

# 基于群智算法优化的 ME 车辙预测模型\*

刘佳佳<sup>1</sup>, 李卓轩<sup>1,2</sup>, 张伟光<sup>3</sup>, 曹进德<sup>1,2</sup>

(1. 东南大学 数学学院, 南京 211189;

2. 中华人民共和国交通运输部 综合交通运输理论交通运输行业重点实验室(南京现代综合交通实验室), 南京 211135;

3. 东南大学 交通学院, 南京 210096)

(我刊编委曹进德来稿)

**摘要:** 车辙, 作为沥青路面的一种常见病害, 不仅影响着道路的行驶质量和安全性, 还在许多国家沥青路面结构设计中占据着举足轻重的地位. 为了更准确地预测和评估车辙的演变趋势, 对现有车辙预测模型进行改进和优化显得尤为重要. 因此, 基于 RIOHTrack 足尺路面加速加载试验环道长期观测数据, 对《公路沥青路面设计规范》(JTG D50—2017) 中的力学经验车辙性能预测模型进行了全面的调整和优化, 引入三个校准参数, 分别对常数项系数、温度和累计载荷次数进行校准, 以提升模型的预测准确性和泛化能力. 接着, 提出了一种多策略自适应粒子群算法, 引入邻域突变策略, 并融合指数自适应惯性权重和正弦自适应学习因子, 有效平衡了局部搜索和全局搜索的能力, 使得粒子可以更高效地找到最优解. 使用该算法求解三个校准参数的值, 进一步提升模型的精度. 最后, 以 RIOHTrack 中 19 种沥青路面的车辙数据为例, 使用本文提出的 MAPSO-RME 模型进行车辙预测. 实验发现, 相对于《公路沥青路面设计规范》(JTG D50—2017) 中的力学经验车辙预测模型, 其拟合性能显著提升, 模型预测均方差 MSE 大幅降低.

**关键词:** 沥青路面; 车辙; 参数校准; 多策略自适应粒子群算法

**中图分类号:** U416.217; TP18 **文献标志码:** A **DOI:** 10.21656/1000-0887.460045

## Optimization of the ME Rutting Depth Prediction Model Using Swarm Intelligence Algorithms

LIU Jiajia<sup>1</sup>, LI Zhuoxuan<sup>1,2</sup>, ZHANG Weiguang<sup>3</sup>, CAO Jinde<sup>1,2</sup>

(1. School of Mathematics, Southeast University, Nanjing 211189, P.R. China;

2. Key Laboratory of Transport Industry of Comprehensive Transportation Theory

(Nanjing Modern Multimodal Transportation Laboratory),

Ministry of Transport of the People's Republic of China, Nanjing 211135, P.R. China;

3. School of Transportation, Southeast University, Nanjing 210096, P.R. China)

(Contributed by CAO Jinde, Member of the Editorial Board of AMM)

\* 收稿日期: 2025-03-10; 修订日期: 2025-04-22

基金项目: 国家重点研发计划(2020YFA0714300); 南京现代综合交通实验室开放课题(MTF2023004)

作者简介: 刘佳佳(2001—), 女, 硕士生(E-mail: 3046838001@qq.com);

李卓轩(1997—), 男, 博士生(E-mail: 230229338@seu.edu.cn);

张伟光(1986—), 男, 副教授(E-mail: wgzhang@seu.edu.cn);

曹进德(1963—), 男, 教授(通信作者. E-mail: jdcao@seu.edu.cn).

引用格式: 刘佳佳, 李卓轩, 张伟光, 曹进德. 基于群智算法优化的 ME 车辙预测模型[J]. 应用数学和力学, 2026, 47(5): 639-654.

**Abstract:** Rutting, a common disease of asphalt pavement, not only compromises the road quality and safety, but also plays a critical role in the structural design of asphalt pavement in many countries. To achieve more accurate prediction and evaluation of rutting evolution trends, it is particularly important to improve and optimize the existing rutting depth prediction model. Therefore, based on the long-term observation data of the RIOHTrack full-scale pavement acceleration loading test loop, the mechanical-empirical rutting depth prediction model in the Highway Asphalt Pavement Design Specifications (JTG D50—2017) was comprehensively adjusted and optimized. Three calibration parameters were introduced to calibrate the constant coefficients, temperatures, and cumulative load times, respectively, to improve the prediction accuracy and generalization ability of the model. Subsequently, a multi-strategy adaptive particle swarm optimization (MAPSO) algorithm incorporating a neighborhood mutation strategy and fusing exponential adaptive inertia weights with sinusoidal adaptive learning factors, was proposed. Then this algorithm was used to estimate the values of three calibration parameters to further improve the accuracy of the model. Finally, with the rutting data of 19 types of asphalt pavements in the RIOHTrack as an example, the MAPSO-RME model proposed in this article was applied for rutting depth prediction. The experimental results demonstrate that, compared with the mechanical-empirical rutting depth prediction model in the Highway Asphalt Pavement Design Specifications (JTG D50—2017), the MAPSO-RME model achieves remarkable improvement in fitting performance with a significant reduction in mean squared error (MSE) of prediction.

**Key words:** asphalt pavement; rutting; parameter calibration; multi-strategy adaptive particle swarm optimization

## 0 引言

沥青路面是公路与城市道路最为常见的路面类型,经过长时间使用后,交通荷载和不利大气条件的综合影响导致沥青路面永久变形的累积,最终在路面上形成车辙<sup>[1]</sup>,其对路面的平整性、安全性和耐久性产生负面影响,同时也是公路进行大修养护的重要诱因<sup>[2]</sup>.车辙是沥青路面的典型和主要病害,大量的车辙会导致沥青路面平整度不规则,对骑行质量和行车安全产生极大危害.因此,对沥青路面车辙的预测和评估成为重要的研究课题,有利于沥青路面维护方案与维护资金的制定、养护耐久性的提升,以及结构材料组合设计方法的优化<sup>[3]</sup>.

路面服役性能的概念最早由 Carey 等<sup>[4]</sup>提出,这一概念的提出为路面材料和施工技术方面提供了客观的评价标准;同时,他们利用传统的多元回归分析方法对路面性能进行了预测.想要建立合适的车辙预测模型,分析车辙发展与关键影响因素之间的关系显得尤为重要.基于这一目的,近几十年来,相关学者对车辙测试方法进行了大量研究,如基于实验室的沥青与沥青混合料抗车辙性能、长期路面性能跟踪和加速路面测试等方法<sup>[5]</sup>.全尺寸测试环道是一种十分经典的加速路面测试方法,早已经被广泛应用于车辙试验的演变和发展,如美国的 MnROAD 测试环道<sup>[6]</sup>、NCAT 测试环道<sup>[7]</sup>和 AASHO 测试环道<sup>[8]</sup>、德国的 BAsT 测试环道<sup>[9]</sup>、新西兰的 CAPTIF 测试轨道<sup>[10]</sup>、中国的 RIOHTrack 试验环道<sup>[11]</sup>等.

根据各种车辙试验的现场数据,综合考虑交通负荷、环境条件和路面材料等影响因素, Radhakrishnan 等<sup>[12-16]</sup>提出了多种模型来预测沥青路面的车辙发展和演变,主要包括经典力学模型、传统经验模型、力学经验模型和机器学习模型等,每种模型都有其独特的优点和局限性.

力学模型能够充分反映沥青路面的力学性能以及不同沥青混合料材料因素的差异,是最严格的车辙预测模型.其中,沥青路面的内部应力通常是应用相应的组成模型和有限元、离散元分析技术,或利用层状黏弹性系统理论计算而出<sup>[17-18]</sup>.但是,因为涉及许多假设,所提出的力学模型通常在一定程度上是理想化的.加上力学参数非常复杂、很难获得等原因,力学模型的实用性不高.在此基础上, Archilla 等<sup>[19-20]</sup>学者将车辙深度与相关关键影响因素相结合,采用多元回归统计方法,建立了传统的经验模型.例如, Archilla<sup>[19]</sup>选取温度、交通荷载和混合特征的函数(包括沥青含量、比表面积、空隙率和沥青填充空隙等),作为车辙深度的影响因素.只是,传统经验模型往往基于简单的线性或多项式关系来描述车辙深度,难以捕捉到沥青路面车辙发展

的非线性特征以及长期的变化趋势,与力学模型相比,传统经验模型通常不直接反映材料属性、结构设计等因素对车辙形成过程的影响,因此在解释车辙产生的机理方面能力较弱。

力学经验车辙预测模型,是基于车辙演化和发展的具体数学形式和力学性能构建而成,其中的参数主要包括材料特性、结构组合、交通荷载与气候荷载等,以及用于表征室内测试与现场实际受力围压差异的调整系数。与力学模型相比,力学经验车辙预测模型使用频率较高,且易于通过统计分析方法进行修改,具有更高的预测信度和准确性<sup>[21]</sup>。例如:力学经验法路面设计指南(MEPDG)研究基于沥青混合层的永久应变与累计荷载次数之间的关系,建立了沥青层车辙性能预测模型<sup>[22]</sup>;《公路沥青路面设计规范》(JTG D50—2017)提出的力学经验模型(mechanical-empirical, ME)考虑沥青路面不同深度应力分布的差异,逐层计算永久变形,建立了基于分层应变累积的车辙性能模型<sup>[23]</sup>;Shell 手册考虑沥青层的厚度、层内平均应力和沥青混凝土刚度,建立了沥青层车辙预测模型,可以用来比较不同种类的沥青混合料的抗永久变形能力<sup>[24]</sup>。

