

文章编号: 1001-0920(2009)03-0371-06

基于自学习模糊 Petri 网的知识化制造系统采购预测

孟宪刚, 严洪森

(东南大学 复杂工程系统测量与控制教育部重点实验室, 南京 210096)

摘 要: 对模糊 Petri 网进行改进,使其增加自学习能力,即自学习模糊 Petri 网(SFPN).提出了自学习模糊 Petri 网模型知识库的建立方法,通过构造 SFPN 模型知识库,建立并保存现有产品的 SFPN 模型,开发新产品或进行新的决策时调出并进行修正后作为新产品模型,通过较短时间和少量样本的自学习训练,便可用于新产品的预测或决策.最后通过采购预测实例验证了该方法的有效性.

关键词: 知识化制造; 模糊 Petri 网; 知识库

中图分类号: F227

文献标识码: A

Purchase forecasting in knowledgeable manufacturing systems based on self-learning fuzzy Petri nets

MENG Xian-gang, YAN Hong-sen

(Key Laboratory of Measurement and Control of Complex Systems of Engineering, Ministry of Education, Southeast University, Nanjing 210096, China. Correspondent: MENG Xian-gang, E-mail: mexga@sohu.com)

Abstract: Fuzzy Petri nets are improved by adding the ability of self-learning, namely self-learning fuzzy Petri nets (SFPN). The method of building the self-learning fuzzy Petri nets model knowledge base is proposed. SFPN models of existing products are established and kept by building the SFPN model knowledge base. While a new product is developed or a new decision is made, the SFPN model of existing product can be read, modified and used as that of new product, which can be used to forecast or make a decision on new product through self-learning and self-training with less time and a few of samples. Finally, an application of forecasting real purchase shows the effectiveness of the method.

Key words: Knowledgeable manufacturing; Fuzzy Petri nets; Knowledge base

1 引言

现代社会已从物质经济时代转向知识经济时代.市场竞争的加剧缩短了产品的生命周期,加速了产品的更新换代,对制造企业快速适应市场变化的能力提出了更高的要求.如能领先市场研发和生产新产品,就能获得最大的效益.在此背景下,产生了知识化制造这种新的制造模式^[1].知识化制造对具体的制造过程进行知识提取,从而将对具体过程的分析及应用转化为对于知识的分析及利用,并根据需要将得到的新知识应用于具体的制造过程.

对于批量生产的专业化制造企业而言,新产品与现有产品(老产品)的模型是有差别的,因而不能将现有产品的模型直接应用到新产品中去.新产品

的设计、采购、生产、销售等环节模型的建立,往往需要投入大量的时间和精力.然而,由于新产品是从老产品延续下来的,新老产品在多个方面都有相似性.考虑到同类产品设计、采购、生产、销售等环节有着较为固定的模式,以及新老产品模型的相似性,如能建立起进而利用好老产品的各个环节的 Petri 网模型,对其加以自学习修正,从而在较短时间内建立起新产品各个环节的 Petri 网模型,便可大大降低新产品开发的时间和成本.知识化制造系统自学习模糊 Petri 网模型正是基于这种思想提出的.本文以零配件采购预测为例,对此方法进行研究.

2 自学习模糊 Petri 网

Petri 网是一种图形化的建模工具,它能精确直

收稿日期: 2007-12-09; 修回日期: 2008-05-22.

基金项目: 国家自然科学基金项目(60574062); 国家 863 计划项目(2007AA04Z112).

作者简介: 孟宪刚(1973—),男,山东济宁人,博士生,从事 CIMS,知识化制造等研究; 严洪森(1957—),男,浙江江山人,教授,博士生导师,从事生产计划与调度、知识化制造等研究.

观地对离散事件动态系统进行描述,从而在包括制造系统在内的许多领域得到了广泛应用.模糊 Petri 网(FPN)^[2-5]是在基本 Petri 网中引入模糊规则,它适用于表述模糊命题,具有较强的建模能力,能简单地建立新系统模型,但其不具备自学习的能力.

