

2016年熊本地震による 交通人身事故増加の分割時系列分析

富永 凌太郎¹・円山 琢也²

¹学生会員 熊本大学大学院自然科学教育部土木建築学専攻 (〒860-8555 熊本県熊本市中央区黒髪 2-39-1)

²正会員 熊本大学准教授 くまもと水循環・減災研究教育センター

(〒860-8555 熊本県熊本市中央区黒髪 2-39-1)

E-mail: takumaru@kumamoto-u.ac.jp (Corresponding Author)

地震などの大規模災害直後は、ストレスが多い状況下での運転を余儀なくされることによる交通事故リスクの増加が懸念される。2016年熊本地震に関して先行研究では物損事故の増加が分析されているが、人身事故は検討されていない。本研究は熊本地震が熊本市の交通人身事故件数へ及ぼした影響を分割時系列分析で明らかにする。分析方法として多様なモデルを適用し、結果の違いも考察する。その結果、熊本市における最良モデルの結果では、地震により人身事故が758件増加し、1.16倍(95%信頼区間: 1.11, 1.21)になっていることが示された。また地震の影響が少ない福岡市での分析との比較から、熊本市の交通人身事故の増加が震災の影響に起因する可能性が高いことを確認した。

Key Words: Interrupted time series analysis, traffic accidents, the 2016 Kumamoto earthquake

1. はじめに

(1) 本研究の背景と目的

近年日本では、地震や豪雨、台風といった大規模災害が発生している。このような災害直後は建物や道路の崩壊により交通環境が悪化し、ボランティアや支援物資輸送など多様な目的の交通に限られた道路空間に集中する。また災害前に比べ、災害後は運転者に精神的な負荷がかかる状況が増えるため、ストレスをより抱えた状態での運転になる。以上により災害後は交通事故が増加しうる。2016年に発生した熊本地震に関して既報¹では、熊本県における物損事故への影響を分析し、市町村単位の影響期間を算出し、地震による被害との関係や物損事故の増加傾向を示した。しかしながら熊本地震後の死傷者を伴う交通事故の変化を検討した研究はない。また物損事故だけでなく、大規模災害後の死傷者を伴う交通事故の実態を分析することは災害後の全体的な交通実態を把握する上で必要である。

本研究では、上記のような背景から熊本地震による熊本市の交通人身事故への影響を分割時系列分析 (Interrupted Time series analysis; ITS) を利用し明らかにすることを目的とする。またITSには多様なモデルが存在するため、様々なモデルを適用し、モデルによる違いを考察することも目的とする。これらの研究成果は、今後の災害後の

交通安全対策の策定に役立つことが期待される。

(2) 本研究の構成

本研究の構成は以下の通りである。まず、2章にて様々な地震や感染症による交通事故件数への影響に関する分析、ITSに関する研究などの既往研究のレビューを行い、本研究の位置づけを述べる。3章では、本研究で用いるITSの概要を述べ、具体的な推定方法を述べる。4章では、分析対象である熊本市および福岡市の交通人身事故のデータの説明をし、上記の年別推移の考察を述べる。5章では3章の概要を踏まえて熊本市の分析結果を考察する。また6章にて分析結果を述べ、7章で結果に対する考察を述べる。最後に6章と7章で得られた結果や考察を基に本研究のまとめおよび今後の展望を記述する。

2. 既往研究のレビューと本研究の位置づけ

本章では既存の研究によって災害後の交通事故実態で明らかになっていることを整理する。さらに本研究の分析の際に用いるITS手法に関する既往研究をレビューし、本研究の位置づけを述べる。

(1) 阪神・淡路大震災に関する事例

過去の地震の交通実態分析として、1995年1月の阪神淡路大震災の事例分析が多数報告されている。萩田・横関²⁾は阪神淡路大震災をはじめとする8つの大地震において、地震による死傷者数が人口の0.1%以上であった市町村を対象とし、発生前後の交通事故を道路交通環境に着目して分析し、前後1年において増加傾向であることを示した。具体的には、交通環境に関連する人口の集積状況や昼夜別、道路形状、事故形態に着目して分析を行った。阪神淡路大震災においては震度7であった神戸のDID地区においては増加傾向がみられ、道路の利用頻度やインフラの被害状況が交通事故の発生傾向に影響していることを示唆した。また、日野ら³⁾は震災によって二次災害的な交通事故の直接・間接的影響を明らかにした。交通事故発生状況を発生後の時間経過別や交通主体別など様々な項目別に分析しており、交通事故への影響の特徴を示した。具体的には、事故特徴からみた発生状況においては、被害状況が比較的小さい地域も貨物車などの迂回路として利用されたため事故の増加につながることを示唆した。

(2) 東日本大震災に関する事例

2011年東日本大震災における様々な事例分析も報告されている。一部の報告書⁴⁾においては、地震の影響で活動エリアや交通密集地域が変化したことにより、交通リスクも同様に変化し、事故が発生しやすいことを指摘している。また物損事故は頻繁な停止と発信の繰り返しが起こりやすい交通密集地域において、人身事故は漫然運転や居眠り運転が起きやすい道路の見通しがよく走行しやすい環境で多発することも明らかにしている。杉山・土田⁵⁾は震災の停電の影響による自動車事故の発生状況を明らかにしている。具体的には、停電により信号機が点灯していないことが要因で事故が多発していることが懸念されている。また警察官の手信号による交通整理に遭遇する機会も少ないため、運転者が正しく理解できていないということや停電による交通の混乱などが指摘されており、運転者の注意が防止策として挙げられている。また地引ら⁶⁾は高速道路において地震発生時に走行中の運転者を対象として、運転者の行動をアンケート形式にて調査した。結果的には緊急地震速報が運転者に及ぼす影響は限定的であり、効果はこの速報を入手した運転者の方がハザードランプを点滅させた割合が高かったことが挙げられる。また地震発生後に高速道路の掲示やテレビなどの報道が運転者に対して有効な情報を提示できていないことが指摘されている。

(3) 熊本地震に関する事例

2016年に発災した熊本地震の交通実態分析として、稲

月⁷⁾は熊本地震において被災者の行動に着目し、過去の災害と比較して車中泊の多さを指摘した。1週間以上車中泊を続けている避難者を対象とし、アンケート調査をもとに計量テキスト分析などを行った。分析より避難所ではなく車中泊を選択した理由としてプライバシーが守れないことや避難所では気を遣うなどが多く、平時以上にストレスがかかることが懸念された。また車中避難者は健康・医療面において最も危惧しており、これもまた精神的負担がかかる要素として挙げられた。荒木ら⁸⁾は想定以上の避難者の発生や想定していた場所以外での避難が行われた事例の行政対応と避難先の対応状況に着目して避難所の支援拠点としての課題を明らかにしている。また避難所が被災したことによって使用不可となり、指定避難所が過密状態であったことから車中泊を選択した避難者もいることを指摘した。

(4) 海外の災害に関する事例

Casey *et al.*⁹⁾は、オクラホマ州にて地下水への廃水注入が原因で発生している地震について交通事故との関連性を示した。具体的にはBox-Jenkins法のモデルであるARIMAモデルを用いて地震の規模別に分析を行った。結果より、マグニチュード4以上の地震発生が多い地域では1回の地震が発生すると翌月の交通人身事故は平均39.2件増加することが明らかとなった。また同地域で1回以上のマグニチュード4以上の地震が発生すると4.6%翌月の交通人身事故が増加することを示した。

