

## 干扰抑制类生成式对抗网络\*

李春腾<sup>1,2</sup>, 蒋宇中<sup>2</sup>, 刘芳君<sup>3</sup>, 贾书阳<sup>2</sup>, 李松林<sup>4</sup>

(1. 中国人民解放军 92330 部队, 山东 青岛 266000; 2. 海军工程大学 电子工程学院, 湖北 武汉 430033;  
3. 云南民族大学 数学与计算机科学学院, 云南 昆明 650500; 4. 海军工程大学 电气工程学院, 湖北 武汉 430033)

**摘要:**为进一步改善超低频频段的通信质量,在传统改进广义旁瓣抵消算法的基础上,提出新的超低频干扰抑制算法——生成式旁瓣抵消算法。该算法将人工智能研究热点之一的生成式对抗网络模型引入广义旁瓣抵消算法中,通过优化设计生成模型的网络结构及相关超参数,有效地解决了原算法存在的期望信号残留问题,为旁瓣抵消通道中的后级滤波算法提供了与主通道相关性更强的干扰参考信息,从而提高了算法对主通道干扰估计的准确性。为了验证优化后生成模型的有效性以及所提算法对不同类别干扰的抑制能力,在实验室环境下搭建实验平台,设计了多组对照实验。实验结果表明:优化后的生成模型具有较好的生成能力、较好的鲁棒性以及相对较低的运算复杂度;相比于传统改进的广义旁瓣抵消算法,所提算法进一步提高了信号带宽内的信干噪比。

**关键词:**超低频通信;生成式对抗网络;干扰抑制;磁性天线;广义旁瓣抵消;阻塞矩阵

**中图分类号:**TN911.7 **文献标志码:**A **文章编号:**1001-2486(2020)05-001-08

## Interference suppression generative adversarial nets

LI Chunteng<sup>1,2</sup>, JIANG Yuzhong<sup>2</sup>, LIU Fangjun<sup>3</sup>, JIA Shuyang<sup>2</sup>, LI Songlin<sup>4</sup>

(1. The PLA Unit 92330, Qingdao 266000, China;

2. College of Electronic Engineering, Naval University of Engineering, Wuhan 430033, China;

3. Academy of Mathematics and Computer Science, Yunnan Nationalities University, Kunming 650500, China;

4. College of Electrical Engineering, Naval University of Engineering, Wuhan 430033, China)

**Abstract:** In order to further improve the communication quality of the extremely-low-frequency communication further, based on the traditional improved generalized sidelobe cancellation, a new interference suppression algorithm in the field of extremely-low-frequency communication called generative sidelobe cancellation algorithm was proposed. Generative adversarial nets as one of the hot research topics in artificial intelligence was introduced into generalized sidelobe cancellation, the network structure and relevant hyperparameters of the generative model were designed and optimized, addressing the problem of the residual desired signal existing into the original algorithm effectively, providing more relevant reference information about the interference components in the main channel for the next-stage filtering algorithm of sidelobe cancellation channel, thereby enhancing the estimation accuracy of the interference components in the main channel. In order to validate the effectiveness of the optimized generative model and the suppression ability of the proposed algorithm on different types of interferences, an experimental platform was set up under the laboratory environment and multiple sets of controlled experiments were designed. The experimental results show that the optimized generative model has better generative ability, better robustness and relatively lower computational complexity. Compared with the traditional improved algorithm, the proposed algorithm can further improve the signal-to-interference-plus-noise ratio within the signal bandwidth further.

**Keywords:** extremely-low-frequency communication; generative adversarial nets; interference suppression; magnetic antenna; generalized sidelobe cancellation; blocking matrix

超低频频段的电磁波凭借其在海水中衰减较小和信号传输稳定等优点<sup>[1]</sup>被视作一种可靠的通信方式。然而,在超低频通信中,天线的辐射效率非常低,加之该频段面临很强的背景噪声干扰,导致接收信号的信干噪比(Signal-to-Interference-

plus-Noise Ratio, SINR)很低。一般而言,有两种方案解决上述问题,一种是增加发射功率,另一种是采用先进高效的数字信号处理技术,而前者不仅成本高,并且改善效果也不是很明显。因此,本文将研究的重点放在后者:一方面通过设计灵敏

\* 收稿日期:2019-03-07

基金项目:国家自然科学基金资助项目(41631072)

作者简介:李春腾(1992—),男,山东威海人,博士研究生,E-mail:249170952@qq.com;

蒋宇中(通信作者),男,教授,博士,博士生导师,E-mail:scholarqh@163.com

度较高的磁性天线接收阵列提高接收机对微弱信号的检测能力;另一方面通过在接收机前端引入信号预处理和在后端采用性能优良的干扰抑制算法提高接收机的抗干扰能力,实现信号带宽内 SINR 的改善。

