

基于 ARIMA-BP 组合模型的智能变电站 遥测数据趋势性分析预警技术研究

周柯¹, 王晓明¹, 李肖博², 宋益¹

(1. 广西电网有限责任公司电力科学研究院, 南宁 530023; 2. 南方电网数字电网研究院有限公司, 广州 510670)

摘要: 为了基于监测数据对智能变电站二次保护装置进行故障预警, 提出了一种基于 ARIMA-BP 组合模型的智能变电站遥测数据趋势性分析预警方法。通过智能变电站继电保护故障分析, 选择装置状态趋势预警遥测数据源, 基于数据源特性分析建立 ARIMA-BP 组合预测模型, 基于 ARIMA-BP 组合预测模型及装置历史遥测数据进行装置运行趋势预测。并以某 220kV 变电站中线路保护装置的遥测数据为例进行算例分析, 结果表明 ARIMA-BP 组合模型的预测误差率比单独的 ARIMA 模型和 BP 模型分别低 5% 和 9%, 验证了 ARIMA-BP 组合模型在遥测趋势预测预警的优越性。

关键词: 智能变电站; 遥测数据; 预警系统; ARIMA 模型; BP 神经网络模型; 趋势分析

DOI: 10.15938/j.jhust.2023.01.012

中图分类号: TM773 **文献标志码:** A **文章编号:** 1007-2683(2023)01-0097-08

Research on Trend Analysis and Early Warning Technology of Smart Substation Telemetry Data Based on ARIMA-BP Combined Model

ZHOU Ke¹, WANG Xiaoming¹, LI Xiaobo², SONG Yi¹

(1. Electric Power Research Institute of Guangxi Power Grid Co., Ltd., Nanning 530023, China;

2. Digital Grid Research Institute, China Southern Power Grid, Guangzhou 510670, China)

Abstract: In order to perform fault early warning on the secondary protection devices of smart substations based on monitoring data, a trend analysis and early warning method of smart substation telemetry data based on the ARIMA-BP combined model is proposed. Based on the analysis of the relay protection failure of the intelligent substation, the remote measurement data source for the early warning of the device status trend is selected, and the ARIMA-BP combined forecasting model is established based on the analysis of the characteristics of the data source. Based on the ARIMA-BP combined forecasting model and the historical telemetry data of the equipment, the equipment operation trend prediction is carried out. Taking the remote measurement data of the line protection device in a 220 kV substation as an example, the prediction error rate of the ARIMA-BP combined model is 5% and 9% lower than that of the ARIMA model and the BP model alone. The superiority of ARIMA-BP combined model in telemetry trend prediction and early warning is verified.

Keywords: intelligent substation; telemetry data; early warning system; ARIMA model; BP neural network model; trend analysis

收稿日期: 2021-08-18

基金项目: 中国南方电网公司科技项目(GXKJXM20190610); 国家重点研发计划项目(2020YFB0906000)。

作者简介: 周柯(1979—), 男, 博士, 教授级高级工程师;

李肖博(1985—), 男, 硕士, 高级工程师。

通信作者: 王晓明(1985—), 男, 硕士, 高级工程师, E-mail: 807156806@qq.com.

0 引 言

随着电网规模的不断扩大以及电力设备自动化和智能化水平的不断提升,电力二次系统的稳定性和安全性是电力系统安全运行的重要保障^[1]。为了保证电力二次系统稳定、安全的运行,日常设备的检修工作显得尤为重要,目前绝大多数继电保护检修仍采用定期检修方式,这种检修方式不考虑设备实际运行状况,易造成过检修或检修不足,已经不再适用当今的电网发展。继电保护装置的自诊断能力随着微机保护功能的完善和发展也在不断增强,可以实现根据继电保护装置的实际情况来制定合理的检修策略,这样不仅节省大量的人力物力,同时有针对性的检修策略能够更好的保障设备的稳定运行^[2-5]。

