

doi: 10.11835/j.issn.1000-582X.2024.051

基于卷积神经网络的高层建筑智能控制算法研究

刘康生, 涂建维, 张家瑞, 李 召

(武汉理工大学 道路桥梁与结构工程湖北省重点实验室, 武汉 430070)

摘要: 浅层学习神经网络对高维数据进行预测时, 会出现预测精度低, 泛化能力差等问题。为此, 在一维卷积神经网络(one-dimensional convolutional neural networks, 1D-CNN)和 Deep Dream 视觉算法的基础上, 提出一种基于 CNN 深度学习网络的高层建筑智能控制算法, 并完成高精度网络模型训练和 1D-CNN 数据特征可视化; 以 20 层 benchmark 模型为对象, 研究了不同工况下 1D-CNN 深度学习智能控制算法的减震效果, 并与 BP(back propagation, BP)和 RBF(radial basis function, RBF)等浅层学习进行对比。结果表明, 1D-CNN 凭借一维卷积和池化特性, 可自动提取数据深层次特征并对海量数据进行降维处理; 在外界激励作用下, 1D-CNN 控制器加速度和位移最高减震率分别为 69.0% 和 55.6%, 控制性能远高于 BP 和 RBF; 改变激励作用后, 3 种控制器控制性能均有所降低, 但 1D-CNN 性能降幅最小且减震率最高, 说明 1D-CNN 具备更好的泛化性能。

关键词: 深度学习; 一维卷积神经网络; 智能控制; 数据特征可视化; 泛化性能

中图分类号: TB381

文献标志码: A

文章编号: 1000-582X(2025)01-066-10

Research on intelligent structural control algorithm for high-rise buildings based on one-dimensional convolution neural network

LIU Kangsheng, TU Jianwei, ZHANG Jiarui, LI Zhao

(Hubei Key Laboratory of Roadway Bridge and Structure Engineering, Wuhan University of Technology, Wuhan 430070, P. R. China)

Abstract: Traditional shallow neural networks exhibit low prediction accuracy and poor generalization when handling high-dimensional data. To solve these problems, this study proposes an intelligent control algorithm for high-rise buildings based on one-dimensional convolutional neural networks(1D-CNN) and the deep dream visualization algorithm. The proposed method enables high-precision network model training and visualizes data features through 1D-CNN. Using a 20-story benchmark model as a case study, the damping performance of the 1D-CNN-based intelligent control algorithm was analyzed under different conditions and compared with back propagation(BP) and radial basis function(RBF) algorithms. Results show that 1D-CNN can effectively extract deep data features and reduce the dimensionality of massive datasets by virtue of one-dimensional convolution and pooling operations. Under external excitation, the maximum damping rates for acceleration and displacement

收稿日期: 2024-01-23 网络出版日期: 2024-05-07

基金项目: 国家自然科学基金资助项目(51978550); 国家重点研发计划资助项目(2018YFC0705601); 中央高校基本科研业务费专项资金资助项目(2019-YB-024)。

Supported by National Natural Science Foundation of China(51978550), Key Research Plan of Ministry of Science and Technology(2018YFC0705601), Fundamental Research Funds for the Central Universities(2019-YB-024).

作者简介: 刘康生(1995—), 男, 硕士研究生, 主要从事土木工程振动控制的研究, (E-mail)2281585945@qq.com。

通信作者: 涂建维, 男, 教授, 博士生导师, (E-mail)tujianwei@whut.edu.cn。

achieved by the 1D CNN controller were 69.0% and 55.6% respectively, significantly outperforming BP and RBF. Although the control performance of all algorithms decreased under modified excitation conditions, the 1D-CNN consistently exhibited superior performance and the best generalization capability.

Keywords: deep learning; 1D-CNN; intelligent control; data feature visualization; generalization performance

根据是否需要外部能源、激励以及结构的反应信号,可以将结构振动控制类型分为:主动、被动、半主动和混合控制等^[1]。目前较为成熟的主动控制策略有:极点配置算法^[2]、线性二次型高斯控制算法^[3]、独立模态空间控制算法^[4]等,但以上方法均需建立建筑结构的精确模型,随着工程技术的发展,超高层建筑模型参数趋于复杂化,控制数据海量,使得以上算法在工程中难以实现。神经网络控制算法为解决这一问题提供了新的途径,该类算法具有不需要建立精确结构模型、泛化能力强、稳定性高等优点^[5]。在浅层学习神经网络控制算法中,Ramezani等^[6]通过人工神经网络算法寻找TMD(tuned mass dampers, TMD)最优参数,验证其在控制方面的准确性。Zhao等^[7]利用RBF神经网络较高的容错性和自适应能力,设计出RBF神经网络滑模控制器。涂建维等^[8]通过RBF神经网络预测MR阻尼器滞后的地震响应,有效抑制了船机顶部的地震鞭梢效应。李宏男等^[9]进行了基于遗传BP神经网络对偏心结构的减震控制研究,解决了被控系统的非线性、时滞、时变等问题。然而,以上浅层结构算法存在复杂函数表达能力有限,训练时间长,易过拟合等缺点,阻碍了其在高层建筑和复杂结构振动控制中的应用^[10]。

为弥补以上浅层学习的不足,深度学习可根据不同任务设计出相应深层网络模型,以应对复杂结构诊断和庞大数据的预测等问题^[11]。涂建维等^[10]采用长短时记忆网络(long short-term memory, LSTM)完成对3层benchmark模型的振动控制,这是深度学习对结构振动的首次运用。卷积神经网络作为深度学习的代表算法之一,由于其内部独特的降维构造和强大的特征提取能力,被广泛应用于轴承故障诊断^[12]、图像识别^[13]及时间序列预测^[14]等领域。其中,图像识别采用二维卷积神经网络(2D-CNN),时间序列预测采用1D-CNN。针对高维时间序列预测问题,1D-CNN在结构健康检测^[15]、电路故障诊断^[16]和管道震动识别^[17]等方面均被成功应用。

