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，控制数据海量化，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。

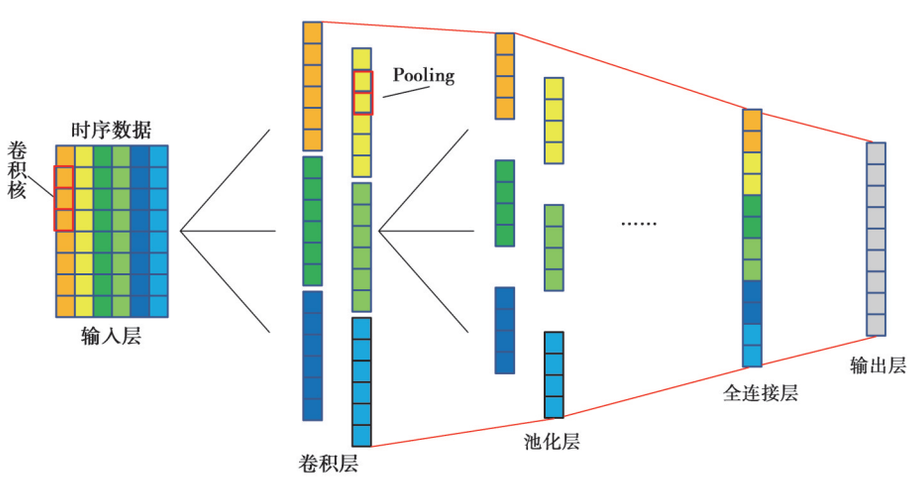


图1　1D-CNN框架结构图

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

$$\boldsymbol{Y}_{d,i,j}=f\left(\sum_{x=0}^{D-1}\sum_{y=0}^{H-1}\sum_{z=0}^{L-1}\boldsymbol{W}_{x-1,y,z}\boldsymbol{X}_{x-1,i+y,j+z}+\boldsymbol{B}\right), \tag{1}$$

式中：$\boldsymbol{Y}_{x,i,j}$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；$\boldsymbol{W}_{x-1,i,j}$为卷积核$x-1$层m行n列权重；$\boldsymbol{B}$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

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

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

$$\left[\frac{W-F}{S}+1\right]\times\left[\frac{W-F}{S}+1\right]。 \tag{3}$$

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

$$\delta_{i,j}^{l}=\sum_{i,i}\frac{\partial E}{\partial \boldsymbol{net}_{i,j}^{l+1}}=\sum_{i,j}\frac{\partial E}{\partial \boldsymbol{\alpha}_{i,j}^{l+1}}\frac{\partial \boldsymbol{\alpha}_{i,j}^{l+1}}{\partial \boldsymbol{net}_{i,j}^{l+1}}, \tag{4}$$

其中，

$$\boldsymbol{net}^{l}=\mathrm{conv}\left(\boldsymbol{W}^{l},X^{l+1}\right)+b, \tag{5}$$

$$\boldsymbol{\alpha}_{i,j}^{l+1}=f^{l+1}\left(\boldsymbol{net}_{i,j}^{l+1}\right), \tag{6}$$

式（4）等号右侧第一、二项可分别表示为

$$\frac{\partial \boldsymbol{\alpha}_{i,j}^{l+1}}{\partial \boldsymbol{net}_{i,j}^{l+1}}=f'\left(\boldsymbol{net}_{i,j}^{l+1}\right), \tag{7}$$

$$\frac{\partial E}{\partial \boldsymbol{\alpha}_{i,j}^{l+1}}=\sum_{m}\sum_{n}\frac{\partial \boldsymbol{E}}{\partial \boldsymbol{net}_{i,j}^{l+1}}\frac{\partial \boldsymbol{net}_{i,j}^{l+1}}{\partial \boldsymbol{\alpha}_{i,j}^{l+1}}=\sum_{m}\sum_{n}\boldsymbol{\delta}_{i,j}^{l+1}\boldsymbol{\omega}_{i,j}, \tag{8}$$