设备持续运行过程中记录的自描述数据可以作为衡量设备某一项物理特性健康状态的状态量,通过对设备各种自描述数据进行组合分析可以判断得出设备整体的健康状态,并以此为依据来制定检修策略。实现设备状态检修一方面需要筛选获取合适的装置自描述数据,另一方面需要采用合理的数据分析方法。近年来,对于如何进行继电保护状态检修,相关业内人士做了大量的研究工作,文[6]提出对设备的电磁环境、二次回路等进行监测分析,文[7]提出对保护量采集、开关电源温度、液晶显示器等进行监测分析。但是目前的方案都是采取各种数据分析方法给出保护装置当前的检修状态^[7-9],没有对设备未来的运行状态进行预测,存在一定的缺陷和不足。

针对目前智能变电站设备状态检修研究现状,本文提出了一种基于 ARIMA(自回归移动平均模型)-BP(基于误差反向传播算法的多层前馈型神经网络算法模型)组合模型的智能变电站遥测数据趋势性分析预警方法,基于继电保护故障分析,选取继电保护状态趋势预警遥测数据源构建 ARIMA-BP 组合模型,基于遥测数据 ARIMA-BP 组合模型实现保护装置零部件故障预警,从而提醒运维人员对不符合要求的设备进行检修更换,避免因设备故障导致生产事故。并通过比较 ARIMA-BP 组合模型与单独 ARIMA 模型和 BP 模型的预测准确率,验证了 ARIMA-BP 组合模型在遥测趋势预测预警的优越性。

1 装置状态趋势预警数据源

通过对继电保护历史故障案例进行分类统计分析,可以得出保护装置的故障原因主要有元器件损坏、外部回路故障以及电源模块损坏^[10-14]。分析引起 3 种故障原因及相关的运行数据,可以确定用于装置状态趋势预警的数据源。

1) 元器件损坏分析

环境因素是影响元器件使用寿命的最主要原因,其中包含电气环境因素和自然环境因素^[15]。电气环境因素中,当装置的电源电压波动较大时候,会导致芯片等元器件损伤,加速元器件老化损坏进程;自然环境因素中,过高温度会缩短元器件使用寿命。因此装置电源电压以及 CPU 等重要部件的温度与元件检修状态密切相关。

2) 外部回路故障分析

智能变电站实现数据网络化、信息化,光缆代替传统站内的电缆,外部回路故障原因主要集中在光模块的损坏,因此纵联通道以及过程层光口模块状态与装置外部回路的检修状态密切相关。

3) 电源模块损坏分析

统计分析表明,电源模块的工作温度严重影响电源模块的使用寿命,温度过高或者过低都会降低电源的负载能力,加速电源模块的老化,甚至产生严重故障。因此电源模块的工作温度与装置电源的检修状态密切相关。

通过对继电保护的主要故障类型进行统计分析可以得出装置电源电压、电源温度、CPU 温度、光模块光强等数据能够很大程度体现保护装置检修状态。根据 IEC61850 模型规范,此类数据都会包含在装置遥测数据集中,保护装置自身会实时监测此类数据,并通过 MMS 报文将数据送到站控层网络中,通过周期性订阅保护装置遥测数据集相关的报文控制块即可周期性获取此类数据。

保护装置长时间运行产生的历史遥测数据完整记录了设备的某一物理特性,随着时间的变化过程,可以用来作为装置状态趋势预警的数据来源。因此可以通过对此类历史数据采用合理的模型算法进行趋势分析,预测数据的未来走向。通过设置检修阈值,可以预测达到检修阈值的时间点,从而提醒运维检修人员进行检修和替换,提前消除安全隐患。

2 预测模型原理

2.1 时间序列预测方法

时间序列趋势性预测分析方法是统计学常用的一种方法,通过分析和研究时间序列,提取其中规律性信息,挖掘数据的固有特性,掌握数据之间的联系,从而推断出数据的未来变化趋势^[15-17]。将时间序列分析方法应用到特定的场景,能够系统的研究分析数据的变化趋势,解决很多实际的问题。保护装置遥测数据的监测值随时间的推移而发生改变,因此遥测数据变化可以被看作是非平稳的时间序列,通过对监测数据建立时间序列模型,并以历史数据进行参数估计,可以进行模拟预测。

