

基于径向先验与残差学习的畸变校正方法

贾丰毓, 杨海波*

沈阳工业大学信息科学与工程学院, 辽宁 沈阳

收稿日期: 2026年4月1日; 录用日期: 2026年5月2日; 发布日期: 2026年5月12日

摘要

图像畸变是广角镜头、鱼眼镜头等大视场成像系统的固有缺陷, 直接影响后续计算机视觉任务的精度。针对现有畸变校正方法物理先验缺失且难以应对透镜装配误差等非理想畸变的问题, 文章提出一种基于径向先验与残差学习的畸变校正方法。该方法采用双分支解耦设计: 径向物理分支利用物理模型约束, 通过Brown-Conrady模型校正主要的桶形或枕形畸变, 保证几何结构的整体正确性; 残差修正分支利用数据驱动优势, 通过U-Net架构预测高频非刚性位移场, 精准补偿装配误差与非对称畸变。双分支通过位移场逐像素叠加与可微网格采样实现端到端联合优化。实验结果表明, 本方法PSNR为24.49 dB、SSIM为0.9145, 直线偏差为1.81 px, 为视觉测量场景下的图像畸变校正提供了可靠的技术方案。

关键词

畸变校正, 深度学习, 视觉测量

Distortion Correction Method Based on Radial Prior and Residual Learning

Fengyu Jia, Haibo Yang*

School of Information Science and Engineering, Shenyang University of Technology, Shenyang Liaoning

Received: April 1, 2026; accepted: May 2, 2026; published: May 12, 2026

Abstract

Image distortion is an inherent defect of wide-field imaging systems, such as wide-angle and fisheye lenses, which directly impacts the accuracy of subsequent computer vision tasks. To address the limitations of existing distortion correction methods, which lack sufficient physical priors and struggle with non-ideal distortions such as lens assembly errors, this paper proposes a distortion correction method based on radial prior and residual learning. The approach employs a dual-branch

*通讯作者。

decoupling design: the radial physical branch leverages physical constraints, using the Brown-Conrady model to correct primary barrel or pincushion distortions, thereby ensuring the overall geometric consistency of the structure; the residual correction branch capitalizes on data-driven advantages, employing a U-Net architecture to predict high-frequency non-rigid displacement fields, which accurately compensate for assembly errors and asymmetric distortions. The two branches are jointly optimized end-to-end through pixel-wise displacement field superposition and differentiable grid sampling. Experimental results show that the proposed method achieves a PSNR of 24.49 dB, an SSIM of 0.9145, and a line deviation of 1.81 px, providing a reliable technical solution for image distortion correction in visual measurement scenarios.

Keywords

Distortion Correction, Deep Learning, Visual Measurement

Copyright © 2026 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

镜头畸变是计算机视觉相机标定与精密视觉测量领域的共性核心问题。受镜片加工公差、镜头模组装配偏心、光学折射偏差及成像传感器对位误差等因素影响, 图像会出现像素位置偏移、规则网格扭曲、直线形变等几何失真, 直接破坏三维物理空间与二维像素图像的标准投影映射关系, 大幅降低特征匹配精度与相机标定可靠性, 最终影响尺寸检测、点位校准等工程任务的测量准确性。传统固定参数畸变校正方法依赖标准标定板离线拟合, 场景、镜头安装状态发生微小变化即会失效; 纯深度学习校正方案虽拟合能力强, 但普遍缺少光学物理先验约束, 易出现几何失真、直线偏移, 难以满足高精度测量任务的刚性要求。因此, 构建兼具物理可解释性与精细残差补偿能力的畸变校正算法, 是提升复杂现场相机标定精度的关键。

本文旨在解决上述挑战, 提出一种基于径向先验与残差学习的畸变校正方法, 在无需精确相机标定的前提下, 融合径向物理先验的可解释性与残差学习的精细拟合能力, 兼顾校正精度、泛化性与推理效率。主要贡献包括:

- 1) 提出径向先验与残差学习融合的双分支校正架构, 依托经典畸变物理模型实现全局径向畸变粗校正, 保障成像几何结构严谨性;
- 2) 引入 U-Net 残差分支构建像素级位移场, 精准补偿物理模型无法描述的非对称畸变、装配误差与局部波浪纹畸变;
- 3) 设计多约束复合损失函数, 融合像素保真、边缘梯度与残差平滑约束, 实现端到端可微优化, 在合成数据集与真实工业场景下均实现高精度畸变校正, 兼顾泛化能力与几何保真度。

2. 相关工作

镜头畸变由光学透镜固有属性与成像工艺误差共同引发, 表现为像素偏移与几何形变, 是制约视觉测量与图像匹配精度的关键瓶颈。为消除此类误差, 畸变校正技术需同时满足几何保真度与计算鲁棒性两大要求, 现有方案主要分为传统模型驱动与深度学习驱动两大类。

2.1. 传统畸变校正方法

传统方法基于几何光学模型与数学优化, 通过拟合畸变参数实现校正。在模型构建方面, Chi 等人[1]

提出混合结构模型, 采用全局固定模型与局部随机模型结合的多层回溯策略, 有效补偿非均匀畸变; 王翊等人[2]针对鱼镜头的短焦距设计引发的径向畸变问题, 提出了基于抛物面模型的参数修正鱼眼图像校正算法, 通过改进的逐行逐列扫描法进行有效区域提取, 根据校正效果修正模型参数后再次校正, 有效改善了鱼眼图像的校正质量。Wang 等人[3]基于单应性映射构建透视变换模型, 同时处理非线性畸变与透视变形。在参数求解优化方面, Kang [4]提出“径向畸变 snake”半自动求解策略, Alvarez 等[5]采用代数方法高效拟合系数; Zhang [6]与 Li 等[7]借助极线几何约束求解畸变参数。

2.2. 基于深度学习的畸变校正方法

深度学习技术凭借强大的特征拟合能力, 成为复杂畸变校正的主流方向。生成对抗网络(GAN)为无监督校正提供新思路, 如 DR-GAN [8]引入低到高感知损失, 实现端到端的无标签径向畸变校正; CanopyGAN [9]结合改进 U-Net 与小波增强注意力块(WEAB), 显著降低均方根误差。卷积神经网络(CNN)及其变体(如 U-Net [10])因优异的像素级回归能力被广泛应用, Xue 等人[11]提出线感知校正网络, 融合传统先验与深度网络, 通过三阶段串行模块实现鱼眼畸变端到端校正, 在自建合成线条鱼眼数据集上获 0.33 像素的平均重投影误差。Li 等人[12]提出了能够自动校正单张输入图像中多种几何畸变的通用框架, 通过模型拟合方法对 CNN 输出的位移场进行参数化估计, 最终通过高效重采样生成校正图像, Yang 等人[13]针对鱼眼图像畸变分布不均匀的特点, 提出了环形切片方法, 确保了每个切片内部畸变的一致性, 从而降低了网络训练难度。

