

采用双通道时间稠密网络的高光谱影像分类方法

张帆¹, 张景森², 裴昌幸¹

(1. 西安电子科技大学通信工程学院, 710071, 西安; 2. 西安电子科技大学人工智能学院, 710071, 西安)

摘要: 针对多数高光谱影像分类方法提取信息不够充分导致分类准确率不够高的问题,提出了一种双通道时间稠密网络的高光谱影像分类方法。该方法利用时间卷积网络模型提取高光谱数据的光谱特征信息,利用稠密网络模型提取高光谱影像数据的空间信息特征,然后将两个网络各自提取到的特征进行融合,最后将融合后的特征送入 Softmax 分类器进行分类。在 Pavia 大学经典数据集上进行了仿真实验,将该方法分别同传统高光谱影像分类方法、单空间信息高光谱影像分类方法、单光谱信息分类方法进行了对比。实验结果表明,与多种经典分类方法相比,所提出的方法可以有效地从空间结构和光谱通道提取目标的特征信息,在常用的经典数据集上分类精度可达到 99% 分,较其他方法高出 2%~3%。

关键词: 高光谱影像分类;特征提取;双通道;卷积神经网络

中图分类号: TP753 **文献标志码:** A

DOI: 10.7652/xjtuxb202004016 **文章编号:** 0253-987X(2020)04-0126-07



OSID 码

A Classification Algorithm of Hyperspectral Images Based on Double Channel Temporal Dense Network

ZHANG Fan¹, ZHANG Jingsen², PEI Changxing¹

(1. School of Telecommunications Engineering, Xidian University, Xi'an 710071, China;

2. School of Artificial Intelligence, Xidian University, Xi'an 710071, China)

Abstract: A novel classification algorithm of hyperspectral images based on double channel temporal dense network is proposed to solve the problem that most existing classification methods of hyperspectral images cannot extract sufficient information and their classification accuracy is not high enough. First, the proposed method uses temporal convolutional network and dense convolutional network to process the spectral information and spatial information of an hyperspectral image's data, separately, and then fuses the features extracted by these two networks. Finally, the merged features are sent to the softmax classifier for classification. Simulation results on the dataset of the University of Pavia and comparisons with the traditional hyperspectral image classification algorithm, the spatial hyperspectral image classification algorithm and the spectral classification algorithm show that the proposed algorithm effectively extracts the features of the target from its spatial structure and spectral channel, and its classification accuracy on the classical dataset reaches 99%, which is 2% to 3% higher than those of other methods.

Keywords: hyperspectral image classification; feature extraction; double channel; convolutional neural network

高光谱影像可以通过使用卫星传感器、机载传感器和地面设备获得^[1-2]。传统的光学影像一般包含红绿蓝3个通道,而高光谱影像常具有上百个通道,包含了更多光谱段的图像信息^[3]。因此高光谱影像可以捕获可见光图像所涵盖不到的特征。高光谱影像无法通过肉眼直接识别,因此需要专业人员去标注分类。高光谱图像分类^[4]是高光谱遥感影像应用和分析中的一项重要内容,其最终目的是利用算法给数据中的每个像素点自动赋以唯一的类别标识,缓解标注人员的工作压力。近年来,国内外都针对高光谱分类问题提出了各种解决方案^[5-7]。如:文献[8]采用基于加权 K 近邻和卷积神经网络的方法将传统机器学习和深度学习结合起来提升分类精度;文献[9]利用多尺度稀疏理论对高光谱影像进行分类,并取得了不错的效果;文献[10]利用 ISODA-TA 聚类方法和高斯混合模型对高光谱影像进行聚类,然后融合分割图和原始数据图并使用支持向量机进行分类等。然而,大部分方法只关注光谱信息或空间信息,对整体信息的综合利用率较低。将光谱带压缩仅着重提取空间信息会丢失大量光谱通道特征,而仅考虑单个像素的光谱信息则会丧失区域像素点之间的关联,因而上述算法不能综合利用高光谱数据的信息,造成分类精度较低。

