

doi: 10.7690/bgzdh.2023.10.005

基于改进残差网络的高光谱图像分类算法研究

易 琰, 张宇航, 王 清, 宗艳桃

(中国人民解放军陆军装甲兵学院兵器与控制系, 北京 100071)

摘要: 针对高光谱图像在训练样本较少时无法构建有效的深度学习分类模型的问题, 对传统的残差块(residual block)模型进行改进, 提出一种“金字塔”残差块分类算法。设计一种包含数十个卷积层的深度学习网络, 与传统残差模型相比大大减少了参数量, 且可以充分提取高光谱图像的深层空间-光谱特征; 在 2 种开源数据集 Indian Pines 和 University of Pavia 上进行实验, 同时选取了 3 种经典的分类方法作为对比。实验结果表明: 该算法表现效果最佳, 可以有效提高高光谱图像的分类精度。

关键词: 深度学习; 高光谱图像; 卷积神经网络; 图像处理

中图分类号: TP391.41 **文献标志码:** A

Research on Hyperspectral Image Classification Algorithm Based on Improved Residual Network

Yi Quan, Zhang Yuhang, Wang Qing, Zong Yantao

(Department of Weaponry and Control, Army Academy of Armed Forces, Beijing 100071, China)

Abstract: Aiming at the problem that it is impossible to construct an effective deep learning classification model for hyperspectral images when there are few training samples, a “pyramid” residual block classification algorithm is proposed by improving the traditional residual block model. A deep learning network containing dozens of convolution layers is designed, which greatly reduces the number of parameters compared with the traditional residual model, and can fully extract the deep spatial-spectral features of hyperspectral images; Experiments are carried out on two open source datasets Indian Pines and University of Pavia, and three classical classification methods are selected for comparison. The experimental results show that the algorithm has the best performance and can effectively improve the classification accuracy of hyperspectral images.

Keywords: deep learning; hyperspectral image; convolutional neural network; image processing

0 引言

高光谱遥感图像由于其图谱合一、光谱分辨率高、波段范围广等特点, 可以实现复杂场景下对地面物体的精准识别。在一定范围的地面区域内, 高光谱遥感图像可以提供物体从可见光到近红外波段内上百个光谱波段的光谱信息, 使得在可见光遥感图像和多光谱遥感图像技术中无法有效识别的地物, 能在高光谱遥感中得以探测。目前, 高光谱遥感技术已经成为一种重要的军事应用手段, 在战场环境侦察^[1]、军事目标检测^[2]、伪装识别^[3]等方面均有广泛应用。

高光谱图像分类技术利用图像中丰富的光谱和空间信息实现对像元类别的划分, 是高光谱图像研究的重要分支。传统的分类方法通常是通过提取高光谱数据中浅层的人工特征实现的, 这种浅层人工特征的设计不仅需要丰富的专家经验, 而且人工特征在复杂场景下难以保证算法的泛化性^[4]。近年来,

卷积神经网络(convolutional neural network, CNN)作为计算机视觉中特征提取能力最好的网络, 也被应用于高光谱图像分类。CNN 使得计算机可以通过深度网络自主提取的深层特征实现高光谱图像分类。在提取特征的过程中不需要人工干预, 而且得到的特征有很强的泛化性和鲁棒性, 适合于各种复杂场景的高光谱图像地物分类。文献[5-7]展现了 CNN 用于高光谱图像分类取得的成果, 但 CNN 是一种基于数据驱动模型, 模型深度与训练样本需求成正比, 越深的模型训练起来需要的样本就越多。由于高光谱图像数据标注困难、可用样本少等问题限制了 CNN 网络的深度, 而浅层网络无法得到更加有效的深层光谱-空间特征。

基于以上问题, 笔者提出一种基于改进残差网络的高光谱图像分类网络, 利用光谱和空间信息实现了快速、准确的高光谱图像分析和分类。在 CNN 网络中引入残差块可有效克服模型过深而导致过拟合的问题, 而笔者对传统 residual block 改进, 引入