(5) COVID-19に関する事例

COVID-19の拡大に伴う影響および交通実態分析に関しても多数報告されている¹⁰⁻¹⁵⁾。Saladié *et al.*¹⁰⁾は、スペイン政府が3月中旬にCOVID-19の感染を対処するため宣言したロックダウン政策がタラゴナ県の交通事故に与えた影響を分析した。この政策期間中において事故件数の減少率は、同年の政策前と比較すると74.3%、前年同期と比較すると76.0%であり、これは交通量の減少率(62.9%)よりも高かったことを明らかにした。したがって交通量の減少が交通安全におよぼす効果を示すことができ、交通量低下に向けて自家用車ではなく公共交通機関の利用促進を提言している。またColonna and Intini¹¹⁾は、イタリアでのCOVID-19による死亡者数の増加と政策による死亡者数の減少との間の補償効果の可能性について検討している。分析結果より2種類間にはいくつかのトレードオフの関係があり、この効果は政策に応じて増大することを明らかにした。またこの間に政策によって生理学的な人間の特徴である恒常性の補償効果を生み出す可能性が示唆された。一部記事¹²⁾には、全国の2020年度の交通人身事故件数は1948年以降最も少ないことが示されている。しかしながら東京都などの都市部

は死者数が最も多く、交通量が減ることにより人身事故につながる要因が増えていることが危惧されている。Nomura *et al* ¹³⁾は 2020 年度の交通人身事故は約 95.0%減少し、COVID-19 およびそれ以外の影響があることを示唆した。

(6) 分割時系列分析 (ITS)

本研究の分析で用いる分割時系列分析 (ITS) は、医学研究をはじめとする研究分野で頻繁に利用されている^{14,17)}。Maruyama and Taguchi¹⁾は熊本県内市町村における物損事故発生件数への熊本地震の影響をこの手法によって明らかにした。具体的には推定モデルによって相対リスクを算出し、それによって地域を分類し各々の震災による影響を段階的に定量化した。これにより主要道路が震災によって被害を受けた地域において事故は減少したが、それを除くと地震被害と交通物損事故には正の関連性があることが明らかとした。松下¹⁶⁾は熊本地震後に観光業の復興を目的とした助成制度「ふっこう割」が観光客の回復にもたらした影響を ITS 手法で明らかにした。九州全体で分析した結果、熊本県および大分県において観光客の回復は認められ、復興支援策の影響を施策の段階に分けて示すことに成功した。またそれ以外の地域は、ふっこう割の予算規模や割引率などが不十分であったことから影響が認められなかった。

(7) 本研究の位置づけ

このように災害によって被害状況や特徴は異なるため、交通事故リスクも同様に变化する。そのため災害後の影響を定量的に示すことは、今後の特徴が似た災害が発災した際の交通計画の策定に有用となる。これは交通安全に対しても同様である。また熊本地震による交通人身事故の影響を検討した研究は見当たらない。以上のようなことから、熊本市における震災による人身事故の影響を ITS 手法によって定量化し、震災が人身事故件数に及ぼした影響期間を明らかにする。

3. 分析方法

本章では、本研究で用いる分割時系列分析 (ITS: Interrupted time series analysis) の根本的な説明とこの手法を用いるにあたって重要な因果推論について述べる。また ITS で設定する介入期間の推定方法と修正 AIC についても説明する。その後一般化線形モデルや Box-Jenkins 法によるモデルといった本研究で用いる推定モデルについて問題とその改善を踏まえながら述べる。

(1) ITS 手法の概要

熊本地震が人身事故にもたらした影響は、地震の有無

別の件数の違いで表すことができる。しかしながら現実には災害が発生しなかった場合の状況を観測することは不可能である。そこで本研究では、このような場合に適用可能な分割時系列解析 (ITS) を適用する^{18,19)}。ITS とは、ある介入の前後の時系列で目的変数がどう変化するかをみるデザインである。介入とは、目的変数の変化に影響されていると考えられている事象であり、本研究では熊本地震を事象としているが、法律改定や政策実施等、様々な介入がある。ITS の前提条件は 3 つ挙げられる。まず 1 つ目は介入前後で集団の分布が変化しておらず同じような背景をもっているということである。2 つ目は介入前の時系列変化が線形であるということである。3 つ目は介入以外に時系列の変化を説明できるものがないということである。熊本市内の人身事故件数はカウント型データということと地震が最も影響していると推測できること、集団分布は変化していないこと等から、条件は満たしているといえる。次に ITS の考え方の概略図を図-1 に示す。まず時間 t_0 において政策の実施や地震等の発生によって目的変数が何かしらに影響している場合には、そのような介入前後で回帰式のレベル (切片) とトレンド (傾き) が変化するものと考えられる。そこで式 (1) のような式を用いて変化を推計する。

$$y_t = \beta_0 + \beta_1 T + \beta_2 lev + \beta_3 T_X + \varepsilon_t \quad (1)$$

ここで、 y_t は観測値、 $T (= 1, 2, 3, \dots)$ は時間経過を表現する変数であり、 T_X は介入後からの時間経過を表現する変数である。また lev は介入前 0、介入後は 1 をとる変数、 ε_t は誤差項を示している。また β_2 において介入時のレベル (切片) の変化を示しており、 β_3 は介入後のトレンド (傾き) を示す。のちに述べるが、介入なしの場合は、 β_2 、 β_3 を 0 にした時のモデルとなる。

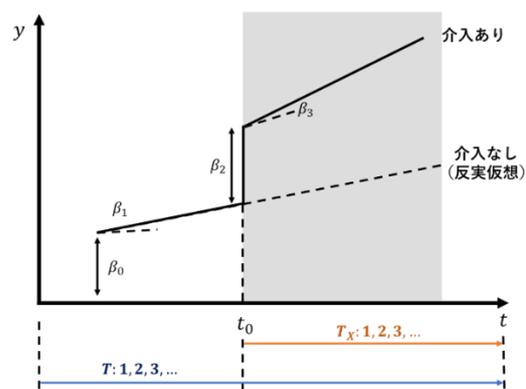


図-1 ITS の考え方

(2) 因果推論との関係

ITS を用いる際には因果推論という概念が重要である¹⁹⁾²⁰⁾。この手法は介入を原因としたときに影響していると考えられる結果に因果関係があるのか結論を出すプロセスである。また本研究のうち因果関係を成立させるための条件は、後述するモデル式の介入以外の変数を同一にすることで満たしているといえる。また因果推論を行う際は、反事実アプローチを用いて推測する。反事実（反実仮想）とは、もし介入（原因）がなければ、結果は発生しなかったという事実である。これは実際には観測されないため、本研究では回帰モデルを用いることで算出する。またこのアプローチは、このように算出された反事実と実際に観測されたデータのモデルと差を出すことで影響（因果効果）を定量的に示し、因果関係を確立することが可能となる。

(3) 介入期間の推定方法

熊本地震による交通人身事故の影響を分析する際に介入（影響）期間を推定しなければならない。本研究では様々な回帰モデルを用いて影響を算出する。そこで介入期間はこれらの統計モデルの良さを評価するための基準である AIC（赤池情報量基準）によって決定する。詳細には介入変数を熊本地震が発生した 2016 年 4 月から 1 ケ月ごとに変化させ、最大 32 ケ月後までのモデルの AIC を算出し、最小であった期間をそのモデルの介入期間とする。

