杨晓昶, 程清楠. 人脸多先验融合的超分辨率重建方法[J]. 智能计算机与应用,2026,16(8):91-97. DOI:10.20169/j.issn.2095-2163.25012501

# 人脸多先验融合的超分辨率重建方法

杨晓昶, 程清楠
(上海第二工业大学 计算机与信息工程学院, 上海 201209)

**摘 要**: 随着数字图像广泛应用于安防、监控和刑侦办案等领域,监控视频和图像已成为重要的取证资料。然而,受自然环境和硬件设备的限制,在某些场景中难以获取高质量人脸图像,导致身份识别的准确性和效率下降,增加了案件侦办的难度与成本。本文提出了一种人脸超分辨率重建网络架构,旨在提高人脸图像的重建效果与清晰度,从而提升身份识别的准确性与效率,降低办案成本。该网络融合人脸关键点、属性信息和人脸轮廓等多维特征,结合注意力机制、残差连接和多属性融合的特征提取方法,有效提取人脸的先验信息。此外,本文对生成对抗网络(GAN)进行了改进,并通过在开源数据集 CelebA 上的实验,验证了该网络的优越性。

**关键词**: 图像处理; 神经网络; 人脸先验; 人脸超分辨率; 生成对抗网络
**中图分类号**: TP391.41 **文献标志码**: A **文章编号**: 2095-2163(2026)08-0091-07

# A super-resolution reconstruction method based on multi-prior fusion for face images

YANG Xiaochang, CHENG Qingnan
(School of Computer and Information Engineering, Shanghai Polytechnic University, Shanghai 201209, China)

**Abstract**: With the widespread application of digital images in fields such as security, surveillance, and criminal investigation, monitoring videos and images have become essential evidence. However, due to limitations of natural environment and hardware devices, high-quality facial images are often difficult to obtain in certain scenarios, leading to reduced accuracy and efficiency in identity recognition, which increases the difficulty and cost of case handling. This paper proposes a facial super-resolution reconstruction network architecture aimed at improving the reconstruction quality and clarity of facial images, thereby enhancing the accuracy and efficiency of identity recognition and reducing the case-handling cost. The network integrates multiple facial features, including keypoints, attribute information, and facial contours, and incorporates attention mechanisms, residual connections, and multi-attribute fusion for effective feature extraction. Additionally, the paper optimizes the Generative Adversarial Network (GAN) and validates the network's superior performance through experiments on the public CelebA dataset.

**Key words**: image processing; neural networks; facial priors; facial super-resolution; Generative Adversarial Network

## 0 引 言

超分辨率重建技术[1-4]在图像处理领域中扮演着至关重要的角色,尤其是在增强图像放大过程中的细节与质量方面,而人脸超分辨率重建[5]是图像超分辨率重建研究的一个重要分支。

当前多数人脸超分辨率研究通常仅采用人脸的五官关键点位置[6],热力图等单一的人脸先验信息作为指导约束来参与人脸超分辨率重建,这些先验信息较为单一,并且在人脸图像分辨率较低时,存在特征不可靠的问题,容易导致超分辨率重建的人脸局部细节出现偏差。其次,这些方法在实际应用场景中结构复杂,尤其在低分辨率的人脸场景中,单一关键点或者热力图检测容易重建失败,预测人脸的关键信息极其困难,而多先验融合可以在一定程度上互相弥补信息缺失。

考虑到上述问题,提出了人脸多先验融合的超分辨率重建方法,即 SRFFN,该网络由人脸先验信息预测模块与人脸重建模块组成。先验信息预测模块负责提取人脸的关键特征信息并将这些信息进行