针对以上问题,本文提出了基于双通道时间稠密网络的高光谱影像分类方法。该方法主要有以下改进:①将面向自然图像分类的稠密卷积网络(DenseNet)^[11]运用到高光谱影像特征提取问题上;②将序列分析领域的时间卷积网络(TCN)^[12]迁移到高光谱特征提取问题上;③提出了一种新的双通道结构模型,分别采用稠密网络提取空间特征信息,时间卷积网络提取光谱特征信息,最后将特征信息融合送入 softmax 分类器进行分类。实验结果表明,本文提出的方法可以有效提高光谱影像分类的准确性。

1 DenseNets 网络

DenseNets 是 2017 年黄高等人提出的一种面向光学图像处理的神经网络^[11],该网络在特征提取上有非常强大的处理能力。本文提出的算法将 Dense Nets 用于两个通道之一的空间特征提取。

1.1 DenseNets 网络连接

为了进一步改善层之间的信息流,DenseNets 网络采用了和传统网络不同的连接方式,从任何层到所有后续层直接连接。图 1 为 DenseNets 网络连

接示意图,从图 1 中可以看到,第 l 层接收所有前面的层 $X_0, \dots, X_{l-1}$ 的特征图作为输入,第 l 层的输入表示为

$$X_l = H_l[X_0, X_1, \dots, X_{l-1}] \quad (1)$$

式中: $[X_0, X_1, \dots, X_{l-1}]$ 为第 $0, \dots, l-1$ 层中产生的特征图拼接矩阵。由于密集的连接性,所以网络结构称为密集卷积网络,这种紧密连接的直接结果是,任何网络层学习的特征图可以被后续所有网络层访问。图 1 中 H_1, H_2, H_3, H_4 包含 3 种操作^[13]:批量归一化(BN)^[14],激活函数(ReLU)^[15], 3×3 卷积神经网络层(Conv)。




图 1 DenseNets 网络连接示意图

当特征图的大小改变时,层与层之间的连接操作显然是不可行的。然而,下采样是卷积网络的一个重要组成成分,需要借助它改变特征图大小。为了在不影响层间连接的前提下使用下采样,将网络划分成多个密集块。密集块之间的层称为过渡层。过渡层具体由批处理层, 1×1 卷积层和 2×2 平均池化层组成。

虽然每个层只输出 k 个特征图,但它通常有更多的输入。 1×1 卷积可以用来减少输入特征图的数量,从而提高计算效率,这个设计称为网络的瓶颈层。仿真实验中,每个 1×1 卷积产生 $4k$ 个特征图。

1.2 增长率

如果每个函数 H_l 产生 k 个特征图,那么 l 层就有 $k_0 + k(l-1)$ 个特征图输入,其中 k_0 是输入层的通道数, k 是网络的增长率,设置很小时就可以取得较为理想的结果。因此,DenseNets 不仅保持了密集连接,而且由于 DenseNets 密集块内的网络层很窄,每层输出的通道数较少,所以和现有的网络体系结构相比,它简化了网络训练参数。

1.3 压缩

如果过渡层学习的参数太多,会导致密集块之间差异过大,因此减少过度层输出的特征图数量,可

以使模型变得更为紧凑。假设密集块包含 m 个特征图,特征图经过过渡层后,输出 θm 个特征图,其中 $0 < \theta \leq 1$ 被称为压缩因子。当 $\theta = 1$ 时,特征图经过过渡层后数量保持不变。对于 $\theta < 1$ 的 DenseNets 称为 DenseNet-C,在仿真实验中设压缩因子为 $\theta = 0.5$ 。

2 TCN 网络

采用时间卷积网络(TCN)作为序列分析模型的优点主要有 2 个:①卷积网络层层之间有因果关系,TCN 不会遗漏历史信息或提前处理未来数据,相较于同类模型中的 LSTM^[16],虽然它也有记忆门,但也无法完全的记得所有的历史信息,而该信息一旦无用就会逐渐被遗忘;②TCN 架构可以伸缩自如的调整成任何长度,并可以根据输出端需要几个接口就映射成对应的样子,非常灵活。该网络作为双通道中的序列通道,用于提取高光谱数据的光谱信息特征。

