doi:10.6041/j.issn.1000-1298.2024.09.023

基于多特征优化的 PolSAR 数据农作物精细分类方法

郭　交[1,2]　王鹤颖[1]　项诗雨[1]　连嘉茜[1]　王　辉[3]

(1.西北农林科技大学机械与电子工程学院,陕西杨凌 712100;
2.陕西省农业信息感知与智能服务重点实验室,陕西杨凌 712100;
3.上海卫星工程研究所,上海 201109)

摘要:农作物精细分类在农业资源调查、农作物种植结构监管等诸多领域具有重要意义。极化合成孔径雷达(Polarimetric synthetic aperture radar, PolSAR)能够有效探测伪装和穿透掩盖物,提取多种散射特征信息,获取覆盖农作物生长关键物候阶段的连续时序信息,有效提升表达作物遥感特征的丰富度,在农作物分类中独具优势。但多时相和多特征的引入必然导致模型运算量剧增,不利于工程应用。针对上述问题,本文提出了一种基于多特征优化的 PolSAR 数据农作物精细分类方法,首先对 PolSAR 数据进行多种极化目标分解及参数提取以获得多个散射特征;然后使用基于栈式稀疏自编码网络和 ReliefF 优选的方法进行特征增强与优化,获取最优特征集;最后构建具有 2 个分支结构的卷积神经网络,融合不同卷积深度输出的特征,完成农作物的高精度分类。通过对单时相数据的特征分析、单时相数据初步分类实验和多时相数据不同特征集结合分类器的对比实验,证明本文所提方法能够在低维特征输入的前提下,最大程度提取不同作物之间的差异性特征,准确高效地实现对农作物的精细分类,最高分类精度和 Kappa 系数分别达到 97.69% 和 97.24%。

关键词:农作物分类;PolSAR;栈式稀疏自编码网络;ReliefF;卷积神经网络

中图分类号:S127　　**文献标识码**:A　　**文章编号**:1000-1298(2024)09-0275-11　　**OSID**:

Crop Classification Based on PolSAR Data Using Multiple Feature Optimization

GUO Jiao[1,2]　WANG Heying[1]　XIANG Shiyu[1]　LIAN Jiaqian[1]　WANG Hui[3]

(1. *College of Mechanical and Electronic Engineering*, *Northwest A&F University*, *Yangling*, *Shaanxi* 712100, *China*
2. *Shaanxi Key Laboratory of Agriculture Information Perception and Intelligent Service*, *Yangling*, *Shaanxi* 712100, *China*
3. *Shanghai Institute of Satellite Engineering*, *Shanghai* 201109, *China*)

Abstract: Crop fine classification is of great significance in many fields such as agricultural resources survey and crop planting structure supervision. Polarimetric synthetic aperture radar (PolSAR) can effectively detect camouflage and penetrate masks, extract multiple scattering feature information, obtain continuous time series information covering the key climatic phases of crop growth, and effectively enhance the richness of crop remote sensing features, which is a unique advantage in crop classification. However, the introduction of multi-temporal phases and multi-features inevitably leads to a drastic increase in model arithmetic, which is not conducive to engineering applications. In view of the above problems, a multi-feature optimization-based approach for crop fine classification of PolSAR data was proposed, which firstly carried out multiple polarization target decomposition and parameter extraction of the PolSAR data in order to obtain multiple scattering features, and then a stacked sparse self-coding network based and ReliefF preferred method was used for feature enhancement and optimization to obtain the optimal set of features, and finally a convolutional neural network with two branching structures was constructed to fuse the features output from different convolutional depths to complete the high-precision classification of crops. Through the characterization of single-time-phase data, the preliminary classification experiments of single-time-phase data and the comparison experiments of combining classifiers with different feature sets of multi-time-phase data, it was proved that the method proposed can maximally extract the differential features between different crops under the premise of low-dimensional

收稿日期:2024-04-18　修回日期:2024-06-13

基金项目:国家自然科学基金项目(U22B2015)和陕西省重点研发计划项目(2024NC-ZDCYL-05-02)

作者简介:郭交(1984—),男,教授,博士生导师,主要从事微波遥感提取地表植被信息研究,E-mail:jiao.g@163.com

feature input, and accurately and efficiently realize the fine classification of crops, with the highest classification accuracy and Kappa coefficient reaching 97.69% and 97.24%, respectively.

Key words: crop classification; PolSAR; stack sparse self-coding network; ReliefF; convolutional neural network

0 引言

农作物分类是农业监测技术的起点和枢纽,对开展农作物种植结构管理与优化、长势监测、产量预估等专题研究有重要意义[1]。遥感技术因其覆盖面广、时效性强、经济便捷等特性,在大规模监测作物种植结构方面独具优势,其数据源主要包括光学数据和微波数据 2 种。以极化合成孔径雷达(Polarimetric synthetic aperture radar, PolSAR)为代表的微波遥感能够有效探测伪装和穿透掩盖物,全天时、全天候成像,弥补了光学遥感易受云雨雾等天气条件影响的不足[2],在农作物精细分类方面有巨大应用潜力。

一般地,随着作物生长周期的推移,农作物生物外在形态和冠层率会发生明显变化,促使其在对应不同观测日期下的 PolSAR 影像中表现出不同的极化散射特性[3]。仅基于单时相 PolSAR 的原始特征不能提供足够的作物类别间物候信息差异,这限制了单时相分类研究的发展[4]。因此,为进一步提高分类精度,提升表达作物遥感特征的丰富度是必然趋势。目前主要通过增加时序和增加单时相特征量的方式提升特征丰富度。例如,SKRIVER 等[5]使用包含 11 个时相的 SAR 影像进行农作物分类,结合最大似然分类方法仍能取得 85% 以上的总体精度,显示了多时相数据用于精准分类的潜力;孙勋等[6]提取包括 Huynen 分解、Yamaguchi 分解等极化 SAR 图像的多重分解特征,利用多特征融合和集成学习的极化 SAR 图像监督分类算法对单时相 AIRSAR 数据集内地物进行分类,总体分类精度达到 89%。孙政等[7]通过多种特征提取方法,使用 3 个时相的 117 个极化特征,结合随机森林分类器,对河北省冀州市地物进行分类,总体分类精度达 92.89%。

然而,多时相和多特征的引入必然导致维数及分类模型运算量的增加,适宜的特征降维能够在提高分类精度的同时解决上述问题,避免特征冗余,减少计算时间和复杂度,利于工程应用。降低 PolSAR 特征维数的方法包括特征压缩和特征优选,前者是通过某种编码或压缩技术将原始特征映射到一个较低维度的子空间,常用方法有主成分分析(Principal component analysis, PCA)[8]、线性判别分析(Linear discriminant analysis, LDA)[9]以及人工神经网络(Artificial neural network, ANN)[10-11]等,但压缩程度过大时易造成关键信息丢失;后者则是从原始特征集中选择出最具代表性的特征子集,常用选择依据有 JM 距离[12]、可分性指数[13]、随机森林方法[14]等,但需要剔除一定信息,这可能导致模型泛化能力降低。丰富的特征提取和适宜的特征降维优化能够在减少冗余信息干扰的前提下,高效准确地建立各农作物和重要分类特征之间的对应关系,为种植结构相似的不同地区农作物分类提供参考,利于实际应用。

为了解决农作物分类中 PolSAR 数据的多特征优化问题,本文首先通过多种方法进行特征提取,然后使用基于栈式稀疏自编码网络和 ReliefF 的特征优化方法,对丰富的散射特征进行高效的低维表征,并结合具有 2 个卷积分支结构的轻量化卷积神经网络,完成作物的高精度分类。利用 Flevoland 单时相和 Indian Head 多时相 PolSAR 数据,从定性和定量角度开展特征分析,并设计不同特征集输入与分类器结合的单、多时相分类对比实验,以证明本文方法的优越性。

1 研究方法

本文方法技术流程如图 1 所示,主要包括:①对单时相数据进行特征提取,构建原始特征集。②对原始特征集进行基于栈式稀疏自编码器网络的特征压缩,以从高维数据中提取出低维有效信息。③对压缩特征集进行基于 ReliefF 算法的特征优选,构成单时相最优特征集。④若数据集包含多个时相,则

