

微观力学机理与深度学习的融合方法

——在ECC材料极限拉应变预测中的应用

叶斌斌, 敦梓檬, 马荣刚

中国矿业大学(北京)力学与土木工程学院, 北京

收稿日期: 2026年2月3日; 录用日期: 2026年2月17日; 发布日期: 2026年3月17日

摘要

为克服传统水泥基材料依赖经验设计与重复试验、抗拉强度低且脆性易裂的问题, 基于微观力学原理设计的高延性水泥基复合材料(ECC)显著提升了材料的延展性与控裂性能, 其极限拉应变高出普通混凝土2~3个数量级, 适用于工程结构抗震韧性提升。然而, ECC的配合比设计与性能优化仍依赖于试验测试与验证。因此, 文章提出将深度学习(DNN)模型应用于ECC性能预测与验证, 利用既有数据与微观力学原理筛选关键特征参数, 构建DNN模型, 实现对极限拉应变的准确预估, 从而显著降低试验依赖。结果表明, 该方法概念清晰、准确性高, 对学生理论基础要求适中, 适用于本科智能建造类课程教学, 有助于培养学生跨学科解决实际工程问题的能力。

关键词

微观力学, ECC材料, 深度学习, 模型预测

Integrating Micromechanical Principles with Deep Learning

—Application to Ultimate Tensile Strain Prediction of Engineered Cementitious Composites

Binbin Ye, Zimeng Dun, Ronggang Ma

School of Mechanics and Civil Engineering, China University of Mining and Technology (Beijing), Beijing

Received: February 3, 2026; accepted: February 17, 2026; published: March 17, 2026

Abstract

To overcome the limitations of traditional cementitious materials, such as reliance on empirical design

and iterative testing, low tensile strength, and brittle behavior, Engineered Cementitious Composites (ECC) have been developed based on micromechanical principles. ECC significantly enhances material ductility and crack control, with its ultimate tensile strain exceeding that of ordinary concrete by 2~3 orders of magnitude, making it highly suitable for improving seismic resilience in engineering structures. However, the mix design and performance optimization of ECC still heavily depend on experimental testing and validation. Therefore, this paper proposes the application of a Deep Neural Network (DNN) model for predicting and validating the mechanical properties of ECC. By leveraging existing experimental data and incorporating micromechanical principles to screen key feature parameters, a DNN model was constructed to accurately predict the ultimate tensile strain, thereby substantially reducing reliance on physical testing. The results demonstrate that the proposed method is conceptually clear and exhibits high predictive accuracy. With moderate requirements for students' theoretical background, this approach is suitable for integration into undergraduate courses such as intelligent construction, fostering students' ability to solve practical engineering problems through interdisciplinary means.

Keywords

Micromechanics, Engineered Cementitious Composites (ECC), Deep Learning, Predictive Modeling

Copyright © 2026 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

水泥基材料是现代土木工程的基石，然而其固有的脆性与低抗拉强度一直是制约结构性能与耐久性的核心瓶颈。传统混凝土材料的设计与优化主要依赖长期工程经验与大量重复性试验，这种“试错法”模式周期长、成本高，而且难以系统揭示材料组成、微观结构与宏观性能之间的内在关联。在高性能、长寿命及极端荷载(如地震、冲击)工程应用背景下，开发兼具高延展性、优异控裂性能及损伤容限的新型水泥基材料，已成为提升工程结构韧性的重要前沿方向[1]。

为从根本上突破传统水泥基材料的性能局限，基于微观力学(Micromechanics)原理进行材料设计的理念应运而生。高延性(超高韧性)纤维增强水泥基复合材料(Engineered Cementitious Composites, ECC)是这一理念的成功典范。其通过系统调控纤维、基体与界面过渡区的微观力学行为，实现了拉伸荷载下的稳态多缝开裂与显著的应变硬化特性，其极限拉应变通常可达 3%~12%，超出普通混凝土 2~3 个数量级，同时裂缝宽度可控制在 100 μm 以内，其已在结构抗震加固等领域展现出巨大应用潜力[1]-[4]。

