

文章编号: 1007-7294(2025)01-0012-11

基于神经网络的船舶阻力预报研究

吴 钦^a, 杜 林^{a,b}, 李广年^{a,b}, 舒跃辉^a, 郭海鹏^{a,b}

(宁波大学 a. 海运学院; b. 东海战略研究院, 浙江 宁波 315000)

摘要: 常规代理模型的阻力预报是以主尺度比、船型系数等作为输入, 相比于CFD计算时输入完整船型, 其较低的信息密度导致代理模型预报精度较低。本文以4108个完整船型几何形状特征张量作为输入, 采用神经网络作为代理模型, 以船舶的总阻力系数作为输出, 研究船型阻力的高维度、高精度预报方法。首先, 将船型进行无量纲化处理, 并提取特征张量作为输入; 然后, 建立神经网络模型, 搭建输入层、隐藏层和输出层; 最后, 将船型的特征张量与总阻力系数输入神经网络, 通过误差反向传播进行训练, 直至损失函数值收敛。本文研究结果可为基于高维代理模型的阻力性能预报提供理论和技术支持。

关键词: 船舶工程; 阻力性能; 高维代理模型; 人工神经网络

中图分类号: U661.31+1 **文献标识码:** A **doi:** 10.3969/j.issn.1007-7294.2025.01.002

Ship resistance prediction based on neural network

WU Qin^a, DU Lin^{a,b}, LI Guang-lian^{a,b}, SHU Yue-hui^a, GUO Hai-peng^{a,b}

(a. Faculty of Maritime and Transportation; b. East China Sea Strategic Research Institute, Ningbo University, Ningbo 315000, China)

Abstract: Conventional resistance prediction method of proxy models takes main scale ratios, ship form coefficients, and other similar parameters as inputs. Compared to CFD calculations, in which the complete hull form is used as input, prediction method with lower information density of proxy models results in lower prediction accuracy. In this paper, a high-dimensional, high-precision resistance prediction method was proposed for ship hulls using 4108 sets of complete hull geometry feature tensors as input and employing neural networks as proxy models. The total resistance coefficient of the ship was taken as the output. Dimensionless treatment of the hull forms was conducted at first and feature tensors were extracted as inputs. Next, a neural network model was constructed, comprising input layers, hidden layers, and an output layer. Finally, the feature tensors of the hull forms and the corresponding total resistance coefficients were fed into the neural network, and the model was trained using error back propagation until the loss function converges. The research findings in this paper can provide theoretical and technical support for high-dimensional proxy model-based resistance performance prediction.

Key words: ship engineering; ship resistance; high-dimensional surrogate model; artificial neural network

收稿日期: 2024-07-24

基金项目: 高等学校学科创新引智计划资助项目(D21013); 国家自然科学基金-青年科学基金资助项目(52201368); 船舶总体性能创新研究开放基金资助项目(11322203)

作者简介: 吴 钦(2000-), 男, 硕士研究生; 杜 林(1988-), 男, 博士, 讲师;
李广年(1980-), 男, 博士, 教授, 通讯作者, E-mail: liguangnian@nbu.edu.cn;
舒跃辉(1999-), 男, 硕士研究生; 郭海鹏(1988-), 男, 博士, 副教授。

0 引 言

船舶作为海上重要运输工具,其性能研究和发展直接关系着海洋强国战略的实施。阻力性能作为船舶性能的一个分支,是船型优化工作中需要着重解决的内容^[1]。随着计算机技术的不断提高、数值模拟技术的不断发展,基于数值仿真的船舶优化设计方法^[2](Simulation Based Design,简称SBD技术)与基于代理模型的阻力性能优化方法^[3]在船型阻力优化研究中得到广泛运用。由于SBD优化方法需要执行大量CFD仿真计算任务^[4],时间成本较高^[5],而基于代理模型的优化是一个单向的线性流程,系统结构更为简单,方法更为成熟^[6],所以目前在实际工程应用中更为普遍^[7]。

