

中图分类号 P631

学校代码 10533

UDC 550

学位类别 学术学位

## 硕士学位论文

# 基于深度学习的大地电磁时间域信噪识别与分离

## Deep learning-based signal-to-noise identification and separation for time-domain Magnetotelluric data

作者姓名	蒋恩华
一级学科	地质资源与地质工程
二级学科	地球探测与信息技术
研究方向	大地电磁去噪
二级培养单位	地球科学与信息物理学院
指导教师	朱德兵 副教授

论文答辩日期\_\_\_\_\_ 答辩委员会主席\_\_\_\_\_

中南大学

2023年05月



## 学位论文原创性声明

本人郑重声明，所提交的学位论文是本人在导师指导下进行的研究工作及取得的研究成果。尽我所知，除了论文中特别加以标注和致谢的地方外，论文中不包含其他人已经发表或撰写过的研究成果，也不包含为获得中南大学或其他教育机构的学位或证书而使用过的材料。与我共同工作的同志对本研究所作的贡献均已在论文中作了明确的说明。

申请学位论文与资料若有不实之处，本人承担一切相关责任。

学位论文作者签名：\_\_\_\_\_ 日期：\_\_\_\_\_年\_\_\_月\_\_\_日

## 学位论文授权使用授权书

本学位论文作者和指导教师完全了解中南大学有关保留、使用学位论文的规定：即学校有权保留并向国家有关部门或机构送交学位论文的复印件和电子版，允许本学位论文被查阅和借阅。本人授权中南大学可以将本学位论文的全部或部分内 容编入有关数据库进行检索和公开传播，可以采用复印、缩印或其它手段保存和汇编学位论文。本人同意按《中国优秀博硕士学位论文全文数据库出版章程》规定享受相关权益。本人保证：毕业后以学位论文内容发表的论文作者单位注明中南大学；学位论文电子文档的内容和纸质学位论文的内容相一致。

延缓公开论文延缓到期后适用本授权书，涉密论文在解密后适用本授权书。

本学位论文属于：（请在以下相应方框内打“√”）

公开

延缓公开，延缓期限（\_\_\_年\_\_\_月\_\_\_日至\_\_\_年\_\_\_月\_\_\_日）

学位论文作者签名：\_\_\_\_\_

日期：\_\_\_\_\_年\_\_\_月\_\_\_日

指导教师签名\_\_\_\_\_

日期：\_\_\_\_\_年\_\_\_月\_\_\_日

## 基于深度学习的大地电磁时间域信噪识别与分离

**摘要:** 大地电磁法具有对地下低阻率区域的探测能力强等优点,能够探测到更深部的地质构造信息,已广泛应用于地质勘探、矿产资源探测、地下水资源探测、地热资源勘探等领域。大地电磁天然场源的信号微弱、频带宽等特点决定了其信号极易受到各种噪声的影响,因此如何识别出有效信号成分,消除强噪声干扰一直是该领域的重要研究课题。针对上述问题,本文在分析总结国内外研究成果的基础上,提出了基于深度学习的大地电磁时间域信噪识别与分离算法,从基于深度学习的大地电磁信号识别、去噪分析、仿真实验和阻抗估计等几个方面研究其在大地电磁信号处理中的应用方法和应用效果,试图提供大地电磁数据处理的新思路。

本文首先从大地电磁测深法的基本原理出发,对大地电磁场源和噪声源进行了系统地研究。详细地讨论了大地电磁的信号特征,针对噪声的类型不同,分析了它们的主要来源、时频特征及对阻抗估算的影响,指出大地电磁采集数据存在强噪声干扰的普遍现象。

针对音频大地电磁“死区”问题,本文提出了基于卷积神经网络 VGG 的天电信号自动识别算法,并且重点阐述了算法原理、工作流程和具体步骤。通过实测数据验证了该网络可以鲁棒地从嘈杂时间序列中自动识别和抽取出天电场源信号,具有一定的有效性和泛化性。与传统方法相比,该方法在“死区”可以产生更平滑的视电阻率-相位曲线结果。

矿集区噪声类型复杂且不可预测,传统方法往往难以实现自适应去噪效果。在已有工作的基础上,本文更进一步地提出了基于自监督学习的大地电磁去噪算法。该算法无需人工标注,利用数据本身进行标签自动生成。通过多尺度高分辨率样本掩码对高质量信号段与含噪信号段进行识别,随后使用 U-net 网络对含噪信号段进行去噪处理,通过从观测数据中自主学习时序波形特征来提取噪声轮廓,在保证失真较小的前提下,实现信噪分离。此外,对大地电磁信号中的脉冲干扰、三角波干扰、方波干扰等几种常见噪声进行了仿真试验和分析,仿真结果表明:(1)本文方法能自适应地识别和分离大地电磁时间序列中的大尺度强干扰;(2)本文方法有效地抑制了噪声,改善了受干扰数据的质量,获得了稳定的参数估计值;(3)本文方法能较好地保留原始数据中的有效信号,失真程度较小。

最后,为了验证本文方法对实测数据的处理效果,将论文研究成果应用于江苏南京、湖北武汉地区和贵州省西北部赫章县水塘乡猪拱塘铅锌矿集区的大地电磁实测数据处理中。天电识别结果在不同信噪比数据上取得了

很好的一致性，证明了网络强大的泛化能力，同时提高数据质量和可靠性；去噪结果表明本文方法能够自适应地压制各种电磁噪声，与其他传统去噪方法相比，本文方法可以有效地降低大地电磁时间序列的噪声，显著地改善了低频段的视电阻率-相位曲线，矿集区的近源干扰得到了有效抑制，处理后的数据特征更加接近天然场信号特征。

综上所述，本文基于深度学习实现了大地电磁信噪识别与分离，一定程度上提高大地电磁原始数据的信噪比，为大地电磁资料的处理与解释提供了全新的技术参考。

图 67 幅，表 17 个，参考文献 119 篇

**关键词：**大地电磁测深法；深度学习；卷积神经网络；自监督学习；信噪识别与分离；时间序列

**分类号：**P631

## **Deep learning-based signal-to-noise identification and separation for time-domain Magnetotelluric data**

**Abstract:** Magnetotelluric(MT) method has advantages such as strong detection ability for low-resistance areas underground. It can detect geological structures at deeper levels and has been widely used in geological exploration, mineral resource exploration, groundwater resource exploration, geothermal resource exploration, and other fields. The magnetotelluric method has the advantages of non-invasiveness and strong detection ability for underground low-resistivity areas, and can detect deeper geological structure information. It has been widely used in geological exploration, mineral resource detection, groundwater resource detection, geothermal resource exploration, etc. field. The weak signal and frequency bandwidth of the magnetotelluric natural field source determine that its signal is easily affected by various noises. Therefore, how to identify effective signal components and eliminate strong noise interference has always been an important research topic in this field. Aiming at the above problems, on the basis of analyzing and summarizing domestic and foreign research results, this paper proposes a deep learning-based magnetotelluric time-domain signal-to-noise recognition and separation algorithm. And this paper studies its application methods and effects in magnetotelluric signal processing from the aspects of deep learning-based magnetotelluric signal identification, denoising analysis, simulation experiment and impedance estimation, trying to provide new ideas for magnetotelluric data processing.

Starting from the basic principles of the magnetotelluric method, this paper systematically studies the sources of magnetotelluric field and noise. It discusses in detail the signal characteristics of the magnetotelluric field, and analyzes the main sources, time-frequency characteristics, and their impact on impedance estimation according to the different types of noise, pointing out the common phenomenon of strong noise interference in the acquisition of magnetotelluric data.

This paper proposes an automatic identification algorithm for sferic signals based on the convolutional neural network VGG to address the problem of the "dead band" in audio-magnetotelluric sounding, and focuses on the principle, workflow and specific steps of the algorithm. It is verified by field data that the network can robustly and automatically identify and extract sferic signals from noisy time

series, with certain effectiveness and generalization. Compared with traditional methods, our method can produce smoother apparent resistivity-phase curve results in the "dead band".

The types of noise in mine concentration areas are complex and unpredictable, and traditional methods are often difficult to achieve adaptive denoising effects. Based on the existing work, this paper further proposes a magnetotelluric denoising algorithm based on self-supervised learning. This algorithm generates labels automatically without manual annotation by using data itself. Then we identify the high-quality signal segment and the noisy signal segment through the multi-scale high-resolution sample mask, and use U-net network to denoise the noisy signal segment. It extracts noise profile by autonomously learning time-series waveform features from observation data, enabling signal-to-noise separation while minimizing distortion. In addition, this paper conducts simulation experiments and analyzes several common noises in magnetotelluric signals, such as pulse interference, triangular wave interference, and square wave interference. The simulation results show:(1) the proposed method can adaptively identify and separate large-scale strong interference in the magnetotelluric time series; (2) the proposed method effectively suppresses noise, improves the quality of the interfered data, and obtains stable parameter estimation values; and (3) the proposed method can better preserve the effective signals in the original data with low distortion.

Finally, in order to verify the processing effectiveness of the proposed method on the measured data, the research results of this paper are applied to the processing of the magnetotelluric measured data in Nanjing, Jiangsu, Wuhan, Hubei, and Zhugongtang ore concentration area, Shuitang Township, Hezhang County, Northwest Guizhou Province. The sferics identification results have achieved good consistency on different signal-to-noise ratios(SNRs) data, demonstrating the network's strong generalization ability, and improving the data quality and reliability; the denoising results show that the proposed method can adaptively suppress various electromagnetic noises. Compared with other traditional denoising methods, the method can effectively reduce the noise in the magnetotelluric time series, significantly improve the smoothness of apparent resistivity-phase curve in the low-frequency band, and effectively suppress the near-source interference in the ore-concentrated area. The processed data features are closer to the natural field signal features.

In conclusion, this paper realizes the identification and separation of magnetotelluric signal and noise based on deep learning, partially improves the magnetotelluric raw data SNR to a certain extent, and provides a new technical reference for the processing and interpretation of magnetotelluric data.

**Keywords:** magnetotelluric; deep learning; convolutional neural network; self-supervised learning; signal-to-noise identification and separation; time series

**Classification:** P631



# 目 录

目 录.....	VI
<b>第一章 绪论.....</b>	<b>1</b>
1.1 研究目的与意义.....	1
1.2 研究现状及面临的问题.....	1
1.2.1 国内外研究现状.....	2
1.2.2 面临的主要问题.....	9
1.3 本论文的主要研究内容及结构.....	10
1.3.1 主要研究内容.....	10
1.3.2 本文结构.....	11
<b>第二章 大地电磁测深及其噪声.....</b>	<b>13</b>
2.1 大地电磁测深基本原理.....	13
2.2 大地电磁场源及其频谱特征.....	14
2.3 大地电磁噪声源.....	17
2.3.1 随机噪声.....	17
2.3.2 场源噪声.....	17
2.3.3 地质噪声.....	17
2.3.4 人文噪声.....	18
2.4 本章小结.....	21
<b>第三章 基于卷积神经网络的天电信号自动识别.....</b>	<b>22</b>
3.1 引言.....	22
3.2 数据集制作.....	23
3.2.1 数据生成.....	23
3.2.2 数据增强.....	25
3.3 模型结构设计.....	25
3.4 模型训练细节.....	26
3.4.1 损失函数.....	26
3.4.2 评价指标.....	27
3.4.3 训练细节.....	28
3.5 本章小结.....	31
<b>第四章 基于自监督学习的音频大地电磁时间域去噪.....</b>	<b>32</b>
4.1 引言.....	32
4.2 数据集制作.....	33

4.2.1 训练样本 .....	33
4.2.2 样本掩码 .....	33
4.3 模型结构设计 .....	36
4.4 模型训练细节 .....	37
4.4.1 损失函数 .....	37
4.4.2 评价指标 .....	40
4.4.3 训练细节 .....	40
4.5 模拟数据处理 .....	42
4.5.1 模拟周期噪声 .....	43
4.5.2 模拟方波噪声 .....	45
4.5.3 模拟充放电三角波噪声 .....	47
4.5.4 模拟脉冲噪声 .....	48
4.5.5 模拟阶跃噪声 .....	50
4.5.6 模拟复合噪声 .....	51
4.6 本章小结 .....	53
<b>第五章 实测数据结果 .....</b>	<b>54</b>
5.1 实测天电信号资料处理解释 .....	54
5.1.1 案例一：南京 .....	54
5.1.2 案例二：武汉 .....	58
5.2 实测 AMT 数据去噪处理 .....	62
5.2.1 时域波形和频谱对比 .....	64
5.2.2 处理结果对比 .....	73
5.3 本章小结 .....	80
<b>第六章 总结与展望 .....</b>	<b>82</b>
6.1 本论文主要研究成果 .....	82
6.2 进一步的研究方向与建议 .....	83
<b>参考文献 .....</b>	<b>84</b>
<b>攻读学位期间主要的研究成果 .....</b>	<b>92</b>
<b>致 谢 .....</b>	<b>93</b>

# 第一章 绪论

## 1.1 研究目的与意义

大地电磁法 (Magnetotelluric, MT) 是 Tikhonov 和 Cagniard 提出的利用地球表面的自然交变电磁场来推断地下地质结构电性特征的一种地球物理方法。该方法通过测量相互垂直的电场、磁场并计算视电阻率后,再经反演解释来获取地球深部电性结构信息。因其具有对地下低阻率区域的探测能力强等优点,能够探测到更深部的地质构造信息,已被广泛应用于地质勘探、矿产资源探测、地下水资源探测、环境地质、地热资源勘探等领域。

大地电磁时序信号是勘探领域中最常见的一种信号,具有频率高、灵敏度高的特点。然而,作为一种被动源勘探方法,大地电磁法获取到的时序信号通常比较微弱,而且天气变化、周围环境干扰、设备参数变化等各种因素往往会导致 MT 时序信号受到大量噪声干扰。因此,开发一种能够有效地压制噪声的去噪算法,对于提高大地电磁时序信号的信噪比具有重要意义。

正确可靠的大地电磁响应函数对后续的资料处理与解释都至关重要,确定可靠的大地电磁响应函数是大地电磁测深法的前提条件,在此基础上,才能进行数据分析和定量反演,并准确地解释地下电性结构。而响应函数的准确估计依赖于大地电磁采集时序信号的信噪比,因此信号去噪是确定响应函数的关键步骤之一,噪声抑制技术是大地电磁测深法中至关重要的一环。

## 1.2 研究现状及面临的问题

一般来说,大地电磁去噪方法可以分为两类,一类是频率域去噪,另一类是时间域去噪。前者是指对采集到的数据进行 Fourier 变换,将信号从时域转换到频域,利用频域的特性对信号进行滤波处理来抑制噪声信号,最终保留地下构造信息。后者则是在时域中对信号进行处理,主要是利用信号的局部特征来去除噪声干扰。

频率域去噪需要基于观测电磁信号的长期稳定性。对于非稳定信号,频率域去噪可能会产生一些问题,例如失真、振铃等现象,这些问题主要是由于非稳定信号的频谱存在时间变化,导致信号在不同时间上的频率响应不同。而时间域去噪方法在处理非平稳噪声和局部信号时具有很大的优越性。时间域去噪方法可以利用信号在时域上的局部平稳性质,即信号在小时间窗口内是平稳的。此外,时域去噪方法还可以利用信号在时间上的相关性和空间上的相关性。相比于频域去噪方法,时域去噪方法可以有效地处理非稳定信号和复杂噪声,提高数据处理的精度和可靠性。鉴于此,国内外大地电磁学者开

展了一系列相关研究，也提出了许多新方法。

### 1.2.1 国内外研究现状

时间域滤波方法是一种针对大地电磁测深数据中典型的具有波形特征的噪声干扰而设计的滤波方法。噪声特点一般为周期较短、振幅较大且在时间域中异常特征明显。目前的主流方法有人工手动编辑法、自适应噪声抵消、经验模式分解、小波变换、数学形态滤波和神经网络等<sup>[1-2]</sup>。

#### 1.2.1.1 人工编辑法

大地电磁时间域人工手动编辑法 (Manual Editing) 是一种常用的大地电磁数据处理方法，通过对时间域的大地电磁测量数据进行人工手动编辑来剔除异常值和噪声，从而提高数据质量和信噪比。该方法通常包括以下步骤：①数据处理前的预处理，如去直流、去趋势、校准和滤波等；②对数据进行人工手动编辑，剔除异常值和噪声，保留符合物理规律的有效数据；③对处理后的数据进行分析，如计算 MT 响应函数和反演地下介质等。

该方法的优点主要包括：①可以通过人工干预的方式，对异常值和噪声进行有效的消除，从而提升数据的质量和信噪比；②可以对不同测量点的数据进行不同程度的编辑，根据实际情况进行灵活处理；③在数据处理中，可以结合先进的处理算法和方法，如小波变换、EMD 等，进一步提高数据质量；④方法可解释性强，通俗易懂。

#### 1.2.1.2 自适应滤波

大地电磁自适应滤波方法 (Adaptive Noise Cancelling, ANC) 是常见时间域滤波方法。该方法是一种基于滤波的信号处理技术，旨在从带噪声的信号中去除干扰噪声，提取出所需的信号。该算法采用一个自适应滤波器来估计噪声，然后将其从输入信号中去除。自适应滤波法适合于主通道接收待处理信号，参考通道接收与主通道中的噪声分量有联的纯噪声信号的这一类特点信号处理问题。自适应滤波器通过持续地调整其参数，利用反馈的误差信号将参考通道输入转换为对主通道内相关信号成分的估计。最终，通过从主通道信号中减去变换得到的信号估计，从而获得主通道不相干信号分量的估算值<sup>[3]</sup>。该方法与人工筛选时间序列的方法在去噪原理上明显不同。

该方法在在时序去噪中主要存在以下优点：①自适应滤波能够实时地对输入信号进行处理，适用于需要实时处理的信号去噪场景。②对非线性系统有很好的适应性，自适应滤波能够自适应地处理非线性系统的信号，因为其基于反馈原理，可以将系统的动态特性纳入考虑。③自适应滤波不需要事先知道噪声信号的统计特性，只需要通过输入信号和反馈信号来估计噪声信号的统计特性。这使得自适应滤波能够快速适应各种噪声环境，具有高效性。④自适应滤波适用于多种噪声类型，包括稳态和非稳态噪声，以及周期性和随机性噪声。⑤自适应滤波能够降低系统的复杂度，因为其不需要使用额外的传感器或硬件，只需要利用反馈信号进行处理。

由于其自适应特点,该算法已被广泛应用在各种场景中。Hattingh (1989) 在处理连续宽频谱噪声时,提出了一种关联自适应降噪方法<sup>[4]</sup>。K.B. Olsen (1992) 提出了使用自适应滤波来远程测量磁场,以改善延迟响应的信噪比<sup>[5]</sup>。姚同起 (1995) 提出了利用自适应信号处理的原理消除地磁观测数据中的干扰噪音<sup>[6]</sup>。针对 50H 工频及其谐波干扰,曹建章 (1997) 提出了相关一自适应滤波方法来提高测量精度<sup>[7]</sup>。昌彦君 (2004) 将自适应滤波方法应用到瞬变电磁中以消除工频干扰<sup>[8]</sup>。余灿林 (2009) 对自适应滤波作了系统性的综述,并将 LMS、RLS 两种自适应滤波算法用于大地电磁信号的降噪,并证实了其在抑制工频干扰、矫正基线等方面的效果<sup>[9]</sup>。最近,李晋 (2022) 提出了基于自适应多分辨率奇异值分解的方法,结合奇异值分解在去噪方面的优越性,能够有效地分离出相关性较强的噪声<sup>[10]</sup>。

### 1.2.1.3 小波变换

小波变换 (Wavelet Transform, WT) 是一种基于小波分析的信号处理方法,主要用于去除时间序列中的噪声。该算法的基本思想是将信号分解成多个不同频率的子带,并对每个子带进行分析和处理,最后将各子带的处理结果合并来得到去噪后的信号。近年来,小波变换在信号处理领域受到广泛应用<sup>[11-13]</sup>,主要是由于它具有以下优点:①高效性,小波变换具备对信号进行多尺度分解的能力,可将信号以不同的分辨率分解,可以快速处理大量的数据,对于实时应用非常有用。②自适应性,小波去噪算法可以根据信号的特性自适应地选择阈值,使其适用于各种类型的信号,并且不需要手动设置参数。③保留信号的重要信息,小波去噪算法可以去除信号中的噪声,同时保留信号的重要信息,例如信号的趋势和周期性等。④通用性,小波去噪算法可以应用于不同类型的信号,例如语音、图像、地震数据等,因此具有广泛的应用价值。⑤鲁棒性,小波去噪算法可以有效地处理信号中的非高斯噪声和离群值,具有很强的鲁棒性。⑥具备出色的时间-频率局部化特性和多尺度分析能力。

小波分析最初由法国工程师 Morlet(1974)提出,用于石油勘探信号处理。目前,小波分析在大地电磁信号处理领域得到了广泛的应用, M.Alexandrescu (1995) 将小波分析方法应用于地球磁场研究中,探测和分析了磁震现象的发生和演化<sup>[14]</sup>。宋守根和汤井田 (1995) 提出利用小波分析识别、分离和压制大地电磁的静态效应和噪声<sup>[15]</sup>。高怀静 (1997) 提出了一种基于小波变换的方法来求解能量有限实信号对应的解析信号,并给出了详细的算法步骤<sup>[16]</sup>。Xiao-Ping Li (1998) 提出了一种基于小波功率谱分析的方法,用于在声波速度测井曲线中检测和描述非均质性特征<sup>[17]</sup>。M. Fedi (1998) 利用小波分析方法对地球物理勘探中的位势场异常数据进行区域-残差和局部分离<sup>[18]</sup>。V.Tarasov (1998) 主要研究了小波分析在分析火星弓形激波上游区域磁场湍流特征中的应用<sup>[19]</sup>。T.A.Ridsdill - Smith (1999) 提出了使用离散小波变换 (DWT) 替代传统的 Fourier 和空间卷积处理技术,通过分离具有相似频率内容的信号和噪声取得了更优的效果<sup>[20]</sup>。P.Hornby (1999) 通过在小波域中计算梯度和拉普拉斯算子来有效地检测边缘和提取地

质特征<sup>[21]</sup>。付彪(1999)在理论上提出了一种基于小波变换的新方法,用于求解非连续性变系数电磁波动方程高频解,有效地克服了 Fourier 变换法所难以处理的层状、非均质、无损耗介质中的波动传输和反射问题<sup>[22]</sup>。Trad 等(2000)将小波滤波应用于地球物理数据处理中的磁电测深数据,并探讨了小波滤波在去除数据中噪声和信号分离方面的有效性和优势,但该法在去噪的同时也损失了有用信号<sup>[23]</sup>。何兰芳(1999)提出了对采集数据应用小波变换的方法,将时序分解为多个成分,再将“干净”成分重建以实现去噪,通过前后谱分析对比发现信噪比明显提高<sup>[24]</sup>。师学明建立了多尺度逐次逼近遗传算法以解决遗传算法中有效基因丢失和早熟收敛问题<sup>[25]</sup>。徐义贤(2000)研究了小波变换中的参数选择问题,并提供了相应的经验公式和详细算法说明<sup>[26]</sup>。李世雄(2000)提出了一种正交小波变换,该变换的频谱支持紧凑且具有解析表达式,可以用于计算信号的瞬时参数。该方法具有抗噪声干扰的能力,同时具备快速、局部计算的优点<sup>[27]</sup>。何兰芳(2001)在其研究中提出用小波分析对 MT 信号进行降噪处理,并探讨了其对于噪声识别方面的能力和不足。结果表明,通过对 MT 时间序列进行分解和重构,可以相对成功地实现 MT 数据的去噪,从而提高 MT 数据的处理和解释的分辨率<sup>[28]</sup>。考虑到小波域脉冲类噪声的变化特性,严家斌(2007)提出了一种利用小波变换进行脉冲类干扰压制的方法,使用了迭代式回归方法对脉冲类噪声的变化特性进行了分析和抑制<sup>[29]</sup>。针对大地电磁勘探中的“死区”问题,Garcia X(2008)提出了一种新的时间序列处理技术,利用小波变换的局部特性选择能量最高的事件。随后,采用两个相干性阈值和一系列鲁棒权重来获得最可靠的 MT 响应估计。最后使用非参数的 jackknife 算法估计误差<sup>[30]</sup>。张伟(2011)提出了一种利用小波变换和经验模式分解的降噪方法,在龙门山地震带区域的实测数据得到了明显的效果<sup>[31]</sup>。针对小波阈值去噪中存在的阈值函数和取值的问题,蔡剑华(2015)利用小波变换多分辨 Stein 无偏风险估计,实现自适应获取最优阈值的方法<sup>[32-33]</sup>。Larnier(2018)提出了一种新颖的基于小波变换的闪电源检测算法,该算法通过识别频谱内的短时波形特征和极大频率响应点,实现了闪电源的高精度检测和定位,并且对于不同的地质背景和噪声环境下的数据也具有较好的适应性<sup>[34]</sup>。万云霞(2021)利用小波变换进行时频联合分析后,依据大地电磁天然场源信号和人文干扰的频谱特性,再通过选取适当的小波变换超参数,从而成功地压制了一部分人文噪声<sup>[35]</sup>。

#### 1.2.1.4 经验模式分解

经验模式分解 (Empirical Mode Decomposition, EMD)是一种基于数据的局部特征分解方法,可以将任意非线性或非平稳信号分解成若干个固有模函数 (Intrinsic Mode Function, IMF) 的线性组合。固有模函数是在局部时间尺度上具有单调性和带通性的函数,是信号本身的本征特征,可以描述信号的局部振动特性。EMD 可以应用在时间序列数据的去噪、特征提取、时频分析、非线性建模、预测等方面。在去噪方面,EMD 可以将信号分解成若干个固有模函数和一个残余项,可以通过去除某些固有模函数来去除信号中的噪声;在特征提取方面,EMD 可以将信号分解成若干个固有模函数,提取每

个固有模函数的幅值、频率等特征，进而描述信号的局部特性；在时频分析方面，EMD 可以通过固有模函数的带通特性，提供更好的时频分析精度；在非线性建模和预测方面，EMD 能将一个信号分解成若干个本征模式，然后对每个本征模式进行单独的建模和预测。相较于小波，EMD 过程本质上是一个频段筛选的过程，该方法对待分解的信号具有很强的自适应能力，与小波变换不同，EMD 方法无需对基函数进行预先选择，从而避免了其分解过程中对于基函数的选择问题，具有更好的自适应能力和更强的灵活性。

相较于其他方法，经验模态分解具有以下优点：①非参数性，EMD 算法不需要对信号进行任何先验假设，因此可以自适应地分解信号，并且不会对信号特征造成影响。②适应性，EMD 算法可以对不同频率和幅度的信号进行分解，并且可以根据信号自身的特征进行分解，因此具有很强的适应性。③高精度，由于 EMD 算法是一种局部分解方法，因此可以在每个时刻对信号进行分解，并保证分解结果的高精度性。④强抗噪能力，EMD 算法可以将信号分解为一系列 IMF，其中高频 IMF 代表噪声成分，低频 IMF 代表信号成分，可以通过滤除高频 IMF 来去除噪声成分，因此 EMD 算法具有很强的去噪能力。⑤可解释性，EMD 算法可以将信号分解为一系列 IMF，每个 IMF 代表着信号的一种特定频率成分，因此可以对信号的频率特征进行分析，具有很好的可解释性。

EMD 算法具有很强的适应性和去噪能力，并且具有很好的可解释性，因此在大地电磁时序去噪中具有很广泛的应用前景。汤井田与化希瑞（2008）首次将希尔伯特-黄变换（HHT）用于电法勘探，并利用经验模式分解法成功地消除和矫正了大地电磁信号中的工频干扰和基线漂移<sup>[36]</sup>。在此基础上，汤井田与蔡剑华（2010）等人提出了一种基于 HHT 的边界频谱估计方法。他们对如何改进 Hilbert 频谱估计的两种途径作了较为详尽的探讨，并对模拟和实测的 MT 信号进行了相应的数值实验。研究表明，该方法能有效抑制强白噪声干扰<sup>[37]</sup>。蔡剑华（2010）提出了一种基于 EMD 分解的多分辨率、可重构等特征来构建时空滤波器对大地电磁去噪的新方法。然而考虑到时间成本，他认为在长周期大地电磁信号的实际应用方面，经验模态分解仍需要进一步改进<sup>[33]</sup>。由于 MT 信号具有非线性、非平稳、非最小相位等特性，罗皓中（2012）提出了一种方法：将 EMD 与小波变换结合，对时序信号进行分解。该方法首先使用 EMD 将信号分解为多个 IMF，然后通过小波阈值去噪对选定的 IMF 分量进行去噪，最后重构信号<sup>[38]</sup>。汤井田（2018）在时频域 Hilbert—Huang 变换的筛选基础上，结合经验模式分解法的多尺度滤波特点，实现了对 MT 噪声分布的高效分析和压制<sup>[39]</sup>。汤井田（2019）利用 EMD 分解获得的 IMF 再通过 Hilbert—Huang 变换来计算得到大地电磁功率谱和阻抗估计<sup>[40]</sup>。

#### 1.2.1.5 数学形态滤波

数学形态滤波（Mathematical Morphological Filtering, MMF）是一种非线性滤波方法，它基于形态学的基本操作（如膨胀和腐蚀）对信号进行滤波处理。其核心思想是使用结构元素来改变信号的形态，以此去除噪声或弱化信号中的某些特定部分<sup>[41]</sup>。在时间序列中，数学形态学滤波可以用于去除不同类型的噪声，如随机噪声、尖峰噪声和周期性噪

声等。此外，它还可以用于信号的分析 and 特征提取，如求解信号的极值、边界等。因此，数学形态滤波在许多领域都有广泛的应用<sup>[42-46]</sup>。

数学形态学滤波方法以结构元素为基础，结构元素是一种小型模板，可以在信号上滑动，用于检测信号中的特定模式或形状。在大地电磁时间序列中，可以利用结构元素来检测信号中的极值点或波峰、波谷等特征，从而进行信号去噪和滤波。常见的结构元素有线性结构元素、圆形结构元素等。而主要方法包括膨胀、腐蚀、开运算和闭运算等操作。其中，膨胀和腐蚀是形态学滤波的基本操作，可用于扩大和缩小信号特征。膨胀运算是将结构元素与信号进行叠加，取叠加后的最大值作为输出结果的运算。腐蚀运算是将结构元素与信号进行叠加，取叠加后的最小值作为输出结果的运算。其定义如下：

$$(S \oplus B) = \max_{(i,j) \in B} S(x+i, y+j) \quad (1-1)$$

$$(S \ominus B) = \min_{(i,j) \in B} S(x+i, y+j) \quad (1-2)$$

其中， $S$ 为输入信号； $B$ 为结构元素； $\oplus$ 表示膨胀运算符号； $\ominus$ 表示腐蚀运算符号； $(i, j)$ 是结构元素 $B$ 中的元素坐标； $(x, y)$ 表示信号 $S$ 中的实处坐标。

在数学形态滤波中，通过对信号进行膨胀和腐蚀运算，可以实现对噪声的抑制。具体来说，通过对信号进行腐蚀运算可以消除噪声中的高频成分，对信号进行膨胀运算可以平滑信号中的低频成分。在实际应用中，可以通过调节结构元素的大小和形状，以及膨胀和腐蚀运算的次数和顺序，来达到不同的滤波效果。通过级联膨胀和腐蚀，可以构成如下开运算和闭运算：

$$S \circ B = (S \ominus B) \oplus B \quad (1-3)$$

$$S \cdot B = (S \oplus B) \ominus B \quad (1-4)$$

其中， $\circ$ 和 $\cdot$ 分别表示开运算和闭运算。开运算是先进行腐蚀再进行膨胀的操作，可以用于去除噪声和细小物体，同时保留信号的整体形态特征。闭运算是先进行膨胀再进行腐蚀的操作，可以用于填补信号中的小孔和断裂，同时保留信号的整体形态特征。通过不同的结构元素和运算次数，可以得到不同的滤波效果。开运算和闭运算常用于预处理信号，提取目标特征，去除噪声等。

数学形态学滤波可以有效地去除各种类型的噪声，包括高斯噪声、椒盐噪声等。且相比于一些线性滤波方法，数学形态学滤波可以更好地保留信号的局部特征，如峰值、边缘等，从而更好地描述信号的形态。其次，数学形态学滤波的算法简单，仅仅涉及加减等，运算速度较快，适用于对大量时间序列进行去噪处理。数学形态学滤波还可以对不同种类的时间序列数据进行处理，对异常点、离群值等有很好的鲁棒性。基于以上优点，数学形态滤波已被广泛应用于大地电磁时序去噪领域。李晋（2011）提出了一种基于数学形态学滤波的去噪算法，根据结构元素的特性设计了数学形态学滤波器，通过滤



波性能构造元素类型选择程序。最后讨论了其在大地电磁测深数据处理和强干扰分离中的应用<sup>[47]</sup>。汤井田（2011）出了一种基于数学形态学滤波的噪声抑制新方法，能消除大地电磁测深数据的较大尺度干扰，同时保持原始信号的主要特征<sup>[48]</sup>。汤井田（2011）提出了广义形态学组合滤波器，以消除大地电磁测深数据中的大尺度扰动和基线漂移。该方法能够更准确地恢复大地电磁场的原始特征，解决标准形态学算子的统计优势问题，并且具有高精度和快速的优点<sup>[47]</sup>。在矿区采集的大地电磁信号中，汤井田（2012）通过采用数学形态滤波法对大地电磁强干扰进行分离，解决了常遇到的强噪声干扰等问题。经过仿真和实测结果的验证，该方法能够有效地抑制和消除大尺度干扰和基线漂移现象，并且经过重建的信号可以很好地保持原有的大地电磁场源特征<sup>[49-50]</sup>。李晋（2012）将数学形态学理论引入大地电磁领域，对时序噪声干扰进行广义形态滤波研究，在此基础上再对重构信号进行二次信噪分离，以提升数据信噪比<sup>[51]</sup>。汤井田和李灏（2014）提出了一种基于数学形态学 top-hat 变换的去噪方法，以克服传统广义形态滤波器在提取噪声波形时可能导致低频信息丢失的问题。该方法利用 top-hat 变换的波峰和波谷检测能力，采用直线型结构元素对大地电磁时间域信号进行去噪。降噪效果显示所述方法能够消除噪声波形，并且保持时域信号的低频信息<sup>[52]</sup>。

#### 1.2.1.6 神经网络

神经网络（Neural Network）在大地电磁时序中是一种基于模式识别的数据处理方法。它由大量的人工神经元或网络层相互连接组成，可以通过学习和训练来完成特定的任务。其主要优点是①可以自适应地学习数据特征，并在一定程度上对噪声和干扰具有较强的鲁棒性。②时序信号往往存在着复杂的非线性关系，而神经网络作为一种强大的非线性建模工具，能够很好地处理这种关系。③神经网络能够自适应地调整自身的权重和偏置，从而适应不同的输入数据，使得神经网络能够很好地处理时序信号中的变化和波动。④神经网络能够同时处理多个输入数据，从而实现并行处理，提高处理效率。⑤时序信号中经常存在着数据缺失的情况，而神经网络能够通过插值等技术来处理缺失数据，从而提高数据利用率。

近年来，随着硬件、分布式系统和云计算技术的发展，特别是基于神经网络计算的进步，深度学习为包括大地电磁时间序列分类和去噪在内的许多任务提供了新的解决方案。最初，Manoj C（2003）提出使用前馈神经网络来对大地电磁时间序列进行编辑，该算法展示了网络即使在高噪声环境中也能挑选出信号的能力，同时表明使用人工神经网络自动编辑 MT 时间序列的可能性，但 ANN 网络结构较为简单，无法捕捉时序中波形等结构特征的影响<sup>[119]</sup>。吴小平（2006）利用 BP 神经网络优化方法，实现了电阻率二维非线性反演。与传统线性化的迭代反演比较，神经网络反演能够克服传统方法的不足、获得更好的反演结果<sup>[53]</sup>。陈阳康（2020）提出了一种 CWT-CNN 方法用于波形分类和到达拾取，尤其是对于嘈杂的合成数据和现场数据情况下，在到达拾取方面取得了比 DNN 更好的效果<sup>[54]</sup>。王涵（2022）将随机优化算法 DQN（Deep Q-Network）和 U-net 网