3. 本文方法

3.1. 模型网络结构

本网络采用双分支解耦设计, 旨在同时处理大尺度的径向畸变与复杂的非刚性局部变形, 模型网络结构如图 1 所示。

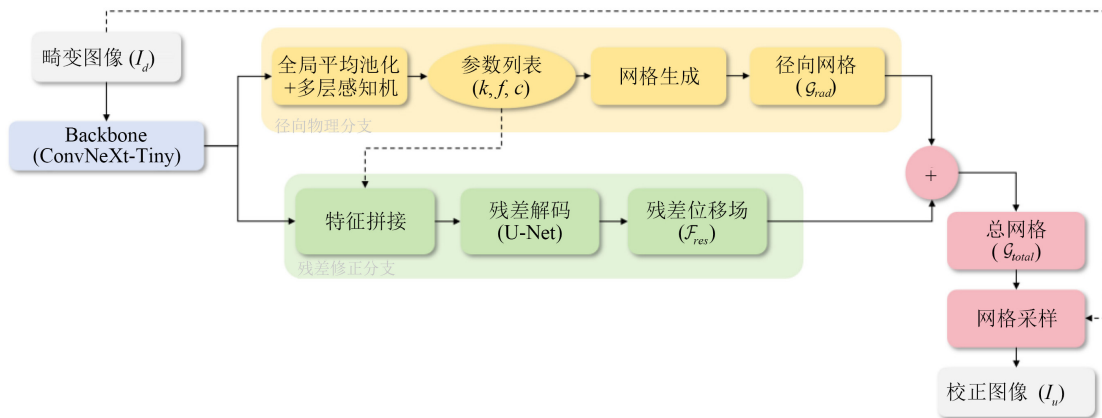


Figure 1. Model network structure diagram
图 1. 模型网络结构图

网络以畸变图像为输入, 通过共享的 Backbone (ConvNeXt-Tiny)提取多尺度特征。上方为径向先验模块(Radial Prior Module), 利用物理参数回归预测 Brown-Conrady 畸变系数并构建刚性采样网格, 以捕捉主要几何结构; 下方残差学习模块(Residual Learning Module), 通过 U-Net 结构并以物理参数为条件, 预测高频非刚性位移场以补偿装配误差与非对称畸变。最终通过位移场叠加生成总采样网格, 并利用可微网格采样(Grid Sample)直接输出校正图像。

3.2. 径向物理分支

径向物理分支旨在利用光学物理定律解决主要的径向畸变问题。传统方法中, 畸变系数由标定得到, 无法适配动态场景, 本文将其设计为可学习参数, 通过多层感知机(MLP)编码径向特征实现自适应预测。

1) 径向畸变物理模型

对于畸变图像中的任意像素, 其畸变前后的坐标转换遵循经典径向畸变模型。无畸变图像像素坐标为 (x, y) , 畸变图像像素坐标为 (x_d, y_d) , 径向距离为 $r = \sqrt{x^2 + y^2}$ 。畸变过程的坐标映射关系为:

$$\begin{cases} x_d = x \cdot (1 + k_1 r^2 + k_2 r^4 + k_3 r^6) \\ y_d = y \cdot (1 + k_1 r^2 + k_2 r^4 + k_3 r^6) \end{cases} \quad (1)$$

校正过程需反向求解无畸变坐标, 对式(1)变形得:

$$\begin{cases} x = \frac{x_d}{1 + k_1 r_d^2 + k_2 r_d^4 + k_3 r_d^6} \\ y = \frac{y_d}{1 + k_1 r_d^2 + k_2 r_d^4 + k_3 r_d^6} \end{cases} \quad (2)$$

其中, $r_d = \sqrt{x_d^2 + y_d^2}$ 表示畸变图像中的径向距离。

2) 径向物理分支设计

输入全局特征 $F_3 \in \mathbb{R}^{\frac{H}{32} \times \frac{W}{32} \times C}$, 经过 MLP 得到参数列表 $\theta = \{k_1, k_2, k_3, f_x, f_y, c_x, c_y\}$, 其中 k_1, k_2, k_3 为径向畸变系数, 决定了桶形或枕形畸变的程度; f_x, f_y, c_x, c_y 为相机内参, 决定了光心的位置和焦距缩放。基于可微分的 Brown-Conrady 模型, 对于目标图像上的每个像素坐标 (u, v) , 计算其在畸变图像上的对应位置 (u_d, v_d) , 由此生成的网格记为 \mathcal{G}_{rad} , 此过程完全可微分, 梯度可直接回传至回归头, 实现端到端训练。该方法通过物理模型约束, 保证全局几何一致性, 又通过可学习参数实现了对不同相机与场景畸变模式的自适应适配, 突破了传统标定方法在泛化能力上的限制。径向物理分支设计如图 2 所示。




Figure 2. Radial physical branch design
图 2. 径向物理分支设计

3.3. 残差修正分支

残差修正分支是本文架构中至关重要的组成部分, 其核心使命是弥补物理模型在描述复杂真实世界畸变时的局限性。虽然径向物理分支能够基于 Brown-Conrady 模型高效地校正主要的桶形或枕形畸变, 但实际成像系统往往受限于制造工艺和组装误差, 表现出难以用简单参数化公式描述的非理想特性, 例如透镜光轴与传感器平面的非垂直对齐导致的切向畸变、透镜组内部的偏心误差以及成像传感器本身的微小形变。这些因素共同作用, 在图像中引入了非对称的几何扭曲和局部的波浪状位移场。

