

2000年代以後の全国と三大都市圏の別にみた月別人口動態の趨勢

菅桂太・小池司朗・鎌田健司

1. はじめに

本研究では1995年1月から2024年11月の「人口動態統計」による都道府県別出生数と死亡数並びに2000年1月から2025年3月の「住民基本台帳人口報告」都道府県間転入数と転出数を用いて、月別変動のパターンを地域別に分析することを目的とする。これら動態件数の月別系列には季節性(1年のなかの月による系列の安定な変化)が認められるため、センサス局法を用いて季節成分分解を行い、中長期的な趨勢の変化(1年を超える系列の趨勢的な変化)を観察した。とくに、新型コロナウイルス感染症の流行が始まり、最初の緊急事態宣言が発出された2020年4～5月前後に、趨勢の変化があったのか否かについて検証することを目的とする。

2020年に始まった新型コロナウイルス感染症の世界的な大流行は、直接的な健康被害への影響だけでなく、多くの国々で法的な都市封鎖が実施され人流・物流に甚大な影響を招くとともにオンライン会議や在宅勤務(テレワーク)の増大等の社会の有り様を大きく変える影響を及ぼしている。新型コロナウイルス感染症の影響は広範で甚大であったため、最新データに基づく現在の状況の精確な把握が重要となり、わが国においても速報性が重視されて関連する統計の2次的な取りまとめが多くなされてきた。なかでも人口動態に関する統計として、出生と死亡については「人口動態統計月報」が約5ヶ月後(子の住所地と死亡者の住所地についての件数)¹、「住民基本台帳人口移動報告月報」が調査月の2ヶ月後に、都道府県別の実数が公表されている。しかし、これらの人口動態には季節性がある。死亡の場合には6～9月に5～10%少なく、12月から翌1月に10～15%多くなっている。出生も7～9月に5%ほど多い。人口移動については3～4月に集中しており、他の月の2～2.5倍という規模になっている。そのため、新型コロナウイルス感染症が流行する前から地域人口の変化について最小限のタイムラグをおいた最新の人口変化の状況を知ることができたのだが、月別原系列は当該地域で現在総人口はどの程度の速度で減少しているのかという最も基本的な事実について客観的な知見を得ることが難しい季節変化を含んでいる。本研究では、経済統計に広く適用され一般的・標準的な季節調整(季節成分分解)の手法であるセンサス局法を月別人口動態の系列に適用し、季節性のパターンと一時的な攪乱の変動を除去した中長期的な趨勢の変化について分析する。

¹ 「人口動態統計速報」が調査月の約2ヶ月後に届出地についての件数を取りまとめ報告しているが、届出地の地域が住所地とどのような関係にあるのかは定かではない。また、日本における外国人、外国における日本人と前年以前に発生したものを含む。本研究では「人口動態統計(確定数)」と同一の観察対象について、同一の地域を表章する月報を用いた。

本研究は、センサス局法という経済統計の領域で標準的な手法を用いることによって人口動態系列からも簡便に季節性を除去し（月別系列の背後にある）中長期的な趨勢の観察が可能であることを示すことを一つの目的としている。そのため、詳細は後述の通り、センサス局法には多彩なモデリングオプションがあるものの、詳細なモデルの精緻化には立ち入らずに初期設定を用いることとする。分析モデルの精緻化により結果は変わりうる可能性があることに留意されたい。また、同じ理由で人口動態件数「実数」を分析対象とする。わが国の人口は急速な少子高齢化が進行しており、分母人口の変化により出生数と移動数は減少、死亡数は増加傾向にある。長期的な趨勢の観察においては人口（年齢）構造の影響を除去する「率」の観察が重要であるが、季節性の分析は典型的には1年以内の期間の変化のような短期の系列変化に着目した分析である。本研究が「数」を対象とする分析であること、新型コロナウイルス感染症の流行が始まった後の期間のせいぜい2～3年程度のスパンの変化に注目する分析であることに留意されたい。

著者らは2022年に月別人口動態の最新の動向について（センサス局法を援用した季節成分分解の結果について）のモニタリングを開始し、概ね半年に一回程度の頻度で結果を報告してきた²。センサス局法は、ごく大雑把に言えば中心化（対称な）移動平均（当該月と前後同一期間幅の平均）によって季節成分を除去する手法である。最新の趨勢の算出には将来についての（最大7年間程度の）観測値を要求する。そのため、季節成分分解の分析一般に、新しいデータが加わる度に推定結果が変化するという「時系列の不安定性」の問題がつきまとう。分析上関心が高い最新の期間において「時系列の不安定性」の影響は大きくなるという本質的に難しい問題である。一方で、本稿執筆時点の分析において2024年11月までの「人口動態統計 月報」と2025年3月までの「住民基本台帳人口移動報告 月報」の結果を利用することができるようになっており、本研究が最も着目する時期（2020年前半）については、このような不安定性の影響を大きくは受けなくなってきた分析結果を示すものである。他方で、死亡数については新型コロナウイルス感染症の流行が始まった2020年は従来からの趨勢と比べて減少したものの2022年以後かなり多く推移しており、最新の状況については今後公表されるデータ次第で結果が変わる可能性があることに留意されたい。

2. 分析手法

2.1. センサス局法の概要

センサス局法として知られる季節調整の方法には膨大な先行研究が存在し、数々のバージョンアップを重ねてきたが、最新のものはX-13-ARIMA-SEATSと呼ばれる。このX-13-ARIMA-SEATSでは、季節調整（季節成分分解）手法の基本的な考え方として、X-11アルゴリズムが選択できる。X-11は1950年代半ばに米国センサス局で開発され、1960年代半ばに確立（Shiskin et. al 1967, Ladiray & Quenneville 2001）したものであり、極めて長い

² 菅他（2022）、Suga et al.（2023a）、菅他（2023b）、Suga et al.（2024a）、菅他（2024b）。

歴史を有し、広く用いられている（X-11 族に関して膨大な文献が存在）。

X-11 には、時系列の最新部分に中心化フィルターを用いることができないため、新たなデータが利用可能になる度に最新期間の調整結果に相対的に大きな改訂を余儀なくされるという「時系列の不安定性」の問題があった。このような問題に対して、時系列解析モデル（Auto Regressive Integrated Moving Average, ARIMA）を用いて系列の最古と最新部分を補うという対処法が考案され、1970~1980 年代にかけて X-11-ARIMA は確立した。さらに、X-11 の季節性フィルターと ARIMA モデルを発展させた regARIMA モデルを組み込んだ X-12-ARIMA は 2000 年前後に確立している（Findley et. al 1998）。

2010 年代に入り登場した X-13-ARIMA-SEATS は、1990 年代末にスペイン銀行で開発され欧州諸国で広く用いられる TRAMO-SEATS（Time Series Regression with ARIMA Noise Missing Observations and Outliers–Signal Extraction in ARIMA Time Series, Gómez & Maravall 1996）を組み込み、X-12-ARIMA とともに利用できるようにしたものである。TRAMO-SEATS 法は「季節性フィルターとして Wiener-Kolmogorov フィルターをベースにした信号抽出の手法を用いており、無限の過去から無限の未来までの観測値が存在すると想定した場合の最小二乗法によるデータ空間への射影として数理的な最適な分解を行うものである一方、分析にあたって仮定される制約がやや強く恣意的な部分や合理的でないと考えられる部分がある（高部 2009）」とされる。本研究では X-13-ARIMA-SEATS プログラムを利用するが、季節調整（季節成分分解）手法の基本的な考え方として X-11 フィルターを利用しており、「時系列の不安定性」の問題に対処するための最新部分の系列値の予測には regARIMA モデルを用いた。X-13-ARIMA-SEATS では regARIMA モデルの自動選択機能に TRAMO アルゴリズムとほぼ同等の手法が採用されており（U.S. Census Bureau 2020）、X-12-ARIMA に TRAMO を組み合わせたものを用いていることになる。