综上所述,1D-CNN适用于高维时间序列的特征降维和预测,可将此特性用于高层建筑结构的振动控制。因此,文中提出了基于1D-CNN的智能控制算法,用于高层建筑在地震作用下的振动控制。以结构地震响应作为时间序列训练神经网络,可视化1D-CNN降维过程,并将控制仿真结果与浅层学习(BP、RBF)对比,验证文中方法的有效性。

1 CNN 理论

CNN根据输入数据类型和卷积方式的不同可分为1D-CNN、2D-CNN和3D-CNN^[18],但基本框架结构相似。1D-CNN结构如图1所示,分别由输入层、卷积层、池化层、全连接层和输出层组成。CNN相较于全连接网络具有稀疏连接和权值共享两大优点,可降低过拟合风险和提高网络稳定性。

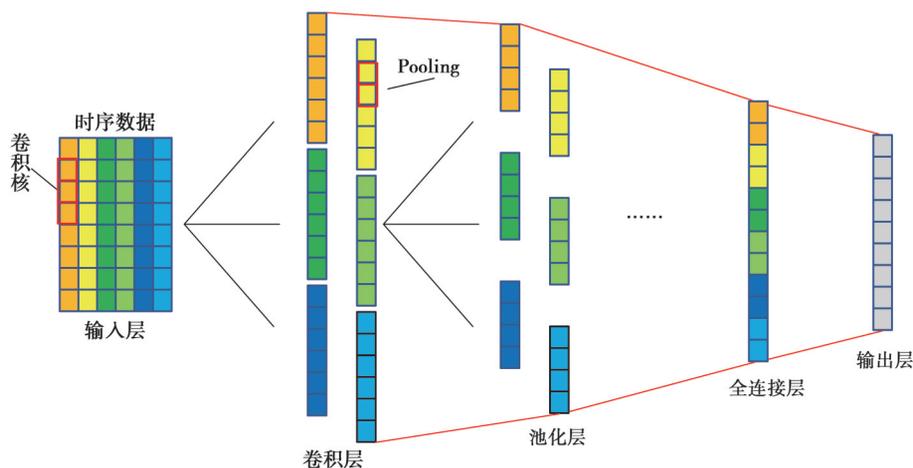


图1 1D-CNN框架结构图

Fig. 1 Structure diagram of 1D-CNN

1.1 CNN 运算理论

卷积层是CNN核心部分,决定处理的数据类型。其每一层的输入是通过卷积核(filter)完成卷积运算得到的,每个卷积核经运算后可得到一个特征图(feature map),也称作通道(channel),卷积公式为

$$Y_{d,i,j} = f \left(\sum_{x=0}^{D-1} \sum_{y=0}^{H-1} \sum_{z=0}^{L-1} W_{x-1,y,z} X_{x-1,i+y,j+z} + B \right), \quad (1)$$

式中: $Y_{d,i,j}$ 为通道 x 层 i 行 j 列特征映射; $f(\cdot)$ 为激活函数; D, H, L 分别为卷积核深度、高度和长度; $W_{x-1,i,j}$ 为卷积核 $x-1$ 层 m 行 n 列权重; B 为卷积核的偏置; $X_{x-1,i,j}$ 为 $x-1$ 层 $i+y$ 行 $j+z$ 列特征映射。卷积运算时,设输入数据维度为 $W \times W$,步长为 S ,填充数为 P ,经卷积计算后的输出数据维度为

$$\left[\frac{(W+2P-F)}{S} + 1 \right] \times \left[\frac{(W+2P-F)}{S} + 1 \right]. \quad (2)$$

池化操作时,无需进行填充,设输入数据维度为 $W \times W$,步长为 S ,经池化后的输出数据维度为

$$\left[\frac{W-F}{S} + 1 \right] \times \left[\frac{W-F}{S} + 1 \right]. \quad (3)$$

由以上公式可知,每层神经元仅与上层神经元连接,且每个卷积核的固定权值与输入层所有神经元进行卷积运算,减少了运行参数;池化操作过程中,使用最大池化方式,进一步降低了数据维度,提高了神经网络运行效率。

在CNN误差反向传递过程中,根据链式求导法则,卷积层误差 δ 可表示为

$$\delta_{i,j}^l = \sum_{i,d} \frac{\partial E}{\partial \mathbf{net}_{i,j}^{l+1}} = \sum_{i,j} \frac{\partial E}{\partial \alpha_{i,j}^{l+1}} \frac{\partial \alpha_{i,j}^{l+1}}{\partial \mathbf{net}_{i,j}^{l+1}}, \quad (4)$$

其中,

$$\mathbf{net}^l = \text{conv}(W^l, X^{l+1}) + b, \quad (5)$$

$$\alpha_{i,j}^{l+1} = f^{l+1}(\mathbf{net}_{i,j}^{l+1}), \quad (6)$$

式(4)等号右侧第一、二项可分别表示为

$$\frac{\partial \alpha_{i,j}^{l+1}}{\partial \mathbf{net}_{i,j}^{l+1}} = f'(\mathbf{net}_{i,j}^{l+1}), \quad (7)$$

$$\frac{\partial E}{\partial \alpha_{i,j}^{l+1}} = \sum_m \sum_n \frac{\partial E}{\partial \mathbf{net}_{i,j}^{l+1}} \frac{\partial \mathbf{net}_{i,j}^{l+1}}{\partial \alpha_{i,j}^{l+1}} = \sum_m \sum_n \delta_{i,j}^{l+1} \omega_{i,j}, \quad (8)$$

式中: $\delta_{i,j}^l$ 为 l 层 i 行 j 列误差项; E 为损失函数; \mathbf{net}^l 为 l 行神经元加权输入; $\alpha_{i,j}^{l+1}$ 为 $l+1$ 层神经元输出; W^l 为权重矩阵,其他参数同上。

联立式(4)(7)和(8),最终误差传递公式为

$$\delta_{i,j}^l = \sum_m \sum_n \omega'_{m,n} \delta_{i+m,j+n}^{l+1} f'(\mathbf{net}_{i,j}^{l+1}) = \delta^{l+1} * W^{l+1} \circ f'(\mathbf{net}^{l+1}), \quad (9)$$

