

基于神经网络算法的建筑结构振动分散控制研究

汪 权^{*1,2}, 王 文¹, 韩新节¹, 韩强强¹, 周超杰¹

(1. 合肥工业大学 土木与水利工程学院, 合肥 230009;

2. 土木工程防灾减灾安徽省工程技术研究中心, 合肥 230009)

摘 要:针对地震作用下建筑结构振动分散控制问题,引入神经网络算法,研究结构振动分散神经网络控制策略,来解决分散控制中各子系统的耦合问题和神经网络算法的训练成本问题。利用径向基函数 RBF(Radical Basis Function)神经网络模型并基于 newrb 函数构建了 RBF 神经网络控制器,对某 20 层 Benchmark 结构模型分别进行集中控制和多工况子系统划分分散控制的数值模拟分析,结果表明,提出的各子系统耦合的分散 RBF 神经网络振动控制策略考虑了子系统间的信息共享,可有效控制结构的振动响应,且子系统达到理想训练结果所需的训练次数与 BP 网络相比显著降低。

关键词:分散控制;地震作用;神经网络;径向基函数

中图分类号:O327;TP183

文献标志码:A

文章编号:1007-4708(2021)05-0580-06

1 引 言

目前结构振动控制形式中,分散控制是针对集中控制中一旦中央处理器损坏会导致整个控制系统失效的缺陷所提出的,若想取得更精确的控制效果,应考虑分散控制各子系统间的信息共享问题,即控制耦合问题。神经网络算法则是依托大量的数据进行反复训练来构建一个近似于原模型的网络结构,不需要传统控制算法依赖的精确数学模型,但缩减训练成本是其能否拓展工程应用领域的关键。

建筑结构振动分散控制考虑各子结构相应子系统耦合问题的研究取得了一定的成果。文献[1-4]基于传统控制算法实现了建筑结构振动分散控制形式下的各子系统控制耦合问题,汪权等^[5,6]将包含原理与线性二次型最优控制原理和 H_∞ 鲁棒控制相结合,通过扩展分解控制系统及协调收缩获得重叠分散控制器,虽然控制效果良好,但算法需要建立控制结构对象的精确数学模型进行推导,较为复杂。

神经网络极强的非线性映射特性、信息并行处理、自学习和泛化能力使其在建筑结构振动控制领域得到了广泛应用。文献[7-11]用神经网络算法预测了地震作用下结构的未来响应,取得了较好的

控制效果,但忽视了其在集中控制下的训练成本等问题。

目前人工神经网络模型有数十种之多,其中较为典型的有 BP 和 RBF 神经网络等,汪权等^[12]将 BP 神经网络和分散控制相结合,成功应用于 20 层 Benchmark 结构模型,该方法能简化神经网络的结构且能有效地控制结构振动响应,并消除时滞,但未指出神经网络与分散控制相结合是否考虑了分散控制中的控制耦合问题。杜永峰等^[13]在结构动力响应预测方面指出 RBF 神经网络学习速度更快,动态仿真性更强。潘兆东等^[14]借助 RBF 神经网络通过设置全局控制器消除了子系统间的关联耦合。

本文将 RBF 神经网络与分散振动控制相结合进行研究,主要包括设计考虑各子系统间耦合作用的 RBF 神经网络算法近似模型,同时通过数值计算分析其神经网络算法的训练量。选取 20 层 Benchmark 建筑结构模型为对象,分别进行了集中控制和将结构分别划分为 2 个、4 个及 5 个子结构的分散控制^[5],比较分析基于 RBF 神经网络算法的分散控制效果及训练次数。

2 RBF 神经网络结构模型

RBF 神经网络的思想是,隐含层神经元的激活函数采用径向基函数(RBF)构成隐含层的转换空间,将低维的输入转换到隐含层的高维空间中,

收稿日期:2020-08-07;修改稿收到日期:2020-09-08.

基金项目:国家自然科学基金(51408178)资助项目.