对于干扰抑制算法而言,传统的算法主要采用基于自适应类滤波算法<sup>[2]</sup>及其相关改进方案<sup>[3-4]</sup>。考虑到超低频通信较低的 SINR,本文采用间接干扰抑制方式,即首先通过参考通道获取的相关信息估计主信号中的干扰分量,而后利用估计的干扰分量将主信号中的干扰移除。鉴于在实际的超低频通信时,期望信号的来向无法提前知晓,参考通道会不可避免地接收到期望信号分量,使得上述传统算法在进行干扰抑制的同时抵消部分期望信号分量,从而导致传统算法信号带宽内 SINR 的改善不明显。为了有效地解决传统算法的失效问题,本文将研究目光聚焦于语音信号增强领域中常用的广义旁瓣抵消(Generalized Sidelobe Cancellation, GSC)算法<sup>[5]</sup>,该类算法凭借主通道的信号增强、参考通道的阻塞输出以及后级滤波方案,在超低频干扰抑制领域中展现出较好的应用前景。然而,传统的 GSC 算法存在以下几个问题:第一,主通道采用的固定波束形成算法的性能受限于主通道接收天线的数量,且需要信号来波方向先验信息;第二,阻塞矩阵的设计过于简单,使得参考通道无法获取不含期望信号的干扰参考信息;第三,后级最小均方(Least Mean Square, LMS)误差算法存在收敛速度较慢和稳态误差较大的缺点。

针对上述问题,课题组提出了基于 GSC 算法的改进方案<sup>[6]</sup>,实现了较好的干扰抑制效果。但在文献[6]中提出的改进方案考虑的通信环境过于理想,即参考通道接收到的期望信号分量较少,且仅针对信号带宽内的单干扰源进行抑制,该干扰源是人为产生的固定中心频率的宽频干扰,而在实际的超低频通信中,信号带宽内可能会存在多个干扰源,且部分干扰源辐射出的噪声分布杂乱无章,中心频率随时间的变化而变化。本文从实际的超低频通信环境出发,采用绕线用的电机辐射出的干扰模拟随机干扰,通过结合人工智能领域新兴的生成模型和之前提出的改进方案实现了接收机在极端情况下(干扰和期望信号的来波方向相同,均位于接收阵列的 45°方向,此时参考通道会接收较多的期望信号分量,该部分期望信号的强度与主通道中的期望信号强度相差不大)的双干扰抑制,取得了较

好的干扰抑制效果。

## 1 信号模型

设计的磁性天线接收阵列结构如图 1 所示,①和③的  $C_{m1}$  和  $C_{m2}$  为两个相互平行的主天线,②和④的  $C_{r1}$  和  $C_{r2}$  为两个相互平行的参考天线,采用与主天线空间正交的方式布设,每根磁性天线的参数基本一致,具体的设计制作过程已在文献[6]中阐述,此处不再赘述。在接收机前端引入信号预处理方案,设计并制作了模拟滤波电路,有效地抑制了工频干扰以及谐波分量,其详细的滤波方案已在文献[6]中阐述,此处不再赘述。




图 1 磁性天线接收阵列结构示意图

Fig. 1 Schematic diagram of receiving array

假设主天线  $C_{mi}$  在某一时刻接收信号为  $y_i(k)$ , 其可表示为:

$$y_i(k) = \alpha_i x(k) + \sum_{l=1}^J P_l(\theta_{r_l}) r_l(k) + n_i(k), \quad i = 1, 2 \quad (1)$$

式中:  $x(k)$  表示期望信号,  $k$  表示采样点索引;  $\alpha_i$  表示期望信号在第  $i$  路主通道上的投影因子;  $r_l(k)$  为第  $l$  个强干扰;  $n_i(k)$  为背景噪声;  $J$  表示强干扰的总数。  $P_l(\theta_{r_l}) = \zeta_{il} \cos \theta_{r_l}$ , 其中  $P_l(\cdot)$  为投影算子符号, 表示某个信号在第  $i$  路主天线上的投影;  $\theta_{r_l}$  表示强干扰与磁性天线接收阵列的中心形成的水平夹角;  $\zeta_{il}$  ( $0 \leq \zeta_{il} \leq 1$ ) 表示强干扰在第  $i$  路主通道上的投影系数。鉴于工频及其谐波分量干扰已被前端滤波电路滤除, 接收阵列接收到的该部分干扰较弱。因此, 在式(1)中并未考虑该部分干扰。

由图 1 可知, 接收阵列结构中各路天线摆放间距较小, 而超低频信号的波长可达 1000 ~

10 000 km,远大于上述摆放间距。因此,因摆放间距而导致的期望信号时延  $\tau$  可忽略不计,则参考天线  $C_n$  在某一时刻收到的信号  $y_n(k)$  可近似表示为:

$$y_n(k) = \alpha_n x(k) + \sum_{l=1}^J P_n(\theta_l) r_l(k + \tau_{il}) + n_n(k + \tau_i), i = 1, 2 \quad (2)$$

式中:  $\alpha_n$  表示期望信号在第  $i$  路参考天线上的投影因子;  $\tau_i$  和  $\tau_{il}$  分别表示背景噪声和强干扰到达参考天线的时延(相比于他们到达主天线的的时间);  $P_n(\theta_l) = \kappa_{il} \sin \theta_l$ , 其中  $\kappa_{il} (0 \leq \kappa_{il} \leq 1)$  表示强干扰在第  $i$  路参考天线上的投影系数,虽然考虑的应用环境是期望信号和强干扰均位于接收阵列的  $45^\circ$  方向,且主天线与参考天线采用正交对称布设,但由于磁性天线和预处理滤波电路的制作工艺有限,并不能保证各路天线接收到的信号具有完全相同的增益,因此在式(1)和式(2)的投影算子中分别引入不同的投影系数。