**作者简介**: 杨晓昶 (1997—),男,硕士研究生。主要研究方向:图像处理与机器视觉。Email:136000550@qq.com; 程清楠(2001—),女,硕士研究生。主要研究方向:图像处理与机器视觉。

**收稿日期**: 2025-01-25

融合,得到最终的人脸特征,重建模块则根据人脸关键特征来对人脸进行超分辨率重建。

其中人脸先验信息预测模块由本研究精心设计的人脸通用特征预测模块(Residual Attribute Attention Module, RAAM)与人脸边缘模块(Edge Module, EM)构成。这些模块可以提取人脸结构不同类别的信息,并在最终将这些感受特征融合到一起,作为人脸重建模块的输入。对于人脸超分辨率重建模块,本文对 GAN 的判别器和生成器分别进行了改进,以增强在真实退化模式下的泛化能力,并进行消融实验对比不同先验信息融合方式,验证其对人脸重建精度的影响。

## 1 方法

### 1.1 整体网络框架

本文提出的 SRFFN 网络整体架构如图 1 所示。该网络包含上采样模块、浅层特征提取模块、堆叠的 RAAM、边缘预测模块、特征融合块与重建模块。

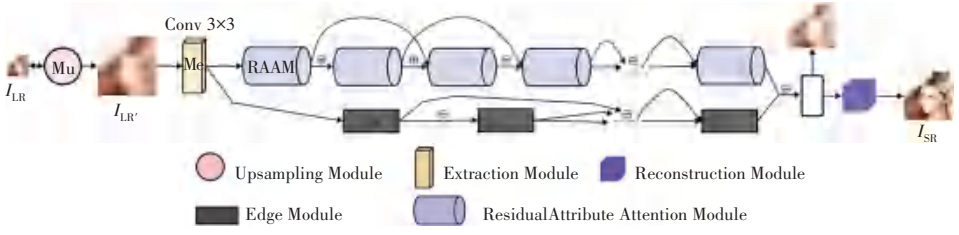



**图 1 SRFFN 网络结构**

**Fig. 1 SRFFN network architecture**

$I_{LR}$ 表示输入的低分辨率人脸图像,$I'_{LR}$ 表示经过上采样的初步高分辨率人脸图像,$I_{SR}$ 表示最终重建的超分辨率人脸图像。网络将低分辨率 $I_{LR}$ 人脸图像作为输入至上采样模块进行放大[7],缩放因子为 8,像素数从 16×16 到 128×128,得到初步人脸图像 $I'_{LR}$。该过程可由下式表示:

$$I'_{LR} = M_u(I_{LR}) \tag{1}$$

随后,本文用一个浅层卷积网络(记为 $M_e$),从 $I'_{LR}$ 中提取初步特征 $F^0$,即:

$$F^0 = M_e(I'_{LR}) \tag{2}$$

### 1.2 多先验特征提取模块设计

浅层特征 $F^0$ 被送入带有残差连接的 RAAM 模块中,在 RAAM 模块中,针对人脸特征预测任务设计了两个并行的特征提取分支与一个特征融合分支。两个特征提取分支以相同的初始特征 $F^0$ 作为输入,分别侧重于对人脸特征点位置和人脸属性信息的多尺度特征提取与表示。在这两个分支中,引入沙漏块[8]进行多级尺度特征融合,利用自上而下与自下而上的特征处理路径,捕捉人脸整体轮廓、关键点局部结构以及面部属性相关的全局信息与局部细节。通过沙漏块的编码-解码对称结构以及跳跃连接的设计,对人脸关键点位置和属性预测分别使用沙漏进行多尺度特征提取,网络可在缩小特征图分辨率的过程中获得全局上下文信息,并在上采样恢复过程中重新整合低层次细节特征,从而在特征点检测与属性预测中兼顾全局与局部特征表达。定义关键点预测分支与属性预测分支两个沙漏块 $H_K$ 和 $H_A$,分别处理相同的输入特征 $F^0$,计算公式如下:

$$F_K^{HG} = H_K(F^0) \tag{3}$$

$$F_A^{HG} = H_A(F^0) \tag{4}$$

其中,$H_K$、$H_A$ 为具有对称的编码-解码结构和跳跃连接的沙漏模块;$F_K^{HG}$ 为关键点预测分支经沙漏块后的特征;$F_A^{HG}$ 为属性预测分支经沙漏块后的特征,用于提取全局与局部相结合的多尺度特征。

