

因果効果分析による緊急事態宣言の介入効果に関する予備的研究

A Preliminary Study on Intervention Effect of Emergency Declaration by Causal Impact Analysis

渡邊 泰典

Yasunori Watanabe

要旨: 2019年に発見された新型コロナウイルス感染症 (Covid-19) は変異を繰り返しながら、2022年現在でも猛威を振るっている。この感染症の流行を防ぐために、日本政府は東京都における緊急事態宣言を過去4回発令した。本稿では東京都における新型コロナウイルス感染症の陽性者数のデータを使い、緊急事態宣言の発令が陽性者数の変化に与えた影響を因果効果分析を用いて分析する。因果効果分析はベイズ構造時系列モデルを使って仮想的なデータを作成し、実際の観測データと比較することで一時的な介入の効果を推定する手法である。この手法を緊急事態宣言の分析に実際に応用することで、実用上の課題について検討する。

キーワード: 因果効果分析、ベイズ構造時系列モデル、Covid-19、緊急事態宣言

Abstract: Coronavirus disease (Covid-19), a new type of coronavirus infection discovered in 2019, has repeatedly mutated and is still raging as of 2022. The Japanese government has declared a state of emergency in Tokyo four times to prevent an outbreak of this infectious disease. In this paper, I will study the impact of the emergency declaration on the number of positive cases using causal impact analysis with the data on the number of positive cases of Covid-19 infection in Tokyo. Causal impact analysis is a method for estimating the effects of temporary interventions by creating hypothetical data using a Bayesian structural time-series model and comparing them with actual observed data. By applying this method to the analysis of emergency declarations, I will discuss practical issues with it.

Keywords: Causal Impact Analysis, Bayesian Structural Time-Series Model, Covid-19, Emergency Declaration

1. はじめに

2019年末から世界的に流行している新型コロナウイルス感染症 (Covid-19) は、2022年10月現在となっても依然として大きな社会的な問題となっている。今後、経済・社会活動と感染症の拡大防止を両立させていくためには、様々な政策手段の効果を検討する必要がある。そのためには過去発令された緊急事態宣言についても、その効果を分析する必要があるだろう。

東京都においては過去4回緊急事態宣言が発令されている。

- 2020年4月7日発令、2020年5月25日解除
- 2021年1月8日発令、2021年3月21日解除
- 2021年4月25日発令、2021年6月20日解除
- 2021年7月12日発令、2021年9月30日解除

本稿では2020年4月7日に発令された第1回の緊急事態宣言に注目し、これがどの程度東京都の陽性者数を減らすことができたのか推定することを試みる。

緊急事態宣言の発令による介入効果を推定するためには、介入がなかった場合の陽性者数を推定し、これを実際の陽性者数と比較する必要がある。介入がなかった場合というのは現実には起こらなかったことであるから、これは仮想的な状況を推定することになる。こうした一時的な介入の効果を時系列データを用いて推定する手法として Brodersen et al. (2015) が提案する因果効果 (Causal Impact) 分析を使い、その性質について検討する。

2. データおよび分析手法

新型コロナウイルス感染症の新規陽性者数は厚生労働省 (2022) で公表されているデータを使い、東京都の数値のみを抽出して用いた。今回の分析対象はいわゆる第一波 (2020年4月～5月) であることから、データの範囲は2020年3月1日から2020年5月31日とした。この期間の東京都における1日あたり新規陽性者数の概要は表1の通りである。

表1：1日あたり新規陽性者数の要約

最小値	第1四分位点	中央値	平均値	第3四分位点	最大値
0	7.75	25	56.46	98.50	204

図1には1日あたりおよび週あたり新規陽性者数を示した。2020年3月後半から陽性者数が増え始め、4月7日の緊急事態宣言の発令後にピークを迎え、5月の後半には感染の拡大が止まっている様子が確認できる。

