

基于卷积神经网络特征提取的莴苣生长无损监测

阳昊¹, 黄超^{1,2}, 刘欣然¹, 王中举¹, 王龙^{1,2}

(1. 北京科技大学 计算机与通信工程学院, 北京 100083;

2. 北京科技大学 顺德创新学院, 广东 佛山 528399)

摘要: 基于计算机视觉的莴苣生长无损监测对莴苣的种植管理有重要的意义。彩色图像包含的纹理、色泽等信息与莴苣生长参数密切相关。以往的研究包括基于人为设计的特征结合机器学习算法估计生长参数, 以及通过卷积网络估计生长参数。该文设计了一种结合卷积神经网络和机器学习模型的二阶段算法, 用于莴苣的生长参数无损估计。生长参数包括叶片鲜重(LFW)、叶片干重(LDW)、植株高度(H)、植株直径(D)和叶面积(LA)。算法的第一阶段训练卷积网络自动从图像中提取特征, 第二阶段基于卷积网络提取的特征, 利用集成机器学习算法 Stacking(随机森林, 深度森林)估计生长参数。实验结果表明, 相比直接使用卷积网络估计, 设计的二阶段算法能显著降低误差, 在五个生长参数上的归一化均方误差(NMSE)分别为 2.25%, 2.61%, 1.63%, 0.84%, 3.18%, 估计值与真实值的决定系数(R^2)为 0.955 2, 0.957 8, 0.892 1, 0.884 4, 0.936 2。通过引入深度图, 使用 3D 卷积网络从彩色图和深度图的组合中提取特征, 高度(H)的估计准确度能进一步提高(NMSE: 1.27%, R^2 : 0.916 1)。表明通过卷积神经网络自动从图片中提取特征并结合集成机器学习算法用于莴苣的生长参数估计是可行的。

关键词: 莴苣; 无损监测; 卷积神经网络; 机器学习; 特征提取

中图分类号: TP301

文献标识码: A

文章编号: 1673-629X(2023)08-0137-07

doi: 10.3969/j.issn.1673-629X.2023.08.020

Convolutional Neural Networks Feature Extraction for Non-destructive Lettuce Growth Monitoring

YANG Hao¹, HUANG Chao^{1,2}, LIU Xin-ran¹, WANG Zhong-ju¹, WANG Long^{1,2}

(1. School of Computer and Communication Engineering, University of Science and Technology Beijing,

Beijing 100083, China;

2. Shunde Innovation School, University of Science and Technology Beijing, Foshan 528399, China)

Abstract: Computer vision based non-destructive growth monitoring is essential for lettuce planting management. The texture and color etc. in lettuce image are closely related with its growth traits. Previous studies on image-based traits estimation include machine learning-based methods with hand-crafted features and convolutional neural network (CNN)-based methods. We propose a two-stage method consisting of CNN and machine learning for lettuce growth traits estimation, including leaf fresh weight (LFW), leaf dry weight (LDW), height (H), diameter (D), and leaf area (LA). In the first stage, CNN is trained to automatically extract feature from images. In the second stage, Stacking regression (random forest, deep forest) is trained to estimate traits based on extracted features by CNN. Experiment results illustrate that the proposed two stage method outperforms CNN-based method with normalized mean square error (NMSE) of 2.25%, 2.61%, 1.63%, 0.84%, 3.18% for five traits respectively, and with R^2 values of 0.955 2, 0.957 8, 0.892 1, 0.884 4, 0.936 2, respectively. For height estimation, the introduction of depth image could further enhance performance with NMSE of 1.27% and R^2 of 0.916 1. The result indicates that CNN based feature extraction is valuable for lettuce growth traits estimation.

