

文章编号: 1671-0576(2021)01-0055-06

基于神经网络的复杂电子装备调试决策技术

巫婕妤, 胡 刚, 吕海飞, 汪智萍

(上海无线电设备研究所, 上海 201109)

摘 要: 针对复杂电子装备性能指标和调试元器件参数之间存在非线性耦合关系, 难以用精确数学模型表示的问题, 提出一种基于神经网络的复杂电子装备调试决策方法, 并构建了复杂电子装备调试数据库与知识库, 开发了调试决策系统。该决策方法通过建立神经网络模型, 利用历史调试数据进行训练, 模拟电子装备性能指标和调试元器件参数之间的关联关系, 实现调试参数的预测。仿真试验结果表明: 基于神经网络模型的调试决策系统调试参数预测效果较好, 可以为人工调试提供决策支持。

关键词: 电子装备调试; 神经网络; 模型预测; 决策系统

中图分类号: TP183

文献标志码: A

DOI: 10.3969/j.issn.1671-0576.2021.01.010

Decision Technology of Complicated Electronic Equipment Debugging Based on Neural Network

WU Jie-yu, HU Gang, LYU Hai-fei, WANG Zhi-ping

(Shanghai Radio Equipment Research Institute, Shanghai 201109, China)

Abstract: Aiming at the problem that it is hard to express the nonlinear coupling relationship between the complex electronic equipment performances and the debugging components parameters by a precise mathematical model, a debugging decision method of complicated electronic equipment based on neural network is put forward. The electronic equipment debugging database and knowledge base are constructed, and the debugging decision system is developed. By using historical data for training, a neural network model is established to simulate the incidence relationship between the electronic equipment performances and the debugging parameters, and the prediction of the debugging parameters is realized. The simulation results show that the prediction effect of the debugging decision system based on the neural network model is good, which can provide decision support for manual debugging.

Key words: electronic equipment debugging; neural network; model prediction; decision system

0 引言

复杂电子装备是由大量相互关联、相互制约的电子元器件、电路板和组件组成的。由于电子元器件参数的离散性及不同环境条件下的性能变化会对装备性能指标产生影响,一般需要设置多个可调参数,并根据测试结果选配最优的调试参数。目前电子装备调试依赖人工经验,调试效率低、准确度差、反复次数多,大大影响了复杂电子装备的生产效率及成品率。通过对复杂电子装备的电路特性进行分析,可知其性能和调试元器件参数之间存在关联关系,但无法得出精确的数学模型。基于神经网络建立的非参数化模型,可模拟电子装备性能和调试参数的关系,用于调试参数的预测。

神经网络是近几年国内外人工智能领域的研究热点,其基本思想来源于人脑神经元的构造。神经网络具有大规模并行运算、自适应、自组织和自学习能力,适用于处理需要同时考虑多个因素和条件的模糊信息问题^[1]。范爱锋等^[2]在雷达装备状态监测与故障趋势预测系统中引入基于指数衰减的神经网络预测模型,并将该模型应用于某型雷达磁控管的高压数据预测。李静雯等^[3]将灰色 Verhulst 模型与小波神经网络相结合,来解决小样本故障数据在误差反向传播(back propagation, BP)神经网络训练中存在缺陷的问题,提出了基于灰色 Verhulst-小波神经网络的组合预测模型,并在某型航空设备工作电压的故障预测中对该模型进行了验证。文莹等^[4]将粗糙变量作为神经元的输入,通过交叉连接方式构造粗糙神经网络,以此来对设备特征参数进行预测,并将该方法应用于某型航空电子设备的故障趋势预测。胡雷刚等^[5]应用免疫算法对神经网络隐含层激励函数进行改进,得到免疫神经网络,并将该模型应用于某型航空装备特征参数的跟踪预测。孙文珺等^[6]提出一种将去噪编码融入稀疏自动编码器的深度神经网络,实现非监督学习的特征提取,并用于感应电动机的故障诊断。

