探地雷达杂波抑制技术研究综述：机理、方法与挑战

雷文太*①② 王以明② 钟继卫①⑤ 徐齐国③ 姜玉印①④ 李 成①④

①(桥梁智能与绿色建造全国重点实验室 武汉 430050)

②(中南大学电子信息学院 长沙 410000)

③(中南大学计算机学院 长沙 410000)

④(中铁大桥科学研究院有限公司 武汉 430050)

⑤(中铁大桥局集团有限公司 武汉 430050)

摘 要：探地雷达(GPR)因其无损、快速、高分辨的检测能力广泛应用于城市地下空间、公路铁路轨道交通、地球物理探测和军事等领域。然而，由于收发天线的宽频带和宽波束特性，以及复杂探测场景中的感兴趣目标受到的非均匀背景媒质和临近目标的影响，探地雷达回波中无可避免地包含了相当多成分的杂波信号。杂波信号与感兴趣目标的回波信号在时频域部分重叠，对其产生干扰，严重影响了后续的目标定位、成像、参数估计、结构反演和分类识别等任务。在探地雷达数据处理中，通常需要先进行杂波抑制工作。该文是对冲激脉冲体制探地雷达杂波抑制方法的综述，分析了冲激脉冲体制探地雷达的各典型杂波的成因和杂波抑制效果评估的定量指标，对基于信号模型的杂波抑制和基于神经网络模型的杂波抑制这两大类方法进行了系统的分析和阐述。最后，讨论了将深度学习技术应用于探地雷达杂波抑制时面临的挑战和未来的发展方向。

关键词：探地雷达；杂波抑制；深度学习；性能指标；综述

中图分类号：TN957.51 **文献标识码**：A **文章编号**：1009-5896(2025)11-4079-17

DOI: 10.11999/JEIT250524 **CSTR**: 32379.14.JEIT250524

1 引言

探地雷达(Ground Penetrating Radar, GPR)作为一种无损的地下探测技术[1]，广泛应用于城市地下空间[2]、公路铁路轨道交通[3]、地球物理探测[4]和军事[5]等领域。在城市地下空间探测领域，GPR常用于地下管线走向和渗漏探测[6]、建筑物的地基结构探测、城市道路脱空疏松探测等。在交通领域，GPR用于路基路面的隐蔽病害探测、地铁轨道的脱空探测、隧道工程的裂隙和渗水路径探测[7]等。在地球物理探测领域，GPR用于浅层地质结构的探测和反演。在军事领域，GPR用于地下军事目标、未爆弹等目标的探测。

GPR通过天线向地下发射宽带电磁波进行目标探测。GPR在单点进行探测，可以获得一道回波数据，通常称为A-scan。沿一条测线进行探测时，在测线上的各测点可以分别获得一道A-scan数据，组合成一幅B-scan回波数据。沿多条测线进行探测时，多幅B-scan数据可以组合成一个C-scan数据。本文主要针对GPR B-scan数据进行分析。通过对GPR B-scan数据的处理，有望获得地下区域内感兴趣目标的位置[8]、参数与结构估计[9]、成像识别[10]和分类结果[11]。

当采用单个天线结合开关切换进行数据采集时，由于切换开关的非理想特性，在接收通道中存在电磁能量的泄漏。当采用分置的发射和接收天线进行数据采集时，两个天线间存在电磁能量的耦合。GPR对地探测时，基于GPR天线的近区辐射特性，地下目标和背景的差异性导致的金属目标表面的感应电流和非金属表面的极化电荷产生的二次辐射场，在GPR接收天线表面产生感应电流，经采样接收后生成一道回波。发射天线辐射的电磁波，部分能量经地表散射后被接收天线接收，部分能量透射到地下。由于地下媒质的复杂性和地下目标的多样性，同时由于GPR天线的近区辐射特性，无论将地下区域视为一个整体，还是按所处的空间分为非均匀背景、感兴趣的目标、临近异常体等，散射回波与目标参数之间都呈现出非线性特征，通常无法按照散射中心模型进行建模。GPR的数据处理效果，一方面取决于针对各处理任务所

收稿日期：2025-06-09；改回日期：2025-09-29；网络出版：2025-10-11
*通信作者： 雷文太 leiwentai@csu.edu.cn
基金项目：桥梁智能与绿色建造全国重点实验室开放研究基金项目(BIGCSKL24-09-GF)，西藏自治区科技计划项目(XZ202501ZY0005)，中国中铁股份有限公司科技研究开发计划重大专项(2023-专项-02)

Foundation Items: The Open Research Fund Project of State Key Laboratory of Bridge Intelligent and Green Construction(BIGCSKL24-09-GF), The Science and Technology projects of Xizang Autonomous Region, China(XZ202501ZY0005), The Major Special Project of Science and Technology Research and Development of China Railway Group limited (2023-Special Project-02)

设计的数据处理算法的能力，如介质分层算法、目标检测算法、目标参数估计算法、目标成像与电磁反演算法等，另一方面取决于GPR原始数据的质量，而后者是决定GPR数据处理效果的更重要因素。如果没有高质量的数据输入，仅凭针对各处理任务所设计的数据处理算法，是无法“无中生有”地实现高质量的数据处理。其中，杂波干扰是首先要面对的问题。探地雷达杂波是指除了目标回波以外的各种回波，通常包括GPR硬件的非理想特性导致的杂波、天线间的直接耦合波、地表反射波、天线振铃噪声、外部随机噪声、背景非均匀介质的回波和诸如钢筋网、轨道枕木等非感兴趣目标的回波等。这些回波成分在时域和频域体现出与感兴趣目标回波类似的特征，对目标回波造成了干扰。

本文首先分析了GPR杂波的产生机理及其典型表现形式，其次，对比分析了现有杂波抑制技术的定量评价指标及其适用性，系统梳理了基于信号建模与神经网络数据驱动的杂波抑制方法，分析阐述了其基本原理与技术演进规律，为研究者优化算法设计提供参考。最后，深入探讨了当前GPR杂波抑制的技术瓶颈，并展望了GPR杂波抑制技术在物理机理与智能算法融合方向的发展趋势。

2 GPR杂波产生机理和典型的杂波形式

GPR系统通常由控制模块、发射模块、接收模块、发射天线和接收天线组成。GPR对地探测时，控制模块设置参数，驱动发射模块通过发射天线辐射电磁波，电磁波在不同介质分界面散射，部分散射波被接收天线接收并经接收模块数字采样和存储，以冲激脉冲体制GPR为例，其探测原理如图1所示。

散射回波的幅度和相位均与探测区域的反射系数有关。在垂直入射且非磁性介质情况下，电磁波从介质1入射到介质2时，反射系数Γ可简化为

$$\Gamma \approx \frac{\sqrt{\varepsilon_1}-\sqrt{\varepsilon_2}}{\sqrt{\varepsilon_1}+\sqrt{\varepsilon_2}} \tag{1}$$

其中，ε_1，ε_2分别为介质1和介质2的相对介电常数。若介质间的相对介电常数差异较大，反射系数Γ越大，则反射波的能量越强，同时透射波的能量越弱，下面分析主要杂波成分。

(1)天线间的直接耦合波：发射天线直接传播到接收天线的直接耦合波，未经地下介质中的反射与散射，是GPR信号中最先到达接收天线的波形，衰减小、能量强，占据了GPR动态范围的大部分，导致地下目标回波成分减弱，尤其在浅层物体探测时更为显著。gprMax[12]采取时域有限差分法(Finite Difference Time Domain, FDTD)求解麦克斯韦方程模拟电磁波在复杂介质中的传播、反射和折射等现象，模拟直接耦合波见图2(a)。

(2)地表反射波：地表单次反射波能量弱于直

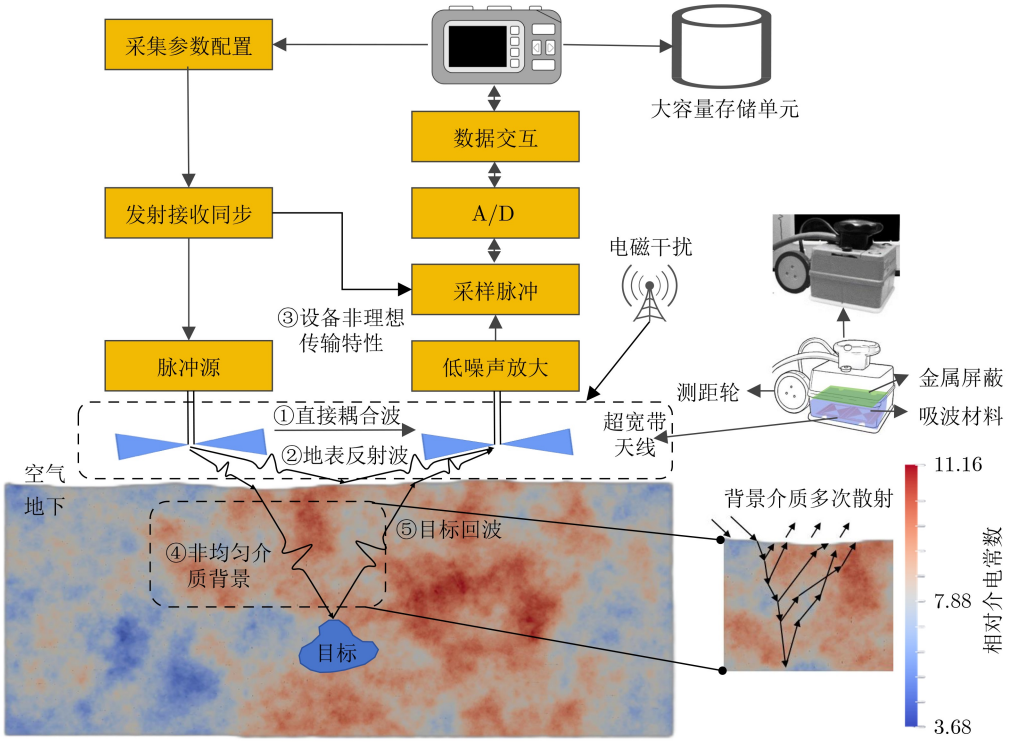

图 1 GPR对地探测原理示意图

接耦合波但强于目标信号。起伏或粗糙的地表会改变入射波的入射角θ，依据斯涅尔定律，对斜入射的反射系数Γ_2定义为

$$\Gamma_2=\frac{\cos\theta-\sqrt{\varepsilon_2/\varepsilon_1-\sin^2\theta}}{\cos\theta+\sqrt{\varepsilon_2/\varepsilon_1-\sin^2\theta}} \tag{2}$$

起伏或粗糙地表造成反射系数Γ_2随位置变化，当地表粗糙或有起伏时，不规则的反射和散射会增加传播路径的多样性，多个路径的相干叠加可能导致局部振幅增强或减弱，尤其是当地表粗糙尺度与雷达发射波长相当时，会引发显著的散射。此外，地表高度变化会导致传播时延差异，相同深度的目标因地表呈现虚假的“地形”相位[13]，需进行时延矫正。

(3)GPR设备的非理想传输特性导致的杂波：GPR设备的非理想传输特性也会引入额外杂波。例如，由于非理想匹配、设备老化或环境(如雨水、冰霜)等，天线与馈线的阻抗不匹配时，发射信号会在接口处发生反射形成驻波，这种反射能量会在天线系统中来回振荡，产生振铃噪声，在时域上表现为固定周期衰减振荡，在B-scan图像上表现为直接耦合波后方的多条水平或近水平条带。在实际的GPR系统中，GPR天线(特别是低频天线)的带宽有限，发射脉冲的衰减不完全，产生拖尾振荡，也会造成振铃噪声，增加浅层目标特征的解释难度。此外，GPR的系统噪声在B-scan图中表现为随机振幅波动，屏蔽性能不足的天线易受外部电磁辐射源(如城市环境手机信号)的射频干扰，在B-scan中形成随机亮线或亮斑[14]，这些干扰对后续的信号处理带来很大的影响。

