

# 基于 LSTM-Attention 融合的电力客户 主动服务推荐方法

张 帝<sup>1</sup>, 王 韬<sup>3</sup>, 朱吉然<sup>1</sup>, 唐海国<sup>1</sup>, 张志丹<sup>1</sup>, 唐小伟<sup>2</sup>, 颜宏文<sup>3</sup>

(1. 国网湖南省电力有限公司电力科学研究院, 湖南 长沙 410007; 2. 长沙理工大学电气与信息工程学院, 湖南 长沙 410114;  
3. 长沙理工大学计算机与通信工程学院, 湖南 长沙 410114)

**摘 要:**为提升用电水平,借助人工智能技术进行电力客户主动服务是必然趋势。针对电力行业中在客户主动服务方面的研究不足,提出一种基于 LSTM-Attention 融合的电力客户主动服务推荐方法。该方法能够有效地解决单一深度学习模型在服务推荐当中出现的梯度弥撒以及梯度爆炸等问题。本文首先建立从电力投诉工单提取客户潜在服务需求的模型;进而获得基于 LSTM-Attention 融合算法的电力客户主动服务推荐方法;最后采用某市电力客户投诉工单实例随算法和模型进行验证。实验表明本文方法正确有效。

**关 键 词:**主动服务推荐;电力投诉;潜在服务需求;LSTM-Attention

DOI:10.19781/j.issn.1673-9140.2022.02.025 中图分类号:TM-9 文章编号:1673-9140(2022)02-0213-06

## Active service recommendation method for power customers based on LSTM-Attention fusion

ZHANG Di<sup>1</sup>, WANG Tao<sup>3</sup>, ZHU Jiran<sup>1</sup>, TANG Haiguo<sup>1</sup>, ZHANG Zhidan<sup>1</sup>,  
TANG Xiaowei<sup>2</sup>, YAN Hongwen<sup>3</sup>

(1. Electric Power Science Research Institute, State Grid Hunan Electric Power Co., Ltd., Changsha 410007, China; 2. School of Electrical & Information Engineering, Changsha University of Science & Technology, Changsha 410114, China; 3. School of Computer and Communication Engineering, Changsha University of Science & Technology, Changsha 410114, China)

**Abstract:** In order to improve the level of electricity consumption, it is an inevitable trend to use artificial intelligence technology to provide active service to electricity customers. Under the background, an active customer service recommendation method is proposed based on LSTM-Attention fusion considering the lack of research on active customer service in the power industry. The proposed method can effectively solve the problems of gradient mass and gradient explosion in the service recommendation of a single deep learning model. Firstly, a model is established for extracting potential service demands of customers from electric power complaint work orders. Then, an active service recommendation method is obtained for electric power customers based on the LSTM-Attention fusion algorithm. Finally, an electric power customer complaint work order in one city is included to verify the algorithm and model. It is shown that this method is effective.

**Key words:** active service recommendation; electricity complaint; potential service needs; LSTM-Attention

电网企业因其行业的特殊性,本身拥有大量的客户群体及历史用电数据,且提供的传统电力服务是全面的。但随着电力体制深入改革及售电侧放开,大量资本涌入电力市场并展开激烈的市场竞争,电网企业不再具有垄断地位,电力客户的购电对象选择也变的多样化<sup>[1]</sup>。为此,全方位了解用户需求,提供迎合电力用户需求的主动优质服务是及其必要且可行的,不断稳固且提高电力用户的保有量,也是提高市场竞争力的必要手段。与传统 95598 派工工单方式相比,主动服务主要通过提取用户特征,从而发现用户的潜在需求,进而为用户推荐服务。目前,在主动服务主动推荐方面算法方面,较著名也最常用的算法是协同过滤推荐算法<sup>[2-5]</sup>。按照主动服务推荐应用对象划分,可将其分为基于项目与基于用户的 2 种不同的协同过滤推荐算法,二者原理相似,主要优点在于简单有效、便于理解,但缺点也十分明显,具有推荐精度较低、冷启动等问题。

