

基于物理先验引导生成对抗网络的中子图像超分辨率重建

李佳豪, 仲新源, 刘梦滢, 付艳龙, 刘 洋*

华北电力大学核科学与工程, 北京

收稿日期: 2026年4月1日; 录用日期: 2026年4月14日; 发布日期: 2026年7月27日

摘 要

中子照相技术在复杂装备的无损检测中不可或缺, 但受限于探测器闪烁屏的光学散射与泊松-高斯混合噪声, 原始图像常面临空间分辨率低、边缘模糊的困境。传统的图像恢复算法极易导致“过平滑”效应, 而常规的深度生成模型在重建高频细节时, 往往因脱离物理规律而产生严重的“AI幻觉”与结构失真。针对上述痛点, 本文提出了一种基于物理先验引导的生成对抗网络(PI-GAN)超分辨率重建算法。该算法创新性地构建了基于中子点扩散函数(PSF)的可微分正向物理退化层, 并引入物理一致性损失, 将神经网络的纹理生成空间严格限制在物理法则允许的流形内。同时, 结合残差通道注意力机制与相对论判别器, 网络在极低信噪比下实现了端到端的高保真特征提取。以典型工业样品为测试对象的实验结果表明, 本文算法不仅彻底抑制了强混合噪声, 更从根本上杜绝了虚假波纹等伪影。与传统滤波方法相比, 该算法在结构相似性(SSIM)和峰值信噪比(PSNR)上取得显著提升, 调制传递函数(MTF)分析进一步证实其近乎无损地保留了极限空间分辨率。本文研究为突破中子成像硬件瓶颈、实现高精度无损检测提供了全新的理论框架与算法支撑。

关键词

中子成像, 超分辨率重建, 生成对抗网络, 无损检测

Neutron Image Super-Resolution Reconstruction Based on Physics-Informed Generative Adversarial Network

Jiahao Li, Xinyuan Zhong, Mengshi Liu, Yanlong Fu, Yang Liu*

School of Nuclear Science and Engineering, North China Electric Power University, Beijing

Received: April 1, 2026; accepted: April 14, 2026; published: July 27, 2026

*通讯作者。

文章引用: 李佳豪, 仲新源, 刘梦滢, 付艳龙, 刘洋. 基于物理先验引导生成对抗网络的中子图像超分辨率重建[J]. 核科学与技术, 2026, 14(3): 193-206. DOI: 10.12677/nst.2026.143017

Abstract

Neutron radiography is indispensable in the non-destructive testing (NDT) of complex equipment. However, constrained by optical scattering within the detector's scintillator screen and high Poisson-Gaussian mixed noise, raw projection images often suffer from low spatial resolution and blurred edges. Traditional image restoration algorithms easily lead to an "over-smoothing" effect, while conventional deep generative models, when reconstructing high-frequency details, frequently produce severe "AI hallucinations" and structural distortions due to the lack of physical constraints. To address these bottlenecks, this paper proposes a Physics-Informed Generative Adversarial Network (PI-GAN) for super-resolution reconstruction. The proposed algorithm innovatively constructs a differentiable forward physical degradation layer based on the neutron Point Spread Function (PSF) and introduces a physical consistency loss, strictly restricting the neural network's texture generation space to a manifold permitted by physical laws. Simultaneously, by combining a residual channel attention mechanism with a relativistic discriminator, the network achieves end-to-end high-fidelity feature extraction under extremely low signal-to-noise ratios. Experimental results on typical industrial samples demonstrate that the proposed algorithm not only thoroughly suppresses strong mixed noise but also fundamentally eliminates artifacts such as fabricated wavelets. Compared with traditional filtering methods, this algorithm achieves significant improvements in Structural Similarity (SSIM) and Peak Signal-to-Noise Ratio (PSNR). Furthermore, Modulation Transfer Function (MTF) analysis confirms that it preserves the ultimate spatial resolution almost losslessly. This research provides a novel theoretical framework and algorithmic support for breaking through the hardware bottlenecks of neutron imaging and realizing high-precision NDT.

Keywords

Neutron Imaging, Super-Resolution Reconstruction, Generative Adversarial Network, Non-Destructive Testing (NDT)

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

中子成像技术凭借其“穿重避轻”的独特物理核截面特性，在航空发动机叶片、燃料电池原位监测以及核能材料的无损检测中发挥着不可替代的作用。然而，与日益成熟的高分辨 X 射线微纳 CT 相比，中子成像系统的空间分辨率始终存在着难以逾越的物理硬件瓶颈。这一瓶颈主要根源于中子探测器核心组件——中子闪烁屏的固有物理机制。

在中子照相系统中，由于中子不带电，无法被 CCD 或 CMOS 相机直接记录，必须依赖含有特定同位素的闪烁屏将其转换为可见光子，再通过光学透镜耦合至探测器。这就引发了一个不可调和的物理矛盾：探测效率与空间分辨率的相互制约。为了提高对弱中子束的捕获概率、减少泊松统计噪声，通常需要增加闪烁屏的厚度；然而，较厚的闪烁屏会导致次级可见光子在屏内发生严重的多重光学散射与漫反射[1]。这种物理散射在宏观图像上表现为点扩散函数(Point Spread Function, PSF)的显著展宽，使得原本锐利的样品物理边缘发生严重的几何退化与光学模糊。因此，如何在不牺牲中子探测效率的前提下，突破厚闪烁屏带来的光学模糊，实现高频细节的超分辨率重建，成为了当前计算中子成像领域亟待解决的共性难题。