络引入大地电磁反演中，在一定程度上改善了大地电磁反演的精度，为大地电磁反演提供了新的技术依据<sup>[55]</sup>。针对大地电磁数据的一维反演，廖晓龙（2021）提出了一种结合了卷积神经网络（CNN）和长短时记忆网络（LSTM）的混合模型 CNN-LSTM 用于建立电阻率模型与大地电磁响应之间的复杂非线性映射关系<sup>[56-57]</sup>。王鹤（2018）在大地电磁反演中引入了神经网络算法，将遗传算法的全局寻优性和神经网络的局部寻优性充分结合。通过网络模型训练，使得求解的收敛率和计算效率都比单一神经网络算法有了更大的提升，并在反演测试中能够更加精确地接近实际模型<sup>[58]</sup>。在此基础上，王鹤（2019）提出了基于深度置信网络的大地电磁反演方法，以进一步提高大地电磁非线性反演的稳定性、运算效率及准确性。这种方法能够显著地改善网络的收敛成功率和稳定性，并能保持更高的收敛效率<sup>[59]</sup>。Carbonari, R 等（2018）利用 SOM 神经网络对噪声大地电磁信号进行滤波<sup>[60]</sup>。李晋（2019）提出了一种基于 ApEn-MSE 和分步正交匹配追踪(StOMP)的大地电磁信号噪声识别与分离新方法。通过引入近似熵(ApEn)和多尺度熵(MSE)，结合 k-means 聚类来准确地识别受噪声干扰的数据段，然后使用 StOMP 用于噪声抑制，最后重建了高质量信号<sup>[67]</sup>。刘晓琼（2020）提出了一种将小生境粒子群（NPSO）和正交匹配追踪（OMP）稀疏分解的方法相结合的自组织竞争神经网络（SOM），实现了大地电磁高质量数据和大尺度噪声的识别和分离<sup>[61]</sup>。范振宇（2020）对大地电磁深度学习反演进行了研究，通过与传统反演方法的对比，确立了深度学习在大地电磁数据处理上计算效率的优势<sup>[62]</sup>。陈杭（2020）设计了一种具有长短期记忆架构的循环神经网络（RNN）算法来对 MT 数据进行去噪，而 RNN 受限于串行反向传播过程往往在训练效率上不占优势<sup>[116]</sup>。Sampedro（2021）使用了机器学习中的 K-Means 技术，最终得到初步的噪声情况识别方法。但 K-Means 聚类算法受初值和离群点影响大，该方法在鲁棒性方面存在不足<sup>[117]</sup>。李广（2021）出了一种新颖的 CSEM 数据处理方法，使用无监督机器学习代替传统的人工干预以自动从嘈杂的数据中准确地选择最佳数据片段，然而无监督学习没有标签作为参考，评估模型的性能通常较为困难<sup>[118]</sup>。为了打破稀疏假设的限制，张良（2022）提出了一个 ResNet 残差网络来去噪，通过格拉姆角场（GAF）将一维时序信号转换为二维图像来信噪识别，再将噪声数据部分馈入残差网络，最终在保证网络退化的鲁棒性的同时取得了理想的去噪效果<sup>[63]</sup>。为了解决现有字典学习算法中使用的约束条件需要手动设置的限制，Zuo G（2022）提出了一种新的基于深度残差收缩网络（DRSN）的时间序列编辑方法来消除人文噪音。通过学习特征并分离信号和噪声，可以去除未知的电噪声，校正电阻率和相位的畸变，使电场和磁场的分布随机化<sup>[64]</sup>。李广（2022）提出了一种深度学习优化的字典学习去噪方法，使用深度卷积网络独立学习高质量 MT 数据的特征参数，然后将其作为字典学习的约束，实现完全自适应的稀疏分解。实验结果证明，该方法具有良好的适应性，可以有效的替代远程参考处理方法<sup>[65]</sup>。李晋（2023）出了一种基于深度学习的数据非线性映射方法，用于大地电磁 信噪分离，然而训练数据是通过数学函数构造而成，与实测数据仍然存在一定程度上的差异<sup>[115]</sup>。李晋（2023）

结合 CNN 和 LSTM 模型对大地电磁时序数据进行去噪处理。首先利用 CNN 学习大量噪声样本和干净数据样本之间的特征差异进行信噪识别。其次，利用识别获得的干净数据训练 LSTM 神经网络对噪声数据进行预测去噪。该方法在低频部分获得了更高质量的数据<sup>[66]</sup>。除此之外，无监督学习在大地电磁信号处理领域也有应用。

### 1.2.2 面临的主要问题

人工编辑法由于需要手动编辑，处理效率较低，而且结果极易受到数据处理人员的主观影响。其次，处理结果的稳定性和可靠性与编辑者的经验和技术水平密切相关，不同的编辑者可能会得到不同的结果。对于大量数据处理任务，人工编辑的成本较高，需要耗费大量的时间和精力，难以满足大规模数据处理的需求。受限于以上缺点，在数据处理流程中一般将该方法作为预处理步骤。

自适应滤波是一种有效的时序信号去噪方法，但是它对参考信号的要求高，且需要一个参考信号，用来估计噪声信号，如果参考信号的质量不好，如参考信号中也包含了噪声，那么自适应滤波的去噪效果会受到很大的影响。而且，由于自适应滤波系统需要使用反馈，一些系统参数的改变可能会影响系统的稳定性。如果反馈信号中包含了与参考信号相关的信息，那么这些信息也可能会影响系统的稳定性。除此之外，该方法对信号特征的要求高，效果易受到信号特征的影响，如果信号中存在非线性、非平稳、非高斯等特征，那么自适应滤波的去噪效果可能会下降。通常来说，这种方法需要输入额外的 PLI 参考信号，在大多数情况下这个参考信号并不容易得到，因此其在大地电磁领域适用范围相对较为局限<sup>[7-8]</sup>。

小波去噪可以有效地去除时序中的高频噪声，包括一些周期性的方波噪声。但对于高幅度、高频率的方波噪声，小波去噪可能会产生一些不良影响，例如振铃现象。此外，该方法的有效性在很大程度上取决于小波函数的选择，但在面对复杂的干扰信号时，选择合适的小波函数可能会变得困难。并且小波基一经选择，在分解与重构过程中将无法改变，从而限制了该方法在信号分析中的自适应性<sup>[15][25][50][67-69]</sup>。

经验模态分解通常对于周期性噪声的去除效果不太好，因为 EMD 分解是基于局部的信号特征进行分解的，而周期性噪声会在局部产生高频振荡，因此很难被分解成低频和高频部分。此外，EMD 分解过程中存在模式混淆问题，导致难以准确分离周期性噪声和信号本身。因此，对于时序中的周期方波噪声，使用 EMD 去噪的效果可能不如小波去噪或其他方法。除此之外，EMD 对噪声敏感，特别是在存在强干扰噪声时，可能会引入虚假模态或振荡，从而导致不准确的结果<sup>[36][39][70]</sup>。其次，EMD 分解的计算成本很高，特别是在处理长且复杂的信号时。EMD 基于数据局部平稳的假设，这在现实世界中并不总是成立。在存在非平稳数据的情况下，EMD 可能无法提供准确的分解结果。并且 EMD 方法是一种基于经验的信号处理方法，其形成没有一个完整而严密的理论体系作为依据。综上所述，尽管基于经验模式分解的方法在某些情况下可能具有一定的合

理性，但目前的判别方法并不总是可靠，它对不同输入信号的消噪效果的稳定性还存在着不足<sup>[68-70]</sup>。

数学形态滤波可能无法有效地去除某些特定类型的噪声，例如高频或脉冲噪声。数学形态滤波还会改变信号的形状和幅度，这种变形可能会导致某些信号特征的丢失或不准确，从而影响信号的分析 and 解释。其次，该方法运算复杂度较高，需要进行多次膨胀、腐蚀等形态学操作，因此计算成本较高。对于较长的时间序列或需要实时处理的数据流，可能会导致计算资源的瓶颈。形态学滤波的效果主要依赖于所选取的构造元素的尺寸和形状。如果结构元素选择不当，可能会导致信号特征的误差或丢失。需要指出的是，对于长周期高振幅噪声，无法实现有效的端到端的一次滤波，缺乏自适应性和泛化性。

神经网络虽然已经在各个领域都有了很好的泛化，但仍然存在着一些共同的问题有待解决。首先，神经网络需要大量的数据进行训练，否则很容易出现过拟合的情况。其次，神经网络中的模型参数很多，需要耗费较多的计算资源进行训练和推理。另外，由于神经网络中的模型参数过多，导致其对于模型的结果可解释性较差，很难对模型的输出进行解释和分析。而且神经网络大多都是用的监督学习，当获取的训练数据不具有普遍代表性时，学习到的规则可能不完整。那么使用这些规则进行预测可能会进一步导致不可靠的结果。通常情况下，监督学习需提前构建训练库，这是一项非常耗时耗力的工作。

## 1.3 本论文的主要研究内容及结构

### 1.3.1 主要研究内容

大地电磁测深技术在过去多年的发展中，在理论和技术上的研究已日趋成熟。但是“死区”（1.5~5 KHz）问题和强噪声干扰问题一直是目前该领域的痛难点。虽然在引入多种识别和去噪的技术手段之后，这些问题得到了改善，但并没有得到彻底解决。如今，已有大量基于频域去噪的相关工作发表，而时域去噪这一问题仍然没有较为突破性的进展。在该领域，理想的方法就是将大地电磁采集时序中的有效信号和强噪声干扰完全分离，以获得高质量的大地电磁信号。

深度学习作为一种先进的机器学习方法，其主要优势在于其强大的非线性映射和泛化能力。只要提供足够的数据和标签信息，模型就可以自动学习并提取出时间序列中的特征。此外，深度学习具有端到端的学习能力，能够将输入和输出之间的映射关系直接建立，不需要手工设计特征和规则，从而可以避免人为因素的干扰。同时，深度学习的可扩展性也使得它在处理大规模数据时具有很好的性能表现。另外，深度学习还具有自适应性，即能够自动调整模型的参数以适应不同的数据分布和任务需求。这使得深度学习在处理复杂、非线性时序数据时能够更好地捕捉数据的内在规律，并且能够应对数据中存在的噪声和干扰，能够在实际应用中处理各种不同类型、不同分布的数据，具有较强的适应性。深度学习还能够学习多层次的抽象特征表示，这使得模型能够对数据进行

更深入的理解和分析。与传统的时序分析方法相比，深度学习在处理非线性、非平稳的时序数据方面表现出了更好的效果。

受到以上结论的启发，以及深度学习在其他地球物理领域的积极应用，本文将深度学习算法应用于大地电磁信号信噪识别与分离，具体内容如下：

(1) 针对大地电磁“死区”问题，提出基于卷积神经网络的天电信号自动识别和提取方法。该方法的主要思路是将 VGG 网络应用于大地电磁数据中的天电信号识别，以自动提取出信号中的关键特征。由于天电事件的不频繁性和不可预见性，实际勘探中通常需要采集非常庞大的长周期冗余数据，且面临严重的噪声干扰。在该问题上，传统的手工特征提取方法效果较差，而卷积神经网络可以更好地提取信号中的特征，弥补传统方法的不足。在使用 VGG 网络进行天电信号识别后，可以使用这些信号来估算视电阻率和相位，从而提高阻抗估计的准确性。这种方法的优点在于它可以减少手工处理和特征提取的工作量，同时提高了识别和估算的准确性，使得对大地电磁数据中的“死区”问题有更好的解决方案。

(2) 针对大地电磁时间域去噪问题，提出基于自监督学习的音频大地电磁时间域去噪方法。通过对原始数据进行预处理和分析，制作高精度样本掩码。搭建改进的一维 U-net 网络基本框架，设计基于 MSE 和 SSIM 的复合损失函数，采用多种评价指标监控模型训练过程，使用基于模拟退火策略的优化器优化学习过程。并采用模拟加噪数据和实测数据来验证网络性能，讨论不同噪声的幅值和类型对去噪效果的影响。最终，将训练好的模型应用于实测数据中，以有效地去除大地电磁时间域信号中的噪声，提高信号质量，从而为后续数据处理和分析提供更加准确和可靠的基础。

### 1.3.2 本文结构

第一章 绪论。主要介绍论文研究目的与意义，综述了目前的研究现状以及面临的问题，并提出本文的研究内容。

第二章 大地电磁测深法与噪声。主要介绍了大地电磁测深法的基础理论，对大地电磁场源信号的组成和频谱特点进行了阐述，并分类讨论了多种噪声的波形特征以及其对实际资料处理与解释的影响，其中着重分析了人文噪声。

第三章 基于卷积神经网络的天电信号自动识别。介绍了整体工作流程，介绍了数据集制作方法以及模型结构设计，详细阐述了包括损失函数设计、评价指标选取和各种超参数选择在内的模型训练细节，展示了模型训练最终结果。

第四章 基于自监督学习的音频大地电磁时间域去噪。介绍了整体工作流程，解释了数据集制作策略，介绍了模型整体网络结构以及改动，重点讨论了复合损失函数和多尺度掩码的关键作用，分析了评价指标选取原则，展示了模型训练细节。最后通过模拟实验验证模型训练结果。

第五章 实测数据结果。以南京、武汉实测大地电磁信号为例，重点研究不同信噪比

下的识别效果，对比处理前后的资料解释，验证流程的合理性和可行性，讨论和总结神经网络对解决“死区”问题的意义。针对贵州等地的大地电磁实测数据，对比研究了本文方法与传统方法去噪效果的好坏，最后建立基于自监督学习的大地电磁资料处理流程。

第六章 总结与展望。总结本论文的主要研究成果，指出进一步的研究方向与建议。

## 第二章 大地电磁测深及其噪声

大地电磁测深法是由 A.N.Tikhonov 和 L.Cagniard 于 20 世纪 50 年代初提出的基于电磁感应原理来研究地电结构的一种地球物理勘探方法。它以天然交变电磁场作为场源,当天然交变电磁场入射地球表面后,在地下以波的形式传播。由于电磁感应的作用,在地表观测点处测得的电磁场将携带地下介质电阻率分布的信息。由于趋肤效应的作用,即高频电磁场穿透浅,低频电磁场穿透深,在场源和接收点间距不变的条件下,改变电磁场的频率来进行测深,其频响将反映着地壳内电性的垂向分布情况<sup>[71]</sup>。大地电磁适用于研究地下垂向电性结构和地下电导率分布。它无需人工供电,成本较低,施工便利,且具备任务效率高、勘探深度大、分辨率高、地形影响小、高阻屏蔽作用弱等优点,因此在矿产勘探、地质勘探、地下水资源评价、环境地球物理、工程地质勘察等领域有着广泛的应用。

### 2.1 大地电磁测深基本原理

大地电磁测深法假设天然交变电磁场所产生的电磁波为垂直入射的平面波,根据麦克斯韦方程组,可以得到交变电磁场的传播方程:

$$\nabla \times \mathbf{E} = -\frac{\partial \mathbf{B}}{\partial t} \quad (2-1)$$

$$\nabla \times \mathbf{H} = \mathbf{J} + \frac{\partial \mathbf{D}}{\partial t} \quad (2-2)$$

$$\nabla \cdot \mathbf{B} = 0 \quad (2-3)$$

$$\nabla \cdot \mathbf{D} = q \quad (2-4)$$

其中,  $\nabla$  为哈密顿算子,  $\mathbf{E}$  为电场强度 (V/m),  $\mathbf{H}$  为磁场强度 (A/m),  $\mathbf{B}$  为磁感应强度 (Wb/m<sup>2</sup>),  $\mathbf{D}$  为电通量密度 (C/m<sup>2</sup>),  $\mathbf{J}$  为电流密度 (A/m<sup>2</sup>),  $q$  为自由电荷密度 (C/m<sup>3</sup>)。  $\nabla$  为哈密顿算子, 定义如下:

$$\nabla = \frac{\partial}{\partial x} \mathbf{i} + \frac{\partial}{\partial y} \mathbf{j} + \frac{\partial}{\partial z} \mathbf{k} \quad (2-5)$$

假若电场强度和磁场强度都为谐变场, 则可以表示为:

$$\mathbf{E} = \mathbf{E}_0 e^{-i\omega t} \quad (2-6)$$

$$\mathbf{H} = \mathbf{H}_0 e^{-i\omega t} \quad (2-7)$$

其中,  $e^{-i\omega t}$  为谐变场时间因子。结合媒质本征方程:

$$\mathbf{B} = \mu \mathbf{H} \quad (2-8)$$

$$\mathbf{J} = \sigma \mathbf{E} \quad (2-9)$$

$$\mathbf{D} = \varepsilon \mathbf{E} \quad (2-10)$$

其中,  $\mu$ 为磁导率, 一般令 $\mu = \mu_0 = 4\pi \times 10^{-7} H/M$ ,  $\varepsilon$ 为介电常数, 一般令 $\varepsilon = \varepsilon_0 = \frac{1}{36\pi} \times 10^{-9} F/M$ ,  $\sigma$ 为电导率。由此可将 Maxwell 方程组转换到频域中:

$$\nabla \times \mathbf{E} = i\omega\mu\mathbf{H} \quad (2-11)$$

$$\nabla \times \mathbf{H} = \sigma\mathbf{E} \quad (2-12)$$

$$\nabla \cdot \mathbf{E} = 0 \quad (2-13)$$

$$\nabla \cdot \mathbf{H} = 0 \quad (2-14)$$

在水平均匀非各向同性大地介质中, 并且令 $E_y$ 和 $H_x$ 以及 $E_x$ 和 $H_y$ 之间是正交的, 则对称非各向同性介质的电磁场分量之间的关系为:

$$\mathbf{E}_x = \mathbf{Z}_{xx}\mathbf{H}_x + \mathbf{Z}_{xy}\mathbf{H}_y \quad (2-15)$$

$$\mathbf{E}_y = \mathbf{Z}_{yx}\mathbf{H}_x + \mathbf{Z}_{yy}\mathbf{H}_y \quad (2-16)$$

其中,  $\mathbf{E}_x, \mathbf{E}_y, \mathbf{H}_x, \mathbf{H}_y$ 为采集时序的 Fourier 变换。当测量轴和电性主轴重合时,  $\mathbf{Z}_{xx}=\mathbf{Z}_{yy}=0$ , 由此导出波阻抗的表达式为:

$$\mathbf{Z}_{xy} = \frac{\mathbf{E}_x}{\mathbf{H}_y} = \sqrt{-i\omega\mu\rho_{xy}} \quad (2-17)$$

$$\mathbf{Z}_{yx} = \frac{\mathbf{E}_y}{\mathbf{H}_x} = \sqrt{-i\omega\mu\rho_{yx}} \quad (2-18)$$

由此可推出介质的视电阻率 $\rho$ 和相位 $\varphi$ 与地面波阻抗 $\mathbf{Z}$ 的关系为:

$$\rho_{xy} = \frac{1}{\omega\mu} |\mathbf{Z}_{xy}|^2 = \frac{1}{5f} |\mathbf{Z}_{xy}|^2 \quad (2-19)$$

$$\rho_{yx} = \frac{1}{\omega\mu} |\mathbf{Z}_{yx}|^2 = \frac{1}{5f} |\mathbf{Z}_{yx}|^2 \quad (2-20)$$

$$\varphi_{xy} = \frac{180}{\pi} \arctan \frac{\mathbf{Z}_{xy}^I}{\mathbf{Z}_{xy}^R} \quad (2-21)$$

$$\varphi_{yx} = \frac{180}{\pi} \arctan \frac{\mathbf{Z}_{yx}^I}{\mathbf{Z}_{yx}^R} \quad (2-22)$$

## 2.2 大地电磁场源及其频谱特征

根据地磁振动的幅值、频率、形式和分布特征, 大地电磁场源可大致分为以下三类 [72-75]:

### (1) 天电现象



主要指大气中雷暴放电产生的瞬时电流产生的磁场引起的电磁波辐射,传播到地面上形成观测信号,频率在 1Hz 以上。通常具有高频率和强瞬态特性,振幅和波形受地球电离层和电导率结构的影响较小。天电具有宽频带的性质,根据趋肤效应,其高频分量随距离逐渐减弱,而低频分量则因其在地面与电离层间的连续反射,使其某些频段会随着传播过程的增加而增强。

从全球范围看,天电现象主要分布在赤道地区、高纬度地区和沿海地区,且具有区域性和季节性。在大地电磁测深法勘探中,音频大地电磁法便是利用其高频特性来对地下浅层电性结构进行探测。当观测点与闪电源距离较远时,闪电所激发的地面垂直大气电场会随着时间的推移而发生变化,其变化规律为<sup>[76]</sup>:

$$E(t) = \frac{1}{R^3} M \left( t - \frac{R}{C} \right) + \frac{1}{CR^2} \frac{dM(t-R/C)}{dt} + \frac{1}{C^2R} \frac{d^2M(t-R/C)}{dt^2} \quad (2-23)$$

其中,  $C$  为光速,  $R$  为闪电距离;  $M(t - R/C)$  是闪电距离时间的变化。

### (2) 太阳活动

主要指太阳风、日冕质量抛射等太阳活动引起的等离子体运动和变化所产生的电磁场扰动<sup>[77]</sup>。这些扰动主要是由太阳的磁场引起的,它们在进入地球磁场后,与地球磁场相互作用,产生地球磁场扰动,从而产生大地电磁场变化。这些扰动的频率范围一般低于 1Hz,相比雷电干扰,它们的频率更低,波长更长。

太阳活动场源主要产生的大地电磁场变化是具有全球性和周期性,周期一般为 27 天,对应于太阳活动的周期。在太阳活动高峰期,太阳活动场源的强度会增加,产生的大地电磁场变化也会更加显著。太阳活动场源的信号特征除了频率较低、波长较长外,还有较强的时空相关性,例如极光。此外,太阳活动场源也可以在短时间内产生较为剧烈的扰动,例如日冕质量抛射等事件。这些扰动可以在数小时内到达地球,引起较为明显的大地电磁场变化。

当太阳活动剧烈时,太阳风中的带电粒子会产生强烈的等离子体扰动,这些扰动会与地球磁场相互作用,导致磁层和电离层中的电子和离子发生大规模的运动和加速。这些加速的粒子会沿着地球磁力线进入大气层,与大气层中的原子和分子碰撞,产生大量的激发态原子和分子,进而引起大气层中的化学反应和辐射过程,形成磁暴。磁暴产生的地磁扰动会在大气中激发出电流,这些电流会产生大地电磁场扰动。这些扰动会影响地磁场、电离层和大气等多个层次的物理过程,所以应当在对电磁场观测和处理中特别关注此类现象。

### (3) 地磁脉动

地磁脉动指的是地球磁场在不同频率范围内的变化,其频率范围为 0.001 Hz 到 10 Hz 左右,可以分为长周期、中周期和短周期三种类型。其中,长周期地磁脉动的周期为数分钟到几十分钟,主要受到太阳风的影响;中周期地磁脉动的周期为数秒到数十秒,主要受到地球磁层的共振引起;短周期地磁脉动的周期为几百毫秒到几秒,主要受到太

阳活动和地球磁场的相互作用引起。

根据特有的频率范围和持续时间，一般将地磁脉动分为以下两大类：规则型（Pc）和不规则型（Pi）。规则型又可细分为 Pc1-Pc6，Pc1 型持续时间短，通常只有 0.2s 到 5s，振幅一般为 0.01-0.1nT；Pc2、Pc3 型持续时间稍长，通常在 5s-45s，振幅最高可达 20nT；Pc4 型持续时间为 45s-150s，振幅一般在几 nT 左右；Pc5 型持续时间范围较广，通常在 150-600s，振幅为 50-70nT 之间；持续时间>600s 的规则型统称为 Pc6。不规则型可分为三种类型 Pi1-Pi3，其频谱随时间变化差异较大，如表 2-1 所示。

表 2-1 地磁脉动分类

脉动类型		周期 (s)
Pc	Pc1	0.2-5
	Pc2	5-10
	Pc3	10-45
	Pc4	45-150
	Pc5	150-600
	Pc6	>600
Pi	Pi1	1-40
	Pi2	40-150
	Pi3	>150

大地电磁天然场源频谱特征主要包括以下几个方面：①频率范围广，大地电磁场的频率范围非常广，涵盖了从极低频率（ELF，<300 Hz）到超高频（UHF，>300 MHz）的所有频段。②存在明显的频率峰值，在大地电磁场频谱中有许多明显的频率峰值，这些峰值通常被归类为不同的地球电磁脉动（如 Pc1、Pc2、Pc3 等）。③大地电磁场频谱中不同频率峰值的强度存在空间差异，例如，Pc1 型脉动的强度在赤道地区最强，在极地地区最弱。④大地电磁场频谱的强度随时间变化，受到太阳活动和地球磁场等多种因素的影响。例如，在磁暴期间，大地电磁场频谱的强度会出现明显的增强。⑤大地电磁场频谱的特征具有明显的时空相关性，例如，Pc1 型脉动的强度在地球磁赤道区域最强，在极地地区最弱。

大地电磁天然场源电场频谱和磁场频谱在某些频率点有较好的相关性，其余频点在振幅上有明显差别，其振幅的动态范围可达 60-150dB<sup>[78-82]</sup>。根据电磁场的强度大小可分为低、中、高三个频段<sup>[81-82]</sup>，其中低频段为  $10^{-4}$ — $10^{-1}$ Hz；中频段为  $10^{-1}$ —7Hz；高频段为 7Hz 以上。从图中可以看出，在低频段中随着频率的降低，电磁场强度呈现上升趋势，并在 0.1Hz、0.01Hz 和 0.004Hz 左右出现峰值。中频段总体振幅较弱，在 1Hz 附近天然场信号存在一局部最小值，即所谓的死频带或者“死区”。在此频段，天然电磁场的功率谱通常会达到一个最小值，导致大地电磁测深曲线在该频段显示出较差的数据质量。出现死频带的原因是高频段与低频段的天然场场源机理不同，即太阳风和闪电活动产生的

信号波段并不一致，两者以 0.5Hz-5Hz 的频段作为界限，在音频大地电磁测深中，这个界限范围为 1.5KHz-5KHz。高频段电磁场强度随着频率的增高而增大，在 1KHz 附近有一个峰谷值。

## 2.3 大地电磁噪声源

大地电磁场信号非常微弱，因此在观测时很容易受到噪声的影响，根据不同的噪声来源，影响大地电磁观测的噪声主要可以分为四类：场源噪声、地质噪声、人为噪声和随机噪声<sup>[81]</sup>。

### 2.3.1 随机噪声

大地电磁中的随机噪声是指不具有明显场源、地质或人为起源的噪声信号，其主要特点是随机性和广谱性。这些噪声信号可能来源于自然界的各种物理过程，如风吹、地表微动等，也可能受到各种仪器设备的影响，如观测系统本身所固有的噪声。随机噪声通常导致各道噪声不相关、信噪之间也不相关，给大地电磁场的观测和分析带来了很大的困难，不过该噪声可以通过多窗口叠加的方式予以消除。

### 2.3.2 场源噪声

场源噪声主要来自天电活动和人类设备的高频电磁噪声。这些噪声信号可以在一定条件下作为大地电磁测量的场源，但通常会对电磁勘探的结果产生负面影响。在电离层下界面和地球表面之间反复反射的过程中，由天电活动产生的电磁波可以形成舒曼共振。这种共振现象会使某些频率的能量变得更强，而使某些频率的能量变得更弱。除此之外，天电活动还具有频率高，强度大等特点。在观测点与天电活动之间不满足远区条件的情况下，电磁场信号表现出非平面波场特征。在这种情况下，观测数据中会出现强度极大的高频干扰，这些干扰信号的强度远远超过天然电磁场信号，最终占据观测数据的主要成分，导致观测结果严重失真。

场源噪声在时间序列上较难识别，而在视电阻率及相位曲线上则表现得较为明显：在对数坐标系上，含噪视电阻率曲线呈 45° 倾角变化趋势，而相位曲线趋于 0°。目前，此类噪声在实际资料处理中仍然没有一个有效的解决方法。

### 2.3.3 地质噪声

地质噪声主要是由地表的地形起伏和地下浅层介质的非均匀性等因素引起的，一般也称为静态效应和地形影响<sup>[83-82]</sup>。此类噪声具有的低频特性往往引起相邻测点的视电阻率曲线存在上下平移现象，而平移程度与频率无关，故相位曲线基本不受影响<sup>[84]</sup>。

对于此类噪声，前人提出了许多方法尝试予以解决。针对地形起伏因素，可以使用 EMAP 法<sup>[85]</sup>、分解法、直接校正法<sup>[86]</sup>和联合反演法<sup>[87]</sup>等校正方法；针对浅层非均匀体，

可以使用相位张量分解<sup>[88]</sup>、全张量阻抗分解<sup>[89]</sup>、G-B 分解<sup>[90]</sup>等张量阻抗畸变分解方法进行校正。

### 2.3.4 人文噪声

人文噪声包括人类活动所产生的各种电子设备和信号干扰，如城市中的电力传输系统（交流高压线、电气设备）、现代交通工具（汽车、火车等）、通信设备（无线电台、雷达站、有线广播、载波电话、电台等）、工厂的机械震动（机器振动、输送带振动、点火开关等）和电子设备的运行等。此类噪声的特点是噪声能量大，频率在几十赫兹到 10KHz 范围内，使得大地电磁场背景变得复杂，对于大地电磁信号的连续性和光滑性产生了显著影响。

人文噪声一般离观测区较近，无法满足信号为平面波的假设，并且其能量远远大于天然场源信号能量，使得有效信号被噪声干扰彻底淹没，极大地降低了信号信噪比，给观测带来灾难性的困难和挑战<sup>[82]</sup>。因此，在野外开展大地电磁勘探任务时，应当远离城市等人类活动丰富的地方，恰当选取仪器接收方位，减少通道增益的同时加大对特定频率的压制能力，在选取测线及测点时，应尽量远离高压输电网和公路等干扰源。

人文噪声根据时间域波形特征可以分为以下几类：

#### （1）类脉冲噪声

脉冲噪声指的是出现在电磁场中的突发干扰信号，其多存在于电场中，有时也存在于磁场，其特点是持续时间非常短，通常只有几个毫秒到几十毫秒，由于其持续时间非常短暂，所以不会对大地电磁场的长期变化产生显著的影响，但会对短时段内的测量结果产生很大的干扰。这种脉冲噪声可以由各种因素引起，如雷击、地下游散电流、人造电磁脉冲等<sup>[91]</sup>。在时域信号中的具体表现是某一时间点的幅值通常会显著地高于正常信号的幅值，如图 2-3 所示。




图 2-1 类脉冲噪声

## (2) 类方波噪声

方波噪声是大地电磁勘探中对原始数据影响最为严重的一种噪声。此类噪声具有高幅值、宽频带、周期性、非随机性等特点，在时域上表现为一个周期性的波形，波形上升和下降时间较短，振幅比较稳定，类似于方波的形状。在频域上表现为包含多个奇次谐波的波形，其能量分布集中在高频区域，频率范围通常在几十赫兹至几百千赫兹。这种噪声的主要来源是人类活动，例如电力系统和电气设备的开关操作、交通运输中机械震动、矿集区机动车辆的点火系统和产生电火花的机器，并且常常贯穿于整个勘探过程中。

因为方波噪声对电道数据的影响较大，而对磁道数据的影响较小，若原始数据中存在大量的方波噪声，那么所计算得到的视电阻率和相位结果通常会呈现出严重的近源效应。即在双对数坐标系下，视电阻率呈  $45^\circ$  角上升趋势，相位曲线趋于  $0^\circ$  [92-93]。如图 2-4 所示，方波干扰会造成数据与零点基线之间的偏差，导致数据段的总体偏移，从而产生了一个很长周期的噪声波形，并且具有很好的相关性。




图 2-2 类方波噪声

## (3) 类充放电三角波噪声

类充放电三角波噪声在时间序列上的特点是波形呈现出带有快速上升和缓慢下降的三角波形，形态更加类似于充放电过程，且一般都以一正一负的形式成对出现，各噪声间振幅和形态相似，出现间隔较短。在频谱上，具有较高的频率分量，通常在数百赫兹到数千赫兹的范围内，其频谱形状呈现出倒尖峰状或者带状，并且噪声的能量分布比较平均，主要集中在高频段。这种噪声的主要来源是人类活动，例如电力系统和电气设备的充放电过程、交通运输中机械震动、建筑施工等。

与方波噪声相反，充放电三角波噪声一般只存在于磁道，为磁相关噪声，如图 2-5 所示。此类噪声在局部具有较强的能量，可能会造成数据段的总体偏移，并且毫无规律

性。它的振幅比宽度更显著地影响较高的频率，当宽度变窄时，它的影响范围将扩展到更高的频率。若原始资料中含有较多的这类噪音，则计算所得到的视电阻率曲线常呈现出较强的近源效应。

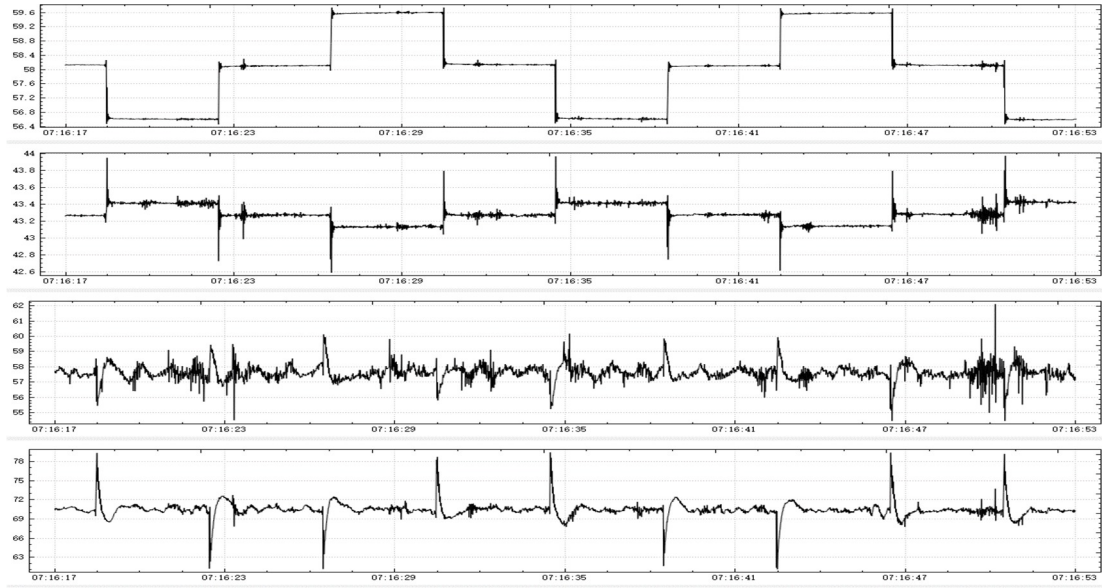


图 2-3 类充放电三角波噪声

#### (4) 类阶跃噪声

类阶跃噪声在波形上呈现为台阶状，在时序中具体表现为一个突然的幅度变化，在一个较长时间内趋于稳定，随后急剧下降，导致数据产生整体性偏移，前后数值落差较大，严重影响数据的连续性和稳定性，如图 2-6 所示。在采集到的原始数据中，阶跃噪声的形态比较复杂，包含了不同频段的能量，其具体表现形式与噪声来源有关，通常是由于电气设备的开关操作引起的电压或电流突变所产生的。




图 2-4 类阶跃噪声

### (5) 工频噪声

工频噪声在时域上表现为具有一定周期性的波动，呈现出规律性的重复波形。在波形上，周期噪声通常表现为连续的正弦波或余弦波，其波形通常具有较为平滑的曲线，波峰和波谷之间的过渡较为缓慢，如图 2-7 所示。与其他噪声相比，周期噪声的频率范围通常较窄，在频谱上表现为一个或多个峰值，通常某个特定频率附近（50Hz、60Hz）。工频噪声能量往往远大于正常电磁信号，从而使得信号在频率上被压制，难以被准确地提取出来。此类噪声通常存在于电道中，为电相关信号，主要对基频及其谐波频率上的阻抗估计影响较大。

工频噪声的出现通常与电力设备的运转有关，如变压器、电缆、电机、高压线、信号塔等，尤其是在工业发达、人口稠密地区，这些干扰普遍存在，其强度与距离这些设备的远近也有关系。




图 2-5 工频噪声

## 2.4 本章小结

本章首先对大地电磁测深的基本原理和理论基础进行了阐述，介绍了大地电磁勘探是基于天然交变电磁场所产生的电磁波为垂直入射的平面波的假设。然后对信号场源进行了分类讨论，总结分析了大地电磁场源特征及其频谱特征，从振幅谱图中引出“死区”问题。

着重介绍了大地电磁噪声源种类，分析了各类噪声的时域和频域特点，并对各种噪声干扰对大地电磁信号的影响进行了分析。其中，详细介绍了人文噪声中常见的类脉冲噪声、类方波噪声、类充放电噪声、类阶跃噪声和工频噪声的来源和特征规律，从采集时序角度讨论了上述噪声对大地电磁信号质量的影响。

## 第三章 基于卷积神经网络的天电信号自动识别

为了实现相干电导率深度估计，音频大地电磁（Audio-magnetotelluric, AMT）源场必须在宽频段内保持足够的信号。然而，在实际中很少采集到高信噪比数据（S/N），其主要原因有两个：①地球电离层波导在 1.5 到 5kHz 之间的电磁场有一个衰减。②AMT 数据在信号和噪声方面本质上是非平稳的。其中，AMT 的主要信号被称为天电（sferic），它们是由全球闪电活动产生的。当天电信号较小或不频繁时，电场和磁场中的测量噪声会导致估计的视电阻率和相位曲线出现误差，从而导致模型产生很大的不确定性。

针对上述问题，本章提出了一个深度卷积神经网络 VGG 来自动识别长时间范围内冗余记录数据中的天电信号，并使用它们来准确估计视电阻率。首先，我们使用不同测区所采集的具有不同信噪比（S/N）的野外时序数据来制作训练集用以训练 CNN，然后提出了一种训练策略来解决过拟合问题。此外，我们还对使用的模型结构进行了研究和讨论，并进行消融实验来选择最终的模型结构及参数。其次，重点介绍了模型具体的训练细节以及网络优化参数的选择和评估。最后，通过实测数据验证了受到良好训练的模型的鲁棒性和泛化性。

