

DOI: 10.16544/j.cnki.cn43-1494/u.202209062024101996

文章编号: 1674-599X(2025)01-0098-07

引用格式: 覃聪, 田仲初, 马连峰, 等. Adam优化神经网络的连续刚构桥施工线形预测[J]. 交通科学与工程, 2025, 41(1): 98-104, 139.

Citation: QIN Cong, TIAN Zhongchu, MA Lianfeng, et al. Construction alignment prediction of continuous rigid frame bridge based on Adam-optimized neural network [J]. Journal of Transport Science and Engineering, 2025, 41(1): 98-104, 139.

Adam优化神经网络的连续刚构桥施工线形预测

覃聪¹, 田仲初¹, 马连峰², 张凤祺²

(1. 长沙理工大学 土木与环境工程学院, 湖南 长沙 410114;

2. 中交一公局第九工程有限公司, 广东 广州 511338)

摘要:【目的】针对现有桥梁施工线形预测方法的不足, 提出一种基于自适应矩估计(adaptive moment estimation, Adam)优化反向传播(back propagation, BP)神经网络的连续刚构桥线形预测方法。【方法】以小乌江大桥为研究对象, 通过正交试验确定了桥梁施工线形的敏感参数为混凝土容重、混凝土弹性模量、张拉控制应力和温度。以均方根误差、平均绝对误差、决定系数和运算耗时为评价指标, 在初始学习率相同的条件下, 对梯度下降、梯度下降最小化、均方根传播和Adam四种优化算法的性能进行对比。【结果】基于Adam优化算法的BP神经网络收敛时的运算耗时为0.518 s, 相较于其他三种优化算法, Adam优化算法下BP神经网络具有更快的收敛速度和更高的拟合精度。【结论】所提方法可较准确地预测连续刚构桥施工过程的线形。

关键词: 连续刚构桥; 施工监控; 线形预测; 多层BP神经网络; Adam算法

中图分类号: U448.23

文献标志码: A

Construction alignment prediction of continuous rigid frame bridge based on Adam-optimized neural network

QIN Cong¹, TIAN Zhongchu¹, MA Lianfeng², ZHANG Fengqi²

(1. School of Civil and Environmental Engineering, Changsha University of Science & Technology, Changsha 410114, China; 2. The Ninth Engineering Co., Ltd. of China First Highway Engineering Co., Ltd., Guangzhou 511338, China)

Abstract: [Purposes] Given the shortcomings of existing construction alignment prediction methods for bridges, a alignment prediction method for continuous rigid frame bridge based on back propagation (BP) neural network optimized by adaptive moment estimation (Adam) was proposed. [Methods] With the project of Xiaowujiang Bridge taken as the research object, the sensitive parameters of bridge construction alignment were determined through the orthogonal test, namely concrete bulk density, concrete elastic modulus, tension control stress, and temperature. With the root mean square error, average absolute error, coefficient of determination, and operation time taken as evaluation indexes, under the same incipient learning rate, the four optimization algorithms of gradient descent, minimum gradient descent, root mean square propagation, and Adam were compared. [Findings] The results indicate that the operation time for the BP neural network optimized by Adam when it finishes convergence is 0.518 s and that the Adam algorithm has a faster convergence speed and

收稿日期: 2022-09-06

基金项目: 国家自然科学基金面上项目(51478049)

通信作者: 田仲初(1963—), 男, 教授, 主要从事大跨桥梁结构分析与施工控制方面的研究工作。E-mail: 752885515@qq.com

投稿网址: <https://jtkxygc.csust.edu.cn/jtkxygc/home>

a higher fitting accuracy than the other three optimization algorithms. [Conclusions] The proposed method can predict the alignment of rigid frame bridge construction in a relatively accurate way.

