

DOI: 10.7652/xjtuxb201910002

采用卷积神经网络的电站锅炉燃烧效率建模方法

胡怀中, 张建博, 刘汉青, 李梦迪, 杨清宇
(西安交通大学电子与信息工程学院, 710049, 西安)

摘要: 针对电站锅炉燃烧效率经典建模方法精度较低的问题,提出了一种基于卷积神经网络(CNN)的新型建模方法。通过分析影响锅炉燃烧效率的各项因素,建立了以锅炉负荷、一二次风配风方式、烟气含氧量等参数为输入,锅炉燃烧效率为输出的建模数据集。由于 CNN 的核心特征是通过卷积运算从样本数据的空间关联中进行特征提取,所以为了加强输入样本数据的空间特征,利用主成分分析法(PCA)对数据进行重构。在此基础上,采用 LeNet-5 结构的 CNN 构建锅炉燃烧效率模型。仿真结果表明,经过 PCA 重构的锅炉燃烧效率 CNN 模型的检验集相对误差最小,相比经典模型减小了 19.58%,该方法为锅炉燃烧效率的优化提供了新的思路。

关键词: 电站锅炉燃烧效率;卷积神经网络;特征提取;主成分分析法

中图分类号: TP273 **文献标志码:** A **文章编号:** 0253-987X(2019)10-0010-06

Power Plant Boiler Combustion Efficiency Modeling Approach Based on Convolutional Neural Networks

HU Huaizhong, ZHANG Jianbo, LIU Hanqing, LI Mengdi, YANG Qingyu
(School of Electronic and Information Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: A novel modeling approach based on a convolutional neural network (CNN) is proposed to solve low precision problem of the classical modeling approaches for combustion efficiency of power plant boilers A data set for modeling is established through analyzing factors affecting boiler combustion, and operation parameters including the boiler load, the primary and secondary air distribution, the oxygen content in flue gas are taken as inputs and the combustion efficiency is an output. Since the core characteristic of CNN is to extract features from the spatial association among sample data by convolution, the input data are reconstructed by principal component analysis (PCA) method to enhance its spatial features. On this basis, the CNN with LeNet-5 structure is adopted to build the boiler combustion efficiency model. Simulation results and comparisons with some classical modeling methods show that the relative error of the proposed model for boiler combustion efficiency on testing set is minimal, and the relative error reduces by 19.58%. This novel modeling approach provides a new idea for the optimization of boiler combustion efficiency.

Keywords: power plant boiler combustion efficiency; convolutional neural networks; feature extraction; principal component analysis

随着我国电力技术的发展以及可持续发展观念的深入,提高锅炉燃烧效率已经成为现今各个电厂的研究热点,燃烧优化技术是解决电站锅炉高效燃烧与经济运行的最有效方法之一。目前,电站锅炉的燃烧优化技术主要是基于分布式控制系统,通过人工智能技术建立锅炉燃烧效率模型,采用各种启发式算法进行优化,从而实现锅炉的燃烧效率提升^[1-4]。电站锅炉是一个具有大延迟、非线性、强耦合等特性的多输入多输出对象,所以如何建立一个精确、完善的电站锅炉燃烧效率模型成为燃烧优化技术的关键。文献[5-10]基于 BP 神经网络对某台 300 MW 锅炉飞灰含碳量进行建模,建立了锅炉热效率和锅炉相关运行参数之间的函数关系,由于受到 BP 神经网络自身的限制,其训练速度较慢、易陷于局部最优;文献[11-12]将支持向量机(SVM)算法引入配煤和燃烧优化的建模过程中,在 15 个工况下进行了预测,具有良好的泛化能力,但是对于大样本数据,SVM 算法的建模精度不高,容易出现过拟合现象;文献[13]采用了径向基函数(RBF)神经网络方法对电站锅炉燃烧系统进行建模,与 BP 神经网络方法相比,RBF 神经网络方法具有全局逼近能力,而且结构简单、结构参数可实现分离学习、收敛速度快,但是 RBF 神经网络方法选取训练样本作为径向基函数中心点,对样本的噪声抵抗能力较差,模型的准确性依然不太理想。

