

DOI:10.19651/j.cnki.emt.2210938

基于阴影增强和注意力机制的高光谱图像分类^{*}

刘秋月 刘雪峰 孙绍华

(青岛科技大学自动化与电子工程学院 青岛 266061)

摘要: 基于深度学习网络的高光谱图像分类能够有效地提取图像中的特征信息,促进遥感图像中丰富信息的挖掘与利用。然而,现有方法性能仍然受限于阴影信息不能充分提取、特征不能有效利用。针对阴影区域信息提取,动态随机共振能够利用噪声增强信号,提高信息的表达能力;针对特征利用,在卷积神经网络中嵌入注意力机制,能够在其提取的高层特征的基础上,从空间维度和通道维度进一步提取融合,筛选出对当前任务目标更为关键的特征,提升网络分类性能。实验结果表明:通过在含有阴影区域的真实高光谱图像数据集 Hydice 上仿真,动态随机共振能够有效增强信号进而将分类精度从 96.48% 提升到 97.14%,卷积注意块的加入使分类精度提升了 0.408 4%。进一步与其他分类方法在 Hydice、Indian Pines、Pavia University 进行实验对比验证,本文方法分类精度分别达到了 97.436 1%、99.219 5% 和 99.929 9%,对不同数据集的分类都具有良好的表现,相较于其他方法具有明显优势,证明了该方法的有效性和良好的分类性能,在高光谱图像分类领域具有广阔的应用前景。

关键词: 高光谱图像;DSR;阴影增强;卷积神经网络;图像分类;注意力机制

中图分类号: TP751 文献标识码: A 国家标准学科分类代码: 510.4050

Hyperspectral image classification based on shadow enhancement and attention mechanism

Liu Qiuyue Liu Xuefeng Sun Shaohua

(College of Automation & Electric Engineering, Qingdao University of Science & Technology, Qingdao 266061, China)

Abstract: Techniques based on deep learning for hyperspectral image classification can effectively extract features and promote the mining and utilization of the rich information. The performance of existing methods is still limited by the insufficient extraction of shadow information and the inefficient use of features. For information extraction in shadow areas, dynamic stochastic resonance can enhance the signal by using noise to improve the ability of information expression. For feature utilization, the attention mechanism is embedded in the convolutional neural network, which can further extract and fuse from the space dimension and channel dimension based on the high-level features extracted, screen out features more critical to the current task target, so as improving the classification performance. The experimental results show that dynamic stochastic resonance can effectively enhance signal, the classification accuracy on real world dataset Hydice is improved from 96.48% to 97.14%, and is improved by 0.408 4% with convolutional attention block added. Further verification by comparison with other methods, the classification accuracy on Hydice, Indian Pines and Pavia University reaches 97.436 1%, 99.219 5% and 99.929 9% respectively, which has obvious advantages. It is proved that the method is effective and has good classification performance, and has broad application prospects in the field of hyperspectral image classification.

Keywords: hyperspectral image classification;dynamic stochastic resonance;shadow enhancement;convolutional neural network;image classification;attention mechanism

0 引言

高光谱图像(hyperspectral image, HSI)因具有丰富的

空间和光谱信息^[1]的特征,在工业环境^[2]、生态环境评价^[3]、生物医学^[4]等诸多领域具有广泛的应用。因此,高光谱图像的检测和分类也成为了当前面临的一项重要任

收稿日期:2022-08-03

*基金项目:国家自然科学基金(61971253)、山东省自然科学基金(ZR201910300033)项目资助

务^[5-6]。传统分类算法有小波变换、支持向量机等,仅能提取到较为浅层的特征,不能取得很好的分类效果。近年来,深度学习已成功应用于图像分类领域^[7],如自编码网络(stacked autoencoder, SAE)、深度置信网络(deep belief nets, DBN)等。其中,基于卷积神经网络^[8](convolutional neural network, CNN)的框架应用最为广泛,如生成对抗网络^[9]、残差网络^[10]等。与传统方法相比,这些方法能够有效增强和提取深层特征,取得很好的分类效果^[11-13]。

现有的针对高光谱图像进行分类的方法取得很好成就,但对所提取的高层特征还可以更大程度上予以利用,提升网络的分类性能。受人类视觉系统快速聚焦场景中重要区域的启发,研究人员提出了注意力机制^[14](attention mechanism, AM)的概念,可以辅助模型对每个特征赋予不同的权重,提取更关键和重要的信息,使模型做出更准确的判断,且不会带来更大的计算和存储成本。目前已应用于自然语言处理^[15]、图像和语音识别等领域,如置换注意力^[16](shuffle attention, SA)、卷积注意^[17](convolutional block attention module, CBAM)、有效通道注意力^[18](efficient channel attention, ECA)、和压缩和激励注意力^[19](squeeze and excitation, SE)等。

目前高光谱图像分类任务中,不可避免的会因光照和物体遮挡产生的阴影^[20],导致该区域像素的地物信息被削弱,致该区域目标的识别和分类受到限制。当前高光谱图像分类的方法中,阴影区域通常被标记为单独的一类或被直接忽略,以致其中包含的地物信息无法被很好地识别和利用,因此对阴影区域信号进行增强和利用对提升高光谱图像分类的效果具有重要意义。经典的基于空域、变换域^[21]及视觉传达^[22]增强技术的图像增强方法,多是对噪声采用消除的方式进行处理,但同时有效信息处理过程中也易有损失。动态随机共振(dynamic stochastic resonance, DSR)具有很好的弱信号检测能力^[23-24],能够有效利用噪声增强有用信号,且已成功应用于图像处理领域^[25]。

基于上述问题本文提出采用动态随机共振的方法增强阴影区域信息表达能力从而提升分类效果,并提出嵌入注意力机制的CBAM-3DCNN的高光谱图像分类网络,利用CBAM卷积注意模块进一步在空间和通道维提取高阶特征信息,提升网络分类性能。首先,利用动态随机共振对高光谱图像阴影区域信号进行增强处理;继而将增强后的阴影区域与原始图像的非阴影区域进行融合;最后,搭建高光谱图像分类网络模型,在真实高光谱图像数据上仿真验证,并与其它方法在分类性能上进行比较和评估。

本文的其余部分主要内容如下:第1章介绍了DSR、3DCNN和CBAM的基本算法;第2章详细描述了所嵌入CBAM的3D CNN高光谱图像分类的方法的结构;第3章进行了仿真实验和验证,并对结果进行了分析;第4章对文章进行了总结和展望。

