

基于空时融合和注意力机制的直流电能质量扰动辨识方法

曾凡 苏小玲*

青海大学 新能源电力系统智慧运行教育部重点实验室, 青海西宁, 810001;

摘要: 随着使用的电气设备数目越来越多, 对电力系统的提出要求也越来越高, 因此, 确保电力系统的稳定运行变得日益关键。作为电力系统的核心微电网在世界范围内得到了特别的研究, 而其中的直流电能质量扰动特征的辨识是治理改善微电网中直流电能质量问题的关键。本研究引入了一种改进的混合 CTA-net 深度学习模型, 该模型结合了时空融合技术和注意力机制, 用于实时分类辨识微电网中直流电能质量扰动类别。并且通过仿真生成直流电压偏差、直流电压波动、直流电压纹波、动态电压暂降、线路故障暂降和正常六大类直流电能质量扰动信号进行消融实验, 本研究提出改进深度学习 CTA-net 模型, 相对于消融后单一的 LSTM 模型和 CNN 模型, 平均召回率、平均精确率和总准确率分别提升了 7.0%、5.1%, 13.7%、8.2%, 以及 15.4%、8.9%, 相对于基于传统空时融合 CLSTM 模型的总准确率、平均召回率和平均精确率分别提升了 4.6%、3.2%和 4.55%。与其他最新参考文献中提出的其他最新分类模型相比, CTA-net 模型在准确性方面也有所改进。因此, 本文提出的 CTA-net 模型为微电网直流电能质量扰动辨识系统提供了一种新型的超高精度、鲁棒性更强、稳定性更好的改进深度学习模型。

关键词: 深度学习; 长短时记忆; 注意力机制; 电能质量; 扰动辨识; 直流微电网

DOI: 10.69979/3041-0673.25.01.014

引言

近年来, 随着电气设备的普及, 电力系统的稳定性也变得越来越重要。作为电力系统的核心微电网在世界范围内得到了特别的研究^[1], 而如何实现直流电能质量扰动特征的辨识是确保微电网稳定的关键。大多数微电网采用交流配电和常规电力系统。在这种情况下, 直流输出型电源, 如光伏(PV)系统、燃料电池和储能装置(如锂离子二次电池和超级电容器)需要逆变器。此外, 一些燃气发动机热电联产(GEC)和风力涡轮机也需要逆变器, 因为输出电压和频率不同于公用电网。因此, 直流分布式微电网(DC microgrids)也被提出和研究, 以减少从电源到负载的转换损耗^[2]。

直流微电网的优势主要表现为:

- (1) 由于直流输出源和负载之间逆变器的转换损耗降低, 系统效率变得更高^[3]。
- (2) 不需要考虑与公用电网和无功功率的同步。
- (3) 当公用电网发生停电或电压跌落时, 由于直流电容器的储能和 AC/DC 变换器的电压控制, 不会直接影响直流微电网的直流母线电压。

因此, 直流系统中的分布式电源不容易因这些干扰而跳闸。换句话说, 直流微电网已经具备了自身的故障穿越能力。另一方面, 将直流微电网投入实际使用也存在如下一些不足之处:

- (1) 直流微电网需要建设专用直流配电线路。
- (2) 直流系统中的保护比交流系统中的保护更困难, 因为直流系统中没有电压过零点。
- (3) 为了提高系统效率, 需要适合直流电源的负载。

作为直流微电网的一个实例, 文献^[4]中描述的系统采用直流 380 V 作为直流母线电压, 当存储能量变低时, 系统由公用电网供电, 并给电池充电。独特之处还在于可以通过开关将系统转换成交流微网, 以便对直流系统和交流系统进行比较。另一方面, 对于银行、医院和半导体工厂等客户来说, 高质量的电力是必不可少的, 电力安全在我们的日常生活中变得越来越重要^[5]。

针对电能质量问题, 当前学者研究分析了电压偏差、电压纹波、电压波动^[6-7]等直流电能质量扰动较为典型现象的产生机理以及常用的治理手段, 并在交流系统标准的基础上制定了直流电能质量的评估标准^[8], 并且针对具体的直流电能质量扰动提出了一些基于机器学习(ML)分类算法的辨识方法。

