

基于注意力机制的卷积神经网络指针式 仪表图像读数识别方法

张 森¹, 万吉林¹, 王慧芳¹, 管敏渊², 杨 斌^{2,3}, 李 凡²

(1. 浙江大学 电气工程学院, 浙江 杭州 310027;

2. 国网浙江省电力有限公司湖州供电公司, 浙江 湖州 313000;

3. 湖州电力设计院有限公司, 浙江 湖州 313000)

摘要:目前关于指针式仪表图像读数识别的研究大多建立在指针线段检测的基础上,然而该方法流程较多、读数识别效率低。并且仪表图像校准、指针线段拟合等中间过程积累的误差容易使指针倾角偏离真实值。因此从另一角度对基于图像特征映射仪表读数的方法进行了研究,该方法的优点是流程短、效率高。首先构建了融合卷积注意力模块的双路异构卷积神经网络,强化了对仪表图像特征的提取,改善了特征的类型和分布,提高了仪表读数识别的准确率;然后采取了软区间分级回归的策略,极大地简化了模型的体积,使得模型易于部署;最后通过算例对比了所提方法和基于指针线段检测的深度学习、机器学习模型识别仪表读数的准确率和效率。算例表明,所提方法在仪表图像读数识别准确率和效率之间取得了较好的平衡。

关键词:指针式仪表;读数识别;卷积神经网络;注意力机制;分级回归;软区间

中图分类号:TM 63;TM 930

文献标志码:A

DOI:10.16081/j.epae.202112027

0 引言

由于变电站环境中存在大量电磁干扰以及指针式仪表具有价格优势等原因,目前变电站中依然存在着大量的指针式仪表^[1-4]。而巡检机器人在变电站的推广极大地方便了指针式仪表图像的获取^[5-7]。为了进一步节约人力成本、提升变电站的自动化、智能化水平,提高变电站巡检图像中指针式仪表读数识别的准确率和效率是非常必要的。

目前绝大部分关于指针式仪表读数自动识别的研究都是建立在仪表指针检测基础上,其中包括文献[8-12]等都是采用霍夫变换方法检测指针获取指针倾角来识别仪表的读数。然而变电站巡检机器人拍摄的仪表图像中,表盘面往往存在较多杂质,在这种情形下以霍夫变换为代表的图形检测算法会检测到大量干扰线段。文献[13]使用图像分割的方法替代霍夫变换提高了检测指针的准确率,但是该方法的流程依然较多,因而计算指针倾角的过程中容易积累误差。通过检测指针线段计算指针倾角来获取仪表读数的方法还会受到仪表表盘校准程度、指针形状与外观等因素的影响。对于精密的指针式仪表而言,指针倾角的细微差异就会使读数识别结果偏离真实值。

近年来,以卷积神经网络 CNN (Convolutional Neural Network) 为代表的深度学习算法在电力图像

识别领域得到了广泛的应用^[14-17]。然而对指针式仪表图像直接采用卷积神经网络回归仪表读数的做法并不合理,因为指针式仪表图像中和读数识别最相关的是仪表指针附近区域,而该区域的面积占据整个表盘区域面积的比例往往很小。卷积神经网络识别仪表读数的准确率取决于提取的图像特征质量,所以目标尺寸小会增加其准确识别仪表读数的难度。此外,目前构建的基于深度学习算法的指针式仪表图像读数识别方法需要较为庞大的数据计算量,并且模型体积比较大。因此,对应用的平台算力等硬件性能有一定的要求,限制了效果优秀的深度学习算法的实际应用。

为了突破检测指针线段识别仪表读数方法的局限及弥补卷积神经网络识别仪表读数的缺陷,本文在卷积神经网络中引入注意力机制:采用双路异构卷积神经网络强化了对仪表图像特征的提取,并加入卷积注意力模块改善了提取特征的类型和分布;考虑到直接回归仪表读数的方式会大幅增加卷积神经网络的参数量,为了减少模型的空间复杂度,本文在设计卷积神经网络时采取分级回归的策略,因而构建的模型还具有体积小、易部署、效率高的优势。

1 指针式仪表图像读数识别方法概述

1.1 基于仪表指针检测的读数识别方法

目前关于指针式仪表图像读数识别的研究大多是建立在仪表指针检测的基础上,该方法的流程如图1所示。可以发现,检测指针识别仪表读数的方法步骤较多,导致该方法识别仪表读数的速度受到限制。并且流程中的步骤2和步骤4容易积累误差,