在每个特征提取分支内,为了更好地聚焦于目标区域与关键特征,本文进一步嵌入通道与空间注意力机制[9]。通道注意力通过对特征图进行全局统计,动态调节不同通道特征的重要性,使网络优先选取与关键点位置、人脸特定属性高度相关的特征通道。而空间注意力则通过强调特定空间位置的响应,将注意力集中于具有显著结构和纹理信息的人脸区域,精确定位如眼睛、鼻子、嘴唇等关键部位。对 $F_K^{HG}$ 与 $F_A^{HG}$ 进行全局平均池化,$\boldsymbol{Z}_k$ 与 $\boldsymbol{Z}_A$ 分别是关键点分支特征与人脸属性分支特征在通道维度上的全局描述向量,二者将经沙漏块处理后的特征空间信息汇聚到每个通道的平均值上。该过程表示如下:

$$\boldsymbol{Z}_k = \frac{1}{H \times W}\sum_{i=1}^{W}\sum_{j=1}^{H} F_K^{HG}(c,i,j) \tag{5}$$

$$\boldsymbol{Z}_A = \frac{1}{H \times W}\sum_{i=1}^{W}\sum_{j=1}^{H} F_A^{HG}(c,i,j) \tag{6}$$

将 $\boldsymbol{Z}_k$ 与 $\boldsymbol{Z}_A$ 经两层全连接层与激活函数 ReLU 生成通道权重向量 $\boldsymbol{\alpha}^{cK}$ 与 $\boldsymbol{\alpha}^{cA}$:

$$\boldsymbol{\alpha}_K^c = \sigma(W_2^c\delta(W_1^c Z_K)) \tag{7}$$

$$\boldsymbol{\alpha}_A^c = \sigma(W_2^c\delta(\boldsymbol{W}_1^c Z_A)) \tag{8}$$

其中，$\delta(\cdot)$表示 ReLU 非线性激活函数；$\sigma(\cdot)$表示 Sigmoid；$\boldsymbol{W}_1^c$ 和 $\boldsymbol{W}_2^c$ 是可学习的参数矩阵。随后，将通道权重向量扩展并与原特征相乘获得通道加权特征 $F_K^{\mathrm{CA}}$ 与 $F_A^{\mathrm{CA}}$：

$$F_K^{\mathrm{CA}}(c,i,j) = \boldsymbol{\alpha}_K^c(c) * F_K^{\mathrm{HG}}(c,i,j) \tag{9}$$

$$F_A^{\mathrm{CA}}(c,i,j) = \boldsymbol{\alpha}_A^c(c) * F_A^{\mathrm{HG}}(c,i,j) \tag{10}$$

接下来对通道加权后的特征再进行空间注意力处理，以突出特定空间位置的重要性。空间注意力函数定义为：通过对通道平均池化生成空间描述信息，然后经过卷积与 Sigmoid 激活函数生成空间权重图 $\alpha^s$，该过程计算公式如下：

$$f_K^{\mathrm{sp}} = \frac{1}{C}\sum_{c=1}^{C} F_K^{\mathrm{CA}}(c,i,j) \tag{11}$$

$$f_A^{\mathrm{sp}} = \frac{1}{C}\sum_{c=1}^{C} F_A^{\mathrm{CA}}(c,i,j) \tag{12}$$

$$\alpha_K^s(i,j) = \sigma(\mathrm{conv}(f_K^{\mathrm{sp}}(i,j))) \tag{13}$$

$$\alpha_A^s(i,j) = \sigma(\mathrm{conv}(f_A^{\mathrm{sp}}(i,j))) \tag{14}$$

其中，$f_K^{\mathrm{sp}}$ 与 $f_A^{\mathrm{sp}}$ 是经过通道压缩后的空间描述信息；$\alpha_K^s$ 与 $\alpha_A^s$ 是空间权重图；conv(·)表示卷积操作。

