

doi:10.11835/j.issn.1000-582X.2018.06.011

ACPSO-BP 神经网络在矿井突水水源判别中的应用

徐 星¹, 李垣志², 田坤云¹, 张瑞林¹

(1.河南工程学院 安全工程学院, 郑州 451191; 2.河南理工大学 安全科学与工程学院, 河南 焦作 454000)

摘要: 矿井多年来的连续开采使各含水层水质特征变得更加复杂、更为接近, 应用经典数学方法难以建立精确的判别模型, 使用具有非线性映射功能的 BP 神经网络可以克服以上问题, 但其仍然具有易陷入局部最优和收敛速度慢缺点。通过将“早熟”判断机制、Tent 混沌映射以及权重自适应调整策略引入粒子群算法中, 建立基于自适应混沌粒子群算法和 BP(ACPSO-BP)神经网络突水水源判别模型, 应用结果表明: 与 BP 神经网络模型、基于标准粒子群算法和 BP(SPSO-BP)神经网络模型相比, ACPSO-BP 神经网络模型具有收敛速度快、精度高和泛化能力强的特点。

关键词: 突水水源; BP 神经网络; SPSO 算法; 自适应变异; Tent 混沌映射

中图分类号: TD745

文献标志码: A

文章编号: 1000-582X(2018)06-091-11

Application of ACPSO-BP neural network in discriminating mine water inrush source

XU Xing¹, LI Yuanzhi², TIAN Kunyun¹, ZHANG Ruilin¹

(1. School of Safety Engineering, Henan University of Engineering, Zhengzhou 451191, P.R.China;

2. School of Safety Science and Engineering, Henan Polytechnic University,
Jiaozuo 454000, Henan, P.R.China)

Abstract: The continuous mining in the coal mine has made the water quality characteristics of each aquifer become more complex and more similar, and it is difficult to establish a precise discriminating model by using classical mathematical methods. The BP neural network with nonlinear mapping function can overcome the above problems, but it still has the disadvantage of being easy to fall into local optimization and having slow convergence speed. We introduced the “premature” judgment mechanism, Tent chaos map and adaptive weight adjusting strategy into particle swarm optimization algorithm, establishing a water inrush discrimination model on the basis of adaptive chaos particle swarm optimization algorithm and BP(ACPSO-BP) neural network. The application results show that compared with the BP neural network model and the model based on standard particle swarm algorithm and BP (SPSO-BP) neural network, the ACPSO-BP neural network model has faster convergence speed, higher accuracy and stronger generalization.

收稿日期: 2018-01-05

基金项目: 国家自然科学基金资助项目(51604091, 51474094); 河南省科技攻关计划项目(182102310743); 河南省高等学校重点科研项目(18A440010)。

Supported by the National Natural Science Foundation of China(51604091, 51474094), Henan Science and Technology Research Project (182102310743) and Key Scientific Research Projects of Colleges and Universities in Henan Province (18A440010)。

作者简介: 徐星(1979—), 男, 河南工程学院讲师, 博士研究生, 现从事矿山灾害防治及安全评价教学与科研工作, (E-mail) xxzhengjie2001@163.com。

Keywords: inrush water source; BP neural network; standard particle swarm optimization algorithm; adaptive mutation; Tent chaotic map

矿井突水是矿建与生产过程中最具威胁的自然灾害之一。一旦发生突水灾害事故,将会给矿井带来严重的经济损失和人员伤亡,因此,准确判别突水来源是防治水害的关键。由于地下水各含水层岩性组分各不相同,在经长期的水化学作用下,含水层之间的水化特征明显不同,因此,通过研究水化学特征判别突水水源具有快速、有效的特点^[1]。近年来,根据特征组分判断矿井突水来源得到了广泛的应用^[2-4]。学者们亦提出了众多的方法,其中,智能算法正备受广大研究者的青睐,如:人工神经网络(ANN)^[5-7]、遗传算法(GA)^[8-10]、粒子群算法(PSO)^[11-14]、果蝇算法(FOA)^[15]等智能算法。相比于 GA, PSO 具有结构简单,参数少,运行速度快的特点,能以较大的概率收敛到全局最优解。笔者考虑到由于 PSO 后期全局搜索能力的减弱,容易导致算法陷入局部最小,出现所谓的“早熟”收敛现象,同时,鉴于在煤矿水害防治领域及突水水源的判别中还未见过更多有关改进 PSO-BP 神经网络的相关参考文献,为此,笔者拟将“早熟”收敛现象判定机制、Tent 混沌映射机制以及惯性权重的自适应调整策略引入到标准粒子群算法中,对 BP 神经网络的权值和阈值进行初始优化,以期建立具有更强全局搜索能力和收敛速度的 ACPSO-BP 神经网络模型。从训练过程中的适应度方差收敛过程(主要包括收敛速度和收敛精度)以及测试输出精度上进行不同神经网络模型的对比,从而说明 ACPSO-BP 神经网络具有更高的准确性和泛化性。这对高效的判别矿井突水水源及推广其应用范围具有一定的借鉴意义。

1 标准粒子群算法(SPSO)

粒子群算法的发展始于 1995 年 Eberhart 和 Kennedy 提出的基本粒子群算法^[16]。该算法基于群体迭代,群体在解空间中追随个体最优位置(P_{best})和群体最优位置(G_{best})进行搜索,在此过程中,群体之间通过信息共享机制不断更新这两个位置,经反复迭代,最终获得全局最优解。由此可以看出该算法具有逻辑结构简单、易于实现、运算速度快等特点。