尽管微观力学原理为 ECC 材料的设计提供了科学框架(如基于能量准则与强度准则的配比设计方法)，但其在实际工程中的推广仍面临显著挑战：其一，理论模型往往包含若干测定难度较高的细观参数(如纤维-基体界面粘结强度、基体断裂韧性等)，仍需借助精细试验进行标定；其二，ECC 性能受水泥类型、掺合料品种与比例、纤维特性、水胶比等众多因素交织影响，存在高度的非线性效应。因此，ECC 的研发与应用仍无法摆脱“设计-制备-测试-调整”的循环，制约了材料创新与性能优化。机器学习模型，以其强大的非线性拟合、高维特征识别与从数据中自动学习规律的能力，在材料性能预测、新发现及工艺优化等领域取得了突破性进展。研究者已成功将支持向量机、随机森林等算法应用于预测混凝土强度、弹性模量、耐久性等指标，证明了数据驱动方法在捕捉材料组成-性能关联方面的有效性[5] [6]。

本文提出一种微观力学机理与深度学习相融合的 ECC 极限拉应变预测与验证新方法，深入剖析 ECC

应变硬化的微观力学能量准则与桥联规律，系统提炼出影响极限拉应变的关键物理特征；构建“物理-数据”混合训练集，建立从材料配合比到极限拉应变的预测模型，并将本方法流程进行模块化、步骤化设计，形成一套概念清晰、操作性强的技术方案。该方案对学生的先修力学知识要求适中，却完整展现了从物理建模、数据准备、机器学习到工程验证的材料研发全流程，非常适合作为本科生智能建造的教学案例，有助于培养学生的多学科交叉创新思维与解决复杂工程实际问题的综合能力。

2. 研究方法

2.1. ECC 微观力学模型

纤维增强水泥基复合材料的核心制备理论基于纤维桥联效应。该效应保障了材料在受拉状态下裂缝的稳态扩展，进而形成了高延性水泥基复合材料特有的多点开裂力学行为。这一过程的实现，主要依托于强度准则与能量准则的共同调控，见图 1 [7]。

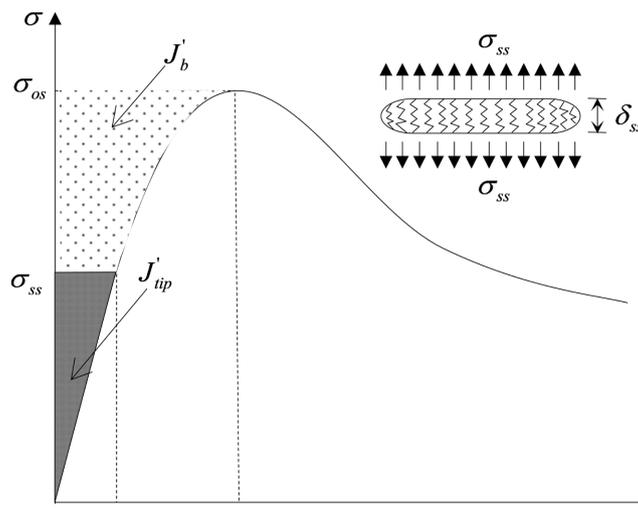


Figure 1. Microscopic mechanical mechanism of Engineered Cementitious Composites (ECC) [7]

图 1. ECC 材料微观力学机理[7]

