

APIR Trend Watch No. 54

都道府県別訪日外客数の月次推計と予測

APIR 研究統括/数量経済分析センター長 稲田 義久
主席研究員 松林 洋一
研究推進部員 野村 亮輔

要旨

戦略策定には、それにふさわしい主要業績評価指標(KPI)が必要となる。インバウンド・ビジネス産業戦略を例にとると、都道府県別訪問率や訪日外客数といったデータが重要である。戦略担当自治体やDMO(Destination Management/Marketing Organization)にとっては、これら2指標とその積である都道府県別訪日外客数が重要な指標となる。具体的には当該自治体が特定の海外プロモーション政策を実施した場合、数カ月後、その成果を各府県への訪日外客数や彼らの消費の変化から読み取ることができれば、その指標は戦略のPDCAサイクルを回すうえでも客観的で有益なものとなる。ただこれらのデータはタイムリー(ここでは月次ベースで公表には1カ月程度のラグ程度)に利用可能となることが望ましいが、現実にはそうなっておらず解決すべき課題である。これらの望ましい条件を満たす指標作成の可能性検討が本稿作成のモチベーションである。

具体的には、(1)四半期データである都道府県別訪問率を月次変換することで公表頻度の課題を解決し、(2)その月次指標を時系列モデル(ARIMA)で特定化を行い足元の予測(早期推計)を行うことで公表に伴うタイムラグの課題を解決した。結果、ほぼリアルタイムで都道府県別訪日外客数を推計することができた。このようなタイムリーなKPIの開発は戦略のダイナミックな展開に役立ち、今後の分析適応範囲を拡大するものとなろう。

はじめに：指標作成の背景

筆者達はこれまでインバウンド・ビジネス産業の戦略を意識しながらマクロミクロのデータに基づく分析を行ってきた¹。その際、分析から得られた政策への含意を政策関係者と共有することで分析の深化をはかってきた。具体的には、APIR ではプロジェクト「インバウンド先進地域としての関西+MICE」(2017-18年)を通して、研究会に参加する政策担当関係者と政策に関する対話や議論を重ねてきた²。本稿で報告する内容は、研究会参加メンバーである関西観光本部との議論から生まれた一つの成果である。

関西観光本部は関西2府8県(福井県、三重県、滋賀県、京都府、大阪府、兵庫県、奈良県、和歌山県、鳥取県、徳島県)を対象とした広域連携DMOである。2017年4月設立され、関西の自治体、経済団体、観光振興団体、観光関連を中心とした民間事業者等が参画し、府県や官民の枠にとられない組織として、その自由度と広域性を発揮しながら、関西広域でのインバウンド(訪日外国人旅行)をはじめとする、観光振興に取り組んでいる。事業の一つに、市場動向に基づく関西全体の施策の方向性の提示(マーケティング&ターゲティング)がある。その具体的指標として、関西を訪れる外国人旅行客の動態に関する調査をもとに、現状分析をもとにした、関西広域での観光振興ビジョンの立案(「関西ツーリズムグランドデザイン」の策定)がある。

たしかに、指標の中で戦略立案に必要な基礎データ(例えば、訪日外国人消費動向調査)は存在するが、公表頻度が四半期や年次でありしかも公表時期が4カ月以上のタイムラグを伴うという、タイムリーな利用可能性に欠ける現状がある。議論の結果、もし、(1)府県別の訪日外客の動向(流入数や消費額)や、(2)府県別訪日外国人のシェア等の指標がタイムリーに利用可能となれば、インバウンド・ビジネス産業戦略にとって有益なツールとなることを理解できた。