残差修正分支采用了基于 U-Net 架构的编解码器结构, 并引入了条件参数注入(Conditional Parameter Injection)机制。该分支将径向分支预测得到的 7 维物理参数向量 $\theta = \{k_1, k_2, k_3, f_x, f_y, c_x, c_y\}$ 视为一种全局

几何先验(Global Geometric Prior)。在特征提取阶段, 共享主干网络已经生成了多尺度的特征金字塔 $\{F_0, F_1, F_2, F_3\}$ 。为了让残差网络知晓当前的物理校正状态, 将参数向量进行空间广播, 即将其复制扩展为与 F_3 具有相同空间分辨率的特征图 $M_\theta \in \mathbb{R}^{\frac{H}{32} \times \frac{W}{32} \times 7}$ 。

随后将扩展后的物理特征图 M_θ 与高层特征 F_3 在通道维度上进行拼接, 得到融合特征 F_m 。这一注入操作的物理意义在于, 它为残差网络提供了一个明确的参考坐标系。网络不再是盲目地从零开始预测位移场, 而是基于已知的物理畸变参数来推断剩余的误差分布。残差修正分支设计如图 3 所示。

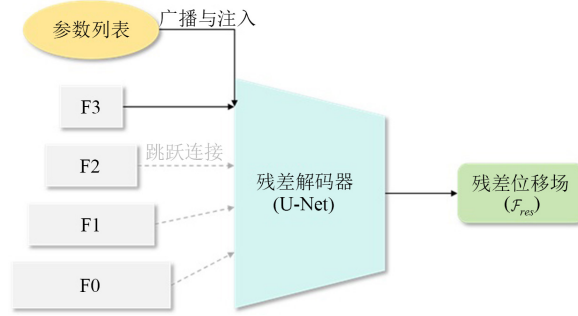


Figure 3. Residual correction branch design
图 3. 径向物理分支设计

最终的校正过程是一个物理与数据驱动的融合过程。将径向物理分支生成的全局基础采样网格与残差修正分支预测的微调位移场进行逐像素叠加, 得到最终的高精度采样网格。这种加性融合方式保证了校正结果的可解释性和鲁棒性。在解码阶段, 融合特征 F_m 被送入一系列上采样模块(Upsampling Blocks)。每个模块包含转置卷积(Transposed Convolution)或双线性插值操作, 用于逐步恢复特征图的空间分辨率。为了保留图像的细节纹理信息, 采用了跳跃连接(Skip Connections), 将主干网络中提取的浅层特征 $\{F_2, F_1, F_0\}$ 逐级融合到解码器的对应层级中。这种设计确保了网络不仅能捕捉到全局的几何结构, 还能精确地定位图像中的边缘和纹理边界。最终, 解码器的输出层通过一个卷积操作生成密集的双通道残差位移场 $F_{res} \in \mathbb{R}^{H \times W \times 2}$ 。该位移场的每一个像素值 $F_{res}(x, y) = (\Delta u, \Delta v)$ 代表了在物理校正网格的基础上, 像素点 (x, y) 在水平和垂直方向上需要进一步移动的微小距离。

最终的校正过程是一个物理与数据驱动的融合过程。将径向物理分支生成的全局基础采样网格 G_{rad} 与残差修正分支预测的微调位移场 F_{res} 进行逐像素叠加, 得到最终的高精度采样网格 G_{total} :

$$G_{total}(x, y) = G_{rad}(x, y) + F_{res}(x, y) \quad (3)$$

这种加性融合方式保证了校正结果的可解释性和鲁棒性: G_{rad} 提供了正确的宏观拓扑结构, 防止图像发生严重的透视崩塌; 而 F_{res} 则专注于精细修补, 消除了非对称畸变和局部波浪纹。通过这种方式, 残差修正分支成功地将物理模型的稳定性与深度神经网络的灵活性结合在一起, 实现了对复杂畸变场景的高保真校正。

3.4. 损失函数设计

为了兼顾像素保真度与几何结构性, 设计复合损失函数:

$$\mathcal{L}_{total} = \lambda_{rec} \mathcal{L}_{rec} + \lambda_{ssim} \mathcal{L}_{ssim} + \lambda_{geo} \mathcal{L}_{geo} + \lambda_{edge} \mathcal{L}_{edge} + \lambda_{smooth} \mathcal{L}_{smooth} \quad (4)$$

