

基于遗传算法-BP神经网络的动车组 列车轮对磨耗模型^{*}

高明亮¹ 邵俊捷¹ 常振臣¹ 王连富¹ 刘德权¹ 牛振虎² 陈之恒²

(1. 中车长春轨道客车股份有限公司检修研发部, 130062, 长春;

2. 西南交通大学牵引动力国家重点实验室, 610031, 成都//第一作者, 高级工程师)

摘要 鉴于动车组运行过程中轮径磨耗及轮缘厚度磨耗对于列车的平稳、安全运行的重要影响,利用相关性算法确定了轮对磨耗的影响因素,并在传统BP神经网络的基础上采用GA(遗传)算法对其初始权重和阈值进行了优化,构建出GA-BP神经网络模型。输入某动车组列车的历史数据,对该模型进行训练,轮径磨耗预测准确率达到95.29%,平均误差为0.212 mm;轮缘厚度磨耗预测准确率达到91.76%,平均误差为0.052 mm。证实了此模型在轮对磨耗预测方面的可用性。

关键词 动车组; 列车; 轮对磨耗; 遗传算法; BP神经网络

中图分类号 U270.331^{+.1}

DOI:10.16037/j.1007-869x.2022.06.013

EMU Train Wheelset Abrasion Model Based on Genetic Algorithm-BP Neural Network

GAO Mingliang, SHAO Junjie, CHANG Zhenchen, WANG Lianfu, LIU Dequan, NIU Zhenhu, CHEN Zhiheng

Abstract In view of the important influence of wheel abrasion and wheel rim thickness abrasion on smooth and safe operation of the train, wheelset abrasion influencing factors are determined by using correlation algorithm. By adopting GA (genetic algorithm) on the basis of the conventional BP neural network, the initial weights and thresholds of the factors are optimized, establishing the GA-BP neural network model. By imputing historical data of certain EMU train and training the model, wheel diameter abrasion prediction accuracy has reached 95.29%, and the average error is 0.212 mm; wheel rim thickness abrasion prediction accuracy has reached 91.76%, and the average error is 0.052 mm. Applicability of the model in the aspect of wheelset abrasion prediction is

proved.

Key words EMU; train; wheelset abrasion; genetic algorithm; BP neural network

First-author's address Overhaul R & D Department, CRRC Changchun Railway Vehicles Co., Ltd., 130062, Changchun, China

轮对是动车组走行部的核心部件之一。准确预测轮对的磨耗,可以提前安排镟修计划,并做出精准镟修决策,从而延长轮对的使用寿命,保证列车的运行安全。因此,建立一个精准、高效的轮对磨耗预测模型很有必要。本文构建了相关性算法-GA算法(遗传算法)-BP神经网络预测模型,对轮对磨耗的历史数据进行了相关性分析。提取影响轮对磨耗的两个主要参数:轮径磨耗,轮缘厚度磨耗,并将其作为BP神经网络的输入参数。同时采用GA算法优化BP神经网络,对轮径磨耗、轮缘厚度磨耗两个参数进行拟合。

1 基于相关性算法的轮对磨耗影响因素分析

动车组轮对从运行开始,磨耗便伴随其整个服役周期直至报废。由于不同条件下轮对磨耗速率有很大差别,故确定轮对磨耗的影响参数是准确预测轮对磨耗的前提。针对各参数间关联形式的不确定性,结合线性、非线性相关算法计算相关系数,并提取相关性强的影响参数,得到训练模型的样本集。

Pearson 系数 r_p 的计算公式如下:

^{*} 国家重点研发计划项目(2016YFB1200401-102A);中国铁路总公司重大课题(K2018J2018);中车长春轨道客车股份有限公司委托科技项目(19JXB006);神华铁路货车运输有限责任公司委托科技项目(SHGF-17-54)

$$r_p = \frac{\sum_{i=1}^n (y_i - \bar{y})(b_i - \bar{b})}{\sqrt{\sum_{i=1}^n (y_i - \bar{y})^2 \sum_{i=1}^n (b_i - \bar{b})^2}} \quad (1)$$

式中：

y_i, b_i ——分别为两个相关参数的实际数值；
 \bar{y}, \bar{b} ——分别为两个相关参数的样本均值；
 n ——样本数量。
 r_p 的取值范围为 $[-1, 1]$ 。若 $|r_p|$ 越靠近 1，表明轮对磨耗与该检测参数的线性相关性越高。

