



The Canon Institute for Global Studies

CIGS Working Paper Series No. 23-002J

## 日本におけるコア・インフレとトレンド・インフレ

白井大地（キャノングローバル戦略研究所/東北学院大学）

2023.12

※Opinions expressed or implied in the CIGS Working Paper Series are solely those of the author, and do not necessarily represent the views of the CIGS or its sponsor.  
※CIGS Working Paper Series is circulated in order to stimulate lively discussion and comments.  
※Copyright belongs to the author(s) of each paper unless stated otherwise.

General Incorporated Foundation

**The Canon Institute for Global Studies**

一般財団法人 キャノングローバル戦略研究所

Phone: +81-3-6213-0550 <https://cigs.canon/>

# 日本におけるコア・インフレとトレンド・インフレ\*

白井大地<sup>†</sup>

2023年12月3日

## 概要

本稿は [Stock and Watson \(2016\)](#) によって開発された一変量及び多変量の状態空間モデルを用いて、日本のトレンド・インフレを推定する。構造変化を捉えるために確率的ボラティリティと一時的な大きな変動（外れ値）の発生を確率的に扱えるモデルとなっている。一変量モデルではコア指標を用いることで、多変量モデルではセクター別のインフレ率を用いることで、クロスセクション情報がトレンド・インフレの不確実性や予測精度を改善するかを検討する。推定されたトレンド・インフレによると2022年以降のインフレ率の上昇は、トレンド・インフレの上昇によるものとなっている。予測精度を比較した結果、14セクター別のインフレ率を用いた多変量モデルが最も予測精度が優れており、クロスセクション情報の利用がトレンド・インフレの推定に有用であることを示している。

*Keywords:* トレンド・インフレ、コア指標、確率的ボラティリティ、状態空間モデル、動学的ファクター・モデル

## 1 はじめに

2010年代後半よりインフレ率の上昇が世界的な問題となっている。長期的にデフレないしはゼロ近傍のインフレ率が続いていた日本においても、2022年から顕著に物価上昇が生じている。2022年末から2023年上半期においては前年比で3%以上のインフレ率となって

---

\*本稿の作成にあたり、稲葉大氏、小林慶一郎氏、新谷元嗣氏、地主敏樹氏、菅原晃樹氏、高尾築氏、竹田陽介氏、奴田原健悟氏、舟島義人氏、堀健夫氏より有益なコメントを頂いた。本研究はJSPS 科研費 JP23K12470の助成を受けたものである。深く感謝したい。

<sup>†</sup>東北学院大学経済学部経済学科、キャノングローバル戦略研究所 Email: shirai.daichi@mail.tohokugakuin.ac.jp

いる。日本銀行のインフレ目標の2%を上回る状況となっており、こうしたインフレ率の上昇は一時的な要因なのか、それとも長期的な要因であるのかによって、今後の金融政策の運営が左右され得る。

本稿では日本の長期的なセクター別のパネル時系列データを用いて動学的ファクターモデルを推計することで、インフレ率を一過性成分とトレンド成分に分解を行う。用いるモデルは [Stock and Watson \(2016\)](#) (以下、SW とする) が開発した一変量および多変量の未観測成分確率的ボラティリティ外れ値調整 (Unobserved-Components Stochastic Volatility Outlier-adjusted, 以下、UCSVO) モデルであり日本経済に応用する。

SW の UCSVO モデルは状態空間モデルの一種であり、時系列分析における信号処理の方法を用いてトレンド・インフレを観測不可能成分として抽出するものとなっている。モデルは、集計されたインフレ率を扱う一変量モデルと、セクター別のインフレ率を扱う多変量モデルの2つを用いる。多変量モデルでは、クロスセクションの情報としてセクター別のインフレ率を用いることで、集計されたマクロのトレンド・インフレの予測精度が改善するかを検討する。推定にはベイズアン推定の方法の一つである [Kim, Shephard and Chib \(1998\)](#) と [Omori, Chib, Shephard and Nakajima \(2007\)](#) によって提案された方法を用いる。彼らの推定方法の特徴は、確率的ボラティリティを含むモデルを近似し、標準的な正規分布を仮定した線形状態空間モデルとして扱うことができるようにすることで、効率的なサンプリングを可能にした点にある。

本稿で用いる SW が開発した UCSVO モデルに最も近いモデルに [Del Negro and Otrok \(2008\)](#) がある。[Del Negro and Otrok \(2008\)](#) は未観測成分確率的ボラティリティモデルを用いて国際的な景気循環を分析対象としている。[Del Negro and Otrok \(2008\)](#) と SW との違いは、SW は米国のセクター別のインフレ率を用いた分析となっていること、トレンドをセクター固有成分とセクター間共通成分に分けていること、外れ値をモデルで扱うことを可能にしていることが挙げられる。標準的なモデルでは、確率的ショックは分散を一定としているが、本稿で用いる UCSVO モデルでは、この仮定を緩めて分散の時間変動を許容している。このようなモデルを確率的ボラティリティ (SV) モデルと呼ぶ。そうすることで、ある程度の構造変化にも対応ができるモデルとなる。また大きな変動に関しては外れ値 (Outliers) で対応できるようになっている。外れ値は税制などの制度変更や統計の基準変更などを捉えられると考える。

トレンド・インフレは、数年先の物価変動の予測が反映されており、中央銀行の関心事の一つとなっている。しかし、トレンド・インフレは直接観察することができないため、何らかの方法で抽出することが必要となる。抽出方法としては、大きく分けて2つに分類することができる。1つ目が、クロスセクションデータを用いる方法である。代表的な方法の1つが、変動の大きい項目を除外したコア指標を作成し、トレンド・インフレの代理指標と見なす方法である。コア指標は総務省が公表する毎月の資料においても指標が掲載されており、代表的なコア指標として、生鮮食品を除く総合指数や、生鮮食品及びエネルギーを除く総合指数がある。本研究の一変量モデルでは、CPI 総合を用いた推定だけでなく、コア指標を用いた推定も行う。また推定したトレンド・インフレと、コア指標の予測精度の比較も行う。

2つ目の方法が、時系列分析の1つである信号抽出の方法を用いるものである。最も簡単な方法が前年同期比を取ることであり、前年同期比はトレンドとして見ることできる。また、Hodrick-Prescott フィルター、Band-Pass フィルター、Beveridge-Nelson 分解といったフィルターを用いるもの、AR モデルや IMA モデルを用いるもの、本稿のように状態空間モデルを用いるものが挙げられる。ニュー・ケインジアン・フィリップス曲線を用いて構造推定する研究もあるが、最終的には状態空間モデルとして扱われるので、この方法も信号抽出の方法と見なすことができよう。本稿ではトレンド・インフレを観測不可能成分として状態空間モデルを用いた推定を行う。

推定によって得られた結果は以下の通りである。第1に推定されるトレンド・インフレの推移を見ると、90年代～2020年までは概ね $-1\% \sim +1\%$ の範囲で推移していたものの、2020年に入ってトレンド・インフレは3%を超えるまでになっていることが分かる。第2に、推定されるトレンド・インフレと総務省統計局が公表するコア指標は高い相関を示すものの、推定されるトレンド・インフレはより滑らかな推移を示す。日本において顕著な物価上昇を示さなかった2010年代においても、インフレ率の確率的ボラティリティの大きさが、トレンド・インフレ、一過性成分の両者において高まっている。第3に、多変量モデルと一変量モデルをトレンド・インフレの結果を比較すると、2010年以降の乖離が大きくなっている。トレンド・インフレをセクター別に要因分解すると、食料と教養娯楽の寄与が大きいことが分かる。教養娯楽にはパソコン、家電などの耐久消費財が含まれており、技術革新による価格下落や、半導体などの原材料価格の変動による影響を大きく受けられていると考えられる。第4に、一変量モデルと多変量モデルのパフォーマンスを比較すると、14セクター別の多変量

モデルは一変量モデルと比べて、多変量モデルの方がトレンド・インフレの事後分布の信用区間が狭く不確実性が小さいことが分かる。これはクロスセクションの情報を用いることによって、不確実性の低下に役立っていることを示唆するものである。一方、分類を粗くした3セクター別の多変量モデルは、一変量モデルと比べて信用区間が広がっており、クロスセクションの情報による不確実性低下効果よりも、モデルが複雑になることに伴う不確実性増加効果の方が大きくマイナスに寄与していると解釈できる。最後に、予測精度を比べた結果では、因子負荷量を固定した14セクター別の多変量 UCSVO モデルの予測精度が優れている結果が得られている。多変量 UCSVO モデルを用いてトレンド・インフレを推定する方法は計算が煩雑であるが、その分、予測精度が優れた結果が得られており、金融政策の運用上も利用を検討する価値があることを示唆する。

## 関連文献

トレンド・インフレはマクロ経済学における重要なトピックの一つである。サーベイ論文に [Faust and Wright \(2013\)](#) や [Ascari and Sbordone \(2014\)](#) がある。

SV を考慮した実証分析として、ベイジアン VAR モデルを用いた研究には、例えば、[Cogley and Sargent \(2002, 2005\)](#), [Cogley, Primiceri and Sargent \(2010\)](#) がある。SV を導入した状態空間モデルを用いて推定した研究に、[Stock and Watson \(2007, 2016\)](#), [Kiley \(2008\)](#), [Clark and Doh \(2011\)](#), [Garnier, Mertens and Nelson \(2015\)](#) が挙げられる。

日本におけるトレンド・インフレの計測に関しても膨大な蓄積があるが、近年の研究には [高橋 \(2016\)](#), [Kaihatsu and Nakajima \(2018\)](#), [Okimoto \(2019\)](#), [Sekine, Packer and Yoneyama \(2022\)](#), [柴本 \(2023\)](#) がある。

日本の CPI を用いたコア指標に関しては、[白塚 \(1997, 2006, 2015\)](#)、[川本・中浜・法眼 \(2015\)](#) が手際よくまとめられている。[三尾・肥後 \(1999\)](#) は刈り込み平均指数の特性を分析している。[岩崎・開発 \(2016\)](#) は動的モデル平均化法を用いたコア指標を提案している。