《公路沥青路面设计规范》(JTG D50—2017)提出的 ME 沥青路面车辙预测模型<sup>[23]</sup>,是目前应用最广泛的力学经验车辙预测模型之一,基于温度、等效单轴荷载等变量,预测沥青路面的车辙性能。该模型综合考虑了结构受力状态与实际交通气候荷载等环境条件,预测精度与适用性高于传统力学或经验模型,然而,其预测的适用性和准确性在很大程度上受到本构方程的形式、模型发展的数据源和经验参数等因素的影响。Wu 等<sup>[25]</sup>基于 RIOHTrack 足尺路面加速加载试验环道不同路段的车辙数据,对 ME 车辙性能预测模型进行了评估,并提出了一种模型修正方法,提高了模型的可靠性。然而,这里并未详细说明具体的修正方法和参数优化求解策略,这也是当前研究的一个难点。

综合考虑上述问题,本文利用 RIOHTrack 足尺路面加速加载试验环道不同路段车辙数据,基于 JTG D50—2017 规范中的 ME 车辙预测模型<sup>[23]</sup>,提出了一种 MAPSO-RME 车辙预测模型,主要贡献如下:

① 针对传统粒子群优化算法在寻优过程中容易陷入局部最优、收敛速度慢等问题,引入邻域突变策略,并融入指数自适应惯性权重和正弦自适应学习因子,提出了一种多策略自适应粒子群优化算法(multi-strategy adaptive particle swarm optimization, MAPSO)。该算法能够根据搜索进程动态调整惯性权重和学习因子,有效平衡全局搜索与局部搜索的能力,提高算法的全局寻优性能和收敛速度,为后续模型参数的精确求解奠定了坚实基础。

② 由于力学经验模型的预测适用性和准确性深受其本构方程形式、模型开发所依据的数据源以及经验参数等多重因素的制约,基于 JTG D50—2017 规范中的 ME 车辙预测模型<sup>[23]</sup>,创新性地引入了三个校准参数,分别对常数项系数、温度和累计荷载次数进行校准,得到一种修正力学经验车辙预测模型(rectified mechanistic empirical, RME),该模型不仅能够更准确地反映车辙的演变规律,还显著提高了预测的准确性和泛化性。

③ 为了验证提出的 MAPSO-RME 车辙预测模型的有效性,基于 RIOHTrack 足尺路面加速加载试验环道 19 种道路数据,使用 MAPSO 算法,分别求解 RME 车辙预测模型中三个校准参数的最优值,得到了 MAPSO-RME 车辙预测模型。实验结果表明,该模型在预测精度和稳定性方面均显著优于 JTG D50—2017 规范中的 ME 模型,为沥青路面车辙的预测和防治提供了更为科学、可靠的支持。

## 1 算法原理

### 1.1 修正力学经验(RME)车辙预测模型

《公路沥青路面设计规范》(JTG D50—2017)中提出的车辙性能预测模型<sup>[23]</sup>,是使用最广泛的力学经验车辙预测模型之一。JTG D50—2017 规范中的 ME 车辙预测模型的基础是累积永久变形的计算,可以大致分为以下部分:首先,根据材料结构将沥青路面划分为多个层次,如面层、基层和土壤层等。其中,面层位于路面最上层,直接和车辆接触,承受车辆荷载,一般会产生较大的永久变形量,大幅度影响车辆行驶的安全性和稳定性;基层位于面层下方,为面层提供支撑并起到分散荷载的作用,其变形虽然不如面层明显,但也会影响路面的整体性能;土壤层一般位于路面最底部,能提供基础支撑,其承载能力和稳定性对整个路面的安全性能起着十分重要的作用。接着,在特定温度、载荷等标准条件下进行车辙试验,测量并记录每层沥青混合料的永

久变形量,将其累加,计算出总的沥青路面结构的永久变形,从而预测车辙的发展趋势,如式(1)所示<sup>[5]</sup>:

$$\begin{cases} R_a = \sum_{i=1}^n R_{ai}, \\ R_{ai} = 2.31 \times 10^{-8} k_{Ri} T_{\text{pef}}^{2.93} p_i^{1.80} N_e^{0.48} R_{0i}, \end{cases} \quad (1)$$

其中,  $R_a$  表示实验室条件下测定的沥青混合料层的永久变形(单位 mm);  $R_{ai}$  表示第  $i$  层的永久变形(单位 mm);  $R_{0i}$  表示在 60 °C 实验室车辙试验中,沥青混合料第  $i$  层的永久变形(单位 mm);  $N_e$  表示等效单轴荷载(equivalent single axle load, ESAL)的累计数量,用于衡量沥青路面累计荷载次数;  $T_{\text{pef}}$  表示沥青混合料层的车辙当量温度(单位 °C),一个用于考虑温度影响的指标;  $p_i$  表示第  $i$  层顶面的竖向压应力(单位 MPa),这是影响车辙的重要力学参数;  $k_{Ri}$  表示综合修正系数,用于调整模型以考虑实际情况,  $k_{Ri}$  的数值由该层中点到路面的深度  $h_{ai}$  和该层沥青混合料的厚度  $z_i$  两个参数决定,具体表达式如式(2)所示:

$$\begin{cases} k_{Ri} = (d_1 + d_2 \cdot z_i) \cdot 0.973 1^{z_i}, \\ d_1 = -1.35 \times 10^{-4} h_{ai}^2 + 8.18 \times 10^{-4} h_{ai} - 14.5, \\ d_2 = 8.78 \times 10^{-7} h_{ai}^2 - 1.50 \times 10^{-3} h_{ai} + 0.90, \end{cases} \quad (2)$$

其中,  $z_i$  表示第  $i$  层沥青混合层的厚度(单位: mm),如果某一层的厚度  $z_i$  超过 200 mm,取 200 mm 作为计算的基准;  $h_{ai}$  表示从第  $i$  层中点到路面的深度(单位: mm),即第  $i$  层沥青混合层的厚度  $z_i$  的一半与该层顶点到路面表面的距离之和;  $d_1$  和  $d_2$  是根据  $h_{ai}$  计算得出的系数。

在实际工程应用中,综合修正系数  $k_{Ri}$ 、竖向压应力  $p_i$  和 60 °C 实验室车辙  $R_{0i}$  等参数的物理意义虽各不相同,但它们共同反映了路面结构组合和温度对车辙发展的影响.例如,竖向压应力  $p_i$  和 60 °C 实验室车辙  $R_{0i}$  的关系密切,前者直接影响后者的变化规律.因此,综合修正系数  $k_{Ri}$ 、竖向压应力  $p_i$  和 60 °C 实验室车辙  $R_{0i}$  之间的强相关性会导致模型参数估计不稳定,容易引发多重共线性问题,这不仅会增加模型复杂度,还可能使模型训练过程中出现过拟合现象,即模型对训练数据过度适应,而无法很好地泛化到新数据.因此,将它们合并为一个综合参数可以有效减少模型的自由度,同时保留主要影响因素.通过这种方式,单一参数  $a$  能够间接反映路面结构组合、温度效应以及荷载水平的综合影响.即将 JTG D50—2017 规范中的 ME 车辙性能预测模型简化为式(3),使用最小二乘法求解参数  $a$  的值:

$$R_a = a \cdot T_{\text{pef}}^{2.93} \cdot N_e^{0.48}. \quad (3)$$

力学经验车辙预测模型在很大程度上受本构方程形式、数据来源和经验参数的影响. JTG D50—2017 规范中的 ME 车辙性能预测模型因其数据源与 RIOHTrack 足尺路面试验环道的环境条件、沥青路面材料特性和累计荷载重复次数等参数存在显著差异,无法直接用于预测 RIOHTrack 的车辙数据.因此,需要对模型参数进行调整与优化.为此,本文引入了三个校准参数  $\beta_1$ 、 $\beta_2$  和  $\beta_3$ , 分别对常数项系数、温度效应以及累计荷载次数进行校正,调整后的 RME 模型表达式如式(4)所示:

$$R_{ai} = \beta_1 \cdot a \cdot T_{\text{pef}}^{2.93\beta_2} \cdot N_e^{0.48\beta_3}, \quad (4)$$

其中,  $\beta_1$  用于调整常数项系数,使得模型能够灵活地应对不同的实验条件和数据来源,在不同情境下都能保持较高的预测准确性;  $\beta_2$  用于校正温度效应,确保模型在温度变化时仍能保持稳定的预测性能,可以有效应对温度变化对车辙深度的影响;  $\beta_3$  则调整累计荷载次数的影响,确保模型能够准确预测不同交通荷载下的车辙变化,为道路维护和修复提供有力的决策支持.这些校准参数的引入不仅提高了模型的灵活性和准确性,还增强了模型的泛化能力,使其能够更好地适用于各种环境和条件下的车辙预测.通过合理设置这些参数,可以显著提升预测模型在实际应用中的可靠性和实用性。

然而,在 RME 车辙预测模型中,参数  $\beta_2$  和  $\beta_3$  都呈现出指数型非线性特征,这一特性无疑为模型的实际求解过程带来了极大的复杂性和挑战性.此时,传统的优化方法往往难以奏效,无法满足高效、准确的求解需求.为了有效应对这一难题,本文精心设计了一种多策略自适应粒子群优化算法,巧妙地融合了多种自适应优化策略,显著提高搜索效率和全局寻优能力,从而更有效地解决这类复杂的非线性参数优化问题.该算法通过设置融合了指数函数的自适应惯性权重,使得粒子在搜索过程中能够根据当前状态动态调整搜索方向,更加灵活地适应参数空间的变化;同时,引入了融合正弦函数的自适应学习因子,有效避免了算法陷入局部

最优解的风险,提高了全局寻优的可靠性和稳定性.这一创新性的优化算法为车辙预测模型的准确性和实用性提供了坚实的保障,其具体实现过程见 1.2 小节.

