

doi: 10.7690/bgzd.2025.08.010

一种 CNN-CG 图像特征识别模型

文 竹¹, 于昊生²

(1. 广西警察学院信息技术学院, 南宁 530028; 2. 东华大学旭日工商管理学院, 上海 200051)

摘要: 针对低分辨率下深度学习网络模型对图像特征识别能力有限、影响识别精度和速度等问题, 提出一种卷积神经网络和共轭梯度法(convolutional neural networks-conjugate gradient, CNN-CG)模型。通过改进共轭梯度图特征识别算法, 搭建卷积神经网络模型对图像进行特征识别和预测。将输入的图像由 3 维依次经过卷积层和激活函数投射到 32, 64, 128 和 256 维, 编码器输出高维分类特征, 经全连接层后得到图像类别信息。与其他模型在相同数据集上仿真实验比对, 所提模型在识别精度、收敛情况、图像数据分析等方面表现优异, 识别训练集准确率为 100%, 测试集准确率为 80.26%, 识别结果优于一般模型。结果表明: 该模型在交通标志图像识别应用上有良好的效果, 并表现出较强的鲁棒性和消融性, 适合用作自动驾驶应用场景下交通标志图像识别模型的优化算法, 且可以拓展到其他领域图像的特征识别。

关键词: 自动驾驶; 卷积神经网络; 共轭梯度; 特征识别; 深度学习

中图分类号: TP391.41 **文献标志码:** A

A CNN-CG Image Feature Recognition Model

Wen Zhu¹, Yu Haosheng²

(1. School of Information Technology, Guangxi Police College, Nanning 530028, China;

2. School of XuriBusiness Administration, Donghua University, Shanghai 200051, China)

Abstract: In order to solve the problem that the deep learning network model has limited ability to recognize image features in low resolution, which affects the recognition accuracy and speed, a convolutional neural network-conjugate gradient (CNN-CG) model is proposed. By improving the conjugate gradient map feature recognition algorithm, the convolutional neural network model is built to recognize and predict the image features. The input image is projected from three dimensions to 32, 64, 128 and 256 dimensions through convolution layer and activation function in turn. The encoder outputs high-dimensional classification features, and the image category information is obtained after full connection layer. Compared with other models on the same data set, the proposed model performs well in terms of recognition accuracy, convergence and image data analysis. The recognition accuracy of the training set is 100%, and the accuracy of the test set is 80.26%, which is better than that of the general model. The results show that the model has a good effect on the traffic sign image recognition application, and shows strong robustness and ablation, which is suitable for the optimization algorithm of the traffic sign image recognition model in the automatic driving application scene, and can be extended to the feature recognition of images in other fields.

Keywords: autonomous driving; convolutional neural network; conjugate gradient; feature recognition; deep learning

0 引言

近年来,随着智能汽车的市场占有率日益增长,自动驾驶应用场景中能否正确、快速识别出交通标志对自动驾驶算法影响重大,但在低分辨率情况下,图像的识别成功率不高^[1]。近年来,已有许多基于卷积神经网络(convolutional neural networks, CNN)模型在自动驾驶图像识别领域的研究^[2]。研究结果表明:支持向量机(support vector machine, SVM)^[3]图像增强算法能优于传统数据增强方法,可以更有效地解决图像数据分析中数据不均衡问题,提升深度卷积神经网络的图像分类性能^[4];Res2Net 结合卷

积块注意力模型(convolutional block attention module, CBAM)^[5]和 YOLOv4-Tiny 对象检测^[6]具有较强的泛化性,能显著提升图检测的效率;简化图卷积(simplified graph convolution, SGC)改进了图神经网络的编码方式,使用线性网络编码原始图信息,能够降低复杂度并减少模型参数^[7];线性变分图分解器(linear-variational graph autoencoders, Linear-VGAE)用简单的线性模型取代了图卷积网络(graph convolutional networks, GCN)编码器,涉及更少的操作和参数,在链路预测中,Linear-VGAE 比基于 GCN 的算法更具有竞争性^[8]。

上述研究能在一定程度上提取图特征并进行分

收稿日期: 2024-09-12; 修回日期: 2024-10-22

基金项目: 广西哲学社会科学课题(24KSB008)

第一作者: 文 竹(1982—), 女, 贵州人, 硕士。

通信作者: 于昊生(1995—), 男, 广西人, 博士。

类, 但仍然存在不足: 如模型在低分辨率下对图像的特征识别能力有限, 导致网络识别精度不高; 深度学习网络模型层数影响识别精度和速度^[9]; 未专门针对混合概率分布的原始图识别和预测^[10]等。此外, 现有的方法极大地限制了属性和拓扑的不足。