Key words: continuous rigid bridge; construction monitoring; alignment prediction; multi-layer BP neural network; Adam algorithm

在桥梁的施工过程中,由于受到多种因素的影响,桥梁的参数在实际施工时难以与设计时保持一致,如混凝土的收缩徐变、预应力损失、预应力张拉控制力等,因此,桥梁的实际状态很难与设计状态完全一致。这种误差在施工过程中不断积累,使得桥梁上部结构的受力状态和线形逐渐偏离设计目标。如果在施工的过程中没有采取有效的施工控制,就会严重影响桥梁的使用寿命和可靠性^[1]。因此,有必要对桥梁的变形进行长期监测,及时获取桥梁施工过程中的信息,为后续的施工提供指导^[2]。

随着人工智能的发展,反向传播(back propagation, BP)神经网络在土木工程领域的应用日益广泛^[3]。BP神经网络以最小化损失函数为目标,通过前向传播对训练样本进行学习并计算输出和误差,再根据误差梯度通过反向传播不断修正网络的权值和阈值,最终使得BP神经网络误差满足精度要求^[4]。徐学松^[5]利用BP神经网络模型对江西省某大跨预应力混凝土连续梁桥施工过程中的线形进行了预测,经过训练后的模型在训练样本集的输出误差小于2.5%。LU等^[6]提出一种基于多尺度输入的BP神经网络大结构损伤辨识方法,在不同层次的噪声环境中通过仿真大跨度空间结构,验证了该方法的鲁棒性和有效性。鄢秉红^[7]利用BP神经网络对既有桥墩进行变位分析,分析结果可对受多种复杂因素影响的桥墩倾斜和沉降的监测分析起指导作用。录哲元等^[8]采用基于思维进化算法的BP神经网络对大跨径波形钢腹板连续刚构桥的施工线形进行预测,一定程度上降低了神经网络的预测误差。石娟等^[9]提出一种基于BP神经网络的工人不安全行为预警模型,该模型具有较强的预警能力,可有效地发出预警,预防不安全行为的产生。胡庆国等^[10]建立了基于遗传算法的BP神经网络预测模型,对综合管廊工程进行投资估算,其估算精度优于BP神经网络预测模型。

BP神经网络虽然在土木工程领域得到了一定的应用,但其实质上是利用梯度下降算法反复迭代寻优,存在容易陷入局部最优、收敛速度慢和梯度消失等问题^[11]。鉴于此原因,本文提出基于自适应

矩估计(adaptive moment estimation, Adam)优化的多层BP神经网络连续刚构桥线形预测模型。

1 基于Adam优化的BP神经网络

在预测桥梁线形的方法中,最小二乘法、卡尔曼滤波法、灰色理论法等方法存在考虑参数少,只能处理线性关系的不足。BP神经网络具有较好的非线性逼近能力,是拟合输入和输出之间非线性映射关系的有效工具^[12]。因此,本文建立多层BP神经网络桥梁线形预测模型,利用已施工梁段数据对模型进行训练,进而对待施工梁段线形进行预测。

1.1 多层BP神经网络结构

多层BP神经网络的基本结构如图1所示。第一层为输入层, $x_1, x_2, \dots, x_i$ 为输入;最后一层为输出层, $y_1, y_2, \dots, y_j$ 为输出;中间层均为隐含层。




图1 多层神经网络基本结构

Fig. 1 Basic structure of a multi-layer neural network

神经节点的结构如图2所示。 $x_1, x_2, \dots, x_m$ 为输入, X 为输入向量, W 为特征的权值, b 为特征的阈值, a 表示神经节点的输出, $f(Z)$ 为激活函数, $f(W^T X + b) = a$ 。




图2 神经节点

Fig. 2 Neural node

神经网络超参数的设定会对模型的收敛速度和误差产生影响。BP神经网络的超参数包括:迭代次数、隐含层层数、每层隐含层包含的节点数、初始的权值和阈值及初始的学习率等^[13]。首先,通过大量试验或参考已有的研究成果选择合适的超参数建立初步的模型;然后,将训练数据输入模型进行训练;最后,通过不断迭代训练和调整超参数直至满足终止条件。本文定义目标函数为:

$$J(\mathbf{W}, \mathbf{b}) = \frac{1}{m} \sqrt{\sum_{i=1}^m (\hat{y}_i(\mathbf{W}, \mathbf{b}) - y_i)^2} \quad (1)$$