从数学本质上讲, 由于闪烁屏光学散射导致的图像模糊, 可以建模为一个典型的退化过程: $y = Hx + n$ 。其中, y 为观测到的模糊且含噪的中子投影图像, x 为理想的高分辨率清晰图像, H 为系统的退化矩阵(即闪烁屏的二维 PSF), n 为系统加性及泊松混合噪声。求解 x 是一个极其典型的病态逆问题。

在传统的图像处理框架下, 研究者主要采用反卷积算法来求解这一逆问题, 例如维纳滤波(Wiener Filter) [2]、Richardson-Lucy (R-L) 迭代算法 [3] 以及正则化约束的盲反卷积算法。这些线性或迭代方法在光学相机的去模糊中取得了一定效果, 但在中子成像中却遭遇了严重的水土不服。原因在于: 中子图像的本底噪声远高于普通光学图像。传统反卷积算子在频域内尝试恢复被衰减的高频信号时, 不可避免地会将高频噪声指数级放大, 最终在图像的边缘处产生严重的“振铃伪影”与伪特征。这种“去模糊即放大噪声”的窘境, 使得传统数学解析方法在中子成像高分辨重建中基本走入了死胡同。

近年来, 随着深度学习尤其是卷积神经网络(CNN)的飞速发展, 单图像超分辨率(Single Image Super-Resolution, SISR)技术迎来了颠覆性的突破。从早期的 SRCNN [4] 到后续的 VDSR [5]、RCAN [6] 等网络, 深度学习通过在大规模数据集上学习低分辨率(LR)到高分辨率(HR)图像之间的非线性映射, 展现出了超越传统插值与反卷积算法的惊人潜力。

然而, 传统的基于均方误差(MSE)或绝对误差(MAE)损失函数优化的超分辨率网络, 虽然能获得极高的信噪比(SNR), 但往往会输出极其平滑、缺乏真实高频纹理的“过度平滑”图像(如常规 U-Net 的处理结果)。为了重建出符合人眼视觉感知的真实物理细节, 生成对抗网络(Generative Adversarial Networks, GANs) [7] [8] 以及最新的扩散模型(Diffusion Models) [9] 被引入超分辨率领域。

以 ESRGAN 为代表的生成模型, 通过引入判别器的对抗博弈机制以及感知损失, 赋予了网络“幻化”极高频结构的能力 [10]。模型不再仅仅是“平滑”边缘, 而是能够基于低频上下文信息, 无中生有地生成出逼真的微观纹理。这类生成式模型为解决中子成像的闪烁屏模糊问题提供了革命性的工具箱。

尽管生成对抗网络与扩散模型在自然图像处理上取得了巨大成功, 但将其直接移植至中子无损检测领域仍面临着巨大的学术挑战。最核心的问题在于“缺乏成对数据集”与“AI 幻觉导致的物理失真”。

在真实的中子源实验环境中, 由于系统硬件的固定性, 研究人员极难在完全相同的视角下同时获取一张模糊厚屏图像和一张清晰的理想薄屏图像。此外, 通用生成模型缺乏物理世界的先验认知, 当面对严重模糊的中子图像时, 极易产生不受控的“AI 幻觉”(例如将模糊的均匀基体错误地渲染成波纹状或鳞片状伪影) [11]。在以“保真度”为生命线的工业无损检测中, 这种物理不可靠的伪影生成是致命的。

因此, 当前该领域最前沿的研究切入点, 是构建“物理先验引导”的深度生成模型 [12]。如何利用蒙特卡洛粒子输运代码精准模拟中子闪烁屏的物理 PSF, 通过合成大规模的退化数据集来驱动模型训练; 或者如何将中子成像的 MTF 物理退化规律直接作为正则项嵌入到生成器网络的损失函数中, 限制其生成域的空间, 从而在极大提升空间分辨率、去模糊的同时, 严格保证生成的边缘细节符合样品的真实物理形貌, 是突破中子成像超分辨率瓶颈的核心关键。

2. 理论分析

2.1. 中子成像系统的物理降质机理与数学建模

2.1.1. 闪烁屏的光学散射与空间分辨率限制

与 X 射线直接与核外电子发生相互作用不同, 中子不带电荷, 无法引起物质的直接电离。因此, 在基于电荷耦合器件(CCD)或互补金属氧化物半导体(CMOS)的现代中子照相系统中, 必须依赖中子闪烁屏作为转换介质。




Figure 1. Mechanism of neutron interaction with matter
图 1. 中子与物质反应机理

当中子束穿透样品后，会与图 1 所示的闪烁屏中的靶核(如 6Li、10B 或 Gd)发生核反应，释放出带电粒子并激发发光材料，最终将不可见的中子空间分布转换为可见光信号。然而，这一转换过程引入了中子成像系统中最核心的物理矛盾：探测效率与空间分辨率的制约关系。工程上通常倾向于增加闪烁屏的厚度以提高探测效率，但较厚的闪烁屏会导致次级可见光子在逸出屏表面之前，于荧光材料内部发生严重的多重光学散射与漫反射。这种光学散射效应在宏观尺度上表现为点扩散函数(Point Spread Function, PSF)的空间展宽，直接导致了图像高频结构的光学模糊。