与上述通过复杂神经网络编码方式传递权值信息和线性方式提升模型性能的研究不同, 提出一种 (CNN-CG) 模型, 通过改进共轭梯度 (conjugate gradient, CG) 算法, 搭建卷积神经网络改善图像特征识别的全局收敛性、线性收敛性及数值效果。根据模型目标函数的特殊性, 计算 n 个下降方向的线性组合, 每次迭代使得约束目标中的梯度线性组合减小 1 维, 把一个极小化问题转化成 2 个, 以实现在固定 n 个下降方向上的全局最优解。基准数据集上进行的实验表明: 所提模型在保持高泛化性和可伸缩性的同时, 实现了最优性能。

1 模型与算法

1.1 模型结构

笔者搭建模型使用的优化算法为共轭梯度法。由于本模型需要计算输入和输出都为向量的函数偏导数, 因此需要计算导数如何随着输入的变化而改变。它表示只基于梯度信息的梯度下降步骤是否会产生预期的改善。本质上, 共轭梯度优化算法是基于反向传播 (back propagation, BP) 来实现的, 当前向传播得出的预测结果与真实值不相符时, 将预测结果与真实值之间的差值即误差 loss 从后向前进行传播, 从而更新权值, 达到训练目的的阶段, 即反向传播阶段。

笔者设定误差小于或等于 10^{-5} 或迭代 20 次时停止训练。卷积神经网络设计为 5 层, 其中包含 4 层卷积层和 1 层全连接层, 卷积层中包含了激活函数和池化层。激活函数使用 Relu 激活函数, 池化层使用最大池化方法, 卷积核采用 3×3 大小。数据标准化方法通道均值设置为 0.5, 通道标准差设置为 0.5^[11]。卷积层与全连接层的 I/O 参数设置如表 1 所示。

表 1 网络具体参数表

图层	输入大小	输出大小	卷积核大小
conv2d_1	3	32	3×3
conv2d_2	32	64	3×3
conv2d_3	64	128	3×3
conv2d_4	128	256	3×3
ful_conn	$256\times 14\times 14$	1,024	

训练过程如图 1 所示。




图 1 模型训练过程

1.2 关键算法

CG 是一种通过迭代下降的共轭方向以有效避免 Hessian 矩阵求逆计算的方法。为了解决该问题衍生出来的单调非线性方程组模型, 因其局部超线性收敛特性, 很多算法包括投影牛顿法、拟牛顿法、牛顿法和一系列牛顿法的变形被提出来。由于在迭代过程中矩阵需要存储, 这些算法并不适合于求解大规模问题。由于共轭梯度法的简洁性和低存储性, 被广泛地应用于求解大规模的无约束优化问题。

假设前一个搜索方向为 d_{t-1} , 在极小值处先搜索终止, 方向 d_{t-1} 处的方向导数为零。因为该点的梯度定义了当前的搜索方向, $d_t = \nabla \theta J(\theta)$ 将不会贡献于方向 d_{t-1} , 因此方向 d_t 正交于 d_{t-1} 。最速下降多次迭代中方向 d_{t-1} 和 d_t 下降正交方向的选择不会保持前一搜索方向上的最小值。其线搜索迭代地用于与梯度相关的方向上, 增加了对下降方向限制的条件: 方向共轭。建模过程中直接把 x 表示成 n 个下降方向的线性组合, 根据目标函数的特殊性, 把线性组合的 2 部分较好的分开^[12]。要让目标每一步的最优解升级成整体最优解, 只需令这个优化目标中关于步长和迭代方向 x 的交叉项消失, 即增加对下降方向的约束来实现共轭, 这是算法核心。然后把问题等价迭代, 每次迭代使得约束目标中的梯度线性组合减小 1 维, 同时增加一个方向步长的优化目标^[13], 即把一个极小化问题严格转化成 2 个极小化问题, 从而实现在固定 n 个下降方向上的全局最优解。如图 2 所示, 在每个步骤中沿着由初始点处梯度定义的线跳到最低代价的点, 解决了使用固定学习率遇到的问题, 即使使用最佳步长, 算法仍然朝最优方向前进, 在沿着给定方向的目标最小值处, 最终点处的梯度与该方向正交^[14]。




