

基于半监督深度神经网络管路抓举车伸缩臂的可靠性分析

袁国秩¹ 刘伟¹ 闫子龙² 张睿琳¹ 赵明轩¹ 桑建兵¹

(1. 河北工业大学机械工程学院, 天津 300400)

(2. 廊坊景隆重工机械有限公司, 廊坊 065300)

摘要: 伸缩臂作为管路抓举车的关键部件,连接着升降台和机械爪并承担着大部分载荷,对其进行可靠性分析十分必要。由于传统的可靠性方法对于多维度不确定性问题存在计算成本高且精度不高等问题,为了解决这些问题,基于Adams动力学仿真、半监督学习、神经网络并结合蒙特卡洛(Monte Carlo, MC)方法提出了一种应用于工程机械可靠性分析的方法。建立了管路抓举车的虚拟样机模型,确定了其危险工况,并结合伸缩臂模型的几何参数和其总体结构确定了影响最大的 von Mises 应力的不确定因素,并对其进行敏感性分析;使用最优拉丁超立方采样(Optimal Latin Hypercube Sampling, OLHS),依据不确定参数的分布情况进行采样,利用有限元分析软件Ansys WorkBench建立有限元模型,得到样本量对应的输出结果,并引入半监督学习对有限元模拟数据进行处理,提高神经网络训练的准确度;最后根据第四强度理论确定了伸缩臂部件的破坏准则,并结合神经网络和MC方法预测了伸缩臂部件的可靠度和失效概率。研究表明,此方法远高于实际工程要求精度,具有一定的工程指导意义。

关键词: 伸缩臂; 可靠性分析; 半监督学习; 神经网络; 最优拉丁超立方采样

中图分类号: TH213 **DOI:** 10.16579/j.issn.1001.9669.2025.08.019

0 引言

在煤矿行业中,许多工程机械都属于大功率设备,这些设备的内部结构复杂,在长时间、高负荷的运转过程中,某些关键零部件在其载荷施加的过程中会出现磨损、腐蚀甚至裂纹等失效现象,因此对这些工程机械进行可靠性分析十分必要。在传统的可靠性分析中,常当成概率问题,后来发展的理论可对此加以补充,如证据理论^[1]、模糊理论^[2]、凸集理论^[3]等。在一些实际工程问题中,限制可靠性分析方法的最大阻碍就是某些不确定变量样本量的不足,致使其概率分布情况不确定或未知。近年来,国内外专家学者对此提出了诸多方法。ALISHAYANFAR等^[4]提出了一种将蒙特卡洛模拟(Monte Carlo Simulation, MCS)法和一阶可靠度方法相结合的方法,在一定程度上减少了样本量,提高了效率。ROY等^[5]提出了一种基于人工神经网络的可靠性模型,利用粒子群优化(Particle Swarm Optimization, PSO)算法提高可靠性预测的准确度。张宏斌等^[6]提出了一种基于反向传播(Back Propagation, BP)神经网络应用于小样本量可靠性数据的预测方法。

对于工程机械的可靠性问题,不能简单等同于显

式计算问题,其中包括各种不确定变量。为解决这些问题,赵丽娟等^[7]以采煤机截割部分输出轴为对象,以应力-强度可靠性理论为基础,建立了动态可靠性模型,利用Adams进行动力学仿真,得到不同工况下的模型数据,并结合神经网络对其余工况进行预测。LI等^[8]针对振动压路机的可修理特性,利用Matlab和可靠性工程理论,提出了一种可靠性模型识别方法。YAN等^[9]针对传统可靠性方法误差较大,提出了一种基于Adams算法的前馈神经网络预测方法。林景亮等^[10]提出了一种主动闭环蒙特卡洛(Monte Carlo, MC)试验方法,利用多层感知器建立了某伸缩臂叉车臂架的深度代理模型,结合最小预测方法设计并优化了其液压系统。王璟等^[11]采用Abaqus建立了船舶撞击群桩的有限元模型,通过模拟得到不同参数下的数据,并基于人工神经网络(Artificial Neural Network, ANN)方法进行了评估。

对此,本文以管路抓举车伸缩臂部分为对象进行研究,管路抓举车上装部分结构如图1所示,由于伸缩臂连接着大臂和小臂,作为主要受力和传力部分,它的可靠性问题关系到整个工程作业的安全。

本文首先建立管路抓举车整车的虚拟样机,模拟

收稿日期: 2023-10-13 修回日期: 2024-03-08

基金项目: 河北省自然科学基金项目(A2020202015); 国防科技重点实验室基金项目

作者简介: 袁国秩,男,1999年生,河北泊头人,硕士研究生; 主要研究方向为动力学仿真与可靠性分析; E-mail: 1448436848@qq.com。

桑建兵(通信作者),男,1974年生,河北邢台人,博士研究生,教授; 主要研究方向为可靠性分析与优化; E-mail: sangjianbing@hebut.edu.cn。

引用格式: 袁国秩,刘伟,闫子龙,等. 基于半监督深度神经网络管路抓举车伸缩臂的可靠性分析[J]. 机械强度, 2025, 47(8): 159-167.

