

基于改进萤火虫算法的模糊 Petri 网学习能力研究

颜明

(中国传媒大学计算机与网络空间安全学院, 北京, 100024)

摘要: 模糊 Petri 网 (Fuzzy Petri net, FPN) 能够合理的描述现实世界中的不确定性和模糊性并能用于进行不确定知识的推理, 被广泛运用于专家系统的建模和推理中。与其它模糊系统建模工具类似, FPN 也具有自学习能力不强的固有缺陷。这个缺陷具体表现在三大参数值 (权值、阈值和确信度) 的确定上, 这些参数只能由特定领域的专家结合其经验给出, 无法通过机器学习等手段获得。因此如何提高 FPN 的学习能力来优化其初始的参数值是 FPN 研究领域的一个研究热点。本文通过对经典萤火虫算法的系统分析, 从求解的精度提升和收敛速度优化提出一种改进萤火虫算法, 并结合 FPN 的固有特点, 提出一种基于改进萤火虫算法的 FPN 学习能力训练策略。仿真实验表明, 针对同一个 FPN 模型, 经改进后的萤火虫算法训练出来的参数整体性能较其它两类对比算法的训练结果更佳, 泛化能力更强。

关键词: 模糊 Petri 网; 萤火虫算法; 参数优化;

中图分类号: TP301.6 **文献标识码:** A

Research on fuzzy Petri Net learning Ability based on improved Firefly Algorithm

YAN Ming

(Communication University of Chain, Beijing, 100026, China)

Abstract: Fuzzy Petri Net (FPN) can reasonably describe the uncertainty and fuzziness in the real world and can be used for the reasoning of uncertain knowledge, which is widely used in the modeling and reasoning of expert system. Similar to other fuzzy system modeling tools, FPN also has the inherent defect of weak self-learning ability. This defect is embodied in the determination of three parameter values (weight, threshold and degree of certainty), which can only be given by experts in a specific field combined with their experience and cannot be obtained by means of machine learning. Therefore, how to improve FPN's learning ability to optimize its initial parameter value is a research hotspot in the field of FPN. Based on the systematic analysis of the classical firefly algorithm, this paper proposes an improved firefly algorithm from the perspective of the improvement of solving accuracy and the optimization of convergence speed, and combines with the inherent characteristics of FPN, and proposes a FPN learning ability training strategy based on the improved firefly algorithm. The simulation results show that the overall performance of the parameters trained by the improved firefly algorithm for the same FPN model is better than the training results of the other two algorithms, and the generalization ability is stronger.

Key words: Petri Nets; Firefly Algorithm; Parameter Optimization;

1 引言

Petri网(Petri Net, PN)是1962年德国博士C.

A. Petri提出的一种用来模拟一些具有并行或并发事件的离散事件系统的数学模型, 近年来广泛的应用于计算机科学、自动化控制、通信等

作者简介: 颜明, 男 (汉族), 湖南湘潭人, 中国传媒大学研究生, yan-ming@cuc.edu.cn, 导师: 邬丽云。

领域的建模和性能分析过程中。但由于PN难以描述不确定、模糊的系统，学者们将Petri网和模糊数学相结合，扩充其模糊处理能力提出模糊Petri网（Fuzzy Petri Net, FPN^[1]）。FPN在具有PN的固有优点基础上，还能够精确描述模糊知识并兼有模糊系统的推理功能，能够促进知识分析、推理和决策，被广泛应用在知识库系统的建模和诊断过程中^[2]。但FPN的自适应能力较差，其权值、阈值、确信度往往依赖于人工的经验，从而影响推理结果的精度^[3]。国内外目前对于FPN参数优化研究大多建立在具体的适用范围的基础上，如Pedrycz与Gomide在文献^[4]中为提高FPN的调整（学习）能力，采用了一种广义模糊Petri网（Generalized Fuzzy Petri Net, GFPN），Li和Lara-Rosano等在文献^[5]提出的在严格条件下FPN的权值参数的学习，Yang等通过遗传算法与FPN结合，提升FPN的学习能力^[6]。在加权模糊Petri网上，文献^[7]通过蚁群算法进行优化FPN的参数，并将该思路运用与故障诊断推理过程中，取得了较好结果。LI等在基于FPN的矿用变压器故障诊断通过利用Elman网络算法的自适应能力对FPN的模型的初始参数进行优化^[8]。在这些优化的例子中，FPN的模型大都局限在某一特定的领域，并且在优化的结果上，这些算法大都存在精度不够，易陷入局部最优解，且易受初始参数的影响。本文拟在经典萤火虫算法（Firefly Algorithm, FA）的基础上，利用经典萤火虫算法的全局搜索能力，通过优化萤火虫算法的步长策略，改进移动策略，优化簇间关系，对于FPN的参数进行调整优化，提高FPN的自适应能力。

