

# 基于模糊网络和粒子群优化的油田指标预测<sup>①</sup>

李盼池<sup>1,2</sup>, 王海英<sup>2</sup>, 杨 雨<sup>2</sup>

<sup>1</sup>(东北石油大学 石油与天然气工程博士后科研流动站, 大庆 163318)

<sup>2</sup>(东北石油大学 计算机与信息技术学院, 大庆 163318)

**摘 要:** 针对油田开发指标预测问题, 提出一种模糊神经网络模型, 该模型包括输入层、模糊化层、规则层和输出层。模糊化层采用高斯隶属函数, 规则层每个节点对应一条模糊逻辑规则。网络可调参数为模糊集参数和输出层权值。提出了基于改进量子粒子群优化的网络训练方法。以油田开发指标中含水率预测为例, 结果表明该方法是有效的可行的。

**关键词:** 模糊神经网络; 粒子群优化; 指标预测; 算法设计; 优化算法

## Forecast of Oilfield Indexes Based on Fuzzy Neural Networks and Particle Swarm Optimization

LI Pan-Chi<sup>1,2</sup>, WANG Hai-Ying<sup>2</sup>, YANG Yu<sup>2</sup>

<sup>1</sup>(Post-doctoral Research Center of Oil and Gas Engineering, Northeast Petroleum University, Daqing 163318, China)

<sup>2</sup>(School of Computer & Information Technology, Northeast Petroleum University, Daqing 163318, China)

**Abstract:** Aiming at the forecast of oilfield development indexes, a fuzzy neural networks model is proposed that includes input layer, fuzzification layer, rules layer, and output layer. The Gauss function is applied in fuzzification layer, and each node in rules layer corresponds to a fuzzy logic rule. The adjustable parameters of proposed model include the fuzzy set parameters and the weight value of output layer. For determining these parameters, an improved quantum particle swarm optimization is presented. With forecast of moisture content as an example, the experimental results show that this method is effective and feasible.

**Key words:** fuzzy neural networks; particles swarm optimization; indexes forecast; algorithm design; optimization algorithm

油田开发系统包含各种指标, 由于油田开发的复杂性, 多变性, 各指标性质的不相同, 影响各类指标的因素种类繁多, 各指标及影响各类指标的因素之间相互联系又相互制约, 因此常规预测方法往往不尽人意。文献[1]通过将广义翁氏预测模型及反正切函数预测模型应用到聚合物驱开发指标预测中, 提出了新的聚驱指标预测方法, 该方法克服了“定液求含水”的局限性, 具有一定的应用价值。文献[2]提出了用函数方法对水驱油藏剩余油饱和度分布预测的新方法。矿场实际应用表明, 预测结果准确可行。上述方法过分依赖于专业知识, 不具有普适性。

模糊逻辑是处理不确定性、非线性等问题的有力

工具, 它比较适合于表达模糊或定性知识, 推理方式比较适合于人的思维模式, 但缺乏学习和自适应能力。神经网络具有并行计算、分布式信息存储、容错能力强以及自适应学习等优点。但不适合直接利用基于规则的知识, 因此在训练过程中常常陷入局部最优解。智能优化算法具有很好的全局优化能力, 可使大多数优化问题避免陷入局部最优解, 并提高优化效率。因此, 这三者的融合可以实现优势互补。基于这种思想, 本文首先提出一种模糊神经网络模型, 进而提出一种基于改进量子粒子群算法的网络训练算法。以大庆萨北油田北二西东后续水驱含水率预测为例, 实验结果表明该方法是有效的、可行的。

① 基金项目:国家自然科学基金(61170132);黑龙江省教育厅科学基金(11551015);中国博士后基金(20090460864)

收稿时间:2011-07-20;收到修改稿时间:2011-08-17

# 1 模糊神经网络模型

## 1.1 模糊逻辑系统

在模糊逻辑中，模糊规则一般可描述为：如果  $x_1$  为  $A_{k1}$ ， $x_2$  为  $A_{k1}$ ， $\dots$ ， $x_n$  为  $A_{kn}$ ，则  $y_1$  为  $B_{k1}$ ， $y_2$  为  $B_{k2}$ ， $\dots$ ， $y_m$  为  $B_{km}$ 。其中  $A_{ki}$  和  $B_{kj}$  分别为论域  $U_i$  和  $V_j$  的模糊集， $b_{k1}, b_{k2}, \dots, b_{km}$  分别为模糊集  $B_{k1}, B_{k2}, \dots, B_{km}$  的中心，且  $X = (x_1, x_2, \dots, x_n)^T$ ， $Y = (y_1, y_2, \dots, y_m)^T$  分别为模糊逻辑系统的输入和输出， $k$  为模糊规则序号。设系统有  $M$  条模糊规则，由中心平均反模糊化器、乘积推理规则和模糊产生器构成的模糊逻辑系统数值型输出具有如下形式

