

DOI: 10.11835/j.issn.2096-6717.2023.154



开放科学(资源服务)标识码 OSID:



基于深度学习的带减振器斜拉索索力 智能识别方法

张玉平¹, 姜嘉萍¹, 吴健², 储永豪¹, 唐鑫¹

(1. 长沙理工大学土木工程学院, 长沙 410114; 2. 中交路桥华南工程有限公司, 广东 中山 528403)

摘要:为解决实际工程中带减振器斜拉索索力测试难度大、精度低的问题,提出一种基于IWPA-LKCNN-LSTM的带减振器斜拉索索力智能识别方法。对实际工程中的带减振器斜拉索开展动态响应试验,基于试验数据开发了一种可以智能化识别带减振器斜拉索索力的深度学习模型。模型以斜拉索索力、长度、线密度、频率和阶次作为特征输入,首先采用改进狼群算法(improved wolf pack algorithm, IWPA)对LSTM神经网络中的超参数进行自适应寻优,然后利用LKCNN-LSTM (large convolutional kernel convolutional neural network-long and short-term memory)进行训练,从而实现带减振器斜拉索索力的智能识别。训练后的网络在测试集上识别的索力值与实际索力值之间的平均误差为2.024%,均方误差值为0.0994%,决定系数为0.9806,索力误差均小于5%。与索力计算公式和其他机器学习算法对比结果表明,该方法可实现带减振器斜拉索索力的智能化精准识别,拥有广阔的应用前景。

关键词:斜拉索;索力识别;减振器;深度学习;改进狼群算法

中图分类号:U446.1 文献标志码:A 文章编号:2096-6717(2026)02-0163-09

Intelligent identification of cable tension with damper based on deep learning

ZHANG Yuping¹, JIANG Jiaping¹, WU Jian², CHU Yonghao¹, TANG Xin¹

(1. School of Civil Engineering, Changsha University of Science and Technology, Changsha 410114, P. R. China;

2. Road and Bridge South China Engineering Co., Ltd., Zhongshan 528403, Guangdong, P. R. China)

Abstract: In order to address the challenges posed by the complexity and imprecision inherent in assessing cable tension with a damper in practical engineering, an intelligent identification method of the cable tension with damper based on IWPA-LKCNN-LSTM is proposed. The dynamic response test of the cable with a damper in practical engineering is carried out. Based on the data obtained from the test, a deep learning model that can intelligently identify the cable tension with a damper is developed. The model takes the cable tension, length,

收稿日期:2023-10-18

基金项目:国家重点基础研究发展计划(973计划)(2015CB057702);国家自然科学基金(52078059)

作者简介:张玉平(1976-),男,博士,副教授,主要从事桥梁结构研究,E-mail:zyp5032@163.com.

姜嘉萍(通信作者),男,研究员,E-mail:1145358526@qq.com.

Received: 2023-10-18

Foundation items: National Basic Research Program of China (973 Program) (No. 2015CB057702); National Natural Science Foundation of China (No. 52078059)

Author brief: ZHANG Yuping (1976-), PhD, associate professor, main research interest: bridge structure, E-mail: zyp5032@163.com.

JIANG Jiaping (corresponding author), researcher, E-mail: 1145358526@qq.com.

line density, frequency, and order as the feature inputs. First, the hyperparameters in the LSTM neural network are adaptively optimized by using the IWPA. Then LKCNN-LSTM is used for training. The intelligent recognition of the cable tension with a damper is realized. The average error between the recognized cable tension value on the test set and the actual cable tension value is a mere 2.024%, the mean square error value is only 0.0994%, the coefficient of determination is 0.9806, and the cable tension error is less than 5%. In conclusion, a comparison is made with the formula of cable tension calculation and other machine learning algorithms. The results show that this method can realize the intelligent and accurate recognition of the cable tension with a damper, signifying a broad spectrum of potential applications.

Keywords: stay cable; tension identification; damper; deep learning; improved wolf pack algorithm (IWPA)

拉索索力测量识别的准确性对斜拉桥施工和运营阶段的安全监测具有重要意义。现有的索力测试方法主要有压力表测定法、压力传感器测定法、频率法、磁通量法等^[1],其中,频率法以其方便快捷的特点在实际工程中得到了广泛应用。然而,其精度受到拉索垂度、抗弯刚度、边界条件和减振器的存在等因素的影响,这些因素限制了它的应用。

近年来,研究人员采用参数灵敏度法(PSM)来估计索张力。Kim等^[2]采用有限元法求解考虑垂度和抗弯刚度影响的索的动力特性,并利用参数灵敏度法识别索的张力、抗弯刚度和轴向刚度。Wang等^[3]采用参数灵敏度法研究了多点支撑外预应力索的张力识别问题。陈彦江等^[4]分析了吊杆频率对各参数的敏感程度,基于参数灵敏度的迭代算法可同时计算出吊杆索力值、抗弯刚度和计算长度。Ma^[5]提出了一种利用矩阵特征值导数识别索系统参数的改进参数灵敏度方法。Noh等^[6]认为,参数灵敏度迭代算法可能得到不稳定甚至发散的索力结果,提出了一种结合灵敏度更新法和先进的混合微遗传算法的斜拉结构张力检测方法。针对频率信息不足的问题,袁佩等^[7]和Xie等^[8]提出了一种附加质量法,利用遗传算法反求拱桥吊杆张力。Haji Agha Mohammad Zarbaf等^[9]将遗传算法与粒子群优化算法相结合,对索力进行识别,通过数值模拟和实验结果验证了该方法的准确性,并提出了一种基于神经网络的索力估计框架^[10]。Zhan等^[11]采用贝叶斯统计方法和马尔可夫链蒙特卡罗方法识别吊杆的索张力和频率阶。周银等^[12]提出了一种由实测索形直接估计索力的新方法,基于悬链线公式推导了由实测索形点集精确估计拉索张力的计算公式。肖军等^[13]基于梁结构中的行波传播特性,通过3个测点的频域响应,利用最小二乘法拟合得到波分量系数,再以拟合残差最小为目标进行了拉索索力和抗弯刚度的识别。

