

doi: 10.3969/j.issn.1006-1576.2012.07.018

## 基于粗糙集和 BP 神经网络的导弹备件消耗预测

赵建忠<sup>1,2</sup>, 徐廷学<sup>3</sup>, 刘勇<sup>1</sup>, 高杰<sup>2</sup>(1. 海军航空工程学院研究生管理大队, 山东 烟台 264001; 2. 中国人民解放军 92752 部队, 合肥 231614;  
3. 海军航空工程学院兵器科学与技术系, 山东 烟台 264001)

**摘要:** 针对神经网络预测导弹备件消耗时参数过多会导致事件过长并易陷入局部最优的问题, 建立一种基于粗糙集和 BP 神经网络的导弹备件消耗预测模型。在对采集到的导弹备件消耗信息进行特征提取、形成决策表的基础上, 用粗糙集理论对原始信息表进行约简, 去除冗余的属性和属性值, 并将约简的影响因素值输入到 BP 神经网络中进行训练预测。实例结果表明: 该预测方法大大减少了网络的收敛时间, 提高了模型的预测精度, 为导弹备件消耗预测提供了一个新的思路。

**关键词:** 导弹; 备件; 粗糙集; BP 神经网络; 消耗预测**中图分类号:** TJ765.4 **文献标志码:** A

## Consumption Forecasting of Missile Spare Parts Based on Rough Sets and BP Neural Network

Zhao Jianzhong<sup>1,2</sup>, Xu Tingxue<sup>3</sup>, Liu Yong<sup>1</sup>, Gao Jie<sup>2</sup>(1. *Administrant Brigade of Postgraduate, Naval Aeronautical Engineering University, Yantai 264001, China;*  
2. *No. 92752 Unit of PLA, Hefei 231614, China;* 3. *Dept. of Ordnance Science & Technology, Naval Aeronautical Engineering University, Yantai 264001, China*)

**Abstract:** When neural network forecasts missile spare parts, redundant parameter is prone to making event too long and getting into part optimization, in order to solve these problems, established a consumption forecasting model of missile spare parts based on rough sets and BP neural network. Firstly, consumption information of missile spare parts was abstracted and made into decision-making table; Secondly, simplified original information table and deleted redundant property and property value by rough sets theory; Lastly, the simplified influence factor value was put into BP neural network to carry out training and forecasting. The example results proved the consumption forecasting method reduced greatly convergence time of neural network, improved forecast precision, and afforded a new way for consumption forecasting of missile spare parts.

**Key words:** missile; spare parts; rough sets; BP neural network; consumption forecasting

### 0 引言

导弹备件的消耗预测是导弹备件保障工作中的重要环节。导弹备件消耗预测准确与否, 将直接影响导弹备件保障的军事和经济效益。目前, 导弹备件消耗预测采用的主要方法有因果预测、时序预测、灰色理论和神经网络预测等<sup>[1-2]</sup>。这些方法大都是基于历史消耗数据规律的预测, 没有考虑影响因素对备件消耗的影响。其中, 神经网络具有强大的任意函数逼近能力、学习能力、自组织和自适应能力, 但当输入参数过多, 样本数量过大时, 网络收敛速度变慢, 需较长的训练时间, 并易陷入局部最优<sup>[3]</sup>。

导弹备件的消耗与很多因素有关, 而且每种因素对导弹备件消耗的影响程度也不尽相同。现有文献一般根据经验来选择输入变量, 无法体现各输入变量对于输出值影响的重要性程度<sup>[4-5]</sup>。而粗糙集理

论最大的特点就是利用数据本身所提供的信息, 不需要任何附加信息或先验信息或先验知识(如统计学中的概率分布, 模糊集理论中的隶属度或隶属函数等), 在保持知识库分类能力不变的条件下, 删除不相关或不重要的信息, 降低信息冗余<sup>[6]</sup>。因此, 笔者提出采用粗糙集约简方法来选择与导弹备件消耗预测相关性大的影响因素作为 BP 神经网络的输入, 充分发挥粗糙集在处理冗余数据上的优势, 保证模型输入参数的合理性, 有效地减少模型的复杂程度, 提高模型的预测速度和精度。

