

改进 SHO 优化神经网络模型

李健^{1,2}, 王海瑞¹, 王增辉³, 付海涛¹, 于维霖¹

(1. 吉林农业大学 信息技术学院, 长春 130118;

2. 吉林省生物信息学研究中心, 长春 130118;

3. 长春人文学院 理工学院, 长春 130117)

摘要: 针对 Googlenet 模型识别准确率低、敏感性不佳等问题, 提出一个应用改进的海马优化(SASHO)算法超参数优化 Googlenet 模型。首先, 利用 Sobel 序列和自适应权重算法对海马优化算法进行改进; 其次, 对比 4 个基础神经网络选出最适合本文数据集的 Googlenet 作为基础识别模型; 最后, 利用改进后的 SASHO 算法对 Googlenet 模型参数进行优化, 构建新模型 SASHO-Googlenet。为验证 SASHO-Googlenet 模型的有效性, 将 SASHO-Googlenet 模型与经过其他 4 个群智能算法优化的模型针对 7 个指标进行比较。结果表明, SASHO-Googlenet 模型准确率达 95.36%, 敏感性达 95.35%, 特异性达 95.39%, 精度达 96.47%, 召回率达 95.35%, f_{measure} 达 95.90%, g_{mean} 达 95.37%。实验结果表明, SASHO-Googlenet 模型综合性能最佳。

关键词: 人工智能; 深度学习; 海马优化算法; 参数优化

中图分类号: TP399 **文献标志码:** A **文章编号:** 1671-5489(2025)03-0835-10

Improved SHO Optimization Neural Network Model

LI Jian^{1,2}, WANG Hairui¹, WANG Zenghui³, FU Haitao¹, YU Weilin¹

(1. College of Information Technology, Jilin Agricultural University, Changchun 130118, China;

2. Jilin Bioinformatics Research Center, Changchun 130118, China;

3. School of Science and Technology, Changchun University of Humanities, Changchun 130117, China)

Abstract: Aiming at the problems of low recognition accuracy and poor sensitivity of Googlenet model, we proposed a hyperparameter optimization Googlenet model by using the improved sea-horse optimization (SASHO) algorithm. Firstly, the sea-horse optimization algorithm was improved by using Sobel sequence and adaptive weight algorithm. Secondly, the four basic neural networks were compared to select the most suitable Googlenet for this dataset as the basic recognition model. Finally, the improved SASHO algorithm was used to optimize the parameters of Googlenet model, and a new model SASHO-Googlenet was constructed. In order to verify the effectiveness of SASHO-Googlenet model, the SASHO-Googlenet model was compared with the model optimized by the other four swarm intelligence algorithms for seven indicators. The results show that the accuracy rate of SASHO-Googlenet model is 95.36%, the sensitivity is 95.35%, the specificity is 95.39%, the accuracy is 96.47%, the recall rate is 95.35%, the f_{measure} is 95.90%, and the g_{mean} is

收稿日期: 2023-11-03.

第一作者简介: 李健(1981—), 男, 汉族, 博士, 教授, 从事人工智能和生物信息学的研究, E-mail: liemperor@163.com. 通信

作者简介: 王增辉(1956—), 男, 汉族, 教授, 从事应用统计方法及其应用的研究, E-mail: wzh195693@163.com.

基金项目: 吉林省农业农村厅科学技术项目(批准号: 2024PG1204)和吉林省教育厅科学研究项目(批准号: JJKH20250574BS).

95.37%. Experimental results show that the SASHO-Googlenet model has the best comprehensive performance.

Keywords: artificial intelligence; deep learning; sea-horse optimization algorithm; parameter optimization

随着深度学习^[1-3]的发展,神经网络被广泛应用于各领域中,如故障诊断^[4]、医学^[5]、农业^[6-7]等领域.虽然神经网络在各领域都展现了特有的优势,但随着社会发展需求的提高,传统神经网络已不能满足人们的需求,因此,对提升神经网络性能的研究备受关注. Verma 等^[8]提出了一个单一的轻量级卷积神经网络(CNN)模型,该模型使用同一水平上可变大小的卷积层准确检测感染区域,并将其应用于识别领域,与其他模型相比,该模型识别的准确率可达 82.67%. Rahman 等^[9]采用并微调了最先进的大规模架构,提出了一种两级小型 CNN 架构,并将该架构应用于检测领域,实验证明,模型精度可达 93.3%. Yang 等^[10]基于神经网络模型的图像识别技术开发了具有更高精度的系统,实验结果表明,该系统在图像鉴定中展现了良好的性能,与其他模型相比准确率也有提高. Chen 等^[11]选择了 ImageNet 和 Inception 模块上预先训练的 VGGNet,且使用大型标记数据集 ImageNet 上的预训练网络初始化权重,实验结果表明,即使在复杂背景下,该模型准确率也可达 92.00%.

