

# 基于改进双线性细粒度模型的压板状态识别

杨倩文<sup>1\*</sup>, 周克<sup>1,2</sup>

<sup>1</sup>贵州大学电气工程学院, 贵州 贵阳 550025;

<sup>2</sup>茅台学院酿酒工程自动化系, 贵州 遵义 564507

**摘要** 在变电站二次侧管理中, 压板承担着重要作用。针对现有压板状态识别方法效果不理想的问题, 提出了一种融合注意力机制的双线性细粒度压板状态识别方法。首先, 通过注意力机制将注意力集中到压板接触部分; 然后, 利用双线性细粒度模型将重点集中到与压板开闭相关的关键区域; 最后, 从关键区域中提取有效的特征以实现对接板状态的准确识别。实验结果表明, 本方法能实现压板状态的端到端识别, 识别准确率可达到 98%; 且相比传统方法, 本方法的精确率、召回率均有明显提升。

**关键词** 图像处理; 压板状态识别; 图像分类; 注意力机制; 双线性细粒度模型

中图分类号 TN957.52

文献标志码 A

doi: 10.3788/LOP202158.2010007

## Press-Plate State Recognition Based on Improved Bilinear Fine-Grained Model

Yang Qianwen<sup>1\*</sup>, Zhou Ke<sup>1,2</sup>

<sup>1</sup> School of Electrical Engineering, Guizhou University, Guizhou, Guiyang 550025, China;

<sup>2</sup> Department of Brewing Engineering Automation, Moutai College, Zunyi, Guizhou 564507, China

**Abstract** In the secondary side management of a substation, the press-plate plays an important role. Aiming at the problem of unsatisfactory results of the existing accurate recognition methods for press-plate states, this study proposes a bilinear fine-grained press-plate state recognition method that incorporates the attention mechanism. First, the attention mechanism is used to focus attention on the contact part of the press-plate; then, the bilinear fine-grained model is used to focus on the key areas related to the opening and closing of the press-plate; finally, effective features are extracted from the key areas to achieve accurate recognition of the state of the press-plate. Experimental results show that the method can realize the end-to-end state recognition of the pressure plate, and the recognition accuracy can reach up to 98%. Compared to the traditional method, the accuracy and recall rate of the method are significantly improved.

**Key words** image processing; press-plate state recognition; image classification; attention mechanism; bilinear fine-grained model

**OCIS codes** 100.3005; 100.2960; 150.3040

## 1 引言

随着传统化石能源的逐渐枯竭, 大量可再生能源的间歇接入, 使电网结构变得越来越复杂, 电力系统的稳定安全也面临着巨大挑战。在此背景下, 优

势显著的智能变电站逐渐成为电力建设的热点<sup>[1]</sup>。为保证电网的高效安全运行, 大量的继电保护设备被用于电力系统中。保护压板作为继电保护装置与外部连接的桥梁, 是继电保护跳闸的最后一道关键屏障, 其设计依然采用机械的电气连接<sup>[2]</sup>。长期以

收稿日期: 2020-10-29; 修回日期: 2020-12-07; 录用日期: 2021-01-02

基金项目: 国家自然科学基金(61861007)、贵州省科技支撑计划(黔科合支撑[2018]2151)

通信作者: \*2583494073@qq.com

来,保护压板的管理都是继电保护管理工作中的一个薄弱环节,其难点和关键技术问题在于没有可行的方法获取压板真实的投退状态,继电保护整定和压板投退之间缺少必要的联系<sup>[3]</sup>。

各类保护压板作用不统一且投退状态逻辑复杂,仅依靠人工检测压板状态容易产生视觉疲劳、记忆错乱等问题,最终造成压板投退错误等事故。为了防止对保护压板的误操作,除了制定严格的规章制度、提高保护整定人员的素质和责任感外,还可以采用一些技术手段辅助提高保护压板的管理水平。按实现技术可将现有压板状态识别方法分为智能监测方法<sup>[4-5]</sup>和图像识别方法<sup>[6-8]</sup>两大类。其中,智能监测方法需要在原压板屏柜中安放传感器,通过传感器实时监测压板的投退状态,并将其与保护系统的正常状态进行对比,以此检测压板状态的变化。图像识别方法主要通过计算机对压板的状态图像进行分析、处理,从而识别压板状态。相比智能监测方法,图像识别方法不需要改变原有屏柜的结构,也不用额外添加传感器,识别后的图像信息更容易跨平台使用,因此得到了广泛应用。但该方法的准确率与拍摄时光线的强度、拍摄角度等因素息息相关,尤其是保护压板投切不到位,闭合角度非常小的情况下,压板状态的识别难度较大,识别效果不理想。压板的投、退、投退不到位等情况都可以看作是类内的图像识别问题,而细粒度模型是处理类内图像识别问题时常用的方法。如冀中等<sup>[9]</sup>为了解决极端海洋条件下鱼类图像分辨率低、图像类内差异大的问题,使用空间变换的双线性细粒度模型对鱼的种类进行分类,相比其他对比方法,准确率均都有不同程度的提高。葛疏雨等<sup>[10]</sup>提出用核化的双线性卷积神经网络(B-CNN)进行图像分类,在公共数据集 FGVC-Aircraft 和 Cars 上

