



No. 2009

Working Paper

汇率货币模型的非线性协整关系检验 ——基于深度 GRU 神经网络

丁剑平 陆晓琴 冯玲

【摘要】

本文采用深度门控循环单元 (GRU) 神经网络探讨三种汇率货币模型 (弹性价格、前瞻性和实际利率差模型) 的非线性协整关系。GRU 技术在深度学习中具有智能记忆、自主学习和强逼近能力等优点。为此, 本文运用该技术对 6 组典型浮动汇率制国别数据进行了非线性 Johansen 协整检验。结果表明, 汇率与宏观经济基本面之间存在非线性协整关系, 从而说明了货币模型在非线性的条件下的有效性, 以及先进的深度学习工具在检验经济理论中的优势。

【关键词】

汇率; 货币模型; 非线性协整; 深度 GRU 神经网络

【文章编号】

IMI Working Paper No.2009



微博·Weibo



微信·WeChat

更多精彩内容请登陆 国际货币网

<http://www.imi.org.cn/>

1937

汇率货币模型的非线性协整关系检验

——基于深度GRU神经网络

丁剑平¹ 陆晓琴² 冯玲³

【摘要】本文采用深度门控循环单元(GRU)神经网络探讨三种汇率货币模型(弹性价格、前瞻性和实际利率差模型)的非线性协整关系。GRU 技术在深度学习中具有智能记忆、自主学习和强逼近能力等优点。为此,本文运用该技术对 6 组典型浮动汇率制国别数据进行了非线性 Johansen 协整检验。结果表明,汇率与宏观经济基本面之间存在非线性协整关系,从而说明了货币模型在非线性的条件下的有效性,以及先进的深度学习工具在检验经济理论中的优势。

【关键词】汇率; 货币模型; 非线性协整; 深度 GRU 神经网络

一、引言

汇率变动不仅从宏观层面上影响一国的政策制定,也从微观角度影响投资者的收益。因此,汇率货币模型的研究无论对于经济理论还是政策实践都有着重大的意义。学术界有关宏观基本面影响汇率波动的研究可以追溯到 20 世纪七十年代中期, Frenkel (1976) [1], Mussa (1976) [2] 和 Bilson (1978) [3] 提出了弹性价格货币模型 (FPMM 模型), 从理论上分析了货币供给、实际收入及长期利率水平对汇率造成的影响。之后较多的文献基于该理论模型及其理论模型变体进行了实证研究。但在实证检验中,并没有得到一致的结论。其支持方普遍认为,货币模型对某些国家某个时间段的检验是有效的,且使用面板数据能较好实现汇率与

经济基本面之间的长期均衡关系,其中外商直接投资(FDI)、生产率等也会影响汇率,认为无约束下的货币模型胜过随机游走及其他模型[4-8]。而作为理论模型的反对方, Meese and Rogoff (1983a, b) [9-10] 和 Cheung 等(2005) [11]都指出货币模型的解释力是非常差的,文[12-14]进一步验证了理论模型检验效果不佳。Dinçer Afat (2015) [15]则对经济合作与发展组织(OECD)成员国数据进行了协整检验,也指出传统理论模型存在不足。

总体来看,有关汇率货币模型的研究,无论是支持方还是反对方、短时间检验或者长时

¹ 丁剑平, 中国人民大学国际货币研究所学术委员, 上海国际金融与经济研究院副院长

² 陆晓琴, 上海财经大学金融学院博士生

³ 冯玲, 上海财经大学金融学院

期测度, 现有文献主要关注汇率与经济基本面之间的长期线性关系。而在线性回归预测或线性协整检验结果不理想的情况下, 学术界倾向认为理论模型存在失效。然而现实经济系统中, 非线性关系才是最普遍的, 当假设为线性时, 检验通常是低效力的[16]。所以线性检验结果不理想, 是否有可能源自于线性方法并不足以捕捉宏观基本面和汇率之间的关系? 事实上, 理论模型普遍推测宏观基本面和汇率波动之间存在非线性关系, 即便是最简单的购买力平价理论, 也认为汇率和宏观基本面之间存在非线性关系, 而居于学术前沿的一般均衡理论模型更是认为汇率和宏观基本面之间存在非常复杂的非线性关系。近年来, 有关汇率和宏观基本面的研究, 也逐渐转向非线性协整关系[17-18]。计算机领域机器学习的发展更是为探讨汇率和宏观基本面之间的非线性关系提供更加可靠的工具。本文即旨在通过使用机器学习中的 GRU 循环神经网络, 以挖掘汇率和宏观基本面之间的非线性关系, 为理解汇率理论提供新的证据。

非线性协整旨在研究序列之间长期非线性均衡关系, 最早由 Meese and Rose(1991)[19]、Granger(1995)[20]运用线性可加模型对协整进行了拓展。张喜彬等(1999)[21]、孙青华(2000)[22]等对非线性协整的存在、及其各分整序列的非线性协整性质进行了相关研究。检验非线性协整的关键在于非线性协整模型的构造。为此, 张喜彬等(1999)[21]提出使用神经网络来构造非线性协整模型。这为多变量非线性均衡关系的研究提供了理论工具。相关文献使用神经网络对 1999 年 1 月 4 日至 2001 年 12 月 31 日年间的上证综合指数(SH)和深证成分指数(SZ)数据进行非线性协整检验, 发现检验结果比线性协整检验结果好, 在线性协整未找到协整关系的情况下, 运用神经网络方法捕捉到了两指数之间的长期非线性协整关系[23-24]。

近年来, 随着智能时代来临及金融数据分析需求提升, 深度学习已成为金融领域的应用前沿[25]。深度学习中对时序数据具有较强记忆与智能逼近能力的长短期记忆神经网络(Long Short-Term Memory, 简称 LSTM), 门控循环单元神经网络(Gated Recurrent Unit, 简称 GRU)等循环神经网络模型, 为构建非线性协整模型, 探讨长时间序列货币模型的非线性均衡关系提供了一条新思路。已有文献采用传统神经网络来研究变量之间的非线性协整关系[23,26]。但传统神经网络只做简单的特征提取, 且偏好截面数据分析, 不适合研究长时间序列之间的非线性均衡关系, 因为后者强调时间轴上的相关性, 比之传统神经网络, GRU 和 LSTM 循环神经网络的优势在于可以进行更为复杂的多层特征提取, 挖掘时间轴上的特性, 更适合研究长时间序列关系。因为深度 LSTM 和 GRU 循环网络具有强大的学习能力和建模能力, 在时序经济数据建模中有着较大的优势, 所以经济学文章倾向使用此类模型去预

