

WT-FFDNet: 引入小波卷积的图像去噪网络

刘帅骞

西京学院电子信息学院, 陕西 西安

收稿日期: 2025年3月18日; 录用日期: 2025年4月16日; 发布日期: 2025年4月25日

摘 要

本文提出一种将小波变换引入FFDNet的图像去噪方法WT-FFDNet。WT-FFDNet通过结合深度可分离的小波变换卷积模块DepthwiseSeparableConvWithWTConv2d (DpSeWTConv), 利用多级小波分解提取图像的低频和低频特征, 进行特征融合。网络进一步通过VGGBlock和结合通道注意力机制的ResNetBlock实现多尺度特征提取。在Berkeley Segmentation Dataset 500数据集上分别测试15、35、50、70噪声强度下的PSNR值, 经过改进后的网络, 其PSNR指标较原FFDNet网络有所提高, 又在CBSD68、Urban100等数据集上测试不同噪声强度下的PSNR和SSIM指标, 经过实验验证了该方法的有效性。

关键词

小波变换, FFDNet, 图像去噪, 深度可分离卷积

WT-FFDNet: Image Denoising Network with Wavelet Convolution

Shuiqian Liu

School of Electronic Information, Xijing University, Xi'an Shaanxi

Received: Mar. 18th, 2025; accepted: Apr. 16th, 2025; published: Apr. 25th, 2025

Abstract

This paper proposes a wavelet-transform-integrated FFDNet method for image denoising, named WT-FFDNet. The WT-FFDNet incorporates a Depthwise Separable Convolution with Wavelet Transform module (DpSeWTConv) to achieve multi-level wavelet decomposition, extracting both low-frequency and high-frequency features of images for feature fusion. The network further implements multi-scale feature extraction through VGGBlocks and ResNetBlocks integrated with channel attention mechanisms. Experimental results on the Berkeley Segmentation Dataset 500 (BSD500) demonstrate improved PSNR metrics compared to the original FFDNet under noise levels of 15, 35,

50, and 70. Additional evaluations on datasets including CBSD68 and Urban100 across various noise intensities confirm enhancements in both PSNR and SSIM metrics, validating the effectiveness of the proposed method.

Keywords

Wavelet Transform, Fast and Flexible Denoising Network, Image Denoising, Depthwise Separable Convolution

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

图像去噪(Image Denoising)是图像处理中的核心任务之一,在医学影像诊断、视频监控、卫星遥感、数字摄影等领域广泛应用[1]。噪声影响图像质量,且影响图像分析等任务,因此,图像去噪是计算机视觉需要研究的问题[2]。

根据去噪方式的不同图像去噪分为传统方法与深度学习方法。传统方法以 BM3D 算法为代表[3],其通过非局部相似块的三维变换域协同滤波抑制高斯噪声,非局部均值滤波则利用图像自相似性进行加权平均,此类方法虽在特定噪声去除中有效,但普遍面临边缘退化与计算复杂度高的问题[4]。

深度学习领域[5],DnCNNs 首次将残差学习引入去噪网络[6],FFDNet 通过噪声水平映射实现自适应去噪[7],但是对高频噪声的提取能力不足,可能导致细节效果不佳,且依赖合成高斯噪声数据进行训练,真实场景去噪性能受限。CBDNet 提出结合噪声估计与非盲去噪子网络,通过非对称学习和真实噪声建模提升真实图像去噪效果[8]。

本文提出了一种改进图像去噪方法小波变换增强的 FFDNet (Fast and Flexible Denoising Network),简称为 WT-FFDNet。将小波变换卷积(WTConv2d)引入 FFDNet,通过多尺度小波变换提取图像的低频和高频特征,从而增强网络对噪声的处理能力[9]。结合深度可分离卷积(Depthwise Separable Convolution)进一步降低计算复杂度,提升去噪效率。

2. 网络改进介绍

2.1. FFDNet 介绍

FFDNet 是一种基于卷积神经网络的图像去噪方法,网络首先将输入的噪声图像与噪声水平参数拼接,形成多通道输入,通过一系列卷积层提取特征,最终输出恢复的干净图像[10]。

