. Hinton and R. R. Salakhutdinov: Reducing the Dimensionality of Data with Neural Networks, SCIENCE, vol.313, pp.504-507, 2006.6.
- (3-4) Yan Xia and Xudong Cao, Fang Wen, Gang Hua, Jian Sun: Learning Discriminative Reconstructions for Unsupervised Outlier Removal, 2015 ICCV, 2015.12, (DOI:10.1109/ICCV.2015.177).  
Leo Breiman: Bagging Predictors, Machine Learning, vol.24, issue 2, pp.123-140, 1996.8.

## 第 4 章

- (4-1) Leo Breiman: Random Forests, Machine Learning, vol.45, pp.5-32, 2001.
- (4-2) Trevor Hastie・Robert Tibshirani・Jerome Friedman: 統計的学習の基礎 データマイニング・推論・予測, pp.348-351, 共立出版, 2014.

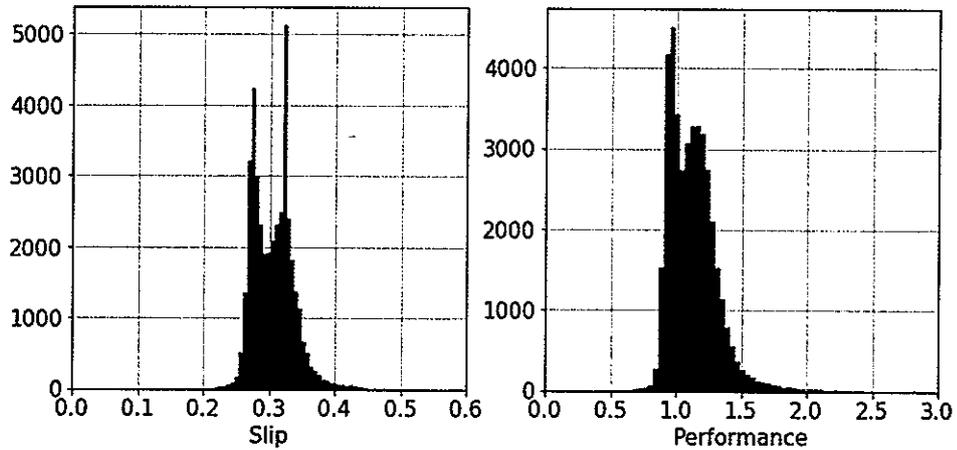
## 第5章

- (5-1) 繁樹算男：ベイズ統計入門，東京大学出版会，pp.1-10，1985.
- (5-2) AI プロダクト品質保証ガイドライン，pp.23-36，AI プロダクト品質保証コンソーシアム，2019.5.
- (5-3) David Gunning, Explainable Artificial Intelligence (XAI),  
<https://www.darpa.mil/program/explainable-artificial-intelligence>, 2020/1/20.
- (5-4) P. Hajela and Z.P. Szewczyk : Neurocomputing Strategies in Structural Design - on Analysing Weights of Feedforward Neural Networks, Structural Optimization 8, pp.236-241, 1994.
- (5-5) 津金正典・金子仁・伊藤格：長期滞船が船体汚損に与える影響に関する研究，日本航海学会論文集，vol.121，pp.69-76，2009.9.

## Appendix.1 A丸の外れ値除外結果

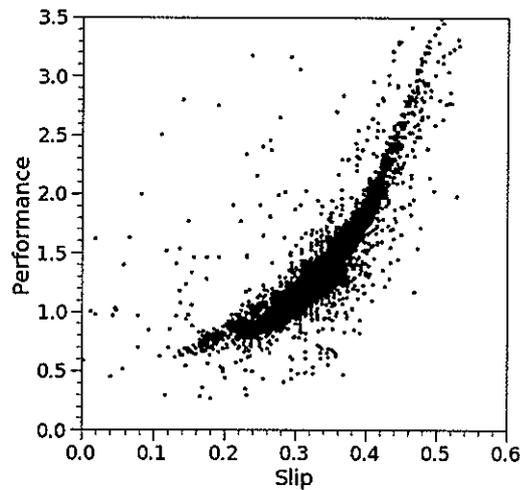
### 1.1 マハラノビス距離による外れ値検出

A丸の「Slip」と「Performance」のヒストグラムと散布図を図A.1-1に示す。図A.1-1(a), (b)より、両指標は正規分布から外れている。汐路丸と同様に「Performance」の分散が大きく、最頻値よりも大きい値が多いために、「Performance」の分布は右側の裾野が長い。図A.1-2は軸馬力、軸回転数、対水速力の散布図であり、低速域において軸馬力と軸回転数の分散が大きいことが分かる。これが、「Performance」の分布の右側の裾野が長い原因だと考えられる。



