

文章编号: 1674-9057(2016)03-0521-05

doi:10.3969/j.issn.1674-9057.2016.03.016

# 基于混合神经网络(GANN)的沥青路面使用性能预测模型

俞竞伟<sup>1,2</sup>, 傅 睿<sup>2</sup>, 李雄威<sup>2</sup>, 王新军<sup>2</sup>

(1. 东南大学 建筑学院, 南京 210096; 2. 常州工学院 土木建筑工程学院, 江苏 常州 213002)

**摘 要:** 针对 GM 模型要求的样本点少、不必有较好的分布规律, 且计算量少、操作简便, 而 BP 神经网络可以反馈校正输出的误差, 具有并行计算、分布式信息存储、强容错力、自适应学习功能等特点, 将 GM (1, 1)模型与 BP 神经网络模型相结合, 建立了混合神经网络预测模型, 并结合实例进行了检验性预测。结果表明: 混合神经网络模型在预测精度方面优于传统灰色模型。该模型的算法概念明确、计算简便, 有较高的拟合和预测精度, 具有良好的应用前景。

**关键词:** 沥青路面; 使用性能; GM 模型; 人工神经网络; 混合神经网络模型

**中图分类号:** U416.217 **文献标志码:** A

路面使用性能预测模型是路面管理系统(PMS)的核心, 同时也是高速公路沥青路面 LCCA 分析方法的重要组成部分<sup>[1]</sup>。近年来, 灰色理论在路面使用性能预测中得到了广泛的应用<sup>[2-4]</sup>。灰色模型具有建模要求样本点少、可以通过离散数据建立微分方程、具有较强适应性的优点, 但其本身缺乏自学习、自组织和自适应能力, 处理信息的能力较弱; 灰色模型建模时, 确定性信息使用很少; 没有解决误差的反馈调整问题且计算复杂; 计算误差较大, 而且不可控等缺点。而神经网络技术<sup>[5-6]</sup>的信息处理能力强, 可以校正输出误差反馈, 具有较强的自学习、自组织和自适应能力, 可以有效弥补灰色模型的缺点。因此, 本文提出一种新的沥青路面性能组合预测方法, 即首先采用 GM 模型方法建模, 然后用人工神经网络中多层节点模型与误差反向传播(BP)算法修正模型残差<sup>[7-9]</sup>。检验结果表明: 混合神经网络(GANN)可以有效提高路面使用性能预测模型的精度<sup>[10-12]</sup>。

## 1 混合神经网络模型建模过程

混合神经网络建模算法的具体步骤如下:

① 设已知原始数据序列为

$$x^0 = \{x^0(1), x^0(2), \cdots, x^0(n)\}。 \quad (1)$$

对式(1)数据处理, 对  $x^0$  进行一次累加生成, 得到 AGO (accumulating generation operator) 的递增数列  $x^1$ :

$$x^1 = \{x^1(1), x^1(2), \cdots, x^1(n)\}, \quad (2)$$

式中:  $x^1(i) = \sum_{m=1}^i x^0(m), i = 1, 2, \cdots, m。$

② 构造数据矩阵  $B$  和数据向量  $y_n$ :

$$B = \begin{bmatrix} -0.5(x^1(1) + x^1(2)) & 1 \\ -0.5(x^1(2) + x^1(3)) & 1 \\ \cdots & \cdots \\ -0.5(x^1(n-1) + x^1(n)) & 1 \end{bmatrix}, \quad (3)$$
$$y_n = [x^0(2), x^0(3), \cdots, x^0(n)]^T。$$

③ 设  $\hat{\alpha} = (\alpha, u)^T$  为参数序列, 对其进行最小二乘估计, 得到:

$$\hat{\alpha} = (B^T B)^{-1} B^T y_n, \tag{4}$$

式中,  $\alpha$ 、 $u$  为待估计参数, 分别称为发展灰数和内生控制灰数。

④ 确定 GM(1, 1) 模型的形式及预测结果。

对一阶生成数据序列  $x^1$ , 建立的预测模型形式为

$$\frac{dx^1}{dt} + ax^1 = u, \tag{5}$$

确定的一阶生成数据序列  $x^1$  和原始数据序列  $x^0$  的预测模型为

$$\hat{x}^1(i+1) = \left(x^0(1) - \frac{u}{\alpha}\right)e^{-\alpha i} + \frac{u}{\alpha}; \tag{6}$$

$$\hat{x}^0(i+1) = \hat{x}^1(i+1) - \hat{x}^1(i), \tag{7}$$

这个  $\hat{x}^0$  数列为原始数列的模拟值, 当  $i \geq n$  时,  $\hat{x}^0$  便是根据原始数列  $x^0$  的预测值。

