

多尺度特征融合1D-CNN的马铃薯植株 高光谱数据地物分类和缺素识别*

高文强^{1,2}, 肖志云^{1,2}

(1. 内蒙古工业大学电力学院, 呼和浩特市, 010080;

2. 内蒙古自治区机电控制重点实验室, 呼和浩特市, 010051)

摘要:针对传统机器学习算法对高光谱数据建模步骤繁琐、常规的卷积神经网络在高光谱图像上细节表现力不强等问题,设计一种基于多尺度特征融合的网络结构。通过采样和池化层参数优化,将1D-CNN中不同深度的特征层进行融合,获得更加丰富的高光谱的判别特征。网络训练采用独热编码进行标记训练,解决了分类器处理属性数据困难的问题,在一定程度上起到了扩充特征的作用。结果表明,相比于SVM和常规1D-CNN网络,利用多尺度特征融合1D-CNN在地物分类实验中对感兴趣区域进行分类的准确率提高了63.99%和5%,在缺素识别实验中对缺氮缺磷缺钾以及正常的马铃薯叶片的识别准确率都在99%以上,其中利用该研究所提算法相比于SVM对正常叶片、缺氮叶片、缺磷叶片以及缺钾叶片的识别准确率分别提升了1.7%、6.82%、2.99%、24.8%。相比于常规1D-CNN在对正常叶片、缺钾叶片、缺磷叶片的识别准确率分别提升了0.03%、0.17%、0.76%。将多个尺度的高光谱信息特征融合并结合1D-CNN进行特征提取可提高对高光谱图像地物分类精度以及马铃薯植株的缺素识别准确率。

关键词:多尺度特征融合;独热编码;卷积神经网络;高光谱图像分类

中图分类号:S-3 **文献标识码:**A **文章编号:**2095-5553 (2022) 03-0111-09

高文强, 肖志云. 多尺度特征融合1D-CNN的马铃薯植株高光谱数据地物分类和缺素识别[J]. 中国农机化学报, 2022, 43(3): 111-119

Gao Wenqiang, Xiao Zhiyun. Multi-scale feature fusion 1D-CNN potato plant hyperspectral data feature classification and element identification [J]. Journal of Chinese Agricultural Mechanization, 2022, 43(3): 111-119

0 引言

马铃薯含有丰富蛋白质、膳食纤维、维生素等,是仅次于小麦、水稻、玉米的世界第四大主要粮食作物^[1]。在马铃薯植株的生长发育过程中,氮、磷、钾三大营养元素起着至关重要的作用,营养元素配比不合理,施肥时期不科学,会影响马铃薯的生长、产量和品质。常用的农作物营养元素检测方法为化学法,虽然测量准确、稳定性高,但时间久,检测成本高,且会破坏叶片本身,不宜在实际农业生产中推广使用。随着机器学习算法的不断发展,为农产品的营养元素亏缺检测提供了新方案。杨红云等^[2]应用机器学习算法对水稻敏感叶位全氮含量进行了估测。李哲等通过利用BP神经网络算法和图像数据对甜菜氮素含量进行预测。虽然利用

传统的机器学习算法结合图像处理可以对农作物进行缺素检测,但由于传统基于图像的营养元素检测方法只考虑图像信息,检测精度较差。

高光谱图像(HSI)具有波段范围广,可同时获取被测样本的图像信息和光谱信息,这使其拥有强大的对目标区分能力,因此近年来被广泛用于农作物产品的检测领域。卓伟等^[3]利用贝叶斯正则化一反向传播神经网络模型实现了马铃薯叶片的无损检测,且该方法较传统的预测模型可获得更高的预测精度。罗建军等^[4]利用优化参数后的SVM模型对水稻氮素营养状况进行了定性诊断。孙红等^[5]利用CA-PLSR和RF-PLSR两种模型对马铃薯叶片的含水量进行了可视化分析。虽然利用高光谱图像和机器学习算法在农作物产品的检测方面效果较好^[6-9],但高光谱图像各个波段

收稿日期:2021年5月12日 修回日期:2022年2月17日

*基金项目:国家自然科学基金项目(61661042);内蒙古自治区科技计划项目(2021GG0345);内蒙古自治区自然科学基金项目(2021MS06020)

第一作者:高文强,男,1996年生,内蒙古呼伦贝尔人,硕士研究生;研究方向为有关机器学习算法在农业中应用。E-mail: 1451522890@qq.com

通讯作者:肖志云,男,1974年生,湖南嘉禾人,博士,教授;研究方向为图像处理与模式识别等。E-mail: xiaozhiyun@imut.edu.cn

关系复杂且共线性较强,传统的机器学习算法处理能力有限,在训练模型之前需要进行特征波段的提取以减少数据量,过程较为繁琐^[10-12]。如何使用一种既能简化数据预处理过程又可以保证建模精度的方法显得十分重要。

