

文章编号: 2095-4980(2023)06-0751-08

## 基于时间序列分解的信号挖掘与预测

郭锦桥, 柳禹名, 曹卫东, 林云

(哈尔滨工程大学 信息与通信工程学院, 黑龙江 哈尔滨 150001)

**摘要:** 随着电磁信号环境日趋复杂以及通信设备数量的不断增加, 电磁信号受到干扰问题逐渐加剧。因此, 对于信号在不同噪声环境下的接收与处理技术的研究以及在复杂的电磁环境中对信号各项数据指标及其携带信息的利用十分关键。为了解在不同电磁环境下含噪信号的性能表现, 提高信号的利用质量及可靠性, 本文提出一种基于时间序列分解的电磁数据处理方法。建立了基于加法季节性时间序列分解的含噪信号处理模型, 并利用该模型对信号在有噪环境下的表现与规律性、趋势、误码率等性能进行分析与评估, 对原始信息、载波信息进行挖掘预测。与传统方法相比, 本文提出的基于时间序列分解的信号挖掘与预测模型在高噪环境下对信号预测更为准确。

**关键词:** 时间序列分解; 特征提取; 数据挖掘; 数据预测; 机器学习

中图分类号: TN97

文献标志码: A

doi: 10.11805/TKYDA2023063

## Signal mining and prediction based on time series decomposition

GUO Jinqiao, LIU Yuming, CAO Weidong, LIN Yun

(School of Communication and Information Engineering, Harbin Engineering University, Harbin Heilongjiang 150001, China)

**Abstract:** With the increasing complexity of the electromagnetic signal environment and the increasing number of communication devices, the interference with electromagnetic signals is gradually increasing. Therefore, the study on signal reception and processing techniques in different noise environments and the use of signal data indicators and the information they carry in complex electromagnetic environments is very critical. In order to understand the performance of noisy signals in different electromagnetic environments and improve the quality and reliability of signal utilization, a time series decomposition-based electromagnetic data processing method is proposed. A noisy signal processing model is established based on additive seasonal time series decomposition, and the model is also employed to analyze and evaluate the performance of signals in noisy environments with regularity, trend, BER, etc., and to data-mine the original information and carrier information. Compared with the traditional methods, the proposed time series decomposition-based signal mining and prediction model is more accurate for signal prediction in noisy environment.

**Keywords:** time series decomposition; feature extraction; data mining; data prediction; machine learning

随着移动通信技术的发展, 通信设备对所接收到的信号质量要求逐渐增高, 对于信号的异常检测也越发重视。因此, 对于信号稳定性的评估、信号的异常检测与处理也变得不可或缺。信号检测、分析与处理技术在军用和民用领域都有广泛应用。目前在信号异常检测与处理等领域通常采用人工智能、机器学习等技术对已有信号进行挖掘、清洗等, 从而实现时域、频域、空域、能域等维度的异常信息、信息的分析与挖掘。

数据挖掘是指从大量的、有噪声的、模糊的、随机的数据中, 提取隐含其中可用的信息以及知识的过程。由于信号是一种时间序列, 可以基于时域对信号进行评估, 利用一些时域信号分析方法, 达到对数据挖掘、分析及信息处理, 并提取可用隐藏信息的目的。目前对于电磁信号的挖掘与分析方面已有众多的研究, 文献[1]利用大量的频谱数据分析被研究的电磁环境, 对频谱使用规律进行挖掘与预测分析, 建立了网络化通信系统, 全面分析电磁环境数据各项指标; 文献[2]提出一种基于特征提取和机器学习的电磁目标识别方法, 对多种信号在不同环境、不同信噪比下进行处理与识别, 提高了信号识别准确率; 文献[3]建立了一种新型、基于时间序列分

解的高效遗传神经网络(Genetic Neural Network, GNN)模型, 利用复杂神经网络、权重与偏置矩阵对时间序列进行数据处理、挖掘并预测信号信息; 文献[4]建立了一种面向电磁目标识别的分布式机器学习算法, 分析了基于机器学习算法的电磁解调方案与传统解调方案之间的差异性, 并对比了不同方法在信号过程中的优劣。