输入的图像进行预处理,原始的噪声图像经过下采样生成 4 个子图,形成多通道输入,宽度和高度尺寸缩小为原图的 1/2。将噪声水平扩展为噪声图与下采样后的图拼接,作为输入通道。

网络结构主体由多组卷积网络组成,第一层: Conv + ReLU 组合,中间层: Conv + Batch Normalization + ReLU,最后一层: Conv 层。FFDNet 采用轻量化的 U-Net 结构,使用 3×3 卷积核减少参数量。网络的参数通过正交矩阵初始化。网络能处理噪声水平[0, 75]的高斯噪声,不需要根据不同噪声的级别训练不同的模型。FFDNet 使用残差学习的思想,直接预测噪声残差,不预测干净图像本身,通过上述卷积层组实现噪声特征到干净特征的映射。

最后,通过上采样和残差连接重建去噪图像,将得到的低分辨率特征图恢复至原始尺寸,保证与输

入图像尺寸一致。

2.2. 网络的整体设计

本文设计的 WT-FFDNet 模型利用小波变换的多尺度分析能力, 能够有效地捕获噪声图像中的不同细节特征。为了在提升性能的同时保持计算效率, 模型采用深度可分离卷积替代标准卷积操作, 有效地降低了计算的复杂度, 同时保持了模型的表达能力。此外, WT-FFDNet 还结合了通道注意力机制, 使网络能够自适应地增强重要特征的权重, 从而提高特征表达的有效性。模型还采用了多尺度特征提取策略, 通过在不同尺度上提取和融合特征, 提高对不同尺度噪声的适应性和鲁棒性。

网络的整体工作流程, 原始图像数据经 OpenCV 读取并转换为适当的通道格式, 使用缩放因子(1.0, 0.9, 0.8, 0.7)生成多分辨率图像。利用窗口 50×50 (patch_size = 50)和步长 100 (stride = 100)进行切块, 每个补丁通过 aug_times 的值控制数据增强程度, 最终存储为.h5 文件, 分别用于训练集和验证集。数据加载时, 每个批次从 HDF5 文件中提取原始图像补丁, 并动态添加高斯噪声。接着, 通过 concatenate_input_noise_map 将噪声图像与其噪声标准差拼接, 作为输入。输入数据经过 VGGBlock 提取初步特征, 其中 VGGBlock 由两层 3×3 卷积 + BatchNorm + ReLU 组成, 以增强局部特征表达能力。随后, ResNetBlock 进一步提升特征提取能力, 使用跳跃连接(skip connection)保留关键信息, 并通过 Squeeze-and-Excitation (SE)模块自适应调整通道权重, 突出重要特征。在降噪过程中, 模型使用 db2 小波基进行小波分解, 将输入特征分解为低频分量(LL)和高频分量(LH, HL, HH)。高频分量易受噪声影响, 使用 DepthwiseSeparableConvWithWTConv2d 进行处理, 以抑制噪声相关特征。随后, 从最后 1 级到第 1 级逐层进行小波逆变换(inverse_wavelet_transform), 将校准后的高频分量与低频分量拼接, 恢复完整的特征图。最后, UpSampleFeaturesFunction 采用反卷积(F.conv_transpose2d)进行上采样, 使特征图恢复至原始输入尺寸, 并细化高频细节, 确保边缘与纹理信息对齐。该网络不直接预测干净图像, 而是预测噪声分量, 最终的去噪结果通过残差计算(输入图像 - 预测噪声)得到, 使模型能适应不同的噪声水平。网络整体架构图如图 1 所示, 其中 DpSeWTConv 为 DepthwiseSeparableConvWithWTConv2d 的缩写。




Figure 1. Overall Architecture of the WT-FFDNet Network

图 1. WT-FFDNet 网络整体架构图

2.3. 小波变换

小波变换是一种时频分析工具, 能将信号分解为不同频率和时间尺度的小波系数。在图像处理方面, 小波变换可以将图像分解为低频和三个方向的高频细节特征, 分别对应水平、垂直和对角线方向的细节特征信息。其多尺度、多方向的分解特性使小波变换在捕获图像的局部和全局特征方面比传统卷积具有优势, 对于同一张图片使用小波卷积和普通卷积进行特征提取, 观察得到小波卷积能提取更多的细节特征, 如图 2 所示。