式中: m 为训练样本的个数; $\hat{y}_i$ 为神经网络对第 i 个样本的预测值; y_i 为第 i 个样本对应的真实值。

这样神经网络的优化问题就转变成求目标函数 $J(\mathbf{W}, \mathbf{b})$ 的最小值问题。BP神经网络采用梯度下降法调整参数,其迭代公式如下:

$$\mathbf{W}_{t+1} = \mathbf{W}_t - \alpha \frac{\partial J(\mathbf{W}, \mathbf{b})}{\partial \mathbf{W}} \quad (2)$$

$$\mathbf{b}_{t+1} = \mathbf{b}_t - \alpha \frac{\partial J(\mathbf{W}, \mathbf{b})}{\partial \mathbf{b}} \quad (3)$$

式中: α 为学习率(步长); t 为时间步数; $\mathbf{W}_t$ 、 $\mathbf{b}_t$ 为第 t 步时的权值和阈值; $\mathbf{W}_{t+1}$ 、 $\mathbf{b}_{t+1}$ 为调整后的权值和阈值。

梯度下降法实质上是从权值和阈值的初始位置开始,沿目标函数的负梯度方向不断地修正权值和阈值,使目标函数不断逼近最小值。在多层神经网络中,目标函数通常是高维空间中的复杂曲面,采用梯度下降法可能会出现不同的问题,如在梯度平缓的区域权值调整缓慢,在梯度陡峭的区域发生震荡阻碍收敛或收敛到局部最优点。

1.2 Adam优化算法

文献[14]提出了动量梯度下降法(gradient descent with momentum, GDM)。GDM的基本思想是:计算梯度的指数加权移动平均数,利用该值更新权值和阈值,更新的幅度不仅取决于当前的梯度,还取决于过去的梯度。

文献[15]提出了均方根传播法(root mean square propagation, RMSProp)。该优化算法在训练过程中动态地调整学习率,对于较大的梯度给予一个较小的学习率,对于较小的梯度则给予一个较大的学习率,避免在最优点处发生震荡。RMSProp可自适应调整学习率,以加快神经网络的收敛。

Adam是一种自适应调整学习率的方法,它结合了RMSProp和GDM的优点。Adam根据梯度的一

阶矩和二阶矩,自适应地调整不同参数的学习率,使参数的更新幅度不受梯度重新缩放的影响。Adam适用于稀疏的梯度,可自然地执行步长退火的过程^[16]。参数更新计算公式如下:

$$v_t = \beta_1 v_{t-1} + (1 - \beta_1) g_t \quad (4)$$

$$s_t = \beta_2 s_{t-1} + (1 - \beta_2) g_t^2 \quad (5)$$

$$\hat{v}_t = \frac{v_t}{1 - \beta_1^t} \quad (6)$$

$$\hat{s}_t = \frac{s_t}{1 - \beta_2^t} \quad (7)$$

$$\theta_t = \theta_{t-1} - \alpha \frac{\hat{v}_t}{\sqrt{\hat{s}_t} + \varepsilon} \quad (8)$$

式中: v 、 s 分别为梯度的一阶矩、二阶矩; $\hat{v}$ 、 $\hat{s}$ 分别为修正后梯度的一阶矩、二阶矩; θ 为神经网络的参数; g 为梯度; β_1 、 β_2 为超参数(梯度的一阶矩、二阶矩的衰减因子), $0 \leq \beta_1 < 1$, $0 \leq \beta_2 < 1$,取 $\beta_1=0.900$, $\beta_2=0.999$; ε 为一个较小的数,防止分母为0。

2 工程应用

2.1 工程概况

小乌江大桥位于贵州省余庆县,主桥全长400.0 m,上部结构采用变截面箱梁,根部梁高8.5 m,跨中梁高3.3 m,箱梁高度和底板厚度按二次抛物线变化,桥墩为双肢等截面矩形实体薄壁墩。上部结构采用挂篮悬臂施工,单个T构包括32个悬臂节段和2个合龙段,其中主梁0号块节段长13.0 m,1~13号块的每个节段长3.5 m,14~16号块的每个节段长4.0 m,合龙段长2.0 m。

2.2 输入、输出参数的确定

参考文献[17]的研究成果及工程的实际情况,确定对桥梁施工状态(变形)影响较大的参数,并对这些参数进行敏感性分析。具体的参数为:混凝土容重、混凝土弹性模量和管道摩擦系数等。将桥梁单T悬臂施工时主梁的线形作为控制目标,各个参数的变化范围控制在设计值 $\pm 10\%$ 以内,根据各参数对主梁线形的影响程度,确定关键参数。为了准确得到小乌江大桥悬臂施工过程中的挠度值,利用Midas Civil软件建立全桥的有限元模型(图3),并划分施工阶段,得到各施工阶段梁段挠度的计算值。

