

基于深度学习的数字图像处理实验平台开发

刘康¹, 刘才学², 周成宁², 黄磊¹, 刘文骏¹, 李振颖¹, 刘宝弟¹

(1. 中国石油大学(华东)控制科学与工程学院, 山东 青岛 266580;

2. 中国核动力研究设计院, 成都 610213)

摘要: 数字图像处理实验平台在工业、医学、农业等领域具有重要意义, 可以为图像处理任务提供高效、准确的解决方案; 为解决数字图像处理中存在的信息缺失、噪声干扰、低分辨率等问题, 通过结合卷积神经网络和生成对抗网络等先进技术, 采用模块化设计及数据增强、迁移等方法, 设计了一种多功能的数字图像处理平台, 包括图像超分辨率重建、风格转换、去噪、去雾、修复、抠图等功能; 用户可以根据需求选择不同的处理模块构建自己的处理系统, 展现了平台的灵活性和可定制性; 通过案例验证, 证实了该图像处理实验平台的有效性和便捷性。

关键词: 深度学习; 数字图像处理; 卷积神经网络; 生成对抗网络

Development of Digital Image Processing Experiment Platform Based on Deep Learning

LIU Kang¹, LIU Caixue², ZHOU Chengning², HUANG Lei¹, LIU Wenjun¹, LI Zhenying¹, LIU Baodi¹

(1. College of Control Science and Engineering, China University of Petroleum (East China), Qingdao 266580, China;

2. Nuclear Power Institute of China, Chengdu 610213, China)

Abstract: It is of great significance for digital image processing experimental platform in industry, medicine, agriculture and other fields, which provides efficient and accurate solutions for image processing tasks. In order to solve the problems of information loss, noise interference and low resolution in digital image processing, a multi-functional digital image processing platform is successfully designed by combining advanced technologies such as convolutional neural network and generative adversarial network, and adopting the methods of modular design, data enhancement and migration, including image super resolution reconstruction, style conversion, noise removal, fog removal, repair, matting and other functions. Users can choose different processing modules to build their own processing system as needed, showing the flexibility and customizability of the platform. Through a case experiment, the image processing experimental platform verifies its effectiveness and convenience.

Keywords: deep learning; digital image processing; convolutional neural network; generative adversarial networks

0 引言

数字图像相关技术在近几年发展迅速, 随着深度学习技术在图像处理中的广泛应用, 集成了多种数字图像处理技术的算法平台应运而生。

数字图像处理平台是一种集成了多种数字图像处理技术的软件系统, 通过使用深度学习等先进技术, 为用户提供图像处理、编辑、分析等功能, 可帮助用户实现图像的优化、识别、分割、分类等功能, 使图像处理更

加高效、方便和准确。数字图像处理平台往往具有直观、操作简单的特点, 来满足用户的个性化需求。与边缘检测^[1]、图像分割、模糊处理、特征提取匹配^[2]等传统算法相比, 深度学习通过学习大量训练数据中的先验知识, 具有更强的泛化能力和更复杂的参数化表达^[3-4], 且无需调节算法参数以适应不同应用场景。

近年来, 深度学习模型已被证明在计算机视觉领域具有卓越分类能力。深度学习强调模型结构的深度和对特征学习的重要性, 采用有监督或无监督的方式对图像

收稿日期:2024-04-29; 修回日期:2024-06-06。

基金项目:四川省自然科学基金(2023NSFSC0861);核动力院原创基金(KJCX-2022-YC1-11)。

作者简介:刘康(2003-),男,大学本科。

通讯作者:周成宁(1989-),男,博士,副研究员。

引用格式:刘康,刘才学,周成宁,等. 基于深度学习的数字图像处理实验平台开发[J]. 计算机测量与控制, 2025, 33(6):223-231.

进行底层到高级语义特征的学习^[5]。其中,卷积神经网络(CNN)^[6]受动物视觉神经系统启发,通过多个卷积层和池化层逐步提取图像细节,实现模式和特征识别^[7]。CNN具有局部连接、权值共享和池化操作等优良特性,降低了网络计算复杂度、提升了泛化能力^[8]。例如,深层CNN结构在图像分类竞赛中表现出色,引发更多更深的神经网络提出,如VGGNet、GoogleNet、ResNet、DenseNet等神经网络^[9-10]。深度学习还涌现出许多变形结构,如去噪自动编码器^[11]、sum-product^[12]等,进一步推动了模型的发展。文献[13-16]对神经网络的特征图通道、空间和卷积核等方面进行结构改进,提出了SEblock、SKblock等注意力机制,以及Res2Net、ResNeSt等模型,在图像分类任务上取得优异表现。文献[17]提出了基于Fukushima网络的卷积神经网络的图像分类方法,可以从海量且有噪声的图像中学习到目标的高层特征,且这种特征对于目标某种程度的形变有很好的鲁棒性。自2016年文献[18]提出GAN以来,相关研究呈现指数级增长。

这些技术的快速发展为数字图像处理技术赋予了强大的活力,然而,现有的数字图像处理平台仍存在一些缺点,如:现有平台在处理大规模图像数据时,往往存在性能不足的问题,表现为处理速度较慢,对图像质量处理较为有限,难以有效地去除噪点、纠正失真。其次,现有平台的算法和功能有限,无法满足用户的多样化需求,且在用户体验和界面设计方面还有待提升,用户操作不够简单直观。因此,提升图像处理效果的关键是如何利用深度学习技术来解决现有平台无法克服的难题。