1) 强度准则

根据 ECC 的微观设计理论，其多点开裂的触发依赖于基体与纤维之间的应力重分布。当外荷载使基体应力超过其初裂强度 σ_{ss} (该强度受内部孔隙及缺陷控制) 时，便会形成首条裂缝。此时，跨越裂缝的纤维通过界面粘结作用立即承担该处的拉应力，并将其回传至上下方的基体。由于纤维的桥联作用 σ_{os} ，应力传递区域内的基体应力再度累积，直至达到新的开裂强度，从而引发下一条裂缝。此过程循环往复，最终形成饱和的微裂缝体系。如果纤维在裂缝处过早断裂或轻易拔出，无法实现应力有效传递，导致纤维桥联应力 σ_{os} 小于基体开裂强度 σ_{ss} ，材料无法实现受拉应变硬化特性。一般而言，提高强度准则系数 σ_{os}/σ_{ss} 有助于优化 ECC 的应变硬化与多点开裂性能。影响 ECC 材料开裂强度 σ_{ss} 的指标包括水胶比、集胶比、活性胶凝材料用量等基体参数。而影响纤维桥联应力的因素则包括纤维/基体界面粘结强度、纤维掺量、纤维长径比等。

2) 能量准则

根据能量平衡原理，裂缝实现稳态扩展需满足以下守恒条件：外力对 ECC 试件所做的功，在数值上

应等于两部分能量消耗之和：其一是驱动裂缝尖端向前扩展所需克服的基体断裂能 J_{ip} ，其二是克服纤维桥联约束，使裂缝稳定张开所耗散的能量 J'_b 。该能量守恒关系可由式(1)和式(2)定量描述。此外，为确保裂缝扩展处于稳态，裂缝尖端扩展强度必须小于纤维桥联提供的最大补足能量 J'_b 。因此，需通过定向设计，获取足够的补足能量，从而促使材料实现多点开裂。

$$\sigma_{ss}\delta_{ss} - \int_0^{\delta_{ss}} \sigma(\delta)d\delta = J_{ip} \quad (1)$$

$$J_{ip} = \frac{K_m^2}{E_c} \quad (2)$$

式中 J_{ip} 为抵消裂缝尖端强度所需的能量， K_m 为基体的断裂韧性， E_c 为复合材料的弹性模量。式(1)左侧通常称为补足能量，补足能量 J'_b 的最大值见式(3)。

$$J'_b = \sigma_0\delta_0 - \int_0^{\delta_0} \sigma(\delta)d\delta \quad (3)$$

提升能量准则系数 J'_b/J_{ip} 对获得裂缝的稳态扩展有利。影响最大补足能量的主要因素包括纤维/基体界面粘结强度、纤维体积掺量、纤维长径比等。裂缝尖端扩展强度的主要影响因素为基体水胶比、集胶比、活性胶凝材料用量。

综上所述，ECC 成功实现高延性的核心在于纤维、基体与界面的多尺度协同。借助微观力学理论，通过设计纤维桥联机制来满足强度与能量准则，能够有效引导裂缝以稳态模式扩展，进而使材料展现出特征性的多点开裂行为与优异的应变硬化能力。基于微观力学理论，影响上述三方面性能的关键配合比参数包括：水胶比、集胶比、活性胶凝材料用量、纤维类型与体积掺量、纤维长径比等。

2.2. ECC 极限拉应变数据构建

基于 ECC 材料制备的微观力学机理，从已有的文献报道中共收集了 403 组 ECC 材料极限拉应变数据，数据集统一设定水泥用量比例为 1.0，其他组分比例均以水泥为基准进行表述。输入特征共 11 项，包括水胶比(WB)、硅灰(SF)、矿渣(GGBS)、粉煤灰(FA)、煤矸石粉(CGP)、石英砂(SS)、纤维体积掺量(FC)、减水剂(WR)、纤维类型(FT)、纤维长径比(FAR)、水泥标号(CG)。输出标签为极限拉应变(TSC：0.002%~12.3%)。其中，纤维类型分为：表面涂油聚乙烯醇纤维(PVA-O)、表面未涂油聚乙烯醇纤维(PVA-UO)、超高分子量聚乙烯纤维(PE)、无纤维(NF)以及聚丙烯纤维(PP)，水泥标号分为 PO.42.5 和 PO.52.5。本数据集包含的数据为 28 天标准养护条件下采用变速搅拌方法制备的试件数据[5]。

