

DOI:10.19651/j.cnki.emt.2518861

基于选择性状态空间模型改进的图像隐写方法*

杜尤伟¹ 曹毅²

(1.南京信息工程大学计算机学院、网络空间安全学院 南京 210044;2.无锡学院物联网工程学院 无锡 214105)

摘要: 针对现有基于 CNN 的生成式隐写术存在生成图像质量差、抗隐写分析能力弱的问题,本文提出一种基于选择性状态空间模型的改进 U-Net 隐写架构——SSEU-Net,旨在实现高质量图像生成与高安全性隐写。方法核心包括:首先,设计了 Res-SS2D 模块,对输入图像进行四方向的全局空间建模,在保证线性计算复杂度的同时提升含密图像的视觉质量;其次,基于图像高频区域的微小扰动对整体统计特征影响更小的特性,提出高频特征强化策略,通过提取载体图像的边缘并融合至编码器,引导秘密图像优先嵌入高频区域,从而降低被隐写分析方法检测出的可能性;最后,设计多目标损失函数,结合 PSNR 与 MS-SSIM 优化生成质量,同时通过引入低频分量的 L1 范数损失,约束载体图像与含密图像的低频区域一致性,迫使秘密信息优先隐藏于高频分量。实验表明,SSEU-Net 在 COCO 与 ImageNet 数据集上均优于现有方法;在 ImageNet 上,生成的含密图像 PSNR 平均达 40.588 dB,恢复出的秘密图像的 PSNR 平均达 41.863 dB,且对常见的隐写分析方法表现出较高的抵抗能力。

关键词: 生成式隐写术;U-Net;状态空间模型;高频特征嵌入

中图分类号: TP309.7;TN40 **文献标识码:** A **国家标准学科分类代码:** 520.2040

Improved image steganography method based on selective state space model

Du Youwei¹ Cao Yi²

(1. School of Computer Science, School of Cyber Science and Engineering, Nanjing University of Information Science and Technology, Nanjing 210044, China;2. School of Internet of Things Engineering, Wuxi University, Wuxi 214105, China)

Abstract: To address the limitations of existing CNN-based generative steganography in poor image quality and weak resistance to steganalysis, this paper proposes SSEU-Net, an improved U-Net-based steganographic architecture incorporating selective state space model, aiming to achieve high-quality image generation and secure steganography. The core contributions include: first, designing Res-SS2D module that performs quad-directional global spatial modeling on input images while maintaining linear computational complexity, thereby enhancing the visual quality of stego images; next, proposing a high-frequency feature enhancement strategy based on the observation that subtle perturbations in high-frequency regions minimally affect statistical characteristics. This strategy extracts and integrates edge features of carrier images into the encoder to guide secret information embedding into high-frequency regions, thereby reducing detectability by steganalysis; finally developing a multi-objective loss function combining PSNR and MS-SSIM for generation quality optimization, alongside introducing an L1 norm loss on low-frequency components to enforce consistency between cover and stego images in low-frequency regions, ensuring secret information is predominantly embedded in high-frequency components. Experiments demonstrate that SSEU-Net outperforms existing methods on COCO and ImageNet datasets. On ImageNet, the generated stego images achieve an average PSNR of 40.588 dB, with extracted secret images attain an average PSNR of 41.863 dB, while exhibiting strong resistance to common steganalysis.

Keywords: generative steganography;U-Net;state space model;high-frequency feature embedding

0 引言

在信息安全领域中,隐写术是一种能够将秘密信息嵌

入到无感知载体(如图像^[1-3]、音频^[4]、视频^[5]等)中的技术。与传统密码学仅通过加密信息内容来保护数据不同,隐写术的独特之处在于它不仅隐藏了信息本身,还掩盖了信息

收稿日期:2025-05-19

* 基金项目:“太湖之光”科技攻关(基础研究)项目(K20241046)、2023年度高校哲学社会科学研究一般项目(2023SJB0919)、国家传感网工程技术研究中心开放课题基金(2024YJZXKFKT02)、无锡学院引进人才科研启动专项经费(2022r043)项目资助

被加密的事实,从而提升了秘密信息在通信过程中的安全性。

传统的图像隐写技术主要致力于寻找图像中修改后失真较小的区域,以实现信息的隐秘嵌入。其中,最经典的方法是最低有效位(least significant bit, LSB)技术,通过修改图像像素的最低有效位来隐藏信息,但是这种方法无法针对不同的图像给出个性化的嵌入方案,导致图像像素的统计特性异常,从而被隐写分析器检测出来。随后,研究者们引入了失真函数^[6]的概念,从而更精确地控制修改带来的失真,优化隐写效果。随着深度学习技术的兴起,一些研究者开始利用神经网络自动生成失真函数^[7],进一步提升了隐写的性能和隐蔽性。

近年来,得益于深度学习和卷积神经网络(convolutional neural networks, CNN)的快速发展,图像隐写技术取得了显著进步,不仅隐藏方法变得更加高效,抗检测能力也得到了提升,使其在现代信息安全领域中展现出更大的应用潜力。Zhu 等^[8]构建的 HiDDeN 模型开创了该领域的新范式,其基于编码器-解码器-判别器的架构不仅实现了高效的信息隐藏,还为后续研究奠定了坚实的基础。Zhang 等^[9]进一步揭示了深度隐写成功的关键,指出其归因于载体图像与秘密图像之间的频率差异,并提出了一种通用的深度隐藏框架。该框架通过隐藏网络对秘密图像进行编码,从而生成含密图像,这为隐写术提供了新的思路。

在此基础上,Subramanian 等^[10]提出了一种基于深度卷积自编码器的端到端图像隐写术方法。该方法通过特征提取而非直接操作原始图像来隐藏秘密图像,并设计了自定义损失函数以优化模型性能,显著提升了隐写的鲁棒性和隐蔽性。Zhang 等^[11]则通过结合注意力频率提取和渐进深度提取的方法,逐步提取并融合秘密图像与载体图像的必要信息,从而进一步提升了隐写质量。

随着研究的深入,Guan 等^[12]提出了一种基于可逆神经网络的多图像隐藏框架 DeepMIH。该框架将图像隐藏和恢复建模为网络的正向和反向过程,成功实现了将多个秘密图像隐藏到单个载体图像中的任务,为多目标隐写提供了创新解决方案。Duan 等^[13]提出了一种基于改进 Inception 模块和注意力机制的双层 U-Net 模型。该方法通过将秘密图像的子带特征隐藏到载体图像中,结合 Haar 小波变换,实现了高质量的隐写图像生成和秘密图像恢复,同时显著提高了隐写图像的抗分析能力。

然而,基于一般 CNN 方法的隐写网络无法对图像进行全局建模,这主要源于 CNN 依赖局部卷积操作的特性,虽然在捕捉局部特征方面表现出色,但其感受野受限,难以有效捕捉图像中的长距离依赖关系和整体结构信息,导致隐写网络在生成含密图像时,无法充分学习图像的全局统计特性,使得生成的图像的视觉质量和抗隐写分析能力受限。

近年来,视觉 Transformer (vision transformer, ViT)^[14]