收稿日期: 2023-06-21; 修回日期: 2023-07-22

作者简介: 易 琰(1967—), 男, 陕西人, 博士。

1×1 CNN 构成“瓶颈层”，实现对输入特征的降维与升维的同时减少参数量，分批归一化 (batch normalization, BN) 也被置于所有卷积层之后以加快模型收敛。相对于其他 2D/3D-CNN 模型，笔者所提网络涉及的参数更少，但可获得更高的分类精度。在 2 个开源的高光谱数据集上进行了实验验证，与其他几种分类算法相比，分类效果最好。

1 研究方法

1.1 residual block 介绍

在计算机视觉领域用于图像分类的主要模型是 CNN，利用小尺寸卷积核在整个图像上以滑窗的方式提取局部特征，并通过激活函数对特征进行非线性映射。由于 CNN 这种“局部感知”和“权值共享”的特点，通过多层 CNN 的叠加，可以用较少的模型参数提取提取图像中深层次的抽象语义特征。2 维 CNN 的计算公式如下：

$$\text{map}_{i,j}^{x,y} = f \left(\sum_m \sum_{h=0}^{H_l-1} \sum_{w=0}^{W_l-1} k_{i,j,m}^{h,w} \text{map}_{(l-1),m}^{(x+h),(y+w)} + b_{i,j} \right) \quad (1)$$

式中： $k_{i,j,m}^{h,w}$ 表示第 l 层第 j 个卷积核在 (h, w) 位置的具体值，该卷积核对应第 $(l-1)$ 层中第 m 个特征图； H_l 和 W_l 分别表示卷积核的高和宽； $b_{i,j}$ 表示偏置； $\text{map}_{(l-1),m}^{(x+h),(y+w)}$ 表示第 $(l-1)$ 层中第 m 个特征图在 $((x+h), (y+w))$ 处的值； $\text{map}_{i,j}^{x,y}$ 表示第 l 层第 j 个特征图在 (x, y) 位置得到的输出值。位于模型前端的几层 CNN 通常提取图像的纹理、颜色和边缘等浅层特征，随着模型的深度逐渐增加，深层的 CNN 可从浅层特征图中提取深度语义特征，这些深度特征具有强鲁棒性、抗空间变异性等优点，用于数据分类可得到更好的效果，且已在 Imagenet 等国际计算机视觉大赛上得到验证^[8]。虽然更深的网络可以得到更好的学习效果，但研究者发现，当一个深度网络趋于收敛时，随着训练批次的增加，训练精度会先趋于饱和然后急剧下降^[9]，这种现象在很长时间内限制着深层网络的构建。直到 He K M 等^[10]提出了残差网络 (Resnet)，有效克服因模型深度而导致的精度下降问题，Resnet 中起主要作用的是 residual block。

Residual block 的原理如图 1 所示。其中： X 代表输入特征，其可能是源于之前网络的输出特征或原始数据；Conv layer 代表卷积层； $F(\cdot)$ 代表残差函数，即中间若干层卷积层和激活函数对输入数据的残差映射；右侧支路代表通过捷径连接 (shortcut

connection) 得到的对 X 的恒等映射。网络将输入和输出相加在一起得到 $F(X)+X$ ，再通过激活函数得到新的特征。实验表明，Residual block 的这种应用很好地解决了深度神经网络的退化问题，并在 ImageNet 和 CIFAR-10 等图像任务上取得了非常好的结果^[10]，网络层数相等的前提下，拥有残差块结构的网络也收敛的更快。关于 residual block 的作用机理一直富有争议，目前存在几种可能的解释，在文献^[11-13]中有所讨论，在此不再赘述。