随着人们在信息技术领域的不断探索,深度学习技术已经得到了巨大的发展,并在各行各业大放异彩,在推荐系统方面,由于深度学习模型的使用,能够极大地克服传统推荐方法的不足。文献[6]利用深度学习算法进行用户行为推荐,能克服矩阵分解和协同过滤的数据稀疏性以及过拟合问题;文献[7]在推荐系统中应用了深度学习,提出一种多交互的混合推荐模型,能够聚合考虑多维度的评分信息,具有更好的推荐性能;文献[8]构建了基于深度神经网络和卷积神经网络的混合推荐模型,能够更深层次的获取隐式信息反馈,有效提高推荐性能;文献[9]将 BP 神经网络应用于窃电检测,其结果十分理想,在提高窃电检测准确率的同时,也有效地降低了管理线损;针对风力发电中风况不可控原因,文献[10]将小波神经网络应用于风力发电机故障预测,其实现结果证明方法能有效预测其故障发生。在电力行业中,深度学习主要应用于保障供电可靠性、电力设备稳定性等方面,对电力服务方面的研究探索较少<sup>[11-12]</sup>。

由于应用于电力客户主动服务推荐的数据是时序的,循环神经网络在时间特征序列特征中具有更优良的预测及推荐性能<sup>[12]</sup>。实际应用中由于其结构设计,对于时间长久的信息记忆力不足,无法建立

长期依赖,从而导致特征提取不充分,长短时间记忆网络(long short-term memory, LSTM)具有更好的性能,在数据间建立长期依赖。注意力机制(attention mechanisms)能够对 LSTM 进行优化处理,能更好应用于主动服务推荐<sup>[13-14]</sup>。为此,本文提出一种 LSTM-Attention 融合算法的电力客户主动服务推荐,基于投诉工单数据构建客户潜在需求模型,并利用实际数据进行仿真分析。

## 1 基于 LSTM-Attention 融合算法

LSTM 隶属于循环神经网络(recurrent neural network, RNN),是一种改良过的 RNN,与 RNN 相比,LSTM 在原有的 RNN 上增加了 3 个门控单元:输入门、忘记门以及输出门,其主要解决了 RNN 所存在的固有问题<sup>[15]</sup>。LSTM 的结构与 RNN 不同,其增添了特殊的隐层结构,通过增加隐层单元,从而能够更加有效地与长久信息建立长期依赖,是目前应用最为广泛的循环神经网络模型。同时结合 Attention 机制的优越性能,从而提高模型的准确度。

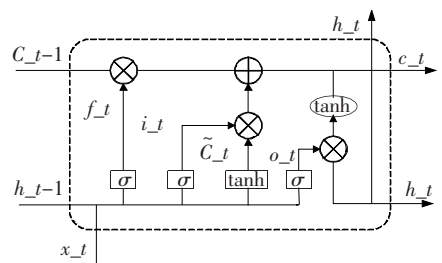


图 1 LSTM 单元结构

Figure 1 LSTM cell structure

## 2 电力投诉工单提取客户潜在服务需

本文采用 C 市的电力数据,其主要来源为电力服务工单,每条数据都有用户编号、用户性别、台区信息、服务类别等相关信息。以台区信息属性为例,台区属性为文字信息,不易进行直接输入,因此,对其进行编码处理,每个台区拥有自己独立的编码,输入数据为原始数据,数据输入嵌入层(embedding layer),主要目的是将数据向量化,经嵌入完成后, $\mathbf{X} = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n)$ ,其中  $\mathbf{x}_i$  表示用户对第  $i$  个项目类型的交互特征向量。

项目特征嵌入完成后将其输入特征提取层,本层采用的是 LSTM 神经网络进行特征提取,输入数据为特征嵌入输出数据  $\mathbf{X} = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n)$ 。

以  $\mathbf{X}_t$  为例,即  $\mathbf{X}_t$  表示  $t$  时刻用户对项目交互数据,  $\mathbf{X}_t$  进入特征提取层,即进入 LSTM 神经网络当中,  $f_t$  表示结构中的忘记门,  $\mathbf{W}_f$  为其所属的权值矩阵,  $\mathbf{h}_{t-1}$  为  $t-1$  时刻用户的状态,  $\mathbf{b}_f$  为忘记门中的偏移值。忘记门采用 sigmoid 函数,该门控单元将根据  $t$  时刻输入数据与  $t-1$  时刻的用户状态进行对比,即根据用户前一时刻状态,对当前数据进行对比,从而筛选有用数据,即

$$f_t = \sigma(\mathbf{W}_f[\mathbf{h}_{t-1}, \mathbf{X}_t] + \mathbf{b}_f) \quad (1)$$

