第 50 卷 第 11 期：5184-5191 高电压技术 Vol.50, No.11: 5184-5191
2024 年 11 月 30 日 High Voltage Engineering November 30, 2024
DOI: 10.13336/j.1003-6520.hve.20231990

基于多通道卷积神经网络的甚低频/低频雷电辐射电场波形分类方法

肖力郎[1]，陈维江[2]，王　宇[3,4]，贺恒鑫[1]，傅　中[5]，向念文[6]
（1. 华中科技大学电气与电子工程学院强电磁工程与新技术国家重点实验室，武汉 430074；2. 国家电网有限公司，北京 100192；3. 国网电力科学研究院武汉南瑞有限责任公司，武汉 430074；4. 电网雷击风险预防湖北省重点实验室，武汉 430074；5. 国网安徽省电力有限公司电力科学研究院，合肥 230022；6. 合肥工业大学电气与自动化工程学院，合肥 230009）

摘　要：雷电过程中产生多类雷电辐射电场波形，基于特征值的传统分类方法易误分类。为准确分类雷电辐射电场波形，该文提出了一种基于多通道卷积神经网络的甚低频/低频雷电辐射电场信号分类方法，该方法采用深度网络直接处理电场波形以减少先验知识依赖，设计多通道并行卷积核以有效提取雷电波形多尺度特征，引入 shortcut 连接以加速模型收敛。基于合肥地区实测雷电数据，该文建立了回击、初始预击穿、窄双极性脉冲以及云闪 4 分类波形数据集，模型训练结果表明该模型识别准确率达到 99.4%，与经典机器学习方法以及主流深度神经网络模型分类性能相比，所提模型在分类准确率及训练收敛速度上均达更优水平。基于该模型，该文采用知识蒸馏方法获得了适用于低算力计算平台的部署模型，部署模型在合肥某雷暴活动中单次分类耗时仅 59 ms，算力需求降低 66%，分类准确率为 99.0%，实现了模型在低算力计算平台上的可靠应用。

关键词：卷积神经网络；VLF；雷电辐射电场；波形分类；模型部署

Classification Method for VLF/LF Lightning Radiated Electric Field Waveforms Based on Convolutional Neural Networks

XIAO Lilang[1], CHEN Weijiang[2], WANG Yu[3,4], HE Hengxin[1], FU Zhong[5], XIANG Nianwen[6]
(1. State Key Laboratory of Advanced Electromagnetic Engineering and Technology, Huazhong University of Science and Technology, Wuhan 430074, China; 2. State Grid Corporation of China, Beijing 100192, China; 3. Wuhan NARI Co., Ltd. of State Grid Electric Power Research Institute, Wuhan 430074, China; 4. Hubei Province Key Laboratory of Lightning Risk Prevention for Power Grids, Wuhan 430074, China; 5. Electric Power Research Institute, State Grid Anhui Electric Power Company, Hefei 230022, China; 6. School of Electrical and Automation Engineering, Hefei University of Technology, Hefei 230009, China)

Abstract: The lightning process generates multiple types of lightning electric field waveforms. Traditional classification methods based on waveform parameters are prone to make misclassification. To address this issue, we proposed a method of VLF/LF lightning electric field signal classification based on a multi-channel convolutional neural network. This method uses a deep network to directly process the field waveforms, reducing dependency on prior knowledge. The network was constructed with multiple convolutional kernels to effectively extract the multi-scale waveform features. The shortcut connections were introduced to accelerate model convergence. Based on the data collected in Hefei, a training dataset of four typical waveforms, namely, return stroke, preliminary breakdown, narrow bipolar event, and intracloud, was established. The training results show that the model achieves an accuracy of 99.4%. Compared with classic machine learning methods and deep learning models, the proposed model performs better in classification accuracy and training convergence speed. By using the knowledge distillation method, a model suitable for low-computing-power platforms can be obtained. The distilled model takes only 59 ms for single classification, with a 66% reduction in computing power requirements and a classification accuracy of 99.0%, demonstrating reliable application of the proposed model on low-computing-power platforms.

基金资助项目：国家电网有限公司科技项目(5500-202120583A-0-5-SF)。
Project supported by Science and Technology Project of SGCC(5500-202120583A-0-5-SF).

Key words：convolutional neural network; VLF; lightning radiation electric field; waveform classification; model deployment

0　引言

甚低频/低频频段雷电电场辐射信号强度高，传播范围广，是雷电探测系统的重要观测对象。雷电探测系统探测不同雷电活动激发的甚低频/低频频段电场波形，通过波形匹配定位以及参数反演获取雷电流幅值、波前波尾时间、先导发展速度等雷电活动关键物理参数。准确分类不同雷电活动的雷电辐射电场不仅为雷电防护设计提供了坚实的基础，也为深入研究雷电的发展过程提供了数据支持[1-2]。

