

彭涛,曹嘉旭,赵耀. 建筑平面图室内轮廓识别算法研究[J]. 智能计算机与应用,2026,16(4):203-210. DOI:10.20169/j.issn.2095-2163.25110401

建筑平面图室内轮廓识别算法研究

彭涛¹,曹嘉旭²,赵耀¹

(1 中国铁路设计集团有限公司,天津 300308;2 南开大学 计算机学院,天津 300350)

摘要:建筑平面图是承载建筑内部门、窗、房间、墙壁的标注位置信息的载体,可以反映建筑的平面布局 and 空间关系,因此自动识别平面图在实际的项目流程中起到了关键作用。平面图识别目前面临两个主要挑战,一是因为包含房间、门、窗等尺度差异显著的元素,导致多尺度目标识别困难。二是因为部分图像分辨率较低且包含噪声,使得识别难度进一步提升。为了解决上述问题,本文提出了一种带有超分辨率重建预处理的多任务卷积神经网络(CNN),通过完成语义分割与关键点检测任务来实现平面图识别,通过设计通道注意力模块与多尺度模块解决了多尺度识别问题。同时引入了具备自适应降噪模块的超分辨率重建模型,通过提升图像分辨率并抑制噪声,从而增强图像质量。在 CubiCasa5K 数据集上的实验结果表明,所提算法在准确率和交并比指标上均优于现有方法,验证了本文所提算法的有效性。

关键词:平面图识别;语义分割;卷积神经网络;超分辨率重建;注意力机制

中图分类号:TP391.41

文献标志码:A

文章编号:2095-2163(2026)04-0203-08

Research on indoor contour recognition algorithms for architectural floor plans

PENG Tao¹, CAO Jiayu², ZHAO Yao¹

(1 China Railway Design Corporation, Tianjin 300308, China;

2 College of Computer Science, Nankai University, Tianjin 300350, China)

Abstract: Architectural floor plans, as carriers of detailed information including annotations and locations of doors, windows, rooms, and walls within a building, reflect the spatial layout and relationships of the structure. As such, automatic recognition of floor plans plays a critical role in practical architectural engineering workflows. However, current floor plan recognition methods face two main challenges. First, the presence of elements with significant scale differences—such as rooms, doors, and windows—renders multi-scale object detection particularly difficult. Second, many floor plan images suffer from low resolution and contain varying degrees of noise, further increasing the complexity of the recognition task. To address these issues, this paper proposes a multi-task Convolutional Neural Network (CNN) with super-resolution reconstruction as a preprocessing step. The model performs floor plan recognition through a combination of semantic segmentation and keypoint detection tasks. A channel attention module and a multi-scale feature module are introduced to enhance the model's ability to handle objects of diverse sizes. In addition, a super-resolution reconstruction module with adaptive denoising capabilities is incorporated to enhance image quality by increasing resolution and suppressing noise. Experiments conducted on the CubiCasa5K dataset demonstrate that our method outperforms existing approaches in terms of Accuracy (Acc) and Intersection over Union (IoU), thereby validating the effectiveness of the proposed approach.

Key words: floor plan recognition; semantic segmentation; Convolutional Neural Network; super-resolution reconstruction; attention mechanism

0 引言

建筑平面图是一种从顶部视角展示建筑物结构

的可缩放图纸,是建筑信息的核心数字化载体^[1],一般由专业建筑师通过 CAD 软件绘制,这些软件输出的是矢量图形的格式,但矢量平面图在应用前需

基金项目:中国铁路设计集团有限公司科技开发课题(2024A0151201)。

作者简介:曹嘉旭(2003—),男,硕士研究生,主要研究方向:计算机视觉;赵耀(1985—),男,博士,正高级工程师,主要研究方向:铁路通信信息技术。

通信作者:彭涛(1991—),男,硕士,高级工程师,主要研究方向:铁路四电 BIM 应用,智能设计开发。Email: pengtao02@crdc.com。

收稿日期:2025-11-04

经过光栅化处理,以此来适配不同硬件设备的显示需求,在这一过程中会发生几何与语义信息的损失,原本在矢量图形中标注好的信息无法从光栅化后的二维图像中直接获取,建筑师需通过人工测量的原始方法来提取平面图中的相关信息,这不仅降低了工作效率,还可能会在测量过程中引入人为的视觉误差。