2.2. センサス局法の構成と利用

季節調整（季節成分分解）についてのセンサス局法 X-12-ARIMA は、次の三段階の要素（もしくは手順）から成る。第一段階は regARIMA を用いた事前調整パートである。第二段階は X-11 フィルターを適用する季節成分分解である。第三段階では、事前調整や季節成分分解の良好さに関する種々の統計量が計算される。センサス局法の手法に関する先行研究には膨大な文献が存在し、その網羅的なレビューは本稿の目的とするものではない。本稿では分析結果の解釈に直接関わる部分のみを取り上げることとし、2.3 節で第一段階の事前調整、2.4 節で季節成分分解のための X-11 フィルターについて扱う。

X-13-ARIMA-SEATS プログラムは、基本的には初期設定のまま利用した。ただし、3つの項目を追加的に設定している。1つ目は、regARIMA モデルの自動選択にあたり、初期モデル（ $SARIMA(0,1,1)(0,1,1)_{12}$ ）を特定する際に曜日効果とイースター効果の統計的な有意性に関する AIC テストを追加し、統計的に有意な場合には季節性 ARIMA モデルを適用する残差からこれらの効果を除外するようにした。2つ目は、初期設定では外れ値の類型とし

て加法的外れ値と水準変化しか検索しないが、減衰的外れ値についても自動探索の対象とした（これら外れ値の類型は 2.3 節に後述）。先述の通り、本研究では季節性フィルターに SEATS ではなく X-11 を用いる。以上の設定でモデル識別を実施したところ、最終的な季節性移動平均フィルターの次数として 3x9 が選択される場合があり、5 年前と 5 年後の同月の観測値が移動平均の算出に用いられることがあった。そのため、X-11 フィルターを適用するインプットデータの作成にあたっては、最終的に自動識別された regARIMA モデルを用いて 5 年間の予測値を得た（X-13-ARIMA-SEATS プログラムの初期設定では regARIMA モデルを用いた事前調整が行われる場合には 12 ヶ月の予測値が自動的に算出され用いられる）。

本研究は都道府県別の月別人口動態系列（出生数、死亡数、都道府県間転入数と転出数）を対象として季節成分分解を実施する。本稿では、膨大な分析結果を全国と三大都市圏³に縮約して主要な分析結果を示すこととした。三大都市圏の季節成分分解を行う場合、これら地域を構成する都道府県各々の季節成分分解の結果を集計する方法（間接分解; indirect adjustment もしくは composite adjustment）と、三大都市圏（合計値）を直接分解する方法（direct adjustment）がある。地域によって季節性（系列の変動パターン）が異なるなら間接調整が好ましい（合計系列では 2 つの地域の変動が打ち消し合い失われることがあるため）。一方、対象地域の季節性（と中長期の変動）が同じパターンなら、合計系列に対する直接調整が好ましいとされる（攪乱が均され、複数の地域の季節性がお互いに補完しあうため）。本研究では、全国・三大都市圏についての間接分解の分析結果を取り上げる⁴。

2.3. 季節成分分解のための事前調整

センサス局法 X-12-ARIMA における季節成分分解の第一段階の事前調整パートでは、ARIMA モデルを用いて原系列を近似（記述）し、「時系列の不安定」の問題に対処するために将来の一定期間（X-11 による中心化移動平均の算出に必要な期間）についてのモデル予測値を得ることを目的とする。そもそも ARIMA モデルは独立同分布の定常な確率項（ホワイト・ノイズ）を用いて原系列を記述するモデルであり、このパートの目的はホワイト・ノイズから原系列を（統計的によりよく）復元できる関数を発見することである。また、ARIMA モデルの係数推定値と予測値は種々の外れ値（Outliers）の存在に対し極めて敏感に反応することが知られており（たとえば Burman and Otto 1989）、予測値を得る際には曜日構成効果（Trading day effects）等のカレンダー効果と呼ばれる 時系列に固有な構造的影響とともに

³ 東京圏（埼玉県、千葉県、東京都、神奈川県）、名古屋圏（岐阜県、愛知県、三重県）、大阪圏（京都府、大阪府、兵庫県、奈良県）、非大都市圏（その他の道県）とした。

⁴ ただし、間接修正は、個別都道府県についての分解結果を足し上げたものであり、三大都市圏についての推定結果（regARIMA モデルが識別した外れ値等）について言及する場合には直接分解の結果を参照している。

に外れ値の影響を除去することが重要とされる。以下では、センサス局法で採用されている TRAMO アルゴリズムにおける regARIMA モデルの自動選択方法の概要を紹介する。詳細は、U.S. Census Bureau（2020：4 章及び 7.2 節）を参照されたい。

まず、原系列を対数変換することが望ましい場合には変換を行う（対数変換を実施する場合には、次節で紹介する X-11 フィルターの適用にあたって乗法モデルを用い、そうでない場合には加法モデルを用いる）。そのうえで、曜日構成効果等のカレンダー効果や定数項と外れ値の探索と季節性 ARIMA モデルの次数の選択を行う。最後に、選択されたモデルを用いて、カレンダー効果や外れ値の影響を取り除いた予測値を算出し、X-11 フィルターを適用するインプットデータを作成する。

一般に、月別データ z_t についての季節性 $ARIMA(p, d, q)(P, D, Q)_{12}$ モデルは次式で特定される独立同分布で平均ゼロの確率項 a_t の関数である。

$$\phi(B)\Phi(B^{12})(1-B)^d(1-B^{12})^D z_t = \theta(B)\Theta(B^{12})a_t$$

ここでは B は期間を交代させるラグオペレーター（ $Bz_t = z_{t-1}$ ）、 $\phi(B) = (1 - \phi_1 B - \dots - \phi_p B^p)$ は非季節性自己相関オペレーター、 $\theta(B) = (1 - \theta_1 B - \dots - \theta_q B^q)$ は非季節性移動平均オペレーター、 $\Phi(B^{12}) = (1 - \Phi_1 B^{12} - \dots - \Phi_p B^{12p})$ は季節性自己相関オペレーター、 $\Theta(B^{12}) = (1 - \Phi_1 B^{12} - \dots - \Phi_Q B^{12Q})$ は季節性移動平均オペレーターである。 $(1-B)^d(1-B^{12})^D z_t$ は、月別系列 z_t の d 回の階差と同じ月（12 ヶ月前）の D 回の階差をとるという操作に対応する。regARIMA モデルは観察される系列 y_t の平均を説明する次の回帰式を用いて季節性 $ARIMA(p, d, q)(P, D, Q)_{12}$ モデルを拡張する。

$$y_t = \sum_i \beta_i x_i + z_t$$

つまり、regARIMA モデルは月別系列観測値をカレンダー効果や外れ値で説明する回帰式の残差について季節性 $ARIMA(p, d, q)(P, D, Q)_{12}$ モデルを適用するものである。

