

基于深度信任网络模型的乌东选煤厂 铁路车号图像识别方法

尉维洁¹, 齐健¹, 周南¹, 刘化男¹, 高会颖^{2†}

(1. 国家能源集团 新疆能源有限责任公司洗选中心, 新疆维吾尔自治区 乌鲁木齐 830000;

2. 天津美腾科技股份有限公司, 天津 300000)

摘要:精准识别铁路车号可以为煤厂装车提供依据,从而保证装车环节高效顺利地完。为此,提出了基于深度信任网络模型的乌东选煤厂铁路车号图像识别方法。首先,利用高速摄像机设备采集原始的车号图像,并利用索贝尔算子检测图像边界;然后,根据列车车号的字体笔画宽度特点,采笔画宽度变换算法定位确定图像中的车号区域,并利用LBP算法提取车号区域内的特征;最后,将提取的特征输入到深度信任网络模型中,在训练网络模型并不断更新参数后,准确识别车号图像。实验表明:该方法能够精准识别乌东选煤厂铁路列车车号图像。在深度信任网络模型中,当受限玻尔兹曼网络为4层、隐含层节点个数为128个时,该模型的分类识别能力最强,训练损失最小,性能最佳。

关键词:深度信任网络;边界检测;车号定位;图像识别;笔画宽度变换;特征提取

中图分类号:TP751

文献标识码:A

Image Recognition Method of Railway Car Number of Wudong Coal Preparation Plant Based on Deep Trust Network Model

WEI Weijie¹, QI Jian¹, ZHOU Nan¹, LIU Huanan¹, GAO Huiying^{2†}

(1. National Energy Group Xinjiang Energy Co., Ltd., washing Center, Urumqi, Xinjiang 830000, China;

2. Tianjin Meiteng Technology Co., Ltd., Tianjin 300000, China)

Abstract: Accurate identification of railway vehicle number can provide basis for coal plant loading, thus ensuring the efficient and smooth completion of the loading process. Therefore, a method of railway vehicle number image recognition based on deep trust network model in Wudong Coal Preparation Plant is proposed. Firstly, the original vehicle number image is collected by high-speed camera equipment, and the image boundary is detected by Sobel operator; Then, based on the font stroke width characteristics of the train number, a stroke width transformation algorithm is used to locate and determine the train number area in the image, and the LBP algorithm is used to extract features within the train number area; Finally, the extracted features are input into the deep trust network model. After training the network model and constantly updating the parameters, the vehicle number image is accurately recognized. The experiment shows that this method can accurately recognize the train number image of Wudong Coal Preparation Plant. In the deep trust network model, when the restricted Boltzmann network is 4 layers and the number of hidden layer nodes is 128, the model has the strongest classification recognition ability, the minimum training loss and the best performance.

Key words: deep trust network; boundary detection; vehicle number positioning; image recognition; stroke width change; feature extraction

乌东选煤厂坐落于新疆,是我国西部地区规模最大的动力煤选煤厂^[1,2]。在该煤厂原装车系统中,已配备了 RFID 车号识别系统,正常情况下可以满足日常作业需求,但是车厢射频识别 IC 卡消磁或 RFID 系统出现故障时,则无法对煤厂铁路车号进行识别,进而影响装车作业进度。另外在自动化改造的大环境下,对铁路车号实行自动化识别改造也是一种趋势,所以提出另外一种铁路车号图像识别方法对原有 RFID 车号识别系统进行补充非常必要^[3-5]。

近年来,国内外学者关于车号图像识别问题进行了较多研究,并取得了一定的研究成果,如李猛坤等^[6]利用车载视频获取原始车号图像,再通过滤波算法对原始车号图像实行预处理,去除图像噪声及畸变影响,再将去噪后的图像输入至神经网络结构中识别车号。王志明等^[7]依据 YOLOv3 算法将车号图像的识别过程分为两个阶段,首先是利用全局检测确定车号所在区域,然后通过局部检测获取车号字符,依据字符的空间关系确定最终的车号。上述两种方法虽然可以对车号图像起到一定的识别作用,但是第一种方法在对车号图像进行识别前没有对车号所在区域进行定位,这会导致算法在对车号进行识别时,不能直接找到准确位置,影响识别效率;第二种方法则没有对原始车号图像进行预处理,这样会影响最终的识别效果。

