基于 WOA-BP 神经网络的液滴铺展预测

伍星^{1a}, 陈小勇^{1,2}, 伍鹏飞^{1a}, 徐泽华^{1a}, 谢艳艳^{1a}

(1.桂林电子科技大学 a.机电工程学院 b.电子信息材料与器件教育部工程研究中心, 广西 桂林 541004; 2.广西制造系统与先进制造技术重点实验室,广西 桂林 541004)

摘要:目的 提高 BP 神经网络对电喷印过程中液滴铺展行为的预测能力。方法 提出一种鲸鱼优化算法 (WOA)优化 BP 神经网络的液滴铺展预测模型。首先,采用相场方法建立电场作用下液滴铺展的数值 模型,并通过实验验证仿真结果的准确性。然后,选取初始直径、撞击速度、接触角和电场强度作为神 经网络的输入参数,将最大铺展直径作为神经网络的输出参数,利用鲸鱼优化算法优化神经网络中的初 始权值和阈值,构建液滴铺展预测模型。最后,基于仿真结果对预测模型进行训练与测试,并将其与传 统的 BP 神经网络模型进行对比分析。结果 相较于传统 BP 神经网络预测模型,WOA-BP 神经网络预 测模型的平均绝对误差、均方根误差分别降低了 72.60%、77.60%,而平均绝对百分比误差则从 15.029 3% 减小为 4.585 3%。结论 WOA-BP 神经网络预测模型可以更好地预测液滴铺展,可为液滴铺展的预测提 供新的方法。

关键词: 液滴; 铺展; 鲸鱼优化算法; BP 神经网络; 预测 中图分类号: TP183; O35 文献标识码: A 文章编号: 1001-3563(2023)13-0181-07 DOI: 10.19554/j.cnki.1001-3563.2023.13.022

Droplet Spreading Prediction Based on WOA-BP Neural Network

WU Xing^{1a}, CHEN Xiao-yong^{1,2}, WU Peng-fei^{1a}, XU Ze-hua^{1a}, XIE Yan-yan^{1a}

(1. a. School of Mechatronics Engineering b. Engineering Research Center of Electronic Information Materials and Devices, Ministry of Education, Guilin University of Electronic Technology, Guangxi Guilin 541004, China;
 2. Guangxi Key Laboratory of Manufacturing System and Advanced Manufacturing Technology, Guangxi Guilin 541004, China)

ABSTRACT: The work aims to improve the prediction ability of BP neural network for droplet spreading behavior during electrojet printing. A whale optimization algorithm (WOA) was proposed to optimize the droplet spreading prediction model based on BP neural network. Firstly, the numerical model of droplet spreading under the action of electric field was established by the phase field method, and the accuracy of the simulation results was verified by experiments. Then, the initial diameter, impact velocity, contact angle and electric field strength were selected as input parameters for the neural network, the maximum spreading diameter was taken as the output parameter of the neural network, and the initial weights and thresholds in the neural network were optimized by the whale optimization algorithm to construct the droplet spreading prediction model. Finally, the prediction model was trained and tested based on the simulation results, and was compared and analyzed with the traditional BP neural network model. Compared with the traditional BP neural network

收稿日期: 2022-11-02

作者简介: 伍星 (1994—), 男, 硕士生, 主攻微纳电子制造工艺。

通信作者:陈小勇(1984-),男,博士,高级实验师,主要研究方向为微纳电子制造工艺及流动控制技术。

基金项目:广西自然科学基金(2022GXNSFAA035616);广西制造系统与先进制造技术重点实验室基金(2006540007Z); 电子信息材料与器件教育部工程研究中心(EIMD-AB202008)

prediction model, the mean absolute error and root mean square error of the WOA-BP neural network prediction model were reduced by 72.60% and 77.60% respectively, while the mean absolute percentage error was reduced from 15.029 3% to 4.585 3%. It is demonstrated that the WOA-BP neural network prediction model can better predict the droplet spreading and can provide a new method for the prediction of droplet spreading.