根据闪电发生位置，雷电活动可分为地闪、云闪 2 类[3]。地闪回击(return stroke, RS)过程电流幅值高，雷击通道连接地面及地面物体，破坏性强，是雷电探测的主要目标。学者们对地闪回击波形参数开展了大量研究观测，总结了波形上升时间、幅值、过零时间等多项波形参数典型取值范围，形成云地闪判据分类法，在云地闪二分类任务中分类准确率可达 89%~91%[4-6]。随着对雷电放电波形的深入认识，部分特殊云闪波形，如初始击穿脉冲(preliminary breakdown, PB)、窄双极性脉冲(narrow bipolar event, NBE)被发现极易误判为 RS 波形。根据文献报道，美国国家雷电探测网络(national lightning detection network, NLDN)探测结果中，约 18%的 RS 波形是被错误分类的 PB 波形[7]，超过 97%的 NBE 波形被错误分类为 RS 波形[8]。PB、NBE 等雷电波形的高误判率原因在于其关键波形参数分布范围，如幅值、脉宽等与 RS 波形存在较大重叠，难以划分合适判据完成分类。此外，同一类型电场辐射波形的同一波形参数在不同地区典型值分布也存在较大差别。不同地区气象条件、海陆地形等复杂因素影响下难以提出通用的不同类别的波形判据。例如瑞典地区 RS 波形过零时间可达马来西亚地区的 5 倍[8-10]，美国佛罗里达地区的 PB 波形持续时间可达马来西亚地区的 3 倍[11]，中国地区的 NBE 波形脉宽可达日本地区的 2 倍[11-13]。波形参数的区域性差异进一步限制了泛用化判据法分类模型的提出。

机器学习方法基于数据驱动，被广泛应用于解决波形分类问题[14-16]，取得了良好效果[17-20]。为满足类别细分需求，学者们将基于数据驱动的机器学习方法应用于雷电辐射电场波形分类。目前已有学者利用支持向量机[21]、逻辑斯蒂回归[22]等算法开展雷电波形分类，分类准确率可达 98%。传统机器学习方法基于人工先验知识与经验准则进行特征工程完成训练，训练过程简捷高效，但依然存在问题。首先，特征工程预先提取的波形特征是波形部分信息的概括，在提取过程中将损失部分波形信息，影响分类性能进一步提升。其次，模型性能与特征选择紧密相关，在选取特征过程中引入人工选择可能导致模型存在偏见，降低模型泛用性。

神经网络方法因其自主特征提取能力在复杂波形分类[18-19]以及故障诊断领域[23-24]表现不俗。为降低对特征工程依赖性，进一步提高分类准确率，学者们尝试将神经网络方法引入雷电波形分类领域。Peng 等人采用卷积模型，经由 51 000 份数据训练达到了 98%分类准确率[25]。Wang 等人采用 1 维卷积神经网络对雷电波形进行分类，在经过 50 000 条数据训练后达到 97.5%的分类准确率[26]。有学者构建 5 层残差模块形成 1 维残差神经网络，经由 11 万条数据训练后平均准确率可达 98%[27]。相较于传统机器学习方法，基于神经网络的波形分类模型可实现全波形输入以及自适应特征提取，在波形特征识别能力以及泛化能力上均有提升。然而，为充分提取数据内蕴规律，神经网络模型包含参数可达百万级，在训练与部署阶段均需求大量算力资源，限制了其在边缘计算设备等算力受限平台中的应用。

为进一步提高雷电辐射电场多分类准确率，完成分类模型在设备部署应用，本文基于卷积神经网络进行结构优化设计，提出了适用于雷电辐射电场波形的分类模型。模型在 RS、PB、NB、IC 4 分类数据集上完成训练，训练结果分别与传统机器学习模型以及常用深度学习模型分类结果进行了对比。最后本文通过模型蒸馏得到低算力平台下的可部署模型，并在实际雷暴过程中进行性能验证。

1　数据集构建

1.1　观测设备及数据采集

本文采用安装于安徽省合肥市的甚低频/低频频段雷电辐射电场测量仪[28]来开展雷电辐射电场信号探测。图 1 为测量仪主要构架框图，测量仪由电场探测天线以及数据采集单元组成。电场探测天

线为平板电容天线，工作频带范围为 2 kHz~3.4 MHz。数据采集单元集成于现场可编程门阵列(field programmable gate array, FPGA)开发板及嵌入式开发板内，采集单元采样频率为 10 MHz ，采样深度为 16 位，采样时长 200 ms，预触发时间为 100 ms。数据采集单元同时集成有高精度全球定位系统(global positioning system, GPS)授时模块以保证授时同步，授时误差<50 ns[29]。

本文所用数据共来自于 2023 年内合肥区域 13 个探测站点所采得的 24 511 条辐射电场波形。为保证数据集平衡性，4 种雷电辐射电场波形类别均包含 2 000 份波形。数据集采用 5 折交叉验证方式，训练集包含 6 000 份波形，剩余 2 000 份波形参与测试。

1.2 数据预处理

本文所用波形预处理包含分帧筛选标注以及滤波降噪 2 部分。由于原始波形持续 200 ms，存在大量背景噪声，因此需要提取其中雷电辐射脉冲部分并标注其类型。本文采用滑动窗口法分割原始波形，窗口大小为 2 ms，滑动步长为 0.5 ms，以分割后每一片段为 1 帧。将每一帧波形数据归一化至[−1,1]区间后计算帧能量，当某帧的帧能量小于设定阈值时将该帧被标记为噪声帧并舍弃，帧能量可表示为：

$$\begin{cases} e^{\min} < e \\ e = \sum_{i=1}^{h} \omega_i^2 \end{cases} \tag{1}$$

式中：$e^{\min}$ 为帧能量设定阈值；e 为帧能量；h 为帧长度；ω_i 为帧内第 i 个数据点。

非噪声帧将进行滤波降噪处理以去除其所含低频分量，保证波形平直。本文采用经验模态分解(empirical mode decomposition，EMD)方法去除低频分量，采用小波去噪方法进一步提高信噪比。图 2 为一帧波形滤波降噪处理前后对比图。

