

基于改进 VGG16 的超短波时频谱图分类方法

马博昂^{1,2}, 张海瑛¹

(1. 中国电子科技集团公司第 54 研究所, 石家庄 050081;
2. 河北省电磁频谱认知与管控重点实验室, 石家庄 050011)

摘要: 现代战场电磁环境日益复杂, 战术通信网台主要集中在超短波频段; 而未来的技术侦察对智能化、大数据处理的支撑需求越来越强烈; 为实现超短波盲信号的分类, 提出了一种将盲信号的时频谱图与优化后 VGG16 网络相结合的分类方法; 该方法首先将电磁战场中实际采集到的超短波盲信号转换为时频谱图, 然后通过迁移学习将其与优化后的 VGG16 卷积神经网络结合起来, 并将空洞卷积引入网络, 完成了对超短波盲信号的分类; 实验结果表明, 优化后的 VGG16 网络比原网络有更高的识别准确率, 达到了 93.1%; 当将空洞卷积引入到优化后的 VGG16 网络的第 7 层和第 10 层时, 识别率达到最高为 92.2%, 学习时间减少了 34.1%, 大大减少了模型的训练时长, 验证了空洞卷积在超短波盲信号分类识别上的有效性。

关键词: 超短波; 时频谱图; VGG16; 迁移学习; 空洞卷积

Classification Method of Ultrashortwave Time Spectrum Based on Improved VGG16

MA Boang^{1,2}, ZHANG Haiying¹

(1. 54th Research Institute of CETC, Shijiazhuang 050081, China;
2. Hebei Province Key Laboratory of Electromagnetic Spectrum Cognition and Control, Shijiazhuang 050011, China)

Abstract: The electromagnetic environment of modern battlefield is becoming more and more complex, and the tactical communication network stations mainly focus on the ultra-short wave frequency band. The future technical reconnaissance has an increasingly strong support demand for intelligent and big data processing. In order to realize the classification of ultra-short wave blind signals, a classification method combining the time spectrum of blind signals with the optimized VGG16 network is proposed. The method first converts the actual VHF blind signals collected in the electromagnetic battlefield into time-spectrum maps, then combines them with the optimized VGG16 convolutional neural network through transfer learning, and introduces the dilated convolution into the network to complete the classification of VHF blind signals. Experimental results show that the optimized VGG16 network has a higher accuracy of recognition than the original network, reaching 93.1%. When the cavity convolution is introduced into the 7th and 10th layers of the optimized VGG16 network, the recognition rate reaches the highest of 92.2%, and the learning time is reduced by 34.1%, which greatly reduces the training time of the model, and verifies the effectiveness of cavity convolution in VGG16 blind signal classification and recognition.

Keywords: ultrashort wave; time spectrum diagram; VGG16; transfer learning; dilated convolution

0 引言

现代战场电磁环境日益复杂, 战术通信网台主要集中在超短波频段, 常规信号、跳频、扩频信号普遍存在。我军需要针对目标区域进行例行性侦察监视, 重点对当面机场和空军基地进行侦察监视, 截获其电磁信号, 对重控信号进行通信组网特征提取和分析, 提升对作战目标的内涵情报获取以及信息作战支援能力。

超短波 (ultra-short wave) 是一种频率范围由 30 MHz 到 300 MHz 的无线电波, 其波长在 1 至 10 米之间, 也叫做

甚高频 (VHF, very high frequency)、米波。超短波宽带信号侦察包括信号搜索、跳频信号检测、超短波频段信号的采集、分选、检测以及信号分析等技术。传统的超短波信号分类已知信号的相关先验信息, 多以告知侦察对象及任务范围为主。针对超短波频谱资源的利用问题, 文献 [1] 将采集到的信号进行时、频域特征分析, 通过对获取的宽带信号进行时频分析, 并采用相关匹配的算法, 实现了在复杂电磁环境下对截获的宽带信号的检测和自动分选。文献 [2] 提出了一种利用峰度和小波变换对超短波信号进

收稿日期: 2022-11-04; 修回日期: 2022-11-08。

基金项目: 国家自然科学基金项目 (U20B2071)。

作者简介: 马博昂 (1997-), 男, 河北石家庄人, 硕士研究生, 主要从事技术侦察、信号与信息处理方向的研究。

通讯作者: 张海瑛 (1973-), 女, 河北石家庄人, 博士, 正高级工程师, 主要从事通信侦察和情报处理方向的研究。

引用格式: 马博昂, 张海瑛. 基于改进 VGG16 的超短波时频谱图分类方法[J]. 计算机测量与控制, 2022, 30(12): 211-217.

