

文章编号: 2095-2163(2023)12-0124-05

中图分类号: S323;TP183

文献标志码: A

基于注意力 ResNet 模型的小麦锈病检测方法研究

亢建华, 刘成忠, 杨红强

(甘肃农业大学 信息科学技术学院, 兰州 730070)

摘要: 针对小麦锈病识别率不高和病症难以判断问题, 提出一种基于注意力机制(Attention Mechanism, AT)的残差网络模型(Residual Network, ResNet)。该模型利用 ResNet 网络能够抑制梯度弥散的优势, 并引入注意力机制对小麦锈病特征因子赋予权重。对输入的小麦锈病图像进行通道注意力权重赋值, 并提取图像空间细粒度特征完成小麦锈病检测。研究结果表明: 该网络模型在 Wheat-data 数据集上平均识别精确率为 95.20%, F_1 -score 为 96.35%; 与非注意力 ResNet 网络模型相比其平均识别精确率和 F_1 -score 平均提高 0.63% 和 1.03%。通过对网络模型参数和识别准确率分析, 表明 AT-ResNet100 网络模型具有较好的性能。

关键词: 深度学习; 注意力机制; ResNet 网络模型; 小麦锈病; 检测方法

Research on wheat rust detection method based on attention ResNet model

KANG Jianhua, LIU Chengzhong, YANG Hongqiang

(School of Information Science and Technology, Gansu Agricultural University, Lanzhou 730070, China)

Abstract: In view of the low recognition rate of wheat rust and the difficulty in judging the disease, a residual network model (ResNet) based on Attention Mechanism (AT) was proposed. The model makes use of the advantage of ResNet network to restrain gradient dispersion and introduces attention mechanism to give weight to the characteristic factors of wheat rust. The channel attention weight is assigned to the input wheat rust image, and the image space fine grain feature is extracted to complete the wheat rust detection. The results show that the average recognition accuracy of the network model on the Wheat data set is 95.20%, and F_1 -score is 96.35%. Compared with the non-attentional ResNet network model, its average recognition accuracy and F_1 -score are improved by 0.63% and 1.03% on average. The analysis of network model parameters and recognition accuracy shows that AT ResNet100 network model has good performance.

Key words: deep learning; attention mechanism; ResNet network model; wheat rust; detection method

0 引言

小麦是人类赖以生存的主要作物, 在中国种植面积广泛、产量丰富, 是中国主要的食物之一。因此, 小麦的健康生长对于中国经济发展和社会稳定提供了良好的物质基础。然而小麦的生长往往受到小麦病害的制约。其中小麦锈病^[1]是影响小麦健康生长最主要的真菌疾病, 其会造成小麦的大量减产, 甚至影响人类健康。因此, 对于小麦锈病的研究具有实际意义和社会价值。

在小麦锈病检测和病症判别方面利用深度学习技术是一个新的研究方向, 公开的相关文献较少, 多

数文献都是基于机器学习算法进行小麦锈病的检测和识别。冷伟锋等人^[2]对不同生长时期的小麦株条进行监测, 构建小麦锈病图像反射率与病变特征之间严重程度关系模型, 从而研究小麦种植密度、光照面积等对模型检测和识别的影响。雷雨等^[3]采用实验的方法, 对小麦锈病进行了分析。虽然该方法能够很好的检测和识别小麦条锈病的病变区域, 但对于图片的质量要求较高, 在自然条件下难以获取高质量的光谱图片。Bohnenkamp D 等^[4]利用高光谱成像技术对小麦叶片条锈病进行检测和识别, 采用最小二乘法进行分解, 得到小麦锈病孢子的光谱信号, 完成小麦条锈病病害区域检测。但该方法

基金项目: 甘肃省高等学校创新基金项目(2021A-056); 甘肃省高等学校产业支撑计划项目(2021CYZC-57); 甘肃农业大学研究生重点课程建设项目(GSAU-ZDKC-2006); 国家级大学生创新创业训练计划(202110733021)。

