

8-15-2024

Digital Twin Method of Stress Field of Deep Submersible Spherical Shell Based on Simulation Database

Yu Cao

Shanghai Ocean University, Shanghai 201306, China; State Key Laboratory of Industrial Equipment Structure Analysis of Dalian University of Technology, Dalian 116081, China

Jie Li

Shanghai Ocean University, Shanghai 201306, China

Fang Wang

Shanghai Ocean University, Shanghai 201306, China

Zhixiang Liu

Shanghai Ocean University, Shanghai 201306, China

See next page for additional authors

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

This Special Column: Digital Twin and Intelligent Simulation of Marine and Maritime is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation. For more information, please contact xtfzxb@126.com.

Digital Twin Method of Stress Field of Deep Submersible Spherical Shell Based on Simulation Database

Abstract

Abstract: This paper presents a method for predicting the stress field of deep diving spherical shells based on simulation databases and digital twin technology. By establishing simulation databases of stress field distribution of pressure-resistant spherical shells under different scales and loads, virtual sensing monitoring of stress states in other parts of the vessel is realized through finite sensor layout of pressure-resistant shells on the submersible. Based on the DT(digital twin) technology, a three-level virtual structure layer is constructed. The Level-1 DT layer realizes the spatial mapping and cloud image display from the finite element simulation model to the digital model. The error between the experimental and numerical results of the ultimate bearing capacity of the spherical shell is less than 9.4%. The Level-2 DT layer realizes the data sample deduction of the digital model by create database. The stress field distribution of the spherical shell under the condition that the size and load are not obtained in the simulation database is obtained by the local Lagrange interpolation method. The relative error of the stress interpolation result is 4.8%. The Level-3 DT layer develops a machine learning prediction function for the stress field distribution in the dangerous area of the deep-submersible spherical shell digital model. The BP neural network optimized by the particle swarm optimization algorithm ensures that the error between the prediction result and the simulation result is less than 1%. This method comprehensively considers the material properties, structural dimensions and environmental loads, which can provide a reference for the real-time safety assessment of the pressure hull structure, and realize the dynamic perception, intelligent diagnosis and scientific prediction of the dynamic stress field distribution of all deep-submersible spherical shells on the hull.

Keywords

simulation database, digital twin, deep submerged spherical shell, stress field distribution, optimization algorithm

Authors

Yu Cao, Jie Li, Fang Wang, Zhixiang Liu, and Xueliang Wang

Recommended Citation

Cao Yu, Li Jie, Wang Fang, et al. Digital Twin Method of Stress Field of Deep Submersible Spherical Shell Based on Simulation Database[J]. Journal of System Simulation, 2024, 36(8): 1764-1779.

基于仿真数据库的深潜球壳应力场数字孪生方法

曹宇^{1,2}, 李杰¹, 王芳¹, 刘智翔¹, 汪雪良³(1. 上海海洋大学, 上海 201306; 2. 大连理工大学 工业装备结构分析国家重点实验室, 辽宁 大连 116081;
3. 中国船舶科学研究中心, 江苏 无锡 214082)

摘要: 提出一种基于仿真数据库及数字孪生技术的深潜球壳应力场预报方法, 通过建立不同尺度及载荷下耐压球壳的应力场分布仿真数据库, 在潜水器上实现了通过单个耐压壳有限传感器布点虚拟传感监测其他关键部位的应力状态。基于数字孪生技术构建三级虚拟结构层, Level-1 DT层实现从有限元仿真模型到数字模型的空间映射及云图展示, 球壳的极限承载力实验与数值结果对比误差小于9.4%。Level-2 DT层通过创建数据库实现数字模型的数据样本推演, 仿真数据库中未获得尺寸及载荷条件下的球壳应力场分布通过局部拉格朗日插值方法获得, 插值应力结果相对于仿真结果的相对误差为4.8%。Level-3 DT层开发了深潜球壳数字模型危险区域应力场分布的机器学习预报功能, 通过粒子群算法优化后的BP神经网络保证预测结果与仿真结果的误差小于1%。该方法综合考虑材料性能、结构尺寸和环境载荷, 可以为耐压壳结构的实时安全评估提供参考, 实现对潜水器单个或多个球壳应力场分布的动态感知、智能诊断和科学预测。

关键词: 仿真数据库; 数字孪生; 深潜球壳; 应力场分布; 优化算法

中图分类号: TP391.9 文献标志码: A 文章编号: 1004-731X(2024)08-1764-16

DOI: 10.16182/j.issn1004731x.joss.24-0173

引用格式: 曹宇, 李杰, 王芳, 等. 基于仿真数据库的深潜球壳应力场数字孪生方法[J]. 系统仿真学报, 2024, 36(8): 1764-1779.

Reference format: Cao Yu, Li Jie, Wang Fang, et al. Digital Twin Method of Stress Field of Deep Submersible Spherical Shell Based on Simulation Database[J]. Journal of System Simulation, 2024, 36(8): 1764-1779.

Digital Twin Method of Stress Field of Deep Submersible Spherical Shell Based on Simulation Database

Cao Yu^{1,2}, Li Jie¹, Wang Fang¹, Liu Zhixiang¹, Wang Xueliang³

(1. Shanghai Ocean University, Shanghai 201306, China; 2. State Key Laboratory of Industrial Equipment Structure Analysis of Dalian University of Technology, Dalian 116081, China; 3. China Ship Scientific Research Center, Wuxi 214082, China)

Abstract: This paper presents a method for predicting the stress field of deep diving spherical shells based on simulation databases and digital twin technology. By establishing simulation databases of stress field distribution of pressure-resistant spherical shells under different scales and loads, virtual sensing monitoring of stress states in other parts of the vessel is realized through finite sensor layout of pressure-resistant shells on the submersible. Based on the DT(digital twin) technology, a three-level virtual structure layer is constructed. The Level-1 DT layer realizes the spatial mapping and cloud image display from the finite element simulation model to the digital model. The error between the experimental and numerical results of the ultimate bearing capacity of the spherical shell is less than 9.4%. The Level-2 DT layer realizes the data sample deduction of the digital model by create database. The stress field

收稿日期: 2024-02-29 修回日期: 2024-05-14

基金项目: 国家自然科学基金(52371282); 大连理工大学工业装备结构分析国家重点实验室开放课题基金(GZ22113)

第一作者: 曹宇(1982-), 男, 副教授, 博士, 研究方向为结构应力场数字孪生方法应用。

distribution of the spherical shell under the condition that the size and load are not obtained in the simulation database is obtained by the local Lagrange interpolation method. The relative error of the stress interpolation result is 4.8%. The Level-3 DT layer develops a machine learning prediction function for the stress field distribution in the dangerous area of the deep-submersible spherical shell digital model. The BP neural network optimized by the particle swarm optimization algorithm ensures that the error between the prediction result and the simulation result is less than 1%. This method comprehensively considers the material properties, structural dimensions and environmental loads, which can provide a reference for the real-time safety assessment of the pressure hull structure, and realize the dynamic perception, intelligent diagnosis and scientific prediction of the dynamic stress field distribution of all deep-submersible spherical shells on the hull.

