

基于空 - 谱融合和深度神经网络的机载 高光谱影像作物精细识别

徐国斌¹, 叶 鹏²

¹湖北省空间规划研究院, 湖北 武汉

²湖北大学资源环境学院, 湖北 武汉

收稿日期: 2023年9月18日; 录用日期: 2024年1月10日; 发布日期: 2024年1月19日

摘 要

针对目前农作物精细识别中由于没能充分利用影像特征, 导致识别精度不足的局限, 本文提出了一种耦合空 - 谱融合框架和深度神经网络的机载高光谱遥感影像作物精细识别方法。该方法首先提取作物的GLCM纹理、形态学轮廓、端元丰度三种空间信息, 构建决策级融合模型将这三种空间信息与作物的光谱信息进行融合计算。然后引入基于深度神经网络和条件随机场的混合模型进行高精度作物识别。本研究选择了河北雄安有人机数据集进行实验, 结果表明, 本文方法能融合生成具有互补性的作物特征数据, 并能有效减少识别过程中的噪声影响, 保持地物边缘, 获取高精度的农作物识别信息。

关键词

机载高光谱, 精细识别, 空 - 谱融合, 深度学习

Crop Fine Identification of Crops in Airborne Hyperspectral Images Based on Space-Spectral Fusion and Deep Neural Network

Guobin Xu¹, Peng Ye²

¹Hubei Provincial Institute of Spatial Planning and Research, Wuhan Hubei

²Faculty of Recourses and Environmental Science, Hubei University, Wuhan Hubei

Received: Sep. 18th, 2023; accepted: Jan. 10th, 2024; published: Jan. 19th, 2024

文章引用: 徐国斌, 叶鹏. 基于空-谱融合和深度神经网络的机载高光谱影像作物精细识别[J]. 测绘科学技术, 2024, 12(1): 47-56. DOI: 10.12677/gst.2024.121007

Abstract

Aiming at limitations of insufficient accuracy due to the insufficient utilization of image features in crop fine recognition, this paper proposes a crop fine recognition method for airborne hyperspectral remote sensing images by coupling a space-spectral fusion framework and a deep neural network. This method first extracts three spatial information of crops: GLCM texture, morphological contour, and end element abundance, and constructs a decision-level fusion model to fuse and calculate the three spatial information with the spectral information of crops. Then, a hybrid model based on deep neural networks and conditional random fields is introduced for high-precision crop recognition. This study selected a human-machine dataset from Xiong'an, Hebei for experimentation, and the results showed that the proposed method can fuse and generate complementary crop feature data, effectively reduce the impact of noise during the recognition process, maintain the edge of land features, and obtain high-precision crop recognition information.

Keywords

Airborne Hyperspectral, Fine Identification, Space-Spectral Fusion, Deep Neural Network

Copyright © 2024 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

准确、及时地掌握农业资源信息对农业发展至关重要。精准识别作物种类及其空间分布信息是获取农业信息的重要途径[1] [2]。传统方法主要是通过实地测量、调查统计等手段进行监测,存在周期长、成本高的局限[3] [4]。目前,高光谱遥感技术发展迅速,高光谱遥感数据在农作物生产状态评估、农业产量估算、病虫害监测等农业领域得到了广泛应用[5] [6],特别是机载高光谱数据同时具备高空间分辨率和高光谱分辨率,已经成为进行农作物精细识别的优质数据源[7]。

目前,国内外学者利用机载高光谱遥感数据进行农作物识别已经获得了显著成效,如 Melgani 等人针对 AVIRIS 数据特点,提出了无核变换线性支持向量机与基于高斯核函数的非线性支持向量机两种模型,对玉米和其他作物进行高精度的识别和分类[8]; Tarabalka 等人提出了基于支持向量机和马尔科夫随机场混合模型的 AVIRIS 影像分类框架,通过兼顾影像空间上下文信息,实现了对大豆和小麦精细分类[9]; Wei 等人提取汉川等地农田无人机数据的空间特征,并将其与光谱特征融合,构建了一个单变量条件随机场函数,实现了农田全部作物精准识别[10]; Liu 等人针对北京顺义地区农田作物种类复杂的问题,提出了一种高光谱遥感数据逐步分层计算框架,通过选择不同的参数进行不同目标层提取,进而深度挖掘作物信息,实现高精度的小麦、玉米等作物的识别和分类[11]。这些方法虽然在一定程度上取得了较好的识别效果,但对于机载高光谱图像显示出来的丰富空间信息没有进行充分的挖掘,其精度尚有待提高。

