

基于BP神经网络的超高性能混凝土抗压强度预测

曹昌昊, 王 涛, 江可飞

上海理工大学环境与建筑学院, 上海

收稿日期: 2025年1月18日; 录用日期: 2025年2月11日; 发布日期: 2025年2月18日

摘 要

超高性能混凝土(UHPC)因其优异的力学性能和耐久性, 广泛应用于高层建筑、桥梁等结构中。抗压强度是评估其力学性能的重要指标, 掌握其规律并准确预测抗压强度是研究UHPC的关键。然而, 传统的抗压强度预测方法往往存在复杂性、计算量大和缺乏自适应能力的问题。相较之下, BP神经网络能够通过学习大量实验数据, 自主调整网络权重, 从而优化预测精度。本文基于BP神经网络, 提出了一种用于预测UHPC抗压强度的新方法。通过收集不同配比下的实验数据, 设计了一个包含输入层(10个节点)、双隐含层(第一层12个节点、第二层24个节点)和输出层(1个节点)的神经网络结构。结果表明, BP神经网络能够有效捕捉UHPC的非线性特征, 并具有较高的预测精度。研究表明, 该方法为UHPC抗压强度的快速预测提供了有效的解决方案, 并为其配比设计与工程应用提供了理论支持。

关键词

超高性能混凝土, BP神经网络, 抗压强度预测, 配合比设计

The Prediction of Compressive Strength of Ultra-High Performance Concrete Based on BP Neural Networks

Changhao Cao, Tao Wang, Kefei Jiang

School of Environment and Architecture, University of Shanghai for Science and Technology

Received: Jan. 18th, 2025; accepted: Feb. 11th, 2025; published: Feb. 18th, 2025

Abstract

Ultra-high performance concrete (UHPC) is widely used in high-rise buildings, bridges, and other

文章引用: 曹昌昊, 王涛, 江可飞. 基于BP神经网络的超高性能混凝土抗压强度预测[J]. 建模与仿真, 2025, 14(2): 17-24. DOI: 10.12677/mos.2025.142127

structures due to its excellent mechanical properties and durability. Compressive strength is a key indicator for evaluating its mechanical performance, and understanding its patterns and accurately predicting compressive strength are crucial for UHPC research. However, traditional methods for predicting compressive strength often suffer from complexity, large computational demands, and a lack of adaptability. In contrast, BP neural networks can learn from large amounts of experimental data and autonomously adjust the network weights, thereby optimizing prediction accuracy. This paper proposes a novel method for predicting the compressive strength of UHPC based on a BP neural network. By collecting experimental data from different mix proportions, a neural network structure consisting of an input layer (10 nodes), two hidden layers (12 nodes in the first layer and 24 nodes in the second layer), and an output layer (1 node) was designed. The results indicate that the BP neural network can effectively capture the nonlinear characteristics of UHPC and achieve high prediction accuracy. The study demonstrates that this method provides an effective solution for the rapid prediction of UHPC compressive strength and offers theoretical support for its mix design and engineering applications.

Keywords

Ultra-High Performance Concrete, BP Neural Network, Compressive Strength Prediction, Mix Ratio Design

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

混凝土作为建筑工程中最常用的材料，在结构安全与耐久性中扮演着至关重要的角色。经过数十年的技术发展，混凝土的种类从普通混凝土扩展到高性能混凝土(High-Performance Concrete, HPC)、轻质混凝土(Lightweight concrete, LWC)以及超高性能混凝土(Ultra-High Performance Concrete, UHPC)等多个类别[1]-[3]。其中，UHPC 以其优异的力学性能和耐久性在高层建筑、桥梁、大跨度结构等领域展现出巨大的应用潜力。UHPC 通常具有超过 150 MPa 的抗压强度，同时表现出显著的延性和抗裂性。这些特性得益于其精细化的配合比设计，包括超细矿物掺合料、高效减水剂、钢纤维以及优化的骨料级配。随着 UHPC 应用场景的拓展，对其力学性能的精准预测需求越发迫切。

混凝土的抗压强度是评价其力学性能的重要指标[4]，直接关系到结构设计的合理性与施工安全性。传统的强度预测方法通常依赖于统计、经验公式和数值模型[5]-[7]。这些方法尽管直观，但在实际工程中存在明显的局限性[8]。一方面，试验方法成本高、耗时长，难以适应复杂工程的需求；另一方面，统计方法通常假设输入参数与强度之间具有线性或简单非线性关系，未能充分考虑影响混凝土性能的复杂非线性特征，尤其是在涉及多种掺合料和精细配比的 UHPC 中，这种局限性尤为突出。因此，迫切需要一种能够有效捕捉复杂影响因素关系的预测方法。