2.1 TCN 的序列模型

序列模型的作用是,可以根据一个输入的已知序列去评判未来的某个时间点 t 上什么样的输出出现更合适。假设序列模型的输入为 $x_0, x_1, x_2, \dots, x_T$,输出为 $y_0, y_1, y_2, \dots, y_T$,那么序列模型的学习目的就是获得一个映射 f ,可以根据输入序列产生对应的输出序列,表达式如下

$$y_0, y_1, y_2, \dots, y_T = f(x_0, x_1, x_2, \dots, x_T) \quad (2)$$

得到预测结果后,需要对应的一个评判机制去评价预测结果的好坏,并基于这个结果去训练整个模型,也就是对应的目标函数,训练采用的方法是经典的梯度下降和反向传播,可表示为

$$\text{minimum}\{L(y_0, y_1, y_2, \dots, y_T), \\ f(x_0, x_1, x_2, \dots, x_T)\} \quad (3)$$

2.2 因果卷积

TCN 网络的设计基于 2 个原则:①网络产生与输入相同长度的输出;②未来信息不会用于过去的训练。为了实现第 1 点,TCN 使用 1D 全卷积网络架构,其中每个隐藏层与输入层的长度相同,使用 0 填充(卷积核大小为 1)以使后续层保持与先前层相同的长度。要达到第 2 点,TCN 需要利用因果卷积,其中时间 t 的输出仅与来自前一层中的时间 t 和更早的历史信息。这种结构带来了一个非常严重的缺点,为了获得长的有效历史尺寸,TCN 需要一个极深的网络或非常大的滤波器。为此 TCN 采用了膨胀卷积这一策略。

2.3 膨胀卷积

TCN 采用膨胀卷积来解决反向训练的问题,图 2 为膨胀卷积结构的示意图。其中 d 是扩张系数, k 是滤波器大小。膨胀相当于在每两个相邻滤波器之间引入固定步长。当 $d = 1$ 时,膨胀卷积变为一般的卷积,而使用较大的扩张系数时,顶层的输出就能够接收到更广泛的输入,从而有效地扩展卷积层的感受域。




图 2 膨胀卷积结构示意图

3 基于双通道时间稠密网络的高光谱影像分类方法

双通道网络是一种很经典的结构,在高光谱领域上也有很广泛的应用,多数结构或是直接将 2 种卷积神经网络拼接^[17],或是重复运用同一种网络^[18],并不能很好地提取高光谱数据的空间特征和光谱特征。

为此,本文建立了基于双通道时间卷积稠密网络的高光谱影像分类模型,将稠密网络处理空间信息的能力和时序卷积网络针对序列问题分析的能力引入高光谱分类问题中。模型的 2 个通道分别为经过细致设计的稠密网络和时序卷积网络,前者会从输入中提取高光谱数据的空间特征,后者会从输入中提取高光谱数据的光谱特征,2 种特征并非简单拼接组合,而是送入融合层进行深度处理,最终将既包含空间特征又包含光谱特征的综合特征送入分类层。本文所提模型结构如图 3 所示。

整体模型分为两个通道,通道 1 由稠密网络 DenseNets 构成,该通道接收降维后的高光谱数据块,主要进行空间域特征的提取;通道 2 由时序卷积网络 TCN 构成,该通道接收包含全光谱信息光谱序列,主要进行光谱域的特征提取。两者分别从自己的输入 1 和输入 2 中提取特征 1 和特征 2,提取




图 3 双通道时间稠密网络的高光谱影像分类模型框架

到的特征会在融合层进行融合,最终输入 Softmax 层得到分类结果。

通道 1 的具体结构为 DenseNets 结构如图 4 所示,输入是高光谱影像中一个像素点的 $K \times K \times B$ 邻域, $K \times K$ 是空间邻域的大小,在深度学习中又称为空间感受野, B 是光谱频带的数量。仿真实验中 K 取 32、 B 取 3。DenseNets 包含 2 个密集块,每个块都有 7 层。在进入第一密集块之前,对输入图像执

行 16 输出通道的卷积。卷积层的卷积核大小为 3×3 ,输入的每一边都被填充一个像素以保持特征图的大小不变。特征图从密集块输出后,使用卷积核大小为 1×1 的卷积和 2×2 平均池化作为 2 个连续密集块之间的过渡层。在第 2 个密集块之后,采用一个全局平均池化,之后送入全连接层,输出一个 256 维的特征向量。2 个密集块中的特征图的大小分别是 32×32 像素、 16×16 像素,增长率为 12。

