

# 基于改进BP神经网络的变电站 检修运维成本预测

熊 一<sup>1</sup>, 詹智红<sup>1</sup>, 柯方超<sup>1</sup>, 周秋鹏<sup>1</sup>, 孙利平<sup>1</sup>  
廖 爽<sup>1</sup>, 任羽纶<sup>1</sup>, 周任军<sup>2</sup>

(1. 国网湖北省电力有限公司经济技术研究院, 湖北 武汉 430050; 2. 长沙理工大学电气与信息工程学院, 湖南 长沙 410114)

**摘要:** 变电站的检修运维成本受众多复杂因素影响, 且检修费用数据记录具有模糊性和波动性。为解决检修费用记录不明的问题, 首先对变电站检修条目划分并采用水平和垂直方向的数据分析方法进行处理, 再利用BP神经网络预测检修运维成本。为提高BP神经网络预测精度, 采用K-fold交叉验证对原始数据训练模型进行精准调整, 应用遗传算法对BP神经网络的初始值和阈值进行调整和改进, 从而建立基于遗传算法的改进BP神经网络检修运维成本预测方法。以某地市变电站为例进行变电检修运维成本预测, 对比分析显示所提方法能有效提高模型预测精度, 从而为电网给变电站拨付检修费用提供参考价值。

**关键词:** 变电检修运维成本预测; BP神经网络; 遗传算法; K-fold交叉验证

DOI: 10.19781/j.issn.1673-9140.2021.04.006 中图分类号: TM-9 文章编号: 1673-9140(2021)04-0044-09

## Overhaul operation and maintenance cost prediction of substation based on improved BP neural network

XIONG Yi<sup>1</sup>, ZHAN Zhihong<sup>1</sup>, KE Fangchao<sup>1</sup>, ZHOU Qiupeng<sup>1</sup>, SUN Liping<sup>1</sup>,  
LIAO Shuang<sup>1</sup>, REN Yulun<sup>1</sup>, ZHOU Renjun<sup>2</sup>

(1. Economic and Technological Research Institute, State Grid Hubei Electric Power Co., Ltd., Wuhan 430050, China;  
2. School of Electrical & Information Engineering, Changsha University of Science & Technology, Changsha 410114, China)

**Abstract:** Overhaul operation and maintenance costs of substations are affected by many complicated factors. Fuzzy and fluctuating data records of maintenance costs worsen the situation. In order to solve the unclearness of the overhaul cost record, this paper firstly divides the substation maintenance items and uses data analysis method of horizontal and vertical direction to process the items. Then BP neural network is used to predict the maintenance cost. In order to improve the accuracy of BP neural network prediction, K-fold cross-validation is used to accurately adjust the original data training model. The genetic algorithm is used to adjust and improve the initial value and threshold of the BP neural network. Therefore an improved BP neural network maintenance and operation cost prediction method is established based on the genetic algorithm. Taking a substation in a certain city as an example to predict the operation

收稿日期: 2020-12-04; 修回日期: 2021-05-22

基金项目: 国网湖北省电力有限公司科技项目(52153820000A); 国家自然科学基金(91746118); 湖南省自然科学基金(2019JJ40302)

通信作者: 熊 一(1988-), 男, 博士, 主要从事电网管理等研究; E-mail: 675786099@qq.com

and maintenance cost of substation maintenance, comparative analysis shows that the proposed method can effectively improve the accuracy of model prediction, thereby providing reference value for the power grid to allocate maintenance costs to substations.

**Key words:** substation overhaul operation and maintenance cost prediction; BP neural network; genetic algorithm; K-fold cross validation

变电工程是一个耗资巨大、结构复杂的系统,而一般针对变电工程费用的研究采用全寿命周期成本(life cycle cost, LCC)进行分析。变电检修运维成本是 LCC 一个部分,是指在变电站的运行期间所发生的一切费用的总和,包括一次设备、二次设备,站内所有线路检修运维费用及其他费用。且在变电工程总资产中占比较大,对检修运维成本进行精准预测具有研究意义。

文献[1]对电气设备在寿命周期内的可靠性参数进行模糊预测,建立了检修策略的优化决策模型;文献[2]以智能变电站为基础,对不同类别的检修方法的可靠性进行分析,对智能变电站的后续检修运维提供参考;文献[3]提出了一种新的变电站设备维护的优化策略,可以有效降低变电站供电风险,提高设备维护效率,并降低其维护费用;文献[4]通过控制数字化成本的同时提高项目的集成度,利用全寿命周期成本理论最小化变电站 LCC;文献[5]从电力设备全寿命周期成本最低的角度分析,针对 220 kV 变压器设备建立故障检修优化成本模型,但是只针对变压器故障情况下做检修成本优化,并未涉及设备运行的全过程。