2.2 ARIMA 模型原理

ARIMA 模型全称为自回归移动平均模型,是时间序列预测方法的一种,是由博克斯 (Box) 和詹金斯 (JenKins) 于 70 年代初提出,它有效地结合了自回归模型 (AR) 和移动平均模型 (MA) 模型的优点,并且通过差分能够很好地处理非平稳时间序列。

p 阶自回归模型 $AR(p)$ 公式如下:

$$X_t = \sum_{i=1}^p \phi_i X_{t-i} + \omega_t \tag{1}$$

q 阶的移动平均模型 $MA(q)$ 公式如下:

$$X_t = \sum_{i=1}^q \theta_i \varepsilon_{t-i} + \omega_t \tag{2}$$

将式(1)和式(2)结合,得到自回归移动平均模型 $ARMA(p,q)$ 公式如下:

$$X_t = \omega_t + \sum_{i=1}^p \phi_i X_{t-i} + \sum_{j=1}^q \theta_j \varepsilon_{t-j} \tag{3}$$

式中: X_t 表示任意一个 t 时刻的序列值; ω_t 代表 t 时刻的随机误差; $\sum_{i=1}^p \phi_i X_{t-i}$ 表示 t 时刻的前 p 个序列值的线性组合; $\sum_{j=1}^q \theta_j \varepsilon_{t-j}$ 表示 t 时刻的前 q 个序列的白噪声累加和的线性组合。

$ARMA(p,q)$ 模型只能用于预测时间序列相对平稳的数据,对于非平稳时间序列需要进行 d 阶差分后再进行处理,由此可以得到 $ARIMA(p,d,q)$ 模型。建立 ARIMA 预测模型的流程如图 1 所示。主要包括时间序列数据的预处理、ARIMA 模型定阶及参数预判、检验诊断模型的合理性、基于建立的 ARIMA 模型进行数据预测。

2.3 BP 模型原理

BP 模型全称为基于误差反向传播算法的多层




图 1 ARIMA 建模步骤流程图

Fig. 1 Flow chart of ARIMA modeling steps




图 2 神经网络模型

Fig. 2 Neural network model

前馈型神经网络算法模型,是一种架构简单、使用方便的时间序列预测模型。BP 神经网络通过模拟人脑神经突触进行信息传递来建立数学模型,拓扑结构包含输入层、隐藏层和输出层,具体结构如图 2 所示。图中 $Z_1、Z_2、Z_3、Z_4$ 表示神经网络的输入值, w_{mp}

表示输入层第 m 个神经元与隐藏层第 p 个神经元之间的权重值, W_{pi} 表示隐藏层第 p 个神经元与输出层第 1 个神经元之间的权重值; $y_1, y_2, \dots, y_p$ 表示神经元激活函数; b_{mp} 和 b_{pi} 表示神经元之间的阈值; O_1 表示神经网络的输出值^[18-21]。

BP 模型前期的训练过程决定 BP 模型最终的预测效果。训练过程首先从输入层输入训练样本数据,把计算后的输出结果作为第一隐含层的输入,第一隐含层根据激活函数进行数据分析处理输出,输出结果作为第二隐含层的输入,循环往复直到满足输出层阈值要求后进行最终结果输出。隐含层循环的层数是根据数据量的大小以及精度要求来决定的,误差反向传播的含义是通过比较隐含层的结果与输出层阈值大小得到一个误差值,根据误差值来动态调整隐含层与输出层神经元之间的权值系数,然后逐步修正误差达到理想效果。

建立 BP 预测模型的流程如图 3 所示。主要包括样本数据的预处理、神经网络模型训练、检验诊断模型的合理性、调整模型参数、基于建立的 BP 模型进行数据预测。




图 3 BP 模型流程图

Fig. 3 Flow chart of BP modeling steps

2.4 ARIMA-BP 模型原理

组合模型是一种提升模型预测能力的常用方法,在实际模型应用过程中,由于保护装置遥测数据受到各种影响因素的影响,实际数据不仅仅包含线

性特征,也包含有非线性特征,一种模型无法很好处理所有的复杂情况。ARIMA 模型具有很好的线性拟合能力,BP 模型对于非线性关系的预测拟合表现得很好,因此将两种模型的优势结合起来,能够弥补单一模型的不足,提高预测的准确性。

