

•智能交叉科学与工程•

DOI:10.15961/j.jsuese.202200665



经验知识监督的RC墩柱力学性能神经网络分析方法

刘振亮^{1,2}, 李素超^{2,3}, 赵存宝^{1*}

(1.石家庄铁道大学 安全工程与应急管理学院, 河北 石家庄 050043; 2.河北省大型结构健康诊断与控制重点实验室, 河北 石家庄 050043; 3.哈尔滨工业大学(威海) 土木工程系, 山东 威海 264209)

摘要: 基于试验或数值模拟的单一墩柱力学性能分析方法难以兼顾计算精度和效率, 纯数据驱动的分析方法存在可解释性差和对数据依赖性强等问题。为此, 本文通过研究钢筋混凝土(RC)墩柱力学性能试验数据、经验知识和机器学习的融合机制, 提出了经验知识监督的RC墩柱力学性能神经网络(knowledge-guided neural network, KGNN)分析方法。首先, 建立了包含761组RC墩柱拟静力试验样本的数据库; 随后, 基于经验知识分析了RC墩柱主要特征对其力学性能的影响规律, 构建了相应的数学表征方法; 最后, 将RC墩柱试验数据及经验知识融入人工神经网络架构和训练过程, 建立了高精度、可解释、可通用且不依赖大量训练数据的RC墩柱力学性能KGNN分析模型。本文提出的KGNN分析方法与纯数据驱动神经网络(BPNN)的结果对比表明: BPNN在测试集上表现更好, 在分析墩柱承载力时均方根误差(E)和拟合系数(R^2)分别为0.070和0.978, KGNN模型的 E 和 R^2 分别为0.108和0.942; 但由于BPNN所预测的墩柱特征对承载力的影响规律与经验知识并不吻合, 即未能准确反映墩柱特征与其力学性能间的关系, BPNN模型发生了过拟合; 而KGNN方法不仅可以快速准确获得RC墩柱力学性能, 且预测规律与经验知识吻合较好, 具有更高的可靠性和实用性。因此, 融合试验数据与经验知识的神经网络有望成为一种新的RC结构力学性能分析方法。

关键词: 钢筋混凝土墩柱; 数物融合的神经网络; 经验知识; 力学性能; 试验数据库

中图分类号: TU375.4

文献标志码: A

文章编号: 2096-3246(2024)01-0035-09

钢筋混凝土(RC)墩柱可以综合利用钢筋和混凝土的材料力学特性, 是建筑、桥梁等现代结构的主要支撑构件。然而, 灾后调查表明: 在地震等自然灾害作用下墩柱容易受到损伤, 这可能导致严重后果^[1-2]。例如, 1995年日本神户地震导致25%的桥梁墩柱完全损坏, 严重阻碍震后抢险救灾和恢复重建工作的开展, 直接经济损失达268亿美元^[3]。为了确保结构安全, 需要进行合理的抗震设计和分析, 即能够快速准确地获得RC墩柱力学性能^[4-5]。

国内外学者已经对RC墩柱性能进行了大量的试验和理论研究, 并据此发展了许多力学性能计算公式, 广泛应用于抗震设计和评估中。代旷宇等^[6]对混

凝土构件的试验数据进行了研究, 提出了改进Ibarra-Medina-Krawinkler材料模型的RC圆柱恢复力模型参数分析公式; 吕西林等^[7]对9根足尺高强混凝土柱模型进行了试验研究, 分析了轴压比、箍筋形式等因素对位移延性的影响。然而, 此类方法大多基于专家经验和少量试验数据, 不同专家建立的公式所考虑的影响因素和关系并不一致。这种方法通常比较保守, 具有较大的局限性^[8-9]。

近年发展的机器学习方法是数据驱动的, 具有强非线性学习能力, 在许多领域取得了重要进展^[10-11]。Miao等^[12]采用卷积神经网络算法对RC构件的力学性能进行分析, 并将其与传统的半经验模型进行对

收稿日期: 2022-06-28

基金项目: 国家自然科学基金青年基金项目(52308512); 河北省自然科学基金青年基金项目(E2022210048); 河北省大型结构健康诊断与控制重点实验室开放基金项目(KLLSHMC2105); 河北省省级科技计划项目(21567625H)

作者简介: 刘振亮(1991—), 男, 博士。研究方向: 基于机器学习的钢筋混凝土结构及桥梁抗震性能研究。E-mail: liuzhenliang@stdu.edu.cn

*通信作者: 赵存宝, 高级工程师, E-mail: zhaocb@stdu.edu.cn

网络出版时间: 2023-11-15 11:43:55 网络出版地址: <https://link.cnki.net/urlid/51.1773.TB.20231115.1029.001>

比,证明了该方法在构件性能预测方面的优势;Oreta等^[13]建立了基于神经网络的RC梁尺寸效应分析方法,效果较好。但是,纯数据驱动的机器学习方法仍然存在可解释性差、理论基础薄弱、对训练样本数量和质量依赖性高等问题^[14-15]。而RC墩柱试验成本高昂,不同学者所开展试验的研究对象、年代和设备均有所差异,常用的试验数据库包含的样本数量较少,且特征分布不均匀^[16-17]。例如:美国太平洋工程地震研究中心(PEER)墩柱试验数据库包含292组矩形墩柱样本,其中仅有两个样本纵筋配筋率小于1%^[18]。因此,粗略地将不同学者的试验数据收集到一起难以作为机器学习方法提供足够可靠的训练数据。

