

基于神经网络的混凝土柱峰值承载力预测

林庄慧* 唐和生 李大伟 薛松涛

(同济大学结构防灾减灾工程系,上海 200092)

摘要 提出了基于人工神经网络预测钢筋混凝土柱峰值承载力的方法。该方法采用5个设计参数作为神经网络的输入:混凝土强度、轴压比、剪跨比、纵筋配筋率和纵筋屈服强度。为验证该方法的可行性与有效性,基于PEER 154组实验数据,利用神经网络模型对矩形混凝土柱的峰值承载力进行预测并与经验模型的预测结果进行比较。比较分析结果表明:神经网络模型预测结果与实验结果吻合度远高于其他经验模型;同时也表明神经网络为精确预测结构在地震作用下的性能提供了一种新方法。

关键词 神经网络,钢筋混凝土柱,预测精度,峰值承载力

DOI:10.15935/j.cnki.jggcs.2019.01.023

Prediction of the Peak Load Capacity of RC Columns by Neural Network

LIN Zhuanghui* TANG Hesheng LI Dawei XUE Songtao

(Disaster Mitigation for Structure, Tongji University, Shanghai 200092, China)

Abstract An artificial neural network method for the prediction of the peak load capacity of RC columns was presented in this paper. In this method, 5 design parameters: concrete compression stress, axial load ratio, aspect ratio, longitudinal reinforcement ratio and longitudinal reinforcement yield strength were chosen as inputs of the ANN. In order to demonstrate the feasibility and effectiveness of proposed method, the ANN models were applied to predict the peak load capacity of rectangular RC columns using 154 sets of experimental data provided by PEER. Furthermore, the predicted results were compared with empirical model results. Comparative analysis showed that prediction degree of agreement with the experimental results of ANN models is much better than that of other empirical prediction models. Meanwhile, the result reveals that the proposed method provides a novel way for accurately estimating structural performance under earthquake.

Keywords neural network, RC columns, prediction accuracy, peak load capacity

0 引言

基于性能的地震工程^[1](PBEE)和基于性能的抗震设计^[2](PBSD)要求建筑结构在使用期限内实现预定的性能目标。对于建筑结构体系中的重要形式——钢筋混凝土框架结构,其抗震性能主要由竖向承重构件钢筋混凝土柱决定,故混凝土柱在水平往复地震作用下的受力性能对于结构抗震设计与性能评估具有重要意义。需对钢筋混

凝土柱的抗震性能进行合理研究,对混凝土柱在水平往复荷载作用下的性能曲线(力-位移骨架曲线)进行准确刻画。

国内外学者对钢筋混凝土柱性能曲线上的特征点与性能点(如屈服位移、极限位移、峰值承载力等)作了许多预测研究。Fardis^[3]基于1000多组单向受弯混凝土柱的实验数据,通过回归分析模型分别建立了柱屈服转角、极限转角与设计参数之间的关系式。Bae^[4]采用混凝土柱力-位移曲线的理想化模型,简化了非线性拟合得到的极限

收稿日期:2017-05-11

* 联系作者:林庄慧,Email:lzhui69@163.com

位移公式。Erberik^[5] 基于能量方法研究了退化钢筋混凝土体系的非线性行为,并提出体系在地震作用下变形能力要求的计算公式。Perus^[6] 采用了无参数的 CAE 方法对混凝土柱性能曲线上各性能点进行预测。蒋欢军^[7] 建立了半经验模型预测塑性铰的长度,由塑性铰长度得到混凝土柱在一系列地震破坏状态下的水平位移。钱稼茹^[8] 建议了钢筋混凝土柱的四折线弯矩-转角骨架曲线并给出特征点和性能点的定义,他以柱峰值承载力降低 20% 作为极限状态,提出了混凝土柱极限转角的计算公式^[9]。