将空间权重图与对应特征相乘，获得最终注意力增强后的特征 $F_K^{\mathrm{out}}$ 与 $F_A^{\mathrm{out}}$：

$$F_K^{\mathrm{out}}(c,i,j) = \alpha_K^s(i,j) * F_K^{\mathrm{CA}}(c,i,j) \tag{15}$$

$$F_A^{\mathrm{out}}(c,i,j) = \alpha_A^s(i,j) * F_A^{\mathrm{CA}}(c,i,j) \tag{16}$$

最后，将经过注意力增强的两个分支输出特征 $F_K^{\mathrm{out}}$ 与 $F_A^{\mathrm{out}}$ 在通道维度上进行融合，融合策略采用通道拼接后经过一层 1×1 的卷积进行融合，该过程可由如下公式表示：

$$F_{\mathrm{concat}} = |F_K^{\mathrm{out}}; F_A^{\mathrm{out}}|, F_{\mathrm{concat}} \in R^{2\times C\times H\times W} \tag{17}$$

$$F_{\mathrm{out}} = W_f * F_{\mathrm{concat}}$$

其中，$F_{\mathrm{concat}}$ 为在通道维度上进行融合后的特征；$F_{\mathrm{out}}$ 为最终输出的特征；* 表示卷积操作，通过该卷积层，可将特征通道整合回所需维度并完成特征融合。

边缘块可被表示为一个可学习的映射函数 $H_E(\cdot)$，通过对输入图像进行若干层卷积与非线性变换，获得高维度的边缘特征表示 $F_{\mathrm{e}}$：

$$F_{\mathrm{e}} = H_E(I_{\mathrm{LR}'}) \tag{18}$$

为实现特征融合，本文将 $F_{\mathrm{out}}$ 与 $F_{\mathrm{e}}$ 在通道维度上进行拼接，然后利用 1 * 1 卷积加权求和策略对拼接特征进行整合。设特征融合操作为 $H_F(\cdot)$，则融合特征 $F_{\mathrm{f}}$ 表示为：

$$F_{\mathrm{f}} = H_F(|F_{\mathrm{out}}; F_{\mathrm{e}}|) \tag{19}$$

其中，$|F_{\mathrm{out}}; F_e|$ 表示在通道维度上的拼接操作，该融合方式使模型在同一特征表示中同时具备面部局部纹理、全局语义及轮廓细节信息。

### 1.3　改进的生成对抗重建模块

本文在研究中引入了改进的 GAN[10-14] 来作为后续的人脸超分辨率重建模块，在处理图像任务时，传统 GAN 通常使用均方误差(MSE)作为内容损失来度量重建图像与目标图像之间的差异。由于 MSE 在像素层面的差异上有平均的趋向，这对于图像的细节关注程度不够高，为解决这一问题，本文采用了 PatchGAN 判别器。

传统的 ReLU 激活函数虽然有效缓解了梯度消失问题，但在深层网络中可能会引入训练不稳定的风险。为克服这一问题，本文引入了 PReLU (Parametric ReLU)，在人脸超分辨率这种对细节要求极高的任务中，PReLU 能够为每层网络提供更稳定的梯度传播，从而确保模型能够有效地捕捉到细微的细节和高频信息。在处理细节密集的图像时，BN 层对特征的强制标准化可能会抹去图像的局部细节，尤其是在输入的图像分辨率较低时，BN 可能会将一些微小的结构信息平滑掉。为此，本文引入了实例归一化(IN)。在人脸超分辨率的场景中，IN 能够确保图像中的微小纹理和边缘细节在训练过程中不被平滑掉，从而帮助生成器更好地恢复人脸的细节结构。