本文提出一种基于神经网络的复杂电子装备调试决策方法,通过建立神经网络模型,模拟电子装备性能指标和调试元器件参数之间的关联关系,实现电子装备调试元器件参数最优值的预测。

1 神经网络模型建立

1.1 神经网络结构

电子装备性能指标与调试元器件参数之间存在某种非线性关系,利用电子装备的历史调试数据进行神经网络训练,可以使神经网络学习到近似于输入与输出之间潜在关系的规律。

神经网络由多个神经元以不同层的形式连接。每个神经元都是一个数学运算:对输入进行加权求和,加偏置,得到待激活值;将待激活值作为激活函数的输入,得到输出值,并将其传递给其他神经元。神经元结构如图 1 所示。




图 1 神经元结构

神经网络分为输入层、隐藏层、输出层。具有一个隐藏层的单输出神经网络结构如图 2 所示。通过调节神经元内部的激活函数参数以及神经元之间的连接权重,最终得到预测值。进行复杂电子装备调试决策时,输入层为电子装备性能指标,输出层为调试元器件参数,隐藏层的设置与待解决的问题有关,通常为 1~2 层。

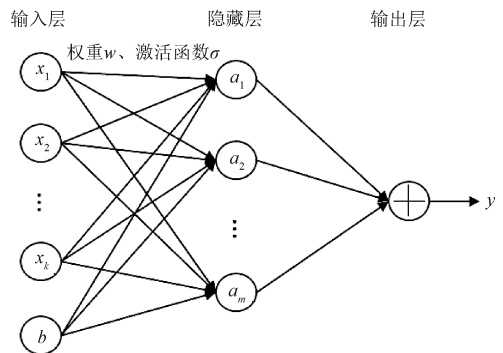


图 2 神经网络结构

利用神经网络预测输入与输出间的关系,以最小化损失函数为目标,选择合适的优化算法迭代求解最优的神经网络参数,即可得到近似真实关系的神经网络模型。激活函数是神经网络解决

非线性问题的关键,可以将网络连接非线性化。常用的激活函数有 ReLU 函数、Sigmoid 函数、Softmax 函数等。

一般利用均方误差 (mean squared error, MSE) 指标进行神经网络模型选择或者预测结果评价。将 MSE 作为损失函数,并以最小化 MSE 为目标进行参数求解,则损失函数可以表示为

$$\delta = \frac{1}{m} \sum_{i=1}^m (Y_{p,i} - Y_{a,i})^2 \quad (1)$$

式中: m 为样本点数; $Y_{p,i}$ 为第 i 个样本预测值; $Y_{a,i}$ 为第 i 个样本实际值。

通过优化算法使得损失函数的值最小,以便寻找到最优的参数。常用的优化算法是随机梯度下降 (stochastic gradient descent, SGD) 算法。SGD 算法每次随机选择一个样本来更新模型参数,训练速度更快。

1.2 神经网络模型参数

以某复杂电子装备单机为例,单机由 5 类组件构成,每类组件由 10~20 块电路板构成,共设置 8 项调试元器件。根据单机特性,梳理其性能指标与调试元器件的对应关系,如表 1 所示。灵敏度指标与调试电阻 *R44、*R30、*R46 有关,加速度指令指标与调试电阻 *R15、*R25、*R45、*R55 有关,耦合系数指标与调试电阻 *R54 有关。针对表 1 中的 3 类性能指标和对应的 8 项调试元器件,通过建立神经网络模型进行数据分析和模型训练,模拟单机性能指标和调试元器件之间的关联关系,实现以单机性能指标为输入、调试元器件参数为输出的调试决策,辅助指导实际生产中的人工调试。