### 1 粗糙集基本原理

粗糙集理论是波兰华沙大学的 Pawlak 教授于 1952 年提出的一种处理模糊性和不确定性的新型数学工具, 能有效处理不精确、不一致和不完整的信息, 并从中发现隐含的知识, 揭示潜在的规律<sup>[7]</sup>。

收稿日期: 2012-02-01; 修回日期: 2012-02-21

作者简介: 赵建忠(1978—), 男, 山东人, 博士, 工程师, 从事装备综合保障理论与技术研究。

$X$  在粗糙集理论中, 知识是基于对对象分类的能力<sup>[8]</sup>。对于任一信息系统  $K = (U, R)$ ,  $U$  为所研究对象的全集, 称为论域,  $U = \{x_1, x_2, \dots, x_n\}$ 。  $R$  为属性集,  $R = \{r_1, r_2, \dots, r_n\}$ 。任一  $P \subseteq R, P \neq \Phi$ , 则全集  $U$  上的元素关于  $P$  的等价类构成一种不可分辨关系, 记为  $\text{ind}(P)$ 。以  $f(x, a)$  表示元素  $x$  关于属性  $a$  的取值, 若  $x_{i1}, x_{i2}$  关于  $P$  不可分辨, 则对任一  $r_i \in R$ , 满足  $f(x_{i1}, r_i) = f(x_{i2}, r_i)$ 。

若存在不可分辨关系  $P$ , 则由  $P$  形成的等价类可表示为  $U/\text{ind}(P) = \{X_1, X_2, \dots, X_n\}$ 。对于集合  $X \subseteq U$ , 若  $X$  能表示成这些等价类的并集时, 则称集合  $X$  相对于关系  $P$  可精确定义, 否则只能通过上下近似来表示。集合  $X$  关于  $P$  的下近似和上近似分别用  $P_-(X)$  和  $P^-(X)$  来表示, 满足:  $P_-(X) = \cup\{X_i | X_i \subseteq X\}$  和  $P^-(X) = \cup\{X_i | X_i \cap X \neq \Phi\}$ 。下近似  $P_-(X)$  又称为  $X$  的  $P$  正域, 记为  $\text{pos}_p(X)$ 。

设  $P, S$  为  $U$  中的 2 个等价关系,  $U/S = \{X_1, X_2, \dots, X_n\}$ ,  $S$  的  $P$  正域记为  $\text{pos}_p(S)$ , 即  $\text{pos}_p(S) = \cup_{i=1}^n P_-(X_i)$ 。若存在  $r \in R$  有  $\text{pos}_p(S) = \text{pos}_{p-\{r\}}(S)$ , 则认为  $r$  为  $P$  中  $S$  可省略的, 即  $P - \{r\}$  为  $P$  的  $S$  相对简化。

## 2 BP 神经网络基本原理

误差反向传播网络(back propagation network, BP 网络)是一种应用最广泛的神经网络。BP 模型是一个多层感知器, 是由输入层、中间层(隐含层)和输出层构成的前馈网络, 如图 1<sup>[9]</sup>所示。




图 1 BP 网络模型图

BP 神经网络的自学习过程是一个反复迭代的过程, 首先给网络一组初始权值, 然后输入一个样

本并计算其输出, 通过实际的输出与期望值之间的差值用一定的方法来修改网络的权值, 以达到减小这个差值的目的。反复执行这个过程直到这个差值小于预先确定的值为止。对足够的样本进行这样的训练后, 网络所得的那组权值便是网络经过自适应学习得到的正确的内部关系。

BP 神经网络自适应学习过程的具体算法<sup>[10]</sup>如下:

- 1) 给网络赋一组小的随机初始权值, 其值在 0 到 1 之间, 并使其互不相等;
- 2) 将输入数据归一化, 使其在 0 到 1 之间, 根据所研究的问题确定期望输出信号  $(d_0, d_1, \dots, d_{k-1})$ ;
- 3) 逐层计算神经网络的实际输出值;
- 4) 从输出层开始, 反向调整权值;
- 5) 算总的误差  $E$ , 若  $E \leq \epsilon$ , 学习停止, 否则转到 1) 重新计算。