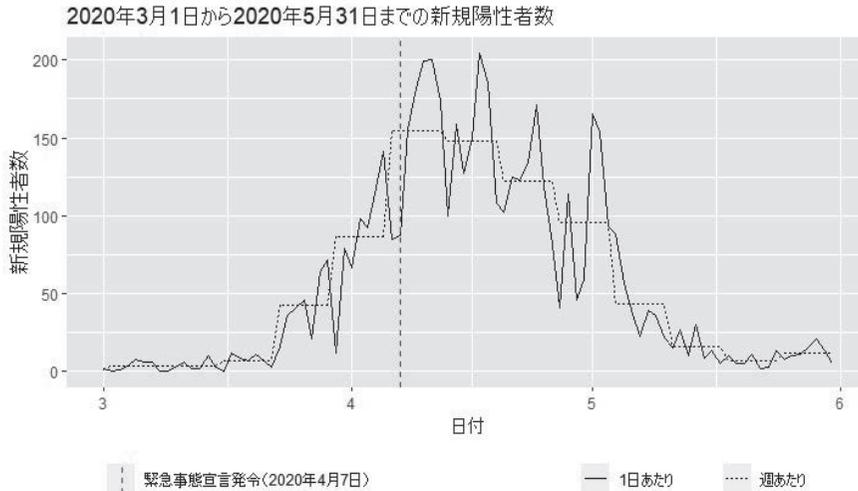


図1：新規陽性者数

緊急事態宣言の発令による感染拡大抑止効果の推定は、以下の2段階で行う。第一に、Scott and Varian (2014) のベイズ構造時系列 (Bayesian Structural Time-Series, BSTS) モデルによって新規陽性者数のデータをモデル化する。次に、このモデルを用いて Brodersen et al. (2015) の因果効果 (Causal Impact) 分析を行い、緊急事態宣言の発令がなかった場合の仮想データと実際のデータのギャップを計測する。

ベイズ構造時系列モデルは、時系列データをモデル化する際に、観測可能な時系列に加え、隠れた状態変数を含む状態空間モデルの一種である。状態空間モデルを用いることで、トレンドや季節性といった観測データそのものから得られる性質だけでなく、他の変数の影響を含む構造をモデル化することが可能になる。例えば、ある製品の特定の地域での売上をモデル化するにあたって、観測された売上データそのものから得られるトレンドや季節性だけでなく、各観測時点での可処分所得や他地域での売上データなどによる回帰要素を含むことができる。

状態空間モデルの各パラメータをベイズ的手法によって推定することを提唱したのが Scott and Varian (2014) である。彼らのモデルでは説明変数が多い場合を想定し、“spike-and-slab”型の事前分布から出発する。これは連続変数である回帰係数 β の事前分布を、各要素が0となる確率 (probability) が正となるような確率関数と、回帰係数 β の定義域上の確率密度関数 (probability density function) の積とするものである。例えば、 γ を $\beta_i = 0$ のとき $\gamma_i = 0$ 、 $\beta_i \neq 0$ のとき $\gamma_i = 1$ となるようなベクトルとし、 β_γ を $\beta_i \neq 0$ ($\gamma_i = 1$) となる β の部分集合であるとする、 “slab-and-spike” 型の前分布はベルヌーイ分布の確率関数 $f(\gamma)$ と、多変量正規分布の確率密度関数 $g(\beta_\gamma|\gamma)$ の積 $g(\beta_\gamma|\gamma) \cdot f(\gamma)$ として構成することができる¹。

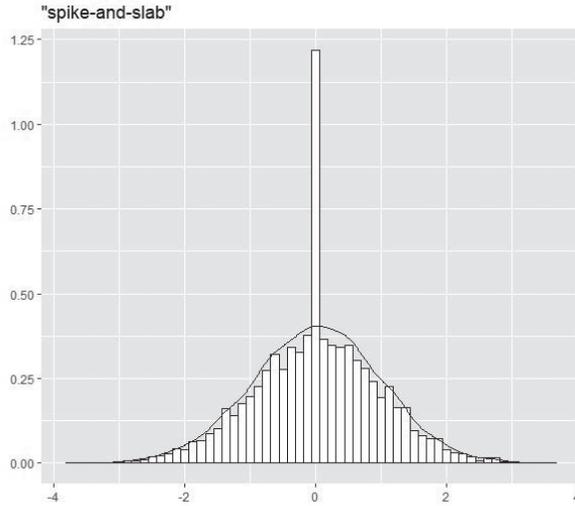


図 2 : “Spike-and-slab”

