

基于 CNN 网络的跳频信号个体识别

梁 策, 郭 英, 李红光

(空军工程大学信息与导航学院, 西安, 710077)

摘要 针对传统跳频信号指纹特征提取只是利用深度学习进行分类的问题,利用 CNN 网络特征提取的特性,实现了一种基于 CNN 网络的对预处理后的跳频信号实现特征提取和分类网络模型。首先将收集的跳频信号进行短时傅里叶变换转换到跳频信号敏感的频域,将跳频信号频谱图作为 CNN 网络模型的输入,CNN 网络通过多层卷积提取信号频域深层次特征,通过 Batch Normalization、Callback 函数的优化加快了网络的收敛速度,同时防止了过拟合现象,最终输出跳频信号的识别分类结果。对比实验结果表明,CNN 网络的分类识别正确率较以往的方法更高,在信号信噪比越大的情况下,识别效果越好。

关键词 跳频信号;CNN 卷积神经网络;多层卷积;特征提取

DOI 10.3969/j.issn.1009-3516.2020.03.010

中图分类号 TN975 **文献标志码** A **文章编号** 1009-3516(2020)03-0057-06

Individual Identification of Frequency-Hopping Signals Based on CNN Network

LIANG Ce, GUO Ying, LI Hongguang

(Information and Navigation College, Air Force Engineering University, Xi'an 710077, China)

Abstract Previous researches of fingerprinting feature extraction of frequency-hopping signals have just classified signals through deep learning. We wish to create a new model based on CNN convolutional neural network which can extract the characteristics of the pre-processed frequency hopping signals and classify them using those characteristics. Firstly, we perform short-time Fourier transform on the collected frequency-hopping signals to present them in frequency hopping sensitive frequency domain. The converted signals will be putted into the CNN network model and convolved, pooled and fully connected so that we can get final classification results. In this process, we use multi-layer convolution to extract deep-level features in the frequency domain of the signals and apply Batch Normalization and Callback functions which can not only optimize and accelerate network convergence speed, but also prevent overfitting effectively. From the final data, the new network model has higher individual recognition accuracy rate than the previous.

Key words frequency hopping signal; CNN convolutional neural network; multilayer convolution; feature extraction

跳频信号因其具备良好的抗干扰性、低截获概率性以及良好的组网特性,一直以来都广泛应用于

收稿日期: 2019-08-27

基金项目: 国家自然科学基金(61601500,61871396)

作者简介: 梁 策(1996—),男,河南漯河人,硕士生,主要从事通信信号处理、深度神经网络研究。E-mail:afeu_lc@163.com

通信作者: 郭 英(1961—),女,山西临汾人,教授,博士生导师,主要从事通信信号处理、自适应信号处理研究。E-mail:yguo163@163.com

引用格式: 梁策,郭英,李红光.基于 CNN 网络的跳频信号个体识别[J].空军工程大学学报(自然科学版),2020,21(3):57-62. LIANG Ce, GUO Ying, LI Hongguang. Individual Identification of Frequency-Hopping Signals Based on CNN Network[J]. Journal of Air Force Engineering University (Natural Science Edition), 2020, 21(3): 57-62.

各类通信中,在军事通信应用中尤为突出。现阶段,电磁环境复杂、无线电干扰多、跳频通信电台数量多、非法占用电磁频谱多、空中跳频信号种类复杂,如何在复杂的电磁环境中对敌我双方跳频信号进行个体识别已经成为当今跳频通信领域的重要研究课题,也是通信安全领域亟待解决的问题。

传统的跳频通信信号识别方法主要分为两大类:基于参数估计的网台分选技术和基于盲源分离的网台分选技术。基于参数估计的网台分选技术主要依靠跳频信号的跳周期、空间侧向 DOA 信息、接收功率以及信号相关特性等信息,但是随着跳频信号的广泛应用和调制样式的愈加多样化,传统的网台分选技术由于可估计参数数量少,估计精度低,分选正确率极大地依赖于特征参数估计的精确度,缺乏电台个体信息,已经不能够满足在复杂电磁环境下的跳频电台识别需求;基于盲源分离的网台分选技术由于限定条件下混合矩阵的估计难度大,也无法满足当今需求。