YUAN Guozhi, LIU Wei, YAN Zilong, et al. Reliability analysis of telescopic arm of pipeline-catching vehicle based on semi-supervised deep neural network[J]. Journal of Mechanical Strength, 2025, 47(8): 159-167.




图1 管路抓举车上装部分结构

Fig. 1 Structure of the superstructure of the pipeline-catching vehicle

不同工况和不同载荷下的运动情况,随后对伸缩臂部分进行分析,结合虚拟样机得出的数据结果,进行数值仿真并结合数值模拟结果与深度神经网络建立了伸缩臂的代理模型,最后结合MC方法对管路抓举车伸缩臂进行可靠性分析。

1 管路抓举车的动力学仿真

1.1 管路抓举车作业过程的动力学仿真

利用虚拟样机模拟管路抓举车的抓举过程^[12-13],首先将整体模型保存为“*.x_t”格式文件,然后导入到动力学仿真软件Adams中,导入的模型如图2所示。设置虚拟样机模型的工作环境,其中包括坐标系设定,重力加速度、长度、重量单位的统一。




图2 虚拟样机模型

Fig. 2 Virtual prototype model

1) 参数设定。根据管路抓举车的工作特性,整车模型的材料选取为Q345钢,其弹性模量为210 GPa,材料密度为7 850 kg/m³。

2) 约束条件。根据实际模型的运动情况,为虚拟样机模型零部件之间创建连接副。例如:液压缸伸缩运动设置移动副;两部件间的旋转设置为旋转副;底座部分设置为固定约束等。

3) 添加step5驱动函数。则函数为

$$F = \text{step5}(x, x_0, y_0, x_1, y_1) \quad (1)$$

式中, x 为自变量; x_0, x_1 分别为自变量 x 的初始值和终止值; y_0, y_1 分别为 x_0, x_1 的函数值。

1.2 仿真结果分析

按照上述操作流程进行仿真,根据管路抓举车的抓举重物质量设置载荷,在后处理模块对仿真结果进行分析,图3为抓举过程中的最高位置(即危险工况),对图3中 J_1, J_2, J_3 这3个关节进行全工况受力分析可得到伸缩臂模型各关节受力幅值曲线(图4),其受力大小和方向由三向力合成可得。由图4可知,当 $t=100$ s时,伸缩臂模型综合受力最大,因此确定此时为最危险工况。




图3 抓举最高位置关节示意图

Fig. 3 Diagram of the joint at the maximum elevation position in Weightlifting




图4 关节受力幅值曲线

Fig. 4 Curves of the force amplitude for the joint

通过调整抓举重物的质量可以得到各关节受力情况,该仿真为可靠性分析提供了数据支撑。

2 伸缩臂的有限元分析

为提高计算的准确性和精度,本文将伸缩臂进行预处理,伸缩臂部件如图5所示,其主要是作为摆动臂和小臂之间的传力部件,通过液压缸连接实现整体的

抬升和机械爪角度变化。在作业时煤矿环境比较恶劣,因此伸缩臂的材料选取广泛适用于车辆、特种设备的 Q345 钢。为了提高有限元的计算速度,针对实际样机对模型进行了简化。




图 5 伸缩臂部件

Fig. 5 Parts of the telescopic arm

对动力学仿真确定的最危险工况进行分析,将伸缩臂部件按照几何结构分成 $t_1 \sim t_6$ 个不确定变量。基于 Ansys WorkBench 有限元软件建立伸缩臂的模型,模型的初定参数为表 1 中的基准值,表 1 中,角度 D 为大臂与摆动臂的夹角; M 为抓举重物的质量; $t_1 \sim t_6$ 分别为板厚;以此对该模型进行数值仿真。

表 1 不确定性参数基准值及变化范围

Tab. 1 Fiducial value and variable range of uncertain parameters

参数 Parameter	基准值 Fiducial value	变化范围 Variable range
$D/(\circ)$	120	$\pm 5\%$
M/kg	750	$\pm 5\%$
t_1/mm	70	$\pm 3\sigma$
t_2/mm	15	$\pm 3\sigma$
t_3/mm	20	$\pm 3\sigma$
t_4/mm	12	$\pm 3\sigma$
t_5/mm	30	$\pm 3\sigma$
t_6/mm	12	$\pm 3\sigma$

伸缩臂模型采用八节点六面体单元划分,对网格质量进行检查后,确定其网格模型(图 6),其中单元数 409 145 个,节点数 721 458 个。本文采用 Adams 仿真的数据结果进行有限元计算,因此在确定边界条件时,将大臂底部进行固定,伸缩臂与大臂两零件间进行固定连接操作,在伸缩臂-小臂连接处和液压缸连接处施加载荷,其中载荷 F_1 、 F_2 、 F_3 分别对应关节 J_1 、 J_2 、 J_3 在最危险工况时的受力,参照图 3 所示坐标系,其三向分力大小如表 2 所示。