同时输入的  $\mathbf{X}_t$  数据与  $\mathbf{h}_{t-1}$  也会传入输入门  $f_i$ , 输入门同样采用 sigmoid 函数作为激活函数,拥有自己的权值矩阵  $\mathbf{W}_i$  以及偏移值  $\mathbf{b}_i$ , 其公式表示为

$$i_t = \sigma(\mathbf{W}_i[\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_i) \quad (2)$$

与此同时,  $\mathbf{X}_t$ 、 $\mathbf{h}_{t-1}$  还会传入单元状态区,此块区域采用 tanh 函数作为激活函数,拥有自己的权值矩阵  $\mathbf{W}_c$  以及偏移值  $\mathbf{b}_c$ , 即

$$\tilde{\mathbf{C}}_t = \tanh(\mathbf{W}_c[\mathbf{h}_{t-1}, \mathbf{X}_t] + \mathbf{b}_c) \quad (3)$$

产生的  $\tilde{\mathbf{C}}_t$  为一个临时值,最终将于输入门的输出数据进行运算,产生真实的单元状态:

$$\mathbf{C}_t = f_t \cdot \mathbf{C}_{t-1} + i_t \cdot \tilde{\mathbf{C}}_t \quad (4)$$

最终的特征提取值将由输出门进行处理输出,  $\mathbf{X}_t$ 、 $\mathbf{h}_{t-1}$  作为输入数据进入输出门,将 sigmoid 函数作为其激活函数,其中  $\mathbf{W}_o$ 、 $\mathbf{b}_o$  分别为输出门的权值矩阵以及偏移值,经过输出门的输出值与单元状态进行运算,最终生成输出值  $\mathbf{h}_t$ , 即

$$o_t = \sigma(\mathbf{W}_o[\mathbf{h}_{t-1}, \mathbf{X}_t] + \mathbf{b}_o) \quad (5)$$

$$\mathbf{h}_t = o_t \cdot \tanh \mathbf{C}_t \quad (6)$$

### 3 基于 LSTM-Attention 融合算法的电力客户主动服务推荐方

本文针对电力客户进行主动服务推荐,其中,使用 LSTM-Attention 融合算法对提取的特征进行特征预测,其模型主要架构如图 2 所示。

原始数据首先进入嵌入层,将数据转化为有效的

计算数据,即将数据进行向量化处理,之后进入特征提取层,特征提取层主要是针对用户需求在时序上的改变,同时结合用户历史行为,充分提取隐藏特征。

数据经过提取之后送入特征预测层,伴随时间的推移,用户对服务的需求也会有所改变,其主要原因是主要影响因素发生了变化,从而导致用户需求发生变化。特征预测层主要优势在于可以为最终的预测结构提供丰富的历史信息,从而提高用户需求的预测准确率,推荐给用户更加适合的服务。

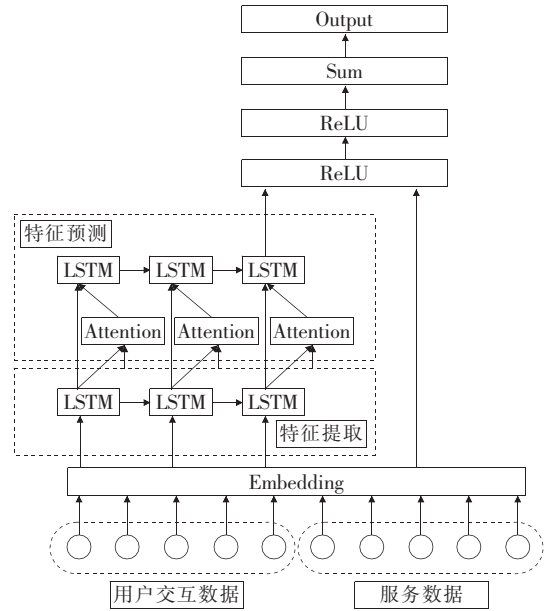


图 2 模型架构

Figure 2 Model architecture

类似于式(1)~(6),使用  $i_t$ 、 $\mathbf{h}_t$  分别代表特征预测层的输入和隐藏状态,在特征预测层当中还采用 Attention 机制来加以优化,其公式表示为

$$\mathbf{u}_t = \tanh(\mathbf{h}_t \mathbf{W}_t + \mathbf{b}_t) \quad (7)$$

$$\mathbf{a}_t = \frac{\exp(\mathbf{u}_t \mathbf{W}_e \mathbf{e}_a)}{\sum_{j=1}^T \exp(\mathbf{u}_j \mathbf{W}_e \mathbf{e}_a)} \quad (8)$$

