

基于深度学习的悬链式单点系泊设计指标预测

孙强^{1,2}, 李颜³, 彭东升², 王宇新³, 阎军¹, 岳前进¹, 钟万勰¹

1. 大连理工大学运载工程与力学学部, 大连 116024

2. 大连船舶重工集团有限公司, 大连 116005

3. 大连理工大学电子信息与电气工程学部, 大连 116024

摘要 悬链式单点系泊需要建立基于基础条件、工作条件、自存条件、运动和力要求等输入的模拟环境, 并进行多点测试来寻找最佳设计。通过仿真计算构建2个主要数据集, 即 operation 数据集和 self 数据集。对 self 数据集进行预测, 并将数据分为局部、全局和全局加局部3类进行训练和验证, 使用4层全连接神经网络来预测回归问题, 准确率可达90%以上。将该模型应用于更复杂的 operation 数据集时的效果并不理想。采用DNN+BN+ReLU作为最小分量自建模型DBRNet12复杂网络处理 operation 的数据得到86%的平均准确率。依据残差思想在DBRNet12基础上自建RNet40网络取得了90%的平均准确率。在网络架构方面, 搭建了深度神经网络, 通过全连接层进行预测, 并对网络结构进行了持续的优化。最后, 通过相对误差的评估来衡量预测效果的优劣, 并利用残差网络进行优化。

关键词 多元回归; 单点系泊; 深度学习; 残差网络

单点系泊是最常用的浮式生产储卸油装置 (floating production storage offloading, FPSO) 系泊方案之一, 被广泛应用于世界各地的600多个油轮与陆地岸站之间的油气输送。在进行悬链式单点

系泊系统设计时, 需要考虑众多输入条件, 包括基础条件、工作条件、自存条件、运动和力要求等, 以建立准确的模拟环境。为了找到最佳设计, 还需要进行多点测试。然而, 由于参数众多, 使用传统的

收稿日期: 2023-06-25; 修回日期: 2024-04-22

基金项目: 国家重点研发计划深海关键技术与装备重点专项(2017YFC0307800-02); 国家海洋工程装备研发及产业化专项(船重科[2014]735号)

作者简介: 孙强, 博士研究生, 研究方向为海洋结构物系泊与水动力分析, 电子信箱: sunqiang_0217@163.com

引用格式: 孙强, 李颜, 彭东升, 等. 基于深度学习的悬链式单点系泊设计指标预测[J]. 科技导报, 2024, 42(13): 95-104;

doi: 10.3981/j.issn.1000-7857.2023.06.00958

仿真计算方法会耗费大量时间和计算资源,难以满足现代系泊系统快速设计的需求,因此需要探索新的方法。

为了解决这一问题,研究人员开始探索基于神经网络、深度学习等方法在悬链式单点系泊系统设计中的应用^[1-5]。深度学习方法可以通过学习大量的样本数据和特征表示,自动提取输入条件与系统响应之间的复杂关系。通过建立适当的神经网络架构,并利用图形处理单元(graphics processing unit, GPU)等高性能计算资源,可以加速设计过程,实现快速而准确地预测和优化。相比传统的仿真计算方法,深度学习方法能够在较短的时间内生成多个设计方案,并对其进行评估,为设计师提供更多选择和决策的空间。当然,将深度学习应用于系泊系统也面临一些挑战。首先,系泊系统数据可能存在噪声和缺失值,需要进行数据清洗和处理,以保证深度学习模型的准确性和稳定性。其次,深度学习模型的训练需要大量的标记数据,而在系泊系统领域可能存在数据获取困难的问题^[2-5]。因此,有效利用有限的标记数据和合成数据进行训练是一个重要的研究方向。

1 深度学习在海洋工程领域的应用概述

深度学习方法基于深度神经网络模型,在数据预测等领域已经取得了突破性的成果,并且有望继续推动相关领域的发展^[6]。深度神经网络在这里被视为函数近似机,在定义其结构方面有很大的灵活性,硬件的提升和算法效率的提高更使其成为近似操作系统目录页表(page directory entry, PDE)解决方案的一个重要选择^[7-8]。

