

文章编号 1004-924X(2026)03-0466-15

面向 TDI CCD 噪声建模的物理引导深度神经网络

夏 波¹, 黄 鸿^{1*}, 周建勇^{2*}, 杨利平¹, 王 陶²

(1. 重庆大学 光电技术与系统教育部重点实验室, 重庆 400044;

2. 中国电子科技集团公司第四十四研究所, 重庆 400060)

摘要: 时间延迟积分 CCD (Time Delay Integration CCD, TDI CCD) 在遥感成像领域应用广泛, 由于其存在暗电流、复位噪声及量化噪声等复杂噪声源, 导致现有方法难以表征微光环境下真实传感器中的信号无关性噪声分布。针对该问题, 提出一种面向 TDI CCD 噪声建模的物理引导深度神经网络 (Physics-guided Deep Neural Network, PDNN), 通过从暗场图像中学习信号无关性噪声, 并将其与基于泊松分布建模的信号相关性噪声叠加得到合成噪声, 从而准确表征 TDI CCD 在微光条件下的噪声分布。首先, 该网络通过 TDI CCD 噪声解耦 (TDI CCD Noise Decoupling, TND) 模块将暗场图像解耦成空间无关性的像素噪声。然后, TDI CCD 噪声建模 (TDI CCD Noise Modeling, TNM) 主干网络中的增益多级自适应 (Gain and Multi-stage Adaptive, GMA) 模块和 1×1 卷积模块将初始噪声映射到接近真实噪声水平的分布空间, 并保持像素噪声的独立性。最后, 使用任务平衡损失 (Task Balanced Loss, TBL) 对网络进行约束, 通过动态调整权重因子以维持训练过程的相对均衡, 进一步优化网络性能。实验结果表明, 在自建数据集上所提方法的平均 KL 散度 (Average Kullback-Leibler Divergence, AKLD) 达到 0.106 9, 在现有方法中具备显著优势, 且使用合成噪声图像训练得到的 PSNR 与 SSIM 指标接近真实数据水平。PDNN 能够准确描述 TDI CCD 在微光条件下的噪声分布, 对提升微光遥感影像的视觉质量具有实际应用价值。

关键词: TDI CCD; 物理引导; 神经网络; 噪声解耦; 任务平衡损失

中图分类号: TP751 **文献标识码:** A

doi: 10.37188/OPE.20263403.0466

CSTR: 32169.14.OPE.20263403.0466

Physics-guided deep neural network for TDI CCD noise modeling

XIA Bo¹, HUANG Hong^{1*}, ZHOU Jianyong^{2*}, YANG Liping¹, WANG Tao²

(1. Key Laboratory of Optoelectronic Technology and Systems of the Education Ministry of China,
Chongqing University, Chongqing 400044, China;

2. The 44th Research Institute of China Electronics Technology Group Corporation,
Chongqing 400060, China)

* Corresponding author, E-mail: hhuang@cqu.edu.cn; 526821747@qq.com

Abstract: Time-Delay Integration CCDs (TDI CCDs) are widely used in remote-sensing imaging. However, complex noise sources-including dark current, reset noise, and quantization noise-hinder accurate characterization of the signal-independent noise distribution of real sensors under low-light conditions. To address this challenge, a physics-guided deep neural network for TDI CCD noise modeling

收稿日期: 2025-10-31; **修订日期:** 2025-11-26.

基金项目: 国家自然科学基金资助项目 (No. 42571416, No. 42071302); 北京市航空智能遥感装备工程技术研究中心开放基金资助项目 (No. AIRSE202412)

(PDNN) is proposed. Signal-independent noise is learned from dark-frame images and combined with signal-dependent noise modeled by a Poisson distribution, enabling accurate representation of the TDI CCD noise distribution in low-light scenes. First, a TDI CCD Noise Decoupling (TND) module decomposes dark-frame images into pixel-level noise with spatial independence. Next, a Gain and Multi-stage Adaptive (GMA) module, together with 1×1 convolutional layers in the TDI CCD Noise Modeling (TNM) backbone, maps the initial noise into a distribution space that closely matches the true noise level while preserving pixel-wise independence. Finally, a Task Balanced Loss (TBL) dynamically adjusts weighting factors to maintain training equilibrium, further improving performance. On a self-constructed dataset, the proposed method achieves an average Kullback-Leibler divergence (AKLD) of 0.106 9, demonstrating substantial improvements over existing approaches. Moreover, PSNR and SSIM obtained from models trained with synthetic noisy images closely approximate those achieved with real data. Experimental results indicate that PDNN effectively characterizes the low-light noise distribution of TDI CCDs, providing practical value for enhancing the visual quality of low-light remote-sensing imagery.

Key words: TDI CCD; physics-guided; neural network; noise decoupling; task balanced loss

1 引言

时间延迟积分 CCD (Time Delay Integration CCD, TDI CCD) 在微光条件下仍具有较好的成像性能, 因此被广泛应用于遥感成像领域^[1-5]。然而, 其成像过程中的多种复杂噪声源, 如暗电流、复位噪声、热噪声、 $1/f$ 噪声和量化噪声等严重制约了成像质量与实际应用效果^[6-8]。噪声建模可实现对噪声形成机理的深入解析与数学表征, 提升图像降噪稳定性以及计算摄影质量, 已成为科学探测与遥感成像领域的研究热点。

