

DOI:10.3969/j.issn.1674-1951.2021.08.007

基于 KPCA 算法的电厂设备在线故障诊断研究

Research on on-line fault diagnosis and treatment of power plant equipment based on KPCA

贾志军¹, 白德龙¹, 宋燕杰², 王剑飞¹, 李春新¹

JIA Zhijun¹, BAI Delong¹, SONG Yanjie², WANG Jianfei¹, LI Chunxin¹

(1. 内蒙古京隆发电有限责任公司, 内蒙古 乌兰察布 012100; 2. 内蒙古化工职业学院, 呼和浩特 010070)

(1. Inner Mongolia Jinglong Electric Power Generation Company Limited, Ulanqab 012100, China;

2. Inner Mongolia Vocational College of Chemical Engineering, Hohhot 010070, China)

摘 要:以某 600 MW 亚临界火电机组凝结水系统为研究对象,以实现基于机器学习算法和专家知识的故障诊断和自动事故处理为目的,通过对其历史运行数据的选取、清洗建立适合数据分析和模型训练的样本集,采用核主成分分析算法搭建凝结水泵运行特性预警模型。通过模型对凝结水泵运行参数偏离正常值进行预警,并将预警结果和相关参数进行逻辑整合作为设备故障诊断的判据,最后再将判据作为自动事故处理的触发条件,实现了凝结水泵的预警、故障诊断和事故自动处理的全过程自动控制,结果表明模型对凝结水泵关键参数重构精度大于 95%,能够对凝结水泵进气和出力异常做出准确诊断,提高了凝结水系统自动控制和智能化水平,具备实际工程应用价值。

关键词:大数据;核主成分分析;故障诊断;凝结水系统;自动事故处理;机器学习;智慧电厂

中图分类号:TM 621:TK 321

文献标志码:A

文章编号:1674-1951(2021)08-0048-06

Abstract: Taking the condensate water system of a 600 MW subcritical thermal power unit as the research object, in order to realize fault diagnosis and automatic accident treatment based on machine learning algorithm and expert knowledge, the sample set suitable for data analysis and model training is established by selecting and cleaning the historical operation data, and the kernel principal component analysis algorithm is used to build the early warning model of condensate pump operation characteristics. The model is used to warn the deviation of the operating parameters of the condensate pump from the normal value, and the early warning results and related parameters are logically integrated as the criterion for equipment fault diagnosis. Finally, the criterion is used as the trigger condition for automatic accident treatment, and the whole process of automatic control of the early warning, fault diagnosis and automatic accident treatment of the condensate pump is realized. The results show that the reconstruction accuracy of the model for the key parameters of the condensate pump is greater than 95 %, which can accurately diagnose the abnormal intake and output of the condensate pump, improve the automatic control and intelligent level of the condensate system, and have practical engineering application value.

Keywords: big data; kernel principal component analysis; fault diagnosis; condensate system; automatic accident treatment; machine learning; smart power plant

0 引言

随着“两化融合”的不断深入和“新基建”的开展,智能电厂、智慧电厂的推进逐步深入^[1-4]。依托电厂运行产生的海量数据进行经济性、安全性分析和预测受到了广泛关注,其中参数预警和故障诊断是研究的重点方向。

目前主流的参数预警和故障诊断技术大多是在生产控制系统外对实时生产数据进行诊断,只能为生产运行提供分析和指导,不能直接控制生产设

备和系统,对传统运行方式的改变和生产智能化的提升作用有限,不能满足火电机组生产运行因人员结构、经济环境 and 安全形势等对智能化的迫切需求。文献[5-7]均是研究基于主成分分析和相关技术结合的故障诊断方法,但只是给出了离线故障诊断的方法,没有直接作用于生产系统。姜健^[8]提出了改进型主成分分析(Principal Component Analysis, PCA)算法,将不同工况进行分段线性化处理,再通过平方预测误差(SPE)时间阈实现故障诊断,同样没有对诊断结果与实际控制关联。文献[9]提出一种化工过程故障诊断知识自动化方法,作者基于专家知识库的故障诊断,实现了专业经验的数字化,

但缺乏大数据的支持,对异常工况的覆盖存在局限性。文献[10]改进PCA算法及数据重构在工业系统中的故障诊断研究,通过对历史故障数据进行检查实现故障检测。但在实际生产过程中故障数据过少且故障类型不全,该方法不具备故障诊断普适性。文献[11]基于残差主成分分析的多变量系统故障诊断及方法应用,可进行故障诊断但不能给出具体故障原因。

