

间接空冷背压预测及变频循环泵控制优化

孟宏君 张凯奇 王尚尚 李丽锋

(山西大学自动化与软件学院 山西 太原 030013)

摘要 根据山西省河坡电厂 2×350 MW 循环流化床一号机组 2019 年 7 月 15 日到 8 月 15 日电厂与背压有关的实际运行数据,通过分析其影响因素(环境温度,机组负荷,凝汽器温度、压力等),使用相关系数法和主成分分析法对数据降维,在 Python 平台上使用 Keras、TensorFlow 等库编写预测算法,建立背压预测模型,使用 RNN 神经网络对背压建模预测,分析预测结果。结合现场实际运行实验数据,辨识变频循环泵的模型,并使用模糊 PID 对其控制进行优化。

关键词 间接空冷 背压预测 变频循环泵 LSTM Python

中图分类号 TP3

文献标志码 A

DOI:10.3969/j.issn.1000-386x.2024.04.008

PREDICTION OF INDIRECT AIR COOLING BACK PRESSURE AND CONTROL OPTIMIZATION OF VARIABLE FREQUENCY CIRCULATING PUMP

Meng Hongjun Zhang Kaiqi Wang Shangshang Li Lifeng

(College of Automation and Software, Shanxi University, Taiyuan 030013, Shanxi, China)

Abstract According to the actual operation data related to back pressure of 2×350 MW circulating fluidized bed unit 1 of Hepo power plant in Shanxi Province from July 15 to August 15, 2019, by analyzing the influencing factors (ambient temperature, unit load, condenser temperature, pressure, etc.), the correlation coefficient method and principal component analysis method were used to reduce the dimension of data. On the Python platform, Keras, TensorFlow and other libraries were used to compile the prediction algorithm, and the back pressure prediction model was established. The RNN neural network was used to predict the back pressure, and we analyzed the prediction results. The model of variable frequency circulating pump was identified combining with the actual operation data, and the fuzzy PID was used to optimize its control.

Keywords Indirect air cooling Back pressure prediction Variable frequency circulating pump LSTM Python

0 引言

目前,循环流化床机组有最先进的洁净煤燃烧技术,河坡电厂率先在低劣质煤、污泥掺烧上走在了前列,对阳泉当地经济社会发展做出了贡献。其机组配备的是间接空冷塔,对季节变化不敏感,缺点是要消耗一定量的水,初期投资大,但其后期收益期限长且稳定,其经济性在不太缺水的北方有一定的优势。

本文就以间接空冷机组作为研究对象。对于阳泉

当地夏季冬季平均温度变化可达 50 °C 的特点,机组背压作为影响机组实际负荷的关键因素,对其预测和控制就显得尤为重要。葛晓霞等^[1]提出改进果蝇算法(IFOA)优化支持向量机(SVM)的方法来建立凝汽器真空预测模型,具有非常好的泛化能力,能够更好地应用于凝汽器真空的预测。王建国等^[2]采用粒子群算法(PSO)寻找 RBF 模型中的基宽和输出层权值,并给出了具体实现过程,建立了凝汽器真空软测量模型。并验证了该模型对凝汽器运行状态判断的准确性,为其故障诊断提供了参考依据。张利平等^[3]引入一种采用