此外,文献[8]中提出了一种基于深度学习的模糊车牌字符识别方法,该方法首先将卷积循环神经网络中的常规卷积神经网络改为深度可分离的微改模型,并引入 CTC 损失函数训练网络模型。基于此,为避免模型训练过程过拟合,在损失函数中加入 L2 正则项。最后,引入批量归一化算法来加快训练过程中的学习速度,使得该方法可以在复杂场景下识别模糊车牌字符。文献[9]中提出了一种基于卷积神经网络的复杂光照变化车牌图像识别方法。该方法针对复杂光照变化环境,首先对车牌图像的核心目标实施聚类增强,并将其输入到深度可分离卷积网络中,获取车牌图像特征图。然后,将其变换为特征序列,通过双向循环神经网络的学习与预测过程,得到车牌图像特征序列,从而实现车牌图像的识别。基于上述分析,考虑到深度信任网络模型是深度学习模型的一种,该模型兼具了无监督学习与有监督学习的优点,具有学习深度高、分类识别能力强的特点^[10],因此,本文提出

基于深度信任网络模型的乌东选煤厂铁路车号图像识别方法,可以实现对乌东选煤厂铁路车号图像的精准识别,具有较强的应用性。

1 乌东选煤厂铁路车号图像识别

1.1 乌东选煤厂铁路车号图像识别基本框架

通常情况下,列车车号由字母和数字混合组成,采用喷绘的方式标识在列车上^[11,12],乌东选煤厂也采用此种方法对铁路列车车号进行标识。列车车号的特点主要为:

- ①车号字符容易受到光照条件影响;
- ②车号字符采用水平方式进行排列,但没有明显轮廓边框;
- ③车号区域周围的横向纹理较为显著;
- ④车号字符的笔画宽度大致相同,但大小未必相同。

根据乌东选煤厂铁路列车运行实际情况,结合列车车号的特点,设计了乌东选煤厂铁路车号图像识别基本框架,如图 1 所示。




图 1 车号图像识别基本框架

根据此基本框架可知,对乌东选煤厂铁路车号图像进行识别主要分为五个部分,即车号图像的采集、图像预处理、车号区域定位、图像特征提取、字符识别。其中,车号区域定位是整个识别方法中较为重要的部分,它是进行铁路车号图像识别的前提,只有精准定位了车号所在区域,才能实现乌东选煤厂铁路车号图像的正确识别。

1.2 乌东选煤厂铁路车号图像的采集与预处理

1.2.1 车号图像采集

乌东选煤厂铁路车号图像的采集可以通过高速摄像机、数码相机等设备来实现,具体做法为:在拍摄区域内安装可调节支架,将装有拍摄设备的保护箱固定在支架上,根据实际情况对支架高度与角度进行调整,并利用 LED 光源对拍摄区域的光线进行补偿,以此提升拍摄图像的质量。

1.2.2 车号图像预处理

由于采集到的乌东选煤厂铁路原始车号图像通常为连续的动态图像,图像的边界较为模糊,不利于车号的识别。为了增强车号图像边界,避免图像干扰,就需要对采集到的原始车号图像进行边界检测。车号图像边界实际就是某些像素点的集合,这些像素点描述了四周像素灰度值出现阶跃或屋顶的改变,使图像灰度具有间断性。图像边界检测的结果直接影响后续图像的定位与识别。本文采用在边界问题中应用较为广泛的索贝尔(Sobel)算子对乌东选煤厂铁路原始车号图像进行边界检测。

令 $G(x, y)$ 表示乌东选煤厂铁路原始车号图像,选定相同尺寸区域中的数据,在 3×3 的矩阵模板中得到梯度值 A 。用 A 与设置好的临界值 C 作对比。当 $A > C$ 时,该区域就是车号图像的边界;当 $A \leq C$ 时,该区域不是车号图像的边界。另外,不同场景中, A 与 C 的值也不一样,应根据车号图像实际的拍摄条件对临界值进行相应的设置。针对乌东选煤厂铁路车号图像的灰度值,可将上一帧图像的平均梯度值当作目前帧图像的梯度临界值,再采用模板对检测后的乌东选煤厂铁路车号二值图像实行腐蚀操作,去除孤立点并细化图像边缘,得到边界清晰的车号图像。

1.3 基于 SWT 算法的乌东选煤厂铁路车号区域定位

由于列车车号具有字体笔画宽度较为相近的特点,为此本文从车号图像的边界特征着手,通过笔画宽度变换(Stroke Width Transform, SWT)算法对乌东选煤厂铁路车号进行定位。SWT 算法首先通过运算得到关于笔画宽度的车号图像检测图,然后根据车号字符笔画的宽度对检测图进行挑选,形成连通域,提取所有具有可能性的候选车号区域,并分析这些候选区域的集合特征,从而获取车号区域位置。