目前,基于代理模型的阻力性能优化方法所用的主要模型包括多项式响应面、Kriging模型、径向基函数^[8]、支持向量机^[9]等。常规代理模型仅针对某一种船型的阻力性能的分布情况进行拟合,导致不同船型间的可借鉴性低,且模型输入仅为主尺度比、船型系数等较为宏观的形状特征变量,与CFD计算求解需要输入完整的船型几何形状相比,在所需的信息体量上具有巨大差异,导致代理模型精度较低。从另一个角度讲,将两个型值不同但具有相同主尺度比、船型系数的样本输入常规代理模型后得到的结果必定一致,这显然是不正确的。所以,为了解决这个问题,一方面需要提升输入数据的信息体量,即尽可能完整地将船型几何特征作为输入,另一方面则需要提升代理模型的维度,即模型要能够建立高维映射、逼近更加复杂的非线性关系,以应对型值特征这样的高维度数据。

针对常规方法中船型数据输入信息量少,和常规代理模型自身维度不足的问题,本文通过提取无量纲化后的完整船型特征张量作为输入数据,来弥补输入信息体量差异。采用神经网络模型来提升模型维度的流程见图1,其中,图1(a)为传统代理模型的阻力优化流程图,图1(b)通过对具体船型数据进行栅格化,提取完整的船型特征张量作为输入,图1(c)采用神经网络对模型维度进行提升。以船型特征张量与总阻力系数作为训练集,通过误差反向传播训练神经网络,争取获得更好的模型拟合精度。




图1 引入完整船型特征和神经网络提升代理模型维度

Fig.1 Enhancing surrogate model dimensionality by incorporating complete ship features and neural networks

1 神经网络模型结构设计

近年来,随着计算机视觉、人工智能等技术的高速发展,神经网络模型以其在拟合方面的显著优势受到研究者的广泛青睐^[10-11]。理论上具有充足节点数量的神经网络模型,能够逼近任何复杂非线性关系,这也使其成为一种优秀的高维代理模型^[12]。

全连接神经网络 FCNN(Full Connect Neural Network)作为神经网络最具代表性的网络模型,其特点是模型每一个节点和下一层所有节点都有运算关系。大量的输入参数不仅提高了网络的拟合效率,同时也会导致过拟合,从而导致在特定的模型中表现不佳。但是长期以来的实践证明,FCNN网络在处理非图像相关的模型时表现出稳定的拟合性能。同时对于回归模型,FCNN网络的全连接层特点

能更好地拟合各连接层之间的关系。本文采用 FCNN 网络作为神经网络模型。图 2 为本文 FCNN 网络结构。船舶属于一种复杂的三维曲面结构,较低的信息密度不足以精确地拟合出船体模型。神经网络的输入层信息参数为“4096+12”个船型数据,其中,4096 为对船体栅格化后得到的几何形状特征张量数,12 为船舶主尺度比及船型系数数量。神经网络的输出层为船舶总阻力系数 C_T 。本文以 4108(即 4096+12=4108)个船舶特征张量预测船舶总阻力系数 C_T ,输入数据维度远大于预测值,故设置 3 层隐藏层,输入层与隐藏层之间采用 Leaky ReLU 激活函数,Leaky ReLU 激活函数是对 ReLU 函数的改进,在负值区域引入一个小值斜率,保证神经元在负值区域也能更新权重。损失函数是评价网络模型训练效果的指标,指导训练中权重和偏差的更新。本文采用的损失函数是在回归任务中广泛运用的均方误差损失函数。

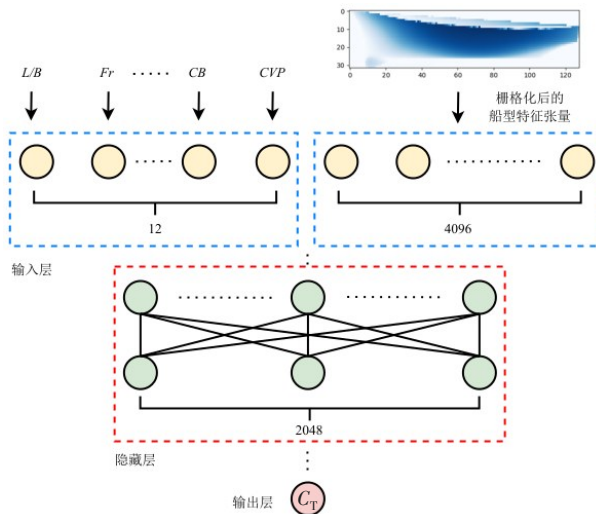


图2 网络模型结构设计

Fig.2 Architecture design of neural network

2 船型数据准备

2.1 船型特征张量提取

船型数据是神经网络构建和训练过程中不可或缺的部分,一组高维度的船型特征张量,能帮助网络模型更准确地学习物理模型的模式和规律,只有通过大量数据集的训练,神经网络才能较好地拟合输入数据与输出之间的关系。本文选择美国泰勒水池 1980 年的一艘战舰的初步设计方案 5415 作为预测模型,主要船型参数如表 1 所示。马娟等^[13]对 5415 进行了仿真计算,为本文预报结果提供参考标准。