为了进一步改进和优化,达到更好的图像处理效果,帮助本科生进行数字图像处理的实验和研究,加深对数字图像处理原理和算法的理解和掌握,提高实践操作能力和解决实际问题的能力,本文开发了一种基于深度学习的数字图像处理实验平台。该平台整合了常用的数字图像处理算法和深度学习技术,可实现图像超分辨率重建、图像风格转换、图像去噪、图像去雾、图像修复、图像抠图等方面的功能。本文主要创新点如下:利用深度学习技术处理图像,提取更加鲜明的特征,不受环境影响;引进先进的深度学习理论和网络模型,突出高光谱图像处理能力;利用大数据分析和挖掘方法深入挖掘海量图像数据中的潜在规律和价值,提高处理结果的准确性和鲁棒性。

1 数字图像处理实验平台主要原理

数字图像处理实验平台是一个综合了多种数字图像处理功能高效算法的平台。该平台通过模块化分类,使用户可以根据自己的需求进行个性化的使用。

平台的主要核心技术包括卷积神经网络和生成对抗

网络。CNN通过一系列的卷积层、池化层和全连接层来提取图像中的特征,并最终用于图像处理。卷积层通过卷积操作提取图像的局部特征(如边缘、角点、纹理等),基本原理可以表示为:

$$output(i, j) = \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} weights(m, n) \times input(i+m, j+n) + bias(i, j) \quad (1)$$

激活函数如ReLU^[19],负责引入非线性因素,使网络可以学习到更加复杂的特征。

$$ReLU(X) = \max(0, x) \quad (2)$$

池化层采用最大池化的池化方式,减小特征图的尺寸,同时保留重要信息,其具体原理可以表示为

$$output(i, j) = \max_{m, n} input(i+m, j+n) \quad (3)$$

全连接层将前一层的所有特征图(或特征向量)转换为最终的分类结果,可以将它看作是一个传统的神经层。

$$output = \text{ReLU}(weights \times input + bias) \quad (4)$$

式中, $input$ 是上一层的输出, $weights$ 和 $bias$ 分别是卷积核的权重和偏置, (i, j) 表示输出特征图上的位置, $M \times N$ 是卷积核的大小。通过这些层的组合, CNN能够从原始图像中自动学习到复杂的特征表示,并在诸如图像分类、目标检测和图像分割等任务中表现出优异的性能。

生成对抗网络是一种深度学习模型,由生成网络(Generator Network)和判别网络(Discriminator Network)^[20-21]两部分组成,它们通过对抗训练的方式共同进步,最终生成逼真的图像。生成网络的目标是生成尽可能真实的图像,欺骗判别网络,其输出可以表示为:

$$G(z) = \text{ReLU}\{FC[\text{Deconvolution}(z)]\} \quad (5)$$

判别网络的目标是区分生成图像和真实图像,输出是一个概率值,表示图片是真实图像的概率:

$$D(x) = \frac{1}{2} \{1 + \log[1 + e^{-\text{ReLU}[-FC(x)]]}\} \quad (6)$$

式中, z 是一个随机噪声向量, x 表示输入图像, FC 表示全连接层, Deconvolution 表示解卷积层,用于恢复图像的空间尺寸。

通过最大化判别网络的损失来训练生成网络,同时最小化判别网络的损失来训练判别网络,损失函数通常定义为判别网络对真实图像的损失 L_r 和生成图像的损失 L_g 的和:

$$L = L_g + L_r \quad (7)$$

通过这种对抗的过程,生成网络不断学习如何生成更接近真实图像的数据,而判别网络则不断学习如何更好地区分真实图像和生成图像。这个过程一直持续到两个网络达到一个动态平衡点,此时生成网络能够生成逼真的图像,而判别网络能够准确地识别真实图像和生成图像。

2 基于深度学习的数字图像处理实验平台开发

数字图像处理实验平台主要功能包括图像超分辨率重建、图像风格转换、图像去噪、图像去雾、图像修复、图像抠图等。首先, 确定平台的需求和功能, 完成用户界面设计; 然后, 进行模型训练和优化; 最后, 对各个功能模块进行测试和优化, 平台开发流程如图 1 所示。

2.1 基于卷积神经网络的图像超分辨率重建

基于卷积神经网络的图像超分辨率重建的基本原理是通过深度学习模型学习低分辨率图像与对应高分辨率图像之间的映射关系, 来实现对低分辨率图像的重建。该方法的输入是低分辨率图像, 经过卷积神经网络的处理后, 输出高分辨率图像。网络通过学习大量训练样本, 学习到低分辨率与高分辨率图像之间的非线性映射函数。这种映射函数能够捕捉到图像中的细节和纹理信息, 从而实现对低分辨率图像的恢复和重建。基于卷积神经网络的图像超分辨率重建流程如图 2 所示。

图像超分辨率重建步骤如下:

