

基于 AGABP 的武器装备效能组合预测

季海,严洪森,张建旭

(东南大学复杂工程系统测量与控制教育部重点实验室,江苏南京 210096;
东南大学自动化学院,江苏南京 210096)

摘要:针对海洋环境影响下武器装备作战效能的评估问题,建立了基于 BP 神经网络的组合预测评估模型。利用神经网络,将多个方案的预测结果作为网络输入,其真实值作为输出,以组合预测模型均方误差最小为目标,属于一种非线性组合预测模型。同时针对 BP 网络收敛速度缓慢,容易形成局部极小解的缺点,提出了 AGABP(自适应遗传反向传播)算法对其进行改进。最后针对某作战平台作战效能的评估实例,在多种单项预测模型的基础上利用 AGABP 算法进行组合预测,得到了较好的实验结果。

关键词:作战效能;自适应遗传反向传播;组合预测;海洋环境;武器装备

中图分类号:TP31

文献标识码:A

文章编号:1673-629X(2015)02-0221-04

doi:10.3969/j.issn.1673-629X.2015.02.050

Combinatorial Forecasting of Weapon Equipment Operational Effectiveness Based on AGABP

JI Hai, YAN Hong-sen, ZHANG Jian-xu

(MOE Key Laboratory of Measurement and Control of Complex Systems of Engineering, Southeast University, Nanjing 210096, China;
School of Automation, Southeast University, Nanjing 210096, China)

Abstract: The combinational forecasting model based on BP neural network is established to evaluate the operational effectiveness of weapon equipment under the influence of marine environment. The model takes advantages of neural network, and takes the prediction results of multiple solutions as the inputs and the true values as output of neural network aiming at getting the smallest mean squared error. It is a kind of the nonlinear combination forecasting model. To solve the problem of BP network slowly converging and easily falling into the local minimum points, an algorithm called AGABP (Adaptive Genetic Algorithm based Back Propagation) is proposed to improve it. Finally, aiming at the operational effectiveness evaluation instance of an operation platform and based on several single-forecasting-models, the AGABP model is used for combinational forecasting and gets good experimental results.

Key words: operational effectiveness; AGABP; combinatorial forecasting; marine environment; weapon equipment

0 引言

随着高科技成果在军事领域的广泛应用,各种高新武器装备在军事行动中起到关键作用。海军武器装备使用环境复杂多变,其性能的发挥受战场环境影响显著,因此其作战效能的评估对于军事辅助决策具有重要价值^[1-2]。针对海洋环境下武器装备效能预测评估的实际问题,已有多种不同的评估预测方法。对于不同的预测方法,其精度和适应范围往往不尽相同。

而对于各种不同的武器效能预测方法,没有哪一种评估模型可以做到零误差。如果只是从几种预测方法中选取某种条件下预测结果最好的一个,而排除其他的单项预测方法,就会造成部分有用信息丢失,难以提高武器效能评估的预测精度,还不具有通用性。针对武器效能的评估预测问题,不同的单项预测方法模型各有其优点和缺点,它们之间并不是相互排斥,而是相互联系,相互补充的。通常来讲,即使一个预测误差较大

收稿日期:2014-02-27

修回日期:2014-05-28

网络出版时间:2014-12-27

基金项目:国家自然科学基金重点资助项目(60934008)

作者简介:季海(1988-),男,硕士研究生,研究方向为计算机集成制造系统;严洪森,博士,教授,博士生导师,研究方向为知识化制造、生产计划与调度、预测等。

网络出版地址: <http://www.cnki.net/kcms/detail/61.1450.TP.20141227.1341.013.html>

的预测方法,如果它包含系统独立的信息,当它与另一个误差较小的方法组合以后,完全有可能增加系统的预测性能。反之,如果对于武器效能的评估预测只采用单一方法,如果方法选取不当,就要冒一定的决策失误风险^[3]。若把多种单项方法正确地组合使用,则组合预测结果对单个较差的预测方法不太敏感,从而提高预测的精确度和可靠度。