表 1 性能指标与调试元器件对应关系

序号	调试元器件位号	性能指标	
1	*R44	灵敏度	灵敏度 1
2	*R30		灵敏度 2
3	*R46		灵敏度 3
4	*R15	加速度指令	加速度指令 1
5	*R25		加速度指令 2
6	*R45		加速度指令 3
7	*R55		加速度指令 4
8	*R54	耦合系数	耦合系数 1
			耦合系数 2
			耦合系数 3
			耦合系数 4

根据表 1 的对应关系,神经网络的输入为性能指标,输入层节点数为 3 或 4,输出为调试元器件参数,输出层节点数为 3、4 或 1。分别针对灵敏度、加速度指令、耦合系数测试项,调整输入和输出层节点数,建立相应的神经网络模型,模型结构如图 3 所示,模型参数如表 2 所示。设置 2 个隐藏层,第一隐藏层节点数设置为 15,第二隐藏层节点数设置为 7。灵敏度调试过程中神经网络结构输入层节点数 k 为 3,输出层节点数 m 为 3;加速度指令调试过程中神经网络结构输入层节点数 k 为 4,输出层节点数 m 为 4;耦合系统调试过程中神经网络结构输入层节点数 k 为 4,输出层节点数 m 为 1。隐藏层激活函数采用 ReLU 函数,损失函数采用均方误差函数,优化算法采用 SGD 算法,迭代 2 000 次,根据不同收敛速度设置学习率。

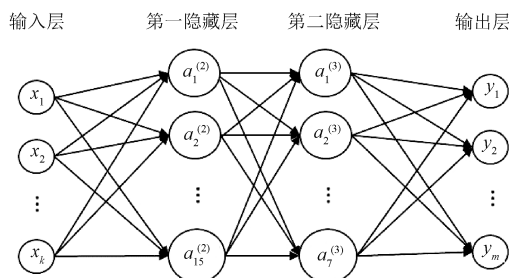


图 3 调试过程神经网络结构

表 2 神经网络模型参数

参数名称	第一隐藏层	第二隐藏层	输出层
权重	$w_1(3, 15)/$ $w_1(4, 15)$	$w_2(15, 7)$	$w_3(7, 3)/$ $w_3(7, 4)/$ $w_3(7, 1)$
偏置	$b_1(1, 15)$	$b_2(1, 7)$	$b_3(1, 1)$
激活函数	ReLU	ReLU	—
输入	x	$a^{(2)}$	$a^{(3)}$
输出	$a^{(2)} =$ ReLU($w_1x + b_1$)	$a^{(3)} =$ ReLU($w_2a^{(2)} + b_2$)	$y = w_3a^{(3)} + b_3$

2 神经网络模型训练

梳理电子装备的历史调试数据共 2 000 项,以 9 : 1 的比例划分神经网络模型训练集和测试

集,训练集数据为 1 800 项,测试集数据为 200 项。训练集中的性能指标和调试元器件参数分别作为神经网络的输入和输出,通过训练得到神经网络每层节点之间的权重。测试集用来评估训练后的神经网络模型,将测试集中的性能指标输入神经网络模型,计算得到调试元器件参数的预测值,和对应的调试元器件参数的真实值进行误差分析,评估该神经网络模型的预测效果,并进一步优化模型参数。神经网络模型训练流程如图 4 所示。

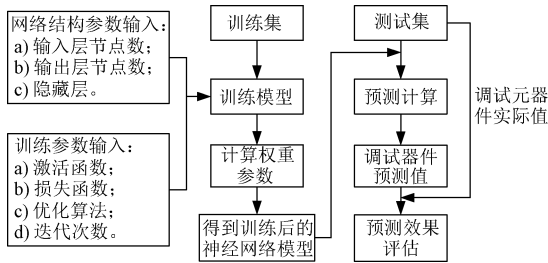


图 4 神经网络模型训练流程

为了让被训练的模型更加准确可信,采用 k 重交叉验证方法。将训练集数据分成 k 份,其中一份作为验证集,然后经过 k 次训练,每次都更换不同的验证集,得到 k 组训练结果,取平均值作为权重的最终结果。