如图 2(a)所示，原始波形 200 s 处存在被低频分量掩盖的雷电脉冲。经过 EMD 分解重构后如图 2(b)所示，帧波形首尾平直，脉冲凸显。通过小波去噪方法可进一步滤除波形背景噪声，提高波形质量，本文采用 sym5 小波基分解波形，保留前 5 层系数，采用软阈值方法处理分解所得小波系数，帧波形在小波降噪后效果图如图 2(c)所示。

经过 EMD 分解重构及小波降噪后，帧中波形脉冲特征凸显，信噪比有效提升。记预处理后帧为样本，本文通过人工筛选方式对样本进行类别标注。4 类波形典型案例如图 3 所示。

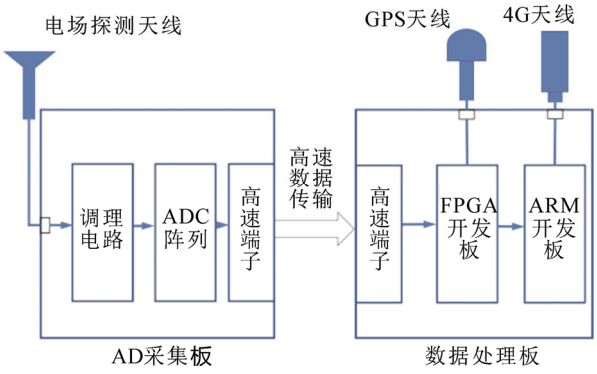


图 1 雷电辐射电场测量仪结构框图

Fig.1 Block diagram of the lightning radiation electric field change meter

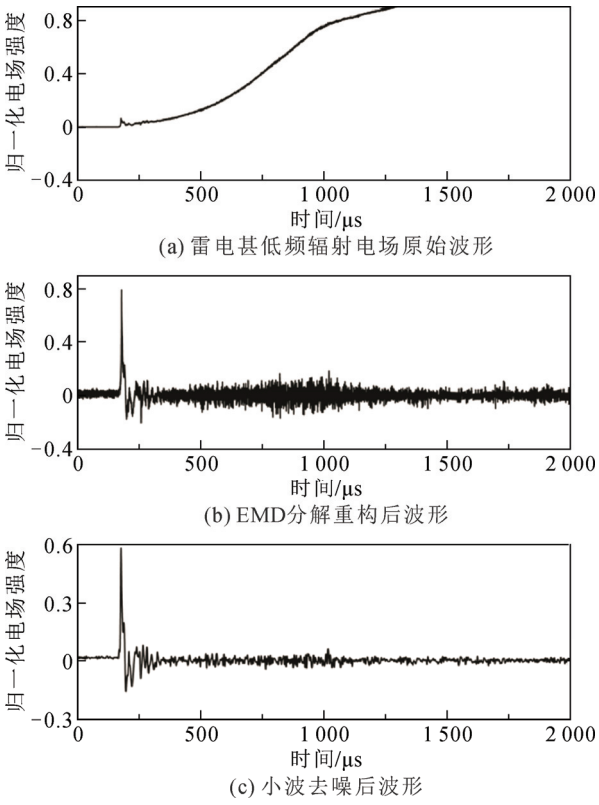


图 2 波形去噪效果示例

Fig.2 Example of the waveform denoising process

2 分类模型构建及其训练

卷积神经网络通过将卷积核与输入数据进行卷积运算完成数据特征提取。相较于其他人工智能分类方法，卷积神经网络模型局部特征提取能力突出，变形特征识别能力强，无需人为设定或选择特

征，在分类准确度及泛化能力上均有巨大提升。

根据分类对象特点，本文设计了适用于雷电辐射电场波形的模型结构。该结构以卷积块作为基本单位。一卷积块包含 3 层卷积层，第 1 层卷积层的输入将由 shortcut 连接传入第 2 层实现特征重用，加速模型训练收敛。由于雷电辐射波形特征时间尺度丰富，本文在卷积层中以并行结构引入多尺寸卷积核，强化模型提取多尺度特征的能力。

为确定卷积核尺寸与数目，本文首先假定模型包含 2 卷积块，共 6 层卷积层。定义模型在输入波形中提取特征的范围为模型的感受野，在该结构下模型的感受野计算式为：

$$F_L = 1 + \sum_{l=1}^{L} (k-1)s^{l-1} \tag{2}$$

式中：F_L 为感受野大小；L 为卷积层层数；k 为卷积核尺寸；s 为卷积步长。

为完成 RS、PB、NB、IC 4 类波形分类，模型应有效提取 4 类波形中的单个脉冲特征。由在瑞典、马来西亚、美国等地区的观测结果可知，RS 的平均过零时间约为 50 μs[30]，NBE 脉冲的脉宽约为 10~20 μs[11-12, 20, 31]，单个 PB 脉冲的脉宽约为 5~15 μs[10, 21, 32]，而单个 IC 脉冲的脉宽约为 1~20 μs[33]。为确保模型的特征提取范围可以包括单个脉冲，本文将模型的感受野设置为 50 μs，由波形采样频率可知，该范围相当于 500 数据点长度。通过式(1)可以计算得到最大的卷积核尺寸为 84.1。由于卷积核以滑动方式在波形上进行卷积计算，为确保每个波形样本中的 20 000 个数据点能被卷积核整除，最大的卷积核尺寸被设置为 80。

