

基于循环生成对抗网络的增强罗兰信号生成^{*}

李 辉 胡登峰 张 恺 邹波蓉 刘 薇

(河南理工大学物理与电子信息学院 焦作 454000)

摘 要: 在信号生成算法中,需要大量标记信号样本用于网络训练,但通常携带电文信息标记的信号难以批量获取。针对此问题本文提出一种基于循环生成对抗网络和迁移学习的方法,实现了无需大量信号及对应电文作为标记的增强罗兰信号生成,并使用迁移学习在少量实测信号情况下快速生成。循环生成对抗网络的结构包括两个生成器和两个判别器,利用无需一一对应的增强罗兰信号和电文数据集,使生成器学习到两个数据集之间的相互转换关系,实现输入电文数据可以生成与之相对应的增强罗兰信号,并且针对增强罗兰信号的特性,使用一维卷积、残差网络、自注意力机制对网络模型进行改进。实验证实,生成信号与实测数据的均方误差为 0.015 3,平均皮尔逊相关系数为 0.984 3,且所含电文信息准确率为 99.02%。本文在 PSK、ASK、FSK 数据集上验证了算法,实验结果表明生成的信号满足预期,为未知参数的信号调制和解调提供一种新的思路。

关键词: 信号生成;循环生成对抗网络;迁移学习;增强罗兰信号

中图分类号: TN911.7 **文献标识码:** A **国家标准学科分类代码:** 510.40

Enhanced LORAN signals generating based on cycle-consistent adversarial networks

Li Hui Hu Dengfeng Zhang Kai Zou Borong Liu Wei

(School of Physics and Electronic Information Engineering, Henan Polytechnic University, Jiaozuo 454000, China)

Abstract: In signal generation algorithms, a large number of labeled signal samples are needed for network training, but it is usually difficult to obtain signals carrying message information markers in bulk. To address this problem, this paper proposes a method based on CycleGAN and transfer learning, which realizes the generation of Enhanced LORAN signals without the need for a large number of signals and the corresponding messages as markers and uses migration learning to generate them quickly with a small number of measured signals. The structure of the CycleGAN includes two generators and two discriminators, using the Enhanced LORAN signals and message data sets that do not need to be one-to-one correspondence, so that the generator learns the interconversion relationship between the two data sets, and realises that the input message data can generate the Enhanced LORAN signals corresponding to it, for the characteristics of the Enhanced LORAN signal, the network model is improved using a one-dimensional convolution, residual network, and self-attention mechanism. Experimentally confirmed, it is confirmed that the mean square error of the signal generated by this paper with the measured data is 0.015 3, the average Pearson correlation coefficient is 0.984 3, and the accuracy of the contained message information is 99.02%. To verify the universality of the algorithm, this paper validates the algorithm on PSK, ASK, and FSK datasets, and the experimental results show that the generated signals satisfy the expectations and provide a new idea for signal modulation and demodulation with unknown parameters.

Keywords: signal generation; CycleGAN; transfer learning; enhanced LORAN signal

0 引 言

罗兰(long range navigation, LORAN)系统是一种远

程双曲线导航定位系统,由美国海军于上世纪 50 年代研发,于 1958 年开始提供服务^[1]。而增强型罗兰(enhanced loran, eLoran)增加了 Eurofix 数据链技术以实现增强数据

信息发播,具有作用距离远、稳定性好、抗干扰能力强等优势,因此 eLoran 系统在航海、航空、军事安全等领域具有重要的应用价值。

在导航安全方面,由于全球导航卫星系统(global navigation satellite system, GNSS)相对脆弱容易受到干扰,eLoran 信号作为针对 GNSS 干扰的防御手段,可以减轻对 GNSS 的依赖。2014 年 4 月 2 日,俄罗斯的格洛纳斯导航系统发生严重故障,韩国的全球卫星定位系统信号的商业和军用频段也遭到多次蓄意攻击^[2]。对于我国而言,在“十三五”规划中也指出了未来 eLoran 系统作为国家授时系统陆基备份建设的方向^[3]。上述事实说明仅使用 GNSS 作为导航系统具有风险,eLoran 系统作为完全独立于 GNSS 的陆基无线电导航系统,在 GNSS 不稳定等情况下,eLoran 系统可以代替 GNSS 继续导航。在军事和灾害应急等 GNSS 无法正常制导的演习中,可以使用生成 eLoran 信号进行模拟。另一方面 eLoran 的识别算法也需要大量的实际测量信号进行训练,然而不同时间、地点、天气情况下大量的数据采集也成为了一个难题。因此 eLoran 信号快速生成也成为了具有重要意义的课题,生成的信号可以在模拟训练、数据扩充等方面进行使用。