图 6 网格模型图

Fig. 6 Diagram of the grid model

表 2 三向分力大小

Tab. 2 Magnitude of the three-way force

载荷 Load	x 方向力 x-directional force F_x/N	y 方向力 y-directional force F_y/N	z 方向力 z-directional force F_z/N
F_1	459.88	$-1.436 5 \times 10^5$	27 642
F_2	518.50	$-1.568 1 \times 10^5$	12 421.6
F_3	227.4	$-1.107 7 \times 10^5$	-35 371

图 7、图 8 为伸缩臂部件在最大载荷下的 von Mises 应力云图和位移云图,该模型最大 von Mises 应力为 286.17 MPa,最大位移为 1.401 9 mm。




图 7 最大 von Mises 应力图

Fig. 7 Nephogram of the maximum von Mises stress




图 8 最大位移图

Fig. 8 Nephogram of maximum displacement

3 伸缩臂不确定性参数敏感性分析

本文采用单因素敏感性分析方法,逐一改变伸缩臂的各不确定性参数,并定量观察比较参数变化前后伸缩臂的最大 von Mises 应力。伸缩臂的不确定性参数基准值及其变化范围如表 1 所示。

以参数基准值得到的最大 von Mises 应力作为主要评价标准,为定量描述不确定参数变化对最大 von Mises 应力的影响,引入相对变化量 $\Delta\omega$,为

$$\Delta\omega = |\omega_i^+ - \omega_i^-|/\omega_0 \quad (2)$$

式中, ω_i^+ 为不确定性参数上限值; ω_i^- 为不确定性参数下限值; ω_0 为不确定性参数基准值。

根据式(2)计算所得到的 $\Delta\omega$ 定量给出了伸缩臂不确定性参数的敏感性大小,各不确定性参数的敏感性分析结果如图 9 所示。该敏感性分析结果验证了这 8 个不确定参数均会对伸缩臂模型的可靠性产生影响,其中伸缩臂与摆动臂之间的角度 D 和板厚 t_6 对最大 von Mises 应力的影响程度远大于其他因素,其次为板厚 t_5 、板厚 t_2 、板厚 t_3 、板厚 t_4 、抓举重物质量 M 、板厚

t_1 , 为后文代理模型训练和预测提供了依据。

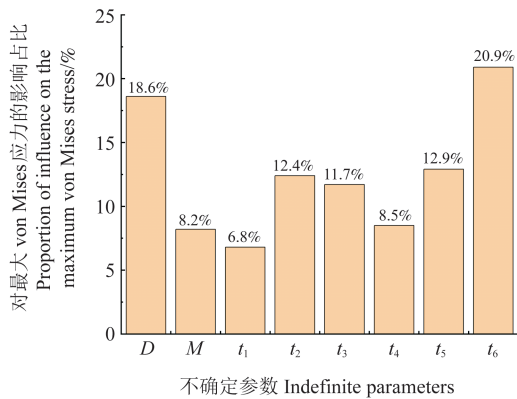


图 9 不确定性参数敏感性分析

Fig. 9 Sensitivity analysis of Uncertainty parameter

4 参数范围以及破坏判断准则

4.1 参数范围

对于伸缩臂模型的几何参数,在机加工过程中会有一些的误差,采用正态分布方式,在其标准差范围内与原模型几何特征无明显差别。对于抓举重物质量 M ,以管路抓举车出厂铭牌上的荷载质量为准,分布方式为区间分布。对于大臂和摆动臂之间的角度 D ,同样也是区间分布,当小臂连接的液压缸处于完全伸出状态时,取机械爪处于最低位置时大臂和摆动臂间的角度为区间下限,取机械爪处于最高位置时的角度为区间上限。所有输入参数均相互独立且互不影响,各输入参数分布规律如表 3 所示。

表 3 各输入参数分布规律

Tab. 3 Distribution law of each input parameter

参数 Parameter	分布类型 Distribution type	均值/上限 Mean/Upper limit	标准差/下限 Standard eviation/ Lower bound
$D/(\circ)$	区间分布 Interval istribution	126.6	64
M/kg	区间分布 Interval istribution	1 500	0
t_1/mm	正态分布 Normal istribution	70	1.4
t_2/mm	正态分布 Normal istribution	15	0.3
t_3/mm	正态分布 Normal istribution	20	0.4
t_4/mm	正态分布 Normal istribution	12	0.24
t_5/mm	正态分布 Normal istribution	30	0.6
t_6/mm	正态分布 Normal istribution	12	0.24