随着计算机技术的发展,以卷积神经网络(CNN)为代表的深度学习逐渐发展起来。利用卷积层和池化层可以提取出数据特征,且卷积层具有权值共享和局部连接的特性,减少了网络参数,使模型得到进一步优化^[13-14]。由于常规1D卷积神经网络(1D-CNN)只能对单一层的特征进行提取^[15-17],细节表现力不强。针对这一问题本文提出一种多尺度特征融合1D-CNN,与常规1D-CNN相比,多尺度特征融合1D-CNN将不同维度的卷积池化层进行融合堆叠,充分利用高光谱的细节特征^[18-19],提高模型的适用性和计算精度。

利用1D-CNN对马铃薯植株叶片的高光谱数据多个尺度特征进行提取,并通过上采样和池化方法将不同深度的特征信息融合,实现马铃薯植株高光谱数

据地物分类以及对不同缺素植株叶片进行识别。

1 材料与方法

1.1 试验材料

本文使用新型手持式高光谱相机 Specim IQ 进行高光谱数据采集,其高光谱摄像头分辨率为512像素×512像素,采集的光谱范围为400~1 000 nm,光谱分辨率为7 nm,共204个波段。高光谱数据采集的地点为内蒙古自治区乌兰察布右中旗的马铃薯绿色高产高效技术试验展示区。采集期间将高光谱相机积分时间统一调整为5 ms,距马铃薯高度20 cm,将白板与植株同时拍摄以消除环境不匹配问题。

采集到的马铃薯植株叶片的高光谱图像共计72个,其中缺氮14个、缺磷15个、缺钾27个以及正常的马铃薯植株叶片16个。选取总样本数的78%作为模型训练集,即将56个样本作为训练集,其余16个样本作为预测集。图1为利用手持式高光谱相机 SpecimIQ 采集到的马铃薯植株的高光谱图像。




图1 高光谱图像数据

Fig. 1 Hyperspectral image data

1.2 基于多尺度特征融合1D-CNN马铃薯营养元素亏缺识别算法

1.2.1 高光谱数据预处理与光谱信息分析

本文利用多尺度特征融合1D-CNN模型对5种地物进行分类,将分类结果中无阴影的马铃薯植株叶片作为研究对象进行提取。由于在每个高光谱波段下,光谱强度分布不均匀,需要对原始光谱数据进行黑白校正,校正式如式(1)所示。

$$R = \frac{I - B}{W - B} \quad (1)$$

式中: R ——校正之后的图像;

W ——标准白板得到全白标定图像;

B ——相机全黑的标定图像;

I ——原始高光谱图像。

图2(a)为经过黑白校正之后的5类地物高光谱曲线,5类地物分别为:马铃薯叶片、带阴影的马铃薯叶片、白板、土地以及花朵。图2(b)为经过黑白校正之后的4种缺素马铃薯植株叶片高光谱曲线,由图中4种马铃薯植株的叶片平均高光谱曲线可知,不同类别马铃薯植株叶片的高光谱曲线有所差异,波段范围500~600 nm之间四类马铃薯植株叶片的高光谱曲线差异明显。

在近红边和近红外范围,正常马铃薯叶片的光谱反射率高于其他三种缺素植株叶片得光谱反射率,而在可见光550 nm附近四类植株叶片的光谱曲线均出现了波峰。由于叶绿素在680 nm附近对光的强烈吸收,四类马铃薯植株叶片在680 nm附近范围内的光谱曲线均出现了波谷。




图2 五类地物与四种缺素马铃薯植株叶片的高光谱信息

Fig. 2 Hyperspectral information of five types of ground features and four kinds of potato plant leaves

1.2.2 多尺度特征融合 1D-CNN 结构

多尺度特征融合 1D-CNN 在常规 1D-CNN 模型的结构基础上将多个特征层进行融合以获得更丰富

的特征信息。

常规的 1D-CNN 的结构如图 3 所示,网络包括 6 个卷积层(Conv1D)和 3 个池化层(MaxPooling1D),最后通过平铺层(flatten)连接到全连接层(Dense)。7 分类操作通过在全连接层使用 Softmax 分类器进行实现^[20]。使用的常规 1D-CNN 中所有卷积层中的卷积核大小为 3 卷积核个数为 64 卷积步长为 1,池化层中池化窗口大小为 2,网络参数分布情况与网络层连接方式如表 1 所示。

多尺度特征融合 1D-CNN 结构如图 4 所示,其主干网络将图 3 中 1D-CNN 结构中第一池化层(pool1)步长由 2 增加为 3,使得 pool1 层的深度由 102 减少为 68,具体网络参数分布情况与网络层连接方式如表 2 所示。

网络通过使用 1D 上采样(UpSaming1D)的方式,将深度不足的池化层进行乘倍数的增加,实现了与深度较大的池化层的合并。

最后将融合层(C2)进行平铺展开,由于平铺层数据增加,D1 层的神经元数由常规 1D-CNN 中的 20 个增加到 200 个。

多尺度特征融合 1D-CNN 将常规 1D-CNN 模型的每个池化层进行堆叠融合,从低层池化层中获得高光谱数据的细节信息,在高层池化中提取光谱曲线的变换趋势,实现了对高光谱数据的变化趋势以及细节信息进行综合分析。

