

试
验
检
测神经网络在机车测速传感器
故障诊断中的应用谢 彬¹, 李国宁¹, 冯 涛¹, 李 博²(1. 兰州交通大学 自动化与电气工程学院, 甘肃 兰州 730070 ;
2. 北京铁路信号有限公司, 北京 102613)

摘 要: 提出了采用径向基(RBF)神经网络设计一种新型的机车测速传感器故障诊断方法。以光电式测速传感器的常见故障为模型建立RBF神经网络预测器,通过对预测器进行在线训练和实时检测来判断测速传感器是否发生故障,并对故障传感器提出决策方法和进行数据重构。仿真结果表明,该方法能够高精度地模拟传感器的输出特性,快速有效地进行测速传感器的故障诊断。

关键词: 测速传感器; RBF神经网络; 故障诊断; 预测器

中图分类号: U269.32²; TP212 **文献标识码:** A **文章编号:** 1000-128X(2012)06-0084-04

作者简介: 谢 彬(1987-),男,硕士研究生,主要研究方向为交通信息工程及控制。

Application of RBF Neural Network to Locomotive Speed Sensor Fault Diagnosis

XIE Bin¹, LI Guo-ning¹, FENG Tao¹, LI Bo²

(1. School of Automation & Electrical Engineering, Lanzhou Jiaotong University, Lanzhou, Gansu 730070, China;

2. Beijing Railway Signal Co., Ltd., Beijing 102613, China)

Abstract: An locomotive speed sensor fault diagnosis method based on Radial Basis Function (RBF) neural network was presented. RBF neural network predictor was built by taking common faults of photoelectric speed sensor as model. Through on-line training and real-time diagnosis, it was determined whether sensor was faulted, and then diagnostic decision methods were put forward and fault date of sensor was reconstructed. The simulation results show that dynamic characteristics of sensor are accurately simulated, which can rapidly and effectively realize speed sensor fault diagnosis.

Key words: speed sensor; RBF neural network; fault diagnosis; predictor

0 引言

机车测速传感器是通过测量机车车辆的主轮轴转速来实现列车控制功能的基础设备之一,其性能指标直接影响机车运行监控装置的正常功能,是整个控制系统的关键^[1]。但由于其工作环境复杂、恶劣,在列车控制系统中,测速传感器较薄弱,是机车车载设备故障的主要根源。目前,人工检测和定期维修校准是诊断测速传感器故障的最基本的方法,但其工作效率低、工作强度大、实时性差,已不能满足现代铁路系统的发展要求。

近年来,为了提高对典型的复杂、多目标、大滞后、非线性系统的故障诊断能力,同时提高故障诊断效率及降低误报率,采用现代故障诊断技术已成为目

前故障诊断领域的研究热点^[2]。BP(Back Propagation, 简称BP)神经网络是故障诊断中研究最广泛的一种,它采用多层感知器,并采用反向传播算法进行网络训练。但由于BP算法涉及到非线性优化问题,同时调节权值采用的负梯度下降法存在局部极小点、收敛速度慢等,因而它就很难应用于实际系统当中^[3-4]。RBF(Radial Basis Function, 简称RBF)神经网络克服了BP神经网络的缺陷,相比BP神经网络,RBF神经网络具有更容易逼近函数的局部、训练时间短、更适合在线诊断等优点^[5]。本文以光电式脉冲测速传感器系统为基础,在分析常见故障模式及故障特征的基础上,提出采用RBF神经网络的预测方法,建立测速传感器的故障诊断模型,实现对传感器系统的故障诊断和数据重构。

1 神经网络的故障诊断方法

人工神经网络是由大量神经元以某种拓扑方式相

互连接而成的, 利用网络拓扑结构和权值分布实现非线性的映射, 通过全局并行处理实现从输入空间到输出空间的信息变换, 由于能够高精度地模拟人脑神经网络的实现过程, 因此在故障诊断领域中得到广泛的应用。

1.1 RBF神经网络结构

RBF神经网络是一种前馈型网络, 一般为3层结构, 其结构如图1所示。该网络有 n 个输入、 h 个隐节点、 m 个输出。其中 $X=(x_1, x_2, \dots, x_n)^T \in R^n$ 为网络输入矢量, $W \in R^{h \times m}$ 为输出权值矩阵, $b_0, b_1, \dots, b_m$ 为输出单元偏移, $Y=(y_1, y_2, \dots, y_m)^T$ 为输出向量, $\Phi_i(*)$ 为第 i 个隐节点的激活函数, Σ 表示输出层的线性激活函数, $\|*\|$ 则表示欧式范数。




