

DOI:10.19651/j.cnki.emt.2211110

基于注意力机制的FPGA布线拥塞预测*

聂廷远 徐坤鹏 孔琪

(青岛理工大学信息与控制工程学院 青岛 266520)

摘要: 随着FPGA设计复杂性的不断增加,物理设计需要大量的优化迭代才能实现,布线拥塞影响芯片的面积及时延等性能指标,因此需要准确快速的预测并提前解决。提出一个FPGA布线拥塞预测模型CBAM-CGAN,模型在布局阶段提取特征合成学习图像,引入注意力机制学习增强图像各个特征通道的重要程度,提高布线拥塞的预测性能。实验结果表明,方法在布局阶段的布线拥塞预测取得了较好效果。相比于条件对抗生成网络模型,结构相似度平均值提高了0.89%,峰值信噪比平均值提高了1.37%,归一化均方根像素差平均值降低了3.8%,像素精度差平均值降低了0.06%,单张图像的预测时间约为0.1s。实验数据证明了模型在FPGA布线拥塞的准确性和快速性。

关键词: 布线拥塞;条件生成对抗网络;注意力机制;现场可编程门阵列;机器学习

中图分类号: TP391 **文献标识码:** A **国家标准学科分类代码:** 510

Attention mechanism based routing congestion prediction for FPGA

Nie Tingyuan Xu Kunpeng Kong Qi

(School of Information & Control Engineering, Qingdao University of Technology, Qingdao 266520, China)

Abstract: With the increasing complexity of FPGA design, physical design requires a large number of optimization iterations to achieve. Cabling congestion affects chip area, delay and other performance indicators, so accurate and rapid prediction and early resolution are required. A FPGA routing congestion prediction model CBAM-CGAN is proposed. The model extracts feature in the layout phase to synthesize learning images, and introduces attention mechanism learning to enhance the importance of each feature channel of the image, so as to improve the routing congestion prediction performance. The experimental results show that the method achieves good results in routing congestion prediction in the layout phase. Compared with the conditional countermeasure generation network model, the average value of structure similarity is increased by 0.89%, the average value of peak signal to noise ratio is increased by 1.37%, the average value of normalized root mean square pixel difference is decreased by 3.8%, the average value of pixel accuracy difference is decreased by 0.06%, and the prediction time of a single image is about 0.1 seconds. Experimental data prove the accuracy and rapidity of the model in FPGA routing congestion.

Keywords: routing congestion;CGAN;attention mechanism;FPGA;machine learning

0 引言

随着集成电路设计技术与工艺的不断发展,物理设计的复杂性显著增加。物理设计是电子设计自动化(electronic design automation,EDA)流程中的关键阶段^[1],设计收敛需要布局和布线的不断迭代优化,花费大量的人工与时间成本。物理设计前端的预测有助于提前预知物理设计后端棘手的布线困难和串扰等问题,减少物理设计运行时间,提高设计效率^[2-3]。

近年来,机器学习在许多场景的应用使其成为研究热点。机器学习方法在分类、检测和空间探索等方面取得

令人瞩目的成就。机器学习方法在解决EDA领域常见的非确定性多项式(non-deterministic polynomial,NP)完全问题也显示出巨大潜力,而传统方法解决这些问题需要耗费大量的时间和资源^[4]。机器学习在解决集成电路物理设计中的布线拥塞问题取得了重要成就。Zhou等^[5]采用多元自适应回归训练模型进行建模,并基于布局 and 全局布线两个阶段的特征预测详细布线的设计规则检查(design rule checking,DRC)违例。Al-hyari等^[6]则将拥塞图映射为红绿蓝(red-green-blue,RGB)图像,运用卷积神经网络进行建模处理,Xie等^[7]使用基于图的深度学习对布线拥塞进行预测,Maarouf等^[8]