机器学习和深度学习方法在海洋工程领域有着较广泛的应用^[9]。海洋洪水预警系统(EWS)的开发是对危机管理战略和预防及准备措施的补充。由于计算时间成本极高,高分辨率水动力模型被集成到EWS中将很困难。通过对预先计算的模拟结果进行统计分析,建立快速(计算时间成本低)的统

计预测模型,可以有效缓解这一问题^[10]。求解无黏欧拉方程的拉格朗日方法在激波附近容易产生数值振荡,减少这些振荡的常用方法是在离散方程中加入人工黏性(artificial viscosity, AV)^[11]。通过改进标准的二次线性人工黏性类型,用一个学习过的神经网络进行替代,产生一个混合的数值-神经网络流体动力学解算器,可以改善纯数值方法中存在的某些性能问题。针对舰船涂层损伤定位问题^[12],通过在随机船体表面位置定义所述损伤,并使用外加电流阴极保护(ICCP)系统提供的信息,以及计算的水下电位(UEP)特征作为输入参数来训练人工神经网络(ANN)以预测涂层损伤位置。

近年来,深度神经网络在系泊系统的预测问题中扮演了重要角色^[13]。首先,收集并准备了与预测问题相关的数据,包括环境参数、系统输入和输出等。其次,通过进行数据清洗和预处理,确保数据的质量和可用性。接着,进行了特征的选择和提取,以提高模型对系统动态的理解和预测能力。在网络架构设计方面,选择了适当的深度神经网络架构,以适应预测问题的复杂性。此外,将数据集划分为训练集、验证集和测试集,用于模型的训练、超参数调优和性能评估。通过使用适当的损失函数和优化算法,对模型进行了训练和优化,以最小化预测误差并提高泛化能力。通过评估指标,对模型的性能进行了验证。最后,通过模型推断和预测,能够获得准确的预测结果,并为改善系泊系统的性能和安全性提供有力支持。

在系泊系统预测问题中进行的相关工作,包括数据收集与准备、特征工程、网络架构设计、数据集划分、模型训练与优化,以及性能评估和预测等关键步骤。传统的深度神经网络在网络加深的过程中,网络的梯度可能会变得非常小,导致训练变得困难。为了解决这个问题,提出了残差结构,通过在网络中引入shortcut连接,将输入直接跨越多层连接到输出中,使得网络能够更加高效地学习特征。这样可以避免信息在网络中的丢失,同时也能使得网络更容易训练。在实践中,残差结构被广泛地应用于深度神经网络中,取得了很好的效果^[14]。

2 系泊系统数值模型与数据集构建

2.1 系泊系统数值模型

在系泊方案设计中,需要同时考虑作业工况和自存工况,作业工况是指油轮与浮筒呈连接状态,环境条件较为温和;自存工况是指浮筒单独漂浮的状态,环境条件较为恶劣,一般选取百年一遇海况。

无论是作业还是自存工况,都需要考虑某一根锚链断开的影响,称为破断工况,而锚链完整的状态称为完整工况。环境载荷入射方向与锚链位置的相对关系也会对锚泊系统响应造成影响,入射方向与某根锚链方向相同称为共线工况,入射方向处于两根或两组锚链之间则称为夹线工况。综合锚链是否破断、环境载荷是否共线及环境载荷与锚链的相对方向可以形成若干工况组合。

系泊设计过程需要进行水动力系泊耦合分析,针对每个计算工况模拟计算得到运动和受力响应,其中重点需要关注的是锚链和系泊缆受力极值、浮筒运动极值等。图1为作业工况的数值模型与典型环境载荷方向示意图。




图1 作业工况的时域分析数值模型与典型环境载荷方向

2.2 基础数据集

为验证系泊系统设计的质量,需要将设计与给定的环境和其他条件相结合作为输入,并通过计算得到的输出结果来判断设计的合理性。operation数据集和self数据集分别是作业工况和自存工况对应的数据集。

在operation数据集中,输入包括12种特征,分别为vw、vc、hs、tp、moor_d、d、pta、cabel_L、cabel_stiff_p、cabel_stiff_q、cable_br和ad。该数据集的输出由5个特征组成,分别为minlaidl、max_hawserC、maxchainFC、maxchainFC_DNV和maxoffsetC。在self数据集中,输入包括8种特征,分别为vw、vc、hs、tp、moor_d、d、pta和ad。输出由4个指标组成,表示为minlaidl、maxchainFC、maxchainFC_DNV和maxoffsetC。

