

# 时频双域注意力机制 GAN 的电磁信号降噪<sup>①</sup>



边杏宾, 石 森, 胡志勇, 马俊明

(中国电子科技集团公司 第三十三研究所, 太原 030032)  
通信作者: 边杏宾, E-mail: [xbbian33@163.com](mailto:xbbian33@163.com)

**摘 要:** 在电磁信息安全领域, 电磁泄漏红信号的检测受电磁噪声干扰影响严重. 传统降噪方法在处理非平稳信号和复杂噪声环境时存在局限性. 提出一种基于生成对抗网络 (GAN) 的降噪方法, 通过生成器与判别器的对抗学习实现高效降噪. 针对电磁信号的非平稳特性设计了时频双域注意力机制 (time-frequency dual-domain attention mechanism, TF-DAM), 生成器采用基于 TF-DAM 改进的 U-Net 架构, 结合残差网络和 dropout 层增强泛化能力, 利用编码器-解码器结构和跳跃连接保留信号细节, 训练过程中采用动态调整损失权重的策略提高训练效率和降噪效果. 实验表明, 该方法在信噪比提升和细节保留上优于传统方法, 在非平稳信号处理中表现突出. 本研究为电磁信号降噪提供了新思路, 具有较高应用价值.

**关键词:** 非平稳电磁信号; 生成对抗网络; 时频双域注意力机制; U-Net 改进架构; 损失权重动态调整

引用格式: 边杏宾, 石森, 胡志勇, 马俊明. 时频双域注意力机制 GAN 的电磁信号降噪. 计算机系统应用. <http://www.c-s-a.org.cn/1003-3254/10097.html>

## Electromagnetic Signal Denoising Using Time-frequency Dual-domain Attention Mechanism GAN

BIAN Xing-Bin, SHI Sen, HU Zhi-Yong, MA Jun-Ming

(The 33rd Research Institute of China Electronics Technology Group Corporation, Taiyuan 030032, China)

**Abstract:** In the field of electromagnetic information security, the detection of electromagnetic leakage of red signals is severely affected by electromagnetic interference. Traditional denoising methods exhibit limitations when dealing with non-stationary signals and complex noise environments. In this study, a denoising method based on generative adversarial network (GAN) is proposed, and efficient noise reduction is achieved through adversarial learning between the generator and discriminator. To address the non-stationary characteristics of electromagnetic signals, a time-frequency dual-domain attention mechanism (TF-DAM) is designed. The generator adopts an improved U-Net architecture that incorporates TF-DAM and integrates residual networks and dropout layers to enhance generalization capability. The encoder-decoder structure and skip connections are utilized to preserve signal details. During training, a dynamic loss-weight adjustment strategy is employed to improve training efficiency and denoising performance. Experimental results demonstrate that the proposed method outperforms traditional approaches in terms of signal-to-noise ratio (SNR) improvement and detail preservation, exhibiting superior performance in nonstationary signal processing. This study provides a novel solution for electromagnetic signal denoising, demonstrating high practical application value.

**Key words:** non-stationary electromagnetic signal; generative adversarial network (GAN); time-frequency dual-domain attention mechanism (TF-DAM); enhanced U-Net architecture; dynamic loss-weight adjustment

<sup>①</sup> 基金项目: 中央引导地方科技发展资金 (YDZJSX2025B009, YDZJSX2025B010); 太原市关键核心技术攻关“揭榜挂帅”项目 (2024TYJB0129).  
收稿时间: 2025-08-21; 修改时间: 2025-09-16; 采用时间: 2025-10-14; csa 在线出版时间: 2026-01-08



降噪、物理勘探、通信等领域的信号降噪<sup>[20-27]</sup>. 本文训练基于 TF-DAM 改进的 GAN 来得到具有对电磁信号降噪能力的生成模型算法. 降噪 GAN 包含一个降噪生成器和一个判别器. 在训练过程中, 生成器尽力产生接近无噪声的信号, 判别器识别输入信号是真实的无噪声信号还是生成器生成的无噪声信号, 这样形成生成器与判别器的博弈. 在多轮训练的博弈过程中, 生成器和判别器在提升各自能力的同时促使对方提升能力, 生成器生成信号的信噪比逐渐提高.

降噪 GAN 训练使用带噪声数据和无噪声数据, 而现实中不能获得纯净的无噪声数据, 因此, GAN 网络使用合成数据进行训练, 这些数据由无噪声和含噪声信号对组成. 所以, 构建用于训练降噪的 GAN 网络的合成训练集也是一项重要工作.

电磁信号降噪 GAN 的模型结构图如图 1 所示.

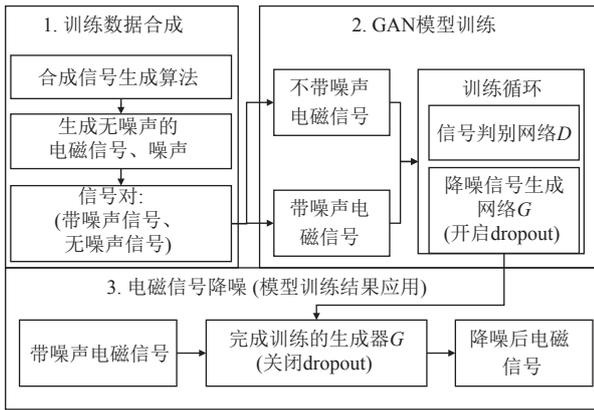


图 1 TF-DAM GAN 电磁信号降噪总体设计

## 2.2 基于 TF-DAM 的降噪生成器模型设计

针对电磁信号的非平稳特性, 本文提出了一种基于并行双注意力机制的时频域注意力模块 (TF-DAM), 该设计通过并行双路径结构, 兼顾通道敏感性与时频局部性, 为电磁信号处理提供了高效的特征优化机制.

TF-DAM 是为电磁信号降噪设计的动态特征加权机制, 通道注意力和空间注意力机制通过联合分析信号的时域瞬态特性和频域能量分布, 自适应地增强有效信号成分并抑制噪声. TF-DAM 同时捕捉时域脉冲突变和频域窄带干扰, 权重由数据驱动, 无需预设噪声统计特性. TF-DAM 通道注意力表达式为:

$$\alpha_c = \sigma(MLP(GAP(F_{ff})) \odot \sigma(MLP(GMP(F_{ff}))) \quad (1)$$

其中,  $F_{ff}$  为时频特征图 ( $T$  时间步  $\times F$  频率点  $\times C$  通道);  $GAP/GMP$  是全局池化层, 分别提取平均/最大能量

特征;  $MLP$  是两层全连接, 中间层压缩率  $r = 16$ ;  $\odot$  为 Hadamard 积 (逐元素乘).

空间注意力表达式为:

$$\alpha_s = \sigma(f^{3 \times 3}([\text{AvgPool}(F_{ff}); \text{MaxPool}(F_{ff})])) \quad (2)$$

其中,  $f^{3 \times 3}$  为  $3 \times 3$  卷积核, 感受野覆盖  $5 \mu\text{s} \times 200 \text{ kHz}$  时频区域;  $[\cdot; \cdot]$  为通道拼接操作.

TF-DAM 结构由并行的通道注意力和空间注意力支路构成, 如图 2 所示.