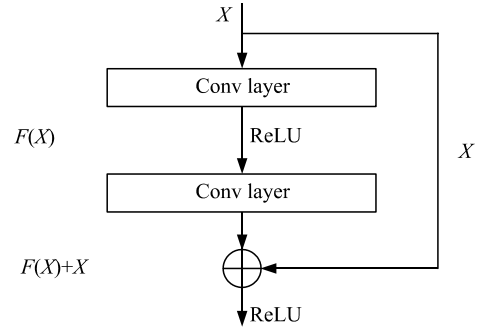


图 1 Residual block 的原理

1.2 改进的 residual block

传统的残差块中的若干卷积层通常具有相同的尺寸结构，如图 2(a)所示。每个 residual block 内卷积层输入特征和输出特征的维度相同，结尾处将 shortcut 得到的恒等映射和残差映射相加，这种方式虽然也可以有效提取深层特征，但仍通过改进结构以减小参数量。在每个 residual block 的中间层引入 1×1 卷积以改变特征图通道数，达到减小模型参数、提升训练速度的效果。受文献^[14]启发，笔者将传统的 residual block 设计成“金字塔”形，如图 2(b)所示，灰色色块的长度代表特征图的深度 (即通道数)，输入特征送入 1 个 block 后，特征图的通道数首先会减小，经过特征提取后输出的特征通道数会比输入时更大。具体地，1 个“金字塔”残差块由许多网络层堆叠而成，其中最主要是 2 个 1×1 卷积层和 1 个 $n \times n$ 卷积层 (本文中 $n=3, 7, 8$)。参数量较少 1×1 卷积层对输入的高维特征进行降维，再用 $n \times n$ 卷积核对降维后的特征图进行特征提取，最后再用 1×1 卷积核特征图实现通道数扩增，扩增后的特征图深度比输入时还要高，加深通道数的目的是为了弥补 $n \times n$ 卷积作用与特征图时导致特征图面积变小而失去信息。其核心设计在于巧妙地利用 1×1 卷积核特征图的深度进行扩充或缩小，这种操作既可以减少网络参数，提升训练速度，而且已经有实验证明，利用这种方法实现的特征图维数

扩增, 提取到的是更加多样性的高阶属性, 对分类任务非常有效^[11]。

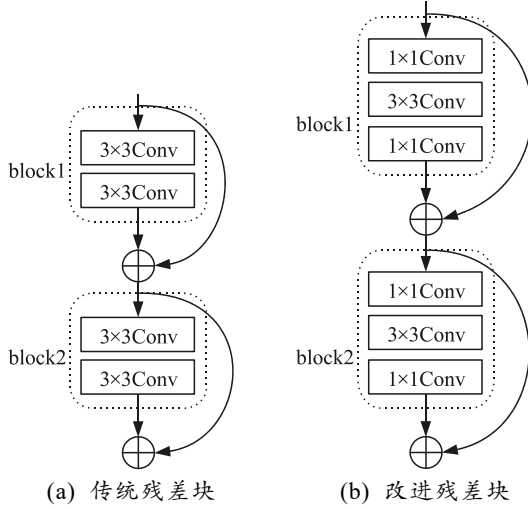


图 2 残差块

1.3 总体模型设计

网络的总体设计如表 1 所示。该网络主要由 3 个残差单元 U_1 , U_2 和 U_3 构成, 其中每个残差单元由 3 个“金字塔”residual block 构成, 分别是 B_1^i , B_2^i 和 B_3^i ($i=1, 2, 3$)。表 1 展示了网络中起主要作用的卷积层的结构分布及相关参数, 每个 B_j^i 由几个网络层堆叠而成, 且每个卷积层前面都添加了相应的 BN 层, 最后在每个 B_j^i 的末端有 1 个 ReLU 激活函数实现特征的非线性映射。具体来说, 各 block 的结构可概括为 BN1-CNN1-BN2-CNN2-BN3-CNN3-ReLU。值得注意的是, 在网络的入口处添加了 1 层单独的 CNN-BN 层, 该层的目的是对原始输入数据进行第 1 次空谱特征提取的同时, 对输出特征图的通道数进行整合, 为特征送入后续残差单元做准备。

图 3 展示了利用笔者所提出的网络实现高光谱图像分类的流程。1 个原始的高光谱数据首先会经过标准化处理, 使其所有的数据归一化后才会被送入网络。1 个高光谱图像 X 是 1 个数据立方体, 可表示为 $X \in \mathbb{R}^{N \times W \times H}$, 其中 N, W, H 分别代表图像的波段数、长和宽。高光谱图像的分类是逐像素实现的, 因此要把每个像素 $x_{i,j} \in \mathbb{R}^N$ 都送入网络中进行预测。为利用高光谱图像图谱合一的优势, 笔者选取每个像素点周围的 d^2 个邻域像素构成 1 个邻域像素立方体 $p_{i,j} \in \mathbb{R}^{N \times d \times d}$ 作为网络的输入数据, 同时样本的标签即为像素 $x_{i,j}$ 的标签。