在粒子群算法中,每个个体称为一个“粒子”,代表着一个潜在的空间解,设 $\mathbf{z}_i = (z_{i1}, z_{i2}, \dots, z_{iD})$ 为第 i 个($i=1, 2, \dots, m$)粒子的 D 维位置矢量;根据目标函数设定的适应度函数,并计算 \mathbf{z}_i 对应的适应度 F ; $\mathbf{v}_i = (v_{i1}, v_{i2}, \dots, v_{id}, \dots, v_{iD})$ 为第 i 个粒子的飞行速度; $\mathbf{p}_i = (p_{i1}, p_{i2}, \dots, p_{id}, \dots, p_{iD})$ 为第 i 个粒子历史中所经历过的最优位置; $\mathbf{p}_g = (p_{g1}, p_{g2}, \dots, p_{gd}, \dots, p_{gD})$ 为整个粒子群历史中所经历过的最优位置。

粒子根据下面的公式更新速度与位置:

$$\mathbf{v}_{id}^{k+1} = \omega \mathbf{v}_{id}^k + c_1 r_1 (\mathbf{p}_{id} - \mathbf{z}_{id}^k) + c_2 r_2 (\mathbf{p}_{gd} - \mathbf{z}_{id}^k), \quad (1)$$

$$\mathbf{z}_{id}^{k+1} = \mathbf{z}_{id}^k + \mathbf{v}_{id}^{k+1}, \quad (2)$$

式中: $d=1, 2, \dots, D$, 为粒子中第 d 维变量; ω 为惯性权重; k 为迭代次数; $r_1, r_2 \in [0, 1]$ 为服从均匀分布的随机数; c_1, c_2 为学习因子。

惯性权重 ω 在基本粒子群算法中是一个固定值,而后经多次改进,提出了多种调整策略,如:线性衰减策略、指数衰减策略、Logistic Map 混沌映射策略等,而采用 ω 从 0.9 线性衰减至 0.4 已成为当前默认的标准粒子群算法。如式(3)所示。

$$\omega = \omega_{\max} - \frac{\omega_{\max} - \omega_{\min}}{I_{\max}} k, \quad (3)$$

式中: ω_{\max} 和 ω_{\min} 分别为初始权重、最终权重; k 为当前迭代次数, I_{\max} 为最大迭代次数。

从式(3)可以看出,在算法前期, ω 较大,表明粒子群处于全局搜索状态,随着迭代次数的增加,逐步转为局部搜索状态,这使得粒子群算法的性能在原有基础上有了很大的提高。

r_1, r_2 保证了初始种群的多样性; c_1, c_2 大小决定了粒子飞向目标的步长,过大的步长可能错过最优位置,过小有可能陷入局部最小或延长收敛时间。通常取 1.49 或 2.0;为保证粒子位置和速度的有效性,需要控制粒子飞行的速度和范围,即:

$$v_{\min} \leqslant v_{id} \leqslant v_{\max}, \quad (4)$$

$$z_{\min} \leq z_{id} \leq z_{\max}, \quad (5)$$

式中: v_{\max} 、 v_{\min} 为速度上下限, z_{\max} 、 z_{\min} 为位置上下限。

2 早熟判定机制

粒子群算法在执行过程中, 整个种群会追随当前最优粒子, 并同时搜索所经位置。如果全局最优位置在当前种群中或种群附近, 那么粒子在聚集时极有可能搜索到这个全局最优位置; 如果全局最优位置不在或距当前种群较远时, 由于算法后期粒子已转入局部搜索阶段, 粒子失去了原有“活力”(全局搜索能力), 无法跳出当前最优位置而去寻找更优位置, 从而导致算法出现所谓的“早熟”收敛现象。

为解决该问题, 首先对“早熟”收敛这一现象进行判定, 为此拟引入适应度方差判定策略。为使算法更具合理性, 在此基础上附加一条规则, 即如果最优位置和最优适应度在 10 次连续迭代中在一定阈值内发生变化时, 则认定当前种群已经陷入了局部最小, 出现了“早熟”收敛现象, 因而采用种群适应度的整体变化来判断种群所处的状态。

种群适应度方差 σ^2 定义为

$$\sigma^2 = \frac{1}{m} \sum_{i=1}^m \left(\frac{f_i - f_{\text{avg}}}{f} \right)^2, \quad (6)$$

式中: m 为种群的粒子总数, f 为归一化定标因子, 用以限制 σ^2 的大小, f_i 为种群第 i 个粒子适应度值, f_{avg} 为种群当前平均适应度值。

其中

$$f = \begin{cases} \max_{1 \leq i \leq m} |f_i - f_{\text{avg}}|, & \max_{1 \leq i \leq m} |f_i - f_{\text{avg}}| > 1, \\ 1, & \text{其他。} \end{cases} \quad (7)$$

由式(6)、(7)可以看出, 适应度方差越小, 表明种群聚集程度越大, 反之, 则聚集程度越小。在应用中需要设定一个阈值 φ , 当 $\sigma^2 < \varphi$ 时, 并满足附加规则时, 即判定为“早熟”收敛现象。

3 混沌映射原理

混沌现象是非线性系统普遍存在的现象, 它具有随机性、遍历性、规律性等特点, 将其应用于粒子群中, 一方面使粒子能够在解空间中随机而不重复的遍历到任意空间位置; 另一方面, 当粒子群陷入局部最小时, 通过混沌映射使其有机会跳出局部最小, 而去寻找全局最优, 从而解决了算法“早熟”收敛的问题^[17-19]。