近年来，随着人工智能技术的飞速发展，基于机器学习的方法在工程领域得到了广泛应用[9] [10]。神经网络因其强大的非线性建模能力和自适应学习特性，为 UHPC 抗压强度的预测提供了全新的解决方案。相比传统方法，神经网络能够自动从大规模数据中学习特征模式，有效整合多种影响因素(如水泥种类与用量、矿物掺合料、骨料级配、养护条件等)，显著提升预测的精度与可靠性。此外，神经网络无需预设复杂的数学模型，而是通过训练数据直接生成预测模型，既降低了对人工经验的依赖，又使模型具有较强的泛化能力和动态调整能力。

基于上述背景, 本文结合近年来 UHPC 抗压强度预测领域的研究进展, 构建了一种基于神经网络的预测模型。本研究搜集并整合了国内外 181 组不同掺合料配比的 UHPC 试验数据, 建立了以水泥、硅灰、粉煤灰、水、钢纤维等参数为输入变量, UHPC 抗压强度为输出变量的数据库。在此基础上, 通过训练和验证, 分析预测结果与试验数据的偏差, 优化模型结构并确定最佳预测方案。研究旨在探索机器学习方法在 UHPC 强度预测中的应用潜力, 推动混凝土性能预测的智能化和自动化。

本研究不仅为 UHPC 抗压强度的快速预测提供了新思路, 同时也为其材料设计与性能优化奠定了数据支持和技术基础。

2. 数据库构建

2.1. 数据库建立标准

对于数据库制定以下标准以筛选现有文献中的试验数据, 以确保研究数据库的一致性和适用性。

- 1) 实验中的混凝土强度指试块养护条件应为温度 $20 \pm 2^{\circ}\text{C}$ 、相对湿度 90%、28 天龄期的立方体抗压强度。
- 2) 收集的试验数据应该包含几何特征、材料特性及用量、试验结果等方面。
- 3) 文献中混凝土试块制备过程和配合比(水胶比、砂率、胶凝材料与骨料用量、粉煤灰掺量等)需要在文献中说明。

根据以上选择标准, 收集并整合了近年来国内外既有的 181 组不同掺合料配比的混凝土强度试验数据, 建立了数据库。最终确立每立方米中水泥、硅灰、粉煤灰、水、石英粉、高效减水剂、细骨料、钢纤维、石灰粉、高炉矿渣用量 10 个参数作为特征值。

2.2. 数据库参数分布特征

为了更加全面地研究这些参数的分布特征, 本文对数据库进行了参数统计, 具体结果见表 1。

Table 1. Characteristics of database parameter data distribution

表 1. 数据库参数数据分布特征

参数	最大值	最小值	平均值	中值	标准差
水泥/kg.m ⁻³	1251.2	325.3	754.9	788.5	173.6
硅灰/kg.m ⁻³	433.7	0	186	200	109.1
粉煤灰/kg.m ⁻³	356	0	33.8	0	76.2
水/kg.m ⁻³	272.6	144	187.8	178	26.6
石英粉/kg.m ⁻³	397	0	37.1	0	92.8
高效减水剂/kg.m ⁻³	57	5.1	31.4	30.2	14.7
细骨料/kg.m ⁻³	1502.8	407.8	1045.4	1049	215.1
钢纤维/kg.m ⁻³	234	0	82.1	78	81.3
石灰粉/kg.m ⁻³	1058.2	0	26.5	0	116.3
高炉矿渣/kg.m ⁻³	375	0	40	0	95.8
抗压强度/MPa	220.5	88.6	143	139.6	29.6

同时, 分析了输入参数和 UHPC 抗压强度的相关性, 以了解数据集的复杂性, 如图 1 所示。分析表明抗压强度与硅灰掺量相关性最大(0.65)。另一方面, 输入参数之间的相关性相关系数最大值和最小值分

别为 0.57 和-0.64，各参数之间没有依赖关系。




Figure 1. Heat map of feature correlation coefficients
图 1. 特征相关系数热力图

3. 模型建立与结果讨论

3.1. BP 神经网络

本研究使用了 BP 神经网络(Backpropagation Neural Network)，也称为多层感知机(Multi-Layer Perceptron, MLP)，由输入层、隐藏层和输出层组成，其主要特点是通过反向传播从输出层向输入层传播误差信号，更新模型权重参数，以最小化损失函数，得到目标模型，BP 神经网络的工作原理如图 2 所示。