运用核主成分分析(Kernel Principal Component Analysis, KPCA)算法建立模型,运用其参数重构结果,结合专业知识进行逻辑编程实现故障诊断,由故障诊断结果触发自动事故处理流程,提供了预警、诊断和故障自动处理全流程解决方案,具有工程实用价值。

1 火电机组故障诊断方法

1.1 PCA算法基本原理

PCA算法是基于统计学的主流故障诊断方法^[12],通过对训练集数据的坐标体系变化获得新的包含训练集数据主要特征且彼此正交的低维空间,简化了原始过程特性分析的复杂程度。

样本矩阵 $X = [x(1), x(2) \dots x(m)]^T$, $x \in R^n$, m 为设备正常运行条件采样数, n 为每条数据包含的变量数,即每条记录 $x(i)$ 为 n 维向量。首先,将样本矩阵进行标准化,即将其转化成均值为0、方差为1的矩阵,并计算协方差矩阵 S

$$S = \frac{1}{m-1} X^T X. \quad (1)$$

对协方差矩阵进行奇异值分解,得到

$$S = PAP^T + \tilde{P}\tilde{\Lambda}\tilde{P}^T = \hat{S} + \tilde{S}, \quad (2)$$

式中: $\Lambda = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_n)$, λ_i 为矩阵 S 的特征值; A 和 $\tilde{A}$ 分别是各子空间对应特征向量对角矩阵; $P \in R^{n \times l}$ 为载荷矩阵; $\tilde{P} \in R^{n \times (n-l)}$ 为残差矩阵; $\hat{S}$ 为主成分子空间; $\tilde{S}$ 为残差子空间^[13]。

1.2 KPCA基本原理

PCA算法是一种线性映射方法,其忽略了参数间的高阶关系,因此对于存在非线性关系的数据往往无能为力。KPCA算法通过引入核函数,将原空间映射至高维特征空间,利用核函数运算代替高维特征空间的内积运算,简化计算过程^[14-15]。

假定存在非线性映射 $\Phi_i = \Phi(x_i)$ 将 $x(i)$ 从 n 维映射至 h 维空间 ($h > n$), 则有

$$\Phi: R^n \rightarrow R^h, x \rightarrow \Phi(x), \quad (3)$$

定义核函数

$$K(x(i), x(j)) = \Phi^T(x_i) \Phi(x_j). \quad (4)$$

相应的协方差矩阵如下

$$S_h = \frac{1}{m-1} \Phi(x)^T \Phi(x) = \frac{1}{m-1} \sum_{i=1}^m \Phi(x_i) \Phi^T(x_i). \quad (5)$$

将特征空间转化为下式求其特征值

$$\lambda \beta = (m-1) S_h \beta = \Phi(x)^T \Phi(x) \beta, \quad (6)$$

定义矩阵 A 如下

$$A = \begin{pmatrix} \Phi^T(x_1) \Phi(x_1) & \cdots & \Phi^T(x_1) \Phi(x_m) \\ \vdots & \ddots & \vdots \\ \Phi^T(x_m) \Phi(x_1) & \cdots & \Phi^T(x_m) \Phi(x_m) \end{pmatrix}. \quad (7)$$

结合式(6)和(7)有

$$\beta = \frac{\Phi^T(x) \alpha}{\lambda}, \quad (8)$$

式中: $\alpha = \Phi(x) \beta$ 。

显然,需要确保特征向量 β_i 为单位向量,即 $\beta_i^T \beta_i = 1$, 而特征向量 α_i 的模为 $\sqrt{\lambda_i}$, 故对特征向量 α_i 单位化得到

$$\omega = \alpha_i / \sqrt{\lambda_i}, \quad (9)$$

式中: $\omega_i^T \omega_i = 1$ 。

通过非线性映射及相应矩阵变换,计算矩阵 A 的载荷矩阵为 $P^l = [\beta_1, \beta_2, \dots, \beta_l]$, 并进一步分解

$$P^l = [\lambda_1^{-\frac{1}{2}} \Phi^T(x) \omega_1, \dots, \lambda_l^{-\frac{1}{2}} \Phi^T(x) \omega_l] = \Phi^T(x) P^l (\Lambda^l)^{-\frac{1}{2}}, \quad (10)$$

