



# 计算机科学

COMPUTER SCIENCE

## 基于数据学习的结构静力学性能预测方法

赵航, 童水光, 朱郑州

引用本文

赵航, 童水光, 朱郑州. 基于数据学习的结构静力学性能预测方法[J]. 计算机科学, 2022, 49(4): 140-143.

ZHAO Hang, TONG Shui-guang, ZHU Zheng-zhou. [Prediction Method of Structural Static Performance Based on Data Learning](#)[J]. Computer Science, 2022, 49(4): 140-143.

---

## 相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

### [基于时空自适应图卷积神经网络的脑电信号情绪识别](#)

EEG Emotion Recognition Based on Spatiotemporal Self-Adaptive Graph Convolutional Neural Network  
计算机科学, 2022, 49(4): 30-36. <https://doi.org/10.11896/jsjcx.210900200>

### [融合快速注意力机制的节点无特征网络链路预测算法](#)

Link Prediction for Node Featureless Networks Based on Faster Attention Mechanism  
计算机科学, 2022, 49(4): 43-48. <https://doi.org/10.11896/jsjcx.210800276>

### [图神经网络在 Text-to-SQL 解析中的技术研究](#)

Technical Research of Graph Neural Network for Text-to-SQL Parsing  
计算机科学, 2022, 49(4): 110-115. <https://doi.org/10.11896/jsjcx.210200173>

### [共享浅层参数多任务学习的脑出血图像分割与分类](#)

Intracerebral Hemorrhage Image Segmentation and Classification Based on Multi-task Learning of Shared Shallow Parameters  
计算机科学, 2022, 49(4): 203-208. <https://doi.org/10.11896/jsjcx.201000153>

### [基于多级特征融合与注意力模块的场景识别方法](#)

Scene Recognition Method Based on Multi-level Feature Fusion and Attention Module  
计算机科学, 2022, 49(4): 209-214. <https://doi.org/10.11896/jsjcx.210100135>

# 基于数据学习的结构静力学性能预测方法

赵航<sup>1</sup> 童水光<sup>1</sup> 朱郑州<sup>2</sup>

1 浙江大学机械工程学院 杭州 310027

2 北京大学软件与微电子学院 北京 102600

(zhaoyihang@zju.edu.cn)

**摘要** 针对目前机械结构优化中建立预测模型代价较高的问题,提出了一种基于数据学习的结构静力学性能预测方法。以悬臂梁为研究对象,建立有限元仿真模型以获取位移场数据,构建边界条件-位移场代理模型,预测结果表明位移场分布趋势与实际一致,载荷为 1000 N 和 1600 N 时最大位移相对误差分别为  $-0.02\%$  和  $-0.47\%$ 。文中讨论了均布力大小和集中力作用位置对位移场预测结果的影响,结果表明,随着载荷幅值增加,预测误差有所增加。相比均布力,集中力载荷下的预测误差更大,且加载位置靠近边缘处的误差更大。反演问题分别将位移场作为输入,将均布力大小和集中力位置作为输出构建位移场-边界条件代理模型,载荷为 1000 N 和 1600 N 时的预测误差分别为  $0.15\%$  和  $-0.48\%$ ,在 5 mm 和 10 mm 处的载荷位置预测误差分别为  $0.38\%$  和  $-1.84\%$ ,实现了对力边界条件的高精度预测。所提方法从数据学习角度出发,可为机械结构的静力学性能预测提供一种新的思路。

**关键词**: 数据学习;代理模型;神经网络;有限元分析;性能预测

中图分类号 TP183

## Prediction Method of Structural Static Performance Based on Data Learning

ZHAO Hang<sup>1</sup>, TONG Shui-guang<sup>1</sup> and ZHU Zheng-zhou<sup>2</sup>