トレンド・インフレの推定にニュー・ケインジアン型フィリップス曲線を用いた推定がある。例えば、[Galí and Gertler \(1999\)](#), [Cogley and Sbordone \(2008\)](#), [Kim, Manopimoke and Nelson \(2014\)](#), [Inoue and Shintani \(2018\)](#), [Hirose, Kurozumi and Van Zandweghe \(2020\)](#) がある。日本を対象にした研究に、[大石・黒住 \(2022\)](#), [Gemma, Kurozumi and Shintani](#)

(2023) があり、彼らはベジアン一般化積率法 (GMM) を用いて推定している。

本稿の構成は以下の通りである。2 節では、一変量 UCSVO モデルと多変量 UCSVO モデルを導入する。3 節では推定方法とデータを説明し、4 節では推計結果を示す。5 節はまとめである。

## 2 モデル

本節では、SW の UCSVO モデルを導入する。モデルには一変量 UCSVO モデルと多変量 UCSVO モデルの 2 種類がある。まず、一変量 UCSVO モデルについて説明し、その後に変量 UCSVO モデルについて説明する。

### 2.1 一変量 UCSVO モデル

一変量 UCSVO モデルは、最も単純な状態空間モデルの一種であるローカル・レベル・モデルに確率的ボラティリティ (SV) と外れ値を導入したものである<sup>1</sup>。ローカル・レベル・モデルは、観測変数がランダム・ウォーク成分とノイズで表現されると仮定することから、random walk plus noise model と呼ばれる。本稿では、日本の消費者物価指数 (CPI) を用いたインフレ率  $\pi_t$  を観測変数とし、インフレ率はトレンド・インフレ  $\tau_t$  と一過性成分  $\varepsilon_t$  の和であると仮定する:

$$\text{インフレ率: } \pi_t = \tau_t + \varepsilon_t, \quad (1)$$

$$\text{トレンド・インフレ: } \tau_t = \tau_{t-1} + \sigma_{\tau,t} \times \eta_{\tau,t}, \quad (2)$$

$$\text{一過性成分: } \varepsilon_t = \sigma_{\varepsilon,t} \times s_t \times \eta_{\varepsilon,t}. \quad (3)$$

ただし、 $\eta_{\varepsilon,t}$ ,  $\eta_{\tau,t}$  は誤差項でそれぞれ独立した標準正規分布に従う。トレンド・インフレはランダム・ウォーク過程に従っており、トレンド・インフレのショックの分散  $\sigma_{\tau,t}$  と一過性成分のショックの分散  $\sigma_{\varepsilon,t}$  は時間変化し、独立した確率的ボラティリティ過程に従う。また、一過性成分  $\varepsilon_t$  には  $s_t$  が導入されており、確率的に外れ値を生成する。 $s_t$  は独立した確率変

---

<sup>1</sup>ローカル・レベルモデルは、状態空間モデルの多くのテキストで紹介されているが、例えば、Durbin and Koopman (2012) Ch.2 や Harvey (1989) Ch.2 を参照。

数であり、 $s_t$  は確率  $p$  の離散型の一様分布に従う:

$$\text{外れ値: } \begin{cases} s_t = 1, & \text{with prob. } 1 - p, \\ s_t \sim U[1, 10], & \text{with prob. } p, \end{cases}$$

$U$  は一様分布を表す。

確率的ボラティリティは以下のように推移する:

$$\text{トレンドの SV: } \Delta \ln(\sigma_{\tau,t}^2) = \gamma_{\Delta\tau} \times \nu_{\Delta\tau,t}, \quad (4)$$

$$\text{一過性成分の SV: } \Delta \ln(\sigma_{\varepsilon,t}^2) = \gamma_{\varepsilon} \times \nu_{\varepsilon,t}. \quad (5)$$

ただし  $\nu_{\varepsilon,t}$ ,  $\nu_{\Delta\tau,t}$  は誤差項を表しそれぞれ独立した標準正規分布に従う。 $\Delta$  は 1 階差分を表すオペレーターである。このモデルでは、確率的ボラティリティはドリフトを伴わないランダム・ウォークに従う。SV 項は (4) 式と (5) 式によって推移するが、この 2 つの式を (2) 式と (3) 式に代入して整理すると:

$$\ln [(\Delta\tau_t)^2] = \ln(\sigma_{\tau,t}^2) + \ln \eta_{\tau,t}^2,$$

$$\ln(\varepsilon_t^2) = \ln(\sigma_{\varepsilon,t}^2) + \ln s_t^2 + \ln \eta_{\varepsilon,t}^2,$$

となる。ただし  $\ln \eta_{\tau,t}^2$  と  $\ln \eta_{\varepsilon,t}^2$  は自由度 1 の対数カイ二乗分布に従う。標準的な線形ガウシアン状態空間モデルでは非正規分布を扱うことができないので、対数カイ二乗分布を混合正規分布によって近似する:

$$\ln \eta_{\tau,t}^2 \approx \sum_{i=1}^{10} b_{\tau,i,t} p_i a_{\tau,i,t}, \quad a_{\tau,i,t} \sim N(\mu_i, \sigma_i^2),$$

$$\ln \eta_{\varepsilon,t}^2 \approx \sum_{i=1}^{10} b_{\varepsilon,i,t} p_i a_{\varepsilon,i,t}, \quad a_{\varepsilon,i,t} \sim N(\mu_i, \sigma_i^2).$$

ただし  $\mu_i$ ,  $\sigma_i^2$ ,  $p_i$  は表 1 の通り [Omori et al. \(2007\)](#) の Table 1 で報告されている値を用いる。 $b_{\tau,i,t}$  と  $b_{\varepsilon,i,t}$  は 10 個のうち正規分布のうち、どの正規分布に従うかを表す指示変数である。このように正規分布を用いて近似することで、線形ガウス状態空間モデルとして扱うことができる。

	1	2	3	4	5	6	7	8	9	10
$p_i$	0.01	0.05	0.13	0.21	0.23	0.19	0.12	0.06	0.02	0.001
$\mu_i$	1.93	1.35	0.74	0.02	-0.85	-1.97	-3.47	-5.55	-8.68	-14.65
$\sigma_i^2$	0.11	0.18	0.27	0.41	0.63	0.99	1.57	2.54	4.17	7.33

表 1: [Omori et al. \(2007\)](#) Table 1

## 2.2 多変量 UCSVO モデル

本節では多変量 UCSVO (MUCSVO) モデルを導入する。多変量 UCSVO モデルは、動学的ファクター・モデルの一種であり、トレンド・インフレと一過性成分をそれぞれセクター共通ファクターとセクター固有ファクターに拡張したものである。セクター別インフレ率  $\pi_{i,t}$  は、セクター共通トレンド  $\tau_{c,t}$ 、セクター共通一過性成分  $\varepsilon_{c,t}$ 、セクター固有トレンド  $\tau_{i,t}$ 、セクター固有一過性成分  $\varepsilon_{i,t}$  の 4 つの要素の合計である。因子負荷量  $(\alpha_{i,\tau,t}, \alpha_{i,\varepsilon,t})$  は時間変化し、ランダムウォーク過程に従うと仮定する。時間変化する因子負荷量によって、セクター間の連動性を捉えることができる<sup>2</sup>。

$$\text{セクター別インフレ率: } \pi_{i,t} = \alpha_{i,\tau,t}\tau_{c,t} + \alpha_{i,\varepsilon,t}\varepsilon_{c,t} + \tau_{i,t} + \varepsilon_{i,t}, \quad (6)$$

$$\text{セクター共通トレンド: } \tau_{c,t} = \tau_{c,t-1} + \sigma_{\Delta\tau,c,t} \times \eta_{\tau,c,t}, \quad (7)$$

$$\text{セクター共通一過性成分: } \varepsilon_{c,t} = \sigma_{\varepsilon,c,t} \times s_{c,t} \times \eta_{\varepsilon,c,t}, \quad (8)$$

$$\text{セクター固有トレンド: } \tau_{i,t} = \tau_{i,t-1} + \sigma_{\Delta\tau,i,t} \times \eta_{\tau,i,t}, \quad (9)$$

$$\text{セクター固有一過性成分: } \varepsilon_{i,t} = \sigma_{\varepsilon,i,t} \times s_{i,t} \times \eta_{\varepsilon,i,t}, \quad (10)$$

$$\text{トレンドの因子負荷量: } \alpha_{i,\tau,t} = \alpha_{i,\tau,t-1} + \lambda_{i,\tau}\zeta_{i,\tau,t}, \quad (11)$$

$$\text{一過性成分の因子負荷量: } \alpha_{i,\varepsilon,t} = \alpha_{i,\varepsilon,t-1} + \lambda_{i,\varepsilon}\zeta_{i,\varepsilon,t}. \quad (12)$$

<sup>2</sup>例としては、為替やエネルギー価格のパススルーの程度の変化などが挙げられる。

ただし攪乱項である  $(\eta_{\tau,c,t}, \eta_{\varepsilon,c,t}, \eta_{\tau,i,t}, \eta_{\varepsilon,i,t}, \zeta_{i,\tau,t}, \zeta_{i,\varepsilon,t})$  は *i.i.d.* の標準正規分布に従う。  
SV 項は一変量 UCSVO model と同様に以下のように推移する：

$$\begin{aligned}\Delta \ln (\sigma_{\Delta \tau, c, t}^2) &= \gamma_{\Delta \tau, c} \nu_{\Delta \tau, c, t}, \\ \Delta \ln (\sigma_{\varepsilon, c, t}^2) &= \gamma_{\varepsilon, c} \nu_{\varepsilon, c, t}, \\ \Delta \ln (\sigma_{\Delta \tau, i, t}^2) &= \gamma_{\Delta \tau, i} \nu_{\Delta \tau, i, t}, \\ \Delta \ln (\sigma_{\varepsilon, i, t}^2) &= \gamma_{\varepsilon, i} \nu_{\varepsilon, i, t}.\end{aligned}$$

