[文章编号] 1003－4684(2025)02-0001-010

基于 IWOA-LMBP 的水稻插秧机可靠性预测

文昌俊[1,2]，陈　凡[1,2]，康　锁[1,2]，陈洋洋[1,2]

(1 湖北工业大学机械工程学院，湖北 武汉 430068；2 湖北省现代制造质量工程重点实验室，湖北 武汉 430068)

[摘　要] 针对水稻插秧机可靠性评价存在明显滞后的问题，提出一种创新的解决方案：构建改进鲸鱼算法－列文伯格·马夸德优化的 BP 神经网络可靠性预测模型。其设计思路如下：首先，引入 Chebyshev 混沌策略，以增强初始种群的多样性；其次，采用“双阶梯”和“双山谷”非线性自适应因子，动态平衡算法的全局搜索与局部勘探能力；最后，结合趋优透镜反向学习策略，以更新个体位置，进一步提升个体质量，有效帮助算法跳出局部最优。通过 6 个基准测试函数的寻优对比分析和 Wilcoxon 秩和统计检验可知，IWOA 具有更好的寻优性能。随后，利用现场跟踪获取的水稻插秧机故障数据，建立 IWOA-LMBP 模型。为了全面评估该模型的性能，选取 MAE、RMSE、R^2 作为网络模型的评价指标，并将其与其他 5 种模型进行对比。结果表明：采用 IWOA-LMBP 模型进行预测时，效果更好。

[关键词] 水稻插秧机；改进鲸鱼算法；趋优透镜反向学习；LMBP 神经网络；可靠性预测

[中图分类号] TP391.9　　[文献标识码] A

在信息化农业背景下，水稻插秧机的重要性日益凸显，但其复杂结构和恶劣工作环境下的可靠性预测成为亟待解决的难题。相较传统可靠性理论，BP 神经网络凭借其强大的非线性处理能力和出色的泛化能力，在可靠性研究领域内赢得广泛的关注。胡启国等[1]运用 BP 神经网络对发动机部件进行回归拟合，并结合均值矩法，对连杆在稳定工况下的可靠性进行了深入而有效的分析，为机械零部件的可靠性评估开辟了新的思路；郑倩等[2]则构建了一个双隐层的 BP 神经网络模型，用于预测设计应变，并结合蒙特卡洛(monte carlo，MC)法，对走滑断层区 X80 管道进行了可靠性计算。预测结果表明，该模型不仅计算结果准确，而且运行成本相对较低。此外，张烨等[3]为了提高燃气轮机模型的整体仿真精度，利用 BP 神经网络对燃机截面参数进行了拟合计算，所得结果能够紧密地跟随现场运行数据，显示出较高的精度。

然而，上述文献中所采用的 BP 训练算法均为梯度下降法。该方法对全权阈值的选取具有一定的随机性，这往往导致模型的全局收敛性能不佳，且易陷入局部最优[4]。

为了解决上述挑战，LMBP 算法常被采纳作为建模工具，相较于传统的梯度下降算法，LMBP 算法在改善全局收敛性方面展现出了显著优势[5]。然而，LMBP 算法本质上仍是对梯度下降法的改进，因此，它同样面临着因初始随机权阈值设定不当而导致模型精度受限的问题。鲸鱼算法(whale optimization algorithm，WOA)是一种新型的群智能算法[6]，在解决 BP 神经网络局部收敛性差和易陷入局部最优等问题上表现出色[7]。然而，当面对高维复杂非线性问题时，WOA 算法在求解精度上仍有待提升。

鉴于此，本文提出了一种改进的鲸鱼算法——IWOA。该算法通过采用 Chebyshev 混沌策略，有效增强了初始种群多样性；同时，引入“双阶梯”和“双山谷”非线性自适应因子，以在种群迭代全期，动态平衡勘探与开发能力；此外，还结合了趋优透镜反向学习策略更新个体位置，从而提升了个体质量，并帮助算法跳出局部最优。

1　IWOA-LMBP 算法设计

1.1　LMBP 算法

BP 神经网络求解的实质为寻找问题误差集的最小化解，其对应的公式如下：

[收稿日期] 2023－08－29

[基金项目] 国家自然科学基金(51875180)

[第一作者] 文昌俊(1970－)，男，湖北仙桃人，湖北工业大学教授，研究方向为可靠性与质量控制。

[通信作者] 陈　凡(1996－)，男，湖北鄂州人，湖北工业大学硕士研究生，研究方向为群智能算法应用与可靠性分析。

$$\min E(\boldsymbol{x}^*) = \min E(w,b) = \min\left(\frac{1}{2}\sum_{k=1}^{n}(t_k - y_k)^2\right) \tag{1}$$

式中：$\boldsymbol{x}^*$ 为神经元结构 m-p-n 的权阈值 w，b 组合；n 为样本个数；t_k 为第 k 个样本期望输出量，y_k 为第 k 个样本实际输出量。与基本 BP 算法使用单个样本信息计算误差不同，LMBP 算法利用所有样本信息对权阈值进行修正[8]，即：

$$\boldsymbol{x}_{k+1}^* = \boldsymbol{x}_k^* - (\boldsymbol{J}_T J + \mu \boldsymbol{I})^{-1}\boldsymbol{J}_T e \tag{2}$$

式中：$\boldsymbol{x}_{k+1}^*$ 为第 $k+1$ 次迭代的连接权值向量；$-\boldsymbol{J}$ 为误差向量 e 对权阈值 w，b 为求导的雅克比矩阵；$\boldsymbol{I}$ 为单位矩阵，μ 为比例系数。

当 $\mu \to 0$ 时，$\mu\boldsymbol{I} \to 0$，此时为 BFG 拟牛顿法；

当 $\mu\boldsymbol{I} \to \infty$ 时，$\boldsymbol{J}_T\boldsymbol{J} \ll \mu\boldsymbol{I}$，$\boldsymbol{J}_T\boldsymbol{J}$ 趋近于 0，此时则变成梯度下降法。

因此，通过调整 μ 的取值，LMBP 算法能够兼具高斯-牛顿法的局部收敛特性和梯度下降法的良好全局收敛能力[9]。

为了更好地展示 LMBP 算法的性能优势，分别采用梯度下降算法、拟牛顿算法（以 BFG 算法为例）以及 LMBP 算法对水稻可靠性模型进行了训练，训练结果汇总于表 1。从表 1 可以看出，在达到相同训练目标的情况下，LMBP 算法仅需 3 次迭代就完成了训练过程，且耗时最短。而在训练次数相同的情况下，LMBP 算法不仅在时间上保持了最优表现，而且其训练精度相较梯度下降算法和 BFG 算法分别提高了 150 多倍和 10 多倍。因此，采用 LMBP 算法能够显著提升模型的训练精度，是优化水稻可靠性模型训练过程的有效选择。

