

# 基于样条插值与 RBF 网络的道岔故障诊断系统

梅欢<sup>1,2</sup>, 马艳东<sup>1,2</sup>, 单九思<sup>3</sup>, 彭晔<sup>3</sup>

(1. 河北省科学院 应用数学研究所, 河北 石家庄 050081;

2. 河北省信息安全认证工程技术研究中心, 河北 石家庄 050081;

3. 石家庄铁道大学, 河北 石家庄 050043)

**摘要:**随着列车运行速度与行车密度的不断提高,道岔将面临更加严峻的考验,而传统依靠维护人员研读相关监测数据进行故障诊断的手段,越来越不能够适应铁路对运行安全的高要求。为快速、准确诊断出道岔故障,特建立基于三次样条插值与 RBF 神经网络的智能道岔故障诊断模型。利用基于三次样条插值的数据整合模块将不同维数的道岔动作电流数据划归成统一的数据维数。采用新型 RBF 神经网络对其进行故障诊断。利用某火车站道岔动作的真实历史监测数据对所提模型的有效性进行验证。实验结果表明,所提出的模型不仅能够适应不同数据维数的道岔动作曲线数据,而且还可以快速、准确地对道岔故障进行诊断,从而帮助维护人员缩短故障处理时间,提高铁路行车的安全性。

**关键词:**道岔故障诊断;人工智能;RBF 神经网络;三次样条插值;道岔动作电流

中图分类号:TP182

文献标识码:A

文章编号:1673-629X(2017)05-0160-04

doi:10.3969/j.issn.1673-629X.2017.05.033

## Research on Switch Fault Diagnosis System with Cubic Spline Interpolation and RBF Neural Network

MEI Huan<sup>1,2</sup>, MA Yan-dong<sup>1,2</sup>, SHAN Jiu-si<sup>3</sup>, PENG Ye<sup>3</sup>

(1. Institute of Applied Mathematics, Hebei Academy of Sciences, Shijiazhuang 050081, China;

2. Hebei Authentication Technology Engineering Research Center, Shijiazhuang 050081, China;

3. Shijiazhuang Tiedao University, Shijiazhuang 050043, China)

**Abstract:** The train rail switch is facing more demanding request with the increasing speed and traffic density. The traditional fault diagnosis method which relies on maintenance personnel monitoring data cannot meet the higher safety request for the train operation safety. In order to diagnose the faults of the rail switch rapidly and accurately, the new intelligent rail switch fault diagnosis model based on Cubic Spline Interpolation and RBF neural network is established. The data integration module based on Cubic Spline Interpolation has been used to normalize the electric current curves of the rail switch into the same dimension. Then, the new RBF neural network is used to diagnose the new data of the electric current curves of the rail switch with same dimension. The model has been validated and evaluated with the historical and real monitoring data from certain railway station. The experiment results show that this model can not only be used to process the electric current curves of the rail switch action with different dimensions, but also can be used to diagnose rail switch faults rapidly and accurately. With this model, the fault processing time can be significantly decreased and the railway traffic can be safer.

**Key words:** switch fault diagnosis; artificial intelligence; RBF neural network; Cubic Spline Interpolation; electric curves of switch action

## 0 引言

随着列车运行速度与行车密度的不断提高,作为限制火车运行速度的关键设备之一——道岔<sup>[1-5]</sup>将面临更加严峻的考验。如果能够及时发现道岔故障、准确诊断故障类型,不仅可以预防重大事故,避免人员伤亡和财产损失,而且可以减少维修成本,避免维修盲目

性,以获得最大经济效益。目前,国内的道岔故障诊断手段主要是依靠相关业务人员分析微机监测系统现场采集的道岔各组成设备的检测信息,依靠其工作经验、业务水平、精力与责任心。这种传统的发现问题和解决问题的手段越来越不能满足铁路发展的现状。如何采用智能化手段及时、准确地诊断故障是亟待解决的

收稿日期:2016-06-06

修回日期:2016-09-15

网络出版时间:2017-03-07

基金项目:河北省科技计划项目(15210331);河北省科学院科技计划项目(16606)