的准确率较高,分别为 91.3%和 92.8%。

针对上述问题,本文提出了一种融合注意力机制的双线性细粒度模型压板状态识别方法,以解决保护压板投切不到位、闭合角度很小时的压板状态识别问题。压板状态一般定义为完全投状态、完全退状态及投退不到位状态三种,但在实际应用中,当压板与压板圆柱只接触到一小部分,即压板的金属片未完全插入时,传统方法很难进行区分。因此,本方法先通过引入注意力机制,将注意力集中到与压板开闭相关的区域,再利用双线性细粒度模型将焦点聚集在压板投、退或投退不到位等状态区域,最后利用判别函数实现对不同状态的识别。

## 2 双线性细粒度模型

细粒度图像的分类又被称为子类别图像分类,是近年来计算机视觉、模式识别等领域的热门研究课题<sup>[11]</sup>。在细粒度图像分类中,不同类间的差异较小,而同类间的差异较大,导致分类难度大幅上升。针对细粒度图像的分类方法主要有基于强监督信息和基于弱监督信息的方法。强监督方法的分类精度较高,但需要额外的人工标注信息,标注的专业性较强,其实用性大打折扣;弱监督方法不需要物体及部件位置的额外标注信息,减少了网络的复杂度,已逐渐成为细粒度图像分类研究的发展趋势<sup>[12]</sup>。B-CNN 是 Lin 等<sup>[13]</sup>在 2016 年提出的一种具有代表性的分类模型,该模型通过两路深度卷积神经网络 VGGNet 提取图像中的特征,并将两个网络提取的图像特征进行双线性组合,构成双线性向量,最后通过一个分类层对图像进行分类。通过两路 VGGNet 的互协调作用,实现图像识别中的区域检测和特征提取任务<sup>[14]</sup>,常见的 B-CNN 结构如图 1 所示。

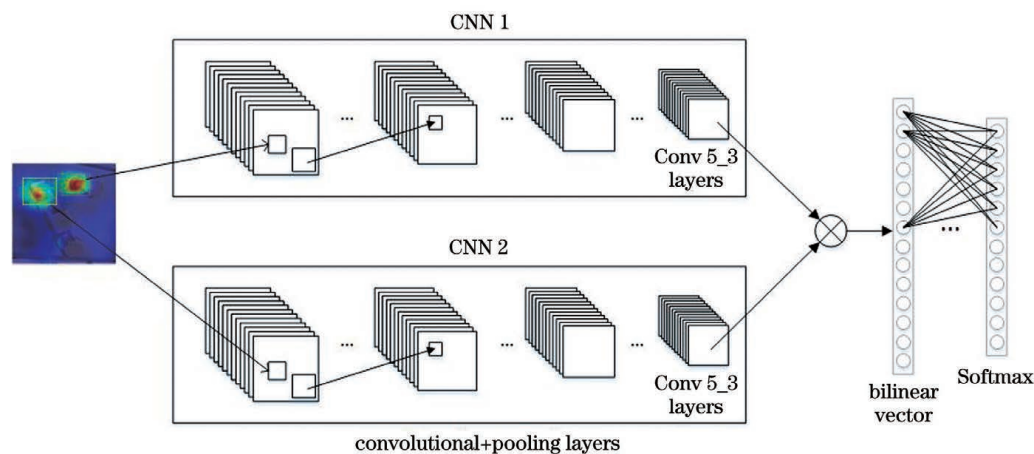


图 1 B-CNN 的结构

Fig. 1 Structure of the B-CNN

B-CNN 主要由两个并列的 VGGNet 共同作用,完成特征的提取,充分利用了图像的二阶统计信息。该网络利用平移不变性实现局部特征间交互关系的建模,同时简化了梯度计算,使端到端的模型更容易训练。B-CNN 模型可由一个四元函数表示为

$$\beta = (f_A, f_B, \Gamma, C_F), \quad (1)$$

式中,  $f_A, f_B$  为特征提取函数,  $A, B$  为不同的特征,  $\Gamma$  为池化函数,  $C_F$  为分类函数, 可通过支持向量机 (SVM) 分类器完成最后的图像分类。

特征提取函数  $f: \mathcal{L} \times \mathcal{I} = \mathbf{R}^{K \times D}$ , 该函数可将输入图像  $I \in \mathcal{I}$  和图像位置区域  $l \in \mathcal{L}$  映射成维度为  $K \times D$  的特征矩阵, 然后利用矩阵外积方法, 将每一个位置  $l$  的组合特征输出, 位置  $l$  处  $f_A, f_B$  的双线性特征组合可表示为

$$\mathbf{X}_b(l, I, f_A, f_B) = f_A(l, I)^T \times f_B(l, I). \quad (2)$$

池化函数  $\Gamma$  可聚集图像中所有位置特征的双线性组合, 以获得全局图像  $\phi(I)$ , 可表示为

$$\begin{aligned} \phi(I) &= \sum_{l \in \mathcal{L}} \mathbf{X}_b(l, I, f_A, f_B) = \\ &= \sum_{l \in \mathcal{L}} f_A(l, I)^T \times f_B(l, I). \end{aligned} \quad (3)$$