深度神经网络虽然在实际应用上展现了很好的性能,但准确率并未达预期,因此研究者开始尝试对深度神经网络进行优化. Lu 等^[12]应用基本粒子群优化(PSO)算法优化了支持向量机,并结合深度置信网络将其应用在识别领域中,与其他模型相比,其具有最好的诊断性能. Shanmugam 等^[13]开发了一种有效的向日葵蚯蚓算法和基于学生心理学的优化(SEWA-SPBO)深度最大化网络,将该模型应用于识别领域中,准确率可达 93.63%. Daniya 等^[14]由骑手优化算法(ROA)和水波优化(WWO)构建了 RWW 算法,并应用 RWW 算法优化神经网络,以此构建新模型 RWW-NN,该模型在应用于识别中时,各项评价指标均有提升.可见,应用群智能算法^[15-17]优化深度神经网络^[18]确实可提升模型的性能.因此,本文应用改进以后的海马优化算法超参数优化 Googlenet 模型,并将新构建的模型应用于水稻褐斑病和稻瘟病的识别中.

1 数据集

本文实验数据来自开源平台(<https://www.kaggle.com/datasets/minhhuy2810/rice-diseases-image-dataset>),共收集了 644 张水稻叶片图像,包括稻瘟病和褐斑病两种病害,其中稻瘟病图像 270 张,褐斑病图像 374 张.水稻稻瘟病和褐斑病表型特征如图 1 所示,其中第一行为褐斑病,第二行为稻瘟病.




图 1 数据集示例

Fig. 1 Dataset example

2 实验方法

2.1 海马优化算法

海马优化(sea-horse optimizer, SHO)算法^[19]是一种较新的群智能优化算法,其构建理念是模拟海马在自然界中的移动、捕食和繁殖行为.在自然界中,海马在移动过程中会根据自然环境在两种移动方式中选其一,在捕食时也会因为各种影响因素出现成功或者失败两个结果.所以根据海马在自然界中的行为进行数学建模时也为这两个二阶段设计了两种不同的位置更新方式,海马优化算法流程如图 2 所示.

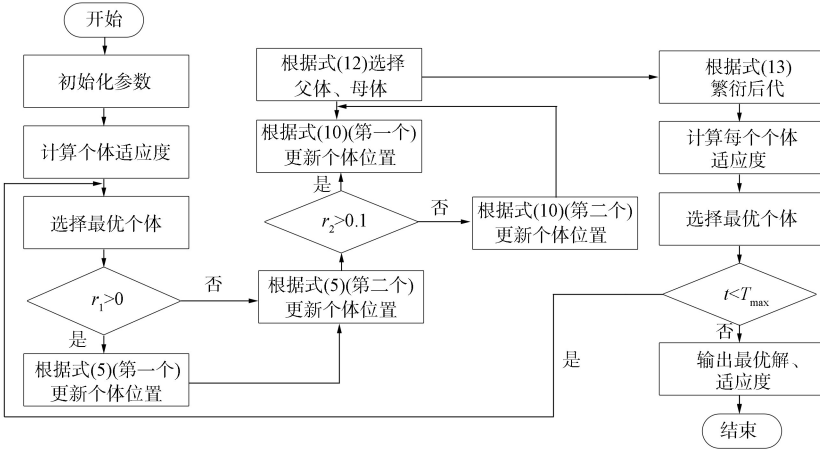


图 2 海马优化算法流程

Fig. 2 Flow chart of sea-horse optimization algorithm

海马优化算法数学建模共分为 4 个阶段,分别是初始化、移动、捕食、繁殖,初始化阶段与其他群智能优化算法相同,需要随机生成种群,种群中的每只海马在数学建模中都代表一个候选解,海马种群数学建模公式如下:

$$\text{Seahorses} = \begin{pmatrix} x_1^1 & \cdots & x_1^{\text{dim}} \\ \vdots & \ddots & \vdots \\ x_{\text{pop}}^1 & \cdots & x_{\text{pop}}^{\text{dim}} \end{pmatrix}, \tag{1}$$

其中 dim 表示维度, pop 表示种群个体数量.

在实际应用中,不同应用场景会有不同限制,所以在数学建模时,为保证获得的解在实际问题中可用,需为搜索空间设置上界和下界,分别用 UB 和 LB 表示,上界和下界构成的区间称为搜索区间.搜索空间内的第 k 个个体 X_k 数学建模公式如下:

$$X_k = \{x_k^1, x_k^2, \dots, x_k^{\text{dim}}\}, \tag{2}$$

$$x_k^i = \text{rand} \times (UB^i - LB^i) + LB^i, \tag{3}$$

其中: rand 表示取值范围在 $[0, 1]$ 内的随机数; x_k^i 表示第 k 个个体的第 i 维, x_k 可以代表海马种群内的任意个体,所以 k 的取值范围为 $[1, \text{pop}]$, x_k^i 可以代表第 k 个个体的任意维度,所以 i 的取值范围为 $[1, \text{dim}]$,但 k 和 i 只能取整数; UB^i 和 LB^i 分别表示第 i 个变量的上界和下界.

在实际应用中,会将优化问题划分为最小优化问题和最大优化问题两种,本文以最小优化问题为例.海马优化算法会根据目标函数计算个体的适应度值,将适应度值最小的个体视为精英个体,即最优解,其数学建模公式如下:

$$X_{\text{elite}} = \text{argmin}(f(X_k)), \tag{4}$$

其中 $f(X_k)$ 表示根据目标函数求出的函数值.

