

基于边缘计算的纺织品瑕疵检测系统

魏 雄, 刘佳祺

(武汉纺织大学 计算机与人工智能学院, 湖北 武汉 430000)

摘要: 由于生产规模的扩大化和加工流程的复杂化, 织物瑕疵成为纺织工业中的常见问题。传统的纺织品瑕疵检测方法主要依赖于人工目视检查, 容易出现视觉疲劳、效率低下等问题。为此, 提出一种基于边缘计算与改进卷积神经网络的纺织品瑕疵检测系统, 实现了对纺织物的数据采集、瑕疵检测与上报预警等功能。该系统将卷积神经网络的全局感受野与注意力机制相结合, 实现了对瑕疵特征的高效捕捉与分类, 可使纺织企业在生产环境中进行瑕疵检测计算与数据处理, 瑕疵检测总体准确率可达97.11%, 其中瑕疵产品检测准确率为84.02%, 无瑕疵产品检测准确率为97.98%, 瑕疵检测召回率为95.28%。该系统在实际场景中应用效果优异, 可有效提高检测效率、加强产品质量控制、降低生产成本, 对于实现纺织工业的智慧化发展具有重要意义。

关键词: 边缘计算; 卷积神经网络; 瑕疵检测; 智能纺织; 自注意力机制

DOI: 10.11907/tj.241383

开放科学(资源服务)标识码(OSID):

中图分类号: TP302.1

文献标识码: A

文章编号: 1672-7800(2025)006-0107-06



Textile Defect Detection System Based on Edge Computing

WEI Xiong, LIU Jiaqi

(School of Computer and Artificial Intelligence, Wuhan Textile University, Wuhan 430000, China)

Abstract: Due to the expansion of production scale and the complexity of processing flow, fabric defects have become a common problem in the textile industry. The traditional textile defect detection methods mainly rely on manual visual inspection, which is prone to problems such as visual fatigue and low efficiency. Therefore, a textile defect detection system based on edge computing and improved convolutional neural network is proposed, which realizes the functions of data collection, defect detection, reporting and early warning of textile. The system combines the global receptive field of convolutional neural networks with attention mechanisms to efficiently capture and classify defect features, enabling textile enterprises to perform defect detection calculations and data processing in production environments. The overall accuracy of defect detection can reach 97.11%, with defect product detection accuracy of 84.02%, defect free product detection accuracy of 97.98%, and defect detection recall rate of 95.28%. The system has excellent application effects in practical scenarios, effectively improving detection efficiency, strengthening product quality control, and reducing production costs. It is of great significance for realizing the intelligent development of the textile industry.

Key Words: edge computing; convolutional neural network; defect detection; intelligent textile; self-attention mechanism

0 引言

纺织工业一直是全球经济的重要支柱产业。然而, 随着生产规模的扩大化和流程的复杂化, 织物瑕疵成为纺织工业中的常见问题。各类断裂、杂质、痕迹、无纤维区域、磨损、线头、错位等问题都会导致纺织物产生瑕疵, 这些瑕疵不仅会破坏纺织品的完整性与美观度, 而且会导致其强

度下降、易磨损开裂, 因此纺织品生产过程中的瑕疵检测十分重要。传统的纺织品瑕疵检测方法主要依赖于人工目视检查, 不仅效率不高, 而且成本高昂, 无法满足现代纺织品产业高效、快速、准确的瑕疵检测需求。

现阶段, 纺织产业正朝着智能化与数字化方向迈进, 专家学者在纺织品瑕疵检测算法方面进行了许多研究^[1]。纺织品瑕疵检测算法主要分为传统图像算法与深度学习算法两大类^[2]。传统图像算法包括基于空间域的统计方

收稿日期: 2024-04-17

扫描二维码阅读全文:



作者简介: 魏雄(1974-), 男, 武汉纺织大学计算机与人工智能学院副教授, 研究方向为软件可靠性、并行计算和纺织服装大数据; 刘佳祺(1999-), 男, 武汉纺织大学计算机与人工智能学院硕士研究生, 研究方向为雷达信号处理。

