

基于深度学习的矿井电力短期负荷预测方法

王怀志,高德欣

(青岛科技大学 自动化与电子工程学院, 山东 青岛 266061)

摘要:短期电力负荷预测能准确评估出煤矿的整体电力负荷变化情况,保证煤矿供电系统的安全与可靠运行。由于煤矿电力负荷预测受多种因素影响,难以实现精确预测,文章针对此问题,基于深度学习理论,提出了一种卷积神经网络(CNN)和双向门控循环单元(BiGRU)相结合的矿井电力短期负荷预测方法,并用于煤矿的实际电力负荷预测中。首先,构建了煤矿电力负荷预测的混合学习模型;然后,给出了数据处理方法,设计了模型评判指标,搭建了仿真平台并进行了多种算法的分析与对比;最后,基于组态软件开发了电力监控与预测系统,并应用于煤矿实际监控中。经现场试验表明,设计的方法可以实现对矿井短期电力负荷的准确预测,为煤矿电力系统的安全运行提供准确的决策支撑。

关键词:深度学习;短期负荷预测;煤矿供电;双向门控循环单元;监控平台

中图分类号:TD602

文章编号:1000-0682(2024)01-0051-06

文献标识码:B

DOI:10.19950/j.cnki.CN61-1121/TH.2024.01.012

Mine power short-term load forecasting method based on deep learning

WANG Huaizhi, GAO Dexin

(School of Automation and Electronic Engineering, Qingdao University of Science and Technology, Shandong Qingdao 266061, China)

Abstract: Short-term power load forecasting can accurately evaluate the change of the whole power load in coal mine, and ensure the safe and reliable operation of the power supply system in coal mine. Due to the influence of many factors, it is difficult to achieve accurate prediction of coal mine electric load prediction. To solve this problem, this paper proposes a short-term mine electric load prediction method based on deep learning theory, which combines convolutional neural network (CNN) and bidirectional gated cycle unit (BiGRU), and applies it to the actual coal mine electric load prediction. Firstly, the hybrid learning model of coal mine power load forecasting is constructed. Then, the data processing method is given, the model evaluation index is designed, the simulation platform is built, and a variety of algorithms are analyzed and compared. Finally, based on the configuration software, the power monitoring and forecasting system is developed and applied to the actual monitoring of coal mine. The field test shows that the proposed method can accurately predict the short-term power load of the mine and provide accurate decision support for the safe operation of the coal mine power system.

Keywords: deep learning; short-term load forecasting; coal mine power supply; BiGRU; monitoring platform

收稿日期:2023-09-06

基金项目:山东省自然科学基金资助项目(ZR2022ME194);
矿能源科技项目(kj20210001)

第一作者:王怀志(1999—),男,黑龙江哈尔滨人,硕士研究生,
研究方向为人工智能、优化控制。E-mail:1281765408@qq.com

通信作者:高德欣(1978—),男,山东青岛人,博士,教授,研究
方向为人工智能、优化控制、电动汽车充电技术等。

E-mail: qdgaodexin@126.com

0 引言

电力是煤矿的大动脉,为了煤矿正常生产,必须保证煤矿供电系统的正常运行,电力设备的安全

是作为高危行业的煤矿业的重要要求^[1]。短期电力负荷预测能准确评估整体电力负荷变化情况^[2-4],为矿井电力系统运行决策提供准确参考,也有助于制定适当的备用和维护计划,降低运维成本。

近年来国内外短期电力负荷预测方法有很多,例如传统数学统计学方法,如多元线性回归^[5-7]、卡尔曼滤波^[7]等。优点是预测方法模型简单效率高。缺点是在应对参数过多的数据时,预测效果显著下降。尤其对于随机性高的数据,效果并不理想。使用机器学习方法的电力负荷预测^[8-11]却可以弥补这一点。文献[12]使用 CNN 网络进行风力发电功率预测,较统计方法和传统 BP 神经网络预测效果更佳。文献[13]改进结合 CNN-GRU 这一组合模型,对光伏电站的电压轨迹进行了预测,结果表明该组合模型的预测精度优于单一模型。文献[14]使用了改进的双向门控循环单元 BiGRU 对短期负荷进行了预测,结果表明双向循环门控单元相比普通门控循环单元,在电力负荷预测上效果更好。

