

DOI:10.14048/j.issn.1671-2579.2021.04.066

# 基于 GA—ELM 的水性环氧乳化沥青黏结性能预测

陆由付<sup>1</sup>, 樊振通<sup>2</sup>, 韩冰<sup>1</sup>, 王朝辉<sup>2\*</sup>, 陈宝<sup>3</sup>

(1. 齐鲁交通发展集团有限公司, 山东 济南 250000; 2. 长安大学 公路学院; 3. 河南官渡黄河大桥开发有限公司)

**摘要:**水性环氧树脂改性乳化沥青原材料组分较复杂,其黏结性能评价往往需要综合考量多重影响因素,试验量繁杂且耗时较长。为快速精准预测水性环氧树脂改性乳化沥青的黏结性能,优选水性环氧树脂、固化剂、乳化沥青等原材料技术指标及测试温度范围作为输入因子、黏结拉拔强度作为输出因子,基于遗传算法(GA)优化后的极限学习机(ELM)算法,建立水性环氧树脂改性乳化沥青黏结性能预测模型,通过与传统单隐层神经网络算法进行对比分析,验证预测模型准确度。结果表明:GA—ELM模型具有更高的准确性和效率,可用来预测水性环氧树脂改性乳化沥青黏结性能,与BP、ELM模型相比,GA—ELM模型的误差分别降低了78.74%~79.67%和83.63%~87.41%。

**关键词:**道路工程; 乳化沥青; 水性环氧树脂; 黏结性能; 极限学习机; 预测模型

## 1 前言

乳化沥青作为道路预防性养护常用黏层材料,具有施工简便、经济、环保等优点,但由于其存在黏度低、耐高温性差、抗老化性差等缺点,严重制约了其在重交

通和特重交通道路中的应用与推广。水性环氧树脂与水性固化剂混合发生交联反应形成热固性材料,具有低VOC(挥发性有机化合物, Volatile Organic Compounds)和使用便捷性的特点。相比于沥青,它具有更高的温度稳定性、物理强度以及化学稳定性。采用水性环氧树脂改性的乳化沥青,兼具了水性环氧树脂

- \*\*\*\*\*
- [3] 付春梅,齐善忠. 掺纤维水泥稳定碎石抗裂性能研究分析[J]. 中外公路,2015(2).
- [4] 冯建生. 水泥稳定碎石基层耐久抗裂的振动搅拌技术的研究与应用[D]. 长安大学硕士学位论文,2015.
- [5] 赵利军,蒋文志,侯劲汝,等. 搅拌方式对水泥稳定碎石混合料抗压强度的影响[J]. 中国公路学报,2018(1).
- [6] 冯忠绪,王新亚,冯建生. 水泥稳定碎石基层耐久抗裂振动搅拌技术与工程应用(上)[J]. 工程机械,2016(4).
- [7] 徐周聪,但路昭,吕少辉,等. 基于振动拌和工艺的水泥稳定碎石混合料强度及拌和均匀性分析[J]. 公路交通技术,2017(6).
- [8] 杨周晓政. 振动搅拌技术发展概述[J]. 建筑工程技术与设计,2017(11).
- [9] 张良奇. 混凝土振动搅拌机理和工业应用研究[D]. 长安大学硕士学位论文,2013.
- [10] 谢海彬,何博谦. 振动搅拌水泥稳定级配碎石基层施工技术应用研究[J]. 公路交通科技(应用技术版),2018(4).
- [11] GB 175—2007 通用硅酸盐水泥[S].
- [12] JTG E42—2005 公路工程集料试验规程[S].
- [13] JTG/T F20—2015 公路路面基层施工技术细则[S].
- [14] JTG E51—2009 公路工程无机结合料稳定材料试验规程[S].
- [15] DB13/T 2470—2017 公路路面骨架密实型水泥稳定碎石基层振动拌和施工技术规范[S].
- [16] 张宜洛,陈阳阳,王涛,等. 基于振动法的水泥稳定破碎砾石级配分形评价及力学性能[J]. 中外公路,2019(2).
- [17] 邹桂莲,刘新海,周浩浩. 水泥粉煤灰稳定再生集料的路用性能研究[J]. 中外公路,2018(3).
- [18] 程箭,许志鸿,李淑明,等. 水泥稳定碎石静态模量与动态模量比较[J]. 建筑材料学报,2009(1).