ARIMA-BP 组合模型是将 ARIMA 模型和 BP 模型进行串联起来,首先建立 ARIMA 模型并进行数据预测,将预测结果作为 BP 模型的输入,真实结果数据作为 BP 模型的标准输出,以此方式来训练 BP 模型。最终测试数据先经过 ARIMA 模型的初步预测,预测结果作为训练完毕的 BP 模型的输入,最终 BP 模型输出优化后的预测结果,流程如图 4 所示。




图 4 ARIMA-BP 模型流程图

Fig. 4 Flow chart of ARIMA-BP modeling steps

3 遥测数据模型构建

3.1 时间序列数据获取

本文通过某 220 kV 变电站中在线监测设备获取某线路的保护装置 2021 年 2 月 22 日到 2021 年 3 月 8 日总共 15 天的遥测历史数据,采用其中的保护装置 CPU 温度数据作为本次实验数据。数据点时间间隔为 1 min,总共 21 600 条数据,对其中前 12 天共 17 280 条的温度数据作为训练数据进行 ARIMA 建模,后 3 天共 4 320 条的温度数据作为检测比对数据,用来检验模型预测数据的准确性。部分数据如表 1 所示。

3.2 构建 ARIMA 模型

1) 数据平稳性处理

通过时间序列数据的直观图和相关图判断数据是否符合平稳性要求。保护装置 CPU 温度绘制时间序列直观图形如图 5 所示。

表 1 保护装置 CPU 温度时间序列数据

Tab. 1 Protection device CPU temperature time series data

时间	温度 /℃	时间	温度 /℃
02-22 11:01:00	52.90	02-22 12:01:00	54.50
02-22 12:56:00	54.80	02-22 14:01:00	54.50
02-22 15:01:00	55.40	02-22 16:01:00	54.70
02-22 17:01:00	54.00	02-22 18:01:00	54.00
02-22 19:01:00	54.10	02-22 19:52:00	54.10
02-22 21:00:00	53.80	02-22 21:59:00	54.50
02-22 23:01:00	52.29	02-22 23:55:00	55.00
02-23 01:01:00	53.10	02-23 02:01:00	55.10
02-23 03:01:00	53.80	02-23 04:01:00	55.50
02-23 05:01:00	53.50	02-23 06:01:00	55.20
02-23 07:01:00	53.90	02-23 08:00:00	55.90
02-23 09:01:00	53.90	02-23 10:01:00	55.20
02-23 11:01:00	53.60	02-23 11:58:00	55.20
02-23 13:01:00	53.90	02-23 14:01:00	55.90
02-23 15:00:00	54.90	02-23 16:01:00	55.50




图 5 时间序列图

Fig. 5 Time series graph

通过分析时间序列直观图中 2021 年 2 月 22 日到 3 月 5 日的数据,可以看出保护装置 CPU 温度具有阶段性升高和降低趋势,是不平稳时间序列。图 6 和图 7 是通过 SPSS17.1 软件相关功能的运行,得到的保护装置 CPU 温度的自相关函数图和偏自相关函数图。图中可以直观看到自相关函数存在衰减的趋势,偏自相关函数也迅速衰减趋向于零,由此可以判断数据属于非平稳时间序列,需要进行差分。图 8 和图 9 是对保护装置 CPU 温度数据进行一阶差

分后的自相关函数图和偏自相关函数图,由图可见,时间序列在滞后 4 到 5 期后,基本上都在置信区间内,因此可以得出时间序列数据在进行一阶差分后满足平稳性要求,适合建立 ARIMA 模型。