因此文章提出了一种融合 CNN 和 BiGRU 的混合模型,利用 CNN 网络挖掘历史数据的深层特征,再结合了 BiGRU 网络进行双向短期电力负荷预测,构建煤矿电力短期负荷预测模型;同时设计了一套基于上位机组态软件的综合解决方案,实现了对矿井电力负荷数据的实时采集和预测,并应用于煤矿实际监控中,为煤矿电力系统的安全运行提供准确的决策支撑。

1 基于 CNN 机制的 BiGRU 算法

1.1 卷积神经网络 CNN

CNN 模型是一种由卷积层、池化层和输出层组成的深度前馈神经网络^[15-17],特征提取能力强,可大幅度减少训练过程中的参数数量,提高模型训练速度,用于提取藏在负荷数据中的深层特征。

1.2 门控循环单元 GRU

GRU 神经网络的出现,改善了 RNN 会梯度消失和梯度爆炸的问题,能够更好地挖掘数据中潜在的信息,与 LSTM 相比^[18],结构更简单,能够保持良好的预测结果,并且提高了训练模型的速度。GRU 内部结构如图 1 所示。




图 1 GRU 内部结构

GRU 中, z_t 代表更新门,即矿井前一时刻的负荷数据,对当前时刻的影响程度。 r_t 代表重置门,即矿井前一时刻负荷数据被忽略的程度,具体计算公式如下:

$$r_t = \sigma(W_r x_t + U_r h_{t-1} + b_r) \quad (1)$$

$$z_t = \sigma(W_z x_t + U_z h_{t-1} + b_z) \quad (2)$$

$$\tilde{h}_t = \tanh(W_{h1} x_t + (r_t \odot h_{t-1}) W_{h2} + b_h) \quad (3)$$

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \quad (4)$$

$$y_t = \sigma(W_o \odot h_t) \quad (5)$$

式中: h_t 为 t 时刻的 GRU 隐藏状态; y_t 为 t 时刻矿井的电力负荷预测输出; σ 和 \tanh 为激活函数, W_r 、 W_z 、 U_r 、 U_z 、 W_{h1} 和 W_{h2} 为矿井电力负荷数据深层特征的权重参数, b_r 、 b_z 和 b_h 为矿井电力负荷数据深层特征的偏差参数, \tilde{h}_t 为 t 时刻矿井电力的 GRU 候选状态,其由重置门 r_t 、 $t-1$ 时刻矿井电力的 GRU 隐藏状态 h_{t-1} 以及当前时刻矿井电力负荷输入 x_t 共同控制^[19]。

1.3 双向门控循环单元 BiGRU

BiGRU 在传统 GRU 上进行了改进,可以同时向前向和后向的值作为下一时刻的输入, BiGRU 模型结构如图 2 所示。在短期负荷预测中,当前时刻的输出,与前、后一时刻的信息都有潜在的关联。因此文章选择使用 BiGRU 模型来学习矿井短期电力负荷特征的变化规律。




图 2 BiGRU 网络结构

与单向 GRU 相比, BiGRU 会同时考虑前后数据的变化规律,所以 BiGRU 可以更好地挖掘数据的时序特征。

BiGRU 的网络结构表^[20] 式如下:

$$\vec{h}_t = GRU(x_t, \vec{h}_{t-1}) \quad (6)$$

$$\overleftarrow{h}_t = GRU(x_t, \overleftarrow{h}_{t-1}) \quad (7)$$

$$h_t = w_t \vec{h}_t + v_t \overleftarrow{h}_t + b_t \quad (8)$$

式中: w_t 为 t 时刻矿井电力负荷数据深层特征的前向隐层 GRU 的输出权重; v_t 为 t 时刻矿井电力

负荷数据深层特征的后向隐层 GRU 的输出权重; h_t 为 t 时刻电力负荷 BiGRU 的隐藏状态; b_t 为 h_t 对应的偏置量。

1.4 混合模型 CNN - BiGRU 设计

单一模型在长时间序列或多维输入数据面前, 仍然存在序列特征信息丢失, 多维特征挖掘不够充分的问题, 所以又将多种模型和组合起来对短期电

力负荷进行预测, 通过结合不同模型特点与优势更好地满足短期电力负荷预测的实际需要, 在大多数情况下, 组合模型预测精度均高于单一模型^[21]。

为了实现对矿井电力负荷数据的充分提取和利用, 设计了一种融合 CNN 和 BiGRU 的混合模型, 即 CNN - BiGRU 模型, 如图 3 所示。

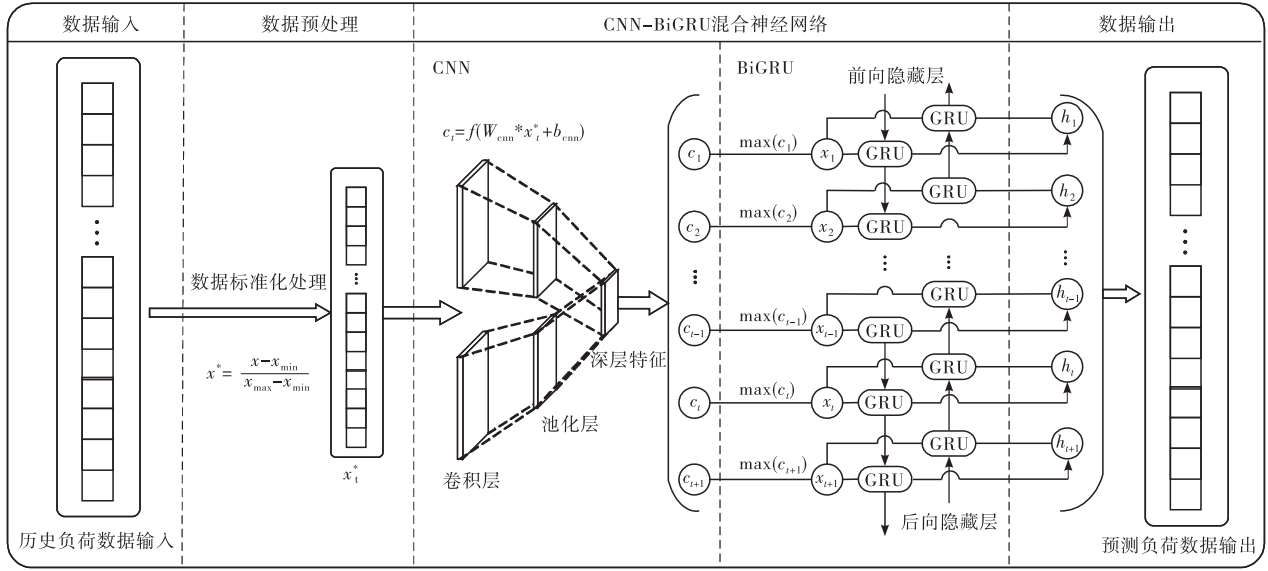


图3 矿井电力负荷预测参数预测的 CNN - BiGRU 混合模型结构图

首先, 对煤矿电力的历史负荷数据, 进行数据标准化处理。然后将处理后的数据输入到 CNN 卷积神经网络中, 经过池化层和卷积层的处理以增强网络的特征提取能力。最终将 CNN 卷积神经网络的输出输入到 BiGRU 神经网络中进行预测, 以获得未来短期电力负荷的预测值。

该模型中 CNN 主要负责负荷时间序列数据的特征提取, 而 BiGRU 则主要负责对矿井短期电力负荷进行预测。通过这种方式, 可以更好地利用矿井电力负荷数据的时序性和关联性特征, 提高预测精度。

2 数据处理及评价指标

2.1 缺失值异常值处理

在模型训练前期处理数据的异常值和缺失值是非常必要的。在这种情况下, 对异常值处理和数据缺失值填充可以有效提高数据的准确性和可靠性, 从而提高预测的精度和准确性。

在数据处理中, 处理缺失数据一般用“ - ”表示空缺值, 处理空缺数值的方法有很多种, 常用的方法有中位数填充、众位数填充、固定值填

充、均值填充和拉格朗日插值法。文中采用 Python 中 `df.isnull()`、`sum()` 函数检测数据集的空缺值^[22]。

对电力负荷数据异常值, 采取均方值法进行剔除处理。计算公式如下:

$$\begin{cases} \bar{x} = \sum_{i=1}^n \frac{x_i}{n} \\ \delta^2 = \sum_{i=1}^n \frac{(x_i - \bar{x})^2}{(n-1)} \end{cases} \quad (9)$$