收稿日期:2021-04-12;修回日期:2021-11-01

基金项目:国网湖州供电公司科技项目(2019-HUZJTKJ-09)

Project supported by the Science and Technology Program of State Grid Huzhou Power Supply Company(2019-HUZJTKJ-09)




图1 检测指针识别仪表读数的流程

Fig.1 Meter reading recognition flowchart based on pointer detection

对仪表指针倾角以及读数识别结果影响较大。

1)步骤2是仪表图像进行自动校准,通常采用的方法是仿射变换或透视变换。要使用这些变换方法,需要在仪表图像中寻找合适的变换基准点。若变换基准点选择得不理想,这些变换方法甚至会增加仪表图像的倾斜程度,而很多情况下理想的变换基准点难以找到。并且这些变换方法通常会对图像造成形变和扭曲,影响后续步骤4中的指针拟合。

2)步骤4决定了仪表读数识别的准确率。为了得到指针的倾角,需要对指针线段进行拟合,通常采用的方法为最小二乘法、梯度下降法、高斯-牛顿法等。然而指针线段拟合的效果受到指针包含的像素数量、指针的外观形状、指针的粗细大小等因素影响。尤其是对于单位角度数值较大的精密仪表而言,指针线段倾角的细微偏差也会使得读数识别结果严重偏离真实值。

而提取仪表指针检测的方法有很多,典型的如采用霍夫变换的方法提取直线段,但是霍夫变换等方法很容易受到表盘面上各种干扰条纹的影响,导致效果不佳。因此文献[13]提出了一种基于U-Net的指针提取方法,并且取得了很好的效果,能够有效排除干扰获取指针。本文也以此作为基于指针检测的仪表读数识别方法的代表。

1.2 基于图像特征映射的读数识别方法

基于图像特征映射的读数识别方法是直接通过分析仪表图像特征来回归仪表读数,该方法没有校准表盘、显式检测仪表指针、拟合指针线段等中间过程,因而流程较短,识别效率较高。该方法直接从已经确定好表盘区域的图像中提取仪表读数结果,因此提取的图像特征质量决定了仪表读数识别的准确率。如前文所述,由于指针等关键部件占据仪表图像的比例极其有限,所以往往很难提取到与读数识别相关的特征,这也是目前该识别方法的研究迟迟未取得进展的重要原因。

早期的图像特征提取方法主要有HOG、SIFT、ORB等,这些方法都需要依靠先验知识进行人工设计,主要差异在于角点检测、边缘计算、图像尺度空间等方面的处理细节。然而人工设计的图像特征抽象程度不足,泛化能力普遍较弱,识别准确率不稳

定,难以适应仪表图像中复杂多变的环境,局限性较大。

自 AlexNet 在 ImageNet 图像分类比赛中取得了优异的成绩后^[18],以卷积神经网络为代表的深度学习算法开始受到更加广泛的关注,并在短短数年内得到了飞速的发展,给基于图像特征映射的读数识别研究带来了新的希望。尽管大量实践证明,在图像识别领域,相比于人工设计方法,卷积神经网络的特征提取能力更强,然而这并不意味着卷积神经网络处理各种图像识别任务时都能轻易获得令人满意的结果。在指针式仪表读数识别任务中,卷积神经网络同样要面临目标特征占比少的难题。如何引导卷积神经网络将注意力集中到与读数识别最相关的特征,提高读数识别的准确率和效率,是本文研究的主要内容。

2 基于注意力机制的卷积神经网络仪表读数识别模型

2.1 强化仪表图像特征提取的双路异构卷积神经网络

卷积神经网络根据功能主要可以划分为卷积层、池化层、归一化层、全连接层等。其中卷积层是通过卷积核提取图像的局部特征,卷积核的大小和数量决定了感受野和特征类型,同时卷积核的滤波方式由于可以共享权值从而极大地减少了模型的参数量。池化层采取的常见方式有最大池化和平均池化,主要作用是进一步减少模型复杂度来缓解过拟合现象。归一化层是将特征图的数据归一化到标准正态分布,主要的作用是抑制梯度消失和梯度爆炸现象。全连接层一般处于卷积神经网络的最后阶段,通过对提取的特征进行加权的方式进行特征分类和筛选。