测股票市值变化、通货膨胀等等[27-28]。尤其 GRU 模型作为循环网络的最新变体，其特殊的门结构能够有效地解决长时间序列上的变化问题，大大的降低了运算量，成为了时序数据建模的有效工具[29-34]。但比较遗憾的是，目前尚无经济学文章将 GRU 引入非线性协整建模工作中。本文希望可以起到抛砖引玉的作用，将 GRU 引入经济学工作中，以扩展宏观经济学中协整实证检验的工具箱。

本文运用深度 GRU 神经网络对弹性价格货币模型（Flexible price monetary model）、前瞻性货币模型（Forward-looking monetary model）和实际利率差模型（The Real Interest Differential Model）三个经典理论货币模型进行非线性协整检验，考察浮动汇率制国家的汇率和宏观基本面之间是否存在长期非线性均衡关系。基于理论模型是小国经济体，且资本自由流动的前提假设，本文选择三组韩元货币对，同时考虑到与一般文献较多选择美元货币对形成对比，本文还选择了三组美元货币对。所以，本文研究的六组货币对所对应的国家分别为：美国与英国、美国与日本、美国与欧盟、韩国与澳大利亚、韩国与加拿大、韩国与墨西哥。研究发现 GRU 神经网络较好的找到了汇率与基本面序列间的长期非线性均衡关系，汇率的货币模型在非线性条件下是有效的。

二、 汇率的货币模型

（一） 汇率的货币模型介绍

本小节介绍三种经典的汇率货币模型，分别为：弹性价格货币模型（FPMM）、前瞻性货币模型（FLMM）和实际利率差模型（RIDM）。除非特别说明，本部分所有带*变量代表国外变量。

第一，弹性价格货币模型（Flexible price monetary model），简称 FPMM 模型或称为 Frenkel-Mussa-Bilson 模型[1-3]。该模型的理论基础是凯恩斯货币需求函数和购买力平价（PPP）。具体数学表达式为：

$$E_t = \frac{P_t}{P_t^*} = \frac{M_t Y_t^{*k} e^{-\alpha^* r_t^*}}{M_t^* Y_t^k e^{-\alpha r_t}} \quad (1)$$

其中， E_t, P_t, M_t, Y_t, r_t 分别代表汇率，商品价格，货币供给，收入和利率。 k, α 为货币需求对收入和利率的弹性系数，并且假定国内外相等。

第二，前瞻性货币模型（Forward-looking monetary model），简称 FLMM 模型。该模型是在 FPMM 模型的基础上进行修正，并且假定理性汇率预期，以及两国货币需求对收入和

利率的弹性系数相同（即 $k = k^*, \alpha = \alpha^*$ ），数学表达式为：

$$E_t = \frac{M_t}{M_t^*} \left(\frac{Y_t}{Y_t^*} \right)^{-k} \quad (2)$$

第三，实际利差模型（The Real Interest Differential Model），简称 RIDM 模型。该模型是 Dornbusch (1976) [35] 和 Frankel (1979) [36] 在 FPMM 模型和 FLMM 模型的基础上进行修正。表达式为：

$$E_t = \frac{M_t}{M_t^*} \left(\frac{Y_t}{Y_t^*} \right)^{-k} e^{\alpha(l_t - l_t^*) - \frac{1}{\rho}(s_t - s_t^*)} \quad (3)$$

其中 s_t 、 l_t 分别表示为短期利率和长期利率， ρ 表示汇率调整到均衡的速度，主要取决于价格的粘性程度。

（二）对三个模型的思考

本小节的分析显示，三个经典模型中，汇率同宏观基本面变量之间存在非线性关系。但技术发展的不足，使得文献在进行相关探讨时，往往采用取自然对数一阶展开的方式得到线性关系，以允许经典线性计量工具（如线性回归、线性协整等）能够对模型进行验证。而较多文献对（1）式、（2）式、（3）式取自然对数进行线性实证检验时，结果都不令人满意，例如表 1。

表 1 相关货币模型实证研究失效的情况

作者	研究对象	理论模型	实证方法	实证结论
Meese and Rogoff (1983) [9-10]	美元货币对（英镑、日元、马克）	FPMM、RIDM	线性回归及向量自回归预测	货币模型预测能力低于随机游走模型
Baillie and Selover (1987) [12]	美元货币对（英镑、日元、马克、加元、法郎）	RIDM	OLS、VAR 预测，Johansen 线性协整	预测结果不理想，线性协整未通过
Kearney and MacDona (1990) [13]	澳元/美元	FLMM、FPMM、RIDM	Johansen 线性协整	没有通过线性协整
Cheung et al (2005) [11]	美元货币对（英镑、日元、马克、加元、瑞士法郎）	FPMM 及变体（含生产力差异等）	线性回归预测，Johansen 线性协整	货币模型预测能力低于随机游走模型
陈平和李凯 (2010) [14]	人民币/美元	RIDM	滚动线性回归预测	货币模型预测能力低于随机游走模型
Dinçer Afat (2015) [15]	OECD 成员国货币	FLMM、FPMM、RIDM	Johansen 线性协整	大部分货币对没有通过线性协整

随着计量经济学和电脑技术的发展，学术界可以使用新的计量方法（如非线性回归、非线性协整等）来寻找不同变量之间的相关性。那么，我们是否有可能在前人研究的基础上，利用新技术，找到汇率与宏观基本面之间的长期非线性关系？得到一致的实证结论？GRU

等循环神经网络模型的发展，则使得人们可以对数据进行深度学习，进一步挖掘时序数据中的记忆功能。为此，本文尝试利用深度 GRU 技术探讨汇率与宏观基本面之间的长期非线性协整关系。

三、基本方法

非线性协整检验方法主要有推广的 E-G 两步法、秩检验法、记录数协整检验及神经网络等方法。其中，神经网络方法可以无限逼近未知的非线性结构，具有较其他方法更好的检验效果。为此，本文借鉴张喜彬等（1999）[21]、樊智等（2005）[23]、许启发（2007）[37]、黄超等（2014）[38]用神经网络构建非线性协整函数的方法，试图找寻理论所预测的汇率与基本面之间非线性协整关系。首先对序列进行长记忆特性检验，因为如果数据序列之间存在非线性协整关系，那么意味着序列数据一定要具有长记忆特性才可以。其次，具体采用深度 GRU 神经网络的方法来构建非线性协整函数。深度 GRU 神经网络继承了一般神经网络自主学习、智能逼近的能力，同时还具有普通神经网络所不具备的传递记忆功能，更具有对时序数据挖掘上的优势。最后，检验所构建的 GRU 模型残差是否为短记忆序列（SMM）。若残差为短记忆序列，则说明 GRU 较好的吸出了序列间的非线性特性，证明序列间存在非线性协整关系。