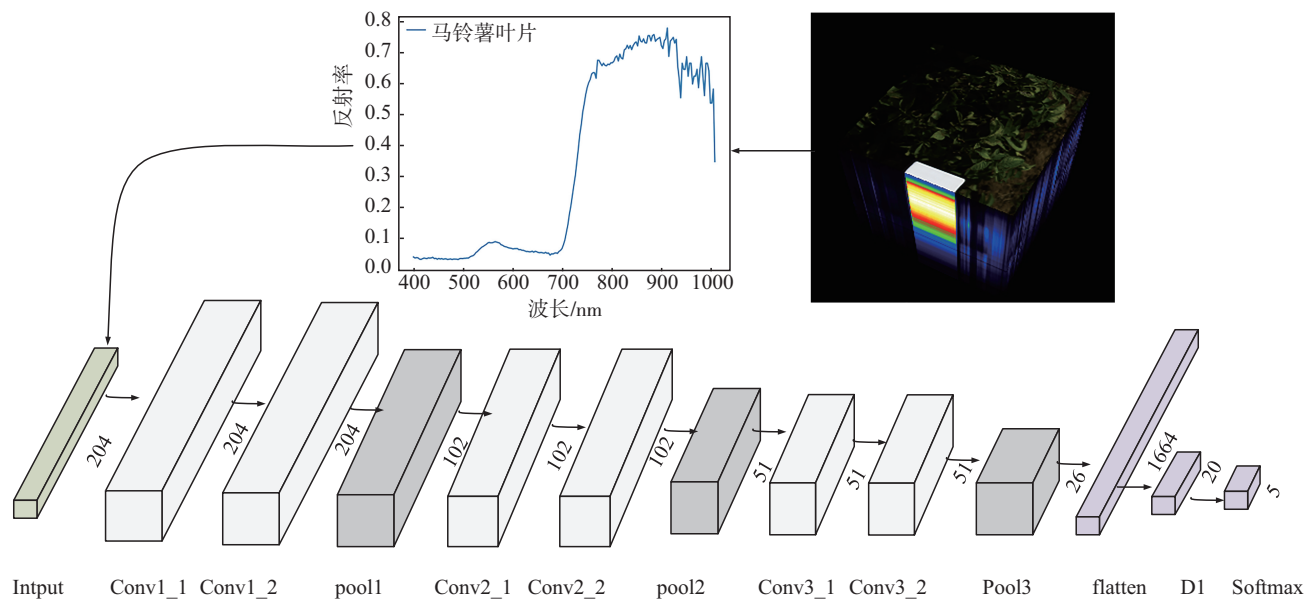


图3 1D-CNN 的网络结构

Fig. 3 Network structure of 1D-CNN

1.2.3 多尺度特征融合 1D-CNN 的模型训练

训练时标签类别使用独热编码进行标记训练,独热编码解决了分类器不好处理属性数据的问题^[21],在

一定程度上也起到了扩充特征的作用。它的值只有 0 和 1,将不同的类型数据存储在垂直的空间。独热编码与顺序编码对照比较如表 3。由于研究对象训练类别

较少适合采用独热编码方法,损失函数使用交叉熵损失函数。

表 1 常规 1D—CNN 网络结构
Tab. 1 Network structure of Conventional 1D—CNN

layer	type	Output Shape	Param	Connected to
input	InputLayer	(None, 204, 1)	0	
conv1_1	Conv1D	(None, 204, 64)	256	input
conv1_2	Conv1D	(None, 204, 64)	12352	conv1_1
Pool1	MaxPooling1D	(None, 102, 64)	0	conv1_2
Conv2_1	Conv1D	(None, 102, 64)	12352	Pool1
Conv2_2	Conv1D	(None, 102, 64)	12352	Conv2_1
Pool2	MaxPooling1D	(None, 51, 64)	0	Conv2_2
Conv3_1	Conv1D	(None, 51, 64)	12352	Pool2
Conv3_2	Conv1D	(None, 51, 64)	12352	Conv3_1
Pool3	MaxPooling1D	(None, 26, 64)	0	Conv3_2
flatten	Flatten	(None, 1664)	0	Pool3
D1	Dense	(None, 20)	33300	flatten
Softmax	Dense	(None, 5)	105	D1

表 2 多尺度特征融合 1D—CNN 结构
Tab. 2 Multi-scale feature fusion 1D—CNN structure

layer	type	Output Shape	Param	Connected to
input	Input Layer	(None, 204, 1)	0	
conv1_1	Conv1D	(None, 204, 64)	256	input
conv1_2	Conv1D	(None, 204, 64)	12352	conv1_1
Pool1	MaxPooling1D	(None, 68, 64)	0	conv1_2
Conv2_1	Conv1D	(None, 68, 64)	12352	Pool1
Conv2_2	Conv1D	(None, 68, 64)	12352	Conv2_1
Pool2	MaxPooling1D	(None, 34, 64)	0	Conv2_2
Conv3_1	Conv1D	(None, 34, 64)	12352	Pool2
Conv3_2	Conv1D	(None, 34, 64)	12352	Conv3_1
Pool3	MaxPooling1D	(None, 17, 64)	0	Conv3_2
Up2	UpSampling1D	(None, 68, 64)	0	Pool2
Up3_1	UpSampling1D	(None, 34, 64)	0	Pool3
C1	Concatenate	(None, 68, 128)	0	Pool1,Up2
Up3_2	UpSampling1D	(None, 68, 64)	0	Up3_1
C2	Concatenate	(None, 68, 192)	0	C1,Up_3_2
flatten	Flatten	(None, 13056)	0	C2
D1	Dense	(None, 200)	2 611 400	flatten
Softmax	Dense	(None, 5)	1 005	D1