当前图像噪声建模方法主要分为三大类: 物理统计模型、数据驱动/深度学习模型以及二者的混合模型。物理统计模型基于半导体物理和电荷转移原理, 对噪声的生成与传递进行严格的数学描述。研究人员提出了 CCD 与 CMOS 成像系统的噪声模型, 将噪声假设为加性高斯白噪声并进行降噪^[9-12]。针对合成噪声与真实噪声不匹配的问题, Wei 等^[13] 提出基于 CMOS 特性的高精度噪声合成模型, 采用 Tukey lambda 分布估计读噪声, 并据此校准相机噪声参数。Zhang 等^[14] 直接从传感器真实噪声数据库中采样, 结合模式对齐和高比特重建恢复高位噪声信息。然而, 上述物理模型往往包含大量难以实时获取的标定参

数, 且多种噪声源之间存在耦合关系, 若直接将其作为独立加性成分进行处理, 容易导致在航空航天等微光环境下建模失准。

近年来, 基于深度学习的方法利用神经网络强大的特征表达能力, 直接从噪声数据中学习噪声分布, 取得了重大进展。文献[15-17] 基于生成对抗网络, 通过联合学习去噪器和生成器来建模干净-噪声图像对的联合分布, 避免了对噪声先验的人工假设。Abdelrahman 等^[18] 结合传统噪声模型与归一化流网络, 进一步提升了真实噪声的建模能力。Maleky 等^[19] 在此基础上提出 Noise2NoiseFlow 框架, 利用成对噪声图像实现了无监督噪声建模。然而, 此类方法通常依赖于大量高质量配对数据 (无论是干净-噪声对还是噪声-噪声对), 这在实际应用中往往难以满足, 同时复杂的网络结构也带来较高的计算成本与优化难度。

为兼顾模型的可解释性与灵活性, 混合模型将物理约束与深度学习相结合, 将物理机理作为先验知识嵌入到网络架构中。Cao 等^[20] 建立一种感光度依赖的噪声模型, 解决了现有方法忽略感光度关联和固定模式噪声的问题。Zhang 等^[21] 分别使用物理模型与生成模型建模信号相关与无关性噪声, 并引入傅里叶变换判别器来提升噪声分布精度。Zou 等^[22] 构建了一种融合细粒度噪声

模型与对比学习的框架,实现了仅基于测试图像即可完成对陌生传感器的噪声建模,无需额外校准帧或配对数据。尽管上述方法在普通 CCD 与 CMOS 图像噪声建模中取得了一定成效,但 TDI CCD 与常规图像传感器存在显著差异,其通过多次电荷转移与积分提升信噪比,噪声源构成更为复杂,这导致现有方法在微光等极端环境下适应性不足,噪声建模效果不佳。

针对上述问题,本文提出了面向 TDI CCD 噪声建模的物理引导深度神经网络(Physics-guided Deep Neural Network, PDNN)。该方法利用部分暗场图像学习信号无关性噪声,并叠加到基于泊松分布建模的信号相关性噪声中,从而准确描述其噪声分布,指导后续图像降噪任务。在自建 TDI CCD 图像数据集上的实验结果表明,PDNN 能够准确描述 TDI CCD 在微光条件下的噪声分布,验证了其有效性与实用性。

2 物理引导的 TDI CCD 噪声建模

本文提出的 PDNN 方法通过 3 个模块协同实现对复杂噪声的高精度建模,整体架构如图 1 所示。首先,TDI CCD 噪声解耦模块(TDI CCD Noise Decoupling, TND)对暗场图像进行预处理,消除空间相关性噪声并执行高比特重构,以获得独立分布的高精度像素噪声。然后,TDI CCD 噪声建模(TDI CCD Noise Modeling, TNM)主干网络中的增益多级自适应(Gain and Multi-stage Adaptive, GMA)模块和 1×1 卷积模




图 1 PDNN 总体框架

Fig. 1 Overall framework of PDNN

块将初始噪声映射到接近真实噪声水平的分布空间,并保持像素噪声与解耦后噪声的一致性。最后,任务平衡损失(Task Balanced Loss, TBL)联合累积分布函数损失与分位数损失,对网络进行约束,以进一步提升建模性能。下面对各模块进行详细阐述。

2.1 TDI CCD 噪声解耦方法(TND)

现有大多数基于学习的噪声建模方法通常直接将噪声图像输入网络进行处理。然而,空间相关性与随机噪声并存增加了网络学习难度。此外,在低光照高增益时,信号无关性噪声成为主要噪声源,其复杂统计特性要求数据具备高精度与高比特率以实现有效建模。为此,提出 TND 对原始图像解耦,分离出空间无关性的像素噪声,并引入高比特重构得到统计特性更接近真实连续噪声的分布。

为具体说明该方法实现流程,以某型号 TDI CCD 器件(电科芯片技术研究院研制)为例进行阐述。在数字增益 $G=500$, TDI CCD 积分级数 $M=32$ 的条件下,对采集的暗场图像进行傅里叶变换。由图 2(a)归一化频谱图可见存在明显的列条纹噪声,且该列条纹噪声服从正态分布。本文采用最大似然估计获取其尺度参数 σ_c ,并通过补偿全局均值与列均值之差消除列条纹。实验结果表明,当补偿因子取 0.9 时去条纹效果最佳。




图 2 条纹去除前后的傅里叶谱图

Fig. 2 Fourier spectra before and after stripe removal

如图2(b)所示,经处理后图像中的列条纹基本消除,归一化频谱中未见明显横条纹,图像中主要剩余噪声为空间无关性的像素噪声。

为进一步提升噪声建模精度,引入文献[14]提出的高比特分布重构方法,以缓解低比特量化导致的噪声统计分布离散化畸变问题。具体而言,该方法通过拟合一组概率分布来估计量化前信号的连续分布,然后,在每个低比特离散值相应的量化区间内依据估计的连续分布进行采样,以生成高比特值,从而重构出高比特数据。该过程并非恢复已丢失的量化信息,而是通过统计估计重建出在统计特性上更接近真实连续噪声的分布。图3展示了不同阶段的噪声分布及其概率密度,从上至下依次为原始暗场 N_{dark} ,像素噪声 N_{pixel} 以及高比特重构后的像素噪声 N_{gt} 。为便于可视化,原始图像灰度由0~16 383映射到0~255,并适当扩展动态范围。可以看出,高比特重构后噪声的总体方差减小,表明由量化引起的统计分布离散化效应被有效抑制,重建后的噪声分布在统计特性上更接近真实的物理噪声过程。