收稿日期:2022-08-18

* 基金项目:国家自然科学基金面上项目(61572269)、山东省自然科学基金(ZR2021MF101)项目资助

提出了线性回归机器学习框架来仿真和预测布线拥塞。

生成对抗网络(generative adversarial network, GAN)是机器学习领域的热点之一^[9],主要用来解决生成图像问题^[10],例如图像修复^[11]和图像超分辨率^[12]等,生成器 G (Generator)和鉴别器 D (Discriminator)的对抗学习最后达到纳什均衡^[13]。由于原始 GAN 模型存在梯度消失和难以训练等问题,因此在 GAN 的基础上增加约束条件,条件生成对抗网络(conditional generative adversarial networks, CGAN)从此诞生^[14]。CGAN 在图像处理领域上取得卓越成果,在集成电路中也被广泛应用^[15-16],CGAN 的图像到图像翻译功能有效解决了布线拥塞预测的可视化问题。Yu 等^[17]基于布局阶段提取的特征,将布局图与表示现场可编程门阵列(field programmable gate array, FPGA)设计连通性的连线图进行堆叠作为输入,使用 CGAN 建立图像转换任务预测布线拥塞,该工作将已使用的可编程逻辑块(configurable logic blocks, CLB)进行着色表示,但未考虑 CLB 中引脚的使用情况。由于引脚密度较高的区域,在布线时更容易出现拥塞问题,因此它可以洞察布线拥塞情况;Alawieh 等^[18]采用高清图像翻译功能的 CGAN,使用布局阶段精心提取的设计特征,能够为大规模的 FPGA 设计提供精确预测并进行性能优化。随着物理设计的复杂性的提升,提取设计特征的信息量逐渐增多,会存在设计连接信息保持不足,深度卷积网络模型卷积过程中存在细节信息丢失等问题。

注意力机制在计算机视觉领域与自然语言处理等领域有着巨大突破,将注意力引入生成对抗网络,提高生成图像质量。例如图像增强^[19],它模仿人类的视觉注意力,抑制无效信息,突出重要的信息特征。

针对现有方法所存在的缺陷,本文提出基于注意力机制的 FPGA 布线拥塞预测方法,该方法利用 CGAN 模型进行预测布线拥塞图,使用跳跃连接减少信息细节的丢失。预测问题被转换为图像翻译问题,提取布局设计的布局图、网表连接关系和块内引脚利用率等信息形成训练输入图像,在 CGAN 框架的基础上引入通道注意力机制与空间注意力机制,突出重要的特征通道,使生成图像的细节更加丰富,提高生成图像质量,能够实现快速准确的 FPGA 布线拥塞预测。

1 基础知识

1.1 GAN 与 CGAN

生成对抗网络是一种用于无监督机器学习任务的神经网络模型。包含两个多层感知器,即生成器 G 与鉴别器 D。生成器将随机噪声 z 映射变换,目标是生成鉴别器 D 无法区分真假的输入映射,鉴别器来区分生成样本与真实样本。网络分为两部分进行训练,损失函数如等式(1)所示。

$$L_{(G,D)} = \min_G \max_D [E_x \log D(x) + E_z \log(1 - D(G(z)))] \quad (1)$$

训练鉴别器 D 最大化为真实样本与生成样本分配正

确标签的概率,训练生成器 G 最小化 $\log(1 - D(G(z)))$ 。条件生成对抗网络加入了附加条件,用来约束生成的样本随机性。与 GAN 相比的主要区别是目标函数中概率为条件概率。损失函数如式(2)所示。

$$cL_{(G,D)} = \min_G \max_D [E_{x,y} \log D(x | y) + E_z \log(1 - D(G(z | y)))] \quad (2)$$

训练鉴别器 D 最大化为真实样本与生成样本分配正确标签的概率,训练生成器 G 最小化 $\log(1 - D(G(z | y)))$ 。其中 y 为附加条件,CGAN 将附加条件 y 作为生成器 G 与鉴别器 D 输入的一部分。

在无条件生成对抗网络中,数据在无任何约束条件下生成。条件生成对抗网络通过加入附加条件设置,模型直接约束数据的生成,这已被证明在图像翻译和图像修复任务中至关重要^[20]。

1.2 注意力机制

深度学习中的注意力机制从本质上说与人类的视觉注意力机制类似,目标是从多个信息中寻找与当前任务相关联的关键信息并抑制不必要的信息。注意力机制有通道注意力、像素注意力、空间注意力和自注意力等。本文将注意力模块 CBAM(convolutional block attention module)融入 CGAN 网络提高布线拥塞预测的准确率^[21],CBAM 由通道注意力模块和空间注意力模块两部分组成,如图 1 所示,输入特征 $F_i F_s$ 经过通道注意力模块与空间注意力模块计算后得到输出特征 $F_i' F_s'$ 。