图 6 差分前自相关函数图

Fig. 6 Autocorrelation function graph before difference




图 7 差分前偏自相关函数图

Fig. 7 Differential pre-partial autocorrelation function graph

2) 模型的识别与定阶

由图 8 和 9 可知,在一阶差分后,自相关和偏自相关在置信区间内,时间序列数据在进行一阶差分后满足平稳性要求,因此可以得出 $ARIMA(p,d,q)$ 模型中 $d=1$;图 8 和图 9 中清楚看到差分后的自相关系数和偏自相关系数都出现了拖尾(序列缓慢衰减现象),自相关图在滞后 5 阶之后缩小为 0,偏自相关图在滞后 4 阶和 5 阶之后缩小为 0,可以确定 $q=5,p=4$ 或者 $p=5$,从而得出几个备选模型: $ARIMA(5,1,5)$ 、 $ARIMA(5,1,4)$ 和 $ARIMA(4,1,5)$ 。根据 AIC 准则(Akaike information criterion,赤池信息准则,是衡量统计模型拟合优良性的一种标准)计算得出模型 $ARIMA(5,1,4)$ 的 AIC 值最小,拟合性能最好,并且结合 DW 检验(Durbin-Watson 检验,又称 DW 检验,是用来检验回归分析中残差的一阶自相关性的检验方法)得出模型 $ARIMA(5,1,4)$ 的 DW 值接近 2,满足自相关性条件,从而确定较优模型为 $ARIMA(5,1,4)$ 。




图8 差分后自相关函数图

Fig. 8 Autocorrelation function graph after difference




图9 差分后偏自相关函数图

Fig. 9 Differential partial autocorrelation function graph

3) 模型检验

通过对上一步得到的 ARIMA(5,1,4)模型的残差做自相关检验,得到数据的残差自相关函数图和偏自相关函数图,如图 10 所示。由图可见,残差满足条件接近于零,且残差位于有效的区间内,说明该模型残差满足白噪声平衡要求,可以用来进行数据预测。因此确定该模型为 ARIMA(5,1,4)。




图10 残差自相关函数和偏自相关函数图

Fig. 10 Residual autocorrelation function and partial autocorrelation function graph

3.3 构建 BP 模型

1) 训练样本

采用 3.1 节中的前 12 天总共 17 280 条的温度数据作为模型训练样本,时间数据作为模型的输入

值,时间对应的温度值作为模型的标准输出值。

2) 隐藏层层数设置

由于 BP 网络对于非线性数据拟合预测效果较好,三层结构的 BP 神经网络即可达到比较好的训练效果,如果隐藏层数设置过多,会导致训练过程变得十分复杂,最终出现过拟合的现象,导致数据拟合预测效果较差。因此,结合遥测数据的自身特点和不断的试验尝试,决定模型为只包含一个隐藏层的三层结构网络。

3) 确定激活函数

根据以往研究经验,Sigmoid 函数可以更好的增加网络的非线性映射能力,能够更好的补偿 ARIMA 模型对于非线性数据拟合的不足,因此决定隐藏层激活函数选择为 Sigmoid 函数。输出层激活函数根据实验拟合效果最终选择了 purelin 激活函数。

4) 模型阈值设置

根据样本数据特性,温度数据记录的最小数据位为 0.01℃,因此设置神经网络训练结束阈值条件为当误差达到 0.001 以下,或者是训练次数达到 1 000 次。

3.4 构建 ARIMA-BP 模型

参照 3.2 节建立 ARIMA 模型,其中模型的训练样本数据和 3.2 节不同,组合模型选择以前 9 天的数据为训练样本数据,然后以第 10 ~ 12 天的数据作为 ARIMA 模型的测试数据,记录模型的测试结果数据供下一步使用。

参照 3.3 节建立 BP 模型,其中训练样本数据和 3.3 节不同,组合模型选择以步骤 1) 中 ARIMA 模型第 10 ~ 12 天的预测输出数据作为训练输入数据,预测数据对应的实际温度数据作为训练标准输出数据,获取到 3 天总共 4 320 条数据作为训练样本数据,训练后得到符合要求的 BP 模型。

将前两步训练好的 ARIMA 模型和 BP 模型进行串联,最终得到 ARIMA-BP 组合模型。

4 模型的数据拟合和预测

利用上述 3 种模型,对 2021 年 3 月 6 日到 2021 年 3 月 8 日 3 天总共 4 320 条保护装置 CPU 温度数据进行预测,并将模型的预测值与实际保护装置 CPU 温度数据进行拟合对比。单独 ARIMA 模型实际值与预测值拟合如图 11 所示,单独的 BP 模型预测数据和实际数据拟合如图 12 所示,ARIMA-BP 组合模型预测数据和实际数据拟合如图 13 所示。从

这 3 张图可以看到,单独的 ARIMA 模型和 BP 模型预测的温度变化趋势和实际值大致相同,但是存在肉眼可见的误差较大时刻,而 ARIMA-BP 组合模型预测出来的数据和实际数据拟合的较好,不存在太明显的误差。