收稿日期:2020—11—26

基金项目:山东省交通运输厅科技计划项目(编号:2018B50);河南省交通运输科技计划项目(编号:2018J8);天津市交通运输科技发展计划项目(编号:2017A—12);长安大学中央高校基本科研业务费专项资金资助项目(编号:300102219314, 300102218210)

作者简介:陆由付,男,硕士,工程师. E-mail:398319860@qq.com

\* 通信作者:王朝辉,男,博士,教授. E-mail:wchh0205@163.com

优良的黏结性和乳化沥青的使用便捷性,显著改善了乳化沥青高温性能,增强了路面层间黏结性能。然而,水性环氧树脂改性乳化沥青是一种由环氧树脂、乳化剂、沥青和固化剂经一系列化学反应制得的混合乳液,成分较为复杂,这就导致水性环氧树脂改性乳化沥青的性能评价需要考虑多重因素影响,试验量较为庞大。为此,考虑到水性环氧树脂改性乳化沥青黏结性能评价方面,有必要建立一种模型快速预测水性环氧树脂改性乳化沥青黏结性能。

为了减少试验量和快速得到较为精确的结果,神经网络、机器学习法越来越多地用来获取材料性能变化规律。一些专家、学者陆续采用误差修正模型(ECM)、灰靶决策(GTD)、支持向量机(SVM)和径向基函数(RBF)等评价方法和算法来预测沥青材料性能。但是这些方法存在求解过程中容易陷入局部最优解、参数不易确定、训练样本要求高、训练难度较大等问题。极限学习机(Extreme Learning Machine, ELM)是一种改进的单隐层前馈神经网络,与BP神经网络模型和支SVM模型相比,具有泛化能力强、迭代次数少和精度高等特点,但由于随机给定权值,使得

ELM存在稳定性差、过拟合等问题。遗传算法(Genetic Algorithm, GA)是通过选择、交叉、变异算子寻找最优解的一种进化算法,具有良好的稳定性,常用于改善神经网络模型收敛性及精确度。

因此,该文采用遗传算法(GA)优化后的极限学习机(ELM)算法,建立基于GA-ELM的水性环氧树脂改性乳化沥青的黏结性能预测模型。通过与BP神经网络和ELM等传统预测模型对比分析,发现GA-ELM模型在预测水性环氧树脂改性乳化沥青黏结拉拔强度方面具有更高的预测精度和效率。这也为水性环氧树脂改性乳化沥青黏结性能的研究提供了一种新思路。

2 数据采集与归一化处理

选取水性环氧树脂环氧值、水性环氧树脂掺量、水性固化剂胺值、水性固化剂掺量、乳化沥青针入度、乳化沥青黏度、乳化沥青软化点和测试温度作为输入参数,黏结拉拔强度作为输出参数。为提高预测模型精度,在文献[7]提供数据的基础上,补充一系列试验获得更多的样本数据,试验参数及指标如表1所示。

表1 试验参数及其指标

序号	材料	技术指标	试验条件
1	水性环氧树脂	环氧值 0.48~0.54 mol/(100 g);掺量 5%~20%	测试温度 25~60 ℃
2	水性固化剂	胺值 100~150 mg KOH/g; 掺量 5%~20%	
3	乳化沥青	针入度(25 ℃)87~89(0.1 mm);延度(15 ℃)>100 cm; 软化点 46.1~46.7 ℃;掺量 60%~90%	

