

DOI:10.20033/j.1003-7241.(2026)03-0152-05

基于特征融合和 RNN 的电力场景图像数据自动标注方法

林嘉鑫, 裴求根, 钱正浩, 阮伟聪, 吴文远

(广东电网有限责任公司, 广东 广州 510620)

摘要:针对现有图像标注技术在处理电力场景复杂序列信息时计算复杂、表征单一的问题,研究提出了一种基于多尺度特征融合与循环神经网络(recurrent neural network, RNN)的电力场景图像自动标注方法。首先,采用卷积神经网络(convolutional neural network, CNN)作为编码器提取图像特征,创新性地引入了多尺度特征融合机制,以捕捉图像的细节与全局信息。其次,利用 RNN 作为解码器处理图像特征序列,通过引入 Dropout 正则化技术抑制模型过拟合,并结合 Sigmoid 交叉熵损失函数优化模型训练过程,构建端到端的图像标注模型。基于多尺度特征融合和 RNN 的图像标注模型在准确率结果分别为 0.41、0.40、0.43、0.41、0.43,召回率结果分别为 0.39、0.40、0.42、0.41、0.41。与语义分割、多边形标注等方法相比,该模型的标注时间最短,仅 2.2 s。研究提出的模型有效解决了电力场景图像中序列关系的建模问题,具有较高的应用推广价值。

关键词:电力场景;图像标注;特征融合;循环神经网络;时间序列;Dropout 正则化;损失函数

中图分类号: TP391.41; TP18

文献标志码: A

文章编号: 1003-7241(2026)03-0152-05

Automatic annotation method of power scenario image data based on feature fusion and RNN

LIN Jiaxin, PEI Qiugen, QIAN Zhenghao, RUAN Weicong, WU Wenyan

(Guangdong Power Grid Co., Ltd., Guangzhou 510620, Guangdong, China)

Abstract: In response to the problems of high computational complexity and single representation in the existing image annotation techniques when dealing with complex sequence information in power scenarios, a method for automatic image annotation of power scenarios based on multi-scale feature fusion and recurrent neural network (RNN) is proposed. Firstly, a convolutional neural network (CNN) is used as the encoder to extract image features, and a multi-scale feature fusion mechanism is innovatively introduced to capture the details and global information of the image. Secondly, RNN is used as the decoder to process the image feature sequence. Dropout regularization technology is introduced to prevent overfitting of the model, and the Sigmoid cross-entropy loss function is combined to optimize the model training process, thereby constructing an end-to-end image annotation model. The image annotation model based on multi-scale feature fusion and RNN achieves accuracy results of 0.41, 0.40, 0.43, 0.41, and 0.43, and recall results of 0.39, 0.40, 0.42, 0.41, and 0.41. Compared with methods such as semantic segmentation and polygon annotation, this model has the lowest annotation time of only 2.2 seconds. The proposed model effectively solves the modeling problem of sequence relationships in power scenario images and has high application and promotion value.

Keywords: power scenario; image annotation; feature fusion; recurrent neural networks; time series; Dropout regularization; loss function

互联网大数据时代引起图像数据数量暴涨,并且图片的增长速度还在逐年增加^[1]。数据庞大的未标注图像数据充斥在网络空间中,使用户在进行网络检索时出现的结果可能大部分都是无效结果^[2]。因此开发出高效率的图像数据标注方法至关重要。传统图像标注方法一般是将图像特征提取和标注分步骤完成^[3]。传统图像标注方法存在计算部分复杂,表征图像太过单一的缺陷。基于深度学习的图像标注方法一般是通过深度学习技术,将网络模型进行连续迭代优化,进而得到较多的图像特征。许多专

家针对 RNN 网络模型进行了研究。李勇等提出一种基于 RNN 模型的兴趣点推荐方法。利用采集到的学习用户空间信息和时间信息进行实时状态嵌入,结合学习用户历史偏好记录和实时具体应用需求实现对用户的兴趣点偏好预测。实验结果表明,所提方法能够较好地预测学习用户的兴趣点偏好^[4]。Farooq U 等提出一种基于 RNN 的智能机器模型。以 RNN 为基础模型,嵌入注意机制进而改善结果精准度。实验结果表明,所提模型在不同粒度水平下工作性能良好^[5]。然而,基于深度学习的图像标注方法难