利用 SWT 算法对乌东选煤厂铁路车号进行定位的步骤如下。

步骤 1:将经过边界检测的乌东选煤厂铁路车号图像输入至 SWT 算法中。

步骤 2:计算所有车号图像边界点的笔划宽度。设定车号图像边界像素点用 P 描述,沿梯度方向的射线用 $H = P + n \cdot DP (n \geq 0)$ 描述,其中,笔划宽度用 D 描述,搜寻范围用 $n = 5D$ 描述。由 P 开始沿 H 进行搜寻,若搜寻到另一个边界像

素 Q , 如果 Q 和 P 的梯度指向相反且 $|DP + DQ| < \frac{\pi}{2}$, 则终止搜寻,二者构成一个笔画,其宽度 $D = \|P - Q\|$ 。如果在 $n > 5D$ 时,仍未找到符合要求的 P , 则选择新的边界点进行上述操作。

步骤 3:利用步骤 2 遍历整个乌东选煤厂铁路车号图像,得到 SWT 检测图,并进行二值化操作。如果拐角位置出现同一边界点存在多个笔画宽度,且每个宽度值均不正确,那么就需要对其进行二次运算,得到合理的笔画宽度值。

步骤 4:根据车号字符笔画的宽度对检测图进行挑选,形成连通域。

步骤 5:将获取的分散的连通域形成车号区域。根据车号字体笔画宽度较为相近的分布特点,通过闭运算去掉中间间隔,初步筛选连通域,然后将符合笔画宽度条件的像素点通过高斯滤波直接聚合成车号区域,再根据车号区域的几何特征进行二次筛选,最终锁定车号区域位置。

1.4 乌东选煤厂铁路车号图像识别

为了减少模型的运算量,提升车号图像的识别效率,在对乌东选煤厂铁路车号图像进行识别前,先对其进行特征提取。

1.4.1 基于 LBP 算法提取车号图像特征

局部二值模式(Local Binary Patterns, LBP)算法是描述图像局部特征的非参数算法,可以较好地表示出特征像素点和所有像素点的灰度关系,尤其在图像纹理信息提取方面的表现极为突出^[13-15]。而乌东选煤厂铁路车号图像的特征主要就表现在纹理特征方面,因此本文利用该算法对其进行特征提取。

通常情况下, LBP 算法的邻域为 3×3 的窗口,设定经过定位后的乌东选煤厂铁路车号图像中位于某一区域的像素点用 $s_m(x_m, y_m)$ 描述,并将其作为参考值。然后,对该像素点 8 个方向上的邻域像素点实施二值化处理,从而获得各像素点的灰度值 s' 。如果 $s' \leq s_m$, 那么邻域点值就设置成 0; 如果灰度值 $s' > s_m$, 则邻域点值设置成 1。关于 LBP 的编码可以描述为:

$$\begin{cases} T_{\text{LBP}}(x_m, y_m) = \sum_{k=0}^7 f(s_k - s_m) 2^k \\ f(x) = \begin{cases} 1, x > 0 \\ 0, x \leq 0 \end{cases} \end{cases} \quad (1)$$

式中,位置是 k 的邻域像素点用 s_k 描述。

利用 LBP 算法提取乌东选煤厂铁路车号图像特征的过程可以描述为:首先利用 LBP 对车号图像各像素点进行编码,得到乌东选煤厂铁路车号 LBP 编码图像,然后提取 LBP 直方图,利用直方图描述乌东选煤厂铁路车号图像特征。为了方便后续运算,将提取出的特征转换为数据矩阵。

1.4.2 基于深度信任网络模型的铁路车号图像识别

深度信任网络(Deep Belief Network, DBN)在各类识别问题中有着广泛的应用,其可以分为两部分内容,分别为受限玻尔兹曼机(RBM)网络与 BP 神经网络,其中 RBM 是无监督网络,层数为多个,而 BP 网络则为有监督网络,层数为 1 个。本文采用 DBN 模型对乌东选煤厂铁路车号图像进行识别。

