

结构时间序列模型的预测原理及应用研究

朱苏荣 郇志坚¹

摘要：在现代计量经济研究广泛使用的时间序列预测模型，利用回归分析估计参数，进而预测未来的值。但是这些预测方法的函数形式是相对固定的，对于具有不同结构的经济时间序列来说，使用固定函数形式的预测方法进行预测的效果并不理想。本文基于标准的结构时间序列（STM）模型，将原序列分解得到趋势、周期、季节及不规则成分，在此基础上增加回归成分和干预成分，将其扩展为复杂结构时间序列模型。本文详细分析了各成分，并参考经济周期叠加原理，设定不同类型和频率的周期成分叠加。本文给出了模型的状态空间的表达形式，探讨了结构时间序列的预测优势。应用中国名义季度 GDP 进行了预测，比较了不同成分的拟合效果。实证研究表明，结构时间序列模型具有良好的预测效果。

Abstract: Based on the standard structural time series (STM) model, the macro-economic series can be decomposed into trend, cycle, season and irregular components. By adding explanatory and intervention components, we extend it into a complicated structural time series model. Cycles of different frequencies can be tested based on goodness of fit. We compare different mixes of components in forecasting China's quarterly GDP and compare the STM model results with those of other models. The results indicate the STM model has superior forecasting performance.

关键词：结构时间序列；状态空间；预测

声明：中国人民银行工作论文发表人民银行系统工作人员的研究成果，以利于开展学术交流与研讨。论文内容仅代表作者个人学术观点，不代表人民银行。如需引用，请注明来源为《中国人民银行工作论文》。

Disclaimer: The Working Paper Series of the People's Bank of China (PBC) publishes research reports written by staff members of the PBC, in order to facilitate scholarly exchanges. The views of these reports are those of the authors and do not represent the PBC. For any quotations from these reports, please state that the source is PBC working paper series.

¹朱苏荣，经济学博士，任职于中国人民银行乌鲁木齐中心支行，email: zsurong@pbc.gov.cn；郇志坚，管理学博士，任职于中国人民银行乌鲁木齐中心支行，email: huanzhijian@163.com。作者感谢中国人民银行刘斌、马骏等专家的悉心指点。本文内容仅代表作者本人学术观点，不代表人民银行，文责自负。

一、引言

在现代计量经济研究中有许多广泛使用的时间序列预测模型，如单变量的指数平滑、ARIMA 模型，多变量的向量自回归(VAR)模型，以及增长曲线模型等。这些预测模型以过去经济变动的的时间序列特征为基础，利用回归分析估计参数，进而预测未来的值。但是这些预测方法的函数形式是相对固定的，对于具有不同结构的经济时间序列来说，使用固定函数形式的进行的预测效果并不理想。

针对时间序列的结构特征，结构时间序列(Structure Time Series, STM)将原时间序列分解为趋势、季节、周期、不规则成分及相关成分。STM 模型直接用其构成的各成分来表示，因此也称为不可观测成分(Unobserved Components, UC)模型。每个成分都被设定为随着时间推移而不断变化的随机过程。所观测到的时间序列分解为不可观测的随机过程，更有助于捕获时间序列的动态特性，因而 STM 模型有较高的预测精度。STM 模型应用于许多领域，包括经济学、金融学、社会学、管理学、生物学、地理学、气象学和工程学。

在经济政策方面，预测往往是最关注的变量，而不是它的独立成分。但是理解时间序列分解及相关成分的动态特性，更有利于原始变量预测。根据时间序列的结构特征，趋势成分通常表示时间序列的长期发展轨迹，经常设定为时间的平滑函数。在一年内经常性和持续变化规律可以通过季节性成分来捕获。在经济时间序列，周期成分可以代表与经济周期（或产出缺口）相关联的动态特性。

STM 模型有一个自然的状态空间表达，其统计处理基于卡尔曼滤波及其相关的方法。由此产生的建模框架为预测提供了极大的便利。卡尔曼滤波的核心步骤包括预测和修正，其具有内在的预测功能，它提供了最佳的点和区间预测，也纳入了相关的预测函数的观测权重。在这种方式下，预测可以直接表示为过去观测值的函数。模型参数估计通过似然函数极大化得到，似然函数值由基于数值优化的卡尔曼滤波进行评估。基于参数估计，可观测时间序列才得以分解为趋势、季节、周期和不规则等成分，并将其可视化。模型检验可以使用标准化的提前一步预测误差的统计量来进行诊断。

本文结构如下：第 2 节对 STM 模型进行了文献综述。第 3 节讨论如何将时间序列分解为趋势、周期、季节及不规则因素等成分。第 4 节讨论状态空间分析方法。我们引入状态空间模型，我们给出了 STM 模型的状态空间表达形式。我们提出了卡尔曼滤波，讨论了参数最大似然估计，并对统计数据进行了一些诊断检验。第 5 节讨论 STM 中对缺失值处理和观测值权重问题。第 6 节给出了 STM 模型的具体运用和比较了预测效果。第 7 节简述了结论。

二、文献综述

结构时间序列模型由英国经济计量学家 Harvey(1983)首次提出。在随后的

近二十年里, Harvey 与其合作者持续进行了系统性的工作, 使得 STM 理论日臻完善, 随之也得到广泛应用。Harvey(1989)在其专著《预测, 结构时间序列模型与卡尔曼滤波》中, 正式提出并详细阐述了 STM 的原理。Harvey & Shephard(1993)系统地论述了和修订了 STM 模型。Harvey & Koopman(1997)研究了多变量的 STM 模型。Proietti(2000)比较了 STM 模型中的不同季节成分。Harvey & Koopman(2000)讨论了信号抽取和不可观测模型的形成。Koopman & Harvey (2003)研究了 STM 模型预测的观测值权重的计算方法。Harvey & Koopman(2000), Harvey (2001)给出了 STM 模型的诊断检验。Harvey et al(2006)再次梳理和修正了 STM 的原理和预测能力。Harvey (2007)将 STM 研究引入到贝叶斯框架下。Harvey & Peters(1990)给出了 STM 的估计程序。Koopman & Ooms(2011)以 UC 模型重新描述了 STM 模型。Harvey & Todd(1983)深入比较了结构时间序列模型和 Box-Jenkins 模型, 证实结构模型的预测能力较高。Andrews(1994)检验和证实了模型的预测精度非常高。Pauly & Schell(1989)考察了日历效应。Butter & Mourik(1990)证实 STM 模型对基于季节调整的精度高于 X11 方法。

结构时间序列模型通常是指将经济指标用其自身的趋势因素(Trend)、周期因素(Cycle)、季节因素(Seasonal)及不规则因素(Irregular)来表示模型。这种结构模型的着眼点并不在于精确表示数据的生成过程, 而在于通过将序列分解成各成份来表示序列。与传统时间序列模型相比, 它对经济变量的描述更为清晰、明确和灵活, 特别是更容易准确表达序列的变动特征。

由于在结构时间序列模型中由经济指标分解得到的各成分均不可观测变量, 无法利用传统的回归分析方法求解模型。因此, 在统计处理上采用状态空间形式来表示结构时间序列模型, 状态空间模型不但可以利用状态向量表示不可观测的各成分, 还可以利用卡尔曼滤波强有力的递推算法对状态向量各成分进行最优估计、平滑和预测, 因而保证了模型预测的精度和可靠性。

结构时间序列模型作为基础计量方法, 其主要应用于时间序列相关成分的分解、估计及预测, 其应用范围非常广泛, 几乎囊括了时间序列的所用相关领域, 包括经济和非经济领域。Harvey & Jaeger(1993)分析了宏观经济序列的去趋势和经济周期问题。Harvey(2011)估计了菲利普斯曲线。Moosa(1999, 2000)分别考察了奥肯系数和英国价格的周期性行为。Moosa(2002)考察原油期货市场的价格发现和风险转移的功能。Carvalho & Harvey(2005a)考察了美国区域经济增长的收敛性。Carvalho & Harvey(2005b)应用多元 STM 模型考察了欧元区的人均收入的收敛性。Buseti, Fabiani & Harvey(2006, 2007)分析了价格和通胀的收敛性。Harvey & Snyder(1990)分析了库存问题。Zizza(2006)估计了意大利的 GDP 缺口。Tawadros(2008)检验了货币政策对汇率的影响。Iyer(2010)分析了美国短期和远期利率的关系。Harvey & Fernandes(1990)分析了保险索赔。Dilaver & Hunt(2011)分析了土耳其的工业电力需求。Jackman & Greenidge(2005)和 Song et al(2011)运用时变系数预测了旅游人数。Thury & Witt(1998)预测了澳大利亚的工

