

DOI:10.3969/j.issn.1001-4551.2014.07.024

基于神经网络的充放电装置可靠性预计研究

王崇方,何通能*,王泽锴

(浙江工业大学 信息工程学院,浙江 杭州 310023)

摘要:针对如何更精确地实现充放电装置可靠性预计的问题,通过研究总体设备效率(OEE)中各元素的作用和关系,选取其中的可用性效率(AE)作为充、放电装置可靠性预计的目标值;同时,对于传统可靠性预计方法中的局限性,提出了一种基于神经网络的可靠性预计方法,建立了三层BP神经网络,并考虑充、放电装置中各个功能模块选取合适的参数作为神经网络输入,通过增加隐含层神经元个数的方法提高了预计精度,在取定合适的参数和样本数据后进行了仿真实验。研究表明,采用该方法对充、放电装置进行可靠性预计,可以达到很好的效果。

关键词:可靠性预计;充放电装置;总体设备效率;可用性效率;神经网络

中图分类号:TM744

文献标志码:A

文章编号:1001-4551(2014)07-0933-05

Charging and discharging device reliability prediction based on neural network

WANG Chong-fang, HE Tong-neng, WANG Ze-kai

(College of Information and Engineering, Zhejiang University of Technology, Hangzhou 310023, China)

Abstract: Aiming at achieving a more accurate charging and discharging device reliability prediction the issue was discussed, By studying the role and relationship of all elements of the overall equipment efficiency (OEE), the available efficiency (AE) was selected as the target of charging and discharging device reliability prediction. Meanwhile, because of limitations of the traditional reliability prediction methods, a reliability prediction method based on the neural network was proposed. During establishing the BP neural network, each function module of the charging and discharging device was considered. Then, the appropriate parameters were selected as the neural network input. By increasing the number of neurons in the hidden layer was expected to improve the accuracy of the method. After selecting the appropriate parameters and sample data, the simulation experiment was conducted. The results indicated that using this method for charging and discharging device reliability could be expected to achieve good results.

Key words: reliability prediction; charging and discharging device; overall equipment efficiency (OEE); availability efficiency (AE); neural network

0 引 言

可靠性预计是在设计阶段对未来产品的可靠性进行定量估计的一种方法^[1],它根据以往的经验、数据和当前的技术水平来预计产品实际的可靠度。它可以降低因硬件故障而导致的产品维修性,同时也可预计

产品的使用寿命。产品设计者可以根据预计的结果发现产品设计中的薄弱环节,并对其采取措施来改进产品的可靠性,实现“预计-改进设计”的循环。由此可知,对于产品设计的可行性决策、器件的选择和使用、产品的维修策略以及整个综合后勤保障要求的制定等过程,可靠性预计都发挥着关键的作用。

收稿日期:2014-03-13

作者简介:王崇方(1988-),男,浙江杭州人,主要从事充放电装置可靠性方面的研究。E-mail:wangchongfang@aliyun.com.

通信联系人:何通能,男,副教授,硕士生导师。E-mail:hntn@zjut.edu.cn

提高设备的可靠性就是指提高该设备的效率与其可用性,是将利润最大化的关键所在^[2]。总体设备效率(OEE)被广泛应用于评估设备的有效性,据其结果,设计者便可将投资添购的设备有效地运用于生产中。

本研究将针对充、放电装置进行可靠性预计。充、放电装置是一种结构复杂、参数不确定性较高以及影响因素较多的非线性系统,通过大量假设建立一个精确的数学模型是不可能,同时,太多的假设也会导致精度的下降。常用的方法,如相似产品法、数学模型法、最小割集近似法^[3]等,在实际应用中适应性差,对于那些带有时序特征呈高度非线性可靠性数据的处理,其精度远远不够,具有很大的局限性。人工神经网络^[4]是一种具有很好的处理非线性问题的能力智能算法,通过学习能够逼近任意非线性,并且能达到足够的精度。因此,本研究设计一种基于神经网络的可靠性预计方法,解决充、放电装置的可靠性预计问题,并通过仿真验证该方法的有效性。