1 算法概述

1.1 动态随机共振理论

在信号处理任务中,对噪声的处理方式多为将其视作消极的干扰信号进行去除。然而,在一些非线性系统中,适当应用动态随机共振理论可以利用噪声有效地放大微弱的输入信号,从而提高系统的信噪比。一维非线性动力系统根据朗之万运动方程可以描述为^[26]:

$$m \frac{d^2x(t)}{dt^2} + \gamma \frac{dx(t)}{dt} = -\frac{dU(x)}{dx} + f(t) + \delta(t) \quad (1)$$

其中, m 和 γ 表示粒子质量和摩擦系数, $\frac{dx(t)}{dt}$ 是粒子位置的变化率, $f(t)$ 和 $\delta(t)$ 是周期性驱动信号和外部噪声信号, t 和 $x(t)$ 分别表示双稳态系统中粒子的时间和位置 $U(x)$ 是 x 的双稳态势函数,可以表示为:

$$U(x) = -a \frac{x^2}{2} + b \frac{x^4}{4} \quad (2)$$

其中, a 和 b 表示双稳态系统的参数。当 $a, b=2$ 时, x 的双稳态情况函数 $U(x)$ 如图1所示。

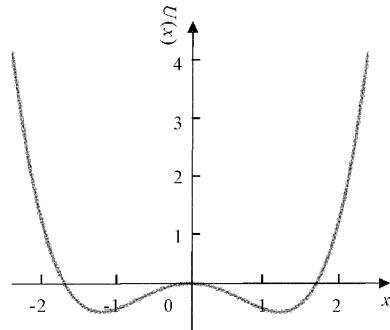


图1 双稳态势函数

如果式(1)中的模型严重阻尼,则可以忽略惯性项 $m \frac{d^2x(t)}{dt^2}$:

$$\frac{dx(t)}{dt} = -\frac{dU(x)}{dx} + f(t) + \xi(t) \quad (3)$$

将式(3)代入式(2):

$$\frac{dx(t)}{dt} = ax(t) - bx^3(t) + f(t) + \xi(t) \quad (4)$$

当 $x_{\pm} = \pm \sqrt{\frac{a}{b}}$ 在式(2)中时,有两个稳定的平衡点,势垒 $\Delta U = \frac{a^2}{4b}$ 。如果外部定期驱动未应用于系统,则系统保持稳定。但当采用外部周期性驱动时,系统的稳定性将受到破坏。当噪声也应用于系统时,粒子的稳定状态可能会由于其能量而转换为另一种状态,这意味着噪声可以用作增强系统中微弱信号的有利因素。

因此,在双稳态系统中,阴影和非阴影区域中的目标可以分别视为噪声 $\delta(t)$ 和弱信号 $f(t)$, DSR 可以用来增加目

标信号的强度。在这种情况下,式(4)可以转换为:

$$x(n+1) = x(n) + \Delta t[(ax(n) - bx^3(n)) + Input] \quad (5)$$

其中, n 表示迭代次数, Δt 表示步长, $Input = f(t) + \delta(t)$ 表示带阴影区域的高光谱图像, $x(n+1)$ 表示得到增强的输出信号。

1.2 三维卷积神经网络

在计算机视觉领域,3DCNN 在特征提取方面具有良好的性能,并被广泛应用^[27]。与二维卷积相比,3DCNN 不仅考虑了空间信息,还将第三维的信息进行了综合,更适合如高光谱图像等三维数据的处理任务。CNN 的特点是权值共享和反向传播,即通过卷积核中的权值共享减少参数数量,并通过梯度反向传播更新参数,实现自学习。

通常,3D CNN 的结构包括输入层、卷积层、池化层、全连接层和输出层等。该模型的核心思想是 3D 卷积,如图 2 所示。

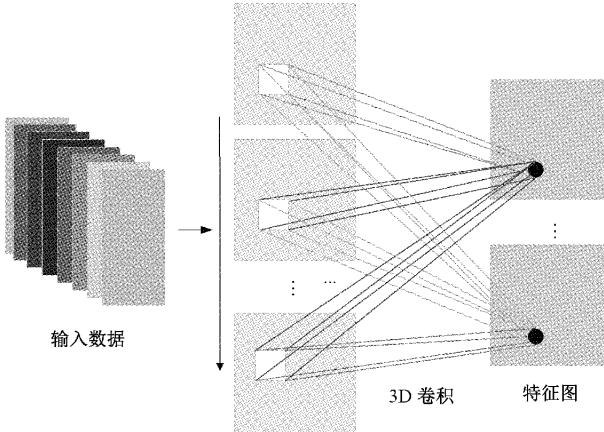


图 2 3D 卷积结构

三维卷积的计算公式如下:

$$\varphi_{lm}^{xyz} = g \left(\sum_{p=0}^{N_1-1} \sum_{n_1=0}^{N_2-1} \sum_{n_2=0}^{N_3-1} \omega_{lmp}^{n_1 n_2 n_3} \varphi_{(l-1)p}^{(x+n_1)(y+n_2)(z+n_3)} + b_{lm} \right) \quad (6)$$

其中, φ_{lm}^{xyz} 是 l 层第 m 个特征图 (x, y, z) 处的输出, l 是当前卷积层, m 为特征图数, p 是第 $l-1$ 和第 l 层之间连接的特征图数, $\omega_{lmp}^{n_1 n_2 n_3}$ 是从坐标 (n_1, n_2, n_3) 到特征图 p 的权重, g 表示激活函数, b 为偏置, $N_{1,2,3}$ 为卷积核的尺寸。

1.3 卷积注意力模块

注意力机制可以通过一定的手段获得每个特征映射的不同重要性,将更多的神经网络计算资源投入到更重要的任务中。卷积注意是一种结合空间和通道信息的注意机制模块,它利用结果指导特征图的权值更新,从而高效、快速地完成任务。CBAM 的基本结构如图 3 所示。

通道和空间注意模块的输出可以分别表示为 $T_c(f)$ 和 $T_s(f)$:

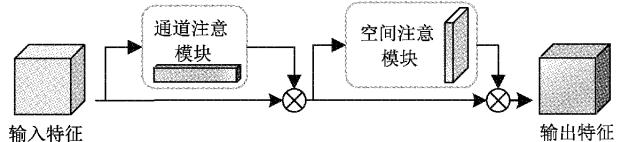


图 3 本文方法主要流程

$$T_c(f) = \sigma(Mlp(Avg(f)) + Mlp(Max(f))) \quad (7)$$

$$T_s(f) = \sigma(Conv(Concat[Avg(f); Max(f)])) \quad (8)$$

其中, f 表示输入特征图, σ 表示“sigmoid”激活函数, Max 和 Avg 表示对输入特征进行全局最大池化和全局平均池化, Mlp 表示多层感知机, 是深度神经网络的基本算法, $Conv$ 表示卷积, $Concat$ 表示将提取的特征图进行拼接。

2 基于动态随机共振和嵌入注意力机制的三维卷积网络 HSI 分类

为了提高系统的分类性能,本章提出了一种结合 3DCNN 和 CBAM 的高光谱图像分类网络,通过动态随机共振理论提升图像的阴影区域信息表达能力再进行分类,达到更好的分类效果。

方法的主要流程如图 4 所示。

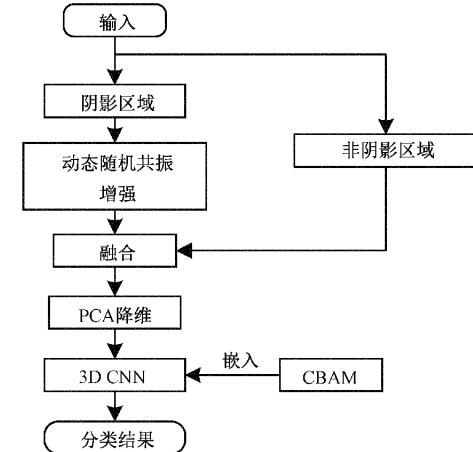


图 4 本文方法主要流程

2.1 动态随机共振阴影增强

利用高光谱图像在每个像素点的光谱信息为一维的数据特征,对图像中信号较弱的像素点的光谱信息进行增强。

首先,利用阴影标签数据分别提取高光谱图像中的阴影和非阴影区域,将阴影区域的干扰因素视为噪声,则双稳态系统的输入即为阴影区域中带有噪声的光谱信息,对该区域信息进行增强后再与非阴影区域信息进行融合,针对高光谱图像进行增强的系统模型建立如下。

高光谱数据可以表示为 $I^{H \times W \times B}$, 其中 H 、 W 和 B 分别表示高度、宽度和波段数。阴影区域位于 (i, j) 处的光谱向量可以定义为 $s_{i,j} = (s_{i,j,1}, s_{i,j,2}, \dots, s_{i,j,B})$, $s_{i,j,k}$ 表示第 k 个波段位于 (i, j) 的光谱强度,因此代入式(5)可得到阴

影区域 (i, j) 处增强后的信号:

$$S_{i,j}(n+1) = S_{i,j}(n) + \Delta t[(aS_{i,j}(n) - bS_{i,j}^3(n) + s_{i,j})] \quad (9)$$

然后,将各像素点光谱信息得以增强的阴影区域与不含阴影的原始 HSI 进行融合。

因此,可以获得要分类的最终数据:

$$I_{enhance} = DSR(I_{shadow}) + I_{non\ shadow} \quad (10)$$

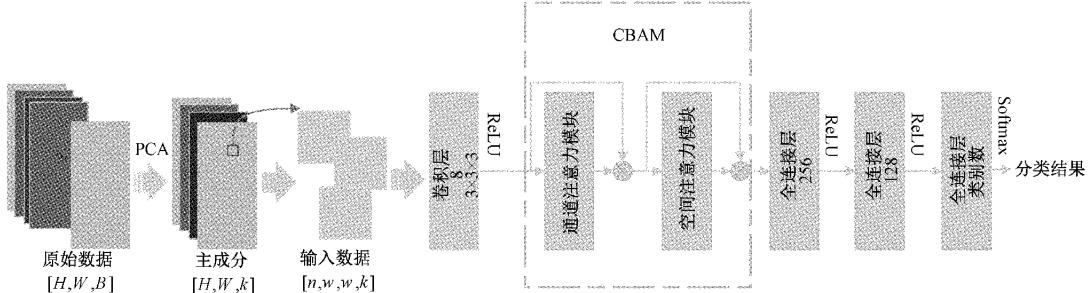


图 5 本文分类方法模型结构

1) 将对增强后的高光谱图像数据划分为训练集和验证集,分别用于对网络性能进行训练和验证;

2) 通过主成分分析法(principal component analysis, PCA)进行降维,提取 k 个主成分;

3) 将降维后的数据划分为窗口大小为 $w \times w \times B$ 的块为了便于处理,

4) 建立 3D 卷积,全连接与 Dropout 层等组成的高光谱图像特征提取网络,调节参数,通过特征提取模块提取到 C 个特征图;

5) 将 CBAM 注意模块嵌入到特征提取分类网络中,重新校准输入特征的权重,其中通道注意(channel attention, CA)和空间注意(spatial attention, SA)模块的详细过程、张量尺寸的变化如图 6 和 7 所示;

6) 通过嵌入 CBAM 的 3D CNN 网络对输入的增强后的高光谱图像数据进行分类,得到分类结果。

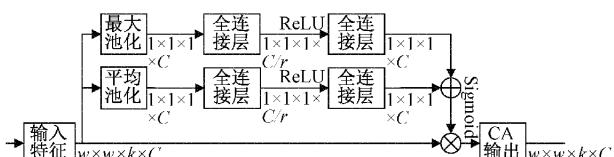


图 6 CA 模块

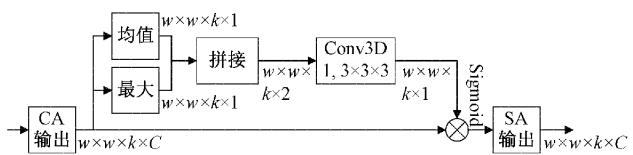


图 7 SA 模块

3 实验及仿真

本文的实验基于 Keras 深度学习框架,执行环境为

其中, I_{shadow} 和 $I_{non\ shadow}$ 分别表示阴影区域和非阴影区域。

2.2 嵌入注意机制的三维卷积网络(CBAM-3DCNN)

为了提高对高光谱图像分类的性能,本文将注意块 CBAM 嵌入到 3D-CNN 中,可以区分网络中更重要的特征,赋予它们更高的权重,并减少不重要特征的权重。文中提出的嵌入 CBAM 的 3D CNN 高光谱图像的分类网络结构如图 5 所示。