随着深度学习的发展,近几年生成对抗网络^[4](generative adversarial networks, GAN)在信号领域的使用也较为广泛,尤其是在信号的重构、增强等方面得到了广泛的应用。在医学信号领域中 Rayavarapu 等^[5]和 Kaleli 等^[6]都尝试利用生成对抗网络生成了异常的心电数据。钱尧佳^[7]使用深度卷积生成对抗网络(deep convolutional generative adversarial networks, DCGAN)实现了高质量的表面肌电信号。但是使用传统的 GAN 无法实现分类生成。因此 Wu 等^[8]则使用多标签条件生成对抗网络生成了多类心电信号。Jayalakshmy 等^[9]使用条件生成对抗网络(conditional generative adversarial networks, CGAN)对呼吸信号增强进行了实验,使用监督学习用于扩充数据集。Ye 等^[10]针对生成不稳定、质量低的情况提出了一种改进的序列生成对抗网络(sequence generative adversarial networks, SeqGAN),该方法采用了强化学习中的梯度政策,生成了高质量的心电信号。

在通信信号方面, Oyamada 等^[11]提出了一种基于 GAN 的幅度谱信号重构方法,解决了仅从幅度谱图重建时域信号的问题。Truong 等^[12]提出了一种用于雷达信号生成的 GAN 的设计,但是网络仅使用了卷积层对复杂信号难以适用。Shi 等^[13]提出了一种无线信号欺骗的深度对抗性学习,生成了无法在统计上与样本信号区分的合成无线信号。赵凡等^[14]利用时域波形直接作为训练集对 GAN 进行训练,生成了目标信号具有相似时域特性和频域特性的干扰波形。秦剑^[15]使用了深度卷积生成对抗网络对复杂电磁环境中的信号进行了重构,并从多方面分析了生成信号的准确性。杨鸿杰等^[16]针对数字采样信号的特点,设计

并搭建了边界平衡生成对抗网络(boundary equilibrium generative adversarial networks, BEGAN)信号生成模型,并选用了常用的 2 进制相移键控信号与 8 进制相移键控信号进行了信号生成仿真试验。在此基础上薛丽莎^[17]使用自注意力机制对 BEGAN 进行改进,用来生成更加细腻的通信信号。面对未知参数的信号难以重构等问题,冯奇^[18]设计了针对帧结构以及直接序列扩频(direct sequence spread spectrum, DSSS)信号的自注意力生成对抗网络(self-attention generative adversarial networks, SAGAN)重构模型。为了生成多类别的信号,使用条件生成对抗网络在生成器和判别器中加入条件信息,将标签与噪声向量拼接作为生成器输入,使得生成器可以根据标签信息生成特定类别的信号。Saarinen 等^[19]使用 CGAN 合成了多输入多输出(multiple input multiple output, MIMO)雷达波形。陈昌美^[20]构建 CGAN 与辅助分类器生成对抗网络(auxiliary classifier generative adversarial networks, ACGAN)两种网络模型进行模拟调制通信信号的生成。Tang 等^[21]使用 CGAN 实现了对无线通信信号的降噪。Tang 等^[22]使用 ACGAN 来实现数据增强,在扩增数据集的同时缓解传统 GAN 存在的过拟合等问题。

现有基于 GAN、DCGAN、SAGAN、BEGAN 等信号生成算法大多只局限于生成一类通信信号,在 GAN 的基础上通过网络、模型的改进提高模型的稳定性和生成效果,然而在生成中忽略了通信信号的中存在的电文信息。为了生成出含有特定电文信息的信号,较好的办法是使用有监督的生成对抗网络,例如 CGAN、ACGAN 等算法,可以将电文信息标记作为额外的输入,以实现生成指定电文的信号。但是也面临着需要大量电文标记的信号的问题,在现实中难以使用。针对这些问题本文提出了一种循环生成对抗网络^[23](cycle-consistent adversarial networks, CycleGAN)的信号生成方法,循环生成对抗网络在图像领域已经广泛使用,易星等^[24]使用该方法实现红外图像的生成,王媛彬等^[25]使用改进 CycleGAN 实现低照度图像的增强,刘致远等^[26]也使用自注意力机制改进 CycleGAN 实现了图像的去雾。但是在—维通信信号领域少有涉及,如董骏捷等^[27]使用 CycleGAN 实现了一维信号的去噪。本文改进后的 CycleGAN 能够学习 eLoran 信号和电文之间的映射关系,使两者互相转换,并且保持转换后的电文准确率。实现了在无需配对 eLoran 信号和电文信息情况下,通过循环生成对抗网络来实现模拟 eLoran 信号的生成。由于实际中的 eLoran 信号都存在环境干扰、传播时延、信号抖动等,使用实测信号重新训练模型需要大量的数据和较长时间的训练,所以本文在 CycleGAN 中引入了迁移学习。在使用模拟信号的预训练 CycleGAN 模型下对少量实测 eLoran 信号进行训练,可以快速生成与实测信号相似的包含特定电文的信号。

