

# 基于免疫神经网络的陀螺仪漂移预测

蔡曦, 胡昌华, 刘炳杰

(第二炮兵工程学院 302 教研室, 西安 710025)

**摘要:** BP 神经网络可用于预测陀螺仪漂移误差, 但容易陷入局部极值, 训练速度很慢。针对上述缺点, 该文提出了一种基于免疫算法的神经网络, 以样本输出为抗原、神经网络权值矩阵为抗体, 通过克隆、变异、抑制等步骤找到最优抗体, 将最优抗体用于陀螺仪漂移预测。仿真试验显示, 免疫训练算法能有效优化网络权值, 基于该模型的漂移预测精度较高。

**关键词:** 免疫算法; 神经网络; BP 算法; 陀螺仪漂移; 预测

## Gyroscopic Drift Forecasting Based on Immune Neural Network

CAI Xi, HU Chang-hua, LIU Bing-jie

(302 Unit, the Second Artillery Engineering Institute, Xi'an 710025)

**【Abstract】** Back Propagation(BP) neural network can be used to forecast Gyroscopic drift. But BP algorithm inclines to fall into local extremum and its training speed is very slow. To overcome the limitation, this paper presents a novel training method based on immune algorithm. The sample output is regarded as the antigen and the weight matrix as antibody. Satisfied antibody can be found after cloning, mutating and restraining. The trained immune neural network is used to forecast gyroscopic drift. Simulation experiments reveal that the algorithm is effective, and the model leads to a precise result in gyroscopic drift forecasting.

**【Key words】** immune algorithm; Neural Network(NN); Back Propagation(BP) algorithm; gyroscopic drift; forecasting

作为导航系统核心的惯性器件, 陀螺仪在整个导航系统中起着十分重要的作用。影响陀螺仪工作精度的一个重要指标是陀螺漂移。陀螺仪的漂移是指对初始零角或参考产生的一个缓慢变化量, 它会带来方向度数的误差, 使惯导系统的性能不断下降, 以致无法正常工作, 引发系统故障<sup>[1]</sup>。利用历史数据对陀螺漂移进行预测, 及时评价陀螺仪性能的可靠性, 对于提高整个导航系统的精度意义重大。陀螺仪的测试寿命是有限的, 实际得到的陀螺漂移数据都是小样本数据, 而且这些数据构成的时间序列一般都是非线性的。传统的时间序列预测模型能很好地处理线性时间序列, 但对于非线性时间序列效果并不好, 另外, 传统预测模型本身的限制条件影响了它的应用范围。人工神经网络由于具有任意逼近非线性函数的特征, 在时间序列预测特别是非线性领域中的应用已非常广泛, 并取得了很好的效果<sup>[2]</sup>。前向网络在神经网络研究中占有很重要的地位, 其中的 BP(Back Propagation)网络研究得最多, 并广泛应用于许多领域。BP 网络所采用的 BP 算法是一种梯度下降算法, 收敛速度慢, 且容易陷入局部极值, 无法使网络性能达到最优。近年来, 许多研究者采用进化规划和遗传算法来设计神经网络的结构和权值, 取得了不错的成果。但是在进化学习中, 如果初始解群分布不均匀, 还是容易出现未成熟收敛、陷入局部极值<sup>[3]</sup>。

### 1 陀螺仪漂移预测神经网络模型

#### 1.1 陀螺仪漂移预测的理论基础

陀螺仪漂移预测的历史数据是一组非线性的时间序列, 对漂移的预测就是对时间序列的预测。时间序列预测的基本思想是认为时间序列的历史将延续到未来, 即根据事物发展的惯性规律作出预测<sup>[4]</sup>。

假设观测样本为  $x_1, x_2, \dots, x_n$ , 用其中  $m$  个值预测  $n+1$  时

刻的值  $x_{n+1}$ , 即建立从  $x_1, x_2, \dots, x_n$  到  $x_{n+1}$  的非线性映射关系  $f$ :

$$\begin{aligned} x_{n+1} &= f(x_1, x_2, \dots, x_n) + e_{n+1} = \hat{x}_{n+1} + e_{n+1} \\ \hat{x}_{n+1} &= f(x_1, x_2, \dots, x_n) \end{aligned} \quad (1)$$

其中,  $e_{n+1} = x_{n+1} - \hat{x}_{n+1}$  为预测误差;  $\hat{x}_{n+1}$  为预测值。

根据 Kolmogorov 连续性定理和 Hornik 等人的研究成果<sup>[4-5]</sup>, 具有单隐层的神经网络能以任意精度逼近任意函数。因此, 神经网络用于预测是可行的。