- 1) 特征提取。利用卷积神经网络提取低分辨率图像的特征, 包括纹理、颜色和边缘信息。
- 2) 多尺度映射。对低分辨率图像进行多尺度特征

映射, 通过卷积、池化等操作提取每个尺度的特征表示, 为超分辨率重建提供更丰富的信息。

3) 图像重建。通过学习特征表示与高分辨率图像之间的映射关系, 使用卷积层来重建高分辨率图像。这一步可以通过反卷积操作或上采样技术来完成。

4) 超分辨率结果优化。对生成的高分辨率图像进行后处理, 如去噪、增强对比度等, 以进一步提升图像质量。

5) 评估效果。评估超分辨率重建算法的效果, 根据评估结果对算法进行调整和优化。

在训练过程中, CNN 模型通过与高分辨率图像进行对比, 优化网络参数, 以最佳方式重建低分辨率图像的细节和结构信息。这种非线性映射能力使 CNN 能够从低分辨率图像中还原出更多的细节。通过非线性映射, CNN 模型增加了高频细节并恢复了原始图像中的结构信息。最终的重建结果可在一定程度上恢复原始图像的清晰度和细节。

2.2 基于卷积神经网络的图像风格转换

图像风格转换技术的核心思想是利用深度卷积神经网络来学习图像的样式和特征表示。通过这种方式, 可以实现将著名画作的风格应用到其他图片上, 从而创作

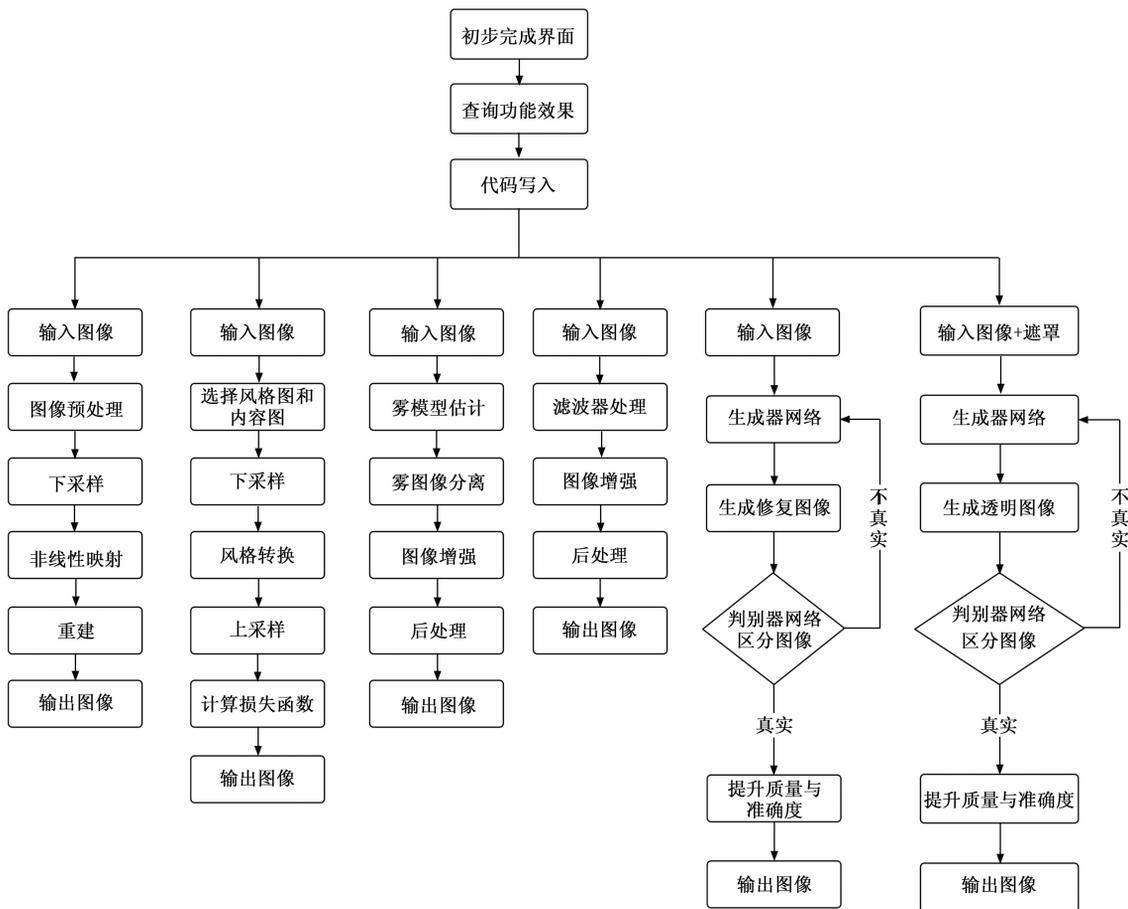


图 1 基于深度学习的数字图像处理实验平台开发流程

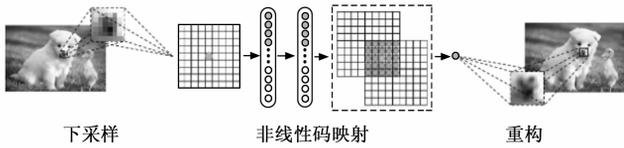


图 2 图像超分辨率重建原理图

出具有特定风格的新图像。

下采样用于捕获图像中的更丰富信息并送入 Res 块, Res 块的核心思想是引入残差连接, 残差连接通过在网络中引入跨层直接连接, 将输入特征与经过卷积后的特征相加, 从而创建一个残差映射。而上采样内容图则可以将迁移后的图像与原始内容图进行匹配, 生成具有相似风格和内容的图像。损失网络用于衡量生成图像与目标风格图之间的差异, 通过将生成的图像与目标风格图在 VGG-19 网络中进行特征提取, 通过卷积操作在图像上提取出不同的特征图, 包含了图像的边缘、纹理等低级特征信息, 并计算它们之间的差异, 可以用来衡量生成图像与目标风格图之间的相似性。