⑤ 建立残差序列  $\{e^{(0)}(L)\}$  的 BP 网络。

时刻  $L$  的原始数据  $\{x^{(0)}(L)\}$  与 GM(1, 1) 模型模拟值  $\hat{x}^0(L)$  之差, 称为时刻  $L$  的残差, 记为  $e^0(L)$ , 即

$$e^0(L) = x^0(L) - \hat{x}^0(L). \tag{8}$$

设  $e^0(L)$  为残差序列,  $i = 1, 2, 3, \dots, n$ , 若预测的阶数为  $S$ , 即用  $e^0(i-1)$ ,  $e^0(i-2)$ ,  $\dots$ ,  $e^0(i-S)$  的信息来预测  $i$  时刻的值, 将其作为 BP 网络训练的输入样本,  $e^0(i)$  的值作为 BP 网络训练的目标期望值, 采用 3 层(含 1 个隐含层)网络结构。

⑥ 求各层的学习误差  $d_i^k$ 。

对于输出层有  $k = m$ , 有

$$d_i^m = x_i^m(1 - x_i^m)(x_i^m - y_i), \tag{9}$$

对于其他各层, 有

$$d_i^k = x_i^k(1 - x_i^k) \sum_i w_{ik} d_i^{k+1}. \tag{10}$$

⑦ BP 神经网络权值的调整。

BP 算法主要用于 BP 神经网络权值和阈值的学习, 网络的权值由误差反馈进行调节, 通过权值的不断修正使网络的实际输出更接近期望输出。把  $x_i^m$  和期望输出  $e^0(i)$  进行比较, 如果两者不等, 则产生误差信号  $e$ , 接着按下面公式反向传播修改权系数:

$$\Delta w_{ij} = \sum w_{ij} x_j^{k-1}. \tag{11}$$

为了加快收敛速度, 一般考虑上一次的权系数, 并以其作为本次修正的依据之一, 故而有修正

公式:

$$\Delta w_{ij}(t+1) = -\eta d_i^k \cdot x_j^{k-1} + \alpha \Delta w_{ij}(t), \tag{12}$$

式中,  $\eta$  为学习速率, 即步长;  $\alpha$  为权系数修正系数, 一般取 0.7 ~ 0.9 左右。

当求出了各层各个权系数之后, 可按给定指标判别是否满足要求。如果满足要求, 则算法结束; 如果未满足要求, 则重新执行学习过程, 通过多个样本的反复训练, 同时向误差渐渐减小的方向对权系数进行修正, 这样便可得到网络经过自适应学习所确定的神经网络权值系数、阈值等训练值。训练好的 BP 网络模型, 即可用以对残差序列进行有效预测。

⑧ 确定新的预测值。

设对  $\{e^{(0)}(L)\}$  用 BP 神经网络训练出的残差序列为  $\{\hat{e}^{(0)}(L)\}$ , 在此基础上构造新的预测值  $x^{(0)}(i, 1)$ , 即

$$x^{(0)}(i, 1) = x^{(0)}(i) + \hat{e}^{(0)}(1), \tag{13}$$

则  $x^{(0)}(i, 1)$  就是混合神经网络组合模型的预测值。

GM 模型和神经网络模型都可以看作数值化、非数学模型的函数估计器。利用 GM 模型求解, 所需的计算量小, 一般可在少样本情况下达到较高精度的要求; BP 神经网络计算精度高, 且误差可控, 它可以将一组样本的输入输出问题转化为一个非线性优化问题, 利用人工神经网络对 GM(1, 1) 模型进行残差的修正, 可以取得较好的预测效果。所以融合两者特点可实现优势互补。

## 2 实例分析

下面利用某地高速公路某段路面多年路面弯沉、摩擦系数作为算例(表 1)<sup>[13]</sup>, 应用混合神经网络来进行路面性能预测值的比较。

GM 方法已经应用多年, 常规建模方法比较成熟, 此处限于篇幅不再赘述其建模过程, 由前述①~④步可得 1989—1993 年弯沉、摩擦系数模拟值, 如表 2 所示。