### 1.4　损失函数

在 SRFFN 网络的设计中，为分别优化人脸特征提取与图像重建这两个关键环节，本文采用了分离的损失函数设计策略。为人脸特征和边缘特征设计了独立损失函数。具体而言，损失函数包括人脸特征预测的 $L1$ 损失与边缘特征的感知损失[15-16]。该过程可由如下公式表示：

$$L_{\mathrm{fe}} = \lambda_1 L_{\mathrm{f}} + \lambda_2 L_{\mathrm{e}} \tag{20}$$

其中，$L_{\mathrm{fe}}$ 表示特征预测与边缘块的联合损失函数；$L_{\mathrm{f}}$ 为人脸特征回归损失，旨在通过 $L1$ 范数衡量生成的人脸特征与真实特征之间的差异；$L_{\mathrm{e}}$ 为边缘特征感知损失，其通过 $L1$ 范数度量生成图像与真实图像在边缘特征层面的差异；$\lambda_1$ 和 $\lambda_2$ 为平衡不同损失项的重要性权重。

设 RAAM 最终输出的特征为 $F_{\mathrm{out}}$，边缘块输出的边缘特征为 $F_{\mathrm{e}}$，$L_{\mathrm{f}}$ 和 $L_{\mathrm{e}}$ 分别可以表示为：

$$L_{\mathrm{f}} = \frac{1}{N}\sum_{i=1}^{N} \| F_{\mathrm{out},i} - F_{\mathrm{gt},i} \|_1 \tag{21}$$

$$L_e = \frac{1}{N}\sum_{i=1}^{N} \| F_{ei} - F_{egt,i} \|_1 \quad (22)$$

其中，$N$ 为样本数量；$F_{gt}$ 和 $F_{egt}$ 表示两个分支的真实特征；$\|\cdot\|_1$ 表示 $L1$ 范数。

重建模块的损失函数 $L_{recon}$ 包括以下几个部分：对抗损失、感知损失、高频损失以及边缘一致性损失，其中 $\lambda_3$、$\lambda_4$、$\lambda_5$、$\lambda_6$ 分别为各损失项的权重系数：

$$L_{recon} = \lambda_3 L_{GAN} + \lambda_4 L_{percep} + \lambda_5 L_{grad} + \lambda_6 L_{edge_consist} \quad (23)$$

对抗损失可由如下公式表示，其中 $D_s$ 表示第 $s$ 尺度的判别器，$G$ 为生成器：

$$L_{GAN} = \sum_{s\in S} \alpha_s L^s_{GAN} \quad (24)$$

$$L^s_{GAN} = E_{I_{HR}}[\log D_s(I_{HR})] + E_{I_{LR}}[\log(1 - D_s(G(I_{LR})))] \quad (25)$$

感知损失 $L_{percep}$ 通过计算生成图像与真实图像在 VGG 网络各层提取的特征之间的差异，来评估图像的语义一致性。本文中，感知损失函数采用了 VGG 网络[17-18]的前 5 层卷积层，这些层分别对应图像特征的不同尺度，能够较好地平衡细节保留和语义信息的提取。感知损失可由下式表示：

$$L_{percep} = \sum_{l\in L} \frac{1}{N_l} \| \emptyset_l(I_{SR}) - \emptyset_{HR}) \|_2^2 \quad (26)$$

