

# 一种参数优化旋转广义回归神经网络模型

黄金杰<sup>1</sup>, 夏静<sup>1</sup>, 满春涛<sup>1</sup>, 王松涛<sup>2</sup>

(1. 哈尔滨理工大学 自动化学院 黑龙江 哈尔滨 150080;

2 哈尔滨理工大学 测控技术与通信工程学院, 黑龙江 哈尔滨 150080)

**摘 要:** 针对传统广义回归神经网络的模型结构与数据分布失配问题和模型参数难以确定问题, 提出了一种参数优化旋转广义回归神经网络模型的设计方法。在传统广义回归神经网络模型的基础上, 通过坐标旋转, 增加了一个模型结构参数, 并采用粒子群算法对旋转广义回归神经网络的模型参数寻找最优值, 从而改进了广义回归神经网络模型精确度。两个工业实例的实验结果表明该方法的有效性。

**关键词:** 广义回归神经网络; 粒子群优化; 坐标旋转; 参数优化

中图分类号: TP183 文献标识码: A 文章编号: 1007-449X(2009)03-0442-06

## Parameter-optimized rotated general regression neural network model

HUANG Jin-jie<sup>1</sup>, XIA Jing<sup>1</sup>, MAN Chun-tao<sup>1</sup>, WANG Song-tao<sup>2</sup>

(1. College of Automation, Harbin University of Science and Technology, Harbin 150080, China; 2. College of Measurement-control Technology & Communication Engineering, Harbin University of Science and Technology, Harbin 150080, China)

**Abstract:** To resolve the problem of the mismatching of model structure and data distribution as well as the problem of determining model parameters difficultly in the traditional general regression neural network (GRNN), a scheme is proposed to design a parameter-optimized rotated general regression neural network. Through the coordinate rotation, an additional parameter of model structure is introduced to the traditional general regression neural network. Moreover, the particle swarm optimization algorithm is adopted to find the best values of parameters of the rotated GRNN; hence the model precision is improved. The experimental results of two industrial applications have shown the effectiveness of the method.

**Key words:** general regression neural network; particle swarm optimization; coordinate rotation; parameter optimization

## 1 引 言

1991年, Lockheed Palo Alto 研究实验室的 Donald Specht 博士提出了广义回归神经网络<sup>[1]</sup> (general regression neural network, GRNN)。GRNN

从概率密度函数 (probability density function, PDF) 出发, 利用观测样本直接计算出因变量对自变量的回归值, 不需要迭代, 网络最后收敛于样本量积聚最多的优化回归面。与其它统计学习方法如支持向量机 (support vector machine, SVM) 等相比, GRNN 在

收稿日期: 2008-11-06

基金项目: 国家自然科学基金 (60575036); 哈尔滨市科技创新人才研究专项资金项目 (2007RFXXG023); 哈尔滨理工大学优秀拔尖创新人才培养基金 (20080103)

作者简介: 黄金杰 (1967-), 男, 博士, 教授, 主要研究方向为复杂工业过程智能优化控制、模式识别与分类等;

夏 静 (1983-), 女, 硕士, 主要研究方向为过程优化控制;

满春涛 (1965-), 男, 博士, 教授, 主要研究方向为工业过程稳态优化控制;

王松涛 (1983-), 男, 硕士, 研究方向为模式识别、数字图像处理。

计算效率上具有明显的优势,得到了人们的重视和应用<sup>[2,3]</sup>。

但是,由于 GRNN 的基函数是径向对称的,通常假定训练样本的每维数据都呈高斯型分布,需要确定的主要参数是隐回归单元核函数中的光滑因子,但是当训练样本的各维数据分布与高斯型分布差别较大时,GRNN 往往产生较大的预测误差<sup>[4]</sup>。

