



RIETI Policy Discussion Paper Series 26-P-007

# 人口減少と地方消滅：克服への処方箋 第5話 都市盛衰の予測モデル

森 知也  
経済産業研究所



Research Institute of Economy, Trade & Industry, IAA

独立行政法人経済産業研究所

<https://www.rieti.go.jp/jp/>

## 人口減少と地方消滅：克服への処方箋

### 第5話 都市盛衰の予測モデル<sup>1</sup>

森 知也（京都大学経済研究所・経済産業研究所）

#### 要 旨

本稿では、日本の都市群の今後の盛衰を予測するための誘導系統計モデルの設計について解説します。このモデルは、第3・4話で論じた経済集積理論と、都市人口分布に現れるべき乗則を理論的基盤とします。推定にあたっては、1970～2020年に日本経済が都市人口分布のべき乗則をおおむね維持しつつ経験した3つの過程——都市化および東京一極集中の進行、個々の都市のべき乗則からの乖離の推移、都市内部の人口分布の変化——を学習します。その上で、国立社会保障・人口問題研究所による全国総人口の将来推計を外生的に与え、2025年から2200年までの国土上の人口分布を1kmメッシュ単位で予測します。

キーワード：都市人口分布、べき乗則、誘導系予測モデル、経済集積、人口減少

JEL classification: R11, R12, C53

RIETI ポリシー・ディスカッション・ペーパーは、RIETI の研究に関連して作成され、政策をめぐる議論にタイムリーに貢献することを目的としています。論文に述べられている見解は執筆者個人の責任で発表するものであり、所属する組織及び（独）経済産業研究所としての見解を示すものではありません。

<sup>1</sup> 本稿は、独立行政法人経済産業研究所（RIETI）におけるプロジェクト「人口減少下での日本の都市と地域の持続可能性」の成果の一部である。本稿の原案は、経済産業研究所（RIETI）のポリシー・ディスカッション・ペーパー検討会で発表を行ったものである。検討会参加者からの有益なコメントに感謝したい。本研究は、JSPS 科研費基盤 S（24H00012）、基盤 A（25H00543）、三菱財団研究助成（202310008）、および鹿島学術振興財団研究助成（2024-2026年「100年後の日本の都市」）の支援を受けたものである。本稿の執筆にあたっては、文献調査・データ分析補助・作図・推敲に AI アシスタント（Claude Code, Anthropic）を利用した。

## 1 はじめに

これまでの話で、人口集積としての都市に注目することによって、人口の地理的分布の変化はきわめてシンプルな秩序に従うパターンに集約されること、そして、それらの秩序形成や変化のしくみは経済集積理論で説明されることを示してきました。鍵となる秩序は都市間の人口分布に現れるべき乗則でした。個々の都市の成長と衰退は、べき乗則に従う都市人口分布の上下移動と回転という2つの動きに集約されます。

過去50年（1970～2020年）では、おおむね単調に都市人口分布は時計回りに回転し、少数の大都市への人口集中が起きました。べき乗則の下では大都市ほど成長するため、この変化は「東京一極集中」として私たちに映りました。しかし、過去50年間で一貫して起こってきた東京一極集中の要因は、時期によって異なります。人口減少が始まる2010年以前は、新幹線網や高速道路網の整備とインターネットの普及により交通・通信費用が大幅に減少したことに加えて、2次産業から3次産業への産業構造の変化によって、産業集積と人口集積の間にかつてない強さで補完関係が生じたことが主要因です。一方、交通・通信費用の減少や産業構造の変化が一段落した2010年以降は、人口減少に伴う地方市場の縮小により、特に労働市場でスケールメリットを求める若年層と企業の東京流入が、東京一極集中を牽引しました。都市人口分布に現れる秩序が今後の都市盛衰の予測の拠り所となるのは、すでに経験してきたように、背景要因が異なっても、実現する「人口集中」が、都市人口分布のべき乗則を維持したまま回転する形に集約されるからです。

今後の都市盛衰を決める要因は過去とまったく同じではないでしょう。しかし、引き続き、物流・通信技術の進歩と人口減少が都市間の人口分布を決める主要因であり続けると考えられます。したがって、今後も大都市に向かう人口集中が進むことには変わりはないでしょう。加えて、急速な人口減少により都市人口分布が下降し、東京を含めて個々の都市の縮小が進みます。予測において都合がよいのは、都市人口分布に、回転・上下移動ともに単調な変化が予想されることです。回転については過去の変化のスピードをベースラインとして設定し、上下移動については社人研による人口減少のシナリオをベースラインとして設定することで、個々の都市の将来の人口を、過去のデータおよび理論と一定の整合性を維持しながら定量的に評価することが可能になります。

一方で、都市人口分布のべき乗則だけでは、個々の都市の将来の姿を十分に見通すことはできません。長期的には、経済の構造変化に伴って、それまでの都市の人口と配置の関係が崩れ、地域内で中心地が入れ替わることもあります。高度成長期には、かつての太平洋工業ベルトに含まれていた静岡や沼津がそれぞれ人口規模で第8位・9位でしたが、現在は東京から大阪までの区間に、名古屋を除いて上位10位に含まれる都市はありません。同様の変化として、第2話では、東京・大阪間の新幹線の導入によるアクセス改善が、大阪を成長させるどころか逆に衰退させた可能性が大きいとする見解を述べました。このような変化は、短期的には個々の都市がべき乗則から逸脱する動きとして現れます。予測では、このような傾向を、個々の都市固有の時系列モデルを用いて過去の成長過程から学習することで捕捉します。

