

# 基于改进粒子群算法的模糊神经网络<sup>①</sup>

衣治安<sup>1</sup>, 牟春苗<sup>1</sup>, 孙寅萍<sup>2</sup>

<sup>1</sup>(东北石油大学 计算机与信息技术学院, 大庆 163318)

<sup>2</sup>(中节能风力发电股份有限公司, 北京 100092)

**摘要:** 油气管道腐蚀失效检测具有随机性、复杂性、多因素性和非线性等特点, 利用精确的数学模型描述有一定的难度. 本文提出了一种基于混合改进粒子群算法的模糊神经网络的管道腐蚀动态检测方法. 优化粒子群算法的收敛性, 加快寻找最优解的速度, 将该算法用于模糊神经网络模型构建中, 建立了基于模糊神经网络的管道腐蚀动态检测模型. 通过利用实际的管道腐蚀检测数据进行诊断应用, 取得了较好的检测效果, 验证了该模型及算法的可行性和有效性.

**关键词:** 粒子群算法; 模糊神经网络; 管道腐蚀动态分析

## Fuzzy Neural Network Based on Improved Particle Swarm Algorithms

Yi Zhi-An<sup>1</sup>, Mu Chun-Miao<sup>1</sup>, Sun Yin-Ping<sup>2</sup>

<sup>1</sup>(School of Computer and Information Technology, Northeast Petroleum University, Daqing 163318)

<sup>2</sup>(CECWP Wind-power Corporation, Beijing, 100092)

**Abstract:** The failure detection of the oil and gas pipeline corrosion involve many characteristics, such as randomness, complex, multiple factors, and non-linear so on, it is difficult to describe by using the precise mathematical model. This paper proposes a failure detection method on pipeline corrosion, which is the Fuzzy neural network, based on Hybrid the improved particle swarm algorithm. It optimizes the convergence of Particle swarm algorithm and accelerates the speed of finding the optimal solution, which is used in the building of the Fuzzy neural network, and in this way, it sets up a pipeline corrosion failure detection model. It obtains a good recognition effect, by using the actual pipeline corrosion failure detection data to diagnostic applications, and the result verify the feasibility and validity of the model and algorithm.

**Keywords:** particle swarm algorithm; fuzzy neural network; dynamic analysis of pipeline corrosion

油气管道受到土壤腐蚀已成为管道安全问题一个很重要的潜在因素. 土壤腐蚀受许多复杂的因素影响, 并且有时变过程性模糊信息. 因此, 管道土壤腐蚀速率与各影响因素间表现的非线性关系是难以建立比较精确的数学模型来对此描述这一过程. 在针对这一复杂问题上, 本章提出一种模糊推理过程神经网络模型. 模型将模糊过程推理规则和过程神经网络可自动处理定性与定量混合信息的处理机制相结合, 集合考虑时间因素, 运用过程神经元表示推理规则. 借助改进的

粒子群算法对模型方法求解进行优化. 实际样本资料处理得到了较理想的结果.

## 1 算法介绍

### 1.1 过程神经元基本模型

过程神经元是由时变函数(或过程)作为输入, 包含空间加权聚合、时间效应累计和激励阈值激励输出等部分运算组成. 在过程神经元中时变函数可以作为输入、连接权值以及激励阈值, 这是与传统神经元

① 收稿时间:2013-11-01;收到修改稿时间:2013-11-25

的区别, 累计算子是其对于时间上产生作用的表示, 将累计算子的聚合可描述输入在空间上的效应. 模型结构如图 1 所示.