### 3.1 引言

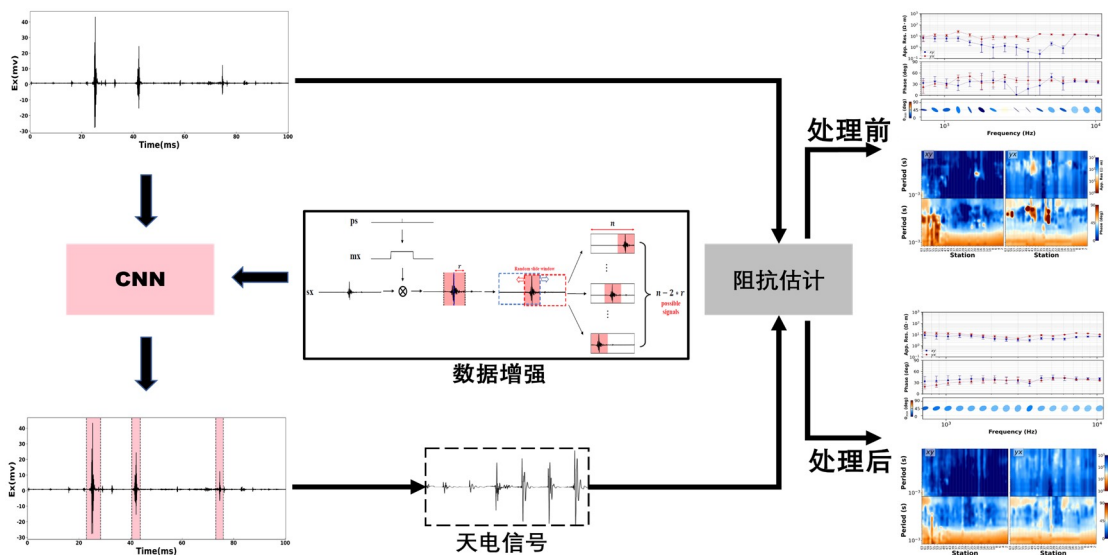


图 3-1 天电识别工作流程

本章基于 CNN 的天电信号识别和数据处理的 workflow 如图 3-1 所示。具体步骤为：首先截取一段 AMT 数据时窗，将其送入训练完毕的 CNN 模型中进行识别。若存在天电信号，则保留该数据段；若不存在，则舍弃。重复上述过程直至该测点采集时序遍历结束。然后将识别出来的天电信号数据时窗进行拼接，用于后续的阻抗估计。最后，计



算处理前后的采集数据的视电阻率和相位曲线，并进行对比。

重复上述流程直至整个测区采集数据处理完毕，即可计算得到相关视电阻率和相位伪截面以及相位张量伪截面等结果。"

## 3.2 数据集制作

在利用深度学习技术解决大地电磁反演问题时，样本数据集需要充分具备海量性、质量和多样性。只有满足这些条件，网络才能更好地泛化并获得更高的反演精度。数据集的完备性对反演结果有着直接的影响，如果在监督学习中，制作的数据集中缺乏与输入数据相似的样本，则会导致错误的预测结果。

因此，训练数据的数量和质量就显得尤为重要。在训练天电识别模型之前，我们需要对大量的 AMT 时间序列数据进行标记。考虑到不同地区对场源分布的影响，我们使用了来自三个勘测区域（即西藏，南京和武汉）的数据来准备训练数据集，分别对应着高信噪比、中信噪比、低信噪比采集数据。我们遵循 Hennessy (2018c) 提供的原则来标记正样本（即天电信号）<sup>[94]</sup>。除此之外，我们还开发和实施了一个随机数据生成策略和数据增强方法来进一步扩大训练数据集大小并提高模型的泛化性能。

### 3.2.1 数据生成

为了正确地训练网络，我们开发了一个工作流程（图 3-2），用于自动生成具有不同波形特征的大型且多样化的训练数据集。以单通道 Ex 数据为例，图中定义一个包含天电信号的时间序列段为  $sx$ 。在  $sx$  中，天电中心点的位置索引表示为  $ps$ ，并用于创建样本掩码  $mx$ 。 $mx$  序列初始化为与  $sx$  长度相同的全零序列，并且将中心点  $ps$  向两侧扩展半径  $r$  处的采样点幅值为 1。




图 3-2 数据生成工作流程

不同于一般的数据标注任务，我们在这个工作流程中采用随机采样方法来生成训练和验证数据集的正负样本。具体而言，我们将样本长度设为  $n$ ，并使用随机滑动窗口来生成正样本，如图 3-2 中的虚线窗口所示。这使得我们能够生成多达  $n - 2 * r$  个不同的正样本，每个样本包含原始时间序列中单个天电的所有可能位置，覆盖从滑动窗口左侧到右侧的所有可能位置。这种方法扩大了正样本的数量，有助于缓解样本不平衡问题，

并使我们的模型能够学习采样窗口内不同位置的天电信号特征。

按照这个工作流程，我们获得了比原始时间序列中要多得多的正样本数量。为了使训练数据具有普遍代表性，我们使用了从西藏、南京和武汉三个包含不同正样本数量和质量的测区中所采集到的时间序列数据来制作训练集，这些数据在每个时间单位中存在的天电信号的数量和振幅方面有所不同。

在我们的实验中，我们从以上三个测区中一共采集了 150 个测点的数据。我们将其中的 90 个测点划分为训练集，30 个测点划分为验证集，30 个测点划分为测试集。其中，训练集包含 30000 个正样本，验证集包含 10000 个正样本。遵循分层抽样原则，每个测区的各数据集比例划分为 6:2:2。

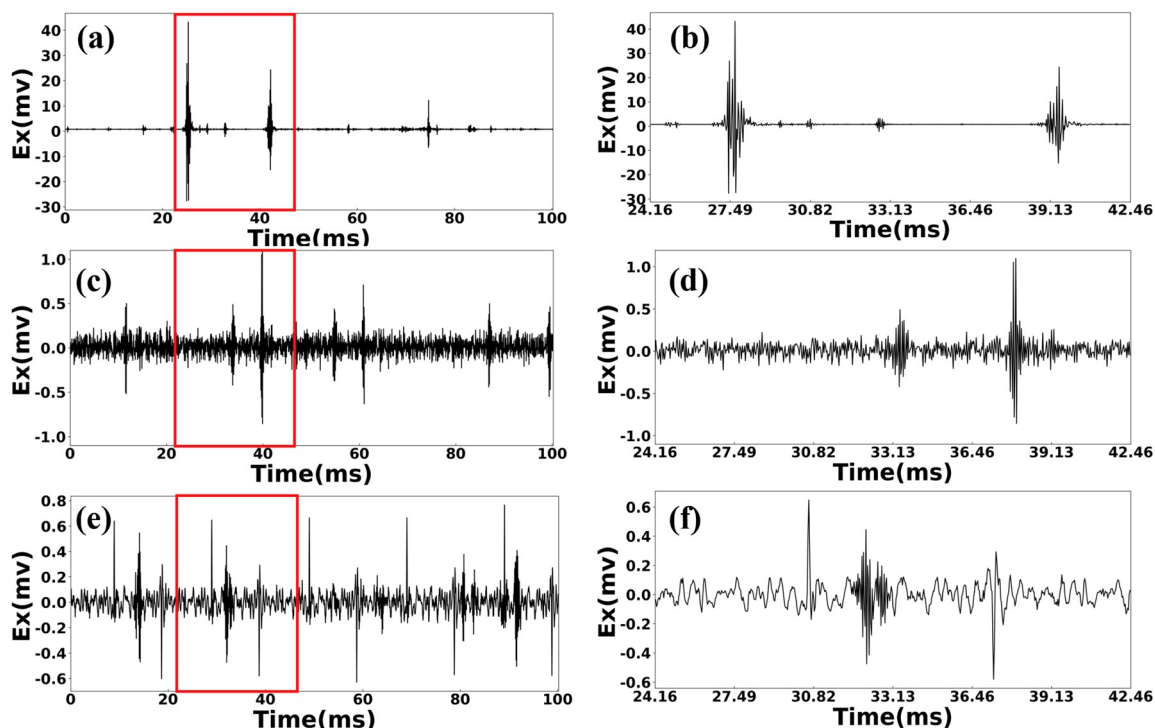


图 3-3 不同信噪比时间序列中的天电波形特征 (a)西藏某测点 100ms 时序片段；(b)(a)中红框部分放大图；(c)江苏某测点 100ms 时序片段；(d)(c)中红框部分放大图；(e)湖北某测点 100ms 时序片段；(f)(e)中红框部分放大图

图 3-3 展示了具有不同信噪比的时间序列中的天电波形特征。图 3-3-a 显示了来自西藏山南某测点的 100 ms 时间序列片段，通常包含大约 3~4 个高振幅信号和若干随机出现的持续时间长达 1.5 ms 的小振幅信号簇。为了提供更多的细节，图 3-3-b 展示了图 3-3-a 中时间序列红框部分的放大视图，从中我们可以看出天电信号十分明显，其幅值高达几十毫伏，且明显高于背景噪声水平。该类数据采集自远离城市干扰的高海拔地区，具有较高的信噪比，并且此类高质量数据是理想的训练样本。图 3-3-c 显示了江苏南京某测点的时间序列片段。勘探区位于城市周边，所采集到的数据受到一定程度的人文噪声干扰。通过观察采集时序数据，我们发现该测区勘探期间受到持续噪声源（例如，

变压器和电源线)的强干扰。同样地,图 3-3-d 显示了图 3-3-c 中时序片段的细节图,我们可以观察到这些天电信号在数量和振幅上都相西藏测区较低,这也反映了不同地质条件下采集时序中所呈现出来的多样性和复杂性。图 3-3-e 显示了湖北武汉某测点的时间序列片段,该测点天电信号几乎被复杂的电磁噪声和周期性脉冲等强干扰所淹没。图 3-3-f 展示了更为细节的部分,想要从图中区分该时窗中识别和提取天电信号极具挑战性。然而,此类时序数据正是 AMT 野外勘探中最为常见的数据种类之一,因此我们也将此类样本包含在我们的训练数据集中。

### 3.2.2 数据增强

数据增强是提高深度模型性能最有力的方法之一,并且在地球物理问题中有一些成功的应用实例<sup>[95]</sup>。在本文中,我们采用简单且有效的数据扩充来进一步增加训练数据集的多样性。

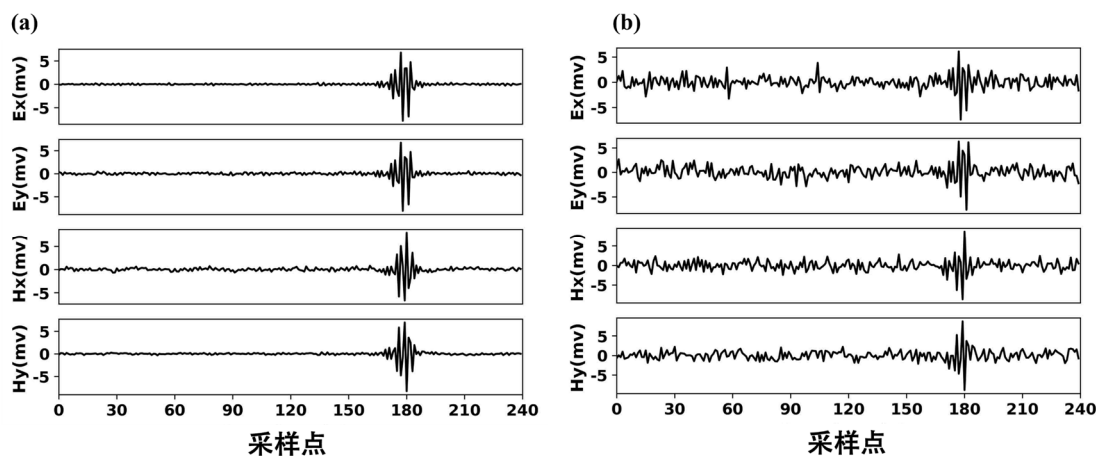


图 3-4 添加随机噪声进行数据增强 (a)未添加随机噪声时序; (b)添加随机噪声时序

为了满足同分布数据的假设并保持天电波形不被破坏,我们在生成用于训练的输入时间序列数据时向数据中添加了随机噪声。图 3-4 显示添加的噪声使时间序列看起来更真实。为了增加训练数据的泛化,同时避免天电信号被添加的噪声淹没,每个训练样本所添加的噪声的信噪比随机定义在 $[0, 1]$ 的范围内。

### 3.3 模型结构设计

从时间序列中进行天电信号识别可以被视为具有滑动窗口的分割或分类任务。然而,几乎不可能为整个 AMT 时间序列制作完整的逐点分割标签,因此我们考虑使用滑动窗口进行分类,而不是逐点分割。

我们将时间序列记录中的天电识别任务视为波形分类问题。VGG19 是一种流行的深度卷积神经网络架构<sup>[96]</sup>,最初是为图像分类任务设计的,但它也可以适用于一维信号

分类问题，如心电图识别。VGG19 的一维变体可以接收一维输入信号并应用一系列卷积层和池化层从信号中提取高维特征。然后可以使用这些特征将输入信号分类为天电事件或非天电事件。通过使用 VGG19，我们可以从时间序列记录中实现天电信号的高精度识别。因此，我们考虑使用 VGG 的一维变体来完成的任务。

本章网络基于一维 VGG 结构，该结构以其深度和简洁的设计而闻名，允许在提取更多信号特征的同时控制参数，并已广泛用于许多分类任务。在网络中，输入映射到分类类别的输出，在加深的网络结构层中以低秩表示特征，然后通过几个全连接层进行融合，最终由另一个全连接层进行分类。网络结构如图 3-5 所示，网络的输入是一个由  $E_x$ 、 $E_y$ 、 $H_x$  和  $H_y$  通道组成的 AMT 时间序列片段，输出是一个二分类值。网络的主干由两部分组成：特征提取块和分类块。特征提取块由五个下采样块组成，每个块具有四个具有内核尺寸为  $1 \times 3$  的卷积层、一个具有内核尺寸为  $1 \times 2$  且步距为 2 的最大池化层，然后是一个整流线性单元 (ReLU)<sup>[97]</sup>。该块通过连续堆叠此类卷积层和池化层来逐步提取抽象数据表示，从而扩大卷积层的感受野并提高特征提取性能。分类块由两个具有完全连接层的特征聚合块、批量归一化层 (BN)<sup>[98]</sup>和 ReLU 组成，后跟一个用于最终输出分类的神经元。

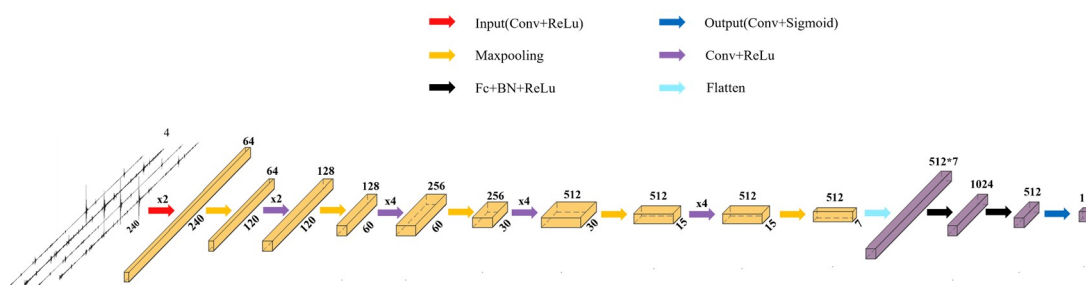


图 3-5 1D-VGG19 网络结构

我们的网络通过逐渐增加通道的深度来丰富学习到的特征图。该网络使用全连接层系统地聚合多通道信息。这些层无损地聚合了卷积层提取的特征信息，有助于利用全局信息进行精确预测。最大池化层有助于捕获时间步长的变化，简化网络复杂度，同时保持平移不变性，其中较小的池化内核更适合捕获更详细的信息并准确描述天电信号波形特征等。

## 3.4 模型训练细节

### 3.4.1 损失函数

如前所述，天电识别是一个二元分类问题，每个样本根据对应的固定长度采样点进行分类。在许多二元分类问题中，二元交叉熵损失 (Binary Cross-Entropy, BCE) 是用

于衡量假设类别和真实类别之间差异的最常见损失函数。

首先, 为了反映概率分布, 网络输出需要通过 Sigmoid 激活函数映射到 0 到 1 之间的取值范围内。随后, 可以通过该值来计算二元交叉熵损失。其中, Sigmoid 激活函数定义如下:

$$\Omega(x) = \frac{1}{1 + e^{-x}}. \quad (3-1)$$

二元交叉熵损失可以在数学上定义为:

$$I(x, y) = \{\mathcal{L}_1, \dots, \mathcal{L}_N\}^T, \quad (3-2)$$

其中,  $N$  表示样本批次大小 (Batch size),  $\mathcal{L}$  的定义如下:

$$\mathcal{L}_{BCE} = -\sum_{i=1}^n y_i \log(\Omega(x_i)) - \sum_{i=1}^n (1 - y_i) \log(1 - \Omega(x_i)), \quad (3-3)$$

其中  $x_i$  表示网络的输出, 并在经过 sigmoid 激活函数  $\Omega(x_i)$  后转换为类别概率。  $y_i$  代表二分类的真实标签, 取值为 0 或 1。  $n$  代表所有样本的个数。然而, 天电识别是一个样本不平衡的任务, 这个问题将迫使网络偏向于学习更多的非天电信号 (即负样本) 特征, 这最终会导致更多真正的正样本被错误地预测为负样本。为了解决这个问题, 需要使用一些针对样本不平衡问题的技术, 例如过采样和欠采样, 以平衡训练数据中不同类别之间的样本数量差异, 从而提高网络的性能和稳定性。

为了解决样本不平衡问题, 在这里我们将损失函数修正为加权二元交叉熵损失 (Weighted Binary Cross-Entropy, BCEW)。在数学上, BCEW 被定义为:

$$\mathcal{L}_{BCEW} = -\beta \sum_{i=1}^n y_i \log(\Omega(x_i)) - (1 - \beta) \sum_{i=1}^n (1 - y_i) \log(1 - \Omega(x_i)), \quad (3-4)$$

其中  $\beta$  表示负样本与总样本的比率,  $1 - \beta$  表示正样本与总样本的比率。

### 3.4.2 评价指标

在训练主流二分类网络时, 往往存在多个评价指标, 包括准确率 (Accuracy)、精确率 (Precision)、召回率 (Recall) 和 F1 分数 (F1 score) 等, 这些指标从多个角度定量评估预测结果。

本章中, 我们采取相同的评价指标对我们的模型进行评估。具体而言, 各指标的定义如下:

$$A = \frac{TP + TN}{TP + TN + FP + FN}, \quad (3-5)$$

$$P = \frac{TP}{TP + FP}, \quad (3-6)$$

$$R = \frac{TP}{TP + FN}, \quad (3-7)$$

$$F1 = \frac{2PR}{P + R}, \quad (3-8)$$

其中 $A$ 表示正确分类的正样本与总样本的比值； $P$ 表示真正样本与预测正样本的比值； $R$ 表示预测正样本与真正样本的比值； $F1$ 表示一个平衡点，即 $P$ 和 $R$ 的加权调和平均值。各符号的数学意义如表 3-1 所示。

表 3-1 二分类混淆矩阵

	真（实际）	假（实际）
正（预测）	TP（真正类）	FN（假正类）
负（预测）	FP（假负类）	TN（真负类）

附注：TPR=TP/(TP+FN)，FPR=FP/(TN+FP)

### 3.4.3 训练细节

如前所述，我们生成了 30000 个正样本用于训练。为了避免与不同测区和采集时间之间的天电波形变化相关的任何不确定性，在训练和推理过程中，输入样本的通道  $x$  将进行以下归一化处理：

$$x^* = \frac{x - \mu}{\sigma}, \quad (3-9)$$

其中， $x^*$ 是经过归一化后的输入通道， $\mu$ 和 $\sigma$ 分别是通道的均值和标准差。然后，我们通过之前讨论的数据增强方式对所有输入样本进行预处理。为了识别超 90%的天电信号，我们将样本长度 $n$ 设为 240，样本掩码半径 $r$ 设为 36。我们使用 Adam 优化器来训练我们的模型并设置参数 $\beta_1$ 、 $\beta_2$ 和 $\epsilon$ 的值分别为 0.9、0.999 和 $10^{-8}$ [99]。学习率初始化为 0.001，并在训练过程中自适应降低。具体来说，当验证指标在 30 个 epoch 内没有改善时，我们将学习率减少 0.5 倍（见图 3-6-c），以实现更好的损失收敛。此外，我们将单批量大小设置为 16，并在每个 epoch 从训练和验证数据集中随机抽取 640 和 160 个样本。我们训练我们的网络共 150 个 epochs，但从图 3-6-a 和 3-6-b 中可以看出损失在训练早期收敛，因此我们引入了提前停止策略来防止过拟合。在这里，我们设置验证数据集上的准确率作为早停策略的监控指标，并在该指标在 20 个 epoch 内没有提高时保存模型参数。

此外，我们还比较了在验证数据集上不同分类模型的评价指标、Flop 计数(GB)和处理时间(s)，并将结果展示在表 3-2 和表 3-3 中。研究结果表明，我们的研究发现，使用数据增强方法可以显著提高网络性能，准确度提高了近 2%。其中，VGG19 在大多数指标上表现最佳，而且在时间开销上也相对较低，略高于 ResNet18。这些结果也是我们最终选择该网络进行研究的重要依据。本研究训练平台基于 NVIDIA Tesla V100(32G)，在

VGG19 上训练一个 epoch 仅需 2.98 秒。

表 3-2 模型消融实验 (VGG[11,13,16,19], ResNet[18,34,50,101,152]<sup>[100]</sup>, 不使用数据增强的 VGG, 不使用数据增强的 ResNet)

网络	评价指标				
	Loss	A	P	R	F1
VGG	0.42(11)	0.883(11)	0.771(11)	0.618(11)	0.686(11)
	0.30(13)	0.914(13)	0.824(13)	0.718(13)	0.767(13)
	0.16(16)	0.935(16)	0.848(16)	0.763(16)	0.803(16)
	<b>0.08(19)</b>	<b>0.951(19)</b>	<b>0.896(19)</b>	<b>0.822(19)</b>	<b>0.857(19)</b>
VGG (不使用数据增强)	0.83(11)	0.863(11)	0.671(11)	0.569(11)	0.615(11)
	0.37(13)	0.899(13)	0.786(13)	0.654(13)	0.713(13)
	0.27(16)	0.913(16)	0.811(16)	0.673(16)	0.715(16)
	0.26(19)	0.936(19)	0.875(19)	0.777(19)	0.823(19)
ResNet	0.28(18)	0.918(18)	0.843(18)	0.779(18)	0.787(18)
	0.20(34)	0.937(34)	0.887(34)	0.791(34)	0.836(34)
	0.24(50)	0.904(50)	0.788(50)	0.654(50)	0.714(50)
	0.27(101)	0.872(101)	0.726(101)	0.583(101)	0.646(101)
ResNet (不使用数据增强)	0.34(152)	0.840(152)	0.649(152)	0.491(152)	0.559(152)
	0.46(18)	0.896(18)	0.784(18)	0.626(18)	0.696(18)
	0.25(34)	0.910(34)	0.810(34)	0.656(34)	0.724(34)
	0.28(50)	0.881(50)	0.737(50)	0.586(50)	0.652(50)
	0.30(101)	0.853(101)	0.661(101)	0.520(101)	0.582(101)
	0.46(152)	0.825(152)	0.571(152)	0.471(152)	0.516(152)

附注: A=准确率, P=精确率, R=召回率, F1=F1 分数

以上是验证数据集上平均实验的结果; 括号中的数字代表不同的版本; 对于除 BCEW 损失之外的所有指标, 较大的值表示更好的性能, 最佳结果以粗体突出显示。

表 3-3 模型参数计算量消融实验 (VGG[11,13,16,19], ResNet[18,34,50,101,152])

网络	FLOPs(GB)	训练时间(s)/epoch	推理时间(s)/测点
VGG	1.78(11)	2.39(11)	14.3(11)
	1.92(13)	2.46(13)	14.5(13)
	2.67(16)	2.57(16)	14.9(16)
	3.43(19)	2.98(19)	15.6(19)

(续) 表 3-3 模型参数计算量消融实验 (VGG[11,13,16,19], ResNet[18,34,50,101,152])

网络	FLOPs(GB)	训练时间(s)/epoch	推理时间(s)/测点
ResNet	0.32(18)	2.00(18)	14.1(18)
	1.38(34)	2.19(34)	14.4(34)
	3.11(50)	2.79(50)	15.3(50)
	6.08(101)	5.14(101)	32.4(101)
	8.71(152)	6.77(152)	47.6(152)

附注：以上是验证数据集上平均实验的结果；括号中的数字代表不同的版本。

我们在图 3-6 中提供了训练细节。图 3-6-a 显示了训练和验证损失曲线，图 3-6-b 显示了训练和验证数据集的准确度曲线，图 3-6-c 显示了学习率的衰减曲线。训练和验证的损失曲线逐渐收敛到小于 0.01 和 0.08，当优化停止时，准确率曲线在 40 个 epoch 后逐渐稳定到 97% 和 95%。这些曲线表明网络经过良好的训练，能够准确地区分正负样本。

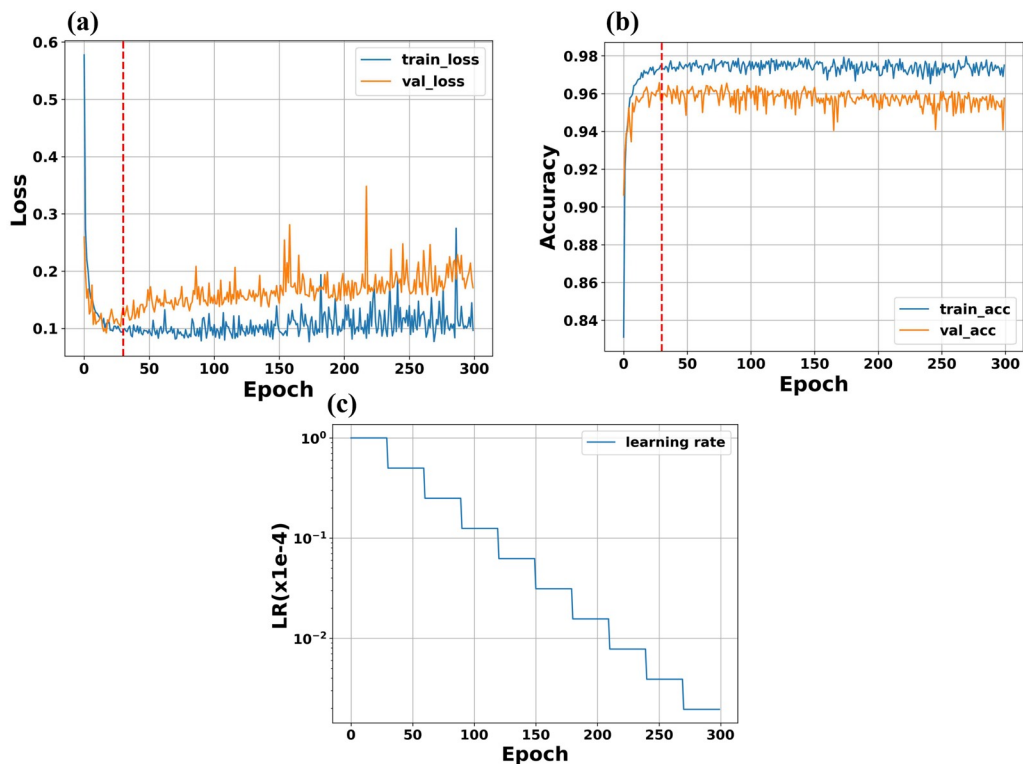


图 3-6 训练曲线 (a) 训练 (蓝色) 和验证 (棕色) 损失曲线; (b) 训练 (蓝色) 和验证 (棕色) 准确率曲线; (c) 学习率衰减曲线。红色垂直虚线表示提前停止的时期。

为了展示训练网络的性能，我们首先随机选择了测试数据集中一个测点的时间序列数据作为网络输入来验证分类结果。如图 3-7 所示，其中图 3-7-a 到图 3-7-c 展示了具有



不同信噪比的正样本的预测，而图 3-7-d 则展示了一个典型的负样本，网络准确地将其预测为非天电信号。从测试结果可以看出，所提出的模型具有较高的准确性和较强的鲁棒性。即使在低信噪比下，我们的模型也能成功地从强背景噪声水平中识别出天电信号，同时排除非信号成分。

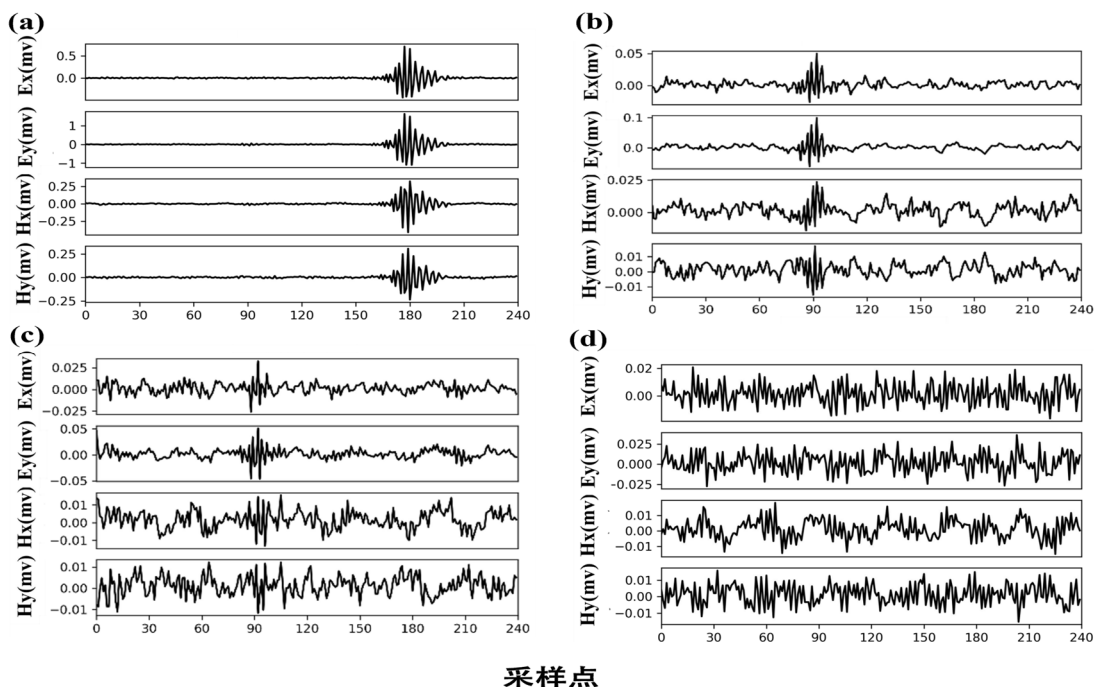


图 3-7 对具有不同信噪比样本的预测：(a) 高信噪比的正样本（预测=1，实际=1）；(b) 中信噪比的正样本（预测=1，GT=1）；(c) 低信噪比的正样本（预测=1，GT=1）；(d) 负样本（预测=0，GT=0）。

综上所述，在验证数据集和测试数据集的出色表现表明，该网络已成功学会自动识别时间序列中的信号。

### 3.5 本章小结

本章针对 AMT 死频带视电阻率估计失真问题，提出了一种深度卷积神经网络来自动识别长时间范围内冗余记录数据中的天电信号，并使用这些信号准确地估算视电阻率。我们使用从中国大陆不同地区采集的具有不同信噪比的野外时间序列数据来训练 CNN。为了解决由于天电标签数量有限而导致的潜在过拟合问题，我们提出了一种训练策略，该策略在优化 CNN 模型参数的同时随机生成训练样本，并且使用随机数据增强。与此同时，我们在训练损失收敛时停止训练和数据生成。此外，我们使用加权二元交叉熵损失函数来解决样本不平衡问题，以更好地优化网络，使用多种合理的指标来评估网络性能，并进行消融实验以优化模型超参数。广泛的野外数据应用表明，我们训练的 CNN 可以稳健地识别嘈杂时间序列中的天电信号，以进行后续的阻抗估计。

## 第四章 基于自监督学习的音频大地电磁时间域去噪

由于大地电磁信号弱等特性，其观测过程中很容易受噪声干扰，噪声严重地影响了阻抗响应参数的稳定估计，造成了测深曲线的畸变，进而影响后续反演、地质解释等工作。尤其是近现代以来，随着城市化建设飞速发展和人文活动范围不断扩大，大地电磁背景噪声问题日益严重。因此，在大地电磁资料处理中，如何有效地去除这些干扰就成为了一个很重要的课题。虽然目前的去噪技术研究是充分的，但去噪仍是具有重要意义且亟待解决的问题。

大地电磁实测资料有着干扰强信号弱、数据海量、干扰种类复杂等特点。而不同类型的噪声表现出的特征也不一样，这些复杂干扰往往在时间序列上具有明显的波形特征如类充放电三角波、类脉冲、类正弦波等噪声波形，这些噪声波形既包含易于区分的形态特征，又独具不同的几何尺寸。

在前人研究的基础上<sup>[47-51]</sup>，通过研究大地电磁时间序列中噪声波形等特点，我们首次提出使用深度学习中自监督学习思想和 U-net 网络结构来进行大地电磁时序去噪任务。本章首先介绍了一维 U-net 整体网络结构，以及在此基础上进行了一些改动，然后详细阐述了数据集的制作以及划分，重点讨论了复合损失函数以及多尺度损失掩码对于信噪识别和去噪的所起到的关键作用。其次，还将基于自监督学习的神经网络模型与传统的主流时序去噪算法进行了消融实验，通过对比来验证提出方法的高效性和优越性。最后，分别使用模拟数据和实测数据对该算法去噪处理前后的时序数据进行视电阻率-相位估计，有力地证明了自监督学习在大地电磁数据处理领域的强大能力和发展潜力。

### 4.1 引言

本研究采用基于自监督学习的方法，对音频大地电磁信号中的噪声进行识别和去除。具体工作流程如图 4-1 所示，包括以下步骤：首先选择某个测点的单通道时序数据，然后将预先制作的样本掩码序列与之相乘，以进行信噪识别，如图 4-1-a 所示。接着，将含噪时序中的噪声部分送入经过训练的 U-net 网络中，以提取噪声轮廓。随后，将含噪时序片段与网络提取出来的噪声轮廓进行差分运算，得到去噪后的时序片段，如图 4-1-b 所示。最后，将去噪部分与信号部分进行拼接处理，以得到去噪后的完整时序数据。

重复上述流程直至该测点所有通道的采集时序数据处理完毕，即可计算去噪前后的采集数据的视电阻率和相位曲线，并进行对比。

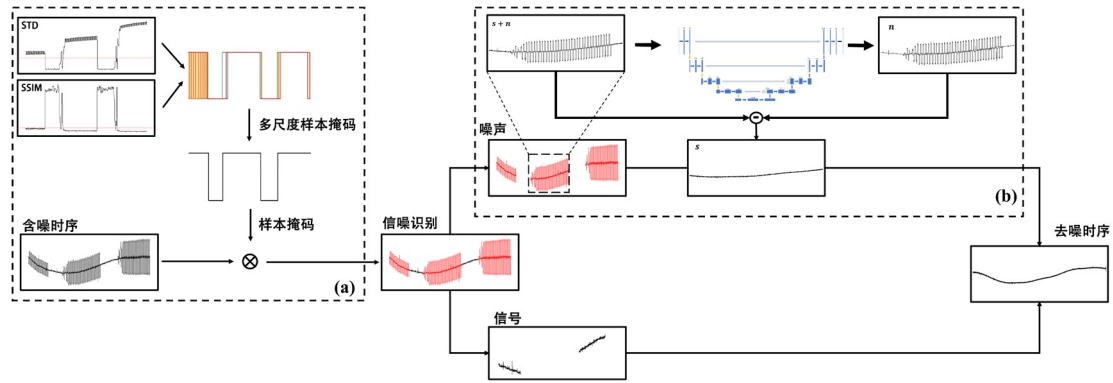


图 4-1 自监督去噪工作流程 (a)信噪识别; (b)去噪

## 4.2 数据集制作

### 4.2.1 训练样本

与前文所需要的训练样本不同,本研究的目的是在于让网络模型学习噪声波形特征,以尽可能地从时序中恢复出强干扰波形,所以我们的训练样本中应涵盖尽可能多的噪声波形种类。因此,为了满足上述条件,本研究将勘探地点选在了贵州省西北部赫章县水塘乡猪拱塘铅锌矿区,该矿集区电磁噪声环境复杂,由密集的城市、交错的电网和发达的交通网络组成,并且干扰环境复杂,存在多种噪声类型,包括相关噪声和非相关噪声。例如,在矿区,大功率直流/交流电力机车用于矿石运输,它们可以在地下产生连续的杂散电流。噪声源按活动持续时间可分为三类:持续噪声源,如变压器和电源线;间歇性噪声源,如火车、汽车和采矿机械;和随机噪声源,如一些人类活动。这些干扰在大地电磁时间域采集信号中往往以多种诸如类方波、阶跃、脉冲、类充放电三角波以及其他多种噪声共同作用所构成的复合波形的形式存在。