针对该问题,本文提出了一种能兼顾机载高光谱遥感影像空-谱信息的农作物精细识别方法。该方法充分考虑影像空间信息的互补性,提取了机载高光谱遥感影像的形态轮廓、GLCM 结构和末端成员丰度三种空间特征,利用堆叠融合准则将影像三种空间特征与光谱特征进行融合计算,在此基础上,构建了混合深度神经网络和条件随机场模型的作物精细识别框架,其中深度神经网络模型通过多层神经网络

的学习, 挖掘高光谱影像的潜在特征, 计算其最大后验概率, 作为一阶势函数输入条件随机场模型, 条件随机场被用作分类器对特定观察场的后验概率进行建模, 实现高精度的作物精细识别。

2. 研究区及机载高光谱数据介绍

2.1. 研究区概况

本文选取的研究区域是位于河北省的雄安新区。雄安新区(东经 116°、北纬 38.9°)范围涵盖河北省雄县、容城、安新及周边部分区域, 是继深圳经济特区和上海浦东新区之后又一具有划时代意义的新区。雄安新区地带, 地势海拔从西北向东南降低, 属暖温带季风型大陆性气候, 优良的气候条件和丰富的水资源使得该地区农业发展迅速, 精准掌握其农业资源信息对该地区农业发展至关重要。

2.2. 实验数据集

本文所用的数据集是由上海技术物理研究所研制的高分专项航空系统全谱段多模态成像光谱仪于 2017 年 1 月所采集, 光谱范围为 400~1000 nm, 波段 250 个, 影像大小为 3750 × 1580 像元, 空间分辨率 0.5 m。主要地物类型包括建筑、水体、裸地和水稻、水稻茬、榆树(Elm)、白蜡、国槐、菜地、杨树、大豆、刺槐、柳树、复叶槭、栾树、桃树、梨树、稀疏林、草地、玉米等 17 种农作物类型, 为保证识别结果的完整性和丰富性, 将建筑、水体、裸地也作为识别实验的一类。雄安数据集的真实遥感影像和地面样本如图 1 所示, 各个地物样本数量如表 1 所示。

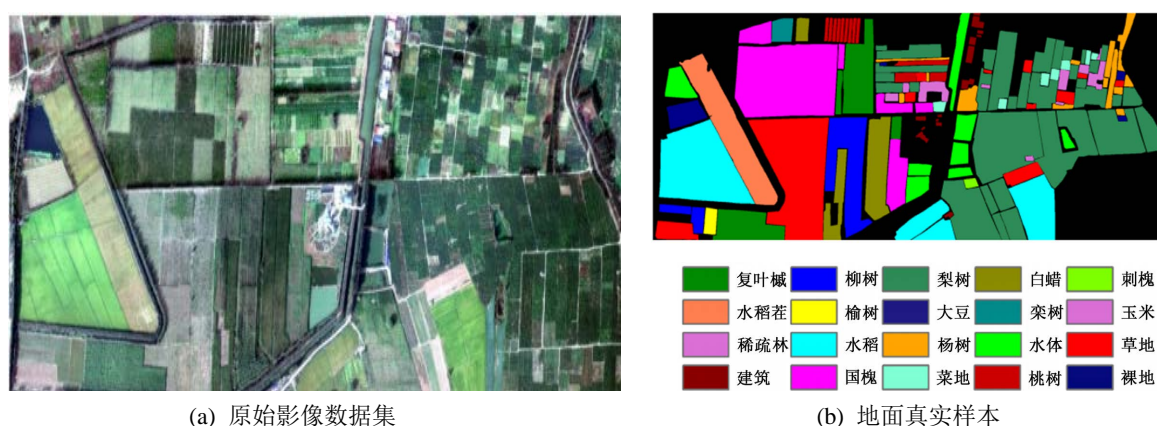


Figure 1. Xiong'an dataset

图 1. 雄安数据集

Table 1. Number of samples in Xiong'an dataset

表 1. 雄安数据集样本数

类型	样本数	类型	样本数	类型	样本数
水体	49,695	玉米	17,750	裸地	11,523
草体	126,569	梨树	308,285	水稻茬	58,149
复叶槭	67,695	大豆	2146	刺槐	1684
柳树	54,384	杨树	27,322	稀疏林	449
国槐	142,827	菜地	8745	建筑	8885
白蜡	50,834	榆树	4606		