Key words: lettuce; non-destructive monitoring; convolutional neural network; machine learning; feature extraction

收稿日期: 2022-10-28

修回日期: 2023-03-01

基金项目: 国家自然科学基金项目(62002016); 广东省基础与应用基础研究基金(2020A1515110431); 佛山市人民政府科技创新专项基金(BK20BF010, BK21BF001, BK22BF009)

作者简介: 阳昊(1996-), 男, 硕士研究生, 研究方向为计算机视觉; 黄超(1988-), 男, 博士, 副教授, CCF 会员(A5866M), 研究方向为数据挖掘和计算智能; 通讯作者: 王龙(1988-), 男, 博士, 副教授, CCF 会员(86711M), 研究方向为数据挖掘、计算机视觉和计算智能。

0 引言

莴苣作为一种叶用蔬菜因其丰富的口感和质地而受到广大消费者的喜爱^[1]。有研究表明,生菜富含维生素、胡萝卜素、铁元素,对减少心血管疾病和慢性病有积极作用^[2]。莴苣的生长状态监测对最大化产量和提高莴苣品质具有重要意义^[3]。叶片鲜重(LFW)、叶片干重(LDW)、生菜高度(H)、生菜直径(D)、和叶面积(LA)是表征莴苣生长的关键指标。准确地获取生长状态指标(LFW、LDW、H、D 和 LA),对采取相应的生产措施有极大的参考价值。人为采集农作物样本获取生长指标的方法简单,能获取较为准确的结果,但会破坏作物,费时费力^[4]。卷积神经网络作为类脑领域重要的研究成果,能高效地处理图像输入,在工业界和学术界得到了广泛的应用^[5-6]。随着计算机视觉技术的发展,基于图像的农作物识别、无损监测方法具有广泛的前景^[7]。基于图像的监测方法通常从图像中抽取人为设计的特征,通过对这些特征与生长指标构建回归模型,进行无损的生长监测。Chen 等人^[8]从彩色图像、荧光图像、近红外图像中提取结构特征和近红外反应生理特征,利用支持向量机、随机森林、线性回归等机器学习算法估计大麦生物量的积累。结果表明,随机森林能更好地建立图像特征与生物量之间的关系。Tackenberg 等人^[9]提出了一种基于数字图像分析的牧草生长状态估计方法,以线性回归估计地表干物质质量、新鲜生物量等。实验结果显示所有模型的决定系数都高于 0.85,表明这些特征和生长特性有较好的线性关系。Casadesús 等人^[10]从不同彩色空间的图片中提取色彩特征来估计大麦的叶面积、绿色面积指数和干重,这些特征包括 HIS 色彩空间的 H 分量,CIELUV 色彩空间的 U 分量,实验结果表明这些特征与不同生长阶段的生长指标有很强的相关性。Fan 等人^[11]设计可见光和近红外摄像系统用于获取意大利黑麦草的时间序列图像,基于这些图像的 R、G 和 NIR 通道数值,利用多元线性回归模型估计叶面积指数从而量化麦草的生长。实验结果表明,对图像进行分割预处理能获得更好的准确率。Liu 等人^[12]利用基于直方图的阈值分割方法从图像中分割植被区域,再提取垂直间隙指数来估计大豆、玉米、小麦的叶面积指数。Sakamoto 等人^[13]从彩色图像和近红外图像中提取植被系数用于估计叶面积指数、总叶面积指数、生物量。实验表明,彩色图像提取的特征能准确地估计叶面积指数和叶片生物量,而从近红外图像中提取的特征能更准确地估计总叶面积指数。Daniel 等人^[14]从彩色图像和多光谱图像中提取归一化植被差异指数、绿色区域面积、简单比指数,利用最小二乘法估计木薯的生长和关键营养特性,实验表明,木薯矿物元素的含量与多光谱特征

的关联性较低。为了评估杂草对小麦生长的影响,Gée 等人^[15]利用支持向量机和视觉词汇袋技术从图像中估计杂草和小麦的覆盖率。除了二维图片,Briglia 等人^[16]利用 3D 图像来获得葡萄叶片角度的变化,由此来监测葡萄水分状况。根据以往的研究,图像的来源包括彩色图片、近红外图片、荧光图片和 3D 图片,针对不同的图片和具体估计的指标,需要设计不同的特征,如色彩特征、几何特征等。并且在设计之前,特征与指标之间的相关性是未知的,导致这类方法的泛化性能较差,特别是对于不同场景、不同的光照和复杂背景下获取的图片。Zhang 等人^[17]设计了一种基于卷积网络的莴苣生长指标估计算法,以图片作为模型的输入,直接输出 LFW、LDW 和 LA。实验表明相比于人工设计的从不同色彩空间提取的特征,卷积网络具有更好的精度,作者认为卷积网络的优势是能够更有效地从图像中提取复杂的特征。基于这一启发^[17],该文结合深度学习和机器学习,设计了两阶段的莴苣生长指标估计算法。在第一阶段通过训练卷积神经网络作为自动的特征提取工具;第二阶段利用神经网络自动从图像中提取的高维特征训练集成机器学习模型直接估计 LFW、LDW、LA、H 和 D。该文输入的图像包括彩色图像和深度图像。通过卷积网络提取特征,免除了人为特征的设计与筛选,算法具有鲁棒性,同时,特征提取网络和机器学习模型有广泛的选择,算法的设计具有灵活性。实验表明,相比直接利用卷积网络估计生长指标,文中算法能够显著降低误差。