综合以往对混凝土柱骨架曲线上性能点的预测研究,大多通过非线性拟合建立参数之间的相关关系。基于拟合的经验模型对混凝土柱性能点的预测精度有限,加之混凝土的复杂非线性行为等不确定因素,经验公式的预测精确性存在较大离散。非线性拟合仅得到参数间简单的表达式,人工神经网络作为建立变量间复杂非线性映射的计算模型而受到研究中的关注。人工神经网络(Artificial Neural Network, ANN) 简称神经网络^[10-11] 是 20 世纪 40 年代以来迅速发展起来的模拟人脑神经活动的新技术,它是一种适用于处理复杂非线性关系的计算模型,特别对求解内部机制天生复杂的问题。人工神经网络能建立任意输入变量到输出变量的复杂非线性映射,其强大的计算能力与泛化性能使之在多个领域得到应用。例如在自动控制领域中,神经网络用于系统建模与辨识、PID 参数整定、极点配置、优化设计、自适应控制等^[12]; 在土木工程领域中,神经网络用于新浇筑混凝土最高温度的预测^[13]、混凝土抗压强度预测^[14] 等。

本文基于 PEER 柱性能数据库中的 154 组样本,通过建立人工神经网络模型,对矩形混凝土柱的峰值承载力进行预测研究。通过网络模型预测结果与实验结果的对比,以及网络模型与经验模型预测精度的对比,探究神经网络用于柱性能预测的可行性与有效性。通过对神经网络模型的敏感性分析,研究输入变量对输出变量的贡献程度,从而得到输入因子对网络预测的影响规律。

1 经验公式预测柱样本

1.1 研究样本

本文的研究样本来自 PEER 柱性能数据库

(PEER Structural Performance Database)^[15]。样本柱满足以下条件:①矩形截面柱;②剪跨比大于 2;③受往复荷载作用直至失效;④失效模式为弯曲破坏。依据遴选条件选出 154 组样本构成本研究的数据库。本研究考虑了柱的五个设计参数:①混凝土强度(f_c);②轴压比($n_0 = F/A_f c$);③剪跨比($\lambda = L/H$);④纵向钢筋的配筋率(ρ_l);⑤纵向钢筋的屈服强度(f_{yt})。样本数据库的这 5 个属性分布范围如表 1 所示,参数分布涵盖了常见的参数设计范围。

表 1 柱性能数据库的主要参数分布
Table 1 Range of main parameters of column database

设计参数	范围
f_c /MPa	21.1 ~ 118
n_0	0 ~ 0.8
λ	2 ~ 5.5
ρ_l	0.012 5 ~ 0.060 3
f_{yt} /MPa	339 ~ 587.05

1.2 经验公式预测柱的峰值承载力

Park^[16] 在《混凝土结构设计》中给出了混凝土柱峰值水平承载力的预测公式,见式(1)和式(2),由于样本柱实验的 $P-\Delta$ 效应不明显,可将其忽略。

$$M_u = \rho b d^2 f_y \left(1 - 0.59 \frac{\rho f_y}{f_c} \right) \quad (1)$$

$$F = \frac{M_u}{L} \quad (2)$$

式中: ρ 为纵向钢筋配筋率; f_y 为纵向钢筋的屈服强度; f_c 为混凝土抗压强度; b 、 d 、 L 为柱的截面宽度、截面高度及柱高。

用 Park 的经验公式对 154 组研究样本进行预测,预测值用峰值水平承载力与截面抗压承载力之比 η 表示($\eta = F_{\text{capping}}/A_g f_c$)。预测结果与实验结果的对比见图 1 和表 2。由图 1 和表 2 可知,样本预测值与实验值的相关系数 R 小于 0.8,表明二者线性相关程度不强。图 1 中的数据点分布相当离散,预测值与实验值比值的变异系数为 0.302,表明预测值与实验值的比值分布离散程度大。预测值与实验值之比的均值大于 1,这与图 1 中大多数数据点分部于直线 $Y = X$ 上方相符,预测误差较大。故经验模型对混凝土柱峰值承载力的预测存在离散程度大的问题。