确定卷积核最大尺寸后，通过每次减半的方式确定其余的卷积核大小。因此卷积核尺寸被设置为 80 402 010，分别对应时域尺度上的 8 421 μs。为了保留模型对波形细节的敏感性，本文在卷积层中额外增加尺寸为 1 的最小卷积核以提取波形中的细节特征。因此最终单一卷积层中将包含 804 020 101 共 5 通道卷积核。

为验证模型深度是否适合，本文改变卷积块数目分别进行训练，测试不同模型深度下的性能。令模型中卷积块数量分别为 1、2、3，训练超参数如表 1 所示，在相同条件下，模型分类准确率如表 2 所示。

由表 2 可知，在 804 020 101 共 5 通道卷积情况下，模型深度为 2 卷积块，共 6 层卷积层时可取

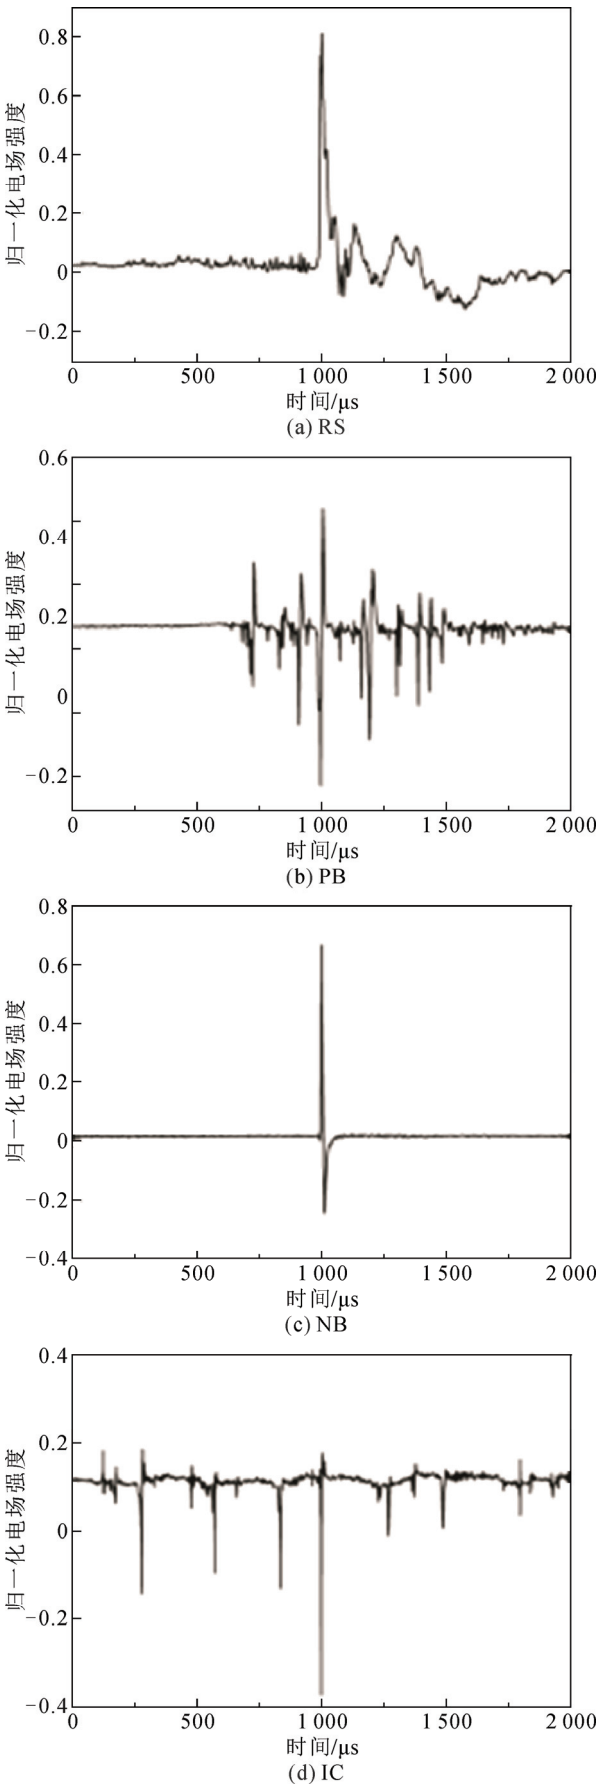


图 3　4 类典型波形示例图

Fig.3　Examples of four typical waveform types

表 1 模型深度寻优所用训练超参

Table 1 Hyperparameters used for model depth optimization

超参数	参数值
批大小	64
迭代数	100
损失函数	CrossEntropy
优化器	Adam
学习率	0.01

表 2 不同深度模型分类准确率

Table 2 Classification accuracies of models with different depths

模型深度(卷积块数)	分类准确率/%
1	96.28
2	97.54
3	97.05

得最好表现。因此本文模型设置为 2 卷积块，每一卷积层中包括 5 通道卷积核完成特征提取。该模型结构被记为 CNN_Lightning 如图 4 所示。

模型被部署在 Tesla A100 显卡上进行训练，训练框架选用 Pytorch 1.9.1。为强化全局寻优能力，避免模型训练陷入局部最小值，在表 1 所示基本训练条件基础上，模型学习率采用了余弦退火衰减策略进行训练。在该策略下学习率将按照余弦规律从设定最大值逐渐衰减至设定最小值，并在 1 个周期后重新从设定最大值开始衰减，实现跳出局部最小值。每一个周期都将比前一个周期延长 1 倍，以允许更仔细的最优值搜寻。本文设置共训练 630 代，包含 5 个完整学习率衰减周期。