现有的基于机器学习方法对于信号的挖掘与处理技术大多基于纯数据处理、对数据直接分析<sup>[5]</sup>, 忽略了数据的规律性变化、信号的周期规律以及载波所携带的信息。

本文采用一种基于滑动平均、STL(Seasonal-Trend-Loss)时间序列分解和趋势检验的时间序列信号处理方法, 对接收信号进行分析与处理, 达到清洗、去除异常、去噪的效果。首先建立基于时间序列分解的含噪信号处理网络模型, 对信号在有噪环境下的表现以及规律性、趋势、误码率等性能进行分析与评估, 对原始信息、载波信息进行挖掘预测; 之后对分解后的趋势项、季节项、误差项进行分析处理, 并利用已有数据对未来数据进行预测。还原幅度移位键控(Amplitude Shift Keying, ASK)以及频率移位键控(Frequency Shift Keying, FSK)波的原始信号、载波信号、噪声干扰信息。最后利用仿真软件对不同信噪比下的4种信号进行仿真、STL分解处理、还原。结果表明, 本文分解算法对不同信噪比、不同信号均具有很好的分解适应性能, 并具有良好的能效性能。

## 1 研究理论与方法

### 1.1 信号处理过程中的异常指标处理

#### 1) 异常信息处理

信号在传输过程中存在异常信息, 异常指在一定时间、一定频率范围内, 如果样本信号的幅度、频率、能量等特征持续偏离某一范围, 则认为在该范围内信号存在异常<sup>[6]</sup>。

信号分析主要用于时域信号的异常检测过程, 常用的方法包括小波分析、谱分析<sup>[7]</sup>, 常用于震动、音频等有规律周期信号的异常检测<sup>[8]</sup>。该方法属于无监督方法, 处理过程中不需要标记的样本, 但对于正常和异常的边界难以明确定义<sup>[9]</sup>。统计分析方法基于数据的经验分布进行异常检测, 该方法的优点是不需要标记的样本, 可以对任意分布的数据进行异常检测, 常用于周期信号的分析。对于判决出的异常数据, 该方法将异常值更换为拟合预测值。

利用移动平均(Moving Average, MA)法对时间序列进行分析, 可以过滤信号所携带的高频噪声, 检测出时间序列信号的异常点。若某时间序列信号的移动平均时间窗口为 $t$ , 则时间序列为:

$$y = \{\dots; y_{t-2}; y_{t-1}; y_t; y_{t+1}; y_{t+2}; \dots\} \quad (1)$$

对该序列进行简单移动平均(Simple Moving Average, SMA)

$$SMA_t = \sum_{i=T-1}^0 y_{t-i} \quad (2)$$

可以将该时间序列过去值的均值作为当前时刻的预测值, 在序列取值随时间波动较小的情况下, 若移动均值与该时刻的真实值的差值超过一定阈值, 则判定该时间的值异常, 从而对含噪数据进行平滑处理。用移动均值替代当前时刻取值以过滤噪声, 从而预测未来的值。

#### 2) 底噪信息处理

信号噪声广泛存在于环境中, 所有处于电磁环境中的电子设备, 都会受到环境中电磁噪声的影响<sup>[10]</sup>。现阶段由于设备数量急剧增加, 电磁环境严重恶化<sup>[11]</sup>, 以及无线电通信业务的高速发展, 各频段内的噪声干扰都十分严重。合理设定阈值, 并将信号通过滤波器, 尽可能减小噪声对于信号的影响<sup>[12]</sup>。