表 1 5415 船舶主要参数

Tab.1 Key parameters of the 5415 vessel

参数	符号/单位	数值	参数	符号/单位	数值
缩尺比	S_r	24.832	方形系数	C_B	0.5060
垂线间长	L/m	5.72	傅如德数	Fr	0.28
吃水	T/m	0.372	雷诺数	Re	12 600 000
湿表面积	S_{DWL}/m^2	4.861	设计航速	$V/(m \cdot s^{-1})$	2.096

船舶主尺度比与船型系数作为影响船舶性能的主要参数,是构建船型特征张量数据集的首选,但是船型作为一个复杂模型,仅依赖这部分主要参数并不能准确地表征船型特征,这也是常规代理模型的问题所在。本文对具体的船型进行栅格化处理,因为船舶结构的对称性,为船舶栅格化处理提供可行性条件。本文预置(32,128)的网格尺寸,将模型向中线面进行投影,放置在预置的网格中。如图 3 所示,通过栅格化即可得到表征船舶特征的 4096 个数据及栅格化网格三个方向的缩尺比值,栅格化数据的运用,解决了代理模型因特征参数较少而导致的预报精度低的问题,同时也解决了船型特征的泛化性问题。如此可获得一个表征船舶特征张量的 4108 个船型数据,将这些数据以 csv 文件进行存储,用于训练 FCNN 网络模型。



图3 模型栅格化
Fig.3 Model meshing

2.2 船型特征张量数据集扩充

本文基于5415船体模型进行线性变形扩充FCNN网络训练数据集,自主编写船体线性变形脚本进行船体线性变形。本文选定船长、船宽和型深变形区间均为[-0.05,0.05],脚本计算STL船舶主尺度比,根据船舶主尺度比及给定的线性变形区间,按式(1)计算变形后的船舶主尺度比。基于变形后的船舶主尺度比,锁定型宽*B*,按式(2)计算出船长、型深的变化区间。根据船长、型深变化区间对船型进行线性变化。

$$\begin{aligned} \alpha_i &= [\alpha \times (1 - R_\alpha), \alpha \times (1 + R_\alpha)] \\ \beta_i &= [\beta \times (1 - R_\beta), \beta \times (1 + R_\beta)] \\ \gamma_i &= [\gamma \times (1 - R_\gamma), \gamma \times (1 + R_\gamma)] \\ L_r &= \alpha_i \times B \\ D_r &= \frac{B}{\beta_i} \end{aligned} \tag{1} \tag{2}$$

式中, α_i 、 β_i 、 γ_i 表示经过线性变形后的船舶主尺度比, α 、 β 、 γ 为5415母型船主尺度比, R_α 、 R_β 、 R_γ 为给定的线性变形区间, L_r 、 D_r 分别为船长、型深变化区间。

本文基于船型线性变形脚本,以5415船型为母型船生成1000个变形区间为[-0.05,0.05]的新船型,作为FCNN网络训练数据集。图4分别展示了5415母型船、新生成的0#、10#、100#、500#及999#船




图4 基于5415母型船线性变形生成新船型

Fig.4 Generating new ship designs based on 5415 parent vessel's linear deformation

表2 船型数据集

Tab.2 Ship dataset

序号	F_n	L/B	B/T	L/T	...	4108
0	0.28	3.7168	4.3116	16.0259	...	0
...						
10	0.28	3.5361	4.3116	15.2467	...	0
...						
100	0.28	3.7590	4.2025	15.7974	...	0
...						
500	0.28	3.5361	4.2025	14.8607	...	0
...						
999	0.28	3.8674	4.0987	15.8518	...	0




图5 主尺度变化区间

Fig.5 Variation range of main scale

型,新生成的船型主尺度比区间如图 5 所示。从图中可知,新生成的 1000 个模型的 L/B 在 $[7.2, 7.8]$ 区间范围, B/D 在 $[1.02, 1.14]$ 区间范围, L/D 在 $[7.25, 8.75]$ 区间范围,上述船型变形区间均以半船进行计算。表 2 为变形后的船型全船主尺度比、船型系数及栅格化后的船型特征张量。