近年来,深度学习理论发展迅猛,吸引了大批学者的关注与研究^[14-15]。与经典神经网络模型相比,卷积神经网络(CNN)模型作为深度学习理论中一种广泛应用的典型网络模型,具有更加优秀的特征学习与泛化能力。CNN 模型稀疏连接、权值共享、降采样等特性不仅有效地减少了训练参数数量、降低了网络复杂度,而且使得 CNN 模型具有强鲁棒性和高容错能力,对数据样本的噪声具有一定的抵抗力^[16]。CNN 模型在很多传统建模问题上取得了准确率的显著提升,例如无人机系统辨识^[17]、金融预测^[18]、车杆摆动系统辨识^[19]、切割机器人动态模型建模^[20]等建模难题。本文针对河南某 600 MW 超临界机组锅炉,在对锅炉的历史运行数据进行分析的基础上,采用一种经过主成分分析法(PCA)数据重构的 CNN 模型对锅炉燃烧效率进行建模。

1 锅炉燃烧效率的影响因素

1.1 锅炉燃烧效率的计算

在锅炉运行中,煤燃烧放出的热量不可能完全

得到有效利用,有的热量被排烟、灰渣带走,有的热量透过炉墙损失了,这些损失的热量,称为锅炉热损失。锅炉的燃烧效率取决于锅炉各项热损失的大小,是评价锅炉运行经济性的重要指标。

锅炉燃烧效率的计算一般采用反平衡法,即通过测定锅炉的各项热损失计算锅炉燃烧效率

$$\eta = 1 - \sum_{i=2}^6 q_i \quad (1)$$

式中: q_i 代表锅炉的各项热损失, $i=2$ 为排烟损失, $i=3$ 为化学不完全燃烧热损失, $i=4$ 为机械不完全燃烧损失, $i=5$ 为锅炉散热损失, $i=6$ 为其他热损失。

1.2 锅炉燃烧效率的主要影响因素分析

一般来说,由于大容量的锅炉排烟量较大、烟温较高,排烟损失 q_2 在锅炉各项热损失中占比最大。影响排烟损失 q_2 的主要因素为排烟量和排烟温度,对于特定的煤种组成成分,排烟处的烟气含氧量(烟气中氧气的质量分数)以及灰渣平均可燃物的含量直接影响到实际排出的排烟量。化学不完全燃烧热损失 q_3 是指一氧化碳未完全燃烧造成的热损失,由排烟处的烟气含氧量决定。在所有热损失中,机械不完全燃烧损失 q_4 的占比仅次于排烟损失,主要由煤种的水分、灰分、挥发分含量,排烟处的烟气含氧量与锅炉负荷所决定。在锅炉结构确定的情况下,影响锅炉散热损失 q_5 的因素主要是锅炉的实际负荷,其他热损失 q_6 一般可以忽略不计。

影响锅炉燃烧效率的因素主要包括锅炉设计参数、燃用煤质特性及锅炉运行参数 3 个方面。锅炉设计参数包括锅炉容量、炉膛主要尺寸、炉膛结构及燃烧方式等;燃用煤质特性包含煤的组成成分、煤的低位发热量及煤粉细度等;锅炉运行参数包含负荷、一次风初温、二次风配风方式、烟气含氧量等。通常情况下,锅炉设计参数与燃用煤质特性一旦选定不会轻易改变,因此影响锅炉燃烧效率的主要因素为锅炉运行参数。

1.3 锅炉燃烧效率建模数据选取

本文以河南某钢厂 600 MW 超临界机组锅炉为研究对象,对该锅炉的燃烧效率进行建模。该锅炉为东方锅炉集团与日本日立-巴布科克公司联合设计的 600 MW 超临界机组锅炉,采用单炉膛、一次中间再热、前后墙对冲的燃烧方式。炉膛前后墙各布置了 3 层煤粉燃烧器,相应配置 6 台中速磨煤机,最上层燃烧器的上部布置了燃尽风喷口。根据锅炉的运行参数,选取了 3 层风门开度、2 个燃尽风