机器学习是实现人工智能时最为普及和频繁采用的技术之一。它可以从多种独立的输入变量中提取特征, 并利用这些特征构建复杂的智能处理模型^[9], 引起了众多研究者和学者的关注。虽然大多数 ML 算法都具有识别各种人体活动的能力, 但它们都存在以下不足^[10]: (1) 其可扩展性会受到数据量的极大影响; (2) 通常需要

丰富的先验知识以及花费大量的时间寻找有效且易于提取的特征；（3）泛化能力和鲁棒性较弱。

深度学习（DL）可以在一定程度上弥补机器学习的不足^[11]。随着 DL 在自然语言处理和计算机视觉领域的显著成就，它逐渐成为其他领域研究者关注的焦点。与 ML 相比，DL 在识别精度和特征提取方面具有巨大优势，其自学习和自适应能力可以有效的避免过拟合问题^[12]。在解决动态非线性系统的建模问题方面，DL 也是一种很好的方法。过去几年，在深度学习领域，卷积神经网络（CNN）^[13]和递归神经网络（RNN）一直是研究人员关注的重点。随着研究人员使用 CNN 和 RNN 进行分类和回归任务，产生了许多新技术，例如，用于人体行为识别的 CNN 分类，用于风速预测的 RNN 回归模型。虽然 CNN 和 RNN 都有很好的特征提取能力，但是它们都有自己的缺陷。CNN 不能表示时间序列数据的时间信息；RNN 是一种有效的时序特征提取方法，但对数据的空间信息分析不够充分。

本研究提出了一种新的基于直流电能质量扰动深度学习分类识别模型（CTA-net），以增强分类能力，提高识别精度，降低对直流电能质量扰动的误识别风险。这项工作的目的是：

（1）为直流电能质量扰动辨识建立一个基于卷积神经网络提取的空间特征和长短时记忆网络提取的时序特征进行空时特征融合，同时引入后置注意力机制，实现提升分类决策能力的改进混合深度学习模型；

（2）利用 CNN 在空间信息提取方面的优势以及 LSTM 在时间信息处理上的长处，以及后置注意力机制聚焦重要特征的能力，进行各种过程参数获取的动态特性，克服数据集的高维性；

（3）将 CTA-net 的性能指标与 CNN、LSTM 和 CLSTM 等模型进行消融实验，验证本文提出的改进混合模型的优越性；

（4）将改进混合模型应用于直流电能质量，用于对扰动进行识别和分类。

1 基本方法原理

1.1 卷积神经网络

卷积神经网络（CNN），通过其特有的卷积操作，与传统神经网络区分开来。通常，卷积神经网络指的是用于处理图像的二维卷积神经网络（2D-CNN），其过程包含：第一步，将特征图（Feature map）对应的数值矩阵，从上及下，由左到右，取出与卷积核尺寸相同的

部分；第二步，从数值矩阵中选取部分元素与卷积核的对应元素进行点乘并求和；第三步，将获得的结果整合成一个新的数值矩阵。

本研究中所处理的直流电能质量扰动信号是由各个时间点对应的电压值组成的一维数据，因此适合使用一维卷积神经网络，即 1D-CNN，该计算过程只需在特征图上进行从上至下或从左到右的滑动窗口操作，然后将每一窗口内的值与卷积核相应位置的值相乘并求和。

相对于图像等维度较高有信息量的数据，直流电能质量扰动数据的信息量较小，当参照高维数据设置 CNN 的结构，通常卷积层结构数太多容易导致训练模型过拟 504 合，从而使得辨识效果不佳。因此，构建一个合适的 CNN 模型显得尤为重要。本研究基于 LeNet-5 的原理设计卷络结构，通过不同尺寸的卷积核来提取多样化的空域特征。

1.2 长短时记忆网络

由于递归神经网络（RNN）容易遇到梯度消失和梯度爆炸等问题，这使得它在实际应用中难以有效捕捉序列中长距离的依赖关系。在本研究中，直流电能质量扰动信号各个时间电压值组成的序列数据，只能获取相邻或相隔一个采样时间点的电压值间的关系，但实际上，所有电压值之间都存在一定的相关性。在 RNN 的基础上，为了更有效地捕捉序列中长距离的依赖关系，长短期记忆网络（LSTM）引入了可学习的门机制来控制信息的流动。