3 模型训练与预报结果

3.1 船舶总阻力系数计算

本文以船舶总阻力系数作为船型数据集的标签,采用 Star CCM+ 进行船舶总阻力仿真计算,基于船舶总阻力及船舶主尺度系数可确定船舶总阻力系数。本文在 Star CCM+ 仿真计算中选择了 $K-\Omega$ 湍流物理模型,初始条件选择如表 3 所示。计算网格如图 6 所示,共 832 204 个网格;自由液面波形图如图 7 所示;仿真 15 s 计算得到船舶总阻力为 42.777 N,总阻力收敛曲线如图 8 所示;图 9 为基于马娟^[13]

表 3 5415 船舶仿真物理模型

Tab.3 Physical model of vessel 5415 simulation

条件	数值类型/单位	数值
体积分数(水)	场函数	Volume Fraction of Heavy Fluid of 静水 VOF 波
体积分数(空气)	场函数	Volume Fraction of Light Fluid of 静水 VOF 波 1
压力	场函数	Hydrostatic Pressure of 静水 VOF 波 1
湍流强度	常数	0.01
湍流速度	常数/($m \cdot s^{-1}$)	1
VOF 波阻尼长度	常数/m	3
速度	场函数	Velocity of 静水 VOF 波 1
仿真时间步长	常数/s	0.02




图 6 5415 整体网格

Fig.6 Grid of Vessel 5415

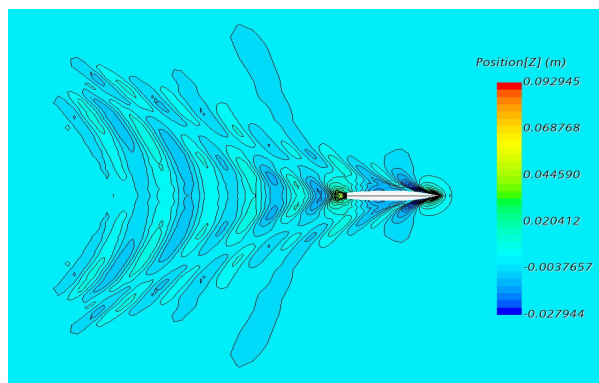


图 7 自由液面波形图

Fig.7 Chart of free surface waveform




图 8 总阻力收敛曲线

Fig.8 Iterative results of total drag




图 9 总阻力计算对比图

Fig.9 Comparison between calculated results and those from Reference [13] for total drag

在典型标准水面船型阻力和黏性流程的计算一文中对5415在相同工况下仿真计算的总阻力与本文总阻力计算对比图。通过对比总阻力误差基本为零,本文基于Star CCM+船舶总阻力计算模型具有较高精度。

3.2 全连接神经网络调参

影响神经网络预测性能的因素有网络的层数和神经元数量、激活函数、损失函数、优化算法、学习率、正则化技术、批量大小等。本文基于全连接神经网络的回归问题,输入参数为4109个船型参数,预测值为船舶总阻力系数 C_T 。为此预置3层神经网络,激活函数为ReLU,采用均方误差损失函数,优化算法采用自适应学习率方法(Adam)。由于是基于高维度数据预测单个数据值,故本文未采用正则化技术,并从网络层数,激活函数及学习率三方面进行FCNN网络性能调参。首先,网络的深度和宽度会直接影响模型的表示能力和学习能力,本文属于高维度数据回归问题,将对3层及4层网络层数进行测试。其次,合适的激活函数可以引入非线性性质,使得网络可以学习非线性关系,本文将对ReLU与Leaky ReLU两类激活函数进行测试。最后,学习率决定了模型参数在每次迭代中更新的步长。

本文采用短时测试与长时测试两种测试工况进行FCNN网络性能调参。其中,将样本数量小于等于5、Star CCM+仿真时间小于等于0.06 s的测试作为短时测试,而样本数量大于10、仿真时间大于10 s的测试作为长时测试。测试工况见表4。由表5~8对4个测试表格进行分析可知,选用Leaky ReLU作为激活函数的预测性能远好于ReLU。此外,当FCNN网络采用3层网络结构、学习率为 5.0×10^{-4} 、负值斜率为0.05或者0.03时,网络预测性能最好。