收稿日期:2024-07-17;录用日期:2024-08-17

基金项目:广东电网有限责任公司人工智能标注中心运营机制研究项目(GDKJXM20230574)

作者简介:林嘉鑫(1992—),男,硕士,工程师,研究方向:技术平台、人工智能。

引用本文:林嘉鑫,裴求根,钱正浩,等.基于特征融合和 RNN 的电力场景图像数据自动标注方法[J].自动化技术与应用,2026,45(3):152-156.

(LIN Jiaxin, PEI Qiugen, QIAN Zhenghao, et al. Automatic annotation method of power scenario image data based on feature fusion and RNN[J]. Techniques of Automation and Applications, 2026,45(3):152-156.)

以处理存在序列关系的图像数据。因此研究创造性地将多尺度特征融合技术和 RNN 模型结合共同构建了一种应用于电力场景的图像数据自动标注模型, 以期对图像标注相关研究提供一定参考价值。

1 电力场景图像标注模型构建

1.1 基于 Dropout 优化的 RNN 模型

在电力系统实际工作中, 有时必须对电力场景图像数据进行标注, 所以电力系统需要找到性能良好的图像自动标注方法^[6-8]。图像自动标注技术主要是基于特定计算机系统, 以图像中的视觉画面为基础, 通过机器学习技术将目标图片具有的特征转化为关键词形式, 进而对其他空白描述的图像进行标注的过程^[9-10]。图像自动标注一般选择经典卷积神经网络结构作为基础模型。CNN 模型在数据训练过程中一般只对单一固定长度的向量进行训练, 并且输出对应固定长度的表示^[11]。因此在对特定长序列数据进行训练时, 会利用模型具有的卷积层和池化层实现对导入数据的向量转化。由于在实际情况下, 输入数据之间可能存在相互关系, 并且电力场景图像数据就属于存在时间关系的序列数据, 所以 CNN 模型被优化设计得到循环神经网络模型结构如图 1 所示。

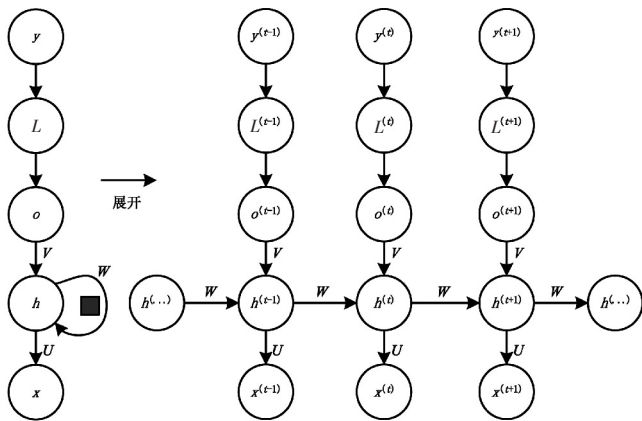


图 1 RNN 模型结构

Fig. 1 Structure of RNN model

由图 1 可知, 图中左侧为 RNN 模型未以时间序列展开的结构, 右侧是以时间序列展开的结构。 $x^{(t)}$ 是导入的第 t 个样本数据, 则 $x^{(t-1)}$ 和 $x^{(t+1)}$ 分别为第 $t-1$ 个训练样本数据、第 $t+1$ 个训练样本数据。 $h^{(t)}$ 代表样本序列中第 t 个循环神经网络单元的隐藏层节点。基于 $x^{(t)}$ 和 $h^{(t-1)}$ 可以运算得到 $h^{(t)}$ 。 $o^{(t)}$ 代表第 t 个循环神经网络单元的输出层节点, 由对应的循环神经网络单元隐藏层节点 $h^{(t)}$ 经过计算得到 $o^{(t)}$ 。 $L^{(t)}$ 为对应模型单元的损失函数。 $y^{(t)}$ 为对应模型单元的实际输出。 U, V, W 为 RNN 模型对应的线性关系参数。RNN 模型在对存在关系的序列数据时具有显著的优势, 可以构建一个特定矩阵参数将对应时间的信息序列数据保存, 使模型具有一定的数据序列记忆功能, 进而能够较好地处理存在特定关系的序列数据。RNN 模型构建后需要进行模型优化, 研究采用 Dropout 正则化