现有对检修运维成本的预测大多体现在设备全寿命周期成本中的一个环节,而且是在保证供电可靠性的情况下 LCC 最优时得到检修运维成本。由于 LCC 涉及到初始投资成本,故这种做法只适用于未建或者新建变电工程中,不适用于已建的变电工程。并且在实际工程中,检修运维费用是按变电站级层面进行拨付,并不能直接到达设备层。因此,该文旨在针对已建变电站的检修运行维护成本进行预测分析,通过采用对财务条目数据进行分类归集检修运维成本,根据数据整理分析得到检修运维成本各具体费用类别,采用 K-fold 交叉验证对数据进行预处理,再基于遗传算法改进的 BP 神经网络进行检修运维成本预测,得到精准的检修运维成本,为电网拨付变电站检修费用提供实际参考意义。

## 1 检修运维成本分析

### 1.1 检修运维成本构成

变电工程的全寿命周期内支付的总费用可分为初始投资成本、检修运维成本和退役处置成本<sup>[6]</sup>。其中,初始投资成本可由新建变电工程的规模大小查询不同地市对应的信息价文件政策,预估出大致数值;报废成本一般是初始投资成本的 3%~5%;运行维护成本在整个全寿命周期内成本占比较大,一般为总成本的 60%~70%左右,且影响运行维护成本的因素较多,成本波动较大。检修运维成本可分为运行成本、维护成本以及故障停电成本<sup>[7-8]</sup>。

文献[7-8]均是从变电设备的角度出发对其各项费用进行划分和计算,但是在实际电网运行规划中,检修运维费用是按地市变电站级拨付,具体检修费用数据不能细化到各类设备层级,所以对于变电站级的检修运维成本分析将会更具有可靠性和实际意义。

### 1.2 检修成本费用数据分析方法

由于电网的变电设备具有种类繁多、设备各参数不尽相同、质量层次不齐的特点。在长期运行的过程中,出现各类故障的几率也会增大,而影响变电设备状况的因素有运行状态、维修情况、设备所处工作环境以及家族质量史等<sup>[9]</sup>,设备的这些状况信息具有模糊性和波动性,且各变量之间关系冗杂、互相影响,因此,电力设备检修运维费用记录数据也是具有模糊性和波动性的。现如今基层运维工作量大,检修运维成本每年都在持续增长。考虑各种因素对检修运维成本的影响,对变电站中的检修运维成本进行预测是很有必要的。

为解决记录数据模糊的问题,该文从财务系统整理分析变电设备检修运维费用条目,如图 1 所示,根据实际情况选取合理的数据样本,并对数据进行处理,采用水平和垂直方向的数据分析方法。

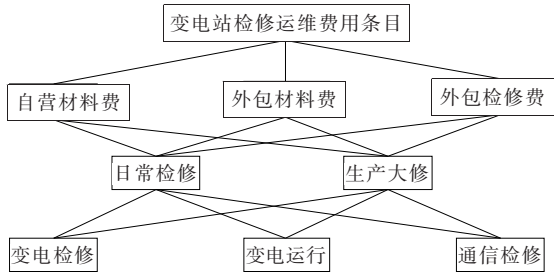


图1 变电检修运维成本费用条目

Figure 1 Substation overhaul operation and maintenance cost item

1)水平方向。

对于设备的检修运维成本水平方向的处理方法通常是取前、后2年成本之和的平均值。这是由于在一般情况下检修运维成本费用在时间序列上是平滑连续的,即某一年份的检修运维数据与它前、后年份的数据相差较近。如果差别较大,则说明该年的数据可能由于某些人为因素导致出现较大偏差。此时应舍弃该年份的数据或采取水平处理,进行修正:

$$\begin{cases} |Y(d,t) - Y(d,t-1)| > \alpha(t) \\ |Y(d,t) - Y(d,t+1)| > \beta(t) \end{cases} \quad (1)$$

$$Y(d,t) = \frac{Y(d,t-1) + Y(d,t+1)}{2}$$

式中  $\alpha(t)$ 、 $\beta(t)$  为阈值;  $Y(d)$  为第  $t$  年的检修运维成本数据;  $Y(d,t-1)$  为第  $t-1$  年的检修运维成本数据;  $Y(d,t+1)$  为第  $t+1$  年的检修运维成本数据。