硬件设备上的个体差异导致跳频通信电台存在着不影响信息传递的可检测、可重现的细微特征差异,我们称之为跳频电台的指纹特征。近年来,通过分析指纹特征来进行跳频电台个体识别的研究取得了巨大的进展。文献[1]提出了一种基于改进的 Prony 算法提取跳频电台的瞬时频率,分离并定量计算其最大 Lyapunov 指数和盒维数等瞬时特征作为指纹特征,通过得到的指纹特征和构造性神经网络进行不同跳频电台的个体识别;文献[2]利用一种改进型的基于小波变换的包络提取算法提取跳频信号的瞬时包络,分离并定量计算其盒维数和信息维数等瞬时特征作为指纹特征,通过得到的指纹特征和构造性神经网络进行不同跳频电台的个体识别;文献[3]提出了将相关维数等基于混沌理论的特征作为跳频电台细微特征的可行性研究。以上文献研究重点都是如何提取跳频电台的某一指纹特征,再将提取到的指纹特征输入到神经网络,实现对跳频电台的个体识别。文献[4]充分利用了卷积神经网络(Convolutional Neural Network, CNN)对输入进行深层次特征提取的优势。

本文跳出传统跳频信号指纹特征提取的局限,不再将深度学习神经网络仅作为对提取到的跳频信号指纹特征的分选工具,而是借助深度学习神经网络将预处理后的跳频信号频谱图作为输入,通过 CNN 进行跳频电台的指纹特征提取并输出分类识别结果。

1 基于 STFT 的跳频信号预处理

跳频信号是指在伪随机码和同步算法的控制下,射频频率在约定的频率集内随伪随机码同步跳变的通信手段,对于频率跳变时的频域变化比较敏感,考虑到在非平稳信号处理过程中,标准傅里叶变换提取信号的频谱需要用到信号的全部时域信息,并且不能够反映出该信号的频率随时间状态的变化情况,Dennis Gabor 等人提出的短时傅里叶变换(Short-Time Fourier Transform, STFT)^[5]是把信号划分为多个小的时间间隔,在划分的每个时间间隔内用傅里叶变换进行分析。本文采用 STFT 作为预处理手段,将经过 STFT 的跳频信号频谱图作为 CNN 网络的输入数据。

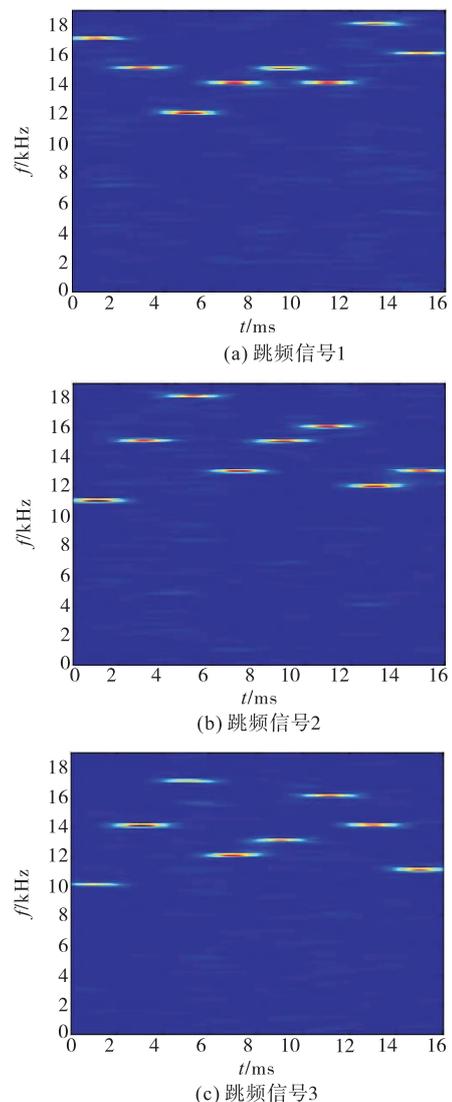


图1 经 STFT 处理 3 类跳频信号频谱图

短时傅里叶变换时通过滑动时间宽度很短的窗函数 $g(t)$,用短时傅里叶变化来分析每一个窗函数包括的信号,信号 $f(t)$ 的 STFT 定义为:

$$\text{STFT}_z(f, \tau) = \int_{-\infty}^{+\infty} [f(t)g(\tau - t)]e^{-j2\pi t} dt \quad (1)$$