为了克服上述缺点,采用一种改进的广义回归神经网络:旋转广义回归神经网络<sup>[4]</sup>(rotated general regression neural network, RGRNN)。RGRNN 的基本思想是在一个变换坐标系里对网络进行训练,引入了另一个模型结构参数变量:旋转角度。由于 RGRNN 也是一种立即学习型神经网络,在训练之前需要事先确定模型的结构参数:旋转角度和光滑因子。如何确定这两个参数的最优值成为 RGRNN 设计中的一个关键问题。为此,采用粒子群优化算法对旋转广义回归神经网络的结构参数和寻找最优值,从而得到一种参数优化的旋转广义回归神经网络模型,并进行相应的数据实验研究。

## 2 广义回归神经网络

GRNN 的理论基础是非线性核回归分析,非独立变量  $y$  相对于独立变量  $x$  的回归分析实际上是计算具有最大概率值的  $y_0$ 。

设随机变量  $x$  和  $y$  的联合概率密度函数为  $f(x, y)$ , 已知  $x$  的观测值为  $X$ , 则  $y$  相对于  $X$  的回归,即条件均值为

$$\hat{Y} = E[y | X] = \frac{\int y f(X, y) dy}{\int f(X, y) dy} \quad (1)$$

对于未知的概率密度函数  $f(x, y)$ , 可由  $x$  和  $y$  的观测样本经非参数估计得到

$$\hat{f}(X, Y) = \frac{1}{(2)^{\frac{p+1}{2}} n} \times \prod_{i=1}^n \exp\left[-\frac{(X - X_i)^T (X - X_i)}{2^2}\right] \times \exp\left[-\frac{(Y - Y_i)}{2^2}\right] \quad (2)$$

式中:  $X_i, Y_i$  为随机变量  $x$  和  $y$  的第  $i$  个样本观测值;  $\sigma$  是光滑因子(或核宽度);  $n$  为样本数目;  $p$  是随机变量  $x$  的维数。

用  $\hat{f}(X, Y)$  代替  $f(x, y)$ , 代入式 (1) 中, 并交换积分与求和顺序, 可得

$$\hat{Y}(X) = \frac{\sum_{i=1}^n \exp\left[-\frac{(X - X_i)^T (X - X_i)}{2^2}\right] \times \int y \exp\left[-\frac{(y - Y_i)^2}{2^2}\right] dy}{\sum_{i=1}^n \exp\left[-\frac{(X - X_i)^T (X - X_i)}{2^2}\right] \times \int \exp\left[-\frac{(y - Y_i)^2}{2^2}\right] dy} \quad (3)$$

对于式 (3) 中的积分项, 利用性质

$$\int_{-\infty}^{+\infty} x \exp(-x^2) dx = 0$$

进行化简, 可得

$$\hat{Y}(X) = \frac{\sum_{i=1}^n Y_i \exp\left[-\frac{(X - X_i)^T (X - X_i)}{2^2}\right]}{\sum_{i=1}^n \exp\left[-\frac{(X - X_i)^T (X - X_i)}{2^2}\right]} \quad (4)$$

在式 (4) 中, 估计值  $\hat{Y}(X)$  为所有样本观测值  $Y_i$  的加权平均, 每个观测值  $Y_i$  的权重因子为相应的样本  $X_i$  和  $X$  之间欧氏距离平方的指数。

可以看出, 广义回归神经网络相当于一个结构形式确定的拟合函数。当训练样本的某维或者某些维数据在原始坐标系下的分布与高斯分布相接近时, 广义回归神经网络通过改变参数光滑因子的取值便可以得到较好的拟合结果; 如果数据分布与高斯分布差别太大, 单靠调节光滑因子的值, 将难以得到最佳的拟合。但是如果通过对原坐标系进行旋转, 找到一个最佳的拟合角度, 在此基础上再对训练样本进行拟合, 将在某种程度上克服广义回归神经网络的这一缺点。RGRNN 保留了神经网络的立即学习能力, 但也带来了模型参数耦合和难以整定的困难。为了克服这一困难, 采用粒子群算法对参数进行寻优, 得到一种参数优化的旋转广义回归神经网络模型。

## 3 参数优化旋转广义回归神经网络设计

设输入向量  $X = (x_1, x_2, \dots, x_i, \dots, x_p)$ , 对应的网络输出为  $Y$ 。本文只研究针对产生最大拟合误差的某一维数据进行坐标旋转, 以设计一个参数优化的旋转广义回归神经网络。