表 1 BP 训练算法比较

算法	相同训练目标（精度值=0.001）		相同训练次数（训练次数=100）	
	平均训练次数	平均训练时间/s	平均精度值	平均训练时间/s
梯度下降法	18550	12.684	0.0501	2.2703
BFG 拟牛顿法	110	1.4287	0.00406	1.7612
LM 算法	3	1.1246	0.000318	1.6431

1.2 标准鲸鱼算法

WOA 的寻优过程巧妙地模拟了鲸鱼的捕猎行为，具体分为三个阶段：包围猎物、气泡网捕食和随机搜索。

1.2.1 包围猎物 WOA 假设当前最优解为猎物位置，随后种群其他个体根据当前最优解来更新自身位置，表示如下：

$$\boldsymbol{D} = |\boldsymbol{C}\boldsymbol{X}_p(t) - \boldsymbol{X}_k(t)| \quad \boldsymbol{D} = |\boldsymbol{C}\boldsymbol{X}_p(t) - \boldsymbol{X}_k(t)| \tag{3}$$

$$\boldsymbol{X}_k(t+1) = \boldsymbol{X}_p(t) - \boldsymbol{A}\boldsymbol{D} \tag{4}$$

式中：t 为当前迭代次数；$\boldsymbol{X}_k(t)$ 为第 k 条鲸鱼个体在第 t 次迭代的位置向量；$\boldsymbol{X}_p(t)$ 为第 t 次迭代种群最优解的位置；$\boldsymbol{X}_k(t+1)$ 为更新后鲸鱼个体位置向量；$\boldsymbol{D}$ 表示搜索步长；$\boldsymbol{A}$ 和 $\boldsymbol{C}$ 是控制向量，$\boldsymbol{A}$ 用于调节鲸鱼个体移动的方向，C 用于修正猎物位置，分别用式(5)和式(6)计算。

$$\boldsymbol{A} = 2a\,\mathrm{rand}() - a \tag{5}$$

$$\boldsymbol{C} = 2\mathrm{rand}() \tag{6}$$

式中：rand()为(0,1)间的随机数；α 为收敛因子，随迭代次数从 2 线性减小至 0，即

$$a = 2 - 2\frac{t}{t_{\max}} \tag{7}$$

其中，$t_{\max}$ 为最大迭代次数。

1.2.2 气泡网捕食 鲸鱼群气泡网攻击的过程中，同时采用两种策略：收缩包围和螺旋更新。

1）收缩包围。通过减少式(7)中的收敛因子 a 值来影响 $|\boldsymbol{A}|$ 的波动幅度以实现：当 $|\boldsymbol{A}| \leqslant 1$ 时，每条鲸鱼都会离猎物更近一步，以此包围猎物，即

$$\boldsymbol{X}_k(t+1) = \boldsymbol{D}' e^{bl}\cos(2\pi l) + \boldsymbol{X}_p(t) \tag{8}$$

式中：$\boldsymbol{D}'$ 表示鲸鱼到猎物间的距离；b 是调整螺旋的常量；l 为[-1,1]间的随机数。

2）螺旋更新位置。在鲸鱼收缩包围圈以逼近猎物的过程中，它们还会遵循一条螺旋路径向猎物移动。为了在计算模型中再现鲸鱼的这两种捕猎行为，采用相同概率 p 进行位置更新：

$$\boldsymbol{X}_k(t+1) = \begin{cases} \boldsymbol{X}_p(t) - \boldsymbol{A}\boldsymbol{D}, p < 0.5, |\boldsymbol{A}| < 1 \\ \boldsymbol{D}' e^{bl}\cos(2\pi l) + \boldsymbol{X}_p(t), p \geqslant 0.5 \end{cases} \tag{9}$$

1.2.3 随机搜索 当 $p < 0.5$，且 $|\boldsymbol{A}| \geqslant 1$ 时，鲸鱼个体通过随机挑选其他鲸鱼个体来更新自身位置：

$$\boldsymbol{D} = |\boldsymbol{C}\boldsymbol{X}_{\mathrm{rand}}(t) - \boldsymbol{X}_k(t)| \tag{10}$$

$$\boldsymbol{X}_k(t+1) = \boldsymbol{X}_{\mathrm{rand}}(t) - \boldsymbol{A}\boldsymbol{D} \tag{11}$$

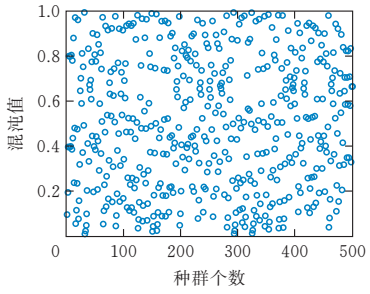
式中，$\boldsymbol{X}_{\mathrm{rand}}(t)$ 表示随机的鲸鱼个体。

1.3 IWOA 算法

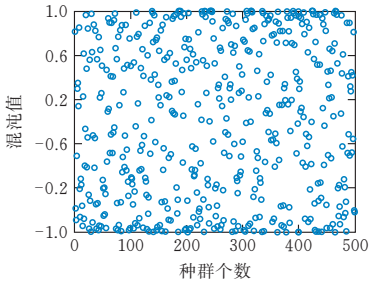
IWOA 从初始化种群，收敛因子与权重因子，种群位置更新等三个方面来进行深度优化：首先，通过引入 Chebyshev 策略来初始化种群，确保初始种群在解空间内既保持低聚集度又具备高覆盖度，为全局搜索构建一个拓扑结构优良的空间基础；其次，采用“双扰动”型非线性自适应因子进行联合调控，实现了"探索-开发"能力的自适应平衡；最后，融入趋优透镜反向学习机制，不仅提升了种群进化质量，还赋予了算法突破局部极值束缚的能力。这三项改进措施互相衔接，形成了"优质初始化-动态搜索调控-智能逃逸"的完整优化链条，帮助 WOA 算法实

现精确寻优。

1.3.1　Chebyshev 混沌映射初始种群　混沌运动以其随机性、内在规律性以及全面的遍历性，在解决函数优化问题时能够发挥重要作用，帮助算法跳出局部最优值，并促进种群多样性的提升。因此，本文采用混沌映射来确定初始种群的分布。常用的混沌映射有 Logistic、Tent、Circle 映射等，岳龙飞[10]等的研究已证实，Tent 混沌映射在遍历性、均匀性等方面表现较好。故本文选取 Tent 和 Chebyshev 映射进行分析与对比(图 1)。



