

基于 3D 卷积神经网络的 PolSAR 图像精细分类(特邀)

张腊梅,陈泽茜,邹 斌

(哈尔滨工业大学 电子与信息工程学院,黑龙江 哈尔滨 150001)

摘要: PolSAR(Polarimetric Synthetic Aperture Radar)图像分类的传统方法在前期需要对数据进行特征提取,涉及较多的人为参与,且分类精度有待进一步提高。此外,在采用监督分类方法时,某些地物存在小样本问题,针对这些问题并结合 PolSAR 图像精细分类的需求,提出基于 3D 卷积神经网络的 PolSAR 图像地物精细分类方法,将传统卷积神经网络扩展为三维并将其应用于 PolSAR 图像分类中,利用 PolSAR 数据多通道特性,充分挖掘数据中的信息,提高分类性能,并采用虚拟样本扩充的方法改善某些地物的小样本情况,获得更好的分类结果。实验结果表明:3D 卷积神经网络较 2D 卷积神经网络在 PolSAR 图像地物精细分类中有较好的性能,且虚拟样本扩充方法能够有效改善小样本分类问题。

关键词: 极化 SAR; 卷积神经网络; 图像分类; 小样本

中图分类号: TN958.2 文献标志码: A DOI: 10.3788/IRLA201847.0703001

Fine classification of polarimetric SAR images based on 3D convolutional neural network(Invited)

Zhang Lamei, Chen Zexi, Zou Bin

(School of Electronics and Information Engineering, Harbin Institute of Technology, Harbin 150001, China)

Abstract: The traditional classification methods of PolSAR image generally required the feature extraction in the early stage, involving more human participation, and the classification accuracy needed further improvement. In addition, when using supervised classification method, there were sometimes small sample problems. In view of these problems and combining the requirement of PolSAR image fine classification, a PolSAR image classification method based on 3D convolution neural network was proposed. The traditional convolution neural network was extended to three dimensions and applied to PolSAR image classification, and the classification method was described in detail. Thus, the characteristics of the multichannel PolSAR image could be fully excavated and improve the classification performance. Moreover, the method of virtual sample expansion was used to improve the small sample situation of certain category and get better classification results. Experimental results showed that 3D convolution neural network could get better performance than 2D convolution neural network in PolSAR image classification and the virtual sample expansion method could effectively improve the small sample classification problem.

Key words: polarimetric SAR; convolutional neural network; image classification; small sample

收稿日期:2018-04-10; 修订日期:2018-05-20

基金项目:国家自然科学基金(61401124); 黑龙江省留学归国人员科学基金(LC2018029)

作者简介:张腊梅(1980-),女,副教授,博士,主要从事遥感图像处理 and 智能解译方面的研究。Email:lmzhang@hit.edu.cn

0 引言

极化合成孔径雷达 (Polarimetric Synthetic Aperture Radar, PolSAR) 可以实现多通道极化发射、接收, 与传统单极化 SAR 相比, PolSAR 加入了相干的极化脉冲, 能够获得更丰富的信息^[1]。作为 PolSAR 图像解译的重要组成部分, PolSAR 图像分类应用广泛。经过多年的研究, 不断有新的 PolSAR 图像分类方法出现, 大致可分为基于极化目标分解、基于统计理论、基于传统图像处理算法以及基于模式识别方法的分类这 4 种。但通常这些方法在前期需要对数据进行特征提取, 需要较多的人为参与。

卷积神经网络 (Convolutional Neural Network, CNN)^[2] 能够通过简单的非线性的多层堆叠的模型将图像等信号原始数据转化为更为抽象的特征表达, 实现对目标的精确识别及分类, 无需在分类前进行人为特征提取, 并且在特征学习过程中不需要过多的人为参与^[3]。因此, 将卷积神经网络应用于 PolSAR 图像分类中可以在减少人为干预的条件下实现准确分类。

在传统卷积神经网络基础上, 学者 Ji 等人^[4]于 2013 年针对视频行为识别的应用, 将传统 2D 卷积神经网络扩展到 3D, 将视频中连续的几帧图像结合为多个通道作为 3D 卷积神经网络的输入, 充分提取空间及时间维度上的信息。此后越来越多的学者将 3D 卷积神经网络应用于手势识别^[5]、行为识别^[6]、视听识别^[7]等。