1 算法设计

算法整体流程如图 1 所示,输入包括 RGB 彩色图像和深度图,伪代码如算法 1 所示。在第一阶段,通过梯度下降训练卷积网络估计莴苣生长指标,在达到最大训练周期后,卷积网络的参数固定。第二阶段,利用训练的卷积网络作为特征提取工具,从图像中提取特征向量,用于训练机器学习模型。测试阶段,利用参数固定的卷积网络从图像中提取特征向量,机器学习模型利用提取的特征估计莴苣的生长参数。

算法 1:二阶段的莴苣生长监测算法

```

1. for  $i = 1, 2, \dots, 5$  do //对生长参数逐个训练模型
2.   for each batch do //循环训练
3.      $L \leftarrow 0$  //损失函数置 0
4.      $X_r, X_d, Y_i \leftarrow \text{dataloader.iter}()$  //数据生成
5.      $\tilde{Y}_i \leftarrow f(X_r, X_d; \theta_i)$ 
6.      $L \leftarrow L_{\text{mse}}(\tilde{Y}_i, Y_i)$  //损失函数计算
7.      $L.backward()$  //模型通过梯度下降优化
8.   end for //第一阶段卷积网络训练完成
9. for  $i = 1, 2, \dots, 5$  do //第二阶段机器学习模型训练
```

10. $X_r, X_d, Y_i \leftarrow \text{dataloader.load}()$ 12. $f(\theta_1, \theta_2, \theta_3).fit(X_r, Y_i)$ //机器学习训练
11. $X_f \leftarrow f(X_r, X_d; \theta_i)$ //卷积网络提取特征 13. end for

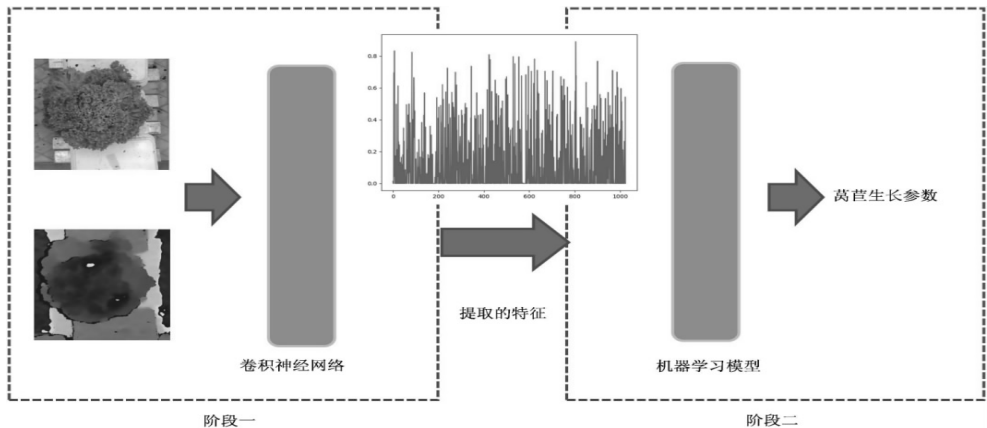



图 1 莴苣生长状态参数估计算法流程

1.1 数据集及图像预处理

该文使用的数据包括 338 张 RGB 图和对应的深度图^[18],原始图片大小为 1 920×1 080,来自四类莴苣品种,包含从幼苗到收获五个生长阶段,数据集还提供每张图片对应的 LFW,LDW,H,D 和 LA。图 2 给出了数据集的示例,四列分别表示不同品种的莴苣,其中第一列给出了对应的标签,一行表示同一生长阶段。由图 2 可以看出,原始图像中目标区域只占整体图像的一部分,特别是对于早期生长阶段的莴苣,并且生菜

