

基于人工神经网络的沥青路面纵向裂缝演化预测

谭林¹, 万诚², 郑建和¹, 陈友雀¹, 范志浩², 王金昌²

¹浙江交工路桥建设有限公司, 浙江 杭州

²浙江大学建筑工程学院, 浙江 杭州

收稿日期: 2025年3月7日; 录用日期: 2025年5月13日; 发布日期: 2025年5月27日

摘要

目的: 预测沥青路面道路在长期服役条件下的纵向裂缝长度。方法: 本研究从长期路面性能数据库中选择和处理与纵向裂缝发展相关的影响因素, 建立人工神经网络预测模型, 研究模型参数对精度的影响。结果: 建立的模型 R^2 为0.804, 预测效果较好。结论: 人工神经网络能较好预测沥青路面纵向裂缝的发展, 能为预防性养护提供支持。

关键词

沥青路面, 人工神经网络, 纵向裂缝, 病害预测

Evolution Prediction of Longitudinal Crack of Asphalt Pavement Based on Artificial Neural Network

Lin Tan¹, Cheng Wan², Jianhe Zheng¹, Youque Chen¹, Zhihao Fan², Jinchang Wang²

¹Zhejiang Jiaogong Road and Bridge Construction Co., Ltd., Hangzhou Zhejiang

²College of Civil Engineering and Architecture, Zhejiang University, Hangzhou Zhejiang

Received: Mar. 7th, 2025; accepted: May 13th, 2025; published: May 27th, 2025

Abstract

Purpose: This paper aims to predict the longitudinal crack length of asphalt pavement under long-term service conditions. **Method:** In this paper, the influencing factors related to the development of longitudinal cracks were selected and processed from the long-term pavement performance database,

文章引用: 谭林, 万诚, 郑建和, 陈友雀, 范志浩, 王金昌. 基于人工神经网络的沥青路面纵向裂缝演化预测[J]. 交通技术, 2025, 14(3): 323-333. DOI: 10.12677/ojtt.2025.143033

an artificial neural network prediction model was established, and the effect of model parameters on accuracy was studied. Result: The R^2 of the established model was 0.804, and the prediction effect was good. Conclusion: Artificial neural network can better predict the development of longitudinal cracks in asphalt pavement, and can provide support for preventive maintenance.

Keywords

Asphalt Pavement, Artificial Neural Network, Longitudinal Cracks, Disease Prediction

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

沥青路面相比其他材料路面,使用性能较好且修建养护简便,被广泛应用于全国的各级公路和城市道路建设中[1]。但由于沥青混合料的材料特点,路面在服役过程中病害多发,其中纵横向裂缝在形成之后,不仅影响行车舒适性,更可能导致路面结构的破坏,对行车安全造成威胁[2]。

对于沥青路面性能演化,以往的研究都集中在综合性能评价指标的预测,而预防性养护则要求对路面具体病害的发展进行掌握,因此,在裂缝预测的回归模型方面,Queiroz 等[3]-[5]引入路面结构、材料、交通、环境和道路使用年限,预测未来的裂缝状况。而对于概率模型,潘旺等[6]改进了灰色理论的背景值和计算公式,在沥青路面裂缝实测数据的基础上进行分析,确定裂缝发展的关键影响因素,建立了裂缝增长的预测模型。近年来,研究人员将道路检测的大量数据应用于机器学习方法,建立了更加多样的预测模型。Lou 等[7]开发了一个反向传播神经网络模型,准确预测佛罗里达公路网裂缝指数的短期时间变化。Gong 等[8]开发了一种梯度提升模型来提高传递函数的疲劳开裂预测性能。Karlaftis [9]利用遗传优化神经网络对路面修复后疲劳裂纹萌生的概率进行建模,提出的方法代表了裂纹萌生概率与各种设计、交通和天气因素以及不同修复策略之间的实际关系。谭冰心[10]使用监督学习中的 GRNN 对道路开裂破坏率进行预测,发现在变量较少时效果比 BPNN 更好;柯文豪等[11]采用相关分析法得到了裂缝发展影响因素相关性,采用广义回归神经网络建立了精度较高的沥青路面裂缝预测模型,但模型的训练数据仅有 50 组,验证集 6 组,数据量较小。

