

基于奇异值分解与神经网络的干扰识别

冯 熲 王梓楠*

(东南大学信息科学与工程学院 南京 211189)

摘要: 无线通信中的抗干扰技术对通信的稳定性和安全性都具有重要意义, 干扰识别作为抗干扰技术的重要环节一直是研究的热点。该文提出一种基于奇异值分解与神经网络的干扰识别方法, 该方法只计算信号矩阵的奇异值即完成特征提取, 与传统方法相比节省了多个谱特性的计算量。仿真结果表明: 基于奇异值分解与神经网络的干扰识别方法与传统方法相比在干信比为0 dB左右的条件下识别准确率有10%~25%的提高。

关键词: 干扰识别; 神经网络; 奇异值分解

中图分类号: TN911.72

文献标识码: A

文章编号: 1009-5896(2020)11-2573-06

DOI: 10.11999/JEIT190228

Interference Recognition Based on Singular Value Decomposition and Neural Network

FENG Man WANG Zinan

(College of Information Science and Engineering, Southeast University, Nanjing 211189, China)

Abstract: The anti-interference technology in wireless communication is great significance to the stability and security of communication. As an important part of anti-interference technology, interference recognition is a research hotspot. An interference recognition method based on singular value decomposition and neural network is proposed. This method only calculates the singular value of the signal matrix as the feature. Compared with the traditional method, it saves the computational complexity of multiple spectral features. The simulation results show that the recognition accuracy based on singular value decomposition and neural network is 10%~25% higher than the traditional method under the condition of jamming-signal ratio at 0 dB.

Key words: Jamming recognition; Neural network; Singular value decomposition

1 引言

随着现代信息化战争中高强度“电子战”和“网络电磁空间战”威胁的与日俱增, 各种人为或非人为干扰问题日益突出, 对通信抗干扰的研究也提出了越来越高的要求。常见的干扰主要有: 单音干扰, 扫频干扰, 部分频带干扰以及噪声调频干扰等, 而常规的盲抗干扰方式在设计之初性能基本确定, 抗干扰效果不佳。若能对干扰信号进行识别, 则可以针对不同的干扰信号, 采用不同的调制编码方案, 实现有针对性的自适应抗干扰。因此对干扰识别的研究就显得尤为迫切。

目前干扰识别方法主流是基于信号中的特征提取技术^[1-3], 而单独任意一种特征都不足以完成分类任务, 因此需要对检测信号做多维度的特征提取^[4], 如载波因子系数、平均频谱平坦系数、峰度系数、偏度系数、参数、高斯白噪声因子等时频特

征^[1-3,5]、高阶累计量^[6]、峰值场、平均功率^[6]等特征, 这样一定程度上增大了计算复杂度。

针对上述问题, 本文提出一种基于奇异值分解和神经网络的新干扰识别方法。奇异值分解是基于代数理论的矩阵处理方法, 可以有效地提取矩阵的特征, 采用奇异值分解法对干扰信号进行预处理, 能有效降低信息维度, 利于分类器的学习。而人工神经网络是20世纪80年代以来人工智能领域兴起的研究热点, 相比于支持向量机等传统分类器, 其内部的隐层单元与非线性激活函数可以完成更复杂的多分类操作。本文将该方法用于单音干扰、扫频干扰、部分频带干扰、噪声调频干扰4种常见干扰, 验证了该方法的有效性, 并比较了其与传统特征提取方法的性能。

2 基于奇异值分解的特征提取

奇异值分解是基于代数理论的矩阵处理方法^[7], 目前已广泛应用于信号处理与统计学等领域。设 \mathbf{A} 为 $M \times N$ 阶的矩阵, \mathbf{A} 中的元素属于实数域或复数域, 则存在一个分解, 使

$$\mathbf{A} = \mathbf{U}\mathbf{\Sigma}\mathbf{V}^T \quad (1)$$

其中, \mathbf{U} 是 $M \times N$ 阶的酉矩阵, $\mathbf{\Sigma}$ 为 $M \times N$ 阶非负实数对角矩阵, \mathbf{V}^T 为 \mathbf{V} 的共轭转置, \mathbf{V} 为 $N \times N$ 阶的酉矩阵。将 $\mathbf{\Sigma}$ 矩阵中对角元素从大到小排列即可得到矩阵 \mathbf{A} 的奇异值。