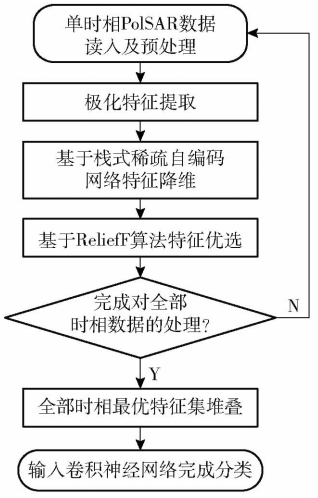

图 1 本文方法流程图

Fig. 1 Flowchart of proposed method

按照观测日期顺序排列单时相特征，构成多时相最优特征集。⑤构建卷积神经网络，输入最优特征集并对其进行训练优化，最终由该网络模型得到农作物分类结果。

1.1　特征提取

PolSAR 图像可以使用特征提取技术获取大量关于地物目标散射特征的信息，全面提取有区分度的特征对提高分类精度具有重要意义。

PolSAR 数据极化特征主要包括基于简单数学变换提取的特征和极化目标分解提取的特征两类[15]。基于简单数学变换是利用对散射矩阵 $\boldsymbol{S}$、协方差矩阵 $\boldsymbol{C}$ 和相干矩阵 $\boldsymbol{T}$ 的计算获取具有一定物理意义的特征，包括不同极化通道下的后向散射系数、极化总功率等。极化分解理论能够从数据的交叉极化相关项中挖掘隐含信息，提取更深层的极化特性，分为相干分解和非相干分解两类。现有研究表明，非相干分解适于描述散射回波部分极化、电场矢量具有随机噪声的情况，因此更适合农作物等自然目标[16]，典型方法包括 Yamaguchi 分解[17]、Freeman 分解[18]、Cloude 分解[19]、Huynen 分解[20]等。

植被指数是反映植被生长状态和分布信息的重要参数，提供了关于植被状况的定性和定量信息。以归一化植被指数（Normalized difference vegetation index，NDVI）、增强型植被指数（Enhanced vegetation index，EVI）为代表的光学遥感植被指数已广泛应用于监测环境变化、作物生长状况等领域[21]。类比光学遥感植被指数，KIM 等[22]于 2009 年提出雷达植被指数的概念，使用各个极化通道数据联合表达的特征参数识别植被区域，建立裸地和植被表面的体积土壤湿度模型，证明了该方法的优越性。马腾等[23]利用基于特征矢量分解的雷达植被指数等特征参数实现地物分类，在土地利用分类维度验证了雷达植被指数的有效性。目前常用的雷达植被指数主要有基于后向散射强度的雷达植被指数（Kim-RVI）、基于 $H/A/\alpha$ 分解计算特征值的雷达植被指数（Van-RVI）和基于 Freeman 分解的雷达植被指数（Freeman-RVI）等。表 1 给出了本文通过上述方法提取的全部特征名称、获取方法及维数。

1.2　特征优化

1.2.1　特征压缩

自动编码器（Auto-encoder，AE）是一种无监督学习算法，其主要思想是限制输出数据与输入数据之间的欧几里得距离，调整编码权重矩阵和解码权重矩阵，使输出数据 z_m 尽可能与输入数据 x_m 相

表 1　极化特征汇总

Tab.1　Summary of polarimetric signatures

特征类型	获取方法	维数
测量数据和简单计算组合的特征	$\lvert S_{HH}\rvert, \lvert S_{HV}\rvert, \lvert S_{VV}\rvert$	3
	$\lvert S_{HH}S_{HV}^*/\sqrt{\lvert S_{HH}\rvert^2\lvert S_{VV}\rvert^2}\rvert$	1
	$\mathrm{atan}(\mathrm{Im}(S_{HH}S_{VV}^*)/\mathrm{Re}(S_{HH}S_{VV}^*))$	1
	$10\lg(\lvert S_{HV}\rvert^2/\lvert S_{VV}\rvert^2)$, $10\lg(\lvert S_{VV}\rvert^2/\lvert S_{HH}\rvert^2)$, $10\lg(\lvert S_{HV}\rvert^2/\lvert S_{HH}\rvert^2)$	3
	$\frac{\lvert S_{HV}\rvert^2}{\lvert S_{HH}\rvert^2+\lvert S_{VV}\rvert^2}$, $\frac{\lvert S_{VV}\rvert^2}{\lvert S_{HH}\rvert^2+\lvert S_{HV}\rvert^2}$	2
极化目标非相干分解	Freeman 分解	5
	Yamaguchi 分解	7
	Cloude 分解	5
	Huynen 分解	9
雷达植被指数	Freeman-RVI	1
	Van-RVI	1
	Kim-RVI	1
合计		39

注：表中 S_{HH}、S_{HV}、S_{VV} 分别表示水平极化、交叉极化和垂直极化后向复散射系数，上角 * 表示取共轭复数。

等[24]。单层自编码器由编码器（Encode）、激活层（Activation）和解码器（Decode）3 部分组成，其网络结构分为输入层、隐含层和输出层，其中隐含层可以为单层或多层，如图 2 所示。

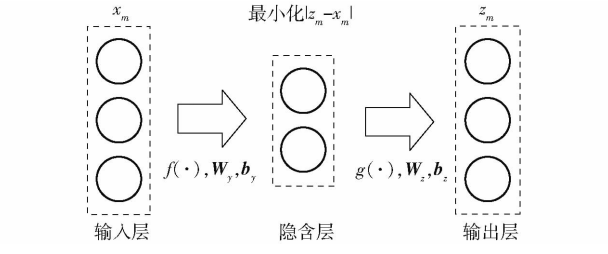

图 2　自编码器网络结构图

Fig.2　Auto-encoder network structure

自编码器可以对原始数据进行抽取表达，表达结果经内部的隐含层进行输出。输入数据 $\boldsymbol{x}$ 经过编码器操作得到隐含层特征表达 $\boldsymbol{y}$，然后经过解码器操作获得重构向量 $\boldsymbol{z}$，其中 $\boldsymbol{y}=f(\boldsymbol{W}_y^{\mathrm{T}}\boldsymbol{x}+\boldsymbol{b}_y)$，$\boldsymbol{z}=g(\boldsymbol{W}_z^{\mathrm{T}}\boldsymbol{x}+\boldsymbol{b}_z)$，式中权重矩阵 $\boldsymbol{W}_y$、$\boldsymbol{W}_z$ 与偏置系数 $\boldsymbol{b}_y$、$\boldsymbol{b}_z$ 分别是编码层与解码层的相关参数，$f(\cdot)$、$g(\cdot)$ 是自编器的激活函数，本文选用非线性 Sigmoid 函数作为激活函数，即

$$f(\cdot)=g(\cdot)=\frac{1}{1+\mathrm{e}^{-1}} \tag{1}$$

在训练中，常使 $\boldsymbol{W}_y=\boldsymbol{W}_z=\boldsymbol{W}$ 以平衡权重，简化网络结构。因此自编码器模型优化调节实际上是通过反向传播训练学习参数 $\{\boldsymbol{W},\boldsymbol{b}_y,\boldsymbol{b}_z\}$ 来最小化一个损失函数 $\psi(\boldsymbol{x},\boldsymbol{z})$，即最小化重构误差。本文中 $\psi(\boldsymbol{x},\boldsymbol{z})$ 函数定义为均方误差，即

$$\psi(\boldsymbol{x},\boldsymbol{z}) = \arg\min_{\boldsymbol{W},\boldsymbol{b}_y,\boldsymbol{b}_z} \frac{1}{m}\sum_{i=1}^{m} \| \boldsymbol{x}_i - \boldsymbol{z}_i \|^2 \quad (2)$$

式中 m——每个输入样本特征维数

同时为了防止出现过拟合,需要在损失函数中添加一个正则化项 $g(\boldsymbol{W})$,定义为

$$g(\boldsymbol{W}) = 0.5(\| \boldsymbol{W}_y \|_F^2 + \| \boldsymbol{W}_z \|_F^2) = \| \boldsymbol{W} \|_F^2 \quad (3)$$