其中, \mathcal{L}_{rec} 为校正图与真值(GT)的 L1 距离, 保证像素级对齐。 \mathcal{L}_{ssim} 直接优化视觉感知质量。 \mathcal{L}_{geo} 预测网格 G_{total} 与 GT 网络的 L1 距离, 强制网格形状正确。 \mathcal{L}_{edge} 计算校正图与 GT 的 Sobel 梯度图之差, 强迫直

线保持笔直, 消除边缘锯齿和波浪纹, 显著提升棋盘格等几何纹理的校正效果。 \mathcal{L}_{smooth} 对残差流 \mathcal{F}_{res} 施加全变分(Total Variation)约束, 防止过拟合产生高频噪声。

4. 实验结果与分析

4.1. 实验环境与评价指标

本实验在操作系统 Windows 11 上进行, 中央处理器为 Intel Core (TM) i7-6700 CPU, 显卡为 NVIDIA RTX 4080 Super GPU; 软件环境为 Python 3.8.16、PyTorch 1.12.1、CUDA 11.6、OpenCV 4.5.5。由于真实世界中的畸变图像往往缺乏精确的无畸变真值(Ground Truth)和对应的畸变参数, 难以直接用于有监督训练, 因此本研究构建了一个大规模的高质量合成数据集。该数据集基于 640×480 分辨率的棋盘格图像作为基准图案, 利用 Brown-Conrady 模型和傅里叶级数残差场生成了共计 9000 对畸变 - 无畸变图像样本。为了保证数据的多样性和挑战性, 在参数空间上进行了精细的采样设计:

1) 径向畸变参数: 主要负责模拟桶形(Barrel)和枕形(Pincushion)畸变。将一阶畸变系数的采样范围设定为 $[-0.15, 0.15]$, 这覆盖了绝大多数商用广角镜头和运动相机的畸变程度。同时, 引入微小的高阶项以模拟边缘区域的非线性压缩。2) 相机内参: 随机扰动焦距和光心, 以模拟不同焦段镜头的成像特性及光轴偏心问题。3) 非对称残差场(Residual Field): 这是本数据集的核心特色。不同于以往数据集仅使用理想物理模型, 本数据集采用额外叠加了一个由随机傅里叶级数生成的非刚性位移场。该残差场的幅度控制在图像尺寸的 2% 左右(约 0.02), 旨在模拟透镜组装误差、传感器平整度偏差以及环境热变形导致的非对称波浪纹畸变。这一设计使得该数据集能够有效区分出仅依赖物理参数的模型与具备残差修补能力的模型之间的性能差异。

将生成的 9000 张数据按照 8:1:1 的比例随机划分为训练集、验证集和测试集用于模型训练及定量评估。此外, 为进一步验证模型泛化能力, 本文基于 Places365-Standard [14] 真实场景图像添加仿真畸变, 构建独立定性测试集。该部分数据不参与训练, 仅在推理阶段用于主观视觉对比, 以评估模型在复杂自然场景下的校正效果与鲁棒性。

为全面、多维度评估畸变校正模型的性能, 本研究选取峰值信噪比(PSNR)、结构相似性指数(SSIM)作为像素级质量评价指标, PSNR 值越高, 表示图像质量越好; SSIM 取值范围是 $[-1, 1]$, 取值越接近 1 表示两幅图像越相似; 并引入直线偏差(L_{dev})作为几何校正效果的专属评价指标, 计算方法为, 先在测试集的合成过程中记录下棋盘格或网格线在理想无畸变图像中的直线方程 $Ax + By + C = 0$ 。然后, 在校正后的图像中提取对应边缘上的采样点集 $P = \{p_1, p_2, \dots, p_N\}$ 。对于每个采样点 $p_k(x_k, y_k)$ 计算其到理想直线的欧氏距离 d_k 。直线偏差定义为所有采样点距离的均方根误差(RMSE):

$$L_{dev} = \sqrt{\frac{1}{N} \sum_{k=1}^N \left(\frac{|Ax_k + By_k + C|}{\sqrt{A^2 + B^2}} \right)^2} \quad (5)$$