1 School of Mechanical Engineering, Zhejiang University, Hangzhou 310027, China

2 School of Software & Microelectronics, Peking University, Beijing 102600, China

**Abstract** Aiming at the high cost of establishing a prediction model in the current mechanical structure optimization, a prediction method of structural static performance based on data learning is proposed. The cantilever beam is taken as the research object, and the finite element model is established to obtain the displacement field data of the simulation results. Then the boundary condition-displacement field surrogate model is constructed. The results show that the trend of displacement field distribution is consistent with the actual situation, and the relative error of the maximum displacement is  $-0.02\%$  and  $-0.47\%$  under the load of 1000 N and 1600 N, respectively. The influences of the magnitude of the uniform force and the position of the concentrated force on the displacement field prediction are discussed. The results show that the prediction error increases with the increase of load amplitude. Compared with the uniform force, the prediction error under the concentrated force load is larger, and the error is larger when the loading position is near the edge. In the inversion problem, the displacement fields are taken as the input, the uniform forces and the positions of concentrated force are taken as the output to construct the displacement field-boundary condition surrogate model. The prediction errors under the uniform loads of 1000 N and 1600 N are  $0.15\%$  and  $-0.48\%$ , respectively, and the prediction errors under the load positions at 5 mm and 10 mm are  $0.38\%$  and  $-1.84\%$ . The method based on data learning can provide new thinking for the prediction of structural static performance.

**Keywords** Data learning, Surrogate model, Neural network, Finite element analysis, Performance prediction

## 1 引言

在机械结构优化问题中,往往需要建立关键设计变量与性能参数之间的模型,进而采取优化算法在设计空间内寻优。此方法的关键在于数据的获取。

数据学习(Data Learning)是一个很宽泛的概念,指从数

据中提取有价值信息的过程,包括应用数学、统计、模式识别、机器学习、数据可视化、数据仓库以及高性能计算等<sup>[1]</sup>。在机械结构分析中,性能参数指标如位移、最大应力等往往通过仿真分析获得,基于力学框架的有限元分析几乎成为了结构力学性能预测的行业标准,而此步骤往往繁琐且代价较大,是制约建模所需数据量进而影响模型精度的瓶颈。通过有限

到稿日期:2021-03-23 返修日期:2021-09-09

基金项目:浙江省重点研发计划(2019C01057)

This work was supported by the Zhejiang Province Key R & D Program(2019C01057).

通信作者:朱郑州(zhuzz@ss.pku.edu.cn)

元模型仿真获取结果本质上是基于现有力学框架对问题的预测,若有限元模型能通过代理模型得到进一步简化,便可以解决数据获取代价较高的难题。因此,本文从数据学习的角度简化有限元分析过程,直接预测结构的力学性能。

## 2 代理模型理论与方法

代理模型(Surrogate Model)最早由 Schmit 等于 1974 年提出<sup>[2]</sup>,指在分析和优化设计中可代替计算复杂且费时的数值分析或物理试验结果的数学模型,通过近似达到“代理”的功能,又被称为近似模型(Approximate Model)、元模型(Meta-model)等<sup>[3-4]</sup>。构建步骤一般为:

- (1)设计试验,在设计空间中确定构造模型的  $n$  个样本点  $\mathbf{x}^i (i=1, \dots, n)$ ,其中  $\mathbf{x}^i=(x_1, x_2, \dots, x_m)$ ,是一个  $m$  维向量。
- (2)通过试验确定系统在样本点  $\mathbf{x}^i$  处的响应值  $\mathbf{y}^i=(y_1, y_2, \dots, y_q)$ ,从而获得样本对  $(\mathbf{x}^i, \mathbf{y}^i)$ 。
- (3)选取一部分样本对,构造模型  $f(\mathbf{x}^i)$ ,使  $f(\mathbf{x}^i)$  能够较好地预测  $\mathbf{y}^i$ 。用剩余样本对检验模型,直至拟合精度满足要求。

目前常用的代理模型有多项式响应面(Polynomial Response Surface, PRS)、克里金(Kriging, KRG)模型、人工神经网络(Artificial Neural Network, ANN)等<sup>[5]</sup>。代理模型广泛应用于工程优化设计领域<sup>[6-9]</sup>,用于建立关键设计变量与性能指标之间的关系。由于仿真试验步骤繁琐,获得样本数据的代价较大,因此数据量较小,模型的构建相对简单,故不同模型之间预测性能的差别并不明显,一般都能较好地预测结构的性能参数<sup>[7,9]</sup>。神经网络由商业软件公司持续开发维护,功能完善且使用方便,因此本文选取神经网络作为代理模型开展研究。