式中: $\delta_{i,j}^l$ 为 l 层 i 行 j 列误差项; \mathbf{net}^l 为 l 行神经元加权输入; W^l 为权重矩阵;“ \circ ”指矩阵乘法; δ^l 、 $\mathbf{net}_{i,j}^{l+1}$ 均为矩阵。卷积过程中可根据特征图尺寸,进行适当填充(padding)。

1.2 数据特征可视化提取

CNN“黑盒式”运行过程,阻碍了人们对其直观的认知。为定量理解CNN的运行逻辑,验证控制器内部降维过程,采用deep dream可视化算法^[19]、activations函数进行中间层局部特征、数据处理层完整特征的提取和分析^[13]。该算法核心函数为matlab中的deep dreamimage,调用方式为

$$I = \text{deepdreamimage}(\text{net}, \text{layer}, \text{channels}, \text{name}, \text{value}). \quad (10)$$

式中:net为预先训练的神经网络;layer为需可视化的中间层;channels为通道数,设置为索引的向量;name、value分别为输入数据的名称及参数值。

Activations 函数激活指定网络层,需与 augmentedimage datastore 函数(通过批量转换增强数据)共同使用来提取网络层完整特征,具体表达式为

$$\text{features} = \text{Activations}(\text{net}, \text{augimds}, \text{layer}), \tag{11}$$

$$\text{auidms} = \text{Augmentedimagedatastore}(\text{outputsize}, \text{imds}), \tag{12}$$

式中:outputsize 为特征图输出尺寸;imds 为数据存储库;augimds 为批处理后数据库;layer、net 含义同式(10)。

2 一维卷积特征可视化

在处理时序数据时,1D-CNN 相较 BP、RBF 等浅层学习神经网络,其优势在于提升预测精度的同时,加快网络运行效率,这主要取决于 1D-CNN 内部独特的降维构造。然而,海量数据的特征提取流程及深度学习“黑盒式”的学习方式很难被直观理解。为深度解析 1D-CNN 运行的工作机理,使用 deep dream 可视化算法分析了 1D-CNN 学习过程中数据降维细节和逻辑变化,验证了控制器工作的有效性和正确性。时序数据提取过程中需保留边缘信息完整性,因此,采用 0 填充(Padding)操作扩大数据集,如图 2 所示,神经网络参数如表 1 所示。

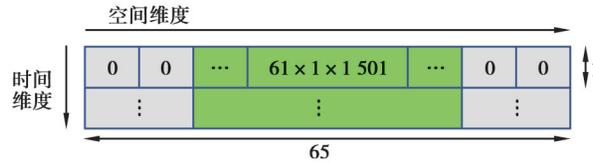


图 2 Conv1 层 0 填充操作示意图

Fig. 2 Zero filling operation diagram of Conv1 layer

表 1 1D-CNN 网络框架参数

Table 1 Network framework parameters of 1D-CNN

卷积层	卷积核尺寸	是否激活	池化过滤器尺寸	dropout	步长	填充
Conv1	3×1×32	是	2×1	0.2	2	2×0
Conv2	2×1×64	是	2×1	0.2	2	2×0

2.1 1D-CNN 特征学习层可视化

1D-CNN 特征学习主要通过卷积层、池化层的特征提取和降维来完成,由于计算机设备和超参数的不同,使得数据的训练结果有所改变,导致了可视化特征学习层具有一定随机性,但预测精度不会发生大幅变化。

数据特征的维度变化体现了 1D-CNN 的降维过程,经试算,Conv1 层和 Pool1 层通道数(Channels)取 64,迭代次数取 50,可视化层数分别为 2 和 3;Conv2 层和 Pool2 层通道数(Channels)取 128,迭代次数取 75,可视化层数分别为 6 和 9。在确定神经网络超参数后,采用 deep dream 可视化算法对中间层特征进行逐层提取。图 3 为 1D-CNN 双层网络的卷积、池化层特征可视化结果,展示了 1D-CNN 对输入数据的降维过程。图 3(a)和(b)分别为第 1 层的卷积(Conv1)和池化层(Pool1),每层特征图数量与卷积核相同,均为 32 张。经池化层降维后,输入尺寸由 Conv1 层的 32×1 降至 Pool1 层的 16×1。图 3(c)(d)分别为第 2 层的卷积(Conv2)和池化层(Pool2),每层特征图数量为 64 张。经池化层降维后,输入尺寸由 Conv2 层的 10×1 降至 Pool2 层的 5×1。上述各层降维结果和理论计算值一致,验证了 1D-CNN 对数据的降维过程和运算逻辑的正确性。

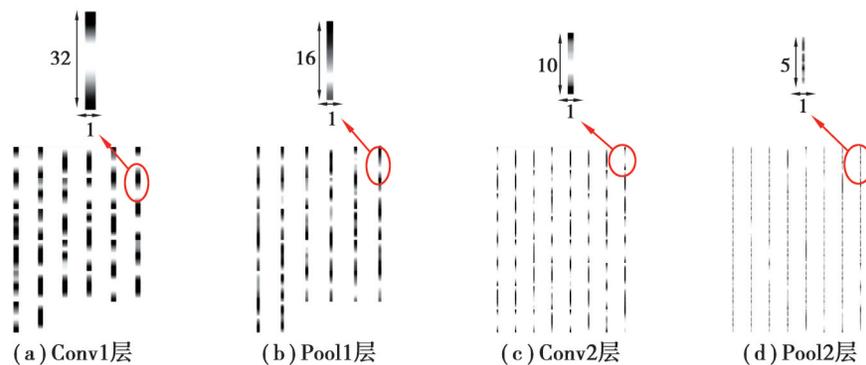


图3 1D-CNN特征可视化效果图

Fig. 3 Feature visualization of 1D-CNN

2.2 1D-CNN数据处理层可视化

Dropout层、ReLU层通过对输入数据负值置零和神经元的随机失活,可提高网络稀疏性,降低过拟合风险,但并不改变数据维度。为定量分析Dropout层、ReLU层前后完整特征变化,分别定义特征尺寸比例和特征层数为3和5;再采用Activations函数激活并保存Dropout和ReLU层数据;最后,通过AugmentedImageDatastore函数提取目标层完整数据特征。如图4和图5所示,输入数据经过Dropout层峰值区间为 $[-1.706, 1.811]$,尺寸为 $2\ 048 \times 1\ 501$,经ReLU层后峰值区间为 $[0, 1.811]$,该图显示数据特征在正值和数据尺寸不变情况下,负值置零,验证了ReLU激活层的功能。