2)垂直方向。

由于同一厂商的同型号设备的相关数据如家族质量史问题、故障率等具有聚类性,不同个体间的差距应该维持在一定范围内,误差应较小,若超过其固定范围即视为扰动数据。对于垂直方向处理方法,先设定数据的合理阈值,如果超出该阈值,则判定该数据错误,应采取更加合理的值进行替换。

$$|Y(d) - m(t)| > r(t)$$

$$Y(d,t) = \begin{cases} m(t) + r(t), Y(d,t) > m(t) \\ m(t) - r(t), Y(d,t) < m(t) \end{cases} \quad (2)$$

式中  $Y(d)$  为第  $d$  年该型号设备的故障率;  $m(t)$  为历史数据近几年该型号设备的故障率的平均值;  $r(t)$  为阈值。

## 2 基于遗传算法改进的BP神经网络

### 2.1 BP神经网络算法

BP神经网络其实质为实际值与预测值之间误差的一个反向传递过程,随着误差对权值或阈值导数的负梯度方向,不断修正权值或阈值,直到输出误差在设定范围内<sup>[10]</sup>。相比于其他预测方法,BP神经网络训练得到的规律表现为由修正后的网络参数,无具体的数学模型,且输入参数之间的关系也可不用明确,所以结合BP神经网络的特点可用于检修运维费用的预测。

BP神经网络如图2所示, $X$ 、 $Y$ 分别为神经网络的输入向量和隐层的输出向量; $X_0$ 、 $Y_0$ 分别为输入层、隐层的阈值,一般取值为-1; $V$ 、 $W$ 分别为输入层、隐层及输出层三者之间的权重向量;若训练结果中输出向量 $O$ 不符合收敛条件,则通过此时的误差调整 $V$ 、 $W$ ,使得输出向量满足条件<sup>[11-12]</sup>。




图2 BP神经网络示意

Figure 2 Schematic diagram of BP neural network

### 2.2 改进K-fold-GA-BP神经网络

神经网络训练数据分为训练集和验证集,为客观评估模型对于其训练集以外数据的应用情况,在验证数据过程中采取交叉验证方法。 $K$ -fold交叉验证中的数据来源于训练数据,但不参与神经网络的训练。首先,将初始数据分成 $K$ 组,对于每组数据依次进行验证和训练,若设定其中一组作为验证集,则其余 $K-1$ 组数据设定为训练集,一般 $K$ 值取4~5,网络共训练 $K$ 次, $K$ 次的评估误差(mean squared error, MSE)加和平均即为最终的交叉验证误差。交叉验证方法利用了有限的的数据,对模型测试集的精度能起到一定效果,可以作为模型优化<sup>[13]</sup>。

而采用遗传算法(genetic algorithm, GA)对 BP 神经网络进行预处理,可以得到较好的网络初值。首先,将 BP 神经网络的初始权值和阈值预处理化,用 GA 中的个体表示;其次,计算预处理后 BP 神经网络的预测误差值,设定其为个体的适应度值;最后,经由对个体适应度选择、交叉和变异操作,在满足设定精度范围内的情况下,获取 BP 神经网络初始权值的最优值<sup>[14]</sup>。

采取 K-fold 交叉验证对数据进行预处理。GA-BP 神经网络的流程如图 3 所示。

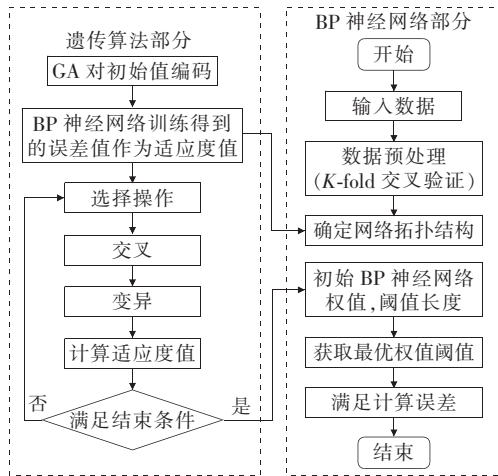


图 3 GA-BP 神经网络的流程

Figure 3 Flow chart of GA-BP neural network

### 3 变电站检修运维成本预测的 K-fold-GA-BP 神经网络设计

BP 神经网络的结构包括输入层、隐含层和输出层,输入参数进入输入层,然后过隐含层,最后由输出层输出<sup>[15]</sup>。利用 K-fold-GA-BP 神经网络方法对变电站检修运维成本预测的步骤如下。

1) 输入输出层的设计。依据 BP 神经网络的设计特性,不考虑各因素之间的相互影响关系,在变电站运维检修成本中可选取费用构成因素作为输入层,输出层为检修运维预测费用值。