都市内部の人口分布は、都市間の人口分布ほどの秩序はありませんが、高密度な都心と低密度な

郊外というシンプルな構造を持っています。また、輸送・通信費用が減少すれば、従来より低密度な集積で同様の集積のメリットが得られることから、都心の人口密度が下がり、居住は郊外化します。企業立地についても基本的に同様の傾向が見られます。これらの変化も単調に起こっている限りにおいては、一定の精度で予測が可能と考えられます。

予測結果を解釈する際に注意が必要なのは、過去のデータを学習して将来を予測するタイプのモデルは、予測対象期間内で過去の傾向が変わる場合には基本的に対応できないということです。この点については第4節にて具体的に指摘します。

## 2 モデルの設計

モデルは国・都市・1km メッシュの3層に分けて地域経済全体の挙動を表現し、相互に整合をとりながら将来の予測を行います。どの層でも、総人口の減少と、都市人口分布がおおよそべき乗則を維持するという制約の下で、1970～2020年のデータから学習した過去の変化の傾向を将来に引き伸ばして、個々の都市の将来像を予測します。第2話で述べた通り、この50年は、新幹線・高速道路による高速交通網がほぼゼロから全国的に整備され、同時にインターネットが普及した時期を含んでいます。交通・通信費用の変化は都市間・都市内の人口分布を説明する主要因です。それらの減少と、この間に起こった人口の大都市への集中と個々の都市内部の人口分布の平坦化は、経済集積理論が示す結果と非常によく整合します。<sup>1)</sup>

そして、今後も輸送・流通の自動化に伴い物流費用は減少していくと考えられますので、やはり今後も人口は大都市に向かって集中し、個々の都市内では分散する傾向が予想されます。<sup>2)</sup>50年に起こった大都市への集中には、産業構造の3次化や、2010年以降の人口減少・少子高齢化による労働市場の縮小が東京一極集中を加速させた効果も含まれますが、直近過去50年に日本が経験した「大都市への集中」「都市内での平坦化」のスピードをベースラインとして、将来の人口分布の変化を予測することには、一定の合理性があります。個々の都市の将来の姿を正確に予測するというよりは、ベースラインの予測結果を起点として、そこから逸脱する場合についても経済集積理論に依拠した思考実験をすることで、この予測モデルが、この国の将来のあり方を模索する拠り所として機能するよう設計します。

以下、各層でのモデル設計について説明します。

---

1) 1kmメッシュレベルのデータにこだわらなければ、おおよそ100年前の1920年の第1回国勢調査まで遡って過去の変化を学習することも可能です。しかし、1次産業が中心で都市化前の戦前から、2次産業への構造変化と都市化が進行した高度成長期で起こった都市の盛衰と、今後の100年単位で起こる変化との間に直接的な関係は希薄ですので、データの地理的粒度の不一致を乗り越えてもなお得られる有益な追加情報は無いと考えます。

2) 本予測は、エネルギー供給の長期的な安定を暗黙の前提としている。化石燃料への依存と再生可能エネルギーへの転換の遅れが顕在化すれば、輸送費用が構造的に高騰し、本書の予測する大都市集中の加速は逆方向に作用する可能性がある(第7話のむすびを参照)。

## 国レベルの挙動

国レベルで制御するのは、総人口の変化、都市化率（総人口に占める都市人口シェア）の変化、そして都市人口分布の変化です。総人口の変化は、社人研による 2023 年の推計（国立社会保障・人口問題研究所, 2023）を与件、つまり与えられた条件とします。ただし、社人研が公開している 2120 年までの総人口の予測を外挿することで、2200 年までの都市盛衰の予測を行います。都市化率は、図 1 に示すように、1970 年以降増加率が減少しつつも単調に増加を続けています。この変化を  $\log(\text{時間})$  の線形関数として表現し、将来に向けて外挿することで、将来時点ではその外挿で得た都市化率を与件とします。最後に、都市人口分布の変化については、まず、都市人口分布がべき乗則に




図 1. 都市化率の長期推移（1970–2215 年）

従うことを仮定します：

$$\log P_{u,t} = A_t + B_t \log(r_{u,t} - 0.5) + \epsilon_{u,t}^{PL}, \quad \epsilon_{u,t}^{PL} \sim N(0, \sigma_{PL}^2), \quad (1)$$

ここで、 $t = 1, 2, \dots$  は時間で、1 期、2 期と数えます。今回の予測では 5 年ごとに実施される国勢調査を用いるため、1 期=5 年と設定し、学習期間の 1970~2020 年を  $t = 1, 2, \dots, 11$  とします。 $P_{u,t}$  は都市  $u$  の  $t$  期の人口、 $r_{u,t}$  は都市  $u$  の  $t$  期の人口順位、 $\epsilon_{u,t}^{PL}$  は正規分布に従う誤差項です。<sup>3)</sup>

予測にあたり、図 3 に示す 1970~2020 年間の切片  $A_t$  と傾き  $B_t$  の変化を学習し、将来の都市人口分布の形状の変化は、過去の変化の延長線上にあるという前提で予測を行います。切片  $A_t$  の変化は総人口、傾き  $B_t$  の変化は大都市への集中傾向を反映します。予測においては、総人口の変