传统卷积神经网络通过堆叠卷积层逐步提取特征, 但在处理多尺度信息时存在局限性。小波变换能在一次操作中实现多尺度分解, 分解为 4 个方向的分量, 为 CNN 提供了更丰富的特征表示。此外, 小波

变换的正交性保证分解的信息接近无损分解，有助于保留图像的细节信息。将小波变换与 CNN 结合，能同时利用小波变换的多尺度分析能力和 CNN 的非线性特征提取能力，两者形成互补优势。




Figure 2. Feature extraction comparison between wavelet convolution and ordinary convolution
图 2. 小波卷积与普通卷积特征提取对比图




Figure 3. Depthwise separable wavelet convolution architecture
图 3. 深度可分离小波卷积架构图

在 FFDNet 的基础上引入小波变换卷积(WTConv2d)，通过多尺度小波分解增强特征提取能力[11]。整个处理过程是：“先分解，再重建”。利用 PyWavelets 库，根据参数 `wt_type` 设置小波基的类型，参数 `wt_levels` 设置小波分解的级数，生成相应的分解滤波器 `dec_filters` 和重构滤波器 `rec_filters`。分解滤波器将输入特征图分解成低频和高频成分；而重构滤波器则用于将各个子带的信息经过处理后重新合成。通过卷积操作将输入特征图下采样，获得四个子带(LL, LH, HL, HH)的系数。为提高特征表达能力，模块采用多层级(`wt_levels` 参数控制)的小波分解，对低频部分进行迭代处理。在每一级中，将得到的小波系数进行重新排列后，通过专门设计的局部卷积和缩放操作(`_ScaleModule`)，对系数进行微调，增强特征表达。将处理后的低频和高频系数重新组合，通过逆小波变换实现上采样重构，从而获得增强后的特征图。

除了小波分解重构分支外，WTConv2d 模块还保留了一条基于常规深度卷积(depthwise convolution)的路径，对原始输入进行特征提取。最终将基础卷积与小波变换分支输出的特征进行特征融合。DepthwiseSeparableConvWithWTConv2d 卷积整体架构图如图 3 所示。

2.4. 深度可分离卷积

深度可分离卷积(Depthwise Separable Convolution)是一种轻量化的卷积，将特征提取与特征融合分开，降低了计算的复杂度[12]。传统卷积与深度可分离卷积的参数量和计算量的对比如下表 1。其中 C_{in} 和 C_{out} 分别是输入通道和输出通道，卷积核大小为 $K \times K$ 。

Table 1. Comparison of parameter quantities
表 1. 参数量对比表

卷积类型	参数量公式
标准卷积	$C_{in} \times C_{out} \times K \times K$
深度卷积	$C_{in} \times K \times K$
逐点卷积	$C_{in} \times C_{out}$
深度可分离卷积总计	$C_{in} \times K \times K + C_{in} \times C_{out}$

深度可分离卷积的思路是将标准卷积分为两个步骤：首先，通过深度卷积对每个通道进行空间卷积。再通过逐点卷积对不同通道进行特征进行融合。深度可分离卷积架构如图 4 所示。




Figure 4. Depthwise separable convolution architecture
图 4. 深度可分离卷积架构图

在 WT-FFDNet 中，将小波变换和深度可分离卷积，用 WTConv2d 替换传统深度卷积形成 DepthwiseSeparableConvWithWTConv2d。

2.5. VGGBlock 与 ResNetBlock

VGGBlock 模块的核心是连续重复的多个 3×3 卷积层，每个卷积层后接归一化和 ReLU 激活函数。该模块在设计上没有池化操作，保持了输入特征图的空间分辨率。先通过一个 3×3 卷积(padding = 1)，接着 BN 层和 ReLU 激活函数，以提取初步特征。再通过一个相同结构的 3×3 卷积层及其对应的 BN 和 ReLU，进一步加强特征表达能力。VGGBlock 结构图如图 5 所示。