典型的神经元模型如图 1(a)所示,包括加权求和和激活两个部分。 $x_1, x_2, \dots, x_n$  为神经元接受的输入,  $\omega_1, \omega_2, \dots, \omega_n$  为对应的权重,即待学习的参数。求输入参数的加权得:

$$y = \sum_{i=1}^n \omega_i x_i + b \quad (1)$$

输出为:

$$h_{\theta}(x) = g(y) \quad (2)$$

其中,  $g(y)$  为激活函数(Activation Function),常用的有 Sigmoid, ReLU 等。




图 1 神经元模型与神经网络  
Fig. 1 Neuron model and neural network

如图 1(b)所示,由许多神经元按层级组织起来的网络称为神经网络。通过神经网络前向传播和反向传播,根据链式求导法则(Chain Rule)采用梯度下降法修正相应的参数,反复迭代以达到最小化损失函数(Loss Function)的目的。

## 3 基于边界条件预测位移场

### 3.1 均布载荷大小-位移场预测

本文选取二维悬臂梁作为研究对象。如图 2(a)所示,

悬臂梁的材料为结构钢,长宽为  $10 \text{ mm} \times 2 \text{ mm}$ ,左侧固定,上方施加沿  $-y$  方向的均布载荷  $q$ ,有限元模型的网格大小划分为  $1 \text{ mm}$ 。采用典型有限元分析流程计算该问题,本构模型采用各向同性的线弹性应力-应变模型,指派材料,划分网格,施加约束和载荷等边界条件,当仅受重力时得出位移云图如图 2(b)所示。显而易见,位移从固定边向边缘处逐渐增大,位移场趋势清晰。

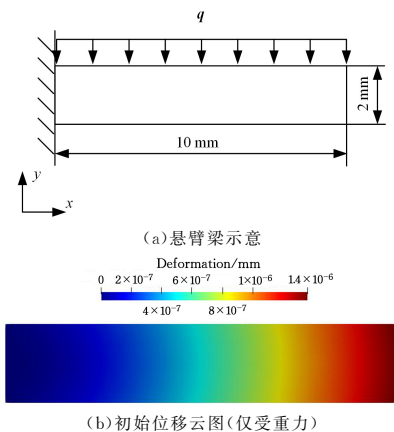


图 2 典型悬臂梁问题及初始位移云图

Fig. 2 Typical cantilever beam problem and initial deformation cloud

分别对边界条件的均布载荷  $q$  取值,  $q = \{10, 100, 300, 500, 700, 900, \dots, 1500\}$  (单位为 N),通过有限元方法计算位移场。本问题属于大变形的几何非线性问题,计算时应加以考虑。提取各节点的位移结果  $y = \{y_1, \dots, y_5\}$  (单位为 mm),加上初始状态,共 10 组数据。本文采用的是 MATLAB 的神经网络工具箱,其功能成熟,操作简便。采取默认设置建立两层神经网络模型,训练时将数据的 15% 作为验证集,得到预测模型,训练结果如图 3 所示。