图1 RBF神经网络结构

径向基函数 $\Phi_i(*)$ 一般采用Gaussian函数, 表示为

$$\Phi_i(t) = e^{-\frac{t^2}{\sigma_i^2}} \quad (1)$$

式中: σ_i 称为该函数的扩展常数或宽度。

σ_i 越小, 径向基函数的宽度就越小, 其函数越具有选择性。于是, RBF网的输出层的第 k 个输出可表示为

$$Y_k = \sum_{i=1}^h w_i \Phi_i(\|x - c_i\|) \quad (2)$$

式中: w_i 为输出层的调节权值; c_i 为隐层的中心向量, $\|x - c_i\|$ 为向量 $x - c_i$ 的欧几里德范数(即 x 与 c_i 之间的径向距离)。

1.2 RBF神经网络的学习算法

RBF神经网络的学习算法首先要解决以下问题:

结构设计, 即确定网络隐节点数 h ; 确定各径向基函数的数据中心 c_i 及扩展常数 σ_i ; 输出权值 w_i 的修正问题。根据径向基函数中心选取方法的不同, RBF神经网络有多重学习方法, 其中最常用的方法有: 随机选取中心法、自组织选取中心法、有监督选取中心法和正交最小二乘法^[6]。

本文采用 k -means聚类算法确定RBF神经网络的数据中心 c_i 及扩展常数 σ_i 。当得到 c_i 和 σ_i 时, 再采用最小二乘法(LMS)直接计算输出权值 w_i 。假设 k 为迭代次数, 第 k 次迭代时的聚类中心为 $c_1(k), c_2(k), \dots, c_h(k)$, 聚类域为 $w_1(k), w_2(k), \dots, w_h(k)$, 则其算法过程如下:

Step0: 算法初始化, 选择 h 个不同的初始聚类中心, 且每个初始数据中心取不同值, 令 $k=1$;

Step1: 计算所有的样本输入与聚类中心的距离

$\|X_j - c_i\|$, 其中 $j=1, 2, \dots, n$, $i=1, 2, \dots, h$;

Step2: 对样本输入 X_j , 按最小距离原则对其进行分类: 即当 $i(X_j) = \min_i \|X_j - c_i(k)\|$, 且 $i=1, 2, \dots, h$ 时, X_j 即被归为第 i 类, 即 $X_j \in w_i(k)$;

Step3: 重新计算各类的聚类中心, 则

$$c_i(k+1) = \frac{1}{N_i} \sum_{x \in w_i(k)} x, \quad i=1, 2, \dots, h, \quad \text{其中 } N_i \text{ 为第 } i \text{ 个聚类域 } w_i(k) \text{ 中包含的样本数};$$

Step4: 如果 $c_i(k+1) \neq c_i(k)$, 转到Step1, 否则聚类结束, 转Step5;

Step5: 得到的 c_i 即为RBF神经网络的数据中心;

Step6: 根据聚类中心之间的距离确定各隐节点的扩展常数 $\sigma_i = \lambda d_i$, 其中 d_i 为第 i 个数据中心之间的距离, 即 $d_i = \min_{j \neq i} \|c_j - c_i(k)\|$, λ 称重叠系数;

Step7: 得到的 σ_i 即为RBF神经网络的扩展常数;

Step8: 根据隐含层输出矩阵 $\hat{H} = [h_{ij}] \in R^{N \times h}$, 当权值矩阵 $W_i = (w_{i1}, w_{i2}, \dots, w_{im})$ (待定), 则对所有样本的网络输出矢量为 $\hat{y} = \hat{H} \times W$;

Step9: 如果令 $\varepsilon = \|y - \hat{y}\| = \|y - \hat{H} \times W\|$ 为逼近误差, 当确定 $\hat{H}$ 就可以利用最小二乘法求得网络的输出权值 $W_i = \hat{H}^+ \times y$, 其中 $\hat{H}^+$ 为 $\hat{H}$ 的伪逆, 即 $\hat{H}^+ = (\hat{H}^T \hat{H})^{-1} \hat{H}^T$ 。

Step10: 算法结束。

1.3 RBF神经网络的故障诊断建模

国内的电力机车和动车组广泛使用光电式测速传感器, 它采用光电转换原理, 利用安装在轴承盖上的信号发生器输出一定数量的脉冲或方波信号, 通过微处理器对数字脉冲进行信号计数, 从而得到速度信息。由于光电式测速传感器是由分立式电子器件组成, 在机车抗振性能上存在弊端, 工作过程中机械部分容易损坏, 而机车空转、滑行等也会造成传感器故障等不利因素, 严重影响着列车的安全运行。因此, 对测速传感器进行实时在线诊断和数据重构很有必要。