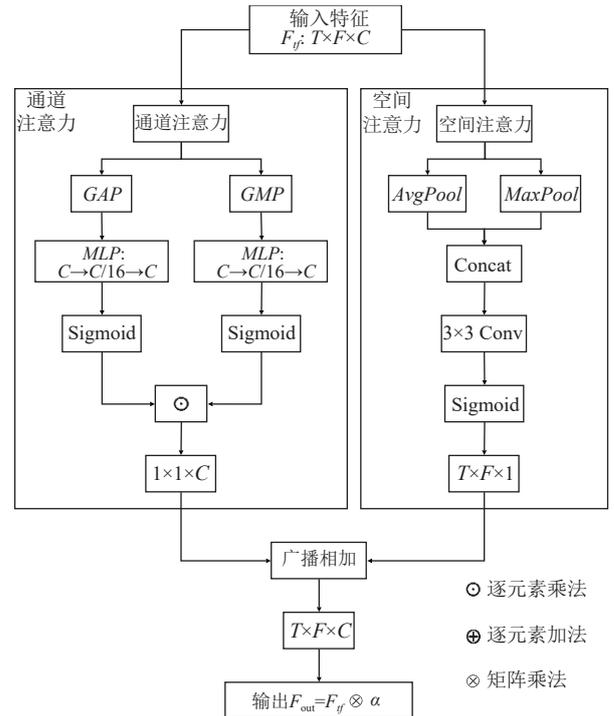


图 2 时频双域注意力机制 (TF-DAM) 结构

如图 3 所示, 该模块由通道注意力支路和空间注意力支路并联构成, 通过协同建模通道间依赖关系与时频空间特征, 实现对关键信息的动态增强.

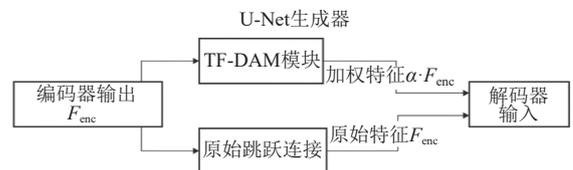


图 3 TF-DAM 与 U-Net 的集成方式

(1) 通道注意力支路. 输入特征  $F_{in} \in \mathbb{R}^{T \times F \times C}$  首先通过全局平均池化 ( $GAP$ ) 压缩时频维度, 生成通道描述符. 随后由两层  $MLP$  构成的瓶颈结构 ( $C \rightarrow C/16 \rightarrow C$ ) 学习通道间非线性交互, 其中,  $\text{ReLU}$  激活函数隐含于  $MLP$  中. 通过  $\text{Sigmoid}$  函数生成通道注意力权重  $\alpha_c \in$

$\mathbb{R}^{1 \times 1 \times C}$ , 与输入特征逐通道相乘, 实现通道维度上的自适应校准。

(2) 空间注意力支路. 在时频空间维度上, 分别采用平均池化与最大池化提取局部区域的聚合特征, 并将结果拼接形成多尺度上下文表征. 通过  $3 \times 3$  卷积层融合空间信息, 生成空间注意力图  $a_s \in \mathbb{R}^{T \times F \times 1}$ , 经 Sigmoid 激活后加权输入特征, 突出重要时频区域。

(3) 特征融合与输出. 两条支路的注意力权重通过广播相加进行融合, 生成综合注意力掩码  $a$ . 最终输出  $F_{out} = F_{in} \otimes a$  通过逐元素乘法实现特征重构, 有效增强非平稳信号中的关键成分。

本文将时频域注意力模块 (TF-DAM) 嵌入 U-Net<sup>[28-30]</sup> 生成器的编码器-解码器结构中, 与原始跳跃连接形成并联连接 (称为 TF-DAM-skip). 通过多尺度特征校准提升生成网络的表征能力. 集成方式如图 3 所示, 其核心设计如下。

(1) 编码器路径的特征增强. 在 U-Net 编码器的每一层级输出引入 TF-DAM 模块, 对提取的时频特征  $F_{enc} \in \mathbb{R}^{T \times F \times C}$  进行动态优化. TF-DAM 通过并行的通道与空间注意力机制生成加权特征  $c_1 F_{enc}$ , 其中  $c_1$  为注意力权重, 用于抑制噪声干扰并增强有效信号成分。

(2) 跳跃连接的改进. 传统 U-Net 的跳跃连接直接传递编码器特征至解码器<sup>[28]</sup>, 可能引入冗余信息. 本方法将原始跳跃连接替换为经 TF-DAM 加权的特征  $c_1 F_{enc}$ , 实现跨层级特征的自适应融合. 该设计保留多尺度信息的同时, 通过注意力机制突出与任务相关的时频局部模式, 缓解梯度传播中的信息稀释问题。

(3) 解码器的特征重构. 解码器输入接收来自编码器的加权特征  $c_1 F_{enc}$  及低层特征, 通过上采样与卷积操作逐步恢复信号分辨率. TF-DAM 的引入使得解码器在特征融合阶段更关注具有高判别性的时频区域, 提升生成信号的结构保真度与能量分布的准确性。

本文降噪 GAN 模型中, 生成器  $G$  由 U-Net model 基于 TF-DAM 改进而来, 保留二维卷积层以便能够学习更复杂的信号和噪声特征, 同时增加一维信号和二维信号转换以适应模型维度. 在训练过程中, 生成器输入信号由一维转换为二维, 输出保留二维 (判别器  $D$  用二维信号作判别处理). 训练完成后  $G$  的测试或应用阶段, 输入信号一维转换为二维, 输出信号从二维转换为一维。

本文基于 U-Net 架构的生成器具有编码器 (encoder)

和解码器 (decoder) 部分, 共同构成残差网络, 在解码过程中利用跳跃连接 (skip connection) 以保留更多空间信息, 有利于生成高质量的输出。

编码器使用带有 Leaky ReLU 激活函数的多个卷积层 (卷积核为  $3 \times 3$ , 步长为 (2, 2)) 逐步下采样输入, 每次下采样特征维度减半, 而通道数增加一倍 (增加滤波器数量:  $64 \rightarrow 128 \rightarrow 256 \rightarrow 512$ ). 在每次下采样后应用批量归一化 (batch normalization) 以加速训练过程和提高模型的泛化能力。

如图 4 所示, 解码器使用转置卷积 (conv2D transpose) 上采样, 同样使用批量归一化和 Leaky ReLU. 利用跳跃连接从相应编码器层的输出合并特征, 以增强细节保留. 最后一层不使用激活函数, 直接输出到所需通道数, 经过裁剪操作 (cropping2D) 以恢复到原始输入尺寸。

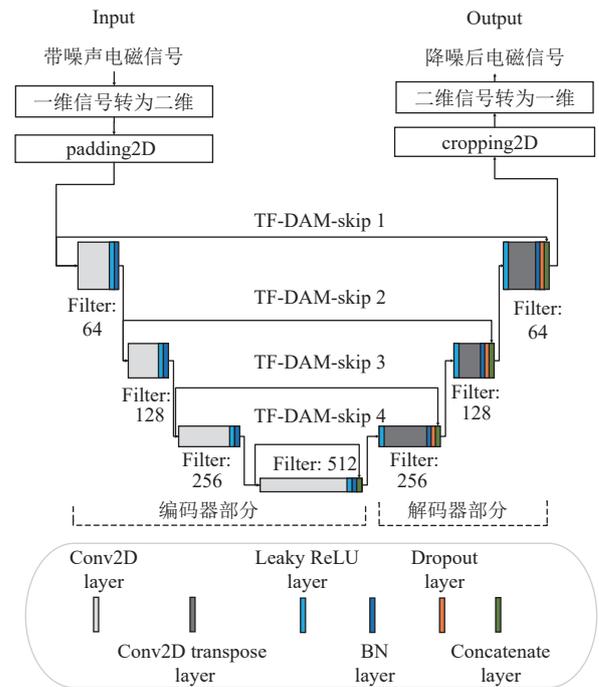


图 4 生成器网络结构

解码器通过上采样和卷积操作 (卷积核为  $3 \times 3$ , 步长为 (2, 2)) 逐步恢复特征图的分辨率, 同时减少通道数 (减少滤波器个数:  $512 \rightarrow 256 \rightarrow 128 \rightarrow 64$ ). 每个卷积层后接 Leaky ReLU 激活函数层、批量归一化层、dropout 层 (防止神经网络过拟合), 最后是跳跃连接层 (concatenate). 跳跃连接将编码器中对应层的特征图与上采样后的特征图拼接, 以融合低级特征 (细节信息) 和高级特征 (结构信息), 提供了额外的梯度传播路

径,解决训练深层网络的梯度消失问题<sup>[31-33]</sup>.