2.1.2. 泊松 - 高斯混合噪声的统计特性

除了空间模糊，中子图像还受到极强噪声的干扰。一方面，由于中子源注量率有限以及中子发射的随机性，到达探测器的中子计数服从泊松分布，构成了信号依赖的量子噪声；另一方面，CCD/CMOS 相机在信号读出与暗电流放大过程中会引入独立于信号的电子噪声，通常可近似为高斯分布。因此，中子投影图像的噪声模型是一个复杂的泊松 - 高斯混合模型，这使得后续的逆问题求解环境极为苛刻[13]。

2.1.3. 图像退化的数学物理模型




Figure 2. Mathematical model of the forward physical degradation process in single image super-resolution reconstruction
图 2. 单图像超分辨率重建中的正向物理退化过程数学模型

综合上述物理过程，如图 2 所示，中子成像系统从理想高分辨物理空间到实际低分辨模糊观测空间的退化过程，可通过如下经典的离散数学物理模型进行描述：

$$y = (x * h) \downarrow_s + n \quad (1)$$

式中, y 表示观测到的低分辨率、模糊且含噪的中子投影图像; x 表示理想的、未降质的高分辨率清晰图像; h 表示系统的光学模糊核(即闪烁屏的二维 PSF); $*$ 为二维卷积算子; $\downarrow_s$ 表示下采样算子(缩放因子为 s), 代表探测器像素尺寸带来的离散化与空间分辨率降低; n 代表系统叠加的泊松-高斯混合噪声。超分辨率与去模糊的本质, 即是在已知 y (以及系统先验 h) 的条件下, x 反向求解的高度病态逆问题。

2.2. 传统图像恢复与超分辨率理论及其局限性

在深度学习广泛应用之前, 求解上述逆问题主要依赖于传统信号处理理论。最基础的空间分辨率提升方法是多项式插值, 但其无法恢复被模糊核 h 截断的高频信息。为了消除模糊, 研究者引入了反卷积算法(如维纳滤波、Richardson-Lucy 迭代算法)。然而, 传统反卷积算法在处理中子图像极低的信噪比时, 极易放大高频噪声, 并在强烈模糊的物理边缘处产生严重的“振铃伪影”, 无法满足无损检测的保真度要求。

2.3. 深度学习在单图像超分辨率中的演进

2.3.1. 基于 CNN 的超分辨率网络重建

自 SRCNN (Super-Resolution Convolutional Neural Network) 引入该领域以来, 网络架构经历了从浅层到深层(如 VDSR)、从单纯卷积到残差学习(如 ResNet、RCAN)的演进。这类模型通过构建深层的级联卷积层, 在大量“低分辨率-高分辨率”图像对上进行端到端的有监督训练, 隐式地学习逆退化函数 $x = F(y, \theta)$, 其中 θ 为网络权重。

2.3.2. 像素级损失函数引发的过平滑困境

绝大多数常规的 CNN 超分辨率模型均采用均方误差(MSE)或绝对误差(L1Loss)作为损失函数。其数学本质是追求像素级别的数值差异最小化, 这使得模型在训练时倾向于收敛到多个可能高频细节的统计平均值。

在宏观表现上, 虽然 MSE 驱动的网络能够获得极高的客观评价指标(如极高的峰值信噪比 PSNR), 但其输出的图像往往表现为令人难以忍受的“过度平滑”状态。正如在前沿中子图像预处理中所观察到的那样, 常规 U-Net 或 ResNet 虽然去除了背景噪声, 但也像橡皮擦一样抹去了样品内部微弱的物理纹理与结构渐变, 完全丧失了超分辨率重建恢复“细节”的初衷。

2.4. 深度生成模型及在中子无损检测中的适用性分析

2.4.1. 生成对抗网络的感知驱动机制




Figure 3. Super-resolution reconstruction architecture and loss function adversarial mechanism based on Generative Adversarial Network (GAN)

图 3. 基于生成对抗网络(GAN)的超分辨率重建架构与损失函数博弈机制

为了突破“过平滑”瓶颈,生成对抗网络(GAN)被引入。

如图3所示,在超分辨率领域,GAN由生成器和判别器构成博弈系统。它们引入了“感知损失”与“对抗损失”,不再强求像素值的绝对一致,而是要求生成图像在深层特征空间上与高分辨率原图分布一致[14]。这种机制赋予了生成器强大的“纹理幻化”能力,能无中生有地推断出高对比度的微观纹理。

2.4.2. 生成模型的物理失真挑战与研究契机

尽管生成模型在视觉上极其惊艳,但在中子无损检测中却暴露出致命缺陷:不受物理约束的结构失真。如图4所示,由于缺乏对物理规律的先验认知,当通用生成模型试图恢复被严重模糊的内部结构时,极易容易产生“过度解析”的伪特征(例如将均匀衰减梯度错误渲染成周期性的水波纹或褶皱状伪影)。




Figure 4. “AI hallucinations” and structural distortions generated by generative models without physical constraints
图4. 生成模型在缺乏物理约束时产生的“AI幻觉”与结构失真现象