最显著的混沌系统是由 Logistic 方程得出的, 使用 Logistic 方程对粒子群进行速度和位置的初始化, 改善了标准粒子群算法在迭代过程中容易出现的“早熟”收敛问题。笔者采用 Logistic 和 Tent 混沌映射对不同维数的测试函数进行测试, 发现针对高维多峰问题解, Tent 映射的遍历性明显优于 Logistic 映射, 其寻优结果更为稳定。考虑 BP 神经网络参数较多, 又属于多峰值问题, 故这里采用 Tent 映射关系, 其方程如式(8)所示。

$$x_{k+1} = G(x_k), \quad (8)$$

其中

$$G(x_k) = \begin{cases} \frac{x_k}{0.7}, & x_k < 0.7, \\ \frac{1}{0.3}x_k(1 - x_k), & \text{其他。} \end{cases} \quad (9)$$

令初值 $x_0 = 0.4$, 迭代 1 000 次可得 Tent 映射离散关系图, 如图 1 所示。

由图 1 可知, Tent 映射在 1 000 次迭代过程中, 其值在 $[0, 1]$ 范围内随机均匀分布且不出现重复现象, 这说明 Tent 混沌映射具有较强的随机性和遍历性。利用其映射特性能够使种群个体随机遍历到解空间任意位置, 不仅能够提高解

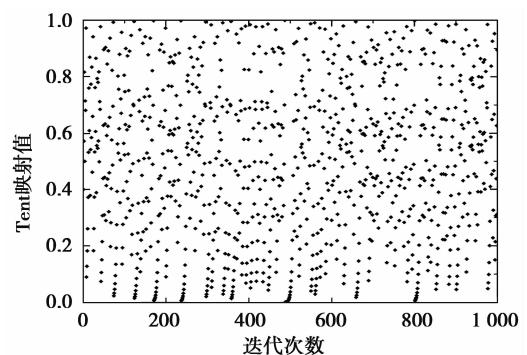


图 1 Tent 映射离散关系
Fig.1 Discrete relation of Tent map

的质量,而且为算法跳出局部位置提供了可能性。

初值取值范围为 $[0,1]$,步长为 0.01,每个初值迭代 100 次,可以得到 Tent 映射的初值敏感度关系图,如图 2 所示。

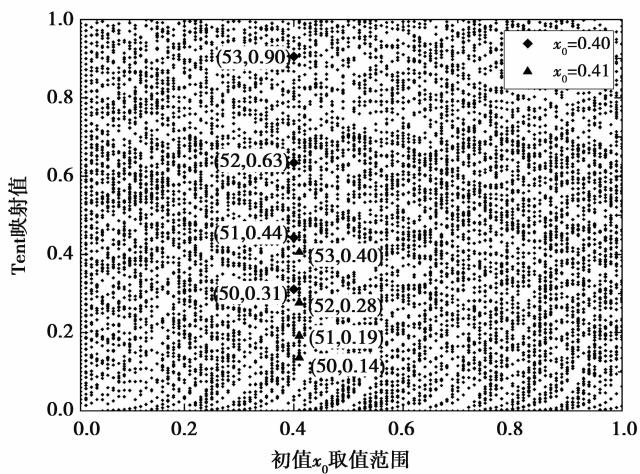


图 2 Tent 映射的初值敏感度

Fig.2 Initial sensitivity of Tent map

图 2 给出了 Tent 映射对初值敏感度的关系。以 $x_0=0.40$ 和 $x_0=0.41$ 为例,通过迭代计算可以得到两组混沌序列,如(50,0.31)表示第 50 次迭代得到的 Tent 映射值为 0.31,不难看出,当初值发生较小变化时,所生成的混沌序列表现出各自独立演化规律,表明了 Tent 映射对初值具有较强的敏感性;纵向对比可以看出同一初值的 Tent 映射值在 $[0,1]$ 之间分布非常均匀,这一特性再次保证了混沌粒子能够均匀遍历到任意解空间;横向对比可以看出,在不同初值的扰动下 Tent 映射值的离散度较高,使同一混沌粒子变量之间并没有表现出传统的“规律性”,而是出现了及其复杂的混沌现象,这一特性较自适应变异粒子群来说,一方面保证了单一变量独立演化的随机性;另一方面也使变量之间具有一定的配合关系,因而能够获得“优质”的混沌序列。

4 ACPSO 算法优化 BP 神经网络

自适应混沌粒子群算法(ACPSO)是为克服标准粒子群算法“早熟”收敛问题,而将早熟判断机制和混沌映射机制引入标准粒子群算法中,使其能够跳出局部最优并加快收敛速度的优化算法。笔者在种群初始化、随机数、“早熟”收敛时三个方面引入了 Tent 混沌映射机制,并将其与 BP 神经网络相结合,以期得到一个最优结构的突水水源判别模型。

ACPSO-BP 神经网络模型算法流程如下:

步骤 1 设定惯性权重 ω 、学习因子 c_1 和 c_2 、速度上下限 v_{\max} 和 v_{\min} 、位置上下限 z_{\min} 和 z_{\max} 、最大迭代次数 I_{\max} 、混沌搜索迭代次数 M 、阈值 φ 。

步骤 2 确定种群规模大小 m ,根据神经网络结构确定粒子维数 D ,利用 Tent 混沌映射初始化种群。

步骤 3 根据式(1)、式(2)更新粒子速度与位置。

步骤 4 根据式(10)计算粒子的适应度,据此更新个体最优值 p_i 和群体最优值 p_g 。

$$F = \frac{1}{4N} \sum_{j=1}^N \sum_{i=1}^n (y_{i,j} - Y_{i,j})^2, \quad (10)$$

式中: n 为网络输出节点个数; N 为网络训练样本数量; $y_{i,j}$ 和 $Y_{i,j}$ 分别为网络第 j 个样本的第 i 个节点的实际输出值、期望值。