### 2.3 判别器模型设计

判别器  $D$  的任务是区分真实样本和生成器产生的假样本. 它是一个相对简单的卷积神经网络 (CNN), 用于输出一个标量值, 表示输入数据的真实性.

图 5 中, 通过一系列带有 Leaky ReLU 激活函数的卷积层 (卷积核为  $3 \times 3$ , 步长为  $(2, 2)$ ) 逐步下采样输入信号, 同时增加特征图的数量 (滤波器数变化:  $64 \rightarrow 128 \rightarrow 256 \rightarrow 512$ ). 使用批量归一化来稳定训练过程. 最后, 数据被展平 (flatten), 并通过一个全连接层 (dense) 输出一个值, 该值表示输入是真实数据的概率.

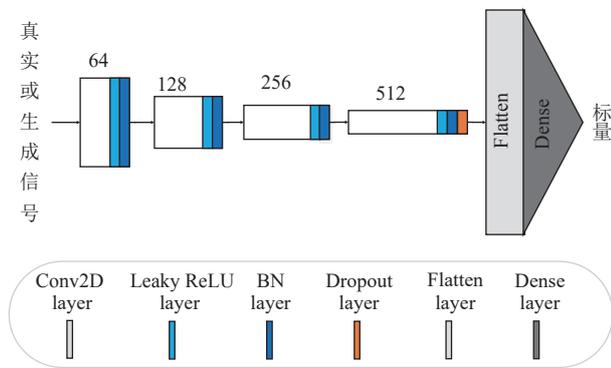


图 5 判别器网络结构

### 2.4 损失函数

#### (1) 动态调整权重的生成器损失函数

生成器的损失函数由两部分损失构成, 分别用于不同的目的. 一是让生成器生成的信号能够“欺骗”判别器, 使得判别器认为生成的信号是真实信号 (即标签为 1), 称为“判别损失”; 二是生成信号和真实信号的差异, 称为“绝对误差损失”.

1) 判别损失. 该部分损失函数使用二元交叉熵损失 (binary cross-entropy loss), 其公式为:

$$\mathcal{L}_G = -\frac{1}{N} \sum_{i=1}^N [y_i \cdot \log(D(G(z_i))) + (1-y_i) \cdot \log(1-D(G(z_i)))] \quad (3)$$

其中,  $D(G(z_i))$  是判别器对生成信号  $G(z_i)$  的输出;  $y_i$  是目标标签, 对于生成器损失, 希望判别器将生成信号判断为真实信号, 因此  $y_i = 1$ ;  $N$  是批量大小 (batch size). 由于  $y_i = 1$ , 损失函数简化为:

$$\mathcal{L}_G = -\frac{1}{N} \sum_{i=1}^N \log(D(G(z_i))) \quad (4)$$

生成器的目标是让判别器将生成信号判断为真

实信号 (即  $D(G(z_i))$  接近 1). 当  $D(G(z_i))$  接近 1 时,  $\log(D(G(z_i)))$  接近 0, 损失  $\mathcal{L}_G$  也接近 0; 当  $D(G(z_i))$  接近 0 时,  $\log(D(G(z_i)))$  会趋向负无穷, 损失  $\mathcal{L}_G$  会变得非常大. 因此, 生成器通过最小化这个损失函数, 逐渐生成更逼真的信号, 使判别器难以区分生成信号和真实信号.

2) 绝对误差损失. 该损失函数旨在最小化生成信号和真实信号 (label) 之间的位点级差异. 具体来说, 这个损失函数使用平均绝对误差 (mean absolute error, MAE) 来衡量生成信号与真实信号之间的差异. 这个损失函数在生成信号和真实信号之间施加位点级别的约束, 使得生成信号在位点级别上尽量接近真实信号. 对于单个位点, 绝对误差是生成信号位点值  $G_i$  和真实信号位点值  $L_i$  之间的绝对差:

$$absolute\_difference_i = |L_i - G_i| \quad (5)$$

对于整个信号 (或批次中的信号), 平均绝对误差是所有位点绝对差的平均值:

$$MAE(L, G) = \frac{1}{N} \sum_{i=1}^N |L_i - G_i| \quad (6)$$

其中,  $N$  是信号中位点的总数 (或批次中所有信号的位点总数);  $L_i$  是真实信号的第  $i$  个位点值;  $G_i$  是生成信号的第  $i$  个位点值. 通过一个超参数  $\lambda_s$  来控制该损失的权重. 因此, 生成器损失函数的形式化表示为:

$$\mathcal{L}_{generator} = \mathcal{L}_G + \lambda_s \cdot MAE(L, G) \quad (7)$$

#### (2) 判别器损失函数

判别器的目标是区分真实信号和生成信号, 因此它的损失函数由两部分组成: 1) 真实信号的损失, 判别器应尽量将真实信号分类为真实 (即输出接近 1). 2) 生成信号的损失, 判别器应尽量将生成信号分类为虚假 (即输出接近 0).

在 GAN 中, 判别器的损失函数使用二元交叉熵损失 (binary cross-entropy loss). 对于单个样本, 二元交叉熵损失的公式为:

$$\mathcal{L}(y, y') = -(y \cdot \log(\sigma(y')) + (1-y) \cdot \log(1-\sigma(y'))) \quad (8)$$

其中,  $y$  是真实标签 (0 或 1);  $y'$  是判别器的输出 (未经过 Sigmoid 激活);  $\sigma(y')$  是 Sigmoid 函数, 将  $y'$  转换为概率值  $\sigma(y') = \frac{1}{1+e^{-y'}}$ .