式(7)、(8)中  $\mathbf{h}_t$  为特征提取层的输出;  $\mathbf{W}_t$  为权重矩阵;  $\mathbf{b}_t$  为偏置值;  $\mathbf{u}_t$  为  $\mathbf{h}_t$  的隐藏表示;  $\mathbf{e}_a$  为服务特征向量;  $\mathbf{W} \in \mathbf{R}^{n_H \times n_S}$ ,  $n_H$  为传入的隐藏状态维度,  $n_S$  为服务嵌入特征维度。  $\mathbf{a}_t$  即 Attention 产生的分数为反应  $\mathbf{e}_a$  与  $\mathbf{h}_t$  间的关系,倘若之间的联系大,则分数越大。

经过 Attention 输出  $\mathbf{a}_t$ , 结合特征提取层中的隐藏状态  $\mathbf{h}_t$ , 对其进行权重求积得到:

$$i_t = a_t \cdot h_t \tag{9}$$

$i_t$  则作为 LSTM 的输入值,最终获得  $h_T$  作为输出值,也就是模型的最终预测值,进入输出层,即

$$x_n = \text{concat}(h_T, e_s) \tag{10}$$

$$y_n = f_{\text{sum}}((f_{\text{relu}}(f_{\text{relu}}(x_n)))) \tag{11}$$

其中,  $e_s$  表示服务嵌入特征向量,  $h_T$  则是最终的预测输出值,concat 表示将 2 组向量进行关联拼接,形成  $x_n$ ,  $x_n$  作为 2 层全连接的输入值,之所以采用 2 层,其主要目的是为了降维,最终输出值  $y_n$  由 sum 函数输出,从而得到用户所使用的次数。

### 4 案例仿真与分析

实验环境为 PyCharm 环境下的 Python3.7,同时以 PyTorch 为底层网络框架创建整个算法数据流图,并搭建深度学习网络,GPU 为 NVIDIA GeForce MX150,部分实验参数如表 1 所示。

表 1 模型实验参数

GPU	Epoch	Batch size	Learn rate
1	5	256	0.000 1

所使用的数据集为 C 市的电力用户数据,总数为 9 278,主要分为用户信息、服务信息以及用户交互数据。用户信息数据为用户的固有属性,主要包括用户编号、性别、用户所在台区、用电属性、开户年限等;服务信息数据主要包括服务编号、服务名称、服务类型等;用户交互数据主要包括用户编号、服务编号、服务名称等。数据中部分主要服务类型如表 2 所示,其中用户编号栏为保护用户隐私,在表中显示为序列号;将获取的数据进行 8 : 2 随机分开,其中 80% 为训练数据集,20% 为测试数据集,训练模型时,将 Epoch 设置为 5 次,同时将 BP 神经网络、卷积神经网络(convolutional neural networks, CNN)以及 LSTM 设置为对比试验。

模型经过训练后为验证模型效果,剩余 20% 的数据作为测试样本输入至模型,其中实验结果如图 3 所示(MAE(mean absolute error)为平均绝对误差、RMSE(root mean square error)为均方根误差),详细数据如表 3 所示。

表 2 主要服务类型

用户编号	服务编号	服务名称
1	320	故障报修
2	321	业扩报装
3	322	业务咨询
4	323	信息查询
5	331	客户催办
6	46811	电压质量服务
7	46771	轮换电表改造
8	46765	欠费停复电
9	46760	用电变更
10	46785	抢修服务
11	46790	增值服务




图 3 测试结果

Figure 3 Test result chart

表 3 模型测试结果

模型	MAE	RMSE
LSTM	0.268	0.284
CNN	0.540	0.688
BP	0.176	0.187
LSTM_Attention	0.140	0.150

本文采用 MAE、RMSE 作为模型评价标准,是由于本文模型输出的最终结果为用户使用服务次数,次数越高,则代表用户更加倾向需要企业提供服务,而模型预测的值越接近真实值,则模型就更加精确。