式中: x_i 为某一时刻电力负荷数据的原始数值; \bar{x} 为选取的电力负荷数据的均值; δ^2 为选取的电力负荷数据的均方值。若 $|x_i - \bar{x}| > 3\delta$, 则判断为异常值点, 进行剔除处理。

2.2 数据标准化处理

文中采用 `min - max` 标准化^[23], 将原始数据 x 进行线性变换, 将数据大小等比缩放到到 $[0, 1]$ 范围内, 变换公式为:

$$x^* = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (10)$$

式中: x^* 为标准化后的值; x_{\max} 为样本数据中的最大值; x_{\min} 为样本数据中的最小值。

2.3 模型评价指标

实验选取平均绝对百分误差 $MAPE$ 、均方根误差 $RMSE$ 和决定系数 R^2 来作为模型训练精度衡量指标。 $MAPE$ 和 $RMSE$ 的值越小,表示预测精度越高,模型拟合效果越好。 R^2 越大说明模型拟合度越好。计算公式如下:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|P_{\text{predict}} - P_{\text{real}}|}{P_{\text{real}}} \quad (11)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (P_{\text{predict}} - P_{\text{real}})^2} \quad (12)$$

$$R^2 = 1 - \sum_{i=1}^n \frac{(P_{\text{real}} - P_{\text{predict}})^2}{(P_{\text{real}} - \bar{P}_{\text{real}})^2} \quad (13)$$

式中: n 为数据样本数; P_{predict} 、 P_{real} 分别表示为矿井电力负荷的预测值、真实值; \bar{P}_{real} 为整体样本的平均值。

3 实验结果分析

3.1 实验平台搭建

实验软件环境为 Python3.8, Tensorflow2.4.1, 计算机的硬件配置为 Inter(R) Core(TM) i5-7400, 16GB 内存, GPU 为 NVIDIA GTX1050Ti 4G DDR5, 以 Keras 深度学习网络框架搭建 CNN-BiGRU 模型。

3.2 多种预测模型对比

为了表明所设计的模型在矿井电力负荷预测中的效果更好,将与其他用于负荷预测的 LSTM、GRU、BiGRU 等方法进行对比。

数据来源为山东某煤矿采区的区域电力负荷,采取了一个月的负荷值,选取频率为每小时 4 次。每日 96 个点,共 2976 个负荷值,将数据集的前 80% 作为训练集,后 20% 作为测试集。

表 1 矿井电力负荷不同模型的预测结果

模型方法	R^2	$MAPE$	$RMSE$	准确度
LSTM	0.988	3.561	0.027 82	0.944 7
GRU	0.990	3.330	0.025 96	0.949 6
BiGRU	0.991	3.866	0.024 69	0.945 8
CNN-BiGRU	0.992	3.064	0.022 26	0.955 3

根据表 1 所示,文中设计的模型准确度最高,达到了 95.53%。 $MAPE$ 与其他模型相比分别降低了 16.22%、8.68%、26.17%, $RMSE$ 分别降低了 24.97%、16.62%、10.91%。

文章中提出的 CNN-BiGRU 模型对比其他三种模型,在预测精度方面有了显著的提高。图 4 为

当日负荷不同模型的预测值与实际值对比的折线图,图 5 为局部放大图,以更直观地看出模型预测结果的差异。

可以看出,文中所选择的模型整体贴合度最好,引入 CNN 网络后,预测曲线在真实数据变化时跟随能力强,相比其他单一的预测模型,对功率数据的变化趋势跟踪的更好。




图 4 矿井电力负荷不同模型预测结果图




图 5 预测结果局部放大对比图

通过负荷预测实验结果表明,在煤矿电力负荷中,使用了 CNN-BiGRU 网络的负荷预测,效果最好。由于 CNN 网络的加入,使得电力负荷数据中潜在的关联被挖掘,提高了数据的预测能力。结合 BiGRU 双向网络提取数据时序特征,从而有效提高预测精度。

4 模型应用

为了将矿井短期电力负荷模型投入实际应用、及时预测未来负荷值,文章提出了一种 Python 深度学习模型与上位机组态软件相结合的应用方案。该方案主要包括以下两部分:

(1) Python 深度学习模型的构建

采用 CNN-BiGRU 模型作为深度学习模型的核心,针对矿井电力负荷进行建模,用于提供准确的电力负荷预测,并设计可视化 GUI,使短期电力负荷预测模型成为一个可交互程序,运行在客户端的