4.2 破坏判断准则

第四强度理论认为,不论材料处于什么应力状

态,只要构件内一点处的形变比能达到单向应力状态下的极限值,材料就发生破坏。对于伸缩臂部件来讲,当部件上的最大 Mises 应力 σ_{\max} 小于部件的许用应力 $[\sigma]$ 时,满足第四强度理论要求,因此不难得出其功能函数 $G(X)$ 为

$$G(X) = \sigma_{\max} - [\sigma] \quad (3)$$

当 $G(X) > 0$ 时,认为伸缩臂部件破坏。

由于 Q345 钢为塑性材料,依据文献[14],确定该钢材的屈服强度为 345 MPa,抗拉强度为 470~630 MPa。对于挖土机,起重机等起重机构在负载平稳运行的情况下,安全系数为 1.1~1.25,本文选取伸缩臂的安全系数为 1.1,则许用应力为 $[\sigma] = 313.64 \text{ MPa}$ 。

5 半监督深度学习神经网络

5.1 半监督学习

半监督学习^[15]就是将训练集中的数据分成有标签数据和无标签数据的机器学习算法。半监督学习使用有标签的数据来改善现有样本并由此对无标签数据进行合理预测。本文中有限元模拟得到的最大 von Mises 应力数据作为训练集样本的结果,对训练集进行前处理,一部分数据标记标签,另一部分不标记,如图 10 所示,有效地利用无标签的训练集进行辅助学习,解决在不同工况下难以确定其是否失效的问题。

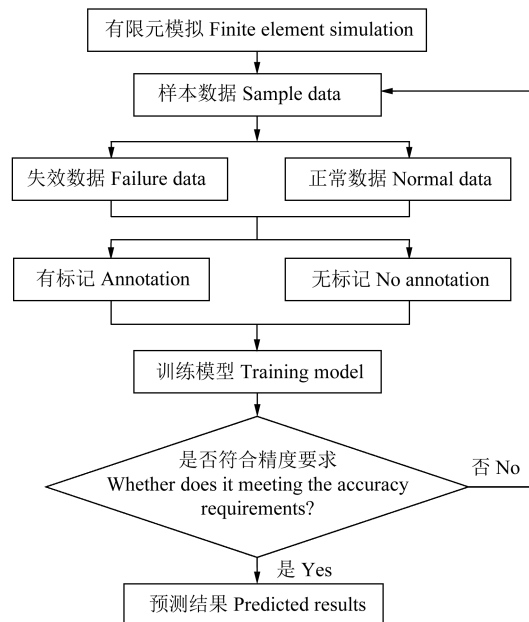


图 10 半监督学习流程图

Fig. 10 Flow chart of semi-supervised learning

5.2 深度神经网络的搭建

深度神经网络 (Deep-Learning Neural Network, DNN) 是一个更深入、更现代的人工神经网络 ANN^[16-17],深度神经网络具有很强的数据拟合能力,但需要大量的样本进行训练^[18],本文结合半监督学习提

高了对小样本的训练精度。采用 Sequential 模型搭建的全连接深度神经网络,如图 11 所示,输入层的神经元个数为 8,按照敏感性的程度分为低权重输入层和

高权重输入层,输出层神经元个数为 1,采用贝叶斯优化算法确定输入层和输出层之间含有 3 个隐藏层,隐藏层神经元个数分别为 6、32 和 16。




图 11 深度神经网络模型图

Fig. 11 Deep neural network model diagram

DNN 模型采用 ReLU 激活函数,它不存在梯度消失的问题,训练速率较快,从而提高网络的稳定性和收敛性。为了有效地抑制训练过程中出现的过拟合问题,采用了 Dropout 正则化方法,即在训练过程中随机将一部分神经元的输出设置为 0,减小模型的复杂程度,这降低了神经元之间的依赖,从而减少过拟合。

将表 1 中的 8 个不确定变量作为输入,根据各参数的分布情况,提取了 400 组训练数据。根据模型的几何参数和载荷情况建立伸缩臂的有限元模型,将有限元结果中的最大 von Mises 应力作为 DNN 模型的输出。将提取的训练数据按照 8:2 的比例分为训练集和验证集,均方误差 (Mean Square Error, MSE) 作为损失函数。MSE 是一种常用的损失函数,用来衡量预测值和实际值之间的差异,即预测值与实际值之间差值的平方, MSE 值越接近于 0,模型的预测效果越好。其定义式为

$$E_{\text{MSE}} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (4)$$

式中, N 为实际值个数; y_i 为真实值; \hat{y}_i 为预测值。

决定系数 R^2 用来评估回归模型的精度。决定系数的取值范围为 0~1; 决定系数越接近 1, 表明回归模型对真实值的拟合程度越好; 决定系数越接近于 0, 表

明回归模型对真实值的拟合程度越差,其定义式为

$$R^2 = 1 - \frac{\sum_{i=1}^N (\hat{y}_i - y_i)^2}{\sum_{i=1}^N (\bar{y}_i - y_i)^2} \quad (5)$$