在 PolSAR 领域中, 2016 年王海鹏等提出了使用相干矩阵的变换形式作为原始数据并结合卷积神经网络进行地物分类^[8], 之后, 在此基础上对比了 3 种尺寸的滑动窗对于分类精度的影响^[9]。此外, 2010 年 Haensch 等针对 PolSAR 数据形式, 提出了复数卷积神经网络, 并将其应用于 PolSAR 图像中进行 6 种地物的分类^[10]。2017 年张志棉、王海鹏等同样采用复数卷积神经网络进行地物分类^[11]。但从国内外研究成果来看, 在运用卷积神经网络进行 PolSAR 图像分类这方面的研究还处于起步阶段, 尤其还未曾出现将 3D

卷积神经网络应用于 PolSAR 图像分类中, 使得卷积神经网络强大的图像处理能力未能充分的在 PolSAR 图像处理领域中发挥其优势。此外, 目前在 PolSAR 图像地物分类的研究中, 地物类别普遍划分较少, 不够精细, 这对应用分类结果进行后续工作会产生一定的影响。在传统卷积神经网络基础上将 3D 卷积神经网络应用于 PolSAR 图像中, 并解决某些地物的小样本问题, 对实现 PolSAR 图像地物的精细准确分类有着重要意义。

1 PolSAR 数据表征及数据预处理

极化散射矩阵可以完全表征不同的地物类别的电磁散射特性, 散射矩阵定义为:

$$[S] = \begin{bmatrix} S_{HH} & S_{HV} \\ S_{VH} & S_{VV} \end{bmatrix} \quad (1)$$

式中: $S_{PQ}(P, Q=H, V)$ 为发射 Q 、接收 P 极化电磁波的后向复散射系数; H 和 V 分别表示水平和垂直极化, 互易介质满足 $S_{HV}=S_{VH}$ 。

为方便表述目标的散射特征, 一般将极化散射矩阵进行矢量化并获取极化相干矩阵或极化协方差矩阵, 它们也包含了全部的极化信息。

Borgeaud 基散射矢量散射矢量如下:

$$\vec{k} = [S_{HH} \quad \sqrt{2} S_{HV} \quad S_{VV}]^T \quad (2)$$

一般认为, 在区域均匀的情况下, 该矢量服从多元复高斯分布。由散射矢量 \vec{k} 即可求得协方差矩阵, 公式如下所示:

$$[C] = \langle \vec{k} \vec{k}^{*T} \rangle = \begin{bmatrix} \langle |S_{HH}|^2 \rangle & \sqrt{2} \langle S_{HH} S_{HV}^* \rangle & \langle S_{HH} S_{VV}^* \rangle \\ \sqrt{2} \langle S_{HV} S_{HH}^* \rangle & 2 \langle |S_{HV}|^2 \rangle & \sqrt{2} \langle S_{HV} S_{VV}^* \rangle \\ \langle S_{VV} S_{HH}^* \rangle & \sqrt{2} \langle S_{VV} S_{HV}^* \rangle & \langle |S_{VV}|^2 \rangle \end{bmatrix} \quad (3)$$

式中: $\langle \cdot \rangle$ 指对统计平均操作。

基于 Pauli 基的极化矢量以及极化相干矩阵分别表示为:

$$k = \frac{1}{\sqrt{2}} [S_{HH} + S_{VV} \quad S_{VV} - S_{HH} \quad 2S_{HV}]^T \quad (4)$$

$$[T] = \langle \vec{k} \vec{k}^{*T} \rangle = \frac{1}{2} \begin{bmatrix} \langle |S_{HH} + S_{VV}|^2 \rangle & \langle (S_{HH} + S_{VV})(S_{HH} - S_{VV})^* \rangle & 2 \langle (S_{HH} + S_{VV}) S_{HV}^* \rangle \\ \langle (S_{HH} - S_{VV})(S_{HH} + S_{VV})^* \rangle & \langle |S_{HH} - S_{VV}|^2 \rangle & 2 \langle (S_{HH} - S_{VV}) S_{HV}^* \rangle \\ 2 \langle S_{HV} (S_{HH} + S_{VV})^* \rangle & 2 \langle S_{HV} (S_{HH} - S_{VV})^* \rangle & 4 \langle |S_{HV}|^2 \rangle \end{bmatrix} \quad (5)$$