作者简介:汪 权*(1981-),男,博士,副教授,硕士生导师

(E-mail:wqhfut@163.com);

使得原来在低维空间中的非线性问题转换成高维空间的线性问题。RBF神经网络是一种局部逼近神经网络,在网络训练时只有少量样本数据输入才会对网络的权值和阈值进行调整;另外 RBF 神经网络的隐含层激活函数采用的是径向基函数,并且网络训练只需调整输出层的权值和阈值,因此 RBF 神经网络学习速率快,实时性好。

本文 RBF 神经网络采用单隐层的三层前馈型神经网络,其网络结构包括输入层、隐含层和输出层。其隐含层的激活函数采用径向基函数,输出层的激活函数采用线性函数,其网络结构如图 1 所示。




图 1 RBF 神经网络结构模型

Fig. 1 RBF neural network structure model

网络的输入层包括 n 个神经元节点连接信号的输入,输入向量为 $\mathbf{X}=[x_1, x_2, \dots, x_n]^T$; 隐含层包括 q 个神经元节点,将输入信号转换到隐含层空间,隐含层输出向量为 $\mathbf{V}=[v_1, v_2, \dots, v_q]^T$, $G(\cdot)$ 表示径向基函数;输出层包括 m 个神经元节点,输出层的输出向量为 $\mathbf{Y}=[y_1, y_2, \dots, y_m]^T$, 输出层的激活函数常采用线性激活函数。

期望输出向量为 $\mathbf{D}=[d_1, d_2, \dots, d_m]^T$ 。隐含层到输出层的权值矩阵为 W_{jk} , 表示隐含层第 j 神经元到输出层第 k 神经元的权值。

网络隐含层采用径向基函数,采用高斯函数,

$$G(x) = e^{-\|x-c\|^2/\sigma^2} \quad (1)$$

c 与 σ 分别表示隐含层神经元径向基函数的数据中心点宽度参数, $\|\cdot\|$ 表示距离函数。

从隐含层到输出层为线性输出,输出为

$$y_k = \sum_{j=1}^q \omega_{jk} v_j + b_k \quad (k=1, 2, \dots, m) \quad (2)$$

式中 b_k 为输出层神经元的阈值向量。

3 RBF 神经网络学习算法

采用 MATLAB 软件的 newrb 函数来构建 RBF 神经网络,其表达式为

$$\text{net} = \text{newrb}(\mathbf{P}, \mathbf{T}, \text{goal}, \text{spread}, \text{MN}, \text{DF}) \quad (3)$$

式中 $\mathbf{P}$ 为输入向量, $\mathbf{T}$ 为输出向量, goal 为均方差的目标(期望误差), spread 为径向基函数的扩展速度(反映径向基函数的宽度参数 σ , 简记为 S , $S = \sigma \sqrt{-\ln(0.5)}$), MN 为最大的神经元个数,即神经元个数到 MN 后立即停止(本文有 500 个采样数据,设 $\text{MN}=500$), DF 为每次加进来的网络神经元个数(本文设为 1,则构建网络的训练次数为隐含层神经元个数)。

newrb 的算法是在有输入向量 $\mathbf{P}$ 与输出向量 $\mathbf{T}$ 的情况下,先预设好期望误差、扩展速度 S 以及每次隐含层神经元节点个数增加次数,然后假定初始隐含层无神经元节点,把开始误差最大的输入向量作为权值向量(即数据中心 c),可计算出隐含层输出向量 $\mathbf{V}$, 并根据隐含层输出向量 $\mathbf{V}$ 与 $\mathbf{T}$ 以最小误差为目的对输出层权重 W_{jk} 与 b_k 进行修改(采用最小二乘法),最后依次增加隐含层神经节点个数重复进行上述运算,直到网络的误差降到预期误差以下或达到最大训练次数。

扩展速度 S 越大,函数的拟合就越平滑,且过大或过小的 S 均需要非常多的神经元以适应函数的快速变化或缓慢变化。本文通过试算来确定扩展速度 S , 首先将集中控制及分散控制的第一个子系统期望误差设为 1×10^{-7} , 而分散控制的其他子系统由于数据较集中且控制数据少,在保证总体误差的情况下可适当减小平均误差(期望误差);然后在 newrb 函数中不断调整扩展速度 S 来比较训练后的训练次数与训练误差,从而得出一个较优值。

4 算 例

为了验证建筑结构分散控制与 RBF 神经网络相结合所设计的考虑各子系统耦合作用的 RBF 神经网络模型的控制效果,以及分析该网络模型的计算成本,将该算法应用于 20 层 Benchmark 抗震钢结构模型控制对象,使用的神经网络辨识器和控制器均是 RBF 神经网络,该模型结构具体的楼层质量、刚度参数和结构布置等详见文献[15]。