此外,在实际工程中,斜拉索常常面临来自风或桥面振动等外界因素的激励,从而引发多种形式的振动。为了抑制拉索的不利振动,常常在拉索两

端安装减振器,给采用频率法准确确定拉索索力带来一定困难。方志等^[14]、Li等^[15]、王朝华等^[16]、马林等^[17]、柯红军等^[18]、黄江明等^[19]、黄竞锋^[20]研究了减振器对拉索自振频率的影响,提出了等效长度法来计算安装减振器之后的合理计算长度。以能量法为理论基础,王红平^[21]、陈庆志等^[22]、刘陈韬^[23]推导了带减振器斜拉索索力与频率的计算公式,经简化后,公式的物理意义明确,包含抗弯刚度、垂度、减振器位置与减振器刚度等必要的参数。Aiko等^[24]使用张紧的伯努利-欧拉梁对拉索进行建模,推导了拉索的固有频率与拉索的拉伸和弯曲刚度以及阻尼器参数之间的理论方程,后经实验和工程实际验证。

综合研究现状并结合工程实践来看,对于安装减振器的斜拉索,由于各种因素的耦合影响,采用现有频率法识别索力的误差较大。同时,减振器的存在对斜拉索的振动产生了一定影响,等效长度法、能量法等对不同工程应用情况下带减振器斜拉索索力识别的泛化能力较差,精度不理想。然而,在大跨径斜拉桥上减振器的应用非常普遍,因此,有必要采取新的思路对带减振器的斜拉索索力与频率的关系进行深入研究。为解决上述问题,对实际工程中的斜拉索开展动态响应测试试验,获取斜拉索在安装减振器前后的动态响应数据。以采集到的斜拉索索力、长度、线密度、频率和阶次作为特征输入,编译并训练了多变量的IWPA-LKCNN-LSTM深度学习网络模型。最后对该智能算法的索力识别效果进行评估和对比。

1 理论基础

1.1 斜拉索振动理论

1.1.1 基本方程

当不考虑垂度效应时,张紧的斜拉索在无阻尼状态下的自由振动可以用式(1)所示方程来描述。

$$EI \frac{\partial^4 u}{\partial x^4} - T \frac{\partial^2 u}{\partial x^2} + m \frac{\partial^2 u}{\partial t^2} = 0 \quad (1)$$

式中: EI 为斜拉索的抗弯刚度; T 为斜拉索索力,假

定其为常量; $u(x,t)$ 为任一时刻 t 斜拉索上各点的横向位移; m 为斜拉索的线密度。

采用分离变量法,设其解为

$$u(x,t) = \varphi(x) \cdot y(t) \quad (2)$$

可解得

$$y(t) = A \sin(\omega t) + B \cos(\omega t) \quad (3)$$

$$\varphi(x) = C_1 \sin(\alpha x) + C_2 \cos(\alpha x) + C_3 \sinh(\beta x) + C_4 \cosh(\beta x) \quad (4)$$

式中: ω 为斜拉索的自振圆频率; $\alpha = \sqrt{\frac{\lambda^4}{4} + a^4 - \frac{\lambda^2}{2}}$;

$$\beta = \sqrt{\frac{\lambda^4}{4} + a^4 + \frac{\lambda^2}{2}}$$

$a^4 = m\omega^2/EI$; $\lambda^2 = T/EI$; A 、 B 、 $C_1 \sim C_4$ 为待定系数,其具体数值可根据边界条件和初始状态确定。

相应的频率方程可由振型函数式(4)和边界条件确定。

1.1.2 弦的振动

当斜拉索的抗弯刚度 EI 很小以至于可以忽略不计,张拉的斜拉索即可视为理想的弦,此时相应的振动方程及振型函数分别为^[13]

$$-T \frac{\partial^2 u}{\partial x^2} + m \frac{\partial^2 u}{\partial t^2} = 0 \quad (5)$$

$$\varphi(x) = C_1 \sin(\alpha x) + C_2 \cos(\alpha x) \quad (6)$$

式中: $\alpha = m\omega^2/T$,根据边界条件,由式(6)可推出相应的频率方程。

当弦两端固定时,有边界条件

$$\varphi(x)|_{x=0} = 0, \varphi(x)|_{x=l} = 0 \quad (7)$$

联合式(6)可得

$$T = 4ml^2 \cdot f_n^2 / n^2 \quad (8)$$

式(8)能满足大部分工程要求,但基于弦理论的振动频率法忽略了拉索垂度、抗弯刚度、边界条件和减振器等的影响。目前,为了抑制拉索的不利振动,越来越多的大跨度斜拉桥采用在拉索两端安装减振器的方法来提高拉索体系的阻尼比,采用式(8)计算安装减振器的斜拉索索力将产生较大误差,学者们通过能量法推导了带减振器斜拉索索力的计算公式,但计算复杂,适用度不高。采用等效长度法得出的经验公式并不能很好地进行解析,精度不高。而深度学习具有极强的非线性拟合能力,十分适合分析带减振器斜拉索索力识别这种复杂的特征映射。

1.2 算法基本理论

1.2.1 狼群算法(WPA)

取狼群算法(wolf pack algorithm, WPA)的设计

方法是基于人工狼主体自上而下,同时采用了基于职责分工的协作式搜索路径结构。如图1所示,整个狼群捕猎的全过程是通过狼群个体对猎物气味、环境信息的探知、人工狼之间相互信息的共享和交互以及人工狼基于自身职责的个体行为决策来实现的^[25]。