综合看来,现有的研究存在只能预测短期内的变化、训练数据集较小、适用性不强,具体的横纵向裂缝发展预测的研究较少等问题。因此本文从长期路面性能数据库(LTPP)中选择半刚性基层沥青路面结构的纵向裂缝检测值及其影响因素,训练人工神经网络模型,并进行验证。

2. BP 人工神经网络

人工神经网络主要分为前向反馈神经网络和递归神经网络,其中前向反馈网络的理论完备、实际应用广泛,它是一种多层前向反馈人工神经网络,根据统计,有 80%上下的人工神经网络模型采用的是前向反馈神经网络及其变形[12]。由于具有深厚的理论基础、严谨的反算和推导过程、适用性良好等优势,本文采取前向反馈人工神经网络模型对纵向裂缝发展进行建模预测。

前向反馈神经网络的结构是由三层及以上的神经元组成,基本结构如图 1 所示,包含一个输入层,一个或多个中间层,一个输出层,前一层与后一层之间每个神经元之间全连接,相同层之间的神经元之间没有连接,各层之间连接强度用权值大小表示,一层中的每个神经元的输出项,作为下一层中神经元的输入项,每一层的神经元内部的激活函数和阈值控制该神经元的输出,用于预测的特征使用输入层进

行输入，中间层代表的是隐藏的变量，最后一个隐藏层与输出层连接，输出项是响应变量的预测值。

前馈神经网络的基本思路是，模型的训练过程分为信号的正向传播与误差的反向传播。在正向传播时，样本数据从输入层输入，经过中间层的依次处理，最后传递给输出层，计算出输出层的预测值与数据真实值的误差之后，进入误差反向传播阶段。误差的反向传播首先计算最后一个中间层中的每个神经元对输出层总误差的贡献程度，之后以此类推，计算这些误差贡献中来自上一层的每个神经元的多少，一直到输入层停止。在误差反向传播过程中，网络中用于连接神经元的权重误差梯度被有效测量和修正。在模型建立过程中，每一次训练，前馈神经网络都先进行一次正向传播，计算误差之后，反向计算每个连接的误差贡献度，调整权重以降低误差，直到网络输出的误差降低到设置的运行接受的范围或达到预设的训练次数停止。




Figure 1. Schematic diagram of neural network structure
图 1. 神经网络结构示意图

人工神经网络的主要参数主要有：各层神经元个数、中间层数量、激活函数类型、权重优化器、学习率和训练次数。参数选择对于人工神经网络模型性能起着至关重要的作用，人工神经网络模型结构会随着层数和神经元个数的增加而变得非常复杂，选择合理的参数能降低模型复杂度的同时得到良好的预测结果。因此，本文将研究不同的参数选择对模型效果的影响，并选择最佳参数进行模型的建立。

3. 数据选择与处理

本次数据来源于长期路面性能数据库中的沥青路面半刚性基层道路结构实验路段，路段总数共有 144 条，纵向裂缝根据损坏的严重程度分为轻、中和重度裂缝。

影响道路裂缝病害发展的因素包括内部因素和外部因素，如表 1 所示，内部因素为道路的结构与材料，外部因素为交通荷载与区域气候。因此，本文的人工神经网络输入特征将从这些影响因素中进行选择，具体的特征选择如表 1 所示。

本研究的病害选择中仅使用未经修复的裂缝作为研究对象，选择沥青混凝土路面的纵向裂缝长度检测数据，并将三种不同长度的裂缝数据进行相加，作为研究的模型输出；道路的结构关系到沥青路面道路的各个层位在行车荷载下和自然因素作用下受到的影响，尤其是在交通荷载下路面结构内部产生的应力应变和产生的断裂能量，因此，在数据库中选择沥青面层各层、基层、底基层的厚度作为道路建设初