目前建筑平面图识别算法主要分为基于规则的方法和基于深度学习的方法两类。基于规则的方法主要依赖人工定义的启发式规则和几何特征来识别建筑元素,易出现识别错误,且泛化性也较弱。深度学习方法则是利用神经网络等模型去识别平面图元素,具有更高的识别准确率与更强的泛化能力。

研究早期使用的是基于规则的处理方法,Cherneff等^[2]提出通过考虑墙壁、门、窗户、房间及其空间关系,提取平面图结构。Hori等^[3]提出了基于轮廓和骨架的线拟合方法,通过将扫描图像数据转换为游程长度编码数据进行预处理,利用线拟合及特定筛选条件确定最佳拟合线,调整端点位置、计算线厚,并结合圆弧拟合完成平面图识别。Ryall等^[4]提出了基于邻近场的半自动化区域划分方法,使用定义在扫描位图上的邻近场确定区域中心并依照像素与中心的接近程度划分区域,以此描绘平面图。Tombre等^[5]首先对扫描图纸进行低层级处理,涵盖分割、矢量化、弧线检测以及显著回路检测等步骤,在此基础上运用两种高层级分析技术进行互补,结合几何结构与标准符号的分析方法识别墙壁、门窗等元素,基于空间的分析用于实现门窗和房间的识别。贾哲明等^[6]利用几何运算提取墙体候选符号的子图,然后再通过规则推理来确定墙体元素的符号。李立等^[7]依据平面图中的设备形态特征和逻辑关系设计了识别规则,结合灰度化、边缘检测等预处理进行识别。基于规则的方法原理相对简单,但泛化性较差,不同的平面图在风格、比例尺等方面存在差异,基于规则的方法难以适配这类差异,因此逐渐被深度学习方法取代。

随着人工智能技术的进步,平面图识别技术开始向深度学习方面发展。Shelhamer等^[8]提出全卷积网络(FCNs)用于语义分割,将现有分类网络进行改编,通过微调预训练权重进行端到端学习,定义了跳层架构,融合深层语义信息和浅层外观信息,显著提升了识别的精度。Zeng等^[9]设计了一种带有房间边界引导注意力机制的多任务网络来识别平面图元素,利用房间边界引导注意力机制的空间上下文

模块,挖掘元素空间关系。Xu等^[10]基于卷积神经网络并引入多尺度房间边界注意力模型,提出了FloorNet,有效提升了对简单宣传册型和复杂建筑型平面图的分割性能。Yang等^[11]提出一种双流图注意力网络(VectorFloorSeg),通过设计调制图注意力层,将另一流的边特征融入到当前流的顶点特征学习中,实现边界线分类和多边形区域分类任务的相互增强。也有研究基于U-Net^[12]语义分割网络等,结合空间和通道注意力机制捕捉特征间关联,从而提高识别精度。Huang等^[13]基于多种模型(U-Net、YOLOX等)的理念和结构改进融合,提出多任务模型MuraNet,实现了高效的平面图识别。深度学习方法可以通过大量的数据,学习到更具代表性的特征,更好地处理复杂关系,相较于基于规则的方法,深度学习方法所训练出来的模型整体准确率更高,泛化性能更好。

基于上述研究背景,本文提出了一种集成了超分辨率预处理的多任务卷积神经网络。为了解决多尺度识别的挑战,本文设计了通道注意力模块和多尺度模块。通道注意力模块通过全局池化自适应加权通道特征,以优先处理关键结构;多尺度模块则通过不同感受野捕获上下文信息,使模型能够有效识别大尺度的房间结构以及小尺度的建筑元素。此外,超分辨率预处理分支通过4层CNN估计噪声分布,并利用空间通道注意力来调整特征处理,从而提升低分辨率图像的质量。

1 本文算法

本文方法由多任务平面图识别模型和图像超分辨率重建模型组成,超分辨率重建模型作为平面图识别前的预处理步骤,将带有噪声的低分辨率图像转换为高质量图像。

1.1 网络结构

本文提出的基于多任务的平面图识别网络模型需完成语义分割与关键点检测两项任务,且两项任务均在同一模型中完成,语义分割用于识别平面图中的房间类型和门窗,关键点检测用于定位墙壁连接点、门窗端点,再借助优化处理算法精准重建平面图结构。