3. 深度学习(DNN)模型训练

人工神经网络(Artificial Neural Network, ANN)通过模拟人脑中神经元之间的联结与信息处理机制，构建出具有学习和泛化能力的计算模型。神经网络的基本结构采用层级堆叠模式，由输入层、若干隐藏层及输出层依次连接而成。随着模型结构的深化，当隐藏层数量显著增加时，便形成了所谓“深度学习”模型(Deep Neural Network, DNN)。这类模型通过构建更深的网络层次(可多达数百层)，能够自动提取数据中的高阶抽象特征，从而在复杂任务中表现出更强的表示与预测能力。

3.1. 数据预处理结果

模型训练与测试采用十折交叉验证结合数据集划分的方式进行：80%的数据用作训练集，剩余 20% 留作测试集，以评估模型的泛化能力。为消除特征量纲差异对模型训练准确性的影响，采用标准化(StandardScaler)对特征数据进行预处理。模型性能评估采用平均绝对误差(MAE)、决定系数(R²)和均方根

误差(RMSE)三项指标。

3.2. 训练细节

构建的神经网络模型包括输入层、隐藏层与输出层，输入层特点为接收 m 维特征向量；隐藏层采用 ReLU 激活函数，引入 Dropout 正则化防止过拟合，输出层为单神经元结构，适用于回归任务，模型采用正则化策略，其中 Dropout 率为 0.2~0.5，根据超参数调优确定，同时采用 Adam 优化器结合权重衰减实现 L2 正则化。

超参数调优采用 Optuna 框架进行贝叶斯优化，将隐藏层数、每层神经元数、学习率、Dropout 率及批大小等参数设置搜索空间，经多轮实验优化，确定最优超参数组合为：隐藏层数 2 层、第一层神经元 59 个、第二层神经元 213、学习率 0.00103、Dropout 率 12.9%、批大小 16。

模型选用 Adam 优化器，损失函数为均方误差(MSE)，训练轮次设定为 100~150 epoch，并采用早停策略，通过监控验证损失以抑制过拟合；为进一步提升模型稳定性与泛化能力，还采用十折交叉验证进行模型进行评估与验证。

3.3. 模型预测性能对比分析

经过上述建模与优化过程，神经网络在训练集与测试集上的表现见图 2：

- 1) 训练集表现：平均绝对误差(MAE)为 0.6041，均方根误差(RMSE)为 0.8340；决定系数(R^2)达到 0.9020。
- 2) 测试集表现：平均绝对误差(MAE)为 0.9396，均方根误差(RMSE)为 1.2687，决定系数(R^2)为 0.7514。