作者简介:梅欢(1981-),女,助理研究员,CCF 会员,研究方向为数据挖掘。

网络出版地址: <http://kns.cnki.net/kcms/detail/61.1450.TP.20170307.0922.072.html>

问题。

相对于传统BP神经网络,RBF神经网络<sup>[6-7]</sup>不仅具有结构简单、收敛速度快、泛化能力强等特点,还具有优异的函数逼近能力、全局寻优和最佳逼近能力。研究表明,RBF神经网络节点的宽度、中心、权重等参数选取的是否合理将直接影响到RBF神经网络的性能表现。故而在所提出的道岔故障诊断系统中,采用基于AutoEncoder的RBF神经网络对道岔动作电流数据进行建模,以期挖掘学习到蕴含其中的道岔故障信息。

由于受到铁路现场温度、湿度、设备状况、天气状况等因素的影响,从微机监测系统中获取的道岔动作电流数据的维数会在一个较大的范围内波动。如何在尽量保留原始监测数据所包含信息的前提下,使其数据维数调整到固定维数,从而能够输入到智能算法模型中,具有重要的现实意义。为此,采用基于三次样条插值的数据处理方法将不同数据维数的道岔动作电流数据划归成统一的数据维数,以便将其输入到RBF神经网络中进行学习训练。

综上所述,采用三次样条插值与新型RBF神经网络等技术,将不同数据维数的道岔动作电流数据划归成统一的数据维数,采用新型的RBF神经网络对其进行故障诊断,以帮助维护人员快速、准确地对道岔故障进行诊断,减少故障处理时间,提高铁路行车的安全性。

## 1 基于三次样条插值的数据整合方法

受设备自身健康状况的变化、环境因素的干扰以及其他未知因素的影响,从微机监测系统采集的数据维数就有可能发生较大的变化。如道岔动作电流的数据维数就很有可能在200~3 000的范围内变化。不管是利用神经网络、深度学习,还是其他人工智能算法,这些算法模型大都要求输入数据的维数固定不变。否则,会给模型的建立、算法的实现带来很大困难。为此,提供一种方法——不管传入数据的维数是如何变化不稳定,这种算法都能够在尽可能保留原始数据所包含信息的前提下,将不同维数的数据划归到指定的维数。

### 1.1 三次样条插值

设 $f(x)$ 是区间 $[a,b]$ 上的一个连续可微函数,在区间 $[a,b]$ 上给定一组基点:

$$a = x_0 < x_1 < x_2 < \cdots < x_n = b$$

设函数 $S(x)$ 满足条件:

- (1)  $S(x)$ 在每个子区间 $[x_i, x_{i+1}]$  ( $i = 0, 1, \cdots, n - 1$ )上是次数不超过 $m$ 的多项式;
- (2)  $S(x)$ 在区间 $[a, b]$ 上有 $m - 1$ 阶连续导数。

则称 $S(x)$ 是定义在 $[a,b]$ 上的 $m$ 次样条函数<sup>[8]</sup>。 $x_0, x_1, \cdots, x_n$ 称为样条节点,其中 $x_1, x_2, \cdots, x_{n-1}$ 称为内节点。 $x_0, x_n$ 称为边界节点。当 $m = 3$ 时,便成为最常用的三次样条函数。利用三次样条函数作为插值函数的插值方法即为三次样条插值。

### 1.2 基于三次样条插值的数据整合算法

前提条件:已知采集上来的原始数据集 $\mathfrak{R}$ 是 $M \times 1$ 维数据。

现场要求:

将 $\mathfrak{R}$ 从 $M \times 1$ 维调整到 $N \times 1$ 维,其中 $N$ 为指定自然数,且 $N \neq M$ ;

尽可能使划归后的新数据与原数据的方差保持最小;

保留原数据集中的极值、零值。

算法步骤如下:

Step1:令 $Q$ 为某个特定的自然数,将原始数据平均划分为 $Q$ 份。

Step2:令 $Q_i$ 为平均划分后的原始数据的第 $i$ 份数据集。

Step3:在 $Q_i$ 份数据集的基础上,利用三次样条插值算法,生成样条函数 $f_i(x)$ 。

Step4:在样条函数 $f_i(x)$ 上等间距采样 $[N/Q]$ 个,形成数据集 $Q_i^*$ 。如果 $Q$ 不能被 $N$ 整除,那么,令 $(\text{int})[N/Q]$ 为 $N/Q$ 的整数部分, $K$ 为 $N/Q$ 的余数部分,则可以随机选择 $K$ 个数据集。这些选中的数据集上选择 $(\text{int})[N/Q] + 1$ 个数据,其他未被选中的数据集上选择 $(\text{int})[N/Q]$ 个数据。

Step5:查找数据集 $Q_i^*$ 的极值点、零点及其位置信息。

Step6:根据Step5的结果,在数据集 $Q_i^*$ 上,查找 $Q_i$ 的极值点与零点与哪个点的距离最近。并用这些极值点与零点替换这些在 $Q_i^*$ 中的数据,从而形成新的数据集 $QQ_i$ ;

Step7:令 $i$ 遍历 $1, 2, \cdots, Q$ ,分别执行Step3~Step6,得到数据子集 $QQ_1, QQ_2, \cdots, QQ_Q$ 。

Step8:将数据子集 $QQ_1, QQ_2, \cdots, QQ_Q$ ,按次序依次拼接成新的最终数据集 $QQ$ 。

Step9:跳出。

## 2 基于AutoEncoder的RBF神经网络训练方法

RBF神经网络是一种特殊的三层前馈神经网络,其网络结构包括一个输入层、一个隐含层和一个输出层。输入层节点负责将网络与外界实际连接起来,其个数由输入数据的维数决定。隐含层节点由径向基函

数构成,其主要作用是输入空间到隐含层空间之间进行非线性变换,在大多数情况下,隐含层空间有较高的维数。而输出层节点通常是由简单的线性函数构成,其作用主要是为输入层信号作出最终响应。

AutoEncoder 自动编码器是深度学习<sup>[9-14]</sup>领域的重要算法之一,是利用神经网络具有层次结构的特点,假定其输出数据与输入数据相同,即输入数据的类标是其本身。然后,训练调整网络各个参数,得到每一层节点的参数及权重。通常隐含层节点的数目要小于输入层节点的数目。那么,在给定的条件下,隐含层节点的直接输出值可以看做是从输入数据抽取出来的特征。也就是说可以利用隐含层直接输出的数据恢复输入层的数据。这样 AutoEncoder 就是一种尽可能复现输入信号的神经网络。

针对 AutoEncoder 自编码器提取的输入特征能够更好地发现样本间的相关性的优点,算法<sup>[15]</sup>拟利用 AutoEncoder 的训练结果,替代随机初始化 RBF 神经网络的各个参数,然后利用梯度下降法进一步调整更新网络的各个参数。

其算法步骤如下:

Step1:设置算法终止条件:

- (1) RBF 神经网络的训练精度。
- (2) 梯度下降更新网络参数的最大迭代次数。

只要满足上述两个条件的任何一个即可结束迭代。

Step2:归一化训练样本,这里采用 min-max 标准化方法,其转换函数如下:

$$x^* = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

其中,  $x^*$  为样本数据转换后的标准数据,且有  $x^* \in [0, 1]$ ;  $x_{\max}$  为样本数据中的最大值;  $x_{\min}$  为样本数据中的最小值;  $x$  为样本数据的原始值。

Step3:随机抽取样本数据的 70% 作为训练集,其余 30% 为测试集。

Step4:在训练集上,利用 AutoEncoder 自编码器进行学习训练。训练结束后得到 RBF 神经网络  $NN^*$ 。

Step5:在网络  $NN^*$  各个参数的基础上,利用梯度下降法继续调整更新各个参数,直至满足终止条件。

### 3 基于三次样条插值与新型 RBF 神经网络的道岔故障诊断系统

#### 3.1 系统整体设计

基于样条插值与 RBF 网络的道岔故障诊断系统(其原理图如图 1 所示)包括基于三次样条插值的数据整合模块与基于 AutoEncoder 的 RBF 神经网络模块。其中前者负责将处于不同数据维数的道岔动作电