Python 3.6。操作系统为 Ubuntu 16.04, 网络在 Linux 系统上搭建,采用 Nvidia GTX 2080Ti 显卡,内存为 11 GB。

3.1 数据集简介

为了验证本文提出的方法的性能,实验采用了 Hydice(hyperspectral digital image collection experiment)数据集(采自 1995 年 8 月的高光谱数字图像采集实验)来进行实验和评估。为进一步验证分类算法的性能,引入了 Pavia University 和 Indian Pines 两个公共数据集进行测试,各数据集的相关信息如下:

Hydice: 图像尺寸 $316 \times 216 \times 148$, 空间和光谱分辨率为 0.7 m 和 10 nm , 光谱波段范围为 $435 \sim 2326 \text{ nm}$ 。此数据集有 7 类地物标签: 场、树、道路、阴影(包括一段道路)等。该数据集标签对应的伪彩色图像如图 8。

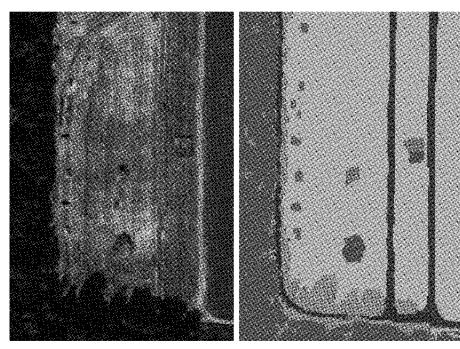


图 8 HYDICE 数据集

Indian Pines: 图像尺寸 $145 \times 145 \times 200$ 。原数据集包括 220 个波段,实际实验中筛选了 20 个不能被水反射的波段。此数据集有 16 类地物标签: 燕麦、苜蓿、玉米、小麦等。该数据集标签对应的伪彩色图像如图 9。

Pavia University: 图像尺寸 $610 \times 340 \times 103$ 。原含

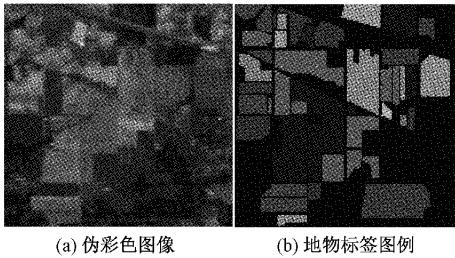


图 9 Indian Pines 数据集

115 个波段, 实际实验中筛选了 12 个受噪声干扰的波段。此数据集有 9 类地物标签, 包括树、沥青道路、树木、牧场、碎石等。该数据集标签对应的伪彩色图像如图 10。

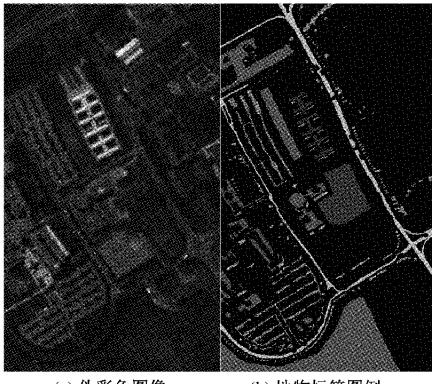


图 10 Pavia University 数据集

3.2 评价指标

针对整体的分类效果采用高光谱图像分类任务中普遍采用的 3 个指标进行评估: 总体精度 (overall accuracy, OA), 平均精度 (average accuracy, AA), Kappa 系数。

OA 表示正确分类的样本在测试样本总数中所占的比例; AA 描述的是每个类别的分类差异; Kappa 系数表示分类和完全随机分类之间减少的错误百分比, 是根据混淆矩阵计算的, 用于衡量分类算法相对于随机分类的误差减少程度。

各评价指标具体计算方法如下^[28]:

$$OA = \frac{1}{M} \sum_{i=1}^L P_{i,i} \quad (11)$$

$$AA = \frac{1}{L} \sum_{i=1}^L \frac{P_{i,i}}{\sum_{j=1}^L P_{i,j}} \quad (12)$$

$$Kappa = \frac{M \sum_{i=1}^L P_{i,i} - \sum_{i=1}^L (\sum_{j=1}^L P_{i,j} \times \sum_{i=1}^L P_{i,j})}{M^2 - \sum_{i=1}^L (\sum_{j=1}^L P_{i,j} \times \sum_{i=1}^L P_{i,j})} \quad (13)$$

针对每个类别具体分类的效果, 采用召回率 Recall 进行评估。每个类别的召回率通过计算检测到的阳性样本与正确阳性样本的比例来获得:

$$Recall = \frac{P_{i,i}}{\sum_{j=1}^L P_{i,j}} \quad (14)$$

其中, L 表示标签数; P 为混淆矩阵, 尺寸为 $L \times L$; $P_{i,j}$ 表示测试样本中属于类别 i 的样本被错分为类别 j 的样本数目; 测试样本总数 $M = \sum_i^L \sum_j^L P_{i,j}$ 。

3.3 参数设置

1) 阴影区域

本文根据文献 [28] 中皮尔逊系数的优化方法, 将式(9)中的参数 a 和 b 设置为 0.01。根据 3D CNN 对在不同参数条件下增强的高光谱图像的分类精度, 迭代次数 n 设置为 11。在该参数条件下, 图像数据在第一波段增强前后的效果图如图 11, 增强前后数据的分类精度如表 1。