基于以上问题,以机器学习算法为基础,将已有领域知识、训练规则及学习过程有效融合,建立一套适用范围更广、泛化性能更好、对训练数据要求更低的数学-物理融合方法体系,成为分析RC墩柱性能的迫切需求。近年来,嵌入领域知识的机器学习方法在解决纯数据驱动机器学习的“黑箱”缺陷方面取得了重大进展^[19]。例如,Jin等^[20]通过自微分技术将Navier-Stokes控制方程直接编码到卷积神经网络架构中,克服了不可压缩层流和湍流流动的限制;Zhang等^[21]发展了动力学定律约束的损失函数建立方法,据此建立了能够准确预测建筑物在地震作用下时程响应的替代模型;Liu等^[22]提出了将领域知识融入支持向量机训练过程的方法,建立了校准的RC墩柱集中塑性模型。然而,许多RC墩柱力学性能的规律是定性的,难以直接嵌入到机器学习框架中,而基于经验的公式本身存在较大的主观性,直接融入到机器学习可能会出现误差。

综上,本文旨在解决基于经验的RC墩柱定性规律的数学表征和经验知识监督的神经网络(KGNN)训练两个问题。为此,本文首先建立了包含761组RC墩柱拟静力试验的标准数据库;然后,总结了RC墩柱力学特性的经验规律,并提出了数学表征方法;最后,建立了经验知识监督的神经网络模型,经过验证,该模型可以快速、准确评估RC墩柱力学特性。本研究将强化机器学习方法的理论基础,为促进数据融合方法在土木工程领域的创新应用奠定基础。

1 经验知识监督的神经网络

典型人工神经网络(ANN)模型主要由输入层、隐含层和输出层组成,每层包含多个与相邻层连接的神经元,通过网络连接和阈值建立输入与输出的映射关系^[23-24]。ANN的学习过程是根据学习规则(如最速下降法)对模型输出与实际值之间的误差进行分析,不断调整网络各层之间连接权重和阈值,从

而使网络的损失函数(如误差平方和)最小的过程^[25]。因此,ANN算法可能训练出多个分析效果相似的模型。此外,纯数据驱动的ANN无法甄别数据中存在的误差,而且在训练样本误差存在不均匀分布的情况下可能致使训练模型过拟合。因此,纯数据驱动的ANN模型的性能并不是衡量墩柱性能分析模型有效性的唯一标准,还需要引入领域经验知识监督ANN训练过程。

根据机器学习模型架构和训练过程,领域知识可以通过5种方式与其融合:1)基于领域知识的模型预训练、初始化或正则化;2)明确部分或全部节点之间的物理或经验关系;3)根据领域知识限制搜索策略或连接权重范围;4)将领域知识融入损失函数;5)将理论或半经验模型融入ANN输入层和输出层。以上方法均需明确领域知识的数学表征,然而,由于钢筋和混凝土材料性能的复杂性,许多RC墩柱特征对其力学性能的经验影响规律是定性的,难以直接用数学公式定量表征。例如:RC墩柱承载力随纵筋配筋率的增大而增大,但具体数学表征公式往往基于根据专家经验作出的假设,存在一定的主观性偏差,无法直接嵌入ANN架构。

因此,本文提出了经验知识监督神经网络的KGNN方法,其主要架构如图1所示。该方法通过在损失函数之前引入经验知识监督层,来监督其训练过程。建立墩柱力学性能KGNN分析模型的过程主要包括3个部分。

1) 试验数据与经验知识:通过对RC墩柱结构与加载条件等特征的分析确定其力学性能主要影响特征 $\mathbf{X}_i = \{X_{ij}\}$ (X_{ij} 为RC构件*i*的第*j*个特征),同时确定其力学特性 $\mathbf{Y}_i = \{Y_{ik}\}$ (Y_{ik} 为RC构件*i*的第*k*个力学特性参数);收集RC墩柱拟静力试验数据,并提取各样本的特征参数和力学性能参数,为KGNN模型训练提供数据支持;基于试验数据和公开发表的研究结果,总结经验知识,为KGNN模型训练提供领域知识支撑。本文提出采用偏微分形式表示输入特征参数与输出力学特性参数的关系,即 $\partial Y_{ik} / \partial X_{ij}$ 。

2) KGNN模型架构设计:将建立RC墩柱试验数据随机划分为训练集和测试集。为了克服特征参数单位不一致带来的误差,将 \mathbf{X} 和 \mathbf{Y} 标准化至[0,1]范围内。将 \mathbf{X} 和 \mathbf{Y} 分别作为KGNN的输入和输出:

$$\begin{cases} x_{ij} = \frac{X_{ij} - \min(X_j)}{\max(X_j) - \min(X_j)}, \\ y_{ik} = \frac{Y_{ik} - \min(Y_k)}{\max(Y_k) - \min(Y_k)} \end{cases} \quad (1)$$

式中, x_{ij} 和 y_{ik} 分别为RC构件*i*的第*j*个特征标准值和第*k*个力学特性参数标准值, \mathbf{X}_j 和 \mathbf{Y}_k 分别为所有RC




图1 RC墩柱力学性能KGNN分析方法

Fig. 1 KGNN for mechanical analysis of RC columns

构件第 j 个特征和第 k 个力学特性参数。根据经验确定潜在的最优隐含层架构(目前不存在确定的理论解析方法,本文通过比较确定最优隐含层神经元数量),同时确定神经网络激活函数 $O = f(\mathbf{x}, \mathbf{w}, q)$ ($\mathbf{x}, \mathbf{w}, q$ 分别为输入向量、权重向量和阈值)、预测值 \hat{y}_{ik} 与试验值 y_{ik} 误差损失函数 $Loss(y_{ik}, \hat{y}_{ik})$ 、误差传递函数和收敛条件(收敛误差和最大迭代次数)等。