针对训练后的神经网络模型,采用网格搜索算法进行模型的权重参数优化,将参数之间的潜在关系考虑进去,整合各参数得到最终的训练模型。将各个参数可能的取值进行排列组合,列出所有可能的组合,生成“网格”,然后将各组合用于神经网络训练,并采用交叉验证方法对训练结果进行评估,自动调整至最佳参数组合。

该电子装备单机的 3 类性能指标的调试元器件数量不同,但由于神经网络可以自由调节各层神经元数量,对于不同的预测项目可以很便利地建立神经网络模型。各调试元器件参数的测试集预测情况如图 5 所示,可看出各调试元器件参数的预测值和实际值误差较小。

以预测值相对于真实值的误差不超过 10% 作为神经网络的预测准确判据,神经网络模型训练集和测试集的预测效果如表 3 所示。各神经网络模型表现良好,其中 *R54 预测误差较大,是由于该调试参数与性能指标的相关性不高。

表 3 预测值与真实值误差在 10% 内的比例

调试元器件位号	训练集预测	测试集预测
*R44	1.000	1.000
*R30	1.000	1.000
*R46	0.951	0.905
*R15	0.989	0.952
*R25	1.000	1.000
*R45	1.000	1.000
*R55	0.967	0.810
*R54	0.857	0.714

3 调试决策系统

本文使用 MySQL 数据库管理系统开发电子装备调试数据库,包括产品信息表、性能指标信息表、测试参数表。产品信息表对产品的种类、生产编号、生产时间、调试时间等基本信息进行描述。性能指标信息表主要对产品的测试项和调试元器件等信息进行描述,包括测试项名称、测试项单位、测试项上下限、调试元器件规格、调试元器件上下限。测试参数表主要对测试指标的实测值和调试元器件实际参数进行描述。

为了满足调试决策系统更新不同产品、不同版本的调试模型的需要,采用算法信息表的形式,建立电子装备知识库,管理调试过程中产生的神经网络模型。具体如表 4 所示。

表 4 算法信息表

列名	数据类型	数据长度	主键	说明
Algorithm	字符型	20	是	算法名称
Description	字符型	20		算法描述
Version	字符型	20	是	算法版本
LearningRate	浮点型	6		学习率
Input	整型	6		输入层节点
Output	整型	6		输出层节点
Layers	整型	6		算法层数
Steps	整型	6		迭代次数
RunTime	浮点型	6		运行时间
Loss	浮点型	6		损失值
MAE	浮点型	6		平均误差
MSE	浮点型	6		均方误差
ModelPath	字符型	20		模型路径