矩阵的几何意义为其对应的一种线性变换, 将这种几何意义映射到奇异值分解中^[8,9], 矩阵 \mathbf{V} 反映了变换前的空间基状态, 矩阵 \mathbf{U} 反映了变换后的空间基状态, $\mathbf{\Sigma}$ 反映了两种基之间的对应关系, 由此可见 \mathbf{V} 和 \mathbf{U} 中的向量间接代表了矩阵 \mathbf{A} 的性质, 因此信号处理中常将 \mathbf{V} 和 \mathbf{U} 矩阵中的向量作为待处理信号的特征。如文献^[10]中提取 \mathbf{V} 和 \mathbf{U} 矩阵作为干扰信号特征进行干扰识别。

通常矩阵 \mathbf{V} 和 \mathbf{U} 维度较高, 处理计算量很大。但对于本文所研究的干扰信号, 如单音干扰、线性扫频干扰、部分频带干扰等, 则有另一种思路。上文提到矩阵的意义是一种线性变换^[3], 那么干扰信号构成的矩阵则表示标准正交基, 如: 标准的单位基到干扰信号基的变换过程。由于干扰信号的形式比较简单, 常常只需1种或几种基就可以表示完全, 因此当此类信号矩阵分解时, \mathbf{V} 和 \mathbf{U} 之间的关系阵 $\mathbf{\Sigma}$ 特征也变得更加明显, 基于此, 本文提出将干扰信号的奇异值矩阵 $\mathbf{\Sigma}$ 作为干扰识别的特征, 设计了基于奇异值分解与神经网络的干扰识别方法。

3 基于奇异值分解与神经网络的干扰识别方案

根据上述分析, 并结合神经网络的特点, 本文提出基于奇异值分解与神经网络的干扰识别方案, 其实现框图如图1所示, 具体地: 首先采集数字化的干扰信号, 并对其功率归一化; 然后将干扰序列排成矩阵形式, 并求其奇异值; 再对所得奇异值序列求导; 最后利用求导得到的序列作为神经网络的输入, 搭建训练网络, 将训练结果送入系统完成干扰识别。

3.1 数字化干扰信号样本

为了保证干扰识别系统具有通用性, 数字化的

干扰信号在处理前需先进行功率归一化处理, 并标明干扰信号的类别, 用于神经网络的训练。

3.2 奇异值分解的预处理

本文提出基于奇异值分解的干扰预处理方法, 设干扰信号序列为 $\mathbf{X} = \{x_i, 1 \leq i \leq l\}$, 其中 $l = m \times n$ 。首先将该序列排列成 $m \times n$ 的矩阵形式, 即

$$\mathbf{X} = \begin{bmatrix} x_1 & x_2 & \cdots & x_m \\ x_{m+1} & x_{m+2} & \cdots & x_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ x_{nm-m+1} & x_{nm-m+2} & \cdots & x_{nm} \end{bmatrix} \quad (2)$$

接着对其进行奇异值分解并得到奇异值序列 $\mathbf{S} = \{s_i, 1 \leq i \leq (m, n)\}$, 则该序列包含了提取的干扰信号特征。不妨设变换后 $m \times n$ 的矩阵为 \mathbf{A} , 则矩阵 \mathbf{A} 与向量做乘法运算相当于原信号与向量做部分卷积, 因此奇异值矩阵 $\mathbf{\Sigma}$ 在一定程度上反映了频域的幅值信息。

本文主要针对单音干扰、线性扫频干扰、部分频带干扰以及噪声调频干扰这4种常见的干扰进行识别分类。其中单音干扰的复基带表达式为

$$\mathbf{J}(t) = \mathbf{A} \exp[j(2\pi f_j t + \phi)] \quad (3)$$

线性扫频干扰的复基带表达式为

$$\mathbf{J}(t) = \mathbf{A} \exp[j(2\pi f_0 t + \pi k t^2 + \phi)], \quad 0 \leq t \leq T \quad (4)$$