4.1 RBF 神经网络结构

神经网络辨识器输入为前两个时刻结构 1~20 层每层的位移、速度、当前时刻每层的控制力和地震加速度,故其神经元节点数为 $2 \times (20+20) + 20+1=101$; 输出为下一时刻结构 1~20 层每层的位移、速度和加速度响应,故其神经元节点数为 $20+20+20=60$ 。RBF 神经网络辨识器取期望误差 $\text{MSE}=1.0 \times 10^{-8}$, 径向基函数的扩展速度试算

为 $S=100$, 隐含层神经元个数由网络训练自动确定为 16, 达到的训练误差为 $MSE=4.2487 \times 10^{-9}$ 。综上 RBF 神经网络辨识器的网络结构为 $101 \times 16 \times 60$ 。

神经网络控制器输入为辨识器得出的下一时刻结构 1~20 层每层的位移、速度响应和地震加速度, 输出为下一时刻结构 1~20 层每层的控制力。

对于神经网络集中控制器设计, 取期望误差 $MSE=1.0 \times 10^{-7}$, 径向基函数的扩展速度试算为 $S=5.2$, 隐含层神经元个数可由 newrb 函数在建立并训练 RBF 神经网络控制器的过程中自动确定为 25, 训练误差为 $MSE=7.69795 \times 10^{-8}$, 综上 RBF 神经网络集中控制器的网络结构为 $41 \times 25 \times 20$ 。

对于神经网络分散控制器设计, 分别将结构每 10 层 (Case 1)、每 5 层 (Case 2) 和每 4 层 (Case 3) 划分为 1 个子系统, 如图 2 所示三种工况进行研究。




图 2 子系统划分工况
Fig. 2 Sub-systems divided cases

Case 1: 将结构从 1~10 层和 11~20 层划分为两个子系统。

Case 2: 将结构从 1~5 层、6~10 层、11~15 层和 16~20 层划分为四个子系统。

Case 3: 将结构从 1~4 层、5~8 层、9~12 层、13~16 层和 17~20 层划分为五个子系统。

以上分散控制的三个工况各子系统神经网络控制器径向基函数的期望误差及扩展速度列入表 1, 隐含层神经元个数同理可由 newrb 函数在建立并训练 RBF 神经网络控制器的过程中自动确定, 训练误差和神经网络分散控制器的网络结构列入表 1。

4.2 RBF 神经网络分散控制效果

RBF 神经网络辨识器和控制器的训练数据分别采用 20 层 Benchmark 模型结构在地震激励 El Centro (NS, 1940) 波 (加速度峰值为 3.147 m/s^2) 作用下, 由 LQR 算法计算得到的结构地震响应前 500 个采样时刻数据 (采样周期为 0.02 s)。本文采用 MATLAB 的 Simulink 模块进行数值仿真, 以 Case 3 为例, 该分散控制系统如图 3 所示。

为了评价 RBF 神经网络分散控制效果, 同时验证神经网络控制器的自学习和泛化能力, 在采样步长 0.02 s , 持时 30 s 的地震激励 Kobe (NS, 1995) 波 (加速度峰值为 8.1782 m/s^2) 作用下, 计算 RBF 神经网络分散控制各工况下的结构地震响应, 并与神经网络集中控制结果进行比较。

图 4 和图 5 分别给出了各工况下结构在两种地震波作用下的结构响应和控制力。表 2 给出了地震作用下各工况结构的位移和加速度峰值。由表 2 可知, 本文研究的 RBF 神经网络分散控制对结构的位移和加速度响应具有良好的控制效果。在各种控制工况下, 其结构控制响应与集中控制相差不大, 表明分散控制可达到与集中控制近似的效果。