## 2 生成式旁瓣抵消算法

提出的生成式旁瓣抵消算法(Generative Sidelobe Cancellation Algorithm, GSCA)的原理框图如图2所示。该算法主要由3部分组成:改进后的生成模型(Improved Generative Model, IGM)、主通道和旁瓣抵消通道。IGM 凭借其强大的学习能力用于生成与主通道干扰相关性更强的且不含期望信号的参考干扰  $n_c(k)$ 。主通道用于实现接收信号的增强和期望信号的估计。旁瓣抵消通道用于估计主通道中的干扰分量,其主要由基于信号带宽内 SINR 最低原则优化设计的阻塞矩阵和基于递归最小二乘(R Recursive Least Square, RLS)的自适应滤波算法组成。阻塞矩阵的输出为估计主通道中的干扰分量提供的另一路不含期望信号的参考干扰  $n_b(k)$ , 将  $n_c(k)$  和  $n_b(k)$  送至后级自适应滤波算法中,实现主通道中干扰分量的估计。主通道利用增强后的接收信号与旁瓣抵消通道估计的干扰分量相减,最终输出估计的期望信号。所提算法的主通道和旁瓣抵消通道中阻塞矩阵的优化设计均采用与文献[6]中提出的传统改进算法相同的技术方案,后级算法均采用 RLS 算法[7]。这意味着 GSCA 与传统改进算法相比,除了引入的参考干扰分量不同之外,其他条件均相同。阻塞矩阵的优化设计和主通道中采用的线性滤波算法参照文献[6],下面将重点介绍 IGM 的优化设计方法。

生成式对抗网络(Generative Adversarial Networks, GANs)[8]是由 Goodfellow 等在 2014 年提出的一种新的生成模型,目前已成为人工智能领域的研究热点之一。GANs 主要由生成器和判别器构成,其基本思想来源于二人零和博弈。生成器用来生成新的样本数据;而判别器作为一个二分类器,用来辨别输入样本是来自真实的数据还是生成的数据。两者均由深度神经网络构成,通过生成器和判别器的不断对抗迭代优化,生成模型的性能不断提升。当判别器无法辨别输入样本的数据来源时,认为生成器已经捕捉到了输入样本的真实分布。

将 GANs 在语音信号增强领域中新的一类生成模型——语音增强类 GANs (Speech Enhancement Generative Adversarial Networks, SEGANs)[9]引入超低频干扰抑制算法中,并在此基础上进行改进,提出了 IGM。对于超低频信号而言,样本的形式是一维数据,无须对其进行预加重和去加重处理。生成器采用卷积神经网络结构中的近似自动编码结构,包括输入层、编码层、去编码层和输出层,其具体结构示意图见图2中的生成器部分。

为了生成与主通道干扰分量相关性更强的参考干扰,输入层采用的样本数据对为两路参考信号  $y_{r1}(k)$  和  $y_{r2}(k)$  的自适应阻塞输出  $y_b(k)$  和主天线  $C_m$  接收的信号  $y_1(k)$ 。具体的自适应阻塞方案为:先计算出两路参考信号  $y_{r1}(k)$  和  $y_{r2}(k)$  的均方根值;然后根据  $y_{r1}(k)$  的均方根值调整  $y_{r2}(k)$  的均方根值,使两路参考信号的幅度大致相同;而后对调整幅度后的参考信号  $\tilde{y}_{r2}(k)$  进行延时对齐;最后通过  $y_{r1}(k)$  减去对齐后的参考信号  $\tilde{y}_{r2}(k + \tau)$ , 得到相减后的信号。在上述阻塞过程中,设置一定的延时范围,即  $\tau \in [2, 100]$ , 通过在该范围内寻找相减后信号 SINR 最低的那组延时,此时,相减后的信号即为阻塞输出  $y_b(k)$ 。

为提高网络训练的稳定性,编码层和去编码层均采用步长卷积,而不引入池化层,其激活函数均采用整流线性函数。在编码层中,设置提取的特征数据长度不断减小,为了避免网络因提取的特征不够而导致模型不收敛,设置网络的深度随网络层数的增加而呈增加趋势。经过编码层后,将该层的输出与额外引入的噪声样本  $z$  在输出通道的维度上进行连接,构成去编码层的输入,去编码层的结构其实是倒序的编码层结构,这意味着去编码层的特征数据长度不断增加,而输出通道