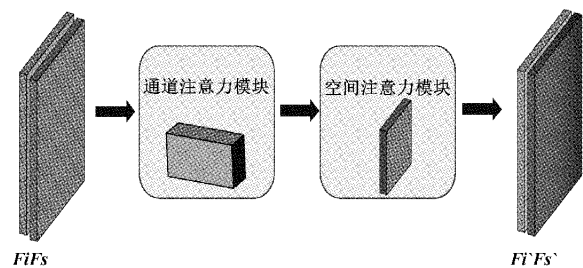


图 1 CBAM 注意力机制模块

1) 通道注意力模块

利用特征的通道间关系生成通道注意力图 $M_c(F) \in R^{C \times 1 \times 1}$,对特征图每个通道进行特征权重计算,通道注意力集中在输入图像的“什么”是有意义的,通过压缩输入特征图的空间维数,提高计算通道注意的效率。同时使用平均池化和最大池化,来推断更详细的通道级注意力。计算公式如式(3)所示,首先使用平均池化和最大池化聚合空间信息 F_{avg}^c 和 F_{max}^c 分别表示平均池化特征和最大池化特征,它们通过共享网络(multi-layer perceptron, MLP)来产生通道注意力映射,最后通过逐元素求和来合并输出特征向量。

$$M_c(F) = \sigma(MLP(AvgPool(F)) + MLP(MaxPool(F))) = \sigma(W_1(W_0(F_{avg}^c)) + W_1(W_0(F_{max}^c))) \quad (3)$$

2) 空间注意力模块

利用特征间的空间关系生成空间注意力图 $M_s(F) \in$

$R^{H \times W}$, 空间注意力主要关注输入图像中基于通道的方向寻找聚集信息最丰富的某一位置。计算公式如式(4)所示, 通过使用两个池化操作聚合一个特征图的通道信息, F_{avg}^s 和 F_{max}^s 分别表示跨通道的平均池化特征和最大池化特征, 通过卷积层将信息连接起来, 产生空间注意力图。最后利用 sigmoid 函数得到最终注意力图。

$$M_s(F) = \sigma(f^{7 \times 7}([AvgPool(F); MaxPool(F)])) = \sigma(f^{7 \times 7}([F_{avg}^s; F_{max}^s])) \quad (4)$$

2 布线拥塞预测机器学习框架

本方法将布线拥塞预测转换为图像翻译工作, 在布局阶段提取的特征映射到图像中, 使用 CGAN 模型进行机器学习, 在模型中融入 CBAM 注意力机制模块以突出生成图像的相关特征。本章介绍机器学习模型结构以及绘制图像配色设置。

2.1 CBAM-CGAN 机器学习模型

本文提出基于注意力机制的 FPGA 布线拥塞预测模型 CBAM-CGAN (convolutional block attention mechanism-conditional generative adversarial networks), 模型引入注意力机制学习增强图像各个特征通道的重要程度, 训练网络架构如图 2 所示。输入图像经过融入 CBAM 的生成器生成假图, 鉴别器检测生成器的输出为真假。生成器选用 U-net256^[22], 在网络的中间层加入 CBAM 注意力模块。生成器结构如图 3 所示。生成器中的跳跃连接对于图像输入到输出的很重要^[23], 输入图像的信息通过所有层, 对图像的细节生成有着很大的帮助。鉴别器为马尔可夫判别器, 包括五层卷积层, 为加快网络的训练和收敛的速度, 控制梯度爆炸防止梯度消失加入批量归一化层, 最后跟有用用于二分类的 sigmoid 函数, 判别器结构如图 4 所示。

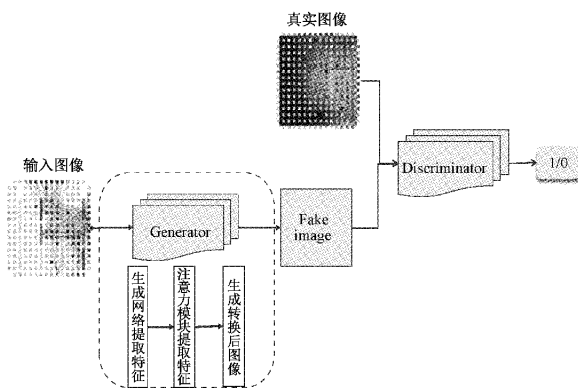


图 2 CBAM-CGAN 机器学习框架

2.2 颜色设置

Yu 等^[17]已经证明了使用 RGB 图像可以获得比灰度图像更高的精度, 本文处理 RGB 图像的颜色设置如表 1 所示, 不同模块使用不同颜色表示, 块内引脚利用率和布线通道利用率使用渐变色表示, 颜色越亮表示利用率越高, 其中 I/O 表示为输入输出。