行分类识别方法。该方法通过决策树的分类方法,完成了 FM、MSK、QPSK 等三类不同调制方式的信号的识别。文献 [3] 针对不同频段的超短波通信信号调制识别的问题,提出决策树分类的方法。利用瞬时幅度、瞬时相位以及构造的瞬时特征实现了十种调制信号有效的识别。

但此类方法都是对特定目标信号进行仿真,诸如信号类型、调制方式、符号速率等,已有较多的先验信息。现行的超短波通信侦察系统中战场测量较为宏观粗放,侦控细节都是由执行者依据对象、任务以及工作惯性,理解性地在工作过程中落实传承。如今,在基于元数据协同的侦察活动中,大量的元数据活跃在每一个信号感知的细节里,如何应对战场环境下各类目标信号测量特征的精确获取需求,设计与之匹配的元数据测量特征,精细化地描述战场测量特征情报,设计完备简约的侦察策略是现代技侦工作的必然要求。未来的技术侦察情报生产,对智能化、大数据信息处理的需求越来越强烈,依托智能化技术的发展,提升情报生产能力,已成为技侦发展的必由之路。

近几年里,深度学习在图像识别领域取得了巨大的成果。文献 [4] 利用最新的人工智能框架 pytorch 以及算力强大的 GPU,对动物的图像进行分类识别。虽然在图像的预处理以及代码迁移问题上需进一步优化和改进。但也证明了 VGG16 网络模型识别准确率非常高,验证了 VGG16 在图像识别问题上的有效性。文献 [5] 提出了一种基于改进 VGG16 和迁移学习的图像分类方法。通过迁移学习传统 VGG16 模型并进行了改进,该方法能将已学习到的特征和性能用到待解决的任务中,极大地节省了训练时间。该方法针对选定的数据集,分别对激活函数、损失函数、优化器进行调整,最终完成了对十种不同猴子图像的识别。但其在细粒度图像的识别上还需对模型进行完善,且当迁移学习到超短波盲信号的时频谱图时需要进一步优化。文献 [6] 在超短波通信中 Link11、Link4A、DQPSK、SOQPSK 信号的识别问题上,将超短波信号的时频谱图和卷积神经网络相结合。该方法需要先得到信号的时频谱图,然后使用得到的信号时频谱图对优化后的卷积神经网络模型进行训练,最后实现了超短波特定信号的识别。对于时频谱图的变换有时域分析法^[7]。时域分析法是把信号按照时间序列划分为许多子序列,分别分析其时域特性。快速傅里叶变换^[8] (FFT, fast fourier transform) 在复杂度上虽有所降低,但仅适用于平稳信号,对非平稳信号和跳变信号不再适用。此外还有短时傅里叶变换 (STFT, short-time fourier transform)、小波变换^[9] (WT, wavelet transform) 和 S 变换^[10]。本文选定 STFT 进行超短波盲信号时频谱图的获取。是因为 STFT 常用于缓慢时变信号的频谱分析,符合超短波盲信号的特征。此外,经 STFT 处理后的信号具有时域和频域的局部化特性,可以借助其分析信号的时频特性。先验信息不足,信号特征缺失,难以满足对作战目标的内涵情报获取需要是当下电磁作战面临的重大问题。且当前对超短波盲信号的研究主要在盲信号的分离