为了详细说明卷积神经网络识别仪表图像读数的过程,本文搭建了一个经典的9层(不包含输入层和输出层)卷积神经网络,网络的结构如图2所示。网络的第1层为归一化层,作用是将仪表图像的RGB值变换到正态分布下,使网络能够更快收敛。网络的第2—6层为卷积层,作用是提取图像的局部特征,卷积层越深则提取特征的抽象程度越高,即浅层特征反映的是纹理细节,深层特征反映的是语义状态。网络的第7—9层为全连接层,作用是将提取的图像特征映射到仪表读数。




图2 卷积神经网络结构

Fig.2 Structure of CNN

为了强化对仪表图像特征的提取,本文参考文献[19]的工作设计了双路异构卷积神经网络。2路卷积神经网络结构大体一致,但是从激活函数、池化方式、通道数等方面进行了异构化,以提取尽可能不同的特征。改进后的模型结构如图3所示。




图3 双路异构卷积神经网络结构

Fig.3 Structure of two-stream heterogeneous CNN

双路异构卷积神经网络中每一路卷积神经网络的主要基本单元都包含 3×3 的卷积层和池化层,但是为了提取尽可能不同的特征,对2路卷积神经网络进行了异构:上路卷积神经网络使用了ReLU激活函数、平均池化方式,卷积层通道数为32;下路卷积神经网络使用了tanh激活函数、最大池化方式,卷积层通道数为16。

2.2 改善仪表图像特征类型和特征分布的卷积注意力模块

判断指针状态是指针式仪表读数识别的关键。然而在有些指针式仪表图像中指针区域所占比例甚至不足1%。为了提升卷积神经网络提取指针特征的能力,本文在卷积神经网络中加入卷积注意力模块CBAM(Convolutional Block Attention Module)^[20]。卷积注意力模块分为通道注意力模块(channel attention module)和空间注意力模块(spatial attention module),分别能够对中间特征图的特征类型和特征分布进行优化。卷积注意力模块结构如图4所示




图4 卷积注意力模块结构

Fig.4 Structure of CBAM

示。图中: C 为通道数; H 为特征图高度; W 为特征图宽度。

中间特征图中的每一层可以理解为某一类型的特征。为了提取更有效的特征,通道注意力模块的核心思想是使用全局最大池化和全局平均池化来改善特征图中的局部特征。具体地,对于输入特征图 $F \in \mathbb{R}^{C \times H \times W}$,首先基于 F 的宽度、高度,分别经过空间最大池化和空间平均池化得到 $F_{\max}^c \in \mathbb{R}^{C \times 1 \times 1}$ 和 $F_{\text{avg}}^c \in \mathbb{R}^{C \times 1 \times 1}$,然后将两者用同一个多层感知机MLP(Multi-Layer Perceptron)处理后逐元素相加,最后使用Sigmoid函数进行激活后得到通道注意力特征图 $M_c \in \mathbb{R}^{C \times 1 \times 1}$,如式(1)所示。

$$M_c(F) = \sigma(f_{\text{MLP}}(f_{\text{MaxPool}}(F)) + f_{\text{MLP}}(f_{\text{AvgPool}}(F))) \quad (1)$$

式中: $f_{\text{MaxPool}}(\cdot)$ 和 $f_{\text{AvgPool}}(\cdot)$ 分别表示卷积神经网络中的最大池化和平均池化操作; $f_{\text{MLP}}(\cdot)$ 表示多层感知器处理操作; $\sigma(\cdot)$ 为Sigmoid函数。由于 M_c 加入了对全局特征的分析,因而能够对 F 的特征进行一定程度的修正。

空间注意力模块是引导模型在特征图中寻找对最终预测结果影响最大的特征所在的位置。具体地,对于输入特征图 $F \in \mathbb{R}^{C \times H \times W}$,基于 F 的通道分别进行最大池化和平均池化得到 $F_{\max}^s \in \mathbb{R}^{1 \times H \times W}$ 和 $F_{\text{avg}}^s \in \mathbb{R}^{1 \times H \times W}$,然后将两者进行融合操作后输入卷积层,最后使用Sigmoid函数激活后得到空间注意力特征图 $M_s \in \mathbb{R}^{1 \times H \times W}$,如式(2)所示。

$$M_s(F) = \sigma(f_{\text{Conv}}([f_{\text{MaxPool}}(F) \quad f_{\text{AvgPool}}(F)])) \quad (2)$$