実際にベルヌーイ分布の成功確率を $p = 0.9$ 、スラブを標準正規分布として 5000 回のランダムサンプリングを行った結果が図 2 である。このような事前分布を用いることで、いくつかの説明変数をモデルから落とし ($\beta_i = 0$ とする) つつ、シミュレーションによって観測データの事後分布をベイズ更新によって計算することで推定量を得ることになる。

Brodersen et al. (2015) の因果効果分析は、BSTS による時系列分析に差分の差分法 (difference-in-difference, DD) による統計的因果推論の考え方を組み合わせた分析方法である。差分の差分法とは、ある介入による統計的効果を測定するときの考え方の 1 つである。通常、ある介入の統計的効果を測定するには、事前にランダムサンプリングを用いた実験設計を行うのが定石であるが、現実的にはそのような実験設計が行われていないデータを用いなければならないこともある。その場合に問題となるのは、処置群 (treatment group) と対照群 (control group) の間で群のそもそもの性質に違いが生じる場合である。

例えば、ある教材を用いた場合の成績向上効果を測定したいものとする。教材を用いる前の成績を Y_i^0 、教材を用いた後の成績を Y_i^1 とし、教材を採用しない対象群については $i = c$ 、教材を採用する処置群については $i = t$ とする。加えて、実際に教材を使った場合を $T = 1$ 、使わなかった場合を $T = 0$ と表す。このとき、処置群で実際に教材を採用することによる効果は期待値 $E[\cdot]$ によって $E[Y_t^1|T = 1] - E[Y_c^1|T = 0]$ と計算できる。ここで $E[Y_c^1|T = 0]$ は処置群において実際には教材を使わなかった場合の成績を表しているが、これは処置群の定義上観測できない。もし教材を使用する学生をランダムサンプリングで選ぶことができれば、処置群と対照群で事後においても成績に違いがなく ($E[Y_t^1|T = 0] = E[Y_c^1|T = 0]$)、教材を使用することによる効果を $E[Y_t^1|T = 1] - E[Y_c^1|T = 0]$

として計算することができる。

ところがランダムサンプリングで学生を選べない場合には、処置群と対称群の均質性が保証されないため、対照群のデータで処置群のデータに代えるということができなくなる。そのため、対照群と処置群で事前に存在する差 $E[Y_t^0] - E[Y_c^0]$ が事後的にも存在する ($E[Y_t^1|T=0] - E[Y_c^1|T=0] = E[Y_t^0] - E[Y_c^0]$) と考え、教材を用いることによる効果を

$$E[Y_t^1|T=1] - E[Y_c^1|T=0] = E[Y_t^1|T=1] - E[Y_c^1|T=0] - (E[Y_t^0] - E[Y_c^0])$$

として差分の差分を計算するのが DD 法の基本的な考え方である。

因果効果分析においては、介入前のデータを用いて BSTS モデルを推定し、他の共変量との関係 (差) が介入後も存在すると仮定して介入がなかった場合の仮想的なデータを予測する。そのようにして予測されたデータを実際の介入後の観測データと比較し、介入による効果を分析するものである。

3. 分析結果および考察

本稿の分析の目的は新型コロナウイルス感染症の流行第 1 波における緊急事態宣言の発令 (2020 年 4 月 7 日) の効果を推定することである。以降の分析は R Core Team (2022) による統計解析言語 R を使い、bsts パッケージと CausalImpact パッケージを用いて行った。

第一段階は bsts パッケージを用いた時系列モデルの推定である。データ範囲は 2020 年 3 月 1 日から緊急事態宣言の発令前の 2020 年 4 月 6 日とする。BSTS モデルの推定に当たっては、新規陽性者数には曜日による変動の影響が大きいと考えられることから、トレンドと季節性項のみで構成されるモデル 1 とモデル 1 に自己回帰 (Autoregression, AR) 項を加えたモデル 2 を推定し、比較検討することにする。