式中: $P^l = [\omega_1, \dots, \omega_l]$, $\Lambda^l = \text{diag}\{\lambda_1, \dots, \lambda_l\}$ 分别是矩阵 A 的主成分特征向量及主成分特征值。相应的,矩阵 A 的残差矩阵 $\tilde{P}^l$ 为

$$\tilde{P}^l = [\lambda_{l+1}^{-\frac{1}{2}} \Phi^T(x) \omega_{l+1}, \dots, \lambda_n^{-\frac{1}{2}} \Phi^T(x) \omega_n] = \Phi^T(x) \tilde{P}^l \tilde{\Lambda}^l. \quad (11)$$

对于新的测量数据 x , 其对应的映射函数为 $\Phi(x)$, 对应主成分得分矩阵 t 及残余得分矩阵 $\tilde{t}$ 为

$$t = (P^l)^T \Phi(x) = (\Lambda^l)^{-\frac{1}{2}} (P^l)^T k(x), \quad (12)$$

$$\tilde{t} = (\tilde{P}^l)^T \Phi(x) = (\tilde{\Lambda}^l)^{-\frac{1}{2}} (\tilde{P}^l)^T k(x), \quad (13)$$

式中: $k(x) = [K(x(1), x), \dots, K(x(m), x)]^T$ 。 (14)

2 建立模型

2.1 训练样本的选取

训练样本的选取直接关系到预警模型精度和性能。火电机组的运行数据具有数量大、种类多和关联性强等特点,训练样本应根据对象模型运行特性、工况和数据特点等进行选取,样本尽可能覆盖目标运行工况下的所有运行区间,在满足目标工况覆盖率的基础上考虑样本的数量和均匀性^[16-17]。

2.2 数据预处理

建立模型所用的数据来自生产系统运行的历史数据库,实际生产数据中包含工况异常和传感器异常造成的部分数据偏离正常运行区间,对模型的精度会产生不利影响,因此需要进行清洗。采用的数据清洗方法主要有有人工设定上下限进行初步处理离群值、根据变化速率进行死点剔除和用多项式绘制参数间的包络线等。数据清洗完毕后统一采用 Z-score 方法标准化^[10]。

2.3 模型训练

数据清洗完毕的训练样本集通过 KPCA 算法进行模型训练。因 KPCA 算法原理所限,对于特定设备模型搭建要结合生产经验考虑各参数间的相关性。如果选取了没有相关性的参数进行建模,不但会产生残差污染问题还会影响模型的泛化能力。

2.4 预警诊断

KPCA 算法具有模型多输入多输出的特性,能够对多个实时运行参数进行数值重构。实测值与重构值的偏差程度是模型预警的依据,需要结合运行经验设定实测值和重构值的差值作为预警的阈值。重构值的可靠性是实现预警的基础,因此需要对模型的重构值进行评测,一般是采用验证样本对整个模型进行验证,只有当验证精度满足要求时,模型的重构值才能作为预警诊断的决策数据。实际生产过程中,同一设备在不同工况下往往表现出不同的特性,受限于 KPCA 原理,单一模型很难满足全工况预警目标,因此需要根据设备不同工况分段建立模型,再组合各模型达到全工况预警的目的。

2.5 求解流程

预警模型的搭建流程主要包括样本选取、数据清洗、数据标准化、模型训练、模型校验和模型下装,如图 1 所示。模型能够对偏离正常运行区间的参数进行重构,基于重构值对参数进行预警。将多个重构参数和其他运行参数进行综合实现故障诊断,综合诊断结果触发故障自动处理控制逻辑,实现预警到故障的全过程自动处理^[18]。

3 设备介绍

以凝结水泵运行特性模型为例进行模型搭建。凝结水泵是机组汽水循环的重要组成部分,其运行的可靠与否直接关系机组运行安全。

3.1 凝结水系统工作流程

凝结水系统工作流程是汽轮机乏汽经过凝汽器进入排汽装置,通过凝结水泵升压后再经过低压加热器(低加)进入除氧器作为锅炉补给水,如图 2 所示。




图 1 模型求解流程

Fig. 1 Model solving process




图 2 凝结水系统工作流程

Fig. 2 Work flow of the condensate system

3.2 凝结水泵运行参数

凝结水泵运行特性模型要实现的功能是对凝结水泵出力异常进行诊断,而能够说明凝结水泵运行是否正常的具体参数额定值和实际运行范围见表 1。

表 1 凝结水系统参数运行范围

Tab. 1 Operating range of the condensate system parameters

项目	额定参数	运行范围
电流/A	168.0	19.0~65.0
运行频率/Hz	27.00~50.00	27.00~50.00
凝结水流量/(t·h ⁻¹)	1 870	700~1 700
凝结水泵入口压力/kPa	—	-60.0~-40.0
#5 低压加热器出口压力/MPa	—	0.80~3.50