的空间位置并不固定。为了减少卷积网络模型的计算量,同时移除无关区域,设计了基于莴苣中心的图片裁剪。裁剪过程如图 3 所示。为了确定莴苣中心,首先根据阈值分割深度图,然后通过计算分割产生的掩膜的空间位置的平均值得到莴苣中心点,最后根据中心点将图片裁剪为 600×600 的大小。深度图也通过同样的方式进行裁剪,确保 RGB 图像和深度图空间分布的一致性。



(a、b、c 和 d 分别来自四个不同的莴苣品种,图像的左上角标出了对应的真实测量值。LFW(克),LDW(克),H(厘米),D(厘米),LA(平方厘米))

图 2 数据集图像示例




图3 图像的预处理过程(包括深度图阈值分割,中心点获取,深度图和原图裁剪)

1.2 卷积神经网络

为了卷积网络能从图像中提取茼蒿生长参数相关的特征,首先训练模型估计茼蒿生长参数。模型的整体结构包括卷积神经网络和全连接层。图像经过卷积神经网络连续的卷积、正则化、激活函数提取高维特征,生长指标的估计通过两层全连接层输出。在卷积网络的输出送到全连接层之前,将其展平为一维特征。第一层全连接层将特征维度压缩一半,之后添加 Dropout^[19]以缓解过拟合的问题。如图2所示,五个指标之间的数量级差异较大,并且有不同的物理意义。不同于文献[17]中的研究,该文对于五个指标分别训练模型,免除归一化的问题。对于单独的 RGB 图像输入,选取 ResNet^[20]提取特征;对于 RGB 和深度图的组合输入,选取 RD3D^[21]提取特征。RD3D 来自于 ResNet

的改进,将 ResNet 中所有的 3×3 卷积替换成 3×3 的 3D 卷积。深度图是单通道图片,为了与彩色图组成 3D 的输入,首先以复制的方式将深度图扩展为三个通道,再与 RGB 图像堆叠,构成三维图像送入 3D 卷积网络中,输入的维度可以表示为“ $T \times H \times W \times C$ ”,其中 $T=2$, H 和 W 和图像的高度和宽度(文中 $H=W=600$), C 为 3。不同深度的卷积网络展平后的一维特征维度有所不同,模型深度为 34 时, $d=512$,深度为 50 或者 101 时, $d=2\ 048$ 。卷积网络训练采用均方误差损失函数:

$$L_{\text{mse}} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (1)$$

其中, n 表示样本个数, y_i 表示真实的生长参数, \hat{y}_i 表示模型的估计值。

1.3 集成机器学习

通过训练后的卷积神经网络自动提取的特征,作为机器学习的输入,该文选择表 1 中第一层全连接层的输出作为提取的特征向量(不经过激活函数)。在机器学习算法的选择上,采用了 Stacking^[22-23]的集成方式,第一层使用随机森林^[24]和深度森林^[25],在第二层使用岭回归。第一层选择基于森林的算法,可以对提取的高维特征自动处理。随机森林在分裂节点时随机选择部分特征,能自动对特征进行筛选。深度森林是一种级联的森林网络,当前层次的输入是上一层的输出与初始输入特征的拼接。为了利用特征之间的相互关系,深度森林引入了多粒度扫描来构建初始的输入特征,具体地,使用不同大小的窗口在特征上滑动,构建出一组初始输入特征,对这一组初始输入特征,其中的每一个都会训练一个级联的森林,最后的输出是所有级联森林输出的均值。

表1 卷积网络估计结果(RD3D 输入由彩色图和深度图构成,误差由归一化均方误差表示) %

指标	ResNet34	ResNet50	ResNet101	RD3D50	RD3D101
LFW	3.61	5.04	3.0	3.27	5.66
LDW	22.02	20.54	8.15	17.82	8.54
H	2.43	2.47	4.11	1.78	9.00
D	1.24	1.48	1.47	1.05	1.07
LA	2.37	5.31	3.16	3.52	1.2
Total NMSE	31.68	34.85	19.89	27.44	25.48