参考已有研究^[14],本文采用ResNet-152作为骨干网络,同时设计了通道注意力模块与多尺度模块,网络整体结构如图1所示。

本文所提网络为典型的编码器-解码器结构,解码器的层次与编码器一一对应,每个层次通过转

置卷积操作将特征图的空间维度增加一倍。为了更好地恢复图像的细节信息, 解码器采用了跳跃连接, 将对应的编码器层次的特征图与上采样后的特征图

相加融合, 充分利用编码器中不同层次提取到的空间细节信息, 从而缓解上采样过程中可能出现的信息丢失问题。

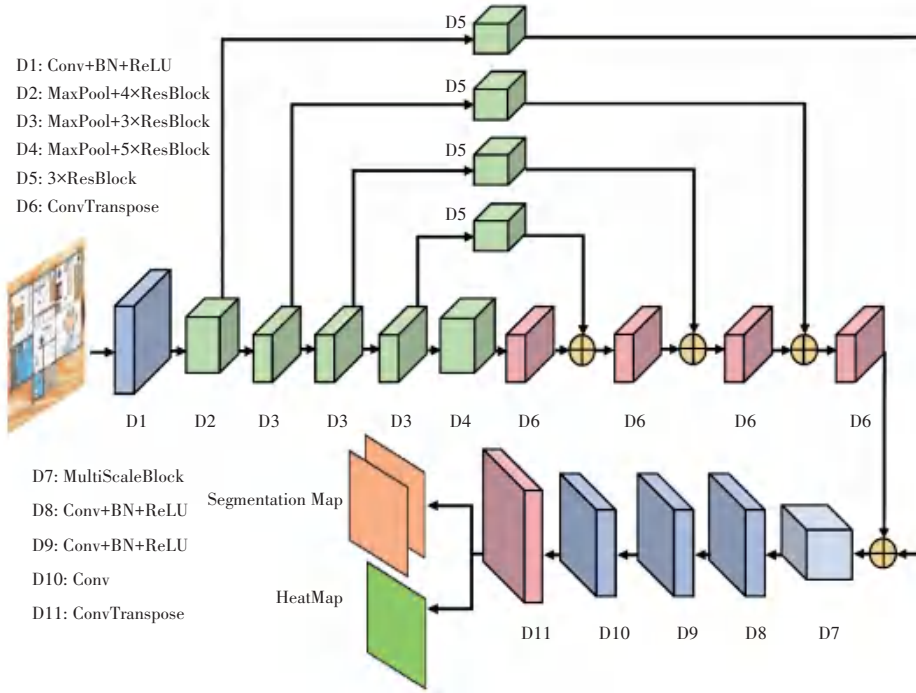


图 1 多任务平面图识别模型架构(融合了沙漏网络^[15]设计)

Fig. 1 Architecture of the multi-task floor plan recognition model (integrating the Hourglass Network^[15] design)

1.1.1 通道注意力模块

受到 SE 注意力机制^[16]的启发, 本文设计了一

种通道注意力模块, 用于自适应地调整各通道的重要性权重, 模块结构如图 2 所示。

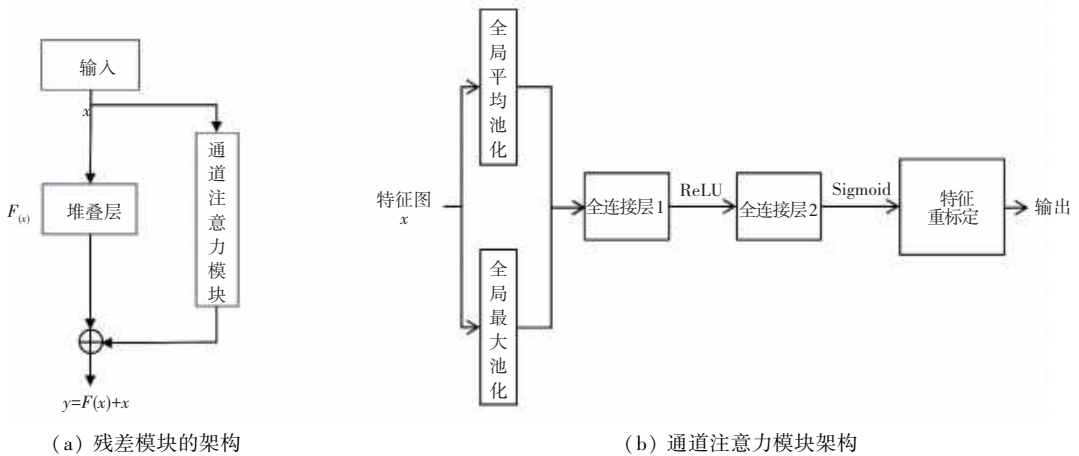


图 2 残差块和通道注意力模块的架构

Fig. 2 The architectures of the residual block and the channel attention module

模块首先通过全局平均池化和全局最大池化进行处理。全局平均池化将每个通道压缩为一个实数, 获取通道的全局统计信息, 公式如下:

$$F_{avg}(X) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W X_c(i, j) \quad (1)$$