期和重建之后的道路结构数据，其中沥青面层进行相加作为一层输入模型中；在材料的属性中，模量能较好反映出材料抵抗变形的能力，其中选取面层 20℃-10 Hz 动态模量作为模量，而基层、底基层和土基则使用其回弹模量，另外，影响抗开裂性能的级配参数、沥青含量和沥青混合料孔隙率同样作为输入变量进行选择，这些数据均进行平均取值以减少误差；交通和气候因素也是本研究中不容忽视的主要影响因素，本文使用道路年的标准轴载次数作为交通量，按照检测时间的间隔进行求和，使用检测期间累积月份的降雨量、高于 32℃ 天数和低于 0℃ 天数作为气候信息。这些数据组成训练模型的数据集合。

Table 1. Summary of input features for neural network model
表 1. 神经网络模型输入特征汇总

特征类型	输入特征	描述	单位
历史病害信息	前一次检测裂缝长度/数量	沥青路面前一次检测的裂缝长度/数量	m/-
结构信息	面层厚度	沥青路面的总厚度	mm
	基层厚度	实验路段的基层厚度	mm
	底基层厚度	实验路段底基层厚度	mm
材料信息	面层模量(20℃-10 Hz)	沥青面层在 20 摄氏度，10 Hz 加载频率下的动态模量	MPa
	基层模量	基层回弹模量	MPa
	底基层模量	底基层回弹模量	MPa
	土基模量	土基回弹模量	MPa
	19 mm 筛孔通过率	集料在 19 mm 筛的通过率	%
	9.5 mm 筛孔通过率	集料在 9.5 mm 筛的通过率	%
	4.75 mm 筛孔通过率	集料在 4.75 mm 筛的通过率	%
	0.075 mm 筛孔通过率	集料在 0.075 mm 筛的通过率	%
	沥青含量	面层中沥青的含量	%
交通量信息	孔隙率	沥青混合料的孔隙率	%
	交通累积量	检测间隔期间标准轴载次数	EASL
	检测间隔时间	两次检测之间的间隔天数	day
时间信息	服役总时间	道路建设/翻修后服役总时间	day
	降雨累积量	检测间隔期间的降雨累计量	mm
气候信息	32℃ 以上天数	检测间隔期间 32℃ 以上的高温天数	day
	0℃ 以下天数	检测间隔期间 0℃ 以下的低温天数	day

4. 参数选择

在本文的人工神经网络模型中，除中间层层数以外，其他参数均使用网格搜索首先进行单个参数的调整，研究单个参数对于模型的影响，最后对参数组合进行网格搜索，找到模型的最优参数组合，使用样本集合中随机选择的 80% 进行模型训练。

本文将中间层设置为一、二、三层，并进行了对比，结果显示，中间层设置为二和三层时效果提升不大，模型训练的效率较低，且容易出现过拟合现象。因此，本文的中间层数量设置为一层，即神经网络为三层结构。选择单隐藏层是为了平衡模型的复杂度和泛化能力。

4.1. 神经元个数

根据经验公式，将神经元个数选择区间设置为[30~120]，每隔 10 进行一次取值。神经元个数太少，模型可能无法充分学习数据的特征；神经元个数太多，模型容易过拟合，导致泛化能力下降。遍历所有候选值，每次训练使用相同的训练集和验证集，评估指标为验证集上的 R^2 拟合度。如图 2 所示，预测模型的神经元个数在 90 个之前预测精度逐步上升，设置为 90 时达到最大，之后下降。因此 90 个神经元在当前数据集上取得了最佳的平衡。