4 实例与分析

以凝结水泵运行特性为研究对象,目的是对关

键运行参数进行重构。凝结水泵运行中有 4 种运行工况,下文选择最为常见的工况 1(单泵变频,再循环全关、旁路全开)运用 KPCA 算法建立模型。

4.1 建模参数选择

建模数的选择直接关系到模型对异常参数的诊出率、误诊率、重构精度及泛化能力,要充分考虑参数的相关性。根据凝结水泵运行特性选取了 A 凝结水泵入口压力、A 凝结水泵出口压力、凝结水精处理出口压力、A 凝结水泵电流、#5 低压加热器出口凝结水压力、凝结水流量、A 凝结水泵频率、机组负荷、给水流量 9 个具有强关联性的参数进行建模。

4.2 预警边界条件设置

生产过程中设备运行方式复杂多变,因外部边界条件的改变导致单一模型不能覆盖同一设备的所有工况,因此需要针对不同工况分别建模,再通过设定不同的边界条件达到覆盖设备所有工况的目的。凝结水泵运行特性模型根据负荷情况、设备情况以及节能情况分为 4 个独立的子模型,见表 2。

表 2 凝结水泵运行特性模型工况划分
Tab. 2 Operation mode division of the operation characteristic model for the condensate pump

工况	工况区分
1	单泵变频,再循环全关,旁路全开
2	单泵变频,再循环全关,旁路全关
3	单泵变频,再循环全开,旁路全关
4	单泵工频,再循环全关,旁路全关

4.3 样本清洗

数据清洗是模型建立的关键步骤,通过数据清洗应该将离群点、死点和非本工况下的数据清理掉。本案例对数据的清洗主要通过多项式拟合建立包络线进行数据清洗,图 3 是选择采用 #5 低压加热器出口凝结水流量和凝结水泵频率建立包络线,对机组深调区间和离群点数据进行了清洗。




图 3 数据清洗

Fig. 3 Data cleaning

4.4 预警验证

从 1 个月的历史运行数据中随机抽取 1 000 组

有效数据,并依据运行人员判断故障的经验对相关参数增加一定幅度的故障以验证模型。图 4—7 分别为凝结水泵电流故障、凝结水泵电机频率故障、#5 低压加热器出口压力故障、凝结水泵入口压力故障测试结果。结果表明,各参数故障诊出率、误诊率、重构精度均达到工程应用要求(见表 3),可作为故障诊断依据。




图 4 凝结水泵电流故障测试结果

Fig. 4 Current fault test of the condensate pump




图 5 凝结水泵电机频率故障测试结果

Fig. 5 Frequency fault test for the condensate pump motor




图 6 #5 低压加热器出口压力故障测试结果

Fig. 6 Pressure fault test at the No. 5 low-pressure heater outlet




图 7 凝结水泵入口压力故障测试结果

Fig. 7 Pressure fault test at the condensate pump inlet

表 3 凝结水泵运行特性模型测试

Tab. 3 Test of the operation characteristics model for the condensate pump

参数	故障幅度	重构偏差	重构精度/%
电流/A	5.0	0.8	97
频率/Hz	1.00	0.13	98
#5 低压加热器出口压力/MPa	0.15	0.01	97
凝结水泵入口压力/kPa	12.0	1.9	95

4.5 事故诊断及处置

根据预警结果可以编写凝结水泵气塞和凝结水系统泄漏的综合事故诊断,以下以 A 凝结水泵气塞为例,给出参数预警的故障幅度(见表 4)以及相应故障的判断逻辑(如图 8 所示)。

表 4 凝结水泵气塞故障诊断设定参数

Tab. 4 Setting parameters for the fault diagnosis of the condensate pump vent plugs