其中, X_c 为输入特征图的第 c 个通道; H 为特征图的高度; W 为特征图的宽度。

全局最大池化则是将每个通道中的所有空间位置压缩为单个最大值, 从而捕获该通道中最活跃响应, 与全局平均池化关注整体统计信息不同, 最大

池化更关注特征图中的显著区域,公式如下:

$$F_{\max}(X) = \max_{1 \leq i \leq H, 1 \leq j \leq W} X_c(i, j) \quad (2)$$

随后将两个特征进行特征拼接,得到通道描述符 z , 公式如下:

$$z = F_{\text{cat}} = [F_{\text{avg}}, F_{\max}] \quad (3)$$

然后通过非线性变换去学习各通道的权重系数,公式如下:

$$s = F_{\text{ex}}(z) = \sigma(W_2 \delta(W_1 z)) \quad (4)$$

其中, σ 是 Sigmoid 函数; δ 是 ReLU 函数; W_1 、 W_2 为全连接层 1 和全连接层 2 的权重矩阵; s 为通过两层全连接层学习的通道权重,这个过程也叫激励过程。最后模块将学习到的权重应用到原始特征上,完成重标定操作得到输出特征 \tilde{X}_c , 公式如下:

$$\tilde{X}_c = F_{\text{scale}}(X_c, s_c) = s_c \cdot X_c \quad (5)$$

通道注意力模块通过这种方式实现了对通道维度的自适应特征学习,增强重要特征,抑制不重要特征,本文将通道注意力模块应用到残差模块中,对残差信息进行通道加权,使网络能够更有效地关注关键特征。

1.1.2 多尺度模块

多尺度模块旨在捕获不同尺度的空间信息,增强网络对不同大小目标的识别能力,通过并行的不同大小卷积核来实现多尺度特征提取,结构如图 3 所示。




图3 多尺度模块架构

Fig. 3 Architecture of the Multi-Scale Module

模块首先通过 3 种不同大小的卷积并行处理,不同大小的卷积核的感受野存在显著差别。1×1 卷积核的感受野最小,仅能聚焦于单个像素点及其周边极为局部的信息;3×3 卷积核的感受野相对大一

些,能够捕捉到更为宽泛的局部特征;5×5 卷积核的感受野最大,可获取更大范围的上下文信息。通过这 3 种卷积提取特征,来关注不同大小的目标,公式如下:

$$x_1 = \text{Conv}_{1 \times 1}(x) \quad (6)$$

$$x_2 = \text{Conv}_{3 \times 3}(x) \quad (7)$$

$$x_3 = \text{Conv}_{5 \times 5}(x) \quad (8)$$

随后将 3 种特征进行拼接,并用一个 1×1 卷积让不同尺度的特征进行交互,以此进行特征融合,公式如下:

$$x_{\text{cat}} = \text{Concat}(x_1, x_2, x_3) \quad (9)$$

$$y = \text{Conv}_{\text{fusion}}(x_{\text{cat}}) \quad (10)$$

其中,Concat 为拼接操作,Conv_{fusion} 是 1×1 卷积。

通过以上操作,模块分别捕获了图像中不同尺度的特征,融合后增加了特征的多样性与丰富性,提升了模型对不同大小目标的表达能力。

与本网络解码器上采样过程中的特征融合相比,多尺度模块关注的是同一分辨率下不同感受野的互补性,以解决目标尺度变化的问题,而上采样过程中的特征融合关注的是不同分辨率下特征间的互补性,解决了分辨率损失的问题。两次融合各自捕获了不同且互补的信息,显著提升了网络对复杂场景的理解能力。