LSTM 的 Cell 中引入了输入门（input gate）、遗忘门（forget gate）和输出门（output gate）3 个门结构，及一个记忆细胞（其形状与隐藏状态相同），分别对应图 4 中的 i_t 、 f_t 、 o_t 和 g_t ，其中的下标 t 表示序列元素间的时间间隔，用以记录额外的特征信息。LSTM 单元通过赋予输入序列距离的依赖性，实现序列的筛选更新，从而获得适用序列数据的分类或回归预测的特征。

1.3 注意力机制

注意力机制（AM）是一种通过权重来进行特征调整的策略。常用的神经网络模型能够对输入数据的特征信息进行组合和提取，但没有进行重要程度筛选的功能，即神经网络模型提取的特征仅仅是按照相同的权重进行资源配置。因此，从大量信息中筛选出对当前任务目标更为关键的信息，提升神经网络模型的性能具有重要的价值。

注意力机制是一种资源分配模型，其数学上的表达

就是对输入数据进行权值计算。设序列长度为 n 的输入 $[x_0, x_1, \dots, x_{n-1}]$ ，为减少计算资源，只需从 $[x_0, x_1, \dots, x_{n-1}]$ 中选择部分和目标任务具有较大相关性的信息。因此，将注意力机制后置分类模型的特征提取层可以使得模型的最终决策更加聚焦，将主要的决策权重分配在真正对最终分类有正向帮助的特征维度上

通过对输入信息中进行目标任务相关信息选择的方法，注意力机制通常可分为三类，包括硬注意力、软注意力和自注意力机制。本研究中输入的序列较短，因此本研究选择一种软注意力机制用于直流电能质量扰动识别模型。该注意力机制的计算过程如图 1 所示，其相应的计算步骤可描述为：

步骤 1：等量全连接输入信息；

步骤 2：计算全连接层输出的概率值；

步骤 3：将概率值加权计算输入信息，输出加注意力机制结果。

计算涉及对输入信息 $[x_0, x_1, \dots, x_{n-1}]$ 进行全连接处理后得到的概率值，使用 Softmax 函数来完成这一计算。其公式表达如下：

$$a_i = \frac{e^{x_i}}{\sum_{k=0}^{n-1} e^{x_k}} \quad (1)$$

其中， $i = 0, 1, \dots, n-1$ 。




图 1 注意力层的计算过程

1.4 CTA-net 分类模型

针对直流电能质量扰动数据本身的特征和以及当前模型不能针对提取的特征进行重要程度筛选的问题，提出基于空时特征融合和注意力机制的改进深度学习模型，本研究将之命名为 CTA-net，用于直流电能质量扰动辨识。CTA-net 进行分类的过程主要包括以下四个步骤中：

第一步，将输入样本序列通过 CNN 模块进行空间特征提取；

第二步，将提取到的特征输入 LSTM 模块，以捕捉

序列中不同时间间隔的依赖关系，实现时序特征的提取；

第三步，在 LSTM 模块输出的特征输入到后置的注意力层；

最后，使用 softmax 层分类，输出对应类别的标签。

本研究提出改进深度学习模型，基于 LeNet-5 结构上设计 CNN、CLSTM 和 CTA-net 中的卷积层部分，然后用 LSTM 取代全连接层（本研究设置 LSTM 的隐藏单元数为 128），然后在 LSTM 后置注意力层，其中对应 CTA-net 结构示意图如图 2 所示。




图 2 CTA-net 结构示意图

2 实验结果与分析

2.1 实验环境

为了让本研究中所有模型都在相同的条件下进行比较，充分反映出 LSTM、CNN、CLSTM 和 CLSTMA 模型的真实性能，所有的仿真实验都在具有相同配置的计算环境下进行。

2.2 数据来源

为了验证本文提出的区间预测模型 CTA-net 的有效性，选用文献^[13]生成直流电压偏差、直流电压波动、直流电压纹波、动态电压暂降、线路故障暂降和正常六大类直流电能质量扰动信号，并且分别加入 5 dB、10 dB 和 50 dB 的高斯白噪声，每类生成 216 个样本。然后按照 8:2 的比例随机划分训练和测试集，取前 711 个周期点为训练集，后 176 个周期点为测试集。