$$y_j = \frac{\sum_{k=1}^M b_{kj} \prod_{i=1}^n \mu_{A_{ki}}(x_i)}{\sum_{k=1}^M \prod_{i=1}^n \mu_{A_{ki}}(x_i)} \quad (1)$$

式中  $\mu_{A_{ki}}$  表示模糊集  $A_{ki}$  的隶属函数。

## 1.2 模糊神经网络模型

模糊神经网络(Fuzzy Neural Networks, FNN)是模糊逻辑与神经网络相融合的产物，是神经网络的一种代表形式，其特点是物理意义清晰，每层甚至每个神经元都有与模糊逻辑系统相对应的物理涵义。为实现式(1)所示的模糊逻辑系统，本文提出一种模糊神经网络模型，该模型结构包括四层，即输入层、模糊化层、规则层和反模糊化输出层，以 4 输入单输出为例，模型如图 1 所示，其中  $G$  表示“高斯隶属函数”， $\Pi$  为“乘积符号”， $\Sigma$  为“求和符号”。网络训练修正的是模糊化层高斯函数的中心、方差和规则层至反模糊化输出层的连接权值。各层功能简介如下。

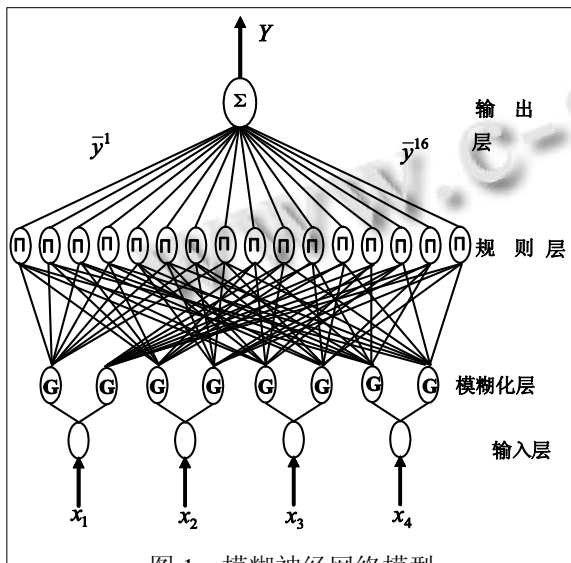


图1 模糊神经网络模型

输入层：该层接收精确数值向量作为 FNN 输入。

模糊化层：该层使用高斯函数作为隶属函数，将输入层输入的非模糊向量模糊化。假定  $x_i$  具有  $n_i$  个用于模糊划分的项节点，则  $x_i$  与该层相应的第  $j$  个节点的输出为

$$\mu_{A_{ij}}(x_i) = e^{-\frac{(x_i - m_{ij})^2}{\sigma_{ij}^2}} \quad (2)$$

式中  $m_{ij}$  和  $\sigma_{ij}$  分别表示  $A_{ij}$  的均值和方差， $j = 1, 2, \dots, n_i$ 。该层有  $N = \sum_{i=1}^n n_i$  个节点。

规则层：该层将前件(模糊化层)和后件(输出层)连接起来。连接的规则是：每个规则节点仅与来自每个输入的一个模糊化节点相连接。因此，FNN 的规则层共有  $M = \prod_{i=1}^n n_i$  个节点，且每个节点对应一条模糊推理规则，第  $k$  个节点的输出为

$$z_k = \prod_{i=1}^n \mu'_{A_{ki}}(x_i) \quad (3)$$

其中， $s = s(k, i)$ ，( $k = 0, 1, \dots, M-1$ ;  $i = 1, 2, \dots, n$ )， $1 \leq s \leq n_i$ 。 $s(k, i)$  可用如下方法确定：将  $k$  用  $n_i$  进制数表示，则第  $s$  位数即为  $s(k, i)$ 。若记  $k = k_1 k_2 \dots k_{n_i}$ ，则立即可得  $s = s(k, i) = k_i$ 。

