

RBF 神经网络在地铁屏蔽门系统故障预测中的应用

华龙

北京市轨道交通运营管理有限公司 北京 100070

【摘要】：现今轨道交通领域飞速发展，伴随着日益拥堵的交通，地铁已经是市民出行的首选交通工具。每天超千万客流量带来的超负荷运转，缩短发车间隔、增加临客所带来的区段内车辆数量接近饱和，都给地铁设备带来了很大的冲击。地铁设备在日常使用过程中，如果发生故障，很可能造成列车的延误。尤其是早晚高峰时段，往往一列列车的延误，将会对整条线路以至于全网带来影响。对于设备的故障，现有的被动式维修模式已无法满足地铁线路应急故障抢险抢修的要求。有效规避设备故障带来的影响，降低故障的影响范围，对地铁系统的安全性与可靠性起着至关重要的作用。在此将使用神经网络对设备故障进行提前预知，通过设备的数值分析，确认设备状态及处理方式，探讨如何向自主式维护体系进行转变，为最终实现预防维修的技术革新奠定基础。

【关键词】：屏蔽门系统；DCU；预测；神经网络

引言

随着地铁线路的不断开通，目前地铁已经形成了一个覆盖面积广、多条线路纵横交叉的庞大城市轨道交通运行网络。在响应城市轨道交通运营网络化、智能化、多样化和层级化的大环境下，对地铁线路运行的安全性、可靠性、易维护性和互联互通也提出了更高的要求。轨道交通作为市民出行的重要交通工具，担负着保障北京交通路网顺畅的重任。这就为地铁线路的应急故障抢险抢修提出了日益严峻的考验乃至挑战。

随之而来的满负荷运行也使得设备故障几率也有了一定程度的增加。在保证安全运营的大环境下，对设备运行情况的掌握及故障的预判能力就显得尤为重要。设备的运行参数在反应系统设备运行情况的同时也可在一定程度上标示设备是否存在故障。所以，将设备运行参数与标准参数进行比较，可以更为有效的掌控整个系统的运行情况。

本课题选用具有自学习功能的 RBF 神经网络（RBFN: Radial Basis Function Network）算法，通过屏蔽门系统中 DCU 的运行参数对 DCU 故障发生几率进行预测。

本次采用的数据，通过在 MATLAB 上使用 Neural Network Toolbox 对结果进行预测。提出的预测手法所达到的预测精度为 6.5%。

对于故障几率的预测，对今后的维修模式的转变起到了决定性作用。本模型还存在不足的方面，通过对模型进一步的，今后将以地铁系统为目标进行预测，以使自主式维护体系变为可能。

1 背景

随着轨道交通的急速发展，同时也为了进一步缓解交通压力，改善乘客的乘坐体验，政府方面多次对地铁运力进行提升。

伴随着地铁运力的提升，发车间隔进一步缩短、大批量临客的增加等，大大增加了设备使用的频率。同时，区段内车辆相对饱和，对整体系统带来了一定的冲击。早晚高峰设备始终处在超负荷运营状态，也对设备的安全性造成一定的风险。以上问题致使设备的故障率也有了一定的提升。如何在满足市民出行需要的同时，又能有效降低设备发生故障的几率，便成为了急需解决的问题。

屏蔽门设备故障有可能造成车辆的延误，在早晚高峰期间，对路网的冲击较大，往往一列列车的延误会祸及多辆列车，造成大面积的延误甚至取消。

为了解决这一难题，对设备运行情况进行监测，在故障发生前及时发现并做出合理处置，避免因设备故障影响扩大，造成地铁车辆的延误。

本研究的实现不仅可以掌握设备情况，根据对更多设备运行状态的预测进而制定有针对性的设备检修保养维护制度，实现对设备全生命周期管理和区域应急抢险数据的采集、存储和应用，最终实现对设

备的维护集中监测与管理的自动化，完成与智能化城市轨道交通管理模式接轨。

2 目的

将来，城市发展以及城市路网压力将进一步加大，伴随着城市轨道交通的急速发展，对设备运行情况提前掌握，有效规避故障的发生将非常重要。本研究作为从被动式维修模式向自主式维护体系转变的参考依据，通过设备计数值分析，确认设备状态及处理方式，为最终实现预防维修的技术革新奠定基础。将屏蔽门系统中核心部件 DCU 作为研究对象，依托项目中设备运行情况数据，通过预测设备故障发生几率，已达到提前预知的目的。