此外,研究RC墩柱力学性能相关经验知识的数学表征方法,并分析KGNN模型预测的规律 $\partial \hat{y}_{ik} / \partial X_{ij}$ (\hat{y}_{ik} 为RC构件 i 的第 k 个力学特性参数预测值),据此建立经验知识一致性判断函数 $L(\partial \hat{\mathbf{Y}} / \partial \mathbf{X})$ ($\partial \hat{\mathbf{Y}} / \partial \mathbf{X}$ 为所有预测值 $\hat{\mathbf{Y}}$ 对输入 \mathbf{X} 的偏导数, $\hat{\mathbf{Y}} = \hat{y}_{ik}$),将其嵌入神经网络架构以监督其训练过程,从而筛选出符合经验知识的训练模型,且剔除不符合经验知识的模型,如下所示:

$$L(\partial \hat{\mathbf{Y}} / \partial \mathbf{X}) = \sum_{i=1}^{N_s} \sum_{j=1}^m \sum_{k=1}^n P(\partial \hat{y}_{ik} / \partial X_{ij}) \quad (2)$$

式中, N_s 、 m 和 n 为样本数量、输入特征数量和输出特征数量, $P(\partial \hat{y}_{ik} / \partial X_{ij})$ 为基于经验知识的判断函数,计算方程如下所示:

$$P(\partial \hat{y}_{ik} / \partial X_{ij}) = \begin{cases} 0, & \partial Y_{ik} / \partial X_{ij} \times \partial \hat{y}_{ik} / \partial X_{ij} > 0; \\ 1, & \partial Y_{ik} / \partial X_{ij} \times \partial \hat{y}_{ik} / \partial X_{ij} \leq 0 \end{cases} \quad (3)$$

$$\partial \hat{y}_{ik} / \partial X_{ij} = \hat{y}_{ik}(X_{i1}, X_{i2}, \dots, X_{ij} + \Delta, X_{ij+1}, \dots) - \hat{y}_{ik}(\mathbf{X}) \quad (4)$$

式中, Δ ($\Delta > 0$)为输入参数增量。当KGNN模型预测规律与经验知识一致时,即 $\partial Y_{ik} / \partial X_{ij} \times \partial \hat{y}_{ik} / \partial X_{ij} > 0$,且 $L(\partial \hat{\mathbf{Y}} / \partial \mathbf{X}) = 0$,说明KGNN模型能够正确反映各参数影响,模型进入最优模型候选区;否则将其剔除。

3)模型训练与验证:将训练集数据输入到训练

模型中反复训练不同架构的KGNN模型,将所有符合经验知识的模型收入最优模型优选区;并通过各模型的性能比较确定最优的模型。为了验证训练结果的有效性,本文采用均方根误差(E)与拟合系数(R^2)来评估各模型的误差和拟合度:

$$E_k = \sqrt{\frac{\sum_{i=1}^{N_s} (\hat{Y}_{ik} - Y_{ik})^2}{N_s}} \quad (5)$$

$$R_k^2 = 1 - \frac{\sum_{i=1}^{N_s} (Y_{ik} - \hat{Y}_{ik})^2}{\sum_{i=1}^{N_s} (Y_{ik}^2 - \bar{Y}_k)^2} \quad (6)$$

式中, E_k 为对第 k 个力学特性参数预测的均方根误差, R_k^2 为对第 k 个力学特性参数预测的拟合度, \bar{Y}_k 为所有样本的第 k 个力学特性参数平均值, N_s 为数据集样本的数量。可以看出, E_k 越小、 R_k^2 越大,则模型预测结果越好。据此可确定最优模型架构及连接权重,得到RC墩柱力学性能KGNN分析模型。

2 RC墩柱特征与试验力学特性

常用RC墩柱拟静力试验如图2所示。RC墩柱的力学性能与其几何尺寸、材料特性、配筋状况和荷载情况等诸多因素相关,可以采用许多参数表示其影响。然而,考虑到神经网络模型的科学性和有效性,作为输入层的特征参数既要有较大的影响,也要方便收集。例如,采用截面边长(b 和 d)和剪跨比(λ)代表几何尺寸的影响;尽管保护层厚度对墩柱力学性能也有较大影响,但是实际工程中保护层厚度变化范围较小,多数试验样本的保护层厚度在20~30 mm

范围内,因此,不考虑为输入特征参数。参考相关文献确定特征参数^[26],本文确定主要影响特征参数为:

$$\mathbf{X} = \{b, d, \lambda, f'_c, f_{y1}, f_{yt}, \rho_l, \rho_{sv}, s/b, n_c\} \quad (7)$$




图 2 RC墩柱拟静力试验示意图

Fig. 2 Schematic of quasi-static test of RC columns

RC墩柱力学特性的准确评估是基于性能的抗震设计和结构分析的基础。图3为RC墩柱的水平恢复力-变形滞回曲线及力学特性参数。由图3可以看出:在水平往复荷载作用下,RC墩柱首先保持弹性状态;到达屈服点之后刚度降低,进入塑性强化阶段;当恢复力超过峰值承载力之后进入下降阶段。




图 3 滞回曲线与力学特性参数

Fig. 3 Hysteretic curves and mechanical parameters

各阶段的关键力学性能参数是力学性能分析的关键。本文提出KGNN方法预测墩柱关键力学性能值。考虑到在试验过程中正负方向的响应值会存在差异,取正负方向力学性能试验值的平均值作为墩柱真实性能,如下所示:

$$\mathbf{Y} = \{V_y, V_{\max}, \Delta_y, \Delta_s, \Delta_u, \dots\} \quad (8)$$