深度信任网络的训练分为预训练与微调二部分。其中,预训练主要是针对 RBM 的训练,其训练方式为依次训练所有的层次;而微调部分则是利用对 BP 网络的训练来调节整个 DBN 参数。总的来说,训练 RBM 在本质上就是对 BP 网络权值的初始化,这样可以解决 BP 网络训练时间过长以及易进入局部最优的问题,从而可以快速、准确地对乌东选煤厂铁路车号图像进行识别。

① RBM

RBM 的主要结构为可见层和隐含层,二者间以神经元互联的形式连接,各层内部则不存在任何连接。

设定可见层和隐含层都是二值变量,两层中神经元个数用 I 与 J 描述,可见层内处于位置 i 的神经元用 v_i 描述,隐含层内处于位置 j 的神经元用 h_j 描述,那么关于 RBM 的能量函数可以描述成:

$$E(v, h | \theta) = - \sum_{i=1}^I a_i v_i - \sum_{j=1}^J b_j h_j - \sum_{i=1}^I \sum_{j=1}^J w_{ij} v_i h_j \quad (2)$$

式中, v_i 和 h_j 的连接权值用 w_{ij} 描述,二者的偏置值分别用 a_i 和 b_j 描述, RBM 的参数用 $\theta = (w_{ij}, a_i, b_j)$ 描述。基于 $E(v, h | \theta)$, 获取关于 (v, h) 的联合概率分布为:

$$p(v, h | \theta) = \exp^{-E(v, h | \theta)} / Z(\theta) \quad (3)$$

式中,配分函数用 $Z(\theta) = \sum_v \sum_h \exp^{-E(v, h | \theta)}$ 描述。

因为 RBM 中各层中的神经元没有任何连接关系,如果已知可见层中节点状态,所有隐含层中节点在激活状态下互为独立,那么隐含层中位置是 j 的节点的激活概率可以描述为:

$$p(h_j = 1 | v, \theta) = \sigma(b_j + \sum_{i=1}^I w_{ij} v_i) \quad (4)$$

式中, Sigmoid 函数用 $\sigma(x) = \frac{1}{1 + \exp^{-x}}$ 描述。

如果已知隐含层中节点状态,那么可见层中位置是 i 的节点的激活概率可以描述为:

$$p(v_i = 1 | h, \theta) = \sigma(a_i + \sum_{j=1}^J w_{ij} h_j) \quad (5)$$

获取 θ 值是 RBM 训练要实现的目标,只有得到 θ 值,才可以拟合训练数据。 θ 的获取可以描述为:

$$\theta^* = \arg \max_{\theta} L(\theta) = \arg \max_{m'} \sum_{m'=1}^M \ln p(v^{m'} | \theta) \quad (6)$$

式中,似然函数用 $L(\cdot)$ 描述,样本数量用 M 描述, $m' \in M$ 。

利用对比散度(Contrastive Divergence, CD)算法更新来 RBM 中的参数,过程如下:

$$\Delta w_{ij} = \ell(\langle v_i h_j \rangle_{\text{data}} - \langle v_i h_j \rangle_{\text{recon}}) \quad (7)$$

$$\Delta a_i = \ell(\langle v_i \rangle_{\text{data}} - \langle v_i \rangle_{\text{recon}}) \quad (8)$$

$$\Delta b_j = \ell(\langle h_j \rangle_{\text{data}} - \langle h_j \rangle_{\text{recon}}) \quad (9)$$

式中,学习率用 ℓ 描述,数学期望用 $\langle \cdot \rangle_{\text{data}}$ 描述,更新后的期望用 $\langle \cdot \rangle_{\text{recon}}$ 描述。

② BP 网络

在 DBN 中,可以将 BP 网络看作有监督的识别器,识别从 RBM 获取的关于乌东选煤厂铁路车号图像的向量信息,并调整深度信任网络的参数,通过迭代寻优实现对乌东选煤厂铁路车号图像的准确识别。

BP 网络的训练方式为前向与后向相结合的传播方式。首先把 RBM 获取的关于乌东选煤厂铁路车号图像向量信息由输入层传播至输出层,得到乌东选煤厂铁路车号图像识别结果,用该结果与预设的期望结果对比可得二者误差,此过程为前向传播;后向传播的目的在于向后回传误差,并调整 DBN 参数。在后向传播时,需要求出各层的灵敏度 ζ , 利用 ζ 的传播调整权值参数。在输出层中,假设 c_i 、 g_i 分别表示节点 i 处的实际输出与期望

输出,则 ζ 的计算过程为:

$$\zeta_i = c_i(1 - c_i)(g_i - c_i)$$

(10)

