

doi:10.19920/j.cnki.jmsc.2025.05.010

趋势成分与周期成分分解的新方法^①

——基于中国经济增长减速换挡的应用

谭政勋¹, 刘娟^{2*}

(1. 深圳大学经济学院, 深圳 518060; 2. 湖南工商大学财政金融学院, 长沙 410205)

摘要:针对已有趋势周期成分分解方法的缺陷,本研究提出基于 MS-FCVAR 模型的新方法。这个新方法同时考虑经济变量可能存在的长期记忆、不同变量间的分数阶协整关系及其结构性变化。根据“让数据说话”的原则,在实际 GDP、固定资产投资、消费和出口组成的系统中,新方法检测到与中国经济发展历程十分吻合的结论:以 2010 年第 4 季度为分界点,不仅中国经济增长发生了减速换挡,而且增长动力发生了转换或结构性变化;经济新常态尤其是供给侧改革以来,我国经济增长的下滑主要是由 GDP 的趋势成分而不是周期成分引起。更重要的是,与已有分解方法相比,新方法具有良好的样本外预测效果,其偏差和均方误差均最小。本研究提出的新方法既具有良好的稳健性,又能广泛应用到长期趋势判断、短期波动分析等诸多经济和管理问题的研究。

关键词:趋势周期成分分解;结构性变化;分数阶协整;MS-FCVAR 模型;经济增长减速换挡

中图分类号:F224 **文献标识码:**A **文章编号:**1007-9807(2025)05-0156-18

0 引言

理论上,变量的趋势成分和周期成分均不可观测;因此,如何估计两个成分,一直是计量经济学的研究焦点。应用上,准确分解变量的趋势成分与周期成分,在宏观层面和微观层面均具有重要政策涵义和应用价值。以中国经济增长减速换挡为例,准确分解 GDP 的两个成分并准确判断经济增长减速换挡的时间以及哪个成分的变化起着主导作用,有助于采取适当的调控政策。但是,近年来我国经济增长出现减速换挡的时间及其主导因素引起很大争论。显然,准确分解 GDP 趋势周期成分后,如果中国经济增长的减速是暂时性冲击引起,则以需求管理政策为主;如果持久性冲击引起了趋势成分增长减速,则以供给侧改革为主。再如,中国房价持续快速上涨和股票市场大幅波动

也引起广泛关注。那么,这是基本面因素引起的趋势成分波动,还是投机因素引起的周期成分波动?这个问题的回答也有赖于准确分解趋势周期成分和把握其中的主导因素。对于政府管理部门,这有助于采取针对性措施和政策对资产价格波动进行宏观管理。对于投资者,这有助于准确判断房价和股价是否存在泡沫、是否具有投资价值,从而进行更有效的风险管理的投资决策。综上所述,提出能准确分离变量的趋势周期成分的新方法是重要学术创新、具有重要方法论价值;对宏观调控、微观风险管理的投资决策都具有重要指导价值。

但是,已有单变量和多变量分解方法存在明显不足。经典的 KPSW 分解法(King, Plosser, Stock 和 Watson^[1])假设变量之间是整数阶协整关系,也没有考虑长期记忆。最近,Tan 等^[2]提出的方法虽然考虑长期记忆,但无法处理结构性变

① 收稿日期:2021-04-23; 修订日期:2023-07-11。

基金项目:国家自然科学基金资助项目(71773035; 72173089);教育部人文社会科学基金资助项目(22YJC790079);广东省哲学社会科学研究课题资助项目(GD24CYJ09);深圳市哲学社会科学规划课题资助项目(SZ2023B008)。

通讯作者:刘娟(1994—),女,湖南长沙人,博士,讲师。Email:rssy1214@126.com

化、特别是分数阶协整关系的结构性变化。为此,本研究克服上述方法的缺陷,提出基于马氏机制转换 (Markov regime switching) 的分数阶协整 (Fractional cointegration) VAR(简称 MS-FCVAR) 的趋势周期分解方法。该方法不仅继承 KPSW 法能分离相互正交的长期与短期冲击的优点,而且克服已有方法没有考虑变量之间的分数阶协整关系及其结构性变化的缺陷。已有变量分解法只是该方法的特例,当变量存在长期记忆和结构性变化、尤其当变量间是分数阶协整关系并发生结构性变化时,已有方法无法准确分解趋势周期成分,而本研究的新方法是可行的。这是方法创新和贡献。另外,为体现新方法的优势,本研究采用“让数据说话”的原则^②,利用新方法分析中国经济增长减速换挡的发生时间和原因,并发现重要而崭新的结论:GDP、投资、消费和出口之间不是整数阶协整,而是分数阶协整关系,并且分数阶协整关系在 2010 年第 4 季度发生结构性变化。也就是说,本着“让数据说话”的原则,新方法能检测到与中国经济发展历程相吻合的结论:以 2010 年第 4 季度为分界点,中国经济增长不仅减速换挡,增长动力也发生转换或结构性变化。

1 文献综述

相关文献分为两类:趋势周期的分解方法与相关实证研究。分解趋势周期成分最初从单变量入手,尔后拓展到多变量分解法。单变量分解法包括 BN 分解法、UC (unobserved components) 分解法等。多变量分解主要有两种经典方法:一是 King 等^[1]的 KPSW 分解法,二是 Gonzalo 和 Ng^[7]的 GN 分解法。KPSW 分解法是 BN 分解法向存在协整关系的多变量分解的扩展;其贡献是,通过施加约束能分离出相互正交的持久性冲击和暂时性冲击^③;但没有考虑共同周期成分。GN 分解法利用共同因子模型考虑共同趋势与周期成分。最近,

Tan 等^[2]结合 FCVAR (fractionally cointegrated vector autoregression) 模型与 KPSW 分解法,提出了考虑长期记忆的多变量分解方法。

上述方法假设变量差分后遵循线性平稳过程,但许多经济变量常常会因某种冲击而发生结构性变化。结构性变化主要包括两种情况,一是时间序列的均值或趋势发生显著变化。Perron^[9]首次提出趋势成分的结构性变化,Johansen 等^[10]在 VECM 中引入虚拟变量,提出趋势成分结构变化的协整检验。Perron 和 Wada^[11]在 UC 模型中假设周期成分及趋势成分斜率的扰动项服从混合高斯分布,提出存在结构性变化的单变量分解法。二是回归系数发生变化。Bai 和 Perron^[12, 13]提出了多个结构性变化点的线性模型及估计方法。Hamilton^[14]认为,经济增长在快速与缓慢之间的状态转换可用离散马氏过程来刻画;Sim 等^[15]借鉴 Hamilton^[14]的做法,把单变量马氏机制转换模型向多变量扩展,提出马氏机制转换的 VAR 模型及其估计方法。叶五一等^[16]利用变系数分位点回归分析我国金融稳定性。

分解趋势周期成分的实证研究中,王少平和胡进^[17]、林建浩和王美今^[3]认为,多变量系统比单变量方法能更全面考虑相关变量的互动关系,估计的产出缺口含有更丰富信息,对宏观政策调整更具参考价值。其中,KPSW 方法具有较好的经济含义和统计意义,被大量学者采用:Garratt 等^[18]建立 GDP、消费、经济领先指标、投资和利率的协整关系,应用 KPSW 法分解出欧洲 GDP 的长期趋势;Lettau 和 Ludvigson^[19]应用 KPSW 方法发现,国际金融危机后美国消费的长期趋势下滑。欧阳志刚^[20]、王少平和杨洋^[21]应用 KPSW 法分解我国 GDP 的趋势和周期成分。

对于中国经济增长减速换挡发生的时间和原因,不同学者持有不同观点^④。林建浩和王美金^[3]、祝梓翔等^[22]认为,中国经济增长减速换挡发生在 2006 年或 2008 年;王少平和杨洋^[21]、李

^② 对于同一个经济问题,由于不同理论会得到不同结论和现实经济的复杂性,很多文献采用“让数据说话”的原则。林建浩和王美今^[3]采用该原则分析我国经济增长减速究竟是趋势成分还是周期成分引起;欧阳志刚和王世杰^[4]使用该原则确定货币政策影响通货膨胀与产出的结构变化时间。其他文献包括欧阳志刚和彭方平^[5]、祝梓翔和邓翔^[6]等。

^③ 最近文献 Cerra 等^[8]表明,周期成分可能对其未来趋势成分产生永久性影响。

^④ 第 3 部分利用本研究的新方法来分解 GDP 并进一步分析这个问题。

扬和张晓晶^[23]、郭克莎^[24] 和田国强^[25] 认为是 2010 年甚至 2012 年. 造成差异的可能原因是: 已有研究没有考虑中国经济增长减速换挡引起的结构性变化和可能的长期记忆; 但大量文献发现中国宏观经济指标具有结构性变化和长期记忆. 刘金全等^[26]、顾光同和许冰^[27]、崔畅和李国伟^[28]认为, 我国通货膨胀、农产品价格存在多个异常点和明显的结构转变. 祝梓翔和邓翔^[6] 发现中国产出和通货膨胀的波动具有结构性变化. Chang 等^[29]发现, 中国宏观经济数据具有明显的趋势漂移特征. 长期记忆方面, 刘金全等^[30]发现我国实际产出和投资的二阶矩具有长期记忆; 金晓彤和闫超^[31]发现我国消费增长的一阶矩和二阶矩均存在显著长期记忆; 祝梓翔等^[32]表明, 考虑技术冲击的持续性和马氏转移机制后, 中国 GDP 长期趋势的预测效果得到大幅改善; Perron 和 Wada^[11]发现美国 GDP 也具有长期记忆和结构性变化.

综上所述, 已有的趋势周期分解法存在以下缺陷. 第一, 单变量分解法, Perron 和 Wada^[11] 虽然考虑美国经济增长的结构性变化, 但没有考虑长期记忆. 第二, 多变量分解法, 目前只有 Tan 等^[2] 考虑长期记忆, 但没有考虑结构性变化. 第三, 两类方法均没有同时考虑结构性变化和长期记忆; 特别是对于多变量的关系, 已有文献没有考虑分数阶协整关系及其潜在结构性变化. 针对上述不足, 首先, 考虑变量间协整关系的潜在结构性变化; 其次, 借鉴 Tan 等^[2] 的模型, 进一步引进长期记忆, 进而构建同时考虑结构性变化和长期记忆的多变量分解方法. 实证上, 已有文献没有考虑经济增长减速换挡引起的结构性变化和长期记忆, 这使得结论存在较大差异. 更重要的是, 经济增长减速换挡发生的时间和原因对于国家宏观经济政策的调整非常重要. 为此, 本研究利用新方法分解中国 GDP 的趋势和周期成分、判断结构性变化的时间和原因, 并与其他方法比较样本外预测效果.