测试结果显示本文模型的性能优于其他对比模型,本文所提模型的 MAE、RMSE 分别为 0.140、0.150,其中,CNN 的 MAE 以及 RMSE 远远大于其他模型,而单一 LSTM 和 BP 虽优于 CNN,但相比本文模型稍有逊色,其主要原因在于 Attention 机制的使用,Attention 机制在服务推荐中将更多的权重集中在用户的主要需求上,从而更能发现用户所需,本文模型的服务推荐性能更佳。

为了更好地验证本文模型优于对比模型,本文使用 MovieLens 数据集对其进行补充实验,得到实验结果如图 4 所示,其中实验中的详细数据如表 4 所示。

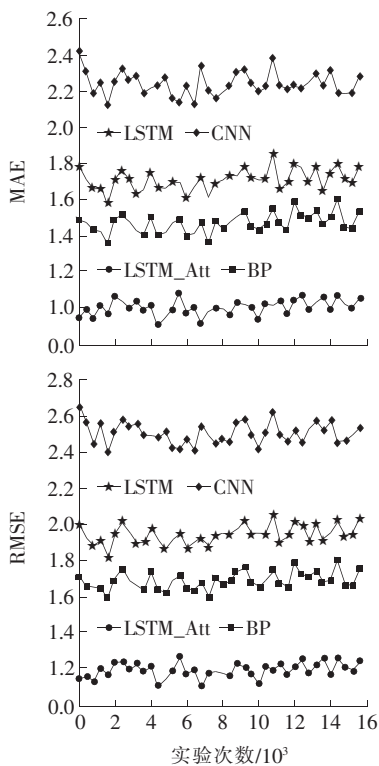


图 4 测试结果 (MovieLens)

Figure 4 Test results chart (MovieLens)

表 4 模型测试结果 (MovieLens)

Table 4 Model test results (MovieLens)

模型	MAE	RMSE
LSTM	1.720	1.957
CNN	2.243	2.519
BP	1.473	1.698
LSTM_Attention	0.995	1.190

从图 4 中可得 LSTM-Attention 在 MovieLens 中也可以取得不错的成绩,MAE、RMSE 均优于对比模型,MAE、RMSE 取值分别为 0.995、1.190。MovieLens 对比 C 市数据测试结果,MAE、RMSE 数值相差过大,其主要原因为数据集大小相差大,从而导致评价指标数值相差大。

## 5 结语

本文提出一种基于 LSTM-Attention 融合的电力客户主动服务推荐方法。

1) 电力行业中在客户主动服务方面的研究较为空缺,且其推荐算法存在相当大的不足,为此,本文提出了将 LSTM-Attention 融合算法应用于电力客户主动推荐,能极大地克服协同过滤推荐算法所存在的冷启动以及神经网络存在的梯度弥散和梯度爆炸等问题;

2) 基于电力投诉工单数据,建立了电力客户潜在需求模型,具体阐述了基于 LSTM-Attention 算法的电力客户主动服务推荐方法;

3) 利用 C 市和 MovieLens 数据集的电力客户投诉工单数据进行了算例仿真,并与 CNN、BP、LSTM 等主流推荐算法进行了比较,算例结果证明,本文提出的主动服务推荐算法的精度更高,具有更好的性能,能更好地应用于主动服务推荐领域。

## 参考文献:

- [1] 裴力耕,张欣,赵明,等.售电公司分时电价盈利策略研究[J].电网与清洁能源,2020,36(11):45-52.  
PEI Ligeng, ZHANG Xin, ZHAO Ming, et al. A study on profit strategy of time-of-use electricity price of electricity sale companies[J]. Power System and Clean Energy, 2020, 36(11): 45-52.
- [2] LIU H F, HU Z, MIAN A, et al. A new user similarity model to improve the accuracy of collaborative filtering [J]. Knowledge Based Systems, 2014, 56: 156-166.
- [3] GOHARI F S, ALIEE F S, HAGHIGHI H, et al. A significance-based trust-aware recommendation approach [J]. Information Systems, 2020, 87: 101421.
- [4] CHEN J Y, ZHANG H W, HE X N, et al. Attentive collaborative filtering: multimedia recommendation with