图 1 过程神经元模型

图 1 中,  $x_1(t), x_2(t), \dots, x_n(t)$  为过程神经元的时变输入函数;  $w_1(t), w_2(t), \dots, w_n(t)$  为相应的连接权函数;  $K(\bullet)$  为过程神经元的聚合核函数, 不同的系统对输入的信息有着不同的特征要求, 依具体情况对信号相应转换;  $f(\bullet)$  为激励函数, 可取线性函数、Sigmoid 函数、Gauss 型函数等等. 用式(1-1)中的数学模型描述过程神经网络模型的输入、输出关系:

$$f\left(\int \left(\sum (K(W(t), X(t)))\right) - \theta\right) \quad (1)$$

在时空聚合运算过程中, 首先进行空间加权聚合, 在同一时刻多个输入信号实现空间聚合, 然后在空间聚合的结果的基础上进行时间累积, 最后, 通过函数  $f$  计算得到最终的输出结果, 该类过程神经元是在实际应用中比较常用的. 过程神经元结构图如图 2 所示.




图 2 过程神经元模型

在式(1)基础上, 引入加权和作为空间聚合运算, 并且用积分表达时间(过程)累积运算,  $K \odot = 1$ , 则该式可以写成

$$f\left(\int_0^T \left(\sum_{i=1}^n w_i(t)x_i(t)\right) dt - \theta\right) \quad (2)$$

上式中描述的运算主要包括: 累加和, 激励函数、以及加权乘积等运算合成, 称之为过程神经元. 若取  $T=0$ ,  $x_i(t) = x_i$ ,  $w_i(t) = w_i$ , 则该式就简化为

$$y = f\left(\sum_{i=1}^n w_i x_i - \theta\right) \quad (3)$$

在上式中, 可以看出, 没有与时间相关的元素, 是过程神经元的特殊情况, 等价于传统神经元.

### 1.2 离散型过程神经元基本模型

离散过程神经元基本结构包含的主要几个部分是: 加权输入信号、空间上聚合运算、时间上的算子

聚合和激励输出等, 该类过程神经元特有的部分是输入信号和连接权值都是离散型时间序列. 图 1.3 描述了该类神经元模型的结构.




图 3 离散型过程神经元模型

图 3 中,  $x_1(t_l), x_2(t_l), \dots, x_n(t_l) \quad l = 1, 2, \dots$  为离散过程神经元的  $n$  个时间离散输入值序列;  $w_1(t_l), w_2(t_l), \dots, w_n(t_l) \quad (l = 1, 2, \dots)$  为相应的连接权值序列; “ $\oplus$ ” 为离散输入信号的空间聚合算子, “ $\odot$ ” 为某种离散时间(过程)累积算子,  $f \odot$  为激励函数.

离散过程神经元输入到输出的映射关系表示为:

$$y = f(W(t) \oplus X(t)) \odot K(\cdot) - \theta \quad (4)$$

其中,  $X(t)$  为离散过程神经元的输入矩阵;  $W(t)$  为对应的连接权值矩阵;  $K \odot$  为时间累积核函数;  $\theta$  为神经元激励阈值.

若 “ $\oplus$ ” 为输入信号对空间的加权, “ $\odot$ ” 为对时间效应的累积, 核函数  $K \odot = 1$ , 则式(4)可写成

$$y = f\left(\sum_{i=1}^n \sum_{l=1}^T w_i(t_l)x_i(t_l)\Delta t_l - \theta\right) \quad (5)$$

式中,  $\Delta t_l = t_l - t_{l-1}$ .

若为时间为有限序列, 则式(5)可表示为

$$y = f\left(\sum_{i=1}^n \sum_{l=1}^T w_i(t_l)x_i(t_l)\Delta t_l - \theta\right) \quad (6)$$

其中,  $T$  为时间序列的长度.

### 1.3 模糊推理过程神经元基本模型

在语义上, 把模糊推理过程神经元(FRPN)表示为一个规则, 即模糊加权过程推理, 用模糊集合作为可变元的模糊谓词, 作为该规则的前提和结论. 该类神经元中, 模糊逻辑规则用来描述论域的“过程知识”, 模糊输入信息经加权聚合以后产生的真值超过阈值时, 按照模糊规则给出一个相应的过程操作, FRPN 的结构如图 4 所示.