### 3.1 旋转维的确定

首先利用 GRNN 对全部训练样本进行拟合, 采用留一法选取一个光滑因子参数值, 用于旋转维的确定。方法如下:

1) 将训练样本的每维数据  $x_i$  分别与输出样本  $Y$  进行拟合, 第  $i$  维样本数据的拟合均方误差记为  $E_{i1}$ , ( $i=1, 2, \dots, p$ ), 最大的拟合均方误差记为  $E_1$ , 即  $E_1 = \max\{E_{i1} | i=1, 2, \dots, p\}$ ;

2) 分别去掉训练样本中的一维数据  $x_i$ , 用剩余维的训练样本与输出样本  $Y$  进行拟合, 记去掉第  $i$  维样本数据时对应的拟合均方误差为  $E_{i2}$ , ( $i=1, 2, \dots, p$ ), 最小的拟合均方误差为  $E_2$ , 即  $E_2 = \min\{E_{i2} | i=1, 2, \dots, p\}$ 。

如果第  $i$  维样本数据对应的上述误差满足如下关系

$$E_{i1} = E_1, \text{ 且 } E_{i2} = E_2. \quad (5)$$

即第  $i$  维样本数据和输出样本拟合时的误差最大, 而去掉第  $i$  维样本数据后的拟合误差最小, 则说明用 GRNN 对训练样本拟合时, 由第  $i$  维样本数据引起的拟合误差较大。因此, 对第  $i$  维数据进行旋转。

### 3.2 基于一维旋转的 RGRNN

对选出的第  $i$  维数据进行旋转, 在新的坐标下建立旋转广义回归神经网络模型。

假设在新坐标下的输入向量为  $X = \{x_1, x_2, \dots, x_i, \dots, x_p\}$ , 输出向量为  $Y$ 。则有如下关系

$$\begin{bmatrix} x \\ Y \end{bmatrix} = \begin{bmatrix} \cos & -\sin \\ \sin & \cos \end{bmatrix} \begin{bmatrix} x \\ Y \end{bmatrix}. \quad (6)$$

新坐标下的回归方程为

$$\hat{Y}(X) = \frac{\sum_{i=1}^n Y^i \exp\left(-\frac{D_i^2}{2}\right)}{\sum_{i=1}^n \exp\left(-\frac{D_i^2}{2}\right)}. \quad (7)$$

式中:  $(X^i, Y^i)$ ,  $i=1, 2, \dots, n$  是新坐标里的训练向量, 定义标量函数  $D_i$  如下:

$$\begin{aligned} D_i^2 &= (X - X^i)^T (X - X^i) = \\ &= \sum_{j=1, j \neq i}^p (x_j - x_j^i)^2 + (x_i - x_i^i)^2 = \\ &= d_i^2 + [(x_i - x_i^i) \cos - (Y - Y^i) \sin]^2. \end{aligned} \quad (8)$$

式中

$$d_i^2 = \sum_{j=1, j \neq i}^p (x_j - x_j^i)^2. \quad (9)$$

为描述简单, 定义

$$A_i = a(x_i - x_i^i)^2, \quad (10)$$

$$B_i = b(Y - Y^i)^2, \quad (11)$$

$$C_i = c(x_i - x_i^i)(Y - Y^i), \quad (12)$$

$$D_i = \frac{d_i^2}{2}. \quad (13)$$

其中:

$$\left. \begin{aligned} a &= \frac{\cos^2}{2^2}; \\ b &= \frac{\sin^2}{2^2}; \\ c &= \frac{-2 \sin \cos}{2^2}. \end{aligned} \right\} \quad (14)$$

简化后, 式 (7) 可以写成

$$\hat{Y}(X) = \frac{\sum_{i=1}^n Y^i \exp(- (A_i + B_i + C_i + D_i))}{\sum_{i=1}^n \exp(- (A_i + B_i + C_i + D_i))} = \frac{\sum_{i=1}^n Y^i \exp(- (qY + r_i Y + z_i + D_i))}{\sum_{i=1}^n \exp(- (qY + r_i Y + z_i + D_i))}. \quad (15)$$