モデル 2 の準備として新規陽性者数の観測データの自己相関関数 (Autocorrelation Function, ACF) と偏自己相関関数 (Partial Autocorrelation Function, PACF) を確認しておく。図 3 と図 4 は ACF プロットと PACF プロットをそれぞれ表している。ACF は t 時点の変数 y_t とその k 期前の変数 y_{t-k} の間の相関係数を k の関数とみなしたものの、PACF は t 時点の変数 y_t とその k 期前の変数 y_{t-k} の間の相関係数を、 t 時点と $t-k$ 時点の間の変数に依存しないように条件付けて求めたものとなる。

図 3 より、 t 時点の新規陽性者数は過去 10 日程度のデータとは正の相関関係を示す一方で、それより以前のデータとは負の相関関係を示しており、これはこの時系列が振動していることを意味している。図 4 ではラグが 7 日のところで偏相関係数が大きくなっていることが読み取れる。以上を踏まえると、AR 項を含んだモデル 2 を推定する際には 14 期前までのラグ変数を含むモデル化を考えることとする。

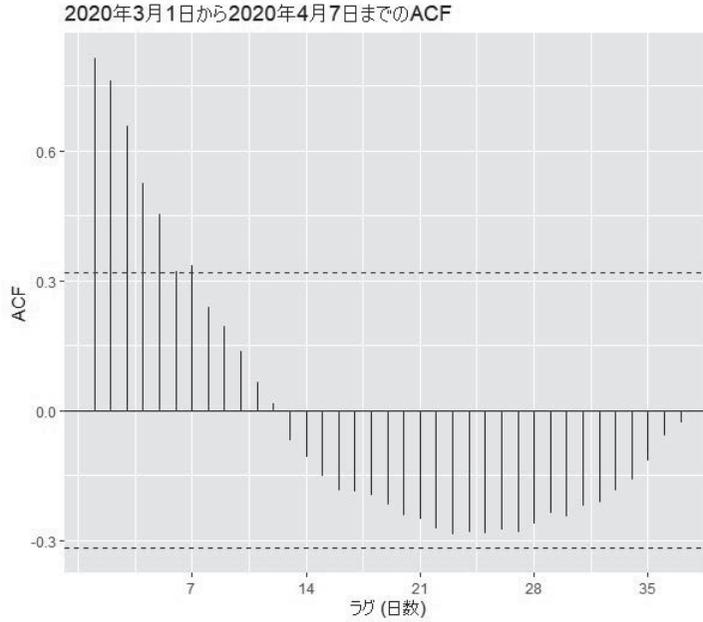


図 3：自己相関関数

モデル化においては、被説明変数そのものではなく、その対数値を用いることとした。すなわち、もとの被説明変数を y_t とすると、実際に推定に用いた被説明変数は $Y_t = \log(y_t + 1)$ である²。図 5 には対数値に変換した新規陽性者数の推移を示した。