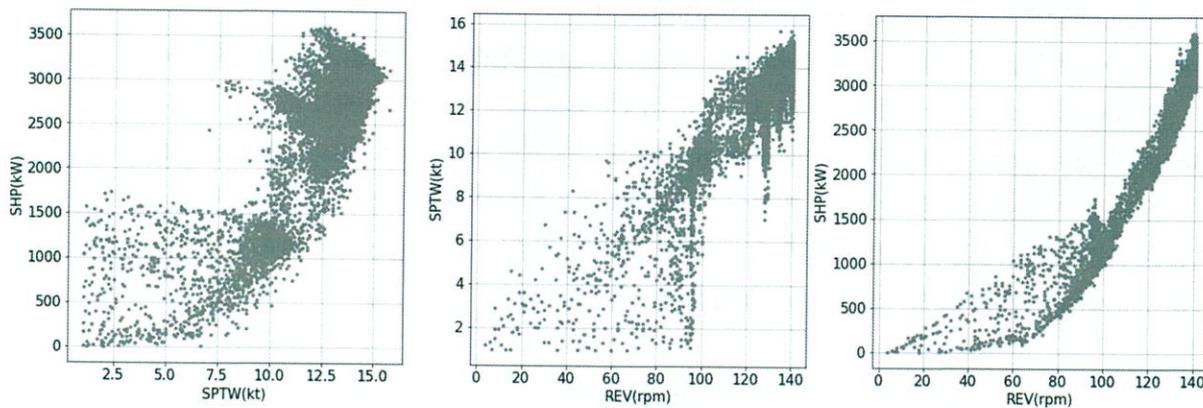
(a) 「Slip」のヒストグラム

(b) 「Performance」のヒストグラム



(c) 「Slip」と「Performance」の散布図

図A.1-1 A丸の「Slip」と「Performance」のヒストグラム及び散布図



(a)対水速力と軸馬力 (b)軸回転数と対水速力 (c) 軸回転数と軸馬力

図 1-2 A 丸の対水速力，軸回転数，軸馬力の散布図

A 丸も汐路丸と同様に，マハラノビス距離計算に利用する指標が正規分布から外れているが，実験的にマハラノビス距離により外れ値検出を行った．図 A.1-3 は異常度のヒストグラムである．外れ値の割合を 1%と仮定した場合，正常値と外れ値の閾値は 12.360 と求めた．図 A.1-4 に外れ値を除外した結果として，正常値と外れ値の分布の差を散布図により示す．

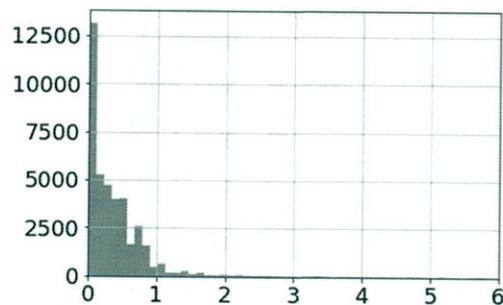
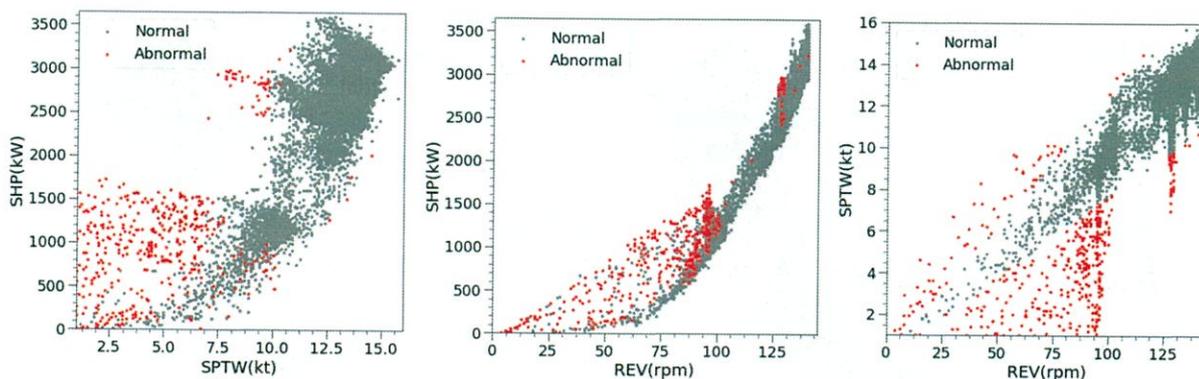