式中, \bar{y}_i 为平均值。

5.3 案例分析

为了进一步验证该网络模型的准确性,本文引入了数值算例——单自由度非线性阻尼系统^[19],如图 12 所示,其功能函数为

$$G_1(X) = g(c_1, c_2, m, t_0, F_1, r) = 3r - \left| \frac{2F_1}{m\omega_0^2} \sin\left(\frac{\omega_0 t_0}{2}\right) \right| \quad (6)$$

式中, r 为振动位移量; $\omega_0 = \sqrt{(c_1 + c_2)/m}$ 。各不确定参数的分布情况如表 4 所示。

对于该数值算例,为了验证 DNN 模型的准确性,本文另外采取了支持向量回归、BP-ANN 2 种方法与之对比,3 种方法训练后的 MSE 值如表 5 所示。由表 5 可知, DNN 模型的均方误差为 2.018×10^{-5} , 远小于其他 2 种方法,由式 (5) 可得本模型 R^2 值为 0.999 4, 接近于 1, 拟合精度较高,说明了 DNN 模型的训练预测效果最佳,为本文应用于伸缩臂模型的可靠性分析提供了有力的基础。




图 12 单自由度非线性振荡器

Fig. 12 Single-degree-of-freedom nonlinear oscillator

表 4 数值算例不确定参数分布情况

Tab. 4 Distribution of uncertain parameters of numerical studies

参数 Parameters	分布类型 Distribution type	均值 Mean	方差 Variance
m	正态分布 Normal distribution	1.0	0.05
c_1	正态分布 Normal distribution	1.0	0.10
c_2	正态分布 Normal distribution	0.1	0.01
r	正态分布 Normal distribution	0.5	0.05
F_1	正态分布 Normal distribution	1.0	0.20
t_0	正态分布 Normal distribution	1.0	0.20

表 5 3 种方法对比情况

Tab. 5 Comparison of three methods

方法 Method	样本点数 Number of sample points N	均方误差 MSE
SVR	400	4.114×10^{-4}
BP-ANN	400	2.164×10^{-4}
DNN	400	2.018×10^{-5}


6 基于 DNN-MC 的可靠性分析

6.1 最优拉丁超立方采样

对于神经网络的训练需要一定量的训练数据来支持,如果采用随机采样的方式,为了达到较好的精度,则需要大量的样本,大大提高了计算成本,因此本文采用了最优拉丁超立方采样 (Optimal Latin Hypercube Sampling, OLHS) 方式,在保证训练精度的同时,减少了样本量,提高了效率。


OLHS 是在拉丁超立方 (Latin Hypercube Sampling, LHS)^[20] 的基础上进行了改进,LHS 是一种均匀采样方式,常用于在多维参数空间内的样本采集,其主要思想是将每个试验影响因素区域分成若干等份,然后在每个区域上随机选取 1 个样本点,保证在每个子区域内只有 1 个样本点,但是它的缺点是样本点之间的最小距离不是最优的。OLHS 使所有样本点均匀分布在样本空间,使用遗传算法进行优化,通过迭代生成和选取样本点组合,逐步优化最小距离,最终得到多维参数空间的分布,提高了试验的准确性和可靠性。图 13 显示了 2 种方法的试验点分布。由图 13 可以看出,LHS 采样的一些样本点比较集中,而 OLHS

的样本点更加均匀。



(a) 拉丁超立方采样

(a) LHS



(b) 最优拉丁超立方采样

(b) OLHS

图 13 2 种采样方法对比

Fig. 13 Comparison of the two sampling methods

6.2 基于 DNN-MC 的可靠性分析

MC 方法是一类基于蒙特卡洛模拟的可靠性分析技术,它的基本思想是通过随机采样来模拟不确定性,并通过重复模拟大量的样本量来得到统计结果,具有较高的精度,但计算成本较高。在实际应用中,通常会采取一些优化措施,以加速模拟过程。本文将 DNN 代理模型和 MC 方法结合起来,大大提升了计算速度。基于 DNN-MC 的伸缩臂的可靠分析流程如下:

1) 根据伸缩臂模型的几何形状、负载情况和材料特性,确定不确定参数,引入了最大 von Mises 应力相对变化量,进行敏感性分析。

2) 使用 OLHS 方法提取训练数据,根据采样的数据和 Adams 提取的负载数据进行有限元分析,为接下来的神经网络模型提供了训练数据。

3) 引入半监督学习,将一部分数据进行标记,提高计算效率,训练 DNN 代理模型,直至模型精度符合要求。

4) 将训练好的 DNN 模型对 MC 数据集进行预测,最终得到伸缩臂的可靠性。

在深度神经网络模型训练过程中,当模型精度不

符合要求时,需要增加训练数据。由图 14 可知,模型的精度随着训练数据的增加而逐步提高,本文将 MSE 作为模型精度的评判标准,当训练数据达到 400 组, DNN 模型精度趋于稳定。损失曲线经常被用于监测模型训练进展的指标,训练损失(Training loss)表示模型在训练数据上的损失,验证损失(Validation loss)表示模型在验证数据上的损失,损失越小说明模型拟合效果越好。由图 15 可以看出,训练损失和验证损失随着训练次数的增加而降低,2 条曲线都趋于稳定并且相差很小,表明模型具有很强的泛化能力,精度较高。