(4)地下非均匀介质回波：地下非均匀介质，如路基路面分层结构、不同类型的土壤等，造成了复杂的散射。在B-csan图像上通常表现为散射强度在时空维度变化的非规则散射曲线，会显著掩盖目标信号，特别是在深层或复杂介质中。

(5)钢筋网、轨道枕木等非感兴趣目标的回波：在某些应用场景中，GPR需要穿透介质结构体或金属网状结构体对较深层的感兴趣的目标进行探测。此时，这些介质结构体或金属网状结构体对GPR的下行入射波和较深层目标的上行散射波产生强干扰，严重影响了GPR对较深层的感兴趣目标的探测。例如，在检测公路或隧道如脱空、缝隙、不密实区域等结构损害时，其上方常铺设有钢筋网，对入射波造成了强散射。GPR发射的电磁波，仅有少量入射波传播至钢筋网下的病害区域并散射。散射波上行传播至接收天线时，还要受到钢筋网的影响，严重制约着诸如枕木、钢筋网场景下的病害检测，上述典型杂波示例见图2。

综上所述，GPR数据中的杂波成因复杂、组成多样，有效的杂波抑制方法旨在改善GPR信号的目标定位、成像、参数估计、结构反演和分类识别等性能。良好的杂波处理能够将处理后的GPR

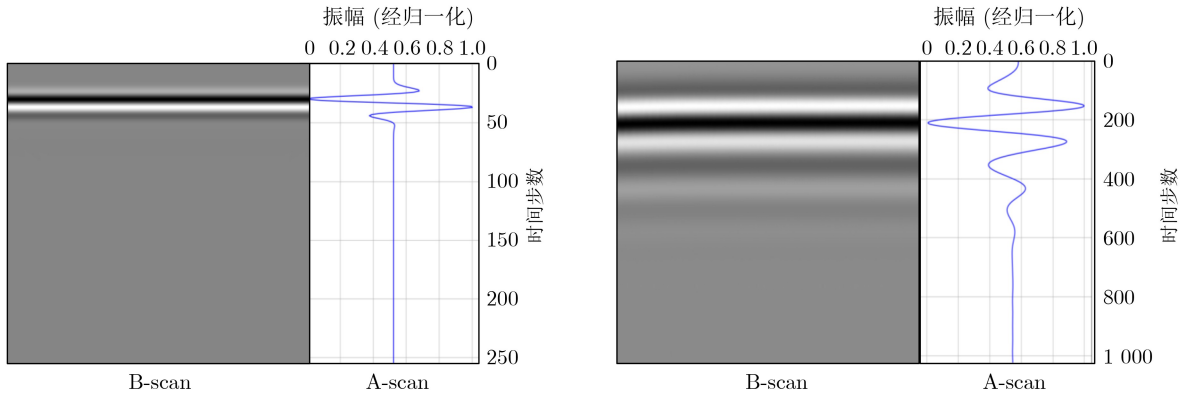

(a) 直接耦合波　　(b) 振铃噪声

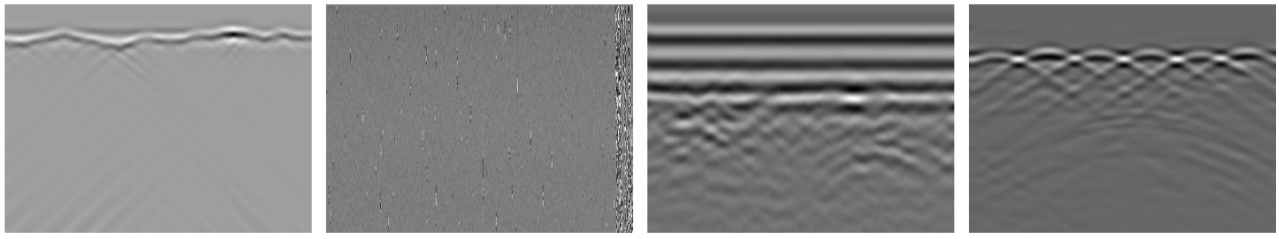

(a) 粗糙起伏地表杂波　(b) 射频噪声　(c) 非均匀介质杂波　(d) 钢筋网杂波

图 2 GPR典型杂波

数据近似为目标在理想均匀介质中的散射表现，从而提高信号的质量。本文以时域冲激脉冲体制的GPR B-scan杂波抑制为主进行阐述，所述方法适用于对GPR C-scan的处理，也适用于对其他体制，如调频连续波、阶跃变频等体制GPR的杂波抑制处理。

3 杂波抑制评价方法

在GPR的杂波抑制任务中，对杂波抑制效果的评价指标选择影响算法优化方向与适用范围，涵盖定性分析和定量指标。

定性评价依赖经验丰富的解译人员通过肉眼对比图像去杂波前后的图像，关注目标及已知的地下结构形状失真、伪影干扰、图像平滑度、目标双曲线特征完整性及边缘保持情况。然而，人眼对于灰度的分辨能力有限(约256级，即8位)，即使图像有更高的灰度等级且能够被高性能显示终端显示出来，人眼也难以捕捉微小灰度变化。GPR常探测强杂波下的弱目标回波，时空域采样可能不完整，导致定性评价粗略、依赖经验，仅适于初步评估。

定量评价通过数据计算评估算法杂波抑制性能，对算法优化、网络设计及模型训练至关重要。定量评价适用于B-scan原始数据和图像数据(均视为二维数组，原始数据的采样点数与扫描道数对应图像的行数和列数，振幅对应像素值)，除数据精度不同以外在定量化指标计算中差异不大。原始数据精度更高(如32位整数或64位浮点数)，但易因数据截断或溢出降低算法性能。复杂的杂波抑制方法通常对原始B-scan数据通常会进行预处理(如尺度调整、归一化、灰度映射，图3所示)，再开展杂波抑制。

随着图像处理算法的发展，尺度调整和归一化等预处理有不同的处理方法，已经能够很好地保留数据的主要信息，在保证同一实验过程中数据的预处理方法一致的前提下，定量化的评价方法对于原始数据与图像数据都适用，下面给出常用的GPR杂波抑制定量化评价指标。

(1)均方误差(Mean Squared Error, MSE)

$$\mathrm{MSE}=\frac{1}{mn}\sum_{i=1}^{m}\sum_{j=1}^{n}\left(I_{\mathrm{o}}\left(i,j\right)-I_{\mathrm{d}}\left(i,j\right)\right)^{2} \tag{3}$$

式中，$I_{\mathrm{o}}(i,j)$ 是杂波抑制后数据的元素值，$I_{\mathrm{d}}(i,j)$ 是参考数据的元素值，m和n分别表示数据的行数和列数。MSE因其平方形式便于数学求导(如梯度下降)常用于优化算法。MSE作为评价指标时适合评估整体像素值或幅度值一致性，若参考数据为无杂波目标数据，MSE越小，抑制后信号与参考信号的误差越小，效果越好；但若参考数据本身含杂波，MSE低仅仅意味着处理后的信号保留了参考信号中的杂波，而不是有效抑制了杂波，所以作为参考指标时通常将参考数据设置为与原始数据配对的无杂波目标数据。

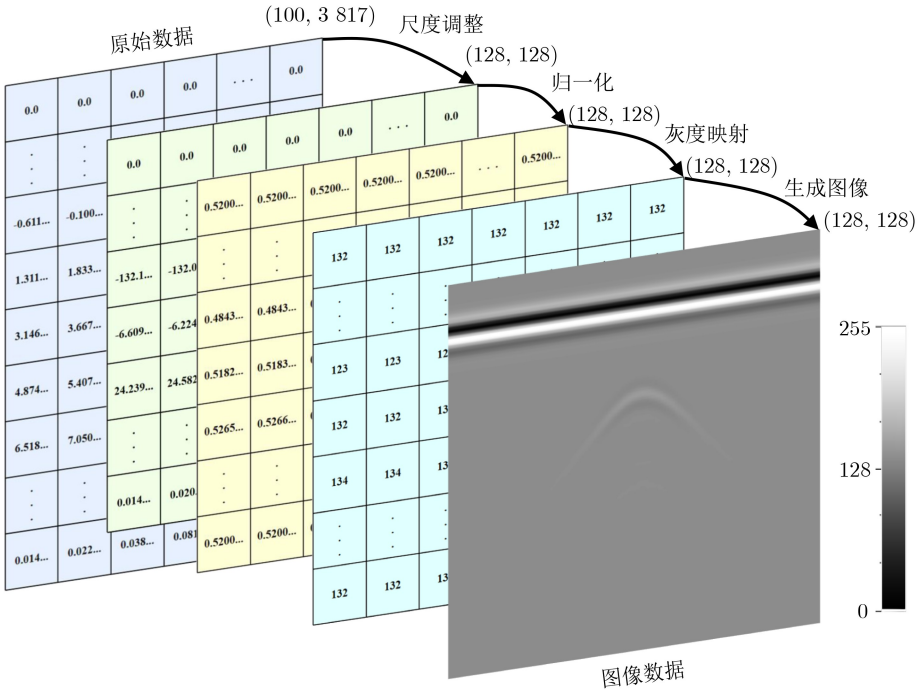

图 3 原始数据到图像数据的转换示例图

(2)峰值信噪比(Peak Signal-to-Noise Ratio, PSNR)

$$\mathrm{PSNR}=10\lg\left(\frac{\mathrm{MAX}^2}{\mathrm{MSE}}\right) \tag{4}$$

式中，MAX是数据中元素的最大值。PSNR基于MSE计算，若参考数据设计为无杂波配对目标数据，则PSNR反映信号的理论最大功率与噪声功率的比值，PSNR值越大，抑制后信号与理想无杂波信号的差异越小，算法杂波抑制性能越好。然而，式(4)中的MSE是基于式(3)中的平方运算，对较大的误差(异常值)更敏感，可能会过分放大局部较大误差的影响。PSNR因直接依赖MSE继承了这一特性，故对结构性杂波(如多次反射波)的评估效果欠佳。

(3)信号-杂波比(Signal-to-Clutter Ratio, SCR)

$$\mathrm{SCR}=\frac{N_\mathrm{c}}{N_\mathrm{s}}\frac{\sum\limits_{p\in R_\mathrm{s}}|I(p)|^2}{\sum\limits_{p\in R_\mathrm{c}}|I(p)|^2} \tag{5}$$

式中，N_c和N_s分别代表所选杂波区域R_c和目标信号区域R_s的元素数，$I(p)$是GPR数据中第p个元素值。SCR的定义为目标的功率与背景杂波功率的比值，SCR值越大，说明目标信号能量相对于杂波越强，数据的杂波越少。SCR需要明确定义信号和杂波区域，在实际应用中需要手动标注或自动分割，例如使用边缘检测算法或形态学操作识别目标区域的边界。而实际探测很难得到与含杂波目标数据配对的无杂波数据，故SCR经常被采用在实测数据杂波抑制效果的评估上，尤其是本身不需要配对数据的无监督算法。

(4)改善系数(Improvement Factor, IF)

$$\mathrm{IF}=10\lg(\mathrm{SCR_o}/\mathrm{SCR_d}) \tag{6}$$

式中，$\mathrm{SCR_o}$与$\mathrm{SCR_d}$分别是GPR杂波抑制前后的SCR。IF量化了杂波抑制算法在提高SCR方面的性能，即比较处理前后目标信号相对于背景杂波的增强程度，IF值越大，说明杂波抑制算法的效果越好，目标信号的突出程度越高。在计算处理前后的SCR时，在选取目标区域和杂波区域的策略必须一致，否则IF值无意义。