通过正交试验可得到影响桥梁施工线形的敏感参数^[18],可将其作为神经网络模型的输入。



图 3 小乌江大桥有限元模型

Fig. 3 Finite element model of the Xiaowujiang Bridge

在正交试验中,假设各参数互不影响,每个参数从 0.9 到 1.1 按 0.1 的步长变化,通过模拟计算得到最大悬臂状态下主梁的最大挠度。对参数在不同水平下的最大挠度按以下公式进行极差计算:

$$R_j = \max \{ K_{1j}, K_{2j}, \dots, K_{ij} \} - \min \{ K_{1j}, K_{2j}, \dots, K_{ij} \} \quad (9)$$

$$K_{ij} = \frac{1}{n} \sum_{t=1}^n Y_t \quad (10)$$

式中: R_j 为极差; K_{ij} 为参数 j 在 i 水平下的平均值; n 为参数 j 在 i 水平下的测试数量; Y_t 为第 t 个响应值。

极差值越大表示该参数的敏感性越高,计算结果见表 1。

表 1 不同参数下主梁最大挠度敏感分析

Table 1 Sensitivity analysis of maximum deflection of main beam under different parameters

参数	取值范围	极差
混凝土容重 $\gamma/(\text{kN} \cdot \text{m}^{-3})$	23.4 ~ 28.6	9.3
混凝土弹性模量 E_c/MPa	$3.105 \times 10^4 \sim 3.795 \times 10^4$	4.6
管道摩擦系数	0.225 ~ 0.275	0.5
管道偏差系数	$1.35 \times 10^{-3} \sim 1.65 \times 10^{-3}$	0.1
张拉控制应力 σ/MPa	1 255.5 ~ 1 534.5	5.3
温度 $T/^\circ\text{C}$	-20 ~ 21	1.9

由表 1 可知,混凝土容重、混凝土弹性模量、张拉控制应力和温度对桥梁施工线形的影响较大,另外两个参数对桥梁施工线形的影响较小,可忽略不计。

本文以左幅 25 个已施工梁段的混凝土容重、混凝土弹性模量、张拉控制应力等参数作为神经网络模型的输入,以预测标高与理论标高的差值作为输出,具体的输入输出参数见表 2。

试验数据为 50 组样本,其中 40 组作为训练样本,10 组作为测试样本。

表 2 输入输出参数

Table 2 Input and output parameters

参数	类型
混凝土容重 $\gamma/(\text{kN} \cdot \text{m}^{-3})$	输入
混凝土弹性模量 $E_c/(10^4 \text{ MPa})$	输入
张拉控制应力 σ/MPa	输入
T 构悬臂长度 L/m	输入
测量时的温度 $T/^\circ\text{C}$	输入
预测标高与理论标高差值 y/mm	输出

2.3 输入数据预处理

对输入数据需进行预处理,在去掉输入数据中的奇异值后,按照公式(11)对数据进行归一化。归一化处理旨在消除不同参数间的数量级差距,让不同维度的特征在数值上具有可比性,以加快神经网络收敛的速度。

$$\dot{x}_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (11)$$

式中: x_i 为原始数据; $\dot{x}_i$ 为归一化后的数据; $x_{\min}$ 、 $x_{\max}$ 分别为原始数据中的最大值和最小值。

2.4 神经网络超参数确定及参数初始化

通常神经网络的层数越多,整个网络预测的误差就越小,但是网络过于复杂会导致其泛化能力降低,训练时间和计算成本增加,也有可能出现过拟合。一般情况下,一两层的隐含层已能解决很多问题,对于较复杂的问题,可在防止过拟合的情况下适当增加隐含层的层数。另外,隐含层的节点数过多也是导致过拟合的直接原因。隐含层节点数的确定与输入层、输出层的节点数相关,输入层的节点数由输入数据的特征数确定,输出层是对标高差的预测。因此,本文设置输入层节点数为 5,输出层节点数为 1;通过试验确定隐含层的层数为 2;通过调试模型并结合经验公式^[13],确定第一层隐含层的节点数为 4,第二层隐含层的节点数为 2;设置激活函数为修正线性单元(rectified linear unit, ReLU)。在已知输入层和输出层节点数的情况下,通常利用式(12)大致确定隐含层节点数。