Figure 2. BP neural network schematic
图 2. BP 神经网络工作原理示意图

3.2. 神经网络的设计

隐含层数、神经元数、学习率等参数是影响神经网络性能的重要参数，是决定预测模型性能的重要因素，但目前没有固定的算法来进行确定，通常需要经过不断迭代和验证来寻找较优的解决方案。

1) 网络层数：

本项目的神经网络包括输入层、输出层和两层隐含层。

2) 输入层：

输入层用于接收数据库中包含的特征值变量，本研究涉及到的特征值个数为 10，神经元个数设定为 10。

3) 输出层：

输出层用于输出模型预测的 UHPC 抗压强度，神经元个数为 1。

4) 隐含层：

经过验证，在本模型中，单隐含层的网络效果不佳，故选用双隐含层的网络结构。第一层隐含层神经元为 j ，第二层为 $2j$ 。隐含层神经元数没有确定的最优算法，采用经验公式[11]，通过不断训练和误差分析来确定合适的隐含层神经元数。经验公式如下：

$$j = \sqrt{m + n} + a$$

式中 m 为输入层神经元个数； n 为输出层神经元个数中， a 为 1~10 之间的常数。根据计算结果，神经元数量与模型训练效果的关系如图 3 所示。对于训练集，随着神经元数量的增加，决定系数呈上升趋势，且误差逐渐减小，但变化趋于平缓。对于测试集，当神经元数量为 12 时，决定系数达到最大值，误差最小；超过 12 个神经元后，模型性能开始下降。因此，隐含层神经元数取 12 时，模型的综合效果最佳。




Figure 3. The number of neurons in the first hidden layer affects the effect of the model

图 3. 第一层隐含层神经元个数对模型效果影响

5) 激活函数：

采用 tanh 激活函数，计算式如下：

$$\tanh = \frac{1 - e^{-2x}}{1 + e^{-2x}}$$

6) 学习率：

学习率的选择至关重要。学习率与权值更新的幅度成正比，过大会导致权值变化过大，而过小则会影响收敛速度。本文模型的学习率设定为 0.001。

7) 学习次数：

学习次数需要根据具体情况确定。较大的学习次数通常提高预测精度，但也会增加计算时间成本。本文所用模型的学习次数设定为 3000 次，以确保模型能够达到收敛状态。

最终的神经网络拓扑结构见图 4。




Figure 4. Neural network topology
图 4. 神经网络拓扑结构

3.3. 神经网络模型训练

从数据集中随机抽取 90%数据作为训练集用于模型训练，其余 10%数据作为测试集对模型进行泛用性检验。

将数据中 10 个特征值作为输入变量，混凝土强度作为输出变量，将训练集均分为五份，定义五折交叉训练，对模型进行训练，建立混凝土强度预测模型；用这个模型对训练集数据进行推广预测，测试其泛化能力。

输出模型参数，并评价模型。以均方根误差(Root Mean Square Error, RMSE)、平均绝对误差(Mean Absolute Error, MAE)、决定系数(Coefficient of Determination, R2)作为对模型的评价指标，其计算方式即代表意义见表 2。

Table 2. Statistical indicators of model prediction results
表 2. 模型预测结果统计指标

参数	计算公式	意义
均方根误差	$\sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - p_i)^2}$	衡量预测值与真实值的差距
平均绝对误差	$\frac{1}{n} \sum_{i=1}^n y_i - p_i $	预测值与真实值之间的平均误差幅度
决定系数	$\frac{\sum_{i=1}^n (y_i - p_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$	表示模型解释数据变异性的比例

3.4. 神经网络模型结果

神经网络模型的均方根误差(RMSE)、平均绝对误差(MAE)、决定系数(R²)指标，见表 3。

Table 3. Model prediction accuracy
表 3. 模型预测精度

参数	训练集	测试集
均方根误差	5.777	10.407
平均绝对误差	3.383	7.692
决定系数	0.959	0.915

对比分析模型所得到的预测值与真实值。图 5 为模型训练、测试数据拟合得到的真实值与预测值关系图。结果表明模型实际值与预测值误差较小，模型拟合效果优异。




Figure 5. Prediction results of UHPC compressive strength of neural network model
图 5. 神经网络模型 UHPC 抗压强度预测结果