其中，$\emptyset_l(\,)$ 表示预训练 VGG 网络在第 $l$ 层提取的特征；$L$ 为选取的特征集合；$N_l$ 为该层特征的像素总数。

高频损失可由下式表示

$$L_{grad} = \| \nabla I_{SR} - \nabla I_{HR} \|_1 \quad (27)$$

其中，$\nabla$ 表示 sobel 梯度运算。

边缘一致性损失 $L_{edge_consist}$ 可由下式表示：

$$L_{edge_consist} = \| E_{SR} - E_{gt} \|_1 \quad (28)$$

其中，$E_{SR}$ 为重建人脸图像 $I_{SR}$ 经过边缘块提取的边缘特征，$E_{gt}$ 为真实高分辨率人脸图像 $I_{HR}$ 的边缘特征。

最终，整个模型的损失函数 $L_{total}$ 由预测模块的损失函数与重建模块的损失函数组成：

$$L_{total} = L_{fe} + L_{recon} \quad (29)$$

将上述各个子损失项代入，总体损失函数可表示为：

$$L_{total} = \lambda_1 L_f + \lambda_2 L_e + \lambda_3 L_{GAN} + \lambda_4 L_{percep} + \lambda_5 L_{grad} + \lambda_6 L_{edge_consist} \quad (30)$$

通过设计多个损失项并对其进行加权，SRFFN 网络能够同时优化人脸特征提取、图像细节恢复与视觉感知的多个方面。各损失项的联合训练保证了生成图像不仅具备高质量的细节和结构，还能在视觉感知上更接近真实人脸，从而实现高效且高质量的超分辨率重建。

## 2 实验结果与分析

### 2.1 实验设置

本文在 CelebA[19]数据集上进行了实验，该数据集包含约两万张人脸图像。数据集被分为训练集（80%）、验证集（5%）和测试集（15%）。在评估重建效果时，使用了 SSIM 和 PSNR[20]作为主要的评价指标。

在实验设置中，首先使用人脸检测工具[21]提取图像中的人脸区域，并将其对齐调整至目标高分辨率尺寸。低分辨率输入图像由对应高分辨率人脸区域下采样至 16×16 大小得到。为增强模型的鲁棒性，训练过程中对图像添加了高斯噪声和椒盐噪声，并进行了图像旋转处理。训练采用 Adam 优化器，初始学习率设置为 $2.5\times10^{-4}$，训练时使用 16 张人脸图像的批量大小，其他超参数 $\beta_1$ 和 $\beta_2$ 分别设置为 0.9 和 0.999。实验在 Pytorch 框架上实现，硬件平台为 NVIDIA GTX 4070Ti，确保了训练过程的高效性与稳定性。

### 2.2 消融实验

为验证 SRFFN 模型各模块的有效性，本文进行了消融实验，通过去除人脸边缘块来评估其对特征提取和超分辨率重建效果的贡献。去除边缘块后的网络被命名为 SRFFN-NE。通过比较 SRFFN-NE 与 SRFFN 的重建结果，发现边缘块在细节恢复、边缘清晰度和纹理还原方面具有显著的正向作用。此外，还对 GAN 模块进行了消融实验，将改进后的 GAN 替换为原始 GAN（命名为 SRFFN-NG），结果表明，未经改进的 GAN 无法有效恢复图像的细节纹理，产生较大的模糊现象。表 1 展示了不同消融实验模型在 PSNR 和 SSIM 指标上的表现。通过对比，可以看到 SRFFN-NE 和 SRFFN-NG 在图像重建质量上的差异，进一步证明了边缘块和改进 GAN 的有效性。

### 2.3 对比实验

将本文提出的方法与其他超分辨率方法进行定量比较，比较的数据集基于 CelebA 的测试集。其他的重建算法选取了传统插值方法、通用图像超分辨率模型 RCAN、SRCNN、HAN、与人脸超分辨率重建模型 FSRNet、FACN、SPA。为保证比较的准确性，本

文在比较前使用 CelebA 的训练数据集对所有比较模型进行了训练。在与其他方法进行比较时，SRFFN 在 PSNR 和 SSIM 两个指标上均表现出较大的优势。表 2 列出了各方法在 CelebA 测试集上的对比结果。可以看到，SRFFN 在所有对比方法中均取得了最高的 PSNR 和 SSIM 值，表明其在图像质量和细节恢复方面具有明显的优势。

