



## 基于点云特征提取的波浪增阻预报及对比研究

吴铭峰 朱仁传 徐德康

### Added wave resistance prediction and comparative study based on point cloud feature extraction

WU Mingfeng, ZHU Renchuan, XU Dekang

在线阅读 View online: <https://doi.org/10.19693/j.issn.1673-3185.03570>

## 您可能感兴趣的其他文章

### Articles you may be interested in

#### 波浪增阻计算方法在船型综合优化设计中的应用

Application of wave added resistance calculation method in comprehensive optimization design of ship hull form

中国舰船研究. 2020, 15(2): 17-22 <https://doi.org/10.19693/j.issn.1673-3185.01823>

#### 面向船舶轴系智能安装的法兰激光扫描点云分割研究

Point cloud segmentation of flange laser scanning for ship shafting intelligent installation

中国舰船研究. 2023, 18(6): 268-274 <https://doi.org/10.19693/j.issn.1673-3185.03114>

#### 波浪中自由自航船舶轴系功率特性的数值预报方法

Numerical prediction method of shafting power characteristics of free self-propelled ship in waves

中国舰船研究. 2022, 17(3): 119-125 <https://doi.org/10.19693/j.issn.1673-3185.02733>

#### 基于云模型的舰船战备完好性评估方法

Warship operational readiness integrity evaluation method based on cloud model

中国舰船研究. 2021, 16(6): 61-71 <https://doi.org/10.19693/j.issn.1673-3185.02337>

#### 基于轻量化快速卷积与双向加权特征融合网络的船舶裂纹检测

Ship crack detection method based on lightweight fast convolution and bidirectional weighted feature fusion network

中国舰船研究. 2024, 19(5): 95-106 <https://doi.org/10.19693/j.issn.1673-3185.03401>

#### 基于CFD的带附体KCS船在波浪中的阻力及纵摇优化

CFD-based optimization for resistance and pitch of KCS ship with appendages in waves

中国舰船研究. 2022, 17(2): 63-72 <https://doi.org/10.19693/j.issn.1673-3185.02169>



扫码关注微信公众号，获得更多资讯信息

本文网址: <http://www.ship-research.com/cn/article/doi/10.19693/j.issn.1673-3185.03570>

期刊网址: [www.ship-research.com](http://www.ship-research.com)

引用格式: 吴铭峰, 朱仁传, 徐德康. 基于点云特征提取的波浪增阻预报及对比研究 [J]. 中国舰船研究, 2025, 20(2): 227–234.

WU M F, ZHU R C, XU D K. Added wave resistance prediction and comparative study based on point cloud feature extraction [J]. Chinese Journal of Ship Research, 2025, 20(2): 227–234 (in Chinese).

# 基于点云特征提取的波浪增阻 预报及对比研究



扫码阅读全文

吴铭峰, 朱仁传\*, 徐德康

上海交通大学 船舶海洋与建筑工程学院, 上海 200240

**摘要:** [目的] 为在设计阶段快速预报船舶波浪增阻, 提出一种基于点云特征提取的神经网络模型——波浪增阻点云预报模型。 [方法] 以 S60 船为例, 与传统的基于主要设计参数的模型预报进行对比; 参照船模试验结果, 分析点云预报模型在准确性和稳定性等方面的优势, 探讨利用静水阻力预训练优化模型的方法。 [结果] 结果显示, 基于点云特征提取的波浪增阻预报模型在全部 5 艘 S60 母型船上的预报结果的决定系数  $R^2 = 0.74 \sim 0.90$ , 而基于主要设计参数的模型会在部分船型中失效。 [结论] 所做研究可为船舶波浪增阻预报提供新的思路和方法, 有利于在设计阶段充分考虑波浪增阻的影响从而有利于设计和优化船型。

**关键词:** 波浪增阻; 船舶设计; 点云特征提取; 预训练

中图分类号: U661.3

文献标志码: A

DOI: 10.19693/j.issn.1673-3185.03570

## 0 引言

船舶在波浪中的阻力增加影响船舶的操纵性能和营运能力, 并且还与船舶安全性以及当前的减碳主题相关, 是船舶领域的研究热点之一。例如, 在实海域航行时, 船舶的失速很大程度上源于风浪中的阻力增加<sup>[1]</sup>, 这将直接影响船舶的航行速度和燃油消耗。随着设计理念的发展, 越来越多的船舶设计者开始在设计初期提前估算波浪增阻, 以规划船舶储备功率并评估船舶性能。此外, 国际海事组织 (IMO) 针对船舶在真实海况下的性能制定了能效指标<sup>[2]</sup>, 随着碳排放标准日渐严格, 对波浪增阻进行预测在船舶设计领域越来越受到重视。

预报波浪增阻最直接和可靠的研究方法是模型试验, 例如分别在静水和波浪中进行拖曳实验, 然后再通过测量二者的阻力并计算差值来评估船舶在波浪中的阻力增加情况<sup>[3-4]</sup>。然而, 由于船模实验成本高且耗时, 难以应用于设计阶段来辅助船型的确定和优化。另外, 计算流体力学 (CFD) 方法也是研究波浪增阻的重要手段。例