1.2 多任务损失函数

在本文的平面图识别任务中,模型肩负着定位关键点(如墙连接点、开口端点等)与分割不同区域(如房间、图标等)两项任务。为使模型能同时处理这些任务,本文构建了一个多任务损失函数 \mathcal{L}_{all} , 公式如下:

$$\mathcal{L}_{\text{all}} = \mathcal{L}_{\text{key}} + \mathcal{L}_{\text{seg}} \quad (11)$$

其中: \mathcal{L}_{key} 为热图回归损失, \mathcal{L}_{seg} 为分割损失,将二者结合在一起,可以让模型在训练时综合考虑不同任务的需求,提升整体性能。

热图回归损失主要负责训练热图回归器,目的是精准确定墙连接点和开口端点这些重要位置,公式如下:

$$\mathcal{L}_{\text{key}} = \sum_i \left(\frac{1}{2\sigma_i} \|L_i - y_i\| + \log(1 + \sigma_i) \right) \quad (12)$$

其中, L_i 代表的是真实的位置信息,也就是实际中这些点所在的准确位置; y_i 是模型预测出来的点的位置; σ_i 是不确定性参数,这个参数会在模型训练过程中不断调整和学习。

分割损失主要用于分割任务,也就是把平面图

中的不同区域,像房间、图标(门、窗)等准确地划分出来,公式如下:

$$\mathcal{L}_{\text{seg}} = - \sum_{j \in \{\text{all}\}} \frac{1}{\sigma_j} L_j \cdot \log \text{Softmax}(Y_j) + \log \sigma_j \quad (13)$$

其中, L_j 是真实的分割标签,代表每个区域实际所属的类别, Y_j 是模型预测的分割结果。

1.3 超分辨率重建预处理

在实际场景中,本文所使用的数据可能会因为各种原因导致分辨率较低,平面图中的墙体、门窗等元素的边缘和轮廓模糊不清,为解决这一问题,本文在识别前对低分辨率平面图进行超分辨率重建处理,以此提高清晰度,方便进行更精准的识别。受到 FFDNet^[17] 的启发,本文基于 Real-ESRGAN^[18] 设计了一个自适应降噪模块,在提高图像分辨率的同时减少噪声。

生成器中的自适应去噪模块首先通过噪声估计器生成一个噪声图,噪声估计器由 4 层卷积网络结

构组成,用于分析输入图像,输出一个范围在 $[0, 1]$ 之间的单通道噪声分布图,表示每个像素位置的噪声强度。

在得到噪声图 $N(x)$ 后,自适应降噪模块通过 3 个关键组件来处理特征,结构如图 4 所示。首先通过空间注意力机制将单通道噪声图转换为多通道的空间注意力图,根据噪声图来确定每个空间位置需要的处理强度,得到空间注意力权重 $SA(N)$,公式如下:

$$SA(N) = f_2(\text{LeakyReLU}(f_1(N))) \quad (14)$$

其中, f_1, f_2 是卷积层,随后将空间注意力图进行特征调制,用空间注意力权重加 1 后与原始特征相乘,根据噪声分布来动态调整特征强度,让网络对不同区域的特征进行自适应的增强或抑制处理,公式如下:

$$FM(x, N) = f_4(\text{LeakyReLU}(f_3(x \cdot (1 + SA(N))))) \quad (15)$$

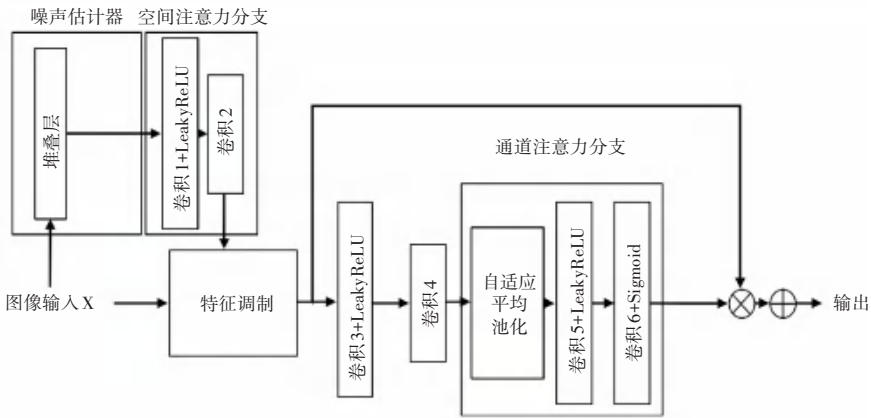


图 4 自适应降噪模块架构

Fig. 4 Architectural structure of adaptive denoising module

最后利用通道注意力机制自动学习和调整不同特征通道的重要性,并结合残差连接保留原始信息,将结果输出,公式如下:

$$CA(F) = \sigma(f_6(\text{LeakyReLU}(f_5(\text{AvgPool}(F))))) \quad (16)$$

其中, AvgPool 是平均池化; σ 是 Sigmoid 激活函数; $CA(F)$ 是通道注意力机制处理后得到的权重。

$AD(x, N)$ 是输出结果,公式如下:

$$AD(x, N) = x + FM(x, N) \cdot CA(FM(x, N)) \quad (17)$$

这种多层次的自适应设计使得网络能够根据不同区域的噪声程度进行差异化处理,既能有效去除

噪声,又能很好地保留图像的细节信息。

2 实验

2.1 数据集与评估指标

目前常见的数据集有 R2V^[19]、R3D^[20]、CubiCasa5K^[14]。与 R2V 和 R3D 数据集相比, CubiCasa5K 数据集规模更大,是之前最大数据集的 5 倍多,标注更为精确,元素类别更加丰富多样,因此本文选择 CubiCasa5K 作为实验数据集。

本文采用了 5 种评价指标去全面衡量模型在平面图识别任务中的表现情况,分别是准确率、总体正确率、平均准确率以及交并比和平均交并比。

在评价指标的计算中,本文会用到预测值和实

际值之间的关系,也就是表1所示的混淆矩阵,其中TP为真正例,表示预测结果中被正确识别的区域,且在真实标签中也属于相对应的类别;FP是假正例,表示模型预测一区域为某一类别,但在真实标签中该区域不是这一类别,即错误地将一些不属于某一类别的区域识别为该类别;FN是假负例,表示真实标签中存在某个类别区域,但模型没有将其识别出来;TN是真负例,表示被模型正确识别为非房间及门窗的区域。

表1 预测值和实际值的混淆矩阵

Table 1 Confusion matrix of predicted values and actual values

预测值	实际值	
	正	负
正	TP	FN
负	FP	TN

本文采用准确率(Accuracy, Acc)来衡量模型正确分类的像素比例,准确率的计算公式如下:

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{FP} + \text{FN} + \text{TN}} \quad (18)$$

准确率直观地展示了模型识别特定元素的准确性,总体准确率(Overall Accuracy, OA)和准确率的计算方式一样,计算范围是针对对象中的所有类别样本。

同时本文还选择使用平均准确率来反映模型在所有类别上的平均分类性能,因为不同类别之间识别难度的不同,只看总体准确率可能会掩盖模型在某些类别上的表现差异,平均准确率的计算公式为:

表2 各个方法在Cubicasa5K数据集上的结果

Table 2 Results of various methods on the Cubicasa5K dataset

数据集	方法	房间			门		窗	
		oAcc	mAcc	mIoU	Acc	IoU	Acc	IoU
验证集	UNet	77.2	64.7	54.6	54.2	49.6	64.4	59.4
	DFPR	74.8	60.3	49.6				
	本文方法	82.4	68.5	57.4	59.9	54.1	74.1	64.6
测试集	UNet	74.1	61.2	52.9	53.1	47.2	61.6	56.5
	DFPR	71.6	58.6	47.7				
	本文方法	81.1	66.6	54.8	56.7	51.4	70.2	62.2

根据分析结果可得, U-Net方法在处理平面图识别任务时具有一定的分割能力,但对于具有复杂布局和微小元素的平面图识别任务而言效果欠佳,在测试集上,其门和窗的指标均落后本文方法,说明U-Net虽然能有效捕捉图像中的部分特征,但由于网络结构的局限性,在面对复杂的建筑平面图时,难以精准定位细小元素,导致识别精度受限。DFPR方法基于VGG模型实现,但在实验中的表现相对较

$$\text{meanAccuracy} = \frac{1}{n} \sum_{i=1}^n \text{Acc}_i \quad (19)$$

其中, n 表示类别数量, Acc_i 表示类别 i 的正确分类像素比例,通过平均准确率可以知道模型对房间和门窗的整体分类效果,有助于发现模型在房间和门窗分类效果上的差异,从而有针对性地优化模型。