PSO 算法改进的 Elman 神经网络,建立双压凝汽器真空预测模型。田松峰等^[4]针对凝汽器污垢热阻难以预测的问题,采用改进粒子群算法优化的 Elman 神经网络建立凝汽器污垢热阻预测模型。改进后的预测模型具有更好的精度和适应能力,为凝汽器污垢热阻预测和清洗时间间隔提供了理论依据。夏琳琳等^[5]为了解决单一网络预测结果不准确的问题,提出一种由 BP、Elman 及 RBF 三网络组合的预测模型。结果表明,与单一网络预测模型相比,组合预测模型的平均绝对误差和均方根误差均显著减小,融合精度更高。陈婷等^[6]通过从凝汽器传热机理和 DCS 采集的数据分析影响真空的主要因素,运用 BP 神经网络建立真空模型,通过对凝汽器真空的软测量,为凝汽器的故障诊断提出理论依据。夏琳琳等^[7]借助 KPCA 法构造 BP、RBF 和 Elman 的软测量模型,实现基于 Dempster 组合证据的凝汽器真空度多网络融合预测。王国涛等^[8]通过使用变频循环水泵,降低了厂用电,提升了经济效益。靖长财等^[9]通过分析循环水泵可靠性、控制方式、转速等问题,提出了新的变频循环水泵的运行方式。综上所述从凝汽器真空角度,基于 MATLAB 平台,应用粒子群、蚁群算法对背压进行预测的研究较多,基于现场实际的循环泵运行组合方式的实践也已经应用到了现场,但上述方法模型结构复杂,且需要迭代次数多,所预测模型的适应性不高,所取样数据不能覆盖更大的范围。本文将在已有研究的基础上,在开源平台 Python 上应用深度学习库 TensorFlow、Keras 对更大时间范围内的背压进行精准预测,使模型更具有广泛的适应能力;并结合现场运行数据辨识变频循环泵模型,单纯从循环泵控制角度并对其控制进行优化,完善对间接空冷机组冷端的相关研究。

对于河坡电厂间接空冷机组而言,当电厂进行 AGC(自动发电控制)调频时,机组的负荷就会随着指令频繁发生变化,低压缸排气随之变化,背压也变化频繁。在高温的夏季,背压过高,一旦超过机组低压缸允许的压力和温度,机组就必须降负荷运行,影响机组效益,严重时会有安全风险。在寒冷的冬季,背压过低,会造成排气温度降低,间冷循环水管有冻裂的危险,间冷塔有结冰的危险。所以背压控制直接关系到间冷机组的安全经济运行背压一旦低于阻塞背压,机组的经济效益也会受到很大的影响。

背压控制的难点在于具有迟延大、非线性、时变、影响因素多且复杂的特点。对于间接空冷机组来说,背压控制的主要手段有限,在高温的夏季,冷凝塔的散热扇区均处在全开状态,有时还会受到高温高速的自

然风影响,散热效果也是达不到设计标准。河坡电厂实际生产中控制背压的最直接的手段就是增加循环水流量,增大进入凝汽器热井的循环水流量,从而带走更多热量。本文所采集数据的电厂采用的是两台变频循环泵,为了更好地监控和控制背压,本文将在精确预测的基础上,对变频循环泵建模并改善其控制效果。

1 背压预测数据处理

影响机组背压的因素比较多,如何建立机组背压的预测模型仍是当前研究的热点。本文将依靠 Python 编译环境,使用 Keras、TensorFlow 等库,应用循环神经网络对机组背压进行预测,最后预测结果进行对比。

其中 Keras 具有高度模块化,极简和可扩充特性;支持 CNN 和 RNN,二者的结合可无缝切换 CPU 和 GPU^[10]。Tensorflow 其广泛应用于深度学习,该库涉及自然语言处理、机器翻译、图像描述、图像分类等一系列技术,为开发者封装了大量机器学习、神经网络的函数,为更好地解决问题提供了强大支撑。

首先从实际出发,从现场运行角度选取出对背压有影响的量。本文一共选取了 15 个影响因素,采样时间持续一个月,采样时间间隔为一分钟,每个影响因素采样 44 641 次,总数据量 714 256 个。对于现场采样数据,由于现场环境的影响,需要先对其进行滤波,去掉传感器测量中的噪声,去掉奇异值^[11],使得数据曲线更加平滑。图 1 给出了数据处理前后的对比,可以看出高频部分被明显减弱。




图 1 数据处理(滤波)前后对比

为了简化神经网络的模型,就需要对影响因素所采样数据进行分析,数据分析方法对后续的仿真建模非常重要,特别是对于如何分析影响背压的主要因素有哪些,对数据的输入进行降维,从而简化模型和缩短仿真的时间。在对数据初始化处理以后,本文使用两