步骤 5 根据式(6)、(7)计算粒子群的适应度方差 σ^2 ,并结合第二节内容判定是否出现“早熟”收敛现象,如果是,转入步骤 6,否则,转步骤 7。

步骤 6 混沌搜索。以当前群体最优位置 p_g 为初始值,产生 M 个混沌序列:

1)通过方程(11)将 p_g 映射到 $[0,1]$ 定义域上:

$$x_1^k = \frac{p_g - p_{\min}^k}{p_{\max}^k - p_{\min}^k}。 \quad (11)$$

2)根据式(8)、(9)将 x_1^k 进行 M 次迭代, 得到混沌序列
 $\mathbf{x}^k = (x_1^k, x_2^k, \dots, x_M^k)$ 。

3)根据式(12)将混沌序列逆映射回原解空间:

$$p_{g,m}^{*k} = p_{\min}^k + (p_{\max}^k - p_{\min}^k)x_m^k, m = 1, 2, \dots, M。 \quad (12)$$

进而产生混沌变量可行解序列: $\mathbf{p}_g^{*k} = (p_{g,1}^{*k}, p_{g,2}^{*k}, \dots, p_{g,M}^{*k})$ 。

4)计算混沌序列的适应度,并保留最优适应度的解,记作 p_g^{*k} 。

5)使用 p_g^{*k} 随机取代当前非最优位置。

步骤7 判断算法是否达到最大迭代次数,若满足转至步骤8,否则转至步骤3。

步骤8 将得到的最优解 p_g 赋值给 BP 神经网络。

ACPSO-BP 神经网络模型算法流程图,如图 3。

5 实例应用

5.1 数据预处理

以文献[20](实例 1)中的突水水源样本为例(水化数据详见文献[20]),将前 35 组水样作为判别模型的训练样本,将后 4 组水样作为待测样本,见表 1。为了更好地定量分析判别结果,对各含水层水源类型自上而下进行二进制编码:第四系含水层为(1 0 0 0)、顶板砂岩含水层为(0 1 0 0)、八灰含水层为(0 0 1 0)、二灰和奥陶纪含水层为(0 0 0 1)。

表 1 待测样本数据

Table 1 The test samples data

编 号	Na ⁺ + K ⁺ / (mg · L ⁻¹)	Ca ²⁺ / (mg · L ⁻¹)	Mg ²⁺ / (mg · L ⁻¹)	Cl ⁻ / (mg · L ⁻¹)	SO ₄ ²⁻ / (mg · L ⁻¹)	HCO ₃ ⁻ / (mg · L ⁻¹)	实际水源类型
I	23.76	66.4	19.59	18.13	57.26	255.29	0 0 0 1
II	9.97	64.45	26.84	9.59	40.53	288.14	0 0 1 0
III	294.75	8.93	3.63	30.27	24.24	680.51	0 1 0 0
IV	14.19	81.96	24.41	25.81	40.99	315.08	1 0 0 0

因不同样本所含离子浓度差异较大,为了建立统一的评判标准,需要将每组数据进行归一化处理,映射区间为 $[-1,1]$,见式(13)。

$$a_i = (z_{\max} - z_{\min}) \frac{b_i - b_{\min}}{b_{\max} - b_{\min}} + z_{\min}, \quad (13)$$

式中: a_i 为输出数据, b_{\min} 和 b_{\max} 分别为样本的最小值、最大值, b_i 为输入数据。

5.2 判别模型的设计

根据 6 个指标判别突水水源,则 BP 神经网络的输入层神经元数量为 6;经实践证明,具有一个中间层的 BP 神经网络能够以任意精度逼近任何连续函数。因此,这里选用具有一个单层结构的 BP 神经网络。根据经验公式确定中间层节点数,当神经元个数为 6 时,网络的收敛速度较快;输出层神经元个数由水源类型来确定,设为 4。训练函数、激励函数等网络参数设定见表 2。这里训练函数采用具有最快速算法的 trainlm 训练函数,不仅能够加快网络收敛速度,又能提高网络稳定性。

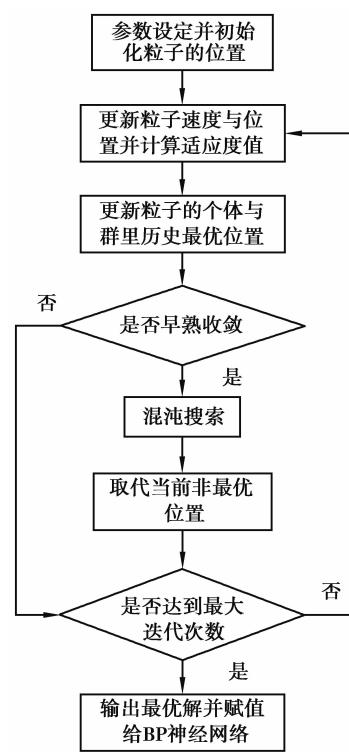


图 3 ACPSO-BP 神经网络模型算法流程

Fig.3 Algorithm flow chart of ACPSO-BP neural network model

表 2 网络参数设定
Table 2 The definition of network parameters

网络结构	中间层函数	输出层函数	训练函数	训练次数	误差	学习率
$6 \times 6 \times 4$	purelin	logsig	trainlm	1 000	E-5	0.04

SPSO、ACPSO 算法的参数设定见表 3, 其中 D 由 BP 网络的权值和阈值个数而确定, 即 $D = 6 \times 6 + 6 + 6 \times 4 + 4 = 70$ 。