図 A.1-3 A 丸の異常度のヒストグラム



(a) 対水速力と軸馬力 (b) 軸回転数と対水速力 (c) 軸回転数と軸馬力

図 A.1-4 A 丸のマハラノビス距離による外れ値検出結果

## 1.2 次元削減後の再構築誤差を用いた外れ値検出

A 丸の再構築誤差計算に用いる項目は「軸馬力, 軸回転数, 対水速力, 排水量」の4項目である。利用したネットワーク構造を表 A.1-1 に示す。ネットワークの訓練においては, バッチサイズ 256, エポック数 60, 訓練データ数 32826, 評価データ数 8207 とした。学習曲線を図 A.1-5 に示す。各項目の再構築誤差の分散 (スケールを標準化済み) を表 A.1-2 に示す。異常度のヒストグラムを図 A.1-6 に示す。外れ値の割合を 1% と仮定した場合, 正常値と外れ値の閾値が 0.734 と求めた。正常値の密度分布と異常度の分布を図 A.1-7 に示す。

表 A.1-1 A 丸の再構築誤差計算に用いるネットワーク

	入力層	第1中間層	第2中間層	第3中間層	出力層
ノード数	4	4	3	4	4

表 A.1-2 各項目の再構築誤差の分散

	軸馬力	軸回転数	対水速力	排水量
再構築誤差の分散	0.008	0.043	0.007	0.003

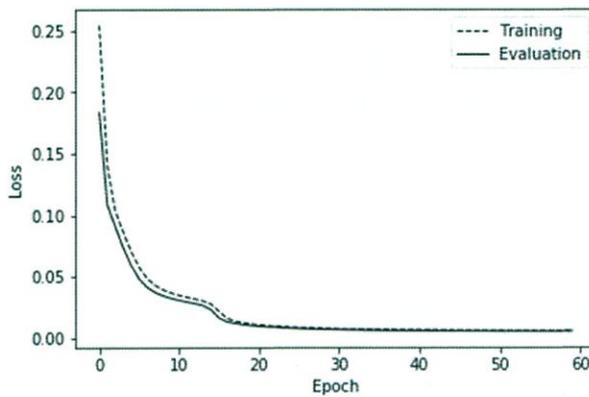


図 A.1-5 オートエンコーダ学習曲線

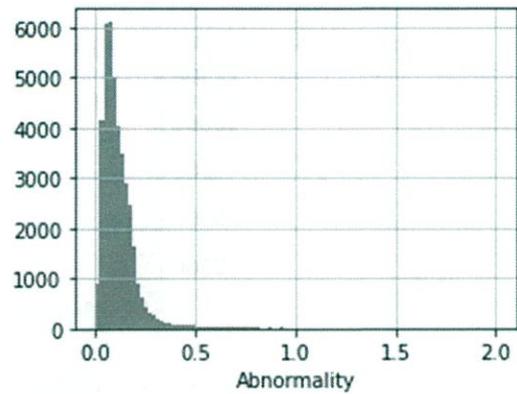
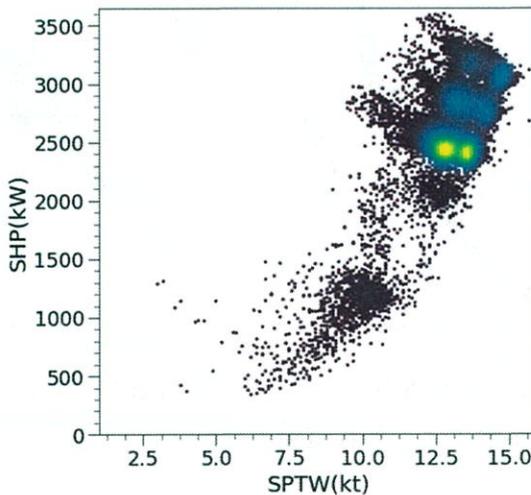
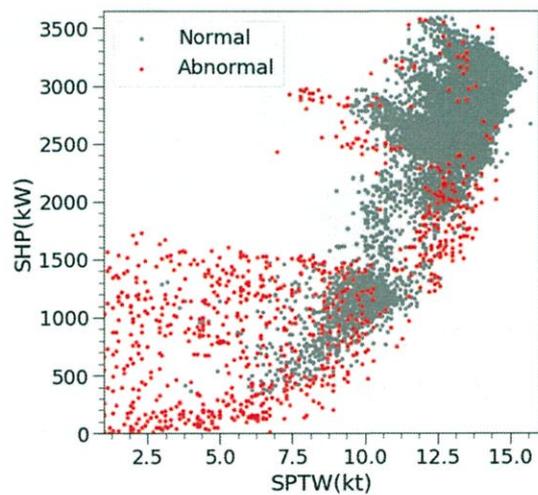