业产出。Komaki & Penzer(2005)估计牛奶的时变价格供给弹性。Harvey & Durbin(1986)分析了英国交通死伤的原因和安全带法案的影响。Harvey & Koopman(1996)将 STM 应用于药品销售研究。Adhikaria et al(2007)分析了美国生猪的供应反应函数。

国内的研究相对较少，郭向军和顾岚(1992)介绍了结构经济序列分析的状态空间方法，分年度、季度和月度数据给出了计算案例。顾岚(1992)介绍了结构经济时间序列的分解，并比较了 X11 的季节调整方法。韩冬梅和高铁梅(2000)基于结构时间序列模型研究了季节调整方法。陈飞和高铁梅(2005)介绍了结构时间序列模型在经济预测方面的应用，但它是把 ARIMA 模型纳入到结构时间模型来求解，并没有真正应用 STM 的本质。王群勇(2011)以中国季度 GDP 为例研究了结构时间序列方法的季节调整应用，证实其优于 X-11 和 SEATS 方法。

三、结构时间序列模型各成分

经济时间序列 Y_t 一般由趋势(μ_t)、周期(φ_t)、季节(γ_t)及不规则因素(ε_t) 等成分构成。结构时间序列模型可分为加法模型、乘法模型和混合模型，描述各种成分的表达式也不唯一。趋势成分通常表示时间序列的长期发展轨迹，经常设定为时间的平滑函数。在一年内经常性和持续变化规律可以通过季节性成分来捕获。周期成分可以代表与经济周期（或产出缺口）相关联的动态特性， φ_t 是以数年或数十年为周期的景气波动，波动的周期通常是不固定的，很难用数学模型把它精确地表达出来。

基本的结构时间序列模型包括上述四个基本成分：

$$y_t = \mu_t + \varphi_t + \gamma_t + \varepsilon_t, \quad \varepsilon_t \sim NID(0, \sigma_\varepsilon^2) \quad (1)$$

其中， μ_t 为趋势， φ_t 为周期， γ_t 为季节， ε_t 为不规则成分。所有四个成分均为随机且驱动其的扰动相互均不相关。趋势、季节和周期成分由确定性时间函数导出，在限定情形下简化为确定性时间函数。不规则成分为白噪声。

基本结构时间序列模型提供了对时间序列的良好描述，仍有必要纳入一些辅助变量以增强模型的灵活性。在季节经济时间序列中，时间序列的动态变化常受到交易日效应和节日效应的影响，此外序列可能存在异常点和结构断点，干预变量可以很好的捕获上述效应。在其他情形下，模型纳入一组解释变量可以捕获时间序列的特定变化。因此，基本结构时间序列模型经过扩展可包含多重回归效应：

$$y_t = \mu_t + \varphi_t + \gamma_t + \beta_i x_t + \delta_i w_t + \varepsilon_t, \quad \varepsilon_t \sim NID(0, \sigma_\varepsilon^2) \quad (2)$$

x_t 为 K 维决定变量， β_i 为 K 维回归系数向量， w_t 为干预虚拟变量，对 w_t 的不同设定可表征水平平移、斜率平移和脉冲型干预变量， δ_i 为其系数。所有的成分都分为随机型（时变）和确定型（时不变，其依赖于方差是否设定为零。所有成分，包括 β_i 和 δ_i ，均允许随着时间变化，但 β_i 和 δ_i 一般简化为时间不变的固定值。

(一) 趋势成分

时间序列的非平稳性由趋势成分来表征。在经济序列中，主要有 I(1)、I(2)、及 I(K)以及相关模型。趋势成分通过递归设定其漂移项(drift)来表征主要的时间序列。趋势成分包含水平(level)和斜率(slope)成分，分别记为 μ_t 、 β_t ：

$$\begin{aligned} \mu_{t+1} &= \mu_t + \beta_t + \eta_t, & \eta_t &\sim NID(0, \sigma_\eta^2) \\ \beta_{t+1} &= \beta_t + \zeta_t, & \zeta_t &\sim NID(0, \sigma_\zeta^2) \end{aligned} \quad (3)$$

其中， η_t 和 ζ_t 为相互不相关的白噪声，均值为零，方差分别为 σ_η^2 和 σ_ζ^2 。方差越大，则其随机变动越大。如果 $\sigma_\eta^2 > 0$ 且 $\sigma_\zeta^2 > 0$ ，其称之为局部线性趋势(local linear trend)模型，其表征 I(2)类时间序列，如月度的工业生产总值、货币供应量；如果 $\sigma_\eta^2 > 0$ 且 $\sigma_\zeta^2 = 0$ 且 $\beta_1 \neq 0$ ，其称之为带漂移项的随机游走(random walk with drift)模型，其表征 I(1)类时间序列；如果 $\sigma_\eta^2 > 0$ 且 $\sigma_\zeta^2 = 0$ 且 $\beta_1 = 0$ ，其称之为局部水平(local level)模型，其表征 I(1)类时间序列，如季度 GDP；如果 $\sigma_\eta^2 = \sigma_\zeta^2 = 0$ ，则退化为确定线性。

(二) 季节成分

季节成分捕获时间序列在一年内的重复动态变化。季节成分主要处理两个特性。第一是跨整年的季节数值差异很小。第二是在一整年内季节均值等于或近似于零。季节成分通常有虚拟变量法、三角函数法和随机游走法，其中前两种较为常见。S 为一年的季节数，季度为 4，月度为 12，也可表征日数据和日内高频数据。

虚拟变量法，较为直接表达并容易理解。对于季节成分的第一个要求可表示为： $y_t - y_{t-s} \approx 0$ 或 $(1-L^s)y_t \approx 0$ 。将滞后多项式因子分解可得： $(1-L)(1+L+L^2+\dots+L^{s-1})y_t \approx 0$ 。第一项因子我们并不感兴趣，如果时间序列本身几乎不变，则其跨年度的差分也近似于零。第二项与季节相关，即可表示为：

$$\gamma_{t+1} + \gamma_t + \dots + \gamma_{t-s+2} = \omega_t \quad (4)$$

这就是所谓的加法或虚拟季节变量模型。它需要相邻两个季节的值相近，适合于气候不相关的季节序列。

如果相邻的两个季节的值变化不大，季节模型较为平滑，则需要三角函数季节变量，也称谐波或傅立叶模型。季节模式通过一组三角函数项来建模，其季节频率为 $\lambda_j = 2\pi j / s, j=1, \dots, [s/2]$ ，其中如果 s 为偶数，则 $[s/2]$ 为 $s/2$ ，如果 s 为奇数，则 $[s/2]$ 为 $(s-1)/2$ 。对于月度数据来说， λ_j 为 12、6、4、3 和 2.4 个月。

三角季节模型中每个谐波为二状态模型，包括一个辅助的独立部分。

$$\begin{pmatrix} \gamma_{j,t+1} \\ \gamma_{j,t+1}^* \end{pmatrix} = \rho \begin{pmatrix} \cos \lambda_j & \sin \lambda_j \\ -\sin \lambda_j & \cos \lambda_j \end{pmatrix} \begin{pmatrix} \gamma_{j,t} \\ \gamma_{j,t}^* \end{pmatrix} + \begin{pmatrix} \omega_{j,t} \\ \omega_{j,t}^* \end{pmatrix} \quad (5)$$

式(3)中每个谐波成分的方差互不相同，即不同季节成分的变化模式有所差异。不过 Harvey(2005)认为，从实践应用的角度来看，除了季节 $j=s/2$ 之外，令其他季节的方差相同具有良好的估计结果。将这些不同频率的谐波递归叠加，以表征完全的灵活性。季节效应在 t 时点为：

$$\gamma_t = -\sum_{j=1}^{[s/2]} (\gamma_j \cos \lambda_j t + \gamma_j^* \sin \lambda_j t) \quad (6)$$