自治体が観光戦略を立案する場合も同様の状況にあるといえよう。担当者はPDCAサイクルを意識して事業展開に取り組むことになる。その際、KPIがタイムリー(ここでは月次ベースで公表には1カ月程度のラグ程度)に入手できることができれば望ましい。具体的には当該自治体が特定の海外プロモーション政策を実施した場合、数カ月後に、その成果を各府県への訪日外客数や消費の変化から読み取ることができれば、その指標はPDCAサイクルを回すうえでも客観的で有益なものとなる。これら2つの具体的な指標作成の可能性が本稿作成のモチベーションである。

¹ 後掲参考文献、稲田義久・下田充(2017)、稲田義久・松林洋一・木下祐輔(2018)、稲田義久・下田充(2018)、稲田義久・松林洋一・野村亮輔(2018)、稲田義久・野村亮輔(2019)を参照のこと。

² プロジェクト参加関係者は、APIR 以外は国土交通省近畿運輸局観光部、日本旅行業協会、関空エアポート株式会社からなる。

1. 基本的アイデア

1-1. 基本方程式

以下では、(1)の都道府県別訪日外客数の動向を決定する基本方程式：都道府県別訪日外客数=都道府県別訪問率×訪日外客数が議論の中心となる。

$$F_{it}=R_{it} \times N_t \quad (1)$$

F_{it} : 第 t 期の都道府県別訪日外客数 R_{it} 第 t 期の都道府県別訪問率 $i=47$ 都道府県

$N_t = \sum N_{jt}$: 第 t 期の訪日外客数 j = 韓国、台湾、香港、中国、欧州、北米、豪州、その他

この簡単な基本方程式から推計される月次ベースの都道府県別訪日外客数のタイムリーな利用可能性(早期推計)が本稿の目的であり、各府県の観光戦略の基礎的な指標として参照されることを意図している。だが、現実にはデータ公表の頻度やタイミングの問題もあり、積極的にビジネス戦略に使用されているとは聞かない。その理由としては、2つのオープンデータ、都道府県別訪問率と訪日外客数の公表頻度が異なることである。前者の公表頻度が四半期ベースであるのに対して、後者の公表頻度は月次ベースで翌月に推計値が発表される。このため、両指標(都道府県別訪問率と訪日外客数)の積である都道府県別訪日外客数の利用可能性は当然四半期となる。問題はこの公表頻度だけでなく、発表に伴うタイムラグもある。都道府県別訪問率の公表頻度は四半期であることに加え、発表にはタイムラグ(6 カ月)が伴う。ここで、訪問率を月次ベースでかつ早期推計することができれば、基本方程式から都道府県別訪日外客数をほぼリアルタイムで早期推計できることになる。この指標を月次ベースでモニターすれば、インバウンド・ビジネス戦略の基礎データとしての重要度が増すといえよう。