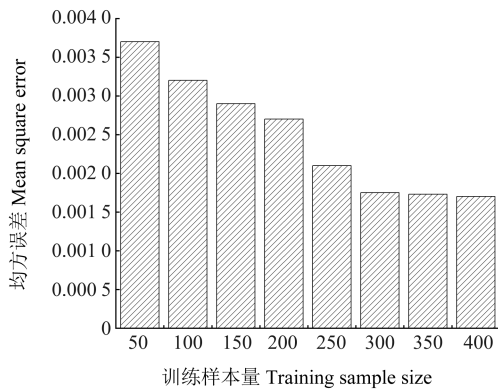


图 14 训练样本量对方均误差的影响

Fig. 14 Effect of training sample size on MSE

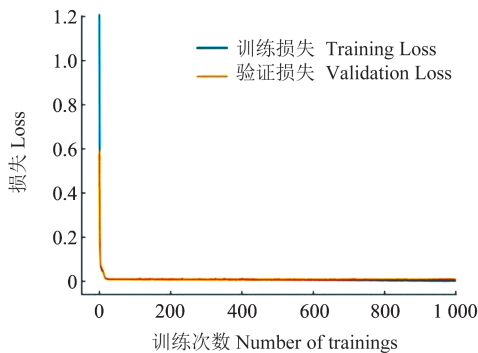


图 15 损失曲线

Fig. 15 Loss curve

DNN 模型对提取的数据进行训练后, MSE 达到最小值 0.001 7, 由式(5)可得 R^2 为 0.895 4。表 6 所示为训练后的模型参数。随机取 50 组数据来验证模型的准确性, 将训练好的 DNN 模型进行预测。图 16 所示为伸缩臂模型在不同工况下最大 von Mises 应力的预测情况。此模型的精度和预测效果均能满足工程要求, 因此将此模型作为伸缩臂可靠性分析的代理模型。

根据各输入量的分布情况, 利用训练好的 DNN 模型对 MC 方法的 100 万组数据进行预测。代入式(3)中, 当 $G(X)$ 小于 0 时, 伸缩臂部件可靠, 反之则不可靠。

伸缩臂可靠度 P 为

表 6 DNN 模型参数

Tab. 6 Parameters of DNN model

参数 Parameter	值 Value
输入层神经元数目 Number of neurons in the input layer	8
输出层神经元数目 Number of neurons in the output layer	1
隐藏层数 Number of the hidden layers	3
隐藏层神经元数目 Number of neurons in the hidden layer	6、32、16
激活函数 Activate function	ReLU
学习率 Learning rate	0.000 5
优化器 Optimizer	Adam
误差评价函数 Error evaluation function	MSE、 R^2
最高训练次数 Maximum number of training	1 000
最小误差值 Minimum error value	0.000 1

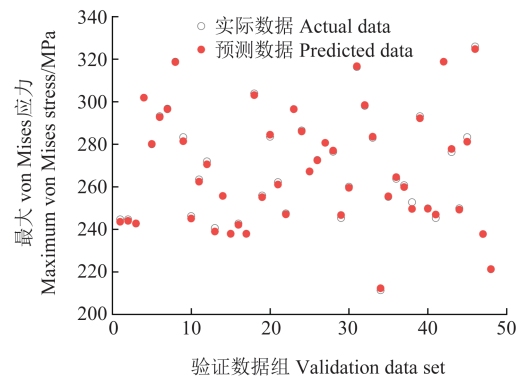


图 16 最大 von Mises 应力预测效果图

Fig. 16 Prediction effect diagram of maximum von Mises stress

$$P = \frac{N - n}{N} \quad (7)$$

式中, N 为样本总数; n 为失效的样本数。

使用训练好的深度神经网络代理模型对 MC 数据集进行预测, 得出伸缩臂部件的可靠度为 0.970 87, 其失效概率为 0.029 13。同时, 使用支持向量回归 (Support Vector Regression, SVR)、BP-ANN 2 种算法对数据集进行预测, 之后对伸缩臂可靠性分析模型进行了 1 000 次蒙特卡洛模拟 (Monte Carlo Simulation, MCS) 迭代, 对比 3 种算法后可以发现, DNN 代理模型的结果与 MCS 方法误差较小, 具有较高的精度, 如表 7 所示。由于 1 次 MCS 迭代需要较长时间, 本文提出的代理模型大大提高了计算效率。

表 7 3 种算法与 MCS 方法结果对比

Tab. 7 Comparison of results of three algorithms and the MCS method

方法 Method	均方误差 MSE	失效概率 Probability of failure	相对误差 Relative error /%
SVR	0.008 8	3.385×10^{-2}	17.28
BP-ANN	0.009 8	3.461×10^{-2}	19.10
DNN	0.001 7	2.913×10^{-2}	4.04
MCS	—	2.8×10^{-2}	—

