

文章编号: 1003-207(2001)05-0001-07

汇率的非线性组合预测方法研究*

董景荣, 杨秀苔

(重庆大学工商管理学院博士后流动站, 重庆 400044)

摘要:近年来的经济统计研究表明, 组合预测比单项预测具有更高的预测精度, 但线性组合预测方法在汇率的组合建模与预测方面存在着较大的局限性。本文提出了一种基于模糊神经网络的汇率非线性组合建模与预测新方法, 并给出了相应的混合学习算法。对于英镑、法郎、瑞士法郎、日本元对美元等汇率时间序列的组合建模与预测结果表明, 该方法具有很强的学习与泛化能力, 在处理外汇市场这种具有一定程度不确定性的非线性系统的组合建模与预测方面有很好的应用价值。

关键词: 汇率; 组合预测; 信息集; 模糊神经网络

中图分类号: C931:F224 **文献标识码:** A

1 引言

自1973年布雷顿森林体系崩溃以来, 西方各主要工业国家普遍实行了浮动汇率体制, 浮动汇率的频繁且剧烈波动以及由此带来的外汇风险对国际金融、国际贸易和投资以及国家安全都具有关键性的影响作用。因此, 外汇风险问题已引起国际货币基金组织和世界各国的高度重视和广泛研究, 其中如何准确地预测汇率变动的方向和程度是外汇风险管理的基础^[1], 它对于中央银行加强金融监管和微观经济主体规避外汇风险具有重要意义。

在汇率决定理论和预测模型或方法方面, 国外学者取得了显著的进展^[2]。已从不同角度并使用大量的数量经济模型和实证分析对外汇汇率和外汇市场进行了深入的分析研究, 形成了各自不同的观点和模型。然而, 由于汇率系统具有复杂的非线性动力系统特征, 它既受确定性规律支配, 同时又表现出某种随机现象, 即汇率具有时变性、随机性和模糊性的特征^[3], 故目前尚没有一个模型能对频繁波动的汇率事实拟合得非常紧密和对汇率波动的原因作出稳定一致的解释, 尤其是在结构化模型(Structural models)对随机游动模型(the random walk models)是否有效方面, 存在着大量的争论和经验分析^[4]。因此, 各种汇率决定理论和预测模型的提出和争论, 为汇率的组合预测方法研究提供了强有力的背景。

组合预测本质上是将各种单项预测看作代表不同信息的片段(pieces of information)^[5], 通过信息的集成分散单个预测特有的不确定性和减少总体不确定性, 从而提高预测精度。这就如同证券组合分散风险的原理一样, 组合预测相对于单项预测具有更高的预测性能和出现极小预测误差的更小风险^[6]。目前, 根据集结或组合单项预测模型的方式不同, 组合预测一般可分为线性组合预测

收稿日期: 2001-03-05

基金项目: 国家博士后科学基金资助项目(10640); 重庆市科委和重庆市教委科学基金资助项目

作者简介: 董景荣(1966-), 男(汉族), 重庆市巫溪县人, 博士后, 副教授, 硕士研究生导师, 研究方向: 计量经济、技术经济、金融经济。

与非线性组合预测。文献[7-8]虽然从线性组合预测的角度研究了汇率的组合建模与预测问题,并得出了一些有意义的结论,但由于线性组合预测方法本身的局限性和汇率系统的非线性特征,其预测效果并不令人满意^[9]。

基于上述考虑,本文将从一个新的角度即非线性组合预测的角度来研究汇率预测问题,提出了一种基于模糊神经网络的汇率非线性组合预测新方法,并给出了由 Kohonen 自组织算法、有监督的竞争算法以及 BP 算法等组成的混合学习算法,对于 1980 年 1 月至 1989 年 12 月英镑、法国法郎、瑞士法郎和日本元等对美元月末汇率数据,通过数量经济模型、时间序列模型、判断预测和远期汇率的非线性组合建模与预测结果表明,该方法具有很强的学习特性与泛化能力,在处理外汇汇率和外汇市场这种具有一定程度不确定性的非线性系统的组合建模与预测方面有很好的应用价值。