式中 $\| \cdot \|_F$——Frobenius 范数

稀疏自编码器网络是在自编码器基础上的延伸,要求大部分节点为 0,少部分不为 0,从而具有更优的学习数据特征的能力[25]。当隐含层神经元数目过多时,通过添加额外的稀疏正则化方式,对隐含层的输出进行稀疏性约束。其中额外的稀疏惩罚项 $\boldsymbol{\Omega}$ 定义为

$$\boldsymbol{\Omega} = \sum_{i=1}^{Q} \rho \lg\left(\frac{\rho}{\hat{\rho}_i}\right) + (1-\rho)\lg\left(\frac{1-\rho}{1-\hat{\rho}_i}\right) \quad (4)$$

式中 Q——隐含层神经元个数

ρ——稀疏参数

$\hat{\rho}_i$——第 i 个神经元平均输出激活量

稀疏自编码通过限制网络的平均激活度 $\hat{\rho}_i = \rho$ 来实现其惩罚方式,$\hat{\rho}_i$ 计算公式为

$$\hat{\rho}_i = \frac{1}{n}\sum_{j=1}^{m} f(\boldsymbol{W}_i^{\mathrm{T}}\boldsymbol{x}_j + \boldsymbol{b}_i) \quad (5)$$

式中 $\boldsymbol{x}_j$——第 j 个输入样本

$\boldsymbol{W}_i$——第 i 行权值矩阵

$\boldsymbol{b}_i$——第 i 个偏置系数

n——样本数量

综上,稀疏自编码器网络损失函数为

$$\tau(\boldsymbol{W},\boldsymbol{b}_y,\boldsymbol{b}_z) = \frac{1}{m}\sum_{i=1}^{m} \| \boldsymbol{z}_i - \boldsymbol{x}_i \|_F^2 + \lambda g(\boldsymbol{W}) + \beta\boldsymbol{\Omega}(\rho) \quad (6)$$

式中 λ——正则化项权值

β——稀疏正则化项权值

栈式稀疏自编码器(Stacked sparse auto-encoder, S-SAE)是由若干串联的稀疏自编码器和一个 Softmax 分类器组成的深度学习网络,如图 3 所示,采用依次连接的方式提高网络深度,从而产生更佳的压缩效果,其训练过程分为无监督预训练和有监督微调[26]。在网络预训练过程中,栈式稀疏自编码器使用贪婪训练方法进行逐层训练,输入数据经第 1 层稀疏自编码器训练,提取隐含层特征,然后将其作为下一层稀疏自编码器的输入来获取更深层表达,依次重复,从而实现对高维散射特征更深层次的提取。最后结合标签训练样本对网络参数进行优化微调,以获取更好的数据压缩效果。具体通过在 S-SAE 网络末端添加 Softmax 分类器对降维特征进行分类,使分类结果与训练标签形成有监督训练,通过反向传播梯度下降训练方法来对网络中的参数进行再次优化调整。

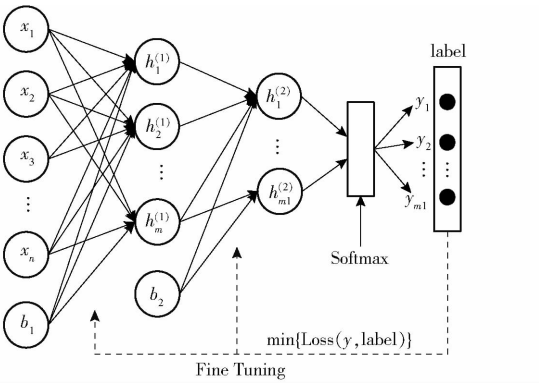

图 3 栈式稀疏自编码网络结构图

Fig. 3 Stack sparse network structure

1.2.2 特征优选

使用栈式稀疏自编码网络进行特征降维时,若压缩程度过大,易出现原始数据重要信息丢失、数据失真等问题,使得重构的数据质量下降,模型泛化能力降低,甚至导致梯度消失,模型难以收敛。为进一步有效降低特征维数,采用 ReliefF 特征优选算法进行最优特征子集构建。

ReliefF 算法于 1994 年被提出,是基于 Relief 的延伸算法。与只能解决二分类问题的 Relief 算法相比,ReliefF 算法通过将多类数据的问题转换为多个一对多问题,从而解决多类特征选择问题[27-28]。该算法利用特征区分相邻区域样本的能力计算样本与特征间的相关性并赋予每个特征权重,其基本思想为:从训练集 D 中随机抽取一个样本 R,从该样本的同类样本中寻找出 k 个最近邻样本 $H_j(C)(j=1,2,\cdots,k)$,从样本的每个不同类样本中找出 k 个最近邻样本 $U_j(C)(j=1,2,\cdots,k)$。根据 R 与所有同类样本和异类样本的距离和更新特征的权重 W_A^i,其计算公式为

$$W_A^i = W_A^{i-1} - \frac{\sum_{j=1}^{k} d_A(R,H_j(C))}{hk} + \sum_{C\neq \mathrm{class}(R)} \frac{p(C)}{1-p(\mathrm{class}(R))} \frac{\sum_{j=1}^{k} d_A(R,U_j(C))}{hk} \quad (7)$$

式中 i——当前迭代次数

A——某个分类特征

$d_A(\cdot)$——2 个样本在特征 A 上的距离差

C——样本类别 h——迭代次数

$p(\cdot)$——某类样本在训练集 D 中所占比例

$\mathrm{class}(R)$——属于 R 类别

特征权重 W_A^i 表示该特征分类能力,权重越大意味着分类能力越强,反之则分类能力越弱。图 4

给出了本文 ReliefF 算法的流程图。

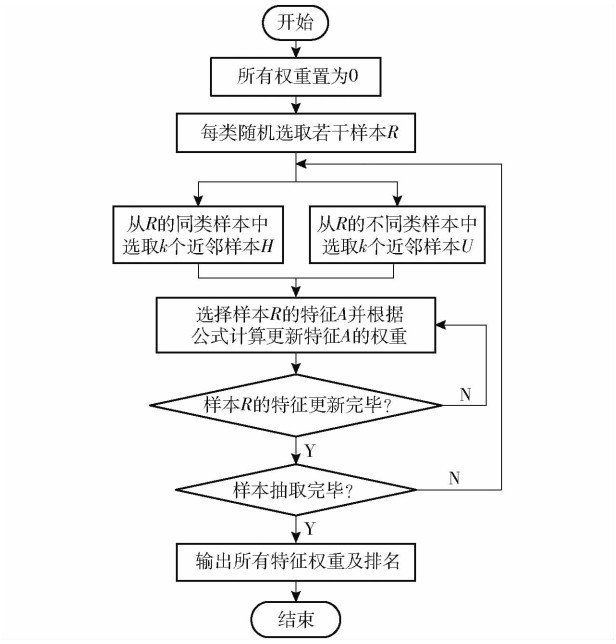

图 4　ReliefF 特征优选算法流程图

Fig. 4　ReliefF algorithm flowchart

1.3　分类方法

近年来，以卷积神经网络（Convolutional neural networks，CNN）为代表的深度学习技术发展迅速，在遥感图像分析研究中发挥重要作用，在土地覆盖分类、目标检测等问题上显示出巨大潜力。卷积神经网络用卷积运算取代了传统全连接神经网络的矩阵乘法运算，具有神经元局部连接、权重共享、池化等特性，在 GPU 并行计算能力的支持下，能够快速高效地处理包括图像在内的二维结构数据，表现出一定优势[29]。

本文设计的 CNN 网络结构及网络参数如图 5 所示，包括 4 个卷积层、1 个池化层、1 个 addlayer 层、1 个全连接层以及 1 个 Softmax 分类器。该网络具有与经典深度神经网络 GoogLeNet[30] 基本相同的分支元素，采用 2 个不同深度的卷积分支，在每个卷积操作后通过零填充操作保持输出特征大小不变，对输出特征进行批标准化 BN（Batch normlization）和 ReLU（Rectified linear units）非线性整流激活函数以激活输出特征，并将其作为下一层的输入，使用 addlayer 结构融合不同卷积深度输出的特征，在两卷积分支输出特征结合后添加平均池化层以减少全连接层训练参数数量，降低网络复杂度，使网络能够快速学习调整参数并增强分类特征。