在图像风格转换中, ResNet 通常由多个残差块堆叠而成。每个残差块包含多个卷积层、批量归一化和非线性激活函数, 以构建深层神经网络。通过堆叠多个残差块, ResNet 可以逐渐学习和应用输入图像的风格, 生成具有所需风格的输出图像。

如图 3 所示, VGG-19 网络由 16 个卷积层、5 个池化层、3 个全连接层组成, 卷积核大小为 3×3 , 卷积步长为 1, 池化层中的池化方式为最大池化 maxpool。

图像风格转换原理如图 4 所示, 其转换步骤如下:

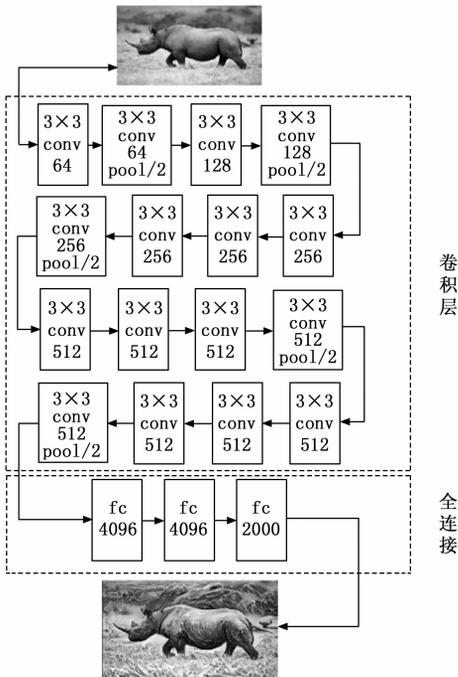


图 3 VGG-19 神经网络图

1) 特征提取。利用卷积神经网络 (VGG19) 提取原始图像和目标风格图像的特征表示, 包括颜色、纹理、形状等特征。

2) 多尺度映射。对原始图像和目标风格图像的特征表示进行多尺度映射, 通过卷积、池化等操作提取每个尺度的特征表示, 为风格转换提供更丰富的信息。

3) 风格匹配。通过计算原始图像和目标风格图像的特征之间的差异, 确定如何调整原始图像的特征表示, 以使其在风格上接近目标图像。

4) 风格重建。基于调整后的特征表示, 通过卷积操作重新构建原始图像, 使其具有目标风格的外观和纹理。

5) 风格转换结果优化。对生成的风格转换图像进行后处理, 如去噪、增强对比度等, 以进一步提升图像质量。

6) 评估效果。评估风格转换算法的效果, 根据评估结果对算法进行调整和优化。

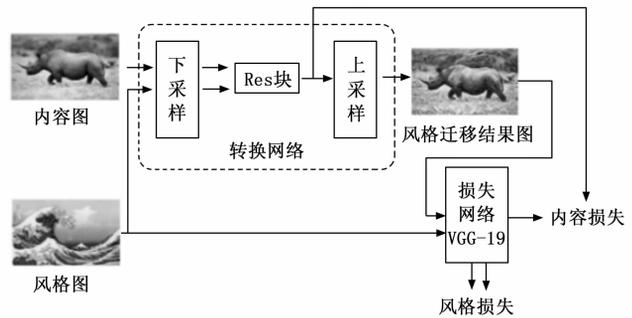


图 4 图像风格转换原理图

2.3 基于卷积神经网络的图像去雾

本模块基于 DehazeNet 算法实现图像的去雾功能, 这是一种用于估计透射率的可训练端到端系统模型, 采用 3 个卷积层和 2 个全连接层来构建恢复模型。DehazeNet 将雾图作为输入, 输出为其透射率, 随后用于反演大气散射模型恢复无雾图像。DehazeNet 采用基于卷积神经网络的深层架构, 其层经过专门设计以生成几乎所有与雾霾相关的特征。在训练过程中, 该算法以加入噪声的雾天图像作为输入, 并利用其对应的无噪声图像进行监督学习。通过反向传播算法, 优化网络参数, 使网络能够生成高质量的去雾结果, 如图 5 所示。

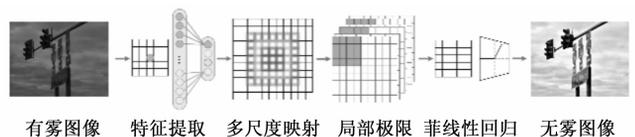


图 5 图像去雾原理图

图像去雾步骤如下:

1) 特征提取。采用卷积层提取雾天图像的颜色信息、边缘信息等特征, 通过卷积操作, 获取雾天图像的

纹理、颜色和形状等特征;

2) 多尺度映射。提取不同尺度的特征表示, 通过卷积、池化等操作提取每个尺度的特征表示;

3) 检测深度信息。通过寻找图像中的极值点, 识别雾天图像中的大气散射深度、背景深度等信息;