直线偏差的单位为像素(pixel), 该值越低, 意味着校正后的线条越接近完美的直线。

4.2. 对比实验

为验证本研究方法的有效性, 分别在合成畸变数据集与真实畸变数据集上与主流畸变校正方法开展对比实验。分别选取 U-Net [10]、LaRecNet [11]、GeoProj [12]、FishFormer [13] 作为对比方法。本数据集特意引入了物理模型难以描述的非对称畸变和局部波浪纹残差, 旨在模拟真实世界中廉价镜头或组装误差带来的复杂场景。

如表 1 所示, 在合成畸变数据集上, 各方法在像素级评价指标上呈现出明显的性能差异。GeoProj 在

PSNR 指标上取得 25.01 的最佳结果, 本文方法的 PSNR 为 24.49, 仅比最佳值低 0.52, 处于次优水平; 在 SSIM 指标上, 本文方法以 0.9145 取得最优性能, 优于其他对比方法。这两种指标对于图像质量的评价存在不同的侧重, SSIM 强调图像结构信息的相似性, 而 PSNR 则关注像素级别的绝对误差, 本文方法兼顾了物理模型的参数拟合与残差畸变的精细修补, 因此在结构信息保持上表现更优。

Table 1. Comparison experiment of distortion correction methods based on radial prior and residual learning (synthetic dataset)
表 1. 基于径向先验与残差学习的畸变校正方法对比实验(合成数据集)

方法	PSNR↑	SSIM↑
U-Net [10]	23.10	0.9100
LaRecNet [11]	24.62	0.8953
GeoProj [12]	25.01	0.9031
FishFormer [13]	18.89	0.8139
Ours	24.49	0.9145

Table 2. Comparison experiment of distortion correction methods based on radial prior and residual learning (real dataset)
表 2. 基于径向先验与残差学习的畸变校正方法对比实验(真实数据集)

方法	$L_{dev} \downarrow$
U-Net [10]	2.00
LaRecNet [11]	1.85
GeoProj [12]	4.42
FishFormer [13]	1.75
Ours	1.81

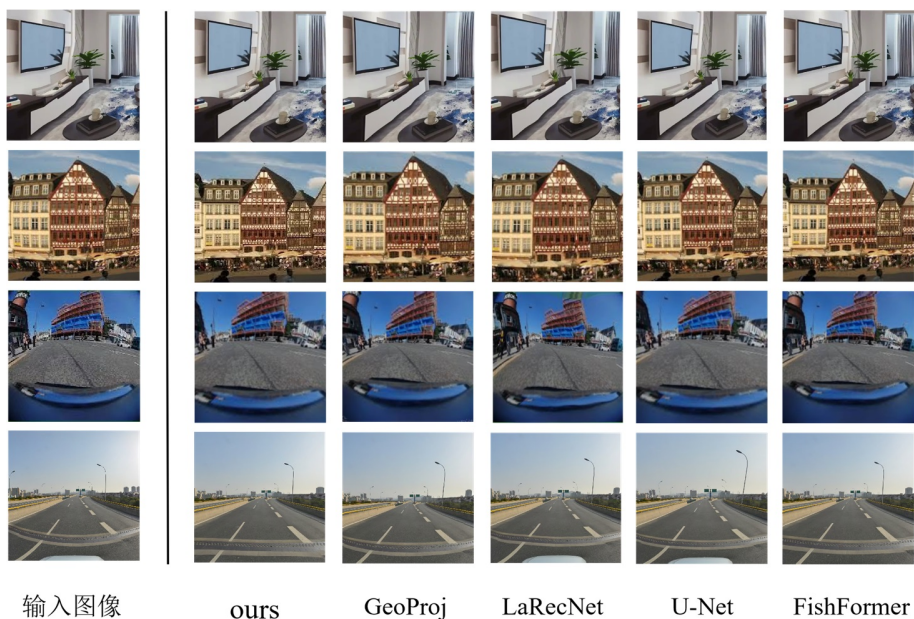


Figure 4. Distortion correction effect
图 4. 畸变校正效果

由于真实畸变图像缺乏精确的无畸变真值, 无法计算像素级指标 PSNR 与 SSIM, 因此仅采用几何校正专属指标 L_{dev} 对各方法在真实数据集上的性能进行对比, 结果如表 2 所示。FishFormer 在 L_{dev} 指标上以 1.75 取得最佳结果, 本文方法的 L_{dev} 为 1.81, 与最佳值接近。这一结果证明, 本文方法在真实复合畸变场景下, 仍能保持优异的几何校正能力。