对表 2 数据进行残差处理。按前述方法应用多层节点模型与误差反向传播神经网络(BP)算法对残差序列进行训练, 采用 3 层神经网络: 输入层、S 型隐含层、线性输出层, 收敛率为 0.001, 训练次数为 1 000 次。训练过程如图 1、图 2。

表 1 某地高速公路某路段弯沉、摩擦系数实测值  
Table 1 Deflection of an expressway section and the friction coefficient values

年份	1989	1990	1991	1992	1993	1994	1995	1996	1997
弯沉/0.01 mm	27.9	28.5	29.8	31.1	33.7	35.3	36.9	39.0	40.3
摩擦系数	49.0	48.4	46.7	45.3	43.2	41.8	39.9	38.7	37.2

表 2 某地高速公路某路段弯沉、摩擦系数 GM(1,1) 模拟值  
Table 2 Deflection and the friction coefficient simulated values by GM(1,1)

年份	弯沉/0.01 mm			摩擦系数		
	实际值	GM(1,1) 模拟值	残差	实际值	GM(1,1) 模拟值	残差
1989	27.9	27.9	0	49	49	0
1990	28.5	28.27	0.23	48.4	48.48	-0.08
1991	29.8	29.89	-0.09	46.7	46.72	-0.02
1992	31.1	31.57	-0.47	45.3	45.02	0.28
1993	33.7	33.37	0.33	43.2	43.38	-0.18




图 1 弯沉神经网络训练过程

Fig. 1 Map of deflection of neural network training process




图 2 摩擦系数神经网络训练过程

Fig. 2 Map of friction coefficient of neural network training process

得到 1991—1993 年混合神经网络计算模拟值 (GANN), 将其与传统 GM(1,1) 模型得到的结果 (表 3) 进行对比, 其精度如图 3、图 4 所示。

可以看出, 应用混合神经网络方法得到的模拟值精度较传统的 GM(1,1) 方法有了明显的提高。

表 3 某地高速公路某路段弯沉、摩擦系数混合神经网络模拟值  
Table 3 Deflection and the friction coefficient simulated values by GANN

年份	弯沉/0.01 mm			摩擦系数		
	实际值	GM(1,1) 模拟值	GANN 模拟值	实际值	GM(1,1) 模拟值	GANN 模拟值
1991	29.8	29.89	29.81	46.7	46.72	46.72
1992	31.1	31.57	31.41	45.3	45.02	45.25
1993	33.7	33.37	33.39	43.2	43.38	43.37




图 3 弯沉 GANN、GM(1,1) 预测效果对比

Fig. 3 Contrast prediction effect chart of deflection GANN and GM(1,1)




图 4 摩擦系数 GANN、GM(1,1) 预测效果对比

Fig. 4 Contrast prediction effect chart of coefficient of friction GANN and GM(1,1)

应用混合神经网络模型对 1994—1997 年的弯沉、摩擦系数进行预测, 并与文献 [12] 中应用传统的 GM(1,1) 模型得到的值进行对比, 列表如表 4、表 5 所示。

结果表明, 应用混合神经网络模型对未来几年的弯沉、摩擦系数进行预测得到的预测值精度明

表 4 1994—1997 年弯沉预测值对比

Table 4 Comparison of predicted deflection from 1994 to 1997  
0.01 mm

年度	实际值	GM(1,1)模型		混合神经网络模型	
		预测值	相对误差/%	预测值	相对误差/%
1994	35.3	35.28	0.0567	35.38	-0.224
1995	36.9	37.31	-1.111	37.24	-0.925
1996	39	39.43	-1.103	39.23	-0.601
1997	40.3	40.13	0.422	40.15	0.377

表 5 1994—1997 年摩擦系数预测值对比

Table 5 Comparison of predicted coefficient of friction  
from 1994 to 1997

年度	实际值	灰色 GM(1,1)模型		混合神经网络模型	
		预测值	相对误差/%	预测值	相对误差/%
1994	41.8	42.2	-0.957	41.81	-0.024
1995	39.9	40.9	-2.506	39.87	0.075 2
1996	38.7	39.6	-2.326	38.52	0.465 1
1997	37.2	36.1	2.957	36.90	0.806 5