海马在自然界中移动时会出现两种方式,分别是随海洋漩涡进行的螺旋运动和随海浪进行的 Brown 运动.在进行数学建模时可将海马位置更新公式设置两个:

$$X_{\text{new}}^1(t+1) = \begin{cases} X_k(t) + \text{Levy}(\lambda)((X_{\text{elite}}(t) - X_k(t)) \times x \times y \times z + X_{\text{elite}}), & r_1 > 0, \\ X_k(t) + \text{rand} \times l \times \beta_t \times (X_k(t) - \beta_t \times X_{\text{elite}}), & r_1 \leq 0, \end{cases} \quad (5)$$

其中: t 表示迭代次数; $r_1 = \text{randn}()$ 为服从标准正态分布的随机数; l 为系数, 是设置的常数, 取值为 0.05; x, y, z 分别表示螺旋运动下三位坐标的各分量, 计算公式为

$$\begin{cases} x = \rho \cos(\theta), \\ y = \rho \sin(\theta), \\ z = \rho \theta, \end{cases} \quad (6)$$

$\rho = u \times e^{v\theta}$, u 和 v 为设置的常数, 取值均为 0.05, θ 为 $[0, 2\pi]$ 内的随机数.

由式(5)可见, 在第一种位置更新公式中引入了函数 $\text{Levy}(z)$, 其是一种分布函数, 计算公式如下:

$$\text{Levy}(z) = \frac{s \times \omega \times \sigma}{|G|^{1/\lambda}}, \quad (7)$$

其中: λ 为 $[0, 2]$ 内的随机数; s 为设置的固定常数, 取值为 0.01; ω 和 G 均为 $[0, 1]$ 内的随机数; σ 的计算公式为

$$\sigma = \left(\frac{\Gamma(1+\lambda) \times \sin\left(\frac{\pi\lambda}{2}\right)}{\Gamma\left(\frac{1+\lambda}{2}\right) \times \lambda \times 2^{(\lambda-1)/2}} \right). \quad (8)$$

在式(5)的第二个位置更新公式中引入新参数 β_t , 其表示 Brown 运动的随机游走系数, 也是服从标准正态分布的随机值, 计算公式如下:

$$\beta_t = \frac{1}{\sqrt{2\pi}} \exp\left\{-\frac{x^2}{2}\right\}. \quad (9)$$

海马在捕食过程中会出现成功、失败两种结果, 因此在进行数学建模时, 也给出了两种捕食行为的数学表达式:

$$X_{\text{new}}^2(t+1) = \begin{cases} \alpha \times (X_{\text{elite}} - \text{rand} \times X_{\text{new}}^1(t)) + (1-\alpha) \times X_{\text{elite}}, & r_2 > 0.1, \\ (1-\alpha) \times (X_{\text{new}}^1(t) - \text{rand} \times X_{\text{elite}}) + \alpha \times X_{\text{new}}^1(t), & r_2 \leq 0.1, \end{cases} \quad (10)$$

其中: r_2 为 $[0, 1]$ 内的随机数; α 为变量, 其随迭代次数的增加逐渐减小, 计算公式为

$$\alpha = \left(1 - \frac{t}{T_{\text{max}}}\right)^{2t/T}, \quad (11)$$

T_{max} 表示最大迭代次数.

海马依靠父体繁殖, 因此在对海马繁殖行为进行数学建模时, 根据个体适应度值将适应度值好的一半作为父体, 其余一半作为母体, 该行为数学建模公式如下:

$$\begin{cases} F_s = X_{\text{sort}}^2 \left(1 : \frac{\text{POP}}{2}\right), \\ M_s = X_{\text{sort}}^2 \left(\frac{\text{POP}}{2} + 1 : \text{pop}\right), \end{cases} \quad (12)$$

其中 F_s 表示父体, M_s 表示母体, X_{sort}^2 表示所有 X_{new}^2 按适应度值升序排列. 假设一个父体和一个母体只能繁衍一个后代, 则第 k 个子代的表达式为

$$X_k^{\text{offspring}} = r_3 X_k^F + (1-r_3) X_k^M, \quad (13)$$

其中 r_3 为 $[0, 1]$ 内的随机数, k 为 $[1, \text{pop}/2]$ 内的正整数, X^F 和 X^M 分别表示自父体和母体中随机抽取的个体.

2.2 Sobel 序列

群智能优化算法在进行种群初始化时普遍存在随机性过大的问题, 为解决该问题, 在海马优化算法中引入了 Sobel 序列^[20]. Sobel 序列通过精心选择的低差异点集在多维空间中均匀地覆盖参数空间, 使产生的初始化种群落入每个范围内的个体数量大致相同, 分布更均匀, 遍历性更广, 计算公式如下:

$$x_n = x_{\min} + K_n(x_{\max} - x_{\min}), \tag{14}$$

其中 K_n 为 $[0, 1]$ 内的随机数. 经过 Sobel 序列改进后的海马优化算法命名为 SSHO.