X-13-ARIMA-SEATS プログラムが regARIMA モデルについて自動探索する構造的な要因 x_i としては、曜日効果（月別の日曜日の数からの各曜日の数の差に対応する 6 つの変数で識別）、イースター効果の他、次の 3 種類の外れ値（Outliers）がある。

第一の外れ値は、加法的な外れ値（Additive Outlier、以下 AO と略記する）であり、特定の月に 1 をとり、その他は 0 の以下のダミー変数 $AO_t^{(t_0)}$ によって識別される。

$$AO_t^{(t_0)} = \begin{cases} 1 & \text{for } t = t_0 \\ 0 & \text{for } t \neq t_0 \end{cases}$$

第二の外れ値は、水準変化（Level Shift、以下 LS と略記する）であり、特定の月より前は -1 、特定の月以後は 0 をとる以下のダミー変数 $LS_t^{(t_0)}$ によって識別される。通常は特定の月以後に 1 をとるダミー変数が想起されることが多いと思われるが、X-13-ARIMA-SEATS プログラムの水準変化効果は最新時点の値をベースとするため特定の月より前の値をシフトさせている。

$$LS_t^{(t_0)} = \begin{cases} -1 & \text{for } t < t_0 \\ 0 & \text{for } t \geq t_0 \end{cases}$$

第三の外れ値は、減衰的变化（Temporary Change、以下 TC と略記する）であり、特定の月より前は 0、特定の月以後は指数的に減衰する値をとる以下の変数 $TC_t^{(t_0)}$ によって識別される。

$$TC_t^{(t_0)} = \begin{cases} 0 & \text{for } t < t_0 \\ \alpha^{t-t_0} & \text{for } t \geq t_0 \end{cases}$$

ここで α は従来水準への減衰率に対応するパラメータであり（ $0 < \alpha < 1$ ）、初期値は 0.7 になっている。

なお、X-13-ARIMA-SEATS プログラムでは次の手順で外れ値の自動選択をおこなっている。まずカレンダー効果が F 値修正 AIC を用いて統計的に有意なのかを計測し、統計的に有意ならこれらを加えたモデルを用いる（さらに定数項が統計的に有意なのかテストし有意なら加える）ことで外れ値を探索するための初期モデルを識別する。そのうえで、概ね次の[1]から[4]の手順で外れ値を探索する。[手順 1]観測期間中の各月に対して、探索する種類の外れ値を一つずつモデルに加えた場合の t 値を算出する。外れ値候補に対して算出された t 値のなかで、最も大きな t 値が閾値（観測値数に依存するが 4 前後の高めの水準が用いられる）を超えるならモデルに加える。[手順 2]前の手順で発見した外れ値を加えたモデルを用いて[手順 1]を再度実施し、閾値を上回る外れ値を発見できなくなるまで探索を続ける。[手順 3]新たな外れ値を追加することができなくなったら、すべての外れ値候補を投入したモデルで各外れ値の t 値を算出し、閾値を下回るものがあれば最小の外れ値をモデルから除外する。[手順 4]前の手順で除外した変数を除く新たなモデルで[手順 3]を再度実施し、すべての外れ値を同時に用いたモデルにおいて各外れ値の t 値が閾値を上回るようになったら探索を終了する。

ただし、実際には、季節性 $ARIMA(p, d, q)(P, D, Q)_{12}$ モデルの 階差と ARMA 次数の選択と同時に 外れ値等の探索が行われる。そのため、まず初期モデル（ $SARIMA(0,1,1)(0,1,1)_{12}$ ）を用いてカレンダー効果と定数項、外れ値等についてのモデル選択を行う。識別された説明変数を用いて単位根検定により階差が決められ、ベイズ情報量基準（BIC）を用いて ARMA 次数を更新する。そのうえで、選択された $SARIMA(p, d, q)(P, D, Q)_{12}$ モデルの残差が初期モデルよりも好ましい性質を持つことを確認し自動選択された $SARIMA(p, d, q)(P, D, Q)_{12}$ モデルの方が優れているなら、外れ値等を含む説明変数の探索を再度実施する。最後に単位根検定とモデル係数の有意性を確認する、という操作を何度か繰り返すことになる。

2.3. 季節成分分解 X-11 の基本的な考え方

季節成分分解は原系列 Y_t を、乗法モデルもしくは加法モデルのうち統計的に好ましいモデルを用いて、趨勢系列 T_t 、複合季節成分 S_t 、攪乱成分 I_t の 3 要素に分解することを目的とする。

$$Y_t = T_t \cdot S_t \cdot I_t \quad (\text{乗法モデル})$$

$$Y_t = T_t + S_t + I_t \quad (\text{加法モデル})$$

趨勢系列 (Trend-cycle series) は、原系列のうち 1 年を超える期間の趨勢的 (周期的) な変化を抽出する。複合季節成分 (Combined Seasonal, trading day, and holiday factor) は、原系列のうち 1 年以内の期間の安定な (周期的) 変化を抽出する。攪乱成分 (Irregular factor) は、これら趨勢系列や複合季節成分によらない (カレンダー効果も含まない) 短期的なショックに対応する。

季節調整済み系列 A_t とは、原系列から複合季節成分を除去したものであり、季節成分分解結果から $Y_t = T_t \cdot I_t$ もしくは $Y_t = T_t + I_t$ として得られるものである。なお、regARIMA モデルが識別した外れ値及び曜日効果等のカレンダー効果を除去した事前調整済み系列に対して X-11 は季節成分分解を行うが、水準変化 (LS) は最終的な趨勢系列に含まれ (最終的な趨勢系列に LS は戻される)、また加法的な外れ値 (AO) と減衰的な外れ値 (TC) は最終的な攪乱成分に含まれることから、季節調整済み系列に含まれることになる。カレンダー効果は複合季節成分を構成する要素であり、季節調整済み系列からは除外されることになる。

X-11 フィルターは、事前調整済み原系列に 2 種類の中心化移動平均 (中心化 MA) を繰り返し適用することで原系列を 3 つの要素に分解する手法である。2 種類の中心化移動平均とは、隣あった月の平均 (トレンド移動平均) と、同じ月について前後の年次の平均 (季節性移動平均) であり、前者を趨勢系列の推定に、後者を季節成分の推定に用いる。X-11 の基本アルゴリズムは、表 1 に示す通り概ね 3 段階で、これら 2 種類の中心化移動平均 (MA) を繰り返し適用することによって構成される。

第一段階では、事前調整済みの月次原系列 $\tilde{Y}_t$ にトレンド移動平均 (当月を中心に 6 ヶ月前～6 ヶ月後の平均) を適用して趨勢系列初期値 $T_t^{(1)}$ を推定し、事前調整済み原系列 $\tilde{Y}_t$ から趨勢系列を取り除いた系列 $SI_t^{(1)}$ (Seasonal-irregular) に季節性移動平均 (月別の中心化移動平均) を適用することで季節成分初期値 $S_t^{(1)}$ を推定する。事前調整済み原系列 $\tilde{Y}_t$ からこの季節成分初期値 $S_t^{(1)}$ を除去すれば季節調整済み系列初期値 $A_t^{(1)}$ を得る。