如, 孟巧等<sup>[5]</sup>的一项数值计算与模型试验的对比研究表明, 采用基于二维切片理论的方法能够得到与相应船模试验结果相近的增阻值; 2016—2019年, 韩国政府联合 7 家研究机构对 4 种主要商用船型 (LNG 船<sup>[6]</sup>、油轮<sup>[7]</sup>、集装箱船<sup>[8]</sup>、散货船<sup>[9]</sup>) 进行了数值方法和模型试验的比较研究, 验证了数值工具在预报时的准确性和可靠性。然而, 采用数值方法进行预报需要输入较为完整的船舶外形特征, 难以在考虑大量设计参数时布置大规模的实验来进行优选, 其更多地成为设计完成品的验证手段。此外, Shigunov 等<sup>[10]</sup>于 2018 年针对半经验公式、势流方法和 RANS 求解器的一项基准研究表明, 数值方法已成为波浪中船舶运动性能模拟的重要工具, 但在工程应用上仍显不足, 计算资源的需求以及数值网格的敏感性仍然限制着它的大量应用。

为能在船舶设计阶段快速预报波浪增阻, Liu 等<sup>[11]</sup>指出经验或半经验公式可能是一种高效的预报方法, 这些结合物理规律的统计模型利用大量的试验数据能够为波浪增阻预报提供一种实用的手段。类似地, Lang 等<sup>[12]</sup>提出了一套半经验

收稿日期: 2023-09-19 修回日期: 2023-11-15 网络首发时间: 2025-01-20 14:20

基金项目: 上海交通大学“深蓝计划”资助项目 (SL2020ZD104)

作者简介: 吴铭峰, 男, 1999 年生, 硕士生。研究方向: 船舶与海洋工程水动力学。E-mail: wmf1702159@sytu.edu.cn

朱仁传, 男, 1969 年生, 博士, 教授, 博士生导师。研究方向: 船舶与海洋工程水动力学。

E-mail: renchuan@sytu.edu.cn

徐德康, 男, 1996 年生, 博士生。研究方向: 船舶与海洋工程水动力学。E-mail: xyq397702@sytu.edu.cn

\*通信作者: 朱仁传

模型,用于研究 S175, DTC 等船型的阻力增加和失速,经与试验结果进行对比,发现半经验模型通过将波浪增阻的物理机理与统计数据相结合,能够预报真实海况下的波浪增阻。为了研究大量设计参数与阻力之间的复杂关系,一些学者还采用机器学习的方法帮助处理和分析统计数据。Cepowski<sup>[13]</sup>使用神经网络对多种船型在规则波下的试验结果进行回归分析,建立了若干船舶设计参数与波浪增阻之间的映射关系,结果显示使用神经网络能够快速获得增阻曲线并进行预报。Duan 等<sup>[14]</sup>采用深度前馈神经网络(DFN)对波浪增阻数据进行了学习,通过学习船舶的几何外形主要参数,发现模型能够为船舶波浪增阻提供高精度的快速预报。

然而,传统的机器学习方法比较粗糙,形式也不够直接,其仅能建立起阻力与若干参数之间的关系,若能从型表面中提取出更多的三维船体信息而非人为地选取若干设计参数,则从理论上讲可以提高设计船增阻预报的精度和稳定性。采用母型设计法的思路,设计船的型表面可以近似地由母型船的型表面与两船的尺度比变换得到。深度学习和点云特征提取技术为这一思路提供了支持:深度学习强调让模型自动提取对象的特征,这在波浪增阻预报中即为提取船舶型表面的特征;而将船舶的三维表面离散成点云是一种使三维物体具有统一表达形式的常用处理方式。2017年, Qi 等<sup>[15]</sup>提出了一种 PointNet 模型,为点云特征提取领域的重要模型,该模型通过使用最大化操作来从点云中提取该区域的空间特征,然后通过多层感知机改变特征的维度。PointNet++网络<sup>[16]</sup>进一步利用神经网络的层次化结构进行点云的三维特征提取,其通过堆叠的特征提取层(核心仍是 PointNet),逐级将区域的空间特征整合成全局的特征。类似的三维几何特征提取方法已经在船舶领域得到应用,例如 Abbas 等<sup>[17]</sup>使用另一种点云特征提取模型 RandLA-Net<sup>[18]</sup>对一种高速快艇的船舶性能进行了预报。

综上所述,本文拟应用一种基于点云特征提取的神经网络模型进行波浪增阻预报,并与基于主要设计参数的传统机器学习模型进行对比,然后以 S60 波浪增阻船模试验结果为参考,分析基于点云的模型在波浪增阻预报方面的特点和价值。首先,介绍基于设计参数的波浪增阻预报网络(design parameter based network for added wave resistance prediction, DPN-AW)模型和基于点云特征提取的波浪增阻预报网络(point cloud based network for added wave resistance prediction, PCN-AW)

模型的输入形式、数据及模型结构,指出其特点;然后,通过对比实验分析基于点云特征提取的预报模型在准确性和稳定性方面的独特优势,进一步提出利用预训练优化模型的方法,以解决点云模型较传统模型训练难度大的问题。