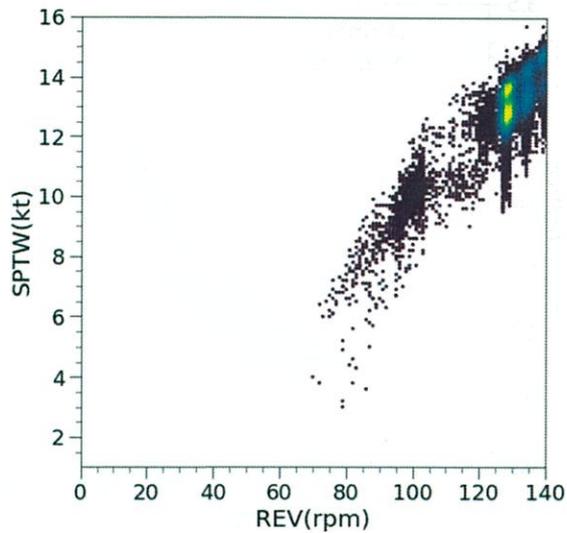
図 A.1-6 再構築誤差による異常度



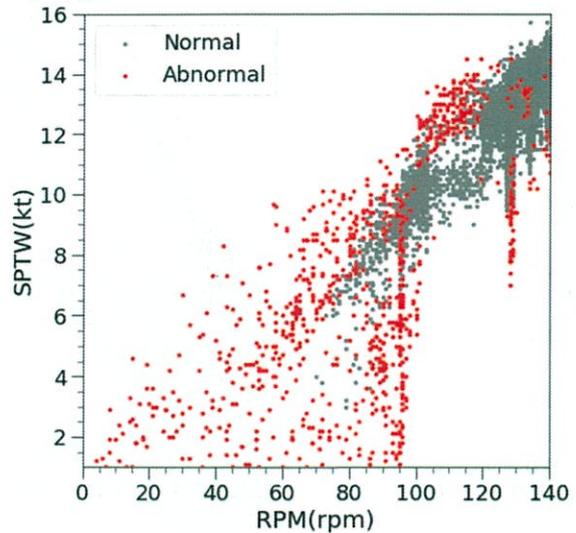
(a)対水速力と軸馬力-正常値



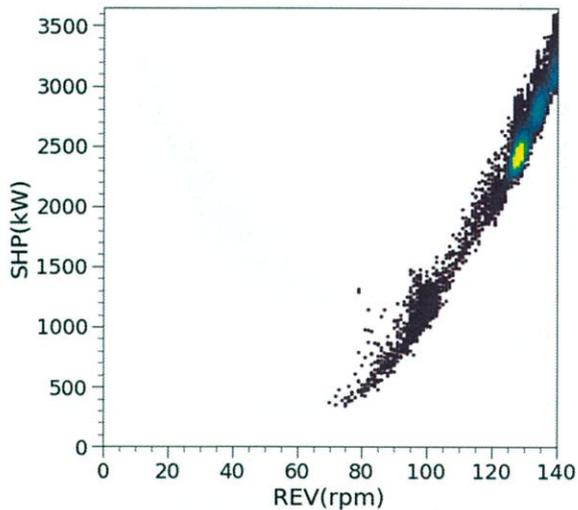
(b)対水速力と軸馬力-外れ値



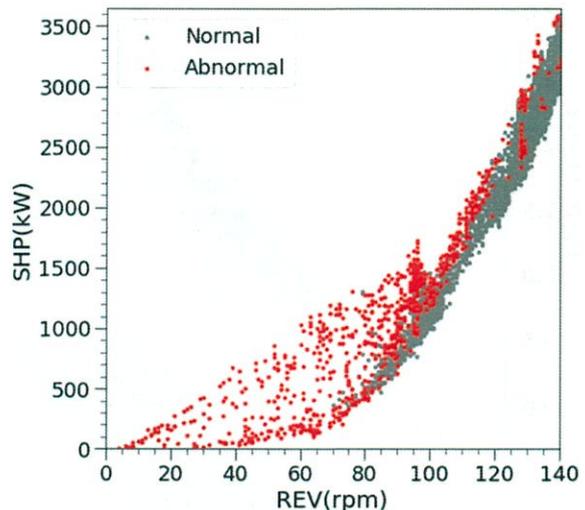
(c) 軸回転数と対水速度-正常値



(d) 軸回転数と対水速度-外れ値



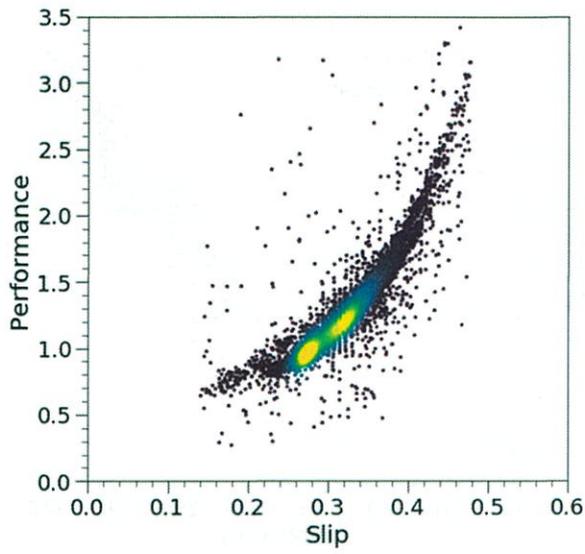
(e) 軸回転数と軸馬力-正常値



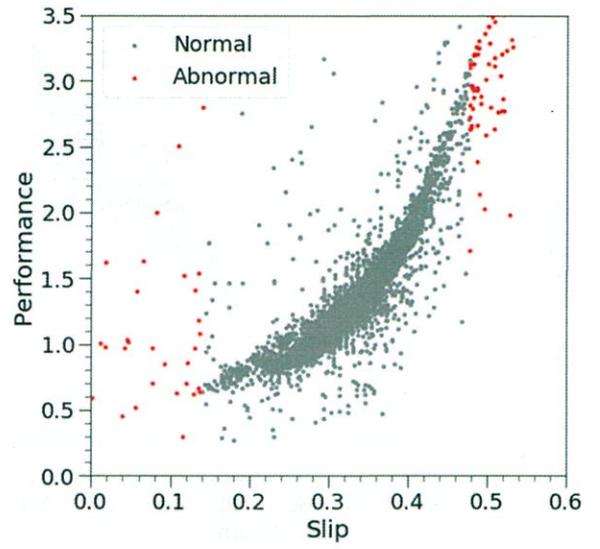
(f) 軸回転数と軸馬力-外れ値

図 A.1-7 対水速度・軸回転数・軸馬力の散布図

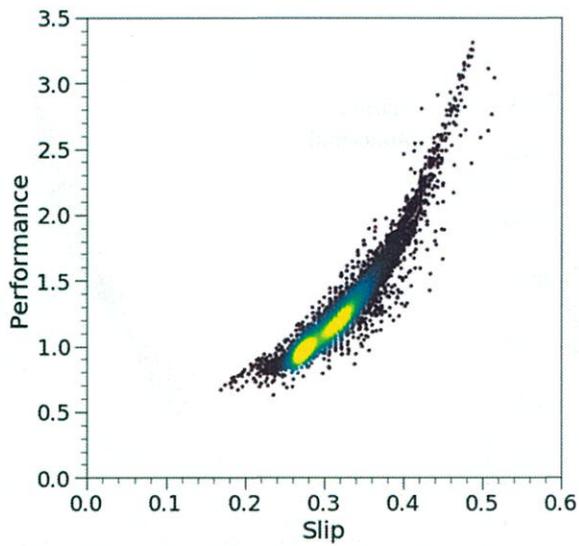