法、基于频率域的谱方法、基于中值滤波的图像处理方法、遗传算法等^[3-7]；深度学习算法包括 YOLO 系列算法、Fast-er-RCNN 算法与对抗神经网络算法等^[8-13]。然而,传统图像算法对于纺织品瑕疵的检测准确度较差,深度学习算法模型较为复杂,难以满足企业对于边缘端的实时检测需求。

边缘计算是一种在物理与数字世界之间搭建桥梁的新兴计算技术,在较多领域发挥了重要作用^[14-19]。该技术可使纺织企业在生产环境中进行高效的检测计算与数据处理,能够实现低延迟、高带宽和低能源消耗的数据传输,并且能与纺织物联网系统进行融合,从而形成智慧纺织工厂^[20-24]。

为解决传统瑕疵检测方法存在的问题,本文提出基于边缘计算的纺织品瑕疵检测系统,采用改进的卷积神经网络(Convolutional Neural Networks, CNN)作为瑕疵分类检测算法,利用其优秀的图像识别和分类性能实现纺织品瑕疵的检测与分类。此外,该系统还采用高效的数据存储与传输机制,以及友好的软件界面设计,提高了其易用性和人机交互性。验证实验结果表明,该系统可提高瑕疵检测的准确性和效率,减少人力资源需求,有利于推进纺织工业智慧化进程。

1 系统设计

1.1 边缘计算系统架构

现阶段基于深度学习的纺织品瑕疵检测方法主要依赖于昂贵的高性能计算设备和云计算资源,限制了实时瑕疵检测的可行性,而且增加了传输延迟和带宽需求。边缘计算技术为纺织品瑕疵检测系统提供了一种全新的解决方案。该技术可以将瑕疵检测算法与模型部署到靠近纺织品的边缘设备上,避免了数据传输延迟和带宽消耗;同时利用边缘设备的计算能力进行纺织品瑕疵的实时检测,减少对云计算中心的依赖,还可以通过数据本地化和隐私保护等功能来加强瑕疵检测系统的安全性和隐私性。

本文系统将智能化边缘设备部署在生产线上,能够对来自传感器的实时数据进行快速处理与分析。通过将计算任务从云端转移到边缘设备上,系统实现了低延迟的瑕疵检测响应,即当检测到纺织品瑕疵时,边缘设备可以立即发出报警并采取相应措施,不需要等待云端响应。此外,边缘设备可以将检测到的数据上传至云端进行模型训练与决策方案优化。这种边缘—云协同的架构使得系统在保证实时响应能力的同时可以充分利用云计算的强大性能进行数据分析与模型支持,从而提高瑕疵检测的准确性和可靠性。

边缘计算纺织品瑕疵检测系统主要包括硬件层、数据层、算法层和应用层。具体架构见图 1。其中,硬件层主要负责纺织品生产线上传感器和摄像头数据的采集,并执行

相应的硬件操作;数据层作为系统的中间层,负责不同层之间的数据交互与转换;算法层嵌入改进的 CNN 瑕疵分类算法,对数据层提供的数据进行分析,并将结果传递给应用层;应用层直接与工程师进行交互,负责分析生产数据和瑕疵判断结果,并通过程序界面或云端接收指令,将其转化为对应的硬件指令代码并发送给数据层,以实现纺织品瑕疵检测系统的控制与管理。




Fig. 1 Architecture of edge computing textile defect detection system

图 1 边缘计算纺织品瑕疵检测系统架构

在该架构下,边缘计算系统具有较强的可拓展性与稳定性,通过数据层实现层次之间的解耦,使得系统能够根据具体需求进行灵活配置与功能拓展,实现了管理系统的高度定制化与智能多样化。通过数据层的无缝连接,整个系统能够进行实时数据的交换与共享,提高了整体效率和可靠性。