在工业检测的语境下,这种AI幻觉会导致严重的缺陷误判。因此,如何提出一种物理先验引导的生成式超分辨率框架——将中子闪烁屏的退化核(PSF)作为正则项或物理损失函数直接嵌入神经网络的生成博弈过程中,限制其生成域的空间,确保所恢复的高频细节严格吻合样品的真实物理形貌,正是本课题亟待攻克的核心科学问题,也是下一章算法设计的核心动机。

2.5. 本章小结

除本章详细探讨了中子成像系统空间分辨率受限的物理根源,即闪烁屏的光学散射造成的严重PSF模糊,并建立了“模糊+下采样+混合噪声”的数学退化模型。在此基础上,系统梳理了传统反卷积算法因病态逆问题导致的噪声放大与振铃伪影缺陷,以及常规CNN超分辨率网络基于像素误差优化所固有的“过度平滑”问题。重点剖析了以GAN和扩散模型为代表的深度生成技术,论证了其在重建高频细节方面的卓越潜力,同时尖锐指出了其脱离物理规律导致的“AI幻觉”在无损检测中的致命性。上述理论分析揭示了现有方法的根本性矛盾,为后续提出基于物理先验引导的生成式重建算法指明了理论方向。

3. 生成式超分辨率算法设计

针对传统深度生成模型在中子图像超分辨率重建中存在的“物理失真”与“AI 幻觉”问题，本章提出了一种基于物理先验引导的生成对抗网络(Physics-Informed GAN, PI-GAN)。本章将详细阐述该算法的整体网络架构、物理退化先验的嵌入机制、生成器与判别器的模块设计，以及多维联合损失函数的数学构建过程，为实现中子图像的高保真、超分辨率重建提供完整的算法框架。

3.1. PI-GAN 算法整体架构框架

传统的超分辨率生成对抗网络(如 SRGAN、ESRGAN)通常只包含生成器和判别器两个核心组件，其训练完全由数据分布驱动，缺乏物理约束。为了纠正这一缺陷，本文提出的 PI-GAN 架构在标准 GAN 的基础上，创新性地引入了第三个核心组件：正向物理退化层。

算法的整体工作流程如下：首先，低分辨率且含噪的中子投影图像 y 被输入到深度生成器 G 中，生成器负责“幻化”并输出初步的高分辨率重建图像 x_{pred} 。随后，网络兵分两路：

1) 对抗鉴别分支： x_{pred} 与真实的高分辨率参考图像 x_{hr} (由蒙特卡洛仿真或多帧叠加获取)一同送入判别器 D ，通过二者的博弈提升图像的视觉逼真度与高频纹理丰富度。

2) 物理一致性约束分支：这是本算法的核心。将生成的 x_{pred} 输入至正向物理退化层，该层完全按照第二章推导的中子闪烁屏物理退化方程运作，对 x_{pred} 进行点扩散函数(PSF)卷积模糊与下采样，得到模拟的低分辨率观测图像 $\hat{y}$ 。网络要求 $\hat{y}$ 必须与真实的原始输入 y 保持高度一致。

这种闭环设计不仅强迫生成器学习高频纹理的统计分布，更强制要求其生成的任何微小细节都必须能完美符合中子射线与闪烁屏的物理相互作用规律，从而从根本上杜绝了无中生有的“波纹”或“褶皱”等 AI 幻觉伪影。

3.2. 物理退化先验的嵌入机制

要实现上述的物理约束，必须将离散的物理退化过程转化为神经网络可以进行反向传播的可微分张量运算。

3.2.1. 中子闪烁屏 PSF 的参数化建模

物理退化层的核心是中子闪烁屏的模糊核 h 。在实际中子源实验中，点扩散函数通常呈现出重尾特性，单纯的二维高斯分布无法精准拟合。因此，本节采用高斯函数与洛伦兹函数的线性组合来参数化建模系统 PSF：

$$h(u, v) = \alpha \cdot \exp\left(-\frac{u^2 + v^2}{2\sigma^2}\right) + (1 - \alpha) \frac{\gamma}{\pi((u^2 + v^2) + \gamma^2)} \quad (2)$$

式中， (u, v) 为空间坐标， σ 为高斯分布的标准差(表征光子的短程散射)， γ 为洛伦兹分布的尺度参数(表征光子的长程漫反射)， α 为权重系数。这三个参数可通过对成像系统边缘扩展函数(ESF)进行实验标定获得，并作为固定不变的物理先验(先验知识)冻结在网络中。

3.2.2. 可微分退化层的张量化实现

在获取物理模糊核 h 后，将其转化为一个固定权重、无偏置、且不参与梯度更新的二维深度卷积层。对于缩放因子为 s 的下采样操作，本网络采用基于反走样滤波的步长卷积来替代传统的双三次插值，以更真实地模拟 CCD/CMOS 探测器的像素积分效应。整个正向物理退化过程可表示为可微分的张量映射：

$$\hat{y} = \text{Downsample}(x_{pred} * h, s) \quad (3)$$

由于该层中的所有运算(卷积与降采样)均对输入张量 x_{pred} 连续可导, 因此物理约束产生的误差梯度能够顺利回传至生成器 G, 指导其网络权重的更新。

3.3. 生成器与判别器网络设计

在确立了物理框架后, 需要对生成器与判别器的内部拓扑结构进行专门优化, 以适应中子图像强噪声、弱边缘的极端特性。

3.3.1. 引入残差注意力机制的生成器

传统的残差块在提取特征时对各个通道一视同仁, 忽略了高频边缘信息与低频背景信息的差异。本算法的生成器采用残差密集块作为骨干网络, 并在每个 RRDB 模块后嵌入了通道注意力机制(Channel Attention Mechanism, CAM)。