1 eLoran 信号传播模型

eLoran 信号的工作频率为 90~110 kHz,其中每个脉冲信号都是由 100 kHz 载波信号调制的钟形脉冲。eLoran 系统的发射台分为主台和副台,每个副台发射 8 个脉冲为一组的脉冲信号,主台在副台的基础上增发第 9 个脉冲信号。使用“三态脉冲位移平衡调制”的调制方式,该调制方式是对信号每个脉冲组周期从第 3 个脉冲到第 8 个脉冲进行时延上的移位调制,对于每个 eLoran 脉冲都进行超前 1 μs 或者滞后 1 μs 的移位调制。脉冲组的相位编码是固定的,第一个脉冲组重复周期称为 GRI-A,第二个脉冲组重复周期称为 GRI-B。

实际接收的 eLoran 信号往往是复杂环境的,eLoran 信号在大气中传播会受到各种噪声和其他无线电信号的影响。eLoran 接收系统接收到的信号包括地波信号、天波信号以及频带内外的噪声和干扰。

eLoran 信号传播示意图如图 1,图中 S 为信号源,eLoran 信号经过电离层反射到接收系统的信号为天波信号 X_s ,沿地面传播到达接收系统的信号为地波信号 X_g ,图中 e 表示信号传输路径上的噪声干扰,信号接收系统接收到三者的叠加信号 X_c 。




图 1 eLoran 信号传播示意图

X_c 可使用如下模型表示:

$$x_c(t) = x_g(t - \tau_g) + \sum_{n=1}^N x_s(t - \tau_n) + e(t) \quad (1)$$

$x_c(t)$ 为接收信号; $x_g(t)$ 为地波信号; $x_s(t)$ 为天波信号; τ_g 是地波信号相对于发射信号的时间延迟; τ_n 是 n 次天波信号相对于发射信号的时间延迟; $e(t)$ 为噪声和干扰。

2 增强罗兰信号生成算法

2.1 CycleGAN

CycleGAN 是一种基于生成对抗网络的图像风格转换算法,它能够学习两个领域之间的图像映射,与传统图像风格转换的方法不同,CycleGAN 不需要成对的训练数据。它利用了两个生成器模型和两个判别器模型实现了两个领域之间的自然映射和逆映射的训练。

2.2 CycleGAN 模型

对于增强罗兰信号的生成,将 eLoran 信号和电文信息作为两个数据集。生成器(eLoran-电文)负责将 eLoran 信号转换为电文,生成器(电文-eLoran)负责将电文转换回 eLoran 信号。两个判别器分别用于判别生成器生成电文、eLoran 信号的真假。首先将 eLoran 数据集输入生成器(eLoran-电文)中以生成电文(fake),使用判别器(电文)判断生成的电文(fake)与电文数据集是否相似,同时将电文(fake)输入到生成器(电文-eLoran)生成 eLoran(cycle)。由于 CycleGAN 是双向的,对应的另一部分同理,模型结构如图 2 所示。




图 2 eLoran 信号生成的 CycleGAN 模型

CycleGAN 的损失包含 3 个部分,设 eLoran 数据集为 Dataset A,电文数据集为 Dataset B。

对抗性损失(Adversarial loss):通过训练判别器模型和生成器模型,使生成器网络能够生成更加逼真的数据。

$$L_{GAN-A}(G_{A \rightarrow B}, D_B, A, B) = E_{B \sim P_{data(B)}} [\lg D_B(B)] + E_{A \sim P_{data(A)}} [\lg(1 - D_B(G_{A \rightarrow B}(A)))] \quad (2)$$

$$L_{GAN-B}(G_{B \rightarrow A}, D_A, B, A) = E_{A \sim P_{data(A)}} [\lg D_A(A)] + E_{B \sim P_{data(B)}} [\lg(1 - D_A(G_{B \rightarrow A}(B)))] \quad (3)$$

$$L_{GAN} = L_{GAN-A}(G_{A \rightarrow B}, D_B, A, B) + L_{GAN-B}(G_{B \rightarrow A}, D_A, B, A) \quad (4)$$

循环一致性损失(cycle-consistency loss):为了保证转

换的双向性和一致性,该损失通过在 eLoran 和电文之间进行双向转换,并将样本数据与重构的数据之间的差异最小化,来约束生成器网络。

$$L_{cycle}(G_{A \rightarrow B}, G_{B \rightarrow A}) = E_{A \sim P_{data(A)}} [\|G_{B \rightarrow A}(G_{A \rightarrow B}(A)) - A\|] + E_{B \sim P_{data(B)}} [\|G_{A \rightarrow B}(G_{B \rightarrow A}(B)) - B\|] \quad (5)$$