传统的组合预测,就是设法将不同的单项预测模型组合起来,利用各种单项预测方法所提供的预测信息,一般通过适当的加权平均的形式得到组合预测模型,从而达到提高预测精确度和可靠度的目的^[4]。然而在实际应用中,固定权重的组合预测方法有一定的局限性,并不能根据具体情况的不同而改变权重系数,从而影响组合预测的准确性^[5]。与传统方法不同,文中首先将 BP 神经网络运用到组合预测中;然后针对 BP 神经网络的固有缺点,提出了 AGABP (Adaptive Genetic Algorithm based Back Propagation) 算法并用于解决武器效能组合预测问题;最后针对某作战平台某导弹的作战效能评估实例,验证文中模型的可行性。

1 基于 BP 神经网络的组合预测模型

针对武器效能的评估预测问题,对于 n 组样本数据,由 m 种单项预测方法对其进行预测评估,产生了 m 组评估结果。现将 m 组评估结果再次作为基于 BP 神经网络的组合预测模型的输入样本数据,表示为 $x = [x_1, x_2, \dots, x_m]^T$,则输入层的神经元个数为 m 。为了提高神经网络模型的性能,对于输入层的样本数据往往还要有一定的预处理操作。文中通过归一化操作进行样本预处理,从而提高神经网络的训练效率。对于神经网络的归一化的常用方法如公式(1)所示^[6]。

$$x'_i = (x_{\text{upper}} - x_{\text{lower}}) \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} + x_{\text{lower}} \quad (1)$$

式中, x_{upper} 、 x_{lower} 分别表示输入样本指标归一化以后目标范围的最大值和最小值; x_{\max} 、 x_{\min} 分别表示输入样本指标归一化以前的最大值和最小值; x_i 和 x'_i 分别表示归一化之前和归一化之后的输入样本指标值。

对于基于神经网络的组合预测模型的输出层,将武器的作战效能作为输出,则模型的输出层只含有一个神经元,可以表示为 y ,且满足 $y \in [0, 1]$ 。

对于神经网络而言,隐含层的设计一般比较重要^[7]。如果隐含层的神经元太少,则网络的学习能力低下,往往训练结果精度不能让人满意;如果隐含层的神经元太多,则会导致网络的训练时间过长,泛化能力不高。所以在神经网络的实际应用中,隐含层的层数和隐含层节点数的设计,往往是神经网络模型设计的关键。目前,隐含层节点数的设计尚未取得统一的观

点,实际应用中通常根据 Kolmogorov 定理来确定,具体如公式(2)所示^[6]。

$$l = \sqrt{m + k + 1} + a \quad (2)$$

式中, m 表示输入节点数; l 表示隐含层节点个数; k 表示输出层节点个数; a 为调节常数,取值范围通常在 1 到 10 之间。

对于隐含层层数的设计,一般的设计原则是如果一个隐含层可以满足设计要求,则使用单隐含层。因为多隐含层虽然能获得更好的训练结果,但付出的代价是网络训练速度缓慢,参数调整复杂。对于武器效能组合预测的实际问题,输入层和输出层都较为简单,所以单隐含层的设计是合理的。

通过对神经网络的输入层、隐含层和输出层的分析,可以得到神经网络模型的结构如图 1 所示。

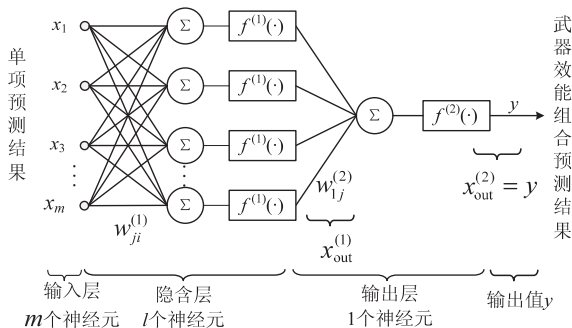


图 1 基于神经网络的武器效能组合预测模型结构

由图 1 可以得到武器效能的组合预测模型为

$$y = f^{(2)} \left(\sum_{j=1}^l (w_{lj}^{(2)} f^{(1)} \left(\sum_{i=1}^m w_{ji}^{(1)} x_i \right)) \right) \quad (3)$$