反变换公式为:

$$f(t) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} [\text{STFT}(f, \tau)g(\tau - t)]e^{j2\pi t} df d\tau \quad (2)$$

其中窗函数 $g(t)$ 的选择不同也会带来一定的差异,但信号特性分析并不会随着窗函数的变化而产生显著的差异,本文采用汉明窗作为窗函数。

本文将实采的跳频信号作为训练数据,经过 STFT 变换后的跳频信号频谱图为 3 通道 $901 \times 1\ 201$ 、位深度为 8 的图片。图 1 为除跳频频集不同之外所有参数均相同的 3 类跳频信号频谱图,由图可知,其特征主要体现在跳频频点的不同,体现在频谱图上为亮点的位置差异。

为了方便将跳频信号频谱图作为 CNN 网络的输入,对信号频谱图进行处理,图片信息为数据 data,对应增加 0、1、2 作为标签 label,即数据集包含了数据 data 和标签 label 两大部分。将所有图片存储为数据格式为 uint8 的 $300 \times 3\ 246\ 303$ 维的数组,数组的每 1 行储存 1 幅 $901 \times 1\ 201 \times 3$ 的彩色图像,前 1 082 101 个条目包含红色通道的值,接下来的 1 082 101 是绿色通道,最后的是蓝色通道分别使用 0、1、2 作为 3 类跳频信号的标签。同时为了避免深度学习拟合能力过强,将数据输入顺序的规律作为数据识别的一个特征导致的训练效果特别好但

是测试效果一般,我们把标签和数据同步进行随机乱序处理。

2 基于 CNN 的跳频信号指纹特征提取

深度学习 (Deeplearning) 近年来在人脸识别^[6-10]、信号识别等多领域都得到了广泛的应用。CNN 网络^[6-10]多用于对图像进行分类,其分类识别率高,可将跳频信号个体识别问题转变为对经过 STFT 处理后的跳频信号频谱图分类的问题,实现调频信号个体识别。CNN 网络具有多隐藏层非线性的网络结构,使卷积神经网络具备非常好的拟合能力;多层隐藏层能够实现隐藏特征的提取;卷积核权值共享和滑动窗口降低了网络参数的数量;调整卷积核的大小和参数以及卷积核的个数可以实现输入跳频信号数据的深度特征提取。

2.1 基于 CNN 的跳频信号指纹特征提取网络构建

基于 keras 不需要写循环去更新每次的梯度所带来的搭建网络的便利,本文采用 keras 框架进行 CNN 网络的搭建。采用多层卷积结构对跳频信号频谱图进行频域指纹特征的提取,网络包含了 4 个卷积层 (Convolution Layer)、2 个池化层 (Pooling Layer) 和 2 个全连接层 (Full Connection Layer)。基于 CNN 网络的跳频信号频域指纹特征提取的网络结构见图 2。