图1 经验模型预测柱的峰值承载力

Fig.1 Peak load capacity prediction of empirical model

表2 经验模型预测结果的实验验证

Table 2 Experimental verification of the empirical model

预测值与实验值的相关系数	预测值/实验值		
	范围	均值	变异系数
0.009 2	[0.457 2.245]	1.25	0.302

2 神经网络

2.1 BP 神经网络

神经网络的本质是一个计算模型,可以建立任意输入与输出之间的非线性映射,适合处理复杂的非线性关系,具有较好的自主学习能力和泛化能力。根据神经网络连接的拓扑结构,可以将神经网络分为前向型网络和反馈网络。前向型网络中信号的流向是从输入通向输出,网络中间无反馈。而反馈网络中神经元间有反馈,使得输出信号得以返回输入端,从而形成一个回路。

BP神经网络是一种采用误差反向传播学习算法的多层前向型网络。BP神经网络通常采用三层的结构形式,包含一个输入层、一个隐含层和一个输出层,见图2。网络的每一层由若干个节点组成,每个节点代表一个神经元,层与层之间的节点通过权值 w 和阈值 b 连接。网络的训练包含两个过程:一是输入训练样本,初始化网络的权值 w 和阈值 b ,逐层向后得到输出;二是从网络最后一层向前计算各个权值和阈值对输出误差的影响梯度,从而修正权值和阈值。训练的正向和逆向过程交替反复进行,直至误差收敛至一定精度。

神经网络采用均方差 (MSE) 作为性能函数,依据方程式 (3) 和式 (4) 求出网络估计值和目标值之间的均方差,以此作为网络预测性能评估的依据。




图2 三层神经网络

Fig.2 Three-layer neural network

$$e = t - y \tag{3}$$

$$MSE = \frac{1}{n} \left(\sum_{i=1}^n e_i^2 \right) \tag{4}$$

式中: e 是误差; t 是目标值; y 是网络的输出估计值; n 是输出向量中的样本数。

本文建立了三层的BP神经网络,输入层有5个节点,对应5个输入参数:①混凝土强度 (f_c); ②轴压比 ($n_0 = F/Af_c$); ③剪跨比 ($\lambda = L/H$); ④纵向钢筋的配筋率 (ρ_l); ⑤纵向钢筋的屈服强度 (f_{yl})。隐含层节点数取5~20。输出层含1个节点,对应输出值 $\eta = F_{capping}/A_g f_c$ 。网络训练前对样本数据进行归一化处理,将数据限制在0.1~0.9范围内,以加快网络训练的收敛速度。

本研究中网络的学习算法为LM算法,LM算法适于训练中型网络,具有内存需求量大、收敛速度最快、保证全局优化的特点。其迭代式见式(5)。

$$x(k+1) = x(k) - [J^T J + \mu J]^{-1} J^T e \tag{5}$$

式中: $J^T J$ 为包含网络误差函数对权值和阈值一阶导数的雅克比矩阵; e 为网络的误差向量; μ 为调节因子,保证网络的性能函数始终在减小。

2.2 神经网络预测柱的峰值承载力

将研究样本进行分组,以训练组样本具有良好代表性为目标,从154组样本中选出107组构成训练组,其余样本中23组作为校正组、24组作为测试组。构建三层的BP神经网络,隐含层节点数取5~20个,训练网络使其达到一定精度 (1×10^{-5}),网络模型的性能值 (MSE) 见表3。在表3中, N 5-10-1 表示包含5个输入节点、10个隐含层节点和1个输出节点的网络。表中列出了16个神经网络模型预测训练组、测试组和总体样本的均方差 MSE , MSE 数值基本为 10^{-6} 数量级,表明网络预测值和实验值的平均差异很小。综合比较三个 MSE 值,网络 N 5-10-1、N 5-17-1 和 N 5-18-1 具有较小的预测误差。