2) 目标值的选取。根据已建变电站检修运维成本费用进行处理,采用水平垂直方向处理数据的方法,估算目标检修运维成本预期费用,作为输出的目标值。

3) 模型的建立。

遗传算法部分:首先利用 GA 对种群进行初始化,得到 BP 神经网络的初始权值和阈值,将种群初始化后个体代入 BP 神经网络进行迭代寻最优初始权重和阈值<sup>[16]</sup>。

①对输入层、隐含层及输出层之间的权值、隐含层与输出层的阈值组成的实数串种群进行编码。

②个体的适应度值  $F$  由其期望输出值与预测输出值的误差绝对值构成:

$$F = k \left( \sum_{i=1}^m |p_i - o_i| \right) \quad (3)$$

式中  $m$  为输出节点的个数;  $p_i$  为第  $i$  个节点的输出期望值;  $o_i$  为第  $i$  个节点的输出预期值。

③根据式(3)计算的个体适应度结果,选择较好的个体组成新的种群,计算方式为

$$f_i = \frac{k}{F_i} \quad (4)$$

$$P_i = \frac{f_i}{\sum_{i=1}^k f_i} \quad (5)$$

其中,  $F_i$  为第  $i$  个群体的适应度值,由式(3)计算得到,  $k$  为群体规模,  $f_i$  为  $i$  群体被选择的概率。

④在种群中随机抽取 2 个父体个体  $P_k$  和  $P_l$ , 在一定概率下第  $j$  个点位的实数交叉方式为

$$\begin{cases} P_{kj} = \alpha P_{lj} + P_{kj}(1 - \alpha) \\ P_{lj} = \alpha P_{kj} + P_{lj}(1 - \alpha) \end{cases} \quad (6)$$

其中,  $\alpha$  为  $0 \sim 1$  之间的随机数。

⑤通过概率计算,在组成的新的种群中随机抽取某个个体  $P_i$  进行变异,第  $j$  个点位变异方式为

$$P_{ij} = \begin{cases} P_{ij} + (P_{ij} - P_{\max})\mu(1 - \frac{v}{V_{\max}}), \mu > 0.5 \\ P_{ij} + (P_{\min} - P_{ij})\mu(1 - \frac{v}{V_{\max}}), \mu < 0.5 \end{cases} \quad (7)$$

式中  $P_{\max}$ 、 $P_{\min}$  分别为个体上、下界;  $v$  为此时迭代次数;  $V_{\max}$  为最大进化次数;  $\mu$  为随机数,取值范围为  $0 \sim 1$ 。

⑥检查所得个体是否符合最优标准,对无法达到标准的个体再次进行适应度校验;若符合标准,则将最优个体作为 BP 神经网络的权值和阈值,重复学习训练次数,调整神经网络参数到所设定的精度

范围内或满足学习次数为止<sup>[17]</sup>。

神经网络部分:得到 BP 神经网络初始权重和阈值后其内部结构模型分析步骤如下。

①初始化网络。

$$\begin{cases} \mathbf{X} = (x_1, x_2, \dots, x_n) \\ \mathbf{Y} = (y_1, y_2, \dots, y_m) \end{cases} \quad (8)$$

式中  $\mathbf{X}$  为神经元输入向量,为变电站检修运维成本费用构成因素; $n$  为输入层节点数; $\mathbf{Y}$  为神经元输出向量,为变电站检修运维成本, $m$  为输出层节点数。

②计算隐含层输出。隐含层输出值  $H_a$  的计算方式为

$$H_{aj} =$$

$$f\left(\sum_{i=1}^n \omega_{ij} x_i - \lambda_{aj}\right), 1 \leq j \leq p, 1 \leq i \leq n \quad (9)$$

式中  $p$  为隐含层节点数; $\omega_{ij}$  为输入层与隐含层之间的权值; $\lambda_a$  为阈值; $f$  为激励函数。

③计算输出层输出。输出层输出值  $H_b$  的计算方式为

$$H_{bk} = \sum_{j=1}^m H_{aj} \omega_{jk} - \lambda_{bk}, 1 \leq k \leq m \quad (10)$$

式中  $\omega_{jk}$  为隐含层与输出层间的权值; $\lambda_b$  为阈值。

④计算误差并验证。误差  $e$  表示为预测输出  $H_b$  与期望输出  $\mathbf{Y}$  之差,计算方式为

$$e_k = |Y_k - H_{bk}| \quad (11)$$

设  $e_0$  为允许最大误差值,若  $\max(e_m) > e_0$ ,则调整 BP 神经网络参数,重新进行学习训练,直至所有的训练数据均满足所定误差标准。