作者简介: 亢建华(1980-), 男, 硕士研究生, 主要研究方向: 人工智能、农业信息技术。

通讯作者: 刘成忠(1969-), 男, 硕士, 教授, 硕士生导师, 主要研究方向: 人工智能、农业信息技术。Email: liucz@gsau.edu.cn

收稿日期: 2022-11-19

法也要求具有高质量的图像,且采用最小二乘法分解速度较慢。

神经网络模型^[5]可以通过端到端的学习过程自动构建识别模型,因此本文借助神经网络模型的优点,提出一种基于注意力 ResNet 网络模型的小麦锈病检测方法。对输入的小麦锈病图像通过注意力模型进行权重赋值,在 ResNet 网络模型中进行小麦锈病特征提取并进行小麦锈病检测,经过在自定义数据集上进行对比验证,说明了该模型的有效性和鲁棒性^[6]。

1 网络模型及小麦锈病检测

1.1 ResNet 网络模型

2015 年 He 等人^[7]提出残差网络模型(Residual Network, ResNet),该模型能够有效抑制训练过程中由于网络层数过多而导致的网络退化问题,模型的提出对于深层网络的训练具有里程碑意义。通常情况下,在神经网络的训练过程中,卷积层和全连接层往往存在空间特征的丢失问题,而 ResNet 网络模型由于残差块的存在,能够有效保留图像空间细粒度特征,这对于训练过程中简化模型参数和保留细节特征达到了很好的平衡,也是本文选用此网络作为小麦锈病检测和识别的依据。ResNet 网络有 BasicBlock 和 Bottleneck 两种基本结构,其中 Bottleneck 结构用于较深层次网络的训练,具体网络模型结构如图 1 所示。




图 1 ResNet Bottleneck 网络模型

Fig. 1 ResNet Bottleneck network model

由图中可知,首先对输入数据 X 使用 1×1 的卷积核进行操作,重复卷积操作 64 次;再通过 ReLU 激活函数进行非线性变换,并将非线性结果作为下一卷积层的输入数据;其次将非线性结果使用 3×3 的卷积核进行 64 次卷积操作,通过 ReLU 激活函数进行变换操作;最后使用 1×1 的卷积核进行 256 次卷积操作,并将卷积输出结果与原始输入信息 X 经过下采样的数据进行融合处理,将融合后的数据进行非线性变换作为下一层神经网络的输入数据。

传统神经网络模型虽然具有良好的特征提取能力和较高的识别效率,但在解决序列图像时忽略了图像空间细粒度特征信息,并且神经网络层数越深网络

参数的增加呈指数级增长,对于普通 CPU 来说很难达到理想的效果。因此,为挖掘小麦锈病图像属性之间的相关性和空间特征,以及小麦锈病细粒度特征,本文采用 ResNet 神经网络模型代替传统神经网络模型。ResNet 网络模型对小麦锈病图像的空间特征捕获能力和细粒度特征提取能力都具有优越的性能,并且能够有效抑制由于网络层数过多而导致的网络退化问题,可以更好地提取小麦锈病图像病变相关特征,进而进行小麦锈病检测和识别。

1.2 注意力 ResNet 网络模型小麦锈病检测

深度学习中的注意力机制^[8]是根据人类视觉原理发展而来,近年来广泛应用于计算机视觉^[9]、模式识别^[10]、自然语言处理^[11]等领域。据查阅现有文献可知,本文首次将注意力 ResNet 网络模型应用于小麦锈病检测和识别的研究,通过引入注意力机制模型,根据小麦锈病的特征因子对注意力权重进行赋值和归一化操作,进而提取小麦锈病图像特征和识别小麦锈病的症状,再通过分析小麦锈病图像数据的局部特征与预测结果之间的关联性,使注意力 ResNet 网络模型可重点关注输入数据的关键特征,因此对一些重要特征增大相应的权重值,使预测结果更加趋近于真实值。由于注意力机制模型对于数据中的重要特征进行实时动态监测,当数据中的多种特征相互交叠,且存在非重要特征的干扰时,注意力机制的优越性会更加明显。基于注意力机制 ResNet 网络模型的优势,本文以小麦锈病图像的空间特征和细粒度特征为目标,实现小麦锈病图像特征提取和病症识别。