(5)结构相似性指数(Structural Similarity Index, SSIM)[15]

$$\mathrm{SSIM}(I_\mathrm{o},I_\mathrm{d})=\frac{(2\mu_{I_\mathrm{o}}\mu_{I_\mathrm{d}}+C_1)(2\sigma_{I_\mathrm{o}I_\mathrm{d}}+C_2)}{(\mu_{I_\mathrm{o}}^2+\mu_{I_\mathrm{d}}^2+C_1)(\sigma_{I_\mathrm{o}}^2+\sigma_{I_\mathrm{d}}^2+C_2)} \tag{7}$$

式中，μ_{I_o}，μ_{I_d}是杂波抑制后数据I_o和参考数据I_d的平均值，σ_{I_o}，σ_{I_d}是对应数据的标准差，$\sigma_{I_\mathrm{o}I_\mathrm{d}}$是对应两数据协方差，$C_1$和$C_2$是常量。SSIM是图像处理领域中用于评估图像质量的指标，注重图像的结构信息、亮度和对比度，旨在模拟人眼对图像质量的主观感知。SSIM的取值范围通常为[–1,1]，SSIM越接近1，杂波抑制后数据与参考数据的结构、亮度和对比度越相似，一般认为若SSIM小于0.6则可能丢失关键信息。SSIM依赖于数据网格的统计特性(如均值、方差)，应用在原始未处理的数据上时需要额外的归一化。

(6)多尺度结构相似性指数(Multi-Scale Structural Similarity Index, MS-SSIM)[16]

MS-SSIM是对SSIM的改进，该方法将数据多次高斯模糊和下采样，生成不同尺度的图像。对于每个尺度，计算该尺度下的SSIM值，对所有尺度的SSIM值进行加权平均，得到最终的MS-SSIM值。

$$\text{MS-SSIM}\left(I_\mathrm{o},I_\mathrm{d}\right)=\prod_{i=1}^{N}\left(\mathrm{SSIM}_i\left(I_\mathrm{o},I_\mathrm{d}\right)\right)^{\alpha_i} \tag{8}$$

式中，SSIM_i是对应尺度i下的SSIM值，α_i是每个尺度的权重，权重的选择基于实验，因应用场景不同而变化。加权平均的目的是综合考虑不同尺度上的相似度，通过多尺度分析，MS-SSIM能更好地模拟人眼对细节和全局结构的感知。MS-SSIM依赖于SSIM的计算， MS-SSIM的取值范围为[0,1]，值越接近1表示图像质量越高，并且其通常也需要无杂波目标数据作为参考，在实测等无参考场景中应用受限。

杂波抑制输入数据类型和定量评价指标应根据具体的应用场景、算法需求和处理流程进行合理选择，上述定量化指标通常进行结合使用，再辅以基于肉眼观察的定性分析。除这些定量化指标以外，还有一些计算机视觉和医学图像等领域广泛使用的参考指标，如注重视觉感知的图像质量评估指标LPIPS(Learned Perceptual Image Patch Similarity)[17]和FSIM(Feature Similarity Index)[18]、无参考的图像质量评估指标NIQE(Natural Image Quality Evaluator)[19]、GAN生成图像质量的两个常用指标IS(Inception Score)[20]和FID(Fréchet Inception Distance)[21]等。未来应该分析新的衡量指标的理论依据、优势与GPR数据的特征，在选用公认的衡量指标的同时，设计适合于GPR杂波抑制评价的衡量指标。在确定了杂波抑制评价方法之后，就可以开展GPR杂波抑制方法的研究。按杂波建模方法，GPR杂波抑制方法可以分为基于信号模型的杂波抑制方法和基于神经网络模型的杂波抑制方法这两大类。

4 基于信号模型的GPR杂波抑制

基于信号模型的GPR杂波抑制方法，是通过对GPR回波模型的建模，将杂波成分通过时频域、变换域及低秩稀疏表示的处理方法加以抑制。该方法有较为明确清晰的物理解释，在神经网络处理方法出现之前作为主要的GPR杂波抑制方法。随着GPR硬件技术的发展和对杂波抑制需求的不断提高，信号模型的构建和分析也趋于复杂化。下面分别从时频域分析、子空间分解及字典学习3方面加以阐述。

4.1 时频域分析

减均值法[22](Mean Substraction, MS)是去除直达波等平稳杂波的常用方法，通过从B-scan二维矩阵中减去均值消除背景噪声。减背景矩阵法[23](Background Matrix Subtraction, BMS)延续MS的思路通过减去代表纯水平背景噪声的综合矩阵来消除水平背景噪声，适应局部变化。移动平均减背景法[24](Moving Average Background Reduction, MABR)则将每一点减去特定窗口区域均值。文献[25]提出的基于交叉相关的背景减法(Cross-Correlation-based Background Subtraction, CCBS)参考每个A-scan与预设的参考波形之间的相似性来减去背景信号。这些方法简单高效，适合低复杂度、快速处理及简单杂波场景，但复杂场景下需结合其他方法。

频率-波数(Frequency-Wavenumber, F-K)域滤波利用信号和噪声在F-K的分布差异设计滤波器来抑制噪声。文献[26]利用F-K域中直达波和目标发射波之间明显的水平速度差异，根据发射与接收天线位置自适应抑制直达波。文献[27]将F-K滤波应用于C-scan数据，引入高斯拉普拉斯算子作为滤波器，验证了F-K滤波在三维探地雷达数据中的应用潜力。文献[28]提出了一种分段式F-K滤波，针对高低频设置不同阈值，优化了信噪比。文献[29]用边缘高斯平滑滤波器替换传统边缘陡峭的通带或阻带滤波器，解决了GPR信号在频域到时域变换过程中引起的振铃干扰问题。文献[30]通过在预设的窗口中不断迭代F-K滤波提取钢筋网杂波，并从原始数据中去除。F-K滤波适合抑制周期性噪声，计算快速，但局部适应性差。

小波变换通过多尺度分解保留目标边缘与细节，适合局部特征处理。文献[31]用二维物理小波作为基础小波来去除GPR杂波，内存占用小、计算快速。剪切变换(Shearlet Transform, ShT)可以看作小波变换的拓展，引入剪切矩阵捕捉多方向信息。文献[32]利用ShT的多尺度和多方向特性成功分离直达波和反射波，抑制随机噪声。标准ShT为减少计算量会对信号进行下采样，这会导致信号的部分信息丢失，尤其是高频部分，而非下采样剪切变换(Non-Subsampled Shearlet Transform, NSST)取消了这一过程来克服其缺陷。文献[33]设计时变阈值函数处理变NSST系数实现杂波抑制。这种采用阈值函数来处理NSST系数的方法并不少见，常见的分类有软阈值、硬阈值和自适应阈值等。文献[34]在使用NSST来抑制GPR杂波时不仅设计了一种自适应阈值函数，并且为了解决软阈值函数固有的偏置问题提出了一种新的软阈值函数，该算法结合两种阈值函数进行杂波抑制。小波变换适用于杂波与目标信号在时间-频率域有一定区分的场景，如随机噪声或局部高频杂波等非平稳信号，计算复杂度中等；NSST更适合高分辨率需求的应用，可以更好地区分复杂地层或多方向干扰这种在方向性或尺度上与目标信号有差异的场景，计算复杂度较高。

4.2 子空间分解

子空间技术以线性代数和优化理论为处理工具，将高维数据映射到低维子空间来保留数据的主要结构或特征，属于机器学习的范畴。下面对基于子空间技术的GPR杂波抑制方法加以阐述。

(1)奇异值分解(Singular Value Decomposition, SVD)：B-scan数据矩阵可分解为$\boldsymbol{X}=\boldsymbol{USV}^{\mathrm{T}}$，其中$\boldsymbol{U}$是$M\times M$的酉矩阵，列向量为左奇异向量$\boldsymbol{u}_n$，$\boldsymbol{S}$是$M\times N$的对角矩阵，对角线上的非负元素为奇异值$\boldsymbol{s}_n$，按降序排列，$\boldsymbol{V}$是$N\times N$的酉矩阵，列向量为右奇异向量$\boldsymbol{v}_n$，则B-scan数据可以分解为一系列矩阵之和。

$$\boldsymbol{X}=\boldsymbol{u}_1\boldsymbol{s}_1\boldsymbol{v}_1^{\mathrm{T}}+\boldsymbol{u}_2\boldsymbol{s}_2\boldsymbol{v}_2^{\mathrm{T}}+\cdots+\boldsymbol{u}_n\boldsymbol{s}_n\boldsymbol{v}_n^{\mathrm{T}} \tag{9}$$

较大奇异值所在项对应数据的主要特征，较小的通常对应噪声，通过截断小奇异值所在项来减少噪声。

(2)主成分分析(Principal Component Analysis, PCA)：数据变量之间可能存在相关性，导致分析难度增大，所以考虑由少数不相关的变量来代替相关的变量，用来表示数据，并且要能够保留数据的大部分信息，因此相较于SVD, PCA中要求变量的方差和(信息保存)最大，将新变量依次成为第1主成分、第2主成分，就是PCA的基本思想，通常情况下采用计算协方差矩阵描述数据在不同维度之间的相关性。PCA的主要局限性在于选取的主成分不能完全重建地面杂波或目标，文献[35]证明了均方根高度(Root-mean-square Height, RMSH)与地面杂波主成分相关的奇异值个数有明确的正相关

关系，有效解决了地面杂波抑制中的主成分选择问题。

(3)独立成分分析(Independent Component Analysis, ICA)：ICA的目标是找到一组新的变量或成分，这些成分不仅仅是不相关，并且在统计上是尽可能独立的，而杂波通常会集中在某些独立分量上，通过设定阈值或滤波策略去除杂波相关的分量，最后用去杂波后的独立分量重建数据。假设混合信号$\boldsymbol{X}$是一些未知的独立信号$\boldsymbol{S}$的线性混合$\boldsymbol{X}=\boldsymbol{AS}$。其中$\boldsymbol{A}$是未知的混合矩阵，ICA的目标是估计混合矩阵$\boldsymbol{A}$的逆或伪逆，从而恢复源信号$\boldsymbol{S}$。进行ICA前通常对数据进行中心化和白化处理(即使协方差矩阵转化为单位阵)，而ICA为了区分独立成分，不仅依赖2阶统计量(如协方差)，而且依赖峭度、熵和互信息等统计量。文献[36]解决了ICA算法中的信号相位不定性问题，且在进行完全总体经验模态分解算法后无须依靠传统的人工方式进行噪声剔除的步骤。

(4)低秩、稀疏矩阵分解(Low-Rank Sparse Matrix Decomposition, LRSD)：PCA通过提取数据主成分来保留最大方差信息，但对异常值敏感且假设杂波为高斯分布，难以处理非高斯或稀疏杂波，ICA分离统计独立成分，但当杂波与信号不满足独立性假设时，效果不稳定，且难以建模低秩背景。GPR杂波通常具有局部性、随机性或稀疏性，LRSD通过将含杂波B-scan数据分解为低秩和稀疏部分，结合PCA的低秩减模和ICA的稀疏性优势，无须独立性假设或高斯分布限制。以鲁棒主成分分析(Robust Principal Component Analysis, RPCA)[37]为例，其基本思想和原理如下所述。