每个特征的具体描述如下:vw表示风速,vc表示流速,hs表示有义波高,tp表示波浪谱峰值周期,moor_d表示水深,ad表示工作条件类型,d表示锚链直径,pta表示预紧角。需要说明的是,工作条件类型是从0开始的整数值,每个类型对应一个特定的环境参数组合,由于该数值本身并没有实际的物理意义,因此在数据可视化过程中通常不对其进行显示和分析。

2.3 训练集、验证集和测试集构建

拉丁超立方抽样是一种从多个参数分布中进行近似随机抽样的方法(假设在n维向量空间中抽取m个样本,如图2所示)。该方法具体流程是:

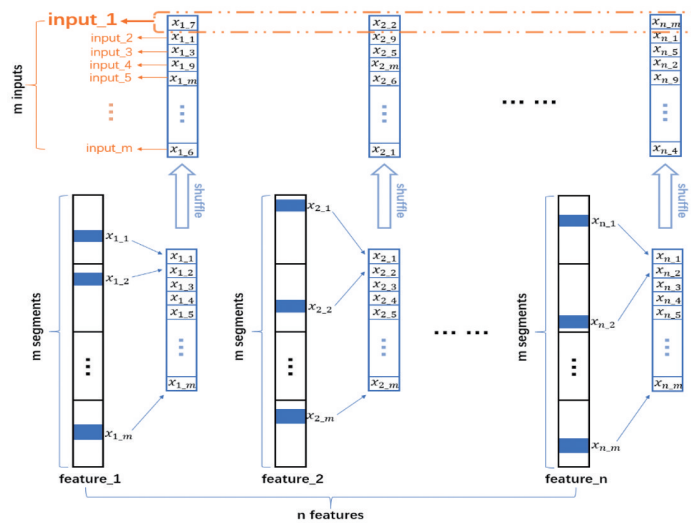


图2 拉丁超立方抽样

(1) 将每个维度平均分成 m 个区间, 这些区间互不重叠, 因此每个区间的采样概率相同; (2) 在每个维度的每个区间随机抽取一个点; (3) 将每个维度上随机抽取的点进行洗牌, 与其他维度上的点形成一个向量, 即为输入数据。如果每个维度被划分为 m 个区间, 就有 m 个输入数据。与随机法相结合, 可以用概率法客观地衡量实验结论^[8]。

采用拉丁超立方抽样方法在全局范围内均匀取点, 并将所选数据点作为输入, 通过 ANSYS 仿真计算得到输出结果并建立数据库。由于 ANSYS 计算时间较长, 因此, 在云平台上搭建了一个环境, 实现并行计算。由于作业条件和输入输出特点较多, 计算复杂度高, 因此在有限的时间内, 只能对少量作业点进行计算。虽然 self 数据集大致覆盖了整个领域, 但是点分布稀疏, 因此需要进一步增加数据量。Operation 数据总量为 60880 个, self 数据总量为 57840 个。

针对 self 数据集, 本研究将其分为 3 组。首先, 是测试点周围产生的局部数据; 其次, 是在全局范围内通过拉丁超立方抽样方法产生的全局数据; 最后, 是在全局数据的基础上加入局部数据, 以探讨预测数据密度对模型精度的影响。在评价模型的预测效果时, 需要将数据集分为 3 个部分: 训练集、验证集和测试集。其中, 训练集用于训练模型, 而验证集和测试集则用于检验模型的预测效果。在本实验中, 验证集的数据与训练集相似, 但 2 个数据集在大多数情况下的主要区别在于工作条件的类型。测试集则由过去的实际工程数据组成, 与训练集和验证集不同之处在于其存在很多相关性, 因此模型对测试集的预测效果往往不如对验证集的预测效果好。在划分训练集和验证集时, 为了保证均匀抽样, 本实验采用伪随机数的方法, 从数据集中抽取 1/5 作为验证集, 其余则作为训练集。