### 1.2 信号评价指标

为了评价时间序列分解过程中的模型预测精确度, 选取平均绝对误差( $E_{MAE}$ )、均方误差( $E_{MSE}$ )、均方根误差( $E_{RMSE}$ )作为信号处理结果的评价指标, 定义如下:

$$E_{MAE} = \frac{\sum_i |\hat{y}_i - y_i|}{n} \quad (3)$$

$$E_{MSE} = \frac{\sum_i (\hat{y}_i - y_i)^2}{n} \quad (4)$$

$$E_{RMSE} = \sqrt{\frac{\sum_i (\hat{y}_i - y_i)^2}{n}} \quad (5)$$

式中： $n$ 为测试数据的数量； $y_i$ 为数据的预测值； $\hat{y}_i$ 为数据的实际值。

## 2 系统模型构建

STL时间序列分解法是以局部加权回归作为平滑方法的时间序列分解方法。STL是一种滤波方式，可以把时间序列分解为趋势项、季节项和剩余项。在预处理时序数据时，可以有效处理复杂信号，降低噪声干扰。对于有一定周期性规律的时间序列信号，可将原始序列分解成Trend、Seasonal和Loss 3项。其中，Trend代表数据的长期趋势，Trend是长期增长的；Seasonal代表循环项，即能够周期出现的季节性因子；Loss代表原始数据分解完Trend和Seasonal之后的残差<sup>[13]</sup>。

STL是一种迭代算法，对趋势和季节成分的估计逐步细化和改进。STL分解方法由内循环和外循环2个递归过程组成，是内循环与外循环的共同嵌套。内循环主要计算Trend和Seasonal两项，假定 $T_t^{(k)}$ 、 $S_t^{(k)}$ 为内循环中第 $k-1$ 次结束时的趋势分量、季节分量，初始化时 $T_t^{(k)}=0$ ，同时计算各个步骤结束时的平滑参数。内循环主要步骤如下：

- 1) 去趋势项：去除上一轮结果的趋势分量 $Y_t - T_t^{(k)}$ ；
- 2) 对季节项进行平滑操作，将平滑结果记为 $C_t^{(k+1)}$ ；
- 3) 对季节项子序列进行过滤：对上一步骤的结果序列做滑动平均、局部加权回归处理，得到序列 $L_t^{(k+1)}$ ；
- 4) 去除平滑季节项子序列： $S_t^{(k+1)} = C_t^{(k+1)} - L_t^{(k+1)}$ ；
- 5) 去季节项：减去季节项分量 $Y_t - S_t^{(k+1)}$ ；
- 6) 对去季节项、趋势项后的数据进行平滑操作，并进行局部加权回归处理，最终得到趋势分量 $T_t^{(k+1)}$ 。

趋势性、季节性程度及季节项波峰的计算结果如下：

$$Y_t = T_t + S_t + R_t \quad (6)$$

式中： $Y_t$ 为 $t$ 时刻的观测值； $T_t$ 、 $S_t$ 和 $R_t$ 分别为 $t$ 时刻的趋势项、季节项和残差项。

对于趋势性很强的数据，经季节项调整后的数据应比残差项的变动幅度更大。因此， $Var(R_t)/Var(T_t + R_t)$ 相对较小，可以定义趋势强度为：

$$F_T = \max\left(0, 1 - \frac{Var(R_t)}{Var(T_t + R_t)}\right) \quad (7)$$

当趋势强度 $F_T$ 接近0时，表示该序列几乎没有趋势性；当趋势强度 $F_T$ 接近1时，表示该序列趋势性与时间具有强相关性<sup>[14]</sup>。在时间序列中，季节性一般呈现周期性变化规律，季节性周期中的波峰大体上也是固定的，因此只需找到季节性周期中的最大值即可确定波峰期<sup>[15]</sup>。时间序列分解模型分为2类：相加模型(additive)和相乘模型(multiplicative)。对于正弦、含噪的信号，应选用相加模型。

通过STL时间序列分解，可以计算出时间序列的变化趋势、周期值、周期频率、波动范围等信息，并了解它们之间的联系。对于周期时间序列信号，理想的STL分解结果中的残差项均值为0。