（一）序列长记忆检验

对于长记忆序列(LMM)的检验，最早由 Hurst(1951) [39]提出用重标极差分析法(rescaled range analysis, 简称经典 R/S) 来分析时间序列的长记忆性，后由 Lo(1991) [40]进行修正：

$$\mathcal{Q}_n^0 = \frac{1}{p} \sum_{i=1}^p \mathcal{Q}_n^i = \frac{1}{p} \sum_{i=1}^p \frac{R^i(n)}{\sigma_n^i(q)} \quad (4)$$

$$\text{其中, } R^i(n) = \max_{1 \leq n \leq T} \sum_{j=1}^n (x_{ji} - \bar{x}_i) - \min_{1 \leq n \leq T} \sum_{j=1}^n (x_{ji} - \bar{x}_i),$$

$$\begin{aligned} \sigma_n^{2i}(q) &= \frac{1}{n} \sum_{j=1}^n (x_j^i - \bar{x}^i)^2 + \\ &\frac{2}{n} \sum_{j=1}^q \omega_j^i(q) \left[\sum_{k=j+1}^n (x_k^i - \bar{x}^i)(x_{k-j}^i - \bar{x}^i) \right] \\ &= S^{i2}(n) + 2 \sum_{j=1}^q \omega_j^i(q) \gamma_j^i \end{aligned}$$

$x_t, (t=1, 2L T)$ 表示时间序列，将其划分为 $p = \text{int} \left[\frac{T}{n} \right]$ 个子样本区间，并取整数。每个子样本区间都含有 n 个观测值，用 i 表示第 i 个子样本区间， $(1 \leq n \leq T, i=1, 2, L l)$,

$\omega_j^i(q) = 1 - \frac{j}{q+1}$, q 为滞后期, γ_j^i 为第 i 个子样本区间的自协方差估计值。 $S^{2i}(n)$ 为每个子样本的方差。不同的 n 值可以得到修正的 R/S 统计量序列。

在 $\{X_t, t=1, 2, \dots, n\}$ 是短记忆序列的零假设下, 修正 R/S 统计量 Q_n 具有分布函数 $F(v) = 1 + 2 \sum_{k=1}^{\infty} (1 - 4k^2 v^2) e^{-2(kv)^2}$, 其中, v 为分位数。通过该分布函数可以得到任意显著性水平下的临界值。

Lloyd 等 (1966) [41] 研究表明, 当 n 无限增大时, 重标极差统计量 Q_n 可用经验公式表示:

$$Q_n = R/S = \theta n^H \quad (5)$$

其中, θ 为常数, H 为 Hurst 指数。对 (5) 式两边取对数, 得到:

$$\log(R/S) = \log(\alpha) + H \log(n) \quad (6)$$

绘制 $\log\text{-}\log$ 图, OLS 拟合 $(\log(R/S), \log(n))$, 就可以求出 Hurst 指数。当 Hurst 指数大于 0.5 时, 说明序列具有长记忆性。

彼得斯 (1999) [42] 研究指出, Hurst 指数与差分阶数 d 还存在如下关系: $H = 0.5 + d$ 。

因此, 通过 Hurst 指数可以求得差分阶数 d 。若所得 d 为分数 ($0 \leq d \leq 1$), 则认为序列具有长记忆特性。

为更精确的判断序列的长记忆特性, 本文在对各序列长记忆检验时将对比验证运用 $F(Q)$ 值、Hurst 指数以及差分阶数 d 值三种不同方法所测度的长记忆检验结论。

(二) 深度 GRU 构建非线性协整函数

GRU 神经网络由 Cho, et al. (2014) [29] 提出, 用于序列数据建模。根据非线性协整系统的特点, 构建图 1 的 GRU 神经网络模型。




图 1 用于非线性协整建模的 GRU 神经网络模型

在每个时刻 t ($t=1, 2, \dots, T$)，网络分为输入层、隐藏层和输出层三层，输入层与隐藏层、隐藏层与输出层之间用不同的权重值来连接。其中，输入层 $X_{nt} = (x_{1t}, x_{2t}, \dots, x_{Nt})$ 表示 N 维输入向量 ($n=1, 2, \dots, N$)；隐层神经元数为 m 个 L 模块（图 1 表示每个时刻有 $m=1$ 个神经元 L 模块，多个神经元只需重复叠加，并用不同权重连接输入向量和输出向量即可），其中 ($m=1, 2, \dots, M$)；输出层为 1 维 y_t 。本文在 FLMM 模型中，设置输入层由两国汇率、货币供给之差、收入之差构成的 3 维 ($n=3$) 输入向量 $X_{3t} = (e_{1t}, m_{2t}, y_{3t})^T$ ，FPMM 模型中，设置输入层由两国汇率、货币供给之差、收入之差及长期利率差构成的 4 维 ($n=4$) 输入向量 $X_{4t} = (e_{1t}, m_{2t}, y_{3t}, l_{4t})^T$ ，RIDM 模型中，设置输入层由两国汇率、货币供给之差、收入之差、短期利率差及长期利率差所组成的 5 维 ($n=5$) 输入向量 $X_{5t} = (e_{1t}, m_{2t}, y_{3t}, s_{4t}, l_{5t})^T$ ；基于隐层神经元数不超过观测值三分之二及极小化误差的原则，将隐层神经元数控制在 150 ($m=1, 2, \dots, M, M \leq 150$) 以内进行调试；输出层为 1 维 y_t 。

在 t 时刻，从 n 维输入层向量到 m 个隐层神经元 L 模块的连接权重为 V_{nmt} ，从 m 个隐层神经元 L 模块到输出层 y_t 的连接权重为 ω_{mt} ，($t=1, 2, \dots, T$)，($n=1, 2, \dots, N$)，($m=1, 2, \dots, M$)，因此 FLMM、FPMM 及 RIDM 模型中需要学习的主循环参数向量分别为 V_{nmt}, ω_{mt} 。