为了实现 Petri 网模型基础上的制造及管理过程的自学习功能,本文在模糊 Petri 网的基础上引入了神经网络^[6],即自学习模糊 Petri 网(SFPN).下面给出自学习模糊 Petri 网的定义:

定义 1 SFPN 可定义为一个 9 元组

$$\text{SFPN} = (P, T, D, I, O, M, \beta, \lambda, \omega). \quad (1)$$

其中: $P = \{p_1, p_2, \dots, p_n\}$ 是一个库所的有限集合; $T = \{t_1, t_2, \dots, t_q\}$ 是一个变迁的有限集合; $D = \{d_1, d_2, \dots, d_n\}$ 是一个命题的有限集合,且满足 $|P| = |D|$; $I(O): T \rightarrow P^\infty$ 为输入(输出)函数,反映变迁到库所的映射; $M: P \rightarrow [0, 1]$ 为标识集合, $m(p_i)$ 为对应库所的标识; $\beta: P \leftrightarrow D$ 为 P 的关联函数,表示 P 与命题集合之间一一对应的映射,若 $\beta(p_i) = d_i$,则称 p_i 与命题 d_i 关联; $\lambda = \{\lambda_1, \lambda_2, \dots, \lambda_q\}$, $\lambda \in [0, 1]$ 为变迁 T 的阈值; $\omega = \{\omega_1, \omega_2, \dots, \omega_r\}$, $\omega \in [0, 1]$ 为变迁 T 各个输入有向弧上的权值.

2.1 自学习模糊 Petri 网及其产生式规则

SFPN 的产生式规则有以下 3 类:

类型 1: 简单规则

IF d_j THEN d_k, λ_j, ω_j .

类型 2: 与规则

IF d_{j1} and d_{j2} and ... d_{jn}

THEN $d_k, \lambda_j, \omega_{j1}, \omega_{j2}, \dots, \omega_{jn}$.

与规则如图 1 所示.

类型 3: 或规则

IF d_{j1} or d_{j2} or ... d_{jn}

THEN $d_k, \lambda_{j1}, \lambda_{j2}, \dots, \lambda_{jn}, \omega_{j1}, \omega_{j2}, \dots, \omega_{jn}$.

或规则如图 2 所示.




图 1 与规则的 SFPN 模型 图 2 或规则的 SFPN 模型

以上规则中, d_j 是前提命题, d_k 是结果命题, λ_j 为阈值, ω_j 为权值.

2.2 自学习模糊 Petri 网的计算方法

2.2.1 使能规则与托肯值输出计算

设 λ_j 为变迁 t_j 的阈值,且 $\lambda_j \in [0, 1], j = 1, 2, \dots, q$; 库所 $p_{j1}, p_{j2}, \dots, p_{jn}$ 中的托肯值分别为 $m(p_{j1}), m(p_{j2}), \dots, m(p_{jn})$; $\omega_{j1}, \omega_{j2}, \dots, \omega_{jn}$ 为变迁 t_j 的各个输入有向弧上的权值.

对于类型 1 的简单规则 SFPN,只有一个输入有向弧,当 $m(p_j)\omega_j > \lambda_j$ 时, t_j 使能,使能的变迁 t_j 触发后, t_j 会向库所 p_k 传送新托肯值 $m^p(p_k) = m(p_j)\omega_j$,而库所 p_k 在样本作用下的托肯值输出为 $m(p_k) = f(m^p(p_k))$;

对于类型 2 的与规则 SFPN,当 $\sum_{i=1}^n m(p_{ji})\omega_{ji} > \lambda_j$ 时, t_j 使能,得到新的托肯值 $m^p(p_k) = \sum_{i=1}^n m(p_{ji})\omega_{ji}$,库所 p_k 托肯值输出为 $m(p_k) = f(m^p(p_k))$;

对于类型 3 的或规则 SFPN,当 $m(p_j)\omega_{ji} > \lambda_{ji}$ 时, t_j 使能,得到新的托肯值 $m^p(p_k) = \max\{m(p_{j1})\omega_{j1}, \dots, m(p_{jn})\omega_{jn}\}$,库所 p_k 托肯值输出为 $m(p_k) = f(m^p(p_k))$.