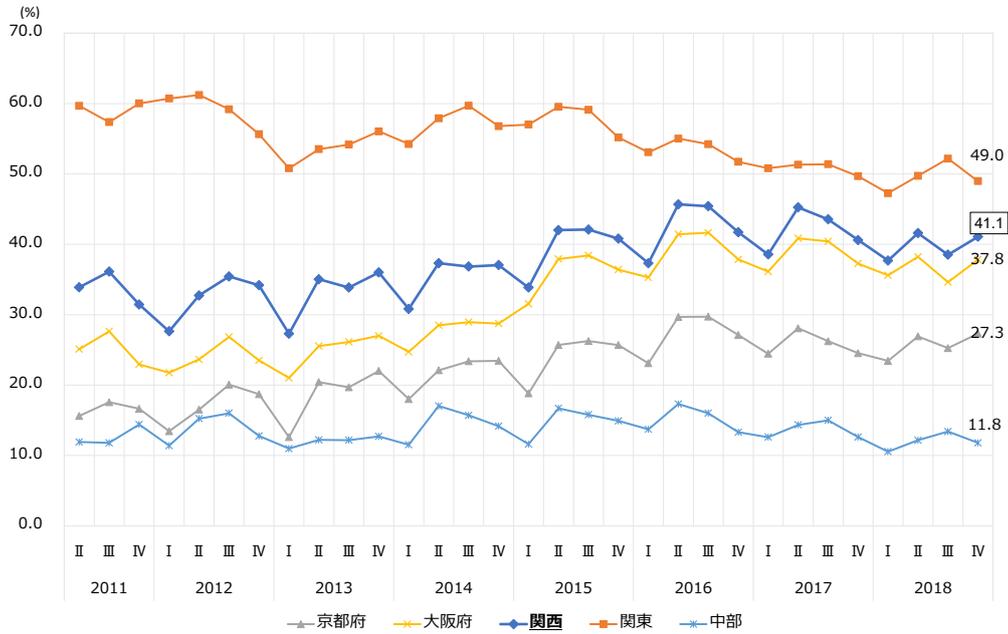
1-2. 都道府県別訪問率

訪日外国人が 47 都道府県に訪問した割合を示すのが訪問率(R_i)である。公表頻度は四半期で、『訪日外国人消費動向調査』2 次速報ないし確報発表時に表 6-1(後掲図表 1-4 参照)、表 6-2 として発表される。図表 1-1 には、関東、近畿、中部の各運輸局ベースの訪問率に加えて関西のうち大阪府と京都府の訪問率の推移が示されている。標本期間は、2011 年第 2 四半期~18 年第 4 四半期である。また図表 1-2 には、関西 2 府 8 県のうち大阪府、京都府を除く各県の訪問率が示されている。

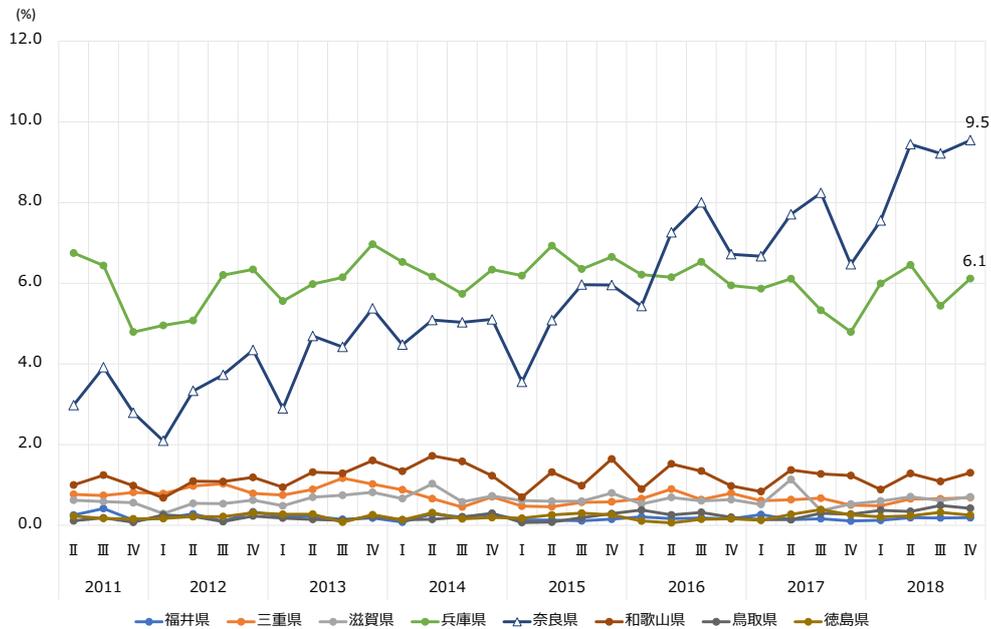
近畿と関東の訪問率を見れば、この間、関東の訪問率は 60%から 50%へと緩やかに低下していることがわかる。一方、近畿の訪問率は 30%から 40%へと緩やかに上昇している。中部圏訪問率は 10%~15%の間で安定的に推移している。このような中期的なトレンドとともに、短期的な変動も目に付く。例えば、2018 年第 3 四半期に自然災害(台風 21 号)の影響で、近畿の訪問率が一時的に低下し、関東、中部のそれが上昇していることがわかる。台風 21 号による関西国際空港閉鎖の影響により、外国人の訪問地に代替が起こったと考えられる。関西のうち、大阪府の訪問率は 15・16