图 2 共轭梯度算法二次搜索

假设目标函数 $f(x)$ 是连续可微的, 无约束优化问题可表示为:

$$\min(f(x)) = x^T A x / 2 + b^T x + c. \quad (1)$$

因为 $\nabla f(x) = Ax + b$, 有 $\nabla f(x_k) = Ax_k + b$, 可得:

$$\nabla f(x_n) = \nabla f(x_{k+1}) + \lambda_{k+1} A p_{k+1} + \dots + \lambda_{n-1} A p_{n-1}. \quad (2)$$

对于 $k=0, 1, 2, \dots, n-1$, x_n 是最后一次 1 维搜索后的解, 将 $\nabla f(x_n)$ 可以形式上表示为 x_n 之前的解 x_k .

根据 1 维搜索的性质 $\nabla f(x_{k+1})^T p_k = 0$ 以及共轭向量的定义等于零, 所以 $p_k^T \nabla f(x_n) = 0$ 对所有的 k 均成立, $\nabla f(x_n)$ 与 n 个线性无关的共轭向量组都正交, 即 $\nabla f(x_n) = 0$. 因此 $x_n = x^*$, x_n 为极小点 x^* .

确定 x_n 为极小值点后, 为了寻找共轭方向, 运用施密特正交化方法, 得出共轭向量组本身的公式为:

$$p_{k+1} = -\nabla f(x_{k+1}) + \beta_k p_k; \quad (3)$$

$$\beta_k = \nabla f(x_{k+1})^T \nabla f(x_{k+1}) / \nabla f(x_k)^T \nabla f(x_k). \quad (4)$$

式中 p_{k+1} 为下一步权值更新的方向。

式(3)—(4)为本文中研究改进共轭梯度算法的通用公式, 即具体权值参数的关键公式。基于共轭梯度算法的研究主要围绕 p_{k+1} 展开, 可以有效避免局部收敛情况。

2 实验结果

2.1 实验方案

本文中数据集参考“German Traffic Sign Benchmarks”上开源的交通标志图像——GTSRB 数据集, 包含 43 类交通标志, 这些图像具有不同的光照条件和丰富的背景。所有图像均分为训练集与测试集, 比例为 7:3。数据集不含有交通标志边界信息, 首先, 使用标注软件对数据集进行边界标注, 便于对卷积神经网络模型进行训练; 然后, 使用有标注的数据对预训练的模型进行训练, 得到初步的检测模型; 最后, 使用模型对其余数据进行检测, 将结果反馈到标注软件中比对准准确率。

实验使用型号为 NVIDIA GeForce RTX 2060 的 GPU, 单次迭代训练图像量 10 000 张, 单次迭代约

需 12 min。将输入的交通标志图像按每批次 256 张图像拉伸为 256×256 大小的像素块, 再由 3 维依次经过 4 层卷积层投射到 32、64、128 和 256 维, 由编码器输出高维分类特征, 经全连接层后输出交通标志的识别结果。单次卷积神经网络训练完成后记录并评估卷积神经网络的拟合效果。

图像识别模型训练流程包括:

- 1) 输入图片数据集(单次 10 000 张);
- 2) 初始化卷积神经网络结构参数矩阵;
- 3) 使用优化算法调整模型参数, 提取训练集, 前向传播计算网络输出;
- 4) 与真实数据对比计算网络误差;
- 5) 判断误差是否在允许范围内并判断训练迭代次数, 结果为否, 跳至 6); 结果为是, 跳至 9);
- 6) 后向反馈误差到每一层网络参数中;
- 7) 使用共轭梯度算法计算出参数调整方向;
- 8) 调整网络参数, 跳至 3);
- 9) 保存模型参数, 预测交通标志图片类别。

2.2 模型训练结果

使用上述改进共轭梯度算法搭建的神经网络模型对 GTSRB 图像集经过 20 次迭代训练后, 得到训练可视化结果如图 3 所示。网络训练集损失从第 1 次迭代的 0.019 07 单调递减至第 20 次的 0.000 05, 训练集准确率从第 1 次迭代的 0.416 79 单调递增, 在第 17 次迭代时达到 1。测试集误差处于波动状态, 基本稳定在 0.014, 测试集精确度处于先递增后波动状态, 稳定在 0.8 左右。由图 3 可见: 网络在第十次迭代时已基本处于收敛状态。算法时间复杂度为 $O(n\sqrt{k})$, 空间复杂度为 $O(n)$, 其中 n 是数据量, k 是数据维度。