3 深度神经网络模型构建

本研究的模型首先在较小的 self 数据集上进行实验, 然后逐步扩展至更复杂的 operation 数据集。

3.1 模型的建立和评价指标的选择

根据 self 数据集的特点, 建立了如图 3 所示的包含 1 个输入层、2 个隐藏层和 1 个输出层的神经网络, 该网络有 8 个输入节点、40 个隐藏节点和 4 个输出节点。本项目的学习率 lr 为 0.001, 每个训练批次的样本数为 32, 损失函数采用均方误差。




图3 深度神经网络

由于这是一个回归问题, 每个数据有 8 个输入属性和 4 个输出属性。使用均方误差 (mean square error, MSE)、平均绝对误差 (mean absolute error, MAE) 和决定系数 (coefficient of determination, R^2 score) 等评价指标来衡量模型性能、显示输出数据结果之间的差异大小。例如, 有些属性是 3 位数, 有些属性是个位数, 这会导致数值差异较大, 计算时可能会产生小数精度问题, 虽然能获得较高的准确率, 但不能保证预测结果的准确性。为了更好地预测每个数据的属性, 采用相对误差法来检验预测准确性。具体而言, 计算每个输出数据属性的相对误差, 将每个数据属性的 4 个相对误差求和, 作为该数据的预测准确性指标。使用公式(1)计算准确率

$$acc = 1 - \frac{|predict - actual|}{actual} \quad (1)$$

3.2 算法模型的建立

本实验旨在解决实际应用问题, 采用 Python 自建的深度神经网络 (deep neural network, DNN) 全连接网络, 利用深度学习进行预测。使用全连接神经网络进行训练, 并选择合适的评价指标以衡量预测性能。

首先, 需要进行数据预处理。在本实验中, 模型的输入数据分为训练数据和测试数据。由于原始数据中每一项的差异可能非常大, 需要对输入的

数字进行归一化以消除数字之间的差异。具体来说,使用 MinMaxScaler 将数据特征缩放到一定范围,将数据缩放到 0 和 1 之间。

其次,需要选择合适的网络评价指标。在本实验中,主要采用 R^2 Score、MAE、MSE,以及相对误差等指标来评价神经网络的性能。由于神经网络将输出 4 个指标,存在着“大数吃小数”的问题,为了避免这个问题,对这 4 个指标逐一进行分析,即计算每个指标的相对误差,观察其预测精度,使用 1-(相对误差之和的平均值)来表示数字预测的准确性,这样更能反映预测值与真实值之间的预测误差。

再次,需要找到合适的网络训练次数。在选择了一个合适的评价系统后,可以将其作为训练神经网络的基础。为了选择最合适的训练次数,在手动调节的情况下修改代码,同时修改训练损失,达到一定数据量时停止训练。在本实验中,选择 2000 作为最后的训练轮数。在前 1000 个 epochs 中,损失率非常快,下降幅度也非常大。在前 1000 个历时之后,损失仍然在下降,而且下降的速度很慢。在 2000 个 epochs 之后,损失几乎不再下降,因此在这个时候停止训练以防止过度拟合。

最后,需要找到一个合适的网络结构。有 2 种方法可以优化网络结构:在原网络结构下进行优化,或者改变网络结构使用一个全新的网络。在本实验中,主要采用第 1 种方法,在现有的网络结构下进行优化。首先将神经网络结构从原来的 2 个隐层结构增加到 4 层,然后再增加到 8 层,并分别进行训练。但是,当网络结构增加到 8 层时,神经网络无法训练,损失不变。因此,最终采用了 4 层神

经网络,并使用 self 数据进行训练。通过预测 10 种工作条件的数据,可以获得更好的训练结果。得到的 acc 准确率曲线如图 4 所示。




图 4 准确率曲线

观察图 4 中的准确率曲线,可以看到在 10 个工况中,第 5 个工况的预测具有最高的准确率,达到了 89%。

接下来,使用开源神经网络库 Keras 构建一个 4 层的神经网络,再使用正则化数据改进的 Keras 网络(Regularized Keras)进行实验比较。使用局部数据来进行训练,取 10 组 self 数据作为测试数据。可以发现,此时无论使用哪种网络,第 6 条和第 7 条数据的预测都极不准确,而第 4 条和第 10 条数据的预测相对不准确。其他 6 条数据的预测准确性比较高。