技术优化 RNN 模型。Dropout 正则化技术主要是在每回合的迭代过程中将半数隐藏层节点对应数值设定为 0, 进而防止需要优化的神经网络模型出现过拟合的现象^[12-13]。利用 Dropout 正则化技术优化神经网络模型能够快速降低出现过拟合现象的概率, 并且可以削弱神经元之间的共适应关系^[14-16]。Dropout 正则化技术优化后的 RNN 模型如图 2 所示。

由图 2 可知, 未加入 Dropout 正则化技术时, RNN 模型首先将导入数据进行向前传播阶段, 通过损失函数的反向传播确定权值的更新, 进而完成再学习过程。在加入 Dropout 正则化技术后, 首先会随机将半数隐层节点剔除, 并且不会对输入神经元和输出神经元造成影响。随后, 再次将之前的导入数据输入优化后的 RNN 模型进行训练, 并且针对未剔除的隐藏神经元根据专门的梯度下降法完成权重偏置更新, 数据训练和权重偏置更新一直持续到判定条件满足为止。在迭代完成后进行加权平均, 进而使 RNN 模型避免出现过拟合现象。

1.2 多尺度特征融合图像标注模型

在根据 RNN 模型组建图像标注模型过程中, 在 RNN 模型的卷积层需要进行卷积特征运算, 具体计算如公式 (1) 所示。

$$X^i = f(X^i \otimes W^i + b^i) \tag{1}$$

式中, W^i 代表在第 i 个卷积层中的卷积核; \otimes 代表对应卷积核进行的图像特征计算; b^i 代表对应卷积层的偏置; $f(\cdot)$ 代表卷积运算的激活函数。另外, 卷积运算后得到的图像尺寸计算如公式 (2) 所示。




图 2 RNN 模型优化前后对比

Fig. 2 Comparison of RNN model before and after optimization

$$Q = (W - F + 2P) / S + 1 \tag{2}$$

式中, F 代表卷积核的大小; P 代表输入图像进行的补零参数; S 代表图像每次在卷积层移动的步长。卷积特征计算后得到的基于多尺度特征融合和 RNN 的图像标注模型如图 3 所示。

由图 3 可知, 基于多尺度特征融合和 RNN 的图像标注模型包含 1 层特征融合层、2 层空间金字塔池化层、3 层全连接层和 5 层卷积层。首先针对训练数据集和测试数据集输入对应的电力场景图像数据, 在第 1 层的卷积层中通过卷积核对电力场景图像数据提取特征, 并且将提取到的特征导入最大池化层中完成降采样处理, 对于第 2 层卷积层和连接的最大池化层进行相同操作, 针对第 3 层卷积层和第 4 层卷积层导入经过一系列处理的特征, 然后通过

排第5层卷积层的非对称卷积核再次进行特征提取,在一系列卷积层特征提取过程中,特征尺寸不断缩小,并且通过第3层卷积层和第5层卷积层时对应特征导入到与卷积层连接的空间金字塔池化层中,然后经过2层空间金字塔池化层处理后的特征进行融合,随后导入相互连接的三

层全连接层进行全链接操作。最终完成针对电力场景图像数据的多尺度特征融合。在基于多尺度特征融合和RNN的图像标注模型中,选取 Sigmoid 交叉熵损失函数作为模型的损失函数,具体运算如公式(3)所示。