通道注意力机制能够通过全局平均池化获取每个特征通道的全局响应分布, 并通过多层感知机(MLP)动态计算并重新分配各个通道的权重。这种机制赋予了网络一种“自适应筛选”能力: 网络会自主抑制包含大量泊松噪声的冗余通道, 而赋予那些表征叶片边缘、孔隙结构的高频纹理通道更大的权重。最终, 深层特征经过亚像素卷积层完成空间维度的上采样, 输出高分辨率图像 x_{pred} 。

3.3.2. 相对论平均判别器

标准 GAN 的判别器旨在输出一个绝对概率, 即“输入图像是真实图像的概率”。然而, 这种绝对判定在训练后期极易导致梯度消失或模式崩溃。为了提高对抗训练的稳定性, 本节采用相对论平均判别器(Relativistic Average Discriminator, RaD)。

RaD 不再评估图像绝对的真实性的, 而是评估“真实图像 x_{hr} 比生成图像 x_{pred} 更逼真的相对概率”。其网络结构包含连续的步长卷积、批归一化和 Leaky ReLU 激活函数。相对论机制使得生成器的梯度不仅来源于“让自己看起来更真”, 同时也来源于“让真实的图像看起来更假”, 从而显著加速了模型的收敛速度, 并促使生成器幻化出更加锐利、自然的物理纹理。

3.4. 联合损失函数设计

损失函数是驱动模型朝着正确方向收敛的核心引擎。为了在“高频细节重建”、“主观视觉感知”与“物理法则一致性”三者之间取得完美平衡, 本文设计了由四项组成的联合损失函数。总损失函数 L_{total} 定义为:

$$L_{total} = \lambda_1 L_{pixel} + \lambda_2 L_{perceptual} + \lambda_3 L_{adv} + \lambda_4 L_{phys} \quad (4)$$

式中, $\lambda_1, \lambda_2, \lambda_3, \lambda_4$ 为调节各损失项权重的超参数。

1) 像素级内容损失 L_{pixel}

为了保证图像宏观结构和低频亮度的正确性, 采用 L1 范数(平均绝对误差)计算生成图像与真实高频图像在像素域的差异:

$$L_{pixel} = \frac{1}{CHW} \sum \|x_{pred} - x_{hr}\|_1 \quad (5)$$

相比于均方误差(MSE), L1 损失对异常噪点具有更强的鲁棒性, 且不易导致图像过度平滑。

2) 感知损失 $L_{perceptual}$

感知损失旨在缩小两幅图像在人类视觉感知及高级语义层面的差距。本文利用在大规模数据集上预训练的 VGG-19 网络作为特征提取器, 计算两者在深层特征空间的欧氏距离:

$$L_{perceptual} = \frac{1}{C_j H_j W_j} \sum \|\phi_{3,4}(x_{pred} - \phi_{3,4}(x_{hr}))\|_2^2 \quad (6)$$

这一项是激发生成器“幻化”微观纹理的关键。

3) 对抗损失 L_{adv}

基于前文描述的相对论判别器，生成器的对抗损失定义为：

$$L_{adv} = -\mathbb{E}_{x_{hr}} \left[\log(1 - D_{Ra}(x_{hr}, x_{pred})) \right] - \mathbb{E}_{x_{pred}} \left[\log(D_{Ra}(x_{hr}, x_{pred})) \right] \quad (7)$$

对抗损失迫使生成图像的概率分布不断逼近真实高分辨图像的边缘分布。

4) 物理一致性损失 L_{phys}

这是扼杀“AI 幻觉”的制胜法宝。我们将生成的 x_{pred} 通过第 3.2.2 节定义的物理退化层，并约束其退化结果必须等同于原始输入 y ：

$$L_{phys} = \left\| \text{Downsample}(x_{pred} * h, s) - y \right\| \quad (8)$$

这一损失项构成了一个强大的数据保真项。如果生成器为了迎合感知损失而“捏造”了物理上不存在的波纹状伪影，那么这些伪影在经过 PSF 卷积模糊并下采样后，必然无法与原始输入 y 的像素分布相匹配，从而引发巨大的 L_{phys} 惩罚。因此，物理一致性损失有效地将生成器的解空间收敛到了符合射线物理学定律的流形上。

3.5. 小结

本章详细提出并构建了基于物理先验引导的生成对抗网络(PI-GAN)。该架构通过在生成器中引入残差通道注意力机制，大幅提升了模型对中子图像弱边缘特征的提取能力；通过使用相对论平均判别器，稳定了超分辨率重建的对抗训练过程。最关键的是，本算法在损失函数中前瞻性地嵌入了模拟闪烁屏光学散射行为的可微分物理退化层。联合优化的机制确保了生成的超分辨率图像既能具备由对抗博弈带来的高频视觉保真度，又能通过物理一致性损失严格锚定在物理法则允许的解空间内，从根本上攻克了生成式模型应用于无损检测时易产生“AI 结构性失真”的行业痛点。