2.3 评价指标

本研究选取三种评价指标作为直流电能质量扰动分类识别性能的评价指标，具体定义如下：

（1）准确率（Acc），是针对预测分类的所有样本，其值越大，说明模型的性能越好。计算如式（2）所示：

$$Acc = \frac{TP+TN}{TP+TN+FP+FN} \quad (2)$$

（2）精确率（Pre），是针对具体类别而言，其值越大，表示对应这一类别在模型中的预测分类效果越好。计算如式（3）所示：

$$\text{Pre} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (3)$$

(3) 召回率 (Re)：也是针对具体的某一类别而言的，其值越大越好，表示对应这一类别在模型中的预测分类效果可信度越高。其计算公式如式 (4) 所示：

$$\text{Re} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (4)$$

其中式 (13) - (15) 中的 TP、TN、FP 和 FN 分别代表真阳性、真阴性、假阳性和假阴性的样本实例。

此外，模型在训练过程中收敛速度、运算量以及所占内存空间大小也是也是衡量模型性能优劣的重要指标，其中模型的收敛速度和运算量主要可以通过对训练样本的准确率收敛曲线和运行时间进行量化，模型所占内存空间可由模型的参数量来量化。

2.4 参数设置

其中所有模型在训练过程，参照深度学习模型训练常用的参数设置，使用 Kaiming 法对 CNN 层和全连接层的权系数初始化，使用正交方法对 LSTM 层的权系数进行初始化，有利于加速模型的收敛速度。使用 Adam 优化器，使得模型在训练过程具有更快的收敛速度和更好的鲁棒性，同时无需使用验证集。将分割处理后的样本随机打乱后按照 8:2 的比例划分为训练集和测试集，具体设置如表 1 所示。

表 1 LSTM、CNN、CLSTM 和 CTA-net 模型训练参数配置

CNN 层初	LSTM 层	全连接层	优化器方	学习	损失
始化	始化	始化	法	率	函数
Kaiming	正交法	Kaiming 法	Adam	1e-3	MSE
法					
训练集数	测试集	训练轮数	丢弃率	批尺	激活
量	数量			寸	函数
1036	260	100	0.5	128	Relu

2.5 结果及其分析

本文利用 Matlab 内置的库函数来展示直流电能质量扰动分类结果的混淆矩阵。在此矩阵中，每一行对应预测的类别，而每一列代表实际的类别。对角线上的单元格表示正确分类的实例数，而非对角线单元则显示了错误分类的情况。此外，每个单元格不仅展示了观测数量，还提供了这些观测值占总观测数的比例。所生成的混淆矩阵图，在最右侧列出了预测为特定类别的所有样本的准确率和误发现率。同时，底部一行则给出了召回率和假阴性率的数据，右下角的单元格特别标示了整体

准确率与整体错误率。

通过上述的参数设置，对本文实验选用的数据集进行仿真，得到的 LSTM、CNN、CLSTM 和 CTA-net 模型在训练过程的准确率曲线如图 3 所示。LSTM、CNN、CLSTM 和 CTA-net 模型在测试集上得到的混淆矩阵分别如图 4 (a) - (d) 所示。

从图 4 可以看出，LSTM 模型大约在 150 轮时达到稳定，CNN 和 CLSTM 模型则大约在 200 轮时趋于稳定，而 CTA-net 模型在约 130 轮时就已经达到稳定状态。这意味着 CTA-net 模型拥有最快的收敛速度，并且收敛时的准确率最高；LSTM 模型收敛速度次之，但收敛时的准确率最低；CNN 和 CLSTM 模型收敛速度相当，且收敛时的准确率差别不明显。




图 3 LSTM、CNN、CLSTM 和 CTA-net 模型训练过程准确率比较曲线图

LSTM模型混淆矩阵

直流电压偏差	48 18.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
直流电压波动	0 0.0%	23 8.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
直流电压纹波	0 0.0%	0 0.0%	32 12.3%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
动态电压暂降	0 0.0%	0 0.0%	0 0.0%	41 15.8%	0 0.0%	0 0.0%	100% 0.0%
线路故障暂降	0 0.0%	0 0.0%	0 0.0%	0 0.0%	32 12.3%	0 0.0%	100% 0.0%
正常	0 0.0%	28 10.8%	0 0.0%	0 0.0%	17 6.5%	39 15.0%	46.4% 53.6%
	100% 0.0%	45.1% 54.9%	100% 0.0%	100% 0.0%	65.3% 34.7%	100% 0.0%	82.7% 17.3%