图 11 实际值与 ARIMA 预测值拟合图

Fig. 11 Fitting graph between actual and ARIMA model predicted values




图 12 实际值与 BP 模型预测值拟合图

Fig. 12 Fitting graph between actual and BP model predicted values




图 13 实际值与 ARIMA-BP 模型预测值拟合图

Fig. 13 Fitting graph between actual and ARIMA-BP predicted values

经过统计所有数据点的预测数据和实际数据的差值得到 ARIMA 模型的最大误差率和平均误差率为 12%、8% ;BP 模型的最大误差率和平均误差率为 15%、12% ;ARIMA-BP 模型的最大误差和平均误差为 5%、3%。图 14 中柱状图展示了 3 种模型的最大误差率和平均误差率的比较,ARIMA-BP 组合模型的最大误差率和平均误差率明显低于单独的 ARIMA 模型和 BP 模型。

通过上述预测结果可以得出,ARIMA-BP 模型能够较为准确的预测装置温度数据,可以通过设置装置温度阈值来进行趋势性预警,如当装置温度达到 70℃ 时候需要对装进行检修,那么可以将装置温度阈值设置为 70℃ ,若规定时间内预测装置温度会达到 70℃ ,则给出告警信息,提醒运维人员关注此设备存在安全隐患。




图 14 准确率比较

Fig. 14 Accuracy comparison

5 结 论

本文通过对智能变电站设备状态检修现状的分析研究,提出了一种基于 ARIMA-BP 组合模型的智能变电站遥测数据趋势性分析预警方法,通过提取保护装置状态趋势预警数据,采用 ARIMA-BP 组合模型对数据进行时间序列预测分析,预测保护装置的物理特性数据的未来趋势是否超过限定阈值,从而给运维检修人员提供合理的检修意见。本文以某 220kV 变电站中线路保护装置的遥测数据为例验证了所提方法的可行性,并经过统计预测数据发现 ARIMA-BP 组合模型误差率比 ARIMA 模型、BP 模型分别要低 5% 和 9% ,验证了 ARIMA-BP 组合模型预测变电站遥测数据的优越性。

参考文献:

[1] 叶楠. 继电保护装置概述及其故障检修策略[J]. 电力系统装备, 2019(22): 85.
YE Nan. Overview of Relay Protection Devices and Their Troubleshooting Strategies[J]. Power System Equipment, 2019(22): 85.
[2] 马文杰, 毛智力. 高压线路的带电作业及快速检修技术探析[J]. 山东工业技术, 2018(8): 185.
MA Wenjie, MAO Zhili. Analysis of Live Work and Rapid Overhaul Technology of High-voltage Lines[J]. Shandong Industrial Technology, 2018 (8): 185.
[3] 于新民, 田野, 赵施阳, 等. 继电保护状态检修在现