表 3 算法参数设定
Table 3 Parameter definition of the algorithms

粒子群算法	D	粒子数量	I_{\max}	ω	$\frac{c_1}{c_2}$	r_1, r_2	M	v_{\max}	z_{\max}, z_{\min}	φ
SPSO	70	20	500	0.90~0.40 线性衰减	2	rand	无	1.90	$[-1, 1]$	无
ACPSO	70	20	500	0.90~0.40 线性衰减	2	Tent	20	1.90	$[-1, 1]$	2.25E-05

5.3 判别模型的训练

使用 Matlab 软件中的 newff() 函数建立 $6 \times 6 \times 4$ 的 BP 神经网络判别模型。同时, 结合表 3 的 ACPSO 参数设定、根据图 3 的算法流程进行 BP 神经网络的训练, 最终将 ACPSO 算法所得到的最优解作为 BP 神经网络训练的初始参数, 进而建立矿井突水水源的 ACPSO-BP 判别模型, 建立 SPSO-BP 判别模型则与之类似, 略。ACPSO 和 SPSO 算法在优化 BP 神经网络过程中的适应度进化曲线见图 4。

由图 4 可知, 二者的适应度值 f 均是减少趋势, 这表明两种优化算法在全局寻优过程中能够使各自判别模型中的 BP 神经网络逐渐达到其误差最小化, 达到算法优化目的。在对 BP 神经网络的优化效果上, 也可以看出 ACPSO 算法要明显优于 SPSO 算法, ACPSO 算法的第一条水平直线段, 即进化曲线在第 1 代至 5 代出现未进化过程, 其适应度值一直保持在 $6.15E-6$; SPSO 算法在第 2 代适应度值由 $6.45E-6$ 减少为 $2.78E-6$, 此次的适应度值减少量十分明显, 相比较前者的减少量要大的多, 紧接着出现该算法的第一条水平直线段, 即进化曲线的第 1 个未进化过程出现在第 3 代至 96 代, 在初始阶段, 相比较前者, 由于 SPSO 算法结构简单, 可调参数较少, 能够使进化曲线较快收敛。ACPSO 算法在第 6 代适应度值由 $6.15E-6$ 减少为 $3.92E-6$, 发生了较大进化的幅度, 紧接着出现第二条水平直线段, 即进化曲线的第 2 个未进化过程出现在第 7 代至 12 代, 其适应度值一直保持在 $3.92E-6$ 。在第 13 代适应度值由 $3.92E-6$ 减少为 $2.85E-6$, 出现其第三条水平直线段, 即进化曲线的第 3 个未进化过程出现在第 13 代至 19 代, 其适应度值一直保持在 $2.85E-6$ 。在第 20 代适应度值由 $2.85E-6$ 减少为 $1.81E-6$, 亦发生了明显的进化幅度, 紧接着出现其第四条水平直线段, 即进化曲线的第 4 个未进化过程出现在第 21 代至 63 代, 其适应度值一直保持在 $1.81E-6$ 。在第 64 代适应度值由 $1.81E-6$ 变为 $6.91E-7$, 适应度值进入 $1.00E-7$ 数量级, 紧接着出现其第五条水平直线段, 即进化曲线的第 5 个未进化过程出现在第 65 代至 91 代。而此时的 SPSO 算法适应度值仍然保持在 $2.77E-6$, 有 93 代的迭替寻优徒劳无获, 反映出此时所有的粒子聚集到相同位置并停止了移动, 拒绝搜索解空间的其他领域, 呈现出不易收

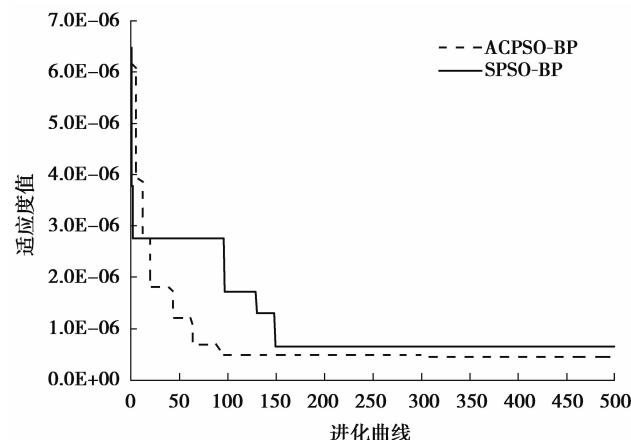


图 4 进化曲线对比
Fig.4 Evolution curve comparison

敛的状态。ACPSO 算法在第 92 代适应度值由 $6.91E-7$ 减少为 $4.91E-7$, 出现其第六条水平直线段, 即进化曲线的第 6 个未进化过程出现在第 93 代至 300 代。在第 301 代适应度值由 $4.91E-7$ 变为 $4.51E-7$, 进化幅度很小, 紧接着出现其第七条水平直线段, 即进化曲线的第 7 个未进化过程出现在第 302 代至 500 代。SPSO 算法在第 97 代适应度值由 $2.77E-6$ 减少为 $1.71E-6$, 紧接着出现其第二条直线段, 未进化阶段由 98 代保持到 129 代, 在第 130 代适应度值由 $1.71E-6$ 减少为 $1.30E-6$, 有了小幅度的减少, 并出现其第三条直线段, 未进化阶段由 131 代保持到 148 代, 在第 149 代适应度值由 $1.30E-6$ 减少 $6.47E-7$, 适应度值亦进入 $1.00E-7$ 数量级, 相比较 ACPSO 算法落后了 135 代, 从侧面反映出 SPSO 算法收敛速度慢的缺点, 紧接着出现其第四条直线段, 即第 4 个未进化阶段出现在第 150 代至 500 代。