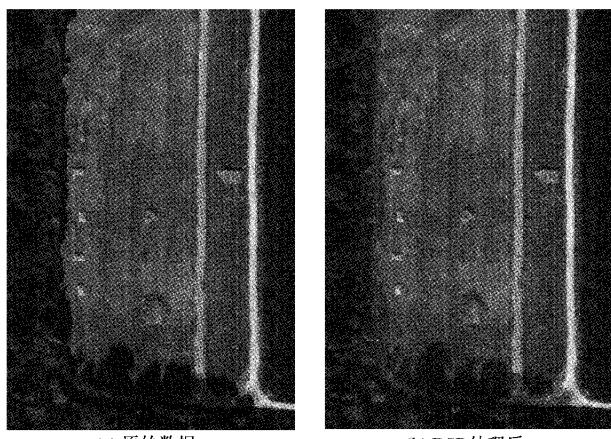


图 11 HYDICE 增强前后对比

表 1 HYDICE 数据集分类精度

数据	原始数据	DSR 增强后
OA/%	96.48	97.14

2) 嵌入注意力机制的卷积神经网络

本文采用的模型结构如图 5, 参数配置如表 2 所示。

表 2 参数设置

参数	设置
学习率	0.001
优化器	Adam
迭代次数	100
损失函数	categorical_crossentropy

实验中主成分的数为 10, 训练集和测试集比例设置为 1 : 4, 空间邻域大小为 11×11 。CA 模块和 SA 模块的压缩比 r 根据网络结构设置为 2。

4 实验结果及分析

为验证动态随机共振在阴影区域图像信息表达能力的提升及分类任务的积极影响, 在 Hydice 数据集上针对阴影部分进行了处理。通过对该数据集增强前后在第一

维度的灰度图像进行了显示从而实现视觉上的直观评估,又通过增强前后的数据集在3DCNN上的总体分类精度进行了对比,如图11和表1。对比图11中的(a)、(b)两图可以看出,位于图像左侧和下方的树木阴影区域,在该算法的作用下,亮度相较之前有所提升,尤其位于右下角较亮区域的交叉口,路面信息也更清晰,而表1中的总体分类精度0.66%的增幅也进一步验证了该方法在图像增强和

分类精度提升中的有效性。

为测试所提嵌入卷积注意块分类方法的性能,通过2DCNN及嵌入GAB(global attention block)、CBAM注意力块的2DCNN,3DCNN及嵌入GAB、SE、DA(dual attention)和ECA注意力块的3DCNN作为对比方法进行实验。表3~5及图12~14给出了各数据集在不同评价指标下的分类结果精度和分类结果。

表3 HYDICE分类结果

编号	名称	样本数量	2DCNN	3DCNN	2DCNN-GAB	3DCNN-GAB	2DCNN-CBAM	3DCNN-SE	3DCNN-DA	3DCNN-ECA	本文方法
1	草	33 184	0.99	0.99	0.99	0.99	0.99	0.99	0.99	0.99	0.99
2	树	10 850	0.96	0.98	0.96	0.98	0.95	0.97	0.98	0.98	0.98
3	路	3 376	0.96	0.97	0.96	0.98	0.95	0.97	0.97	0.97	0.97
4	阴影下的路	1 686	0.41	0.87	0.55	0.86	0.57	0.85	0.86	0.84	0.87
5	阴影下的草	323	0.82	0.96	0.86	0.93	0.86	0.95	0.93	0.90	0.95
6	目标1	537	0.78	0.84	0.81	0.88	0.84	0.89	0.88	0.89	0.92
7	目标2	514	0.69	0.61	0.73	0.66	0.67	0.63	0.59	0.66	0.68
8	目标3	4 135	0.87	0.9	0.88	0.9	0.85	0.88	0.90	0.89	0.92
OA/%			95.416	2	97.027	7	95.408	8	97.104	7	97.436 1
AA/%			83.779	0	88.182	9	84.257	3	89.672	9	91.004 5
Kappa/%			92.103	2	94.847	1	92.088	8	95.013	8	95.582 5

表4 Indian pines分类结果:

编号	名称	样本数量	2DCNN	3DCNN	2DCNN-GAB	3DCNN-GAB	2DCNN-CBAM	3DCNN-SE	3DCNN-DA	3DCNN-ECA	3DCNN-CBAM	
1	苜蓿	46	0.97	1.00	0.97	1.00	0.95	1.00	1.00	1.00	1.00	
2	非耕犁-玉米地	1 428	0.98	0.97	0.99	0.91	0.99	0.97	0.95	0.98	0.99	
3	幼苗玉米地	830	0.99	1.00	1.00	0.98	0.99	0.99	0.96	0.99	1.00	
4	玉米	237	0.99	0.99	1.00	0.86	0.99	0.99	0.99	0.99	0.99	
5	草地-牧场	483	1.00	0.96	0.99	0.98	0.99	0.97	0.95	0.99	0.98	
6	草地-树木	730	0.97	1.00	0.99	0.99	1.00	1.00	0.99	1.00	1.00	
7	草地-已修剪	28	0.95	1.00	1.00	1.00	0.91	1.00	1.00	1.00	1.00	
8	干草-料堆	478	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	
9	燕麦	20	0.94	0.56	0.88	0.67	0.75	0.62	0.94	0.94	0.88	
10	非耕犁-大豆地	972	0.98	0.97	0.97	0.98	0.97	0.99	0.98	0.99	0.99	
11	幼苗-大豆地	2 455	0.99	0.99	0.99	0.99	0.99	1.00	1.00	1.00	1.00	
12	大豆地-已修剪	593	0.95	0.94	0.95	0.92	0.95	0.95	0.97	0.96	0.95	
13	小麦	205	1.00	1.00	0.99	1.00	0.99	1.00	1.00	1.00	1.00	
14	木材	1 265	1.00	1.00	1.00	1.00	0.99	1.00	1.00	1.00	1.00	
15	建筑-草-树木-机器	386	1.00	0.99	0.99	0.93	0.99	0.97	1.00	1.00	1.00	
16	石钢塔	93	0.97	0.99	0.96	0.98	1.00	0.97	0.96	0.97	0.97	
OA/%			98.484	4	98.585	4	98.780	5	99.097	6	98.695	1
AA/%			98.079	4	92.481	4	97.896	1	98.419	5	96.571	7
Kappa/%			98.670	7	98.385	5	98.609	4	98.970	6	98.511	4
			98.483	2	97.995	5	98.483	2	97.995	5	99.123 8	99.109

表 5 Pavia University 分类结果

编号	名称	样 本数量	2DCNN	3DCNN	2DCNN- GAB	3DCNN- GAB	2DCNN- CBAM	3DCNN- SE	3DCNN- DA	3DCNN- ECA	3DCNN- CBAM
1	沥青	6 631	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
2	草甸	18 649	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
3	碎石	2 099	1.00	1.00	0.99	1.00	0.99	1.00	1.00	1.00	1.00
4	树木	3 064	1.00	0.99	0.99	0.99	0.99	0.99	0.99	1.00	1.00
5	金属板	1 345	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
6	裸地	5 029	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
7	柏油	1 330	1.00	1.00	1.00	1.00	0.99	1.00	1.00	1.00	1.00
8	砖	3 682	0.99	0.98	0.99	1.00	1.00	0.99	0.99	0.99	0.99
9	阴影	947	1.00	0.99	1.00	1.00	1.00	1.00	1.00	1.00	1.00
OA/%		99.813 0	99.798 4	99.760 4	99.850 9	99.772 1	99.813 0	99.827 6	99.874 3	99.929 9	
AA/%		99.742 5	99.694 2	99.641 1	99.808 3	99.640 1	99.733 4	99.768 6	99.852 7	99.875 1	
Kappa/%		99.752 2	99.732 8	99.682 5	99.802 5	99.697 9	99.752 1	99.771 4	99.833 5	99.907 1	