种方法对数据进行降维。

1.1 相关系数分析法

机组背压的影响因素很多,表1给出了背压影响因素及其与背压的相关系数。本文先对各影响因素查看其分布,选择 Python 的 pandas 库^[12]进行相关系数的求解,它有 Pearson、Kendall 和 Spearman 三种算法。pearson 针对线性数据的相关性计算;Kendall 用于反映分类变量相关性的指标,即针对无序序列的相关系数,非正态分布的数据;Spearman 适用于非线性的,非正态分布的数据的相关系数。由于数据均具有非线性和非正态分布,所以这里选用 Spearman 来进行相关系数分析,分析结果如表1所示。

表1 背压影响因素及其与背压的相关系数

序号	影响因素	与背压的相关系数	排序
1	实际负荷	0.726 753	9
2	排气温度	0.937 567	3
3	热水井水位	0.339 588	12
4	凝汽器热井温度	0.949 210	1
5	循环水出口温度	0.742 087	8
6	循环水管出口水压	0.864 793	4
7	循环水入口温度	0.0391 16	14
8	循环水管入口水压	0.064 712	13
9	罗茨泵电流	-0.665 399	11
10	水环泵电流	0.767 445	7
11	凝结水泵电流	0.679 365	10
12	循环水泵1+2变频器电流	0.783 743	5
13	环境气温	0.769 890	6
14	低压缸进气流量	0.742 087	8

可以看出,与背压负相关的仅有凝汽器出口罗茨泵的电流,其余变量都与背压正相关。通过比较相关系数,结合实际生产经验同时为了减少数据量,提高训练效率,选取凝汽器热井温度、排气温度、循环水出口温度、循环水入口温度、环境气温、低压缸进气流量、凝结水泵电流、循环水管出口水压、实际负荷、循环泵电流这10个影响因素来训练模型。这里要说明的是变频循环泵整体作为一个影响因素,它既是背压的影响因素又是控制背压的极其重要的手段,相比较于14个影响因素,选取的影响因素少了四个,加预测结果背压,共15组数据。其部分数据如表2所示。

表2 350 MW 循环流化床机组凝结水系统数据

负荷/MW	排气温度/℃	热井温度/℃	循环水出口温度/℃	循环水入口温度/℃	环境温度/℃
226.455 4	51.153 1	50.549 3	49.783 6	40.792 1	24.606 0
226.429 6	51.149 1	50.555 6	49.795 0	40.779 4	24.595 1
226.403 9	51.145 1	50.562 0	49.806 5	40.766 8	24.584 2
226.378 1	51.141 0	50.568 3	49.817 9	40.754 1	24.573 3
进气流量(t/h)	凝结泵电流/A	循环水出口压力/MPa	循环泵电流/A	背压/kPa	
520.931 3	57.291 1	0.354 4	291.098 1	14.158 4	
517.423 8	60.217 8	0.354 4	291.102 6	14.158 1	
518.209 0	62.247 5	0.354 4	291.106 2	14.157 9	
516.544 9	60.876 6	0.354 4	291.108 6	14.157 6	

1.2 主成分分析法(PCA)

主成分分析法^[13]在本文仿真中主要是用于对数据进行降维,在多数实际情况中,各个变量因为有一定的先后顺序,因果关系等存在一定的相关关系,当两个变量之间有某种相关关系时,就认为它在数据上表现为特性信息的重叠,主成分分析法就是对所提出的所有影响因素,将重复的特征信息和影响小的因素去掉,建立尽可能少的新变量,使得这些新建立起来的数据每个特征间内积为0,并且这些新数据信息仍然能充分的反映原始数据集的绝大部分数据信息。

PCA 过程:

(1) 准备数据集。

(2) 将各类型数据求取平均值后,去除掉平均值:

$$x' = x - \bar{x} \quad (1)$$

(3) 计算数据集各变量之间的协方差矩阵。

$$\text{Cov}(\mathbf{X}, \mathbf{Y}) = E[(\mathbf{X} - E(\mathbf{X}))(\mathbf{Y} - E(\mathbf{Y}))] \quad (2)$$

$$\text{Cov}(\mathbf{X}, \mathbf{Y}, \mathbf{Z}) = \begin{bmatrix} \text{Cov}(x, x) & \text{Cov}(x, y) & \text{Cov}(x, z) \\ \text{Cov}(y, x) & \text{Cov}(y, y) & \text{Cov}(y, z) \\ \text{Cov}(z, x) & \text{Cov}(z, y) & \text{Cov}(z, z) \end{bmatrix} \quad (3)$$