对于真实信号, 判别器的目标是将其分类为真实 (即输出接近 1). 因此, 真实信号损失函数为:

$$\mathcal{L}_{\text{real}} = \frac{1}{N} \sum_{i=1}^N -\log(\sigma(y_{\text{real}}^i)) \quad (9)$$

其中,  $y_{\text{real}}^i$  是判别器对第  $i$  个真实信号的输出;  $N$  是真实信号的数量。

对于生成信号, 判别器的目标是将其分类为虚假(即输出接近 0)。因此, 生成信号的损失函数为:

$$\mathcal{L}_{\text{fake}} = \frac{1}{M} \sum_{j=1}^M -\log(1 - \sigma(y_{\text{fake}}^j)) \quad (10)$$

其中,  $y_{\text{fake}}^j$  是判别器对第  $j$  个生成信号的输出;  $M$  是生成信号的数量。

判别器的总损失函数是真实信号损失和生成信号损失的和:  $\mathcal{L}_{\text{discriminator}} = \mathcal{L}_{\text{real}} + \mathcal{L}_{\text{fake}}$ , 因此:

$$\begin{aligned} \mathcal{L}_{\text{discriminator}} = & \frac{1}{N} \sum_{i=1}^N -\log(\sigma(y_{\text{real}}^i)) \\ & + \frac{1}{M} \sum_{j=1}^M -\log(1 - \sigma(y_{\text{fake}}^j)) \quad (11) \end{aligned}$$

其中,  $y_{\text{real}}^i$  是判别器对第  $i$  个真实信号的输出;  $y_{\text{fake}}^j$  是判别器对第  $j$  个生成信号的输出。

### 3 实验与分析

#### 3.1 构造训练数据

信号降噪 GAN 模型训练面临的一个问题是, 获取纯净信号存在显示困难, 构造具有复杂成分的非平稳合成信号数据。

##### (1) 纯净电磁信号合成与物理约束增强

纯净电磁信号  $s(t)$  通过参数化建模生成基信号并叠加典型调制特征, 同时注入物理约束以符合实际传播规律。具体表达式为:

$$\begin{aligned} s(t) = & \sum_{k=1}^K A_k \cdot m_k(t; \theta_k) \cdot \exp(j(2\pi f_k t + \phi_k)) \\ & \cdot h(t; \tau_k, \beta_k) \cdot \frac{d_0}{d} e^{-\mu(f_k)d} + \epsilon(f_k, d) \quad (12) \end{aligned}$$

其中,  $A_k$  为第  $k$  个信号分量的幅度;  $m_k(t; \theta_k)$  为调制函数(如 AM/FM/QAM), 其参数为  $\theta_k$ ;  $f_k$  和  $\phi_k$  分别为载波频率与初始相位;  $h(t; \tau_k, \beta_k)$  为模拟多径效应的衰减模型,  $\tau_k$  为时延,  $\beta_k$  是频散系数;  $d$  为信号传播距离,  $d_0$  为参考距离;  $\mu(f_k)$  为频率相关的衰减系数;  $\epsilon(f_k, d)$  为多径效应残差项, 服从复高斯分布  $CN(0, \sigma_\epsilon^2(f_k)d^{-2})$ 。

信号的频带范围被限制为  $f_k \in [f_{\min}, f_{\max}]$  以拟合设

备发射频带特性。此外, 时频域联合增强进一步约束信号: 时域上引入随机时移  $\Delta t \sim \mathcal{U}(0, T_{\max})$  和时钟抖动  $\delta t \sim \mathcal{N}(0, \sigma_t^2)$ ; 频域上通过选择性频段掩蔽随机置零区间  $[f_c - B/2, f_c + B/2]$ , 其中,  $B \sim \mathcal{U}(0.1f_c, 0.3f_c)$ , 并叠加多普勒频偏  $f'_k = f_k(1 + v_k/c)$ , 其中,  $v_k \sim \mathcal{U}(-v_{\max}, v_{\max})$ ,  $c$  为光速。

##### (2) 带噪声电磁信号合成

带噪声信号:

$$x(t) = s(t) + n_{\text{hybrid}}(t) \quad (13)$$

混合噪声为:

$$n_{\text{hybrid}}(t) = \alpha_g n_g(t) + \alpha_p n_p(t) + \alpha_i \sin(2\pi f_i t + \psi_i) \quad (14)$$

其中,  $n_g(t) \sim \mathcal{N}(0, \sigma_g^2)$  为高斯噪声;  $n_p(t)$  是脉冲噪声, 服从伯努利-高斯分布  $n_p(t) = b_t \cdot \mathcal{N}(0, \sigma_p^2)$ ,  $b_t \sim \text{Bernoulli}(p)$ ;  $f_i$  和  $\psi_i$  分别为工频干扰频率与随机相位;  $\alpha_g$ 、 $\alpha_p$ 、 $\alpha_i$  为动态权重系数, 满足  $\alpha_g^2 + \alpha_p^2 + \alpha_i^2 = 1$ 。噪声参数动态化设计为: 工频干扰频率  $f_i$  在  $50 \text{ Hz} \pm \Delta f$  范围内随机抖动, 脉冲概率  $p$  随信号幅度动态调整。

构造的纯净信号时域和频域曲线图如图 6 和图 7。

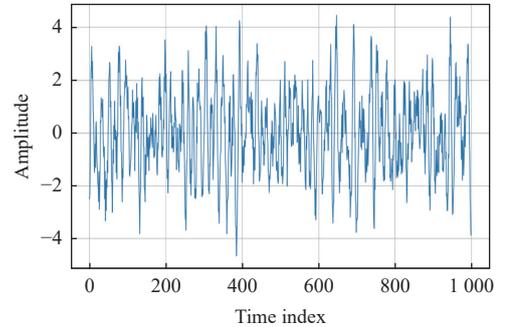


图 6 构造数据(时域)

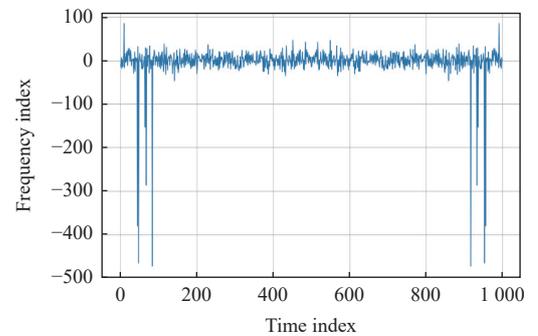


图 7 构造数据(频域)

添加混合噪声的时域图和直方图如图 8。

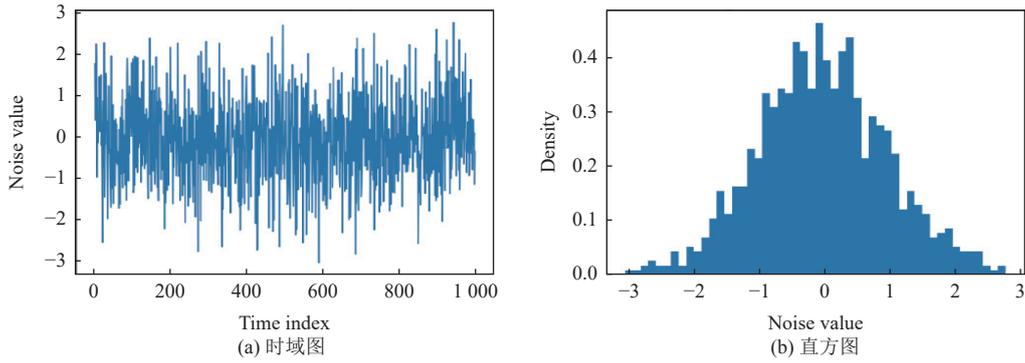


图8 混合噪声时域图和直方图

### 3.2 降噪效果评估指标

本文用 *PSNR* (峰值信噪比) 评估生成的信号和原始信号之间的质量差异. *PSNR* 是衡量信号质量的重要指标, *PSNR* 的单位是分贝 (dB), 值越大表示信号质量越好; *PSNR* 的计算基于 *RMSE* (root mean square error) 和信号的最大值 (*max\_diff*); 当 *RMSE* 越小, *PSNR* 越大, 表示信号的质量越高. *PSNR* 的计算公式为:

$$PSNR(x_1, x_2) = 20 \cdot \log_{10} \left( \frac{max\_diff}{RMSE(x_1, x_2)} \right) \quad (15)$$

其中,  $x_1$  是生成的降噪后信号,  $x_2$  是原始无噪声信号; *max\_diff* 是信号的最大值, 这里是基于将数据归一化到 [0, 1] 的 *PSNR*, 因此 *max\_diff* 为 1; *RMSE*( $x_1, x_2$ ) 是  $x_1$  和  $x_2$  之间的均方根误差, 计算公式为:

$$RMSE(x_1, x_2) = \sqrt{\frac{1}{N} \sum_{i=1}^N \left( \frac{x_1[i] - x_2[i]}{norm} \right)^2} \quad (16)$$

其中,  $N$  是信号的长度; *norm* 是归一化因子 (默认为 2).