1.2 数据处理

1.2.1 数据采集与指令下达

边缘计算纺织品瑕疵检测系统采用 Android 应用程序来控制摄像头进行纺织品照片数据的采集,同时通过 RS485 串口和 Modbus 工业通讯协议实现对硬件设备的控制。Android 应用程序通过 Camera 类提供的接口与摄像头进行通信。具体步骤为:①使用 Camera.open()方法打开摄像头设备;②使用 Camera.getParameters()方法获取当前摄像头的参数,然后通过 setParameter 方法进行预览尺寸、照片尺寸等参数的设置;③调用 Camera 对象的 takePicture()方法触发摄像头进行拍照;④保存到本地存储器。

系统与数控设备之间的通讯采用 RS485 串口、Modbus 工业通讯协议,利用 Java 语言以及 C++ 包开发设备连接管理驱动程序,从而实现对硬件设备的控制。具体流程为:①配置串口并打开连接。系统根据上位机串口的虚拟地址以及下位机的串口配置数据对串口实例进行配置,包括串口名称、波特率、校验位、数据位和停止位等参数,系统通过调用串口通信库打开串口连接;②分配线程并发送/接收 MODBUS 数据。系统从线程池中分配线程,用于发送和接收 Modbus 数据。在分配的线程程序以及子线程中加入串口异常捕捉机制,用于处理通信过程中可能出现的异

常情况。当出现异常时,系统关闭并重新启动串口连接,以确保通信的稳定性;③数据校验。系统在接收到数据后将进行位数校验以确保数据的完整性和正确性,同时检测硬件设备是否正确执行指令;④关闭串口。当整个系统关闭时,将同时关闭RS485串口连接。

1.2.2 数据存储

采用SQLITE数据库保存设备数据以及日志数据,开发SQLITE Utils模块实现数据库连接池,对数据库进行连接、读取、写入等操作。数据库连接池的实现逻辑如图2所示。数据存储的主要流程为:①获取数据库连接池中的连接并连接数据库;②定义表的实体类,包括Camera data、CNN-Transformer result、Instructions data、Log等;③进行数据增、删、改、查等操作。




Fig. 2 Implementation logic of database connection pool

图2 数据库连接池的实现逻辑

1.2.3 数据传输

系统采用MQTT(Message Queuing Telemetry Transport)协议与云端服务器进行数据交互,实现实时可靠的消息传输。详细流程及主题设计为:①MQTT模块通过云端服务器的地址和端口与云端服务器建立连接;②边缘计算系统主题订阅或发布。根据不同需求来进行主题的订阅或发布操作,发布主题格式通常包含{Topic type}\{Workshop ID}\{Device UUID}\{Data type},其中Topic type表示主题类型,Workshop ID表示纺织工厂车间ID,Device UUID表示设备的唯一标识,Data type表示数据类型。订阅的主题格式通常为{Topic type}\{Workshop ID}\{Device UUID}\#,其中#代表通配符,用于匹配所有的主题;③服务器订阅和主题发布。云端服务器订阅{Topic type}\#主题,用于接收所有来自终端设备的数据,同时服务器可以发布Instructions\{Workshop ID}\{Device UUID}\{Instructions type}主题,向系统中不同的硬件设备下发指令;④发送数据至

云端服务器。MQTT模块对来自Event Bus消息总线中的数据进行加工处理,通常将其转换成JSON字符串的格式,并通过MQTT协议将传感器数据、瑕疵检测结果发送至云端服务器;⑤解析并控制设备动作。MQTT模块对接收到的指令进行解析,并对设备进行相关动作控制。根据服务器发布的Instructions\{Workshop ID}\{Device UUID}\{Instructions type}主题,系统解析其中包含的指令信息,然后执行相应的动作控制,如调整纺织品瑕疵检测算法参数、重新启动设备、控制自动设备对瑕疵纺织品进行处理等。