2 同时考虑长期记忆与结构性变化的多变量分解方法

2.1 马氏机制转换 FVAR 模型及其参数估计

马氏机制转换是刻画结构性变化的重要工

具, Hamilton^[14]、Sims 等^[15] 先后将其引入 AR 与 VAR 模型中; Johansen^[33] 首次把 VAR 模型拓展为分数阶 VAR 模型, 即 FVAR(Fractional VAR) 模型. 本研究则首次将马氏机制转换引入到 FVAR 模型, 进而提出 MS-FVAR (Markov regime switching fractionally vector autoregression) 模型. 对于 n 维时间序列向量 \mathbf{x}_t , MS-FVAR 模型为

$$\mathbf{x}_t = \mathbf{c}(s_t) + \sum_{i=1}^p \mathbf{A}_i(s_t) L_d^i \mathbf{x}_t + \mathbf{D}(s_t) \boldsymbol{\varepsilon}_t, \quad t = 1, 2, \dots, T \quad (1)$$

模型(1)的系数矩阵 $\mathbf{c}(\cdot)$ 、 $\mathbf{A}_i(\cdot)$ 以及 $\mathbf{D}(\cdot)$ 都由一条具有 m 个状态的马氏链 s_t 所控制; 不妨假设 $s_t \in \{1, 2, \dots, m\}$, 这意味着 \mathbf{x}_t 中存在 $m - 1$ 个结构性变化点, 假设这 $m - 1$ 个未知的结构性变化时间点分别为 $\{\tau_1, \tau_2, \dots, \tau_{m-1}\}$; 进一步令 $\tau_0 = 0$, $\tau_m = T$, 并假设当 $\tau_{k-1} < t \leq \tau_k$ ($k = 1, 2, \dots, m$) 时, $s_t = k$. s_t 的转移概率矩阵

$$\mathbf{Q} = \begin{pmatrix} q_{11} & q_{12} & 0 & \cdots & 0 \\ 0 & q_{22} & q_{23} & \cdots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & \cdots & 0 & q_{m-1,m-1} & q_{m-1,m} \\ 0 & 0 & \cdots & 0 & q_{mm} \end{pmatrix} \quad (2)$$

其中 $q_{ij} = p(s_t = j | s_{t-1} = i)$ 表示 s_t 从状态 i 转移到状态 j 的概率. 根据转移矩阵 \mathbf{Q} 的形式可知, 若 s_t 在 t 时刻处于状态 k ($k = 1, 2, \dots, m - 1$), 那么它在 $t + 1$ 时刻继续停留在原状态的概率为 q_{kk} , 而转移到状态 $k + 1$ 的概率为 $1 - q_{kk}$, 转移到其他状态的概率均为 0; 当 s_t 处于状态 m 时, 那么它停留在该状态的概率为 1. 以上假设表明模型(1)中存在一种不可逆的马氏转换机制.

对于任意状态 $k \in \{1, 2, \dots, m\}$, $\mathbf{c}(k)$ 是一个 n 维的常数向量, $\mathbf{D}(k)$ 是一个 n 维的对角矩阵, 对角线上的元素为 $\xi(k) = (\xi_1(k), \xi_2(k), \dots, \xi_n(k))'$. $\boldsymbol{\varepsilon}_t$ 是由 n 个独立同分布的标准正态随机冲击组成的向量. p 为滞后阶数, 对于任意的 $i = 1, 2, \dots, p$, $\mathbf{A}_i(k)$ 是 $n \times n$ 维的滞后项系数矩阵. 与 1 阶滞后算子 L 不同的是, $L_d = 1 - (1 - L)^d$ 为分数 d 阶滞后算子; $(1 - L)^d = \Delta^d$ 则为分数 d 阶差分算子, 其展开式为

$$(1 - L)^d = \Delta^d = \sum_{j=0}^{\infty} \frac{\Gamma(j-d)}{\Gamma(j+1)\Gamma(-d)} L^j \quad (3)$$

其中 $\Gamma(\cdot)$ 为伽马函数. 若令 $\mathbf{A}(s_t) = (\mathbf{A}_1(s_t), \mathbf{A}_2(s_t), \dots, \mathbf{A}_p(s_t), \mathbf{c}(s_t))$, $\mathbf{y}_t = (L_d \mathbf{x}_t, L_d^2 \mathbf{x}_t, \dots, L_d^p \mathbf{x}_t, 1)'$, 那么模型(1)可表示为下列紧凑形式

$$\mathbf{x}_t = \mathbf{A}(s_t) \mathbf{y}_t + \mathbf{D}(s_t) \boldsymbol{\epsilon}_t, t = 1, 2, \dots, T \quad (4)$$

下面借鉴 Sims 等^[15]和 Sims 和 Zha^[34]对 MS-VAR 的参数估计方法, 提出 MS-FVAR 模型的贝叶斯估计方法. 不同的是, Sims 等^[15]和 Sims 和 Zha^[34]模型的滞后阶数为整数; 而本研究结合马氏链蒙特卡洛法和 Metropolis-Hastings (MH) 算法, 将整数阶滞后推广到分数阶滞后. 做法是令 $\mathbf{S}_t = (s_1, s_2, \dots, s_t)'$, $\mathbf{X}_t = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_t)'$, $\boldsymbol{\theta} = \{\boldsymbol{\theta}_k\}_{k=1}^m$, 其中 $\boldsymbol{\theta}_k = (\boldsymbol{\xi}^2(k), \mathbf{A}(k))$. 从模型(1)的假设可知, 在已知 $(\mathbf{X}_{t-1}, \mathbf{S}_t, \boldsymbol{\theta}, d, \mathbf{Q})$ 的条件下, \mathbf{x}_t 服从均值为 $\mathbf{A}(s_t) \mathbf{y}_t$ 、方差为 $\mathbf{D}^2(s_t)$ 的正态分布. 进一步整理可得到 \mathbf{x}_t 的条件密度函数满足条件

$$p(\mathbf{x}_t | \mathbf{X}_{t-1}, \mathbf{S}_t, \boldsymbol{\theta}, d, \mathbf{Q}) = \prod_{i=1}^n \frac{1}{|\xi_i(s_t)|} \exp \left[- \frac{1}{2 \xi_i^2(s_t)} (x_{t,i} - \mathbf{a}_i(s_t) \mathbf{y}_t)^2 \right] \quad (5)$$

其中 $x_{t,i}$ 和 $\mathbf{a}_i(s_t)$ 分别表示 \mathbf{x}_t 和 $\mathbf{A}(s_t)$ 的第 i 行元素. 根据贝叶斯规则, $(\mathbf{S}_t, \boldsymbol{\theta}, d, \mathbf{Q})$ 的条件后验分布为

$$p(\mathbf{S}_t, \boldsymbol{\theta}, d, \mathbf{Q} | \mathbf{X}_t) \propto p(\mathbf{S}_t, \boldsymbol{\theta}, d, \mathbf{Q}) \times p(\mathbf{X}_t | \mathbf{S}_t, \boldsymbol{\theta}, d, \mathbf{Q}) \quad (6)$$

由于 $\{\tau_1, \tau_2, \dots, \tau_{m-1}\}$ 和 \mathbf{S}_t 不可观测, 且上述条件后验密度函数也不是常见的密度函数, 因此不能根据传统方法从条件后验密度得到参数估计值. 针对这一问题, 最普遍的解决方法是 Gibbs 抽样和 MH 方法. 将所有待估参数分为四部分, $\mathbf{S}_t, \boldsymbol{\theta}, \mathbf{Q}$ 和 d . Gibbs 抽样包括以下步骤

(1) 选定 $\boldsymbol{\theta}, \mathbf{Q}$ 以及 d 的初始值, 假设它们分别为 $\boldsymbol{\theta}^{(0)}, \mathbf{Q}^{(0)}$ 以及 $d^{(0)}$;

(2) 依次从下列条件后验分布中抽取第 i ($i = 1, 2, 3, \dots, N$) 组样本

$$\begin{aligned} & p(\mathbf{S}_t^{(i)} | \boldsymbol{\theta}^{(i-1)}, d^{(i-1)}, \mathbf{Q}^{(i-1)}, \mathbf{X}_t), \\ & p(\boldsymbol{\theta}^{(i)} | \mathbf{S}_t^{(i)}, d^{(i-1)}, \mathbf{Q}^{(i-1)}, \mathbf{X}_t), \\ & p(d^{(i)} | \mathbf{S}_t^{(i)}, \boldsymbol{\theta}^{(i)}, \mathbf{Q}^{(i-1)}, \mathbf{X}_t), \\ & p(\mathbf{Q}^{(i)} | \mathbf{S}_t^{(i)}, \boldsymbol{\theta}^{(i)}, d^{(i)}, \mathbf{X}_t); \end{aligned}$$

当 N 足够大时, Gibbs 抽样得到的 N 个样本均值为参数估计值. 下面介绍第(2)步的四个条件后验分布.

首先, \mathbf{S}_t 的条件后验分布满足

$$p(\mathbf{S}_t | \boldsymbol{\theta}, d, \mathbf{Q}, \mathbf{X}_t) = p(s_t | \boldsymbol{\theta}, d, \mathbf{Q}, \mathbf{X}_t) \times \prod_{t=1}^{T-1} p(s_t | s_{t+1}, \boldsymbol{\theta}, d, \mathbf{Q}, \mathbf{X}_t) \quad (7)$$

其中等号右边的单个条件分布满足下式

$$\begin{aligned} & p(s_t = k | s_{t+1} = k, \boldsymbol{\theta}, d, \mathbf{Q}, \mathbf{X}_t) \\ & = \frac{p(s_t = k | \boldsymbol{\theta}, d, \mathbf{Q}, \mathbf{X}_t) q_{kk}}{\sum_{l=k+1}^m p(s_t = l | \boldsymbol{\theta}, d, \mathbf{Q}, \mathbf{X}_t) q_{lk}} \quad (8) \end{aligned}$$

$$\begin{aligned} & p(s_t = k-1 | s_{t+1} = k, \boldsymbol{\theta}, d, \mathbf{Q}, \mathbf{X}_t) = 1 - \\ & p(s_t = k | s_{t+1} = k, \boldsymbol{\theta}, d, \mathbf{Q}, \mathbf{X}_t) \quad (9) \end{aligned}$$

然而, 式(8)中的 $p(s_t = k | \boldsymbol{\theta}, d, \mathbf{Q}, \mathbf{X}_t)$ 可以从式(10)中得到

$$\begin{aligned} & p(s_t = k | \boldsymbol{\theta}, d, \mathbf{Q}, \mathbf{X}_t) = \\ & \frac{p(s_t = k | \boldsymbol{\theta}, d, \mathbf{Q}, \mathbf{X}_{t-1}) p(x_t | s_t = k, \boldsymbol{\theta}, d, \mathbf{Q}, \mathbf{X}_{t-1})}{\sum_{l=1}^m p(s_t = l | \boldsymbol{\theta}, d, \mathbf{Q}, \mathbf{X}_{t-1}) p(x_t | s_t = l, \boldsymbol{\theta}, d, \mathbf{Q}, \mathbf{X}_{t-1})} \quad (10) \end{aligned}$$

其中 $p(s_t = k | \boldsymbol{\theta}, d, \mathbf{Q}, \mathbf{X}_{t-1}) = \sum_{l=k+1}^k p(s_{t-1} = l | \boldsymbol{\theta}, d, \mathbf{Q}, \mathbf{X}_{t-1}) q_{lk}$.

由此可见, 若给定初始值 $p(s_1 = 1 | \boldsymbol{\theta}, d, \mathbf{Q}, \mathbf{X}_1) = 1$, 则可得到式(10), 将其代入式(8), 并结合式(7), 便可得到 \mathbf{S}_t 的条件分布.