RPCA的目的是分解一个观测矩阵$\boldsymbol{X}$，将其表示为低秩矩阵$\boldsymbol{L}$和稀疏矩阵$\boldsymbol{S}$之和$\boldsymbol{X}=\boldsymbol{L}+\boldsymbol{S}$，为了恢复$\boldsymbol{L}$和$\boldsymbol{S}$，RPCA通过解决优化问题

$$\min_{\boldsymbol{L},\boldsymbol{S}}\|\boldsymbol{L}\|_*+\lambda\|\boldsymbol{S}\|_1 \quad \text{s.t. } \boldsymbol{X}=\boldsymbol{L}+\boldsymbol{S} \tag{10}$$

由于该优化问题难以直接求解，通常采用交替方向乘子法或增广拉格朗日法交替更新$\boldsymbol{L}$和$\boldsymbol{S}$。文献[38]将RPCA应用在了GPR数据处理中并作了改进，首先对数据做了预处理来增强数据的稀疏性，然后将最小化核范数用于恢复低秩成分(杂波分量)，将l_1范数用于恢复稀疏成分(目标响应)，实现杂波的分离与抑制。文献[39]引入的GoDec(Go Decomposition)算法通过交替更新的方式提取低秩和稀疏成分，并通过双向随机投影(Bilateral Random Projections, BRP)显著加速了算法的计算过程，表现出了较强的鲁棒性和高效性。鲁棒非负矩阵分解(Robust Nonnegative Matrix Factorization, RNMF)[40]将原始数据分解为两个低秩非负矩阵的乘积，通过选择合适的分解维度控制低秩特性，进而有效去除杂波，并使用正则化构造稀疏性来增强对杂波数据处理的鲁棒性，减少异常值的影响。文献[41]提出了基于因子组稀疏正则化(Factor Group-Sparse Regularization, FGSR)的杂波抑制方法，采用非凸矩阵分解来取代RPCA中的最小化核范数，其对正则化参数不敏感，也不需要预先设置参数。文献[42]则采用加权最小化核范数(Weighted Nuclear Norm Minimization, WNNM)代替RPCA中的最小化核范数，更好地针对天线与地面不平行情况下的杂波抑制。文献[43]在LRSD抑制GPR数据杂波的过程中引入了总变差正则化(Total Variation Regularization, TVR)，通过SVD阈值化计算低秩部分，通过总变差模型来求解稀疏部分，进一步提高了杂波去除的有效性。

4.3 字典学习

不同于LRSD分离低秩与稀疏分量，字典学习(Dictionary Learning, DL)通过学习数据驱动的过完备字典$\boldsymbol{D}$捕捉GPR数据内在结构，强调数据重构和特征提取，通常采用交替优化策略使得输入数据$\boldsymbol{X}$能够通过字典$\boldsymbol{D}$和稀疏编码矩阵$\boldsymbol{A}$表示为$\boldsymbol{X}\approx\boldsymbol{DA}$，最小化重构误差并保证$\boldsymbol{A}$尽可能稀疏，其求解模型为

$$\min_{\boldsymbol{D},\boldsymbol{X}}\|\boldsymbol{X}-\boldsymbol{DA}\|_{\mathrm{F}}^2+\lambda\|\boldsymbol{A}\|_1, \quad \text{s.t. } \|\boldsymbol{D}(:,i)\|_2\le 1 \tag{11}$$

不同于DL学习一个通用字典，形态成分分析(Morphological Component Analysis, MCA)使用多个预定义字典(如小波、曲波等)将数据$\boldsymbol{X}$分解为不同形态成分(如纹理、边缘、噪声)，每个成分由特定的预定义字典稀疏表示，而不是从数据中学习得到，因此MCA是否能成功分离目标和杂波取决于字典的选择。文献[44]采取实验比对选取离散余弦变换(Discrete Cosine Transform, DCT)、非抽样离散小波变换(Undecimated Discrete Wavelet Transform, UDWT)和曲波变换作为字典下杂波抑制效果，UDWT适合各向同性目标分量，曲波变换适于杂波分量，效果最佳。文献[45]在采用UDWT和曲波变换分别作为目标分量、杂波分量的字典的基础上，结合相移偏移来增强目标特征，提升B-scan的空间分辨率和近埋目标区分能力。

与MCA固定多个字典不同，DL的字典是数据驱动的，适应性强。文献[46]采用的Online DL通过随机生成字典和小批量数据迭代更新，在F-K域增强了目标响应的稀疏性，提高了DL的杂波抑制

能力。文献[47]采用正交匹配追踪(Orthogonal Matching Pursuit, OMP)算法用于稀疏编码，将K-SVD字典学习引入到GPR数据的高斯噪声和随机杂波抑制中，以DCT为初始字典，自适应学习杂波特征，通过SVD重构误差训练完备字典，优于DCT直接处理随机介质杂波。文献[48]提出改进的K均值字典算法SGK(Sequential Generalized K-means)来更新字典，与K-SVD性能相当但运算效率更高。

MCA依赖于字典之间的互不稀疏性，需要先验知识选择合适的字典，相比DL计算效率更高，强调数据中的形态差异，当下研究主要是将目标回波与杂波作为两种分量进行分离，抑制的杂波类型主要取决于杂波分量的字典，如曲波变换擅长捕捉图像中的光滑曲线、边缘或具有方向性的几何结构，适合GPR数据中的细小纹波；DL在学习过程中需要交替优化字典和稀疏矩阵，适应性较强，但计算复杂度较高，较少需要先验信息。两种方法都需要优化稀疏编码，常采用LASSO, FISTA和OMP算法。在实际工程中，可以先采用简单方法如减背景法进行初步处理评估效果后再尝试复杂方法。若有现场实测数据，可先对少量的典型数据进行处理，对比不同方法的杂波抑制结果，评估具体项目场景的杂波特性后再选用对应方法。

5 基于神经网络模型的GPR杂波抑制

基于信号模型的GPR杂波抑制算法需假设杂波分布，如减背景均值法假设噪声为高斯白噪声；小波变换及其变体(如NSST)依赖于特定的阈值选择；子空间法通常假设目标信号相对于杂波稀疏或弱相关。这些算法通过参数优化可以实现一定程度的自适应性，但仍需手动调优特征或阈值。相比之下，神经网络通过多层神经元和非线性激活函数，数据驱动地学习杂波与目标信号的非线性模型，适应复杂的场景。随着计算能力和数据集制作能力的不断提升，神经网络算法的杂波抑制中应用广泛。

在神经网络算法中，除多层感知机和卷积神经网络(Convolutional Neural Network, CNN)，针对GPR杂波抑制任务，涌现出结构更复杂、性能更优的网络模型，主要分为基于编码-解码结构和基于生成-判别结构两大类。本节分别对这两类杂波抑制方法进行系统阐述，也介绍了除这两种结构以外的其他典型神经网络模型，最后讨论了神经网络算法在GPR杂波抑制上的局限性和潜在的解决策略。

5.1 基于编码-解码结构

在GPR杂波抑制研究当中，深度学习网络的架构持续创新。简单的CNN在处理高分辨率GPR数据时，深层结构可能导致参数量激增，需优化卷积核大小和层数以平衡性能与计算成本，自编码器(AutoEncoder, AE)通过对称的编码-解码结构和稀疏约束提升计算效率，结合信号稀疏性引入正则化损失函数，更好地适应GPR数据的物理特性。

AE通过编码器和解码器压缩并重构数据，最小化重构误差以学习低维表示，标准AE使用全连接层进行数据编码和解码，展平GPR数据为一维向量，忽略了数据的空间结构和局部相关性，导致空间信息的丢失，卷积自编码(Convolutional AutoEncoder, CAE)利用卷积和池化操作，提取多尺度特征，生成更完整的目标回波，显著提高杂波抑制的精度。作者团队[49]提出的多尺度卷积自编码器(Multi-scale Convolutional AutoEncoder, MCAE)通过多尺度卷积核提取B-scan信号特征，结合WGAN网络进行数据增强，有效抑制杂波。文献[50]提出的鲁棒自编码器(Robust AutoEncoder, RAE)引入ℓ_1正则化项，实现了对信号低秩分量和稀疏分量的有效分解，从而增强了模型的鲁棒性和非线性表示能力，性能优于传统RPCA。文献[51]将B-scan数据中的粗糙表面区域划分为小块作为深度编码器(Deep AutoEncoder, DAE)的训练数据集，仅需要少量GPR数据，将粗糙地表的杂波抑制视为异常检测问题进行处理，性能优于传统的子空间方法。文献[52]设计的深度卷积自编码(Deep Convolutional AutoEncoder, DCAE)采用了更深层次的卷积，在异构土壤背景模拟数据上表现优异，但在实测数据上性能下降，且易出现梯度消失或梯度爆炸的问题。U-Net通过引入跳跃连接克服深层网络训练过程产生的问题，改善梯度传递，提升训练稳定性。

在复杂杂波模式(如多重杂波叠加)下，标准AE的简单编码-解码结构难以有效区分目标和杂波，U-Net网络通过深层网络结构和跳跃连接融合全局上下文和局部细节，增强复杂杂波区分能力，并缓解梯度消失。文献[53]设计的CR-Net(Clutter-Removal Neural Network)在U-Net的跳跃连接处集成残差密集块(Residual Dense Blocks, RDBs)，结合密集连接和残差网络优势，提高杂波抑制能力，并开源CLT-GPR数据集，验证了采用平均绝对误差(Mean Absolute Error, MAE)结合MS-SSIM的混合损失优于传统MSE。文献[54]设计的CI-Net(Clutter-Immune Network)基于U-Net的拓展U^2-Net，在编码解码层中嵌套小型U-Net，深度融合特征，适应地下管道检测等复杂场景。文献[55]将子

空间投影注意力(Subspace Projection Attention, SPA)机制引入到U-Net跳跃连接，克服了传统子空间方法在有效选择目标分量方面的挑战，并基于随机骨料模型构建异质混凝土数据集。如图4所示(引自文献[55]，BY-NC-ND 4.0)，SPA模块通过自适应地学习子空间基向量，使网络在多尺度下识别并抑制杂波，同时保留目标特征。作者团队[56]提出的MIS-SE-Net(Mutual Interference Suppression and Signal Enhancement Network)通过将空间注意力模块(Spatial Attention Module, SAM)集成到跳跃连接，结合VGG16提取的MAE感知损失，抑制多目标相互干扰波并增强信号。文献[57]在SAM的基础上加入通道注意力模块(Channel Attention Module, CAM)增强通道间依赖，利用全局信息突出双曲线特征，采用域自适应微调提升泛化能力，证明了高FLOPs不一定改善对未见数据的性能，模型的架构和数据质量更关键。文献[58]采取级联架构联合训练，引入指数加权移动平滑损失，动态调整自网络中权重，其中第1阶段网络为第2阶段三维重建网络提供杂波抑制后的C-scan数据，并通过蒙特卡罗抽样生成真实三维骨料散射模型。表1总结了编码解码结构神经网络在GPR杂波抑制任务中的主要研究。

5.2 基于生成-判别结构

GAN通过生成器和判别器对抗训练，生成器从含杂波数据中恢复干净无杂波数据，判别器判断其真实性。文献[59]提出的Declutter-GAN首次将条件生成对抗网络(Conditional Generative Adversarial Network, cGAN)应用于GPR杂波抑制，通过添加条件信息提升生成的可控性，展现出计算效率与抑制效果的优势。作者团队[60]提出的解纠缠生成对抗网络(Disentanglement Representation Generative Adversarial Network, DR-GAN)无须成匹配数据，解纠缠的基本思想是将B-scan数据解构到不同的域，DR-GAN分别提取GPR数据中的目标特征和杂波特征，杂波抑制生成器和杂波重建生成器分别基于目标特征生成无杂波数据、基于目标与杂波特征生成含杂波数据，判别器提供对抗损失，驱动生成器生成相应数据，在不均匀介质数据集上表现优异。文献[61]结合GAN和离散小波变