部分频带噪声干扰在部分频带内表现为高斯白噪声, 其复基带表达式为

$$\mathbf{J}(t) = \mathbf{U}_n(t) \exp[j(2\pi f_j t + \phi)] \quad (5)$$

噪声调频干扰的复基带表达式为

$$\mathbf{J}(t) = \mathbf{A} \exp \left[j2\pi f_j t + j2\pi k_{fm} \int_0^t \varepsilon(t') dt' \right] \quad (6)$$

其中, $\varepsilon(t)$ 为0均值, 方差恒定的窄带高斯白噪声。

下面给出了在单位功率下, 4种不同类型的干扰信号分别对应的奇异值序列, 每种干扰信号给出两种不同的随机参数, 如图2所示, 其中干扰序列长度 $l=1024$, $m=n=32$ 。

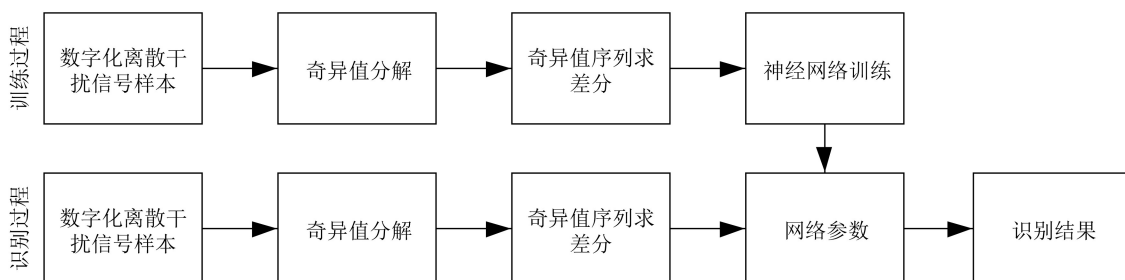


图1 基于奇异值与神经网络到的干扰识别原理

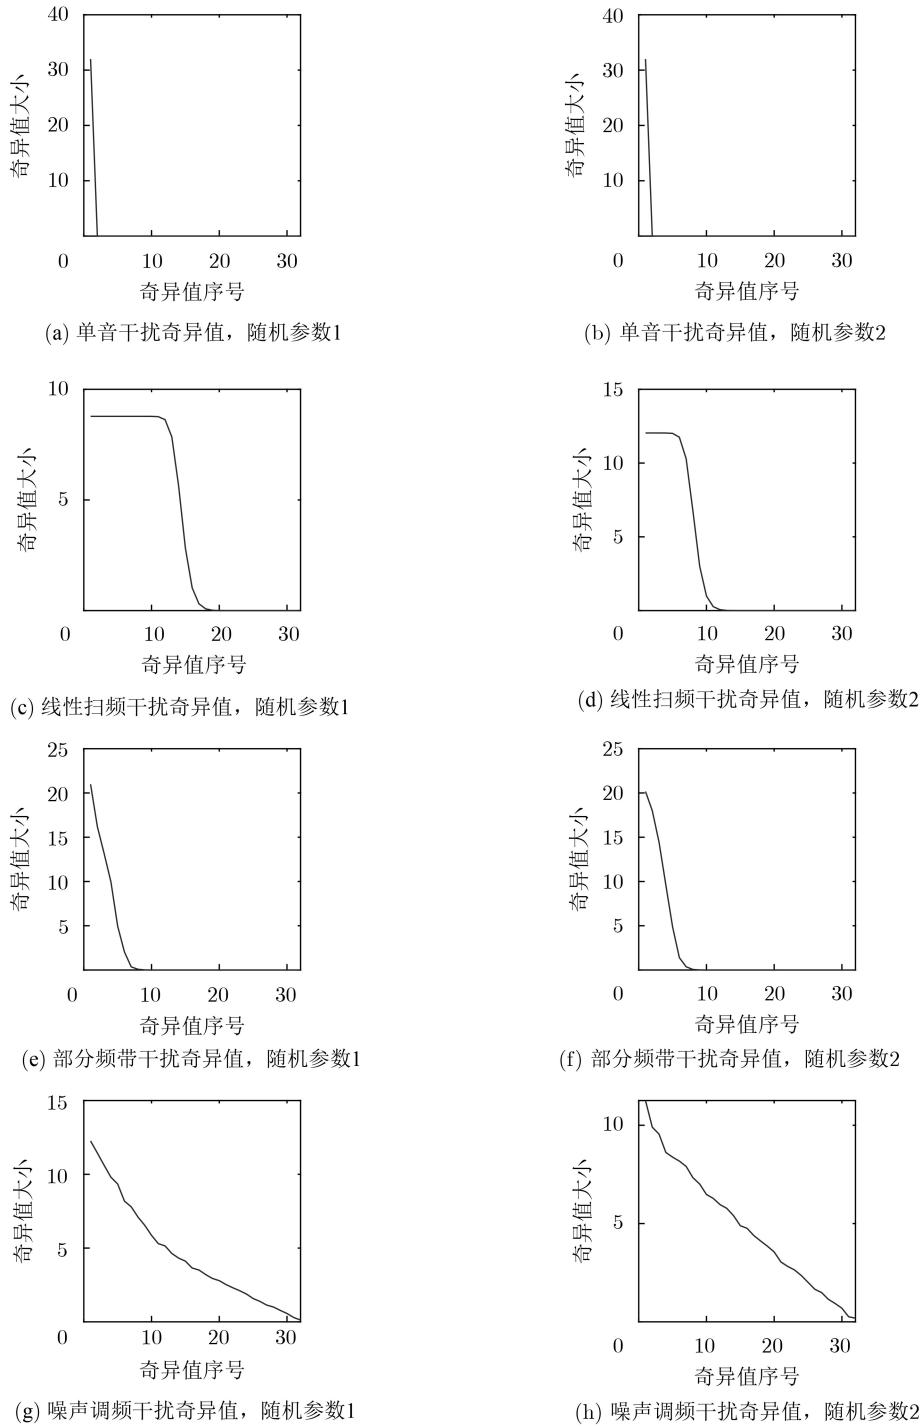


图 2 单音干扰、线性扫频干扰、部分频带干扰、噪声调频干扰信号的奇异值图