进一步地,使用机器学习库 Pytorch 建立神经网络进行测试,此时每条数据的预测准确率几乎都保持在 90% 以上。当每层的节点数优化调整(optimized pytorch)为 32 时,预测结果得到进一步提升改善。这个结果远远超出了使用 Python 自建网络的结果,也比使用 Keras 库更加稳定,代表了对数据更准确的预测能力。表 1 列出了上述结果。

表 1 Pytorch 建立神经网络测试准确率

神经网络	工况									
	Article 1	Article 2	Article 3	Article 4	Article 5	Article 6	Article 7	Article 8	Article 9	Article 10
Python	0.804428	0.863205	0.864914	0.828456	0.892218	0.739075	0.733828	0.881177	0.750537	0.7353217
Keras	0.944224	0.853424	0.871578	0.771578	0.900008	0.740113	0.734809	0.951118	0.925852	0.7198990
Regularized Keras	0.927934	0.886298	0.897295	0.782202	0.912768	0.726274	0.687471	0.967696	0.924402	0.7058966
Pytorch	0.928404	0.903308	0.917733	0.916165	0.919236	0.944247	0.935354	0.895936	0.927596	0.9278055
Optimized Pytorch	0.920549	0.920863	0.904253	0.934635	0.933494	0.931232	0.951335	0.947785	0.932724	0.9521567

3.3 模型验证

根据以上训练模型,使用局部数据进行训练,并在10个工况数据上进行测试。基于这些结果,选择了最佳的Pytorch网络。接下来,将使用全局加局部数据和全局数据来进行模型的训练和验证。

3.3.1 使用全局数据进行训练验证

根据上述步骤,使用包含28642个样本和8个特征的全局训练数据集,以及7098个样本和4个特征的验证数据集。在不对原有Pytorch网络模型做基本改动的情况下,进行了训练,并通过2000轮的迭代获得了验证结果。图5显示了全连接训练的过程。




图5 全局数据下自持工况响应预测的全连接训练过程

使用验证数据进行验证,得到7098个验证结果,如图6所示。图6显示了验证集的相对误差的准确性描述。可以看出,对于大部分的数据,数据预测的准确率大多在80%以上。




图6 全局数据下自持工况响应预测的完整连接验证结果

3.3.2 使用全局和局部数据进行训练验证

根据以上步骤进行训练,在不基本改变原有Pytorch网络模型的基础上,使用全局和局部数据进行模型训练和验证。全局和局部训练数据集的特征大小为46412×8,其中训练数据量为46412件,

验证数据集特征大小为11428×4,验证测试量为11428。经验证,全连接训练轮数基本为6000轮输出结果。图7展示了全局结合局部数据的全连接训练过程。




图7 全局结合局部数据下自持工况系泊响应预测的全连接训练过程

使用验证数据集进行验证,得到11428个验证结果,全局数据预测的相对误差结果如图8所示。可以看出,对于全局和局部数据,大多数数据预测的准确率已经达到了90%以上,预测效果超过了仅使用全局数据的预测结果。




图8 全局结合局部数据下自持工况系泊响应预测的全连接验证结果

3.4 建立 operation 数据集上的算法模型

上述算法在self数据集上表现更好。实际系泊系统中,悬链锚腿系泊装置(catenary anchor leg mooring, CALM)系统由1个浮筒、6根锚索和1对系泊锚索组成。对于正常环境条件,设计考虑了环境的极端组合,并适当地选择和组合为以下情况:operation条件下,1艘油轮挂在1个CALM浮筒上,该浮筒由一个完整或损坏的系泊系统停泊。系泊油轮所考虑的2种装载条件是满载和压载。此外,CALM浮筒在完整或损坏的系泊系统下,可以在没有附属油轮的情况下独立存在。因此,需要考虑更复杂的情况,故使用operation数据集进行训练和验证。

本研究使用上面提到的准确率作为验证集的评价指标,以验证实验预测集的预测准确性。在使用 operation 数据集进行验证后,得到了如图9所示的结果。可以看到之前提出的模型在 operation 数据集上得到了较差的准确率。