表4 全连接神经网络参数调节测试工况

Tab.4 Fully connected neural network parameter adjustment test scenarios

工况	样本数量	采样数量	批处理量	仿真时间/s	航速/($m \cdot s^{-1}$)
短时测试	5	1	1	0.06	2.096
长时测试	15	3	5	15	2.096

表5 ReLU短时测试

Tab.5 Short-term testing for ReLU

网络层数	学习率	试验次数	预测时间/s	合格率
3	1.0×10^{-4}	2	均未收敛	0
3	5.0×10^{-4}	3	(1)168 2次未收敛	0.3
3	5.5×10^{-4}	3	均未收敛	0
3	6.0×10^{-4}	3	(1) 24 2次未收敛	0.3
3	6.5×10^{-4}	3	(1) 30.5 2次未收敛	0.3
3	7.0×10^{-4}	6	(1) 94 (2) 82 4次未收敛	0.3
3	7.5×10^{-4}	10	(1) 163 (2) 360.1 (3) 11 (4) 60.06 (5) 295 (6) 22 4次未收敛	0.6

续表 5

网络层数	学习率	试验次数	预测时间/s	合格率
			(1) 60.09	
3	8.0×10^{-4}	5	(2) 31 3次未收敛	0.4
3	8.5×10^{-4}	2	(1) 24 1次未收敛	0.5
3	9.0×10^{-4}	1	未收敛	0
4	5.0×10^{-4}	1	未收敛	0
4	5.5×10^{-4}	1	未收敛	0
4	6.0×10^{-4}	1	未收敛	0
4	7.0×10^{-4}	1	未收敛	0

表 6 ReLU 长时测试

Tab.6 Long-term testing for ReLU

网络层数	学习率	试验次数	预测时间/s	合格率
3	1.0×10^{-4}	1	未收敛	0
			(1)13 (2)39 (3)28	
3	5.0×10^{-4}	6	(4)267 2次未收敛	0.66
3	5.5×10^{-4}	2	未收敛	0
4	1.0×10^{-4}	1	未收敛	0
4	5.0×10^{-4}	2	(1)73 (2)18	1

表 7 Leaky-ReLU 短时测试

Tab.7 Short-term testing for Leaky-ReLU

网络层数	学习率	负值斜率	试验次数	预测时间/s	合格率
3	1.0×10^{-4}	0.01	2	未收敛	0
3	1.0×10^{-4}	0.05	1	未收敛	0
3	5.0×10^{-4}	0.01	2	未收敛	0
				(1)26 (2)57 (3)20 (4)238	
3	5.0×10^{-4}	0.03	5	1次未收敛	0.8
				(1)26 (2)204 (3)50 (4)190	
3	5.0×10^{-4}	0.05	8	(5)528 (6)476 (7)625 (8)202	1

续表 7

网络层数	学习率	负值斜率	试验次数	预测时间/s	合格率
				(1)1422	
3	5.0×10^{-4}	0.1	4	(2)46 (3)31 (4)196	1
3	8.0×10^{-4}	0.2	1	(1)240.06	1
4	1.0×10^{-4}	0.01	1	未收敛	0
4	5.0×10^{-4}	0.01	1	未收敛	0
4	5.0×10^{-4}	0.03	2	未收敛	0
4	5.0×10^{-4}	0.05	4	(1)104 (2)596 (3)150 (4)120	1
4	5.0×10^{-4}	0.1	1	(1)60.07	1

表 8 Leaky-ReLU 长时测试

Tab.8 Long-term testing for Leaky-ReLU

网络层数	学习率	负值斜率	试验次数	预测时间/s	合格率
				(1)84	
3	5.0×10^{-4}	0.03	4	(2)45 (3)295 (4)337	1
3	5.0×10^{-4}	0.05	4	(1)28 (2)36 (3)12 (4)40	1

3.3 网络结构测试

FCNN 网络的结构测试是神经网络可行性验证的重要阶段。本文将数据集中的 80% 作为训练集,其余的 20% 作为测试集,将 1000 个船型数据样本按 4:1 的比例随机划分,1000 个船型数据样本并未包括对应的船舶总阻力系数 C_T 。在 3.1 节中本文已经通过 Star CCM+ 仿真计算求得 5415 船型总阻力为 42.777 N,根据总阻力及船型主尺度系数得到 5415 船舶总阻力系数为 0.003 91,对 1000 个船型数据样本在 $0.003\ 91 \pm 0.0005$ 区间随机生成伪 C_T ,用于测试 FCNN 网络可行性。