方法^[11]及准则的优化上^[12],因此实现盲信号的智能化分类对于电磁环境日益复杂现代战场具有重要意义。

随着深度学习在图像分类识别领域的飞速进步,运用卷积神经网络对图像分类相较于传统的图像处理方法更加高效与方便。研究人员们针对图像分类等问题提出了很多特征维度提取更深的神经网络模型。模型复杂的神经网络虽然会有较高的准确率,但是会出现过拟合的问题,具有效率不高、训练时间长等不可忽视的短板。因此轻量化卷积神经网络的研究具有深远的意义和影响。文献 [13] 提出轻量化卷积神经网络,在保证准确率的同时能够提高图像分类的效率,降低参数量,并且可以用于小型终端设备中。文献 [14] 将优化后的空洞卷积与普通卷积相结合,提出一种将融合型空洞卷积引入神经网络中的方法。该方法利用空洞卷积可以增大特征映射与扩大感受野的结构特性,可实现模型计算复杂度的降低,实现了对训练效率与准确率的权衡。但由于迁移学习到新的网络,将基本空洞卷积直接应用于超短波盲信号时频谱图的分类,虽准确率会有所降低,但是整体上来看仍具有轻量化效果好的特点,可以解决超短波盲信号时频谱图学习过程时间过长的问题。

基于以上,本文提出了一种将超短波盲信号的时频谱图与 VGG16 相结合的识别方法,并通过引入空洞卷积减少网络的训练时长。该方法首先用 STFT 将电磁战场中实际采集到的盲信号转换为时频谱图,然后将其与优化的 VGG16 卷积神经网络结合起来。通过仿真实现了在先验信息不足条件下超短波信号的分类。将空洞卷积引入优化后的网络,在保证较高分类准确率的条件下,最大程度的减少了训练时长,验证了空洞卷积在盲信号分类上的实用性,增强电磁战场作战目标的内涵情报获取以及信息作战支援能力。

1 时频谱图提取

本文对超短波盲信号的时频谱图通过 STFT^[15] 方法得到。STFT 常用于缓慢时变信号的频谱分析,与超短波盲信号的特征相匹配,如图 1 所示,不同信号的时频谱图存在明显差异。且经 STFT 处理后的超短波盲信号的时频谱图具有时频域的双重特征,可以作为深度学习的输入。

STFT 本质上是对超短波盲信号时域上的局部处理,在信号进行傅里叶变换 (FFT, fourier transform) 之前,对信号乘以一个时间极短的窗函数,用窗函数截取信号,原本非平稳的信号就可以采用平稳信号的手段进行分析。最后将时间窗口滑动,各个窗函数信号的频谱组合就是整个超短波盲信号的时频谱图。

STFT 的定义为:

$$STFT(t) = \int_{-\infty}^{\infty} s(u)g^*(u-t)e^{-j2\pi fu} du \quad (1)$$

其功率谱为:

$$SPEC(t, f) = |STFT(t, f)|^2 \quad (2)$$

对于 STFT 窗函数的选择,设窗函数 $g(t)$ 的有效时




图 1 两种信号的短时傅立叶变换谱图对比

宽为 Δt , 带宽为 Δf , 则它们二者的乘积服从 Heisenberg 不等式^[16]:

$$\Delta t \cdot \Delta f \geq \frac{1}{2} \quad (3)$$

从上式可以看出, 需要根据需求权衡窗函数的有效时宽 Δt 和带宽 Δf 的数值。为了局部频谱清晰可辨, 窗的长度应该足够宽。

STFT 最重要的还是窗口函数长度的选取。窗口较长, 频域刻度和平移步长足够密时, 频率能够清晰的显示出来, 但是时间上有些模糊。窗口较短, 时间上的分界线能够清晰显示, 但是频率的值会很模糊。

选择合适的窗函数及长度, 是影响后续深度学习准确率的关键。针对本文选定的超短波盲信号, 最终进行的 STFT 变换参数如表 1 所示。

表 1 变换参数

STFT 参数	
FFT 运算点数	512
FFT 滑动点数	50%
FFT 加窗类型	Hamming

2 空洞卷积

空洞卷积核^[17]是由 Yu 等人进行系统研究的。从特征提取的原理上来看, 空洞卷积与传统卷积核的结构相似。但是通过添加空洞元素, 实现了输入层和输出层特征映射的扩张。空洞卷积的引入可以大大减少卷积网络的训练时长。部分学者已经将空洞卷积应用在目标检测与语义分割中的空洞卷积池化金字塔^[18]、ESPNet^[19]等多个领域中。