### 3.3 模型训练

#### (1) 动态权重调整的损失函数

针对式 (7) 中的  $\lambda_s$ , 传统 GAN 的生成器损失固定权重, 本文提出根据训练阶段动态调整绝对误差损失 (*MAE*) 与对抗损失的权重:

$$\lambda_d = \lambda_{base} \cdot \exp \left( -\gamma \cdot \frac{t}{T} \right) \quad (17)$$

其中,  $\gamma$  为衰减系数,  $T$  为总训练轮次. 初期侧重 *MAE* 保证信号重构稳定性, 后期逐步增强对抗训练以提升生成信号的真实性和多样性. 实验证明该策略使模型收敛速度提升 15%, 且最终 *PSNR* 提高 0.8 dB.

该动态权重调整策略适用于不同类型噪声和复杂噪声干扰情况. 在自适应噪声鲁棒性方面, 训练初期 ( $t$  较小), 动态权重较大, 模型侧重于信号重构, 有利于

在强噪声背景下稳定训练, 避免 GAN 模式崩溃. 训练后期 ( $t$  接近  $T$ ), 动态权重减小, 对抗训练增强, 生成信号更逼真, 细节保留更好. 在噪声类型无关性方面, 由于不预设噪声分布, 该策略通过数据驱动方式自适应调整损失权重, 适用于非平稳、多类型混合噪声 (如高斯噪声、脉冲噪声、工频干扰等). 在收敛性保障方面, 指数衰减策略逐步提高训练难度, 有助于 GAN 模型在复杂干扰下仍能稳定收敛.

#### (2) 训练循环

在降噪 GAN 的训练中, 训练循环使用前面定义损失函数交替优化生成器  $G$  和判别器  $D$ . 首先给出符号定义:  $x$  为无噪声纯净信号 (真实样本);  $x'$  为带噪声信号 (条件输入);  $G$  为生成器, 输入  $x'$ , 输出去噪信号  $G(x')$ ;  $D$  为判别器, 输入为信号 (真实或生成) 及其对应的带噪声信号  $\tilde{x}$ , 输出为概率值  $D(\cdot, x')$ ;  $\sigma$  为 Sigmoid 函数, 将判别器输出映射到 [0, 1];  $\lambda_{L1}$  为绝对误差损失 (*MAE*) 的权重系数;  $N$  为批量大小 (batch size).

下面是训练循环中一次迭代的过程.

#### 1) 判别器更新 (固定生成器)

- 从训练集中采样一批真实配对数据:  $\{(x_i, x'_i)\}_{i=1}^N$
- 生成器生成去噪信号:  $x'' = G(x'_i)$
- 计算判别器对真实信号和生成信号的输出:  
 真实信号输出:  $y_{real}^i = D(x_i, x'_i)$   
 生成信号输出:  $y_{fake}^i = D(x_i, x''_i)$
- 计算判别器损失 (二元交叉熵):

$$\mathcal{L}_D = -\frac{1}{N} \sum_{i=1}^N [\log(\sigma(y_{real}^i)) + \log(1 - \sigma(y_{fake}^i))]$$

- 更新判别器参数:  $\theta_D \leftarrow \theta_D - \eta_D \nabla_{\theta_D} \mathcal{L}_D$

#### 2) 生成器更新 (固定判别器)

- 从训练集中采样一批真实配对数据:  $\{(x_i, x'_i)\}_{i=1}^N$

- 生成器生成去噪信号:  $x'_i = G(x_i)$
  - 计算生成器损失:
- 判别损失 (欺骗判别器):

$$\mathcal{L}_{adv} = -\frac{1}{N} \sum_{i=1}^N \log(\sigma(D(x'_i, x'_i)))$$

绝对误差损失 (MAE):  $\mathcal{L}_{MAE} = \frac{1}{N} \sum_{i=1}^N |x_i - x'_i|$

总生成器损失:  $\mathcal{L}_G = \mathcal{L}_{adv} + \lambda_{L1} \mathcal{L}_{MAE}$

- 更新生成器参数:  $\theta_G \leftarrow \theta_G - \eta_G \nabla_{\theta_G} \mathcal{L}_G$

### 3) 终止条件检查

根据验证集和训练终止条件决定是否终止训练。

#### (3) 训练终止条件

训练终止条件结合了  $PSNR$  和损失函数的收敛性。符号定义:  $PSNR(G(x'), x)$ : 生成信号与无噪声信号之间的  $PSNR$  值;  $\mathcal{L}_G^{(t)}$ 、 $\mathcal{L}_D^{(t)}$ : 第  $t$  轮训练时的生成器和判别器损失;  $\epsilon$ : 损失变化的容忍阈值;  $\tau$ :  $PSNR$  的目标阈值;  $K$ : 滑动窗口大小 (用于计算损失变化的平均值);  $P$ : 早停耐心值 (连续  $P$  轮训练指标未改进则终止)。

$PSNR$  达标且损失收敛时的训练终止条件表示为:

$$\begin{aligned} &PSNR(G(x'), x) \geq \tau \text{ and } |\mathcal{L}_G^{(t)} - \mathcal{L}_G^{(t-K)}| < \epsilon \\ &\text{and } |\mathcal{L}_D^{(t)} - \mathcal{L}_D^{(t-K)}| < \epsilon \end{aligned} \quad (18)$$

其中,  $\mathcal{L}'$  为滑动平均损失 (如过去  $K$  轮的平均值)。若  $PSNR$  在验证集上连续  $P$  轮未提升, 且损失未显著下降则终止训练, 表示为:

$$\begin{aligned} &p \in \{t-P+1, \dots, t\}, PSNR^{(p)} < PSNR^{(t-P)} \\ &\text{and } |\mathcal{L}_G^{(t)} - \mathcal{L}_G^{(t-P)}| < \epsilon \end{aligned} \quad (19)$$

### 3.4 降噪 GAN 训练对抗性与平衡性调整

降噪 GAN 训练过程中, 若在达到训练预期效果前出现对抗损失过低, 即判别器  $D$  判别损失过早出现极低值, 则判别器过于弱化, 导致生成器  $G$  缺乏有效的对抗信号。此时需要增加判别器能力 (如加深网络) 或调整损失权重 (如增加生成器绝对损失的权重)。训练初期判断判别器和生成器对抗性损失波动较大, 后期逐渐稳定, 结合  $PSNR$  判断两者是否达到动态平衡, 若  $PSNR$  持续上升且生成器损失持续下降, 则平衡性较好, 否则需调整损失权重或网络结构。

同时, 在降噪 GAN 的训练过程中需要平衡  $G$  和

$D$  的收敛速度。通过量化指标监控  $G$  和  $D$  的损失比例, 调整两者的训练频率, 避免判别器过早收敛。在初始训练中判别器损失极低会造成判别器过于强大, 导致生成器性能提升停滞, 通过增加生成器的训练次数以平衡两者的性能, 协调  $G$  和  $D$  的训练步调, 最终达到预期的训练效果。