3. 方法原理

3.1. 机载高光谱影像作物多特征融合

充分考虑影像空间信息的互补性, 本研究提取机载高光谱遥感影像形态轮廓、GLCM 结构和末端成员丰度三种空间特征, 然后构建基于堆叠准则的遥感数据融合模型, 将所提取的三种空间特征与影像原始光谱特征进行融合计算。

3.1.1. 机载高光谱影像特征提取

本文提取影像的形态学轮廓、GLCM 结构和末端成员丰度三种空间特征, 具体如下:

1) 形态学轮廓特征。形态学是一种基于数学形态学的理论, 用于挖掘目标物体的形态学轮廓。形态学轮廓是提取影像的结构信息, 设 $\gamma^{SE}(I)$ 为具有结构元素 SE 的图像 I 上开口的形态重构, 其中 $\gamma^{SE}(I)$ 是开运算, $\varphi^{SE}(I)$ 是闭运算。一系列大小逐渐增加的 SE_s 被定义为 MP_s :

$$MP_\gamma = \{MP_\gamma^\lambda(I) = \gamma^\lambda(I)\}, \forall \lambda \in [0, n] \quad (1)$$

$$MP_\varphi = \{MP_\varphi^\lambda(I) = \varphi^\lambda(I)\}, \forall \lambda \in [0, n] \quad (2)$$

式中, λ 是 SE 的半径。一系列大小逐渐增加的 SE_s 用于显示图像的多尺度信息。

2) GLCM 结构特征。高光谱遥感影像不仅具有连续而丰富的光谱特征, 还具有丰富的纹理特征。纹理特征可以有效反映影像中相邻像元相似信息, 涵盖了物体表面结构组织规律的重要信息以及它们与周围环境的关系。GLCM 是一种被广泛用于有效提取纹理信息的方法, 其原理是通过计算具有特定距离和方向的两个点之间的灰度共生矩阵, 从矩阵中提取相应的特征量进行纹理分析。设 $f(x, y)$ 的大小为 $M \times N$, 则 GLCM 可以表示为:

$$P(i, j) = \#\{(x_1, y_1), (x_2, y_2) \in M, N \mid f(x_1, y_1) = i, f(x_2, y_2) = j\} \quad (3)$$

其中, $\#$ 为集合 X 中的元素个数, P 为 $N_g \times M_g$ 的矩阵, 若 (x_1, y_1) 与 (x_2, y_2) 之间的距离为 d , θ 是它们与横坐标轴的夹角度数, 那么各种间距及角度的灰度共生矩阵 $P(i, j, d, \theta)$ 为:

$$P(i, j, d, \theta) = \#\{(x_1, y_1), (x_2, y_2) \in M, N \mid f(x_1, y_1) = i, f(x_2, y_2) = j\} \quad (4)$$

将 GLCM 作为基础提取纹理统计量, 共有 14 个纹理统计量, 本文选择了同质性、角二阶距、对比度、不相似性、均值和熵等 6 个特征量进行后续融合。

3) 末端成员丰度特征。受传感器的混合效应、大气传输等原因的影响, 高光谱图像中存在大量混合像元现象。解决上述现象对高光谱图像分类的影响是提取端元丰度特征的重要原因。连续最大角凸锥模型是通过约束条件识别图像端元波谱, 直至完全满足指定端元波谱类别的端元提取算法。本文采用该方法从影像中提取端元波谱和丰度图像来组成端元组分特征:

$$H(c, i) = \sum_k^N R(c, k) A(k, j) \quad (5)$$

式中, H 是光谱的端元, 频带索引为 c , 像素索引为 i 。 k 和 j 表示从 1 到最大端元的索引; R 是端元光谱的矩阵; A 是像素矩阵中 j 到 k 的丰度。

3.1.2. 基于堆叠准则的高光谱影像多特征融合

堆叠融合方法是通过向量组合进行分类, 本文将 GLCM 纹理、形态学轮廓、端元丰度特征三个已经提取的特征与光谱信息结合起来, 以形成新的分类特征。然后, 将新的分类特征向量直接叠加。通过叠