2 FPN的形式化定义

FPN多种形式的定义方式，但主要有库所、变迁、确信度、阈值、权值这几个部分构成，因此本文采用一种通用的八元组来定义FPN^[1]：

$$FPN = \{P, T, I, O, M, \tau, W, U\} \quad (1)$$

其中：

$P = \{p_1, p_2, \dots, p_n\}$ 为库所的集合；

$T = \{t_1, t_2, \dots, t_m\}$ 表示所有变迁集；

$I: P \times T \rightarrow \{0,1\}$ 是一个 $n \times m$ $n \times m$ 的输入矩阵，用于表示库所至变迁之间是否存在有向弧；

$O: P \times T \rightarrow \{0,1\}$ 是一个 $n \times m$ $n \times m$ 的输出矩阵，表示从变迁至库所是否存在有向弧；

$M = (m_1, m_2, \dots, m_n)^T$ 为标识向量，表示映射的完成度，初始值由 M_0 表示；

$\tau: T \rightarrow (0,1]$ 为各个变迁的阈值；

$W(i, j)$ 是规则的权值集合，表示从库所 p_i 到变迁 t_j 的支持度；

U 是确信度的集合， $U = \{U_1, U_2, \dots, U_m\}$ ，

其中 $U_i \in [0,1]$ 表示由变迁 t_i ($i = 1, 2, \dots, m$) 至库所 p_i ($i = 1, 2, \dots, n$) 的确信度。

在FPN中，若某库所结点只有连线指向变迁结点，而无变迁结点指向它时，称该库所结点为输入结点，反之称该库所结点为输出结点^[9]。

3 模糊 Petri 网的推理算法

一般而言，FPN模型运用于工程实践中，主要有两大步骤：根据特定的问题（或者说是特定问题的知识库）构建对应的FPN模型与根据得到的FPN模型构造相应的模糊推理算法，再将其运用于实际问题^[10]。

3.1 变迁点燃函数

为了将判断变迁是否使能的问题，建立一个变迁点燃函数。该函数的自变量满足一定要求并具有连续性，同时其模糊推理结果容易求导，建立的变迁点燃函数如下：

设 $y(x)$ 是一个 Sigmoid 型函数，其中 b 为满足要求的常量，则 $y(x)$ 的表达式为 $y(x) = 1/(1 + e^{-b(x-k)})$

3.2 变迁点燃连续函数

设 $x = \sum_{j=1}^n M(p_{ij}) \times w_{ij}$ ， $k = \tau(t)$ ，则，当 b 足够大时，由前面的分析可知：若 $x > k$ ，则 $y(x) \approx 1$ ，表示变迁 t 使能。反之，若 $x < k$ ， $y(x) \approx 0$ ，表示变迁 t 没有使能。因此通过连续函数 $y(x) \times u \times \sum_{j=1}^n M(p_{ij}) \times w_{ij}$ 来表示 t 是否被点燃，以及对获取库所输出的标记值。对于或规则，同样可以建立以下最大运算连续函数。

3.3 最大运算连续函数

根据前面的 $y(x)$ 函数，假设 x_1, x_2, x_3 为3个变迁使能时的输出，则当 b 足够大时，下列推导过程显然成立：

$$M_0 = \max(x_1, x_2) \approx \frac{x_1}{1 + e^{-b(x_1 - x_2)}} + \frac{x_2}{1 + e^{-b(x_2 - x_1)}} \quad (2)$$

$$M_1 = \max(x_1, x_2, x_3) = \max(M_0, x_3) \approx \frac{M_0}{1 + e^{-b(M_0 - x_3)}} + \frac{x_3}{1 + e^{-b(x_3 - M_0)}} \quad (3)$$

$$M_3 = \max(x_1, x_2, x_3, x_4) = \max(M_1, x_4) \approx \frac{M_1}{1 + e^{-b(M_1 - x_4)}} + \frac{x_4}{1 + e^{-b(x_4 - M_1)}} \quad (4)$$

根据以上规则，当多个变迁使能时，对应的输出库所 p 终可得到一个连续的最大函数值 M_p 。通过建立模糊推理函数，接下来便可以构建FPN模型从而进行相应推理。

3.4 模糊 Petri 网建模及推理

本文通过一个具体FPN模型来研究改进萤火虫算法对其参数的优化。

已知库所 $p_1, p_2, p_3, p_4, p_5, p_6, p_7, p_8$ 各自对应

着一个专家系统中的有关命题 $d_1, d_2, d_3, d_4, d_5, d_6, d_7, d_8$, 它们之间存在着如下的模糊产生式规则:

R1: IF d_1 THEN $d_2(u_2, \tau_2)$,

R2: IF d_1 or d_2 THEN $d_3(u_1, \tau_1, u_3, \tau_3)$,

R3: IF d_3 and d_4 and d_5 THEN

$d_6(w_1, w_2, w_3, u_4, \tau_4)$,

R4: IF d_6 and d_7 THEN $d_8(w_4, w_5, u_5, \tau_5)$.