空洞卷积可以认为是基于卷积操作的一种变形, 空洞卷积在卷积核中添加空洞元素, 增大感受野, 实现了获取更多的信息的目的。感受野是输入层到输出层的特征映射, 决定着输出层中元素对应的输入层的区域大小。在图像分类和目标识别上, 感受野的选择直接影响任务效果。

感受野的计算公式如下:

$$sp_n = sp_{n-1} + (k_n - 1) \times \prod_{i=1}^{n-1} r_i \quad (4)$$

sp_n 代表第 n 层的感受野, sp_{n-1} 表示第 $n-1$ 层的感受野, k_n 是第 n 层卷积核的尺寸, r_i 表示 n 层前第 i 层卷积的步长。

如图 2 所示, 图像的像素为 25, 以 5×5 卷积核对一个 5×5 的图像进行一次卷积操作。输入层经过卷积操作后, 得到 1×1 的输出, 即输出层对应的整个特征映射为输

入层。




图 2 普通 5×5 卷积核一次卷积过程

如图 3 所示，步长为 1 的 3×3 的空洞卷积与普通 5×5 卷积核的感受野相同。只不过在卷积元素之间添加了一个空洞，可以理解为在此位置的特征值与 0 相乘。该空洞卷积对一个输入图像进行一次卷积操作，同样得到了与普通卷积后相同大小的结果。




图 3 步长为 1 的 3×3 卷积核一次卷积过程

由于增加了空洞元素，空洞卷积利用较小的参数量实现较大的感受野，在神经网络的训练过程中可以减少参数量，减少训练时长，提升模型的训练效率。

2.1 盲信号的选取

当前对超短波盲信号的研究主要在盲信号的分离方法及准则的优化上。本文选则超短波盲信号分类识别是为了减少信号的先验信息，在不知道信号调制方式、符号速率参数的情况下，仅根据输入信号的特性，通过时频谱图实现盲信号的分类，可以增加网络的鲁棒性和应用价值。

本文首先对已采集到的宽带信号进行离线分析得到瀑布图，然后对信号进行短时傅立叶变换得到对应的时频谱图，由于盲信号的频谱样本的选取需要满足一定的视觉差异，同时需要满足细粒度图像^[20]的要求。基于此本文选择以下四种盲信号作为分类数据集。

由图 4 可以看出，信号 (a) 的谱图呈双带宽形式，信号 (b) 的谱图具有突发的特点，信号 (c) 和信号 (d) 的谱图呈现包络差异明显的锯齿状。

四种盲信号的中心频率及带宽如表 2 所示。

2.2 数据集的预处理

数据增强^[21] (data augmentation) 技术通常用于深度学习中。在图像识别领域，在不改变图像标签的情况




图 4 特定信号的谱图

表 2 四种盲信号的频率参数

	中心频率	带宽
a	11 626 439	93 770
b	18 154 108	27 478
c	14 358 275	49 811
d	13 929 625	91 305

下，通过对图像进行不同的变换操作，达到扩充原来的数据集的目的。而且卷积神经网络具有尺度、平移不变性，成为图像数据增强的理论支撑。常见的数据增强方法有旋转、翻转、缩放等^[22]。即这些变换经过卷积操作也不会改变图像的分类特征。

本文针对盲信号的特点，对输入的时频谱图进行平移变换、缩减和中心裁剪处理。读取图像时，首先把图像的短边分辨率裁剪为 256。然后对图像进行中心切割，得到大小为分辨率为 224 × 224 的图像。再将形状为 [H, W, C] 的数据转换为 [C, H, W] 的张量后，然后对图像进行归一化处理，每类盲信号有 2 000 个时频谱图用来作为后续网络的输入。