Spearman 算法是一种非线性相关系数的计算方法。Spearman 系数 r_s 的计算公式如下：

$$r_s = \frac{\sum_{i=1}^n (m_i - \bar{m})(s_i - \bar{s})}{\sqrt{\sum_{i=1}^n (m_i - \bar{m})^2 (s_i - \bar{s})^2}} \quad (2)$$

式中：

m_i, s_i ——分别为两个相关参数的实际数值；
 \bar{m}, \bar{s} ——分别为两个相关参数的样本均值。

根据两种算法计算出 r_p, r_s ，并分别给予其对应的权重 p, q 。本次 p 取 0.6, q 取 0.4。则：

$$r_{ab} = pr_p + qr_s \quad (3)$$

式中：

r_{ab} ——总相关系数。
以某路局某型动车组列车为例，整理出近 500 条轮对磨耗数据。选取车厢号、轴号、间隔天数、轮径值、轮缘厚度、轮径差、轮缘厚度差等影响因素做相关性分析。根据式(1)—式(3)，计算相关系数，见表 1。

表 1 某型动车组列车轮对磨耗相关性分析结果
Tab.1 Correlation analysis results of wheelset wear of a certain type of EMU train


影响因素	不同影响因素下轮对磨耗参数的 r_{ab}	
	轮径磨耗	轮缘厚度磨耗
车厢号	-0.086	0.025
轴号	-0.057	-0.025
轮径值	-0.056	0.370
轮缘厚度	0.029	0.534
间隔天数	0.642	0.169
同轴轮径差	-0.101	-0.275
同轴轮缘厚度差	-0.059	-0.021

由表 1 可见，对轮对磨耗的影响由大到小依次

是：间隔天数、轮缘厚度、轮径值、同轴轮径差、车厢号、轴号、同轴轮缘厚度差。其中，间隔天数对轮径磨耗、轮缘厚度磨耗的影响最大，此处的间隔天数可近似当作“里程”。偏相关系数反映了两个变量间的净相关程度，在控制了轮径值、轮缘厚度的线性影响后，轮缘厚差与轮缘厚磨耗之间的偏相关系数为 -0.14，有较大相关性。结合车厢号、轴号的特殊性，选取间隔天数、轮径值、轮缘厚度、轮径差、轮缘厚度差 5 个因素作为 BP 神经网络的输入参数。

2 BP 神经网络模型结构的确定

如图 1 所示，BP 神经网络模型结构由 3 层构成，即 1 个输入层、1 个隐含层和 1 个输出层， n, m, o 分别为输入层、隐含层和输出层的层数。其中，输入层和输出层不变，隐含层的层数可以根据模型要求而调整。设输入 $X = [X_1, X_2, \dots, X_n]$ ，输出 $Y = [Y_1, Y_1, \dots, Y_1]$ ，隐含层个数为 m 。



注： W_{ij} 为输入层与隐含层之间的连接权值； W_{jk} 为隐含层层与输出层之间的连接权值； H_m 为第 m 个隐含层的输出值； m 为隐含层的节点个数。

图 1 BP 神经网络模型结构

Fig.1 Structure of BP neural network model

该模型的训练原理如下：随机设置连接权值 W ，以及隐含层、输出层的阈值 γ_j, θ_k ，然后进行隐含层的输出计算。计算公式为：

$$H_j = f(\alpha_j - \gamma_j) \quad (4)$$

其中：

$$\alpha_j = \sum_{i=1}^n W_{i,j} X_i, j = 1, 2, \dots, m \quad (5)$$

式中：

H_j ——第 j 个隐含层的输出值；
 γ_j ——第 j 个隐含层的阈值；
 f ——隐含层激励函数；
 α_j ——第 j 个隐含层的输入。
输出层输出 Y_k 的计算公式为：

$$Y_k = g(\beta_k - \Theta_k) \quad (6)$$

其中:

$$\beta_k = \sum_{j=1}^i H_j W_{j,k}, k = 1, 2, \dots, l \quad (7)$$

式中:

g ——输出层激励函数;

Θ_k ——第 k 个输出层的阈值;