交并比(IoU)是语义分割任务中评估模型性能的关键指标,用于衡量模型预测的目标区域和真实的目标区域这两个集合的重叠程度,公式如下:

$$\text{IoU} = \frac{\text{TP}}{\text{TP} + \text{FP} + \text{FN}} \quad (20)$$

IoU越接近1,说明预测区域与真实区域的重叠度越高,模型对该目标的分割效果越好;反之如果IoU越接近0,则表示两者重叠度越低,分割效果越差。

平均交并比(mIoU)是所有类别交并比的平均值,反映对所有类别的分割性能,公式如下:

$$\text{mIoU} = \frac{1}{n} \sum_{i=1}^n \text{IoU}_i \quad (21)$$

其中, n 表示类别数量,先分别计算每个类别预测区域和真实区域的IoU值,再求平均得到mIoU。

2.2 对比实验

本文针对不同方法在Cubicasa5K数据集上的表现进行了比较,分别用到了U-Net^[21]、DFPR方法^[9]和本文采用的方法。实验结果见表2。

弱,说明难以适应Cubicasa5K数据集中复杂的空间关系。

与之相比,本文采用的方法展现出了显著的优势。通过引入通道注意力模块和多尺度模块,本文方法能够更好地聚焦关键特征,捕捉不同尺度的信息,从而有效提高识别精度。本文方法在验证集和测试集的各项指标上均处于前列,能够更准确地识别平面图中的各类元素,为室内建筑房屋轮廓识别

提供了更可靠的解决方案。

2.3 消融实验

为验证通道注意力模块、多尺度模块对模型性能的影响,开展消融实验。以未添加这些模块的网络为基础模型,构建多个对比模型,分别单独添加各模块或进行组合,记录测试集指标变化。通过对比各模型结果,分析各模块单独及组合作用时对模型性能的贡献,进而验证本文改进方法的有效性和必要性。

实验结果见表3,其中设置一为原始的模型,设置二为引入了通道注意力模块的模型,设置三为引入了多尺度模块的模型,设置四是引入了超分辨率重建预处理的模型,设置五是引入了通道注意力模块和多尺度模块的模型,设置六、设置七、设置八分

别在设置二、设置三和设置五的基础上引入了超分辨率重建预处理。根据实验结果分析可得,仅添加通道注意力模块后,房间类别的指标有明显的提高,说明通道注意力模块能有效增强模型对关键特征的关注,提升了识别性能;仅添加多尺度模块后,门和窗的结果指标有一定的提高,说明该模块有助于捕捉不同尺度信息,以此提升对不同大小目标的识别能力。设置五将二者融合后则进一步增强了模型的性能,融入超分辨率重建预处理后则使模型指标得到了额外提升。本实验结果充分验证了通道注意力模块、多尺度模块、超分辨率重建预处理共同作用时,能一定程度上提升模型性能,体现了本文改进方法的有效性。

表3 在 Cubicasa5K 数据集上进行的消融实验

Table 3 Results of ablation experiments on the Cubicasa5K dataset

方法	房间			门		窗	
	oAcc	mAcc	mIoU	Acc	IoU	Acc	IoU
设置一	68.1	43.9	33.4	34.7	31.3	44.7	39.6
设置二	78.4	62.0	50.0	53.1	48.5	61.8	56.4
设置三	78.1	60.8	49.5	54.4	49.1	59.9	55.1
设置四	67.9	43.7	33.2	34.9	31.5	45.4	40.2
设置五	81.0	66.4	54.6	56.3	51.0	69.9	61.9
设置六	78.5	62.2	50.2	53.4	48.8	62.3	56.8
设置七	78.2	61.1	49.7	54.7	49.3	60.3	55.4
设置八	81.1	66.6	54.8	56.7	51.4	70.2	62.2

3 结束语

本文提出一种融合超分辨率预处理的多任务卷积神经网络,用于建筑平面图识别。通过引入通道注意力模块与多尺度模块,网络能有效提取不同尺度的特征;超分辨率模块则通过提升分辨率与降低噪声,在识别前进一步改善图像质量。

未来的工作中,本文计划扩展模型的应用场景,在识别后的结果基础上基于房间面积对房屋中的家具进行智能布置,例如照明设备、通讯设备等,根据每个房间的面积不同,分配不一样的数量和位置,以此达到全覆盖的效果。

参考文献

[1] PIZARRO P N, HITSCHFELD N, SIPIRAN I, et al. Automatic floor plan analysis and recognition[J]. Automation in Construction, 2022, 140: 104348.
 [2] CHERNEFF J, LOGCHER R, CONNOR J, et al. Knowledge-based interpretation of architectural drawings[J]. Research in

Engineering Design, 1992, 3: 195-210.