通过自注意力机制突破了传统卷积神经网络在全局特征建模上的局限性,在图像处理任务中得到广泛应用。如 Zhou 等^[15]提出了一种基于通道注意力 Transformer 的图像隐写方法,通过构建长距离依赖关系来识别隐藏数据的不显眼位置,有效提高了隐写图像的质量和安全性。然而,ViT 架构的自注意力机制存在二次时间复杂度问题,尤其在处理长序列输入(如高分辨率图像)时,其计算效率显著下降。为提高模型的性能与效率,状态空间模型因其线性复杂度特性逐渐成为 Transformer 的潜在替代方案,受到研究界广泛关注。

为解决目前研究存在的问题,本文的主要贡献包括:

1) 针对传统 CNN 无法对图像进行全局建模,以及 ViT 虽然引入了全局自注意力机制但是时间复杂度较高的问题,本文设计了 Res-SS2D 模块。该模块利用了选择性状态空间模型,因而具有线性时间复杂度。同时,通过四向交叉扫描设计,实现了图像的全局建模。

2) 为将秘密图像有效嵌入载体图像的高频区域,本文提出了一种边缘特征融合方法。该方法提取载体图像的高频信息并融合至隐藏网络的各层,提高了生成的含密图像的质量以及抗隐写分析能力。

3) 结合上述提出 Res-SS2D 模块以及边缘特征融合方法,本文对 U-Net 进行改进,提出了全新的 SSEU-Net 作为编码器网络。

4) 为进一步提高含密图像质量和抗隐写分析能力,本文设计了新的损失函数,将 PSNR 以及 MS-SSIM 加以融合,并对载体图像和含密图像引入了低频小波损失。此设计旨在更好地配合边缘特征融合方法,使其更有效地将秘密图像嵌入载体图像的高频区域。

5) 在 COCO 数据集以及 ImageNet 数据集上的实验表明,本文所提出的隐写模型,不仅能够生成具有较高的视觉质量的含密图像和恢复图像,还具有较高的抗隐写分析性能。

1 相关工作

状态空间模型(state space model, SSM)为生成式隐写术提供了新的研究方向。状态空间模型源于卡尔曼滤波器,是一种描述线性时不变(linear time invariant, LTI)系统的数学框架,核心思想是将动态系统中的输入信号通过隐藏状态映射为输出信号,在连续时间域中可表示为:

$$\mathbf{h}'(t) = \mathbf{A}\mathbf{h}(t) + \mathbf{B}x(t) \quad (1)$$

$$y(t) = \mathbf{C}\mathbf{h}(t) + \mathbf{D}x(t) \quad (2)$$

式(1)称为“状态方程”,式(2)称为“输出方程”。其中,输入信号 $x(t) \in \mathbb{R}$, 隐藏状态 $\mathbf{h}(t) \in \mathbb{R}^N$, 输出信号 $y(t) \in \mathbb{R}$ 。张量 $\mathbf{A} \in \mathbb{R}^{N \times N}$ 、 $\mathbf{B} \in \mathbb{R}^{N \times 1}$ 、 $\mathbf{C} \in \mathbb{R}^{1 \times N}$ 、 $\mathbf{D} \in \mathbb{R}^1$ 为可学习的参数。整个系统随时间 t 不断演化,能够捕捉输入信号的动态特征。然而连续时间模型无法直接应用于深度学习,需要通过离散化实现数值计算。离散化能够将连续微

分方程转化为差分方程,零阶保持(zero-order hold, ZOH)技术就是一种常用的离散化技术,其假设输入信号在采样间隔 Δt 内保持恒定,则可通过以下公式来近似:

$$\mathbf{A}_d = e^{\mathbf{A}\Delta t} \quad (3)$$

$$\mathbf{B}_d = (\mathbf{e}^{\mathbf{A}\Delta t} - \mathbf{I})\mathbf{A}^{-1}\mathbf{B} \quad (4)$$

离散化后,状态方程变为:

$$\mathbf{h}_{k+1} = \mathbf{A}_d\mathbf{h}_k + \mathbf{B}_d\mathbf{x}_{k+1} \quad (5)$$

其中, \mathbf{A}_d 、 \mathbf{B}_d 为张量 \mathbf{A} 、 \mathbf{B} 离散化后的结果, \mathbf{I} 为单位矩阵, k 为离散时间步的索引,表示第 k 个采样时刻。

传统的SSM在处理长序列数据时仍然面临与循环神经网络相似的挑战:隐藏状态 \mathbf{h}_t 的维度固定,难以有效捕获长期依赖关系。同时随着输入序列的长度增加,梯度反向传播时易消失,导致学习远距离关联存在困难。高阶多项式投影算子(high-order polynomial projection operator, HiPPO)^[16-17]的提出解决了这一问题。其核心思想是通过高维多项式投影,将历史输入信号的动态信息压缩到低维状态空间中,从而显式建模长程依赖。具体来说,HiPPO将历史输入信号 $x(t)$ 投影到一组正交多项式基函数上,通过在训练过程中动态调整基函数的系数,使得隐藏状态 \mathbf{h}_t 能够以最优方式逼近历史信号。结合上述技术,序列的结构化状态空间(structured state space for sequences)模型(又称为S4模型)^[18]被正式提出。

LTI系统规定,SSM中的参数 \mathbf{A} 、 \mathbf{B} 、 \mathbf{C} 、 \mathbf{D} 不会随着输入的不同而改变,即模型一旦训练完毕,参数值就完全固定,在推理过程中无法改变,这导致S4模型对不同的输入实现针对性推理的能力不足。选择性状态空间(selective state space)模型(又称为S6模型)^[19]的提出解决了这一问题,该模型使参数 \mathbf{B} 、 \mathbf{C} 以及时间步长 Δt 动态依赖于输入 $x(t)$ 。具体来说,S6模型设计了3个多层感知神经网络 f_B 、 f_C 、 f_t ,来动态生成对应的参数:

$$\mathbf{B} = f_B(x_k) \quad (6)$$

$$\mathbf{C} = f_C(x_k) \quad (7)$$

$$\Delta_t = f_t(x_k) \quad (8)$$

这种设计方式,既考虑了静态参数的高效率,又考虑了动态参数在推理时的灵活性,提高了模型的综合性能。

2 基于选择性状态空间模型改进的图像隐写方法

2.1 整体框架

本文所提出的隐写框架主要由边缘提取器、编码器网络、解码器网络组成,如图1所示。

本文将载体图像记为 I_C ,秘密图像记为 I_S ,载体图像经过边缘提取器所得到的载体边缘图像记为 I_E 。将载体图像、秘密图像以及载体边缘图像一起输入到编码器中,编码器能够结合载体边缘图像的特征,将秘密图像隐藏进载体图像中,输出为含密图像,记为 I_C' 。在解码阶段,将含密图像输入至解码器,解码器能够从中恢复出原始的秘密图像(以下简称“恢复图像”),记为 I_S' 。