式中: f_{Conv} 表示卷积层操作。基于通道注意力模块和空间注意力模块可以分别得到2个注意力特征图 M_c 与 M_s 。 M_c 与 F 逐元素相乘即可得到特征类型改善后的特征图。 M_s 重新计算了特征图平面上各个位置的权重,与 F 逐元素相乘即可得到特征空间分布改善后的特征图。

3 基于软区间分级回归的卷积神经网络

3.1 简化卷积神经网络的分级回归方法

第2节构建的融合卷积注意力模块的双路异构卷积神经网络模型依然有可改进的地方。该模型结构的最后部分使用多个全连接层的方式直接回归仪表读数,而全连接层参数冗余,因此模型的参数较多,空间复杂度较大。要降低模型部署的难度,势必要减小模型体积。为了实现该目标,本文参考Yang等人的工作^[21],将原卷积神经网络模型的直接回归方式替换为分级回归,极大地简化了模型的体积。

分级回归首先将回归任务转化为分类任务,用各类别的期望值来表示回归预测值。具体地,当仪表读数 Y 分布在区间 $[0, V]$ 内时,将该区间细分为 s 个无重叠的子区间,每个子区间的宽度 $w = V/s$ 。并且每个子区间都有1个代表值,当选取子区间的左值

为其代表值时,第 i 个子区间的代表值 $\mu_i = i(V/s)$ 。对于输入图像,模型将输出一组向量 $\mathbf{p} = (p_0, p_1, \dots, p_{s-1})$ 表示预测值 $\tilde{y}$ 在各子区间分布的概率, $\tilde{y}$ 的计算公式为:

$$\tilde{y} = \mathbf{p} \boldsymbol{\mu} = \sum_{i=0}^{s-1} p_i \mu_i = \sum_{i=0}^{s-1} p_i i \left(\frac{V}{s} \right) \quad (3)$$

式(3)所示的识别仪表读数的方式还比较粗糙,为了提升预测精度,可以进一步采取由粗到细、分级回归的策略。假设预测过程共分为 K 个层级,每一层级 k 有 s_k 个子区间,该层级子区间的概率分布为 $\mathbf{p}^{(k)} = (p_0^{(k)}, p_1^{(k)}, \dots, p_{s_k-1}^{(k)})$,则 $\tilde{y}$ 的计算公式为:

$$\tilde{y} = \sum_{k=1}^K \mathbf{p}^{(k)} \boldsymbol{\mu}^{(k)} = \sum_{k=1}^K \sum_{i=0}^{s_k-1} p_i^{(k)} i \left(\frac{V}{\prod_{j=1}^k s_j} \right) \quad (4)$$

分级回归将预测过程划分成多个层级,每一层级只对前一层级的预测结果进行微调,这种方式能够大幅减少每个层级需要预测的类别数,从而能够极大减少模型的参数量,降低模型的复杂度。

3.2 基于分级回归的软区间方法

分级回归过程可以看作是逐级地确定指针所在的区间:先粗略识别仪表读数所在的大范围,然后不断微调缩小区间最终得到更精确的仪表读数预测值。而考虑到仪表读数 Y 在各区间之间存在的“连续性”问题,如指针式仪表的指针落在相邻2个刻度之间等场景,将区间划分为各个不重叠的子区间显得不够灵活,因此软区间回归网络在式(4)的基础上给各子区间加入了缩放量和平移量。加入缩放量的方式为:给各层级的 s_k 添加一个增量 Δ_k ,即 $\bar{s}_k = s_k(1 + \Delta_k)$,则相应子区间的宽度 $\bar{w}$ 如式(5)所示。

$$\bar{w} = \frac{V}{\prod_{j=1}^k \bar{s}_j} = \frac{V}{\prod_{j=1}^k s_j (1 + \Delta_k)} \quad (5)$$

加入平移量的方式为:使每个子区间的索引 i 添加一个增量 η ,即 $\bar{i} = i + \eta$ 。更具体地,当层级 k 共包含 s_k 个子区间时,则有 $\boldsymbol{\eta}^{(k)} = (\eta_0^{(k)}, \eta_1^{(k)}, \dots, \eta_{s_k-1}^{(k)})$,此时有:

$$\bar{i} = i + \eta_i^{(k)} \quad (6)$$

当加入这些缩放量和平移量后,相邻子区间之间便产生了联系,因此能够更好地解决 Y 的连续性分布问题。 $\tilde{y}$ 的最终计算公式为:

$$\tilde{y} = \sum_{k=1}^K \sum_{i=0}^{s_k-1} p_i^{(k)} (i + \eta_i^{(k)}) \left[\frac{V}{\prod_{j=1}^k s_j (1 + \Delta_k)} \right] \quad (7)$$