β_k ——第 k 个输出层的输入;

l ——输出层的节点个数。

由网络预测输出 Y 和期望输出 O , 计算均方误差 E_k :

$$E_k = \frac{1}{2} \sum_{k=1}^m (O_k - Y_k)^2 \quad (8)$$

任意参数 ν_i 的更新估计式为:

$$\nu_{i+1} = \nu_i + \Delta \nu_i \quad (9)$$

BP 神经网络算法基于梯度下降策略,以目标的负梯度方向对权值和阈值进行调整。根据计算出的均方误差 E_k , 设定学习速率 η 。 $W_{j,k}$ 的调整方法为:

$$W_{j,k} = -\eta \frac{\partial E_k}{\partial W_{j,k}} \quad (10)$$

$$\frac{\partial E_k}{\partial W_{j,k}} = \frac{\partial E_k}{\partial Y_k} \frac{\partial Y_k}{\partial \beta_k} \frac{\partial \beta_k}{\partial W_{j,k}} \quad (11)$$

同理可得:

$$W_{i,j} = -\eta \frac{\partial E_k}{\partial W_{i,j}} \quad (12)$$

$$\frac{\partial E_k}{\partial W_{i,j}} = \frac{\partial E_k}{\partial H_j} \frac{\partial H_j}{\partial \alpha_j} \frac{\partial \alpha_j}{\partial W_{i,j}} \quad (13)$$

输出层阈值的更新方法为:

$$\Delta \theta_k = -\eta \frac{\partial E_k}{\partial Y_k} \frac{\partial Y_k}{\partial \beta_k} \quad (14)$$

$$\Delta \gamma_j = -\eta \frac{\partial E_k}{\partial H_j} \frac{\partial H_j}{\partial \alpha_j} \quad (15)$$

根据上述算法对权值、阈值进行迭代调整。若迭代算法结束,则输出相关结果;若迭代算法未结束,则返回重复该训练过程。

3 BP 神经网络优化步骤

采用遗传算法来优化 BP 神经网络,即采用遗传算法优化 BP 神经网络的初始权值和阈值。实现步骤如下:

1) 整理数据。对数据进行预处理,并确定 BP 神经网络的输入、输出变量。

2) 确定 BP 神经网络的基本模型。确定 BP 神

经网络的各层层数,并初始化其权值和阈值。

3) 初始化种群和构建适应度函数。确定各权值和阈值的个数,给每个个体进行编码。适应度函数的计算公式如式(14):

$$F = \left[\sum_{i=1}^n |O_i - Y_i| \right] / n \quad (16)$$

式中:

n ——预测数据量;

O_i ——输出参数实际值;

Y_i ——输出参数预测值;

F ——个体适应度。

根据式(16)计算出初始种群每个个体的适应度值。

4) 种群的选择、交叉与变异。随机选择个体的概率与其适应度函数值成反比,遗传算法选择轮盘赌法;交叉是为了将上一代优秀基因组合遗传至下一代,随机选取两个个体的 1 个基因位置作为交叉位置,组成新的优秀个体:

$$\begin{cases} A_{j_0} = A_{j_0}(1 - e) + B_{j_0}e \\ B_{j_0} = B_{j_0}(1 - e) + A_{j_0}e \end{cases} \quad (17)$$

式中:

A_{j_0} 、 B_{j_0} ——两个个体;

j_0 ——基因位置;

e —— $[0, 1]$ 内的随机数。

则变异参数 $f(g_0)$ 为:

$$f(g_0) = [r(1 - g_0/G)]^2 \quad (18)$$

若 $p > 0.5$, 则第 i 个个体 j_0 位置的基因数值 $a_{i,j,n+1}$ 为:

$$a_{i,j,n+1} = a_{i,j,n} + (a_{i,j,n} - a_{\max})f(g_0) \quad (19)$$

若 $p < 0.5$, 则:

$$a_{i,j,n+1} = a_{i,j,n} + (a_{\min} - a_{i,j,n})f(g_0) \quad (20)$$

式中:

r ——随机数;

g_0 ——已进化代数;