(a)Tent 映射



(b)Chebyshev 映射

图 1　2 种映射在 500 次迭代下的初始种群

由图 1 可知，Chebyshev 映射生成的随机个体分布在[−1,1]的区间内，它不仅具备空间遍历性和反向抑制的双重特性，而且通过增强边界群体的多样性，帮助算法更好地处理极端问题。其数学描述为：

$$x_{n+1}=\cos(k\arccos x_n),x_n\in[-1,1] \tag{12}$$

式中：x_n 为第 n 次迭代个体；k 为阶次，当 $k\geqslant 2$ 时，迭代出的序列是混沌和遍历的，本文取 $k=4$。

1.3.2　“双扰动”型非线性自适应因子　WOA 算法的全局搜索和局部开发能力由参数 $\boldsymbol{A}$ 决定。由式(5)可知，$\boldsymbol{A}$ 值随收敛因子 a 的变化而变化。这意味着，WOA 算法在全局搜索和局部开发之间的切换，完全依赖于收敛因子 a 的变化情况。然而，原有的收敛因子 a 是采用线性递减的方式，这种方式的协调能力较弱。同时，权重因子 λ 对算法寻优性能有着至关重要的影响，一个合理的权重设置能优化算法的寻优效率。因此，引入“双扰动机制”，并对收敛因子 a 进行改进，采用“双阶梯”自适应非线性收敛因子，如图 2 所示。相应地，将式(7)调整为：

$$a=a_{\min}+(a_{\max}-a_{\min})/(1+e^{\frac{20t}{t_{\max}}}-10) \tag{13}$$

式中：t 为当前迭代次数；$t_{\max}$ 为最大迭代次数；$a_{\max}=2$，$a_{\min}=0$。

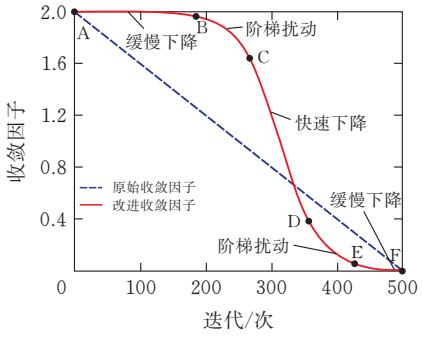


图 2　“双阶梯”收敛因子

由图 2 可知，改进后的收敛因子 a 在迭代前期呈现缓慢递减的趋势，且其初值设定得相对较大。该设计可使种群大范围、慢速度遍历整个搜索空间有利于算法寻优至全局最优位置附近。在 BC 段，采用阶梯扰动机制，使得收敛因子 a 由缓慢下降逐渐过渡到快速下降阶段(FM)，这一快速变化，可降低寻优点停留在局部极值的概率。而在 DE 阶段，再次运用阶梯扰动机制，使收敛因子 a 从急速下降转变为缓慢下降，算法以小步长进行精细开发，进一步增强其局部开发能力。因此，通过引入“双阶梯”扰动机制，显著提升了收敛因子 a 的协调性与灵活性，这有助于算法在寻优过程中实现更快的速度与更高的精度。

类似地，对权重因子采用了“双山谷”扰动机制，如图 3 所示，这一机制的数学模型如下：

$$\lambda=\begin{cases}\gamma_1(\cos(\dfrac{(t-1)\pi}{\gamma_2})+\gamma_3)t/t_{\max}\leqslant 0.5\\ \mu_1\sin(\mu_2(t-1)\pi)+\mu_3 t/t_{\max}>0.5\end{cases} \tag{14}$$

式中：γ_1、γ_2、γ_3 为前半个迭代周期的调整参数，分别取值为 0.225，180，3；μ_1、μ_1、μ_1 为后半个迭代周期的调整参数，分别取值为 0.3，0.01，0.3。

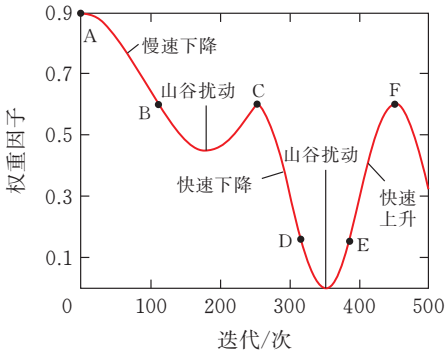


图 3　“双山谷”权重因子

结合 WOA 位置公式，IWOA 公式定义如下：

$$\boldsymbol{X}_k(t+1)=\lambda\boldsymbol{X}_p(t)-\boldsymbol{AD},|\boldsymbol{A}|<1,p<0.5 \tag{15}$$

$$\boldsymbol{X}_k(t+1)=\lambda\boldsymbol{X}_{\text{rand}}(t)-\boldsymbol{AD},|\boldsymbol{A}|\geqslant 1,p<0.5 \tag{16}$$

$$\boldsymbol{X}_k(t+1)=\boldsymbol{D}'\,e^{bl}\cos(2\pi l)+\lambda\,\boldsymbol{X}_p(t),p\geqslant 0.5 \quad (17)$$

最后，在迭代后期，权重 λ 再次呈现快速下降的趋势，这一设计有利于算法在接近最优解时快速收敛，确保最终能够找到全局最优解。

由图 3 可知，权重 λ 通过“双山谷”扰动机制实现了与算法迭代特点的自适应匹配。在迭代初期 AB 段，权重 λ 呈现慢速下降的趋势，与收敛因子 a 缓慢下降形成差异对比，这一设计有助于算法在前期快速收敛。

进入迭代中期 BD 段，引入了“山谷”扰动机制，使得权重 λ 经历了“慢速下降−适中上升−快速下降”的阶段变化，与收敛因子 a 在此期间的急速下降形成显著反差。

在迭代中后期，再次引入“山谷”扰动机制，使权重 λ 由快速下降转变为快速上升，这一转变阶段与收敛因子 a 变化明显不同，形成了较大的扰动效应。这种扰动有助于权重 λ 在迭代后期再次快速下降，确保最终能够找到全局最优解。