式中:

$$\left. \begin{aligned} q &= b; \\ r_i &= -2bY^i + c(x_i - x_i^i); \\ z_i &= bY^2 + a(x_i - x_i^i)^2 - cY^i(x_i - x_i^i). \end{aligned} \right\} \quad (16)$$

式 (16) 代入式 (15) 得

$$\hat{Y}(X) = \frac{\sum_{i=1}^n Y^i \exp(- (r_i Y + z_i + D_i))}{\sum_{i=1}^n \exp(- (r_i Y + z_i + D_i))}. \quad (17)$$

根据坐标转换关系

$$\left. \begin{aligned} Y &= x_i \sin + Y \cos, \\ Y^i &= x_i^i \sin + Y^i \cos. \end{aligned} \right\} \quad (18)$$

最后, 网络输出为

$$\hat{Y}(X) = \frac{1}{\cos} \frac{\sum_{i=1}^n Y^i \exp(- (r_i Y + z_i + D_i))}{\sum_{i=1}^n \exp(- (r_i Y + z_i + D_i))} - x_i \tan. \quad (19)$$

### 3.3 光滑因子 和旋转角度 的寻优

粒子群算法 (particle swarm optimization, PSO) 是一种基于群体智能理论的优化算法<sup>[5]</sup>, 群体中的粒子在每次迭代搜索过程中, 通过跟踪群体两个极值: 粒子本身所找到的最优解  $P_{best}$  和群体找到的最优解  $G_{best}$ , 来动态调整自己的位置和速度, 完成对问题的寻优。具有算法简单, 全局寻优能力强等优点。采用 PSO 算法来寻求光滑因子 和旋转角度 的最优参数值, 进而设计出参数优化的旋转广义回归神经网络模型。步骤如下:

a) 对粒子群中粒子的位置  $x$  和速度  $v$  进行随机

初始化,并设定群体规模  $m = 50$ , 粒子维数  $q = 2$  (分别代表旋转角度和光滑因子), 最大迭代次数  $T = 1\ 000$ , 停止迭代的最小适应度值为  $= 0.001$ 。

b) 计算每个粒子的适应度 (目标函数值),

$$\min f = \frac{1}{n} \sum_{k=1}^n (Y(x) - Y)^2. \quad (20)$$

式中: 函数  $f$  表示预测均方误差;  $Y(x)$  是输入样本  $x$  的预测值;  $Y$  是样本输出值;  $n$  是输入样本的个数。

c) 计算粒子  $x_i, i = 1, 2, \dots, m$  所经历的最好位置, 也就是粒子  $x_i$  所经历过的具有最小的均方误差的位置,

$$p_i = \begin{cases} x_i^t, & f(p_i) > f(x_i^t), \\ p_i, & f(p_i) \leq f(x_i^t). \end{cases} \quad (21)$$

计算群体中所有粒子经历过的最好位置, 即全局最好位置,

$$p_g = p_i: f(p_i) = \min\{f(p_1), f(p_2), \dots, f(p_m)\}. \quad (22)$$

d) 根据式子

$$v_{id}^{t+1} = v_{id}^t + c_1 r_1 (p_{id} - x_{id}^t) + c_2 r_2 (p_{gd} - x_{id}^t), \quad (23)$$

$$x_{id}^{t+1} = x_{id}^t + v_{id}^{t+1}, \quad (24)$$

对速度和位置进行更新。式中:  $x_{id}^t, (i = 1, 2, \dots, m; d = 1, 2)$  表示在第  $t$  次迭代计算时群体中第  $i$  个粒子第  $d$  维的数值;  $v_{id}^t$  是其对应的速度;  $c_1, c_2$  为加速常数 (学习速率), 取为 2;  $r_1, r_2$  为  $[0, 1]$  均匀分布的随机数。

e) 判断结束条件。若  $f(p_g)$  或迭代次数  $t = T$ , 则迭代结束, 输出结果; 否则,  $t = t + 1$ , 返回步骤 b), 继续进行。