后台。

(2) 上位机组态软件的开发

为了更好地实现模型的实时应用,文中提出了一种基于上位机组态软件的解决方案。该软件可以实现对矿井电力负荷数据的实时采集和处理,并将处理后的数据实时反馈给深度学习模型进行预测,从而实现对矿井电力负荷的实时预测。

4.1 基于 Python 的模型设计与系统开发

为能够实时观测负荷预测情况,使用 Python 中的 Tkinter 库设计了神经网络短期负荷预测程序的 GUI,为用户提供一个可视化的操作窗口。使其可持续在客户端的后台运行,用于实时负荷预测,运行结果如图 6 所示。




图 6 基于 Python 的电力负荷预测趋势图

4.2 基于组态软件的电力监控与负荷预测系统设计

基于组态王 7.5SP4 版本的上位机软件,根据设计需求开发了能耗负荷监控平台。该平台能够实时检测各区域的用电情况,并生成数据报表。通过该平台,可以更加全面地了解能耗情况,为能源管理提供科学依据。



图 7 基于组态王的煤矿负荷监控平台

组态软件将实时电力负荷数据传送给预测模型进行预测,预测结果将被返还给组态界面进行展示,以使用户了解未来用电负荷的情况,如图 8 所示,将神经网络预测模型应用于实际监控平台中。




图 8 基于组态王的电力负荷预测曲线图

5 结论

针对煤矿电力短期负荷问题,文中提出了一种基于 CNN - BiGRU 的短期负荷预测模型。利用 CNN 挖掘数据集的深层特征,并将其送入 BiGRU 网络中,以完成对矿井短期电力负荷的预测。实验结果表明,CNN - BiGRU 预测模型与 LSTM、GRU、BiGRU 预测模型相比准确度最高,达到了 95.53%,MAPE 相比其他模型分别降低了 16.22%、8.68%、26.17%,RMSE 分别降低了 24.97%、16.62%、10.91%。

文章设计的预测模型不仅实现了对矿井电力负荷的精确和实时预测,还与煤矿电力监控系统相结合,解决了算法的实际应用问题,具有一定理论意义和实用推广价值。

参考文献:

- [1] 吴君. 基于改进的灰色模型的煤矿电力短期负荷预测[J]. 测控技术, 2018, 37(09): 26 - 28.
- [2] 郭傅傲, 刘大明, 张振中, 等. 基于特征相关分析修正的 GPSO - LSTM 短期负荷预测[J]. 电测与仪表, 2021, 58(06): 39 - 48.
- [3] 王琨, 高敬更, 张勇红, 等. 基于 LSTM 神经网络的复合变量电动汽车充电负荷预测方法技术研究[J]. 工业仪表与自动化装置, 2019(01): 27 - 31.
- [4] 赵茂胜, 段嘉琪, 肖政杰. 基于 PSO - RBF 的短期电力负荷预测模型[J]. 电子设计工程, 2023, 31(14): 127 - 131.
- [5] 董维振, 陈燕, 李媛媛. 基于多元逐步回归的带钢性能预测模型[J]. 工业仪表与自动化装置, 2022(02): 107 - 111.
- [6] 王宝财. 基于温度近因效应的多元线性回归电力负荷预测[J]. 水电能源科学, 2018, 36(10): 201 - 205.
- [7] 宋娟, 廖尚泰. 基于 BP 神经网络与多元线性回归的短期燃气负荷预测[J]. 宁夏工程技术, 2019, 18(04): 343 - 346.
- [8] 戴礼灿, 刘欣, 张海瀛, 等. 基于卡尔曼滤波算法展开的飞行目标轨迹预测[J]. 系统工程与电子技术,