综上所述，“双阶梯”和“双山谷”扰动机制相互协作，有效地帮助算法在寻优过程中实现快速收敛与跳出局部最优。

1.3.3 趋优透镜反向学习 在鲸鱼算法的迭代寻优进程中，螺旋收缩和包围猎物这两种更新模式均紧密围绕当前最优的鲸鱼个体展开搜索，这使得最优个体的位置尤为重要。然而，基本鲸鱼算法并未充分挖掘和利用最优个体所蕴含的信息，导致对最优个体的开发利用不足。透镜反向学习作为一种已被证明能增强群智能算法局部搜索能力的技术[11]，虽然具有其独特的优势，但一旦选择空间内不存在最优解，算法仍可能陷入局部最优的困境。所以，本文将透镜反向学习与最优个体相结合进行位置更新。这一策略旨在提升算法寻优个体的质量，并增强算法跳出局部最优的能力。

对当前个体实施透镜反向学习，其原理如图 4 所示，在横坐标区间 $[a,b]$ 内，位于 x 处、高度为 h 的物体，在透镜的作用下，于位置 x^* 处形成一个高度为 h^* 的像。透镜的位置为 $[a,b]$ 的中点。由成像原理：

$$x^*=\frac{a+b}{2}+\frac{a+b}{2k}-\frac{x}{k} \quad (18)$$

式中：a，b 分别代表个体的上下界，k 为透镜的聚焦能力。通过调节 k 值可更有效地寻找最优位置，从而帮助鲸鱼算法摆脱局部最优的束缚。

文献[12]指出，虽然反向个体质量在总体上占优，但仍有部分个体质量降低的情况。为了改善此种状况并丰富种群多样性，将求得的透镜反向个体

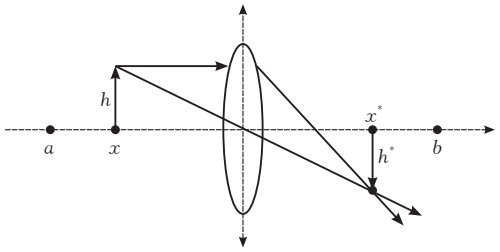


图 4 透镜反向学习原理

与当前种群中最优个体进行组合，从而得到趋优透镜反向个体。

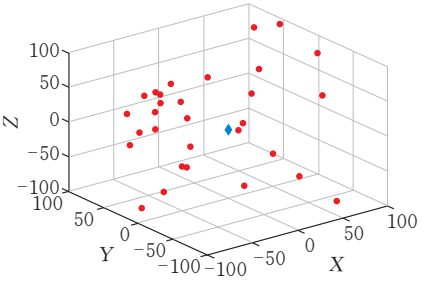
$$\eta=t/t_{\max} \quad (19)$$

$$x'=\eta x^*+(1-\eta)x_{\text{best}} \quad (20)$$

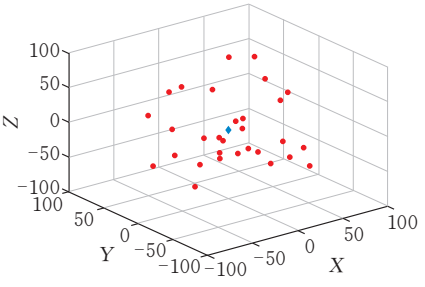
式中，η 是一个随迭代自适应更改的参数。在迭代早期阶段，η 的值相对较小，此时 x_{best} 在组合中占据比较大比重，算法围绕 x_{best} 来快速定位到种群最优解附近，有效提升了算法的全局搜索能力与收敛速度。而在迭代的中后期，η 逐渐增大，算法侧重于透镜成像学习策略，围绕局部开发阶段进行反向学习，以进一步提高算法寻优精度。

此外，本文将新生成的 N 个镜像个体和原种群的 N 个个体合并，通过比较适应度来进行筛选，进而确定最优解。为了验证迭代后种群的高质量与多样性，选取了 30 个鲸鱼个体对式(21)进行迭代寻优实验。

实验结果如图 5 所示。



(a)学习前



(b)学习后

图 5 趋优透镜反向学习前后种群位置

图中红色圆点表示 30 个种群个体，蓝色菱形则表示全局最优位置，其坐标为(0,0,0)。通过观察趋优透镜反向学习前后的种群位置对比，可见趋优透镜反向学习生成的种群更加出色，可以较好地提高

算法的寻优精度与收敛速度。

$$f(x)=\sum_{i=1}^{d}(\sum_{j=1}^{i}x_j)^2 \tag{21}$$

1.4 IWOA 算法验证

仿真实验环境为：Win10 64 位，AMD Ryzen 5 5600X CPU，运行内存 16GB，Matlab R2021b。为保证实验公平性，所有算法（除单独说明）实验均独立运行 30 次，每次 t_{max} 均为 500 次，种群 N 均设为 30。

为了验证本文所提出的 IWOA 算法在求解优化问题时的寻优性能及其鲁棒性，将其与新改进的智能优化算法 MPSO（采用自适应策略的粒子群优化算法）[13]、经典灰狼算法 GWO[14]、最新改进的灰狼算法 DSFGWO（扰动翻滚觅食灰狼优化算法）[15]、原始的 WOA 算法以及最新改进的鲸鱼算法 MSWOA（多策略鲸鱼优化算法）[16]这 6 种算法进行对比。

对比实验针对表 2 中 6 个基准函数展开，并对所得数据进行 Wilcoxon 秩和统计检验[17]，在复现文献[4,17-19]的实验过程中，按照表 3 给出的主参数设置对每种算法进行了配置，以确保实验的公平性和一致性。实验结果汇总于表 4。

表 2　基准函数

序列	函数符号	维度	范围	最优解
f_1	Sphere	30	[−100,100]	0
f_2	Schwefel 2.22	30	[−10,10]	0
f_3	Schwefel 1.2	30	[−100,100]	0
f_4	Schwefel 2.21	30	[−100,100]	0
f_7	Quartic	30	[−1.28,1.28]	0
f_{10}	Rastrigin	30	[−5.12,5.12]	0

表 3　各算法主参数

算法	主参数
MPSO	$V_{max}=2, w=(0.9\rightarrow 0.4)$ 线性递减 $c_1=c_2=2$
GWO	$a=(2\rightarrow 0)$ 线性递减
DSFGWO	$S=2$，$w=2.5$，$r_1=r_2=$ rand
WOA	$b=1$
MSWOA	$b=1, u=1$，$z=0.152$，$\omega=(1.5\rightarrow 0.5)$ 非线性递减，$a=(2\rightarrow 0)$ 非线性递减
IWOA	$a=(2\rightarrow 0)$，$\lambda=(0.9\rightarrow 0)$ 非线性递减，$k=15000$，$b=1$