经典循环神经网络 L 模块只是一个 $\tanh$ 函数，而 GRU 神经网络 L 模块是复杂的门限结构，网络不仅要自主学习并调节以上主循环的参数向量，还要学习每个单元门限结构中重置门、更新门及候选记忆单元中的参数向量，能够更有效的挖掘数据中的记忆功能。以隐层神经元节点为 1（即 $m=1$ ）时分析，其实现的单个 L 模块单元映射关系如下：

$$\begin{aligned} \text{重置门: } z_t &= \delta(W_{nzt} X_{nt} + W_{zt} h_{t-1} + b_{zt}) \\ \text{更新门: } r_t &= \delta(W_{nrt} X_{nt} + W_{rt} h_{t-1} + b_{rt}) \\ \text{候选记忆单元: } \hat{h}_t &= \tanh(W_{rht} (r_t * h_{t-1}) + W_{nh_t} * X_{nt}) \\ \text{当前时刻记忆单元: } h_t &= (1-z_t) * h_{t-1} + z_t * \hat{h}_t \\ \text{输出层: } y_t &= \delta(\omega_t * h_t) \end{aligned}$$

其中， δ 为激活函数（通过对网络调试，选择非线性的 sigmoid 函数或 $\tanh$ 函数）。 z_t 和 r_t 分别为重置门和更新门。 W_{nzt} 和 W_{nrt} 分别代表重置门 z_t 和更新门 r_t 中输入向量

$X_{nt} = (x_{1t}, x_{2t}, \dots, x_{Nt})$ 的权重, W_{zt} 和 W_{rt} 分别代表重置门 z_t 和更新门 r_t 中上一时刻记忆单元 h_{t-1} 的权重, b_{zt} 和 b_{rt} 分别表示重置门 z_t 和更新门 r_t 中的偏置 (截距项), W_{rht} 和 W_{nrht} 分别表示候选记忆单元中上一时刻记忆信息 $r_t * h_{t-1}$ 和当期输入向量 $X_{nt} = (x_{1t}, x_{2t}, \dots, x_{Nt})$ 的权重。因此, FLMM、FPMM 及 RIDM 模型在 L 模块单元中需要学习权重向量 W_{nzt} 、 W_{nrt} 和偏置 b_{zt} 、 b_{rt} 。

网络学习按照极小化误差来实现:

$$E = \frac{1}{2} \sum_{t=1}^T (D_t - y_t)^2 \quad (7)$$

其中输出层指导值序列 $\{D_t\}$ 选择以序列样本 X_{nt} 的平均值为均值的白噪声时间序列[37]。通过自主学习循环权重和每个 L 模块单元中的权重, 能够较好的实现网络误差极小化, 实现对过往信息的深度记忆学习, 从而构建有效的非线性协整函数。

在模型极小化误差过程中, 本文主要采用 RMSprop 优化器来实现, 在无法获得最优解的情况下, 选用 Nadam 优化器进行调试。RMSprop 优化器是将学习率 η 替换为 η 除以平方梯度的指数衰减平均值。而 Nadam 优化器是对学习率和梯度方向都添加了衰减项。这两种优化器能防止时间序列信息传递过程中的衰减难题, 具有更高的学习效率。同时, 为了提高学习效率, 我们也在输入层设置了丢弃率 dropout (维持在 0.2-0.3 进行调试), 即暂时丢弃个别神经单元以提高学习速率。

最后采用修正 R/S 统计量 $\mathcal{Q}_n^{\%}$ 对以上 GRU 模型的残差序列进行短记忆特性检验。

四、实证研究

(一) 数据的选取及基本描述

根据第二部分的汇率货币模型和第三部分的基本方法, 本节分别对 FLMM、FPMM、RIDM 三个理论模型进行非线性协整检验。本文选取美国与英国 (USA-UK)、美国与日本 (USA-JP)、美国与欧盟 (USA-EU)、韩国与澳大利亚 (KOR-AUS)、韩国与加拿大 (KOR-CAN)、韩国与墨西哥 (KOR-MEX) 六组典型浮动汇率制国家的货币对进行实证检验, 并采用月度数据进行分析。M1 和工业生产指数分别为理论模型中的货币供给数据 (M) 和实际收入数据 (Y), 并经过季节性调整。理论模型中的短期利率和长期利率均来自 OECD 官网给出的长短期利率数据。

所有数据来源于 OECD 官网, 除了墨西哥长期利率用墨西哥央行提供的 3 年期国债收

益率替代，美元与欧元汇率由 Wind 数据库给出的日度数据取均值得到。此外，考虑数据的可得性，有韩元参与的货币对样本区间统一为 2000 年 10 月至 2017 年 10 月，美国与英国的样本区间为 1986 年 10 月至 2017 年 11 月，美国与日本的样本区间为 2002 年 4 月至 2017 年 11 月，美国与欧盟的样本区间为 1999 年 1 月至 2017 年 11 月。

除利率外对所有数据取自然对数，考虑到数据量纲不同及数量级差别较大，会影响神经网络训练精度，因此，在此基础上再对所有数据进行归一化处理：

$$x_t' = \frac{x_t - x_{\min}}{x_{\max} - x_{\min}} \quad (8)$$

其中， x_t 为某一指标在 t 月的实际数值， $x_{\min}$ 和 $x_{\max}$ 分别表示某一指标所有月份中的最小值和最大值。 x_t' 为 t 月某指标归一化后的值。用 e_t ， m_t ， y_t ， s_t ， l_t 分别代表两国汇率、货币供给 M1 之差、实际收入（工业产出指数）之差、短期利率之差和长期利率之差，并已完成归一化处理。

基于数据准备，本文先运用常规 Johansen 线性秩检验方法，对三种理论模型六组货币对进行线性协整检验。表 2 汇报了线性协整秩检验的迹统计量结果（最大特征值检验结果相同，介于篇幅限制，没有汇报，有需要的读者可问作者索要）。由表 2 可知，韩元和澳元货币对的三个理论模型，美元和英镑货币对、韩元和加元以及韩元和比索货币对的部分理论模型都没有通过线性协整检验。这说明仅用线性检验方法不足以捕捉宏观基本面和汇率之间的关系。因此，有必要进一步探究序列间的非线性协整关系。