3.3 识别指针式仪表图像读数的卷积神经网络模型

加入软区间分级回归方法后,本文最终构建的

识别指针式仪表图像读数的模型结构如图5所示。图中,PB表示分级仪表读数预测模块。




图5 融合卷积注意力模块的双路异构软区间分级回归卷积神经网络

Fig.5 Structure of two-stream heterogeneous soft stagewise regression CNN fused with CBAM

图5在图3基础上增加了卷积注意力模块和软区间分级回归方法,模型分为2路卷积神经网络,每路卷积神经网络的基本单元都是 3×3 的卷积层、池化层、卷积注意力模块,主要区别在于卷积层数、激活函数以及池化方式。模型将读数识别回归过程分为3个层级,层级1预测仪表读数的大致区间,层级3预测仪表读数的精细值,融合3个层级的预测结果以回归最终仪表读数。

4 算例分析

4.1 算例情况

实验数据集来源于由巡检机器人在不同时间、不同环境下拍摄的1106张某变电站内多个指针式压力表的图像,这些图像数据集包括了气象因素、角度因素等的影响。上述原始数据集首先采用文献[13]的方法进行预处理,检测并获得仪表盘区域图像,然后经过裁剪缩放后,每张表盘图像的分辨率为 256×256 。处理后的指针式压力表图像如附录A图A1所示。图像中仪表盘倾斜角度不一、指针纤细短小,若采用基于指针线段检测思路识别仪表读数,则图像校准、指针拟合等环节容易产生误差。将数据集按照约4:1的比例随机取884张作为训练集和222

张作为测试集。测试平台为CPU为Core i7-9700K, GPU为单核GEFORCE RTX 3090 Ti。

单一的准确率指标难以全面反映模型的性能表现,为此定义如下3个分指标:小偏差率为读数识别相对误差绝对值在1个单位刻度范围内的图像数量与总图像数量之比;中偏差率为读数识别相对误差绝对值在1~2个单位刻度范围内的图像数量与总图像数量之比;大偏差率为读数识别相对误差绝对值高于2个单位刻度的图像数量与总图像数量之比。定义平均绝对误差MAE(Mean Absolute Error)为测试集中预测值与真实值的绝对误差的平均值。

为了说明融合注意力机制的卷积神经网络识别指针式仪表读数的效果,本文设置了6个对照组。其中,前5个对照组是基于图像特征映射的读数识别方法,分别为基于HOG特征的支持向量机(SVM)模型^[22]、基于HOG特征的随机森林(RF)模型^[23]、基于卷积神经网络的模型(下文简称CNN模型)、加入卷积注意力模块的卷积神经网络模型(下文简称CNN+CBAM模型)、基于软区间分级回归方法的双路异构卷积神经网络模型(下文简称2-CNN模型);第6个对照组为基于仪表指针检测的深度学习方法,具体是表现优秀的基于U-Net图像分割的模型(下文简称U-Net模型)^[13]。

4.2 实验结果与分析

基于图A1所示的仪表盘区域图像,本文模型及6个对照模型的识别结果对比如表1所示。表中, λ_{MAE} 为MAE的值。

表1 指针式仪表读数识别结果对比
Table 1 Comparison of reading recognition results of pointer meter

模型	小偏差率/%	中偏差率/%	大偏差率/%	λ_{MAE} /MPa	总耗时/s	体积/MByte
SVM	50.45	9.01	40.54	0.043 31	0.294	17.4
RF	48.65	21.62	29.73	0.029 65	0.023	2.4
CNN	62.16	22.52	15.32	0.020 07	1.278	49.7
CNN+CBAM	66.67	26.13	7.20	0.018 11	1.387	49.9
2-CNN	72.07	20.27	7.66	0.014 26	2.322	0.6
U-Net	85.58	5.41	9.01	0.012 03	66.477	355.3
本文模型	75.68	17.11	7.21	0.013 75	2.534	0.9