式中, V_y 和 V_{\max} 分别为屈服恢复力和峰值承载力, Δ_y 、 Δ_s 和 Δ_u 分别为屈服位移、峰值承载力位移和极限位移。 Δ_y 取为图3中区域 I 和 II 面积相等 ($S_I = S_{II}$) 时构

式中, b 和 d 分别为垂直和平行于往复水平力的截面尺寸, λ 为剪跨比, f'_c 、 f_{y1} 和 f_{yt} 分别为混凝土轴心抗压强度、纵筋和箍筋屈服强度, ρ_l 和 ρ_{sv} 分别为纵筋配筋率和箍筋体积配箍率, s 为箍筋间距, n_c 为轴压比。

件的水平位移, Δ_u 取为当水平承载力 V 下降到 $0.8 V_{\max}$ 时构件的水平位移^[27]。

3 经验知识及数学表征

各国学者对RC墩柱特征与其力学特性的关系进行了大量的试验、理论和数值模拟研究,得到了许多重要的规律。本文总结了近年来该领域的部分代表性结论^[28],如下:

1) 截面尺寸 b 和 d 、混凝土强度 f'_c 、纵筋强度 f_{y1} 和配筋率 ρ_l 对墩柱最大承载力 V_{\max} 有很大的正面影响,即 $\partial Y_{ik} / \partial X_{ij} > 0$;

2) 剪跨比 λ 对水平承载力 V_y 和 V_{\max} 有影响,剪跨比增大会导致水平承载力降低,即 $\partial Y_{ik} / \partial X_{ij} < 0$;

3) 轴压比 n_c 对RC墩柱变形能力 Δ_y 、 Δ_s 和 Δ_u 的影响很大,当轴压提高时,变形能力下降,即 $\partial Y_{ik} / \partial X_{ij} < 0$;

4) 箍筋配箍率 ρ_{sv} 的提高可以改善截面承载力、变形能力和延性,即 $\partial Y_{ik} / \partial X_{ij} > 0$;

5) 混凝土强度 f'_c 对墩柱水平变形能力有一定影响,变形能力下降,即相应的 $\partial Y_{ik} / \partial X_{ij} < 0$ 。

根据以上经验知识可建立表征为 $\partial Y_{ik} / \partial X_{ij}$, 在建立RC墩柱力学性能KGNN模型过程中可以将其用于监督训练过程。另有一些参数的影响为非单调的,例如:轴压比较小时,轴压比增加可以提高水平承载力;当轴压比较大时,轴压比增加会使水平承载力降低。此外,还有一些结论存在争议,如关于纵向钢筋对变形能力和延性的影响,部分学者认为纵筋配筋率和强度的增加会降低约束区混凝土极限压应变,

从而降低其变形能力;但另一部分专家却提出了相反的结论。此类经验知识不在本文考虑范围内,在建立经验知识表征时, $P(\partial Y_{ik}/\partial X_{ij}) = 0$ 。

4 RC墩柱试验数据库

首先需要收集足够数量且可靠的RC墩柱拟静力试验数据建立数据库。将80%的样本随机划分为训练集,剩余20%样本用作测试集。本文收集和整理了公开的试验数据库和文献中的RC墩柱拟静力试验数据建立数据库,详见文献^[26]。由于不同学者的研究目标不同,所开展试验的结构和技术细节均有所差异,为保证试验样本的质量,在收集试验样本时按如下要求进行严格筛选:

- 1) 试件截面为实心矩形,不包含空心墩柱、异形柱等截面型式;
- 2) 试验过程中只有恒定轴向荷载和往复水平荷载;
- 3) 试验原始文献提供完整的试验特征介绍和试验结果;

4) 试验构件只由钢筋和混凝土组成(不考虑水灰比、石子粒径等影响);

5) 试验对象仅包括RC墩柱力学性能,不包括研究腐蚀、老化等效应的构件;

6) 考虑到试验装置和边界条件的差异性,试验数据能够标准化为等效悬臂柱;

7) RC墩柱截面尺寸不小于300 mm。

经过筛选,本文共收集到761组RC墩柱试验数据,每个墩柱样本由其墩柱特征 X 及其试验力学特性参数 Y 组成。数据库样本主要参数分布如图4所示。可以看出,本文收集到的数据中构件截面尺寸主要为0.30~0.60 m,剪跨比分布范围主要为1.5~6.5,其他构件参数(如几何尺寸、材料强度等)分布也较为广泛,能够覆盖常见RC柱试验模型的参数范围。但是各参数分布并不均匀,例如,仅包含一组截面尺寸为2.0 m的构件。这使得基于该数据库的模型可能无法准确反映在部分工况下RC墩柱的性能,据此建立的模型可能缺乏泛化性能。进一步证明了发展KGNN方法的必要性。