而极化协方差矩阵与极化相干矩阵是线性相关的,在互易的散射情况下,两者可以通过式相互转换:

$$\langle [C] \rangle = [A]^{-1} \langle [T] \rangle [A] \text{ or } \langle [T] \rangle = [A] \langle [C] \rangle [A]^{-1} \quad (6)$$

其中

$$[A] = \frac{1}{\sqrt{2}} \begin{bmatrix} 1 & 0 & 1 \\ 1 & 0 & -1 \\ 0 & \sqrt{2} & 0 \end{bmatrix},$$

$$[A]^{-1} = \frac{1}{\sqrt{2}} \begin{bmatrix} 1 & 1 & 0 \\ 0 & 0 & \sqrt{2} \\ 1 & -1 & 0 \end{bmatrix} \quad (7)$$

2 基于 3D 卷积神经网络 PolSAR 地物分类

2.1 3D 卷积神经网络原理

PolSAR 数据是多通道数据,为了充分提取数据的空间信息及通道信息,采用 3D 卷积神经网络进行训练及识别。下面,先对关键的 3D 卷积和池化进行介绍。

一般,3D 卷积神经网络由输入输出层、隐层及全连接层等组成,隐层主要指 3D 卷积层、3D 池化层,在经过一层的图像特征抽取后,最后由 softmax 层得到一个分数进行分类。每一层有许多通道,每个通道代表一种特征。对于 3D 卷积神经网络而言,卷积池化实际上是一个立体的 3D 特征块。与 2D 不同的是,3D 的特征是一组神经元以立体的形式呈现的。

2.1.1 3D 卷积原理


构造一个 3D 卷积层,首先要建立一系列的 3D 特征抽取块来扫描所有的输入,也就是 3D 卷积核。采用不同的 3D 卷积核去处理不同的特征输入块,所得到的每个特征块对应一个卷积核,最后得到多个立体特征块。然后添加偏置项和一个非线性激活函数。3D 卷积的公式表示如下:

$$v_{ij}^{xyz} = f \left(b_{ij} + \sum_m \sum_{p=0}^{P_i-1} \sum_{q=0}^{Q_i-1} \sum_{r=0}^{R_i-1} w_{ijm}^{pqr} v_{(i-1)m}^{(x+p)(y+q)(z+r)} \right) \quad (8)$$

式中: $P_i \times Q_i \times R_i$ 为卷积核尺寸; $f(\cdot)$ 为激活函数; w_{ijm}^{pqr} 为与上一层中第 m 个特征相连的卷积核在 (p, q, r) 点处的值; b_{ij} 为第 i 层第 j 个特征的偏置; v 为第 j 层 (x, y, z) 处的输出。


图 1 体现了 2D 卷积与 3D 卷积的区别。通过同一种 3D 卷积核在输入数据的 3D 立方体上有重叠

的卷积,可以得到一个 3D 立体的特征图谱。当使用多种不同 3D 卷积核对输入处理时,可以得到多种特征。相比于 2D 卷积神经网络,3D 卷积神经网络能充分利用数据的空间及通道间的信息,获得更多特征信息。




(a) 2D 卷积示意图

(a) Schematic diagram of 2D convolution



(b) 3D 卷积示意图

(b) Schematic diagram of 3D convolution



(c) 3D 卷积立体示意图

(c) Stereoscopic schematic diagram of 3D convolution

图 1 2D 卷积与 3D 卷积方式比较示意图

Fig.1 Schematic diagram of 2D convolution and 3D convolution

2.1.2 3D 池化原理

在利用 3D 卷积神经网络处理多通道 3D 数据时,为了在保留原有特征信息的情况下减少后续计算量,也会将要进行池化的区域扩展至 3D,这样在 $S_1 \times S_2 \times S_3$ 区域内的 3D 最大池化的公式为:

$$v_{x,y,z} = \max_{0 \leq i \leq S_1, 0 \leq j \leq S_2, 0 \leq k \leq S_3} (u_{x \times s+i, y \times t+j, z \times r+k}) \quad (9)$$