(4) 通过奇异值分解(SVD)计算协方差矩阵的特征值和对应的特征向量。

(5) 把特征值从大到小排序,选择其中较大的 k 个特征值。然后将它们的特征向量分别作为列向量组成特征向量矩阵。

(6) 将数据转换到由 k 个特征向量构成的新空间中。

本文选取主成分最终维度为5维,相比起初的14维,影响因素明显减少。主成分分析最后得到的部分数据如表3所示。

表3 主成分分析法处理后部分数据

1 维	2 维	3 维	4 维	5 维
0.035 445	0.262 469	0.103 668	-0.006 370	-0.015 500
0.035 847	0.262 559	0.103 743	-0.006 400	-0.015 410
0.036 259	0.262 648	0.103 821	-0.006 500	-0.015 310
0.036 684	0.262 733	0.103 900	-0.006 670	-0.015 200

其各自的贡献度如下,保留小数点两位,具体如表4所示。5维数据总的贡献度为99.93%。其单纯在数据特征上已经能反映原有的数据特征。

表4 各主成分的贡献率(%)

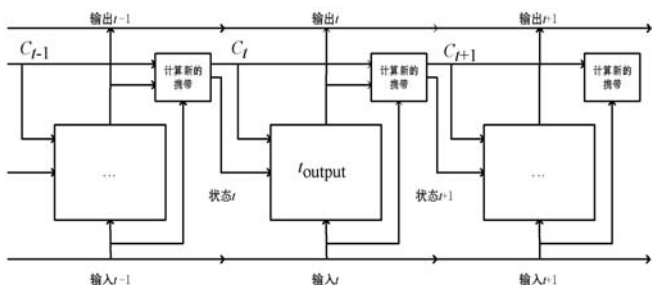
1 维	2 维	3 维	4 维	5 维
94.13	4.79	0.60	0.32	0.09

2 模型仿真与结果分析

本文将使用两种数据(相关系数法10维变量,主成分分析法5维变量),使用RNN+LSTM建模,并评估其预测结果,这里均以平均绝对误差(MAE)作为评价指标。

循环神经网络(RNN)是一种对过去状态有所记忆的一种神经网络。对于这种网络,其实现更像是人在认识事物一样,学习的时候总是带有先前的经验,特别像学习语言句子一类。循环神经网络模型是以过去的信息构建的,并伴随着新信息的进入而不断更新。对于RNN来说,其最终的输出一定程度来说就能反应其前面的所有状态。循环神经网络也适用于序列数据,传统的循环神经网络RNN容易出现梯度消失与梯度爆炸的问题,因此目前比较常用的一般是LSTM(长短期记忆)及其变种^[10]。它每次都会计算新的携带信息,方向上与所传入网络的数据平行。序列中的信息可以在任意位置跳上传送带,然后被送到更晚的时间步;如果需要,它也可以跳回原来的位置。

LSTM基本原理:保存信息以便后面使用,防止较早期的信息在处理过程中逐渐消失。LSTM基本机构如图2所示。

图2 LSEM剖析^[10]

由图2可见,携带信息的输出由三部分组成,当前状态 t_{state} 、当前输入 t_{input} 、新的信息携带 C_t 、 U_o 、 V_o 、 W_o 为权重矩阵, b_o 为偏置,则其表达式为:

$$t_{output} = activation(dot(t_{state}, U_o) + dot(t_{input}, W_o) + dot(C_t, V_o) + b_o) \quad (4)$$

循环神经网络中LSTM对具有时间属性的序列的数据很敏感,本文将选取LSTM层作为模型的构成。添加两层LSTM,层节点数分别为100、50(在神经网络建模中,节点数的选取没有理论指导,超参数优化也是当前研究的重点,本文节点数的选取经过了多次实验,综合训练时间和过拟合情况等选出),模型需要优化的参数为70 000多个,损失函数均选取均方误差(MSE),优化器选取自适应矩估计(adam),步长为144,其余参数为默认。