图 3 融入 CBAM 的生成器结构

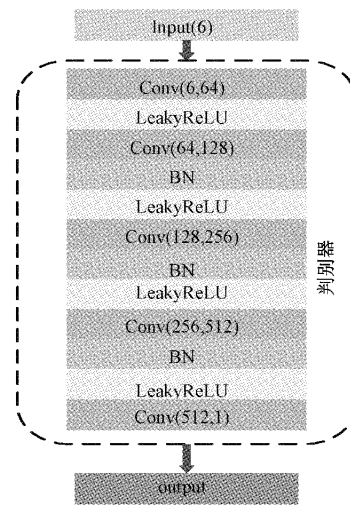


图 4 判别器结构

表 1 绘制图像配色方案

颜色	名称
白色	布线通道
亮蓝色	CLB
粉色	乘数器
亮黄色	存储器
黑色	已使用的 CLB 和 I/O
黄色到紫色	块内引脚利用率/布线通道利用率

3 实 验

基于注意力机制的 FPGA 布线拥塞预测主要分为以下 3 个步骤: 1) 在布局阶段提取特征, 制作并划分成对的预测布线拥塞数据集。2) 将数据集放入到改进的 CBAM-CGAN 模型中进行训练。3) 与 CGAN 模型进行对比实验, 验证并分析改进 CBAM-CGAN 模型对预测布线拥塞的有效性。

3.1 实验环境与参数设置

数据集的图像是基于 VTR8.0 生成^[24], 输入图像首先

生成矢量图形,转换并过滤为 256×256 大小的位图。机器学习模型的超参数设定如下:初始学习率设置为 0.000 2, batchsize 为 1, epoch 为 200, 采用 Adam 优化器, 设置生成器的 $\beta_1=0.5$, 鉴别器的 $\beta_2=0.999$ 。实验软硬件环境配置具体情况如表 2 所示。

表 2 实验软硬件环境配置情况表

实验环境	配置版本
操作系统	Ubuntu18.04
CPU	Inter(R) Xeon(R) Silver 4214R
框架	Pytorch1.8
GPU	NVIDIA GeForce RTX 3090
Cuda	11.5
开发工具	Pycharm 2020.2
内存	128 G

3.2 FPGA 基准电路

实验所使用的基准测试电路来自于多伦多大学的 VTR8.0, 电路涵盖图像处理、计算等多个功能, 每个测试用例都是一个完整的电路系统。每一个基准电路设计生成 200 个随机的布局方案, 共获得约 1 600 对图像作为数据集, 基准电路具体信息如表 3 所示。其中, #P(#Placements)表示输入和输出图像对的数量, #LUTs 表示查找表的数量, #FF 表示触发器的数量, #Nets 表示线网的数量。

3.3 数据集生成

数据集所采用的 8 个基准测试电路均由 VTR8.0 软件处获得, 通过更改 VTR8.0 的参数设置生成不同的布局, 为防止机器学习中的过拟合现象, 我们选择影响布线拥塞较高的参数进行设置, 在布局阶段选择三种特征组合生成堆叠图作为输入, VTR8.0 工具布线后生成的拥塞图作为标签, 二者合并生成一条训练数据。配色根据表 1 设置来

表 3 VTR 基准电路详细信息与图像对数量

测试用例	#LUTs	#FF	#Nets	#P
diffeq1	563	193	2 059	210
diffeq2	419	96	1 560	210
SHA	2 501	911	10 910	207
ode	5 448	1 316	20 981	209
spree	796	201	1 187	210
dscg	9 088	1 618	36 912	208
OR1200	2 823	670	12 336	209
raygentop	1 920	1 047	5 023	210