按照上述模糊产生式规则，可建立以下 FPN 模型:

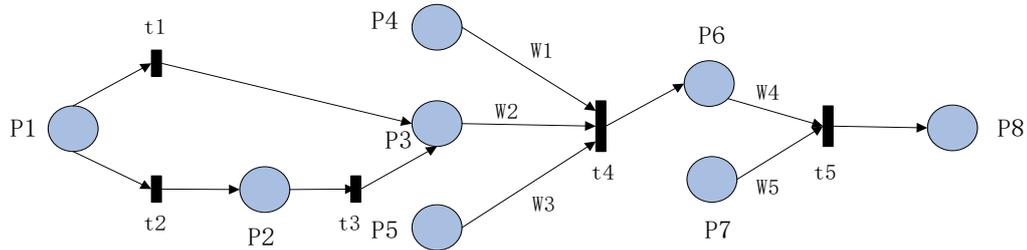


图1 FPN 模型实例

4 改进萤火虫算法

萤火虫算法作为一种基于群体的随机搜索算法，其算法过程简单，对初始参数依赖小的特点，被广泛应用于参数寻优中，但是算法的性能是以牺牲大量的时间来提升为代价的。因此，本文在已有萤火虫算法的基础上，提出一种基于分簇策略的振荡萤火虫改进算法 (Cluster-Based Oscillate Firefly Algorithm, CBOFA)，以期提高了算法的精度同时减少不同个体间的运算次数。

4.1 萤火虫算法的改进思路

本文提出的改进萤火虫算法，具体改进思想表现在如下三个方面。

首先，通过采用 $K - means$ 聚类算法对萤

火虫种群进行分簇；

其次，针对萤火虫算法中全局最优个体对于算法寻优功能的导向作用，引入 $Levy$ 飞行^[11] 策略与边界约束，为平衡算法的寻优速度和精度，引入改进的精英邻居策略，通过采用不同的进化策略，以分而治之的方式，极大的增强了寻优速度；

最后，利用全局自适应步长与光强对萤火虫算法输入参数进行优化，针对萤火虫算法在高维时寻优精度不够，引入振荡策略，极大的提高了算法精度。

4.2 分簇策略

$K - means$ 算法是一种经典的基于距离大小的聚类算法，CBOFA 算法通过借鉴的 $K - means$ 的距离作为分类依据，同时采用与标准 $K - means$ 不同的聚类步骤，将每一代前 k 个适

应度最高的个体作为簇内中心，按照距离，将其余的个体划分到不同的簇间。经过一次迭代，所有个体重新开始按照适应度排序，选择适应度最高的前 k 个个体，再次进行簇划分^[12]。

其中，簇间距离采用欧式距离，具体计算如下：

$$dis(x_i, x_j) = \sum_{k=1}^d (x_{i,k} - x_{j,k})^2 \quad (5)$$

$x_i = (x_{i,1}, x_{i,2}, \dots, x_{i,d})$, $x_j = (x_{j,1}, x_{j,2}, \dots, x_{j,d})$ 为两个不同的个体，其中 d 为数据维度， $i, j \in [0, n]$, n 为种族大小。

4.3 进化策略

针对萤火虫算法中全局最优个体对于算法寻优功能的导向作用，通过引入Levy飞行策略提高最优个体的随机扰动能力，提升寻优的范围，同时为控制寻优过程中，随机飞行造成的个体超出问题边界，对最优个体加入边界控制，利用最优个体的导向性能，从而控制所有个体均在问题范围内求解。其次，对于分簇后的簇间最优个体，为防止求解部分问题时，由于缺少信息交流而陷入局部最优解，通过改进的精英邻居策略，防止部分个体丢失其搜索性能。通过不同的采用不同的进化策略，以分而治之的方式，在不影响萤火虫搜索能力的同时，极大的增强了FA算法的搜索范围和寻优速度，具体实现如下所示：

4.4 移动策略

对于分簇后的种群，每一个种簇因为种群多样性的减小，局限于局部搜索，为避免分簇后的每一个进化单位陷入局部最优，因此引入精英邻居引导策略，每一个簇间的最优个体都为其它簇间最优个体的邻居，通过比较不同邻居的适应度值，来确定具体的移动方式。