表 2 线性协整检验结果

货币对	理论模型	原假设	特征值	迹统计量	5%临界值	p 值
USA-UK	FLMM	None	0.046	25.403	29.797	0.148
		At most 1	0.017	8.068	15.495	0.458
	FPMM	None *	0.101	69.912	47.856	0.000
		At most 1 *	0.055	30.645	29.797	0.040
	RIDM	None *	0.109	85.966	69.819	0.002
		At most 1	0.063	43.198	47.856	0.128
USA-JP	FLMM	None *	0.165	50.591	29.797	0.000
		At most 1 *	0.084	17.236	15.495	0.027
	FPMM	None *	0.178	73.294	47.856	0.000
		At most 1 *	0.125	36.940	29.797	0.006
	RIDM	None *	0.185	88.176	69.819	0.001
		At most 1 *	0.123	50.248	47.856	0.029
USA-EU	FLMM	None *	0.182	57.691	29.797	0.000
		At most 1	0.045	12.385	15.495	0.139

	FPMM	None *	0.214	83.488	47.856	0.000
		At most 1	0.080	29.421	29.797	0.055
	RIDM	None *	0.222	97.178	69.819	0.000
		At most 1	0.095	40.769	47.856	0.196
	FLMM	None	0.044	17.668	29.797	0.591
		At most 1	0.034	8.6756	15.495	0.396
KOR-AUS	FPMM	None	0.101	38.899	47.856	0.264
		At most 1	0.037	17.562	29.797	0.599
	RIDM	None	0.138	64.266	69.819	0.128
		At most 1	0.087	34.471	47.856	0.476
	FLMM	None	0.074	24.574	29.797	0.177
		At most 1	0.037	9.101	15.495	0.356
KOR-CAN	FPMM	None *	0.131	54.233	47.856	0.011
		At most 1	0.083	25.705	29.797	0.138
	RIDM	None *	0.154	84.124	69.819	0.002
		At most 1 *	0.117	50.184	47.856	0.030
	FLMM	None	0.080	23.560	29.797	0.220
		At most 1	0.031	6.717	15.495	0.611
KOR-MEX	FPMM	None *	0.154	58.763	47.856	0.003
		At most 1	0.077	25.064	29.797	0.159
	RIDM	None *	0.145	73.357	69.819	0.025
		At most 1	0.120	41.825	47.856	0.164
	FLMM	None	0.080	23.560	29.797	0.220
		At most 1	0.031	6.717	15.495	0.611

（二）序列的长记忆性检验

参照樊智等（2005）[23]、许启发（2007）[37]、黄超等（2014）[38]通过 $F(\frac{R}{S})$ 值来判断序列的长记忆性方法。本文利用 Lo(1991)[40]提出的修正 R/S 统计量 $\hat{R}_n^H$ 对序列进行 LMM 检验，运用 MATLAB 2016 编程，对时间序列 e_t , m_t , y_t , s_t , l_t 进行长记忆检验，其结果见表 3。

表 3 汇率及宏观经济基本面序列的长记忆检验

货币对（国家）	检验参数	e_t	m_t	y_t	s_t	l_t
USA-UK	$\hat{R}_n^H$	4.1532	5.2545	9.5426	8.2434	7.9930
	$F(\frac{R}{S})$	1	1	1	1	1
	显著性水平	0	0	0	0	0
USA-JP	$\hat{R}_n^H$	4.2511	5.2333	3.2827	3.0424	4.6032
	$F(\frac{R}{S})$	1	1	1	1	1
	显著性水平	0	0	0	0	0
USA-EU	$\hat{R}_n^H$	3.7538	4.1352	4.1123	2.8590	5.8039
	$F(\frac{R}{S})$	1	1	1	1	1
	显著性水平	0	0	0	0	0
KOR-AUS	$\hat{R}_n^H$	5.0489	3.7904	7.3167	4.9899	2.5260
	$F(\frac{R}{S})$	1	1	1	1	1

	显著性水平	0	0	0	0	0
KOR-CAN	χ^2	5.8984	4.1241	7.3479	4.1166	4.1543
	F	1	1	1	1	1
	显著性水平	0	0	0	0	0
KOR-MEX	χ^2	3.2799	4.5105	7.1266	4.3424	7.7891
	F	1	1	1	1	1
	显著性水平	0	0	0	0	0

由表 3 可知,在零假设为短记忆的显著性水平都为 0,说明拒绝原假设的出错概率为 0,六组国家的汇率及基本面各序列都为长记忆序列。

钟正生和高伟(2009)[43]、谢赤和岳汉奇(2012)[44]等学者认为采用 F 值来判断序列长记忆特性是不够的,应继续求 Hurst 指数来判断序列是否为长记忆序列。为此,基于第三部分基本方法,本文进一步建立 $\log(R/S)-\log(n)$ 图,通过 OLS 对点列 $(\log(R/S), \log(n))$ 进行拟合(见图 2),其中纵坐标为修正 R/S 统计量序列取对数,横坐标为对应的子样本序列数 n 取对数。所有 OLS 回归的拟合优度 $R^2 \geq 0.98$ 。由图 2 可知,最小二乘法较好的拟合了点列 $(\log(R/S), \log(n))$ 。根据式(6),Hurst 指数为拟合函数的斜率。从图 2 发现所有 Hurst 指数(函数斜率)均大于 0.5,说明六组国家的汇率与各经济基本面序列都为长记忆序列。




图 2 汇率与各经济基本面序列

Bailie 等(1996) [45]、钟正生和高伟 (2009) [43]等认为还应该进一步用差分阶数 d 来验证序列的长记忆特性。为此, 由彼得斯 (1999) [42]所提出的 $H = 0.5 + d$ 关系式, 得到差分阶数 d (见表 4)。由表 4 结果显示, 六组国家的汇率与各经济基本面序列的差分阶数不是整数, 而是分数, 并且差分阶数各不相同, 说明各序列为长记忆序列。

表 4 样本序列差分阶数 d

货币对	e_t	m_t	y_t	s_t	l_t
USA-UK	0.3356	0.8022	0.6361	0.4874	0.5592
USA-JP	0.4771	0.5134	0.4664	0.5182	0.6724
USA-EU	0.4808	0.6825	0.3220	0.2402	0.4540
KOR-AUS	0.5725	0.4902	0.6553	0.5518	0.4520
KOR-CAN	0.5985	0.5715	0.6382	0.4170	0.5110
KOR-MEX	0.4959	0.7607	0.6718	0.4302	0.5202

通过以上三种方法验证了经过归一化后的六组国家的汇率与各经济基本面序列都具有长记忆特性。因此依据文[20], 线性协整理论将不再适用, 应运用非线性协整理论来讨论汇率与经济基本面之间的关系。