- item-and component-level attention[C]//The 40<sup>th</sup> International ACM SIGIR Conference on Research and Development in Information Retrieval, Tokyo, Shinjuku, Japan, 2017.
- [5] 宾晟,孙更新. 基于多关系社交网络的协同过滤推荐算法[J]. 计算机科学, 2019, 46(12): 56-62.  
BIN Sheng, SUN Gengxin. Collaborative filtering recommendation algorithm based on multi-relational social network[J]. Computer Science, 2019, 46(12): 56-62.
- [6] 张祖平,沈晓阳. 基于深度学习的用户行为推荐方法研究[J]. 计算机工程与应用, 2019, 55(4): 142-147+158.  
ZHANG Zuping, SHEN Xiaoyang. Research on user behavior recommendation method based on deep learning [J]. Computer Engineering and Application, 2019, 55(4): 142-147+158.
- [7] 吴云亮,张建新,李豹,等. 深度学习辅助约束辨识的电力市场快速出清方法[J]. 中国电力, 2020, 53(9): 90-97+207.  
WU Yunliang, ZHANG Jianxin, LI Bao, et al. A fast power market clearing method based on active constraints identification by deep learning[J]. Electric Power, 2020, 53(9): 90-97+207.
- [8] 李正浩,李孟凡. 基于深度学习的智能型负荷预测方法的研究[J]. 智慧电力, 2020, 48(10): 78-85+112.  
LI Zhenghao, LI Mengfan. Smart load forecasting method based on deep learning[J]. Smart Power, 2020, 48(10): 78-85+112.
- [9] 李卫国,陈立铭,张师,等. 分时电价下考虑储能调度因素的短期负荷预测模型[J]. 电力系统保护与控制, 2020, 48(7): 133-140.  
LI Weigu, CHEN Liming, ZHANG Shi, et al. Short-term load forecasting model considering energy storage scheduling factors under time-sharing price[J]. Power System Protection and Control, 2020, 48(7): 133-140.
- [10] 肖桂雨,向健平,凌永志,等. 基于小波神经网络的风力发电机故障预测方法[J]. 电力科学与技术学报, 2019, 34(2): 195-202.  
XIAO Guiyu, XIANG Jianping, LING Yongzhi, et al. Prediction of wind turbine faults based on wavelet neural networks[J]. Journal of Electric Power Science and Technology, 2019, 34(2): 195-202.
- [11] 高强,刘畅,金道杰,等. 考虑综合需求响应的园区综合能源系统优化配置[J]. 高压电器, 2021, 57(8): 159-168.  
GAO Qiang, LIU Chang, JIN Daojie, et al. Optimal configuration of park-level integrated energy system considering integrated demand response[J]. High Voltage Apparatus, 2021, 57(8): 159-168.
- [12] 彭文,王金睿,尹山青. 电力市场中基于 Attention-LSTM 的短期负荷预测模型[J]. 电网技术, 2019, 43(5): 1745-1751.  
PENG Wen, WANG Jinrui, YIN Shanqing. Short term load forecasting model based on Attention-LSTM in electricity market[J]. Power System Technology, 2019, 43(5): 1745-1751.
- [13] 苑威威,彭敦陆,吴少洪,等. 自注意力机制支持下的混合推荐算法[J]. 小型微型计算机系统, 2019, 40(7): 1437-1441.  
YUAN Weiwei, PENG Dunlu, WU Shaohong, et al. Hybrid recommendation algorithm supported by self attention mechanism[J]. Journal of Chinese Computer Systems, 2019, 40(7): 1437-1441.
- [14] 张宇帆,艾芊,林琳,等. 基于深度长短时记忆网络的区域级超短期负荷预测方法[J]. 电网技术, 2019, 43(6): 1884-1892.  
ZHANG Yufan, AI Qian, LIN Lin, et al. A very short-term load forecasting method based on deep LSTM RNN at zone level[J]. Power System Technology, 2019, 43(6): 1884-1892.
- [15] 杨景刚,邓敏,马勇,等. 基于深度学习的 PRPD 数据特征提取方法[J]. 电测与仪表, 2020, 57(3): 99-104+115.  
YANG Jinggang, DENG Min, MA Yong, et al. Feature extraction of PRPD data based on deep learning[J]. Electrical Measurement & Instrumentation, 2020, 57(3): 99-104+115.