

DOI: 10.19650/j.cnki.cjsi.J2412748

# 基于列向语义分割的悬浮间隙视觉检测方法研究

靖永志<sup>1,2,3</sup>,倪胜<sup>1,3</sup>,贾兴科<sup>1,2</sup>,刘治辛<sup>1,3</sup>,刘国清<sup>1,2</sup>

(1. 西南交通大学磁浮技术与磁浮列车教育部重点实验室 成都 611756; 2. 西南交通大学电气工程学院 成都 611756;  
3. 西南交通大学唐山研究院 唐山 063000)

**摘要:**针对传统语义分割网络存在参数量大、实时性低以及抗干扰能力差的问题,提出了一种基于列向语义分割的悬浮间隙视觉检测方法。该方法将间隙检测定义为寻找间隙在图像中部分列位置的集合,简化分类问题以缩减计算复杂度。首先,设计了基于视觉间隙检测悬浮系统结构,基于列方向上的位置选择和分类设计了一种间隙检测语义分割网络(GMSSNet),并采用 $1\times 1$ 卷积加列向亚像素卷积层模块代替全连接层进一步减少模型参数量;然后,构建了悬浮间隙样本集并配置训练环境,对所设计的GMSSNet模型分别进行了抗干扰能力测试、消融实验和闭环悬浮实验。实验结果表明,GMSSNet模型具有较高的检测精度,正常悬浮间隙检测样本时的最大检测误差为 $\pm 0.1$  mm,线性度为0.5% F.S,存在偏移或特定遮挡情况下,网络最大检测误差为 $\pm 0.15$  mm,线性度为0.75% F.S,闭环悬浮实验表明基于GMSSNet模型的悬浮间隙检测精度和速度均满足悬浮系统要求。

**关键词:** 语义分割; 悬浮间隙检测; 深度学习; 超分辨率

中图分类号: TP183 TH702 文献标识码: A 国家标准学科分类代码: 470.40

## Research on the visual detection method of levitation gap based on column-oriented semantic segmentation

Jing Yongzhi<sup>1,2,3</sup>, Ni Sheng<sup>1,3</sup>, Jia Xingke<sup>1,2</sup>, Liu Zhixin<sup>1,3</sup>, Liu Guoqing<sup>1,2</sup>

(1. Key Laboratory of Maglev Technology and Maglev Train, Ministry of Education, Southwest Jiaotong University, Chengdu 611756, China; 2. College of Electrical Engineering, Southwest Jiaotong University, Chengdu 611756, China; 3. Tangshan Institute, Southwest Jiaotong University, Tangshan 063000, China)

**Abstract:** To address the problems of a large number of parameters, low real-time performance, and poor anti-interference ability of traditional semantic segmentation networks, a visual detection method of suspension gap based on column-oriented semantic segmentation is proposed. The method defines gap detection as finding the set of disaggregated locations of gaps in the middle of the image and simplifies the classification problem to reduce the computational complexity. Firstly, the structure of the visual gap detection-based suspension system is designed. A gap detection semantic segmentation network (GMSSNet) is designed based on position selection and classification in the column direction. The number of model parameters is further reduced by using a  $1\times 1$  convolution plus column-wise sub-pixel convolution layer module instead of a fully connected layer. Then, the suspension gap sample set is constructed and the training environment is configured. The designed GMSSNet model is tested for anti-jamming ability, ablation experiments, and closed-loop suspension experiments, respectively. The experimental results show that the GMSSNet model has high detection accuracy, the maximum detection error is  $\pm 0.1$  mm and the linearity is 0.5% F.S for normal levitation gap detection samples. The maximum detection error of the network is  $\pm 0.15$  mm and the linearity is 0.75% F.S in the presence of offset or specific occlusion. The closed-loop levitation experiments show that the levitation gap detection accuracy and speed of the GMSSNet model meet the requirements of the suspension system.

**Keywords:** semantic segmentation; levitation gap detection; deep learning; super resolution

## 0 引言

磁悬浮技术因为其无接触、无摩擦、无磨损等特点,广泛应用于磁悬浮轴承、磁悬浮电机、磁悬浮列车、医疗设备等领域<sup>[1-3]</sup>。由于悬浮系统本质上强耦合、非线性、不稳定,为实现系统稳定悬浮,悬浮控制器需要获得悬浮间隙,控制器根据特定的控制策略计算出相应的控制量并作用于电磁铁,间隙传感器是磁悬浮系统重要组成部分,负责悬浮间隙值的检测。悬浮间隙传感器的稳定性、准确性和实时性对于磁悬浮系统的稳定运行至关重要<sup>[4]</sup>。因此在磁悬浮领域,关于间隙传感器的研究始终是研究热点。

传统间隙传感器主要包括电涡流式传感器、光电传感器和电容式传感器,其中电涡流式传感器在磁悬浮间隙测量领域应用最为广泛。其通过电涡流效应测量悬浮间隙值,结构简单、灵敏度高、能够实现非接触式测量,但是对温度变化敏感,容易受到电磁干扰和齿槽效应等影响。为了解决这些问题,学者们提出了多种技术和方法,如多频段法、多传感器测量、温度补偿技术、屏蔽技术和差分测量技术等,可以提高电涡流传感器的测量精度和稳定性,使其在实际应用中更加准确可靠。文献[5]分析单磁铁模块模型认为悬浮磁场的漏磁和端部涡流磁场为低频干扰,通过屏蔽和滤波两种方法,设计了一种 FIR 高通滤波器,能有效抑制干扰。文献[6]使用基于径向基函数(RBF)神经网络的间隙传感器温度补偿模型,并采用一种混合算法对该模型进行参数优化,该混合算法结合了粒子群优化算法和梯度下降算法,提高了 RBF 温度补偿模型的精度,有效地降低了间隙传感器的温度漂移误差。文献[7]对传统矩形检测线圈进行了仿真,设计了一种新的检测线圈结构,该新型线圈结构能够有效地减小齿槽效应的影响,从而显著提高悬浮间隙传感器的测量精度和可靠性。文献[8]针对传统电涡流传感器体积大、无法直接测量真实电磁间隙等问题,提出了一种基于电磁铁复合线圈的磁浮车悬浮间隙检测方法。