其中, $f^{(1)}$ 和 $f^{(2)}$ 分别为隐含层和输出层神经元的激活函数,通常选取 S 型函数; $w_{ji}^{(1)}$ 和 $w_{lj}^{(2)}$ 分别为输入层到隐含层的连接权重和隐含层到输出层的连接权重。

标准反向传播算法的建立基础是最快下降梯度算法,即连接权值的修正是沿着损失函数下降最快的方向进行的。对于图 1 神经网络结构,可以定义损失函数为:

$$E_q = \frac{1}{2} \sum_{h=1}^n (d_{qh} - x_{\text{out},h}^{(2)})^2 \quad (4)$$

式中, E_q 表示第 q 组输入样本的损失函数; $x_{\text{out}}^{(2)}$ 表示网络的实际输出; n 表示样本数量。

根据最快梯度下降法,对于 s 任意层的神经网络的学习规则表示为:

$$\Delta w_{ji}^{(s)} = -\mu^{(s)} \frac{\partial E_q}{\partial w_{ji}^{(s)}} \quad (5)$$

式中, $s=1, 2$ 表示相应的网络层; $\mu^{(s)} > 0$ 表示网络的学习率。

关于 BP 网络学习的推导,很多文献都给出了详

细的推导过程,此处将不一一赘述。参见文献[8]的推导过程,给出关于任意隐含层的BP神经网络的权重递推公式:

$$w_{ji}^{(s)}(k+1) = w_{ji}^{(s)}(k) - \mu^{(s)} \delta_j^{(s)} x_{out,i}^{(s-1)} \tag{6}$$

其中, $\delta_j^{(s)}$ 表示局部误差。

对于输出层和隐含层,局部误差的表示各不相同。
对于输出层

$$\delta_j^{(s)} = - [d_{qh} - x_{out,j}^{(s)}] g(v_j^{(s)}) \tag{7}$$

对于隐含层

$$\delta_j^{(s)} = \left(\sum_{h=1}^{n_s+1} \delta_h^{(s+1)} w_{hj}^{(s+1)} \right) g(v_j^{(s)}) \tag{8}$$

其中, g 表示非线性激活函数 f 的一阶导数。

从而,基于BP神经网络的组合预测算法步骤为:

- (1) 对输入样本按照公式(1)进行归一化处理;
- (2) 初始化神经网络连接权值 w ;
- (3) 从输入样本中提取输入 x , 根据公式(3) 计算网络输出 y ;
- (4) 根据公式(7) 和(8) 计算网络的局部误差 δ ;
- (5) 根据公式(6) 更新网络连接权值 w ;
- (6) 根据公式(4) 计算损失函数 E_q , 如果满足精度要求则结束; 否则重复步骤(3) 到步骤(6)。

2 基于AGABP的武器效能组合预测模型

在BP神经网络的训练学习中,权值的初始化对整个网络训练学习的好坏影响十分明显。完全随机产生的初始化权值可能会对网络的训练时间、收敛等造成严重的影响。为了更好地解决网络初始化权值所带来的不确定性问题,可利用自适应遗传算法(AGA)的全局搜索能力来确定初始化权值,加快网络的学习速率,减小陷入局部极小解的风险,从而提高网络的鲁棒性^[9-10]。将AGA算法与BP网络相结合,训练时先用自适应遗传算法进行寻优,将搜索范围缩小后,再利用BP网络来进行精确求解,以达到全局寻优和快速高效的目的。这就是AGABP的基本思想。