第二段階では、季節調整済み系列初期値 $A_t^{(1)}$ にトレンド移動平均を適用することで趨勢系列中間値 $T_t^{(2)}$ を推定し、事前調整済み原系列 $\tilde{Y}_t$ から趨勢系列中間値 $T_t^{(2)}$ を取り除いた系列 $SI_t^{(2)}$ に、季節性移動平均を適用して最終的な季節成分 $S_t^{(2)}$ を推定する。事前調整済み原系列 $\tilde{Y}_t$ から最終的な季節成分 $S_t^{(2)}$ を除去すれば 最終的な季節調整済み系列 $A_t^{(2)}$ が得られる。

第三段階で、最終的な季節調整済み系列 $A_t^{(2)}$ にトレンド移動平均を適用することで 最終的な趨勢系列 $T_t^{(3)}$ を推定する。最終的な季節調整済み系列 $A_t^{(2)}$ から 最終的な趨勢系列 $T_t^{(3)}$ を除去すれば 最終的な攪乱成分 $I_t^{(3)}$ が得られる。以上の手順により、事前調整済み原系列 $\tilde{Y}_t$ は、趨勢系列 $T_t^{(3)}$ 、季節成分 $S_t^{(2)}$ 、攪乱成分 $I_t^{(3)}$ に分解される。最終的な季節調整済み系列 $A_t^{(2)}$ は、これらのうち趨勢系列 $T_t^{(3)}$ と攪乱成分 $I_t^{(3)}$ から構成される。

表 1. X-11 の基本アルゴリズム (加法モデルの例)

手順	処理内容
1	(a) 中心化 12 項 (2x12) トレンド MA による趨勢系列初期値$T_t^{(1)}$の推定 $T_t^{(1)} = \frac{1}{24} \tilde{Y}_{t-6} + \frac{1}{12} \tilde{Y}_{t-5} + \cdots + \frac{1}{12} \tilde{Y}_t + \cdots + \frac{1}{12} \tilde{Y}_{t+5} + \frac{1}{24} \tilde{Y}_{t+6}$ (b) 原系列$\tilde{Y}_t$から趨勢系列を取り除いた系列$SI_t^{(1)}$ (Seasonal-irregular) の推定 $SI_t^{(1)} (= S_t + I_t) = \tilde{Y}_t - T_t^{(1)}$ (c) 3x3 季節性 MA の適用及び中心化 12 項 MA を用いた標準化による季節成分初期値$S_t^{(1)}$の推定 $S_t^{(1)} = \hat{S}_t^{(1)} - \left(\frac{1}{24} \hat{S}_{t-6}^{(1)} + \frac{1}{12} \hat{S}_{t-5}^{(1)} + \cdots + \frac{1}{12} \hat{S}_{t+5}^{(1)} + \frac{1}{24} \hat{S}_{t+6}^{(1)} \right)$ ただし、$\hat{S}_t^{(1)} = \frac{1}{9} SI_{t-24}^{(1)} + \frac{2}{9} SI_{t-12}^{(1)} + \frac{3}{9} SI_t^{(1)} + \frac{2}{9} SI_{t+12}^{(1)} + \frac{1}{9} SI_{t+24}^{(1)}$ (d) 季節調整済み系列初期値$A_t^{(1)}$の推定 $A_t^{(1)} (= T_t + I_t) = \tilde{Y}_t - S_t^{(1)}$
2	(a) トレンド (Henderson) MA による趨勢系列中間値$T_t^{(2)}$の推定 $T_t^{(2)} = \sum_{j=-H}^H h_j^{(2H+1)} A_{t+j}^{(1)}$ ただし、$h_j^{(2H+1)}$は以下に示す$(2H+1)$項 Henderson MA ウェイトであり、9 項、13 項、23 項のなかからデータに合わせて (攪乱成分(t-1~t 期)変化の平均と趨勢系列(t-1~t 期)変化の平均の比の大きさに応じて) 自動選択される。ウェイトは対称であるため最初の$(H+1)$項を示した。 9 項($H=4$): $\frac{1}{2431} \{-99, -24, 288, 648, 805\}$ 13 項($H=6$): $\frac{1}{16796} \{-325, -468, 0, 1100, 2475, 3600, 4032\}$ 23 項($H=11$): $\frac{1}{4032015} \{-17250, -44022, -63250, -58575, -19950, 54150, 156978, 275400, 392700, 491700, 557700, 580853\}$ (b) 原系列$\tilde{Y}_t$から趨勢系列を取り除いた系列$SI_t^{(2)}$ (Seasonal-irregular) の推定 $SI_t^{(2)} (= S_t + I_t) = \tilde{Y}_t - T_t^{(2)}$ (c) 3x5 SMA の適用及び中心化 12 項 MA を用いた標準化による季節成分$S_t^{(2)}$の推定 $S_t^{(2)} = \hat{S}_t^{(2)} - \left(\frac{1}{24} \hat{S}_{t-6}^{(2)} + \frac{1}{12} \hat{S}_{t-5}^{(2)} + \cdots + \frac{1}{12} \hat{S}_{t+5}^{(2)} + \frac{1}{24} \hat{S}_{t+6}^{(2)} \right)$ ただし、$\hat{S}_t^{(2)} = \frac{1}{15} SI_{t-36}^{(2)} + \frac{2}{15} SI_{t-24}^{(2)} + \frac{3}{15} SI_{t-12}^{(2)} + \frac{3}{15} SI_t^{(2)} + \frac{3}{15} SI_{t+12}^{(2)} + \frac{2}{15} SI_{t+24}^{(2)} + \frac{1}{15} SI_{t+36}^{(2)}$である。最終的な (D 表の作成では) 季節性 MA の次数は大域的 MSR (Moving Seasonality Ratios) を用いて 3x3、3x5、3x9 のなかから自動選択される。

	(d) 最終的な季節調整済み系列 $A_t^{(2)}$ の推定 $A_t^{(2)} (= T_t + I_t) = \tilde{Y}_t - S_t^{(2)}$
3	(a) Henderson MA による最終的な趨勢系列 $T_t^{(3)}$ の推定 $T_t^{(3)} = \sum_{j=-H}^H h_j^{(2H+1)} A_{t+j}^{(2)}$ Henderson MA ウェイトは手順 2(a)と同様に自動選択される。 (b) 最終的な攪乱成分 $I_t^{(3)}$ の推定 $I_t^{(3)} = A_t^{(2)} - T_t^{(3)}$ (c) 季節成分分解結果 $\tilde{Y}_t = T_t^{(3)} + S_t^{(2)} + I_t^{(3)}$

資料：Findley et al. (1998：Appendix A)並びに Ladiray and Quenneville (2001)を元に著者作成。

X-11 の実際の計算では、基本アルゴリズムを 3 回繰り返している。また、最初の 1～2 回の基本アルゴリズムの適用では、原系列 $\tilde{Y}_t$ から趨勢系列を取り除いた系列 SI_t を推定した後、極端な値（extreme value）のウェイトを下げて季節性 MA を適用して季節成分を推定している。また、趨勢系列が推定されると季節調整済み系列から攪乱成分が抽出されるが、1～2 回目の計算で識別された極端な攪乱成分を除去して 2～3 回目の計算を開始する初期値としている。このように X-11 は慎重に 原系列を 中長期的な（1 年を超える期間の）趨勢の変化を示す趨勢系列、1 年なかの一定の定期的な（周期的な）パターンを示す複合季節成分、短期的な繰り返しのないショックである攪乱成分という 3 つの要素に分解し、原系列から複合季節成分（特定の月に指標が大きくなりやすい効果、どの程度大きくなるかは変化する）を除去するための手法となっている。強い季節性を示す系列の変化を調べる際に利用される最も簡便かつ有用な指標は対前年比であると思われるが、複合季節成分を除去した季節調整済み系列をみれば、中長期的な趨勢のなかで直前の月と比べた変化を知ることができる⁵。そのため、本稿では基本的に趨勢系列と季節調整済み系列に着目し、中長期的な趨勢の変化と、季節調整済み系列の趨勢に対する比（趨勢と比べて当月にどのようなショックがあったのか）を中心に分析結果を紹介する。