4.2. 权重优化器

本文对比了三种常用的优化器：SGD (Stochastic Gradient Descent)、Adam (Adaptive Moment Estimation) 和 RMSprop (Root Mean Square Propagation)。分别使用三种优化器训练模型，其他参数保持一致，评估指标为验证集上的 R^2 拟合度。图 3 为三种优化器的预测结果，预测模型选择 SGD 权重优化器时模型效果最好，略高于 Adam 优化器。虽然 Adam 在某些情况下收敛速度更快，但在本研究中，SGD 的泛化能力更强。因此，本文预测模型权重优化器选择为 SGD。

4.3. 学习率

本文从学习率 0.001 出发，在区间[0.03~0.0005]中选取候选参数，遍历所有候选值，每次训练使用相同的训练集和验证集，评估指标为验证集上的 R^2 拟合度。如图 4 所示，纵向裂缝长度预测模型设置学习率为 0.008 时效果最佳。学习率过大可能导致模型震荡，无法收敛；学习率过小可能导致收敛速度过慢。0.008 在当前数据集上取得了最佳的平衡。




Figure 2. Influence of the number of neurons on the model
图 2. 神经元个数对模型的影响




Figure 3. Impact of weight optimizers on models
图 3. 权重优化器对于模型的影响




Figure 4. Impact of learning rate on model performance
图 4. 学习率对模型效果的影响




Figure 5. Influence of activation functions on models
图 5. 激活函数对模型的影响

4.4. 激活函数

本文对 logistic、tanh、relu 三种激活函数进行对比, 分别使用三种激活函数训练模型, 其他参数保持一致, 评估指标为验证集上的 R^2 拟合度。模型效果如图 5 所示, 预测模型中选择 logistic 激活函数的效果比其他两种激活函数更好, tanh 相较 relu 的效果略好。Logistic 激活函数更适合本研究的数据分布和模型结构。

4.5. 训练次数

本研究在[200, 20000]区间内调整训练次数, 遍历所有候选值, 每次训练使用相同的训练集和验证集, 评估指标为验证集上的 R^2 拟合度。模型在训练次数为 5000 次以下时, 模型的效果随着训练次数的增加提升较大, 而在 5000 次的基础上增加训练次数, 模型效果提升的幅度非常小, 但是大量增加了训练时间, 因此, 本文最大训练次数设置为 5000 次。

综上所述, 本文的参数最终选择一个中间层, 中间层神经元为 90 个, 中间层激活函数为 logistic, 权重优化方法为随机梯度下降法, 学习率为 0.008, 模型训练 5000 次。

5. 模型训练与预测

使用 80% 的样本数据作为训练数据, 剩余 20% 作为测试集, 模型训练 5000 次, 采用决定系数 R^2 、平均绝对误差 MAE 和均方根误差 RMSE 判断模型的预测效果。三项指标的计算如公式(1)~(3)所示。

$$R^2 = \frac{\sum (x - y)^2}{\sum (x - \bar{x})^2} \quad (1)$$

$$MAE = \frac{1}{n} \sum |(x - y)| \quad (2)$$

$$RMSE = \sqrt{\frac{\sum (x - y)^2}{n}} \quad (3)$$




Figure 6. Prediction effect of the longitudinal crack quantity

图 6. 纵向裂缝数量测试集预测效果




Figure 7. Prediction effect of longitudinal crack quantity sample set
图 7. 纵向裂缝数量样本集预测效果

纵向裂缝数量预测模型在测试集和所有数据集上的效果如图 6 和图 7 所示，预测值与真实值形成的散点基本在 $x=y$ 附近，在测试集上，预测结果与检测值之间的 R^2 为 0.562，在所有数据集上，模型预测结果与检测值之间的 R^2 为 0.804，平均绝对误差为 32.18，均方根误差为 49.38，此模型对于沥青路面纵向裂缝长度的预测较为准确。

6. 模型优化

虽然使用包含大量影响因素的数据集能够得到较好的预测模型，但同时会使得模型的适用性较低。因此，本节使用随机森林模型得到特征的重要度排序，删减重要度的特征之后对模型进行重新训练，得到优化模型，模型优化的流程如图 8 所示。