KEY WORDS: droplet; spreading; whale optimization algorithm; BP neural network; prediction

电喷印技术是一种基于电流体动力学原理的新 兴打印技术,其不仅能克服传统喷墨打印过程中容易 出现喷嘴堵塞的缺点,还具有成型精度高、选材广泛^[1] 等优点,因而被广泛应用于光学器件、柔性电子等领 域^[2-3]。电喷印的打印效果除了会受锥射流形态^[4]和喷 嘴结构^[5]影响外,还与液滴在基板上的铺展行为密切 相关。因此,为了提高打印精度,对液滴铺展行为进 行预测就显得尤为重要。由于实验条件的限制,现阶 段学者们主要通过理论分析、经验公式以及数值模拟 等方法对液滴铺展行为进行预测。

在理论分析方面, Lee 等^[6]改进了黏性耗散表达 式,并推导出了最大铺展因子的预测公式。春江等^[7] 考虑到辅助耗散和重力势能的影响,修正了最大铺展 直径的预测公式。在经验公式方面,李大树等^[8]基于 实验数据拟合得到了最大铺展系数与雷诺数之间的 表达式。郝晓莹^[9]运用最小二乘法得到了液滴撞击微柱 表面时最大铺展直径与韦伯数、粒径、接触角和微结构 高度之间的函数关系。在数值模拟方面,闫哲等^[10]通 过建立不同微结构下液滴铺展预测模型,发现液滴在 三角沟槽表面的最大铺展因子最小。梁超等[11]基于 VOF 方法研究发现最大铺展系数与壁面的接触角有 关。李培生等^[12]基于 LBM 方法模拟了液滴铺展行为, 研究发现高雷诺数下液滴更容易铺展。虽然上述方法 都取得了一定的成果,但也存在着各自的不足。其中 理论分析方法推导出的预测公式存在特定的适用范 围,经验公式计算的结果往往与实验结果之间存在较 大误差, 而数值模拟方法虽然能得到较为精准的结 果,但计算复杂且容易出现重复性建模的情况,需要 耗费大量时间。

随着机器学习技术的发展,为解决液滴铺展这类 受众多因素影响且内在关系复杂的非线性预测问题 提供了一种新的思路。李光远^[13]将 BP 神经网络用于 预测液滴铺展过程中的能量变化。针对传统 BP 神经 网络预测精度不高且收敛速度慢的问题,学者们采用 了智能优化算法优化 BP 神经网络中的初始权值和阈 值^[14-16]。虽然改进后的 BP 神经网络在部分领域得到 了应用,但将其用于电场作用下液滴铺展行为的预测 研究还未见报道。

综上所述,本文采用鲸鱼优化算法优化 BP 神经 网络,建立电场作用下液滴铺展预测模型,并通过实 例验证了模型的预测性能。

1 数值模型与模型验证

1.1 控制方程

本文基于 COMSOL Multiphysics 软件,采用相场 方法建立对应的数值模型。由于电场作用下液滴在铺 展过程中主要受到重力、电场力、黏性力和表面张力 的影响。因此,对应的 Navier-Stokes 方程和连续性 方程^[17]分别为:

$$\rho\left(\frac{\partial u}{\partial t} + u \cdot \nabla u\right) =$$

$$-\nabla P + \nabla \cdot \left[\mu\left(\nabla u + \nabla u^{\mathsf{T}}\right)\right] + \rho g + F_{\mathsf{st}} + F_{\mathsf{e}}$$

$$\nabla \cdot u = 0$$
(1)
(2)

式中: ρ 为液滴密度;u为液滴速度矢量; μ 为液滴黏度; F_{st} 为单位体积界面张力矢量; F_{e} 为电场力矢量。

在相场中, Cahn-Hilliard 方程可以表示为:

$$\frac{\partial \phi}{\partial t} + \boldsymbol{u} \cdot \nabla \phi = \nabla \cdot \frac{3\chi \sigma \varepsilon_{\rm pf}}{2\sqrt{2}} \nabla \psi$$
(3)

$$\Psi = -\nabla \cdot \varepsilon_{\rm pf}^{2} \nabla \phi + (\phi^{2} - 1) \phi \tag{4}$$

式中: ϕ 为相场变量; χ 为迁移率调节参数; ε_{pf} 为界面厚度控制参数。

液滴受到电场力可由麦克斯韦应力张量T表示为: $F_{a} = \nabla \cdot T$ (5)