Keywords: simulation database; digital twin; deep submerged spherical shell; stress field distribution; optimization algorithm

0 引言

深水潜器是深海环境科学调查、资源勘探和环境监测等各种任务的重要工具。耐压壳是深水潜器的核心部件,主要用于抗高压,保护内部人员及仪器设备等^[1]。在下潜作业中,深水潜器通常有多个壳体需要健康监测,典型载人潜水器至少有10个壳体,在每个外壳上安装传感器将非常复杂、耗时和费力。传统的结构应力场监测主要依赖物理传感器。Huang等^[2]将微型圆柱形应变片嵌入滚刀底部和侧面的预钻孔中,并使用无线应变节点测量,实现对结构应力及应变的实时监测;Chen等^[3]提出了一种使用有限元仿真软件显示二次开发子程序的计算结果,以达到监测应力的实时显示;张涛等^[4]提出一种基于人工智能的三维结构全局应力求解方法,通过少量应力测点实现对三维结构物应力场的空间分布求解,为全局应力的监测提供了新的思路;Yao等^[5]考虑了结构的老龄化导致材料属性的变化规律,通过神经网络训练获得了更精确的全局应力求解。结构实时健康监测在工程领域应用广泛,但在潜水器应用中,由于超高水压和水密性要求,传统监测仪器仅能获得有限节点的结构响应信息,需要探寻结合机器智能的结构整体应力场虚拟传感监测技术。

随着数字孪生方法、大数据分析及机器学习技术的快速发展,结构响应预测模型正在向数字化模

型转变。Liu等^[6]将管道故障的应力数据存储到数据库中,通过神经网络训练完成了相对精准的结构故障预测;Chen等^[7]将支持向量机回归方法应用于沙漠线熔沉区不同位置的管拱和背拱轴向应力预测,虚拟监测结果与现场实测结果的相对误差小于15%;Huang等^[8]利用Arrhenius模型和随机森林、支持向量机、BP神经网络和径向基函数神经网络4种机器学习算法成功预测了GH3536高温合金的高温流变应力变化规律;毛子泉等^[9]从数字孪生、LVC仿真和平行系统3个方向总结了目前虚实结合仿真的优势和不足,指出数字孪生方法会成为预测的热门技术。可以看出,数字孪生方法、大数据分析及机器学习技术可以应用于结构应力场虚拟传感监测。

耐压壳体的全局应力监测可以更好地了解壳体的服役健康状态以及是否有潜在裂纹产生,目前,潜水器耐压壳体的整体应力监测技术尚不多见,光纤应力应变计是实时监测结构应力的主要手段,但测点只能布置在有限的区域内,无法监测整个耐压壳体的应力场分布。此外,潜水器通常有多个大小不一的仪器保护壳,在保护壳中设置监测点不仅容易损坏,而且维护费用也高。本文将仿真数据库技术与智能优化算法相结合,提出了一种基于仿真数据库的深潜球壳应力场分布快速预测的数字孪生(DT)方法。通过构建三级数

字孪生体，采用智能优化算法修正误差，基于潜水器耐压壳有限传感器布点数据反演其他部位的应力状态，为潜水器单个或多个球壳的实时虚拟传感监测以及结构整体健康评估提供科学依据。

1 理论与数字模型

1.1 数字孪生模型

三级数字孪生体的模型架构如图 1 所示。数字孪生模型由 3 个级别的 DT 组成，一级 DT 将仿真结果数据映射到二级 DT，并将三维有限元模型 (finite element models, FEM) 转化为一维数字模型，

一级 DT 主要执行预设样本的创建和模型映射；二级 DT 扩展、推演数字模型样本信息并将其存储在数据库中，之后将数字模型推演结果信息提交到三级 DT，二级 DT 完成了数字模型的存储以及扩展推演计算；三级 DT 利用机器学习识别样本数据模式，预测结构整体应力场分布状态，快速显示应力场分布云图。三级数字孪生模型通过建立仿真数据库，利用数据推演技术将三维有限元模型转化为一维数字模型，实现结构整体应力场分布的快速预测及呈现，数字孪生技术流程如图 2 所示。

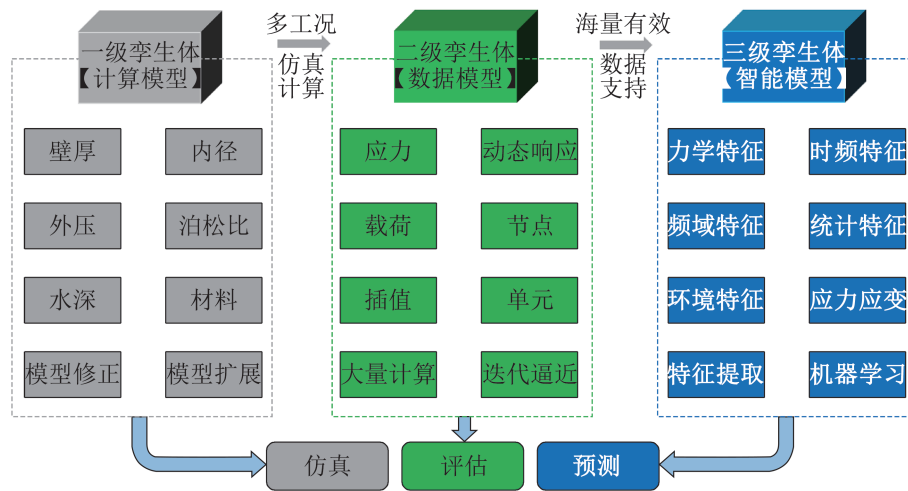


图 1 三级数字孪生体的模型架构
Fig. 1 Three-level digital twin flow chart

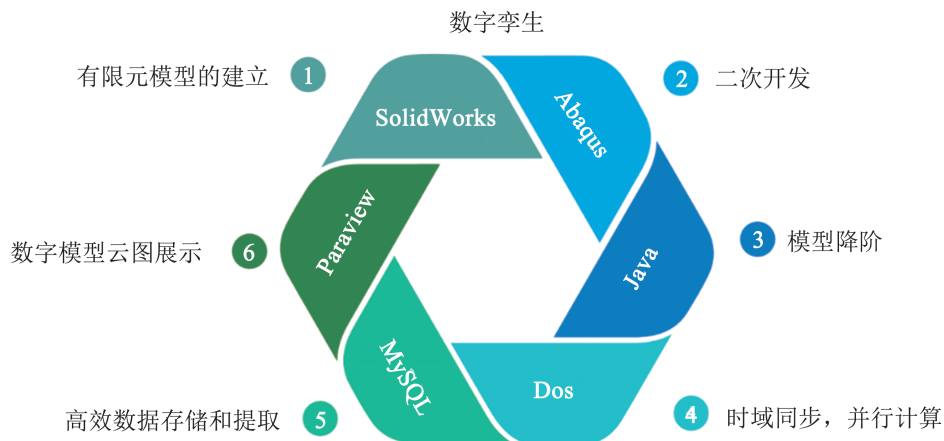


图 2 数字孪生技术流程图
Fig. 2 Digital twin technology flowchart

1.2 数据处理方法

数据库构建和结果推演技术是二级数字孪生的重要组成部分, 为数字模型提供了数据处理支持及系统性能优化。为了实现结果数字化快速调用, 采用数据库构建技术将预设样本数据进行存储、模式识别和推演处理。选择关系数据库存储数据, 常用的关系型数据库有MySQL、SQLServer、Oracle等。MySQL数据库具有体积小、速度快、成本低等优势, 支持多种操作系统和大型数据库^[10]。考虑到实用性和快速性, 本文选用MySQL数据库将结

果数据存储在三级数据层中。第一层结构分析层, 主要是利用批处理批量产生样本数据, 结合Dos环境下的时域同步计算得到结果应力数据阵列。第二层数据存储层, 将结果数据分为三个维度, 对应MySQL三级库表, 分别存储不同形式的数据。第三层模型重构层, 先利用Python的meshio模块将预处理文件进行格式转换, 然后解析数据并通过输入输出流技术将模型进行重构, 重构之后的VTK文件可以用于可视化软件Paraview中进行云图展示。数据库数据层设计如图3所示。