(4) 構造変化を考慮した AIC

本研究では適切なモデルの選択を AIC によって決定するが、災害や法律改定などのモデルの構造を変化させるような事象を考慮する際は式(2)に示すような従来の AIC では不十分であることが指摘されている²¹⁾。

$$AIC = -2\ln L + 2K \quad (2)$$

ここで、 $\ln L$ は最大対数尤度、 K は説明変数のパラメータ数を示している。また $2K$ はペナルティ項と称され、これにより説明変数の追加に対するペナルティを課している。しかし Kurozumi and Tuvaandog²¹⁾ は、この項では構造変化を伴う適切なモデルを選択することが困難であることを考慮し、式(3)に示すような修正 AIC を提案した。

$$AIC = -2\ln L + 2K + 6m \quad (3)$$

ここで m は構造変化回数であり、これをペナルティ項に追加することで高い確率で正しいモデルが選択されることが期待される。本研究では介入項をモデル式に組み込む場合は、上記の修正 AIC を用いることとする。

表-1 本研究で用いる一般化線形モデル

一般化線形モデル			
ポアソン回帰モデル		負の二項回帰モデル	
A:フーリエ級数	B:共変量	C:フーリエ級数	D:共変量

表-2 本研究で用いる Box-Jenkins 法

Box-Jenkins 法	
E:ARIMAX	F:SARIMAX

(5) ITS 手法を用いた推定モデル

本研究で用いるモデルを表-1、表-2に示す。ITS手法を用いた推定方法として一般化線形モデルであるポアソン回帰モデルおよび代表的な時系列モデルである Box-Jenkins法の1つである ARIMA モデルについて述べる。また前者のモデルについては、問題点および改善法についても説明する。

(6) ポアソン回帰モデル

交通事故においては稀に発生する事象であるため、一般的にポアソン分布が用いられる。また本研究のデータは事故増加率や住宅被害率から分析するのではなく、カウント型データでかつ非負の整数である事故件数を用いるため一般線形モデルであるポアソン回帰モデルを適用する。このモデル式を式(4)に示す。

$$y_t \sim \text{Pois}(\lambda_t) \\ \log \lambda_t = \beta_0 + \beta_1 t + \beta_2 \text{crisis} \quad (4)$$

ここで、 β_0 は地震発生前のレベルを示しており、 β_1 においても地震発生前のトレンドを示している。地震発生前後の変化は、*crisis* の地震発生前に 0、発生後に 1 とするダミー変数によって表現している。しかしながらこのモデル式では、様々な問題が懸念される。このような問題とその改善方法を以下で述べる。

a) 過分散の問題

式(4)のようなポアソン分布を用いた回帰式では過分散が発生することが多い。過分散とはデータから得られる分散が平均から推定される分散に比べて大きいことで発生する現象である。ポアソン分布は平均と分散が等しいことを仮定しているため、上記のような現象が発生することが懸念される。この問題が発生すると仮定したモデルの標準誤差が実際のデータより小さく推定され、結果的に有意差が大きくなるため推定値の制度を過大に評価してしまう。このような問題の改善方法としては主に 2つ挙げられる。まず1つは誤差の調整をポアソン分布ではなく疑似ポアソン分布に指定して過分散を解決する方法である。しかしこの分布は誤差構造に関して疑似的に指定しているものにすぎないため AIC を算出することが

できない。本研究では最適なモデルをAICによって決定するためこの方法は用いられないこととする。

次に2つ目は分布を負の二項分布に指定することが挙げられる。この分布はポアソン分布とは違い、平均とは別に分散を推定することができる。したがって本研究ではこの分布を適用し、モデル式を式(5)に示す。

$$y_t \sim \text{NegBi}(\lambda_t, \phi) \\ \log \lambda_t = \beta_0 + \beta_1 t + \beta_2 \text{crisis} \quad (5)$$

b) 季節性の問題

長期的な時系列データには多くの場合、周期的なパターンをもっている。交通事故は日照時間が短いことや交通量の増加により冬季に発生しやすい傾向がある。このような周期性は介入前後の影響を分析するうえで考慮しなければならない。本研究では季節性の問題改善に下記の2つの方法を用いてモデル化し、AICによって最良モデルを決定することとする。まずフーリエ級数によって複雑な周期を正弦波関数の和で表現することが挙げられる。次に、日別や月別等の周期要因のダミー変数を設定し共変量としてモデル式に組み込む方法が挙げられる。この方法の懸念点としては、モデルのパラメータが多くなるため推定精度が低下することが挙げられる。この方法と式(4)および式(5)を組み合わせたものを式(6)と式(7)に示す。monthfを月別ダミー変数として、該当する月が1、それ以外の月は0をとる。

$$y_t \sim \text{Pois}(\lambda_t) \\ \log \lambda_t = \beta_0 + \beta_1 t + \beta_2 \text{crisis} + \sum_{k=3}^{13} \beta_k \text{month} f_{k-1} \quad (6)$$

$$y_t \sim \text{NegBi}(\lambda_t, \phi) \\ \log \lambda_t = \beta_0 + \beta_1 t + \beta_2 \text{crisis} + \sum_{k=3}^{13} \beta_k \text{month} f_{k-1} \quad (7)$$

(7) Box-Jenkins法による時系列モデル

時系列分析の代表的なモデルとしてBox-Jenkins法の1つであるARIMAモデルが挙げられる。このモデルは様々なモデルの組み合わせおよび過程を総じて適用したものである。さらに他の要因を組み込んだモデルもあるため以下に順を追って述べる。

a) 自己回帰モデル(AR)

時系列分析においては、通常的回帰分析ではなく過去の値を用いてモデル化する場合がある。説明変数を過去値とし、p時点前までのデータを使うモデルを自己回帰モデルAR(p)と表記し、モデル式を式(8)に示す。

$$y_t = c + \sum_{i=1}^p \phi_i y_{t-i} + \varepsilon_t \quad \varepsilon_t \sim N(0, \sigma^2) \quad (8)$$

式(8)においてcは定数項、 ε_t はホワイトノイズ、 ϕ_i は自己回帰推定値を示す。後者は未来を予測する情報がほとんど含まれていない純粋な雑音を指し、平均0、分散 σ^2 の正規分布に従うことが仮定される。

b) 移動平均モデル(MA)

AR(p)とは別に時系列データの自己相関を表現するモデルの1つとして移動平均モデル(MA)が挙げられる。このモデルはq時点間の観測値が近似していることを仮定し表現することによって自己相関を表す。q時点間の移動平均モデルをMA(q)と表記し、モデル式を式(9)に示す。

$$y_t = \mu + \sum_{j=1}^q \theta_j \varepsilon_{t-j} + \varepsilon_t \quad \varepsilon_t \sim N(0, \sigma^2) \quad (9)$$

式(9)において μ は定数項、 θ_j は移動平均推定値を示す。AR(p)とは異なり、MA(q)では過去の観測値からではなく過去のノイズからモデル化する。

c) 自己回帰和分移動平均モデル(ARIMA)

AR(p)とMA(q)を組み合わせたものを自己回帰移動平均モデル(ARMA)という。これにより時系列データにおける自己相関を柔軟に表現することができる。このモデルはARMA(p,q)と表記し、モデル式を式(10)に示す。

$$\varepsilon_t \sim N(0, \sigma^2) \\ y_t = c + \sum_{i=1}^p \phi_i y_{t-i} + \varepsilon_t + \sum_{j=1}^q \theta_j \varepsilon_{t-j} \quad (10)$$