图3 不同噪声分布

Fig. 3 Distribution for different noises

综上所述,TND模块通过对原始暗场图像进行列条纹去除和高比特分布重建,最终输出较为纯净的、空间无关的像素噪声 N_{gt} 。该结果将作为后续TNM主干网络的训练目标,指导网络学习从简单随机噪声到真实传感器噪声的复杂映射。

2.2 TDI CCD噪声建模主干网络(TNM)

TNM主干网络旨在将标准高斯噪声分布映射至真实传感器噪声分布。该网络由GMA、 1×1 卷积、SiLU激活函数以及Res残差块构成,其中残差块的数量 n 影响建模效果,具体见3.3.2节实验结果。网络输入为标准高斯分布的随机噪声 $N_{\text{init}} \sim N(0, 1)$,输出为最终的噪声变换结果 N_{pre} 。其基本变换过程可表述为:

$$N_{\text{pre}} = \text{TNM}(N_{\text{init}}, g, M), \quad (1)$$

其中: $N_{\text{pre}}, N_{\text{init}} \in \mathbb{R}^{C \times H \times W}$, g, M 分别表示实际增益与积分级数。此处,实际增益 g 由数字增益 G 经过式(2)转换得到:

$$g = \frac{10^{(0.0359G + 5.76)/20}}{1.94}. \quad (2)$$

在设计上,GMA模块旨在解决网络直接变换标准高斯噪声分布所面临的两个挑战:其一,标准噪声的幅值水平与真实噪声存在显著差异,导致网络优化难度较大;其二,标准噪声中的大量负值经过激活函数后被抑制,降低了网络的收敛效率。为此,在网络输入端构建了GMA模块,将初始噪声预映射至更接近真实噪声水平的空间,为后续的精细变换奠定基础。增益与积分级数是影响TDI CCD噪声特性的关键成像参数,文献[6]理论分析表明,暗电流与这些参数之间存在线性依赖关系。由图4可知, g 与 M 和暗电流均值满足线性关系,验证了其线性特性。

为建立暗均值 μ_d 与关键成像参数 (g, M) 的数学关系,构建了线性模型如下:

$$\mu_d = (gM, g, M, c)(k_1, k_2, k_3, k_4)^T, \quad (3)$$

其中 $c=1, k_1, k_2, k_3, k_4$,为可学习系数。类似地, g 与 M 和暗电流方差也满足线性关系,可构建暗电流方差线性模型如下:


$$\sigma_d = (gM, g, M, c)(s_1, s_2, s_3, s_4)^T, \quad (4)$$

其中 s_1, s_2, s_3, s_4 为相应的可学习系数。结合两个模型能够准确捕捉增益与积分级数对暗信号的综合影响。由此构建了增益积分级数自适应模块GMA,初始图像 N_{init} 经过GMA模块映射到接近真实的分布 $N_{\text{GMA}} \sim N(\mu_d, \sigma_d)$:

$$N_{\text{GMA}} = \text{GMA}(N_{\text{init}}, g, M). \quad (5)$$


GMA通过物理引导的初始化策略,显著降低了由于输入噪声水平与实际差异过大导致的

网络优化初始误差,为后续变换奠定了基础。



(a) 暗均值-增益变化曲线

(a) Curve of dark mean changing with gain



(b) 暗均值-积分级数变化曲线

(b) Curve of dark mean changing with integration stage

图 4 不同增益、积分级数下暗均值的变化曲线

Fig. 4 Variation curves of dark mean under different gains and integration stages

为遵循像素噪声空间独立性的物理先验, TNM 主干网络在结构设计上进行了以下优化:

(1) 卷积核选择

采用 1×1 卷积替代所有 3×3 卷积。 3×3 卷积中非零参数的存在引入了空间相关性,这与像素噪声空间无关性的先验假设相矛盾。 1×1 卷积在实现特征变换的同时保持了像素间的独立性,同时显著降低了模型的优化自由度。

(2) 归一化层处理

移除所有批归一化层,该层通过对批次内样

本进行标准化处理,会混合不同空间位置的统计信息,破坏噪声的自然统计特性。

以上设计确保了网络在变换过程中严格保持噪声的空间独立性,与解耦后噪声的物理特性保持一致,同时提升了模型的收敛性与稳定性。

2.3 任务平衡损失(TBL)

基于 TND 解耦后噪声的空间无关特性,采用累积分布函数来度量真实噪声与预测噪声分布之间的差异,并构建了累积分布函数损失 L_{CDF} 与分位数损失 L_{Quantile} 两种损失函数。对于任意真实像素噪声 N_{gt} 和预测噪声 N_{pre} ,令 F 表示累积分布函数, F^{-1} 表示分位数函数。给定一组采样点 $Q = \{q_i | i=1, 2, \dots, N\}$, L_{CDF} 可以表示为:

$$L_{\text{CDF}} = \sum_{i=1}^N |F_{\text{gt}}(q_i) - F_{\text{pre}}(q_i)|, \quad (6)$$

其中: F_{gt} , F_{pre} 分别表示真实噪声和预测噪声的累积分布值。类似地, L_{Quantile} 被定义为:

$$L_{\text{Quantile}} = \sum_{i=1}^N |F_{\text{gt}}^{-1}(q_i) - F_{\text{pre}}^{-1}(q_i)|. \quad (7)$$