3)  $N(0, \sigma^2)$  は平均 0、分散  $\sigma^2$  の正規分布を意味します。個々の都市のべき乗則からの乖離は、都市の規模によらず、同じ分散  $\sigma_{PL}^2$  をもつ正規分布に従うと仮定しています。PL は「べき乗則=Power law」の略です。式 (1) で、 $r_{u,t}$  から 0.5 を引いている部分は、 $A_t$  や  $B_t$  の推定バイアスを除く操作ですが、このバイアス補正の有無が結果に大きく影響を及ぼすことはありませんので、特に注意を払う必要はありません。




図 2. べき乗則の下での都市の盛衰

化は社人研の推定値を与件としますので、特に重要なのは  $B_t$  の変化となります。図 3 が示すように、 $A_t$  も  $B_t$  も時間に  $t$  対して単調な変化を示しており、 $\log(\text{時間})$  の線形関数として表現するのが適切と考えられます：

$$A_t = a_0^A + a_1^A \log t + \epsilon_t^A, \quad \epsilon_t^A \sim N(0, \sigma_A^2/t^2), \quad (2)$$

$$B_t = a_0^B + a_1^B \log t + \epsilon_t^B, \quad \epsilon_t^B \sim N(0, \sigma_B^2/t^2), \quad (3)$$

$a_0^A, a_1^A, a_0^B, a_1^B$  はデータから推定する定数、 $\epsilon_t^A, \epsilon_t^B$  は誤差項です。これらの誤差項は正規分布に従うとします。ただし、分散はそれぞれ  $\sigma_A^2/t^2, \sigma_B^2/t^2$  と、時間  $t$  が大きいほど小さく設定してあります。この操作は、2020 年に近いほど観測値とモデル (2)(3) の乖離が小さくなるように、つまり、直近の変化により大きなウェイトを置いて学習することを意味しています。




図 3. べき乗則モデルの係数の変化

都市人口分布のべき乗則の下では、 $t$  期に人口が  $\hat{P}_{u,t}$  であった都市  $u$  の次期 ( $t+1$  期) の人口は以下のように近似できます：

$$\hat{P}_{u,t+1}^{PL} = \hat{P}_{u,t} + \Delta \hat{P}_{u,t}^{PL} \approx \left[ 1 + \frac{a_1^A + a_1^B \log(r_{u,t} - 0.5)}{t} \right] \hat{P}_{u,t}. \quad (4)$$

ただし、 $\Delta \hat{P}_{u,t}^{PL} = \hat{P}_{u,t+1}^{PL} - \hat{P}_{u,t}^{PL}$  で、都市  $u$  の  $t$  から  $t+1$  期間の人口増加です。 $\hat{X}$  は変数  $X$  の推定値を意味します。 $\hat{P}_{u,t}$  は、都市  $u$  の第  $t$  期の確定した推定値です。

## 都市レベルの挙動

冒頭で述べたように、都市人口分布はおおよそべき乗則に従っているとしても、地域経済が構造変化を起こしているときには、その構造変化に大きく関わっている都市は、べき乗則に整合しない挙動を示します。高度成長期後に産業構造が3次化するときに静岡や沼津が順位を落としたように、あるいは、東京・大阪間の交通・通信アクセスが劇的に向上して以降、大阪が衰退傾向を示してきたように。このような挙動を完全に捉えることは難しいですが、学習データで起こり始めた変化を将来に向けて外挿することは可能です。特に、このようなシンプルな統計モデルを使った予測では、直近過去の傾向がそのまま続く将来をベースラインとして設定するのが、自然な方法と考えられます。学習データの時系列が11時点と短いことを踏まえて、以下の3つの標準的かつシンプルな時系列モデルを使います。

### ARI1: ARIMA(1,1,0) モデル

$$\Delta P_{u,t+1} = \rho_u \Delta P_{u,t} + \epsilon_{u,t}^{ARI1}, \quad \epsilon_{u,t}^{ARI1} \sim N(0, \sigma_{u,ARI1}^2) \quad (5)$$

ただし、 $\Delta P_{u,t+1} \equiv P_{u,t+1} - P_{u,t}$ 、 $P_{u,t}$  は、都市  $u$  の  $t$  期の人口です。 $\rho_u$  が推定される係数で、自己相関係数と呼ばれます。つまり、都市  $u$  の  $t$  期の人口変化量が前期  $t-1$  期の変化量の定数倍であるとして、人口の変化を予測するモデルです。誤差項  $\epsilon_{u,t}^{ARI1}$  は、平均ゼロ、分散  $\sigma_{u,ARI1}^2$  の正規分布に従うと仮定します。実際には、個々の都市の盛衰は他の都市との関連性で決まるので、この誤差項には本来そのような相互依存性が反映されます。しかし、この将来予測において重要な都市間の連関は、他の様々な連関に比べて圧倒的に上位な秩序である都市人口分布のべき乗則に絞って反映します。

### ARI2: ARIMA(2,1,0) モデル

$$\Delta P_{u,t+1} = \rho_{1,u} \Delta P_{u,t} + \rho_{2,u} \Delta P_{u,t-1} + \epsilon_{u,t}^{ARI2}, \quad \epsilon_{u,t}^{ARI2} \sim N(0, \sigma_{u,ARI2}^2). \quad (6)$$

こちらは、前期からの人口の変化量を、過去2期分の変化量の線形関数として予測するモデルで、定数  $\rho_1$  と  $\rho_2$  を推定します。このモデルでも、誤差項は正規分布に従うとします。