⁵ 複合季節成分にはカレンダー効果が含まれるため、たとえば 3 月は 2 月と比べて約 11%長いという効果は季節調整済み系列からは除去されている。また、季節調整済み系列には攪乱成分を含む。そのため、たとえば東日本大震災（2011 年 3 月）が 2011 年 2 月と比べて月単位の死亡をどの程度増やしたかの示唆を与える。

3. 分析結果

本稿では「住民基本台帳人口移動報告」⁶による 2000 年 1 月から 2025 年 3 月の月別 都道府県別 都道府県間転出数と転入数（291 ヶ月）、ならびに、「人口動態統計」⁷による 1995 年 1 月から 2024 年 11 月の月別 都道府県別 出生数と死亡数（347 ヶ月）の延べ 188 系列の 1,276 ヶ月に対して、X-13-ARIMA-SEATS プログラムを用いて regARIMA モデル+X-11 フィルターによる季節成分分解を実施した。正確には、4 つの月次人口動態系列に対し全国・東京圏・名古屋圏・大阪圏・非大都市圏の 5 区分の地域についての間接調整のプログラムを実行した。また、季節成分分解された系列の転出入の差分をとることで社会増減、出生と死亡の差から自然増減の季節成分分解を得た。以下では、まず全国について、次いで三大都市圏についての間接調整結果を紹介する。

3-1. 全国の動向


① 死亡数

図 1 に全国の月別死亡数についての季節成分分解の結果を示した。要因分解の手順としてはまず regARIMA モデルにより原系列から外れ値とカレンダー効果が除去される。そして、X-11 フィルターの適用により、季節成分が除去され季節調整済み系列が得られると同時に趨勢系列（Trend-cycle）に分解される。図中には、趨勢系列に対する季節調整済み系列の比は（外れ値を含む）攪乱成分（乗法モデルの場合）の大きさを示すことになり、外れ値が識別された年月とともに括弧内にこの比を示した。以降の図も形式は基本的に同一であり、以降は趨勢系列に対する季節調整済み系列の比を「攪乱成分比」と呼ぶ。また、図 1 と図 5（後出）については、regARIMA モデルにより識別された外れ値のタイプ・年月と括弧内に係数推定値の t 値を示した。

全国の死亡数は、原系列や事前調整済み系列でみると一定間隔のスパイクがあり、非常に強い季節性を示す。このような季節性を除去した趨勢系列をみると長期的に増加傾向にあるが、2020 年前半頃から増加速度を加速させている。2020 年以後の新型コロナウイルス感染症が拡大した期間に着目すると、月別死亡数は 2023 年 1 月に約 16.8 万件と過去最高を記録した。2022 年 2 月に水準変化（LS、持続的拡大）、2022 年 8 月、12 月に減衰的变化


⁶ 2000 年から 2024 年までの年報と、2025 年 1 月から 3 月までの月報を用いた。なお、2013 年 7 月に「住民基本台帳法の一部を改正する法律」が施行されたことに伴い、外国人も住民基本台帳への登録対象となったため、2013 年 7 月以後の「住民基本台帳人口移動報告」（年報及び月報）では、日本人と（外国人を含む）総数が表章されるようになった。本研究では系列の連続性を担保するため、2013 年以後の期間も日本人移動者の転出入数を用いた。

⁷ 1995 年から 2023 年までの「人口動態統計（確定数）」と 2024 年 1 月から 11 月までの「人口動態統計月報（概数）」を用いる。したがって、前年以前に発生したものを除く日本における日本人の出生数と死亡数を用いた。




注: regARIMA推定において統計的に有意な外れ値の年月に続く()内の数字は, 季節調整値のTrend-cycleに対する比。

図 1. 全国の死亡数の季節成分分解：1995 年 1 月～2024 年 11 月




注: regARIMA推定において統計的に有意な外れ値の年月に続く()内の数字は, 季節調整値のTrend-cycleに対する比。
 実直線は2015年1月～2019年12月における趨勢系列の(対数)線型予測であり, 2020年1月以後に補外した予測値を破線で示した。

図 2. 全国の 2015～2019 年の趨勢が続いた場合の死亡数：2015 年 1 月から 2024 年 11 月



注: regARIMA推定において統計的に有意な外れ値の年月に続く()内の数字は, 原系列のTrend-cycleに対する比。

図 3. 全国の出生数の季節成分分解：1995 年 1 月～2024 年 11 月



注: regARIMA推定において統計的に有意な外れ値の年月に続く()内の数字は, 季節調整値のTrend-cycleに対する比。
実直線は2015年1月～2019年12月における趨勢系列の(対数)線型予測であり, 2020年1月以後に補外した予測値を破線で示した。

図 4. 全国の 2015～2019 年の趨勢が続いた場合の出生数：2015 年 1 月から 2024 年 11 月

(指数的に減衰する一時的なショック TC)があったことを regARIMA モデルは識別したため、季節調整済み死亡数で見ると 2022 年 12 月に約 14.2 万件(趨勢系列に対する比は約 1.107)で最も大きくなる。攪乱成分比(季節調整済み系列の趨勢系列に対する比)の推移をみると、東日本大震災の後 2021 年までは、2012 年 2 月(1.057)を除いて、1.05 を超えたことはなかった。しかし、2022 年 2 月の水準変化以後の期間では、新型コロナウイルス感染症の流行との関連でいうと 2022 年 1~3 月(第 6 波)や 2022 年 7~8 月(第 7 波)以後の時期に相当する、2022 年 8 月(1.090)、2022 年 12 月(1.082)、2023 年 1 月(1.079)に、断続的に高水準の死亡ショックが発生している。ただし、これらの攪乱成分比の水準は、東日本大震災が発生した 2011 年 3 月の 1.181 や、全国的にインフルエンザが流行した 1999 年 1 月の 1.234 には及ばない。これまでもインフルエンザの流行等により、1997 年 1 月(1.124)、1998 年 2 月(1.079)、1999 年 1→2 月(1.234→1.115)、2000 年 2 月(1.064)、2003 年 1 月(1.079)、2005 年 3 月(1.113)、2012 年 2 月(1.057)と定期的に死亡ショックは起こっており、ショックの水準としても 2022 年以後のものと同程度かそれ以上のものは定期的に発生していた。しかしながら、それらは加法的外れ値(AO)や減衰の変化(TC)と識別される一時的なショックであるのに対し、2022 年 2 月以後には水準変化(LS、死亡拡大の持続)が識別されている。また 1 年のうちに 3 回の断続的な一時ショックが発生したことはこれまでになかった。