7 结论

对于大型工程机械而言,在产品初期,对其关键部位进行可靠性分析十分必要。本文基于半监督深度神经网络对管路抓举车伸缩臂进行了可靠性分析,得到以下结论:

1)对伸缩臂部件的厚度 $t_1 \sim t_6$ 、负载、举升角度以及材料特性进行了敏感性分析,其中厚度 t_6 的敏感性明显高于其他参数。

2)采用了OLHS方式对不确定参数进行数据采集,采样数据更加均匀,从而提高了预测的准确性和可靠性。采用半监督学习与神经网络结合的方法,对部分训练数据进行标记,提高了训练的速度和精度。随着训练数据量的增加,神经网络模型的精度也趋向最优,最终训练后的模型MSE值为0.0017,符合实际工程精度要求。

3)采用DNN-MC方法对伸缩臂部件进行了可靠性分析,最终得出其可靠度为0.97087,失效概率为0.02913,符合工程机械要求的可靠度。与MCS方法对比,其结果相对误差较小,说明本文提出的可靠性方法对于工程机械在可靠性设计方面具有良好的工程适用性。

参考文献(References)

- [1] DEMPSTER A P, LAIRD N M, RUBIN D B. Maximum likelihood from incomplete data via the EM algorithm[J]. *Journal of the Royal Statistical Society: Series B(Methodological)*, 1977, 39(1): 1-22.
- [2] JIANG C, HAN X, LU G Y, et al. Correlation analysis of non-probabilistic convex model and corresponding structural reliability technique[J]. *Computer Methods in Applied Mechanics and Engineering*, 2011, 200(33/34/35/36): 2528-2546.
- [3] ZHI P P, LI Y H, CHEN B Z, et al. Fuzzy design optimization-based fatigue reliability analysis of welding robots[J]. *IEEE Access*, 2020, 8: 64906-64917.
- [4] ALISHAYANFAR M, ALI BARKHORDARI M, BARKHORI M, et al. Improving the first-order structural reliability estimation by Monte Carlo simulation[J]. *Proceedings of the Institution of Civil Engineers-Structures and Buildings*, 2017, 170(7): 532-540.
- [5] ROY P, MAHAPATRA G S, DEY K N. Forecasting of software reliability using neighborhood fuzzy particle swarm optimization based novel neural network[J]. *IEEE/CAA Journal of Automatica Sinica*, 2019, 6(6): 1365-1383.
- [6] 张宏斌,贾志新,郗安民. 基于神经网络的小样本系统可靠性预计[J]. *机械科学与技术*, 2009(12): 1555-1559.
ZHANG Hongbin, JIA Zhixin, XI Anmin. System reliability prediction with small samples based on neural networks[J]. *Mechanical Science and Technology for Aerospace Engineering*, 2009(12): 1555-1559. (In Chinese)
- [7] 赵丽娟,靳予记,黄凯. 随机载荷下截割部输出轴可靠性分析[J]. *机械强度*, 2019, 41(4): 864-870.
ZHAO Lijuan, JIN Yuji, HUANG Kai. Reliability analysis of output shaft of cutting edge section under random load[J]. *Journal of Mechanical Strength*, 2019, 41(4): 864-870. (In Chinese)
- [8] LI H Q, TAN Q. Recognition of reliability model of vibratory roller based on artificial neural network[C]//2008 International Conference on Intelligent Computation Technology and Automation (ICICTA). IEEE Computer Society, 2008: 231-234.
- [9] YAN W X, PIN W, HE L. Reliability prediction of CNC machine tool spindle based on optimized cascade feedforward neural network[J]. *IEEE Access*, 2021, 9: 60682-60688.
- [10] 林景亮,黄运保,李海艳,等. 基于深度代理模型的叉车臂架液压系统设计优化[J]. *中国机械工程*, 2022, 33(3): 290-298.
LIN Jingliang, HUNG Yunbao, LI Haiyan, et al. Design optimization for hydraulic systems of forklift boom based on deep surrogate model[J]. *China Mechanical Engineering*, 2022, 33(3): 290-298. (In Chinese)
- [11] 王璟,孙克俐. 基于ANN的船舶撞击高桩码头群桩损伤位置预测[J]. *港工技术*, 2020, 57(2): 34-38.
WANG Jing, SUN Keli. Prediction of damaged position of pile clusters while a ship colliding with piled berth structure based on ANN[J]. *Port Engineering Technology*, 2020, 57(2): 34-38. (In Chinese)
- [12] 孔宁宁,朱海清,李天津. 基于Adams的安全阀搬运自动导向车原地转向力学仿真研究[J]. *机械强度*, 2022, 44(5): 1243-1248.
KONG Ningning, ZHU Haiqing, LI Tianjin. Mechanical simulation research on in situ steering of automatic steering vehicle for handling safety valve based on Adams [J]. *Journal of Mechanical Strength*, 2022, 44(5): 1243-1248. (In Chinese)
- [13] 李铮,李敏,王爱国,等. 基于多体动力学的电动助力转向系统仿真与试验研究[J]. *机械强度*, 2022, 44(5): 1194-1200.
LI Cheng, LI Min, WANG Aiguo, et al. Simulation and experimental research of electric power steering system based on multi-body dynamics[J]. *Journal of Mechanical Strength*, 2022, 44(5): 1194-1200. (In Chinese)
- [14] 温秉权,黄勇. 金属材料手册[M]. 2版. 北京:电子工业出版社, 2009: 71-73.
WEN Bingquan, HUANG Yong. Handbook of metal materials [M]. 2nd ed. Beijing: Publishing House of Electronics Industry, 2009: 71-73. (In Chinese)
- [15] GOLDBERG X, GOLDBERG A B. Introduction to semi-supervised learning[J]. *Synthesis Lectures on Artificial Intelligence and Machine Learning*, 2009, 6: 1-116.
- [16] CAO Y D, DING Y F, JIA M P, et al. A novel temporal convolutional network with residual self-attention mechanism for remaining useful life prediction of rolling bearings[J]. *Reliability Engineering & System Safety*, 2021, 215: 107813.
- [17] 邵可鑫,桑建兵,田魏昌,等. 基于深度神经网络水下清淤机器