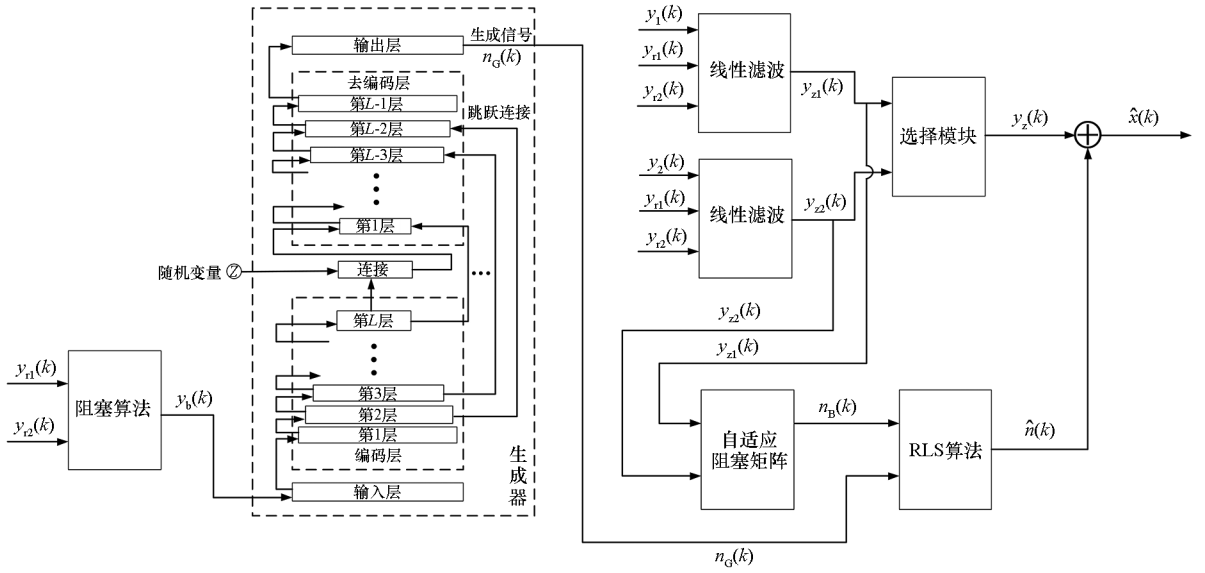


图 2 生成式旁瓣抵消算法原理框图

Fig. 2 Schematic diagram of the proposed GSCA

数不断减小。此外,在编码层和去编码层之间引入跳跃连接,不仅可以使生成模型提取较多的信号特征,还能有效地解决生成模型存在的梯度消失问题。

判别器采用的网络结构为传统的卷积分类网络,主要用于辨别输入样本的数据来源。针对判别器而言,重点对其卷积网络的层数和每层网络的深度进行优化设计,而采用的网络模型与SEGAN模型类似,具体的判别器卷积网络结构参考文献[9]。IGM下生成器和判别器的交替迭代优化过程如图3所示。在优化判别器网络参数时,固定生成器模型,尽量提高判别器的准确率;而在优化生成器网络参数时,固定判别器模型,尽量降低判别器的准确率。为了实现稳定的网络训练和提高生成模型的样本质量,在IGM生成器的代价函数中引入用于衡量生成样本与真实样本之间距离关系的L1正则化准则,通过此方法引导生成器和判别器的优化方向。IGM采用的代价函数<sup>[10]</sup>可表示为:

$$\begin{cases} \min_G V_{\text{IGM}}(G) = \frac{1}{2} E_{z \sim p_z(z), y_b \sim p_{\text{data}}(y_b)} \{ |D(G(z, y_b), y_b) - 1|^2 + \lambda \|G(z, y_b) - y_1\|_1 \\ \min_D V_{\text{IGM}}(D) = \frac{1}{2} E_{y_1, y_b \sim p_{\text{data}}(y_1, y_b)} \{ |D(y_1, y_b) - 1|^2 + \\ \frac{1}{2} E_{z \sim p_z(z), y_b \sim p_{\text{data}}(y_b)} \{ |D(G(z, y_b), y_b) - 1|^2 \end{cases} \quad (3)$$

其中,G表示生成器,D表示判别器,E表示期望

运算符, $\lambda$ 表示正规化参数。

一般而言,滤波器的尺寸越大,网络的深度越深,网络能提取到的信号特征也就越丰富。然而,考虑到以下两个方面的原因:一方面,超低频信号的样本形式过于简单,相比于语音信号而言,学习起来相对较容易;另一方面,为了生成与主通道干扰分量相关性更强的参考干扰,IGM采用的真实样本(被判别器标记为1)为主天线 $C_m$ 接收到的信号 $y_1(k)$ ,这意味着真实样本中包含期望信号,而该信号是不希望被网络学习到的。一旦上述参数设置过大,很可能会导致网络出现过拟合现象,即学习到真实样本中的期望信号,导致IGM生成的样本中包含期望信号,达不到预期的干扰抑制效果。因此,主要对生成模型的过滤器尺寸、卷积网络的层数以及每层网络的深度进行优化设计。采用的优化原则是在保证信号带宽内具有较优SINR的前提下,尽量降低生成器的运算复杂度。网络的运算复杂度包含时间复杂度和空间复杂度,其可分别表示为:

$$\begin{cases} \text{Time} \propto o\left(\sum_{l=1}^D L_l K_l C_{l-1} C_l\right) \\ \text{Space} \propto o\left(\sum_{l=1}^D K_l C_{l-1} C_l\right) \end{cases} \quad (4)$$

其中: $l$ 表示网络的层数索引, $D$ 表示生成器的网络层数, $L$ 表示网络提取的特征数据长度, $K$ 表示滤波器的尺寸, $C_{l-1}$ 和 $C_l$ 表示第 $l$ 层网络的输入和输出通道数量。