图 4 模糊推理过程神经元模型

其中,  $P_i(t)$  为模糊过程输入谓词,  $Q(t)$  为模糊结论谓词, 均取真值于  $[0,1]$ ; “&” 和 “ $\oplus$ ” 分别为模糊过程神经元的模糊时、空聚合算子; 模糊连接权  $\tilde{w}_i$  为第  $i$  个前提在模糊过程推理中的权重, 满足  $\tilde{w}_i \geq 0$  且  $\sum_{i=1}^n \tilde{w}_i = 1$ ;  $cf$  为推理规则的置信度 ( $0 < cf < 1$ ),  $\tau$  为阈限.

图 4 中, 模型中包含的模糊过程推理规则可表示为, 公式:  

$$\tilde{w}_1 \& P_1(t) \oplus \tilde{w}_2 \& P_2(t) \oplus \dots \oplus \tilde{w}_n \& P_n(t) \rightarrow Q(t), cf, \tau$$
 (7)

### 1.4 输入/输出为连续时间函数的过程神经元基本模型

该类过程神经元中模型结构中, 以连续时间函数作为其输入与输出. 时变函数作为输入信号, 累计算子描述时间上的效应, 并在空间上进行分散聚集, 以及激励输出等部分组成了该神经元模型. 其中采用多输入的信号聚合加权作为神经元空间聚合算子, 含有时变参数的积分作为时间累积算子. 结构如图 1.5 所示.




图 5 连续型过程神经元模型

图 1.5 中, 设定随时间改变的输入时变函数  $x_1(t), x_2(t), \dots, x_n(t)$ ;  $w_1(t), w_2(t), \dots, w_n(t)$  为连接权对应的函数; “ $\Sigma$ ” 为神经元在空间上的聚合算子, 取多输入信号的加权和; “ $\int$ ” 为过程神经元的时间累积算子, 取时变参数积分; 激励函数  $f(\bullet)$ , 可取 Sigmoid 函数、Gauss 型函数等, 也才采用其他有界函数, 形式不限.

由图 1.5, 输入到输出存在于时变输入输出函数的过程神经元中的映射关系为:

$$y(t) = f\left(\int_0^t \sum_{i=1}^n w_{ij}(\tau) x_i(\tau) d\tau - \theta(t)\right)$$
 (8)

其中,  $\theta(t)$  表示激励阈值, 也为时间的函数.

其实, 连续输入输出的过程神经元可以采用与输入时间对应的点  $t$  等运算作为它的时空聚合算子,  $\max$  或  $\min$  都可以对空间加权进行聚合运算; 时间聚合算子的描述可以通过一些运算: 区间中的褶积、 $\max$  或  $\min$ .

式(8)表示, 该类神经元模型描述了空间上输入时变信号的加权聚合, 同时也描述了输入的信号在时刻

$t$  之前的时间效应累计, 可实现输入/输出之间的同步映射关系.

对式(8)泛化处理, 考虑某些单元有延时情况下的聚合运算, 式(8)可改写为

$$y(t) = f\left(\int_0^{t-k\delta} \sum_{i=1}^n w_i(\tau) x_i(\tau) d\tau - \theta(t-k\delta)\right)$$
 (9)

式(9)中, 时间粒度设为  $\delta$ ,  $k$  大于等于零的整数, 且满足  $t-k\delta > 0$ .

式(8)、式(9)定义的过程神经元可实现复杂的网络延迟传输功能, 网络模型包含多隐层、时变信息流.

## 2 基于改进粒子群算法的模糊推理过程神经网络模型

### 2.1 粒子群优化算法及其改进

粒子群算法 (particle swarm optimization), 简称 PSO, 基本思想来源于鸟群、鱼群觅食过程中的迁徙和聚集行为, 实现对实际问题的优化. 搜索空间的解用 PSO 中的粒子一对一的表示, 先随机标记每个粒子的位置和速度, 在局部或者种群全局最优解的指引下, 飞向最优解. 设定一个维数为  $D$  的搜索空间,  $S$  为粒子群, 则式(10)中  $v_{id}$  表示第  $i$  个粒子在第  $d$  维空间的速度,  $x_{id}$  则表示它对应的位置:

$$\left. \begin{aligned} v_{id} &= wv_{id} + c_1r_1(P_{id} - x_{id}) + c_2r_2(P_{gd} - x_{gd}) \\ x_{id} &= x_{id} + v_{id} \end{aligned} \right\}$$
 (10)