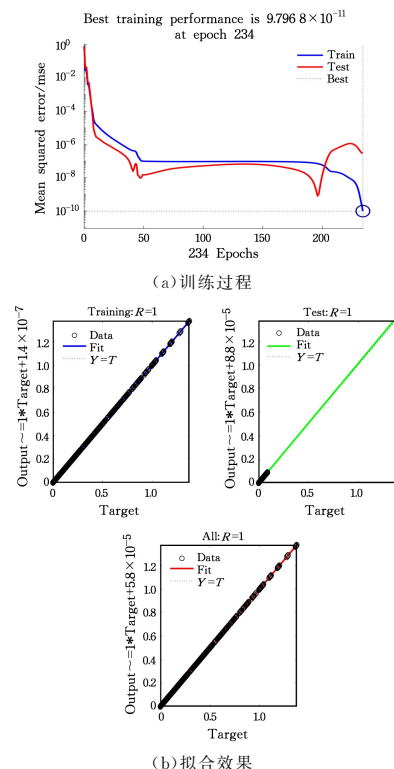


图 3 神经网络模型的训练结果

Fig. 3 Training results of neural network model

可以看出,神经网络模型对载荷  $q$  和位移场的拟合十分精确,训练误差达到了  $10^{-10}$  量级,相关系数  $R=1$ 。选取  $q$  为 1 000 N 和 1 600 N 进行测试,分别得到预测位移场数据,渲染后的结果如图 4 所示。可以看出,模型对位移场的预测结果近乎完美,对两测试载荷预测结果的趋势也基本相同。

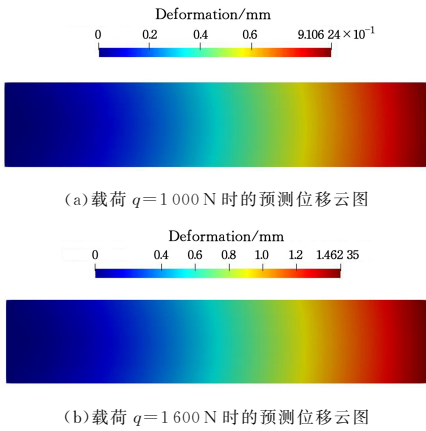


图 4 均布测试载荷下的模型预测位移云图

Fig. 4 Deformation cloud of model prediction under uniform testing loads

为验证结果的准确性,与行业标杆有限元分析软件最大位移的结果进行对比,结果如表 1 所列。载荷为 1 000 N 和 1 600 N 时最大位移的相对误差分别为  $-0.02\%$  和  $-0.47\%$ ,具有很高的预测精度。由于考虑了几何大变形,随着载荷的增加变形增幅加快,且超出了训练集的载荷范围,因此预测精度有所下降。

表 1 载荷大小-位移模型与有限元分析结果的比较

Table 1 Deformation comparison between load magnitude-deformation model prediction and FEA

载荷 $q/\text{N}$	模型预测最大位移/mm	有限元分析最大位移/mm	相对误差/%
1 000	0.91062	0.91084	-0.02
1 600	1.46235	1.46920	-0.47

### 3.2 集中力位置-位移场预测

将图 2(a)中悬臂梁均布载荷  $q$  替换为集中力,  $F=500\text{N}$ , 研究作用位置对位移场的预测模型。对悬臂梁上方沿  $x$  轴方向距离固定端  $l=\{1,2,3,\dots,10\}$  (单位为 mm) 位置处依次加载集中力  $F$ , 有限元分析考虑大变形, 分别得到 10 组位移场结果  $y=\{y_1, y_2, y_3, \dots, y_{10}\}$  (单位为 mm)。加上初始  $l=0\text{mm}$  位置处的位移结果, 共 11 组数据。将  $l=5\text{mm}$  和对应位移场结果取出, 将其余 10 组数据力加载位置作为输入, 将位移场作为输出建立神经网络模型, 建立代理模型和训练的过程如上文所述, 不再赘述。

预测  $l=5\text{mm}$  条件下的位移场结果如图 5(a) 所示。同理,  $l=10\text{mm}$  条件下位移场预测结果如图 5(b) 所示。从位移场云图可以看出, 代理模型对结构变形趋势都有较好的预测。从悬臂梁固定端到自由端位移呈梯度增加, 作用在 10 mm 处集中力对结构的整体变形影响更靠外侧, 与实际情况相符。

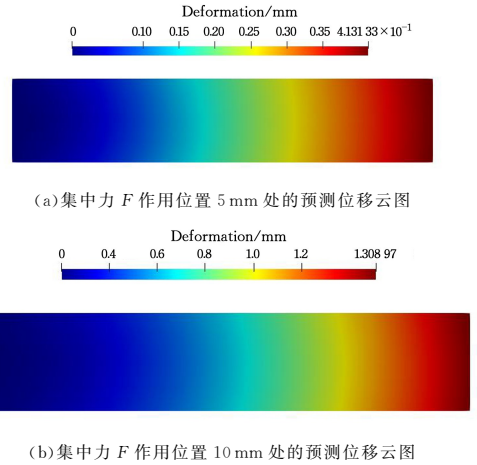


图 5 不同集中力位置下的预测位移云图

Fig. 5 Deformation cloud of model prediction under concentration forces at different positions