定义集成机器学习的训练集为 $L = \{(y_n, x_n), n = 1, 2, \dots, N\}$, 其中 x_n 表示卷积网络提取的特征向量, y_n 表示茼蒿生长参数的真实值, N 为样本个数。Stacking 第一层包含的随机森林、深度森林表示为 v_k , $k \in \{1, 2\}$, 第一层两个模型通过留一法进行训练,训练完成后模型的输出为:

$$z_{kn} = v_k^{(-n)}(x_n) \quad (2)$$

留一法保留的数据组成新的训练集,用于训练第二层岭回归算法,将第一层两个算法组合。新的训练集定义为 $\{(y_n, z_n), n = 1, \dots, N\}$, 岭回归算法的训练:

$$\begin{aligned} \min & \sum_n (y_n - \alpha_k z_{kn})^2 \\ \text{s. t.} & \alpha_k \geq 0 \end{aligned} \quad (3)$$

α_k 即需要求解的第一层算法的组合权重。

2 实验与分析

2.1 实验设置

实验环境基于 Linux 操作系统,使用 Python 语言,在 Pytorch 框架中搭建卷积网络,机器学习使用 Scikit-learn 包。主要硬件环境为:GPU 为 GTX 3080 10 GB 显存,CPU 为 AMD 3950X 16 核。

数据集划分为训练集和测试集,其中训练集 288 张,测试集 50 张。卷积网络的训练使用均方误差损失函数,优化器选择 AdaBound^[26]以加速模型的收敛,初始学习率设定为 $1e-3$,所有的模型训练 50 个周期。训练过程中每张图片有 50% 的几率采用数据增强,增强方式包括左右翻转,上下翻转,旋转 10、30、60、90 度角。随机森林和深度森林中,树的个数设为 100,特征选择的判断基于均方误差。

2.2 评价指标

实验结果的评价指标采用归一化均方误差 (NMSE),计算方式如下:

$$NMSE = \frac{\sum_{i=1}^m \sum_{j=1}^n (y_{ij} - \hat{y}_{ij})^2}{\sum_{j=1}^n y_{ij}^2} \quad (4)$$

其中, m 表示莒荻指标的种类(文中 $m = 5$),包括 LFW、LDW、H、D 和 LA, n 表示测试样本的个数(文中 $n = 50$)。

2.3 结果与分析

算法的整体可以分为两个阶段,第一阶段训练卷积网络提取特征,第二阶段利用训练好的卷积网络提取特征训练 Stacking 模型。第一阶段训练完成后模型

在测试集上的估计结果如表 1 所示。根据表 1,随着模型深度的增加,五个指标的总误差 (Total NMSE) 是降低的,表明网络复杂度的增加能在一定程度上提升准确率。其中单个指标下降最为明显的是 LDW(只输入彩色图片时,误差从 22.02% 下降到 8.15%,对深度图和彩色图片的组合输入,从 17.82% 下降到了 8.54%)。另外,对比 ResNet 和 RD3D,ResNet101 的误差是最小的。同样深度下,RD3D50 的误差比 ResNet50 低(27.44% 和 34.85%),而 RD3D101 的误差却比 ResNet101 高(25.48% 和 19.89%),可能的原因是 RD3D101 的模型复杂度高,参数量大,需要更多的样本进行学习。

在卷积网络训练完成后,提取的特征用于训练 Stacking 模型。Stacking 模型在测试集上的表现如表 2 所示。根据表 2,基于卷积网络提取的特征,所有模型的误差都有明显的降低,如对于 ResNet50,误差从 34.85% 下降到 12.78%,证明使用卷积网络自动提取特征是可行的,对于卷积网络提取的高维特征,使用随机森林、深度森林来自动处理,能有效减小误差。其中 NMSE 下降最为明显的是 LDW,直接使用卷积网络估计 LDW 的误差范围为 8.15% ~ 22.02%,二阶段算法 LDW 的误差范围为 2.61% ~ 3.08%。在所有的模型当中,Total NMSE 最低的是 ResNet101 (10.53%),其次是 RD3D50 (10.62%)。图 4 是使用卷积网络直接估计和提出的二阶段的算法的误差对比图,可以直观看出二阶段算法对降低误差是有效的。