1 总体设备效率概述

OEE 是一个简单且清晰的总体性能指标,其概念是由 Nakajima 提出的^[5],它是对生产设备的每个项目生产效率的定量测量,可以用 4 个重要因素来表示:可用性效率(AE)、运行效率(OE)、比例效率(RE)和品质效率(QE)。具体计算如下式所示:

$$OEE = AE \times (OE \times RE) \times QE \quad (1)$$

其中:

$$AE = \frac{\text{设备的正常运行时间}}{\text{总时间}} \quad (2)$$

$$OE = \frac{\text{生产时间}}{\text{设备的正常运行时间}} \quad (3)$$

$$RE = \frac{\text{实际单元的理论生产时间}}{\text{生产时间}} \quad (4)$$

$$QE = \frac{\text{有效单元的理论生产时间}}{\text{实际单元的理论生产时间}} \quad (5)$$

总时间、设备正常运行时间以及生产时间由国际半导体设备材料产业协会(SEMI)^[6]定义。OEE 的变化是由 AE、OE、RE 或者 QE 的变化引起的。其中,AE 是机器的利用率(运行时间/总时间)和机器的可靠性(正常运行时间/运行时间)的乘积。假如 OEE 的变化是由 AE 的变化引起,而机器的利用率是 100% 的话,那么 OEE 的变化就意味着该机器可靠性的改变。OE 可被看作是估计经营管理有效性的指标,OE 值的高低指明了经营管理的好坏。RE 是机器的生产率,无

需手动调节,RE 的任何变化都可能是该机器可靠性变化的结果。QE 是一台机器的收益率,取决于操作者的技能、机器的可靠性以及材料的质量等。因此,根据 OEE、AE、OE、RE 和 QE 的变化,设计者不仅可以知道生产过程中存在问题与否,同时可以初步判断大概是什么问题,并通过适当地调整使这些指标值保持在一个合理的范围内,从而来避免损失。本研究讨论的装置可靠性预计,主要工作是预计装置的可用性效率(AE)。首先需要建立装置的各单元与 AE 的关系,并据此调整各个单元的参数,提高装置整体的可靠性,同时也可了解各单元的细微变化对装置整体可靠性的影响。

2 神经网络结构及算法分析

人工神经网络是由人脑的功能和结构启发而来,它是由相互连接的自适应单元组成,十分类似于人类神经系统的响应^[7],其目的便是建立有用的模型以类似于人类解决问题和获取知识的方式来解决。神经网络方法可以用来解决一些传统数学和算法无法解决的问题,已经被证明是一种很有前景的预计工具^[8],并在许多行业都得到成功的应用^[9-10]。

人工神经网络模型通过神经元迭代地更新权值来实现实际输出和期望输出之间误差的最小化。多层感知器是最流行的神经网络,也是一种前馈网络,它可以实现输入空间和输出空间之间的静态映射,多层感知器结构如图 1 所示。它包含输入层、隐含层和输出层,其中隐含层的神经元可以为一层、两层或者更多层,可根据问题的需要和一般性的要求进行确定。




图 1 多层感知器结构

本研究选用了神经网络中经典的基于误差反传的 BP 神经网络。它的学习过程包括正向传播和反向传播:正向传播时,输入数据从输入层经隐含层传到输出层,每一层神经元的状态只会影响下一层神经元的状态;如果实际输出和期望输出不一致,则进入反向传播

阶段。反向传播阶段中,误差信号从输出层传到输入层,并对各个权值进行修改,使误差不断减小,在多次反复的学习中得到满意的精度指标。

3 充、放电装置的可靠性预计方法

充、放电装置的可靠性预计,是一个根据装置的各项组成元器件和零部件的可靠性来近似预计装置整机在实际上所能达到的可靠性指标的过程。该进程由局部到整体、由小到大、由下到上,逐层预计装置可靠性参数。只有各组成元器件和零部件的可靠性全部达到分配的可靠性要求,才能保证充放电装置整机的可靠性。

当某些子单元的可靠性数据未知时,普通的数学模型法由于较高的数据完整性要求而失去了预计功能。基于神经网络的预计方法则能够克服这一难题,同时还能满足足够的精度要求。

3.1 BP神经网络构架

首先,研究人员通过网络层数的选取、隐含层数目和隐含层神经元数目的选取、初始权值的选取、学习速率的选取以及迭代计算终点的判定,建立合适的BP神经网络,并对其进行训练和测试,使输出误差达到满意的精度,具体流程图如图2所示。