假设 x_i, x_j 为两个不同的个体，若 x_j 的适应度大于 x_i ，则 x_i 的移动公式为^[13]：

$$x_i^{t+1} = x_i + \beta \cdot r(x_j - x_i^t) + \alpha \cdot \frac{\|x_j - x_i\|}{(Bound_{max} - Bound_{min})} \quad (6)$$

$$x_i = \begin{cases} (r \cdot Bound_{min} + (1-r) \cdot x_i) \bmod (Bound_{max} - Bound_{min}), & x_i < Bound_{min} \\ (r \cdot Bound_{max} + (1-r) \cdot x_i) \bmod (Bound_{max} - Bound_{min}), & x_i > Bound_{max} \end{cases} \quad (13)$$

其中， $Bound_{max}, Bound_{min}$ 分别为搜索区域的上限和下限。

Levy飞行的随机步长服从Levy分布，Levy分布与高斯分布与柯西分布相比较，其尾翼更加的宽大，具有更强的扰动效果^[14]。其简化形式为：

$$L(s) \sim |s|^{-\lambda}; 1 < \lambda < 3 \quad (7)$$

其中， λ 为指数参数， s 为随机步长， s 的计算通常采用Mantegna^[15]提出的计算公式：

$$s = \frac{\mu}{|v|^{\frac{1}{\sigma}}}; 0 < \sigma < 2 \quad (8)$$

其中，参数 μ, v 服从式(5)的正态分布：

$$\begin{cases} \mu \sim N(0, \delta_\mu^2) \\ v \sim N(0, \delta_v^2) \end{cases} \quad (9)$$

式中的 δ_μ 与 δ_v 定义为：

$$\begin{cases} \delta_\mu = \frac{\Gamma(1+\lambda)\sin(\pi\lambda/2)}{2^{(\lambda-1)/2}\Gamma[(1+\lambda)/2]} \\ \delta_v = 1 \end{cases} \quad (10)$$

结合Levy飞行策略，将全局最优个体进行改进，假设为第 t 次迭代下的全局最优个体，则 x_i 的改进移动公式如下^[11]：

$$x_{i+1} = x_i + \text{sign}(\text{rand}) \cdot \text{Levy}(\lambda) \cdot \alpha \quad (11)$$

其中， $\text{Levy}(\lambda)$ 为Levy飞行产生的步长， α 为CBOFA的步长， $\text{sign}(\text{rand})$ 为Levy飞行的方向， rand 为 $[0,1]$ 上服从均匀分布的随机数：

$$\text{sign}(\text{rand}) = \begin{cases} 1, & \text{rand} \geq 1/2 \\ -1, & \text{rand} < 1/2 \end{cases} \quad (12)$$

为防止FA在随机移动时，造成其位置超出问题边界，而引起运算速度的降低与精度的损失，在对最优个体的移动上引入边界控制机制^[16]，其公式表示为：

4.5 全局策略

由FA算法的描述可知,光吸收系数 γ 与 α 对于算法的收敛速度与精度有着重要的影响,对FA算法中固定步长 α 在搜索解的过程中,算法精度低,易陷入局部最优解^[17],算法后期容易在最优解附件振荡的问题,引入自适应步长策略,通过算法的迭代次数,动态的更新步长,具体实现如下:

$$\alpha_{new} = \frac{1}{e^{\frac{t}{T_{max}}} + e^{\frac{t}{t_{max}}}} \cdot \alpha \quad (14)$$

光吸收系数的改进有利于进一步加快算法的寻优速度,通过引入变尺度光强策略,利用文献^[18]的变尺度混沌映射 $Sinusoidal\ map$,引入尺度变换后,光强吸收系数简化可表示为^[19]:

$$\gamma_{new} = \frac{t}{T_{max}} \cdot \sin(\pi\gamma) \quad (15)$$

在经典的FA算法中,萤火虫对于高维寻优问题易陷入局部最优,很难从局部的极值中跳出。随着迭代次数增加,萤火虫向聚集在一块,有着较强的吸引力,从而使得种群多样性降低。为增加种群多样性,增打跳出局部最优值得概论,在移动公式中加入振荡因子^[20],改进后的萤火虫移动公式如下:

1、普通萤火虫个体,假设 x_j 的亮度大于 x_i ,则 x_i 的移动公式为:

$$x_i(t+1) = \xi \cdot x_{id} + \beta \cdot (r_{ij}) \cdot (x_j - x_i(t)) + \alpha \cdot \varepsilon \quad (16)$$