上述特点恰好构成了本研究理想训练样本的条件,故本次训练样本直接取自猪拱塘测区,勘探采集得到共 13 条测线 870 个测点。我们将其中的 700 个测点划分为训练集,100 个测点划分为验证集,70 个测点划分为测试集,训练集包含 110000 个样本,验证集包含 15000 个样本,测试集包含 10000 个样本。

### 4.2.2 样本掩码

掩码 (mask) 是深度学习中的常见操作,可以用来对张量进行过滤或屏蔽一些特定的元素。具体来说,掩码是一个布尔型张量,其形状与原始张量相同,用于控制哪些元素需要被保留或舍弃。在卷积神经网络中,掩码通常用于添加在损失函数位置用以进行监督,从而实现对样本特征的提取和筛选。简单而言,其相当于在原始张量上盖上一层掩膜,从而屏蔽或选择一些特定元素。

如前文所述,自监督去噪工作流程首先需要进行信噪分离,然后再将噪声部分送入网络参与训练,非噪声部分不参与训练。在这个过程中,需要对原始时序进行掩码操作。

对于自监督去噪任务中的信号序列，生成掩码的方式如图 4-2 所示，具体步骤如下：

- (1)、生成一定比例的伪随机数序列，该伪随机数序列的长度与原始信号序列相同。
- (2)、将伪随机数序列中小于一定阈值的值置为 0，其余置为 1，从而得到一个与原始信号序列长度相同的掩码序列。
- (3)、将掩码序列乘以原始信号序列，即可得到掩码后的信号序列，其中被掩蔽的部分对应的元素为 0。

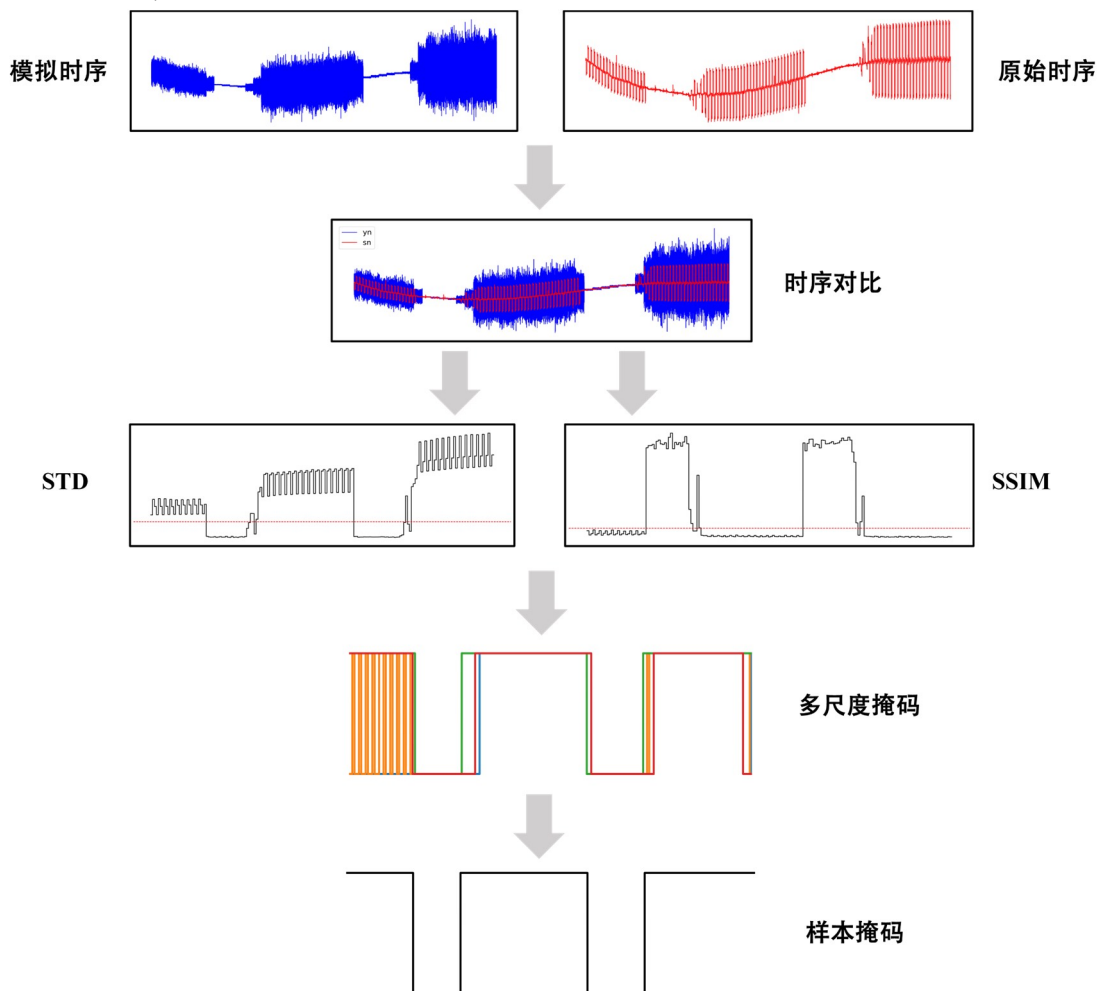


图 4-2 制作样本掩码，红色虚线代表阈值线

这样生成的掩码序列可以用于将原始信号序列中的一些比例的元素屏蔽，从而实现去噪任务中的自监督学习。根据大量的消融实验以及先验知识，选定滑动时窗的标准差 (Standard Deviation, STD) 和结构相似性指数 (Structural Similarity Index Measure, SSIM) 两个统计量作为反映时序信号信噪的判别指标。标准差用来评估去噪前后曲线的平稳性，标准差的定义如下：

$$STD = \sqrt{\frac{1}{N} \sum_{n=1}^N [x(n) - \overline{x(n)}]^2}, \quad (4-1)$$

其中， $N$  表示窗口长度； $x(n)$  为信号； $\overline{x(n)}$  为信号均值。

结构相似性指数是一种用于图像质量评估的指标，原本用于衡量两幅图像的相似度

[101], 现多用于评估图像降噪算法的性能, 其度量系统如图 4-3 所示。作为结构相似性理论的一种具体实现, 结构相似性指标是从图像构成的角度, 定义了一种不依赖于亮度或对比度的图像结构信息, 能够用于反映场景中物体结构属性的相似性。同时, 该指数将失真现象建模为亮度、对比度和结构三个不同影响因子的组合, 以更全面地描述图像质量的影响因素。具体而言, 该指数通过采用均值作为亮度的估计值, 标准差作为对比度的估计值, 并利用协方差作为结构相似度的度量, 以量化图像的结构相似程度。

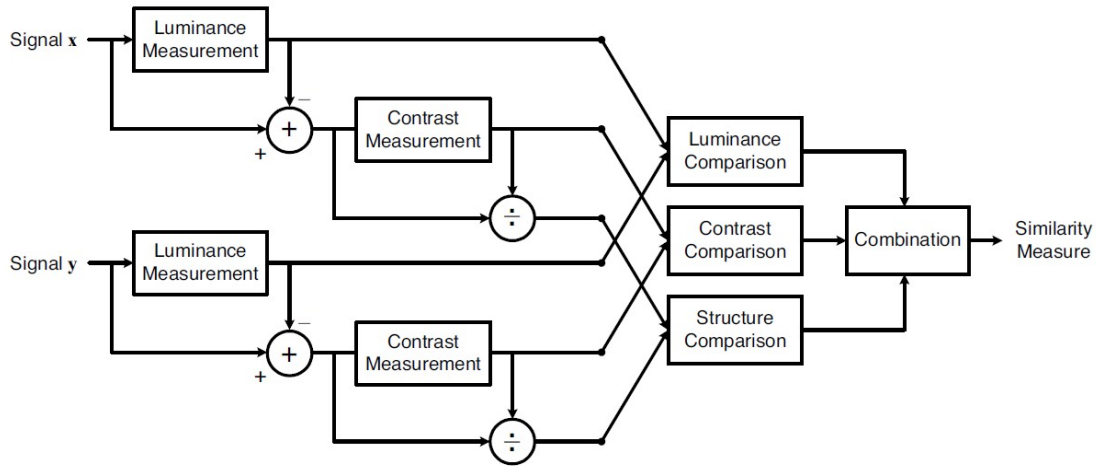


图 4-3 结构相似性度量系统

根据其性质和物理意义, 在时序数据中, 每个时间点的数据可以被视为图像中的一个像素点, 然后计算两个时间序列之间的平均结构相似性指数分数。本研究可以利用其来衡量两时序之间的相似程度以制作样本掩码。具体地, 结构相似性指数的定义如下:

$$SSIM(x, y) = [l(x, y)]^\alpha \cdot [c(x, y)]^\beta \cdot [s(x, y)]^\gamma \quad (4-2)$$

其中

$$l(x, y) = \frac{2\mu_x\mu_y + c_1}{\mu_x^2 + \mu_y^2 + c_1} \quad (4-3)$$

$$c(x, y) = \frac{2\sigma_x\sigma_y + c_2}{\sigma_x^2 + \sigma_y^2 + c_2} \quad (4-4)$$

$$s(x, y) = \frac{\sigma_{xy} + c_3}{\sigma_x\sigma_y + c_3} \quad (4-5)$$

其中,  $x$  是原始时序,  $y$  是伪随机时序;  $\mu_x$  是时序  $x$  的均值,  $\mu_y$  是时序  $y$  的均值;  $\sigma_x^2$  是时序  $x$  的方差,  $\sigma_y^2$  是时序  $y$  的方差,  $\sigma_{xy}$  是  $x$  和  $y$  的协方差;  $c_1, c_2, c_3$  是用来维持稳定的常数,  $l(x, y), c(x, y), s(x, y)$  分别表示时序  $x$  和  $y$  之间的三个测量值: 时序中的平均幅值、标准差、波形结构相似性;  $\alpha, \beta, \gamma$  是三个测量值的相应权重, 并且必须为正。结构相似性指数的取值范围为  $[-1, 1]$ , 当  $x = y$  时,  $SSIM = 1$ ; 当  $x = -y$  时,  $SSIM = -1$ 。

实际计算中, 为了简化起见, 通常会将参数设为  $\alpha = \beta = \gamma = 1, c_3 = c_2/2$ , 最终得到:

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (4-6)$$

通过计算时序数据窗口内的标准差和结构相似性，可以区分出信号和噪声。当标准差较小时，窗口内的数据较为集中且趋近于信号分布；反之则趋近于噪声分布。结构相似性反映了窗口内数据的结构相似程度，值越大表示原始时序与伪随机信号越相似，即属于信号的概率越大，反之则越接近噪声信号。通过实验，我们设定标准差和结构相似性阈值为 0.2 和 0.9，只要某段时窗标准差小于 0.2 且结构相似性指数大于 0.9（即  $STD > 0.2, SSIM < 0.1$ ），我们就将其分类为信号，否则分类为噪声。

除此之外，我们提出使用加权多尺度融合的方法进行信噪分类。具体来说，我们将滑动时窗分别缩放到不同的尺度，然后对每个尺度下的窗口进行标准差和结构相似性指数的计算，以得到每个尺度下的分类结果。最后，我们将不同尺度下的分类结果采用绝对多数投票原则（majority voting）进行加权融合<sup>[102]</sup>，得到最终的样本掩码。通过这种方法，我们可以在保证高准确率的同时，避免了单一尺度所带来的误判问题。本研究设置的多尺度为 800,1600,3200,6400，权重设置为 0.4,0.3,0.2,0.1。

### 4.3 模型结构设计

U-net 是一种常用于图像分割的卷积神经网络结构<sup>[103]</sup>，具有编码器和解码器两个部分，其中编码器用于提取输入图像的特征表示，解码器用于将这些特征映射到输出分割图像上。该网络基于全卷积网络<sup>[104]</sup>，其架构经过修改和扩展，以处理更少的训练图像并产生更精确的分割。

网络包括两个部分：收缩路径和扩展路径。收缩路径是一种典型的基于多个可重复使用的卷积层，每个卷积层后跟一个 ReLU 激活函数和一个最大池化层，通过堆叠这种结构来提取样本的特征表示。其中，卷积层通过滤波器对输入数据进行卷积操作，提取信号的不同特征，如边缘、纹理、形状等。卷积层可以帮助捕捉图像中的局部信息，而最大池化层则通过将每个区域内的最大值作为代表，减少输入数据的空间尺寸，从而降低计算复杂度，同时保留重要的特征信息。在收缩路径中，由于卷积层和最大池化层的作用，空间信息会逐渐减少，而特征信息会增加，这种路径的设置模式也使得编码器可以逐步地将样本的空间信息压缩成为高维的特征表示，从而使得网络具有更强的表征能力。

扩展路径与收缩路径相互对称，从而形成了 U 形结构的神经网络。该网络只使用每个卷积的有效部分，而不使用任何全连接层。相对于其他网络，这一点也是该网络减少计算量的重要原因之一。扩展路径通过一系列上采样和卷积的串联来与收缩路径中的高分辨率特征组合成为特征和空间信息，然后将编码器中提取的特征信息映射到输出样本上。为了避免在上采样过程中产生信息丢失，U-net 采用了跳跃连接（Skip Connection）

来连接编码器和解码器之间的不同层，从而使得网络可以在高层次和低层次特征之间进行信息交流，有助于提高网络的精度和稳定性。

本研究所使用的 U-net 的网络结构如图 4-4 所示。该网络由编码器和解码器组成，呈 U 型结构。网络输入是一维的时间序列数据，输出与输入长度相同的时间序列。网络共有 19 个卷积层，网络深度为 5，包含 4 次最大池化下采样和 4 次插值上采样。与传统 U-net 网络架构不同的是，我们取消了第一、二级跳跃连接，并将初始通道数从 64 减至 48，然后以此类推。该结构是我们通过对原始网络结构进行大量消融实验最终得出的结果，对此合理的解释是：与传统面向分割任务的 U-net 不同，本研究面向对象为大地电磁一维时序数据。由于网络接受一维输入，相较于二维图像，在数据层面本身缺少了大量信息，若仍然使用网络输入尺度为  $512 \times 512$  的 U-net 原始结构，则极易在训练过程中出现过拟合，这一点在我们后续的实验过程中也得到了证实。




图 4-4 U-net 网络结构

为了进一步简化模型以适应研究任务，同时减少模型参数和计算量，降低模型复杂度，加快计算速度。在 U-net 网络中，使用双线性插值代替卷积上采样操作。一方面，双线性插值是一种计算速度非常快的插值方法并且不需要额外的参数，而上采样操作需要进行大量的计算且需要额外的可学习参数，导致计算速度变慢。另一方面，双线性插值可以使网络输出更加平滑，减少锯齿状边缘的出现，是一种比较平滑的插值方法，可以在一定程度上减小过拟合的风险。此外，双线性插值还能够有效地避免一些由于采样过程引起的噪声或失真问题，提高样本重建的质量。

## 4.4 模型训练细节

### 4.4.1 损失函数

作为回归问题，模型的目标是尽可能准确地还原出原始信号。为了有效监督模型训练，我们将均方误差<sup>[105]</sup>(Mean Squared Error, MSE)和多尺度结构相似性指数(MultiScale Structural Similarity Index Measure, MS-SSIM)组成一个复合损失函数，通过优化该损失函数来进行训练。使用复合损失函数的优点在于它可以同时考虑还原误差和结构相似性，MSE 用于衡量还原后信号与原始信号之间的均方误差，它可以度量采样点级别的误差，但是忽略了结构相似性，因此在面对诸如类方波、类阶跃等噪声时可能会出现边缘效应。而 MS-SSIM 则用于衡量还原后信号与原始信号之间的结构相似性，能够有效地缓解边缘效应，并且能够保留更多的细节信息，避免出现还原后信号看起来很平滑但失去了原始信号的结构信息的情况。另一方面，有相关研究显示 MSE 对于噪声信号的表现不够鲁棒，过度强调信号中较大的幅值变化<sup>[106]</sup>。图 4-5 中展示了在 MSE 等值解空间中不同 SSIM 值的图像恢复效果，证明了依赖单一指标往往并不能收敛到全局最优。与 MSE 相比，SSIM 在测量非高斯分布的噪声时具有更好的表现，而且它是单调可微的函数。因此，SSIM 能够更好地适应信号处理中的实际需求，成为了一种更为全面和准确的信号保真度量。同时，SSIM 可以通过多尺度结构相似性 (MS-SSIM) 的方式，更好地适应不同尺度的图像特征，提高图像恢复的效果。

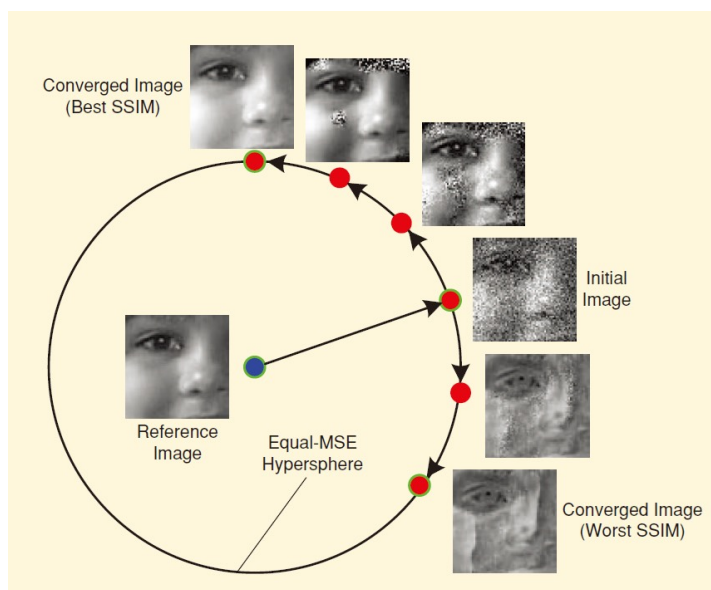


图 4-5 在解空间中沿着相等的 MSE 超球面寻找最大/最小 SSIM 值图像

均方误差损失函数表达式如下：

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (4-7)$$

其中， $N$ 为数据样本数量， $y_i$ 为样本的真实值， $\hat{y}_i$ 为模型对样本的预测值。该损失函数度量了 $y_i$ 与 $\hat{y}_i$ 之间的平均差异，对于模型训练的过程中，希望通过最小化该损失函数来优化模型参数，使得模型能够更准确地预测样本的真实值。

在 4.2.2 节中介绍了 SSIM 的基本定义和取值区间，即 $[-1,1]$ 。若将其作为损失函数



添加到网络中，在计算损失时，我们希望最小化损失，即将两个时序尽可能地恢复到相似的状态，因此可以直接采用 1-SSIM 的形式作为损失函数，其值域为[0,2]。通过这样计算得到的损失值越小，则代表二者的相似度越高，恢复效果越好。具体地，SSIM 损失函数表达式如下：

$$\mathcal{L}^{SSIM} = 1 - SSIM(x, y) \quad (4-8)$$

其中， $x$ 和 $y$ 分别表示原始信号和网络输出信号。

类似地，多尺度结构相似性定义如下<sup>[105]</sup>：

$$MSSSIM(x, y) = [l_M(x, y)]^{\alpha_M} \cdot \prod_{j=1}^M [c_j(x, y)]^{\beta_j} \cdot [s_j(x, y)]^{\gamma_j} \quad (4-9)$$

其中， $M$ 表示尺度因子。通常将 $M$ 设置为 5， $\alpha_5 = 0.1333$ ， $\alpha = \beta = \gamma = [0.0448, 0.2856, 0.3001, 0.2363, 0.1333]$ 。多尺度意味着我们在不同尺度上计算 SSIM，即首先通过一个缩放因子逐步缩小 $2^{j-1}$ 倍，然后计算每项的 SSIM，最后将它们与相应的权重 $\alpha_j$ ， $\beta_j$ ， $\gamma_j$ 相乘，具体流程如图 4-6 所示。




图 4-6 多尺度结构相似性度量系统

这里我们通过简单的平均池化层来实现尺度缩放。需要注意的是，MS-SSIM 取值范围不是[0,1]。因为协方差 $\sigma_{xy}$ 可能为负，这可能导致 $s(x, y)$ 为负数。为了将其满足损失函数条件，我们需要通过

$$MSSSIM = \frac{(MSSSIM+1)}{2} \quad (4-10)$$

将其归一化到[0,1]。

具体地，MS-SSIM 损失函数表达式如下：

$$\mathcal{L}^{MS-SSIM} = 1 - MSSSIM(x, y) \quad (4-11)$$

多尺度结构相似性 (MS-SSIM) 损失函数和结构相似性 (SSIM) 损失函数的区别主要在于其充分考虑了分辨率。MS-SSIM 损失函数在计算结构相似性指数时，采用了多个尺度的信息，并且在每个尺度上计算结构相似性指数，最后加权求和得到整体的 MS-SSIM 指数。这样做的好处是能够更好地捕捉图像的局部和全局特征，从而在评估图像质量时更加准确。而 SSIM 损失函数只考虑了一个尺度的信息，因此在评估图像质量时可能会存在一定的偏差。

为了兼顾时序整体趋势和局部细节的恢复效果，我们将损失函数权重比值设置为 5:2，使得 MSE 在损失函数中占据更大的比重，以更好地还原信号的整体趋势，同时保证 MS-SSIM 在损失函数中占据一定比重，以避免过度拟合信号的局部细节。这样可以有效平衡整体趋势和局部细节的重要性，从而得到更好的信号恢复效果。

#### 4.4.2 评价指标

为了量化评估噪声压制的效果，本文使用曲线相似性参数（NCC）、曲线相对均方误差（NRMSE）、信噪比（SNR）和误差（Error）这四个参数对原始数据和去噪后数据进行相似性评价<sup>[107]</sup>。

曲线相似性参数定义式为：

$$NCC = \frac{\sum_{n=1}^N x(n)*y(n)}{\sqrt{\sum_{n=1}^N x^2(n)*\sum_{n=1}^N y^2(n)}} \quad (4-12)$$

曲线相对均方误差定义式为：

$$NRMSE = \frac{1}{N} * \frac{\sum_{n=1}^N [y(n)-x(n)]^2}{x_{max}-x_{min}} \quad (4-13)$$

信噪比的定义式为：

$$SNR = 10\log_{10} * \frac{\sum_{n=1}^N x^2(n)}{\sum_{n=1}^N [x(n)-y(n)]^2} \text{ (dB)} \quad (4-14)$$

误差的定义式为：

$$E = \frac{1}{N} \sum_{n=1}^N |y(n) - x(n)| \quad (4-15)$$

其中， $N$ 表示数据的长度； $x(n), y(n)$ 分别为模型输入和输出的时间序列； $x_{max}, x_{min}$ 表示序列 $x$ 中的最大值和最小值。

由以上三组定义可知，曲线相似性参数表征模型输入和输出曲线的整体趋势上的相似程度，当 $\mathbf{x} = \mathbf{y}$ 时， $NCC = 1$ ；当 $\mathbf{x} \perp \mathbf{y}$ 时， $NCC = 0$ ；当 $\mathbf{x} = -\mathbf{y}$ 时， $NCC = -1$ ，取值范围为 $[-1,1]$ 。曲线相对均方误差表征两数据曲线之间的相对误差，值越小代表二者越相近，取值范围为 $[0,1]$ 。信噪比表征两曲线数据之间功率谱的比值，值越大代表信号受到的噪声干扰越小，信号的质量越好。一般地， $NCC > 0.9$ ， $NRMSE < 0.03$ ， $SNR > 10\text{dB}$ ，可以认为两组数据基本一致<sup>[3]</sup>。误差通常用于衡量预测值与真实值之间的差异，在此我们将其用来衡量信号的失真程度，它也是评估模型或算法性能的重要指标之一。

#### 4.4.3 训练细节

图 4-7 展示了带掩码的损失函数在训练和预测阶段的计算流程。在图 4-7-a 中，展示了训练阶段的具体步骤：首先，我们将一段原始时序送入网络，网络输出一段等长的时间序列，接下来，将原始时序和网络输出通过掩码序列进行掩码操作，具体来说，掩码值为 1 的序列部分维持原值，掩码值为 0 的序列部分则被置 0。通过这样一个布尔运

算，我们控制网络使其仅优化噪声部分损失，以防止网络对有效信号进行滤波而导致失真。最后将计算所得损失进行梯度反传以进行下一次参数更新。图 4-7-b 显示的是前向预测阶段，与训练不同，前向预测无需梯度反传。因此我们仅需在识别为噪声部分对原始时序和网络输出进行掩码差分，再将信号部分与取反掩码做布尔运算，最后将两者相加即可得到去噪后时序。

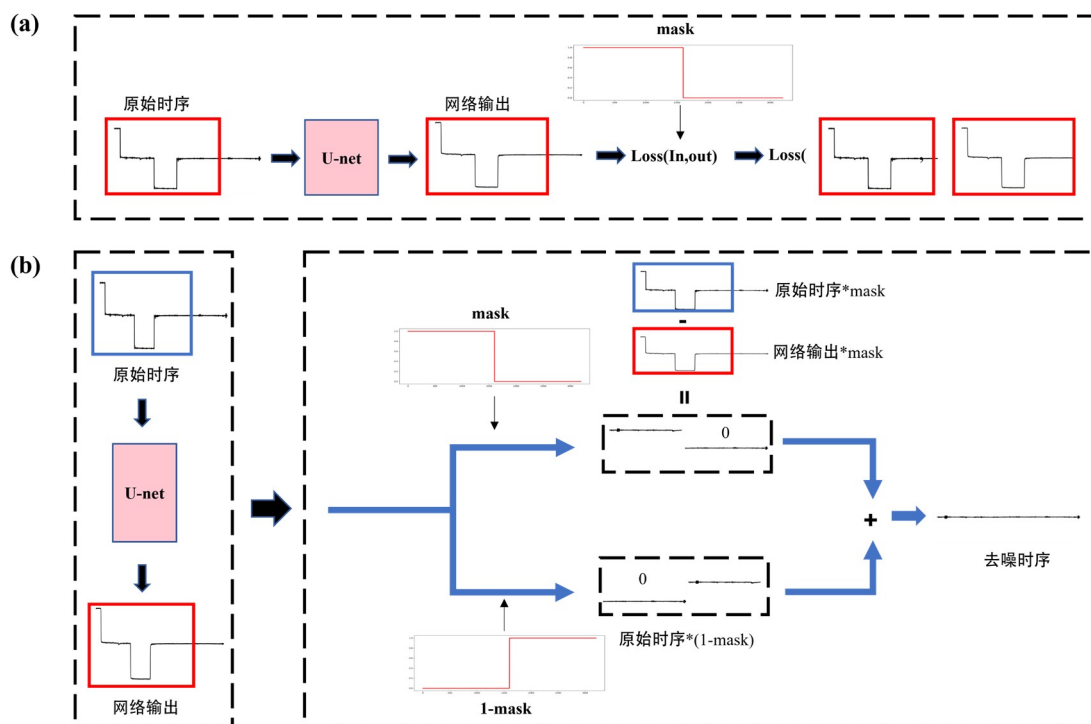


图 4-7 训练和预测阶段损失函数计算流程图 (a)训练阶段；(b)预测阶段

我们采取 3.4.3 节相同的方法对输入通道进行均值方差归一化处理，防止梯度反传过程中带来的梯度消失、梯度爆炸等收敛问题。为了尽可能在单个样本中包含多尺度下的噪声波形，我们将样本长度 $n$ 设置为 3200，批次大小 $batch$ 设置为 1024，每个训练迭代从数据集中随机采样 10240 个训练集样本和 5120 个验证集样本，一共训练 500 个轮次，每 5 个轮次保存一次模型参数，其他设置与 3.4.3 节保持一致。得益于 Tesla V100 强大的算力和显存，迭代一个轮次仅需 40 分钟。此外，我们还在模型的训练过程中加入了早期停止策略，当网络在验证集上的性能不再提升时，便停止训练，以避免过拟合的情况发生。从图 4-8 中可以看到，验证损失曲线在第 200 个训练轮次时停止下降，随后在各个指标上都显示出了明显的过拟合现象，于是我们保存该轮次的权重参数作为最终的模型参数，并在后续的前向预测阶段加载该参数。

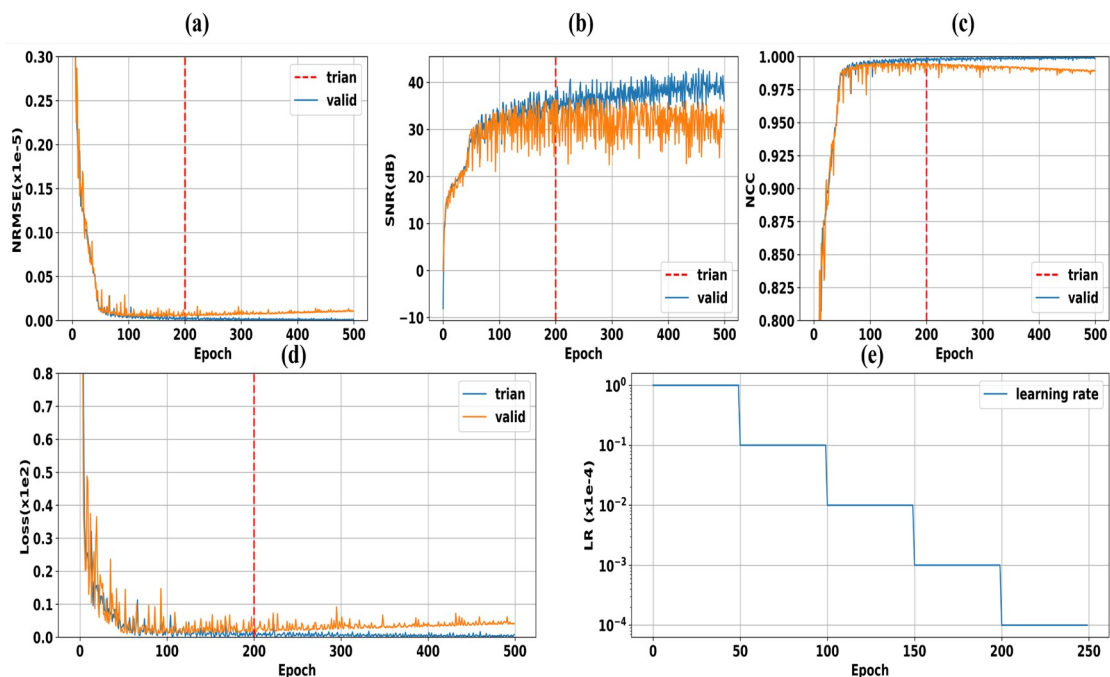


图 4-8 训练曲线，蓝色代表训练集指标，棕色代表验证集指标，红色垂直虚线表示提前停止的时期。(a) NRMSE 曲线；(b) SNR 曲线；(c) NCC 曲线；(d) 损失曲线；(e) 学习率衰减曲线。

最终各指标收敛结果如表 4-1 所示。

表 4-1 训练结束时各指标最终结果

数据集	NRMSE	SNR	NCC	Loss(x1e2)
训练集	0.008	35.9	0.993	0.0125
验证集	0.012	30.6	0.987	0.02

### 4.5 模拟数据处理

为了验证本文方法对各种干扰压制的有效性，我们实施了模拟数据试验，使用前文中所述方法来制作数据集、搭建网络、设计损失函数，并对模型进行训练，最终利用训练好的模型进行前向预测。

在本次试验中，我们将于西藏测区所采集的高质量 AMT 数据中 Ex 分量时间序列片段作为“干净”样本，其采样频率为 150 Hz，采样点数为 3200，如图 4-9 所示。通过对时间序列的分析，可以发现该时序片段中没有显著的噪声成分，并且具有相对较高的数据质量。




图 4-9 西藏测区采集的“干净”样本，无明显噪声干扰 (a)时间序列 (b)频谱

此外，我们生成了一组涵盖多种干扰噪声的模拟数据，通过向“干净”样本添加各种噪声来模拟现实世界中可能存在的干扰源，其中包括方波噪声、脉冲噪声、周期噪声和三角波噪声等。

#### 4.5.1 模拟周期噪声

周期噪声作为大地电磁勘探中最常见的噪声之一，往往是由勘探期间存在多种主动源电磁勘探方式或 50Hz 左右工业谐波所造成，其形态多表现为 50Hz 为主频的整数倍正弦谐波。该噪声的特征如下：

(1) 呈周期性规律出现，噪声振幅通常远大于信号振幅，使得有效信号被完全淹没，无法识别。

(2) 及其谐波通常以固定频率在频谱图上呈现，具体表现为明显波峰且该噪声及其谐波的能量远大于其他频点。

(3) 通常出现在电道，仅对固定频点的阻抗估计产生干扰，可通过数字滤波器予以消除。

模拟周期噪声如图 4-10 所示。图 4-10-b 和图 4-10-c 分别为固定频率为 0.22Hz 周期干扰和添加干扰后的含噪信号，所添加的周期噪声幅值远超过干净信号幅值。很明显，周期噪声的加入使得原始有效信号被完全淹没，已无法看出信号的时域细节特征。我们将加噪信号传入模型进行噪声分量估计，模型输出结果如图 4-10-d 所示，从中可以看出我们的模型能够很好地将添加的噪声特征学习出来，最终输出一个相对纯净的噪声波形。图 4-10-e 为含噪信号减去模型输出的噪声分量估计所恢复的有效信号，图 4-10-f 为原始干净信号减去去噪后信号的残差，红色曲线为零值线，其含义为残差越接近于零，去噪信号与原始信号相似性越高，即去噪效果越好。从图 4-10-e 和图 4-10-f 中可以看出模型已很好地完成了对周期信号的压制，成功地将有效信号从强噪声中恢复出来并且仅造成了微小的失真。

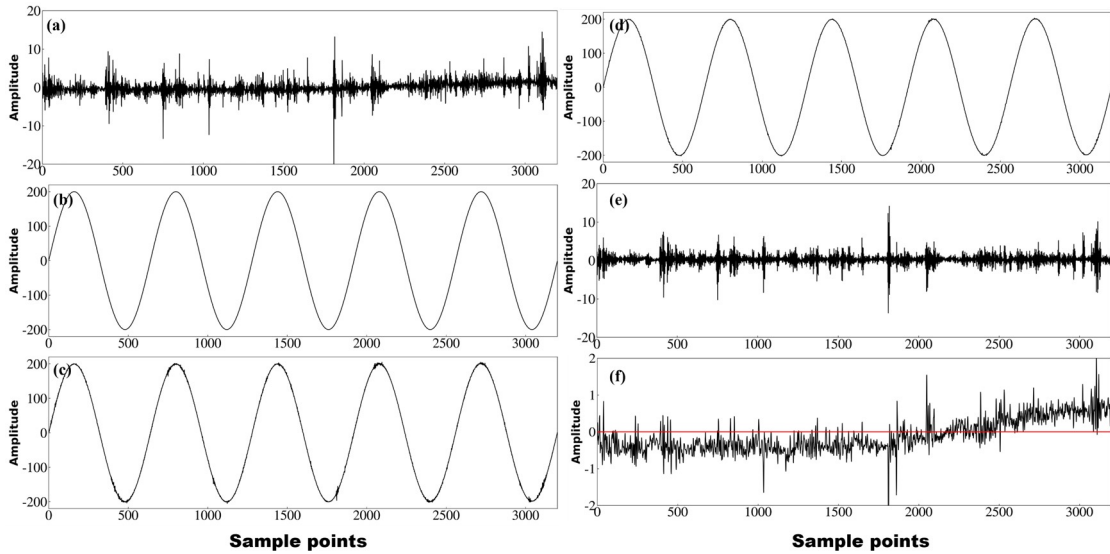


图 4-10 模拟周期噪声 (a)原始信号 (b)模拟周期噪声 (c)含噪信号 (d)模型输出 (e)去噪信号 (f)残差，红线为等零值线

图 4-11 为图 4-10 时间序列相对应的频谱图。正弦周期信号的频谱特点是单个峰值，峰值在频谱中心，并且频谱呈现对称性。在峰值处，频谱的幅值与信号的振幅成正比，而峰值的位置则对应着正弦波的频率，如图 4-11-b 所示。与原始信号频谱（图 4-11-a）相比，含噪信号（图 4-11-c）在特定频点处出现了一个明显波峰，而在去噪信号频谱（图 4-11-d）中，可以看到该噪声频率成分已经被去除干净，而根据信号的统计结果，对于其他频率的信号而言，幅值的损失很小。由此可以看出，该网络对周期噪声具有很好的抑制效果。