当 s 为偶数，在 $j = s/2$ 时，正弦项为零，季节成分简化为 $\gamma_{j,t} = \gamma_{j,t-1} \cos \lambda_j + \omega_{j,t}$

(三) 周期

为捕获时间序列的周期特征，需要纳入平稳的周期结构。周期结构可设定为多种随机过程，并运行这些过程可以叠加在一起。周期有两类基本的设定：ARMA 和三角函数周期。

ARMA 设定，即周期成分 φ_t 可表达为平稳的自回归移动平均过程 (autoregressive moving average, ARMA):

$$\phi_p(L)\varphi_{t+1} = \theta_q(L)\xi_t, \quad \xi_t \sim NID(0, \sigma_\xi^2) \quad (7)$$

$\phi_p(L)$ 为 p 阶自回归多项式， $\theta_q(L)$ 为 q 阶移动平均多项式， L 为滞后算子。自回归过程平稳的必要条件是多项式的根 $|\phi_p(L)| = 0$ 在单位圆之外。当其根在复数范围内，ARMA 过程的自相关函数在理论上具有周期的属性。它也要求 $p > 1$ 。在这种情形下，自相关收敛为零，随着滞后阶数增加，收敛的模式为周期性。它暗示时间序列自身具有周期性的动态属性。一旦自回归系数被估计， φ_t 就可以检测到时间序列的周期性动态。Clark(1987)在经济周期分解模型中对平稳的 ARMA 成分的设定为 $p=2$ 和 $q=0$ 。

三角函数法：令 φ_t 为频率为 λ_c 的时间周期函数，其单位为弧度。周期的长度，为 $2\pi/\lambda_c$ 。周期可以表达为正弦波和余弦波的叠加，其取决于两个参数， α, β ，即：

$$\varphi_t = \alpha \cos(\lambda_c t) + \beta \sin(\lambda_c t)$$

其中 $\sqrt{(\alpha^2 + \beta^2)}$ 为幅度， $\tan^{-1}(\beta/\alpha)$ 为其相位。周期成分也以递归方式构建，最终得到其随机模型：

$$\begin{pmatrix} \varphi_{t+1} \\ \varphi_{t+1}^* \end{pmatrix} = \rho \begin{pmatrix} \cos \lambda_c & \sin \lambda_c \\ -\sin \lambda_c & \cos \lambda_c \end{pmatrix} \begin{pmatrix} \varphi_t \\ \varphi_t^* \end{pmatrix} + \begin{pmatrix} \kappa_t \\ \kappa_t^* \end{pmatrix} \quad (8)$$

κ_t 和 κ_t^* 为相互不相关但具有共同的方差 σ_κ^2 。 ρ 为衰减因子，其满足 $0 \leq \rho \leq 1$ 。如果 ρ 严格小于 1，则模型为平稳。 λ_c 为零或 π ，则模型退化为一阶自回归过程。不同的 λ_c 可以表征不同长短周期，即高频短波，中频中波，及低频长波。

在这里强调，季节成分的子模式为互斥，而周期成分的子模式可以多选并可叠加。其依赖于经济理论和统计条件的限制。

四、线性高斯状态空间模型

STM 模型具有自然的状态空间形式，能够统一表达各类线性时间序列。线性高斯状态空间形式包含状态方程和测量方程。

$$\begin{aligned} y_t &= Z_t \alpha_t + G_t e_t & e_t &\sim ND(0, H) \\ \alpha_t &= T_t \alpha_{t-1} + R_t \eta_t & \eta_t &\sim ND(0, Q) \end{aligned} \quad (9)$$

$m \times 1$ 维的状态向量 α_t 包含不可观测成分及其相关变量。测量方程为第一个方程，它将观测向量 y_t 与状态向量 α_t 通过选择矩阵 Z_t 相联系， $Z_t \alpha_t$ 也称之为信号。状态方程为第二个方程，它描述了不可观测的状态向量 α_t 为一阶马尔可夫

的动态过程。 Z_t, T_t, G_t, R_t 为系统矩阵，可表达时变系数，常为已知的稀疏矩阵。系统矩阵中，特定元素可设定为未知参数向量的函数。

(一) 卡尔曼滤波

考虑线性高斯状态空间模型。状态向量 α_t 的预测算子为观测变量 y_1, \dots, y_t 的线性函数。给定观测变量 y_1, \dots, y_{t-1} ，卡尔曼滤波计算状态向量 α_t 的最小平方均值线性估计值 (minimum mean square linear estimator, MMSLE, 记为 $a_{t|t}$ ，及其平均误差平方(mean square error, MSE)矩阵，记为 $P_{t|t}$ 。 $a_{t+1|t}$ 也称为状态预测估计值， $P_{t+1|t}$ 称为其状态预测误差方差矩阵。卡尔曼滤波为：

$$\begin{aligned} v_t &= y_t - Z_t a_{t|t-1}, & F_t &= Z_t P_{t|t-1} Z_t' + G_t G_t' \\ M_t &= T_t P_{t|t-1} Z_t' + R_t G_t' \end{aligned} \quad (10)$$

$$a_{t+1|t} = T_t a_{t|t-1} + K_t v_t, \quad P_{t+1|t} = T_t P_{t|t-1} T_t' + R_t R_t' - K_t M_t'$$

其中卡尔曼增益矩阵 $K_t = M_t F_t^{-1}$ ，对于其初始值 $a_{1|0}$ 和 $P_{1|0}$ 。提前一步预测误差 $v_t = y_t - E(y_t | y_1, \dots, y_{t-1})$ 及其方差 $\text{var}(v_t) = F_t$ 。新息为零均值且序列不相关，因此 $E(v_t v_s') = 0, \quad t \neq s, \quad t, s = 1, \dots, n$

在卡尔曼滤波计算 $a_{t+1|t}$ 和 $P_{t+1|t}$ 之前，状态向量 α_t 在给定 y_1, \dots, y_t 的条件 MMSLE 记为 $a_{t|t}$ ，其相应的 MSE 矩阵记为 $P_{t|t}$ ，其计算为

$$a_{t|t} = a_{t|t-1} + P_{t|t-1} Z_t' F_t^{-1} v_t, \quad P_{t|t} = P_{t|t-1} - P_{t|t-1} Z_t' F_t^{-1} Z_t P_{t|t-1} \quad (11)$$

$$\text{然后, } a_{t+1|t} = T_t a_{t|t}, \quad P_{t+1|t} = T_t P_{t|t} T_t' + R_t R_t'$$

卡尔曼滤波的形式化证明参见 Harvey(1989)和 Durbin & Koopman(2012)。

(二) 似然估计

卡尔曼滤波可用来计算高斯似然函数，其通过预测误差分解 (Harvey, 1989)。给定模型，我们将 y_1, \dots, y_n 的联合密度记为 $p(y_1, \dots, y_n)$ ，其预测误差分解为：

$$p(y_1, \dots, y_n) = p(y_1) \prod_{t=2}^n p(y_t | y_1, \dots, y_{t-1}) \quad (12)$$

预测密度 $p(y_t | y_1, \dots, y_{t-1})$ 为高斯分布，且均值为 $E(y_t | y_1, \dots, y_{t-1}) = Z_t a_{t|t-1}$ ，方差为 $\text{var}(y_t | y_1, \dots, y_{t-1}) = Z_t P_{t|t-1} Z_t' + G_t G_t'$ 。对于已实现的时间序列 y_1, \dots, y_t ，其对数似然函数为：

$$\begin{aligned} L = \log p(y_1, \dots, y_n) &= \sum_{t=1}^n \log p(y_t | y_1, \dots, y_{t-1}) \\ &= -\frac{n}{2} \log(2\pi) - \frac{1}{2} \sum_{t=1}^n \log |F_t| - \frac{1}{2} \sum_{t=1}^n v_t' F_t^{-1} v_t \end{aligned} \quad (13)$$

提前一步预测误差 v_t 及其方差 F_t 由卡尔曼滤波在给定参数向量 θ 下计算可得。为了显性表明似然函数依赖于参数向量 θ ，可记为 $L = L(\theta)$ 。