由于流体不可压缩,故麦克斯韦应力张量 T 为:

$$\boldsymbol{T} = \boldsymbol{\varepsilon} \left(EE - \frac{|E|^2}{2} \boldsymbol{I} \right)$$
(6)

式中: E 为外加电场; e 为介电常数; I 为单位矩阵。

1.2 动态接触角模型

接触角作为表征基板润湿性的重要参数,对其设置不当将直接影响仿真结果的准确性。目前,接触角的设置方式主要分为静态接触角模型和动态接触角模型。其中静态接触角模型认为液滴运动过程中接触角始终是一个定值,该模型虽然设置简单,但模拟结果并不理想。动态接触角模型由于考虑了毛细数对接触角的影响,能更真实地模拟出液滴撞击基板的过程^[18-20]。本文选用 Kistler 动态接触角模型, 对应的动态接触角 θ_d可表示为:

$$\theta_{d} = f_{H} \left[C_{a} + f_{H}^{-1} \left(\theta_{e} \right) \right]$$

$$f_{H} = \arccos \left\{ 1 - 2 \tanh \left[5.16 \left(\frac{x}{1 + 1.31x^{0.99}} \right)^{0.706} \right] \right\}$$

$$(8)$$

$$C_{a} = \mu U_{1} / \sigma$$

$$(9)$$

式中: *C*_a为毛细数; *U*₁为接触线速度; σ为界面 张力系数。

1.3 模型验证

为了验证数值模型的可行性,在相同工况下:液 滴初始直径为3mm、电场强度为6.5kV/cm、撞击速 度为0.766m/s,与文献[21]的实验结果进行对比。由 图1可知,该模型能较好地模拟不同时刻液滴铺展的 形态演化过程且仿真得到的铺展因子与实验值之间 误差较小。说明该模型用于研究电场作用下液滴铺展 行为是可行的,可以为后续WOA-BP神经网络模型 的训练与效果验证提供样本数据。



图 1 电场作用下液滴铺展行为实验与仿真对比 Fig.1 Comparison between experiment and simulation of droplet spreading behavior under electric field

2 构建 WOA-BP 神经网络预测模型

2.1 BP 神经网络

BP 神经网络是一种以信息前向传递,误差反向 传播为主要特点的多层前馈神经网络。其网络结构包 括输入层、隐含层和输出层^[22]。在信息前向传递过程 中,输入信号依次通过输入层、隐含层,最终到达输 出层。当输出结果与期望结果之间的误差不满足预设 的学习精度时,不断更新网络中不同层与层之间的连 接权值以及隐含层、输出层的阈值的过程,称为误差 的反向传播。

BP 神经网络模型的预测精度除了受权值和阈值

的影响外,还受到网络中隐含层节点数的制约^[23]。如 果隐含层节点数过少,会造成 BP 神经网络的预测精 度偏低,但是隐含层节点数过多,又容易出现过拟合 现象。通常隐含层节点数的确定方法如下:先根据经 验公式^[24]得到隐含层节点数的取值范围,再分别计算 不同隐含层节点数下的训练集均方误差,将训练集均 方误差最小时所对应的隐含层节点数确定为最佳隐 含层节点数。具体公式见式(10)。

 $p = \sqrt{m+n} + q \tag{10}$

式中: *m* 为输入层节点数; *n* 为输出层节点数; *q* 为[1,10]之间的任意整数; *p* 为隐含层节点数。

2.2 鲸鱼优化算法

鲸鱼优化算法(Whale Optimization Algorithm, WOA)是一种通过模拟座头鲸的狩猎行为而衍生出 的智能优化算法^[25]。在狩猎过程中,座头鲸会成群包 围猎物,随后在螺旋向上运动的同时,吐出大量气泡 形成气泡网将猎物包围并驱赶至气泡网中心,最后吞 食猎物。座头鲸狩猎行为如图 2 所示。



图 2 座头鲸的狩猎行为^[25] Fig.2 Hunting behavior of humpback whales^[25]