通道 2 的结构为 TCN 结构如图 5 所示,输入是高光谱图像中一个像素点的 $1 \times 1 \times B$ 光谱序列, B 保持原有的光谱带数量不改变。TCN 每层的输出通道数为 25,膨胀卷积核大小为 7,膨胀系数分别为 4、2、1,每层边缘采用 SAME padding 方式保持特征图的大小不变。层与层之间采用 BN 操作进行批处理,最后输入全卷积层,将特征图映射为 256 维的特征向量 F_2 。




图 4 通道 1 结构




图 5 通道 2 结构

在特征融合层,将 2 个 256 维的特征向量 F_1 和 F_2 合并成 512 维的特征向量,然后用卷积核为 1×1 的卷积层进行融合处理,再用全卷积层将其映射成维度为类别数的特征向量,最后送入 Softmax 进行

分类。

网络的损失函数为分类问题中经典的交叉熵损失函数

$$L = - \sum_{j=1}^T y_j \log s_j \tag{4}$$

式中: S 为 Softmax 分类器的输出; y 为真实的样本标签; T 为样本数量。实验时学习率为 0.001,迭代次数为 100,每个批次大小为 32。

4 实验结果分析


在意大利 Pavia 大学数据集上进行了测试。Pavia 大学数据集的大小为 610×340 像素,空间分辨率为 1.3 m/像素。它是 2003 年用 ROSIS-03 传感器在意大利的帕维亚城拍摄所得到的。Pavia 大学数据集是高光谱领域的经典数据集,非常具有代表性,是高光谱领域实验的常用数据集。

为了显示本文方法的高效性,将本文方法与其他 5 种方法进行对比分析。这 5 种方法分别是:基

于 RBF 核函数的支持向量机(SVM)方法(SVM-RBF)^[19]、利用 PCA 降维的卷积神经网络方法(CNN-PCA)^[20]、基于 3D-CNN 的高光谱影像分类方法(3D-CNN)^[21]、基于 DenseNets 的高光谱分类方法(DenseNets)及基于 TCN 的高光谱影像分类方法(TCN)。第 1 种是经典的 SVM 方法,后 2 种是基于现在非常流行的深度学习的,最后 2 种是框架中包含的 2 种网络的独立测试,因此与这 5 种方法进行效果对比很有意义。



(a)SVM-RBF($P_{OA}=95.17\%$) (b)CNN-PCA($P_{OA}=95.32\%$) (c)3D-CNN($P_{OA}=97.89\%$)



(d)DenseNets($P_{OA}=98.43\%$) (e)TCN($P_{OA}=91.93\%$) (f)本文方法($P_{OA}=99.24\%$)

图 6 本文方法与其他 5 种方法对 Pavia 大学数据集分类的结果比较

注图更为清晰,噪点更少,各类边缘清晰。在表 1 中同样可以看出本文方法的有效性。其中:SVM-RBF 和 CNN-PCA 方法效果较差,这是因为该方法仅考虑到光谱信息;3D-CNN 方法的总体精度高出前两者 2%,这是由于它加入了二维的信息空间,实现了空谱联合提取高光谱的图像特征,但是 3D-CNN 用 3D 卷积结构的同时提取空谱信息,提取特征的能力不够,导致其结果不如本文提出的方法。本文方法中的 DenseNets 和 TCN 单独进行分类时,DenseNets 取得了较好的效果,单独用 TCN 则效果非常差。总体来说,本文提出的方法在 Pavia 大学数据集上取得了最好的效果,整体精度、平均精度和卡帕系数

在高光谱领域训练数据常取 5%~10% 不等,本文方法因可同时提取双通道特征,所以仅需少量数据即可收敛。对 Pavia 大学数据集随机选取 5% 的样本作为训练集,余下的作为测试集。对比指标采用整体精度 P_{OA} 、平均精度 P_{AA} 和卡帕系数 K 。