## 4 实例研究

对两个实例进行实验研究: 某化工企业过氧化氢异丙苯的分解过程和某风洞平板边界层压力实验<sup>[6]</sup>。将提出的基于粒子群算法的参数优化旋转广义回归神经网络 (PSO-RGRNN), 与采用粒子群算法寻找训练参数最优值的 GRNN (PSO-GRNN) 和采用留一法寻找训练参数最优值的 GRNN (LYF-GRNN) 分别应用于这两个实例建模, 并进行结果比较。实验过程如下:

i) 根据式 (5) 规则选择需要旋转的数据维。

ii) 从  $N$  组数据样本中随机选取  $m$  个样本数据作为测试样本  $\left( \text{一般地 } m < \frac{N}{3} \right)$ , 其余的作为训练样本。

iii) 对训练样本分别用 LYF-GRNN、PSO-GRNN 和 PSO-RGRNN 进行拟合, 并在测试样本集上进行

测试, 记录测试样本数据在现场样本数据中的序号  $k_1, k_2, \dots, k_m$  以及相应的三种方法在本次实验中各自的预测误差  $E_i = y_i - \hat{y}_i (i = k_1, k_2, \dots, k_m)$ , 并求取三种方法各自相应的预测均方误差,  $E_{mse} = \frac{1}{\sum_{i=k_1}^{k_m} m} E_i^2$ , 这里  $y_i$  和  $\hat{y}_i$  分别表示第  $i$  号数据样本的输出变量的真实值和预测值。

iv) 重复步骤 ii)、iii) 共 20 次。记录现场样本数据在这 20 次随机选取测试样本中出现的次数  $r_k (k = 1, 2, \dots, N)$ , 计算相同序号的测试样本数据在各方法下的平均预测误差  $E_{km} = \frac{1}{r_k} \sum_{j=1}^{r_k} (y_k - \hat{y}_{kj})$ , 这里  $\hat{y}_{kj}$  表示各方法对在测试样本中第  $j$  次出现的第  $k$  号数据样本的输出变量预测值。最后, 计算三种方法在这 20 次随机选取实验后各自的均方误差的平均值,  $E_{mse} = \frac{1}{20} \sum_{l=1}^{20} E_{mse}^{(l)}$ , 其中  $E_{mse}^{(l)}$  表示在第  $l$  次随机实验中步骤 iii) 所计算的预测均方误差  $E_{mse}$ 。

v) 画出  $S$  个样本数据的平均预测曲线。为客观起见, 找出在这 20 次随机实验中出现在测试样本中 3 次及 3 次以上的数据样本, 设其数目为  $S (1 \leq S \leq N)$ , 画出各方法在这  $S$  个数据样本上的平均预测误差曲线。

实验结果如下:

1) 某石化企业过氧化氢异丙苯 (CHP) 的分解单元。过氧化氢异丙苯的分解单元有 5 个参数, 包括: 反应塔压力  $x_1$  (30 ~ 50 kPa)、反应塔液位  $x_2$  (25% ~ 50%)、过氧化氢异丙苯  $x_3$  流量 (10.44 ~ 20 m<sup>3</sup>/h)、分解器温度 (冷凝液控制)  $x_4$  (55 ~ 65) 和粗产品温度  $y$  (70 ~ 100)。其中, 前 4 个参数为自变量, 粗产品的温度  $y$  为因变量。采集了现场 18 组数据如表 1 所示。从 18 组样本数据中随机选取 3 组数据作为测试样本, 剩余 15 组数据作为训练样本。

首先利用 GRNN 按照 3.1 节方法对 CHP 分解单元各维数据进行拟合, 拟合情况如表 2 所示。

其中:  $Q$  表示整体训练样本拟合;  $Q_{iv} (i = 1, 2, \dots, 4)$  表示第  $i$  维输入样本和输出样本拟合,  $Q_j (j = 1, 2, \dots, 4)$  表示去掉第  $j$  维数据的其他样本输入和输出样本拟合。由表 2 的拟合均方误差数据可知, 输入样本的第 4 维数据与输出样本拟合的均方误差最大,  $E_{41} = 18.411$ , 而去掉以后剩余维的输入样本与输出样本拟合的均方误差又最小,  $E_{42} = 1.667$ , 满足旋转维关系式 (5), 所以对输入样本的第 4 维数据进行旋转。