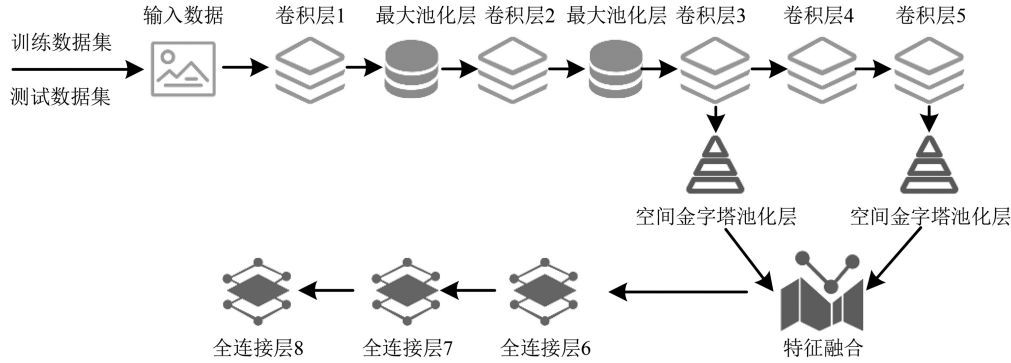


图3 基于多尺度特征融合和RNN的图像标注模型

Fig. 3 Image annotation model based on multi-scale feature fusion and RNN

$$L = -\frac{1}{m} \sum_{n=1}^m [y_n \log p_n + (1 - y_n) \log(1 - p_n)] \quad (3)$$

式中, p_n 代表第 n 个样本的预测结果; y_n 代表对应样本的实际结果; m 代表电力场景图像数据集中的样本总数。当预测输出样本标签为 1 则对应概率如公式(4)所示。

$$p_n = P(y = 1 | x) \quad (4)$$

式中, P 代表电力场景图像数据集中每张图像在标注子集中的映射合集。预测输出样本标签为 0 的概率如公式(5)所示。

$$1 - p_n = P(y = 0 | x) \quad (5)$$

根据极大似然性分析,将公式(4)和公式(5)用整体概率表达式表示,如公式(6)所示。

$$P(y | x) = p_n^y (1 - p_n)^{1-y} \quad (6)$$

式中, p_n^y 代表第 n 个样本对应标签为 1 或者 0 的预测结果。当实际样本标签数量是 $y = 0$ 时,概率计算如公式(7)所示

$$P(y = 0 | x) = 1 - p_n \quad (7)$$

如果实际样本标签数量是 $y = 1$ 时,概率计算如公式(8)所示。

$$P(y = 1 | x) = p_n \quad (8)$$

因为 $P(y | x)$ 的值越大越好,所以为优化概率 $P(y | x)$,基于整体概率表达式结合 \log 函数,如公式(9)所示。

$$\log P(y | x) = \log(p_n^y (1 - p_n)^{1-y}) = y \log p_n + (1 - y) \log(1 - p_n) \quad (9)$$

式中, $\log P(y | x)$ 代表图像在标注子集中映射合集的 \log 运算表征。对于损失函数来说, $\log P(y | x)$ 的值越大越好。因此损失函数表达式如公式(10)所示。

$$L = -\frac{1}{q} \sum_{n=1}^q [y_n \log p_n + (1 - y_n) \log(1 - p_n)] \quad (10)$$

式中, q 代表样本数量。基于多尺度特征融合和 RNN 的图像标注模型中还包含两个激活函数用以非线性激活卷积层得到的线性特征,分别为 Sigmoid 激活函数和 ReLu

激活函数。Sigmoid 激活函数如公式(11)所示。

$$S(t) = \frac{1}{1 + e^{-t}} \quad (11)$$

式中, t 代表预激活输出; e 代表自然对数底数。ReLU 激活函数如公式(12)所示。

$$F(x) = \max(0, x) \quad (12)$$

式中, x 代表输入值。在构建好基于多尺度特征融合和 RNN 的图像标注模型后需要确定标注结果的评价指标。研究采用准确率、召回率和 F_1 作为模型标注性能的评价指标。由于召回率和准确率存在矛盾的可能,因此研究将召回率和准确率作为参考评价指标,确定 F_1 作为最终评价图像标注模型的性能指标。