身份损失(Identity loss):在 CycleGAN 中,身份损失是一个可选的损失。该损失通过比较生成器输入和输出之间的差异来约束生成器网络,防止生成的数据过于远离样本数据集。

$$L_{Identity}(G_{A \rightarrow B}, G_{B \rightarrow A}) = E_{A \sim P_{data(A)}} [\|G_{B \rightarrow A}(A) - A\|] + E_{B \sim P_{data(B)}} [\|G_{A \rightarrow B}(B) - B\|] \quad (6)$$

生成器的总的损失函数可以表示为:

$$L_{total} = L_{GAN} + \lambda_{cyc} \times L_{cycle}(G_{A \rightarrow B}, G_{B \rightarrow A}) + \lambda_{identity} \times L_{identity}(G_{A \rightarrow B}, G_{B \rightarrow A}) \quad (7)$$

其中, λ_{cyc} 和 λ_{id} 是超参数, 用于调节循环一致性损失和身份损失的相对权重。

1) 生成器网络

在 CycleGAN 中往往会因为生成器网络的不合理, 导致梯度爆炸、训练不收敛、无法实现对应转换等问题。在 eLoran 信号的生成中, 过于简单的网络结构会使模型难以准确学习到信号的特征, 而过于复杂的模型存在训练困




图 3 生成器网络模型图

采用了一维卷积神经网络代替传统的二维卷积神经, 只在一个维度上滑动窗口进行卷积, 它可以对输入 eLoran 信号进行局部特征提取, 从而更好地捕获信号的序列相关性, 因此在长序列数据中被广泛使用。

为了提高生成器的训练效率和泛化性能, 使得模型更加易收敛。本文在网络中添加了残差网络, 加强深度神经网络的表达能力, 残差网络的引入使模型可以直接学习输入输出之间的差异, 从而减轻梯度消失和梯度爆炸等问题, 残差块网络如图 4 所示。




图 4 残差块

由于卷积在时间序列中捕获长距离交互能力比较差, 在感受野大时缩放特性弱。本文引入了自注意力机制, 自注意力机制在处理时间序列中的作用是提取和处理时序数据中的关键特征, 对于长序列的 eLoran 信号, 具有很强的特征提取能力和准确性, 自注意力机制如图 5 所示。

激活函数采用 LeakyReLU 代替传统的 ReLU, 可以避免神经元死亡问题、改进模型的泛化能力、加速训练。

2) 判别器网络

在 CycleGAN 中, 一般将生成器设计得更加复杂, 因为生成器负责进行数据的生成, 所以需要捕获更多的特征来实现这一目标。相比之下, 判别器的任务相对简单, 只需要在输入数据与真实数据之间进行区分, 并判断生成器生成的数据是否足够真实即可。因此, 本文只使用了传统

难、易过拟合、计算资源消耗过多等问题。为了解决这些问题, 本文对生成器网络进行了以下改进。

在生成器网络中为了减少内存的占用和加速训练, 首先把形状为 (batchsize, 16 000) 的数据重塑成为 (batchsize, 16, 1 000) 三维张量作为输入。生成器网络中含有 4 个一维卷积层 (卷积核为 3, 卷积步长为 1, 填充数量为 1, 激活函数为 LeakyReLU); 一个残差块 (特征维数为 128); 一个自注意层 (特征维数为 128); 三个全连接层 (前两个线性层激活函数为 LeakyReLU, 并添加 Dropout 层, 最后一个线性层激活函数为 Tanh)。生成器网络结构如图 3 所示。




图 5 自注意力机制

的卷积层和全连接层设计该判别器。判别器网络包括: 四个一维卷积层 (卷积核为 3, 卷积步长为 1, 填充数量为 1, 激活函数为 LeakyReLU); 一个全连接层 (激活函数为 Sigmoid)。判别器网络如图 6 所示。




图 6 判别器网络模型图

3 实验结果及分析

3.1 数据集设置

1) 模拟 eLoran 信号训练集

本次实验中使用的是模拟主台信号, 主台信号中存在

GRI-A 和 GRI-B 两组不同的调制相位,因此本文采用的数据集都删除了主台标志脉冲(只保留含有信息的脉冲)由两个相邻脉冲组组成,调制参数如表 1 所示。训练集包含了 1 000 个模拟 eLoran 信号训练样本。

表 1 模拟信号参数

调制参数	参数值
归一化幅度	1/550
信噪比/dB	20
采样频率/Hz	1×10^6
采样点数	16 000

所使用的电文训练集为 1 000 个 16 位的符合 eLoran 信号规则的随机电文信息,对电文信息中的每一个电文都重复采样了 1 000 次,使得与 eLoran 信号数据长度一致。

训练集、验证集、测试集的比例为 10 : 1 : 1,验证集和测试集均为包含了 100 个模拟信号及其对应的电文数据。

2) 实测 eLoran 信号数据集

本文所使用的实测 eLoran 信号是在西安临潼 BPL 长波授时监测站测得的脉冲组重复周期为 6 000 的信号。包含了 30 个实测 eLoran 信号训练样本。所采用的电文数据集与模拟信号的电文数据集一致。