将100组样本数据中80组试验数据用于模型训练,20组数据用来验证模型精度。根据式(1),样本数据做归一化处理。

$$X_i = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \tag{1}$$

式中: $X_i$  为归一化样本数据; $X$  为初始样本数据; $X_{\max}$ 、 $X_{\min}$  分别为初始样本数据最大值、最小值。

3 预测模型构建

利用遗传算法优化极限学习机网络的输入权值和隐含层节点数,弥补极限学习机初始权值和隐含层节点数随机选取带来的缺陷,提高ELM模型的拟合精度。构建基于遗传算法优化极限学习机的水性环氧树脂改性乳化沥青黏结性能预测模型,具体步骤如下:

(1) 对于已经归一化处理的输入样本  $X$ ,根据式

(2),计算隐含层神经元输出矩阵( $H$ )。

$$H = g(WX^T + b) \tag{2}$$

式中: $W$  为输入层权值矩阵; $b$  为隐含层阈值矩阵; $g$  为隐含层神经元激活函数——“sigmoid”函数。

(2) 根据式(3),计算ELM神经网络输出值( $P$ )。

$$P = (H^T \beta) \tag{3}$$

式中: $\beta$  为隐含层到输出层的权值矩阵,只要确定  $\beta$  即可唯一确定ELM神经网络。

(3) 采用给定的训练输出样本( $Y$ )替代神经网络输出值。 $\beta$  可以通过求解式(4)的最小二乘解获得。

$$y = \min_{\beta} \| H^T \beta - Y \| \tag{4}$$

(4) 采用遗传算法寻找ELM的最优初始  $W$  和  $b$ 。遗传算法通过适应度函数经选择、交叉和变异操作得到最小适应度值所对应个体。

(5) ELM经遗传算法优化后得到最优初始权值和阈值。设定隐含层节点个数,建立GA-ELM

模型。

(6) 按照式(5)~(7),误差判别标准采用平均绝对误差(Mean Absolute Error,MAE)、平均绝对百分比误差(Mean Absolute Percent Error,MAPE)和均方根误差(Root Mean Squared Error, RMSE)。利用测试集样本数据训练和评价 GA-ELM 模型。

$$MAE = \frac{1}{n} \sum_{i=1}^n |P - P'| \tag{5}$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{P - P'}{P} \times 100\% \right| \tag{6}$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (P - P')^2} \tag{7}$$

式中:  $P$  为实际值;  $P'$  为预测值;  $n$  为测试样本数。

4 预测模型优化

4.1 ELM 隐藏层优化

隐藏层数量的确定是 ELM 设计中最为关键的环节,隐藏层数量与求解问题要求、输入单元数有着直接关系。隐藏层数量过少,则模型精度和可靠性较差;隐藏层数量过多,则弱化训练后模型泛化能力。因此,基于测试集数据多次测试确定 ELM 预测模型较优的隐藏层数量,如图 1 所示。




图 1 ELM 模型的隐藏层的优化结果

由图 1 可知:随着 ELM 模型隐藏层数量不断增加,MAE、MAPE 和 RMSE 变化规律一致,均呈现出先减小后增大再减小再增大的趋势;隐藏层数量过少或过多时,各类误差均较大;当隐藏层数量为 45~55 时,误差较小。为了寻求隐藏层数量变化下各类误差极小值,多次测试隐藏层数量为 45~55 的误差值,结果如图 2 所示。

由图 2 可知:当隐藏层数量为 45~55 时,MAE 和 MAPE 表现出先减小后增大的总体趋势;RMSE 在隐藏层数量为 47 时出现突变值,但其总体趋势与前




图 2 ELM 隐藏层数量下的最小误差

两者变化规律一致。当隐藏层数量为 51 时,MAE、MAPE 和 RMSE 同时达到极小值,此时隐藏层数量最优。最终,确定 ELM 模型较优的隐藏层数量为 51。此时 MAE、MAPE 和 RMSE 分别为 9.77%、10.75% 和 12.33%,与隐藏层数量为 10 时相比,各类误差分别降低了 65.86%、66.53% 和 62.83%。