2 实验对比结果分析

为确定基于多尺度特征融合和 RNN 的图像标注模型的有效性,设计相关仿真实验进行验证。仿真实验基本参数具体指标如表 1 所示。

表 1 仿真实验基本参数

Tab. 1 Basic parameters of simulation experiment

参数	参数设置
操作系统	Windows 10
算法语言	Python3.7
学习框架	TensorFlow2.0.0GPU 版本
硬件环境	GeForce2080TI
训练 batch	64
学习率	0.001
优化算法	Adam 优化
迭代次数	300
训练集	LAPR TC-12 数据集

由表 1 可知,仿真实验所用操作系统为 Windows 10,

采用 Python3.7 算法语言,设定训练 batch 为 64,学习率为 0.001,共进行 300 次迭代。选择 LAPR TC-12 数据集作为训练数据集。为确定基于多尺度特征融合和 RNN 的图像标注模型中特征融合层对于模型性能的优化,基于电力场

景图像数据设置 3 种方案进行对比,分别为卷积层 4 和卷积层 5 特征融合,卷积层 3 和卷积层 5 特征融合,只采用卷积层 5 的特征。研究所提出的图像标注模型为卷积层 3、4、5 特征融合。仿真实验对比结果如图 4 所示。




图 4 不同卷积层融合特征对比结果

Fig. 4 Comparison results of fused features from different convolutional layers

由图 4 可知,研究所提出的图像标注模型对应的卷积层 5、4、3 特征融合方法得到的电力场景图像数据标注结果在评价指标上具有显著的表现。在电力场景图像数据标注正确率方面,卷积层 5、4、3 特征融合的 5 组结果分别为 0.464、0.455、0.465、0.459、0.463。在电力场景图像数据标注精度方面,卷积层 5、4、3 特征融合的 5 组结果分别为 0.375、0.377、0.379、0.383、0.381。在电力场景图像标注时间对比方面,卷积层 5、4、3 特征融合的 5 组结果分别为 3 s、2.8 s、2 s、2.7 s、2.2 s。而参与比较的卷积层融合方案的电力场景图像数据标注时间均在 3 s 以上。对比结果分析可知,在电力场景图像标注方面,卷积层 5、4、3 特征融合方案相对于其他融合卷积层方案图像标注效率最高,标注速度方面最快。进行卷积层特征融合比未进行卷积层特征融合在对于电力场景下图像数据标注的性能更加优秀,并且卷积层特征融合较低层卷积层优秀。因此,基于多尺度特征融合和 RNN 的图像标注模型对应特征融合分层在性能方面具有一定优势。为确定基于多尺

度特征融合和 RNN 的图像标注模型相对于其他图像数据标注方法是否具有优秀的标注性能,将 3 种经典图像标注模型作为性能比较对象,分别为语义分割、多边形标注、目标追踪。具体仿真对比实验结果如图 5 所示。

由图 5 可知,基于多尺度特征融合和 RNN 的图像标注模型在电力场景图像数据标注方面具有优秀的表现。基于多尺度特征融合和 RNN 的图像标注模型在准确率方面的 5 组数据结果分别为 0.41、0.40、0.43、0.41、0.43。在召回率方面结果分别为 0.39、0.40、0.42、0.41、0.41。在 F_1 值方面结果分别为 0.42、0.39、0.37、0.40、0.43。仿真对比结果可知,当基于多尺度特征融合和 RNN 的图像标注模型应用于电力场景图像数据标注时,能够表现出优越的性能。根据最终性能评价指标 F_1 值可知,基于多尺度特征融合和 RNN 的图像标注模型相对于其他常用图像标注方法,具有显著的性能优势,在实际场景中具有一定的应用价值。