图 3 模型训练结果

2.3 鲁棒性分析

大多数图像识别方法都需要高质量的训练数据, 然而当训练集包含复杂的噪声、缺失的数据等

问题时，模型的有效性往往不能得到保证，这被称为鲁棒性问题。为了保证模型的表现能力，笔者选择了 GTSRB 数据集在鲁棒性实验中进行测试。

笔者通过模糊像素、移除属性、攻击边缘等实验来评估基线和稳健性。在随机攻击边缘的实验中，每次从训练集中减少 10% 的边缘。在随机攻击属性的实验中，每次从训练集中减少 10% 的属性。测试结果如图 4 所示，共轭梯度模型的性能始终表现优异。在攻击边缘的情况下，高阶邻居可以作为一阶邻居的补充，增强边缘图节点之间的拓扑关系。在攻击属性的情况下，引入二次搜索允许图节点聚合更多的潜在特征，从而减轻了缺失属性的影响。实验结果表明，在属性和边缘图节点拓扑结构不足的情况下，引入二次搜索可以保留更全面的原始图信息，增强模型的表示能力。




图 4 共轭梯度算法模型 ROC 曲线

2.4 消融实验

在机器学习和深度学习领域，消融实验被广泛应用于评估模型的鲁棒性、稳定性等性能。本研究提出的 CNN 模型包含多个卷积层、池化层和全连接层，这些层共同作用以提取图像的高层次特征。然而，并非所有的层对最终的分类结果都同等重要。因此，本研究进行了消融实验来评估特定特征对模

型性能的影响。在目标检测任务中，逐步去除隐藏层以检测其对准确性的影响。

为了评估卷积层层数对模型准确率的影响，笔者分别设计了 6、5、4、3 层卷积层的不同模型，以准确率、召回率、综合指标 F1 值作为评估指标进行消融实验。分别对模型进行了 50 次迭代训练，实验结果如表 2 所示。

表 2 不同模型对比的消融实验

卷积层数	准确率/%	召回率/%	F1 值
6	79.85	83.40	0.817 4
5	80.18	82.15	0.811 3
4	80.25	84.50	0.827 8
3	75.87	83.75	0.796 4

由表 2 可以看出：模型在本文中提出的卷积层数为 4 层时，表现最佳，图像特征提取上达到最优。

3 对比实验

3.1 算法对比实验

为检验壁纸所提算法的拟合效果，现使用梯度下降算法 (gradient descent, GD) 对该模型使用相同数据集进行训练，并对结果进行了对比。将目标函数的负梯度方向 $-\nabla\varphi(x^{(1)})$ ，即 $x^{(0)}$ 到 $x^{(1)}$ 的方向向量作为搜索方向^[15]，得到梯度下降算法权值变换公式如表 3 所示。算法在 GTSRB 数据集上的识别可视化结果如图 5 所示。经过 20 次迭代后，训练集误差为 0.004 14，训练集准确率为 0.568 44，测试集误差为 0.005 06，测试集准确率为 0.445 11，识别时间为 0.087 5 s，时间复杂度 $O(nk)$ ，空间复杂度为 $O(n)$ ，其中 n 是数据量， k 是数据维度。此时网络明显处于尚未收敛状态，若增加迭代次数，理论上能取得更好的拟合效果。

表 3 梯度下降算法与共轭梯度算法权值更新对比表

算法	权值更新方向	权值变化	权值更新公式
梯度下降	每次均沿目标函数的负梯度方向	$-ug(k)$	$\nabla w^{(k)} = w^{(k+1)} - w^{(k)} = -ug(k)$
共轭梯度	首次搜索方向为负梯度方向 搜索方向相互共轭	$-\lambda p(k)$	$P_{k+1} = -\nabla f(x_{k+1}) + \beta_k \nabla f(x_k)$ $\beta_k = \frac{\nabla f^T(x_{k+1}) \nabla f(x_{k+1})}{\nabla f^T(x_k) \nabla f(x_k)}$




图 5 梯度下降算法实验结果

共轭梯度算法与梯度下降算法的识别结果对比如表 4 所示。2 种算法针对测试集和训练集的训练结果如图 6 所示。

表 4 算法识别结果对比

算法	训练误差	训练 精确度/%	测试误差	测试 精确度/%
共轭 梯度	0.000 05	100.000	0.001 45	80.257
梯度 下降	0.004 14	56.844	0.005 06	44.511