流数据划归为统一的数据维数。之后,由后者对该数据进行学习训练与测试。

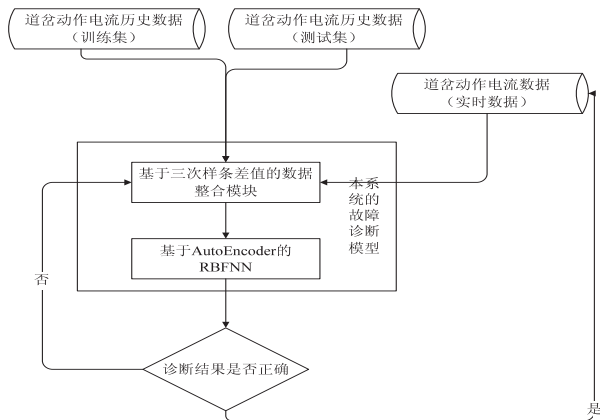


图 1 基于样条插值与 RBF 网络的道岔故障诊断系统原理图

该道岔故障诊断系统可分为针对历史数据的离线学习与针对实时数据的在线诊断两个阶段。在其历史数据离线学习阶段,将历史数据按比例随机拆分成训练集与测试集两个部分。该道岔故障诊断系统将训练集数据输入到基于三次样条插值的数据整合模块中,将原始数据维数划归为某个特定维数;之后,将整合后的数据输入到 RBF 神经网络进行学习训练;在训练结束后,将验证集输入到该 RBF 神经网络以验证网络的泛化推广能力;在 RBF 神经网络满足泛化需求之后,将其拷贝到现场进行实时故障诊断;通过人机交互模块,对该道岔故障诊断系统的诊断结果进行反馈。如果诊断错误,则需要将诊断的正确结果输入到 RBF 神经网络,并启动 RBF 神经网络的增量训练模式,对网络参数进行微调,以使其学习到新的信息,进一步提高网络性能。

#### 3.2 算法实现

步骤 1:将道岔动作电流数据的维数划归为某特定维数。

步骤 2:对道岔动作电流的历史数据采用式(2)进行归一化处理。

$$x^* = \frac{x - \mu}{\sigma} \quad (2)$$

其中,  $x$  为原始数据;  $x^*$  为归一化后的数据;  $\mu$  为所有样本数据的平均值;  $\sigma$  为所有样本数据的标准差。

步骤 3:基于训练集,学习训练基于 AutoEncoder 的 RBF 神经网络。

步骤 4:用步骤 3 中训练好的 RBF 神经网络对测试集进行故障诊断,并计算诊断的精度。如果精度较低,则返回步骤 3。否则,进入下一步。

步骤 5:将 RBF 网络各个参数拷贝到对道岔动作电流进行实时诊断的电脑。



步骤6:对实时诊断结果进行判断。如果诊断正确,则进入对下一条数据进行诊断的流程。否则,则将该条道岔动作电流数据与其正确的故障类型输入到RBF神经网络,并启动增量学习模式,对网络参数进行微调,以使该网络学习到新的知识。

3.3 仿真实验

道岔动作电流历史数据集采集自某车站的——包括正常、启动电路断线、外线混线、继电器接触不良、电机匝间短路、道岔动作困难、未能解锁、转换不畅、电机转子断线、转换阻力增大、道岔不闭锁与减速器或电机抱死等12种故障类型的——真实的现场监测数据,共1050条,数据维数在189~693之间。

在仿真实验中,随机选择历史数据集中30%的数据作为训练数据,用来学习训练RBF神经网络的各个节点的参数;再随机抽取该数据集另外20%的数据作为验证集,用来检验RBF神经网络的学习性能,以决定是否终止网络的学习过程;其余50%的数据作为测试集,用来模拟实时数据,以判断整个模型的最终表现。

设定数据整合后的维数为100,即将数据维数在189~693之间的历史监测数据,通过基于三次样条插值的数据整合模块,统一划归为100维。

因此,模型中的RBF神经网络的输入节点个数等于输入数据的维数100;输出节点的个数等于故障类型的数目12;其隐含层节点数目的确定到目前为止没有很好的方法,在实验仿真过程中,就采用不断尝试的方法以确定RBF神经网络隐含层节点的最终数目。并且,在训练过程中,对每一个所尝试的隐含层节点数目都重复实验10次,以便从这10次训练好的RBF神经网络中挑选中表现最好的网络。