2.2.2 权值的调整

自学习模糊 Petri 网的权值调整采用下述方法:对于具有 l 层, n 个输入节点 $x_1, x_2, \dots, x_n$, m 个输出节点 $y_1, y_2, \dots, y_m$ 的自学习模糊 Petri 网,设每一输入样本为 s ,其对应的误差函数为

$$E_s = 2^{-1} \sum_k (m'(p_k)^s - m(p_k)^s)^2, \quad (2)$$

其中 $m'(p_k)^s$ 和 $m(p_k)^s$ 分别为样本 s 作用下的期望输出和实际输出.

U 批样本总的误差函数为

$$E = 2^{-1} \sum_s \sum_k (m'(p_k)^s - m(p_k)^s)^2. \quad (3)$$

权值应按 E_s 函数梯度变化的反方向调整,从而使网络收敛.根据梯度法,可得到第 l 层权值的修正公式

$$\Delta \omega_{kj} = -\eta \frac{\partial E_s}{\partial \omega_{kj}} = -\eta \frac{\partial E_s}{\partial m^l(p_k)^s} \frac{\partial m^l(p_k)^s}{\partial \omega_{kj}}. \quad (4)$$

第 l 层节点权值的改进公式为

$$\omega_{kj}(k+1) = \omega_{kj}(k) + \Delta \omega_{kj}. \quad (5)$$

其中: η 为学习率, ω_{kj} 为第 $l-1$ 层节点 j 与第 l 层节点 k 之间的连接权值, $m^l(p_k)$ 为终止库所的托肯值输出.

同理,可得第 $l-1, l-2, \dots, 1$ 层权值的修正公式和改进公式.

3 自学习模糊 Petri 网知识库模型的建立及训练

同一种产品的现有产品(老产品)和后续产品(新产品),在生产和零配件采购等方面往往具有相同或相似的 SFPN 模型结构.利用这种特性,可建立现有产品的 SFPN 网模型并存储于知识库,需要时调出用于后续产品的开发过程,以提高设计、采购、生产、销售等环节的效率.

3.1 现有产品 SFPN 模型知识库的建立

为方便问题的阐述,首先给出两个定义:

定义 2 SFPN 模型的网络架构:指 SFPN 模型的 Petri 网结构,即库所、变迁及其连接关系所组成的网络结构.例如 Petri 网结构相同但参数不同的两类模型便属于同一网络架构.

由于不同企业的同种产品在生产、采购、销售等方面具有相似性,其模型的网络架构也大体相同或相近.

定义 3 SFPN 模型的产品类别:指依据产品之间的相似关系而对产品进行的分类,具备相似性的两种产品可分为一类.例如一种产品与其改进型产品便属于同一类别.

现有产品 SFPN 模型知识库的建立及参数更新步骤如下:

- 1) 知识库初始化为空;
- 2) 等待加入 SFPN 模型,模型输入全部完成后转 7),未完成则继续等待;
- 3) 当有新的 SFPN 模型加入时,将新加入的 SFPN 模型与知识库中已有模型相比较,若它与库中已有模型的网络架构相同且产品类别相同,则将其归为同一架构类别类,并进行参数更新,转 2);
- 4) 若它与库中已有模型的网络架构不同而产品类别相同,则将其归为同一类别类,并进行参数更新,转 2);
- 5) 若它与库中已有模型的网络架构相同而产品类别不同,则将其归为同一架构类,并进行参数更新,转 2);
- 6) 若它与库中已有模型的网络架构和产品类别都不相同,则将其归为一新类,并标注架构和类别标示,转 2);
- 7) 结束.

3.2 新产品 SFPN 模型的建立方法

现有产品 SFPN 模型知识库建立完成后,便可着手建立新产品 SFPN 模型.将新产品所需模型应具有的结构和参数输入知识库,由比较器进行搜索对比,具体步骤如下:

- 1) 在架构类别类中进行搜索,若搜索到同类产

品的 SFPN 模型,则转 6);

- 2) 搜索网络架构类,若搜索到同一网络架构的 SFPN 模型,则转 5);

- 3) 搜索产品类别类,若搜索到同一产品类别的 SFPN 模型,则转 5);

- 4) 未搜索到符合的 SFPN 模型,则将其归为一新类,标注架构和类别标示存入知识库,转 7);

- 5) 将新产品需要具有模型与所搜索到的类的模型相比较,并按下述规则 1 ~ 规则 3 进行处理;

- 6) 新产品 SFPN 模型存入知识库;

- 7) 结束.