门开度、6 个磨煤机给煤量、负荷、总给煤量、总风量、环境温度、烟气含氧量共计 19 个参数作为燃烧效率模型的输入量,锅炉燃烧效率作为模型的输出

量。所有锅炉燃烧效率建模数据选自锅炉历史稳态运行数据,共计 261 组,部分数据见表 1。

表 1 部分锅炉燃烧效率数据样本

负荷 /MW	A 风门 开度/%	B 风门 开度/%	E 风门 开度/%	燃尽风门 1 开度/%	环境温度 /℃	F 风门 开度/%	D 风门 开度/%	C 风门 开度/%	燃尽风门 2 开度/%	总风量 /m ³ · h ⁻¹	总燃料量 /t
480	99	34	21	45	15.8	96.3	31.9	0.2	47.7	1 624	219
276	64	18	1	31	15.7	63.4	19.0	0.2	30.3	1 156	129
326	78	13	1	40	15.6	78.9	12.1	0.0	39.3	1 234	146
270	64	28	1	27	15.1	63.4	28.8	0.0	24.9	1 118	129
604	99	42	35	51	16.3	99.4	43.9	37.3	50.8	2 018	264
278	74	10	1	32	15.4	73.4	9.4	0.0	35.9	1 147	128

A 磨煤机给 煤量/kg · h ⁻¹	B 磨煤机给 煤量/kg · h ⁻¹	C 磨煤机给 煤量/kg · h ⁻¹	D 磨煤机给 煤量/kg · h ⁻¹	E 磨煤机给 煤量/kg · h ⁻¹	F 磨煤机给 煤量/kg · h ⁻¹	烟气含氧量 平均值/%	锅炉燃烧 效率/%
54.8	46.8	0.0	48.6	48.2	45.2	3.180	93.101 17
38.1	33.7	0.0	34.7	0.0	37.1	5.495	92.937 85
45.4	39.4	0.0	39.5	0.0	36.8	4.430	93.540 7
38.5	33.7	0.0	34.9	0.0	37.5	5.350	92.977 43
54.2	49.7	40.4	50.8	48.2	49.9	3.545	92.412 88
37.1	33.7	0.0	34.8	0.0	36.4	5.450	92.951 88

2 锅炉燃烧效率 CNN 模型

2.1 锅炉燃烧效率 CNN 模型结构

CNN 模型最早应用于图像处理,并且取得了显著的效果。与经典神经网络的全连接方式相比,CNN 模型凭借着稀疏连接、权值共享、降采样等特性,很好地解决了经典神经网络中因为忽略了局部特性而产生过拟合的问题。CNN 模型能够充分挖掘数据本身的局部特征,对网络进行更好地优化,从而具有更强的建模能力,因此本文使用 CNN 模型来对锅炉燃烧效率进行建模。

采用 LeNet-5 结构的卷积神经网络对锅炉燃烧效率进行建模,LeNet-5 结构如图 1 所示,包含 2 个

卷积层、2 个池化层、2 个全连接层^[21]。每一个卷积层都包含多个卷积核,卷积核重复作用在输入的特征图上,对其进行卷积操作,经过激活函数后得到输出的特征图。卷积层的数学表达式为

$$c_j^l = \sum_{i \in M_j} o_j^{l-1} * k_{ij}^l + b_j^l \tag{2}$$

$$o_j^l = g(c_j^l) \tag{3}$$

式中: c_j^l 为网络卷积层第 j 个卷积核的输出; o_j^l 表示第 l 层网络第 j 个神经元的输出; k_{ij}^l 为卷积核矩阵; b_j^l 为偏移量; $g(\cdot)$ 为激活函数。在卷积层进行特征提取后,输出的特征图被传递至池化层进行特征选择和信息过滤。池化层包含预设定的池化函数,池化层的作用是用特征图中节点相邻区域的统计特征代替节点的输出值。池化层的数学表达式为

$$p_j^l = \beta_j^l \text{down}(o_j^{l-1}) + b_j^l \tag{4}$$

$$o_j^l = g(p_j^l) \tag{5}$$

式中: p_j^l 为第 l 层池化层第 j 个池化函数的输出; β_j^l 为池化层权重系数;down($\cdot$)为池化函数。

CNN 模型中的全连接层等价于经典神经网络中的隐含层。全连接层搭建在 CNN 模型的最后部分,并只向其他全连接层传递信号。

全连接层的数学表达式为

$$f_j^l = g(\alpha_j^l o_j^{l-1} + b_j^l) \tag{6}$$




图 1 锅炉燃烧效率 CNN 模型 LeNet-5 结构图

式中: f_j^l 为第 l 层全连接层第 j 个神经元的输出; α_j 为全连接层权重系数。

2.2 锅炉燃烧效率建模数据重构

由于 CNN 模型的建模效果依赖于样本空间的数据分布,而本文研究对象锅炉燃烧效率数据之间分布规律并不明显,为了加强数据的空间特性,采用主成分分析法对锅炉燃烧效率建模数据进行重要性重构^[22]。PCA 算法是多元统计分析中常用的方法之一,它能将数据投影到另一正交空间,使得投影后的数据按照重要程度排布,而且投影后的数据互不相关,原始数据的全部信息也能得到保留。