2 基于模糊神经网络的汇率非线性组合预测模型及算法

假设对同一预测问题或事物,有 m 种预测方法,那么可以用映射 $x \in R^n \xrightarrow{u_i} y \in Y \subset R$ 表示第 i 种预测方法。组合预测的非线性组合原理是说不同预测方法的非线性组合(或集结)函数。

$$\hat{y} = f(X) = f(u_1, u_2 \dots u_m) \tag{1}$$

在某种测度之下, $f(X)$ 的度量要比 $u_i(x)$ ($i = 1, 2, \dots, m$) 优越。但在实际的应用中,如何构造出有效的非线性组合函数 $f(X)$ 是十分困难的。因此,有必要引入新的理论和方法来确定相应的非线性组合函数。

在文献[10~12]中,笔者分别采用了人工神经网络的 BP 模型与模糊逻辑系统进行了非线性组合预测函数的模拟,取得了较好的效果。本文进一步将神经网络与模糊逻辑系统相结合,采用模糊神经网络来进行非线性组合预测函数 $f(X)$ 的模拟。其主要好处在于模糊神经网络不但具有人工神经网络的适应能力、学习能力、映射能力与模糊模型的泛化能力,而且还具有以下两方面的优势^[13]:对于神经网络,模糊系统可以将其输入输出信息模糊化,使它能处理模糊信息,可以自适应调整神经网络训练参数,可以辅助理解权值的意义以及确定网络的拓朴结构等;而对于模糊系统,神经网络可以帮助其确定隶属函数、模糊规则及模糊决策算法。

2.1 模糊神经网络的结构

本文采用的汇率非线性组合预测的模糊神经网络的结构如图 1 所示。它本质上是一个基于模糊规则基的 5 层神经网络。第一层结点是输入结点,表示输入语言变量;第五层结点是输出语言变量,它有两个作用,一个是用于训练数据进入网络,另一个是用于输出信号;第二层和第四层的结点是语言项结点,表示各语言项的隶属函数;第三层的每个结点是表示模糊推理规则的规则结点,所有的三层结点构造一个模糊推理规则库。

令 u_i^k 和 o_i^k 分别表示第 k 层第 i 个结点 (net_i^k) 的输入值和输出值,则每一层结点的输入函数 net 和输出函数 f 分别定义如下:

第一层: 结点仅是直接把输入值传递到下一层,则对于第一层的第 i 个结点,有:

$$net_i^1 = u_i^1, o_i^1 = f(net_i^1) = net_i^1 \quad i = 1, 2, \dots, m \tag{2}$$

第二层: 每个结点表示一个模糊集合,如果将隶属层函数确定为正态分布型,那么第二层的第 j 个结点的输出函数便是这个模糊集合的隶属函数,即有:

$$u_{ij}^2 = f(net_i^1), \tag{3}$$

$$net_j^2 = - (u_{ij}^2 - m_{ij}^2) / \sigma_{ij}^2 \text{ 和 } o_j^2 = f(net_j^2) = e^{-n a_j^2} \tag{4}$$




图 1 模糊神经网络的结构简图

其中 $i = 1, 2, \dots, m; j = 1, 2, \dots, n; m_{ij}^2$ 和 σ_{ij}^2 分别表示第 j 个结点隶属函数的中心和宽度。

第三层: 每个结点表示一条推理规则, 规则结点将执行模糊 AND 操作, 则有:

$$u_{ij}^3 = f(\text{net}_i^2) \tag{5}$$

$$\text{net}_j^3 = \min\{u_{ij}^3 \cdot w_{ij}^3\} \text{ 和 } o_j^3 = (\text{net}_j^3) = \text{net}_j^3 \tag{6}$$

其中 $i = 1, 2, \dots, n; j = 1, 2, \dots, h$; 连接权 $W_{ij}^3 = 1$ 。

第四层: 这一层结点将执行模糊 OR 操作, 则有:

$$u_j^4 = f(\text{net}_i^3), u_j^4 = \max\{f(\text{net}_1^3), f(\text{net}_2^3), \dots, f(\text{net}_h^3)\} \tag{7}$$

$$\text{net}_j^4 = u_j^4 \cdot r_{ij} \text{ 和 } o_j^4 = f(\text{net}_j^4) = \text{net}_j^4 \tag{8}$$

其中 $i = 1, 2, \dots, h, j = 1, 2, \dots, p, c \in \{1, 2, \dots, h\}$ 。 r_{ij} 是规则值, 初始规则值可以取一个随机数或由专家直接设定。