表 4　各算法求解测试函数的结果对比

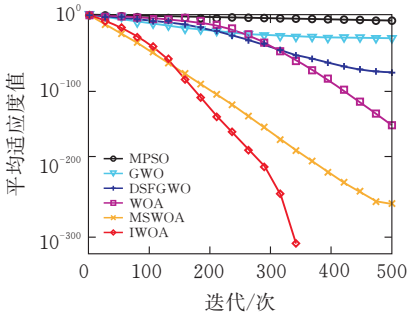
函数	性能指标	MPSO	GWO	DSFGWO	WOA	MSWOA	IWOA
f_1	Ave	1.45E-03	1.05E-27	2.26E-255	3.16E-75	2.70E-147	**0**
	Std	1.09E-03	1.87E-27	0	1.38E-74	1.47E-146	**0**
	P	1.14E-12	1.14E-12	1.14E-12	1.14E-12	1.14E-12	
	Time/s	0.146	0.130	0.081	0.032	0.028	**0.026**
f_2	Ave	5.13E-02	1.17E-16	8.08E-132	2.90E-51	2.73E-81	**0**
	Std	2.29E-02	1.07E-16	1.95E-131	1.03E-50	7.20E-80	**0**
	P	1.14E-12	1.14E-12	1.14E-12	1.14E-12	1.14E-12	
	Time/s	0.168	0.149	0.121	0.058	0.052	**0.048**
f_3	Ave	2.10E+01	1.90E-05	1.51E-119	4.63E+04	2.57E-131	**0**
	Std	5.70E+00	6.37E-05	8.30E-119	1.32E+04	9.08E-131	**0**
	P	1.14E-12	1.14E-12	1.14E-12	1.14E-12	1.14E-12	
	Time/s	0.153	0.136	0.107	0.034	0.033	**0.029**
f_4	Ave	4.64E-01	8.30E-07	5.17E-120	5.73E+01	1.14E-70	**8.76E-318**
	Std	8.76E-02	1.19E-06	2.44E-119	2.82E+01	9.23E-71	**0**
	P	1.62E-12	1.62E-12	1.62E-12	1.62E-12	1.62E-12	
	Time/s	0.125	0.132	0.096	0.036	0.032	**0.031**
f_7	AvE10	2.24E+00	1.90E-03	3.00E-04	3.30E-03	1.82E-04	**8.73E-05**
	Std	3.74E+00	1.06E-03	2.93E-04	4.08E-03	1.42E-04	**8.79E-05**
	P	2.87E-11	2.87E-11	2.90E-05	1.04E-10	4.32E-03	
	Time/s	0.289	0.201	0.181	0.105	0.974	**0.953**
f_9	Ave	6.04E+01	2.32E+00	**0**	9.47E-15	3.74E-02	**0**
	Std	2.12E+01	3.00E+00	**0**	3.01E-14	2.05E-01	**0**
	P	1.14E-12	1.13E-12	Na	7.81E-02	3.17E-02	
	Time/s	0.217	0.139	0.116	0.045	0.038	**0.036**
+/=/−		6/0/0	6/0/0	5/1/0	6/0/0	6/0/0	

表 4 中：Ave、Std 分别代表平均值、标准差这 2 项关键性能指标；最优值以粗体字突出显示；Time 为算法求解函数所需的时间；P 为 30 次运算后与 IWOA 进行 Wilcoxon 秩和检验的结果，当 $P<0.05$ 时，可以认为 IWOA 与该算法具有显著性差异；Na 表示两者几乎相同；“+”“=”“−”分别表示 IWOA 优于、相等和劣于该对比算法。

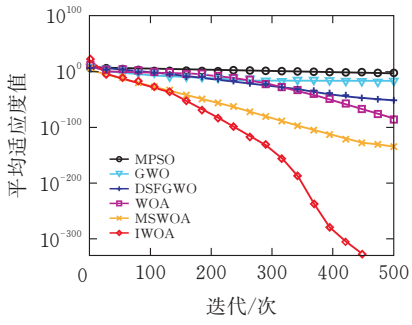
由表 4 知，在这 6 个测试函数的寻优实验中，本文所提出的 IWOA 的寻优效果明显优于其他 6 种对比算法，对于单峰函数 F1、F2、F3，IWOA 算法不仅成功找到理论最优值，而且在寻优精度和稳定性方面也优于 MPSO、GWO、DSFGWO、WOA、MSWOA 等算法。对于单峰函数 F4，虽未寻优到最优值，但 IWOA 寻优精度远超 WOA 及其他改进算法多达 100 多个数量级；对于多峰函数 F7，尽管 IWOA 同样未能寻得最优值，但其寻优精度和稳定性仍位列第一。而对于多峰函数 F9，IWOA 则能稳定地找寻到最优值，这进一步验证了该算法的优越性。此外，在 Wilcoxon 检验方面，所有检验的 P 值均未小于 0.05，这表明 IWOA 算法的寻优性能与其他算法存在显著差异，且其性能优于其他算法。

综上所述，IWOA 算法在平均值和标准差这两项关键性能指标上均明显优于其他对比算法，这体现出 IWOA 算法强大的寻优性能和鲁棒性。

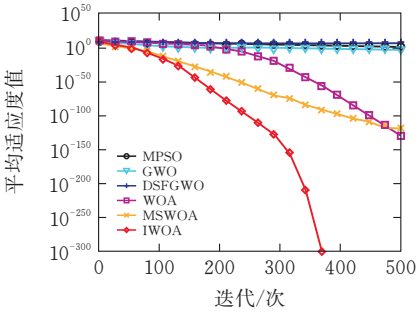
为了更直观地展现上述算法的收敛速度与性能特点，绘制 IWOA 与其他对比算法的收敛曲线（图 6）。



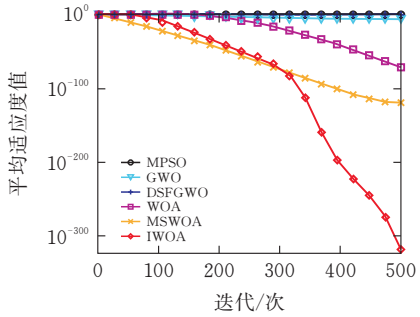
（a）函数 f_1 的测试平均收敛曲线



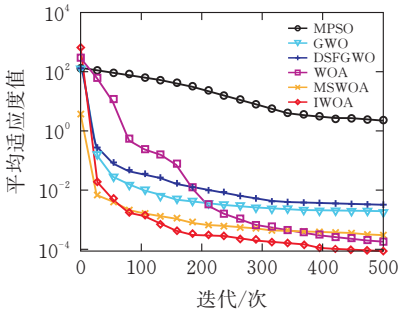
（b）函数 f_2 的测试平均收敛曲线



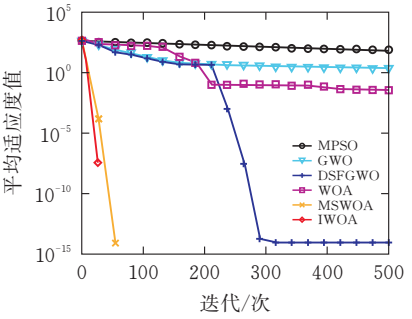
（c）函数 f_3 的测试平均收敛曲线



（d）函数 f_4 的测试平均收敛曲线



（e）函数 f_7 的测试平均收敛曲线



（f）函数 f_9 的测试平均收敛曲线

图 6　测试函数平均收敛曲线

由图 6 可见，IWOA 在收敛速度、精度及鲁棒性方面优于其他改进算法，尤其是在处理多峰函数优化问题时具有更强的全局寻优能力。IWOA 算法中的三阶段改进策略相辅相成，使得算法性能显著提升。