表 1 网络结构

残差单元/C	残差块	卷积层	卷积核
C	-	-	3×3
U_1	B_1^1	C_1^1	1×1
		C_2^1	7×7
		C_3^1	1×1
	B_2^1	C_1^2	1×1
		C_2^2	7×7
		C_3^2	1×1
	B_3^1	C_1^3	1×1
		C_2^3	7×7
		C_3^3	1×1
U_2	B_1^2	C_1^1	1×1
		C_2^1	8×8
		C_3^1	1×1
	B_2^2	C_1^2	1×1
		C_2^2	7×7
		C_3^2	1×1
	B_3^2	C_1^3	1×1
		C_2^3	7×7
		C_3^3	1×1
U_3	B_1^3	C_1^1	1×1
		C_2^1	8×8
		C_3^1	1×1
	B_2^3	C_1^2	1×1
		C_2^2	7×7
		C_3^2	1×1
	B_3^3	C_1^3	1×1
		C_2^3	7×7
		C_3^3	1×1




图 3 高光谱图像分类流程

2 实验及分析

实验所采用的计算机硬件环境为 Intel(R) Core(TM) i7-10870H CPU @ 2.20 GHz、内存 16.0 GB, 编程 IDE 为 Pycharm, 采用 Pytorch1.10.1 深度学习框架, GPU 型号为 2060Ti。通过平均精度 (average accuracy, AA)、总体精度 (over accuracy, OA)、Kappa 系数对分类结果进行精度评价。

2.1 数据集介绍

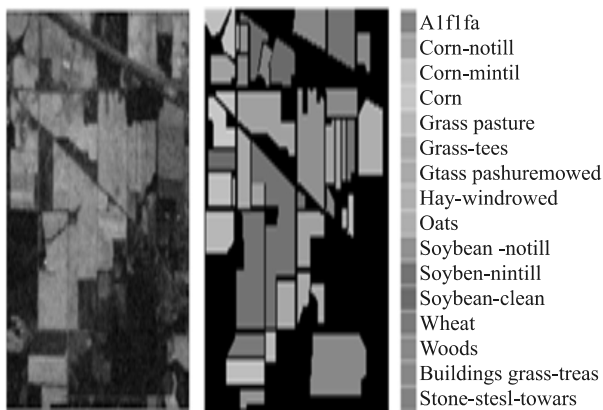
第 1 套数据集是由 ROSIS-3 传感器于 2002 年 7 月 8 日对意大利帕维亚市拍摄得到的高光谱图像, 称为 University of Pavia。图像的空间大小为 610×340 像素, 空间分辨率 1.3 m, 共记录了 115 个波段, 波长范围 430~860 nm, 覆盖可见光和红外波段, 去除 12 个噪声波段后, 余下 103 个波段用于实验验证。此场景共包含 9 类地物, 共 43 923 个样本, 主要地物类别是城市建筑材料, 如沥青、金属

板材、地砖等。本数据集的伪彩色图片和相应的 ground truth 如图 4(a)所示。

第 2 套数据集是由 AVIRIS 传感器对美国中北部的印第安纳州采集得到的，称为 Indian Pines。图像大小为 144×144 像素，共 224 个波段，空间分辨率 20 m，波长范围 400~2 500 nm，取出 4 个零波段和 20 个水吸收波段后，余下 200 个波段用于实验验证。此场景共包含 12 类地物，大多数类别为农作物，如大豆、玉米、小麦等。本数据集的伪彩色图片和相应的 ground truth 如图 4(b)所示。



(a) University of Pavia 数据集



(b) Indian pines 数据集

图 4 数据集的伪彩色图(左)和 ground truth(右)

2.2 实验参数设定

从 3 个数据集的每个类别中随机选取 20% 的像素作为训练集，剩余像素作为验证集和测试集，训练集、验证集和测试集的划分比例为 2: 1: 7。经过反复实验验证与讨论，具体的模型超参数设计确定如下：实验设置的数据集的批处理大小为 32，邻域像素的长和宽为 11，选取 SGD 作为优化器。采用指数衰减学习率的优化方法来提高网络的性能，其中，初始学习率为 0.01，衰减率为 0.93，衰减步长为 16，训练迭代次数为 200。

2.3 实验结果与分析

为验证笔者所提出网络的有效性，特选取一些

经典的高光谱图像分类方法作为对比，分别是基于传统机器学习的支持向量机 (support vector machine, SVM)^[15]以及近些年提出的深度学习方法 2D-CNN^[16]和 3D-CNN^[17]。