4. 实验设置

为了验证所提基于物理先验引导的生成对抗网络(PI-GAN)超分辨率重建算法的有效性，本节将详细阐述网络训练与测试数据集的构建流程，并公开模型训练过程中的所有关键超参数，以确保本研究的严谨性与可复现性。

4.1. 数据集构建与来源

鉴于在真实中子源实验中极难在完全相同的视角下同时获取完美对齐的“模糊-清晰”图像对，本研究采用蒙特卡洛物理仿真与实测特征结合的方式构建数据集：

训练集(Training Set): 利用蒙特卡洛粒子输运代码精确模拟中子与闪烁屏靶核的物理相互作用及后续的次级光子散射过程，从而获取高精度的点扩散函数(PSF)先验。随后，从开源高分辨率图像库中筛选大量清晰图像作为基准，严格按照系统的物理退化数学模型(即施加 PSF 模糊、空间下采样以及泊松-高斯混合噪声)进行正向降质处理。最终合成了约 10,000 组具有对应关系的“低分辨率含噪-高分辨率清晰”图像对，作为生成网络端到端训练的数据驱动基础。

测试集(Test Set): 为了检验算法在真实复杂工业场景下的泛化能力，测试集选取了三个典型的工业无损检测样品：圆柱体、正方体以及带有精密小孔的指示器。这些样本的输入数据包含了极强的混合噪

声和严重的边缘模糊退化特征。此外，用于计算结构相似性(SSIM)和峰值信噪比(PSNR)等客观评价指标的伪无噪参考图像，同样基于蒙特卡洛仿真进行拟合获取。

4.2. 训练环境与关键超参数设置

本算法的深度学习框架基于 PyTorch 搭建，所有模型的训练与推理均在配备单张 NVIDIA RTX 4090 GPU 的高性能工作站上完成。

在网络优化方面，生成器与相对论平均判别器均采用 Adam 优化器进行梯度更新。为了在“高频细节重建”、“主观视觉感知”与“物理法则一致性”这三者之间取得最佳平衡，联合损失函数的各项权重需要进行精细调优。网络训练的关键超参数配置如表 1 所示：

Table 1. Key hyperparameter settings for the training of the PI-GAN algorithm
表 1. PI-GAN 算法训练关键超参数设置表

参数名称	参数符号	CNR
初始学习率	lr	$1 * 10^{-4}$
优化器动量参数	β_1	0.9
优化器动量参数	β_2	0.999
训练批次大小	Batch size	16
训练总轮数	Epochs	200
像素级损失权重	λ_1	1.0
感知损失权重	λ_2	0.1
对抗损失权重	λ_3	0.005
物理一致性权重	λ_4	0.5

5. 结果分析

本章将利用前述的三个典型工业样品(圆柱体、正方体、指示器)作为测试数据集，从定性分析和定量评价两个维度，对本文提出的 PI-GAN 算法与传统的非线性滤波算法(如大窗口中值滤波)进行深度对比。

为了公平评估不同方法的保边和去噪细节保持能力，传统非线性滤波采用了能够基本去除原图中伽马斑点的大窗口中值滤波器参数(例如， 7×7 像素窗口)。客观评价指标采用了信噪比(SNR)、对比度噪声比(CNR)、峰值信噪比(PSNR)、结构相似性(SSIM)以及调制传递函数(MTF)。这些指标将基于蒙特卡洛仿真获取的伪无噪参考图像(用于计算 PSNR 和 SSIM)或手动标记的背景和目标区域进行计算。

5.1. 定性视觉对比分析

图 5 展示了本文拟合的传统滤波结果与 PI-GAN 算法结果的视觉对比。以下对三个样品的具体细节进行深度剖析：

圆柱体(Row 1)：原始图像的边缘退化极其严重，几乎呈现出非连续的“刷子”状。传统的中值滤波(Middle Column)成功去除了绝大部分伽马斑点和高频噪声，使得背景和目标变得平滑。然而，代价是致命的：圆柱体的顶部和侧面边缘出现了严重的模糊和展宽，原本锐利的几何轮廓变得圆润和模糊，失去了对边缘细节的解析。相比之下，PI-GAN 算法不仅去噪彻底，而且成功恢复了圆柱体锐利的物理边缘，使得边界清晰可辨，这在传统方法中是无法实现的。

正方体(Row 2)：这是一个更具挑战性的案例。原图的顶部边缘呈现出多层模糊和分层(退化缺陷)。

传统滤波结果将这些多层模糊的边缘融合为了一个均匀的模糊区域，不仅丢失了锐利边缘，更丢失了原有的结构信息。PI-GAN 算法则精准地处理了这一缺陷，将顶部恢复为了一个清晰、单一的锐利边缘，说明其在深度保边细节恢复上的卓越能力。

指示器(Row 3): 这是最能体现传统方法细节丢失缺点的案例。指示器最核心的细节是顶部的两个圆形标记点和中间的一个小孔。在原图中，这些细节由于噪声和模糊而变得微弱。传统滤波结果为了追求背景的平滑，将两个标记点模糊化，而中间最关键的小孔细节由于窗口平滑过度而完全丢失或融合成了一个模糊块。PI-GAN 算法则实现了对这些微小高频细节的精准复原，两个标记点和中间的小孔清晰可见，体现了其在复杂、细微结构恢复上的压倒性优势。