第五层: 该层实施逆模糊化作用。按照区域中心(COA)的逆模糊方法, 则有:

$$u_j^5 = f(\text{net}_j^4) \text{ 和 } W_j^5 = \sigma_j^5 \cdot m_j^5 \tag{9}$$

$$\text{net}^5 = \sum_{j=1}^p W_j^5 \cdot u_j^5 = \sum_{j=1}^p \sigma_j^5 \cdot m_j^5 u_j^5 \text{ 和 } f(\text{net}^5) = \text{net}^5 / \sum_{j=1}^p \sigma_j^5 \cdot u_j^5 \tag{10}$$

$$\hat{y}(t) = f(\text{net}^5) \tag{11}$$

其中 $j = 1, 2, \dots, p, m_j^5$ 和 σ_j^5 分别为隶属函数的中心和宽度。

2.2 学习算法

这里采用了一个混合学习算法。首先利用无监督的自组织学习算法初步确定每个输入和输出隶属函数; 然后利用有监督的竞争学习算法发现模糊规则; 最后利用有监督的反传学习算法解决隶属函数的优化问题, 这个混合学习算法优于纯反传学习算法, 因为在反传学习之前, 快速的自组织学习将训练样本分类, 也就是说数据在网络中的内部表示已基本确定, 这样为反传学习节省了许多时间, 大大地提高了反传学习的收敛速度。

2.2.1 发现隶属函数

这一步骤的目的是要在输入空间和输出空间发现隶属函数, 具体地说, 就是要对训练数据进行聚类(cluster), 每一类对应一个模糊子集。这里采用科霍南(kohonen)提出的自组织特征映射(self-organizing Feature Map)算法来发现隶属函数的个数和它们各自的中心和宽度。其具体学习过程如下:

(1) 初始化。对于每一输入模式 $x = (x_1, x_2, \dots, x_n)$, 初始中心值 m_1, m_2, \dots, m_k 可以随机地赋

以 $[\min(x_n), \max(x_n)]$ 区间的值。

(2) 竞争。对初始中心值,按下式进行聚类,即:

$$|x_j - m_c| = \min_i \{|x_j - m_i|\} \quad 1 \leq i \leq k \text{ 和 } 1 \leq j \leq n \quad (12)$$

其中 m_c 是 m_i 中与 x_j 距离最小的中心值。

(3) 学习。将优胜者(距离最小)的中心值 m_c 向 x_j 靠拢,其学习方程为:

$$\begin{cases} m_c(t+1) = m_c(t) + \alpha(t)[(x_j(t) - m_c(t))] & \text{当 } x_j \text{ 属于 } m_c \text{ 的聚类} \\ m_c(t+1) = m_c(t) & \text{当 } x_j \text{ 不属于 } m_c \text{ 的聚类} \end{cases} \quad (13)$$

其中 $t(t = 0, 1, 2, \dots)$ 是迭代次数, $\alpha(t)$ 是时刻 t 的学习率($0 < \alpha(t) < 1$) 是随时间降低的。一般定义 $\alpha(t) = 1/t$ 或 $\alpha(t) = 0.2(1 - t/10000)$ 。当条件 $|m_c(t+1) - m_c(t)| \leq \delta$ 满足时,迭代就中止,其中 δ 是由用户确定的误差限定值。

一旦初步确定了隶属函数的中心,隶属函数的宽度可由下式确定:

$$\sigma_i = \sqrt{\sum_{j=1}^{P_i} (x_j - m_i)^2 / P_i} \quad (1 \leq i \leq k) \quad (14)$$

其中, σ_i 和 m_i 分别为第 i 个隶属函数宽度和中心, x_j 是被观察数据样本, k 是隶属函数结点总数, P_i 是关于第 i 个隶属函数聚类的数据样本总数, R 是复合参数。

2.2.2 确定模糊规则

在隶属函数已经被建立之后,接下来是用同样的数据样本集合确定模糊规则。这个辨识过程从一个全连接神经网络开始。对网络训练之前,初始规则结点个数为 $\Pi T(x_k) = T(x_1) \cdot \dots \cdot T(x_k) \cdot \dots \cdot T(x_p)$, 其中 $T(x_k)$ 是第 k 个输入语言变量 x_k 的隶属函数个数。每个规则结点的扇入连接个数等于输入语言变量的个数,分别从输入语言变量的某个语言项(第二层结点)引入,这些连接表示规则的前提条件。第三层的规则结点和第四层的结点是全连接的,也就是说,每个规则的结点扇出连接个数等于第四层的结点数,这也意味着规则的结果还没有确定,在学习过程中会删去一些结点和连接,最后,每个规则结点的扇出连接个数最多等于输出语言变量的个数,分别引出到各个输出语言变量的某个语言项(第四层结点)上,这一阶段采用有监督的竞争学习算法。其实质与 SOM 一样,目的是对输入模式聚类。不同的是:(1)输入模式是指第三层结点的输出;(2)进行有监督学习,即预先知道输入模式的类别,当一个输入模式送入到网络后,由于预先知道它的类别,可以直接将它对应的连接向量向输入模式靠拢,其具体学习过程可参见文献[14]。