2、簇间最优萤火虫个体,假设 x_j 为亮度大于 x_i 的邻居,则 x_i 的移动公式为:

$$x_i^{t+1} = \xi \cdot x_i + \beta \cdot r(x_j - x_i^t) + \alpha \cdot \frac{\|x_j - x_i\|}{(Bound_{max} - Bound_{min})} \quad (17)$$

$$\xi = \begin{cases} \frac{(2\sqrt{rand}-1)(1+rand)}{rand} & t \leq \frac{T_{max}}{2} \\ \frac{(2\sqrt{rand}-1)rand}{rand} & t > \frac{T_{max}}{2} \end{cases} \quad (18)$$

其中, ξ 是由公式(14)确定的随机数,用来确定目前萤火虫受上一代萤火虫的位置的影响程度。在算法初期 $\xi \geq \frac{2\sqrt{rand}-1}{\sqrt{rand}}$,加大萤火虫的振荡,在后期, $\xi < \frac{2\sqrt{rand}-1}{\sqrt{rand}}$,有利于增强种群的多样性,提高算法的精度。

4.6 基于分簇策略的振荡 FA 改进算法

综上所述,具体的算法步骤如下:

1. 设置算法最大迭代次数 T_{max} ,种群大小 n ,光吸收系数 λ ,步长因子 α ;
2. 随机生成 n 只萤火虫,计算其适应度;
3. 对所有个体按适应度进行排序,选取适应度靠前的 k 个个体作为簇中心,并计算其余个体与簇中心个体的距离,完成分簇;
4. 通过全局自适应步长与变尺度光强策略更新步长与光强;
5. 全局最优个体利用式(11)进行扰动,除全局最优个体以外的簇间最优个体利用式(17)进行位置更新,簇内普通个体利用式(16)进行位置更新;
6. 对所有萤火虫个体的适应度进行重新计算;
7. 若算法迭代达到 T_{max} ,则输出最优解,否则转到步骤3。

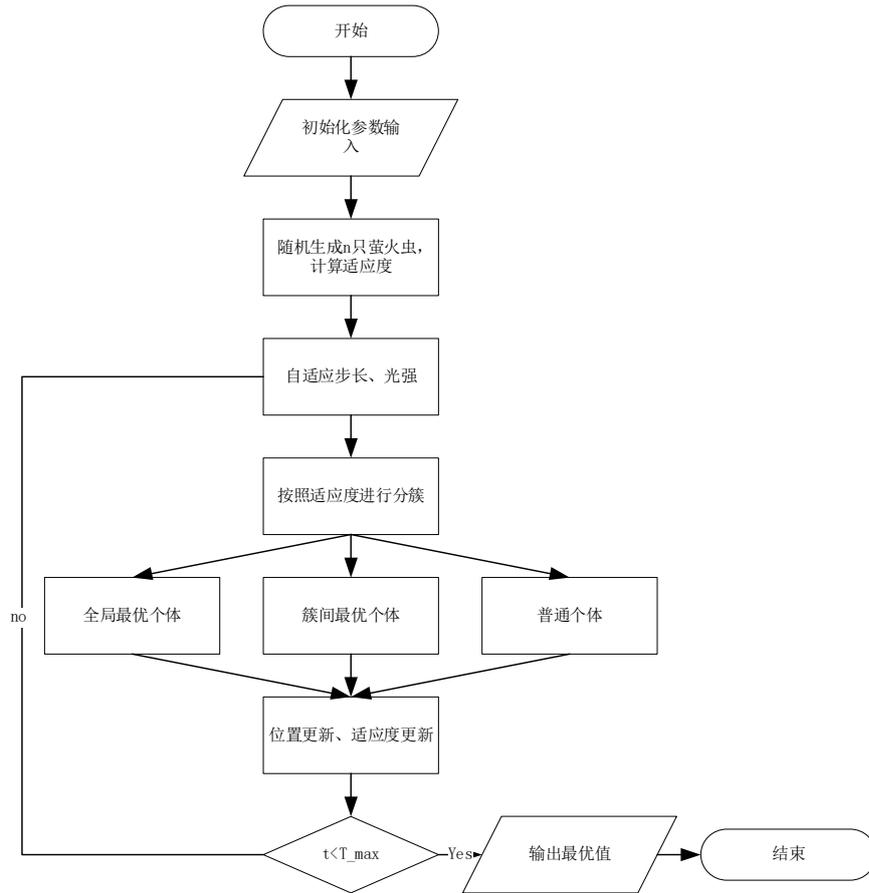


图2 程序流程图

5 基于改进萤火虫算法的模糊 Petri 网的自学习能力研究

人工智能方面的存在大量的优化算法，这些算法与神经网络相结合，在解决系统仿真、最优化查找、网络优化、以及模式识别等问题时，都取得不错的优化效果，而将它们运用到 FPN 参数优化的问题上，大部分的研究都存在适应能力不强，容易陷入局部最优值的缺点。本文拟用 CBOFA 算法对给定的 FPN 进行优化，并与已有的优化算法 DE 算法和 PSO 算法优化 FPN 作对比。