$$H = \sqrt{M + N} + a \quad (12)$$

式中: M 、 H 、 N 分别为输入层、隐含层及输出层的节点数; a 为 1 ~ 10 之间的常数,本文 a 取值 3.55。

考虑到隐含层激活函数为 ReLU,权值的初始化采用 He 初始化^[19],He 初始化可有效地解决隐含层的激活函数为 ReLU 时梯度消失或梯度爆炸的问题。对神经网络的训练,通常选择从一个较大学习率开

始,然后逐渐减小学习率,直至损失函数收敛。本文依次选取0.050、0.010、0.005、0.001作为初始学习率进行试验,不同初始学习率下基于Adam优化的神经网络的损失函数曲线如图4所示。由图4可知,初始学习率越大,损失函数(均方根误差)曲线下降越快,但过大的初始学习率会导致损失函数发生震荡。因此,在保证神经网络预测精度的前提下,同时兼顾神经网络的收敛速度,初始学习率取0.005。




图4 不同学习率下损失函数曲线

Fig. 5 Loss function curves at different learning rates

2.5 Adam优化的BP神经网络性能分析

在初始学习率均为0.005的条件下,利用Python中time模块的perf_counter()函数进行计算,对比梯度下降(gradient descent, GD)、GDM、RMSProp和Adam四种优化算法的性能。不同优化算法下的损失函数曲线如图5所示。GD、GDM、RMSProp及Adam四种优化算法下BP神经网络收敛时的运算耗时分别为2.769、1.933、1.416、0.518 s,Adam优化算法下BP神经网络收敛速度最快。






图5 不同优化算法下损失函数曲线

Fig. 5 Loss function curves for different optimization algorithms


利用测试集对训练好的神经网络的性能进行评价,四种优化算法下预测值与实测值的对比如图6所示。由图6可知,GD优化算法下的预测曲线与实测曲线的拟合度一般,其他三种算法下的预测曲线大致分布在实测曲线附近,拟合效果更好。




(a) GD



(b) GDM



(c) RMSProp



(d) Adam

图6 四种优化算法下预测值与实测值对比


Fig. 6 Comparison of measured and predicted values

为定量地评价四种优化算法的性能,用均方根误差(root mean squared error, RMSE)、平均绝对误差(mean absolute error, MAE)、决定系数 R^2 对基于四种优化算法的 BP 神经网络的预测效果进行评价,预测误差见表 3。预测值与实测值的回归分析结果如图 7 所示。


RMSE 与 MAE 越小, R^2 越接近于 1,表明预测值与实测值越接近,即预测精度越高。由表 3 可知,Adam 算法下均方根误差和平均绝对误差最小,决定系数最接近 1,预测效果最佳。因此,不论在收敛速度上还是预测精度上,Adam 均为四种算法中的最佳优化算法。

表 3 预测误差
Table 3 Prediction errors

优化算法	RMSE/mm	MAE/mm	R^2
GD	7.957	5.850	0.948
GDM	7.406	5.107	0.974
RMSProp	7.468	5.144	0.972
Adam	7.386	5.031	0.984



(c) RMSProp



(d) Adam

图 7 预测值与实测值回归分析

Fig. 7 Regression analysis of predicted and measured values


3 结论

本文以贵州小乌江大桥为工程背景,探究基于神经网络的施工线形预测方法在大跨度连续刚构桥上的应用,主要结论如下:


1) 传统 BP 神经网络在预测连续刚构桥施工线形时,存在收敛速度慢、误差较大等缺点。优化算法 Adam 结合了 GDM 算法和 RMSProp 算法的优点。本文提出的基于 Adam 优化的 BP 神经网络施工线形预测方法,实现了学习率的自适应,在后续的预测工作中运用该方法取得了较好的效果。

2) 采用正交试验确定了对桥梁施工线形影响较大的参数,分别是混凝土容重、混凝土弹性模量、张拉控制应力和温度。管道摩擦系数和管道偏差系数影响很小,可忽略不计。在大跨度连续刚构桥悬臂浇筑过程中应注意这些参数对施工线形的影响。