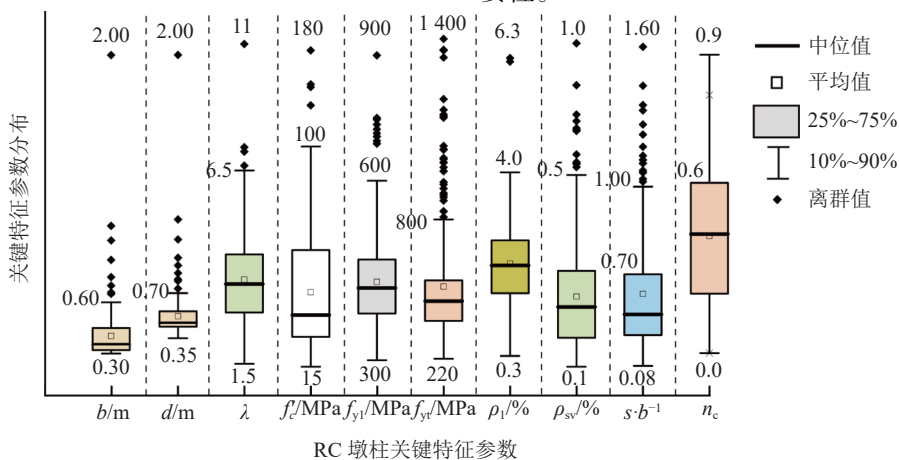


图4 试验数据集中主要参数分布箱型图

Fig. 4 Boxplot of the main parameter distribution of test dataset

5 KGNN模型训练与验证

采用本文提出的KGNN方法、建立的试验数据库和经验知识表征方法,可以对RC墩柱力学性能进行分析,图5为建立KGNN模型的流程图。首先,将80%和20%的试验数据分别随机划分为训练集和测试集;随后,确定KGNN架构:输入层为10个RC墩柱特征 X ,输出层为力学特性 Y ,隐含神经元数量为8~30(经过比较不同隐含层神经元数量的模型性能选择最优隐含层神经元数量),激活函数为sigmoid函数,终止条件为最大循环次数 10^4 或误差容错 10^{-3} ,学习率为0.15,动量因子为0.05,噪声为0.01;最后,用训练集数据和领域经验知识训练KGNN模型,并通过比较得到RC

墩柱力学性能最优分析模型。这里通过采用K-折交叉验证方法以进一步保证模型的泛化性能,即将训练集数据随机分为K份(本文K取10),每次取1份作为验证集,将其他K-1份数据作为训练集,训练得到的模型都要经过筛选;之后,将与经验知识相符的模型划入最优模型候选区,并采用验证集数据进行循环验证;最后,采用测试集数据即可验证该KGNN模型。

RC墩柱主要力学特性包括承载力和变形能力,这些特性可以用于RC结构有限元模拟和抗震分析及设计。本节以峰值承载力 V_{max} 和极限变形能力 Δ_u 为预测指标,验证本文提出的KGNN方法的有效性。该方法也可以无缝学习其他力学特性。为了比较本文方法与传统机器学习方法的有效性,本文采用常用

的反向传播神经网络 (BPNN) 算法学习试验数据, 建立纯数据驱动的 RC 墩柱力学特性分析模型。

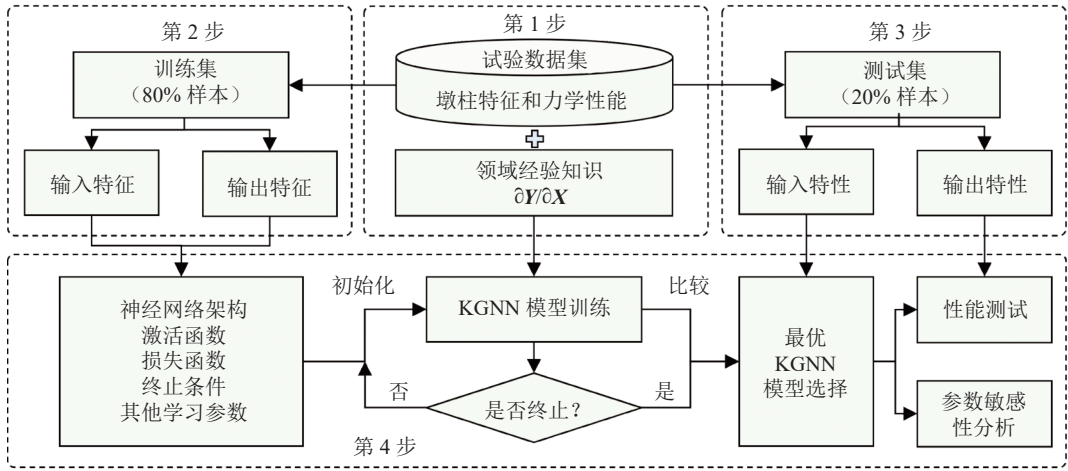


图 5 RC 墩柱力学性能 KGNN 模型训练过程

Fig. 5 Training procedure for KGNN model of mechanical property analysis of RC columns

5.1 承载力分析

经过比较不同隐含层神经元数量的模型性能, 本文选择 12 为最优 KGNN 和 BPNN 隐含层神经元数量, 建立 RC 墩柱峰值承载力 KGNN 和 BPNN 模型。图 6 为各模型在训练集和测试集上的预测结果与试验值比较。由图 6 可以看出, KGNN 和 BPNN 模型在训练集和测试集数据样本分析中均取得了较可靠的分析结果, 与试验结果吻合较好。其中, BPNN 模型在训练集和测试集数据的分析指标 E 分别为 0.106 和 0.070, R^2 分别为 0.963 和 0.978; 而 KGNN 模型在训练集和测试集数据上的分析指标 E 分别为 0.110 和 0.108, R^2 分别为 0.936 和 0.942。因此, 仅以分析精度而言, BPNN 模型分析结果比 KGNN 模型结果更为准确。