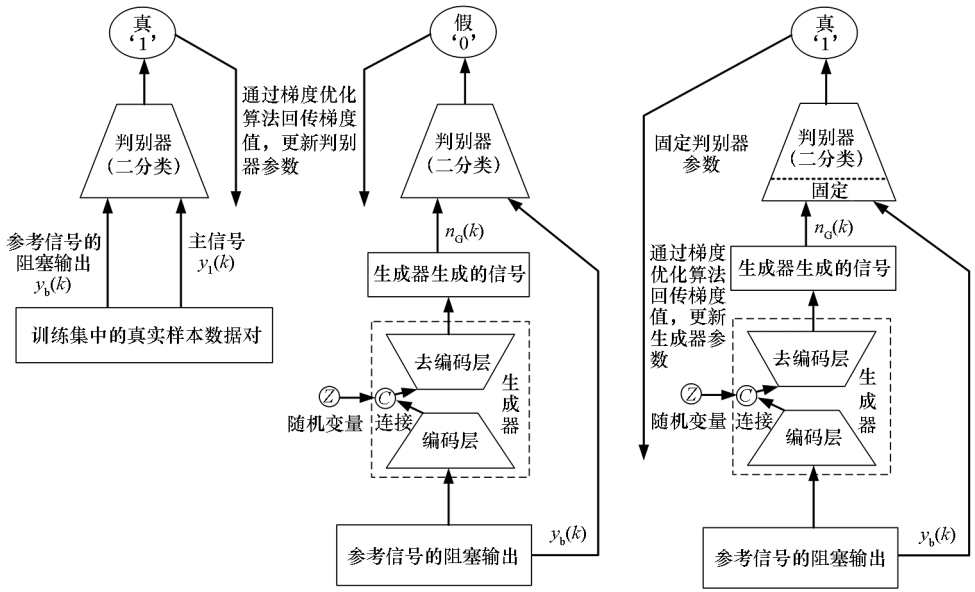


图 3 生成器和判别器优化训练示意图

Fig. 3 Schematic diagram of the optimized training about generator and discriminator

### 3 实验结果与分析

#### 3.1 生成模型的优化结果

为了验证 IGM 的有效性,在实验室环境下搭建数据采集平台,分别获取生成模型的训练集和测试集。该采集平台主要由第 1 节提出的磁性天线接收阵列、各类信号发生器、发射线圈 1、发射线圈 2、绕线用的电机(用于提供随机强干扰)、以太网箱 NI 9184 和数据采集卡 NI 9239 组成的数据采集单元以及计算机组成。信号发生器 TDK AFG3021 产生频率为 130 Hz、幅度为 10 mV 的信号并送至发射线圈 1,以此作为期望信号;函数发生器 DG1022U 产生幅度为 5V 的宽带高斯白噪声并送至信号发生器 GFG-8016G,进行随机相位调制,将调制后的信号送至发射线圈 2,以此人工宽频调相强干扰作为强干扰 1;将电机置于接收阵列的下方,通过调节电机的转速,使其辐射出的随机强干扰位于信号带宽范围内,以此电机辐射出的随机干扰作为强干扰 2。将发射线圈 1、发射线圈 2 和电机均放置在接收阵列的 45° 方向,分别距离接收阵列 3.5 m、1.5 m 和 0.5 m。数据采集卡 NI 9239 的采样频率设置为 5 kHz,采集时间为每组数据 30 s,共采集 1000 组数据,以此组数据作为 IGM 的训练集。为了避免引入工频干扰以及谐波分量,数据采集单元和模拟电路板均采用 ±6 V 的蓄电池供电。

为确保 IGM 具有较好的鲁棒性,测试集和训练集严格分开,测试集的数据采集过程为:保持电

机的位置和发射线圈 1 的位置不变,在以接收阵列中心为圆心、以 1.5 m 为半径的圆周上调整发射线圈 2 与接收阵列的角度  $\theta$ ,使其分别为 15°、30°、45°、60°、75°,通过此方式获取不同角度下的随机调相宽频干扰。每个角度下分别采集 10 组数据,共 50 组数据。其他实验设置均与训练数据采集过程中的设置相同。

该生成模型的训练平台采用 ubuntu16.04 系统中的 Tensorflow,处理器为 Intel Core i7-6700,显卡为 GeForce GTX 1050Ti,运行内存为 8 GB。鉴于上述计算机性能有限,无法实现对数据块参数的优化,故将该参数设置为计算机能实现的最大值 30。生成模型在训练优化过程中的学习率设为 0.000 2,优化算法采用 RMSprop 梯度下降算法,式(3)中的超参数  $\lambda$  设为 40。基于在实现较好干扰抑制效果的同时降低 IGM 运算复杂度的原则,通过控制变量法分别对 IGM 的训练次数、过滤器的尺寸、网络层数、每层网络的深度以及跳跃连接的方式进行优化,IGM 网络结构的优化结果见表 1。表 1 中的字母 'B' 表示随机调相宽频干扰, 'M' 表示电机辐射的随机干扰, G22 表示生成器网络层数为 22,每层编码层深度为 {16, 32, 32, 64, 64, 128, 128, 256, 256, 512, 1024}, G20 和 G18 对应的每层编码层深度分别为 {16, 32, 32, 64, 64, 128, 128, 256, 256, 512} 和 {16, 32, 32, 64, 64, 128, 128, 256, 512}, D11 表示判别器的卷积层数为 11,其深度为 {16, 32, 32, 64, 64, 128, 128, 256, 256, 512, 1024}, D10 和 D9 对应的卷积层深度分别为 {16, 32, 32, 64, 64, 128, 128, 256,