(三) 非线性协整检验

接下来运用 GRU 神经网络来探测序列之间是否存在非线性协整关系。分别对六组国家序列数据的 FLMM、FPMM、RIDM 三个理论模型进行非线性协整检验。

1. 非线性协整模型的构建

本文在 Python 的 pycharm 软件上构建 GRU 基本网络模块, 并实现对网络的训练和学习。根据第三部分的基本方法, 通过选择非线性激活函数, 调节隐层神经元数, 主要选择 rmsprop 优化器, 在无法实现最优时尝试 namth 优化器, 输入层采用丢弃率 dropout, 同时调节教师指导值 $\{D_t\}$, 最终实现了最大迭代次数 1000 次下的极小化误差。具体见表 5。

表 5 各国最优深度 GRU 协整模型

货币对 (国家)	理论模型	神经元数	激活函数	dropout	优化器	极小化误差
USA-UK	FLMM	150	sigmoid,tanh	0.2	rmsprop	0.02750
	FPMM	120	sigmoid,tanh	0.2	rmsprop	0.00026
	RIDM	120	sigmoid,tanh	0.3	rmsprop	0.00005
USA-JP	FLMM	130	tanh, tanh	0.3	rmsprop	0.00067
	FPMM	150	tanh, tanh	0.3	rmsprop	0.00392
	RIDM	150	tanh, tanh	0.3	rmsprop	0.01060
USA-UE	FLMM	120	sigmoid,tanh	0.3	rmsprop	0.00344
	FPMM	100	sigmoid,tanh	0.2	rmsprop	0.00411
	RIDM	120	sigmoid,tanh	0.2	rmsprop	0.00221
KOR-AUS	FLMM	110	sigmoid,tanh	0.3	rmsprop	0.00101
	FPMM	140	sigmoid,tanh	0.3	namth	0.00070
	RIDM	120	tanh, tanh	0.2	rmsprop	0.00282

KOR-CAN	FLMM	130	sigmoid,tanh	0.3	rmsprop	0.00639
	FPMM	150	sigmoid,tanh	0.3	namth	0.00057
	RIDM	130	sigmoid,tanh	0.2	rmsprop	0.00812
KOR-MEX	FLMM	140	sigmoid,tanh	0.3	rmsprop	0.00617
	FPMM	130	sigmoid,tanh	0.3	rmsprop	0.00361
	RIDM	120	sigmoid,tanh	0.2	rmsprop	0.00094

从表 5 看出，各模型的极小化误差都在 0.03 以下。并且模型时间序列残差波动较为平缓，除 USA 和 UK 的 FLMM 模型残差值的标准差是-0.0121，其余所有模型残差值的标准差都是四位小数，这些结果都说明模型得到了较好的训练，汇率与各经济基本面序列有了较好的拟合。另外，文章在进行模型调试过程中，激活函数曾尝试选用线性函数 linear，但实现的误差值都较大，而改用非线性激活函数 sigmoid 或者 tanh 时，大大降低了误差值，再次说明汇率与基本面序列间是非线性关系，而不是线性关系。

2.残差的短记忆检验

接下来需要检验 GRU 模型拟合后的残差序列是否为 SMM 序列。按照理论，如果是 SMM 序列，则说明他们之间存在非线性协整关系，否则不存在非线性协整关系。依然采用 Lo(1991)[40]提出的修正 R/S 可知（具体见表 6），六组国家的三个理论模型拟合后的残差序列的显著性水平都高于 10%，拒绝原假设为短记忆序列出错的概率较大，有的甚至达到 100% 的概率，即在 10% 的显著性水平下都不显著，因此拒绝备择假设，接受原假设，可判断各残差序列为 SMM 序列。说明汇率与经济基本面序列间都存在非线性协整关系，所构建的 GRU 网络为非线性协整函数。从另一个层面来讲，鉴于 GRU 神经网络强大的非线性时序数据逼近能力，为汇率货币模型找到了长期均衡的非线性关系。

表 6 残差短记忆检验

货币对	检验参数	FLMM	FPMM	RIDM
USA-UK	R/S	0.1226	1.4939	0.8398
	$F(2,9)$	0	0.8173	0.0382
	显著性水平	1	0.1827	0.9618
USA-JP	R/S	1.1570	0.7167	0.6047
	$F(2,9)$	0.4003	0.0045	0.0002
	显著性水平	0.5997	0.9955	0.9998
USA-EU	R/S	0.4540	0.7311	0.9345
	$F(2,9)$	0	0.0062	0.1065
	显著性水平	1	0.9938	0.8935
KOR-AUS	R/S	0.8339	1.2240	0.5319
	$F(2,9)$	0.0353	0.5008	0
	显著性水平	0.9647	0.4992	1
KOR-CAN	R/S	0.5770	1.4055	0.5589
	$F(2,9)$	0	0.7345	0
	显著性水平	1	0.2655	1
KOR-MEX	R/S	0.9572	0.8377	0.9335

$F(29)$	0.1292	0.0372	0.1056
显著性水平	0.8708	0.9628	0.8944

(四) 对比分析

为能更好的说明本文所提方法的有效性,接下来将线性协整检验结果和非线性协整检验结果进行对比分析(具体见表7)。由表7可知,针对部分货币对,某些理论模型无法通过线性协整检验,但所有模型均可以通过GRU非线性协整检验。这意味着,汇率和宏观基本面之间存在着线性协整检验所无法捕捉到的非线性协整关系。本文运用先进的GRU智能技术较好的找到了汇率与宏观基本面之间的非线性协整关系,验证了理论模型的有效性。

表7 线性协整与非线性协整检验结论对比

货币对	理论模型	线性	非线性
USA-UK	FLMM	未通过	通过
	FPMM	≤ 2	通过
	RIDM	≤ 1	通过
USA-JP	FLMM	≤ 2	通过
	FPMM	≤ 2	通过
	RIDM	≤ 2	通过
USA-EU	FLMM	≤ 1	通过
	FPMM	≤ 1	通过
	RIDM	≤ 1	通过
KOR-AUS	FLMM	未通过	通过
	FPMM	未通过	通过
	RIDM	未通过	通过
KOR-CAN	FLMM	未通过	通过
	FPMM	≤ 1	通过
	RIDM	≤ 2	通过
KOR-MEX	FLMM	未通过	通过
	FPMM	≤ 1	通过
	RIDM	≤ 1	通过