表 1 CHP分解单元现场数据样本

Table 1 Sampling data of CHP decomposing unit

$x_1$	$x_2$	$x_3$	$x_4$	$y$
0.200	0.090	0.076	0.484	14.661
0.350	0.180	0.106	0.512	15.567
0.500	0.270	0.136	0.657	15.892
0.650	0.360	0.166	0.742	18.637
0.800	0.450	0.197	0.841	22.875
0.950	0.540	0.227	0.863	23.749
1.100	0.630	0.257	0.892	26.340
1.250	0.720	0.287	0.932	28.959
1.400	0.810	0.318	0.952	30.497
1.550	0.900	0.348	0.973	31.040
1.700	0.990	0.378	0.979	35.078
1.850	1.080	0.408	0.981	40.253
2.000	1.170	0.439	0.990	45.921
2.150	1.260	0.469	0.992	49.223
2.300	1.350	0.499	0.994	52.847
2.450	1.440	0.529	0.996	57.945
2.600	1.530	0.559	1.000	59.958
2.750	1.620	0.590	1.012	63.008

表 2 CHP分解单元各维拟合情况

Table 2 Fitting results of each dimension of CHP decomposition unit

GRNN 拟合情况	光滑因子取值	拟合均方误差
Q	0.099	1.675
Q <sub>1y</sub>	0.029	1.669
Q <sub>2y</sub>	0.017	1.669
Q <sub>3y</sub>	0.006	1.622
Q <sub>4y</sub>	0.014	18.411
Q <sub>1</sub>	0.055	1.870
Q <sub>2</sub>	0.086	1.702
Q <sub>3</sub>	0.097	1.677
Q <sub>4</sub>	0.034	1.667

分别应用 LYF-GRNN、PSO-GRNN 和 PSO-RGRNN 三种方法对此过氧化氢异丙苯的分解单元按实验过程步骤 ii) ~ v) 进行建模。

在 20 次测试样本的随机选取中,共有 11 个样本数据 (序号分别是 4、6、7、9、10、11、13、14、15、16、17) 在测试数据集中出现 3 次或者 3 次以上,图 2 为三种方法在这 11 个样本数据的平均预测误差曲线。

从三种方法在测试样本集上得到的总的预测均方误差均值  $E_{\text{mmse}}$  来看,PSO-RGRNN 的预测均方误差最小,为 0.063,采用 PSO-GRNN 的预测均方误差

为 2.742,而采用 LYF-GRNN 的预测均方误差最大,为 3.411。具体到这三种方法在各个测试样本上的预测误差,则由图 2 可以看出,在所示的 11 个数据样本上,参数优化旋转广义回归神经网络的平均预测误差均比其它两种方法都小,这进一步证明了所提方法的有效性。

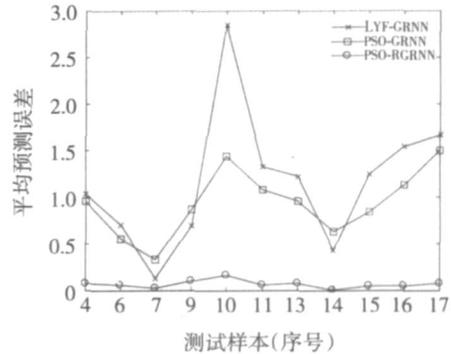


图 2 CHP分解单元的平均预测误差

Fig 2 Average predictive error of CHP decomposing unit

2) 某风洞平板边界层压力实验 (简称风洞试验)。输入变量为  $P$ , 表示压力系数; 输出变量为  $T$ , 表示平板边界厚度, 此风洞试验采集数据如表 3 所示。