根据图2可以看出，各干扰信号的奇异值虽然变化趋势不同，但整体都呈现衰减趋势，若受到噪声影响，其差异会减小，从而对识别性能产生影响。通过观察上述曲线变化规律，发现其下降斜率差异较大，基于此，本文提出对奇异值求差分，进而将变化的趋势信息转化为幅度信息，使各干扰信号的特征区别更大，更容易被分类器学习。图3给出了对各干扰信号奇异值求差分之后的波形曲线，

显然，各曲线变化趋势各不相同，有的近似常数，有的仅起始位置存在较大峰值，有的则在中间位置出现凸起的峰，进而为后续神经网络分类器的学习提供了良好的条件。

3.3 神经网络分类器设计

神经网络的基本原理是利用全连接层、隐层单元以及非线性激活函数来拟合一个未知函数，通过调整网络中的向量值来满足固定要求的输入输出，




图3 各干扰信号奇异值求差分后波形

是一种有监督的学习^[11]。当神经网络的输出为逻辑值0或1时，即为一个分类器。本文使用神经网络作为分类器，来识别求导之后的奇异值向量，进而实现对干扰信号的识别。

神经网络的核心问题是结构设计。由于奇异值分解的方法已经完成了对信号的特征提取，因此神经网络只需要完成分类作用，对深度的要求不大。因此本文采用的网络结构为：输入层——单层隐层——输出层的结构，其中输入层单元个数为奇异值向量的长度，隐层单元个数略大于输入单元个数，输出层单元个数为3，即要识别的干扰类别数。以 $l=1024$, $m=n=32$ 为例，对应的神经网络结构如图4所示。