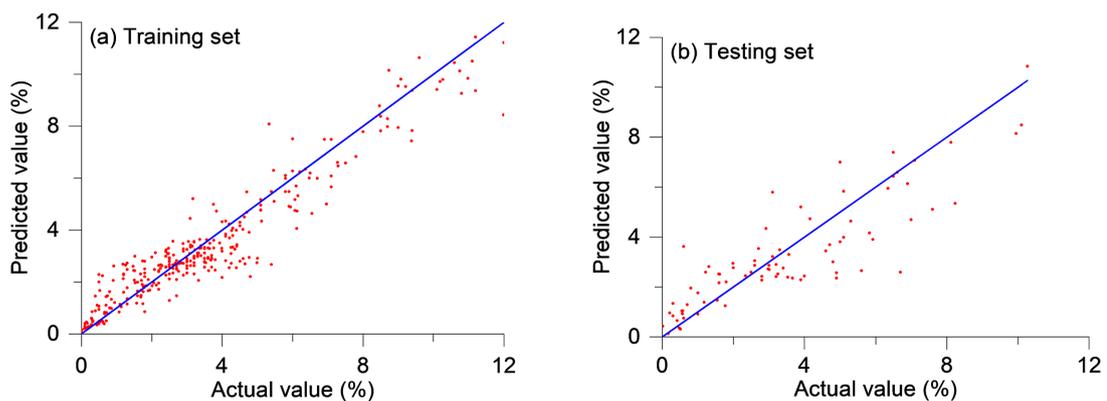


Figure 2. Comparison between predicted and actual ultimate tensile strain

图 2. 极限拉应变预测值与实际值对比

从结果可以看出，模型在训练集上取得了较高的拟合优度($R^2 > 0.9$)，表明其具备良好的学习能力；在测试集上 R^2 为 0.7514，说明模型具备一定的泛化能力，具有较好的预测实用性，但训练集和测试集在误差指标上存在明显差距，未来可考虑引入更复杂的网络结构、增强数据多样性或采用集成学习方法以增强模型鲁棒性与泛化能力。

4. 结论

本研究针对 ECC 材料配合比设计与性能预测中试验依赖性强、理论模型与经验方法能力不足的问题，提出了一种融合微观力学机理与深度学习的数据驱动预测方法，并成功应用于 ECC 材料极限拉应变的高精度预估与验证。构建了基于神经网络(DNN)的 ECC 极限拉应变预测模型，经十折交叉验证优

化后,在测试集上 RMSE 为 1.2687%。该精度可用于材料初步筛选与性能趋势预测,但尚不足以直接支撑关键构件的极限状态设计,主要瓶颈在于数据规模有限、关键微观参数缺失及缺乏物理准则的显式约束。此方法步骤明确、逻辑闭环,对学生先修知识要求适中,适用于本科智能建造课程教学,有助于培养学生多学科交叉创新与解决复杂工程问题的综合素养。

基金项目

本研究受到中国矿业大学(北京)本科教育教学改革与研究项目(J251511)支持。

参考文献

- [1] Ye, B., Wang, H., Chen, X., Su, Y., Miao, Q. and Pan, P. (2025) Full-Scale Test of Damaged Reinforced Concrete (RC) Columns Retrofitted with High-Strength Engineered Cementitious Composites (HSECC). *Journal of Building Engineering*, **112**, Article ID: 113525. <https://doi.org/10.1016/j.jobbe.2025.113525>
- [2] 曹明莉, 许玲, 张聪. 高延性纤维增强水泥基复合材料的微观力学设计、性能及发展趋势[J]. 硅酸盐学报, 2015, 43(5): 632-642.
- [3] 蔡履沐, 叶斌斌, 王海深, 等. ECC 材料性能进展及其在建筑结构中的应用[J]. 建筑结构, 2024, 54(22): 93-99.
- [4] Ding, Y., Yu, K. and Li, M. (2022) A Review on High-Strength Engineered Cementitious Composites (HS-ECC): Design, Mechanical Property and Structural Application. *Structures*, **35**, 903-921. <https://doi.org/10.1016/j.istruc.2021.10.036>
- [5] Qing, S. and Li, C. (2024) Data-Driven Prediction on Critical Mechanical Properties of Engineered Cementitious Composites Based on Machine Learning. *Scientific Reports*, **14**, Article No. 15322. <https://doi.org/10.1038/s41598-024-66123-9>
- [6] Wang, Y., Sun, J., Wang, X., Li, S., Zhao, H., Huang, B., *et al.* (2024) Multi-Objective Optimization of Engineered Cementitious Composite Based on Machine Learning and Generative Adversarial Network. *Journal of Building Engineering*, **96**, Article ID: 110471. <https://doi.org/10.1016/j.jobbe.2024.110471>
- [7] Li, V.C. (1993) From Micromechanics to Structural Engineering—The Design of Cementitious Composites for Civil Engineering Applications. *Journal of Structural Mechanics and Earthquake Engineering*, **10**, 37-48.