表 3 独热与顺序编码比较
Tab. 3 Comparison of one-hot encoding and sequential encoding

三种标签类别:	类别	A	B	C	损失函数
A,B,C	独热编码	[1,0,0]	[0,1,0]	[0,0,1]	categorical_crossentropy
	顺序编码	0	1	2	sparse_categorical_crossentropy

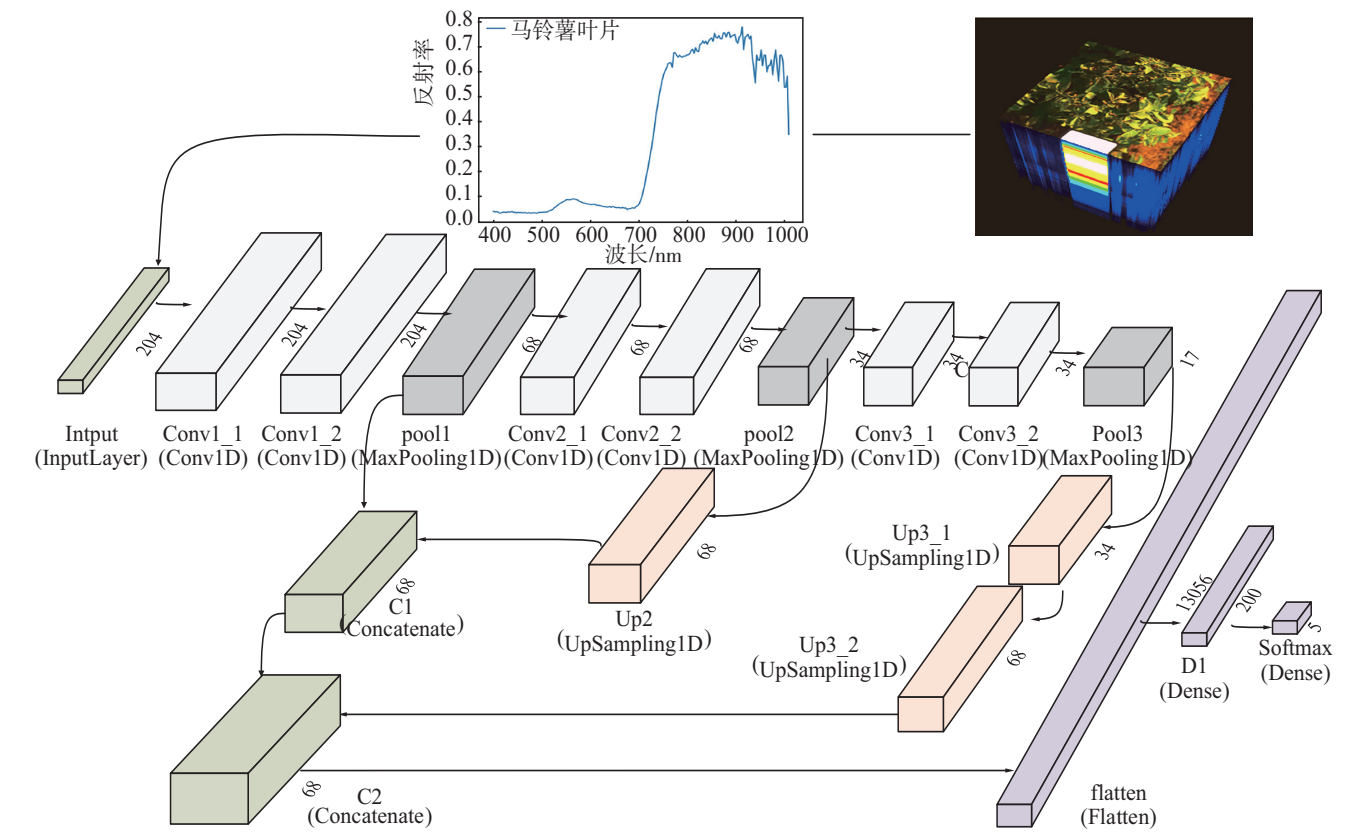


图 4 多尺度特征融合 1D-CNN

Fig. 4 Multi-scale feature fusion 1D-CNN

2 实验结果与分析

2.1 五类地物分类结果与分析

一组高光谱数据包括 262 144 个像素点,其中训练集 209 408 个,测试集 52 736 个,表 4 为利用多尺度特征融合 1D-CNN 模型对地物分类训练集与测试集进行预测结果的混淆矩阵,其中标识区域为正确预测出地物类别的个数。表 5 为利用训练集和测试集预测结果的混淆矩阵计算出对地物分类预测结果的准确率和召回率,其中准确率表示预测正确的正例数据占预测