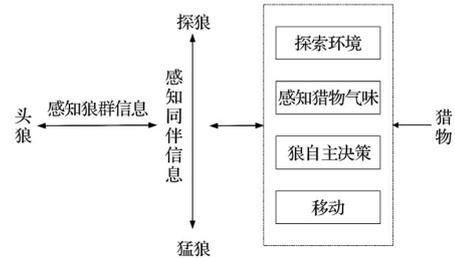


图1 WPA框架

Fig. 1 Framework of WPA

狼群共分为3种:起指挥作用的头狼;在环境四周搜寻猎物的探狼;感应头狼呼唤、奔向猎物的猛狼。

狼群的整个捕猎行动可以概括为3种智能行为:游走行为、召唤行为和围攻行为。在初始状态下,具有最优目标函数值的人工狼即为头狼。在迭代过程中,若有猛狼对发现猎物的适应度比原头狼更高,则会取代原来的头狼,指挥其他狼向猎物方向行动。定义人工狼所能感知到的猎物气味浓度为 $Y = f(X)$ 。

游走行为:探狼搜寻猎物,选择气味最浓并且大于当前位置气味浓度 Y_{i0} 的方向前进一步。

$$x_{id}^p = x_{id} + \sin(2\pi \times p/h) \times s_a^d \quad (9)$$

式中: s_a^d 为游走步长; h 为游走方向; $p = 1, 2 \dots h$ 。

召唤行为:头狼通过嚎叫发起召唤行为,引导周围的猛狼以较大的奔袭步长逼近头狼所在位置。

$$x_{id}^{k+1} = x_{id}^k + s_c^d \cdot \frac{(g_d^k - x_{id}^k)}{|g_d^k - x_{id}^k|} \quad (10)$$

式中: g_d^k 为第 k 代群体头狼在第 d 维空间的位置; $step_c^d$ 为奔袭步长。

围攻行为:猛狼和探狼联合对猎物进行围攻,以捕获猎物。

$$x_{id}^{k+1} = x_{id}^k + \lambda \cdot s_c^d \cdot |G_d^k - x_{id}^k| \quad (11)$$

式中: G_d^k 为第 k 代群体中猎物在第 d 维空间的位置; s_c^d 为攻击步长; λ 为 $[-1, 1]$ 之间均匀分布的随机数。

1.2.2 长短期记忆(LSTM)神经网络

长短期记忆(long and short-term memory, LSTM)神经网络是一种用于处理可变长序列的神经网络,由Hochreiter等^[26]提出,LSTM框架如图2所示。

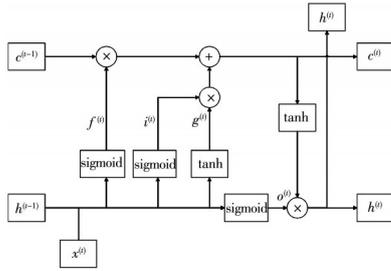


图 2 LSTM 框架

Fig. 2 Framework of LSTM

如图 2 所示,首先通过上一时刻的输出 $h^{(t-1)}$ 和当前时刻的输入 $x^{(t)}$ 一起经过 sigmoid 转换,获得遗忘门 $f^{(t)}$,然后将其作用于上一时刻的记忆信息 $c^{(t-1)}$,其数学表达式为

$$f^{(t)} = \text{sigmoid}(W_f[x^{(t)}, h^{(t-1)}] + b_f) \quad (12)$$

式中: W_f 为遗忘门的权重参数; b_f 为遗忘门的偏置参数。

同时, $x^{(t)}$ 与 $h^{(t-1)}$ 分别经过 sigmoid 和 tanh 转换后,获得输入门 $i^{(t)}$ 和向量 $g^{(t)}$,将 $i^{(t)}$ 作用于 $g^{(t)}$,得到的结果向后传递,其数学表达式为

$$i^{(t)} = \text{sigmoid}(W_i[x^{(t)}, h^{(t-1)}] + b_i) \quad (13)$$

$$g^{(t)} = \text{tanh}(W_g[x^{(t)}, h^{(t-1)}] + b_g) \quad (14)$$

式中: W_i 和 W_g 分别为输入门和向量的权重参数, b_i 和 b_g 为其偏置参数。

然后,将遗忘门 $f^{(t)}$ 处理过的上一时刻记忆信息 $c^{(t-1)}$ 和输入门 $i^{(t)}$ 处理过的向量 $g^{(t)}$ 进行求和,获得当前时刻的记忆信息 $c^{(t)}$,其数学表达式为

$$c^{(t)} = f^{(t)} \times c^{(t-1)} + i^{(t)} \times g^{(t)} \quad (15)$$

最后 $x^{(t)}$ 与 $h^{(t-1)}$ 经过 sigmoid 转换获得输出门 $o^{(t)}$,将其作用在经过 tanh 转换的记忆信息 $c^{(t)}$ 上,获得当前时刻的输出 $h^{(t)}$,同时, $h^{(t)}$ 继续向后传递,作为下一时刻的输入,其数学表达式为