## 1.2 多策略自适应粒子群优化 (MAPSO) 算法

非线性参数求解方法通常分为两类.一类是解析法,通过数学推导和解析计算求解非线性方程或方程组,从而获得理论上的精确解,典型方法如 Newton-Raphson 迭代法、同伦分析法等.这类方法在低维、弱非线性问题中展现出良好的求解性能,其解析解具有明确的数学物理意义.然而,当面对高维参数空间、强非线性耦合或非光滑目标函数时,解析法往往面临 Jacobi 矩阵奇异、收敛域狭窄等问题,导致计算复杂度呈指数级增长,这在工程实践中严重制约了其应用范围.

另一类是数值法,通过建立迭代计算框架和收敛性控制机制,对非线性问题进行近似求解,在无法获得解析解的复杂系统中展现出独特的应用价值.相较于传统解析法对数学形式的高度依赖,数值法通过离散化处理和误差控制策略,能够在可接受的计算资源内获得满足工程精度的近似解.常见的数值方法包括梯度下降法、Newton 法以及元启发式算法等.其中,粒子群优化 (particle swarm optimization, PSO) 算法作为元启发式算法的典型代表,以其概念简单、易于实现、搜索策略高效、收敛速度快和全局寻优能力强的特点,被广泛应用于工程、生物和经济等多个领域<sup>[26]</sup>.

PSO 算法是由电气工程师 Russell Eberhart 和社会心理学家 James Kennedy 于 1995 年共同提出的一种创新型群体智能优化算法<sup>[27]</sup>,该算法的设计灵感来源于鸟类觅食行为的仿生学研究.研究者观察到,鸟群在搜索食物过程中通过个体间的信息共享与协作,能够快速定位最优食物源.这种生物群体智能机制被抽象为数学建模,最终发展成为一种具有全局搜索能力的优化范式.PSO 从一组潜在解决方案 (称为粒子群) 开始,每个粒子代表一个问题的可能解.在迭代过程中,粒子根据自身的最佳位置  $p_{best}$  和群体最佳位置  $g_{best}$  调整速度和位置,其更新公式如式 (5) 和式 (6) 所示:

$$V_k(i+1) = w \cdot V_k(i) + c_1 r_1 \cdot (p_{best,i}^k - X_k(i)) + c_2 r_2 \cdot (g_{best,i} - X_k(i)), \quad (5)$$

$$X_k(i+1) = X_k(i) + V_k(i+1), \quad (6)$$

其中,  $V_k(i)$  表示粒子  $k$  在第  $i$  次迭代时的速度,  $X_k(i)$  表示粒子  $k$  在第  $i$  次迭代时的位置,  $p_{best,i}^k$  表示粒子  $k$  在第  $i$  次迭代时的历史最优位置,  $g_{best,i}$  表示种群在第  $i$  次迭代时的全局最优位置,  $r_1$  和  $r_2$  为  $[0, 1]$  范围内的随机数.  $w$  为惯性权重,用于平衡全局搜索和局部搜索,其取值通常在  $[0, 1]$  之间.  $c_1$  和  $c_2$  分别为个体学习因子和社会学习因子,其中  $c_1$  反映粒子向自身历史最优位置  $p_{best,i}^k$  学习的权重,而  $c_2$  反映粒子向群体历史最优位置  $g_{best,i}$  学习的权重,取值范围通常都在  $[0, 4]$  之间.在更新过程中,粒子的运动受到其自身历史最优位置和种群全局最优位置的双重引导,逐步趋向于找到更加优良的解.简而言之,PSO 算法是通过个体与群体之间的信息共享和协作,寻找问题的最优解.

在实际工程优化与复杂系统建模中,由于问题背景的多样性和复杂性,传统 PSO 算法的性能面临严峻挑战,固定参数设置往往无法满足不同优化阶段的搜索需求,导致算法性能受限,难以达到预期效果.为了有效应对这一难题,本文提出了一种 MAPSO 算法:在学习因子的调整中引入了正弦函数,使得个体学习因子和社会学习因子能够根据迭代进程动态变化,既保持了算法的全局搜索能力,又增强了局部搜索的精细度;同时,在惯性权重的设置中采用基于指数函数的自适应策略,根据迭代次数动态调整惯性权重,平衡了算法的全局探索和局部开发能力;此外,引入邻域突变策略,通过局部精细搜索,引导粒子在潜在的全局最优解区域内进行高效搜索,优化算法的搜索路径,显著增强算法对于多样化初始条件及参数配置的适应能力,为优化问题的解决提供了强有力的算法保障.

这种多策略的自适应调整机制使得 MAPSO 算法能够根据问题的具体特点自适应地调整参数,从而在一定程度上减轻不利因素对算法性能的影响,使得算法在大部分情况下都能保持较为稳定的性能表现.具体内容如下:

### ① 自适应学习因子

在实际应用场景中,PSO 算法的性能深受个体学习因子  $c_1$  和社会学习因子  $c_2$  的影响,学习因子的动态平衡是决定算法性能的核心要素.个体学习因子  $c_1$  反映了粒子向自身历史最优位置  $p_{best}$  学习的权重,当  $c_1$  取

较大值时,粒子更倾向于向自身历史最优位置移动,有助于算法在搜索过程中保持多样性,避免过早收敛到局部最优解;社会学习因子  $c_2$  反映了粒子向群体历史最优位置  $g_{\text{best}}$  学习的权重,当  $c_2$  取较大值时,粒子更倾向于向群体历史最优位置移动,有助于算法加速收敛,但也可能导致算法陷入局部最优解。

为了平衡这两者的关系,本文引入了一种基于正弦函数的自适应惯性学习因子,个体学习因子  $c_1$  和社会学习因子  $c_2$  的取值随着迭代次数  $I_{\text{iter}}$  的改变如式(7)所示:

$$\begin{cases} c_1 = c_{\max} - (c_{\max} - c_{\min}) \cdot \sin\left(\frac{I_{\text{iter}}}{I_{\text{iter,max}}} \cdot \frac{\pi}{2}\right), \\ c_2 = c_{\min} + (c_{\max} - c_{\min}) \cdot \sin\left(\frac{I_{\text{iter}}}{I_{\text{iter,max}}} \cdot \frac{\pi}{2}\right), \end{cases} \quad (7)$$

其中,  $c_{\max}$  和  $c_{\min}$  分别取为 2.5 和 0.5,  $c_1$  和  $c_2$  变化趋势如图 1 所示。

如图 1 所示,迭代初期,个体学习因子  $c_1$  取值较大,粒子更倾向于向自身历史最优位置移动,有助于算法在搜索过程中保持多样性,避免过早收敛到局部最优解;迭代后期,社会学习因子  $c_2$  取值较大,粒子更倾向于向群体历史最优位置移动,有助于算法加速收敛。且整体呈现平缓的非线性变化趋势,能够确保算法的收敛性,提升收敛效率,方便寻找最优值。在整个调整过程中,个体学习因子  $c_1$  和社会学习因子  $c_2$  都呈现出一种平缓的非线性变化趋势,这种设计既确保了算法的收敛性,又提升了收敛效率,使得算法能够在保持全局搜索能力的同时,快速而准确地找到最优值。

## ② 自适应惯性权重

在粒子群优化算法中,惯性权重  $w$  扮演着至关重要的角色,作为算法的核心控制参数,巧妙地平衡了算法的全局搜索和局部搜索能力。当惯性权重  $w$  取较大值时,粒子更新后的速度受前一次迭代速度的影响较大,更多地保留前一次迭代的速度信息,使得全局寻优能力较强,局部寻优能力较弱;当惯性权重  $w$  取较小值时,粒子更新后的速度受前一次迭代速度的影响较小,更多地依赖于当前的位置信息,使得全局寻优能力弱,而局部寻优能力强。