加形成的新矢量作为融合结果输入到分类器。堆叠融合模型如下所示:

$$\gamma = [\varphi_{spec}^T X_{spec}, \varphi_{spat}^T X_{spat}] \quad (6)$$

式中, X_{spec} 是机载高光谱影像的光谱特征, X_{spat} 是影像形态学轮廓、GLCM 纹理和端元丰度特征的扩展相关的特征, γ 是融合特征, φ 是提取特征的线性映射矩, 最后获得兼顾空间特征和光谱特征的精细识别输入数据源。

3.2. 机载高光谱影像作物精细识别

获得机载高光谱作物多特征融合信息后, 本文构建一个混合深度神经网络和条件随机场模型的作物精细识别框架, 以融合数据为基础, 输入作物精细识别模型中, 从而获得识别结果。其中, 深度神经网络模型可通过多层神经网络的学习, 挖掘高光谱影像的潜在特征用于识别, 作为一阶势函数输入条件随机场模型。条件随机场识别方法可降低识别结果中的噪声及边缘效应现象, 从而提高农作物精细识别精度。

3.2.1. 作物精细识别框架一元势能函数

本文中, 引入深度神经网络作为作物精细识别框架的一元势能函数。深度神经网络的基本结构由几个输入层、隐藏层和输出层组成。输入后, 在隐藏层中学习线性关系, 并通过激活函数获得输出结果。深度神经网络的训练包括正向传播和反向传播过程, 其中正向传播使用权重系数矩阵 W 和偏置向量 b 。输入数据后, 通过上一层特征输入计算下一层的特征结果。输出结果不限于单个神经, 输出层可以具有多个神经元, 而不是局限于一个神经元。正向传播公式为:

$$a^l = \sigma(Z^l) = \sigma(W^l a^{l-1} + b^l) \quad (7)$$

式中, l 代表输入层的总数, W 是所有隐藏层和输出层的矩阵, b 是偏移向量, 最终输出是 a 。反向传播是深度学习的核心。通过定义损失参数, 可以计算出模型的概率输出与实际样本之间的差距。在此, 选择交叉熵作为损失参数。反向传播算法是与正向传播算法相反的过程。它从 L 层向后推到第一层, 通过反复迭代反复修改和, 最后获得 W 和 b 作为最终识别的参数。

3.2.2. 条件随机场模型

本文引入的条件随机场模型作为一种判别模型, 通过特定观测场对标签场的后验概率直接进行建模。条件随机场模型使用统一的概率框架来模拟随机变量之间的局部邻域交互。它直接模拟标签 x 的后验概率, 得到相应的吉布斯能如下:

$$E(x|y) = -\log P(x|y) - \log Z(y) = \sum_{c \in C} \psi_c(xc, y) \quad (8)$$

式中, $y = \{y_1, y_2, \dots, y_n\}$ 是观察值, $\psi_c(xc, y)$ 是随机场模型的势函数, Z 是分区函数。此时, 利用贝叶斯最大后验规则可使作物识别影像找到使后验概率 $P(x|y)$ 最大化的标签图像 y , 则随机场的最大后验规则标记 X_{MAP} 如下所示:

$$X_{MAP} = \arg \max_x P(x|y) = \arg \max_x E_x(x|y) \quad (9)$$

由上可知, 后验概率 $P(x|y)$ 越大, 能量函数 $E(x|y)$ 越小, 本文整个记载高光谱遥感影像作物识别过程中, 条件随机场模型计算过程如下:

$$E(x|y) = \sum_{i \in V} \psi_i(x_i, y) + \lambda \sum_{i \in V, j \in N_i} \psi_{ij}(x_i, x_j, y) \quad (10)$$

式中, $\sum_{i \in V} \psi_i(x_i, y)$ 是点 i 局部领域 N_i 领上的一元势能函数, 本文是引入上述深度神经网络分类结果来定

义整个作物识别框架的一元势能, 作用为通过特征向量计算具有特定类别标签的单个像素。 $\psi_{ij}(x_i, x_j, y)$ 是二元势能函数, 作用是通过考虑场和观测场来模拟像素与其邻域之间的空间上下文信息, 降低计算结果中的噪声及边缘效应现象, 从而提高农作物精细识别精度。