ただし誤差項である  $(\nu_{\Delta \tau, c, t}, \nu_{\varepsilon, c, t}, \nu_{\Delta \tau, i, t}, \nu_{\varepsilon, i, t},)$  は *i.i.d.* の標準正規分布に従う。

トレンド・インフレの集計には、家計による消費支出のシェア  $w_{it}$  を用いて共通トレンドとセクター別のトレンドを加重和している：

$$\text{aggregate trend} = \tau_t = \sum_{i=1}^n w_{it} (\alpha_{i,\tau,t} \tau_{c,t} + \tau_{i,t}). \quad (13)$$

### 3 データと推定方法

#### 3.1 データ

データは日本の 14 セクターに分類した CPI を用いる。CPI は総務省統計局によって公表されており、本稿の分析に合わせて独自にセクターの分類を変更したものを表 2 に示している。CPI は 10 大費目となっているが、コア・インフレの集計のために、10 大費目の一部をサブグループに分けて集計し直している。具体的には、食品から生鮮食品と酒類を除き、それぞれを独立したセクターに分類している。同様に、光熱・水道を、光熱と上下水道料に分け<sup>3</sup>、交通・通信からガソリンを除き、それぞれ独立したセクターとしている。エネルギーに関しては、コア CPI の計算のために、光熱からエネルギー関連品目（電気代、都市ガス代、プロパンガス、灯油、ガソリン）を別立てにしている。

以上のように分類したセクターを用いて、CPI 総合（CPI-all）と 3 つのコア CPI（コア CPI、コアコア CPI、エネルギーを除く CPI）を独自に集計する。コア CPI（Core）は生鮮食品を除いた CPI 総合である。コアコア CPI（Core2）は食品（アルコール飲料を除く）と

<sup>3</sup> 上下水道料は 1984 年 12 月以前のデータが現在の基準では公表されていないので、品目別の水道料の前年同月比を用いて遡及計算している。

セクター
食品 (生鮮食品、酒類を除く)
生鮮食品
酒類
住居
光熱
上下水道料
家具・家事用品
被服及び履物
保健医療
交通・通信 (ガソリン除く)
ガソリン
教育
教養娯楽
諸雑費
エネルギー (コア CPI の集計にのみ利用)

表 2: セクターの分類

エネルギーを除いた CPI 総合 (xE) である。エネルギーは軽油とガソリンの合計として定義され、コア CPI の集計にのみ利用する。

CPI の原データは月別データになっているが平均を取って四半期データとして集計している。さらに、これらの系列に独自に X11 のデフォルトの季節調整を適用している<sup>4</sup>。

多変量 UCSVO モデルに関しては、表 2 の 14 セクターを使ったモデルと、14 セクターを 3 セクターに集約したモデルの 2 つを検討する。後者に関しては、「コア」、「エネルギー」、「食品」の 3 セクターを考える。コアは、総合指標からエネルギーと食品を除いた全てのセクターを集計したものである。

### 3.2 推定方法

推定方法は SW に従って、Kim et al. (1998) と Omori et al. (2007) によって提案された方法を用いる。彼らの方法は、ベイジアン推定の方法の一つで Markov Chain Monte Carlo (MCMC) の方法を用いるものである。推定に用いるモデルは、SV 項が含まれているため推定にあたっては工夫が必要となる。第 1 に、SV 項は対数カイ二乗分布に従っているため、正規分布を前提とする標準的なカルマン・フィルターでは推計をすることができない。そこで

<sup>4</sup>季節調整には計量ソフトの Gretl の X13-ARIMA-SEATS を用いている。

本稿では対数カイ二乗分布をガウス混合分布（正規分布）によって近似する方法を用いる<sup>5</sup>。

この方法を採用するもう一つのメリットとして、効率的なサンプリングが可能な点が挙げられる。通常のMCMCによる推定では、1回の推計で事後分布からパラメーターを数万回サンプリングし、その平均値を推定されたパラメーターとして用いる。しかし、SVモデルの推定では分散（パラメーター）が時間変動するため、 $t$ 期毎にサンプリングが必要となってくる。サンプリング総数は、時系列のサンプルサイズ  $\times$  1期毎のサンプリング回数となる。長期時系列データを用いる場合、計算時間が莫大に増加するため、効率的なサンプリング方法を用いる必要がある。Kim et al. (1998) が提案した方法では、非正規分布を混合正規分布で近似することで、標準的な線形状態空間モデルで扱うことを可能となり、サンプリング回数を通常のベイジアン推定のように一度のサンプリングでパラメーター推定を可能としている。

事前分布の設定に関しては表 3 と表 4 でまとめている。これらの設定は SW に従っている。サンプリングの詳細な説明は SW の Appendix を参照のこと。

表 3: 一変量 UCSVO モデルの事前分布

	分布	設定
$\gamma_\varepsilon$	一様	下限 = 0, 上限 = 0.2
$\gamma_{\Delta\tau}$	一様	下限 = 0, 上限 = 0.2
$p$	ベータ	$\alpha = 2.5, \beta = -1.5$
$\tau_0$	正規	平均 = 0, 標準偏差 = $10^6$
$\ln(\sigma_{\varepsilon,0})$	正規	平均 = 0, 標準偏差 = $10^6$
$\ln(\sigma_{\Delta\tau,0})$	正規	平均 = 0, 標準偏差 = $10^6$

<sup>5</sup>混合正規分布による近似に関しては、例えば Bishop (2006) を参照。

表 4: 多変量 UCSVO モデルの事前分布

	分布	設定
$\gamma_{\varepsilon,c}$	一様	下限 = 0, 上限 = 0.2
$\gamma_{\varepsilon,i}$	一様	下限 = 0, 上限 = 0.2
$\gamma_{\Delta\tau,c}$	一様	下限 = 0, 上限 = 0.2
$\gamma_{\Delta\tau,i}$	一様	下限 = 0, 上限 = 0.2
$p_c$	ベータ	$\alpha = 2.5, \beta = -1.5$
$p_i$	ベータ	$\alpha = 2.5, \beta = -1.5$
$\ln(\sigma_{\varepsilon,i,0})$	正規	平均 = 0, 標準偏差 = $10^6$
$\ln(\sigma_{\Delta\tau,i,0})$	正規	平均 = 0, 標準偏差 = $10^6$
$\alpha_{\Delta\tau,0}$	正規	平均 = 0, 標準偏差 = $\kappa_1^2 ll' + \kappa_2^2 I_n$
$\alpha_{\Delta\varepsilon,0}$	正規	平均 = 0, 標準偏差 = $\kappa_1^2 ll' + \kappa_2^2 I_n$
$\lambda$	逆ガンマ	形状 = $T/10$ , 尺度 = $0.0625 \times 10/T$

(注)  $l$  はすべての要素が 1 の  $n \times 1$  のベクトル、 $\kappa_1 = 10$ ,  $\kappa_2 = 0.4$ ,  $T$  はサンプルサイズである

## 4 推定結果

この節では、2 節のモデルに基づいて推定したトレンド・インフレの事後分布の結果と予測精度を評価する。尚、推定されたパラメーターの数量的な評価は関心事ではないため付録 A にまとめて掲載している。

### 4.1 単変量 UCSVO モデルの推定結果

図 1 は CPI の総合指数、エネルギーを除く CPI 総合、コアコア CPI、コア CPI といった 3 つのコア指標のインフレ率と、それらを観察データとして一変量 UCSVO モデルを用いて推定されたトレンド・インフレを示している。推計されたトレンド・インフレの動きはインフレ率よりも滑らかな動きを示している。コアコア CPI やコア CPI によるインフレ率と推定されたトレンド・インフレに近い動きをしていることがわかる。