式中: $u_{x \times s+i, y \times t+j, z \times r+k}$ 为输入点 $(x \times s+i, y \times t+j, z \times r+k)$ 的值; s, t, r 分别表示三个方向的移动步长; $v_{x,y,z}$ 为在点 (x, y, z) 处采样后的输出值。

3D 池化使得网络在空间及通道维度上都有了一定的不变性,增加了对目标的位置、角度、尺寸等变化的适应性。

2.1.3 激活函数及权值优化方法选择

(1) ReLU 激活函数

ReLU 函数的公式如下:

$$f(x)=\max(0, x) \quad (10)$$

在卷积神经网络中,每一层稍弱的非线性能力,在层层叠加后,也会具有很强的非线性能力,并且由于稀疏特性,网络一般不需要具有很强的处理非线性不可分的机制。那么,在深度学习模型中,简单快速的非线性激活函数更为适合。ReLU 具有简单并且线性近似的非线性特征。当使用 ReLU 函数,网络的非线性部分来自于神经元的部分选择性激活。

另外,ReLU 可以减轻网络训练时的梯度弥散现象,它的激活函数梯度是 1,梯度可以很好地在反向传播中流动,训练速度得到了很大的提高。

最后,ReLU 增加了网络的稀疏性,通过使得部分神经元输出为零,减少参数间的相互依赖,从而缓解过拟合现象的发生。

因此,ReLU 激活函数特点包括:单方向的,一端饱和,更贴近脑神经元模型;使网络自行引入稀疏性;可以有效缓解梯度弥散;计算速度快。

(2) Adam 权值优

深度学习的难点主要在于训练部分,尤其是利用大量数据训练出好的模型。对于大量数据的训练、非线性模型的局部极小值等问题需要进行解决。

梯度下降算法、Momentum 算法、NAG(Nesterov Accelerated Gradient) 算法等对每个参数进行更新时均采用相同的学习率,但实际中,考虑到各参数不同的重要性,应对这些参数采用不同的学习率,使得目标函数更快的收敛。

Adam(Adaptive Moment Estimation)算法可以看作是带有动量的 RMSprop 算法,它可以动态调整每个参数的学习率,这种调整方法是利用梯度的一阶和二阶矩估计。经过偏置矫正后,学习率在每次迭代中都会有一个确定的范围,使得参数更新更为平稳。

令 $g_t = \nabla_{\theta} J(\theta)$, 其计算公式如下:

$$m_t = \beta_1 m_{t-1} + (1 + \beta_1) g_t$$

$$n_t = \beta_2 n_{t-1} + (1 - \beta_2) g_t^2 \quad (11)$$

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t}$$

$$\hat{n}_t = \frac{n_t}{1 - \beta_2^t} \quad (12)$$

$$\Delta \theta_t = -\frac{\eta}{\sqrt{\hat{n}_t + \varepsilon}} \hat{m}_t \quad (13)$$

式中: m_t, n_t 可以看作对期望 $E[g_t], E[g_t^2]$ 的估计,即对梯度的一阶和二阶矩估计; \hat{m}_t, \hat{n}_t 是 m_t, n_t 的校正,近似为期望的无偏估计。

一般,Adam 算法 β_1 的默认值为 0.9, β_2 的默认值为 0.999, ε 默认为 10^{-8} 。

Adam 算法综合了 RMSprop 算法善于处理非平稳目标以及 Adagrad 算法善于处理稀疏梯度的优点,它可以为不同参数计算不同自适应学习率,可以比较快地得到一个预估结果。

2.2 3D 卷积神经网络结构

设计初步使用的网络结构,其包含两个卷积层,两个池化层,一个全连接层及 softmax 层,具体网络结构如图 2 所示。

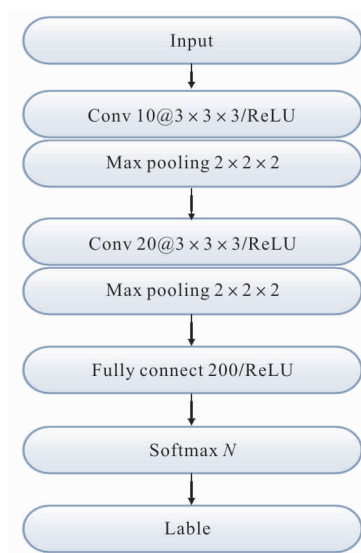


图 2 3D 卷积神经网络结构示意图

Fig.2 Schematic diagram of 3D convolution neural network structure

当采用的样本大小为 $m \times m \times n$ 时,其中 n 为通道数,为了在特征提取过程中,能对小块的每个像素进行卷积操作,首先对每个小块进行外围补零,使其