4. 实验与分析

4.1. 多特征融合实验分析

本节分析论文提出的多特征融合对最终识别精度的影响, 利用本文提出的混合深度神经网络和条件随机场模型分别对基于原始光谱数据、形态学轮廓、GLCM 结构和末端成员丰度三种单一空间特征数据及将前面四种数据利用堆叠融合准则融合计算后的数据进行识别分析, 其识别效果图如图 2 所示。

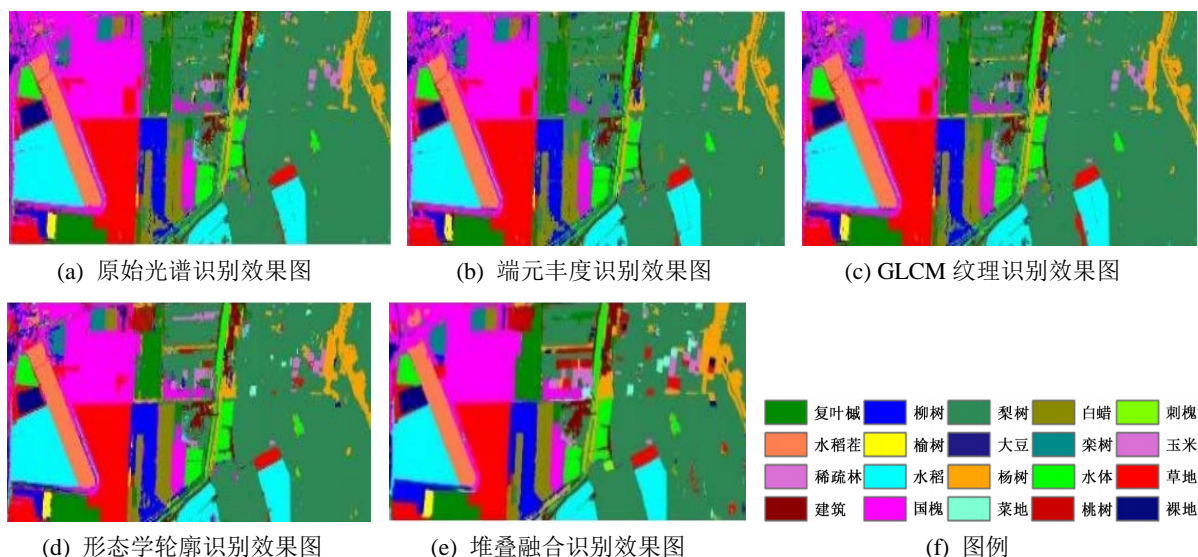


Figure 2. Identification results of Xiong'an dataset

图 2. 雄安数据集识别效果图

图 2 是雄安数据集不同特征的识别结果。针对不同的特征统一使用本文提出的机载高光谱影像作物精细识别模型, 图 2(a)是仅利用原始光谱进行农作物精细识别的结果, 左边水稻中间有少量的噪声, 以及上部的国槐有部分错分成草地, 还有部分的桃树错分成了梨树, 右上角整体分类效果差, 多种农作物没有被识别出来, 例如少量草地、水稻等。图 2(b)在识别过程中用到的是端元丰度特征, 它的识别结果多数分类错误现象与利用原始光谱分类的错误大致相同, 桃树没有被识别出来, 而是梨树分在了桃树对应的区域, 中部一些碎块区域的农作物识别效果差, 多被分成了梨树。图 2(c)利用 GLCM 纹理进行农作物精细识别。菜地、草地、水稻茬、裸地等识别效果较好, 能完整地识别出来且有明显的边界, 但是中间的桃树、草地、玉米等没有被识别出来, 而是错分成了梨树。分类结果右上角的菜地、草地几乎都被错分成了梨树。图 2(d)是利用形态学轮廓进行识别的结果, 其中中上部的桃树有被完整地识别出来, 但是部分草地、菜地依然未被分出来, 右上角的识别效果较前面几组结果, 效果改善, 有小部分的草地、菜地、裸地被识别出来, 边界完整度提高, 噪声有所减少。图 2(e)则是多种特征堆叠融合的作物识别结果, 其识别效果图明显优于前面四种单一特征的识别效果图, 难以识别的中部和右上方小范围的农作物也得到较好的体现, 例如水体、裸地、草地等, 证明相对于基于单一特征的农作物识别而言, 融合后的农作物识别精度更优, 有效解决了农作物的边界混淆、错分、漏分等问题。具体精度如表 2 所示。