⑤更新权值和阈值。由所求的误差进行更新  $\omega_{ij}$  和  $\omega_{jk}$  :

$$\omega_{ij} = \omega_{ij} + \eta H_{aj} (1 - H_{aj}) x_i \sum_{k=1}^m \omega_{jk} e_k \quad (12)$$

$$\omega_{jk} = \omega_{jk} + \eta H_{aj} e_k \quad (13)$$

其中,  $\eta$  为学习速率,介于 0~1 之间。阈值修正为

$$\lambda_a = \lambda_a + \eta H_{aj} (1 - H_{aj}) \sum_{k=1}^m \omega_{jk} e_k \quad (14)$$

$$\lambda_b = \lambda_b + e_k \quad (15)$$

4)模型的计算。模型计算采用 Matlab 软件,在计算过程中,将变电站设备检修运维成本已有数据作为样本,采用 GA-BP 神经网络进行训练;为避免

出现过拟合情况,同时提升 GA-BP 神经网络模型准确度,对训练数据采取 K-fold 交叉验证方法,判定模型精准度。

该文选取能耗费、人工费、材料费、修理费、电费损耗以及交通运输费作为输入层,输出层为变电站设备运维检修费用,选定其初始权值进行学习,由输入层的相应数据预测得到变电站设备检修运维费用。基于 K-fold-GA-BP 神经网络的变电站设备检修运维费用模型如图 4 所示。




图 4 基于 K-fold-GA-BP 神经网络的变电站设备检修运维费用模型

Figure 4 Overhaul operation and maintenance cost model of substation equipment based on K-fold-GA-BP neural network

5)预测效果评价指标。在对模型的结果进行检验时,需要考虑模型的信度和效度。信度是指模型的可靠程度,表现为模型结果的再现性和稳定性;效度是指模型的有效程度,表现为模型的结果与要考察内容的吻合程度<sup>[18]</sup>。

该文主要采用  $e_{MSE}$  评估 K-fold 交叉验证对模型精准度的影响,计算公式为

$$e_{MSE} = \frac{1}{n} \sum_{i=1}^n (D_i - Y_i)^2 \quad (16)$$

采用平均绝对百分比误差(mean absolute percentage error, MAPE)和均方根误差(root mean square error, RMSE)来衡量网络的效度,即预测效果,其计算公式为

$$e_{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{D_i - Y_i}{Y_i} \right| \times 100\% \quad (17)$$

$$e_{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (D_i - Y_i)^2} \quad (18)$$

其中,  $D_i$  为模型实际输出,  $Y_i$  为预期输出。为了检验模型的信度,该文取多次运行后的  $e_{MAPE}$ 、 $e_{RMSE}$  的标准差作为最终检验指标。

## 4 算例仿真

### 4.1 参数设置及说明

选取中国某省典型地市变电站的检修运维费用数据为例进行分析。选取 2014—2019 年地市检修拨款数据作为数据源,利用 Matlab 仿真首先应用遗传算法优化初始权值,遗传算法群体规模设定为 50,迭代次数为 500,交叉概率为 0.2,变异概率为 0.01,再进行 BP 训练,BP 神经网络隐层设置为单隐含层网络。隐含层节点数一般依据经验来选取,原则上应该取值尽量偏小,计算公式为

$$L = \sqrt{n + m} + c \quad (19)$$

式中  $L$  为所需要设置的隐含层节点数目; $n$ 、 $m$  分别为输入层、输出层节点数目; $c$  为任意 1~10 之间的常数值。

根据式(19)权衡最优可以确定隐含层的节点数。网络学习速率设为 0.05,训练误差选为  $1 \times 10^{-5}$ ,最大训练次数为  $10^5$ 。隐层激活函数 tansig、输出激活函数 purelin 以及权值与阈值由遗传算法优化得到。

### 4.2 检修运维成本预测分析

为检验检修运维成本的预测精准度,设置 3 个方法进行预测分析,通过预测效果评价,验证各模型的有效性。

- 1) 采用传统的 BP 神经网络算法进行预测;
- 2) 采用基于遗传算法改进的 GA-BP 神经网络算法进行预测;
- 3) 采用 K-fold 交叉验证对训练数据进行预处理,再用 GA-BP 神经网络算法进行预测。

采用 3 种不同的方法对检修运维成本数据进行训练的结果和相对误差如表 1、2 所示。以 2017 年份数据为例,2017 年的运维检修成本为 5 583.700 万元,传统 BP 预测值为 5 810.976 万元,采用 GA-BP 预测结果为 5 688.921 万元,K-fold-GA-BP 预测结果为 5 527.372 万元。3 种方法的相对误差分别为 0.040 70、0.018 84 和 0.010 09。如图 5、6 所示,可直观地表示出 3 种方法对检修运维成本费用的预测,采用 K-fold-GA-BP 法最优,相对误差只有 1.009%,而采用传统的 BP 预测值相对误差较大,达到 4.070%,说明此种方法的预测效果不佳。