最终实验结果参见图2与表1。




图2 故障诊断精度与隐含层节点个数的变化关系曲线

由图2可知,当RBF神经网络隐含层节点数目为52时,网络的泛化能力最高。

表1 实验仿真结果

| 隐含层节点个数 | 训练次数 | 训练集精度/%  | 验证集精度/%  | 测试集精度/%  |
|---------|------|----------|----------|----------|
| 52      | 1    | 99.682 5 | 95.714 3 | 96.571 4 |
| 52      | 2    | 99.682 5 | 95.714 3 | 96.952 4 |
| 52      | 3    | 99.682 5 | 95.714 3 | 94.857 1 |
| 52      | 4    | 99.682 5 | 96.190 5 | 96.381 0 |
| 52      | 5    | 99.682 5 | 93.809 5 | 95.047 6 |
| 52      | 6    | 99.365 1 | 93.809 5 | 94.285 7 |
| 52      | 7    | 99.682 5 | 95.238 1 | 96.381 0 |
| 52      | 8    | 98.730 2 | 94.285 7 | 94.857 1 |
| 52      | 9    | 99.682 5 | 95.714 3 | 96.190 5 |
| 52      | 10   | 99.682 5 | 96.190 5 | 97.142 9 |

由表1可知,当RBF神经网络的隐含层节点数目等于52时,该模型在其第10次训练时,所学习训练得到的RBF神经网络的训练精度、验证精度、测试精度分别高达99.6825%、96.1905%与97.1429%。也说明此时该神经网络具有更好的泛化能力,也就是具有更好的识别未知样例故障类型的能力。

4 结束语

针对道岔故障数据维数变化不定且故障数据量大,难以实时、快速、准确地进行人工诊断这一现实需求,综合采用基于三次样条插值与RBF神经网络等技术手段,建立了新型道岔故障诊断系统。通过应用某站真实历史监测数据进行验证,证明所建立的模型不仅能够适应不同数据维数的现场监测数据,而且还可以帮助维护人员快速、准确地对道岔故障进行诊断,减少故障处理时间,提高铁路行车的安全性。

参考文献:

[1] 冯琳玲. 运用微机监测道岔电流曲线分析提速道岔故障[J]. 铁路通信信号工程技术,2011,8(1):73-75.

[2] 周桂强. 利用微机监测道岔动作电流曲线指导日常维修[J]. 铁道运营技术,2006,12(3):34-35.

[3] 候志宇,崔泽彬. 电动转辙机自动开闭器故障原因及解决方法[J]. 铁道通信信号,2005,41(6):25.

[4] 姜玥,韩丽英,张晓锋. 微机监测道岔电流采集中的故障分析[J]. 铁道通信信号,2011,47(11):45-46.

[5] 王玉芬. S700K1/30提速道岔常见故障分析与对策[J]. 上海铁道科技,2009(1):38-39.

[6] Schwenker F, Kestler H A, Palm G. Three learning phase for radial-basis-function networks[J]. Neural Networks,2001,14:439-458.

[7] Roy A, Govil S, Miranda R. An algorithm to generate Radial Basis Function (RBF)-like nets for classification problems

4 结束语

对于同时具有时延和丢包的网络控制系统,假设时延存在于传感器到控制器之间和控制器到执行器之间且时延是时变的。将时变短时延系统建模成含有不确定参数的系统。利用 Lypunov 稳定性原理和 LMI 方法给出并证明了  $H^\infty$  控制器存在的充分条件。由仿真实例证明了设计的控制器是可行有效的。

参考文献:

[1] 陈志明,崔宝同. 数据包丢失的无线网络控制系统的故障检测[J]. 计算机技术与发展,2012,22(11):61-64.

[2] Hetel L, Daafouz J, Iung C. Stabilization of arbitrary switched linear systems with unknown time-varying delays[J]. IEEE Transactions on Automatic Control, 2006, 51(10): 1668-1674.