WOA 算法的核心就是用数学模型描述座头鲸包 围猎物、气泡网攻击和搜索猎物这 3 种行为。

1)包围猎物。在包围猎物阶段,先将最靠近猎物的鲸鱼定义为最佳鲸鱼,然后其他鲸鱼根据最佳鲸 鱼的位置更新自身的位置,从而实现对猎物的包围。 此过程对应的数学公式见式(11)。

$$x(\lambda+1) = x'(\lambda) - A \cdot |2r_2 \cdot x'(\lambda) - x(\lambda)|$$
(11)

$$4 = 2ar_1 - a \tag{12}$$

式中: λ 为迭代次数; $x'(\lambda)$ 为最佳鲸鱼的位置; $x(\lambda)$ 为当前鲸鱼的位置;A为系数变量;a为收敛因 子,且会随着 λ 的增大,逐渐从2线性递减为0; r_1 、 r_2 为[0,1]之间的随机数。

2) 气泡网攻击。进入气泡网攻击阶段后, 座头 鲸不仅会进一步收缩包围圈, 还会螺旋上升游向猎 物。假设选择这 2 种行为的概率是相同的, 根据式 (13) 计算出更新后鲸鱼的位置。

$$x(\lambda+1) = \begin{cases} x'(\lambda) - A \cdot \left| 2r_2 \cdot x'(\lambda) - x(\lambda) \right| & P < 0.5 \\ x'(\lambda) + \left| x'(\lambda) - x(\lambda) \right| \cdot e^{bl} \cdot \cos(2\pi l) & P \ge 0.5 \end{cases}$$
(13)

式中: *b* 为对数螺旋形状常量; *l* 为[-1,1]之间的随机数。

3)搜索猎物。在搜索猎物阶段,鲸鱼会随机从 种群中选择一条鲸鱼靠近,以此提高鲸鱼群体的全局 搜索能力。此过程对应的数学公式见式(14)。

 $x(\lambda+1) = x_{rand}(\lambda) - A \cdot |2r_2 \cdot x_{rand}(\lambda) - x(\lambda)|$ (14) 式中: $x_{rand}(\lambda)$ 为随机选择要靠近的鲸鱼位置。

2.3 WOA-BP 神经网络模型

由于传统 BP 神经网络中的初始权值和阈值具有随机性,使得算法容易收敛于局部最优点,从而影响最终的预测效果^[26]。为解决上述问题,本文利用 WOA 算法对 BP 神经网络进行改进。具体流程如下。

1)采集数值模型得到的数据,划分数据集,并 进行归一化处理。

2) BP 神经网络初始化,设置训练次数、学习速 率和学习精度,并确定神经网络结构。

3)初始化 WOA 参数,将训练样本与测试样本 的均方误差作为适应度函数。

4) 计算鲸鱼的适应度值,记录最佳个体位置。

5) 更新参数 *a*、*A*、*P*、*l*。

6)判断 P 值与 0.5 以及 |A| 值与 1 之间的大小关系,选择不同方式更新鲸鱼位置。

7)判断是否满足终止条件。若达到最大迭代次数,则输出最优的初始权值和阈值。否则重复执行步骤(4)—(7)。

8)将最优的初始权值和阈值带回神经网络。

9) 计算 BP 神经网络的输出误差。

10)判断是否满足终止条件。若输出误差达到预 设的学习精度或最大训练次数,经反归一化处理后, 即可输出预测结果。否则先更新权值和阈值,然后重 复执行步骤(9)—(10)。

WOA 算法改进 BP 神经网络的流程如图 3 所示。

3 实例分析

3.1 数据获取与归一化处理

采用上文所建立的数值模型获取初始直径 R(2, 2.5, 3 mm)、撞击速度 v(0.5, 0.6, 0.7 m/s)、接触 角 $\theta_{c}(67^{\circ}, 155^{\circ})$ 和电场强度 E(4.5, 5.5, 6.5 kV/cm)不同组合条件下的最大铺展直径,共计 30 组样本数 据。从中随机选择 21 组数据作为训练样本,剩余 9 组数据作为测试样本。

为了消除量纲对预测精度的影响,采用最大最小 法对原始数据进行归一化处理。根据式(15)确定归





一化后的输入值 $X_{i,j}^*$ 。

$$X_{i,j}^{*} = \frac{X_{i,j} - X_{i,\min}}{X_{i,\max} - X_{i,\min}}$$
(15)