损失函数的选择直接影响到优化结果和网络模型最终的分类效果，本文采用的损失函数为交叉熵，相比于均方误差等损失函数，交叉熵更适合处理逻辑回归问题，而本文对干扰信号的识别就属于逻辑回归的一种。对于给定的两个概率分布 p 和 q ，通过 q 来表示 p 的交叉熵为

$$H(p, q) = - \sum p(x) \log_2 q(x) \quad (7)$$

实际中， p 用来表示理想状态下神经网络的输出，即训练样本的输出值。 q 表示神经网络的实际输出。

为了解决分类器的线性特性，常常要引入非线性

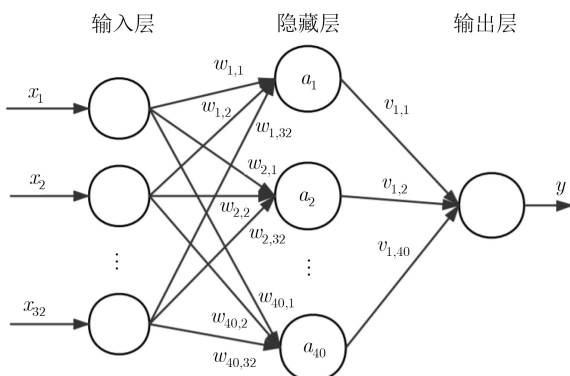


图4 神经网络结构图

性的激活函数。本文在输出层采用Softmax的激活函数，其常被用于多分类问题，表达式为

$$\sigma(z)_j = \frac{e^{z_j}}{\sum_k e^{z_k}} \quad (8)$$

其中， z_j 表示第 j 类的网络输出值， $\sigma(z)_j$ 结果判定为 j 类的概率，其等于当前类别输出值的自然指数比全部类别的自然指数和。

Softmax函数实际上是有限项离散概率分布的梯度对数归一化。经过测试，在本文的仿真实验中，在隐层也采用Softmax函数的网络其性能要优于采用Sigmoid函数的网络，因此在隐层也采用Softmax激活函数。

4 仿真结果分析

4.1 仿真结果

为了验证该系统的干扰识别效果，本文采用MATLAB与TensorFlow框架对常见的4种干扰信号：单音干扰、线性扫频干扰、部分频带干扰及噪声调频干扰进行仿真实验。首先随机生成4种干扰信号，每种干扰信号的数量为4096个，其中前2048个作为训练样本，后2048个作为测试样本，将每个干扰信号截取出长度为1024的序列，并进行 32×32 的奇异值分解，得到奇异值并求导。之后利用TensorFlow框架搭建神经网络^[12]，进行训练。训练数据共有 2048×4 个，batchsize大小为16。经过调参测试后，发现当网络结构为单隐层，输入单元为32个，隐层单元为40个，输出单元为3个时，网络收敛效果最好。在无噪声和调制信号的情况下，仅对这4种干扰进行识别，仿真得到如表1所示的干扰识别率。测试方法为随机输入4种干扰信号，检测并统计系统的识别结果是否正确。

从表1中可以看出，不论对于训练样本还是测试样本，基于奇异值分解与神经网络的干扰识别法能以高的准确度完成训练与分类过程。

4.2 性能对比

为了验证该系统性能，本文将实验结果与传统的基于特征提取的干扰识别方法进行对比。干扰识别属于信号识别的一种，因此干扰识别的特征提取方法为经典的信号特征提取方法^[1-6,13]。特征提取后

表1 对单音干扰、线性扫频干扰、部分频带干扰及噪声调频干扰信号的识别率(%)

BP神经网络输入	训练样本识别正确率	测试样本识别正确率
奇异值导数	99.753	98.437

仍采用神经网络作为分类器来重点对比其与奇异值分解法的性能差别。此外, 本文还同时对比了未对奇异值求差分的情况。其中, 通信信号采用QPSK调制, 干扰信号仍为单音干扰、线性扫频干扰、部分频带干扰以及噪声调频干扰4种, 图5给出了不同干信比情况下, 上述3种方法的识别率。测试方法仍为随机输入4种干扰信号, 检测并统计系统的识别结果是否正确。