A 丸の異常度の高いデータは低速域が中心であった。汐路丸とは異なる傾向である。図 A.1-4 のマハラノビス距離による外れ値検出結果と比べると、外れ値の分布は比較的似ていることが分かる。図 A.1-8 は 2 つの手法による外れ値除外後の「Slip」と「Performance」の散布図である。再構築誤差利用時の異常判定には「Slip」と「Performance」の項目を用いていないが、(d)より正常値と外れ値の「Slip」及び「Performance」の分布がはっきりと分かれた点が興味深い。



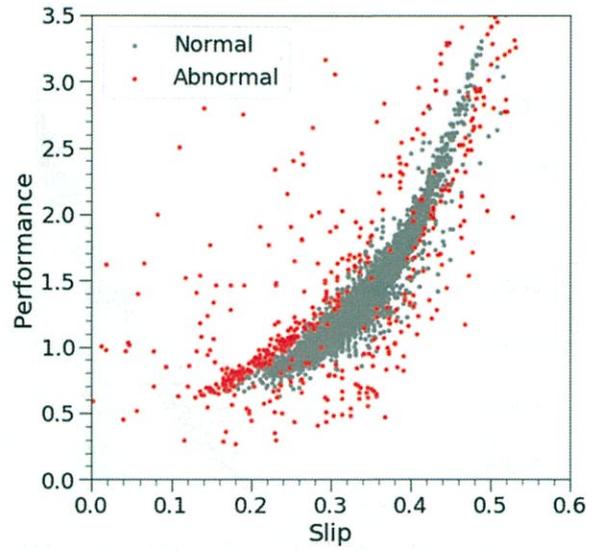
(a) 正常値(マハラノビス距離)



(b) 外れ値(マハラノビス距離)



(c) 正常値(再構築誤差)



(d) 外れ値(再構築誤差)

図 A.1-8 A 丸の「Slip」と「Performance」の散布図

### 1.3 A 丸の次元削減結果

A 丸の軸馬力，軸回転数，対水速力の3項目を，2次元に次元削減した全てのデータの密度分布を図 A.1-9 に示す．図 A.1-10 に，その際の正常値と外れ値の分布を示す．