1.5　IWOA-LMBP 算法步骤

IWOA-LMBP 模型的核心思路为：将 IWOA 算法的优化目标（初始鲸鱼位置）设定为神经网络的初始权阈值组合，在 IWOA 算法的寻优过程中，仅

以适应度函数来指引鲸鱼行进的方向。本文采用鲸鱼与猎物之间的距离——均方误差(MSE)作为IWOA算法的适应度函数,以此指导算法寻找最优解:

$$\text{fitness}(w,b)=M_{\text{SE}}(y_k-t_k)=\frac{1}{N}\sum_{k=1}^{N1}(y_k-t_k)^2 \tag{22}$$

IWOA算法模拟鲸鱼不断调整自身位置以捕获猎物的行为,这一过程实质上对应调整 LMBP 神经网络的权阈值,旨在寻找并输出最优的预测性能。整个流程如图 7 所示,具体步骤如下。

Step1:初始化参数。设定种群规模 N,最大迭代次数 $t_{\max}$,根据式(13)、(14)计算收敛因子 a 和权重 λ。同时神经元结构 m-p-n 与权阈值 w,b 组合为初始位置 $x_{\text{ini}}=\{w_{11},w_{12},\cdots;w_{mp},b_{11},b_{12},\cdots b_{np}\}$,其维度 dim 如式(23)所示。同时根据式(22)计算初始适应度,令初始最优解 $x_{\text{best}}=x_{\text{ini}}$,最优适应度 $\text{fitness}_{\text{best}}=\text{fitness}(x_{\text{ini}})$。

$$\dim=(m+n+1)p+n \tag{23}$$

Step2:鲸鱼位置更新。比较 $|A|$ 的值,将随机数 p 与 0.5 作对比,若 $p<0.5$ 且 $|A|<1$,则按式(15)更新位置,若 $P<0.5$ 且 $|A|\geqslant 1$,则按式(16)随机搜索猎物,若 $P\geqslant 0.5$ 则按式(17)更新位置。根据以上情况更新鲸鱼位置 x_a,即调整 LMBP 权阈值,计算当前适应度 $\text{fitness}(x_a)$。

Step3:对于 Step2 中保存下的解,引入 x_{best} 通过式(20)进行趋优透镜反向学习,得到新解 x_b 与适应度 $\text{fitness}(x_b)$,若 $\text{fitness}(x_a)>\text{fitness}(x_b)$,则保留反向学习的更新结果,$x_{\text{best}}=x_b$,$\text{fitness}_{\text{best}}=\text{fitness}(x_b)$;若 $\text{fitness}(x_a)<\text{fitness}(x_b)$,则保留反向学习之前解的信息,$x_{\text{best}}=x_a$,$\text{fitness}_{\text{best}}=\text{fitness}(x_a)$。

Step4:判断迭代是否停止。判断当前适应度函数值是否达到设定精度($\text{fitness}_{\text{best}}<0.001$),或者是否达到最大迭代次数($t_{\max}$),如达到则进入步骤 5,否则,回到步骤 1 继续迭代。

Step5:全局最优解输出。当迭代停止时,所得 $\text{fitness}_{\text{best}}$ 即为 IWOA 算法训练所得的 LMBP 初始最优权阈值组合,将 $\text{fitness}_{\text{best}}$ 引入 LMBP 神经网络,计算误差直至达到模型训练精度,输出数值。

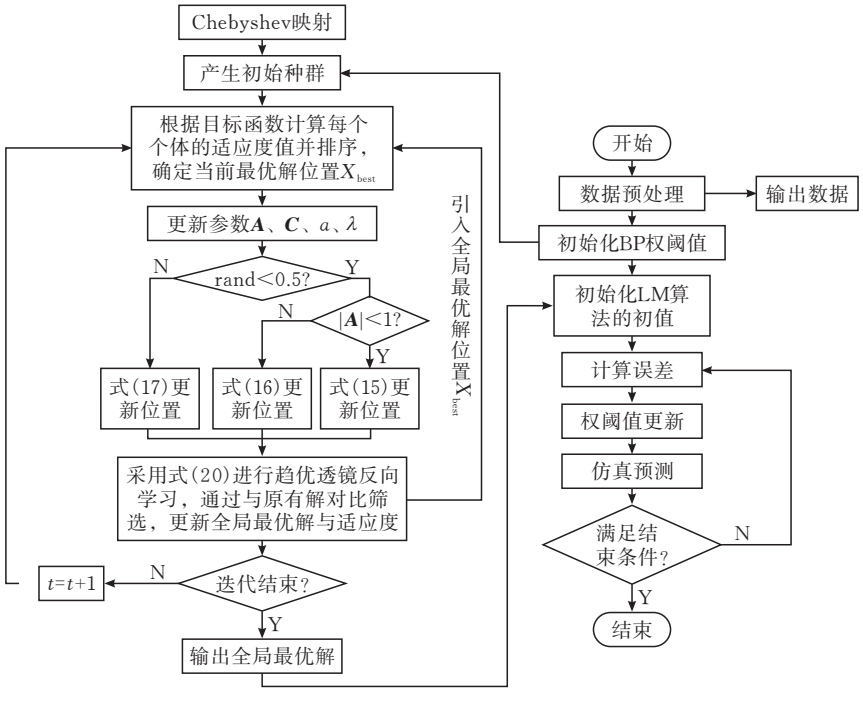


图 7　IWOA-LMBP 流程

2　试验与分析

2.1　数据处理

根据现场跟踪实验所收集到数据,将 23 台 Z 型插秧机的 81 个故障时间数据按照从小到大的顺序进行排列,即 $t_1\leqslant t_2\cdots\leqslant t_m\leqslant\cdots\leqslant t_N$,则其经验分布函数:

$$F_N(t)=\begin{cases}0, t<t_1\\ \dfrac{m-0.3}{N+0.4}, t_1\leqslant t\leqslant t_N\\ 1, t_N<t\end{cases} \tag{24}$$