(三) 参数估计

在状态空间分析给定一个模型设定，需要估计的两组参数。第一组包含在参数向量 θ ，参考 3.1 的说明。第二组包括不可观测的（非平稳的）过程的变量初始值和如式 (13) 中的回归系数 δ 。在理论上，不可观测的平稳过程的初始条件可由自协方差函数导出。

参数向量 θ 的极大似然估计。式 (13) 的对数似然函数关于 θ 的极大化估

计可以通过拟牛顿法来估算。一般认为 Broyden-Fletcher-Goldfarb-Shanno (BFGS)在收敛速度和数值稳定方面最具计算优势。BFGS 迭代最优化算法是基于梯度(gradient 或 score)的信息。在状态空间分析方法中计算 θ 的当前值的梯度的最快的解析和数值算法是由 Koopman & Shephard(1992)开发的。当事前选定的收敛条件满足, 则 BFGS 算法终止。收敛条件一般基于对梯度的当前评估, 相对之前的估计的参数值变化或者似然函数值变化。迭代次数的依赖于初始参数值的选择, 条件的严格程度, 以及似然函数的形状等因素。

极大似然估计的替代算法为 EM 算法。EM 算法的计算流程如下。考虑联合密度 $p(y_1, \dots, y_n, \alpha_1, \dots, \alpha_n)$, 期望(expectation, E)步骤取状态向量关于 $p(y_1, \dots, y_n)$ 的条件期望, 极大化(Maximization, M)步骤极大化关于 θ 的结果。E 步骤需要使用与卡尔曼滤波相关的平滑算法估计状态向量(de Jong, 1989)。M 步骤通常采取解析计算, 比完全直接极大化似然函数要相对简单。从 M 步骤得到最“新”的 θ 估计值, 再回到 E 步骤, 根据新估计值评估平滑估计。迭代过程收敛于 θ 的极大似然估计。在较弱的条件下, 可证明 EM 算法的每次迭代都能增加似然函数值。

初始状态和回归系数的估计。非平稳的趋势和季节成分依赖于初始变量, 其处理为未知的固定系数。当模型增加回归效应, 其处理为未知的固定回归系数。4.1 节演示了初始状态和回归系数收集在初始状态向量。在这里, 我们重点关注初始状态向量 α_1 的估计。

假设采用极大似然方法联合估计 α_1 和 θ 。当似然函数关于包含 α_1 和 θ 的高维参数向量的极大化时, 产生数值计算的问题。由于提前一步预测误差 v_t 是初始状态 α_1 的线性函数, 即 $v_t = v_t^o + v_t^a \alpha_1$, 关于 α_1 直接的极大化就可以避免。当卡尔曼滤波计算始于 $a_{10} = 0$ 和 $P_{10} = 0$, v_t^o 等于 v_t , v_t^a 是系统矩阵 Z_t, T_t, G_t 和 H_t 的函数。假定线性无关, 鉴于这种线性关系, 初始状态向量可以从通常的方式对数似然函数压缩 (Rosenbeg, 1973)。

Harvey & Shephar(1990)令人信服地证实 α_1 的极大似然估计可能会导致未知 θ 的估计方差产生偏差, 例如, 它可以增加一个方差估计为零的概率而真实方差并不为零。他们主张 θ 的估计通过关于初始状态下 α_1 的边际极大化或扩散似然函数来估计。在状态空间分析, 这种方法可以嵌入到统一的卡尔曼滤波关于初始状态和回归系数的初始化过程中 (de jong, 1991 和 Koopman, 1997)。

初始状态的平稳条件。当状态向量只包含平稳向量, 对 α_1 的初始条件可从自协方差函数理论获得。在时间不变的平稳状态空间模型中, 则有 $\alpha_t = T_t \alpha_{t-1} + H_t \varepsilon_t$ 及 $E(\alpha_t) = 0$ 和 $P = \text{var}(\alpha_t)$ 当 $t = 1, \dots, n$ 。它遵循 $P = TP + HH'$, 其解得: $\text{vec}(P^*) = (I - T \otimes T)^{-1} \text{vec}(HH')$, 求解黎卡提方程的有效算法在其维度较高时, 可以计算 P^* 。因为这个解法也可应用于 α_1 , 可以采用 $a_{10} = 0$ 和 $P_{10} = P^*$ 来初始化卡尔曼滤波。在大多数模型中, 初始状态向量 α_1 , 包含初始向量和回归系数及平稳变量。

五、缺失值处理和观测值权重问题

STM 模型及其状态空间分析用于预测优势在于三点：第一，STM 所基于的卡尔曼滤波的核心步骤就包含预测与修正，天然具有预测功能；第二，卡尔曼滤波及相关方法的特性就是具有观测数据集缺失的容错能力；第三、STM 纳入了预测观测权重的计算。第一个特性已在前文分析，不再赘述，本节主要讨论后两个特性。

(一) 缺失值与预测

卡尔曼滤波计算出状态向量提前一步的预测，并标记为 $a_{t|t-1}$ 其误差方差矩阵为 $P_{t+1|t}$ ，其中 $t=1, \dots, n$ 。如果 y_t 缺失，卡尔曼滤波并不知道它的数值或其单步预测误差 v_t 。 v_t 缺少的信息反映为 $F_t \rightarrow \infty$ ，表明没有关于 v_t 的信息。

对于卡尔曼滤波， $F_t \rightarrow \infty$ 的结果就是使得 $K_t \rightarrow 0$ ，而卡尔曼滤波的其余计算仍然可以进行。卡尔曼滤波的预测步骤简化为：

$$a_{t+1|t} = T_t a_{t|t-1}, \quad P_{t+1|t} = T_t P_{t|t-1} T_t' + R_t R_t' \quad (14)$$

当 $t = \tau$ 时为 $F_t \rightarrow \infty$ 。在 $t = \tau$ 时， $a_{t|t} = a_{t|t-1}$ 和 $P_{t|t} = P_{t|t-1}$ 。卡尔曼滤波的缺失数据填补的实现非常简单，其依赖于简单的条件语句：如果 y_t 可观测，执行卡尔曼滤波式 (10) 的计算；如果 y_t 缺失，执行预测步骤式 (14)。缺失数据的数量允许在整个数据样本 y_1, \dots, y_n 区间内，既可单独也可连块存在。

缺失值处理可以采用预测及预测误差方差的计算。在观测序列末端，添加了一系列缺失值构成数据集并进行卡尔曼滤波计算。它把未来的观测作为上述方式的缺失值，就可有效地获得状态预测估计的 $a_{n+h|n}$ 和其预测误差方差矩阵 $P_{n+h|n}$ 当 $h=1, 2, \dots$ 。观测值的预测 $\hat{y}_{n+h|n} = E(y_{n+h} | y_1, \dots, y_n)$ ，其误差方差矩阵 $V_{n+h|n} = \text{Var}(y_{n+h} - \hat{y}_{n+h} | y_1, \dots, y_n)$ ，然后计算： $\hat{y}_{n+h|n} = Z_{n+h} a_{n+h|n}$ ， $V_{n+h|n} = Z_{n+h} P_{n+h|n} Z_{n+h}' + H_{n+h} H_{n+h}'$ 其中 $h=1, 2, \dots$ 。这种简单的处理缺失观测值的预测方法是状态空间分析的吸引点之一。

(二) 预测函数的观测权重

当预测未来的观测值时，如何对观测值加权也是非常重要的问题。对于含有时变成分的线性时间序列模型，随着预测时点跨距逐渐加大，预测权重应逐步下降，较远的观测值重要性下降。当时间变化波动较大，权重下降得更快，时间变化平滑的情况下，权重下降得稍慢。Koopman & Harvey(2003)讨论了在状态空间分析中特殊算法来计算预测权重。在这里，重点关注预测 y_{n+h} 的观测序列 y_1, \dots, y_n 的权重。在高斯线性状态空间模型 (9) 中， y_{n+h} 的 MMSLE 是观测序列 y_1, \dots, y_n 的线性函数，即：

$$E(y_{n+h} | y_1, \dots, y_n) = \hat{y}_{n+h|n} = \sum_{j=1}^n w_j (\hat{y}_{n+h|n}) y_j \quad (15)$$