新型コロナウイルス感染症が拡大した 2020 年以後に、それ以前と比べて趨勢の変化があったのかをみるため、2015 年 1 月~2019 年 12 月の趨勢系列に年月を対数線形回帰した場合の予測値とその 95%信頼区間並びに 2020 年以後の補外値を重ねて示したのが図 2 である⁸。2015~2019 年の全国の死亡数の趨勢は対数線型トレンドで良好に説明されており、予測値の 95%信頼区間のレンジに収まる。2020 年の新型コロナウイルス感染症の流行が始まった最初期に趨勢系列は 95%信頼区間の下限を僅かに下回った後は増加速度を加速させ、2022 年には信頼区間の上限を上回っている。2022~2023 年にかけて持続的な拡大と一時ショックの連続があったことは既述の通りであるが、2020~2022 年と比べると 2022 年末から死亡数の増加ペースはやや緩やかになっているように見えるものの、2024 年 11 月までのところ 95%信頼区間上限から一定の距離を保って推移しており、顕著な低下あるいは 2015~2019 年トレンドへの回帰の傾向は示されていない。ただし、2 節(分析手法)で言及した通り、趨勢系列を推定する中心化トレンド移動平均は当月を中心に前後 1~2 年の観

⁸ X-13-ARIMA-SEAT プログラムは regARIMA モデルによる事前調整を行う前に原系列を対数変換する(乗法モデル)か否か(加法モデル)を自動的に判定することができる(前出 2.2~2.3 節)。対数変換が行われた場合には 2015~2019 年のトレンドに対し対数線形回帰を行い、対数変換が行われなかった場合には線形回帰を行って予測値を得た。この手順はすべての系列について同様であり、出生の全国・名古屋圏・大阪圏は線型、その他の系列・地域については対数線形の回帰モデルを用いた。なお、自然増減と社会増減は出生・死亡と転出入の季節成分分解結果の差分として算出しており、2015~2019 年のトレンドは線型を仮定した。

測値を要求し、また季節成分を除去するための中心化季節性移動平均は同様に前後 2～5 年の（同月の）観測値を要求する。そのため、観測期間の最後の 1～2 年は regARIMA モデルの予測値に依存している（構造変化が起きないことを前提とする）ことには留意されたい。

② 出生数


全国の出生数の季節成分分解の結果を図 3～4 に示した。出生数についても、原系列や事前調整済み系列でみると、一定間隔のスパイクがあり、強い季節性を示すことがわかる。この季節性を除去した趨勢系列をみると、長期的に減少傾向にあり、（新型コロナウイルス感染症流行前の）2015 年頃から その前と比べ減少速度をやや加速させている（図 3）。死亡数についての分解結果とは異なり出生数については、2021 年 1 月にやや大きな一時ショック（攪乱成分比は 0.942）を経験したものの、regARIMA モデルは本稿の分析対象期間において恒常的・一時的なショックを示す外れ値を 統計的に有意には識別していない。

しかしながら、2015 年以後の期間に着目すると、やや違った状況も見えてくる。死亡数の場合と同様に、出生についても趨勢系列の 2015～2019 年の線型のトレンドはこの間の低下傾向を良好に説明しており、趨勢系列は 95%信頼区間のレンジに収まる。2020 年以後の期間については、2023 年前半頃から出生数の趨勢系列は線型トレンド予測値の 95%下限を下回り、2024 年 11 月現在においても 2015～2019 年トレンドを下回って推移していることがわかる。新型コロナウイルス感染症への対策として人の接触が嚴重に制限された頃、結婚が減少した。結婚の減少は若干のタイムラグをもって第 1 子出生の減少を招き、低次パリティ人口の低下が高次パリティ出生数を減少させる（国立社会保障・人口問題研究所 2023:p.30-36）という見方と整合的な分析結果であり、新型コロナウイルス感染症拡大の影響は 2023 年頃から顕在化しているとみることができる。

③ 全国の人口移動


全国の都道府県間人口移動の季節成分分解の結果を図 5～6 に示す。全国の都道府県間移動は、転入数と転出数が合致するため人口移動による人口増減を示すものではなく、都道府県境をまたぐ人口移動（住民票所在地変更）の総量を示す。冒頭で触れたように、人口移動は転出入ともに 3～4 月に集中しておりその他の月の 2～2.5 倍という水準になっている。そのため原系列からは（過去 20 年程の期間をみれば）減少傾向にあることは察しが付くが、過去 3～5 年程度の趨勢と比較して今年の 5 月の水準はどの程度増加・低下したのかを推し量るのは困難であろう。季節成分分解の手法は、このように非常に強い季節性を示し（出生や死亡と比べると地域経済等の状況を反映し）急速に変わりやすい人口移動の現状を調べるためのツールである。

まず、趨勢系列をみると、都道府県間移動の総量は 2000 年から 2010 年頃まで低下し、以後 2019 年頃まで同水準で推移した。直近では、2019 年 4 月頃をピークにやや減少している。攪乱成分比の推移をみると、ちょうど最初の緊急事態宣言が発令されていた 2020 年



注: regARIMA推定において統計的に有意な外れ値の年月に続く()内の数字は, 原系列のTrend-cycleに対する比.

図 5. 全国の都道府県間移動数 (=転入数-転出数) の季節成分分解: 2000 年 1 月から 2025 年 3 月



注: regARIMA推定において統計的に有意な外れ値の年月に続く()内の数字は, 季節調整値のTrend-cycleに対する比.
 実直線は2015年1月~2019年12月における趨勢系列の(対数)線型予測であり, 2020年1月以後に補外した予測値を破線で示した.

図 6. 全国の 2015~2019 年の趨勢が続いた場合の都道府県間移動数: 2015 年 1 月から 2025 年 3 月

5月に0.784という、大きな人口移動量の減少（一時ショック）があったことがわかる。分析対象期間中、regARIMAモデルは4つの加法的・減衰的な外れ値を識別しており、それらの攪乱成分比は2009年1月の1.140、2011年5月の1.160、2015年9月の1.100となっているが、これら新型コロナウイルス発生前の3つと比べても大きな変化率であったことがわかる。なお、2000年代以後では、コロナ前の一時ショックはすべて正であり、活発な人口移動ブームが外れ値として識別されているのに対し、2020年5月の新型コロナショックは人為的な制限によるはじめての人口移動量の衰退ショックとなったことは興味深い。


2015年以後の期間に着目し趨勢系列の変化をみると、直近では都道府県間移動量は若干の増加傾向にあった（対数線形トレンドの係数推定値は0.1%水準で統計的に有意な正）。しかし、2019年4月頃から趨勢系列は減少を開始したことがわかる（図6）。最初の緊急事態宣言下の2020年5月に一時的なショックがあったことは指摘したが、この月の趨勢系列は95%信頼区間のちょうど下限になった。その後、2021年後半に信頼区間下限を下回ったのを除くと2023年のはじめ頃まで信頼区間下限を維持していた。つまり、新型コロナ感染症の拡大が始まって「巣ごもり」と言われ人口移動が忌諱される社会的風潮にあった3年程度の間、一時期を除いて、実際には都道府県間人口移動の総量としては減少してはおらず僅かながら上昇したことになる。そして、2023年頃からは2019年以来の低下トレンドに回帰している可能性がある。

3-2. 三大都市圏別にみた 出生数と死亡数

三大都市圏別の出生数及び死亡数について、2015年以後の変化について着目した季節成分分解の結果を図7に示した。出生・死亡については、いくつかの地域差もあるものの、後にみる人口移動と比べると2015年以後の変化パターンは共通しており、全国的なショックが広範な地域で観察されたといえる。