2.3 自适应权重

群智能优化算法普遍存在勘探和开发之间不平衡的问题, 海马优化算法也存在该问题, 为解决该问题, 可在海马优化算法中引入自适应权重(adaptive weight)算法^[21]. 自适应权重算法可以动态调节海马优化算法的搜索方式, 决定海马优化算法在勘探和开发之间进行抉择. 自适应权重算法计算公式如下:

$$w = \begin{cases} \frac{1}{2} \left[1 + \cos\left(\frac{\pi t}{T_{\max}}\right) \right]^{1/K}, & t \leq \frac{T_{\max}}{2}, \\ \frac{1}{2} \left[1 - \cos\left(\pi + \frac{\pi t}{T_{\max}}\right) \right]^{1/K}, & t > \frac{T_{\max}}{2}, \end{cases} \tag{15}$$

其中 K 表示调节系数. 加入自适应权重算法后的海马优化算法位置更新公式如下:

$$X_{\text{new}}^1(t+1) = \begin{cases} wX_k(t) + \text{Levy}(\lambda)((X_{\text{elite}}(t) - X_k(t)) \times x \times y \times z + X_{\text{elite}}), & r_1 > 0, \\ wX_k(t) + \text{rand} \times l \times \beta_t \times (X_k(t) - \beta_t \times X_{\text{elite}}), & r_1 \leq 0. \end{cases} \tag{16}$$

经过 Sobel 序列和自适应权重算法改进后的算法命名为 SASHO.

2.4 Googlenet 模型

神经网络有很多种, 但 Googlenet 模型^[22-23]的参数相对较少, 所以本文选择 Googlenet 作为基础识别模型. Googlenet 模型在进行改进过程中, 摒弃了传统通过加深网络层数提升网络性能的思路^[24-26], 在结构中引入了 Inception 模块. Inception 模块包含池化层和卷积层, 池化层窗口大小为 3×3 , 卷积层大小有 3 个, 分别为 $1 \times 1, 3 \times 3, 5 \times 5$. 在进行特征提取时, 通过这 4 种方式分别对输入图像进行特征提取, 会提取到大量的特征信息, 这样就会增加模型的计算量. 为降低模型计算量, Inception 模块还内置了 1×1 的卷积核实现数据降维^[27-28].

2.5 本文模型

通过调节 Googlenet 模型内部参数值可改善 Googlenet 模型的性能, 基于此, 本文应用改进后的 SASHO 自适应优化 Googlenet 模型内部的 3 个参数, 分别是学习率、层数和批量, 以此构建新模型 SASHO-Googlenet. 新模型构建伪代码如下:

```

初始化参数  $T_{\max}, \text{dim}, \text{pop}$  等.
应用 Sobol 序列初始化 Seahorses
计算个体适应度值
while ( $t < T_{\max}$ )
    根据式(16)更新个体位置
    根据式(10)更新个体位置
    根据式(12)选择父体、母体
    根据式(13)生成下一代海马种群
    计算适应度值
     $t = t + 1$ 
end
输出最优解
将最优解赋值给 Googlenet 模型.

```

3 实验及结果分析

3.1 实验设置

本文实验全部在实验室进行, 模型实现依托于 MATLAB. 首先, 为验证 SASHO 算法的有效性, 分别将本文 SASHO 算法与 SHO, SSHO, ASHO 算法基于 30 个测试函数进行对比. 其次, 为选择适

合本文实验数据集的基础神经网络模型, 分别将 Googlenet, Resnet18, Alexnet 和 Inceptionv3 模型基于实验数据集进行识别, 选择准确率最高的深度神经网络作为本文实验的基础识别模型. 最后, 为验证 SASHO-Googlenet 模型的有效性, 选取 4 种不同群体智能算法分别对 Googlenet 模型进行优化, 这些群体智能算法分别是遗传算法(GA)、灰狼优化(GWO)算法、粒子群优化(PSO)算法和鲸鱼优化算法(WOA). 为验证本文预测模型的性能, 选用 7 个常见性能指标作为评价指标, 分别是准确率、敏感性、特异性、精度、召回率、f_measure 和 g_mean.

3.2 实验结果

3.2.1 优化算法对比

为使展示结果不过于繁琐, 本文选择 6 个效果最好的函数结果进行展示, 实验结果列于表 1.

表 1 不同优化算法实验对比结果

Table 1 Experimental comparison results of different optimization algorithms

函数	指标	SHO 算法	SSHO 算法	SASHO 算法	ASHO 算法
F_{11}	最优值	1 800.501 513	1 556.038 766	1 491.088 462	1 969.121 280
	最差值	6 250.018 956	5 909.020 87	7 267.347 919	6 568.829 649
	平均值	3 603.852 222	3 120.740 285	3 109.796 777	3 385.917 494
	标准差	1 321.864 974	1 146.632 135	1 371.363 292	1 201.663 502
F_{13}	最优值	8 745 028.913	4 603 904.726	1 605 436.34	4 216 342.456
	最差值	3 056 060 913	6 395 092 981	3 308 740 992	5 067 724 006
	平均值	305 328 360.1	802 492 520	311 453 908.2	465 749 306.9
	标准差	579 919 760.8	1 394 640 528	641 937 851.1	1 266 444 435
F_{15}	最优值	13 192.288 73	17 792.427 89	11 409.459 3	17 377.592 50
	最差值	293 664 288	60 047 789.44	293 521 933.2	43 197 581.22
	平均值	30 277 890.08	3 088 799.558	12 778 862.43	4 954 145.918
	标准差	87 766 522.83	10 904 385.14	54 083 682.57	11 268 027.07
F_{16}	最优值	2 742.097 838	2 521.005 965	2 443.014 822	2 569.570 321
	最差值	4 179.910 689	3 809.244 671	3 911.418 552	4 805.106 781
	平均值	3 186.007 975	3 222.204 426	3 019.494 853	3 103.378 368
	标准差	337.441 546 8	334.900 545 9	340.150 595 5	396.514 566 5
F_{21}	最优值	2 475.258 726	2 478.781 628	2 474.267 065	2 477.678 686
	最差值	2 607.087 982	2 618.789 565	2 566.095 127	2 592.726 374
	平均值	2 525.156 613	2 529.839 213	2 512.205 807	2 524.709 034
	标准差	33.010 618 92	32.726 934 27	22.730 198 92	23.269 134 18
F_{26}	最优值	6 398.811 102	6 181.442 827	5 432.770 676	5 569.204 430
	最差值	8 665.132 452	8 594.622 462	8 822.997 868	9 116.172 786
	平均值	7 458.971 072	7 616.434 119	7 296.355 878	7 234.282 082
	标准差	682.060 488 1	602.627 704 9	857.495 389 5	807.108 504 1