しかしこのモデルは定常過程にのみ適用でき、非定常過程のデータでは適用できないことが懸念点として挙げられる。定常過程とは期待値が一定で、自己共分散は時点によらず時間差のみに依存するものを指す。そのような場合はデータに差分や対数をとることで定常過程に変換する方法が用いられる。このように差分をとってデータを定常過程に変換し、ARMAモデルに適用するものを自己回帰和分移動平均モデル(ARIMA)といい、表記をARIMA(p,d,q)とする。ここでdはデータに対してd階差分することを指す。

d) 季節性ARIMAモデル(SARIMA)

ARIMA(p,d,q)において季節成分を加味したモデルを季節性ARIMAモデル(SARIMA)という。このモデル式はラグ演算子を用いて式(11)のように表現され、表記をSARIMA(p,d,q)(P,D,Q)[s]と表す。

$$\phi(B)\Phi(B)\Delta^d \Delta_s^P y_t = \theta(B)\Theta(B)\varepsilon_t \quad (11)$$

ここで B はラグ演算子を示し、時点をずらすという行為を累乗で表現している。 Δ^d はデータに対して d 階差分をとることを示しており、 Δ_s^d は 1 周期が s としたときに D 階季節差分をとることを示す。また季節成分を示す係数として $\Phi(B)$ および $\Theta(B)$ を用いている。

e) 外生変数付きARIMAモデル (ARIMAX)

地震などの災害や大きなイベントなど、目的変数に影響をもたらす事象を補正するためのARIMAを外生変数付きARIMAモデル (ARIMAX) という。表記をARIMAX(p,d,q)とし、式を式(12)に示す。

$$\varepsilon_t \sim N(0, \sigma^2)$$

$$y_t = c + \sum_{i=1}^p \phi_i y_{t-i} + \varepsilon_t + \sum_{j=1}^q \theta_j \varepsilon_{t-j} + \sum_{k=1}^r \beta_k x_{k,t} \quad (12)$$

ここで $x_{k,t}$ は、 r 個の説明変数があり、時点 t における k 番目の説明変数を示している。また曜日や祝日の効果をモデルに組み込むときにSARIMAではなく、ダミー変数を用いたARIMAXを適用することも可能である。ARIMAX(p,d,q)はSARIMA(p,d,q)(P,D,Q)[s]との併用が可能であり、組み合わせたものをSARIMAX(p,d,q)(P,D,Q)[s]と表記する。本研究では、ITS手法による影響を示すために外生変数を用いたARIMAX(p,d,q)とSARIMAX(p,d,q)(P,D,Q)[s]を用いて分析することとする。

(8) 自己相関の問題

本研究のような時系列データを用いて分析する際は自己相関の有無を確認することが必須である。自己相関とは異なる2つの変数間ではなく、1つの変数の時間差を考慮した相関関係を示す指標である。これがみられると回帰モデルにおける最も強い仮定の1つである独立性の仮定を損ねることになる。また関係がみられることでモデル式の変数以外に影響している要因があると考えられるため式の見直しが必要となる。この自己相関の有無の確認方法の1つとしてLjung-Box検定がある。帰無仮説を「自己相関関係を有していない」とし、この仮説を棄却することで自己相関が有している可能性があるといえる。本研究では、適切なモデルを選択する際の判断基準として、上記の検定および自己相関・偏自己相関図であるコログラムを用いる。なお有意水準は5%とした。

4. 分析対象

(1) 対象データ

本研究ではwebで長期間のデータが公開されている熊本市と福岡市を分析対象とした。どちらも統計書に記載されている月別交通人身事故件数をデータとしている。期間は2011年1月から2018年12月まで8年間であり、熊本市内では3つの警察署（熊本中央警察署、熊本南警察署、熊本東警察署）の総数としている。また熊本地震による影響を裏付けるためには、地震の影響がないと考えられる地域に分析し比較することが必要である。そこで本研究では福岡市と比較している。

(2) 熊本市の交通人身事故の年別推移

熊本市の交通人身事故の年別推移を図-2に示す。灰色の箇所は熊本地震発生後の期間を示している。全体的にみると地震発生前までは人身事故が減少傾向を示しているが、地震発生後何ヶ月かは増加傾向を示していることが読み取れる。このことから熊本市においては、物損事故だけではなく人身事故についても影響していることが考えられる。

(3) 福岡市の交通人身事故の年別推移

福岡市の交通人身事故の年別推移を図-3に示す。

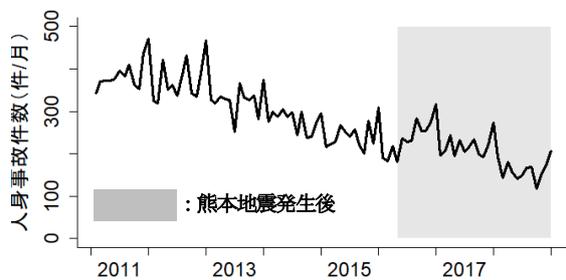


図-2 熊本市交通人身事故の年別推移

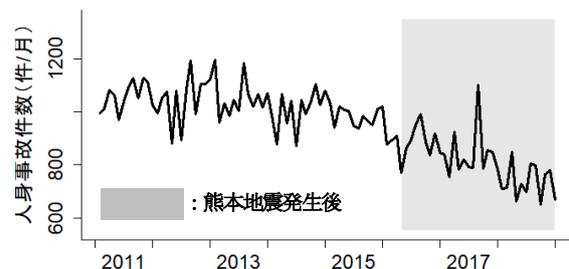


図-3 福岡市交通人身事故の年別推移

表-3 熊本市のモデル A-F の介入期間推定結果

モデル	ポアソン回帰モデル		負の二項回帰モデル		Box-Jenkins法	
	A:フーリエ級数	B:共変量	C:フーリエ級数	D:共変量	E:ARIMAX	F:SARIMAX
修正AIC	1122.4	935.5	962.8	908.5	974.9	948.1
介入期間	2016.4-2017.12	2016.4-2018.1	2016.4-2017.12	2016.4-2018.1	2016.4-2016.12	2016.4-2018.4
Ljung-Box検定	0.39	0.49	0.35	0.54	0.09	0.05

表-4 福岡市における ITS 手法の推定方法

	負の二項回帰モデル		SARIMAX	
	介入あり	介入なし	介入あり	介入なし
修正AIC	1099.0	1109.3	1093.5	1088.7
介入期間	2016.4-2018.12		2016.4-2016.5	
Ljung-Box検定	0.14	4.2×10^{-3}	0.44	0.68

全体的にみると、熊本市と同様に地震発生前までは人身事故が減少傾向を示している。しかし異なる箇所として、熊本市に関して災害後数ヶ月は増加傾向を示しているのに対し、福岡市は減少傾向のまま推移しているように見える。そこで福岡市の人身事故の影響を分析し熊本市の分析結果と比較することで、熊本市の人身事故の影響と地震が関係するのかどうかを明らかにする。