根据库所、变迁以及连接关系,二者的差别将满足以下 3 个规则之一:

规则 1 知识库已有模型的库所、变迁以及连接关系的数量多于新产品需要具有的模型,即知识库已有模型包含新产品所需模型,则将知识库模型比新产品所需模型多出的库所和变迁去掉,使其在构架上与新产品所需模型一致.

规则 2 知识库已有模型的库所、变迁以及连接关系的数量少于新产品所需模型,即新产品所需模型包含知识库已有模型,则为知识库已有模型添加相应的库所、变迁以及连接关系,使之与新产品所需模型一致.新添加的网络参数可取现有模型同层参数的算术平均值.

规则 3 知识库已有模型与新产品所需模型的库所、变迁以及相互连接,有的相同,有的不同,则按规则 1 和规则 2 的方法,去掉知识库已有模型比新产品所需模型多出的部分,添加少于新产品所需模型的部分.

SFPN 模型知识库建立及更新流程如图 3 所示.




图 3 SFPN 模型知识库建立及更新流程

新产品 SFPN 模型建立后,虽然在 Petri 网结构上已经完成,但其参数却是现有产品的,因此对刚刚建立的新产品 SFPN 模型进行训练以确定参数是很重要的.由新老产品的相似性,这两个模型在很多参数上是相近的,有些参数甚至是相同的,因此通过较少的训练,在较短时间内便可得到较好的结果.

3.3 新产品 SFPN 模型的训练

本文采用误差反传算法对 SFPN 模型进行训练. 激活函数取非线性连续可导的 S 型 (Sigmoid) 函数

$$f(x) = 1 / (1 + e^{-(x+\theta_1)/\theta_0}). \tag{6}$$

设每一训练样本为 s , 将 U 批样本对网络进行训练. 训练步骤如下:

- 1) 初始化参数 θ_0 和 θ_1 , 允许误差值 ε , 最大训练次数 t , 阈值 λ_j , 学习率 η ;
- 2) 读取样本数据, 按 2.2.1 节计算模型托肯值输出;
- 3) 按 2.2.2 节修正权值;
- 4) 判断误差是否小于 ε 或训练次数是否达到 t , 若达到则停止训练并转 5), 若未达到则继续训练并转 2);
- 5) 将学习后的数据存入知识库并进行参数更新, 样本指针加一, 判断全部样本是否都学习完毕, 若是则转 6), 否则转 2);
- 6) 结束.

为了提高训练时参数收敛的速度, 避免因进入饱和区而导致灵敏度降低的问题, 本例在 SFPN 不同层采用不同参数的 S 型函数. S 型函数的参数可根据先验知识确定^[7], 或通过其他方法^[7,8] 计算得到. 本文在第 4 节的采购预测算例中, 以经验方式对参数进行选择, 各层的 θ_0 均取 0.2.

对于单纯的与规则层, 设集合 $A = \{a_1, a_2, \dots, a_s\}$, 其中元素 a_s 为该层已知第 s 个库所的初始托肯值与对应的初始权值的乘积. 若 $s \leq 6$, 则 θ_1 选取的经验公式为

$$\theta_1 = -\theta_1' \frac{4s}{s^2 + 4}, \theta_1' = \sum_i^s (a_1, a_2, \dots, a_s). \tag{7}$$

对于单纯的或规则层或既有与规则又有或规则的层, 设集合 $B = \{b_1, b_2, \dots, b_t\}$, 其中元素 b_t 为该层已知第 t 个库所的初始托肯值与对应的初始权值的乘积. 若 $t \leq 6$, 则 θ_1 选取的经验公式为

$$\theta_1 = -\theta_1' \frac{t^2 + 4}{4t}, \theta_1' = \max\{b_1, b_2, \dots, b_t\}. \tag{8}$$

当 $s \geq 7$ 或 $t \geq 7$ 时, 应选择其他经验公式, 或通过其他方法计算^[7,8].

4 采购预测举例


下面以某电视机制造企业在零配件采购管理^[9,10] 中的 CPU 采购数量预测为例, 说明 SFPN 在生产管理中的应用.