256,512} 和 {16, 32, 32, 64, 64, 128, 128, 256, 512}。G22(1)、G22(2)、G22(3)、G22(4)、G22(5)和 G22(6)对应的每层编码层深度分别为 {16, 32, 32, 64, 64, 128, 128, 256, 256, 256, 512}, {16, 32, 32, 64, 64, 128, 128, 128, 256, 256, 512}, {16, 32, 32, 64, 64, 64, 128, 128, 128, 256, 256}, {16, 32, 32, 32, 64, 64, 64, 128, 128, 256, 512}, {16, 32, 32, 64, 64, 64, 128, 128, 256, 256, 512}, {16, 32, 32, 64, 64, 64, 128, 128, 256, 256, 256}。跳跃连接方式中的数字代表生成器中包含的跳跃连接数,以编码层的第 1 层为 0 算起,4 表示在编码层的第 1、2、3、4 层与去编码层的第 8、7、6、5 层之间增加跳跃连接,5 表示在编码层的第 1、2、3、

4、5 层与去编码层的第 8、7、6、5、4 层之间增加跳跃连接,其他数字代表的连接方式与上述表示方式的原理一致。

由表 1 可知,在数据样本较多的情况下,较多的训练次数并不会提升 IGM 的生成能力,IGM 的训练次数选定为 30。优化后的生成器由 21 层步长为 2 的卷积层和 1 层输出层构成,过滤器的尺寸为  $9 \times 1$ ,其中包含 11 层编码层、10 层去编码层和 1 层输出层。对于一个样本数据而言,输入层和 11 层编码层可分别表示为特征数据长度  $\times$  过滤器的数量,即  $16\ 384 \times 1, 8192 \times 16, 4096 \times 32, 2048 \times 32, 1024 \times 64, 512 \times 64, 256 \times 64, 128 \times 128, 64 \times 128, 32 \times 256, 16 \times 256, 8 \times 512$ 。噪声样

表 1 IGM 网络结构优化结果汇总表

Tab. 1 Summary table of the optimized results about the network structure of IGM

IGM 网络结构	测试集上的 SINR 增益/dB					G 的运算复杂度( $\times 10^9$ )		
	15°'B'和 45°'M'	30°'B'和 45°'M'	45°'B'和 45°'M'	60°'B'和 45°'M'	75°'B'和 45°'M'	时间	空间	
	生成器 过滤器的 尺寸	5 $\times$ 1	20.93	19.00	17.00	15.63	18.60	31.24
	7 $\times$ 1	20.90	17.54	18.83	16.55	16.22	43.73	0.83
	9 $\times$ 1	20.88	17.93	20.93	16.65	19.42	56.23	1.06
	11 $\times$ 1	20.80	17.96	21.09	16.43	18.87	68.73	1.30
生成器的 网络 层数和 判别器 的网络 层数	G22 - D11	20.96	17.96	19.91	16.89	18.39	56.23	1.06
	G22 - D10	21.06	18.98	21.34	17.67	19.12	56.23	1.06
	G20 - D12	20.79	16.52	18.53	16.50	18.50	46.04	0.35
	G20 - D11	20.45	18.63	18.40	16.48	17.21	46.04	0.35
	G20 - D10	19.72	16.94	18.26	16.31	19.81	46.04	0.35
	G18 - D12	21.09	17.55	17.11	15.10	17.76	46.04	0.26
	G18 - D11	20.65	17.40	17.64	15.31	17.76	46.04	0.26
	G18 - D10	20.67	17.72	16.07	15.54	15.63	46.04	0.26
生成器 每层 网络的 深度	G22(1)	21.00	19.29	20.07	15.92	18.55	46.04	0.44
	G22(2)	20.96	17.53	20.06	16.95	18.14	39.67	0.29
	G22(3)	20.54	19.41	19.48	16.43	17.53	32.03	0.20
	G22(4)	20.31	15.85	21.56	15.41	16.70	23.11	0.12
	G22(5)	21.06	18.98	21.34	17.67	19.12	35.85	0.36
	G22(6)	20.30	19.01	19.25	16.26	18.58	34.58	0.27
生成器的 跳跃 连接 方式	4	21.47	17.05	12.10	15.74	16.71	24.45	0.18
	5	20.04	14.97	18.50	17.53	19.65	26.15	0.19
	6	20.20	18.02	19.25	15.83	18.22	27.85	0.20
	<b>7</b>	<b>21.18</b>	<b>19.75</b>	<b>22.11</b>	<b>17.74</b>	<b>19.87</b>	29.55	0.22
	8	20.38	18.62	21.35	16.95	18.29	31.25	0.25