## 1 波浪增阻预报模型

### 1.1 DPN-AW

DPN-AW 旨在通过输入船舶的相关参数来预测船舶在波浪中的阻力增加情况。常见的船舶设计参数包括长宽比  $L/B$ 、宽度吃水比  $B/D$ 、弗劳德数  $Fn$ 、方形系数  $C_B$  和棱形系数  $C_p$ 。为进一步考虑船首形状可能对波浪增阻产生的影响,还选取了设计吃水处半宽与船首长度的比值  $\tan\beta$ 。另外,由于船舶在波浪中运动的特性与波浪的特性相关,有必要再引入波长船长比  $\lambda/L$  作为输入参数。综上,即可将模型对波浪增阻的预报表达为

$$C_{AW} = f\left(\frac{L}{B}, \frac{B}{D}, C_B, C_p, \tan\beta, Fn, \frac{\lambda}{L}\right) \quad (1)$$

为使模型学习如式(1)所示的“波浪增阻-设计参数”映射关系,选取了 S60 船的试验数据<sup>[19-20]</sup>对模型进行训练。S60 船是单桨运输船的代表,具有 5 艘母型( $C_B = 0.60, 0.65, 0.70, 0.75, 0.80$ ),多年来,许多研究者对其进行了波浪增阻试验,试验结果多为无因次化波浪增阻系数  $C_{AW}$  与船型、航速及波长船长比  $\lambda/L$  的关系。其中,波浪增阻系数  $C_{AW}$  通常由式(2)得来:

$$C_{AW} = \frac{R_{AW}}{\zeta^2 \rho g \frac{B^2}{L}} \quad (2)$$

式中:  $R_{AW}$  为船舶的波浪增阻;  $\zeta$  为规则波的波幅;  $\rho$  为海水密度;  $g$  为重力加速度。对 5 艘船的设计参数以及相应的阻力进行无因次化后即可用于训练模型,如图 1 所示。

DPN-AW 模型主要由多层感知机(MLP)构成,采用经典的“编码器-解码器”架构进行组织。其中,编码器网络由 5 层感知机 MLP ( $7 \times 64 \times 256 \times 512 \times 1024$ ) 构成,而解码器则为 MLP ( $1024 \times 128 \times 64 \times 16 \times 1$ )。模型的输入为船舶和波浪的 7 个特征参数,输出为波浪增阻的预报值,通过编码器将输入参数转换为高维特征表示,然后通过解码器将这些特征映射为波浪增阻的预测结果。多层感知机的预测原理是,学习船舶特征与波浪增阻之间的非线性映射关系。通过样本数据和反向传播算法,模型能够优化权重参数从而最小化预

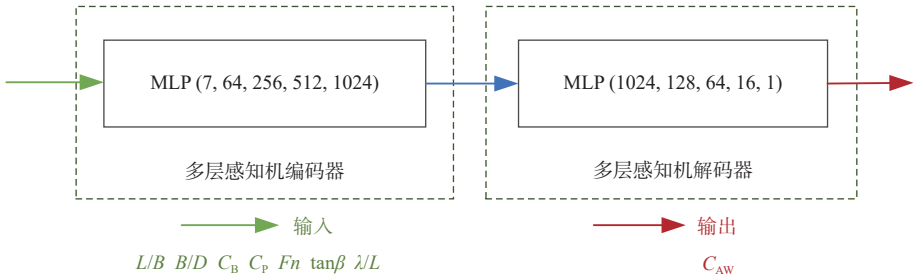


图 1 DPN-AW 模型架构

Fig. 1 Architecture of the DPN-AW model

测结果与实际波浪增阻之间的差异。

### 1.2 PCN-AW

PCN-AW 主要通过对船型、速度和波长的学习来提升预报能力。与 DPN-AW 不同的是: 1) PCN-AW 是接收船体表面点云而非设计参数作为输入的一部分, 其通过“速度编码”和划分子模型这 2 种手段来处理特征的输入; 2) PCN-AW 对输入的阻力数据进行预处理, 以便于子模型的训练; 3) PCN-AW 借助点云特征提取模块对船舶表面的局部特征和全局特征进行分析, 从而实现对波浪增阻的准确预测。

#### 1) PCN-AW 的输入形式。

模型的输入有 3 个来源: 船型、航速与波浪的特性。本文中, 波浪的特性仅考虑迎浪规则波的波长船长比  $\lambda/L$ , 由此, 可将模型输入、输出的关系总结为

$$C_{AW} = f\left(\text{船型}, Fn, \frac{\lambda}{L}\right) \quad (3)$$

其中, 船型由船体表面的点云, 也即大量点的坐标数据表示。这些坐标点以及它们的相对位置蕴含了可供提取的船体几何信息。点云数据可以通过激光扫描或摄影测量等技术获取。并且, 采用某些测量方法得到的点云还可能包含其他属性, 如法向量、语义信息等。此处为简单起见, 采用了从船舶数字三维模型表面上取样而来的 1 024 个三维点坐标作为输入, 得到的点云如图 2 (S60 系列的 4210W 船) 所示。