变为 $(m+2) \times (m+2) \times (n+2)$ 的小块,并对其采用 10 个 $3 \times 3 \times 3$ 的卷积核进行步长为 1 的卷积,得到 10 个大小为 $m \times m \times n$ 的特征图谱,接着采用 $2 \times 2 \times 2$ 大小的池化窗口进行最大池化,得到 10 个大小为 $(m/2) \times (m/2) \times (n/2)$ 的特征图谱;再将它们与 20 个 $3 \times 3 \times 3$ 卷积核进行卷积操作,进一步提取特征,同时采用 ReLU 函数加入非线性特性。最后,连接全连接层,每个节点的输出值经过 softmax 归一化后对应于一个类别的概率。

2.3 3D 卷积神经网络 PolSAR 地物分类

采用 3D 卷积神经网络进行 PolSAR 图像地物分类主要包括样本集的获取、网络的训练以及调用训练好的权值模型进行测试样本及待分类样本的识别分类。

对要处理的 PolSAR 图像数据进行选择,假设采用 m 个通道的数据,即 m 个初步特征图谱,将其

转换为 m 幅灰度图。采用滑动窗方式获取样本,在所选定的各类地物的训练样本块中选取 $n \times n$ 大小的滑动窗,以步长为 1 进行从左到右、从上到下的裁剪,获得最终的训练样本,该训练样本集包括 b 个 $n \times n \times m$ 的三维立体样本块,共有 a 个地物类别标签。

将所获得的训练样本集输入如图 2 所示的卷积神经网络进行训练,经过反复迭代的前向传播及反向传播过程获得训练好的权值模型。在对在进行测试及原图像进行识别分类的时,调用已获得的权值模型,判别大小 $n \times n \times m$ 的图像块所属类别,最后将该图像块中中心的像素判定为该类别。

在对原图像进行识别分类的过程中,采用与训练样本相同的获取方式,从左到右,从上到下,以步长为 1 进行 $n \times n \times m$ 大小的裁剪,并对这些大小为 $n \times n \times m$ 的图像块进行识别分类,判定每个图像块所属类别,并将该图像块中心的像素判定为该类别。