#### 1.2 免疫神经网络预测模型

对网络权值进行训练前, 必须先确定网络的结构参数, 包括隐层数、隐层节点数和激活函数等。对陀螺仪漂移数据进行预测, 需要建立一个多输入单输出的系统, 即神经网络的输出节点数为 1, 并假定输入节点数、隐层节点数和激活函数已知。将网络权值作为待训练和优化的参数, 即免疫算法中的抗体。网络结构如图 1 所示。




图 1 免疫神经网络结构

**作者简介:** 蔡曦(1982-), 男, 硕士研究生, 主研方向: 控制系统测试, 故障智能诊断与预报技术; 胡昌华, 教授、博士生导师; 刘炳杰, 博士研究生

**收稿日期:** 2007-01-30 **E-mail:** caiwhat@sohu.com

其中, 输入层端点数为  $N$ ; 隐层节点数为  $M$ ; 输出层节点数为 1; 由输入端点至隐含层节点的权重表示为  $\omega_{jh}$ ; 由隐层节点至输出节点的权重表示为  $\omega_h$ ; 其中的下标  $j=1, 2, \dots, N$ ,  $h=1, 2, \dots, M$ 。

若采用  $K$  个训练样本对  $\{x_i, y_i, i=1, 2, \dots, K\}$  训练网络, 令  $X = [x_1, x_2, \dots, x_K] \in R^{N \times K}$ ,  $Y = [y_1, y_2, \dots, y_K] \in R^{1 \times K}$ , 则  $K$  个不同的输入样本在隐层节点的输出矩阵为

$$X' = f(W_1 \cdot X) \quad (2)$$

其中,  $X' \in R^{M \times K}$ ;  $W_1 = (\omega_{jh})_{M \times N}$ ;  $f(\cdot)$  是隐层的转移函数。

从隐层节点到输出层节点的输出矩阵为

$$Y' = W_2 \cdot X' \quad (3)$$

其中,  $W_2 = (\omega_h)_{1 \times M}$ 。

定义网络输出端的误差代价函数为

$$E = \|Y - Y'\|^2 = \|Y - W_2 \cdot X'\|^2 = \|Y - W_2 \cdot f(W_1 \cdot X)\|^2 \quad (4)$$

其中,  $\|\cdot\|$  表示范数。

网络学习的目的是通过调节网络权重  $W_1$  和  $W_2$ , 使得  $E$  趋于最小。由于该误差代价函数是个复杂的非线性函数, 其对应的误差曲面存在局部最小点, 因此本文采用全局寻优能力较强的免疫算法训练权重。

## 2 神经网络的免疫训练算法

### 2.1 算法的实现

#### 2.1.1 抗原抗体设计

将样本中的输出值作为抗原  $Ag$ , 即通过训练后网络期望达到的值; 每个抗体  $Ab$  中包含一组网络权值, 即对应一种网络权值结构。

#### 2.1.2 亲和力计算

抗体  $Ab_i$  与抗原  $Ag_i$  之间的亲和力表示为网络的误差函数的倒数, 记为  $f_i$ :

$$f_i = \frac{1}{E + a} \quad (5)$$

其中,  $E$  是抗体所对应的网络的误差函数;  $a$  是常数, 避免  $E=0$  时算法溢出。

抗体  $Ab_i$  和抗体  $Ab_j$  的亲和力记为  $s_{ij}$ :

$$s_{ij} = 1 - \frac{\|Ab_i - Ab_j\|}{\max_{\substack{1 \leq i \leq n \\ 1 \leq j \leq n}} \|Ab_i - Ab_j\|}, \quad i=1, 2, \dots, n, \quad j=1, 2, \dots, n \quad (6)$$

其中,  $\|Ab_i - Ab_j\|$  是  $Ab_i$  与  $Ab_j$  两向量的范数, 距离越小, 亲和力越大; 抗体越相似, 亲和力越大, 抗体之间的抑制作用就越强。

#### 2.1.3 抗体克隆和变异

抗体的克隆数和变异率由抗体与抗原之间亲和力决定。抗体克隆的数目用  $N_c$  表示:

$$N_c = \sum_{i=1}^n \text{round}(N - \text{norma}(f)N) \quad (7)$$

其中  $N$  为抗体数目;  $\text{round}(\cdot)$  为最近整数取整函数;  $\text{norma}(\cdot)$  为归一化函数。

克隆细胞要经历变异过程:

$$Ab_i^* = Ab_i + \alpha \cdot N(0, 1) \quad (8)$$

其中,  $\alpha = (1/\beta) \cdot \exp(-f_i)$  为抗体变异率;  $N(0, 1)$  为高斯随机数;  $f_i$  为抗体-抗原亲和力值。