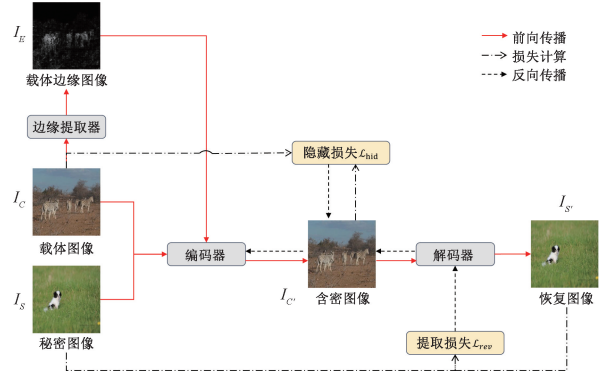


图1 本文提出方法的整体框架

Fig. 1 The overall framework of the proposed method

2.2 Res-SS2D 模块

经典的选择性状态空间模型在序列建模中表现出显著优势,但由于其存在的单向传播机制,导致了因果效应的局限性。该效应表现为特征更新时仅允许历史信息参与当前状态计算,而禁止未来时间步信息的前向反馈。在图像生成任务中,由于像素间空间关系需同时考虑多向上下文关联(如边缘连续性、纹理一致性),这种严格的时间因果性约束将割裂二维空间的全局感知,导致生成图像出现结构断裂或语义失真^[20]。

为解决上述问题,本文提出的SSEU-Net模型引入了Res-SS2D模块,这是一种专为图像生成优化的选择性状态空间计算单元。该模块的核心在于SS2D模块^[21],其通过四向特征遍历与重组机制,将传统状态空间模型扩展至二维图像域,具体流程如下:

1)交叉扫描:对输入特征图分别沿4个不同的方向进行并行遍历,生成4组具有不同空间关联性的特征序列。此操作等效于构造4个互补的伪时间轴,为后续状态空间计算提供多视角的特征输入;

2)S6模块特征提取:采用4个独立的S6模块分别处理各方向序列。每个S6模块通过动态权重选择机制,自适应融合当前扫描路径下的局部特征与跨步长全局依赖;

3)交叉合并:将4组输出序列按逆扫描路径重新映射至二维空间,最终恢复与输入同尺寸的特征图。

SS2D模块的工作流程如图2所示。在此基础上,为进一步平衡模型效率与特征表达能力,Res-SS2D模块集成了深度可分离卷积(depthwise separable convolution, DWConv)^[22],首先对输入特征图进行逐通道的卷积,接着用若干个 1×1 的卷积核进行通道间的特征提取。DWConv将标准卷积分解为空间滤波与通道映射的级联操作,在保持等效感受野的同时,大幅减少了计算复杂度。最后,Res-SS2D模块还引入了残差连接,这样不仅有效避免了梯度消失问题,还能够增强全局特征融合。Res-SS2D模块的结构如图3所示。

2.3 边缘提取方法

传统像素域隐写方法因直接修改空间域像素值,易引

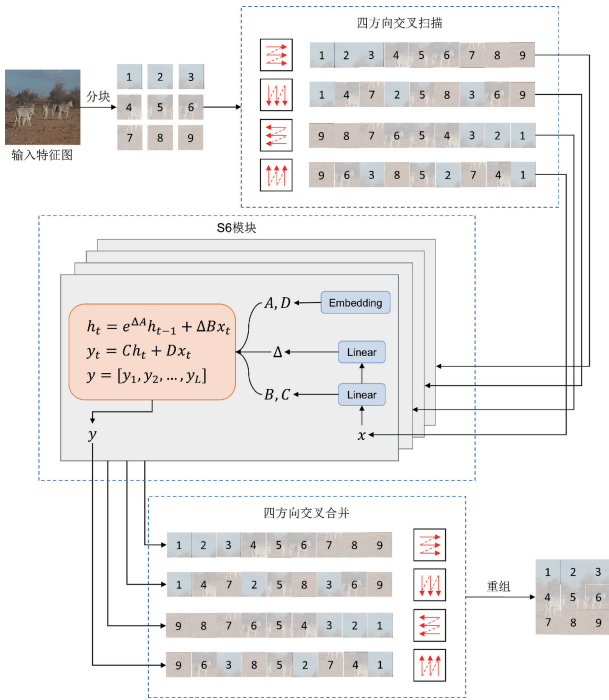


图 2 SS2D 模块工作流程
Fig. 2 Workflow of the SS2D module




图 3 Res-SS2D 模块结构
Fig. 3 Architecture of the Res-SS2D module

发纹理复制伪影与色度失真^[23]。相较于像素域嵌入,研究领域普遍认为高频敏感区域在信息隐藏中具备更优的安全性优势。这是因为图像高频分量本质对应边缘或纹理等局部剧烈变化的区域,其统计分布具有高方差、低相关性和类噪声特性^[24]。主流的隐写分析器往往通过检测统计特征的异常来识别秘密信息的存在,即使是基于深度学习的隐写分析器,其卷积核在训练过程中仍会优先学习低频特征的差异,这是因为高频分量在自然图像中具有低信噪比特性和空间非一致性,使得 CNN 难以稳定判别其特征,从而

难以察觉其中的异常。基于此,SSEU-Net 提出边缘引导的隐写方法,通过引入拉普拉斯边缘提取算子强化编码器对高频特征的感知能力。具体而言,采用 4 邻域拉普拉斯算子对载体图像进行卷积运算,该算子通过二阶微分计算像素点与邻域的灰度突变强度,其数学本质等价于求解图像二维函数的曲率变化,可以表示为:

$$Laplacian(C) = \frac{\partial^2 C}{\partial x^2} + \frac{\partial^2 C}{\partial y^2} \quad (9)$$

其中, x 和 y 分别表示图像坐标系中的水平方向和垂直方向, $C(x, y)$ 表示二维图像 C 在空间坐标 (x, y) 处的像素强度值。此外,还存在一种 8 邻域的拉普拉斯算子可用于图像边缘提取。与 4 邻域算子仅能提取图像上下左右四个方向的边缘信息有所不同,8 邻域算子能够进一步提取四个对角方向的边缘信息。然而,经实验研究表明,两种算子在最终模型性能方面造成的差距很小,且 4 邻域算子在计算速度上更具优势。鉴于此,本文选择 4 邻域拉普拉斯算子来进行边缘提取工作。

最后,将提取出的边缘图与原始图像融合后输入编码器,迫使神经网络优先学习高频区域特征,以将秘密信息优先隐藏进载体图像的高频区域。4 邻域拉普拉斯算子如图 4(a)所示,边缘特征提取效果示例如图 4(b)所示。




图 4 本文使用的拉普拉斯算子与边缘特征提取效果示例
Fig. 4 Laplacian operator used in this paper and example of edge feature extraction

2.4 编码器网络

本文提出的 SSEU-Net 编码器基于 7 层 U-Net 架构改进,通过多尺度特征融合机制实现隐写特征的高效建模,其总体结构如图 5 所示。

在下采样阶段,除最后一层外,每一层的卷积块(由卷积层、归一化层与 ReLU 激活构成)后均嵌入 Res-SS2D 模块,利用其交叉扫描与状态空间建模能力增强全局上下文感知,同时通过残差连接保留局部细节。上采样阶段为平衡计算效率,采用纯卷积结构,通过跳跃连接将下采样各层输出的多尺度特征与上采样对应层级联,实现跨层级特征互补,有效抑制信息丢失。

边缘特征强化方面,首先利用 2.3 节介绍的边缘提取方法生成载体边缘图,在调整其分辨率并经过一个卷积层提取特征后,逐级以相加方式与下采样各层进行融合,迫使网络优先关注高频敏感区域。输入层将载体图像与秘密图像沿通道维度拼接,随后经五级下采样将特征图尺寸逐级压缩至原图的 1/32,通道数逐级递增至 512,该渐进式通道扩展策略能够有效提升特征表达能力。整体架构兼顾全局