为了充分利用惯性权重的这一调节作用,使其能够适应不同优化阶段的需求,本文提出了一种基于指数函数的自适应惯性权重策略,其随着迭代次数  $I_{\text{iter}}$  的改变如式(8)所示:

$$w = w_{\min} + (w_{\max} - w_{\min}) \cdot \exp\left(-10 \cdot \frac{I_{\text{iter}}}{I_{\text{iter,max}}}\right), \quad (8)$$

其中,  $w_{\max}$  和  $w_{\min}$  分别取为 0.9 和 0.1, 以确保算法在全局搜索和局部搜索之间取得良好的平衡,惯性权重  $w$  的变化趋势如图 2 所示。




图 1 自适应学习因子  $c_1$  和  $c_2$  变化曲线

Fig. 1 Change curves of adaptive  $c_1, c_2$




图 2 自适应惯性权重变化曲线

Fig. 2 The change curve of adaptive  $w$

注 为了解释图中的颜色,读者可以参考本文的电子网页版本,后同。

如图 2 所示,迭代初期,惯性权重  $w$  取值较大,算法的全局寻优能力得到加强,有助于算法在广阔的解空间中快速定位到潜在的最优区域;随着迭代的进行,惯性权重  $w$  逐渐减小,迭代后期,惯性权重  $w$  取值较小,

算法的局部寻优能力得到增强,使得算法能够在已定位的最优区域内进行精细搜索,加速收敛至最优解.整体而言,自适应惯性权重  $w$  呈现平缓的非线性变化趋势,既确保了算法的收敛性,又提升了收敛效率,为寻找最优值提供了有力支持.

### ③ 邻域突变策略

在传统 PSO 算法中,粒子倾向于聚集在全局最佳位置  $g_{best}$  附近,这种特性在一定程度上有助于加速算法的收敛过程,但也显著降低了种群的多样性,从而限制了算法在解空间中的全面搜索能力,容易导致早熟收敛问题,使得算法可能收敛到局部最优解而非全局最优解.为了应对这一挑战,本文提出了一种邻域突变策略,其核心思想是在全局最佳位置  $g_{best}$  的邻域内进行局部精细搜索,这种方法不仅能够有效避免粒子因过早收敛而陷入局部最优解,还能够显著提升算法的全局探索能力.

具体地,引入一种邻域突变策略,对全局最佳位置  $g_{best}$  进行局部扰动,生成新的个体  $X'$ :

$$X' = g_{best} + \eta \cdot \delta \cdot \zeta, \quad (9)$$

其中,  $\eta$  表示邻域范围参数,控制突变的邻域范围,通常取值为 0.1;  $\zeta \sim \mathcal{N}(0,1)$  表示服从标准正态分布的随机数;  $\delta$  表示搜索空间中最长对角线的长度,其数学表达式如式(10)所示:

$$\delta = \sqrt{\sum_{j=1}^n (x_j^{\max} - x_j^{\min})^2}, \quad (10)$$

其中,  $n$  表示粒子位置  $X$  的维度,  $x_j$  表示粒子位置  $X$  的第  $j$  个分量,  $x_j^{\max}$  和  $x_j^{\min}$  分别表示群体中各粒子第  $j$  个分量的最大值和最小值.

之后,计算新个体  $X'$  的适应度值,如果该适应度值优于当前全局最佳位置的适应度值,则更新全局最佳位置  $g_{best} = X'$ ; 否则,新个体  $X'$  以一定概率  $P$  随机替换种群中的一个个体,其数学表达式如式(11)所示:

$$P = \frac{f_{X'} - f_{\min}}{f_{\max} - f_{\min}}, \quad (11)$$

其中,  $f_{X'}$  表示新个体  $X'$  的适应度值,  $f_{\max}$  和  $f_{\min}$  分别表示当前种群中个体的最高适应度值和最低适应度值.

如式(11)所示,当新个体  $X'$  的适应度值接近种群中个体的最高适应度值  $f_{\max}$  时,  $P$  值趋近于 1,即新个体有很高的概率被用于替换种群中的其他个体.相反,如果新个体  $X'$  的适应度值接近种群中个体的最低适应度值  $f_{\min}$ ,则  $P$  值将趋近于 0,意味着新个体被替换的概率相对较低.

邻域突变策略在保障算法收敛效率的同时,大幅提升了搜索过程的全面性和准确性.通过局部精细搜索,邻域突变策略能够引导粒子在潜在的全局最优解区域内进行高效搜索,优化了算法的搜索路径,从而显著增强了算法对于多样化初始条件及参数配置的适应能力,为优化问题的解决提供了强有力的算法保障.

## 2 实验与分析

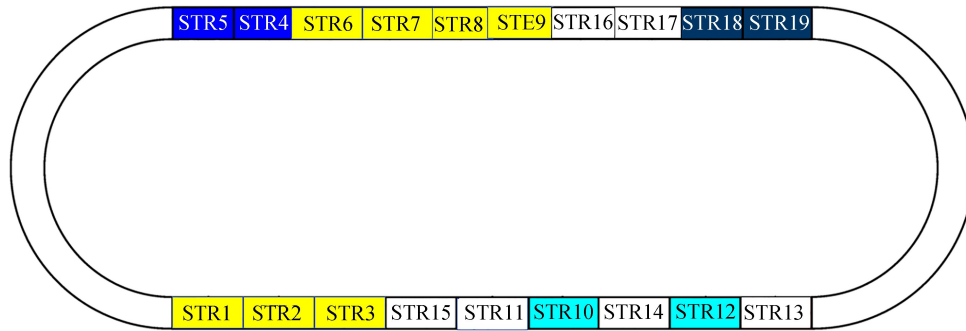
### 2.1 实验数据集

2015 年 11 月,交通运输部公路科学研究院主持建造了 RIOHTrack 足尺路面试验环道,通过足尺加速加载试验,模拟路面在长期使用过程中的各种复杂交通荷载和环境条件,为路面长期服役性能研究提供了可靠的数据支撑<sup>[28]</sup>.这一创新性试验平台的建成,不仅标志着我国在路面加速加载试验技术领域的重大突破,更为路面设计理论的发展注入了新的活力和动力.RIOHTrack 主要测试路面结构段为东西两侧的直线段和缓和曲线段,共铺设了 19 种不同的沥青路面结构,总长度达到 1 428 m,分别命名为 STR1 至 STR19.这些路面结构涵盖了国内外多种工程应用案例,包括柔性、半刚性和刚性基层结构等多种沥青结构层和材料组合模式,具有极高的代表性和实用性.

图 3(a)展示了 RIOHTrack 的路段布局,将 STR1 至 STR19 的 19 种不同的沥青路面结构划分为五类:半刚性基层结构(STR1-3、STR6-9)、复合式基层结构(STR4、STR5)、倒装式基层结构(STR10、STR12)、厚沥青混凝土结构(STR11、STR13-17)、全厚式结构(STR18、STR19).图 3(b)展示了部分测试路段的具体结构.

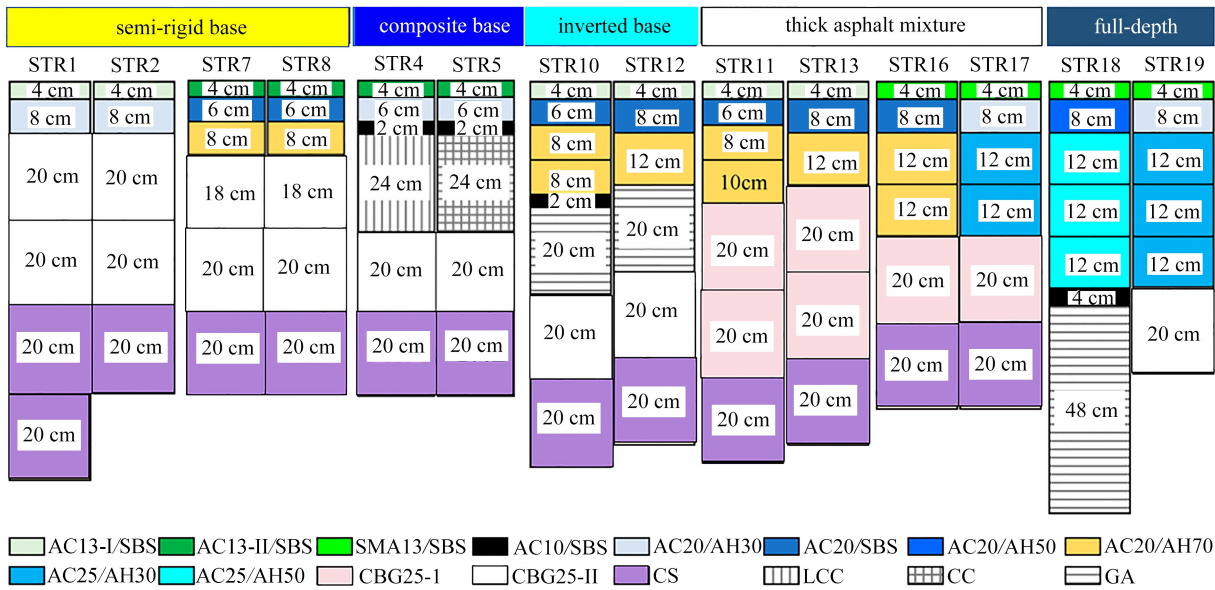
如图 3 所示,STR1 至 STR19 的 19 种不同的沥青路面结构可以被划分为五类:

① STR1-3 和 STR6-9 代表不同厚度的半刚性基层 (semi-rigid base) 结构, 在基层使用水泥稳定碎石 (cement-bound granular material, CBG)、水泥稳定土 (cement stabilized soil, CS) 等半刚性材料, 使得结构具有较高的强度和稳定性, 适用于承受重载交通和复杂环境条件道路, 能够有效抵抗重载交通产生的剪切变形, 从而保障了道路的长期使用安全, 其独特的板体效应赋予结构卓越的抗弯拉强度与荷载扩散能力, 尤其适用于重载交通及冻融循环频繁地区。



(a) RIOHTrack 的路段布局

(a) The road section layout of RIOHTrack



(b) RIOHTrack 不同测试路段的结构

(b) Structures of different test sections of RIOHTrack

图3 RIOHTrack 的路段布局 and 不同测试路段的结构

Fig. 3 The layout and structure of RIOHTrack

② STR4-5 是复合式基层 (composite base) 结构, 在基层采用多层不同材料的混合, 形成梯度模量结构, 不仅继承了各自材料的优势, 而且提高了整体的强度和稳定性, 既提高了基层的强度和稳定性, 实现了荷载的梯度消减, 又增强了路面的耐久性和抗裂性。

③ STR10 和 STR12 为倒装式基层 (inverted base) 结构, 将传统基层与面层的材料顺序进行颠倒, 展现出优异的排水降温性能与疲劳寿命, 给路面工程带来了新的可能性, 为路面设计提供新的思路和方法, 有助于探索更高效、更经济的道路结构。

④ STR11 和 STR13-17 是不同厚度的厚沥青混凝土 (thick asphalt mixture) 结构, 突破传统层状弹性理论框架, 通过增加沥青层的厚度, 提高了路面的承载能力和使用寿命, 以适应不同道路等级和交通荷载需求, 为

不同类型的道路提供了灵活的解决方案。

⑤ STR18-19 为全厚式(full-depth)结构,在整个路面结构中采用统一的材料组合和厚度设计,消除层间薄弱界面,其独特的材料连续性使结构整体刚度梯度更趋合理,在移动荷载作用下展现出优异的应力消散特性,实现了路面的整体协调性和长期稳定性,进而提高路面的耐久性和抗裂性。

通过对这些精心设计的路面结构进行系统试验与深入研究,不仅实现了对各类路面结构在长期使用周期内性能演化机理的全面剖析,揭示了其性能退化规律及相应的表现特征,而且为后续路面结构设计提供了坚实且可靠的科学依据与技术支撑。在此基础上,这些研究成果将极大地提高路面结构设计的合理性与有效性,优化维护策略,延长路面结构的使用寿命,同时降低对环境的负面影响,有力推动构建出更加安全可靠且环境友好的道路交通网络体系,进而为民众的出行提供更加便捷舒适的交通服务体验。

RIOHTrack 不同路段的部分车辙原始数据如表 1 所示。

表 1 RIOHTrack 原始车辙数据(rutting/mm)

Table 1 Original rutting data of RIOHTrack (rutting/mm)

loading date	cycle number	STR1	STR2	...	STR19
2016-11-30—2016-12-10	N1	1.556	1.567	...	1.844
2016-12-13—2016-12-24	N2	1.585	1.598	...	1.704
2016-12-27—2017-01-09	N3	1.495	1.481	...	1.857
2017-01-12—2017-02-23	N4	1.515	1.636	...	1.892
2017-02-26—2017-03-10	N5	0.633	0.853	...	0.848
2017-03-13—2017-03-23	N6	1.529	1.656	...	1.881
⋮	⋮	⋮	⋮	⋮	⋮
2023-11-09—2023-11-20	N157-mid	9.477	10.326	...	7.347
2023-11-30	N157	6.819	10.696	...	7.071
2023-11-25—2023-12-05	N158-mid	8.465	10.336	...	5.203
2023-12-19	N158	7.684	10.614	...	7.827
2023-12-10—2023-12-24	N159	8.558	10.689	...	6.543

本文使用 2016—2023 年的 RIOHTrack 足尺路面试验环道的车辙数据作为数据源,一共有 242 条数据,选择最后 48 条数据作为测试集,前面 194 条数据按照 7:3 比例拆分为训练集和验证集。为了充分展现本文所提出的 MAPSO-RME 车辙预测模型在性能上的显著优势,精心设计了以下两组实验,以进行全面系统的评估:

① 基于 RME 车辙深度预测模型,开展参数校准实验。将 MAPSO 算法与经典 PSO 算法、仅加入自适应惯性权重的 PSO- $w$  算法、仅加入自适应学习因子的 PSO- $c$  算法、加入自适应惯性权重和学习因子的 PSO- $cw$  算法进行实验对比,验证 MAPSO 算法中引入的改进策略的有效性。

② 将本文提出的 MAPSO-RME 车辙预测模型,与传统 ME 模型、MEPDG 模型<sup>[29]</sup>、ALF 模型<sup>[29]</sup>进行实验对比,验证 MAPSO-RME 车辙预测模型在预测精度和稳定性等方面的出色表现。

## 2.2 MAPSO 算法有效性

为了充分验证本文提出的 MAPSO 算法中几种自适应策略的有效性,基于 RME 车辙预测模型框架,分别使用经典 PSO 算法、仅加入自适应学习因子策略的 PSO- $c$  算法、仅加入自适应惯性系数策略的 PSO- $w$  算法、加入自适应惯性权重和学习因子的 PSO- $cw$  算法,以及同时加入三种改进策略的 MAPSO 算法校准参数。

在实验设置上,为了确保初始条件的统一性,粒子的速度和位置均选择为 1。同时,选取惯性系数  $w = 0.7$ ,个体学习因子  $c_1 = 2$ ,社会学习因子  $c_2 = 2$  作为基准参数,并设定粒子数量为 30 和最大迭代次数  $I_{iter,max} = 200$ ,使得算法能够在合理的计算成本下达到收敛。为了客观评估各算法的性能,采用均方误差 MSE 作为评价指标,对 RIOHTrack 足尺路面试验环道上采集的 19 种不同结构的沥青路面车辙数据进行预测实验。

这些数据涵盖了多种路面结构和材料,具有较高的代表性和实用性。在数据处理过程中,按照沥青路面的不同结构进行分组,并分别对训练集、验证集、测试集上的预测结果进行了统计和分析,具体的实验结果如

表 2 所示.

如表 2 所示,在使用不同 PSO 算法求解 RME 车辙深度预测模型参数的过程中,相较于经典 PSO 算法, PSO-*w* 算法、PSO-*c* 算法、PSO-*cw* 算法、MAPSO 算法均展现出了更出色的性能,验证了三种改进策略的有效性.整体来看,训练集和验证集上,MAPSO 算法表现最佳,平均 MSE 为 0.310 075,0.801 145,PSO-*c* 算法和 PSO-*cw* 算法次之,但相差不大.相较而言,训练集上 MAPSO 算法的平均 MSE 仅下降了 5.01%,0.23%,验证集上 MAPSO 算法的平均 MSE 下降了 1.28%,7.94%.然而,测试集上,MAPSO 算法明显优于其他四种 PSO 算法,平均 MSE 大幅下降.相较于经典 PSO 算法、PSO-*w* 算法、PSO-*c* 算法和 PSO-*cw* 算法,MAPSO 算法的平均 MSE 分别下降了 70.41%,43.82%,13.61%,28.54%,验证了 MAPSO 算法出色的泛化性能,在未见过的数据上表现良好.