目标类

(a)

CNN模型混淆矩阵

直流电压偏差	48 18.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
直流电压波动	0 0.0%	33 12.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
直流电压纹波	0 0.0%	0 0.0%	32 12.3%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
动态电压暂降	0 0.0%	0 0.0%	0 0.0%	41 15.8%	0 0.0%	0 0.0%	100% 0.0%
线路故障暂降	0 0.0%	0 0.0%	0 0.0%	0 0.0%	39 15.0%	0 0.0%	100% 0.0%
正常	0 0.0%	18 6.9%	0 0.0%	0 0.0%	10 3.8%	39 15.0%	58.2% 41.8%
	100% 0.0%	64.7% 35.3%	100% 0.0%	100% 0.0%	79.6% 20.4%	100% 0.0%	89.2% 10.8%

目标类

(b)

CLSTM模型混淆矩阵

直流电压偏差	48 18.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
直流电压波动	0 0.0%	39 15.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
直流电压纹波	0 0.0%	0 0.0%	32 12.3%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
动态电压暂降	0 0.0%	0 0.0%	0 0.0%	41 15.8%	0 0.0%	0 0.0%	100% 0.0%
线路故障暂降	0 0.0%	0 0.0%	0 0.0%	0 0.0%	44 16.9%	0 0.0%	100% 0.0%
正常	0 0.0%	12 4.6%	0 0.0%	0 0.0%	5 1.9%	39 15.0%	69.6% 30.4%
	100% 0.0%	76.5% 23.5%	100% 0.0%	100% 0.0%	89.8% 10.2%	100% 0.0%	93.5% 6.5%

目标类

(c)

CTA-net模型混淆矩阵

直流电压偏差	48 18.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
直流电压波动	0 0.0%	47 18.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
直流电压纹波	0 0.0%	0 0.0%	32 12.3%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
动态电压暂降	0 0.0%	0 0.0%	0 0.0%	41 15.8%	0 0.0%	0 0.0%	100% 0.0%
线路故障暂降	0 0.0%	0 0.0%	0 0.0%	0 0.0%	48 18.5%	0 0.0%	100% 0.0%
正常	0 0.0%	4 1.5%	0 0.0%	0 0.0%	0 0.0%	39 15.0%	88.6% 11.4%
	100% 0.0%	92.2% 7.8%	100% 0.0%	100% 0.0%	98.0% 2.0%	100% 0.0%	98.1% 1.9%

目标类

(d)

图 4 LSTM、CNN、CLSTM 和 CTA-net 模型在测试集上辨识结果的混淆矩阵

表 2 LSTM、CNN、CLSTM 和 CTA-net 模型预测分类指标

方法 标签	LSTM 模型		CNN 模型		CLSTM 模型		CTA-net 模型	
	Pre	Re	Pre	Re	Pre	Re	Pre	Re
直流电压偏差	100%	100%	100%	100%	100%	100%	100%	100%
直流电压波动	100%	45.1%	100%	64.7%	100%	76.5%	100%	92.2%
直流电压纹波	100%	100%	100%	100%	100%	100%	100%	100%
动态电压暂降	100%	100%	100%	100%	100%	100%	100%	100%
线路故障暂降	100%	65.3%	100%	79.6%	100%	89.8%	100%	98.0%
正常	46.4%	100%	58.2%	100%	69.6%	100%	88.6%	100%
平均	91.1%	85.2%	93.0%	90.7%	94.9%	94.4%	98.1%	98.9%
总准确率	82.7%		89.2%		93.5%		98.1%	