图9 全局结合局部数据下作业工况系泊响应预测的全连接验证结果

3.4.1 建立复杂模型验证复杂数据集

神经网络的训练是一个复杂的过程,在神经网络训练的过程中,每一层训练数据的分布一直在发生变化,一直变化的数据分布会在一定程度上对神经网络的训练产生影响, Batch Normalization (BN) 就是要解决在训练过程中,中间层数据分布发生改变的情况。

BN层的原理和计算过程如图10所示,假设输入的数据集集合为 \mathbf{B} ,其中包括2个可以训练的参数 γ, β ;先计算 \mathbf{B} 的均值和方差,再将 \mathbf{B} 的均值和方差变为0和1,再将 \mathbf{B} 中的每一个元素先乘 γ 再加 β ; γ, β 作为可以训练的参数参与整个网络的BP; BN 归一化后使用 γ, β 作为还原参数,可以在一定的程度上保留原始数据的分布^[15]。

$$\begin{aligned}
 \text{Input: } \mathbf{B} &= \{x_{1,2,\dots,m}\}; \\
 \gamma, \beta &(\text{parameters to be learned}) \\
 \text{Output: } \{y_i &= BN_{\gamma, \beta}(x_i)\} \\
 \mu_B &\leftarrow \frac{1}{m} \sum_{i=1}^m x_i \\
 \sigma_B^2 &\leftarrow \frac{1}{m} \sum_{i=1}^m (x_i - \mu_B)^2 \\
 \tilde{x}_i &\leftarrow \frac{x_i - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}} \\
 y_i &\leftarrow \gamma \tilde{x}_i + \beta
 \end{aligned}$$

图10 Batch Normalization 计算过程

在引入了BN层之后,可以提高网络的泛化能力不会产生过拟合,不用考虑 drop out 等使用;由于BN本身的作用就是归一化网络层,所以就不需要使用局部相应归一化层;选择过大的学习率或者过小的学习率都不会对模型产生较大的影响。

激活函数是神经网络中非常重要的组成部分之一,它的作用是为神经网络引入非线性特性,从而能够更好地拟合非线性数据,并提高神经网络的表达能力。在神经网络中,每个神经元的输入都是加权和,如果直接把输入传递给下一层神经元,那么神经网络的输出就是一个线性函数。因此,需要使用激活函数将其加权和转换为非线性函数,以增加神经网络的表达能力和拟合能力^[16]。

激活函数的作用是使神经网络能够更好地拟合非线性数据,同时可以避免梯度消失或梯度爆炸问题。通过引入非线性特性,激活函数使神经网络能够更好地处理非线性数据,提高了神经网络的表达能力和拟合能力。

使用建立的模型来验证 operation 数据集,但是结果偏差很大。因此,修改了网络结构和优化算法模型,使其在 operation 数据集上有更好的效果。进一步深化了网络结构以获得更好的结果。该模型的基本组件 DBR 组成部分是 DNN+BN+ReLU (rectified linear unit), 整个网络的基本组件如图11所示。其中, BN层可以加速神经网络的训练,使得网络的训练更加稳定,并在一定程度上起到正则化的效果。激活函数的作用是可以处理非线性关系,扩大网络的表达能力,从而处理更加复杂的情况。整个网络由 DBRX 基本组件组成, X 表示 DBR 组件的个数,而每一层的节点数都是不同的。继续使用 operation 数据集来验证这些结果。



图11 DBRX 神经网络

自建 DBRNet12 网络用于对 operation 复杂数据集进行预测,对 operation 进行验证得到以下的结果,如图12所示。

为了更加直观地观察预测结果的准确性并便于与后续结果进行比较,截取一些预测结果进行展




图 12 全局结合局部数据下作业工况系泊响应预测的复杂网络验证

表 2 DBRNet12网络复杂数据预测准确率表

Net	Num1	Num2	Num3	Num4	Num5	Num6	Num7	Num8	Num9
DNN	0.83	0.81	0.80	0.84	0.86	0.83	0.82	0.79	0.84
DNN+BN+ReLU	0.93	0.90	0.88	0.92	0.94	0.91	0.89	0.87	0.93