5.1 函数说明

本算例中对 FPN 模型中的权值、阈值和确信度均采用十进制的编码方案。适应度函数目的通过实际的标记值和期望的标记值之间的差值，通过取最小的一组参数，作为寻优结果，其定义式为^[21]： $E_i = \sum_{j=1}^{r_2} [M_{i,j}(p_8) - M_{i,j}^*(p_8)]^2$ ，其中， $i = 1, 2, \dots, r_1$ 为参数编码构成的种群数， $j = 1, 2, \dots, r_2$ 为初始输入的样本数，

$M_{i,j}(p_8)$ 和 $M_{i,j}^*(p_8)$ 分别表示终止库所 p_8 的第 i 个个体在第 j 个输入样本下的实际的标记值和期望的标记值。

5.2 对比实验

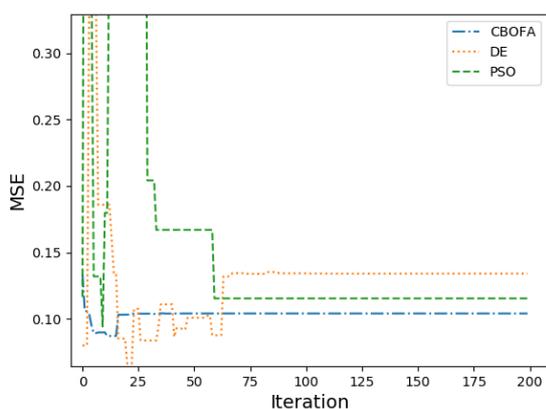
为验证 CBOFA 在复杂的 FPN 中的优化效果，因此采用图 1 添加虚变迁的 FPN 模型，结合给定的推理算法，与 DE、PSO 算法做泛化对比实验。实验的期望参数设置为 $w1=0.2$ ， $w2=0.5$ ， $w3=0.3$ ， $w4=0.4$ ， $w5=0.6$ ， $u1=0.7$ ， $u2=0.9$ ， $u3=0.6$ ， $u4=0.8$ ， $u5=0.7$ ， $\tau1=0.3$ ， $\tau2=0.4$ ， $\tau3=0.2$ ， $\tau4=0.5$ ， $\tau5=0.4$ ，样本数为 10，样本输入如表 3 所示，种群数量为 $n=50$ ，在推理函数中 $b=1000$ ，在 CBOFA 中初始步长为 1，光吸收系数为 1，在 DE 算法中交叉概率设置为 0.7，缩放因子 0.6，在 PSO 算法中，粒子的最大速度为 0.5。其中所有的算法均以 Python 实现。

表 1 样本参数输入

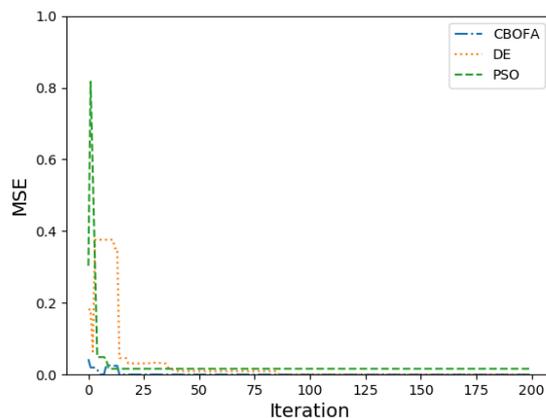
样本号	参数		
	P_4	P_5	P_7
1	0.2	0.8	0.5
2	0.9	0.9	0.9
3	0.4	0.7	0.6
4	0.8	0.4	0.2
5	0.9	0.5	0.4
6	0.3	0.7	0.5
7	0.5	0.4	0.9
8	0.2	0.6	0.7
9	0.5	0.4	0.6
10	0.2	0.8	0.7