在机车测速系统中, 一个基本测速单元至少包括2个测速传感器同时独立地对列车进行测速。由于测速传感器的工作原理和故障诊断方法相同, 所以只对机车测速系统中的传感器2进行故障诊断建模。假设机车测速系统一开始运行时, 测速传感器处于正常工作状态。此时, 通过采集测速传感器的实际输出值, 在线训练RBF神经网络预测器

2, 以 X 表示预测器输入, Y 表示预测器输出, 建立机车测速传感器的故障诊断模型, 其结构如图2所示。




图2 RBF神经网络预测器2结构

RBF神经网络预测器2采集传感器2的前 k 个输出 $x_2(1) \sim x_2(k)$ 作为输入样本,采集传感器输出的下一时刻的数据 $x_2(k+1)$ 作为网络输出样本,组成第一组训练样本^[7]。然后,数据向前递退一步,再采集 k 个数据 $x_2(2) \sim x_2(k+1)$ 作为预测器输入数据,组成第二组训练样本,样本表示为:

$$X_2 = \begin{bmatrix} x_2(1) & x_2(2) & \cdots & x_2(k) \\ x_2(2) & x_2(3) & \cdots & x_2(k+1) \end{bmatrix}^T, Y_2 = \begin{bmatrix} x_2(k+1) \\ x_2(k+2) \end{bmatrix}^T \quad (3)$$

如式(3)所示,以 X 表示预测器输入, Y 表示预测器输出,对RBF预测器进行在线训练。当网络达到一定精度以后,RBF神经网络预测器开始工作。此时,再以 $x_2(3) \sim x_2(k+2)$ 作为网络新的输入,预测器输出数据为 $\hat{x}(k+3)$,与这一时刻测速传感器的实际输出值 $x_2(k+3)$ 相比较,得到误差 e_1 ,表示为

$$e_1 = |\hat{x}_2(k+3) - x_2(k+3)| \quad (4)$$

这时,有2种情况:

若 e_1 小于系统设定阈值 e^* (e^* 表示预测器的输出与传感器输出的最大绝对误差)时,这一时刻测速传感器2工作正常,并将当前采集的传感器的实际输出值加入到下一组学习样本中,替换预测器2的前一组训练样本,继续对预测器进行训练,此时学习样本为

$$X_3 = \begin{bmatrix} x_2(2) & x_2(3) & \cdots & x_2(k+1) \\ x_2(3) & x_2(4) & \cdots & x_2(k+2) \end{bmatrix}^T, Y_3 = \begin{bmatrix} x_2(k+2) \\ x_2(k+3) \end{bmatrix}^T \quad (5)$$

若 e_1 大于系统设定阈值 e^* 时,这一时刻测速传感器2工作不正常,但是这种不正常可能是由传感器信号的瞬时突变引起的,而非传感器本身的故障。此时,为了避免误诊断,将传感器输出的数据 $x_2(k+3)$ 用预测器输出的数据 $\hat{x}_2(k+3)$ 替换,将其加入到学习样本中,求取下一时间段内的平均误差 $\overline{e_{\Delta t}}$,再与 e^* 相比较。若误差 $\overline{e_{\Delta t}}$ 大于 e^* ,则表明传感器故障;反之则认为传感器本身并没有故障,继续对RBF神经网络进行训练和预测。其中, Δt 表示采样点数,可由系统本身和人工经验来确定其大小。

依次类推,测速传感器的RBF神经网络预测器一边不断在线学习新的样本,一边对传感器的下一时刻输出值作预测。当误差 $e_i > e^*$ (e_i 表示第 i 时刻预测器与传感器输出的绝对误差),测速传感器工作不正常,此时用RBF神经网络预测器的输出值代替传感器的输出值实现数据重构。

2 仿真试验及结果分析

本文以光电式测速传感器为例,在分析常见故障模式及故障特征的基础上,利用MATLAB软件对RBF神经网络故障诊断模型进行仿真^[8]。表2给出光电式测速传感器常见故障类型的分析与比较。

表1 测速传感器故障分析与比较

故障类型	故障特征	故障原因	决策方法
空转	脉冲突增后恢复正常	瞬时突变	校正
滑行	脉冲缺失后恢复正常	瞬时突变	校正
机械故障	脉冲丢失不恢复	传感器故障	更换传感器