式中：$\boldsymbol{\delta}_{i,j}^{l}$为1层$i$行$j$列误差项；$E$为损失函数；$\boldsymbol{net}^{l}$为$l$行神经元加权输入；$\boldsymbol{\alpha}_{i,j}^{l+1}$为$l$+1层神经元输出；$\boldsymbol{W}^{l}$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

$$\begin{aligned}\boldsymbol{\delta}_{i,j}^{l}&=\sum_{m}\sum_{n}\boldsymbol{\omega}'_{m,n}\boldsymbol{\delta}_{i+m,j+n}^{l+1}f'\left(\boldsymbol{net}_{i,j}^{l+1}\right)=\\&\boldsymbol{\delta}^{l+1}*\boldsymbol{W}^{l+1}\circ f'\left(\boldsymbol{net}^{l+1}\right),\end{aligned} \tag{9}$$

式中：$\boldsymbol{\delta}_{i,j}^{l}$为$l$层$i$行$j$列误差项；$\boldsymbol{net}^{l}$为$l$行神经元加权输入；$\boldsymbol{W}^{l}$为权重矩阵；“∘”指矩阵乘法；$\boldsymbol{\delta}^{l}$、$\boldsymbol{net}_{i,j}^{l+1}$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。为定量化理解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

$$I=\mathrm{deepdreamimage}(\mathrm{net},\mathrm{layer},\mathrm{channels},\mathrm{name},\mathrm{value})。 \tag{10}$$

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

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

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

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。

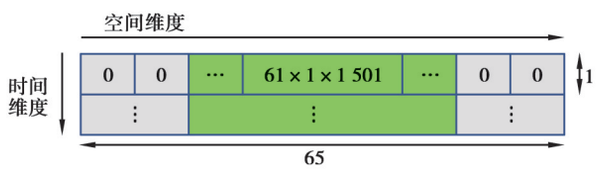


图 2　Conv1 层 0 填充操作示意图

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。

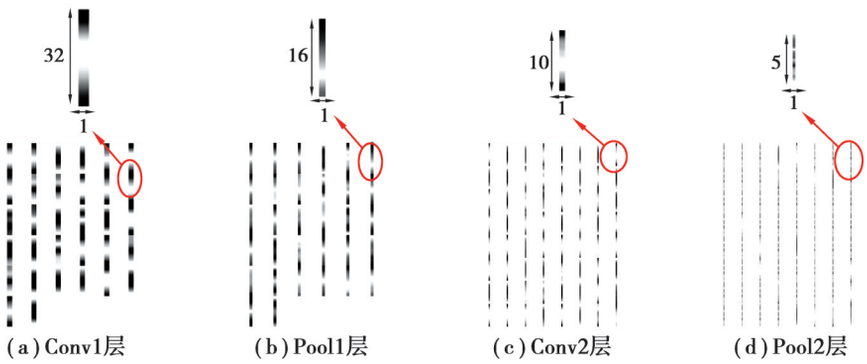


图3 1D-CNN特征可视化效果图

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2 048×1 501，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。