为正例数据的比例,召回率为预测为正确的正例数据占实际为正例数据的比例。

表 6 为利用多尺度特征融合 1D-CNN 模型对含有地物信息高光谱数据的训练集和测试集进行预测的结果对比,预测时间上由于每次模型加载过程需要时间损耗,所以在训练集和测试集加载时间比要小于数据量之比。分类精度上、平均准确率、平均召回率、F1 值(调和平均值)在训练集和测试集都达到了 0.985 以上,表明该模型对高光谱数据的地物分类具有一定的有效性。

表 4 地物分类训练集与测试集预测结果的混淆矩阵

Tab. 4 Confusion matrix of the prediction results of the ground object classification training set and test set

		无阴影叶片	有阴影叶片	土地	斑点	白板
无阴影叶片	train5	46 844	58	313	62	0
	test5	11 675	14	76	18	0
有阴影叶片	train5	605	38 935	484	255	0
	test5	162	10 456	148	68	0
土地	train5	46	98	40 068	792	0
	test5	10	30	10 397	205	0
斑点	train5	4	3	9	73 135	0
	test5	1	2	1	17 046	0
白板	train5	0	0	0	23	7 674
	test5	0	0	0	4	2 423

表 5 地物分类不同类别预测结果的准确率和召回率

Tab. 5 Accuracy and recall rate of prediction results of different categories of ground feature classification

	无阴影叶片	有阴影叶片	土地	斑点	白板
训练集准确率	0.986	0.996	0.980	0.985	1.000
测试集准确率	0.985	0.996	0.979	0.983	1.000
训练集召回率	0.991	0.967	0.977	1.000	0.997
测试集召回率	0.991	0.965	0.977	1.000	0.998

表 6 地物分类的预测结果

Tab. 6 Forecast results of ground feature classification

	训练时间/s	加载时间/s	精度	平均准确率	平均召回率	F1
训练集	559.110	15.270	0.987	0.989	0.986	0.988
测试集	—	4.870	0.986	0.989	0.986	0.987

表 7 为使用多尺度特征融合 1D-CNN、1D-CNN、SVM 三种方法对马铃薯植株的高光谱数据部分像素点进行分类的结果。从结果中看,SVM 对高光谱的 5 种地物分类较差,且对于感兴趣区域马铃薯叶片的

像素点无法进行有效的分类识别。
这是因为传统的机器学习算法泛化能力差无法考虑到高光谱的细节信息,不足以应对高光谱图像复杂的空间分布。

表 7 不同模型对高光谱数据的像素点分类结果

Tab. 7 Results of pixel point classification of hyperspectral data by different models

高光谱样本数据	SVM		1D-CNN		多尺度特征融合 1D-CNN	
	正确数	准确率/%	正确数	准确率/%	正确数	准确率/%
马铃薯叶片像素点(17 379)	6 223	35.81	16 462	94.72	17 344	99.80
马铃薯阴影叶片像素点(10 595)	10 536	99.44	9 571	90.34	10 459	98.72
土地像素点(8 524)	1 869	21.92	8 131	95.39	8 282	97.16
斑点像素点(2 075)	1 767	85.16	2 062	99.37	2 063	99.42
白板像素点(1 427)	1 398	97.97	1 412	98.95	1 426	99.93

利用多尺度特征融合 1D-CNN 算法对不同缺失马铃薯植株进行地物分类的结果如图 5 所示。

及二者误差,误差图像中浅色区域为正确分类的像素点,阴影区域为错误分类的像素点。

相比利用深度学习算法和卷积操作可以对高光谱数据的一些重要特征进行有效提取,对 5 种地物种类进行有效的分类。所提的多尺度特征融合 1D-CNN 算法在细节特征的表现力上优于常规 1D-CNN 算法,能够更加准确地实现了对 5 种地物的高光谱数据像素点的分类。与使用常规 1D-CNN 方法相比,利用多尺度特征融合 1D-CNN 方法对感兴趣区域进行分类的准确率提高了 5%。

2.2 四种植株叶片缺素识别结果与分析

对不同种类植株叶片高光谱数据进行地物分类,并对其分类结果进行筛选,选取出类别为无阴影区域的叶片作为缺素识别的研究对象。将研究对象进行数据集划分,其中训练集 303 246 个,测试集 75 812 个,表 8 为利用多尺度特征融合 1D-CNN 模型对缺素识别训练集和测试集预测结果的混淆矩阵,其中标识区域为正确预测出地物类别的个数。表 9 为利用训练集和测试集预测结果的混淆矩阵计算出对缺素识别预测结果的准确率和召回率。