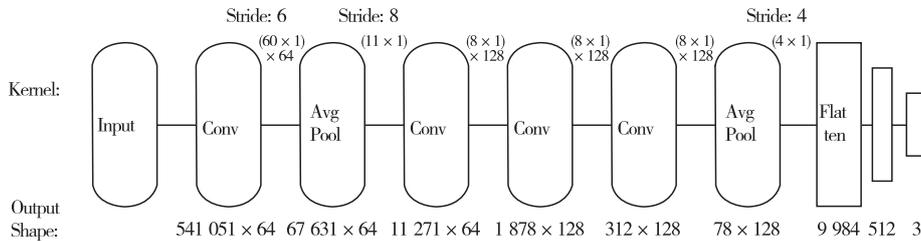


图 2 CNN 网络架构

输入层将经过 STFT 变换的跳频信号频谱图作为原始数据,输入到深度学习网络中,输入值是信号的频谱图则为像素值。卷积层通过卷积核进行特征提取,多层卷积是为了提取输入的深层次特征,同时也会使数据的维度增大。池化层具体操作和卷积层类似,主要用来降低数据的维度,本网络采用平均池化 (Average-Pooling) 进行池化操作,全连接层是将提取到的所有特征连接在一起,最终通过 Soft-max 函数实现分类送至输出层,输出层的神经元就是信号种类的数目。

CNN 网络模型部分参数见表 1 (除 Drop, BatchNormalization 等网络层)。

表 1 CNN 网络模型部分参数

Layer	Kernel	Stride	Output Shape
Input			(3 246 303, 1, 1)
Conv1	(60, 1) × 64	(6, 1)	(541 051, 1, 64)
Pool1	(11, 1)	(8, 1)	(67 631, 1, 64)
Conv2	(8, 1) × 128		(11 271, 1, 128)
Conv3	(8, 1) × 128		(1 878, 1, 128)
Conv4	(8, 1) × 128		(312, 1, 128)
Pool2	(4, 1)	(4, 1)	(78, 1, 128)
Flatten			(9 984)
Dense1			(512)
Dense2			(b, 3)

网络模型共有 5 446 083 个参数,可训练参数为 5 445 955 个,不可训练参数为 128 个,CNN 网络的损失函数为交叉熵(Cross Entropy Loss):

$$H(p, q) = - \sum_i p(i) \log q(i) = H(p) + D_{KL}(p | q) \quad (3)$$

式中: p 为实际值; q 为预测值; $D_{KL}(p | q)$ 表示 p 和 q 之间的距离,分类问题中数据转换为 one-hot encoding 格式,本文为 3 类跳频信号的分类问题,某信号实际值为 p ,其预测值为 q ,此时:

$$p = [0 \ 1 \ 0], q = [q_0 \ q_1 \ q_2] \quad (4)$$

$$H(p, q) = H(p) + D_{KL}(p | q) = (-1 \log 1) + (-1 \log q_1) = -1 \log q_1 \quad (5)$$

当 $p=q$ 时交叉熵最小为 0,预测值和实际值完全一样,正是我们所期望的结果,与均方误差(Mean Squared Error, MSE)作为损失函数时相比,在预测错误的情况下拥有更大的梯度,保证网络快速向着正确的方向更新,有效避免了梯度消失的情况。

2.2 激活函数

深度学习中的激活函数是一种非线性的函数,实现了神经元输入到输出的映射功能。如果不使用激活函数,无论神经网络包含了多少层,输出都是输入的线性组合,但是使用了激活函数之后,在神经元之间引入了非线性因素,神经网络可以逼近于任何非线性函数。常见的激活函数有以下几种: Sigmoid、Tanh、Relu、ELU^[11] 和 Softmax^[12]。

Sigmoid 函数的输入范围在 0 和 1 之间,函数简单,输出也趋于稳定,但是存在容易产生梯度消失和只有正数输出(不是 zero-centered,也就是所谓的 zigzag 现象)的弊端。Tanh 相比 Sigmoid 函数收敛速度更快,输入范围在 -1 和 1 之间,同时输出也是 zero-centered,但是还是没有解决 Sigmoid 函数的梯度消失问题。Relu 函数是一个被认为具有生物学意义的激活函数,当输入小于指定阈值时,输出为零,输入大于指定阈值时,输出等于输入,但是在负数区域会出现 Dead Relu。有些人用一个稍大于零的值进行初始化,但这种方式仍然存在争议。ELU 具有 Relu 的优势,同时也可以解决 Dead Relu。通过多次实验发现 ELU 作为激活函数时收敛速度最快,故本网络采用 ELU 作为主要的激活函数,定义式如下:

$$ELU(x) = \begin{cases} \alpha(e^x - 1), & x \leq 0 \\ x, & x > 0 \end{cases} \quad (6)$$