表 2 和 3 分别展示笔者所提出的分类方法与其他分类方法在不同数据集上的表现。

表 2 Pavia University 分类结果对比

Classification Name	SVM	2D-CNN	3D-CNN	Proposed Network
Asphalt	84.730	93.640	98.150	99.910
Meadows	92.240	94.750	95.920	99.990
Gravel	30.320	77.220	96.170	99.770
Trees	93.170	94.910	98.720	99.800
Painted metal sheets	99.400	99.800	99.930	100.000
Bare Soil	63.480	82.720	99.630	100.000
Bitumen	75.660	88.000	98.660	99.660
Self-Blocking Bricks	78.770	85.870	98.570	99.920
Shadows	100.000	99.800	99.940	100.000
AA/%	79.750	90.750	98.410	99.890
OA/%	84.160	91.420	95.480	99.940
Kappa coefficient	0.782	0.885	0.941	0.992
Time/s	1 008.920	140.290	172.090	269.190

表 3 Indian Pines 分类结果对比

Classification name	SVM	2D-CNN	3D-CNN	Proposed network
Alfalfa	33.370	44.450	1.000	93.040
Corn-notill	52.190	76.560	97.250	99.130
Corn-mintill	55.700	69.230	91.640	99.540
Corn	23.280	56.530	97.400	99.920
Grass-pasture	63.910	86.900	96.110	99.830
Grass-tees	87.440	92.340	99.960	99.890
Grass-pasture-mowed	64.680	57.110	100.000	99.290
Hay-windrowed	91.140	93.740	100.000	100.000
Oats	00.000	20.000	100.000	99.000
Soybean-notill	57.260	70.450	94.540	98.480
Soyben-mintill	67.590	79.380	96.370	99.580
Soybean-clean	29.330	71.760	96.210	98.550
Wheat	86.750	98.910	100.000	99.510
Woods	87.810	93.600	99.800	99.810
Buildings-Grass-Trees-Drives	29.680	66.000	87.630	99.530
Stone-Steel-Towers	91.840	91.780	97.910	98.490
AA/%	57.620	73.050	90.990	98.970
OA/%	66.760	80.230	94.120	99.400
Kappa coefficient	0.608	0.773	0.943	0.971
Time/s	308.980	56.450	79.620	103.210

从上表可以看到，在 University of Pavia 数据集中，笔者所提方法在所有类别的分类中都取得了最高的精度。在 Indian Pines 数据集的 3 个综合衡量指标 AA、OA 和 Kappa 系数中，本文中的方法比第 2 优的 3D-CNN 方法分别高出 7.98%、5.28%和 0.028。基于 SVM 的分类方法性能表现最差，这是由于 SVM 仅仅基于图像的 1 维光谱信息做分类，当面对地物分布情况比较复杂的场景时，感兴趣地物的光谱信息往往会被周围物体所干扰，出现同谱异物的现象，因此 SVM 对很多种类都无法正确识别。图 5 和 6 展示了不同分类方法对已标注数据的分类结果。