生成, 如图 5(a) 所示。FPGA 布局以网表的形式描述, 每一个可编程逻辑块可以包含一个或者多个基本逻辑元件, 布局为每个逻辑块分配特定的二维物理位置, 示例如图 5(b) 所示。我们把逻辑块用黑色填充表示, 直线表示它们之间的连接关系, 生成网表连接关系图, 如图 5(c) 所示。逻辑块内使用的引脚数目越多, 意味着该逻辑块周围布线越多, 会影响周围区域的布线拥塞情况。将每个块内的引脚利用率转换为热图作为输入特征。对于块内引脚利用率, 每种类型模块的输入引脚数和输出引脚数, 统计到总输入引脚数量与总输出引脚数量中, 其中时钟引脚视为输入。对于每个模块的引脚利用率计算为该模块使用的引脚与其类型使用的总数之比, 使用 colormap 函数将其映射为热图, 如图 5(d) 所示。将前面生成的布局图、网表连接关系图和块内引脚利用率热图 3 种图像堆叠生成输入图像, 如图 5(e) 所示。最后通过 VTR8.0 布线后获取布线拥塞图作为真实图像(标签), 如图 5(f) 所示。网络训练使用成对的图像, 即图 5(e) 和 (f) 作为一条训练数据。数据集获取流程如图 6 所示, 通过扫描 VTR8.0 的布局选项生成布局结果, 选项包括 Seed、Alpha_T 和 Inner_num, 布线后得到真实拥塞图, 所有图像均由 VTR8.0 所获取。




图 5 布线拥塞预测输入输出图像

3.4 评估指标

本文利用图像翻译实现布线拥塞预测, 因此利用图像处理方面的指标来评估学习的性能。本文共使用四项图像指标, 归一化均方根误差和像素精度用于评估预测的准确性, 结构相似性来评估布线拥塞预测任务相关的图像相似性度量, 峰值信噪比^[25]用来评估生成图像的质量。

1) 归一化均方根像素差(NRMS)

定义为图像 Y 与图像 \bar{Y} 之间的归一化均方根像素差,

公式表达为:

$$NRMS = \frac{\sqrt{\sum_{j=1}^H \sum_{j=1}^W (Y_{i,j} - \bar{Y}_{i,j})^2}}{(Y_{\max} - Y_{\min}) \cdot (H \times W)} \quad (5)$$

2) 结构相似性(SSIM)

结构相似性, 是评价两幅图像相似性的一个重要指标。该指标从图像构成的角度出发, 捕捉图像之间结构信息的变化。取值范围为 $[-1, 1]$, 值越大表示图像之间的相似度就越高, 公式表达为:

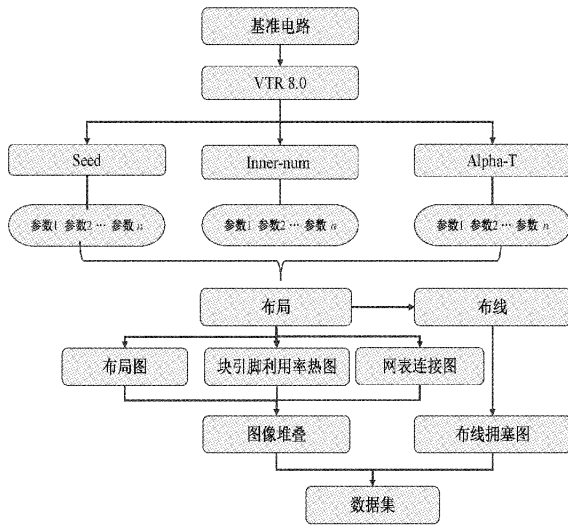


图6 数据集获取流程

$$SSIM(I_a, I_b) = \frac{(2\mu_{I_a}\mu_{I_b} + c_1)(2\sigma_{I_a, I_b} + c_2)}{(\mu_{I_a}^2 + \mu_{I_b}^2 + c_1)(\sigma_{I_a}^2 + \sigma_{I_b}^2 + c_2)} \quad (6)$$

其中, μ_{I_a}, μ_{I_b} , 分别表示生成图像 I_a 和 I_b 的均值, $\sigma_{I_a}, \sigma_{I_b}$, 分别表示图像 I_a 和 I_b 的标准差。 c_1, c_2 是为了避免分母为 0 而引入的常数。

3) 像素精度差 (PIX)

像素精度差定义为图像 Y 与图像 \bar{Y} 之间的归一化像素级差异, 公式表达为:

$$PIX = \frac{\sum_{i=1}^H \sum_{j=1}^W |Y_{i,j} - \bar{Y}_{i,j}|}{255 \cdot (H \times W)} \quad (7)$$