遗传算法借鉴了生物界自然选择和进化发展的机制,模拟生物的进化过程,从某一初始种群开始,通过选择、交叉、变异等操作,产生更加适应环境的个体,从而使整个种群一代代不断繁衍进化,直至最后产生一群最适应环境的个体,从而得到问题的最优解。所以,遗传算法编码方式、选择、交叉、变异等操作,对于问题的求解成功与否,起着至关重要的作用。

(1) 编码。

遗传算法并不对待求解问题的变量直接进行操作,而是对表示可行解的个体编码,即染色体进行操作。遗传算法的常用编码方式有二进制编码和实数编码两种。二进制编码具有编码解码操作简单、交叉变

异操作容易实现、符合最小字符集编码原则等优点。然而二进制编码有一个明显的缺点,就是编码的精度受到限制。如果要取得一定精度的编码,就需要较长的二进制串,从而导致染色体长度过长,使得遗传算法的进化过程变得极为缓慢。实数编码则一定程度上克服了二进制编码的不足,具有在较大范围内遗传搜索、数值精度可以很高并且无需编码解码、降低了遗传算法的复杂性并且提高了运算速度等优点^[11]。遗传算法优化神经网络权值时,将网络中的各个权值按照从输入到输出、从上到下的顺序级联为一个长串,串上的每一个位置对应着网络的权值。

(2) 适应度函数。

适应度函数是个体对于种群适应度的评价,也即问题求解质量的评价,起着引导种群不断向最优进化的作用。所以在遗传算法中,要合理地设计适应度函数从而获得最优解。一般而言,适应度函数由目标函数转化而来,对于不同的问题需要设计不同的适应度函数。遗传算法优化神经网络权值时,将染色体上的各个连接权值按照对应方式分配到网络结构中,计算出此时网络的输出均方误差(MSE),从而适应度函数可以表示为:

$$\text{fitness} = \frac{1}{1 + \text{MSE}} \tag{9}$$

$$\text{MSE} = \frac{1}{n} \sum_{k=1}^n (Y - y)^2$$

式中, fitness 为适应度函数; MSE 为均方误差; n 为样本总数; y 为神经网络输出; Y 为样本实际输出。当 fitness 一定程度上接近 1 时,可认为网络精度得到要求。

(3) 遗传操作:选择、交叉、变异。

遗传算法采用选择算子或者复制算子来模拟自然选择,依据某种原则,选择出适当的当前个体遗传到下一世代中去,从而实现种群中个体的优胜劣汰。通常采用的有轮盘赌选择、排序选择、精英选择等。轮盘赌选择是遗传算法中最基本也最常用的算法,每个个体的选择概率与其适应度函数值成比例。设种群中每个染色体的适应度函数值为 f_u , 则种群中所有染色体的适应度函数之和 $S = \sum_{u=1}^{\text{pop_size}} f_u$, 其中 pop_size 为种群规模。令 $t=2,3,\dots,\text{pop_size}$, 计算 $\sum_{u=1}^t f_u$, 形成 pop_size 个区间:

$$\left[0, \frac{f_1}{S}\right], \left[\frac{f_1}{S}, \frac{f_1 + f_2}{S}\right], \dots, \left[\frac{\sum_{u=1}^{t-1} f_u}{S}, \frac{\sum_{u=1}^t f_u}{S}\right], \dots, \left[\frac{\sum_{u=1}^{\text{pop_size}-1} f_u}{S}, 1\right] \tag{10}$$

产生 pop_size 个[0,1]间的随机数,落在第几个区间内,就表示第几个染色体被选中。这就是轮盘赌选择的基本思想^[11]。

交叉操作是遗传算法中另外一个重要的操作。模仿生物遗传进化过程中的交配重组现象,交叉操作使得遗传算法的搜索能力得到质的提升,是遗传算法的显著特征之一。所谓交叉操作,即某两个被选中的染色体按照一定的规则交换基因,从而形成新的个体。对于实数编码的染色体,交叉操作通常采用全概率算术交叉方法^[11],具体表示为:

$$\begin{aligned} P_1^{v+1} &= \alpha P_1^v + (1 - \alpha) P_2^v \\ P_2^{v+1} &= \alpha P_2^v + (1 - \alpha) P_1^v \end{aligned} \tag{11}$$