在实际应用中, 为了提高模型性能<sup>[15]</sup>, 可对 (3) 式中的  $\phi(I)$  进行归一化操作, 令  $x = \phi(I)$ , 符号平方根  $y \leftarrow \text{sign}(x) \sqrt{|x|}$ , 则变量的归一化可表示为  $z \leftarrow y / \|y\|_2$ 。可以发现, 通过计算特征  $A$  和  $B$  的梯度, 就能采用端到端的方式训练整个模型, 具体过程如图 2 所示。




图 2 梯度计算的流程

Fig. 2 Process of the gradient calculation




图 3 SENet 的基本结构

Fig. 3 Basic structure of the SENet

### 4 改进的网络结构

标准 B-CNN 的特征函数为两路 VGGNet, 虽

### 3 注意力机制模型

普通卷积神经网络 (CNN) 的核心是卷积运算符, 卷积运算符能使网络在每一层的局部接受域内融合空间和通道信息, 从而构造信息特征。为了加强目标检测的准确度, 在普通卷积中加入注意力模块。注意力机制是图像识别中的一项特征强化策略, 该策略源于人类大脑对视觉信号的处理机制。但该方法对一张图像的每个通道都无差别进行特征提取, 与人类关注一张图时的机制明显不同。注意力机制实际上是一种选择性关注机制, 将注意力集中在目标显著部位而忽略一些全局和背景信息, 可赋予包含重要判别信息的特征通道更高的权重分布, 从而有效提升细粒度的分类效果<sup>[17]</sup>。SENet (Squeeze-and-excitation networks) 是 Hu 等<sup>[18]</sup>提出的一种注意力机制模型, 与从空间维度上提升网络性能的模型不同, SENet 从特征通道间的关系入手, 通过学习自动获取每个特征通道的重要程度, 然后提升有用特征、抑制无效特征。SENet 中的注意力机制主要由挤压 (Squeeze)、激励 (Excitation) 及重标定 (Reweight) 构成, 其基本结构如图 3 所示。其中,  $\mathbf{X}$  为输入,  $C$  为特征层的深度,  $W$  为特征图的宽,  $H$  为特征图的高,  $F_{tr}$  为卷积操作,  $F_{tr}(\cdot)$  为卷积操作中的一维展开,  $F_{ex}(\cdot, w)$  为一维展开数据与权重系数  $w$  的乘积,  $F_{scale}(\cdot)$  为两个矩阵相乘的操作。

SENet 的实现流程如图 4 所示, 其中, Conv 为卷积操作。①表示挤压过程, 由一个全局池化函数构成。②表示激励过程, 由两个全连接层 (FC) 构成, 包括 1 个线性整流单元 (ReLU) 激活函数和 1 个 Sigmoid 激活函数。为了减少参数的计算量, 第一个全连接层的系数为  $1/r$ , 第二个全连接层的系数用  $1/r$  乘以  $r$ , 从而实现先降维再升维的操作。③表示重标定过程, 由一个乘积函数构成。

然具有一定的特征表示能力, 但在局部特征的提取上存在一定的局限性<sup>[18]</sup>; 且该网络在参数计算时会耗费较多的计算资源, 计算效率降低。为了提升网

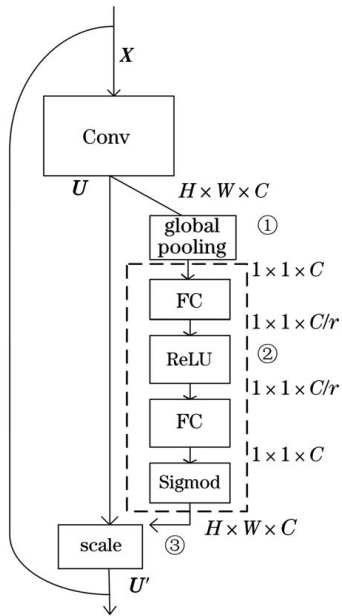


图 4 SENet 的流程

Fig. 4 Flow chart of the SENet

网络的识别准确率,对原始网络结构进行改进。首先,

在原始网络结构中引入注意力机制模块 SENet, 直接对压板的判别性部位特点进行特征提取,从通道相关性角度对原始网络结构进行改进。然后,引入深度残差网络(ResNet-34)提高网络的分类精度。改进后的网络结构如图 5 所示,下文将这种结构统一称为 B-Se-ResNet。

#### 4.1 残差卷积网络

对深度神经网络的研究表明,提升网络深度可以提高图像分类的准确率<sup>[19]</sup>;但当层数超过一定数目(如 30 层)时,会明显增加网络结构的复杂度,使网络在训练时难以达到收敛状态,导致整个系统的误差增大,梯度消失和梯度爆炸<sup>[20]</sup>是导致误差增大的直接原因。针对网络深度增加引起的误差增大问题,文献[21]提出了一种深度 ResNet,通过残差学习(Residual learning)结构将原始输入的信息采用跳跃连接方式堆叠传输至下一层神经网络。残差网络由基本的残差单元构成,其结构如图 6 所示。其中,  $H(X)$  为特征输出,  $F(X)$  为卷积操作后的输出的。