5. 分析結果

本章では、2つの対象地域の各推定モデルの分析結果を述べる。表-1、表-2のAからFまでの推定の介入期間の結果をそれぞれ考察し、その後最良モデルを決定する。

(1) 熊本市における介入期間推定結果

熊本市の推定モデルである A から F までの介入期間の結果を表-3に示す。本研究では、残差の自己相関の有無を確認したうえで修正 AIC が最小のものを最良モデルとしている。結果より季節性を考慮した 2 種類の一般化線形モデルはどちらも同様な傾向を示した。また介入期間は、フーリエ級数を用いたモデル(A,C)は地震発生から 20 ヶ月後の 2017 年 12 月を対象とし、共変量を用いたモデル(B,D)は 21 ヶ月後の 2018 年 1 月を対象とする。一方、ARIMAX(E)では震災から 8 か月後の 2016 年 12 月、SARIMAX(F)は 24 ヶ月後の 2018 年 4 月を対象とする。また介入項がないモデルの AIC は、A: 1172.3, B: 993.6, C: 972.4, D: 935.3 となり、どれも介入項があるモデルより大きく良好でない。また Box-Jenkins 法のモデルでは、E: 974.2, F: 831.5 と介入項があるモデルと比較するとどちらも小さくなっている。これは過去の値が影響することが原因であると考えられる。なお介入なしのモデルの残差の自己相関は A および C のモデルにおいて問題は見受けられなかったが、それ以外のモデルは自己相関が検出されたことから、介入項を用いた方が良好であることが推測できる。

表-5 A: ポアソン回帰モデル (フーリエ級数) 推定結果

	推定値	標準誤差	P 値
β_0 (Intercept)	6.07	0.0116	$2.0 \times 10^{-16}^{***}$
$\beta_1(t)$	-0.01	0.0003	$2.0 \times 10^{-16}^{***}$
β_2 (crisis)	0.15	0.0192	$2.2 \times 10^{-14}^{***}$
β_3 (harmonic1)	-0.04	0.0088	$5.3 \times 10^{-7}^{***}$
β_4 (harmonic2)	-0.02	0.0087	0.07
β_5 (harmonic3)	0.04	0.0086	$7.1 \times 10^{-6}^{***}$
β_6 (harmonic4)	0.05	0.0087	$4.9 \times 10^{-8}^{***}$
介入期間	2016.4-2017.12		
修正 AIC	1122.4		
Ljung-Box	0.39		

* $p < 0.05$; ** $p < 0.01$; *** $p < 0.001$

表-6 B: ポアソン回帰モデル (共変量) 推定結果

	推定値	標準誤差	P 値
β_0 (Intercept)	5.95	0.0236	$2.0 \times 10^{-16}^{***}$
$\beta_1(t)$	-0.01	0.0003	$2.0 \times 10^{-16}^{***}$
β_2 (crisis)	0.16	0.0193	$3.5 \times 10^{-16}^{***}$
β_3 (month2)	0.02	0.0312	0.49
β_4 (month3)	0.14	0.0304	$6.3 \times 10^{-6}^{***}$
β_5 (month4)	0.07	0.0308	0.02*
β_6 (month5)	0.11	0.0306	$3.1 \times 10^{-4}^{***}$
β_7 (month6)	0.07	0.0310	$2.6 \times 10^{-2}^*$
β_8 (month7)	0.15	0.0305	$1.4 \times 10^{-6}^{***}$
β_9 (month8)	0.22	0.0301	$9.1 \times 10^{-13}^{***}$
β_{10} (month9)	0.07	0.0313	0.02*
β_{11} (month10)	0.13	0.0309	$3.4 \times 10^{-5}^{***}$
β_{12} (month11)	0.20	0.0305	$3.0 \times 10^{-11}^{***}$
β_{13} (month12)	0.39	0.0293	$2.0 \times 10^{-16}^{***}$
介入期間	2016.4-2018.1		
修正 AIC	935.5		
Ljung-Box	0.49		

* $p < 0.05$; ** $p < 0.01$; *** $p < 0.001$

(2) 福岡市における介入期間推定結果

福岡市の推定モデルの介入期間の結果を表-4に示す。福岡市では熊本市の推定モデルのうち良好な AIC を得た負の二項回帰の共変量のモデルと SARIMAX を適用し比較を行う。なお福岡市は震災による影響が比較的小さいことが考えられるため介入項の有無別に推定する。負の二項回帰モデルにおいて修正 AIC が最小であったのは地震発生から 32 ヶ月後の 2018 年 12 月までであり、1099.0 であった。また SARIMAX において最小の修正 AIC は地震発生から 1 ヶ月後の 2016 年 5 月までの 1093.5 で、この期間をそれぞれの介入期間とする。また SARIMAX は介入期間が 1 ヶ月と短く、これは熊本地震による影響が少ないことを示唆していると考えられる。

(3) 熊本市の各推定結果

a) 一般化線形モデル

ポアソン回帰モデルの推定結果を表-5, 表-6に示す。表-5はフーリエ級数によって季節性考慮したものの、表-6は共変量によって考慮したものである。2種類のモデルとも介入項の $crisis$ は0.15, 0.16と正に有意であり、熊本地震が発生してから約2年間において交通人身事故が増加傾向を示すことが明らかとなった。表-5ではフーリエ級数により4種類の正弦波関数を用いており、3種類が有意となっている。また表-6は共変量を用いており、結果は1月の交通人身事故と比較してほとんどの月が正に有意を示している。これより1月は1年を通して人身事故件数が少ないことが考えられる。また12月は1月と比較して0.39と正に有意であることから、冬季および交通量などの観点から事故が発生しやすいことが推測できる。残差による自己相関の有無の検定であるLjung-Box検定は有意水準を5%としたとき、どちらも帰無仮説を棄却できないことから自己相関を有していないことが確認できた。

表-7 C: 負の二項回帰モデル (フーリエ級数) 推定結果

	推定値	標準誤差	P 値
β_0 (Intercept)	6.08	0.0250	$2.0 \times 10^{-16}***$
$\beta_1(t)$	-0.01	0.0005	$2.0 \times 10^{-16}***$
$\beta_2(crisis)$	0.16	0.0355	$1.3 \times 10^{-5}***$
$\beta_3(\text{harmonic}1)$	-0.04	0.0177	0.02*
$\beta_4(\text{harmonic}2)$	-0.01	0.0176	0.43
$\beta_5(\text{harmonic}3)$	0.04	0.0176	0.02*
$\beta_6(\text{harmonic}4)$	0.05	0.0176	$5.4 \times 10^{-3}**$
ϕ	91.1	17.6	$2.3 \times 10^{-7}***$
介入期間	2016.4-2017.12		
修正 AIC	962.8		
Ljung-Box	0.35		

* $p < 0.05$; ** $p < 0.01$; *** $p < 0.001$

表-8 D: 負の二項回帰モデル (共変量) 推定結果

	推定値	標準誤差	P 値
β_0 (Intercept)	5.96	0.0332	$2.0 \times 10^{-16}***$
$\beta_1(t)$	-0.01	0.0004	$2.0 \times 10^{-16}***$
$\beta_2(crisis)$	0.16	0.0257	$2.9 \times 10^{-10}***$
$\beta_3(\text{month}2)$	0.02	0.0434	0.67
$\beta_4(\text{month}3)$	0.14	0.0429	$1.3 \times 10^{-3}**$
$\beta_5(\text{month}4)$	0.07	0.0431	0.12
$\beta_6(\text{month}5)$	0.11	0.0430	0.01*
$\beta_7(\text{month}6)$	0.07	0.0433	0.12
$\beta_8(\text{month}7)$	0.14	0.0429	$7.5 \times 10^{-4}***$
$\beta_9(\text{month}8)$	0.21	0.0426	$7.2 \times 10^{-7}***$
$\beta_{10}(\text{month}9)$	0.06	0.0435	0.14
$\beta_{11}(\text{month}10)$	0.13	0.0432	$2.7 \times 10^{-3}**$
$\beta_{12}(\text{month}11)$	0.20	0.0429	$3.5 \times 10^{-6}***$
$\beta_{13}(\text{month}12)$	0.39	0.0421	$2.0 \times 10^{-16}***$
ϕ	284.7	83.7	$7.1 \times 10^{-4}***$
介入期間	2016.4-2018.1		
修正 AIC	908.5		
Ljung-Box	0.54		