基于机器视觉的传统图像分割办法可以有效提取图片特征,进行尺寸测量。文献[9]通过快速双纹线边缘检测法提取双纹线边缘数据,可以实现纹距实时高精度检测。文献[10]通过基于区域灰度梯度差异的摆片基片边缘检测算法,在其特征边缘点进行搜索分类,完成不同位姿下的摆片基片特征尺寸测量。传统图像处理分割方法对像素进行划分,在处理图像时能够提供一定程度的准确性和可靠性,但仍存在表示能力有限、对噪声及光照变化等干扰因素较敏感导致鲁棒性不足等局限性<sup>[11]</sup>。因此,最近的研究将深度学习引入到图像分割领域,如语义分割及实例分割等。与传统的图像分割方法相比,基

于深度学习的语义分割在处理大规模数据和复杂任务时表现更加出色,也已经取得了显著进展。深度学习减少了人为干扰,具备学习更抽象和高维特征的能力,表现出优异的特征学习潜力,能够取得更为理想的分割效果且具有较强的泛化能力。

语义分割是机器视觉的一个重要任务,是一种高级的图像分割技术,不仅对图像进行分割,而且对分割后的每个像素进行语义标注,即将像素分配给不同的类别。可以将图像中的每个像素与其所属的语义类别进行关联,以便更好地理解图像的内容<sup>[12-14]</sup>。正因为语义分割的特点,语义分割被广泛应用于目标跟踪和检测<sup>[15-16]</sup>、交通运输<sup>[17]</sup>、自动驾驶<sup>[18]</sup>等领域。文献[19]介绍了一种单目内窥镜下目标尺寸测量方法,利用内窥镜沿主光轴方向的位移和图像目标长度信息,建立了目标尺寸测量模型。通过利用针孔相机的成像技术,将目标物体的比例关系和内窥镜的位置变化联系起来,从而实现了一种准确的目标尺寸测量。文献[20]利用 Micro-CT 技术获取批量玉米籽粒的 CT 图像,通过 Watershed 算法准确分割出单颗籽粒,为后续的分析提供准确的数据基础。文献[21]针对船闸水位传感器精度易受水质影响、传统图像检测方法适应性差等问题,提出一种基于语义分割和由粗到精策略的水位线检测方法。文献[22]提出一种基于像素面积和卷积神经网络的悬浮间隙检测方法,在没有干扰的正常样本图像下能够得到较好检测精度,但由于卷积网络结构复杂处理帧率不高,且没有考虑存在偏移和遮挡等实际工况。

语义分割网络通常采用逐像素分类的方法,即对每一个像素进行分类,导致网络模型的参数量和计算量非常大,从而限制了网络的应用范围。同时,在网络模型主干简单的情况下,过多的分类结果将导致网络模型泛化能力差。基于以上分析,本文设计了一种基于列方向上位置选择和分类方法的间隙检测语义分割模型(gap measure semantic segmentation model, GMSSNet),该模型无需转置卷积进行上采样,并采用  $1 \times 1$  卷积加列向亚像素卷积层(column-oriented sub-pixel convolution layer, CSPCL)模块代替全连接层,进一步减少模型参数量提高网络模型运行速度。该模型在存在偏移或遮挡等干扰情况下,依然可以保持较高的检测准确度,具有抗干扰能力强和实时性高等优点。

## 1 基于列向语义分割的悬浮间隙检测系统

### 1.1 基于视觉检测的悬浮系统

基于视觉检测的悬浮系统结构如图 1 所示,由工业相机、控制器、斩波器、电流传感器、电磁铁、悬浮球和视觉检测模块等组成,采用基于列向语义分割的视觉检测

模块替代传统电涡流间隙传感器,采用电流-间隙双闭环控制实现系统稳定悬浮。工业相机对悬浮间隙图像进行实时采集,列向语义分割模块对图像进行特征提取得到间隙检测值,控制器将检测到的间隙信息与给定间隙进行比较并将位置差信息转换为电流信息,斩波器根据控制器输出的计算电流与电流传感器采集的实时电流差值调整电磁铁电流,从而使悬浮球稳定悬浮在给定间隙位置。

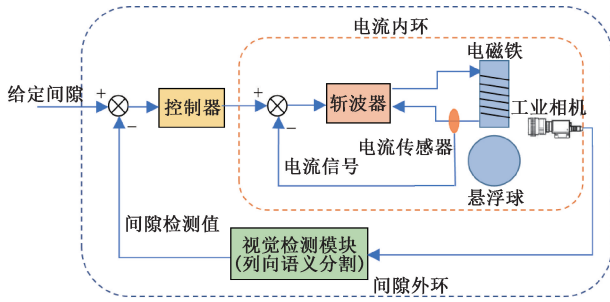


图 1 基于视觉检测的悬浮系统

Fig. 1 Suspension system based on visual detection

悬浮间隙测量的精度和速度直接影响悬浮系统稳定性,悬浮间隙传感器需要满足一些技术指标才能保证悬浮系统稳定工作,悬浮球系统间隙检测的量程为 0~20 mm,悬浮间隙的检测精度应满足  $\pm 0.4$  mm 且线性度  $< 2\%$ 。