4) 去雾。通过学习特征与深度的非线性关系, 去除雾霾, 生成清晰的图像结果。对去雾后的图像进行后处理, 如增强对比度、去除噪声等, 以进一步提升图像质量;

5) 评估效果。评估去雾算法的效果, 根据评估结果对算法进行调整和优化。

2.4 基于生成对抗网络的图像去噪

基于生成对抗网络的图像去噪主要是通过训练生成网络和判别网络来实现。生成网络负责生成与原始图像相似但无噪声的图像, 而判别网络则负责判断输入图像是否真实。具体来说, 生成网络通过学习噪声图像的特征, 并利用这些特征生成新的图像, 从而在一定程度上消除噪声。而判别网络则通过比较输入图像与噪声图像之间的差异, 判断输入图像是否真实, 以辅助训练生成网络。这两个网络在训练过程中相互竞争, 最终生成网络能够生成高质量的图像, 从而达到去噪目的。

图像去噪原理如图 6 所示, 步骤如下:

1) 特征提取。利用生成对抗网络的结构, 通过卷积神经网络提取原始图像的特征, 包括颜色信息、纹理信息、形状信息等。

2) 多尺度映射。对原始图像的特征表示进行多尺度映射, 通过卷积、池化等操作提取每个尺度的特征表示, 为去噪处理提供更全面的信息。

3) 生成对抗训练。设计一个生成器网络, 用于学习如何将含噪声的图像映射到去噪的图像, 同时设计一个判别器网络, 用于判断生成的图像是否真实。通过生成对抗训练不断优化生成器网络和判别器网络。

4) 去噪处理。生成器网络通过学习特征与噪声的非线性关系, 去除图像中的噪声, 生成清晰的图像结果。

5) 后处理优化。对去噪后的图像进行后处理, 如增强对比度、锐化处理等, 以进一步提升图像质量。

6) 评估效果。评估去噪算法的效果, 根据评估结果对算法进行调整和优化。

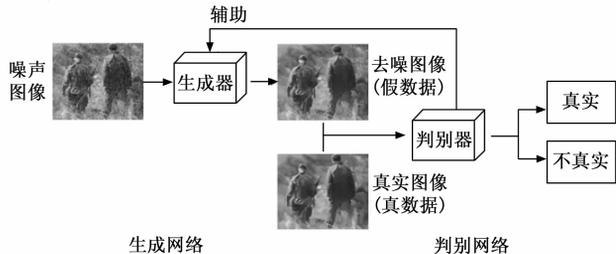


图 6 图像去噪原理图

2.5 基于生成对抗网络的图像抠图

图像抠图技术的核心思想是利用生成对抗网络(GAN)来学习图像的前景和背景, 并实现精确分割图像的前景主体。通过这种方式, 可以将图像中的物体或人物从背景中准确抠出, 实现图像的智能分割和合成。

生成器网络接收输入图像和相应的遮罩(表示要抠取的目标区域), 生成以目标区域为主体的透明化图像。判别器网络用于区分生成器生成的透明图像与真实透明图像之间的差异。在训练过程中, 生成器和判别器相互竞争, 并逐渐提升生成器生成透明图像的质量和准确度。最终生成的透明图像可以用于目标抠图, 将目标区域从原始图像中分离出来, 实现精准的图像抠图效果。这种方法通过生成对抗网络的学习和优化, 将图像抠图任务转化为一个生成器和判别器之间的竞争和对抗过程, 从而实现高质量的图像抠图。用户可以输入包含前景物体的图像, 经生成对抗网络处理后, 得到准确的分割结果, 使得前景物体与背景清晰地分离, 可以方便地进行图像合成或后期编辑处理。

图像抠图原理如图 7 所示, 其步骤如下:

1) 特征提取。使用卷积层提取包含目标物体的原始图像的颜色信息、纹理信息、边缘信息等特征。

2) 多尺度映射。对原始图像中目标物体的特征表示进行多尺度映射, 通过卷积、池化等操作提取每个尺度的特征表示, 为图像抠图提供更全面的信息。

3) 生成对抗训练。设计一个生成器网络以及一个判别器网络, 生成器网络用于学习如何从原始图像中抠出目标物体, 判别器网络用于评估生成的抠图结果是否真实。通过生成对抗训练优化生成器网络和判别器网络。

4) 图像抠图处理。生成器网络通过学习特征与背景的非线性关系, 实现抠出目标物体的效果, 生成干净、准确的抠图结果。

5) 后处理优化。对抠图后的图像进行后处理, 如边缘平滑、去除残留像素等处理, 以进一步提升抠图质量。

6) 评估效果。评估图像抠图算法的效果, 根据评估结果对算法进行调整和优化。

2.6 基于生成对抗网络的图像修复

基于生成对抗网络的图像修复是通过训练生成器与判别器实现的。生成器的目标是通过生成具有缺陷或损

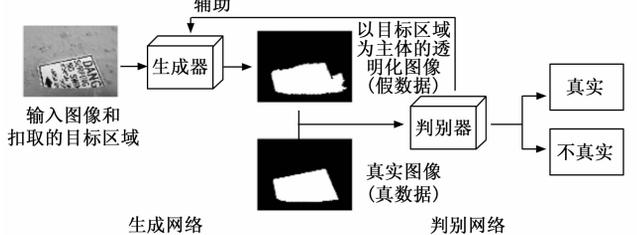


图 7 图像抠图原理图

坏的图像，尽可能准确地恢复原始图像。而判别器则旨在判断给定的图像是真实的原始图像还是由生成器生成的修复图像。首先，生成器接收缺陷图像作为输入，并尝试生成与原始图像相似的修复图像。生成器会逐渐改进其修复图像，以尽可能减少与原始图像之间的差异。然后，生成器生成的修复图像与原始图像一起传递给判别器。判别器的任务是判断给定的图像是真实的原始图像还是由生成器生成的修复图像。判别器接受修复图像和原始图像，并尝试区分这两者。