表 3 网络模型的性能值
Table 3 Performance value of ANN models

BP_ANN Model	MSE/(× 10 ⁻⁶)			BP_ANN Model	MSE/(× 10 ⁶)		
	训练组	测试组	总样本		训练组	测试组	总样本
N5-5-1	8.688 7	9.116 6	8.755 4	N5-13-1	4.131 2	8.409 7	4.798 0
N5-6-1	7.666 3	9.135 5	7.895 2	N5-14-1	4.706 2	7.514 5	5.143 8
N5-7-1	6.150 4	5.878 8	6.108 1	N5-15-1	4.033 0	11.67 4	5.223 8
N5-8-1	4.942 2	7.738 4	5.378 0	N5-16-1	4.648 0	10.03 0	5.486 8
N5-9-1	4.653 5	23.01 2	7.514 5	N5-17-1	3.391 6	6.521 7	3.879 4
N5-10-1	3.864 6	7.000 6	4.353 3	N5-18-1	3.653 2	6.836 7	4.149 3
N5-11-1	4.616 4	6.470 2	4.905 3	N5-19-1	3.885 2	9.374 0	4.740 6
N5-12-1	5.504 3	7.274 9	5.780 3	N5-20-1	4.878 3	9.416 2	5.585 5

网络模型预测值与实验值之比的变异系数反映了网络对样本估计的总体误差水平,不同网络对应的变异系数见图 3。随着隐含层节点数的变化,训练组、测试组和总样本的变异系数在 0.04 ~ 0.08 范围内变动。除网络 N 5-9-1 出现较大值外,测试组的变异系数基本在 0.05 ~ 0.07 范围内,表明网络应用于测试组样本预测的预测精度高且预测性能稳定。当隐含层节点数大于 10 时,训练组、测试组和总样本的变异系数波动范围都进一步缩小,表明这些网络的预测水平趋于稳定。

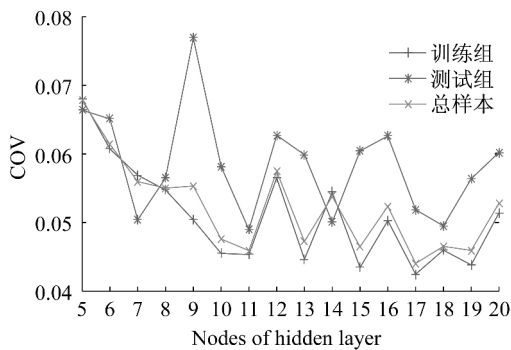


图 3 不同隐含层节点数对应的变异系数
Fig. 3 Coefficient of variance corresponding to different hidden layer nodes

为了进一步检验网络模型的预测能力,对隐含层节点数为 10 ~ 20 的网络对总体样本的预测结果作进一步验证,见表 4。表中各网络对应比值的均值都接近 1,比值关于 1 在较小的范围内上下波动,偏差不超过 0.271,表明整体上网络的预测结果与实验结果吻合。预测值与实验值比值的变异系数稳定在 0.05 附近,远小于 Park^[16] 经验模型的对应值 0.302,网络模型的预测值关于实验值的离散程度很小,表明网络预测的整体误差水平低且预测稳定,神经网络模型的预测精度远高于经验模型。

表 4 预测结果与实验结果的对比
Table 4 Comparison of predicted results and experimental results

BP_ANN Model	预测值 / 实验值		
	范围	均值	变异系数
N5-10-1	0.842 ~ 1.232	0.999	0.0476
N5-11-1	0.855 ~ 1.228	0.999	0.0459
N5-12-1	0.840 ~ 1.266	0.992	0.0575
N5-13-1	0.857 ~ 1.241	0.997	0.0473
N5-14-1	0.860 ~ 1.271	1.003	0.0538
N5-15-1	0.850 ~ 1.233	1.002	0.0465
N5-16-1	0.858 ~ 1.235	1.000	0.0524
N5-17-1	0.848 ~ 1.218	1.002	0.0441
N5-18-1	0.860 ~ 1.242	1.000	0.0465
N5-19-1	0.850 ~ 1.221	0.999	0.0460
N5-20-1	0.829 ~ 1.190	1.012	0.0528