其次, 对于 $(\boldsymbol{\theta}^{(i)} | \mathbf{S}_t^{(i)}, d^{(i-1)}, \mathbf{Q}^{(i-1)}, \mathbf{X}_t)$, 需依次对 $(\boldsymbol{\theta}_k | \boldsymbol{\theta}_1, \dots, \boldsymbol{\theta}_{k-1}, \boldsymbol{\theta}_{k+1}, \dots, \boldsymbol{\theta}_m, \mathbf{S}_t, d, \mathbf{Q}, \mathbf{X}_t)$ ($k = 1, \dots, m$) 进行抽样; 实际上, $\boldsymbol{\theta}_k$ 的条件后验只依赖于状态 k 下的观测值与滞后阶数 d . 若将状态 k 下的观测值记为 $\widehat{\mathbf{X}}_k$, 即 $\widehat{\mathbf{X}}_k = \{\mathbf{x}_t; s_t = k\}$, 那么上述条件后验则等价于 $(\boldsymbol{\theta}_k | d, \widehat{\mathbf{X}}_k)$. 由于 $\boldsymbol{\theta}_k = (\boldsymbol{\xi}^2(k), \mathbf{A}(k))$, 下面再次运用 Gibbs 抽样, 将参数 $\boldsymbol{\theta}_k$ 分为两部分: $\boldsymbol{\xi}^2(k)$ 和 $\mathbf{A}(k)$. 对于 $(\mathbf{A}(k) | \boldsymbol{\xi}^2(k), d, \widehat{\mathbf{X}}_k)$, 假设其先验分布为高斯分布, 并且对于先验均值和先验方差的假定与 Sims 和 Zha^[34]保持一致. 结合该先验分布假设以及式(5), 再根据贝叶斯规则便可得到 $(\mathbf{A}(k) | \boldsymbol{\xi}^2(k), d, \widehat{\mathbf{X}}_k)$ 的后验分布. 对于 $(\boldsymbol{\xi}^2(k) | \mathbf{A}(k), d, \widehat{\mathbf{X}}_k)$, 假设 $\boldsymbol{\xi}^2(k)$ 的先验分布为伽马分布, 即

$$p(\xi_i^2(k)) = \gamma(\xi_i^2(k) | \alpha_j, \beta_j) \quad (11)$$

其中 $\gamma(x | \alpha, \beta) = \frac{1}{\Gamma(\alpha)} \beta^\alpha x^{\alpha-1} e^{-\beta x}$, α_j 与 β_j 是先验超参数值. 那么, $\xi^2(k)$ 的后验条件分布则为

$$\begin{aligned} p(\xi_i^2(k) | A(k), d, \hat{X}_k) &= \gamma(\xi_i^2(k) | \hat{\alpha}_j(k), \\ &\quad \hat{\beta}_j(k)) \end{aligned} \quad (12)$$

其中 $\hat{\alpha}_j(k) = \alpha_j + T_k/2$, $\hat{\beta}_j(k) = \beta_j + \frac{1}{2} \times \sum_{t \in \{l; s_t=k\}} (x_{t,j} - \alpha_j(k) y_t)^2$, T_k 为状态 k 下观测值的个数.

然后, 对于 $(d^{(i)} | S_T^{(i)}, \theta^{(i)}, Q^{(i-1)}, X_T)$, 主要运用 MH 算法对其进行抽样. 在已抽取第 $i-1$ 个样本 $d^{(i-1)}$ 的条件下, 主观选择一个合适的方差参数 σ^2 , 并从均值为 $d^{(i-1)}$ 、方差为 σ^2 的正态分布中抽取一个候选样本 $d^{(*)}$. 计算下列比值

$$\lambda = \frac{p(d^{(*)} | S_T^{(i)}, \theta^{(i)}, Q^{(i-1)}, X_T) p(d^{(i-1)} | d^{(*)})}{p(d^{(i-1)} | S_T^{(i)}, \theta^{(i)}, Q^{(i-1)}, X_T) p(d^{(*)} | d^{(i-1)})} \quad (13)$$

再从均匀分布 $U(0, 1)$ 中随机抽取一个 u , 若 $u \leq \min(1, \lambda)$, 则将候选样本 $d^{(*)}$ 作为第 i 个样本 $d^{(i)}$, 即 $d^{(i)} = d^{(*)}$, 否则 $d^{(i)} = d^{(i-1)}$.

最后, 对于 $(Q^{(i)} | S_T^{(i)}, \theta^{(i)}, d^{(i)}, X_T)$, 假设矩阵 Q 对角线上元素的先验分布为贝塔分布, 那么其条件后验分布满足

$$p(q_{kk} | \theta, d, S_T, X_T) \text{Beta}(a + T_k, b + 1) \quad (14)$$

其中 a 和 b 是先验贝塔分布的超参数, T_k 为状态 k 下观测值的个数.

给出了似然函数 $p(X_T | \theta, d, Q, S_T)$ 和先验分布 $p(S_T, \theta, d, Q)$, 模型的边际似然函数定义如下

$$p(X_T) = \int p(X_T | S_T, \theta, Q) p(S_T, \theta, Q) dS_T d\theta dQ \quad (15)$$

综上所述, 当存在长期记忆时, Sims 等^[15] 的 MS-VAR 模型将无能为力, 只能采用 MS-FVAR 模型. 谭政勋和张欠^[35] 发现我国股票市场收益率具有长期记忆、大量文献发现股票波动率具有长期

记忆^[36, 37]; 因此, 在探讨股票市场收益率、波动率的影响因素或者两者的关系时, 相较于 MS-VAR 模型, MS-FVAR 模型是更好选择.

2.2 MS-FCVAR 模型及其趋势与周期分解

受到 VAR 推广到 VECM 的启发, 把 MS-FVAR 推广到马氏机制转换的分数阶协整即 MS-FCVAR 模型: 根据 MS-FVAR 模型的系数得到其误差纠正形式, 即 MS-FCVAR 模型. 在模型(1)中, n 维向量 x_t 是平稳过程: $I(d)$ ($0 < d < 0.5$) 过程. 但是, 如果向量 x_t 是由 n 个非平稳 $I(d)$ ($d > 0.5$) 过程组成, 则 x_t 不仅包含非平稳的长期成分与平稳的短期成分, 而且变量间可能存在协整关系甚至分数阶协整关系, 这种协整关系可能导致变量的共同趋势或共同周期. 为进一步明确刻画变量间的长期协整关系与短期动态变化, 将模型(1)转化为下列误差纠正形式, 进而首次提出基于协整的 MS-FVAR 模型, 即 MS-FCVAR 模型

$$\begin{aligned} \Delta^d x_t &= c(s_t) + \alpha(s_t) \beta'(s_t) L_d x_t + \\ &\quad \sum_{i=1}^{p-1} \Gamma_i(s_t) L_d^i \Delta^d x_t + D(s_t) \varepsilon_t \end{aligned} \quad (16)$$

其中 d 为分数且大于 0.5, $n \times r$ 维矩阵 $\beta(s_t)$ 和 $\alpha(s_t)$ 分别为协整矩阵和调整矩阵, r ($0 < r < n$) 为协整秩. 根据共同趋势理论, 协整系统存在 $n-r$ 个长期冲击, 它们累积形成系统的共同趋势成分; 剩下的 r 个冲击为短期冲击, 对变量只有短期影响、累积形成周期成分^⑤. 模型(1)与模型(16)满足

$$\begin{aligned} \alpha(s_t) \beta'(s_t) &= \sum_{i=1}^p A_i(s_t) - I, \\ \Gamma_i(s_t) &= - \sum_{j=i+1}^p A_j(s_t) \end{aligned} \quad (17)$$

虽然在 FVAR 模型中引入马氏机制转换结构得到 MS-FVAR 即模型(1), 但没有考虑协整, 而模型(16)在模型(1)的基础上进一步考虑协整. 也就是说, 模型(16)同时考虑分数阶协整关系和结构性变化, 即 MS-FCVAR 模型. 强调的是, 这里本研究首次提出分数阶协整关系的结构性变化, 其含义是指在多变量系统中, 变量之间的协整关系并不恒定, 而是可以变化. 而且模型(16)刻画

^⑤ 本研究假设 n 为有限整数. 当 n 趋于无穷时, 该结论不成立, 具体可参考 Barigozzi 和 Trapani^[38].

的不是传统整数阶协整关系,而是分数阶协整关系以及分数阶协整关系的结构性变化.

下面结合 KPSW 分解法,利用 MS-FCVAR 模型,将分数阶多元非平稳过程 \mathbf{x}_t 分解为趋势成分与周期成分. 当 \mathbf{x}_t 处于第 k ($k=1, 2, \dots, m$) 个状态时,即当 $\tau_{k-1} < t \leq \tau_k$ 时,将模型(16) 变为

$$\left[\mathbf{I} - (\boldsymbol{\alpha}(k) \boldsymbol{\beta}'(k) L_d \Delta^{-d} + \sum_{i=1}^{p-1} \boldsymbol{\Gamma}_i(k) L_d^i) \right] \times \Delta^d \mathbf{x}_t = \mathbf{c}(k) + \mathbf{D}(k) \boldsymbol{\varepsilon}_t \quad (18)$$

记 $\boldsymbol{\Pi}(L, k) = \boldsymbol{\alpha}(k) \boldsymbol{\beta}'(k) [(1-L)^{-d} - 1] + \sum_{i=1}^{p-1} \boldsymbol{\Gamma}_i(k) [1 - (1-L)^d]^i$, 则式(18)可变为

$$[\mathbf{I} - \boldsymbol{\Pi}(L, k)] \Delta^d \mathbf{x}_t = \mathbf{c}(k) + \mathbf{D}(k) \boldsymbol{\varepsilon}_t \quad (19)$$

令 $\mathbf{I}_+ \mathbf{x}_t = \mathbf{x}_t I_{\{t \geq 1\}}$, $\mathbf{I}_- \mathbf{x}_t = \mathbf{x}_t I_{\{t \leq 0\}}$, $I_{\{.\}}$ 为示性算子; 对于任意的算子 f , 定义 $f_+ = f \mathbf{I}_+$, $f_- = f \mathbf{I}_-$, 那么式(19)等价于

$$[\mathbf{I} - \boldsymbol{\Pi}(L, k)]_+ \Delta^d \mathbf{x}_t + [\mathbf{I} - \boldsymbol{\Pi}(L, k)]_- \Delta^d \mathbf{x}_t = \mathbf{c}(k) + \mathbf{D}(k) \boldsymbol{\varepsilon}_t \quad (20)$$

将式(20)左右两边同时左乘 $[\mathbf{I} - \boldsymbol{\Pi}(L, k)]_+^{-1}$, 并根据 $[\mathbf{I} - \boldsymbol{\Pi}(L, k)]_+^{-1} [\mathbf{I} - \boldsymbol{\Pi}(L, k)]_+ = \mathbf{I}_+$, 可得

$$\Delta_+^d \mathbf{x}_t = [\mathbf{I} - \boldsymbol{\Pi}(L, k)]_+^{-1} [\mathbf{c}(k) + \mathbf{D}(k) \boldsymbol{\varepsilon}_t] + \boldsymbol{\eta}_t \quad (21)$$

其中 $\boldsymbol{\eta}_t = -[\mathbf{I} - \boldsymbol{\Pi}(L, k)]_+^{-1} [\mathbf{I} - \boldsymbol{\Pi}(L, k)]_- \Delta^d \mathbf{x}_t$, 它是一个关于 \mathbf{x}_t 的初始值的函数. 根据泰勒展开式 $(1-z)^{-1} = \sum_{n=0}^{\infty} z^n (|z| < 1)$, 式(21)等价于

$$\Delta_+^d \mathbf{x}_t = \sum_{n=0}^{t-1} \mathbf{I}_+ \boldsymbol{\Pi}^n(L, k) [\mathbf{c}(k) + \mathbf{D}(k) \boldsymbol{\varepsilon}_t] + \boldsymbol{\eta}_t \quad (22)$$

由此可知, 经过 d 阶差分后的平稳序列 $\Delta_+^d \mathbf{x}_t$ 可以表示成如下的 Wold 形式

$$\Delta_+^d \mathbf{x}_t = \boldsymbol{\delta}_t + \mathbf{B}(L, k) \mathbf{D}(k) \boldsymbol{\varepsilon}_t \quad (23)$$

其中 $\mathbf{B}(L, k) = \sum_{n=0}^{t-1} \mathbf{I}_+ \boldsymbol{\Pi}^n(L, k)$, $\boldsymbol{\delta}_t = \mathbf{B}(L, k) \mathbf{c}(k) + \boldsymbol{\eta}_t$.