其中 $w_j(\hat{x})$ 表示为 \hat{x} 的计算观测序列 y_j 相关联的权重。

基于观测序列 y_1, \dots, y_{t-1} 的预测状态估计的 a_t 可写为：

$$a_{t|t-1} = \sum_{j=1}^{t-1} w_j (a_{t|t-1}) y_j \quad (16)$$

卡尔曼滤波式 (10) 提供了通过保留卡尔曼增益矩阵 K 来计算预测权重的方法，其由下面的向后递归的算法来实现：

$$w_j(a_{\eta|t-1}) = B_{t,j} K_j, \quad B_{t,j-1} = B_{t,j} K_j - w_j(a_{\eta|t-1}) Z_j, \quad j = t-1, t-2, \dots, 1 \quad (17)$$

其中，初始化 $B_{t,t-1} = I$ 。它计算预测状态 $a_{\eta|t-1}$ 的观测权重。观测权重 $\hat{y}_{\eta|t-1} = Z_t a_{\eta|t-1}$ 是由 $Z_t w_j(a_{\eta|t-1})$ 给出，但也可直接从后向递推计算得到：

$$w_j(\hat{y}_{\eta|t-1}) = B_{t,j} K_j, \quad b_{t,j-1} = b_{t,j} K_j - w_j(\hat{y}_{\eta|t-1}) Z_j, \quad j = t-1, t-2, \dots, 1 \quad (18)$$

其中， $b_{t,j} = Z_t B_{t,j}$ 和初始化的 $b_{t,t-1} = Z_j$ 。

当数据集存在缺失值时，卡尔曼滤波仍然可以应用。假设 y_τ 缺失，递归 (17) 在时刻 $j = \tau$ 简化为：

$$w_\tau(a_{\eta|t-1}) = 0, \quad B_{t,\tau-1} = B_{t,\tau} K_\tau \quad (19)$$

因此，计算观测权重的状态空间分析算法可容纳缺失值。预测观测的权重，可以从式 (19) 获得。使用式 (17) 初始化到时间 $t = n+h$ 时，即设定 $B_{n+h,n+h-1} = I$ ，并应用式 (19)，对于 $j = n+j-1, \dots, n+1$ ，得到 $w_n(a_{n+h|n}) = T_{n+h-1} \dots T_{n+1} K_n$ 。当 y_j 可观测，其权重为以式 (17) 计算，当 y_j 缺失，对于 $j = n-1, \dots, 1$ 的，以式 (19) 计算。预测观测权重通过 $Z_t w_j(a_{\eta|t-1})$ 或直接通过 (18) 计算得到，详细讨论见 Durbin & Koopman(2012)。

然而在现实中，公布的数据并不是一成不变，而是存在频繁的数据修订 (Croushore & Stark, 2001)。数据修订的幅度和频度过大，使得对未来预测和当前经济形势估计均变得更加复杂，尤为重要是最近的数据通常最不可靠 (Koenig et al, 2003)。在数据修订情形下，最近的数据应赋予较低的权重，这与前面的讨论产生了冲突。在仅包含最新可得数据序列的情形下，如何处理末端数据的预测权重则成为新的挑战。

六、应用案例

(一) 数据

我们使用 1992Q1-2013Q4 年的 GDP 季度数据，来源为 Wind 数据库。由于这些数据是根据当年价格季度累计数据，年内季度之间的累计差计算可得各季度数据。本文主要考察 GDP 的预测，因此不需在对 GDP 数据平减，以避免数据转换过程中产生误差。最终计算 GDP 的数据为名义季度 GDP 的对数，即 $L y_t = \log(gdp_t)$ 。

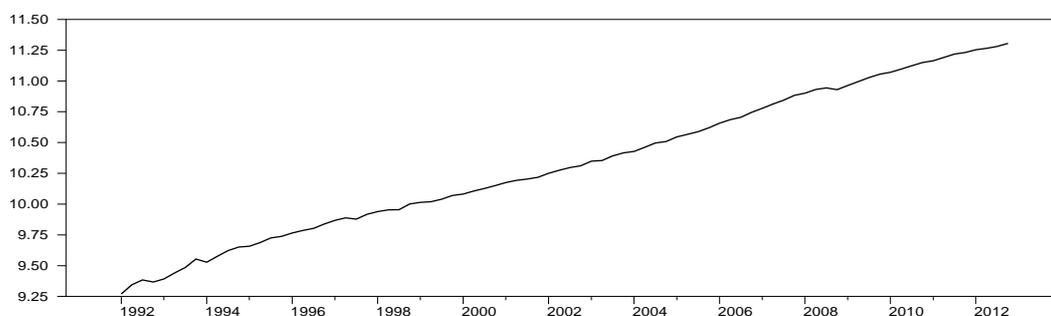


图 1: 1992—2013 年中国对数名义季度 GDP

首先判定中国实际 GDP 为趋势平稳还是差分平稳，分别使用 ADF 和 PP 单

位根检验，所有的检验结果列入表 1。结果表明 Ly_t 是一个差分平稳过程，这意味着实际 GDP 中含有随机趋势。

表 1：我国对数名义季度 GDP 的趋势平稳检验和单位根检验

检验方法	检验方程的形式与估计结果	原假设	统计量值	临界值	结论
ADF	$\Delta ly_t = 0.0279 - 1.1351 \Delta ly_{t-1}$	单位根	-10.3952	-3.5216	是
PP	$\Delta ly_t = 0.0789 - 1.3571 \Delta ly_{t-1}$	单位根	-10.7420	-3.5216	是

注：表中临界值为 1% 显著水平下的临界值，滞后阶数由 AIC 确定。

得到 Ly_t 为一阶单整后，再应用 Box-Jenkins 模型测定 Ly_t 的结构为 ARIMA(2,1,2)，具体结果为：

$$\Delta Ly_t = 0.024 + 0.3193 \Delta Ly_{t-1} - 0.7600 \Delta Ly_{t-2} + \varepsilon_t - 0.6070 \varepsilon_{t-1} + 0.8475 \varepsilon_{t-2} \quad (20)$$

19.9472 5.3109 -17.01660 -7.7667 11.6077

式(21)下方为各变量相应的 T 值，均为 1% 显著性水平。式(20)表明中国 GDP 周期成分是一个二阶自回归平稳过程。

(二) 实证结果

为了充分验证结果，我们考虑了替代模型。首先构建基本模型 Model 1，即基本结构时间序列模型，包括水平、斜率、季节、以 AR(2)表示的周期、以及不规则充分；在此基础上，考察干预效应，增加 $w_t \delta_t$ ，构建 Model 2；依次增加三角函数高频短周期，构建 Model 3；增加中频率中周期，构成 Model 4；仅增加中频率中周期，构建 Model 5。

应用 Bai-Perron 内生段断点检验，发现在 2009Q1 存在水平断点，因此添加虚拟变量以捕获干预效应。完整估计模型为下列组合：

$$\begin{aligned} y_t &= \mu_t + \gamma_{1,t} + \varphi_{1,t} + \varphi_{2,t} + w_t \delta_t + \varepsilon_t, & \varepsilon_t &\sim NID(0, \sigma_\varepsilon^2) \\ \mu_{t+1} &= \mu_t + \beta_t + \eta_t, & \eta_t &\sim NID(0, \sigma_\eta^2) \\ \beta_{t+1} &= \beta_t + \zeta_t, & \zeta_t &\sim NID(0, \sigma_\zeta^2) \\ \gamma_{1,t+1} &= -\gamma_{1,t} - \gamma_{2,t} - \gamma_{3,t} + \omega_t, & \omega_t &\sim NID(0, \sigma_\omega^2) \\ \gamma_{2,t+1} &= \gamma_{1,t} \\ \gamma_{3,t+1} &= \gamma_{2,t} \\ \varphi_{1,t+1} &= c_1 \varphi_{1,t} + c_2 \varphi_{1,t-1} + \tau_t, & \tau_t &\sim NID(0, \sigma_\tau^2) \\ \begin{pmatrix} \varphi_{2,t+1} \\ \varphi_{2,t+1}^* \end{pmatrix} &= \rho \begin{pmatrix} \cos \lambda_c & \sin \lambda_c \\ -\sin \lambda_c & \cos \lambda_c \end{pmatrix} \begin{pmatrix} \varphi_{2,t} \\ \varphi_{2,t}^* \end{pmatrix} + \begin{pmatrix} \kappa_t \\ \kappa_t^* \end{pmatrix}, & \kappa_t &\sim NID(0, \sigma_\kappa^2) \\ \lambda_{t+1} &= \lambda_t + \rho_t, & \rho_t &\sim NID(0, \sigma_\rho^2) \end{aligned} \quad (21)$$