2　研究区与数据

2.1　Flevoland 数据集

Flevoland 数据是 NASA/JPL 实验室公开的全极化机载 SAR 数据集，其研究区域位于荷兰 Flevoland 地区（52°26′45.73″N，5°33′53.67″W），于 1989 年 8 月获取，研究区概况如图 6 所示，尺寸为 750 像素 × 1 024 像素，空间分辨率为 6 m × 12.1 m。

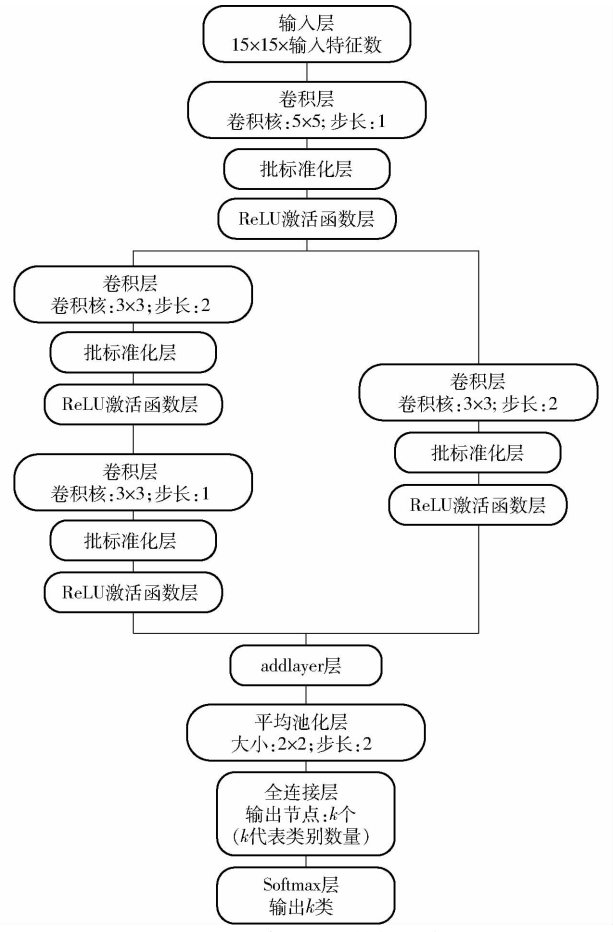

图 5　卷积神经网络结构示意图

Fig. 5　CNN classifier architecture

研究区地物种类丰富且地块面积合适，其中 15 类地物像素数量信息如图 7a 所示。用于训练和验证的地面真值数据是通过 Rapideye 光学卫星遥感影像和结合人工实地调查建立的。Flevoland 数据集作为公开源，在全极化研究中被广泛使用，适宜作为单时相数据集展开初步研究。

2.2　Indian Head 数据集

Indian Head 数据是由欧空局提供，利用 Radarsat－2 卫星系统的实测数据根据 Sentinel－1 的系统参数仿真生成，其研究区域位于加拿大萨斯喀彻温省的 Indian Head 农场（50° 53′ 18.1″ N，103°66′87.3″W）。实验数据共包括 7 个时相，采集时间为 2009 年 4 月 21 日、5 月 15 日、6 月 8 日、7 月 2 日、7 月 26 日、8 月 19 日和 9 月 12 日。研究区概况如图 8 所示，地图投影为 WGS84 坐标系，占地面积约为 9 km × 16 km。

该地区包含 176 块田地，优势作物以旱地作物为主，14 种主要作物像素数量信息如图 7b 所示。用于训练和验证的地面样本采集主要参考 Indian

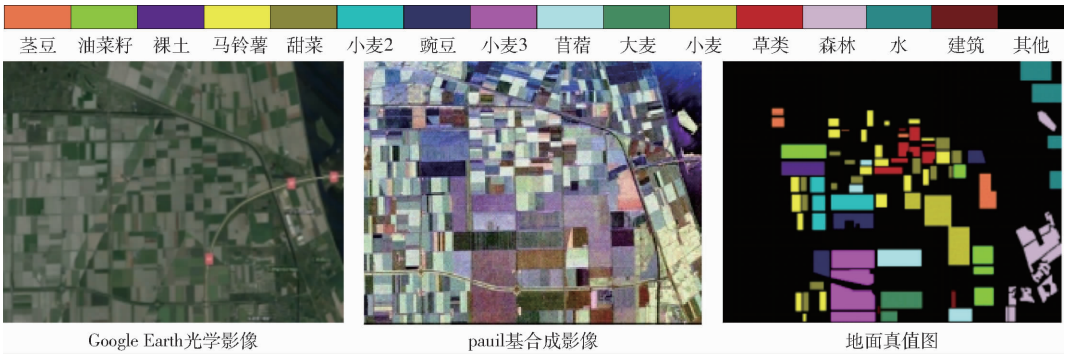

图 6 Flevoland 数据集概况

Fig. 6 Overview of Flevoland dataset

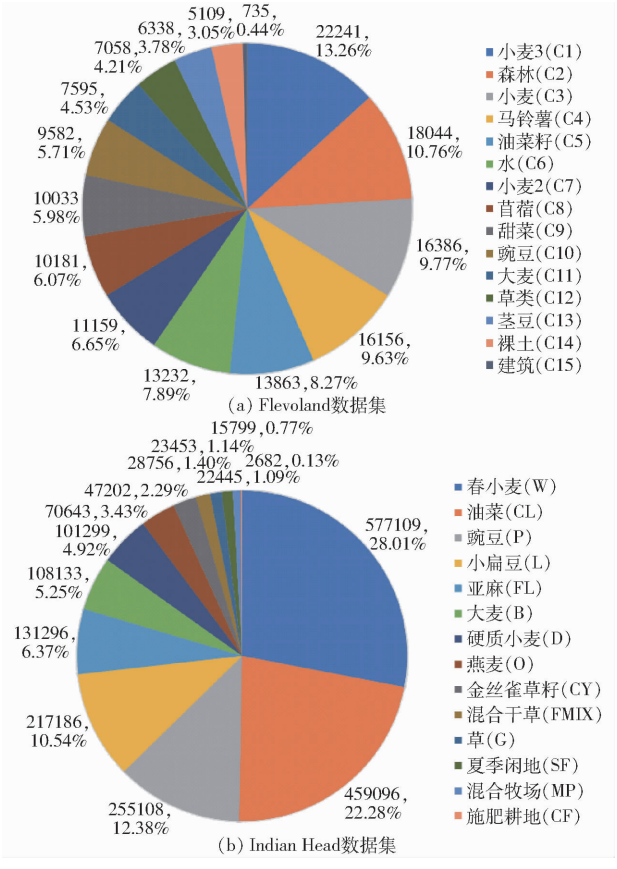

图 7 数据集地物分布信息

Fig. 7 Dataset ground feature distribution information

Head 农业研究机构(Indian Head Agriculture Research Facility, IHARF)和里贾纳大学所做工作,将高分辨率光学图像与地面调查结合进行目视判读勾画形成地面真值图。获取图像时间覆盖实验区内主要农作物从播种到收获的整个生长周期,弥补了 PolSAR 分类现有研究针对旱地作物较少的空白,适宜作为多时相数据集展开研究。

3 实验与结果分析

3.1 实验设计与参数设置

为研究本文方法(简称“SAE9 - ReliefF3”)表征农作物信息、实现农作物精细分类的能力,首先通过特征可分离性实验对所获单时相最优特征集进行定性和定量评估,然后对本文方法的单时相分类性能进行初步探索,最后结合不同分类方法进行多时相分类性能评估。