图 2 由 S60 船(4210W)表面采样得到的点云

Fig. 2 Point cloud sampled from a S60 ship (4210W)

从几何信息的丰富程度来看, 点云和船舶的表面近似, 而且明显覆盖了由几个主要的主尺

度和船型参数表征的特征。例如, 点云在 3 个维度下的最大与最小坐标之差体现了船舶在长、宽、吃水这 3 个方向上的尺度信息; 船中附近的轮廓也体现了中横剖面的丰满程度; 由点云形成的包络面显示了船体在排水体积上的特征; 各个站号的轮廓信息也能呈现横剖面面积曲线的变化趋势。总而言之, 点云这一形式使得模型有可能通过合理的手段提取并表达各个层次的几何信息, 形式统一且损失的信息较少。

在进行特征提取之前, 模型需要将点云、航速和波长的信息融合成统一的形式, 以便点云特征提取模块能够更好地利用这些数据。PCN-AW 首先使用最远点采样(FPS)方法从三维数字船体表面得到离散化的点, FPS 能使采集到的点尽量覆盖整个船体表面, 有助于完整描述船型特征; 随后, 模型将船体点云与航速结合起来作为输入, 本文将这一步骤称为“速度编码”。对于给定的一艘船(一个坐标集合), 其中的点  $(X_i, Y_i, Z_i)$  可以通过多种方法与航速相结合, 本文推荐使用式(4)所示的方法进行编码, 即可得到包含船型和航速信息的三维点云数据  $(D_i^1, D_i^2, D_i^3)$ 。

$$(D_i^1, D_i^2, D_i^3) = (X_i, Y_i, Z_i) \cdot V \quad (4)$$

式中:  $(X_i, Y_i, Z_i)$  为点云中的一个点  $V$  所表示的点云对应的速度;  $(D_i^1, D_i^2, D_i^3)$  为经过速度编码后的点云数据。然后, 进行数据归一化, 本文推荐使用式(5)所示的最小最大归一化。

$$\bar{D}_i^d = \frac{D_i^d - \min_m D_m^d}{\max_m D_m^d - \min_m D_m^d} \quad (5)$$

式中:  $d = 1, 2, 3$ , 为输入的维度;  $i$  为当前点在所属点集中的序号;  $m$  为在全体点集中的序号。然而经过实验, 波浪特征参数  $\lambda/L$  不能用类似的方法与点云结合, 因此本文将设计的模型根据不同的  $\lambda/L$  值训练子模型, 然后再将子模型的预报拼接形成完整的预报, 也即将式(3)所示的训练分解成式(6)所示的形式。

$$C_{AW} = f_{\lambda/L}(\text{船型}, Fn) = f_{\lambda/L}(\text{编码后的点云}) \quad (6)$$

为方便起见,本文所用的特征提取模块将按照 $\lambda/L=0.5, 0.6, \dots, 2.4$ 分为20个子模型,模型处理输入过程中数据的维度变化如图3所示。图中, $M$ 为子模型数量, $b$ 为每批次同时用于训练的样本数量, $N$ 为一艘船离散化后点的数量, $s$ 为特征的维度,本文中取 $M=20, b=16, N=1\,024, s=3$ 。

### 2) PCN-AW 的数据及预处理。

为与DPN-AW的预报效果进行对比,PCN-AW也采用S60船5艘母型的试验数据构建了数据集。由于模型在 $\lambda/L$ 这一维度(图3)是交由子模型分别完成的,故训练集应为每一个 $\lambda/L$ 提供点云矩阵和相应的增阻值以作为训练数据,然而,

试验数据并不能直接满足这一需求。因此,本文推荐将试验数据中相近的 $\lambda/L$ 取局部平均值,然后使用线性插值将其拓展至需要的 $\lambda/L$ 处。图4示出了以 $C_B=0.65, Fn=0.237$ 为例进行预处理的效果。通过这种方法,试验数据被转化为适用于模型训练的形式。

局部平均使得同一艘船在同一个速度下处于某个 $\lambda/L$ 时阻力值是一个确定的量,而插值填补了试验值在某些 $\lambda/L$ 处的空缺,保证了每个子模型都能利用试验数据进行训练。因此,这2项预处理步骤也可为模型精度评估提供依据,后文中训练和测试的误差将以插值后的阻力值作为标准进行计算。

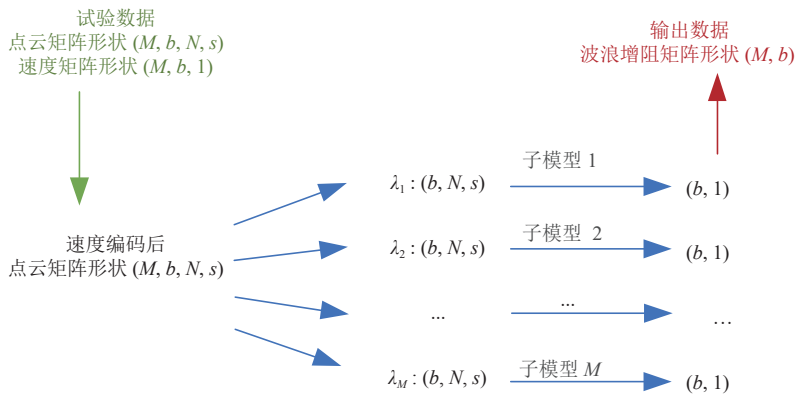


图3 数据的维度变化

Fig. 3 Dimension changes of the data




图4 对试验值进行局部平均和线性插值后的效果( $C_B=0.65, Fn=0.237$ )