分析表中数据可以得到如下结论。

1)与其他基于图像特征映射的读数识别方法相比,本文模型的读数识别小偏差率、大偏差率、MAE指标均为最优,表明本文模型提取的图像特征质量更高,更适合映射仪表读数。其中,SVM、RF这2种机器学习模型的优势在于模型结构相对简单,识别消耗时间更少,但小偏差率、大偏差率、MAE等指标均劣于以卷积神经网络为代表的深度学习模型。对比CNN+CBAM模型与CNN模型的识别结果可以发现,卷积注意力模块在不明显增加模型大小和识别

耗时的情况下,能够提高读数识别小偏差率,降低大偏差率,减小平均绝对误差,说明了卷积注意力模块能够对模型提取的中间特征进行优化,改善了模型的整体性能。对比2-CNN模型与CNN模型的识别结果可以发现,由于采用分级回归方法减少了每一层级需要预测的类别数,因此大幅减少了全连接层的参数冗余,极大地简化了双路异构卷积神经网络模型体积,读数识别小偏差率、大偏差率、MAE等指标也相对更好,说明了双路卷积神经网络的设计以及软区间分级回归的方式比堆叠全连接层直接回归的方式更优。

2)与基于仪表指针检测的读数识别方法相比,本文方法在小偏差率上虽然不如基于仪表指针检测的U-Net深度学习算法,然而小偏差率、中偏差率的综合表现还是本文方法最优,且两者的MAE指标非常接近,说明本文方法能够实现更高比例的仪表准确读数。同时,基于仪表指针检测的算法流程多、耗时长,识别总耗时为本文模型的26倍,并且该算法模型体积大,约为本文模型体积的400倍,部署难度非常大。因此,本文方法在仪表读数识别准确率、效率、部署难度中取得了较好的平衡。

5 结论

针对基于图像校准、指针拟合思路的指针式仪表图像读数识别方法存在的流程长、效率低、指针倾角计算容易存在偏差以及算法部署难度大等问题,本文提出了基于注意力的卷积神经网络模型,该模型具有以下特点:

1)构建了融合卷积注意力模块的双路异构卷积神经网络,强化了对仪表图像特征的提取,改善了提取特征的类型和分布,提高了仪表读数识别的准确率和效率;

2)采取了软区间分级回归的方式,大幅减少了模型的体积,使得模型适用性更广且容易部署在中小型机器内。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

- [1] 孙凤杰,安田江,范杰清,等. 电力变压器温度表指针位置识别研究[J]. 中国电机工程学报,2007,27(7):70-75.
SUN Fengjie, AN Tianjiang, FAN Jieqing, et al. Study on the recognition of pointer position of electric power transformer temperature meter[J]. Proceedings of the CSEE, 2007, 27(7): 70-75.
- [2] 王欣,孙鹏. 智能变电站中指针式仪表图像自动识别方法[J]. 电气技术,2016(5):7-10.
WANG Xin, SUN Peng. Automatic identification method of the pointer instrument in intelligent substation[J]. Electrical Engineering, 2016(5): 7-10.
- [3] FERRERO A, LAZZARONI M, SALICONE S. A calibration procedure for a digital instrument for electric power quality