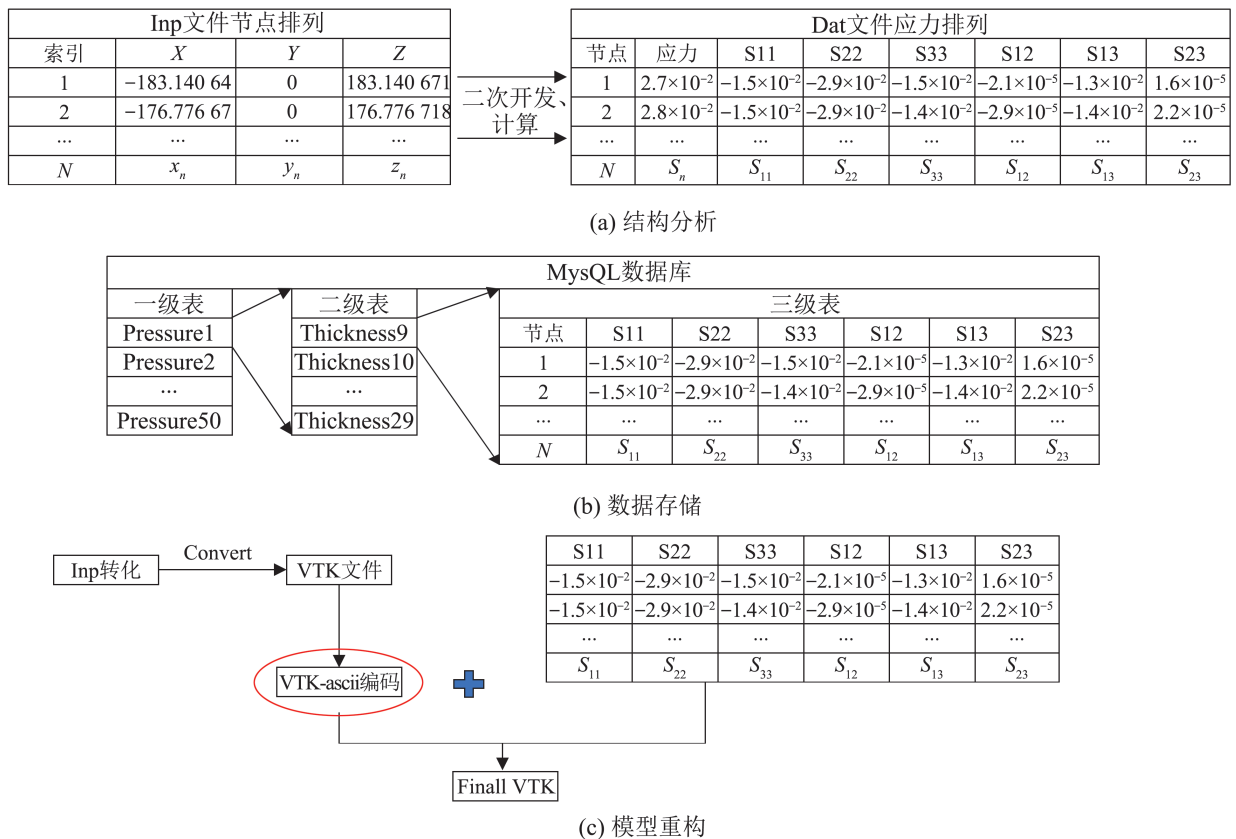


图3 数据库存储数据层
Fig. 3 Database storage data layer

1.3 推演插值理论

数字孪生数据库推演方法主要包括数据插值、数据学习、数据优化等。由于结构应力场分析结果节点数据量大、参数样本多、计算耗时, 为实现数据库快速推演及映射功能, 主要采用数据插

值方法开展应力场结果样本数字模型推演。拉格朗日插值是一种多项式插值方法, 使用多项式插值函数通过对 n 个点的曲线进行建模, 点的坐标分别为 $(x_0, y_0), (x_1, y_1), \dots, (x_{n-1}, y_{n-1})$, 通过基函数建立局部拉格朗日插值多项式, 当 x 坐标为 x_k 时,

只有一个基函数开关值为1，而其他 $n-1$ 个开关关闭^[11]。基函数表达式如下：

$$L_k(x) = \frac{(x-x_1)(x-x_2)\cdots(x-x_n)}{(x_k-x_1)(x_k-x_2)\cdots(x_k-x_n)} \quad (1)$$

当 $x \neq x_k$ 时，该开关的值为0，该开关构造的插值多项式为

$$P_{n-1}(x) = y_1 L_1(x) + y_2 L_2(x) + \cdots + y_n L_n(x) \quad (2)$$

式中：当 $x = x_k$ 时， $P_{n-1}(x) = y_k$ 。

1.4 机器学习算法

1.4.1 BP神经网络

采用BP神经网络和优化算法对三级数字孪生模型进行预测。BP神经网络可以很好地模拟数据之间的复杂非线性关系，主要由三部分组成：输入层、隐藏层和输出层，如图4所示。BP神经网络的核心是数字模型和纠错功能，整个神经网络涉及3个过程：前向传播、后向传播和权重更新^[12]，通过分析每次训练的实际结果和预期结果之间的误差，逐步优化学习结果。

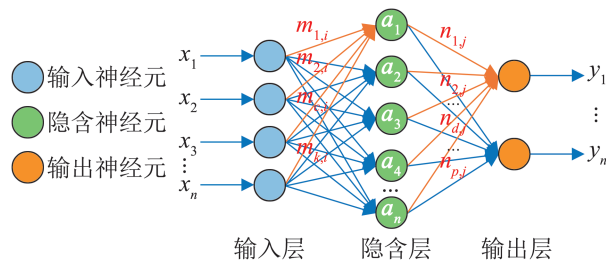


图4 BP神经网络结构

Fig. 4 BP neural network structure

(1) 前向传播过程

前向传播是数据从输入层输入，通过隐藏层的计算到达输出层的过程。在图4中， x_1, x_2, \dots, x_n 为输入值； y_1, \dots, y_n 为输出值； a_1, a_2, \dots, a_n 为中间值； $m_{1,i}, m_{2,i}, \dots, m_{c,i}, \dots, m_{k,i}$ 为输入层到隐含层的权值； $n_{1,j}, n_{2,j}, \dots, n_{d,j}, \dots, n_{p,j}$ 为隐含层到输出层的权值。 x 和 a 是每层的值， m 和 n 是相应的权重， y 计算为(每层的值 \times 权重)+偏差变量(即阈值)。偏差用 θ 表示。

输入层到隐式层：

$$a_n = \sum_{c=1}^k m_{c,i} x_n + \theta_1 \quad (3)$$

隐式层到输出层：

$$y_n = \sum_{d=1}^l n_{d,i} a_n + \theta_2 \quad (4)$$

(2) 后向传播过程

后向传播是通过分析输出值与真实值之间的误差来调整参数的过程，从而将误差降至最低。 L 是学习率，会影响收敛速度。适当的速率可以加速收敛。误差函数^[13]为

$$E = \frac{1}{2} \sum_{k=1}^n (y_k - T_k)^2 \quad (5)$$

式中： T_k 为预期值； y_k 为神经网络计算值。

(3) 权重反向更新

$$\Delta n_{i,j} = LE y_k \quad (6)$$

$$n_{i,j} = n_{i,j} + \Delta n_{i,j} \quad (7)$$

式中： Δn 为权重更新因子，由误差函数与学习率 L 的乘积而得。

1.4.2 PSO-BP算法

由于BP神经网络的初始权重和偏置函数是随机的，导致BP神经网络学习结果可能局部数据最优，但整体预测性能不佳。PSO可以利用个体的局部信息和群体的全局信息进行协同搜索，具有良好的全局搜索能力^[14]。因此，本文采用PSO和BP神经网络算法的PSO-BP混合优化算法，在初始化BP神经网络的权重和偏差的过程中，引入了粒子群概念，通过全局优化获得初始权重和偏差，以提高模型数据的整体预测性能。PSO-BP混合优化算法流程如图5所示。

2 案例分析

2.1 耐压球壳的参数设定

本文研究的深海耐压球壳模型有一个舱口盖开口，具体参数如表1所示。

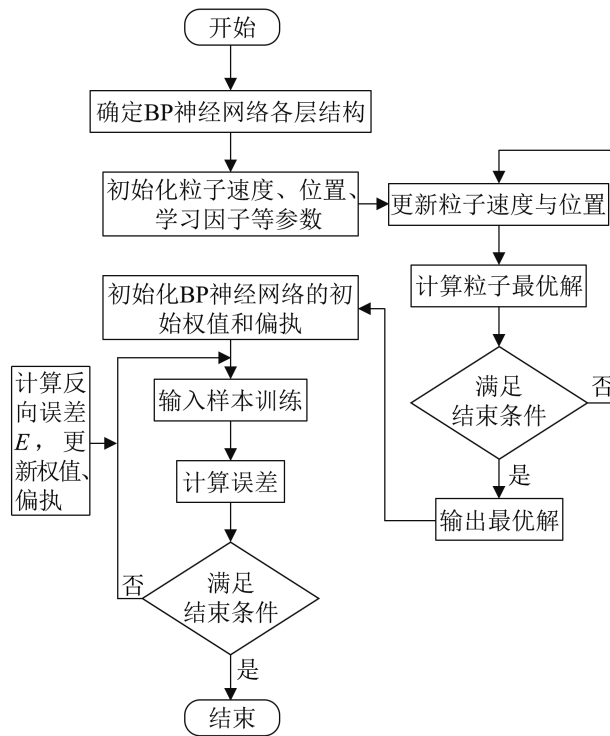


图5 PSO-BP混合优化算法流程图

Fig. 5 Flow chart of PSO-BP hybrid optimization algorithm

表1 深海耐压球壳参数

Table 1 Parameters of deep-sea pressure-resistant spherical shell

参数	值
耐压壳内径 r/mm	250
初始壁厚 w/mm	9
舱口盖外倾角 $s/(\text{°})$	45
弹性模量 $E/(\text{kg} \cdot \text{mm}^{-2})$	1.08×10^5
泊松比 ν	0.3
密度 $\rho/(\text{kg} \cdot \text{mm}^{-3})$	4.43×10^{-9}
材料	Ti-6Al-4V