* $p < 0.05$; ** $p < 0.01$; *** $p < 0.001$

したがって共変量を用いたモデル(B)の方が0.49と高いことや、修正AICが935.5と低いことから、フーリエ級数を用いるより共変量を用いた方が季節性の当てはまりが良いことがわかる。次に負の二項回帰モデルを前者のモデルと同様に季節性を考慮した2種類の推定結果を表-7および表-8に示す。まず介入項および季節成分はポアソン回帰モデルと同じような傾向を示しており、介入期間においても0.16と正に有意であった。また推定時間パラメータ(β_i)は負に有意となっていることから、全体的に減少傾向にあることがわかる。これは交通安全対策と車両安全対策の長期的な効果によるものと思われる。しかしながらポアソン回帰モデルと異なる箇所として、修正AICが負の二項回帰モデルの方が小さいことが挙げられる。また各項に関しても負の二項分布の方が有意差が出にくくなっている。これはポアソン分布が負の二項分布に比べ標準誤差が小さく推定され、結果的に有意差が出やすくなっているためであると考えられる²⁵⁾。また共変量のモデルで有意差が出ていない月は、1月と比べてそれほど事故件数の差がないため傾向を示すことが困難であると考えられる。したがって、上記の結果やLjung-Box検定において0.54と最も高いことから共変量を組み込んだ負の二項回帰モデル(D)が一般化線形モデルにおいて最良であるといえる。

b) Box-Jenkins法による時系列モデル

Box-Jenkins法の1つであるARIMAXおよびSARIMAXの推定結果を表-9および表-10に示す。

表-9 E: ARIMAXによる推定結果

ARIMA (2,1,3) errors			
	推定値	標準誤差	P 値
AR1	0.14	0.1271	0.27
AR2	-0.93	0.0542	$2.0 \times 10^{-16}***$
MA1	-0.94	0.2048	$4.4 \times 10^{-6}***$
MA2	1.07	0.2309	$3.6 \times 10^{-6}***$
MA3	-0.56	0.1094	$3.1 \times 10^{-7}***$
Crisis	34.10	17.9736	6.0×10^{-2}
介入期間	2016.4-2016.12		
修正 AIC	974.9		
Ljung-Box	0.09		

* $p < 0.05$; ** $p < 0.01$; *** $p < 0.001$

表-10 F: SARIMAによる推定結果

ARIMA (0,1,1) (2,0,0) [12] errors			
	推定値	標準誤差	P 値
MA1	-0.89	0.0738	$2.0 \times 10^{-16}***$
SAR1	0.43	0.0963	$8.0 \times 10^{-6}***$
SAR2	0.26	0.1137	0.02*
Crisis	33.15	10.0663	$6.9 \times 10^{-3}**$
Drift	-2.51	0.9287	$9.9 \times 10^{-4}***$
介入期間	2016.4-2018.4		
修正 AIC	948.1		
Ljung-Box	0.05		

* $p < 0.05$; ** $p < 0.01$; *** $p < 0.001$

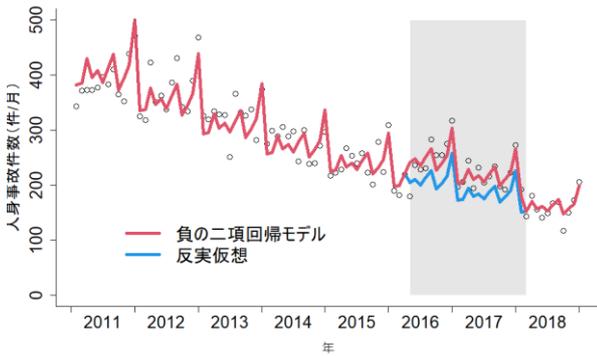


図-4 熊本市の人身事故における負の二項回帰モデルを用いたITS手法の適用

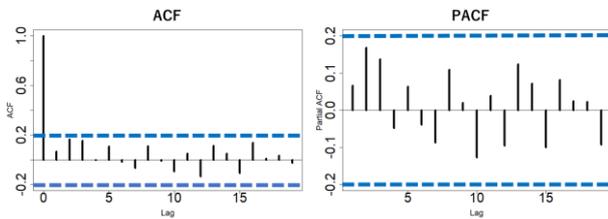


図-5 負の二項回帰モデルの残差における自己相関

表-9より、ARIMAXの介入項は有意差が出ていないことがわかる。これは介入期間が他のモデルより短く、かつ季節性が考慮できていないことが原因であると考えられ、うまくモデル化できていないことが推測できる。また表-10のSARIMAXは介入項が正に有意であり、他の項に関して有意差が出ていることから、季節性を考慮したSARIMAXの方が適しているといえる。介入項に注目すると、このモデルも一般化線形モデルと同様に地震発生から約2年間交通人身事故に影響していることがわかる。

(4) 最良モデルによるITS手法の適用

熊本市では、共変量を組み込んだ負の二項回帰モデルの修正AICが908.5と最も小さく最良モデルといえる。このモデルを用いて反実仮想などを予測した結果を図-4に示す。ここで、赤線は負の二項回帰モデルを用いて予測したものであり、青線は反実仮想を予測したものである。予測図より、介入項を考慮した予測が地震発生から勾配や切片を段階的に変化できていることが読み取れる。また反実仮想との比較より、介入期間において人身事故件数は758件増加し、約1.16倍（95%信頼区間：1.11，1.21）であり、熊本地震発生による人身事故への影響を定量的に示すことができた。次にこのモデルの残差の自己相関をLjung-Box検定を用いて分析した。図-5より残差における自己相関および偏自己相関はどちらも相関関係がみられないことが確認できた。これより、このモデルにおいて独立性を損なうことなく、モデル式の変数以外に影響している要因がないことがいえる。

表-11 福岡市の介入あり負の二項回帰モデルの推定結果

	推定値	標準誤差	P 値
β_0 (Intercept)	6.99	0.0266	$2.0 \times 10^{-16}^{***}$
$\beta_1(t)$	-3.0×10^{-3}	0.0004	$1.2 \times 10^{-9}^{***}$
β_2 (month2)	-0.11	0.0248	$7.5 \times 10^{-6}^{***}$
β_3 (month3)	-0.05	0.0326	0.10
β_4 (month4)	0.05	0.0324	0.10
β_5 (month5)	-0.05	0.0327	0.13
β_6 (month6)	0.02	0.0325	0.63
β_7 (month7)	-0.04	0.0326	0.26
β_8 (month8)	0.06	0.0324	$4.8 \times 10^{-2}^*$
β_9 (month9)	0.12	0.0323	$3.0 \times 10^{-4}^{***}$
β_{10} (month10)	3.0×10^{-3}	0.0326	0.94
β_{11} (month11)	0.06	0.0325	0.06
β_{12} (month12)	0.07	0.0325	0.04^*
β_{13} (month12)	0.04	0.0326	0.25
ϕ	317.4	61.6	$2.6 \times 10^{-7}^{***}$
介入期間	2016.4-2018.12		
修正 AIC	1099.0		
Ljung-Box	0.14		