4.1 Pavia 大学数据集的实验结果与分析

Pavia 大学数据集实验分类结果如图 6 所示,具体分类精度对比结果如表 1 所示。

从图 6 结果可以看出,本文提出的方法分类标

都非常高。
实验运行在 Ubuntu 14.04 系统上,搭载 2 个 1080ti GPU,本文提出方法的运行时间和其他对比方法的运行时间如表 2 所示。由表 2 可见:CNN-PCA 方法网络结构简单,虽然其识别准确率不高但是运行速度是最快的;本文所提出方法仅比 CNN-PCA 方法落后 4.15 s 位列第 2;单独使用 DenseNets 或 TCN,为了达到较高的识别准确率都需要更深的网络层级,所以缩短了运行时间;3D-CNN 方法因为要使用 3D 卷积层,运行时间相对较长,为 51.23 s;SVM-RBF 为传统机器学习分类方法,运行时间是最长的。

表 1 各类方法在 Pavia 大学数据集上的分类精度 %

类别及分类 效果指标	分类精度					
	SVM-RBF	CNN-PCA	3D-CNN	DenseNets	TCN	本文方法
0	96.40	95.80	98.61	99.55	91.59	98.86
1	98.65	98.44	97.24	99.96	97.72	100.00
2	87.61	83.19	97.15	90.31	71.13	93.38
3	98.26	83.36	98.06	96.59	88.18	97.73
4	100.00	97.85	100.00	99.26	99.35	99.53
5	84.09	91.52	100.00	97.15	85.03	100.00
6	79.28	98.66	99.83	95.24	85.90	100.00
7	95.05	93.56	99.84	98.28	85.10	93.32
8	99.30	88.25	89.01	94.48	100.00	98.89
整体精度	95.17	95.32	97.89	98.43	91.93	99.24
平均精度	93.19	92.71	97.42	96.70	89.33	98.64
卡帕系数	93.55	93.76	97.22	97.80	89.25	99.00

表 2 各类方法在 Pavia 大学数据集上的运行时间

方法	SVM-RBF	CNN-PCA	3D-CNN	DenseNets	TCN	本文方法
运行时间/s	134.31	18.89	51.23	25.41	29.51	23.04

5 结 论

本文通过分析空域和谱域的高光谱数据特点,提出了一种双通道时间稠密网络的高光谱影像分类方法,给出了从数据处理、网络结构、训练方法等完整的方法流程,并通过一系列实验证明了方法的有效性。本文方法的优势有 2 个:一是提出了一种双通道的网络模型,两个通道分别处理高光谱数据的光谱维和空间维,契合了高光谱影像数据、维度高、信息大量冗余和标签数据有限等特点;二是将先进的序列模型 TCN 和面向空间特征的 DenseNets 引入了高光谱影像分类问题,将它们结合起来综合提取高光谱数据的特征,使特征信息更加丰富、客观。除了本文中实验的数据集外,本文方法可面向更多高光谱数据集进行分类,如 Indian Pines 数据集和 Salinas 数据集等,在一些多通道图像中也能取得较好的分类效果。使用双通道模型进行训练会导致超参数增加,训练难度增大,找到最优的超参数将面临更大挑战,这将是未来的优化方向之一;未来还将进一步探索融合空谱信息的高光谱分类方法,用新的模型深度挖掘高光谱影像数据中的特征,获得了效果更佳的分​​类器模型。

参考文献:

[1] 焦李成,冯婕,刘芳,等. 高分辨遥感影像学习与感知 [M]. 北京: 科学出版社, 2017: 1-3.

[2] 闫敬文,陈宏达,刘蕾. 高光谱图像分类的研究进展 [J]. 光学精密工程, 2019, 27(3): 680-693.

YAN Jingwen, CHEN Hongda, LIU Lei. Overview of hyperspectral image classification [J]. Optics and Precision Engineering, 2019, 27(3): 680-693.

[3] 韩嫒莉,侯卫民,孙靖国. 基于 PCA 与协同表示的高光谱图像分类研究 [J]. 电子科技大学学报, 2019, 48(1): 119-123.

HAN Yuli, HOU Weimin, SUN Jingguo. Hyperspectral image classification algorithm based on PCA and collaborative representation [J]. Journal of University of Electronic Science and Technology of China, 2019, 48(1): 119-123.

[4] 吕飞,韩敏. 基于深度极限学习机的高光谱遥感影像分类研究 [J]. 大连理工大学学报, 2018, 58(2): 166-173.