2.1 相关系数法+RNN循环神经网络

循环神经网络更适用于带有时间特性的量的预测,比如当地气温,本文中全部数据均取自电厂DCS系统,并且电厂运行也带有极强的时间属性,即每天AGC指令和上一天的趋势是相似的。基于RNN的这种特性,下面将使用LSTM对背压进行预测,仍然用MAE对其预测结果进行评估。迭代次数选择6次,再训练更多次,其损失降低更加不明显,该选择也是经过多次实验得出的。相比于前面介绍的神经网络预测,选取6次也正体现了LSTM对于时间序列的敏感程度。图3给出其模型的图形描述。

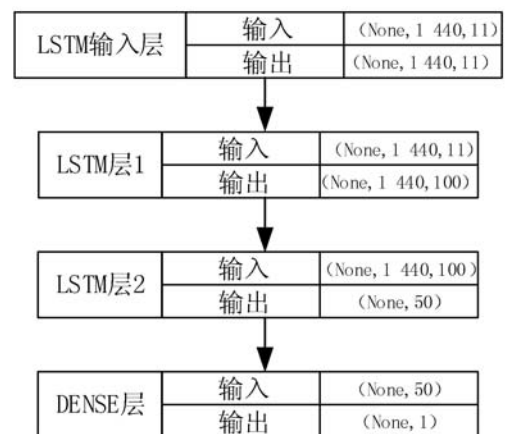


图3 相关系数法建模

训练6次以后其预测值与真实值的MAE=0.065,训练损失和预测结果如图4-图5所示,前者训练损失很快降到了0,后者展示了其7 000个数据的预测结果,大约有5天背压数据量,除了在剧烈变化部分还有一些小的误差外,其余部分表现都比较好。




图 4 相关系数分析 + RNN 训练损失




图 5 相关系数分析 + RNN 预测结果

2.2 主成分 + RNN 循环神经网络

主成分分析法所得数据在代入到 RNN + LSTM 模型以后,同样训练 6 次,其模型的图形描述如图 6 所示,得到主成分 + RNN 的训练损失和预测结果如图 7 - 图 8 所示,其 MAE = 0.033,从图 8 可以看出在一些变化大的极点处,拟合准确度相比相关系数法有所提高。

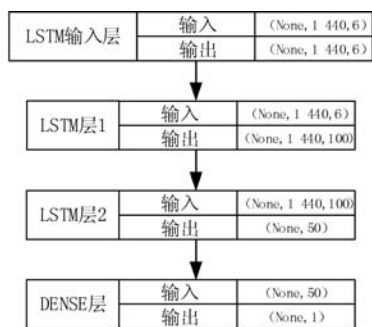


图 6 主成分分析法建模




图 7 主成分分析法 + RNN 训练损失




图 8 主成分分析法 + RNN 预测结果

2.3 背压预测结果分析

通过使用两种数据处理方法,都对背压进行了精准预测,相较于相关系数法处理数据,主成分分析法处理数据将变量维度减少到了 5 维数据,缩短了训练时间,评价指标 MAE 主成分 + RNN (MAE = 0.033) 是相关系数 + RNN (MAE = 0.065) 的 0.5 倍。从图 8 也可以看出,主成分 + RNN 的预测结果更加准确。两者都存在极点处预测结果不是很准确的现象,但误差都比较小。在实际预测中时间长度很短,预测误差可以忽略。

本文在数据处理上使用了两种方法,基于模型合成的理论^[10],其关键在于,使用不同的数据处理方法和不同的模型都会造成机器学习到的特征不同,所以将最后的结果按照好坏比例进行合成,期望得到更优的预测结果。模型合成结果如图 9 所示,通过寻找最优的权重系数,其 MAE 为 0.024 3 比主成分 + RNN 精度要更高。