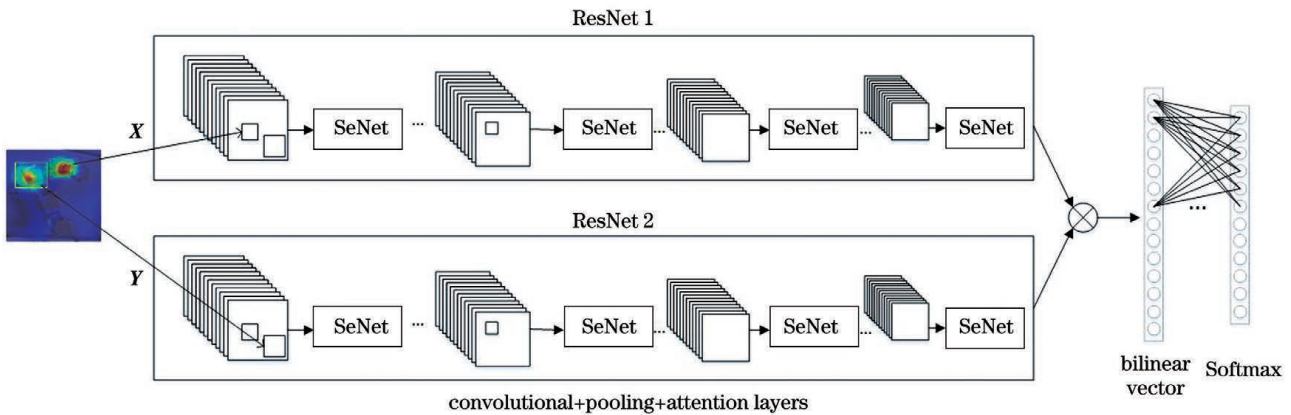


图 5 改进后的网络结构

Fig. 5 Improved network structure




图 6 残差单元的结构

Fig. 6 Structure of the residual unit

#### 4.2 改进的双线性注意力模型

相比 B-CNN 模型的特征函数 VGGNet, ResNet 的网络结构更深,能更准确地提取图像中的局部特征,有效提升分类精度。因此,选取 ResNet-34 作为特征提取函数,在基础 ResNet-34 特征提取网络中,将通道注意力模块添加至卷积层 Conv2 与

Conv3、Conv3 与 Conv4、Conv4 与 Conv5 之间以及 Conv5 后面,形成新的特征提取网络,以获取不同维度和更丰富的图像特征。图 5 中两个多通道的输入分别为  $X \in \mathbf{R}^{N \times \rho}$  和  $Y \in \mathbf{R}^{M \times \phi}$ , 其中,  $\rho = |\{x_i\}|$  和  $\phi = |\{y_j\}|$  分别为两个输入通道的编号,引入的双线性注意力权重矩阵  $\mathbf{A} \in \mathbf{R}^{\rho \times \phi}$ , 则中间层的第  $k$  个

元素可表示为

$$\mathbf{f}'_k = (\mathbf{X}^T \mathbf{U}')^T \mathbf{A} (\mathbf{Y}^T \mathbf{V}')_k, \quad (4)$$

式中,  $\mathbf{U}' \in \mathbf{R}^{N \times K}$ ,  $\mathbf{V}' \in \mathbf{R}^{M \times K}$  ( $\mathbf{X}^T \times \mathbf{U}'$ ) $_k \in \mathbf{R}^\rho$ ,

( $\mathbf{Y}^T \times \mathbf{V}'$ ) $_k \in \mathbf{R}^\phi$ 。(4)式是两组输入通道的双线性模型,也可以表示为

$$\mathbf{f}'_k = \sum_{i=1}^{\rho} \sum_{j=1}^{\phi} A_{i,j} (\mathbf{X}_i^T \mathbf{U}'_k) \times (\mathbf{V}'_k^T \mathbf{Y}_j) = \sum_{i=1}^{\rho} \sum_{j=1}^{\phi} A_{i,j} \times \mathbf{X}_i^T \times (\mathbf{U}'_k \times \mathbf{V}'_k^T) \times \mathbf{Y}_j, \quad (5)$$

式中,  $\mathbf{X}_i$  和  $\mathbf{Y}_j$  为输入  $\mathbf{X}$  的第  $i$  个通道(列)和输入  $\mathbf{Y}$  的第  $j$  个通道,  $\mathbf{U}'_k$  和  $\mathbf{V}'_k^T$  分别为矩阵  $\mathbf{U}'$  和  $\mathbf{V}'$  的第  $k$  列,  $A_{i,j}$  为矩阵  $\mathbf{A}$  第  $i$  行、第  $j$  列的元素。为方便表示,将双线性注意力网络定义为由双线性注意力图参数化的两个多通道输入函数,可表示为

$$\mathbf{f} = X_{\text{BAN}}(\mathbf{X}, \mathbf{Y}; \mathbf{A}). \quad (6)$$

用 Hadamard 乘积和矩阵乘法,将注意力图  $\mathbf{A}$  定义为

$$\mathbf{A} = \text{Softmax}\{[(\mathbf{L} \times \mathbf{p}^T) \times \mathbf{X}^T \mathbf{U}] \mathbf{V}^T \mathbf{Y}\}, \quad (7)$$