对应的函数图像见图 3。

Softmax 函数多用于多元信号分类问题,在给定的一个输出模型中取值 C 来表示算法所要预测

的样本类别数。模型可以是全连接神经网络的输出 a ,那么输出个数为 C ,具体输出为 a_1, a_2, \dots, a_C ,因此对每个样本来说,它属于类别 i 的概率为:

$$y_i = \frac{e^{a_i}}{\sum_{k=1}^C e^{a_k}} \quad \forall i \in 1, 2, \dots, C \quad (7)$$

Softmax 函数的输出值都在 0 和 1 之间,同时所有输出值之和为 1,可以把所有的输出看作输入的所有概率分布,通过最大概率来判断该信号的类别,进而达到信号分类的目的。

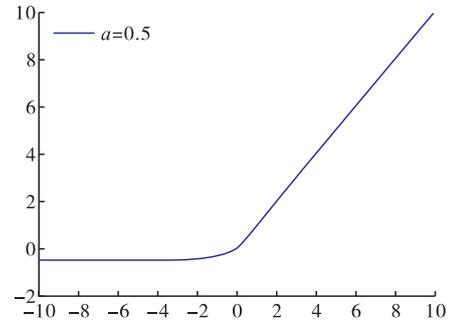


图 3 ELU 函数

2.3 加速网络收敛的改进

深度神经网络的收敛速度是很重要的一个指标,网络收敛越快,实现分类所用时间越短,对于所获得信号的时效性就越好,因此为了加快网络收敛速度,本文进行了以下改进。

白化(Whiten)是指将输入数据的分布变换到零均值单位方差的正态分布。在图像处理中对输入进行白化操作,则神经网络会较快收敛;图像是深度神经网络的输入,白化能加快收敛,那么对于深度神经网络来说,其每一个隐藏层的神经元相对于下一层而言也是输入层,Batch Normalization 就是对深层神经网络每个隐藏层神经元的激活值做简化版本的白化操作。

Batch Normalization 加快网络收敛速度的原理为:深层神经网络在做非线性变换前的激活输入值随着训练或网络深度加深,其分布逐渐发生偏移或者变动,往非线性函数的取值区间的上下限两端靠近,在非线性函数的上下限处其导数为零,导致反向传播时低层神经网络出现梯度消失。而 Batch Normalization 就是通过一定的规范化手段,把每层神经网络任意神经元的输入值分布强行拉回到均值为 0、方差为 1 的标准正态分布,使得非线性函数输入值落在对输入比较敏感的区域,此时梯度变大,学习收敛速度更快,大大加快训练速度。

2.4 防止网络过拟合的改进

神经网络在训练时会出现过拟合的情况,当网络的测试正确率达到 100% 时,因为网络还没有训

练结束,网络的参数量、模型复杂度会随着训练的进一步增加,出现拟合过度的情况,本网络通过调用 Callback 函数避免过拟合,包含两部分:Model-checkpoint 和 Earlystopping。

Modelcheckpoint 通过自动检测观测值,本网络为 val_acc,即验证集正确率,将自动存储验证集上性能最好的网络模型;Earlystopping 也是通过自动检测观测值测试正确率 val_acc,当正确率没有增加时,则经过 patience 个(本网络设置为 5)epoch 后停止训练,防止网络正确率不再提升,训练仍然进行,通过提前结束进程,防止过拟合和加快收敛速度。在每次训练进程中,通过 Callback 函数的 Modelcheckpoint 存储验证集上性能最佳的网络模型,通过 Callback 函数的 Earlystopping 在网络模型不再优化时提前结束训练,大大加快网络收敛速度的同时避免过拟合现象的发生。

3 实验分析

3.1 实验条件

本文实验硬件条件如下:64 位 Microsoft Windows 10 操作系统, Intel Core i7-7700HQ 处理器, NVIDIA GTX2080TI 11 G 显卡,仿真软件 Matlab R2014a、PyCharm Community Edition 2019. 2. 1、Python3. 7。