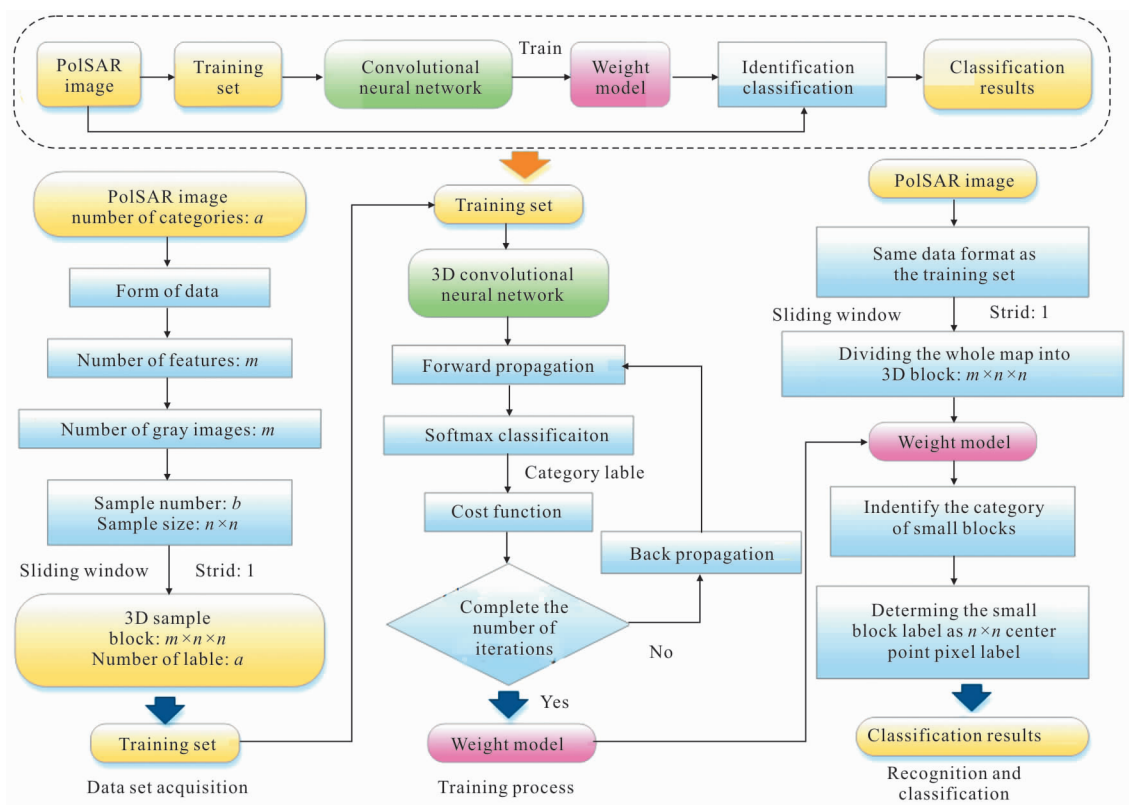


图 3 基于 3D 卷积神经网络的 PolSAR 图像分类

Fig.3 PolSAR image classification based on 3D convolution neural network

2.4 小样本问题的改善

卷积神经网络依靠训练样本进行监督训练,当训练样本十分充足时,网络能够表现出极具竞争力的性能,然而,若训练样本不够充分,则会表现出对

样本的强烈依赖性,从而无法发挥其优越性。

针对于 PolSAR 图像中存在的某些地物小样本问题,采用样本扩充的方式进行改善。样本扩充是指对原有小样本采用某种方式进行操作,合理地生成

虚拟样本,扩充样本集,从而达到提高分类器泛化能力的目的,是改善小样本分类准确率的有效手段。

目前,虚拟样本生成的方法主要有:

(1) 基于分布函数或先验知识。该方法需要对该领域有充分的研究,并且先验知识非常明显,或能够通过研究分布函数,构造合理的新样本;

(2) 基于扰动思想。是指对原有训练样本进行一定的扰动,引入的一种正则化形式,生成新的样本^[12]。

文中利用扰动思想构造小样本地物的虚拟样本。将噪声引入输入数据来提高泛化能力。即对小样本地物的训练样本进行一下几种变换。具体如下:

- (1) 旋转 10°和-10°;
- (2) 向上向右分别平移 1 个像素;
- (3) 添加高斯噪声、泊松噪声和椒盐噪声。

通过上述操作,将小样本地物的样本数量补齐至与其他地物种类样本数相同,以添加虚拟样本的样本集作为卷积神经网络输入数据。

3 实验结果与分析

3.1 实验数据

验证实验采用 UAVSAR 系统 San Francisco 地区某港口 PolSAR 图像,分辨率为 0.6 m×1.6 m,大小为 3 377×5 501 个像素点。其 Pauli 分解图如图 4(a)所示,对应的真实地物图如图 4(b)所示。该地区的地物可分为 11 种,包括浅海、海洋、森林、人造目标、道路、植被、平坦裸地、粗糙裸地及三种农田地区。



(a) Pauli 分解图 (b) 部分光学图

(a) Pauli decomposition image (b) Partial optical image

图 4 UAVSAR 极化 SAR 图像

Fig.4 PolSAR image of UAVSAR

3.2 3D 卷积神经网络分类结果

实验中直接选取极化相干矩阵元素 T_{11}, T_{22}, T_{33} 以及 T_{12}, T_{13} 及 T_{23} 的实部及虚部共 9 个通道的数据作为网络所用数据。样本大小尺寸为 14×14,除小样本地物(粗糙裸地)外,每种地物采用 8 000 个训练样本,粗糙裸地采用十分之一即 800 个训练样本,采用图 2 所示的 3D 卷积神经网络结构,训练迭代 15 个 epoch,得到的基于 3D 卷积神经网络的 PolSAR 图像分类结果如图 5 所示。