在该设置下，模型训练损失值变化，准确率变化趋势如图 5 所示，最终模型在测试集上分类准确率达到 99.4%。为衡量模型分类平衡性，本文还计算了模型分类的精准率、召回率以及 F1 指标，计算结果如表 3 所示。可见模型性能平衡，分类不存在偏差(bias)。

3 与传统方法分类性能对比

为验证多通道 1 维卷积神经网络在雷电辐射电场波形识别上的优势，本文分别根据文献[16, 29]描述搭建了支持向量机(support vector machine, SVM)、随机森林 (random forest, RF) 模型对 4 类雷电辐射电场波形进行分类。其中 SVM 模型通过降采样将样本中 20 000 数据点降至 2 000 点作为特征向量，采取径向基函数(radial basis function, RBF)作

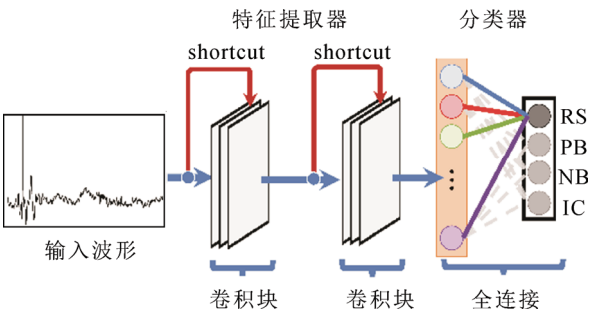


图 4 雷电辐射电场分类模型结构示意图

Fig.4 Schematic of the lightning electric field classification model structure

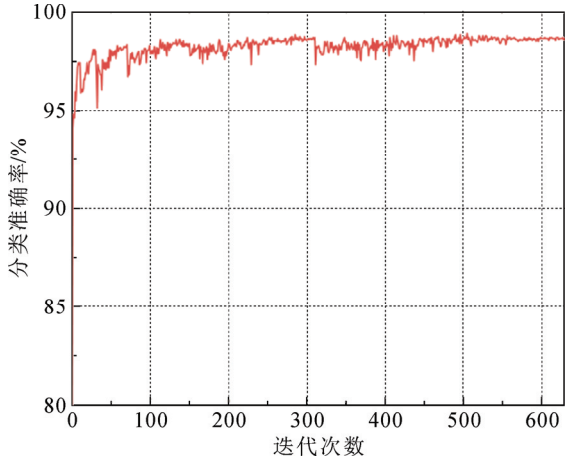


图 5 训练过程中损失函数与准确率变化

Fig.5 Loss function and accuracy changes during the training process

表 3 模型分类性能指标

Table 3 Metrics for model classification performance

类别	准确率/%	精准率	召回率	F1
RS	100	1.00	1.00	1.00
PB	100	0.99	1.00	1.00
NB	100	0.99	1.00	0.99
IC	96	1.00	0.96	0.98

为核函数。RF 模型以 2 000 点降采样点与人工提取所得波形上升时间、下降时间、过零时间 3 项波形参数合并，形成长度为 2 003 的特征向量，决策树数量设置为 100，最大树深度设置为无限制。SVM、RF 及 CNN_Lightning 在同一数据集上不同类别分类波形准确率如表 4 所示。可见 CNN_Lightning 取得了最高分类准确率，达到 99.4%；而 SVM 和 RF 分类准确率有明显下降，准确率分别为 86%与 84%。3 类模型在 RS 和 NB 识别上均取得了较高准确率，而 SVM 与 RF 模型分类在 PB 与 IC 分类上均较低。SVM 方法与 RF 方法均基于预先提取的特征完成模

表 4　所提模型与传统机器学习方法的分类准确率对比

Table 4　Comparison of classification accuracy between the proposed model and traditional machine learning methods

%

类别	CNN_Lightning	SVM	RF
RS	100	90	88.3
PB	100	91	83
IC	96	86.2	84.5
NB	100	92	92.7
Avg	99.4	86	84

型训练，在特征提取过程中损失了一定波形信息，同时人工设定特征向量组成也引入了偏差，限制了模型的分类性能。CNN_Lightning 能够接收完整波形作为输入，利用多通道卷积核自适应提取波形特征，在充分利用波形的同时也避免了偏差，能够取得更强的分类效果。

为研究本文所提出的改进分类模型与经典深度卷积分类网络在雷电辐射电场分类任务上的优势，本文建立了 DenseNet121、ResNet18 以及 plain_CNN 等主流卷积神经网络模型，在本文数据集上采用相同参数训练后将训练结果与 CNN_Lightning 训练结果作为对比。其中 plain_CNN 模型层数与 CNN_Lightning 模型层数一致，取消 shortcut 结构。DenseNet121、ResNet18 以及 plain_CNN 模型均仅设置单通道卷积核，大小为 80。在同一训练参数设置下，4 类卷积神经网络模型均在 70 代内完成收敛，收敛过程如图 6 所示。

由图 6 可知，DenseNet121、ResNet18、plain_CNN、CNN_Lightning 的分类准确率均显著优于传统机器学习算法，分别为 96.18%、96.72%、98.10%、99.4%。其中 CNN_Lightning 与 ResNet18 在 10 次迭代内即趋于收敛。plain_CNN 结构由于不包含 shortcut 结构，因此训练收敛速度相较于 CNN_Lightning 以及 ResNet18 等含 shortcut 连接模型显著降低，约在 20 次迭代后收敛。DenseNet121 结构虽然包含 shortcut 连接，但由于层数过多，参数量过大，因此收敛速度更慢，约 40 次迭代后收敛。参数量过大同样带来过拟合的问题，使得 ResNet18 与 DenseNet121 模型分类准确率反而低于 plain_CNN 与 CNN_Lightning 等浅层分类结构。由此可见，在不同分类任务中，不可依赖通用模型结构，有必要针对分类对象具体特点开展结构设计以取得最佳分类性能。