图 9 模型合成结果

对于背压预测,LSTM 在复杂影响因素下表现突出,训练出的模型能够精确地预测出背压,达到了本文

对间接空冷预测背压的目的。

3 变频循环泵模型辨识及控制优化

在间接空冷机组背景下,对背压的控制手段最主要的就是循环水泵和扇区的联动,本文选取变频循环泵作为控制手段,对其进行建模,优化对其的控制。

结合现场实际,要对变频循环泵进行控制优化就要先得到变频循环泵的模式。结合现场实际,对变频循环泵整体做系统辨识。本文选取变频器的电流作为系统辨识的输入,选取循环泵出口压力作为系统辨识的输出。需要强调的是,在实际采样中并没有循环水流量这一参数,从循环泵出口到循环泵出口压力测点之间距离很短且没有阀门,所以其值可以表征循环泵的出力。当前流量的计算公式如,其中: Q 为管道流量, R 为管道半径, P 为管道压力, ρ 为介质密度。

$$Q = IIR^2 \sqrt{2P/\rho} \quad (4)$$

本文选取该厂一号机组一号变频循环泵作为辨识对象,工况选定在 19~20 MW 负荷之间,选取 2019 年 7 月 30 日运行数据,采样间隔为 1 s,采样总数 602 个,时间长度 10 min,图 10 展示了当变频器电流变化时,循环泵出口压力的变化情况,和此时对应的实际负荷和背压的变化。




图 10 模型辨识数据选取

本文将选取这样的阶跃激励信号作为系统辨识的输入,使用 MATLAB 系统辨识工具箱^[15]对系统进行辨识,通过多次实验,本文选取极点数 3,零点数 2,并加入延迟环节,系统辨识结果如图 11 所示,辨识精度达到了 95.63%。




图 11 变频循环泵辨识结果

最终得到变频循环泵的开环传递函数为:

$$G(s) = e^{-1s} \frac{0.01592s^2 + 1.584 \times 10^{-4}s + 1.523 \times 10^{-5}}{s^3 + 0.043392s^2 + 1.092 \times 10^{-3}s + 1.236 \times 10^{-5}} \quad (5)$$

为了改进变频循环泵的控制,将常规 PID 与模糊 PID 自整定^[14]进行比较,常规 PID 参数由系统 PID 控制器自整定给出 $K_P = 12.09$ 、 $K_I = 1.29$ 、 $K_D = 10.18$ 。

模糊控制器的输入为误差 e 及误差变化率 e_c ,模糊控制器的输出为 P 、 I 、 D 。根据实际的工程经验,并把其子集均定义{负大、负中、负小、零、正小、正中、正大}且简记为{NB、NM、NS、ZE、PS、PM、PB},论域范围为 $[-1, 1]$,其中 e 及 e_c 的隶属函数采用高斯分布函数型, K_p 、 K_i 、 K_d 的隶属函数采用等腰三角函数型。经过多次仿真模糊 PID 参数, $P = 28.5$ 、 $I = 0.9$ 、 $D = 0.001$ 。simulink 仿真如图 12 所示




图 12 常规 PID 与模糊 PID 仿真示意图

仿真结果如图 13 所示,从仿真结果入手,经过计算,模糊 PID 相比常规 PID,超调量减少了 12.23%,上升时间减少了 47.48%,稳定时间两者相差不大。相比常规 PID,模糊 PID 控制效果更好。




图 13 常规 PID 与模糊 PID 对比

综上所述,使用 MATLAB 系统辨识工具箱准确辨识了变频循环泵的系统模型,并对系统进行了控制优化,为进一步结合预测结果与经济背压进行控制打下了坚实的基础。

4 结 语

本文通过分析背压影响因素,使用两种数据处理方法,对数据进行降维,在 Python 平台上使用循环神经网络进行预测,得到了精度较高的背压预测模型。预测结果均优于^[1-9]的预测结果。本文还分析了间接空冷的控制手段,并且选取变频循环泵作为其控制对象,依靠数据对变频循环泵进行建模。并使用模糊 PID 进行控制优化,优化了其上升时间和超调量。对未来将经济背压引入,精确计算实际条件下循环泵出力具有重要的意义。