表 2 使用不同 PSO 算法校准参数时 RME 车辙模型预测 MSE  
Table 2 MSE of the RME rutting model with different PSO algorithms

structure	STR	dataset	PSO	PSO- <i>w</i>	PSO- <i>c</i>	PSO- <i>cw</i>	MAPSO
semi-rigid base	1	training set	0.410 595	0.185 487	0.203 388	0.178 934	0.152 480
		validation set	0.696 990	0.582 992	0.596 342	0.563 521	0.530 709
		test set	2.509 542	1.177 000	1.474 362	1.221 109	0.967 856
	2	training set	0.606 712	0.412 764	0.253 175	0.209 692	0.166 210
		validation set	0.912 542	0.659 501	0.842 561	0.703 448	0.564 336
		test set	4.624 047	2.848 571	2.979 764	2.420 495	1.861 227
	3	training set	0.425 854	0.390 227	0.209 142	0.202 680	0.196 218
		validation set	0.877 747	0.729 117	0.965 374	0.837 196	0.709 018
		test set	3.169 630	1.315 188	1.194 343	1.374 164	1.553 986
	6	training set	0.516 525	0.865 394	0.258 599	0.258 599	0.258 600
		validation set	0.988 402	0.712 187	1.570 256	1.140 831	0.711 407
		test set	2.715 440	2.239 869	1.114 442	1.121 091	1.127 740
7	training set	1.134 145	0.553 150	0.362 448	0.362 255	0.362 062	
	validation set	1.736 897	0.932 510	1.050 403	0.992 835	0.935 268	
	test set	3.799 113	1.899 565	0.782 371	0.776 644	0.770 918	
8	training set	1.553 299	0.691 531	0.410 541	0.402 776	0.395 011	
	validation set	1.715 339	1.052 580	1.331 017	1.210 249	1.089 482	
	test set	5.949 349	3.498 445	1.564 804	1.333 661	1.102 519	
9	training set	0.882 199	1.019 762	0.413 015	0.392 358	0.371 702	
	validation set	1.573 723	0.946 857	1.806 158	1.401 802	0.997 447	
	test set	3.765 739	2.775 897	1.338 344	1.196 726	1.055 109	
4	training set	0.451 810	0.338 917	0.342 544	0.340 038	0.337 533	
	validation set	0.728 057	0.603 934	0.588 322	0.595 650	0.602 979	
	test set	2.374 773	1.245 610	1.231 211	1.265 825	1.300 439	
base	training set	0.407 643	0.256 997	0.235 612	0.235 594	0.235 576	
	5	validation set	0.927 610	0.778 510	0.740 710	0.740 252	0.739 794
	test set	2.108 517	0.614 362	0.922 068	0.928 251	0.934 434	
10	training set	1.247 075	0.651 788	0.424 257	0.424 231	0.424 206	
	validation set	1.737 176	1.260 077	1.096 066	1.095 811	1.095 556	
	test set	2.791 466	1.431 539	0.430 544	0.430 167	0.429 791	
base	training set	0.755 677	0.377 483	0.375 019	0.367 551	0.360 083	
	12	validation set	1.334 464	0.991 834	1.009 769	1.019 796	1.029 823
	test set	1.892 574	1.394 988	1.273 527	1.257 019	1.240 511	

接续表

续表

structure	STR	dataset	PSO	PSO- <i>w</i>	PSO- <i>c</i>	PSO- <i>cw</i>	MAPSO
thick asphalt mixture	11	training set	0.980 259	0.274 138	0.277 521	0.274 496	0.271 471
		validation set	1.598 245	1.016 558	1.021 496	1.023 717	1.025 939
		test set	3.625 655	0.944 324	0.954 184	0.906 389	0.858 595
	13	training set	0.482 084	0.215 051	0.214 200	0.213 234	0.212 268
		validation set	0.968 232	0.711 305	0.725 866	0.721 866	0.717 867
		test set	1.332 715	1.068 594	1.053 880	0.881 943	0.710 006
	14	training set	0.919 257	2.194 195	0.488 585	0.488 584	0.488 584
		validation set	1.438 904	3.026 559	0.992 537	0.992 513	0.992 489
		test set	1.057 984	2.576 982	0.777 095	0.677 353	0.577 611
	15	training set	0.764 079	0.356 896	0.225 591	0.224 920	0.224 249
		validation set	1.272 832	0.940 174	0.835 076	0.834 197	0.833 318
		test set	1.596 950	1.413 084	1.396 155	1.351 480	1.306 806
	16	training set	0.608 094	0.284 710	0.273 694	0.273 691	0.273 689
		validation set	1.028 781	0.686 561	0.699 881	0.699 583	0.699 285
		test set	1.733 118	1.539 418	1.400 808	1.402 209	1.403 611
	17	training set	0.550 707	0.390 883	0.291 573	0.289 111	0.286 650
		validation set	0.847 637	0.730 998	0.585 582	0.578 780	0.571 979
		test set	1.012 510	0.702 791	0.764 194	0.722 844	0.681 495
full-depth structure	18	training set	1.340 227	0.738 468	0.625 697	0.449 693	0.273 689
		validation set	1.454 363	1.040 647	0.517 088	0.608 186	0.699 285
		test set	2.683 918	0.860 402	1.123 262	0.961 056	0.798 851
19	training set	0.508 108	0.319 305	0.316 766	0.316 469	0.316 172	
	validation set	0.893 133	0.780 262	0.773 359	0.773 730	0.774 101	
	test set	1.288 807	0.524 418	0.461 374	0.488 395	0.515 417	
mean value	1-19	training set	0.765 492	0.326 387	0.553 534	0.310 785	0.310 075
		validation set	1.196 372	0.811 559	1.089 961	0.870 209	0.801 145
		test set	2.633 255	0.901 943	1.387 940	1.090 359	0.779 180

图 4 为基于 RME 车辙预测模型,分别使用经典 PSO 算法、仅加入自适应学习因子策略的 PSO-*c* 算法、仅加入自适应惯性系数策略的 PSO-*w* 算法、加入自适应惯性权重和学习因子的 PSO-*cw* 算法、同时加入三种改进策略的 MAPSO 算法校准参数,对 RIOHTrack 足尺路面试验环道的 19 种沥青路面的车辙数据进行预测实验的对比箱线图。




图 4 使用不同 PSO 算法校准参数时 RME 车辙模型预测箱线图

Fig. 4 The boxplots of the RME rutting model with different PSO algorithms

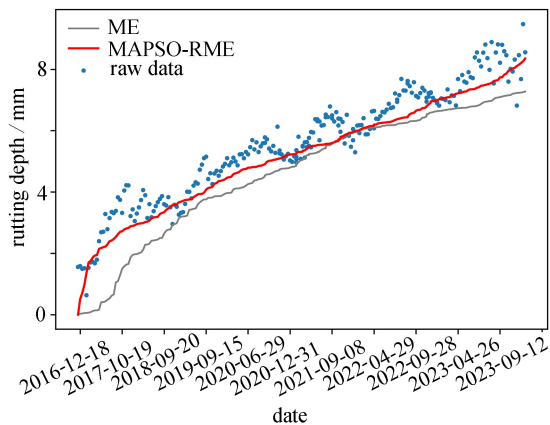
观察图 4 可以发现,与经典 PSO 算法相比,仅引入正弦自适应学习因子的 PSO-*c* 算法、仅引入指数自适

应惯性权重的 PSO- $w$  算法、加入自适应惯性权重和学习因子的 PSO- $cw$  算法被应用于 RME 车辙模型时,模型的 MSE 均实现了一定程度的降低.这一结果表明,无论是正弦自适应学习因子还是指数自适应惯性权重,都能在在一定程度上提升算法性能.然而,这几种算法仍存在一些异常值,表明模型在某些结构的路段上效果并不是特别理想.进一步,当使用 MAPSO 算法校准参数时,RME 车辙预测模型的 MSE 显著减小,并且不再出现异常值.这不仅验证了三种优化策略结合的有效性,还表明 MAPSO 算法在提升模型整体性能方面表现出色,实现了预测精度和稳定性的双重提升.

### 2.3 MAPSO-RME 模型预测实验

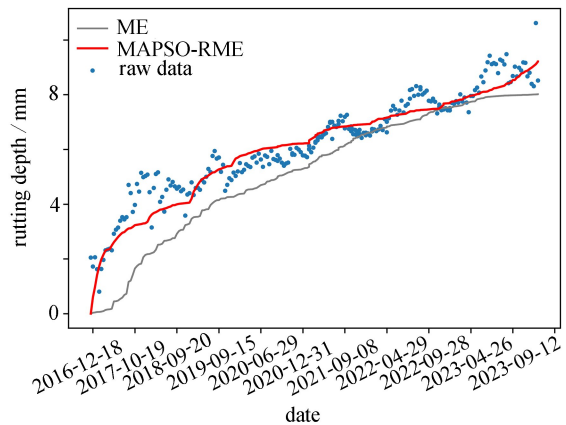
由于力学经验模型的预测适用性和准确性深受其本构方程形式、模型开发所依据的数据源以及经验参数等多重因素的制约,本文基于 JTG D50—2017 规范中的 ME 车辙预测模型<sup>[23]</sup>,创新性地引入了三个校准参数,分别对常数项系数、温度和累计载荷次数进行校准,得到了一种 RME 车辙预测模型,并使用 MAPSO 算法求解这些校正参数,开发了 MAPSO-RME 车辙预测模型.

为了验证所提出的校正策略的有效性,分别使用 JTG D50—2017 规范中的 ME 与 MAPSO-RME 两种车辙预测模型,对 RIOHTrack 足尺路面加速加载试验环道上铺设的 19 种不同沥青路面结构的车辙数据进行了预测实验.为了更加直观地对比 JTG D50—2017 规范中的 ME 车辙模型与 MAPSO-RME 车辙模型在预测性能上的优劣,本文选取了五种具有代表性的沥青路面结构进行深入分析,并在每种结构类型中选择一种或者两种路面进行展示:半刚性基层结构的 STR1、半刚性基层结构的 STR6、复合式基层结构的 STR5、倒装式基层结构的 STR12、厚沥青混凝土结构的 STR11、全厚式结构的 STR19.其拟合结果的折线图如图 5 所示.