两种情况下最大位移与有限元分析结果的比较如表 2 所列, 集中力作用位置为 5 mm 和 10 mm 情况下最大位移误差分别为  $-0.46\%$  和  $-1.95\%$ , 模型预测准确度较高。其中集中力位置为 10 mm 时误差较大, 且相比均布力, 集中力载荷下的预测误差更大。这是由于分析时考虑了大变形, 随着集中力增加变形幅度加大, 因此预测难度加大。

表 2 载荷位置-位移模型与有限元分析结果的比较

Table 2 Deformation comparison between loading position-deformation model prediction and FEA

载荷位置 $l/\text{mm}$	模型预测最大位移/mm	有限元分析最大位移/mm	相对误差/%
5	0.41313	0.41504	-0.46
10	1.30897	1.33504	-1.95

## 4 反问题求解

反问题 (Inverse Problem) 是相对于正问题 (Forward Problem) 而言的<sup>[10]</sup>。正问题是已知控制方程和边界条件, 求解研究对象的物理量, 如位移场等。反问题往往是根据已知问题的解反演出未知条件, 如传热问题中根据已知的温度信息恢复模型的边界条件、热源、模型形状等。反问题的求解极具挑战性, 吸引了大量研究<sup>[11-14]</sup>。一般而言, 反问题是非线性且不适定的, 即其解的存在性、唯一性和稳定性很难同时得到保证。反问题的数学求解过程比较复杂, 有正则化方法、最优化计算方法、统计方法、支持向量机 (SVM) 以及其他的数值代数方法等<sup>[14-16]</sup>。本文从数据学习的角度, 采用神经网络代理模型并基于位移场预测力边界条件。

### 4.1 位移场-均布载荷大小预测

将位移场作为输入, 载荷  $q$  作为目标训练神经网络模型, 构建代理模型的方法同上, 不再赘述。训练完成后将位移场作为输入预测载荷大小, 结果如表 3 所列。载荷为 1 000 N 和 1 600 N 时的预测误差分别为  $0.15\%$  和  $-0.48\%$ , 达到了很高的精度。由于考虑大变形后位移增加幅度加大, 随着载荷增加预测误差有所增加。

表3 模型预测载荷大小与真实值比较

Table 3 Value comparison between model prediction and real load

载荷大小 $q/N$	模型预测值/ $N$	相对误差/%
1000	$1.00150 \times 10^3$	0.15
1600	$1.59233 \times 10^3$	-0.48

#### 4.2 位移场-集中载荷位置预测

将位移场作为输入,将集中载荷位置  $l$  作为输出训练神经网络模型,方法同上。预测 5 mm 和 10 mm 处的载荷位置如表 4 所列,预测误差分别为 0.38% 和 -1.84%,精度较高。可以看出,加载位置靠近边缘处的误差更大,且集中力的预测相比均布力的误差更大,这是由于集中力造成的大变形更加明显,变形增加幅度加大,预测难度加大。

表4 模型预测载荷位置与真实值比较

Table 4 Position comparison between model prediction and real load

载荷位置 $l/mm$	模型预测值/ $mm$	相对误差/%
5	5.01924	0.38
10	9.81567	-1.84

**结束语** 本文提出了基于数据学习的结构力学性能预测方法,可为机械结构的力学性能预测提供一种新的思路。

(1)构建边界条件-位移场代理模型,用于预测悬臂梁结构的力学性能。结果表明,位移场分布的趋势与实际一致,载荷为 1000 N 和 1600 N 下最大位移相对误差分别为 -0.02% 和 -0.47%,具有很高的预测精度。

(2)讨论了均布力大小和集中力作用位置对位移场预测结果的影响。随着载荷幅值的增加,预测误差有所增加。相比均布力,集中力载荷下的预测误差更大,且加载位置靠近边缘处的误差更大。