**LL:** 対数線形モデル (Smith et al., 2002) 最後は時間に関する対数線形モデルで、3つの時系列モデルのなかでも、今回の予測においては最も重要な役割を果たします。いま構築している誘導系統計予測モデルは、基本的に単調な変化の組み合わせで表現できる変化の予測に強く、そうでない、時間に対して非単調で不規則に起こる変化の予測は得意ではありません。都市固有の時系列モデルでは、特に直近過去の傾向を将来の変化に反映することが、予測でできるせいぜいの配慮です。

$$P_{u,t+1} = a_{u,0}^{LL} + a_{u,1}^{LL} \log(t+1) + \epsilon_{u,t}^{LL}, \quad \epsilon_{u,t}^{LL} \sim N\left(0, \frac{\sigma_{u,LL}^2}{t^2}\right), \quad (7)$$

誤差項  $\epsilon_{u,t}^{LL}$  は正規分布に従いますが、(2)(3)と同様に、分散を  $\sigma_{u,LL}^2/t^2$  として、直近過去の ( $t$  が 11 に近い) 変化により大きなウェイトを置いて、係数  $a_{u,0}^{LL}$  と  $a_{u,1}^{LL}$  を推定します。<sup>4)</sup>

都市時系列 (TS) 統合モデル これらの 3 モデルを「最適に」組み合わせて統合モデルを作ります：

$$\hat{P}_{u,t}^{TS} = \frac{\sum_{m \in \mathbf{M}} w_{u,t}^m \hat{P}_{u,t}^m}{\sum_{m \in \mathbf{M}} w_{u,t}^m}, \quad V[\hat{P}_{u,t}^{TS}] = \frac{1}{\sum_{m \in \mathbf{M}} w_{u,t}^m}, \quad (8)$$

ここで、 $\hat{P}_{u,t}^m$  は、モデル  $m$  による  $t$  期の都市  $u$  の人口予測値、 $w_{u,t}^m = \frac{1}{V[\hat{P}_{u,t}^m]}$  はモデル  $m$  のウェイトです。つまり、統合モデルによる予測値は、個々のモデルによる予測値の加重平均になっています。  $V[\hat{P}_{u,t}^m]$  は  $\hat{P}_{u,t}^m$  の予測誤差と呼ばれるもので、学習データに基づいて算出されます。この値が小さいほどモデルの精度がよいと判断されます。予測誤差が小さいモデルによる予測値ほど大きなウェイトが与えられます。

都市レベル PL+TS 統合 最終的な都市レベルの予測値  $\hat{P}_{u,t+1}$  は、べき乗則モデル (PL) による予測値  $\hat{P}_{u,t+1}^{PL}$  と時系列統合モデル (TS) による予測値  $\hat{P}_{u,t+1}^{TS}$  を、それぞれの予測誤差分散の逆数をウェイトとして加重平均したものです：

$$\hat{P}_{u,t+1} = \frac{w_{u,t+1}^{PL} \hat{P}_{u,t+1}^{PL} + w_{u,t+1}^{TS} \hat{P}_{u,t+1}^{TS}}{w_{u,t+1}^{PL} + w_{u,t+1}^{TS}}, \quad (9)$$

$$V[\hat{P}_{u,t+1}] = \frac{1}{w_{u,t+1}^{PL} + w_{u,t+1}^{TS}}, \quad (10)$$

ここで  $w_{u,t+1}^m = 1/V[\hat{P}_{u,t+1}^m]$  ( $m = PL, TS$ ) はそれぞれのモデルのウェイトです。  $V[\hat{P}_{u,t+1}^{TS}]$  は式 (8) により評価し、  $V[\hat{P}_{u,t+1}^{PL}]$  は付録 B.2 に示すブートストラップ手続きで評価します。

## 1km メッシュレベルの挙動

都市内部の人口分布を予測するために、1km メッシュ単位の人口変化も、以下のように都市レベルと同様の、ARI1, ARI2, LL モデルを使います。  $i$  は 1km メッシュのインデックスです。

### ARI1: ARIMA(1,1,0) モデル

$$\Delta p_{i,t+1} = \rho_i \Delta p_{i,t} + \epsilon_{i,t}^{ARI1}, \quad \epsilon_{i,t}^{ARI1} \sim N(0, \sigma_{i,ARI1}^2) \quad (11)$$

### ARI2: the ARIMA(2,1,0) モデル

$$\Delta p_{i,t+1} = \rho_{1,i} \Delta p_{i,t} + \rho_{2,i} \Delta p_{i,t-1} + \epsilon_{i,t}^{ARI2}, \quad \epsilon_{i,t}^{ARI2} \sim N(0, \sigma_{i,ARI2}^2), \quad (12)$$

### LL: 対数線形モデル

$$p_{i,t+1} = a_{i,0}^{LL} + a_{i,1}^{LL} \log(t+1) + \epsilon_{i,t}^{LL}, \quad \epsilon_{i,t}^{LL} \sim N\left(0, \frac{\sigma_{i,LL}^2}{t^2}\right). \quad (13)$$

4) さらに、2020 年までの観測値と 2025 年以降の予測値がスムーズに移行するように、係数の推定は、2020 年時点の予測値と観測値が一致するよう制約して行います。

空間相関モデル 都市は定義上境界を接していませんし、基本的にはある程度の距離をおいて形成されます。しかし、多くの 1km メッシュは連続して人が居住しています。周囲を人口が大きいメッシュに囲まれた 1km メッシュは、相対的に人口が大きくなり、近隣メッシュ間で人口が相関します。この効果を反映するために、個々の 1km メッシュ  $i$  と境界が接するメッシュの合計人口  $q_{i,t}$ (図 4 参照) の変化について、ARI1, ARI2, LL モデルを推定して、各  $t$  期の近隣メッシュ人口  $\hat{q}_{i,t}$  を得て、その定数倍としてメッシュ  $i$  の人口を予測するモデルを含めます：

$$p_{i,t} = b_i \hat{q}_{i,t} + \epsilon_{i,t}, \quad \epsilon_{i,t} \sim N(0, s^2). \quad (14)$$