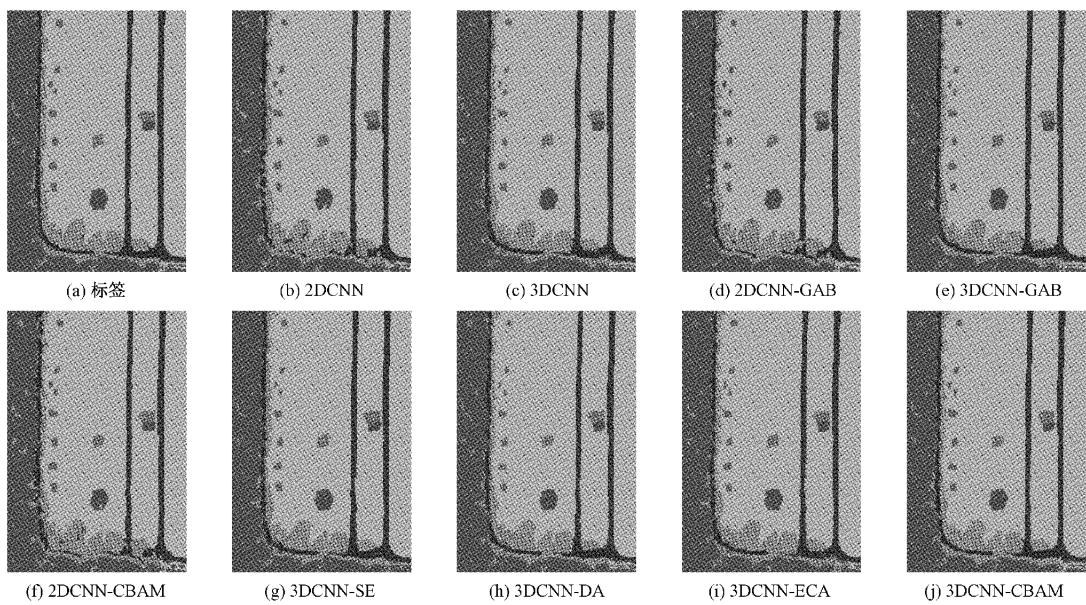


图 12 HYDICE 分类假彩色图

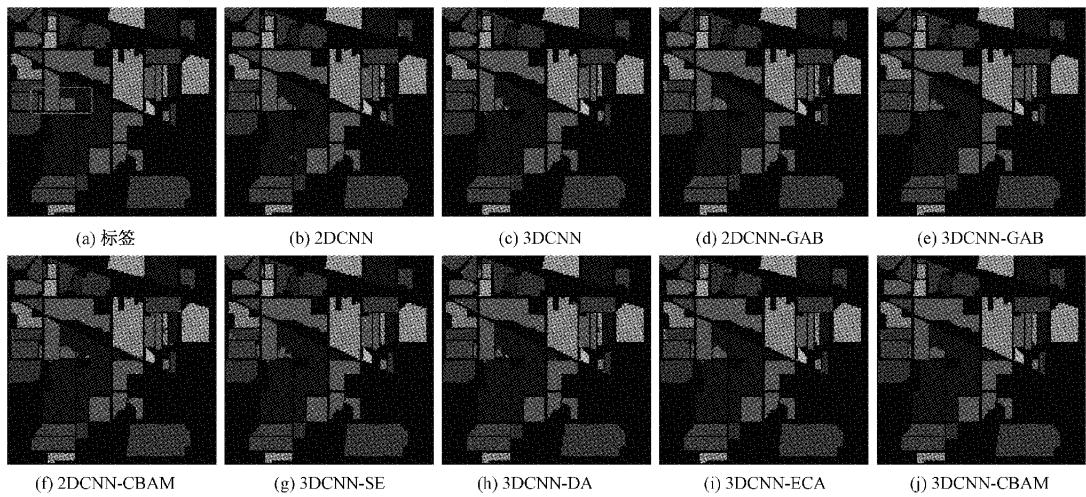


图 13 Indian pines 分类假彩色图

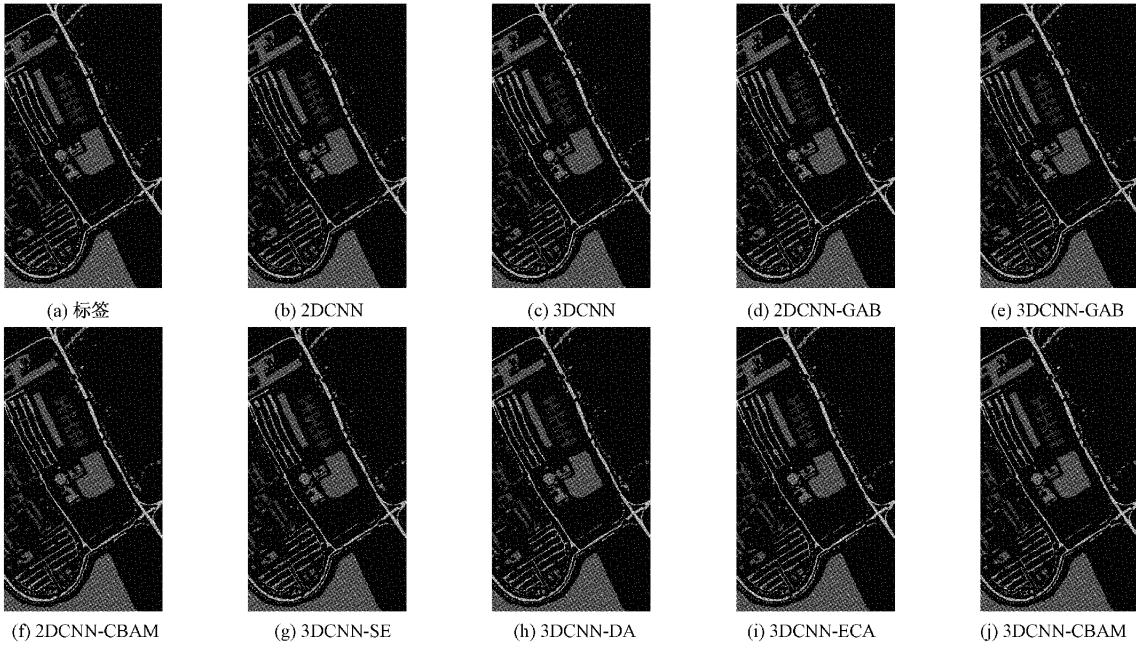


图 14 Pavia University 分类假彩图

综合对比表 3~5,本文所提方法在增强后的 Hydice 数据集、Indian Pines 及 Pavia University 三个数据集上的总体精度分别达到了 97.4361%、99.2125%、99.9299%,整体优于其他所有分类方法。本文方法在 Hydice 数据集上相较于 GAB、SE、DA 和 ECA 注意力模块的网络,精度分别高 0.3314%、0.4615%、0.5475%、0.3754%。针对 3DCNN 的分类方法,加入 CBAM 之后对 Hydice、Indian Pines 和 Pavia University 的分类精度取得了明显提升,分别为 0.4084%、0.6341% 和 0.1315%,证明引入 CBAM 模块的 3DCNN 网络具有更好的特征提取效果和更好的网络分类性能。

如表 3 所示的对 Hydice 数据集的分类结果,3D CNN 在 OA、AA 和 Kappa 中的分类精度分别比 2D CNN 高 1.61%、4.40% 和 2.74%,结合图 12(b)和(c)也可以看出,3DCNN 可以准确地检测到更多属于“阴影下道路”的像素,这说明 3DCNN 能够更加有效提取特征进行分类。而本文方法相对其他结合注意力模块的方法,在对“阴影下道路”进行分类时被标记为该类别的杂乱的像素点更少,准确度也更高。与 3DCNN 相比,本文方法的 OA、AA 和 Kappa 分别增加了 0.41%、2.82% 和 0.74%,表明 CBAM 注意力模块的加入显著提高了分类性能。其中,AA 的增幅约为 3%,与相同 3DCNN 结构下嵌入其他注意力模块的方法相比,本文方法分类精度都明显高于其他方法。综合观察图 12 中的(a)、(c)和(j)以及表 3,对右下角“树”的标签,CBAM 模块的加入可以保持 3DCNN 对其他类别较好的分类效果的同时,提高对小区域像素的分类效果,针对目标 1、2 的分类精度也显著提高,分别达到 8% 和 7%。在 8 个类别中的 5 个类别上所提方法都能达到最好的分类

效果,其中,对目标 1 和目标 3 的分类效果明显更好,相对其他方法对该类别不超过 0.9 的分类精度,本方法在两类别上都能到 0.92,其他方法只能在较少类别上表现更好。