为平衡两种损失的优化过程,提出具有动态权重调整机制的任务平衡损失,该损失被定义为两种损失的动态加权和,具体如下:

$$L_{\text{TBL}}^{(t)} = w_c^{(t)} \cdot L_{\text{CDF}}^{(t)} + w_q^{(t)} \cdot L_{\text{Quantile}}^{(t)}, \quad (8)$$

其中: t 表示迭代次数, $w_c^{(t)}$, $w_q^{(t)}$ 为相应的动态权重,二者初始值均设置为 1。权重更新机制采用滑动窗口均值结合动量更新策略。定义 CDF 相对比例 $r_c^{(t)}$ 为:

$$r_c^{(t)} = \frac{2\bar{L}_{\text{CDF}}^{(t)}}{(\bar{L}_{\text{CDF}}^{(t)} + \bar{L}_{\text{Quantile}}^{(t)})}, \quad (9)$$

其中: $\bar{L}_{\text{CDF}}^{(t)}$, $\bar{L}_{\text{Quantile}}^{(t)}$ 分别表示滑动窗口(窗口大小默认为 5)内两种损失的均值,同理可得 Quantile 相对比例 $r_q^{(t)}$ 。随后通过负指数函数计算 CDF 初始权重因子 $\hat{w}_c^{(t)}$:

$$\hat{w}_c^{(t)} = \frac{2\exp(-r_c^{(t)} \cdot \tau)}{\exp(-r_c^{(t)} \cdot \tau) + \exp(-r_q^{(t)} \cdot \tau)}, \quad (10)$$

其中: 温度参数 τ 设置为 2, 同理可得 $\hat{w}_q^{(t)}$ 。最终采用动量更新(动量因子 $\gamma=0.9$)所得权重为:

$$\begin{cases} w_c^{(t)} = \gamma \cdot w_c^{(t-1)} + (1 - \gamma) \cdot \hat{w}_c^{(t)} \\ w_q^{(t)} = \gamma \cdot w_q^{(t-1)} + (1 - \gamma) \cdot \hat{w}_q^{(t)} \end{cases} \quad (11)$$

该机制自动为收敛较快的损失分配较低权重,为收敛较慢的损失分配较高权重,确保二者相对平衡,从而实现更稳定有效的学习过程。

3 实验结果与分析

3.1 实验条件

为满足实际成像条件下的噪声建模测试,利用TDI CCD模组在室内采集了不同积分级数和增益条件下的明暗场图像,如图5所示。数据涵盖了6种积分级数 $M=8,16,32,48,64$ 和96,9种数字增益 $G=0,10,20,50,100,200,400,500$ 和1000,共包含54幅图像,部分暗场图像实例如下(由上至下条件为: $M=8 \& G=0, M=32 \& G=10, M=96 \& G=100, M=8 \& G=1000$)。

原始图像尺寸为 6144×128 ,为便于模型训练,将其统一裁剪为不重叠的 128×128 像素的图像块,共获得2592个图像块。数据集按照3:1:1




图5 暗场图像实例

Fig. 5 Instances of dark frame images

的比例随机划分,训练集约包含1556个图像块,验证集与测试集各约包含518个图像块。实验采用Adam优化器,初始学习率设置为 10^{-4} ,使用余弦退火衰减策略,模型共训练300个Epoch。实验采用平均KL散度(Average Kullback-Leibler Divergence, AKLD)与决定系数(Coefficient of Determination, R^2)作为评估指标,其中,AKLD是所有样本KL散度的均值,评估概率分布中间区域的重合程度, R^2 评估长尾分布的拟合效果,KL散度 D_{KL} 定义如下:

$$D_{KL}(p||q) = \sum_{i=1}^N p(x_i) \log \frac{p(x_i)}{q(x_i)}, \quad (12)$$

其中: N 是取样的样本数量, $p(x_i), q(x_i)$ 分别表示预测与真实概率分布的当前样本取值。

3.2 对比实验

为验证所提方法的可靠性与优越性,与以下方法进行了对比实验:(1)基于物理统计的噪声建模方法,包括泊松-高斯(P-G)^[9]、ELD^[13]和SFRN^[14];(2)基于学习的噪声建模方法,包括NoiseFlow(NF)^[18]、Noise2NoiseFlow(N2NF)^[19]、DANet^[15]、CA-GAN^[16]、PNGAN^[17]、SeNM-

表1 不同方法对比结果

Tab. 1 Comparison results of different methods

Method	Approach	Calibration	Paired data	AKLD ↓	AKLD _L ↓	AKLD _M ↓	AKLD _H ↓
P-G ^[9]	Physics	✓	×	0.145 7	0.149 5	0.148 5	0.111 2
ELD ^[13]	Physics	✓	×	0.143 2	0.147 1	0.129 2	0.112 2
SFRN ^[14]	Physics	✓	×	0.106 0	0.118 0	0.084 7	0.097 1
NF ^[18]	Flow	×	✓	4.848 7	4.997 7	4.389 2	4.935 9
N2NF ^[19]	Flow	×	✓	11.068 4	11.806 6	12.611 2	11.066 0
DANet ^[15]	GAN	×	✓	13.976 9	15.943 8	15.565 2	7.469 4
CA-GAN ^[16]	GAN	×	✓	/	/	/	/
PNGAN ^[17]	GAN	×	✓	1.727 6	1.399 1	1.717 6	2.558 8
SeNM-VAE ^[23]	VAE	×	✓	4.767 5	4.445 6	4.949 6	5.386 0
LLD ^[20]	Physics+Flow	✓	✓	0.424 2	0.914 4	0.388 5	0.234 2
LRD ^[21]	Physics+GAN	✓	✓	/	/	/	/
DNE ^[22]	Physics+CL	×	✓	15.700 7	15.945 3	15.567 5	15.222 2
PDNN(Ours)	Physics+CNN	✓	×	0.106 9	0.109 6	0.105 4	0.101 8