表 3 风洞实验采集数据

Table 3 Data collected in wind tunnel test

$P$	$T$	$P$	$T$	$P$	$T$
0.487	0.312	0.892	11.087	0.989	27.697
0.512	1.156	0.923	12.479	0.992	32.480
0.625	1.323	0.945	13.756	0.994	34.505
0.751	3.909	0.970	14.001	0.996	37.915
0.832	7.999	0.980	17.696	1.000	41.132
0.854	8.716	0.983	24.480	1.021	44.263

分别应用 LYF-GRNN、PSO-GRNN 和 PSO-RGRNN 三种方法于此风洞试验建模中。三种方法在测试样本集上得到的总的预测均方误差均值  $E_{\text{mmse}}$  依次为 26.698、9.544 和 0.015。PSO-RGRNN 的预测均方误差的均值最小,改进效果非常明显。

在 20 次测试样本的随机选取中共有 12 个样本数据在测试数据集中出现 3 次或者 3 次以上,三种方法对这 12 个样本数据 (序号为 1、4、7、8、9、10、11、13、14、15、16、17) 的平均预测误差曲线如图 3 所示。可以看出,参数优化旋转广义回归神经网络模型在每一个测试数据样本上的平均预测误差都比 PSO-GRNN 和 LYF-GRNN 的平均预测误差要小得多。

综上两个例子的实验结果,基于粒子群算法寻找网络结构最优值的旋转广义回归神经网络与采用留

一法寻找参数最优值的广义回归神经网络和用粒子群算法寻找参数最优值的广义回归神经网络相比,其预测均方误差的平均值和平均预测误差都是最小的,预测效果最好,从而验证了本文方法的有效性。

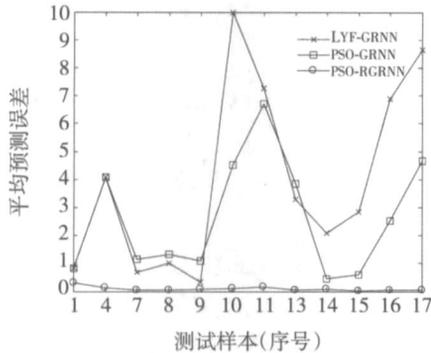


图 3 风洞实验平均预测误差

Fig 3 Average prediction error of wind tunnel test

## 5 结 语

本文提出的参数优化旋转广义回归神经网络模型是对传统广义回归神经网络的改进,可以在训练样本数据偏离高斯分布较大的情况下,通过旋转坐标系,并采用粒子群优化算法,找到一个最佳拟合角度,在新的旋转坐标下建立相应的广义回归神经网络。与传统的广义回归神经网络模型相比,减少了人为设定模型参数值所造成的不利影响,具有更高

的拟合精度和更好的预测效果。需要说明的是,本文仅是对样本数据中一维数据进行旋转的研究,对于多维数据同时旋转需要做进一步的研究。

## 参 考 文 献:

- [1] SPECHT D F. A general regression neural network [J]. *IEEE Transactions on Neural Networks*, 1991, 2(6): 568 - 576
- [2] BURCU E, TULAY Y. Improving classification performance of sonar targets by applying general regression neural network with PCA [J]. *Expert Systems with Applications*, 2008, 35 (1/2): 472 - 475.
- [3] JELENA P, SVETLANA I, ZORICA D, et al. An investigation into the usefulness of generalized regression neural network analysis in the development of level A in vitro - in vivo correlation [J]. *European Journal of Pharmaceutical Sciences*, 2007, 30 (3/4): 264 - 272.
- [4] GHOLAMREZAEIM, GHORBANIAN K. Rotated general regression neural network [C] // *Proceedings of International Joint Conference on Neural Networks*, August 12 - 17, Orlando, Florida, USA, 2007: 1959 - 1964.
- [5] DEL VALLE Y, VENA YAGAMOORTHY G K, MOHAGHEGH I S, et al. Particle swarm optimization: basic concepts, variants and applications in power systems [J]. *IEEE Transactions on Evolutionary Computation*, 2008, 12(2): 171 - 195.
- [6] SOLTANI M R, GHORBANIAN K. *Wind Tunnel Calibration* [R]. Tehran: Sharif University of Technology, 2004.

(编辑:刘素菊)