注: ≤ 1 和未通过分别表示在 0.05%的置信度水平上,最多存在 1 个线性协整方程和不存在线性协整方程。

此外,与已有文献进行比较,我们发现针对本文所使用的三组美元货币对,文献在进行协整检验时,往往没有统一结论。如 Georgoutsos and Kouretas(2017) [47]发现美元与欧元货币对的 FLMM 模型不存在协整关系,当加入需求和生产力因素时,则存在协整关系, Dinçer Afat(2015)[15]发现该组货币对的 FLMM 模型和 FPMM 模型都不存在协整关系,但 RIDM 模型存在协整关系; Cerra,V.and Saxena,S.C (2010) [6]发现美元与日元、美元与英镑货币对的 FLMM 模型存在协整关系,但 Baillie and Selover(1987) [12]发现该组货币对的 RIDM 模型不存在协整关系。本文在进行线性协整检验时,发现美元与欧元、日元、英镑货币对的 FPMM 模型、RIDM 模型存在线性协整,美元与日元、欧元货币对的 FLMM 模型也存在线性协整,而美元与英镑货币对的 FLMM 模型不存在协整关系。但当本文使用 GRU 神经网络进行检

验时，所有货币对均存在非线性协整关系。

五、 结论

汇率的货币模型一直是学术界和理论界探讨的焦点。至今，有较多的学者对汇率的货币模型进行线性协整检验，其结果不令人满意。非线性协整理论是线性协整理论的扩展，能够更好地刻画多变量序列间的非线性均衡关系。本文首次基于非线性协整的视角，来探测汇率与宏观经济基本面之间的非线性关系。论文发现，在进行归一化后的原序列是存在长记忆特性的，适合采用非线性协整理论进行探讨。

但非线性协整函数的构建是一个重要难题。为此，本文运用人工智能方法，用 GRU 神经网络来逼近非线性协整函数，对六组典型浮动汇率制国家货币对（美元/英镑、美元/日元、美元/欧元、韩元/澳元、韩元与加元、韩元/比索）进行非线性协整检验，考察 FPMM、FLMM 和 RIDM 三个理论模型非线性条件下的有效性。研究结果显示：汇率与宏观经济基本面序列都是长记忆序列，GRU 神经网络较好的找到了汇率与基本面序列间的长期非线性均衡关系。因此，本文验证了在非线性的条件下，汇率的货币模型是有效的。进而，通过与传统线性协整检验结果及现有文献对比，本文不仅验证了深度 GRU 技术在非线性协整分析中的有效性，也突显了具有强大学习能力的深度 GRU 技术在经济建模中的优势。

本文主要侧重于研究 GRU 智能技术检验汇率货币模型的有效性，在后续的工作中，我们将进一步探究和检验该模型是否具有一定的预测能力。另外，我们也会考虑将 GRU 技术运用于新兴市场等其他国家货币对的检验和预测，以进一步验证本文所提方法在实践上的普遍意义。

参考文献

- [1] 潘素昆, 文婧. FDI 对人民币实际汇率即期影响研究[J]. 中国管理科学, 2012, (20): 404-408.
- [2] 余湄, 卢雪. 汇改后外国直接投资对人民币实际汇率的影响研究[J]. 中国管理科学, 2014, (22): 247-252.
- [3] 陈平, 李凯. 人民币汇率与宏观基本面: 来自汇改后的证据[J]. 世界经济, 2010, 33, (9): 28-45.
- [4] 丁剑平, 湛卫学. 汇率非线性因素在部分亚洲货币汇率中的特征——检验购买力平价论的新方法[J]. 财经研究, 2010, (2): 4-14.
- [5] 张喜彬, 孙青华, 张世英. 非线性协整关系及其检验方法研究[J]. 系统工程学报, 1999, (1): 59-70.
- [6] 孙青华, 张喜彬, 张世英. 非线性协整关系的存在性研究[J]. 管理科学学报, 2000, (3): 65-88.
- [7] 樊智, 张世英. 非线性协整建模研究及沪深股市实证分析[J]. 管理科学学报, 2005, (1): 73-77.
- [8] 史代敏. 沪深股市股指波动的协整性研究[J]. 数量经济技术经济研究, 2002, (9): 103-105.
- [9] 苏治, 卢曼, 李德轩. 深度学习的金融实证应用: 动态、贡献与展望[J]. 金融研究, 2017, (5): 111-126.
- [10] 舒晓惠. 非线性协整时间序列的非参数方法及其应用研究[D]. 广州: 暨南大学博士毕业论文, 2010.
- [11] 曹赢. 量化宽松货币政策研究[D]. 浙江: 浙江大学博士毕业论文, 2017.
- [12] 牛哲文等. 基于深度门控循环单元神经网络的短期风功率预测模型[J]. 电力自动化设备, 2018, (5): 36-42.
- [13] 李雪莲. 基于门控循环单元神经网络的中文分词法[J]. 厦门大学学报(自然科学版), 2017, (2): 237-243.
- [14] 黄兆玮等. 基于 GRU 和注意力机制的远程监督关系抽取[J]. 计算机应用研究, 2019, (10): 1-7.
- [15] 许启发, 蒋翠侠, 张世英. 基于小波多分辨分析的协整建模理论与方法的扩展[J]. 统计研究, 2007, (8): 92-96.
- [16] 黄超, 黄丽丽. 基于双正交小波支持向量机的变结构非线性协整研究[J]. 管理科学学报, 2014, (4): 158-206.
- [17] 彼得斯. 资本市场的混沌与秩序[M]. 北京: 经济科学出版社, 1999.
- [18] 钟正生, 高伟. 我国消费者价格指数长记忆性研究[J]. 财贸经济, 2009, (7): 127-133.
- [19] 谢赤, 岳汉奇. 汇率收益率及其收益波动率存在长记忆性吗?——基于人民币汇率和欧元汇率的经验分析[J]. 经济评论, 2012, (4): 135-144.
- [20] 程细玉, 张世英. 向量分整序列的协整研究[J]. 系统工程学报, 2000, (3): 253-266.
- [21] Frenkel J. A monetary approach to the exchange rate: doctrinal aspects and empirical evidence[J]. Scandinavian Journal of Economics, 1976,(76): 200-224.
- [22] Mussa M. The exchange rate, the balance of payments, and monetary and fiscal policy under a regime of controlled floating[J]. Scandinavian Journal of Economics, 1976,(78): 229-248.
- [23] Bilson J F. Rational expectations and the exchange rate[J]. Economics of Exchange Rates, 1978: 75-96.
- [24] MacDonald R, 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.
- [25] Wong M A. Monetary Approach to the Sterling-US Dollar Exchange Rate[J]. Middlesex University Business School, 2004.