图 6 V_{\max} 模型预测与试验结果对比

Fig. 6 V_{\max} comparisons of predictive and test results

然而, BPNN 模型和 KGNN 模型预测的输入参数对输出参数的影响却并不一致。以截面尺寸 b ($b=d$) 为例说明, 图 7 为在其他参数确定时 ($\rho_l=2.0\%$, $f_{yl}=420\text{ MPa}$, $\rho_{sv}=2.0\%$, $f_{yt}=500\text{ MPa}$, $f'_c=40\text{ MPa}$,

$\lambda=3.0$), 截面尺寸 b 对峰值承载力 V_{\max} 预测值的影响。由图 7 可以看出, BPNN 模型中, RC 墩柱峰值承载力预测值随截面尺寸的增大而先增大后减小, 这与经验知识不符。根据领域经验知识, 峰值承载力随截面尺寸增大而增大, 这与 KGNN 模型预测结果一致。这是由于目前收集到的 RC 墩柱试验数据比较有限且构件离散性较大。纯数据驱动的 BPNN 方法仅会根据误差调整模型, 该方法一般对于训练集特征范围内样本的预测精度较高, 但较难准确反映训练集特征范围以外的参数对 RC 墩柱峰值承载力的影响; 而 KGNN 方法在训练过程中会剔除与经验知识不符的模型, 然后再比较各模型的准确性。因此, 基于此方法建立的模型可以更准确地反映 RC 墩柱特性中蕴含的内在规律。




图 7 截面尺寸 b 对峰值承载力 V_{\max} 影响分析

Fig. 7 Effect analysis of dimension b on V_{\max}

5.2 变形能力分析

采用本文提出的 KGNN 方法和传统的 BPNN 方法分别建立模型预测 RC 墩柱极限变形能力 Δ_u 。选择 20 作为最优隐含层神经元数量。图 8 为建立的 KGNN 和

BPNN模型在训练集和测试集上的分析结果。BPNN模型在训练集和测试集数据上的分析指标 E 分别为0.145和0.168, R^2 分别为0.825和0.783;而KGNN模型在训练集和测试集数据上的分析指标 E 分别为0.153和0.178, R^2 分别为0.801和0.732。由图6和图8可以看出,与峰值承载力模型相比,建立的极限变形分析模型精确度较低。这是由于试验数据中RC墩柱变形能力较承载力存在更多的不确定因素,更加凸显了加入领域经验知识的必要。此外,依然可以看出KGNN和BPNN模型对训练集和测试集数据样本的分析较为准确,与试验结果吻合较好。仅以分析精度而言,BPNN模型分析结果比KGNN模型结果更为准确。

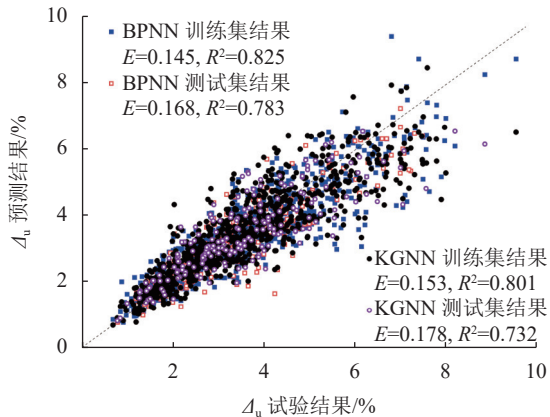


图8 Δ_u 模型预测与试验结果对比

Fig. 8 Δ_u comparisons of predictive and test results

采用建立的BPNN和KGNN模型对截面尺寸为300 mm×300 mm的RC墩柱进行分析,研究各参数对RC墩柱极限变形能力的影响规律。结果表明,BPNN与KGNN对于各参数的影响分析结果并不完全一致。以体积配箍率 ρ_{sv} 为例,图9为在其他参数确定时($n_c = 0.2$, $\rho_l = 2.0\%$, $f_{yl} = 420$ MPa, $f_{yt} = 500$ MPa, $f'_c = 40$ MPa, $\lambda = 3.0$), ρ_{sv} 对 Δ_u 的影响。BPNN模型中,RC墩柱极限变形能力 Δ_u 预测值随 ρ_{sv} 的增加先增加后降低。这与经验规律并不一致,随着体积配箍率的增加,箍筋对于核心区混凝土的约束作用也会提高,RC墩柱的极限变形能力也应逐步增加^[29-30],KGNN模型预测结果与实际规律一致。这是因为训练集中部分特征分布不均匀,纯数据驱动的BPNN模型在训练过程中会更多地倾向于与数据分布密集的特征区间结果相一致,而本文建立的KGNN模型可以克服该缺陷。

综上,本文建立的KGNN方法具有较强的泛化能力,可以准确分析RC墩柱承载力和变形能力,且各种参数对RC构件延性影响规律与经验知识相符。由于RC墩柱力学性能受到多参数的综合影响,采用本文提出的预测模型可以通过初期的分析结果来减少试验工况和降低试验成本,还可以研究各特征参数

对其力学特性的影响,对RC墩柱的抗震设计和评估均有一定借鉴意义。

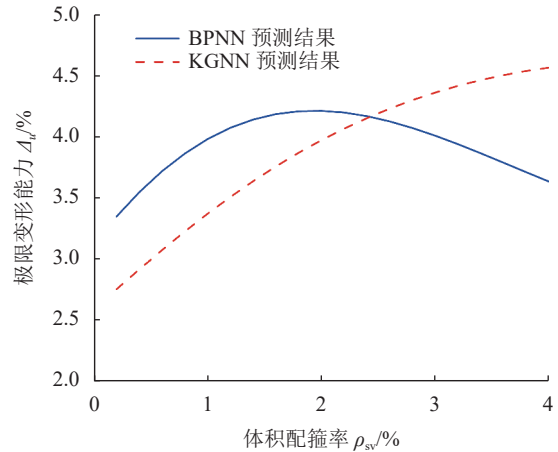


图9 体积配箍率 ρ_{sv} 对 Δ_u 的影响分析

Fig. 9 Effect analysis of stirrup ratio ρ_{sv} on Δ_u

6 结论

本文针对RC墩柱力学性能提出了一种领域经验知识监督的神经网络方法,并利用试验数据和经验知识建立更为高效、准确、稳定的RC墩柱性能分析模型。通过收集与分析761组RC墩柱试验数据,建立了试验数据库,并确定了各特征参数及对RC墩柱性能的影响机理,为RC墩柱力学性能KGNN模型提供数据和经验知识支持。主要研究结论如下:

1) 纯数据驱动的机器学习方法难以克服RC墩柱试验数据的误差和分布不均匀问题,即使在训练集和测试集均表现良好依然不能保证其泛化性能;

2) 本文提出的经验知识表征方法可以方便地用于监督KGNN模型的训练过程,保证训练模型不仅具有较高的模拟精度,还能符合经验知识,克服神经网络过分依赖训练数据质量和数量的缺点;

3) 本文建立的KGNN方法可以同时利用已获得的RC墩柱试验数据和经验知识,能够准确预测RC墩柱的力学性能,可为基于性能的结构抗震设计和评估提供更为科学的依据。

然而,由于所收集的试验数据参数的限制,本文在分析过程中对箍筋形式、钢筋直径等因素进行了简化考虑,在后续研究中仍需要对试验数据库进行丰富和完善,以提高KGNN模型的泛化性和准确性。

参考文献:

- [1] Hose Y, Silva P, Seible F. Development of a performance evaluation database for concrete bridge components and systems under simulated seismic loads[J]. *Earthquake Spectra*, 2000, 16(2): 413-442.
- [2] Liu Zhenliang, Yuan Wei, Li Suchao. Resilience assessment of highway bridge networks subjected to both earthquakes

- and earthquake-induced secondary emergencies[J]. *China Safety Science Journal*, 2022, 32(8): 176–184. [刘振亮, 苑激, 李素超. 地震及次生突发灾害下公路桥梁网络韧性评估[J]. *中国安全科学学报*, 2022, 32(8): 176–184.]
- [3] Horwich G. Economic lessons of the Kobe earthquake[J]. *Economic Development and Cultural Change*, 2000, 48(3): 521–542.
- [4] Ghojarah A. Performance-based design in earthquake engineering: State of development[J]. *Engineering Structures*, 2001, 23(8): 878–884.
- [5] Perdomo C, Monteiro R. Simplified damage models for circular section reinforced concrete bridge columns[J]. *Engineering Structures*, 2020, 217: 110794.
- [6] Dai Kuangyu, Yu Xiaohui, Wang Shuo, et al. Identification of the hysteretic model parameters for reinforced concrete circular columns based on the modified Ibarra-Medina-Krawinkler material model[J]. *Engineering Mechanics*, 2021, 38(1): 154–163. [代旷宇, 于晓辉, 王硕, 等. 基于改进 Ibarra-Medina-Krawinkler 材料模型的 RC 圆柱恢复力模型参数识别[J]. *工程力学*, 2021, 38(1): 154–163.]
- [7] Lv Xilin, Zhang Guojun, Chen Shaolin. Research on seismic behavior of full-scale high-strength concrete frame columns with high axial compression ratios[J]. *Journal of Building Structures*, 2009, 30(3): 20–26. [吕西林, 张国军, 陈绍林. 高轴压比高强混凝土足尺框架柱抗震性能研究[J]. *建筑结构学报*, 2009, 30(3): 20–26.]
- [8] Li Lei, Luo Guangxi, Wang Zhuohan, et al. Prediction of residual behaviour for post-earthquake damaged reinforced concrete column based on damage distribution model[J]. *Engineering Structures*, 2021, 234: 111927.
- [9] Aldabagh S, Hossain F, Alam M S. Simplified predictive expressions of drift limit states for reinforced concrete circular bridge columns[J]. *Journal of Structural Engineering*, 2022, 148(3): 4021285.
- [10] Salehi H, Burgueño R. Emerging artificial intelligence methods in structural engineering[J]. *Engineering Structures*, 2018, 171: 170–189.
- [11] Alipour M, Harris D K, Barnes L E, et al. Load-capacity rating of bridge populations through machine learning: Application of decision trees and random forests[J]. *Journal of Bridge Engineering*, 2017, 22(10): 4017076.
- [12] Miao Zenghui, Ji Xiaodong, Wu Minghui, et al. Deep learning-based evaluation for mechanical property degradation of seismically damaged RC columns[J]. *Earthquake Engineering & Structural Dynamics*, 2023, 52(8): 2498–2519.
- [13] Oreta A W C. Simulating size effect on shear strength of RC beams without stirrups using neural networks[J]. *Engineering Structures*, 2004, 26(5): 681–691.
- [14] Karpatne A, Atluri G, Faghmous J H, et al. Theory-guided data science: A new paradigm for scientific discovery from data[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2017, 29: 2318–2331.
- [15] Yu Bo, Cheng Hao, Yu Zecheng, et al. Physics-supervised ensemble learning model for predicting failure modes of reinforced concrete columns[J]. *Engineering Structures*, 2023, 292: 116560.
- [16] Lam S S E, Wu B, Wong Y L, et al. Drift capacity of rectangular reinforced concrete columns with low lateral confinement and high-axial load[J]. *Journal of Structural Engineering*, 2003, 129(6): 733–742.
- [17] Jin Liu, Du Xiuli, Li Dong, et al. Seismic behavior of RC cantilever beams under low cyclic loading and size effect on shear strength: An experimental characterization[J]. *Engineering Structures*, 2016, 122: 93–107.
- [18] Berry M, Parrish M, Eberhard M. PEER structural performance database user's manual [M]. Berkeley: University of California, 2004.
- [19] Karniadakis G E, Kevrekidis I G, Lu Lu, et al. Physics-informed machine learning[J]. *Nature Reviews Physics*, 2021, 3(6): 422–440.
- [20] Jin Xiaowei, Cai Shengze, Li Hui, et al. NSFnets (Navier-Stokes flow nets): Physics-informed neural networks for the incompressible Navier-Stokes equations[J]. *Journal of Computational Physics*, 2021, 426: 109951.
- [21] Zhang Ruiyang, Liu Yang, Sun Hao. Physics-guided convolutional neural network (PhyCNN) for data-driven seismic response modeling[J]. *Engineering Structures*, 2020, 215: 110704.
- [22] Liu Zhenliang, Guo Anxin. Empirical-based support vector machine method for seismic assessment and simulation of reinforced concrete columns using historical cyclic tests[J]. *Engineering Structures*, 2021, 237: 112141.
- [23] Xie Yazhou, Ebad Sichani M, Padgett J E, et al. The promise of implementing machine learning in earthquake engineering: A state-of-the-art review[J]. *Earthquake Spectra*, 2020, 36(4): 1769–1801.
- [24] Huang Caigui, Huang Surong. Predicting capacity model and seismic fragility estimation for RC bridge based on artificial neural network[J]. *Structures*, 2020, 27: 1930–1939.
- [25] Xu Jigang, Hong Wan, Zhang Jian, et al. Seismic performance assessment of corroded RC columns based on data-driven machine-learning approach[J]. *Engineering Structures*, 2022, 255: 113936.
- [26] Liu Zhenliang, Li Suchao. Development of an ANN-based lumped plasticity model of RC columns using historical pseudo-static cyclic test data[J]. *Applied Sciences*, 2019, 9(20): 4263.