在特征压缩处理过程中,根据主成分分析(PCA)降维后的主特征累计贡献率确定降维维数。本实验中 PCA 降维后前 9 维特征累计贡献率大于 90%,因此降维维数取 9。采用结构为“39 - 20 - 9”的双层栈式稀疏自编码网络进行降维,随机选取 1% 样本作为监督训练集,对该网络进行逐层训练和优化,参照文献[9],稀疏自编码器均采用默认的稀疏参数,正则化项权值 $\lambda = 0.001$,稀疏正则化项权值 $\beta = 4$,稀疏参数 $\rho = 0.05$。

为进一步降低特征维数,减少分类模型运算量,使用 ReliefF 算法对压缩特征进行优选,通过多次实

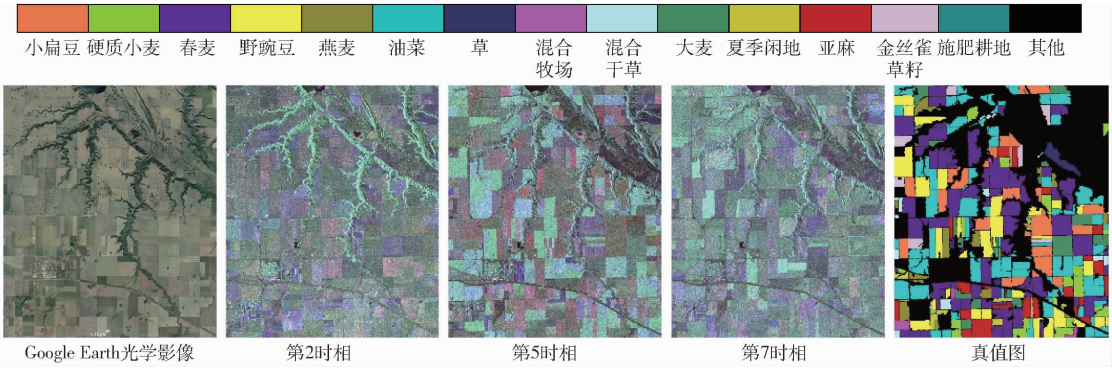

图 8 Indian Head 农场多时相数据集概况

Fig. 8 Overview of Indian Head farm multi-temporal dataset

验对比，设置最邻近样本数量为 2 000，使用与 S－SAE 相同样本进行训练，迭代更新权重，选出权重最大的前三维特征。

对于卷积神经网络模型，设置 CNN 训练的最小批次为 128，学习率为 0.01，动量参数 0.9，最大迭代 50 次，其他参数保持默认，使用相同训练样本作为训练集，对构建好的卷积神经网络模型进行训练，得到训练好的网络模型，输入全图进行预测，完成分类。

针对特征可分离性，采用 Flevoland 单时相 SAR 数据开展实验研究，由于研究区域内地物种类较多，选择区域内种植面积最大的 3 类地物，即小麦 3（C1）、森林（C2）、小麦（C3）为研究对象，以高维特征集进行 S－SAE 降维直接降至三维的降维特征集（简称“SAE3”）、对高维特征集进行 ReliefF 优选直接降至三维的优选特征集（包括 HH－VV 相关系数、幅值 Cloude 分解散射熵、平均散射角三维特征，简称“ReliefF3”）以及从高维特征集中直接选择 S_{HH}、S_{HV}、S_{VV}三维特征构成的原始特征集（简称“原始 3”）作为特征集对照组，首先使用 t 分布随机邻居嵌入（t－SNE）技术进行定性评估。针对 3 类农作物各随机选择 2 000 个样本点，非线性投影到二维空间，进行 t－SNE 可视化，直观展示数据内在分布特点，验证特征可分离性。然后使用可分性系数（Separability index，SI）进行定量评估，每类农作物随机选择 5 000 个样本点，计算两两不同类别间的 SI 及多类间平均 SI。可分性指数定义为

$$SI_{a-b}=\frac{|\mu_a-\mu_b|}{S_a+S_b} \tag{8}$$

式中　SI_{a-b}——a 类和 b 类在某一特征下的可分性指数

μ_a、μ_b——a 类、b 类在某一特征下的均值

S_a、S_b——a 类、b 类在某一特征下的标准差

SI 值越大说明两类间可分性越好，SI 值处于 0.8～1.5 则该特征为有用特征，超过 2 说明该特征基本能够实现类类可分[13]。

针对单时相地物分类，采用 Flevoland 单时相 SAR 数据开展实验研究，将上述 4 种特征集输入本文构建的 CNN 网络，降维算法与分类器均采用随机选取的 1% 样本集进行模型训练，以初步验证本文方法分类能力。

针对多时相农作物精细分类，使用 Indian Head 多时相 SAR 数据集，采用 Wishart 方法（无需特征提取）、支持向量机（SVM）作为分类器对照组，将上述特征集与分类器两两结合，展开对比验证实验，其中降维算法与分类器均采用随机选取的相同 1% 样本进行模型训练。

为合理评价不同方法对不同覆被类型的分类精度，本文分类实验将从总体分类精度 OA 和 Kappa 系数 2 个指标进行比较分析。

3.2　实验结果分析

3.2.1　特征可分离性分析

对于 Flevoland SAR 数据集使用 4 种方法处理的不同特征集的 3 类农作物 t－SNE 可视化效果如图 9 所示。

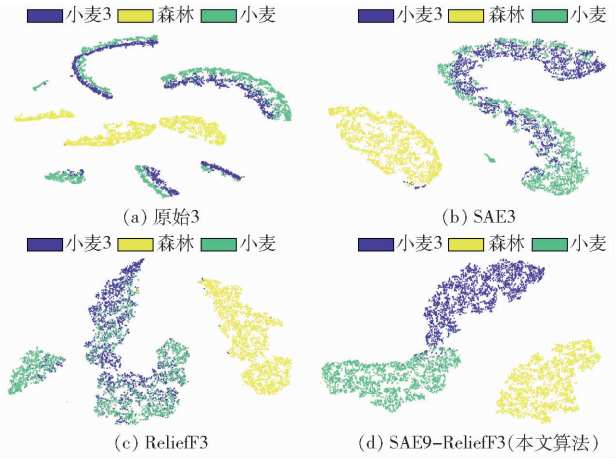

图 9　3 类主要作物的 t－SNE 可视化效果

Fig. 9　Visualization of t－SNE for three main crops

可以直观地发现，在种植面积最大的 3 类农作物上，不同农作物类型的聚类程度及聚类之间的边界在 4 个特征集上有所不同。使用本文特征优化方法所得最优特征集同类样本聚集性更好，不同类样本具有一定分离性，明显优于其他 3 种方法所获同维特征集。虽然 t－SNE 可视化不支持基于距离的样品可分离性定量测量，但聚类形成程度差异表明，本文特征优化方法所得特征集比其他同维特征集具有更好的可分离性。

对于 Flevoland SAR 数据集使用 4 种方法处理的不同特征集计算不同类间可分性系数 SI 的结果（保留 2 位小数）如表 2 所示。

表 2　可分性指数 SI 汇总

Tab. 2　Summary of separabilty index（SI）

特征集		SI_{C1-C2}	SI_{C1-C3}	SI_{C2-C3}	$\overline{SI_i}$	$\overline{SI}$
SAE9－ReliefF3	特征 1	1.81	1.04	1.57	1.47	1.67
	特征 2	3.14	0.91	3.23	2.43	
	特征 3	1.75	0.79	0.77	1.10	
ReliefF3	特征 1	1.68	0.48	1.82	1.33	1.43
	特征 2	1.20	1.09	1.86	1.38	
	特征 3	1.76	0.78	2.16	1.57	
SAE3	特征 1	0.88	0.61	1.05	0.85	1.33
	特征 2	2.35	0.48	2.39	1.74	
	特征 3	1.84	0.54	1.83	1.40	
原始 3	特征 1	1.79	0.82	1.33	1.31	1.22
	特征 2	1.87	0.56	1.95	1.46	
	特征 3	1.06	0.91	0.67	0.88	

对比平均可分性系数 SI,可以发现使用本文特征优化方法的最优特征集计算所得数值平均值最大,ReliefF3、SAE3、原始 3 所得数值依次减少。这从定量角度证明本文方法所获特征集具备良好的区分不同类别的能力。所有特征集的 SI_{C1-C3} 均偏小,是因为该 2 类为不同品种的小麦,它们的物候期及生物外在形态相似性较高。