5.3 进化过程比较

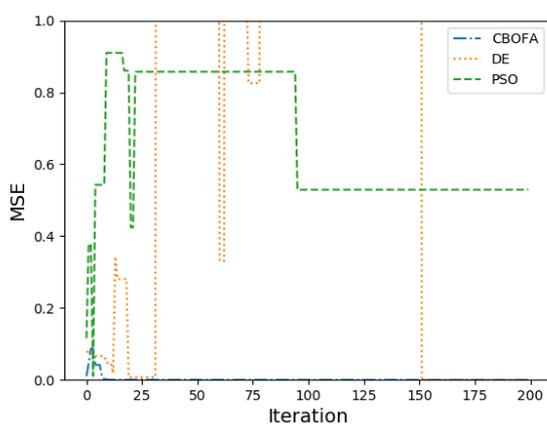
误差均方差(Mean Squared Error, MSE) 用来反映参数的估计值与参数真值之间的差距, 因此选用MSE作为一种进化精度对比参数是一种有效的方式。图3 (a)-(d)是三个算法的进化曲线, 反映的是三个算法在训练中, 最优解的权值 w 、确信度 u 以及阈值 t 的误差均方差进化情况。对于总体的进化曲线, 从图中可明显的看出, 无论是在单一的参数优化, 还是总的寻优过程, CBOFA都表现出较强的性能, 其更高的精度, 快速的收敛能力, 对于FPN的自适应能力的提升, 具有一定的有效性。



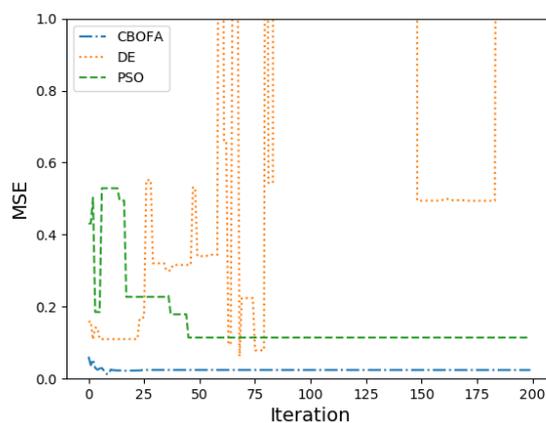
(a) w 进化曲线



(b) u 进化曲线



(c) t 进化曲线



(d) 总进化曲线

图 3 MSE 进化曲线

5.4 泛化性验证

任取5组非样本数据对FPN模型进行参数推理,分别比较在不同的迭代次数下,改进的萤火虫算法CBOFA,DE算法和PSO算法求解精度,从验证三个算法优化下FPN的泛化性能力,具体结果如下表格所示。

表 2 算法推理结果比较

实验算法	第 T 次迭代的 MSE		
	T=50	T=100	T=200
PSO 算法	0.34043	0.80744	0.29908
DE 算法	1.41613	2.22956	0.34257
CBOFA 算法	0.05391	0.00930	0.00660

实验结果表明,实验初期 T=50 代的情况下,CBOFA 便已经将算法优化较优异的位置,而此时的 DE 算法还距离理想的结果有所偏差,同时,我们根据 PSO 的结果可看出,PSO 的也具有一定的优势,原因是 FA 算法和 PSO 算法有着相近的算法理念,均以群思想作为算法的基础。在算法的中期 T=100,DE 算法和 PSO 由于其振荡,其寻优结果反而有所降低,而 CBOFA 却有着不错的表现,这主要因为,在改进的 FA 算法,其步长策略是一个类似高斯分布的函数,其在迭代中期,其步长已经进入一个较小的数值范围,不会有大幅度而扰动而影响算法的精度。同时随着迭代次数的增加,根据 T=200 数据,在算法的后期,三个算法推理结果均达到一个较为有效的值,但明显的可看出,改进的 FA 算法有着极优的性能,这与 CBOFA 算法的特性有着很大的关系,这也表明改进后的萤火虫算法适用于 FPN 的自学习能力的扩展并具有一定的优势,特别在参数维度过大的情况下,改进后的算法有着更高的适用性。

6 总结

群智能优化算法在参数优化算法的研究有很多,而与FPN的结合尚且在起步阶段,各类算法在优化FPN的问题上都存在着些许不足,FA算法作为一种新起的算法,其算法理念简

单,算法实现的代码量低,与优化结果于自身的初始输入参数关系不大的特性一经提出,变得到许多学者的关注,其应用领域包括^[22]故障定位、特征选择^[23]、路径规划^[24]等方面,而将FA与FPN的参数优化目前在国内外还少有案例。

本文在基本FA的基础上,通过改进的K-means聚类、Levy飞行策略、改进的振荡策略、自适应步长、自适应光强的引入,通过具体的FPN模型,选择合适的推理函数,对FPN的三类参数:阈值、权值、确信度利用三个优化算法进行自适应学习仿真实验,仿真结果显示,改进FA算法CBOFA在参数优化上优于其它两种优化算法DE和PSO,特别是在算法精度上面,CBOFA相比较其它两种算法有着更加稳定的输出。