## 3 粗糙集和 BP 神经网络预测模型的建立

利用粗糙集对导弹备件消耗影响因素进行约简处理, 以其数值作为输入, 并以消耗量作为输出, 建立基于粗糙集和 BP 神经网络的预测模型, 其基本步骤见图 2。

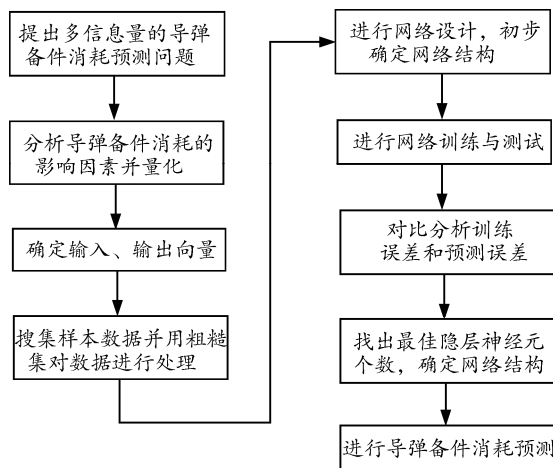


图 2 基于粗糙集和神经网络的预测流程

- Step1: 提出多信息量的导弹备件消耗预测问题, 构思建立预测模型;
- Step2: 分析并量化影响导弹备件消耗的各种因素。把影响因素量化, 并用适当的数值表示出来;
- Step3: 确定输入输出向量。把影响因素量化值作为输入向量, 把导弹备件消耗量作为输出向量;
- Step4: 收集样本数据并用粗糙集理论对数据进行处理;

Step5: 确定输入与输出层神经元个数, 并设计中间层神经元个数可变的网络结构;

Step6: 输入训练样本与测试样本进行网络训练与测试, 对比训练误差和预测误差, 确定最优网络结构;

Step7: 输入新的影响因素样本数据到确定的最优模型中进行预测。

### 4 实例分析

据调研分析, 某型机载导弹装备主要处于储存保管、战备值班、挂机飞行 3 种状态, 其备件消耗受装备自身故障率、通电时间、挂机飞行时间等多种因素影响。这里统计了该型导弹装备某类备件 2000—2009 年的消耗情况。由于保密原因, 没有列出详细的保障数据。

#### 1) 数据准备。

经分析, 影响该类导弹备件消耗的因素组成属性集合  $R = \{A, B, C, D, E, F, G, H\}$ , 具体如下:

$A$  为自然损耗量, 把每年导弹装备定检过程中发现的失效备件数作为自然损耗的备件数。

$B$  为气候条件, 根据该部队气象部门的统计资料, 将天气情况划分为正常、恶劣、极恶劣 3 个等级, 各种天气比例的和为 1 年气候条件的评价值。

$B$  的取值规则如表 1 所示。

表 1 气候条件取值规则

气候条件分类	等级	全年中所占天数
正常	1	$B^{(1)}$
恶劣	3	$B^{(2)}$
极恶劣	5	$B^{(3)}$

$$B = \frac{1 \times B^{(1)} + 3B^{(2)} + 5 \times B^{(3)}}{365}, \quad B^{(1)} + B^{(2)} + B^{(3)} = 365。$$