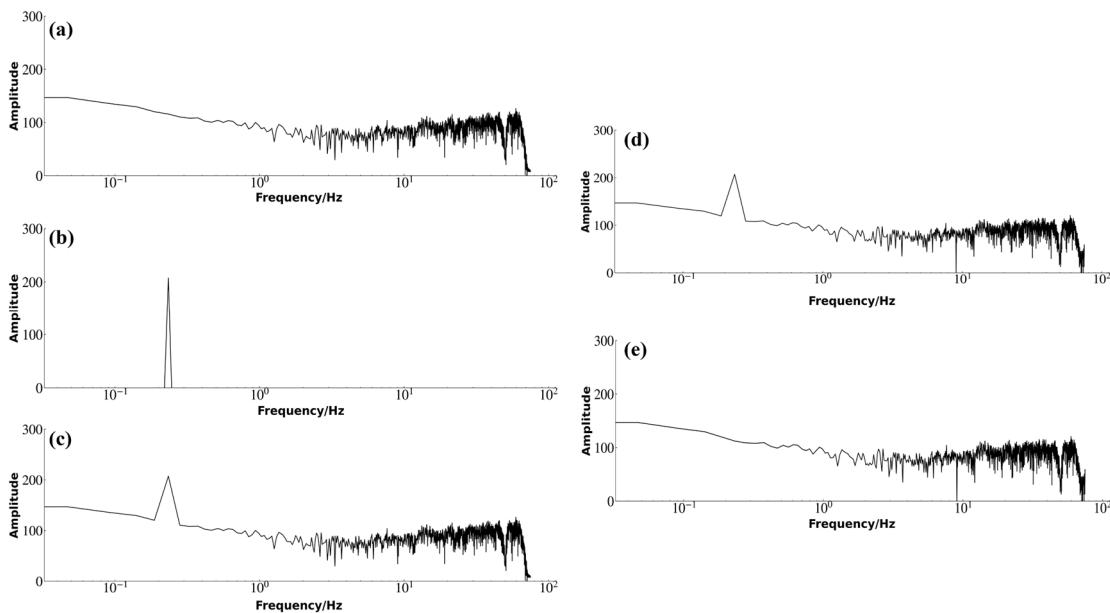


图 4-11 模拟周期噪声频谱 (a)原始信号频谱 (b)模拟周期噪声频谱 (c)含噪信号频谱 (d)模型输出频谱 (e)去噪信号频谱

表 4-2 显示了原始信号与去噪信号评价指标对比结果。从表中可以看出误差 (E) 结果为 0.027, 说明去噪后信号失真程度较小; 信噪比 (SNR) 为 22.79, 曲线相似性 (NCC) 为 0.997, 均方相对误差 (NRMSE) 为 2.35%。这些时序指标皆满足 4.4.2 节中所提出的条件, 即能有效地证明干净信号与去噪后信号两组数据基本一致。频谱的曲线相似性 (NCC) 为 0.984, 均方相对误差 (NRMSE) 为 2.58%。这一结果表明, 去噪数据与原始数据非常接近, 能够准确反映原始干净信号的特征。另外, 通过计算得出原始信号、含噪信号和去噪信号的标准差分别为  $STD_{原始} = 1.89$ ,  $STD_{含噪} = 141.34$ ,  $STD_{去噪} = 1.53$ , 这表明我们的方法可以有效地压制周期噪声并恢复信号的原始特征。

表 4-2 原始信号与去噪信号评价指标对比结果 (添加周期噪声)

E	SNR	NCC	NRMSE	NCC (spectrum)	NRMSE (spectrum)	STD
						1.89 (原始)
0.027	22.79	0.997	0.0235	0.984	0.0258	141.34 (含噪)
						1.53 (去噪)

#### 4.5.2 模拟方波噪声

方波噪声作为大地电磁勘探一种常见噪声, 由于其特殊的频谱特征, 在地球物理勘探中往往被视作一种较为复杂和难以处理的噪声。

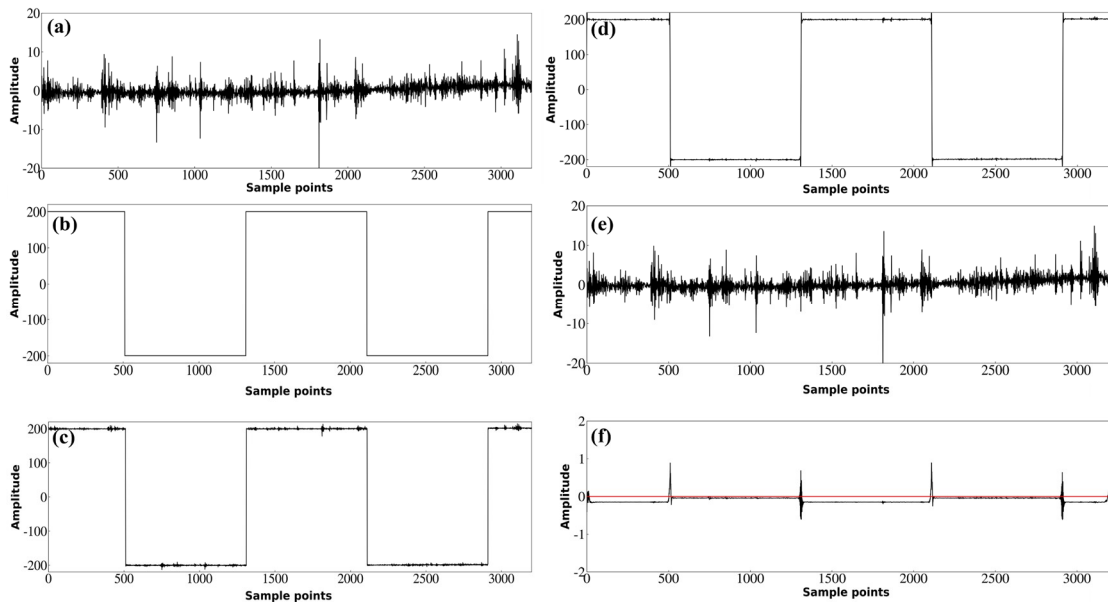


图 4-12 模拟方波噪声 (a)原始信号 (b)模拟方波 (c)含噪信号 (d)模型输出 (e)去噪信号 (f)残差, 红线为等零值线

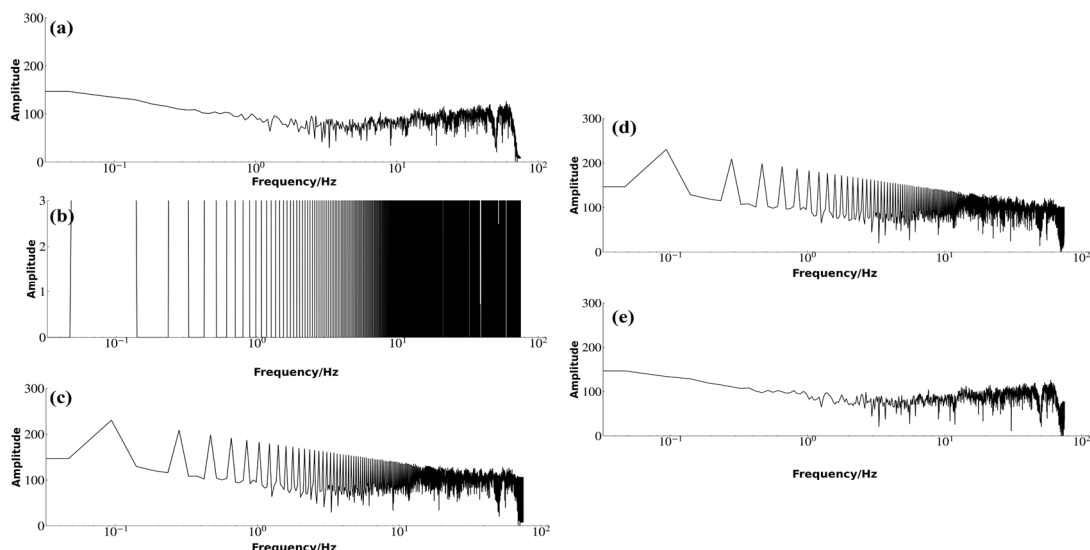


图 4-13 模拟方波噪声频谱 (a)原始信号频谱 (b)模拟方波频谱 (c)含噪信号频谱 (d)模型输出频谱 (e)去噪信号频谱

本小节中，我们构建了一段长周期的方波信号来模拟实际情况。设置方波信号的幅值为 200，采样点为 3200，采样区间包含两个完整的方波信号，如图 4-12 所示。图 4-12-b 和图 4-12-c 分别为所叠加的方波干扰和叠加干扰后的含噪信号，可以看出，所叠加的方波噪声幅值远大于原始信号幅值，且在上升沿和下降沿处存在幅值突变。我们对含噪信号进行噪声分量估计，估计结果如图 4-12-d 所示，训练良好的模型能够恢复出十分纯净的低频信号，其强大的表征能力能够近乎完美地拟合出所添加的方波噪声。图 4-12-e 为去噪信号，从肉眼层面难以分辨二者的差别，图 4-12-f 为残差曲线，该曲线几乎与零值线重合，仅在方波边沿处存在较小的残差。此结果一方面反映了模型能够精准地提取方波信息并从中学习到全部特征，另一方面反映了我们的模型在处理边缘幅值突变的情况时遇到了挑战。

图 4-13 为上述时序相对应的频谱图。方波信号的频谱呈现出无限多个奇次谐波分量（图 4-13-b），即频率为基波频率的奇数倍。这些谐波分量幅值随着频率增大而迅速下降，但整体幅值却与方波的幅值成正比。方波信号的频谱可以看作是由一系列离散的谐波组成的，这些谐波在频域中呈现出突变的特征。在去噪信号频谱（图 4-13-e）中可以看出包含主要能量的噪声成分大部分皆已被滤除，但仍残留有上述的边沿残差和某些高次谐波成分，造成“吉布斯效应”，这些残差会对后面的评价指标结果有所影响，我们将在最后一章分析和讨论这个问题。

表 4-3 显示了原始信号与去噪信号评价指标对比结果。 $E=0.045$ ， $SNR=15.45$ ， $NCC=0.905$ ， $NRMSE=0.031$ 。根据 4.4.1 节的时序指标结果，可以发现与正弦周期噪声相比，方波噪声的去噪效果有所下降，这种下降也在频谱的量化指标上有所反映， $NCC(\text{spectrum})=0.894$ ， $NRMSE(\text{spectrum})=0.034$ 。通过计算原始信号、含噪信号和去噪信



号的标准差，我们得到了以下结果： $STD_{原始} = 1.89$ ， $STD_{含噪} = 199.93$ ， $STD_{去噪} = 1.90$ ，这表明我们的方法可以在一定程度上压制大尺度方波噪声，并将信号幅值恢复至正常水平。

表 4-3 原始信号与去噪信号评价指标对比结果（添加方波噪声）

E	SNR	NCC	NRMSE	NCC (spectrum)	NRMSE (spectrum)	STD
						1.89（原始）
0.085	15.45	0.899	0.031	0.841	0.034	199.93（含噪）
						4.90（去噪）

### 4.5.3 模拟充放电三角波噪声

类充放电三角波噪声属于人文噪声一种，通常在磁道采集时间序列数据上表现出充电、放点性质，其幅值也远大于正常信号，为磁相关噪声。当通道存在此类噪声时，视电阻率-相位曲线往往表现出类似近源效应现象。

模拟充放电三角波噪声如图 4-14 所示。图 4-14-b 到图 4-14-f 分别为模拟充放电三角波、含噪信号、噪声分量估计、去噪信号、残差。与上述结论一致，几乎被完全淹没的原始干净信号能够有效地从大尺度充放电三角波噪声中恢复出来，并且保留了有效信号的细节特征，这些结果可以有力地证明了模型在面对不同采集通道的泛化性和鲁棒性，但噪声边沿处存在的残余现象仍然存在。

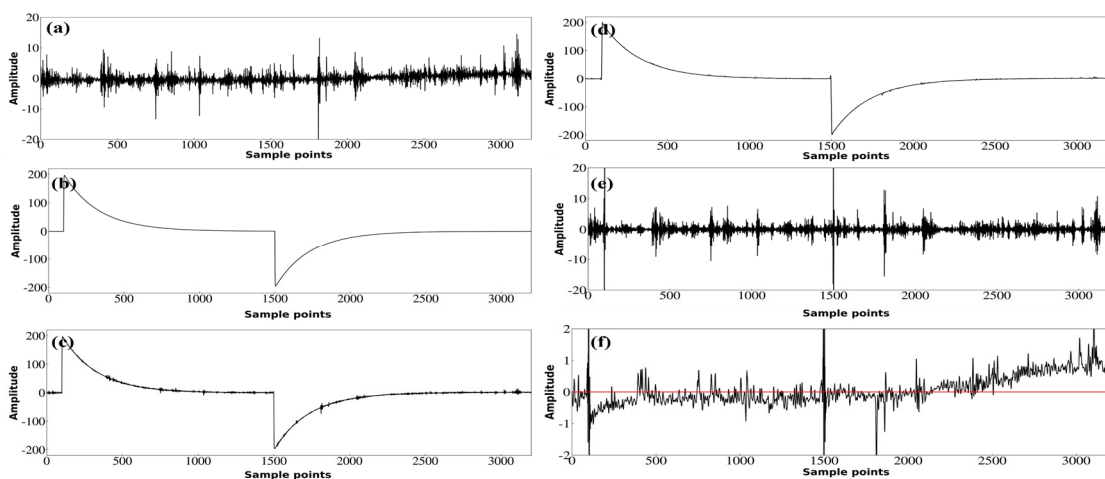


图 4-14 模拟充放电三角波噪声 (a)原始信号 (b)模拟充放电三角波 (c)含噪信号 (d)模型输出 (e)去噪信号 (f)残差，红线为等零值线

图 4-15 为图 4-14 相对应的频谱。类充放电三角波信号在频谱上表现为一系列的谐波，随着频率的增加，谐波幅值逐渐减小。其频谱特点与正弦信号类似，但与正弦信号相比，其谐波幅值的下降速度更快。图 4-15-d 为模型抽取噪声的频谱，该频谱包含了类充放电噪声的主要干扰成分。通过观察去噪结果的频谱，可以发现去噪之后保留了干净

信号主要有效成分，在频谱上体现出随机性。

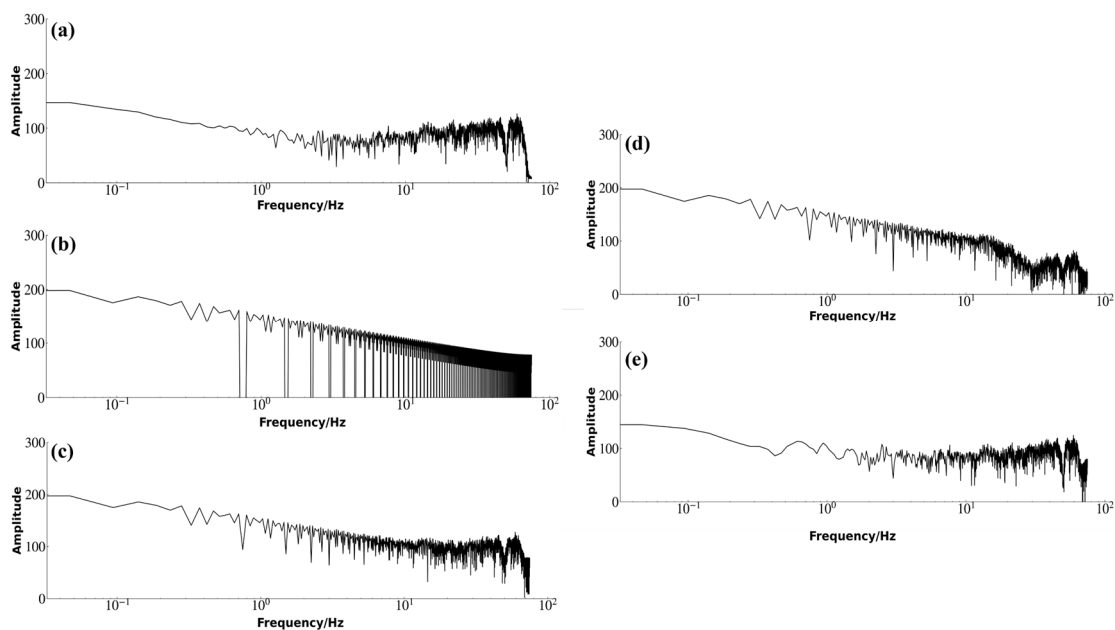


图 4-15 模拟充放电三角波噪声频谱 (a)原始信号频谱 (b)模拟充放电三角波频谱 (c)含噪信号频谱 (d)模型输出频谱 (e)去噪信号频谱

表 4-4 反映了在充放电三角波噪声影响下去噪前后的评价指标结果。  $E=0.047$ ,  $SNR=26.00$ ,  $NCC=0.968$ ,  $NRMSE=0.026$ 。根据 4.4.1 节的时序指标结果，可以发现与正弦周期噪声相比，方波噪声的去噪效果有所下降，这种下降也在频谱的量化指标上有所反映。通过计算原始信号、含噪信号和去噪信号的标准差，我们得到了以下结果： $STD_{原始} = 1.89$ ,  $STD_{含噪} = 199.93$ ,  $STD_{去噪} = 1.90$ ，所有结果也验证了上述的结论。且  $NCC(\text{spectrum})$ 接近于 1,  $NRMSE(\text{spectrum})$ 小于 0.03 足以说明该误差是在可接受范围之内

表 4-4 原始信号与去噪信号评价指标对比结果 (添加充放电三角波噪声)

E	SNR	NCC	NRMSE	NCC (spectrum)	NRMSE (spectrum)	STD
						1.89 (原始)
0.047	26.00	0.968	0.026	0.950	0.028	53.48 (含噪)
						2.67 (去噪)

#### 4.5.4 模拟脉冲噪声

在采集时序中，脉冲噪声往往存在于所有采集频段，可对任一采样率造成影响（图 4-16）。主要表现为具有突发性、高振幅、窄带性、瞬态性等特点的尖峰形态，其幅值可达正常信号的若干数量级。由于这些特性，脉冲噪声对 10~1Hz 和 0.1Hz 左右的频段干扰最为严重，当信噪比低于 0.5 时，视电阻率曲线将会出现剧烈的跳变现象<sup>[108]</sup>。

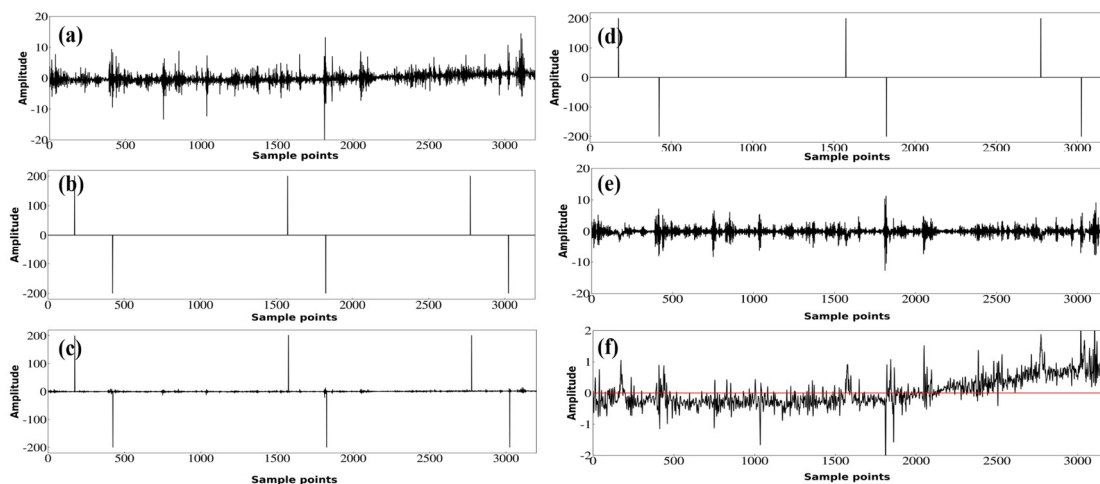


图 4-16 模拟脉冲噪声 (a)原始信号 (b)模拟脉冲波 (c)含噪信号 (d)模型输出 (e)去噪信号 (f)残差，红线为等零线

图 4-17 显示了相应的频谱图。脉冲信号的频谱特点是其频谱幅值是一个常数，而频率为 0 处有一个无限大的峰值。这意味着脉冲信号包含了各种频率的成分，其中包括直流分量，而且幅度随着频率的增加而迅速减小。由于该类噪声具有突变的高频特性，模型无法过多关注和拟合该部分信息，因此能够对此类噪声进行良好的去噪。

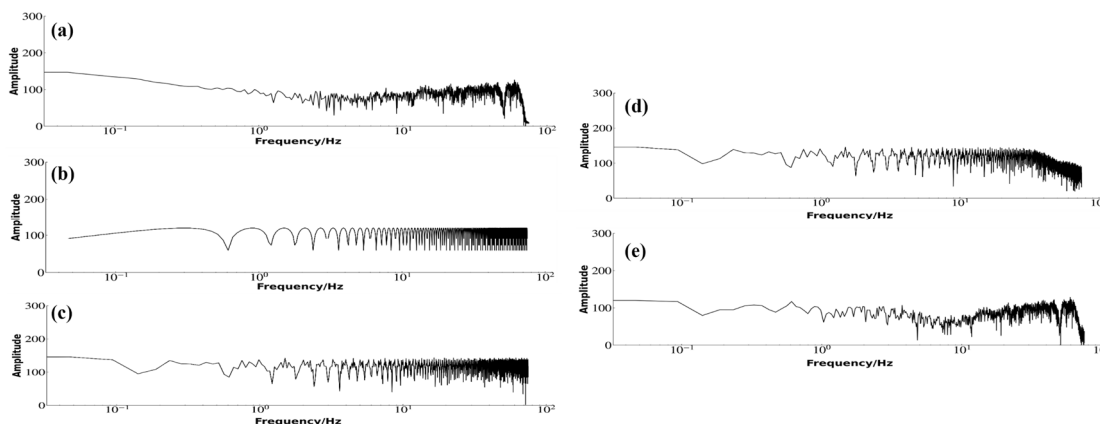


图 4-17 模拟脉冲噪声频谱 (a)原始信号频谱 (b)模拟脉冲波频谱 (c)含噪信号频谱 (d)模型输出频谱 (e)去噪信号频谱

表 4-5 显示的指标反映了在所有噪声种类中，模型在应对脉冲噪声方面取得了最佳的去噪效果，尤其是在曲线一致性指标上，时域和频域的计算结果几乎等于 1。

表 4-5 原始信号与去噪信号评价指标对比结果（添加脉冲噪声）

E	SNR	NCC	NRMSE	NCC (spectrum)	NRMSE (spectrum)	STD
						1.89 (原始)
0.002	28.97	0.994	0.015	0.990	0.021	8.86 (含噪)
						1.65 (去噪)

## 4.5.5 模拟阶跃噪声

阶跃噪声只存在低频采集频段，其波形表现为台阶状。该类噪声的主要特点与方波噪声类似，噪声曲线缓慢变化，在某个时间幅值突变，造成前后曲线的不连续性，存在极大落差。

与构建方波噪声流程类似，我们设置阶跃噪声的幅值为 200，振幅前后落差为 400 来模拟极端条件下的阶跃噪声干扰，如图 4-18 所示。图 4-18-b 和图 4-18-c 分别为模拟阶跃噪声和叠加后的含噪信号。模型输出的噪声估计分量如图 4-18-d 所示，在阶跃边沿处观察到高频振荡信号，初步推测为模型试图通过以多次高频分量来拟合阶跃。图 4-18-e 为去噪信号，存在与模拟方波噪声中一样的问题。

图 4-19 展示了模拟阶跃噪声情况下的频谱，从图 4-19-b 中可以看到阶跃噪声其频谱在低频处存在一个极限，随着频率的增加，幅值呈现出一定程度的下降趋势，但整体在频率范围内均具有一定的幅值。图 4-19-d 反映了模型抽取的噪声频谱，虽然其中包含部分信号频谱，造成了一定的信号失真，但主要呈现出阶跃干扰的频谱特征。

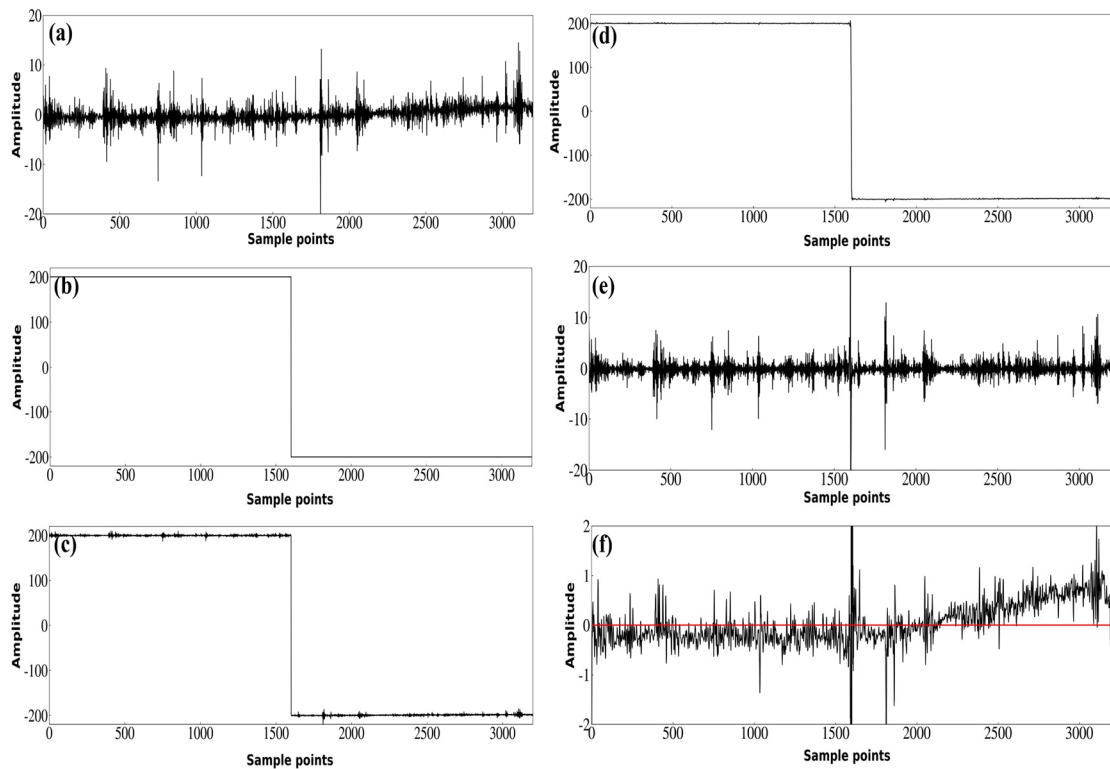


图 4-18 模拟阶跃噪声 (a)原始信号 (b)模拟阶跃波 (c)含噪信号 (d)模型输出 (e)去噪信号 (f)残差，红线为等零线

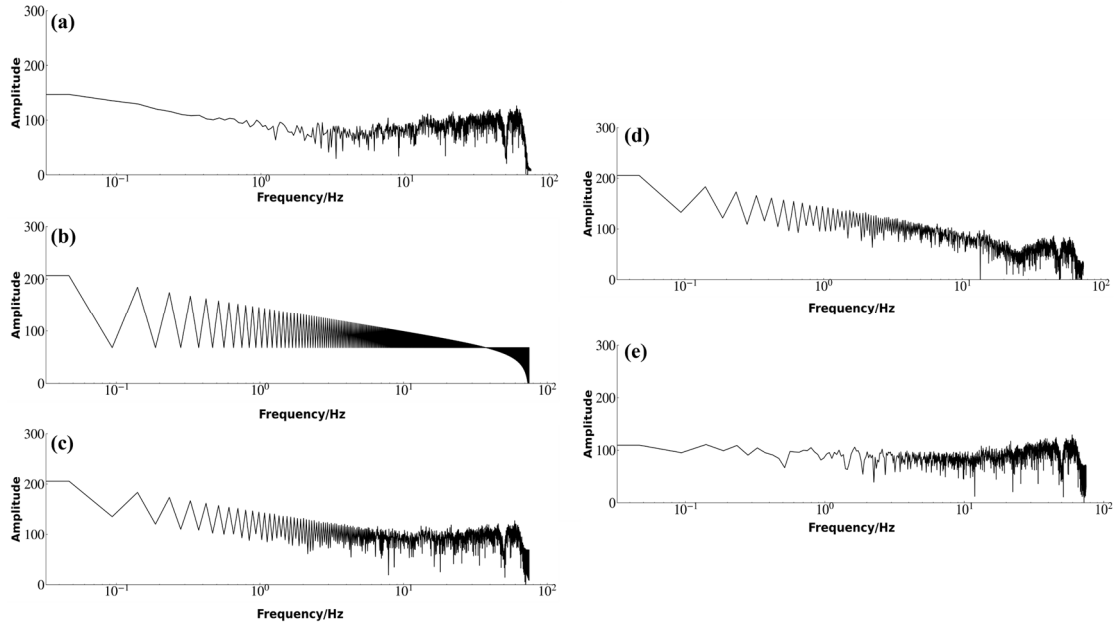


图 4-19 模拟阶跃噪声频谱 (a)原始信号频谱 (b)模拟阶跃波频谱 (c)含噪信号频谱 (d)模型输出频谱 (e)去噪信号频谱

表 4-6 显示了原始信号与去噪信号评价指标的对比结果。其中， $E=0.04, SNR=28.82, NCC=0.918, NRMSE=0.011$ ，标准差计算结果如下： $STD_{原始} = 1.89$ ， $STD_{含噪} = 199.44$ ， $STD_{去噪} = 2.36$ 。从量化结果上看，该结果近似 4.4.2 节方波噪声指标结果。分析其原因，阶跃干扰与方波干扰在形态上近似，这意味着对于模型而言在处理阶跃干扰时可能会遇到类似于处理方波干扰的困难。

表 4-6 原始信号与去噪信号评价指标对比结果（添加阶跃噪声）

E	SNR	NCC	NRMSE	NCC (spectrum)	NRMSE (spectrum)	STD
						1.89（原始）
0.040	28.82	0.918	0.011	0.886	0.021	199.44（含噪）
						2.36（去噪）

#### 4.5.6 模拟复合噪声

为了进一步验证模型的泛化性和鲁棒性，我们在模拟实验中添加了复合噪声。该复合噪声涉及多种噪声类型和不同幅值的噪声，其中添加噪声的幅值从 50 到 200 不等，且均强于干净信号幅值。多种噪声共同作用于该段时间序列，使其呈现出强干扰性和非随机性，如图 4-20-b 所示。根据前文所述的步骤，使用经过训练的模型对图 4-20-c 中的含噪信号进行处理得到去噪结果，其与原始信号对比结果如图 4-20-a 和图 4-20-e 所示。与前述结论一致，模型在应对各种噪声时都展现出了强大的去噪能力和鲁棒性，这一点在残差曲线（图 4-20-f）上也有所体现。图 4-21 显示了模拟复合噪声的频谱。

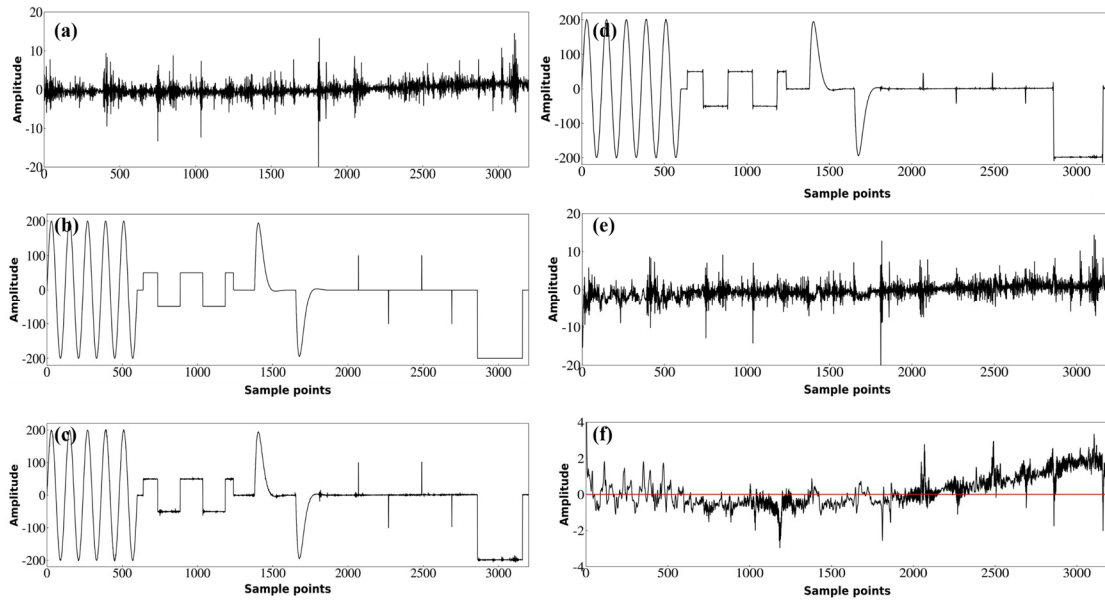


图 4-20 模拟复合噪声 (a)原始信号 (b)模拟复合噪声 (c)含噪信号 (d)模型输出 (e)去噪信号 (f)残差，红线为等零线

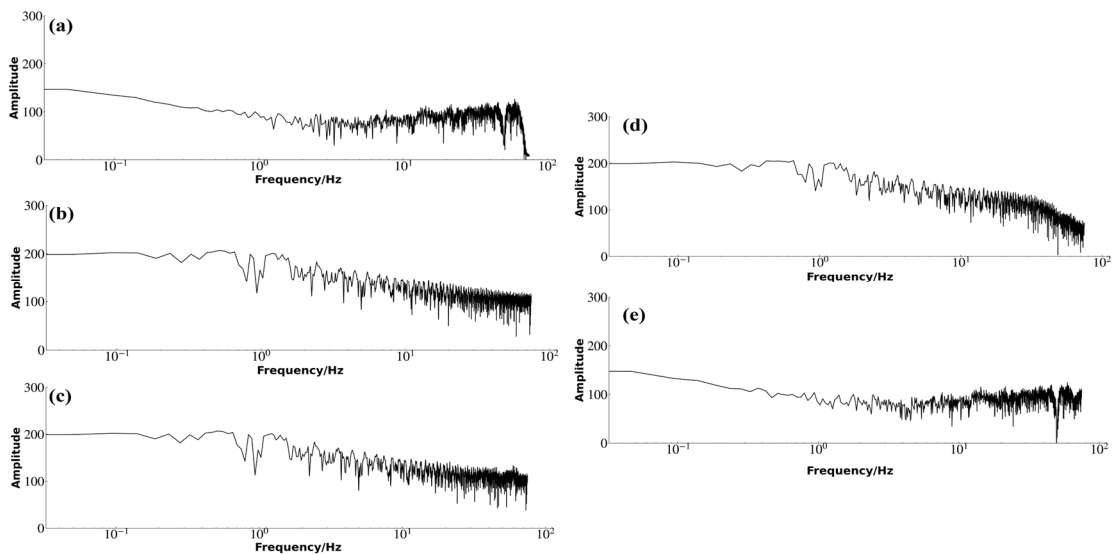


图 4-21 模拟复合噪声频谱 (a)原始信号频谱 (b)模拟复合噪声频谱 (c)含噪信号频谱 (d)模型输出频谱 (e)去噪信号频谱

定量指标显示（表 4-7），在添加噪声干扰幅值为干净信号 1-10 倍的复杂情况下，去噪前后时间序列信噪比为 22.35 dB，误差指标为 0.072，标准差从 265.47 降至 2.23，时域相对均方误差为 3%，频域相对均方误差为 4%，相关系数皆大于 0.87。进一步观察图 4-21 中的频谱结果，可以看到去噪前后信号的频率成分基本一致，而含噪信号中明显的噪声频率在经过去噪处理后被有效地压制，如图 4-21-b 所示，信号数量级由 200 降低至 150。综合时间序列和频谱对比结果，本文提出的方法能够有效去除多种时间域内的干扰信号。

表 4-7 原始信号与去噪信号评价指标对比结果 (添加复合噪声)

E	SNR	NCC	NRMSE	NCC (spectrum)	NRMSE (spectrum)	STD
						1.89 (原始)
0.072	22.35	0.882	0.030	0.876	0.040	265.47 (含噪)
						2.23 (去噪)

通过对添加不同类型和幅值噪声的信号进行测试,我们发现模型仍然能够较好地恢复原始信号,并且去噪效果随着噪声幅值的增加而略微下降。这表明我们的模型具有一定的泛化性和鲁棒性,可以适应多种复杂噪声环境下的信号处理任务。但是需要注意的是,当噪声的幅值过大或剧烈突变时,仍然可能会对去噪效果产生较大的影响,因此在实际应用中需要根据具体情况进行调整。

以上所有结果皆表明模型有足够的应对和学会各种常见的噪声干扰及其波形特征,并且在滤波的同时能稳健地保留有效信号的细节特征,不至于造成严重的信号失真。

#### 4.6 本章小结

本章从大地电磁时间域去噪的角度出发,首次提出基于 U-net 网络的自监督学习的去噪算法思想,通过自监督学习的方式,我们不需要准备大量的带标签数据,只需利用大地电磁信号的自身特征,利用噪声数据进行无监督的预训练,使得模型能够充分利用输入数据的信息,提高对噪声的适应性。在训练过程中,我们还对算法进行了进一步的优化,如引入批量标准化 (Batch normalization) 和跳跃连接 (skip connection),以加速网络训练并提高网络性能。针对大地电磁噪声在采集时序上所呈现出来的特点,我们还对网络结构和损失函数进行了一些改进以更加适合我们的下游任务。

随后,我们通过模拟噪声实验来验证我们模型的去噪能力。在模拟噪声实验中,我们选择了一组真实的高质量大地电磁数据作为干净信号,并在此基础上加入了各种程度的噪声干扰,包括方波、充放电三角波和周期噪声等。通过比较去噪前后的信号成分及其频谱,我们发现该算法能够有效地去除各种类型的噪声干扰,并保留原始数据中的有效信息,通过计算去噪前后的各种量化指标,进一步验证了去噪后的信号与原始干净信号基本一致,证明了算法在实际应用中的可行性和有效性。