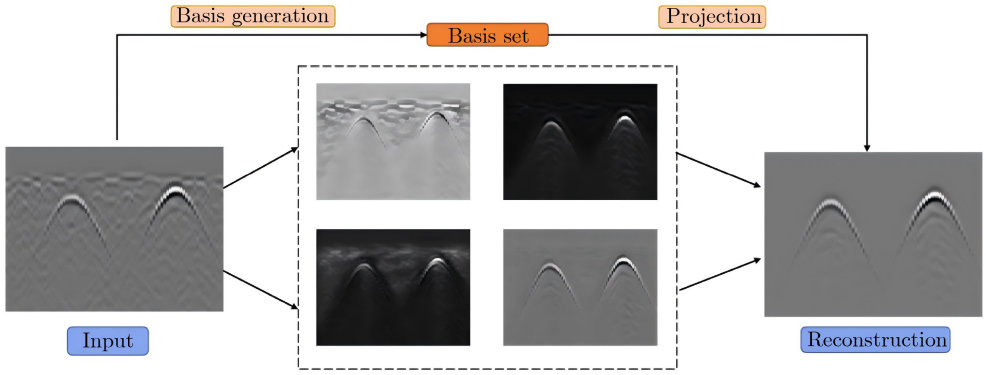

图 4 CB-Net子空间投影

表 1　基于编码-解码结构神经网络算法的对比一览表

分类	方法	时间	技术路线及评价
AE	MCAE	2021	设计了多尺度卷积核和WGAN网络，与CAE方法相比提高了PSNR
	RAE	2022	结合ℓ_1正则化捕捉稀疏分量和自编码器的非线性表示能力，优于RPCA的处理性能
	DAE	2024	将粗糙表面杂波抑制问题转化为异常检测问题，仅需要少量GPR数据，但需要人工选择粗糙表面区域
U-Net	DCAE	2022	采用了更深层次的卷积，在异构土壤背景模拟数据上表现出良好的性能
	CR-Net	2022	将RDBs集成在U-Net中，采用MAE结合MS-SSIM的混合损失函数，获得了更好的杂波抑制能力性能
	CI-Net	2023	在U^2-Net中集成残差模块、注意力机制和自适应权值学习模块，在地下管道探测场景中有更好的处理性能
	CB-Net	2024	采用随机骨料模型构建了异质混凝土数据集，将SPA与数据驱动方法相结合，解决了传统子空间方法在目标分量选择上的困难
	MIS-SE-Net	2024	将空间注意力机制引入到U-Net中，采用MAE感知损失，具有较好的抑制互扰波和信号增强的能力
	U-Net-SAM-CAM	2024	将CAM和SAM引入到U-Net，采用域自适应技术对已训练模型进行微调，提高对开放数据集的泛化能力
	多阶段级联U-Net	2024	采取级联架构和联合训练的策略，引入指数加权移动平均方法来平滑历史损失，实现了从C-scan中重建墙体内弱目标

换，将GPR数据分解为3个频率子数据，分别由3个生成器重构，再通过逆小波变换合并各频带生成新数据，融合了小波变换和深度学习优势，仅需要少量数据集，在提升去杂波质量的同时，加快训练速度并增强了泛化能力。

传统GAN通常需要含杂波的GPR信号与其对应的无杂波的目标信号，但实际场景中无杂波信号难以获取，循环一致生成对抗网络(Cycle-Consistent Generative Adversarial Network, CycleGAN)通过无监督学习和循环一致性损失降低对成对数据的依赖，其两对生成器和判别器及循环一致性损失确保去杂波B-scan数据转换时保留关键信息。在此基础上，文献[62]提出的基于生成对抗网络的钢筋杂波消除网络(Generative Adversarial Network-based Rebar Clutter Elimination Network, RCE-GAN)以集成扩张中心模块和注意力机制的U-Net网络作为生成器，捕获钢筋网杂波的多分辨率特征，采用PatchGAN判别器将输入数据划分为多个局部区域(patch)独立判别，增强局部特征分辨能力。作者团队[63]提出的钢筋网杂波抑制网络SuppRebar-GAN在CycleGAN的基础上引入了卷积块注意力模块(Convolutional Block Attention Module, CBAM)，设计的RE模块对不同类型的输入数据进行不同的操作，当输入数据受到钢筋杂波干扰时，RE模块学习捕捉钢筋杂波干扰的弱缺陷回波特征，放大两种杂波的差异；当输入数据没有钢筋杂波，RE模块将学习模糊缺陷回波，大幅改善了在无配对数据情况下生成器的性能，网络结构和处理流程如图5所示(经授权译自文献[63]，© 2024 IEEE)。文献[64]提出的基于GAN的钢筋消除网络(Rebar Elimination Network based on GAN, REN-GAN)将集成了特征注意力模块和自适应混合机制的自编码器作为生成器，结合预训练VGG19的感知一致性损失，缓解了比较图像像素空间时造成的GPR图像模糊，确保钢筋杂波抑制前后缺陷信号的一致性，提高空洞缺陷的识别精度。针对铁路隧道接触网杂波，文献[65]提出的接触网杂波消除GAN(Catenary Clutter Elimination Generative Adversarial Network, 2C-GAN)集成R5模块增强特征提取能力，铰链损失提升训练的稳定性。文献[66]提出的无监督多注意域自适应模型(Unsupervised Multiattention Domain Adapta-

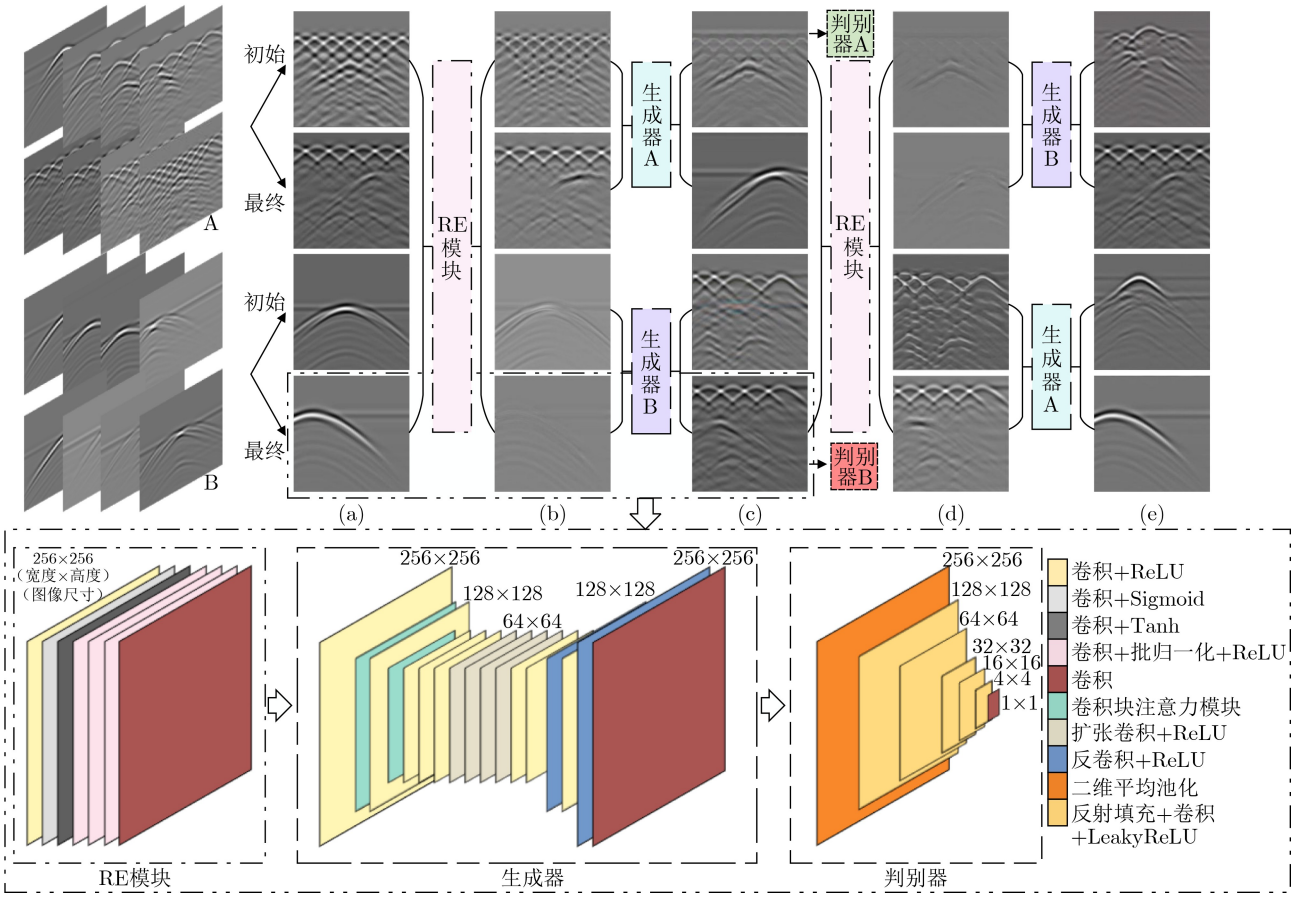

图 5 SuppRebar-GAN网络结构

tion, UMDA-net)融合了通道注意力、空间注意力和多头自注意力机制，关注局部和全局特征。表2总结了GAN在GPR杂波抑制任务中的主要研究。

5.3 其他神经网络模型

除上述研究外，一些其他深度学习模型在GPR杂波抑制中同样表现出色。BiSeNet(Bilateral Segmentation Network)通过双路径结构融合空间细节和上下文信息，有效分离杂波与目标信号。文献[67]对BiSeNetV2网络进行改良并应用于杂波抑制，引入自适应调整卷积核大小的灵活残差块和高效通道注意力机制优化特征的跨通道依赖，提升杂波抑制和目标恢复性能，处理速度快。RefineNet通过残差卷积单元和链式残差池化模块实现多分辨率融合，文献[68]将带有混合损失函数的RefineNet网络应用于GPR杂波抑制，采用全变分正则化的逆时偏移成像检验其性能，通过数值模拟、全尺寸实验和工程应用确认其适用性和可靠性。变分自编码器(Variational Autoencoder, VAE)通过学习潜在变量的概率分布并利用重参数化技巧实现梯度传播，文献[69]先采用VAE抑制地下分层结构对目标回波的扭曲、变形及覆盖，然后采用RefineNet抑制其余杂波干扰，再进行逆时偏移，显著提升目标成像质量。文献[70]将VAE与ResNet结合，利用ResNet的残差学习和跳跃连接解决深层网络的梯度消失问题，与VAE结合后弥补了传统ResNet在无法充分利用每层残差信息的不足，有效处理不均匀介质随机杂波。扩散模型将时间步信息注入各层并引入注意力机制，逐步预测杂波。文献[71]以低频B-scan约束条件扩散模型网络中来限制高分辨率图像的分布，同时实现杂波抑制和超分辨率，展现出显著的稳定性和泛化能力。ViT(Vision Transformer)的编码器由多层Transformer块堆叠而成，通过自注意力和多头注意力捕捉全局依赖。文献[72]提出的DC-ViTs(Declutter Vision Transformers)用卷积来替代经典ViT中的多层感知机，增强上下文捕捉能力，优于DCAE和CR-Net。残差通道注意力网络(Residual Channel Attention Network, RCAN)结合残差机构和通道注意力，将网络划分为多个残差组，融合多层次特征，具有较强的稳定性和特征提取能力。文献[73]采用RCAN网络抑制双层钢筋网杂波并增强缺陷回波，并通过坡印廷矢量分解增强的逆时偏移成像验证，证实了该算法在钢筋混凝土隧道场景中的鲁棒性。表3总结了其他结构网络GPR杂波抑制任务中的主要研究。