**表 1　消融实验**

**Table 1　Ablation experiment**

| 模型 | PSNR | SSIM |
|---|---|---|
| SRFFN-NE | 26.44 | 0.789 1 |
| SRFFN-NG | 25.88 | 0.732 3 |
| SRFFN | 27.05 | 0.795 3 |

**表 2　各方法在测试集上的客观对比结果**

**Table 2　Objective comparison results of each method on the test set**

| 模型 | Bicubic | SRCNN | RCAN | HAN | FACN | FSRNet | SPA | SRFFN |
|---|---|---|---|---|---|---|---|---|
| PSNR | 24.310 0 | 25.660 0 | 25.740 0 | 25.870 0 | 26.890 0 | 26.810 0 | 26.860 0 | 27.050 0 |
| SSIM | 0.652 4 | 0.692 3 | 0.732 3 | 0.742 3 | 0.777 3 | 0.781 1 | 0.782 3 | 0.795 3 |

除定量指标对比外，本文还对不同方法的重建效果进行了可视化对比，所有结果均来自测试集的样本输出，各方法的整体重建效果如图 2 所示。为进一步清晰展现不同方法在人脸关键局部细节上的重建差异，本文分别对重建结果中的眼睛、鼻子、嘴巴区域做了局部放大处理，对比结果如图 3—图 5 所示。




**图 2　各方法在 CelebA 数据集重建效果**

**Fig. 2　Reconstruction performance of each method on the CelebA dataset**

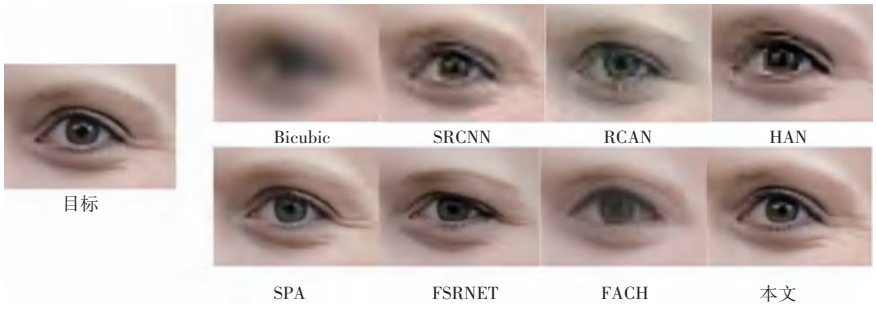



**图 3　各方法在眼睛上局部放大对比**

**Fig. 3　Localized comparison of each method on eye region enlargement**




**图 4 各方法在鼻子上局部放大对比**

**Fig. 4 Localized comparison of each method on nose region enlargement**




**图 5 各方法在嘴巴上局部放大对比**

**Fig. 5 Localized comparison of each method on mouth region enlargement**

综上所述,SRFFN 通过多种人脸先验信息的融合以及边缘特征的精细化处理,显著提高了超分辨率重建任务中的细节恢复能力,尤其在人脸区域的特征提取与重建效果上具有明显优势。实验结果表明,SRFFN 能够生成更加清晰、细节丰富的人脸图像,证明了其在实际应用中的潜力和效果。

## 3 结束语

本文针对小分辨率人脸超分辨率重建,提出了一种人脸多先验融合的残差注意力神经网络结构。首先,算法对人脸图像进行区域提取和尺寸调整。接着,利用残差连接的注意力模块进行特征提取,并将提取到的特征与人脸边缘模块输出的特征进行融合,最终获得完整的人脸特征。最后,重建模块对融合后的特征进行处理,完成高清重建任务。

基于上述设计思想,本章还在公开的 CelebA 数据集上进行了实验验证,结果表明本文提出的算法能够有效提升人脸图像的重建质量,证明了其在实际应用中的可行性与有效性。

## 参考文献

[1] 李赛赛. 基于深度学习的图像超分辨率重建研究[J]. 电脑知识与技术, 2020,16(29): 191-192.