2.2 有限元分析与实验验证

利用仿真软件 Abaqus 对深海耐压球壳进行外压载荷下应力场数值模拟。根据《潜水系统及潜水器分类规则》^[15], 对壳体施加三点约束, 对 x 、 y 、 z 三个方向的位移分量进行约束, 对称设置边界条件, 在不影响相对变形的情况下消除壳体刚体位移, 如图6所示。

有限元模型分为三部分: 舱口盖、上半球和下半球。选择六面体网格进行自由划分, 舱口盖的网格分布不规整, 通过网格划分算法从波前法切换到

中性轴算法后优化网格划分, 如图7所示。由于 Ti-6Al-4V 钛合金材料的极限强度为 890 MPa, 利用线性屈曲有限元计算得到球壳的临界载荷为 141 MPa; 将临界载荷作为输入进行非线性屈曲校核, 获得球壳极限承载力 LPF 曲线分布, 如图8所示, 临界点的极值为 0.396; 经过换算考虑非线性屈曲下球壳的极限承载力为 55.8 MPa, 图9为球壳非线性屈曲的应力分布结果。




图6 球壳上的三点约束

Fig. 6 Three-point constraint on spherical shell




图7 网格划分

Fig. 7 Grid division

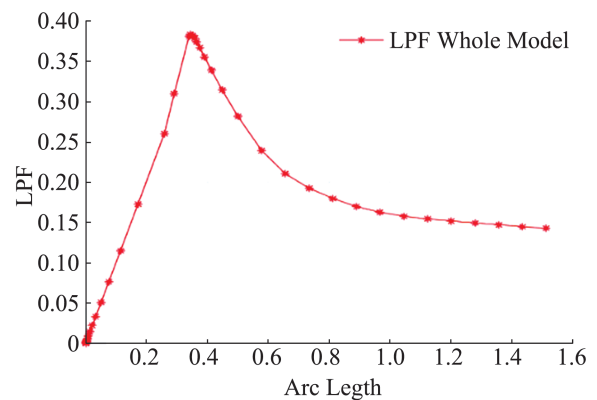


图8 LPF曲线

Fig. 8 LPF curve

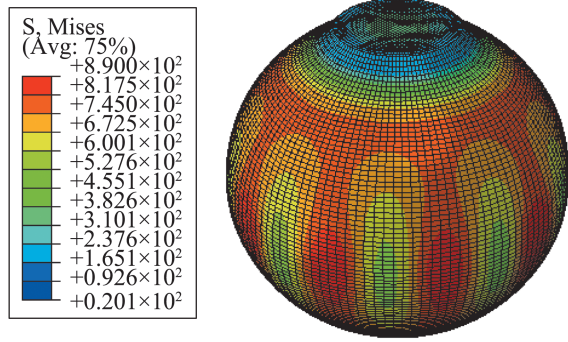


图9 非线性屈曲
Fig. 9 Nonlinear buckling

图10~11通过压力桶内爆实验研究了深海球壳的准静态坍塌和瞬时浸溃^[6]。实验中使用的压力桶内径为1 000 mm，不带支架的内径为814 mm，深度为3 300 mm。本实验以每3分钟5 MPa的加压速率对压力桶进行加压，测得耐压球体的最终坍塌压力为51 MPa。实验结果与有限元分析的误差为9.4%，由此可见，本文有限元模型可以用来开展耐压球壳体在外压作用下的应力场分析。




图10 耐压外壳
Fig. 10 Pressure-resistant shell



图11 耐压壳内爆
Fig. 11 Pressure hull implosion

2.3 Level-1 DT-映射模型

以深水外压载荷和耐压壳体厚度几何尺寸为主要分析参数。本文所建立的实体模型外部压力的载荷范围设置为1~50 MPa，步长为1 MPa，这是基于球壳的坍塌实验获得的实体球壳坍塌外压为51 MPa的数据。在确定壁厚参数时，考虑到了目前国内典型潜器的壁厚范围^[7]，在6 000 m的深海范围内，壁厚通常为内径的2.4%~3.6%。因此，本研究中球壳壁厚参数设置为9~29 mm，步长为1 mm，共1 050组初始样本建立仿真数据库。应力数据用三级表进行存储，一级表定义外压，二级表定义壁厚，三级表存储6个自由度的应力。用MySQL的存储过程批量建库建表，然后用I/O流对仿真结果文件进行特征批量提取，最后将特征数据导入MySQL数据库表中，以满足实际工作中的场景需求，确保模型的广泛性和代表性。仿真数据库中的样本计算结果转换为数字模型后，通过将数字模型导入ParaView软件可以将样本点结果快速映射为应力分布云图，具体流程如图12所示。图13~16为有限元模型和数字模型的应力场分布云图显示结果。

2.4 Level-2 DT-推演模型

深海耐压球壳在作业过程中，由于外压影响及水密性要求，传感器通常布置在球壳内部。本文在舱口盖的内圈区域选取8个虚拟监测点进行分析，如图17所示。

通过仿真计算得到的样本数量有限，为了获得全生命周期参数下的应力场分布结果，必须进一步扩大样本。考虑结构尺寸以及外压变化，利用拉格朗日插值法并在添加新的插值点时重构整个基函数，使插值多项式更符合整体数据分布。确认厚度范围为9~29 mm，步长从1 mm减少到0.1 mm，数据库中共有9 150个样本。