3) GD、GDM、RMSProp 及 Adam 四种优化算法下 BP 神经网络收敛时的运算耗时分别为 2.769、1.933、1.416、0.518 s, Adam 优化算法下 BP 神经网络收敛速度最快。在预测精度上, Adam 算法下均方根误差和平均绝对误差最小,决定系数最接近 1,预



(a) GD



(b) GDM

测效果最佳。综上所述,Adam优化BP神经网络的连续刚构桥施工线形预测模型具有较好的实用性和较高的可靠性。

参考文献(References):

- [1] WAN H. Research on construction control of long-span prestressed concrete continuous girder bridge [J]. Advanced Materials Research, 2014, 1030-1032: 843-846. DOI: 10.4028/www.scientific.net/amr.1030-1032.843.
- [2] 周瑞刚. 大跨度连续刚构桥施工控制研究[D]. 西安: 长安大学, 2018.
ZHOU Ruigang. Study on construction control of long-span continuous rigid frame bridge[D]. Xi'an: Chang'an University, 2018.
- [3] TAN Z, THAMBIRATNAM D P, CHAN T H T, et al. Damage detection in steel-concrete composite bridge using vibration characteristics and artificial neural network [J]. Structure and Infrastructure Engineering, 2020, 16 (9) : 1247-1261. DOI: 10.1080/15732479.2019.1696378.
- [4] 孙娅楠. 梯度下降法在机器学习中的应用[D]. 成都: 西南交通大学, 2018.
SUN Yanan. Application of gradient descent method in machine learning [D]. Chengdu: Southwest Jiaotong University, 2018.
- [5] 徐学松. BP神经网络在大跨度连续梁桥中的预测作用[J]. 九江学院学报(自然科学版), 2016, 31(3): 30-34, 43. DOI: 10.19717/j.cnki.jjun.2016.03.007.
XU Xuesong. The construction linear prediction on long-span continuous girder based on the BP neural network [J]. Journal of Jiujiang University (Natural Science Edition), 2016, 31 (3) : 30-34, 43. DOI: 10.19717/j.cnki.jjun.2016.03.007.
- [6] LU W, TENG J, CUI Y. Damage identification for large span structure based on multiscale inputs to artificial neural networks[J]. The Scientific World Journal, 2014, 2014: 540806. DOI: 10.1155/2014/540806.
- [7] 鄢秉红. 基于BP神经网络的既有桥墩变位分析方法研究[J]. 公路, 2020, 65(3): 148-153.
YAN Binghong. Research on displacement analysis method of existing pier based on BP neural network[J]. Highway, 2020, 65(3): 148-153.
- [8] 录哲元, 王小明, 赵宝俊, 等. 基于MEC-BP代理模型的大跨径波形钢腹板连续刚构桥施工线形预测[J]. 长安大学学报(自然科学版), 2021, 41(6): 53-62. DOI: 10.19721/j.cnki.1671-8879.2021.06.006.
LU Zheyuan, WANG Xiaoming, ZHAO Baojun, et al. Prediction of construction alignment of long span continuous rigid frame bridge with corrugated steel webs based on MEC-BP surrogate model [J]. Journal of Chang'an University (Natural Science Edition), 2021, 41 (6) : 53-62. DOI: 10.19721/j.cnki.1671-8879.2021.06.006.
- [9] 石娟, 常丁懿, 郑鹏. 基于BP神经网络的建筑工人不安全行为预警模型[J]. 中国安全科学学报, 2022, 32 (1) : 27-33. DOI: 10.16265/j.cnki.issn1003-3033.2022.01.004.
SHI Juan, CHANG Dingyi, ZHENG Peng. An early warning model of unsafe behaviors of construction workers based on BP neural network [J]. China Safety Science Journal, 2022, 32 (1) : 27-33. DOI: 10.16265/j.cnki.issn1003-3033.2022.01.004.
- [10] 胡庆国, 蔡孟龙, 何忠明. 基于GA-BP神经网络的综合管廊投资估算研究[J]. 长沙理工大学学报(自然科学版), 2020, 17 (2) : 68-74. DOI: 10.3969/j.issn.1672-9331.2020.02.011.
HU Qingguo, CAI Menglong, HE Zhongming. Research on investment estimation of comprehensive pipe gallery based on GA-BP neural network [J]. Journal of Changsha University of Science & Technology (Natural Science), 2020, 17 (2) : 68-74. DOI: 10.3969/j.issn.1672-9331.2020.02.011.
- [11] 董洲洋, 徐卫明, 庄昊, 等. 深度学习的BP神经网络在GNSS水准拟合中的应用[J]. 海洋测绘, 2019, 39(5): 26-29. DOI: 10.3969/j.issn.1671-3044.2019.05.007.
DONG Zhouyang, XU Weiming, ZHUANG Hao, et al. Application of BP neural network with deep learning in GNSS level fitting [J]. Hydrographic Surveying and Charting, 2019, 39 (5) : 26-29. DOI: 10.3969/j.issn.1671-3044.2019.05.007.
- [12] 周双喜, 邓芳明, 韩震, 等. 基于优化极限学习机的大跨径连续桥梁施工线形预测[J]. 铁道学报, 2019, 41 (3) : 134-140. DOI: 10.3969/j.issn.1001-8360.2019.03.018.
ZHOU Shuangxi, DENG Fangming, HAN Zhen, et al. The construction linear prediction of long-span continuous girder based on improved extreme learning machine [J]. Journal of the China Railway Society, 2019, 41 (3) : 134-140. DOI: 10.3969/j.issn.1001-8360.2019.03.018.
- [13] 高鹏毅, 陈传波, 秦升, 等. 一种新的基于Agent的神经网络隐层节点数的优化算法[J]. 计算机工程与科学, 2010, 32(5): 30-33. DOI: 10.3969/j.issn.1007130X.2010.
GAO Pengyi, CHEN Chuanbo, QIN Sheng, et al. A novel algorithm to optimize the hidden layer of neural networks [J]. Computer Engineering & Science, 2010, 32(5): 30-33. DOI: 10.3969/j.issn.1007130X.2010.
- [14] HORNIK K, STINCHCOMBE M, WHITE H. Multilayer feedforward networks are universal approximators [J]. Neural Networks, 1989, 2(5): 359-366. DOI: 10.1016/0893-6080(89)90020-8.
- [15] Rakshitha K P, Naveen N C. Op-RMSprop (optimized-root mean square propagation) classification for prediction of polycystic ovary syndrome (PCOS) using hybrid machine learning technique [J]. International (下转第139页)