为充分挖掘小麦锈病图像中病症相关的空间特征和细粒度特征,本文在 ResNet 模型中引入通道注意力机制,在对小麦锈病图像进行特征提取和病症识别的同时,注意力机制使网络模型更加关注小麦锈病病症相关的重要特征,选择性忽略一些次要特征。注意力机制 ResNet 网络模型如图 2 所示。




图 2 注意力 ResNet 网络模型

Fig. 2 Attention ResNet network model

注意力模块如图 2 中 AT 所示,在 3×3 卷积后面增加注意力机制,为尽可能保留更多的细节特征将注意力输出通过 3×3 的卷积核,同时通过 1×1 卷积核连接 3×3 卷积核两端的 ReLU 激活函数,以保证

小麦锈病更多的细节特征并减少计算参数,其注意力模块内部结构,如图3所示。




图3 ConvLSTM网络模型注意力机制结构图

Fig. 3 ConvLSTM network model attention mechanism structure diagram

在注意力模块中,通过对经过 3×3 卷积核的数据 X' 分别进行最大池化和平均池化,将池化后的数据再通过融合模型进行注意力权重赋值。为减少数据维数对注意力权重归一化计算,同时为减少计算量和保证小麦锈病细节特征,采用 1×1 卷积核对输入数据和归一化权重进行融合操作,输出 \tilde{X} 作为下一层卷积网络的输入。最终的输入如式(1)~式(3)所示。

$$R_s = W * \text{relu}(W * X' + b_r) \quad (1)$$

$$A_r^i = p(\text{att}_i | X') = \frac{\exp(R_s^i)}{\sum_i \exp(R_s^i)} \quad (2)$$

$$\tilde{X} = A_r \circ X' \quad (3)$$

其中, W 为相应的卷积核, R_s 为输入数据对每个特征区域的注意力权重值,其由当前的输入数据和偏置值通过Relu激活函数进行非线性变化得到。经过式(2)权重归一化操作,得到当前网络层的权重注意力值,表示注意力机制对当前小麦锈病图像每个特征区域的关注程度。式(3)中,符号 \circ 表示Hadamard乘积计算^[12]。

2 实验结果与分析

本文采用百度公司PaddlePaddle(2.3.1稳定版本)开源深度学习平台进行小麦锈病检测实验验证,硬件环境为第10代Intel(R)Core(TM)i7-10710U CPU @ 1.10 GHz 1.61 GHz Inter, 16 G内存, 500 G硬盘,搭载NVIDIA GeForce 1070 Ti显卡加速图像处理,初始学习率设置为0.01,随着迭代次数的增加依次降低学习率,训练迭代次数为50Epochs,批大小为28进行训练。

2.1 数据集

为验证本文所提算法的有效性,本研究对不同生长时期的小麦株条做了数据采集。其中,小麦幼苗期以甘肃省农科院温室内的 wheat 为数据源,以25种人工诱感条锈病幼苗为采集对象,使用华为荣耀手机(P40)

共采集34310张小麦锈病图像;小麦成株期以甘肃省冬小麦新品种选育示范基地为采集地,以31种人工诱感小麦为采集对象,使用华为荣耀手机(P40)拍摄得到分辨率为 3264×1836 的小麦条锈病照片42320张。总共采集到不同时期小麦锈病照片76630张。

在获取小麦照片时采用白色纸盒模型作为遮挡工具,对单个小麦品种植株进行照片采集时,避免了周围杂草及环境的影响和干扰。对每个品种的小麦植株采集70株左右,为了能够最大限度保留小麦锈病照片的特征信息,尽可能拍摄单个小麦品种的全貌。同时为了更好地提取出小麦锈病的细粒度特征和准确识别小麦病变特征,提高神经网络提取特征的能力,对采集到的小麦锈病照片进行相似性筛选,同时为防止过拟合扩大数据集,在拍摄时采用不同的拍摄方式,如顶拍、侧拍、倒拍等。