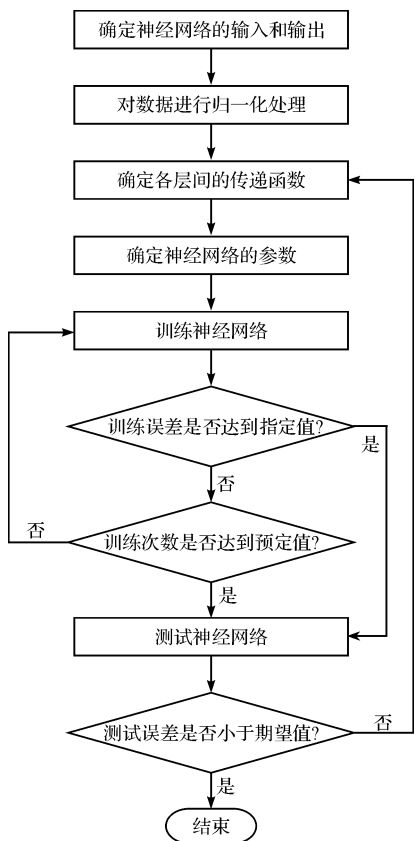


图2 基于神经网络的充、放电装置的可靠性预计的流程图

3.2 神经网络数据的确定

在神经网络方法的设计中,数据的收集以及数据的准备是非常重要的阶段,训练实例需要保证代表所有的可能性。用于本研究的数据已通过实际的试验和计算得到,而且已经通过了可靠性评估审计。

为了保证网络的性能和计算精度,输入单元不宜太多,本研究选用对该充、放电装置影响较大的若干个单元的失效率作为神经网络的输入,同时考虑装置的工作环境因素,把相应的工作环境因子也作为输入,具体输入神经元如图3所示。

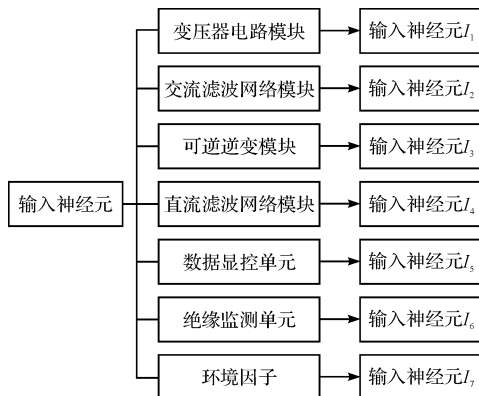


图3 神经网络的输入神经元

各个单元的失效率可根据可靠性理论,采用应力分析法计算得到。元器件的失效率可以根据GJB/Z299B-98《电子设备可靠性预计手册》中所提供的元器件失效率模型及相关数据计算得到。

AE作为神经网络的输出,和隐含层一起构成三层结构的BP神经网络。神经网络的输入输出值都是介于0~1之间,能够保证神经网络的收敛性能,因此不需要对其进行归一化处理。

本研究通过统计充、放电装置前期运行所得到的可靠性数据,建立BP网络的数据库。数据库中包括了完整的输入/输出数据,筛选后,选取其中的18组作为样本数据,将其中的15组数据作为训练样本,另外3组数据作为神经网络的测试样本。若在15次的迭代内误差精度小于设定值,那么便停止学习,后续数据都作为验证样本。

3.3 环境因子的确定

装置的可靠性水平不仅取决于各个单元的可靠性水平以及它们之间相互作用,同时与其工作环境有很大的关系。这里给出了一种确定环境因子的方法,其级别如表1所示。

表 1 环境因子级别

自然环境因子		人为环境因子	
优秀	0.5	熟练	0.5
较好	0.8	较熟练	0.8
一般	1	一般	1
较差	1.2	不熟练	1.2
恶劣	1.5	初次使用	1.5