Table 2. Identification result accuracy of different characteristics of Xiong'an dataset (%)**表 2.** 雄安数据集不同特征的认识结果精度(%)

	原始光谱	端元丰度	GLCM 纹理	形态轮廓	堆叠融合
水稻	98.21	98.40	98.28	98.58	99.95
水体	93.74	92.46	93.87	96.61	99.72
草体	90.63	91.13	90.73	93.42	99.69
复叶槭	58.56	53.11	91.28	95.08	99.86
柳树	78.85	81.02	84.23	93.39	99.98
国槐	83.81	86.21	85.73	94.61	99.95
白蜡	73.32	80.32	82.74	97.27	99.76
桃树	0.00	0.00	3.17	64.27	98.72
玉米	39.34	58.75	52.14	81.22	99.07
梨树	97.68	97.98	97.21	97.60	99.81
大豆	0.00	0.00	12.36	35.97	98.24
杨树	60.39	68.62	70.49	80.56	98.66
菜地	0.00	0.00	0.00	24.61	97.02
榆树	74.78	88.49	85.64	90.69	98.68
栎树	95.65	95.69	94.84	98.62	99.91
裸地	96.07	96.49	96.37	97.24	99.64
水稻茬	94.90	96.95	96.86	98.71	99.64
刺槐	0.00	0.00	0.00	0.00	98.07
稀疏林	0.00	0.00	0.00	0.00	88.84
建筑	85.99	88.46	90.08	94.14	98.69
OA	88.86	87.46	88.85	89.17	99.71
Kappa	0.836	0.846	0.863	0.885	0.995

由表 2 可知, 在原始光谱的认识结果中, 稀疏林、桃树、大豆、菜地、刺槐的认识精度为 0%, 均错被认定为梨树。复叶槭、玉米等的精度低于 60%, 比水稻、梨树、裸地、水稻茬等低了近 30%~40%, OA 为 85.46%。在利用端元丰度的认识结果中可以看出, 大部分的农作物认识精度有所提高, 但桃树、大豆、刺槐、稀疏林等仍未被认识, 认识精度依然为 0%, 认识精度最高的是水稻, 精度达到 98.4%。针对 GLCM 纹理的单一特征分类结果在第三列, 桃树的认识精度得到提升至 3.17%, 大豆的认识精度提升了 12.36%, 大豆、菜地、刺槐等农作物的认识精度仍为 0%, 复叶槭的认识精度也达到 91.28%, OA 达到 90.85%。形态学轮廓的分类结果中, 桃树的分类精度增加了 60%多, 菜地精度提高到 24.61%, 大豆提高了 35%左右, 水稻的认识精度仍为最高 98.83%, 复叶槭的认识精度也达到了 95%以上, OA 为 94.08%。最后是基于堆叠融合的认识精度, 认识精度中达到 99%以上的有 12 类, 包括水稻、水体、柳树、白蜡、栎树、裸地等, OA 为 99.71%, 整体精度均得到提升。