图5 采用不同方法得到的干扰识别率对比

根据图5可知, 识别错误率呈现阶跃式变化, 原因是由于部分频带干扰、噪声调频干扰的特征较为相似, 在干信比为6 dB左右时, 这两种干扰的识别会受到影响, 准确率有一个快速跌落。同理在干信比为2 dB左右时, 扫频干扰的特征也会受到影响而不易区分, 出现了类似的状况。此现象在采用基于特征提取的经典方法时表现得尤为明显。单音干扰的特征比较明显, 在低干信比时依然能够被准确识别。在奇异值分解未求差分的情况下, 其准确率要低于经典方法。但奇异值求差分后的性能要优于前两者性能, 尤其在0 dB左右约有10%~25%准确率的提高。

另外, 奇异值求导的方法相较于传统方法在一定程度上具有更低的复杂度。因为在传统方法中, 奇异谱熵或奇异谱功率都是重要特征之一, 而这两种特征的提取都要计算奇异值分解, 而且还需要另外计算多个特征才能达到较为满意的识别效果, 相比于本文所提方法增大了计算量。

下面给出了不同维度的奇异值分解对识别正确率的影响。对于不同的 l , 都选取 m 和 n 相等的情况, 根据图6可知, 在低干信比情况下, 当 $l=256$, $m=n=16$ 和 $l=576$, $m=n=24$ 时, 该方法会失去识别功能。随着维度增大到 $l=1024$, $m=n=32$ 时, 会具有一定分类效果, 之后继续增大维度, 准确率整体上有略微提升, 但提升的效果不明显。在高干信比情况下, 当 $l=256$, $m=n=16$ 时, 准确率会存在上限, 约为92%, 其他维度的准确度差异不大。由




图6 采用不同维度奇异值分解得到的干扰识别率对比

于矩阵运算的复杂度与 m 和 n 呈平方增长的关系, 因此折中考虑, 取 $l=1024$, $m=n=32$ 较为适宜。

5 结束语

本文提出了一种基于奇异值分解与神经网络的干扰识别方法, 通过对干扰信号进行奇异值分解并求差分, 可以得到差异明显的干扰特征, 为干扰识别的特征提取提供了新的思路。同时, 与传统方法相比, 所提系统设计更为简单、计算量相对较小。仿真结果表明, 该系统对单音干扰、线性扫频干扰、部分频带干扰以及噪声调频干扰可进行有效识别, 尤其在干信比为0 dB左右的情况下, 识别正确率远高于传统方法, 进而验证了该方法的有效性。本文提出的方法目前对单音干扰、线性扫频干扰、部分频带干扰以及噪声调频干扰具有良好的识别效果, 对其他干扰的识别效果将在进一步的研究中验证。

参考文献

- [1] GRECO M, GINI F, and FARINA A. Radar detection and classification of jamming signals belonging to a cone class[J]. *IEEE Transactions on Signal Processing*, 2008, 56(5): 1984–1993. doi: 10.1109/TSP.2007.909326.
- [2] DOBRE O A, ABDI A, BAR-NESS Y, et al. Survey of automatic modulation classification techniques: Classical approaches and new trends[J]. *IET Communications*, 2007, 1(2): 137–156. doi: 10.1049/iet-com:20050176.
- [3] AZZOUE E E and NANDI A K. Automatic identification of digital modulation types[J]. *Signal Processing*, 1995, 47(1): 55–69. doi: 10.1016/0165-1684(95)00099-2.
- [4] 梁金弟, 程郁凡, 杜越, 等. 联合多维特征的干扰识别技术研究[J]. *信号处理*, 2017, 33(12): 1609–1615. doi: 10.16798/j.issn.1003-0530.2017.12.012.
- LIANG Jindi, CHENG Yufan, DU Yue, et al. The research of interference recognition technology based on the joint multi-dimensional features[J]. *Journal of Signal Processing*, 2017, 33(12): 1609–1615. doi: 10.16798/j.issn.1003-0530.2017.12.012.