(3)反演问题实现了对力边界条件的高精度预测。载荷为 1000 N 和 1600 N 时的预测误差分别为 0.15% 和 -0.48%,预测 5 mm 和 10 mm 处载荷位置的误差分别为 0.38% 和 -1.84%,精度达到了较高水平。

综上,基于神经网络代理模型可基于有限元模型结果对位移场作出相当精确的预测,对已知位移场预测力边界条件也有很高的精度,可简化复杂的有限元计算过程,甚至突破现有力学理论框架,基于试验数据直接对结构性能作出预测,很有必要继续进行深入研究。

本文采用的悬臂梁模型比较简单,实际工程中节点的位移场数据量巨大,因此对庞大矩阵的处理方法仍需进一步研究,需要重新构建不同约束条件下的模型。本文只研究了力边界条件,今后可进一步研究复杂边界条件下模型的预测性能。

#### 参考文献

- [1] DHAR V. Data science and prediction[J]. Communications of the ACM, 2013, 56(12): 64-73.
- [2] SCHMIT J R L A, FARSHI B. Some approximation concepts for structural synthesis [J]. AIAA Journal, 1974, 12(5): 692-699.
- [3] FORRESTER A, SOBESTER A, KEANE A. Engineering design via surrogate modelling: a practical guide[M]. Chichester: John Wiley & Sons, 2008.
- [4] HAN Z H, XU C Z, QIAO J L, et al. Recent progress of efficient

global aerodynamic shape optimization using surrogate-based approach [J]. Acta Aeronautica et Astronautica Sinica, 2020, 41(5): 30-70.

- [5] MU X F, YAO W X, YU X Q, et al. Research on surrogate models in multidisciplinary design optimization[J]. Chinese Journal of Computational Mechanics, 2005, 22(5): 608-612.
- [6] CHEN Y Y, ZHENG L. Simulation and Optimization of Vehicle Frontal Crashworthiness Based on Surrogate Model[J]. Automotive Engineering, Zhejiang University, 2018, 40(6): 673-678.
- [7] TONG S G, ZHAO H, LIU H Q, et al. Optimization calculation method for efficiency of multistage split case centrifugal pump [J]. Journal of Zhejiang University (Engineering Science), 2019, 53(5): 988-996.
- [8] QIAN J C, YI J X, CHENG Y S, et al. A sequential constraints updating approach for Kriging surrogate model-assisted engineering optimization design problem[J]. Engineering with Computers, 2020, 36: 993-1009.
- [9] TONG S G, ZHAO H, LIU H Q, et al. Multi-objective optimization of multistage centrifugal pump based on surrogate model [J]. Journal of Fluids Engineering, 2020, 142(1): 011101.
- [10] YANG G F. Algorithms and applications of some forward and inverse problems in mathematical physics[D]. Shanghai: Fudan University, 2007.
- [11] CLERMONT G, SVEN Z. The inverse problem in mathematical biology[J]. Mathematical Biosciences, 2015, 260: 11-15.
- [12] GU Y, LEI J, FAN C M, et al. The generalized finite difference method for an inverse time-dependent source problem associated with three-dimensional heat equation[J]. Engineering Analysis with Boundary Elements, 2018, 91: 73-81.
- [13] MA W C, WANG S L, GU J Y, et al. Deep feedback inverse problem solver[C]//European Conference on Computer Vision. Cham: Springer, 2020: 229-246.
- [14] WANG Y F. Calculation method of inversion problem and its application[M]. Beijing: Higher Education Press, 2007.
- [15] CHAO L M, XING C X, ZHANG Y. Data Science Studies: State-of-the-art and Trends[J]. Computer Science, 2018, 45(1): 1-13.
- [16] CHAO L M, WANG R. Data Science Platform: Features, Technologies and Trends[J]. Computer Science, 2021, 48(8): 1-12.



**ZHAO Hang**, born in 1994, postgraduate. His main research interests include optimization of mechanical structure and data learning.



**ZHU Zheng-zhou**, born in 1979, Ph.D., associate professor, is a member of China Computer Federation. His main research interests include personalized recommendation in the big data environment and educational big data.