在训练过程中，生成器和判别器相互竞争并进行不断的迭代优化。生成器通过生成更逼真的修复图像来欺骗判别器，而判别器则通过学习区分修复图像和原始图像来增强自身的准确性。通过这种竞争和迭代的过程，生成器逐渐学习到如何通过填充缺失区域、修复损坏区域或恢复数据来修复图像。同时，判别器逐渐改进其能力，以更好地区分原始图像和生成的修复图像。最终，生成器将能够产生高质量的修复图像，能够准确地修复具有缺陷或损坏的图像，使其尽可能接近原始图像的外观和特征。

图像修复步骤如下：

- 1) 特征提取。使用卷积层提取包含有缺陷或损坏的原始图像的颜色信息、纹理信息、边缘信息等特征。
- 2) 多尺度映射。对原始图像的特征表示进行多尺度映射，通过卷积、池化等操作提取每个尺度的特征表示，为图像修复提供更全面的信息。
- 3) 生成对抗训练。设计一个生成器网络以及一个判别器网络，生成器网络用于学习如何修复图像中的损坏或缺陷，判别器网络用于评估生成的修复结果是否真实。通过生成对抗训练不断优化生成器网络和判别器网络。
- 4) 图像修复处理。生成器网络通过学习特征与损坏区域的非线性关系，修复图像中的缺陷，生成清晰、完整的图像结果。
- 5) 后处理优化。对修复后的图像进行后处理，如去除伪影、增强对比度等处理，以进一步提升图像质量。
- 6) 评估效果。评估图像修复算法的效果，根据评估结果对算法进行调整和优化。

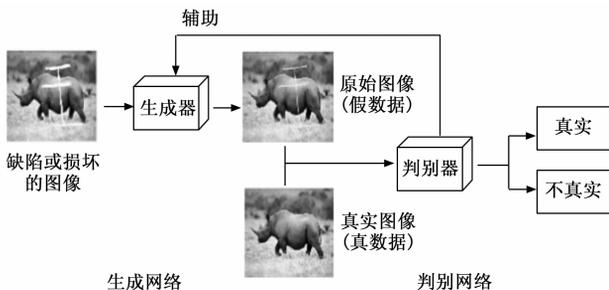


图 8 图像修复原理图

2.7 实验平台搭建

基于上述各个模块的研究、设计，搭建了基于深度学习的数字图像处理实验平台，平台界面如图 9 所示。



图 9 平台界面

平台基于 Python 语言，使用 Tkinter 模块搭建窗口主界面，将上述 6 项功能独立封装至对应名称的 6 个函数中，并通过其对应名称的 button 按钮调用实现功能。

视觉上，作为可供用户使用的软件平台，本平台的界面以及背景是采用 canvas 画布与 turtle 库绘制相结合的方式搭建的。

功能上，通过 tkinter.filedialog 模块下的 askopenfilename 函数实现“选择图片”功能，实现图片的选择，并获取图片的地址，作为图像处理的原始图像。在六个功能按钮中选择需要实现的功能，触发 command 事件，调用对应函数，等待后台处理完成，结果图像以及原始图像会通过 cv2 模块新建画布并弹出窗口展示，并且自动保存至自定义目录。由于图像风格转换需要原始图像和风格图像两个输入图像，因此点击“图像风格转换”按钮后，会继续弹出文件选择界面，选择第二张图片作为风格图像，并完成处理过程。最终通过 tkinter.messagebox 模块下的 showinfo 函数实现关闭程序。

该平台可实现图像超分辨率重建、风格转换、去噪、去雾、修复、抠图等功能。

3 测试结果与分析

为验证平台的有效性，即验证图像超分辨率重建、风格转换、去噪、去雾、修复、抠图等功能，本文选取 Set5 测试集^[22]进行测试。

3.1 测试实验步骤

1) 在已有的深度学习环境中对模型进行训练，在训练好后，考虑到用户不同功能的需求，我们首先对单个任务进行测试，每个任务选择具有代表性的图片作为输入；

2) 按照第 2 节中的步骤对各个功能逐步进行测试。例如图像去雾，分别测试特征提取、多尺度映射、深度信息提取和去雾的效果；在图像风格转换任务中，输入

原始图, 运行功能后选择风格图, 图像修复功能的输入图片导入后, 手动框选修复区域;

3) 在自定义文件夹中获得所有的输出图片, 按照任务功能整理分类; 将这些测试输出图片作为下一个功能的输入图片, 用于测试实现两种及两种以上功能的效果;

4) 对功能进行主观评价和客观评价, 主观评价是通过人为视觉观测, 客观评价主要有 PSNR 和 SSIM; 对完成的测试任务进行封装, 并加入说明性文本来引导用户进行操作。