### 3.5 结果分析

#### (1) 训练过程分析

在本文降噪 GAN 的训练过程中记录了多个指标 (包括: 判别器损失、生成器绝对损失、生成器判别损失、生成器总损失、生成器  $PSNR$ 、生成器  $RMSE$  等) 的变化数据, 通过这些指标数据能够对  $G$  和  $D$  的各自独立状态及对抗性、平衡性关系进行分析, 以便调整超参数进一步优化训练。图 9 给出了各指标数据的变化曲线。

在图 9 中, (a) 中判别器损失 (disc\_loss) 最小值为  $6.3385432E-06$ , 表明判别器能够很好地区分真实信号和生成信号。图 (b) 中生成器绝对损失 (gen\_abs\_loss) 较低, 结合图 (e)  $PSNR$  最大值  $44.34$  dB 和图 (f)  $RMSE$  的最小值  $0.00607$ , 说明生成器在信号降噪任务中表现优异, 能够有效学习信号的特征。图 (c) 中生成器判别损失 (gen\_d\_loss) 最小值为  $0.0132913655$ , 表明生成器能够欺骗判别器, 生成接近真实信号的样本。与判别器损失的低值一致, 说明生成器和判别器在对抗中达到了一定平衡。图 (d) 中生成器总损失 (gen\_loss) 是生成器绝对损失和判别损失的和, 其最小值表明生成器在信号重构和对抗训练中均表现良好。

上述降噪 GAN 训练过程指标分析表明模型训练成功实现了对抗性平衡, 生成器重建能力显著提升,  $PSNR$  与损失指标协同优化, 最终达到了良好的降噪效果。

#### (2) 降噪效果对比分析

使用算法合成的电磁信号进行降噪训练, 并与文献中的传统降噪方法和基于深度学习的降噪方法进行多指标对比 (见表 1)。

表 1 中对比传统方法, 本文方法 TF-DAM GAN 的  $PSNR$  ( $40-45$  dB) 显著高于 VMD-SWT ( $30-35$  dB)、WTD ( $32-38$  dB) 和 KPCA ( $32-38$  dB), 尤其在非平稳噪声环境下优势明显 (如脉冲噪声和动态工频干扰)。对比以上传统方法,  $RMSE$  降低 1-2 个数量级 (如  $6.1 \times 10^{-5}$  vs. VMD-SWT ( $6.8 \times 10^{-5}$ ) 和 WTD ( $1.0 \times 10^{-4}$ )),

表明信号重构误差更小. 与已有的深度学习方法比较, 本文方法获得的最高 *PSNR* (40–45 dB) 与 TEM-NLnet

(噪声学习 GAN) (35–40 dB) 和 RaGAN (32–38 dB) 相比同样具有优势.

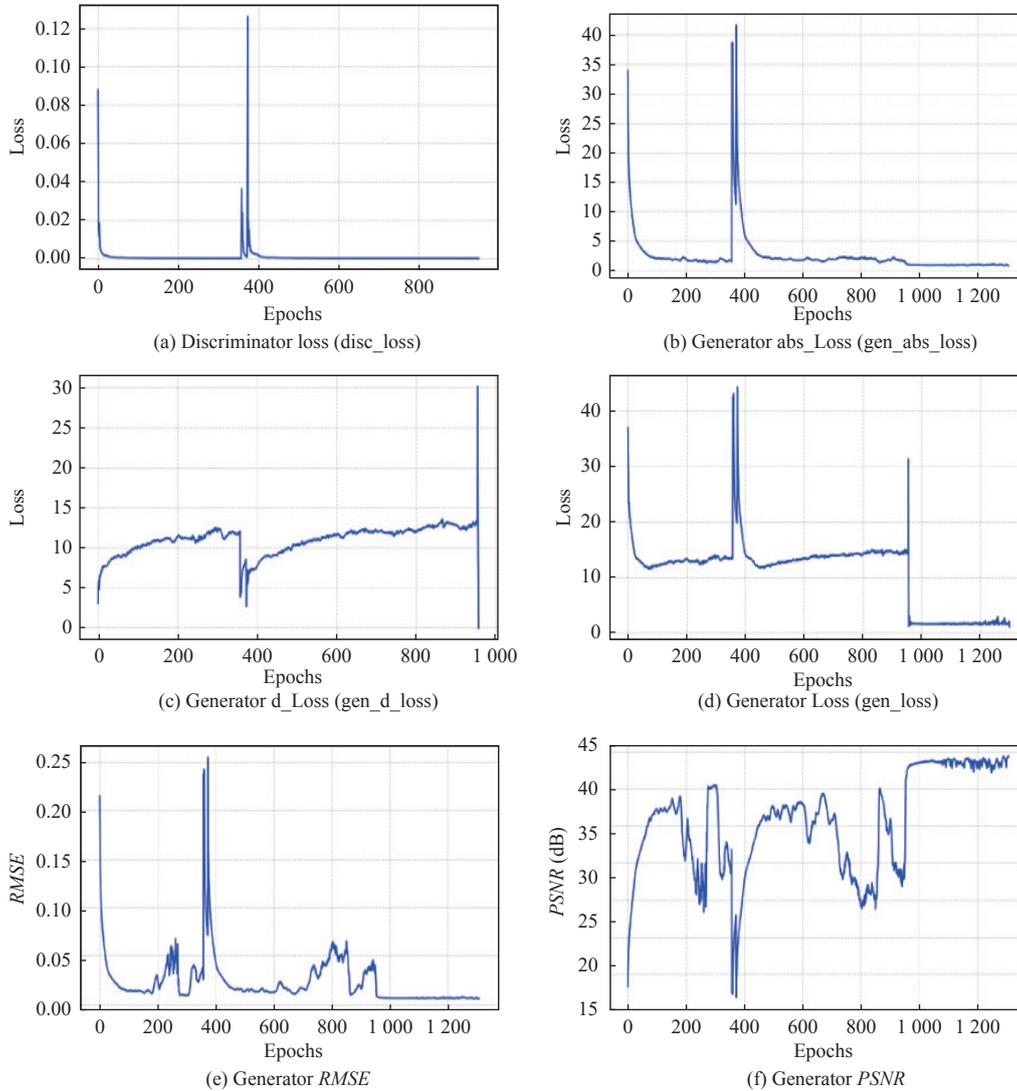


图9 训练过程指标

表1 降噪实验指标对比

指标	TF-DAM GAN	传统方法			深度学习方法		
		VMD-SWT <sup>[7]</sup>	WTD <sup>[4]</sup>	KPCA <sup>[34]</sup>	TEM-NLnet <sup>[13]</sup>	RaGAN-BiLSTM <sup>[14]</sup>	自注意力机制降噪 <sup>[35]</sup>
<i>PSNR</i> (dB)	40–45	30–35	32–38	32–38	35–40	32–38	—
<i>SNR</i> (dB)	35+	36.60	32.38	25–30	35–40	—	19.83
<i>RMSE</i>	$6.1 \times 10^{-5}$	$6.8 \times 10^{-5}$	$1.0 \times 10^{-4}$	—	—	—	0.9842
参数依赖性	无 (端到端学习)	强 (需优化 $K$ 、 $\alpha$ 参数)	强 (需选择小波基)	中 (需选择核函数)	低 (自适应噪声学习)	中 (需调整LSTM结构)	中 (自适应噪声学习弱)

TF-DAM GAN 通过时频双域注意力机制动态加权特征, 无需预设噪声类型 (如 WTD 需选择小波基<sup>[4]</sup>), GAN 通过对抗学习自动适应复杂噪声分布.