4) 峰值信噪比 (PSNR)

提供了一个衡量图像失真或是噪声水平的客观标准,

常用于图像压缩等领域压缩前后图像劣化程度的客观评价。PSNR 越高, 表示图像的质量越高, 公式表达为:

$$PSNR(I_a, I_b) = 10 \lg \left(\frac{\max_i I_a^2}{mse} \right) \quad (8)$$

$$mse(I_a, I_b) = \frac{1}{n} \sum_{i=1}^n (I_b[i] - I_a[i])^2, \max_{I_a} = 255 \quad (9)$$

3.5 实验结果分析

对得到的训练数据集随机进行划分, 其中 80% 的数据用于训练, 20% 的数据用于测试。机器学习训练时间平均为 3~4 h, 每张图像的预测时间平均约为 0.1 s。在图 7 展示了 8 个基准电路在不同方法下的布线拥塞预测效果图与真实图像的比较。如图 7 所示, 从图中可以看出, 与真实布线拥塞图像相比, CGAN 与 CBAM-CGAN 均具有不错的预测效果, 布线拥塞区域 (红色部分) 均得到了很好的体现, 但在某些拥塞区域预测的细节上 CBAM-CGAN 有着更好的性能。表 4 中给出了详细的 CBAM-CGAN 模型与 CGAN 模型的图像评估指标对比, 对视觉观察进行了数值验证。CBAM-CGAN 模型在 SSIM 值、PSNR 值、NRMS 值和 PIX 值等指标上均优于 CGAN 模型。SSIM 平均值达到了 86.97%, 相比于 CGAN 提高了 0.89%, PSNR 平均值为 23.530 2 dB, 提高了 1.37%, NRMS 平均值为 10.40%, 下降了 3.80%, PIX 平均值为 41.57%, 下降了 0.06%, 以上评估指标相对于 CGAN 模型均有提高, 表明了融入注意力机制模块的 CBAM-CGAN 模型在预测布线拥塞具有良好的性能。可以观察到随着电路设计复杂度的增加, CBAM-CGAN 模型对于大型电路比小型电路设计的评估指标提高的更多。原因可能是小型电路设计经布局和布线优化后可以得到接近的最优解。