$$o^{(t)} = \text{sigmoid}(W_o[x^{(t)}, h^{(t-1)}] + b_o) \quad (16)$$

$$h^{(t)} = o^{(t)} \cdot \text{tanh}(c^{(t)}) \quad (17)$$

式中: W_o 为输出门的权重参数; b_o 为输出门的偏置函数。

2 拉索动力响应试验

2.1 拉索参数

考虑到斜拉索不同长度和线密度等因素对拉索动态响应的影响,试验对象采用某桥所有斜拉索,参数信息如表 1 所示。

2.2 试验装置

动态响应试验采用频率法进行索力量测,使用的仪器为 2 台 JMM-268 动测仪。

表 1 某桥斜拉索参数

Table 1 Parameters of the stay cables of a bridge

斜拉索 编号	长度 L/m	线密度 $W/(kg/m)$	斜拉索 编号	长度 L/m	线密度 $W/(kg/m)$
B24	229.969	96.1	Z1	78.596	60.0
B23	222.865	96.1	Z2	85.229	48.7
B22	215.790	96.1	Z3	92.307	48.7
B21	208.746	90.6	Z4	99.630	48.7
B20	201.734	90.6	Z5	107.563	48.7
B19	194.760	90.6	Z6	115.842	48.7
B18	187.827	90.6	Z7	124.470	48.7
B17	180.940	90.6	Z8	133.425	60.0
B16	173.926	81.2	Z9	142.679	60.0
B15	167.011	81.2	Z10	152.117	60.0
B14	160.167	81.2	Z11	161.734	60.0
B13	153.402	81.2	Z12	171.500	60.0
B12	146.504	81.2	Z13	181.432	67.8
B11	139.734	81.2	Z14	191.281	67.8
B10	133.075	67.8	Z15	201.229	67.8
B9	126.543	67.8	Z16	211.263	67.8
B8	120.132	67.8	Z17	221.411	67.8
B7	113.922	67.8	Z18	231.583	81.2
B6	107.916	67.8	Z19	241.812	81.2
B5	102.106	60.0	Z20	252.089	81.2
B4	96.390	60.0	Z21	262.411	81.2
B3	90.994	60.0	Z22	272.772	81.2
B2	85.457	60.0	Z23	283.168	90.6
B1	79.866	67.8	Z24	293.595	90.6

2.3 试验过程

将传感器布置在拉索梁端距减振器 20 cm 处,使用橡胶锤在传感器附近区域随机施加 5 次人工锤击激励,3 s 后开始采集拉索时域振动信号,采样频率为 20~40 Hz,然后通过 JMM-286 动测仪采集记录拉索频率、阶次以及索力。每根拉索在减振器安装之前进行 3 次数据采集,安装减振器后在相同部位再进行 3 次采集,以减小误差。

记录某桥 96 对斜拉索安装减振器前后的动态响应数据,通过安装减振器前的拉索自振频率计算出拉索的实际索力,结合安装减振器后拉索的频率、线密度和长度,共同作为输入 IWPA-LKCNN-LSTM 深度学习模型的参数。

3 索力智能识别模型

3.1 模型搭建

原始狼群算法里的狼群移动方法共有 3 种,但都为固定值,这样会造成在算法最开始时减慢收敛的速度,在末尾时降低狼群搜索的精度。也在一定程度上造成无法获取最优解,只能得到相对较好的解。因此,参考文献[27],使用自适应步长方法,对

原有狼群算法进行改进,如式(18)所示。

$$\text{step} = \text{rand} \times \|x_i - X_{\text{lead}}\|_2 \quad (18)$$

每次移动都由目前自身位置与领头狼位置来确定。距离头狼位置远的狼移动步长相应就会增长,使得收敛速度提高,以减少不必要的资源浪费。距离头狼位置近的狼移动步长相应就会减小,以增加搜索的精细度。

原始的 CNN-LSTM 算法虽然结合了 CNN 与 LSTM 的优点,利用 CNN 提取特征,利用 LSTM 学习,时间序列上的长期依赖关系能够更好地处理时序数据,但依然存在一定缺陷。Ding 等^[28]指出,尽管目前模型都使用小而深的模型结构设计,但使用小而大卷积核的设计效果要优于目前主流设计。故针对原始 CNN-LSTM,将 CNN 的卷积核替换为 13×13 的大卷积核。

基于上述基础理论,提出一种深度学习模型 IWPA-LKCNN-LSTM,结构如图 3 所示。

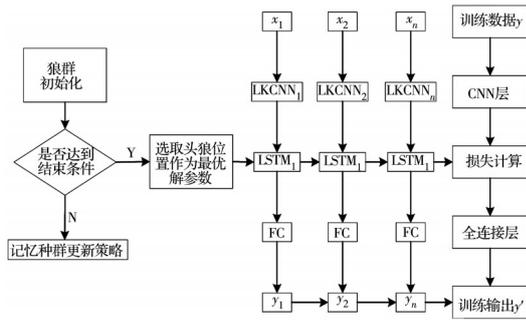


图 3 IWPA-LKCNN-LSTM 深度学习模型框架图

Fig. 3 Framework of the IWPA-LKCNN-LSTM deep learning model

首先通过 IWPA 对 LSTM 神经网络中的超参数进行自适应寻优,然后利用 LKCNN-LSTM 进行训练。其中通过 LKCNN 进行输入特征提取,传递至 LSTM 模型来进行训练。

深度学习模型的训练步骤主要包括:

- 1) 将划分好的数据进行归一化处理;
- 2) 狼群种群初始化,将狼群位置设置在参数范围内;
- 3) 判断是否得到最优解,若达到最优解则赋值给 LSTM;
- 4) 将归一后的训练数据输入 LKCNN-LSTM 进行训练和验证;
- 5) 训练过程中采用交叉熵作为损失函数;
- 6) 重复步骤 4) 和 5),直到达到设置的训练总轮数时停止训练。

在 IWPA-LKCNN-LSTM 网络训练开始之前,经过多次调试,设定超参数的预设值。其中,学习率 α 被设定为 0.000 1,训练数据按照每 5 组数据为

一个 batch 进行分割后输入模型;在训练过程中,通过观察损失函数的下降趋势来确定样本训练的总轮数。经过多次尝试和比较发现,当训练轮数 (Epoch) 达到 1 000 时,损失函数的下降趋势趋于稳定。此外,设置随机抑制的隐藏神经节点比例 (Dropout) 为 0.5,以防止模型过拟合。基于弦理论的振动频率法是实际工程中索力测试最常用的方法,故模型的输入参数为拉索长度、线密度、频率和阶次等频率法所需的参数,方便后续工程广泛应用。模型训练环境使用的是 Windows 10 22H2 计算机,CPU 为 AMD Ryzen 5600,GPU 为 GeForce RTX 3060(12 GB),内存为 32 GB。Python 3.8+ CUDA 11.0+TensorFlow 2.4.0 作为环境设置。