本小节还提供了视觉方面的定性比较, 图 4 展示了各方法在真实畸变图像上的校正效果可视化对比。本文方法结合径向先验的物理约束与残差学习的精细修补, 不仅实现了线条的精准校正, 还能保持图像纹理的完整性, 校正后图像无明显畸变与伪影, 视觉效果更贴合真实场景的视觉需求。

4.3. 消融实验

为验证本文模型中各核心模块的有效性, 设计消融实验进行定量与定性分析, 消融实验共设置四个实验组: 无校正模块(None)、仅径向物理分支模块(Radial Only)、仅残差修正分支模块(Residual Only)、本文完整模型(Full), 各实验组在 PSNR、SSIM、 L_{dev} 三项指标上的性能对比结果如表 3 所示。

Table 3. Ablation experiment of distortion correction method based on radial prior and residual learning
表 3. 基于径向先验与残差学习的畸变校正方法消融实验

方法	PSNR↑	SSIM↑	L_{dev} ↓
None	19.62	0.7856	12.45
Radial Only	23.85	0.8948	2.12
Residual Only	23.27	0.8403	3.85
Full	24.49	0.9145	1.81

从表 3 结果可以清晰看出, 无校正模块的模型在三项指标上均表现最差, 证明了畸变校正模块对提升图像质量的核心作用。仅径向物理分支模块与仅残差修正分支模块均能实现一定的畸变校正效果, 但性能均低于本文完整模型。本文完整模型融合了径向物理分支与残差修正分支的优势, 既通过物理先验实现了径向畸变的精准校正, 又通过残差学习完成了非对称残差畸变的精细修补, 因此在三项指标上均取得最优性能, 证明了双分支融合设计的有效性。

5. 讨论

本文所述的畸变校正模型取得较优实验结果, 是因为采用了物理先验与数据驱动融合的双分支架构, 通过径向物理分支约束全局畸变规律, 通过残差修正分支精准补偿非线性畸变误差, 二者互补兼顾了校正精度与泛化能力; 其次选用 ConvNeXt-Tiny 作为主干网络, 配合 U-Net 结构的细粒度特征提取能力, 可有效捕捉图像边缘、角点等关键区域的畸变特征, 显著提升了畸变校正精度。

但是该模型仍存在一定的适用局限性。首先, 模型的径向物理分支基于 Brown-Conrady 经典模型设计, 其参数学习范围针对主流广角镜头的畸变程度(一阶畸变系数 $[-0.15, 0.15]$)优化, 当面对超鱼镜头、定制化光学系统等产生的极端径向畸变或非径向主导型畸变(如严重切向畸变、倾斜畸变)时, 物理模型的全局约束易出现适配偏差, 导致残差分支需补偿的畸变幅度超出训练分布, 进而影响校正精度; 其次, 当前方法针对畸变图像中的静态场景设计, 未考虑动态目标(如运动行人或车辆)在不同畸变区域可能产生的非刚性形变差异, 模型在动态视觉测量任务中的效果尚未验证。未来可从以下方面开展改进工作: 一是优化物理模型的灵活性, 引入分段式径向畸变模型或融合切向、倾斜畸变参数的扩展物理分支, 提升对极端畸变场景的适配能力; 二是构建时空联合的畸变校正框架, 结合光流估计与递推滤波实现视频级稳定校正。

6. 结论

本文针对现有畸变校正方法在泛化性、几何一致性与局部畸变修复能力方面的不足, 提出了一种基于径向先验与残差学习的畸变校正方法。该方法通过径向物理分支实现全局径向畸变的粗校正, 保证几何结构的整体正确性; 通过残差修正分支实现局部非对称畸变与波浪纹的高精度修复。两个分支在可微分采样模块中融合, 形成物理引导 + 数据驱动的协同优化机制。实验结果表明, 本文方法在 PSNR、SSIM 与直线偏差等指标上优于主流方法, 消融实验进一步验证了径向物理分支模块、残差修正分支模块等的有效性。该方法在无需精确标定的前提下, 显著提升了畸变校正的精度、鲁棒性与泛化能力, 为视觉测量场景下的图像畸变校正提供了可靠的技术方案。

