

人工神经网络在中长期汇率预测中的应用*

Application of the Artificial Neural Network in the Mid and Long Term Exchange Rate Forecasting

杨 炯、马洪波
(清华大学经济管理学院 北京 100084)

随着世界经济的发展,世界各国经济的联系越来越紧密,汇率就成了人们越来越关注的问题。现在各国都投入大量人力和物力进行汇率预测。

影响汇率变动的因素是很多的,既有经济因素又有政治因素和心理因素,还有各国中央银行的直接干预。值得注意的是,汇率也受国际炒家的影响。

汇率下调的经济后果

汇率下调的初始动机一般都是为了刺激出口,改善国际收支状况,促进经济增长。但是实践情况和这种政策动机常有很大的出入,那些遭受金融动荡的国家,尽管币值一贬再贬,但国际收入并未见多大改善,经济状况反而恶化。其原因在于,汇率的突发下调常常成为经济秩序被破坏的导火索,而经济秩序被破坏所产生的负面效用远远大于汇率下调所带来的竞争力增加的正面效用。如前所述,由于预期通过交易行为在汇率决定上发挥着关键作用,汇率下调会产生累积循环效应,从而使得金融危机和经济危机被放大。90年代初的墨西哥,如今的东南亚即是明证。

从我国的实践来看,由于外汇在资本项下不能自由流动,所以汇率下调不至于导致金融危机,但其对出口的刺激作用也很有限,一般只会持续一年左右,因而依靠汇率下调来刺激出口会对其政策本身产生反依赖性,即汇率必须不断下调,才能达到政策初衷。从更长期上讲,这种政策并不可取。在短期上,汇率下调会产生对通货膨胀和经济增长双重刺激作用,其传导机制主要有两个:

第一,由于汇率下调,出口成本相对降低,这会大大增加出口商品价格回旋余地,从而提高其竞争力。其后果是,出口商品往往以降低价格的方式来争夺市场。这样,要取得相同出口额就必须增加出口商品的数量。在一般情况下,这会减少国内供给,加剧国内的通货膨胀。但如果国内需求不足,这恰恰可以刺激经济增长。

第二,汇率调整会增加出口需求,从而刺激出口商品价格上涨,这在一般情况下也会加剧国内的通货膨胀,但在国内需求不足的情况下,反而会改善企业的效益,增加国内需求,从而刺激经济增长。

我国的经济增长在经历了一个较长时间的高速期后,目前正进入相对平稳阶段,预期速度在下降;人民币和美元的国内利率虽经几番调整,后者仍高于前者,而且国内的美元利率水平比国外低;我国出口在经过连续几年高速增长后,1998年大幅滑坡,几乎为零增长;再加上国内有效需求不足,所有这些因素都对人民币汇率产生下调压力。但汇率下调作为一项政策能否付诸实施,则需要慎重评估。我国目前国际收支状况较好,对欧美皆顺差,调整汇率会加剧贸易冲突。而对于亚洲,即使汇率调整,也不会有明显的刺激出口效用。也就是说,在目前情况下,汇率下调的效果令人怀疑。此其一。其二,人民币汇率下调可能会导致亚洲货币再掀起一轮贬值狂潮,反过来也会对我国的出口和在我国的 外商投资产生不利影响。因此,作为一项稳健的策略,暂时保持人民币稳定是适宜的。但是,如果我国出口持续下滑,进出口状况严重逆转,而亚洲其他国家货币始终保持在贬值后的低水平状态,那么,我们就有必要对人民币是否定值过高进行重新评估,届时主动下调汇率的政策将是迫不得已的选择。

主要参考文献

- [1] P. A. 萨缪尔逊、W. D. 诺德豪斯, 经济学, 中国发展出版社, 1992 年 12 版
- [2] 陈炳才, 国际收支的理论实践, 中国计划出版社, 1996 年第 1 版 (责任编辑 王宏章)