ResNetBlock 模块是根据残差学习的思想设计而来，通过引入跳跃连接缓解深层网络的训练难题。在基础卷积块的基础上，模块中增加融合了通道注意力机制——Squeeze-and-Excitation (SE) 模块，自适应地调整各通道的重要程度，增强网络对关键特征的感知力。模块由两个连续的 3×3 卷积层组成，每个卷积后有 BN 层和 ReLU 激活函数。其中，第一个卷积层用于初步特征提取，第二个卷积层进一步提炼特征。在第二个 BN 层后，通过 Squeeze-and-Excitation 机制对卷积输出的通道进行加权调整。该模块内部使用一个缩减比例来降低特征维度，再经过激活和扩展操作，得到每个通道的权重，进而强调重要特征。原始输入通过直接跳跃连接与经过卷积和 SE 调整后的特征进行逐元素相加，随后经过 ReLU 激活。缓解深层网络训练中梯度消失的问题，ResNetBlock 结构如图 5 所示。




Figure 5. VGGBlock and ResNetBlock structures

图 5. VGGBlock 与 ResNetBlock 结构图

3. 实验验证与分析

3.1. 数据集

Urban100、Set12、Kodak24、CBSD68 和 BSDS500 是计算机视觉领域常用的基准测试集。Urban100 包含 100 张高分辨率城市场景图像(500~1500 像素)，其建筑结构和密集纹理用于检验模型对几何结构的重建能力。Set12 作为轻量级测试集，包含 12 张典型自然图像(约 512×512 像素)，用于不同噪声强度下的去噪算法横向对比。Kodak24 数据集的 24 张 sRGB 图像(768×512 像素)因自然色彩过渡和细腻场景细节，成为图像去噪任务的常用数据集。CBSD68 为 68 张彩色自然图像(平均约 481×321 像素)，验证算法对彩色图像细节的保留效果。BSDS 500 有 500 张多样化的高质自然图像，对模型进行综合测试。

3.2. 网络训练环境和参数设定

使用 kaggle 线上环境，GPU 是 NVIDIA Tesla P100，显存为 16G、CPU 是 Intel Xeon，Python 版本为 3.10，深度学习框架为 pytorch，其为版本 2.5.1，训练环境说明如表 2 所示。在网络训练过程中使用 Adam

优化器，均方误差损失函数(MSE)进行优化，参数 **betas** 保持默认设置，初始学习率设为 1×10^{-3} ，通过分阶段调整策略：当训练轮次超过 50 时降为 1×10^{-4} ，超过 60 轮次后降为 1×10^{-6} 。训练过程采用批量大小为 64 的配置，共进行 90 个训练周期，每 10 个迭代保存一次中间结果，每 5 个周期保存完整检查点。噪声强度参数设置为动态范围[0, 75/255]，验证时使用固定噪声强度。模型正则化为每 10 次迭代执行一次滤波器正交化操作，通过 SVD 分解保证卷积核的正交性。

Table 2. Training environment description
表 2. 训练环境说明表

配置	说明
平台	Kaggle
CPU	Intel Xeon
GPU	NVIDIA Tesla P100
框架和语言	Pytorch2.5.1+Python3.10

3.3. 评价指标

PSNR 中文简称峰值信噪比，它是图像质量评价指标，用于评估原始图像与去噪后的图像的还原程度，PSNR 越高说明去噪效果越好。PSNR 的计算公式如下：

$$\text{PSNR} = 10 \cdot \log_{10} \left(\frac{\text{MAX}^2}{\text{MSE}} \right)$$


MAX 为图像中像素的可能最大值。MSE 为均方误差是原始图像与去噪后图像之间的像素值差异的平均值。其计算公式如下：

$$\text{MSE} = \frac{1}{M \cdot N} \sum_{i=1}^M \sum_{j=1}^N [I_1(i, j) - I_2(i, j)]^2$$