训练集、验证集、测试集的比例为 1 : 1 : 1,验证集和测试集均为与训练集不同的 30 个实测 eLoran 信号及其对应的电文数据。

3.2 生成信号评估策略

1) 使生成信号与数据集相似性分析

设 X 为生成 eLoran 信号, Y 为样本信号, Z 为信号长度, i 为信号的采样点数。

在时域方面,采用均方误差(mean square error,MSE)来分析生成信号与样本信号之间的整体差异程度。

$$MSE = \frac{1}{Z} \sum_{i=1}^Z (X_i - Y_i)^2 \tag{8}$$

由于皮尔逊相关系数(pearson correlation coefficient,PCCs)对数据的平移很敏感,而 eLoran 信号正是通过“超前”、“滞后”来调制的,因此当信号发生平移时,皮尔逊相关系数会发生显著变化。

$$\text{sim}(X,Y) = \frac{\sum_{i=1}^Z (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^Z (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^Z (Y_i - \bar{Y})^2}} \tag{9}$$

从统计学的角度评估,核密度估计是一种非参数估计,可以通过有限的样本推断总体数据的分布,核密度估计的结果即为样本的概率密度函数估计。

$$K(u) = \frac{1}{\sqrt{2\pi\sigma^2}} \times e^{-\frac{u^2}{2\sigma^2}} \tag{10}$$

其中, u 是自变量, σ 是核函数的带宽(控制光滑度)。

$$KDE(x) = \frac{1}{Zh} \times \sum K\left(\frac{x - x_i}{h}\right) \tag{11}$$

x 是估计概率密度的点, x_i 是样本观测值, h 是带宽。

$$h = \left(\frac{4}{3Z}\right)^{\frac{1}{5}} \times std \tag{12}$$

其中, std 是信号的标准差。

在频域方面,通过对比生成 eLoran 信号与样本信号的功率谱可以直观的判断两个信号在频域方面的相似性。

2) 信号相互转换准确率分析

评估模型取 n 组已知电文信息的 eLoran 信号,设已知的 eLoran 为 A ,对应的电文信息为 B 。

首先来评估模型从电文信息生成 eLoran 的能力,把 B 输入模型 $G(B-A)$,生成 eLoran 信号 A' ,使用 eLoran 信号的解调器,对生成的 A' 信号进行解调得到电文信息 B' ,计算 B' 与 B 之间的准确率。

$$\text{accuracy}_n = \frac{1}{n} \sum_{i=1}^n \frac{\sum_{i=1}^{16} [B'_i = B_i]}{16} \times 100\% \tag{13}$$

其中, i 是当前信号的电文序号。

其次来评估模型由 eLoran 信号生成电文信息的准确率,把 A 输入模型 $G(A-B)$,生成电文信息 B'' ,计算 B'' 与 B 对应数据的绝对误差,小于 0.1 记 1,否则记 0。

$$ACC_n = \frac{1}{Zn} \sum_{n=1}^n \sum_{j=1}^Z \begin{cases} 1, & |B''_j - B_j| \leq 0.1 \\ 0, & \text{其他} \end{cases} \times 100\% \tag{14}$$

其中, j 是信号的采样点数。

3.3 实验结果及分析

1) 模拟信号生成实验结果

在训练过程中同时计算准确率,结合损失辅助判断模型的收敛情况,其中图 7(a)和(b)分别是训练中的损失和准确率。通过对训练过程中 loss 和准确率的分析,该模型在 epoch=580 时已经基本收敛,对测试集 100 组生成的 eLoran 进行分析,所包含电文的准确率达到 99.78%,电文识别准确率达到 99.85%。




图 7 CycleGAN 训练过程损失与准确率

如图 8 为使用 CycleGAN 模型对模拟信号训练的模型结果,其中图 8(a)为输入电文信息生成的 eLoran 信号时域图,图 8(b)为输入 eLoran 信号生成的电信息图。生成的信号与模拟信号的时域、频域对比图如图 9 所示,其中

图 9(a)、(b) 为模拟信号和生成信号的时域对比图, 图 9(c)、(d) 为模拟信号和生成信号的频谱图。




图 8 CycleGAN 模拟信号相互转换结果




图 9 生成信号与模拟信号时、频域对比图

取测试集中的 30 组模拟 eLoran 信号, 得平均皮尔逊相关系数为 0.993 4, 得平均 MSE 为 0.005 2, 如图 10(a) 所示。生成信号与样本信号的概率密度估计如图 10(b) 所示, 可知生成信号与样本信号的概率密度十分相似。