2.2.3 调整和优化规则值

利用有监督的反传学习算法的目的是通过进一步调整规则值 (r_{ij}) 使误差信号 E 最小。设误差评价函数

$$E = \frac{1}{2} [y(t) - \hat{y}(t)]^2 \quad (15)$$

其中 $y(t)$ 为实际输出值, $\hat{y}(t)$ 为网络的预测输出值。根据反向传播算法,有:

$$W(t+1) = W(t) - \eta \frac{\partial E}{\partial w} \quad (16)$$

其中 W 是任意的需要调整的参数, η 是学习率。所以,规则值(r_{ij}) 的相应调整方程可表示如下:

$$r_{ij}(t+1) = r_{ij}(t) - \eta \frac{\partial E}{\partial r_{ij}} \quad (17)$$

其中

$$\frac{\partial E}{\partial r_{ij}} = \frac{\partial E}{\partial f(\text{net}_j^4)} \cdot \frac{\partial f(\text{net}_j^4)}{\partial(\text{net}_j^4)} \cdot \frac{\partial(\text{net}_j^4)}{\partial r_{ij}} \quad (18)$$

根据式(18)至(11), 可得

$$\frac{\partial E}{\partial f(\text{net}_j^4)} = \frac{\partial E}{\partial u_j^5} = \frac{\partial E}{\partial f(\text{net}_j^5)} \cdot \frac{\partial f(\text{net}_j^5)}{\partial u_j^5} \quad (19)$$

$$\frac{\partial E}{\partial f(\text{net}_j^5)} = \frac{\partial E}{\partial \hat{y}(t)} = \frac{\partial [[y(t) - \hat{y}(t)]^2 / 2]}{\partial \hat{y}(t)} = - [y(t) - \hat{y}(t)] \quad (20)$$

$$\frac{\partial f(\text{net}_j^5)}{\partial u_j^5} = \frac{(\sum \sigma_j^5 \cdot m_j^5 \cdot u_j^5) \cdot \sigma_j^5 \cdot m_j^5 - (\sum \sigma_j^5 \cdot m_j^5 \cdot u_j^5) \cdot \sigma_j^5}{\sum \sigma_j^5 \cdot u_j^5} \quad (21)$$

$$\frac{\partial f(\text{net}_j^4)}{\partial(\text{net}_j^4)} = 1 \quad (22)$$

$$\frac{\partial f(\text{net}_j^4)}{\partial r_{ij}} = u_{ij}^4 \quad (23)$$

根据式(16)至(23), 于是就可得出参数 r_{ij} 的具体算法为:

$$r_{ij}(t+1) = r_{ij}(t) + \eta u_{ij}^4 [y(t) - \hat{y}(t)] \{ (\sum_{j=1}^m \sigma_j^5 u_j^5) \sigma_j^5 m_j^5 - (\sum_{j=1}^m \sigma_j^5 m_j^5 u_j^5) \sigma_j^5 \} / (\sum_{j=1}^m \sigma_j^5 u_j^5)^2 \quad (24)$$

其中 $r_{ij}(t)$ 是 t 时刻连接第三层第 i 个结点与第四层第 j 个结点的规则权(或规则值), u_{ij}^4 表示从第三层第 i 个结点到第四层第 j 个结点的输入值, η 为学习率, u_j^5 表示第五层第 j 个结点的输入值, $y(t)$ 为实际输出, $\hat{y}(t)$ 为预测输出, m_j^5 和 σ_j^5 分别表示第五层第 j 个输出隶属函数的中心和宽度。