视觉分析强烈印证了本文的理论预判：传统非线性滤波为了去噪，牺牲了过多的高频空间分辨率(边缘和微小细节)，而 PI-GAN 算法成功解决了这一长期存在的病态问题。




Figure 5. Visual comparison of different preprocessing algorithms on complex neutron projection images. From top to bottom: cylinder, cube, and indicator with precise small holes. From left to right: raw image with heavy noise, traditional filtering method, and the proposed PI-GAN algorithm

图 5. 不同预处理算法对复杂中子投影图像的视觉效果对比从上到下依次为：圆柱体、正方体、带有精密小孔的指示器。从左到右依次为：原始强噪声图像、传统滤波方法、本文 PI-GAN 算法

5.2. 定量客观评价

除为进一步量化不同算法对投影细节保持和噪声抑制能力的差异，本文计算了表 2 中的客观评价指标。表中的伪无噪参考图像(用于 PSNR 和 SSIM 计算)基于蒙特卡洛仿真结果进行拟合。SNR_{bg} 采用背

景(ROI_bg)区域的均值和标准差计算。CNR 采用目标(ROI_target)和背景区域的均值和组合标准差计算。

Table 2. Comparison of objective evaluation metrics for different preprocessing algorithms on complex neutron projection images

表 2. 不同预处理算法对复杂中子投影图像的客观评价指标对比

算法模型	SNR_bg	CNR	PSNR	SSIM
原始图像	30.15	1.48	24.50	0.62
传统方法	60.32	2.12	34.80	0.76
PI-GAN	65.48	3.65	40.12	0.96

数据结果分析:

信噪比分析: 由于传统方法采用了大窗口平滑滤波器, 其背景信噪比(SNR_bg)提升显著, 达到 60.32, 说明平滑效果好。PI-GAN 的 SNR_bg 也达到了 65.48, 体现了优秀的噪声抑制能力。

对比度噪声比分析: 传统方法的 CNR 提升有限(仅为 2.12), 这主要是因为其边缘模糊导致目标与背景的区分度下降。PI-GAN 的 CNR 跃升至 3.65, 体现了其在深度去噪的同时成功恢复了物理对比度, 实现了真正的信噪提升。

峰值信噪比分析: 虽然基于像素级误差的 PSNR 传统方法也不错, 但 PI-GAN 在保持高保真细节的同时实现了更高的 PSNR (40.12 dB), 说明其在整体图像恢复上的优越性。

结构相似性分析(核心指标): 最关键的 SSIM 指标清晰地量化了“细节和结构保持能力”。由于严重的模糊和细节丢失, 传统方法对这三个复杂样品的结构相似性(SSIM)得分偏低(0.76), 反映了其结构破坏的致命缺陷。相比之下, 本文提出的 PI-GAN 算法获得了几乎满分的 SSIM (0.96), 数值上印证了视觉分析中对小孔和边缘精准保真恢复的结论, 证明了其在深度特征空间保持高保真物理结构的卓越能力。

基于这一分析, 可以明确: PI-GAN 算法在客观数据上展现了其优于传统方法的压倒性细节恢复能力。

5.3. 调制传递函数(MTF)空间分辨率验证

为了在频域定量评估空间分辨率, 图 6 拟合了三个样品的平均 MTF 曲线。极限分辨率定义为 MTF 下降至 10%时对应的空间频率。




Figure 6. Comparison of average MTF curves for different preprocessing algorithms
图 6. 不同预处理算法的平均 MTF 曲线对比

原始图像: 曲线呈现快速下降趋势,但在中低频阶段依然保留了一些对比度。极限分辨率频率较低。

传统滤波: MTF 曲线呈现最陡峭的下降趋势。在中高频阶段的对比度传递率(MTF 值)远低于原图,反映了严重的细节平滑和保边能力丧失。其极限分辨率频率最低,验证了视觉上的模糊。

PI-GAN 算法: MTF 曲线呈现出最平缓的下降趋势。在全频率范围内,特别是高频段(极限频率附近),MTF 值始终保持在原图上方或紧贴原图,这在频域上强有力地证明了该算法在彻底清除高斯-泊松噪声的同时,凭借边缘保护机制,近乎无损地保留了目标物理边缘的高频空间分辨率。这一 MTF 数据是算法保边细节最硬核的证据。

综合视觉和数据分析,结果表明 PI-GAN 算法在复杂降质的中子图像上取得了最优效能,为后续高精度三维层析重建打下了坚实基础。

6. 结论

中子成像技术在航空航天及核工业的高密度复杂装备无损检测中具有不可替代的作用。然而,受限于中子闪烁屏内部严重的光学散射效应以及极高的泊松-高斯混合噪声干扰,中子投影图像长期面临着空间分辨率低下、高频边缘模糊的物理瓶颈。近年来崛起的深度生成模型(如 GAN 和扩散模型)虽具备强大的纹理生成能力,但在应用于物理过程极其严谨的无损检测时,极易因缺乏物理约束而产生“水波纹”、“结构扭曲”等致命的 AI 幻觉。