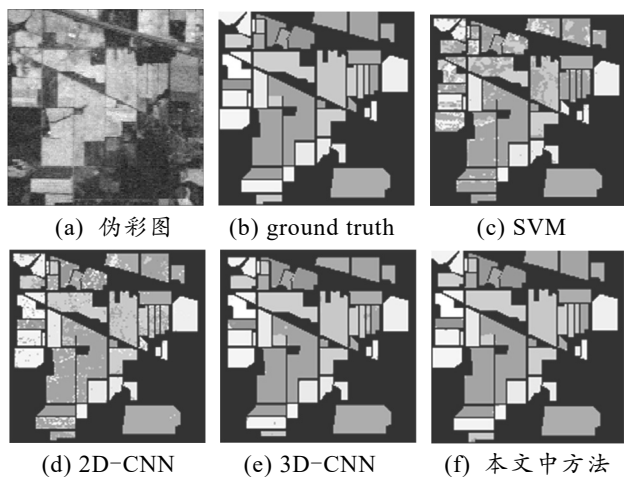


图 5 Indian Pines 分类结果




图 6 University of Pavia 分类结果

从图 5(c)和图 6(c)所示的分类结果可以更直观地看出：这种仅基于光谱信息的分类器往往会产生相当混乱的分类图，因为它们在提供像素预测时没有考虑空间成分，而 3D-CNN 和笔者所提出的网络由于输入的是邻域像素块，可以克服该缺陷。在 Indian Pines 和 University of Pavia 数据集对应的分类结果中，笔者用到的网络提供了与原 ground truth 图更相似的分类结果。SVM 和 2D-CNN 的分类结果有许多噪声点和离群点，而且在各个类别的边界处有大批的错判点，这是由于提取的特征层次较低，泛化性不够强。特别是在图 6 中 SVM 对 Bare soil 和 Meadow 得到了大片的错分像素，这是由于这 2 种地物的光谱曲线本身就比较相似而导致 SVM 无

法有效区分。与此相比，本文中网络得到的结果基本没有明显的噪声点，而且分类边界处非常平滑，说明充分利用了邻域像素的空间和光谱信息，提取到深层的抽象特征。从以上比较可以得出，本文中基于改进残差网络的分类网络在所有数据集中的性能表现最佳，而 SVM 只利用光谱信息而效果很差，在场景复杂的 Indian Pines 数据集中 OA 只能达到 66.76%，其次是空间 2D-CNN(80.23%)。

此外，从计算耗费时间上看，SVM 耗时最久，2D-CNN、3D-CNN 和本文中方法依次增加。虽然 SVM 是本文中计算原理最简单的分类器，但由于 SVM 是基于 CPU 的算力进行训练的，无法使用 GPU 的加速运算能力，与其余 3 种基于 GPU 训练的方法相比，耗时自然最久。而本文中方法由于网络的结构性比其余 2 种网络都要复杂，耗费算力相对较多，但从分类准确性来看尚可接受。且当 GPU 设备计算能力越强时，这种计算时间上的差距也会越小。

3 结论

笔者对深度学习模型中的残差块模型进行改进，设计一种由 3 个“残差单元”构成的深度神经网络，其中每个单元又包含 3 个改进的残差块，可以提取高光谱数据的深层空间-光谱特征，在 Indian Pines 和 University of Pavia 数据集上分别得到了 98.98%和 99.89%的 OA 结果，与其他 3 种分类方法相比，笔者提出的方法精度最高。该方法在精度上已经取得较好效果，下一步将从以下方面做出改进：1) 笔者的实验是基于公开数据集，下一步重点针对一些军事问题制作特定的数据集，实现伪装识别和军事目标检测；2) 实验中不同类别之间像素的数量不均衡，在训练之前可以引入一些数据增强方法，如对邻域像素块进行“翻转”“镜像”等操作，或制作模拟样本以扩充数据集，解决个别类别小样本的问题。

参考文献：

- [1] STEIN D, SCHOONMAKER J, COOLBAUGH E. Hyperspectral Imaging for Intelligence, Surveillance, and Reconnaissance[R]. Space and Naval Warfare Systems Command, San Diego, CA, 2001.
- [2] CHEN K. Military object detection using multiple information extracted from hyperspectral imagery[C]//2017 International Conference on Progress in Informatics and Computing (PIC). IEEE, 2017.
- [3] 马世欣, 刘春桐, 李洪才, 等. 基于高光谱图像探测与

感知的伪装效果评估方法[J]. 兵工学报, 2019, 40(7): 1485-1494.

[4] MUHAMMAD A, SIDRAH S, SWALPA K R, et al. Hyperspectral Image Classification-Traditional to Deep Models: A Survey for Future Prospects[J]. ArXiv, 2021(1): 06116.

[5] LI W, WU G D, ZHANG F, et al. Hyperspectral Image Classification Using Deep Pixel-Pair Features[J]. IEEE Transactions on Geoscience and Remote Sensing, 2016, 55(2): 844-853.

[6] LIU B, YU X, ZHANG P, et al. Supervised Deep Feature Extraction for Hyperspectral Image Classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(4): 1909-1921.

[7] CHEN L, WEI Z, XU Y. A Lightweight Spectral-Spatial Feature Extraction and Fusion Network for Hyperspectral Image Classification[J]. Remote Sensing, 2020, 12(9).

[8] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks[J]. SOR Related, 2012, 25: 1097-1105.