3.2 索力识别结果

基于深度学习的索力识别网络在经过 1 000 轮次的深度学习后,其训练集的损失下降曲线如图 4 所示。

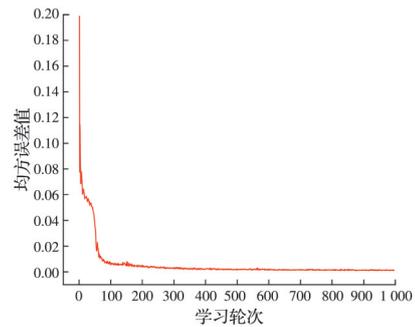


图 4 训练集损失曲线

Fig. 4 Loss curve of the training set

从图 4 可以看出,随着学习轮次的增加,深度学习模型输出值与真实值之间的均方误差也迅速降低,在 10 轮次的学习后下降至 0.06 左右,表明深度学习网络模型对数据特征的提取较为顺利。随后产生较为明显的波动,在 100 轮次后趋于稳定,此为网络在学习到大量特征向量后进一步对异常数据进行非线性拟合,迭代调整各层神经元的权重以及偏置的原因。在经历 200 轮次后,误差继续下降并稳定保持在一个极低水平。在测试集上,网络输出预测的索力值与实际索力的均方误差为 0.099 4%,平均绝对误差值为 2.042 4%,深度学习网络在测试集上的索力识别误差保持在一个极低水平。对测试集数据进行详细的误差对比,数据汇总于表 2。均方误差可以评价网络模型识别能力准确度的高低,但不能很准确地衡量模型对数据的拟合能力。因此在细部误差的比较时引入决定系数 R^2 ,它可以很好地判断模型对数据拟合能力的大小,其数值越趋近于 1,代表拟合能力越强,越趋近于 0,则代表拟合能力越弱。

表 2 测试集数据样本索力识别结果

Table 2 Tension identification results of test set data samples

数据编号	实际索力/kN	网络识别索力/kN	误差百分比/%
1	5 017.62	4 977.59	-0.80
2	4 879.43	4 822.61	-1.16
3	5 106.05	5 049.21	-1.11
4	3 454.36	3 402.50	-1.50
5	4 404.83	4 378.69	-0.59
6	4 805.32	4 703.41	-2.12
7	4 518.37	4 543.24	0.55
8	3 875.58	3 897.29	0.56
9	3 845.35	3 747.19	-2.55
10	2 849.76	2 822.13	-0.97
11	2 652.94	2 657.82	0.19
12	3 516.13	3 481.01	-1.00
13	3 078.42	3 036.67	-1.36
14	3 039.72	2 997.16	-1.40
15	2 831.92	2 820.68	-0.40
16	3 147.02	3 117.36	-0.94
17	4 024.54	3 864.07	-3.99
18	3 673.84	3 839.02	4.50
19	3 856.36	3 822.40	-0.88
20	4 035.98	3 986.29	-1.23
21	4 086.90	4 035.01	-1.27
22	4 612.81	4 465.51	-3.19
23	4 697.81	4 705.25	0.16
24	4 858.32	4 784.04	-1.53
25	5 163.44	5 116.80	-0.90
26	5 257.34	5 285.02	0.53
27	5 642.55	5 515.44	-2.25
28	5 695.26	5 674.70	-0.36

图 5 为测试集数据索力识别值与试验实际索力的比较。由图 5 可知,绝大部分样本的网络识别结果与实际值相差极小,从表 2 中可看出,28 个样本索力误差均在 5% 以下,除 3 个测试样本外,网络识别与实际索力间的误差均小于 3%。深度学习网络识别索力值与实际索力间的决定系数 R^2 达到了

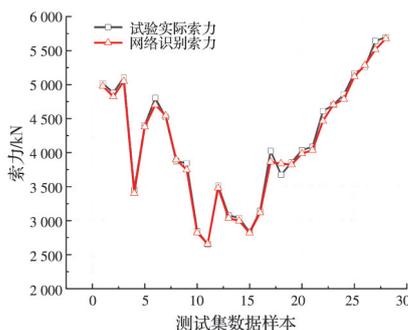


图 5 测试集索力识别值与试验实际索力值的比较

Fig. 5 Comparison of cable tension identification value and actual cable tension value of the test

0.980 6,表明网络识别索力的结果达到较高的精度。证实了在输入一定的参数后提出的网络识别模型能够准确地识别不同参数下的索力特征,实现对带减振器斜拉索索力的高效、智能识别。

4 对比分析及讨论

4.1 与实用公式对比

为了对比分析深度学习网络模型对索力识别的准确性和可靠性,将其与文献[13,16,18,21]中的索力实用计算公式进行比较。将测试集中 28 个样本点对应的拉索各项参数代入各公式中直接计算索力值,并与深度学习网络的识别索力以及实际索力值进行比较,如图 6 所示,计算结果汇总于表 3。

表 3 测试集数据样本索力识别与实用公式计算结果

Table 3 Cable tension identification and calculation results of practical formulas for test set data samples