図 1: データと推定されたトレンド・インフレ

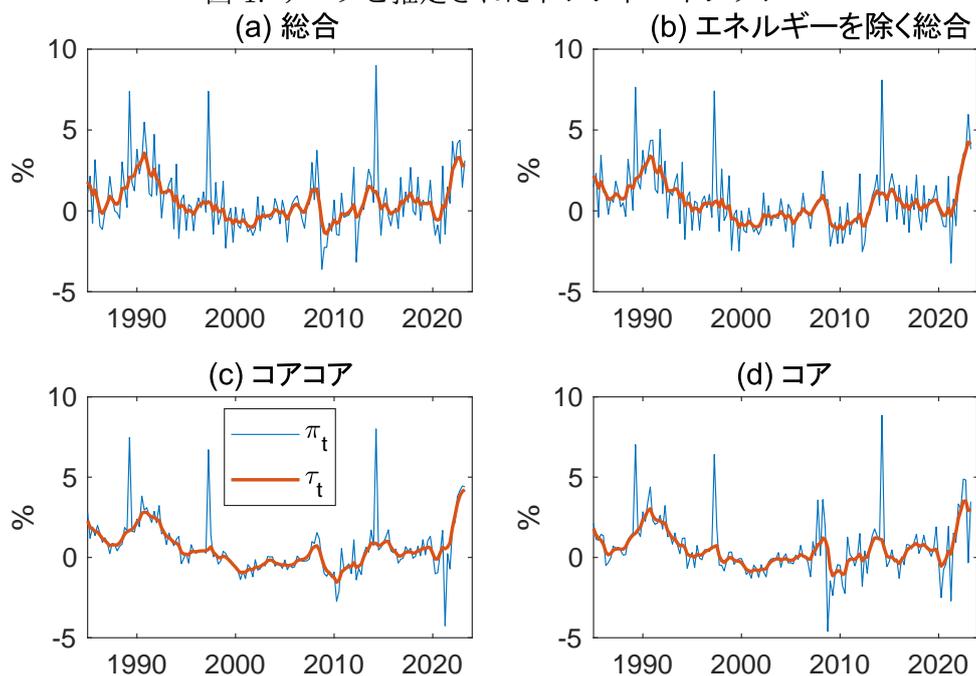


図 2: 一変量 UCSVO モデル: すべてのサンプルを用いて推定した事後分布の平均

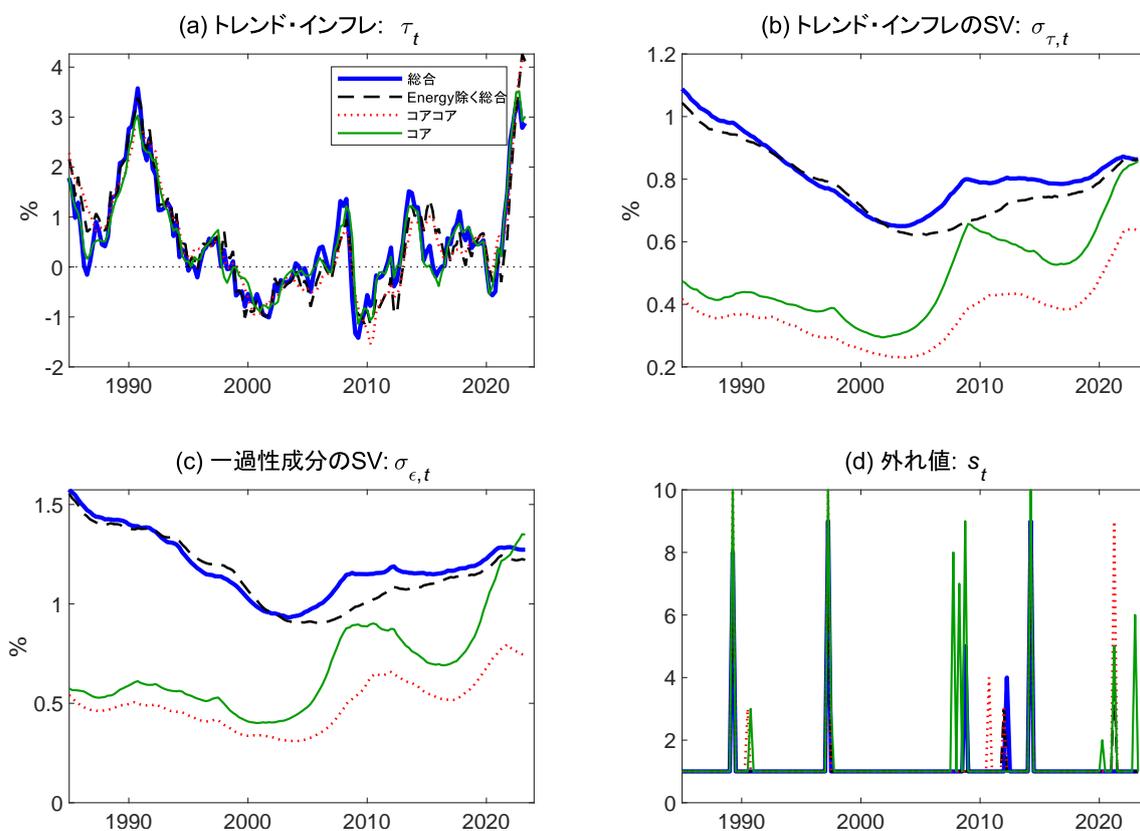


図 2 (a) は図 1 のトレンド・インフレを 1 つの図でまとめ比較したものである。これらのトレンド・インフレの動きは、2000 年代前半までは概ね類似しており、2000 年代後半からその差が大きくなっている。さらに、トレンド・インフレは 1990 年代前半までプラスで推移し、1998 年頃からマイナスに転じた。その後、2010 年代には再びプラスに転じている。長期的には、トレンド・インフレは低下傾向を示していたが、2020 年以降急激に上昇しており、物価高騰は一過性成分ではなくトレンド・インフレの上昇に依るものであることがわかる。図 2 (b) と図 2 (c) が示すように、2000 年中盤頃までのトレンド・インフレの低下傾向は、 $\sigma_{\tau,t}$  と  $\sigma_{\varepsilon,t}$  の減少に依るものと考えられる。また、図 2 (d) に見られるように、1989 年 4 月、1997 年 4 月、2014 年 4 月には、消費税の増税を外れ値として捉えている。

#### 4.2 多変量 UCSVO モデルの推定結果

本節ではセクター別のインフレ率を用いて多変量モデルによって推計した結果を示す。トレンド・インフレを 14 セクター別に推計し、消費支出をウェイトとして加重和して集計トレンド・インフレを求めている。図 3 は総合指数を用いて単変量 UCSVO モデルで推定したトレンド・インフレと 14 セクター多変量 UCSVO (MUCSVO) モデルのトレンド・インフレを比較したものである。80 年代から 2010 年半ば頃までは両者の差はあまりないが、1970 年代や 2010 年半ば以降は両者の乖離が大きくなっている。図 3 (b) は共通成分のトレンドの SV に関して、(c) は一過性成分の SV に関して平均と 67%信用区間を表示している。どちらの SV も 2000 年代中頃から分散が上昇傾向にあることが分かる。また近年ではその信用区間が広がっていることが分かる。一変量モデルでも 2000 年代半ばから SV は上昇傾向にあるのは共通した傾向であると言える。

図 3: 14 セクター多変量 UCSVO モデルの推定結果

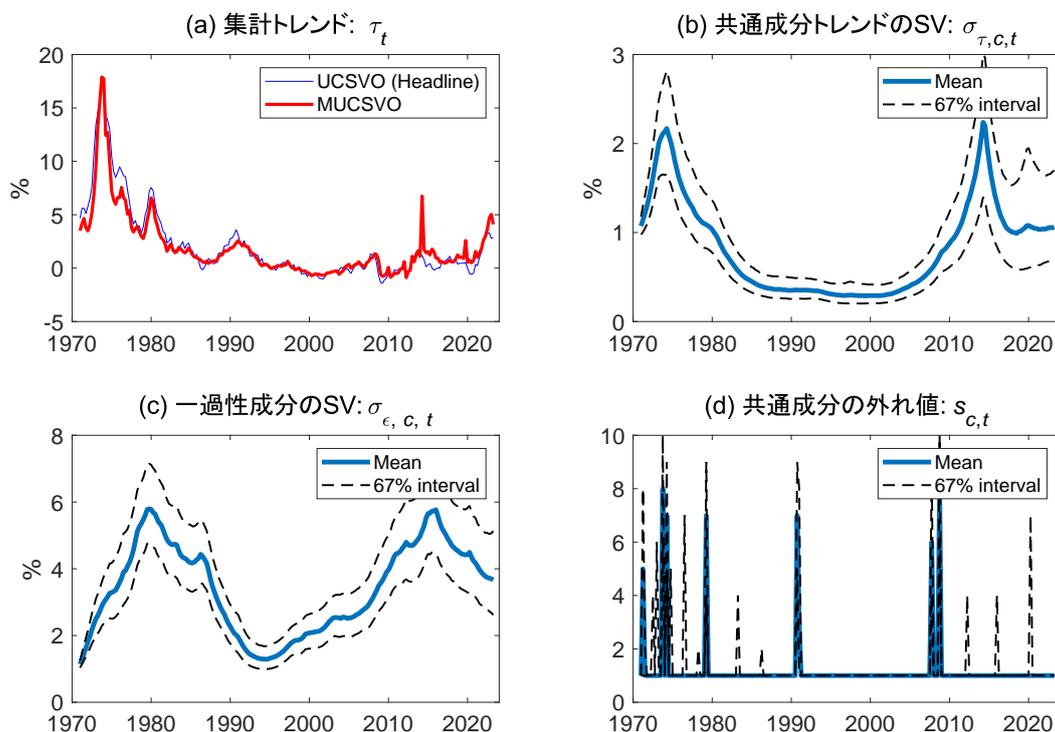


図 4 は MUCSVO モデルで推定された集計トレンドをセクター別に要因分解したものである。期間全体を通じてみると、食料の占める割合が目立つことが分かる。また、教養娯楽も寄与が大きく、特に物価の下落期間におけるマイナスの寄与が大きい。教養娯楽には、テレビ、ビデオ、パソコン、カメラなどの耐久財が含まれており、これらは技術進歩による価格下落が寄与しているものと考えられる。また、2020 年以降の物価上昇においては、教養娯楽はプラスに寄与しており、半導体価格の上昇に伴って耐久財の価格が上昇していることから、トレンド・インフレにも影響していると考えられる。一方、光熱やガソリンなどのエネルギー価格は上昇しているものの、トレンド・インフレに対する寄与は大きくなっていない。2014 年のスパイクは、消費税増税に関して MUCSVO モデルの外れ値が十分、捉え切れていない可能性がある。