其中,  $P_{id}$  表示粒子当前的最优位置,  $P_{gd}$  为全局最优位置,  $C_1$  和  $C_2$  提供记忆最优选择的功能,  $r_1$  和  $r_2$  是区间  $[0,1]$  中的某一随机数,  $w$  为大于 0 的惯性因子,  $w$  的大小决定搜索到全局最优解的难易程度, 越大搜索全局最优解越快, 但是局部的会有比较差的收敛性, 反之亦然. 通过改变式(10)中的某些参数对 PSO 算法进行改进, 产生一些新的改进算法, 优化原算法的收敛性, 加快寻找最优解的速度.

在粒子群算法学习过程中, 当迭代次数在预先规定的 MAX 次数范围内相邻两次得到的最优解不变时, 认为算法进入停滞状态, 粒子群在现有运动轨迹上陷入局部最优. 根据需要, 判断算法早熟的标准的宽松程度与 MAX 的大小成正向变化关系. 用代数 num 记录目前停滞状态下的位置, 两次相邻的最优解相同时, num 加 1, 否则就清 0. 当 num=MAX 时, 表明算法停滞. 即在 MAX 次的迭代中, 粒子运动没有退出局部最优值. 为了打破此僵局, 将当前最好解的任意一维修改成一个随机值, 即

$$B_g = (\hat{z}_{g1}, \hat{z}_{g2}, \dots, z_{rk}, \dots, \hat{z}_{gD}) \quad (11)$$

式中  $z_{rk}$  和  $k$  ( $k=1,2,\dots,D$ ) 均为随机数;  $B_g$  当前粒子群中全局最优解所在的位置。

通过该方法判断粒子寻优活动的停滞, 通过在式 (11) 中增加随机变量, 为粒子随机分配新的位置, 改变其运行的轨迹, 从而摆脱局部最优解的僵局, 这种方式可以减小没有实际意义的迭代过程, 优化了算法的收敛效果, 也相应的提高了寻找最优解的速度。

### 2.2 模糊推理过程神经网络模型

在基本过程神经元结构中, 实现基于模糊推理过程神经元, 需要自学习机制和自身的过程性推理规则。在解决实际问题的过程中, 按照推理规则选择合适的聚合算子, 并根据实际情况对模糊权值做出相应的调整。模糊推理过程神经网络是由多个过程神经元构成的, 如图 6 所示, 各个过程神经元是按照既定的关联关系构成该神经网络, 同时也是具有该模糊过程特点的规则集合。




图 6 模糊推理过程神经网络模型

图 6 中:  $FPN_j$  ( $i=1,2,\dots,m$ ) 为由式(12)定义的 FRPN;  $P_i(t)$  ( $i=1,2,\dots,n$ ) 含有过程性信息的谓词, 表示模糊过程推理模型的输入条件, 即推理规则中的 IF 条件;  $Q_j(t)$  ( $j=1,2,\dots,m$ ) 为推理规则中的 THEN 部分, 即由规则得到的结论输出;  $\tilde{w}_{ij}$  ( $0 \leq \tilde{w}_{ij} \leq 1, \sum_{i=1}^n \tilde{w}_{ij} = 1$ ) 为网络连接权。

### 2.3 模型学习算法

将以上模型的推理过程用方程组等价转换:

$$\begin{cases} cf_1 * (\tilde{w}_{11} \& T(P_1(t)) \oplus \dots \oplus \tilde{w}_{1n} \& T(P_n(t))) = T(Q_1(t)), \\ cf_2 * (\tilde{w}_{21} \& T(P_1(t)) \oplus \dots \oplus \tilde{w}_{2n} \& T(P_n(t))) = T(Q_2(t)), \\ \vdots \\ cf_m * (\tilde{w}_{m1} \& T(P_1(t)) \oplus \dots \oplus \tilde{w}_{mn} \& T(P_n(t))) = T(Q_m(t)). \end{cases} \quad (12)$$