[3] Jung E H, Lee H H, Suh Y S. LMI-based output feedback control of networked control systems[C]//IEEE international workshop on factory communication systems. [s. l.]: IEEE,2004:311-314.

[4] Zhang Y, Tang G Y, Hu N P. Non-fragile control for nonlinear networked control systems with long time-delay[J]. Computers & Mathematics with Applications,2009,57(10): 1630-1637.

[5] Zhang H K. Non-fragile guaranteed-cost robust h-infinity control for a class of nonlinear networked control systems with long time-delay[C]//2010 international conference on intelligent computation technology and automation. [s. l.]: IEEE,2010:784-787.

[6] Fridman E, Shaked U. A descriptor system approach to  $H^\infty$  control of linear time-delay systems[J]. IEEE Transactions on Automatic Control,2002,47(2):253-270.

[7] Chen Z P, Liu L, Zhang J F. Observer based networked control systems with networked-induced time delay[C]//Inter-

national conference on systems. [s. l.]: IEEE,2004:3333-3337.

[8] Mahmoud M S, Khan G D. Dynamic output feedback of networked control systems with partially known Markov chain packet dropouts[J]. Optimal Control Applications and Methods,2015,34(5):505-634.

[9] 黄鹤,韩笑冬,谢德晓,等. 具有数据包丢失的网络控制系统主动容错控制[J]. 控制与决策,2009,24(8):1126-1131.

[10] Dasgupta S, Halder K, Banerjee S, et al. Stability analysis and controller synthesis of Networked Control system (NCS) with arbitrary packet drop-outs[C]//2nd international conference on electronics and communication systems. [s. l.]: IEEE,2015:217-222.

[11] 马卫国,邵诚. 网络控制系统随机稳定性研究[J]. 自动化学报,2007,33(8):878-882.

[12] 阮玉斌,杨富文,王武. 测量丢失概率不确定的网络化系统的鲁棒故障检测[J]. 控制与决策,2008,23(8):894-899.

[13] Yang F W, Wang Z D, Hung Y S, et al.  $H^\infty$  control for networked systems with random communication delays[J]. IEEE Transactions on Automatic Control,2006,51(3):511-518.

[14] 邱占芝,张庆灵,连志春,等. 存在时延和数据包丢失情况下状态反馈网络控制系统的指数稳定性[J]. 信息与控制,2005,34(5):567-575.

[15] Zhou Y, Zhu Y J. Control for uncertain discrete-time system with data packet dropouts and one step delay[C]//34th Chinese control conference. [s. l.]: [s. n.], 2015:6777-6781.

[16] 于之训,陈辉堂. 时延网络控制系统均方指数稳定的研究[J]. 控制与决策,2000,15(3):278-281.

[17] 李秀英,王金玉,孙书利. 具有一步随机时滞和多丢包的网路系统  $H^\infty$  滤波器设计[J]. 自动化学报,2014,40(1):155-160.

(上接第 163 页)

[J]. Neural Networks,1995,8(2):179-201.

[8] 王仁宏. 数值逼近[M]. 北京:高等教育出版社,1999:220-253.

[9] 孙志军,薛磊,许阳明,等. 深度学习研究综述[J]. 计算机应用研究,2012,29(8):2806-2810.

[10] Erhan D, Bengio Y, Coupville A, et al. Why does unsupervised pre-training help deep learning[J]. Journal of Machine Learning Research,2010,11(3):625-660.

[11] Laserson J. From neural networks to deep learing: zeroing in on the human brain[J]. XRDS,2011,18(1):29-34.

[12] Hinton G E, Osindero S, Teh Y. A fast learning algorithm for deep belief nets[J]. Neural Computation,2006,18(7):1527-1554.

[13] Bengio Y. Learning deep architectures for AI[J]. Foundations and Trends in Mach Learning,2009,2(1):1-127.

[14] Lecun Y, Bottou L, Bengio Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE,1998,86(11):2278-2324.

[15] 马艳东. 一种基于 AutoEncoder 的 RBF 神经网络训练算法[J]. 中国科技信息,2015(9):59-60.