図 4: セクター別トレンドの集計トレンドへの寄与

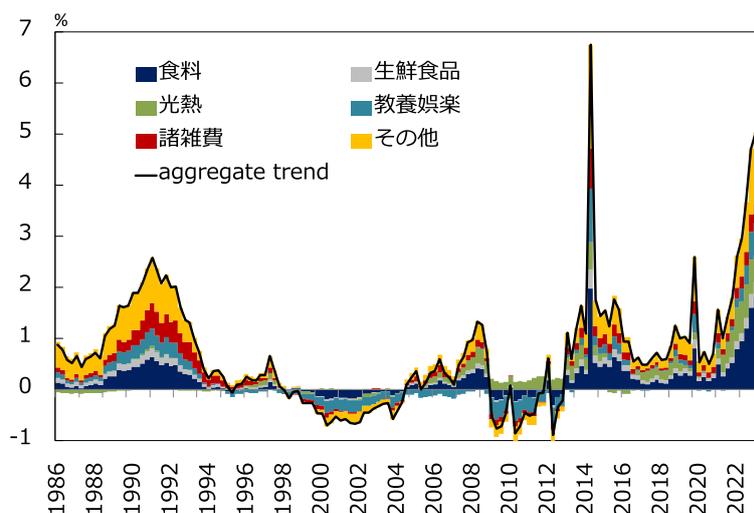
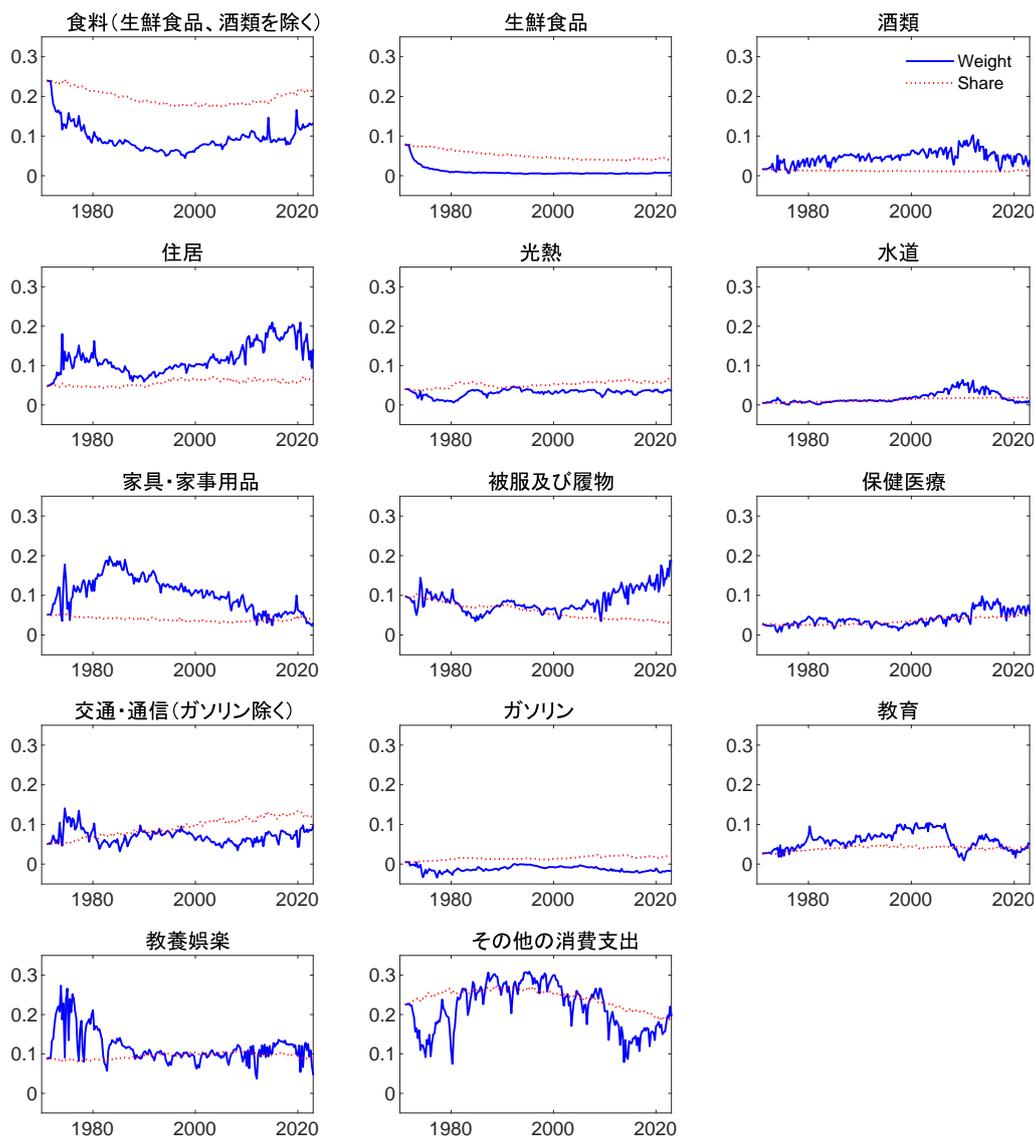


図 5 はカルマン・フィルターのフィルタリングによって求めた各セクターの近似ウェートを表示したものである。モデルでは線形かつ正規分布を仮定しているため、トレンド・インフレは各セクターのインフレ率の現在値及びそのラグの加重和として表現することができる。そのウェートを近似計算によって求めたものである。計算方法の詳細は付録 B に記載している。具体的には、各セクターのインフレ系列の現在値と最初の 3 つのラグ値に対するウェートの平均である。MUCSVO の近似ウェートと支出シェアと比較すると、ある時期においてあるセクターが集計トレンドに対して支出シェアよりも高いウェートを得ているのか、低いウェートを得ているのかがわかる。

図 5 を見ると概ね半数ほどのセクターで支出シェアと近似ウェートは同じような水準で推移していることが分かる。似たような水準となっているのは、光熱、水道、保険医療、交通・通信（ガソリンを除く）、教育、教養娯楽である。ガソリンは、シェアがマイナスとなっているものの水準としては近い動きをしている。乖離が目立つセクターとしては、食料（生鮮食品、酒類を除く）、生鮮食品、住居、家具・家事用品、その他の支出シェアである。被服及び履物も 2000 年以降は乖離が広がっている。食料に関しては支出に対して大きくウェートを下回っている。反対に住居、家事・家具用品は大きく上回っていたが、2020 年頃は両者ともに乖離が狭まっている。

図 6 は単変量モデルと 14 セクター多変量モデルから得られたトレンド・インフレに関する事後分布の 90 % 信用区間をプロットしたものである。これらのパネルは、推定されたト

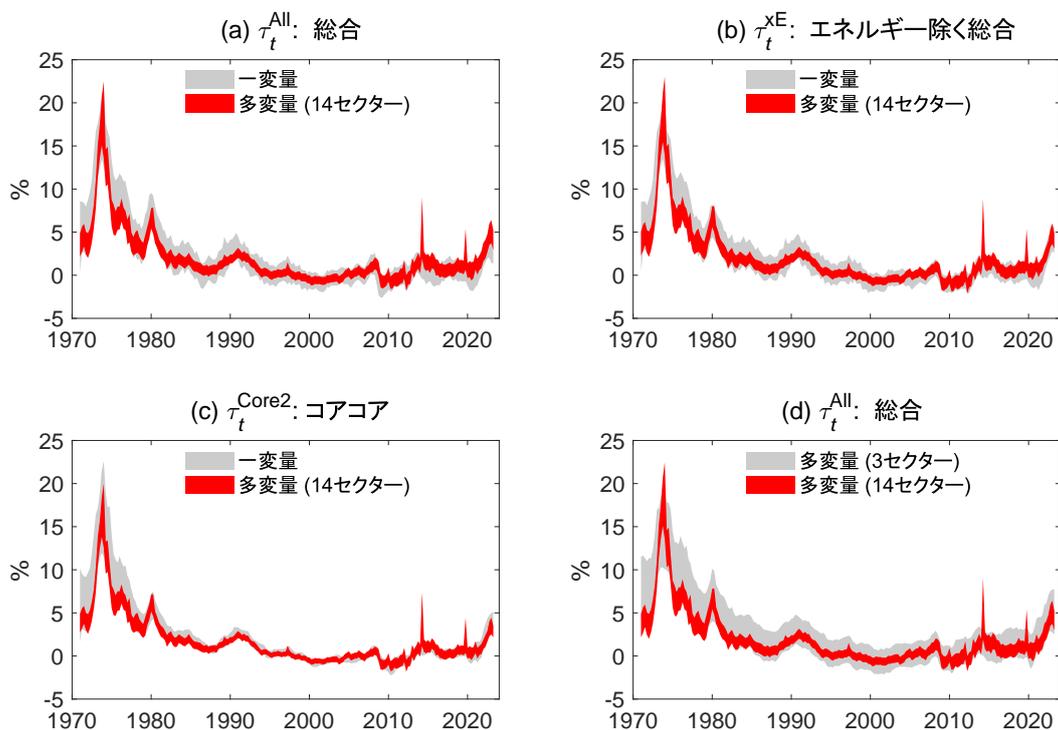
図 5: 17セクター MUCSVO モデルで推定されたトレンドの近似ウェイトと支出シェア



トレンド・インフレ、推定モデル、推定されたパラメーターの不確実性の測定値を示している。結果を見ると、14セクター多変量モデルは、一変量モデルや3セクター多変量モデルよりも信用区間が狭い。これは、クロスセクション情報が不確実性を低減するのに有効であることを示唆している。一方で、3セクター多変量モデルは、一変量モデルや14セクター多変量モデルと比べても、信用区間の幅が広い結果となっている。これはクロスセクションの情報による不確実性低下効果よりも、モデルが複雑になることに伴う不確実性増加効果の方が大きくマイナスに寄与していると解釈できる。

ここまでの結果は、全標本を用いて推定した事後分布のパラメーターの中央値の評価となっている。図7は、1990年第1四半期から $t$ 期までをサンプル期間としたトレンド・イ

図 6: トレンド・インフレの事後分布 (全標本) の 90%信用区間: 各モデルの比較

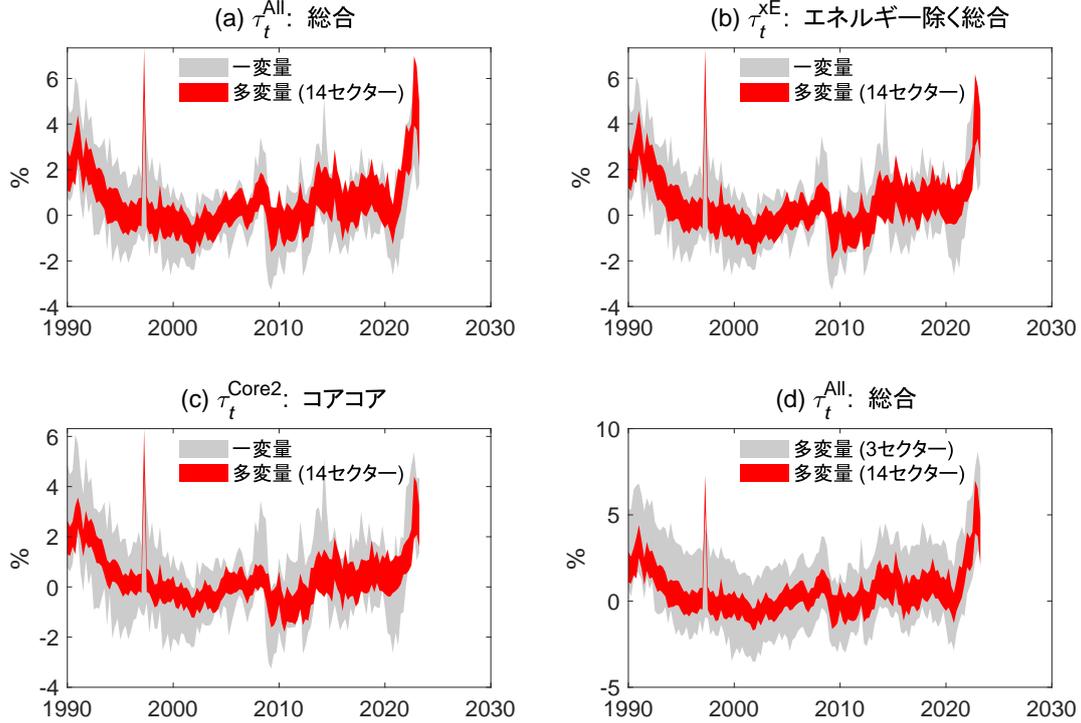


ンフレの 90%片側事後区間である。片側推定は、 $t$  期間までの情報を用いてパラメーターとトレンド・インフレを推定したものである。この推定は、現在のトレンド・インフレの精度を知りたい中央銀行や政策立案者が直面するリアルタイム推定と見ることができる。その結果、図 6 とほぼ同様の結果が得られ、14 セクター多変量モデルの不確実性は他のモデルよりも小さいことがわかる。