表 1 分散控制各子系统 RBF 神经网络结构模型信息

Tab. 1 RBF NNC model information of each subsystem under decentralized control

工况	系统划分	网络结构	S	期望误差	训练误差	训练次数
Case 1	子系统 1	$21 \times 15 \times 10$	30	1×10^{-7}	8.50756×10^{-8}	15
	子系统 2	$21 \times 14 \times 10$	30	1×10^{-7}	8.62935×10^{-8}	14
Case 2	子系统 1	$11 \times 10 \times 5$	85	1×10^{-7}	9.90343×10^{-8}	10
	子系统 2	$11 \times 12 \times 5$	315	1.31×10^{-7}	9.2183×10^{-7}	12
	子系统 3	$11 \times 12 \times 5$	300	8×10^{-7}	4.44442×10^{-7}	12
	子系统 4	$11 \times 12 \times 5$	5	1.1×10^{-5}	1.04612×10^{-5}	12
Case 3	子系统 1	$9 \times 12 \times 4$	142	1×10^{-7}	7.33854×10^{-8}	12
	子系统 2	$9 \times 8 \times 4$	360	2×10^{-6}	1.04154×10^{-7}	8
	子系统 3	$9 \times 13 \times 4$	153	2×10^{-6}	1.05488×10^{-7}	13
	子系统 4	$9 \times 7 \times 4$	5	6.0×10^{-5}	2.30592×10^{-5}	7
	子系统 5	$9 \times 2 \times 4$	1.5	5×10^{-3}	4.83221×10^{-3}	2




图3 神经网络分散控制系统(Case 3)

Fig. 3 Neural network decentralized control system(Case 3)




图4 El Centro作用下受控结构的地震响应与控制力

Fig. 4 Structural response and control force under El Centro




图5 Kobe作用下受控结构的地震响应与控制力

Fig. 5 Structural response and control force under Kobe

5 RBF 与 BP 神经网络分散控制对比

RBF 神经网络分散控制策略考虑了子系统耦合作用且取得了较好的控制效果,为进一步说明本文方法在控制效果和计算成本方面的优势,选取部

分计算结果与文献[12]进行对比分析。

5.1 控制效果

限于篇幅,仅比较 Kobe 波作用下结构采用 RBF 和 BP 神经网络分散控制的位移与加速度反应峰值。由表 2 可知,结构在 Kobe 波作用下,通

过分散 RBF 神经网络振动控制的各工况位移和加速度峰值响应均比分散 BP 神经网络小,说明前者

在控制效果上比后者有一定优势。

表 2 El Centro 和 Kobe 作用下各工况结构的位移和加速度反应峰值及 RBF 和 BP 在 Kode 作用下的控制效果对比

Tab.2 Peak displacement & acceleration under El Centro and Kobe and comparison of the control effect of RBF and BP under the Kode

算法工况		层间位移峰值/cm					加速度峰值/(m•s ⁻²)				
		1 层	5 层	10 层	15 层	20 层	1 层	5 层	10 层	15 层	20 层
El Centro	Uncontrolled	4.43	2.21	3.11	3.22	6.91	7.62	13.42	8.98	4.82	9.62
	Centralized Control	1.32	0.59	0.43	0.67	0.94	4.12	5.60	3.86	3.82	2.92
	Case 1	1.22	0.58	0.40	0.66	0.90	3.98	5.20	3.72	3.92	3.25
	Case 2	1.21	0.58	0.39	0.66	0.87	3.99	5.40	4.46	3.92	3.98
	Case 3	1.22	0.57	0.43	0.52	1.08	3.94	5.22	3.70	3.42	4.00
Kobe	Uncontrolled	15.39	6.58	9.26	10.91	20.97	12.56	29.04	16.00	11.78	17.78
	Centralized Control	4.25	1.84	1.46	2.12	3.19	4.68	9.73	8.58	6.12	2.99
	Case 1	<u>4.08</u>	<u>1.74</u>	<u>1.40</u>	<u>1.98</u>	<u>2.62</u>	<u>4.26</u>	<u>9.18</u>	<u>8.51</u>	<u>5.95</u>	<u>3.18</u>
		4.40	1.93	1.42	2.10	2.77	4.17	9.64	8.58	6.19	3.97
	Case 2	<u>4.06</u>	<u>1.77</u>	<u>1.29</u>	<u>1.99</u>	<u>2.94</u>	<u>4.15</u>	<u>9.61</u>	<u>8.45</u>	<u>6.27</u>	<u>4.04</u>
		4.21	2.07	1.69	2.24	2.86	4.47	9.75	9.62	6.39	4.37
	Case 3	<u>4.07</u>	<u>1.68</u>	<u>1.44</u>	<u>1.25</u>	<u>2.89</u>	<u>4.17</u>	<u>9.07</u>	<u>8.36</u>	<u>5.84</u>	<u>6.10</u>
		4.28	2.01	1.72	2.89	3.16	4.22	11.6	9.33	5.91	4.48