## 3 基于时间序列分解的数据挖掘-预测应用实例分析

### 3.1 含噪ASK信号的STL调制解调传输过程

本文使用的数据来自仿真数据集，ASK含噪信号载波频率 $f_1 = 10$  MHz，FSK含噪信号载波频率 $f_1 = 10$  MHz， $f_2 = 5$  MHz，信噪比-10~100 dB不等，采样过程中最多采样 $10^6$ 个点。为了验证本文算法的有效性，将其与非STL的相干解调算法进行对比。首先以传输情况良好的大信噪比环境下的ASK信号为例进行分解，可以发现，在ASK信号采样点充足时，即使在有噪声、不知道载波信息的情况下，也可以通过STL分解将原始信号分解出载波信息，利用分解出的季节项还原为载波信号对已调信号进行还原处理。

首先将采样后的信号进行拟合与分解，拟合过程采用滑动窗口平均法，窗口大小为5。以信噪比为10条件下的ASK信号为例进行STL分解，见图1。取前450个采样点对未来50个值进行预测，并计算MSE等指标对预测值的误差进行评估。

图2给出了含噪ASK信号的STL分解后的趋势项、季节项、误差项波形，Trend在码元变化的时间点位置产生了上升沿或下降沿。同时，在码元突变时刻，Trend与Loss共同产生了对分解出的Seasonal载波的补偿。Loss项也可以利用突变检测方法进行检测。




Fig.1 Time domain ASK signal with a signal-to-noise ratio of 10

图1 信噪比为10的时域ASK信号




Fig.2 STL decomposition process of ASK signal with S/N ratio of 20

图2 信噪比为20的ASK信号STL分解过程

图3给出了ASK信号传输过程中的波形变化过程。含噪信号经过拟合、圆滑滤波处理之后与STL分解出的季节项 Seasonal 信号相乘并低通进行解调时，可以准确还原出初始基带码元信号，结果如图4所示。




Fig.3 STL decomposition process of ASK signal with SNR of 10

图3 信噪比为10的ASK信号STL分解过程

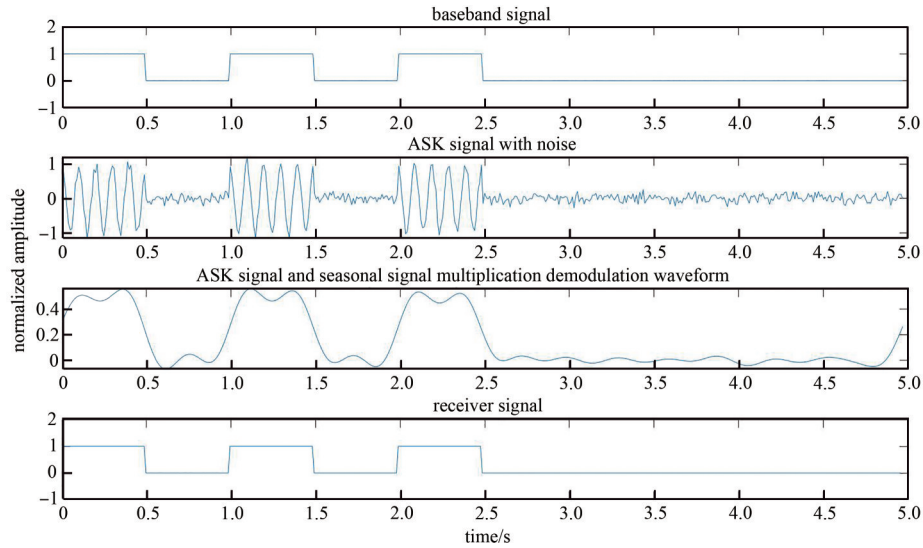


Fig.4 Demodulation of the signal after decomposition of STL and the judgment process  
图 4 对 STL 分解后的信号解调及判决过程

### 3.2 FSK 信号的 STL 二次分解过程

由于 FSK 信号可看作 2 路 ASK 信号的叠加，因此可以通过 2 次 STL 分解进行载波与码元信号的还原。第 1 次分解出的 Trend 中含有另 1 路 ASK 信号分量(见图 5)，故对 FSK 信号进行第 2 次 STL 分解(见图 6)。通过结果可以看出，分解出的 Trend 均值约为 0；季节项即新载波项，可以解调出载波  $f_2$ ；残差在  $f_2$  的码元处主要包含噪声，在  $f_1$  的码元处主要包含对季节项的补偿。