#### 4.3 トレンド・インフレの予測精度

次に、将来のインフレ率が推定されたトレンド・インフレによってどの程度説明できるかについて予測精度を評価する。トレンド・インフレはもともと低頻度のインフレの動きとして抽出されたものであり、中長期的なインフレ期待の情報を含んでいる。トレンド・インフ

図 7: 一変量及び多変量モデルによるトレンド・インフレの 90%片側事後分布の信用区間



レの予測精度は、平均二乗予測誤差 (MSFE) を用いて測定する:

$$MSFE_t = T^{-1} \sum_t^T FE_t^2,$$

$$FE_t = \tau_{t|t} - \bar{\pi}_{t+1:t+h}^{All},$$

$$\bar{\pi}_{t+1:t+h}^{All} = h^{-1} \sum_{i=1}^h \pi_{t+i}^{All}, \quad h = 4, 8, \text{ and } 12.$$

ただし  $T$  はサンプルサイズ、 $FE_t$  は予測誤差、 $\tau_{t|t}$  は  $t$  期に  $t$  期までの情報を用いて推定された片側事後トレンド・インフレ、 $\bar{\pi}_{t+1:t+h}^{All}$  は  $t+1$  期から  $t+h$  期までの CPI 総合のインフレ率の観測平均値、 $h$  は予測期間を表す。予測期間は先行研究に倣い、4 四半期、8 四半期、12 四半期先のインフレ率の平均値の予測を評価する。ここで例を 1 つ挙げる。 $t$  期を 2000 年第 4 四半期とする。そのときのトレンド・インフレは、90 年第 1 四半期から 2000 年第 4 四半期までのデータを使ってパラメーターを推計し、トレンド・インフレを計測する。そして 2 年間のインフレの予測精度を測る場合は、2001 年第 1 四半期から 2002 年第 4 四半期までの 8 四半期の平均インフレ率を予測できるかを測る。予測誤差は  $h$  期までに利用可能であったデータのみに基づいて計算される。各指標の予測の平均二乗誤差はデータが追加されるごとに逐次的に予測誤差を計算し、最後に平均二乗誤差を求めるといった計算になっている。

表5は平均二乗誤差の計測結果を示している。モデルを使った予測と、実績値を用いた予測ではどちらが優れているかを比較する。サンプルは、1990年第1四半期から $t$ 期までとなり、それぞれのサンプル期間に基づいて予測誤差を計算し、サンプル期間末までの平均二乗誤差を計算している。一番上段の多変量モデルについては、14セクターモデル、3セクターモデルの2つのモデルに対して、時変因子負荷量 $\alpha_t$ と固定因子負荷量 $\alpha$ の両方を考慮する。因子負荷量はモデル上で時間変動を許しているが、比較のために因子負荷量を一定値で固定化したモデルも検討する。2段目の一変量UCSVOモデルを用いた予測では、CPI総合、エネルギーを除く総合、コアコアCPI、コアCPIを用いて推定したトレンド・インフレに基づく予測誤差を示している。3段目、4段目に関しては、インフレ率の現在値の予測精度と、インフレ率の4四半期後方平均の予測誤差である。これらのインフレ率は実績値であり、現在のインフレ率が将来のインフレ率をどの程度予測できるかを見る。結果は大きく分けて3つに分かれており、4四半期（1年）先予測、8四半期（2年）先予測、12四半期（3年）先予測となっている。それぞれの予測に関する予測誤差と、予測誤差の差を表している。予測誤差の差は、固定因子負荷量を仮定した14セクターMUCSVOモデルのMSFEを基準としてその差を表している。

この表を見比べると、4四半期先の予測に関して、最も予測パフォーマンスが良いのは、固定因子負荷量を仮定した14セクターMUCSVOモデルであることが分かる。次にパフォーマンスが良いのが、コアCPIで推定した一変量モデルで、MSFEが2番目に小さい結果となっている。一方3セクターMUCSVOは、予測パフォーマンスがコア指標を用いた一変量モデルよりもパフォーマンスが悪い結果となっている。

8四半期先予測と12四半期先予測でも同様に、固定因子負荷量を仮定した14セクターMUCSVOモデルが最もパフォーマンスが良い結果となっている。いずれのモデルも時間変動を認めた因子負荷量モデルよりも、固定因子負荷量のモデルの方がMSFEが小さくなっており、時間変動である必要性に関しては疑問が残る結果となっている。また、実績値のインフレ率を使った予測（モデルを使わず純粋なデータが持っている将来予測の情報）を見ると、後方4四半期平均のインフレ率の方が現在のインフレ率のみを使った予測よりも予測誤差が小さい。またコア指標を用いた後方4四半期平均のインフレ率と、3セクターMUCSVOモデルではMSFEにほとんど差がない結果となった。

総じて結果を見ると、因子負荷量を固定した14セクターMUCSVOモデルが最もMSFE

が改善するという結果になっている。モデルが簡単な一変量モデルにおいてもコア指標を用いた推定では、他の多変量モデルと比べても予測パフォーマンスが優れていることが分かる。以上のように、クロスセクションの情報の利用は予測誤差を小さくすることに貢献することを示している。

表 5: 平均二乗予測誤差

	4 四半期先予測		8 四半期先予測		12 四半期先予測	
	MSFE	差	MSFE	差	MSFE	差
MUCSVO モデルの予測						
14c( $\alpha$ )	1.04(0.24)	0.00(0.00)	0.82(0.19)	0.00(0.00)	0.63(0.13)	0.00(0.00)
3c( $\alpha$ )	1.51(0.29)	0.47(0.19)	1.41(0.31)	0.60(0.22)	1.32(0.37)	0.69(0.28)
14c( $\alpha_t$ )	1.38(0.40)	0.34(0.29)	1.20(0.35)	0.38(0.31)	1.02(0.32)	0.40(0.33)
3c( $\alpha_t$ )	1.49(0.29)	0.46(0.18)	1.39(0.30)	0.58(0.21)	1.30(0.35)	0.67(0.25)
1 変量 UCSVO モデルの予測						
All	1.50(0.34)	0.46(0.17)	1.35(0.33)	0.53(0.16)	1.11(0.22)	0.48(0.11)
xE	1.77(0.40)	0.73(0.27)	1.38(0.33)	0.56(0.18)	1.13(0.26)	0.51(0.16)
Core2	1.45(0.35)	0.41(0.20)	1.10(0.27)	0.28(0.13)	0.92(0.26)	0.29(0.16)
Core	1.21(0.30)	0.18(0.15)	1.06(0.26)	0.25(0.11)	0.82(0.18)	0.20(0.06)
インフレ率の現在値を使った予測						
All	3.46(0.74)	2.42(0.62)	3.54(0.81)	2.72(0.71)	3.33(0.73)	2.71(0.70)
xE	3.65(0.73)	2.61(0.63)	3.43(0.77)	2.61(0.68)	3.08(0.69)	2.46(0.67)
Core2	2.62(0.76)	1.58(0.64)	2.45(0.75)	1.63(0.64)	1.98(0.59)	1.36(0.57)
Core	2.59(0.75)	1.55(0.60)	2.80(0.81)	1.99(0.69)	2.55(0.70)	1.93(0.66)
インフレ率の後方 4 四半期の実績値を使った予測						
All	1.79(0.42)	0.75(0.24)	1.66(0.40)	0.84(0.27)	1.40(0.29)	0.78(0.24)
xE	2.05(0.49)	1.01(0.36)	1.63(0.39)	0.82(0.28)	1.40(0.32)	0.78(0.27)
Core2	1.98(0.53)	0.94(0.41)	1.53(0.36)	0.71(0.25)	1.27(0.30)	0.64(0.24)
Core	1.72(0.44)	0.69(0.27)	1.59(0.38)	0.78(0.26)	1.30(0.28)	0.68(0.22)

(注) サンプル期間は、1990 年第 1 四半期から  $t$  期までで、それぞれの推定期間に基づいて予測誤差を計算する。推定や予測誤差の計算に際して、サンプル期間を逐次増やしてサンプル期間末まで計算している。MSFE は平均二乗予測誤差、差は固定因子負荷量を仮定した 14 セクター MUCSVO 予測 (14c( $\alpha$ )) の MSFE とその行の MSFE との差である。All は CPI 総合、xE: エネルギーを除く CPI 総合、Core2: 食品 (アルコール飲料を除く)・エネルギーを除く CPI 総合、Core: 生鮮食品を除く CPI 総合である。括弧内の数値は標準誤差の HAC (Heteroskedasticity Autocorrelation Consistent) 推定値を表す。 $(\alpha_t)$  とラベル付けされたモデルは、時変因子負荷量を仮定している。 $(\alpha)$  と表示されたモデルは、固定因子負荷量を仮定している。