从图 4 和表 2 中列出的 LSTM、CNN、CLSTM 和 CTA-net 模型对每类直流电能质量扰动的召回率和精确度，以及模型对整个测试集的总准确率、平均召回率和平均精确率。性能指标显示，三个对比消融模型和本研究提出的模型的平均精确率分别 91.1%、93.0%、94.9%和 98.1%，平均召回率 85.2%、90.7%、94.4%和 98.9%，总准确率分别为 82.7%、89.2%、93.5%和 98.1%。采用基于空时融合和注意力机制的 CTA-net 模型，相对于消融后单一的 LSTM 模型和 CNN 模型，平均召回率、平均精确率和总准确率分别提升了 7.0%、5.1%，13.7%、8.2%，以及 15.4%、8.9%，相对于基于传统空时融合 CLSTM 模型的总准确率、平均召回率和平均精确率分别提升了 4.6%、3.2%和 4.55%。对比文献[13]中提出的 PSO-SVM 方法，其总识别准确率为 95.6%，本研究提出的 CTA-net 模型总准确率提升了 2.6%。

3 结论

本研究在基于空时融合和注意力机制的基础上提出了一种新的改进混合深度学习模型 CTA-net 来识别模拟直流电能质量扰动的复杂动态过程，并应用于实现实时有效地分类辨识基于直流电能质量扰动类别。CTA-net 模型主要由以下两个模块组成：（1）用于提取和整合

直流电能质量扰动信号的空间特征和信息的 CNN 模块；

（2）用于提取和融合时间特征和信息的 LSTM 模块；（3）用于聚焦重要特征的 AM 模块。

因此，CTA-net 模型具有提取时空域信息的重要性的特性，从而使其具有抑制冗余信息的功能，增强分类识别的正向特征。并且通过消融实验与单一的 LSTM、CNN 模型以及空时融合模型 CLSTM 模型相比，本研究提出的用于直流电能质量扰动辨识模型 CTA-net 在训练集的训练过程准确率曲线和损失函数曲线收敛速度最快，测试集的总准确率、平均召回率和平均精确率方面具有明显的优势。

参考文献

- [1] 邱赞, 顾雪城, 刘汉宇等. 船舶微电网接入方式及匹配模式研究[J]. 船舶工程, 2016, 38(11): 85-89.
- [2] 曹梦舟, 张艳. 基于卷积-长短期记忆网络的电能质量扰动分类[J]. 电力系统保护与控制, 2020, 48(02): 86-92.
- [3] 韩民晓, 陈宇, 王皓界. 直流配电系统电压偏差限值的研究[J]. 大功率变流技术, 2016(03): 1-5.
- [4] 丁琰, 张宸宇, 李丹奇等. 基于 SVM 的直流电能质量

- 扰动分类算法[J]. 电测与仪表, 2022, 59(03): 10-17.
- [5] 陈鹏伟, 肖湘宁, 陶顺. 直流微网电能质量问题探讨[J]. 电力系统自动化, 2016, 40(10): 148-158.
- [6] 杨剑锋, 乔佩蕊, 李永梅等. 机器学习分类问题及算法研究综述[J]. 统计与决策, 2019, 35(06): 36-40.
- [7] 纪守领, 杜天宇, 邓水光, 等. 深度学习模型鲁棒性研究综述[J]. 计算机学报, 2022, 45(1): 190-206.
- [8] 周念成, 廖建权, 王强钢等. 深度学习在智能电网中的应用现状分析与展望[J]. 电力系统自动化, 2019, 43(04): 180-191.
- [9] 朱煜, 赵江坤, 王逸宁等. 基于深度学习的人体行为识别算法综述[J]. 自动化学报, 2016, 42(06): 848-857.
- [10] 王岩, 陈耀然, 韩兆龙等. 基于互信息理论与递归神经网络的短期风速预测模型[J]. 上海交通大学学报, 2021, 55(09): 1080-1086.
- [11] 季长清, 高志勇, 秦静等. 基于卷积神经网络的图像分类算法综述[J]. 计算机应用, 2022, 42(04): 1044-1049.
- [12] 王华彪, 鲁冠军, 李小勇. 基于卷积和共享权系数长短时记忆网络的空时融合机制在风速预测上的应用研究[J]. 太阳能学报, 2022, 43(11): 156-165.
- [13] 吴建章, 沙浩源, 张宸宇等. 基于 PSO-SVM 的直流配电网电能质量扰动辨识[J]. 电力工程技术, 2019, 38(04): 18-25.
- 作者简介: 曾凡 (1999—) 男, 汉族, 河南周口人, 硕士研究生在读, 研究方向: 稳定裕度与电能质量评估.