FCNN 网络训练流程如图 10 所示。本文网络训练的评判标准为预测值的平均值与实际值的平均

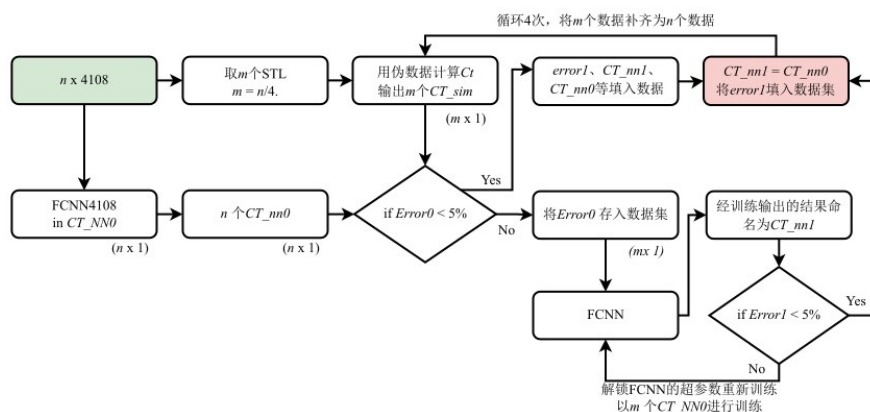


图 10 FCNN 网络测试流程图

Fig.10 Flowchart of FCNN network testing process

值误差小于 5%。为避免输入数据量较大而造成平均误差较大,本文在测试中对输入数据进行批处理,每次测试仅输入数据的 1/4,通过 4 次循环即可完成整个训练集的训练。

3.4 预报结果

通过 800 组船型参数训练 FCNN 网络后,网络训练损失的迭代结果如图 11 所示,从图中可知网络训练结果稳定且收敛效果较好。再将其余的 200 组船型参数数据作为测试集,检测 FCNN 网络的预报结果,计算未经过训练得到的预测值与目标值的平均误差记作 $Error_0$,经过训练并满足条件的预测值与目标值的误差记作 $Error_1$,如表 9 所示。从表中可知,未经过训练的 FCNN 网络预测值平均误差为 1.9415,远大于 5% 的误差标准;经过训练后网络的预测值平均误差为 0.0217,满足误差小于 5% 的条件。由预报结果可知,基于 FCNN 网络的船舶总阻力系数预报具有可行性。

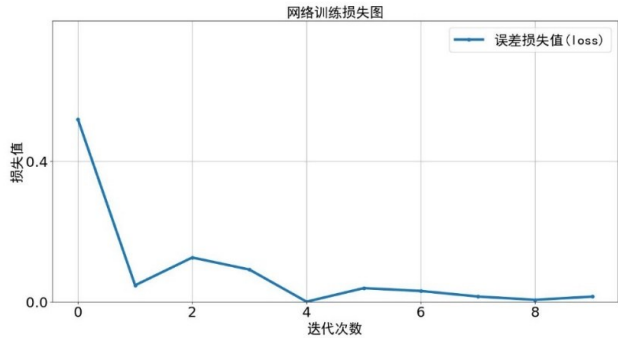


图 11 FCNN 网络训练损失迭代图

Fig.11 FCNN network training loss iteration chart

表 9 FCNN 网络预报结果

Tab.9 FCNN network forecasting results

误差	第一次循环	第二次循环	第三次循环	第四次循环	总平均误差
$Error_0$	1.579	-0.0102	0.0863	0.0658	1.9415
$Error_1$	0.0157	-0.0102	0.0169	0.0441	0.0217