4.1 新产品初始模型的建立

某家电制造企业生产 32 英寸液晶电视机, 其电视机零配件中 CPU 的采购周期为 2 周. 每个采购周

期依据企业内部因素 (零配件库存、成品库存、生产能力、设备及人员状况) 和企业外部因素 (零配件采购价格、产品销售情况、产品利润) 等制定采购计划, 并依据此采购计划在下一采购周期进行采购.

依据前述 SFPN 模型知识库的建立方法, 可建立现有产品——32 英寸电视机的 CPU 采购预测 SFPN 知识库模型, 如图 4(a) 所示. 其中: 库所 p_1 为设备及人员状况, p_2 为成品库存, p_3 为生产能力, p_4 为 CPU 库存量, p_5 为内部因素, p_6 为产品利润, p_7 为产品销售情况, p_8 为 CPU 采购价格高低的程度, p_9 为采购数量预测值.



(a) 32 英寸电视机 (b) 42 英寸电视机

图 4 电视机采购预测 SFPN 模型

依据 3.3 节所述训练方法, 通过将每次采购预测值、实际采购值以及采购依据的各种因素, 对采购预测 SFPN 模型进行训练, 每次训练完成后都将其存入知识库, 并对知识库进行更新. 经过一定次数的训练后, 便可得到较理想的 CPU 采购预测 SFPN 模型的参数值. 本文假定现有产品 32 英寸电视机的 CPU 采购预测 SFPN 知识库模型已建立好.

根据市场发展的要求, 该企业开始生产新产品——42 英寸液晶电视机. 由于 42 英寸电视机是 32 英寸电视机的后续产品, 二者在生产、采购等方面具有相似性. 依据 3.2 节所述方法, 调用知识库中 32 英寸电视机 CPU 采购预测 SFPN 模型并加以修正, 作为新产品的 CPU 采购预测 SFPN 模型. 42 英寸电视机与 32 英寸电视机相比, 模型参数中多出了内部因素中的新产品生产能力和外部因素中的新产品市场前景, 少了外部因素中的产品利润. 依据 3.2 节所述方法, 在模型网络结构上, 增加代表新产品生产能力的库所 p_{10} 和外部因素中代表新产品市场前景的库所 p_{11} , 去掉外部因素中代表产品利润的库所 p_6 . 修正后的模型如图 4(b) 所示.

设知识库中已有的 32 英寸电视机 CPU 采购预测 SFPN 模型权值为

$$\omega_1 = 0.224, \omega_2 = 0.417, \omega_3 = 0.563,$$

$\omega_4 = 0.729, \omega_5 = 0.475, \omega_6 = 0.489,$
 $\omega_7 = 0.486, \omega_8 = 0.632, \omega_9 = 0.620,$
 $\omega_{10} = 0.447.$

新产品模型按规则 3 所述方法新添加的权值为

$\omega_{11} = 0.483, \omega_{12} = 0.525, \omega_{13} = 0.525.$

4. 2 新产品模型的训练与应用

依据图 4(b) 的模型结构及 SFPN 产生式规则, 可得到此模型的托肯值输出计算公式

$$m(p_9) = f_2(\max(a, b, c)). \tag{9}$$

其中

$$a = m(p_{11})\omega_{12} + f_1(m^p(p_5))\omega_{13},$$

$$b = m(p_7)\omega_7 + f_1(m^p(p_5))\omega_8,$$

$$c = m(p_8)\omega_{10} + f_1(m^p(p_5))\omega_9,$$

$$m^p(p_5) = m(p_1)\omega_1 + m(p_2)\omega_2 +$$

$$m(p_3)\omega_3 + m(p_4)\omega_4 + m(p_{10})\omega_{11}.$$

将模型初始数据代入 3.3 节中 S 型函数参数经验公式, 可得到新产品模型各层的 S 型函数参数. 在此例中, 第 1 层激发函数为

$$f_1(x) = 1/(1 + e^{-(x-1.1)/0.2});$$

第 2 层激发函数为

$$f_2(x) = 1/(1 + e^{-(x-0.4)/0.2}).$$

42 英寸电视机 CPU 采购预测 Petri 网模型的初始知识库模型建立后, 在其 CPU 采购的每一周期, 将归一化的新产品 SFPN 内外采购因素数据及本周期实际采购值(见表 1), 按前述方法进行学习训练. 表 1 中的 $m(p_i) (i = 1, 2, 3, 4, 7, 8, 10, 11)$ 为对应于各库所的因素数据值, $m'(p_9)$ 为实际采购值. 每个采购周期经学习训练后的权值如表 2 所示.