* 国家社会科学基金资助项目


因此,要做好汇率预测工作,就需要认真地考虑和分析这些因素,诸如,国际收支状况、通货膨胀率、利率水平、政府的政策和干预态度、外汇市场的投机性力量,以及国际金融环境的变化,甚至社会环境的稳定程度、公众心理因素也会对汇率产生直接或间接的影响。由此可见,进行汇率预测是十分困难的,进行中长期汇率的预测尤其如此。

一、汇率的预测方法

汇率的预测方法多种多样,通常分为两类。

一类为基本因素分析法,比如,假设汇率与各种经济因素之间存在一种因果关系,并可以用数学模型来描述。有的学者将汇率表示为本国货币的国内需求、本国货币的国外需求、外国货币的国内需求、外国货币的国外需求、工业产值之差、名义利率之差、通货膨胀率之差等 7 个变量的函数,并用该模型对美元/ 马克(USD/ DEM), 美元/ 日元(USD/ JPY) 等进行了预测,就属于这种类型。这种方法的基本思路可以用图 1 表示。

另一类汇率预测方法为技术分析方法。这是现在理论界应用较多的一种方法。传统的随机游走模型(Random Walk Model 简称 RW) 和指数平滑模型(Exponential Smoothing Model)、回归模型(AR) 和移动平均模型(MA) 等都属于这一类模型。随着高级数学工具的引入,这种预测方法有了很大的发展。如贝叶斯向量自回归模型(BVAR)、阈值模型(Threshold model)、Box-jenkins 方法,等等。



二、人工神经网络(ANN) 方法

由于经济系统是一个复杂的非线性系统,而且系统的环境每时每刻都在发生着变化,因而我们希望能够建立一个参数随预测环境的变化而变化的

非线性模型。以上介绍的模型都不可能做到这一点,而人工神经网络方法则为这一问题的解决提供了可能性。这种方法是将各种经济变量对汇率影响的机制作为“黑箱”来处理,利用神经网络的自学习功能对将来汇率变动作出预测。

1. 人工神经网络方法的基本原理

人工神经网络是一种按照人脑的组织和活动原理而构造的一种数据驱动型非线性模型。它是由神经元结构模型、网络连接模型、网络学习算法等几个要素组成。例如,图 2 就是一个典型的神经网络连接模型,它由输入层、中间层(称为隐含层)和输出层 3 层神经元组成。每相邻两层的神经元之间都有一条带权值的弧线连接。要使神经网络产生所希望的行为,必须对其进行训练,即通常所说的网络学习。学习时,每一条连接弧都不断地调整自己的权值,以使神经网络的实际输出和期望输出之间的方差达到最小,学习的效果直接影响网络的预测精度。




图 2 神经网络典型连接模型

2. 神经元结构模型

神经元是神经网络的基本计算单元,一般是多个输入和一个输出的非线性单元。图 3 是一个完整的神经元结构,其中 S_i 为反馈信息, t_i 为阈值, F 为特性函数, w 为各弧的权值。这样,神经元的输出 Y_i 与各个输入之间的关系可以用下式表示:

$$X_i = \sum W_j x_j + S_i \quad (1)$$

$$Y_i = F(X_i) \quad (2)$$

根据输入输出的特性不同,选择不同的特性函数,常用的特性函数有线性函数、Sigmoid 函数、双曲正切函数等。

3. 神经网络的连接模型

神经网络是从将许多神经元连成一个网络而得名的。网络的连接有单层连接、多层连接、循环连接等几种模式。单层连接只有一个输入层和一个输

出层;多层连接则包含了一个或多个隐含层,如图2所示;而循环连接是指包含反馈的连接方式。




图3 神经元的结构

4. 学习算法

神经网络学习的目的是用一组输入向量产生一组希望的输出向量,学习的过程是通过按预先确定的算法(我们称之为学习规则),慢慢调整网络的权值来实现的。由于神经网络是一种非线性映射关系,各变量之间的相互关系隐含于网络之中,因而当训练中出现一对无关数据时,网络不会收敛,所以我们可以通过网络学习来剔除非相关变量。