[3] HORI O, TANIGAWA S. Raster-to-vector conversion by line fitting based on contours and skeletons[C]//Proceedings of 2nd International Conference on Document Analysis and Recognition (ICDAR). Piscataway, NJ: IEEE, 1993: 353-358.
 [4] RYALL K, SHIEBER S, MARKS J, et al. Semi-automatic delineation of regions in floor plans[C]//Proceedings of the 3rd International Conference on Document Analysis and Recognition. Piscataway, NJ: IEEE, 1995: 964-969.
 [5] TOMBRE K, AH-SOON C. Variations on the analysis of architectural drawings[C]//Proceedings of the 4th International Conference on Document Analysis and Recognition. Piscataway, NJ: IEEE, 1997: 347-351.
 [6] 贾哲明,付永刚,戴国忠.建筑平面图理解中对墙体符号的识别方法[J].计算机工程与应用,2004(10):201-204.
 [7] 李立,杜文文,李鹏,等.基于OpenCV的车站信号平面图图像识别[J].铁路计算机应用,2024,33(7):7-13.
 [8] SHELHAMER E, LONG J, DARRELL T. Fully convolutional networks for semantic segmentation[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2015: 3431-3440.
 [9] ZENG Z, LI X, YU Y K, et al. Deep floor plan recognition using a multi-task network with room-boundary-guided attention[C]//

- Proceedings of the IEEE/CVF International Conference on Computer Vision. Piscataway, NJ: IEEE, 2019: 9096–9104.
- [10] XU Z, YANG C, ALHEEJAWI S, et al. Automatic floor plan analysis using a boundary attention – based deep network [J]. International Journal on Document Analysis and Recognition (IJ DAR), 2025(1): 28.
- [11] YANG B, JIANG H, PAN H, et al. Vectorfloorseg: Two–stream graph attention network for vectorized roughcast floorplan segmentation[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2023: 1358–1367.
- [12] UPADHYAY A, DUBEY A, KURIAKOSE S M. FPNNet: Deep attention network for automated floor plan analysis [C]// Proceedings of the International Conference on Document Analysis and Recognition. Cham: Springer, 2023: 163–176.
- [13] HUANG L, WU J H, WEI C, et al. MuraNet: Multi–task floor plan recognition with relation attention[C]//Proceedings of the International Conference on Document Analysis and Recognition. Cham: Springer, 2023: 135–150.
- [14] KALERVO A, YLIOINAS J, HÄIKIÖ M, et al. Cubicasa5k: A dataset and an improved multi – task model for floorplan image analysis[C]//Proceedings of the 21st Scandinavian Conference on Image Analysis(SCIA) . Cham: Springer , 2019: 28–40.
- [15] NEWELL A, YANG K, DENG J. Stacked hourglass networks for human pose estimation[C]//Proceedings of European Conference on Computer Vision. Cham: Springer, 2016: 483–499.
- [16] HU J, SHEN L, SUN G. Squeeze – and – excitation networks [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2018: 7132–7141.
- [17] ZHANG K, ZUO W, ZHANG L. FFDNet: Toward a fast and flexible solution for CNN – based image denoising [J]. IEEE Transactions on Image Processing, 2018, 27(9): 4608–4622.
- [18] WANG X, XIE L, DONG C, et al. Real–esrgan: Training real–world blind super – resolution with pure synthetic data [C]// Proceedings of the IEEE/CVF International Conference on Computer Vision. Piscataway, NJ: IEEE, 2021: 1905–1914.
- [19] LIU C, WU J, KOHLI P, et al. Raster – to – vector: Revisiting floorplan transformation[C]//Proceedings of the IEEE International Conference on Computer Vision. Piscataway, NJ: IEEE, 2017: 2195–2203.
- [20] LIU C, SCHWING A G, KUNDU K, et al. Rent3D: Floor–plan priors for monocular layout estimation [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2015: 3413–3421.
- [21] RONNEBERGER O, FISCHER P, BROX T. U–net: Convolutional networks for biomedical image segmentation [C]//Proceedings of the Medical Image Computing and Computer–Assisted Intervention (MICCAI) . Cham: Springer, 2015: 234–241.