3.2 CNN 训练测试和分析

CNN 网络的输入样本数直接关系到网络是否可以提取到跳频信号的深层次指纹特征,训练样本数量过少显然不足以支撑实验,数量过多又会增加网络的负担,导致网络训练时间过长。本文共仿真 3 类跳频信号,分别得到其 STFT 处理后的频谱图。每类拥有 100 个数据,将 300 个数据分为 10 组,每组含有 30 个数据,此时每组数据的 3 类跳频信号不是平均分配的。一共进行 10 次训练,每次训练时分别选取编号为 1,2,⋯,10 的一组作为测试数据,剩余 9 组为训练数据。对样本进行多次训练,多次调整之后,最终设置 batch_size 为 64,每次对测试集 30 个数据进行测试^[13]。

3.2.1 CNN 网络进行个体识别的有效性分析

对仿真跳频信号(信噪比设置为 5dB)进行训练和测试得到混淆矩阵见表 2。

本文经过 CNN 网络对经过 STFT 变化的 3 类跳频信号识别正确率均达到了 96% 以上,平均识别

率为 96.34%,对同一组跳频信号进行基于 CMFS-MIC 特征选择的跳频电台个体识别方法^[14]平均识别正确率为 88.17%,进行模板匹配法的平均识别率为 86.0%,相比之下本文识别率更高。同时本文方法只需要对跳频信号进行 STFT 变换作为预处理,将频谱图直接输入到 CNN 网络中进行训练识别,效率也更高。

表 2 测试结果混淆矩阵

信号样本	样本个数	识别结果			识别正确率 (%)
		跳频信号 1	跳频信号 2	跳频信号 3	
跳频信号 1	95	92	2	1	96.84
跳频信号 2	101	3	97	1	96.03
跳频信号 3	104	2	2	100	96.15

3.2.2 信号信噪比对分类识别率的影响

实验仿真生成的 3 类跳频信号分别增加了高斯白噪声,仿真信噪比为 0、5、10、15、20 dB 进行了 5 次对比实验,发现本网络对信号识别率随信噪比的变化情况见图 4,其中网络识别率为 3 类信号的平均值。从图 4 分析可知,在信噪比达到某一阈值之前,网络识别率随着信噪比的增加有所提升;当信噪比超过阈值之后,噪声对于网络识别率影响不再变化,识别率趋于稳定。通过实验我们得出信噪比 $SNR \geq 10$ dB 时,其对网络影响达到最佳且不再变化,因此本文均采用 $SNR = 10$ dB 的跳频信号进行试验。

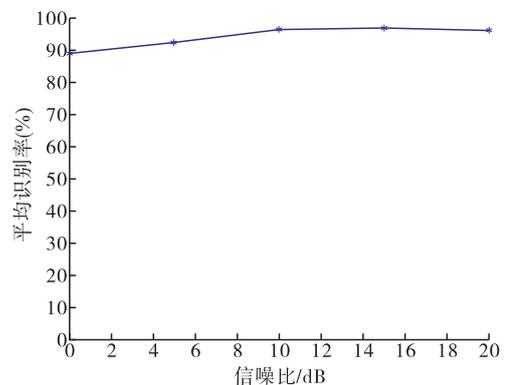


图 4 不同信噪比情况下网络识别率

3.2.3 网络训练迭代次数对识别率的影响

网络的训练迭代次数是算法快慢的一个重要参数,本文通过实验验证得到了最佳迭代次数。在网络其他参数固定的前提下,迭代次数分别设置为 10、50、100、150、200、300 对信噪比为 10 dB 的仿真信号进行识别,得到的 3 类信号平均识别率和模型训练时间见表 3。

表3 训练迭代次数对网络的影响

迭代次数	网络平均识别率(%)	网络训练时间/s
10	34.51	75
50	52.78	159
100	96.34	292
150	96.27	468
200	97.01	612
300	96.85	1 389