5. 神经网络反向传播算法(B- P 算法)

神经网络的学习算法有许多种,比如反向传播(B- P)算法、Hopfield 算法等。其中在非线性预测中最常用的(也是本文采用的)是B- P 算法。下面简单介绍B- P 算法的基本原理。

神经网络学习的目的就是对某一特定的输入产生一个希望的输出,这就需要网络不断地调整连接弧的权值。一般说来,B- P 算法主要有以下几个步骤:(1) 对全部连接弧的权值进行初始化,一般设置成较小的随机数,以保证网络不会出现饱和或反常的情况;(2) 取一组训练数据输入网络,并计算出网络的输出值;(3) 计算该输出值与期望值之间的偏差,然后从输出层反向计算到第一隐含层,向着减少该偏差的方向调整各条弧的权值;(4) 对训练集中的每一组训练数据都重复上面两个步骤,直到整个训练的偏差达到能被接受的程度为止。

B- P 算法的思路清晰,可操作性强,因而被广泛应用。

三、用人工神经网络预测汇率

1. 数据准备

(1) 数据收集

该项研究应用的数据均取自国际货币基金组织编制的‘国际金融统计’(‘International Financial Statistics’)中1991年至1997年上半年的季度统计数据。其中,1991年至1995年的数据作为网络训

练数据,1996年至1997年上半年的数据作为预测效果进行检验的数据。

(2) 变量选取

影响汇率变动的经济因素众多,而且各变量之间又往往具有一定相关性,因而对原始数据进行分析,找出可作为网络输入的变量是一件很复杂的事情。本模型采用了国民生产总值、短期利率、长期利率、工业股票价格指数、消费品价格指数和货币供应量6个变量作为神经网络的输入变量。

2. 数据预处理

本模型采用了以下6个宏观经济变量作为神经网络输入,并进行数据预处理。

I. $g = [\ln(U\ GNP) - \ln(G\ GNP/er)]/10$

II. $C = (UCpi - GCpi)/10$

III. $I = [Ulspi - Glspi]/10$

IV. $r = [Uffr - Gmmr]/10$

V. $m = [\ln(Um2) - \ln(Gm2/er)]/10$

VI. $L = [ULr - GLr]/10$

式中,UGNP为美国GNP(以10亿美元计)

GGNP为德国GNP(以10亿马克计)

UCpi为美国消费品价格指数(1990年为基期)

GCpi为德国消费品价格指数(1990年为基期)

Ulspi为美国工业股票价格指数(折为以1990年为基期)

Glspi为德国工业股票价格指数(折为以1990年为基期)

Uffr为美国短期利率(为美国联邦基金利率)

Gmmr为德国短期利率(为德国市场利率)

Um2为美国货币供应量(以10亿美元计)

Gm2为德国货币供应量(以10亿马克计)

er为德国马克汇率(采用期平均值)

ULr为美国长期利率

GLr为德国长期利率

从研究结果可以看出,这种处理方法是行之有效的,同时,这种处理方法,亦大大地扩大了模型的应用范围。

3. 网络的建立

神经网络的输出变量只有一个,即汇率的对数。该神经网络采用一个输出层、一个输入层和一个隐含层。选用0.8作为隐含层学习率,选用0.6作为输出层学习率,用0.6作为它们共同的动量。

4. 神经网络的学习和检验

用1991年至1995年的数据对神经网络进行训练,为检验网络学习的效果,将训练数据输入网络,得到网络的实际输出。这里,神经网络实际输出为预测汇率,期望输出为实际汇率。则网络学习效果检验如表1所示。