借鉴 King 等^[1]的做法, 在简约形式式(23)中加入结构约束, 将冲击 $\boldsymbol{\varepsilon}_t$ 分离为相互正交的长期冲击和短期冲击, 从而得到结构化冲击 $\boldsymbol{\zeta}_t$. 加入结构约束后, 式(20)变为

$$\Delta_+^{d(k)} \mathbf{x}_t = \boldsymbol{\delta}_t + \boldsymbol{\Lambda}(L, k) \boldsymbol{\zeta}_t \quad (24)$$

其中 $\boldsymbol{\zeta}_t = \boldsymbol{\Lambda}_0^{-1}(k) \mathbf{D}(k) \boldsymbol{\varepsilon}_t$, $\boldsymbol{\Lambda}(L, k) = \mathbf{B}(L, k) \boldsymbol{\Lambda}_0(k)$, $\boldsymbol{\Lambda}_0(k)$ 为结构约束矩阵.

结构约束矩阵 $\boldsymbol{\Lambda}_0(k)$ 的识别条件与 KPSW 方法一致, 包括两点: 一是结构化冲击之间相互正交; 二是结构化冲击 $\boldsymbol{\zeta}_t$ 的前 r 个冲击为暂时性冲击, 而剩余的 $n-r$ 个冲击为持久性冲击, 累积形成 $n-r$ 个共同趋势. 根据识别条件的第一点, $\boldsymbol{\zeta}_t$ 的协方差矩阵为单位矩阵, 从而 $\boldsymbol{\Lambda}_0(k) \boldsymbol{\Lambda}_0'(k)$ 为对角矩阵, 其对角线上的元素为 $(\xi_1(k), \dots, \xi_n(k))$. 根据识别条件的第二点, 结构化形式(24)中的长期乘子 $\boldsymbol{\Lambda}(1, k)$ 需满足 $\boldsymbol{\Lambda}(1, k) = \mathbf{B}(1, k) \boldsymbol{\Lambda}_0(k) \boldsymbol{\beta}'(k) \boldsymbol{\Lambda}(1, k) = 0$, 并且 $\boldsymbol{\Lambda}(1, k)$ 可表示成 $[\mathbf{0}_{n \times r} \ \widetilde{\boldsymbol{\Lambda}}(k) \boldsymbol{\Psi}(k)]$; 其中, $n \times (n-r)$ 维的矩阵 $\widetilde{\boldsymbol{\Lambda}}(k)$ 中不含未知参数, 它只要满足 $\boldsymbol{\beta}'(k) \widetilde{\boldsymbol{\Lambda}}(k) = 0$ 即可; $(n-r) \times (n-r)$ 维的矩阵 $\boldsymbol{\Psi}(k)$ 为满秩的下三角矩阵, 对角线上的元素为 1, 通过 Cholesky 分解唯一确定.

识别出结构化模型(24)后, 结合分数阶差分算子的展开式: $\Delta^d \mathbf{x}_t = (1-L)^d \mathbf{x}_t = \sum_{j=0}^{\infty} \pi_j(d) \mathbf{x}_{t-j}$ (其中 $\pi_0(d) = 1$, $\pi_j(d) = \frac{j-1-d}{j} \times \pi_{j-1}(d)$, $j \geq 1$), 可以得到

$$\mathbf{x}_t = \boldsymbol{\psi}_t + \sum_{j=0}^{t-1} \pi_j(-d) \boldsymbol{\Lambda}(L, k) \boldsymbol{\zeta}_{t-j} \quad \tau_{k-1} < t \leq \tau_k, k = 1, 2, \dots, m \quad (25)$$

由式(25)可以得到 \mathbf{x}_t 的确定性趋势成分、长期趋势成分和周期成分, 分别为

$$\begin{aligned} \boldsymbol{\psi}_t &= \sum_{j=0}^{t-1} \pi_j(-d) \boldsymbol{\delta}_{t-j} \\ \mathbf{x}_t^p &= \boldsymbol{\psi}_t + \boldsymbol{\Lambda}(1, k) \sum_{j=0}^{t-1} \pi_j(-d) \boldsymbol{\zeta}_{t-j} \\ \mathbf{x}_t^s &= \mathbf{x}_t - \mathbf{x}_t^p \end{aligned} \quad (26)$$

下面总结新方法与已有方法之间的关系. 当模型(16)中所有参数都是常数且差分阶数 $d=1$ 时, 模型(16)退化为 VECM

$$\Delta \mathbf{x}_t = \mathbf{c} + \boldsymbol{\alpha} \boldsymbol{\beta}' \mathbf{x}_{t-1} + \sum_{i=1}^{p-1} \boldsymbol{\Gamma}_i \Delta \mathbf{x}_{t-i} + \mathbf{D} \boldsymbol{\varepsilon}_t \quad (27)$$

类似地, 当模型(16)中的差分阶数 $d=1$ 时, 模型(16)退化为 MS-VECM

$$\Delta \mathbf{x}_t = \mathbf{c}(s_t) + \boldsymbol{\alpha}(s_t) \boldsymbol{\beta}'(s_t) \mathbf{x}_{t-1} +$$

$$\sum_{i=1}^{p-1} \boldsymbol{\Gamma}_i(s_i) \Delta \mathbf{x}_{t-i} + \mathbf{D}(s_t) \boldsymbol{\varepsilon}_t \quad (28)$$

当模型(16)中的所有参数都是常数时,即不存在结构性变化,它将退化为 FCVAR 模型

$$\Delta^d \mathbf{x}_t = \mathbf{c} + \boldsymbol{\alpha} \boldsymbol{\beta}' L_d \mathbf{x}_t + \sum_{i=1}^{p-1} \boldsymbol{\Gamma}_i L_d^i \Delta^d \mathbf{x}_t + \mathbf{D} \boldsymbol{\varepsilon}_t, \quad (29)$$

正如前文指出,KPSW 分解法的最大贡献是,通过施加约束可以分离出相互正交的持久性冲击和暂时性冲击.但是,该方法存在 3 个缺陷:1)没有考虑变量潜在的长期记忆和结构性变化;2)变量之间是整数阶协整关系;3)没有考虑不同变量间分数阶协整关系的结构性变化.下面的实证研究分别利用基于模型(16)及其三个退化模型(模型 27 ~ 模型 29)分解趋势周期成分.以模型(27)、模型(28)、模型(29)为基础分别形成 KPSW 分解法、考虑结构性变化的分解法;考虑长期记忆的分解法;以模型(16)为基础就形成本研究既考虑结构性变化又考虑长期记忆,而且分数阶协整关系也可能发生结构性变化的分解方法.简而言之,本研究的新方法克服了已有方法的缺陷,适用范围更广.为行文简练,在下面实证分析中,分别用相应的基础模型即 VECM、MS-VECM、FCVAR、MS-FCVAR 指代上述四种分解方法.

最后,简要总结新方法与其他方法分解趋势周期成分的基本步骤.首先说明 KPSW 分解法的步骤:1)整数阶差分和估计 VECM;2)由 VECM 得到简约形式的 Wold 表达式;3)分离相互正交的持久性冲击和暂时性冲击后得到结构化形式的 Wold 表达式;4)根据 BN 分解进行一阶整合,得到趋势和周期成分.其他三个分解方法也分为四个基本步骤,其中第三步的本质思想都与 KPSW 分解法的第三步相同;关键区别是第一步,第一步的差别也引起第二步和第四步的差异.与 KPSW 分解法相比,Tan 等^[2]的分解方法的第一步是分数阶差分及分数阶协整,所以第四步也不同:后者是分数阶整合,前者是一阶整合.因此,KPSW 法只是 Tan 等^[2]的特例,前者只针对 $I(1)$ 过程;而后者适用范围更大的 $I(d)$ 过程, d 可以是整数或分数.与 Tan 等^[2]的方法相比,新方法的

关键改进是第一步:基于 MS-FCVAR 模型考虑了变量的结构性变化及变量间协整关系的结构性变化,同时克服了 KPSW 分解法的三个缺陷.显然,Tan 等^[2]提出的方法只是本研究的一个特例.因此,本研究提出的基于 MS-FCVAR 模型的分解方法既具有 Tan 等^[2]的优点,又考虑结构性变化、尤其是分数阶协整关系的结构性变化.

3 新方法的应用:中国经济增长减速换挡的时间及其原因^⑥

3.1 数据来源

由于 1992 年以前,中国没有披露 GDP、固定资产投资、最终消费的季度数据,所以本研究的数据从 1992 年第 1 季度至 2020 年第 4 季度.国家统计局公布了 2011 年—2020 年不变价 GDP 季度数据(其中 2011 年—2015 年按 2010 年价格计算,2016 年—2020 年按 2015 年价格计算),但 2011 年之前只公布各季度的名义 GDP 及国内生产总值指数.于是,先将 2011 年—2020 年各季度的名义 GDP 除以相应季度的 GDP 缩减指数,得到以 2010 年为基期的实际 GDP;然后从 2010 年开始,利用下一年的实际季度 GDP 除以当年相应季度的国内生产总值指数,倒推得到 1992 年—2010 年各季度的实际 GDP.这样得到以 2010 年为基期的 1992 年—2020 年实际季度 GDP.对于消费和固定资产投资,在计算 CPI 指数和投资价格指数后,调整为 2010 年为基期的实际数据.对于出口总额,国家统计局未公布 1992 年 1 月—1994 年 7 月的出口数据,假设这段时期内的出口与工业增加值同步增长,由此得到各月份的出口数据并加总得到季度数据;根据出口货物价格指数进行调整,得到 2010 年为基期的实际季度数据.最后,将所有实际季度数据经季节调整后取自然对数.参考多数文献的做法,构建 GDP(y)、固定资产投资(i)、出口(e) 和消费(c) 的协整系统,并对比新方法与其他方法的实证结果.

^⑥ 为节省篇幅,除四个模型的协整系数、差分阶数、结构性变化的时间点外,不报告其他结果(有兴趣的读者可以索取).原因是:当存在结构性变化时,基于 MS-VECM 的分解法优于 KPSW 分解法,当同时存在结构性变化和长期记忆时,新方法优于 Tan 等^[2]和基于 MS-VECM 的分解法.当存在长期记忆时,Tan 等^[2]的方法优于 KPSW 分解法.