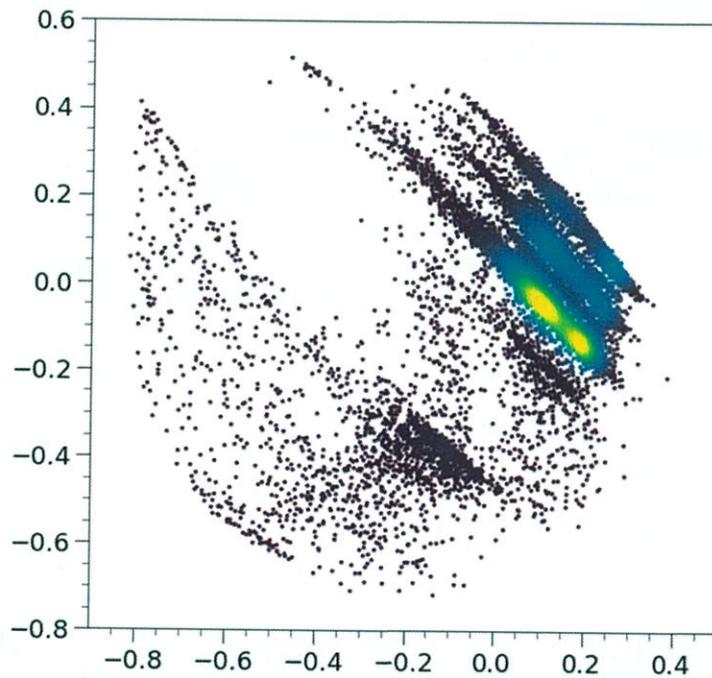


図 A.1-9 全データの次元削減結果

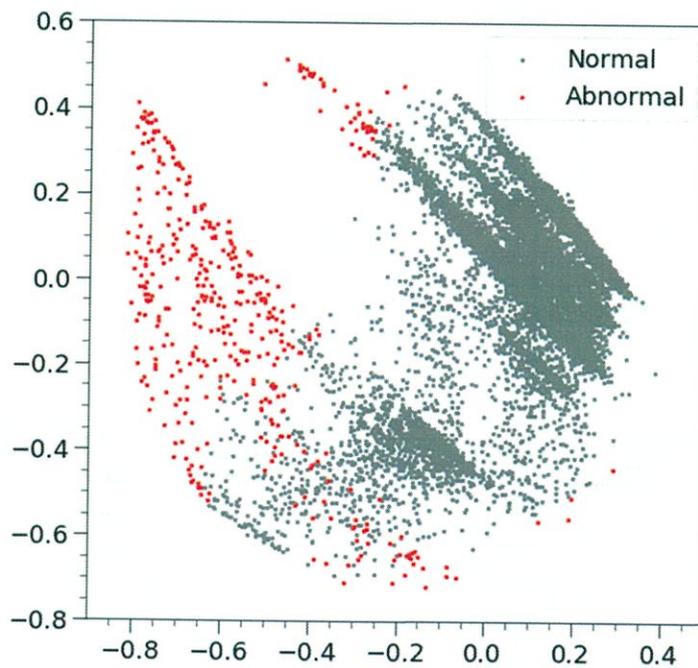


図 A.1-10 次元削減時の正常値と外れ値の分布差

## Appendix.2 ニューラルネットワークの学習曲線

訓練したニューラルネットワークの一部の学習曲線を以下に示す。汐路丸の場合は訓練データと評価データの損失が乖離しているのに対し、A丸の場合は、訓練データと評価データの損失がほぼ一致している点が特徴的である。A丸の場合は、ニューラルネットワークの表現力を高めることで、テストデータに対する損失は減少する可能性がある。