式(11)中,  $cf_j$  为第  $j$  条模糊推理规则的信度因子;  $T(P_i(t))$  为前提  $P_i(t)$  的真度,  $T(Q_j(t))$  为结论  $Q_j(t)$  的真度。

加权模糊推理过程神经网络的学习过程是根据已知的一些事实在关于谓词真度  $T(P_1(t)), T(P_2(t)), \dots, T(P_n(t))$  ;

$T(Q_1(t)), T(Q_2(t)), \dots, T(Q_m(t))$  的若干组合理值中反过来求一组权系数  $\tilde{w}_{ij}$  ( $i=1,2,\dots,n; j=1,2,\dots,m$ ), 使之满足方程组(12)。设有  $K$  组推理事实, 则可得到包含  $n \times m$  个未知数的有  $m \times K$  个方程的方程组, 这是一个特殊的“线性”方程组, 可将其转换为一个线性规划的求解问题, 同时满足真值在范围  $[0,1]$  之内的约束。

选取大量训练样本用于网络学习, 符合网络扩展需求, 所以只考虑在  $k > n$  条件下进行训练。因此, 网络参数的确定方法即为: 超定线性方程组的确定。依据模糊推理逻辑的基本原理, 方程组(12)转换后如下:

$$\begin{cases} T_{11}w_{11} + T_{12}w_{12} + L + T_{1n}w_{1n} = T_{11} / cf_1 \\ L L L L L L \\ T_{11}w_{n1} + T_{12}w_{n2} + L + T_{1n}w_{nn} = T_{1n} / cf_n \\ L L L L L L \\ T_{k1}w_{11} + T_{k2}w_{12} + L + T_{kn}w_{1n} = T_{k1} / cf_1 \\ L L L L L L \\ T_{k1}w_{n1} + T_{k2}w_{n2} + L + T_{kn}w_{nn} = T_{km} / cf_n \end{cases} \quad (13)$$

解上述方程组可视为线性规划求解问题。定义误差方程:

$$R_{ij} = \sum_{p=1}^n T_{ip}w_{jp} - T_{ij} / cf_j \quad i=1,2,\dots,k; j=1,2,\dots,n \quad (14)$$

求解上式最小的误差平方和, 即:

$$\begin{aligned} \min Q(w_{11}, w_{12}, \dots, w_{nn}) &= \min \sum_{i=1}^k \sum_{j=1}^n R_{ij}^2 \quad (15) \\ &= \min \sum_{i=1}^k \sum_{j=1}^n (\sum_{p=1}^n T_{ip}w_{jp} - T_{ij} / cf_j)^2 \end{aligned}$$

式 (14) 即为目标函数。  $w_{ij}$  ( $i=1,2,\dots,n; j=1,2,\dots,n$ ) 为待定参数。将目标函数设为 PSO 算法中的适应度函数  $f_i$  ( $i=1,2,\dots,m$ )。

根据 PSO 的基本运算原理, 给出克服早熟停滞缺点后的改进的粒子群算法的步骤具体如下:

步骤 1: 参数初始化。学习最大迭代次数设为  $M$ ; 适应度误差精度  $\varepsilon > 0$ ; 惯性权重  $w$ ; 加速常数  $c_1, c_2$ ; 速度变化区间为  $[-v_{max}, v_{max}]$ ;  $r_1, r_2 \in [0,1]$ ; 停滞次数计数器 num=0 以及迭代次数计数器 n=0 等。

步骤 2: 随机产生  $m$  个粒子的种群, 初始化  $m$  个维度为  $D$  维的初始位置  $X_i = (x_{i1}, x_{i2}, \dots, x_{iD})$  以及  $m$  个随机初始速度。