LÜ Fei, HAN Min. Hyperspectral remote sensing image classification based on deep extreme learning machine [J]. Journal of Dalian University of Technology, 2018, 58(2): 166-173.

[5] 杨艺,韩崇昭,韩德强. 利用特征子空间评价与多分类器融合的高光谱图像分类 [J]. 西安交通大学学报,

- 2010, 44(8): 20-24.
- YANG Yi, HAN Chongzhao, HAN Deqiang. Hyperspectral image classification based on feature subspace evaluation and multiple classifier fusion [J]. Journal of Xi'an Jiaotong University, 2010, 44(8): 20-24.
- [6] 王怀警. 森林类型高光谱遥感分类研究 [D]. 北京: 中国林业科学研究院, 2018: 13-16.
- [7] ZHANG Mengmeng, LI Wei, DU Qian. Diverse region based CNN for hyperspectral image classification [J]. IEEE Transactions on Image Processing, 2018, 27(6): 2623-2634.
- [8] 付光远, 辜弘炆, 汪洪桥. 基于加权 K 近邻和卷积神经网络的高光谱图像分类 [J]. 计算机应用研究, 2018, 35(8): 306-309, 314.
- FU Guangyuan, PEI Hongjun, WANG Hongqiao. Hyperspectral image classification based on weighted-KNN and CNN [J]. Application Research of Computers, 2018, 35(8): 306-309, 314.
- [9] TARABALKA Y, BENEDIKTSSON J A, CHANUS-SOT J. Spectral-spatial classification of hyperspectral imagery based on partitional clustering techniques [J]. IEEE Transactions on Geoscience and Remote Sensing, 2009, 47(8): 2973-2987.
- [10] JI Rongrong, GAO Yue, HONG Richang, et al. Spectral-spatial constraint hyperspectral image classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 3(52): 1811-1824.
- [11] HUANG Gao, LIU Zhuang, VAN DER MAATEN L, et al. Densely connected convolutional networks [C]// Proceedings of 30th IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA; IEEE, 2017: 2261-2269.
- [12] BAI Shaojie, KOLTER J Z, KOLTUN V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling [EB/OL]. (2018-04-19) [2019-07-21]. <https://arxiv.org/abs/1803.01271>.
- [13] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Identity mappings in deep residual networks [M]// Lecture Notes in Computer Science: Vol. 9908. Berlin, Germany: Springer-Verlag, 2016: 630-645.
- [14] LOFFE S, SZEGEDY C. Batch normalization: accelerating deep network training by reducing internal covariate shift [C]// 32nd International Conference on Machine Learning. Lille, France: International Machine Learning Society, 2015: 448-456.
- [15] GLOROT X, BORDES A, BENGIO Y. Deep sparse rectifier neural networks [C]// Proceedings of the 14th International Conference on Artificial Intelligence and Statistics. Brookline, MA, USA: Microtome Publishing, 2011: 315-323.
- [16] SHI Xingjian, CHEN Zhourong, WANG Hao, et al. Convolutional LSTM network: a machine learn learning approach for precipitation nowcasting [C]// 29th Annual Conference on Neural Information Processing Systems. Red Hook, NY, USA: Neural Information Processing Systems foundation, 2015: 802-810.
- [17] ZHANG Haokui, LI Ying, ZHANG Yuzhu, et al. Spectral-spatial classification of hyperspectral imagery using a dual-channel convolutional neural network [J]. Remote Sensing Letters, 2017, 8(5): 438-447.
- [18] YANG Gefei, GEWALI U B, IENTILUCCI E, et al. Dual-channel densenet for hyperspectral image classification [C]// 38th Annual IEEE International Geoscience and Remote Sensing Symposium. Piscataway, NJ, USA; IEEE, 2018: 2595-2598.
- [19] 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.
- [20] YUE Jun, ZHAO Wenzhi, MAO Shanjun, et al. Spectral-spatial classification of hyperspectral images using deep convolutional neural networks [J]. Remote Sensing Letters, 2015, 6(6): 468-477.
- [21] LI Yang, ZHANG Haokui, SHEN Qing. Spectral spatial classification of hyperspectral imagery with 3D convolutional neural network [J]. Remote Sensing, 2017, 9(1): 67-70.

(编辑 刘杨)