* $p < 0.05$; ** $p < 0.01$; *** $p < 0.001$

表-12 福岡市の介入なし負の二項回帰モデルの推定結果

	推定値	標準誤差	P 値
β_0 (Intercept)	7.03	0.0277	$2.0 \times 10^{-16}^{***}$
$\beta_1(t)$	-4.1×10^{-3}	0.0003	$2.0 \times 10^{-16}^{***}$
β_2 (month2)	-0.05	0.0359	0.15
β_3 (month3)	0.06	0.0357	0.12
β_4 (month4)	-0.06	0.0359	0.11
β_5 (month5)	8.2×10^{-3}	0.0358	0.82
β_6 (month6)	-0.04	0.0359	0.23
β_7 (month7)	0.06	0.0357	0.10
β_8 (month8)	0.11	0.0357	$1.6 \times 10^{-3}^{***}$
β_9 (month9)	1.1×10^{-3}	0.0359	0.98
β_{10} (month10)	0.06	0.0358	0.09
β_{11} (month11)	0.07	0.0358	0.06
β_{12} (month12)	0.04	0.0359	0.25
ϕ	246.5	45.0	$4.3 \times 10^{-8}^{***}$
AIC	1109.3		
Ljung-Box	4.2×10^{-3}		

* $p < 0.05$; ** $p < 0.01$; *** $p < 0.001$

(5) 福岡市の各推定結果

福岡市の4種類のモデルの推定結果を表-11から表-14に示す。結果より、介入がないSARIMAXモデルが最もAICが小さく1088.7であった。これは介入期間の推定結果でも述べたが、熊本地震による福岡市交通人身事故への影響が小さかったためだと推測できる。また介入があるモデルのうち、負の二項回帰モデル(A)の介入項は-0.11と負に有意となっており、人身事故が減少傾向を示していることから、地震による影響とは考えにくいことが挙げられる。また介入を含めたSARIMAX(C)は、介入期間が1ヶ月と短いことから介入項が有意になっていないと考えられる。それぞれのモデルの自己相関をみると、介入を含めない負の二項回帰モデル(B)の自己相関が見受けられることから、うまくモデル化できていな

表-13 福岡市の SARIMAX (介入あり) の推定結果

ARIMA (0,1,1) (2,0,0) [12] errors			
	推定値	標準誤差	P 値
MA1	-0.87	0.0489	$2.0 \times 10^{-16}***$
SAR1	0.32	0.1002	$1.4 \times 10^{-3}**$
SAR2	0.22	0.1243	0.08
Crisis	-80.68	44.9116	0.07
Drift	-3.63	1.7980	0.04^*
介入期間	2016.4-2016.5		
修正 AIC	1093.5		
Ljung-Box	0.44		

*p<0.05; **p<0.01; ***p<0.001

表-14 福岡市の SARIMA (介入なし) 推定結果

ARIMA (0,1,1)(2,0,0)[12]			
	推定値	標準誤差	P 値
MA1	-0.87	0.0489	$2.0 \times 10^{-16}***$
SAR1	0.30	0.0981	$2.2 \times 10^{-3}**$
SAR2	0.25	0.1192	0.04^*
Drift	-3.58	1.7958	$4.6 \times 10^{-2}^*$
AIC	1088.7		
Ljung-Box	0.61		

*p<0.05; **p<0.01; ***p<0.001

いことがわかる。これは福岡市が熊本地震の他に別の要因である事象をモデルに組み込めていない可能性が挙げられる。また季節成分に注目してそれぞれのモデルを比較すると、前者より後者的の方が全体的にみると有意となっており、この面からみても福岡市人身事故に関するモデルはSARIMAXの方が適切であるといえる。

熊本市のデータでは、介入項を含んだモデルが最良となった。その一方で福岡市の交通人身事故への影響は介入を含まないモデルが最良であり、地震の影響は検出されていない。このことは震災後の熊本市人身事故の増加傾向は熊本地震が主な原因である可能性が高いことが支持される。

6. 考察

本章では結果について様々な観点の考察を深める。具体的にはまず熊本市の交通人身事故の影響を予測より考察し、その後一般化線形モデルとBox-Jenkins法によるモデルの違いの原因を明らかにする。そして最後に先行研究との比較を行い考察する。

(1) 熊本市における推定モデルの比較

熊本市の推定モデルである一般化線形モデルと比較してSARIMAXは修正AICが大きいことが結果より読み取れる。図-6は負の二項回帰モデル、図-7はSARIMAXモデルと反実仮想との差の月別推移(2016.4-2018.1)を表す。図-6より、モデルと反実仮想との差はほとんど均一になっていることがわかる。これは負の二項回帰モデルは介入項をダミー変数と設定してモデル化および予測をしているため、他の変数が影響されないことが要因として挙げられる。

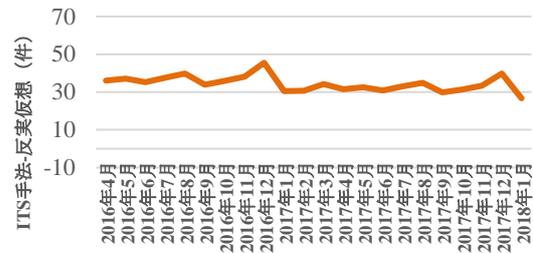


図-6 負の二項回帰モデルと反実仮想の差の月別推移

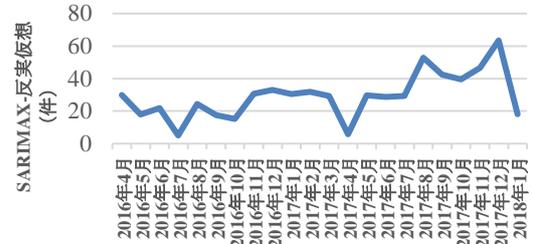


図-7 SARIMAX と反実仮想の差の月別推移

しかしながらSARIMAXは、図-7より年月が経つにつれて反実仮想との差が大きくばらつきがあることが読み取れる。これはSARIMAXが過去の観測値を用いて予測するモデルであり、自己回帰項(AR)に介入項を考慮して予測した過去値を用いていることからうまくモデル化することができないことが考えられる。またAR項だけでなく、季節成分にも過去の観測値を用いているため徐々に反実仮想との差が拡大していくと考えられる。よって今回は負の二項回帰モデルの方が適切なモデルといえる。

(2) 先行研究との比較

阪神淡路大震災による交通人身事故への影響は2章でも述べたように萩田・横関²⁾が震災前後の増加傾向を示している。熊本市は震度6で3つの警察署はDID地区(人口集地区)に該当する。よって阪神淡路大震災の同規模と比較すると、熊本市では17.6%増加しているのに対し神戸市では12.5%増加しており、ほぼ同程度である。日本における先行研究では、前年同月比較や、震災前後1年間の単純比較にとどまっているのに対し、本研究の分析方法は、時系列データの特性を考慮し、統計的な検定を実施し、増加分の信頼区間の推定等も実施している点が特徴である。