其中， $I_1(i, j)$ 和 $I_2(i, j)$ 分别代表原始图像和处理后图像在位置 (i, j) 的像素值， M 和 N 是图像的宽度和高度。

3.4. 实验结果

在 Berkeley Segmentation Dataset 500 数据集测试原模型与改进模型的 PSNR 值对比，对比结果如图 6 所示。






Figure 6. PSNR comparison between improved model and original model

图 6. 改进模型与原模型 PSNR 对比图

在不同数据集上对比不同方法在相同噪声强度下的性能，本文方法在高噪声强度下超越了前面模型，对比结果如表 3 所示。

Table 3. PSNR comparison of different methods at the same noise intensity

表 3. 不同方法在相同噪声强度 PSNR 值对比表

噪声强度	数据集	NLDD	NLB	BM3D	DnCNN	WT-FFDNet
15	CBSD68	33.16	33.14	33.45	33.89	33.28
	Kodak24	33.93	33.84	34.19	34.48	34.46
	Urban100	-	-	-	-	33.28
35	CBSD68	29.08	28.77	28.95	29.58	29.27
	Kodak24	30.04	29.64	29.98	30.46	30.48
	Urban100	-	-	-	-	29.27
70	CBSD68	25.86	25.79	25.86	-	26.35
	Kodak24	26.86	26.76	26.91	26.96	26.96
	Urban100	-	-	-	-	26.11

在 cbsd68、urban100、kodak 测试集测试模型的去噪性能，各测试集的 PSNR 和 SSIM 值如表 4 所示。

Table 4. PSNR/SSIM results on different datasets

表 4. 不同数据集的 PSNR/SSIM 值结果表

数据集	噪声强度			
	15	35	50	70
CBSD68	33.2821/0.9110	29.2787/0.8126	27.7245/0.7120	26.3574/0.6452
Urban100	33.2800/0.9439	29.2766/0.8991	27.7565/0.8363	26.1116/0.7842
Kodak24	34.4618/0.9098	30.4872/0.8453	28.5032/0.7715	26.9652/0.7166

4. 结语

综上所述，本研究通过将小波变换与 FFDNet 结合，形成图像去噪网络 WT-FFDNet。小波变换卷积模块(WTConv2d)通过多级分解 - 重构机制，能分离高频噪声与低频结构特征；引入深度可分离卷积与通

道注意力机制, 进一步提升网络的性能; 动态噪声输入与残差学习的使用, 单个模型可覆盖 0~75 强度宽域噪声, 降低模型的训练投入。实验表明, 该方法在 CBSD68、Urban100 等数据集上 PSNR 指标均提升。

参考文献

- [1] 刘迪, 贾金露, 赵玉卿, 等. 基于深度学习的图像去噪方法研究综述[J]. 计算机工程与应用, 2021, 57(7): 1-13.
- [2] 张阿松. 关于图像去噪的综述及优化模型的提出[J]. 图像与信号处理, 2024, 13(2): 138-150.
- [3] 樊华, 王文旭, 李晓阳, 等. 结合非下采样剪切波变换的 BM3D 去除图像噪声方法研究[J]. 震灾防御技术, 2023, 18(3): 651-663.
- [4] 陈雅玲, 童莹, 何睿清, 等. 基于改进 BM3D 的乳腺超声图像去噪算法研究[J]. 软件导刊, 2024, 23(3): 121-127.
- [5] 张娜娜, 张媛媛, 丁维奇. 经典图像去噪方法研究综述[J]. 化工自动化及仪表, 2021, 48(5): 409-412, 423.
- [6] 侯禹存, 宋辉. 基于小波变换的改进 DnCNN 网络的遥感图像去噪[J]. 计算机测量与控制, 2022, 30(6): 216-221.
- [7] 吴文聪. 基于卷积神经网络的图像去噪方法研究[D]: [硕士学位论文]. 昆明: 云南师范大学, 2023.
- [8] 朱晏梅, 林国军. 基于卷积神经网络的真实图像去噪算法[J]. 成都工业学院学报, 2024, 27(6): 45-50, 62.
- [9] 樊超, 王帆. 可解释的小波卷积神经网络机械故障诊断方法[J/OL]. 振动工程学报: 1-9.
<http://kns.cnki.net/kcms/detail/32.1349.TB.20241101.1704.006.html>, 2025-04-22.
- [10] Zhang, K., Zuo, W. and Zhang, L. (2018) FFDNet: Toward a Fast and Flexible Solution for CNN-Based Image Denoising. *IEEE Transactions on Image Processing*, 27, 4608-4622. <https://doi.org/10.1109/tip.2018.2839891>
- [11] Ben-Sira, Y., Schwartz, E. and Cohen, N. (2024) Wavelet Convolutions for Large Receptive Fields. arXiv: 2407.05848.
- [12] 郑丹, 宋思楠, 贺强. 深度学习中深度可分离卷积网络在遥感图像分类中的优化[J]. 信息系统工程, 2024(10): 132-135.