式中, $0 < \alpha < 1$; P_1^{v+1} 、 P_2^{v+1} 代表第 $v+1$ 代个体; P_1^v 、 P_2^v 代表第 v 代个体。其中, α 可以采用某个固定值,也可以每次随机产生一个 0 到 1 的随机数获取。

模拟生物遗传进化过程中的基因变异环节,遗传算法中的染色体也会以一定的概率发生变异。随机选中某个待变异染色体中的某个基因 r ,则变异后的基因 r' 可表示为^[11]:

$$r' = r_{\min} + (r_{\max} - r_{\min}) \times \alpha$$

式中, r_{\min} 、 r_{\max} 分别表示变异基因的最小值和最大值; α 为 0 到 1 之间的随机数。

在确定了编码方案、适应度函数、选择、交叉、变异的方案后,遗传算法按照一定的算法步骤,就能正确工作。但是在实际的应用中发现,遗传算法中交叉概率 P_c 和变异概率 P_m 的选取对于遗传算法的性能有着重要作用,固定交叉概率和变异概率在一定程度上限制了遗传算法的性能。自适应遗传算法即是基于这样的理念, P_c 和 P_m 的取值应在算法的运行过程中随着适应度的变化而自适应改变。对于适应度高的个体,取较低的交叉概率和变异概率,使优秀个体得以更好地保留;对于适应度低的个体,选取较高的交叉概率和变异概率,使较差的个体更容易被淘汰^[12-13]。自适应遗传算法的 P_c 和 P_m 分别为^[12]:

$$\begin{aligned} P_c &= \begin{cases} P_{c\max} - \frac{(P_{c\max} - P_{c\min})(f_c - f_{\text{avg}})}{f_{\max} - f_{\text{avg}}}, & f_c \geq f_{\text{avg}} \\ P_{c\max}, & f_c < f_{\text{avg}} \end{cases} \\ P_m &= \begin{cases} P_{m\max} - \frac{(P_{m\max} - P_{m\min})(f_m - f_{\text{avg}})}{f_{\max} - f_{\text{avg}}}, & f_m \geq f_{\text{avg}} \\ P_{m\max}, & f_m < f_{\text{avg}} \end{cases} \end{aligned} \tag{12}$$

式中, $P_{c\max}$ 、 $P_{c\min}$ 、 $P_{m\max}$ 、 $P_{m\min}$ 分别表示染色体的最大交叉概率、最小交叉概率、最大变异概率和最小变异概率; f_c 表示待交叉的两个染色体中适应度较大的那个; f_m 表示待变异染色体的适应度值; f_{\max} 表示种群中

染色体的最大适应度值; f_{avg} 表示种群中染色体的平均适应度值。

从而,基于 AGABP 的武器效能组合预测算法步骤为:

- (1) 根据图 1 所示网络结构编码遗传算法染色体,初始化种群;
- (2) 根据公式(9)计算种群中每个染色体的适应度 fitness;
- (3) 判断是否满足停止遗传算法条件,不满足转到步骤(4),满足转到步骤(6);
- (4) 根据公式(13)计算染色体的交叉概率 P_c 和变异概率 P_m ;
- (5) 根据公式(10)~(12)进行选择、交叉、变异操作,产生下一代种群。转到步骤(2);
- (6) 根据最优染色体给神经网络权值 w 赋值;
- (7) 从输入样本中提取输入 x ,根据公式(3) 计算网络输出 y ;
- (8) 根据公式(7) 和(8) 计算网络的局部误差 δ ;
- (9) 根据公式(6) 更新网络连接权值 w ;
- (10) 根据公式(4) 计算损失函数 E_q ,如果满足精度要求则结束;否则重复步骤(7)到步骤(10)。