Fig. 4 The effect of local averaging and linear interpolation on the test values ( $C_B=0.65, Fn=0.237$ )

### 3) PCN-AW 的特征提取与预报。

基于点云的特征提取与预报模块也采用“编码器-解码器”架构,其中编码器主要依靠PointNet++网络进行点云的特征提取,解码器则由多层感知机组成,其大致结构如图5所示。

PointNet++网络由逐级堆叠的点集特征提取模块(set abstraction)构成,其每一部分又可以分

为采样(sampling)层、聚合(grouping)层和PointNet层3个功能层。在这样的结构中,点云将被分割为众多相互重叠的局部区域,这些区域中的点及与其相邻的点描述的空间几何特征会被PointNet层提取出来,然后这些局部特征将与从相邻区域中提取的特征聚合,用以描述更大范围的空间信息。通过这种逐层的特征提取和融合,PointNet++网络可以逐步扩大神经元的感受野,最终通过全局池化操作将所有子区域的特征聚合成一个全局特征向量,包含有向解码器提供的能够用于波浪增阻预报的有效信息。在特征提取过程中,核心工作在PointNet层完成,它实际上是一个如式(7)所示的映射关系。

$$f(x_1, x_2, \dots, x_n) = \gamma(\max_{i=1, \dots, n} \{h(x_i)\}) \quad (7)$$

式中, $\gamma$ 和 $h$ 为调整特征维度的多层感知机; $\max$ 为最大池化层,其能使得提取出的特征不受点的排列顺序的影响。本文模型还利用MSG(multi-scale grouping)技术提高了稳定性,该技术能让同一层级的神经元拥有多个感受野,即同时处理不同尺度的空间信息并综合得到本区域的特

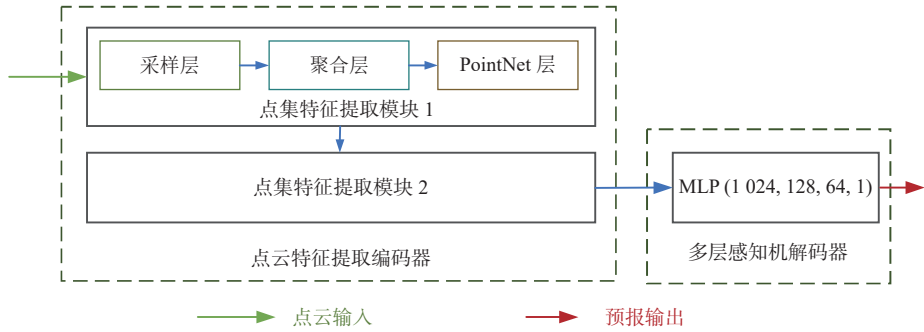


图 5 PCN-AW 模型的特征提取与预报流程

Fig. 5 Feature extraction and prediction of PCN-AW model

征。通过 MSG 网络可以利用各种尺度的局部空间信息, 这使得模型能够理解和收集更复杂的几何结构特征, 并将局部结构及其附近的几何特征结合起来进行训练, 最终使预报效果更加稳定。

## 2 波浪增阻模型预报对比分析

本节将讨论 DPN-AW 和 PCN-AW 这 2 个模型在 S60 船的波浪增阻预报中的效果。在模型原理上, 基于设计参数的 DPN-AW 模型依赖于人为选择和提取重要的设计参数作为输入特征; 而基于点云特征提取的 PCN-AW 模型则是通过对船舶的三维表面进行离散化处理, 将其表示为点云数据, 并利用深度学习技术自动提取船舶型表面的特征。

在实验设计上, 为能更好地对比分析模型的预报精度与泛化能力, 采用五折交叉进行验证, 也即每次不重复地取出 4 艘船的数据作为训练集训练模型, 然后在剩余的一艘船上进行测试。本文将以  $C_B = 0.60, 0.65, 0.70, 0.75, 0.80$  的船作为测试集进行实验, 分别编号为 Exp.1~Exp.5。不失一般性, 下面将以  $C_B = 0.65$  的船作为测试集为例, 介绍基于点云和设计参数这 2 种方法的预报效果。表 1 展示了数据集中各组测试的航速设置。

表 1 S60 各船模试验的对应航速

Table 1 Corresponding speed of each ship model test of S60

$C_B$	$Fn_1$	$Fn_2$
0.60	0.266	0.283
0.65	0.237	0.254
0.70	0.207	0.222
0.75	0.177	0.195