式中,  $\mathbf{L} \in \mathbf{R}^\rho$ ,  $\mathbf{p} \in \mathbf{R}^{k'}$ , Softmax 函数为分类函数。  $A_{i,j}$  可表示为

$$A_{i,j} = \mathbf{p}^T \times [(\mathbf{U}^T \times \mathbf{X}_i) \times (\mathbf{V}^T \times \mathbf{Y}_j)]. \quad (8)$$

受多模式残差网络(MRN)的启发,提出了一种 MRN 的变体网络,以整合来自多个双线性注意力图的联合表示。网络第  $i+1$  个输出可表示为

$$\mathbf{f}_{i+1} = X_{\text{BAN}_i}(\mathbf{f}_i, \mathbf{Y}; \mathbf{A}_i) \times \mathbf{L}^T + \mathbf{f}_i, \quad (9)$$

式中,  $\mathbf{f}_0 = \mathbf{X}$ 。为了获得分类器(如两层 MLP)的对数,对最后一个输出通道维度进行求和操作。

## 5 实验数据与结果

### 5.1 实验平台及参数配置

实验使用的开发平台为 Windows 10 操作系统,平台及实验的具体参数如表 1 所示。

表 1 实验平台的参数

Table 1 Parameter of the experimental platform

Name	Configuration
CPU	Intel i5-5200U 2.20 GHz
RAM	8 GB
GPU	NVIDIA GeForce 920 M 4.0 G
GPU acceleration library	CUDA 9.0 cuDNN v7.1
Deep learning framework	Pytorch1.1.0

通过收集变电站的二次侧压板,获得压板的关状态图像 1000 张,标识为 guan,如图 7(a)所示;开状态图像 1000 张,标识为 kai,如图 7(b)所示;未完全处于关状态的图像 672 张,标识为 NS,如图 7(c)和图 7(d)所示。随机选取 200 张关状态图像,134 张开状态图像,200 张未完全处于关状态的图像作为测试集,其余图像作为训练集。即训练集有 2138 张图像,测试集有 534 张图像。




图 7 不同状态的压板图像。(a)guan;(b)kai;(c)NS1;(d)NS2

Fig. 7 Images of press-plate in different states. (a) guan; (b) kai; (c) NS1; (d) NS2

整个网络的训练流程如图 8 所示。其中一个网络的作用是对目标进行识别,另一个网络的作用是对目标关键区域进行定位。

训练前,将所有图像的尺寸都缩放到  $448 \times 448$ ,优化函数为 Adam 函数,最后的输出为 3 类中

的 1 类。在训练时,超参数及部分函数如表 2 所示。

### 5.2 模型评估方法

为了评估改进后模型的性能,用混淆矩阵作为分类结果的评价指标。表 3 为本方法分类结果的混淆矩阵,其中,  $P$  为实际的正例数量,  $P'$  为预测的正

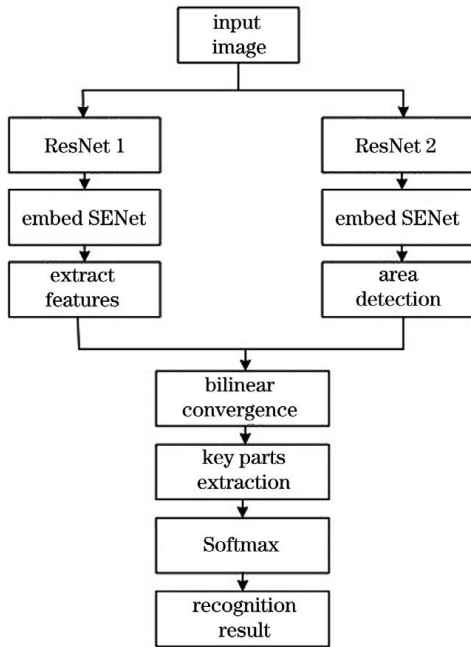


图 8 网络训练的流程图

Fig. 8 Flow chart of network training

表 2 实验的初始参数

Table 2 Initial parameters of the experiment

Experimental parameter	Scene setting
Activation function	ReLU
Number of samples	2672
Learning initial speed	$10^{-4}$
Rate decay coefficient	0.01
Input data dimension	$448 \times 448 \times 3$
Loss function	cross entropy
Number of iterations	3500
Optimization algorithm	Adam
Activation function	Softmax
Output data dimension	3

表 3 混淆矩阵

Table. 3 Confusion matrix

Parameter	Actual value		
Predictive output	$P'$	$X_{TP}$	$X_{FP}$
	$N'$	$X_{FN}$	$X_{TN}$
Total		$P$	$N$

例数量,  $N$  为实际中反例的数量,  $N'$  为预测的反例数量,  $X_{TP}$  为分类正确的正例,  $X_{TN}$  为正确分类的反例,  $X_{FP}$  为错误分类的正例,  $X_{FN}$  为错误分类的反例。