注:表中 Kobe 波作用下 Case 1~3 各工况分式中,分子分母分别为 RBF 网络(本文)和 BP 网络(文献[12])的结构响应。

5.2 计算成本

神经网络计算成本可由控制系统训练次数进行判断,由表 1 可知,RBF 神经网络下结构分散控制的三种划分情形中 case 2 各子系统训练量比 case 1 少,虽然 case 3 个别子系统训练次数比 case 2 多,但相差不大。

为进一步说明 RBF 神经网络分散控制在计算成本问题上的优势,本文将各子系统平均训练次数与 BP 神经网络分散控制^[12]进行对比,列入表 3。

表 3 El Centro 作用下结构各工况神经网络平均训练次数

Tab.3 Neural network training times under El Centro

算法工况	BP 网络 (文献[12])	RBF 网络 (本文)
Centralized Control	526	25
El Centro Case 1	280	15
Case 2	149	12
Case 3	64	9

注:表中训练次数为各子系统训练次数的平均值。

由表 3 可知,本文采用的 RBF 神经网络在训练次数上显著低于 BP 网络,计算成本大幅度降低;同时,表 3 各子系统平均训练次数随子系统划分数量的增多而减少,RBF 网络与分散控制相结合具有更大优势。

6 结 论

本文研究了 RBF 神经网络在建筑结构振动分散控制中的应用,考虑子系统控制耦合问题以及神

神经网络训练成本问题,在神经网络辨识器和控制器均采用 RBF 神经网络的情况下,将选取的 20 层 Benchmark 模型分别划分为 2 个、4 个和 5 个子系统进行研究,并将数值仿真结果与同样采用 RBF 神经网络的集中控制进行对比分析。结果表明,RBF 神经网络算法用于结构振动分散控制具有良好的控制效果,而且 RBF 网络较 BP 网络学习能力更强,与分散控制结合时控制效果更优且计算成本大幅降低,说明 RBF 神经网络分散控制更适用于实际工程。同时,本文将神经网络与分散控制相结合,局部控制器损坏不会导致整个控制系统失效,提高了控制系统在实际工程中应用的可靠性。

参考文献(References):

- [1] Johansen J D. Active Control of Frame Structures: A Decentralized Approach [D]. University of California, 2008.
- [2] Wang Y, Lynch J P, Law K H. Decentralized H_{∞} controller design for large-scale civil structures [J]. *Earthquake Engineering & Structural Dynamics*, 2009, **38**(3):377-401.
- [3] Qu C X, Huo L S, Li H N, et al. A double homotopy approach for decentralized H_{∞} control of civil structures [J]. *Structural Control and Health Monitoring*, 2014, **21**(3):269-281.
- [4] 董 钢,王建国.基于输出的建筑结构分散滑模控制[J]. 计算力学学报, 2016, **33**(1):59-65. (DONG Gang, WANG Jian-guo. Decentralized sliding mode part output feedback control of building structures [J]. *Chinese Journal of Computational Mechanics*, 2016, **33**(1):59-65. (in Chinese))