对于位置是 l 的隐含层来说,其 ζ 可以描述为:

$$\zeta_i^l = y_i^l(1 - y_i^l) \sum_j w_{ij}^l \zeta_j^{l+1}$$

(11)

式中,隐含层 l 的输出用 y_i^l 描述。

求得每一层的灵敏度后,便可以更新 DBN 的权值参数,描述为:

$$w_{ij}^l = w_{ij}^l + \dot{l} \times y_i^l \zeta_j^{l+1}$$

(12)

$$b_j^l = b_j^l + \dot{l} \times \zeta_j^{l+1}$$

(13)

利用上述方法便可完成 DBN 模型的构建。将经过特征提取后的乌东选煤厂铁路车号图像数据输入至 DBN 模型中,最终可实现车号图像的识别。

综上所述,基于 LBP-DBN 算法的乌东选煤厂铁路车号图像识别的实现过程如下。

过程 1:在乌东选煤厂铁路车号图像样本集中,划分出训练集与测试集两部分。然后利用 LBP 算法提取样本特征,将提取后的特征转换成行向量数据矩阵,将用于模型训练的特征数据矩阵集作为训练数据集。

过程 2:构建关于乌东选煤厂铁路车号图像识别的 DBN 模型。设置 DBN 模型 RBN 层数为 4 层、各隐含层节点个数为 128 个。

过程 3:将转换成特征数据矩阵的训练样本输入至构建好的 DBN 模型内进行训练。在 RBN 网络中,上一层隐含层的输出可当作下一层可见层的输入,利用 CD 算法逐层迭代训练 RBN 网络包含的所有层,直至训练完成,得到 RBN 网络的最优参数。

过程 4:将获取的 RBN 最优参数输入 BP 网络中,在正反向传播过程中,根据灵敏度的变化情况调整模型的参数,得到最优模型。

过程 5:将转换成特征数据矩阵的测试样本输入至已调整好的 DBN 模型内进行测试,得到乌东选煤厂铁路车号,完成对车号图像的识别。

2 实验与结果分析

以乌东选煤厂铁路列车为实验对象,该厂属于矿井型选煤厂,使用的是重介工艺,洗选深度高,生产能力强,产品质量好。该选煤厂生产出的产品主

要通过铁路运输的方式进行运送。

为了验证本文方法的有效性,实验对乌东选煤厂铁路列车车号进行了识别。实验使用 Basler acA1920-40gc GigE 高速摄像机、Kowa LM6HC 工业镜头、100 W 可控 LED 补偿光源作为获取原始车号图像的拍摄设备。实验相关参数如表 1 所示。

表 1 实验参数设置

参数名称	数值
RBN 层数/层	4
各隐含层节点数量/个	128
车号图像训练样本数量/个	480
车号图像测试样本数量/个	80
像素点邻域窗口大小	3×3
学习率	0.05
最大迭代次数/次	50

车号图像识别过程与最终的结果如图 2 所示。

由图 2 可知,根据乌东选煤厂铁路列车车号图像平台可以直观地看出,利用本文方法对乌东选煤厂铁路列车车号进行了精准定位与识别,最后得到的识别结果为 C800025874,与采集的车号图像信息一致。由此说明本文方法有效,且识别精度高,可以为乌东选煤厂装车作业提供依据。

Kappa 系数是描述识别结果和参考数据符合程度的评价指标,具有较强的客观性。该指标值与识别精度呈正相关性。因此实验在不同信噪比条件下,运用 Kappa 系数对本文方法的性能进行考量。Kappa 系数可以描述为:

$$K = \frac{N \sum_{i=1} o_{ii} - \sum_{i=1} (o_i + o_i')}{N^2 - \sum_{i=1} (o_i + o_i')}$$

(14)

式中,样本总数用 N 描述,混淆矩阵中位于第 i 行与第 i 列数据分别用 o_i 和 o_i' 描述。

经过测试得出的实验结果,如图 3 所示。

由图 3 可知,利用本文方法识别乌东选煤厂铁路列车车号图像,在 Kappa 系数方面表现较好,即使是在信噪比为 0,学习率为 0.03 的条件下,Kappa 系数值也达到 0.85 以上;当信噪比为 160 dB,学习率为 0.05 时,Kappa 系数值更是接近 1。由此说明,本文方法对于乌东选煤厂铁路列车车号图像的识别精度高,性能好。