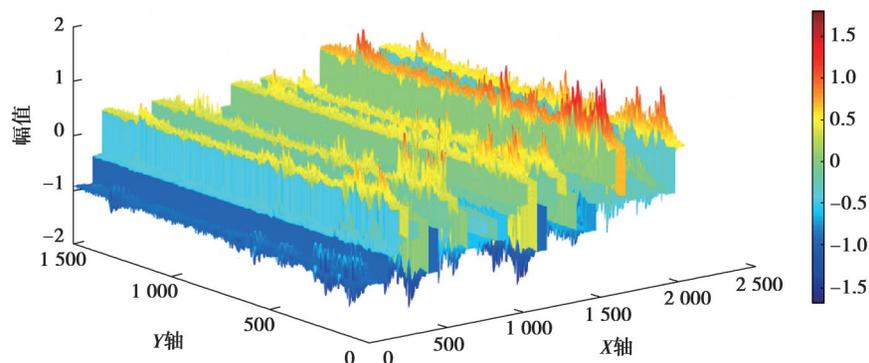


图4 Dropout层完整特征提取

Fig. 4 Complete feature extraction of dropout layer

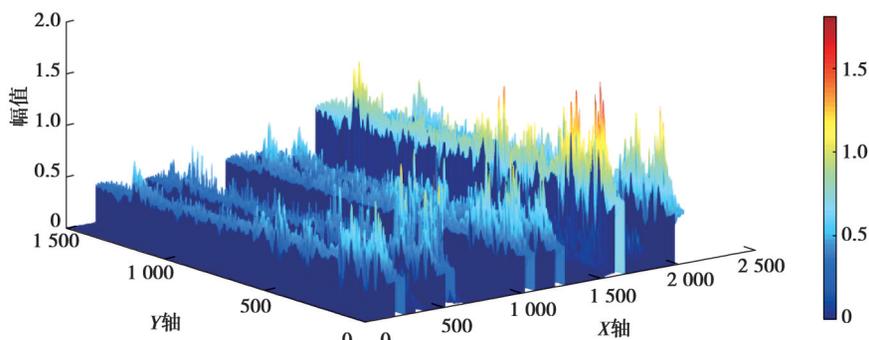


图5 ReLU层完整特征提取

Fig. 5 Complete feature extraction of ReLU layer

3 20层 BENCHMARK 模型地震响应控制仿真分析

3.1 神经网络框架设计

因深度学习超参数的取值尚无规范化的方式,考虑到网络训练精度和控制器的控制效果等因素,采用试算的方式加以确定,最终获取的网络框架为:数据输入层(image input layer)、一维卷积层(convolution layer)、防过拟合层(dropout layer)、一维池化层(maxpooling layer)、全连接层(fully connected layer)和线性回归层(regression layer)。数据训练时采用 32 个 3×1 和 64 个 2×1 的卷积核,池化尺寸与对应层卷积核尺寸相等;Dropout 率取 0.2,激活函数选择线性修正单元(ReLU),初始学习率为 0.003,最大训练步为 500,学习率下降周期为 150,学习速率下降因子取 0.5。

3.2 整体控制器设计

文中选用 ASCE 设计的 Benchmark 模型第 3 阶段 20 层钢 benchmark 模型^[20]作为算例,该模型采用 Rayleigh 阻尼,前二阶振型阻尼比均取 0.05。为获取足够多训练数据,每层均布置作动器与传感器(即作动器与传感器数量为 20,每层各布置 1 个),其余 Benchmark 模型结构参数如表 2 所示。以地震波作为外部激励作用于该模型,将模型的位移、速度、加速度响应作为 1D-CNN 数据集(61×1501 维)。数据集输入 1D-CNN 前进行数据分割,取数据集前 2/3 作为训练集,后 1/3 作为测试集。通过训练集对 1D-CNN 进行指定精度训练,测试集测试未满足精度返回训练集重新迭代,满足精度后作为 1D-CNN 智能控制模块输入控制系统。最终生成作动器控制力后作用于 Benchmark 模型,从而完成结构数据的快速接收、分析、控制振动的任务,1D-CNN 智能控制器具体仿真流程如图 6 所示。