预警参数	预警值
A 凝结水泵入口压力/kPa	+12.0
A 凝结水泵电流/A	-5.0
A 凝结水泵频率增大/Hz	+1.00




图 8 凝结水泵气塞故障判断

Fig. 8 Fault diagnosis for vent plugs in the condensate pump

通过人工模拟凝结水泵气塞故障的参数变化,入口压力增加 15.0 kPa,电流降低 7.0 A,频率增加 2.00 Hz,模型及时得出凝泵气塞的诊断结果,并根

据诊断结果触发凝结水泵气塞的故障处理逻辑,试验表明该方案能够模仿监盘行为及时发现故障并自动处理故障,提升系统运行的智能化水平。

5 结论

通过运用 KPCA 算法对凝结水泵运行特性的建模,以及运用模型结果的故障诊断和自动处理,得出以下结论。

(1)KPCA 算法对关联性强的参数具有很好的重构性能,其重构精度可以满足实际工程应用要求。

(2)运用 KPCA 算法建模无法实现一个模型对某一设备的全工况预警,需要根据不同工况建立子模型,子模型的预警通过边界条件加以限制,各个子模型共同实现对特定设备的全工况预警。

(3)模型对设备的故障诊断需要大量故障工况下的历史数据,实际生产过程中数据采集难度大,采用参数预警结果加逻辑判断是实现故障诊断的可行方法。

(4)通过机器学习算法对电厂海量历史运行数据挖掘,可以有效预测系统和设备的异常,是提高电厂运行智能化的有效途径。

参考文献:

[1]张晋宾,周四维.智能电厂概念、体系架构及核心技术[J].热力发电,2019,48(9):9-13.
ZHANG Jinbin, ZHOU Siwei. Concept, architecture and core technology of smart power plant [J]. Thermal Power Generation, 2019, 48(9): 9-13.

[2]郭为民,张广涛,李炳楠,等.火电厂智能化建设规划与技术路线[J].中国电力,2018,51(10):17-25.
GUO Weimin, ZHANG Guangtao, LI Bingnan, et al. Construction planning and technical route for thermal power plant intelligentization [J]. Electric Power, 2018, 51(10): 17-25.

[3]刘吉臻,胡勇,曾德良,等.智能发电厂的架构及特征[J].中国电机工程学报,2017,37(22):6463-6470.
LIU Jizhen, HU Yong, ZENG Deliang, et al. Architecture and feature of smart power generation [J]. Proceedings of the CSEE, 2017, 37(22): 6463-6470.

[4]杨晓已,陶新磊,韩立.虚拟电厂技术现状及展望[J].华电技术,2020,42(5):73-78.
YANG Xiaosi, TAO Xinlei, HAN Li. Status and prospect of virtual power plant technology [J]. Huadian Technology, 2020, 42(5): 73-78.

[5]李晓杰,田亮.基于多尺度主元分析的磨煤机堵塞检测[J].电力科学与工程,2018,34(1):41-45.