输出层：即模糊判决输出层。所有第三层的规则节点都与该层输出节点连接。该层完成中心平均反模糊化操作。设该层有  $p$  个节点，则第  $j$  个节点输出为

$$y_j = \frac{\sum_{k=1}^M \bar{y}^k z_k}{\sum_{k=1}^M \bar{y}^k} = \sum_{k=1}^M \bar{y}^k \prod_{i=1}^n \mu'_{A_{ki}}(x_i) \quad (4)$$

其中  $\bar{y}^k$ ，( $k = 1, 2, \dots, M$ )为网络权系数，其物理意义对应于式(1)中第  $k$  条模糊规则后件模糊集中心  $b_{kj}$ 。值得指出，式(4)与式(1)并不相同，而是相差一个全局因子  $\sum_{k=1}^M \prod_{i=1}^n \mu_{A_{ki}}(x_i)$ 。但是这并不妨碍网络性能。因为这个因子的缺失完全可以通过调整权值  $\bar{y}^k$  来补偿。

## 2 改进的量子粒子群算法

粒子群优化(Particle Swarm Optimization, PSO)自 1995 年提出之后的改进主要集中在以下三个方面：一是基于算法参数的选择<sup>[3]</sup>；二是基于粒子位置及速度的更新规则<sup>[4]</sup>；三是与量子计算的融合<sup>[5-8]</sup>。本文提出一种基于相位编码的量子 PSO 算法(Phase-based Quantum Particle Swarm Optimization, PQPSO)，基本特点是：粒子位置由量子比特相位描述，全局因子根据粒子当前适应度自适应决定。

### 2.1 编码方案与解空间变换

在 PQPSO 中，直接采用量子比特的相位作为粒子

位置的编码。编码方案如下

$$P_i = [\theta_{i1}, \theta_{i2}, \dots, \theta_{in}] \quad (5)$$

其中  $\theta_{ij} = 2\pi \times \text{rnd}$ , rnd 为 (0, 1) 之间随机数。

记优化问题的第  $j$  个解变量  $X_j \in [a_j, b_j]$ , 粒子  $P_i$  上第  $j$  个量子相位为  $\theta_{ij}$ , 则由  $\theta_{ij}$  得  $X_j$  到的变换式为

$$X_j = a_j + (b_j - a_j)\theta_{ij}/2\pi \quad (6)$$

其中  $i=1, 2, \dots, m$ ,  $j=1, 2, \dots, n$ 。

## 2.2 粒子位置的更新

本文采用量子旋转门按如下两式更新粒子的位置

$$\Delta\theta_i(t+1) = w\Delta\theta_i(t) + c_1r_1(\theta_{is} - \theta_i(t)) + c_2r_2(\theta_{ig} - \theta_i(t)) \quad (7)$$

$$\theta_i(t+1) = \theta_i(t) + \Delta\theta_i(t+1) \quad (8)$$

其中  $\Delta\theta_i$  是量子旋转门的旋转角度。 $\theta_{is}$  和  $\theta_{ig}$  分别为第  $i$  维的自身最优值和全局最优值,  $w$  是惯性因子,  $r_1$ 、 $r_2$  是 [0,1] 之间随机数。 $c_1$ 、 $c_2$  是自身因子和全局因子。

## 2.3 全局因子的自适应确定方法

为取消 PSO 对粒子速率的限制, Eberhart 在速率更新式中引入了惯性因子。文献[9]进一步得出保证 PSO 收敛惯性因子选取的一般原则

$$w > (c_1 + c_2) / 2 - 1 \quad (9)$$

基于文献[9], 我们提出如下全局因子  $c_2$  的自适应调整方法。容易证明此时的  $w$ 、 $c_1$ 、 $c_2$  满足式(7)要求。

$$c_2 = c_{up} - (c_{up} - c_{low})(fit(x) - fit_w) / (fit_b - fit_w) \quad (10)$$

$$\left. \begin{aligned} 0 < \delta < 2(1+w)/3; c_1 = 1+w-\delta/2 \\ 0 < w < 1; c_{up} = c_1 + \delta; c_{low} = c_1 - \delta \end{aligned} \right\} \quad (11)$$

## 2.4 粒子位置的变异

本文采用一种新的量子门, 即 Pauli-Z 门来引导种群的变异。该门在单量子比特  $|\varphi\rangle$  上的作用效果为:

$$Z|\varphi\rangle = \begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix} \begin{bmatrix} \cos\theta \\ \sin\theta \end{bmatrix} = \begin{bmatrix} \cos\theta \\ -\sin\theta \end{bmatrix} = \begin{bmatrix} \cos(2\pi-\theta) \\ \sin(2\pi-\theta) \end{bmatrix} \quad (12)$$