表 1 3 种方法对检修运维成本数据的训练结果

Table 1 Training results of the operation and maintenance cost data by three methods 万元

年份	真实值	预测值		
		BP	GA-BP	K-fold-GA-BP
2014	3 877.0	3 893.673	3 943.525	3 874.328
2015	4 404.0	4 444.600	4 339.355	4 397.532
2016	5 604.4	5 423.453	5 556.078	5 631.609
2017	5 583.7	5 810.976	5 688.921	5 527.372
2018	6 529.2	6 385.458	6 473.004	6 591.704
2019	7 457.9	7 511.336	7 480.192	7 429.191

表 2 3 种方法预测结果的相对误差

Table 2 Relative errors of three methods of forecasting results

年份	相对误差		
	BP	GA-BP	K-fold-GA-BP
2014	0.004 300	0.017 16	0.000 67
2015	0.009 219	0.014 68	0.001 47
2016	0.032 290	0.008 62	0.004 86
2017	0.040 700	0.018 84	0.010 09
2018	0.022 150	0.008 61	0.009 57
2019	0.007 165	0.002 99	0.003 85

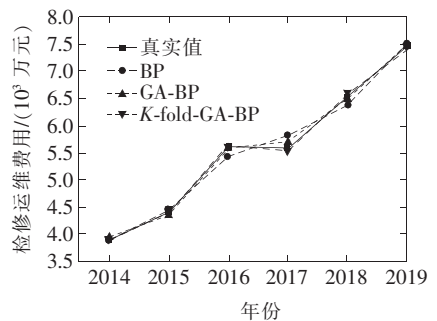


图 5 3 种方法对检修运维成本数据训练结果

Figure 5 Training results of the operation and maintenance cost data by three methods




图 6 3 种方法预测结果相对误差

Figure 6 Relative errors for the prediction results of the three methods

所构建的不同模型训练效果综合评价指标数据如表3所示,可知K-fold-GA-BP预测模型的MAPE、RMSE分别为38.063800、0.005087。如图7所示,可以直观地看出采用K-fold-GA-BP法的综合评价指标误差最小,表明由此种方法所构建的模型适用于该地市检修运维成本费用预测,且效果较好。

表3 所构建的模型训练效果综合评价指标

Table 3 Comprehensive evaluation index of training effect for the training model

算法	$e_{MAPE}$	$e_{RMSE}$
传统BP	0.019280	135.3018
改进GA-BP	0.011820	65.4040
K-fold-GA-BP	0.005087	38.0638

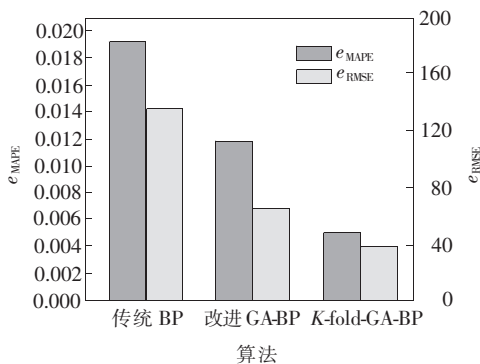


图7 3种模型训练效果综合评价指标

Figure 7 Comprehensive evaluation index of training effects for three models

为体现K-fold交叉验证方法对模型精准度有提升的效果,对比分析是否采用该方法对模型预测误差的影响。如表4所示,当采用K-fold交叉验证对训练数据进行处理后,模型预测误差率降低,MSE为1448.85,比未采用该办法处理的GA-BP模型的效果要好很多。

表4 K-fold模型预测误差

Table 4 K-fold prediction errors for GA-BP and K-fold-GA-BP

算法	$e_{MSE}$
GA-BP	4277.68
K-fold-GA-BP	1448.85

通过对该地市2014—2019年历史检修运维成本数据测试,对神经网络参数进行反复调试,得到适应于地市检修运维成本的K-fold-GA-BP预测模型。运用此模型对检修运维成本进行预测,该地市未来3年的检修运维费用预测值如表5所示,其分布情况如图8所示。

表5 某地市未来3年检修运维费用预测值

Table 5 Forecast value of operation and maintenance costs in a certain city in the next three years 万元

年份	预测值		
	BP	GA-BP	K-fold-GA-BP
2020	8448.204	8158.674	8006.890
2021	8782.368	8383.108	8622.262
2022	9407.674	9142.021	8980.137