5.4 神经网络算法用于GPR杂波抑制的瓶颈及策略

神经网络在GPR杂波抑制中性能优异，但实际工程部署面临数据采集、计算资源和环境部署等多重挑战，这些瓶颈影响着模型的性能及效率，下面分析GPR杂波抑制神经网络算法在实际部署中的主要障碍，分析其技术与非技术层面的影响，并提出相应的优化策略。

(1)数据集规模与分布差异：GPR数据采集需专业人员操作，大规模高分辨率扫描耗时耗力，高成本限制了数据集的规模和多样化。不同环境和设备导致数据特征差异明显，数据集缺乏多样性会导致模型泛化能力不足。优化策略包括：通过FDTD模拟或数据增强(如添加噪声、翻转、GAN生成合成数据)扩充训练集；利用预训练模型迁移学习，适配目标场景，缓解数据分布不一致问题。

(2)计算资源需求与环境部署：神经网络模型复杂度高、数据量大及实时性要求导致计算资源不足。优化策略包括：将推理任务迁移至云端，降低本地硬件需求；通过剪枝、量化和知识蒸馏设计轻量级模型，适配低算力设备；针对离线部署(如野

表 2　基于生成-判别结构神经网络算法的对比一览表

分类	方法	时间	技术路线及评价
GAN	Declutter-GAN	2022	将cGAN应用于GPR杂波抑制，需要配对的无杂波目标数据和含杂波目标数据，将采集的背景数据与仿真计算的目标数据进行相加来制作数据集
	DR-GAN	2023	不需要成对的匹配数据，利用解纠缠表示的思想来提取GPR图像的目标特征和杂波特征
	Wavelet-GAN	2024	利用离散小波变换将GPR数据分为低频、中频和高频分量，设计3个生成器对各频段数据进行重构，加快了训练速度并增强了泛化能力
CycleGAN	RCE-GAN	2022	设计了两对生成器和判别器，在生成器中引入了注意力机制和膨胀中心模块，有效提高了对浅层钢筋网杂波的抑制性能
	SuppRebar-GAN	2024	在CycleGAN中集成了CBAM，设计了RE模块和EC-Yolov7，表现出良好的钢筋网回波抑制能力和较好的泛化能力
	REN-GAN	2024	采用感知一致性损失增强了损失函数，通过两种特征编码器来保证钢筋杂波抑制前后异常目标回波信号的一致性，提高钢筋网下空洞缺陷的识别精度
	2C-GAN	2025	设计了R5模块，采用铰链损失来增强网络训练的稳定性，增强了对实测数据中杂波的抑制能力
	UMDA-net	2025	生成器中融合了通道注意力、空间注意力和多头自注意力机制，可同时关注局部特征和全局语义信息

表 3 基于其他结构神经网络算法的对比一览表

方法	时间	网络原型来源	技术路线及评价
灵活残差BiSeNetV2	2023	IJCV	设计了灵活残差模块，根据不同任务所需的通道数和参数自适应选择卷积核大小，设计了一个高效通道注意力机制来提取通道间依赖关系
RefineNet	2024	CVPR	设计了RefintNet杂波抑制网络，采用基于全变分正则化的逆时偏移成像来对杂波抑制性能进行分析验证
VAE-RefineNet	2024	ICLR CVPR	采用VAE算法来抑制地下分层结构对目标回波的影响，采用RefineNet抑制杂波，通过成像处理验证上述算法的有效性
VAE-ResNet	2024	ICLR CVPR	利用VAE初级网络进行初步杂波抑制，集成残差特征蒸馏块来增强网络特征提取能力，性能优于ResNet
受约束Diffusion	2024	NeurIPS	通过低频B-scan作为约束条件来限制高分辨率图像的分布，克服了经典扩散模型在数据生成过程中易受到当前噪声样本迭代的影响问题
DC-ViTs	2024	ICLR	设计了更善于捕捉局部上下文的卷积来替代经典ViT中的多层感知机，杂波抑制性能优于DCAE和CR-Net
RCAN	2024	ECCV	采用了RCAN网络，构建了双层钢筋网场景下典型病害的数据集，开展了模拟仿真和实测数据的分析验证

外无网络环境)或敏感数据本地处理需求，使用FPGA等专用硬件加速卷积运算，优化信号处理流水线；降低输入数据分辨率或采样率，但要确保模型在低分辨率下仍具良好性能。

6 GPR杂波抑制展望

随着GPR在城市地下空间、公路轨道交通、地球物理探测和军事等领域的广泛应用，有效抑制GPR杂波、提高数据质量越来越重要。近年来，信号处理算法在GPR杂波抑制方面取得显著进展，但仍面临诸多挑战，未来的研究方向如下。

(1)融合多方法的优势：传统方法(如F-K滤波、小波变换和子空间法)基于信号模型，理论严谨、计算高效，在杂波特性明确(如线性杂波或平稳噪声)时表现出较强的稳定性；深度学习算法擅长处理非线性、非平稳杂波，泛化能力强。未来研究可以将传统方法的理论严谨性与深度学习的适应性加以融合，如通过传统方法预处理数据后再交由神经网络精细优化，兼顾高效性与适应性。

(2)实时处理与在线学习：为满足实时应用需求，杂波抑制算法须具备快速处理与在线学习能力，模型不仅要在短时间内完成数据处理，还需在动态环境下不断调整杂波抑制策略，以保证处理效率与效果的平衡。在线学习方法可以使模型在不断接收新数据的过程中进行自我优化，提高其长期适应性和稳定性。

(3)无监督学习与自监督学习：GPR数据中的杂波标注成本高且难度大，无监督学习算法(如DR-GAN, CycleGAN)通过自动发现数据模式、结构和分布降低数据依赖，但计算复杂较高，未来可采用知识蒸馏技术或网络剪枝技术实现轻量化，使其更适合嵌入式或实时处理系统。自监督学习通过数据构造“伪标签”设计监督任务来学习有效的数据表示，是无监督学习的一种子集，未来自监督学习可能成为现有无监督学习方法的补充，例如，通过预测雷达回波的时空连续性或频域特性，使得模型决策更透明和具有可解释性。

(4)跨任务学习与多模态融合：算法可以结合超分辨率、图像修复、目标检测等任务，以提升其泛化能力和效率。多模态融合整合多传感器或数据源的信息，增强杂波抑制的鲁棒性和精度，例如，可以利用不同频带的GPR数据对同一个探测场景进行探测，通过多模态网络(如注意力机制)融合时频特征，拓展GPR的有效观测带宽，提高探测性能。

(5)信号处理算法与物理机理的深入结合：当前杂波抑制方法多从信号处理角度出发，未来可从理论和物理机理层面进行深度融合和优化。核心在于将电磁波传播规律(如麦克斯韦方程)、介质特性(介电常数、电导率)及杂波生成机制融入算法设计。例如，建立基于物理约束的杂波统计模型，改进子空间法或F-K滤波；或者结合天线设计的极化特性，分离地表杂波与目标信号。此外，可通过物理引导神经网络将传播衰减规律嵌入深度学习模型。

(6)与探测应用紧耦合的杂波抑制方法：由于各探测应用中的背景介质的复杂性和待测目标的多样性，GPR在不同应用场景(如隧道、公路)杂波特征差异很大，需针对性地开发与各探测应用紧耦合的杂波抑制方法。如在隧道探测应用中，隧道的曲面结构、内部分层、钢筋网及内部的渗水脱空等异常体，导致GPR的杂波变得复杂。非均匀钢筋网产生的强回波信号与待测目标的弱信号在时域和频域上存在部分重叠，在F-K域中呈现近似周期性的条带，需要针对隧道的曲面结构和GPR天线的辐射特性对GPR回波中包含钢筋网在内的杂波特征

进行多域特征的分析，进而开展有针对性的网络结构优化与改进。此外，可以利用多天线阵列的空间信息，通过波束合成改善信杂噪比，或者利用钢筋网和待测目标在极化域的差异来设计杂波抑制算法。在公路或桥梁探测中，面临道路多层结构(如沥青层、基层、路基)和不同材质带来的复杂反射信号和杂波干扰。层状的背景介质及先验信息可以为深度学习网络设计和训练提供有价值的参考。各层的随机介质建模拟合和层面的高精度追踪与层厚度估计是GPR探测能力提升的基础。探测目标之外的钢筋网或其他异常体在层状介质中的散射特性分析，是决定GPR杂波抑制能力的关键。在训练识别多层结构中病害特征的深度学习模型时，可以采用迁移学习或域自适应技术，使模型快速适应不同的道路结构。

7　结束语

GPR数据中的杂波抑制问题已成为提高目标检测准确性和数据质量的重要课题。在传统的基于信号模型的杂波抑制算法不断发展的同时，以深度学习为代表的神经网络的方法由其较少的人工干预、较强的适应性和可扩展性迅速在杂波抑制方面取得显著进展，但两者都存在一定的局限性。传统方法在复杂模式和非线性特征处理与保持方面受限，而深度学习技术在大规模标注数据的获取以及计算资源的要求等方面面临挑战。根据不同的应用场景，灵活地选择杂波抑制的定量评价指标，融合两者的优势，是GPR杂波抑制领域的潜在突破口和方向。未来，随着传统信号模型算法和深度学习技术的不断优化与创新，GPR数据的杂波抑制方法有望更加智能化和高效，为各个应用领域提供更好的技术支持。

参 考 文 献

[1] JOL H M, 雷文太, 童孝忠, 周旸, 等译. 探地雷达理论与应用[M]. 北京: 电子工业出版社, 2011.
JOL H M, LEI Wentai, TONG Xiaozhong, ZHOU Yang, *et al*. translation. Ground Penetrating Radar: Theory and Application[M]. Beijing: Publishing House of Electronics Industry, 2011.

[2] XU Qiguo, GAO Hang, PANG Zebang, *et al*. GPR Bscan change detection network for structural defect evolution[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 5110815. doi: 10.1109/Tgrs.2024.3480122.

[3] SHI Xinghua, ZHANG Anxue, HAN Guoqing, *et al*. The design of 3-D ground-penetrating radar system for bridge inspection[J]. *IEEE Sensors Journal*, 2024, 24(13): 21276–21285. doi: 10.1109/Jsen.2024.3396467.

[4] ZHOU Haoqiu, FENG Xuan, DONG Zejun, *et al*. Predictive rotation fusion: A physical model-based fusion method for full-polarimetric GPR data[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2025, 63: 5103120. doi: 10.1109/Tgrs.2025.3550887.

[5] ARENDT B, SCHNEIDER M, MAYER W, *et al*. Environmental influences on the detection of buried objects with a ground-penetrating radar[J]. *Remote Sensing*, 2024, 16(6): 1011. doi: 10.3390/rs16061011.

[6] 刘海, 黄肇刚, 岳云鹏, 等. 地下管线渗漏环境下探地雷达信号特征分析[J]. 电子与信息学报, 2022, 44(4): 1257–1264. doi: 10.11999/JEIT211213.
LIU Hai, HUANG Zhaogang, YUE Yunpeng, *et al*. Characteristics analysis of ground penetrating radar signals for groundwater pipe leakage environment[J]. *Journal of Electronics & Information Technology*, 2022, 44(4): 1257–1264. doi: 10.11999/JEIT211213.

[7] LIU Hai, YUE Yunpeng, LIAN Yunlong, *et al*. Reverse-time migration of GPR data for imaging cavities behind a reinforced shield tunnel[J]. *Tunnelling and Underground Space Technology*, 2024, 146: 105649. doi: 10.1016/j.tust.2024.105649.