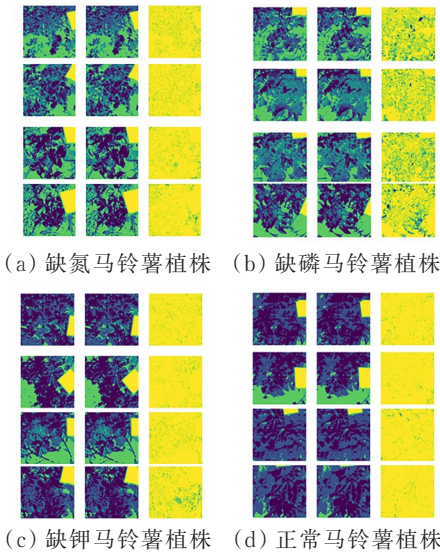


图 5 利用多尺度特征融合 1D-CNN 算法进行地物分类

Fig. 5 Feature classification using multi-scale feature fusion 1D-CNN algorithm

其中每种缺素马铃薯植株各 4 组,每组分类结果包括了利用算法进行分类的结果、原始数据标签图以

表 8 缺素识别训练集和测试集预测结果的混淆矩阵

Tab. 8 Confusion matrix of the lack of element recognition training set and test set prediction results

		缺氮	缺磷	缺钾	正常
缺氮	train4	44 452	54	2116	0
	test4	11 269	14	511	0
缺磷	train4	0	46 915	0	0
	test4	0	11 705	0	0
缺钾	train4	318	91	102 855	9
	test4	69	26	25 620	3
正常	train4	0	58	5	106 373
	test4	0	13	2	26 580

表 9 缺素识别不同类别预测结果的准确率和召回率

Tab. 9 Accuracy and recall rate of predicting results for different types of element-deficiency recognition

	缺氮	缺磷	缺钾	正常
训练集准确率	0.993	0.996	0.980	0.999
测试集准确率	0.994	0.996	0.980	1.000
训练集召回率	0.954	1.000	0.996	0.994
测试集召回率	0.956	1.000	0.996	0.999

表 10 为利用多尺度特征融合 1D-CNN 模型对缺素叶片高光谱数据的训练集和测试集进行预测的结果对比,由于存在模型加载过程的时间损耗,所以在训练集和测试集加载时间比要小于数据量之比。分类精度

表 11 不同模型对缺素马铃薯的像素点分类结果

Tab. 11 Results of pixel point classification of vegetation deficient potatoes by different models

高光谱数据	SVM		1D-CNN		多尺度特征融合 1D-CNN	
	正确数	准确率/%	正确数	准确率/%	正确数	准确率/%
缺氮马铃薯植株叶片像素(46 942)	43 697	93.09	46 918	99.95	46 898	99.91
缺磷马铃薯植株叶片像素(103 279)	100 077	96.90	102 380	99.13	103 169	99.89
缺钾马铃薯植株叶片像素(46 670)	31 512	70.70	44 491	95.33	44 569	95.50
正常马铃薯植株叶片像素(106 356)	104 536	98.29	106 313	99.96	106 352	99.99

图 6 为两种卷积神经网络对 4 种马铃薯植株叶片识别的训练结果,多尺度特征融合 1D-CNN 在第 22 次训练时基本已经达到稳定较优训练结果,常规 1D-CNN 在第 30 次之后才可以到达稳定的训练结果。




图 6 识别训练的损失函数

Fig. 6 Loss function for deficiency recognition training

上、平均准确率在训练集和测试集都达到了 0.99 以上,平均召回率、F1 值在训练集和测试集都达到了 0.985 以上,表明该模型对马铃薯植株叶片高光谱数据的缺素识别具有一定的适用性。

表 10 缺素识别的预测结果

Tab. 10 Prediction results of element deficiency recognition

	训练时 间/s	加载时 间/s	精度	平均准 确率	平均召 回率	F1
训练集	644.640	19.810	0.991	0.992	0.986	0.989
测试集	— — —	6.140	0.992	0.992	0.988	0.990

表 11 为对三种缺素马铃薯叶片以及正常的马铃薯叶片识别结果。从亏损识别结果上看,SVM 对缺钾元素的马铃薯叶片识别率低,准确率仅为 70.7%。而使用带有卷积池化层的 1D-CNN 对缺钾马铃薯叶片的识别准确率为 95.33%。

提出多尺度特征融合 1D-CNN 算法对缺钾马铃薯叶片的识别准确率高达 95.50%,相对于常规的 1D-CNN 网络提升了 0.17%。利用多尺度特征融合 1D-CNN 对缺氮、缺磷以及正常马铃薯叶片数据集进行识别,其识别准确率在 99% 以上,识别精度均高于 SVM 方法。对缺磷、缺钾以及正常的马铃薯叶片的识别,利用多尺度特征融合 1D-CNN 算法相比于使用常规 1D-CNN 算法,其识别精度上有了进一步提升。

根据模型训练的损失函数结果表明,使用多尺度特征融合 1D-CNN 相对 1D-CNN 下降更快,对四种马铃薯植株叶片缺素识别的准确率更高。

3 结论

提出一种基于多尺度特征融合 1D-CNN 的高光谱图像分类方法,并用于对不同缺素马铃薯植株的叶片识别。该方法通过将高光谱数据的多个特征进行融合,使得提取到的光谱特征细节表现力更强,进而提升了对高光谱数据分类的性能。

在 5 种地物的光谱数据分类实验上其分类精度、平均准确率、平均召回率、F1 值在训练集和测试集都达到了 0.985 以上,在 4 种马铃薯叶片缺素识别实验上其分类精度、平均准确率在训练集和测试集都达到了