3 实验结果与分析

文中对某作战平台下武器效能进行组合预测,影响该作战平台的海洋环境要素主要包括风速(X_1)、浪高(X_2)、水平能见度(X_3)、雷暴(X_4)、低云量(X_5)。现针对某武器,有基于 BP 神经网络(F_1)、RBF 神经网络(F_2)、 ε -支持向量机(F_3)和 ν -支持向量机(F_4) 4 种单项预测结果。现在此基础上应用 AGABP 进行组合预测,由于样本有限,取 10 组作为测试样本,5 组作为预测样本,给出 5 次预测详细数据如表 1 所示。预测精度可以通过平均绝对误差来衡量。计算 4 种单项预测的平均绝对误差分别为 0.096,0.080,0.070,0.082,基于 AGABP 的组合预测平均绝对误差为 0.056。显然基于 AGABP 的组合预测获得了更为准确的评估结果。

表 1 基于 AGABP 的武器效能组合预测结果

序号	海洋环境要素					单项预测方法				真实值	组合预测值
	X_1	X_2	X_3	X_4	X_5	F_1	F_2	F_3	F_4		
1	15	4	5	0.3	0.3	0.65	0.63	0.39	0.38	0.5	0.53
2	10	3	6	0.2	0.5	0.70	0.70	0.69	0.71	0.6	0.63
3	3	0.1	0.3	0.4	0.7	0.12	0.26	0.35	0.38	0.3	0.31
4	6	0.5	7	0	0	0.91	0.85	0.94	0.91	0.9	0.72
5	3	0.1	0.5	0.4	0.2	0.46	0.54	0.56	0.59	0.5	0.53

今后还会将生产检测流程的控制设计成一个系统,使其能广泛应用于企业的生产检测流程控制中;分析针对不同的应用场景,按照什么样的生产流程控制步骤能使得控制的效率和效果最好,还会考虑更多的约束情形,使得生产检测流程控制的安全性更高。目前,提出的算法不能处理在某一点上有多个循环的路径,这将在未来的研究中寻找解决的方法;还会进一步将数据挖掘技术应用在生产检测控制领域,考虑更多地影响产品移动的因素,以解决一些生产检测流程控制中遇到的复杂、难以判断的路径问题。

参考文献:

[1] Garfinkel S, Rosenberg B. RFID: applications, security, and privacy[M]. [s. l.]: Pearson Education India, 2006.

[2] Inoue S, Hagiwara D, Yasuura H. Systematic error detection for RFID reliability[C]//Proc of the first international conference on availability, reliability and security. Austria: IEEE Computer Society, 2006: 280–286.

[3] Floerkemeier C, Lampe M. Issues with RFID usage in ubiquitous computing application[C]//Proc of the 2nd international conference on pervasive computing. [s. l.]: [s. n.], 2004: 188–193.

[4] Hahnel D, Burgard W, Fox D, et al. Mapping and localization

with RFID technology[R]. [s. l.]: Intel Research, 2003.

[5] 王妍, 石鑫, 宋宝燕. 基于伪事件的 RFID 数据清洗方法[J]. 计算机研究与发展, 2009, 46(S): 270–274.

[6] 吴爱华. 多固定阅读器下基于路径约束的 RFID 数据清洗算法[J]. 计算机研究与发展, 2011, 48(S): 282–289.

[7] 李战怀, 聂艳明, 陈群, 等. RFID 数据管理的研究进展[J]. 中国计算机学会通讯, 2007, 3(2): 32–40.

[8] Jeffery R, Alonso G, Franklin M, et al. A pipelined framework for online cleaning of sensor data streams[C]//Proc of ICDE. Atlanta: IEEE Computer Society, 2006: 773–778.

[9] 王秋棠, 王鹏, 周皓峰, 等. 基于滑动窗口的概率数据流上的聚集查询[J]. 计算机研究与发展, 2008, 45(S): 169–174.

[10] 谷峪, 于戈, 李晓静, 等. 基于动态概率路径事件模型的 RFID 数据填补算法[J]. 软件学报, 2010, 21(3): 438–451.