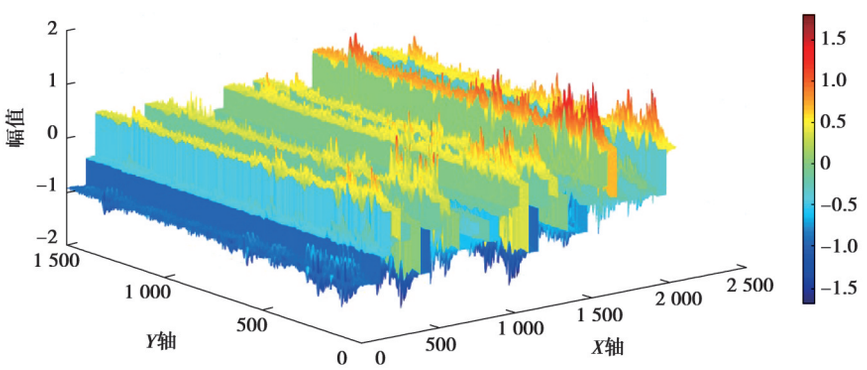


图4 Dropout层完整特征提取

Fig. 4 Complete feature extraction of dropout layer

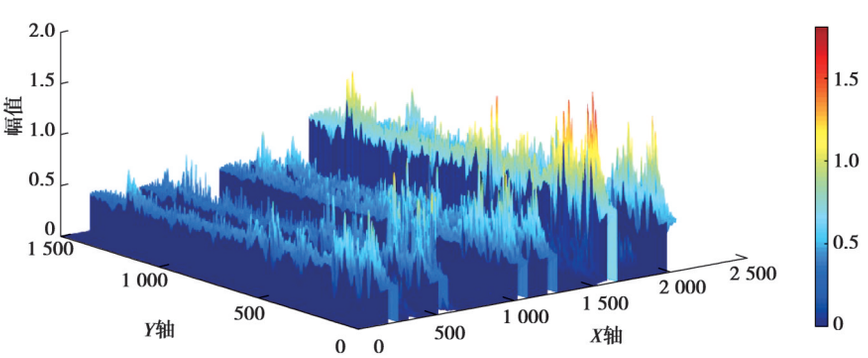


图5 ReLU层完整特征提取

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。

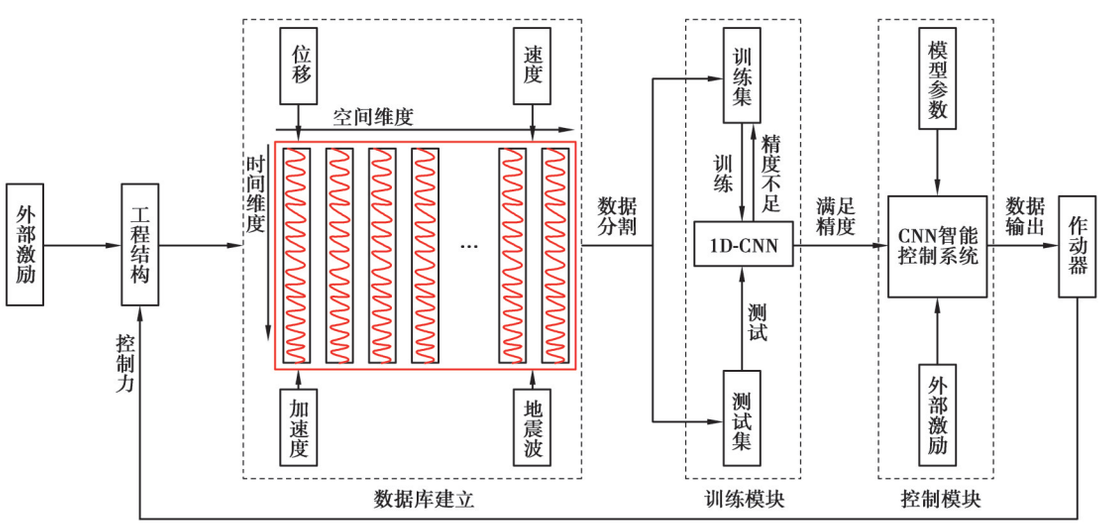


图6　1D-CNN智能控制系统仿真流程图

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

表2　Benchmark模型参数

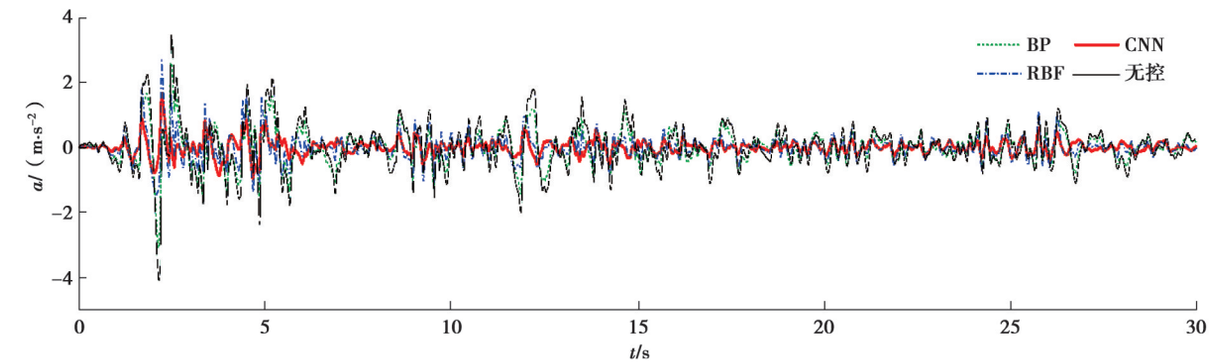
Table 2　Model parameters of benchmark

层数	1	2~5	6~11	12~14	15~17	18~19	20
质量 m/(10^6 kg)	1.126	1.100	1.100	1.100	1.100	1.100	1.170
刚度 k/(10^3 kN·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