基于 DCU 运行电流的故障分析：以松下屏蔽门系统中使用的自产 DCU 作为样本，将屏蔽门开关门过程中 DCU 温度及电流变化曲线为研究对象。通过实验室获取 DCU 电流运行波形，温度将通过监控软件获得。门体自启动至关闭时间为 5s，在启动指令发出时电机通电，电流出现跳跃性变化。随门体开始运动，电机加速至规定的速度，电流按指数规律上升并趋于稳定，最终达到最大稳态值。当门体进入减速阶段，电流迅速下降，至门体到位后，电流下降至静态值。综上分析，由于此变化规律可以直接反映 DCU 在各个阶段状态，并可以体现电机、DCU 电路本身、输入电源在门体运行过程中有无故障。因此，对电流波形变化进行追踪，就可实现运行状态的监测和 DCU 的故障预测。同时，对正常运行的 DCU 电流随门体进程变化的波形进行多次测量，确认 DCU 电流波形变化规律一致，有较好的重复性。

3 预测模型

本次使用 RBF 神经网络（RBFN: Radial Basis Function Network）。RBF 神经网络由三层构成，常用于非线性函数的近似。也被称为径向基函数，以高斯函数为主。RBF 神经网络是利用 RBF 作为隐含层单元的基从而构成隐含层空间，这样，就可将输入矢量直接映射到隐含层空间。当 RBF 的中心点确定以后，这种映射关系也就确定了，而隐含层空间到输出空间的映射是线性的，即网络的输出是隐含层单元输出的线性加权和，此处的权即为网络可调参数。由此可见，网络由输入到输出的映射是非线性的，而网络输出对可调参数而言却又是线性的。这样网络的权就可由线性方程组直接解出，从而大大加快学习速度并避免局部极小问题。

网络构造 RBF 神经网络由输入层、中间层、输出层 3 层构成。RBFN 函数由式 (1.1) 定义。

$$R(x_p - c_i) = \exp\left(-\frac{1}{2\sigma^2} \|x_p - c_i\|^2\right) \quad (1.1)$$

$\|x_p - c_i\|$ 为欧氏范数、 c 为高斯函数的对称中心、 σ 为高斯函数的分布。

网络的输出由式 (1.2) 计算得出。

$$y_j = \sum_{i=1}^n w_{ij} \exp\left(-\frac{1}{2\sigma^2} \|x_p - c_i\|^2\right), j=1, 2, \dots, n \quad (1.2)$$

式 (1.2) 中, $x_p=(x_1^p, x_2^p, \dots, x_m^p)^T$ 为第 p 次的输入数值、 c_i 为网络中间层的节点中心、 w_{ij} 为中间层到输出层的权值、 $i=1, 2, \dots, h$ 为中间层的节点数、 y_j 为第 j 次的实际输出值。

将 d 作为输入的输出值, 分散函数由式 (1.3) 计算得出。

$$\sigma = \frac{1}{p} \sum_{i=1}^m (\|d_i - y_i c_i\|^2) \quad (1.3)$$

为了反映预测的精度, 使用平均绝对误差百分比 (MAPE: Mean Absolute Percentage Error) 进行评价。MAPE 由式 (1.4) 得出。

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{I_i^p - I_i^t}{I_i^t} \right| \times 100\% \quad (1.4)$$

MAPE 用来表示实际用电量与预测用电量的平均绝对误差。其中, N 为预测值数、 I_i^p 为预测值、 I_i^t 为目标值。

3.1 仿真环境

使用的 PC 及仿真软件如下表:

表 1 PC 操作环境

OS	Windows 7 SP1 64-bit
处理器	Intel(R) Core(TM) i7-4710MQ 2.50GHz
内存	16GB
仿真软件	Matlab R2013a(8.1.0.604)
	Neural Network Toolbox Version 8.0.1 (R2013a) 13-Feb-2013

Matlab 为美国 MathWorks 公司开发的解析软件。

4 实验室测试情况分析

利用 RBF 神经网络实现对门体运行过程中 DCU 电流数据进行建模。该模型易于实现且具有较高精度, 可用于门体运行过程中 DCU 状态的预估。根据预计结果精度的要求, 输入特征量要对输出影响大且彼此不相关, 选取启动指令发出时电流的瞬间达到的跳跃峰值, 电机开始加速时的电流值, 电流趋于稳定后的最大稳态值以及电流最终返回的静态值; 输出特征量的选用反应实际可能出现的故障类型, 选择正常、电机故障、DCU 过电流故障、电源故障等 4 类。