3 迁移学习卷积网络模型

3.1 VGG16 模型

VGG16 卷积神经网络通过组合与堆叠多个 3 × 3 卷积核，可以提取输入邻域内更多细小的特征。通过构建和组合多个 3 × 3 卷积核：2 个 3 × 3 卷积核可代替 5 × 5 卷积核，3 个 3 × 3 卷积核可代替 7 × 7 卷积核。多个小尺寸卷积核的组合比单个大的卷积核具有更好的非线性，增加了网络的鲁棒性和判决力。

VGG16 卷积神经网络通过卷积核对输入的图像进行卷积操作，最大池化进行图像降维，提取主要特征，全连接层进一步降低参数量并与分类器 softmax 配合达到分类的目的。并且利用小尺寸卷积核代替大尺寸的卷积核，可以大幅减少由于深度增加所带来的参数量。




图 5 处理后训练 batch 的图像

3.2 损失函数的改进

损失函数 (loss) 用来表征实际值与预期值之间的偏移, 损失函数越小代表模型的置信度越强。分类识别中常用 softmax 函数将多个神经元的输出进行标准化, 通过归一化指数函数, 可以使每一个元素的范围映射到 $0 \sim 1$ 之间, 大大减少因为输出结果不均匀引起的误差。若卷积神经网络的输出为 x_i , 经过 softmax 处理后变为:

$$\text{softmax}(x_i) = \frac{e^{x_i}}{\sum_{j=1}^n e^{x_j}} \quad (7)$$

采用 softmax 函数在于此函数特性的优势, 可以高效完成类间的信号识别, 但是应用在盲信号的时频谱图识别问题上时, 由于类内的间距还是比较大, 识别任务会出现准确率降低的情况。因此为了缩小类内间的残差, 引入了中心损失函数 (center loss)。中心损失函数的意义是在完成分类任务时, 对于每一类特征都维持在一个中心点, 即该类所有样本的特征平均值, 当输入层的数据过于偏离平均值就要剔除或者取舍, 从而更接近类内的特性表征。并且如果只替换为 center loss 函数, 效果并不是很好, 无法有效类间的特性有效区分。

Center loss 的定义:

$$\text{Center loss} = 1/2N \sum_{i=1}^m \|x_i - c_y\|_2^2 \quad (8)$$

令 $\text{Center loss} = L_c$ 。

Softmax loss 的定义:

$$L_s = - \sum_{i=1}^m \log(e^{w_s^T x_i + b_s} / \sum_{j=1}^n e^{w_j^T x_i + b_j}) \quad (9)$$

其中: c_y 代表每类样本特征的平均值。将式 (8) ~ (9) 结合得到损失函数为:

$$L = L_s + \lambda L_c = - \sum_{i=1}^m \log(e^{w_s^T x_i + b_s} / \sum_{j=1}^n e^{w_j^T x_i + b_j}) + \lambda L_c \quad (10)$$

而采用将以上两种损失函数相结合的办法, 优势相结合能够有效完成盲信号的分类任务。将 softmax loss 与 center loss 相结合的方法增加损失函数的价值, 从而提升分类

任务的识别准确率。

3.3 Swish 激活函数

在深度学习中输入与输出的关系复杂, 用普通的线性函数无法表征学习到的特征, 在学习的过程中会出现梯度消失的问题, 因此激活层用来引入非线性因素从而提高整个模型的表征能力。

ReLU 函数的定义为:

$$f(x) = \max(0, x) \quad (11)$$

尽管 ReLU 仅在取值为正数时传输, 具有单调、分散性等优点。但仍存在不足: 当取值大于 0 时, 输出可能会无限大, 出现梯度爆炸的问题。

Swish^[23] 函数则解决了这一缺陷, 并且它非饱和、且不是单调函数。适用于神经网络学习, 且在多个数据集上使用 Swish 激活函数时, 识别率均较高。

Swish 的定义为:

$$f(x) = x \times \frac{1}{1 + e^{-\beta x}} \quad (12)$$

将 VGG13、VGG16 和 AleNet 模型分别在手写数据集上进行学习。学习结果如表 3, 证明了 Swish 函数具有更大优势。因此, 在针对超短波盲信的识别问题上, 将原网络的激活函数替换为 Swish 函数。