G ——总进化代数;

a_{\max} ——基因上界;

a_{\min} ——基因下界。

5) 完成参数优化。当遗传算法迭代次数且预测结果满足期望误差值时,输出最优个体。

6) 构建 BP 神经网络。将通过遗传算法优化后的初始权重和阈值分配给 BP 神经网络,进行训练和预测。

4 GA-BP 神经网络模型训练及结果分析

以某路局某型动车组列车为例,共得到 485 条试验数据,将前 400 条数据用于训练,剩余 85 条数据用于检测。设置 GA-BP 神经网络的结构为 5-12-2,即 5 个输入层、12 个隐含层、2 个输出层。其中,输入层中的 5 个参数分别为间隔天数、轮径值、轮缘厚度、轮径差、轮缘厚度差,输出层的 2 个参数分别为轮径磨损、轮缘厚度磨损。模型共有 84 个权值、14 个阈值。GA-BP 神经网络隐含层激励函数选用 tansig,输出层激励函数选用 purelin,训练函数选用 traingd(梯度下降法),学习率为 0.01,最小目标值误差为 0.1。种群数目为 20,进化代数数为 30,交叉概率为 0.2,变异概率为 0.1。要求轮径值磨损预测误差在 0.5 mm 之内,轮缘厚度磨损误差在 0.1 mm 之内。

对 GA-BP 神经网络进行训练、预测。由图 2 可见,大部分轮径值磨损预测误差小于 0.5 mm,大部分轮缘厚度磨损预测误差小于 0.1 mm,基本满足了精度要求;轮径磨损预测误差稍大于轮缘厚度磨损预测误差。




图2 轮径磨损和轮缘厚度磨损预测误差直方图

Fig.2 Histogram of prediction error of wheel diameter abrasion and rim thickness abrasion

图 3 为 GA-BP 神经网络预测模型中遗传算法迭代 30 次的适应度变化图。由图 3 可见,随着遗传算法的优化,该模型的误差显著降低;在进行 17 次迭代时,适应度降低至最小值,此时的 BP 神经网络参数即为模型的最优参数。




图3 GA-BP 神经网络预测模型适应度随进化代数变化曲线

Fig.3 Algebraic variation curve of fitness of GA-BP neural network prediction model with evolution

为验证遗传算法对 BP 神经网络的优化作用,选取 BP 神经网络模型的预测结果与其作比较。根据预测的准确率和平均误差来评估预测效果。对于预测数据,当其误差满足精度要求时,认为此预测数据是准确的(即轮径磨损预测误差在 0.5 mm 之内,轮缘厚度磨损误差在 0.1 mm 之内);反之,当误差不能满足精度要求时,认为其预测是不准确的。具体结果见表 2。

表 2 不同神经网络下的轮对参数预测结果			
Tab.2 Prediction results of wheelset parameters under different neural networks			
轮对参数	预测模型	准确率/%	平均误差
轮径磨损	GA-BP 神经网络	95.29	0.212
	传统 BP 神经网络	82.73	0.369
轮缘厚度磨损	GA-BP 神经网络	91.76	0.052
	传统 BP 神经网络	76.88	0.126

由表 3 可见,在采用遗传算法对 BP 神经网络进行优化前,BP 神经网络的轮径值、轮缘厚度预测准确率分别为 82.73%、76.88%,轮缘厚度预测的准确率偏低。经优化,轮径磨损预测的准确率提高到了 95.29%(提升了 12.56%);轮缘厚度磨损预测准确率提升幅度更大,达到了 91.76%;预测平均误差亦有明显提高。

由此可见,将遗传算法引入 BP 神经网络有明

显的优化作用。通过对比轮对磨耗模型中的轮径值和轮缘厚度可以发现,无论是传统 BP 神经网络模型还是优化后的 GA-BP 神经网络模型,其轮径磨耗预测的准确性总是高于轮缘厚度磨耗。这一方面是由于模型对轮缘厚度磨耗预测误差的要求更高;另一方面是由于影响轮缘厚度磨耗的因素很多,导致轮缘厚度磨耗预测的不确定性较大。

5 结语

为对动车组列车运行中的轮对磨耗做出更好的预测,本文利用相关性算法分析确定了轮对磨耗的影响因素;引入 BP 神经网络算法,并应用 GA 算法优化 BP 神经网络的初始权值和阈值,从而构造出 GA-BP 神经网络模型。利用历史数据对模型进行训练,最终训练好的模型在对轮对轮径磨耗、轮缘厚度磨耗的预测中展现了较好的预测能力,满足了精度需求,证明了 GA-BP 神经网络模型用于轮对磨耗的预测是可行的。