### 1.2 基于列向语义分割的悬浮间隙检测模型

#### 1) 模型结构

针对悬浮间隙检测实时性要求及语义分割网络存在分类结果过多导致模型泛化能力差的问题,采用基于列方向上位置选择和分类的方法,设计了一种 GMSSNet 网络模型,其结构如图 2 所示。将含有悬浮间隙特征的悬浮间隙图像进行裁剪,获得小尺寸的关键区域图像。使用 3 层卷积作为 GMSSNet 的特征提取模块逐层提取原始图像的全局特征,并使用  $1 \times 1$  卷积加 CSPCL 代替全连接层作为分类器。分类器能够在输入存在小幅波动时准确进行分类,使检测系统具有一定的抗干扰能力。GMSSNet 首先将悬浮间隙图片经过特征提取,获得的特征图经过  $1 \times 1$  卷积调整通道维度,再经过 CSPCL 方法获得列高分辨率图像并映射为样本标记空间,经过最大值索引获得悬浮球位置亚像素值,最后将亚像素值转化为悬浮间隙值。

#### 2) 悬浮间隙列向语义分割

传统基于卷积神经网络的语义分割算法常采用逐像素分类,导致网络模型参数量大计算度复杂。为降低语义分割网络的参数量和计算复杂度,所提模型采用基于列方向上的位置选择和分类方法,设图像大小为  $H \times W$ ,传统语义分割算法将处理  $H \times W$  个分类问题。根据悬浮

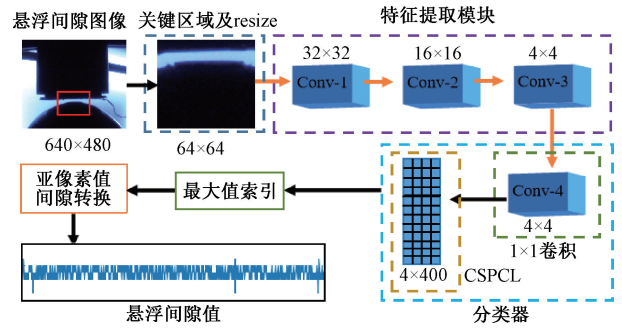


图 2 GMSSNet 模型结构

Fig. 2 GMSSNet model structure

间隙图像样本在列方向上的分布特点,若选择其中  $w$  列图像像素,则只需要处理这  $w$  列上的分类问题,因此就把原来  $H \times W$  个分类问题简化为  $H \times w$  个分类问题。如图 3 所示,关键区域图像的  $H = 64, W = 64$ ,将进行 4 096 个分类,当  $w = 4$  时,仅需处理 256 个分类问题,分类个数缩减了 16 倍。从而大幅缩减了网络模型的参数量和运算量,最终提高了网络模型运行速度。




图 3 列向悬浮间隙

Fig. 3 Column-oriented levitation gap

#### 3) 悬浮间隙列向超分辨率

在基于列向语义分割的悬浮间隙检测中,由于需要对列向图像像素进行精细分类,传统的像素级别分类方式会对语义分割网络模型的精度造成很大限制。为了解决列向图像分辨率限制网络模型精度的问题,所提模型采用超分辨率重构技术,从观测到的低分辨率图像重建出相应的高分辨率图像<sup>[23-25]</sup>。亚像素卷积神经网络 (ESPCN) 最后一层采用亚像素卷积层 (sub-pixel convolution layer, SPCL), 直接对低分辨率图像进行处理,不需要在较高的分辨率上进行卷积操作,适合应用于实时性强的场景。由于悬浮间隙检测是根据列向像素进行悬浮间隙值推断,若对行列方向同时进行超分辨率重建,将带来列向分辨率不足和间隙检测精度下降的问题,因此基于列向超分辨率重构设计了 CSPCL 结构如图 4 所示。抽取不同通道同一位置的 100 个像素特征,不同于排列成  $10 \times 10$  形状,而是仅在列方向上进

行排列  $1 \times 100$ , 作为输出高分辨率像素的一部分, 在相同特征图情况下, CSPCL 方法仅在列向加入超分辨率, 使得列向的语义信息关注度更高, 可以获得高维的列向分辨率从而更好地从亚像素级别理解图像, 提高间隙识别的精度。

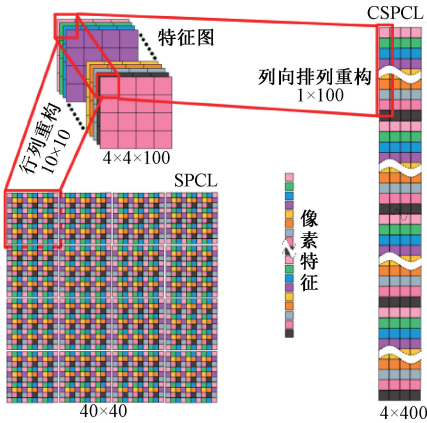


图4 列向超分辨率重构

Fig. 4 Column-oriented super-resolution reconstruction

#### 4) 分类器设计

传统分类器常采用全连接层将卷积层或池化层的输出特征映射转化为最终的分类或回归结果。每个神经元都与上一层的所有神经元相连, 全连接层的参数量很大导致网络模型过大, 同时容易出现过拟合。为避免全连接层作为分类器带来的网络复杂和实时性差问题, 分类器采用  $1 \times 1$  卷积层加 CSPCL 结构, 其中  $1 \times 1$  卷积层用于调整特征图通道数, CSPCL 用于将  $1 \times 1$  卷积层的结果映射到样本标记空间。该分类器结构可以有效降低参数量, 避免全连接层的参数冗余, 带来计算复杂度的降低以及执行速度的提升, 增强网络实时性。此外, 通过  $1 \times 1$  卷积层的调整, 可以增加模型的非线性特征表达能力, 提高模型的泛化能力, 从而进一步提高模型的性能。