表 3 Swish 与 ReLU 在不同的模型结构学习结果 %

网络模型	ReLU	Swish
VGG13	96.58	97.16
VGG16	98.44	98.83
AleNet	93.31	94.45

4 深度学习结果及分析

4.1 VGG16 优化模型的盲信号分类

本文模型的训练是在 pycharm 平台下, 调用 pytorch 深度学习库来完成的。对 VGG16 原模型进行了如下调整: 激活函数改为 Swish 激活函数, 损失函数改为 softmax loss 与 center loss 结合的复合函数。优化后的模型用 VGG16_U 表示。采用前向传播算法, 学习率为 0.03, 每类盲信号的时频谱图有 2 000 个, 四类盲信号共有 8 000 个样本, 训练的 batch 为 64。分别将四种盲信号的时频谱图送入网络进行分类学习。图像在 VGG16 原模型与 VGG16_U 模型上的训练结果如图 6 所示。

由结果可以看出, 当训练轮数达到 10 轮时, 网络模型和准确率已经基本稳定。VGG16_U 的识别准确率比原模型有明显提高, 且 VGG16_U 最高识别率为 93.1%, 说明迁移学习后的卷积神经网络对盲信号分类识别的有效性。

4.2 引入空洞卷积的网络模型

为验证空洞卷积核对 VGG16_U 模型性能的影响, 训练集选取的盲信号的时谱图保持不变, 网络学习率调整为 0.001, 训练的 epoch 为 10, 对 VGG16_U 模型中的卷积层调整为步幅为 2 的 3×3 空洞卷积层。VGG16_U 网络的第 4 层, 第 7 层, 第 10 层均为卷积层, 分别将不同层数的卷




图 6 训练结果

积层替换进行了测试，得到八组训练结果。

表 4 训练的参数配置

组号	改变的层数	空洞卷积核数
1	VGG16_U 原网络	0
2	第 4 层	1
3	第 7 层	1
4	第 10 层	1
5	第 4 层+第 7 层	2
6	第 4 层+第 10 层	2
7	第 7 层+第 10 层	2
8	第 4、7、10 层	3

训练结果如图 7 所示，由图中的折线可知，引入空洞卷积会大大减小模型的训练时长，训练时长与空洞卷积核的数量无关而与空洞卷积核的数量呈正相关：卷积核的数量越多，模型的训练时间越短。同时，识别准确率与空洞卷积的位置和数量均有关，且引入空洞卷积，整体的识别率皆有所降低。




图 7 引入空洞卷积后的模型对比

VGG16_U 未引入空洞卷积时训练时间为 58 分 33 秒，识别准确率为 93.1%。经过分析，当将 VGG16_U 的第 4 层和第 10 层的卷积核同时替换成空洞卷积时，此时的识别准确率为 92.2%，虽比无空洞卷积时有所降低，但仍维持在较高的水平，且训练时长为 38 分 35 秒，训练时长减少了 34.1%，大大降低了训练时长，证明了空洞卷积在模型识别上的有效性，提升对作战目标的内涵情报获取以及信息作战支援能力。

5 结束语

在电磁战场目标识别问题上，以往的仿真都是针对特定的目标信号，诸如信号类型、调制方式等，已有较多的先验信息。当先验信息不足时，信号特征缺失，难以满足对作战目标的内涵情报获取需要，因此，对盲信号的分类识别具有突出意义。

在人工智能领域，对于不同的目标任务通常需要重新构造网络，并采用新的源数据重新学习调整权重参数，任务工作量高且耗时较长。而迁移学习可以将原任务中所学到的知识运用到新任务中，对网络进行调整从而构造出鲁棒性更好的模型。不但降低了训练时长，基于以前的参数信息也可以完成更优化的识别任务。空洞卷积核具有增大输入层和输出层的特征映射特性，可以大大减少网络参数的数量。在保证较高的识别准确率的条件下，最大程度减少任务时长，在电磁环境日益复杂的战场中的高效率完成任务有重要的意义。下一步的工作可以继续增加超短波盲信号的种类、增大数据量。优化空洞卷积核与网络模型，进一步提高识别率并降低训练时长。