其中， $w_t = 0, t < 2009Q1, w_t = 1, t \geq 2009Q1$,

在基准模型的基础上，渐次增加干预成分和高频短波的周期成分，各信息指数逐渐优化，LogL 值均增加，AIC 和 BIC 则减少，Model 3 的拟合最佳。继续增加了中频中波之后，模型的拟合优度指数并未改善，依照简约原则，模型 4 劣于 Model 3。在 Model 4 的基础上，略去低频短波，保留中频中波，则模型的拟合优度指数则全面下降，再次验证 Model 3 为最佳拟合模型。这也反映出

我国由于样本周期较短，尚不能有效表征中波，在现有样本下，仅能捕获高频短波。实证结果见表 2：

表 2：各模型估计结果

	Model 1	Model 2	Model 3	Model 4	Model 5
周期即虚拟变	AR2	AR ₂ +X	AR2+λ _h +X	AR2+λ _h +λ _m +	AR2+λ _m +X
φ ₁	1.3291	1.2391	0.8586	0.42839	1.2391
φ ₂	-0.4417	-0.3838	-0.1843	0.42843	-0.3838
δ		-0.0606	-0.0582	-0.0582	-0.0606
λ _{ch}			0.4763	0.4763	
λ _{cm}				0.0146	0.1183
p.e.v*	5.4622	4.7784	4.3854	4.3854	4.7796
m.d*	4.1297	3.6837	3.3453	3.3453	3.6833
p.e.v/m.d	1.1137	1.0712	1.0941	1.0941	1.0719
LogL	305.7	306.71	308.587	308.587	306.699
AIC	-7.3761	-7.4871	-7.5729	-7.5729	-7.4869
BIC	-7.2072	-7.2901	-7.3759	-7.3759	-7.2898

注：p.e.v，及 m.d 均为 10⁻⁴，λ_h 为高频，λ_m 为中频。

模型 3 经过 99 次迭代，强烈收敛，模型发现稳定状态 (Steady state)。相应的对数似然值 LogL=306.71，杜宾沃特森值 DW=1.7977 表明残差不存在序列相关，1 阶和 14 阶相关系数 r(1)=-0.0096，r(14)=-0.0692 表明残差不存在高阶序列相关，模型估计结果可靠稳定。模型各成分的系数显著性均在 1% 水平，模型各系数均为时变系数，其中水平 μ_t、斜率 β_t、及季节 γ_t 各成分直接在图 2 中给出。

从表 3 模型各成分的方差可以看出，中国名义季度 GDP 的变动主要为周期成分，其次为斜率变化和季节变化，三者的数量级相同，水平成分变动相对更小，不规则成分，即残差变动非常小。

表 3：模型各成分的方差

	水平 σ _η ²	斜率 σ _ξ ²	周期 σ _τ ²	周期 σ _κ ²	季节 σ _ω ²	不规则 σ _ε ²
方差	3.15E-11	2.76E-05	7.57E-05	5.59E-15	1.43E-05	1.02E-40
Q 比率	4.16E-07	0.3643	1	7.39E-11	0.1888	1.34E-36

注：Q 比率即各成分方差与最大成分方差之比。

模型 3 的 ARMA 周期和三角函数形式的周期成分给出的结果一致，频率为 0.47631，即周期为其倒数 13.19 季度，换算为年则为 3.29 年，其结果说明我国名义 GDP 的短周期相对非常短。模型采用内生断点检测，发现 2009Q1 存在水平断点，其系数为-0.05820。由于 GDP 是对数形式，干预变量的变化百分比等于， $(e^{\hat{y}_1} - e^{\hat{y}_0}) / e^{\hat{y}_0}$ 其中 $e^{\hat{y}_0} = e^{\mu_t + \delta w_t} = e^{\mu_t}$ (由于 w_t 在干预前设定为 0， $e^{\hat{y}_1} = e^{\mu_t + \delta w_t} = e^{\mu_t + \delta}$ (由于 w_t 在干预后设定为 1)。干预效应变化等于： $(e^{\mu_t + \delta} - e^{\mu_t}) / e^{\mu_t} = e^{\delta} - 1$ 。计算 $(e^{-0.05820} - 1) = -0.0565$ ，意味着我国经济增长模式转型对名义 GDP 增长潜力有显著影响。

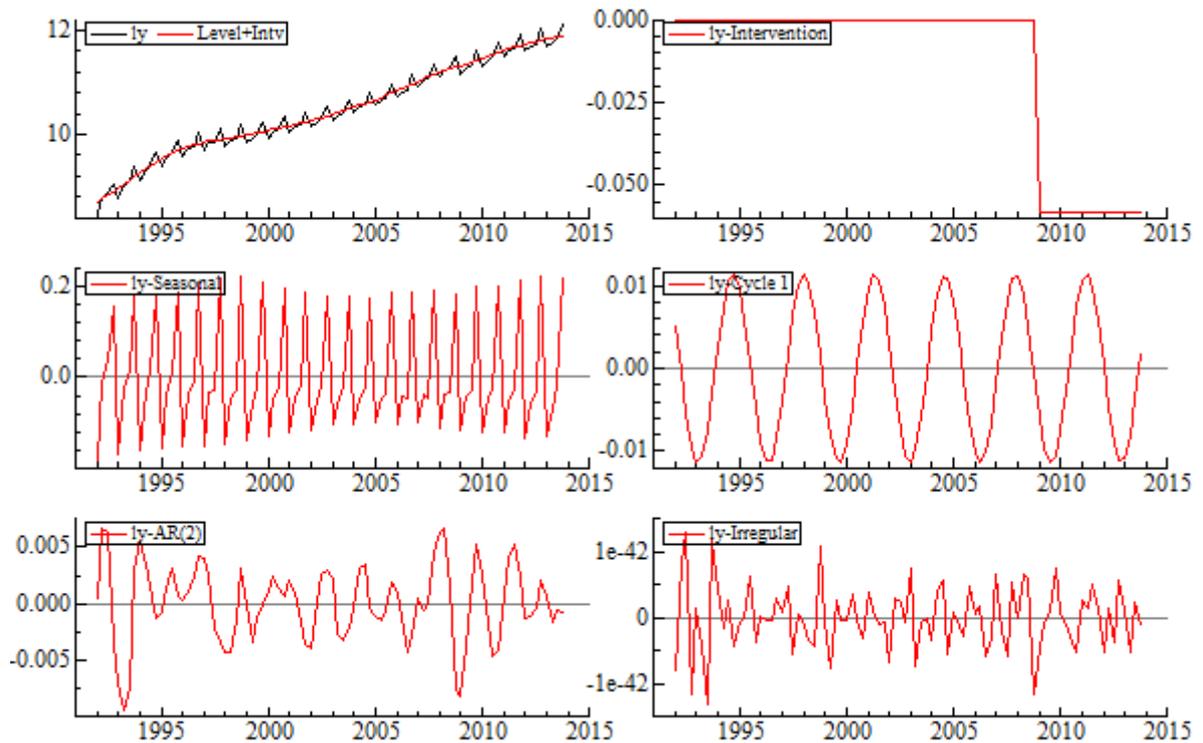


图 2:1992Q1—2013Q4 年中国名义季度对数 GDP 及各成分时序

图 2 给出模型 3 分解的主要成分的时序图，可以看出季节成分的波动幅度最大，由于其变动较为规则，其方差并不是最大；AR2 周期的波动幅度小于谐波周期和季节成分，分别低于 1 和 2 个数量级，但其变化极不规则，其方差最大，其解释了名义 GDP 遭受的各种随机冲击。水平成分的变化较小，近似于直线。斜率成分的变化在 1994 年持续快速下降至 1997 年最低点，之后缓慢增加到 2007 年高点，又缓慢持续下降，变化较为有规律。不规则成分的变化也较小，观察其坐标纵轴可知，其数量级为 e^{-38} ，残差非常小，数量级远远低于模型中的各成分，说明模型对各成分的滤波效果非常好。