## 5 まとめ

本稿では、トレンド・インフレを観測不可能成分として SW が開発した動学的ファクターモデルの 1 種である UCSVO モデルを用いて推定をした。推定に用いたモデルは一変量モデルと多変量モデルの二つである。一変量モデルでは、総合指標と 3 つのコア指標をそれぞれ用いてトレンド・インフレを推定した。多変量モデルでは、セクター別のインフレ率をパネルデータ化して推定に用いている。いずれのモデルにおいても、クロスセクション情報がトレンド・インフレの不確実性や予測精度を改善するかどうかを検討した。

推定されたトレンド・インフレの推移を見ると、2020 年以降のインフレ率の上昇は、一過性ではなく、トレンド・インフレの上昇によるものであることが分かった。セクター別に見ると、食料、教養娯楽セクターのトレンド・インフレの上昇が大きく寄与している。

また UCSVO モデルを用いて推定したトレンド・インフレと、コア指標の予測精度の比較を行った。コア CPI やコアコア CPI は代表的なコア指標であり、トレンド・インフレの代理指標として広く利用されている。分析の結果、因子負荷量を固定化した 14 セクター別の多変量 UCSVO モデルが最も予測精度が高く、このモデルを用いるとトレンド・インフレの不確実性が減少し、予測精度のパフォーマンスが改善することがわかった。因子負荷量を固定化せず、時間変動することを許したモデルは予測精度が悪化し、コア指標を用いて推定した一変量モデルのトレンド・インフレの方が予測精度が優れた結果となった。コア指標とモデルによって推定されるトレンド・インフレを比較すると、モデルを用いたトレンド・インフレの方が予測精度が高い結果となった。コア指標の中では、コアコア CPI が予測精度が優れていることが分かった。

最後に本稿の残された課題を整理する。第 1 に、単位根の問題である。本稿のモデルは、インフレ率は  $I(0)$  を前提としている。1 階の階差によって定常過程になるとき、1 次の和分過程であるとして  $I(1)$  過程と表現される。階差を取らずに定常過程に従っているときには  $I(0)$  と表現される。単位根検定の方法や時期によって、インフレ率は  $I(0)$  過程なのか  $I(1)$  過程なのか結果が変わってくるため議論となっている。長期的な系列では  $I(1)$  過程となることも考えられ、こうした問題を考慮したモデルを開発し推定することが求められる。

第 2 に、インフレ率のみのデータを用いて推定することが妥当であるかの検討である。本稿の推定モデルは誘導型のモデルであり、インフレ率のみを推定に用いている。構造型のモデルや VAR (Vector Autoregression) モデルを用いた推定では、インフレ率以外の変数を

含めて推定を行っている。例えば金融政策とインフレ率の關係に主眼にするのであれば、金利などの政策変数をデータに含めて推定する。少なくとも米国のデータを用いた推定では、他の変数を加えてもインフレ率の予測力の改善はごくわずかであることが知られているが、本来であれば日本においてもインフレ率のみのデータを用いた推定が妥当であるかの検証が必要である。

## 参考文献

- Ascari, Guido and Argia M. Sbordone (2014) “The Macroeconomics of Trend Inflation,” *Journal of Economic Literature*, Vol. 52, No. 3, pp. 679–739, September, DOI: [10.1257/jel.52.3.679](https://doi.org/10.1257/jel.52.3.679).
- Bishop, Christopher M. (2006) *Pattern Recognition and Machine Learning*, New York: Springer.
- Clark, Todd E. and Taeyoung Doh (2011) “A Bayesian Evaluation of Alternative Models of Trend Inflation,” Working Paper 1134, Federal Reserve Bank of Cleveland.
- Cogley, Timothy and Thomas J. Sargent (2002) “Evolving Post-World War II U.S. Inflation Dynamics,” in Bernanke, Ben S. and Kenneth Rogoff eds. *NBER Macroeconomics Annual 2001*, Vol. 16: National Bureau of Economic Research, Inc, pp. 331–388.
- (2005) “Drift and Volatilities: Monetary Policies and Outcomes in the Post WWII U.S.,” *Review of Economic Dynamics*, Vol. 8, No. 2, pp. 262–302, April, DOI: [10.1016/j.red.2004.10.009](https://doi.org/10.1016/j.red.2004.10.009).
- Cogley, Timothy and Argia M. Sbordone (2008) “Trend Inflation, Indexation, and Inflation Persistence in the New Keynesian Phillips Curve,” *American Economic Review*, Vol. 98, No. 5, pp. 2101–2126, December, DOI: [10.1257/aer.98.5.2101](https://doi.org/10.1257/aer.98.5.2101).
- Cogley, Timothy, Giorgio E. Primiceri, and Thomas J. Sargent (2010) “Inflation-Gap Persistence in the US,” *American Economic Journal: Macroeconomics*, Vol. 2, No. 1, pp. 43–69, January, DOI: [10.1257/mac.2.1.43](https://doi.org/10.1257/mac.2.1.43).

- Del Negro, Marco and Christopher Otrok (2008) “Dynamic Factor Models with Time-varying Parameters: Measuring Changes in International Business Cycles,” Staff Reports 326, Federal Reserve Bank of New York.
- Durbin, James and Siem Jan Koopman (2012) *Time Series Analysis by State Space Methods: Second Edition*: Oxford University Press.
- Faust, Jon and Jonathan H. Wright (2013) “Forecasting Inflation,” in Elliott, Graham and Allan Timmermann eds. *Handbook of Economic Forecasting*, Vol. 2A, Amsterdam: Elsevier, Chap. 1, pp. 2–56.
- Galí, Jordi and Mark Gertler (1999) “Inflation Dynamics: A Structural Econometric Analysis,” *Journal of Monetary Economics*, Vol. 44, No. 2, pp. 195–222, DOI: [10.1016/S0304-3932\(99\)00023-9](https://doi.org/10.1016/S0304-3932(99)00023-9).
- Garnier, Christine, Elmar Mertens, and Edward Nelson (2015) “Trend Inflation in Advanced Economies,” *International Journal of Central Banking*, Vol. 11, No. 4, pp. 65–136, September.
- Gemma, Yasufumi, Takushi Kurozumi, and Mototsugu Shintani (2023) “Trend Inflation and Evolving Inflation Dynamics: A Bayesian GMM Analysis,” *Review of Economic Dynamics*, DOI: [10.1016/j.red.2023.05.003](https://doi.org/10.1016/j.red.2023.05.003), forthcoming.
- Harvey, Andrew C. (1989) *Forecasting, Structural Time Series Models and the Kalman Filter*, New York: Cambridge University Press.
- Hirose, Yasuo, Takushi Kurozumi, and Willem Van Zandweghe (2020) “Monetary Policy and Macroeconomic Stability Revisited,” *Review of Economic Dynamics*, Vol. 37, pp. 255–274, DOI: [10.1016/j.red.2020.03.001](https://doi.org/10.1016/j.red.2020.03.001).
- Inoue, Atsushi and Mototsugu Shintani (2018) “Quasi-Bayesian Model Selection,” *Quantitative Economics*, Vol. 9, No. 3, pp. 1265–1297, November, DOI: [10.3982/QE587](https://doi.org/10.3982/QE587).
- Kaihatsu, Sohei and Jouchi Nakajima (2018) “Has Trend Inflation Shifted?: An Empirical

- Analysis with an Equally-spaced Regime-switching Model,” *Economic Analysis and Policy*, Vol. 59, No. C, pp. 69–83, DOI: [10.1016/j.eap.2018.04.003](https://doi.org/10.1016/j.eap.2018.04.003).
- Kiley, Michael T. (2008) “Estimating the Common Trend Rate of Inflation for Consumer Prices and Consumer Prices Excluding Food and Energy Prices,” Finance and Economics Discussion Series 2008-38, Board of Governors of the Federal Reserve System (U.S.).
- Kim, Chang-Jin, Pym Manopimoke, and Charles R. Nelson (2014) “Trend Inflation and the Nature of Structural Breaks in the New Keynesian Phillips Curve,” *Journal of Money, Credit and Banking*, Vol. 46, No. 2-3, pp. 253–266, March, DOI: [10.1111/jmcb.12105](https://doi.org/10.1111/jmcb.12105).
- Kim, Sangjoon, Neil Shephard, and Siddhartha Chib (1998) “Stochastic Volatility: Likelihood Inference and Comparison with ARCH Models,” *Review of Economic Studies*, Vol. 65, No. 3, pp. 361–393, July.
- Okimoto, Tatsuyoshi (2019) “Trend Inflation and Monetary Policy Regimes in Japan,” *Journal of International Money and Finance*, Vol. 92, pp. 137–152, DOI: [10.1016/j.jimonfin.2018.12.008](https://doi.org/10.1016/j.jimonfin.2018.12.008).
- Omori, Yasuhiro, Siddhartha Chib, Neil Shephard, and Jouchi Nakajima (2007) “Stochastic Volatility with Leverage: Fast and Efficient Likelihood Inference,” *Journal of Econometrics*, Vol. 140, No. 2, pp. 425–449, October, DOI: [10.1016/j.jeconom.2006.07.008](https://doi.org/10.1016/j.jeconom.2006.07.008).
- Sekine, Toshitaka, Frank Packer, and Shunichi Yoneyama (2022) “Individual Trend Inflation,” IMES Discussion Paper Series 22-E-14, Institute for Monetary and Economic Studies, Bank of Japan.
- Stock, James H. and Mark W. Watson (2007) “Why Has U.S. Inflation Become Harder to Forecast?,” *Journal of Money, Credit and Banking*, Vol. 39, No. s1, pp. 3–33, February, DOI: [10.1111/j.1538-4616.2007.00014.x](https://doi.org/10.1111/j.1538-4616.2007.00014.x).
- (2016) “Core Inflation and Trend Inflation,” *The Review of Economics and Statistics*, Vol. 98, No. 4, pp. 770–784, October, DOI: [10.1162/REST\\_a\\_00608](https://doi.org/10.1162/REST_a_00608).