3.4.2 建立残差模型验证复杂数据集

Residual(残差)结构是一种广泛应用于深度神经网络的设计思想。在传统的网络结构中,每一层的输出都直接作为下一层的输入,而在 Residual 结构中,每一层的输入不仅传递给下一层,还会被用于计算输出,从而更好地利用输入信息。这种设计可以有效地解决网络退化问题,即网络深度增加时,性能反而下降的现象^[7]。

Residual 结构通常由 1 个或多个 Residual Block 组成。1 个 Residual Block 包含多个卷积层和激活函数,其输入和输出之间的残差被加到输出中,从而实现信息的跳跃连接。这种跳跃连接可以有效地减少梯度消失的问题,提高模型的训练效率和性能。

本研究的 Residual Block 组成如图 13 所示。每个块都由 2 个全连接层、1 个 BN 层和 1 个 ReLU 激活函数构成。在每个残差块内部,把输入 X 保存下来,先对输入 X 进行全连接 BN,再经过激活函数 ReLU,接着进行一次全连接和 BN,最后把这个结果和输入 X 相加,就构成了一个残差块。这样可以避免深度网络中的梯度消失问题,并且可以加速模




图 13 Residual Block 组成

示,如表 2 所示。

经过多次实验,得出了如下结论:简单的神经网络在 self 数据集中可以达到很好的预测效果,但是当使用更复杂的 operation 数据集时,简单的神经网络的预测效果就不够好。因此,需要使用更复杂的网络结构来提高预测效果。在研究中,使用更复杂的网络结构得到了改善的效果,表明 DBRNet12 复杂网络结构在 operation 数据集中有很好的预测效果,准确率平均提升了 10%,达到 86%。

型的训练。经过实验,整个网络共有 40 个这样的残差块,便可以达到最好的效果。

整个网络一共包含 40 个 Residual Block 模块,所以本研究给该网络命名为 RNet40,接下来用该网络对 operation 数据集进行验证得到以下结果,如图 14 所示。该模型在 operation 数据集上取得了 90% 平均准确率,相较于 3.4.1 节提出的 DBRNet12 复杂网络的平均准确率提高了 4%。




图 14 全局结合局部数据下作业工况系泊响应预测的 RNet40

4 结论

将系泊系统中的数据集分为 2 个部分。首先对 self 数据集进行预测,通过建立一个全连接的 4 层神经网络来解决回归问题。该模型具有 8 个输入和 4 个输出,使用的数据包括局部数据、全局数据和全局加局部数据。用相对误差来衡量准确率,结果显示准确率可以保持在 90% 以上。

当模型在 self 数据集上取得良好的效果后,该模型被用于预测和验证 operation 数据集,但预测准确率很低。因此,对网络结构进行优化:通过特征工程,处理过滤掉一些不重要的数据和对实验有影响的数据;建立更加复杂的网络结构,主网络采用 DNN+BN+ReLU;在此基础上,进行训练和验证,最终平均准确率提高了 10% 左右。由于模型随着网络的加深容易出现过拟合,进一步搭建了包含 40 个 Residual Block 模块的网络模型 RNet40,其在 operation 数据集上的平均准确率可以达到 90%。

本文研究了基于深度学习方法单点系泊系统设计问题。通过学习大量的样本数据和特征表示,自动提取出输入条件与系统响应之间的复杂关系,可以替代 ANSYS 等仿真计算工具,在较短的时间内生成多个设计方案,满足现代系泊系统快速设计的需求,为设计师提供更多选择和决策的空间。

参考文献 (References)