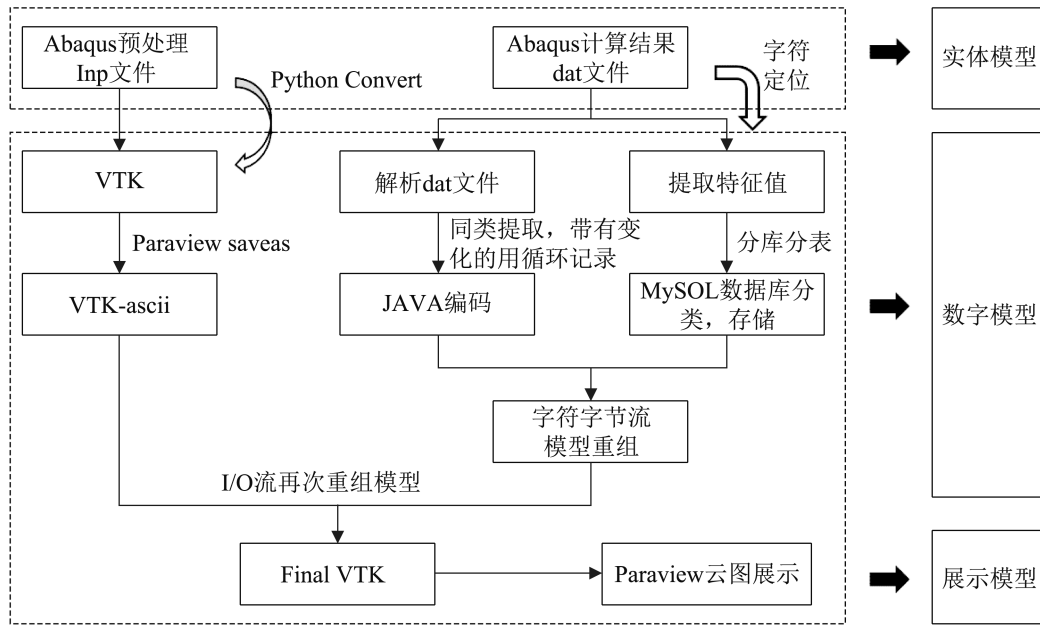


图 12 模型映射流程
Fig. 12 Model mapping process





图 13 有限元云图
Fig. 13 Cloud view of FEM

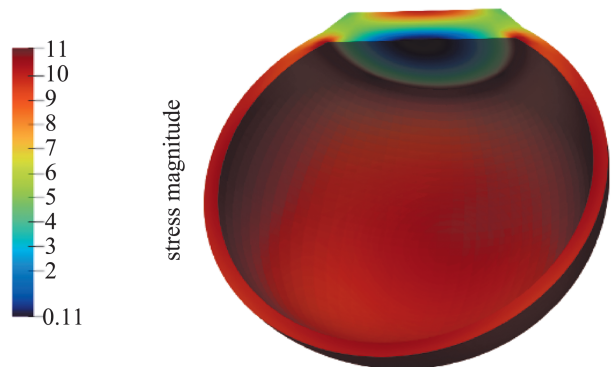


图 15 数字模型云图
Fig. 15 Cloud view of digital model




图 14 有限元局部云图
Fig. 14 Local cloud of FEM




图 16 数字模型局部云图
Fig. 16 Local cloud of digital model




图17 虚拟监测点布置

Fig. 17 Layout of virtual monitoring points

由于拉格朗日插值法在高阶插值的时候会产生龙格现象，即在边缘部分图像产生大幅度的震荡，影响全局的精度，所以本文采用局部拉格朗日插值法，即在插值点的左右各取若干个点进行插值。在距离较近的情况下，可以避免龙格现象也可以提高精度。由于舱口盖附近为结构突变位置，故在此处设置8个测点验证方法的有效性，8个点中选取点1和点5作为方法对比。点1所处环境为外压10 Mpa，球壳壁厚19 mm，点5所处环境为外压19 Mpa，壁厚20 mm，如表2~3，经计算，在插值点左右各取两个点误差最小。

表2 插值点数量的选择(测点1)
Table 2 Selection of interpolation points(point 1)

插值点数量	应力/MPa	误差/%
	87.63 (真实值)	
3	87.877 (左二右一) 87.170 (左一右二)	0.282 0.523
4	87.523 (左二右二)	0.122
5	87.644 (左三右二) 86.786 (左二右三)	0.316 0.963
6	87.215 (左三右三)	0.474
7	88.016 (左四右三) 86.600 (左三右四)	0.440 1.175
8	87.308 (左四右四)	0.367

表3 插值点数量的选择(测点5)

Table 3 Selection of interpolation points(point 5)

插值点数量	应力/MPa	误差/%
	132.800 (真实值)	
3	132.767 (左二右一) 132.867 (左一右二)	0.248 0.504
4	132.817 (左二右二)	0.128
5	132.820 (左三右二) 132.840 (左二右三)	0.151 0.301
6	132.830 (左三右三)	0.226
7	132.831 (左四右三) 132.782 (左三右四)	0.233 0.136
8	132.837 (左四右四)	0.279

表4显示了所选部分样本的应力结果数据。BP神经网络的训练集和测试集的划分采用60%训练集，40%测试集，并在训练前对训练集的数据用randperm函数进行打乱，以保证数据特征的普适性，进一步提高训练的效果。训练集样本编号为1~5 490共计5 490组(外部压力1~30 MPa)。测试集样本编号为5 491~9 150共3 660组(外部压力31~50 MPa)，表4为部分样本的应力结果。

在总计9 150组样本中，进行一组随机抽取20个样本点的误差分析，共进行6次实验，结果如图18所示。在这些实验中，采用局部拉格朗日插值法对数据进行插值，并将插值结果与有限元仿真结果进行对比。研究表明，在所有实验中，局部拉格朗日插值法的插值结果与有限元仿真结果的误差均保持在10%以内，相对误差为4.8%。这表明插值结果的误差在合理范围内，满足研究要求。本文提出的基于仿真数据库及数字孪生技术的深潜球壳应力场预报方法，主要着重于对结构安全的早期预测及异常防范。通过构建仿真数据库，获得正常工作状态下的应力场预测数据，通过与传感器获取的实际数值进行对比，一旦检测到实际应力值与数据库中的数据存在异常情况，系统将触发预警机制，以便及时发现并处理潜在问题，从而实现提前预警的目的。

表4 部分样本的应力结果
Tab.4 Stress results of the selected partial samples

节点	外压/Mpa	壁厚/mm	节点1	节点2	节点3	节点4	节点5	节点6	节点7	节点8
1	1	9	14.5	14.4	14.4	13.5	14.4	10.9	14.5	13.7
2	1	10	9.8	13.1	9.8	12.4	12.4	13.1	12.4	13.1
...
5 480	30	27.1	231.5	129.2	162.6	129.2	162.6	219.5	219.5	129.2
5 481	30	27.2	231.6	128.7	162.1	128.7	162.1	219.5	219.5	128.7
5 482	30	27.3	231.8	128.2	161.6	128.2	161.6	219.5	219.5	128.2
5 483	30	27.4	231.9	127.7	161.1	127.7	161.1	219.5	219.5	127.7
5 484	30	27.5	232.1	127.3	160.6	127.2	160.5	219.6	219.6	127.2
5 485	30	27.6	232.3	126.8	160.1	126.7	160.1	219.6	219.6	126.7
5 486	30	27.7	232.5	126.3	159.6	126.2	159.6	219.7	219.7	126.2
5 487	30	27.8	232.7	125.8	159.1	125.7	159.1	219.7	219.7	125.8
5 488	30	27.9	232.8	125.4	158.6	125.3	158.6	219.7	219.7	125.3
5 489	30	28.0	232.9	124.9	158.1	124.8	158.1	219.7	219.7	124.8
5 490	30	29.0	229.2	120.3	153.4	120.3	153.5	216.3	216.3	120.3
...
9 140	50	27.1	385.7	215.4	271.0	215.4	271.0	365.8	365.8	215.3
9 141	50	27.2	385.9	214.5	270.2	214.5	270.2	365.8	365.8	214.4
9 142	50	27.3	386.2	213.7	269.4	213.7	269.3	365.8	365.8	213.6
9 143	50	27.4	386.5	212.9	268.5	212.9	268.5	365.9	365.9	212.8
9 144	50	27.5	386.9	212.1	267.7	212.1	267.7	366.0	366.0	211.9
9 145	50	27.6	387.2	211.3	266.9	211.3	266.8	366.1	366.1	211.2
9 146	50	27.7	387.5	210.5	266.0	210.5	266.0	366.2	366.1	210.4
9 147	50	27.8	387.8	209.7	265.2	209.7	265.2	366.2	366.2	209.6
9 148	50	27.9	388.0	208.9	264.4	208.9	264.4	366.2	366.2	208.8
9 149	50	28.0	388.2	208.1	263.6	208.1	263.6	366.2	366.2	208.0
9 150	50	29.0	382.0	200.5	255.7	200.5	255.8	360.4	360.4	200.4

2.5 Level-3 DT-数字孪生预测模型

通过将数值推演模型在仿真数据库中扩展的数据用于BP神经网络训练,最终形成的模型能够快速映射目标工况下的应力场分布状态。具体而言,MySQL数据库中包含了球壳的尺寸数据,其中,内径为250 mm,壁厚范围为9~29 mm,间距步长为0.1 mm(即9,9.1,⋯,29 mm)。在此数据库中,初始耐压壳(内径250 mm,壁厚9 mm)的应力数据是通过批量有限元计算所得,而其他不同壁厚的耐压壳应力则通过插值获得。