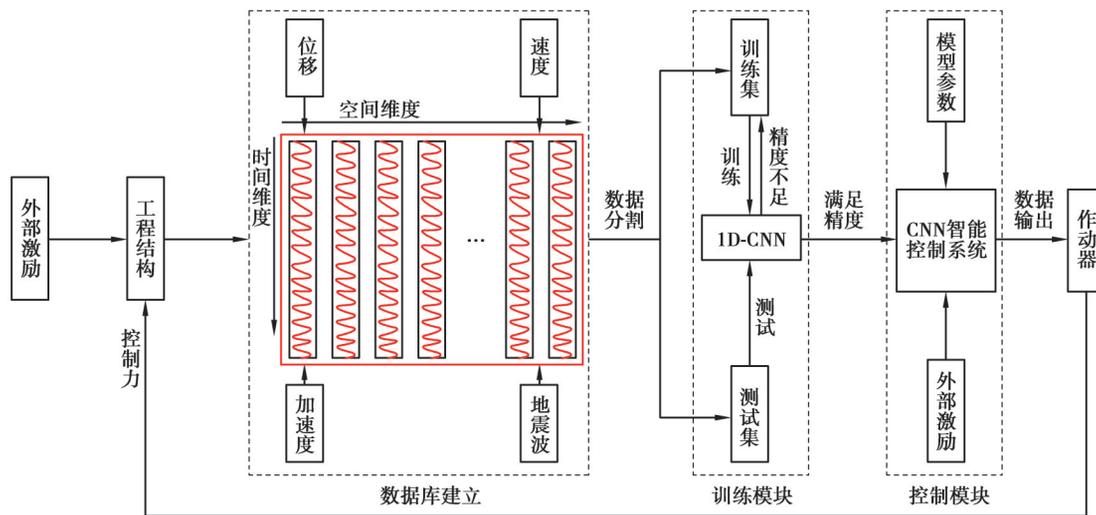


图 6 1D-CNN 智能控制系统仿真流程图

Fig. 6 Simulation flow chart of intelligent control system based on 1d-cnn

表 2 Benchmark 模型参数

Table 2 Model parameters of benchmark

层数	1	2~5	6~11	12~14	15~17	18~19	20
质量 $m/(10^6 \text{ kg})$	1.126	1.100	1.100	1.100	1.100	1.100	1.170
刚度 $k/(10^3 \text{ kN}\cdot\text{m}^{-1})$	862.070	826.070	554.170	453.510	291.230	256.460	171.700
层高/m	5.940	3.960	3.960	3.960	3.960	3.960	3.960

3.3 控制效果对比

为直观了解深度学习控制仿真效果,将持续 30 s 的 El-centro 波(加速度峰值为 3.417 m/s^2)作为外界激励输入神经网络,采用 1D-CNN 对 3.2 节模型进行振动控制,并与 BP、RBF 等浅层学习神经网络进行对比。图 7

为不同神经网络控制时程曲线,可以看出,位移和加速度响应峰值在不同时间点发生偏移,这是由于控制力的输入改变被控系统极点位置所致;相较于无控状态,顶层加速度和位移响应通过神经网络控制后均有所下降,但1D-CNN控制下的响应明显小于浅层学习,说明了深度学习的控制效果均优于浅层学习。图8为各神经网络顶层控制力时程曲线图与各层最大控制力,为直观展示卷积神经网络的特点,采用同为200次迭代次数的BP和RBF神经网络与其进行对比。为便于观测,取峰值波动最大的前0~10 s部分数据进行分析,由图8(a)~(c)可知,保持相同迭代次数情况下,相较于RBF和BP神经网络预测中出现的过拟合现象,1D-CNN预测效果最好,预测数据更贴近计算值。由图8(d)可知,随着楼层的增高,模型振动控制所需的控制力越小;3种神经网络中,1D-CNN网络各层控制力预测值与计算值差值最小,1D-CNN、RBF和BP神经网络最大差值分别为5.4%、17.2%和21.3%。

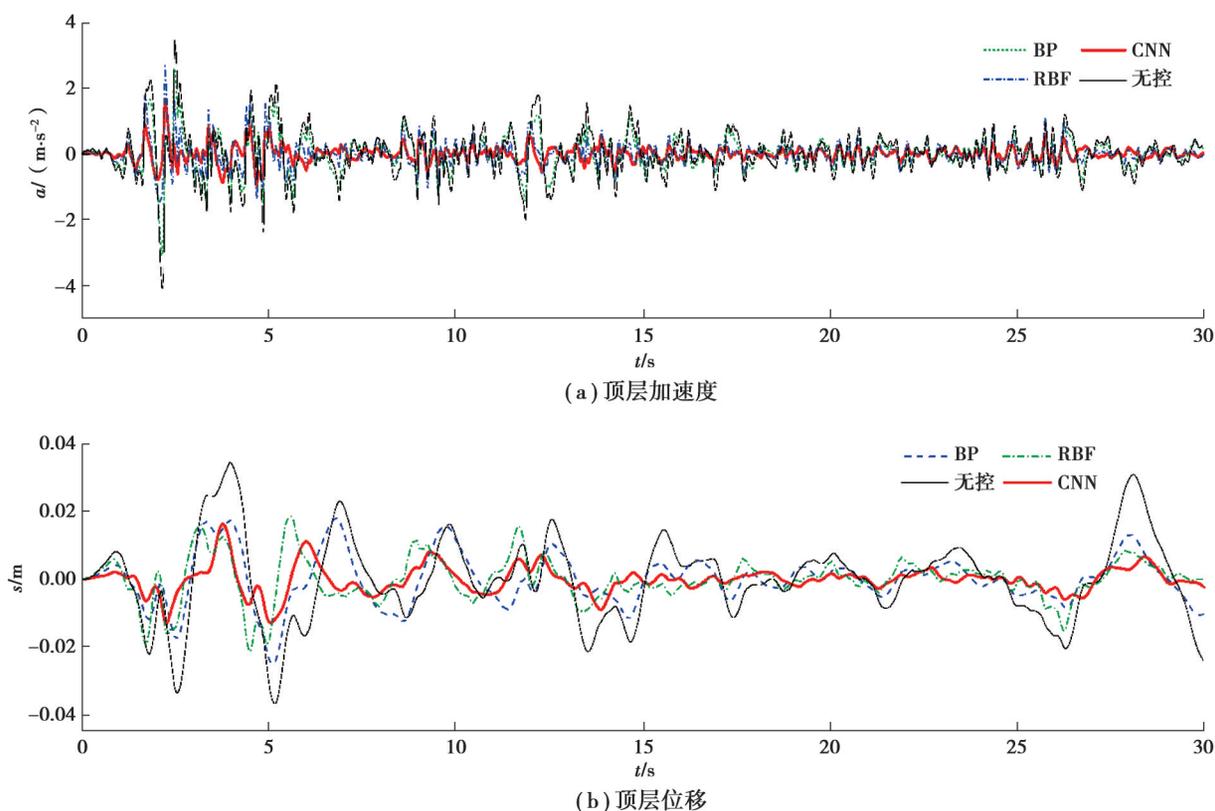


图7 1D-CNN集中控制器控制效果

Fig. 7 Control effect of centralized controller based on 1d-cnn

El-centro地震波激励下无控、BP、RBF和1D-CNN控制的结构各层最大位移和最大绝对加速度响应如图9所示。比较BP、RBF和CNN楼层响应图可以发现,3种控制器对绝对加速度的控制最优效果在第9层,由无控状态下的 $4.19 m/s^2$ 分别下降到2.70、2.65、1.28 m/s^2 ,减震率分别为35.6%、36.8%和69.0%;最大位移由无控状态的36.7 mm分别下降到25.0、21.4、16.3 mm,减震率分别为31.9%、41.7%和55.6%。综上所述,1D-CNN相较于浅层学习神经网络,具有更好的振动控制效果。