实际索力/kN	网络识别索力/kN	实用公式计算索力/kN			
		文献[13]	文献[16]	文献[21]	文献[18]
5 017.6	4 977.6	5 258	4 935	4 863	4 725
4 879.4	4 822.6	5 133	4 801	4 685	4 585
5 106.1	5 049.2	5 252	4 886	4 877	4 649
3 454.4	3 402.5	3 820	3 531	3 369	3 345
4 404.8	4 378.7	4 653	4 276	4 367	4 033
4 805.3	4 703.4	4 846	4 404	4 526	4 121
4 518.4	4 543.2	4 613	4 126	4 247	3 816
3 875.6	3 897.3	3 956	3 469	3 418	3 162
3 845.4	3 747.2	4 183	3 550	3 506	3 156
2 849.8	2 822.1	3 550	3 134	3 599	2 870
2 652.9	2 657.8	3 039	2 765	2 755	2 590
3 516.1	3 481.0	3 418	3 161	3 068	2 995
3 078.4	3 036.7	3 342	3 129	3 057	2 992
3 039.7	2 997.2	3 244	3 063	3 121	2 945
2 831.9	2 820.7	3 143	2 980	2 859	2 874
3 147.0	3 117.4	3 480	3 315	3 350	3 208
4 024.5	3 864.1	4 146	3 964	3 842	3 845
3 673.8	3 839.0	3 758	3 602	3 428	3 499
3 856.4	3 822.4	3 928	3 774	3 731	3 673
4 036.0	3 986.3	4 210	4 054	3 923	3 952
4 086.9	4 035.0	4 198	4 050	3 916	3 953
4 612.8	4 465.5	4 651	4 493	4 341	4 389
4 697.8	4 705.2	4 855	4 696	4 564	4 592
4 858.3	4 784.0	4 892	4 738	4 503	4 637
5 163.4	5 116.8	5 174	5 018	4 779	4 915
5 257.3	5 285.0	5 246	5 092	4 849	4 990
5 642.6	5 515.4	5 643	5 481	5 246	5 375
5 695.3	5 674.7	6 011	5 854	5 572	5 750

由图 6 可知,文献[16,18]对于索力计算值的变化趋势相同,原因是采用了相同的计算方法,但修正的程度不一样。文献[21]采用能量法的思路来推

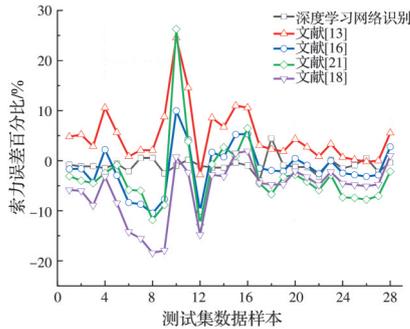


图 6 测试集各公式索力计算值与实际索力值的误差
Fig. 6 Error between cable calculated values of each formula and actual cable tension values in the test set

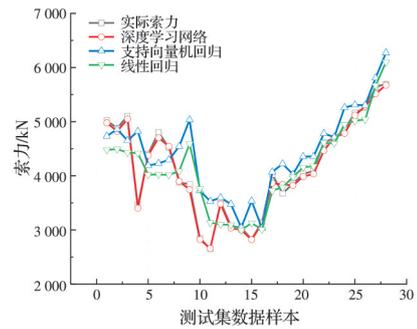


图 7 测试集各算法索力识别结果与实际索力值的比较
Fig. 7 Comparison of cable tension identification results and actual cable tension values of the test set

导索力计算公式,整体效果较差,且需要的拉索参数较多。文献[13]使用的是基于传统弦理论的频率法来计算索力,故误差较大。总的来说,无论哪种公式计算出来的索力值,其误差百分比都偏高,而且波动较大。与之相比,深度学习网络识别索力的误差百分比较小,且在正负间上下浮动,其误差分布均匀,索力识别精度较传统实用计算公式更高。

4.2 与常用机器学习算法对比

为进一步对比分析构建的深度学习网络模型对索力识别的准确性和可靠性,将其与机器学习较为常用的支持向量机回归算法(support vector regression, SVR)以及线性回归算法(linear regression algorithm)进行比较。支持向量机是一种以监督学习方式对数据进行二元分类的广义线性分类机器,其特点是能够同时最小化经验误差并最大化几何边缘,经不断更新优化后已成为解决线性或非线性分类及回归问题的有效手段。线性回归是一种常见的机器学习算法,主要用于建立连续变量之间的线性关系模型,基于变量之间的线性关系假设,在给定输入特征的情况下预测输出变量的值。线性回归的目标是找到最佳拟合直线,使得所有样本点到该直线的距离之和最小,可以通过最小化损失函数来实现,常用的损失函数是平方误差损失,该函数度量了观测值与模型预测值之间的差异。线性回归是一种简单但有效的回归算法,常用于解决连续变量的预测问题。

将相同的训练集和测试集数据输入至SVR算法与线性回归算法中进行索力识别,获得的索力识别值与深度学习网络识别索力以及实际索力进行比较,如图7所示,详细索力识别结果汇总于表4。

由图7可知,相比其他两种算法,深度学习网络识别索力值与实际索力误差更小,识别精度更高。相比支持向量机回归算法,线性回归算法识别精度更高,但仍远逊于深度学习网络。对于测试集中的28个样本,深度学习网络的决定系数达0.9806,而