假设锅炉燃烧效率建模数据为一个 $n \times m$ 的矩阵 $\mathbf{X}$, $\mathbf{X} = [x_1, x_2, \dots, x_m]$, 其中矩阵的每一列对应于一个变量,每一行对应于一个样本。将矩阵 $\mathbf{X}$ 的每一列去均值,归一化得到标准化矩阵为

$$\bar{\mathbf{X}} = \left[\frac{x_1 - \bar{x}_1}{\sigma_1}, \frac{x_2 - \bar{x}_2}{\sigma_2}, \dots, \frac{x_m - \bar{x}_m}{\sigma_m} \right] \quad (7)$$

式中: $\bar{x}_i$ 、 σ_i 分别为第 i 列变量的均值和方差。协方差矩阵表达式为

$$\mathbf{G} = \bar{\mathbf{X}}^T \bar{\mathbf{X}} \quad (8)$$

将 m 维数据投影为 k 维 ($k \leq m$) 数据,问题可以转化为最小化问题

$$\left. \begin{aligned} \min \quad & \| \bar{\mathbf{X}} - \mathbf{V}\mathbf{V}^T \bar{\mathbf{X}} \|^2 \\ \text{s. t.} \quad & \mathbf{V}^T \mathbf{V} = \mathbf{I}_k \end{aligned} \right\} \quad (9)$$

式中: $\mathbf{I}_k$ 为 $k \times k$ 的单位矩阵; $\mathbf{V}$ 为协方差矩阵 $\mathbf{G}$ 的前 k 个特征向量,被称为数据矩阵 $\bar{\mathbf{X}}$ 的主成分,特征向量 $\mathbf{V}$ 对应的特征值 λ 反映了特征向量的重要性。

将锅炉燃烧效率建模数据经过 PCA 重构,重构后样本数据的每一列向量特征值 $\lambda = [11.988\ 2, 2.448\ 0, 1.158\ 7, 0.938\ 8, 0.634\ 9, 0.517\ 2, 0.353\ 5, 0.320\ 5, 0.238\ 3, 0.167\ 0, 0.107\ 9, 0.064\ 6, 0.019\ 1, 0.013\ 7, 0.012\ 0, 0.009\ 4, 0.005\ 7, 0.001\ 8, 0.000\ 7]$ 。从向量特征值 λ 可以看出,前 12 维数据基本能够包含原始数据的全部信息。由于本文采用 PCA 算法的目的是数据重要性重构,而不是降维处理,因此将重构后的全部数据用于 CNN 模型的训练与检验。

2.3 模型的建立与验证

本文构建的锅炉燃烧效率 CNN 模型的卷积层 Conv1 卷积核个数为 50,卷积核大小为 1×11 ;卷积层 Conv2 卷积核个数为 100,卷积核大小为 1×5 ;全连接层 Fc1 神经元个数为 50,全连接层 Fc2 神经元个数为 20。激活函数为 ReLU 函数,池化函数为最大值池化函数。将锅炉燃烧效率建模数据按照负



荷大小排序,均匀挑选其中 174 组数据作为训练集,余下 87 组数据作为检验集。建模数据经过 PCA 重构后对 CNN 模型进行训练与检验,建模效果如图 2a 所示。

为了验证锅炉燃烧效率 CNN 模型的有效性,选取了 BP 神经网络、RBF 神经网络、SVM 3 种经典模型作为对比,采用与 CNN 模型相同数据进行建模,建模效果如图 2b~图 2d 所示。



另外,为了验证 PCA 重构对 CNN 建模效果的影响,采用未重构的数据对 CNN 模型进行训练与检验,建模效果如图 2e 所示。各建模方法训练集与检验集的相对误差见表 2。