[8] 倪志康, 叶盛波, 史城, 等. 一种深度学习辅助的探地雷达定位方法[J]. 电子与信息学报, 2022, 44(4): 1265–1273. doi: 10.11999/JEIT211072.
NI Zhikang, YE Shengbo, SHI Cheng, *et al*. A deep learning assisted ground penetrating radar localization method[J]. *Journal of Electronics & Information Technology*, 2022, 44(4): 1265–1273. doi: 10.11999/JEIT211072.

[9] QIAO Hanqing, ZHANG Minghe, and BANO M. Harris hawks optimization for soil water content estimation in ground-penetrating radar waveform inversion[J]. *Remote Sensing*, 2025, 17(8): 1436. doi: 10.3390/rs17081436.

[10] 雷文太, 隋浩, 姜和俊, 等. DABP: 一种基于深度学习的探地雷达自聚焦后向投影成像方法[J]. 电子学报, 2024, 52(12): 4023–4036. doi: 10.12263/DZXB.20231144.
LEI Wentai, SUI Hao, JIANG Hejun, *et al*. DABP: A deep learning based auto focusing back projection imaging method for ground penetrating radar[J]. *Acta Electronica Sinica*, 2024, 52(12): 4023–4036. doi: 10.12263/DZXB.20231144.

[11] WEI Chuyang, ZHOU Xiren, LIU Shikang, *et al*. Enhanced anomaly detection in GPR data by combining spatial and dynamic information[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 5112010. doi: 10.1109/Tgrs.2024.3504715.

[12] WARREN C, GIANNOPOULOS A, and GIANNAKIS I. gprMax: Open source software to simulate electromagnetic wave propagation for ground penetrating radar[J]. *Computer Physics Communications*, 2016, 209: 163–170. doi: 10.1016/j.cpc.2016.08.020.

[13] 曾波, 刘硕, 杨军, 等. 地表起伏对地下管线GPR探测的影响

[J]. 物探与化探, 2023, 47(4): 1064–1070. doi: 10.11720/wtyht.2023.1516.

ZENG Bo, LIU Shuo, YANG Jun, *et al*. Influence of surface undulations on GPR-based underground pipeline detection[J]. *Geophysical and Geochemical Exploration*, 2023, 47(4): 1064–1070. doi: 10.11720/wtyht.2023.1516.

[14] 王磊. 探地雷达抑制射频干扰技术研究[D]. [硕士论文], 国防科学技术大学, 2009.

WANG Lei. Radio frequency interference suppressing of ground penetrating radar[D]. [Master dissertation], National University of Defense Technology, 2009.

[15] WANG Zhou, BOVIK A C, SHEIKH H R, *et al*. Image quality assessment: From error visibility to structural similarity[J]. *IEEE Transactions on Image Processing*, 2004, 13(4): 600–612. doi: 10.1109/Tip.2003.819861.

[16] WANG Z, SIMONCELLI E P, and BOVIK A C. Multiscale structural similarity for image quality assessment[C]. The Thrity-Seventh Asilomar Conference on Signals, Systems & Computers, Pacific Grove, USA, 2003. doi: 10.1109/ACSSC.2003.1292216.

[17] KIM H S, SEOL J, LEE J Y, *et al*. Style harmonization of panoramic radiography using deep learning[J]. *Oral Radiology*, 2025, 41(1): 111–119. doi: 10.1007/s11282-024-00782-2.

[18] ZHANG Lin, ZHANG Lei, MOU Xuanqin, *et al*. FSIM: A feature similarity index for image quality assessment[J]. *IEEE Transactions on Image Processing*, 2011, 20(8): 2378–2386. doi: 10.1109/Tip.2011.2109730.

[19] ZHANG Hua, DAI Qianwei, FENG Deshan, *et al*. ROI-binarized hyperbolic region segmentation and characterization by using deep residual convolutional neural network with skip connection for GPR imaging[J]. *Applied Sciences*, 2024, 14(11): 4689. doi: 10.3390/app14114689.

[20] SALIMANS T, GOODFELLOW I, ZAREMBA W, *et al*. Improved techniques for training GANs[C]. The 30th International Conference on Neural Information Processing Systems, Barcelona, Spain, 2016.

[21] HEUSEL M, RAMSAUER H, UNTERTHINER T, *et al*. GANs trained by a two time-scale update rule converge to a local Nash equilibrium[C]. The 31st International Conference on Neural Information Processing Systems, Long Beach, USA, 2017.

[22] ZOUBIR A M, CHANT I J, BROWN C L, *et al*. Signal processing techniques for landmine detection using impulse ground penetrating radar[J]. *IEEE Sensors Journal*, 2002, 2(1): 41–51. doi: 10.1109/7361.987060.

[23] RASHED M and HARBI H. Background matrix subtraction (BMS): A novel background removal algorithm for GPR data[J]. *Journal of Applied Geophysics*, 2014, 106: 154–163. doi: 10.1016/j.jappgeo.2014.04.022.

[24] BAI Hao and SINFIELD J V. Improved background and clutter reduction for pipe detection under pavement using ground penetrating radar (GPR)[J]. *Journal of Applied Geophysics*, 2020, 172: 103918. doi: 10.1016/j.jappgeo.2019.103918.

[25] WU Shuxian, WANG Longxiang, ZENG Xiaozhen, *et al*. UAV-mounted GPR for object detection based on cross-correlation background subtraction method[J]. *Remote Sensing*, 2022, 14(20): 5132. doi: 10.3390/rs14205132.

[26] HAYASHI N and SATO M. *F–k* filter designs to suppress direct waves for bistatic ground penetrating radar[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2010, 48(3): 1433–1444. doi: 10.1109/TGRS.2009.2032536.

[27] KANG M S and AN Y K. Frequency-wavenumber analysis of deep learning-based super resolution 3D GPR images[J]. *Remote Sensing*, 2020, 12(18): 3056. doi: 10.3390/rs12183056.

[28] 卢丹平, 沈绍祥, 李玉喜, 等. 一种基于改进*f-k*滤波的编码雷达信号去噪方法[J]. 电波科学学报, 2023, 38(5): 861–869. doi: 10.12265/j.cjors.2022183.

LU Danping, SHEN Shaoxiang, LI Yuxi, *et al*. A denoising method for coded radar signals based on improved *f-k* filtering[J]. *Chinese Journal of Radio Science*, 2023, 38(5): 861–869. doi: 10.12265/j.cjors.2022183.

[29] KONG Qingyang, YE Shengbo, LIANG Xiao, *et al*. A clutter removal method based on the F-K domain for ground-penetrating radar in complex scenarios[J]. *Remote Sensing*, 2024, 16(6): 935. doi: 10.3390/rs16060935.

[30] GE Junkai, SUN Huaifeng, LIU Rui, *et al*. Removing rebar clutter through iterative F-k migration in GPR data[J]. *IEEE Geoscience and Remote Sensing Letters*, 2025, 22: 3500805. doi: 10.1109/Lgrs.2024.3515956.

[31] SHI Xianxin and YANG Qiufen. Suppressing the direct wave noise in GPR data via the 2-D physical wavelet frame[C]. 2011 International Conference on Transportation, Mechanical, and Electrical Engineering (TMEE), Changchun, China, 2011: 1161–1164. doi: 10.1109/TMEE.2011.6199411.

[32] WANG Xiannan and LIU Sixin. Noise suppressing and direct wave arrivals removal in GPR data based on Shearlet transform[J]. *Signal Processing*, 2017, 132: 227–242. doi: 10.1016/j.sigpro.2016.05.007.

[33] HE Xingkun, LI Yujin, WANG Can, *et al*. Separate removal of random noise and clutter in GPR images based on Self2Self and NSST[J]. *International Journal of Remote Sensing*, 2022, 43(9): 3490–3508. doi: 10.1080/01431161.2022.2096420.

[34] TANG Xiaosong, YANG Feng, QIAO Xu, *et al*. A ground-penetrating radar clutter suppression algorithm integrating signal processing and image fusion[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 5936618. doi: 10.1109/Tgrs.2024.3508813.

[35] CHEN Gaoxiang, FU Liyun, CHEN Kanfu, *et al*. Adaptive ground clutter reduction in ground-penetrating radar data

based on principal component analysis[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(6): 3271–3282. doi: 10.1109/tgrs.2018.2882912.

[36] 雷文太, 梁琼, 谭倩颖. 基于自动反相校正和峰度值比较的探地雷达回波信号去噪方法[J]. 雷达学报, 2018, 7(3): 294–302. doi: 10.12000/JR17113.
LEI Wentai, LIANG Qiong, and TAN Qianying. A new ground penetrating radar signal denoising algorithm based on automatic reversed-phase correction and kurtosis value comparison[J]. *Journal of Radars*, 2018, 7(3): 294–302. doi: 10.12000/JR17113.

[37] CANDÈS E J, LI X D, MA Y, *et al*. Robust principal component analysis?[J]. *Journal of the ACM*, 2011, 58(3): 11. doi: 10.1145/1970392.1970395.

[38] SONG Xiaoji, XIANG Deliang, ZHOU Kai, *et al*. Improving RPCA-based clutter suppression in GPR detection of antipersonnel mines[J]. *IEEE Geoscience and Remote Sensing Letters*, 2017, 14(8): 1338–1342. doi: 10.1109/lgrs.2017.2711251.

[39] SONG Xiaoji, XIANG Deliang, ZHOU Kai, *et al*. Fast prescreening for GPR antipersonnel mine detection via go decomposition[J]. *IEEE Geoscience and Remote Sensing Letters*, 2019, 16(1): 15–19. doi: 10.1109/lgrs.2018.2866331.

[40] KUMLU D and ERER I. Improved clutter removal in GPR by robust nonnegative matrix factorization[J]. *IEEE Geoscience and Remote Sensing Letters*, 2020, 17(6): 958–962. doi: 10.1109/lgrs.2019.2937749.

[41] LIU Li, WU Zezhou, XU Hang, *et al*. GPR clutter removal based on factor group-sparse regularization[J]. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19: 3509305. doi: 10.1109/Lgrs.2021.3122262.

[42] LIU Li, SONG Chenyan, WU Zezhou, *et al*. GPR clutter removal based on weighted nuclear norm minimization for nonparallel cases[J]. *Sensors*, 2023, 23(11): 5078. doi: 10.3390/s23115078.

[43] ZHAO Yi, YANG Xiaopeng, QU Xiaodong, *et al*. Clutter removal method for GPR based on low-rank and sparse decomposition with total variation regularization[J]. *IEEE Geoscience and Remote Sensing Letters*, 2023, 20: 3502605. doi: 10.1109/lgrs.2023.3250717.

[44] TEMLIOGLU E and ERER I. Clutter removal in ground-penetrating radar images using morphological component analysis[J]. *IEEE Geoscience and Remote Sensing Letters*, 2016, 13(12): 1802–1806. doi: 10.1109/Lgrs.2016.2612582.

[45] ZHOU Yanhui and CHEN Wenchao. MCA-based clutter reduction from migrated GPR data of shallowly buried point target[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(1): 432–448. doi: 10.1109/Tgrs.2018.2855728.

[46] NI Zhikang, PAN Jun, SHI Cheng, *et al*. DL-based clutter removal in migrated GPR data for detection of buried target[J]. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19: 3507205. doi: 10.1109/Lgrs.2021.3089246.

[47] FENG Deshan, LIU Shuo, YANG Jun, *et al*. The noise attenuation and stochastic clutter removal of ground penetrating radar based on the K-SVD dictionary learning[J]. *IEEE Access*, 2021, 9: 74879–74890. doi: 10.1109/Access.2021.3081349.

[48] FENG Deshan, HE Li, WANG Xun, *et al*. Efficient denoising of multidimensional GPR data based on fast dictionary learning[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2024, 17: 5221–5233. doi: 10.1109/Jstars.2024.3366397.