由表 2 可以看出, 经过 10 个采购周期的训练, 权值已经基本稳定, 尤其是内部因素层的权值. 由于新旧产品模型的相似性, 新旧产品模型对应权值也有相似关系, 而且有些参数是很接近的, 例如初始 ω_3 与训练后的 ω_3 .

在此例中, 如果采用神经网络或其衍生方法进行采购预测, 由于没有模型知识库数据, 不能利用老产品参数, 初始权值的选取只能采用随机值或其他数值, 而无法像 SFPN 那样, 利用相似性在知识库中选取与理想权值相近的权值. 初始参数的优化选取对于更快地得到最终预测结果具有重要作用, 采用接近于理想权值的模型, 训练速度和效果要比其他

表 1 42 英寸电视机采购因素数据

采购周期	$m(p_1)$	$m(p_2)$	$m(p_3)$	$m(p_4)$	$m(p_{10})$	$m(p_{11})$	$m(p_7)$	$m(p_8)$	$m'(p_9)$
1	0.346	0.528	0.834	0.693	0.645	0.476	0.637	0.853	0.920
2	0.453	0.604	0.738	0.359	0.526	0.689	0.408	0.576	0.799
3	0.565	0.779	0.812	0.545	0.508	0.477	0.772	0.656	0.911
4	0.434	0.757	0.823	0.345	0.405	0.502	0.512	0.694	0.763
5	0.423	0.819	0.828	0.771	0.636	0.515	0.762	0.517	0.905
6	0.555	0.734	0.828	0.761	0.731	0.561	0.604	0.432	0.844
7	0.433	0.591	0.756	0.637	0.626	0.699	0.443	0.433	0.827
8	0.328	0.645	0.739	0.572	0.329	0.614	0.561	0.586	0.682
9	0.425	0.634	0.758	0.636	0.527	0.587	0.664	0.833	0.818
10	0.529	0.618	0.846	0.781	0.746	0.623	0.812	0.720	0.853

表 2 新产品零配件采购预测 SFPN 模型权值的训练数据

采购周期	ω_1	ω_2	ω_3	ω_4	ω_{11}	ω_7	ω_8	ω_9	ω_{10}	ω_{12}	ω_{13}
1	0.220	0.411	0.554	0.722	0.476	0.486	0.632	0.585	0.415	0.525	0.525
2	0.209	0.396	0.536	0.713	0.463	0.486	0.632	0.585	0.415	0.505	0.506
3	0.201	0.385	0.524	0.705	0.456	0.455	0.597	0.585	0.415	0.505	0.506
4	0.193	0.371	0.509	0.698	0.448	0.455	0.597	0.569	0.397	0.505	0.506
5	0.190	0.365	0.503	0.693	0.444	0.427	0.563	0.569	0.397	0.505	0.506
6	0.186	0.361	0.498	0.688	0.439	0.404	0.528	0.569	0.397	0.505	0.506
7	0.178	0.349	0.483	0.676	0.427	0.404	0.528	0.569	0.397	0.485	0.482
8	0.168	0.330	0.461	0.659	0.417	0.397	0.517	0.569	0.397	0.485	0.482
9	0.164	0.323	0.453	0.652	0.412	0.397	0.517	0.559	0.386	0.485	0.482
10	0.162	0.321	0.450	0.649	0.409	0.386	0.505	0.559	0.386	0.485	0.482

模型都好. 因此, SFPN 方法可在训练次数较少的情况下, 得到与神经网络方法相同甚至比其更好的预测值, 从而能有效缩短训练过程, 优化预测结果.