神经网络的输入特征量选择运行过程中的实际电流, 输出特征量用编码表示且网络的输出值在 0 到 1 之间。输出值的大小表示对应的故障程度, 0 表示运行正常无故障, 1 表示故障已经发生, 数值越接近 1, 表示发生此类故障的几率越大; 反之则越小。针对本系统, 当输出特征值大于或等于 0.5 即认为设备存在故障。

4.1 预测手法

在 Matlab 环境下选用 RBF 神经网络对门体运动过程中 DCU 电流随门体动作情况的变化曲线进行学习和预测。

(1) 数据处理。设定门体自接受动作指令至停止动作为一个周期, 实验期间门体运作 100 次, 即产生 100 组数据, 随即将其中 80 组作为学习样本, 另外 20 组作为预测样本使用。

(2) 预测函数。本次的数据, 在 MATLAB 环境下, 使用 Neural Network Toolbox 工具箱的 RBF 神经网络对结果进行预测。

4.2 DCU 故障预测仿真

以仿真结果来对本次提案的手法进行仿真使用的数据的有效性判断。仿真使用的数据如下表所示:

表 2 预测 DCU 故障几率仿真数据

学习期间	输入	启动指令发出时电流的瞬间达到的跳跃峰值
		电机开始加速时的电流值
		电流趋于稳定后的最大稳态值
		电流最终返回的静态值
		正常
		电机故障
		DCU 过电流
		电源故障
	DCU 温度	
输出	故障几率 (0-1)	
测试期间	与学习期间使用数据相同	

如上表所示, RBF 神经网络输入层为 9 个输入, 对于预测结果的评价, 使用式 (1.4) 平均绝对误差百分比表示。

4.3 仿真结果

RBF 神经网络所具有的任意函数逼近、自动优化网络结构和较好的泛化能力, 使其在故障诊断方面的应用前景广阔。因此, 将 RBF 神经网络用于断路器的故障诊断是可行的和实用的。

5 总结

伴随着城市轨道交通的极速发展。为了确保系统安全、优质、经济运行, 本研究对每日地铁线路牵引系统日电量的预测手法进行提案。综上所述, 通过对地铁设备运行状态的提前预知, 可以强化设备维修体系, 并通过技术手段使自主式维护体系的转变成为可能。其中对 DCU 设备的故障预测可以达到日常使用的标准, 但对于复杂多变的故障情况还不能全部涵盖, 诸如 DCU 总线故障、无法联动等问题无法预知。因此对于 DCU 故障的预知还需要其它数据作为参照, 该模型还需要不断的改进和完善, 通过预测模型的改善、提高预测精度, 使保证系统安全、优质、经济运行成为可能。

6 展望

(1) 多设备的故障预测

本研究对 DCU 可能发生的故障进行预测。在屏蔽门系统中, 还有诸如电磁锁、接线盒、电机等等。因此, 从实用的角度出发, 对其它设备的故障几率进行预测是有必要的。在现有预测模型的基础上考虑新的需求数据, 对模型进一步改善, 以达到对整体系统的全面掌握。

(2) 全系统的故障预测

本研究中所涉及到的屏蔽门系统, 仅仅是地铁系统很小的一个分支。对于地铁系统来说, 每一个分支系统都是重要的, 每个系统都对地铁的安全运行起着不可或缺的作用。今后, 通过与其他系统数据互通, 入手新的数据, 进一步对预测模型进行改善, 力求达到对整个地铁系统可能发生的故障进行预测。

(3) 探讨模糊理论, 对数据进行改善

前文提到, 网络的输出值在 0-1 之间, 数值表示发生的几率。几率问题有着其自身的不确定性, 在现有输入数据的基础上, 配合模糊理论 (Fuzzy logic), 力求使预测精度接近完美。同时, 可以设想在模型中加入模糊算法将会使模型的应用性得到提升, 可以为更多的环境所使用。

参考文献:

[1] 翁桂鹏, 刘冬香编.城市轨道交通车站屏蔽门系统运行与维护[M].成都:西南交通大学出版社, 2000.1.