注:AKLD_L表示 $G \leq 50$ 内均值,AKLD_M表示 $50 < G \leq 200$ 内均值,AKLD_H表示 $200 < G$ 内均值。

VAE^[23], LLD^[20], LRD^[21]和 DNE^[22]。表 1 为最终实验结果, AKLD 采用最终的合成噪声(即信号无关与相关性噪声的叠加)与真实噪声图像计算得到, 其中, 相关性噪声基于泊松分布构建所得^[13], 图 6 为 $G=500$ & $M=32$ 时各算法的可视化结果。




图 6 各算法的可视化结果

Fig. 6 Visualization results of each algorithm

图 6 第一行图像为相关性噪声建模结果, 真实噪声通过明暗场灰度图像作差所得, 合成噪声通过泊松分布采样得到, KLD 值为 0.049 1, 视觉上噪声模式相近, 因此泊松分布能够较好地描述

信号相关性噪声分布。同时, 由表 1 与图 6 后续结果可知, 基于物理统计的方法在噪声拟合精度上普遍优于基于学习的方法。物理统计方法中, PDNN 方法在仅需少量暗场图像数据, 无需复杂参数标定的情况下, 其噪声建模精度 ($AKLD=0.106\ 9$) 与基于大规模真实噪声数据库采用的 SFRN 方法 ($AKLD=0.106\ 0$) 相当。其他物理统计方法(如 P-G, ELD)尽管具有物理可解释性, 但其建模效果依赖于精细的噪声参数标定与分布假设, 在复杂成像条件下难以准确匹配真实噪声。基于学习的方法中, PDNN 通过引入物理引导结构, 增强了物理可解释性, 同时数据依赖性相对较低且易于训练。相比之下, 其余基于学习的方法受限于以下问题: 数据依赖性缺陷: N2NF, DNE 等需要大规模数据量以提取有效特征; 噪声建模失准: NF 因网络结构不适用导致噪声成分估计失准, 随机噪声强度被高估; 目标偏离: SeNM-VAE 与 DANet 的生成模式与期望噪声分布不一致, 可能其更关注图像内容而非噪声本身。

图 7 为 $M=32$ 时不同增益下的可视化结




图 7 $M=32$ 时不同增益的可视化结果

Fig. 7 Visualization results under different gains for $M=32$

果,其中,前四行图像的局部放大图进行了同等水平对比度与亮度拉伸。可以看到,PDNN在不同增益下的KLD值均处于较低水平,视觉上噪声分布情况与真实噪声相对接近,且KLD随增益增大有下降的趋势,表明建模效果进一步得到提升,这与表1结果中的趋势保持一致。

综上所述,物理统计方法效果稳健但依赖复杂标定;学习方法参数量大、易过拟合,数据依赖性较高。而本文方法在仅依赖少量数据的条件下,实现了对真实噪声分布的高精度逼近,整体性能优于对比方法。

3.3 消融实验

为系统评估本文所提出的TND、TNM与TBL各模块的贡献,在像素噪声与整体噪声任务上进行了消融实验。实验结果如表2所示,定量分析了各模块对噪声建模精度的影响。同时,为直观展示各模块对噪声分布拟合能力的提升,图8给出了在 $G=500$ & $M=32$ 条件下,各模块输出的可视化对比结果:左列为概率密度图,右列为以真值作为横坐标,预测值作为纵坐标的回归图(蓝色代表实际数据分布,红色代表理论分布,彩图见期刊电子版)。下面分别对3个模块的实验结果进行分析与讨论。


表 2 消融实验结果
Tab. 2 Results of ablation experiment

Method	Condition	Pixel-wise noise		All noise	
		AKLD ↓	R^2 ↑	AKLD ↓	R^2 ↑
TND	w/P-G	0.805 4	0.457 5	0.145 7	0.858 9
	w/ELD	0.483 2	0.655 8	0.143 2	0.862 2
	w/o ND	0.697 8	0.464 9	0.124 4	0.909 1
	w/o HB	0.637 9	0.548 0	0.120 1	0.914 1
TNM	w/ 3×3 Conv	0.936 6	0.639 5	0.131 6	0.813 0
	w/o GMA	1.015 3	0.626 3	0.196 3	0.747 8
	w/CDF	0.485 2	0.601 6	0.111 9	0.921 6
TBL	w/Quantile	0.474 8	0.676 8	0.112 2	0.923 7
	CDF+Quantile	0.432 6	0.650 7	0.111 8	0.922 8
	Ours	0.411 1	0.679 6	0.106 9	0.928 9

3.3.1 噪声解耦模块(TND)

如表2所示,与基于物理的建模方法相比,引入TND模块后,PDNN在像素噪声和整体噪声建模任务中取得了显著优势。传统的泊松-高斯模型(图8(a))难以适应复杂的真实噪声分布;ELD方法(图8(b))虽通过细分噪声类型有所改进,但其较低的 R^2 值表明其在拟合长尾分布上仍存在不足。噪声解耦将复杂的噪声模式转换为易于网络训练的像素噪声,有效提升了建模性

能。同时,高比特重建方法的引入缓解了量化导致的离散化效应,进一步使噪声分布更逼近于真实噪声。TND方法通过结合上述两种方法有效减轻了空间相关性噪声与量化引起的干扰,使建模网络能够专注于学习与信号无关的噪声本质,从而在AKLD与 R^2 指标上均获得显著提升。由此可见,TND将噪声从空间相关的混合信号中解耦为空间无关的随机噪声,为后续建模奠定了基础。