通过观察各方法对两公共数据集的分类结果如表 4 和 5,本文中提出的方法相对 3DCNN 对 Indian Pines 及 Pavia University 在 OA、AA、Kappa 系数三个指标上的提升分别为 0.6341%、5.9133%、0.7243% 和 0.1315%、0.1809%、0.1743%,进一步验证了本文方法在不同数据集上都能表现出良好的分类性能,具有广泛适用性。GAB、ECA 等注意力模块的加入能够对 3DCNN 方法的分类性能实现一定程度上的改进,分别为 0.3852% 和 0.6463%,证明了注意力机制在分类网络模型应用中特征提取能力的提升。同时,SE 和 DA 的性能没有明显的影响,说明 GAB、SE、DA 等不同注意力块在该任务中的性能有所差异。在分类精度上本文方法与嵌入 ECA 模块方法的精度相当,但由于本文方法能够在 3 个数据集上都取得很好的分类效果,且在 Hydice 数据集上明显比 ECA 提升效果显著,因此本文方法在适用性上更有优势。

相较于 2DCNN,CBAM 模块在 3DCNN 分类性能上的提升更为明显。与 CBAM 对 2DCNN 总体分类精度仅在 Indian Pines 数据集上提升 0.2% 左右相比,其在 3DCNN 上对 Hydice 和 Pavia University 分类的总体精度提升分别为 0.4084%、0.6341%,提升效果较明显,这表明结合通道注意和空间注意的 CBAM 模块能够在 3DCNN 综合提取三维特征的优势中更好地发挥作用。

综合观察图 12 和 13 中标签数据和各方法分类结果,本文方法的分类精度更高,各类别像素能够更高程度的被检测出来,且具有更少的杂乱的误分像素点,图 12 中通过

观察标记为阴影区域的路的类别更为明显,针对图 13 以各方法对标签(a)中边框所标记区域的分类效果对比最为明显,而图 14 中整体分类精度较高,总体差异不明显,而整体分类效果可通过数据表 5 中的本文方法皆高于其他算法的分类精度数据得以验证。

实验表明,本文方法能够利用动态随机共振理论对图像阴影区域的信息表达能力进行增强,并进一步促进分类效果的提升,且所提出的嵌入卷积注意的 3DCNN 分类网络能够在 3 个数据集上均能更精细化地对目标进行分类,关注更为重要的特征,提升网络性能和分类精度,证明了本文方法的有效性。

5 结 论

针对当前高光谱图像的分类方法的不足,本文在两个角度对目前常用的分类方法进行了补充和改进。一方面通过动态随机共振理论利用噪声对常被忽视的信号强度较弱的阴影区域进行增强,提高信息的表达能力,从而提升分类效果;另一方面提出了嵌入注意力机制的卷积神经网络,通过 CBAM 注意力模块对 3D CNN 提取的高层特征从空间维和通道维分别提取特征的重要性程度,选择和重新标定对任务更为关键的特征,从而实现分类精度的提高。最后,在真实的高光谱图像数据 HYDICE 上对方法性能进行了测试,实验表明:动态随机共振的应用能够有效提升阴影区域的表达能力,提高分类效果;为进一步验证分类方法性能,在 Hydice 数据集的基础上引入了 Pavia University 与 Indian Pines 两个公开数据集,结果表明,本文提出的方法在 OA、AA 和 Kappa 系数等不同评价指标下都具有更高的分类精度,表现更好。