Fig.5 First STL decomposition of the noisy FSK signal  
图 5 对含噪 FSK 信号的第一次拟合并 STL 分解

## 4 性能分析

### 4.1 均方误差分析

将经过去噪与拟合后的发送信号进行 STL 分解再解调还原之后的信号与原始发送端信号进行误差分析。选取采样点与预测点的均方误差与绝对误差值进行对比，利用前 90% 的数据进行训练，后 10% 用于预测验证，计算并分析预测值准确性，得到结果如图 7 所示。

由此可见，随着信噪比  $E_b/N_0$  的增加，接收端信号预测值的均方误差、绝对误差都逐渐减小。信噪比较大时，预测点所还原出信号的均方误差、绝对误差与含噪信号的均方误差、绝对误差相比更小。这是因为经过第一步去噪拟

合，采样过程中数据量足够多时，机器学习进行数据分析权重矩阵更加准确。在大信噪比下能很好地还原原信号以及载波信号，对时间信号预测比较准确；对于低信噪比情况下，预测过程中权重部分包含误差较大。




Fig.6 Second STL decomposition of the noisy FSK signal  
图6 对含噪FSK信号的第二次STL分解




Fig.7 Comparison of MSE and average absolute error before /after decomposition and prediction  
图7 分解前后及预测均方误差和绝对误差对比图

### 4.2 收端误码性能分析

针对ASK调制信号在加性高斯白噪声信道下解调进行性能分析。仿真设置 $E_b/N_0$ 为-4~10 dB，每次增加1 dB，在每个 $E_b/N_0$ 下随机产生 $10^6$ 个符号构成数据集；同时在接收机噪声建模中，添加加性高斯白噪声，并将噪声加到整个信号中。数据集随机分为2部分，其中前90%用于训练，后10%用于预测和验证。图8为不同调制信号在加性高斯白噪声信道下解调的误码性能。

## 5 结论

本文提出了一种基于时间序列分解的电磁数据处理方法，通过仿真对比结果以及理论分析可以发现，相对于传统解调方法，本文提出的方法性能更优。在解调性能上，基于时间序列分解的FSK与ASK解调信号误码率低；在时间复杂度上，基于时间序列分解的FSK与ASK解调的算法实现简单，在信噪比良好，信道传输过程稳定，码元数量大时优势更为明显。高信噪比环境下，采样点充足时，基于时间序列分解的FSK与ASK信号解调方法的误码率比传统相干解调要小很多，利用机器学习的方法更能提升大量信号数据时各种噪声环境下信号处理、调制解调过程的准确性。本文利用机器学习方法对时域信号进行处理，为复杂多样的电磁环境下的信号处理过程提供了一种新的思路。