由表3可知,在迭代次数小于100时,随着迭代次数的增加,信号平均识别率显著增加,同时也付出了网络训练时间更长的代价,当迭代次数大于100时,随着迭代次数的增加,信号平均识别率在某一值附近震荡,不再明显提高,仍然要付出网络训练时间更长的代价。综合考虑信号平均识别率和网络训练时间,认为迭代训练次数为100时,网络已经达到了最优状态,训练时间较短且识别率较高,本网络采用100次作为最佳迭代次数。

4 结语

本文跳出了传统的跳频信号指纹特征提取方法,实现了一种基于CNN网络的跳频信号频域指纹特征提取和个体识别。实验表明有3类跳频信号的10次训练中,平均识别正确率相较于以往有所提高,同时对比研究了不同信噪比情况下的信号样本和不同网络训练迭代次数对于网络的影响情况。后续将针对基于CNN提取到的指纹特征存在特征之间的冗余性以及部分特征和类别之间相关性不够大的问题,实现一种基于LSTM网络^[15-16]的特征选择,来删除特征之间冗余性大的特征,选择特征与类别相关性的特征,实现更高的跳频信号识别正确率。

参考文献

- [1] 顾晨辉,王伦文.基于频域瞬时特征的跳频电台个体识别方法[J].计算机工程与应用,2013,49(22):223-226.
- [2] 顾晨辉,王伦文.基于瞬时包络特征的跳频电台个体识别方法[J].信号处理,2012,28(9):1335-1340.
- [3] 宋春云,徐建敏.基于混沌理论的跳频电台细微特征提取[J].通信对抗,2009(4):10-13,17.

- [4] 高乐乐,周强,王伟刚.基于CNN的深层次特征提取纸病辨识方法研究[J].中国造纸学报,2019,34(4):52-58.
- [5] 陆满君.通信辐射源个体识别与参数估计[D].哈尔滨:哈尔滨工程大学,2010.
- [6] ABU S, ANIRUDHA G, AVIJIT N, et al. BDNet: Bengali Handwritten Numeral Digit Recognition Based on Densely connected Convolutional Neural Networks [J]. Elsevier B V, 2020, 103:1-11.
- [7] KANDIL H, SOLIMAN A, TAHER F, et al. A Novel Computer-Aided Diagnosis System for the Early Detection of Hypertension Based on Cerebrovascular Alterations[J]. Neuro Image: Clinical, 2019, 25:102-107.
- [8] DEMIR F, SENGUR A, BAJAJ V. Convolutional Neural Networks Based Efficient Approach for Classification of Lung Diseases[J]. Health Information Science and Systems, 2020, 8(1):1-8.
- [9] YANN L C, YOSHUA B. Convolutional Networks for Images, Speech, and Time Series [M]// The Handbook of Brain Theory and Neural Networks. Massachusetts: MIT Press, 1998:3361.
- [10] 蒋仕宝,杜翠凤,聂丹彤.融合CNN与LSTM的网络质量KQI数据特征提取与投诉预警[J].移动通信,2020,44(2):69-75.
- [11] CLEVERT DÉ, UNTERTHINER T, HOCHREITER S. Fast and Accurate Deep Network Learning by Exponential Linear Units (ELUs)[J]. Computer Science, 2015:1-14.
- [12] JANG E, GU S, POOLE B. Categorical Reparameterization with Gumbel-Softmax[C]//ICLR, 2017:1-3.
- [13] 杨银松,郭英,李红光,等.基于CMFS-MIC特征选择的跳频电台个体识别方法[J].计算机应用研究,2019(12):1-7.
- [14] 杨安锋,赵知劲,陈颖.利用稀疏自编码器的调制样式识别算法[J].信号处理,2018,34(7):833-842.
- [15] GERS F A, SCHMIDHUBER J, CUMMINS F. Learning to Forget: Continual Prediction with LSTM [J]. Neural Computation, 2000, 12(10):2451-2471.
- [16] GREFF K, SRIVASTAVA R K, JAN Koutnik, et al. LSTM: A Search Space Odyssey[J]. IEEE Transactions on Neural Networks and Learning Systems, 2017, 28(10):2222-2232.

(编辑:徐敏)