3.2 实证结果及分析

首先进行单位根和长期记忆检验。Perron^[9]指出,当平稳序列存在结构性变化时,传统单位根检验方法容易将其误判为单位根过程,可靠性大大降低。为此,除传统方法(表1第1列~第3列)外,还采用能够容纳结构性变化的检验方法(表1第4列~第7列);最后检验长期记忆(表1第8列~第9列)。强调的是,变量是否存在长期记忆和结构性变化,事前并不知道,也不施加任何约束,这体现“让数据说话”的原则。根据表1,所有对数序列均存在单位根。然而,对

于差分序列,传统方法和考虑结构性变化的检验方法得到了相互矛盾的结果:差分序列既不是I(1)过程,也不是I(0)过程。因此只可能是I(d)过程($0 < d < 1$)、即具有长期记忆。表1第8列~第9列进一步证实这一猜想,修正的对数周期图法(MGPH)、完全扩展的局部Whittle法(FELW)的结果均表明,差分序列确实具有显著的长期记忆。上述结果得到诸多文献支持,刘金全等^[26]、金晓彤和闫超^[31]等发现以通货膨胀率、GDP增长率为代表的宏观经济变量具有长期记忆。

表1 单位根检验及长记忆参数估计

Table 1 Unit root tests and long memory parameter estimations

变量	ADF	KPSS	ADF_1B	KPSS_1B	ADF_2B	KPSS_2B	MGPH	FELW
y	-1.82	1.26 ***	-1.24	0.27 **	-2.45	0.28 ***	1.23 ***	1.10 **
Δy	-1.66 *	0.72 **	-4.70 *	0.05	-9.93 ***	0.74 ***	0.29 **	0.27 **
c	-1.27	1.25 ***	-2.08	0.26 *	-2.51	0.29 ***	1.20 ***	1.17 ***
Δc	-1.74 *	0.31	-13.85 ***	0.13	-13.93 ***	0.31 **	0.38 ***	0.14 *
i	-0.87	1.23 ***	-2.36	0.26 *	-2.12	0.29 ***	1.08 *	0.98
Δi	-2.68 *	0.34	-14.27 ***	0.08	-14.37 ***	0.18	0.08	0.07
e	-2.08	1.25 ***	-3.15	0.27 **	-3.89	0.47 ***	1.16 ***	1.05 *
Δe	-4.59 ***	0.31	-7.58 ***	0.05	-8.50 ***	0.08	0.16 *	0.05

注: y、c、i、e 分别表示季节调整取对数后的 GDP、消费、投资及出口的实际值; Δy 、 Δc 、 Δi 、 Δe 表示相应的一阶差分; 下文符号含义相同, 不再说明。ADF_1B、ADF_2B 分别表示存在一个、两个结构性变化点的 ADF 检验; KPSS_1B、KPSS_2B 分别表示存在一个、两个结构性变化点的 KPSS 检验。MGPH、FELW 分别表示利用修正的对数周期图法、完全扩展的局部 Whittle 法估计长记忆参数 d 。*、**、*** 分别表示在 10%、5%、1% 的水平下显著。

表2 单变量结构性变化检验

Table 2 Univariate structural change tests

变量	UDmax	WDmax	supF(1 0)	supF(2 1)	supF(3 2)	BIC	95%CI
y	23.24 ***	44.48 ***	16.24 ***	14.61 *	9.83	1	2010Q3—2013Q3
c	10.75 *	11.58 *	9.17	10.56	10.77	1	2010Q1—2013Q2
i	10.61 *	12.57 *	12.38 **	10.73	11.81	1	2010Q2—2013Q1
e	19.54 ***	25.90 ***	14.82 **	11.90 *	4.05	1	2008Q3—2011Q1

注: UDmax、WDmax 分别是 Bai 和 Perron^[12, 13]提出的等权、加权最大值检验; 原假设是不存在结构性变化点。sup $F(x+1|x)$ 是 Bai 和 Perron^[12]提出的用于检验结构性变化点个数的统计量, 原假设是存在 x 个结构性变化点; 备选假设是存在 $x+1$ 个结构性变化点。BIC 为 Bayesian 信息准则。95%CI 表示基于 BIC 估计的结构性变化时间点的 95% 置信区间。*、**、*** 分别表示在 10%、5%、1% 的水平下显著。

其次进行结构性变化检验,结果见表2。UDmax、WDmax、BIC 检验表明,四个变量均存在结构性变化; sup $F(x+1|x)$ 进一步表明,y、e 和 i 都存在 1 个显著的结构性变化点。95%CI 表明, y、c 和 i 的结构性变化时间是 2010 年—2013 年,e 则稍微早一些。大量文献发现与本研究相似的结果:张凌翔^[39]发现,中国多数宏观经济变量具有非线性平滑转移特征;梁琪和滕建州^[40]发现 M2 等金融变量也具有结构性变化。结合本研究与已有文献的结论,在分解产出时,应考虑其结构性变化。

根据表1~表2的结果,上述四个变量的对数序列存在结构性变化,对数差分序列具有长期记忆和结构性变化。那么,上述变量之间是否存在协整关系、是分数阶还是整数阶协整? 协整关系是否存在结构性变化以及什么时候发生? 对这些重要问题是否进行约束将影响到不同方法能否准确分离趋势与周期成分。KPSW 分解法假设:1)不存在长期记忆,2)变量间是整数阶协整关系,3)协整关系不会发生结构性变化。基于 MS-VECM 的分解法保留前两个约束,放松第3个约束; Tan 等^[2]提

出的分解法放松前两个约束,但未考虑协整关系发生结构性变化。为客观比较不同方法并体现新方法的优势,本研究不对上述问题施加任何约束,这也是“让数据说话”的重要体现。表 3~表 4 分别报告不考虑长期记忆、考虑长期记忆的协整系数估计结果;表 3~表 4 的左右两部分还分别报告存在和不存在结构性变化的结果;表 5 是模型取舍的似然比检验。表 5 表明,既不考虑长期记忆也不考虑结构性变化的 VECM 与其他三个模型相比都被拒绝,因此应

考虑上述两个因素中的一个。与 MS-FCVAR 相比,FCVAR 模型和 MS-VECM 模型均被拒绝,因此要同时考虑长期记忆与结构性变化。特别是 MS-FCVAR 优于 VECM 和 MS-VECM,说明变量之间是分数阶协整且存在结构性变化。总之,FCVAR 和 MS-VECM 优于 VECM,而 MS-FCVAR 优于其他三个模型,因此,应该使用本研究提出的 MS-FCVAR 模型。更进一步,利用本研究的新方法检测到协整关系发生结构性变化的时间为 2010 年第 4 季度,结果放在图 2^⑦。

表 3 VECM 与 MS-VECM 的协整系数

Table 3 Cointegration coefficients of VECM and MS-VECM

变量	VECM		MS-VECM			
			状态 1		状态 2	
y	1.00	1.00	1.00	1.00	1.00	1.00
c	-0.73 (0.10)	0.00	-0.83 (0.16)	0.00	-0.57 (0.04)	0.00
i	-0.25 (0.07)	0.00	-0.14 (0.01)	0.00	-0.36 (0.03)	0.00
e	0.00	-0.71 (0.02)	0.00	-0.58 (0.02)	0.00	-1.65 (0.12)
常数项	-0.95	-3.51	-1.36	-4.31	-1.33	3.82
结构性变化时间	无		2010 年第 4 季度			

注: 协整关系的结构性变化时间为 2010 年第 4 季度;采用 Johansen 和 Nielsen^[41]的检验方法确定表 3~表 4 中四个系统的协整方程个数均为 2;圆括号中为稳健标准差。

表 4 FCVAR 与 MS-FCVAR 的协整系数

Table 4 Cointegration coefficients of FCVAR and MS-FCVAR

变量	FCVAR		MS-FCVAR			
			状态 1		状态 2	
d	1.27 (0.04)		0.94 (0.03)			
y	1.00	1.00	1.00	1.00	1.00	1.00
c	-0.65 (0.12)	0.00	-0.78 (0.18)	0.00	-0.51 (0.07)	0.00
i	-0.36 (0.08)	0.00	-0.17 (0.02)	0.00	-0.41 (0.05)	0.00
e	0.00	-0.70 (0.03)	0.00	-0.57 (0.02)	0.00	-1.76 (0.12)
常数项	-1.10	-3.59	-1.45	-4.34	-1.21	4.68
结构性变化时间	无		2010 年第 4 季度			

注: 表 3 的注释也适合于表 4; d 为差分阶数。

表 5 模型取舍的似然比检验

Table 5 Likelihood ratio tests for model selection

指标	MS-VECMVECM		FCVARVECM		MS-VECMFCVAR	
ln L	1 002.86	945.49	988.22	945.49	1 002.86	988.22
LR	114.74 ***		85.46 ***		29.28	
指标	MS-FCVARVECM		MS-FCVARMS-VECM		MS-FCVARFCVAR	
ln L	1 028.65	945.49	1 028.65	1 002.86	1 028.65	988.22
LR	166.32 ***		51.58 **		80.86 ***	

注: 以第一组“MS-VECMVECM”为例,其原假设是使用 VECM,其他依次类推。ln L 为对数似然函数最大值,LR 为似然比检验统计量。*、**、*** 分别表示在 10%、5%、1% 的水平下显著。

⑦ 尊重审稿专家的建议,经检验发现,2015 年股灾没有引起四个变量之间分数阶协整关系的结构性变化。

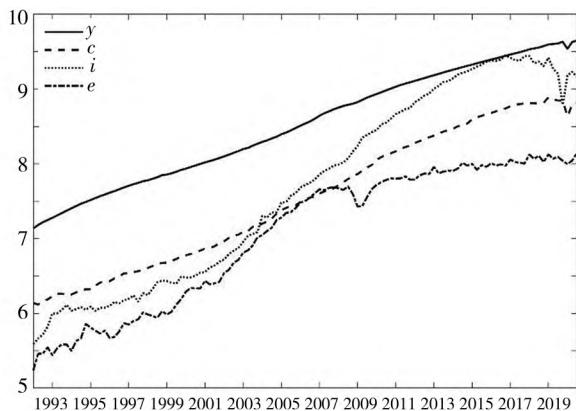


图1 实际变量经季节调整后的对数值

Fig. 1 Seasonally adjusted logarithm of actual variables

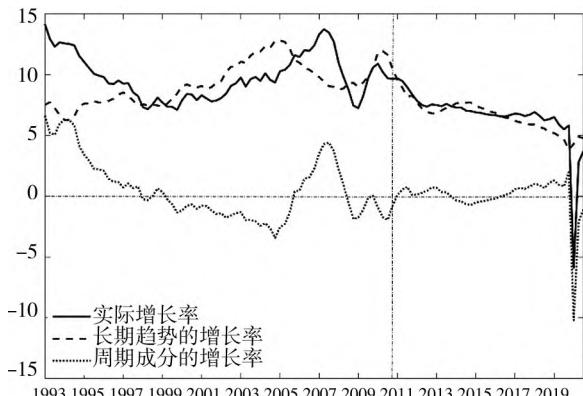


图3 GDP各个序列增长率的比较

Fig. 3 Comparison of GDP growth rates

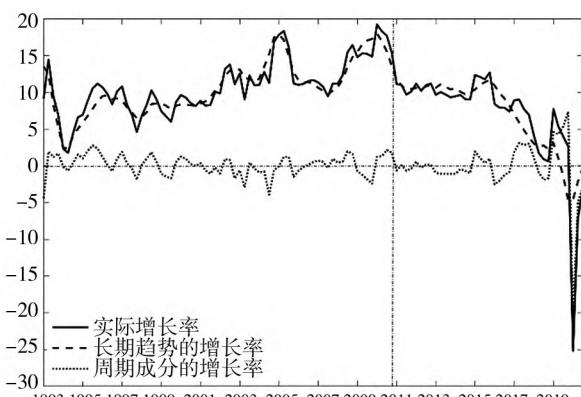


图5 消费各个序列增长率的比较

Fig. 5 Comparison of consumption growth rates

注: 图3~表6的计算方法是, 实际增长率是对数序列的滞后4阶差分, 长期趋势的增长率是长期趋势成分的滞后4阶差分, 周期成分的增长率是周期成分的滞后4阶差分, 因此图3~图6绘制的是年化季度增长率。

下面分析表3~表4中四个模型的协整系数。四个模型中, 当把 y 的系数标准化为1后, 除协整方程 $y = b \times e$ 的状态2外, 其他系数小于1, 并且同一个方程中消费、投资的回归系数之和几乎为1; 这表明消费、投资是推动经济增长的主要动力, 符合经济学原理和常识。更重要的是, c 的