2.2 评价指标

为了评价算法的有效性和鲁棒性,本文选择常用的识别准确率(RA)^[13]和 $F_1\text{-score}$ ^[14]作为算法性能的评价指标。

识别准确率(RA)为预测结果为正例样本中的真实标签为正例的比例,常被用来作为评价目标识别准确性的性能指标,如式(4)表示。

$$RA = \frac{TP}{TP + FP} \quad (4)$$

其中,TP为真实值和预测值均为真的样本数,FP表示真实值为负例样本而预测值为正例的样本数。识别准确率越大,表示小麦锈病识别算法的性能越好。

$F_1\text{-score}$ 为精确率与召回率的调和平均值,反映了模型的稳健性。如式(5)表示。

$$F_1\text{-score} = 2 \frac{RA \times RC}{RA + RC} \quad (5)$$

其中:

$$RC = \frac{TP}{TP + FN} \quad (6)$$

式(5)中:RA表示识别准确率,RC为召回率,FN表示真实值为正例样本数而预测值为负例样本数, $F_1\text{-score}$ 分数越大,表明模型越稳定,其算法有效性越好。

2.3 结果分析

为了验证注意力ResNet网络模型的有效性和优越性,在自定义数据集Wheat-data上对识别准确率和 $F_1\text{-score}$ 性能指标进行对比分析。

在自定义数据集Wheat-data上将本文算法与其它网络模型进行对比实验,结果见表1。

表 1 多种算法在 Wheat-data 数据集 RA 和 F_1 -score 值比较Table 1 Comparison of RA and F_1 -score values of many algorithms in Wheat-data sets

算法名称	RA / %	F_1 -score / %
AlexNet ^[15]	96.62	96.78
GoogLeNet ^[16]	97.24	97.35
ResNet ^[7]	96.35	96.53
本文算法	96.82	97.45

由表 1 可知,本文所提网络模型在自定义数据集 Wheat-data 上对识别准确率和 F_1 -score 均取得最优的效果。文献[15]中网络模型虽然在 2012 年计算机视觉图像识别方面获得冠军,其网络模型对图像的表现特征具有良好的提取能力,相比于传统神经网络该模型在图像识别方面准确率提升了 10% 左右,但对于深层次特征的提取需要很深的网络结构,因此在细粒度特征方面该网络模型稍欠佳。文献[16]中网络模型是 2014 年提出的一种全新的网络模型,该模型能够更高效的利用计算资源,同时在算力相同的情况下能够获得较高的训练效果,由于网络深度较深,所以需要大量的参数,训练过程较为复杂。文献[7]采用非注意力 ResNet 模型在自定义数据集上对识别准确率和 F_1 -score 指标进行验证,也取得了较为良好的效果,但是相比于本文注意力 ResNet 网络模型稍显逊色。由于注意力机制可以动态调节训练过程中关键信息的权重,从而使网络模型更加关注关键特征的提取,以此提高识别准确率。

为验证非注意力 ResNet 网络模型和注意力 ResNet 网络模型性能指标之间的区别,采用 RA 和 F_1 -score 评价指标对数据进行了分析。在保持数据集中小麦各生长期阶段样本数量相近的情况下,采用 5 折交叉验证法^[17],每次随机抽取 15 000 张各阶段小麦生长图片用于实验,其中 12 000 张图片用于训练,3 000 张图片用于测试,对 5 次结果求和再取平均值得到最终结果。使用 RA 和 F_1 -score 对实验结果进行统计分析,结果如图 4 所示。

由图 4 可知,注意力机制 ResNet 网络模型比单一的 ResNet 网络模型在识别准确率和 F_1 -score 性能指标上有明显的提高,且随着迭代次数的增大,识别准确率和 F_1 -score 的提升效果显著增加;当达到一定训练次数后,其性能指标增加速度放缓,主要是因为数据规模限制了性能的进一步提升。其中,基于注意力 ResNet 网络模型在 Wheat-data 数据集上 5 次平均识别准确率和 F_1 -score 分别为 95.20% 和 96.35%,ResNet 网络模型在同样条件下平均识别准确

率和 F_1 -score 分别为 94.57% 和 95.32%。在上述训练 50 Epochs 条件下,基于注意力 ResNet 网络模型比非注意力 ResNet 网络模型识别准确率和 F_1 -score 平均分别提高 0.63% 和 1.03%。由此可见,使用注意力机制的 ResNet 网络模型,能够更好地提取小麦锈病图像的空间特征和细粒度特征,能够更有效进行小麦锈病特征的选择和病症的判别,在小麦锈病识别准确率和 F_1 -score 性能指标方面有明显的提升。