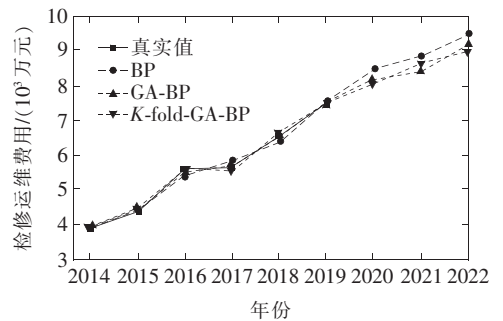


图8 某地市未来3年检修运维费用预测

Figure 8 Forecast of operation and maintenance costs for a certain city in the next three years

该地市未来3年2020—2022检修运维费用分别为8006.890、8622.262、8980.137万元。数据结果可以为电网拨付检修费用成本提供具体参考和建议支撑。

## 5 结语

针对已建变电站设备检修运维成本拨付问题,首先对历史数据进行处理,根据变电检修财务条目的分析和整理,归算出历年检修运维成本费用数据真实值;为避免传统BP神经网络将陷入局部最优,然后对训练数据进行K-fold处理,利用遗传算法改进的BP神经网络预测变电站检修运维成本。通过研究得出结论。

1) 变电运维检修费用历史数据收集过程较为困

难,通过对变电工程检修财务条目的分析整理,得到相关检修费用,并对数据进行水平方向、垂直方向的处理,保证得到数据的真实可靠性。并且分析影响变电站检修运维成本的各种构成因素,并作为预测模型的输入量。

2)对于原始数据进行 BP 神经网络训练时,采用 K-fold 交叉验证能够较好地保证预测模型的准确性,避免出现过拟合现象。

3)采用 K-fold-GA-BP 神经网络模型预测已建变电站未来检修拨付费用,通过对典型地市变电站检修运维成本数据训练和预测,可知该模型能够准确的预测出未来检修运维费用。在每年检修运维成本波动较大的情况下,利用该方法能较为准确的得到检修运维拨付值,为电网给变电站拨付检修费用提供参考意见。

#### 参考文献:

[1] 顾洁,杜渐,秦杰,等. 基于全寿命周期成本的变电站设备检修模糊规划模型[J]. 电力系统自动化,2014,38(1):44-50.

GU Jie,DU Jian,QIN Jie,et al. A fuzzy programming model based on life cycle cost for equipment maintenance in substations[J]. Automation of Electric Power Systems,2014,38(1):44-50.

[2] 何旭,姜宪国,张沛超,等. 考虑检修策略的智能变电站保护系统可用性分析[J]. 电网技术,2015,39(4):1121-1128.

HE Xu,JIANG Xianguo,ZHANG Peichao,et al. Availability analysis of smart substation protection system considering maintenance strategies[J]. Power System Technology,2015,39(4):1121-1128.

[3] 郭丽娟,陶松梅,张炜,等. 兼顾供电可靠性和 LCC 的变电站主设备检修策略优化方法[J]. 电力系统自动化,2016,40(15):99-105.

GUO Lijuan,TAO Songmei,ZHANG Wei,et al. Maintenance strategy optimization for main equipment in substations considering both power supply reliability and life cycle cost[J]. Automation of Electric Power Systems,2016,40(15):99-105.

[4] 刘苏,姚建刚,韦亦龙,等. 基于 Monte Carlo 的主变压

器全寿命周期成本研究[J]. 电源技术,2017,41(2):312-315.

LIU Su,YAO Jiangan,WEI Yilong,et al. Life cycle cost study of main transformer based on Monte Carlo [J]. Chinese Journal of Power Sources,2017,41(2):312-315.

[5] 蔡嘉,江修波. 基于贝叶斯算法的 220 kV 变压器故障检修成本模型分析[J]. 电力科学与技术学报,2013,28(4):15-18.

CAI Jia,JIANG Xiubo. Bayesian econometrics method based maintenance cost model for 220 kV transformers [J]. Journal of Electric Power Science and Technology,2013,28(4):15-18.

[6] 黄俊宁,于群. 基于多源数据融合与设备相似性的高压开关柜评价模型[J/OL]. 高压电器:1-7[2021-04-27]. <http://kns.cnki.net/kcms/detail/61.1127.TM.20210426.1645.002.html>.

Huang Junning,YU Qun. High voltage switch cabinet evaluation model based on multi-source data fusion and equipment similarity[J/OL]. High Voltage Apparatus,1-7[2021-04-27]. <http://kns.cnki.net/kcms/detail/61.1127.TM.20210426.1645.002.html>.

[7] 钱海,贾松江,杨飞,等. 基于移动互联的继电保护设备智能运维技术研究[J]. 智慧电力,2019,47(11):60-66.