4. 结论

基于 BP 神经网络，提出了一种超高性能混凝土(UHPC)抗压强度的预测方法，研究表明：

1) UHPC 的抗压强度主要受水泥、硅灰、减水剂和钢纤维等的影响。本文设计的 BP 神经网络，可以较好地反映 UHPC 配合比和抗压强度的影响关系。

2) BP 神经网络模型预测的均方误差在训练集中为 5.777，在测试集中为 10.407；平均绝对误差在训练集中为 3.383，在测试集中为 7.692；决定系数在训练集中达到 0.959，在测试集中达到 0.915。可见 BP 神经网络模型在预测 UHPC 抗压强度方面表现出较高的准确性、较小的误差和更强的泛化能力，故可以借助 BP 神经网络模型来准确预测 UHPC 的抗压强度。

3) 基于 BP 神经网络的配合比设计可以指导 UHPC 的性能调控，通过进一步的开发，可实现量化不同成分的影响、建立不同配合比同 UHPC 性能的关联来帮助从业者改进配合比设计，能够有效减少试验过程中耗费的人力、物力和财力，提高效率。

参考文献

- [1] Kockal, N.U. and Ozturan, T. (2011) Strength and Elastic Properties of Structural Lightweight Concretes. *Materials & Design*, **32**, 2396-2403. <https://doi.org/10.1016/j.matdes.2010.12.053>
- [2] Zhu, H., Wang, Z., Xu, J. and Han, Q. (2019) Microporous Structures and Compressive Strength of High-Performance Rubber Concrete with Internal Curing Agent. *Construction and Building Materials*, **215**, 128-134. <https://doi.org/10.1016/j.conbuildmat.2019.04.184>

-
- [3] Wetzel, A. and Middendorf, B. (2019) Influence of Silica Fume on Properties of Fresh and Hardened Ultra-High Performance Concrete Based on Alkali-Activated Slag. *Cement and Concrete Composites*, **100**, 53-59. <https://doi.org/10.1016/j.cemconcomp.2019.03.023>
- [4] Ghafoorian Heidari, S.I., Safehian, M., Moodi, F. and Shadroo, S. (2024) Predictive Modeling of the Long-Term Effects of Combined Chemical Admixtures on Concrete Compressive Strength Using Machine Learning Algorithms. *Case Studies in Chemical and Environmental Engineering*, **10**, Article 101008. <https://doi.org/10.1016/j.cscee.2024.101008>
- [5] Bogas, J.A. and Gomes, A. (2013) Compressive Behavior and Failure Modes of Structural Lightweight Aggregate Concrete—Characterization and Strength Prediction. *Materials & Design* (1980-2015), **46**, 832-841. <https://doi.org/10.1016/j.matdes.2012.11.004>
- [6] 许开成, 毕丽苹, 陈梦成. 基于 SPSS 回归分析的锂渣混凝土抗压强度预测模型[J]. 建筑科学与工程学报, 2017, 34(1): 15-24.
- [7] Ke, Y., Tian, J., Zhang, T.R., Lin, G. and Zhang, S.S. (2024) Compressive Behavior and Strength Model of Novel FRP-UHPC Strengthened RC Columns. *Journal of Building Engineering*, **98**, Article 111383. <https://doi.org/10.1016/j.jobbe.2024.111383>
- [8] Yan, J., Su, J., Xu, J., Lin, L. and Yu, Y. (2024) Ensemble Machine Learning Models for Compressive Strength and Elastic Modulus of Recycled Brick Aggregate Concrete. *Materials Today Communications*, **41**, Article 110635. <https://doi.org/10.1016/j.mtcomm.2024.110635>
- [9] Chithra, S., Kumar, S.R.R.S., Chinnaraju, K. and Alfin Ashmita, F. (2016) A Comparative Study on the Compressive Strength Prediction Models for High Performance Concrete Containing Nano Silica and Copper Slag Using Regression Analysis and Artificial Neural Networks. *Construction and Building Materials*, **114**, 528-535. <https://doi.org/10.1016/j.conbuildmat.2016.03.214>
- [10] 张学鹏, 张戎令, 陈心亮, 等. 基于 GA-BP 神经网络长服役期内结构混凝土的强度演变预测[J]. 中南大学学报(自然科学版), 2024, 55(2): 836-850.
- [11] 夏克文, 李昌彪, 沈钧毅. 前向神经网络隐含层节点数的一种优化算法[J]. 计算机科学, 2005, 32(10): 143-145.