岩崎雄斗・開発壮平 (2016) 「動的モデル平均化法による基調的物価変動の分析」, 日本銀行ワーキングペーパーシリーズ 16-J-5, 日本銀行.

大石凌平・黒住卓司 (2022) 「ベイジアン VAR-GMM によるニューケインジアン・フィリップス曲線の日米比較」, 日本銀行ワーキングペーパーシリーズ 22-J-8, 日本銀行.

川本卓司・中浜萌・法眼吉彦 (2015) 「消費者物価コア指標とその特性—景気変動との関係を中心に」, 日銀レビュー 2015-J-11, 日本銀行.

柴本昌彦 (2023) 「日本のトレンドインフレの計測：共和分アプローチ」, 『国民経済雑誌』, 第 227 巻, 第 5 号, 123–137 頁, 9 月.

白塚重典 (1997) 「物価の基調的な変動を捕捉するための指数の構築とその含意」, 『金融研究』, 第 16 巻, 第 3 号, 1–32 頁, 9 月.

—— (2006) 「消費者物価指数のコア指標」, 『日銀レビュー』, 第 2006-J-7 号, 4 月.

—— (2015) 「消費者物価コア指標のパフォーマンスについて」, 『日銀レビュー』, 第 2015-J-12 号, 11 月.

高橋耕史 (2016) 「トレンド・インフレ率の新推計」, 日本銀行ワーキングペーパーシリーズ 16-J-12, 日本銀行.

三尾仁志・肥後雅博 (1999) 「刈り込み平均指数を利用した基調的物価変動の分析」, 『金融研究』, 第 18 巻, 第 1 号, 105–146 頁, 3 月.

## A パラメーターの推定結果

ここでは、UCSVO モデル及び、17 セクター MUCSVO モデルの推定結果を示す。誘導型のモデルであるため、パラメーターの大きさ自身は関心事ではないため解釈の記述は省略する。

表 6:  $\gamma_\varepsilon$  と  $\gamma_{\Delta\tau}$  の事後分布

値	事前確率	事後確率							
		$\gamma_\varepsilon$				$\gamma_{\Delta\tau}$			
		all	xE	コアコア	コア	all	xE	コアコア	コア
0	0.2	0	0	0	0	0	0	0	0
0.05	0.2	0.11	0	0.1	0	0.02	0	0.02	0
0.1	0.2	0.47	0	0.48	0	0.42	0	0.44	0
0.15	0.2	0.3	0.15	0.3	0.13	0.4	0.14	0.4	0.14
0.2	0.2	0.12	0.85	0.11	0.87	0.16	0.86	0.15	0.86

(注) All: CPI 総合、xE: エネルギーを除く CPI 総合、コアコア: 食品（アルコール飲料を除く）・エネルギーを除く CPI 総合、コア: 生鮮食品を除く CPI 総合

表 7:  $p$  の事後分布

四分位	All	xE	コアコア	コア
0.16	0.03	0.04	0.03	0.05
0.50	0.04	0.05	0.04	0.07
0.67	0.06	0.08	0.06	0.10

(注) All: CPI 総合、xE: エネルギーを除く CPI 総合、コアコア: 食品（アルコール飲料を除く）・エネルギーを除く CPI 総合、コア: 生鮮食品を除く CPI 総合

表 8:  $\gamma_{\Delta\tau,c}$  と  $\gamma_{\varepsilon,c}$  の事後分布

値	事前確率	Posterior Prob.	
		$\gamma_{\Delta\tau,c}$	$\gamma_{\varepsilon,c}$
0.0010	0.20	0.00	0.00
0.05	0.20	0.00	0.00
0.10	0.20	0.00	0.00
0.15	0.20	0.01	0.01
0.20	0.20	0.99	0.99

表 9:  $p_c$  の事後分布

16%	50%	67%
0.053	0.074	0.101

表 10:  $\gamma_{\Delta\tau,i}$  の事後分布

$\gamma_{\tau,i}$ の値	0.00	0.05	0.10	0.15	0.20
	事前確率				
	0.20	0.20	0.20	0.20	0.20
セクター	事後確率				
食料（生鮮食品、酒類を除く）	0.36	0.28	0.19	0.10	0.06
生鮮食品	0.27	0.27	0.21	0.15	0.10
酒類	0.30	0.27	0.22	0.13	0.08
住居	0.01	0.09	0.36	0.33	0.21
光熱	0.11	0.11	0.14	0.23	0.41
水道	0.22	0.21	0.22	0.19	0.16
家具・家事用品	0.25	0.25	0.22	0.17	0.12
被服及び履物	0.10	0.16	0.24	0.27	0.23
保健医療	0.36	0.30	0.19	0.09	0.05
交通・通信（ガソリン除く）	0.39	0.29	0.17	0.09	0.05
ガソリン	0.25	0.23	0.20	0.18	0.14
教育	0.07	0.15	0.30	0.29	0.19
教養娯楽	0.34	0.29	0.20	0.11	0.06
その他の消費支出	0.34	0.28	0.19	0.12	0.07

表 11:  $\gamma_{\epsilon,i}$  の事後分布

$\gamma_{\epsilon,i}$ の値	0.00	0.05	0.10	0.15	0.20
	事前確率				
	0.20	0.20	0.20	0.20	0.20
セクター	事後確率				
食料（生鮮食品、酒類を除く）	0.01	0.36	0.36	0.20	0.07
生鮮食品	0.31	0.43	0.18	0.06	0.01
酒類	0.00	0.00	0.12	0.41	0.47
住居	0.00	0.00	0.01	0.22	0.77
光熱	0.00	0.00	0.00	0.06	0.94
水道	0.00	0.00	0.00	0.04	0.96
家具・家事用品	0.00	0.00	0.00	0.06	0.94
被服及び履物	0.00	0.00	0.08	0.29	0.62
保健医療	0.00	0.00	0.02	0.17	0.81
交通・通信（ガソリン除く）	0.02	0.06	0.21	0.35	0.36
ガソリン	0.10	0.11	0.21	0.29	0.29
教育	0.00	0.00	0.00	0.01	0.99
教養娯楽	0.39	0.23	0.14	0.12	0.12
その他の消費支出	0.00	0.00	0.01	0.19	0.80

表 12:  $p_i$  の事後分布

セクター	16%	50%	67%
食料（生鮮食品、酒類を除く）	0.01	0.02	0.03
生鮮食品	0.01	0.01	0.03
酒類	0.16	0.19	0.23
住居	0.04	0.07	0.09
光熱	0.08	0.10	0.14
水道	0.14	0.17	0.21
家具・家事用品	0.05	0.07	0.10
被服及び履物	0.05	0.08	0.12
保健医療	0.14	0.17	0.20
交通・通信（ガソリン除く）	0.05	0.07	0.09
ガソリン	0.02	0.03	0.06
教育	0.07	0.10	0.13
教養娯楽	0.09	0.13	0.16
その他の消費支出	0.08	0.11	0.14

## B 時変ウエートの近似（図5のウエートの計算方法）

線形かつガウジアンを仮定している MUCSVO モデルを用いて推定される集計トレンドは、各セクターのインフレ率の現在値やラグ項の加重和によって決まると考えることができる。各セクターのインフレ率に対するウエートは時間変化し、その値は時変パラメータの値や外れ値に依存して決まる。ただし、モデルには外れ値が含まれていたり時変パラメータが内生的に変化すると仮定しているが、その場合、ウエートは非線形に決まることになり、ウエートを求めるのが困難になる。ここでは2.2節の MUCSVO モデルの設定から、時変パラメータ  $(\alpha_{i,\tau,t}, \alpha_{i,\varepsilon,t}, \sigma_{\Delta\tau,c,t}, \sigma_{\Delta\varepsilon,c,t}, \sigma_{\Delta\tau,i,t}, \sigma_{\Delta\varepsilon,i,t})$  を外生的に所与として、外れ値を含めないように変更する。すると線形ガウジアン状態空間モデルは

$$\text{セクター別インフレ率： } \pi_{i,t} = \alpha_{i,\tau,t}\tau_{c,t} + \alpha_{i,\varepsilon,t}\varepsilon_{c,t} + \tau_{i,t} + \varepsilon_{i,t}, \quad (14)$$

$$\text{共通トレンド： } \tau_{c,t} = \tau_{c,t-1} + \sigma_{\Delta\tau,c,t} \times \eta_{\tau,c,t}, \quad (15)$$

$$\text{共通一過性成分： } \varepsilon_{c,t} = \sigma_{\varepsilon,c,t} \times \eta_{\varepsilon,c,t}, \quad (16)$$

$$\text{セクター固有トレンド： } \tau_{i,t} = \tau_{i,t-1} + \sigma_{\Delta\tau,i,t} \times \eta_{\tau,i,t}, \quad (17)$$

$$\text{セクター固有一過性成分： } \varepsilon_{i,t} = \sigma_{\varepsilon,i,t} \times \eta_{\varepsilon,i,t} \quad (18)$$

となる。ただし、時変パラメータは全てのサンプルを用いて推定された事後分布の平均である。このように変更したモデルでは、ウエートは線形的に求めることができる。その意味で、この方法で求められるウエートは近似計算と捉えることができる。ここではこのモデルを用いたカルマン・フィルターのフィルタリングによって  $\tau_{c,t|t}$  および  $\tau_{i,t|t}$  を得て、集計トレンド  $\tau_{t|t} = \sum_{i=1}^n w_{it} (\alpha_{i,\tau,t}\tau_{c,t|t} + \tau_{i,t|t})$  を求める。線形かつガウジアンを仮定しているの、推定されるトレンドはラグ項によって表され、ウエート  $\omega_{ij,t}$  は時変パラメータの値や、支出シェア  $w_{it}$  に依存するように決まる：

$$\tau_{t|t} = \sum_{i=1}^{17} \sum_{j=0}^{t-1} \omega_{ij,t} \pi_{i,t-j}. \quad (19)$$