针对上述痛点,本文跳出了传统数据驱动算法的固有框架,将深度神经网络的生成能力与中子射线的物理退化规律深度融合,提出了一种基于物理先验引导的生成式超分辨率重建算法(PI-GAN),并取得了一系列具有重要学术价值与工程应用潜力的研究成果。

具体工作总结如下:

1) 构建了可微分的中子物理退化模型: 本文深入剖析了中子闪烁屏的物理响应机制,采用高斯-洛伦兹混合分布对系统的点扩散函数(PSF)进行了精确参数化建模。在此基础上,创新性地将该物理模糊核与空间下采样操作转化为网络中可微分的“正向物理退化层”,为后续的物理先验嵌入打下了数学基础。

2) 提出了物理一致性驱动的联合生成框架: 在传统的对抗博弈架构中,本文前瞻性地引入了物理一致性损失。该机制强制要求生成的高分辨率图像在经过正向物理退化层后,必须严格退化为真实的原始观测图像。这一“物理法则枷锁”成功地将生成器的解空间限制在了符合真实物理规律的流形上,从根本上消除了超分辨率重建过程中的 AI 幻觉与结构失真。

3) 通过复杂工业样品的实验验证了算法的压倒性优势: 依托真实的工业无损检测样品(圆柱体、正方体、精密指示器等),本文开展了详尽的对比实验。定性视觉分析表明,相较于传统的大窗口非线性滤波方法,本文算法不仅彻底清除了混合噪声,更近乎完美地复原了样品的极微小孔隙与锐利边缘。定量客观评价进一步证实,本文算法在结构相似性(SSIM)上取得了极高的保真度得分,且基于调制传递函数(MTF)的频域分析表明,其极限空间分辨率获得了显著提升,真正实现了“保真”与“超分”的双赢。

参考文献

- [1] Knoll, G.F. (2010) Radiation Detection and Measurement. 4th Edition, Wiley.
- [2] Wiener, N. (1949) Extrapolation, Interpolation, and Smoothing of Stationary Time Series: With Engineering Applications. MIT Press. <https://doi.org/10.7551/mitpress/2946.001.0001>
- [3] Richardson, W.H. (1972) Bayesian-Based Iterative Method of Image Restoration. *Journal of the Optical Society of America*, **62**, 55-59. <https://doi.org/10.1364/JOSA.62.000055>
- [4] Dong, C., Loy, C.C., He, K., et al. (2015) Image Super-Resolution Using Deep Convolutional Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **38**, 295-307. <https://doi.org/10.1109/TPAMI.2015.2439281>

- [5] Kim, J., Lee, J.K. and Lee, K.M. (2016) Accurate Image Super-Resolution Using Very Deep Convolutional Networks. *2016 Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Las Vegas, 27-30 June 2016, 1646-1654.
- [6] Zhang, Y., Li, K., Li, K., *et al.* (2018) Image Super-Resolution Using Very Deep Residual Channel Attention Networks. *Proceedings of the European Conference on Computer Vision (ECCV)*, Munich, 8-14 September 2018, 286-301.
- [7] Goodfellow, I., Pouget-Abadie, J., Mirza, M., *et al.* (2014) Generative Adversarial Nets. *Advances in Neural Information Processing Systems*, Montréal, 8-13 December 2014, 2672-2680.
- [8] Ledig, C., Theis, L., Huszár, F., *et al.* (2017) Photo-Realistic Single Image Super-Resolution Using a Generative Adversarial Network. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Honolulu, 21-26 July 2017, 4681-4690. <https://doi.org/10.1109/CVPR.2017.19>
- [9] Ho, J., Jain, A. and Abbeel, P. (2020) Denoising Diffusion Probabilistic Models. *Advances in Neural Information Processing Systems*, **33**, 6840-6851.
- [10] Wang, X., Yu, K., Wu, S., *et al.* (2018) ESRGAN: Enhanced Super-Resolution Generative Adversarial Networks. *Proceedings of the European Conference on Computer Vision (ECCV) Workshops*, Munich, 8-14 September 2018.
- [11] Antun, V., Renna, F., Poon, C., *et al.* (2020) On Instabilities of Deep Learning in Image Reconstruction and the Potential Costs of AI. *Proceedings of the National Academy of Sciences*, **117**, 30088-30095. <https://doi.org/10.1073/pnas.1907377117>
- [12] Raissi, M., Perdikaris, P. and Karniadakis, G.E. (2019) Physics-Informed Neural Networks: A Deep Learning Framework for Solving Forward and Inverse Problems Involving Nonlinear Partial Differential Equations. *Journal of Computational Physics*, **378**, 686-707. <https://doi.org/10.1016/j.jcp.2018.10.045>
- [13] Foi, A., Trimeche, M., Katkovnik, V., *et al.* (2008) Practical Poissonian-Gaussian Noise Modeling and Fitting for Single-Image Raw-Data. *IEEE Transactions on Image Processing*, **17**, 1737-1754. <https://doi.org/10.1109/TIP.2008.2001399>
- [14] Johnson, J., Alahi, A. and Li, F.F. (2016) Perceptual Losses for Real-Time Style Transfer and Super-Resolution. *Proceedings of the European Conference on Computer Vision*, Amsterdam, 11-14 October 2016, 694-711.