- [1] 武文华, 赵梓舒. 基于深度学习的软刚臂系泊系统铰节点损伤识别方法研究[D]. 大连: 大连理工大学, 2020.
- [2] 邓林青, 朱耀文, 王宏伟, 等. 基于 NARX 神经网络的 FPSO 系泊缆张力预报[J]. 海洋工程装备与技术, 2020, 7(2): 85-92.
- [3] 张隆辉, 刘正锋, 魏纳新, 等. 基于 NARX 网络模型的系泊缆截断点运动计算[J]. 船舶力学, 2019, 23(8): 936-947.
- [4] 许小颖, 周盼, 王宽. 基于神经网络和遗传算法的系泊优化设计[J]. 中国舰船研究, 2017, 12(5): 97-103.
- [5] 孙丽萍, 张伟, 艾尚茂. 基于神经网络和遗传算法的系泊线长度参数优化[J]. 船舶工程, 2015, 37(4): 88-91.
- [6] 无深度学习技术下的人工智能时代[J]. 大数据时代, 2021(6): 56-76.
- [7] Shi Q, Chen W Y, Huang S Q, et al. Deep learning for mining protein data[J]. Briefings in Bioinformatics, 2021, 22(1): 194-218.
- [8] Elbrachter D, Perekrestenko D, Grohs P, et al. Deep neural network approximation theory[J]. IEEE Transactions on Information Theory, 2021, 67(5): 2581-2623.
- [9] Lou R R, Lü Z H, Dang S P, et al. Application of machine learning in ocean data[J]. Multimedia Systems, 2023, 29(3): 1815-1824.
- [10] Rohmer J, Idier D, Pedreros R. A nuanced quantile random forest approach for fast prediction of a stochastic marine flooding simulator applied to a macrotidal coastal site[J]. Stochastic Environmental Research and Risk Assessment, 2020, 34(6): 867-890.
- [11] Melland P, Albright J, Urban N M. Differentiable programming for online training of a neural artificial viscosity function within a staggered grid Lagrangian hydrodynamics scheme[J]. Machine Learning: Science and Technology, 2021, 2(2): 025015.
- [12] Thiel C, Neumann K, Ludwar F, et al. Coating damage localization of naval vessels using artificial neural networks[J]. Ocean Engineering, 2019, 192: 106560.
- [13] 周飞燕, 金林鹏, 董军. 卷积神经网络研究综述[J]. 计算机学报, 2017, 40(6): 1229-1251.
- [14] Zhang J, Xiao W D, Li Y J, et al. Residual compensation extreme learning machine for regression[J]. Neurocomputing, 2018, 311(C): 126-136.
- [15] Garbin C, Zhu X Q, Marques O. Dropout vs. batch normalization: An empirical study of their impact to deep learning[J]. Multimedia Tools and Applications, 2020, 79(19): 12777-12815.
- [16] Bawa V S, Kumar V. Linearized sigmoidal activation: A novel activation function with tractable non-linear characteristics to boost representation capability[J]. Expert Systems with Applications, 2019, 120: 346-356.
- [17] Aydemir M E, Aydemir C. Residual displacement estimation of simple structures considering soil structure interaction[J]. Earthquakes and Structures, 2019, 16(1): 69-82.

Deep learning based catenary single point mooring design parameters prediction

SUN Qiang^{1,2}, LI Yan³, PENG Dongsheng², WANG Yuxin³, YAN Jun¹, YUE Qianjin¹, ZHONG Wanxie¹

1. Faculty of Vehicle Engineering and Mechanics, Dalian University of Technology, Dalian 116024, China

2. Dalian Shipbuilding Industry Co., Ltd., Dalian 116005, China

3. Faculty of Electronic Information and Electrical Engineering, Dalian University of Technology, Dalian 116024, China

Abstract A catenary single-point mooring requires a simulation environment based on inputs such as basic conditions, operating conditions, self-storage conditions, motion and force requirements, and multi-point testing to find the optimal design. The paper uses deep learning method to solve the mooring system prediction problem. Firstly, two datasets, i.e., self dataset and operation dataset are acquired by simulation calculation. Then the self dataset is predicted and the data is divided into three categories: local, global, and global plus local for training and validation, and a two-layer full-connected neural network is used to predict the regression problem with an accuracy of over 90%. As the results are not satisfactory when the model is applied to more complex operation datasets, a self-built model DBRNet12 complex network using DNN+BN+ReLU as the minimum component is added to handle more operation data, thus obtaining an average accuracy of 86%. The self-built RNet40 network based on the idea of residuals on DBRNet12 achieves a 90% average accuracy. In terms of network architecture, a deep neural network is built to predict parameters through fully connected layers, and the network structure is continuously optimized. Finally, the evaluation of relative error is used to evaluate the effectiveness of the prediction and the residual network is used for optimization. Through this procedure, the application effect of deep learning methods in mooring system prediction problems is achieved, and the ideas provide references for further research and practice in this field.

Keywords multiple regression; single point mooring; deep learning; residual network ●



(责任编辑 王微)