年に 20%から 30%へと上昇トレンドを示すが、17・18 年度は横ばいとなっている。京都府の訪問率は 11-16 年にかけて 20%から 30%と持続的な上昇トレンドを示すが、17・18 年横ばい傾向となっている。

図表 1-1 訪問率の推移 1



図表 1-2 訪問率の推移 2 : 関西 8 県(除く大阪府、京都府)



出所：『訪日外客消費動向調査』

また図表 1-2 からわかるように、大阪・京都府に次いで関西では兵庫県と奈良県の訪問率が高い。近年、特に、奈良県の訪問率の上昇は著しく、2016 年第 2 四半期には兵庫県と奈良県の訪問率が逆転したことに注意。同じ関西でも各府県の訪問率は変化に富んでいることがわかる。

都道府県別の訪問率の動態を詳細にみていくことで、インバウンド・ビジネス戦略にとって様々な含意が出てくる。これまで兵庫県や奈良県は大阪、京都から近いこともあり、また宿泊設備が少ないこともあり、観光通過圏とみなされてきた。しかし、2017-18 年にかけて訪日外客が急増する中、大阪・京都府の訪問率が飽和現象を示す一方で、奈良県の訪問率が急上昇し、兵庫県のそれは相変わらず停滞しているのはなぜか。その背景には、訪日外客の嗜好の変化とともに各府県の観光戦略の影響が想像される。しかし、これらの訪問率の動態が大きく変化したことに気づくのは 2018 年の統計が発表されてからである。もし都道府県別の訪問率や訪日外客数の動向が月次ベースで分かるならば、変化の兆しをタイムリーに把握することができる。そのような指標が利用可能となれば、インバウンド・ビジネス戦略を考える上で優位性が増すといえよう。

1-3. 訪日外客数

次に重要な指標は訪日外客数で、これにより国籍別・地域別動向が月次ベースで分かる。具体例を示すと、日本政府観光本部(JNTO)が2019年4月17日に発表した訪日外客数の推計値によれば、3月は総計で276万100人、1-3月計は805万3,700人である(図表 1-3)。国籍別・地域別に見れば、中国、韓国、台湾がトップ 3 を占め、米国、香港、タイがこれに続いている。公表されるデータには推計値、暫定値、確定値の 3 種類があり、推計値、暫定値が毎月更新される。このように速報性が高く、訪日外客数の推移を把握できるデータは、インバウンド・ビジネス戦略にとって必要不可欠である。

図表 1-3 2019 年 3 月 訪日外客数(JNTO 推計)