大量仿真实验的结果证明了该方法能够应对任何种类的噪声,不受噪声波形、周期大小、噪声分布等因素影响,并且无需对噪声进行任何假设。从误差指标可以看出,经过我们的方法处理后的信号失真程度较小,这说明我们的算法能够在保持较低失真的情况下有效地去除噪声,并且能够提高大地电磁数据的信噪比和可靠性。

## 第五章 实测数据结果

本章用天电识别程序对南京、武汉测区实测 AMT 数据进行天电挑选和自动识别处理,将挑选前后的视电阻率-相位等处理结果进行对比,验证这一流程在实际资料处理中的合理性和可行性,总结基于神经网络的天电信号识别对改善“死区”问题的意义。

此外,本章还用时间域波形去噪算法对贵州等地的多条测线上的实测大地电磁数据进行了去噪处理,并对去噪结果与多种传统滤波算法进行了对比,验证了本文算法的优越性和创新性,通过对不同测点去噪前后的资料处理解释,总结了自监督学习思想在大地电磁领域的重大意义和发展潜力。

### 5.1 实测天电信号资料处理解释

我们的 CNN 模型在大多数现场数据集上取得了稳健的结果,即使仅在有限的采集数据上训练时也是如此。为了验证模型的能力,我们将来自不同测区的两个现场数据输入到已经训练好的 CNN 模型中。在综合考虑地质条件、场源、噪声水平和其他因素后,我们最终选择了南京和武汉测区来组成测试数据集。为了与训练保持一致,每个输入样本都被归一化与训练样本相同,但没有进行数据增强。

在前向预测期间。为了避免我们的模型无法识别天电信号中心点 (ps) 位于采样窗口边缘的正样本。我们使用了一个重叠率为 50% 的滑动窗口,这使得天电信号的中心点 ps 能够从边缘移动到窗口的中心。

为了方便直观地评价所提方法的有效性,我们比较了各测点在 AMT 死频带范围内的功率谱密度的改善情况和视电阻率-相位曲线的平滑程度。由于 AMT 方法的特性要求地表观测响应函数必须随频率平滑变化,因此我们将曲线平滑度视为数据处理方法优越性的指标<sup>[109-110]</sup>。相位张量椭圆由椭圆的主轴和次轴表示,反映了相位关系随极化方向的变化<sup>[88][111-112]</sup>。对于每一次勘测,我们评估了相位张量拟断面和视电阻率-相位拟断面,这些拟断面提供了有关区域电阻率结构的方向性信息,更直观地反映了地下电阻率分布。这些指标是失真的主要参数<sup>[113]</sup>。

#### 5.1.1 案例一: 南京

第一个野外数据集来自中国江苏省南京市高淳地区。高淳区位于江苏省西南部,东北与溧阳、溧水接壤。西南与安徽省当涂市、宣州市、郎溪县接壤。地质上属南京凹陷边缘。溧高褶皱隆起带背斜自北向南倾斜穿过该区,分布有大面积黄土丘陵。在流水切割下,山头支离破碎,形成了区东部丘陵、丘陵、沟壑为特征的丘陵地貌。该勘探地点地貌以平原为主,离城市较远,受到人文强干扰较少,干扰主要以地下游散电流的形式



存在。

图 5-1 显示了南京 01 号测点的时间序列片段。如图所示，我们可以看到所提出的方法可以有效地从原始时间序列中识别出天电信号，这证明我们的模型确实学习了关于天电波形的特征表示。从表 5-1 中的数据可以看出，每个指标在我们的模型从未见过的测试数据集上也取得了很好的结果，这有力地证明了我们的模型良好的泛化能力。




图 5-1 南京时间序列片段，橘色部分表示我们网络识别的天电信号

表 5-1 南京测区部分测点质量指标

测点	001	002	003	004	005	006	Mean
A	0.969	0.956	0.959	0.932	0.946	0.936	0.949
P	0.723	0.849	0.717	0.791	0.727	0.841	0.774
R	0.960	0.756	0.962	0.782	0.652	0.667	0.796
F1	0.825	0.800	0.822	0.786	0.687	0.744	0.777

图 5-2 为 01 号测点功率谱密度对比图。从图 5-2-a 可以看出，原始时间序列中存在工业电流干扰（基频为 50Hz），在功率谱密度上表现为固定频率的峰值。图 5-2-b 验证了我们的方法能够抑制强频域噪声以恢复真实频谱，并更好地突出天电信号的主要频带（1.5KHz~5KHz）。

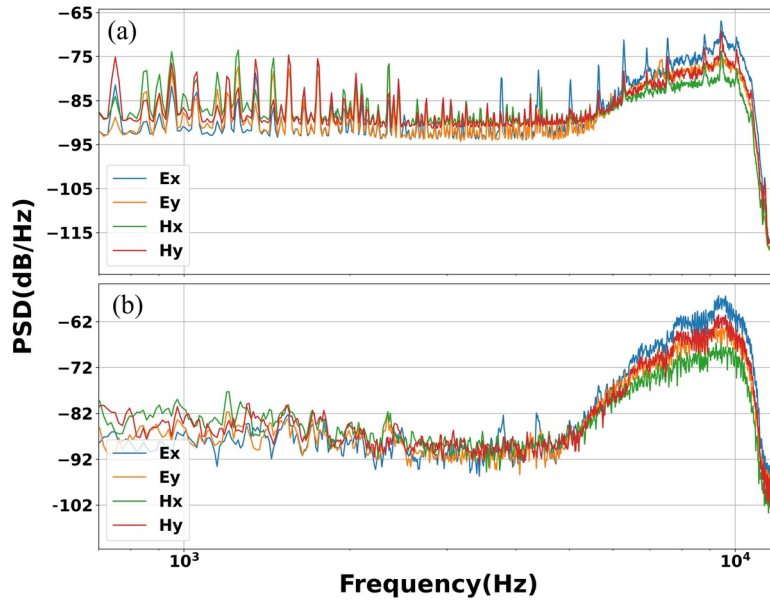


图 5-2 南京 01 号测点功率谱密度 (a)常规方法计算结果 (b) 天电挑选后计算结果

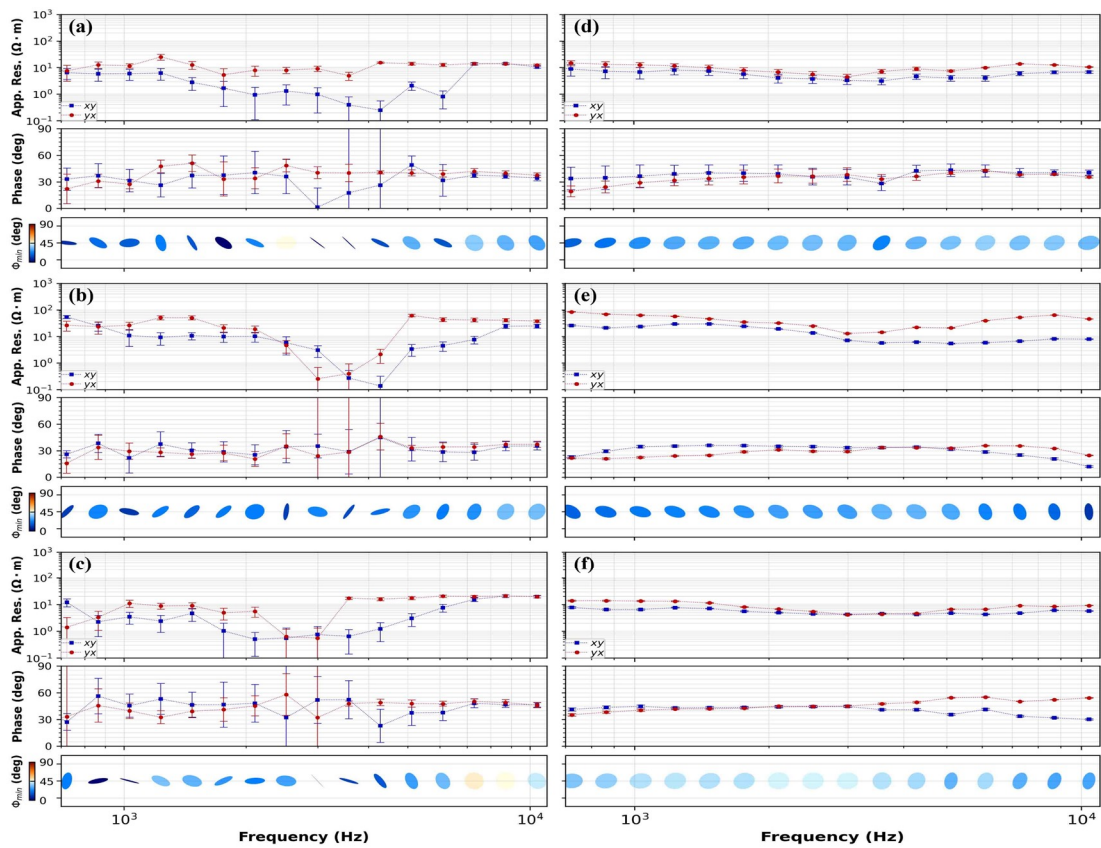


图 5-3 南京 01、02、03 测点视电阻率-相位曲线与相位张量椭圆 (a)-(c)常规方法计算的结果 (d)-(f) 天电挑选后计算结果

图 5-3 对比了三个相邻测点（01 号、02 号和 03 号）在 700 Hz 至 10 KHz 频段内的视电阻率-相位曲线，测点间距为 20 m。从图 5-3-a 到图 5-3-c 可以看出，视电阻率和相位在多个频点之间出现了高达两个数量级的异常衰减，这显然违背了地下电阻率结构应

缓慢变化的客观规律。相位曲线的异常偏差和误差棒置信区间表明“死区”内存在严重的阻抗估计错误。另一方面，图 5-3-d 到图 5-3-f 显示了使用所提出的方法计算的视电阻率-相位曲线。与未经处理的传统方法结果相比，视电阻率和相位恢复到更合理的值，并且所有曲线都更平滑，标准误差更小，这更好地保持了相邻测点之间的一致性。相应地，相位张量椭圆也表现出极佳的去极化特性，其主轴恢复了真实的地下电阻率结构的横向变化。总的来说，这些结果证明了所提出方法对于改善“死区”中天然场能量缺乏的有效性。

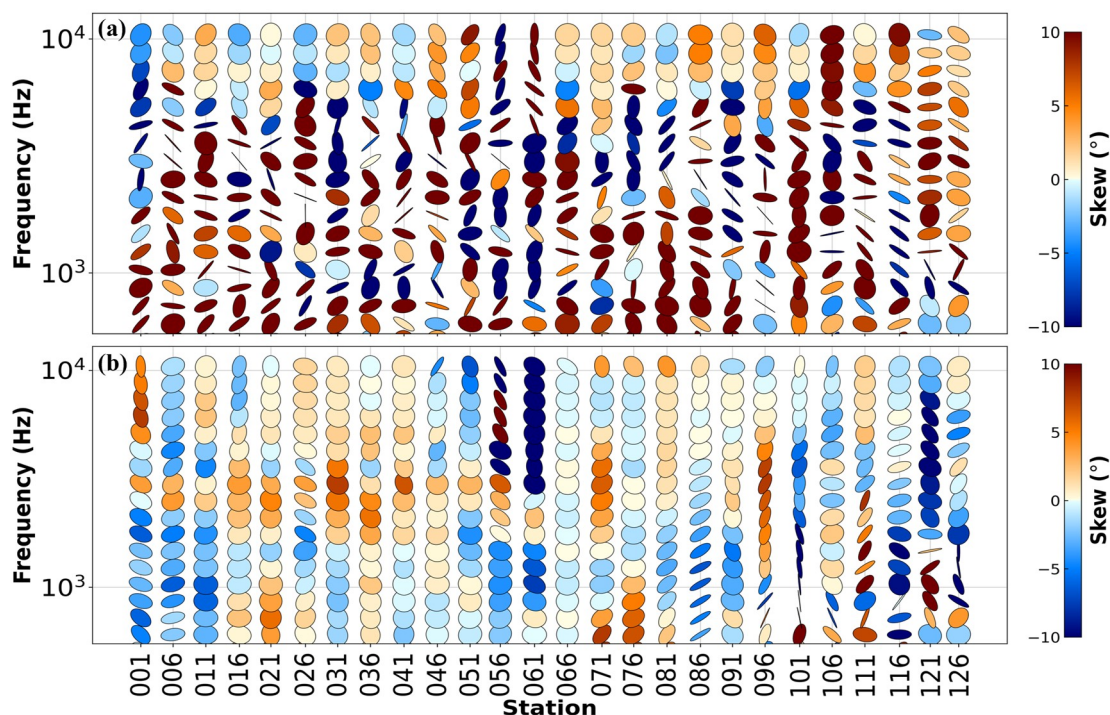


图 5-4 南京相位张量椭圆拟断面 (a)常规方法计算的结果 (b)天电挑选后计算结果

对于本次案例，图 5-4-a 显示原始相位张量拟断面上存在严重的电场畸变，这通常会改变局部电场的极化方向，从而导致观测响应因局部电导率不均匀性而扭曲<sup>[88]</sup>。通过计算所有 26 个同步测点组合的相位张量，如图 5-4-b 所示，我们的方法预处理的拟断面在死频带表现出更平滑的频率变化，同时在很大程度上消除了观测阻抗张量的扭曲，并恢复了涉及 2D 阻抗张量的电流畸变的张量图形表示。

图 5-5-a 显示了本案例中普遍存在的一个问题，即 AMT 场源能量不足导致死频带阻抗估计的误差。具体而言，视电阻率  $\rho_{xy}$  和  $\rho_{yx}$  之间呈现低电阻，在图 5-5-a 中显示为横向的深棕色长轴，并且在第 56、61 和 66 号测点出现异常的相位行为（即，相位反转）。图 5-5-a 突出显示了我们的方法在 700Hz 和 10KHz 之间的优越性。我们观察到图 5-5-b 中的视电阻率-相位拟断面趋于平滑，并且“死区”中的低电阻率的异常估计和相位的估计误差得到了适当地校正。




图 5-5 南京地区视电阻率-相位拟断面 (a) 常规方法计算的结果 (b) 天电挑选后计算结果

尽管这些实际数据的结构模式和波形特征与训练数据不同，但上述结果表明我们的方法在这些实测数据上表现良好，并在数据信噪比方面显著提高了性能。

### 5.1.2 案例二：武汉

为了进一步验证我们模型的普适性，我们提供了来自中国湖北省武汉市的第二个例子。该地区的地貌是汉江平原东缘向大别山南麓的过渡地带，中间为低丘丘陵，南北为丘陵环抱。地处山城交界处，勘探区富含与人类活动相关的电磁场产生的工业噪声（电线、工厂、电气设备等）和地形变化和浅部不均匀体（地形，随机分布的岩体）引起的地质噪声。勘探过程中，多种可控源电磁勘探方法（例如可控源电磁法（CSEM）、可控源音频大地电磁法（CSAMT）、双频感应极化法（DFIP）等）同时在此工作，这给

AMT 勘探带来带来了强烈干扰，具体体现在时间序列中。事实上，第二个实测数据示例是最具挑战性的一个，稳健地计算该实测数据的视电阻率和相位对于现有方法来说仍然是一个重大挑战。




图 5-6 武汉时间序列片段，橘色部分表示我们网络识别的天电信号

表 5-2 武汉测区部分测点质量指标

测点	001	002	003	004	005	006	Mean
A	0.946	0.931	0.949	0.920	0.897	0.916	0.926
P	0.643	0.512	0.678	0.543	0.501	0.507	0.564
R	0.873	0.886	0.865	0.923	0.912	0.927	0.898
F1	0.740	0.649	0.760	0.684	0.648	0.655	0.689

从图 5-6 可以看出，41 号测点采集的实测数据在时间序列上呈现出较强的背景噪声干扰，这些干扰的存在给数据解释带来了很大的困难。然而，即使面对如此多样的时间序列波形，我们训练有素的模型仍然能够准确识别天电信号，并避免将高振幅脉冲噪声误判为天电信号。这一发现进一步支持了我们 CNN 模型强大表达性，并验证了模型对数据噪声的鲁棒性。表 5-2 显示了武汉测区数据集的分类质量指标。受低信噪比数据影响，武汉测区的模型平均分类精度比南京测区低了将近 2%。

图 5-7 显示了第 41 个测点的功率谱密度对比结果。图 5-7-a 显示该站在 1KHz 至 6KHz 频带范围内受到文化噪声的严重干扰。图 5-7-b 显示自然场源信号的真实频率基

本可以从工业干扰中恢复。然而，由于采集到的天电信号较少以及强干扰源(如电源线)的存在，我们仍然可以在“死区”中看到少量干扰谐波残留。

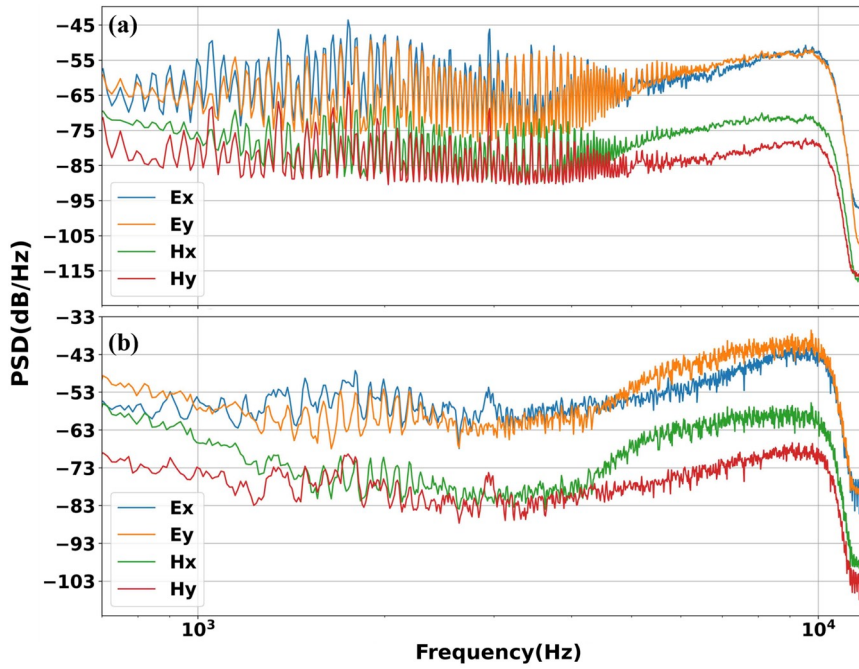


图 5-7 武汉 41 号测点功率谱密度 (a)常规方法计算结果 (b) 天电挑选后计算结果

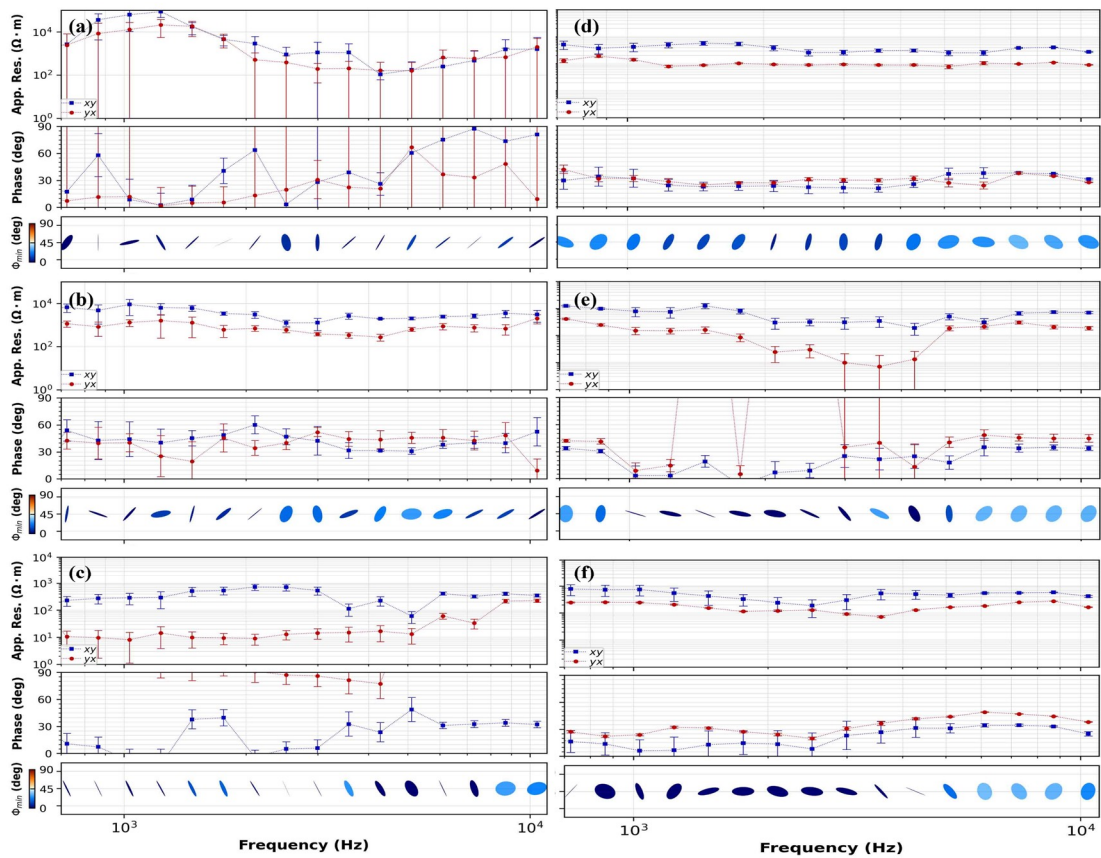


图 5-8 武汉 41、46、50 测点视电阻率-相位曲线与相位张量椭圆 (a)-(c)常规方法计算的结果 (d)-(f) 天电挑选后计算结果

图 5-8 为第 41、46、50 号测点视电阻率及相位对比结果。对比结果表明，低信噪比数据导致对“死区”中的视电阻率和相位的估计不佳。图 5-8-a 到图 5-8-c 显示所有测点的  $\rho_{xy}$  和  $\rho_{yx}$  都缺乏平滑度，并且曲线的最小值和最大值之间的差异接近于 4 个数量级。误差棒和相位张量椭圆也表明传统阻抗估计方法在强噪声下的崩溃，尤其是在第 46 号测点。图 5-8-d 到图 5-8-f 显示了我们的方法处理后的结果。可以看出，视电阻率曲线消除了虚假的电学结构变化同时恢复了平滑性，相位曲线修正了异常偏移以恢复良好的一致性，上述问题已经得到妥善解决，尽管误差棒和相位张量椭圆仍表现出受到噪声的轻微影响。

从图 5-9-a 可以看出，原始数据受到极化的干扰非常严重，特别是在第 26~34、41、43 和 46 号测点。图 5-9-b 显示相位张量拟截面部分从强噪声水平引起的相位张量椭圆畸变中恢复，但仍有进一步改进的空间。从图 5-10-a 可以看出，明显存在视电阻率突变和相位估计误差问题，特别是在上述测点。图 5-10-b 显示了本章使用方法所计算得出的拟断面，计算结果比图 5-10-a 中的更平滑和更合理。此外，图 5-10-a 中出现的异常在图 5-10-b 中得到了有效消除和纠正。这表明我们的方法在处理低信噪比数据方面仍然表现良好。




图 5-9 武汉相位张量椭圆拟断面 (a)常规方法计算的结果 (b)天电挑选后计算结果

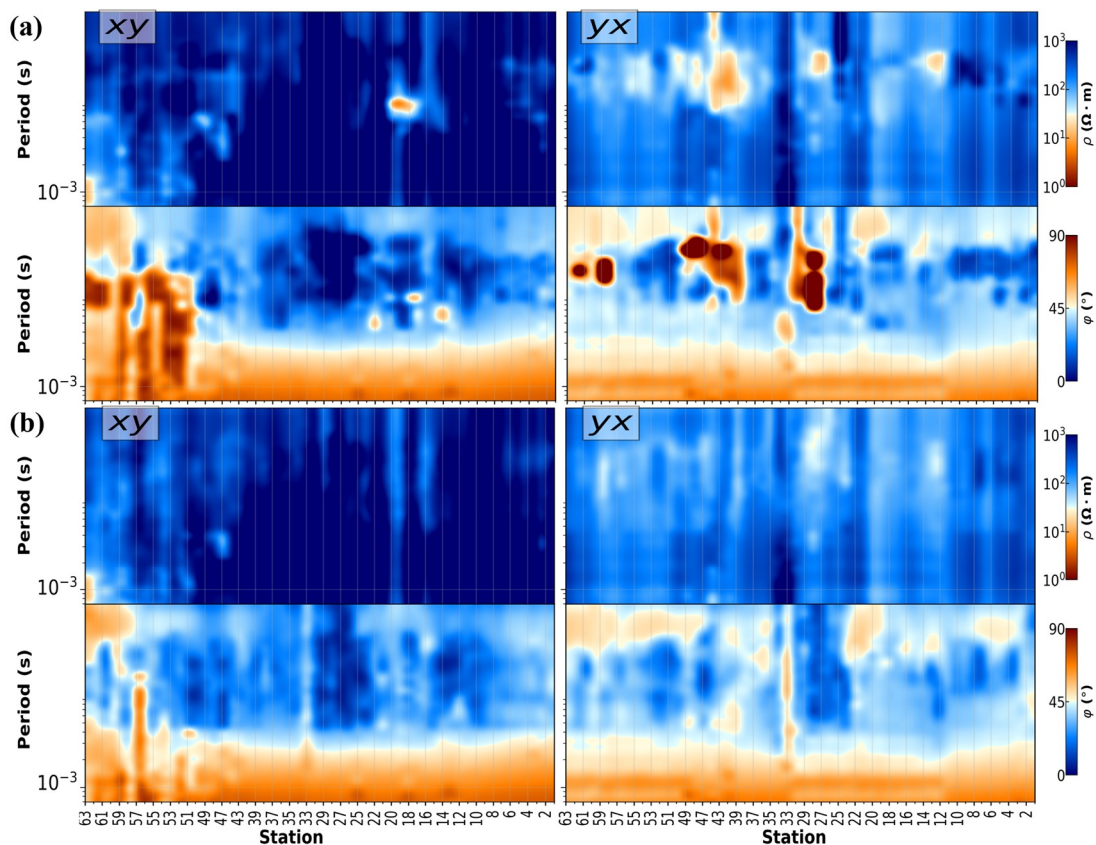


图 5-10 武汉地区视电阻率-相位拟断面 (a) 常规方法计算的结果 (b) 天电挑选后计算结果

对于这两个现场数据示例，我们从未构建具有相似噪声类型和波形特征的特定训练样本。然而，我们的模型仅使用现有时序样本进行训练，通过准确识别高振幅天电信号显示出卓越的性能，即使提取的天电信号可能与手工挑选的实际标签并不严格匹配。但这些表现意味着经过训练的模型已经成功学习了全局特征模式，而不是简单地记住输入训练样本。

## 5.2 实测 AMT 数据去噪处理

本文以贵州省西北地区赫章县水塘乡猪拱塘铅锌矿为例，研究了不同的去噪方法在实测大地电磁数据点中的噪声压制效果。在实际生产过程中，勘探区内存在多种主动源勘探方法（如广域电磁法、可控源音频大地电磁法、激电法等）共同作业。我们将上述方法的发射源作为干扰源，采用未受到发射源干扰的时间周期内的采集信号作为干净信号，再利用该信号所计算的视电阻率-相位曲线与去噪前后的结果进行对比，得出结论。

本次勘探使用长沙巨杉智能科技有限公司与中南大学联合研制的电磁数据采集站（GSEM）对实际大地电磁数据进行采集，其采样率为 150Hz。如图 5-11 所示，这是一组由多个噪声源共同作用而形成的典型的大地电磁信号时序。在强干扰条件下，天然场源的有效信号被完全淹没，难以从时域上识别出天然电磁场信号。此外，受多重干扰源



影响，信号波形杂乱无章，在时域和频域上未见明显的规律性，这对所有去噪算法而言都是一个巨大的挑战。




图 5-11 噪声样本库

在本次试验研究中，我们分别采用了经验模态分解（EMD）、小波去噪、数学形态滤波和神经网络四种方法对大地电磁数据进行了处理。对于 EMD 方法，我们首先将原始数据分解为一系列本征模函数（IMF），通过对每个 IMF 进行滤波得到去噪后的数据，然后将去噪后的 IMF 进行重构，得到最终的去噪数据。这种方法可以适应各种信号类型和噪声情况，对于非线性和非平稳信号的去噪效果尤为明显。小波去噪和数学形态滤波与前文提到的方法类似，都是通过对数据进行分解和滤波处理来实现去噪。针对小波去噪方法，我们首先对数据进行小波分解，得到不同频率范围内的小波系数，然后根据特定的阈值进行系数的滤波处理，最后进行小波重构得到去噪后的数据。数学形态滤波方法则是利用信号的形态特征，如信号的上升和下降沿，进行去噪处理，适用于包含有较多峰值和过渡段的信号。最后，我们将本文使用的神经网络方法对大地电磁数据进行了去噪处理。神经网络方法可以根据原始数据自动学习噪声模型，并对数据进行预测和去噪。在本次试验中，我们采用了基于 U-net 网络结构的自监督学习算法进行去噪处理，我们通过模型对原始数据进行低频拟合，得到拟合曲线，然后将原始数据减去拟合曲线得到去噪后的数据。该方法对于大规模数据的去噪具有较好的效果。

为了评估四种方法的效果，我们将去噪后的数据与原始数据进行比较，分别计算两者的信噪比，并通过统计分析比较了大地电磁法中常用去噪算法的量化评价指标。对于频谱，我们对比各方法去噪前后的主要噪声成分滤除程度，以及在频谱上是否呈现随机性。除此之外，我们还对比了单测点数据的视电阻率-相位曲线、相干度、极化方向等结果；对比了测区的视电阻率-相位伪截面和相位张量伪截面结果。

### 5.2.1 时域波形和频谱对比

我们随机选取了两次测量过程中获取的大地电磁信号片段，如图 5-12 所示，包含两正交电道和磁道信号，采样率为 150Hz，采样时间为 1 分钟。在两测点电道时域波形中，周期性方波充斥整个采集时序片段，噪声波形呈现一定规律性，具有明显的直流特征，幅值高达正常信号的数个量级，曲线呈现出分段断开的特点，整体连续性极差；磁道时域波形中，大量脉冲噪声和类三角波充放电噪声伴随着整个采集时段，正常信号被严重压制。图 5-13 显示了相应的功率谱特征，各功率谱反映出信号失去随机性，且受到强烈的极化干扰。

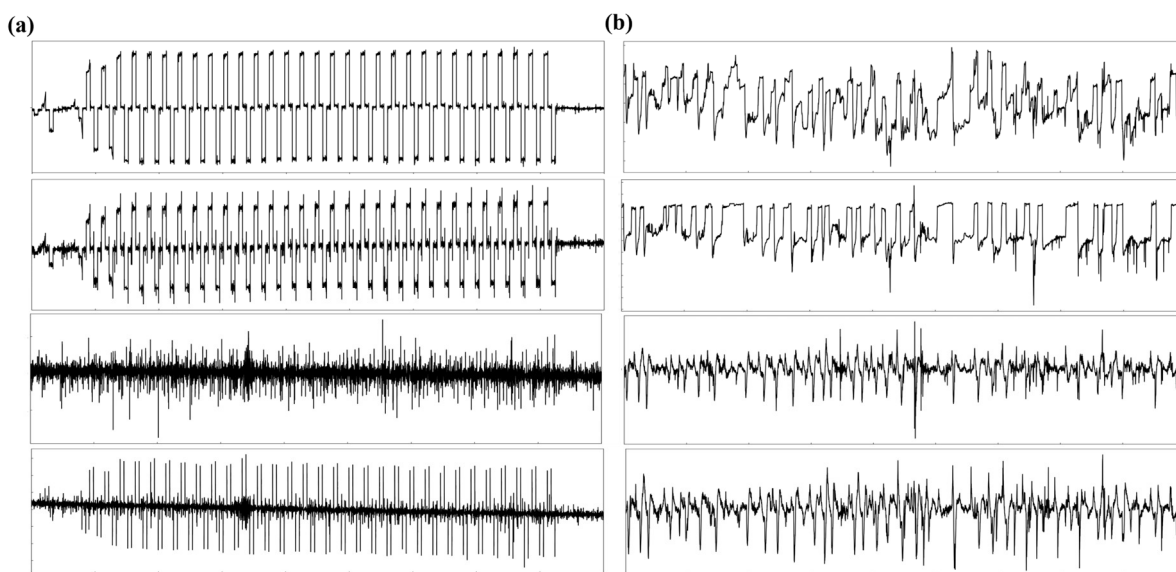


图 5-12 不同测点的采集时序波形 (a) 第 101020 号测点 (b) 第 001180 号测点

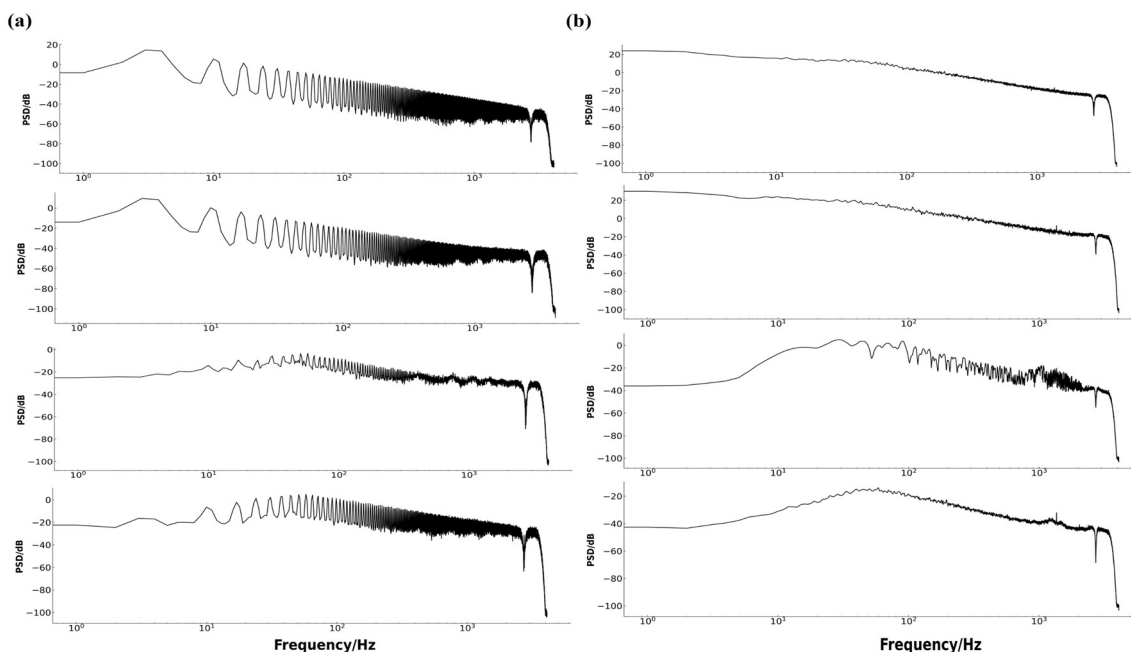


图 5-13 不同测点的采集功率谱 (a) 第 101020 号测点 (b) 第 001180 号测点

5.2.1.1 经验模态分解




图 5-14 实测数据 EMD 分解结果 (a) 多阶 IMF 分量 (b) 频域特征




图 5-15 实测数据 EMD 去噪时域结果 (a) 原始信号 (b) 去噪信号 (c) 抽取噪声




图 5-16 实测数据 EMD 去噪频谱结果 (a) 原始信号 (b) 去噪信号 (c) 抽取噪声

针对经验模态分解方法，我们首先进行了原始含噪数据的分解，得到了不同尺度下的 IMF 分量和剩余项。接着，利用硬（软）阈值方法对各 IMF 分量进行噪声压制。最后，选取主要包含信号能量的 IMF 进行重构，得到去噪后的大地电磁信号。

图 5-14 是 101020 实测数据 EMD 分解图，图 5-14-a 是原始信号及其多阶 IMF 分量，图 5-14-b 是相对应的频谱。从图 5-14 中各阶 IMF 的观察可知，EMD 分解在信号时域中呈现出层层滤波的特点，即从小尺度到大尺度逐渐滤除不同频率的成分。同时从图 5-14 中各阶 IMF 的频谱表现可以观察到，EMD 分解在频域中也具有类似的层次结构，即从高频到低频逐渐滤除不同频率的成分，因此也凸显出了 EMD 分解具有多分辨率分析的特点。

图 5-15 和图 5-16 为实测数据 EMD 去噪时频域结果。可以发现在面对强干扰情况下，EMD 方法具有一定局限性，去噪时序信号中仍有部分噪声残留，频谱中仍残留有高频噪声成分，需要精心选择方法和参数才能取得一个稍好的结果。

表 5-3 显示了去噪前后信号的统计参数：含噪信号的统计参数最大值为 1.97mv，最小值为 -1.80 mv，均值为 0.0372mv，标准差为 0.7448，能量为 489.3  $\text{mv}^2$ 。很明显，由于噪声的影响，信号变得非常不稳定，总能量指标异常。去噪信号的统计参数最大值为 0.59 mv，最小值为 -0.57mv，均值为 0.0026 mv，标准差为 0.0301，能量为 180.37  $\text{mv}^2$ 。