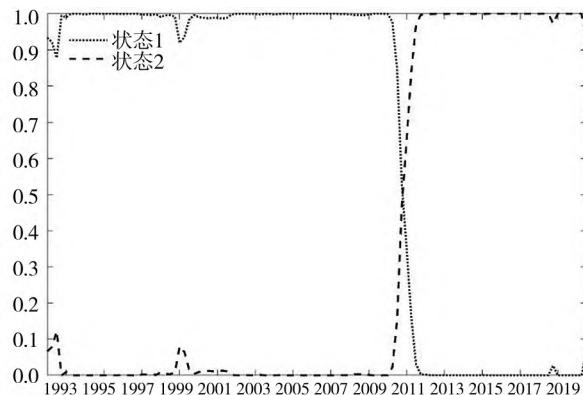


图2 协整系统处于各状态的平滑概率

Fig. 2 Smoothed probability in each state

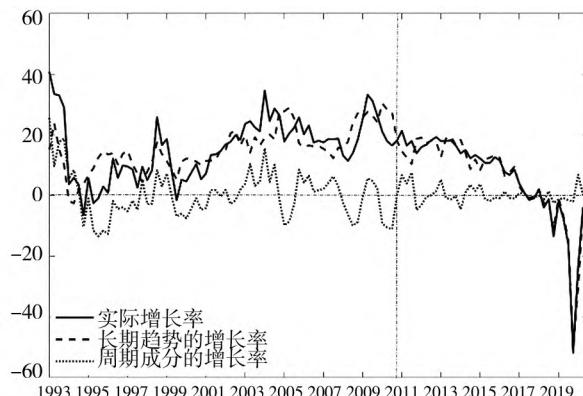


图4 投资各个序列增长率的比较

Fig. 4 Comparison of investment growth rates

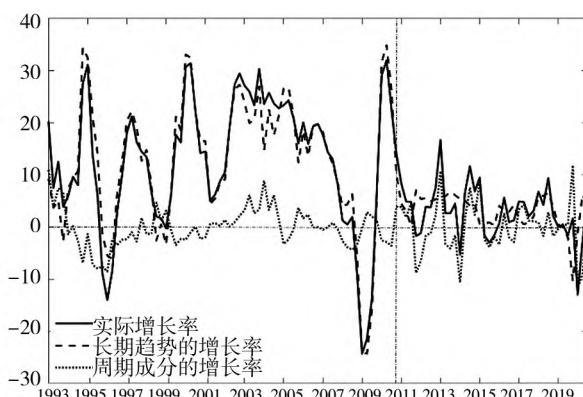


图6 出口各个序列增长率的比较

Fig. 6 Comparison of export growth rates

回归系数在结构性变化前后从大变小; 如果把 c 的回归系数化为1, 则 y 的系数(即 c 的回归系数的倒数)从小变大, 这说明消费对经济增长的拉动作用越来越大。相反, i 和 e 的回归系数从小变大; 同样的, 如果把 i 和 e 的回归系数化为1, 则 y 的系数从大变小, 尤其是在协整方程 $y = b \times e$ 中,

$1/b$ 从大于 1 变为小于 1, 这说明投资和出口推动经济增长的效应越来越小。上述结果表明, GDP、消费、投资和出口的协整关系在 2010 年第 4 季度发生了结构性变化。需要说明的是, 当受到技术进步、制度变革等重大冲击影响时, 不仅 GDP 自身可能发生结构性变化, 如 Perron 和 Wada^[11]发现美国 GDP 在 1970 年发生结构性变化; 本研究还认为, GDP 及其构成成分之间的协整关系也可能发生结构性变化, 这意味着推动经济发展的主要动力发生转变。原因是, 协整关系的结构性变化与经济发展动能转变描述的是同一个问题的两个方面: 前者从计量经济学的角度、后者从经济学的角度; 进一步说, 协整关系的结构性变化从计量经济学的角度验证了经济学意义上经济增长动能的转变。综上所述, 根据协整关系的结构性变化, 可以得出: 结构性变化前后, 推动经济增长的动力发生转换; 在 2010 年第 4 季度前, 推动经

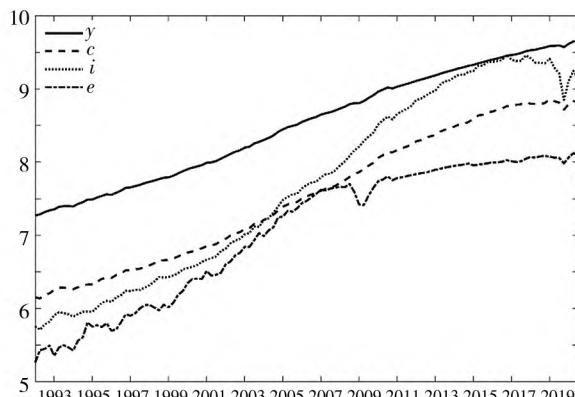


图 7 趋势成分

Fig. 7 Trend components

在估计 MS-FCVAR 即式(16)及其变形式(18)的系数后, 经推导得到相互正交的持久性与暂时性冲击, 即式(24)的随机扰动项; 最终利用式(25)得到趋势成分及周期成分, 结果分别放在图 7~图 8。最后, 利用四个变量的趋势成分和周期成分得到相应的增长率, 结果放在图 3~图 6。从图 3~图 6 可以发现重要结果。1) GDP 与投资趋势成分的增长率的走势最为相似; 只是投资及其长期成分的增长率领先 2 个季度左右。2) 虽然

济发展的主要动力是投资和出口, 尔后变为消费。这是根据“让数据说话”的原则, 新方法得到的重要结论。

那么, 上述重要结果是否合理? 通过对比发现, 新方法所发现的上述重要结论与已有文献对中国经济发展历程的分析、经济理论非常相符。经济理论上, 经济增长的长期趋势主要取决于制度、技术进步、劳动力和土地等供给因素, 这些因素短期内通常不会发生较大变化, 因此受其影响的长期成分一般情况下不会体现出明显的周期性; 只有当影响经济增长的长期因素发生结构性变化时, 其长期成分及其协整关系才会随之发生结构性变化。从实际情况来看, 正如已有文献所分析^[8], 影响我国经济增长的长期因素发生了结构性变化, 而本研究的新方法检测到经济增长与影响因素之间的协整关系的结构性变化及其发生时间。因此, 新方法的结果是合理的。

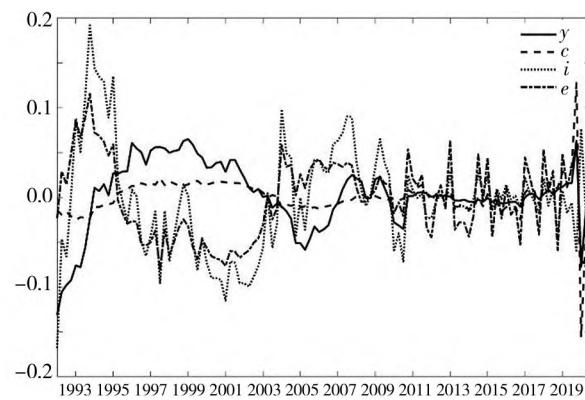


图 8 周期成分

Fig. 8 Cycle components

GDP 与投资增长率的波动较大, 但以 2009 年为结构性变化点: 在此以前, 两者趋势成分的增长率呈现上涨趋势; 尔后呈现下降趋势。显然, 上述两个结果与经济新常态前我国投资拉动经济增长的特征非常吻合, 新方法检测到这些经验事实。3) 2016 年后, 除发生新冠疫情的 2020 年外, 消费和 GDP 的长期趋势增长率在绝大多数时候位于自身增长率的下方, 而周期成分的增长率大于 0; 4) 投资及其趋势、周期成分的增长率不仅低于同期

^⑧ 刘伟^[42]和王一鸣^[43]认为, 我国经济增长的第三轮动力转换是 2011 年并进入新常态。对于工业化进程, 中国在 2010 年后进入工业化后期^[44]。2010 年劳动人口达到峰值后出现负增长、劳动力人口增长和人口抚养比下降是经济增长减速换挡的人口因素^[45]。刘伟和蔡志洲^[46]发现, 从经济增长和通货膨胀波动来看, 2010 年后属于改革开放来的第 4 个周期, 特别是资本形成占 GDP 的比重在 2010 年达到历史峰值 49.7%。

的 GDP 和消费,而且远低于自身前期的增长率。第 3 个结果说明,经济新常态和供给侧改革后,中国经济增长的减速换挡主要是趋势成分的下降而不是周期成分引起。因此,党中央在 2015 年底实施供给侧改革、不搞大水漫灌的决策非常正确。第 4 个结果还说明,新方法还能检测到“经济新常态和供给侧改革后,消费取代投资成为推动经济增长的主要动力”的事实。

3.3 进一步的计量检验

以上分析表明,新方法在“让数据说话”的原则下,准确检测到中国经济减速换挡、经济增长动力发生结构性变化及其时间,因而在经济学意义上具有很大的应用价值。下面通过比较四个方法的样本外预测效果,进一步从计量经济学的角度论证新方法的优越性。基本思路是采取滚动步长为 1、窗口宽度为 84 个季度的向前一步预测^⑨。步骤是:1)利用 1992 年第 1 季度至 2012 年第 4 季度的数据估计相关参数,计算 2013 年第 1 季度的预测值;2)向前滚动一个季度重复第一步,即利用 1992 年第 2 季度至 2013 年第 1 季度的数据估计相关参数,计算 2013 年第 2 季度的预测值;3)依次类推,直至 2020 年第 4 季度。这样得到 32 个样本外预测值,并计算它们与实际值之间的平均误差和均方误差,结果如表 6 所示。从平均误差来看,消费、出口分别在利用 VECM、FCVAR 时最小,而产出和投资都是在利用 MS-FCVAR 时最小;从均方误差来看,与其他三个模型相比,利用

MS-FCVAR 时,四个变量的均方误差都是最小的;综合来看,四个模型中,MS-FCVAR 的预测效果最好。进一步,利用 Diebold 和 Mariano^[47] 的方法比较四个模型的预测效果,其基本思想是对比预测误差的相对大小来检验模型的预测效果,结果如表 7 所示。对于 GDP,VECM 的预测效果最差,MS-FCVAR 模型的预测效果在 5% 的显著水平下优于其他三个模型。对于消费、投资和出口,从表 7 中较难比较 VECM、MS-VECM、FCVAR 预测效果的优劣;但很容易看出,MS-FCVAR 的预测效果具有显著优势,这进一步验证了表 6。最后,表 6~表 7 只比较了四个方法对各个变量的预测效果,接下来利用 Giacomini 和 White^[48] 的条件预测能力指标对四个方法的总体预测效果进行严格检验;该方法的优势是无论是嵌套模型还是非嵌套模型,均能进行比较,而且不受样本大小的限制。检验结果如表 8 所示,其前两列表明,传统的 VECM 比考虑结构性变化或长期记忆的 MS-VECM、FCVAR 的预测效果更差;后三列表明,本研究提出的同时考虑结构性变化和长期记忆的 MS-FCVAR 优于其他三个模型。

综合表 6~表 8 不难看出,由于同时考虑了宏观经济变量的长期记忆、结构性变化,尤其是变量间分数阶协整关系的结构性变化,无论从各个变量还是模型总体的预测效果来看,本研究提出的 MS-FCVAR 模型均优于其他三个模型。

表 6 预测误差对比

Table 6 Prediction error comparison

指标	VECM				MS-VECM			
	y	c	i	e	y	c	i	e
ME($\times 0.01$)	0.702	0.184	0.774	0.718	-0.702	-1.413	1.435	-0.409
MSE($\times 0.01$)	0.086	0.206	3.741	0.568	0.054	0.207	5.077	1.501
指标	FCVAR				MS-FCVAR			
	y	c	i	e	y	c	i	e
ME($\times 0.01$)	-0.640	-1.305	2.012	-0.011	-0.027	-0.401	-0.588	0.221
MSE($\times 0.01$)	0.060	0.210	6.490	1.655	0.051	0.204	3.240	0.441