### 2.1 两种模型在 S60 船上的预报精度对比

以实验 Exp.2(测试集  $C_B = 0.65$ ) 为例, 选取  $C_B = 0.60, 0.70, 0.75, 0.80$  时的船舶几何外形及相应的速度、波长、增阻数据作为训练集, 分别训

练 DPN-AW 和 PCN-AW 模型。图 6 展示了训练后  $C_B = 0.65$  的测试船在  $Fn = 0.237$  时的预报结果。




图 6 实验 Exp.2 中模型的预报结果( $Fn = 0.237$ )

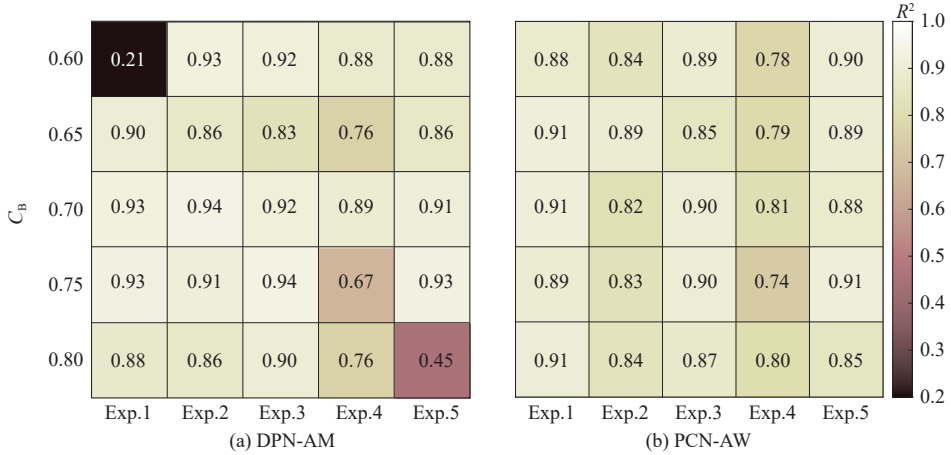
Fig. 6 Prediction results of model in Exp.2 ( $Fn = 0.237$ )

从图 6 中可以看出, 两种模型在该预报中的精度均较高。本文采用决定系数  $R^2$  来描述预报效果, 用于表明试验值被预测值解释的程度。决定系数  $R^2$  的定义如下:

$$R^2 = \frac{\sum (\hat{y}_i - \bar{y})^2}{\sum (y_i - \bar{y})^2} \quad (8)$$

式中:  $y_i$  为试验值;  $\bar{y}$  为试验值的均值;  $\hat{y}$  为预报值。在图 6 中, DPN-AW 和 PCN-AW 预报结果的决定系数分别为 0.95 和 0.96。作为参考, 图 6 还包括了文献 [14] 中所提深度前馈神经网络拟合的结果, 可以看出, 本文提出的 DPN-AW 和 PCN-AW 模型在  $C_B = 0.65$  的测试集上表现优秀, 特别是 PCN-AW 模型在预报极端波长中阻力的变化趋势以及波浪增阻的峰值时表现突出。

为了更全面地分析两种模型的准确性和稳定性, 类似地, 可以进行另外 4 组实验。图 7 列出了两者在 5 组实验中的预报效果, 每组实验训练出的模型均分别对 5 艘船在 2 个航速下的波浪增阻进行了预报, 结果以决定系数  $R^2$  表征。需要说明的是, 由于神经网络在训练前会随机初始化网络参数, 所以 DPN-AW 模型每次训练的结果会有波

图7 DPN-AW与PCN-AW的预报结果(以 $R^2$ 衡量)Fig. 7 Prediction results of DPN-AW and PCN-AW in  $R^2$ 

动。图6和图7中的预测值是由多个独立训练模型的预报结果平均而来,这一点将在2.2节中讨论。

从图7中可以看出,对测试集而言(2张子图的对角线元素),DPN-AW和PCN-AW模型在 $C_B = 0.65, 0.70$ 时预报效果均较好。然而从整体上看,PCN-AW模型表现得更加稳定,特别是在船型偏向极端时( $C_B = 0.60, 0.80$ )的预报中,其表现明显优于DPN-AW,体现出了泛化能力强的特点。此外,考虑到两者在训练集(非对角线元素)上精度相差不大,PCN-AW模型的精度在各个预报结果的表现均不差,而DPN-AW模型有过拟合的情况,阻碍了其精度的进一步提高以及在实际中的稳定发挥。

## 2.2 两种模型预报结果的稳定性对比

考虑到2.1节中出现的多次试验预报效果有波动的情况,对2种模型进行了10次独立的训练,用以研究二者训练效果的稳定性。同样以Exp.2为例,在保证参数一致的情况下,DPN-AW模型用同样的数据重复试验预报结果,如图8所示。




图8 DPN-AW模型重复试验的预报结果(Exp.2)

Fig. 8 Prediction results of repeated experiments with DPN-AW model (Exp.2)