2.2.4 基于模糊神经网络的汇率非线性组合预测原理

基于模糊神经网络的汇率非线性组合预测原理是: 把各参加组合的汇率模型预测结果作为模糊神经网络的输入向量, 将代表相应时刻的汇率实际值作为模糊神经网络的输出; 然后用足够多的预测案例训练这个系统, 使不同的输入向量得到相应的输出量值, 从而在各参加组合的汇率模型预测结果与汇率实际值之间建立一种非线性映射关系。经过不断地学习及测试, 达到较高的精度之后, 该系统就可以作为非线性组合预测的有效工具, 即可将该系统用于汇率的非线性组合预测, 得到最终预测结果。

3 汇率的组合预测实例

为了说明我们所提出的非线性组合预测方法的有效性, 本文以文献[15]中的汇率预测实例说明组合预测方法的应用。文献[15]采用数量经济模型、判断预测、远期汇率和时间序列模型作为组合项, 利用 1980 年 1 月至 1986 年 12 月的月末数据分别建立了英镑、法郎、瑞士法郎、日本元对美元汇率的组合模型, 对 1987 年 1 月至 1989 年 12 月进行外推预测及检验, 得出了一些有意义的结论。为了便于与文献[15]中的组合预测方法相比较, 本文采用的各单项模型和数据与文献[15]相同。

运用本文提出的基于模糊神经网络的汇率非线性组合预测方法对此群组问题 ($m = 4$) 进行组合建模与预测(在式(24)的反传算法中取 $\eta = 0.5$), 其预测效果评价如表 1 所示, 表 1 同时给出了各单项预测方法的效果评价和简单加权算术平均组合预测模型、残差矩阵组合预测模型、线性回归组合预测模型等常见的线性组合预测方法的效果评价以及基于 BP 网络的非线性组合预测模型

的评价效果。

表 1 预测效果评价表

预测方法		币种				
		英镑	法国法郎	瑞士法郎	日本元	
个体预测法	数量经济模型预测	MAE	0.031	0.289	0.083	6.331
		MAPE	4.34%	6.25%	4.55%	9.86%
	判断预测	MAE	0.031	0.420	0.168	8.683
		MAP	4.45%	7.26%	6.21%	10.86%
	时间序列模型预测	MAE	0.022	0.320	0.079	5.048
		MAPE	4.22%	4.46%	4.32%	6.02%
	远期汇率预测	MAE	0.033	0.299	0.087	7.389
	线性组合预测法	简单平均组合预测	MAE	0.027	0.330	0.092
MAPE			4.35%	5.16%	4.36%	6.81%
残差矩阵组合预测		MAE	0.027	0.416	0.085	6.144
		MAPE	4.94%	5.65%	4.34%	7.67%
线性回归组合预测		MAE	0.032	0.289	0.083	6.331
		MAPE	4.88%	5.01%	4.90%	6.93%
非线性组合预测法	基于 BP 网络的组合预测	MAE	0.029	0.275	0.069	5.861
		MAPE	4.24%	4.42%	4.29%	5.98%
	基于模糊神经网络的组合预测	MAE	0.021	0.264	0.062	5.821
		MAPE	4.22%	4.06%	4.30%	5.75%

* MAE 表示平均绝对误差, 即 $MAE = (\sum_{i=1}^n |y_t - \hat{y}_t|) / n$; MAPE 表示绝对平均百分比误差, 即 $MAPE =$

$[\sum_{i=1}^n (|y_t - \hat{y}_t| / |y_t|)] / n$; 其中 y_t 为预测对象实际值, \hat{y}_t 为预测值。

从表 1 的评价效果可以看出, 两种不同的非线性组合预测方法都较原来的单项预测方法和线性组合预测方法取得了更好的预测效果, 而基于模糊神经网络的非线性组合预测技术明显优于文献[15]提出的基于 BP 网络的非线性组合预测技术。理论分析与应用实例都充分说明了基于模糊神经网络的汇率非线性组合预测的有效性。此外, 笔者还运用本文所提供的方法进行了大量的汇率仿真组合模拟与预测, 均取得令人满意的效果。

4 结束语

目前, 有关汇率问题的理论研究和实证分析的核心与目的之一是试图通过建立各种模型来预测汇率未来的变化趋势或寻找其变化规律。当面对基于不同假设采用不同方法建立的不同模型时, 通常的做法是首先采用假设检验和诊断检查的方法选择最好的模型而拒绝其他模型, 然后通过修改接受的模型希望能够更加接近真实。而 Bates 和 Granger 提出的组合预测的基本出发点就是在大多数需要作出预测的情况下, 难以获得完全的信息集, 即使对于给定的信息集也难以做到最优^[16], 即承认构造真实模型的困难, 将各种单项预测看作代表不同信息的片段, 通过信息的集成分散单个预测特有的不确定性和减少总体的不确性, 从而提高预测精度。本文从组合预测的角度出发, 提出了一种基于模糊神经网络的汇率非线性组合预测新方法, 它具有处理分类边界模糊的数据以及易于引入启发性知识的能力和很强的泛化能力, 它对于推动和促进汇率预测理论的进一步研