国・地域	Country/Area	総数 Total			総数 Total		
		2018年 3月	2019年 3月	伸率(%)	2018年 1月~3月	2019年 1月~3月	伸率(%)
総数	Grand Total	2,607,956	2,760,100	5.8	7,618,662	8,053,700	5.7
韓国	South Korea	619,196	585,600	-5.4	2,131,330	2,080,800	-2.4
中国	China	594,920	691,300	16.2	1,943,557	2,169,300	11.6
台湾	Taiwan	387,338	402,400	3.9	1,138,718	1,189,700	4.5
香港	Hong Kong	195,651	171,400	-12.4	534,653	505,000	-5.5
タイ	Thailand	116,213	147,400	26.8	280,822	347,800	23.9
シンガポール	Singapore	38,089	43,700	14.7	82,754	92,500	11.8
マレーシア	Malaysia	47,652	50,600	6.2	114,083	118,700	4
インドネシア	Indonesia	32,428	39,600	22.1	83,401	96,700	15.9
フィリピン	Philippines	56,103	48,300	-13.9	115,308	119,500	3.6
ベトナム	Vietnam	35,235	47,900	35.9	86,304	122,700	42.2
インド	India	13,832	17,800	28.7	33,039	39,400	19.3
豪州	Australia	47,472	44,200	-6.9	162,562	173,000	6.4
米国	U.S.A.	150,964	176,600	17	324,902	372,500	14.6
カナダ	Canada	34,886	38,000	8.9	76,188	84,200	10.5
英国	United Kingdom	36,398	38,600	6	80,203	83,800	4.5
フランス	France	25,332	29,400	16.1	56,186	62,100	10.5
ドイツ	Germany	24,923	28,700	15.2	49,193	53,500	8.8
イタリア	Italy	13,244	15,000	13.3	25,577	26,900	5.2
ロシア	Russia	8,916	11,700	31.2	19,542	23,600	20.8
スペイン	Spain	11,524	8,900	-22.8	19,864	17,800	-10.4
その他	Others	117,640	123,000	4.6	260,476	274,200	5.3

出所:日本政府観光局(JNTO)

1-4. 国籍・地域別、都道府県別訪日外客数

図表 1-4 には『訪日外国人消費動向調査』に所載の表 6-1 が抜粋されている。ここでは、四半期ベースの(1)都道府県別の外国人訪問率と(2) 都道府県別の国籍・地域別の訪問率が報告されている。都道府県別外国人訪問率に四半期ベースの訪日外客数(図表 1-3)を乗じることにより、都道府県別の訪日外客数を推計できる。同様に、都道府県別の国籍・地域別の訪問率に(国籍・地域別)訪日外客数を乗じることにより、都道府県別の国籍・地域別訪日外客数も推計できる。なお本稿では、前者(都道府県別の訪日外客数)を推計対象としている。

図表 1-4 「訪日外国人消費動向調査 (表 6-1)」

表6-1 国籍・地域 (21区分)別 都道府県別訪問率

2018年(平成30年) 10-12月期 【確報】 (単位) 回答数：人、訪問率：%

調査項目	全国籍・地域		韓国		台湾		香港		中国	
	回答数	訪問率	回答数	訪問率	回答数	訪問率	回答数	訪問率	回答数	訪問率
全体 【B1】	26,785	100.0	7,067	100.0	3,909	100.0	2,176	100.0	5,571	100.0
都道府県名	1,538	6.8	414	6.9	346	10.8	157	8.2	253	5.7
(複数回答)	246	0.9	13	0.2	111	2.8	22	1.0	20	0.4
【B1】										
東京都	13,540	45.5	1,799	19.4	1,482	31.3	743	32.0	3,362	51.8
滋賀県	186	0.7	18	0.3	75	1.6	24	1.0	24	0.5
京都府	7,278	27.3	1,170	15.5	768	17.2	442	19.4	2,198	41.5
大阪府	9,922	37.8	2,332	31.6	1,102	25.5	736	32.4	2,954	57.0
兵庫県	1,612	6.1	383	5.3	333	7.6	138	6.0	272	5.7
奈良県	2,472	9.5	268	3.5	294	6.6	153	6.7	1,138	21.7
和歌山県	343	1.3	21	0.3	61	1.3	58	2.6	33	0.7
鳥取県	113	0.4	43	0.6	8	0.3	28	1.4	7	0.1
島根県	71	0.3	26	0.4	8	0.2	11	0.5	2	0.0
岡山県	272	1.1	39	0.8	69	2.0	50	2.2	29	0.5
広島県	924	3.2	84	0.8	62	1.3	56	1.5	51	0.5
山口県	184	0.9	100	2.5	28	0.6	14	0.4	7	0.1
徳島県	95	0.3	3	0.0	28	0.4	33	1.1	7	0.1
香川県	331	0.9	56	0.8	92	1.4	57	1.8	55	0.7
沖縄県	421	6.4	94	8.4	88	15.1	41	7.9	52	4.0
延べ合計	-	248.0	-	170.5	-	225.5	-	224.5	-	284.5