式中: *X_{i,j}*为第 *i* 个因素中第 *j* 组的输入值; *X_{i,min}*为第 *i* 个因素所对应的输入序列中的最小值; *X_{i,max}*为第 *i* 个因素所对应的输入序列中的最大值。

对原始输出数据也进行类似处理:

$$Y_j^* = \frac{Y_j - Y_{\min}}{Y_{\max} - Y_{\min}}$$
(16)

式中: Y_j 为第 j 组原始输出值; Y_{min} 为输出序列 中的最小值; Y_{max} 为输出序列中的最大值; Y_j^* 为第 j组归一化处理后的输出值。

3.2 神经网络结构的确定

由前文可知, BP 神经网络的输入层参数为 4, BP 神经网络的输出层参数为 1。综合考虑训练时间 和网络精度后,选择单隐含层结构。由式(10)计 算得到隐含层节点数的取值范围为[3,12]。在 BP 神 经网络中设置训练次数为 1 000,学习速率为 0.01, 学习精度为 0.000 001,使用 Matlab 软件进行仿真, 得到不同隐含层节点数对应的训练集均方误差如图 4 所示。从图 4 中可以看出,当隐含层节点数为 8 时,对应的训练集均方误差最小。故最佳隐含层节 点数为 8。



图 5 BP 神经网络结构 Fig.5 BP neural network structure

3.3 预测结果与评价

在 WOA 算法中,将种群规模设置为 30,迭代次数设置为 50,建立液滴铺展预测模型。将样本数据导入模型,得到的适应度值变化曲线如图 6 所示。由图 6 可知,在迭代次数增大初期,适应度值逐渐减小。经过大约 14 次迭代后,适应度值不再变化。

真实值与不同模型得到的预测值对比如图 7 所示。从图 7 可以看出,在绝大多数测试样本中,使用 WOA-BP 模型得到的预测结果更接近真实值。

为了能更客观地比较 BP 神经网络预测模型和 WOA-BP 预测模型对液滴铺展的预测效果,选取平均绝对误差(E_{MAE})、均方根误差(E_{RMSE})和平均绝对百分比误差(E_{MAPE})等指标对模型的预测性能进行评价,各评指标的计算式见式(17)-(19)。各评价指标的计算结果如表 1 所示。



different models

$$E_{\text{MAE}} = \frac{1}{N} \sum_{k=1}^{N} \left| y_k - y'_k \right|$$
(17)

$$E_{\rm RMSE} = \sqrt{\frac{1}{N} \sum_{k=1}^{N} (y_k - y'_k)^2}$$
(18)

$$E_{\text{MAPE}} = \frac{1}{N} \sum_{k=1}^{N} \left| \frac{y'_{k} - y_{k}}{y_{k}} \right| \times 100\%$$
(19)

式中: y_k 为测试样本的真实值; y'_k 为经过反归 一化处理后得到的预测值; N 为测试样本个数。

表 1 优化前后模型的预测效果评价 Tab.1 Evaluation of the prediction effect of the model before and after optimization

模型	E _{MAE} 值/mm	E _{RMSE} 值/mm	E _{MAPE} 值/%
BP	0.691 2	0.947 7	15.029 3
WOA-BP	0.189 4	0.212 3	4.585 3

由表1可知,与传统 BP 神经网络预测模型相比, WOA-BP 预测模型的平均绝对误差减小了 72.60%, 均方根误差减小了 77.60%,平均绝对百分比误差也 从15.029 3%减小为了 4.585 3%。由此可见,将鲸鱼 优化算法与 BP 神经网络相结合后,能显著提高模型 对液滴铺展的预测能力,有助于研究液滴铺展的内在 机理。通过控制液滴在基板上的铺展行为,可以对打 印图案的几何形貌和位置精度进行调控,从而实现柔 性电子、光学器件的高精度打印。

4 结语

本文将鲸鱼优化算法与 BP 神经网络相结合,建 立了电场作用下液滴铺展预测模型。相较于传统 BP 神经网络预测模型,WOA-BP 神经网络预测模型的 平均绝对误差、均方根误差以及平均绝对百分比误差 都大幅减小。证明了引入鲸鱼优化算法可以避免 BP 神经网络算法因陷入局部最优点而出现预测精度偏 低的情况。运用该模型可以对液滴铺展行为进行快速 精准地预测,有助于研究液滴铺展的内在机理,可为 提高电喷印的打印效果提供理论基础。