图8 $G=500$ & $M=32$ 各模块的可视化结果Fig. 8 Visualization results of each module for $G=500$ & $M=32$

3.3.2 噪声建模主干网络(TNM)

如表2所示,TNM模块的设计对建模性能具有关键影响。

(1)卷积核结构

使用 3×3 卷积会引入不必要的空间相关性,严重恶化建模效果。如图9(b)所示,图像出现无

规则的短条纹与像素块,与真实像素噪声的物理特性相悖。相比之下,1×1卷积成功保持了像素噪声的空间独立性,建模结果(图 9(c))与真实噪声高度逼近。

(2)GMA 模块

输入端的 GMA 模块通过将网络搜索空间约束在接近真实噪声分布的区域,显著降低了后续网络的优化难度。相比之下,若仅在网络末端添加条件参数,会导致前置网络层优化困难,易出现梯度消失问题,产生粗糙估计且难以收敛。实验证明,TNM 主干网络的设计确保了网络架构与噪声特性的一致性。

此外,针对 TNM 主干的深度(即 Res 残差

块数量 n)进行了验证。由表 3 不同数量残差块结果可知,当 $n=2$ 时,模型在各项指标上均达到最优。过深的网络($n>2$)并不能提高建模性能,反而会导致模型性能下降。这是因为图像噪声本质是一种传感器物理过程的局部现象,这些物理过程空间相关性较弱,遵循严格的统计分布,网络过深会引入较强的非线性变换,破坏物理统计特性。双残差块结构在引入适度非线性来拟合复杂噪声分布的同时,有效避免了过拟合,防止了网络学习虚假的噪声模式,一定程度上保持其物理本质。因此,该设计在统计建模能力与物理可解释性之间达到了更好平衡。




图 9 不同卷积核的可视化结果
Fig. 9 Visualization results of different convolution kernels

表 3 不同数量残差块实验结果				
Tab. 3 Experimental results of different number of residual blocks				
Mode n of Res	Pixel noise		All noise	
	AKLD ↓	R^2 ↑	AKLD ↓	R^2 ↑
1	0.635 7	0.673 6	0.117 9	0.917 5
2	0.411 1	0.679 6	0.106 9	0.928 9
3	0.418 2	0.671 6	0.111 9	0.923 4
4	0.428 8	0.661 9	0.112 4	0.922 7
5	0.439 3	0.644 6	0.113 9	0.921 4
6	0.451 2	0.620 0	0.114 0	0.921 0

3.3.3 任务平衡损失(TBL)

如表 2 所示,TBL 模块消融实验探究了不同损失函数对建模性能的影响,主要结论可归纳如下:

(1)单一损失函数难以全面描述噪声的复杂统计特性

仅使用 CDF 损失时,其较低的 R^2 值(0.601 6)表明对分布长尾区域的拟合能力不足;仅使用 Quantile 损失时,较高的 AKLD 值(0.474 8)则说明对分布核心区域的匹配精度有限。

(2)简单线性叠加无法有效协调多目标优化
将 CDF 与分位数损失直接相加后,AKLD 虽略有下降(0.432 6),但 R^2 值不升反降,说明不

同损失在梯度方向与量级上存在冲突,导致优化过程振荡、收敛困难,这与图 10 中损失曲线剧烈抖动相一致。

(3)动态权重平衡机制显著提升训练稳定性与建模性能

TBL通过动态权重自适应机制,在每次迭代中根据各损失的收敛状态调整其贡献权重。如图 10(a)和 10(b)所示,总体损失在训练与验证过程中均保持较低水平且相对稳定。图 10(c)中两个权重因子在训练过程中在同一水平上浮动,尽

管在中后期存在波动,但在一定时间段后仍趋于平衡,保证两个损失的水平一致且保持稳定。该机制有效协调了不同优化目标间的竞争关系,引导模型寻找同时优化两个目标的平衡点。表 2 证明了该机制的有效性:在两个评估维度上,TBL 均取得了最低的 AKLD(0.411 1,0.106 9)和最高的 R^2 (0.679 6,0.928 9)。

上述结果表明,TBL 能够充分挖掘联合损失的潜力,实现更稳定、更充分的优化,获得最优的噪声建模性能。




图 10 不同损失及权重因子的变化曲线

Fig. 10 Variation curves for different losses and weight factor

3.4 TDI CCD 外景推扫成像降噪

为验证本文所提 PDNN 噪声建模方法的准确性,使用 PDNN 模型生成与真实噪声分布逼近的噪声图像,进而与干净的图像配对,构建出较大规模的“干净-噪声”图像对来训练降噪网络,实验中网络结构与文献[24]一致。若基于合成数据训练的降噪网络能达到与真实噪声数据训练相近的性能,则证明 PDNN 生成噪声的准确性。

真实配对数据利用 TDI CCD 在外场静态场景下(阴天无风傍晚时段)采集短时间序列图像(5 帧)构建。在确保光照稳定的前提下,取首帧为噪声图像,将后续帧经暗电流与非均匀性校正后取平均,作为干净图像的估计。采用数据包含 6 个谱段(非 binning 模式),5 种增益(包含低中高增益),共 30 幅图像,分辨率为 $18\,924 \times 6\,144$ 。为构建高质量数据集,采用一种基于能量估计的