- 代电网中的应用研究[J]. 山东工业技术, 2019 (4): 201.
- YU Xinmin, TIAN Ye, ZHAO Shiyang, et al. Application Research of Relay Protection Status Maintenance in Modern Power Grid[J]. Shandong Industrial Technology, 2019 (4): 201.
- [4] 钱平, 杨松伟, 张永, 等. 面向智能变电站信息流可靠性分析方法研究[J]. 电测与仪表, 2021, 58(10): 106.
- QIAN Ping, YANG Songwei, ZHANG Yong, et al. Research on Reliability Analysis Method of Information Flow in Intelligent Substation[J]. Electrical Measurement & Instrumentation, 2021, 58(10): 106.
- [5] 叶远波, 李端超, 谢民, 等. 面向新型电力系统的智能变电站虚回路自动校验技术研究[J]. 电测与仪表, 2022, 59(7): 91.
- YE Yuanbo, LI Duanchao, XIE Min, et al. Research on Automatic Calibration Technology of Virtual Circuit in Smart Substation for Novel Power System[J]. Electrical Measurement & Instrumentation, 2022, 59(7): 91.
- [6] 刘莎. 继电保护状态数据分析及其检修安排[D]. 广州: 华南理工大学, 2018.
- [7] 薛贵宾, 钟健航. 继电保护状态检修实用性探讨[J]. 通讯世界, 2019 (6): 184.
- XUE Guibin, ZHONG Jianhang. Discussion on the Practicability of Relay Protection Status Maintenance[J]. Communication World, 2019 (6): 184.
- [8] 唐巍, 余运佳, 刘祥吉. 10 kV 继电保护状态检修及实施[J]. 装备维修技术. 2019(3): 35.
- TANG Wei, SHE Yunjia, LIU Xiangji. 10 kV Relay Protection Status Maintenance and Implementation[J]. Equipment Maintenance Technology, 2019 (3): 35.
- [9] 易妍, 方磊, 张小亮, 等. 继电保护检修方法与技术探讨[J]. 电工技术. 2019(6): 48.
- YI Yan, FANG Lei, ZHANG Xiaoliang, et al. Discussion on the Maintenance Method and Technology of Relay Protection[J]. Electro Technical, 2019(6): 48.
- [10] 胡素萍. 继电保护设备状态检修辅助决策系统设计与实现[D]. 南昌: 南昌大学, 2018.
- [11] 张晓东. 基于保信系统的继电保护在线监测评价管理系统的应用研究[D]. 北京: 华北电力大学, 2018.
- [12] 张会文. 220 kV 及以上电压输电线路的继电保护可靠性及状态检修[J]. 科学技术与工程. 2018 (17): 192.
- ZHANG Huiwen. Relay Protection Reliability and Status Maintenance of 220 kV and Above Transmission Lines[J]. Science Technology and Engineering, 2018 (17): 192.
- [13] 黄烽. 自检信息支持下的继电保护状态检修研究[D]. 福州: 福州大学, 2017.
- [14] 李孟刚, 周长生, 连莲, 等. 基于 ARIMA 神经网络的工业生产指数仿真研究[J]. 计算机科学, 2016, (S2): 554.
- LI Menggang, ZHOU Changsheng, LIAN Lian, et al. Research on Industrial Production Index Simulation Based on ARIMA Neural Network[J]. Computer Science, 2016, (S2): 554.
- [15] 赵梦鸽, 李林. 基于 ARIMA 模型的工业生产指数预测分析[J]. 经济研究导刊, 2020, 425(3): 25.
- ZHAO Mengge, LI Lin. Forecast and Analysis of Industrial Production Index Based on ARIMA Model[J]. Economic Research Guide, 2020, 425(3): 25.
- [16] 高鹏飞, 段明圆. 残差修正 GM (1, 1) 对上海工业产值预测分析[J]. 经济研究导刊, 2017(33): 88.
- GAO Pengfei, DUAN Mingyuan. Using Residual Correction GM (1, 1) to Predict Shanghai's Industrial Output Value in the Next Three Years[J]. Economic Research Guide, 2017(33): 88.
- [17] 李焱, 高强, 王勇, 等. 乘积季节模型在软件老化评估中的应用研究[J]. 电子科技大学学报, 2017 (3): 583.
- LI Yan, GAO Qiang, WANG Yong, et al. Research on the Application of Product Seasonal Model in Software Aging Assessment[J]. Journal of University of Electronic Science and Technology of China, 2017(3): 583.
- [18] 李琛, 郭文利, 吴进, 等. 基于 BP 神经网络的北京夏季日最大电力负荷预测方法[J]. 气候与环境研究, 2019, (1): 135.
- LI Chen, GUO Wenli, WU Jin, et al. Forecasting Method of Daily Maximum Electric Power Load in Beijing Based on BP Neural Network[J]. Climatic and Environmental Research, 2019, (1): 135.
- [19] 聂明谏. 基于 BP 神经网络的房地产评估研究[D]. 北京: 华北电力大学(北京), 2017.
- [20] 黄山, 姜淳. 基于 BP 神经网络算法的汇率间隔短期预测研究[J]. 科技创新与应用, 2019(32): 1.
- HUANG Shan, JIANG Chun. Research on Short-term Forecast of Exchange Rate Interval Based on BP Neural Network Algorithm[J]. Science & Technology Innovation and Application, 2019(32): 1.
- [21] 王冬冬. 基于 ARIMA 和 BP 神经网络模型的重庆市 GDP 实证分析[D]. 桂林: 广西师范大学, 2019.

(编辑: 温泽宇)