- measurement[J]. IEEE Transactions on Instrumentation and Measurement, 2002, 51(4): 716-722.
- [4] 韩绍超, 徐遵义, 尹中川, 等. 指针式仪表自动读数识别技术的研究现状与发展[J]. 计算机科学, 2018, 45(S1): 54-57.
HAN Shaochao, XU Zunyi, YIN Zhongchuan, et al. Research review and development for automatic reading recognition technology of pointer instruments[J]. Computer Science, 2018, 45(S1): 54-57.
- [5] 杨森, 董吉文, 鲁守银. 变电站设备巡检机器人视觉导航方法[J]. 电网技术, 2009, 33(5): 11-16.
YANG Sen, DONG Jiwen, LU Shouyin. Visual navigation method of substation patrol robot[J]. Power System Technology, 2009, 33(5): 11-16.
- [6] 蔡焕青, 邵瑰玮, 胡雯, 等. 变电站巡检机器人应用现状和主要性能指标分析[J]. 电测与仪表, 2017, 54(14): 117-123.
CAI Huanqing, SHAO Guiwei, HU Ji, et al. Analysis of the main performance index and application status of inspection robot in substation[J]. Electrical Measurement & Instrumentation, 2017, 54(14): 117-123.
- [7] 李祥, 崔昊杨, 曾俊冬, 等. 变电站智能机器人及其研究展望[J]. 上海电力学院学报, 2017, 33(1): 15-19.
LI Xiang, CUI Haoyang, ZENG Jundong, et al. Research and prospect of intelligent inspection robot for substation[J]. Journal of Shanghai University of Electric Power, 2017, 33(1): 15-19.
- [8] 石伟, 王朝立, 陈建帅, 等. 基于图像处理的变电站指针式仪表读数研究[J]. 电子科技, 2016, 29(1): 118-120, 127.
SHI Wei, WANG Chaoli, CHEN Jianshuai, et al. Substation pointer instrument reading based on image processing[J]. Electronic Science and Technology, 2016, 29(1): 118-120, 127.
- [9] 房桦, 明志强, 周云峰, 等. 一种适用于变电站巡检机器人的仪表识别算法[J]. 自动化与仪表, 2013, 28(5): 10-14.
FANG Hua, MING Zhiqiang, ZHOU Yunfeng, et al. Meter recognition algorithm for equipment inspection robot[J]. Automation & Instrumentation, 2013, 28(5): 10-14.
- [10] 余世洲, 宋凯, 刘辉, 等. 一种电力指针式仪表读数自动识别的鲁棒方法[J]. 计算机技术与发展, 2018, 28(4): 192-195, 200.
SHE Shizhou, SONG Kai, LIU Hui, et al. A robust method for automatic identification of electricity pointer meter[J]. Computer Technology and Development, 2018, 28(4): 192-195, 200.
- [11] 李巍, 王鸥, 刚毅凝, 等. 一种自动读取指针式仪表读数的方法[J]. 南京大学学报(自然科学), 2019, 55(1): 117-124.
LI Wei, WANG Ou, GANG Yining, et al. An automatic reading method for pointer meter[J]. Journal of Nanjing University(Natural Science), 2019, 55(1): 117-124.
- [12] 邢浩强, 杜志岐, 苏波. 变电站指针式仪表检测与识别方法[J]. 仪器仪表学报, 2017, 38(11): 2813-2821.
XING Haoqiang, DU Zhiqi, SU Bo. Detection and recognition method for pointer-type meter in transformer substation[J]. Chinese Journal of Scientific Instrument, 2017, 38(11): 2813-2821.
- [13] 万吉林, 王慧芳, 管敏渊, 等. 基于Faster R-CNN和U-Net的变电站指针式仪表读数自动识别方法[J]. 电网技术, 2020, 44(8): 3097-3105.
WAN Jilin, WANG Huifang, GUAN Minyuan, et al. An automatic identification for reading of substation pointer-type meters using faster R-CNN and U-Net[J]. Power System Technology, 2020, 44(8): 3097-3105.
- [14] 代杰杰, 滕莹冰, 吴奕姣, 等. 用于电网异物识别的生成式对抗卷积神经网络算法[J]. 电力信息与通信技术, 2020, 18(9): 1-7.
DAI Jiejie, TENG Yingbing, WU Yijiao, et al. A generative adversarial convolution neural network algorithm for foreign body recognition of power grid[J]. Electric Power Information and Communication Technology, 2020, 18(9): 1-7.
- [15] 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.
FU Wenlong, TAN Jiawen, WU Xichun, 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.
- [16] 刘姜, 郭景武, 付子峰, 等. 基于卷积神经网络的电力杆塔图像识别学习算法研究[J]. 通信电源技术, 2020, 37(12): 117-119.
LIU Jiang, GUO Jingwu, FU Zifeng, et al. Study on learning algorithm of power tower image recognition based on convolution neural network[J]. Telecom Power Technology, 2020, 37(12): 117-119.
- [17] 刘梓权, 王慧芳, 管敏渊, 等. 隔离开关图像数据扩充方法及其在自动状态识别中的应用[J]. 高电压技术, 2020, 46(2): 441-447.
LIU Ziquan, WANG Huifang, GUAN Minyuan, et al. Data augmentation method for disconnecting switch images and its application in automatic state recognition[J]. High Voltage Engineering, 2020, 46(2): 441-447.
- [18] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6): 84-90.
- [19] YANG T Y, HSU J H, LIN Y, et al. DeepCD: learning deep complementary descriptors for patch representations[C]//2017 IEEE International Conference on Computer Vision (ICCV). Venice, Italy: IEEE, 2017: 3334-3342.
- [20] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module[C]//Proceedings of the European Conference on Computer Vision. Munich, Germany: Springer, 2018: 3-19.
- [21] YANG T Y, HUANG Y H, LIN Y Y, et al. SSR-Net: a compact soft stagewise regression network for age estimation[C]//Proceedings of the Twenty-Seventh International Joint Conference on Artificial Intelligence. Stockholm, Sweden: ACM, 2018: 1078-1084.
- [22] DALAL N, TRIGGS B. Histograms of oriented gradients for human detection[C]//2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05). San Diego, CA, USA: IEEE, 2005: 886-893.
- [23] 李军锋, 王钦若, 李敏. 结合深度学习和随机森林的电力设备图像识别[J]. 高电压技术, 2017, 43(11): 3705-3711.
LI Junfeng, WANG Qinruo, LI Min. Electric equipment image recognition based on deep learning and random forest[J]. High Voltage Engineering, 2017, 43(11): 3705-3711.