[2] An H L, Diao W, Jing Z, et al. Image super-resolution reconstruction based on multi-scale dual-attention[J]. Connection Science, 2023, 35 (1): 142-151.

[3] 王嘉进. 基于深度学习算法的图像超分辨率重建研究[J]. 数字通信世界, 2024 (9): 13-15.

[4] 李岚, 张云, 何方, 等. 基于残差注意力机制的图像超分辨率重建[J]. 兰州文理学院学报(自然科学版), 2024, 38(5): 48-53.

[5] 朱柏霖, 卢涛, 王依伊, 等. 实际场景人脸超分辨率算法综述[J]. 武汉工程大学学报, 2024, 46(5): 564-573.

[6] 安婧, 孙亮. 关键点重建算法在人脸超分辨率重建中的应用[J]. 电子技术与软件工程, 2016 (23): 96-97.

[7] 张思言, 杜周南, 任一心, 等. 一种双三次插值实时超分辨率 VLSI 设计[J]. 西南大学学报(自然科学版), 2024, 46(4): 202-212.

[8] 吴佳豪. 基于堆叠沙漏网络的人体姿态估计研究[D]. 贵阳:贵州大学, 2022.

[9] Yao Z, Gao S, Li W. SNN using color-opponent and attention mechanisms for object recognition[J]. Pattern Recognition, 2025, 158: 111070.

[10] Kancharagunta B K, Ram S D. CDGAN: Cyclic discriminative generative adversarial networks for image-to-image transformation [J]. Journal of Visual Communication and Image Representation, 2022, 82:1120-1136.

[11] 许光宇, 潘月, 华健. 基于感知损失和稠密残差双注意力去雾网络[J]. 滁州学院学报, 2024, 26(2): 33-40.

[12] 吴泓成, 林国军, 朱晏梅, 等. 基于多特征融合的生成对抗网络图像修复算法[J]. 内江师范学院学报, 2024, 39(12): 39-45.

[13] 郭华. 基于生成对抗网络的图像修复技术研究[J]. 长江信息通信, 2024, 37(12): 64-66.

[14] Zhang Hongwei, Qiao Guanhua , Lu Shuai , et al. Attention-

based feature fusion generative adversarial network for yarn-dyed fabric defect detection[J]. Textile Research Journal, 2023, 93(5/6): 1178-1195.

[15]宋昱, 孙文赟. 基于重加权 l1 范数的边缘保持图像平滑算法[J]. 华南理工大学学报(自然科学版), 2021, 49(6): 109-121.

[16]刘潇, 官恺, 金飞, 等. 面向深度学习密集匹配的无监督损失函数[J]. 测绘通报, 2024 (11): 133-139.

[17]陈灵方, 张鹏, 李昆, 等. 基于改进 VGG16 网络的小尺寸图像识别研究[J]. 现代信息科技, 2024, 8(23): 105-109.

[18]Sun M, Yuan J, Li X, et al. LVGG-IE: A novel lightweight VGG-based image encryption scheme[J]. Entropy, 2024, 26 (12): 1013.

[19]Prabhu U V, Yap A D, Wang A, et al. Covering up bias in celeb a-like datasets with markov blankets: A post-hoc cure for attribute prior avoidance[EB/OL]. (2024-11-12)[2025-01-22]. https://arxiv.org/pdf/1907.12917.

[20]汤力, 潘媛, 王菁, 等. 基于加权 SSIM 算法的文档中图像相似度检测方法[EB/OL]. (2019-07-31)[2025-01-22]. http://kns.cnki.net/kcms/detail/23.1474.TP.20241112.1606.049.html.

[21]Xu W, Wang D. A real-time face detection based on skin detection and geometry features[J]. Journal of Optics, 2024, 54 (5): 1-15.