4.2. 不同训练样本量的识别精度分析

本章利用不同大小的样本数进行识别分类, 探讨训练样本数对农作物精细识别结果的影响。选择的训练集样本量为测试集的 3%、5%、10%, 其识别精度如图 3 所示。

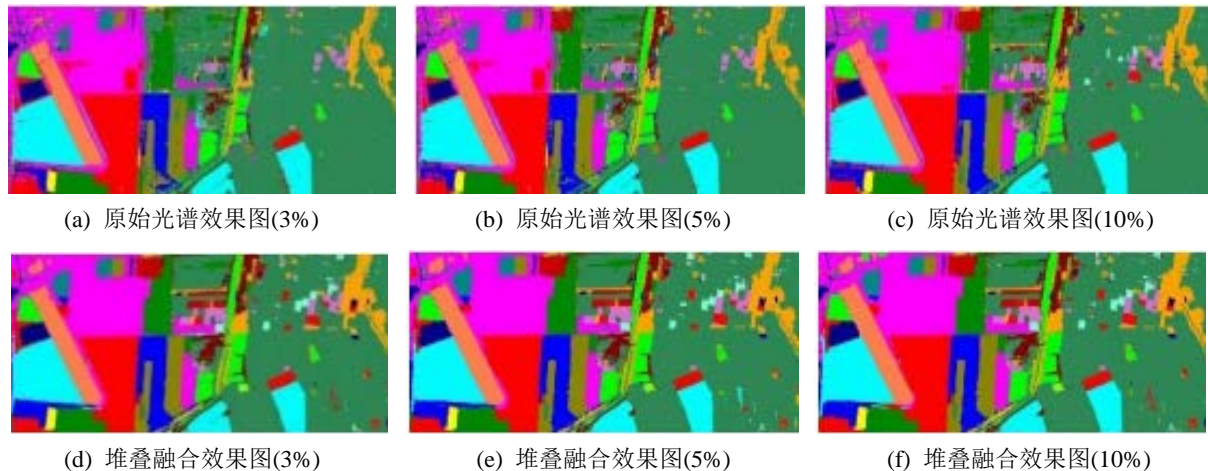


Figure 3. Identification results of different training samples
图 3. 不同训练样本的识别效果图

在图 3 中, 图 3(a)~(c)分别是原始光谱在不同训练样本量上的识别效果图, 可以明显看出, 随着训练样本数的增加, 农作物识别效果有较大的提高, 特别是玉米、桃树、榆树等农作物的识别效果是越来越好, 原本没有识别出来的农作物, 或者识别结果差的农作物, 结果都有所提升。图 3(d)~(f)是基于堆叠融合的农作物识别效果图, 与基于原始光谱的农作物识别效果类似, 识别精度的数值与训练集样本数量正相关, 而且在基于原始光谱的农作物识别框架中无法识别出的刺槐和稀疏林, 在融合识别模型中的精度不断提升。

Table 3. Identification result accuracy of different sample numbers of Xiong'an dataset (%)
表 3. 雄安数据集不同样本数量的识别结果精度(%)

	原始光谱			堆叠融合		
	3%	5%	10%	3%	5%	10%
水稻	98.21	98.79	99.06	99.95	99.97	99.98
水体	93.74	95.74	96.43	99.72	99.72	99.96
草体	90.63	91.38	94.84	99.69	99.76	99.91
复叶槭	58.56	92.36	94.61	99.86	99.95	99.96
柳树	78.85	90.76	96.03	99.98	99.98	99.98
国槐	83.81	87.71	93.38	99.95	99.96	99.96
白蜡	73.32	93.23	95.95	99.76	99.84	99.96
桃树	0.00	49.19	65.00	98.72	99.28	99.65
玉米	39.34	70.84	83.92	99.07	99.14	99.38
梨树	97.68	98.14	97.77	99.81	99.90	99.94

续表

大豆	0.00	12.14	23.79	98.24	98.40	99.39
杨树	60.39	73.89	81.45	98.66	99.06	99.57
菜地	0.00	0.00	25.74	97.02	98.25	99.03
榆树	74.78	91.62	93.18	98.68	99.69	99.81
栎树	95.65	98.44	98.28	99.91	99.91	99.94
裸地	96.07	96.76	97.03	99.64	99.96	99.98
水稻茬	94.90	97.65	98.89	99.64	99.99	99.99
刺槐	0.00	0.00	0.00	98.07	98.63	99.03
稀疏林	0.00	0.00	0.00	88.84	92.47	93.98
建筑	85.99	89.76	90.28	98.69	99.43	99.73
OA	88.86	90.78	91.71	99.71	99.78	99.94
Kappa	0.836	0.873	0.913	0.995	0.997	0.998

从表 3 中看出, 原始光谱、堆叠融合两种数据获得的结果都具有一致性, 随着训练集样本数量的提高, 识别结果逐渐变好, 精度也跟着提高。说明在农作物精细分类的过程中, 农作物不同的样本数量对结果会有影响, 训练集样本量越大, 精度越高。