由表 4,网络 N 5-17-1 取得最小变异系数 0.044 1,其精度最高,将网络 N 5-17-1 对样本的预测结果绘制成图 4。图中训练组与测试组的数据点集中分布在直线 Y = X 附近,网络预测结果与实验值的偏差基本在 ± 15% 范围内。网络输出值与实验值之间的相关系数 R = 0.995 5,线性相关程度很强,表明网络预测值与实验值高度吻合。

3 敏感性分析

敏感性分析^[17]是研究一个数值模型输入变量对输出变量重要性程度的方法,它用敏感性系数来衡量输入的重要性,敏感性系数越大,该输入因子对模型输出的影响程度越大。神经网络的局部敏感性分析通常有:基于连接权的敏感性分析方法;基于输出变量对输入变量的偏导的敏感性分析方法;结合统计方法的敏感性分析方法;基于输入变量扰动的敏感性分析方法。Garson 算




图4 网络模型 N 5-17-1 预测柱的峰值承载力
Fig. 4 Peak load capacity prediction results of N5-17-1 model

法^[18]是基于连接权的敏感性分析的一个代表,它利用神经网络连接权值的乘积来计算输入对输出的贡献程度。以一个单输出的三层前向型神经网络为例,输入层、隐含层和输出层的节点个数分别为 $N, H, 1$, $w = (w_{ij})_{N \times H}$ 为输入层与隐含层间的连接权重, $v = (v_j)_{H \times 1}$ 为隐含层到输出层间的连接权重, Q_i 表示输入变量 x_i 对输出的敏感性系数,其计算表达式见式(6)。

$$Q_i = \frac{\sum_{j=1}^H (|w_{ij}v_j| / \sum_{i=1}^N |w_{ij}v_j|)}{\sum_{j=1}^H \sum_{i=1}^N (|w_{ij}v_j| / \sum_{i=1}^N |w_{ij}v_j|)} \quad i = 1, 2, \dots, N; \quad j = 1, 2, \dots, H. \quad (6)$$

对网络模型 N 5-17-1 进行敏感性分析,得到各输入参数对网络输出的重要性程度,即各输入因子对网络模型预测的影响程度,分析结果见图5。由图5可知,纵筋屈服强度对网络预测的影响最大,纵筋配筋率和剪跨比的影响次之,混凝土强度和轴压比对网络预测的影响最小。




图5 网络模型 N 5-17-1 敏感性分析结果
Fig. 5 Sensitivity analysis results of N5-17-1 model

4 结论

本文提出了用人工神经网络预测混凝土柱峰值承载力的方法,以柱的5个设计参数作为神经网络的输入:混凝土强度、轴压比、剪跨比、纵向钢筋配筋率和纵向钢筋屈服强度,神经网络模型的输出结果与实验结果高度吻合,表明神经网络建立了输入变量与输出变量之间的可靠关系。对比经验模型的预测结果,神经网络具有更高的预测精度。最后利用 Garson 敏感性分析法,得到输入因子对网络预测的影响规律。本文证明了神经网络方法预测混凝土柱峰值承载力的可行性与有效性。神经网络可以有效发掘变量之间隐含的复杂非线性关系,它开辟了一条高效建立数据之间可靠关系的新途径,可作为高精度数据预测的有效手段。