- [12] 余腾,胡伍生,吴杰,等. 基于小波阈值去噪与EMD分解方法提取润扬大桥振动信息[J]. 振动与冲击, 2019, 38(12):264-270. DOI: 10.13465/j.cnki.jvs.2019.12.038.
- YU Teng, HU Wusheng, WU Jie, et al. Extraction of Runyang bridge vibration information based on a fusion method of wavelet threshold denoising and EMD decomposition [J]. Journal of Vibration and Shock, 2019, 38 (12) : 264-270. DOI: 10.13465/j. cnki. jv s.2019.12.038.
- [13] ZHENG K, LUO J F, ZHANG Y, et al. Incipient fault detection of rolling bearing using maximum autocorrelation impulse harmonic to noise deconvolution and parameter optimized fast EEMD [J]. ISA Transactions, 2019, 89: 256-271. DOI: 10.1016/j.isatra. 2018.12.020.
- [14] SUN W, LIU M H. Wind speed forecasting using FEEMD echo state networks with RELM in Hebei, China [J]. Energy Conversion and Management, 2016, 114: 197-208. DOI: 10.1016/j.enconman.2016.02.022.
- [15] DONOHO D L. De-noising by soft-thresholding [J]. IEEE Transactions on Information Theory, 1995, 41(3): 613-627. DOI: 10.1109/18.382009.
- [16] PENG K, GUO H Y, SHANG X Y. EEMD and multiscale PCA-based signal denoising method and its application to seismic P-phase arrival picking [J]. Sensors, 2021, 21(16): 5271. DOI: 10.3390/s21165271.
- [17] 肖凯. 基于刚度相似原理的斜拉桥缩尺模型的设计研究[D]. 武汉: 武汉理工大学, 2012.
- XIAO Kai. Design and research on scale model of cable-stayed bridge based on stiffness similarity principle[D]. Wuhan: Wuhan University of Technology, 2012.
- [18] 蒋田勇, 喻晨宇, 黄可, 等. 基于AO算法优化VMD参数联合小波阈值的桥梁信号去噪方法[J]. 中国公路学报, 2023, 36(7): 158-168. DOI: 10.19721/j.cnki.1001-7372.2023.07.013.
- JIANG Tianyong, YU Chenyu, HUANG Ke, et al. Bridge signal denoising method based on AO algorithm to optimize VMD parameters combined with wavelet threshold [J]. China Journal of Highway and Transport, 2023, 36 (7) : 158-168. DOI: 10.19721/j. cnki. 1001-7372.2023.07.013.
- [19] 陈强, 黄声享, 王伟. 小波去噪效果评价的另一指标[J]. 测绘信息与工程, 2008, 33(5): 13-14. DOI: 10.3969/j.issn.1007-3817.2007.05.019.
- CHEN Qiang, HUANG Shengxiang, WANG Wei. An evaluation indicator of wavelet denoising [J]. Journal of Geomatics, 2008, 33 (5) : 13-14. DOI: 10.3969/j. issn.1007-3817.2007.05.019.
- [20] 石志远, 徐卫明, 周波, 等. 基于经验模态分解和小波阈值的自适应降噪方法[J]. 海洋测绘, 2021, 41(6): 54-57, 72.
- SHI Zhiyuan, XU Weiming, ZHOU Bo, et al. A self-adapting denoising method based on empirical mode decomposition and wavelet threshold [J]. Hydrographic Surveying and Charting, 2021, 41(6): 54-57, 72.
- [21] 吕立蕾. 多光谱激光雷达小波去噪效果评价体系[J]. 海洋测绘, 2016, 36(4): 72-75. DOI: 10.3969/j. issn.1671-3044.2016.04.018.
- LYU Lilei. Evaluation system of wavelet de-noising effect for multispectral LiDAR [J]. Hydrographic Surveying and Charting, 2016, 36 (4) : 72-75. DOI: 10.3969/j.issn.1671-3044.2016.04.018.
- [22] 蒋林锡, 吴伟, 秦少敏. 混行交通流下单交叉口车道布设和信号配时[J]. 交通科学与工程, 2023, 39(5): 139-148. DOI: 10.16544/j. cnki. cn43-1494/u. 2022031623101997.
- JIANG Linxi, WU Wei, QIN Shaomin. The method of lane layout and signal timing at a single intersection under mixed traffic flow [J]. Journal of Transport Science and Engineering, 2023, 39 (5) : 139-148. DOI: 10.16544/j.cnki.cn43-1494/u.2022031623101997.