$C$  为通电时间, 根据履历记录可以统计出导弹年度总测试时间, 单位为小时, 将其作为量化值。

$D$  为战备值班时间, 根据使用记录可以统计出每年外场导弹战斗值班总时间, 单位为千小时, 将其作为量化值。

$E$  为人为因素, 导弹综合业务素质差的人员在全体保障人员所占的比例为该影响因素的量化值, 将其百分比作为量化值。

$F$  为拆卸次数, 根据使用记录可以统计出年度使用、维修或定检中该备件(或者含该备件的部件)被拆卸的总次数, 将其直接作为量化值。

$G$  为挂机飞行时间, 根据平时的训练计划可以统计出导弹年度挂机飞行的总时间, 单位为小时,

将其直接作为量化值。

$H$  为年度重大任务次数, 直接将其作为量化值。

通过极差变换法, 将备件消耗的相关数据均变为属于  $[0, 1]$  区间的值。

#### 2) 数据处理。

该类导弹备件 2000—2009 年的消耗数据, 组成集合  $U = \{1, 2, 3, 4, 5, 6, 7, 8, 9, 10\}$ 。

对每个属性设定阈值, 1 表示不小于阈值, 0 表示没有达到标准。表 2 为影响因素信息表。由表 2 可知,  $B$  的属性值在 10 年跨度里只有一个不同, 这说明每年的环境因素对备件的影响程度基本稳定, 对预测不会有太大影响, 可以把它去掉。 $D$  的属性值和  $G$  的属性值相同, 所以只保留一个, 假设保留  $D$ , 删除  $G$ 。

表 2 备件消耗影响因素信息表

序号	影响因素量化值							
	$A$	$B$	$C$	$D$	$E$	$F$	$G$	$H$
1	1	0	1	0	0	0	0	0
2	1	0	0	0	1	1	0	0
3	0	0	1	1	0	0	1	1
4	1	0	0	0	0	0	0	0
5	1	1	1	1	1	1	1	1
6	0	0	1	1	0	1	1	0
7	1	0	1	1	1	1	1	1
8	1	0	1	1	1	1	1	0
9	0	0	0	0	0	0	0	0
10	1	0	1	1	1	1	1	1

下面对表 2 中的数据进行约简。其中  $U = \{1, 2, 3, 4, 5, 6, 7, 8, 9, 10\}$ ,  $R' = \{A, C, D, E, F, H\}$ 。则  $\text{ind}(R')$  关系有以下等价类:

$$\begin{aligned}
 U / \text{ind}(R') &= \{\{1\}, \{2\}, \{3\}, \{4\}, \{6\}, \{7\}, \{8\}, \{5, 9, 10\}\}, \\
 U / \text{ind}(R' - A) &= \{\{1\}, \{2\}, \{3\}, \{6\}, \{7\}, \{8\}, \{4, 5, 9, 10\}\} \neq U / \text{ind}(R'), \\
 U / \text{ind}(R' - C) &= \{\{1, 4\}, \{2\}, \{3\}, \{6\}, \{7\}, \{8\}, \{5, 9, 10\}\} \neq U / \text{ind}(R'), \\
 U / \text{ind}(R' - D) &= \{\{1\}, \{2\}, \{3\}, \{4\}, \{6\}, \{8\}, \{5, 7, 9, 10\}\} \neq U / \text{ind}(R'), \\
 U / \text{ind}(R' - E) &= \{\{1\}, \{2\}, \{3\}, \{4\}, \{6\}, \{7\}, \{8\}, \{5, 9, 10\}\} = U / \text{ind}(R'), \\
 U / \text{ind}(R' - F) &= \{\{1\}, \{2\}, \{3\}, \{4\}, \{6\}, \{7\}, \{8\}, \{5, 9, 10\}\} = U / \text{ind}(R'), \\
 U / \text{ind}(R' - H) &= \{\{1\}, \{2\}, \{3\}, \{4\}, \{6\}, \{7\}, \{5, 8, 9, 10\}\} \neq U / \text{ind}(R').
 \end{aligned}$$

所以属性  $E, F$  可省, 而  $A, C, D$  和  $H$  不可省。这样就把原来 8 个影响因素减为 4 个。


#### 3) 消耗预测。

采用 3 层 BP 神经网络, 输入层有 3 个神经元, 输出层有 1 个神经元。中间层的神经元个数需要通过实验来确定, 为此需要设计一个隐含层可变的 BP 网络。一般可先根据 Kolmogorov 定理取  $2n+1$  个, 再依据经验在附近选择不同的个数进行实验寻找最