ARI1, ARI2, LL、それぞれのモデルで得られた近隣メッシュ人口を用いるモデルを、 $ARI1_N, ARI2_N, LL_N$  と表します。




図 4. 近隣メッシュ間の相関の反映

**1km メッシュ時系列 (TS) 統合モデル** メッシュ  $i$  の  $t$  期の予測人口は  $\hat{p}_{i,t}^{TS}$  は、ARI1, ARI2, LL モデルと、それらの空間相関モデル、 $ARI1_N, ARI2_N, LL_N$ 、を合わせた 6 つのモデルによる予測値の加重平均として得られます：

$$\hat{p}_{i,t}^{TS} = \frac{\sum_m w_{i,t}^m \hat{p}_{i,t}^m}{\sum_m w_{i,t}^m}, \quad V[\hat{p}_{i,t}^{TS}] = \frac{1}{\sum_m w_{i,t}^m} \quad (15)$$

ただし、 $w_{i,t}^m$  は、モデル  $m$  の  $t$  期におけるウェイトであり、 $V[\hat{p}_{i,t}^{TS}]$  は予測人口  $\hat{p}_{i,t}^{TS}$  の分散です。

### 3 予測の手続き

予測は、準備段階（Step 0）を含め 4 段階あります（図 5 参照）。

**Step 0** パラメータ推定 準備段階では、採用したモデルのパラメータを推定し、モデルを確定します。用いるデータは 1970～2020 年（5 年ごと）の国勢調査地域メッシュ統計（総務省統計局，2020）から得られる、日本の国土を 1km メッシュに分割した各メッシュの人口です。

- i. 都市の定義「人口密度が 1,000 人/km<sup>2</sup> 以上、総人口が 1 万人以上の連続した 1km メッシュの集合」に従って、各時点の都市を検出します。このように都市を定義すると、個々の都市の範囲が広がったり狭まったり、一つの都市が分裂して複数になったり、新たに都市が生まれたり、既存の都市が消滅したりします。過去から未来にわたって個々の都市の盛衰を評価するためには、異時点間で一貫した都市の同定が必要です。この予測においては、異時点間の都市の地理的範囲の重複と、そこに含まれる人口に基づいて、各時点でどの都市が既存の都市で、どの都市が分裂等で新たに生まれた都市なのかを判定しています（詳しくは付録 A 参照）。
- ii.  $t = 1, 2, \dots, 11$  の都市を同定したら、これら 11 時点のデータを用いて、1km メッシュレベルの 6 種の時系列モデル、都市レベルの 3 種の時系列モデル、および、べき乗則モデルのパラメータを推定し、1km メッシュおよび都市の人口予測を行う複合モデルを構築します。

**Step 1** 期先の人口予測 1km メッシュ複合モデル・都市複合モデルを用いて、 $t \geq 11$  期の人口を与件として  $t + 1$  期の人口を予測します。具体的には、 $t = 11$ （2020 年）の人口を与件として  $t = 12$ （2025 年）を予測し、次に  $t = 12$  期の人口を与件として  $t = 13$ （2030 年）を予測する、と順次 5 年先の人口を予測していきます。

ただし、1970～2020 年に存在しなかった都市については、時系列モデルを推定できないため、べき乗則モデルのみを用いて予測します。

**Step 2** 地域レベル間の人口調整 1km メッシュと都市を個別に予測すると、1km メッシュ・都市・都市化率・全国人口の間で人口の整合性が崩れますので、**Step 2** ではこの整合性を回復します。具体的には 2 段階に分けて調整します。第 1 に、与件としている全国人口・都市化率と都市人口が整合するように、都市人口と農村人口をそれぞれ定数倍して調整します。第 2 に、個々の都市について、都市モデルが予測した人口と、その都市に含まれるメッシュの合計人口が一致するように、メッシュ側の人口を比例倍して調整します。