为研究1D-CNN智能控制器泛化能力,采用El-centro波作为训练数据,并添加该地震波作用下20层benchmark模型的地震响应(位移、速度、加速度)以扩充训练集,完成对1D-CNN训练后将其输入智能控制仿真系统。分别采用持时为30 s、采样频率为0.02 s/次的汶川波和某人工波(加速度峰值均取 $2 m/s^2$)作为外界激励,作用于装有智能控制系统的benchmark模型,3种控制器控制效果如表3所示。由表可知,1)更改外部激励后,由于训练数据与外界激励并不同源,神经网络非线性函数与新的地震响应匹配度下降,3种控制器控制效果均有所降低,但1D-CNN降幅最小,减震率最高;2)BP、RBF在更改训练集后,加速度减震率大幅下降,在人工波作用下BP、RBF在第5层减震率为15.1%和19.2%,在汶川波作用下BP、RBF在第1层减震率分别

为 17.2% 和 19.8%, 均在 20% 以下, 而 1D-CNN 减震率最低值为 36.8%, 位于第 5 层, 由上述结果可知, 1D-CNN 具有更好的泛化性。

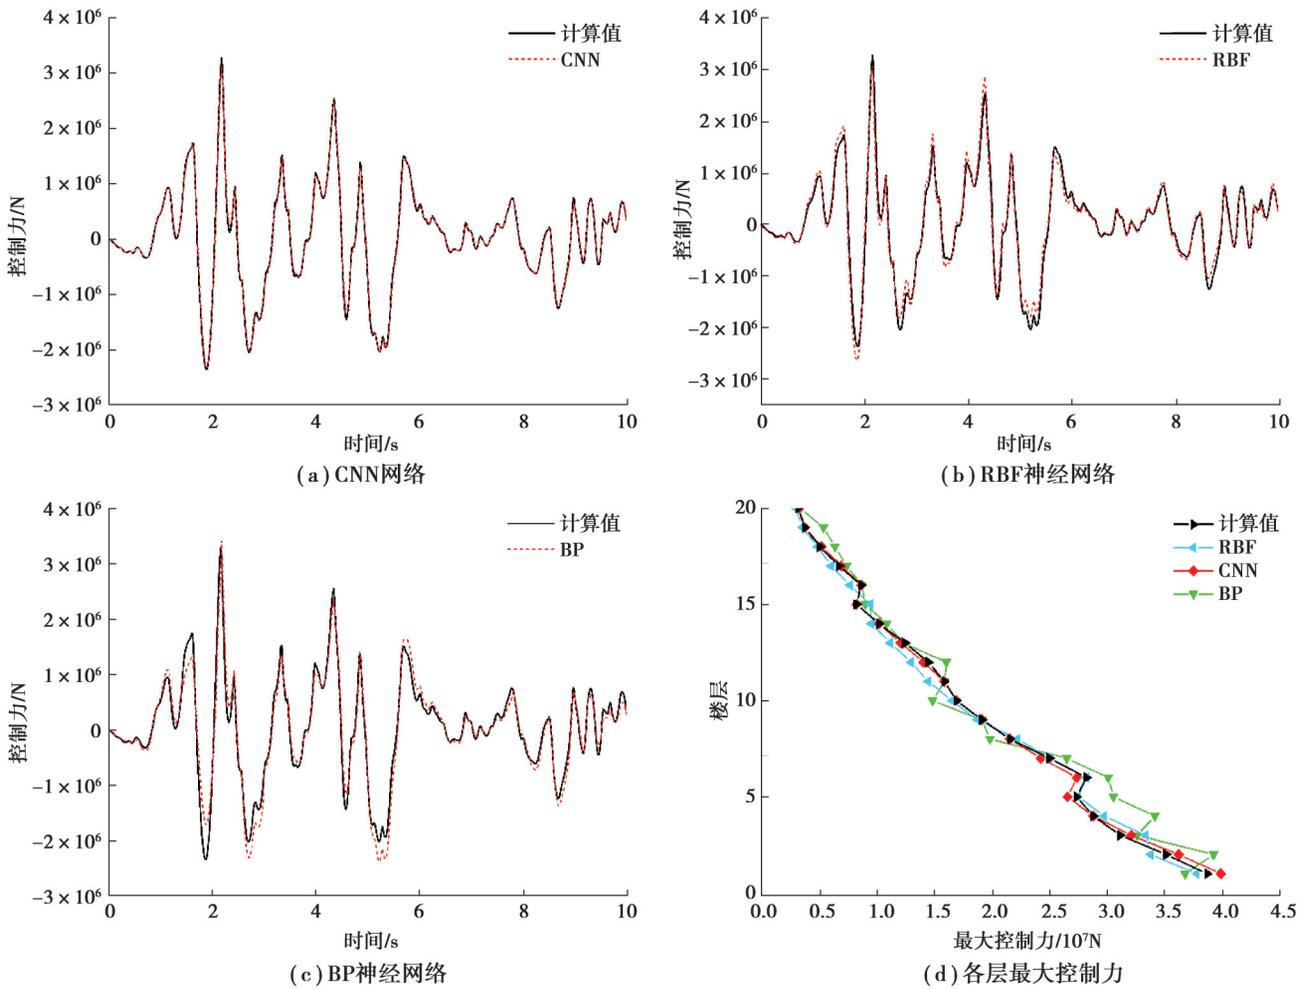


图 8 控制力时程与最大控制力图

Fig. 8 Graph of control force time history and maximum control force

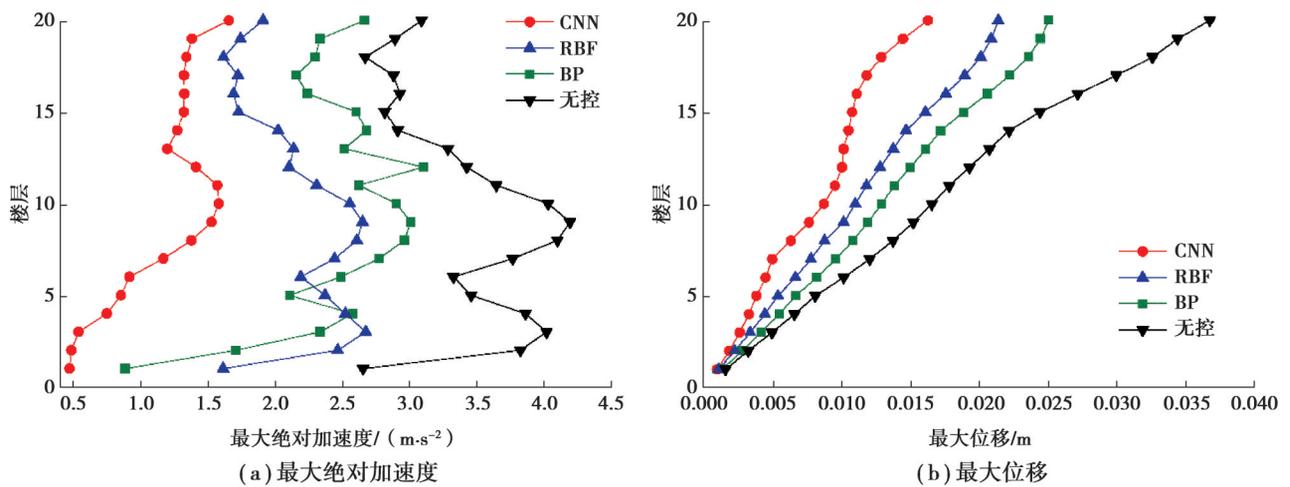


图 9 顶层最大位移和最大绝对加速度

Fig. 9 Maximum displacement diagram and maximum absolute acceleration diagram of top floor

表3 不同地震波作用下不同控制器控制效果
Table 3 Control effect of different controllers under different seismic waves

楼层	控制器	人工波				汶川波			
		位移 峰值/ mm	减震率/ %	加速度 峰值/ ($m \cdot s^{-2}$)	减震率/ %	位移 峰值/ mm	减震率/ %	加速度 峰值/ ($m \cdot s^{-2}$)	减震率/ %
1	无控	1.33	—	1.205	—	1.03	—	1.120	—
	1D-CNN	0.60	55.0	0.644	46.6	0.44	57.3	0.561	49.9
	BP	0.97	26.9	0.904	25.0	0.65	37.3	0.927	17.2
	RBF	0.90	32.6	0.803	33.3	0.62	39.9	0.898	19.8
5	无控	6.79	—	1.948	—	4.25	—	1.032	—
	1D-CNN	4.15	38.8	1.032	47.0	2.64	37.9	0.595	42.4
	BP	4.96	27.3	1.653	15.1	2.49	41.3	0.625	39.4
	RBF	5.53	21.2	1.573	19.2	2.78	34.5	0.580	43.8
10	无控	15.86	—	1.589	—	9.95	—	1.037	—