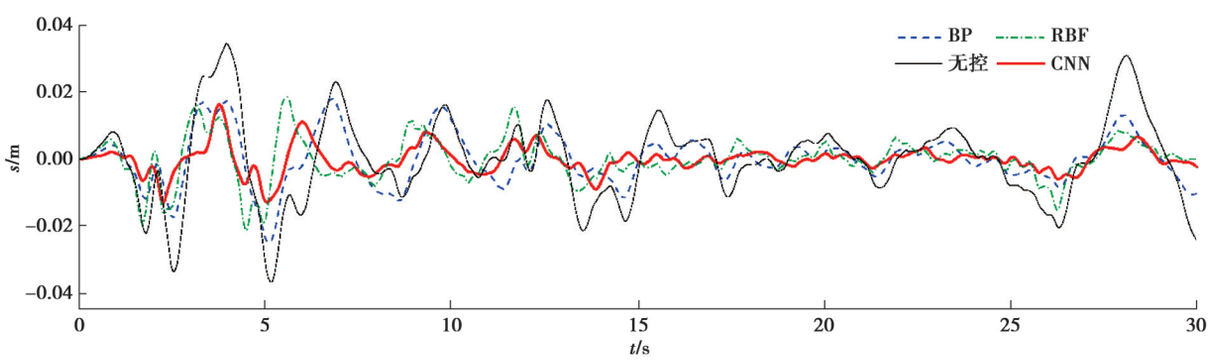
3.3　控制效果对比

为直观了解深度学习控制仿真效果，将持时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%。



(a) 顶层加速度



(b) 顶层位移

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/s²分别下降到2.70 、2.65 、1.28 m/s²，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/s²)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。