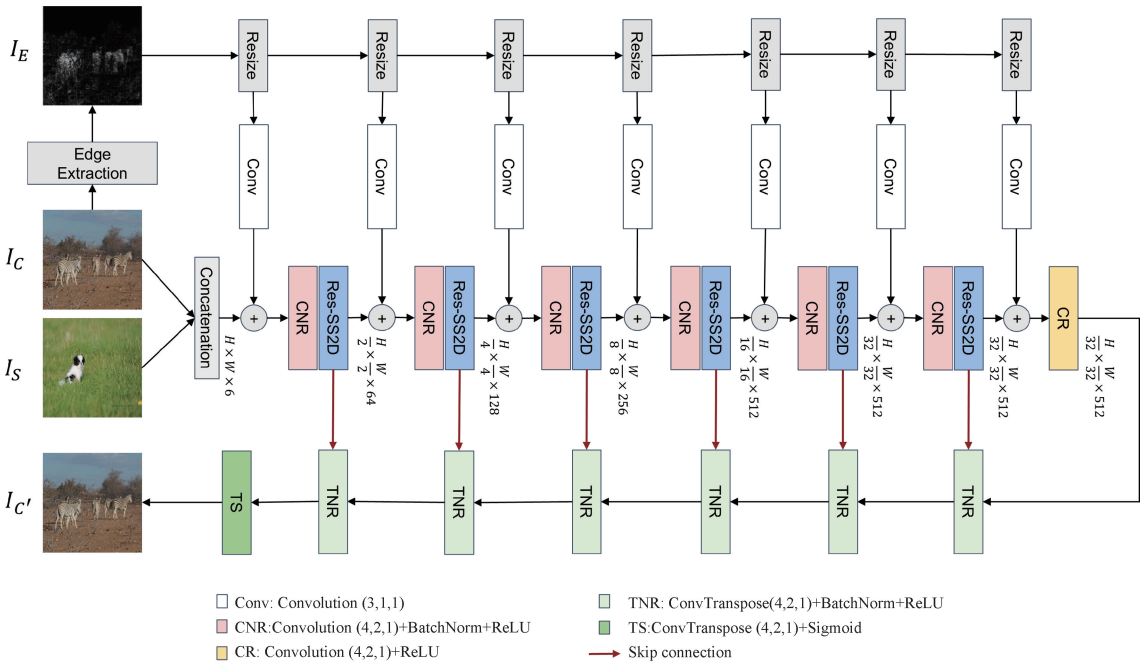


图 5 SSEU-Net 的编码器网络结构

Fig. 5 Encoder network architecture of SSEU-Net

隐写特征建模、边缘引导优化与计算效率的协同提升。

2.5 解码器网络

为兼顾模型训练与推理效率,解码器网络仅采用基本的 7 层 U-Net 结构。与编码器网络不同,解码器网络的输入仅为含密图像,因此输入通道数为 3,在下采样阶段,通道数以及特征图尺寸的变化与编码器一致,因此不赘述。解码器网络的结构如图 6 所示。

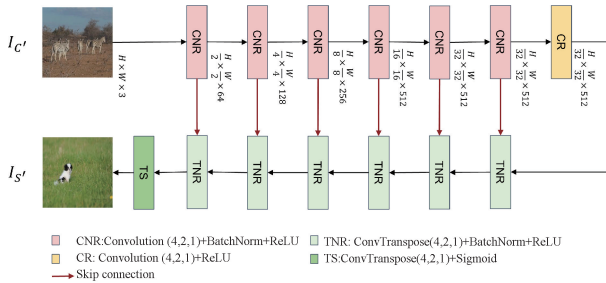


图 6 SSEU-Net 的解码器网络结构

Fig. 6 Decoder network architecture of SSEU-Net

2.6 目标损失函数

为确保生成的含密图像与恢复图像的视觉质量。本文模型所使用的损失函数使用均方误差 (mean squared error, MSE) 计算像素差异,保证生成图像具有统计意义上的高质量,同时引入多尺度结构相似性指数 (multi-scale structural similarity index measure, MS-SSIM) 以提升主观视觉质量。MSE 通过计算两幅图像对应像素差值的平方均值,实现了像素级的误差计算,其值越小表明生成图像与原图越接近,但过度依赖 MSE 易导致高频细节丢失。

MS-SSIM 则模拟人类视觉系统的多分辨率感知特性,通过在多个尺度上分别计算亮度、对比度、结构相似性,最终加权得到 0~1 之间的综合评分(越接近 1 代表视觉一致性越高,即生成质量越高)。相较于单尺度 SSIM,MS-SSIM 对纹理连续性、边缘锐度的敏感性更高,能有效抑制块效应与局部失真,使生成图像的主观视觉质量更高。二者联合使用,形成互补优化机制。隐藏损失表示为:

$$\mathcal{L}_{hid} = \frac{1}{N} \sum_{n=1}^N \left(\alpha \cdot \text{MSE}(x_{cover}^{(n)}, x_{stego}^{(n)}) + \beta \cdot (1 - \text{MSSSIM}(x_{cover}^{(n)}, x_{stego}^{(n)})) \right) \quad (10)$$

其中, N 表示一个批次下输入的载体图像与秘密图像的数量, n 表示当前正在计算第 n 对载体图像与含密图像的损失, x_{cover} 表示输入的载体图像, x_{stego} 表示由编码器生成的含密图像, α 和 β 分别表示 MSE 损失与 MS-SSIM 损失的权重。

恢复损失与隐藏损失的形式一致,表示为:

$$\mathcal{L}_{rev} = \frac{1}{N} \sum_{n=1}^N \left(\alpha \cdot \text{MSE}(x_{secret}^{(n)}, x_{reveal}^{(n)}) + \beta \cdot (1 - \text{MSSSIM}(x_{secret}^{(n)}, x_{reveal}^{(n)})) \right) \quad (11)$$

其中, x_{secret} 表示秘密图像, x_{reveal} 表示由解码器生成的恢复图像。

为更好地利用 2.3 节提出的边缘特征融合方法,本文在损失函数中引入了低频小波损失,即通过 DWT 变换将图像分解为高频和低频小波子带,由于隐藏在高频分量中的信息比隐藏在低频分量中的信息更不容易被检测到,所以本文对载体图像与含密图像的低频分量做 l_1 损失,从而迫使秘密图像尽可能隐藏在载体图像的高频分量中,而在低频分量中保留很少的秘密信息,具体表示为:

$$\mathcal{L}_{freq} = \gamma \cdot \frac{1}{N} \sum_{n=1}^N l_1(DWT(x_{cover}^{(n)})_{LL}, DWT(x_{stego}^{(n)})_{LL}) \quad (12)$$

其中, γ 表示低频小波损失的权重。具体地, 本文所使用的 DWT 变换采用 Haar 小波基进行一层分解, 并使用零填充模式处理图像边界, 这在满足低频特征提取需求的同时又保证了较高的计算效率。最后分离提取一层分解后的低频近似系数子带(即 LL 子带)作为图像的低频特征表示。

于是总训练损失可以定义为:

$$\mathcal{L}_{total} = \mathcal{L}_{hid} + \mathcal{L}_{rev} + \mathcal{L}_{freq} \quad (13)$$