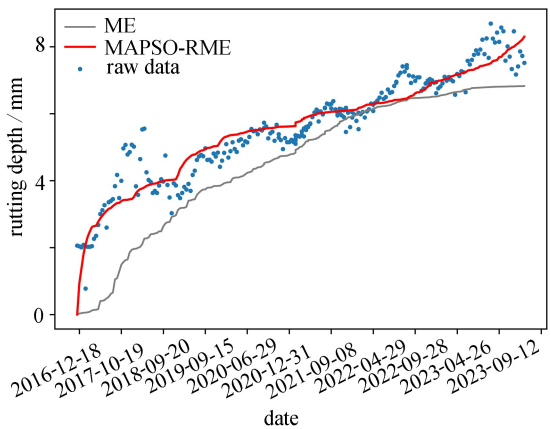
(a) 半刚性基层结构-STR1

(a) The semi-rigid base structure-STR1



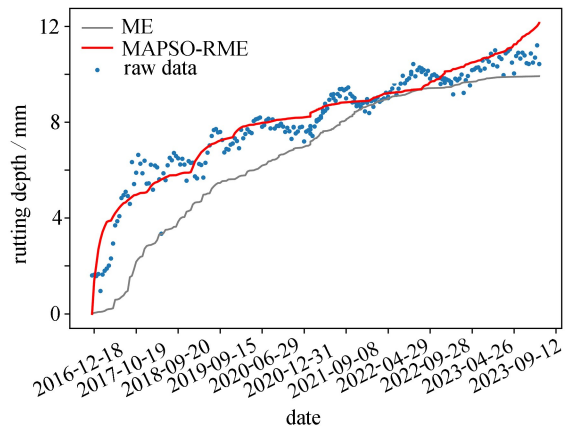
(b) 半刚性基层结构-STR6

(b) The semi-rigid base structure-STR6



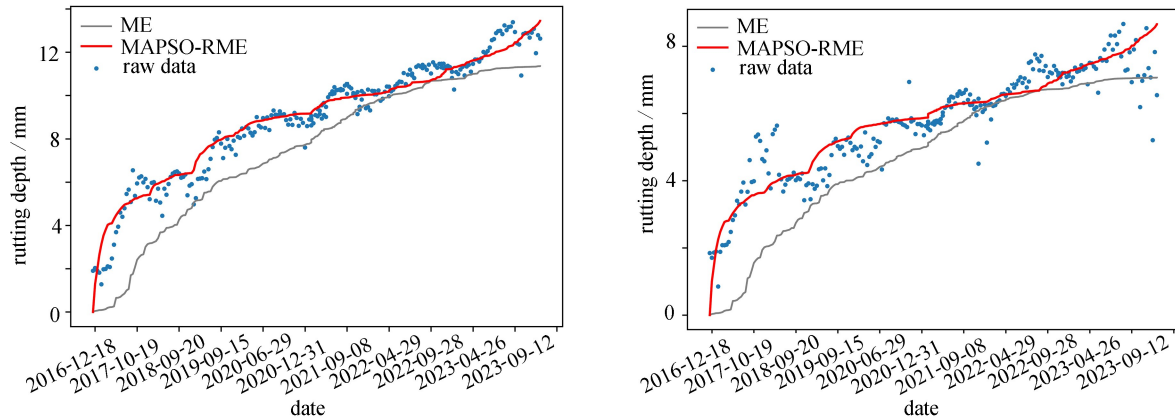
(c) 复合式基层结构-STR5

(c) The composite base structure-STR5



(d) 倒装式基层结构-STR12

(d) The inverted base structure-STR12



(e) 厚沥青混凝土结构-STR11

(f) 全厚式结构-STR19

(e) The thick asphalt mixture structure-STR11

(f) The full-depth structure-STR19

图 5 传统 ME 与 MAPSO-RME 模型车辙数据拟合图

Fig. 5 Fitting diagram of rutting data for the traditional ME and MAPSO-RME models

观察图 5 可以发现,对于 RIOHTrack 足尺路面试验环道各种结构的路面,本文提出的 MAPSO-RME 车辙预测模型都明显优于传统 ME 模型,通过引入三个校准参数并使用多策略自适应 PSO 算法求解参数,模型的整体拟合度获得了较大幅度的提升。

进一步地,为了验证 MAPSO-RME 车辙预测模型的性能,将传统 ME 车辙预测模型、文献[29]中的 MEPDG 车辙预测模型和 ALF 车辙预测模型作为对比,对 RIOHTrack 足尺路面试验环道的 19 种沥青路面的车辙数据进行预测实验,按照不同结构的沥青路面分组统计,在训练集、验证集、测试集上的表现如表 3 所示。

表 3 MAPSO-RME 与其他车辙模型预测 MSE

Table 3 MSE of MAPSO-RME and other rutting depth prediction models

structure	STR	dataset	conventional ME	MEPDG	ALF	MAPSO-RME
semi-rigid base	1	training set	3.028 442	3.220 613	4.558 947	0.152 479
		validation set	3.354 868	3.476 885	4.660 625	0.530 709
		test set	7.871 037	8.784 877	11.996 429	0.967 855
	2	training set	5.035 846	5.373 725	7.524 113	0.166 209
		validation set	5.187 335	5.436 588	7.334 865	0.564 335
		test set	12.489 605	14.480 936	19.786 438	1.861 226
	3	training set	4.200 122	4.133 276	5.785 925	0.196 217
		validation set	4.644 348	4.548 648	6.066 975	0.709 017
		test set	8.951 187	9.881 610	13.793 160	1.553 985
	6	training set	3.851 698	3.912 073	5.471 450	0.258 599
		validation set	4.605 777	4.585 073	6.072 855	0.711 406
		test set	8.568 350	9.525 019	13.199 786	1.127 739
	7	training set	9.181 578	9.733 199	13.474 390	0.362 061
		validation set	9.123 794	9.457 739	12.786 435	0.935 267
		test set	18.169 156	20.029 062	28.020 197	0.770 917
	8	training set	12.190 578	13.114 549	17.864 043	0.395 010
		validation set	12.072 149	12.829 842	17.080 704	1.089 481
		test set	25.204 567	28.628 111	39.376 308	1.102 518
9	training set	6.695 091	6.958 968	9.569 548	0.371 701	
	validation set	7.276 596	7.378 902	9.768 586	0.997 446	
	test set	13.834 582	15.589 380	21.664 890	1.055 108	

接续表

续表

structure	STR	dataset	conventional ME	MEPDG	ALF	MAPSO-RME
composite base	4	training set	2.384 208	2.298 905	3.132 093	0.337 532
		validation set	3.096 253	3.002 693	3.855 451	0.602 978
		test set	5.716 098	6.388 276	8.682 817	1.300 438
	5	training set	3.130 139	3.087 029	4.298 696	0.235 576
		validation set	4.091 722	4.032 026	5.240 113	0.739 793
		test set	6.591 538	7.237 353	10.104 716	0.934 434
inverted base	10	training set	9.858 078	10.559 385	14.721 283	0.424 205
		validation set	10.173 588	10.479 296	14.155 547	1.095 555
		test set	18.439 777	19.492 381	27.630 661	0.429 790
	12	training set	6.654 381	6.828 003	9.563 298	0.360 082
		validation set	7.561 562	7.462 090	9.994 335	1.029 822
		test set	12.120 562	12.274 365	17.467 073	1.240 511
thick asphalt mixture	11	training set	8.495 938	9.050 297	12.662 660	0.271 471
		validation set	9.100 457	9.356 417	12.565 171	1.025 939
		test set	17.356 242	18.876 424	26.457 632	0.858 594
	13	training set	4.662 731	4.631 565	6.501 461	0.212 267
		validation set	5.319 145	5.171 455	6.923 511	0.717 866
		test set	7.352 789	7.553 253	11.084 846	0.710 006
14	training set	7.039 255	7.123 291	9.966 689	0.488 583	
	validation set	7.551 967	7.317 617	9.933 316	0.992 488	
	test set	11.478 991	11.088 329	16.034 980	0.577 611	
15	training set	7.632 578	7.900 890	11.054 452	0.224 248	
	validation set	7.466 344	7.589 090	10.355 889	0.833 317	
	test set	12.051 865	12.430 074	18.060 955	1.306 805	
16	training set	5.671 963	5.695 424	7.906 122	0.273 688	
	validation set	5.853 698	5.768 754	7.767 493	0.699 284	
	test set	9.810 330	10.187 734	14.532 253	1.403 611	
17	training set	5.550 707	6.291 573	6.390 883	0.286 650	
	validation set	6.847 637	6.585 582	6.730 998	0.571 979	
	test set	10.831 145	11.403 217	15.675 145	0.681 495	
full-depth structure	18	training set	8.340 227	8.625 697	9.738 468	0.273 689
		validation set	9.135 367	9.594 851	13.285 677	0.699 285
	19	test set	18.337 959	19.304 372	27.317 153	0.798 851
		training set	3.629 191	3.594 874	4.946 199	0.316 171
19	validation set	4.196 426	4.177 939	5.464 795	0.774 100	
	test set	6.105 749	6.265 470	8.901 877	0.515 416	