（三）结果比较

典型的时间序列的预测模型包括指数平滑模型(ExponentialSmoothing, ES)，整合自回归移动平均模型(AutoRegressiveIntegratedMovingAverage, ARIMA)和 STM 模型。为比较结果，建立了 ARIMA 模型，其带有虚拟变量，经测定其为 ARIMA(1,1,1)(0,1,0)过程，即差分阶数为 1，AR 阶为 2，MA 阶数为 2，季节差分数为 1，参照 STM 模型，也加入 2009Q1 的虚拟变量。为比较 STM 的干预效应，将上述标准的 STM 2 模型和带有虚拟变量的 STM 3 模型。利用滚动窗口技术，固定窗口起始点为 1996Q1，将窗口结束点 2012Q4~2013Q3，步长为 1，建立循环条件。在循环内构建立五个比较模型，进行一步预测。滚动窗口结束点滚动至 2013Q3，最终得到 2013Q1~2013Q4 的静态预测序列。各模型的预测结果如下：

表 4: 各模型静态预测结果

模型	绝对指标					相对指标			
	ME	MAE	RMSE	MSE	Theil's	MPE	MAPE	RMSPE	Theil's
STM 3	-0.0122	0.0167	0.0189	0.0004	0.0858	-0.0010	0.0014	0.0016	0.0871
STM 2	-0.0122	0.0187	0.0200	0.0004	0.0906	-0.0010	0.0016	0.0017	0.0918
ARIMA	0.0028	0.0276	0.0297	0.0009	0.1345	0.0003	0.0023	0.0025	0.1355
RegARIMA	-0.0140	0.0252	0.0314	0.0010	0.1423	-0.0012	0.0021	0.0026	0.1438
ES	-0.0180	0.0180	0.0232	0.0005	0.1053	-0.0015	0.0015	0.0020	0.1069

除了 ME 和 MPE, 大多指标均表明 STM 3 预测的结果最优。整体来讲, STM 模型依次优于 ARIMA 和 ES。在 STM 中, 干预效应显著, 即加入虚拟变量的 STM 3 预测指标显著改善。与此相反, 在 ARIMA 中, 增加虚拟变量, 其预测指标大多有所减弱。Harvey & Todd(1983) 深入比较了 STM 模型和 ARIMA 模型, 证实结构模型的预测能力较高。Andrews(1994) 检验和证实 STM 模型的预测精度非常高。

Granger & Newbold(1973) 提出 GN 检验, Diebold & Mariano(1995) 提出 DM 检验, 考察两类模型间预测准确度是否存在显著差异。在 DM 检验中, 令 $d_t = e_{it}^2 - e_{jt}^2$ 表示模型 i 与模型 j 在第 t 期拟合误差平方的差异, $\bar{d} = T^{-1} \sum_{t=1}^T d_t$ 为 d_t 的样本均值, $\rho_\tau = T^{-1} \sum_{t=\tau+1}^T (d_t - \bar{d})(d_{t-\tau} - \bar{d})$ 为 d_t 的 τ 阶样本自协方差, 则 z 检验统计量可以表示为如下形式: $z = d_t / \sqrt{\Omega/T}$, 其中, $\Omega = \sum_{h=-6}^6 (1 - |h|/7) \rho_h$ 为 d_t 长期方差的异方差-自相关稳健估计量。借用 GN 和 DM 检验评测各模型的预测是否存在显著差异。

表 5: STM 3 与其他模型的预测比较

	GN 检验		DM 检验	
	Stat	P(GN>x)	Stat	P(DM>x)
STM 2	-0.3708	0.63228	-0.4505	0.67382
RegARIMA	-1.9949	0.92999	-1.0284	0.84812
ES	-0.0400	0.51469	-0.8410	0.79984

DM 和 GN 检验都是检验两个预测序列的精度是否存在显著差异。结果显示 STM 3 的结果均略优于其他模型, 但并不显著。结果再次佐证了 STM 的预测优良特性。

七、结论

本文讨论了结构时间序列模型的原理、成分设定和预测优势, 应用中国名义季度 GDP 数据进行了预测, 并将结果与常见模型的预测结果作了比较。结构时间序列模型针对时间序列的结构特征, 将原序列分解为多种随机成分, 各成分可以有效捕获相应的动态特性, 并可纳入虚拟变量和回归变量, 具有较高的准确性和灵活性。重要的是, 结构时间序列模型有自然的状态空间形式, 可充分利用底层的卡尔曼滤波的优良特性, 可以达到较好的预测精度。

本文在标准 STM 模型的基础上，比较了各成分的不同设定，并遴选出最优模型。在传统周期设定的 AR(2)结构上，根据中国实际情况引入高频短波的傅立叶谐波以及内生结构断点。两类改进均提高了模型拟合优度和预测精度。与经典的 ARIMA 和 ES 模型相比，根据绝对指标和相对指标的评估结果都表明 STM 有更好的预测效果。

参考文献

- [1] 陈飞,高铁梅, 2005,《结构时间序列模型在经济预测方面的应用研究》,《数量经济技术经济研究》第2期, 95-103。
- [2] 郭向军,顾岚, 1992,《结构经济序列分析的状态空间方法》,《数理统计与管理》,第5期, 55-50。
- [3] 顾岚, 1992,《关于经济时间序列分解的状态空间方法研究》,《统计研究》,第3期, 46-51。
- [4] 韩冬梅,高铁梅, 2000,《基于结构时间序列模型的季节调整方法研究》,《数量经济技术经济研究》,第3期.40-44。
- [5] 王群勇, 2011,《中国季度 GDP 的季节调整:结构时间序列方法》,《统计研究》,第5期, 78-83。
- [6] Andrews& Rick L.,1994, Forecasting Performance of Structural Time Series Models, Journal of Business & Economic Statistics, anuary1 Vol.12, No.1.
- [7] Bai, J & P. Perron, 2003, Computation and analysis of multiple structural change models, Journal of Applied Econometrics, Vol. 18, no. 1, pp 1-22.
- [8] Carvalho,V.M. Harvey, A. C, 2005a, Growth, cycles and convergence in US regional time series, International Journal of Forecasting, 21, 667-86.
- [9] Carvalho,V.M. Harvey, A. C, 2005b, Convergence in the trends and cycles of Euro Zone income, Journal of Applied Econometrics, 20, 275-289.
- [10] Clark, P. K., 1987, The cyclical component of U.S. economic activity, The Quarterly Journal of Economics 102, 797-814.
- [11] Clements, M. P. and D. F. Hendry Eds., 2011, Oxford Handbook on Economic Forecasting. Oxford: OxfordUniversity Press.
- [12] Croushore, Dean, and Tom Stark, 2001, A Real-Time Data Set for Macroeconomists, Journal of Econometrics, 105(1): 111-30.
- [13] Commandeur, J. J. F. and S. J. Koopman, 2007, An Introduction to State Space Time Series Analysis. Oxford: OxfordUniversity Press.
- [14] Croushore, Dean, Tom Stark., 2001, A Real-Time Data Set for Macroeconomists, Journal of Econometrics 105, pp. 111-130.
- [15] De Jong, P., 1989, Smoothing and interpolation with the state space model. J. American Statistical Association 84, 1085-8.
- [16] De Jong, P., 1991, the diffuse Kalman filter. Annals of Statistics 19, 1073-83.
- [17] Diebold, Francis X., Roberto S. Mariano, 1995, Comparing Predictive Accuracy, JBES, v.13, no.3, pp. 253-63.
- [18] Doz, C., D. Giannone, and L. Reichlin, 2006, A quasi maximum likelihood approach for large approximate dynamic factor models. Discussion paper, CEPR.
- [19] Durbin, J. and S. J. Koopman, 2012, Time Series Analysis by State Space Methods2nd, Oxford: Oxford University Press.