- LI Xiaojie, TIAN Liang. Blockage detection of coal mill based on multi-scale principal component analysis [J]. Electric Power Science and Engineering, 2018, 34(1): 41-45.
- [6] 张承彪, 罗运柏, 文习山. 主成分分析在变压器故障诊断中的应用研究[J]. 高电压技术, 2005, 31(8): 9-11.
- ZHANG Cheng biao, LUO Yunbai, WEN Xishan. Study on fault diagnosis of transformer based on principal component analysis of dissolved gas [J]. High Voltage Engineering, 2005, 31(8): 9-11.
- [7] 张世荣, 程琴, 张芳芳. 基于感测线圈和KPCA的电机轴承故障检测[J]. 电机与控制应用, 2018, 45(4): 98-104.
- ZHANG Shirong, CHENG Qin, ZHANG Fangfang. Fault detection of motor bearings based on detection coils and KPCA algorithm [J]. Electric Machines & Control Application, 2018, 45(4): 98-104.
- [8] 姜健. 基于改进PCA算法的航空发动机状态诊断模型[J]. 燃气涡轮试验与研究, 2017, 30(2): 32-36.
- JIANG Jian. Modeling of aero-engine state diagnosis based on improved PCA algorithm [J]. Gas Turbine Experiment and Research, 2017, 30(2): 32-36.
- [9] 李传坤, 赵东风, 王春利, 等. 一种化工过程故障诊断知识自动化方法研究[J]. 高校化学工程学报, 2018, 32(2): 393-400.
- LI Chuankun, ZHAO Dongfeng, WANG Chunli, et al. Study on a knowledge automation method for fault diagnosis of chemical processes [J]. Journal of Chemical Engineering of Chinese Universities, 2018, 32(2): 393-400.
- [10] 杜海莲, 苗诗瑜, 杜文霞, 等. 改进主元分析方法及数据重构在工业系统中的故障诊断研究[J]. 南京理工大学学报, 2019, 43(1): 72-77, 85.
- DU Hailian, MIAO Shiyu, DU Wenxia, et al. Research on fault diagnosis of industrial process based on improved PCA method and data reconstruction [J]. Journal of Nanjing University of Science and Technology, 2019, 43(1): 72-77, 85.
- [11] 高会, 李彦平. 基于残差主元分析的多变量系统故障诊断方法及应用[J]. 沈阳大学学报(自然科学版), 2016, 28(2): 141-146.
- GAO Hui, LI Yanping. Multivariate system fault diagnosis methods and its applications based on residual principal component analysis [J]. Journal of Shenyang University (Natural Science), 2016, 28(2): 141-146.
- [12] 牛征. 基于多元统计分析的火电厂控制系统故障诊断研究[D]. 北京: 华北电力大学, 2006.
- [13] 薛盛炜, 李川, 李英娜. 改进模糊聚类与主成分分析下的变压器故障识别[J]. 河南科技大学学报(自然科学版), 2020, 41(6): 39-44, 50.
- [14] 贾子文, 顾煜炯. 基于改进的多块核主元分析的风电机组故障诊断方法[J]. 动力工程学报, 2018, 38(10): 820-828.
- JIA Ziwen, GU Yujiong. Fault Diagnosis of wind turbines based on improved multiblock kernel principal component analysis [J]. Journal of Chinese Society of Power Engineering, 2018, 38(10): 820-828.
- [15] 者娜, 杨剑锋, 刘文彬, 等. KPCA和改进SVM在滚动轴承剩余寿命预测中的应用研究[J]. 机械设计与制造, 2019(11): 1-4, 8.
- ZHE Na, YANG Jianfeng, LIU Wenbin, et al. Research on application of KPCA and improved SVM in residual life prediction of rolling bearings [J]. Machinery Design & Manufacture, 2019(11): 1-4, 8.
- [16] 高明明, 杨磊, 于浩洋, 等. 量子计算在火电机组优化控制中的应用综述[J]. 华电技术, 2020, 42(8): 90-96.
- GAO Mingming, YANG Lei, YU Haoyang, et al. Review on the application of quantum computing in optimization control on thermal power units [J]. Huadian Technology, 2020, 42(8): 90-96.
- [17] 冯泽磊, 吴美凤. 基于大数据平台的火电机组实时运行状态监测[J]. 华电技术, 2019, 41(4): 29-32, 39.
- FENG Zelei, WU Meifeng. Real-time operation monitoring of thermal power units based on big data platform [J]. Huadian Technology, 2019, 41(4): 29-32, 39.
- [18] 柴天佑. 工业过程控制系统研究现状与发展方向[J]. 中国科学, 2016, 46(8): 1003-1015.
- CHAI Tianyou. Industrial process control systems: research status and development direction [J]. Scientia Sinica (Informationis), 2016, 46(8): 1003-1015.

(本文责编: 惠忻)

作者简介:

贾志军(1981—), 男, 内蒙古呼和浩特人, 高级工程师, 从事火电运行故障诊断与应用方面的研究工作(E-mail: cctvnet@163.com)。

白德龙(1976—), 男, 山西朔州人, 正高级工程师, 从事热工控制与火电智能化方面的研究工作(E-mail: baidelong@jinglongpower.com)。

宋燕杰(1982—), 女, 内蒙古赤峰人, 讲师, 从事智慧电厂与热能与动力工程方面的研究工作(E-mail: 8925135@qq.com)。

王剑飞(1985—), 男, 辽宁凌源人, 工程师, 从事火电集控运行与故障诊断方面的研究工作(E-mail: wangjianfei@jinglongpower.com)。

李春新(1983—), 男, 内蒙古通辽人, 工程师, 从事火电集控运行与故障诊断方面的研究工作(E-mail: lichunxin@jinglongpower.com)。