图 6 共轭梯度算法与梯度下降算法训练结果比对

由此可见，梯度下降算法与共轭梯度算法在相同卷积神经网络结构、相同数据集上的训练速度与收敛程度并不一致，准确率也相差较大，尽管共轭梯度算法比梯度下降算法复杂度高，但共轭梯度算

法在收敛程度、识别准确率上均优于梯度下降算法。

3.2 模型对比实验

为了验证模型的有效性和前沿性，将本模型与目前图像识别常用的基于改进 Vision Transformer 的交通标志图像识别模型进行对比，在本研究的 GTSRB 数据集上同时进行 50 次迭代，测试集的准确率，召回率，F1 值对比如表 5 所示。由结果可以看出，本模型的召回率要优于基于改进的 Vision Transformer 的交通标志图像识别模型。召回率衡量的是在所有真正为正样本的实例中，被模型正确预测为正样本的比例。在无人驾驶交通标志识别中，高召回率意味着模型能够正确识别出大多数交通标志的特征。这有助于减少误判，避免出现驾驶危险。所以，采用综合指标 F1 来衡量，本模型实验结果优于该模型，具有一定的有效性和前沿性。

表 5 CNN-CG 模型与 Vision Transformer 模型评估指标对比

迭代次数	CNN-CG			Vision Transformer		
	准确率/%	召回率/%	F1 值	准确率/%	召回率/%	F1 值
5	73.78	75.99	0.748 7	78.17	74.72	0.764 1
10	79.33	80.33	0.798 3	82.75	78.15	0.803 8
15	81.87	82.18	0.820 2	83.56	79.12	0.813 1
20	80.26	83.56	0.818 9	84.33	79.69	0.819 8
25	81.25	83.98	0.826 0	83.99	80.15	0.820 6
30	80.91	84.33	0.826 1	84.02	81.01	0.825 0
35	81.13	84.11	0.826 1	82.93	79.25	0.810 7
40	80.12	83.27	0.816 8	83.65	79.35	0.814 8
45	81.10	84.60	0.828 4	83.97	79.92	0.819 3
50	80.93	84.51	0.829 4	83.82	79.19	0.814 6

4 结论

笔者重点研究自动驾驶模式下交通标志图像特征快速准确识别问题，即算法中目标函数 n 维的最优化问题。所提 CNN-CG 模型能够解决模型在低分辨率下对图像特征识别能力有限、网络识别精度不高的问题，可以充分提取图像的特征，并表现出很强的鲁棒性，消融实验表面本模型搭建的 4 层卷积层为最佳。与其他算法、模型的对比结果表明：该模型适合用作图像识别的优化。目前，模型仍有进步空间，未来可能改进的方向为卷积神经网络的结构，例如改进卷积层的数量，提高感受野的大小等方式来增加模型的准确率。

参考文献：

[1] DIVIÁK T. Structural resilience and recovery of a criminal network after disruption: a simulation study[J]. Journal of Experimental Criminology, 2023: 1-29.
[2] 盖荣丽, 莱建荣, 王诗宇, 等. 卷积神经网络在图像识别中的应用研究综述[J]. 小型微型计算机系统, 2021, 42(9): 1980-1984.

[3] GONG N, ZHANG C, ZHOU H. Classification of hyperspectral images via improved cycle-MLP[J]. IET Computer Vision, 2022, 16(5): 468-478.
[4] 李铁柱, 张波, 沈夏炯, 等. 基于改进 CNN 和 GRN 的遥感图像描述方法[J]. 河南大学学报(自然科学版), 2024, 54(3): 294-302.
[5] HY T S, KONDOR R. Multiresolution equivariant graph variational autoencoder[J]. Machine Learning: Science and Technology, 2023, 4(1): 1-24.
[6] 李国权, 姚凯, 庞宇. 基于 CNN 的血液细胞图像自动识别算法[J]. 计算机科学, 2022, 49(4): 247-253.
[7] 王燕, 王振宇. 改进 Res2Net 和注意力机制的高光谱图像分类[J]. 计算机工程与应用, 2023, 19(19): 151-158.
[8] 文竹, 袁立宁, 黄伟, 等. 基于图多层感知机的节点分类算法[J]. 广西科学, 2023, 30(5): 942-950.
[9] 王扬, 陈智斌, 吴兆蕊, 等. 强化学习求解组合最优化问题的研究综述[J]. 计算机科学与探索, 2022, 16(2): 261-279.
[10] 张珂, 冯晓晗, 郭玉荣, 等. 图像分类的深度卷积神经网络模型综述[J]. 中国图象图形学报, 2021, 26(10): 2305-2325.