参考文献

- [1] 徐宗川. 基于 GA-BP 神经网络的交叉口短时交通流预测研究[J]. 科技风, 2020(11): 127.
XU Zongchuan. Research on short-term traffic flow prediction at intersections based on GA-BP neural network[J]. Technology Wind, 2020(11): 127.
- [2] 黄富程, 刘德新, 辛博鹏, 等. 基于遗传算法(GA)优化 BP 神经网络的船舶交通流量预测[J]. 广州航海学院学报, 2020(1): 10.
HUANG Fucheng, LIU Dexin, XIN Bopeng, et al. Prediction of ship traffic flow based on BP neural network optimized by genetic algorithm[J]. Journal of Guangzhou Maritime College, 2020(1): 10.

(上接第 64 页)

- GAO Wenming, LI Zhibao, TANG Qian, et al. Railway vehicle door remote monitoring and fault diagnosis system software design[J]. Machine Design and Manufacturing Engineering, 2016(10): 49.
- [7] 路军, 王梓耀, 余涛. 基于朴素贝叶斯和 D-S 证据理论的多时空数据融合[J]. 电气技术, 2019(11): 27.
LU Jun, WANG Ziyao, YU Tao. Multi-time-space data fusion based on naive Bayes and D-S evidence theory[J]. Electrical

- [3] 邱作成, 马强, 刘杰. 某型城市轨道交通车辆停于分相区时的弓网干扰影响因素分析[J]. 城市轨道交通研究, 2021(3): 116.
QIU Zuo Cheng, MA Qiang, LIU Jie. Influencing factor analysis of urban rail vehicle pantograph catenary interference in the neutral zone[J]. Urban Mass Transit, 2021(3): 116.
- [4] 张伟, 解凯, 张长开, 等. 基于综合监控的城市轨道交通全线能源管理系统研究[J]. 城市轨道交通研究, 2021(3): 120.
ZHANG Wei, XIE Kai, ZHANG Changkai, et al. Urban rail transit energy management system based on integrated supervisory and control system[J]. Urban Mass Transit, 2021(3): 120.
- [5] 姜朝勇, 蒋咏志, 宋庆伟, 等. 浮置板轨道结构对地铁车辆轨道耦合系统动力性能影响分析[J]. 城市轨道交通研究, 2021(3): 163.
JIANG Chaoyong, JIANG Yongzhi, SONG Qingwei, et al. Influence analysis of floating slab track structure on dynamic performance of metro vehicle-track coupling system[J]. Urban Mass Transit, 2021(3): 163.
- [6] 罗慧, 梁笛. 基于智慧地铁视角的广州地铁 AFC 系统架构设计[J]. 城市轨道交通研究, 2021(3): 179.
LUO Hui, LIANG Di. Design of AFC system architecture Guangzhou Metro from the perspective of smart metro[J]. Urban Mass Transit, 2021(3): 179.
- [7] 吴健, 叶正君, 邢宗义. 城市轨道交通列车轮对磨耗模型研究[J]. 铁路计算机应用, 2020(2): 62.
WU Jian, YE Zhengjun, XING Zongyi. Research on wheel set wear model of urban rail transit train[J]. Railway Computer Application, 2020(2): 62.
- [8] 冯俊杰. 考虑多种影响因素的配电网供电可靠性研究[D]. 广州: 华南理工大学, 2019.
FENG Junjie. Study on power supply reliability of distribution network considering various influencing factors[D]. Guangzhou: South China University of Technology, 2019.

(收稿日期: 2021-03-28)

Engineering, 2019(11): 27.

- [8] 张刚, 田福庆, 梁伟阁, 等. 基于改进 D-S 证据理论的滚动轴承故障诊断[J]. 海军工程大学学报, 2019(4): 42.
ZHANG Gang, TIAN Fuqing, LIANG Weige, et al. Fault diagnosis of rolling element bearings based on improved D-S evidence theory[J]. Journal of Naval Engineering University, 2019(4): 42.

(收稿日期: 2020-03-19)

欢迎投稿《城市轨道交通研究》

投稿网址: tougao. umt1998. com