表 2 二阶段算法估计结果(误差由归一化均方误差表示) %

指标	ResNet34	ResNet50	ResNet101	RD3D50	RD3D101
LFW	3.33	3.64	2.25	3.04	3.04
LDW	3.43	3.37	2.61	3.08	3.08
H	1.78	1.56	1.63	1.27	1.27
D	0.98	1.2	0.84	0.93	0.93
LA	2.6	3.00	3.18	2.29	2.29
Total NMSE	12.12	12.78	10.53	10.62	10.88




图 4 直接估计和设计的两阶段算法误差对比

图 5 和图 6 分别是 ResNet101 和 RD3D50 +

Stacking 的估计结果与真实值的对比图。两种算法对五个指标的决定系数 (R^2) 范围分别是 0.884 4 ~ 0.957 8、0.872 9 ~ 0.952 7,表明卷积网络提取的特征与生长参数有较好的相关性。五个指标当中,决定系数较高的是 LFW(0.955 2 和 0.942 4)、LDW(0.957 8 和 0.952 7)和 LA(0.936 2 和 0.947 2),而 H(0.892 1 和 0.916 1)和 D(0.884 4 和 0.872 9)的决定系数相对较低。值得注意的是 RD3D 对高度的估计更为准确,可能的原因是高度是三维空间的信息,而彩色图像只提供了平面的信息,所以 ResNet101 对高度的估计较

为困难,而 RD3D 包含深度图,提供了关于高度的信息,从而能较为准确地估计。此外,对直径的估计较为困难,可能是在图像数据的采集过程中,摄像机和莴苣的相对位置不固定,空间比例不一致,导致无法准确估计。Zhang 等人^[17]在预处理中对图片进行了分割,之后采用卷积网络来估计莴苣的生长参数。在实验中,考虑到图像中莴苣的背景并不复杂,也尝试用超像素分割的方法对图像进行预处理,将莴苣与背景进行分

割,然而超像素分割需要迭代较长的时间才能获得良好的效果,并且对比使用分割后的图片估计的误差与直接利用图片的误差,并没有显著的差异,所以该文最终没有采用类似的方法对图片进行预处理。另外,为了对比设计的二阶段算法与直接通过卷积网络直接预测,只在 ResNet 和 RD3D 进行了对比实验,Zhang 等人^[17]的工作是基于卷积网络直接预测,但代码并未开源,不参与比较。

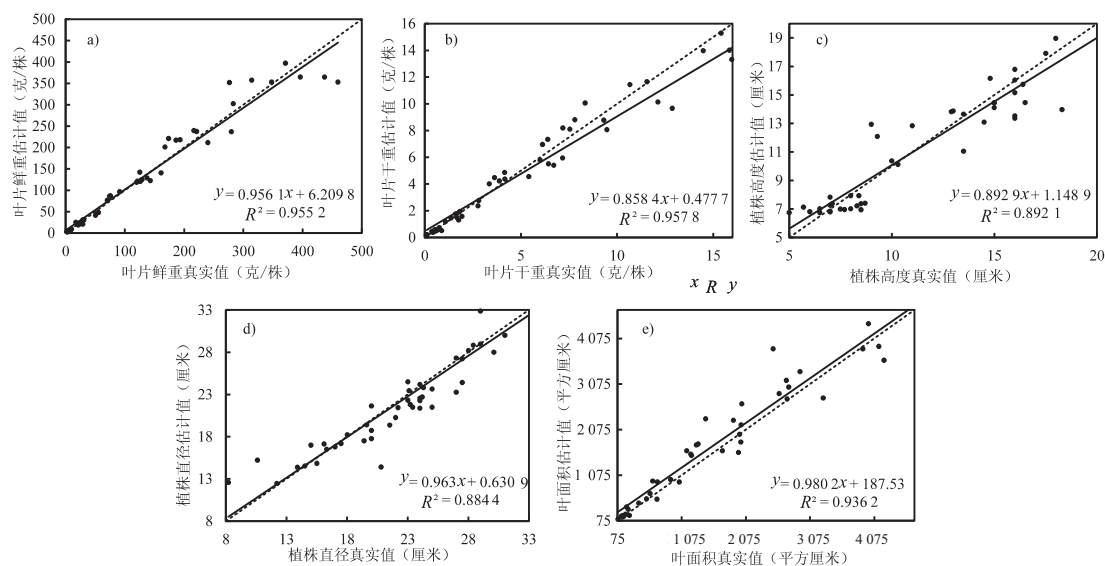


图5 ResNet101 对五种莴苣生长状态参数的估计结果
(输入只包括彩色图片,a-e 分别是 LFW、LDW、H、D 和 LA)