显优于传统的 GM(1,1)模型。

3 结束语

本文将混合神经网络作为预测模型，结合实际对路面性能弯沉、摩擦系数指标进行了模拟与预测，验证了该方法的有效性与可行性。与传统的灰色预测计算方法相比较，混合神经网络模型利用少量原始数据建立 GM 预测模型，然后依据残差序列数据进行神经网络优化和训练，得到新的预测值。这种 GM 预测建模和神经网络技术的融合，可以取长补短，能大幅度提高模型的预测精度。与以前的传统灰色预测方法相比，其更适应目前我国沥青路面结构长期使用性能数据采集较少，同时数据呈非线性、波动性较大的实际特点，能有效地提高沥青路面使用性能的预测效果，可以为路面养护时机选择、养护资金分配提供有力的科学决策支持。此外由于混合神经网络模型是显性灰色组合模型，因此其应用范围更广，有效地拓宽了灰色模型的应用范围。随着我国沥青路面使用性能研究的深入、路面管理信息系统(PMS)的不断完善和神经网络学习样本的不断补

充，本模型的预测精度还将会进一步提高，因此具有良好的工程应用前景。

参考文献：

[1] Yu J W, Huang X M, Liao G Y. Expressway asphalt pavement structure evaluation method frame based on LCCA [C] //Proceedings of International Conference on Transportation Engineering, ICTE2009, ASCE, 2009: 3645 - 3650.

[2] 刘思峰, 蔡华, 杨英杰, 等. 灰色关联分析模型研究进展 [J]. 系统工程理论与实践, 2013, 33 (8): 2041 - 2046.

[3] Xiao X P, Guo H. Optimization method of grey relation analysis based on the minimum sensitivity of attribute weights [M] //Advances in Grey Systems Research. Berlin Heidelberg: Springer-Verlag, 2010: 177 - 189.

[4] 王育红, 党耀国. 基于灰色关联系数和 D-S 证据理论的区间数投资决策方法 [J]. 系统工程理论与实践, 2009, 29 (11): 128 - 134.

[5] 徐黎明, 王清, 陈剑平, 等. 基于 BP 神经网络的泥石流平均流速预测 [J]. 吉林大学学报: 地球科学版, 2013, 43 (1): 186 - 191.

[6] 郭孝玉, 孙玉军, 王轶夫, 等. 基于改进人工神经网络的植物叶面积测定 [J]. 农业机械学报, 2013, 44 (2): 200 - 204.

[7] 王永刚, 李辉. 基于灰色神经网络的民航事故征候预测模型研究 [J]. 中国安全科学学报, 2012, 22 (3): 10 - 15.

[8] 王守相, 张娜. 基于灰色神经网络组合模型的光伏短期出力预测 [J]. 电力系统自动化, 2012, 36 (19): 37 - 41.

[9] 马军杰, 尤建新, 陈震. 基于改进粒子群优化算法的灰色神经网络模型 [J]. 同济大学学报: 自然科学版, 2012, 40 (5): 740 - 743.

[10] Yin H B, Wong S C, Xu J M, et al. Urban traffic flow prediction using a fuzzy-neural approach [J]. Transportation Research Part C: Emerging Technologies, 2002, 10 (2): 85 - 98.

[11] 刘彩红. BP 神经网络学习算法的研究 [D]. 重庆: 重庆师范大学, 2008.

[12] Cheng C S, Hsu Y T, Wu C C. Grey neural network [J]. IEICE Transactions on Fundamentals on Electronics, Communications and Computer Sciences, 1998 (11): 2433 - 2442.

[13] 胡国祥, 李杰, 闵小双. 路面使用性能灰色预测及编程实现 [J]. 华东公路, 2009 (5): 89 - 91.

# Asphalt pavement performance prediction model based on hybrid artificial neural network

YU Jing-wei<sup>1,2</sup>, FU Rui<sup>2</sup>, LI Xiong-wei<sup>2</sup>, WANG Xin-jun<sup>2</sup>

(1. College of Architecture, Southeast University, Nanjing 210096, China; 2. College of Civil Engineering and Architecture, Changzhou Institute of Technology, Changzhou 213002, China)

**Abstract:** The GM model has many advantages, with less calculation and easy operation. It needs neither larger sample points nor better regulate distribution. While the BP neural network can feedback the corrected output errors, it has the characteristics, such as parallel computation, distributed information storage, strong fault tolerance capability and learning adaptivity, et al. Thus a hybrid neural network prediction model is established, with the advantages from both GM (1, 1) model and BP neural network model. It has been applied in test predictions with examples. The results showed that hybrid neural network model in forecast accuracy is better than the traditional gray model. The model algorithm with advantages of clear concept, simple calculation, a higher fitting and prediction accuracy, has good prospect of application.

**Key words:** asphalt pavement; performance; GM model; artificial neural network; hybrid artificial neural network model