在第 150 代之前, ACPSO 算法在优化 BP 神经网络的整个过程中, 进化曲线一共出现五次较大的水平直线段, 其所占据代数分别为 5 代、6 代、7 代、43 代、43 代、27 代, 而 SPSO 算法的优化进化曲线一共出现三次较大的直线段, 其所占据代数分别为 94 代、32 代、8 代。二者相比, 前者的直线段多与后者, 但后者具有最大的直线段, 这说明对前者对可能陷入局部最优的状态进行一定的混沌扰动, 从而引导粒子跳出局部最优—“早熟”, 也说明了后者在全局寻优过程中, 在局部最优上停留时间较长, 未能立即摆脱局部极值点的吸引。

ACPSO 算法在第 64 代, 其适应度值就进入了 $1.00E-7$ 数量级, 而 SPSO 算法在 149 代才进入该数量级; 前者在第 92 代其适应度值减少为 $4.91E-7$, 在第 301 代其适应度值进一步减少为 $4.51E-7$, 并在之后的 199 代停止进化, 而后者在 149 代其适应度值减少为 $6.47E-7$, 并在之后的 351 代停止进化。由此可以看出, 使 BP 神经网络收敛速度更快、收敛精度更高, ACPSO 算法要优于 SPSO 算法。ACPSO 算法能够有效克服 SPSO 算法容易陷入局部最优、收敛速度慢的缺点, 其全局搜索能力更强, 避免陷入“早熟”收敛, 因此, 其优化效果要优于 SPSO 算法。

5.4 判别模型的应用

将表 1 的 4 组待测样本分别带入所建立的 3 种矿井突水水源判别模型: ACPSO-BP 神经网络模型、SPSO-BP 神经网络模型和 BP 神经网络模型, 判别突水水源类型的结果见表 4。

表 4 三种模型判别结果
Table 4 The discriminating results of three models

待测样本	BP	SPSO-BP	ACPSO-BP	期望输出	是否正确
I	2.28E-05	1.60E-08	4.61E-08	0	是
	3.91E-13	2.74E-06	2.42E-14	0	
	6.40E-20	1.87E-10	1.83E-10	0	
	1.00E+00	1.00E+00	1.00E+00	1	
II	1.33E-08	3.34E-11	4.30E-11	0	是
	7.79E-09	6.39E-08	2.33E-09	0	
	1.00E+00	1.00E+00	1.00E+00	1	
	3.56E-14	8.43E-14	3.12E-16	0	
III	1.34E-27	7.73E-13	1.23E-07	0	是
	1.00E+00	1.00E+00	1.00E+00	1	
	2.23E-05	3.56E-09	1.95E-07	0	
	1.71E-05	1.47E-10	3.60E-16	0	
IV	1.00E+00	1.00E+00	1.00E+00	1	是
	2.67E-19	9.00E-10	4.02E-18	0	
	2.41E-09	1.62E-10	9.30E-09	0	
	6.04E-12	7.69E-08	1.21E-07	0	

由表 4 可以看出,针对 4 组待测样本的水源类型,ACPSO-BP 神经网络模型、SPSO-BP 神经网络模型和 BP 神经网络模型均做出了准确判别,为详细对比 ACPSO 和 SPSO 两种算法优化 BP 神经网络的效果,进而引入评价指标:误差二范数和误差平均值,通过对表 4 中二者的判别结果做误差分析,分析见表 5。

表 5 误差分析
Table 5 Error analysis

待测样本	模型	误差二范数	误差平均值
I	BP	3.15E-05	1.11E-05
	SPSO-BP	2.74E-06	7.14E-07
	ACPSO-BP	7.80E-08	2.73E-08
II	BP	1.54E-08	5.26E-09
	SPSO-BP	6.39E-08	1.60E-08
	ACPSO-BP	2.33E-09	5.92E-10
III	BP	2.82E-05	1.02E-05
	SPSO-BP	7.86E-06	1.97E-06
	ACPSO-BP	2.71E-07	1.15E-07
IV	BP	2.41E-09	6.03E-10
	SPSO-BP	7.69E-08	1.95E-08
	ACPSO-BP	1.22E-07	3.27E-08

待测样本总误差如表 6 所示。

表 6 待测样本总误差
Table 6 Total error of test samples

模型	适应度	总误差二范数	总方差
BP	4.93E-06	6.05E-05	4.46E-10
SPSO-BP	6.47E-07	8.37E-06	1.73E-11
ACPSO-BP	4.51E-07	4.91E-07	2.36E-14

从表 6 可以看出:在适应度值上、总误差二范数上以及总方差上的输出表现,ACPSO-BP 神经网络模型要优于 SPSO-BP 神经网络模型,SPSO-BP 神经网络模型要优于 BP 神经网络模型,而 BP 神经网络模型最差。

ACPSO-BP 神经网络模型、SPSO-BP 神经网络模型和 BP 神经网络模型分别对 4 组待测样本进行判别输出的误差对比如图 5 所示。

从图 5 的误差折线对比图中可以看出,在对第 II、IV 组样本判别时,三种神经网络模型差异较小,但在第 I、第 III 组样本判别时,三种神经网络模型差异明显。从整体来看,ACPSO-BP 神经网络模型误差折线最为平稳,而 BP 神经网络模型的误差波动最大,SPSO-BP 神经网络模型的误差波动则次之。

为进一步验证 ACPSO-BP 神经网络模型适用性和准确性,分别以文献[21](实例 2)和文献[22](实例 3)中所引用的工程实例和水化数据为依据,按照以上的分析流程分别建立 ACPSO-BP 神经网络模型、SPSO-BP 神经网络模型和 BP 神经网络模型并计算待测样本总误差以及绘制待测样本误差折线对比图。其中,样本的划分方法为:文献[21]表 1 为新庄孜矿井突水水源水化数据,共 33 组样本,随机选取第 6、17 和 29