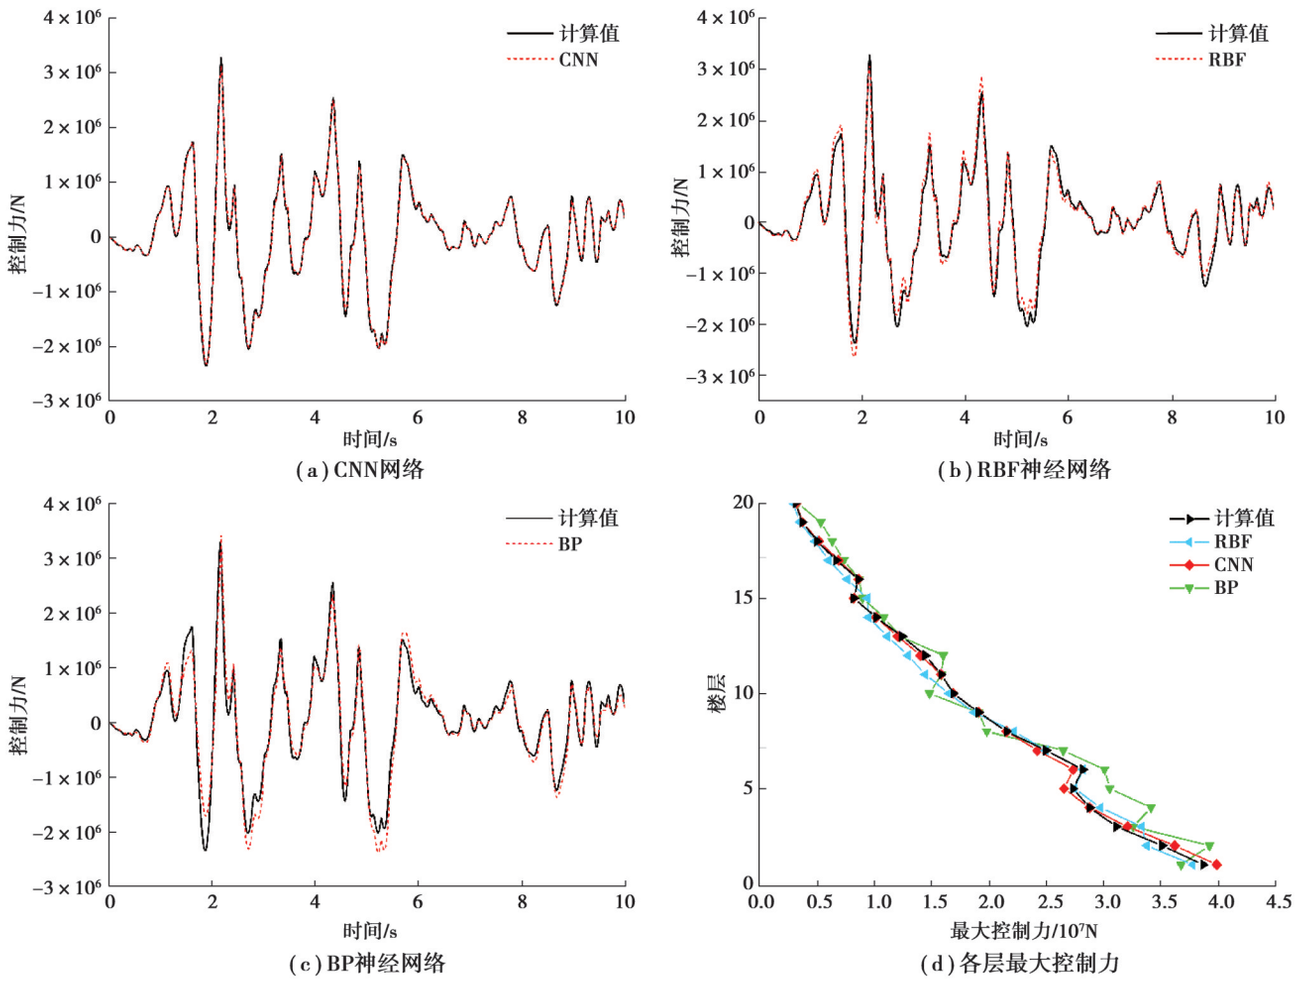


图 8　控制力时程与最大控制力图

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

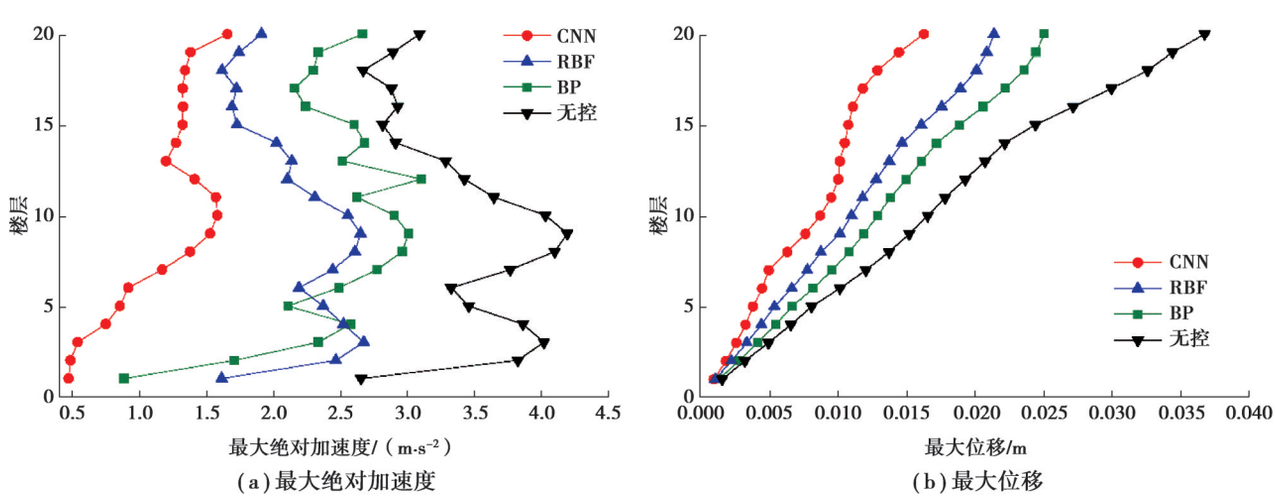


图 9　顶层最大位移和最大绝对加速度

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)

（编辑　陈移峰）