图 4 在 Wheat-data 数据集上平均识别准确率和 F_1 -score 统计图
Fig. 4 Average recognition accuracy and F_1 -score statistics on Wheat-data sets

为验证不同网络模型参数下小麦锈病检测和识别准确率,分别对 ResNet50 网络模型、ResNet100 网络模型、AT-ResNet50 网络模型和 AT-ResNet100 网络模型的参数和识别准确率之间的相关性在融合数据集上进行分析。与上述实验方法相同,采用 5 折交叉验证法进行训练实验,同样采用 5 次实验的平均值作为验证结果,对模型参数和识别准确率 (RA) 之间的关系统计进行分析,结果如图 5 所示。




图 5 在 Wheat-data 数据集上模型参数和识别准确率统计图
Fig. 5 Statistical chart of model parameters and recognition accuracy on Wheat-data sets

从图 5 可知,在 Wheat-data 数据集上对不同层数的神经网络模型在参数和识别准确率方面进行了对比分析。其中,ResNet50 网络模型由于层数较少,所需参数相对较少,识别准确率也相对较低;ResNet100 网络模型和 AT-ResNet50 网络模型在训练次数相同的情况下,识别准确率相当,而 AT-ResNet50 网络模型需要更少的参数即可达到同样的

识别效果。由此可见,加入注意力机制对于小麦锈病的识别和病症判断是有效的。在 AT-ResNet100 网络模型中由于网络层数较高,所需要的模型参数也相应增加,识别准确率也相对其他模型表现更好。

综合考虑网络性能和训练次数等因素,本文选择 AT-ResNet100 网络模型作为小麦锈病识别和病症判断的最终网络模型。

3 结束语

针对小麦锈病检测问题,本文提出一种基于注意力 ResNet 网络模型的小麦锈病检测方法。为验证本文网络模型的有效性和鲁棒性,以自定义数据集 Wheat-data 为实验对象,首先通过对不同算法的识别准确率和 F_1 -score 性能指标进行分析,可知本文网络模型在自定义数据集上均达到良好的效果;其次在自定义数据集上针对 ResNet 网络模型和基于注意力 ResNet 网络模型在识别准确率和 F_1 -score 方面进行对比,本文网络模型在自定义数据集上平均识别准确率和 F_1 -score 均高于非注意力 ResNet 网络模型,表明该网络模型在小麦锈病检测方面的有效性和鲁棒性;最后对网络模型参数和识别准确率进行对比分析,可知 AT-ResNet100 网络模型具有优良的表现性能。

参考文献

- [1] 李玉. 农业植物病理学[M]. 长春:吉林科学技术出版社.1992.
- [2] 冷伟锋,马占鸿. 基于热红外遥感的小麦条锈病菌越冬区精准勘界[J]. 植物保护学报,2018,45(1):118-123.
- [3] 雷雨,韩德俊,曾庆东,等. 基于高光谱成像技术的小麦条锈病

病害程度分级方法[J]. 农业机械学报,2018,49(5):226-232.