图 10 生成模拟信号指标分析图

对图 8~10 进行分析, 从对比图可以看出生成的 eLoran 信号与样本信号的各个指标都十分近似, 说明生成的信号符合预期要求。

2) 实测信号迁移学习实验

如图 11 所示为实测 eLoran 信号的模型电文和信号互相转换结果, 其中图 11(a) 为输入电文生成的 eLoran 信号

时域图, 图 11(b) 为输入实测 eLoran 信号生成的电文信息图。通过迁移学习对实测的 eLoran 信号进行训练, 模型在 epoch 为 20 时就可以快速收敛, 生成的 eLoran 的电文准确率能够达到 99.02%, 电文识别准确率能够达到 99.38%。生成的 eLoran 信号与实测的 eLoran 信号单脉冲时域和功率谱对比如图 12, 其中图 12(a)、图 12(b) 为实测信号和生成信号的时域对比图, 图 12(c)、图 12(d) 为实测信号和生成信号的频谱图, 从图上可知生成的信号与实测信号在时域和频域上差异很小。




图 11 CycleGAN 实测信号相互转换结果




图 12 生成信号与实测信号时、频域对比图

对测试集的实测 eLoran 信号计算每对信号皮尔逊相关系数和均方误差, 得平均皮尔逊相关系数为 0.984 3, 平均均方误差为 0.015 3, 图 13(a) 展示了 30 组生成信号的皮尔逊系数和均方误差。同时计算出 30 组生成信号、实测信号平均概率密度, 如图 13(b) 所示, 生成的信号与实际测量得的信号具有较高的相似度。

从时域图、功率谱、概率密度图可知信号在时域上信号的相似度较高但是仍存在差异, 分析时域波形可知差异集中在脉冲的末端, 不影响信号的能量主要部分。

从上述实验中可以看出, 将迁移学习引入到 CycleGAN 中, 可以极大的降低实测信号的训练集数量和计算成本。使用迁移学习后在 30 个实测信号样本的情况下, 仅训练 20 轮、耗时 15.36 秒即可完成模型的训练, 经过




图 13 生成实测信号指标分析图

检验可知生成的信号符合实际需求。在实际中,eLoran 信号会受到各种因素的影响,使用本文的方法仅需要一次模拟信号的预训练,即可在之后小样本实测信号的情况下,实现实测信号的快速生成。

3.4 网络改进对比实验

为了研究在 CycleGAN 中引入残差块和自注意力机制对生成 eLoran 信号的作用,本文评估了生成器改进前后的生成模拟信号的电文准确率、信号转换为电文的准确率、生成信号的均方误差、皮尔逊系数方面的表现。实验结果如表 2 所示,表中 E→D 表示 eLoran 信号转换为电文的准确率,D→E 表示电文转换为 eLoran 信号的准确率。从表中数据可以得出,在仅使用卷积网络模型进行 eLoran 信号的生成时虽然信号转换为电文的准确率较高,但是电文转信号的准确率不佳,通过模型测试观察时域图可知,生成信号大致符合符合预期,但是某些脉冲在细节处存在异常导致解调出错误的电文,如图 14(a)所示。使用卷积+残差模型进行生成时各种评估指标虽然都有所提升,但是还是存在某些脉冲细节的异常,如图 14(b)所示。本文使用的卷积+残差+自注意的网络模型,在之前的基础上添加了自注意力机制,使得网络能够关注局部信息,提高模型的细节能力,弥补生成的信号某些细节不佳的缺点,如图 14(c)所示。

表 2 网络改进对比实验

评估指标	卷积	卷积+残差	卷积+残差+自注意
E→D	95.13%	96.76%	99.85%
D→E	77.00%	80.52%	99.78%
PCCs	0.920 6	0.937 3	0.993 4
MSE	0.009 1	0.007 9	0.005 2

3.5 算法普适性实验

为了验证本算法在信号生成方面的普遍适用性,本文在相移键控(phase shift keying, PSK)、幅移键控(amplitude shift keying, ASK)、频移键控(frequency shift keying, FSK)3 种常用的通信信号数据集上使用本算法进行生成实验。在仅已知信号的情况下,使用随机的电文和信号进行训练,使生成生成包含指定电文信息且与样本相似的信




图 14 改进网络后生成效果图

号。通过对 3 种不同信号进行训练,当输入如图 15(a)的电文时生成的 PSK 信号如图 15(b)、生成的 ASK 信号如图 15(c)、生成的 FSK 信号如图 15(d)。可以明显观察到生成的信号符合训练集的调制方式且包含有特定电文,说明了生成信号的准确性。




图 15 使用不同数据集生成效果

同时通过计算生成信号的几种评价指标,来准确的评估生成信号的质量,结果如表 3 所示。

表 3 生成的信号质量评估数据

信号类型	电文准确率/%	信号准确率/%	PCCs	MSE
PSK	99.78	100	0.991 2	0.009 1
ASK	99.97	100	0.989 2	0.008 8
FSK	99.15	100	0.985 3	0.013 9