上面提到的权重 α, β, γ 将作为超参数在实验设置部分说明具体的取值。

3 实验结果与分析

3.1 实验设置

本实验基于 PyTorch 2.0 框架实现, 实验平台的 CPU 为 12th Gen Intel Core i5-12600KF, GPU 为 NVIDIA GeForce RTX 4060Ti, 操作系统为 Ubuntu 24.04 LTS。数据集选取方面, 采用 ImageNet 与 COCO 两大数据集, 各自独立划分 10 000 张图像作为训练集, 2 500 张作为验证集, 并保留 500 张作为测试集以评估模型泛化能力。

在模型训练过程中, 输入图像分辨率统一调整为 256×256 , 批量大小(batch size)设置为 16, 训练周期(epoch)为 400 轮。优化器选用 Adam 算法, 其超参数设置为 $\beta_1 = 0.9, \beta_2 = 0.999$ 。学习率初始值为 0.001, 通过余弦退火算法动态调整, 按余弦函数规律衰减至训练结束时的 0.000 01。对于本文提出的多目标损失函数, 设置各部分权重分别为 $\alpha = 1.0, \beta = 0.1, \gamma = 0.1$ 。

3.2 评价标准

为评估模型所生成图像的质量, 本文选取了以下 4 种评价指标:

1) 峰值信噪比(peak signal-to-noise ratio, PSNR)是一种常见的图像质量评价标准, 用于衡量两个图像之间的相似程度。PSNR 是基于均方误差 MSE 计算的, 对于两幅尺寸相同的图像 X 和 Y :

$$MSE = \frac{1}{n} \sum_{i=1}^n (X_i - Y_i)^2 \quad (14)$$

其中, n 是图像像素总数, X_i 和 Y_i 分别表示 X 和 Y 中第 i 个像素值。于是 PSNR 值可以表示为:

$$PSNR = 10 \cdot \lg\left(\frac{MAX_I^2}{MSE}\right) \quad (15)$$

其中, MAX_I 表示输入图片能取到的最大像素值, 例如对于常见的 8 位深度的图片, $MAX_I = 255$ 。PSNR 的单位是分贝(dB), 表示信号与噪声的比例, PSNR 越高, 表示两张图片之间的差距越小。一般可以认为生成图像的 PSNR 超过 40 dB 即具有较高的视觉质量, 若低于 30 dB 则

说明视觉质量较差。

2) 结构相似性指数(structural similarity index, SSIM)也是一种衡量两幅图像相似度的指标, 它考虑了亮度、对比度和结构 3 个因素。SSIM 的设计考虑了人眼对图像质量的感知, 因此它能够更准确地反映人眼对图像变化的感知。

SSIM 的值位于 0~1 之间, 越接近 1, 表示两张图越相似; 越接近 0, 表示两张图越不相似。对于两张尺寸相同的图像 X 和 Y :

$$SSIM(X, Y) = \frac{(2\mu_X\mu_Y + c_1)(2\sigma_{XY} + c_2)}{(\mu_X^2 + \mu_Y^2 + c_1)(\sigma_X^2 + \sigma_Y^2 + c_2)} \quad (16)$$

其中, μ_X, μ_Y 分别表示图像 X 和 Y 的均值, σ_X, σ_Y 分别表示图像 X 和 Y 的标准差, σ_{XY} 表示两图像的协方差。常数 c_1 和 c_2 的引入, 是为了避免除 0 错误。

3) 平均绝对误差(mean absolute error, MAE)是一种衡量预测值与真实值之间平均差异的统计指标, 通过计算预测值与真实值之间差的绝对值的平均值, 提供了一种直观的方式来评估模型的预测性能。对于两张尺寸相同的图像 X 和 Y :

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - X_i| \quad (17)$$

其中, n 是图像像素总数, X_i 和 Y_i 分别表示 X 和 Y 中第 i 个像素值。

4) 学习感知图像块相似度(learned perceptual image patch similarity, LPIPS)是一种基于深度学习的图像相似性度量方法, 用于衡量两幅图像之间的感知差异。LPIPS 通过预训练的深度卷积神经网络(如 VGG 或 AlexNet)提取图像的高阶特征, 并计算这些特征之间的距离, 从而评估图像的感知相似度。与传统的像素级度量方法(如 PSNR、SSIM)相比, LPIPS 更能符合人类视觉感知, 能够更好地反映图像的整体结构和内容相似性。LPIPS 的值越低, 表示两张图像在感知上越相似; 反之, 值越高则表示差异越大。该指标广泛应用于图像生成、图像修复、风格迁移等领域, 能够有效评估模型生成图像的质量。本文选取 VGG 模型作为 LPIPS 的特征提取网络, 以计算图像之间的感知相似度。

3.3 主观效果分析

为对模型生成的图像进行主观质量分析, 本文从 ImageNet 和 COCO 数据集的测试集中各随机抽取了 8 组图像进行展示, 如图 7 和 8 所示。图 7 和 8 中, 第 1 行是载体图像, 第 2 行是经编码器生成的含密图像, 第 3 行是秘密图像, 第 4 行是经解码器生成的恢复图像。

可以发现, 本文模型所生成的含密图像与恢复图像, 已经很难用肉眼察觉出与载体图像和秘密图像之间存在的差距。无论是从图像的整体结构、纹理细节, 还是色彩表现来看, 生成的图像和原始图像之间都高度相似, 几乎达到了以假乱真的程度。这表明本文方法不仅能够有效处理特定类型的图像, 而且在不同风格、不同场景的图像上均能保持良好的性能, 具有较强的泛化能力, 能够广泛应用于多种图像




图 7 本文模型在 ImageNet 数据集上的效果展示

Fig. 7 Demonstration of the effect of the proposed model on ImageNet dataset




图 8 本文模型在 COCO 数据集上的效果展示

Fig. 8 Demonstration of the effect of the proposed model on COCO dataset

处理场景。

为进一步验证模型的性能,本文选取了目前基于深度学习的几种主流隐写方法与本文方法进行对比分析,包括 HiDDeN^[8]、文献[10]方法、DAH-Net^[11]以及 CAISFormer^[15]。通过对生成图像与原始图像分别进行 10 倍和 30 倍残差的方式,直观展示了不同方法生成图像的质量。具体对比的残差图像如图 9 所示,通过直观展示不同方法生成的图像差异,可以更清晰地评估本文方法在图像隐藏和恢复质量方面的优势。

在对模型生成图像的性能进行对比分析时,可以发现一些经典的隐写方法如 HiDDeN 模型,在本文任务中的表

现不佳。具体而言,其生成的含密图像与载体图像之间存在明显的颜色差异,在残差图像中,这种差异更为显著。

在图像恢复阶段,文献[10]方法、DAH-Net 与 HiDDeN 面临同样的挑战。当秘密图像与恢复图像进行 30 倍残差放大对比时,能够明显观察到载体图像的轮廓,这表明其在图像恢复的精度和完整性方面存在不足。相比之下,更为先进的方法,如 CAISFormer 以及本文方法,在视觉效果上有了显著的改进。尤其是在 30 倍残差放大的秘密图像与恢复图像之间,也无法观察到载体图像的轮廓,这表明这些方法在图像隐藏和恢复质量方面具备更高的性能。

在此基础上,本文进一步对现有方法与本文方法所生




图 9 不同隐写方法生成的残差图像对比

Fig. 9 Comparison of residual images generated by different steganographic methods