表 4 测试集各算法的索力识别结果

Table 4 Cable tension identification results of each algorithm in the test set

数据编号	实际索力/kN	深度学习网络识别/kN	支持向量机回归识别/kN	线性回归识别/kN
1	5 017.62	4 977.59	4 733.33	4 478.62
2	4 879.43	4 822.61	4 860.55	4 493.32
3	5 106.05	5 049.21	4 651.73	4 428.22
4	3 454.36	3 402.50	4 823.01	4 417.55
5	4 404.83	4 378.69	4 188.22	4 020.94
6	4 805.32	4 703.41	4 229.34	4 025.20
7	4 518.37	4 543.24	4 296.51	4 015.51
8	3 875.58	3 897.29	4 543.62	4 086.55
9	3 845.35	3 747.19	5 035.27	4 589.52
10	2 849.76	2 822.13	3 726.66	3 760.98
11	2 652.94	2 657.82	3 529.52	3 134.24
12	3 516.13	3 481.01	3 597.48	3 100.86
13	3 078.42	3 036.67	3 475.80	3 094.09
14	3 039.72	2 997.16	3 042.89	2 998.20
15	2 831.92	2 820.68	3 535.27	3 126.11
16	3 147.02	3 117.36	3 034.63	3 007.79
17	4 024.54	3 864.07	4 070.88	3 724.33
18	3 673.84	3 839.02	4 221.67	3 788.93
19	3 856.36	3 822.40	4 027.36	3 976.05
20	4 035.98	3 986.29	4 353.98	4 159.10
21	4 086.90	4 035.01	4 357.49	4 174.70
22	4 612.81	4 465.51	4 781.31	4 611.33
23	4 697.81	4 705.25	4 713.98	4 598.22
24	4 858.32	4 784.04	5 260.57	4 948.60
25	5 163.44	5 116.80	5 309.67	5 014.67
26	5 257.34	5 285.02	5 303.83	5 041.56
27	5 642.55	5 515.44	5 806.88	5 665.61
28	5 695.26	5 674.70	6 271.04	6 098.90

支持向量机回归与线性回归算法仅为0.7061和0.7852。从特征拾取的角度来看,深度学习网络较其他两种算法有明显优势。卷积神经网络的优势是可以高效、准确地处理大批量的数据,其他两种算法无法比拟。综上所述,采用提出的深度学习网络对带减振器斜拉索进行索力识别,其精度和可靠

度远高于支持向量机回归算法和线性回归算法。

5 结论

为解决实际工程中带减振器斜拉索索力测试难度大、精度低的问题,提出一种基于IWPA-LKCNN-LSTM的带减振器斜拉索索力的智能识别模型。构建的深度学习网络可显著提高索力识别精度,实现带减振器斜拉索索力的智能化精准识别。得出以下结论:

1)对实际工程中带减振器的斜拉索开展动态响应测试试验,获得安装减振器前后斜拉索的动态响应数据,基于试验数据开发了一种可实现带减振器斜拉索索力智能化识别的深度学习网络模型。

2)以试验采集到的斜拉索索力、长度、线密度、频率和阶次作为特征输入,最终经深度学习训练后在测试集上输出的预测索力值与实际索力值之间的平均绝对误差值为2.042%,均方误差值为0.0994%,在测试集随机取样的28个点上,索力误差均小5%。

3)将提出的深度学习网络与索力实用计算公式进行比较,得出深度学习网络较已有公式对索力识别的精度更高,波动更小。与支持向量回归算法和线性回归算法进行比较,对于测试集随机取样的28个点,深度学习网络的决定系数为0.9806,远高于支持向量机与线性回归的0.7061和0.7852。充分证明深度学习网络在特征拟合优度方面具有明显优势,数据拟合能力更强。

4)对于实际工程应用中的带减振器斜拉索,提出的索力智能识别方法仅需对少数拉索进行简单试验即可达到较为精确的索力识别效果,在数据达到一定数量后,甚至可以不进行试验即可直接进行智能化索力识别。为带减振器斜拉索的索力识别提供了新的思路,并为后期斜拉索的智能安全评估和寿命预测奠定了基础,拥有广阔的应用前景。

参考文献

[1] 刘志勇. 斜拉桥斜拉索索力测试方法综述[J]. 铁道建筑, 2007, 47(4): 18-20.
LIU Z Y. Summary of cable force testing methods for cable-stayed bridges [J]. Railway Engineering, 2007, 47(4): 18-20. (in Chinese)

[2] KIM B H, PARK T. Estimation of cable tension force using the frequency-based system identification method [J]. Journal of Sound and Vibration, 2007, 304(3/4/5): 660-676.

[3] WANG R H, GAN Q, HUANG Y H, et al. Estimation of tension in cables with intermediate elastic sup-

ports using finite-element method [J]. Journal of Bridge Engineering, 2011, 16(5): 675-678.

- [4] 陈彦江, 程建旗, 闫维明, 等. 基于参数灵敏度分析的吊杆索力识别[J]. 振动与冲击, 2011, 30(7): 256-260.
CHEN Y J, CHENG J Q, YAN W M, et al. Cable force detection based on parametric sensitivity analysis [J]. Journal of Vibration and Shock, 2011, 30(7): 256-260. (in Chinese)
- [5] MA L. A highly precise frequency-based method for estimating the tension of an inclined cable with unknown boundary conditions [J]. Journal of Sound and Vibration, 2017, 409: 65-80.
- [6] NOH M H, HU J W. Tensile force identification in cable-stayed structures: Hybrid system identification algorithm and experimental verification [J]. Journal of Mechanical Science and Technology, 2014, 28(11): 4563-4572.
- [7] 袁佩, 谢旭, 申永刚. 考虑减振装置影响的拱桥吊杆张力测试方法及应用[J]. 浙江大学学报(工学版), 2012, 46(9): 1592-1598.
YUAN P, XIE X, SHEN Y G. Identification method for tensile force in hanger of arch bridges with damper and its application [J]. Journal of Zhejiang University (Engineering Science), 2012, 46(9): 1592-1598. (in Chinese)
- [8] XIE X, LI X Z. Genetic algorithm-based tension identification of hanger by solving inverse eigenvalue problem [J]. Inverse Problems in Science and Engineering, 2014, 22(6): 966-987.
- [9] HAJI AGHA MOHAMMAD ZARBAF S E, NOROUZI M, ALLEMANG R J, et al. Stay cable tension estimation of cable-stayed bridges using genetic algorithm and particle swarm optimization [J]. Journal of Bridge Engineering, 2017, 22(10): 05017008.
- [10] HAJI AGHA MOHAMMAD ZARBAF S E, NOROUZI M, ALLEMANG R, et al. Vibration-based cable condition assessment: a novel application of neural networks [J]. Engineering Structures, 2018, 177: 291-305.
- [11] ZHAN S D, LI Z, HU J M, et al. Model order identification for cable force estimation using a Markov chain Monte Carlo-based Bayesian approach [J]. Sensors, 2018, 18(12): 4187.
- [12] 周银, 黄梓恒, 王玥, 等. 基于激光扫描实测索形的斜拉索索力测量方法[J]. 中国公路学报, 2021, 34(12): 91-103.
ZHOU Y, HUANG Z H, WANG Y, et al. Measurement method of stay cable force based on measured cable shape using laser scanning [J]. China Journal of Highway and Transport, 2021, 34(12): 91-103. (in Chinese)
- [13] 肖军, 代洋, 张永水. 基于子结构中弯曲波的拉索索力