- 人绞龙的可靠性分析[J]. 机械科学与技术, 2024, 43(11): 1894-1900.
- SHAO Kexin, SANG Jianbing, TIAN Weichang, et al. Reliability analysis of packing auger of desilting robot based on deep neural networks [J]. Mechanical Science and Technology for Aerospace Engineering, 2024, 43(11):1894-1900. (In Chinese)
- [18] 彭凡, 邹司农, 任毅如. 基于深度学习的复合材料螺栓连接失效预测[J]. 机械强度, 2023, 45(2):447-453.
- PENG Fan, ZOU Sinong, REN Yiru. Failure prediction of bolted connection of composite materials based on deep learning[J]. Journal of Mechanical Strength, 2023, 45(2):447-453. (In Chinese)
- [19] SCHUEREMANS L, VAN GEMERT D. Benefit of splines and neural networks in simulation based structural reliability analysis [J]. Structural Safety, 2005, 27(3):246-261.
- [20] 辛俊胜, 商跃进, 王红, 等. 基于最优拉丁超立方抽样的动车组轴箱弹簧稳健设计[J]. 铁道机车车辆, 2020, 40(5):60-64.
- XIN Junsheng, SHANG Yuejin, WANG Hong, et al. Robust design of EMU axle box spring based on optimal Latin hypercube sampling [J]. Railway Locomotive & Car, 2020, 40(5):60-64. (In Chinese)

Reliability analysis of telescopic arm of pipeline-catching vehicle based on semi-supervised deep neural network

YUAN Guozhi¹ LIU Wei¹ YAN Zilong² ZHANG Ruilin¹ ZHAO Mingxuan¹ SANG Jianbing¹

(1. School of Mechanical Engineering, Hebei University of Technology, Tianjin 300400, China)

(2. Langfang Jinglong Heavy Equipment Co., Ltd., Langfang 065300, China)

Abstract: The telescopic arm, a pivotal component in the pipeline grabbing vehicle, links the lifting platform and the mechanical claw, shouldering the majority of the load. Conducting a reliability analysis is imperative. Traditional methods for reliability face challenges like high computational costs and low accuracy dealing with multidimensional uncertainties. To overcome these, our study proposed an engineering mechanical reliability analysis method, leveraging Adams dynamic simulation, semi-supervised learning, deep neural networks, and Monte Carlo method. In this study, a virtual prototype model of the pipeline grabbing vehicle was established, identifying hazardous operating conditions. Combining the telescopic arm model's geometric parameters and overall structure, uncertain factors influencing the maximum von Mises stress were determined, conducting a sensitivity analysis was conducted. Utilizing optimal Latin hypercube sampling based on uncertain parameter distributions, Ansys Workbench was employed to build a finite element model, obtain output results for the sample size. Semi-supervised learning processed the finite element simulation data, enhanced deep neural network training accuracy. Finally, based on the fourth strength theory, a failure criteria for the telescopic arm component was determined. Combining deep neural networks and Monte Carlo method, the reliability and failure probability were predicted. Results show that this method surpasses actual engineering precision requirements, provides a certain guiding significance.

Key words: Telescopic arm; Reliability analysis; Semi-supervised learning; Deep neural networks; Optimal Latin hypercube sampling

Corresponding author: SANG Jianbing, E-mail: sangjianbing@hebut.edu.cn

Fund: Natural Science Foundation of Hebei Province (A2020202015); National Defense Science and Technology Key Laboratory Foundation

Received: 2023-10-13 Revised: 2024-03-08