4.2 GA 参数优化

种群规模、终止代数、交叉概率和变异概率作为遗传算法的主要运行参数,在实际应用中,往往需要经过多次测试后才能确定出这些参数的合理取值范围。为简化训练过程,优化种群规模、交叉概率、变异概率和终止代数等参数。一般情况下,这 4 项运行参数建议取值范围分别为 40~100、0.40~0.80、0.001~0.1 和 100~300。在此基础上,利用 Matlab 中 Sheffield 工具箱,多次循环测试确定遗传算法 4 项参数的较优数值,如图 3 所示。

由图 3 可知:随着 GA 的 4 项参数数值变化,相应误差值也呈现一定的变化规律。随着种群规模增大,误差值表现出先下降后上升的趋势,当种群规模达到 40 时,误差值达到极小值;误差值随交叉概率和变异概率的变化规律较为复杂,极小值分别存在于 0.40~0.50 和 0.000 5~0.001 0 之间;终止代数的增加引起误差值不断减小。结合算法测试情况,GA 的种群规模、交叉概率、变异概率和终止代数的较优取值范围分别为 40~50、0.40~0.50、0.000 5~0.001 0 和 400~500。此时,遗传算法部分已经较好地收敛至最优权值和阈值。由于其权值矩阵和阈值矩阵规模较大,其具体取值不再赘述。

5 GA-ELM 模型验证

5.1 GA-ELM 样本拟合

采用 Pearson 相关性检验方法验证 GA-ELM 模型的预测精度,计算测试样本真实值与预测值两者所




图3 GA算法参数优化结果

拟合函数的判别系数  $R^2$ ,如图 4、5 所示。系统分析预测数据与实测数据的拟合优度,确定黏结拉拔强度的 GA-ELM 预测模型精度。




图4 GA-ELM 模型预测精度




图5 GA-ELM 样本拟合

由图 4、5 可知:测试集样本真实值与预测值非常接近。两者所拟合函数的相关系数  $R$  为 0.998 6,大于 0.8。表明预测值与实际值为强相关,预测模型的预测精度较高。另外,相应判别系数  $R^2$  为 0.999 3,

接近于 1。它表明 GA-ELM 预测模型在高预测精度的基础上还能保持较好的输出稳定性。

5.2 模型对比

为进一步验证 GA-ELM 模型的输出稳定性,分别采用 BP 模型、ELM 模型和 GA-ELM 模型对该测试集 20 组样本数据进行预测。其中,经过多次仿真计算后,BP 模型隐藏层数量设定为 7,ELM 模型隐藏层数量取为 51。GA 算法的种群规模、交叉率、变异率和终止代数分别设定为 45,0.50,0.001 和 400。基于不同模型预测结果如图 6、7 所示。




图6 不同模型黏结拉拔强度预测值

由图 6、7 可知:3 种模型都取得了相应预测效果,但 GA-ELM 模型预测误差明显小于 BP 模型和 ELM 模型。GA-ELM 模型的 MAE、MAPE 和 RMSE 分别为 1.23%、1.76%和 1.61%。与 BP 神经网络模型相比,GA-ELM 模型的 MAE、MAPE 和






图 7 不同模型预测误差

RMSE 分别降低了 79.67%、78.74% 和 78.98%；与 ELM 模型相比，GA-ELM 模型的 MAE、MAPE 和 RMSE 分别降低了 87.41%、83.63% 和 86.94%。这表明与传统预测模型相比，GA-ELM 模型在预测准确性和高效性等方面具有更好的优势。

## 6 结论

(1) 采用 GA 算法优化 ELM 模型，建立基于 GA-ELM 的水性环氧树脂改性乳化沥青黏结性能预测模型，预测了水性环氧树脂改性乳化沥青的黏结拉拔强度。

(2) GA-ELM 模型预测水性环氧改性乳化沥青黏结拉拔强度具有较高的精确度，MAE、MAPE 和 RMSE 分别为 1.23%、1.76% 和 1.61%。与 BP 网络模型和 ELM 模型相比，误差降低 78.74%~87.41%。