1.3 CNN-Transformer瑕疵检测算法

1.3.1 CNN

CNN是一种具有卷积结构的深度神经网络,一般由卷积层、池化层、全连接层交替组合构成。数据图像通过卷积层和池化层进行特征提取与降维,再通过全连接层进行特征聚合与分类。卷积层中的每个卷积核具有相同的结构,其利用局部感受野和权值共享机制大大减少了深层网络的内存占用量和计算量。输入数据进行局部卷积后,采用激活函数对结果进行非线性映射,得到输入数据的局部特征,卷积核会根据设定的步长不断在图像上进行平移,从而完成对整个图像的特征采集工作。卷积运算可使原始图像的某些特征增强,并且降低噪声。卷积操作示意图如图3所示。卷积层的计算公式为:

$$X_j^l = f\left(\sum_{i \in M_j} X_i^{l-1} * K_{ij}^l + b_j^l\right) \quad (1)$$

式中: X_j^l 为第 l 层中第 j 个特征映射的激活值; $f(x)$ 为非线性激活函数; M_j 为经过选择后的输入特征; X_i^{l-1} 为第 l 层第 j 个局部感受域;*表示卷积算子; K_{ij}^l 与 b_j^l 分别表示权重矩阵与偏置值。




Fig. 3 Convolution operation schematic

图3 卷积操作示意

为了更好地对复杂特征进行学习,在CNN中加入非线性的激活函数,进一步增强对复杂特征的区分度。一般采用ReLU函数作为激活函数,该函数可使一部分神经元的输出值为0,增加了网络的稀疏程度,有效降低了参数之间的相互依存度与过拟合的风险,避免了梯度消失问题。ReLU的运算表达式为:

$$f(x) = \max\{0, x\} \quad (2)$$

式中:当 $x > 0$ 时,ReLU的梯度恒等于1,不存在梯度消失问题;当 $x < 0$ 时,输出值恒等于0,增加了网络的稀疏程度,有助于加速网络训练。

池化层(下采样层)可缩小参数矩阵的尺寸,减少全连接层的参数量,在进行特征降维的同时保持特征性能稳定,从而加快运算速度并防止网络过拟合。池化运算主要包括最大池化、平均池化、随机池化3种,最常用的为最大池化。最大池化以设定的池化窗口大小与步长对输入特征进行下采样,然后选择窗口区域内的最大值作为该区域池化后的值。具体如图4所示。




Fig. 4 Schematic of maximum pooling

图4 最大池化示意

在CNN中,输入图像经过多层卷积层与池化层后,最终输入到网络尾部的全连接层。全连接层中两层之间的所有神经元均有权重连接,并且有激活函数进行非线性映射,以便对所有特征进行整合与分类。全连接层结构如图5所示。

全连接层对所有特征进行整合,输出层根据全连接层的结果对图像进行分类,一般采用Softmax函数作为多分类问题的最后输出单元,函数的输出值表征了不同类别之间的相对概率。Softmax的表达式为:

$$S_i = \frac{e^{V_i}}{\sum_i^C e^{V_i}} \quad (3)$$

式中: V_i 为分类器前级单元的输出; i 为类别索引; C 为总的类别个数; S_i 表示当前元素指数与所有元素指数和的




Fig. 5 Fully connected layer structure

图5 全连接层结构

比值。

1.3.2 CNN-Transformer 模型构建

针对纺织品生产中普遍存在的瑕疵问题,本文提出一种改进的CNN纺织品瑕疵识别模型CNN-Transformer。改进模型包括2个卷积层、2个池化层、1个Transformer层、2个全连接层和1个分类层。结构如图6所示。在CNN-Transformer模型中,卷积层通过卷积操作识别纺织品瑕疵的局部模式,并利用池化层缩小矩阵尺寸,进一步提取纺织品图像的重要特征;Transformer层通过自注意力机制对微小瑕疵特征进行更加准确的识别;全连接层对所有特征进行整合,并利用Softmax函数进行分类。同时,在卷积层与全连接层中引入激活函数,将线性函数转换为非线性函数,以增强网络的逼近能力。为避免过拟合现象影响模型的泛化能力和准确率,在模型训练时对全连接层使用Dropout操作。每次训练时,随机隐藏网络中的部分神经元,并更新剩余神经元的权重,多次进行这一操作,直至训练完成。CNN-Transformer模型结构简单,大幅减少了计算量和训练时间,具有强大的泛化能力,能够准确、快速地识别纺织品瑕疵。