3.2.2 单时相分类实验结果分析

单时相农作物分类对比验证实验结果如表 3 所示,每种方法进行 10 次实验,取 10 次实验指标的平均值和标准差作为最终结果。使用本文方法所获最优特征集 SAE9 - ReliefF3 结合 CNN 网络的结果和误差如图 10 所示。

表 3 单时相实验精度评价结果

Tab. 3 Accuracy evaluation of single-time phase experiments %

分类方法	分类精度	
	OA	Kappa 系数
原始 3 + SVM	77.93 ± 2.83	75.85 ± 3.13
SAE3 + SVM	88.61 ± 0.33	77.59 ± 0.37
ReliefF3 + SVM	91.12 ± 0.12	90.32 ± 0.13
SAE9 - ReliefF3 + SVM	93.64 ± 0.08	93.08 ± 0.09

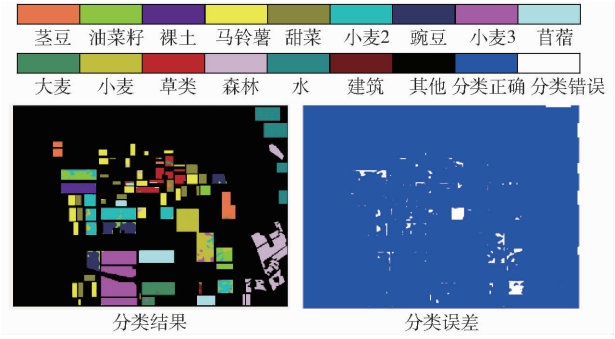

图 10 本文方法分类结果和误差

Fig. 10 Map of classification results and errors with textual algorithm

对比不同特征集输入下的实验结果可以看到,输入最优特征集 SAE9 - ReliefF3 的分类效果最好,精度评价指标较其他 3 种特征集有一定提升,总体分类精度达到 93.64%,Kappa 系数达到 93.08%。这初步证明使用本文提出的特征优化方法构建的特征集相较于其他同维特征具有分类优势。但仅基于单一时相数据的分类不能提供足够的作物类别间物候信息差异,总体分类精度仍有一定的提升空间。

3.2.3 多时相分类实验结果分析

多时相农作物分类对比验证实验结果如表 4 所示,每种方法进行 10 次实验,取 10 次实验指标的平均值和标准差作为最终结果。

表 4 多时相实验精度评价结果

Tab. 4 Accuracy evaluation of multi-temporal phase experiments %

分类方法	分类精度	
	OA	Kappa 系数
复 Wishart 方法	63.75 ± 0.13	59.41 ± 0.12
原始 3 + SVM	49.69 ± 0.23	44.51 ± 0.24
SAE3 + SVM	58.45 ± 0.32	53.18 ± 0.31
ReliefF3 + SVM	66.72 ± 0.25	62.21 ± 0.25
SAE9 - ReliefF3 + SVM	69.99 ± 0.13	65.43 ± 0.12
原始 3 + CNN	91.81 ± 0.35	90.31 ± 0.31
SAE3 + CNN	92.23 ± 0.33	90.80 ± 0.27
ReliefF3 + CNN	95.27 ± 0.28	94.74 ± 0.23
SAE9 - ReliefF3 + CNN	97.69 ± 0.11	97.24 ± 0.13

不同分类方法下的结果和误差如图 11 所示。

多时相多特征相结合能够有效完成研究区域农作物精准分类任务,使用多时相数据不仅增加了参与分类的信息量,还可以表现出作物在相同极化特征下随时相的变化。由于作物在不同生长阶段表现出不同的形态结构,且随时相的变化趋势不同,利用作物不同时相上的差异以及变化趋势的不同,便可更好地区分作物类别,从而提高分类精度,改善分类效果。

从图 11 来看,使用基于复 Wishart 分布的最大似然分类方法虽然省略了特征提取步骤,简单易行,但是无法充分利用多时相信息,只取得 63.75% 的总体分类精度,难以直接进行实际应用。

对比同一特征输入下不同分类方法的实验结果可以发现,基于卷积神经网络的分类模型效果优于支持向量机模型效果,其精度提升达到 30% 以上。针对 SVM 分类器,可以发现 4 种特征集输入的分类精度均较低,难以取得理想效果,其中使用原始 3 和 SAE3 特征集作为输入时,甚至低于基于复 Wishart 分布的分类方法,这是由于输入特征维数较少且特征集区分性较差,同时 SVM 分类器具有难以处理非线性问题以及对参数选择较为敏感的缺点,导致分类精度降低;针对 CNN 分类网络,可以发现 4 种特征集输入时分类精度均达到 90% 以上,这证明了本文设计的 CNN 分类器具有更优的分类能力,能够更加精确地获取地物面积信息和分布信息。

对比不同特征输入下的实验结果可以看到,不同的特征集输入在 SVM 和 CNN 分类器上分类精度变化趋势一致,输入最优特征集 SAE9 - ReliefF3 的分类效果最好,精度评价指标较 SAE3 和原始 3 特征集有较大提升,较 ReliefF3 特征集有一定提升,说明特征优选时,虽然通过评估特征的相关性、重要性及信息量,选择出来对预测目标最有帮助的特征,但