参考文献

- [1] Shyi-Ming Chen, Jyh-Sheng Ke, Jin-Fu Chang. Knowledge representation using fuzzy Petri nets[J]. IEEE Transactions on Knowledge and Data Engineering, 1990, 2(3): 311-319.
- [2] Wang W-M, Peng X, Zhu G, 等. Dynamic representation of fuzzy knowledge based on fuzzy petri net and genetic-particle swarm optimization[J]. Expert Systems with Applications, 2014, 41(4): 1369-1376.
- [3] 苗国义, 穆瑞辉, 许加月. 基于改进人工免疫算法的模糊 Petri 网参数优化[J]. 微电子学与计算机, 2013, 30(09): 102-105.
- [4] Pedrycz W, Gomide F. A generalized fuzzy Petri net model[J]. IEEE Trans Fuzzy Syst, 1994, 2(4): 295-301.
- [5] Li X, Wen Y. Dynamic knowledge inference and learning under adaptive fuzzy Petri net framework[J]. IEEE Transactions on Systems Man & Cybernetics Part C, 2000, 30(4): P.442-450.
- [6] Huang A F M, Yang S J H, Wang M, 等. Improving fuzzy knowledge integration with particle swarm optimization[J]. Expert Systems with Applications, 2010, 37(12): 8770-8783.
- [7] 王长青. 基于 ACO 优化参数的模糊 Petri 网故障诊断技术研究[J]. 计算机测量与控制, 2012, 20(08): 2020-2023.
- [8] 李世光, 薛寒, 李珍, 等. 基于优化模糊 Petri 网的矿用变压器故障诊断[J]. 工矿自动化, 2017, 43(05): 54-57.
- [9] 李洋. 模糊 Petri 网参数优化问题的研究及分析[D]. 长沙理工大学, 2007.
- [10] 尹作重. 基于模糊 Petri 网专家系统的研究[D]. 机械科学研究总院, 2009.
- [11] 刘晓明, 沈明玉, 侯整风. 基于 Levy 飞行的萤火虫模糊聚类算法[J]. 计算机应用, 2019, 39(11): 3257-3262.
- [12] 于超杰. 萤火虫算法的改进及其在图像阈值分割中的应用[D]. 兰州大学, 2014.

- [13] 汪春峰, 褚新月. 基于精英邻居引导的萤火虫算法[J]. 河南师范大学学报(自然科学版), 2019(6): 5-27.
- [14] Fioriti V, Fratichini F, Chiesa S, 等. Levy Foraging in a Dynamic Environment – Extending the Levy Search[J]. International Journal of Advanced Robotic Systems, 2015, 12(7): 1.
- [15] Viswanathan G M, Afanasyev V, Buldyrev S V, 等. Lévy flights search patterns of biological organisms[J]. Physica A: Statistical Mechanics and its Applications, 2001, 295(1): 85-88.
- [16] Gandomi A H, Yang X S. Evolutionary boundary constraint handling scheme[J]. Neural Computing & Applications, 2012, 21(6): 1449-1462.
- [17] 赵杰, 雷秀娟, 吴振强. 基于最优类中心扰动的萤火虫聚类算法[J]. 计算机工程与科学, 2015, 37(2): 342-347.
- [18] Gandomi A H, Yang X S, Talatahari S, 等. Firefly algorithm with chaos[J]. Communications in Nonlinear Ence & Numerical Simulation, 2013, 18(1): 89-98.
- [19] 徐华丽, 苏守宝, 陈家俊, 等. 变尺度混沌光强吸收系数的萤火虫优化算法[J]. 计算机应用研究, 2015(2): 368-371.
- [20] 刘景森, 毛艺楠, 李煜. 具有振荡约束的自然选择萤火虫优化算法[J]. 控制与决策, 2020: 1-9.
- [21] 鲍培明. Learning Capability in Fuzzy Petri Nets Based on BP Net%基于 BP 网络的模糊 Petri 网的学习能力[J]. 计算机学报, 2004, 027(5): 695-702.
- [22] 杨鑫, 张家洪, 李英娜, 等. 配电网故障定位的免疫二进制萤火虫算法[J]. 西北大学学报(自然科学版), 2020, 50(02): 304-310.
- [23] 刘磊, 罗蓉, 尹胜. 基于精英个体划分的变步长萤火虫算法的特征选择方法[J]. 重庆邮电大学学报(自然科学版), 2020, 32(02): 313-321.
- [24] 李凤玲, 陈珊, 范兴江, 等. 基于萤火虫算法动态未知环境的路径规划[J]. 自动化与仪表, 2019, 34(06): 53-58.