出所:観光庁 『訪日外国人消費動向調査 2018年10-12月期(確報)』より抜粋

2. 使用するデータと入手に伴う問題

2-1. データの発表頻度

すでに述べたように、2つのオープンデータから都道府県別の訪日外客数を推計することが出来る。しかし、利用者の観点からすれば、データは公表頻度が異なっていることが課題である。図表 2-1、2-2 には 2 つのデータの最近の公表予定日と内容を示している。『訪日外国人消費動向調査』は四半期毎に、JNTO の『訪日外客数』は毎月公表されている。だが、『訪日外国人消費動向調査』における訪問率の公表は、2018 年以前は四半期調査終了後に公表されていたが、18 年以降は当該四半期終了後の翌月に 1 次速報、4 カ月後に 2 次速報、年度末に確報が更新されるようになり、訪問率の情報は 2 次速報以降でなければ入手出来なくなった。都道府県別の訪日外客数を推計するには、訪問率の情報(表 6-1 と 6-2)が必要不可欠である。このため、データとしては非常に魅力的ではあるものの、公表頻度が低いため速報性に欠けるという欠点がある。

図表 2-1 訪日外国人消費動向調査 公表予定と内容

訪日外国人消費 動向調査	速報	平成31年 1 - 3月分	平成31年 4月 長官会見日
	速報	" 4 - 6月分	" 7月 長官会見日
	速報	" 7 - 9月分	" 10月 長官会見日
	速報	" 10 - 12月分	平成32年 1月 長官会見日
	年次確報	平成30年分	平成31年 3月末頃
	年次速報	平成31年分	平成32年 1月 長官会見日
	年次確報	"	平成32年 3月末頃

出所:観光庁

図表 2-2 訪日外客数 報道発表予定と内容

公表日時			発表内容	
			推計値	暫定値
2019年	1月16日(水)	16:00	2018年12月分・年計	2018年10月分
	2月20日(水)	16:00	2019年1月分	2018年11月分
	3月19日(火)	16:00	2019年2月分	2018年12月分・年計
	4月17日(水)	16:00	2019年3月分	2019年1月分
	5月21日(火)	16:00	2019年4月分	2019年2月分
	6月19日(水)	16:00	2019年5月分	2019年3月分

出所:日本政府観光局(JNTO)

2-2. データ発表のタイムラグ

公表頻度に加えて発表にかかるタイムラグの問題がある。図表 2-3 が示すように、2019 年の 1-3 月期の訪日外客数(暫定・推計値含む)は 4 月発表時に入手可能であるが、19 年 1-3 月期の都道府県別訪問率は 7 月発表の 2 次速報値で判明するため、訪問率が発表されるまでの期間、各都道府県の

訪日外客数を把握することが出来ない課題を抱えている。4月の段階では、訪日外客数の3月推計値と1月暫定値が利用可能である。この時点でもし3月の訪問率が推計できれば、3月の都道府県別訪日外客数を推計できる。1-3月期の訪問率が公表されるのが7月であるため、現行では訪問率入手までには4カ月以上のタイムラグがあり、かつまた四半期推計である。そのため、訪問率が公表されるまでの間を予測することが出来れば、直近の訪日外客数を推計することが可能となり、インバウンド・ビジネス戦略策定にとって有効な指標となるだろう。