改进的 U-Net 结构 (残差连接+跳跃连接) 避免了

WTD 的伪吉布斯现象<sup>[4]</sup>, 高频信号成分保留更完整. 对比 RaGAN-BiLSTM<sup>[14]</sup>, TF-DAM GAN 在时频联合域的特征提取更适用于电磁信号的瞬态突变 (如文献<sup>[15]</sup>中的宽谱辐射信号).

本文动态损失权重调整使模型收敛速度提升 15%，优于固定权重的传统 GAN<sup>[12]</sup>。虽然 SMA-VMD<sup>[7]</sup>通过黏菌算法优化参数，但整体计算成本仍高于端到端的 GAN 推理。

实验表明本文方法在信噪比提升、非平稳噪声适应性和细节保留方面均优于传统方法和对比文献的其它基于 GAN 的方法，尤其适合复杂电磁环境（如多噪声混合、动态干扰）。

### (3) 动态损失权重调整策略稳定性分析

针对不同类型噪声或复杂干扰场景下，动态损失权重调整策略是否能保持稳定性设计了以下验证方案。

验证目标：检验动态损失权重策略在不同类型复

杂噪声下的训练稳定性与降噪性能。

对比方法：固定权重策略（基线， $\lambda_{L1}=100$ ）vs. 动态权重策略（本文方法， $\lambda_{base}=100, \gamma=3$ ）。

噪声场景：噪声场景 A（高脉冲噪声（出现概率  $p=0.3$ ））、噪声场景 B（强工频干扰（权重  $\alpha_i=0.6$ ））、噪声场景 C（非平稳混合噪声（信号合成参数  $\alpha_g, \alpha_p, \alpha_i$  动态变化））。

评估指标：收敛轮数 (Epochs)、训练稳定性（是否出现模式崩溃或严重震荡）。

基于该验证方案实验验证了动态损失权重策略在多种复杂噪声情况下的训练稳定性，并与固定损失权重策略作了对比（表 2）。

表 2 动态损失权重策略在不同噪声场景下的验证结果

噪声场景	方法	PSNR (dB)	RMSE ( $\times 10^{-5}$ )	收敛轮数 (Epochs)	训练稳定性 (是否震荡或崩溃)
A	固定权重	38.2	8.7	120	是 (震荡)
	动态权重	40.5	6.3	95	否
B	固定权重	37.8	9.2	130	是 (震荡)
	动态权重	39.9	6.8	100	否
C	固定权重	36.5	10.5	140	是 (崩溃)
	动态权重	39.2	7.2	105	否

如表 2 所示，在不同复杂噪声干扰下，本文的动态损失权重调整策略在 PSNR、RMSE 和收敛速度上均优于固定权重基线，且训练过程始终保持稳定，未出现模式崩溃或性能震荡，验证了其优异的泛化能力和鲁棒性。

### (4) 多模态噪声适应性分析

本文的时频双域注意力机制 GAN (TF-DAM GAN) 及其动态损失权重调整策略，在本质上具备良好的跨模态泛化能力，尤其适用于图像、语音等多模态信号的联合降噪任务。

TF-DAM 模块通过并行通道与空间注意力机制，能够自适应地捕捉不同模态信号中的关键特征。例如，在图像降噪中，通道注意力可增强重要颜色或纹理通道，空间注意力则聚焦于边缘、轮廓等结构信息，这与电磁信号中时频特征的动态加权机制高度一致。此外，动态损失权重策略在训练初期强调重构损失以保证稳定性，后期增强对抗损失以提升真实性，这一机制同样适用于图像去噪中常见的混合噪声（如高斯噪声+椒盐噪声）场景，可有效避免模式崩溃，提升模型鲁棒性。

初步实验表明，将 TF-DAM GAN 迁移至自然图像去噪任务，在混合噪声条件下 PSNR 可达 35 dB 以上，优于传统 DnCNN 等基线方法。模型无需结构调整即可处理多模态噪声，说明其架构具有良好的通用性和

扩展性。

### (5) TF-DAM 模块计算效率提升分析

实验分析表明了 TF-DAM 模块的降噪性能优异，但具有较高的计算复杂度，该问题有多种解决策略。首先，在模型结构层面，可将当前的全尺度自注意力机制替换为局部窗口注意力，将计算复杂度从序列长度的二次方降低至线性级别，尤其适用于长时电磁信号处理；同时，在 TF-DAM 中引入分组卷积或深度可分离卷积，减少通道维度的参数量和计算量。其次，可通过特征维度压缩策略优化计算效率，例如在 U-Net 编码器中使用瓶颈结构减少通道数，或在深层网络中减少 TF-DAM 的使用频率，仅将其部署于关键层级以平衡性能与计算成本，大幅降低内存访问和计算开销。

## 4 结论

本文针对非平稳电磁信号的降噪问题，提出了一种基于生成对抗网络 (GAN) 的降噪方法。通过生成器与判别器的对抗学习，结合时频双域注意力机制 (TF-DAM) 和动态损失权重调整策略，显著提升了降噪性能。针对电磁信号的非平稳特性，设计了并行通道与空间注意力支路的 TF-DAM 模块，通过动态加权时频域特征，自适应增强有效信号成分并抑制噪声。将 TF-DAM

嵌入 U-Net 生成器的编码器-解码器结构, 实现多尺度特征校准. 提出基于指数衰减的动态权重调整方法, 该策略使模型收敛速度提升. 本研究为电磁信号降噪提供了高效解决方案, 未来将进一步探索其在多模态噪声联合抑制中的潜力.