本  $z$  服从维度为  $8 \times 512$  的正态分布。此外,跳跃连接的数量设置为 7,分别在编码层的第 1、2、3、4、5、6、7 层与去编码层的第 8、7、6、5、4、3、2 层之间增加跳跃连接。同编码层的表示方法相同,10 层去编码层和输出层可分别表示为  $16 \times 256$ ,  $32 \times 512$ ,  $64 \times 256$ ,  $128 \times 256$ ,  $256 \times 128$ ,  $512 \times 128$ ,  $1024 \times 128$ ,  $2048 \times 64$ ,  $4096 \times 64$ ,  $8192 \times 16$ ,  $16384 \times 1$ 。优化后的判别器由 10 层步长为 2 的卷积层构成,过滤器的尺寸为  $31 \times 1$ ,其中包含 9 层卷积层和 1 层全连接层。同生成器编码层的表示方式相同,判别器的输入层和卷积层可分别表示为  $16384 \times 2$ ,  $8192 \times 16$ ,  $4096 \times 32$ ,  $2048 \times 32$ ,  $1024 \times 64$ ,  $512 \times 64$ ,  $256 \times 128$ ,  $128 \times 128$ ,  $64 \times 256$ ,  $32 \times 512$ 。

### 3.2 双干扰抑制结果

鉴于文章篇幅有限,在此仅呈现 GSCA 对测试集中干扰抑制效果最好的那组实验结果,测试集中其他方向干扰抑制结果见表 1 中加粗的那一行。图 4 呈现的三幅子图分别表示主天线接收到的信号  $y_1(k)$ 、参考信号阻塞输出  $y_b(k)$  和 IGM 生成信号  $n_c(k)$  的功率谱。图 5 呈现的三幅子图分别表示原始 GSC 算法、文献[6]中传统改进 GSC 算法和 GSCA 对实验室环境下双干扰的抑制结果。