式中:m 为故障顺序号;N 为故障时间总数,$N=117$。当 $t_1\leqslant t\leqslant t_N$ 时,式(24)为中位值公式,计算故障分布函数值,记为 $\hat{F}(t_m)$。

将现场所得的 81 条 Z 型插秧机故障数据分为 13 组。前 12 组为 6 条数据，第 13 组为 9 条数据。每组第 6 条作为测试数据，其余作为训练数据。为了消除数据间的偏差，利用式(25)对输入数据进行归一化处理。处理后的数据如表 5 所示。

$$\text{input}(x_m)=\frac{t_m-t_{\min}}{t_{\max}-t_{\min}} \tag{25}$$

表 5 水稻插秧机部分数据

样本 m	故障时间 t_i	不可靠度 $\hat{F}(t_m)$	网络输入 $\text{input}(x_m)$	可靠度 $\hat{R}(t_m)$
1	42.7	0.0086	0.0000	0.9914
2	58.9	0.0209	0.0463	0.9791
3	64.2	0.0332	0.0614	0.9668
⋮	⋮	⋮	⋮	⋮
38	170	0.4509	0.3648	0.5491
39	170.4	0.4631	0.3665	0.5369
40	171	0.4754	0.3693	0.5246
⋮	⋮	⋮	⋮	⋮
79	380	0.9668	0.9634	0.0332
80	384.1	0.9791	0.9751	0.0209
81	392.8	0.9914	1.0000	0.0086

2.2 BP 神经网络结构

BP 神经网络层数为三层：输入层、隐含层和输出层。其中，输入层为故障的时间，输出层为预测时间的可靠度。文献[18]表明隐含层节点数是影响神经网络精度的重要因素。因此，本文采用经验公式(26)结合网络性能函数 MSE 来确定隐藏层节点个数：

$$q=\sqrt{m+n}+a \tag{26}$$

本文输入层节点 $m=1$，输出层节点 $n=1$，a 为调节常数，取值为[1,2,…,10]。因此，据式(26)，q 的取值范围为 2～11。表 6 为不同隐含层节点数 MSE 的值。

表 6 不同隐含层节点数计算结果

隐含层节点数	网络性能函数 MSE
2	0.00162
3	0.00172
4	0.00126
5	0.00113
6	0.00069
7	0.00098
8	0.00097
9	0.00238
10	0.00074
11	0.00138

从表 6 可知，取隐含层节点数为 6 时，MSE 最小，为 0.000 69。因此本文最终确定的 BP 神经网络结构为“1-6-1”结构，即神经网络为 3 层，输入层节点为 1，隐含层节点为 6，输出层节点为 1。此外，神经网络的其他参数为：输入函数“tansig”，输出函数“purelin”，训练函数“trainlm”。最大训练次数为 1000，误差精度为 0.001，学习率为 0.01。

2.3 算法权阈值寻优

为了体现 IWOA 算法在 LMBP 权阈值寻优中的优势。采用寻优实验中较优的 MPSO、DSFGWO、WOA、MSWOA、IWOA 等 5 种算法对 LMBP 权阈值进行寻优，设定 $t_{\max}$ 为 100 次，种群规模 N 为 20。各算法参数仍如表 3 所示，图 8 为各适应度曲线对比。

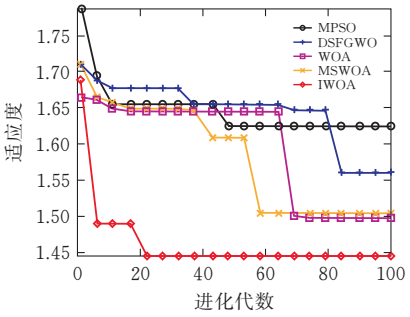


图 8 权阈值寻优适应度曲线对比

对比其他算法，IWOA 算法仅在 22 代就取得了最优适应度，为 1.44×10^{-4}，远优于次优算法的 1.49×10^{-4}。可知 IWOA 的改进策略有效提升了算法的寻优效率。

2.4 试验结果分析

将 IWOA 算法寻优的最优权阈值应用于 LMBP 神经网络中，以此为基础构建了水稻插秧机可靠性预测模型，并将此模型与 LMBP、MPSO-LMBP、WOA-LMBP、DSFGWO-LMBP、MWOA-LMBP 等 5 种预测模型进行对比，测试集 13 条数据的可靠性预测效果见图 9，预测值与真实值的绝对误差见图 10。

由图 9 和图 10 可知，IWOA-LMBP 模型的可靠度预测值与期望值的拟合精度最高，误差值波动幅度最小。为了更直观地展示模型间的精度差异，本文采用平均绝对误差 MAE、均方根误差 RMSE 和决定系数 R^2 作为模型评价标准。评价结果如表 7 所示。

由表 7 可见，IWOA-LMBP 模型可靠度预测结果最优，其数据拟合度达到了 99.871%，相对于 LMBP、MPSO-LMBP、DSFGWO-LMBP、WOA-LMBP、MSWOA-LMBP，MAE 分别降低了 2.063%、0.128%、0.156%、0.122% 和 0.067%，R^2 分别提高了 1.27%、0.049%、0.014%、0.034% 和 0.004%。综上结果表明：IWOA-LMBP 模型有着更

优的预测性能与精度，为用户及时、精准地了解水稻插秧机运行状况提供了有效的参考依据。

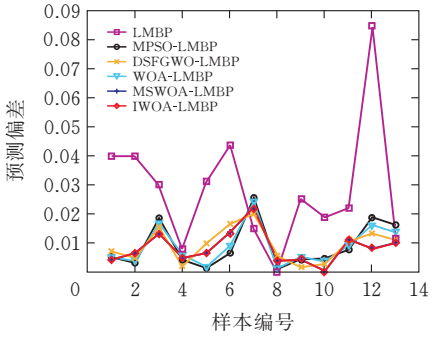


图 9　6 种模型的可靠度预测值

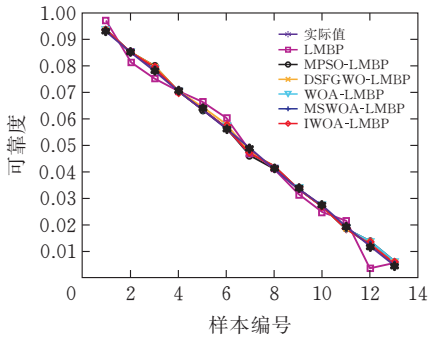


图 10　6 种预测模型的绝对误差值

表 7　模型性能对比

预测模型	MAE/%	RMSE/%	R^2 /%
LMBP	2.844	3.508	98.601
MPSO-LMBP	0.909	1.187	99.822
DSFGWO-LMBP	0.937	1.095	99.857
WOA-LMBP	0.903	1.124	99.837
MSWOA-LMBP	0.848	1.010	99.867
IWOA-LMBP	0.781	1.033	99.871