作者简介:



张森

张森(1998—),男,硕士研究生,主要研究方向为智能电网数据挖掘、人工智能应用(E-mail: 1132435751@qq.com);

万吉林(1995—),男,硕士研究生,主要研究方向为智能电网数据挖掘、电力图像处理、机器视觉(E-mail: 2025819879@qq.com);

王慧芳(1974—),女,副教授,博士生导师,通信作者,主要研究方向为多模态数据挖掘、电网状态检修、继电保护与控制(E-mail: huifangwang@zju.edu.cn)。

(编辑 任思思)

Convolutional neural network based on attention mechanism for reading recognition of pointer-type meter images

ZHANG Sen¹, WAN Jilin¹, WANG Huifang¹, GUAN Minyuan², YANG Bin^{2,3}, LI Fan²

(1. College of Electrical Engineering, Zhejiang University, Hangzhou 310027, China;

2. Huzhou Power Supply Company of State Grid Zhejiang Electric Power Co., Ltd., Huzhou 313000, China;

3. Huzhou Electric Power Design Institute Co., Ltd., Huzhou 313000, China)

Abstract: At present, most researches on the reading recognition of pointer-type meters are based on the detection of pointer line segments. However, this method has many processes and low reading recognition efficiency. Besides, the errors accumulated in the intermediate processes such as meter image calibration and pointer segment fitting can easily cause the pointer inclination angle to deviate from its true value. The image feature mapping method for meter readings is studied from another perspective because this method has the advantage of fewer processes and higher efficiency. Firstly, a two-stream heterogeneous convolutional neural network fused with CBAM (Convolutional Block Attention Module) is constructed, which strengthens the extraction of meter image features, improves the type and distribution of features and the accuracy of meter reading recognition. Then a soft stagewise regression strategy is adopted, which greatly simplifies the size of the model and makes the model easy to deploy. Finally, the proposed method is compared with deep learning models based on the pointer line segment detection and other machine learning models on the recognition accuracy and efficiency of pointer-type meter reading recognition by example. Results show that the proposed method maintains a good balance between the accuracy and efficiency of the meter image reading recognition.

Key words: pointer-type meter; reading recognition; convolutional neural network; attention mechanism; stage-wise regression; soft range

(上接第177页 continued from page 177)

Short-term load prediction model based on Attention-BiLSTM neural network and meteorological data correction

WANG Jidong, DU Chong

(Key Laboratory of Smart Grid of Ministry of Education, Tianjin University, Tianjin 300072, China)

Abstract: Most of the load prediction models based on recurrent neural network take historical load data and other factors such as meteorological data together as input features of prediction model, but the internal regularity of meteorological data is poor, so it is not suitable for the input of recurrent neural network. Aiming at the problem, a short-term load prediction model based on Attention-BiLSTM (Attention Bi-directional Long Short-Term Memory) neural network and meteorological data correction is proposed. The maximum information coefficient is adopted to analyze the main factors that affecting the loads. Considering that the load sequence is long and there exists bi-directional information flow, BiLSTM neural network is used for prediction. The attention mechanism is introduced, the influence of key factors is highlighted by the weight of attention, and the internal regularity of load data is excavated. The kernel extreme learning machine is used for error prediction and correction combined with meteorological data, and the load prediction is completed. The real data of a certain area in eastern China is taken as practical example, and the experimental results show that the proposed model has better prediction effect than other models.

Key words: short-term load prediction; maximum information coefficient; Attention mechanism; bi-directional long short-term memory neural network; kernel extreme learning machine

附录 A



图 A1 指针式压力表盘区域图像样例
Fig.A1 Samples of pointer-type pressure meter