分类准确率  $X_{ACC}$  可表示为

$$X_{ACC} = \frac{X_{TP} + X_{TN}}{X_{TP} + X_{FN} + X_{FP} + X_{TN}} \quad (10)$$

准确率  $X_{ACC}$  为模型判定正确图像数量与总图像数量的比, 在变电站二次侧压板识别中, 总是存在少数标签为 NS 的压板。因此, 单一的准确率已经无法有效评估模型的预测力 ( $X_{PA}$ )。为解决上述问题, 引入精确率 (PPV)、特异度及召回率 (TPR) 指标评估模型的  $X_{PA}$ 。令  $X_{PPV}$  为模型分类正确的正例数量与预测正例数量的比值,  $X_{TPR}$  为模型分类正确的正例数量与实际中所有正例数量的比值, 可分别表示为

$$X_{PPV} = \frac{X_{TP}}{X_{TP} + X_{FP}} \quad (11)$$

$$X_{TPR} = \frac{X_{TP}}{X_{TP} + X_{FN}} \quad (12)$$

混淆矩阵是衡量分类模型准确度中最基本、最直观、计算最简单的方法, 图 9 为本方法和 B-CNN 方法在测试集上的混淆矩阵, 其中, 横坐标为真实标签, 纵坐标为预测的种类。可以发现, 传统 B-CNN 方法对压板状态识别的误差较大, 特别是对于标签

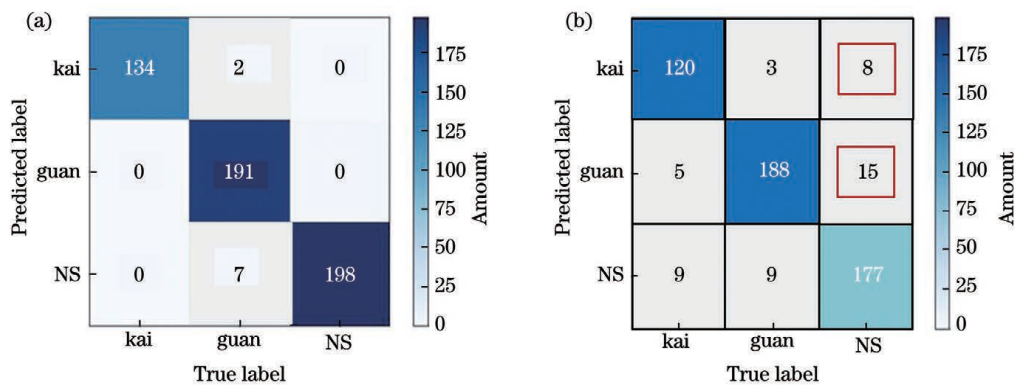


图 9 不同方法的混淆矩阵。(a)本方法;(b)B-CNN

Fig. 9 Confusion matrix of different methods. (a) Our method; (b) B-CNN

为 NS 的压板,误判率高达 11.5%,达不到继电保护的标准。而本方法的误判率有大幅降低,整体准确率较高。

根据混淆矩阵及(7)式、(8)式,计算得到不同方法分类的平均 PPV、TPR,结果如表 4 所示,对比方法包括 Hog+SVM、基于 ResNet 的 B-ResNet、双线性 B-CNN、破坏与重建(DCL)<sup>[22]</sup>、通道机制 CIN<sup>[23]</sup>方法。可以发现,本方法在精确率、召回率上的表现

表 4 不同方法的评价指标

Table 4 Evaluation indicators of different methods

Method	PPV	TPR
B-CNN	0.92	0.91
B-Se-ResNet	0.98	0.94
Hog+SVM	0.88	0.87
B-ResNet	0.94	0.92
DCL	0.95	0.94
CIN	0.96	0.91

均较好,相比目前最先进的 DCL 和 CIN 方法,性能也有小幅度提升。

利用梯度加权类激活映射(Grad-CAM)<sup>[24]</sup>对经神经网络处理后的图像进行可视化,Grad-CAM 可用流入最终卷积层任意目标的梯度生成局部化热图,以突出显示图像中需要预测的目标部分。为验证本方法对不同角度压板状态的识别性能,将这些不同开合角度压板图像送入训练好的网络中,用 Grad-CAM 得到的局部化热图如图 10 所示。可以发现,无论压板的开关角度如何,本方法都能将关注点聚焦于决定压板是否闭合的区域。

图 11 为本方法与 B-CNN 方法识别后的 Grad-CAM 图,可以发现,本方法能在背景杂乱的图像中将关注点聚焦在影响闭合的关键区域;对于压板闭合角度较小(NS 状态)的情况,本方法均能精确定位到图像中的关键区域,传统 B-CNN 方法则出现误判情形。




图 10 不同压板开合角度的 Grad-CAM 图

Fig. 10 Grad-CAM diagrams with different opening and closing angles of the press-plate




图 11 不同方法的识别结果。(a)NS1;(b)NS2;(c)guan;(d)kai

Fig. 11 Recognition results of different methods. (a) NS1; (b) NS2; (c) guan; (d) kai