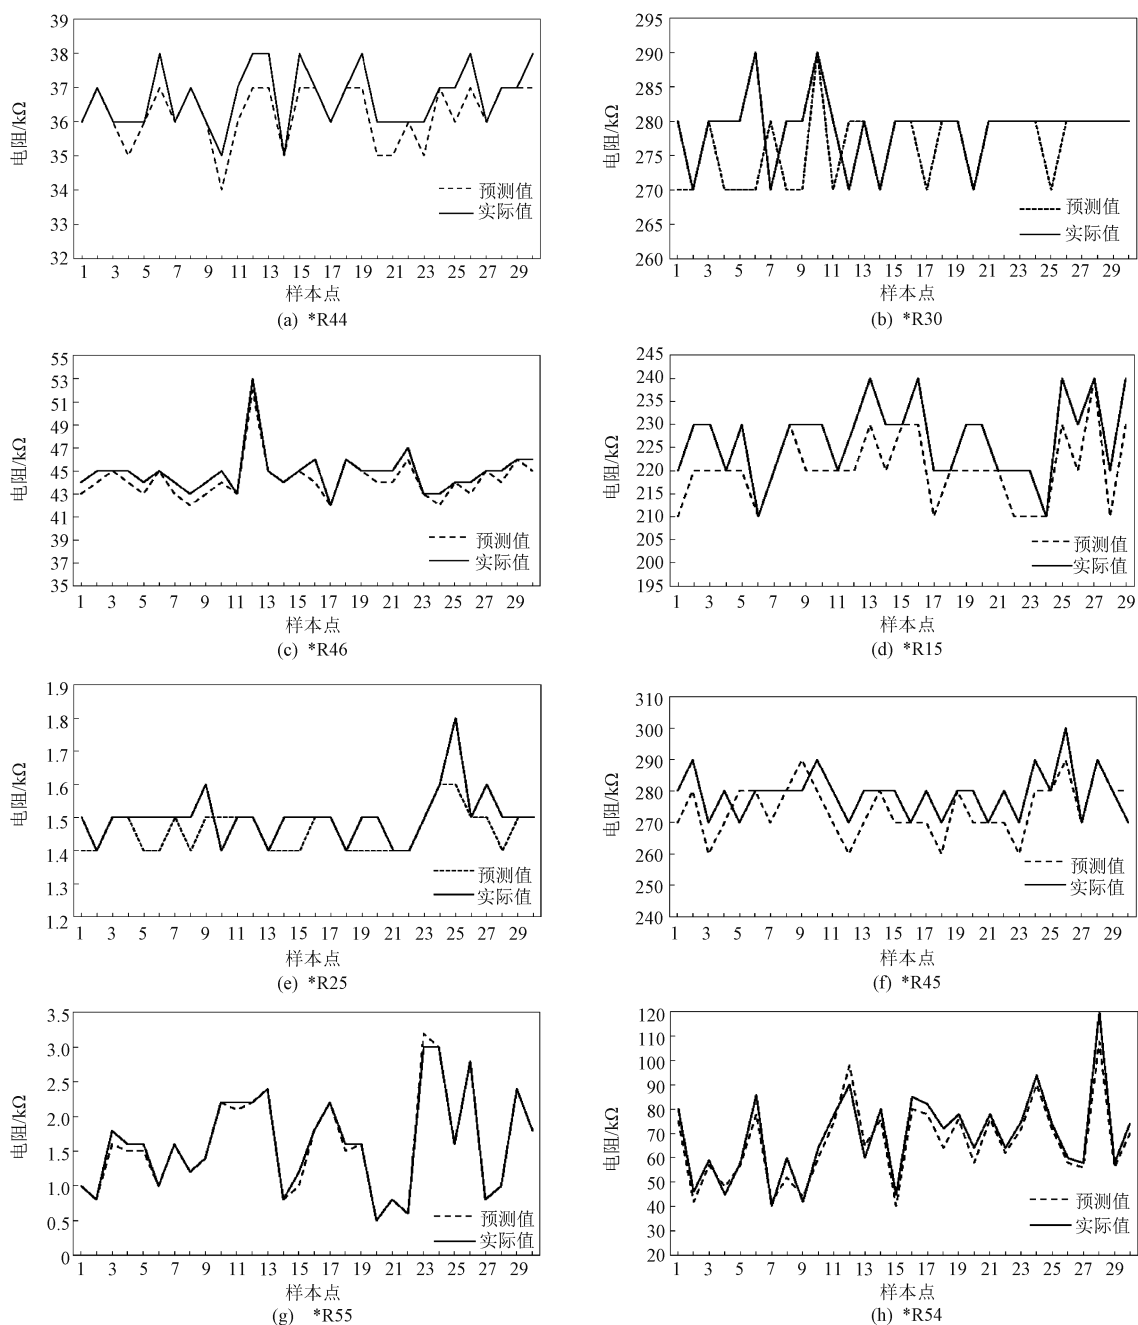


图 5 调试元器件的预测值与真实值对比

基于调试数据库和知识库,开发复杂电子装备调试决策系统,系统业务流程如图 6 所示。

如当前知识库中没有对应神经网络模型,则需进行模型训练。输入对应的训练数据文件路径,指定网络结构参数,包括输入层节点数、输出层节点数、隐藏层节点数、批量大小、迭代次数等参数,训练完成后,对应的训练模型自动保存在指定路径,供预测使用。