本文将 FCNN 网络船舶总阻力系数预报用于船舶建模优化测试。测试工况如表 10 所示,优化前后及其他组织试验结果如表 11 所示,可以看到本文预报方法能较好地给出船体阻力预报结果。优化前总阻力系数预测值低于试验值 8.184% (相对于 INSEAN^[14])、8.43% (相对于 DTMB^[15])。预报值与其他试验值误差均小于 10%,说明本文预报方法具有一定的精度。船舶建模总阻力优化迭代结果如图 12 所示,从迭代图中可知基于 FCNN 网络的船舶建模实现两次优化,优化前后船型减阻效率提高 0.512%。图 13 为 5145 船型优化前后自由液面波高图,由图可知,相较于母型船,优化船靠近船首的第一个波谷峰值减小,船中附近区域兴波的波谷有所减弱,船尾后方的船行波有所增强,船首区域的兴波基本保持一致。优化后船体周围的波形相对母型船得到了改善,其波高低于母型船,波峰波谷的面积也较母型船有所减小,说明本文的预报模型在船型优化中具有一定研究意义。

表 10 船舶建模优化测试工况

Tab.10 Test scenarios for ship modeling optimization

迭代次数	样本数量	检验采样量	批处理量	仿真时间/s	航速/($m \cdot s^{-1}$)	傅汝德数
14	15	3	5	15	2.096	0.28

表 11 优化前后阻力计算结果与试验结果

Tab.11 Calculated (before/after optimization) and experimental results of C_T

阻力系数	船型优化前	船型优化后	试验值(INSEAN) ^[14]	试验值(DTMB) ^[15]
C_T	3.91×10^{-3}	3.89×10^{-3}	4.23×10^{-3}	4.27×10^{-3}

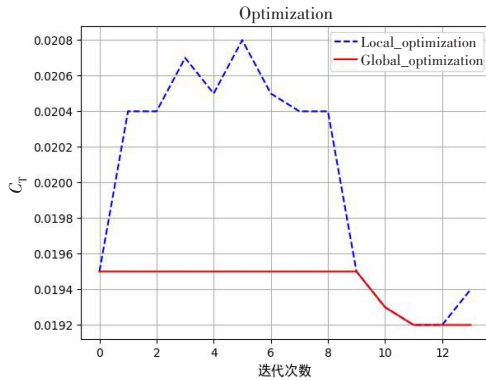


图12 船舶建模优化总阻力迭代图

Fig.12 Total resistance iteration chart of ship modeling optimization




图13 优化前后自由液面波形图

Fig.13 Free surface waveform before and after optimization

4 结 论

本文提出一种基于神经网络的船舶阻力预报方法。通过对母型船线性变形获取大量船型数据,基于船型特征的高度对称性,对船型进行栅格化提取完整的船型几何形状特征张量。再以完整的船型参数作为输入,采用全连接神经网络作为代理模型,以船舶总阻力系数作为输出。有别于传统的代理模型预报方法,对船舶总阻力系数进行高维度、高精度预报。其中,通过大量数据集进行训练,然后,测试验证了预报模型的可行性,由此解决了传统代理模型因为输入参数维度较低引发的预报精度问题。

(1) 船舶特征的高度对称性,为船型数据栅格化提供了理论支撑。传统代理模型因船型数据输入维度低,导致预报精度低,而且不同船型间可借鉴性低,而采用船型栅格化处理可以较好地解决这个问题。

(2) 全连接神经网络在高维船舶阻力预报代理模型中,具有较好的稳定性和较高的预测精度。对于通过高维船型数据预报船舶阻力的回归模型,全连接神经网络的全连接层特点,能较好地拟合各连接层间的关系。通过大量试验测试得知,选用 Leaky ReLU 作为激活函数时神经网络的预测性能最佳。

(3) 基于神经网络代理模型的船舶阻力预报方法,在船型优化中具有重要参考价值。以全连接神经网络船舶总阻力系数代理模型代替 SBD 优化中的求解器部分,建立基于 FCNN 网络的船舶建模优化。以 FCNN 网络作为求解器可大幅度减少优化过程中的仿真计算成本,船型总阻力系数预报值与其他水池试验值误差小于 10%,说明基于 FCNN 网络船舶阻力系数预报具有一定精度。船型优化前后的减阻效果达到 0.512%,基于 FCNN 网络的船舶阻力系数预报在船型优化中具有一定研究意义。

参 考 文 献:

- [1] 赵 峰,李胜忠,杨 磊. 全局流场优化驱动的船舶水动力构型设计新方法[J]. 水动力学研究与进展(A辑), 2017, 32(4): 395-407.
Zhao Feng, Li Shengzhong, Yang Lei. The ship hydrodynamic configurations design driven by a global flow optimization[J]. Chinese Journal of Hydrodynamics (A), 2017, 32(4): 395-407. (in Chinese)
- [2] 李胜忠. 基于SBD技术的船舶水动力构型优化设计研究[D]. 北京: 中国舰船研究院, 2012.
Li Shengzhong. Research on ship hydrodynamic configuration optimization design based on SBD technology[D]. Beijing: China Shipbuilding Industry Corporation, 2012. (in Chinese)