- [5] 汪 权,庄嘉雷,张 俊,等.地震作用下高层建筑结构的重叠分散控制研究[J]. 计算力学学报,2015,**32**(1): 48-52, 58. (WANG Quan, ZHUANG Jia-lei, ZHANG Jun, et al. Overlapping decentralized control of tall buildings under earthquakes[J]. *Chinese Journal of Computational Mechanics*, 2015, **32**(1): 48-52, 58. (in Chinese))
- [6] 汪 权,杨超亚,庄嘉雷,等.地震作用下高层建筑重叠分散控制子结构划分机理研究[J]. 计算力学学报,2017,**34**(3):280-285. (WANG Quan, YANG Chao-ya, ZHUANG Jia-lei, et al. Division tactics of sub-structures of tall buildings under earthquakes by overlapping decentralized control[J]. *Chinese Journal of Computational Mechanics*, 2017, **34**(3): 280-285. (in Chinese))
- [7] Xu Z D, Shen Y P, Guo Y Q. Semi-active control of structures incorporated with magnetorheological dampers using neural networks [J]. *Smart Materials and Structures*, 2003, **12**(1): 80-87.
- [8] Xu Z D, Guo Y Q. Neuro-fuzzy control strategy for earthquake-excited nonlinear magnetorheological structures [J]. *Soil Dynamics and Earthquake Engineering*, 2008, **28**(9): 717-727.
- [9] Jiang X M, Adeli H. Neuro-genetic algorithm for nonlinear active control of structures [J]. *International Journal for Numerical Methods in Engineering*, 2008, **75**(7): 770-786.
- [10] Venanzi I. A review on adaptive methods for structural control[J]. *The Open Civil Engineering Journal*, 2016, **10**(1): 653-667.
- [11] Xu Z D, Guo Y Q, Zhu J T, et al. *Intelligent Vibration Control in Civil Engineering Structures* [M]. Zhejiang University Press, 2016.
- [12] 汪 权,韩强强,王肖东,等.地震作用下高层建筑结构的分散神经网络振动控制研究[J]. 计算力学学报,2019, **36**(1): 77-82. (WANG Quan, HAN Qiang-qiang, WANG Xiao-dong, et al. Decentralized neural networks vibration control of tall buildings under earthquakes[J]. *Chinese Journal of Computational Mechanics*, 2019, **36**(1): 77-82. (in Chinese))
- [13] 杜永峰,郭剑虹.基于RBF神经网络的结构动力响应预测[J]. 兰州理工大学学报,2006, **32**(2): 111-114. (DU Yong-feng, GUO Jian-hong. Prediction of structural dynamic response based on RBF neural network [J]. *Journal of Lanzhou University of Technology*, 2006, **32**(2): 111-114. (in Chinese))
- [14] 潘兆东,谭 平,刘良坤,等.基于自适应RBF神经网络算法的建筑结构递阶分散控制研究[J]. 土木工程学报,2018, **51**(1): 51-57. (PAN Zhao-dong, TAN Ping, LIU Liang-kun, et al. Hierarchical decentralized control of building structure based on adaptive RBF neural network algorithm[J]. *China Civil Engineering Journal*, 2018, **51**(1): 51-57. (in Chinese))
- [15] 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 Jin-ping. *Structural Vibration Control—Active, Semi-Active and Intelligent Control* [M]. Beijing: Science Press, 2003. (in Chinese))

Decentralized control of building structure based on neural network algorithm

WANG Quan^{*1,2}, WANG Wen¹, HAN Xin-jie¹, HAN Qiang-qiang¹, ZHOU Chao-jie¹

(1. School of Civil and Hydraulic Engineering, Hefei University of Technology, Hefei 230009, China;

2. Anhui Civil Engineering Research Center for Disaster Prevention and Mitigation, Hefei 230009, China)

Abstract: Aiming at decentralized vibration control of structures under an earthquake, a neural network algorithm is introduced to study the decentralized neural network control strategy of structural vibration, so as to solve the coupling problem of individual subsystems in the decentralized control and reduce the training cost of the neural network algorithm. Employing the Radial Basis Function (RBF) neural network model, an RBF neural network controller is formed on the basis of the newrb function. And a 20-layer Benchmark structure model is respectively tested by centralized control and multi-condition subsystems-division decentralized control, the data of which is later processed by numerical simulation analysis. The simulation analysis shows that the decentralized RBF neural network vibration control strategy for the coupling of individual subsystem herein takes into account the information sharing between the subsystems, which can effectively control the vibration response of the structure and rationalize the training frequency required for the subsystems to achieve the ideal training result. Compared with that in BP network, the required frequency is significantly reduced.

Key words: decentralized control; earthquake action; neural network; radial basis function

引用本文/Cite this paper:

汪 权,王 文,韩新节,等.基于神经网络算法的建筑结构振动分散控制研究[J]. 计算力学学报,2021,**38**(5):580-585.

WANG Quan, WANG Wen, HAN Xin-jie, et al. Decentralized control of building structure based on neural network algorithm [J]. *Chinese Journal of Computational Mechanics*, 2021, **38**(5): 580-585.