图8示出了其中4次独立训练的预报结果以及10次训练得到的模型预报平均值。从中可明显看出,模型对于峰值位置、峰值大小、短波区阻力变化趋势等特征的预报均有一定的波动。将预报效果以 $R^2$ 进行衡量,4次典型预报结果的决定系数 $R^2 = 0.854, 0.922, 0.927, 0.773$ ;综合10次训练得到的结果,显示DPN-AW模型预报的 $R^2$ 的方差为 $3.9 \times 10^{-3}$ ,而PCN-AW给出的预报曲线几乎全部重合,其 $R^2$ 的方差为 $9.12 \times 10^{-5}$ ,效果更加稳定,预报的误差可控。因此,本文建议在使用传统DPN-AW模型时应取多次训练后预报结果的平均值作为模型的输出,以尽量控制因模型训练效果不一所造成的无法估计的误差,而使用PCN-AW模型时则能保证预报结果的稳定性。

## 2.3 模型优化

由于有关波浪增阻的试验数据较少,而点云特征提取模块又比较复杂,故PCN-AW模型的训练难度较大。为此,提出了一种基于预训练的优化方案,即将S60船的静水阻力数据<sup>[21-22]</sup>用于训练静水阻力预报模型,然后将编码器(点云特征提取模块)的参数作为波浪增阻预报模型编码器的初始参数。由于两个任务对于点云的特征提取有一定的共性,因此经过预训练的特征提取模块的性能有可能会提升。为了验证其效果,对优化前、后模型进行了训练和预报,并在全部5艘船上进行留一交叉验证的结果如表2(仅展示了测试集上的预报结果)所示。

从表2中可以看出,未经预训练的模型在约100轮次的训练后其预报精度大致稳定,而经过预训练的模型在第50轮次就已经达到一个较高且稳定的精度。结果表明,预训练利用了部分在静水阻力预报中已经训练的特征提取模块,因而

加快了训练的进程,且最终的预报精度也略高于未经预训练的模型,这一方法有助于在波浪增阻

数据量较小时对模型尽可能地进行优化以提升训练效果以及结果的收敛速度。

表2 测试集上预训练优化对模型预报效果的影响

Table 2 The impact of pre-training optimization on the prediction effect on the test set

训练轮次	$R^2$					
	$C_B = 0.60$	$C_B = 0.65$	$C_B = 0.70$	$C_B = 0.75$	$C_B = 0.80$	
优化前	50	0.797	0.808	0.911	0.494	0.712
	100	0.885	0.871	0.898	0.746	0.838
	150	0.882	0.892	0.895	0.743	0.846
优化后	50	0.896	0.853	0.883	0.711	0.876
	100	0.895	0.899	0.904	0.712	0.868
	150	0.897	0.900	0.899	0.714	0.868

### 3 结 语

本文提出了一种 PCN-AW 模型,通过将其与 DPN-AW 模型进行对比,发现基于 PCN-AW 的预报模型优势较多,这是因为其能更全面地捕捉船舶的几何特征,而非局限于有限的设计参数,因而也降低了人为选择特征的主观性。利用这样的模型结构,PCN-AW 模型的稳定性和准确性较高,能够更好地满足不同船舶外形和波浪条件的预测需求。在以 S60 船为例的预报中,DPN-AW 模型在  $C_B = 0.60$  时预报的决定系数  $R^2$  仅为 0.21,几乎失效;而 PCN-AW 模型在全部 5 艘船中的效果均较稳定, $R^2$  在 0.74~0.9 范围内。此外,本文还提出了一种通过静水阻力进行解码器预训练的模型优化策略,有助于解决在波浪增阻试验数据较少时模型训练的有效性,优化后的模型仅需 50 轮训练即可达到未优化模型 150 轮训练的效果,且最终的收敛精度也有所提高。

综上,本文提出的 PCN-AW 模型在船型的设计和 optimization 方面具有一定的潜力和应用前景,为改进船舶波浪增阻预测方法提供了新的思路和方法。未来,也可进一步探索点云特征提取技术在船舶设计和运营中的应用,以达到提高船舶综合航行性能的目的。

受限于波浪增阻的船模试验数据,本文仅探讨了对规则波的处理方法,对于非规则波,认为如果能够得到相应的船型、频谱及阻力数据,有希望通过将非规则波分解为规则波来预报各个组成部分的阻力值,然后再用在非规则波中测得的阻力训练出能将各个分量叠加起来的网络,从而达到对非规则波中增阻进行预报的目的。

### 参考文献:

[1] PÉREZ ARRIBAS F. Some methods to obtain the ad-

ded resistance of a ship advancing in waves[J]. *Ocean Engineering*, 2007, 34(7): 946–955.

[2] IMO. Interim guidelines for determining minimum propulsion power to maintain the manoeuvrability of ships in adverse conditions: MSC-MEPC. 2/CIR. 11[S]. MEPC, 2013.

[3] LEE J, PARK D M, KIM Y. Experimental investigation on the added resistance of modified KVLCC2 hull forms with different bow shapes[J]. *Proceedings of the Institution of Mechanical Engineers, Part M: Journal of Engineering for the Maritime Environment*, 2016, 231(2): 395–410.