(责任编辑:薛仪)

(上接第104页)

- Journal of Advanced Computer Science and Applications, 2022, 13(6):53-78.
- [16] KINGMA D P, BA J L. Adam: a method for stochastic optimization [C]//3rd International Conference on Learning Representations, ICLR 2015-Conference Track Proceedings. Washington DC: ICLR, 2015: 1-15. DOI: 10.48550/arXiv.1412.6980.
- [17] 周瑞高. 大跨度连续刚构桥施工监控及误差分析[D]. 济南: 山东大学, 2011.
- ZHOU Ruigao. Construction monitoring and error analysis of long-span continuous rigid frame bridge [D]. Jinan: Shandong University, 2011.
- [18] 宋宽彬, 王笑风, 褚付克, 等. 基于正交试验的胶粉改性沥青配方优化[J]. 交通科学与工程, 2021, 37(4): 14-19. DOI: 10.16544/j.cnki.cn43-1494/u.2021.04.014.
- SONG Kuanbin, WANG Xiaofeng, CHU Fuke, et al. Formulation optimization of crumb rubber modified asphalt based on orthogonal test [J]. Journal of Transport Science and Engineering, 2021, 37 (4) : 14-19. DOI: 10.16544/j.cnki.cn43-1494/u.2021.04.014.
- [19] HE K, ZHANG X, REN S, et al. Delving deep into rectifiers: surpassing human-level performance on ImageNet classification [C]//2015 IEEE International Conference on Computer Vision (ICCV). Santiago: IEEE, 2015: 1026-1034. DOI: 10.1109/ICCV.2015.123.

(责任编辑:熊怡)