Fig. 6 Structure of CNN-Transformer

图6 CNN-Transformer 结构

1.3.3 模型训练

改进CNN模型的构建与训练均基于Python语言和

TensorFlow神经网络框架,在带有NVIDIA RTX4090 GPU的Windows10系统的主机上进行。具体实验环境参数如

表 1 所示。

Table 1 Experimental environment parameters
表 1 实验环境参数

名称	参数	描述
CPU	AMD Ryzen 9	快速处理数据预处理和其他非 GPU 加速任务
GPU	NVIDIA RTX 4090	加速神经网络的训练
内存	128GB DDR4	支持大量数据加载
存储	2TB NVMe SSD	快速读写训练数据集
操作系统	Windows 10	提供稳定的运行环境
深度学习框架	TensorFlow	构建和训练神经网络模型
编程语言	Python 3.8	编写和执行训练脚本

在训练前按照 6:2:2 的比例将织物疵点数据集分为训练集、测试集与验证集。网络总迭代次数 Epoch 设置为 150 次,学习率为 0.000 5。采用分批次训练的方式,每次训练随机不重复地选取 50 张图片输入网络中,得到其训练准确率和交叉熵损失曲线如图 7、图 8 所示。可以看出,模型准确率在训练次数为 1 500 次以前呈上升趋势,之后稳定在 0.98 左右;交叉熵损失一直呈下降趋势,训练 8 700 次时最小,达到 0.005。




Fig. 7 Training accuracy curve

图 7 训练准确率曲线




Fig. 8 Cross entropy loss curve

图 8 交叉熵损失曲线

网络训练完毕后需要进行性能评估。将验证集输入训练好的网络中,准确率达到 0.98。训练集、测试集与验证集的准确率相差很小,说明网络不存在过拟合现象,能够非常准确地对纺织品图像进行瑕疵检测。

2 验证实验

将边缘计算纺织品瑕疵检测系统部署在生产现场,选取系统运行过程中产生的纺织品数据及瑕疵检测结果日志进行分析,验证其在生产线上对纺织品瑕疵的检测准确

度。系统部署在生产设备上正常运行后将产生大量生产数据,但无法直接用于评估系统性能,需人工对检测结果进行标注。由于时间和人力成本限制,本文仅选择部分生产日志数据进行标注,得到系统判断结果的混淆矩阵,具体如表 2 所示。由混淆矩阵可知,模型总体准确率为 97.11%,其中瑕疵产品的判断准确率为 84.02%,无瑕疵产品的判断准确率为 97.98%,对瑕疵的召回率为 95.28%。模型实际效果与实验室数据相比有小幅下降,但仍维持在较高水平。

Table 2 Confusion matrix of textile defect detection results
表 2 纺织品瑕疵检测结果混淆矩阵

真实值\预测值	有瑕疵	无瑕疵
有瑕疵	343	17
无瑕疵	65	3 175

为验证本文算法的优越性,选取 Faster R-CNN、SSD、YOLOv3、YOLOv5s、VGG16+FANS、Inception-Net+M-LSTM 作为比较算法,在相同试验条件下进行训练与测试。准确率比较结果如表 3 所示。可以看出,本文算法的准确率较次优算法 Inception-Net+M-LSTM 提高了 2.81%。

Table 3 Comparison of the accuracy of different algorithms
表 3 不同算法准确率比较

检测算法	准确率/%
Faster R-CNN	57.30
SSD	55.40
YOLOv3	53.80
YOLOv5s	51.70
VGG16+FANS	92.50
Inception-Net+M-LSTM	94.30
本文算法	97.11

为验证改进 CNN 模型各模块设计的有效性,以 2 层卷积层、2 层池化层、2 层全连接层的基础 CNN 为基准模型,在相同数据集上进行消融实验。结果如表 4 所示。