3.2 测试结果分析

测试结果如图 10~15 所示。

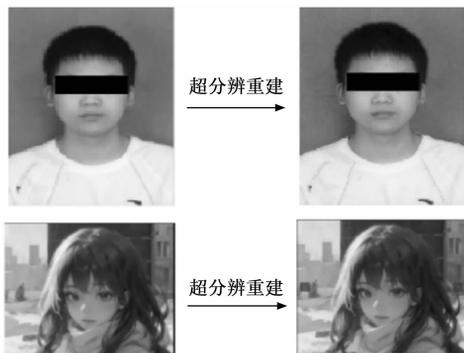


图 10 图像超分辨重建测试结果

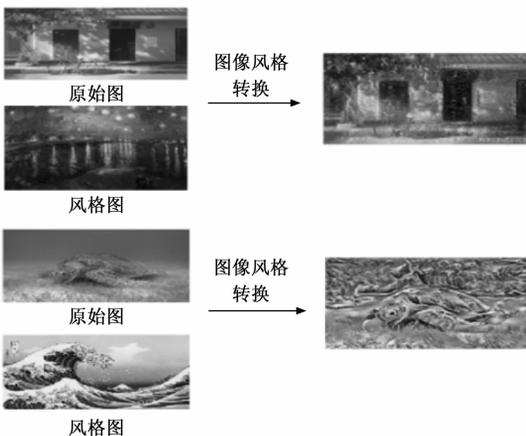


图 11 图像风格转换测试结果

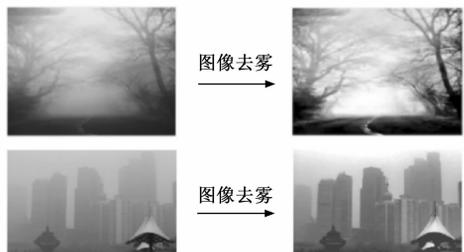


图 12 图像去噪测试结果

为量化图像处理实验平台测试结果, 本文采用峰值信噪比 (PSNR) 和结构相似性指数 (SSIM) 作为图像

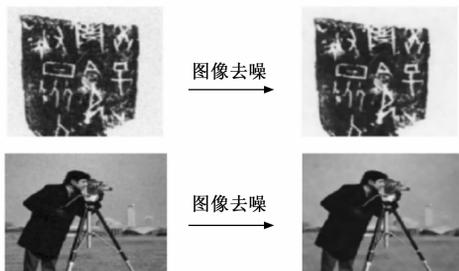


图 13 图像去雾测试结果

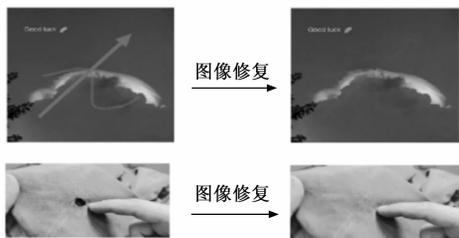


图 14 图像修复测试结果

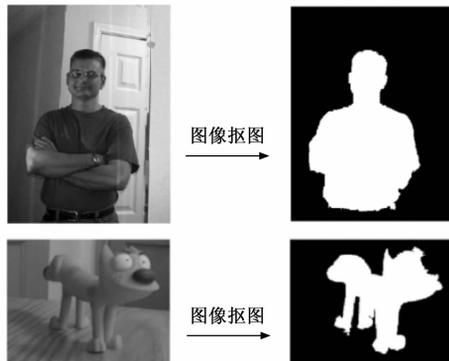


图 15 图像抠图测试结果

质量评价指标, 在各个功能中选取适量图片进行测试, 两种指标的测试结果如图 16 和图 17 所示, 并对测量结果取平均值, 所得评估结果如表 1 所示。

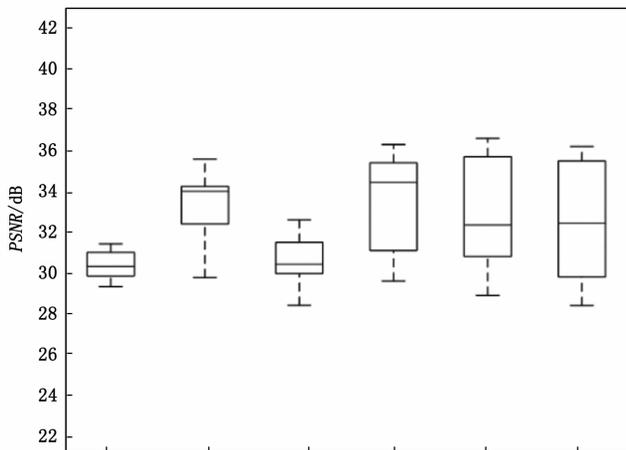


图 16 图像质量评价指标 PSNR

从图 16 可以看出，实现图像超分辨率重建、风格转换、图像去噪等功能时，PSNR 值在 28~36 之间，中位数在 30~34 之间，表明通过该实验平台生成的图像失真较小。