## 2 实验结果与分析

### 2.1 样本采集与训练参数配置

#### 1) 相机与光源

由于悬浮系统的实时性要求, 悬浮间隙检测时需要选择高帧率的工业相机, 且不宜选择过高分辨率的相机, 过高分辨率的图像需要相对更长的处理时间, 实验采用分辨率为  $640 \times 480$  的工业相机采集悬浮间隙图像, 相机采集帧率为 790 fps。为保证成像的清晰度和对比度, 需要选择合适的镜头, 根据相机安装位置和悬浮间隙检测距离, 最终选择焦距为 4 mm、畸变小于 0.1%、最大镜面为  $1/2.5''$  的镜头。同时高帧率会减少曝光时间, 影响图

像的亮度和清晰度, 采用 LED 光源背光照明方式, 可以使悬浮间隙图像亮度更高, 边缘更加明显。

#### 2) 样本采集

样本采集过程如图 5 所示。利用步进电机调整悬浮间隙在 0~20 mm 每隔 0.025 mm 采集一张悬浮间隙图像样本, 为提高语义分割模型的泛化能力, 另外再分别采集悬浮球左右偏移电磁铁中心位置和成像区域有部分遮挡等具有干扰的悬浮间隙图像作为样本, 一共采集 3 600 张图像样本, 取 3 200 张图像作为训练集, 其余 400 张图像作为验证集。利用相机关键区域裁剪功能获得 0~20 mm 悬浮间隙区域附近的原始图像样本, 其大小为  $120 \times 120 \times 3$ , 为了进一步加快网络的运行速度, 再将图片大小调整为  $64 \times 64 \times 3$ , 每个像素具有 3 个通道的不同颜色分量值。




图5 悬浮间隙样本采集过程

Fig. 5 Levitation gap sample collection process

#### 3) 训练参数配置

训练实验环境 CPU 为 AMD Ryzen 74800H, GPU 为 NVIDIA GeForce GTX 1650 Ti。优化器选用随机梯度下降 (stochastic gradient descent, SGD) 算法, 参数动量设为 0.9, 权重衰减设为 0.000 1。批大小设为 128, 损失函数设为 Focal loss, 训练 500 个 epoch, 网络模型学习率设为 0.01。

### 2.2 语义分割模型性能测试

#### 1) 正常样本测试特性

为验证 GMSSNet 网络模型性能, 将其与传统常用网络模型全卷积神经网络 (FCN)、UNet 和 SegNet 进行对比, 不同模型检测误差结果如图 6 所示。可以看出 4 个模型对正常悬浮间隙检测样本测试的误差都在  $\pm 0.1$  mm, GMSSNet 检测误差最小, 检测精度最高。

悬浮间隙检测速度是悬浮控制系统的关键指标之一, 分别对不同网络模型的计算复杂程度、参数量和检测速度进行对比, 结果如表 1 所示。可以看出 GMSSNet 具有最小的浮点运算量和参数量, 网络检测速度最快。

综上所述, 所设计的 GMSSNet 模型在保持较高检测精度的同时, 具有更少的运算量和参数量, 处理速度显著提高, 更适用于实时性检测。

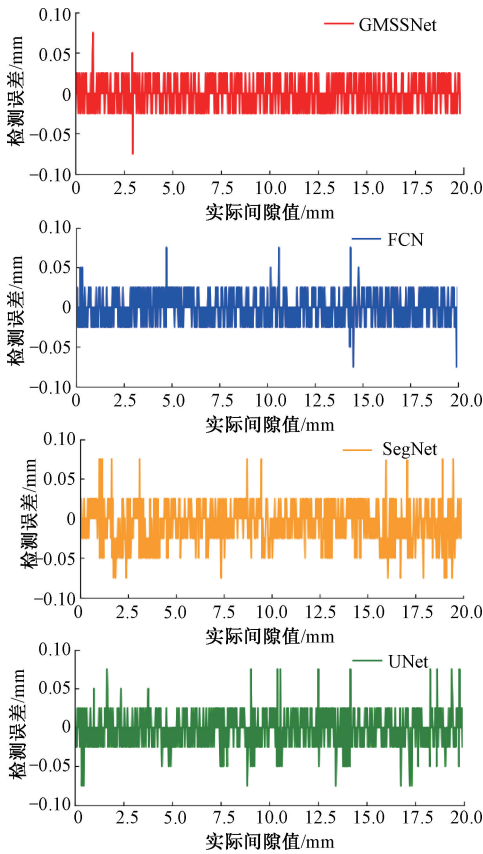


图6 不同模型检测误差

Fig.6 Detection errors of different models

表1 不同模型的参数量和运算速度

Table 1 Number of parameters and speed of computation for different models

模型	浮点运算量/MFLOPs	参数量/( $\times 10^6$ )	帧率/fps
GMSSNet	56.0	0.19	1 603
FCN	564.2	5.37	497
SegNet	2 520	29	192
UNet	509.4	14.5	218

2) 抗噪声特性

受图像传感器电子噪声、信号传输过程信噪比低、传输介质和记录设备不完善因素影响,数字图像处理过程中,常面临高斯噪声、泊松噪声和椒盐噪声等不同类型噪声干扰。为验证 GMSSNet 网络模型对不同类型噪声的抗干扰能力,引入 TOP1~TOP4 误差表征网络模型误差分布情况以衡量模型检测的稳定性。TOP1 为检测误差绝对值 $<0.05$  mm 所占百分比, TOP2 为检测误差绝对值 $\geq 0.05$  mm 且 $<0.1$  mm 所占百分比, TOP3 为检测误差绝对值 $\geq 0.1$  mm 且 $<0.15$  mm 所占百分比, TOP4 表示检测误差绝对值 $>0.15$  mm 所占百分比。分别对 0~20 mm 正