实验说明本算法可以实现在仅已知信号,没有额外的人工标注的情况下,实现了生成包含指定电文的与样本相似的信号,生成信号的符合预期,能推广到不同数据集上进行生成,具有一定的普遍适用性。

3.6 与其他信号生成方法生成对比实验

表 4 展示了其他一些信号生成方法,其中包括传

统的数字信号处理方法与 3 种具有代表性的生成对抗网络模型。传统的 eLoran 信号生成都是依靠数字信号处理进行生成,虽然计算量较小,但是需要充分的先验知识,例如调制方式、调制参数、电文数据等。该方法对于实测的信号并不适用,很难模拟出与实测相似的信号。

表 4 与其他信号生成方法对比

信号生成方法	能否生成特定电文	能否生成近似实测的信号	是否需要标注数据	PCCs	MSE	生成信号电文准确率	信号转化为电文准确率
数字信号处理	是	否	否	—	—	—	—
GAN	否	是	否	0.867 4	0.0121	—	—
CGAN	是	是	是	0.971 7	0.003 5	92.50%	—
CycleGAN	是	是	否	0.993 4	0.005 2	99.78%	99.85%

然而将生成对抗网络引入到信号生成领域可以使用于实测信号的生成,但使用经典 GAN 及其网络优化模型都只能生成出一种与数据集相似的信号,无法生成指定电文信息的信号。在该部分本文构建了一种基于 GAN 的 eLoran 信号生成模型,通过对生成数据分析,该模型生成了一种虚假的 eLoran 信号,但是无法生成指定电文的信号。

因此在该部分还构建了一种有监督的条件生成对抗网络,利用 CGAN 可以将电文信息作为标签作为额外的输入,通过模型的训练,可以实现将噪声和电文同时输入模型输出指定电文的 eLoran 信号。通过对生成的数据分析,可以知道模型生成一种包含指定信息的 eLoran 信号。虽然使用条件生成对抗网络可以生成包含指定信息的信号,但是需要大量具有电文作为标注的 eLoran 信号作为训练集。

相比于上述的 3 种信号生成方式,本文提出的基于 CycleGAN 的信号生成算法实现了无需标注的情况下可以实现生成与数据集相似且包含指定电文的信号,同时引入迁移学习来进行实测信号的生成,克服了传统数字信号无法生成实测信号、GAN 无法生成指定电文信号、CGAN 需要大量标记等缺陷。可以生成更加复杂的实测 eLoran 信号,用于扩充已有的有限实测信号数据集,并增加数据的多样性,优化电子对抗系统和算法。

4 结 论

本文提出了一种基于 CycleGAN 的信号生成方法,此方法克服其他信号生成方法中存在的缺陷,同时针对 eLoran 信号的特效对网络模型进行了优化,在仅已知 eLoran 信号的情况下,实现了信号和电文的相互转换,并通过迁移学习实现小样本实测 eLoran 信号的快速生成,从多方面证明了生成信号与实际信号相似度较高,符合预期

需求。同时使用该算法生成了常见的通信信号验证该算法的可行性与优越性,说明该算法可以适用于未知参数信号的生成和解调。

由于 eLoran 信号有 GRI-A 和 GRI-B,两组不同的调制相位,针对该问题本文使用的 eLoran 数据集是由两组拼接而成的,后续工作可以分组训练模型以克服该困难。

参考文献

[1] 李婉清,王建辉,李实锋,等. eLoran 系统新型数据调制/信道编码方案设计与评估[J]. 全球定位系统, 2020, 45(5):84-89.

[2] 孙延伟. eLoran 信号处理关键技术研究[D]. 哈尔滨: 哈尔滨工程大学, 2019.

[3] 聂乾震. eLoran 与导航安全[J]. 港工技术, 2017, 54(6):113-117.

[4] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks [J]. Advances in Neural Information Processing Systems, 2014, 3: 2672-2680.

[5] RAYAVARAPU S M, SHANMUKHAPRASANTHI T, LAVANYA Y L, et al. Synthesis of ECG signals using generative adversarial networks [C]. 2023 Second International Conference on Electrical, Electronics, Information and Communication Technologies(ICEEICT), 2023: 1-4.

[6] KALELI H S, DEHALWAR V. Generation of synthetic ECG signal using generative adversarial network with transformers[C]. 2023 14th International Conference on Computing Communication and Networking Technologies(ICCNT), 2023: 1-6.

[7] 钱尧佳. 基于对抗神经网络的肌电信号生成模型研究[D]. 杭州: 杭州电子科技大学, 2024.