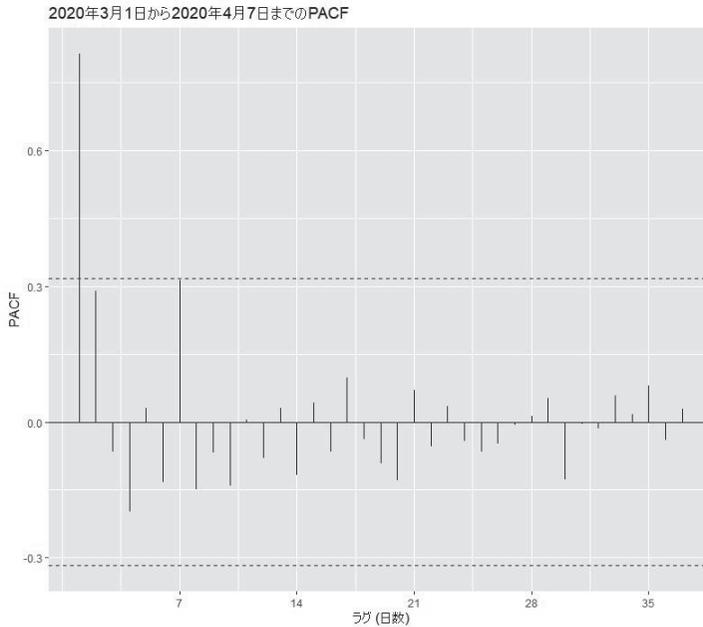


図 4：偏自己相関関数

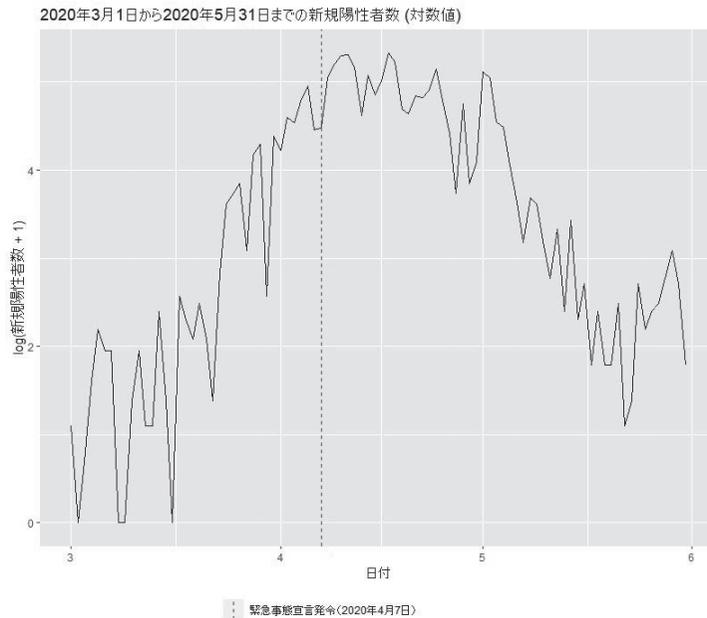


図 5：新規陽性者数の対数値

実際に 2020 年 3 月 1 日から 2020 年 4 月 7 日までのデータを用いて、以下のモデル 1 とモデル 2 を推定した。

1. モデル 1：トレンド項 + 季節性項 (曜日)
2. モデル 2：トレンド項 + 季節性項 (曜日) + 自己回帰項 (14 日)

モデルによる当てはめと累積誤差をプロットしたものが図 6 である。下半分に実際の被説明変数の推移、上半分にはモデル 1、モデル 2 それぞれの累積誤差が描かれている。この図からはモデル 2 の方がモデル 1 と比べて累積誤差が少ないことがわかるため、以降の分析ではモデル 2 を採用する。

図 7 はモデルの各要素の変動を描いている。上段より、自己回帰項、季節性項、トレンド項である。縦軸は対数値ではなく通常のスケールに戻しているため、トレンド項 \times 季節性項 \times 回帰項 = 陽性者数の推定値 + 1 が成立する。実際にこれにしたがって陽性者数の推定値を計算し、観測値と比較したものが図 8 である。図 8 からは陽性者数が急増するにしたがって誤差が大きくなる様子が観測できる。

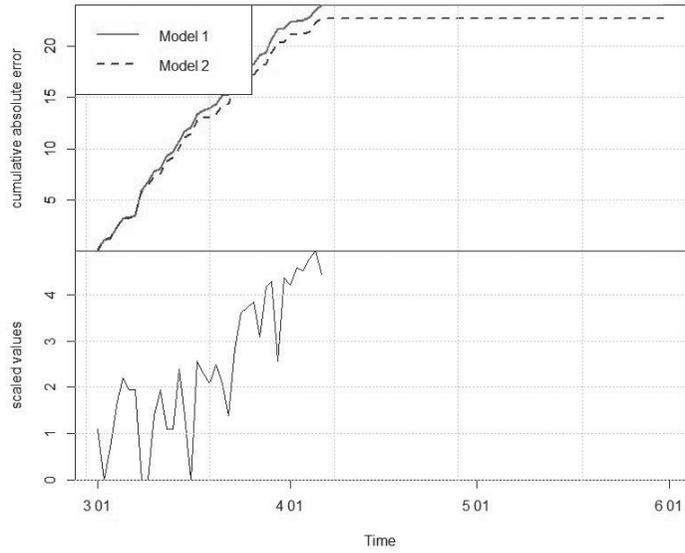


図 6：モデル 1 とモデル 2 の比較

CausalImpact パッケージでは、bsts パッケージで推定したモデルを指定する必要がある。ここでは緊急事態宣言の発令を介入として考え、緊急事態宣言の発令前の観測値に対してフィットしたモデルを使い、緊急事態宣言の発令がなかった場合の仮想データを予測する。