- [20] Fabio Buseti, Silvia Fabiani, Harvey, A. C., 2007, Convergence of prices and rates of inflation, *Oxford Bulletin of Economics and Statistics*, 68, 863-77.
- [21] Francke, M., S. J. Koopman, and A. de Vos, 2010, Likelihood functions for state space models with diffuse initial conditions. *Journal of Time Series Analysis* 31, forthcoming.
- [22] Granger and Newbold, 1973, Some Comments on the Evaluation of Economic Forecasts, *Applied Economics*, vol. 5, pp. 35-47
- [23] Harvey, A.C, Todd, P H J., 1983, Forecasting Economic Time Series with Structural and Box-Jenkins Models, *Journal of Business and Economic Statistics*, 1983, 1, 299-315.
- [24] Harvey, A.C, 1989, Forecasting, structural time series models and the Kalman Filter. Cambridge, UK: Cambridge University Press.
- [25] Harvey, A.C., 2001, Testing in Unobserved Components Models, *Journal of Forecasting*, 20, 1-19.
- [26] Harvey, A.C., 2011, Modelling the Phillips curve with Unobserved Components. *Applied Financial Economics*, special issue in honour of Clive Granger, 21, 7-17.
- [27] Harvey, A.C, Durbin, J., 1986, The Effects of Seat Belt Legislation on British Road Casualties. *Journal of the Royal Statistical Society, Series A*, 149, 187-227.
- [28] Harvey, A.C, Fernandes, C., 1990, Time Series Models for Insurance Claims. *Journal of the Institute of Actuaries*, 116, 513-28.
- [29] Harvey, A.C, Jaeger, A. Detrending, 1993, Stylized Facts and the Business Cycle, *Journal of Applied Econometrics*, 8, 231-47.
- [30] Harvey, A.C, Koopman S.J, 1996, Structural Time Series Models in Medicine, *Statistical Methods in Medical Research*, 5, 23-49.
- [31] Harvey, A. C., Koopman S. J. 1997, Multivariate structural time series models. In C. Heij, H. Schumacher, B. Hanzon, and C. Praagman Eds., *Systematic dynamics in economic and financial models*, pp. 269–98. Chichester: John Wiley and Sons.
- [32] Harvey, A. C., Koopman, S. J. 2000, Signal Extraction and the Formulation of Unobserved Components Models, *Econometrics Journal*, 2000, 3, 84-107.
- [33] Harvey, A. C., S. J. Koopman, and J. Penzer, 1998, Messy Time Series: A Unified Approach. In T. B. Fomby and R. Carter Hill Eds., *Advances in Econometrics*, Volume 13, pp. 103–143. New York, NY, USA: JAI Press.
- [34] Harvey, A. C., Peters, S., 1990, Estimation Procedures for Structural Time Series Models. *Journal of Forecasting*, 1990, 9, 89-108.
- [35] Harvey, A. C., Shephard N., 1990, On the probability of estimating a deterministic component in the local level model. *J. Time Series Analysis* 11, 339–47.
- [36] Harvey, A. C., Shephard, N. G., 1993, Structural Time Series Models N G Shephard, in Maddala, G S, Rao, C R and H D Vinod eds, *Handbook of Statistics. Vol. 11: Econometrics*, Amsterdam: North-Holland, 261-302.
- [37] Harvey, A. C, Snyder, R, 1990, Structural Time Series Models in Inventory Control,

- International Journal of Forecasting,6, 187-98.
- [38] Harvey, A.C., T. Trimbur,H.K. van Dijk ,2007, Cyclical components in economic time series: a Bayesian approach. *Journal of Econometrics*, 140, 618-49.
- [39] Harvey, A. C., T. Trimbur, 2003, Generalised model-based filters for extracting trends and cycles in economic time series. *Rev. Economics and Statistics* 85, 244–55.
- [40] Iyer sridha, 2000 , The relationship between short-term and forward interest rates: a structural timeseries analysis.*Applied Financial Economics*, 10, 143-153.
- [41] Jan P.A.M. Jacobs, Simon van Norden, 2011, Modeling data revisions: Measurement error and dynamics of ‘true’ values. *Journal of Econometrics* 161,101-109.
- [42] Koenig, E.F., Dolmas, S., Piger, J., 2003. The use and abuse of ‘real-time’ data in economic forecasting. *Review of Economics and Statistics* 85, 618–628.
- [43] Koopman, S. J., 1993, Disturbance smoother for state space models. *Biometrika* 80, 117–26.
- [44] Koopman, S. J., 1997, Exact initial Kalman filtering and smoothing for non-stationary time series models. *J. American Statistical Association* 92, 1630–8.
- [45] Koopman, S. J. and A. C. Harvey, 2003, Computing Observation Weights for Signal Extraction and Filtering. *Journal of Economic Dynamics & Control* 27, 1317–1333.
- [46] Koopman, S. J., A. C. Harvey, J. A. Doornik, and N. Shephard, 2008, *Stamp 8.0: Structural Time Series Analyser, Modeller and Predictor*. London: Timberlake Consultants.
- [47] Koopman, S. J., and M. Ooms, 2012, Forecasting economic time series using unobserved components time series models, in *The Oxford Handbook of Economic Forecasting*, Edited by Michael P. Clements and David F. Hendry. Series: Oxford Handbooks.
- [48] Makridakis, S., S. C. Wheelwright, and R. J. Hyndman, 1998, *Forecasting: Methods and Applications* 3rd ed., New York: John Wiley and Sons.
- [49] Murali Adhikaria, Krishna Paudel, Laxmi Paudelc and James Bukenyad,2007, Modelling swine supply response using a structural time series approach.*Applied Economics Letters*,14, 467–472.
- [50] Moosa Imad A., 1999, Cyclical output, cyclical unemployment,and Okun’s coefficient A structural time series approach*International Review of Economics and Finance* 8 293–304.
- [51] Moosa Imad A. ,2000, A structural time series test of the monetary model of exchange rates under the German.*Journal of International Financial Markets,Institutions and Money* 10 213–223.
- [52] Moosa Imad A,2000, The cyclical behaviour of prices in the U.K.:Some structural time series evidence.*Empirical Economics* 25:261-278
- [53] Pauly,R., Schell.A.,1989, Calendar Effects in Structural Time Series Models With Trend and Season.*empec* 14:241-256
- [54] Proietti, T., 2000, Comparing seasonal components for structural time series models. *International Journal of Forecasting* 16, 247–260.

- [55] Rosenberg, B., 1973, Random coefficients models: the analysis of a cross-section of time series by stochastically convergent parameter regression. *Annals of Economic and Social Measurement* 2, 399–428.
- [56] Sargent, T. J. and C. A. Sims, 1977, Business cycle modeling without pretending to have too much a priori economic theory. In C. A. S. et al. Ed., *New methods in business cycle research*. Minneapolis: Federal Reserve Bank of Minneapolis.
- [57] Stock, J. H. and M. Watson, 2002, Macroeconomic forecasting using diffusion indexes. *J. Business and Economic Statist.* 20, 147–162.
- [58] Stock, J. H. and M. Watson, 2011, Dynamic factor models, in *The Oxford Handbook of Economic Forecasting*. Edited by Michael P. Clements and David F. Hendry. Series: Oxford Handbooks.
- [59] Tawadros, George B., 2008, A structural time series test of the monetary model of exchange rates under four big inflations, *Economic Modelling* 25 1216–1224.
- [60] Trimbur, T., 2006, Properties of higher order stochastic cycles. *J. Time Series Analysis* 27, 1–17.
- [61] Tunnicliffe-Wilson, G., 1989, on the use of marginal likelihood in time series model estimation. *J. Royal Statistical Society B* 51, 15–27. 31.
- [62] Watson, M. W. and R. F. Engle, 1983, Alternative algorithms for the estimation of dynamic factor, MIMIC and varying coefficient regression. *J. Econometrics* 23, 385–400.
- [63] Zizza Roberta, 2006, A Measure of Output Gap for Italy: Through Structural Time Series Models. *Journal of Applied Statistics* Vol. 33, No. 5, 481–495, June.