- [27] Verderame G M, Ricci P. An empirical approach for nonlinear modelling and deformation capacity assessment of RC columns with plain bars[J]. *Engineering Structures*, 2018, 176: 539–554.
- [28] Haselton C B, Liel A B, Taylor C, et al. Calibration of model to simulate response of reinforced concrete beam-columns to collapse[J]. *ACI Structural Journal*, 2016, 113(6): 1141–1152.
- [29] Xiao Yan, Yun H W. Experimental studies on full-scale high-strength concrete columns[J]. *ACI Structural Journal*, 2002, 99(2): 199–207.
- [30] Ahn J M, Shin S W. An evaluation of ductility of high-strength reinforced concrete columns subjected to reversed cyclic loads under axial compression[J]. *Magazine of Concrete Research*, 2007, 59(1): 29–44.

Empirical Knowledge-guided Neural Network Method for Mechanical Performance Analysis of RC Columns

LIU Zhenliang^{1,2}, LI Suchao^{2,3}, ZHAO Cunbao^{1*}

(1. School of Safety Eng. and Emergency Management, Shijiazhuang Tiedao Univ., Shijiazhuang 050043, China;

2. Key Lab. of Large Structure Health Monitoring and Control, Shijiazhuang 050043, China;

3. School of Civil Eng., Harbin Inst. of Technol. (Weihai), Weihai 264209, China)

Abstract: The mechanical performance analysis of reinforced concrete (RC) columns using only experimental or numerical methods usually faces challenges in balancing computational accuracy and efficiency, while purely data-driven methods suffered from poor interpretability and over-dependence on available data samples. To address this issue, an empirical knowledge guided neural network (KGNN)-based RC column analysis by investigating the fusion mechanism of empirical knowledge, test data and machine learning methods. A test database is firstly built based on 761 quasi-static test specimens. In succession, the influence rules of primary characteristics of RC columns on their mechanical properties are analyzed based on empirical knowledge to formulate mathematical representations. Finally, the test data and empirical knowledge were implemented into the artificial neural network to develop high performance, explainable, generalizable KGNN model with only minor training samples. The result comparisons of the proposed KGNN method and the pure data-driven neural network (BPNN) demonstrate that although the BPNN slightly over the KGNN in terms of the load-carrying capacity prediction accuracy, with mean square error and correlation coefficient of 0.070 and 0.978 comparing to 0.108 and 0.942 of the KGNN. However, the results of the BPNN are not consistent with the empirical knowledge and further causes overfitting problem since it fails to capture the relationship between the characteristics and mechanical properties of RC columns. Fortunately, the KGNN method can not only quickly and accurately provide the mechanical properties of RC columns, but also present a higher consistency with the empirical knowledge with greater reliability and practicality. Through this work, the neural network-based methods integrating experimental data and empirical knowledge are expected to provide a novel analysis approach for RC structures.

Key words: RC column; physics and data driven neural network; empirical knowledge; mechanical properties; test database

(编辑 吴芝明)

引用格式: Liu Zhenliang, Li Suchao, Zhao Cunbao. Empirical knowledge-guided neural network method for mechanical performance analysis of RC columns[J]. *Advanced Engineering Sciences*, 2024, 56(1): 35–43. [刘振亮, 李素超, 赵存宝. 经验知识监督的RC墩柱力学性能神经网络分析方法[J]. *工程科学与技术*, 2024, 56(1): 35–43.]