通过BP神经网络的训练,能够仅依靠单个耐压球壳的监测数据来预测其他不同尺寸耐压球壳的应力状态。具体而言,如果目标尺寸在数据库

中已存在,则可以直接进行映射;反之,若数据库中不存在相应尺寸的数据,则可以通过数字孪生模型进行预测,并进一步进行展示。

BP神经网络的输入层由外部压力载荷和球壳壁厚参数组成,输出层为监测点处的应力响应。因此,输出层设置一个神经元,输入层设置两个神经元,隐藏层设置一层。隐藏层中的神经元数量通过经验公式^[18]评估:

$$m = \sqrt{n+l} + \alpha \quad (8)$$

式中: n 为输入层中的神经元数2; l 为输出层中的神经元数1; α 为1~10的常数,隐藏层神经元的数量 $m \in 3 \sim 12$ 。

表5给出了隐藏层中不同神经元数量的均方根误差(RMSE)。




图 18 局部拉格朗日插值法误差分析

Fig. 18 Error analysis of local Lagrange interpolation method

表 5 隐藏层中不同神经元数量的 RMSE
Table 5 RMSE of number of different neurons in hidden layer

参数神经元数量	均方根误差	参数神经元数量	均方根误差
3	0.000 618 78	8	0.000 603 58
4	0.000 264 22	9	0.000 152 86
5	0.000 195 16	10	0.000 203 48
6	0.000 177 27	11	0.000 085 343
7	0.000 615 34	12	0.000 013 195

可以看出，当隐藏层设置为 12 个神经元时，RMSE 是最小的。隐藏层需要非线性激活函数，由于线性函数的叠加误差较大，本文将隐藏层的神经元激活函数设置为切线 S 型激活函数 tansig。采用 BP 神经网络进行回归预测，将输出层的神经元激活函数设置为线性激活函数 purelin。将反向传播的训练函数设置为 trainlm 函数，该函数采用 Levenberg-Marquardt 算法，收敛速度较好。

$$\text{tansig}(x) = 2 / (1 + e^{-2x}) - 1 \quad (9)$$

$$\text{purelin}(x) = x \quad (10)$$

将外压 13 MPa 工况的结果数据作为训练集和外压 50 MPa 工况的结果数据作为测试集，BP 神经网络训练集和测试集的应力预测结果如图 19~20 所示。




图 19 BP 神经网络训练集效果

Fig. 19 BP neural network training set effect

在 60% 样本作为训练集的条件下，训练集能够准确预测应力趋势，均方根误差为 2.47，平均绝对误差为 2.65%。然而，测试集总体偏离较大，

均方根误差为19.69, 平均绝对误差为3.07%, 需要从学习算法上对BP神经网络进行优化, 以提高预测精度。




图20 BP神经网络测试集效果
Fig. 20 BP neural network test set effect

3 算法优化

3.1 PSO-BP算法

BP神经网络的初始权重和偏执是随机的, 存在不稳定性, 而PSO可以在全局范围内对位置和速度两个变量进行寻优, 本文将初始权重和偏执等效为粒子群算法里的位置和偏执, 在BP神经网络进行训练的前期先获取最优的权重和偏执, 进一步提高算法的求解精度^[19], 结果如图21~22所示, 经

过PSO优化后的BP神经网络测试集平均绝对误差为0.514%, 小于1%, 满足精度要求。




图21 PSO-BP训练集
Fig. 21 PSO-BP training set

3.2 PSO-BP样本点数据集大小的影响

通过测试两个不同大小的数据集, 量化数据集大小对模型预测精度的影响。分别使用5490个和9150个随机样本点进行测试。样本中70%作为训练集, 30%作为测试集, 与前文一样进行切分(记作7-3划分, 后文同样)。图23分别给出了这两种不同数量的样本点的训练集和测试集的回归线。




图22 PSO-BP测试集预测效果
Fig. 22 Prediction performance of PSO-BP test set

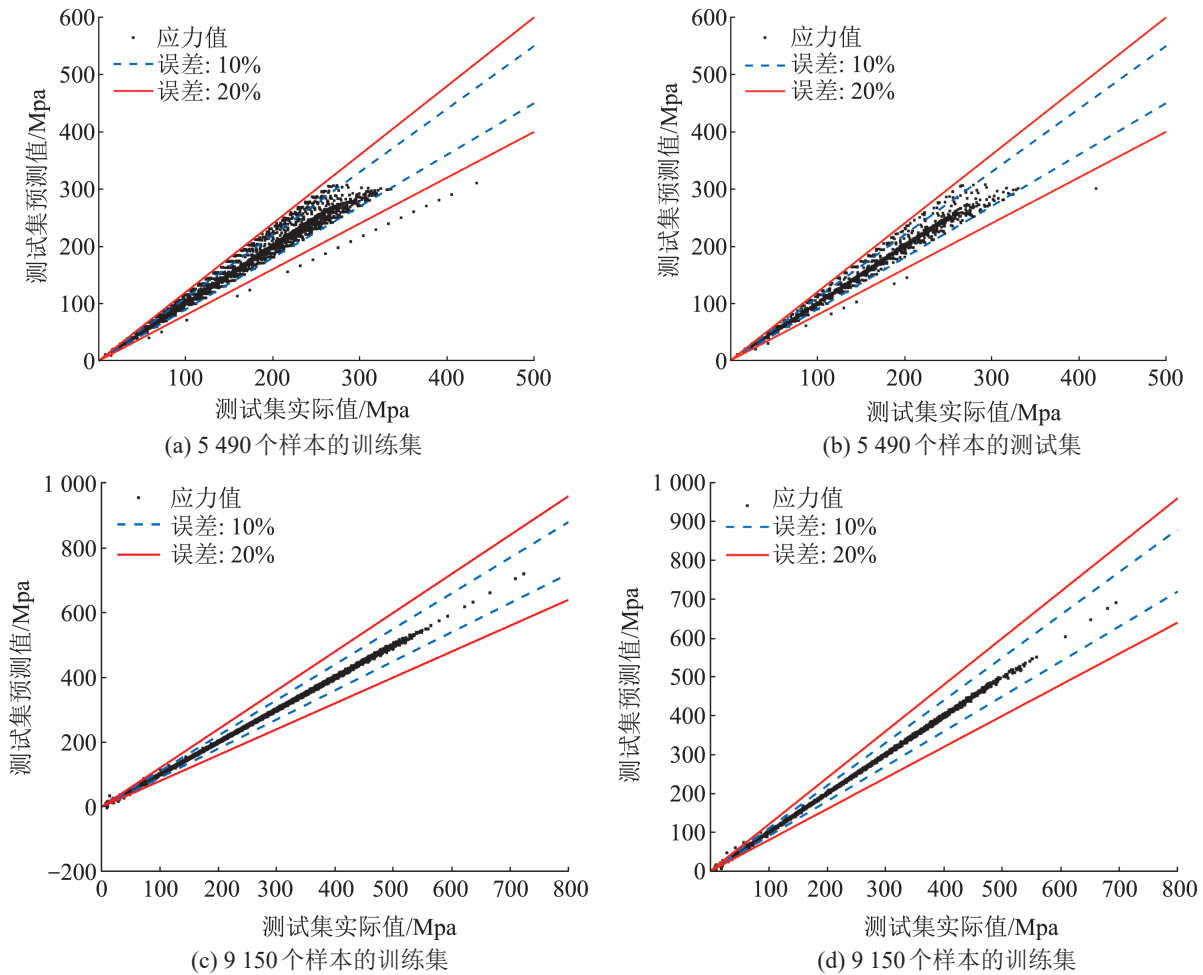


图23 不同样本回归结果

Fig. 23 Regression results of different samples

如图23(a)所示, 5 490个样本点训练集中的大多数误差在10%以内, 且在10%~20%之间也存在样本点, 有些甚至超过20%。将模型应用于测试集时, 误差较大, 如图23(b)所示。然而, 当样本量增加到9 150时, 模型学习的效果会发生显著的提升。图23(c)中训练集及图23(d)中的测试集回归线接近直线分布, 绝对误差小于1%, 表明该算法在样本量较大时可以有效地提升预测精度。

3.3 BP神经网络结构优化

BP神经网络训练集和测试集的比例设置为60%~40%, 70%~30%, 80%~20%, 记作6-4划分, 7-3划分, 8-2划分。隐含层神经元个数都设为12, 通过对比实测值与预测值的误差, 不同比