图 5 图像标注模型对比结果

Fig. 5 Comparison results of image annotation models

3 结论

为提升电力场景图像数据标注效率,研究提出一种基于多尺度特征融合和 RNN 的图像标注模型。首先将经典 CNN 模型作为基础神经网络模型,然后针对 CNN 模型无法处理存在时间序列关系的序列数据相关问题优化得到 RNN 模型,并且引入 Dropout 正则化技术改善 RNN 模型存在的拟合偏差现象。随后结合多尺度特征融合技术构建应用于电力场景的图像数据自动标注模型。根据实验结果可知,基于多尺度特征融合和 RNN 的图像标注模型在 F_1 值方面结果分别为 0.42、0.39、0.37、0.40、0.43。实验结果表明,基于多尺度特征融合和 RNN 的图像标注模型在电力场景下图像标注方面具有显著的性能优势,并且在实际应用场景中可以起到较好的标注效果。不过由于多尺度特征融合技术还存在很大的发展空间,因此下一步将对多尺度特征融合技术进行深入研究。

参考文献

- [1] 曹敏, 曹东朗. 基于视觉描述符的图像大数据分类算法仿真[J]. 计算机仿真, 2024, 41(4):170-174, 300.
- [2] 欧阳雪, 徐彦彦, 毛养素, 等. 云计算与区块链平台的遥感影像安全检索方案[J]. 电子与信息学报, 2023, 45(3):856-864.
- [3] 冯孝鑫, 王子健, 吴奇. 基于三元采样图卷积网络的半监督遥感图像检索[J]. 电子与信息学报, 2023, 45(2):644-653.
- [4] 李勇, 韩志媛, 安敬民. 基于循环神经网络的实时偏好感知兴趣点推荐[J]. 计算机工程与设计, 2023(12):3772-3777.
- [5] FAROOQ U, MOHD RAHIM M S, ABID A. A multi-stack RNN-based neural machine translation model for English to Pakistan sign language translation[J]. Neural Computing and Applications, 2023, 35(18):13225-13238.
- [6] 刘威, 郭直清, 王东, 等. 改进鲸鱼算法及其在浅层神经网络搜索中的权值阈值优化[J]. 控制与决策, 2023, 38(4):1144-1152.
- [7] 高伟, 郭美青, 张兴忠, 等. 基于改进 PP-YOLOv2 的红外图像电力设备检测[J]. 计算机仿真, 2023, 40(9):81-87, 241.
- [8] 黄湛华, 阳浩, 徐启源, 等. 电力设备场景智能锁具状态远程授权控制技术[J]. 自动化技术与应用, 2025, 44(1):154-157, 172.
- [9] RÄDSCH T, REINKE A, WERU V, et al. Labelling instructions matter in biomedical image analysis[J]. Nature Machine Intelligence, 2023, 5(3):273-283.
- [10] 萧威, 殷志祥, 叶子, 等. 结合自适应模糊推理和神经网络的物联网混合发电系统[J]. 现代电子技术, 2022, 45(5):97-102.
- [11] 谭会生, 徐界铭, 张驾祥. BP 神经网络 FPGA 实现结构的优化设计[J]. 计算机工程与应用, 2022, 58(21):264-271.
- [12] 赵旭剑, 李杭霖. 基于混合机制的深度神经网络压缩算法[J]. 计算机应用, 2023, 43(9):2686-2691.
- [13] 孟祥福, 温晶, 李子函, 等. 卷积神经网络的 top-k 相似节点搜索方法[J]. 小型微型计算机系统, 2023, 44(11):2516-2521.
- [14] 徐红, 矫桂娥, 张文俊. 基于非平衡问题的高斯混合模型卷积神经网络[J]. 应用科学学报, 2023, 41(4):657-668.
- [15] 覃浩, 刘振华, 苏立伟. 基于多模态融合的电力智能客服系统情绪识别方法[J]. 自动化技术与应用, 2024, 43(4):169-172.
- [16] 王菁, 文晓东, 王春枝. 基于动态扩散卷积交互图神经网络的网络流量预测[J]. 计算机应用研究, 2023, 40(1):97-101.
- [17] 刘金, 黄国健, 王新华, 等. 门座起重机参数化建模与仿真分析[J]. 自动化技术与应用, 2017, 36(1):83-87.
- [18] WU Y, SUN N, CHEN H, et al. Adaptive output feedback control for 5-DOF varying-cable-length tower cranes with cargo mass estimation[J]. IEEE Transactions on Industrial Informatics, 2021, 17(4):2453-2464.
- [19] 黄青青, 张金波. 起重机大功率锂电池组管理系统研究[J]. 自动化技术与应用, 2025, 44(2):4-8, 99.
- [20] SUN Z, OUYANG H. Adaptive fuzzy tracking control for vibration suppression of tower crane with distributed payload mass[J]. Automation in Construction, 2022(142):104521.