成的图像进行了直方图对比分析,结果如图 10 所示。

通过对载体图像与含密图像的直方图进行对比分析,可以明显观察到,本文方法与当下一些较为先进的方法如 DAH-Net 和 CAISFormer,在对载体图像的扰动方面表现都很出色,这有效确保了含密图像在视觉感知层面与原始载体图像的高度一致性,避免了因信息嵌入而导致的明显

图像质量退化或异常特征暴露。在进一步聚焦于秘密图像与恢复图像的直方图对比时,本文方法蕴含的优势便愈发凸显。相较于其他主流方法,本文方法在对秘密图像的扰动控制上展现出显著的优越性,这说明在整个编码与解码的过程中,本文方法能够将原始图像信息的干扰程度控制在一个极低的范围内,从而实现了最优的生成图像质量。

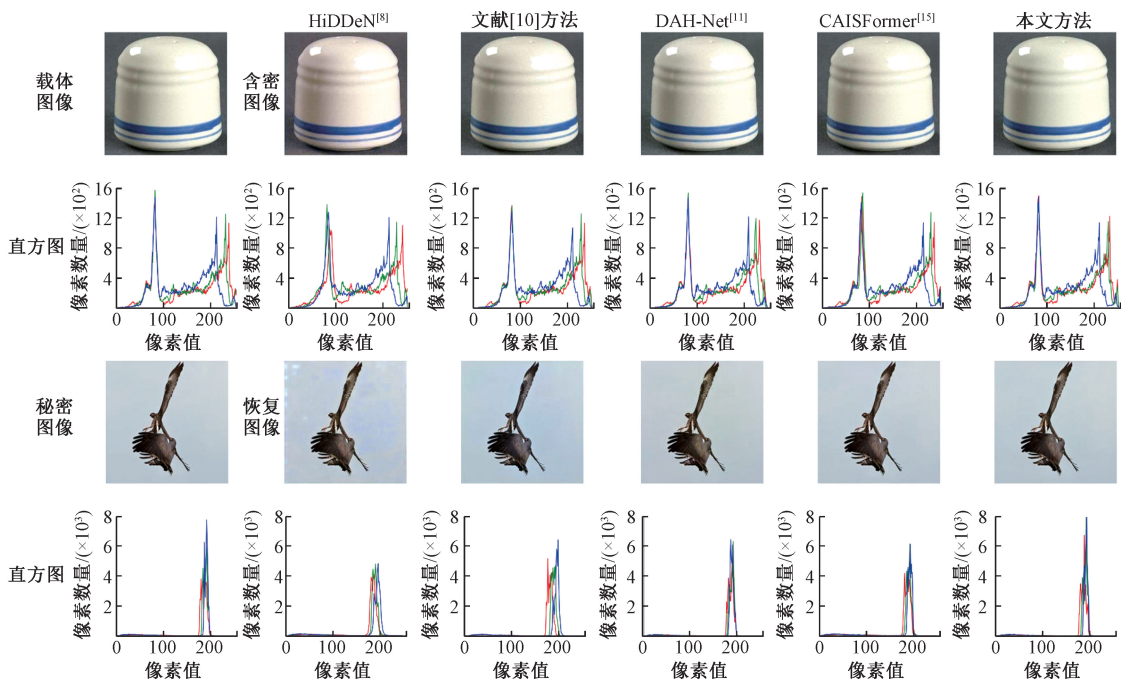


图 10 不同隐写方法生成的直方图对比

Fig. 10 Comparison of histograms generated by different steganographic methods

3.4 客观指标分析

在保证实验环境相同的情况下,本文选取了HiDDeN^[8]、文献[10]方法、DAH-Net^[11]、CAISFormer^[15]与本文方法分别在ImageNet与COCO数据集上进行对比实验,针对图像生成质量的实验结果如表1和2所示。

表1和2中加粗的数据代表当前指标下的最优值。实验数据表明,本文方法在ImageNet与COCO数据集上均展示出了卓越的图像生成质量:载体图像与含密图像的平均PSNR分别达到40.588与41.319 dB,均超过40 dB。SSIM指标稳定在0.970与0.994,同时秘密图像与恢复图像的指标也同样优秀。4项核心质量评价指标中超过87%

的对比结果为最优解,其余则为次优解。与当前性能最佳的CAISFormer相比,虽在SSIM与MAE指标上存在微小差距,但就编码阶段而言,本文方法相比CAISFormer的PSNR在ImageNet与COCO数据集上分别达到0.445与1.251 dB的显著提升。此外,针对秘密信息重建质量,本文方法对比CAISFormer在ImageNet数据集上的恢复图像PSNR提升了0.578 dB,COCO数据集上提升了0.075 dB,充分验证了本文模型的有效性。

对于抗隐写分析性能,本文选择了目前主流的3种隐写分析器进行实验,包括XuNet^[25]、YeNet^[26]、SRNet^[27],实验结果如表3所示。

表1 不同方法在ImageNet数据集上的生成图像质量对比

Table 1 Comparison of generated image quality on the ImageNet dataset among different methods

方法	载体图像/含密图像				秘密图像/恢复图像			
	PSNR ↑	SSIM ↑	MAE ↓	LPIPS ↓	PSNR ↑	SSIM ↑	MAE ↓	LPIPS ↓
HiDDeN ^[8]	35.357	0.942	0.016 2	0.122 1	34.960	0.955	0.011 2	0.136 8
文献[10]方法	34.559	0.938	0.014 0	0.022 4	35.182	0.952	0.010 5	0.018 1
DAH-Net ^[11]	38.286	0.969	0.013 3	0.020 1	37.023	0.975	0.005 6	0.017 3
CAISFormer ^[15]	40.143	0.971	0.007 5	0.044 9	41.285	0.983	0.005 1	0.028 1
本文方法	40.588	0.970	0.006 1	0.010 3	41.863	0.986	0.004 7	0.010 8

表2 不同方法在COCO数据集上的生成图像质量对比

Table 2 Comparison of generated image quality on the COCO dataset among different methods

方法	载体图像/含密图像				秘密图像/恢复图像			
	PSNR ↑	SSIM ↑	MAE ↓	LPIPS ↓	PSNR ↑	SSIM ↑	MAE ↓	LPIPS ↓
HiDDeN ^[8]	33.045	0.943	0.016 3	0.137 7	35.383	0.973	0.011 0	0.105 2
文献[10]方法	38.588	0.964	0.008 2	0.039 1	35.058	0.954	0.014 2	0.020 9
DAH-Net ^[11]	39.481	0.977	0.009 0	0.015 9	35.610	0.982	0.013 3	0.016 5
CAISFormer ^[15]	40.068	0.976	0.006 8	0.033 5	40.653	0.989	0.004 7	0.021 6
本文方法	41.319	0.994	0.005 7	0.011 0	40.728	0.989	0.005 7	0.013 1

表3 不同方法的抗隐写分析性能对比

Table 3 Comparison of anti-steganalysis performance of different methods

方法	XuNet	YeNet	SRNet
HiDDeN ^[8]	81.91	85.06	88.09
文献[10]方法	62.88	75.30	76.01
DAH-Net ^[11]	63.85	70.17	72.36
CAISFormer ^[15]	55.94	58.75	61.06
本文方法	56.21	56.08	60.37

表3中加粗的数据表示针对当前隐写分析器下的最优值。需要说明的是,当隐写分析器的检测准确率接近50%时,即意味着分析器的检测行为和随机猜测没有区别,说明生成图像已经能够很好地欺骗分析器,即具备较强的抗隐写分析性能。