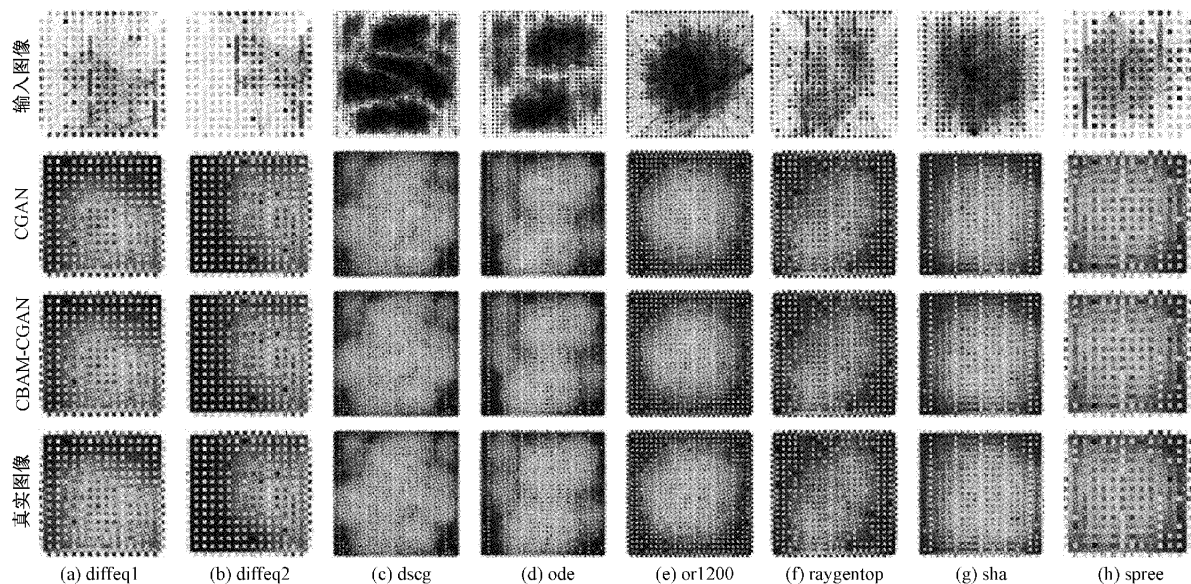


图7 预测结果比较

表 4 CBAM-CGAN 与 CGAN 的布线拥塞预测比较

基准电路	SSIM/%			PSNR/dB			NRMS/%			PIX/%		
	CGAN	CBAM- CGAN	变化率/ %	CGAN	CBAM- CGAN	变化率/ %	CGAN	CBAM- CGAN	变化率/ %	CGAN	CBAM- CGAN	变化率/ %
diffeq1	88.83	89.25	0.48	23.635 0	23.938 7	1.28	10.13	9.75	-3.76	40.42	39.75	-1.66
diffeq2	87.30	88.08	0.90	22.648 9	23.050 4	1.77	11.84	11.13	-6.04	39.91	39.34	-1.43
SHA	82.00	83.39	1.70	22.074 4	22.494 2	1.90	12.18	11.60	-4.76	41.50	42.01	1.22
ode	84.27	84.81	0.63	23.520 7	23.727 5	0.88	10.39	10.17	-2.14	42.68	43.27	1.39
spreed	87.00	87.87	1.00	23.646 8	24.040 8	1.67	9.92	9.47	-4.47	37.59	38.17	1.52
dscg	84.11	85.37	1.49	23.298 6	23.680 1	1.64	10.38	9.96	-4.08	42.48	42.87	0.93
OR1200	89.21	89.42	0.24	24.214 0	24.283 7	0.29	9.80	9.77	-0.29	44.28	43.60	-1.53
raygentop	86.86	87.56	0.81	22.655 8	23.026 3	1.64	11.88	11.39	-4.14	43.87	43.54	-0.76
平均值	86.20	86.97	0.89	23.211 8	23.530 2	1.37	10.82	10.40	-3.80	41.59	41.57	-0.06

4 结 论

本文结合注意力机制与条件对抗生成网络,提出了一种新的布线拥塞预测模型 CBAM-CGAN。模型将问题描述为图像翻译任务,使用在布局阶段提取的特征如电路布局、设计连通性和引脚利用率等合成学习图像作为输入,并注入注意力机制提高模型的代表能力。实验结果表明,方法在布局阶段的布线拥塞预测取得了较好效果。预测布线拥塞图像的平均结构相似度、峰值信噪比、归一化像素差和像素精度等指标相对于 CGAN 模型均有提高,平均结构相似度达到了 86.97%,相比于 CGAN 提高了 0.89%,平均峰值信噪比为 23.530 2 dB,提高了 1.37%,平均归一化像素差为 10.40%,下降了 3.80%,平均像素精度差为 41.57%,下降了 0.06%。预测图像相对于 CGAN 模型也更接近真实的布线拥塞图像。未来,提出的模型在预测准确性上需进一步提高,并整合到 EDA 设计流程中以提高 FPGA 物理设计的效率。

参考文献

- [1] YU B, XU X, ROY S, et al. Design for manufacturability and reliability in extreme-scaling VLSI[J]. Science China Information Sciences, 2016, 59(6): 1-23.
- [2] YU C, HUANG C C, NAM G J, et al. End-to-end industrial study of retiming[C]. 2018 IEEE Computer Society Annual Symposium on VLSI(ISVLSI), IEEE, 2018: 203-208.
- [3] 王佳伟,黄志洪,高同强,等. 一种高精度的 FPGA 电路面积时序预测方法[J]. 国外电子测量技术, 2017, 36(6): 31-35, DOI: 10.19652/j. cnki. femt. 2017. 06. 006.
- [4] HUANG G, HU J, HE Y, et al. Machine learning for electronic design automation: A survey[J]. ACM Transactions on Design Automation of Electronic

Systems(TODAES), 2021, 26(5): 1-46.