- 2023,45(06):1814-1820.
- [9] 李萍. 基于 BP 和多项式拟合模型在电力系统短期负荷的研究[J]. 工业仪表与自动化装置,2018(05):135-138.
- [10] 徐晴,周超,赵双双,等. 基于机器学习的短期电力负荷预测方法研究[J]. 电测与仪表,2019,56(23):70-75.
- [11] 李大中,李颖宇. 基于深度学习与误差修正的超短期风电功率预测[J]. 太阳能学报,2021,42(12):200-205.
- [12] 查雯婷,杨帆,陈波,等. 基于 CNN 的区域风功率预测方法[J]. 计算机仿真,2021,38(05):318-323.
- [13] 冯裕祺,李辉,李利娟,等. 基于 CNN-GRU 的光伏电站电压轨迹预测[J]. 中国电力,2022,55(07):163-171.
- [14] 曾囡钧,肖先勇,徐方维. 基于小波变换与 BiGRU-NN 模型的短期负荷预测方法[J]. 电测与仪表,2023,60(06):103-109.
- [15] HU Y, ZHANG Q. A hybrid CNN-LSTM machine learning model for rock mechanical parameters evaluation[J]. Geoenergy Science and Engineering, 2023:225.
- [16] WANG Delu, GAN Jun, MAO Jinqi, et al. Forecasting power demand in China with a CNN-LSTM model including multimodal information[J]. Energy, 2023, 263(PE).
- [17] 范士雄,刘幸蔚,於益军,等. 基于多源数据和模型融合的超短期母线负荷预测方法[J]. 电网技术,2021,45(01):243-250.
- [18] HOU Jingwei, WANG Yanjuan, ZHOU Ji, et al. Prediction of hourly air temperature based on CNN-LSTM[J]. Geomatics, Natural Hazards and Risk, 2022, 13(1).
- [19] 乔石,王磊,张鹏超,等. 基于时间模式注意力机制的 GRU 短期负荷预测[J/OL]. 电力系统及其自动化学报:1-9[2023-06-05].
- [20] 董雪,赵宏伟,赵生校,等. 基于二次分解和多目标优化的超短期海上风电功率预测[J]. 高电压技术,2022,48(08):3260-3270.
- [21] 朱凌建,荀子涵,王裕鑫,等. 基于 CNN-BiLSTM 的短期电力负荷预测[J]. 电网技术,2021,45(11):4532-4539.
- [22] 梁宏涛,王莹,刘红菊,等. 基于注意力机制的 CNN-BiGRU 短期光伏发电功率预测[J]. 计算机测量与控制,2022,30(06):259-265.
- [23] 刘倩倩,刘钰山,温烨婷,等. 基于 PCC-LSTM 模型的短期负荷预测方法[J]. 北京航空航天大学学报,2022,48(12):2529-2536.

(上接第 41 页)

上,最后分别测试上游安装直管和安装弯管时流量计的性能(主要关注重复性和示值误差差值这两个技术指标)。试验结果表明装有 10 片起旋器的整流器性能优于装有 8 片起旋器的整流器,缩短了上游直管段长度,减少了单弯管引起的误差偏差值。该文的意义在于给出了整流器设计的理论依据、整流器性能的优化过程,对于设计气体超声波流量计整流器的从业人员有一定的帮助。

参考文献:

- [1] 鲍敏. 影响气体超声波流量计计量精度的主要因素研究[D]. 杭州:浙江大学,2004.
- [2] 陈炜刚. 气体超声波流量计非理想流场分析与补偿方法[D]. 杭州:浙江大学,2015.
- [3] 田顺佳. 不同整流器对超声波流量计计量的影响[J]. 油气储运,2021,40(7):780-790.
- [4] 章圣意. 气体超声波流量计整流装置设计与仿真分析[J]. 自动化仪表,2021,42(3):8-11.

- [5] 万勇. CFD 流动调整器性能评价方法研究[J]. 中国测试,2016,42(6):33-36.
- [6] 陈红. 超声波流量计整流器设计及验证[J]. 自动化仪表,2018,39(7):91-94.
- [7] 用气体超声流量计测量天然气流量:GB/T 18604-2014[S]. 2014.
- [8] 熊光德. 流动调整器对气体流量计量的影响[J]. 天然气与石油,2009,27(4):34-37.
- [9] 杨运旅. 基于 CFD 的流动调整器性能评价方法研究与安装优化[D]. 广州:华南理工大学,2017.
- [10] 陈国宇. 超声流量计声道设计与调整器流场优化方法研究[D]. 广州:华南理工大学,2018.
- [11] 厉胜男. 气体超声波流量计流场分析及整流器设计[D]. 成都:电子科技大学,2021.
- [12] 朱国俊. 典型扰流流场对超声流量计计量性能的影响研究[D]. 北京:北京化工大学,2022.
- [13] 姚平. 复杂流场下气体超声波流量计测量精度提升方法[D]. 杭州:浙江大学,2018.