注: ME、MSE 分别表示平均误差、均方误差。

^⑨ 选择滚动窗口宽度为 84 的理由包括:1)模型参数较多,用于估计参数的样本量不能太少;2)样本应包含结构性变化点即 2010 年第 4 季度,因此窗口宽度须大于 76;3)总样本期是 116 个季度,为便于检验及对比模型的预测效果,滚动窗口宽度不能太大,这样才能得到较多的样本外预测值。

表 7 Diebold-Mariano 检验 p 值
Table 7 P values of Diebold-Mariano tests

变量	模型	VECM	MS-VECM	FCVAR	MS-FCVAR
y	VECM	—	0.084 *	0.063 *	0.023 **
	MS-VECM	0.916	—	0.761	0.040 **
	FCVAR	0.936	0.239	—	0.032 **
	MS-FCVAR	0.977	0.960	0.968	—
c	VECM	—	0.858	0.901	0.083 *
	MS-VECM	0.142	—	0.589	0.036 **
	FCVAR	0.099 *	0.411	—	0.028 **
	MS-FCVAR	0.917	0.964	0.972	—
i	VECM	—	0.919	0.926	0.047 **
	MS-VECM	0.081 *	—	0.931	0.028 **
	FCVAR	0.074 *	0.069 *	—	0.019 **
	MS-FCVAR	0.953	0.972	0.981	—
e	VECM	—	0.942	0.098 *	0.081 *
	MS-VECM	0.058 *	—	0.355	0.019 **
	FCVAR	0.902	0.645	—	0.011 **
	MS-FCVAR	0.919	0.981	0.989	—

注: 以 y 所在组(表 7 第 2 行~第 5 行)为例, 第 2 行的原假设是 VECM 的预测效果优于 MS-VECM、FCVAR 以及 MS-FCVAR, 其他行以此类推. *、**、*** 分别表示在 10%、5%、1% 的水平下显著.

表 8 条件预测能力检验
Table 8 Conditional prediction ability tests

指标	MS-VECM vs VECM	FCVAR vs VECM	FCVAR vs MS-VECM	MS-FCVAR vs VECM	MS-FCVAR vs MS-VECM	MS-FCVAR vs FCVAR
CPA 统计量	4.825 **	3.899 **	0.485	3.413 *	4.983 **	3.274 *
p 值	0.028	0.048	0.486	0.065	0.026	0.070

注: CPA 统计量即条件预测能力指标. 每对检验的原假设都是后一个方法比前一个方法好, 如第一对“MS-VECM vs VECM”的原假设是 VECM 比 MS-VECM 的预测效果好. *、**、*** 分别表示在 10%、5%、1% 的水平下显著.

4 稳健性检验

为进一步验证新方法具有广泛的使用范围, 本研究进行 3 个外延越来越大的稳健性检验. 一是考虑到 2020 年的新冠疫情对 GDP 及其三个构成成分产生较大影响, 所以把上述四个变量的样本量缩减一年, 即不包括 2020 年四个季度的数据, 这种去掉异常值或缩小样本区间是常见的稳健性检验. 二是采用第 3 部分四个变量的名义值. 正如文献综述部分所述, 中国通货膨胀率同时具有长期记忆和结构性变化的特征; 第 3 部分已经表明, 4 个变量的实际值也具有长期记忆和结构性变化. 显然, 双重因素的叠加使得名义值具有更

明显的长期记忆及结构性变化. 因此, 这能进一步检验新方法的稳健性. 三是利用与 Tan 等^[2] 相同的数据, 比较本研究提出的基于 MS-FCVAR 模型和 Tan 等^[2] 提出的基于 FCVAR 模型的分解方法; 在这个检验中, 无论变量、数据还是样本量均有很大变化, 因此, 这能在更大范围检验本研究提出的新方法. 对于第一个稳健性检验, 其结果与第 3 部分几乎相同. 在第二个稳健性检验中, 即在上述四个变量的名义值所构成的系统中, 变量的长期记忆和结构性变化, 尤其是协整关系的结构性变化更加显著. 第三个稳健性检验发现, 以 2012 年为分界点, 推动中国房价上涨的主要因素发生了变化: 2012 年前, 中国房价上涨的主要推动力是以经济发展为代表的实体经济因素; 2012 年后,

货币供应量为代表的虚拟经济因素代替实体经济因素成为房价上涨的主要驱动力。或者说,房价、货币供应量、GDP、房地产开发投资之间的协整关系发生了结构性变化,这与第3部分构建的GDP、投资、消费和出口组成的系统具有相似性质。因此,综合三个检验表明,新方法的结果是稳健的^⑩。

5 结束语

厘清不同趋势周期分解方法的逻辑关系及其优点和缺陷后,本研究提出基于MS-FCVAR模型的新分解方法。新方法既继承KPSW分解法如何分离相互正交的持久性冲击和暂时性冲击的优点,还同时考虑变量潜在的结构性变化和长期记忆、特别是变量之间的分数阶协整关系及其结构性变化。已有多变量分解方法只是新方法的一个特例。因此,无论变量是否存在长期记忆或结构性变化,还是变量间的协整关系是否发生结构性变化,均可使用本研究的新分解方法。

在GDP、消费、投资和出口组成的协整系统中,新方法捕捉到与中国经济发展历程相吻合的经验事实。1)从计量经济学来看,这些变量之间不是传统的整数阶、而是分数阶协整关系,其协整关系在2010年第4季度发生结构性变化。从经济学角度来看,在结构性变化前后,我国经济增长动力发生了转换:在2010年第4季度前,主要动力是投资和出口;尔后变为消费。2)计算分解后的趋势和周期成分的相应增长率,结果表明,GDP与投资的趋势成分增长率的走势最为相似,且投资及其趋势成分的增长率领先GDP两个季度左右;2009年前,两者趋势成分的增长率呈现上涨趋势;而此后呈现下降趋势。显然,新方法能够检测到“经济新常态前投资推动经济增长”以及“经济新常态和供给侧改革后,消费取代投资成为推动经济增长的主要动力”的经验事实。3)经济新常态和供给侧改革后,中国经济增长的减速换挡

主要是趋势成分的下降而不是周期成分引起。进一步的计量检验表明,无论从单个变量还是模型总体的预测效果来看,新方法均优于其他分解方法。

本研究提出的新方法具有广泛而实用的应用前景。对于学术研究,该方法还能用于分解石油价格、汇率、股票价格、房价等资产价格的趋势周期成分及其影响因素。基本面因素决定经济变量的长期趋势,而投机行为对周期成分产生重要影响。根据相关经济理论建立合适的协整系统后,可利用该方法来分解所关注变量的趋势与周期成分,并进一步判断其长期走势与短期波动、以及究竟是趋势还是周期成分发生变化亦或是两者共同变化而引起。

对于实务研究而言,利用本研究的新方法准确分离房价、石油价格、汇率、股票价格的趋势和周期成分后,既可以进一步利用趋势成分来判断上述资产价格处于上升趋势还是下跌趋势;也可以利用周期成分来深入分析资产价格波动性特征如周期长度,判断资产价格处于波峰还是波谷、以及价格波动的转折点,还可判断房价和股价等资产价格是否存在泡沫。显然,这有助于进行正确的投资决策、投资组合管理和风险管理,既规避风险,又使收益最大化。

从宏观经济管理的角度来看,利用本研究的新方法得到的重要结论具有重要的政策应用价值。根据“经济新常态前投资推动经济增长;经济新常态后尤其是供给侧改革后,消费取代投资成为推动经济增长的主要动力;中国经济增长的减速换挡主要是趋势成分的下降而不是周期成分引起的”等结论,本研究认为,目前党中央的重要决策和宏观经济管理政策非常正确,如调整投资和消费的关系、推动内循环等决策有助于使中国逐步成为内生性的需求大国和通过扩大消费和提高消费层次来实现经济的趋势性增长,进而推动我国经济的长期稳定增长和高质量发展。

最后,方法上,由于周期成分可能对其未来趋

^⑩ 篇幅所限,上述稳健性检验的结果放在《管理科学学报》的官方网页,感兴趣的读者也可向作者索取。

势成分产生永久性影响^[8],本研究仅考虑长期冲击与短期冲击的相互正交,未来可进行拓展,并进

一步分析新冠疫情等短期冲击对世界经济和中国经济的潜在长期影响.

参 考 文 献:

- [1] King R, Plosser C, Stock J, et al. Stochastic trends and economic fluctuations[J]. American Economic Review, 1991, 81(4): 819–840.
- [2] Tan Z, Liu J, Chen P. The trend and cycle components of China's housing prices: A new decomposition method[J]. Applied Economics, 2021, 53(28): 3288–3305.
- [3] 林建浩, 王美今. 新常态下经济波动的强度与驱动因素识别研究[J]. 经济研究, 2016, 51(5): 27–40.
Lin Jianhao, Wang Meijin. Intensity and driving forces of macroeconomic fluctuations in the new normal[J]. Economic Research Journal, 2016, 51(5): 27–40. (in Chinese)
- [4] 欧阳志刚, 王世杰. 我国货币政策对通货膨胀与产出的非对称反应[J]. 经济研究, 2009, 44(9): 27–38.
Ouyang Zhigang, Wang Shijie. The asymmetric reaction of monetary policy to inflation and real GDP in China[J]. Economic Research Journal, 2009, 44(9): 27–38. (in Chinese)
- [5] 欧阳志刚, 彭方平. 双轮驱动下中国经济增长的共同趋势与相依周期[J]. 经济研究, 2018, 53(4): 32–46.
Ouyang Zhigang, Peng Fangping. The common trend and the codependent cycle of China's economic growth by the two-wheel drive[J]. Economic Research Journal, 2018, 53(4): 32–46. (in Chinese)
- [6] 祝梓翔, 邓翔. 时变视角下中国经济波动的再审视[J]. 世界经济, 2017, 40(7): 3–27.
Zhu Zixiang, Deng Xiang. A revisit of China's economic fluctuations from the perspective of time-varying analysis[J]. Journal of World Economy, 2017, 40(7): 3–27. (in Chinese)
- [7] Gonzalo J, Ng S. A systematic framework for analyzing the dynamic effects of permanent and transitory shocks[J]. Journal of Economic Dynamics and Control, 2001, 25(10): 1527–1546.
- [8] Cerra V, Fatás A, Saxena S C. Hysteresis and business cycles[J]. Journal of Economic Literature, 2023, 61(1): 181–225.
- [9] Perron P. The great crash, the oil price shock, and the unit root hypothesis[J]. Econometrica, 1989, 57(6): 1361–1401.
- [10] Johansen S, Mosconi R, Nielsen B. Cointegration analysis in the presence of structural breaks in the deterministic trend[J]. Econometrics Journal, 2000, 3(2): 216–249.
- [11] Perron P, Wada T. Let's take a break: Trends and cycles in US real GDP[J]. Journal of Monetary Economics, 2009, 56(6): 749–765.
- [12] Bai J, Perron P. Estimating and testing linear models with multiple structural changes[J]. Econometrica, 1998, 66(1): 47–78.
- [13] Bai J, Perron P. Computation and analysis of multiple structural change models[J]. Journal of Applied Econometrics, 2003, 18(1): 1–22.
- [14] Hamilton J D. A new approach to the economic analysis of nonstationary time series and the business cycle[J]. Econometrica, 1989, 57(2): 357–384.
- [15] Sims C A, Waggoner D F, Zha T. Methods for inference in large multiple-equation Markov-switching models[J]. Journal of Econometrics, 2008, 146(2): 255–274.
- [16] 叶五一, 肖丽华, 缪柏其. 基于变系数分位点回归的金砖四国金融稳定分析[J]. 管理科学学报, 2018, 21(5): 44–52.
Ye Wuyi, Xiao Lihua, Miao Baiqi. Analysis of financial stability of BRIC countries based on varying coefficients quantile regression model[J]. Journal of Management Sciences in China, 2018, 21(5): 44–52. (in Chinese)
- [17] 王少平, 胡进. 中国 GDP 的趋势周期分解与随机冲击的持久效应[J]. 经济研究, 2009, 44(4): 65–76.