环境因子包括自然环境因子和人为环境因子,装置的工作环境是两者综合的结果,其计算公式如下所示:

$$\beta = \frac{1}{2}\beta_1 + \frac{1}{2}\beta_2 \quad (6)$$

式中: β_1 —自然环境因子, β_2 —人为环境因子。

3.4 BP 网络的参数选择

一个三层 BP 神经网络能够逼近任意非线性函数,增加隐含层的层数可以提高精度,但同时也会使网络复杂化,增加网络训练时间。实践证明,通过增加隐含层神经元的数目也能够提高训练精度,训练增加层数要更加简单。所以本研究选择增加隐含层的神经元数目的方法来提高精度。

目前对隐含层神经元数目的选择主要依靠经验,无准确的理论与方法。隐含层神经元的数目太少会导致训练精度不高,太多会使计算过于复杂。因此,本研究采用试验尝试的方法来选取隐含层神经元数数目,可以参考文献[11]中的经验公式:

$$\begin{cases} h \geq \sqrt{n+m} + 1 \\ h \geq \sqrt{mn} \\ h \geq \log_2 n \end{cases} \quad (7)$$

式中: h —隐含层神经元数, n —输入神经元数, m —输出神经元数, l —1~10 之间的常数。

在该 BP 神经网络中采用的作用函数为 Sigmoid 函数。初始权值的选取对网络的收敛性有一定的影响,为了网络易于收敛,该算法根据实际情况选取(-1~1)之间的随机数作为初始权值。学习速率的选取也需要适中,合理的学习速率可以提高网络学习的效率,一般情况下,学习速率的选取最好介于 0.01~0.8 之间,同时还可以针对不同的训练阶段自动设置不同的学习速率。在网络训练过程中,需要设定一个判定条件来终止该迭代运算,研究者预先指定误差精度,当总体误差小于指定误差精度或者迭代次数达到预定次

数时,停止网络训练,建立所需的 BP 神经网络模型,然后将测试样本输入训练完成的神经网络进行测试,如果达到足够的精度则完成任务,否则将再次训练,重新调整网络结构。

4 仿真及分析

本研究采用上面分析的基于神经网络的充放电装置可靠性预计方法,设定三层 BP 神经网络中隐含层中包含 5 个节点。学习速率取 0.7,初始权值选取(-1~1)之间的随机数,误差精度取 $\varepsilon = 0.05$ 。仿真后,训练误差 $e(t)$ 的曲线如图 4 所示。




图 4 训练误差 $e(t)$ 的曲线

仿真中,训练误差在第 14 次迭代时满足了跟踪精度要求,并结束整个训练过程。保存本次的权值后,后面 4 次的样本数据都为测试所用,可以看出 4 次测试结果都能保证误差精度的要求,从而验证了本研究所提出的基于神经网络的预计方法。

5 结束语

为解决充、放电装置在实际应用中的可靠性提高的问题,本研究根据神经网络能够逼近未知非线性复杂系统的特性,设计了一种基于 BP 神经网络的充放电装置可靠性预计方法。在三层 BP 神经网络中,笔者通过增加隐含层神经元的方法提高预计误差精度,最后的仿真实验验证了所提出方法的有效性。

(下转第 941 页)

本文引用格式:

王崇方,何通能,王泽楷. 基于神经网络的充放电装置可靠性预计研究[J]. 机电工程,2014,31(7):933-936,941.

WANG Chong-fang, HE Tong-neng, WANG Ze-kai. Charging and discharging device reliability prediction based on neural network[J]. Journal of Mechanical & Electrical Engineering, 2014,31(7):933-936,941.

运行时间计算方法。基于这种细致化负荷模型的全网无功优化规划,不仅使代表负荷更接近实际负荷,代表性更为充分,既避免了过于简单的负荷模型带来的决策质疑,也避免了复杂化负荷模型带来的繁重计算。本研究提供的方法也适应更细致的负荷时段划分,如全年按12个月,日划分为峰、谷、平3段等。该方法已在新昌县电网进行了应用,研究结果表明,本研究所提方法可行,由于负荷模型更接近实际,决策更为科学和准确。

参考文献(References):

- [1] 余卫国,熊幼京,周新风,等. 电力网技术线损分析及降损对策[J]. 电网技术,2006,30(18):54-57.
- [2] 任震,唐卓尧,张勇军. 电网无功优化的改进遗传算法[J]. 电力自动化设备,2002,22(8):16-19.
- [3] 张勇军,任震,钟红梅,等. 基于灾变遗传算法的无功规划[J]. 电力系统自动化,2002,26(23):29-32.
- [4] 侯学勇,丁晓群. 基于遗传-模拟退火算法的配电网电容器优化配置[J]. 电网技术,2005,29(4):81-84.
- [5] 史燕琨,熊华强. 基于伪并行遗传算法的配电网电容器优化配置[J]. 电力系统保护与控制,2009,37(20):57-60.