Figure 8. Model feature selection process
图 8. 模型特征选择流程

建立由 200 棵子决策树组成的随机森林模型，每棵树的最大深度为 10，允许每个子决策树使用特征的最大数量参数设置为 1，其他参数使用模型默认值。得到的随机森林重要度特征如图 9 所示。




Figure 9. Importance ranking of random forest feature

图 9. 随机森林特征重要度排序

可以发现,服役时间、环境因素(降雨、极端温度)、面层厚度对纵向裂缝发展的影响最大。与工程经验高度吻合:

服役时间直接反映路面累积损伤。沥青混合料在长期荷载和环境循环下发生疲劳老化,胶结料逐渐脆化,导致裂缝扩展速率加快。降雨和极端温度方面,水分渗透会软化基层和土基,降低结构整体刚度,加速反射裂缝形成;高温导致沥青软化,低温引发收缩应力,温差循环诱发疲劳开裂。

而不同的特征之间也存在相互作用,如交通荷载与气候条件的耦合效应,在降雨频繁地区,水分通过裂缝或孔隙渗入基层,软化半刚性基层材料(如水泥稳定碎石),降低其承载能力。此时,交通荷载的反复作用会加剧基层疲劳损伤,导致反射裂缝加速向上延伸至面层。例如,美国 LTPP 数据显示,年降雨量超过 1000 mm 的地区,高交通量路段($>1 \times 10^6$ ESALs/年)的纵向裂缝扩展速率比干燥地区高 30%~50%;低温下面层模量升高至 8000 MPa 以上,材料脆性增强,收缩应力超过沥青胶结料的抗拉强度时,易引发温缩裂缝。若此时交通荷载施加拉-压循环应力,裂缝尖端易发生疲劳断裂。

沥青含量与服役时间也存在相互作用,高沥青含量($>5\%$)初期可增强混合料柔韧性,延缓裂缝萌生;但随着服役时间延长,沥青氧化硬化导致黏弹性丧失,混合料抗疲劳性能下降。例如,美国 SHRP 计划研究发现,沥青含量从 4.5% 提升至 5.5% 可使裂缝萌生时间延迟 3 年,但 20 年后裂缝扩展速率反而提高 20%。

而道路自身方面,面层厚度对纵向裂缝的发展影响较大,根据此分析结果对模型输入特征进行删减和重训练,模型效果的变化情况和优化后的模型效果如图 10 所示。

在减少 5 个低重要度特征之后,如图 11 所示,纵向裂缝长度预测模型预测值与检测值之间的 R^2 为 0.834,平均绝对误差为 8.83,均方根误差为 15.05。模型效果更加良好。而减少 8 个特征的预测模型 R^2 为 0.804,平均绝对误差为 8.83,均方根误差为 15.05,模型的效果良好。




Figure 10. The impact of reducing low-importance features on model performance
图 10. 减少低重要度特征对模型效果的影响




Figure 11. Optimization effect of longitudinal crack length prediction model
图 11. 纵缝长度预测模型优化效果

7. 结语与展望

本文从路面长期性能数据库中选择关键影响因素数据并预处理，建立人工神经网络模型，利用网格搜索研究模型参数影响和确定最佳参数，得到了有效的纵向裂缝预测模型，得出如下结论：

- 1) 从道路结构、路面材料、交通轴载次数及气候方面选取数据，全面考虑纵向裂缝发展的影响因素，是预测模型成功的关键。
- 2) 人工神经网络模型中参数具有不同程度的影响，本文使用网格搜索得到的最佳参数为一个中间层，90 个中间层神经元，激活函数为 *logistic*，权重优化方法是 *sgd*，学习率 0.008，模型训练 5000 次。
- 3) 使用样本训练集数据对模型进行训练，模型在全部数据集上的 R^2 为 0.804，MAE 为 32.18，RMSE 为 49.38，模型对沥青路面纵向裂缝长度的预测效果较好。