3　结束语

针对水稻插秧机可靠性评价存在明显滞后的问题，本文提出一种 IWOA-LMBP 神经网络可靠性预测模型。该模型通过采用 Chebyshev 映射来优化初始种群分布，确保其更加均匀。同时，引入“双扰动”型非线性自适应因子，这使得适应度在短时间内达到稳定状态。此外还引入了趋优透镜反向学习机制，有效避免了 WOA 算法陷入局部最优。通过 6 个基准函数的寻优对比，以及 Wilcoxon 秩和统计检验，表明 IWOA 在寻优性能上显著优于其他对比算法。随后，利用 IWOA 算法对 LMBP 神经网络的权阈值进行了优化，从而得到了更为精准的权阈值组合，提升模型的准确性与稳定性。将 IWOA-LMBP 模型应用于水稻插秧机可靠性预测的实践表明：相较于其他 5 种预测模型，IWOA-LMBP 模型展现出最优的预测精度，其拟合系数达到 0.9987 以上，且预测误差最小。此模型为实现水稻插秧机可靠性精准预测提供了新的方法和思路，也为水稻插秧机的使用及后续维修提供了重要参考依据。

[参 考 文 献]

[1] 胡启国，袁帅辉，王高爽.应用 BP 神经网络和均值一次二阶矩法的连杆频率可靠性分析[J].机械设计与制造，2021，363(05)：63-67.

[2] 郑倩，张宏，刘啸奔.基于 BP-MC 方法的断层区管道可靠性分析[J].油气储运，2020，39(03)：277-283.

[3] 张烨，黄伟.基于不同压气机特性曲线预测方法的燃气轮机建模研究[J].舰船科学技术，2023，45(01)：129-134.

[4] 胡泽文，金昕悦，崔静静.基于改进 BP 神经网络和函数拟合的细胞生物学领域“睡美人”识别与典型应用探测[J].情报学报，2023，42(06)：711-728.

[5] 王召广，杨宇飞，闫召洪，等.基于 ReliefF-LMBP 算法的涡轴发动机气路故障模式识别[J].推进技术，2021，42(01)：220-229.

[6] MIRJALILI S，LEWIS A.The whale optim-ization algorithm[J]. Advances in Engineering Software，2016，95：51-67.

[7] 陈志浩，王建华，龙拥兵，等.基于 Spark 的 WOA-BP 水稻产量预测[J].华南农业大学学报，2023，44(04)：613-618.

[8] 王燕华，吕静，吴京.基于遗忘因子和 LMBP 神经网络的混合试验在线模型更新方法[J].振动与冲击，2020，39(09)：42-48.

[9] 王海军，金涛，门克内木乐.FA-LMBP 混合神经网络算法在图像压缩中的应用[J].激光与光电子学进展，2019，56(19)：127-133.

[10] 岳龙飞，杨任农，张一杰. Tent 混沌和模拟退火改进的飞蛾扑火优化算法[J]. 哈尔滨工业大学学报，2019，51(05)：146-154.

[11] OUYANG C，ZHU D，QIU Y.Lens learning sparrow search algorithm[J].Mathematical Problems in Engineering，2021(2)：1-17.

[12] TIZHOOSH H R.Opposition-based learning：a new scheme for machine intelligence[J].IEEE，2005，1：695-701.

[13] LIU H，ZHANG X W，TU L P.A modified particle swarm optimization using adaptive strategy[J].Expert Systems with Application，2020(152)：1-18.

[14] MIRJALILI S，MIRJALILI S M，Lewis A D.Grey wolf optimizer[J]. Advances in Engineering Software，2014，69：46-61.

[15] 王正通，程凤芹，尤文，等.基于翻筋斗觅食策略的灰狼优化算法[J].计算机应用研究，2021，38(05)：1434-1437.

[16] YANG W, XIA K, FAN S, et al. A Multi-Strategy Whale Optimization Algorithm and Its Application[J]. Engineering Applications of Artificial Intelligence, 2022(108):108.

[17] 成守尧,陈占寿,娘毛措,等.一类长记忆时间序列趋势项变点的 Wilcoxon 秩检验[J].浙江大学学报(理学版),2022,49(04):427-434.

[18] ASTHANA S, PANDIT A, Bhardwaj a. analysis of multiple hidden layer vs. accuracy in performance using back propagation neural network[J]. Indian Journal of Science & Technology,2017,10(04):1-4.

Reliability Prediction of Rice Transplanter Based on IWOA-LMBP

WEN Changjun[1,2], CHEN Fan[1,2], KANG Suo[1,2], CHEN Yangyang[1,2]

(1 *School of Mechanical Engineering, Hubei Univ. of Tech., Wuhan* 430068, *China*;

2 *Hubei Key Laboratory of Modern Manufacturing Quality Engineering, Wuhan* 430068, *China*)

Abstract: Aiming at the problem that the reliability evaluation of Rice transplanter lags behind, an improved Whale Optimization Algorithm (IWOA)-Levenberg Marquard (LM) BP neural network reliability prediction model was established. First, the initial population diversity is enhanced through the Chebyshev chaotic strategy; Second, the "double ladder" and "double valley" nonlinear adaptive factors are used to achieve the global search and local exploration capabilities of the Dynamic equilibrium algorithm; Finally, combining the optimization lens reverse learning strategy to update individual positions, improve individual quality, and help the algorithm jump out of local optima. Through comparative analysis of six benchmark test functions and Wilcoxon rank sum statistical test, it can be concluded that IWOA has better optimization performance. Then, the IWOA-LMBP model is established based on the fault data of the Rice transplanter tracked on site. Selecting MAE and RMSE and R^2 as evaluation indicators for the network model, and comparing them with the other five models, the results show that the IWOA-LMBP model performs better in prediction. The model can provide a reference for the accurate prediction of Rice transplanter.

Keywords: rice transplanter; whale algorithm; optimal dimensional reverse learning; LMBP neural network; Reliability prediction

[责任编校:张 众]