参考文献:

- QU Xiao-li, XIA Peng, HE Jian-kang, et al. Microscale Electrohydrodynamic Printing of Biomimetic PCL/nHA Composite Scaffolds for Bone Tissue Engineering[J]. Materials Letters, 2016(185): 554-557.
- [2] AN H S, PARK Y G, KIM K, et al. High-Resolution 3D Printing of Freeform, Transparent Displays in Ambient Air[J]. Advanced Science, 2019, 6(23): 1901603.
- [3] IM H G, AN B W, JIN J, et al. A High-Performance, Flexible and Robust Metal Nanotrough-Embedded Transparent Conducting Film for Wearable Touch Screen Panels[J]. Nanoscale, 2016, 8(7): 3916-3922.
- [4] 王莎莎, 唐正宁, 缪斌鹰, 等. EHD 喷印技术相关参数数值分析[J]. 包装工程, 2015, 36(7): 145-148.
 WANG Sha-sha, TANG Zheng-ning, MIAO Bin-ying, et al. Numerical Analysis of the Relevant Parameters in EHD Micro-Jet Printing[J]. Packaging Engineering, 2015, 36(7): 145-148.
- [5] ZHANG Lei. Characteristics of Drop-on-Demand Droplet Jetting with Effect of Altered Geometry of Printhead Nozzle[J]. Sensors and Actuators A: Physical, 2019, 298: 111591.
- [6] LEE J B, DEROME D, GUYER R, et al. Modeling the Maximum Spreading of Liquid Droplets Impacting Wetting and Nonwetting Surfaces[J]. Langmuir: the ACS

Journal of Surfaces and Colloids, 2016, 32(5): 1299-1308.

- [7] 春江,王瑾萱,徐晨,等. 液滴撞击超亲水表面的最大 铺展直径预测模型[J]. 物理学报, 2021, 70(10):248-258.
 CHUN Jiang, WANG Jin-xuan, XU Chen, et al. Theoretical Model of Maximum Spreading Diameter on Superhydrophilic Surfaces[J]. Acta Physica Sinica, 2021, 70(10): 248-258.
- [8] 李大树, 仇性启, 于磊, 等. 液滴碰撞水平壁面实验研究[J]. 实验技术与管理, 2015, 32(4): 66-71.
 LI Da-shu, QIU Xing-qi, YU Lei, et al. Research on Experiments of Droplet Impacting on a Flat Surface[J].
 Experimental Technology and Management, 2015, 32(4): 66-71.
- [9] 郝晓莹. 液滴撞击微结构表面的数值研究[D]. 哈尔 滨: 哈尔滨工程大学, 2021.
 HAO Xiao-ying. Numerical Study of Droplet Impact on Microstructured Surfaces[D]. Harbin: Harbin Engineering University, 2021.
- [10] 闫哲,李艳,李川,等. 液滴撞击不同固体表面的数 值模拟研究[J]. 热科学与技术, 2018, 17(1): 8-14.
 YAN Zhe, LI Yan, LI Chuan, et al. Numerical Simulation Study of Droplet Impact on Various Solid Surface[J]. Journal of Thermal Science and Technology, 2018, 17(1): 8-14.
- [11] 梁超, 王宏, 朱恂, 等. 液滴撞击不同浸润性壁面动态 过程的数值模拟[J]. 化工学报, 2013, 64(8): 2745-2751.
 LIANG Chao, WANG Hong, ZHU Xun, et al. Numerical Simulation of Droplet Impact on Surfaces with Different Wettability[J]. CIESC Journal, 2013, 64(8): 2745-2751.
- [12] 李培生,李志豪,黄逸宸,等. 基于 LBM 伪势模型下的三维大密度液滴撞击壁面数值研究[J]. 水动力学研究与进展(A 辑), 2020, 35(4): 532-540.
 LI Pei-sheng, LI Zhi-hao, HUANG Yi-chen, et al. Numerical Study of Three-Dimensional Large Density Ratio Droplet Impact Wall Surface Based on LBM Pseudopotential Model[J]. Chinese Journal of Hydrodynamics, 2020, 35(4): 532-540.
- [13] 李光远. 液滴撞击壁面铺展流动特性的数值模拟及预测研究[D]. 乌鲁木齐: 新疆大学, 2021.
 LI Guang-yuan. Numerical Simulation and Prediction of Flow Characteristics of Droplet Impacting on the Wall[D]. Urumqi: Xinjiang University, 2021.
- [14] CHENG Peng-peng, CHEN Dao-ling, WANG Jian-ping. Clustering of the Body Shape of the Adult Male by Using Principal Component Analysis and Genetic Algorithm-BP Neural Network[J]. Soft Computing, 2020, 24(17): 13219-13237.