由表 1 可见, 针对所有函数, 本文 SASHO 算法的最优值都优于其他算法, 尤其对 F_{13} 函数, SASHO 算法的最优值明显小于其他算法求得的最优值, 而对其他算法, 每种算法在不同函数上都寻到过最好的最优解. 但针对最优解评价指标, SASHO 算法在大部分函数上都寻到了最好的最优解, 其次是 ASHO, SSHO 算法, 最后是 SHO 算法. 针对最差值指标, 本文 SASHO 算法针对每个函数所求得的最差值与最优解值之间的差距大部分都最小, 而其他算法最优值与最小值之间大部分都存在较大差距, 说明与其他算法相比, SASHO 算法寻优的稳定性较好. 针对平均值和标准差这两个指标, SASHO 算法也展现了相对较好的性能, 所有值大部分均比其他算法的值低. 因此, 加入两个改进点创建的新算法 SASHO 的性能优于其他算法.

3.2.2 模型对比

图 3 为 4 个基础神经网络针对本文实验数据集进行识别得出的混淆矩阵, 依次是 Googlenet, Resnet18, Alexnet, Inceptionv3. 由图 3 可见, 与 Resnet18 神经网络相比, Googlenet 网络在真阳性、

假阳性、假阴性和真阴性指标上性能都更好; 与 Alexnet 网络和 Inceptionv3 相比, 虽然不是所有指标结果都是最好的, 但 Googlenet 网络具有最高的准确率.

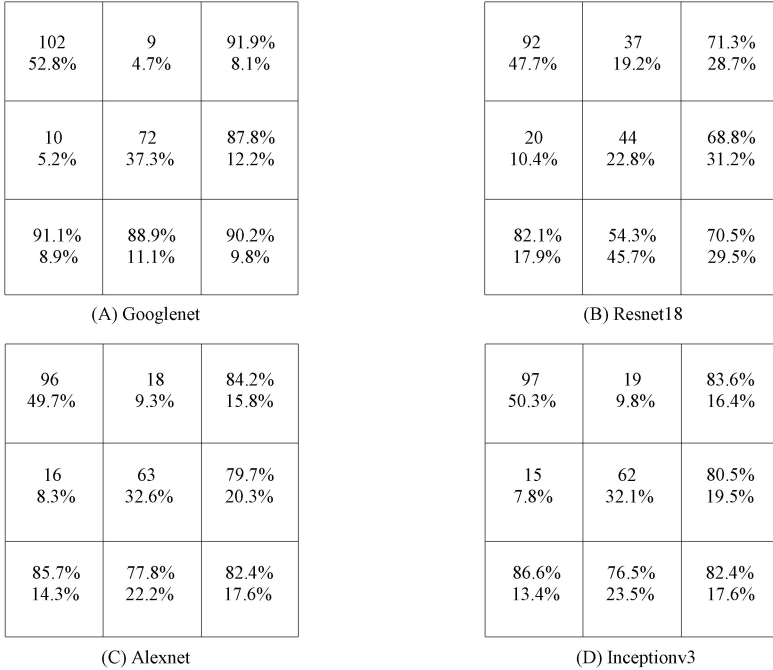


图 3 基础神经网络混淆矩阵

Fig. 3 Basic neural network confusion matrix

神经网络各指标对比结果列于表 2. 由表 2 可见, 在所有指标上 Googlenet 网络都展现了卓越的识别性能, 明显优于其他神经网络. 针对最经典的准确率指标, Googlenet 网络比其他模型高出 7.78~19.69 个百分点. 目前有多种神经网络被应用到水稻的病害识别问题中, 都提供了较好的识别精度. 但针对不同的数据集, 不同神经网络的识别结果存在差异. 针对敏感性和特异性两个指标, Googlenet 模型也给出了最好的结果. 针对敏感性指标, 只有 Googlenet 模型的数值达到 90%, 其他模型的结果均低于 90%, 其中 Inceptionv3 模型排第二, 达到 86.60%, 与 Googlenet 模型相差了 4.47 个百分点. 针对特异性指标, 只有 Googlenet 模型达到 80% 以上, 而其他模型均低于 80%, Resnet18 排在最后, 仅达到 54.32%. 综合实验结果表明, Googlenet 网络提供了最好的识别性能, 所以本文实验选取 Googlenet 网络作为基础模型.