如表3所示,本文提出的MAPSO-RME车辙预测模型明显优于传统ME车辙预测模型、文献[29]中的MEPDG车辙预测模型和ALF车辙预测模型,训练集、验证集和测试集上的MSE都大幅度降低,模型效果显著提升。

### 3 总 结

车辙是沥青路面常见的病害之一,在许多国家沥青路面结构设计中都占据着极其重要的地位.现有的车辙性能预测模型主要可以分为经典力学模型、传统经验模型、力学经验模型和机器学习模型等类型,每种模型都有其独特的优点和局限性.其中,力学经验模型使用频率较高,且易于通过统计分析方法进行修改,具有更高的预测信度和准确性,只是,该模型的适用性和准确性,在很大程度上受到模型发展的数据源和经验参

数等因素的影响。

因此,本文提出了一种 MAPSO-RME 车辙预测模型,主要贡献如下:

1) 引入邻域突变策略,并融入指数自适应惯性权重和正弦自适应学习因子,提出了一种 MAPSO 算法,有助于保证算法的收敛性,提升收敛效率,方便寻找最优值。

2) 基于《公路沥青路面设计规范》(JTG D50—2017)中提出的 ME 车辙预测模型,引入三个校准参数,分别对常数项系数、温度和累计荷载次数进行校准,建立了 RME 车辙预测模型。

3) 基于 RIOHTrack 足尺路面加速加载试验环道的 19 种沥青路面的车辙数据,使用 MAPSO 算法,求解三个校准参数的值,得到 MAPSO-RME 车辙预测模型。相较于传统 ME 模型,模型预测均方误差 MSE 实现大幅降低。

4) 这种引入校准参数并基于试验数据使用 MAPSO 算法求解校准参数的方法,对于其他地区车辙预测模型的设计也有一定的参考价值,具有推广意义,可以增强车辙预测模型的区域适用性。

但是,本研究也存在一定的局限性。因为使用的数据源是 RIOHTrack 足尺路面加速加载试验环道沥青路面数据,总数据量只有 242 条,数量太少,参数校准和模型拟合预测的效果并不是特别理想。因此,在未来的研究中,计划对原始数据进行数据增强处理,以进一步优化车辙预测模型,提升模型性能。

#### 参考文献 (References):

- [1] GUNGOR O E, AL-QADI I L. All for one: centralized optimization of truck platoons to improve roadway infrastructure sustainability[J]. *Transportation Research (Part C): Emerging Technologies*, 2020, **114**: 84-98.
- [2] CHEN X, DONG Q, ZHU H, et al. Development of distress condition index of asphalt pavements using LTPP data through structural equation modeling[J]. *Transportation Research (Part C): Emerging Technologies*, 2016, **68**: 58-69.
- [3] ZHENG J, LÜ S, LIU C. Technical system, key scientific problems and technical frontier of long-life pavement[J]. *Chinese Science Bulletin*, 2020, **65**(30): 3219-3229.
- [4] CAREY W N, IRICK P E. The pavement serviceability-performance concept[J]. *Highway Research Board Bulletin*. 1960.
- [5] WU T, CAO J, MA T, et al. Development of rutting forecasting models for distinct asphalt pavement structures in RIOH testing track using different approaches[J]. *Construction and Building Materials*, 2023, **368**: 130483.
- [6] WOREL B, VAN DEUSEN D. Benefits of MnROAD phase- II research: MN/RC 2015-19[R]. St Paul, MN: Minnesota Department of Transportation, 2015.
- [7] TIMM D H, PRIEST A L. Dynamic pavement response data collection and processing at the NCAT test track [R]. 2004.
- [8] Federal Highway Administration. AASHO road test[EB/OL]. (2022-03-08) [2025-04-22]. <https://www.fhwa.dot.gov/infrastructure/50aasho.cfm>.
- [9] ZHANG X, OTTO F, OESER M. Pavement moduli back-calculation using artificial neural network and genetic algorithms[J]. *Construction and Building Materials*, 2021, **287**: 123026.
- [10] NZ Transport Agency. Canterbury accelerated pavement testing indoor facility[EB/OL]. [2025-04-22]. <https://www.nzta.govt.nz/resources/captif/>.
- [11] WANG X D, ZHOU G L, LIU H Y, et al. Key points of RIOHTRACK testing road design and construction[J]. *Journal of Highway and Transportation Research and Development (English Edition)*, 2020, **14**(4): 1-16.
- [12] RADHAKRISHNAN V, DUDIPALA RR, MAITY A, et al. Evaluation of rutting potential of asphalts using resilient modulus test parameters[J]. *Road Materials and Pavement Design*, 2019, **20**(1): 20-35.
- [13] ZHANG J R, CAO J D, HUANG W, et al. Rutting prediction and analysis of influence factors based on multi-variate transfer entropy and graph neural networks[J]. *Neural Networks*, 2023, **157**: 26-38.
- [14] LI Z, SHI X, CAO J, et al. CPSO-XGBoost segmented regression model for asphalt pavement deflection basin area prediction[J]. *Science China Technological Sciences*, 2022, **65**(7): 1470-1481.

- [15] KIM W J, LE V P, LEE H J, et al. Calibration and validation of a rutting model based on shear stress to strength ratio for asphalt pavements[J]. *Construction and Building Materials*, 2017, **149**: 327-337.
- [16] LIU G, CHEN L L, QIAN Z D, et al. Rutting influencing factors and prediction model for asphalt pavements based on the factor analysis method[J]. *Journal of Southeast University(English Edition)*, 2021, (4): 421-428.
- [17] CHOI Y T, KIM Y R. Implementation and verification of a mechanistic permanent deformation model (shift model) to predict rut depths of asphalt pavement [J]. *Road Materials and Pavement Design*, 2014, **15** (sup1): 195-218.
- [18] LING J, REN L, TIAN Y, et al. Analysis of airfield composite pavement rutting using full-scale accelerated pavement testing and finite element method[J]. *Construction and Building Materials*, 2021, **303**: 124528.
- [19] ARCHILLA A R. Use of superpave gyratory compaction data for rutting prediction[J]. *Journal of Transportation Engineering*, 2006, **132**(9): 734-741.
- [20] SUH Y C, CHO N H. Development of a rutting performance model for asphalt concrete pavement based on test road and accelerated pavement test data[J]. *KSCE Journal of Civil Engineering*, 2014, **18**(1): 165-171.
- [21] 刘俊卿, 刘红, 李倩. 变温条件下考虑车辆-路面相互作用的车辙分析[J]. *应用数学和力学*, 2017, **38**(2): 170-180. (LIU Junqing, LIU Hong, LI Qian. Pavement rutting analysis based on vehicle-road interaction under thermal effects[J]. *Applied Mathematics and Mechanics*, 2017, **38**(2): 170-180. (in Chinese))
- [22] AASHTO. Mechanistic-empirical pavement design guide: a manual of practice, interim edition[S]. Washington, DC, USA: American Association of State Highway and Transportation Officials, 2008.
- [23] 中华人民共和国交通运输部. 公路沥青路面设计规范[M]. 北京: 人民交通出版社, 2017. (Ministry of Transport of the People's Republic of China. *Specifications for Design of Highway Asphalt Pavements*[M]. Beijing: China Communications Press, 2017. (in Chinese))
- [24] SHELL. *Pavement Design Manual*[M]. London, UK: Shell International Petroleum Company, Ltd., 1978.
- [25] WU Y, ZHOU X, WANG X, et al. Evaluation and correction method of asphalt pavement rutting performance prediction model based on RIOHTrack long-term observation data[J]. *Applied Sciences*, 2022, **12**(13): 6805.
- [26] WANG Y Y, ZHANG B Q, CHEN Y C. Robust airfoil optimization based on improved particle swarm optimization method[J]. *Applied Mathematics and Mechanics (English Edition)*, 2011, **32**(10): 1245-1254.
- [27] KENNEDY J, EBERHART R. Particle swarm optimization[C]//*Proceedings of ICNN'95-International Conference on Neural Networks*. Perth, WA, Australia, 1995: 1942-1947.
- [28] 李敏, 李卓轩, 时欣利, 等. 基于可解释性集成学习的 RIOHTrack 车辙预测模型及驱动因素研究[J]. *应用数学和力学*, 2025, **46**(1): 92-104. (LI Min, LI Zhuoxuan, SHI Xinli, et al. Research on driving factors of the RIOHTrack rutting prediction model based on interpretable ensemble learning[J]. *Applied Mathematics and Mechanics*, 2025, **46**(1): 92-104. (in Chinese))
- [29] 冯伟. 基于足尺环道试验的沥青路面车辙预估模型及变形机理研究[D]. 长沙: 长沙理工大学, 2021. (FENG Wei. Study on rutting prediction model and deformation mechanism of asphalt pavement based on full-scale test loop[D]. Changsha: Changsha University of Science & Technology, 2021. (in Chinese))