- [4] BOHNENKAMP D, KUSKA M T, MAHLEIN A K, et al. Utilising pure fungal spore spectra as reference for a hyperspectral signal decomposition and symptom detection of wheat rust diseases on leaf scale[J]. Plant Pathol, 2019, 68(6): 1188-1195.
- [5] 祝诗平,卓佳鑫,黄华,等. 基于 CNN 的小麦籽粒完整性图像检测系统[J]. 农业机械学报,2020,51(5):36-42.
- [6] 林点,潘理,易平. 面向图像识别的卷积神经网络鲁棒性研究进展[J]. 网络与信息安全学报,2022,8(3):111-122.
- [7] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition [C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas:IEEE,2016:770-778.
- [8] ABEDINIA O, AMJADY N, ZAREIPOUR H. A new feature selection technique for load and price forecast of electrical power systems [J]. IEEE Transactions on Power Systems,2017,32(1):62-74.
- [9] 张玉玉. 计算机视觉注意力机制建模研究[D]. 西安:西安工业大学,2022.
- [10] 王彦彪,陈振勇,郭文萍,等. 基于双注意力机制优化 CNN 架构的 GIS 局部放电模式识别[J]. 电力科学与技术学报,2022,37(2):22-29.
- [11] 石磊,王毅,成颖,等. 自然语言处理中的注意力机制研究综述[J]. 数据分析与知识发现,2020,4(5):1-14.
- [12] 张晓凤,陈付彬,罗欢. 矩阵 Hadamard 积与 Fan 积的特征值新界[J]. 西南师范大学学报(自然科学版),2022,47(7):1-6.
- [13] 孙瑞安,张云华. 结合 AdaBERT 的 TextCNN 垃圾弹幕识别和过滤算法[J]. 智能计算机与应用,2021,11(4):9-13.
- [14] 赵静,李志铭,鲁力群,等. 基于无人机多光谱遥感图像的玉米田间杂草识别[J]. 中国农业科学,2020,53(8):1545-1555.
- [15] 焦计晗,张帆,张良. 基于改进 AlexNet 模型的油菜种植面积遥感估测[J]. 计算机测量与控制,2018,26(2):186-189.
- [16] BALLESTER P, ARAUJO R. On the performance of GoogLeNet and AlexNet applied to sketches[C]//Proceedings of the Thirtieth AAAI Conference on Artificial Intelligence. Phoenix, AZ, USA. Phoenix, AI, USA. 2016:1124-1128.
- [17] 杨琪威. 线性模型平均中惩罚因子选择的交叉验证法[D]. 上海:华东师范大学,2022.

(上接第123页)

- [7] WANG J, YANG B, LIU H, et al. Global spatio-temporal aware graph neural network for next point-of-interest recommendation [J]. Applied Intelligence, 2023, 53(13): 16762-16775.
- [8] LIU Y, WU H, REZAEE K, et al. Interaction-enhanced and time-aware graph convolutional network for successive point-of-interest recommendation in traveling enterprises [J]. IEEE Transactions on Industrial Informatics, 2022, 19(1): 635-643.
- [9] CAPANEMA C G S, SILVA F A, SILVA T R M B, et al. POI-RGNN: Using recurrent and graph neural networks to predict the category of the next point of interest[C]//Proceedings of the 18th ACM Symposium on Performance Evaluation of Wireless ad Hoc, Sensor, & Ubiquitous Networks. 2021: 49-56.
- [10] WANG D, WANG X, XIANG Z, et al. Attentive sequential model based on graph neural network for next poi recommendation [J]. World Wide Web, 2021, 24(6): 2161-2184.
- [11] XU S, HUANG Q, ZOU Z. Spatio-Temporal Transformer Recommender: Next Location Recommendation with Attention Mechanism by Mining the Spatio-Temporal Relationship between

Visited Locations [J]. ISPRS International Journal of Geo-Information, 2023, 12(2): 64-79.

- [12] TSAI C Y, CHEN Y J, PEÑA A S, et al. A visiting sequence recommendation framework; enhanced by dynamic landmark and stay time [J]. Expert Systems with Applications, 2023, 230: 120649-120662.
- [13] WANG E, JIANG Y, XU Y, et al. Spatial-temporal interval aware sequential POI recommendation[C]//Proceedings of 2022 IEEE 38th International Conference on Data Engineering (ICDE). IEEE, 2022: 2086-2098.
- [14] OU J, JIN H, WANG X, et al. STA-TCN: Spatial-temporal Attention over Temporal Convolutional Network for Next Point-of-interest Recommendation [J]. ACM Transactions on Knowledge Discovery from Data, 2023, 17(9): 1-19.
- [15] LI Q, XU X, LIU X, et al. An Attention-Based Spatiotemporal GGNN for Next POI Recommendation [J]. IEEE Access, 2022, 10: 26471-26480.
- [16] LI H, YUE P, LI S, et al. Spatio-temporal intention learning for recommendation of next point-of-interest[J]. Geo-spatial Information Science, 2023: 1-14. DOI:10.1080/10095020.2023.2179428