4) 模型利用随机森林特征重要度排序结果进行优化, 在减少 5 个低重要度特征之后模型效果最佳, R^2 为 0.834; 在减少 8 个特征后预测模型的 R^2 为 0.804。

由于不同的裂缝开裂影响因素之间存在相关性, 如文中提到的交通荷载与气候条件的耦合效应以及材料属性与温度环境的动态关系等, 可以考虑在模型中引入更多的评价体系。

如在 ANN 输入层中加入“交通量 $\times$ 降雨量”和“轴载 $\times$ 低温天数”等交互项, 或采用分段建模(如按气候分区调整交通量权重), 来探究交通荷载与气候条件的耦合效应; 采用时变参数模型, 例如将沥青含量与服役时间关联为衰减函数或引入温度-模量耦合的动态输入层, 来分析材料属性与温度环境的动态关系。此外, 还可对比 ANN、XGBoost(内置交互检测)和 LASSO 交互模型的预测效果, 筛选最优交互表达形式。

基金项目

浙江省交通运输研发项目(202303)。

参考文献

- [1] 沈金安. 沥青及沥青混合料路用性能[M]. 北京: 人民交通出版社, 2003.
- [2] 谭忆秋. 沥青及沥青混合料[M]. 哈尔滨: 哈尔滨工业大学出版社, 2000.
- [3] Queiroz, C. (1983) A Mechanistic Analysis of Asphalt Pavement Performance in Brazil. *Journal of Association of Asphalt Paving Technology*, **52**, 474-488.
- [4] Sood, V.K., Sharma, B.M., Kanchan, P.K., *et al.* (1994) Pavement Deterioration Modeling in India. *Proceedings of the Third International Conference on Managing Pavements*, San Antonio, 22-26 May 1994, 47-54.
- [5] Jackson, N.C., Deighton, R. and Huft, D.L. (1996) Development of Pavement Performance Curves for Individual Distress Indexes in South Dakota Based on Expert Opinion. *Transportation Research Record: Journal of the Transportation Research Board*, **1524**, 130-136. <https://doi.org/10.1177/0361198196152400115>
- [6] 潘旺, 严世涛, 李双蓓. 基于灰色理论的沥青路面裂缝预测模型研究[J]. 中外公路, 2020, 40(3): 54-60.
- [7] Lou, Z., Gunaratne, M., Lu, J.J. and Dietrich, B. (2001) Application of Neural Network Model to Forecast Short-Term Pavement Crack Condition: Florida Case Study. *Journal of Infrastructure Systems*, **7**, 166-171. [https://doi.org/10.1061/\(asce\)1076-0342\(2001\)7:4\(166\)](https://doi.org/10.1061/(asce)1076-0342(2001)7:4(166))
- [8] Gong, H., Sun, Y. and Huang, B. (2019) Gradient Boosted Models for Enhancing Fatigue Cracking Prediction in Mechanistic-Empirical Pavement Design Guide. *Journal of Transportation Engineering, Part B: Pavements*, **145**, Article ID: 04019014. <https://doi.org/10.1061/jpeodx.0000121>
- [9] Karlaftis, A.G. and Badr, A. (2015) Predicting Asphalt Pavement Crack Initiation Following Rehabilitation Treatments. *Transportation Research Part C: Emerging Technologies*, **55**, 510-517. <https://doi.org/10.1016/j.trc.2015.03.031>
- [10] 谭冰心. 基于 GRNN 监督学习的混凝土路面开裂破损率预测[J]. 内蒙古煤炭经济, 2021(10): 229-230.
- [11] 柯文豪, 陈华鑫, 雷宇, 张涛. 基于 GRNN 神经网络的沥青路面裂缝预测方法[J]. 深圳大学学报(理工版), 2017, 34(4): 378-384.
- [12] 卓金武. MATLAB 在数学建模中的应用[M]. 北京: 北京航空航天大学出版社, 2014.