まず、出生については、趨勢系列の2015～2019年の線型（非大都市圏のみ対数線形）の低下トレンドはどの地域においてもこの間の低下傾向を良好に説明しており、趨勢系列は95%信頼区間のレンジに収まる。2020年以後もその傾向は継続しており、程度の差こそあれ、すべての地域において2021年前半に信頼区間の範囲内で低下した後も上下動を繰り返しながら概ね2015～2019年の低下トレンドにしたがっている。ただし、（最も出生数の規模が大きな）非大都市圏では、2022年以後に低下速度が加速しており、2023年以後は信頼区間下限を下回って推移している。三大都市圏別にみた出生について、regARIMAモデルが識別した唯一の外れ値は非大都市圏における2024年1月の加法的な外れ値（AO）のみである（攪乱成分比は0.966）。全国では2023年前半頃から出生数の趨勢系列は線型トレンド予測値の95%下限を下回っていたのは、非大都市圏の寄与が大きいことがわかる。

死亡数についても、趨勢系列の2015～2019年の対数線形の上昇トレンドはどの地域においてもこの間の趨勢をよく説明しており、2020年に死亡数は一時的に減少し信頼区間の下



注: 実直線は2015年1月~2019年12月におけるTrend-cycle系列の年月による線形予測(死亡は対数線形予測)であり、2020年1月以後に補外した予測値を破線で示した。

図 7. 三大都市圏別にみた 2015~2019 年の趨勢が続いた場合の自然動態数：2015 年 1 月から 2024 年 11 月

限付近にあったこと、その後反転・上昇に転じたことはどの地域においても共通している。とくに、2022 年 2 月には、大阪圏を除くすべての地域で水準変化 (LS) が起こっており、死亡数の持続的な拡大があると regARIMA モデルは識別している。なかでも、東京圏における趨勢系列の上昇速度の加速が目立つ。なお、医療崩壊が起こったとされる大阪圏では 2022 年 2～3 月（攪乱成分比は 1.208～1.130）と 8～9 月（攪乱成分比は 1.188～1.103）に顕著な死亡数の増加があり、どちらも減衰的外れ値 (TC) と識別された。

2022 年 2（～3）月のショックを攪乱成分比で見ると、大阪圏で最も大きく（攪乱成分比は 1.208～1.130）、次いで名古屋圏（1.107）、東京圏（1.096）の順で、非大都市圏（1.029）は最も小さかった。しかし、2020 年 12（～翌 1）月のショックは、逆に非大都市圏（攪乱成分比は 1.095～1.087）で最も大きく、名古屋圏（1.069）、東京圏（1.072）、大阪圏（1.069～1.070）の順になった。2022 年 2 月のショックは非大都市圏で最も小さかったが、2022 年末のショックは非大都市圏で最も大きくなったことは、新型コロナショックが都市中心から郊外、非大都市圏へと拡散したことを示唆するのかも知れない。

このように新型コロナウイルス感染症が拡大した 2020 年以後、死亡数は増加速度を加速させ、出生数は減少速度を加速させたため、自然減少の速度は加速した。どの地域においても自然減少数の趨勢系列の 2015～2019 年の線型低下トレンドはこの間の低下傾向を良好に説明していたが、東京圏・名古屋圏・非大都市圏では 2022 年のはじめ頃から、大阪圏においても 2022 年末から自然減少数の趨勢系列は信頼区間下限を明瞭に下回りはじめた。その要因としては、非大都市圏を除くと、死亡数の顕著な増加（とくに 2020 年以後の死亡数拡大の持続）の影響が大きい。

3-3. 三大都市圏別にみた 転出数と転入数


三大都市圏別の転出数と転入数及びこれらの差分である社会増減について、2015 年以後の変化について着目した季節成分分解の結果を図 8 に示した。出生・死亡と異なり、人口移動は地域によってかなり事情が異なり、複雑な変化をした。ここでは 2020 年 5 月前後のショックとその後の変化に論点を絞って分析結果を紹介したい。

まず、最初の緊急事態宣言が発令された 2020 年 5 月の一時ショックは全国的に都道府県間移動量を大きく減少させた（3-1-③項）。図 8 によれば、これはすべての地域において、転出数と転入数の双方を減少させる加法的な外れ値 (AO) があったことによる。ただし、地域によって転出減少と転入減少の相対的な大きさが異なることにより、転入超過数の変化は異なっていた。すなわち、総じて人口集中が進んだ大都市地域において転入数の減少幅が大きく、逆に非大都市地域において転出数の減少幅が大きかった。まず、大阪圏と名古屋圏では転入減と転出減が概ね同程度の大きさであった（攪乱成分比は大阪圏では転入減 (0.780) > 転出減 (0.788)、名古屋圏では転入減 (0.820) < 転出減 (0.839) であった）。一方、東京圏では転出減（攪乱成分比 0.822）よりも転入減（攪乱成分比 0.776）の方が大きく、その結果、転入超過数の減少を招いた。他方で、非大都市圏では転出減（攪乱成分比 0.764）の

方が転入減（攪乱成分比 0.820）よりも大きく、転出超過数の縮小があった。


このような 2020 年 5 月の「新型コロナショック」の人口移動への影響は、すべての地域において加法的外れ値（AO）として識別されていることから、趨勢系列に直接的に影響を及ぼすことのない一時的なものである。しかし、図 8 をみると、2020 年 5 月前後に東京圏の趨勢系列に転入数の縮小と転出数の顕著な拡大という不連続な変化があることがわかる。その理由を調べるため、東京圏の一都三県について 2015 年以後の変化に着目した転出数と転入数の季節成分分解の結果を図 9 に示した。図 9 によれば、東京都の転入数と転出数（いずれも趨勢系列）に水準変化が起きており、持続的な転出数拡大と転入数の縮小があった。まず、2020 年 3 月から 4 月にかけて転入数が約 3.5 万件から約 3.3 万件へ 7.6% 縮小した。そして、最初の緊急事態宣言があけた 2020 年 6 月から 7 月にかけての転出数の拡大はとりわけ大きく約 2.9 万件から約 3.3 万件へ 15.0% 増加した。その結果、東京都の転入超過数（趨勢系列）は 2020 年 3 月の約 7 千から 4 月には 4 千強へ約 4 割減少し、さらに 7 月のほぼゼロへと断続的に縮小している。

2020 年 5 月以後の人口移動の趨勢の変化に関して、2015～2019 年転入超過数（趨勢系列）の対数線型のトレンドからの乖離に着目しよう。2015～2019 年の趨勢は、大阪圏では転出超過の縮小、東京圏では転入超過数の増加があり、人口移動による人口減を緩やかにするもしくは人口増加を加速させる趨勢だった。逆に、名古屋圏と非大都市圏では転出超過数の拡大があり、人口移動による人口減少が拡大していた。このような 2015～2019 年の趨勢系列はすべての地域において対数線形トレンド予測値の 95% 信頼区間の範囲内にあったが、2020 年頃からすべての地域において転入超過数の趨勢は反転した。大阪圏では転出超過が 2015～2019 年には縮小していたが拡大に転じ、東京圏では転入超過が拡大していたが縮小に転じた。名古屋圏と非大都市圏では転出超過が拡大していたが、縮小に転じた。これらのうち、大阪圏においては 2025 年 3 月までに転入超過数の趨勢は 2015～2019 年の対数線形トレンドに回帰している。一方で、東京圏の転入超過の趨勢系列は 2015～2019 年対数線形トレンド信頼区間下限をかなり下回って推移している。他方で、名古屋圏・非大都市圏の転出超過は 2015～2019 年対数線形トレンド信頼区間上限をかなり上回って推移している。東京圏における転出数は 2015～2019 年対数線形トレンドの水準に 2025 年 3 月までに回帰しており、転入超過の戻りが遅いのは 2015～2019 年に増加趨勢であった転入数が 2020 年以後低迷しているためである。逆に、名古屋圏と非大都市圏では 2015～2019 年転出数の増加数が 2019 年後半頃から変調し、2020 年に対数線形トレンド信頼区間の下限を下回るようになったが、この転出数の縮小が継続している。これらの結果は 2015～2019 年の間は加熱を続けていた非大都市圏から東京圏（なかでも東京都の変化が顕著だが、3 県においても転入数は低下趨勢）へ向かう「都心回帰」の人口移動の趨勢が、2020 年前後に減速したことを示唆する。ただし、2025 年 3 月の時点において、東京圏の転入超過数はプラス、非大都市圏ではマイナスであり、非大都市圏から東京圏への人口移動がなくなったわけではない（2020 年頃縮小したが、縮小前の水準に戻りつつあるものの、戻り切れてはいない）。