表 2 不同神经网络各指标对比结果

Table 2 Comparison results of various indicators of different neural networks

指标	Googlenet	Resnet18	Alexnet	Inceptionv3
准确率	90.16	70.47	82.38	82.38
敏感性	91.07	82.14	85.71	86.60
特异性	88.89	54.32	77.78	76.54
精度	91.89	71.32	84.21	83.62
召回率	91.07	82.14	85.71	86.60
f_measure	91.48	76.35	84.96	85.09
g_mean	89.97	66.70	81.60	81.42

图 4 为经过不同群智能优化算法优化后模型的混淆矩阵, 依次是 SASHO-Googlenet, GA-Googlenet, GWO-Googlenet, PSO-Googlenet, WOA-Googlenet 模型. 由图 4 可见, SASHO-Googlenet 模型针对真阳性、假阳性、假阴性和真阴性指标上性能都更好. 表 3 列出了优化后不同神经网络各指标对比结果. 由表 3 可见, 在 7 个指标上, 本文 SASHO-Googlenet 模型都具有最好的性能. 准确率评价指标 SASHO-Googlenet 模型达到 95.36%, 与未经优化的 Googlenet 网络相比提高了

5.20 个百分点. 与经过其他群体智能算法优化的模型相比, SASHO-Googlenet 模型也提高了 12.46~16.60 个百分点. 针对敏感性、特异性、精度、召回率、f_measure 和 gmean 指标, SASHO-Googlenet 模型也有明显提高, 几个指标均达 90% 以上, 其他模型均低于 90%. 针对敏感性指标, GA-Googlenet 模型仅达 78.57%, 甚至未达到 80%. 针对特异性指标, 其他模型均低于 80%, PSO-Googlenet 模型甚至低于 70%, 仅达 67.90%. 针对精度指标, 只有 PSO-Googlenet 模型结果较差, 仅达 78.86%. 针对剩余指标, 所有模型普遍达 80% 以上, 只有 GA-Googlenet 模型在召回率与 g_mean 上未达 80%.

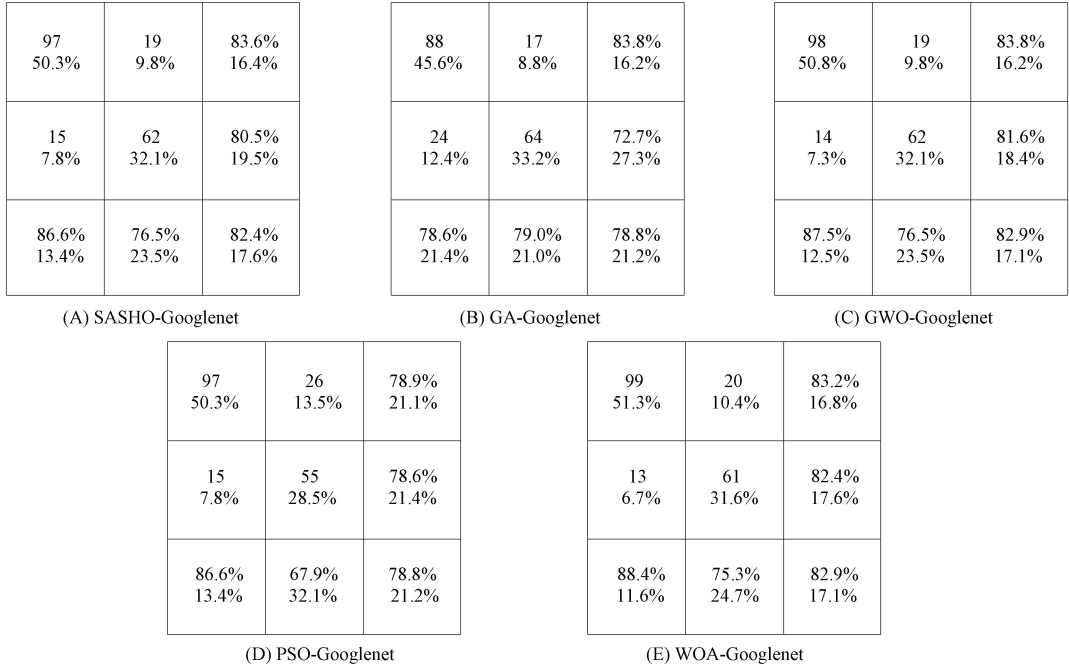


图 4 优化后神经网络混淆矩阵

Fig. 4 Optimized neural network confusion matrix

表 3 优化后不同神经网络各指标对比结果

Table 3 Comparison results of various indicators of different neural networks after optimization

指标	SASHO-Googlenet	GA-Googlenet	GWO-Googlenet	PSO-Googlenet	WOA-Googlenet
准确率	95.36	78.76	82.90	78.76	82.90
敏感性	95.35	78.57	87.50	86.60	88.39
特异性	95.39	79.01	76.54	67.90	75.31
精度	96.47	83.81	83.76	78.86	83.19
召回率	95.35	78.57	87.50	86.60	88.39
f_measure	95.90	81.10	85.60	82.55	85.71
g_mean	95.37	78.79	81.84	76.69	81.59

实验结果表明, 本文 SASHO-Googlenet 模型无论与基础神经网络相比, 还是与经过其他群智能优化算法优化的模型相比, 都具有最好的识别性能, 说明本文模型有效.