从图 2a~图 2d 与表 2 中数据可以看出:基于 BP 神经网络的建模方法训练集与检验集相对误差较大,建模效果不理想;基于 SVM 的建模方法出现了过拟合现象,虽然其训练集相对误差极小,但是检验集相对误差较大;RBF 神经网络在 3 种经典建模方法中表现最好,其检验集相对误差最小。


RBF 神经网络模型检验集相对误差为 0.019 4,




(a) PCA-CNN




(b) BP 神经网络



(c)RBF 神经网络



(d)SVM



(e)未重构 CNN

图 2 PCA-CNN、未重构 CNN 与 3 种经典建模方法的建模效果

与 RBF 神经网络模型相比,PCA-CNN 模型检验集相对误差减少了 19.58%,与经典网络模型相比,锅炉燃烧效率 CNN 模型具有更加优越的建模能力。特别地,未经数据重构的 CNN 模型训练集与检验

集相对误差都与 BP 神经网络模型相近,说明未经 PCA 重构的 CNN 模型无法发挥模型优势,只有经过 PCA 重构后 CNN 模型才能具有更好的建模能力。

表 2 PCA-CNN、未重构 CNN 与经典建模方法建模效果对比

方法	训练集相对误差	检验集相对误差
PCA-CNN	0.001 6	0.015 6
BP 神经网络	0.009 5	0.021 1
RBF 神经网络	0.003 8	0.019 4
SVM	0.002 5	0.020 2
未重构 CNN	0.009 7	0.021 1

3 结 论

与经典网络模型相比,CNN 网络作为深度学习理论中一种广泛应用的典型网络,具有良好的泛化能力、强鲁棒性、易于训练与优化等诸多优越特性。本文针对河南某 600 MW 超临界机组锅炉,提出了一种经过 PCA 数据重构的锅炉燃烧效率 CNN 建模方法。从锅炉的运行参数中选取 3 层风门开度、2 个燃尽风门开度、6 个磨煤机给煤量等共计 19 个参数作为燃烧效率模型的输入量,对锅炉燃烧效率进行建模。建模结果表明,本文方法建模效果有显著提升,其训练集相对误差最小,训练精度达到了 0.001 6,与 3 种经典建模方法中建模效果最好的 RBF 神经网络相比,本文提出的建模方法检验集相对误差减少了 19.58%,具有很好的工程应用价值。

参考文献:

[1] YU Tingfang, LIAO Lei, LIU Ran. Prediction of NO_x emissions from coal-fired boilers based on support vector machines and BP neural networks [J]. Nature Environment and Pollution Technology, 2017, 16(4): 1043-1049.

[2] 王培红, 李磊磊, 陈强, 等. 人工智能技术在电站锅炉燃烧优化中的应用研究 [J]. 中国电机工程学报, 2004, 24(4): 184-188.

WANG Peihong, LI Leilei, CHEN Qiang, et al. Research on application of artificial intelligence to combustion optimization in a coal-fired boiler [J]. Proceedings of the CSEE, 2004, 24(4): 184-188.

[3] 杨兵. 电站锅炉预测控制与燃烧优化研究 [D]. 合肥: 中国科学技术大学, 2006: 45-60.