常图像样本加入高斯噪声、泊松噪声和椒盐噪声, GMSSNet 网络模型在不同噪声下的检测误差分布与线性度如表 2 所示。相对原始图像,加入噪声干扰后 GMSSNet 网络模型 TOP1 误差有所降低,但总体 TOP1 误差仍高于 98%,检测误差都在 $\pm 0.1$  mm 内,表明 GMSSNet 网络模型对噪声干扰具有较强的鲁棒性。

表2 噪声下误差分布与线性度

Table 2 Error distribution and linearity under noise (%)

图像类别	TOP1	TOP2	TOP3	TOP4	线性度
原始图像	99.50	0.50	0	0	0.5
加高斯噪声	97.75	2.25	0	0	0.5
加泊松噪声	99.00	1.00	0	0	0.5
加椒盐噪声	98.25	1.75	0	0	0.5

3) 抗偏移特性

悬浮球处于悬浮状态时,由于悬浮系统参数或外界环境因素的变化,悬浮球不可避免地偏离电磁铁中心线产生横向偏移,悬浮间隙图像特征会受到影响,因此有必要分析 GMSSNet 网络模型的抗偏移特性。GMSSNet 网络模型对悬浮球分别左右偏离电磁铁中心线 1、2 和 3 mm 的检测误差如图 7 所示,在左右 3 mm 范围内偏移时,最大绝对误差为 0.075 mm,线性度为 0.5% 内,表明 GMSSNet 对悬浮球间隙的偏移情况有较强的抗干扰能力。

4) 抗遮挡特性

悬浮球悬浮过程中,由于环境因素影响会有如灰尘、颗粒甚至线缆或工具等异物入侵成像关键区域,这些异物会对检测区域产生遮挡,从而导致悬浮间隙检测精度和准确性的下降。为验证 GMSSNet 网络模型在关键区域有遮挡时的精度和鲁棒性,采集 I~IV 4 类典型遮挡程度的间隙图像(如图 8 所示),分别对应不同大小的遮挡范围,每种遮挡分别采集 0~20 mm 范围内 100 张间隙图像进行测试。

为验证 GMSSNet 网络模型的抗遮挡性能,将其与传统常用网络模型 FCN、UNet 和 SegNet 进行对比,不同模型检测误差分布结果如表 3 所示。可以看出在有遮挡的情况下,所有网络模型的 TOP1 误差分布大幅降低,但主要集中在 TOP1 和 TOP2 范围内,个别情况在 TOP3 和 TOP4 也出现少量分布,总体而言 FCN 网络由于其较深的网络结构可以从图像中提取丰富的高层次特征,抗遮挡能力较好,而 SegNet 和 UNet 在均出现较明显的 TOP3 误差分布。GMSSNet 网络除在第 IV 类较大区域遮挡时产生 0.15 mm 检测误差外,对其余遮挡情况检测误差均未超过 0.1 mm,而 SegNet 和 UNet 在遮挡情况下出现超过

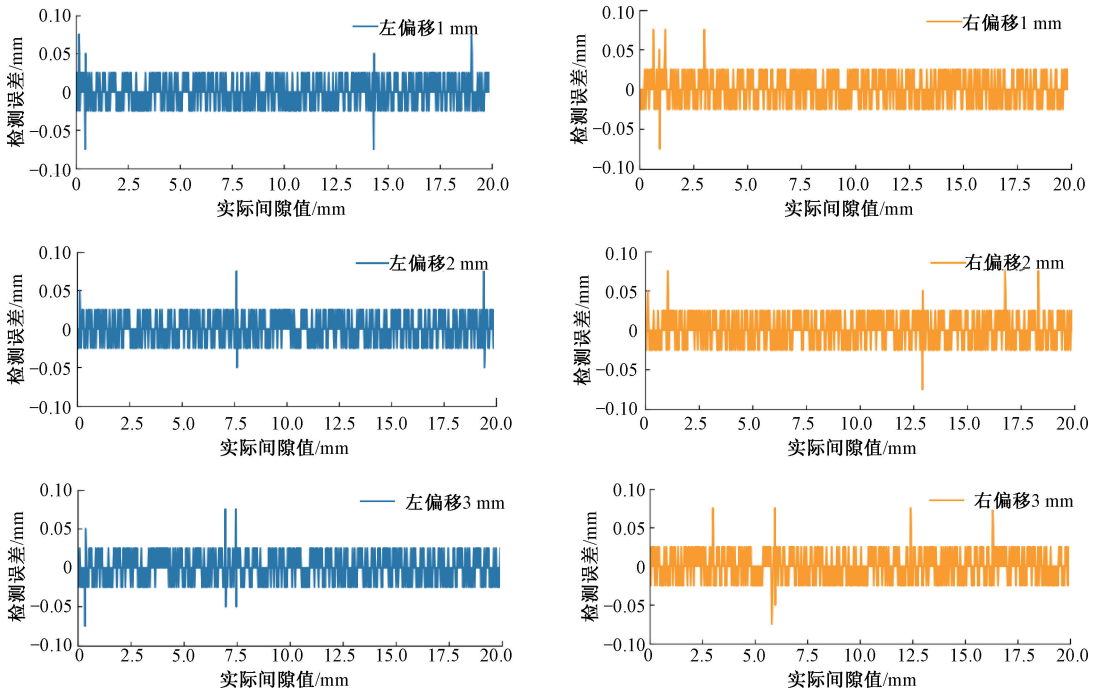


图7 不同偏移时的检测误差

Fig. 7 Detection errors at different offsets




图8 4类典型遮挡样本

Fig. 8 Samples of four types of typical masking

0.1 mm 甚至达到 0.2 mm 的检测误差,说明 GMSSNet 网络具有更好的抗遮挡能力。

### 2.3 消融实验

#### 1) 分类列数的影响

为验证分类列数  $w$  取不同值时对 GMSSNet 网络模型抗遮挡性能的影响,将分类列数  $w$  分别设置为 2、4 和 8,在遮挡数据集上进行消融实验,实验结果如表 4 所示。可以看出,当分类列数为 8 时,网络模型出现较明显的 TOP3 误差分布,尤其在遮挡 III 和遮挡 IV 的情况下检测精度显著下降,最大误差时的线性度为 4.5%。当分类列数为 2 或 4 时,网络具有良好的抗遮挡能力,但当分类列数为 4 时,网络模型精度最高,且仅在遮挡 IV 出现少量的 TOP3 误差分布。综上所述当分类列数选取 4 时,网络模型在保证检测精度的同时具有较强的抗遮挡能力。