(3) GA-ELM 模型为以后研究水性环氧树脂改性乳化沥青黏结性能提供了新思路，与原始 ELM 模型相比，遗传算法降低了 GA-ELM 模型的训练效率，因此在增加样本数据提高模型预测精度的同时，还需要进一步减少模型训练时间。

## 参考文献:

- [1] 邓玉训, 谢群. 水性环氧乳化沥青碎石封层性能研究[J]. 中外公路, 2019(3).
- [2] 弓锐, 郭彦强, 徐鹏. SBS/SBR 复合改性乳化沥青的性能研究[J]. 中外公路, 2019(1).
- [3] Pang J, Du S, Chang R, et al. Effect of Emulsifier Content on the Rheological Properties of Asphalt Emulsion Residues[J]. Journal of Applied Polymer Science, 2015, 132(15).
- [4] 张庆, 郝培文, 白正宇. 水性环氧树脂改性乳化沥青制备及其黏附性研究[J]. 公路交通科技, 2015(9).
- [5] Zhang Q, Xu Y H, Wen Z G. Influence of Water-Borne Epoxy Resin Content on Performance of Waterborne Epoxy Resin Compound SBR Modified Emulsified Asphalt for Tack Coat[J]. Construction and Building Materials, 2017, 153: 774-782.
- [6] 李秀君, 毕伟林, 拾方治, 等. 水性环氧树脂对 SBR 乳化沥青的复合改性作用[J]. 重庆交通大学学报(自然科学版), 2018(11).
- [7] Liu M, Han S, Pan J, et al. Study on Cohesion Performance of Waterborne Epoxy Resin Emulsified Asphalt as Interlayer Materials[J]. Construction and Building Materials, 2018, 177: 72-82.
- [8] Chen Q, Wang C H, Fu H, et al. Durability Evaluation of Road Cooling Coating[J]. Construction and Building Materials, 2018, 190: 13-23.
- [9] Chen Q, Wang C H, Wen P H, et al. Comprehensive Performance Evaluation of Low-Carbon Modified Asphalt Based on Efficacy Coefficient Method[J]. Journal of Cleaner Production, 2018, 203: 633-644.
- [10] Prabu R, Harikumar R. A Performance Analysis of GA-ELM Classifier in Classification of Abnormality Detection in Electrical Impedance Tomography (EIT) Lung Images[J]. Journal of Scientific and Industrial Research, 2016 75 (7): 404-411.
- [11] 王彪龙, 孟凡利, 曾超, 等. 基于自然选择策略的 PSO-BP 神经网络的滑坡可靠性评价方法[J]. 中外公路, 2019(3).
- [12] Chen Q, Wang C H, Wen P H, et al. Performance Evaluation of Tourmaline Modified Asphalt Mixture Based on Grey Target Decision Method[J]. Construction and Building Materials, 2019 205: 137-147.
- [13] 张林林, 胡熊伟, 李鹏, 等. 基于极限学习机的电力系统暂态稳定评估方法[J]. 上海交通大学学报, 2019(6).
- [14] 杨新, 麻哲瑞, 申赫男, 等. 基于多尺度特征能量-核极限学习机的双循环流化床气流堵塞故障智能诊断[J]. 化工学报, 2019(7).
- [15] 律方成, 刘怡, 亓彦珣, 等. 基于改进遗传算法优化极限学习机的短期电力负荷预测[J]. 华北电力大学学报(自然科学版), 2018(6).
- [16] 刘浩然, 赵翠香, 李轩, 等. 一种基于改进遗传算法的神经网络优化算法研究[J]. 仪器仪表学报, 2016(7).
- [17] 梅益, 孙全龙, 喻丽华, 等. 基于 GA-ELM 的铝合金压铸件晶粒尺寸预测[J]. 金属学报, 2017(9).