训练后的权值可作为新产品模型的参数, 并在以后的使用中继续训练, 以不断得到优化. 学习训练后的权值参数与当次周期数据一起, 经计算可得到所需的 CPU 采购预测值. 例如在第 10 周期的训练完成后, 需要得到第 11 周期的采购预测值, 可调入知识库中第 10 周期的权值参数, 并与当前的内外因素数据一起, 按式 (9) 进行计算, 便得到第 11 采购周期采购预测值. 假如第 10 周期的 CPU 实际采购值为 4035 片 (归一化后的值为 0.853), 第 11 周期的内外因素数据为

$$\begin{aligned} m(p_1) &= 0.544, m(p_2) = 0.721, \\ m(p_3) &= 0.730, m(p_4) = 0.625, \\ m(p_7) &= 0.781, m(p_8) = 0.423, \\ m(p_{10}) &= 0.498, m(p_{11}) = 0.562. \end{aligned}$$

调入第 10 周期的权值参数, 经计算可得到第 11 周期的零配件采购预测值 $m(p_9)$ 为 0.776, 还原成实际量为 3967, 即第 11 采购周期应采购 CPU 的数量为 3967 片.

5 结 论

1) 本文利用 Petri 网易于建模和模型直观的特点, 构造了知识化制造系统的自学习模糊 Petri 网知识库, 建立并保存现有产品的 SFPN 模型. 在开发新产品或进行新的决策时, 调出并建立新产品的 SFPN 模型, 便可实现快速决策.

2) 自学习模糊 Petri 网能克服神经网络等预测方法需要大量训练或学习样本的缺点, 利用新老产品模型及参数的相似性, 通过较少时间和少量样本的自学习训练, 就能作出较准确的预测.

3) 采购预测实例验证了自学习模糊 Petri 网的有效性. 自学习模糊 Petri 网不仅可应用于采购, 而且可应用于生产管理和产品制造等其他方面.

参考文献 (References)

- [1] 严洪森, 刘飞. 知识化制造系统——新一代先进制造系统[J]. 计算机集成制造系统, 2001, 7(8): 7-11.
(Yan H S, Liu F. Knowledgeable manufacturing

system: A new kind of advanced manufacturing system [J]. Computer Integrated Manufacturing Systems, 2001, 7(8): 7-11.)

- [2] 江志斌. Petri 网及其在制造系统建模与控制中的应用[M]. 北京: 机械工业出版社, 2004.
(Jiang Z B. Petri nets and the application on modeling and control of manufacturing systems [M]. Beijing: China Machine Press, 2004.)
- [3] Chen S M. Weighted fuzzy reasoning using weighted fuzzy Petri nets[J]. IEEE Trans on Knowledge and Data Engineering, 2002, 14(2): 386-397.
- [4] Li X, Lara R F. Adaptive fuzzy Petri nets for dynamic knowledge representation and inference [J]. Expert Systems with Applications, 2000, 19(3): 235-241.
- [5] Ahson S I. Petri net models of fuzzy neural networks [J]. IEEE Trans on Systems, Man and Cybernetics, 1995, 25(6): 926-932.
- [6] 蔡自兴. 智能控制[M]. 北京: 电子工业出版社, 2004.
(Cai Z X. Intelligent control [M]. Beijing: Publishing House of Electronic Industry, 2004.)
- [7] 吴佑寿, 赵明生, 丁晓青. 一种激励函数可调的新人工神经网络及应用[J]. 中国科学(E 辑), 1997, 27(1): 55-60.
(Wu Y S, Zhao M S, Ding X Q. A new artificial neural network with adjustable excitation function and its application [J]. Science in China: Series E, 1997, 27(1): 55-60.)
- [8] 黄敬频, 周永权. 可调激活函数神经元参数选取方法研究[J]. 工程数学学报, 2005, 22(6): 995-1000.
(Huang J P, Zhou Y Q. The parameter selection method for variable activation function neuron [J]. Chinese J of Engineering Mathematics, 2005, 22(6): 995-1000.)
- [9] Gavirneni S. Periodic review inventory control with fluctuating purchasing costs [J]. Operations Research Letters, 2004, 32(4): 374-379.
- [10] Aburto L, Weber R. Improved supply chain management based on hybrid demand forecasts [J]. Applied Soft Computing, 2007, 7(1): 136-144.