为了测试网络深度及节点个数对 DBN 模型分类识别效果的影响,实验在识别不同数量乌东选煤厂铁路车号图像的情况下,对 DBN 模型中 RBN

层数为 3 层、4 层、5 层时的识别精度,以及各隐含层节点个数分别为 64、128、256 时的训练损失情况进行了测试,得出的结果如图 4 所示。



(a)原始车号图像



(b)图像边界检测结果



(c)车号区域划分结果



(d)特征识别结果



(e)最终的识别结果

图 2 车号图像识别过程与结果






图 3 不同学习率下的 Kappa 系数变化情况



(a) 识别精度比较



(b) 训练损失比较

图 4 网络深度及节点个数对 DBN 模型分类识别效果的影响

由图 4 可知,从识别精度方面看,RBN 层数为 4 层时 DBN 模型的识别精度最高,均在 95% 以上,尤其是车号图像数量为 50 时,识别精度已趋于 100%,而其他结构的 DBN 模型的在识别精度方面均逊色于该结构。由此说明,在 DBN 模型中 RBN 层数设置 4 层时,有着较强的分类识别能力。

从训练损失方面看,各条训练损失曲线均随着车号图像数量的增加呈小幅度上升趋势,其中各隐含层节点的数量为 264 个时,DBN 模型的训练损失最大;隐含层节点的数量为 128 个时,训练损失值最小。

综上所述,当 RBN 层数为 4 层、各隐含层节点个数为 128 个时,DBN 模型的分类识别能力最强,训练损失最小,性能最佳。

3 结 论

为了解决乌东选煤厂原装车系统中,有时不能识别铁路列车车号的问题,提出了一种基于深度信任网络模型的乌东选煤厂铁路车号图像识别方法,对原有的装车系统进行了有力补充。该方法利用深度信任网络模型较强的学习能力,实现了乌东选煤厂铁路车号图像的精确识别。通过实验证明,本文方法在车号图像识别方面有着较好的表现,比较适合用于此类问题的解决。

参考文献

[1] 郭松,范存群. 基于重要度理论的图像识别方法[J]. 计算机集成制造系统,2021,27(9):2736—2740.

[2] 刘昱彤,李鹏,孙云云,等. 基于深度动态联合自适应网络的图像识别方法[J]. 计算机科学,2021,48(6):131—137.

[3] 王军敏,樊养余,李祖贺. 基于深度卷积神经网络和迁移学习

的纹理图像识别[J]. 计算机辅助设计与图形学学报,2022,34(5):701—710.

[4] 胡龙辉,王朝立,孙占全,等. 基于 WGAN 的图像识别方法[J]. 控制工程,2020,27(12):2168—2175.

[5] 樊红卫,胡德顺,高烁琪,等. 基于深度信念网络的铁谱图像智能识别方法与试验验证[J]. 润滑与密封,2021,46(7):15—22.

[6] 李猛坤,柯正轩,于定荣,等. 基于移动边缘计算的车联网车牌号码识别算法[J]. 计算机工程与设计,2021,42(11):3151—3157.

[7] 王志明,刘志辉,黄洋科,等. 基于深度学习的高效火车号识别[J]. 工程科学学报,2020,42(11):1525—1533.

[8] 张彩珍,李颖,康斌龙,等. 基于深度学习的模糊车牌字符识别算法[J]. 激光与光电子学进展,2021,58(16):259—266.

[9] 陆志香,杨梅. 基于卷积神经网络的复杂光照变化车牌图像识别[J]. 激光杂志,2022,43(5):145—150.

[10] 刘洋,金忠. 一种结合非局部和多区域注意力机制的细粒度图像识别方法[J]. 计算机科学,2021,48(1):197—203.

[11] 赵升,赵黎. 基于双向特征金字塔和深度学习的图像识别方法[J]. 哈尔滨理工大学学报,2021,26(2):44—50.

[12] 秦毅,吴蔚. 基于 CNN 的计算机生成图像识别方法[J]. 西南师范大学学报(自然科学版),2019,44(5):109—114.

[13] 曹子昱,任宛星,付连著,等. 基于卷积神经网络的调车机车前方车列图像识别算法[J]. 中国铁道科学,2020,41(6):156—163.

[14] 徐自远,蔡妍娜. 复杂形状物体的图像识别方法研究[J]. 计算机仿真,2022,39(6):228—232.

[15] 闫涵,张旭秀,张净丹. 多感知兴趣区域特征融合的图像识别方法[J]. 智能系统学报,2021,16(2):263—270.