**Step 3** 都市再検出 地域レベル間の人口調整後の都市は、都市の 3 条件を満たしていない可能性がありますので、ここで改めて都市を再検出します。

**Steps 1-3** を繰り返すことで、2025 年以降の個々の都市および 1km メッシュの人口を順次予測していきます。

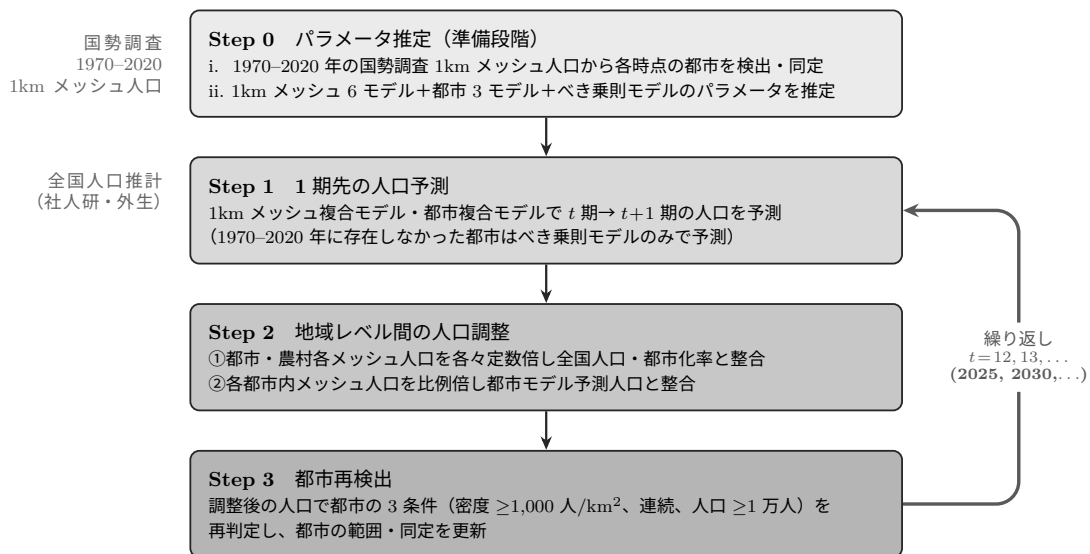


図 5. 予測の手続き

## 4 誘導系モデルの長所と短所

本稿で紹介した予測モデルは、第 3・4 話で紹介した都市形成の理論モデルのミクロな構造（世帯や企業の行動）を省き、マクロな構造（都市の大小と配置）を規定する秩序をシンプルな統計モデルで表現しています。ミクロ構造を省きつつも、輸送・交通費用や人口など経済の前提が変化したときに、都市人口分布などのマクロ構造がどのように変化するかは、背景にある理論モデルから想定することができます。このようなモデルを元の理論モデルの「誘導系」と呼びます。

一方、世帯や企業などミクロな主体の行動から積み上げた仮想経済の中で、日本地図上に現実の都市群を再現するモデルを構造モデルと呼びます。構造モデルでは、都市人口分布の回転や下降といった地域経済のマクロ構造の変化が、経済の与件の変化に伴うミクロな主体の行動の変化の結果として説明されます。誘導系モデルと構造モデルは、それぞれに利点と欠点を持ち、補完的な関係にあります。

まず誘導系モデルの利点を考えてみましょう。人口集積としての都市に関しては、そもそもマクロ構造が非常にシンプルな秩序で特徴づけられるという事実が、誘導系モデルの利点を際立たせます。秩序とは、各地域レベルで都市人口分布がおおよそ同じべき乗則に従うことでした。人口の地理的分布の変化を都市を介して見れば、その変化は常に、このべき乗則を伴うフラクタル的な構造を維持しながら起こります。今後予想される物流の自動化や通信技術の高度化、人口減少、少子化などの構造変化の多くは、大都市、とりわけ東京へ向かう集中をもたらします。都市人口分布がべき乗則に従う下でこのような単調性が見込まれることが、構造変化を予測に反映することを容易にします。都市人口分布が単調に時計回りに回転しながら下降する状況を、一定のシナリオの下で具体的に計算すれば、全国そしてローカルな地域のマクロ構造の変化と整合する個々の都市の将来の

姿を見通すことができるからです。

一方、個々の都市は面積を持ち、都市の人口はその上に分布しています。都市内部の人口の地理的分布は都市によってそれぞれ異なる変化を示します。しかし、都市レベルの挙動を誘導系モデルで捉えるならば、1km メッシュの解像度で行う予測を、まず数百の都市に集計したレベルで見通しを立てることができます。その上で、個々の都市内部の人口分布の変化を予測すればよいのです。それでもなお自由度はありますが、都市の総人口が決まっている下では、過去の個々の 1km メッシュ人口の変化過程を時系列モデルで捉えて外挿するシンプルな予測を用いても、大きくは外れないと考えます。それは、第 2 話で述べたように、交通・通信アクセスの向上は基本的に都市内の人口分布を都心から郊外へ単調に分散させる効果を持つこと、人口減少は人口密度を低下させる効果を持つことなど、期待される変化のパターンが都市内部でもおおよそ単調であると考えられるからです。<sup>5)</sup>

このように誘導系モデルでは、シンプルな統計モデルを組み合わせることで、ミクロレベルのメカニズムを捨象しても、単調な構造変化の下では構造モデルと整合する予測を立てることができます。これが最大の利点です。

誘導系モデルの欠点は、学習データにない効果については明確な予測ができないことです。例えば、中央リニア新幹線が東京・大阪間という限定的な区間に導入されたときに何が起るか、震災によって一部の交通網が寸断されインフラがダメージを受けた場合にその将来への影響はどのようなものか、そういった局所的に起こるショックの効果をシミュレートすることは、ごく暫定的にしかできません。

この欠点は、そのまま構造モデルの利点になります。理論化が可能である限り、学習データの無いショックについても予測に組み込むことができます。一方、誘導系モデルではすべての現存する都市についてその将来を予測することが可能ですが、構造モデルでは多くの場合、現実のすべての都市を地図上に再現することが（恣意的な方法に頼らない限り）できません。そしてなにより、本稿で紹介している誘導系モデルの対になる構造モデルを構築すること自体が（現在取り組み中ですが）きわめて困難です。このように、誘導系モデルと構造モデルは利点と欠点がおおよそ逆になっており、補完的です。

最後に、理論化できないメカニズムは、いずれのモデルにも組み込むことができないため、説明可能な限界についても認識しておく必要があります。具体的には、本予測モデルには、地域経済の将来予測において大変重要な人口の年齢構成の効果が含まれていません。これは、年齢構成を適切に組み込むだけの理論モデルが未完成であり、どのような誘導系が考えられるのかが不明だからです。この側面については、まず理論モデルを構築することから始める必要があります。各都市の人口の年齢構成の変化はその都市の持続可能性にも深く関わりますので、非常に重要ですが、まずは背景理論が明確な、年齢構成を含まない人口のみの予測を行います。