例数据集预测效果如图24所示。

根据表6所示, 训练集占总体样本数的比例对于训练效果有着显著影响。结果表明, 在不同的训练集占比下, 训练集误差有所降低, 但下降幅度并不显著, 同时测试集的预测范围也减小。在7-3的样本划分中, 样本与真实数据之间的平均绝对误差为2.25%, 相较于6-4样本划分, 误差降低了0.82%; 在8-2的样本划分下, 相较于7-3样本划分, 预报精度提高了1.18%。随着训练集占比的增加, 训练的网络模型会更接近整个样本的数据分布, 因此测试集的效果会更好。然而, 这也会导致对未知工况的预测范围减小, 从而浪费了一部分学习资源。

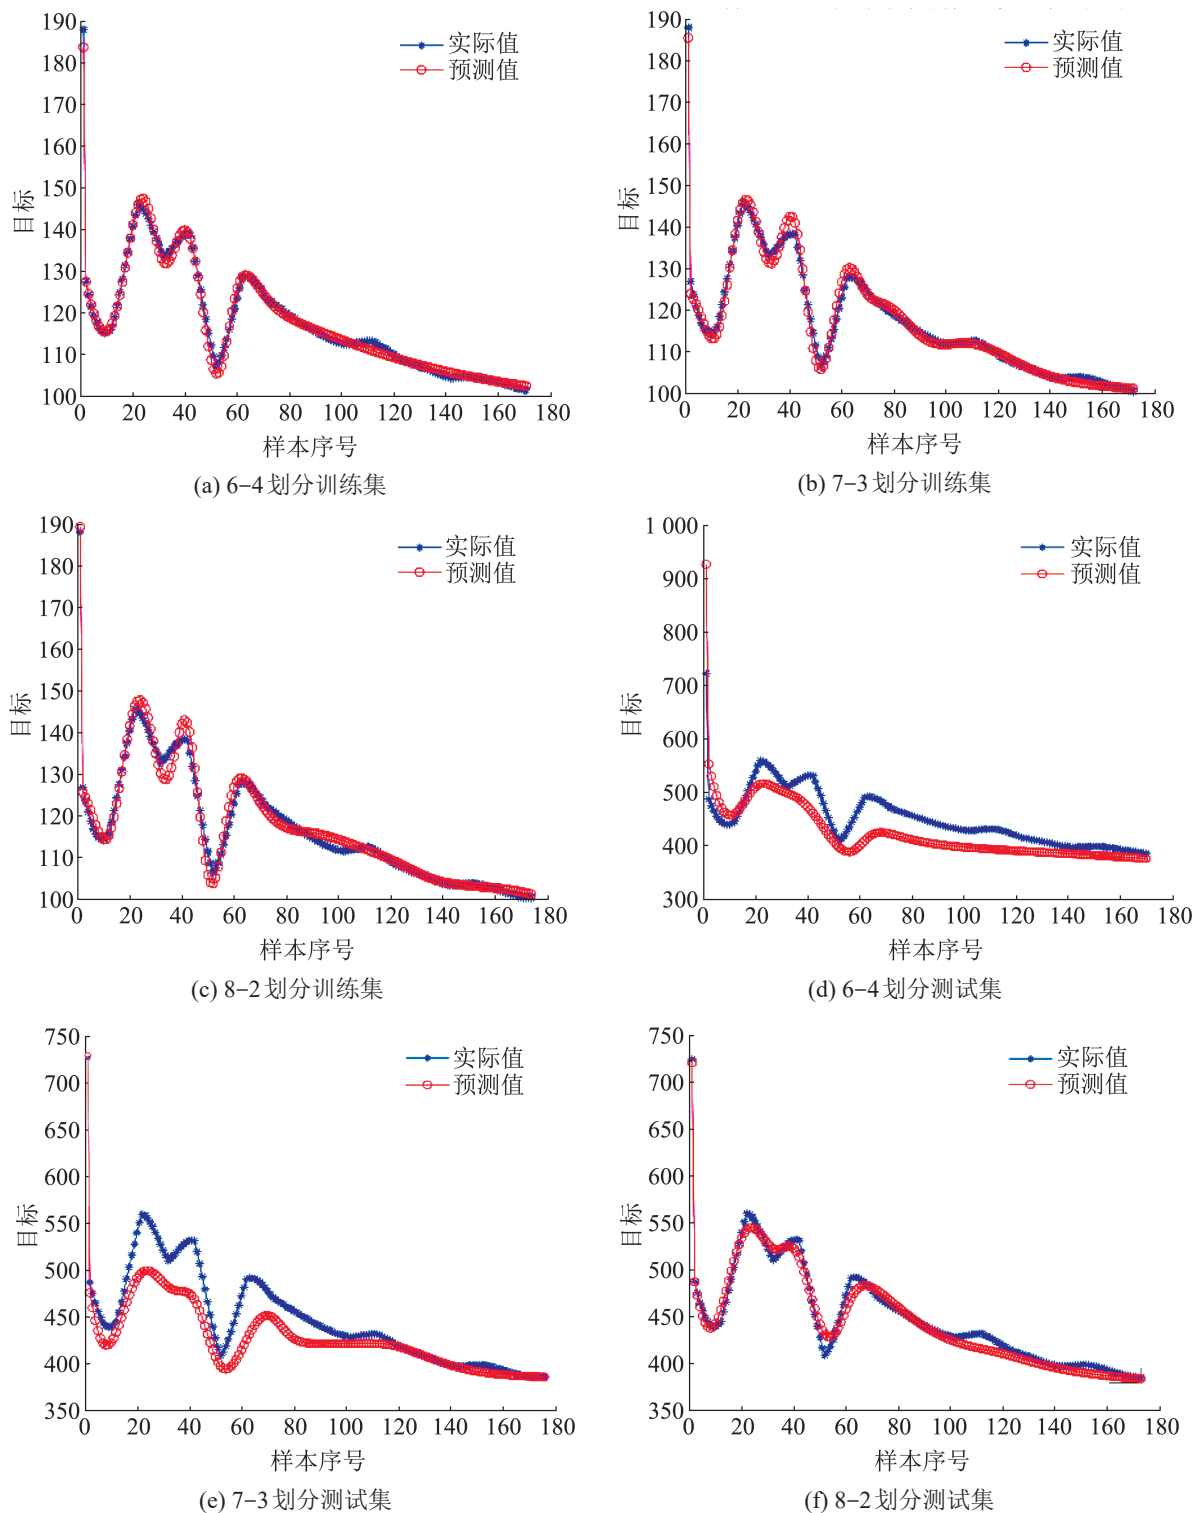


图24 数据集不同划分比例预测效果

Fig. 24 Data set prediction effect of different division ratio

在隐含层神经元个数为12时, 经过对BP神经网络在不同训练集和测试集比例(6-4、7-3、8-2)下的拟合度(R^2)进行比较, 如表7所示, 可以得

出以下结论: 首先, 在6-4的比例下, 神经网络表现出了较高的拟合度, 说明其能够较好地拟合训练数据, 并在一定程度上泛化到测试数据上。

其次，在7-3和8-2的比例下，训练集的拟合优度一直上升，测试集虽然拟合优度略有下降，但依然保持在可接受的范围内，显示出神经网络对不同数据集划分的稳健性。综合考虑，随着训练集比例的增加，模型在训练集上的性能有所提升，但在测试集上的性能会略有下降，主要是由于过多的数据用于训练导致了模型对训练集的过度拟合。因此，在选择训练集和测试集比例时，需要权衡模型的泛化能力和对训练数据的拟合程度，以获得更好的模型性能，本文建议选择7-3划分。

表6 样本不同划分比例的均方根误差
Table 6 RMSE of the test set and training set of the sample with different partition ratios

参数	6-4划分	7-3划分	8-2划分
训练集RMSE	2.47	2.38	2.35
训练集MAPE/%	2.65	2.49	1.99
测试集RMSE	19.69	15.42	5.96
测试集MAPE/%	3.07	2.25	1.07

表7 样本不同划分比例的R²
Table 7 R² of test set and training set of sample with different partition ratios