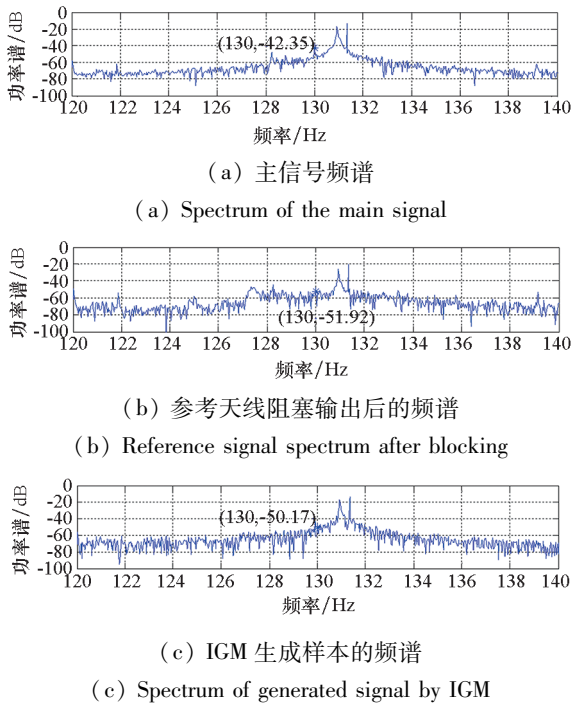


图 4 IGM 相关信号频谱

Fig. 4 Power spectrum of the relative signals in IGM

由图 4 可知,虽然 IGM 中的真实样本含有期望信号分量,但由表 1 优化后的生成模型 IGM 只

学习到了输入数据的主要特征,并未学习到真实样本中的期望信号分量,这在一定程度上证明了上述网络优化方法的有效性。

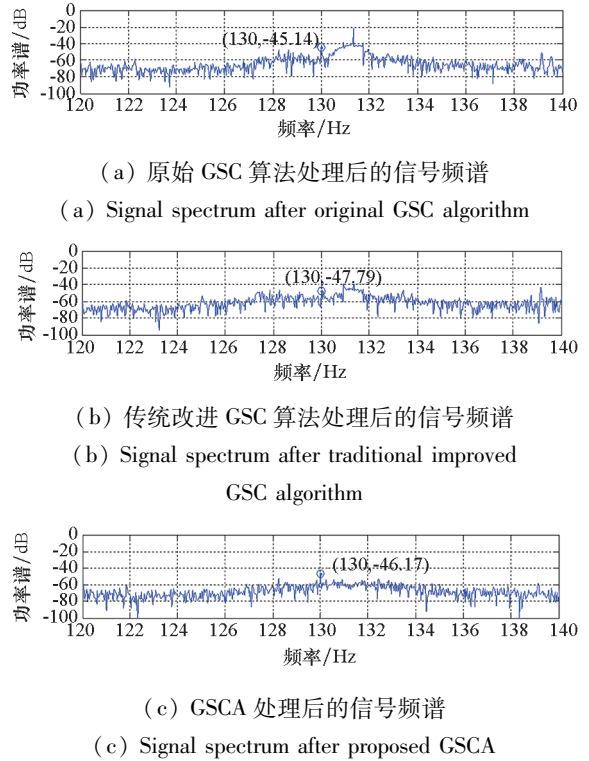


图 5 不同算法的抑制结果

Fig. 5 Suppressed results of various algorithms

由图 5 可知,当双干扰均位于接收阵列的  $45^\circ$  方向时,相比于传统的改进算法,本文所提的 GSCA 进一步提升了算法对干扰的抑制能力, SINR 增益约为 10 dB。其原因主要是传统的改进算法送入后级 RLS 算法中的信号包含 1 路参考天线接收到的信号,该信号包含较多的期望信号分量,这会在一定程度上降低算法的性能;并且该信号中包含的干扰信息在进行主信号增强时已被利用,后级 RLS 算法很难再从该信号中获取到其他有用的干扰参考信息。而 GSCA 通过 IGM 生成的样本成功地为后级 RLS 算法提供了额外的干扰参考信息,且由前面的理论分析可知,IGM 直接学习的是主通道中的信号,由 IGM 生成的样本中不包含期望信号分量,因此,IGM 生成的样本与主通道中的干扰分量相关性更强,这提高了算法对主通道中干扰分量估计的准确性,从而进一步改善了算法的性能。当人工调相宽频干扰位于其他方向时,相比于传统的改进算法,GSCA 也实现了较好的干扰抑制效果, SINR 增益至少为 2 dB。该 SINR 增益不如宽频干扰位于  $45^\circ$  方向时的增益,其原因主要有两个方面:一方面,IGM 采用的训练集是双干扰均位于接收阵列的  $45^\circ$  方



向的数据,其他方向干扰与  $45^\circ$  方向干扰是存在一定差异性的,IGM 捕捉其他方向干扰的能力相对较弱;另一方面,对于其他方向的干扰而言,参考天线与主天线接收到的干扰分量差异性较大,而传统的改进算法能够利用这部分差异为后级 RLS 算法提供部分干扰参考信息,从而在一定程度上提升了传统改进算法的干扰抑制能力。

## 4 结论

本文从进一步改善超低频通信质量的角度出发,将人工智能领域研究热点之一的 GANs 引入超低频干扰抑制领域,基于在实现较好干扰抑制效果的同时降低生成模型运算复杂度的原则,对生成模型的输入样本和网络结构进行优化设计,使生成模型生成与主通道干扰分量相关性更强的参考干扰,结合传统的 GSC 改进方案,提出了 GSCA,实现了较好的干扰抑制效果。通过实验室环境下采集的测试集验证了优化后生成模型对双干扰抑制的有效性;通过与 GSC 算法及其传统改进算法进行比较发现,本文所提算法不仅进一步提高了算法对不同类别干扰的抑制能力,同时也为解决超低频通信领域的干扰抑制问题提供了一种新的思路。

## 参考文献 (References)

[1] Ying W W, Jiang Y Z, Liu Y L, et al. A blind receiver with multiple antennas in impulsive noise modeled as the sub-Gaussian distribution via the MCMC algorithm [J]. IEEE Transactions on Vehicular Technology, 2013, 62 (7): 3492 - 3497.

[2] Ferrara E, Widrow B. Multichannel adaptive filtering for signal enhancement [J]. IEEE Transactions on Circuits and Systems, 1981, 28(6): 606 - 610.

[3] Doclo S, Moonen M. Multimicrophone noise reduction using recursive GSVD-based optimal filtering with ANC postprocessing stage [J]. IEEE Transactions on Speech and Audio Processing, 2005, 13(1): 53 - 69.

[4] 张兰勇, 王帮民, 刘胜, 等. 一种新的变步长自适应噪声消除算法 [J]. 电子学报, 2017, 45(2): 321 - 327.  
ZHANG Lanyong, WANG Bangmin, LIU Sheng, et al. A novel variable step-size adaptive interference cancellation algorithm [J]. Acta Electronica Sinica, 2017, 45(2): 321 - 327. (in Chinese)

[5] Griffiths L J, Jim C W. An alternative approach to linearly constrained adaptive beamforming [J]. IEEE Transactions on Antennas and Propagation, 1982, 30(1): 27 - 34.

[6] 李春腾, 蒋宇中, 刘芳君, 等. 感应式磁性天线设计及干扰抑制算法研究 [J]. 国防科技大学学报, 2019, 41(5): 147 - 152, 158.  
LI Chunteng, JIANG Yuzhong, LIU Fangjun, et al. Design of search coil magnetic antenna and research on interference suppression algorithm [J]. Journal of National University of Defense Technology, 2019, 41(5): 147 - 152, 158. (in Chinese)

[7] Benesty J, Paleologu C, Ciochina S. Regularization of the RLS algorithm [J]. IEICE Transactions on Fundamentals of Electronics Communications and Computer Sciences, 2011, E94 - A(8): 1628 - 1629.

[8] Goodfellow I, Jean P, Mehdi M, et al. Generative adversarial nets [EB/OL]. (2014 - 06 - 10) [2019 - 01 - 10]. <https://arxiv.org/pdf/1406.2661v1.pdf>.

[9] Santiago P, Antonio B, Joan S. SEGAN: speech enhancement generative adversarial network [EB/OL]. (2017 - 06 - 09) [2019 - 01 - 10]. <https://arxiv.org/pdf/1703.09452v3.pdf>.

[10] Mao X, Li Q, Xie H, et al. Least squares generative adversarial networks [EB/OL]. (2017 - 04 - 05) [2019 - 01 - 10]. <https://arxiv.org/pdf/1611.04076.pdf>.