注：実直線は2015年1月～2019年12月におけるTrend-cycle系列の対数線形予測であり、2020年1月以後に補外した予測値を破線で示した。

図8. 三大都市圏別にみた2015～2019年の趨勢が続いた場合の転出数と転入数：2015年1月から2025年3月



注：実直線は2015年1月～2019年12月におけるTrend-cycle系列の対数線形予測であり、2020年1月以後に補外した予測値を破線で示した。

図9. 東京圏における2015～2019年の趨勢が続いた場合の転出数と転入数：2015年1月から2025年3月

4. 結語

本稿では月次人口動態系列の季節性に対処したうえで、新型コロナウイルス感染症の流行が始まった以後の時期に人口動態にどのような趨勢の変化があったのかを全国と三大都市圏別に観察した。最小限のタイムラグをおいた最新のデータを分析した本報告の知見として、出生と死亡に全国的なショックが広範な地域で観察される傾向にあった。まず、出生数については、2020 年以後新型コロナショックは全国的に検出されていない。死亡に対する新型コロナショックは全国的に 2022 年 2 月以後に水準変化 (LS、拡大の持続) を生じさせたことを regARIMA モデルは識別した。この背後には同時期の非大都市圏・東京圏・名古屋圏における死亡数の水準変化がある。一方、大阪圏では 2022 年 2 月と 8 月に断続的に大きな新型コロナショックがあり、一時的な (減衰的) 外れ値として推定されている。出生・死亡・人口移動という人口動態のなかでも 2022 年以後は死亡の変化が著しくなっており、新型コロナウイルス感染症拡大前 (2015~2019 年) の出生・死亡の趨勢系列は概ね単調な増減を示していたが、コロナ渦以後の死亡数は新型コロナウイルス感染症の流行の波に沿った周期的な動きを示すようになっている。地域差も相対的には大きくなっているように見え、慎重なモニタリングの継続が望まれる。

一方、人口移動は地域によってかなり事情が異なっていた。おそらく、新型コロナウイルスの人口動態への影響のなかで、最初の緊急事態宣言が発令されていた 2020 年 5 月の人口移動への「新型コロナショック」が最も大きなものの一つであった。分析の結果、2020 年 5 月の「新型コロナショック」は、すべての地域で転入数・転出数の双方を減らしたものの、東京圏では転出減よりも転入減が大きく転入超過数の減少をまねき、非大都市圏では転出減よりも転入減の方が小さく転出超過数の縮小があった。この知見は筆者らが月次人口動態系列のモニタリングを開始した 2022 年以来、最新データの分析結果によっても継続して観察されており、頑健な結果であることが示唆された。さらに、東京都では 2020 年 4 月以後の転入数の縮小、2020 年 7 月以後の転出数の拡大のそれぞれに持続的な変化が生じていたものの、東京圏全体でみればこれらの時期の変化は一時的なものであった。東京圏 (東京都) における転出数は新型コロナ前の水準に概ね戻っており水準変化 (LS) は解消に向かっているとみられる一方、転入数の戻りは遅い。「新型コロナショック」後の調整は現在も続いているものと見られるため、地域人口動態の継続的なモニタリングとより精緻な分析への深化が不可欠である。

参考文献

- Burman, J. Peter and Mark C. Otto (1988) “Outliers in Time Series,” Research Report 88/14, Bureau of the Census, Washington, D.C., Statistical Research Division.
- Findley, David F., Brian C. Monsell, William R. Bell, Mark C. Otto and Bor-Chung Chen (1998) “New Capabilities and Methods of the X-12-ARIMA Seasonal-Adjustment Program,” *Journal of Business & Economic Statistics*, Vol. 16, No. 2 (Apr., 1998), pp.

- Gómez, Victor and Agustin Maravall (1996) Programs TRAMO and SEATS : Instructions for the user (beta version: June 1997). Banco de España, Servicio de Estudios, DT 962
- 国立社会保障・人口問題研究所 (2023)『日本の将来推計人口－令和 3(2021)～52(2070)年－令和 5 年推計』人口問題研究資料第 347 号, 国立社会保障・人口問題研究所.
- Ladiray, D. and B. Quenneville (2001). *Seasonal Adjustment with the X-11 Method*, New York: Springer. Lecture Notes in Statistics, Vol. 158.
- Shiskin, J., A. H. Young, and J. C. Musgrave (1967). The X-11 variant of the Census Method II seasonal adjustment program. Technical Paper No. 15, U.S. Department of Commerce, U. S. Census Bureau.
- 菅桂太・小池司朗・鎌田健司 (2022)「2000 年代以後の地域別月別人口動態の趨勢」日本人人口学会 2022 年度第 1 回東日本地域部会, 札幌市立大学, 2022 年 10 月 1 日.
- SUGA, Keita, Shiro KOIKE, and Kenji KAMATA (2023a) "A structural change? Regional population dynamics after the COVID-19 pandemic in Japan: An examination of monthly births, deaths, and migration," 2023 Annual Meeting of Population Association of America, New Orleans, LA: Hyatt Regency New Orleans. (2023.4.14).
- 菅桂太・小池司朗・鎌田健司 (2023b)「2000 年代以後の地域別月別人口動態の趨勢と新型コロナ・パンデミック以後の変化」, 2023 年度第 1 回東日本地域部会, 2023 年 9 月 20 日.
- SUGA, Keita, Shiro KOIKE, and Kenji KAMATA (2024a) "Regional Population Dynamics After the COVID-19 Pandemic in Japan: An Examination of Seasonally Adjusted Monthly Births, Deaths, and Migration," 2024 Annual Meeting of Population Association of America, Columbus, OH: Hyatt Regency Columbus. (2023.4.19).
- 菅桂太・小池司朗・鎌田健司 (2024b)「2000 年代以後の地域別月別人口動態の趨勢：新型コロナ・パンデミックの時系列的な影響は構造変化なのか?」, 2023 年度第 1 回東日本地域部会 (札幌市立大学サテライトキャンパス), 2024.9.20.
- 高部勲(2009)「季節調整法 TRAMO-SEATS 法の分析」,『統計局研究彙報』第 66 号:pp.33-75
- U. S. Census Bureau (2020) X-13-ARIMA-SEATS Reference Manual, Version 1.1, U. S. Census Bureau: Washington, DC. <Accessed on 2022/1/11 at <https://www.census.gov/data/software/x13as.html>>