0.99以上,平均召回率、F1值在训练集和测试集都达到了0.985。实验结果证明,所提方法较传统的机器学习算法和单一的1D-CNN具有更优秀的分类结果,是一种更有效的网络结构。

在未来的研究中将在网络中加入注意力机制,对不同特整层进行权重重新分配,进一步增强对高光谱数据特征的获取能力,从而提升网络的整体性能。

参 考 文 献

- [1] Arun K B, Chandran J, Dhanya R, et al. A comparative evaluation of antioxidant and antidiabetic potential of peel from young and matured potato [J]. Food Bioscience, 2015, 9(4): 36–46.
- [2] 杨红云, 罗建军, 孙爱珍, 等. 基于图像特征的水稻叶片全氮含量估测模型研究[J]. 浙江农业学报, 2020, 32(12): 2232–2243.
- Yang Hongyun, Luo Jianjun, Sun Aizhen, et al. Study on estimation model of total nitrogen content in rice leaves based on image characteristics [J]. Acta Agriculturae Zhejiangensis, 2020, 32(12): 2232–2243.
- [3] 卓伟, 于旭峰, 李欣庭, 等. 高光谱成像技术实现马铃薯叶片叶绿素无损检测[J]. 光学仪器, 2020, 42(6): 1–8.
- Zhuo Wei, Yu Xufeng, Li Xinting, et al. Non-destructive detection of potato leaf chlorophyll with hyperspectral imaging technology [J]. Optical Instruments, 2020, 42(6): 1–8.
- [4] 罗建军, 杨红云, 路艳, 等. 基于高光谱和参数优化支持向量的水稻施氮水平分类研究[J]. 中国土壤与肥料, 2020(5): 250–257.
- Luo Jianjun, Yang Hongyun, Lu Yan, et al. Classification of nitrogen application levels in rice based on hyperspectral and parameter optimized support vector machine [J]. Soil and Fertilizer Sciences in China, 2020(5): 250–257.
- [5] 孙红, 刘宁, 吴莉, 等. 高光谱成像的马铃薯叶片含水率分布可视化[J]. 光谱学与光谱分析, 2019, 39(3): 910–916.
- Sun Hong, Liu Ning, Wu Li, et al. Visualization of water content distribution in potato leaves based on hyperspectral image [J]. Spectroscopy and Spectral Analysis, 2019, 39(3): 910–916.
- [6] 刘燕德, 姜小刚, 周衍华, 等. 基于高光谱成像技术对脐橙叶片的叶绿素、水分和氮素定量分析[J]. 中国农机化学报, 2016, 37(3): 218–224.
- Liu Yande, Jiang Xiaogang, Zhou Yanhua, et al. Quantitative analysis of chlorophyll, water and nitrogen for navel orange leaf based on hyper-spectral imaging technology [J]. Journal of Chinese Agricultural Mechanization, 2016, 37(3): 218–224.
- [7] 霍迎秋, 张晨, 李宇豪, 等. 高光谱图像结合机器学习方法无损检测猕猴桃[J]. 中国农机化学报, 2019, 40(4): 71–77.
- Huo Yingqiu, Zhang Chen, Li Yuhao, et al. Nondestructive detection for kiwifruit based on the hyperspectral technology and machine learning [J]. Journal of Chinese Agricultural Mechanization, 2019, 40(4): 71–77.
- [8] 魏利峰, 纪建伟. 高光谱图像技术检测农作物含水量的研究进展[J]. 中国农机化学报, 2016, 37(7): 80–84.
- Wei Lifeng, Ji Jianwei. Advancement of detection of crop moisture content based on hyperspectral imaging [J]. Journal of Chinese Agricultural Mechanization, 2016, 37(7): 80–84.
- [9] 孙旭东, 郝勇, 张光伟. 近红外光谱结合最小二乘支持向量的脐橙叶片含水率无损检测[J]. 中国农机化学报, 2015, 36(2): 150–153, 168.
- Sun Xudong, Hao Yong, Zhang Guangwei. Nondestructive detection of water content for navel oranges' leaves using near-infrared spectroscopy combined with least squares support vector machine [J]. Journal of Chinese Agricultural Mechanization, 2015, 36(2): 150–153, 168.
- [10] 阳昌霞, 刘汉湖, 张春. 基于SVM与RF的无人机高光谱农作物精细分类[J]. 河南科学, 2020, 38(12): 1987–1995.
- Yang Changxia, Liu Hanhu, Zhang Chun. UAV hyperspectral remote sensing image crop fine classification based on SVM and RF [J]. Henan Science, 2020, 38(12): 1987–1995.
- [11] 李广洋, 寇卫利, 陈帮乾, 等. 多核学习算法及其在高光谱图像分类中的应用研究进展[J]. 地球信息科学学报, 2021, 23(3): 492–504.
- Li Guangyang, Kou Weili, Chen Bangqian, et al. Multiple kernel learning algorithm and its application research progress in hyperspectral image classification [J]. Journal of Geo-information Science, 2021, 23(3): 492–504.
- [12] 赵凡, 闫昭如, 薛建新, 等. 高光谱无损识别野生和种植黑枸杞[J]. 光谱学与光谱分析, 2021, 41(1): 201–205.
- Zhao Fan, Yan Zhaoru, Xue Jianxin. Identification of wild black and cultivated goji berries by hyperspectral image [J]. Spectroscopy and Spectral Analysis, 2021, 41(1): 201–205.
- [13] 李超, 柴玉梅, 南晓斐, 等. 基于深度学习的问题分类方法研究[J]. 计算机科学, 2016, 43(12): 115–119.
- Li Chao, Chai Yumei, Nan Xiaofei, et al. Research on problem classification method based on deep-learning [J]. Computer Science, 2016, 43(12): 115–119.
- [14] 周飞燕, 金林鹏, 董军. 卷积神经网络研究综述[J]. 计算机学报, 2017, 40(6): 1229–1251.
- Zhou Feiyan, JinLinpeng, Dong Jun. Review of convolutional neural network [J]. Chinese Journal of Computers, 2017, 40(6): 1229–1251.
- [15] Huang K K, Ren C X, Liu H, et al. Hyperspectral image classification via discriminative convolutional neural network with an improved triplet loss [J]. Pattern Recognition, 2020, 112(2): 107744.