其中实践 B 表示实际汇率,虚线 C 表示预测汇率。由图 4 可以看出,网络的学习效果还是不错的。

表 1 网络学习效果的检验

时间(年,月)	1991, 1	1991, 2	1991, 3	1991, 4	1992, 1
实际汇率	1.5307	1.7348	1.7440	1.6287	1.6194
预测汇率	1.5527	1.7507	1.7683	1.6487	1.6323
时间(年,月)	1992, 2	1992, 3	1992, 4	1993, 1	1993, 2
实际汇率	1.6143	1.4632	1.5422	1.6349	1.6181
预测汇率	1.6000	1.4623	1.5527	1.6653	1.6323
时间(年,月)	1993, 3	1993, 4	1994, 1	1994, 2	1994, 3
实际汇率	1.6777	1.6826	1.7242	1.6617	1.5612
预测汇率	1.6820	1.6989	1.7333	1.6820	1.5683
时间(年,月)	1994, 4	1995, 1	1995, 2	1995, 3	1995, 4
实际汇率	1.5431	1.4803	1.3962	1.4322	1.4232
预测汇率	1.5527	1.4770	1.4049	1.4333	1.4191




图 4 学习效果检验图

值。 $T - T_1$ 为预测区间的个数。对比结果如下:

表 3 ANN 与 RW模型的预测效果比较 (季度水平)

	MSE	MAPE
ANN	0.000300	0.007477
RW	0.004999	0.037926

由上表对比可见, ANN 模型的预测效果较 RW 模型的预测效果的确有了很大提高。




图 5 季度水平预测效果检验图

(2) 半年及一年水平的预测

表 4 半年、一年期限水平的预测效果

	1996 年 上半年	1996 年 下半年	1997 年 上半年	1996 年 全年
实际汇率	1.4954	1.5142	1.6862	1.5048
预测汇率	1.4770	1.4770	1.4477	1.6820

表 5 ANN 与 RW 预测效果比较

	MSE	MAPE
ANN	0.000300	0.007477
RW	0.004999	0.037926

为检验模型的预测效果,引入 MSE 指标和 MAPE 两项指标将该模型(ANN)的预测效果与随机游走模型(RM)进行对比,这两项指标的定义如下:

$$MSE = \frac{1}{T - T_1} \sum_{t=T_1}^T (x_{t+n} - f_{t,n})^2$$

$$MAPE = \frac{1}{T - T_1} \sum_{t=T_1}^T \left| \frac{x_{t+n} - f_{t,n}}{x_{t+n}} \right|$$

式中, x_{t+n} 为 $t + n$ 期的实际值, $f_{t,n}$ 为 t 期预测

计算结果证明, 人工神经网络模型(ANN)比随机游走模型(RW)的预测效果好。并且该人工神经网络模型在实际汇率预测中获得了较好的效果。

人工神经网络是一门新兴的学科,它以分布方式存储信息,以并行协同方式处理信息,具有较强的学习能力和自适应能力,因此日益受到人们的关

(下转第 52 页)

就有 14 种之多。中甸龙胆分布于滇西北地区, 生长在海拔 3 200~3 800 米高山林间、林缘或草甸。

14. 黄花杓兰 *Cypripedium flavum* Marq. 隶属兰科。云南分布有兰科 85 个属, 大约 472 种。兰花系兰科 (*Orchidaceae*) 植物通俗之总称, 为世界著名的花卉, 也是云南八大名花之一, 我国栽培和观赏兰花有着 1 000 多年的悠久历史。杓兰属是兰科中高海拔的代表类群, 全球有大约 40 种, 分布于北温带和喜马拉雅地区, 我国大约有 23 种, 云南约有 15 种。黄花杓兰分布于滇西北地区, 生长在海拔 2 600~3 800 米的山坡林下、灌丛下、草坡, 花大色艳, 造型独特, 有很高的观赏价值。

15. 金脉鸢尾 *Iris chrysographes* Dykes 隶属鸢尾科。我国有大约 60 种, 云南分布有鸢尾属植物

约 20 种。鸢尾 (*Iris*) 植物以花大、鲜艳、造型奇特而著称于世, 栽培历史悠久, 深为各国园艺界所喜爱。在滇西北鸢尾植物遍布亚高山或高山草甸、林下、溪边, 常形成大面积的鸢尾群落。鸢尾植物叶色翠绿, 叶型似剑, 花篮带紫, 浪漫多姿, 许多种类可直接引种栽培供人们观赏。金脉鸢尾分布滇西北地区, 生长在海拔 3 000~4 500 米高山草甸、灌丛下或林缘。