关键区域裁剪方法,通过计算图像梯度幅值图来量化各区域的局部信息能量,优先在能量高的关键区域(如丰富纹理、锐利边缘)进行裁剪采样。经此处理,共得到 3 000 幅图像,按照 3:1:1 比例划分为训练集、验证集和测试集。评价指标采用峰值信噪比(Peak Signal-to-Noise Ratio, PSNR)和结构相似性(Structure Similarity, SSIM),分别从数值准确性和结构相似性两个方面衡量降噪效果。PSNR 定义为:

$$\text{PSNR} = 10 \times \lg \left(\frac{\text{MAX}^2}{\text{MSE}} \right), \quad (13)$$

其中:MAX 为图像最大像素值,MSE 是均方误差。对于大小为 $H \times W$ 的图像 x 和 y ,MSE 定义为:

$$\text{MSE} = \frac{1}{HW} \sum_{i=0}^{H-1} \sum_{j=0}^{W-1} (x_{i,j} - y_{i,j})^2, \quad (14)$$

其中: i, j 为位置索引。对于图像 x 和 y ,SSIM 定

义为:

$$\text{SSIM} = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)}, \quad (15)$$

其中: μ_x, μ_y 分别是图像 x 和 y 的均值, σ_x^2, σ_y^2 分别是其方差, σ_{xy} 是协方差, c_1, c_2 是平衡方程常量。

由表4结果可知,使用合成噪声图像训练所得降噪网络,在PSNR与SSIM指标上均接近于使用真实配对数据训练的结果,表明PDNN能够生成高度逼近真实噪声分布的噪声图像,验证了所提方法的准确性和可靠性。图11展示了不同增益下的可视化结果。可以看出,基于PDNN合成数据训练的降噪网络有效消除了原始图像中的条纹噪声与随机噪声,其视觉质量与基于真实数据训练的结果相当,且在PSNR与SSIM指标上接近。

表4 图像降噪实验结果

Tab. 4 Experimental results of image denoising

Method	PSNR ↑	SSIM ↑
P-G ^[9]	31.98	0.891 4
ELD ^[13]	31.91	0.890 6
DANet ^[15]	30.36	0.864 2
LLD ^[20]	31.97	0.866 3
PDNN(Ours)	32.33	0.894 8
Paired data	32.44	0.897 0

上述结果表明,本文所提噪声建模方法能够解决TDI CCD推扫成像中“干净-噪声”图像对获取困难的问题,为在缺乏真实配对数据的场景下构建高质量数据集提供了可行方案。




图11 不同增益下的可视化结果

Fig. 11 Visualization results under different gains

4 结 论

针对微光环境下 TDI CCD 噪声建模失准的问题,本文提出了一种面向 TDI CCD 噪声建模的物理引导深度神经网络 PDNN。该网络通过噪声解耦模块将复杂的混合噪声分解为易于建模的像素噪声,并设计了双残差块噪声建模网络与动态平衡损失,在引入传感器物理先验约束模型优化的同时,确保了网络结构简洁,且仅需少量数据即可高效训练,展现出较低的数据依赖性。在基于自建数据集上的实验结果表明,PDNN 能够生成与真实噪声分布高度逼近的合成图像,AKLD 低至 0.106 9,性能与基于大规模真实数据库采样的 SFRN 方法(AKLD=0.106 0)相当,且显著优于其他需要复杂校准流程或大量配对数据的对比方法。此外,在使用 PDNN 生成的合成噪声数据训练的图像降噪任

务中,降噪后图像的 PSNR 与 SSIM 指标达到了与使用真实噪声数据训练接近的水平,进一步验证了本文所提噪声建模方法的准确性与可靠性。

未来工作将验证该方法在不同型号传感器上的普适性,并基于 PDNN 噪声模型设计适应于 TDI CCD 的降噪网络,以进一步提升微光成像性能。

作者贡献声明:

夏波:论文构思,方法论,调查研究,数据整理分析与初稿写作;

黄鸿:获取资助,项目管理,论文审核与编辑;

周建勇:提供资源与指导,论文审核与编辑;

杨利平:论文审核与编辑;

王陶:调查研究与论文修改。

参考文献:

- [1] 刘则洵,万志,李宪圣,等. 时间延迟积分 CCD 空间相机信噪比的影响因素[J]. 光学精密工程, 2015, 23(7): 1829-1837.
LIU Z X, WAN ZH, LI X SH, *et al.* Influence factors on SNR of TDICCD space camera[J]. *Optics and Precision Engineering*, 2015, 23(7): 1829-1837. (in Chinese)
- [2] SONG M Z, LI L Z, ZHANG Y F, *et al.* A sea surface roughness retrieval model using multi angle, passive, visible spectrum remote sensing images: simulation and analysis[J]. *Remote Sensing*, 2025, 17(17): 2951.
- [3] 冯熠斌,王煜,刘国华,等. CCD 图像快速 Smear 消除算法及其在星载成像设备地面检测系统上的应用[J]. 光学精密工程, 2025, 33(9): 1471-1480.
FENG Y B, WANG Y, LIU G H, *et al.* Smear quick removing algorithm of CCD image and its application in ground test system for satellite-born imaging devices [J]. *Optics and Precision Engineering*, 2025, 33(9): 1471-1480. (in Chinese)
- [4] 曹小涛,胡君,王栋. 基于 FPGA 的空间光学遥感器 CCD 信号检测系统设计[J]. 液晶与显示, 2009, 24(5): 751-755.
CAO X T, HU J, WANG D. Detection system design of CCD signals for space optics remote sensing device based on FPGA[J]. *Chinese Journal of Liquid Crystals and Displays*, 2009, 24(5): 751-755. (in Chinese)
- [5] 薛旭成,韩诚山,薛栋林,等. 应用双排 TDI CCD 提高空间推扫遥感相机动态范围[J]. 光学精密工程, 2012, 20(12): 2791-2795.
XUE X CH, HAN CH SH, XUE D L, *et al.* Increasing dynamic range of space push-broom remote sensing camera by two-row TDI CCD [J]. *Optics and Precision Engineering*, 2012, 20(12): 2791-2795. (in Chinese)
- [6] ZHENG L L, JIN G, XU W, *et al.* Noise model of a multispectral TDI CCD imaging system and its parameter estimation of piecewise weighted least square fitting[J]. *IEEE Sensors Journal*, 2017, 17(12): 3656-3668.
- [7] JIANG Y Q, TIAN Y Y, MAO T Y, *et al.* A high resolution TDI-CCD system with measurement matrix coding[C]. *Sixth Conference on Frontiers in*