	1D-CNN	10.02	36.8	0.530	66.6	5.58	43.9	0.544	47.5
	BP	11.64	26.6	0.822	48.3	6.94	30.3	0.579	44.1
	RBF	9.82	38.1	0.709	55.4	6.43	35.4	0.552	46.7
15	无控	24.83	—	1.767	—	13.88	—	1.253	—
	1D-CNN	13.53	45.5	0.902	48.9	8.10	41.7	0.552	56.0
	BP	14.46	41.8	1.085	38.6	9.49	31.6	0.655	47.7
	RBF	13.76	44.6	0.974	44.9	9.78	29.5	0.626	50.0
20	无控	30.76	—	2.133	—	15.90	—	1.125	—
	1D-CNN	16.31	47.0	1.132	46.9	9.06	43.0	0.593	47.3
	BP	22.56	26.7	1.384	35.1	13.92	12.4	0.715	36.4
	RBF	20.36	33.8	1.300	39.0	11.68	36.5	0.729	35.2

4 结 论

文中将 1D-CNN 用于振动控制领域,提出基于 1D-CNN 的高层建筑智能控制算法,通过构造时间序列数据集训练网络模型、可视化中间层数据特征以及完成神经网络的振动控制仿真,得出主要结论如下。

1) 根据 1D-CNN 理论可知,经过双层卷积、池化后,特征图尺寸由 32×1 降至 5×1 ,说明利用 1D-CNN 对时间序列的敏感性,将其用于高层建筑振动控制数据的降维提取是切实可行的。

2) 在采用相同训练数据的情况下,1D-CNN 预测的控制力时程曲线更贴近计算值,对于非线性数据集的预测能力相较于 BP、RBF 等浅层神经网络具有预测精度更高的优点。

3) 在对 20 层 benchmark 模型的振动控制仿真中,经试算确定最优参数后,1D-CNN 加速度和位移减震率最高分别为 69.0% 和 55.6%,相较 BP 和 RBF 等浅层学习神经网络具备更好的减震效果;改变不同地震激励后,1D-CNN 对结构响应的控制效果更为稳定,最低减震率为 36.8%,高于 BP 和 RBF 神经网络的 15.1% 和 17.2%,即 1D-CNN 较 BP 和 RBF 等浅层学习具备更好的泛化性。

参考文献

- [1] 阎维明,周福霖,谭平. 土木工程结构振动控制的研究进展[J]. 世界地震工程, 1997, 13(2): 8-20.
Yan W M, Zhou F L, Tan P. Research progress of vibration control of civil engineering structures[J]. World Earthquake Engineering, 1997, 13(2): 8-20.(in Chinese)
- [2] 王中生,何汉林,廖晓昕. 线性系统极点配置的神经网络算法[J]. 华中科技大学学报(自然科学版), 2002, 30(1): 4-5, 8.