根据式(5), 该门对粒子  $P_i$  的变异效果为:

$$Z(P_i) = [2\pi - \theta_{i1}, 2\pi - \theta_{i2}, \dots, 2\pi - \theta_{in}] \quad (13)$$

其实, 这种变异的实质还是进行量子比特的相位旋转。设某一量子比特当前相位为  $\theta$ , 则变异后的相位为  $2\pi - \theta$ , 即正向旋转了  $2\pi - 2\theta$ 。由于这种旋转不与当前最佳粒子比较, 一律正向旋转且幅度较大, 所以有助于突破早熟收敛, 增加粒子的多样性。

## 2.5 基于 PQPSO 的 PNN 训练

FNN 的训练问题, 实质上是对误差函数的多元求极值问题。由于参数较多、映射关系复杂, 常规的 BP 算法很容易陷入局部极小而导致训练失败。因此, 本文提出一种基于 PQPSO 的网络训练方案。在 PQPSO 中量子机制的引入可以提高计算效率; 全局因子的自适应确定方法可以提高收敛速度; 加之 PSO 固有的全局搜索能力, 可以达到使 FNN 快速收敛的目的。

## 3 实际应用

本节结合具体预测实例, 验证 FNN 预测算法的有效性。数据资料采用大庆萨北油田北二西东块的后续水驱含水率实测数据, 如表 1 所示。

表 1 大庆萨北油田北二西东后续水驱含水率实测数据

时间(月)	注入量(104t)	采液量(104t)	含水率(%)
200306	15.74	19.36	92.15
200307	14.52	19.24	92.66
200308	14.58	18.81	92.68
200309	14.99	17.95	92.41
200310	17.02	18.89	92.60
200311	18.07	17.26	92.78
200312	19.85	18.58	93.10
200401	19.87	17.99	93.20
200402	19.79	17.68	93.58
200403	19.71	17.62	93.80
200404	11.45	10.30	92.74
200405	11.05	9.77	92.81
200406	12.88	12.89	93.30
200407	16.44	15.69	93.71
200408	17.31	15.94	93.99
200409	16.28	17.10	94.16
200410	15.24	16.50	93.95
200411	14.56	16.36	94.53
200412	14.25	15.29	94.54
200501	13.05	16.78	94.56
200502	11.70	13.87	94.31
200503	11.05	15.37	93.92
200504	12.00	13.06	94.33
200505	12.11	12.14	94.11
200506	10.65	12.14	94.11

由表 1 可知, FNN 的 2 个输入指标为注入量和采液量, 1 个输出指标为含水率(用 W 表示)。为使预测算法尽量精确, 将两个输入指标均划分为“大(B)”、“较大(BM)”、“中(M)”、“较小(SM)”、“小(S)”五个模糊集。综上, FNN 的结构为: 输入层 2 个节点, 模糊化层 10 个节点, 规则层 25 个节点, 反模糊化输出层 1 个节点。每个输入指标对应 5 个模糊集, 均采用高斯隶属函数, 每个高斯函数包含中心和方差两个参数, 所以 2 个状

态变量共有  $2 \times 10 = 20$  个参数。由于每个规则层节点输出均有一个连接权，所以共有 25 个连接权。这样，整个 FNN 预测模型共有  $20 + 25 = 45$  个参数需要确定。连接权的初始范围设置为  $(-1, 1)$  之间随机数，注入量和采液量的模糊集中心和方差初始范围设置如表 2 和表 3 所示。

表 2 注入量的中心、方差初始范围(104t)

	B	BM	M	SM	S
$c$	18.5 ~	16.5 ~	14.5 ~	12.5 ~	11.5 ~
	19.5	17.5	15.5	13.5	12.5
$\sigma^2$	2.0 ~ 3.0	2.0 ~ 3.0	2.0 ~ 3.0	2.0 ~ 3.0	2.0 ~ 3.0

表 3 采液量的中心、方差初始范围(104t)

	B	BM	M	SM	S
$c$	18.0 ~	16.0 ~	14.0 ~	12.0 ~	10.0 ~
	19.0	17.0	15.0	13.0	11.0
$\sigma^2$	2.0 ~ 3.0	2.0 ~ 3.0	2.0 ~ 3.0	2.0 ~ 3.0	2.0 ~ 3.0