参考文献：

- [1] 秦强. 超短波信号的频谱监测与信号源定位 [J]. 通讯世界, 2016 (3): 13-14.
- [2] 谢跃辉, 张一闻, 赵亚欣, 等. 基于峰度和小波变换的超短波信号调制识别 [J]. 现代电子技术, 2016, 39 (23): 9-12.
- [3] 罗今梅, 刘海家, 李智. 基于 FPGA 的超短波信号调制识别算法研究 [J]. 现代计算机, 2021, 27 (33): 54-56, 76.
- [4] 王彬, 张正平, 贾明俊, 等. 基于卷积神经网络 VGG 的猫狗识别 [J]. 智能计算机与应用, 2021, 11 (7): 162-165.
- [5] 田佳鹭, 邓立国. 基于改进 VGG16 的猴子图像分类 [J]. 信息技术与网络安全, 2020, 39 (5): 6-11.
- [6] 杨司韩, 彭华, 许漫坤, 等. 基于卷积神经网络的超短波特定信号谱图识别 [J]. 系统工程与电子技术, 2019, 41 (4): 744-751.
- [7] 何卫国, 饶金涛, 李军, 等. 一种基于短时域分析的侧信道信号预处理方法 [J]. 通信技术, 2020, 53 (6): 1495-1498.
- [8] 周秀珍, 肖雷. 基于快速傅里叶变换的实时频谱分析方法研究 [J]. 信息通信, 2018 (8): 21-22.
- [9] 王佰辉. 基于小波变换的图像去噪与边缘检测算法研究与应用 [D]. 成都: 西南交通大学, 2019.
- [10] 许旭. 基于同步挤压 S 变换和深度残差网络的压裂车压裂

泵故障诊断 [D]. 北京: 北京建筑大学, 2020.

- [11] 李小军, 朱孝龙, 张贤达. 盲信号分离研究分类与展望 [J]. 西安电子科技大学学报, 2004 (3): 399-404.
- [12] 朱 茉, 季 策, 于 洋. 盲信号分离问题的分类和现状 [J]. 化工自动化及仪表, 2009, 36 (3): 7-11.
- [13] 孙若帆. 基于轻量化卷积神经网络的图像分类研究 [D]. 贵州: 贵州大学, 2020.
- [14] 马 利, 刘新宇, 李皓宇, 等. 应用空洞卷积的神经网络轻量化方法 [J]. 计算机工程与应用, 2022, 58 (5): 85-93.
- [15] 崔光辉. 基于时频分析的信号检测与参数估计方法研究 [D]. 哈尔滨: 哈尔滨工程大学, 2015.
- [16] 韩芳明. 无线数字通信: 一种时频观点 [D]. 西安: 西安电子科技大学, 2006.
- [17] YU F, KOLTUN V. Multi-scale context aggregation by dilated convolutions [C] //4th International Conference on Learning Representations, San Juan, Puerto Rico, May2-4, 2016.
- [18] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. Deep-

Lab: semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs [J]. IEEE Trans Pattern Anal Mach Intell, 2018, 40 (4): 834-848.

- [19] MEHTA S, RASTEGARI M, CASPI A et al. ESPNet: efficient spatial pyramid of dilated convolutions for semantic segmentation [C] //15th European Conference on Computer Vision, Munich Germany, September 8-14, 2018: 561-580.
- [20] 王佳浩. 基于深度学习的小样本图像分类算法研究 [D]. 西安: 西安电子科技大学, 2021.
- [21] 张晓峰. 深度对抗式数据增强技在小规模数据集上的应用研究 [D]. 合肥: 中国科学技术大学, 2019.
- [22] 葛 芸. 基于 CNN 迁移特征融合与池化的高分辨率遥感图像检索研究 [D]. 南昌: 南昌大学, 2019.
- [23] 米 硕, 田丰收, 孙瑞彬, 等. Swish 激活函数在中小规模数据集上的性能表现 [J]. 科技创新与应用, 2018 (1): 4-5.