本文所提方法在一定程度上提高了模型的分类性能,但是在训练时间上及在前期的数据增强处理上还可以进一步的改进优化,更充分地利用高光谱图像数据的空间光谱特征,从而进一步提高网络的分类性能。

参 考 文 献

- [1] 叶珍,白璘,何明一. 高光谱图像空谱特征提取综述[J]. 中国图象图形学报, 2021, 26(8): 1737-1763.
- [2] 安庆,程耀瑜,管今哥,等. 燃烧火焰的动态辐射高光谱测温方法研究[J]. 国外电子测量技术, 2021, 40(12): 67-71.
- [3] 丁文清,丁林. 岩矿高光谱遥感及其在青藏高原的应用前景[J]. 地质科学, 2022, 57(3): 924-944.
- [4] 李伟,吕蒙,陈天虹,等. 高光谱图像在生物医学中的应用[J]. 中国图象图形学报, 2021, 26(8): 1764-1785.
- [5] 付涵,范湘涛,严珍珍,等. 基于深度学习的遥感图像目标检测技术研究进展[J]. 遥感技术与应用, 2022, 37(2): 290-305.
- [6] 陈彦彤,李雨阳,陈伟楠,等. 基于深度语义分割的遥感图像海面舰船检测研究[J]. 仪器仪表学报, 2020, 41(1): 233-240.
- [7] 杨明莉,范玉刚,李宝芸. 基于 LDA 和 ELM 的高光谱图像降维与分类方法研究[J]. 电子测量与仪器学报, 2020, 34(5): 190-196.
- [8] AYYAR M P, BENOIS-PINEAU J, ZEMMARI A. Review of white box methods for explanations of convolutional neural networks in image classification tasks [J]. Journal of Electronic Imaging, 2021, 30(5), DOI: 10.1117/1.JEI.30.5.050901.
- [9] 陈亮,吴攀,刘韵婷,等. 生成对抗网络 GAN 的发展与最新应用[J]. 电子测量与仪器学报, 2020, 34(6): 70-78.
- [10] 徐胜军,张若暄,孟月波,等. 融合分形几何特征 Resnet 遥感图像建筑物分割[J]. 光学精密工程, 2022, 30(16): 2006-2020.
- [11] WANG C, LIU B, LIU L, et al. A review of deep learning used in the hyperspectral image analysis for agriculture[J]. Artificial Intelligence Review, 2021, 54(7): 5205-5253.
- [12] LIU G, SU J, LI Y, et al. Aircraft detection in SAR image based on convolutional neural network and attention mechanism [J]. Systems Engineering and Electronic Technology, 2021, 43(11): 3202-3210.
- [13] 刘雪峰,刘佳明,付民. 生成对抗网络扩充样本用于高光谱图像分类[J]. 电子测量技术, 2022, 45(3): 146-152.
- [14] GHAFFARIAN S, VALENTE J. Effect of attention mechanism in deep learning-based remote sensing image processing: A systematic literature review[J]. Remote Sensing, 2021, 13(15): 2965.
- [15] 武瑞沁,陈雪勤,俞杰,等. 结合注意力机制的改进 U-Net 网络在端到端语音增强中的应用[J]. 声学学报, 2022, 47(2): 266-275.
- [16] WANG J, JIANG J. SA-Net: A deep spectral analysis network for image clustering[J]. Neurocomputing, 2020, 383: 10-23, DOI: 10.1016/j.neucom.2019.11.078.
- [17] HUANG G, GONG Y, XU Q, et al. A convolutional attention residual network for stereo matching[J]. IEEE Access, 2020, 8: 50828-50842, DOI: 10.1109/ACCESS.2020.2980243.
- [18] YANG Q, KU T, HU K. Efficient attention pyramid network for semantic segmentation[J]. IEEE Access, 2021, 9: 18867-18875, DOI: 10.1109/ACCESS.2021.3053316.
- [19] LIN B, ZHU Y, LIANG X. Heterogeneous excitation-and-squeeze network for visual dialog[J]. Neurocomputing, 2021, 449: 399-410, DOI: 10.1016/j.neucom.2021.03.104.

- [20] 刘洋,张国军.基于NSCT及RT的遥感图像阴影消除方法[J].计算机仿真,2022,39(5):465-469.
- [21] 徐炜君,刘国忠.空间域和频域结合的图像增强技术及实现[J].中国测试,2009,35(4):52-54.
- [22] 张莉,任群.基于视觉传达技术的高光谱图像去噪和复原方法[J].激光杂志,2022,43(8):155-158.
- [23] ZHOU Z, YU W, WANG J, et al. A high dimensional stochastic resonance system and its application in signal processing[J]. Chaos, Solitons and Fractals, 2022, 154, DOI: 10.1016/j.chaos.2021.111642.
- [24] YANG Y, LI F, ZHANG N, et al. Research on the cooperative detection of stochastic resonance and chaos for weak snr signals in measurement while drilling[J]. Sensors, 2021, 21(9), DOI: 10.3390/s21093011.
- [25] LIU X, WANG H, MENG Y, et al. Classification of hyperspectral image by CNN based on shadow area enhancement through dynamic stochastic resonance[J]. IEEE Access, 2019, 7: 134862-134870, DOI: 10.1109/ACCESS.2019.2941872.
- [26] 高文,肖海峰.基于动态双稳随机共振的低照度彩色图像增强[J].液晶与显示,2021,36(6):861-868.
- [27] AHMAD M, KHAN A M, MAZZARA M, et al. A fast and compact 3-D CNN for hyperspectral image classification [J]. IEEE Geoscience and Remote Sensing Letters, 2022, 19: 1-5, DOI: 10.1109/LGRS.2020.3043710.
- [28] KAVITHA M, GAYATHRI R, KEMAL P, et al. Performance evaluation of deep e-CNN with integrated spatial-spectral features in hyperspectral image classification [J]. Measurement: Journal of the International Measurement Confederation, 2020, 191, DOI: 10.1016/j.measurement.2022.110760.

作者简介

刘秋月,硕士,主要研究方向为图像处理等。

E-mail:1668127995@qq.com

刘雪峰,教授,博士,主要研究方向为图像处理、模式识别等。

E-mail:nina.xf.liu@hotmail.com

孙绍华(通信作者),讲师,博士,主要研究方向为图像处理、模式识别等。

E-mail:ss@sina.com, 734171049@qq.com