图 6 调试决策系统业务流程图

对知识库中已有神经网络模型的数据进行预测时,输入待预测的数据文件及对应的神经网络模型文件路径,指定预测结果输出文件的保存路径,运行预测程序,会在指定路径下产生预测结果文件。

4 结束语

针对复杂电子装备调试指标多、调试难度大等问题,基于神经网络模型,对历史调试数据进行分析与挖掘,模拟电子装备性能指标和调试元器件参数之间的关联关系。构建复杂电子装备调试数据库与知识库,开发调试决策系统,通过获取电子装备单机性能指标,预测相应的调试元器件参数,为人工调试提供指导。

参考文献

- [1] 胡伍生. 神经网络理论及其工程应用 [M]. 北京: 测绘出版社, 2006: 30-36.
- [2] 范爱锋, 孟亚峰, 张宏伟. 神经网络在雷达装备故障趋势预测中的应用[J]. 火力与指挥控制, 2011, 36(10): 180-181, 185.
- [3] 李静雯, 杨善红. 基于灰色 Verhulst-小波神经网络的装备故障预测研究[J]. 电子技术应用, 2014, 40(8): 91-93, 97.
- [4] 文莹, 肖明清, 胡雷刚, 等. 基于粗糙神经网络的航空电子设备故障预测研究[J]. 计算机测量与控制, 2010, 18(4): 807-809.
- [5] 胡雷刚, 肖明清, 谢澜. 基于免疫神经网络的航空设备故障预测研究[J]. 计算机工程与应用, 2011, 47(20): 231-233, 237.
- [6] 孙文珺, 邵思羽, 严如强. 基于稀疏自动编码深度神经网络的感应电动机故障诊断[J]. 机械工程学报, 2016, 52(9): 65-71.
- [7] 胡伍生. 神经网络理论及其工程应用 [M]. 北京: 测绘出版社, 2006: 30-36.
- [8] WIVELL C E, STEINWAND D R, KELLY G G, et al. Evaluation of terrain models for the geocoding and terrain correction of synthetic aperture radar (SAR) images[J]. IEEE Transactions on Geoscience and Remote Sensing, 1992, 30(6): 1137-1144.
- [9] AO C V, HU Y. A comprehensive study of the rational function model for photogrammetric processing[J]. Photogrammetric Engineering and Remote Sensing, 2001, 67(12): 1347-1357.
- [10] 王青松. 星载干涉合成孔径雷达高效高精度处理技术研究[D]. 长沙: 国防科学技术大学, 2011.
- [11] 李锦伟, 李真芳, 侯英龙, 等. 基于递推公式的星载 SAR 高效正向定位算法[J]. 电子与信息学报, 2014, 36(2): 409-414.
- [12] CAPALDO P. High resolution radargrammetry with COSMO-SkyMed, TerraSAR-X and RADARSAT-2 imagery: development and implementation of an image orientation model for digital surface model generation[D]. Rome: University of Rome La Sapienza, Faculty of Engineering, 2013.
- [13] CAPALDO P, NASSCETTI A, PORFIRI M, et al. Evaluation and comparison of different radargrammetric approaches for digital surface models generation from COSMO-SkyMed, TerraSAR-X, RADARSAT-2 imagery: analysis of Beauport (Canada) test site[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2014, 40(3): 159-163.
- [14] CURLANDER J C. Location of spaceborne SAR imagery[J]. IEEE Transactions on Geoscience and Remote Sensing, 1982, GE-20(3): 359-364.

(上接第 41 页)