在 PQPSO 中，惯性因子的取值范围通常为  $0.5 < w < 0.8$ 。根据式(11)，我们取  $w = 0.7298$ ， $\delta = (1+w)/3 = 0.5766$ ， $c_1 = 1.4415$ ， $c_{up} = 2.0181$ ， $c_{low} = 0.8649$ 。对于 FNN 的 45 个模型参数，分别用 PQPSO 和普通 PSO 实施优化。两种算法的种群规模均取 50，最大优化步数均取 500，PQPSO 变异概率取 0.05。对于普通 PSO， $w = 0.7298$ ， $c_1 = c_2 = 1.49618$ 。对于含水率预测，希望 FNN 预测模型的输出尽量逼近矿场实际采样数据，因此本节采用如下所示的二次型性能指标

$$J = \sum_{i=1}^M (W_i - \tilde{W}_i)^2 \quad (14)$$

其中  $w$  和  $\tilde{w}$  分别为 FNN 模型的期望输出和实际输出， $M$  为样本数。优化目标是使性能指标值最小，因此适应度函数可取为

$$f = b / (J + a) \quad (15)$$

其中  $a = 10^{-2}$  使分母不为 0， $b = 10^3$  使适应度不至太小。

对于 FNN 的二次型性能指标，PQPSO 优化结果为  $J = 0.4578$ ，PSO 优化结果为  $J = 3.8338$ 。预测结果对比如图 2 所示。

由图 2 预测结果可知，本文提出的 FNN 模型具有很好的预测能力，另外对比曲线也表明 PQPSO 的优化性能优于普通 PSO。实验结果揭示出模糊逻辑、进化计算和神经网络的融合在油田开发指标预测方面具有一定的应用潜力。

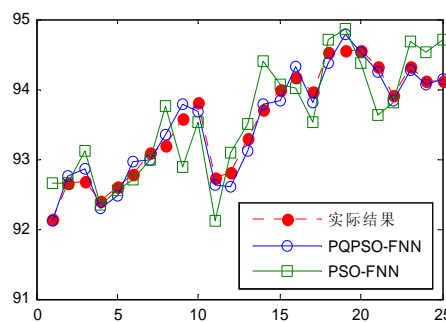


图 2 两种算法的预测结果对比

#### 4 结论

为解决油田开发工程中的指标预测问题，将模糊计算、神经计算以及群智能优化相融合，首先提出一种模糊神经网络模型，然后提出一种基于量子比特相位的量子粒子群算法，用于优化 FNN 的模型参数。采用矿场开发中的含水率指标作为预测对象，仿真结果表明，该方法具有较快的收敛速度和预测精度，从而为求解复杂的油田开发指标预测提供了新思路。

#### 参考文献

- 刘义坤, 毕永斌, 隋新光. 聚合物驱开发指标预测方法研究. 大庆石油地质与开发, 2007, 26(2): 105-107.
- 宋考平, 聂洋, 邵振波. 聚合物驱油藏剩余油饱和度分布预测的函数法. 石油学报, 2008, 29(6): 899-903.
- Cai XJ, Cui ZH, Zeng JC. Dispersed particle swarm optimization. Information Processing Letters, 2008, 105(6): 231-235.
- Chatterjee A, Slarry P. Nonlinear inertia weight variation for dynamic adaptation in particle swarm optimization. Computers & Operations Research, 2007, 33(3): 859-871.
- Meng K, Wang HG, et al. Quantum inspired particle swarm optimization for valve-point economic load dispatch. IEEE Trans. on Power Systems, 2010, 25(1): 215-222.
- Zhang ZS. Quantum-behaved particle swarm optimization algorithm for economic load dispatch of power system. Expert Systems with Applications, 2010, 37(2): 1800-1803.
- Lu SF, Sun SF, Lu ZD. An improved quantum-behaved particle swarm optimization method for short-term combined economic emission hydrothermal scheduling. Energy Conversion and Management, 2010, 51(3): 561-571.
- Leandro SC. Gaussian quantum-behaved particle swarm optimization approaches for constrained engineering design problems. Expert Systems with Applications, 2010, 37(2): 1676-1683.
- wagatam D, Ajith A, Amit K. Automatic kernel clustering with a multi-elitist particle swarm optimization algorithm. Pattern Recognition Letters, 2008, 29(5): 688-699.