5. 结束语

本研究针对机载高光谱遥感数据同时具备高空间分辨率和高光谱分辨率的特点, 提出了一种耦合影像空间特征和光谱特征的作物精细识别方法。该方法通过对雄安机载高光谱遥感数据的光谱特征及形态轮廓、GLCM 结构和末端成员丰度三种空间特征进行堆叠融合, 将融合后作物影像数据输入深度神经网络和条件随机场的混合模型进行计算。与传统方法相比, 本文提出的方法能更有效兼顾到影像的空间信息和光谱信息, 因此获得了比传统方法更高精度的农作物识别效果。同时, 与目前主流方法相比, 本文提出的深度神经网络和条件随机场的混合识别模型, 通过一元势能与二元势能的计算, 能准确模拟像素与其邻域之间的空间上下文信息, 降低计算结果中的噪声及边缘效应现象, 从而提高农作物精细识别的精度。因此, 该方法提出的农作物识别模型能有效实现高精度的农作物精细识别, 其结果为精准农业生产过程提供有效的数据支撑。

参考文献

- [1] Zhang, S.W., Lei, Y.P., Wang, L.P., Li, H.J. and Zhao, H.B. (2011) Crop Classification Using MODIS NDVI Data Denoised by Wavelet: A Case Study in Hebei Plain, China. *Chinese Geographical Science*, **21**, 322-333. <https://doi.org/10.1007/s11769-011-0472-2>
- [2] Proadhan, F.A., Zhang, J.H., Yao, F.M., Shi, L.M., Pangali Sharma, T.P., Zhang, D., Cao, D., Zheng, M.X., Ahmed, N. and Mohana, H.P. (2021) Deep Learning for Monitoring Agricultural Drought in South Asia Using Remote Sensing Data. *Remote Sensing*, **13**, Article 1715. <https://doi.org/10.3390/rs13091715>
- [3] 杨能榜. 遥感技术在地质防灾与矿产勘测中的应用和发展[J]. 价值工程, 2020, 39(7): 242-243.
- [4] Zhang, H.D., Wang, L.Q., Tian, T. and Yin, J.H. (2021) A Review of Unmanned Aerial Vehicle Low-Altitude Remote Sensing (UAV-LARS) Use in Agricultural Monitoring in China. *Remote Sensing*, **13**, Article 1221. <https://doi.org/10.3390/rs13061221>

- [5] Peng, X.S., Han, W.T., Ao, J.Y. and Wang, Y. (2021) Assimilation of LAI Derived from UAV Multispectral Data into the SAFY Model to Estimate Maize Yield. *Remote Sensing*, **13**, Article 1094. <https://doi.org/10.3390/rs13061094>
- [6] Liu, X.L. and Bo, Y.C. (2015) Object-Based Crop Species Classification Based on the Combination of Airborne Hyperspectral Images and LiDAR Data. *Remote Sensing*, **7**, 922-950. <https://doi.org/10.3390/rs70100922>
- [7] Yi, C., Nasrabadi, N.M. and Tran, T.D. (2013) Hyperspectral Image Classification via Kernel Sparse Representation. *IEEE Transactions on Geoscience and Remote Sensing*, **51**, 217-231. <https://doi.org/10.1109/TGRS.2012.2201730>
- [8] Melgani, F. and Bruzzone, L. (2004) Classification of Hyperspectral Remote Sensing Images with Support Vector Machines. *IEEE Transactions on Geoscience and Remote Sensing*, **42**, 1778-1790. <https://doi.org/10.1109/TGRS.2004.831865>
- [9] Tarabalka, Y., Fauvel, M., Chanussot, J. and Benediktsson, J.A. (2010) SVM- and MRF-Based Method for Accurate Classification of Hyperspectral Images. *IEEE Geoscience and Remote Sensing Letters*, **7**, 736-740. <https://doi.org/10.1109/LGRS.2010.2047711>
- [10] Wei, L.F., Yu, M., Zhong, Y.F., Zhao, J., Liang, Y.J. and Hu, X. (2019) Spatial-Spectral Fusion Based on Conditional Random Fields for the Fine Classification of Crops in UAV-Borne Hyperspectral Remote Sensing Imagery. *Remote Sensing*, **11**, Article 780. <https://doi.org/10.3390/rs11070780>
- [11] Liu, L., Jiang, X.-G., Xian-Bin, Li, X.B. and Tang, L.-L. (2006) Study on Classification of Agricultural Crop by Hyperspectral Remote Sensing Data. *Journal of University of Chinese Academy of Sciences*, **23**, 484-488.