- 识别方法[J]. 土木与环境工程学报(中英文), 2020, 42(04): 135-143.
- XIAO J, DAI Y, ZHANG Y S. A cable force identification method based on flexural waves in substructures [J]. Journal of Civil and Environmental Engineering, 2020, 42(04): 135-143.
- [14] 方志, 张智勇. 斜拉桥的索力测试[J]. 中国公路学报, 1997, 10(1): 51-58.
- FANG Z, ZHANG Z Y. Test of cable tension in cable-stayed bridges [J]. China Journal of Highway and Transport, 1997, 10(1): 51-58. (in Chinese)
- [15] LI F C, WANG D P, YANG O, et al. Cable tension measurement for cable-stayed bridge considering on the effect of damper [C]//2009 International Conference on Mechatronics and Automation. Changchun. IEEE, 2009: 2586-2590.
- [16] 王朝华, 李国蔚, 何祖发, 等. 斜拉桥索力测量的影响因素分析[J]. 世界桥梁, 2004, 32(3): 64-67.
- WANG C H, LI G W, HE Z F, et al. Analysis of influential factors in cable force measurement of cable-stayed bridges [J]. World Bridges, 2004, 32(3): 64-67. (in Chinese)
- [17] 马林, 魏峰. 北京市五环路斜拉桥的索力测试和分析[J]. 铁道建筑, 2008, 48(1): 13-15.
- MA L, WEI F. Cable force test and analysis of cable-stayed bridge in Beijing fifth ring road [J]. Railway Engineering, 2008, 48(1): 13-15. (in Chinese)
- [18] 柯红军, 李德慧, 李晓宝. 减震器对斜拉索索力检测的影响[J]. 中外公路, 2008, 28(3): 103-105.
- KE H J, LI D H, LI X B. Influence of shock absorber on cable force detection of stay cables [J]. Journal of China & Foreign Highway, 2008, 28(3): 103-105. (in Chinese)
- [19] 黄江明, 毛媛. 斜拉桥索力参数识别与测试评价[J]. 公路交通科技(应用技术版), 2019, 15(7): 226-228.
- HUANG J M, MAO Y. Identification and test evaluation of cable force parameters of cable-stayed bridge [J]. Highway Traffic Science and Technology (Applied Technology Edition), 2019, 15(7): 226-228. (in Chinese)
- [20] 黄竞锋. 大跨钢箱梁斜拉桥的施工监控及索力测试[D]. 长沙: 湖南大学, 2020.
- HUANG J F. Construction controlling and cable tension testing of long span steel box girder cable-stayed bridge [D]. Changsha: Hunan University, 2020. (in Chinese)
- [21] 王红平. 斜拉桥索力监测技术研究与应用[D]. 西安: 长安大学, 2002.
- WANG H P. Research and application of cable force monitoring technology for cable-stayed bridge [D]. Xi'an: Chang'an University, 2002. (in Chinese)
- [22] 陈庆志, 蒋玲玲. 频率法索力测试计算公式研究[J]. 公路, 2018, 63(12): 164-166.
- CHEN Q Z, JIANG L L. Study on calculation formula of cable tension test by frequency method [J]. Highway, 2018, 63(12): 164-166. (in Chinese)
- [23] 刘陈韬. 独塔不对称斜拉桥索力优化与施工监控实践[D]. 江苏苏州: 苏州科技大学, 2021.
- LIU C T. Practice of cable force optimization and construction monitoring of single-tower asymmetric cable-stayed bridge [D]. Suzhou, Jiangsu: Suzhou University of Science and Technology, 2021. (in Chinese)
- [24] AIKO F, KATSUYA H, RYOSUKE K. Verification of the tension estimation method for cables with dampers using laboratory experiments and field measurements on a Cable-Stayed bridge [J]. AI・データサイエンス論文集, 2022, 3(2): 2-10.
- [25] 吴虎胜, 张凤鸣, 吴庐山. 一种新的群体智能算法: 狼群算法[J]. 系统工程与电子技术, 2013, 35(11): 2430-2438.
- WU H S, ZHANG F M, WU L S. New swarm intelligence algorithm: Wolf pack algorithm [J]. Systems Engineering and Electronics, 2013, 35(11): 2430-2438. (in Chinese)
- [26] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. Neural Computation, 1997, 9(8): 1735-1780.
- [27] 郭立婷. 基于自适应和变游走方向的改进狼群算法[J]. 浙江大学学报(理学版), 2018, 45(3): 284-293.
- GUO L T. Improved wolf pack algorithm based on adaptive step length and adjustable scouting direction [J]. Journal of Zhejiang University (Science Edition), 2018, 45(3): 284-293. (in Chinese)
- [28] DING X H, ZHANG X Y, HAN J G, et al. Scaling up your kernels to 31×31 : Revisiting large kernel design in CNNs [C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). New Orleans, LA, USA. IEEE, 2022: 11953-11965.