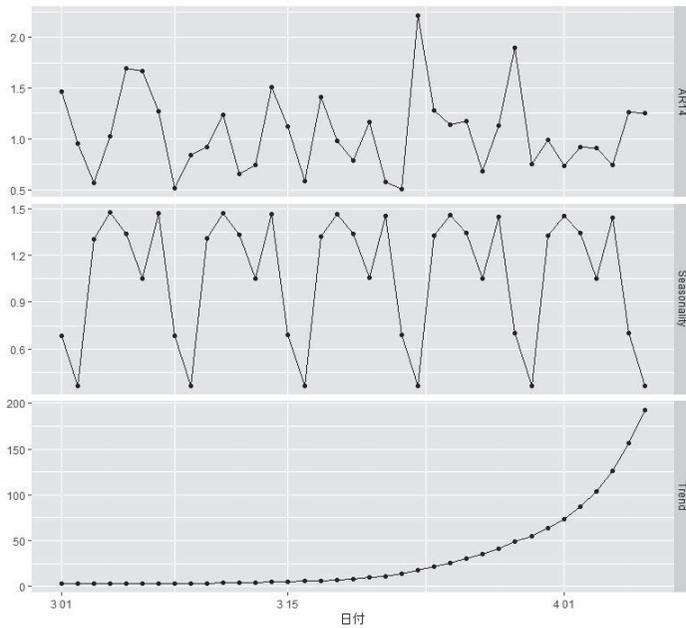


図 7：モデル 2 の各要素

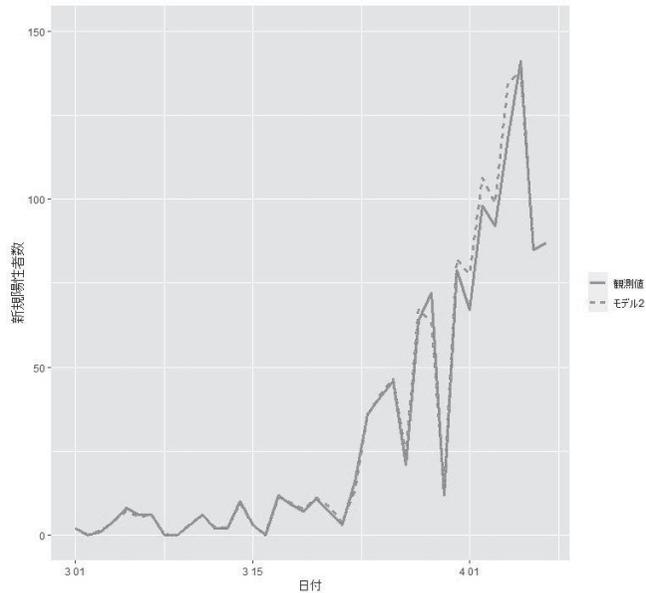


図 8：モデル 2 と観測値の比較

この仮想データと実際の観測データを比較することで介入の効果を推定できることになる。

仮想データと実際の観測データの比較を図 9 と図 10 に示した。図 9 は対数値による比較であり、図 10 は原数値に直した比較である。図 11 には仮想データと実際の観測データの差 (実際の観測データ - 仮想データ) を原数値によって計算し介入効果の推定値として示した。