#### 2) 分类器模块的影响

为验证  $1 \times 1$  卷积层加 CSPCL 代替全连接层作为分类器模块对 GMSSNet 网络性能的影响,在正常样本数据

表3 不同遮挡时的检测误差分布与线性度

Table 3 Detection errors distribution and linearity under different occlusions (%)

类型	网络模型	TOP1	TOP2	TOP3	TOP4	线性度
遮挡 I	GMSSNet	39.0	61.0	0.0	0.0	0.25
	FCN	49.0	51.0	0.0	0.0	0.25
	SegNet	78.0	22.0	0.0	0.0	0.25
	UNet	48.0	43.0	7.0	2.0	1.50
遮挡 II	GMSSNet	54.0	46.0	0.0	0.0	0.25
	FCN	72.0	28.0	0.0	0.0	0.50
	SegNet	44.0	49.0	7.0	0.0	0.50
遮挡 III	UNet	40.0	58.0	2.0	0.0	0.50
	GMSSNet	26.0	74.0	0.0	0.0	0.25
	FCN	61.0	37.0	2.0	0.0	0.50
遮挡 IV	SegNet	38.0	52.0	10.0	0.0	0.50
	UNet	34.0	54.0	12.0	0.0	0.50
	GMSSNet	34.0	61.0	5.0	0.0	0.50
遮挡 IV	FCN	74.0	26.0	0.0	0.0	0.25
	SegNet	50.0	41.0	9.0	0.0	0.50
	UNet	32.0	56.0	12.0	0.0	0.50

集上进行消融实验,实验结果如表 5 所示。模型采用相同的主干网络,当分类器模块采用  $1 \times 1$  卷积加 CSPCL 结

表 4 分类列数消融实验结果

Table 4 Results of categorical column ablation experiments (%)

类型	$w$	TOP1	TOP2	TOP3	TOP4	线性度
遮挡 I	2	6.0	88.0	6.0	0.0	0.75
	4	39.0	61.0	0.0	0.0	0.5
	8	47.0	39.0	14.0	0.0	0.75
遮挡 II	2	77.0	23.0	0.0	0.0	0.5
	4	54.0	46.0	0.0	0.0	0.5
	8	36.0	49.0	14.0	1.0	3.75
遮挡 III	2	36.0	58.0	6.0	0.0	0.75
	4	26.0	74.0	0.0	0.0	0.5
	8	42.0	42.0	16.0	0.0	0.75
遮挡 IV	2	9.0	76.0	15.0	0.0	0.75
	4	34.0	61.0	5.0	0.0	0.75
	8	25.0	40.0	32.0	2.0	4.5

构时,检测误差在 $\pm 0.1$  mm 内, TOP1 误差为 99.5%, 均优于全连接层分类器。同时,相对于全连接层分类器,  $1 \times 1$  卷积由于在处理通道较多的特征图时需要要对每个位置上的通道进行计算,因此会使模型浮点运算量有所增加,但模型的参数量显著降低,最终提高了网络处理速度并保证了网络模型的轻量化,模型处理帧率可达 1 603 fps。

表 5 不同分类器的对比

Table 5 Comparison of different classifiers

分类器	TOP1 /%	TOP2 /%	线性度 /%	浮点运算量 /MFLOPS	参数量 /( $\times 10^6$ )	帧率 /fps
$1 \times 1$ 卷积加 CSPCL	99.50	0.50	0.20	56.0	0.19	1 603
全连接层	79.25	20.75	0.25	24.4	4.20	1 377

### 2.4 闭环悬浮实验

为了评估 GMSSNet 检测模型在实际悬浮系统中的有效性,进行实时检测与闭环悬浮实验。基于悬浮间隙视觉检测原理的悬浮实验平台如图 9 所示,主要由电磁铁、步进电机、悬浮球、高速工业相机、PC (GMSSNet)、电涡流传感器、悬浮控制器和斩波器构成。

GMSSNet 模型实时检测悬浮间隙值,悬浮控制器依据控制律调节电磁铁电流,使悬浮球在给定间隙处稳定悬浮,基于 GMSSNet 模型间隙检测的悬浮实验波形如图 10 所示,其中电涡流传感器检测值用于对比验证并不参与悬浮控制。




图 9 悬浮实验平台

Fig. 9 Suspension experiment platform




图 10 基于 GMSSNet 间隙检测的悬浮实验波形

Fig. 10 Waveforms of levitation experiments based on GMSSNet gap detection

从图 10 可以看出,基于 GMSSNet 悬浮间隙视觉检测的悬浮系统能够将悬浮球稳定悬浮在 8 mm 悬浮间隙位置,额定悬浮电流约为 3.8 A,表明所设计的 GMSSNet 网络模型能够满足悬浮系统对间隙检测精度及实时性要求,视觉间隙检测值与电涡流传感器检测值基本一致。为验证 GMSSNet 网络模型在悬浮过程中的抗干扰能力,在悬浮球稳定悬浮后过分别在 4.5 和 11.5 s 附近加入 3 mm 偏移和第 IV 类遮挡干扰,实验结果表明 GMSSNet 网络模型在存在遮挡和偏移等干扰情况下,仍然能够精确测量悬浮间隙满足悬浮系统稳定性要求。