究和发展具有一定意义。而且在处理诸如汇率时间序列这种具有一定程度不确定性系统的组合建模与预测方面具有广泛的应用价值。

参考文献:

- [1] Taylor, M. P. The economic of exchange rates[J]. Journal of Economic Literature, 1995, 33: 13- 47.
- [2] Copeland, L. S. Exchange rate and international finance[M]. Addison- Wesley, 1989.
- [3] Hsieh, D. The statistical property of daily foreign exchange rates[J]. Journal of International Economic, 1988, 24: 132 - 145.
- [4] MacDonald, R. and Taylor, M. P. The monetary model of the exchange rate: long-run relationships, short-run dynamics and how to beat a random walk[J]. Journal of International Money and Finance, 1994, 13: 276- 290.
- [5] Winkler, R. L. Combining forecasts: a philosophical basis and some current issues[J]. Int. J. Forecasting, 1985, 5: 605 - 609.
- [6] West, C. T. System-based weight versus series-specific weights in the combination of forecasts [J]. J. Forecasting, 1996, 15(5): 369- 393.
- [7] MacDonald, R. and MaRsh, I. W. Combining exchange rate forecasts: what is the optimal consensus measure[J]. J. Forecasting, 1994, 13: 313- 332.
- [8] 唐小我, 滕颖, 曾勇. 汇率的组合预测模型及应用[J]. 预测, 1996, 3: 31- 36.
- [9] 魏巍贤. 非平稳时间序列的组合预测建模条件及应用[J]. 系统工程与电子技术, 1998, 6: 30- 33.
- [10] Dong Jingrong, Yang Xiutai. Neural network approach to combining forecasts in the ownerships of Chinese motor vehicle[M]. Proceeding of ' 97 international conference on management science & engineering, Harbin institute of technology press, 1997, 99- 104.
- [11] 董景荣, 杨秀苔. 基于模糊逻辑系统的非线性组合预测方法研究[J]. 管理科学学报, 1999, 2(3): 28- 32.
- [12] 董景荣, 杨秀苔. 经济时间序列的非线性组合建模与预测方法研究[J]. 中国管理科学, 2000, 8(1): 27- 33.
- [13] 董景荣, 段虞荣. 用模糊神经网络定量类比龙滩库周区经济[J]. 系统工程理论与实践, 2000, 20(6).
- [14] 谢康林, 傅劲游. 神经模糊逻辑控制系统隶属函数和推理规则的确定[J]. 上海交通大学学报, 1997, 31(8): 28 - 33.
- [15] Thomas, H. L. , Kyung D. N. Combining foreign exchange rate forecasts using neural networks[J]. Global Finance Journal, 1998, 9(1): 5- 27.
- [16] Graner, C. W. J. Forecasting economic time series[M]. 2nd ed. Orland: Acadmic Press, 1986.

Research on Nonlinear Combining Exchange Rate Forecasts

DONG Jing- rong, YANG Xiu- tai

(School of Business Administration, Chongqing University, Chongqing 400044, China)

Abstract: It has been shown in recent economic and statistical studies that combining forecasts may produce more accurate forecasts than individual ones. However, the linear combination forecasting method is known to have the limitation for composite modeling and forecasting of foreign exchange rates. This paper presents a new nonlinear composite forecasting method for exchange rate modeling and forecasting based on fuzzy neural network. Furthermore, the corresponding composite learning algorithm including Kohonen self-organizing future map, supervise competitive learning and back-propagation are used to learn the connection weights of fuzzy neural network and partitions of fuzzy subsets. It has been shown by the composite modeling and forecasting results about the exchange rate time series of the British pound, the French franc, the Swiss franc and the Japanese yen against U. S. dollar that the method has reinforcement learning properties and mapping capabilities. With respect to composite modeling and forecasting of nonlinear system which has some uncertainties, the method is available.

Key words: exchange rates; combining forecasts; information sets; fuzzy neural network