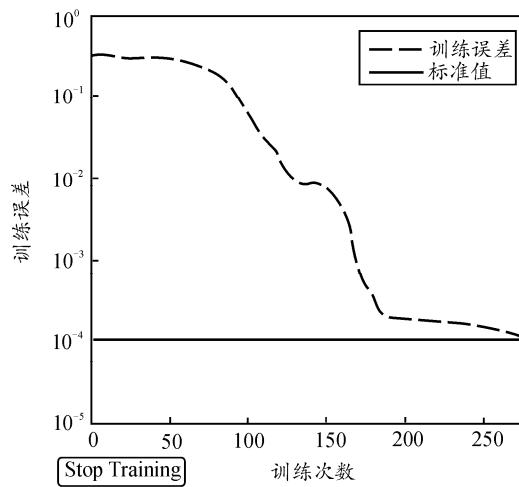
佳数目。依实际情况分别选取 6, 10, 15, 20, 25, 29, 33 和 40 进行实验。

取 2000—2005 年的影响因素数据作为输入向


量,以 2001—2006 年的消耗数量作为目标向量进行网络训练。训练目标设定为 0.000 1, 进行 1 000 次训练, 不同隐单元数的网络训练误差曲线如图 3。




(a) 训练误差曲线(隐单元数: 6)




(b) 训练误差曲线(隐单元数: 10)




(c) 训练误差曲线(隐单元数: 15)



(d) 训练误差曲线(隐单元数: 20)



(e) 训练误差曲线(隐单元数: 25)



(f) 训练误差曲线(隐单元数: 29)





图 3 不同隐单元数的网络训练误差曲线对比图

由图 3 可以看出, 训练次数与预测误差不随着隐单元数的增加而线性增加或者减少, 也证明了隐单元数的增加可以提高网络的映射精度, 但并不意味着一定提高网络的性能的重要结论。当隐单元数为 29 时, 网络只需要训练 162 次就能达到精度要求, 可以作为最优网络模型。

网络训练代码如下:

```
net.trainParam.epochs=1000;
net.trainParam.goal=0.0001;
net=train(net,p,t);
```

在最优网络模型中输入 2006—2008 年的影响因素数据, 可以预测 2007—2009 年的导弹备件消耗量。作为对比, 同时分别采用同一神经网络, 但分别用该类导弹备件历史消耗量和所有的影响因素作为输入, 对 2007—2009 年的消耗量进行预测, 其预测结果见表 3 和图 4。可以看到, 考虑影响因素的神经网络预测误差相对较小, 经过粗糙集属性约简后的神经网络预测误差略微更小, 但网络的训练速度明显变快。

表 3 预测结果对比表

年份	实际值	历史消耗量作为输入		全部影响因素作为输入		约简后的影响因素作为输入	
		预测值	相对误差	预测值	相对误差	预测值	相对误差
2007	38	41.352	-0.088 2	40.872	-0.075 6	41.876	-0.102 0
2008	34	38.593	-0.135 1	38.435	-0.130 4	37.302	-0.097 1
2009	45	42.016	0.066 3	42.538	0.054 7	43.284	0.038 1
平均相对误差		0.096 5		0.086 9		0.079 1	
均方根相对误差		0.100 7		0.087 0		0.084 2	




图 4 预测结果对比图

### 5 结束语

笔者提出了一种集成粗糙集理论和神经网络的导弹备件消耗预测方法, 既充分考虑了多种影响因素, 又通过粗糙集属性约简压缩了 BP 神经网络输入变量, 避免了由于输入变量过多而导致神经网络拓扑结构复杂等不足。实例结果表明: 该方法大大减少了网络的收敛时间, 同时也提高了模型的预测精度, 为导弹备件消耗预测提供了一个新的思路。

### 参考文献:

[1] 李武胜. 备件需求预测技术综述[J]. 物流技术, 2007, 26(8): 30-33.  
 [2] 王宏焰, 高崎, 王家鹏. 装备维修器材消耗预测综述[J]. 四川兵工学报, 2008, 29(5): 92-96.

[3] 杜智慧, 俞晓红. 基于粗糙集与 RBF 神经网络的农业总产值预测方法[J]. 洛阳理工学院学报: 自然科学版, 2010: 20(1): 76-79.

[4] Papadkis S E, Theocharis J B, Kiartzis S J, et al. A novel approach to short-term load forecasting using fuzzy neural networks[J]. IEEE Trans on Power Systems, 1998, 13(2): 480-489.