数据集	6-4划分	7-3划分	8-2划分
训练集	0.999 02	0.999 49	0.999 51
测试集	0.932 33	0.989 30	0.988 36

4 结论

本文提出了一种基于仿真数据库的深潜球壳应力场快速预测的三级架构DT方法。DT方法可以将虚拟传感器完全覆盖整个耐压壳，利用有限的球壳监测数据为提供潜水器整体应力场状态预测，并且DT模型指令可以传递到物理空间，物理空间中监测到的变化也可以通过数字模型数据反馈，达到自学习的目的。主要结论如下：

(1) Level-1 DT实现了有限元模型到数字模型的映射，经实验验证，实验结果与数值结果相差小于9.4%。同时，本文提出的深潜球壳DT方法与仿真具有较好的性能匹配性，整个DT框架可应用于大多数类型的深潜球壳装备。

(2) Level-2 DT实现数字模型的推演，扩展仿真数据库样本。利用局部拉格朗日插值法，将仿真数据库中未计算的应力场样本结果数据推演获取，局部拉格朗日插值法的插值结果与有限元仿真结果的误差均保持在10%以内，平均绝对误差为4.8%。

(3) Level-3 DT开发了深潜球壳数字模型应力场分布的快速预测功能。采用PSO对BP神经网络学习结果进行优化，PSO-BP混合算法表现出较强的寻优能力和快速收敛性。单独使用BP神经网络的预测值与真实值误差为3.07%，而使用PSO-BP混合算法的预测值和真实值误差仅为0.514%。

(4) 通过对机器学习算法结构优化，能有效预测不同壁厚和外压作用下球壳的应力场分布结果，用于学习的样本数据量比例越大，模型模拟数据规律越精准，但对未知工况的预测范围减小、浪费学习资源，需合理设置测试集与训练集的样本划分比例。

该方法可以结合实际传感器实测数据和历史经验数据，对动态应力数字孪生的健康状态进行实时映射和同步推演，可以实现整个船体所有深潜球壳应力场分布的虚拟监测、动态感知和智能诊断。

参考文献：

- [1] Wang Fang, Zhang Xuezhong, Kong Pinin, et al. An Improved Small-time-scale Crack Growth Rate Model Considering Overloading and Load-sustaining Effects for Deep-sea Pressure Hulls[J]. Ocean Engineering, 2022, 247: 110361.
- [2] Huang Xing, Wang Shaohua, Liu Quansheng, et al. Development of a Real-time Monitoring and Calculation Method for TBM Disc-cutter's Cutting Force in Complex Ground[J]. Geotechnical Testing Journal, 2022, 45(5): 961-984.
- [3] Chen Mingsheng, Li Chunbao, Han Zhaolong, et al. A Simulation Technique for Monitoring the Real-time Stress Responses of Various Mooring Configurations for Offshore Floating Wind Turbines[J]. Ocean Engineering, 2023, 278: 114366.
- [4] 张涛, 胡嘉骏, 汪雪良, 等. 基于人工智能的三维结构全

- 局应力求解方法研究[J]. 船舶力学, 2023, 27(2): 238-249.
- Zhang Tao, Hu Jiajun, Wang Xueliang, et al. Solving Approach for Global Stress Field of the 3D Structures Based on Artificial Intelligence[J]. Journal of Ship Mechanics, 2023, 27(2): 238-249.
- [5] Yao Ji, Wang Xueliang, Ye Cong, et al. Long-term Life Stress Mapping Algorithm of the Deep-sea Pressurized Spherical Shell Based on Digital-twin Technology[J]. Ocean Engineering, 2023, 286, Part 2: 115667.
- [6] Liu Xiaoben, Zheng Qian, Wu Kai, et al. Development of a Novel Approach for Strain Demand Prediction of Pipes at Fault Crossings on the Basis of Multi-layer Neural Network Driven by Strain Data[J]. Engineering Structures, 2020, 214: 110685.
- [7] Chen Jie, Liu Zhixin, Yin Zhengtong, et al. Predict the Effect of Meteorological Factors on Haze Using BP Neural Network[J]. Urban Climate, 2023, 51: 101630.
- [8] Huang Minjie, Jiang Jufu, Wang Ying, et al. Comparison and Error Evaluation of Arrhenius Model and Typical Machine Learning Algorithms for High-temperature Flow Stress Prediction of GH3536 Superalloy[J]. Materials Letters, 2023, 349: 134754.
- [9] 毛子泉, 高家隆, 龚建兴, 等. 虚实结合仿真在军事领域的应用综述[J]. 系统仿真学报, 2023, 35(11): 2289-2311.
- Mao Ziquan, Gao Jialong, Gong Jianxing, et al. Application of Virtual-real Simulation in Military Field[J]. Journal of System Simulation, 2023, 35(11): 2289-2311.
- [10] 熊群毓. 大数据时代MySQL数据库的应用分析[J]. 信息与电脑, 2023, 35(14): 209-212.
- Xiong Qunyu. Application Analysis of MySQL Database in the Era of Big Data[J]. Information & Computer, 2023, 35(14): 209-212.
- [11] 胡沛然, 陈少辉. 权重归一化拉格朗日插值及其空间降尺度应用[J]. 遥感信息, 2019, 34(6): 63-71.
- Hu Peiran, Chen Shaohui. Weight Normalization Based Lagrange Interpolation and Its Application in Downscaling[J]. Remote Sensing Information, 2019, 34(6): 63-71.
- [12] Wu Yangwei, Li Aijun, Lei Su, et al. Prediction of Pyrolysis Product Yield of Medical Waste Based on BP Neural Network[J]. Process Safety and Environmental Protection, 2023, 176: 653-661.
- [13] 米春, 李思颖, 牟佳祎, 等. 基于多传感器的城市隧道环境监测数据协同融合方法研究[J]. 现代隧道技术, 2023, 60(5): 177-185.
- Mi Chun, Li Siying, Mou Jiayi, et al. Study on Collaborative Fusion Method for Urban Tunnel Environmental Monitoring Data Based on Multi-sensor[J]. Modern Tunnelling Technology, 2023, 60(5): 177-185.
- [14] 中国船级社. 潜水系统与潜水器入级规范: 标准编号缺失[EB/OL]. (2018-12-01) [2023-12-19]. <https://www.ccs.org.cn/ccswz/file/download?fileid=202206270495335944>.
- China Classification Society. Rules for Classification of Diving Systems and Submersibles[EB/OL]. (2018-12-01) [2023-12-19]. <https://www.ccs.org.cn/ccswz/file/download?fileid=202206270495335944>.
- [15] 刘丹, 杜青海, 刘峰西, 等. 基于神经网络的深海球形结构机器学习设计与优化[J]. 中国造船, 2022, 63(6): 161-173.
- Liu Dan, Du Qinghai, Liu Fengyou, et al. Machine Learning Design and Optimization of Deep-sea Spherical Shell Based on Artificial Neural Network[J]. Shipbuilding of China, 2022, 63(6): 161-173.
- [16] Wu Yu, Ding Jian, Wang Fang, et al. Research on the Quasi-static Collapse and Instantaneous Implosion of the Deep-sea Spherical Pressure Hull[J]. Marine Structures, 2022, 83: 103191.
- [17] 张颖, 赖长亮, 和卫平, 等. 潜水器耐压壳结构选材应用综述[J]. 舰船科学技术, 2022, 44(5): 1-6.
- Zhang Ying, Lai Changliang, He Weiping, et al. Review of Materials Selection and Application of Submersible Pressure Hull Structure[J]. Ship Science and Technology, 2022, 44(5): 1-6.
- [18] 刘纳琳, 满轲, 刘晓丽, 等. 基于GA-BP神经网络的富水砂层渣土改良效果预测[J]. 隧道建设(中英文), 2023, 43(增1): 222-232.
- [19] 王娟, 杨小渝, 王宗国, 等. 基于混合学习算法的材料计算数据误差估计[J]. 系统仿真学报, 2018, 30(10): 3843-3852, 3860.
- Wang Juan, Yang Xiaoyu, Wang Zongguo, et al. Error Estimation for Material Simulation Data Based on Hybrid Learning Algorithm[J]. Journal of System Simulation, 2018, 30(10): 3843-3852, 3860.