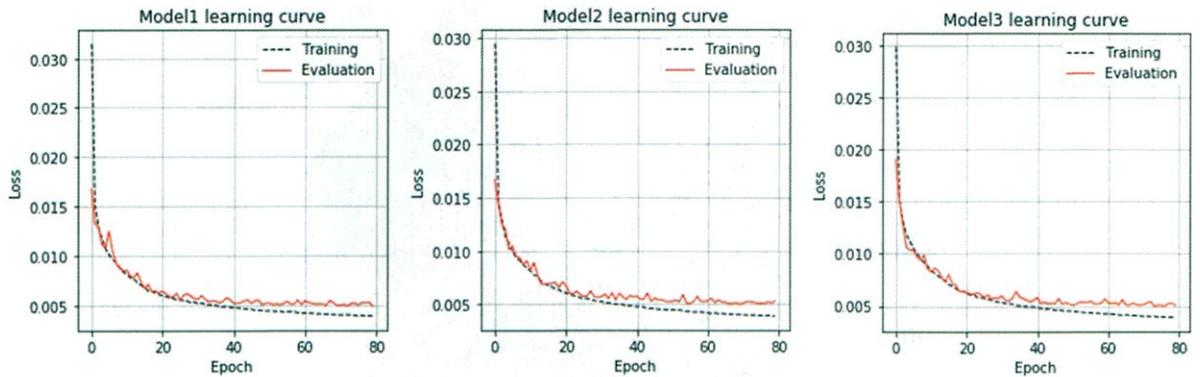


図 A.2-1 汐路丸の軸馬力推定ニューラルネットワーク

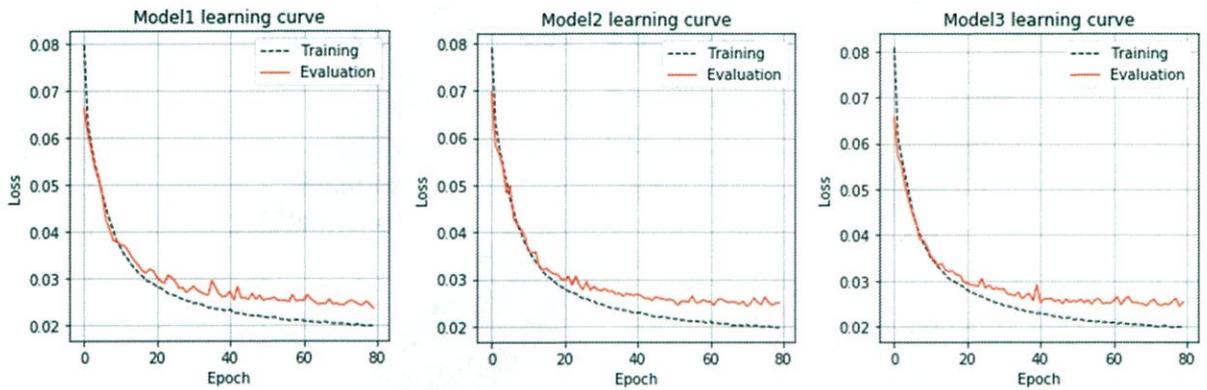


図 A.2-2 汐路丸の対水速力推定ニューラルネットワーク