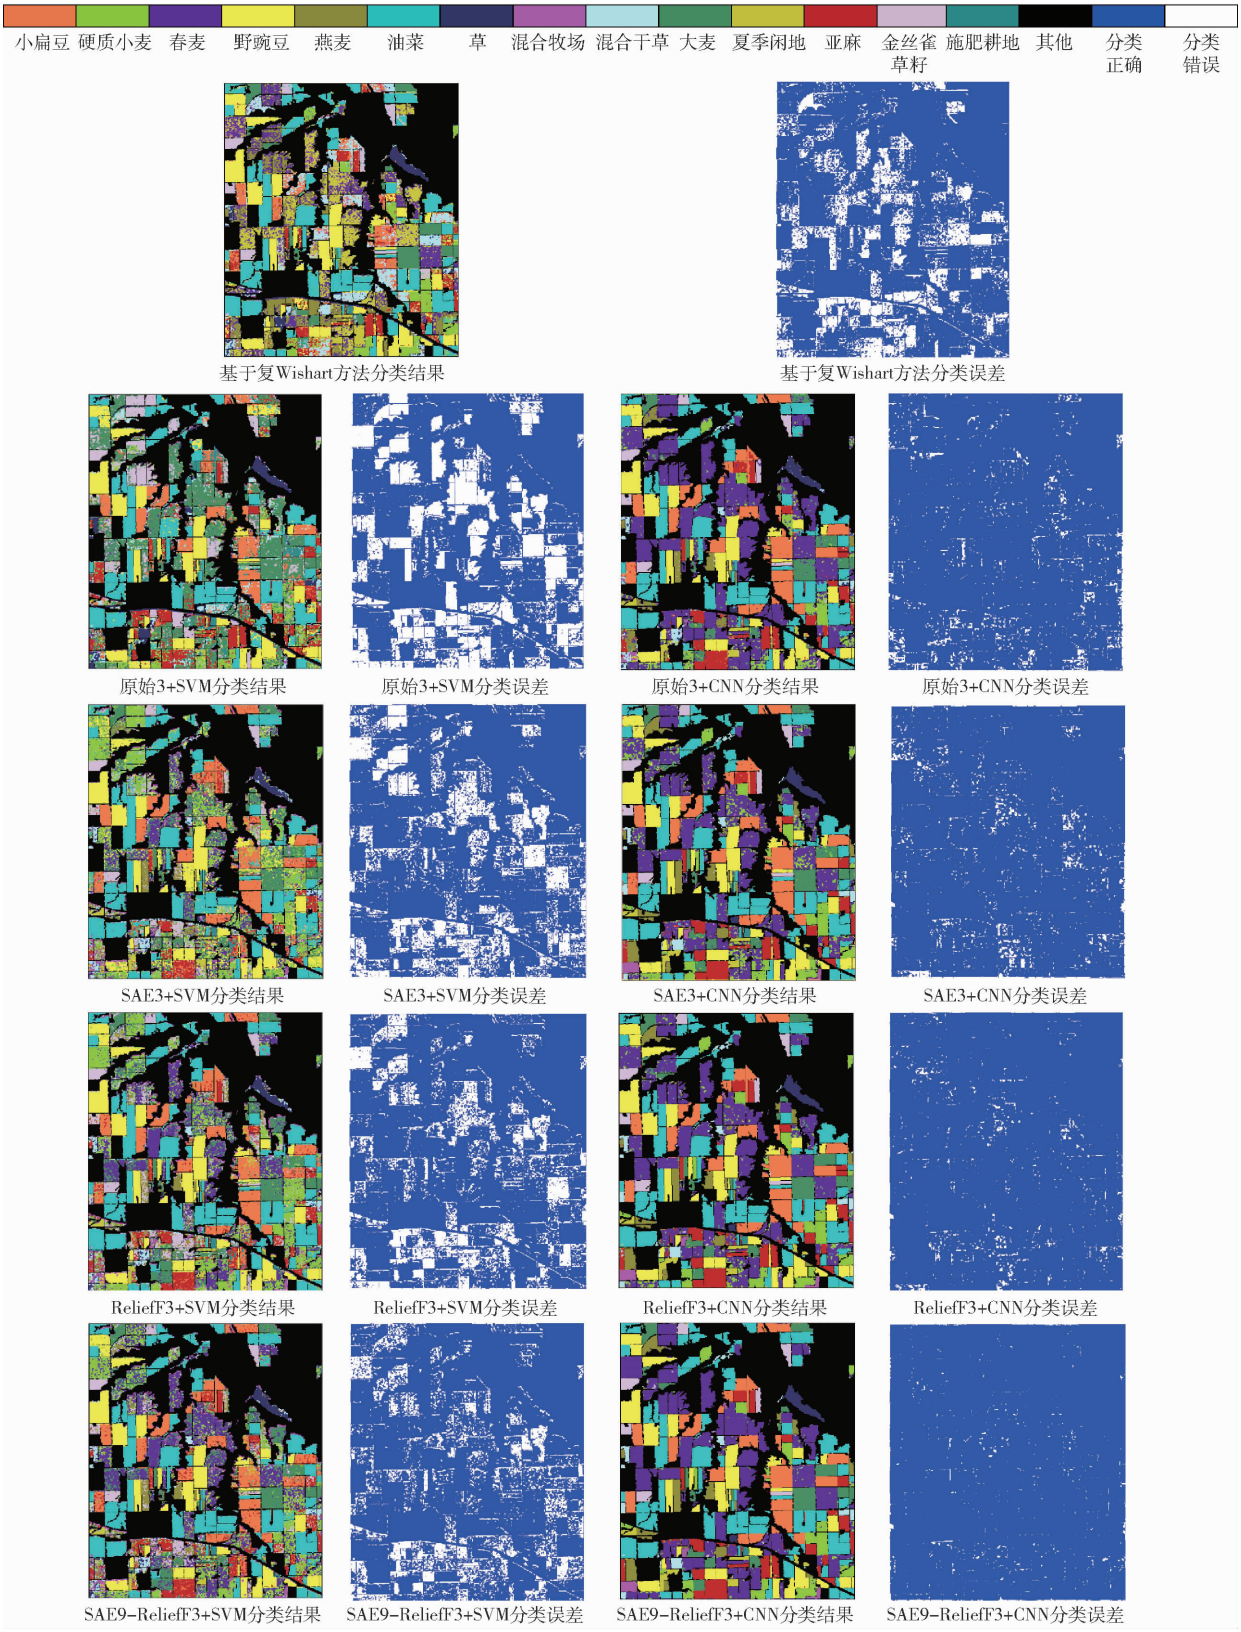

图 11　不同特征集和分类方法下结果和误差

Fig. 11　Map of results and errors with different feature sets and classification method

仍有一定的信息丢失，如雷达植被指数等。这证明使用本文提出的特征优化方法构建的特征集相较于其他同维特征具有分类优势。

基于上述实验结果可以发现，本文研究的方法顾及特征输入和分类器优化 2 个方面，使用先压缩降维后特征优选的最优特征集结合双分支轻量化卷积神经网络，在选择 1% 随机样本训练的情况下，能够实现高精度农作物分类，总体分类精度达到 97.69%，Kappa 系数达到 97.24%，对比其他方法，本文提出的方法有较为优异的分类识别效果，进一

步验证了本文方法的优越性。

4 结论

(1)提出了一种基于多特征优化的 PolSAR 数据农作物精细分类方法,即在广泛提取包括雷达植被指数在内的多种极化 SAR 特征的基础上,通过特征优化与增强,得到优于传统方法的低维优化特征,并结合卷积神经网络充分挖掘深度信息,提高了 PolSAR 数据分类质量,为实现农作物精准分类提供了新方案。

(2)以 Flevoland 单时相和 Indian Head 多时相 PolSAR 数据集作为研究数据展开实验,通过特征分析及单、多时相分类对比实验充分证明本文方法增强了特征可分度,提高了分类精度,单时相分类实验总体分类精度达到 93.64%,Kappa 系数达到 93.08%,多时相分类实验总体分类精度达到 97.69%,Kappa 系数达到 97.24%,与传统方法相较具有一定的优越性。

参 考 文 献

[1] 汪传建, 赵庆展, 马永建,等. 基于卷积神经网络的无人机遥感农作物分类[J]. 农业机械学报, 2019, 50(11): 161 - 168.
WANG Chuanjian, ZHAO Qingzhan, MA Yongjian, et al. Crop identification of drone remote sensing based on convolutional neural network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(11): 161 - 168. (in Chinese)

[2] 唐琪, 李恒凯, 周艳兵, 等. 基于 Sentinel - 2 与时序 Sentinel - 1 SAR 特征的赣南柑橘种植区识别方法[J]. 农业机械学报, 2024, 55(3): 193 - 202.
TANG Qi, LI Hengkai, ZHOU Yanbing, et al. Identification of Gannan citrus planting area based on Sentinel - 2 and temporal Sentinel - 1 SAR features[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(3): 193 - 202. (in Chinese)

[3] HUANG X, WANG J, SHANG J. Simplified adaptive volume scattering model and scattering analysis of crops over agricultural fields using the RADARSAT - 2 polarimetric synthetic aperture radar imagery[J]. Journal of Applied Remote Sensing, 2015, 9(1): 96026.

[4] 郭交, 尉鹏亮, 周正舒, 等. 基于时变特征的多时相 PolSAR 农作物分类方法[J]. 农业机械学报, 2017, 48(12): 174 - 182.
GUO Jiao, WEI Pengliang, ZHOU Zhengshu, et al. Crop classification method with differential characteristics based on multi-temporal PolSAR images[J]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(12): 174 - 182. (in Chinese)

[5] SKRIVER H, MATTIA F, SATALINO G, et al. Crop classification using short-revisit multitemporal SAR data[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2011, 4(2): 423 - 431.

[6] 孙勋, 黄平平, 涂尚坦, 等. 利用多特征融合和集成学习的极化 SAR 图像分类[J]. 雷达学报, 2016, 5(6): 692 - 700.
SUN Xun, HUANG Pingping, TU Shangtan, et al. Polarimetric SAR image classification using multiple-feature fusion and ensemble learning[J]. Journal of Radars, 2016, 5(6): 692 - 700. (in Chinese)

[7] 孙政, 刘长安, 梁庆国, 等. 多时相极化 SAR 数据的旱地作物分类研究[J]. 中国农业资源与区划, 2021, 42(8): 260 - 270.
SUN Zheng, LIU Chang'an, LIANG Qingguo, et al. Classification of dryland crops based on multi temporal polarimetric SAR data[J]. Chinese Journal of Agricultural Resources and Regional Planning, 2021, 42(8): 260 - 270. (in Chinese)

[8] YI Y, BAKIAN-DOGAHEH K, MOGHADDAM M, et al. Mapping surface organic soil properties in arctic tundra using C-Band SAR data[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2023, 16: 1403 - 1413.