(上接第 179 页)

1) 设计出多协议通信网关, 实现 RS-485 接口设备、CAN 接口设备和总线接口设备的之间的数据传输, 控制器和收发器具有冗余双线机制, 收发模块具有 RS-485 收发器和 CAN 收发器, 完成控制单元与外界网络的通信。

2) 提出基于队的 MAC 协议的传输机制, 在高负载的情况下能够有效缓解数据的冲突, 路由节点进行动态时隙分配, 根据数据节点发送的数据包更新序号列表和时隙分配列表。

在智慧楼宇的实际应用中, 实际的数据与仿真数据肯定会存在一定的差距, 以后研究中需要根据实际情况设计出更合理的数据传输机制, 考虑数据节点规模较大的应用场景。

参考文献:

- [1] 余苏敏, 杜 洋, 史一炜, 等. 考虑 V2B 智慧充电桩群的低碳楼宇优化调度 [J]. 电力自动化设备, 2021, 41 (9): 95-101.
- [2] 夏 林. 楼宇照明控制系统智能化应用探索 [J]. 建筑电气, 2021, 40 (5): 32-34.
- [3] 程王峰, 王枫宁. 电力信息与通信的技术融合分析 [J]. 电子技术, 2021, 50 (12): 216-217.
- [4] 杨本胜. 基于 GA-SVM 算法的通信网络入侵信号自动识别技术 [J]. 机械与电子, 2021, 39 (12): 25-29.
- [5] 蒋 炜, 李艳波, 张 慧, 等. 建设工程现场信息网络传输关键技术研究 [J]. 电力信息与通信技术, 2021, 19 (12): 88-94.
- [6] 王玉福, 陈子春, 侯占友, 等. 开滦集团智慧调度通信系统建设研究 [J]. 能源技术与管理, 2021, 46 (6): 189-191.
- [7] 陈李彬. OTN 技术在电力通信系统中的应用分析 [J]. 技术与市场, 2021, 28 (12): 127, 129.
- [8] 贾敬敦, 鲁相洁, 黄 峰, 等. 远程控制与无线通信技术在农

业中的应用分析与展望 [J]. 农业机械学报, 2021, 52 (S1): 351-359.

- [9] 张彦芝. 无线通信技术在智能化污水处理系统中的应用与评估 [J]. 江苏科技信息, 2021, 38 (35): 41-43.
- [10] 崔 琳, 朱 磊, 刘小龙, 等. 基于 STM32F407 的以太网通信模块设计 [J]. 计算机测量与控制, 2018, 26 (1): 260-263.
- [11] 牛 雨. 基于 JAVA 的太阳能热水工程现场监控系统的设计 [J]. 计算机测量与控制, 2018, 26 (2): 85-88.
- [12] 王祖武, 丁 健, 魏文力, 等. 基于无人机双目图像的线目标测量的研究 [J]. 计算机测量与控制, 2020, 28 (1): 61-65, 104.
- [13] 周 盈, 童斐斐, 刘 思. 环境保护视角下电力通信在电网智能化中的支撑作用 [J]. 能源与环保, 2021, 43 (11): 51-57, 63.
- [14] 冯 宝, 刘金锁, 牟霄寒, 等. 星地一体电力量子保密通信关键技术研究及应用 [J]. 电力信息与通信技术, 2021, 19 (11): 1-8.
- [15] 郑佳品, 高荣荣. 基于 NDK 的 DSP 网络通信技术研究 [J]. 电子工业专用设备, 2021, 50 (5): 42-45.
- [16] HU S, CHEN X, NI W, et al. Distributed machine learning for wireless communication networks: techniques, architectures, and applications [J]. IEEE Communications Surveys & Tutorials, 2021 (99): 1.
- [17] SI Y, KORADA N, AVVANAR R, et al. A high performance communication architecture for a smart micro-grid testbed using customized edge intelligent devices (EIDs) with SPI and modbus TCP/IP communication protocols [J]. IEEE Open Journal of Power Electronics, 2021 (99): 1-18.
- [18] HSU C H, AMILINENI K, WU H, et al. A novel scalable network architecture for the evolution of robot swarm networks with dual connectivity application in control-data plane [J]. Swarm and Evolutionary Computation, 2021, 64 (5): 100889.