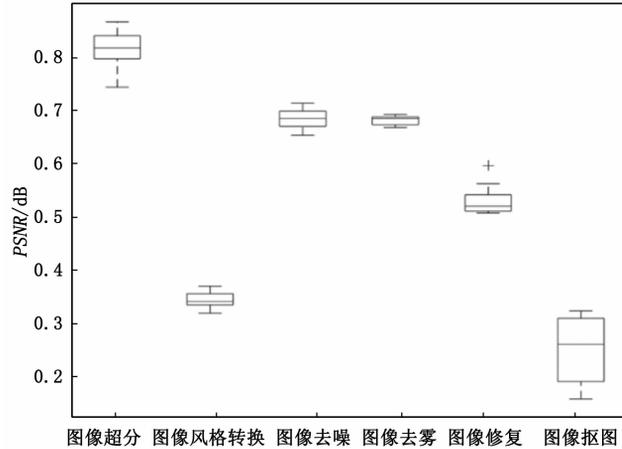


图 17 图像质量评价指标 SSIM

从图 17 可以看出，各项功能的 SSIM 值变化范围较小。图像超分辨率重建的 SSIM 值接近于 1，表明生成的图像与原图非常相似。图像去雾和图像去噪的 SSIM 值反映噪声图像和雾图像的处理程度基本良好。

从表 1 各项功能评价指标的平均值可以看出，通过该实验平台生成的图像失真较小，并且处理后图像的质量在可接受的范围内。这表明了算法在完成图像的功能的同时，还保持了生成图像的质量。

表 1 图片质量评估数据表

功能	图像超分辨率重建	图像风格转换	图像去噪
PSNR	30.04	33.44	30.45
SSIM	0.810 4	0.348 1	0.685 9
功能	图像去雾	图像修复	图像抠图
PSNR	33.22	32.54	32.89
SSIM	0.677 8	0.535 9	0.266 8

在图像超分辨率重建方面，实现了将低分辨率图像恢复为高分辨率图像，提高了图像细节的清晰度和质量。在图像风格转换方面，用户能够将图像转化为具有不同艺术风格的图像，实现个性化的图像效果和风格呈现。在图像去噪方面，能够减少图像中的噪声干扰，提高图像的清晰度和质量。在图像去雾方面，能够去除图像中的雾霾效果，恢复图像的真实视觉效果。在图像修复方面，能够修复图像中的缺失或损坏部分，恢复图像的完整性和可视化效果。在图像抠图方面，能够准确地将前景物体从图像中分离，方便后续的图像处理和分析。

4 结束语

本文针对数字图像处理平台性能不足、处理速度

慢、图像处理质量不理想等问题，基于卷积神经网络和生成对抗网络，搭建了一种现代数字图像处理实验平台，实现了图像超分辨率重建、风格转换、去噪、去雾、修复及抠图 6 项功能，且模块布局清晰操作简便。通过选取大量的图片开展测试，验证了所搭建平台的有效性。研究成果将促进数字图像处理平台的发展。

参考文献：

- [1] 邓建新, 黄秋林, 袁邦颐, 等. 基于边缘重构图像的边缘检测算法优选研究 [J]. 机电工程, 2023, 40 (9): 1441 - 1448.
- [2] 李校林, 王复港, 张鹏飞, 等. 基于多尺度特征提取的 YOLOv5s 算法优化 [J]. 计算机工程与科学, 2023, 45 (6): 1054 - 1062.
- [3] 罗 畅, 王 洁, 王世强, 等. 基于泛化深度迁移特征的高分遥感场景分类 [J]. 系统工程与电子技术, 2018, 40 (3): 682 - 691.
- [4] 张 永, 吕 庚. 双回归网络的单图像超分辨率重建 [J]. 计算机工程与应用, 2022, 58 (18): 277 - 283.
- [5] 刘桂雄, 黄 坚. 基于标签预留 Softmax 算法的机器视觉检测鉴别语义分割迁移学习技术 [J]. 光学精密工程, 2022, 30 (1): 117 - 125.
- [6] DEMBELE A, MWANGI R W, KUBE A O. A light-weight convolutional neural network with hierarchical multi-Scale feature fusion for image classification [J]. Journal of Computer and Communications, 2024, 12 (2): 173 - 200.
- [7] 周飞燕, 金林鹏, 董 军. 卷积神经网络研究综述 [J]. 计算机学报, 2017, 40 (6): 1229 - 1251.
- [8] SHIVANI G, ISHAN B, VIMAL K, et al. A federated calibration scheme for convolutional neural networks: models, applications and challenges [J]. Computer Communications, 2022, 192: 144 - 162.
- [9] 常 亮, 邓小明, 周明全, 等. 图像理解中的卷积神经网络 [J]. 自动化学报, 2016, 42 (9): 1300 - 1312.
- [10] BABU H G, VENKATRAM N. An efficient image dehazing using Googlenet based convolution neural networks [J]. Multimedia Tools and Applications, 2022, 81 (30): 971 - 991.
- [11] 杨锋平, 马博迪, 王金荣, 等. 基于深度去噪自动编码器的无人机航空影像目标检测 [J]. 西北工业大学学报, 2020, 38 (6): 1345 - 1351.
- [12] 李 俊. Sum-Product Networks 模型的研究及其在文本分类的应用 [J]. 电子设计工程, 2016, 24 (24): 42 - 45.
- [13] 李 平, 高清源, 夏 宇, 等. 基于 SE-DR-Res2Block 的声纹识别方法 [J]. 工程科学学报, 2023, 45 (11): 1962 - 1969.
- [14] 李武斌, 李春国, 杨绿溪. 基于 CA-Res2Net 和可变形卷