综上所述, 针对 Googlenet 模型识别准确率低、敏感性不佳等问题, 本文提出了一种新的识别模型 SASHO-Googlenet, 并将模型应用于水稻褐斑病和稻瘟病的识别中. 首先, 为选择出针对本文数据集最合适的神经网络模型设置了对比实验, 将 Googlenet 网络、Resnet18 网络、Alexnet 网络和 inceptionv3 网络分别以本文数据集作为输入, 并在 7 个评价指标上进行对比, 实验结果表明, Googlenet 网络最适用于本文数据集, 因此选择 Googlenet 网络作为本文实验的基础网络; 其次, 为提升原始 SHO 算法的寻优性能, 应用 Sobel 序列和自适应权重机制对算法进行了优化, 并为验证本文算法的有效性, 将 SHO, SSHO, SASHO 和 SSHO 算法基于 30 个测试函数进行对比, 由对比结果可见,

本文算法具有最好的寻优性能;再次,应用改进后的SASHO算法对Googlenet网络的参数进行了寻优以提升基础网络的识别性能;最后,为验证本文模型的性能,分别应用4个其他群体智能算法对Googlenet网络进行了优化,并针对7个指标进行了对比,对比结果表明,本文模型具有最好的识别性能。基于实验结果,本文模型可应用于水稻褐斑病和稻瘟病的识别中,有助于降低水稻因为病害而降低产量的问题。

参 考 文 献

- [1] SHAFAY M, AHMAD R W, SALAH K, et al. Blockchain for Deep Learning: Review and Open Challenges [J]. *Journal of Networks Software Tools and Applications*, 2023, 26(1): 197-221.
- [2] KHOEI T T, SLIMANE H O, KAABOUCH N. Deep Learning: Systematic Review, Models, Challenges, and Research Directions [J]. *Neural Computing & Applications*, 2023, 35(31): 23103-23124.
- [3] WANG L N, ZHENG Y C, WEI H X, et al. Stretching Deep Architectures: A Deep Learning Method without Back-Propagation Optimization [J]. *Electronics*, 2023, 12(7): 1537-1-1537-21.
- [4] QIAN C H, ZHU J J, SHEN Y H, et al. Deep Transfer Learning in Mechanical Intelligent Fault Diagnosis: Application and Challenge [J]. *Neural Processing Letters*, 2022, 54(3): 2509-2531.
- [5] SERGHIOU S, ROUGH K. Deep Learning for Epidemiologists: An Introduction to Neural Networks [J]. *American Journal of Epidemiology*, 2023, 192(11): 1904-1916.
- [6] MAMAT N, OTHMAN M F, ABDOLGHAFOR R, et al. Advanced Technology in Agriculture Industry by Implementing Image Annotation Technique and Deep Learning Approach: A Review [J]. *Agriculture-Basel*, 2022, 12(7): 1033-1-1033-35.
- [7] FARJON G, HUIJUN L, EDAN Y. Deep-Learning-Based Counting Methods, Datasets, and Applications in Agriculture: A Review [J]. *Precision Agriculture*, 2023, 24(5): 1683-1711.
- [8] VERMA S, KUMAR P, SINGH J P. A Unified Lightweight CNN-Based Model for Disease Detection and Identification in Corn, Rice, and Wheat [J]. *LETE Journal of Research*, 2023, 70(3): 2481-2492.
- [9] RAHMAN C R, ARKO P S, ALI M E, et al. Identification and Recognition of Rice Diseases and Pests Using Convolutional Neural Networks [J]. *Biosystems Engineering*, 2020, 194: 112-120.
- [10] YANG H B, LIU Z D. Image Recognition Technology of Crop Diseases Based on Neural Network Model Fusion [J]. *Journal of Electronic Imaging*, 2023, 32(1): 011202-1-011202-16.
- [11] CHEN J D, CHEN J X, ZHANG D F, et al. Using Deep Transfer Learning for Image-Based Plant Disease Identification [J]. *Computers and Electronics in Agriculture*, 2020, 173: 105393-1-105393-11.
- [12] LU Y, DU J J, LIU P F, et al. Image Classification and Recognition of Rice Diseases: A Hybrid DBN and Particle Swarm Optimization Algorithm [J]. *Frontiers in Bioengineering and Biotechnology*, 2022, 10: 855667-1-855667-12.
- [13] SHANMUGAM V, RAO T V M, RAO H J, et al. Internet of Things Based Smart Application for Rice Leaf Disease Classification Using Optimization Integrated Deep Maxout Network [J]. *Concurrency and Computation-Practice & Experience*, 2023, 35(6): 7545-1-7545-21.
- [14] DANIYA T, VIGNESHWARI S. Rider Water Wave-Enabled Deep Learning for Disease Detection in Rice Plant [J]. *Advances in Engineering Software*, 2023, 182: 103472-1-103472-12.
- [15] 刘威, 高新成, 王启龙, 等. 基于离散粒子群的SDN动态流调度算法 [J]. *吉林大学学报(理学版)*, 2023, 61(5): 1139-1146. (LIU W, GAO X C, WANG Q L, et al. SDN Dynamic Flow Scheduling Algorithm Based on Discrete Particle Swarm [J]. *Journal of Jilin University (Science Edition)*, 2023, 61(5): 1139-1146.)
- [16] 王李祺, 侯宇超, 高翔, 等. 基于深度学习与狮群SVM算法的遥感场景分类 [J]. *吉林大学学报(理学版)*, 2023, 61(4): 863-874. (WANG L Q, HOU Y C, GAO X, et al. Remote Sensing Scene Classification Based on Deep Learning and Lion Swarm SVM Algorithm [J]. *Journal of Jilin University (Science Edition)*, 2023, 61(4): 863-874.)
- [17] 李健, 孙晓海, 廖昌义, 等. 基于双起点蚁群算法的机器人路径规划新方法 [J/OL]. *吉林大学学报(工学版)*,