表 5-3 原始信号与去噪信号统计参数 (EMD 去噪)

信号	最大值	最小值	均值	标准差	能量
原始信号	1.97	-1.80	0.0372	0.7448	489.3
去噪信号	0.59	-0.57	0.0026	0.0301	180.37

实验结果表明,经验模态分解方法在去除大地电磁数据中的噪声方面具有一定的效果。通过对不同 IMF 的分析和选择,可以减少噪声对信号的干扰,从而得到更为准确的深度探测结果。但需要注意的是,经验模态分解方法在处理大地电磁数据时需要考虑到数据的特点,如信号的频带、噪声的特性等,需要根据实际情况进行参数调整和优化,否则会因方法选择不当而导致较大误差。

### 5.2.1.2 小波分解

小波去噪方法的步骤如下:(1)将原始的大地电磁时序数据进行小波分解,得到不同尺度下的小波系数。(2)根据小波系数的大小和阈值进行去噪,去掉小于阈值的小波系数。(3)利用去噪后的小波系数重构小波,恢复去噪信号。这里我们采用 Trad 等人的原则对小波基函数(Wavelet)和不同阈值进行了大量消融实验<sup>[23]</sup>,对于本任务,确定小波基函数为 Daubechies, 阈值选择硬阈值法, 值为 0.1。

图 5-17 和图 5-18 为实测数据小波去噪时频域结果。可以发现当噪声波形复杂且部分噪声能量相对较弱时,去噪效果却不理想,反而在去噪的同时又添加了部分人为噪声。




图 5-17 实测数据小波去噪时域结果 (a) 原始信号 (b) 去噪信号 (c) 抽取噪声




图 5-18 实测数据小波去噪频谱结果 (a) 原始信号 (b) 去噪信号 (c) 抽取噪声

表 5-4 显示了去噪后信号的统计参数：最大值为 0.16 mv，最小值为-0.17mv，均值为-0.00014 mv 标准差为 0.0385，能量为 120.14 mv<sup>2</sup>。

表 5-4 原始信号与去噪信号统计参数 (小波去噪)

信号	最大值	最小值	均值	标准差	能量
去噪信号	0.16	-0.17	-0.00014	0.0385	120.12

综合分析实验结果，小波去噪算法的性能受到小波基函数的选择、去噪阈值的设置等参数的影响，这些参数的不同组合可能会导致不同的去噪效果，使得算法的稳定性较差。虽然该方法能够去除大部分平稳强噪声，但由于小波分解与重构相当于带阻滤波技术，消除这些噪声的同时却牺牲了部分有用信号。而且由于硬阈值法的阈值函数具有不连续性，重构所得的信号会产生伪吉布斯效应。

### 5.2.1.3 数学形态滤波

针对数学形态滤波方法，首先根据需求选择合适的结构元素，然后使用所选的结构元素对原始数据进行开运算操作，随后进行闭运算操作，最后将原始数据与其进行差分得到去噪后的结果。




图 5-19 实测数据数学形态滤波去噪时域结果 (a) 原始信号 (b) 去噪信号 (c) 腐蚀运算/开-闭运算信号 (d) 膨胀运算/闭-开运算信号




图 5-20 实测数据数学形态滤波去噪频谱结果 (a) 原始信号 (b) 去噪信号 (c) 腐蚀运算/开-闭运算信号 (d) 膨胀运算/闭-开运算信号

图 5-19 和图 5-20 为实测数据数学形态滤波去噪时频域结果。可以发现数学形态滤波可以对信号进行局部处理，不会破坏信号的整体性质，去噪结果呈现很好的随机性。但当噪声尺寸和种类较为复杂时，可能会在信号中引入一定的失真或偏差，需要在去噪效果和信号完整性之间做出权衡。

表 5-5 显示了去噪前、后信号的统计参数：最大值为 0.44 mv，最小值为-0.44mv，均值为-0.00044 mv，方差为 0.325，能量为 185.6 mv<sup>2</sup>。

表 5-5 原始信号与去噪信号统计参数 (数学形态滤波)

信号	最大值	最小值	均值	标准差	能量
去噪信号	0.44	-0.44	-0.00044	0.0325	185.6

数学形态滤波是一种非线性的信号处理方法,与其他方法相比,其对信号的局部特征更加敏感,能够更好地保留信号的特征。但是,算法的参数需要根据信号的特点手动调整,不够自适应。原则上,对于每一种噪声波形,应分别设计对应合适的结构元素。但矿集区内噪声波形复杂多样,难以找到适用于所有噪声波形的通用结构元素集。

#### 5.2.1.4 自监督去噪

图 5-21 为经本文方法处理后所得信号,对比图 5-21-a 和图 5-21-b 能够看出,此组信号不再具有周期结构,显示出大地电磁信号随机的特性,图 5-21-c 展示了所提取的噪声波形,可以看到提取的噪声轮廓连续、清晰且光滑,从而使得去噪信号中尽可能地保留了大地电磁有效信号的细节信息,对有效信号失真较小。图 5-22 显示出了对应的频谱曲线,图 5-22-a 可以明显观察到 50 Hz 及其谐波的强干扰尖峰,该频点处的信号能量显著强于周围频点,从图 5-22-b 部分可以看出,经自监督去噪后,50 Hz 处的峰值得到了很好的抑制,仅在其附近频点产生较少的能量损失。




图 5-21 实测数据自监督去噪电道时域结果 (a) 原始信号 (b) 去噪信号 (c) 抽取噪声






图 5-22 实测数据自监督去噪电道频谱结果 (a) 原始信号 (b) 去噪信号 (c) 抽取噪声




图 5-23 实测数据自监督去噪磁道时域结果 (a) 原始信号 (b) 去噪信号 (c) 抽取噪声




图 5-24 实测数据自监督去噪磁道频谱结果 (a) 原始信号 (b) 去噪信号 (c) 抽取噪声

此外，我们还针对磁场通道的噪声进行了去噪实验。图 5-23-a 显示了该采集磁道多受脉冲噪声干扰，呈正负交替规律出现，图 5-24-a 显示了对应的频谱，从中可以明显看出噪声干扰存在的频点及其特征。图 5-23-b 显示了磁道时域的去噪结果，有效去除了大部分高振幅脉冲噪声，保留了场源信号，整体呈现出有效信号的细节部分，图 5-24-b 所对应的去噪信号频谱也验证了方法的有效性和较小的失真。

表 5-6 显示了去噪前后信号的统计参数：去噪信号（电道）的统计参数最大值为 0.01mv，最小值为-0.01mv，均值为 0.00021mv，标准差为 0.0027，能量为 161.2  $\text{mv}^2$ 。含噪信号(磁道)的统计参数最大值为 25.73mv，最小值为-12.82 mv，均值为-0.00083mv，标准差为 2.468，能量为 253.7 $\text{mv}^2$ 。去噪信号（磁道）的统计参数变为最大值为 2.21mv，最小值为-2.23mv，均值为-0.00058mv，标准差为 0.373，能量为 112.9  $\text{mv}^2$ 。将去噪前后的信号进行比较，信号的极值与均值等指标的比值从原来的十几倍降低到了几倍，同时方差也减小了一个数量级。这说明去噪处理有效地减小了信号的振幅差异和波动性，使信号更加平稳和稳定，本文方法在所有指标上都取得了优越的效果。

表 5-6 原始信号与去噪信号统计参数（自监督去噪）

信号	最大值	最小值	均值	标准差	能量
去噪信号（电道）	0.01	-0.01	0.00021	0.0027	161.2
原始信号（磁道）	25.73	-12.82	-0.00083	2.468	253.7
去噪信号（磁道）	2.21	-2.23	-0.00058	0.373	112.9

在实验中，我们将模型应用于不同采集通道和不同种类的噪声干扰，并通过对比去噪前后的信号质量来评估去噪性能。综合实测数据处理的时间序列与频谱对比结果，本文所提出的基于深度学习的去噪方法在处理复合噪声时表现最佳，其去噪效果能够有效压制多种噪声的影响，同时保留了原始信号的特征信息，对有效信号损失较小。相比于其他传统方法，该方法在去噪结果和处理效率都展示了其强大的优越性。

### 5.2.2 处理结果对比

#### 5.2.2.1 测点结果对比

为了验证不同去噪算法的能力，我们计算了上述算法去噪后的信号视电阻率-相位曲线来进一步评估各个算法的去噪效果。为此，我们挑选了两个受强噪声干扰极端情况下的测点进行算法的对比。

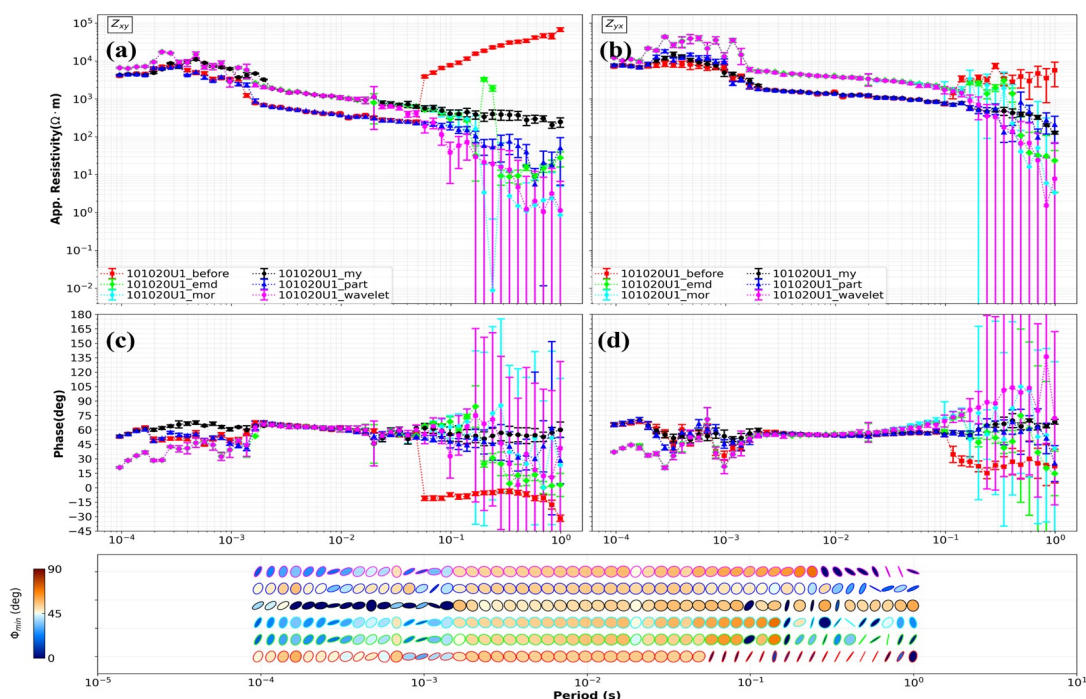


图 5-25 第 101020 号测点视电阻率-相位结果 (a)  $\rho_{xy}$  (b)  $\rho_{yx}$  (c)  $\phi_{xy}$  (d)  $\phi_{yx}$  红色为原始数据结果；绿色为 EMD 结果；青色为数学形态滤波后结果；黑色为本文方法结果；蓝色为人工编辑结果；粉色为小波去噪后结果

图 5-25 显示了实测数据中第 101020 号测点的视电阻率-相位结果。从图 5-25-a 中可以看出在 xy 方向上原始视电阻率存在一个低频跳变，曲线在相邻频点间开始不连续，异常值提升了将近 2 个数量级。相位不连续，并伴随着相位反转的异常现象。yx 方向上跳变程度稍小，这是因为 Hy 通道的采集数据受干扰较小（图 5-12-a）。相位仍然存在一定程度的反相行为。两方向上的视电阻率曲线在不同程度上均有  $45^\circ$  上升趋势，在 17Hz 附近就出现明显的近源效应，视电阻率曲线整体飙升，数值达到了接近  $10^5 \Omega \cdot m$  的异常值。这种低频跳变和曲线不连续的现象是由于方波周期噪声干扰引起的。该干扰信号在

频域上存在大量的高次谐波成分，这些高次谐波信号会混叠到原始信号中，从而导致了原始信号的失真和跳变。

图中数学形态滤波所计算的  $\rho_{xy}$  在 4.18Hz 处存在一个离群点，且在 5Hz 附近仍然存在异常突变现象； $\rho_{yx}$  曲线平滑度有所改善，但误差棒表明该方法在强噪声下的崩溃，相位结果上呈现较大波动，说明仍有强噪声残留，低频计算结果不具备参考价值。小波去噪结果稍好于数学形态滤波，曲线在低频段更为连续，但在  $\rho_{yx}$  方向上存在向下衰减趋势，且误差棒范围过大，相位上消除了反相行为，但依旧存在估计不稳定现象。从图 5-25 中可以看出时序中存在长周期性方波噪声，由于周期方波噪声包含多个频率成分，传统的 EMD 方法无法有效地将其从信号中去除。特别是在信号和噪声之间存在相位差异时，EMD 方法甚至会产生不良影响，如模态混叠和失真。人工编辑方法通过截取一段不受噪声干扰或受干扰较小的时序片段进行阻抗估计，即便所得结果能较好地反映真实地下情况，若不采取去噪措施，最终仍会在单个频点处存在突变。通过对比，可以明显看出本文方法的去噪效果优于其他方法，视电阻率曲线和相位曲线在所有频点上都呈现出良好的连续性和平滑性，消除了低频跳变和相位反转现象，误差棒大小也恢复到了正常区间。此外，相位椭圆张量也显示了去极化性质，有力地证明了本文方法在去噪结果上的优势。

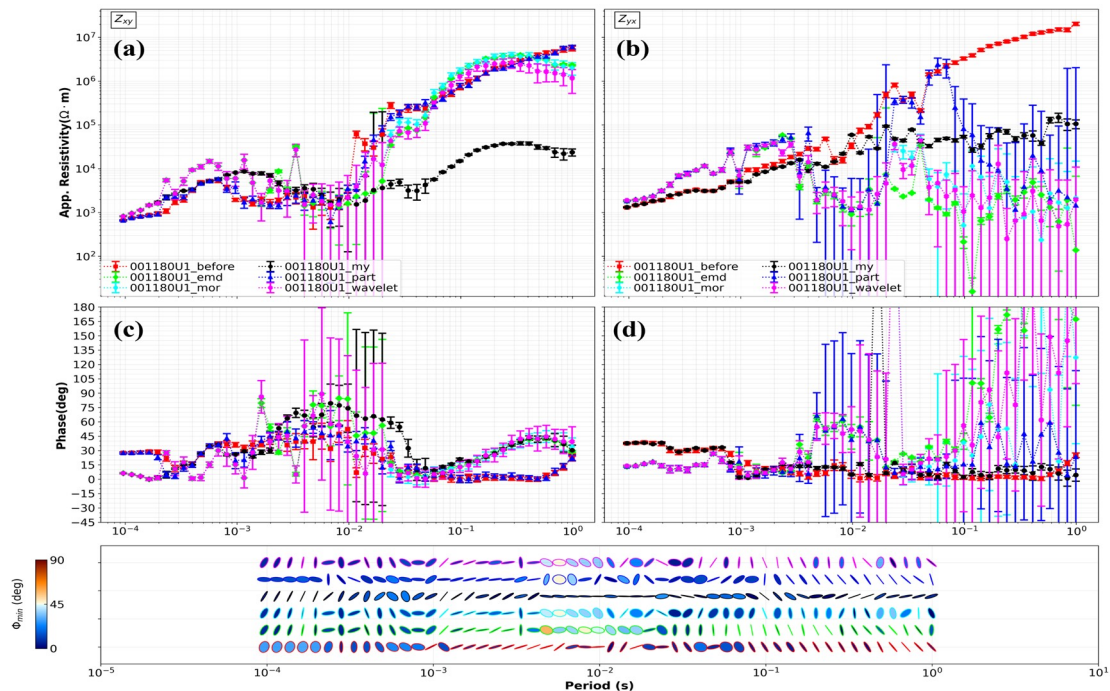


图 5-26 第 001180 号测点视电阻率-相位结果 (a)  $\rho_{xy}$  (b)  $\rho_{yx}$  (c)  $\phi_{xy}$  (d)  $\phi_{yx}$  曲线含义同上

图 5-26 显示了实测数据中第 001180 号测点的视电阻率-相位结果。该测点勘探期间，人工干扰源活动最为频繁，故该测点为受干扰最为严重的情况，对任何去噪算法而言都是一个严峻的挑战。原始采集时序中存在的长周期强干扰造成了视电阻率曲线整体向上漂移，这些强干扰几乎完全湮灭有用信号，使得数据的信噪比极低。而由于受到强

噪声的干扰, 阻抗估计主要信号成分为噪声成分, 最终计算结果仅仅只能体现出噪声源的特征, 无法带来地下真正电性结构等有效信息。除此之外,  $y_x$  方向视电阻率高达  $10^7 \Omega \cdot m$ , 这明显违背了客观事实。

数学形态滤波方法受全频段长周期噪声干扰, 已失去了去噪的鲁棒性。 $\rho_{xy}$  仅在 24Hz-50Hz 频带内的曲线连续性有所改善, 其余频点效果改善不明显;  $\rho_{yx}$  方向中频和低频结果估计失真, 体现在误差棒大小以及不合理地跳变现象上, 说明该方法不适用于该测点情况。小波去噪方法面临了同样的问题, 原始采集时序噪声成分过多, 小波分解无法有效分离噪声与信号成分, 故无法重构有效信号, 去噪效果不尽如人意。EMD 方法假设数据是局部平稳的, 而这一假设在该极端情况下并不成立。因此, 在存在非平稳数据的情况下, EMD 无法提供准确的分解结果, 最终导致了错误的结果。本文提出的方法在曲线整体连续性上得到了很大的改善, 在 100 Hz ~ 1 Hz 范围内, 其他方法的显著电阻率曲线在  $y_x$  方向上有  $45^\circ$  上升趋势, 而本文方法的显著电阻率曲线仅略有上升趋势。

图 5-27-a 显示了 101020 号测点去噪前的相干度结果。受强噪声影响, 10Hz 以下的相干度急剧下降, 最低仅 0.15。在使用本文的方法进行去噪处理后, 低频相干度有了明显改善, 90% 的频点相干度水平提升至 0.9 以上 (图 5-27-b), 仅在 2Hz 附近有轻微散射, 同时高频的相干度也从 0.8 提升到了接近 1.0。

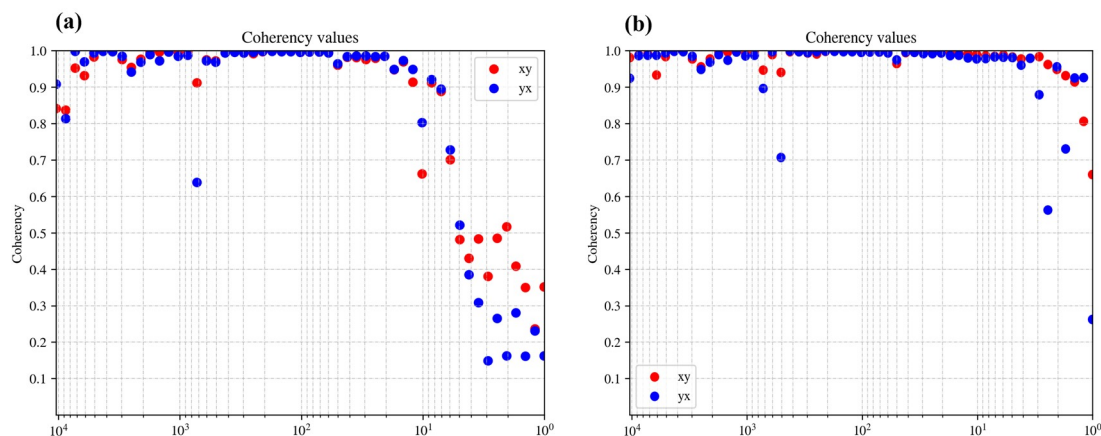


图 5-27 第 101020 号测点相干度对比结果 (a) 原始数据 (b) 去噪数据

图 5-28 显示了另外一个实例去噪前后的相干度结果。可以观察到所有频率的相干度都非常低 (图 5-28-a), 尤其是在中频段两个方向上的相干度值都在 0.6 以下。采用上述的流程进行去噪处理后, 我们可以观察到重新处理数据后的结果有了显著的改善 (图 5-28-b)。

电磁场的极化方向是衡量电磁干扰程度的一个重要指标<sup>[114]</sup>。为了进一步验证所提方法的有效性, 我们对电磁场极化方向进行了计算和分析。根据极化方向的物理意义, 当没有强干扰存在时, 极化方向是随机的; 反之, 极化方向会相对集中且规则。

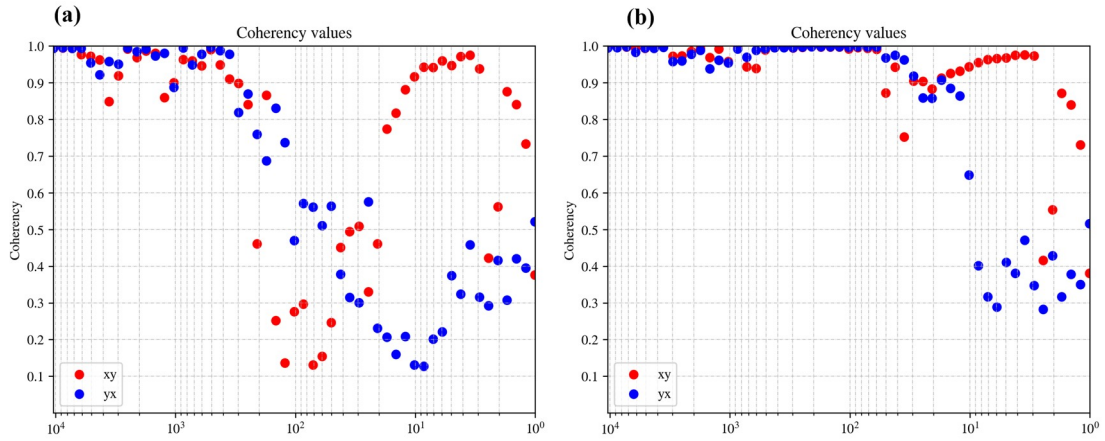


图 5-28 第 001180 号测点相干度对比结果 (a) 原始数据 (b) 去噪数据

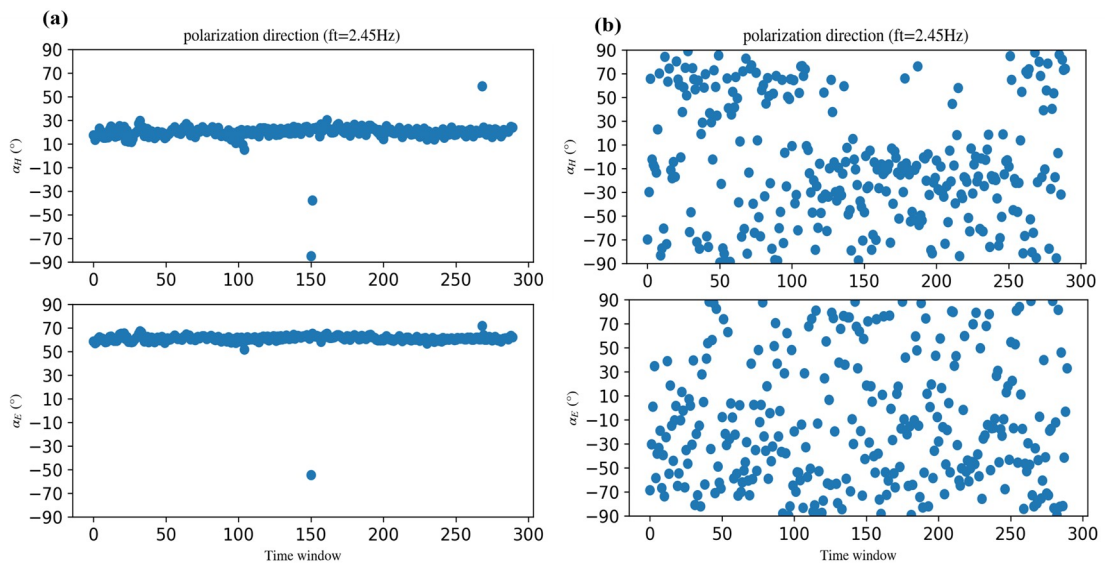


图 5-29 第 101020 号测点极化方向 (2.45Hz) 对比结果 (a) 原始数据 (b) 去噪数据

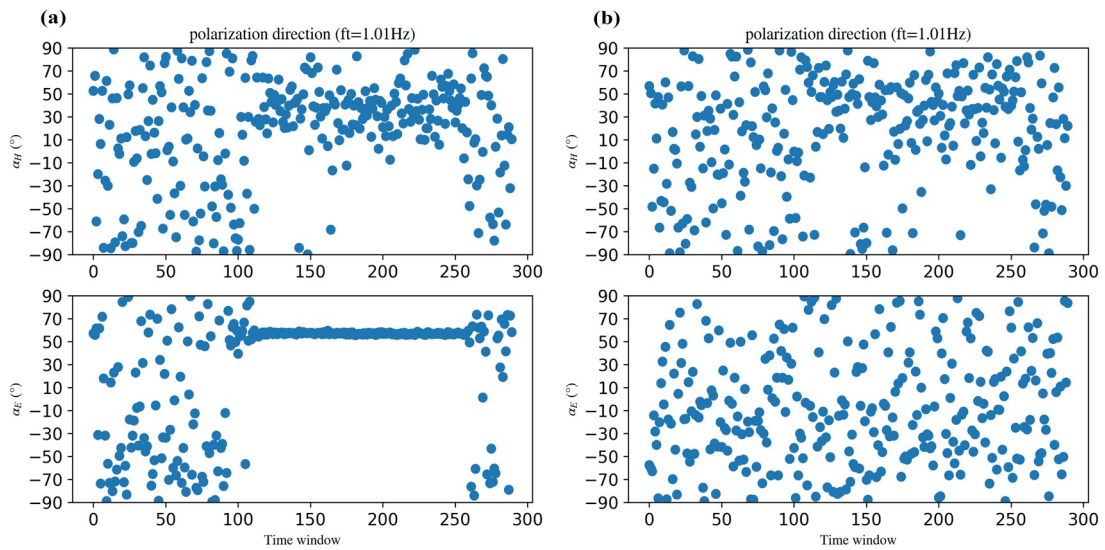


图 5-30 第 101020 号测点极化方向 (1.01Hz) 对比结果 (a) 原始数据 (b) 去噪数据

如图 5-29-a 所示, 101020 号测点 ( $f_t=2.45\text{Hz}$ ) 的电磁道均受到了强烈的极化干扰, 磁场通道 ( $\alpha_H$ ) 的极化方向集中在  $10^\circ \sim 30^\circ$  之间, 电场通道 ( $\alpha_E$ ) 的极化方向集中在  $50^\circ \sim 70^\circ$  之间。图 5-29-b 为本文方法处理的数据极化方向示意, 分析发现电场和磁场的极化方向已经完全向不同方向散射, 更加接近自然电磁场的随机特性。同样地, 101020 号测点 ( $f_t=1.01\text{Hz}$ ) 在 100-250 时间窗口内也受到了强电磁极化干扰 (图 5-30),  $\alpha_H$  的极化方向集中在  $30^\circ \sim 50^\circ$  之间。结合图 5-25 中这两个实测点在 2.45 Hz 和 1.01 Hz 处的视电阻率-相位可以看出, 数据质量有了很大提高, 保留了更多有用可靠的地下地电信息。

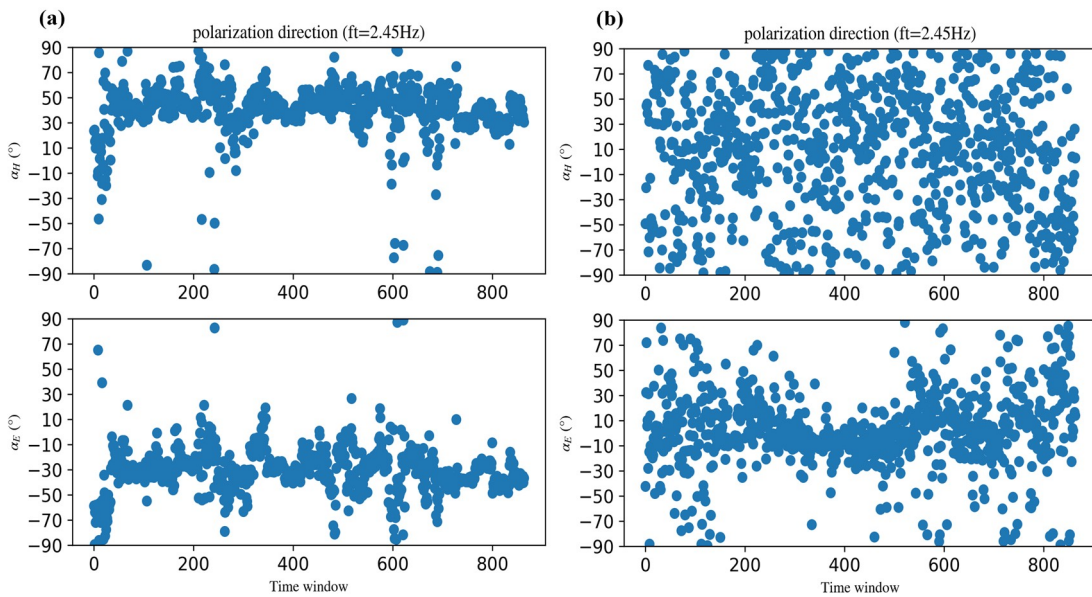


图 5-31 第 001180 号测点极化方向 (2.45Hz) 对比结果 (a) 原始数据 (b) 去噪数据

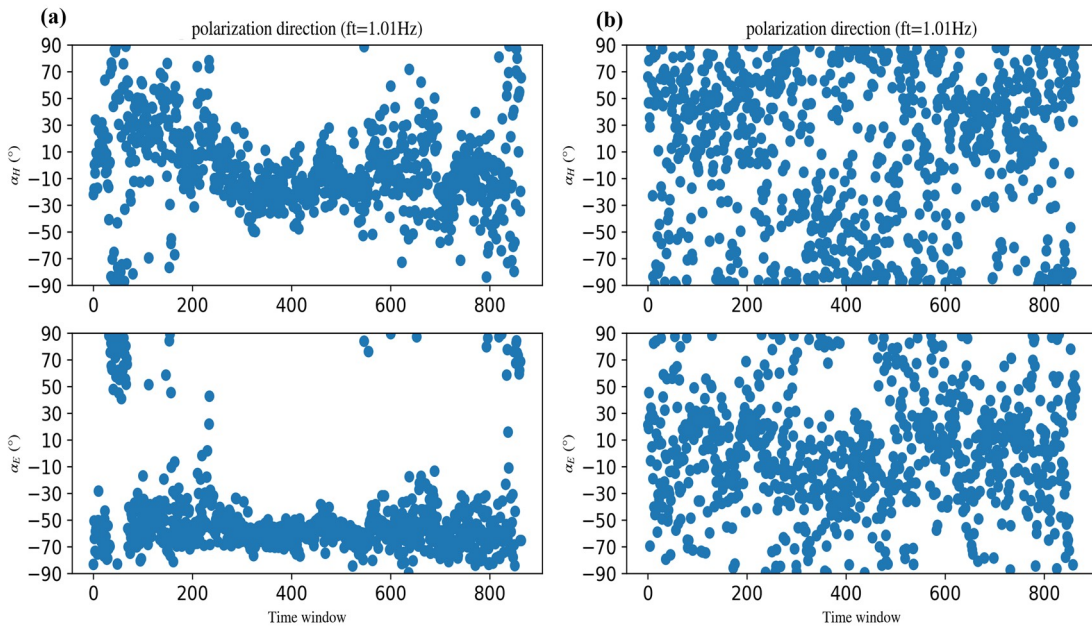


图 5-32 第 001180 号测点极化方向 (1.01Hz) 对比结果 (a) 原始数据 (b) 去噪数据

噪声导致偏振方向在某些角度汇聚, 001180 号测点 ( $f_t=2.45\text{Hz}$ ) 几乎所有时间窗的  $\alpha_E$  和  $\alpha_H$  都在  $30^\circ \sim 70^\circ$  和  $-50^\circ \sim -10^\circ$  的范围内被强烈极化 (图 5-31-a), 显示出强烈的近场效应。图 5-32 为 001180 号测点 ( $f_t=1.01\text{Hz}$ ) 的  $\alpha_E$  和  $\alpha_H$  在  $-70^\circ \sim -50^\circ$  和  $-30^\circ \sim 10^\circ$  范围内高度集中。图 5-31-b 和图 5-32-b 显示了本文方法处理后的电磁场极化方向, 整体分布上具有较高的随机性和均匀性, 消除强烈的近场效应, 更符合天然大地电磁场源的随机分布特征。同时, 这些结果进一步证明了该方法能够有效地抑制大地电磁数据中的强噪声, 恢复信号在强噪声下的特征。

实验结果表明, 本文提出的方法能够有效地去除各种类型的干扰噪声, 使得信号质量得到显著提高。同时, 我们还与其他常用的去噪方法进行了比较, 结果表明本文方法在各结果上均取得了优于对比方法的效果。

#### 5.2.2.2 测区结果对比

最后, 将本文方法应用于在中国贵州省西北部赫章县水塘乡猪拱塘铅锌矿区采集的现场 AMT 数据。采集仪器为由长沙巨杉智能科技有限公司研发的物联网宽频带大地电磁仪 GSEM-W10, 频率范围为  $10^{-1}\text{-}10^4\text{Hz}$ 。初步的地质调查结果显示, 该矿区位于中国四川、云南和贵州成矿区的东侧, 位于紫云—垭都断裂带的北西段, 属于垭都—蟒硐构造带。矿体以透镜体状、脉状和似层状的方式分布于断裂破碎带中。这些矿体在平面上部分重叠, 形成错列式矿体的剖面分布。矿石结构类型主要为浸染状、块状和脉状, 矿石矿物包括闪锌矿、方铅矿和黄铁矿等。该测区地质情况复杂, 存在多种强干扰源的共同作用。

图 5-33 显示了贵州猪拱塘矿区 L101 去噪前后相位张量椭圆拟断面对比结果。图 5-33-a 为原始数据相位张量椭圆拟断面, 可以明显地看到在  $1\text{KHz}\text{-}5\text{KHz}$  频率范围内受到严重的极化干扰, 相位椭圆长轴趋于一致, 在  $10\text{Hz}$  以下频率范围同样存在上述现象, 然而这些频段往往是观测中最感兴趣的区域之一。经过本文方法去噪处理后, 相位张量椭圆拟断面在死频带中极大地消除了极化干扰, 恢复了正常信号的张量图形表示, 中频连续性也得到了增强, 低频极化现象也有所改善, 如图 5-33-b 所示。



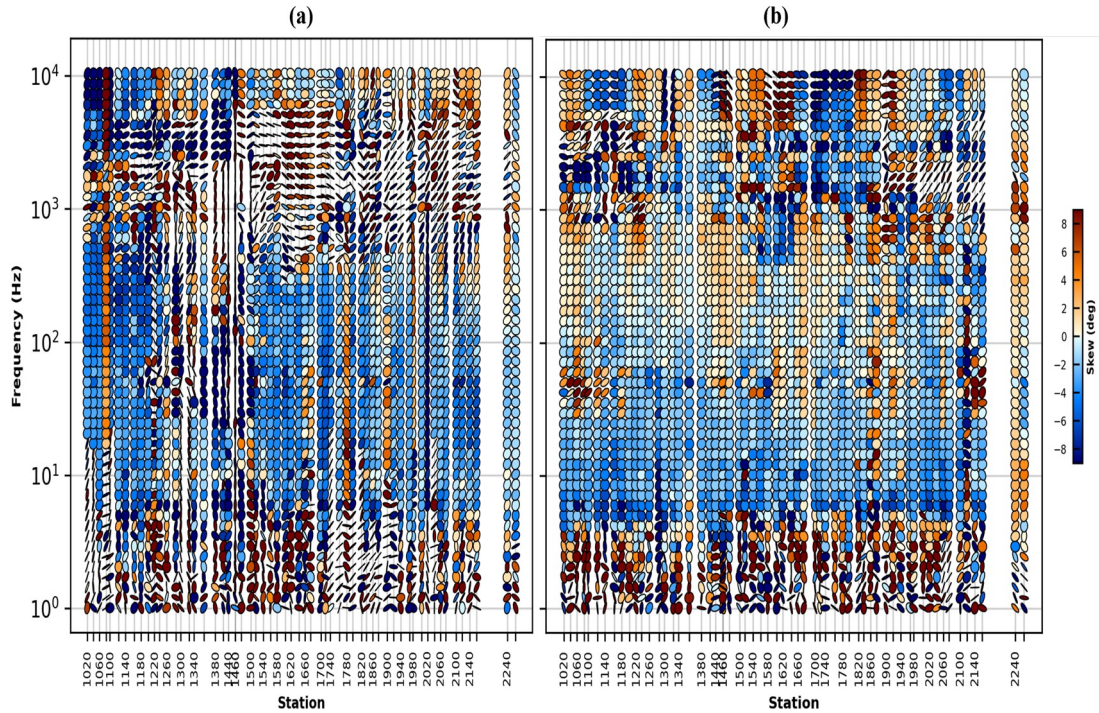


图 5-33 贵州猪拱塘矿区 L101 相位张量椭圆拟断面对比 (a)去噪前 (b)去噪后




图 5-34 贵州猪拱塘矿区 L101 视电阻率-相位拟断面对比 (a)去噪前 (b)去噪后

图 5-34 显示了贵州猪拱塘矿区 L101 去噪前后视电阻率-相位拟断面对比结果。图 5-34-a 显示了去噪前的视电阻率拟断面上存在两个明显的低电阻率区域，横向位置分别位于 1740 和 1500 测点，但结合相位拟断面可知，该地受到严重的静态效应干扰，具体表现为横向范围不大的陡立密集视电阻率等值线，在定性解释中常误解为虚假的陡立深大断裂或垂向大延伸的异常体，给观测数据和对地电信息或地质构造解释都将带来不可避免的误差。从图 5-34-b 可以看出，去噪后的视电阻率拟断面消除了原始数据在测点 1100、1220、1240、1440、1460、1500、1540、1820 处的电性假轴，非常有效地去除了静态效应问题，同时消除了  $\varphi_{yx}$  的相位翻转现象，具体表现为死频带范围的横向深棕色不连续长轴，相位拟断面图恢复了平滑合理的结果。