- [3] 韩忠华. Kriging 模型及代理优化算法研究进展[J]. 航空学报, 2016, 37(11): 3197–3225.
Han Zhonghua. Research progress on Kriging model and surrogate optimization algorithm[J]. Journal of Aeronautics, 2016, 37(11): 3197–3225. (in Chinese)
- [4] 何靖仪. 基于 RANS 法与 SBD 技术的船舶阻力性能优化方法研究[D]. 大连: 大连理工大学, 2020.
He Jingyi. Research on ship resistance performance optimization method based on RANS method and SBD technology[D]. Dalian: Dalian University of Technology, 2020. (in Chinese)
- [5] Lampros N, Evangelos B. A novel method for the holistic, simulation driven ship design optimization under uncertainty in the big data era[J]. Ocean Engineering, 2020, 218(12): 107634.1–107634.15.
- [6] Wan Yuejin, Hou Yuanhang, Xiong Yeping, et al. Interval optimization design of a submersible surface ship form considering the uncertainty of surrogate model[J]. Ocean Engineering, 2022, 263: 112262.
- [7] 于 群, 李广年, 杜 林, 等. 基于阻力性能的金枪鱼船型参数优化研究[J]. 中国造船, 2021, 62(2): 224–235.
Yu Qun, Li Guangnian, Du Lin, et al. Research on tuna vessel's hull form parameter optimization based on resistance performance[J]. Shipbuilding of China, 2021, 62(2): 224–235. (in Chinese)
- [8] 冯佰威, 王首茗, 冯 梅. 改进的径向基插值方法在船型优化中的应用[J]. 华南理工大学学报(自然科学版), 2022, 50(3): 57–64.
Feng Baiwei, Wang Shouming, Feng Mei. Application of improved radial basis interpolation method in ship hull form optimization[J]. Journal of South China University of Technology (Natural Science Edition), 2022, 50(3): 57–64. (in Chinese)
- [9] 冯榆坤. 基于支持向量回归算法的船型优化设计研究[D]. 上海: 上海交通大学, 2020.
Feng Yukun. Research on ship hull form optimization design based on support vector regression algorithm[D]. Shanghai: Shanghai Jiao Tong University, 2020. (in Chinese)
- [10] 郭浩成. 基于 CFD 和神经网络的三体船快速性优化研究[D]. 大连: 大连理工大学, 2021.
Guo Haocheng. Research on fast performance optimization of trimaran ship based on CFD and neural networks[D]. Dalian: Dalian University of Technology, 2021. (in Chinese)
- [11] Tomasz C, Paweł C. Determination of design formulas for container ships at the preliminary design stage using artificial neural network and multiple nonlinear regression[J]. Ocean Engineering, 2021, 238: 109727.
- [12] 李 纳, 陈 明, 刘 飞, 等. 基于广义回归神经网络与遗传算法的玻璃钢渔船船型要素优化研究[J]. 船舶工程, 2012, 34(4): 18–20+65.
Li Na, Chen Ming, Liu Fei, et al. Optimization of fiberglass fishing vessel hull form parameters based on generalized regression neural network and genetic algorithm[J]. Ship Engineering, 2012, 34(4): 18–20+65. (in Chinese)
- [13] 马 娟, 万德成. 典型标准水面船型阻力和黏性流场的计算[J]. 中国科学: 物理学 力学 天文学, 2011, 41: 178–193.
Ma J, Wan D C. A numerical study of resistance and viscous flow around typical benchmark surface ship hull[J]. Scientia Sinica Phys, Mech & Astron, 2011, 41: 178–193. (in Chinese)
- [14] Olivieri A, Pistani F, Avanzini A, et al. Towing tank experiments of resistance, sinkage and trim, boundary layer, wake, and free surface flow around a naval combatant INSEAN 2340 model[J]. Security, 2001, 421: 1–42.
- [15] Stern F, Longo J, Penna R, et al. International collaboration on benchmark CFD validation data for surface combatant DT-MB model 5415[C]//Twenty-Third Symposium on Naval Hydrodynamics, 2001: 402–422.