16. 象南星 *Arisaema elephas* Buchet. 隶属天南星科。天南星植物具有一肉穗花序, 外为形态各式各样的佛焰苞, 是很好的园艺观赏植物。云南天南星植物种类丰富, 遗传育种资源丰富多彩。象南星分布在海拔 1 800~4 000 米的河边、林下、草地、草甸或林缘。
(责任编辑 王宏章)

科技动态

有助于建筑物防震的新技术

据英《新科学家》1998 年 10 月 3 日报道: 美国印第安纳诺特里·戴姆大学的工程师宣称, 他们利用细小的磁性颗粒可以防止建筑物或桥梁在地震或飓风时倒塌。这些磁性颗粒是减振的磁性缓冲装置的一部分。建筑师们把缓冲装置埋入建筑物中, 用来吸收来自地震或飓风的能量, 以延长建筑物的寿命和防止建筑物在地震或飓风中倒塌。

目前在建筑物中使用的防震缓冲方法是把橡胶一类的材料和弹性装置安装在建筑物下, 使建筑物的上层结构和地基隔离。但是, 这些方法存在一个问题, 即建筑物的刚性总是一成不变, 仍然不能防止巨大的外力的破坏。

而现在的这种磁性缓冲装置, 可以在建筑物受到地震或飓风的冲击并开始振动时控制其刚性的变化, 对建筑物起到减振作用; 另一方面, 这种装置有一定的弹性,

这样在有飓风时, 建筑物可以像树一样地摇摆, 不会因为“宁折不弯”而倒塌。这一点也是相当重要的。

诺特里·戴姆大学的缓冲装置的原理是: 安装在建筑物地下室(即底层)上的缓冲装置有一个活塞, 它可在一种称为磁性流变体的流体中自由运动, 磁性流变体由悬浮在油中的细小磁性颗粒组成; 在发生地震时, 安在建筑物内的运动传感器可自动检测到有破坏性的水平加速度, 这时计算机就自动接通一个电路, 并驱动一连串的电磁铁, 电磁铁产生的磁场使磁性流变体中的磁性颗粒垂直排列成一行行的小磁棒, 从而使流体阻止横向运动的作用加强, 防止建筑物的摇摆。

诺特里·戴姆大学已在一幢三层楼的建筑物模型上安装了一台实验性缓冲装置, 楼房所受外力相当于里氏 6.9 级地震产生的振动。结果证明, 缓冲装置能减少楼房顶层的横向摇摆(位移) 75%。
(刘先曙)

(上接第 41 页)

注。人工神经网络能通过学习实现输入输出间的非线性映射, 从而达到对所研究的系统内部结构的模拟。人工神经网络在非线形预测方面具有明显优势, 它用于汇率预测的效果比随机游走模型(RW)更好, 所以这种预测是具有现实意义的。

参考文献

[1] 施鸿宝. 神经网络及其应用. 西安交通大学出版社, 1993.
[2] 孙增圻等. 智能控制理论与技术. 清华大学出版社, 广西科学技术出版社, 1997.

[3] Macroeconomics Detenminats of Exchange Rate: a Frequency- Specific Analysis, Wincet Dropsy, Applied Economics, 1996, 28, P55- 63
[4] Currency Substitution and Exchange Rate Determination, Yijian He and Subhash C. Sharma, Applied Financial Economics, 1997. 7, P327- 336
[5] Minimum Variance Prediction of Bilinear Time Series: Derect and Adaptive Versions, Ewa M. Bielinska, Journal of Forecasting, Vol. 12, P459- 480(1992)
(责任编辑 肖庆山)