参考文献

- [1] Cornell C A ,Krawinkler H. Progress and challenges in seismic performance assessment [J]. PEER Center News 2000 ,3(2) : 1-3.
- [2] SEAOC V C. Performance-based seismic engineering [S]. Structural Engineers Association of California , Sacramento ,California ,1995.
- [3] Panagiotakos T B ,Fardis M N. Deformations of reinforced concrete members at yielding and ultimate [J]. ACI Structural Journal 2001 ,98(2) : 135-148.
- [4] Bae S ,Bayrak O. Drift capacity of reinforced concrete columns [J]. ACI Structural Journal 2009 ,106(4) : 405-415.
- [5] Erberik M A ,Lu H S ,Acun B. Inelastic Displacement Response of RC Systems with Cyclic Deterioration—An Energy Approach [J]. Journal of Earthquake Engineering 2012 ,16(7) : 937-962.
- [6] Peruš I ,Fajfar P. Prediction of the force-drift envelope for RC columns in flexure by the CAE method [J]. Earthquake Engineering & Structural Dynamics , 2007 ,36(15) : 2345-2363.
- [7] Jiang H ,Lu X ,Kubo T. Damage displacement estimation of flexure-dominant RC columns [J]. Advances in Structural Engineering 2010 ,13(2) : 357-368.
- [8] 钱稼茹,冯宝锐. 钢筋混凝土柱弯矩-转角骨架线特征点及性能点转角研究 [J]. 建筑结构学报, 2014 , 35(11) : 10-19.

Qian Jiaru ,Feng Baorui. Study on rotation angles at

- characteristic point and performance point of M- θ skeleton curve for RC columns [J]. Journal of Building Structures 2014 35(11): 10-19. (in Chinese)
- [9] 钱稼茹,徐福江. 钢筋混凝土柱基于位移的变形能力设计方法[J]. 建筑结构 2007 37(12): 30-32.
Qian Jiaru, Xu Fujiang. Displacement-based deformation capacity design of RC columns [J]. Building Structure 2007 37(12): 30-32. (in Chinese)
- [10] 张德丰. MATLAB 神经网络应用设计 [M]. 北京: 机械工业出版社 2011.
Zhang Defeng. MATLAB application and design of neural network [M]. Beijing: China Machine Press, 2011. (in Chinese)
- [11] Haykin Simon, 叶世伟, 史忠植. 神经网络原理 [M]. 北京: 机械工业出版社 2004.
Haykin Simon, Ye Shiwei, Shi Zhongzhi. Neural networks [M]. Beijing: China Machine Press, 2004. (in Chinese)
- [12] 王学武, 谭得健. 神经网络的应用与发展趋势 [J]. 计算机工程与应用 2003 39(3): 98-100.
Wang Xuewu, Tan Dejian. Application and developing trends of neural network [J]. Computer Engineering and Applications 2003 39(3): 98-100. (in Chinese)
- [13] 杜晓帆, 卢兴毅, 张文熙. BP 神经网络在新浇筑混凝土最高温度预测中的应用 [J]. 水电能源科学, 2013 31(5): 70-72.
Du Xiaofan, Lu Xingyi, Zhang Wenxi. Application of BP neural network in predicting maximum temperature of pouring concrete [J]. Water Resources and Power, 2013 31(5): 70-72. (in Chinese)
- [14] 李红, 彭涛. 基于 BP、RBF 神经网络混凝土抗压强度预测 [J]. 武汉理工大学学报, 2009 31(8): 33-36.
Li Hong, Peng Tao. Prediction of concrete compression strength based on BP and RBF neural network theories [J]. Journal of Wuhan University of Technology, 2009 31(8): 33-36. (in Chinese)
- [15] PEER. Peer structural performance database [DB/OL]. [2003-42-29]. <http://nisee.berkeley.edu/spd.e>
- [16] Park R, Paulay T. Reinforced concrete structures [M]. John Wiley & Sons, 1975.
- [17] 董现, 王湛. 基于改进混沌粒子群的混合神经网络和蒙特卡洛法结构随机灵敏度分析方法 [J]. 工程力学 2015 32(12): 49-57.
Dong Xian, Wang Zhan. Stochastic sensitivity analysis method based on hybrid neural network or improved chaotic particle swarm and monte carlo [J]. Engineering Mechanics 2015 32(12): 49-57. (in Chinese)
- [18] Garson D G. Interpreting neural network connection weights [J]. AI Expert, 1991 6(4): 46-51.