- [11] 于昊生, 王素芬, 李富有, 等. 基于卷积神经网络的模糊车牌图像检测与识别优化[J]. 广西大学学报(自然科学版), 2023, 48(4): 985-996.
- [12] 王玫, 邓伟洪, 苏森. 面向图像识别的公平性研究进展[J]. 中国图象图形学报, 2024, 29(7): 1814-1833.
- [13] 张弛, 郭媛, 黎明. 人工神经网络模型发展及应用综述[J]. 计算机工程与应用, 2021, 57(11): 57-69.

(上接第 11 页)

当生产任务开始后, 各单元各工位根据工艺模式及当前物料剩余个数判断是否需要 AGV 送料, 若需要, 管控系统首先将 AGV 送料任务保存在 AGV 任务调度列表中, 该任务调度列表系统每隔 5 s 定时轮询一次, 判断任务是否下发成功, 若成功则将其从任务列表中移除, 反之则标记“任务失败”, 通知上层系统, 下次轮询时再进行下发。

2.5.4 人工配送

对于人工物料配送模式, 车间各个单元均有使用。物料来源可能是立体库也可能是线边库和去湿间。人工配送物料除了在 3 单元某工位需要人工叫料外, 其余各工位均自动叫料。管控系统收到叫料命令后, 经上层 MES 向立体库或者线边库发送出料请求, 待物料出库以后, 在对应工位操作界面弹出物料是否到位按钮, 当操作人员点击该按钮时, 即表示物料到位, 可以进入下一步操作。

3 结束语

从提升该装配车间数字化、信息化、智能化水平的角度触发, 结合立体库、自动化生产线、AGV、机械臂、桁架等底层控制系统优点与特点, 设计并

(上接第 28 页)

- [10] 蔡永强. 计算机远程网络通信问题分析与技术革新[J]. 中国质量万里行, 2022(9): 64-67.
- [11] 周红艳, 姚利侠, 付萍华. 网络通信中的数据信息安全保障技术研究[J]. 网络安全技术与应用, 2022(8): 54-56.
- [12] 朱琳琳. 大数据时代计算机远程网络通信技术及應用[J]. 产业创新研究, 2022(14): 90-92.

- [14] WANG Y F, HUANG H Y, RUDIN C, et al. Understanding how dimension reduction tools work: an empirical approach to deciphering t-sne, umap, trimap, and pacmap for data visualization[J]. The Journal of Machine Learning Research, 2021, 22(1): 9129-9201.
- [15] WANG Y, XU B, KWAK M. A noise injection strategy for graph autoencoder training[J]. Neural Computing and Applications, 2021, 33: 4807-4814.

实现了装配车间一体化智能管控系统。该系统的成功应用, 促进了车间数字化管理水平的进一步发展, 同时基于产品的装配特点, 完成了其整个装配周期的质量数据准确追踪, 为上层管理系统提供了可靠、简洁、安全的数据源, 促进了该类型产品装配过程的信息化水平。

该装配车间每个产品数据字段众多, 每班生产产品数量大, 考虑到 PLC 记录数据量小的问题, 本系统将产品过程数据存储在上位机中, 结合调度模块有效地保证了数据与生产线实物对应, 且为后续生产提供历史数据, 实现了产品数据的可靠采集与管理。

参考文献:

- [1] 宋锦涛. 面向数字化车间设备状态的监控技术研究与应用[D]. 北京: 中国科学院大学, 2019.
- [2] 蒋龙宁. 面向数字化装配过程的质量信息管控系统开发[D]. 沈阳: 沈阳理工大学, 2023.
- [3] 刘成义. 液压泵装配过程智能管控系统设计与开发[D]. 南京: 南京理工大学, 2022.
- [4] 李志东. 数字化制造车间系统构建[J]. 一重技术, 2011(1): 66-68.
- [5] 陈永平. 数字化制造车间管理系统的集成研究[D]. 沈阳: 沈阳理工大学, 2014.
- [13] 贾俊. 计算机无线网络通信中的传输控制技术[J]. 信息记录材料, 2022, 23(7): 198-201.
- [14] 夏祎, 殷倩倩, 申鑫欣. 大数据时代计算机远程网络通信技术的优化[J]. 数字技术与应用, 2022, 40(5): 101-103.
- [15] 施向荣. 计算机网络通信技术和光纤通信技术研究[J]. 光源与照明, 2022(1): 119-121.