- [6] 张伏生,李燕雷,汪鸿. 基于Tabu搜索算法的配电网电容器优化配置[J]. 电网技术,2003,27(4):72-75.
- [7] 胡海燕,刘健,武晓朦. 配电网低压侧自动无功补偿装置安装位置的优化规划[J]. 继电器,2004,32(19):21-25.
- [8] 杨洪,罗滇生,霍明. 基于SA-PSO的配电网电容器优化配置[J]. 电力系统及其自动化学报,2009,31(3):111-114.
- [9] 胡瑛俊,章坚民,刘大业,等. 基于前推回代法和量测数据资源的多电源供电配电网线损计算[J]. 电力自动化设备,2009,33(12):43-47.
- [10] 徐华月,章坚民,王跃强. 基于CIM和配电网自动化系统的配网快速潮流计算[J]. 电力系统保护与控制,2009,37(7):45-48.
- [11] 刘莉,王刚,翟登辉. k-means聚类算法在负荷曲线分类中的应用[J]. 电力系统保护与控制,2011,39(23):65-73.
- [12] 蔡国伟,王大亮,王燕涛,等. 一种基于最短距离聚类与关联度分析的典型日选取新方法[J]. 中国电力,2008,41(4):15-18.

[编辑:李辉]

本文引用格式:

张学军,陆献传,章坚民,等. 基于负荷持续模型的10 kV 配电线路无功优化配置[J]. 机电工程,2014,31(7):937-941.

ZHANG Xue-jun, LU Xian-chuan, ZHANG Jian-min, et al. 10 kV distribution line reactive optimal configuration based on load duration modeling[J]. Journal of Mechanical & Electrical Engineering, 2014,31(7):937-941.

《机电工程》杂志;http://www.meem.com.cn

(上接第936页)

参考文献(References):

- [1] 张生延. 可靠性预计中存在的问题及对策[J]. 电子产品可靠性与环境试验,2006,24(1):49-51.
- [2] HUNG M H, CHEN K Y, HO R W, et al. Development of an e-diagnostics/maintenance framework for semiconductor factories with security considerations[J]. **Advanced Engineering Informatics**,2003,17(3):165-178.
- [3] 刘翔飞. 基于神经网络的数控系统可靠性预计[J]. 矿业科学技术,2005,33(1):12-18.
- [4] 黄瑞毅,杨少华,李坤兰,等. BP神经网络在元器件非工作可靠性参数预测中的应用[J]. 电子产品可靠性与环境试验,2006,23(5):7-9.
- [5] NAKAJIMA S. Introduction to TPM: total productive maintenance[M]. Cambridge, MA: Productivity Press,1988.
- [6] SEMI. SEMI E79-0299. Standard for definition and measurement of equipment productivity[S]. Semiconductor e-

quipment and material international, Mt. View, CA,1999.

- [7] KOHONEN T. An introduction to neural computing[J]. **Neural networks**,1988,1(1):3-16.
- [8] ASSARZADEH S, GHOREISHI M. Neural-network-based modeling and optimization of the electro-discharge machining process[J]. **The International Journal of Advanced Manufacturing Technology**,2008,39(5-6):488-500.
- [9] ZHANG Z, FRIEDRICH K. Artificial neural networks applied to polymer composites: a review[J]. **Composites Science and technology**,2003,63(14):2029-2044.
- [10] YIN C, ROSENDAHL L, LUO Z. Methods to improve prediction performance of ANN models[J]. **Simulation Modelling Practice and Theory**,2003,11(3):211-222.
- [11] 朱磊,杨丹,吴映波. 基于BP神经网络的软件可靠性模型选择[J]. 计算机工程与设计,2007,28(17):4091-4093.

[编辑:李辉]