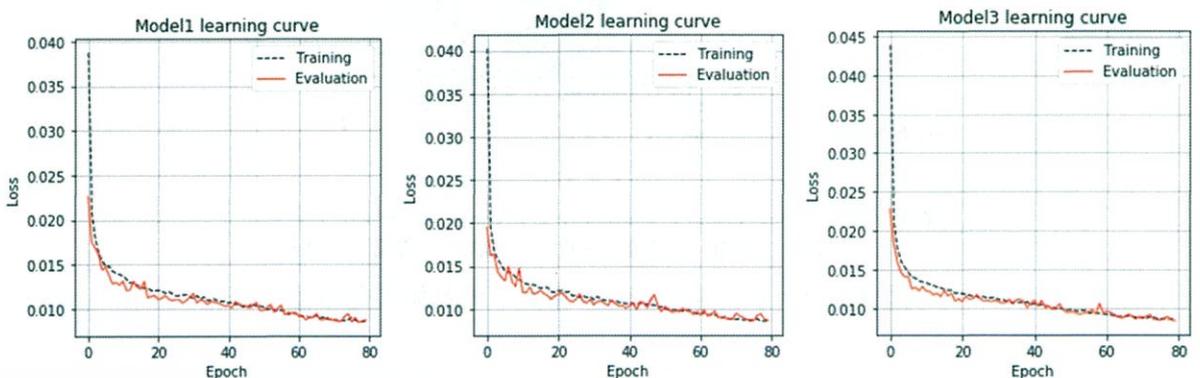


図 A.2-3 A丸の軸馬力推定ニューラルネットワーク

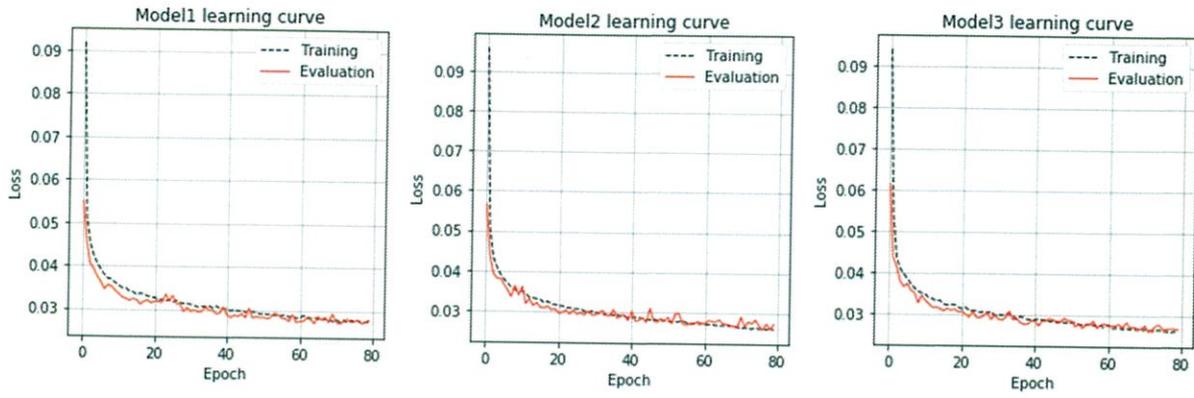


図 A.2-4 A 丸の対水速度推定ニューラルネットワーク