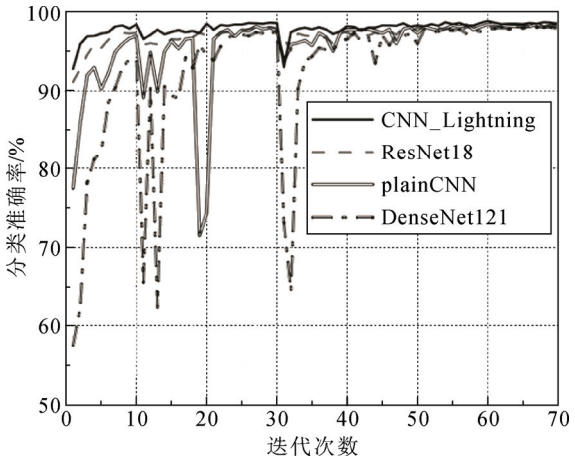


图 6　不同深度学习模型收敛过程图

Fig.6　Convergence process of different deep learning models

4　分类模型实际部署验证

为验证模型在实际环境下的分类性能是否符合要求，本文将模型部署在第 2.1 节所提到的雷电探测器中。模型被部署于探测器 ARM 系统上，系统 python 版本、pytorch 版本与第 3 节一致。由于探测器不存在 GPU 设备用于计算加速，在 CPU 推断模式下，模型单次分类时间为 0.94 s，难以满足实时性要求。因此本文采用知识蒸馏方式将模型所学波形特征从存在参数冗余的复杂模型转移到轻量化模型中。该方法在尽量保持原有模型分类能力的同时，有效减少了模型参数量，降低了模型运行算力占用，有利于在算力有限的分布式平台上部署模型。

知识蒸馏过程如图 7 所示。在学习过程中将训练完毕的 CNN_Lightning 模型作为教师模型，将轻量化网络作为学生模型。轻量化网络选择 MobileNet 结构，该结构采用深度可分离卷积替代标准卷积，将卷积操作分解为深度卷积与逐点卷积 2 部分，从而减少参数量。

在训练过程中教师模型参数将被冻结保持不变，学生模型将基于总损失函数值完成反向参数更新。总损失函数值将由 2 部分组成：第 1 部分为教师模型输出结果与学生模型输出结果差异，第 2 部分为学生模型输出结果与真实标注差异，计算式为：

$$L=\alpha L_1+(1-\alpha)L_2 \tag{3}$$

式中：L_1 为教师模型与学生模型输出之间的巴氏距离；L_2 为学生模型输出与真实标注之间的交叉熵计算结果。

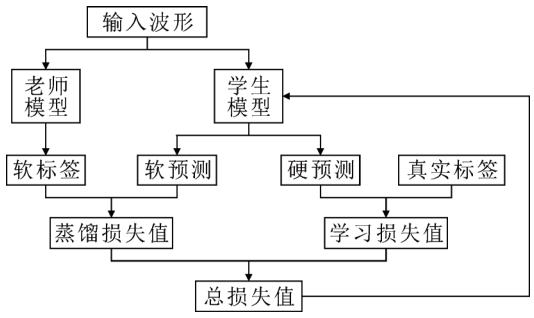


图 7 知识蒸馏流程

Fig.7 Flow chart of the knowledge distillation process

表 5 给出了不同α下学生模型达到的分类准确率。可见当$\alpha=0.5$时，模型达到最佳分类性能，且与教师分类模型相比，分类准确率仅下降 0.5%。以单次分类过程中模型完成浮点运算数衡量模型算力需求，学生模型浮点运算数为 15.8 亿次浮点运算数每秒，而教师模型浮点运算数量为 46.3 亿次浮点运算数每秒，模型算力需求降低 66%。

2023 年 6 月 17 日合肥发生雷暴，探测网络共采集得到 1 300 条波形数据，经由第 1.1 节所述分帧处理，共获取 3 063 条待分类样本。应用蒸馏后模型进行分类，分类平均单次分类时间为 59 ms，为蒸馏前分类速度的 6.2%。模型分类结果见表 6，模型总分类准确率为 99%，相较于教师模型仅下降 0.4%，且精准率、召回率与 F1 分数均达到较高水平，表明模型性能在实际不平衡数据分布中依然可靠。

5 结论

1）本文成功开发了针对雷电辐射电场分类的改进 1 维卷积神经网络。通过特定设计的 5 通道卷积核和 shortcut 连接，模型在分类雷电波形方面的准确率达到 99.4%，显示出对特定波形特征的高效提取能力。

2）相较于 SVM、RF 等传统机器学习模型及 ResNet、DenseNet 等深度学习模型，本文提出的模型在参数适中的情况下有效避免了过拟合和收敛难题，同时能够自动学习并提取关键波形特征，显示出更优的分类性能。

3）通过模型蒸馏技术，本文在保持高分类性能的同时显著降低了模型算力需求。在实际雷暴日数据测试中，算力需求降低了 66%，单次分类速度为 59 ms，准确率保持在 99%，有效满足了实时性和准确性的双重要求，为模型在边缘计算环境部署提供了重要技术支持。