- Wang Shaoping, Hu Jin. Trend-cycle decomposition and stochastic impact effect of Chinese GDP[J]. Economic Research Journal, 2009, 44(4) : 65 – 76. (in Chinese)
- [18] Garratt A, Lee K, Pesaran M H, et al. Global and National Macroeconometric Modelling: A Long-run Structural Approach [M]. Oxford: Oxford University Press, 2012.
- [19] Lettau M, Ludvigson S C. Shocks and crashes[J]. NBER Macroeconomics Annual, 2014, 28(1) : 293 – 354.
- [20] 欧阳志刚. 中国经济增长的趋势与周期波动的国际协同[J]. 经济研究, 2013, 48(7) : 35 – 48.
- Ouyang Zhigang. The international co-movement of trend and cycle fluctuation of China's economic growth[J]. Economic Research Journal, 2013, 48(7) : 35 – 48. (in Chinese)
- [21] 王少平, 杨洋. 中国经济增长的长期趋势与经济新常态的数量描述[J]. 经济研究, 2017, 52(6) : 46 – 59.
- Wang Shaoping, Yang Yang. The long-term trend of economic growth and quantitative characteristics of the economic "new normal" in China[J]. Economic Research Journal, 2017, 52(6) : 46 – 59. (in Chinese)
- [22] 祝梓翔, 邓翔, 赵绍阳. 中国经济波动来自趋势还是周期——基于多种 UC 模型的比较分析[J]. 统计研究, 2018, 35(11) : 26 – 41.
- Zhu Zixiang, Deng Xiang, Zhao Shaoyang. Trend fluctuations or cycle fluctuations for China: Comperison analysis based on multiple UC models[J]. Statistical Research, 2018, 35(11) : 26 – 41. (in Chinese)
- [23] 李扬, 张晓晶. “新常态”: 经济发展的逻辑与前景[J]. 经济研究, 2015, 50(5) : 4 – 19.
- Li Yang, Zhang Xiaojing. "The new normal": The logic and perspective of economic development[J]. Economic Research Journal, 2015, 50(5) : 4 – 19. (in Chinese)
- [24] 郭克莎. 中国经济发展进入新常态的理论根据——中国特色社会主义政治经济学的分析视角[J]. 经济研究, 2016, 51(9) : 4 – 16.
- Guo Kesha. Theoretical rationales for China's economy entering the new normal: A political economic analysis of the socialism with Chinese characteristics[J]. Economic Research Journal, 2016, 51(9) : 4 – 16. (in Chinese)
- [25] 田国强. 中国经济增长下滑的原因[J]. 学习与探索, 2018, (4) : 5 – 15.
- Tian Guoqiang. Reasons for China's economic growth[J]. Study and Exploration, 2018, (4) : 5 – 15. (in Chinese)
- [26] 刘金全, 金春雨, 郑挺国. 我国通货膨胀率动态波动路径的结构性转变特征与统计检验[J]. 中国管理科学, 2006, (1) : 1 – 6.
- Liu Jinquan, Jin Chunyu, Zheng Tingguo. Tests for the structural changes in the volatilities of inflation rates path of China's economy[J]. Chinese Journal of Management Science, 2006, (1) : 1 – 6. (in Chinese)
- [27] 顾光同, 许冰. 中国核心 CPI 随机游走识别和异常点分析[J]. 数量经济技术经济研究, 2016, 33(12) : 144 – 158.
- Gu Guangtong, Xu Bing. Identification of core CPI with outlier random walk in China[J]. Journal of Quantitative and Technical Economics, 2016, 33(12) : 144 – 158. (in Chinese)
- [28] 崔畅, 李国伟. 我国农产品价格的结构变化特征及影响因素分析[J]. 数理统计与管理, 2019, 38(1) : 1 – 15.
- Cui Chang, Li Guowei. Analysis of structural change characteristics and influencing factors of China's agricultural product prices[J]. Journal of Applied Statistics and Management, 2019, 38(1) : 1 – 15. (in Chinese)
- [29] Chang C, Chen K, Waggoner D F, et al. Trends and cycles in China's macroeconomy[J]. NBER Macroeconomics Annual, 2016, 30(1) : 1 – 84.
- [30] 刘金全, 隋建利, 闫超. 中国实际产出增长率及其不确定性中的长期记忆性和相关性测度[J]. 社会科学战线, 2010, (1) : 47 – 55.
- Liu Jinquan, Sui Jianli, Yan Chao. Measures of long-term memory and correlation in China's real output growth rate and its uncertainty[J]. Social Science Front, 2010, (1) : 47 – 55. (in Chinese)
- [31] 金晓彤, 闫超. 我国消费增长均值和波动过程的双长期记忆测度[J]. 经济问题探索, 2011, (1) : 28 – 32.
- Jin Xiaotong, Yan Chao. The measurement of the double long-term memory of the average process and the fluctuation

- process of consumption growth in my country [J]. Inquiry into Economic Issues, 2011, (1) : 28 – 32. (in Chinese)
- [32] 祝梓翔, 邓 翔, 路 征. 中国经济波动的持久性成分高吗? [J]. 经济学(季刊), 2019, 18(4) : 1531 – 1554.
- Zhu Zixiang, Deng Xiang, Lu Zheng. Are China's economic fluctuations permanent? [J]. China Economic Quarterly, 2019, 18(4) : 1531 – 1554. (in Chinese)
- [33] Johansen S. A representation theory for a class of vector autoregressive models for fractional processes [J]. Econometric Theory, 2008, 24(3) : 651 – 676.
- [34] Sims C A, Zha T. Bayesian methods for dynamic multivariate models [J]. International Economic Review, 1998, 39(4) : 949 – 968.
- [35] 谭政勋, 张 欠. 中国股票市场的长期记忆性与趋势预测研究 [J]. 统计研究, 2016, 33(10) : 57 – 66.
- Tan Zhengxun, Zhang Qian. Research on the long-term memory of Chinese stock market and its trend prediction [J]. Statistical Research, 2016, 33(10) : 57 – 66. (in Chinese)
- [36] 陈 王, 魏 宇, 马 锋, 等. 高频视角下股市波动预测的新方法: HARFIMA 模型 [J]. 管理科学学报, 2020, 23(11) : 103 – 116.
- Chen Wang, Wei Yu, Ma Feng, et al. A new method of stock market volatility forecasting in high-frequency perspective: HARFIMA model [J]. Journal of Management Sciences in China, 2020, 23(11) : 103 – 116. (in Chinese)
- [37] 李木易, 方 颖. 动态混合 HGARCH 模型的估计和预测 [J]. 管理科学学报, 2020, 23(5) : 1 – 12.
- Li Mu Yi, Fang Ying. Estimation and forecasting of mixture HGARCH model [J]. Journal of Management Sciences in China, 2020, 23(5) : 1 – 12. (in Chinese)
- [38] Barigozzi M, Trapani L. Testing for common trends in nonstationary large datasets [J]. Journal of Business and Economic Statistics, 2022, 40(3) : 1107 – 1122.
- Zhang Lingxiang. Research on the time trend properties of China's macroeconomic variables [J]. Journal of Quantitative and Technical Economics, 2015, 32(2) : 129 – 143. (in Chinese)
- [40] 梁 琪, 滕建州. 中国宏观经济和金融总量结构变化及因果关系研究 [J]. 经济研究, 2006, (1) : 11 – 22.
- Liang Qi, Teng Jianzhou. Structural change of Chinese macroeconomic and financial series and causality analysis [J]. Economic Research Journal, 2006, (1) : 11 – 22. (in Chinese)
- [41] Johansen S, Nielsen M Ø. Likelihood inference for a fractionally cointegrated vector autoregressive model [J]. Econometrica, 2012, 80(6) : 2667 – 2732.
- [42] 刘 伟. 经济新常态与供给侧结构性改革 [J]. 管理世界, 2016, (7) : 1 – 9.
- Liu Wei. New economic normal and supply-side structural reforms [J]. Management World, 2016, (7) : 1 – 9. (in Chinese)
- [43] 王一鸣. 中国经济新一轮动力转换与路径选择 [J]. 管理世界, 2017, (2) : 1 – 14.
- Wang Yiming. A new round of power conversion and path selection in China's economy [J]. Management World, 2017, (2) : 1 – 14. (in Chinese)
- [44] 黄群慧. “新常态”、工业化后期与工业增长新动力 [J]. 中国工业经济, 2014, (10) : 5 – 19.
- Huang Qunhui. "New normal", late industrialization and new power of industrial growth [J]. China Industrial Economics, 2014, (10) : 5 – 19. (in Chinese)
- [45] 蔡 眇. 从中国经济发展大历史和大逻辑认识新常态 [J]. 数量经济技术经济研究, 2016, 33(8) : 3 – 12.
- Cai Fang. Understanding the new normal from the great history and great logic of China's economic development [J]. Journal of Quantitative and Technical Economics, 2016, 33(8) : 3 – 12. (in Chinese)
- [46] 刘 伟, 蔡志洲. 经济周期与长期经济增长 [J]. 经济学动态, 2019, (7) : 20 – 36.
- Liu Wei, Cai Zhizhou. Economic cycle and long-term economic growth [J]. Economic Perspectives, 2019, (7) : 20 – 36. (in Chinese)

- [47] Diebold F X, Mariano R S. Comparing predictive accuracy [J]. Journal of Business and Economic Statistics, 2002, 20(1): 134–144.
- [48] Giacomini R, White H. Tests of conditional predictive ability [J]. Econometrica, 2006, 74(6): 1545–1578.

A new method for decomposing trend and cyclical components: Application based on the deceleration and shifting gears of China's economic growth

TAN Zheng-xun¹, LIU Juan^{2*}

1. College of Economics, Shenzhen University, Shenzhen 518060, China;
2. School of Finance, Hunan University of Technology and Business, Changsha 410205, China

Abstract: To address the shortcomings of the existing trend and cycle decomposition methods, we propose a new method based on the MS-FCVAR model. This new method considers the possible long-term memory of economic variables, the fractional cointegrated relationships among variables and their structural changes. Based on the principle of “letting the data speak for itself”, the new method obtains the following findings in the system of real GDP, fixed asset investment, consumption, and export, which are consistent with the development history of China’s economy. With the fourth quarter of 2010 as the cut-off point, not only has China’s economic growth decelerated and shifted gears, but also the growth momentum has shifted. Since the economy entered “a new normal”, especially the supply-side reform, the declaration of China’s economic growth is mainly caused by the trend rather than the cycle of GDP. More importantly, compared with the existing decomposition methods, the prediction deviation and mean square error of the new method are the least when making out-of-sample predictions. Overall, the new method has both good robustness and can be widely applied to research on many economic and management problems, such as long-term trend judgment and short-term fluctuation analysis.

Key words: decomposing trend and cyclical components; structural changes; fractional cointegration; MS-FCVAR model; deceleration and shifting gears of economic growth