---

5) 2002 年の都市再生特別措置法以降、大都市を中心に都心回帰の傾向が顕著になったことで、2020 年付近の傾向を強調して学習する Mori and Murakami (2025) の予測では、特に大都市で都心回帰傾向が将来も継続すると仮定した予測となっています。このため、将来の都心回帰傾向は過大評価されている可能性があります。

## 5 むすび

以上が都市盛衰予測モデルの概要です。このモデルを用いて、2200年という一見はるかに遠い将来までの予測を行います。社人研によるシナリオの中で最も現実的と思われる「出生率低位・死亡率中位」の下では、2200年頃の人口は約900万人、出生数は年間約3万人で、ほとんど子どもがいない社会になっているはずで、2200年は遠すぎる不確かな未来で、今からそんな先のことを考えても無駄だと思われるかもしれません。しかし、出生率が回復する見通しのない現在の延長線上では、その頃には日本の消滅が現実味を帯びてくるでしょう。消滅も一つの選択肢ではあります。しかし、それを望まないのだとしたら、先延ばしにせずすぐにでも人口減少と向き合い、私たちはどうしたいのか、何をすべきなのか、議論を始める必要があります。この予測を改良を繰り返しながら、未完成のまま公開するのは、まさに今すぐ議論を始めるきっかけを作るための取り組みです。

少ないデータかつシンプルなモデルを用いた予測ですが、この予測モデルの核は、事実再現性に裏打ちされた経済集積理論と、都市集積パターンに明確に現れる秩序を予測の拠り所としている点にあります。1kmメッシュレベルの詳細については精度に欠ける部分が残ると思われませんが、全国の都市群が相互に関連した系を構成しつつ人口減少に伴って縮小していく過程については、大筋で具体的なイメージを提示できるのではないかと考えています。特に、総人口の減少予測だけではそのインパクトの大きさを実感できなくても、一人ひとりが住む、あるいは幼少期に育った街の行く末となると、その縮小のスピードを具体的に感じるができるでしょう。次話では、本稿で紹介したモデルを用いて日本の都市の盛衰を予測した結果について解説します。

## 参考文献

Mori, Tomoya and Daisuke Murakami (2025) “Sustainability of cities under declining population and decreasing distance frictions: The case of Japan,” arXiv:2505.08333.

Smith, Stanley K, Jeff Tayman, and David A Swanson (2002) *State and Local Population Projections: Methodology and Analysis*, The Springer Methods and Population Analysis: Springer Dordrecht.

国立社会保障・人口問題研究所 (2023) 「日本の将来推計人口 (全国)」, URL : [https://www.ipss.go.jp/pp-zenkoku/j/zenkoku2023/pp\\_zenkoku2023.asp](https://www.ipss.go.jp/pp-zenkoku/j/zenkoku2023/pp_zenkoku2023.asp).

総務省統計局 (2020) 「国勢調査地域メッシュ統計」.

# 付録

## A 都市集積

各時点  $t = 1, \dots, 36$  (1970 年、1975 年、…、2200 年に対応) における各都市集積 (UA) は、以下の条件をすべて満たす 1km メッシュの集合として定義される：(i) 人口密度が  $1\text{km}^2$  あたり 1,000 人以上であること、(ii) 地理的に連続していること、(iii) 合計人口が 10,000 人以上であること。UA の集合は各時点  $t = 1, \dots, 36$  ごとに更新される。各 UA の時系列的な追跡を可能にするため、以下の手順により、分析期間を通じて一意の識別子 (ID) を付与する：

1. 時点  $t = 1$  における UA の ID は、 $t$  時点の人口規模順位とする。人口規模が同一の場合は、平均人口密度の降順で順位を定める。
2. 時点  $t$  の UA と時点  $t + 1$  の UA が同一であるとみなされるのは、両者の領域の重複部分において、時点  $t$  の人口が最大となる組み合わせである場合とする (同順位が複数存在する場合は、重複部分における人口密度が最大である組を優先する)。この場合、時点  $t + 1$  の ID は時点  $t$  から引き継がれる。
3. 時点  $t$  の UA  $i$  が、時点  $t + 1$  の UA  $j$  との重複部分において時点  $t$  の人口が最大であるが、時点  $t + 1$  の UA  $j$  の重複部分における最大人口が  $i$  以外の時点  $t$  の UA に対応する場合、UA  $i$  は時点  $t + 1$  において UA  $j$  に吸収されたとみなす。
4. 時点  $t + 1$  の UA  $j$  が、時点  $t$  のいずれの UA とも重複しない場合、UA  $j$  は新規に形成された UA、または既存の UA から分離した UA とみなす。 $t$  より前の時点で前身を持たない新規 UA または分離 UA には、時点  $t + 1$  における人口規模の降順で新たな ID を付与する (同順位の場合は、平均人口密度が最も高いものを先に割り当てる)。
5. 時点  $t + 1$  において既存の UA から分離した UA が、時点  $t$  より前に前身を持つ場合は、最も直近の前身の ID を復元する。最も直近の前身が複数存在する場合は、当該 UA との重複部分における人口が最大のものを選択する (同順位の場合は、平均人口密度が最大の前身を選択する)。したがって、UA  $i$  が一度 UA  $j$  に吸収され、その後 UA  $j$  から分離した場合、再び  $i$  の ID が付与される。