- [5] ZHOU Q, WANG X, QI Z, et al. An accurate detailed routing routability prediction model in placement[C]. 2015 6th Asia Symposium on Quality Electronic Design(ASQED), IEEE, 2015: 119-122.
- [6] AL-HYARI A, SZENTIMREY H, SHAMLI A, et al. A deep learning framework to predict routability for fpga circuit placement[J]. ACM Transactions on Reconfigurable Technology and Systems (TRETS), 2021, 14(3): 1-28.
- [7] XIE Z, HUANG Y H, FANG G Q, et al. RouteNet: Routability prediction for mixed-size designs using convolutional neural network [C]. 2018 IEEE/ACM International Conference on Computer-Aided Design (ICCAD), IEEE, 2018: 1-8, DOI: 10.1145/3240765.3240843.
- [8] MAAROUF D, ALHYARI A, ABUOWAIMER Z, et al. Machine-learning based congestion estimation for modern FPGAs [C]. 2018 28th International Conference on Field Programmable Logic and Applications(FPL), IEEE, 2018: 427-4277.
- [9] GOODFELLOW I, POUGET A J, MIRZA M, et al. Generative adversarial networks[J]. Communications of the ACM, 2020, 63(11): 139-144.
- [10] 陈亮,吴攀,刘韵婷,等. 生成对抗网络 GAN 的发展与最新应用[J]. 电子测量与仪器学报, 2020, 32(6): 70-78.
- [11] 宋文净,金恒宏. 基于生成对抗网络的面部遮挡还原算法研究[J]. 电子测量技术, 2020, 43(23): 109-114.
- [12] 王延年,李文婷,任劼. 基于生成对抗网络的单帧图像超分辨算法[J]. 国外电子测量技术, 2020, 39(1): 26-32.
- [13] RATLIFF L J, BURDEN S A, SASSTRY S S. Characterization and computation of local Nash equilibria in continuous games[C]. 2013 51st Annual

- Allerton Conference on Communication, Control, and Computing (Allerton), IEEE, 2013: 917-924.
- [14] MIRZA M, OSINDERO S. Conditional generative adversarial nets [J]. ArXiv Preprint, 2014, ArXiv: 1411.1784.
- [15] ALAWIEH M B, LIN Y, ZHANG Z, et al. GAN-SRAF: Sub-resolution assist feature generation using conditional generative adversarial networks [C]. Proceedings of the 56th Annual Design Automation Conference, 2019, 2019: 1-6.
- [16] YANG H, LI S, DENG Z, et al. GAN-OPC: Mask optimization with lithography-guided generative adversarial nets [J]. IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems, 2019, 39(10): 2822-2834.
- [17] YU C, ZHANG Z. Painting on placement: Forecasting routing congestion using conditional generative adversarial nets [C]. Proceedings of the 56th Annual Design Automation Conference, 2019, 2019: 1-6.
- [18] ALAWIEH M B, LI W, LIN Y, et al. High-definition routing congestion prediction for large-scale FPGAs [C]. 2020 25th Asia and South Pacific Design Automation Conference (ASP-DAC), IEEE, 2020: 26-31.
- [19] 蒲燕虹, 张金艺, 姜玉稀. 双重注意力引导的弱监督雨滴图像增强 [J]. 电子测量技术, 2022, 45(4): 79-84.
- [20] ZHU J Y, PARK T, ISOLA P, et al. Unpaired image-to-image translation using cycle-consistent adversarial networks [C]. Proceedings of the IEEE International Conference on Computer Visio, 2017: 2223-2232.
- [21] WOO S, PARK J, LEE J Y, et al. Cbam: Convolutional block attention module [C]. Proceedings of the European Conference on Computer Vision (ECCV), 2018: 3-19.
- [22] 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.
- [23] ISOLA P, ZHU J Y, ZHOU T, et al. Image-to-image translation with conditional adversarial networks [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 1125-1134.
- [24] MURRAY K E, PETELIN O, ZHONG S, et al. Vtr 8: High-performance cad and customizable fpga architecture modelling [J]. ACM Transactions on Reconfigurable Technology and Systems (TRETS), 2020, 13(2): 1-55.
- [25] TANCHENKO A. Visual-PSNR measure of image quality [J]. Journal of Visual Communication and Image Representation, 2014, 25(5): 874-878.

作者简介

聂廷远, 博士, 教授, 主要研究方向为 VLSI 设计优化、IP 保护技术、复杂网络机器学习。

徐坤鹏, 硕士研究生, 主要研究方向为 VLSI 设计优化、复杂网络机器学习。

E-mail: 15263046561@163.com

孔琪, 硕士研究生, 主要研究方向为 VLSI 设计优化、复杂网络机器学习。