- [8] WU J, WANG L, PAN H, et al. MLCGAN: Multi-lead ECG synthesis with multi label conditional generative adversarial network [C]. ICASSP 2023-2023 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 2023: 1-5.
- [9] JAYALAKSHMY S, PRIYA L, SUDHA G F. Synthesis of respiratory signals using conditional generative adversarial networks from scalogram representation[M]. Amsterdam: Academic Press, 2021.
- [10] YE F, ZHU F, FU Y, et al. ECG generation with sequence generative adversarial nets optimized by policy gradient [J]. IEEE Access, 2019, 7: 159369-159378.
- [11] OYAMADA K, KAMEOKA H, KANEKO T, et al. Generative adversarial network-based approach to signal reconstruction from magnitude spectrograms[C]. 2018 26th European Signal Processing Conference (EUSIPCO), IEEE, 2018: 2514-2518.
- [12] TRUONG T, YANUSHKEVICH S. Generative adversarial network for radar signal synthesis [C]. 2019 International joint conference on neural networks (IJCNN), IEEE, 2019: 1-7.
- [13] SHI Y, DAVASLIOGLU K, SAGDUYU Y E. Generative adversarial network for wireless signal spoofing[C]. Proceedings of the ACM Workshop on Wireless Security and Machine Learning, 2019: 55-60.
- [14] 赵凡, 金虎. 基于 GAN 的通信干扰波形生成技术[J]. 系统工程与电子技术, 2021, 43(4): 1080-1088.
- [15] 秦剑. 基于生成对抗网络的信号重构[D]. 西安: 西安电子科技大学, 2018.
- [16] 杨鸿杰, 陈丽, 张君毅. 基于生成对抗网络的数字信号生成技术研究[J]. 电子测量技术, 2020, 43(20): 127-132.
- [17] 薛丽莎, 葛瑞星, 朱宇轩, 等. 基于 SABEGAN 的通信干扰信号生成与效能分析[J/OL]. 系统工程与电子技术, 1-11 [2024-04-08]. <http://kns.cnki.net/kcms/detail/11.2422.TN.20230816.1033.008.html>.
- [18] 冯奇. 基于生成对抗网络的帧结构及 DSSS 信号生成技术研究[D]. 北京: 中国电子科技集团公司电子科学研究院, 2022.
- [19] SAARINEN V, KOIVUNEN V. MIMO radar waveform synthesis using generative adversarial networks[C]. 2023 IEEE 33rd International Workshop on Machine Learning for Signal Processing (MLSP), 2023: 1-6.
- [20] 陈昌美, 李艳斌, 杨鸿杰, 等. 基于条件生成对抗网络的信号生成技术[J]. 信息技术, 2023(10): 136-140, 146.
- [21] TANG H, ZHAO Y, WANG G, et al. Wireless signal denoising using conditional generative adversarial networks [C]. IEEE INFOCOM 2023-IEEE Conference on Computer Communications Workshops (INFOCOM WKSHPS), 2023: 1-6.
- [22] TANG B, TU Y, ZHANG Z, et al. Digital signal modulation classification with data augmentation using generative adversarial nets in cognitive radio networks[J]. IEEE Access, 2018, 6: 15713-15722.
- [23] ZHU J Y, PARK T, ISOLA P, et al. Unpaired image-to-image translation using cycle-consistent adversarial networks [C]. Proc of the IEEE International Conference on Computer Vision, 2017: 2223-2232.
- [24] 易星, 潘昊, 赵怀慈, 等. 基于改进循环生成对抗网络实现红外图像生成[J]. 电子测量技术, 2023, 46(18): 171-178.
- [25] 王媛彬, 郭亚茹, 刘佳, 等. 基于注意力机制和空洞卷积的 CycleGAN 煤矿井下低照度图像增强算法[J/OL]. 煤炭科学技术, 1-10 [2024-04-08]. <http://kns.cnki.net/kcms/detail/11.2402.TD.20240119.1728.013.html>.
- [26] 刘致远, 但志平. 基于注意力增强的 CycleGAN 图像去雾[J]. 国外电子测量技术, 2023, 42(9): 162-168.
- [27] 董骏捷, 唐建, 周然之, 等. 基于循环生成式对抗网络的一维时变信号自适应去噪研究[J]. 机电工程技术, 2021, 50(5): 10-12, 17.

作者简介

李辉, 教授, 博士研究生, 主要研究方向为智能信息处理。
E-mail: li20022004@hpu.edu.cn

胡登峰, 硕士研究生, 主要研究方向为智能信息处理、长波传播。

E-mail: 1505999511@qq.com

张恺(通信作者), 讲师, 博士研究生, 主要研究方向为长波传播、卫星导航、人工智能。

E-mail: zhangkai@hpu.edu.cn

邹波蓉, 讲师, 硕士研究生, 主要研究方向为智能数字信号处理。

E-mail: wdzbr296@hpu.edu.cn

刘薇, 硕士研究生, 主要研究方向为光纤传感器、智能信息处理。

E-mail: 1781836724@qq.com