[4] SIGMUND S, EL MOCTAR O. Numerical and experimental investigation of added resistance of different ship types in short and long waves[J]. *Ocean Engineering*, 2018, 147: 51–67.

[5] 孟巧,曲媛,陈玲.波浪增阻计算方法在船型综合优化设计中的应用[J].*中国舰船研究*, 2020, 15(2): 17–22.

MENG Q, QU Y, CHEN L. Application of wave added resistance calculation method in comprehensive optimization design of ship hull form[J]. *Chinese Journal of Ship Research*, 2020, 15(2): 17–22 (in Chinese).

[6] KIM Y, PARK D M, LEE J H, et al. Numerical analysis and experimental validation of added resistance on ship in waves[J]. *Journal of Ship Research*, 2019, 63(4): 268–282.

[7] PARK D M, LEE J H, JUNG Y W, et al. Experimental and numerical studies on added resistance of ship in oblique sea conditions[J]. *Ocean Engineering*, 2019, 186: 106070.

[8] PARK D M, LEE J H, LEE J, et al. Comparative study on added resistance of a container ship in waves[C]//The 29th International Ocean and Polar Engineering Conference. Honolulu: ISOPE, 2019.

[9] LEE J H, KIM B S, KIM B S, et al. Comparative study on added resistance of a bulk carrier in regular head and oblique waves[C]//The 30th International Ocean and Polar Engineering Conference, 2020.

[10] SHIGUNOV V, EL MOCTAR O, PAPANIKOLAOU A,

- et al. International benchmark study on numerical simulation methods for prediction of manoeuvrability of ships in waves[J]. *Ocean Engineering*, 2018, 165: 365–385.
- [11] LIU S K, PAPANIKOLAOU A. Regression analysis of experimental data for added resistance in waves of arbitrary heading and development of a semi-empirical formula[J]. *Ocean Engineering*, 2020, 206: 107357.
- [12] LANG X, MAO W G. A semi-empirical model for ship speed loss prediction at head sea and its validation by full-scale measurements[J]. *Ocean Engineering*, 2020, 209: 107494.
- [13] CEPOWSKI T. The prediction of ship added resistance at the preliminary design stage by the use of an artificial neural network[J]. *Ocean Engineering*, 2020, 195: 106657.
- [14] DUAN W Y, YANG K, HUANG L M, et al. A DFN-based method for fast prediction of ships' added resistance in heading waves[J]. *Ocean Engineering*, 2022, 245: 110484.
- [15] QI CHARLES R, SU H, MO K C, et al. PointNet: deep learning on point sets for 3D classification and segmentation[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu: IEEE, 2017.
- [16] QI C R, YI L, SU H, et al. PointNet++: deep hierarchical feature learning on point sets in a metric space [C]//Advances in Neural Information Processing Systems 30 (NIPS 2017), 2017.
- [17] ABBAS A, RAFIEE A, HAASE M, et al. Geometrical deep learning for performance prediction of high-speed craft[J]. *Ocean Engineering*, 2022, 258: 111716.
- [18] HU Q Y, YANG B, XIE L H, et al. RandLA-Net: efficient semantic segmentation of large-scale point clouds [C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle: IEEE, 2020.
- [19] STRØM-TEJSEN J, YEH H Y H, MORAN D D. Added resistance in waves[C]//Transactions of the Society of Naval Architects and Marine Engineers collection, 1973.
- [20] ITTC Seakeeping Committee. Report of seakeeping committee[C]//Proc. 11th ITTC, 1966: 329–479.
- [21] TODD F H. Some further experiments on single-screw merchant ship forms-series 60[C]//Transactions of the Society of Naval Architects and Marine Engineers, 1953.
- [22] TODD F H, STUNTZ G R, PIEN P C. Series 60—the effect upon resistance and power of variation in ship proportions[C]//Transactions of the Society of Naval Architects and Marine Engineers, 1957.

## Added wave resistance prediction and comparative study based on point cloud feature extraction

WU Mingfeng, ZHU Renchuan\*, XU Dekang

School of Ocean and Civil Engineering, Shanghai Jiao Tong University, Shanghai 200240, China

**Abstract:** [ **Objective** ] In order to rapidly forecast added wave resistance in the ship design stage, this paper proposes a neural network based on point cloud feature extraction. [ **Methods** ] Taking the Series 60 as an example, the corresponding added wave resistance prediction model is set up and compared with the traditional model based on the principal design parameters. By referring to S60 ship tests, the characteristics of the point cloud prediction model in terms of accuracy and stability are discussed, as well as the method of pre-training and optimizing the model using ship calm-water resistance data. [ **Results** ] The prediction results indicate that the proposed model can perform well in all five S60 ships, with the coefficient of determination  $R^2$  ranging from 0.74 to 0.90, while the traditional model based on the design parameters fails to make the correct prediction in some case. [ **Conclusion** ] This study provides new insights and a new approach to predicting added resistance in ship design, and may help to optimize ship forms by fully considering the impact of added wave resistance in the design phase.

**Key words:** added wave resistance; naval architecture; point cloud feature extraction; pre-training