[11] 蒋宗礼, 姜守旭. 形式语言与自动机理论[M]. 第2版. 北京: 清华大学出版社, 2013.

[12] Wu E, Diao Yanlei, Rizvi S. High-performance complex event processing over streams[C]//Proc of ACM SIGMOD. [s. l.]: [s. n.], 2006: 407–418.

[13] 刘海龙, 李战怀, 陈群. 乱序 RFID 数据流上的复杂事件检测方法[J]. 西北工业大学学报, 2009, 27(4): 449–454.

(上接第 224 页)

4 结束语

文中针对海洋环境下武器装备效能的组合预测问题,首先构建了基于 BP 神经网络的组合预测模型,然后对于 BP 神经网络的固有缺点构建了基于 AGABP 的组合预测模型和详细的实现步骤,最后在实际的预测过程中与单项预测作了比较。通过组合预测,充分利用各个单项预测的结果,减小预测的相对误差,降低单一模型选取不当的风险性,验证了基于 AGABP 的组合预测模型的有效性和合理性。

参考文献:

[1] McLaughlin J W, Henderson S. Applying globe measurements and resources to the study of marine environments[C]//Proceedings of MTS/IEEE Oceans. [s. l.]: IEEE, 2005: 2621–2624.

[2] Huang Y Y. A methodology of simulation and evaluation on the operational effectiveness of weapon equipment[C]//Proc of 2009 Chinese control and decision conference. Guilin, China: [s. n.], 2009: 17–19.

[3] Bates J M. The combination of forecasts[J]. Operational Research Quarterly, 1969, 20(4): 451–468.

[4] 汪同三, 张涛. 组合预测—理论、方法及应用[M]. 北京: 社会科学文献出版社, 2008.

[5] 陈青. 在高层建筑沉降预测中组合模型的应用研究[D]. 昆明: 昆明理工大学, 2011.

[6] 孙光民, 李岩, 王鹏, 等. 用于神经网络手写体字符识别的自适应归一化处理方法[J]. 模式识别与人工智能, 2005, 18(3): 268–272.

[7] 崔吉峰, 乞建勋, 杨尚东. 基于粒子群改进 BP 神经网络的组合预测模型及其应用[J]. 中南大学学报: 自然科学版, 2009, 40(1): 190–194.

[8] Ham F M, Kostanic I. 神经计算原理[M]. 北京: 机械工业出版社, 2007.

[9] 杨梅, 卿晓霞, 王波. 基于改进遗传算法的神经网络优化方法[J]. 计算机仿真, 2009, 26(5): 198–201.

[10] Zhao Z, Luo Z, Zhang W. Real estate investment risk assessment based on GABP algorithm of neural network[J]. International Journal of Digital Content Technology & Its Applications, 2012, 6(3): 122–131.

[11] 田雨波. 混合神经网络技术[M]. 北京: 科学出版社, 2009.

[12] 张国强, 彭晓明. 自适应遗传算法的改进与应用[J]. 舰船电子工程, 2010, 30(1): 83–84.

[13] 李剑, 景博. 自适应遗传算法在多边多议题协商中的应用[J]. 北京邮电大学学报, 2008, 31(6): 67–70.

基于AGABP的武器装备效能组合预测

作者：[季海](#)，[严洪森](#)，[张建旭](#)，[JI Hai](#)，[YAN Hong-sen](#)，[ZHANG Jian-xu](#)

作者单位：[东南大学 复杂工程系统测量与控制教育部重点实验室](#)，[江苏 南京210096](#)；[东南大学 自动化学院](#)，[江苏 南京210096](#)

刊名：[计算机技术与发展](#)

英文刊名：[Computer Technology and Development](#)

年，卷(期)：2015 (2)

引用本文格式：[季海](#).[严洪森](#).[张建旭](#).[JI Hai](#).[YAN Hong-sen](#).[ZHANG Jian-xu](#) [基于AGABP的武器装备效能组合预测](#)
[期刊论文]-[计算机技术与发展](#) 2015 (2)