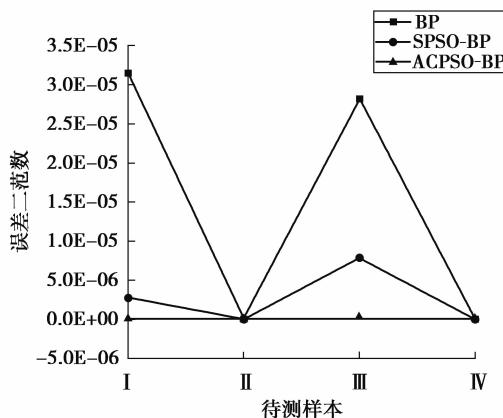


图 5 错误折线对比

Fig.5 Error line contrast

号样本作为待测样本,其余的 30 组样本作为训练样本。文献[22]表 1 为某矿井的水质数据,随机选取第 3、5 和 6 号样本作为待测样本,其余的 23 组样本作为训练样本。

则待测样本总误差分别如表 7 和表 8 所示。

表 7 待测样本总误差(实例 2)

Table 7 Total error of test samples (example 2)

模型	适应度	总误差二范数	总方差
BP	6.86E-06	2.90E-03	5.05E-07
SPSO-BP	8.64E-07	1.22E-03	1.17E-07
ACPSO-BP	2.68E-07	1.39E-04	8.17E-10

表 8 待测样本总误差(实例 3)

Table 8 Total error of test samples (example 3)

模型	适应度	总误差二范数	总方差
BP	7.50E-04	1.64E-03	9.66E-08
SPSO-BP	1.59E-06	2.58E-04	9.17E-10
ACPSO-BP	1.95E-08	5.73E-05	2.11E-10

综合实例 1、实例 2 和实例 3 可以得知,通过 ACPSO 算法优化过的 BP 神经网络能够对不同的水化数据样本判别具有更强的适用性和准确性,将所建立的 ACPSO-BP 神经网络模型应用于矿井突水水源的判别可以为推演地下水来源提供一种新方法。

由表 5 可以看出,实例 1 中 ACPSO-BP 神经网络模型在待测样本第 I、II 和 III 组上的判别输出,判别误差明显小于 BP、SPSO-BP 两种神经网络模型的判别误差,但在第 IV 组则不然。结合实例 2 和实例 3 的判别输出,可以得知在三组待测样本上,ACPSO-BP 神经网络模型判别误差均小于其他两种模型的判别误差。因此,实例 1 中的在第 IV 组样本上判别输出较差仅是个偶然。为了增强神经网络模型判别的精度和泛化性,达到突水水源的准确判别,应选取更多具有代表性的样本来建立数据库,以增强 ACPSO-BP 神经网络模型判别突水来源的适用性和准确性。

6 结 论

将早熟判断机制和 Tent 混沌映射引入到标准粒子群算法中,建立了自适应混沌粒子群优化算法,并用该算法对 BP 神经网络参数进行优化,从而建立了 ACPSO-BP 神经网络判别模型,进而将其应用于矿井突水水源的判别。

1)相比于 SPSO 算法,ACPSO 算法通过早熟判定机制,可以判断是否陷入“早熟”状态;因 Tent 混沌映射机制的引入,增强了其算法后期的全局搜索能力,并能以较快的速度收敛到全局最优位置,大大提高了算法的性能;使用线性递减策略进行惯性权重的自适应调整可以平衡算法在全局和局部搜索之间的搜索能力,使粒子能够跳出局部最优点并朝着全局最优的方向进化。

2)通过实例应用和测试结果可以得知:ACPSO-BP 神经网络模型无论是在适用性还是泛化性上均要优于 SPSO-BP 神经网络模型和 BP 神经网络模型,其具有更快的收敛速度和较高的判别精度,并具有较强鲁棒性。因此,将其应用于矿井突水水源的判别是可行、有效的,可以为开展矿井防治水工作提供有力的辅助决策依据。

参考文献:

- [1] 杨永国, 黄福臣. 非线性方法在矿井突水水源判别中的应用研究[J]. 中国矿业大学学报, 2007, 36(3):283-286.
YANG Yongguo, HUANG Fuchen. Water source determination of mine inflow based on nonlinear method[J]. Journal of China University of Mining and Technology, 2007, 36(3): 283-286. (in Chinese)
- [2] 朱玮, 邓红卫, 吴彦霖. 基于 Modpath 的矿井突水应用[J]. 重庆大学学报, 2015, 38(6):31-36.
ZHU Wei, DENG Hongwei, WU Yanlin. Research on mine water inrush based on Modpath[J]. Journal of Chongqing University, 2015, 38(6):31-36. (in Chinese)
- [3] 王心义, 赵伟, 刘小满, 等. 基于熵权-模糊可变集理论的煤矿井突水水源识别[J]. 煤炭学报, 2017, 42(9):2433-2439.
WANG Xinyi, ZHAO Wei, LIU Xiaoman, et al. Identification of water inrush source from coalfield based on entropy weight-fuzzy variable set theory[J]. Journal of China Coal Society, 2017, 42(9):2433-2439.(in Chinese)
- [4] 杨海军, 王广才. 煤矿突水水源判别与水量预测方法综述[J]. 煤田地质与勘探, 2012, 40(3):48-54.
YANG Haijun, WANG Guangcai. Summarization of methods of distinguishing sources and forecasting inflow of water inrush in coal mines[J]. Coal Geology & Exploration, 2012, 40(3):48-54.(in Chinese)
- [5] Kroese B, Smagt P V D. An introduction to neural networks [M]. Amsterdam, Netherlands: The University of Amsterdam, 1996.
- [6] Galushkin A I. Neural networks theory[M]. Fairmont, USA:Springer, 2007.
- [7] 徐星, 郭兵兵, 王公忠. 人工神经网络在矿井多水源识别中的应用[J]. 中国安全生产科学技术, 2016, 12(1): 181-185.
XU Xing, GUO Bingbing, WANG Gongzhong. Application of artificial neural network in recognition mine multiple water sources[J]. Journal of Safety Science and Technology, 2016, 12(1):181-185. (in Chinese)
- [8] Holland J H. Adaptation in natural and artificialsystems: An introductory analysis with applications to biology, control, and artificial intelligence[M]. 2nd ed. Cambridge:MIT Press, 1992.
- [9] Boris P L, Jessica S C. A deterministic annular crossover genetic algorithmoptimisation for the unit commitment problem[J]. Expert Systems with Applications, 2011,38(6):6523-6529.
- [10] 徐星, 田坤云, 郑吉玉. 基于遗传 BP 神经网络模型的矿井突水水源判别[J]. 工业安全与环保, 2017,43(11): 21-24.
XU Xing, TIAN Kunyun, ZHENG Jiyu. Discriminating mine water inrush source based on genetic BP neural network model[J]. Industrial Safety and Environmental Protection, 2017, 43(11):21-24.(in Chinese)
- [11] Parsopoulos K E, Vrahatis M N. Particle swarm optimization method for constrained optimization problems[C]// Proceedings of the Euro-International Symposium on Computational Intelligence 2002. [S.l.]: IOS Press, 2002.
- [12] Hsieh S T, Sun T Y, Liu CC, et al. Solving large scale global optimization using improved particle swarm optimizer[C]// 2008 IEEE Congress on Evolutionary Computation, June 1-6, 2008, Hongkong, China. [S. l.]: IEEE Press, 2008: 1777-1784.
- [13] Suran de Silva. Cisco 6500 FIB forwarding capacities [EB/OL]. [2017-12-08] <http://www.nanog.org/mtg-0702/presentations/fib-desilva.pdf>.

- [14] 徐星, 李垣志, 张文勇, 等. MPSO-BP 模型在矿井突水水源判别中的应用[J]. 自然灾害学报, 2017, 26(5):140-148.
XU Xing, LI Yuanzhi, ZHANG Wenyong, et al. Application of MPSO-BP model in discriminating mine water inrush source[J]. Journal of Natural Disasters, 2017, 26(5):140-148.(in Chinese)
- [15] Pan W T. A new Fruit Fly Optimization Algorithm: Taking the financial distress model as an example[J]. Knowledge-Based Systems, 2012, 26(2):69-74.
- [16] Kennedy J, Eberhart R. Particle swarm optimization[C/OL]// Proceedings of IEEE International Conference on Neural Networks, Nov 27-Dec 1, 1995, Perth, WA, Australia. [S. l.]: IEEE, 1995: 1942-1948. [2017-12-20]. paperuri: (f3814db83e1d2b7eae68a86d78db2241). DOI: 10.1109/ICNN.1995.488968.
- [17] Taylor D E, Turner J S. ClassBench: a packet classification benchmark[J]. IEEE/ACM Transactions on Networking, 2007, 15(3):499-511.
- [18] 杨琳. 基于自适应混沌粒子群算法的多目标无功优化研究[D]. 吉林:东北电力大学, 2011.
YANG Lin. Multi-objective reactive power optimization based on adaptive chaos particle swarm optimization algorithm[D]. Jilin: Northeast Dianli University, 2011.(in Chinese)
- [19] 胡方霞, 谢志江, 岳茂雄. 混沌粒子群优化模糊聚类的旋转机械故障诊断[J]. 重庆大学学报, 2011, 34(6):26-30.
HU Fangxia, XIE Zhijiang, YUE Maoxiong. Fault diagnosis of rotating machinery based on fuzzy clustering optimized by chaos embedded particle swarm optimization[J]. Journal of Chongqing University, 2011, 34(6):26-30.(in Chinese)
- [20] 张许良, 张子戌, 彭苏萍. 数量化理论在矿井突(涌)水水源判别中的应用[J]. 中国矿业大学学报, 2003, 32(3): 251-254.
ZHANG Xuliang, ZHANG Zixu, PENG Suping. Application of the second theory of quantification in identifying gushing water sources of coal mines[J]. Journal of China University of Mining & Technology, 2003, 32(3):251-254. (in Chinese)
- [21] 鲁金涛, 李夕兵, 宫凤强, 等. 基于主成分分析与 Fisher 判别分析法的矿井突水水源识别方法[J]. 中国安全科学学报, 2012, 22(07): 109-115.
LU Jintao, LI Xibing, GONG Fengqiang, et al. Recognizing of mine water inrush sources based on principal components analysis and fisher discrimination analysis method[J]. Journal of Safety Science and Technology, 2012, 22(07): 109-115.(in Chinese)
- [22] 聂凤琴, 许光泉, 关维娟, 等. 马氏距离判别模型在矿井突水水源判别中应用[J]. 地下水, 2013, 35(06): 41-42.
NIE Fengqin, XU Guangquan, GUAN Weijuan, et al. Application of Ma Distance discriminant model on water source identification of mine water inrush[J]. Ground Water, 2013, 35(06): 41-42.(in Chinese)

(编辑 郑洁)