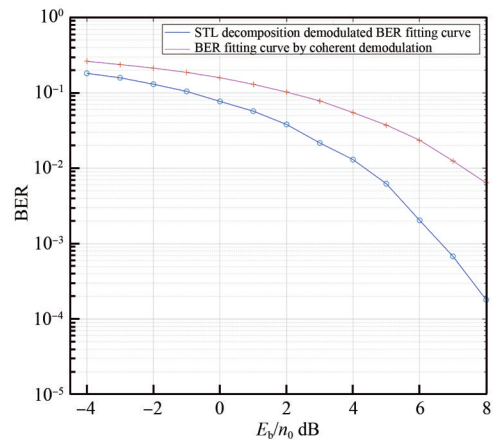


Fig.8 BER comparison under different demodulation methods  
图8 不同解调方式下的误码率对比

## 参考文献：

- [1] 徐洪志,姚家驰,刘超,等. 基于特征提取和机器学习的电磁目标识别方法[J]. 火控雷达技术, 2022,51(2):10–14. (XU Hongzhi, YAO Jiachi, LIU Chao, et al. An electromagnetic target recognition method based on feature extraction and machine learning[J]. Fire Control Radar Technology, 2022,51(2):10–14.) doi:10.19472/j.cnki.1008–8652.2022.02.002.
- [2] 陈显敏. 基于机器学习方法的数字调制信号解调研究[D]. 桂林:桂林电子科技大学, 2021. (CHEN Xianmin. Research on demodulation of digitally modulated signals based on machine learning methods[D]. Guilin, Guangxi, China: Guilin University of Electronic Science and Technology, 2021.) doi:10.27049/d.cnki.gglde.2021.000079.
- [3] 齐思航,徐争光. 脉冲噪声下 MSK 信号解调算法研究[J]. 舰船电子工程, 2021,41(7):89–92,101. (QI Sihang, XU Zhengguang. Research on MSK signal demodulation algorithm under impulsive noise[J]. Ship Electronics Engineering, 2021, 41(7): 89–92,101.)
- [4] 赵笙岚. 面向电磁目标识别的分布式机器学习算法[D]. 成都:电子科技大学, 2022. (ZHAO Shenglan. Distributed machine learning algorithms for electromagnetic target recognition[D]. Chengdu, Sichuan, China: University of Electronic Science and Technology, 2022.) doi:10.27005/d.cnki.gdzku.2022.001073.
- [5] 施国威. GNSS 信号异常识别技术研究及实现[D]. 桂林:桂林电子科技大学, 2020. (SHI Guowei. Research and Implementation of GNSS signal anomaly identification technology[D]. Guilin, Guangxi, China: Guilin University of Electronic Science and Technology, 2020.) doi:10.27049/d.cnki.gglde.2020.000453.
- [6] 韩悦. 水库水质多维数据挖掘技术及应用[D]. 大连:大连理工大学, 2017. (HAN Yue. Multi-dimensional data mining technology and application for reservoir water quality[D]. Dalian, Liaoning, China: Dalian University of Technology, 2017.)
- [7] 赵然杭,甘甜,逢晓腾,等. 基于时间序列分解的降雨数据挖掘与预测[J]. 中国农村水利水电, 2021(11):116–122. (ZHAO Ranhang, GAN Tian, PANG Xiaoteng, et al. Rainfall data mining and prediction based on time series decomposition[J]. China Rural Water Conservancy and Hydropower, 2021(11):116–122.)
- [8] 杨长春,聂倩倩. 面向 PM<sub>2.5</sub> 预测的时间序列分解与机器学习融合模型[J/OL]. 安全与环境学报, 2022:1–11. (YANG Changchun, NIE Qianqian. A time series decomposition and machine learning fusion model for PM<sub>2.5</sub> prediction[J/OL]. Journal of Safety and Environment, 2022:1–11.) doi:10.13637/j.issn.1009–6094.2022.1616.
- [9] 赵振华,罗振江,黄林显,等. 基于 STL 和 Mann–Kendall 法的济南市降雨与地下水变化分析[J]. 水文, 2022,42(6):73–77. (ZHAO Zhenhua, LUO Zhenjiang, HUANG Linxian, et al. Analysis of precipitation and groundwater variation based on STL and Mann–Kendall methods in Jinan City[J]. Journal of China Hydrology, 2022,42(6):73–77.)
- [10] 王圆春,肖东,林云. 电磁频谱数据的关联规则挖掘[J]. 电波科学学报, 2022,37(5):802–809,836. (WANG Yuanchun, XIAO Dong, LIN Yun. Mining association rules for electromagnetic spectrum data[J]. Chinese Journal of Radio Science, 2022,37(5): 802–809,836.)
- [11] WU Yunqiu, TANG Zongxi, ZHANG Biao, et al. Using support vector machine regression for measuring electromagnetic parameters of magnetic materials[C]// International Symposium on Microwave, Antenna, Propagation and EMC Technologies for Wireless Communications. Hangzhou, China: IEEE, 2007:1020–1022.
- [12] 李爽,刘海鹏,郭兰图. 基于电磁环境数据的信息挖掘与关联分析[J]. 太赫兹科学与电子信息学报, 2022,20(1):8–15. (LI Shuang, LIU Haipeng, GUO Lantu. Information mining and correlation analysis based on electromagnetic environment data[J]. Journal of Terahertz Science and Electronic Information Technology, 2022,20(1):8–15.)
- [13] ZHANG Yubo, GUO Lijuan, YIN Liqun, et al. Predicting electromagnetic environment parameters of power transmission line with data mining methods[C]// IEEE International Symposium on Electromagnetic Compatibility. Beijing: IEEE, 2017:1–4.
- [14] LI S, SUN Y, HAN Y, et al. A novel joint Time–Frequency Spectrum resources sustainable risk prediction algorithm based on TFBRL–network for the electromagnetic environment[J]. Sustainability, 2023,15(6):4777.
- [15] LI S, SUN Y, ZHANG H, et al. MTF<sup>2</sup>N: multi–channel temporal–frequency fusion network for spectrum prediction[C]// 2022 IEEE Global Communications Conference. Rio de Janeiro, Brazil: IEEE, 2022:4703–4709.