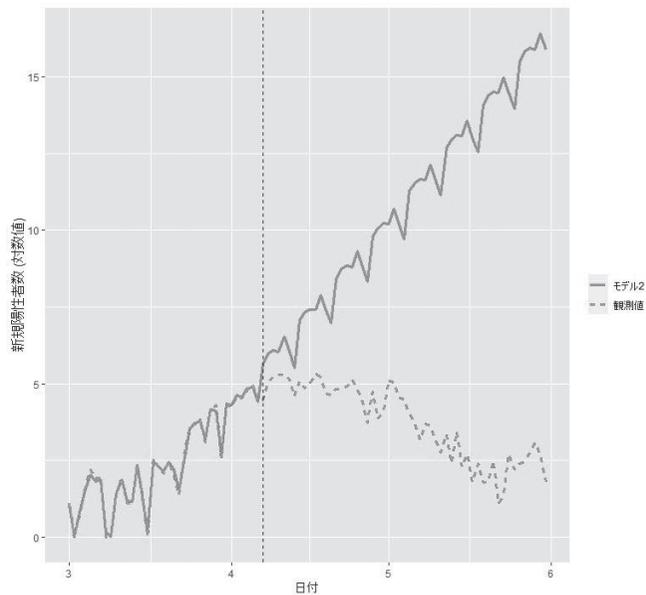


図 9：仮想データと観測データ (対数値)

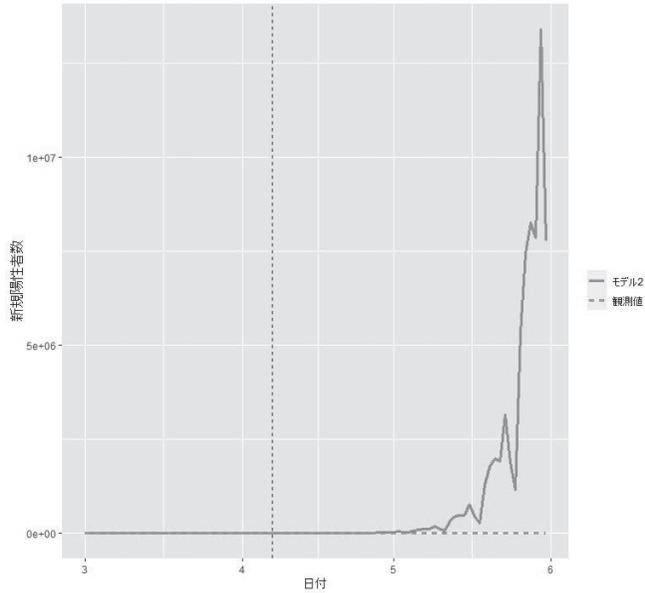


図 10：仮想データと観測データ

表 2 には緊急事態宣言が終了した 2020 年 5 月 25 日の段階での観測値と推定値を対数値と原数値の両方で示してある。実際の陽性者数が 8 人に対して推定値は 1,149,729 人となっており、介入がない場合には陽性者数がピークアウトすることなく指数的に増加することが予想された結果の数値となっている。しかし、いくつかの観点からこの数値をそのまま利用することが妥当とは言い難いと考えられる。