图 5 UAVSAR 数据基于 3D CNN 的分类结果

Fig.5 Classification results of UAVSAR image based on 3D CNN

可以看出,当采用 3D CNN 时图像各个类别区分明显,海洋分类结果显著改善,由海面杂波引起的错分明显减少,更为明显的是,将森林错分为人造目标的部分大大减少,森林分类的正确性提高。此外,农田 2 及农田 3 类别的杂点减少,一致性更好。因此,综合来说,3D 卷积神经网络的分类性能更佳。

3.3 分类结果对比

为了更明显地对比 3D 卷积神经网络分类效果,采用除卷积和池化层是 2D 结构外具有相同结构相同参数的 2D 卷积神经网络进行对比实验,所用网络结构如图 6 所示,实验数据基于 2D 卷积神经网络的分类结果如图 7 所示。对比图 5 可以看出,2D 卷积神经网络的分类中各个类别中存在误分杂点,尤其是浅海区域。

采用已知类别的测试样本对 3D 网络的分类性能进行了定量分析,同时也采用传统 BP 神经网络作为对比进行实验,实验中所用训练样本以及测试样本的数量、尺寸以及循环迭代次数与前面卷积神经网络实验中完全相同,实验结果如表 1 所示。




图 6 2D 卷积神经网络结构示意图

Fig.6 Schematic diagram of 2D convolution neural network structure

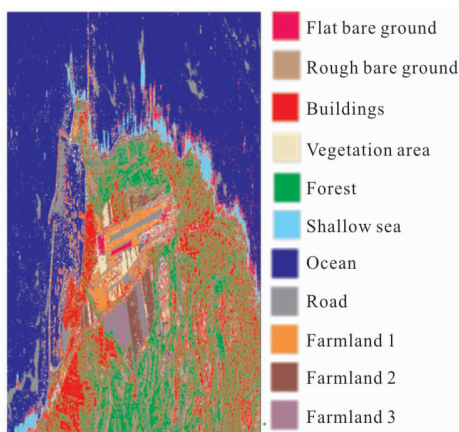


图 7 UAVSAR 图像基于 2D CNN 的分类结果

Fig.7 Classification result of UAVSAR image based on 2D CNN

表 1 不同分类方法的精度比较

Tab.1 Accuracy comparison of different classification methods

	2D CNN	3D CNN	BP neural network
UAVSAR	95.74%	97.15%	91.37%

当采用 2D 卷积神经网络，分类精度为 95.74%，3D 卷积神经网络分类总体精度较其有明显提升为 97.15%，而传统 BP 神经网络的分类精度只有 91.37%。通过对比实验分类结果可以看出，当采用 3D 卷积神经网络能够很好地利用 PolSAR 数据的多通道维度的特点，充分抽取特征，分类精度较

采用 2D 卷积神经网络，尤其是传统 BP 神经网络有较大提升。

3.4 小样本问题的改善

为了改善训练样本不足时卷积神经网络表现的强烈依赖大样本的特性，从样本扩充入手，生成虚拟样本并添加至原始样本集进行样本集扩充，从而提高分类器泛化能力。

对于所选定的小样本地物类别 7（粗糙裸地），其训练集中样本仅为其他种类地物样本数的十分之一，即 800 个样本。实验中对这些样本分别进行旋转 10°和-10°，向上向右分别平移 1 个像素，分别加入高斯、椒盐和泊松三种噪声，将生成的扰动样本加入原始样本中，最后用原始样本补齐至 8 000 个，使小样本地物数量与其余种类一致，然后再利用图 2 所示的 3D 卷积神经网络进行分类，结果如图 8 所示。




图 8 UAVSAR 小样本扩充后分类结果

Fig.8 Classification result of UAVSAR image after small sample expansion

由图 8 可以看出，经过样本扩充后，粗糙裸地、农田 2 及农田 3 的分类结果区域一致性更好，错分杂点减少，并且，未扩充样本时，在内陆部分中存在粗糙裸地错分为浅水域的情况，在样本扩充后，这部分已被正确划分为粗糙裸地，分类结果得到改善。