### 3 结 论

本文提出一种基于列向语义分割的悬浮间隙视觉检

测方法,采用列方向上位置选择和分类方法,设计了GMSSNet网络模型,该模型具有检测精度高、抗干扰能力强、运算速度快等优点。首先根据悬浮间隙样本在列方向上的位置特点,从原始 $W$ 列中选择 $w$ 列图像进行列向语义分割,将 $H \times W$ 个分类问题简化为 $H \times w$ 个分类问题,在提高网络抗干扰能力的同时缩减了网络模型的计算量和参数量。其次基于列向超分辨率重构设计了CSPCL结构,采用 $1 \times 1$ 卷积层加CSPCL代替传统全连接层作为分类器模块,获得更高维的列向分辨率,提高检测精度和执行速度,增强了网络实时性。最后进行了不同类型噪声、偏移和遮挡干扰实验,实验结果表明,所设计的GMSSNet模型具有较好的抗干扰能力,正常悬浮间隙最大检测误差为 $\pm 0.1$  mm,线性度为0.5% F. S,在存在遮挡以及偏移情况下,网络最大检测误差为 $\pm 0.15$  mm,线性度为0.75% F. S。通过消融实验,验证了分类列数取值以及 $1 \times 1$ 卷积层加CSPCL结构的有效性。闭环悬浮实验表明基于GMSSNet模型的悬浮间隙检测精度和速度均满足悬浮系统要求。且与电涡流传感器相比,GMSSNet检测模型不需要考虑温度漂移、电磁干扰等因素,可以用于温度变化较大,电磁干扰较强的间隙测量领域,在面对遮挡和偏移等干扰情况下,仍然能够精确测量悬浮间隙并保持稳定悬浮,具有广泛的实际应用价值。

## 参考文献

- [1] 刘子琦,陈启梦,李子博,等. 基于磁悬浮式基因生物成像扫描仪电磁结构设计[J]. 仪器仪表学报, 2022, 43(2): 128-137.
- LIU Z Q, CHEN Q M, LI Z B, et al. Design of electromagnetic structure based on magnetic levitation gene biological imaging scanner[J]. Chinese Journal of Scientific Instrument, 2022, 43(2): 128-137.
- [2] LIN M C, LIU L Y, LI Y H. SoPC-based function-link cerebellar model articulation control system design for magnetic ball levitation systems[J]. IEEE Transactions on Industrial Electronics, 2014, 61(8): 4265-4273.
- [3] ZHANG T, MO L H, LIU X F, et al. Modeling and performance analysis on the slice hybrid magnetic bearing with two radial air-gaps [J]. IEEE Transactions on Applied Superconductivity, 2018: 1-2.
- [4] MORALES R, FELIU V, SIRA-RAMIREZ H. Nonlinear control for magnetic levitation systems based on fast

online algebraic identification of the input gain[J]. IEEE Transactions on Control Systems Technology, 2011, 19(4): 757-771.

- [5] 罗茹丹,吴峻,李中秀. 中低速磁浮列车悬浮间隙传感器所处环境空间电磁干扰的研究[J]. 仪表技术与传感器, 2018(11):1-6.
- LUO R D, WU J, LI ZH X. Research on electromagnetic interference in the environmental space of the suspension gap sensor of medium and low speed maglev trains[J]. Instrument Technology and Sensors, 2018 (11): 1-6.
- [6] 靖永志,何飞,廖海军,等. 基于PSO优化RBF-NN的磁浮车间隙传感器温度补偿[J]. 西南交通大学学报, 2018, 53(2):367-373,384.
- JING Y ZH, HE F, LIAO H J, et al. Temperature compensation of magnetic levitation clearance sensor based on PSO optimization RBF-NN [J]. Journal of Southwest Jiaotong University, 2018, 53(2):367-373, 384.
- [7] 雷学国,张昆仑,靖永志,等. 基于Maxwell 3D高速磁浮车间隙传感器检测线圈的分析设计[J]. 仪表技术与传感器, 2010(11):102-104,107.
- LEI X G, ZHANG K L, JING Y ZH, et al. Analysis and design of gap sensor detection coil for Maxwell 3D high-speed maglev trains [J]. Instrument Technique and Sensor, 2010 (11): 102-104,107.
- [8] 靖永志,刘沁宇,贾兴科,等. 基于电磁铁复合线圈的磁浮车悬浮间隙检测方法[J]. 仪器仪表学报, 2024, 45(3): 35-44.
- JING Y ZH, LIU Q Y, JIA X K, et al. Method of levitation gap detection for maglev train based on electromagnet with a composite coil[J]. Chinese Journal of Scientific Instrument, 2024, 45(3): 35-44.
- [9] 李俊晖,石守东,谢志军,等. 基于边缘重建的双绞线绞距实时检测方法[J]. 仪器仪表学报, 2019, 40(6): 86-95.
- LIN J H, SHI SH D, XIE ZH J, et al. Twisted pair pitch real time detection method based on edge reconstruction[J]. Chinese Journal of Scientific Instrument, 2019, 40(6): 86-95.
- [10] 许斌,徐凡颖,辛若铭. 基于区域灰度梯度差异的摆片基片特征尺寸视觉测量方法[J]. 仪器仪表学报, 2022, 43(5): 128-135.
- XU B, XU F Y, XIN R M. A visual measurement