[5] Mori H, Kobayashi H. Optimal fuzzy inference for short-term load forecasting[J]. IEEE Trans on Power Systems, 1996, 11(1): 390-396.

[6] 王国胤, 姚一豫, 于洪. 粗糙集理论与应用综述[J]. 计

算机学报, 2009, 32(7): 1230-1246.

[7] 张文修, 吴伟志, 梁吉业, 等. 粗糙集理论与方法[M]. 北京: 科学出版社, 2005: 76-102.

[8] 王国伟, 闫丽, 姚玉霞. 基于熵权法加权的模糊 C 均值聚类算法研究[J]. 农业网络信息, 2010(8): 52-58.

[9] 史成东, 陈菊红, 胡健. 基于粗糙集和神经网络的供应链绩效预测研究[J]. 计算机工程与应用, 2007, 43(33): 203-245.

[10] 吴清亮, 董辉, 张政, 等. 基于神经网络对航材备件需求率的预测分析[J]. 兵工自动化, 2009, 28(1): 54-64.

(上接第 65 页)

### 3.3 分布式仿真容错原型系统

设计并实现了分布式仿真容错原型系统, 分为仿真运行、状态监控、数据保存、容错迁移等模块, 已实现对运行中的仿真节点进行状态监控, 对仿真数据进行保存, 客户端超时情况下自动断开连接等功能。在实验室环境下进行了测试, 为模拟出不同的网络传输条件, 在百兆以太局域网, 使用网络带宽控制软件, 将不同链路的带宽人为降低, 营造一个较为复杂的网络环境。采用 6 台 PC 机和 1 台交换机进行模拟测试, 分别测试了基于心跳的端服务器错误恢复、基于租约的客户端错误和基于日志的中心服务器错误恢复。系统主界面如图 4, 测试结果表明能有效提高分布式仿真系统的容错性。

大规模作战仿真的需要, 对于实现云计算与 HLA 的结合也具有一定的参考价值。下一步, 将借鉴云计算开源平台 Hadoop 的实现<sup>[10]</sup>, 重点对日志的保存与恢复、服务器间的动态负载均衡和容错迁移等开展深入研究。

### 参考文献:

[1] 刘云生, 查亚兵, 张传富, 等. 分布式仿真系统容错机制研究[J]. 系统仿真学报, 2005, 17(2): 355-357.

[2] 刘鹏. 云计算[M]. 2 版. 北京: 电子工业出版社, 2011.

[3] Björn Möller. Make your HLA Federations Fault Tolerant with HLA Evolved, Pirch Technologies[R]. Sweden: Simulation Interoperability Standards Organization, 2005. 05S-SIW-048.

[4] Björn Möller. Developing the Fault Tolerance Support Extensions for HLA Evolved, Pitch Technologies[R]. Sweden: Simulation Interoperability Standards Organization, 2005. 05E-SIW-019.

[5] Möller B, Morse K L, Lightner M, et al. HLA evolved-a summary of major technical improvements[C]//Fall Simulation Interoperability Workshop. Sweden: Simulation Interoperability Standards Organization, 2008.

[6] 钟蔚, 龚建兴, 郝建国, 等. HLA Evolved 规范研究分析[J]. 系统仿真学报, 2011, 23(4): 691-696.

[7] 刘云生. 大规模分布式仿真系统容错关键技术研究[D]. 长沙: 国防科学技术大学, 2006: 30-31.

[8] 李利, 马毅. 电子对抗作战仿真系统容错机制设计[J]. 四川兵工学报, 2010, 31(5): 110-113.

[9] 王鹏. 云计算的关键技术与应用实例[M]. 北京: 人民邮电出版社, 2010: 82-83.

[10] Caibinbupt. Hadoop 源代码分析[EB/OL]. <http://caibinbupt.iteye.com/blog/262412#bc2244008>.



图 4 分布式仿真容错原型系统

## 4 结束语

基于多服务器的容错网络模型及采用的错误恢复策略能有效提高分布式仿真系统的鲁棒性, 满足