[9] HE K M, SUN J. Convolutional neural networks at constrained time cost[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2015.

[10] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE

(上接第 10 页)

[3] 孙高俊. 一种相控阵雷达时序控制装置设计[J]. 雷达科学与技术, 2019, 17(6): 660-664.

[4] 冯博琴, 吴宁. 微型计算机原理与接口技术[M]. 北京: 清华大学出版社, 2011: 34-86.

[5] 薛扬. 某平台自动化测试系统的研制[D]. 北京: 北京航空航天大学, 2004.

[6] 王子龙, 路景泽. 基于 CPCI 总线的雷达导引头测试系统设计[J]. 计算机测量与控制, 2016, 24(7): 141-143.

[7] 刘丽亚, 杜舒明, 闫俊锋, 等. 基于改进粒子群算法的

(上接第 14 页)

参考文献:

[1] 吴文皓. 校园网环境下的 MPLS 技术研究与仿真[D]. 哈尔滨: 哈尔滨理工大学, 2013.

[2] 刘俊斌, 王勇. 基于 MPLS VPN 技术多校区校园网应用研究[J]. 价值工程, 2014(3): 188-190.

[3] HOU J F, MA M K, LI X H. Application of Dynamic QoS Mechanism in MPLS VPN[J]. Computer Engineering, 2010, 36(3): 106-108.

[4] 陈雪非, 黄河, 李蓬. MPLS VPN 关键技术研究[J]. 计

算机工程与设计, 2007, 28(13): 3138-3140, 3150.

算机工程与设计, 2007, 28(13): 3138-3140, 3150.

[5] 宋高俊, 胡成, 周芳. 基于分层 PE 技术的 MPLS VPN 架构优化[J]. 计算机工程, 2017, 43(6): 66-72.

[6] KALAMANI K, PALANISWAMI S, KAARTTHICK B. An Optimized Link Management Algorithm for Handling Link Failure in MPLS[J]. International Journal of Computer Science Issues, 2012, 9(3): 123-129.

[7] 杨云. MPLS 快速重路由方案的仿真实验与分析[J]. 微计算机信息, 2009(18): 132-134.

[8] 王必荣, 孟昭鹏, 孙静, 等. MPLS 流量工程提升 IP 网络 QoS 性能的研究[J]. 计算机工程与应用, 2006, 42(2): 131-134.

Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2016.

[11] HE K M, ZHANG X Y, REN S Q, et al. Identity mappings in deep residual networks[C]//European conference on computer vision. Springer, 2016.

[12] VEIT A, WILBER M J, BELONGIE S. Residual networks behave like ensembles of relatively shallow networks[J]. ArXiv, 2016, 29: 550-558.

[13] BALDUZZI D, FREAN M, LEARY L, et al. The shattered gradients problem: If resnets are the answer, then what is the question[C]//proceedings of the International Conference on Machine Learning. PMLR, 2017.

[14] HAN D Y, KIM J H, KIM J M. Deep pyramidal residual networks[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2017.

[15] MELGANI F, BRUZZONE L. Classification of hyperspectral remote sensing images with support vector machines[J]. IEEE Transactions on Geoscience and Remote Sensing, 2004, 42(8): 1778-1790.

[16] CHEN Y, JIANG H, LI C, et al. Deep Feature Extraction and Classification of Hyperspectral Images Based on Convolutional Neural Networks[J]. IEEE Transactions on Geoscience and Remote Sensing, 2016, 54(10): 6232-51.

[17] LI Y, ZHANG H, SHEN Q. Spectral-Spatial Classification of Hyperspectral Imagery with 3D Convolutional Neural Network[J]. Remote Sensing, 2017, 9(1): 67.

雷达成备测试性设计优化技术[J]. 计算机测量与控制, 2020, 28(8): 160-164.

[8] 徐鸣一, 李峰, 夏元彩, 等. 新一代天气雷达 2009-2014 年运行状态分析[J]. 气象, 2017, 43(3): 365-372.

[9] 中国人民解放军总装备部. 电子设备可靠性预计手册: GJB/Z299B—1998[S]. 北京: 中国人民解放军总装备部, 1998.

[10] 吴振亚, 郝建平, 陈汉青, 等. 装备平均修复时间验证方法研究综述[J]. 系统工程与电子技术, 2020, 42(12): 2931-2943.