- method for feature size of pendulum substrate based on regional gray gradient difference[J]. Chinese Journal of Scientific Instrument, 2022, 43(5): 128-135.
- [11] 赵朗月, 吴一全. 基于机器视觉的表面缺陷检测方法研究进展[J]. 仪器仪表学报, 2022, 43(1): 198-219.
- ZHAO L Y, WU Y Q. Research progress of surface defect detection methods based on machine vision[J]. Chinese Journal of Scientific Instrument, 2022, 43(1): 198-219.
- [12] 罗会兰, 张云. 基于深度网络的图像语义分割综述[J]. 电子学报, 2019, 47(10): 2211-2220.
- LUO H L, ZHANG Y. A survey of image semantic segmentation based on deep network [J]. Acta Electronica Sinica, 2019, 47(10): 2211-2220.
- [13] LUO H L, ZHANG Y. Overview of image semantic segmentation based on deep networks [J]. Journal of Electronics, 2019, 47(10): 2211-2220.
- [14] MO Y J, WU Y, YANG X N, et al. Review the state-of-the-art technologies of semantic segmentation based on deep learning [J]. Neurocomputing, 2022, 493: 626-646.
- [15] 田萱, 王亮, 丁琪. 基于深度学习的图像语义分割方法综述[J]. 软件学报, 2019, 30(2): 440-468.
- TIAN X, WANG L, DING Q. Overview of image semantic segmentation methods based on deep learning[J]. Journal of Software Science, 2019, 30(2): 440-468.
- [16] 闫利, 董孟源. 基于层级卷积特征通道注意的目标跟踪方法[J]. 华中科技大学学报, 2019, 47(9): 90-94.
- YAN L, DONG M Y. Target tracking method based on hierarchical convolution feature channel attention [J]. Journal of Huazhong University of Science and Technology, 2019, 47(9): 90-94.
- [17] 马素刚, 赵祥模, 侯志强, 等. 一种基于 ResNet 网络特征的视觉目标跟踪算法[J]. 北京邮电大学学报, 2020, 43(2): 129-134.
- MA S G, ZHAO X M, HOU ZH Q, et al. A visual object tracking algorithm based on ResNet network features[J]. Journal of Beijing University of Posts and Telecommunications, 2020, 43(2): 129-134.
- [18] 郭磊, 王邱龙, 薛伟, 等. 基于改进 YOLOv5 的小目标检测算法[J]. 电子科技大学学报, 2022, 51(2): 251-258.
- GUO L, WANG Q L, XUE W, et al. Small target detection algorithm based on improved YOLOv5 [J]. Journal of University of Electronic Science and Technology of China, 2022, 51(2): 251-258.
- [19] 李睿, 代煜, 张建勋, 等. 融合五自由度位姿信息的单目内窥镜目标尺寸测量[J]. 仪器仪表学报, 2022, 43(6): 230-238.
- LI R, DAI Y, ZHANG J X, et al. Measurement of target size for a monocular endoscope using fusion of five degrees of freedom pose information[J]. Chinese Journal of Scientific Instrument, 2022, 43(6): 230-238.
- [20] 杜建军, 李大壮, 廖生进, 等. 基于 CT 图像和 RAUNet-3D 的玉米籽粒三维结构测量[J]. 农业机械学报, 2022, 53(12): 244-253, 289.
- DU J J, LI D ZH, LIAO SH J, et al. Measurement of three-dimensional structure of corn kernels based on CT images and RAUNet-3D [J]. Journal of Agricultural Machinery, 2022, 53(12): 244-253, 289.
- [21] 曹文卓, 王太固, 徐兵, 等. 基于语义分割的船闸水位检测方法研究[J]. 仪器仪表学报, 2023, 44(2): 238-247.
- CAO W ZH, WANG T G, XU B, et al. Research on water level detection of ship lock based on semantic segmentation [J]. Chinese Journal of Scientific Instrument, 2023, 44(2): 238-247.
- [22] JING Y ZH, MA X CH, ZHANG ZH F, et al. Research on visual measurement for levitation gap in maglev system[J]. IEEE Transactions on Industrial Electronics, 2022, 69(8): 8377-8386.
- [23] DONG CH, LOY CH CH, HE K M, et al. Image super-resolution using deep convolutional networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 38(2): 295-307.
- [24] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation[C]. International Conference on Medical Image Computing and Computer-Assisted Intervention, Springer, Cham, 2015: 234-241.
- [25] SHELHAMER E, LONG J, DARRELL T. Fully convolutional networks for semantic segmentation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015: 3431-3440.

## 作者简介



靖永志, 分别在 2005 年和 2014 年于西南交通大学获得硕士学位和博士学位, 现为西南交通大学副研究员, 2023~2024 年, 英国南安普顿大学做访问学者, 主要研究方向为磁悬浮列车、电磁悬浮控制和机器学习。

E-mail: jingyongzhi@swjtu.edu.cn

**Jing Yongzhi** received his M. Sc. and Ph. D. degrees in electrical engineering from Southwest Jiaotong University in 2005 and 2014, respectively. He is currently a Research Associate Professor in the Department of Electrical Engineering at Southwest Jiaotong University. From 2023 to 2024, he was a visiting scholar in University of Southampton in UK. His main research interests include maglev train, electromagnetic suspension control, and machine learning.



倪胜, 2021 年于河南工业大学获得学士学位, 现为西南交通大学硕士研究生, 主要研究方向为磁悬浮技术和图像处理。

E-mail: 1587138754@qq.com

**Ni Sheng** received his B. Sc. degree from Henan University of Technology in 2021. He is currently a master student at Southwest Jiaotong University. His main research interests include maglev technology and image processing.



刘国清(通信作者), 2005 年于西南交通大学获得硕士学位, 现为西南交通大学副研究员, 主要研究方向为电磁悬浮与线性驱动。

E-mail: 034115@163.com

**Liu Guoqing** (Corresponding author) received his M. Sc. degree in Electrical Engineering from Southwest Jiaotong University in 2005. He is currently an associate researcher in the Department of Electrical Engineering at Southwest Jiaotong University. His main research interests include electromagnetic levitation and linear drive.