## B 予測分散

複数の統計モデルを統合する際に用いる個別モデルのウェイトは、各モデルの予測誤差分散の逆数で与えられる。予測誤差分散とは、学習データに対するモデルフィットに基づいて算出された、将来時点で期待される予測誤差の分散である。

## B.1 都市レベルモデル

都市レベルの時系列モデルの統合において、 $t_0 = 12, \dots, 31$  期における AR1、AR2、LL モデルの予測分散は以下の通りである。

- AR1:  $V(\epsilon_{u,t_0}^{AR1}) = \hat{\sigma}_{u,AR1}^2 \frac{1-\hat{\rho}_u^{2t_0}}{1-\hat{\rho}_u^2}$ 、ただし、 $\hat{\sigma}_{u,AR1}^2 = \frac{\sum_{t=1}^{11} (\Delta P_{u,t+1} - \hat{\rho}_u \Delta P_{u,t})^2}{10-1}$ 。
- AR2:  $V(\epsilon_{u,t_0}^{AR2}) = \hat{\sigma}_{u,AR2}^2 \sum_{t=12}^{t_0} \psi_{u,t}^2$ 、ただし、 $\psi_{u,t}^2$  は  $\hat{\rho}_{1,u}$  および  $\hat{\rho}_{2,u}$  に依存するインパルス応答を表し、 $\hat{\sigma}_{u,AR2}^2 = \frac{\sum_{t=1}^{11} (\Delta P_{u,t+1} - \hat{\rho}_{1,u} \Delta P_{u,t} - \hat{\rho}_{2,u} \Delta P_{u,t-1})^2}{9-1}$ 。
- LL:  $V(\epsilon_{u,t_0}^{LL}) = \hat{\sigma}_{u,LL}^2 (1 + x'_{t_0} (X'WX)^{-1} x_{t_0})$ 、ただし  $X$  は第  $u$  行が  $[1, \log t]$  に等しい行列、 $x'_{t_0} = [1, \log t_0]$ 、 $W$  は対角要素が  $1, \dots, 11$  である対角行列であり、 $\hat{\sigma}_{u,LL}^2 = \frac{\sum_{t=1}^{11} (P_{u,t} - \hat{a}_{u,0}^{LL} - \hat{a}_{u,1}^{LL} \log t)^2}{11-1}$ 。

## B.2 全国・都市レベルのアンサンブル

$t+1$  期における分散  $V[\hat{P}_{u,t+1}^{PL}]$  は、以下のブートストラップ手続きにより評価する：

1. 各  $l \in \{1, \dots, 200\}$  について以下の手続きを繰り返す：
  - (a) 各  $t \in \{1, \dots, 11\}$  について、 $A_t^{(l)} \sim N(\hat{A}_t, V[\hat{A}_t])$  および  $B_t^{(l)} \sim N(\hat{B}_t, V[\hat{B}_t])$  を独立に抽出する。
  - (b)  $A_t^{(l)}$  に対して式 (2) を当てはめ、 $\hat{a}_1^{A(l)}$  および  $V[\hat{a}_1^{A(l)}]$  を推定する。同様に  $B_t^{(l)}$  を用いて  $\hat{a}_1^{B(l)}$  および  $V[\hat{a}_1^{B(l)}]$  を推定する。
  - (c)  $a_1^{A(l)} \sim N(\hat{a}_1^{A(l)}, V[\hat{a}_1^{A(l)}])$  および  $a_1^{B(l)} \sim N(\hat{a}_1^{B(l)}, V[\hat{a}_1^{B(l)}])$  を抽出する。
  - (d)  $P_{u,t}^l \sim N(\hat{P}_{u,t}, V[\hat{P}_{u,t}])$  を抽出する。ここで  $\hat{P}_{u,t}$  および  $V[\hat{P}_{u,t}]$  は式 (9) および式 (10) により評価する。
  - (e)  $a_1^{A(l)}, a_1^{B(l)}, P_{u,t}^l$  を式 (4) に代入し、 $P_{u,t+1}^{PL(l)}$  を評価する。
2.  $V[\hat{P}_{u,t+1}^{PL}] = \frac{\sum_{l=1}^{200} (P_{u,t+1}^{PL(l)} - \bar{P}_{u,t+1}^{PL})^2}{200-1}$  を評価する。ここで  $\bar{P}_{u,t+1}^{PL}$  は 200 回のアンサンブルの平均である。

## B.3 メッシュレベルモデル (近隣人口)

$ARI1_N, ARI2_N, LL_N$  の分散は、以下の手順で評価する。

1.  $ARI1, ARI2, LL$  モデルを適用して近隣の人口  $q_{i,t}$  を 2120 年まで予測し、標準的な手続きに従って期待値  $\hat{q}_{i,t}$  および分散  $V[\hat{q}_{i,t}]$  を求める。
2. 2020 年までの人口データを用いて式 (14) を推定し、係数の推定値  $\hat{b}_i$  およびその分散  $V[\hat{b}_i]$ 、ならびに誤差分散  $\hat{s}^2$  を求める。
3.  $t \in \{2025, \dots, 2120\}$  について、予測分散  $V[\hat{p}_{i,t}] = V[\hat{q}_{i,t} \hat{b}_i] + \hat{s}^2$  を評価する。ここで  $V[\hat{q}_{i,t} \hat{b}_i] = V[\hat{q}_{i,t}]V[\hat{b}_i] + \hat{q}_{i,t}^2 V[\hat{b}_i] + V[\hat{q}_{i,t}] \hat{b}_i^2$  であり、各要素は手順 (a) および (b) で評価したものである。