综合以上分析，在矿区勘探期间，受多种噪声源干扰，这些干扰能量强、频域广，导致时间序列中存在大量方波、脉冲、三角波等噪声，其数据全频段均受到污染。因此在勘探期间，应尽量避免被动源与主动源同时施工，并且勘探区域应相互间隔一定距离，这样做可以免除大部分主要人工源干扰，从而减少数据后期处理工作所要面对的困难和挑战，另一方面，也能有效地提高数据信噪比，获得真实有用的反演结果。

### 5.3 本章小结

在本章中，我们成功地提出并验证了一种基于卷积神经网络的天电信号自动识别方法和基于自监督学习策略的大地电磁时序去噪的新方法。反演结果表明两种方法在各自的任務上具有良好的泛化性和鲁棒性，总结如下：

(1) 天电信号识别中的两个现场数据的应用验证了经过训练的 CNN 模型不仅在未包含在训练中的数据上表现良好，而且在具有不同信噪比的数据上表现出良好的鲁棒性和泛化性。识别出的天电信号被进一步用于后续的 AMT “死区”数据处理，多项结果表明，所提出的方法有效解决了 AMT “死区”自然场能量不足的问题，消除了相位张量椭圆拟断面所展示的强电流畸变效应，并修正了视电阻率相位拟断面所表现出的异常畸变。与传统方法相比，该方法在“死区”产生更平滑的视电阻率-相位曲线，从而估算出真实的地下电阻率结构。本研究的这些结果对涵盖矿产资源勘探到地热能生产在内的应用具有重要的意义。

(2) 自监督去噪任务中的多个实测数据案例验证了自监督思想在大地电磁时域去噪应用中的可行性和有效性。通过与传统方法进行对比，综合分析四种方法的去噪效果，实验结果表明经验模态分解方法和小波分解方法对于强平稳噪声的去噪效果较好，但在去噪的同时也会对信号产生较大的失真，特别是在信号频率较高的情况下，失真效果更加显著；数学形态滤波方法适用于包含有较多峰值和过渡段的信号，但在信号中存在多个频率相似的成分时，数学形态滤波的效果会变差。另外，数学形态滤波方法对信号的处理是非线性的，难以用简单的数学公式描述，需要通过多次试验来确定滤波参数，这

也增加了使用难度。

以上方法皆无法自适应噪声种类和幅值的变化，而需要人工根据具体应用场景和要求选择参数的设置，不同的参数可能会对去噪效果产生影响，这种基于专家经验的方法存在一定的主观性和不确定性。而本文提出的方法则无需基于噪声先验信息，仅从数据本身特性和神经网络结构性质出发，自学习噪声波形等潜在信息，打破对于噪声种类和尺度、幅值的假设，实现完全意义上的自适应去噪。

综上所述，本文提出的方法在模拟数据和实际数据的试验中皆取得了优越的去噪效果，证明了其对各种干扰压制的有效性。同时，与其他方法相比，本文方法在各项评估指标上均取得了最佳结果，进一步证实了神经网络强大的能力。这些实验结果为本文所提出的方法在实际应用中的可行性和有效性提供了有力地支持。因此，我们认为提出的基于自监督学习的方法是解决大地电磁时间域去噪问题的有效工具。

## 第六章 总结与展望

### 6.1 本论文主要研究成果

全文取得了以下主要研究成果：

(1) 研究了大地电磁测深法的基本原理和理论推导，研究分析了大地电磁场的场源特征和噪声源特征。研究表明大地电磁场是由多个场源在不同距离上综合作用而产生的，这些场源具有不同的激发机制、特性和能量，并且在不同频段上的能量差异很大，同时具有复杂的时变特性。根据噪声产生的原因和波形特征的不同分为多种类型。

(2) 创新地提出了基于卷积神经网络的天电信号自动识别方法。在这项研究中，本文从采集记录的长时间范围内冗余数据中识别和提取天电信号，并使用提取信号准确地估算视电阻率和相位。同时提出了一种新型的数据集构建方法——随机数据生成策略，该策略在模型训练期间生成训练数据，以保证数据集的足量性与完备性。训练过程中，使用模拟退火策略自适应地降低学习率，引入早停策略和数据增强方式来防止过拟合。此外，还对输入样本进行均值方差归一化以加速收敛。结果表明：①VGG 网络具有极高的精度和速度，在各类评价指标上皆取得优异的结果，识别准确率达到 95%以上；②VGG 网络具有很强的鲁棒性和泛化性，能够应对不同信噪比的情况；③广泛的野外数据应用表明，该方法可以有效提高数据质量，解决 AMT “死区”天然场能量不足的问题；④与传统方法相比，该方法在“死区”（1.5~5 KHz）产生更平滑的视电阻率-相位曲线，从而估算出准确合理的地下电阻率结构。本研究的这些结果对涵盖矿产资源勘探到地热能生产在内的应用具有重要的意义。

(3) 本文创新性地提出一种基于自监督学习的大地电磁时序去噪算法，以解决传统监督学习算法面临的构建数据集难、数据集泛化性不足等问题。经过与传统方法进行比较并综合分析四种方法的去噪效果，实验结果表明自监督学习在噪声分布和数据先验方面都不受传统算法面临的限制。除此之外，我们采用了模拟加噪实验和实测数据混合验证了该方法的有效性。本研究取得了以下结果：①首次将自监督学习的思想引入大地电磁信号处理领域，取代了该领域传统的基于人工标注的监督学习，减少了人力成本与时间开销，在实际应用中具有广阔的应用前景；②本文提出的方法则无需基于噪声先验信息，仅从数据本身特性和神经网络结构性质出发，自学习噪声波形等潜在信息，打破了噪声种类和尺度、幅值的限制；③误差指标显示，本文去噪算法处理后的信号失真程度较小，能够在保持较低失真的情况下有效地去除噪声，并且能够提高信号信噪比和可靠性；④本文方法在应对各种复杂的地质情况下均取得最优异的去噪效果，能够有效处理强干扰性和非随机性的复合噪声，显著提升了采集数据的信噪比，为后续良好的反演

结果提供了基础。

## 6.2 进一步的研究方向与建议

基于本文已有的研究工作，针对研究中存在的问题和不足，提出以下几点建议和未来进一步的研究方向：

(1) 理论上，本文提出的天电识别方法对不同信噪比的数据集具有良好的泛化性，但本质上该方法基于数据驱动，受限于训练样本的数量和质量。当有效信号非常微弱且噪声完全淹没时间序列时，该方法可能会面临失效。所生成的被强噪声污染的样本不足以稳健地计算视电阻率和相位结果，最终导致 AMT 数据解释严重失真。因此，我们建议预处理多种先进的探索方法和抗干扰算法以获得高信噪比的时间序列数据，尤其是在采集过程中干扰较大的区域。原则上，多种处理方法的组合将会比单独使用我们的方法产生更好的结果。

(2) 鉴于模型在现有数据集上实现了较高的识别精度，计划在未来的工作中利用自监督学习方法自动标记数据并获得具有代表性的时间序列数据以扩展训练集。如此便可以进一步降低人工标注的时间成本，实现复杂条件下的高精度信号识别。

(3) 如何将先进的识别与去噪算法合理结合，实现场源中主要有效信号的高精度提取，需要进一步研究。此外，建议在数据生成工作流程中提高立体波形的多样性，以获得更真实的波形特征和数据分布，从而在更多现场数据应用程序上的泛化，改进整体工作流程。

(4) 自监督方法实质仍然是对时间序列中噪声形态的识别，难以规避时间序列中有效信号的损失与噪声的残留，尤其难以应对边缘幅值突变的情况。初步推测可能与损失函数设定相关，复合损失函数相当于加上一个软约束，限制模型训练过程中不要过于拟合每个点。在面对类突变噪声的情况下，模型将采取调和折中的方式来降低损失，因此最终会留下了较小的类脉冲残差。此类情况往往存在于周期方波等规律干扰波中，建议通过陷波等后处理方法将该部分残差成分予以滤除。

(5) 由于方波具有尖峭的边缘和跳跃的幅值变化，这些特性在时域和频域中都会导致信号的高频成分增多，使得神经网络难以对其进行精确的预测和处理。另外，神经网络的输入层和输出层之间存在的非线性映射关系也可能对方波信号的处理造成一定的影响。未来将探究如何通过调整神经网络结构和优化算法来提高其在处理方波等复杂信号方面的性能。

(6) 本文中使用的训练参数并不适用所有情况，建议因地制宜地选择合适的训练超参数。

## 参考文献

- [1] 汤井田, 张弛, 肖晓, 等. 大地电磁阻抗估计方法对比[J]. 中国有色金属学报, 2013, 23(9): 2351-2358.
- [2] 杨长福, 徐世浙. 国外大地电磁研究现状[J]. 物探与化探, 2005, (03): 243-247.
- [3] WANG H, CAMPANYà J, CHENG J, et al. Synthesis of natural electric and magnetic time - series using inter - station transfer functions and time - series from a neighboring site (STIN): Applications for processing MT data[J]. Journal of Geophysical Research: Solid Earth, 2017, 122(8): 5835-5851.
- [4] HATTINGH M. The use of data-adaptive filtering for noise removal on magnetotelluric data[J]. Physics of the earth and planetary interiors, 1989, 53(3-4): 239-254.
- [5] OLSEN K B, HOHMANN G W. Adaptive noise cancellation for time-domain EM data[J]. Geophysics, 1992, 57(3): 466-469.
- [6] 姚同起, 范国华. 自适应滤波器在地磁数据噪音处理中的应用[J]. 地震地磁观测与研究, 1995, 16(2): 12-18.
- [7] 曹建章, 宋建平, 唐天同. 瞬变电磁测量中的自适应滤波方法[J]. 煤田地质与勘探, 1997, 25(6): 44-47.
- [8] 昌彦君, 韩永琦, 江浩. 瞬变电磁法中消除工频噪声的自适应滤波器研究 (英文)[J]. 工程地球物理学报, 2004, 1(5): 407-411.
- [9] 余灿林. 大地电磁信号处理的自适应滤波研究 [D]; 中南大学, 2009.
- [10] 李晋, 马翻红, 汤井田, 等. 基于自适应多分辨率奇异值分解的大地电磁数据处理 [J]. 地球物理学报, 2022, 65(12): 4944-4962.
- [11] MALLAT S, HWANG W L. Singularity detection and processing with wavelets[J]. IEEE transactions on information theory, 1992, 38(2): 617-643.
- [12] MALLAT S G. A theory for multiresolution signal decomposition: the wavelet representation[J]. IEEE transactions on pattern analysis and machine intelligence, 1989, 11(7): 674-693.
- [13] 王玉平, 蔡元龙. 小波分析在信号处理中的应用[J]. 无线电工程, 1994, 24(3): 11-18.
- [14] ALEXANDRESCU M, GIBERT D, HULOT G, et al. Detection of geomagnetic jerks using wavelet analysis[J]. Journal of Geophysical Research: Solid Earth, 1995, 100(B7): 12557-12572.
- [15] 宋守根, 汤井田. 小波分析与电磁测深中静态效应的识别, 分离及压制[J]. 地球物理学报, 1995, 38(1): 120-128.

- [16] 高静怀, 汪文秉, 朱光明. 小波变换与信号瞬时特征分析[J]. 地球物理学报, 1997, 40(6): 821-832.
- [17] LI X P. Wavelet power spectrum analysis of heterogeneities from sonic velocity logs [Link][J]. Geophysical prospecting, 1998, 46(5): 455-475.
- [18] FEDI M, QUARTA T. Wavelet analysis for the regional - residual and local separation of potential field anomalies [Link][J]. Geophysical prospecting, 1998, 46(5): 507-525.
- [19] TARASOV V, DUBININ E, PERRAUT S, et al. Wavelet application to the magnetic field turbulence in the upstream region of the Martian bow shock[J]. Earth, planets and space, 1998, 50: 699-708.
- [20] RIDSDILL-SMITH T, DENTITH M. The wavelet transform in aeromagnetic processing[J]. Geophysics, 1999, 64(4): 1003-1013.
- [21] HORNBYP, BOSCHETTI F, HOROWITZ F. Analysis of potential field data in the wavelet domain[J]. Geophysical Journal International, 1999, 137(1): 175-196.
- [22] 付彪, 吴先良, 李世雄. 小波变换法求电磁波动方程的高频解[J]. 安徽大学学报: 自然科学版, 1999, 23(3): 58-64.
- [23] TRAD D O, TRAVASSOS J M. Wavelet filtering of magnetotelluric data[J]. Geophysics, 2000, 65(2): 482-491.
- [24] 何兰芳, 王绪本. 应用小波分析提高 MT 资料信噪比[J]. 成都理工学院学报, 1999, 26(3): 299-302.
- [25] 师学明, 王家映, 张胜业, 等. 多尺度逐次逼近遗传算法反演大地电磁资料[J]. 地球物理学报, 2000, 43(1): 122-130.
- [26] 徐义贤, 王家映. 基于连续小波变换的大地电磁信号谱估计方法[J]. 地球物理学报, 2000, 43(5): 677-683.
- [27] 李世雄, 汪继文. 信号的瞬时参数与正交小波基[J]. 地球物理学报, 2000, 43(1): 97-104.
- [28] 何兰芳, 王绪本, 何展翔, 等. MT 时间序列的小波去噪分析[J]. 地震地质, 2001, 23(2): 222-226.
- [29] 严家斌, 刘贵忠. 基于小波变换的脉冲类电磁噪声处理[J]. 煤田地质与勘探, 2007, 35(5): 61-65.
- [30] GARCIA X, JONES A G. Robust processing of magnetotelluric data in the AMT dead band using the continuous wavelet transform[J]. Geophysics, 2008, 73(6): F223-F234.
- [31] 张伟. 长周期大地电磁法信号处理关键技术研究与应用 [D]; 成都: 成都理工大学, 2011.
- [32] 蔡剑华, 肖晓. 基于小波自适应阈值去噪的 MT 信号处理方法[J]. 地球物理学进展, 2015, (6): 2433-2439.

- [33] 蔡剑华. 基于 Hilbert-Huang 变换的大地电磁信号处理方法与应用研究 [D]; 长沙: 中南大学, 2010.
- [34] LARNIER H, SAILHAC P, CHAMBODUT A. Detection and characterization of lightning-based sources using continuous wavelet transform: application to audio-magnetotellurics[J]. *Geophysical Journal International*, 2018, 212(1): 103-118.
- [35] 万云霞, 王力鑫, 张宏伟, 等. 基于小波变换的 MT 数据人文噪声抑制方法[J]. *吉林大学学报 (信息科学版)*, 2021, 39(6): 624-629.
- [36] 化希瑞, 曹哲明, 刘铁, 等. 高频大地电磁系统数据处理方法研究[J]. *工程地球物理学报*, 2009, (S1): 25-32.
- [37] 蔡剑华, 汤井田. 基于 Hilbert-Huang 变换的大地电磁信号谱估计方法[J]. *石油地球物理勘探*, 2010, (5): 762-767.
- [38] 罗皓中, 王绪本, 张伟, 等. 基于经验模态分解法与小波变换的长周期大地电磁信号去噪方法[J]. *物探与化探*, 2012, 36(3): 452-456.
- [39] 汤井田, 化希瑞, 曹哲民, 等. Hilbert-Huang 变换与大地电磁噪声压制[J]. *地球物理学报*, 2008, 51(2): 603-610.
- [40] 汤井田, 蔡剑华, 任政勇, 等. Hilbert-Huang 变换与大地电磁信号的时频分析[J]. *中南大学学报: 自然科学版*, 2009, 40(5): 1399-1405.
- [41] 龚炜, 石青云, 程民德. 数字空间中的数学形态学: 理论及应用 [M]. 科学出版社, 1997.
- [42] SERRA J, SOILLE P. *Mathematical morphology and its applications to image processing* [M]. Springer Science & Business Media, 2012.
- [43] 李兵, 张培林, 任国全, 等. 基于数学形态学的分形维数计算及在轴承故障诊断中的应用[J]. *振动与冲击*, 2010, 29(5): 191-194.
- [44] 任获荣. 数学形态学及其应用[J]. 西安: 西安电子科技大学机电工程学院, 2004, 2:
- [45] 岳蔚, 刘沛. 基于数学形态学消噪的电能质量扰动检测方法[J]. *电力系统自动化*, 2002, 26(7): 13-17.
- [46] 赵晓群, 王津. 一种基于形态学的语音增强方法[J]. *同济大学学报: 自然科学版*, 2006, 34(10): 1394-1397.
- [47] LI J, TANG J-T, XIAO X. De-noising algorithm for magnetotelluric signal based on mathematical morphology filtering[J]. *Noise & Vibration Worldwide*, 2011, 42(11): 65-72.
- [48] TANG J, LI J, XIAO X, et al. Application of mathematical morphology filtering method in noise suppression of magnetotelluric sounding data; proceedings of the International Workshop on Gravity, Electrical & Magnetic Methods and Their Applications 2011: International Workshop on Gravity, Electrical & Magnetic Methods and Their Applications, Beijing, China, October 10–13, 2011, F, 2011 [C]. Society of Exploration



Geophysicists.

- [49] 汤井田, 李晋, 肖晓, 等. 基于数学形态滤波的大地电磁强干扰分离方法[J]. 中南大学学报: 自然科学版, 2012, 43(6): 2215-2221.
- [50] 汤井田, 李晋, 肖晓, 等. 数学形态滤波与大地电磁噪声压制[J]. 地球物理学报, 2012, 55(5): 1784-1793.
- [51] 李晋. 基于数学形态学的大地电磁强干扰分离及应用 [D]; 中南大学, 2012.
- [52] TANG J, LI H, LI J, et al. Top-Hat transformation and magnetotelluric sounding data strong interference separation of Lujiang-Zongyang ore concentration area[J]. Journal of Jilin University (Earth Science Edition)(in Chinese), 2014, 44(1): 336-343.
- [53] 徐海浪, 吴小平. 电阻率二维神经网络反演[J]. 地球物理学报, 2006, 49(2): 584-589.
- [54] ZHANG G, LIN C, CHEN Y. Convolutional neural networks for microseismic waveform classification and arrival picking[J]. Geophysics, 2020, 85(4): WA227-WA240.
- [55] 王涵. 基于 DQN 和 U-NET 的大地电磁反演研究 [D]; 吉林大学, 2022.
- [56] 廖晓龙, 张志厚, 姚禹, 等. 基于卷积神经网络的大地电磁反演[J]. 中南大学学报 (自然科学版), 2020, 51(09): 2546-2557.
- [57] 张志厚, 廖晓龙, 曹云勇, 等. 基于深度学习的重力异常与重力梯度异常联合反演 [J]. 地球物理学报, 2021, 64(4): 1435-1452.
- [58] 王鹤, 刘梦琳, 席振铎, 等. 基于遗传神经网络的大地电磁反演[J]. 地球物理学报, 2018, 61(4): 1563-1575.
- [59] 王鹤, 刘威, 席振铎. 基于深度置信网络的大地电磁非线性反演 (英文) [J]. Journal of Central South University, 2019, 26(09): 2482-2494.
- [60] CARBONARI R, DI MAIO R, PIEGARI E, et al. Filtering of noisy magnetotelluric signals by SOM neural networks[J]. Physics of the earth and planetary interiors, 2018, 285: 12-22.
- [61] 刘晓琼. 基于稀疏度自适应和 NPSO-OMP 的大地电磁强干扰压制[D]. 湖南师范大学, 2020. DOI:10.27137/d.cnki.ghusu.2020.002369.
- [62] 范振宇. 基于卷积神经网络的大地电磁深度学习反演研究[D]. 中国地质大学(北京), 2020. DOI:10.27493/d.cnki.gzdzy.2020.001642.
- [63] ZHANG L, REN Z, XIAO X, et al. Identification and Suppression of Magnetotelluric Noise via a Deep Residual Network[J]. Minerals, 2022, 12(6): 766.
- [64] ZUO G, REN Z, XIAO X, et al. Magnetotelluric Noise Attenuation Using a Deep Residual Shrinkage Network[J]. Minerals, 2022, 12(9): 1086.
- [65] LI G, GU X, REN Z, et al. Deep learning optimized dictionary learning and its application in eliminating strong magnetotelluric noise[J]. Minerals, 2022, 12(8): 1012.
- [66] LI J, LIU Y, TANG J, et al. Magnetotelluric data denoising method combining two deep-

- learning-based models[J]. *Geophysics*, 2023, 88(1): E13-E28.
- [67] LI J, CAI J, PENG Y, et al. Magnetotelluric signal-noise identification and separation based on apen-mse and stomp[J]. *Entropy*, 2019, 21(2): 197.
- [68] PENG Z, PETER W T, CHU F. An improved Hilbert–Huang transform and its application in vibration signal analysis[J]. *Journal of sound and vibration*, 2005, 286(1-2): 187-205.
- [69] RATO R, ORTIGUEIRA M D, BATISTA A. On the HHT, its problems, and some solutions[J]. *Mechanical systems and signal processing*, 2008, 22(6): 1374-1394.
- [70] 覃庆炎, 王绪本, 罗威. EMD 方法在长周期大地电磁测深资料去噪中的应用[J]. *物探与化探*, 2011, 35(1): 113-117.
- [71] 陈乐寿, 刘任, 王天生. 大地电磁测深资料处理与解释 [M]. 石油工业出版社, 1989.
- [72] VOZOFF K. The magnetotelluric method[J]. 1991:
- [73] 刘国栋, 陈乐寿. 大地电磁测深研究[J]. 地震出版社, 北京, 1984, 4: 13-16.
- [74] 魏文博. 我国大地电磁测深新进展及展望[J]. *地球物理学进展*, 2002, 17(2): 245-254.
- [75] 柳建新, 童孝忠, 郭荣文, 等. 大地电磁测深法勘探[M]. 北京: 科学出版社, 2012.
- [76] 孙洁, 晋光文, 白登海, 等. 大地电磁测深资料的噪声干扰[J]. *物探与化探*, 2000, 24(2): 119-127.
- [77] 曾治权. 日地关系[J]. 北京: 地震出版社, 1989, 19(89): 25-26.
- [78] SIMPSON F, BAHR K. Practical magnetotellurics [M]. Cambridge University Press, 2005.
- [79] 考夫曼 AA. 凯勒 GV 著 [M]. 北京: 地质出版社. 1987.
- [80] 陈乐寿. 大地电磁测深——探测地球深部电性和物质状态的一种有效手段[J]. *自然杂志*, 2009, 31(1): 39-46.
- [81] 严家斌. 大地电磁信号处理理论及方法研究 [D]; 长沙: 中南大学, 2003.
- [82] 杨生. 大地电磁测深法环境噪声抑制研究及其应用[J]. 长沙: 中南大学, 2004:
- [83] 胡玉平. 大地电磁阻抗的地质噪声畸变研究及校正方法 [D]; 中南大学, 2002.
- [84] MORRISON H, WOMBWELL E, WARD S. Analysis of earth impedances using magnetotelluric fields[J]. *Journal of Geophysical Research*, 1968, 73(8): 2769-2778.
- [85] 李晓晨, 杨淼鑫, 刘冲, 等. EMAP 处理方法在 MT 静校正中的应用[J]. *工程地球物理学报*, 2012, 9(4): 394-399.
- [86] 李爱勇, 唐冬春, 杨生. 直接消除电场分量静态效应的静改方法[J]. *石油地球物理勘探*, 2004, 39(B11): 96-98.
- [87] 张旭, 刘宽厚, 李貅. CSAMT 的静校正应用[J]. *西北地质*, 2010, 43(2):
- [88] CALDWELL T G, BIBBY H M, BROWN C. The magnetotelluric phase tensor[J]. *Geophysical Journal International*, 2004, 158(2): 457-469.
- [89] CHAVE A D, SMITH J T. On electric and magnetic galvanic distortion tensor decompositions[J]. *Journal of Geophysical Research: Solid Earth*, 1994, 99(B3): 4669-

- 4682.
- [90] GROOM R W, BAILEY R C. Decomposition of magnetotelluric impedance tensors in the presence of local three - dimensional galvanic distortion[J]. *Journal of Geophysical Research: Solid Earth*, 1989, 94(B2): 1913-1925.
- [91] 娄源清, 李伟. 大地电磁测量中的尖峰干扰抑制问题[J]. *地球物理学报*, 1994, 37(A02): 493-500.
- [92] 刘祥. 方波噪声对大地电磁远参考效果影响研究 [D]; 中南大学, 2014.
- [93] SCHUMANN W O. Über die strahlungslosen Eigenschwingungen einer leitenden Kugel, die von einer Luftschicht und einer Ionosphärenhülle umgeben ist[J]. *Zeitschrift für Naturforschung A*, 1952, 7(2): 149-154.
- [94] HENNESSY L, MACNAE J. Sferic signals for lightning sourced electromagnetic surveys[J]. *ASEG Extended Abstracts*, 2018, 2018(1): 1-5.
- [95] KIM J, LEE J K, LEE K M. Accurate image super-resolution using very deep convolutional networks; proceedings of the Proceedings of the IEEE conference on computer vision and pattern recognition, F, 2016 [C].
- [96] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. *arXiv preprint arXiv:14091556*, 2014:
- [97] Nair V, Hinton G E. Rectified linear units improve restricted boltzmann machines[C]//*Proceedings of the 27th international conference on machine learning (ICML-10)*. 2010: 807-814.
- [98] IOFFE S, SZEGEDY C. Batch normalization: Accelerating deep network training by reducing internal covariate shift; proceedings of the International conference on machine learning, F, 2015 [C]. pmlr.
- [99] KINGMA D P, BA J. Adam: A method for stochastic optimization[J]. *arXiv preprint arXiv:14126980*, 2014:
- [100] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition[C]//*Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016: 770-778.
- [101] WANG Z, 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.
- [102] ZHOU Z-H, ZHOU Z-H. *Ensemble learning* [M]. Springer, 2021.
- [103] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation; proceedings of the Medical Image Computing and Computer-Assisted Intervention–MICCAI 2015: 18th International Conference, Munich,

- Germany, October 5-9, 2015, Proceedings, Part III 18, F, 2015 [C]. Springer.
- [104] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation; proceedings of the Proceedings of the IEEE conference on computer vision and pattern recognition, F, 2015 [C].
- [105] WANG Z, SIMONCELLI E P, BOVIK A C. Multiscale structural similarity for image quality assessment; proceedings of the The Thrity-Seventh Asilomar Conference on Signals, Systems & Computers, 2003, F, 2003 [C]. Ieee.
- [106] WANG Z, BOVIK A C. Mean squared error: Love it or leave it? A new look at signal fidelity measures[J]. IEEE signal processing magazine, 2009, 26(1): 98-117.
- [107] 王辉, 许滔滔, 罗景程, 等. 基于地磁台网数据的长周期大地电磁数据远参考处理 [J]. 地球物理学进展, 2018, 33(6): 2270-2277.
- [108] 徐志敏. 庐枞大地电磁干扰噪声研究 [D]; 长沙: 中南大学, 2012.
- [109] BOOKER J. The magnetotelluric phase tensor: A critical review: Survey in Geophysics[J]. 2014:
- [110] GARCÍA X, JONES A G. A new methodology for the acquisition and processing of audio-magnetotelluric (AMT) data in the AMT dead band[J]. Geophysics, 2005, 70(5): G119-G126.
- [111] LILLEY F. Magnetotelluric tensor decomposition: Part II, Examples of a basic procedure[J]. Geophysics, 1998, 63(6): 1898-1907.
- [112] LILLEY F. Magnetotelluric tensor decomposition: Part I, Theory for a basic procedure[J]. Geophysics, 1998, 63(6): 1885-1897.
- [113] HENNESSY L, MACNAE J. Magnetotelluric distortions directly observed with lightning data[J]. Geophysical Journal International, 2017, 210(2): 1171-1175.
- [114] LI G, XIAO X, TANG J-T, et al. Near-source noise suppression of AMT by compressive sensing and mathematical morphology filtering[J]. Applied Geophysics, 2017, 14(4): 581-589.
- [115] Li J, Liu Y, Tang J, et al. Magnetotelluric noise suppression via convolutional neural network[J]. Geophysics, 2023, 88(1): WA361-WA375.
- [116] Chen H, Guo R, Liu J, et al. Magnetotelluric data denoising with recurrent neural network[C]//SEG 2019 Workshop: Mathematical Geophysics: Traditional vs Learning, Beijing, China, 5-7 November 2019. Society of Exploration Geophysicists, 2020: 116-118.
- [117] Nocelo Sampedro P. Processing of Magnetotelluric Data Using Machine Learning Techniques[J]. 2021.
- [118] Li G, He Z, Deng J, et al. Robust CSEM data processing by unsupervised machine learning[J]. Journal of Applied Geophysics, 2021, 186: 104262.

- [119] Manoj C, Nagarajan N. The application of artificial neural networks to magnetotelluric time-series analysis[J]. *Geophysical Journal International*, 2003, 153(2): 409-423.

## 攻读学位期间主要的研究成果

### 一、发表的学术论文

[1] **Jiang, E.**, R. Chen\*, X. Wu\*, J. Liu, D. Zhu, and W. Liu, 2022, Deep learning based sferics recognition for AMT data processing in the dead band, Geophysics, in press.

[2] **Jiang E.**, Chen R, Zhu D, et al. Static-shift suppression and anti-interference signal processing for CSAMT based on Guided Image Filtering[J]. Earthquake Research Advances, 2022, 2(1): 100117.

[3] 蒋恩华,陈儒军,朱德兵. 引导图像滤波在 MT 和 CSAMT 测量抗干扰及压制静态效应中的应用[C]. 2020 年中国地球科学联合学术年会论文集.北京伯通电子出版社,2020:236-239.DOI:10.26914/c.cnkihy.2020.059384.

### 二、主持和参与的科研项目

[1]湖南省科技创新重大项目《深海矿产资源与地质勘探关键技术及装备研究》，项目编号：2022YFF0706201，参与。

### 三、个人获奖情况

[1]国家级，第十八届华为杯全国研究生数学建模竞赛，国家二等奖，2021.

[2]国家级，中国地球科学联合学术年会，优秀学生论文奖，2022.

[3]校级，中南大学 2021-2022 学年校级评优，优秀学生，2022.

[4]校级，中南大学 2020-2021 学年校级评优，优秀学生干部，2021.

## 致 谢

蓦然回首，即将走过三年硕士生活，这段时光匆匆而过。感慨万千，我想起初涉学术时的茫然无措，但愿成长的艰辛、学术的辛苦，都将在这一页页论文中得以显现。求学之路艰难且崎岖，所幸，这一路上得到了不少人的倾情相助，在此，我想向那些曾经帮助过我的人们道一声感谢。

首先，感谢我的导师朱德兵教授和陈儒军副教授，您们给予我深厚的学术底蕴和独特的思维启迪，是我学术路上的坚强支柱，也是我人生中的重要导航灯。您们的指导和关怀让我在硕士研究生阶段茁壮成长。感谢您们对我的科研工作的悉心指导，不仅为我提供了极具价值的研究思路和方法，更是在我的研究过程中给予了我无微不至的关心和支持。

还要特别感谢中国科学技术大学伍新明教授，在学生对科研陷入迷茫困惑时，是您为我答疑解惑，指点迷津。与您的每一次交流都令学生获益匪浅，您博学而温柔，对新事物和新技术拥有极强的包容性和探索精神。您对科研热爱且严谨，对教学热情且负责，对学生关爱且体贴，这些都令学生叹服。您和您课题组所营造出的良好的科研氛围，让学生能在最好的条件下安心科研，再次感谢。

感谢 CIG 的每一位成员，你们富有创造性和价值性的工作和精彩绝伦的报告都令我印象深刻，你们脚踏实地、勤奋刻苦的科研态度深深令我动容。感谢你们在科研和生活方面给我提供的帮助。

感谢课题组的姚红春、申瑞杰师兄和彭鑫、刘璿、刘峰海师弟，感谢你们平时的帮助和对我的支持和理解，让我感受到了温暖和力量。课题组大家庭温暖而有趣，同门情牢固且纯洁。感谢研究生同班同学，感谢篮球队的各位球星，怀念和你们在球场上一起挥洒汗水的时光。

因风道感谢，情至笔载援。感谢我的室友罗建，一起通宵备赛的日子真是令人难忘，得奖的那一刻也真是开心。感谢室友朱昱承，你总是能以一种轻松的方式给大家带来快乐。感谢室友郑兴福，身为博士生的你总能给我们提供科研上的帮助。

感谢我志同道合的好友杨威、刘庆斌、尚阶平、任一、郭伟昊、吴洋，我会永远记得我们一起度过的最快乐的那个夏天，纵使未来天各一方，亦有光阴熟知我们的故事。

感谢家人，在我最困难的时候毫无条件地支持我，给予我最大的帮助；在我情绪最低落的时候安慰我，尊重我的每一个决定；在我被压力和焦虑折磨的时候，让我有一个倾诉口，我爱你们。

感谢李沐，沐神是我在探索 AI 这条路上的启蒙，也一直是我的科研路上精神力量的

来源。您温暖亲切的笑容时常感染到我，让我暂时卸下焦虑和忧愁，您的教学永远带给人鼓舞和信心，您的《博士这五年》和《工作五年反思》这两篇文章真是常读常新，字里行间透露着无限亲和力和人格魅力，身居高位却低调谦逊，一心为国内学生提供技术扶贫，凭一己之力打破技术壁垒。您的精神将一直感染我，让我坚定地走下去。感谢罗翔教授和刘擎教授，你们的《圆圈正义》和《西方现代思想讲义》用坦诚、自省而尖锐的笔调启蒙了我的法律意识和哲学意识，给我在焦虑的环境中带来了心灵上的慰藉，帮助我树立更加健全的人格和价值观，成为一个更加理性、公正、独立思考的人。

感谢母校，目之所及，皆是回忆。2016年秋，我带着一纸录取通知书踏上了通往中南大学的求学之路。七年求学，如今也将告一段落，纵有万般不舍，仍然心怀感激。回首过往，可能感触太多，一瞬间竟只能想起图书馆七楼的窗景，楚怡路边的荷塘，玉带河里的涟漪，南校礼堂的桂花香，荷花池里摇曳的月光，观云池倒影和左家垅海棠，还有永远准时挂上的“热烈祝贺毕业生奔赴祖国各地建功立业”的横幅。“知行合一，经世致用”的校训深刻地影响着我的每一次选择，“向善、求真、唯美、有容”的校风指导我从容地面对每一个挑战。在我心中，麓山南路932号早已不是一个地址，而是我的整个青春。清水路昏黄的路灯温暖着晚归的人，而我也终于走到了麓山南路的尽头。

感谢我的家乡长沙，时间愈久，我对这座城市的感情越深也越真挚。难忘橘子洲璀璨夺目的焰火，梅溪湖宁静惬意的晚风，爱晚亭火红的枫叶，天心阁饱经风霜的古城墙，岳麓书院的朗朗书声，还有岳麓山顶的那些畅所欲言，这些都是我最珍贵的回忆。还想再去麓山南路散一次步，再喝一杯茶颜悦色，再嗦一碗长沙米粉，再爬一次岳麓山，再和好友一起相聚在星城。但愿这些回忆足够丰富我炽热而滚烫的青春。

感谢真诚的自己，二十余载求学路，风雨兼程，一路阳光，一路泥泞，有挫折也有幸运。我深知，人生中的每一步都是自己选择的结果，每一次成长也都是奋斗的记录。真诚的力量在驱使我前行，那股力量来自于内心的信念和坚定的目标，以及不断克服困难的勇气和毅力。我也明白，只有真诚地自我审视，才能真正地认识自己。我坚信，真诚是人性最质朴的底色。

最后，感谢生活教会我独立，让我认识到自己作为一个人的有限性，坦诚地承认自己的不足，坦然地接受自己的失败。感谢命运让我学会对可控的事情保持谨慎，对不可控的事情保持乐观。感谢我所经历的一切，感谢这段际遇，但愿我成为一个更好的人。

行文至此，思绪万千，言语道不尽；又历三年，终将别离，岁月再难遇。莫气馁，前路尚远；莫骄傲，道阻且长。