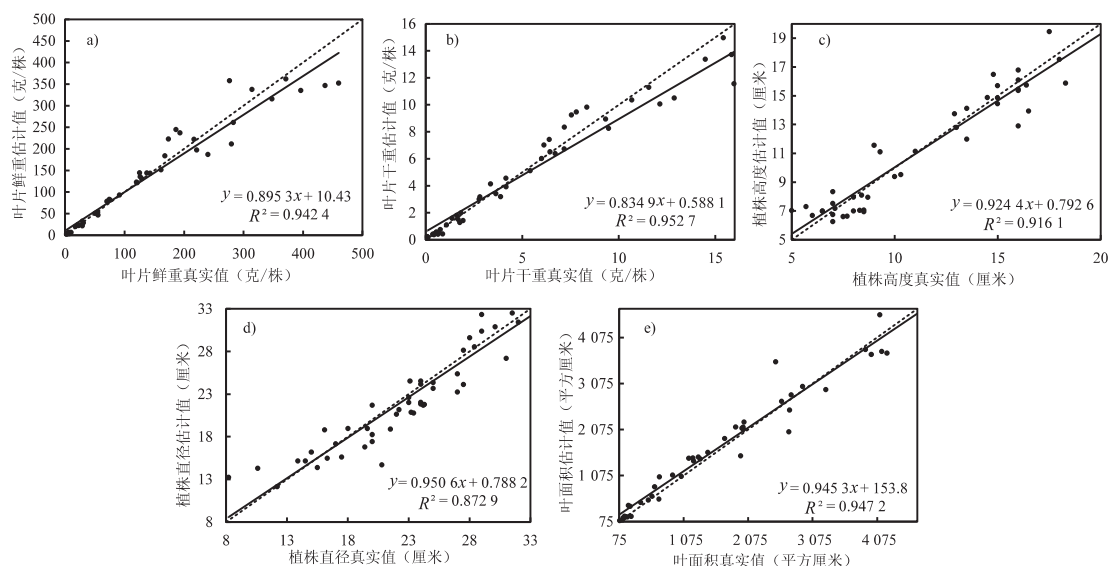


图6 RD3D50+Stacking 模型对莴苣五种生长状态参数的估计结果(a-e 分别是 LFW、LDW、H、D 和 LA)

3 结束语

针对莴苣的生长状态参数监测,设计了一种两阶段的算法。第一阶段训练卷积网络自动从图像中提取特征,第二阶段利用提取的特征训练机器学习模型估计莴苣生长状态参数。输入的图像包括彩色图片和深度图,通过自适应的中心裁剪对图片进行预处理。使

用 ResNet 从彩色图片中提取特征,使用 RD3D 从彩色图和深度图的组合输入中提取特征。在机器学习算法的选择上,采用随机森林和深度森林自动对提取的高维特征进行处理。

实验表明,相比直接使用卷积网络估计莴苣生长参数,设计的二阶段算法能明显降低误差(0.84% ~ 3.18%),并且真实值和估计值之间的决定系数较高

(0.87~0.95),表明卷积网络提取的特征与生长参数之间有较强的相关性。此外,对于莴苣高度的估计,引入深度图提供空间信息能进一步减小误差。

参考文献:

- [1] MOU B. Mutations in lettuce improvement[J]. *International Journal of Plant Genomics*, 2011, 2011(1): 723518.
- [2] KOUDELA M, PETRÍKOVÁ K. Nutrients content and yield in selected cultivars of leaf lettuce[J]. *Horticultural Science*, 2008, 35(3): 99–106.
- [3] BAUER A, BOSTROM A G, BALL J, et al. Combining computer vision and deep learning to enable ultra-scale aerial phenotyping and precision agriculture: a case study of lettuce production[J]. *Horticulture Research*, 2019, 6(1): 1–12.
- [4] TEOBALDELLI M, ROUPHAEL Y, FASCELLA G, et al. Developing an accurate and fast non-destructive single leaf area model for loquat (*Eriobotrya japonica* Lindl) cultivars[J]. *Plants*, 2019, 8(7): 230–241.
- [5] 何 力, 郑灶贤, 项凤涛, 等. 基于深度学习的文本分类技术研究进展[J]. *计算机工程*, 2021, 47(2): 1–11.
- [6] 张小瑞, 陈 旋, 孙 伟, 等. 基于深度学习的车辆再识别研究进展[J]. *计算机工程*, 2020, 46(11): 1–11.
- [7] 孟庆宽, 张 漫, 叶剑华, 等. 基于轻量二阶段检测模型的自然环境多类蔬菜幼苗识别[J]. *农业机械学报*, 2021, 52(10): 282–290.
- [8] CHEN D, SHI R, PAPE J M, et al. Predicting plant biomass accumulation from image-derived parameters[J]. *Giga-Science*, 2018, 7(2): 1–11.
- [9] TACKENBERG O. A new method for non-destructive measurement of biomass, growth rates, vertical biomass distribution and dry matter content based on digital image analysis[J]. *Annals of Botany*, 2007, 99(4): 777–783.
- [10] CASADESÚS J, VILLEGAS D. Conventional digital cameras as a tool for assessing leaf area index and biomass for cereal breeding[J]. *Journal of Integrative Plant Biology*, 2014, 56(1): 7–14.
- [11] FAN X, KAWAMURA K, GUO W, et al. A simple visible and near-infrared (V-NIR) camera system for monitoring the leaf area index and growth stage of Italian ryegrass[J]. *Computers Electronics in Agriculture*, 2018, 144: 314–323.
- [12] LIU J, PATTEY E. Retrieval of leaf area index from top-of-canopy digital photography over agricultural crops[J]. *Agricultural Forest Meteorology*, 2010, 150(11): 1485–1490.
- [13] SAKAMOTO T, GITELSON A A, WARDLOW B D, et al. Application of day and night digital photographs for estimating maize biophysical characteristics[J]. *Precision Agriculture*, 2012, 13(3): 285–301.
- [14] WASONGA D O, YAW A, KLEEMOLA J, et al. Red-green-blue and multispectral imaging as potential tools for estimating growth and nutritional performance of cassava under deficit irrigation and potassium fertilization[J]. *Remote Sensing*, 2021, 13(4): 598–608.
- [15] GÉE C, DENIMAL E, MERIENNE J, et al. Evaluation of weed impact on wheat biomass by combining visible imagery with a plant growth model: towards new non-destructive indicators for weed competition[J]. *Precision Agriculture*, 2021, 22(2): 550–568.
- [16] BRIGLIA N, WILLIAMS K, WU D, et al. Image-based assessment of drought response in grapevines[J]. *Frontiers in Plant Science*, 2020, 11: 595–606.
- [17] ZHANG L, XU Z, XU D, et al. Growth monitoring of greenhouse lettuce based on a convolutional neural network[J]. *Horticulture Research*, 2020, 7(1): 1–12.
- [18] HEMMING S, DE ZWART H F, ELINGS A, et al. 3rd autonomous greenhouse challenge: online challenge lettuce images[EB/OL]. 2021. https://data.4tu.nl/articles/dataset/3rd_Autonomous_Greenhouse_Challenge_Online_Challenge_Lettuce_Images/15023088/1.
- [19] BALDI P, SADOWSKI P J. Understanding dropout[J]. *Advances in Neural Information Processing Systems*, 2013, 26: 2814–2822.
- [20] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//*Proceedings of the IEEE conference on computer vision and pattern recognition*. Las Vegas: IEEE, 2016.
- [21] CHEN Q, LIU Z, ZHANG Y, et al. RGB-D salient object detection via 3D convolutional neural networks[J]. *arXiv*: 2101.10241v1, 2021.
- [22] BREIMAN L. Stacked regressions[J]. *Machine Learning*, 1996, 24(1): 49–64.
- [23] WOLPERT D H. Stacked generalization[J]. *Neural Networks*, 1992, 5(2): 241–259.
- [24] BREIMAN L. Random forests[J]. *Machine Learning*, 2001, 45(1): 5–32.
- [25] ZHOU Z H, FENG J. Deep forest[J]. *arXiv*: 1702.08835, 2017.
- [26] LUO L, XIONG Y, LIU Y, et al. Adaptive gradient methods with dynamic bound of learning rate[J]. *arXiv*: 1902.09843, 2019.