实验表明,本文方法在YeNet和SRNet上的抗隐写分析性能均优于其他方法,只有在XuNet上的检测率比CAISFormer高0.27%。且总体上检测率均低于61%,说明本文方法具备较高的抗隐写分析性能。

在与基于ViT的CAISFormer方法的对比分析中,可以发现本文方法在图像生成质量与抗隐写分析性能方面与CAISFormer方法较为接近,二者均展现出良好的性能表现,能够生成高质量的图像并在一定程度上抵御隐写分析。然而,选择性状态空间模型的优势则体现在较低的时间复杂度上。推理时间复杂度是指模型进行一次前向反馈过程所消耗的时间,为了更直观地展现这一优势,本文针对主流方法进行了对比实验,实验结果如表4所示。

可以看出,本文方法虽然在图像生成质量优于经典的HiDDeN模型,但是就推理时间而言更慢一些。在和基于ViT的CAISFormer相比时,基于选择性状态空间模型的

本文方法就展现出优势,在保持图像生成质量和抗隐写分析能力方面,本文方法不仅略优于 CAISFormer,更为重要的是,本文方法在推理速度上比 CAISFormer 提升了约 100 ms,这一显著的提升充分展现了选择性状态空间模型在实际应用中的效率优势。

表 4 不同方法的推理时间对比

Table 4 Comparison of inference time of different methods

方法	推理时间/ms
HiDDeN ^[8]	172
CAISFormer ^[15]	290
本文方法	189

3.5 消融实验

为系统性评估本文模型中各核心组件的贡献,本研究基于 ImageNet 数据集构建了统一的实验基准,采用 10 000 张图像作为训练集,2 500 张作为验证集,并保留 500 张独立测试集进行最终性能验证。通过设计四组渐进式消融实验模型,重点针对 Res-SS2D 模块与边缘特征融合方法展开定量分析。4 组模型的配置如下:

模型 1: U-Net + Res-SS2D + 边缘特征融合。即为本文提出的完整方案;

模型 2: U-Net + Res-SS2D。去除了边缘特征融合方法;

模型 3: U-Net + 边缘特征融合。去除了 Res-SS2D 模块;

模型 4: 仅保留最基本的 U-Net。

通过以上消融实验设计,可有效说明各核心模块对系统整体性能的独立贡献度,为各模块的有效性提供严谨的实验依据。对图像生成质量的消融实验结果如表 5 所示,对抗隐写分析性能的消融实验结果如表 6 所示。表 5 和 6 中加粗的数据表示在该评价指标下的最优值。

表 5 各核心组件对图像生成质量影响的消融实验

Table 5 Ablation study on the impact of core components on image generation quality

模型	载体图像/含密图像		秘密图像/恢复图像	
	PSNR	SSIM	PSNR	SSIM
1	40.588	0.970	41.863	0.986
2	39.128	0.960	39.805	0.971
3	37.124	0.955	36.890	0.954
4	36.544	0.937	36.172	0.949

从表 5 可以看出,去掉任意一个核心组件都会对生成图像质量造成影响,但影响程度有所不同。对比模型 1 和 2,去掉了边缘特征融合的情况下,含密图像与恢复图像的 PSNR 分别下降了 1.46 和 2.058 dB。而对比模型 1 和 3,

去掉了 Res-SS2D 的情况下,PSNR 则分别下降了 3.464 和 4.973 dB。显然,边缘特征融合对生成图像质量有影响,但不如 Res-SS2D 模块产生的影响大,这突出显示了全局建模能力对生成图像质量的重要性。

表 6 各核心组件对抗隐写分析性能影响的消融实验

Table 6 Ablation study on the impact of various core components on anti-steganalysis performance

模型	XuNet	YeNet	SR-Net
1	56.21	56.08	60.37
2	67.23	70.06	76.38
3	66.40	67.32	71.15
4	75.35	74.11	80.27

从表 6 来看,情况有所变化。以 SR-Net 为例,对比模型 1 和 2,判断准确率提升了 16.01%,而对比模型 1 和 3,判断准确率则提升了 10.78%。进一步对比模型 3 和 4,如果在基础 U-Net 上增加了边缘特征融合,判断准确率降低了 9.12%。相比之下,对比模型 2 和 4,若在基础 U-Net 上增加 Res-SS2D 模块,则判断准确率仅降低了 3.89%。这表明,就抗隐写分析性能而言,边缘特征融合的作用比 Res-SS2D 更大。

综上所述,本文提出的两个核心模块 Res-SS2D 和边缘特征融合,各自分别对生成图像质量与抗隐写分析性能这两方面起到了独特的作用,且二者相辅相成,共同提升了整个模型的综合性能。

为验证不同嵌入区域对模型抗隐写分析性能的影响,本文设计消融实验以展开深入分析。首先去除了模型中的边缘特征融合模块以排除其对模型的干扰,即使用上述模型 2 的配置,且仅通过修改损失函数中对频率的约束部分来限制秘密信息隐藏的区域。为此,本文设置了以下 3 种不同的损失函数:

1) 本文提出的原始损失函数,且权重 $\alpha = 1.0, \beta = 0.1, \gamma = 0.1$ 保持不变,代表将秘密信息嵌入至高频区域;

2) 本文提出的原始损失函数,且权重 $\alpha = 1.0, \beta = 0.1$ 保持不变,设置 $\gamma = 0$,代表不对嵌入区域进行人为约束;

3) 修改 \mathcal{L}_{freq} , 如下:

$$\mathcal{L}_{freq} = \gamma \cdot \frac{1}{N} \sum_{n=1}^N l_1(DWT(x_{cover}^{(n)})_{HH}, DWT(x_{stego}^{(n)})_{HH}) \quad (18)$$

该损失函数约束了载体图像与含密图像的对角线细节子带(即 HH 子带)尽量保持一致,且权重 $\alpha = 1.0, \beta = 0.1, \gamma = 0.1$ 保持不变,代表将秘密信息嵌入至低频区域。

这 3 种不同的损失函数对生成的图像的质量与抗隐写分析性能的影响如表 7 所示。

表 7 中加粗的数据代表在该指标下的最优值。对比损失函数 1 和 2,在去除对载体图像和含密图像的低频约

表7 约束不同嵌入区域的损失函数对图像生成质量与抗隐写分析性能的影响

Table 7 The impact of loss functions constraining different embedded regions on image generation quality and anti-steganalysis performance

损失函数	载体图像/含密图像		秘密图像/恢复图像		SR-Net 检测率
	PSNR	SSIM	PSNR	SSIM	
1	39.128	0.960	39.805	0.971	76.38
2	38.223	0.944	40.196	0.972	86.07
3	36.774	0.898	38.525	0.969	92.13

束后,生成的含密图像质量有所下降,这反而使解码器从含密图像中提取秘密信息的过程变得相对容易,导致恢复图像的质量略有提升。然而,不可忽视的是,此时模型的抗隐写分析性能显著降低。

对比损失函数1和3,如果对载体图像与含密图像的高频区域施加约束,秘密信息则更倾向于隐藏在图像的低频区域。由于图像低频区域的变化更容易引起人眼和隐写分析器的注意,与高频区域相比,这会导致模拟人眼视觉的评价指标(如SSIM)显著降低,同时被隐写分析器检测出的概率也大幅增加。综上所述,为权衡图像生成质量与抗隐写分析性能,本文选择对图像低频部分进行约束的策略是有效的。