为了对比本方法 (B-Se-ResNet) 与现有方法的性能, 选取原始 B-CNN、B-ResNet 方法进行对比, 3 种方法在测试集上的准确率、训练集上的损失率如图 12、图 13 所示。可以发现, 3 种方法的分类准确率均随训练步数的增加不断提升, 最终达到较高水平, 但本方法的性能更好, 原因是相比 B-ResNet 与 B-CNN 方法, 本方法引入的 ResNet 深度更深, 且引入了短路结构。此外, 本方法所需的训练步数最少。由于 B-ResNet 深度较深, 卷积层数多, 训练开始时本方法的性能不如 B-CNN 方法, 但随着训练步数的增长, 其最终效果超过了 B-CNN 方法。相比其他 2 种方法, 本方法拥有更高的准确率和更低的损失率。




图 12 不同方法的准确率

Fig. 12 Accuracies of different methods




图 13 不同方法的损失率

Fig. 13 Loss rates of different methods

在测试集中, 将本方法与传统 Opencv、Hog+SVM、AdaBoost、ResNet、B-ResNet、B-CNN、DCL 以及 CIN 方法的准确率进行对比, 结果如图 14 所示。可以发现, 基于 CNN 的方法准确率明显大于传统方法, 而本方法在 CNN 的基础上对识别分类网络进行改进, 提升了压板状态的识别准确率。

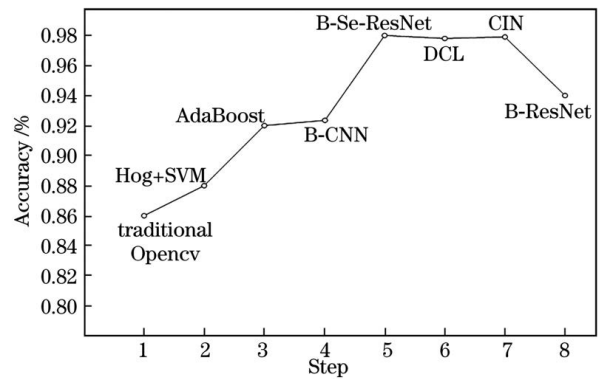


图 14 不同方法在测试集中的准确率

Fig. 14 Accuracies of different methods in the test set

## 6 结 论

为了解决保护压板投切不到位、闭合角度很小时的压板状态识别问题, 提出了一种融合注意力机制的双线性细粒度压板状态识别方法。该方法在基础双线性 CNN 的基础上进行改进, 在原始网络基础上增加了注意力机制模块, 并用残差网络替换了 VGGNet, 增加了网络的深度, 提升了网络的识别精度。实验结果表明, 对于不同压板开合角度, 本方法始终可以聚焦在与压板闭合相关的区域, 为后续的准确识别分类奠定了基础。由于新模型中增加了网络的深度, 为下一层网络的输入引入了更丰富的参考信息, 进一步提高了对应模型的分类精度。下一步研究还需用精确的数量值判定压板是否投退到位。

## 参 考 文 献

- [1] Wang T W, Liu H J, Shao Q Z, et al. Research on intelligent early warning and fault diagnosis technology for the secondary loop of smart substation [J]. *Electrical Measurement & Instrumentation*, 2020, 57(8): 59-63, 98.  
王同文, 刘宏君, 邵庆祝, 等. 智能变电站二次回路智能预警及故障诊断技术研究 [J]. *电测与仪表*, 2020, 57(8): 59-63, 98.
- [2] Gao Y S, Chen Q, Xiong X F, et al. An intelligent verification method for relay protection pressed board [J]. *Journal of Chongqing University*, 2015, 38(6): 91-98.  
高元生, 陈强, 熊小伏, 等. 继电保护压板的智能校核方法 [J]. *重庆大学学报*, 2015, 38(6): 91-98.
- [3] Li X W. Research on the control system of relaying plate of 500 kV substation [D]. Beijing: North China Electric Power University, 2018: 30-34.  
李兴文. 500 kV 变电站二次压板防误管控系统的研