[49] LUO Jiabin, LEI Wentai, HOU Feifei, *et al*. GPR B-scan image denoising via multi-scale convolutional autoencoder with data augmentation[J]. *Electronics*, 2021, 10(11): 1269. doi: 10.3390/electronics10111269.

[50] NI Zhikang, YE Shengbo, SHI Cheng, *et al*. Clutter suppression in GPR B-scan images using robust autoencoder[J]. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19: 3500705. doi: 10.1109/Lgrs.2020.3026007.

[51] ZHANG Yan, DIAO Enmao, HUSTON D, *et al*. A data-efficient deep learning method for rough surface clutter reduction in GPR images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 5104610. doi: 10.1109/tgrs.2024.3382545.

[52] TEMLIOGLU E and ERER I. A novel convolutional autoencoder-based clutter removal method for buried threat detection in ground-penetrating radar[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5103313. doi: 10.1109/tgrs.2021.3098122.

[53] SUN Haihan, CHENG Weixia, and FAN Zheng. Learning to remove clutter in real-world GPR images using hybrid data[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5113714. doi: 10.1109/Tgrs.2022.3176029.

[54] YANG Gexing, YUAN Da, XU Tianjia, *et al*. An adaptive clutter-immune method for pipeline detection with GPR[J]. *IEEE Sensors Journal*, 2023, 23(19): 22984–22997. doi: 10.1109/Jsen.2023.3305681.

[55] CAO Yanjie, YANG Xiaopeng, GUO Conglong, *et al*. Subspace projection attention network for GPR heterogeneous clutter removal[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2024, 17: 3917–3926. doi: 10.1109/jstars.2024.3355213.

[56] LEI Wentai, TAN Xin, LUO Chaopeng, *et al*. Mutual interference suppression and signal enhancement method for ground-penetrating radar based on deep learning[J]. *Electronics*, 2024, 13(23): 4722. doi: 10.3390/electronics13234722.

[57] PANDA S L, SAHOO U K, MAITI S, *et al*. An attention U-Net-based improved clutter suppression in GPR images[J]. *IEEE Transactions on Instrumentation and Measurement*, 2024, 73: 8502511. doi: 10.1109/tim.2024.3378267.

[58] 兰天, 盛世文, 孙熙韬, 等. 探地雷达多阶段级联U-Net墙内小目标三维重建方法[J]. 雷达学报(中英文), 2024, 13(6): 1184–1201. doi: 10.12000/JR24163.
LAN Tian, SHENG Shiwen, SUN Xitao, *et al*. Three-dimensional reconstruction method for detecting small targets within walls based on a multistage cascade U-Net approach using ground penetrating radars[J]. *Journal of Radars*, 2024, 13(6): 1184–1201. doi: 10.12000/JR24163.

[59] NI Zhikang, SHI Cheng, PAN Jun, *et al*. Declutter-GAN: GPR B-scan data clutter removal using conditional generative adversarial nets[J]. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19: 4023105. doi: 10.1109/lgrs.2022.3159788.

[60] 雷文太, 毛凌青, 庞泽邦, 等. DR-GAN: 一种无监督学习的探地雷达杂波抑制方法[J]. 电子与信息学报, 2023, 45(10): 3776–3785. doi: 10.11999/JEIT221072.
LEI Wentai, MAO Lingqing, PANG Zebang, *et al*. DR-GAN: An unsupervised learning approach to clutter suppression for ground penetrating radar[J]. *Journal of Electronics & Information Technology*, 2023, 45(10): 3776–3785. doi: 10.11999/JEIT221072.

[61] GE Junkai, SUN Huaifeng, SHAO Wei, *et al*. Wavelet-GAN: A GPR noise and clutter removal method based on small real datasets[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 5918214. doi: 10.1109/Tgrs.2024.3410277.

[62] WANG Yuanzheng, QIN Hui, TANG Yu, *et al*. RCE-GAN: A rebar clutter elimination network to improve tunnel lining void detection from GPR images[J]. *Remote Sensing*, 2022, 14(2): 251. doi: 10.3390/rs14020251.

[63] MA Yalou, LEI Wentai, PANG Zebang, *et al*. Rebar clutter suppression and road defects localization in GPR B-scan images based on SuppRebar-GAN and EC-Yolov7 networks[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 1–14. doi: 10.1109/tgrs.2024.3373025.

[64] REN Qiuyang, WANG Yanhui, XU Jie, *et al*. REN-GAN: Generative adversarial network-driven rebar clutter elimination network in GPR image for tunnel defect identification[J]. *Expert Systems with Applications*, 2024, 255: 124395. doi: 10.1016/j.eswa.2024.124395.

[65] XIONG Hongqiang, LI Jing, LIU Tieyu, *et al*. Catenary clutter elimination network for railway tunnel ground penetrating radar data[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2025, 63: 5905614. doi: 10.1109/Tgrs.2025.3533609.

[66] GUO Zhishun, GAO Yesheng, SHI Mengyang, *et al*. Unsupervised multiattention domain adaptive decluttering model for metal pipe targets in GPR images[J]. *IEEE Sensors Journal*, 2025, 25(10): 17503–17513. doi: 10.1109/Jsen.2025.3553381.

[67] LI Boyang, YUAN Da, YANG Gexing, *et al*. Flexibility-residual BiSeNetV2 for GPR image decluttering[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, 61: 5106812. doi: 10.1109/Tgrs.2023.3296722.

[68] LEI Jianwei, FANG Hongyuan, ZHU Yining, *et al*. GPR detection localization of underground structures based on deep learning and reverse time migration[J]. *Ndt & E International*, 2024, 143: 103043. doi: 10.1016/j.ndteint.2024.103043.

[69] 戴前伟, 熊泽平, 丁浩, 等. 基于VAE-RefineNet算法流程的GPR杂波抑制和目标成像[J]. 地球物理学进展, 2023, 38(5): 2250–2262. doi: 10.6038/pg2023GG0645.
DAI Qianwei, XIONG Zeping, DING Hao, *et al*. Clutter suppression of GPR B-scan and target imaging based on VAE-RefineNet algorithm process[J]. *Progress in Geophysics*, 2023, 38(5): 2250–2262. doi: 10.6038/pg2023GG0645.

[70] WANG Xiangyu and LIU Hai. VAE-ResNet cascade network: An advanced algorithm for stochastic clutter suppression in ground penetrating radar data[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 5913212. doi: 10.1109/Tgrs.2024.3394750.

[71] LAN Tian, LUO Xi, YANG Xiaopeng, *et al*. A constrained diffusion model for deep GPR image enhancement[J]. *IEEE Geoscience and Remote Sensing Letters*, 2024, 21: 3003505. doi: 10.1109/Lgrs.2024.3433481.

[72] KAYACAN Y E and ERER I. A vision-transformer-based approach to clutter removal in GPR: DC-ViT[J]. *IEEE Geoscience and Remote Sensing Letters*, 2024, 21: 3505105. doi: 10.1109/Lgrs.2024.3385694.

[73] WANG Xiangyu, LIU Hai, MENG Xu, *et al*. Enhanced imaging of concealed defects behind concrete linings using residual channel attention network for rebar clutter suppression[J]. *Automation in Construction*, 2024, 166: 105574. doi: 10.1016/j.autcon.2024.105574.

雷文太：男，教授，博士生导师，研究方向为探地雷达系统集成和信号处理.
王以明：男，硕士生，研究方向为探地雷达、深度学习.
钟继卫：男，教授级高工，研究方向为桥梁结构健康监测.
徐齐国：男，博士生，研究方向为探地雷达、深度学习、图像处理.
姜玉印：男，助理工程师，研究方向为桥梁结构健康监测.
李 成：男，高级工程师，研究方向为桥梁安全监测、智慧运维与防灾减灾.

责任编辑：马秀强

A Review of Clutter Suppression Techniques in Ground Penetrating Radar: Mechanisms, Methods, and Challenges

LEI Wentai[①②]　WANG Yiming[②]　ZHONG Jiwei[①⑤]　XU Qiguo[③]
JIANG Yuyin[①④]　LI Cheng[①④]

[①](*State Key Laboratory of Bridge Intelligent and Green Construction*, *Wuhan* 430050, *China*)
[②](*Department of Electronic Information*, *Central South University*, *Changsha* 410000, *China*)
[③](*Department of Computer Science and Engineering*, *Central South University*, *Changsha* 410000, *China*)
[④](*China Railway Bridge Science Research Institute*, *Ltd.*, *Wuhan* 430050, *China*)
[⑤](*China Railway Construction Bridge Engineering Bureau Group Co.*, *Ltd.*, *Wuhan* 430050, *China*)

Abstract:

Significance　Ground Penetrating Radar (GPR) is a widely adopted non-destructive subsurface detection technology, extensively applied in urban subsurface exploration, transportation infrastructure monitoring, geophysical surveys, and military operations. It is employed to detect underground pipelines, structural foundations, road voids, and concealed defects in roadbeds, railway tracks, and tunnels, as well as shallow geological formations and military targets such as unexploded ordnance. However, the presence of clutter—unwanted signals including direct coupling waves, ground reflections, and non-target echoes—severely degrades GPR data quality and complicates target detection, localization, imaging, and parameter estimation. Effective clutter suppression is therefore essential to enhance the accuracy and reliability of GPR data interpretation, making it a central research focus in improving GPR performance across diverse application domains.

Progress　Significant progress has been achieved in GPR clutter suppression, largely through two main approaches: signal model-based and neural network-based methods. Signal model-based techniques, such as time-frequency analysis, subspace decomposition, and dictionary learning, rely on physical modeling to distinguish clutter from target signals. These methods provide clear interpretability but are limited in addressing complex and non-linear clutter patterns. Neural network-based methods, employing architectures such as Convolutional Neural Networks, U-Net, and Generative Adversarial Networks, are more effective in capturing non-linear features through data-driven learning. Recent advances, including multi-scale convolutional autoencoders, attention mechanisms, and hybrid models, have further enhanced clutter suppression under challenging conditions. Quantitative metrics such as Mean Squared Error, Peak Signal-to-Noise Ratio, and Structural Similarity Index are commonly used for performance evaluation, often complemented by qualitative visual assessment.

Conclusion　The complexity and diversity of GPR clutter, originating from direct coupling, ground reflections, equipment imperfections, non-uniform media, and non-target scatterers, demand robust suppression strategies. Signal model-based methods provide strong theoretical foundations but are constrained by simplified assumptions, whereas neural network-based approaches offer greater adaptability at the expense of large data requirements and high computational cost. Hybrid approaches that integrate the strengths of both paradigms show considerable potential in addressing complex clutter scenarios. The selection of evaluation metrics plays a pivotal role in algorithm design, with quantitative measures offering objective assessment and qualitative analyses providing intuitive validation. Despite recent advances, significant challenges remain in suppressing non-linear clutter, enabling real-time processing, and reducing reliance on labeled data.

Prospect　Future research in GPR clutter suppression is likely to emphasize integrating the strengths of signal model-based and neural network-based methods to develop robust and adaptive solutions. Real-time processing and online learning will be prioritized to meet the requirements of dynamic applications. Self-supervised and unsupervised learning approaches are expected to reduce dependence on costly labeled datasets and improve model adaptability. Cross-task learning and multi-modal fusion, combining data from multiple sensors or frequencies, are expected to enhance robustness and precision. Furthermore, deeper integration of physical principles, including electromagnetic wave propagation and media properties, into algorithm design is expected to improve suppression accuracy and computational efficiency, advancing the development of more intelligent and effective GPR systems.

Key words: Ground Penetrating Radar (GPR); Clutter suppression; Deep learning; Performance metrics; Review