- [5] 郝万兵, 马若飞, 洪伟. 基于时频特征提取的雷达有源干扰识别[J]. 火控雷达技术, 2017, 46(4): 11–15. doi: [10.3969/j.issn.1008-8652.2017.04.003](https://doi.org/10.3969/j.issn.1008-8652.2017.04.003).
HAO Wanbing, MA Ruofei, and HONG Wei. Radar active jamming identification based on time-frequency characteristic extraction[J]. *Fire Control Radar Technology*, 2017, 46(4): 11–15. doi: [10.3969/j.issn.1008-8652.2017.04.003](https://doi.org/10.3969/j.issn.1008-8652.2017.04.003).
- [6] 程汉文, 朱雷, 吴乐南. 基于累计量的干扰信号调制识别算法[J]. 电子与信息学报, 2009, 31(7): 1741–1745. doi: [10.3724/SP.J.1146.2008.00910](https://doi.org/10.3724/SP.J.1146.2008.00910).
CHENG Hanwen, ZHU Lei, and WU Lenan. Modulation classification algorithm for jamming signal based on cumulant[J]. *Journal of Electronics & Information Technology*, 2009, 31(7): 1741–1745. doi: [10.3724/SP.J.1146.2008.00910](https://doi.org/10.3724/SP.J.1146.2008.00910).
- [7] 李伟, 魏光辉, 潘晓东, 等. 复杂电磁环境下通信装备干扰预测方法[J]. 电子与信息学报, 2017, 39(11): 2782–2789. doi: [10.11999/JEIT170107](https://doi.org/10.11999/JEIT170107).
LI Wei, WEI Guanghui, PAN Xiaodong, et al. Interference prediction method of communication equipment under complex electromagnetic environment[J]. *Journal of Electronics & Information Technology*, 2017, 39(11): 2782–2789. doi: [10.11999/JEIT170107](https://doi.org/10.11999/JEIT170107).
- [8] 姜丹丹. 张量奇异值及高阶奇异值分解具有的若干性质[D]. [硕士学位论文], 哈尔滨工业大学, 2017.
JIANG Dandan. A number of properties of singular value and higher order singular value decomposition of tensor[D]. [Master dissertation], Harbin Institute of Technology, 2017.
- [9] KALMAN D. A singularly valuable decomposition: The SVD of a matrix[J]. *The College Mathematics Journal*, 1996, 27(1): 2–23. doi: [10.1080/07468342.1996.11973744](https://doi.org/10.1080/07468342.1996.11973744).
- [10] SEILER M C and SEILER F A. Numerical recipes in C: The art of scientific computing[J]. *Risk Analysis*, 1989, 9(3): 415–416. doi: [10.1111/j.1539-6924.1989.tb01007.x](https://doi.org/10.1111/j.1539-6924.1989.tb01007.x).
- [11] KONG Lei, XU Zhijun, WANG Jinming, et al. A novel algorithm for jamming recognition in wireless communication[C]. The 2013 6th International Congress on Image and Signal Processing, Hangzhou, China, 2013: 1473–1477. doi: [10.1109/CISP.2013.6743907](https://doi.org/10.1109/CISP.2013.6743907).
- [12] 章敏敏, 徐和平, 王晓洁, 等. 谷歌TensorFlow机器学习框架及应用[J]. 微型机与应用, 2017, 36(10): 58–60. doi: [10.19358/j.issn.1674-7720.2017.10.017](https://doi.org/10.19358/j.issn.1674-7720.2017.10.017).
ZHANG Minmin, XU Heping, WANG Xiaojie, et al. Application of Google TensorFlow machine learning framework[J]. *Microcomputer & Its Applications*, 2017, 36(10): 58–60. doi: [10.19358/j.issn.1674-7720.2017.10.017](https://doi.org/10.19358/j.issn.1674-7720.2017.10.017).
- [13] 徐国进. 典型通信干扰信号识别技术研究[D]. [硕士学位论文], 电子科技大学, 2018.
XU Guojin. Research on identification of typical communication jamming signals[D]. [Master dissertation], University of Electronic Science and Technology of China, 2018.
- 冯 嫚: 女, 1979年生, 副教授, 主要研究方向为超窄带通信、无线携能通信、军事抗干扰通信、智能通信信号处理等。
王梓楠: 男, 1993年生, 硕士生, 主要研究方向为通信信号处理、机器学习。

责任编辑: 马秀强