由以上过程可见, 抗体的克隆和变异大大地扩大了抗体的搜索范围, 对找到全局最优值起到很重要的作用。

### 2.1.4 抗体抑制

当抗体间的亲和力很大时, 说明它们之间非常相似, 这些相似个体容易使算法在训练过程中陷入未成熟收敛。因此, 对抗体-抗体亲和力  $s_{ij}$  超过一定阈值的个体必须进行抑制。

根据式(9)选择抑制阈值  $t_s$ , 清除相似抗体:

$$t_s = \frac{\sum_{i=1}^N \sum_{j=1}^N s_{ij}}{N(N-1)/2} \quad (9)$$

其中,  $s_{ij}$  为抗体间的亲和力;  $N$  为抗体的总个数。

随机产生新抗体个体加入抗体矩阵, 以取代清除掉的抗体, 这样, 保证了抗体的多样性, 避免了算法陷入局部极值。

## 2.2 算法的步骤

**步骤 1** 随机产生初始抗体矩阵;

**步骤 2** 计算抗体-抗原亲和力  $f_i$ ;

**步骤 3** 根据亲和力值对每个抗体进行克隆和变异;

**步骤 4** 计算变异后的抗体-抗原亲和力  $f_i$  和抗体-抗体亲和力  $s_{ij}$ ;

**步骤 5** 对每个抗体, 选择克隆后抗体-抗原亲和力  $f_i$  最大的个体, 并保留最优抗体;

**步骤 6** (抗体的抑制和更新) 计算抗体抑制阈值, 亲和力越大, 抗体越相似, 抑制作用越强, 清除亲和力值高于抑制阈值的抗体; 并随机产生新的抗体加入抗体矩阵;

**步骤 7** 如果满足终止条件, 优化训练过程结束, 否则返回步骤 2, 直到满足终止条件为止。

本文采用了设置迭代次数和判断误差值范围相结合的终止条件: 如果网络训练误差值在预设的迭代次数中达到了精度要求, 则停止优化过程。

## 3 实例仿真分析

陀螺仪是核心的惯性器件, 它的可靠性直接影响到导弹控制系统的性能。有资料表明, 惯性平台中 60% 属于陀螺故障。以某型导弹捷联惯性测量组合中的双轴动力调谐速率陀螺仪某段时间内的 33 个逐日漂移系数时间序列数据作为研究对象, 应用本文的免疫神经网络对该时间序列作预测, 通过数值仿真实验对陀螺仪漂移进行预测, 为陀螺仪的性能预报提供参考。

首先对样本数据进行归一化, 然后将归一化后的数据分组: 6 个数据组成一个样本, 其前 5 个值作为输入数据, 后 1 个值是期望输出, 如表 1 所示。

表 1 时间序列预测样本的形成

| 输入数据                            | 期望输出     |
|---------------------------------|----------|
| $x_1, x_2, \dots, x_5$          | $x_6$    |
| $x_2, x_3, \dots, x_6$          | $x_7$    |
| ...                             | ...      |
| $x_{28}, x_{29}, \dots, x_{32}$ | $x_{33}$ |

将形成的 28 个样本分成 2 组, 前 19 个构成训练样本, 用于训练网络权值, 后 9 个构成检验样本用于预测。利用免疫算法对网络权值进行学习和训练, 免疫神经网络误差结果如图 2 所示。

分别采用免疫神经网络、基于梯度下降法训练权值的 BP 网络和基于 LM 训练算法的 LMBP 网络对以上样本进行训练和预测。结果如表 2 所示。

(下转第 241 页)

因为每个数据包必须传递相同位数，即每个中继中的相同数量电容必须拴在一起（互连电容除外）。由于每个中继的互连能量远低于每个中继的路由能量，因此建校网络距离是减少动态功耗的有效方式。




图5 NoC体系结构功耗比较

漏电功耗的最坏情况是假设在一个有效仿真周期中，所有缓冲器都处于上电过程，NoC结构还在传输有效数据包。当控制单元和横杆结合的数目较小时，聚束环面NoC结构具有最小的漏电功耗，并保持很好的性能。

### 5 结束语

NoC作为基于多处理器技术的一种新型计算集成形式，涉及硬件通信结构、中间件、操作系统通信服务、设计方法及工具等。其设计重点是实现低功耗和高效通信/计算能力。本文介绍了4种新型NoC体系结构，并在同等条件下进行了功耗比较。结果显示，聚束环面NoC结构是一种性能及功耗最优的体系结构。