- 究[D]. 北京: 华北电力大学, 2018: 30-34.
- [4] Yao Q H, Dong L H, Zhou L, et al. Research on design and application of intelligent remote switching platen[J]. *Power System Protection and Control*, 2015, 43(20): 143-149.  
姚庆华, 董林会, 周磊, 等. 智能远方投退电动压板的设计与应用研究[J]. *电力系统保护与控制*, 2015, 43(20): 143-149.
- [5] Bao W, Wang K, Gao X, et al. Verification of security measures for smart substations based on visualized simulation[J]. *Power System Protection and Control*, 2018, 46(24): 150-157.  
鲍伟, 王可, 高翔, 等. 基于可视化仿真的智能变电站二次安措校核方法[J]. *电力系统保护与控制*, 2018, 46(24): 150-157.
- [6] Fu W L, Tan J W, Wu X C, et al. Protection platen status recognition based on image processing and morphological feature analysis for smart substation[J]. *Electric Power Automation Equipment*, 2019, 39(7): 203-207.  
付文龙, 谭佳文, 吴喜春, 等. 基于图像处理与形态特征分析的智能变电站保护压板状态识别[J]. *电力自动化设备*, 2019, 39(7): 203-207.
- [7] Deng Y S, Duan Q G, Song X S. State identification of relaying plate based on image recognition[J]. *Shaanxi Electric Power*, 2015, 43(10): 49-53, 67.  
邓应松, 段秦刚, 宋小松. 基于图像识别的保护压板投退状态辨识方法[J]. *陕西电力*, 2015, 43(10): 49-53, 67.
- [8] Xu C, Chen H, Liu S Q, et al. Relaying plate condition recognition technology based on model-based cluster matching and morphological characteristics recognition[J]. *Shaanxi Electric Power*, 2017, 45(1): 32-36, 85.  
许超, 陈昊, 刘少情, 等. 基于模型聚类匹配和形态特征识别的保护压板状态辨识技术[J]. *陕西电力*, 2017, 45(1): 32-36, 85.
- [9] Ji Z, Zhao K X, Zhang S P, et al. Fine-grained fish image classification based on a bilinear network with spatial transformation[J]. *Journal of Tianjin University (Science and Technology)*, 2019, 52(5): 475-482.  
冀中, 赵可心, 张锁平, 等. 基于空间变换双线性网络的细粒度鱼类图像分类[J]. *天津大学学报(自然科学与工程技术版)*, 2019, 52(5): 475-482.
- [10] Ge S Y, Gao Z L, Zhang B B, et al. Kernelized bilinear CNN models for fine-grained visual recognition[J]. *Acta Electronica Sinica*, 2019, 47(10): 2134-2141.  
葛疏雨, 高子淋, 张冰冰, 等. 基于核化双线性卷积网络的细粒度图像分类[J]. *电子学报*, 2019, 47(10): 2134-2141.
- [11] Zhao B, Feng J S, Wu X, et al. A survey on deep learning-based fine-grained object classification and semantic segmentation[J]. *International Journal of Automation and Computing*, 2017, 14(2): 119-135.
- [12] Wang Y, Liu L B. Bilinear residual attention networks for fine-grained image classification[J]. *Laser & Optoelectronics Progress*, 2020, 57(12): 121011.  
王阳, 刘立波. 面向细粒度图像分类的双线性残差注意力网络[J]. *激光与光电子学进展*, 2020, 57(12): 121011.
- [13] Lin T Y, Maji S. Visualizing and understanding deep texture representations[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 2791-2799.
- [14] Li Q N, Sun H X, Sun K J. Fine-grained classification of sleeper shoulder crack images based on improved B-CNN[J]. *Laser & Optoelectronics Progress*, 2020, 57(14): 141013.  
李启南, 孙海鑫, 孙可佳. 基于改进 B-CNN 的轨枕挡肩裂纹图像细粒度分类[J]. *激光与光电子学进展*, 2020, 57(14): 141013.
- [15] Perronnin F, Sánchez J, Mensink T. Improving the fisher kernel for large-scale image classification[M]//Daniilidis K, Maragos P, Paragios N. *Computer vision-ECCV 2010. Lecture notes in computer science*. Heidelberg: Springer, 2010, 6314: 143-156.
- [16] Ma Y J, Ma Y T, Chen J H. Vehicle recognition based on multi-layer features of convolutional neural network and support vector machine[J]. *Laser & Optoelectronics Progress*, 2019, 56(14): 141001.  
马永杰, 马芸婷, 陈佳辉. 结合卷积神经网络多层特征和支持向量机的车辆识别[J]. *激光与光电子学进展*, 2019, 56(14): 141001.
- [17] Zhang Y. Research on the algorithm for fine-grained image classification[D]. Harbin: Harbin Institute of Technology, 2018: 22-23.  
张阳. 细粒度图像分类算法研究[D]. 哈尔滨: 哈尔滨工业大学, 2018: 22-23.
- [18] Hu J, Shen L, Albanie S, et al. Squeeze-and-excitation networks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2020, 42(8): 2011-2023.
- [19] Wu D, Tang X B, Li P, et al. State monitoring technology of substation relay protection device based on deep neural network[J]. *Power System Protection and Control*, 2020, 48(5): 81-85.  
吴迪, 汤小兵, 李鹏, 等. 基于深度神经网络的变电站继电保护装置状态监测技术[J]. *电力系统保护与*

- 控制, 2020, 48(5): 81-85.
- [20] Glorot X, Bengio Y. Understanding the difficulty of training deep feedforward neural networks [J]. Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics, 2010, 9: 249-256.
- [21] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [22] Chen Y, Bai Y L, Zhang W, et al. Destruction and construction learning for fine-grained image recognition [C] // 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA, USA. New York: IEEE Press, 2019: 5152-5161.
- [23] Gao Y, Han X T, Wang X, et al. Channel interaction networks for fine-grained image categorization[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(7): 10818-10825.
- [24] Selvaraju R R, Cogswell M, Das A, et al. Grad-CAM: visual explanations from deep networks via gradient-based localization [J]. International Journal of Computer Vision, 2020, 128(2): 336-359.