致 谢

作者贾丰毓衷心感谢导师杨海波教授在研究过程中给予的宝贵指导、持续支持和深刻建议, 同时感谢同学们的建设性讨论和技术协助。此外, 作者还感谢匿名评审专家提出的有益意见和建议。

参考文献

- [1] Chi, G., Huang, Y., Hu, C. and Yan, C. (2026) Adaptive Multi-Layer Region-Backtracking Compensation with Hybrid-Structure Model for Concentric Camera Distortion Correction. *Optics & Laser Technology*, **197**, Article ID: 114784. <https://doi.org/10.1016/j.optlastec.2026.114784>
- [2] 王翊, 李志辉, 许耀华. 一种基于抛物面模型的参数修正的鱼眼图像校正算法[J]. 现代电子技术, 2026, 49(3): 13-18.
- [3] Wang, C., Ding, Y., Cui, K., et al. (2025) A Perspective Distortion Correction Method for Planar Imaging Based on Homography Mapping. *Sensors*, **25**, Article No. 1891.
- [4] Kang, S. (2000) A Method for Estimating Radial Distortion Coefficients. *IEEE Conference on Computer Vision and Pattern Recognition*, Hilton Head Island, 13-15 June 2000, 488-493.
- [5] Alvarez, L., Gomez, L. and Sendra, J. (2000) Algebraic Methods for Estimating Radial Distortion Coefficients. *Journal of Optical Society of America A*, **17**, 1392-1401.
- [6] Zhang, Z. (2000) A Flexible New Technique for Camera Calibration. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **22**, 1330-1334. <https://doi.org/10.1109/34.888718>
- [7] Li, H. and Hartley, R. (2004) Improved Methods for Estimating Radial Distortion Coefficients. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **26**, 949-954.
- [8] Liao, K., Lin, C., Zhao, Y. and Gabbouj, M. (2020) DR-GAN: Automatic Radial Distortion Rectification Using Conditional GAN in Real-Time. *IEEE Transactions on Circuits and Systems for Video Technology*, **30**, 725-733. <https://doi.org/10.1109/tcsvt.2019.2897984>
- [9] Liu, H., Wang, P., Fu, L. and Li, Y. (2026) CanopyGAN: A Wavelet-Enhanced GAN for Image Distortion Correction in Aircraft Canopy. *Displays*, **91**, Article ID: 103248. <https://doi.org/10.1016/j.displa.2025.103248>
- [10] Ronneberger, O., Fischer, P. and Brox, T. (2015) U-Net: Convolutional Networks for Biomedical Image Segmentation. In: Navab, N., et al., Eds., *Medical Image Computing and Computer-Assisted Intervention—MICCAI 2015*, Springer International Publishing, 234-241. https://doi.org/10.1007/978-3-319-24574-4_28
- [11] Xue, Z.C., Xue, N. and Xia, G.S. (2020) Fisheye Distortion Rectification from Deep Straight Lines. <https://arxiv.org/abs/2003.11386>
- [12] Li, X., Zhang, B., Sander, P.V. and Liao, J. (2019) Blind Geometric Distortion Correction on Images through Deep Learning. 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Long Beach, 4850-4859. <https://doi.org/10.1109/cvpr.2019.00499>
- [13] Yang, S., Lin, C., Liao, K. and Zhao, Y. (2025) FishFormer: Annulus Slicing-Based Transformer for Fisheye Rectification. *ACM Transactions on Multimedia Computing, Communications, and Applications*, **21**, 1-16. <https://doi.org/10.1145/3719348>
- [14] Zhou, B., Lapedriza, A., Khosla, A., Oliva, A. and Torralba, A. (2018) Places: A 10 Million Image Database for Scene Recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **40**, 1452-1464. <https://doi.org/10.1109/tpami.2017.2723009>