(上接第238页)




图2 免疫神经网络训练误差曲线

表2 3种网络模型的预测结果比较

| 序号     | 实测值   | BP网络    | LMBP网络   | 免疫网络    |
|--------|-------|---------|----------|---------|
| 1      | 0.151 | 0.194 9 | 0.187 2  | 0.168 0 |
| 2      | 0.189 | 0.135 0 | 0.171 0  | 0.123 1 |
| 3      | 0.177 | 0.147 8 | 0.121 3  | 0.142 5 |
| 4      | 0.020 | 0.229 5 | 0.086 7  | 0.037 3 |
| 5      | 0.067 | 0.010 9 | 0.121 4  | 0.060 2 |
| 6      | 0.067 | 0.063 0 | 0.033 25 | 0.049 3 |
| 7      | 0.049 | 0.068 7 | 0.028 5  | 0.043 8 |
| 8      | 0.046 | 0.041 0 | 0.039 1  | 0.040 7 |
| 9      | 0.032 | 0.047 9 | 0.029 1  | 0.033 4 |
| 平均相对误差 |       | 0.593 4 | 0.152 9  | 0.072 7 |
| 均方误差   |       | 4.858   | 3.279    | 1.902   |

由表2可以看出，基于免疫算法的神经网络在预测精度上远胜于BP网络，较LMBP网络也有很大的提高。网络训练目标误差定为0.01，BP网络在1000训练周期内未能收敛

### 参考文献

- [1] Goossens K. A Ethereal Network on Chip: Concepts, Architectures, and Implementations[J]. IEEE Design & Test of Computers, 2005, 22(5).
- [2] Hu Jingcao, Marculescu R. Energy and Performance-aware Mapping for Regular NoC Architectures[J]. IEEE Trans. on CAD of Integrated Circuits and Systems, 2005, 24(4): 551-562.
- [3] Pande P P, Micheli G D. Design, Synthesis and Test of Networks on Chips[J]. IEEE Design & Test of Computers, 2005, 22(5).
- [4] Benini L, Micheli G D. Networks on Chips: A New SoC Paradigm[J]. IEEE Computer, 2002, 35(1): 70-78.
- [5] Bertozzi D, Benini L. A Network-on-chip Architecture for Gagascale System-on-chip[J]. IEEE Circuits and Systems Magazine, 2004, 4(1).
- [6] Vahid F. The Softening of Hardware[J]. IEEE Computer, 2003, 36(4).
- [7] Forsell M. A Scalable High-performance Computing Solution for Networks on Chips[J]. IEEE Micro, 2002, 22(5): 46-55.
- [8] Simunic T. Managing Power Consumption in Networks on Chips[J]. IEEE Trans. on VLSI Systems, 2004, 12(1): 96-107.
- [9] Gerstlauer A. System-level Communication Modeling for Network-on-chip Synthesis[C]//Proceedings of ASP-DAC'05. Shanghai: [s. n.], 2005.
- [10] Pande P P. Performance Evaluation and Design Trade-offs for Network-on-chip Interconnect Architectures[J]. IEEE Transactions on Computers, 2005, 54(8): 1025-1040.

到0.01，LMBP网络需要20个周期，而免疫神经网络需要16个周期。可见，免疫神经网络在收敛速度和效率上均有较大提高。

### 4 结束语

本文利用免疫算法中抗体识别抗原原理、抗体多样性保持等技术，针对前向神经网络的权值优化训练问题，提出了一种基于免疫算法的前馈神经网络权值训练方法。并将这种免疫神经网络用于陀螺仪漂移误差的预测。实验结果证明，相比BP网络，采用免疫算法训练神经网络权值在全局收敛性和收敛速度两方面均有很大提高，对陀螺仪漂移误差的预测也达到了较高的精度。

### 参考文献

- [1] 张春华, 陶俊勇, 陈 循. 陀螺仪模糊性能可靠性评价[J]. 中国惯性技术学报, 2000, 8(3).
- [2] 阎平凡, 张长水. 神经网络与模拟进化计算[M]. 北京: 清华大学出版社, 2000.
- [3] 曹先彬, 刘克胜, 王熙法. 基于免疫进化的多层前馈网络设计[J]. 软件学报, 1999, 10(11): 1180-1184.
- [4] 吕瑛洁. 基于神经网络的惯性器件故障预报技术研究[D]. 西安: 第二炮兵工程学院, 2000.
- [5] Hornik K, Stinchcom B M. White Universal Approximation of an Unknown Mapping and Its Derivatives Using Multilayer Feedword Networks[J]. Neural Network, 1990, 3(2): 551-560