[4] 孙伟. 基于改进模糊神经网络的电站锅炉燃烧系统建

- 模及优化控制研究 [D]. 南京:东南大学, 2017: 26-43.
- [5] 曹庆才, 高德欣, 刘芳. 基于神经网络与遗传算法的锅炉燃烧优化系统设计 [J]. 自动化技术与应用, 2016, 35(6): 10-14.
- CAO Qingcai, GAO Dexin, LIU Fang. Design of boiler combustion optimization system based on neural network and genetic algorithm [J]. Techniques of Automation & Application, 2016, 35(6): 10-14.
- [6] 徐齐胜, 罗胜琪, 陶欣, 等. 基于神经网络遗传算法的锅炉燃烧优化系统 [J]. 自动化与仪表, 2014, 29(6): 30-32.
- XU Qisheng, LUO Shengqi, TAO Xin, et al. Optimizing combust system for the boiler based on neural network and genetic algorithm [J]. Automation and Instrumentation, 2014, 29(6): 30-32.
- [7] 赵敏. 基于神经网络的电厂锅炉燃烧系统建模及优化研究 [D]. 杭州: 浙江大学, 2010: 21-47.
- [8] 王春林. 大型电站锅炉配煤及燃烧优化的支持向量机建模与实验研究 [D]. 杭州: 浙江大学, 2007: 76-97.
- [9] 周昊. 大型电站锅炉氮氧化物控制和燃烧优化中若干关键性问题的研究 [D]. 杭州: 浙江大学, 2004: 189-219.
- [10] 王子杰, 李健, 孙万云. 基于神经网络和遗传算法的锅炉燃烧优化方法 [J]. 华北电力大学学报(自然科学版), 2008, 35(1): 14-17.
- WANG Zijie, LI Jian, SUN Wangyun. Boiler combustion optimization based on neural network and genetic algorithm [J]. Journal of North China Electric Power University (Natural Science Edition), 2008, 35(1): 14-17.
- [11] 郑立刚. 煤粉射流的高温空气燃烧特性与燃煤锅炉低 NO_x 燃烧优化研究 [D]. 杭州: 浙江大学, 2009: 134-160.
- [12] 李勤道. 基于炉内参数测量的燃烧系统优化运行理论与技术的研究 [D]. 北京: 华北电力大学, 2013: 28-69.
- [13] 李智. 电站锅炉燃烧系统优化运行与应用研究 [D]. 沈阳: 东北大学, 2005: 42-57.
- [14] LECUN Y, BENGIO Y, HINTON G. Deep learning [J]. Nature, 2015, 521(7553): 436-444.
- [15] LI Haoxiang, LIN Zhe, SHEN Xiaohui, et al. A convolutional neural network cascade for face detection [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2015: 5325-5334.
- [16] 段艳杰, 吕宜生, 张杰, 等. 深度学习在控制领域的研究现状与展望 [J]. 自动化学报, 2016, 42(5): 643-654.
- DUAN Yanjie, LV Yisheng, ZHANG Jie, et al. Deep learning for control: the state of the art and prospects [J]. Acta Automatica Sinica, 2016, 42(5): 643-654.
- [17] 陈绍冯. 基于深度辨识模型的无人直升机自适应控制 [D]. 合肥: 中国科学技术大学, 2018: 39-54.
- [18] 张贵勇. 改进的卷积神经网络在金融预测中的应用研究 [D]. 郑州: 郑州大学, 2016: 50-70.
- [19] LENZ I, KNEPPER R, SAXENA A. DeepMPC: learning deep latent features for model predictive control [M] // Robotics: Science and Systems. Cambridge, MA, USA: The MIT Press, 2015: 108-117.
- [20] ANDERSON C W, LEE M, ELLIOTT D L. Faster reinforcement learning after pre-training deep networks to predict state dynamics [C] // Proceedings of the 2015 International Joint Conference on Neural Networks. Piscataway, NJ, USA: IEEE, 2015: 1-7.
- [21] 周飞燕, 金林鹏, 董军. 卷积神经网络研究综述 [J]. 计算机学报, 2017, 40(6): 1229-1251.
- ZHOU Feiyan, JIN Linpeng, DONG Jun. Review of convolutional neural network [J]. Chinese Journal of Computers, 2017, 40(6): 1229-1251.
- [22] OU Jun, LI Yujian, SHEN Chengkai, et al. Unlabeled PCA-shuffling initialization for convolutional neural networks [J]. Applied Intelligence, 2018, 48(12): 4565-4576.
- [本刊相关文献链接]**
- 刘丹, 周熙宏, 杨冬, 等. 燃煤电站锅炉炉膛结渣特性计算分析. 2019, 53(9): 150-158. [doi: 10.7652/xjtuxb201909020]
- 梁志远, 桂雍, 赵钦新. 超临界二氧化碳条件下 3 种典型耐热钢腐蚀特性实验研究. 2019, 53(7): 23-29. [doi: 10.7652/xjtuxb201907004]
- 邢超, 张晓明, 赵亚琳, 等. 利用图像信息熵差检测炉渣碳质量分数. 2018, 52(8): 49-53. [doi: 10.7652/xjtuxb201808008]
- 林宗虎. 中国燃煤锅炉节能减排技术近况及展望. 2016, 50(12): 1-5. [doi: 10.7652/xjtuxb201612001]
- 朱晓静, 毕勤成. 垂直上升内螺纹管中高压汽水-水两相流截面含汽率的测量. 2015, 49(3): 50-55. [doi: 10.7652/xjtuxb201503009]

(编辑 武红江)