参 考 文 献

- [1] 葛晓霞,赵舒莹,肖洪闯,等. 基于改进果蝇算法优化 SVM 的凝汽器真空预测[J]. 热能动力工程,2020,35(11):39-45.
- [2] 王建国,林乐平. 粒子群算法与径向神经网络相结合的凝汽器真空预测模型[J]. 热力发电,2015,44(10):72-76.
- [3] 张利平,陈浩天,王伟锋,等. 应用 PSO 算法改进 Elman 神经网络的双压凝汽器真空预测[J]. 热力发电,2015,44(3):53-57.
- [4] 田松峰,吴昭延,王子光,等. 基于神经网络的凝汽器污垢热阻预测模型[J]. 热力发电,2019,48(2):78-82.
- [5] 夏琳琳,台金娟,刘惠敏,等. 权重提取与 Dempster 多重融合的凝汽器真空预测[J]. 沈阳工业大学学报,2015,37(3):329-334.
- [6] 陈婷,孟娜,王建国. 凝汽器真空的监测模型[J]. 东北电力大学学报,2012,32(3):54-58.
- [7] 夏琳琳,台金娟,文磊. 基于组合证据冲突修正的凝汽器真空度多网络融合预测[J]. 化工自动化及仪表,2015,42(12):1331-1335.
- [8] 王国涛. 循环水泵变频改造节能分析[J]. 能源与节能,2020(7):51-52.
- [9] 靖长财,张冬青. 某 1000MW 汽轮机循环水泵变频存在问题及运行优化探讨[J]. 能源科技,2020,18(2):44-46.
- [10] 弗朗索瓦肖莱. Python 深度学习[M]. 张亮,译. 北京:人民邮电出版社,2018.
- [11] 伊德里斯. Python 数据分析[M]. 韩波,译. 北京:人民邮电出版社,2016.
- [12] Stepanek H. Thinking in pandas[M]. Berkeley: Apress,2020.
- [13] Naik G R. Advances in principal component analysis[M]. Singapore: Springer,2018.
- [14] 武彬,张栾英. 模糊自整定 PID 控制在主汽温控制中的应用[J]. 计算机仿真,2015,32(2):387-390.
- [15] 吴凡,李伟雄. 基于 MATLAB 系统辨识工具的系统辨识[J]. 河北农机,2016(11):59-60.

(上接第 52 页)

方法,便捷地写出不同的客观先验,并找到最优先验,从而得到较为精确的研究结果。此外,这种思想和方法还可以推广到混合治愈模型中去,这正是本文今后研究的方向。

参 考 文 献

- [1] Lambert D. Zero-inflated Poisson regression, with an application to defects in manufacturing[J]. Technometrics,1992,34(1):1-14.
- [2] Xie F C, Wei B C, Lin J G. Score tests for zero-inflated generalized Poisson mixed regression models[J]. Computational Statistics & Data Analysis,2009,53(9):3478-3489.
- [3] 罗付岩,赵佳星. 基于零膨胀模型的我国银企关系规模影响因素研究[J]. 数理统计与管理,2017,36(2):351-360.
- [4] 李二倩,田茂再. 零膨胀泊松分布参数的固定宽度置信区间构造方法[J]. 应用概率统计,2018,34(1):49-74.
- [5] Maria M, Christina O. Is visiting the dentist a good habit? Analyzing count data with excess zeros and excess ones[M]// Working Paper, Umea Economic Studies. Västerbotten; Umeå universitet,1999.
- [6] 田震. 零一膨胀回归模型及其统计诊断[D]. 昆明:云南大学,2016.
- [7] Tang Y C, Liu W C, Xu A C. Statistical inference for zero-and-one-inflated Poisson models[J]. Statistics Theory and Related Fields,2017,1(2):216-226.
- [8] Liu W C, Tang Y C, Xu A C. A zero-and-one inflated Poisson model and its application[J]. Statistics and its Interface,2018,11(2):339-351.
- [9] 夏丽丽,田茂再. 零一膨胀泊松回归模型的非参数统计分析及其应用[J]. 数理统计与管理,2019,38(2):235-246.
- [10] Bernardo J M. Reference posterior distributions for Bayesian inference[J]. Journal of the Royal Statistical Society,1979,41(2):113-128.
- [11] Berger J O, Bernardo J M. On the development of the reference prior method[J]. Bayesian Statistics,1992,4(4):35-60.
- [12] Berger J O, Bernardo J M. Reference priors in a variance components problem[J]. Bayesian Analysis in Statistics and Econometrics,1992,177-194.