QIAN Hai,JIA Songjiang,YANG Fei,et al. Intelligent operation and maintenance technology for relay protection equipment based on mobile internet[J]. Smart Power,2019,47(11):60-66.

[8] 韩俊,谢珍建,黄河,等. 基于停电损失计算与成本分析的配电网单元制供电网格可靠性规划[J]. 智慧电力,2020,48(1):63-68+117.

HAN Jun,XIE Zhenjian,HUANG He,et al. Unit mesh reliability planning for distribution network based on outage cost calculation and cost analysis[J]. Smart Power,2020,48(1):63-68+117.

[9] 付成然,何永秀. 基于解释结构模型的变电设备实物资产效益影响因素分析[J]. 山东电力技术,2019,46(5):35-40.

FU Chengran,HE Yongxiu. Analysis on influencing factors of physical assets benefit of substation equipment based on interpretative structural model[J]. Shan-



- dong Electric Power, 2019, 46 (5): 35-40.
- [10] 李正明, 梁彩霞, 王满商. 基于 PSO-DBN 神经网络的光伏短期发电出力预测[J]. 电力系统保护与控制, 2020, 48(8): 149-154.
- LI Zhengming, LIANG Caixia, WANG Manshang. Short-term power generation output prediction based on a PSO-DBN neural network[J]. Power System Protection and Control, 2020, 48(8): 149-154.
- [11] 王宏刚, 田洪迅, 李浩松, 等. 考虑小样本统计的 BP 神经网络配电系统可靠性预测方法[J]. 电力科学与技术学报, 2019, 34(2): 40-46.
- WANG Honggang, TIAN Hongxun, LI Haosong, et al. Reliability prediction method of power system based on a BP neural network considering small samples[J]. Journal of Electric Power Science and Technology, 2019, 34 (2): 40-46.
- [12] 何廷一, 田鑫萃, 李胜男, 等. 基于蜂群算法改进的 BP 神经网络风电功率预测[J]. 电力科学与技术学报, 2018, 33(4): 22-28.
- HE Tingyi, TIAN Xincui, LI Shengnan, et al. Improved BP neural network based on Artificial Bee Colony algorithm for wind power prediction[J]. Journal of Electric Power Science and Technology, 2018, 33 (4): 22-28.
- [13] 汉京善, 吕海平, 李丹煜, 等. 基于 GA-BP 神经网络算法的输电线路舞动预警方法[J]. 电网与清洁能源, 2021, 37(4): 1-7+14.
- HAN Jingshan, LV Haiping, LI Danyu, et al. Prediction of transmission line galloping using improved BP neural network based on genetic algorithm[J]. Power System and Clean Energy, 2021, 37(4): 1-7+14.
- [14] 黄玲玲, 寻健, 王浩. 海上风机综合检修优化策略[J]. 电测与仪表, 2020, 57(22): 112-119.
- HUANG Lingling, XUN Jian, WANG Hao. Optimization strategy for comprehensive maintenance of offshore wind turbines[J]. Electrical Measurement & Instrumentation, 2020, 57(22): 112-119.
- [15] 张武军, 程远林, 周捷, 等. 基于特性分析的改进 BP 神经网络短期电力预测方法[J]. 湖南电力, 2020, 40(3): 17-22.
- ZHANG Wujun, CHENG Yuanlin, ZHOU Jie, et al. Short term power forecasting method of improved BP neural network based on characteristic analysis[J]. Hunan Electric Power, 2020, 40 (3): 17-22.
- [16] 何凯, 王剑晓, 王佳伟, 等. 基于全成本电价的电网规划方案评估与优选[J]. 中国电力, 2020, 53(3): 66-75.
- HE Kai, WANG Jianxiao, WANG Jiawei, et al. Evaluation and optimization of power network planning scheme based on total-cost price[J]. Electric Power, 2020, 53(3): 66-75.
- [17] 刘巍, 李猛, 李秋燕, 等. 基于改进遗传算法的电网投资组合预测方法[J]. 电力系统保护与控制, 2020, 48(8): 78-85.
- LIU Wei, LI Meng, LI Qiuyan, et al. Power grid portfolio forecasting method based on an improved genetic algorithm[J]. Power System Protection and Control, 2020, 48(8): 78-85.
- [18] 吕何, 孔政敏, 张成刚. 基于混合优化随机森林回归的短期电力负荷预测[J]. 武汉大学学报(工学版), 2020, 53(8): 704-711.
- LV He, KONG Zhengmin, ZHANG Chenggang. Short term load forecasting based on hybrid optimized random forest regression[J]. Engineering Journal of Wuhan University, 2020, 53 (8): 704-711.