具体各类地物分类精度如表 2 所示，其中粗糙裸地经样本扩充后，精度由 92.25%提高至 98.45%，实验结果表明，采用虚拟样本扩充的方法可以改善由于精细分类中，地物类别划分更细而引起的个别地物训练样本数不足的情况，提高小样本地物分类正确性，改善整体分类结果，使得基于卷积神经网络

的 PolSAR 地物分类更加准确。

表 2 UAVSAR 图像小样本扩充前后分类精度

Tab.2 Classification accuracy of UAVSAR image before and after small sample expansion

Category	Original samples	Expanded samples
Flat bare ground	93.70%	95.85%
Rough bare ground	92.25%	98.45%
Buildings	94.42%	99.98%
Vegetation area	96.21%	97.84%
Forest	95.88%	97.59%
Shallow sea	95.66%	97.15%
Ocean	97.40%	98.67%
Road	99.98%	99.98%
Farmland 1	97.40%	99.18%
Farmland 2	96.82%	96.83%
Farmland 3	99.98%	99.98%
Accuracy	97.15%	98.41%

4 结 论

针对传统分类算法的需要人工提取特征造成特征不足或者冗余的弊端,结合 PolSAR 图像精细分类的需求,基于 PolSAR 图像的多通道数据特点,提出了 3D 卷积神经网络,研究了其基本思想、结构特点、工作原理以及 PolSAR 图像的数据表征形式,并应用在 PolSAR 图像精细分类中,给出基于 3D 卷积神经网络的 PolSAR 图像分类的具体方法,该方法可以利用 PolSAR 数据多通道的特性,充分挖掘数据中的信息,提高分类性能。并且为了解决精细分类中某些地物训练样本不足的小样本问题,采用虚拟样本扩充的方法进行改善,获得更好的分类结果。最后通过对比实验,证实了 3D 卷积神经网络及虚拟样本扩充的方法在 PolSAR 图像地物分类上的优越性和应用前景。

参考文献:

[1] Hara Y, Atkins R G, Yueh S H, et al. Application of neural networks to radar image classification[J]. *IEEE Transactions*

on Geoscience and Remote Sensing, 1994, 32(1): 100–109.

[2] Lecun Y, Bottou L, Bengio Y, et al. Gradient –based learning applied to document recognition [J]. *Proceedings of the IEEE*, 1998, 86(11): 2278–2324.

[3] Lecun Y, Bengio Y, Hinton G. Deep learning [J]. *Nature*, 2015, 521: 436–444.

[4] Ji S W, Xu W, Yang M. 3D convolutional neural networks for human action recognition [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2013, 35 (1): 221–231.

[5] ElBadawy M, Elons A S. Arabic sign language recognition with 3D convolutional neural networks [C]//8th International Conference on Intelligent Computing and Information Systems, 2017: 66–71.

[6] Jing L L, Ye Y C. 3D Convolutional neural network with multi–model framework for action recognition[C]//2017 IEEE International Conference on Image Processing, 2017: 1837 – 1841.

[7] Torfi A, Mehdi S. 3D Convolutional neural networks for cross audio–visual matching recognition [J]. *IEEE Access*, 2017, 5: 22081–22091.

[8] Zhou Y, Wang H P, Xu F, et al. Polarimetric SAR image classification using deep convolutional neural networks [J]. *IEEE Geoscience and Remote Sensing Letters*, 2016, 13 (12): 1935–1939.

[9] Zhou Y, Wang H P, Xu F. PolSAR terrain classification using deep convolutional networks [C]//2016 Progress In Electromagnetic Research Symposium (PIERS), 2016: 5121–5124.

[10] Haensch R, Hellwich O. Complex –valued convolutional neural networks for object detection in PolSAR data [C]// 8th European Conference on Synthetic Aperture Radar, 2011: 1–4.

[11] Zhang Z M, Wang H P. Complex –valued convolutional neural network and its application in polarimetric SAR image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 55(12): 7177–7188.

[12] Bishop C M. Training with noise is equivalent to tikhonov regularization [J]. *Neural Computation*, 1995, 7 (1): 108–116.