- [15] HUANG Li-bin, JIANG Lin, ZHAO Li-ye, et al. Temperature Compensation Method Based on an Improved Firefly Algorithm Optimized Backpropagation Neural Network for Micromachined Silicon Resonant Accelerometers[J]. Micromachines, 2022, 13(7): 1054.
- [16] HUANG Yu-an, XIANG Yu-xing, ZHAO Rui-xiao, et al. Air Quality Prediction Using Improved PSO-BP Neural Network[J]. Ieee Access, 2020, 8: 99346-99353.
- [17] TIAN Ye, WANG Hong, ZHOU Xin, et al. A Combined Experimental and Numerical Study on Droplet-Impact Induced Breakup and Ejection Behaviors in Vertical Electric Field[J]. Chemical Engineering Science, 2021, 239: 116636.
- [18] BRACKE M, VOEGHT F D, JOOS P. The Kinetics of Wetting: the Dynamic Contact Angle[J]. Trends in Colloid and Interface Science III, 1989: 142-149.
- [19] KISTLER S F. Hydrodynamics of Wetting[J]. Wettability, 1993, 6: 311-430.
- [20] 周鑫, 马小晶, 胡丽娜, 等. 不同壁面条件下液滴撞 击铺展特性的模拟研究[J]. 计算力学学报, 2022, 39(6): 761-767.
 ZHOU Xin, MA Xiao-jing, HU Li-na, et al. Simulation

Study of Droplet Impact Spreading Characteristics under Different Wall Conditions[J]. Journal of Computational Mechanics, 2022, 39(6): 761-767.

[21] 李英杰. 电场下液滴撞击过冷壁面的数值模拟研究
[D]. 重庆: 重庆大学, 2021.
LI Ying-jie. Numerical Simulation Study on Droplet Impacting Supercooled Wall under Electric Field[D]. Chongqing: Chongqing University, 2021.

- [22] DING Shi-fei, SU Chun-yang, YU Jun-zhao. An Optimizing BP Neural Network Algorithm Based on Genetic Algorithm[J]. Artificial intelligence review, 2011, 36(2): 153-162.
- [23] 王毅红, 张建雄, 兰官奇, 等. 压制生土砖强度的人 工神经网络预测模型[J]. 华南理工大学学报(自然科 学版), 2020, 48(7): 115-121.
 WANG Yi-hong, ZHANG Jian-xiong, LAN Guan-qi, et al. Artificial Neural Network Prediction Model for Compressive Strength of Compacted Earth Blocks[J]. Journal of South China University of Technology (Natural Science Edition), 2020, 48(7): 115-121.
- [24] 曹杨, 王红红, 林超, 等. 海底管道清管器运行时间 预测[J]. 油气储运, 2022, 41(4): 451-457.
 CAO Yang, WANG Hong-hong, LIN Chao, et al. Prediction on Running Time of Pigs in Submarine Pipelines[J]. Oil & Gas Storage and Transportation, 2022, 41(4): 451-457.
- [25] MIRJALILI S, LEWIS A, et al. The Whale Optimization Algorithm[J]. Advances in engineering software, 2016, 95: 51-67.
- [26] 董江涛, 杜震宇. 基于 GA-BP 神经网络的土壤-空气 换热器换热量预测分析[J]. 可再生能源, 2021, 39(3): 307-314.

DONG Jiang-tao, DU Zhen-yu. Heat Exchange Quantity Prediction of Earth-Air Heat Exchanger Based on GA-BP Neural Network[J]. Renewable Energy Resources, 2021, 39(3): 307-314.

责任编辑:曾钰婵