- Wang Z S, He H L, Liao X X. A neural network algorithm for pole assignment in linear systems[J]. Journal of Huazhong University of Science and Technology, 2002, 30(1): 4-5, 8.(in Chinese)
- [3] 郭空明, 江俊. 悬臂 Kagome 夹心板独立模态空间振动控制研究[J]. 振动与冲击, 2015, 34(2): 55-60.
Guo K M, Jiang J. Independent modal space vibration control of cantilever Kagome sandwich plate[J]. Journal of Vibration and Shock, 2015, 34(2): 55-60.(in Chinese)
- [4] 宗长富, 朱天军, 麦莉, 等. 基于全局增益调度控制的重型半挂车主动侧倾控制算法[J]. 机械工程学报, 2008, 44(10): 138-144.
Zong C F, Zhu T J, Mai L, et al. Active roll control algorithm of heavy tractor semi-trailer based on global gain scheduling control[J]. Chinese Journal of Mechanical Engineering, 2008, 44(10): 138-144.(in Chinese)
- [5] 李志军, 刘正洋, 邓子辰. 结构基于 RBF 神经网络的变结构控制研究[J]. 地震工程与工程振动, 2012, 32(6): 136-143.
Li Z J, Liu Z Y, Deng Z C. New variable structure control for buildings using RBF neural network[J]. Journal of Earthquake Engineering and Engineering Vibration, 2012, 32(6): 136-143.(in Chinese)
- [6] Ramezani M, Bathaei A, Ghorbani-Tanha A K. Application of artificial neural networks in optimal tuning of tuned mass dampers implemented in high-rise buildings subjected to wind load[J]. Earthquake Engineering and Engineering Vibration, 2018, 17(4): 903-915.
- [7] Zhang C, Zhang A M, Zhang H, et al. RBF neural networks sliding mode controller design for static var compensator[C]//2015 34th Chinese Control Conference (CCC). July 28-30, 2015, Hangzhou, China. IEEE, 2015: 3501-3506.
- [8] 涂建维, 瞿伟廉. 升船机地震鞭梢效应基于神经网络预测的 MR 智能半主动控制[J]. 噪声与振动控制, 2006, 26(2): 20-23.
Tu J W, Qu W L. Semi-active control over roof MR intelligent isolation system in ship lift based on RBF network prediction[J]. Noise and Vibration Control, 2006, 26(2): 20-23.(in Chinese)
- [9] 李宏男, 金峤. 遗传 BP 神经网络主动 AMD 对偏心结构的减震控制[J]. 地震工程与工程振动, 2003, 23(2): 134-142.
Li H N, Jin Q. AMD active control for irregular buildings using GA-BP neural network[J]. Earthquake Engineering and Engineering Vibration, 2003, 23(2): 134-142.(in Chinese)
- [10] 涂建维, 高经纬, 李召, 等. 基于长短时记忆网络的结构智能控制算法研究[J]. 华中科技大学学报(自然科学版), 2019, 47(12): 110-115.
Tu J W, Gao J W, Li Z, et al. Research on structural intelligent control algorithms based on long short-term memory networks [J]. Journal of Huazhong University of Science and Technology (Natural Science Edition), 2019, 47(12): 110-115.(in Chinese)
- [11] Sarraf S, Tofighi G, Sarraf S, et al. Classification of Alzheimer's disease using fMRI data and deep learning convolutional neural networks[EB/OL]. 2016: 1603.08631. <https://arxiv.org/abs/1603.08631v1>.
- [12] Wu X Y, Peng Z K, Ren J S, et al. Rub-impact fault diagnosis of rotating machinery based on 1-D convolutional neural networks[J]. IEEE Sensors Journal, 2020, 20(15): 8349-8363.
- [13] Xu Y, Li S L, Zhang D Y, et al. Identification framework for cracks on a steel structure surface by a restricted Boltzmann machines algorithm based on consumer-grade camera images[J]. Structural Control and Health Monitoring, 2018, 25(2): e2075.
- [14] 张浩, 刘振娟, 李宏光, 等. 基于关联变量时滞分析卷积神经网络的生产过程时间序列预测方法[J]. 化工学报, 2017, 68(9): 3501-3510.
Zhang H, Liu Z J, Li H G, et al. Process time series prediction based on application of correlated process variables to CNN time delayed analyses[J]. CIESC Journal, 2017, 68(9): 3501-3510.(in Chinese)
- [15] Liu T W, Xu H, Ragulskis M, et al. A data-driven damage identification framework based on transmissibility function datasets and one-dimensional convolutional neural networks: verification on a structural health monitoring benchmark structure[J]. Sensors, 2020, 20(4): 1059.
- [16] Yang H H, Meng C, Wang C. Data-driven feature extraction for analog circuit fault diagnosis using 1-D convolutional neural network[J]. IEEE Access, 2020, 8: 18305-18315.
- [17] Wu H J, Chen J P, Liu X R, et al. One-dimensional CNN-based intelligent recognition of vibrations in pipeline monitoring with DAS[J]. Journal of Lightwave Technology, 2019, 37(17): 4359-4366.
- [18] LeCun Y, Bottou L, Bengio Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.
- [19] Tang Z Y, Chen Z C, Bao Y Q, et al. Convolutional neural network-based data anomaly detection method using multiple information for structural health monitoring[J]. Structural Control and Health Monitoring, 2019, 26(1): e2296.
- [20] 欧进萍. 结构振动控制: 主动、半主动和智能控制[M]. 北京: 科学出版社, 2003.
Ou J P. Structural vibration control: active, semi-active and intelligent control[M]. Beijing: Science Press, 2003.(in Chinese)