步骤 3: 计算每个粒子对应位置的适应值  $f(X_i)$  ( $i=1,2,\dots,m$ )。记录  $B_i = X_i$ ,  $P_{best}$  为算法运算当前最优的  $f$  对应的  $X_i$ ,  $f_{best}$  表示第  $i$  个粒子当前获取到的最优值。并且得到当前个体极值  $P_{best}$ , 全局极值  $G_{best}$ 。

步骤 4: 根据公式(10)更新每个粒子的位置  $x_i$  和速度  $v_i$ , 并把速度限制规定的范围  $[-v_{max}, v_{max}]$  内, 利用迭

代次数  $j$  和算法总的迭代次数  $M$  按照线性递减计算惯性权重  $w$ , 则  $w = 0.9 - 0.6 * j / M$ .

步骤 5: 在  $\forall i < m$ , 用适应值函数  $f(x_i)$  对当前的  $x_i$  进行评价, 得到新的适应值  $f_i$ .

表 1 土壤腐蚀样本数据

$C(H_2O)$ (%)	$C(Cl^-)$ (mg/mg)	$C(SO_4^{2-})$ (mg/mg)	$C(CO_3^{2-})$ (mg/mg)	$C(HCO_3^-)$ (mg/mg)	PH	$v_m$ (g/dm 2.a)	$v_p$ (g/dm 2.a)
17.09	124.10	660.42	150.36	215.44	6.9	20.84	20.89
16.65	212.69	1561.05	575.09	4201.28	9.4	24.15	24.08
18.29	124.10	1981.29	302.71	1169.61	7.2	20.75	20.63
19.53	130.02	601.44	30.19	524.23	7.1	12.40	13.31
22.87	35.43	480.33	90.86	1246.51	7.0	51.31	51.32
...	...	...	...	...	...	...	...

步骤 6: 针对每一个粒子, 将当前适应值  $f_i$  与个体极值  $P_{best}$  作比较, 选择最优进行个体极值  $P_{best}$  的更新.

步骤 7: 针对每一个粒子, 将当前适应值  $f_i$  与全局极值  $G_{best}$  作比较, 选择最优进行全局极值  $G_{best}$  的更新.

步骤 8: 令  $X_q$  是  $m$  个随机粒子在该次迭代中得到的最优解的位置,  $B_s$  为当前得到全局最优解所在的位置, 则如果有  $f(X_q) < f(B_s)$ , 令  $B_s = X_q$ ,  $num = 0$ ; 否则,  $num = num + 1$ . 如果  $num = M$ , 则需要随机产生一个维度  $k (k = 1, 2, \dots, D)$ , 参照式(11), 将产生的  $k$  个新的随机值替换到  $B_s$  中的对应的  $k$  个位置上,  $num = 0$ .

步骤 9: 迭代继续,  $n = n + 1$ , 当  $n < M$ , 返回步骤 4; 否则迭代结束, 输出  $B_s$ , 其对应的适应度函数值  $f(B_s)$  即为最优解. 算法流程图如下图所示.

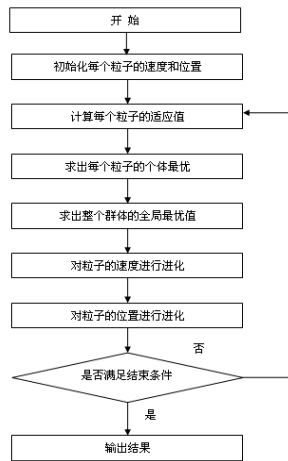


图 7 算法流程图

### 3 面向管网腐蚀数据的动态预测

#### 3.1 样本筛选及处理

以某地区管道土壤腐蚀部分样本数据作为实验训

练数据. 选取 28 测试点(试坑), 采集每个埋片点的阶段数据. 以正在服役的管道中取 Q235 钢作为埋藏点用的试件, 埋片选择的土壤类型有几种类型, 共检测了将近 4 年的埋片数据. 取表 1 中第一行所示的 2-8 单元格中所列的 7 个因素作为预测试验参数. 用于试验训练的样本集选取 20 个试坑的检测数据, 剩余 8 个试坑的检测数据为测试样本集.