4 结 论

针对现有基于传统CNN的生成式隐写术所面临的生成图像质量欠佳、抗隐写分析能力较弱的问题,本文创新性地提出了一种四向状态空间驱动的边缘融合图像隐写方法。核心在于设计了Res-SS2D模块,该模块能够对输入图像进行四向全局空间建模,在显著提升图像生成质量的同时,将时间复杂度控制在线性范围内,平衡了性能与效率。

此外,为了进一步增强生成图像的视觉质量和抗隐写分析性能,本文还引入了边缘特征融合机制,通过强调图像的边缘特征,使得秘密图像能尽可能地隐藏在载体图像的高频区域。同时,本文设计了一种多目标损失函数,进一步提高了模型的性能。

在ImageNet和COCO这两个图像数据集上进行的实验表明,本文所提出的方法在生成含密图像和恢复秘密图像方面均展现出卓越的性能。具体而言,生成的含密图像在视觉质量上达到了最优或次优水平,同时在面对多种主流隐写分析工具时,展现出了强大的抗检测能力,有效抵御了XuNet、YeNet和SRNet等先进隐写分析技术的检测。此外,该方法在保持高性能的同时,还维持了较低的推理时间,确保了其在实际应用场景中的高效性和实用性,为其在隐私保护和秘密通信等领域的广泛应用奠定了坚实的基础。

参考文献

[1] HU D H, WANG L, JIANG W J, et al. A novel

image steganography method via deep convolutional generative adversarial networks [J]. IEEE Access, 2018, 6: 38303-38314.

[2] 郝堃,任晓霞,李帅,等.数字医疗中的患者图像信息加密隐藏方法[J].国外电子测量技术,2025,44(2):62-67.

HAO K, REN X X, LI SH, et al. Encryption and hiding method for patient image information in digital medicine [J]. Foreign Electronic Measurement Technology, 2025, 44(2):62-67.

[3] 吴建斌,费潇潇,王年丰.基于混沌序列和DCT变换的图像零隐藏算法研究[J].电子测量技术,2017,40(5):174-179.

WU J B, FEI X X, WANG N F. Zero-steganography algorithm research based on chaotic sequences and image DCT transform [J]. Electronic Measurement Technology, 2017, 40(5):174-179.

[4] LIU J D, LI ZH H, JIANG X H, et al. A high-performance CNN-applied HEVC steganography based on diamond-coded PU partition modes [J]. IEEE Transactions on Multimedia, 2021, 24: 2084-2097.

[5] WANG J, JIA X Q, KANG X G, et al. A cover selection HEVC video steganography based on intra prediction mode [J]. IEEE Access, 2019, 7: 119393-119402.

[6] LIAO X, YU Y B, LI B, et al. A new payload partition strategy in color image steganography [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2019, 30(3): 685-696.

[7] YANG J H, RUAN D Y, HUANG J W, et al. An embedding cost learning framework using GAN [J]. IEEE Transactions on Information Forensics and Security, 2019, 15: 839-851.

[8] ZHU J R, KAPLAN R, JOHNSON J, et al. Hidden: Hiding data with deep networks [C]. European Conference on Computer Vision (ECCV), 2018: 657-672.

[9] ZHANG CH N, BENZ P, KARJAUV A, et al. UDH: Universal deep hiding for steganography,

- watermarking, and light field messaging [J]. Advances in Neural Information Processing Systems, 2020, 33: 10223-10234.
- [10] SUBRAMANIAN N, CHEHEB I, ELHARROUSS O, et al. End-to-end image steganography using deep convolutional autoencoders[J]. IEEE Access, 2021, 9: 135585-135593.
- [11] ZHANG L, LU Y, LI J X, et al. Deep adaptive hiding network for image hiding using attentive frequency extraction and gradual depth extraction[J]. Neural Computing and Applications, 2023, 35(15): 10909-10927.
- [12] GUAN ZH Y, JING J P, DENG X, et al. DeepMIH: Deep invertible network for multiple image hiding[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 45(1): 372-390.
- [13] DUAN X T, WU G M, LI CH, et al. DUIANet: A double layer U-Net image hiding method based on improved Inception module and attention mechanism[J]. Journal of Visual Communication and Image Representation, 2024, 98: 104035.
- [14] DOSOVITSKIY A, BEYER L, KOLESNIKOV A, et al. An image is worth 16×16 words: Transformers for image recognition at scale [J]. ArXiv preprint arXiv:2010.11929, 2020.
- [15] ZHOU Y H, LUO T, HE ZH Y, et al. CAISFormer: Channel-wise attention transformer for image steganography [J]. Neurocomputing, 2024, 603: 128295.
- [16] GU A, DAO T, ERMON S, et al. Hippo: Recurrent memory with optimal polynomial projections [J]. Advances in Neural Information Processing Systems, 2020, 33: 1474-1487.
- [17] GU A, JOHNSON I, GOEL K, et al. Combining recurrent, convolutional, and continuous-time models with linear state space layers[J]. Advances in Neural Information Processing Systems, 2021, 34: 572-585.
- [18] GU A, GOEL K, RÉ C. Efficiently modeling long sequences with structured state spaces [J]. ArXiv preprint arXiv:2111.00396, 2021.
- [19] GU A, DAO T. Mamba: Linear-time sequence modeling with selective state spaces [J]. ArXiv preprint arXiv:2312.00752, 2023.
- [20] YU W H, WANG X CH. Mambaut: Do we really need mamba for vision [C]. Computer Vision and Pattern Recognition Conference, 2025: 4484-4496.
- [21] LIU Y, TIAN Y J, ZHAO Y ZH, et al. Vmamba: Visual state space model [J]. Advances in Neural Information Processing Systems, 2024, 37: 103031-103063.
- [22] HAN Q, FAN Z J, DAI Q, et al. On the connection between local attention and dynamic depth-wise convolution [J]. ArXiv preprint arXiv: 2106.04263, 2021.
- [23] WENG X Y, LI Y ZH, CHI L, et al. High-capacity convolutional video steganography with temporal residual modeling [C]. 2019 on International Conference on Multimedia Retrieval, 2019: 87-95.
- [24] BALUJA S. Hiding images in plain sight: Deep steganography[J]. The 31st International Conference on Neural Information Processing Systems, 2017, 30: 2066-2076.
- [25] XU G SH, WU H ZH, SHI Y Q. Structural design of convolutional neural networks for steganalysis [J]. IEEE Signal Processing Letters, 2016, 23(5): 708-712.
- [26] YE J, NI J Q, YI Y. Deep learning hierarchical representations for image steganalysis [J]. IEEE Transactions on Information Forensics and Security, 2017, 12(11): 2545-2557.
- [27] BOROUHAND M, CHEN M, FRIDRICH J. Deep residual network for steganalysis of digital images[J]. IEEE Transactions on Information Forensics and Security, 2018, 14(5): 1181-1193.

作者简介

杜尤伟, 硕士研究生, 主要研究方向为计算机视觉、信息隐藏。

E-mail: 202412492570@nuist.edu.cn

曹燧(通信作者), 博士, 讲师, 主要研究方向为数字取证、信息隐藏。

E-mail: caoyi@cxwu.edu.cn