## 作者简介:

郭锦桥(2000-), 男, 在读本科生, 主要研究方向为电磁数据分析挖掘、电磁兼容 .email:guojinqiao@hrbeu.edu.cn.

柳禹名(2001-), 男, 在读本科生, 主要研究方向为信息传输理论与系统.

曹卫东(2001-), 男, 在读本科生, 主要研究方向为宽带智能通信系统、智能无线电.

林云(1980-), 男, 博士, 教授, 主要研究方向为智能无线电技术、人工智能和机器学习、大数据分析 with 挖掘、智能信息处理.

(上接第 750 页)

- [16] PARK D C, JEONG T K J. Complex-bilinear recurrent neural network for equalization of a digital satellite channel[C]// 1999 International Joint Conference on Neural Networks. Washington, DC, USA: IEEE, 1999.
- [17] TRABELSI C, BILANIUK O, ZHANG Y, et al. Deep complex networks[J/OL]. arXiv:1705.09792, 2018.
- [18] 张航, 吴泓霖, 余勤, 等. 基于多特征信息的深度学习网络调制识别算法[J]. 计算机工程与设计, 2022, 43(10): 2762-2768. (ZHANG Hang, WU Honglin, YU Qin, et al. Modulation recognition algorithm for multiple feature information based on deep learning[J]. Computer Engineering and Design, 2022, 43(10): 2762-2768.)
- [19] WANG Q, WU B, ZHU P, et al. ECA-Net: efficient channel attention for deep convolutional neural networks[C]// 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, WA, USA: IEEE, 2020: 11531-11539.
- [20] ZHANG Wei, LI Chuanhao, PENG Gaoliang, et al. A deep convolutional neural network with new training methods for bearing fault diagnosis under noisy environment and different working load[J]. Mechanical Systems and Signal Processing, 2018(100): 439-453.
- [21] ZEILER M D, FERGUS R. Visualizing and understanding convolutional networks[C]// 2014 European Conference on Computer Vision. Zurich, Switzerland: Springer, 2014.
- [22] 张良, 杨威, 李玮杰, 等. 基于复数卷积-残差网络的雷达杂波幅度统计模型分类[J]. 系统工程与电子技术, 2021, 43(11): 3086-3097. (ZHANG Liang, YANG Wei, LI Weijie, et al. Classification of radar clutter amplitude statistical model based on complex-valued convolutional-ResNet[J]. Systems Engineering and Electronics, 2021, 43(11): 3086-3097.)

## 作者简介:

肖飒(1987-), 女, 硕士, 工程师, 主要研究方向为信号处理和识别、电磁对抗与仿真 .email: quanqingxiao@163.com.

马莫涵(2000-), 女, 在读本科生, 主要研究方向为电磁信号识别.

艾佳俊(1998-), 女, 在读硕士研究生, 主要研究方向为通信干扰决策.

胡华超(1981-), 男, 博士, 研究员, 主要研究方向为态势感知、电子对抗.

王刻庸(2001-), 男, 在读本科生, 主要研究方向为电磁信号识别方法研究.

张文中(2000-), 男, 在读硕士研究生, 主要研究方向为分布式通信对抗.