- [16] 万亚玲, 钟锡武, 刘慧, 等. 卷积神经网络在高光谱图像分类中的应用综述[J]. 计算机工程与应用, 2021, 57(4): 1—10.
Wan Yaling, Zhong Xiwu, Liu Hui, et al. Survey of application of convolutional neural network in classification of hyperspectral images [J]. Computer Engineering and Applications, 2021, 57(4): 1—10.
- [17] Polder G, Blok P M, Villiers H, et al. Potato virus y detection in seed potatoes using deep learning on hyperspectral images [J]. Other, 2019, 10.
- [18] 高红民, 曹雪莹, 陈忠昊, 等. 基于多尺度近端特征拼接网络的高光谱图像分类方法[J]. 通信学报, 2021, 42(2): 92—102.
Gao Hongmin, Cao Xueying, Chen Zhonghao, et al. Hyperspectral image classification method based on multi-scale proximal feature concatenate network [J]. Journal on Communications, 2021, 42(2): 92—102.
- [19] 潘绍明. 基于多融合多尺度特征的高光谱图像分类研究[J]. 激光杂志, 2021, 42(2): 110—114.
- [20] 陈俊芬, 赵佳成, 韩洁, 等. 基于深度特征表示的 Softmax 聚类算法[J]. 南京大学学报(自然科学), 2020, 56(4): 533—540.
Chen Junfen, Zhao Jiacheng, Han Jie, et al. Softmax clustering algorithm based on deep features representation. Journal of Nanjing University(Natural Science), 2020, 56(4): 533—540.
- [21] 梁杰, 陈嘉豪, 张雪芹, 等. 基于独热编码和卷积神经网络的异常检测[J]. 清华大学学报(自然科学版), 2019, 59(7): 523—529.
Liang Jie, Chen Jiahao, Zhang Xueqin, et al. One-hot encoding and convolutional neural network based anomaly detection [J]. Journal of Tsinghua University(Science and Technology), 2019, 59(7): 523—529.

Multi-scale feature fusion 1D-CNN potato plant hyperspectral data feature classification and element identification

Gao Wenqiang^{1, 2}, Xiao Zhiyun^{1, 2}

(1. College of Electric Power, Inner Mongolia University of Technology, Huhhot, 010080, China;

2. Inner Mongolia Key Laboratory of Mechatronic Control, Huhhot, 010051, China)

Abstract: Aiming at the challenges facing traditional machine learning algorithms such as cumbersome modeling steps for hyperspectral data and conventional convolutional neural networks not being very expressive in details on hyperspectral images, a network structure based on multi-scale feature fusion was designed. By up-sampling and pooling layer parameter optimization, feature layers of different depths in 1D-CNN were fused to obtain richer discriminative features for hyperspectral. The network training used unique thermal coding for labeling training, which solved the problem of the classifier having difficulty in processing attribute data and also played a role in expanding the features to a certain extent. The results showed that the accuracy of classifying regions of interest using multi-scale feature fusion 1D-CNN in feature classification experiments was improved by 63.99% and 5% compared to SVM and conventional 1D-CNN networks. In the deficiency recognition experiments, the recognition accuracies of nitrogen deficiency, phosphorus deficiency, and potassium deficiency, as well as normal potato leaves, were above 99%, and were improved by 1.7%, 6.82%, 2.99%, and 24.8%, respectively, using the proposed algorithm compared with SVM. Compared with conventional 1D-CNN, the accuracy of recognition of normal leaves, potassium-deficient leaves, and phosphorus-deficient leaves was improved by 0.03%, 0.17%, and 0.76%, respectively. The fusion of hyperspectral information features at multiple scales and the combination of 1D-CNN for feature extraction can improve the accuracy of feature classification of hyperspectral images as well as the accuracy of deficiency identification of potato plants.

Keywords: multi-scale feature fusion; one-hot encoding; convolutional neural network; hyperspectral image classification