- Optical Imaging and Technology: Novel Imaging Systems. October 22-24, 2023. Nanjing, China. SPIE, 2024: 27.*
- [8] ZHENG J, ZHANG X H, ZHANG Y Q. Key performance and reliability verification of visible light TDICCD detector[C]. *Tenth Symposium on Novel Optoelectronic Detection Technology and Applications. November 1-3, 2024. Taiyuan, China. SPIE, 2025: 115.*
- [9] BOSCO A, BRUNA R A, GIACALONE D, *et al.* Signal-dependent raw image denoising using sensor noise characterization *via* multiple acquisitions [J]. *Digital Photography VI*, 2010, 7537: 753705.
- [10] PYATYKH S, HESSER J. Image sensor noise parameter estimation by variance stabilization and normality assessment [J]. *IEEE Transactions on Image Processing*, 2014, 23(9): 3990-3998.
- [11] LUISIER F, BLU T, UNSER M. Image denoising in mixed Poisson-Gaussian noise [J]. *IEEE Transactions on Image Processing*, 2011, 20(3): 696-708.
- [12] LE MONTAGNER Y, ANGELINI E D, OLIVO-MARIN J C. An unbiased risk estimator for image denoising in the presence of mixed Poisson-Gaussian noise [J]. *IEEE Transactions on Image Processing*, 2014, 23(3): 1255-1268.
- [13] WEI K X, FU Y, YANG J L, *et al.* A physics-based noise formation model for extreme low-light raw denoising [C]. 2020 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). June 13-19, 2020, Seattle, WA, USA. IEEE, 2020: 2755-2764.*
- [14] ZHANG Y, QIN H W, WANG X G, *et al.* Rethinking noise synthesis and modeling in raw denoising [C]. 2021 *IEEE/CVF International Conference on Computer Vision (ICCV). October 10-17, 2021, Montreal, QC, Canada. IEEE, 2022: 4573-4581.*
- [15] YUE Z S, ZHAO Q, ZHANG L, *et al.* Dual adversarial network: toward real-world noise removal and noise generation [C]. *Computer Vision-ECCV 2020. Cham: Springer, 2020: 41-58.*
- [16] CHANG K C, WANG R, LIN H J, *et al.* Learning camera-aware noise models [C]. *Computer Vision-ECCV 2020. Cham: Springer, 2020: 343-358.*
- [17] CAI Y H, HU X W, WANG H Q, *et al.* Learning to generate realistic noisy images *via* pixel-level noise-aware adversarial training [C]. *Proceedings of the 35th International Conference on Neural Information Processing Systems. ACM, 2021: 3259-3270.*
- [18] ABDELHAMED A, BRUBAKER M, BROWN M. Noise flow: noise modeling with conditional normalizing flows [C]. 2019 *IEEE/CVF International Conference on Computer Vision (ICCV). October 27-November 2, 2019. Seoul, Korea. IEEE, 2019: 3165-3173.*
- [19] MALEKY A, KOUSHA S, BROWN M S, *et al.* Noise2NoiseFlow: realistic camera noise modeling without clean images [C]. 2022 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). June 18-24, 2022, New Orleans, LA, USA. IEEE, 2022: 17611-17620.*
- [20] CAO Y, LIU M, LIU S, *et al.* Physics-guided ISO-dependent sensor noise modeling for extreme low-light photography [C]. 2023 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). June 17-24, 2023, Vancouver, BC, Canada. IEEE, 2023: 5744-5753.*
- [21] ZHANG F, XU B, LI Z Q, *et al.* Towards general low-light raw noise synthesis and modeling [C]. 2023 *IEEE/CVF International Conference on Computer Vision (ICCV). October 1-6, 2023, Paris, France. IEEE, 2024: 10786-10796.*
- [22] ZOU Y H, FU Y, ZHANG Y L, *et al.* Calibration-free raw image denoising *via* fine-grained noise estimation [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2025, 47(7): 5368-5384.
- [23] ZHENG D H, ZOU Y H, ZHANG X W, *et al.* SeNM-VAE: semi-supervised noise modeling with hierarchical variational autoencoder [C]. 2024 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). June 16-22, 2024,*

- Seattle, WA, USA. IEEE, 2024: 25889-25899.
- [24] CHEN C, CHEN Q F, XU J, *et al.* Learning to see in the dark[C]. 2018 *IEEE/CVF Conference*

on Computer Vision and Pattern Recognition. June 18-23, 2018, *Salt Lake City, UT, USA.* IEEE, 2018: 3291-3300.

作者简介:



夏 波(1999—),男,重庆垫江人,硕士研究生,2023年于重庆大学获得学士学位,研究方向为遥感影像处理和计算机视觉。E-mail: 20192504@stu.cqu.edu.cn

通讯作者:



黄 鸿(1980—),男,湖南新宁人,博士,教授,博士生导师,2005年、2008年于重庆大学分别获得硕士和博士学位,主要从事图像处理、机器视觉和图像测量方面的研究。E-mail: hhuang@cqu.edu.cn