[9] SAKARYA U, DEMİRPOLAT C. SAR image time-series analysis framework using morphological operators and global and local information-based linear discriminant analysis[J]. Turkish Journal of Electrical Engineering and Computer Science, 2018, 16(6): 2959 - 2967.

[10] LIU X, JIAO L, TANG X, et al. Polarimetric convolutional network for PolSAR image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 57(5): 3040 - 3054.

[11] GUO J, LI H, NING J, et al. Feature dimension reduction using stacked sparse auto-encoders for crop classification with multi-temporal, Quad-Pol SAR data[J]. Remote Sensing, 2020, 12(2): 321.

[12] 于飞, 吕争, 隋正伟, 等. 基于特征优选的多时相 SAR 数据水稻信息提取方法[J]. 农业机械学报, 2023, 54(3): 259 - 265, 327.
YU Fei, LÜ Zheng, SUI Zhengwei, et al. Extraction of rice information using multi-temporal SAR data based on feature optimization[J]. Transactions of the Chinese Society for Agricultural Machinery,2023,54(3):259 - 265, 327. (in Chinese)

[13] 李平, 徐新, 董浩, 等. 利用可分性指数的极化 SAR 图像特征选择与多层 SVM 分类[J]. 计算机应用, 2018, 38(1): 132 - 136.
LI Ping, XU Xin, DONG Hao, et al. Polarimetric SAR image feature selection and multi-layer SVM classification using divisibility index[J]. Journal of Computer Applications, 2018, 38(1): 132 - 136. (in Chinese)

[14] SHEN Z, MIAO J, WANG J, et al. Evaluating feature selection methods and machine learning algorithms for mapping mangrove forests using optical and Synthetic Aperture Radar data[J]. Remote Sens., 2023, 15(23): 5621.

[15] 曾妍, 王迪, 田甜, 等. 极化 SAR 农作物分类研究进展[J]. 中国农业信息, 2020, 32(2): 13 - 26.
ZENG Yan, WANG Di, TIAN Tian, et al. Research advances on crop classification using PolSAR data[J]. China Agricultural Informatics, 2020, 32(2): 13 - 26. (in Chinese)

[16] 赵丽仙, 张王菲, 李云, 等. 基于高分三号卫星数据与 H/A/α-分解特征参数的农作物分类研究[J]. 浙江农业学报,

2022, 34(11): 2491 – 2503.
ZHAO Lixian, ZHANG Wangfei, LI Yun, et al. Crops classification based on GF – 3 satellite data and H/A/α-decomposition characteristic parameters[J]. Acta Agriculturae Zhejiangensis, 2022, 34(11): 2491 – 2503. (in Chinese)
[17] YAMAGUCHI Y, MORIYAMA T, ISHIDO M, et al. Four-component scattering model for polarimetric SAR image decomposition[J]. Technical Report of Ieice Sane, 2005, 104(8): 1699 – 1706.
[18] FREEMAN A, VAN ZYL J J. Calibration of Stokes and scattering matrix format polarimetric SAR data[J]. IEEE Transactions on Geoscience & Remote Sensing, 1992, 30(3): 531 – 539.
[19] CLOUDE S R, POTTIER E. An entropy based classification scheme for land applications of polarimetric SAR[J]. IEEE Trans. Geo. Remote Sens., 1997, 35(1): 68 – 78.
[20] HUYNEN J R. Phenomenological theory of radar targets[D]. Rotterdam: Drukkerij Bronder-offset N V, 1970.
[21] 王川, 范景辉, 林思美, 等. 光学遥感植被指数与 SAR 遥感参数的相关性及其主要影响因素研究[J]. 国土资源遥感, 2020, 32(2): 130 – 137.
WANG Chuan, FAN Jinghui, LIN Simei, et al. Study of the correlation between optical vegetation index and SAR data and the main affecting factors[J]. Remote Sensing for Land and Resources, 2020, 32(2): 130 – 137. (in Chinese)
[22] KIM Y, YAN ZYL J J. A time-series approach to estimate soil moisture using polarimetric radar data[J]. IEEE Transactions on Geoscience and Remote Sensing, 2009, 47(8): 2519 – 2527.
[23] 马腾, 王耀强, 李瑞平, 等. 基于微波遥感极化目标分解的土地覆盖/土地利用分类[J]. 农业工程学报, 2015, 31(2): 259 – 265.
MA Teng, WANG Yaoqiang, LI Ruiping, et al. Land cover/land use classification based on polarimetric target decomposition of microwave remote sensing[J]. Transactions of the CSAE, 2015, 31(2): 259 – 265. (in Chinese)
[24] DOLZ J, BETROUNI N, QUIDET M, et al. Stacking denoising auto-encoders in a deep network to segment the brainstem on MRI in brain cancer patients: a clinical study[J]. Computerized Medical Imaging & Graphics, 2016, 52: 8 – 18.
[25] SUN W, SHAO S, ZHAO R, et al. A sparse auto-encoder-based deep neural network approach for induction motor faults classification[J]. Measurement, 2016, 89: 171 – 178.
[26] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313: 504 – 507.
[27] XIANG Songyang, XU Zhanghua, ZHANG Yiwei, et al. Construction and application of ReliefF – RFE feature selection algorithm for hyperspectral image classification[J]. Spectroscopy and Spectral Analysis, 2022, 42(10): 3283 – 3290.
[28] KONONENKO I, IMEC E, ROBNIK- IKONJA M. Overcoming the myopia of inductive learning algorithms with ReliefF[J]. Applied Intelligence, 1997, 7(1): 39 – 55.
[29] 李彦冬, 郝宗波, 雷航. 卷积神经网络研究综述[J]. 计算机应用, 2016, 36(9): 2508 – 2515.
LI Yandong, HAO Zongbo, LEI Hang. Survey of convolutional neural network[J]. Journal of Computer Applications, 2016, 36(9): 2508 – 2515. (in Chinese)
[30] SZEGEDY C, LIU Wei, JIA Yangqing, et al. Going deeper with convolutions[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015: 1 – 9.

(上接第 193 页)

[28] 都鑫, 刘彩玲, 姜萌, 等. 基于离散元的包膜肥料 Bonding 模型参数标定[J]. 农业机械学报, 2022, 53(7): 141 – 149.
DU Xin, LIU Cailing, JIANG Meng, et al. Calibration of Bonding model parameters for coated fertilizers based on discrete element method[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(7): 141 – 149. (in Chinese)
[29] HANG C, GAO X, YUAN M, et al. Discrete element simulations and experiments of soil disturbance as affected by the tine spacing of subsoiler[J]. Biosystems Engineering, 2018, 168: 73 – 82.
[30] 张喜瑞, 胡旭航, 刘俊孝, 等. 香蕉秸秆离散元仿真黏结模型参数标定与试验[J]. 农业机械学报, 2023, 54(5): 121 – 130.
ZHANG Xirui, HU Xuhang, LIU Junxiao, et al. Calibration and verification of bonding parameters of banana straw simulation model based on discrete element method[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(5): 121 – 130. (in Chinese)
[31] HU R, LIU H H, CHEN Y, et al. A constitutive model for unsaturated soils with consideration of inter-particle bonding[J]. Computers and Geotechnics, 2014, 59: 127 – 144.
[32] 刘俊安. 基于离散元方法的深松铲参数优化及松土综合效应研究[D]. 北京: 中国农业大学, 2018.
LIU Jun'an. Study on subsoiler parameters optimization and comprehensive effect of subsoiling based on the discrete element method[D]. Beijing: China Agricultural University, 2018. (in Chinese)
[33] ZHAO W, CHEN M, XIE J, et al. Discrete element modeling and physical experiment research on the biomechanical properties of cotton stalk[J]. Computers and Electronics in Agriculture, 2023, 204: 107502.
[34] 王学振. 土壤–带翼深松铲互作关系及其效应研究[D]. 杨凌: 西北农林科技大学, 2022.
WANG Xuezhen. Soil – winged subsoiler interactions and their effects[D]. Yangling: Northwest A&F University, 2022. (in Chinese)