- (2023-10-11)[2023-11-01]. <https://doi.org/10.13229/j.cnki.jdxbgxb.20230339>. (LI J, SUN X H, LIAO C Y, et al. A New Method for Robot Path Planning Based on Dual-Starting Ant Colony Algorithm [J/OL]. Journal of Jilin University (Engineering and Technology Edition), (2023-10-11)[2023-11-01]. <https://doi.org/10.13229/j.cnki.jdxbgxb.20230339>.)
- [18] SANKARESHWARAN S P, JAYARAMAN G, MUTHUKUMAR P, et al. Optimizing Rice Plant Disease Detection with Crossover Boosted Artificial Hummingbird Algorithm Based AX-RetinaNet [J]. Environmental Monitoring and Assessment, 2023, 195(9): 1070-1-1070-24.
- [19] ZHAO S J, ZHANG T R, MA S L, et al. Sea-Horse Optimizer: A Novel Nature-Inspired Meta-Heuristic for Global Optimization Problems [J]. Applied Intelligence, 2023, 53(10): 11833-11860.
- [20] SUN X F, CROKE B, ROBERTS S, et al. Comparing Methods of Randomizing Sobol' Sequences for Improving Uncertainty of Metrics in Variance-Based Global Sensitivity Estimation [J]. Reliability Engineering & System Safety, 2021, 210: 107499-1-107499-10.
- [21] XIANG Z X, PENG W, LIU X, et al. Self-adaptive Loss Balanced Physics-Informed Neural Networks [J]. Neurocomputing, 2022, 496: 11-34.
- [22] STROZZI F, POZZI R. Trend and Seasonality Features Extraction with Pre-trained CNN and Recurrence Plot [J]. International Journal of Production Research, 2023, 62(9): 3251-3262.
- [23] SWARUP C, SINGH K U, KUMAR A, et al. Brain Tumor Detection Using CNN, AlexNet & GoogLeNet Ensembling [J]. Electronic Research Archive, 2023, 31(5): 2900-2924.
- [24] 范英, 石磊, 苏伟伟, 等. 基于 PINet+RESA 网络的车道线检测算法 [J]. 江苏大学学报(自然科学版), 2023, 44(4): 373-378. (FAN Y, SHI L, SU W W, et al. Lane Line Detection Algorithm Based on PINet+RESA Network [J]. Journal of Jiangsu University (Natural Science Edition), 2023, 44(4): 373-378.)
- [25] 黄金钾, 詹永照, 赵逸飞. 整体与局部相互感知的图网络时序动作检测 [J]. 江苏大学学报(自然科学版), 2024, 45(1): 67-76. (HUANG J J, ZHAN Y Z, ZHAO Y F. Graph Network Temporal Action Detection Based on Global and Local Mutual Perception [J]. Journal of Jiangsu University (Natural Science Edition), 2024, 45(1): 67-76.)
- [26] 王民水, 王明常, 王婧瑜, 等. 融合注意力机制和权重平衡算法的遥感图像分类 [J/OL]. 吉林大学学报(地球科学版), (2024-10-16)[2025-02-06]. <https://link.cnki.net/urlid/22.1343.P.20241016.1003.001>. (WANG M S, WANG M C, WANG J Y, et al. Remote Sensing Image Classification Based on Attention Mechanism and Weight Balance Algorithm [J/OL]. Journal of Jilin University (Earth Science Edition), (2024-10-16)[2025-02-06]. <https://link.cnki.net/urlid/22.1343.P.20241016.1003.001>.)
- [27] 田亮, 金积德, 郑庆祥. 基于检测增强型 YOLOv3-tiny 的道路场景行人检测 [J]. 江苏大学学报(自然科学版), 2024, 45(4): 441-448. (TIAN L, JIN J D, ZHENG Q X. Pedestrian Detection in Road Scene Based on Detection-Enhanced YOLOv3-tiny [J]. Journal of Jiangsu University (Natural Science Edition), 2024, 45(4): 441-448.)
- [28] 王蕾, 党时鹏, 潘丰. 基于卷积神经网络的隐匿性旁路预测模型 [J]. 计算机工程, 2024, 50(8): 40-49. (WANG L, DANG S P, PAN F. Insidious Bypass Prediction Model Based on Convolutional Neural Network [J]. Computer Engineering, 2024, 50(8): 40-49.)

(责任编辑: 韩 啸)