Table 4 Results of ablation experiments
表 4 消融实验结果

模型	卷积层	池化层	全连接层	Transformer 层	准确率/%
CNN	2	2	2	0	88.15
CNN-2	2	2	4	0	91.81
CNN-3	2	2	6	0	90.46
CNN-Transformer	2	2	2	1	97.11

可以看出,CNN 基准模型对纺织品瑕疵的检测准确率为 88.15%。CNN-2 模型在基准模型的基础上增加了 2 层全连接层,模准确率提升至 91.81%,表明增加一定量的全连接层能更有效地识别全局信息,从而提高瑕疵分类准确率。CNN-3 模型在基准模型的基础上增加了 4 层全连接层,但与 CNN-2 模型相比准确率略有下降,为 90.46%,可能是由于增加过多全连接层引入了大量参数,导致模型难以优化。本文提出的 CNN-Transformer 模型在基准模型的基础上增加了 1 层 Transformer 层,准确率提升较为明显,为 97.11%,表明 Transformer 层起到了关键作用,其拥有的注意力机制能够更好地帮助模型捕捉卷积层与池化层提

取的瑕疵特征信息。

3 结语

本文提出的边缘计算纺织品瑕疵检测系统能够对纺织工厂内的纺织物进行快速处理与分析,实现了低延迟的瑕疵检测与响应。当检测到纺织品出现瑕疵时,边缘设备可以立即发出报警并采取相应的措施,而不需要等待云端响应。随着人工智能技术的不断发展,纺织物瑕疵检测系统可融入更高级的算法和模型,进一步应用于更多生产环节,如鞋类瑕疵检测、纺织品颜色变化检测等领域,从而实现纺织工业的全程智能化。

参考文献:

- [1] GONG L. Application research of machine vision technology in textile industry[J]. Textile Report, 2023, 42(4): 31-33.
宫丽. 机器视觉技术在纺织产业中的应用研究[J]. 纺织报告, 2023, 42(4): 31-33.
- [2] ZENG Y H, ZHANG P F, GUO L L, et al. Fabric defect detection method based on deep learning and Raspberry PI[J]. Shanxi Electronic Technology, 2022(6): 19-20, 26.
曾永恒, 张鹏飞, 郭龙龙, 等. 基于深度学习与树莓派的织品瑕疵检测方法[J]. 山西电子技术, 2022(6): 19-20, 26.
- [3] CHERRI A K, KARIM M A. Optical symbolic substitution: edge detection using Prewitt, Sobel, and Roberts operators[J]. Applied Optics, 1989, 28(21): 4644-4648.
- [4] PARULSKI K A, AXMAN M S. Automatic image sharpening in an electronic imaging system[P]. U. S. Patent 5,696,850. 1997-12-09.
- [5] BROWN R G, HWANG P Y C. Introduction to random signals and applied Kalman filtering[M]. New York: Wiley, 1992.
- [6] GUAN X W. Flaw detection system of warp knitted fabric based on digital image processing[D]. Changchun: Jilin University, 2016.
关向伟. 基于数字图像处理的经编布瑕疵检测系统[D]. 长春: 吉林大学, 2016.
- [7] YANG P P. Research on Gabor filter constructed based on genetic algorithm and flaw detection of printed fabrics with regular band features[D]. Xi'an: Xi'an Polytechnic University, 2016.
杨盼盼. 基于遗传算法构造的Gabor滤波器及规则带特征的印花织物瑕疵检测研究[D]. 西安: 西安工程大学, 2016.
- [8] ZHANG X. Research on spindle detection and sorting system based on machine vision[D]. Wuhan: Wuhan Textile University, 2023.
张熙. 基于机器视觉的纱锭检测与分检系统研究[D]. 武汉: 武汉纺织大学, 2023.
- [9] LONG Y. Research on fabric defect detection algorithm based on deep learning[D]. Xiamen: Xiamen University of Technology, 2023.
龙玥. 基于深度学习的织物瑕疵检测算法研究[D]. 厦门: 厦门理工学院, 2023.
- [10] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 779-788.
- [11] CAI X Z, LI R X, DAI Y D, et al. Fabric defect identification system based on Faster RCNN[J]. Computer System Application, 2021, 30(2): 83-88.
蔡兆信, 李瑞新, 戴逸丹, 等. 基于Faster RCNN的布匹瑕疵识别系统[J]. 计算机系统应用, 2021, 30(2): 83-88.
- [12] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.
- [13] LIU J. Research on defect detection of highlight fabric based on generative adversarial network[D]. Wuhan: Wuhan Textile University, 2021.
刘杰. 基于生成对抗网络的高光织物瑕疵检测研究[D]. 武汉: 武汉纺织大学, 2021.
- [14] SUN P. Research on edge cloud computing architecture and data migration method[J]. Information and Computers (Theory), 2014(12): 127-128.
孙鹏. 边缘云计算体系结构及数据迁移方法研究[J]. 信息与电脑(理论版), 2014(12): 127-128.
- [15] ZHANG W. Research on task migration mechanism in edge computing[J]. Software Guide, 2020, 19(9): 48-53.
张伟. 边缘计算的任务迁移机制研究[J]. 软件导刊, 2020, 19(9): 48-53.
- [16] ZHANG H C, WANG H J. SDN-based mobile edge computing offloading strategy in vehicular networks[J]. Software Guide, 2021, 20(8): 105-109.
章宜成, 王海江. 车联网中基于SDN的移动边缘计算卸载策略[J]. 软件导刊, 2021, 20(8): 105-109.
- [17] LI F R, YI Y P, SHI W. Big data technology for active distribution networks based on edge computing[J]. Software Guide, 2021, 20(8): 160-165.
李芙蓉, 易映萍, 石伟. 基于边缘计算的主动配电网配电大数据技术[J]. 软件导刊, 2021, 20(8): 160-165.
- [18] LIU X Y, XU Z W, LI W Y, et al. Classification-based data compression and transmission mechanism for efficient edge computing[J]. Software Guide, 2022, 21(11): 38-43.
刘晓燕, 许志伟, 李文越, 等. 面向高效边缘计算的可分类数据压缩传输机制[J]. 软件导刊, 2022, 21(11): 38-43.
- [19] YANG X H, XIONG X F, SONG Y J, et al. Energy-constrained migration strategy in mobile edge computing[J]. Software Guide, 2022, 21(1): 164-170.
杨晓慧, 熊小峰, 宋逸杰, 等. 移动边缘计算中以节点能耗约束的迁移策略研究[J]. 软件导刊, 2022, 21(1): 164-170.
- [20] XU A, WANG L, WANG J, et al. Resource allocation scheme for real-time video streaming in edge computing[J/OL]. Software Guide, 1-7. [2024-04-25]. <http://kns.cnki.net/kcms/detail/42.1671.TP.20240321.1337.036.html>.
徐奥, 王磊, 王俊, 等. 面向实时视频流传输的边缘计算资源分配方案[J/OL]. 软件导刊: 1-7 [2024-04-25]. <http://kns.cnki.net/kcms/detail/42.1671.TP.20240321.1337.036.html>.
- [21] HU L B, LI P D. Image edge detection system based on programmable SoC[J]. Software Guide, 2020, 19(3): 244-247.
胡龙宝, 李丕丁. 基于可编程SOC的图像边缘检测系统[J]. 软件导刊, 2020, 19(3): 244-247.
- [22] ALI S, HAMED A, SPASENOV A Y, et al. Decentralized edge-AI system for real-time syrian license plate recognition using Khadas Vim3[C]//2024 6th International Youth Conference on Radio Electronics, Electrical and Power Engineering, 2024: 1-5.
- [23] REDDY B V, SK K B, POLANKI K, et al. Smarter way to monitor and detect intrusions in cloud infrastructure using sensor-driven edge computing[C]//IEEE International Conference on Computing, Power and Communication Technologies, 2024: 918-922.
- [24] SMINK M, LIU H, DÖPFER D, et al. Computer vision on the edge: individual cattle identification in real-time with ReadMyCow system[C]//Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision, 2024: 7056-7065.

(责任编辑:尹晨茹)