为了消除样本中各参数取样的差异, 对原始数据进行标准化处理. 为了处理所有的网络输入和输出数据, 输入、输出取值范围为 0~1, 归一化采用最小规范化的方法进行处理. 若第  $i$  个样本数值的某一个特征指标为  $x_i$ , 则经过归一化后的数据  $x'_i$  为:

$$x'_i = \frac{x_i - \min x_i}{\max x_i - \min x_i} \tag{16}$$

#### 3.2 实现及应用

选取的试验数据是离散型, 对其进行归一化处理之后, 选取结构为: 7 个输入节点, 10 个模糊推理过程神经元隐层节点, 1 个腐蚀速率输出节点的模糊推理过程神经网络. 根据土壤腐蚀速率的变化趋势, 选取适合的多项式函数, 作为过程神经元中的核中心函数, 即:

$$X^j(t_i) = (1 + \sum_{l=1}^T v(t_l) \Delta t)^d \tag{17}$$

按照已经建立好的算法学习流程进行网络训练.  $\sigma$  由式(15)和式(16)求解得到, 式(17)中  $d \in (0, 1.5)$ . 因此网络训练的过程只需要求解连接权系数  $w_j, j = 1, 2, \dots, m$  即可. 经过式(17)迭代, 来调整误差函数中的权值. 学习效率  $\eta = 0.45$ , 误差精度取  $\varepsilon = 0.1$ , 迭代次数  $M = 863$ . 利用改进的粒子群算法对算法求解过程进行优化,  $v_p$  即为网络训练的结果. 网络训练成熟后, 预测土壤中 Q235 钢的腐蚀速率, 结果显示的预测准确率可达 85.6%. 图 8 为预测结果截图, 图中 “+” 表示 21#埋片试坑的腐蚀速率预测结果, “o” 表示与时间埋片结果, 即实际腐蚀速率.




图 8 预测结果对比

基于选取的实验室样本和7个影响土壤腐蚀的特征指标,模型的训练取得了比较好的预测结果,验证了该动态预测模型的有效性.

#### 4 结语

针对管道腐蚀速率这一问题,如果根据实际情况,提出快速防护措施,是世界范围内研究的重点.本章建立了一种改进的粒子群算法的模糊推理过程神经网络的动态预测模型,并将模型及算法应用于管道土壤腐蚀速率的动态预测中,与实测结果对比,显示预测模型的预测结果比较理想.此模型具有较好的鲁棒性、自学能力和很强的记忆能力,特别适用于类似土壤腐蚀这种多因素的、模糊性的复杂问题.通过试验样本的预测分析,验证了该模型及算法的有效性.

#### 参考文献

- 1 许少华,庞跃武,何新贵.一种模糊推理过程神经网络及其应用研究.控制与决策,2012,27(6): 933 - 936.
- 2 孙慧,张雪英,宁爱平.粒子群优化模糊神经网络在语音识别中的应用.数学的实践与认识,2010,06:113-118.
- 3 鞠初旭.模糊神经网络的研究及应用[学位论文].成都:电子科技大学,2012.
- 4 Gobi AF, Pedryez W. The potential of fuzzy neural networks in the realization of approximate reasoning engines. Fuzzy Sets and Systems 2006, 157: 2954-2973.
- 5 Zhou J, Li W, Zhu J. Particle swarm optimization computer simulation of Ni clusters. Transactions of Nonferrous Metals Society of China, 2008, (2): 410-415.
- 6 周岩,王盛,高传善,孙慰迟.基于改进粒子群算法的模糊神经网络及其在短时天气预报中的应用.计算机应用与软件,2010,5:234-237
- 7 张兴华.基于粒子群优化的模糊神经网络的柴油机故障诊断[学位论文].太原:中北大学,2012.
- 8 沙宝良.埋地管道的防腐参数采集传输与防腐性能评价[学位论文].大庆:东北石油大学,2013.