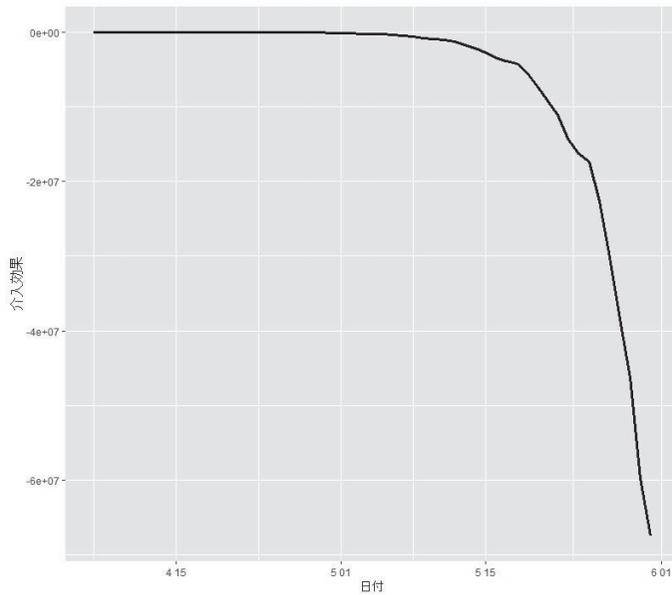


図 11：介入効果

表 2：2020 年 5 月 25 日時点での数値

	観測値	推定値
対数値	2.197	13.96
原数値	8	1,149,729

第一に、感染症流行のメカニズムそのものの性質がある。今回の分析では感染症の流行が緊急事態宣言の発令等の介入なしにはピークアウトしない、という仮定の下で仮想データを作成した。しかし実際には感染の拡大にともない、感染者の活動量の低下、集団免疫の獲得、人々の自主的な活動制限など、感染の拡大速度を緩めるような要因がいくつも考えられる。こうした感染拡大のメカニズムそのものはここでは明示的にはモデル化されていないため、感染拡大期の傾向をそのまま延長した推定では過剰推定になる可能性がある。

第二に、推定期間の問題が考えられる。第一の問題とも関連するが、回帰モデルを推定するためのデータ量に比べて予測をする期間が長くなる場合、予測の妥当性はどうしても下がらざるを得ない。より精度の高い分析を行うためには、緊急事態宣言の期間全体を通じた効果を推定するよりも、発令直後における効果を分析するなどの工夫が必要であろう。

第三は因果効果分析の性質にもとづくものである。Brodersen et al. (2015) で議論されているように、精度の高い仮想データを作成するためには、(i) 被説明変数との関連が強く、(ii) 介入によっては影響を受けず、(iii) 介入前と介入後で被説明変数との関係が変わらない、ような共変量をできるだけ多く見つける必要がある。彼らはこの点を説明するために、ある製品の販売プロモーションを例にとり、プロモーションを行っていない地域の変量をそのような共変量として扱うことを提案した。今後の分析ではそのような共変量をモデルに組み込むことが必要となるだろう。

4. 終わりに

本稿では、東京都における新型コロナウイルス感染症の陽性者数を題材とし、因果効果分析による緊急事態宣言の介入効果の推定を試みた。すでに議論したように、いくつかの理由で今回の推定量は不十分なものと考えられるが、今回のモデルを発展させるためには陽性者数の仮想データを作成するために必要となる共変量を検討することがまずは必要となるだろう。

新型コロナウイルス感染症の流行に関連して利用可能なデータとしては、例えば内閣官房新型コロナウイルス等感染症対策推進室 (2022) が公表している人流データなどもあるが、これは因果効果分析で役に立つ共変量とはならない。確かに人々の活動量は新型コロナウイルス感染症の流行と関連はしているが、これも緊急事態宣言によって影響を受けてしまうため、仮想データを作成するために必要な介入がなかったとしたら何が起こるかを

知る参考にはならないのである。

現状で利用可能なデータから、望ましい条件を満たすものを見つけることを当面の課題としたい。

注

- ¹ 実際には正規分布のパラメータ σ^2 などに関する事前分布も必要となるが、ここでは省略している。
- ² 予測値の信頼区間を構成する際に陽性者数の下限が負値になることを防ぐためである。また陽性者数が 0 であると、 $\log 0 = -\infty$ となり処理が煩雑であることから陽性者数に 1 を加えてから対数値としている。

参考文献

- 厚生労働省 (2022) 「データからわかる - 新型コロナウイルス感染症情報 -」
(<https://covid19.mhlw.go.jp/>, 2022 年 10 月 20 日アクセス)
- 内閣官房新型コロナウイルス等感染症対策推進室 (2022) 「新型コロナウイルス感染症 (COVID-19) の対応について」
(<https://corona.go.jp/dashboard/>, 2022 年 10 月 20 日アクセス)
- Brodersen, K. H., F. Gallusser, J. Koehler, N. Remy, and S. L. Scott (2015) “Inferring Causal Impact using Bayesian Structural Time-Series”, *The Annals of Applied Statistics*, Volume 9, Issue 1, pp. 247-274.
- R Core Team (2022) *R: A Language and Environment for Statistical Computing*, R Foundation for Statistical Computing, Vienna, Austria, <https://www.R-project.org>.
- Scott, S. L., and H. Varian (2014) “Predicting the Present with Bayesian Structural Time Series”, *International Journal of Mathematical Modelling and Numerical Optimisation*, Volume 5, Issue 1-2, pp. 4-23.