次に熊本地震の物損事故の影響と比較する。先行研究¹⁾では市町村別に分析し、交通事故リスクおよび地理的要素が類似しているものを分類している。熊本市が含まれる地域では、物損事故の介入期間は震災後から32ヶ月後の2018年12月、事故増加率は1.25倍(95%信頼区間: 1.14, 1.35)となっている。人身事故と比較すると、介入期間が長く、事故増加率も高いことがわかる。これは物損事故が人身事故と比べ発生しやすいことが一因と想定されるが、明解な理由は不明であり今後の研究が必要である。

7. 結論

本研究では、2016に発生した熊本地震後の交通人身発生件数への影響をITS手法および様々なモデルによって分析した。また比較的被害が少ないと考えられる福岡市の交通人身事故の影響を示すことで、熊本市が地震によって事故件数が増加したことがより明らかとなった。以下が具体的な成果である。

- 1) 熊本市の交通人身事故において最良モデルである負の二項回帰モデルを用いて分析した結果、地震発生の2016年4月から21ヶ月後の2018年1月までの期間において統計的に有意に増加していることが明らかとなった。
- 2) 負の二項回帰モデルによって予測した結果、反実仮想との差は758件であり、1.16倍 (95%信頼区間: 1.11, 1.21) 増加傾向にある。
- 3) 熊本市のデータでは、一般化線形モデルにおいて季節成分を考慮する際は、フーリエ級数を用いるよりも共変量をモデルに組みこむとAICが小さく良好となる。
- 4) 熊本市のデータにおいてITS手法の推定モデルは、Box-Jenkins法のARIMAでは過去の観測値からモデル化するため、うまく表現することができないことから一般化線形モデルの方が良好である。
- 5) 福岡市の交通人身事故データに推定モデルを適用すると、介入項がないSARIMAが最も修正AICが小さく良好である。福岡市の分析で熊本地震の影響が検出できないことは熊本市の交通人身事故の増加は地震が主な原因であるという考察を支持している。
- 6) 熊本地震後の物損事故の増加と比べると、人身事故の増加率は小さい。

今後の展望として、熊本市だけでなく熊本県に地域を拡大することや、海外においても地震によって交通事故が増加した事例が報告されており、それらとの詳細な比較も今後行いたい。また国内外の災害でまだ影響が示されていない事例においても同様に分析していきたい。

参考文献

- 1) Maruyama, T. and Taguchi, K.: Traffic accident increase following the 2016 Kumamoto earthquake, Japan: An interrupted time series analysis of accidents resulting in property damage, presented at 34th Annual Meeting of ARSC, 2020.
- 2) 萩田 賢司, 横関 俊也: 道路交通環境に着目した大地震発生前後の交通事故分析, 交通工学論文集, 第5巻, 第1号, pp.30-38, 2019.
- 3) 日野 泰雄, 増田 勝茂, 上野 精順: 阪神淡路大震災による交通事故および自動車利用動向の実態とその課題, 大阪市立大学工学部紀要・震災特別号, pp.105-114, 1997.
- 4) 東京海上日動: 被災地復興途上の交通リスクと対応策, 2016.

- <https://www.tokiorisk.co.jp/publication/report/riskmanagement/pdf/pdf-riskmanagement-160.pdf> (2020年1月閲覧)
- 5) 杉山毅, 土田敏勝: 東日本大震災レポート第8報 (震災の停電による自動車事故の発生とその対策について), NKSJ リスクマネジメント, 2011.
https://image.sompo-rc.co.jp/reports_org/r54.pdf (2020年1月閲覧)
 - 6) 地引 泰人, 大原 美保, 田中 淳, 古村 孝志: 東日本大震災における高速道路走行中の運転者の行動に関する分析, 地域安全学会論文集, No.26, 2015.
 - 7) 稲月 正: 熊本地震における車中避難の選択理由と生活上の困難, 西日本社会学会年報, No.16, pp.5-22, 2018.
 - 8) 荒木 裕子, 宇田川 真之, 高田 洋介, 坪井 塑太郎, 北後 明彦: 指定避難所以外に避難者が発生した場合の対応に関する研究: 2016年熊本地震における益城町を事例として, 地域安全学会論文集, No.31, pp.167-175, 2017.
 - 9) Casey, J. A., Elser, H., Goldman-Mellor, S., and Catalano, R.: Increased motor vehicle crashes following induced earthquakes in Oklahoma, USA. *Science of the Total Environment*, Vol. 650, pp. 2974–2979, 2019.
 - 10) Saladić, O., Bustamante, E., Gutiérrez, A.: COVID-19 lockdown and reduction of traffic accidents in Tarragona province, Spain. *Transp. Res. Interdiscip. Perspect.* 8, 100218, 2020.
 - 11) Colonna, P., Intini, P.: Compensation effect between deaths from Covid-19 and crashes: The Italian case. *Transp. Res. Interdiscip. Perspect.* 6, 100170., 2020.
 - 12) 日本経済新聞, 2021, <https://www.nikkei.com/article/DGXZQODG040D90U1A100C2000000> (2020年1月閲覧)
 - 13) Nomura, S., Kawashima, T., Yoneoka, D., Tanoue, Y., Eguchi, A., Gilmour, S., & Hashizume, M.: Trends in deaths from road injuries during the COVID-19 pandemic in Japan, January to September 2020. *Injury Epidemiology*, 7(1), 66, 2020
 - 14) Calderon-Anyosa, R.J.C. and Kaufman, J. S.: Impact of COVID-19 lockdown policy on homicide, suicide, and motor vehicle deaths in Peru, *Preventive Medicine*, Vol. 143, 106331, 2021.
 - 15) Oguzoglu, U.: COVID-19 lockdowns and decline in traffic related deaths and injuries, IZA Discussion Paper, No. 13278, 2020.
 - 16) 松下 哲明: 熊本地震における復興支援策「ふっこう割」が観光客の回復過程に及ぼした影響, 土木学会論文集 D3 (土木計画学), Vol.75, No.1, pp. 1-10, 2019.
 - 17) Bernal, J. L., Cummins, S., and Gasparrini, A.: Interrupted time series regression for the evaluation of public health interventions: a tutorial, *International Journal of Epidemiology*, Vol. 46 (1), pp. 334-335, 2017.
 - 18) Wagner, A. K., Soumerai, S. B., Zhang, F., and Ross-Degnan, D.: Segmented regression analysis of interrupted timeseries studies in medication use research, *Journal of Clinical Pharmacy and Therapeutics*. 27, pp. 299-309, 2002.
 - 19) 分割時系列解析の入門, 2017,
<https://www.slideshare.net/koichirogibo/its-81063341>
(2020年1月閲覧)

- 20) 統計的因果推論はなぜ機械学習で重要か？反事実モデルと因果効果の導出
<https://ailearn.biz/learn/20200830769#i-3> (2020年1月閲覧)
- 21) Kurozumi, E., Tuvaandorj, P.: Model selection criteria in multivariate models with multiple structural changes. *J. Econom.*1642,218–238,2011. (2021. 3. 7. 受付)

INTERRUPTED TIME SERIES ANALYSIS OF TRAFFIC ACCIDENTS WITH
INJURY FOLLOWING THE 2016 KUMAMOTO EARTHQUAKE

Ryotaro TOMINAGA, Takuya MARUYAMA