表 5 不同α取值下的学生模型分类准确率

Table 5 Classification accuracy of the student model under different α

α取值	0.4	0.5	0.6
准确率/%	97.1	98.9	91.2

表 6 实测情况下模型分类性能指标

Table 6 Classification performance metrics in real thunderstorm

类别	准确率/%	精准率	召回率	F1
RS	99.47	0.993 5	0.987 9	0.990 7
PB	99.23	0.993 2	0.947 7	0.969 9
NB	98.60	0.938 8	0.987 0	0.962 3
IC	99.00	0.978 0	0.982 9	0.980 4

参考文献 References

[1] LI Y F, YANG Q, SIMA W X, et al. Optimization of transmission-line route based on lightning incidence reported by the lightning location system[J]. IEEE Transactions on Power Delivery, 2013, 28(3): 1460-1468.

[2] RODRIGUES R B, MENDES V M F, CATALAO J P S, et al. An investigation over the lightning location system in Portugal for wind turbine protection development[C]//2008 IEEE Power and Energy Society General Meeting-Conversion and Delivery of Electrical Energy in the 21st Century. Pittsburgh, USA: IEEE, 2008: 1-8.

[3] RAKOV V A, UMAN M A. Lightning: physics and effects[M]. New York, USA: Cambridge University Press, 2003.

[4] ZHU Y, RAKOV V A, TRAN M D, et al. Evaluation of ENTLN performance characteristics based on the ground truth natural and rocket-triggered lightning data acquired in Florida[J]. Journal of Geophysical Research: Atmospheres, 2017, 122(18): 9858-9866.

[5] ZHU Y, RAKOV V A, TRAN M D, et al. A study of national lightning detection network responses to natural lightning based on ground truth data acquired at LOG with emphasis on cloud discharge activity[J]. Journal of Geophysical Research: Atmospheres, 2016, 121(24): 14651-14660.

[6] KOHLMANN H, SCHULZ W, PEDEBOY S. Evaluation of EUCLID IC/CG classification performance based on ground-truth data[C]//2017 International Symposium on Lightning Protection (XIV SIPDA). Natal, Brazil: IEEE, 2017: 35-41.

[7] NAG A, RAKOV V A. Pulse trains that are characteristic of preliminary breakdown in cloud-to-ground lightning but are not followed by return stroke pulses[J]. Journal of Geophysical Research: Atmospheres, 2008, 113(D1): D01102.

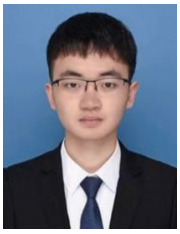
[8] LEAL A F R, RAKOV V A, ROCHA B R P. Compact intracloud discharges: new classification of field waveforms and identification by lightning locating systems[J]. Electric Power Systems Research, 2019, 173: 251-262.

[9] COORAY V, LUNDQUIST S. Characteristics of the radiation fields from lightning in sri lanka in the tropics[J]. Journal of Geophysical Research: Atmospheres, 1985, 90(D4): 6099-6109.

[10] WOOI C L, ABDUL-MALEK Z, AHMAD N A, et al. Statistical analysis of electric field parameters for negative lightning in Malaysia[J]. Journal of Atmospheric and Solar-Terrestrial Physics, 2016, 146: 69-80.

[11] BAHARUDIN Z A, AHMAD N A, FERNANDO M, et al. Comparative study on preliminary breakdown pulse trains observed in Johor, Malaysia and Florida, USA[J]. Atmospheric research, 2012, 117:

111-121.
[12] LÜ F C, ZHU B Y, MA M, et al. Observations of narrow bipolar events during two thunderstorms in Northeast China[J]. Science China Earth Sciences, 2013, 56(8): 1459-1470.
[13] WU T, YOSHIDA S, USHIO T, et al. Lightning-initiator type of narrow bipolar events and their subsequent pulse trains[J]. Journal of Geophysical Research: Atmospheres, 2014, 119(12): 7425-7438.
[14] 杨　庆，赵洪彬，司马文霞，等. 基于阈值判断和支持向量机的电网实测过电压识别[J]. 高电压技术，2016，42(10)：3188-3198.
YANG Qing, ZHAO Hongbin, SIMA Wenxia, et al. Identification method of grid measured over-voltage based on threshold judgment and support vector machine[J]. High Voltage Engineering, 2016, 42(10): 3188-3198.
[15] 杨贺雅，邢纹硕，陈　聪，等. 基于随机森林二分类器的模块化多电平换流器子模块开路故障检测方法[J]. 中国电机工程学报，2023，43(10)：3916-3928.
YANG Heya, XING Wenshuo, CHEN Cong, et al. Modular multilevel converter submodule open-circuit fault detection method based on random forest binary classifier[J]. Proceedings of the CSEE, 2023, 43(10): 3916-3928.
[16] 陈健宁，周远翔，白　正，等. 基于多通道卷积神经网络的油纸绝缘局部放电模式识别方法[J]. 高电压技术，2022，48(5)：1705-1715.
CHEN Jianning, ZHOU Yuanxiang, BAI Zheng, et al. Pattern recognition method of partial discharge in oil-paper insulation based on multi-channel convolutional neural network[J]. High Voltage Engineering, 2022, 48(5): 1705-1715.
[17] 戴永东，姚建光，李　勇，等. 基于定点化自适应选择卷积神经网络的电力缺陷识别方法[J]. 高电压技术，2021，47(11)：3827-3835.
DAI Yongdong, YAO Jianguang, LI Yong, et al. Power defect recognition method based on fixed-point adaptive selection convolution neural network[J]. High Voltage Engineering, 2021, 47(11): 3827-3835.
[18] 龙官微，穆海宝，张大宁，等. 基于多特征融合神经网络的串联电弧故障识别技术[J]. 高电压技术，2021，47(2)：463-471.
LONG Guanwei, MU Haibao, ZHANG Daning, et al. Series arc fault detection technology based on multi-feature fusion neural network[J]. High Voltage Engineering, 2021, 47(2): 463-471.
[19] 杨秋玉，王　栋. 卷积神经网络在复合绝缘子憎水性智能识别中的应用[J]. 高电压技术，2022，48(2)：603-611.
YANG Qiuyu, WANG Dong. Application of convolutional neural network in intelligent classification of hydrophobicity of composite insulators[J]. 2022, 48(2): 603-611.
[20] 杨晓丽，黄宏光，舒　勤，等. 基于 SVD 和低秩 RBF 神经网络的局部放电信号提取方法[J]. 高电压技术，2021，47(10)：3608-3616.
YANG Xiaoli, HUANG Hongguang, SHU Qin, et al. Partial discharge signal extraction method based on svd and low rank rbf neural network[J]. High Voltage Engineering, 2021, 47(10): 3608-3616.
[21] ZHU Y N, BITZER P, RAKOV V, et al. A machine-learning approach to classify cloud-to-ground and intracloud lightning[J]. Geophysical Research Letters, 2021, 48(1): e2020GL091148.
[22] ZHU Y N, STOCK M, LAPIERRE J, et al. Upgrades of the earth networks total lightning network in 2021[J]. Remote Sensing, 2022, 14(9): 2209.
[23] 刘传洋，吴一全. 基于红外图像的电力设备识别及发热故障诊断方法研究进展[J/OL]. 中国电机工程学报，1-27[2024-01-05]. http://kns.cnki.net/kcms/detail/11.2107.TM.20240226.0957.002. html.
LIU Chuanyang, WU Yiquan. Research progress of power equipment identification and thermal fault diagnosis based on infrared images[J]. Proceedings of the CSEE, 1-27[2024-01-05]. http://kns.cnki.net/kcms/detail/11.2107. TM. 20240226.0957.002. html.
[24] INCE T, KIRANYAZ S, EREN L, et al. Real-time motor fault detection by 1-D convolutional neural networks[J]. IEEE Transactions on Industrial Electronics, 2016, 63(11): 7067-7075.
[25] PENG C Z, LIU F F, ZHU B Y, et al. A convolutional neural network for classification of lightning LF/VLF waveform[C]//2019 11th Asia-Pacific International Conference on Lightning (APL). Hong Kong, China: IEEE, 2019: 1-4.
[26] WANG J Q, HUANG Q J, MA Q M, et al. Classification of VLF/LF lightning signals using sensors and deep learning methods[J]. Sensors, 2020, 20(4): 1030.
[27] GAO C, WANG J Q, ZHOU X, et al. Classification of lightning electric field waveform based on deep residual one-dimensional convolutional network[C]// Advances in Natural Computation, Fuzzy Systems and Knowledge Discovery. Cham: Springer, 2020: 1648-1659.
[28] WANG Y, QIE X S, WANG D F, et al. Beijing lightning network (BLNET) and the observation on preliminary breakdown processes[J]. Atmospheric Research, 2016, 171: 121-132.
[29] WANG Y, GU S Q, FANG Y H, et al. Compact electric field change meter and its application in lightning detection and fault analysis for power grids[C]//2020 IEEE International Conference on High Voltage Engineering and Application (ICHVE). Beijing, China: IEEE, 2020: 1-4.
[30] ROJAS H E, CRUZ A S, CORTES C A. Characteristics of electric field waveforms produced by negative return strokes in Colombia and their comparison with other regions[J]. Journal of Atmospheric and Solar-Terrestrial Physics, 2022, 227: 105809.
[31] GUNASEKARA T A L N, FERNANDO M, SONNADARA U, et al. Characteristics of narrow bipolar pulses observed from lightning in Sri Lanka[J]. Journal of Atmospheric and Solar-Terrestrial Physics, 2016, 138/139: 66-73.
[32] GOMES C, COORAY V, JAYARATNE C. Comparison of preliminary breakdown pulses observed in Sweden and in Sri Lanka[J]. Journal of Atmospheric and Solar-Terrestrial Physics, 1998, 60(10): 975-979.
[33] BRUNNER K N. Explorations in intracloud lightning and leader processes[D]. Huntsville, USA: The University of Alabama in Huntsville, 2016.



XIAO Lilang
Ph.D. candidate

肖力郎
2000—，男，博士生
主要从事机器学习及电力系统防雷技术方面的研究
E-mail: husthvxiao@qq.com



CHEN Weijiang
Professor
CAS member

陈维江
1958—，男，教授，博导，中国科学院院士
主要从事电力系统暂态分析、雷电防护、绝缘配合及先进输配电技术等方面的研究
E-mail: weijiang-chen@sgcc.com.cn



WANG Yu
Ph.D.
Senior engineer
Corresponding author

王　宇(通信作者)
1987—，男，博士，高工
主要从事雷电物理及电力系统防雷技术方面的研究
E-mail: wangyu16@sgepri.sgcc.com.cn

收稿日期　2023-11-07　修回日期　2024-01-25　　编辑　程子丰