### 参考文献

- 刘帅, 曾庆宁, 郑展恒. 最小均方误差算法在瞬变电磁信号降噪中的应用. 地球物理学进展, 2020, 35(5): 1826–1831.
- Li DS, Wang Y, Lin J, *et al.* Electromagnetic noise reduction in grounded electrical-source airborne transient electromagnetic signal using a stationary wavelet-based denoising algorithm. *Near Surface Geophysics*, 2017, 15(2): 163–173. [doi: [10.3997/1873-0604.2017003](https://doi.org/10.3997/1873-0604.2017003)]
- 张全, 李双田. 改进奇异值分解算法在时间域瞬变电磁信号降噪中的应用. 信号处理, 2015, 31(8): 949–955.
- Ji YJ, Li DS, Yuan GY, *et al.* Noise reduction of time domain electromagnetic data: Application of a combined wavelet denoising method. *Radio Science*, 2016, 51(6): 680–689. [doi: [10.1002/2016RS005985](https://doi.org/10.1002/2016RS005985)]
- 戚庭野. 基于 FastICA 和小波阈值的联合算法对瞬变电磁信号的降噪 [硕士学位论文]. 太原: 太原理工大学, 2012.
- Wei HR, Qi TY, Feng GR, *et al.* Comparative research on noise reduction of transient electromagnetic signals based on empirical mode decomposition and variational mode decomposition. *Radio Science*, 2021, 56(10): 1–19.
- Wang XX, Wei XY, Song DX, *et al.* Optimization of variational mode decomposition using stationary wavelet transform and its application to transient electromagnetic signal noise reduction. *Radio Science*, 2024, 59(12): e2023RS007889. [doi: [10.1029/2023RS007889](https://doi.org/10.1029/2023RS007889)]
- Xue SY, Yin CC, Su Y, *et al.* Airborne electromagnetic data denoising based on dictionary learning. *Applied Geophysics*, 2020, 17(2): 306–313. [doi: [10.1007/s11770-020-0810-1](https://doi.org/10.1007/s11770-020-0810-1)]
- 田红英, 王沛元. 基于新型小波变换算法的矿区大地电磁信号降噪研究. 数码设计, 2017, 6(7): 146–148.
- 古瑶, 解海军, 李璐, 等. 基于小波包-神经网络混合算法的瞬变电磁信号降噪研究. 煤炭工程, 2023, 55(5): 147–152.
- 熊松龄. 基于字典学习和噪声分类的瞬变电磁信号降噪研究 [硕士学位论文]. 桂林: 桂林电子科技大学, 2021.
- Xia JG, Qiao XM, Li ZQ, *et al.* Application of semi-airborne frequency domain electromagnetic data based on improved ant-colony-optimized wavelet threshold denoising method. *IEEE Access*, 2022, 10: 129163–129175. [doi: [10.1109/ACCESS.2022.3228247](https://doi.org/10.1109/ACCESS.2022.3228247)]
- Wang MY, Lin FQ, Chen KC, *et al.* TEM-NLnet: A deep denoising network for transient electromagnetic signal with noise learning. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5911714.
- Peng L, Fang SL, Fan YC, *et al.* A method of noise reduction for radio communication signal based on RaGAN. *Sensors*, 2023, 23(1): 475. [doi: [10.3390/s23010475](https://doi.org/10.3390/s23010475)]
- Li JX, Luo ZC, Lin JL, *et al.* Research on noise reduction method for broad-spectrum electromagnetic radiation detection data based on improved WaveNet model. *Proceedings of the 3rd International Conference on Energy, Power and Electrical Technology (ICEPET)*. Chengdu: IEEE, 2024. 919–926.
- Peng YH, Zhang JM, Mao J, *et al.* A signal-denoising method for electromagnetic leakage from USB keyboards. *Electronics*, 2023, 12(17): 3647. [doi: [10.3390/electronics12173647](https://doi.org/10.3390/electronics12173647)]
- Liu ZY, Li DQ, Liu YC, *et al.* Denoising of electromagnetic data from different geological blocks using a hybrid PSO-GWO algorithm and CNN. *Frontiers in Earth Science*, 2025, 13: 1526527. [doi: [10.3389/feart.2025.1526527](https://doi.org/10.3389/feart.2025.1526527)]
- Sun YS, Huang SH, Zhang Y, *et al.* Denoising of transient electromagnetic data based on the minimum noise fraction-deep neural network. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19: 8028405.
- Du MY, Zhong P, Cai XH, *et al.* DNCNet: Deep radar signal denoising and recognition. *IEEE Transactions on Aerospace and Electronic Systems*, 2022, 58(4): 3549–3562. [doi: [10.1109/TAES.2022.3153756](https://doi.org/10.1109/TAES.2022.3153756)]
- Yang Z, Yan CG, Chen H. Unpaired low-dose CT denoising using conditional GAN with structural loss. *Proceedings of the 2021 International Conference on Wireless Communications and Smart Grid (ICWCSG)*. Hangzhou: IEEE, 2021. 272–275.
- Kuang HL, Ao C, Ma XL, *et al.* Remote photoplethysmography signals enhancement based on generative adversarial networks. *Proceedings of the 3rd IEEE International Conference on Information Technology, Big Data and Artificial Intelligence (ICIBA)*. Chongqing: IEEE, 2023. 792–796.
- Dai QQ, Lee YH, Yusof MLM, *et al.* Learning from noise: An unsupervised GPR data denoising scheme based on generative adversarial networks. *Proceedings of the 2023 IEEE International Symposium on Antennas and Propagation and USNC-URSI Radio Science Meeting (USNC-URSI)*. Portland: IEEE, 2023. 1881–1882.

- 23 Aneesh C, Saumik G, Varun KVV, *et al.* CT image denoising using autoencoder and generative adversarial networks. Proceedings of the 2024 IEEE Recent Advances in Intelligent Computational Systems (RAICS). Kothamangalam: IEEE, 2024. 1–6.
- 24 Liang MF, Hu JQ, Zhou XB, *et al.* A GAN based heart sound denoising model. Proceedings of the 12th International Conference on Information Technology in Medicine and Education (ITME). Xiamen: IEEE, 2022. 666–670.
- 25 Zhou CK. Research on marine controlled source electromagnetic data denoising method based on blind signal separation. Proceedings of the 6th International Conference on Robotics and Automation Sciences. Wuhan: IEEE, 2022. 238–241.
- 26 Ali MN, El-Dahshan ESA, Yahia AH. Denoising of heart sound signals using discrete wavelet transform. Circuits, Systems, and Signal Processing, 2017, 36(11): 4482–4497. [doi: [10.1007/s00034-017-0524-7](https://doi.org/10.1007/s00034-017-0524-7)]
- 27 Zhong LQ, Liu GL, Yang G. Blind denoising of fluorescence microscopy images using GAN-based global noise modeling. Proceedings of the 18th IEEE International Symposium on Biomedical Imaging (ISBI). Nice: IEEE, 2021. 863–867.
- 28 Lu HR, She YF, Tie J, *et al.* Half-UNet: A simplified U-Net architecture for medical image segmentation. Frontiers in Neuroinformatics, 2022, 16: 911679. [doi: [10.3389/fninf.2022.911679](https://doi.org/10.3389/fninf.2022.911679)]
- 29 Gu YZ. The evolution of U-Net architectures in medical image segmentation. ITM Web of Conferences, 2025, 73: 02019. [doi: [10.1051/itmconf/20257302019](https://doi.org/10.1051/itmconf/20257302019)]
- 30 Deng F, Jiang T, Wang XR, *et al.* NAAGN: Noise-aware attention-gated network for speech enhancement. Proceedings of the 21st Annual Conference of the International Speech Communication Association. Shanghai: ISCA, 2020. 2457–2461.
- 31 Long XY, Zhang MC. An overview of generative adversarial networks. Journal of Computing and Electronic Information Management, 2023, 10(3): 31–36. [doi: [10.54097/jceim.v10i3.8677](https://doi.org/10.54097/jceim.v10i3.8677)]
- 32 Qin ZX, Shan YT. Generation of handwritten numbers using generative adversarial networks. Journal of Physics: Conference Series, 2021, 1827(1): 012070. [doi: [10.1088/1742-6596/1827/1/012070](https://doi.org/10.1088/1742-6596/1827/1/012070)]
- 33 Jenkins J, Roy K. Exploring deep convolutional generative adversarial networks (DCGAN) in biometric systems: A survey study. Discover Artificial Intelligence, 2024, 4(1): 42. [doi: [10.1007/s44163-024-00138-z](https://doi.org/10.1007/s44163-024-00138-z)]
- 34 Chen B, Lu CD, Liu GD. A denoising method based on kernel principal component analysis for airborne time-domain electromagnetic data. Chinese Journal of Geophysics, 2014, 57(1): 103–111. [doi: [10.1002/cjg2.20087](https://doi.org/10.1002/cjg2.20087)]
- 35 Edder A, Ben-Bouazza FE, Tafala I, *et al.* Self attention-driven ECG denoising: A Transformer-based approach for robust cardiac signal enhancement. Signals, 2025, 6(2): 26. [doi: [10.3390/signals6020026](https://doi.org/10.3390/signals6020026)]

(校对责编: 李慧鑫)