以横轴表示数据采样点,纵轴表示电平或工作状态,规定2 000个采样点,对测速传感器输出的正常波形、故障波形、重构波形及故障模式的辨别结果进行仿真,如图3~图6所示。




图3 测速传感器的正常脉冲信号




图4 测速传感器的故障脉冲信号




图5 RBF预测器的故障诊断及数据重构




图6 测速传感器故障类型辨识

图3为光电式测速传感器正常工作时的输出脉冲信号。图4为测速传感器的输出故障脉冲,在采样点1 000时刻为输出脉冲缺失故障,1 400时刻为输出脉冲突增故障,1 800时刻以后为脉冲丢失故障。图5为RBF神经网络预测器对故障波形的诊断结果,此时,系统采用预测器的输出值代替传感器的实际输出以实现数据重构。图6为测速传感器故障类型的辨识结果,以此来判断传感

器故障输出是瞬时突变还是传感器本身故障。

3 结语

本文采用基于径向基(RBF)神经网络来构建机车测速传感器系统的预测模型,比较传感器的实际输出与预测器的输出值,以此来检测测速传感器是否发生故障,并对故障信号进行数据重构和故障类型辨识。通过MATLAB仿真实现诊断功能,仿真结果表明此模型能够高精度地模拟测速传感器的故障模式和实现故障检测,为提高机车测速传感器的自诊断功能和自动化水平具有极其重要的现实意义。

参考文献:

[1] TB/T 2760.3—2010, 机车转速传感器[S]

- [2] 胡昌华,许化龙. 控制系统故障诊断与容错控制的分析和设计[M] 北京:国防工业出版社,2008.
- [3] Gou T H, Nrrre J. Sensor Failure Detection and Recovery by Neural Network[C] IEEE IJCNN,1991: 221-226.
- [4] WANG Yujia, ZHANG Mingjun. Study of model of fuzzy neural networks applied to system condition monitoring[J] Journal of Marine Science and Application, 2002(2): 42-45.
- [5] 韩逸飞,何 琳. RBF神经网络在传感器故障诊断中的应用研究[J] 舰船电子工程,2008,28(9): 16-18.
- [6] 曹正红,沈继红. 基于RBF时间序列预测器的传感器故障诊断方法研究[J] 传感器与微系统,2012(5): 63-65.
- [7] 周桂法,王 坚. 基于神经网络的机车速度传感器故障诊断方法研究[J] 机车电传动,2010(1): 36-38.
- [8] 郭 晶,孙伟娟. 神经网络理论与MATLAB实现[M] 北京:电子工业出版社2005.

(上接第83页)




图 11 轮重减载率的变化曲




图 12 脱轨系数的变化曲线

计算结果与轨道扭曲的设置相关,AS 7509.1标准扭曲测试轨道与BS EN 14363标准计算机仿真的轨道设置内容基本相同,但AS 7509.1标准中扭曲轨道的缓和曲线坡度和沉陷坡度都比BS EN 14363标准计算机仿真的轨道更大,AS 7509.1标准扭曲测试轨道设置更为苛

刻。且标准的适用范围也不一样,AS 7509.1标准适用于各种轴数、类型转向架,BS EN 14363计算机仿真只适用四轴机车车辆。所以,AS 7509.1标准比BS EN 14363标准验证车辆适应轨道扭曲能力计算方法更可靠,适用性更广。

4 结语

轨道扭曲是造成机车车辆脱轨的重要因素,软件仿真计算中AS 7509.1标准比BS EN 14363标准验证车辆适应轨道扭曲能力的计算方法更可靠,适用性更广,但我国尚未对轨道扭曲制定出相应的计算标准,可根据我国铁路的实际情况,参照澳大利亚和欧洲标准制定出符合我国铁路的轨道扭曲评判标准。

参考文献:

- [1] 李洪涛. 货车动力学性能仿真及脱轨原因分析[D] 大连:大连铁道学院,2003.
- [2] 陆冠东,徐荣华. 线路扭曲与脱轨安全性分析方法介绍[J] 铁道车辆,2008,46(7): 1-4.
- [3] AS 7509.1—2009, Railway Rolling Stock-Dynamic Behavior-Part 1: Locomotive Rolling Stock[S]
- [4] BS EN 14363—2005, Railway applications—Testing for the acceptance of running characteristics of railway vehicles—Testing of running behaviour and stationary tests[S]
- [5] 罗 赞,陈 康,罗世辉. 计算机仿真评价机车车辆低速抗爬轨能力[J] 机车电传动,2002(5): 13-15.