- [26] Cerra V, Saxena S C. The monetary model strikes back: evidence from the world[J]. *Journal of International Economics*, 2010,(81): 184-196.
- [27] Meese R A, Rogoff K. Empirical exchange rate models of the seventies: do they fit out-of sample?[J]. *Journal of International Economics*, 1983a,(14): 3–24.
- [28] Meese R A, Rogoff K. The out of sample failure of empirical exchange rate models: sampling error or mis-specification?[M]. *Exchange Rates and International Macroeconomics*, University of Chicago Press, 1983: 67-105.
- [29] Cheung Y W, Chinn M D, Garcia Pascual. An empirical exchange rate models of the nineties: are any fit to survive? [J]. *Journal of International Money and Finance*, 2005, 24, (7): 1150-1175.
- [31] Baillie R T, Selover D D. Cointegration and models of exchange rate determination[J]. *International Journal of Forecasting*, 1987, 3,(1) : 43-51.
- [32] Kearney C, Macdonald R. Rational expectations, bubbles and monetary models of the exchange rate: the australian/us dollar rate during the recent float[J]. *Australian Economic Papers*, 1990, 29,(54):1-20.
- [33] Dinçer Afat. The failure of the monetary model of exchange rate determination[J]. *Applied Economics*, 2015, 47,(43): 4607-4629.
- [34] Grote C, Sibbertsen P. Testing for Cointegration in a Double-LSTR Framework[M]. *Empirical Economic and Financial Research*. Springer International Publishing, 2015.
- [35] Imad A, Ming Ma. Linear and nonlinear attractors in purchasing power parity[J]. *Economia Internazionale*, 2018, 71,(2): 149-172.
- [36] Meese R. A, Rose A. K. An empirical assessment of non-linearities in models of exchange rate determination[J]. *International Finance Discussion Papers*, 1991, 58,(58): 603-619.
- [37] Granger C W. Modeling nonlinear relationships between extended-memory variables[M]. *Essays in econometrics*, Cambridge University Press, 1995.
- [38] Xiong R, Nichols E P, Shen Y. Deep learning stock volatility with google domestic trends[R]. *Papers*, 2015.
- [39] Cho K, Merriënboer B V, Gulcehre C, et al. Learning phrase representations using rnn encoder-decoder for statistical machine translation[J]. *Computer Science*, 2014, 1724-1734.
- [40] Dey R, Salemt F M. Gate-variants of Gated Recurrent Unit (GRU) neural networks[C]. *International Midwest Symposium on Circuits and Systems*, IEEE, 2017,1597-1600.
- [41] Li L, Wan J, Zheng J, et al. Biomedical event extraction based on GRU integrating attention mechanism[J]. *Bmc Bioinformatics*, 2018, (19): 177-184.
- [42] Dornbuschn R. Expectations and exchange rate dynamics[J]. *Journal of Political Economy*, 1976, (84): 1161-1176.
- [43] Frankel J A. On the mark: a theory of floating exchange rates based on real interest differentials[J]. *American Economic Review*, 1979, (69): 610-622.
- [44] Hurst H E. Long Term Storage Capacity of Reservoirs[J]. *Transactions of the American Society of Civil Engineers*, 1951, (116): 770-799.
- [45] Lo Adrew W. Long-Term Memory in Stock Market Prices[J]. *Econometrica*, 1991, (59): 1279-1313.
- [46] Lloyd E H, Hurst H E, Black R P, et al. Long-term storage: an experimental study[J]. *Journal of the Royal Statistical Society*, 1966, 129, (4): 591.
- [47] Baillie R T, Chung C F, Tieslau M A. Analysing inflation by the fractionally integrated ARFIMA-GARCH model[J]. *Journal of Applied Econometrics*, 1996,11, (1): 23-40.
- [48] Georgoutsos D A, Kouretas G P. The Relevance of the Monetary Model for the Euro / USD Exchange Rate Determination: a Long Run Perspective[J]. *Open Economies Review*, 2017, 28, (5):1-22.

Testing the nonlinear cointegration relation of monetary models of exchange rate determination

----An analysis based on the deep GRU neural network

Ding Jianping Lu Xiaoqin Feng Ling

Abstract: The monetary model of exchange rate has been the focus of academic that many scholars have conducted linear cointegration test on it, which the results are not satisfactory. In this paper, We test three versions of monetary models of exchange rate determinations (Flexible price, Forward-looking and Real Interest Differential Models) for six selected countries with floating exchange rate regimes, by applying the nonlinear Johansen cointegration tests, facilitated by the Gated Recurrent Unit (GRU) neural network technique. The GRU technique has the advantages of intelligent memory, autonomous learning and strong approximation ability in deep learning. Based on country-by-country analysis, we found evidence of nonlinear cointegration between exchange rates and macroeconomic fundamentals. This suggests the validity of monetary models and the advantage of advanced deep learning tools in testing economic theory.

The concrete steps of the nonlinear cointegration test in this paper are: First, the long memory characteristics of the sequences are tested, because if there is a nonlinear cointegration relationship between the data sequences, it means that the sequence data must have the long memory characteristics. Secondly, the deep GRU neural network method is used to construct the nonlinear cointegration function, which has the transfer memory function that the ordinary neural network does not have, and has the advantage on the time series data mining. Finally, test whether the residuals of the constructed GRU model are short memory sequences (SMM). If the residuals are short memory sequences, the GRU can extract the non-linear characteristics between the sequences and prove the existence of nonlinear cointegration relationship between the sequences.

The results show that: (1) The original sequence after normalization has the feature of long memory, which is suitable for the discussion with the nonlinear cointegration theory. (2) The residual of the nonlinear cointegration model constructed by GRU neural network is short memory sequence, which found evidence of nonlinear cointegration between exchange rates and macroeconomic fundamentals.

In this paper, advanced deep GRU technology is introduced into nonlinear cointegration test, which can play a role in attracting valuable contributions to expand the tool box of cointegration empirical test.

Key words: exchange rate; monetary models; nonlinear cointegration; the deep GRU neural network



中国人民大学国际货币研究所

INTERNATIONAL MONETARY INSTITUTE OF RUC

地址：北京市海淀区中关村大街 59 号文化大厦 605 室，100872 电话：010-62516755 邮箱：imi@ruc.edu.cn