- [21] SUN N, WU Y, CHEN H, et al. Antiswing cargo transportation of underactuated tower crane systems by a nonlinear controller embedded with an integral term[J]. IEEE Transactions on Automation Science and Engineering, 2019, 16(3):1387-1398.
- [22] FASIH UR REHMAN S M, MOHAMED Z, HUSAIN A R, et al. Input shaping with an adaptive scheme for swing control of an underactuated tower crane under payload hoisting and mass variations[J]. Mechanical Systems and Signal Processing, 2022(175):109106.
- [23] 李元琪, 王丁军, 叶嵩, 等. 基于模糊滑模控制的物料吊运定位防摆控制[J]. 计算机仿真, 2023, 40(4):245-250.
- [24] 陈猛. 有界扰动条件下 PMSM 的扰动观测-积分滑模控制[J]. 自动化技术与应用, 2025, 44(3):29-33, 109.
- [25] 朱志宇, 高国琴. 具液阻干扰混联机构固定时间非奇异分段滑模控制[J]. 自动化技术与应用, 2025, 44(11):11-16, 96.
- [26] 张晨, 陈辉, 梁昕. 基于滑模控制的地铁塞拉门电机控制系统设计[J]. 自动化技术与应用, 2025, 44(4):11-14, 163.
- [27] ABOSSERRE L T, EL-BADAWY A A. Robust integral sliding mode control of tower cranes[J]. Journal of Vibration and Control, 2021, 27(9/10):1171-1183.
- [28] 丁承君, 李庆, 高少彬, 等. 基于改进差分进化算法优化的塔机防摆控制研究[J]. 机电工程, 2021, 38(3):350-355.
- [29] ZHANG M, JING X. Model-free saturated PD-SMC method for 4-DOF tower crane systems[J]. IEEE Transactions on Industrial Electronics, 2022, 69(10):10270-10280.
- [30] SUN N, FANG Y, CHEN H, et al. Slew/Translation positioning and swing suppression for 4-DOF tower cranes with parametric uncertainties: design and hardware experimentation[J]. IEEE Transactions on Industrial Electronics, 2016, 63(10):6407-6418.
- [31] CHEN H, FANG Y, SUN N. An adaptive tracking control method with swing suppression for 4-DOF tower crane systems[J]. Mechanical Systems and Signal Processing, 2019(123):426-442.
- [32] ZHANG M, ZHANG Y, OUYANG H, et al. Adaptive integral sliding mode control with payload sway reduction for 4-DOF tower crane systems[J]. Nonlinear Dynamics, 2020, 99(4):2727-2741.
- [33] 王祥, 陈志梅, 邵雪卷, 等. 基于滑模自抗扰控制的变绳长塔机防摆控制[J]. 机电工程, 2023, 40(3):444-451.
- [34] TIAN Z, YU L, OUYANG H, et al. Swing suppression control in tower cranes with time-varying rope length using real-time modified trajectory planning[J]. Automation in Construction, 2021(132):103954.
- [35] ZHANG M, ZHANG Y, JI B, et al. Adaptive sway reduction for tower crane systems with varying cable lengths[J]. Automation in Construction, 2020(119):103342.
- [36] TIAN Z, YU L, OUYANG H, et al. Sway and disturbance rejection control for varying rope tower cranes suffering from friction and unknown payload mass[J]. Nonlinear Dynamics, 2021, 105(4):3149-3165.

(上接第 67 页)