図表 2-3 公表スケジュールのタイムラグ

公表予定時期		訪日外国人消費動向調査			訪日外客数		
		1次速報	2次速報	確報	推計値	暫定値	
2019年	1-3月期	1月			2018年12月分・年計	2018年10月分	
		2月			2019年1月分	2018年11月分	
		3月			2018年確報	2019年2月分	2018年12月分・年計
	4-6月期	4月	2019年 1-3月分			2019年3月分	2019年1月分
		5月				2019年4月分	2019年2月分
		6月				2019年5月分	2019年3月分
	7-9月期	7月	2019年 4-6月分	2019年 1-3月分		2019年6月分	2019年4月分
		8月				2019年7月分	2019年5月分
		9月				2019年8月分	2019年6月分
	10-12月期	10月	2019年 7-9月分	2019年 4-6月分		2019年9月分	2019年7月分
		11月				2019年10月分	2019年8月分
		12月				2019年11月分	2019年9月分
2020年	1-3月期	1月	2019年 10-12月分	2019年 7-9月分	2019年12月分・年計	2019年10月分	
		2月			2020年1月分	2019年11月分	
		3月			2019年確報	2020年2月分	2019年12月分・年計

※「訪日外国人消費動向調査」のうち、太字部分で府県別訪問率発表

出所:観光庁、日本政府観光局(JNTO)より筆者作成

3. データの月次化と時系列モデルの推計

先に説明したように、われわれの目的は、“都道府県別の訪日外国人客のできるだけ直近の動向を知る”という点にある。そのためには以下の4つの手順に基づく作業が必要となる。

手順① 都道府県別訪問率の四半期データを月次データに変換する。

手順② 手順①で生成した訪問率の月次データに全国の訪日外客数の月次データを乗じることによって、都道府県別の訪日外客数の月次データを推計する。

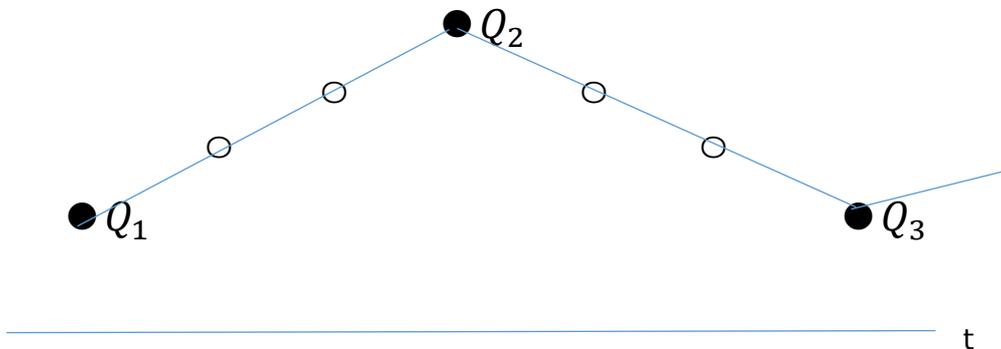
手順③ 手順①で計算した訪問率の月次データを用いて時系列モデルを特定化、推定する。

手順④ 手順③で計測した推定モデルをもとにして、足元までの訪問率を6カ月予測し、それを訪日外客数の実績を乗ずることで都道府県別訪日外客数を早期推計する。

以下では各手順の概要について説明しておく³。

3-1. 訪問率の月次化(手順①)

図表 3-1 データ系列の補間のイメージ



四半期データを月次データに変換する作業は、図表 3-1 のイメージ図で示されるように、2つの四半期データ(●で表示)の間に、何らかの関数関係を想定し、その関数上に載る形で月次データ(○で表示)を補間することになる。したがってこのような作業は、「補間」(interpolation)と呼ばれることが多い。図表 3-1 のイメージ図では補間する際の関数として直線を想定しており、線形補間(linear interpolation)と呼ばれている。2次関数を想定する場合も多く、2次関数補間(quadratic interpolation)と呼ばれている⁴。なお、データの補間についての具体例は、後掲付録(1)を参照のこと。

³ 以下の一連の作業は、ソフトウェア Eviews9.5 を用いて行っている。ここでは一連の作業の一部を記述するが、詳細については同ソフトウェアのマニュアルを参照のこと。

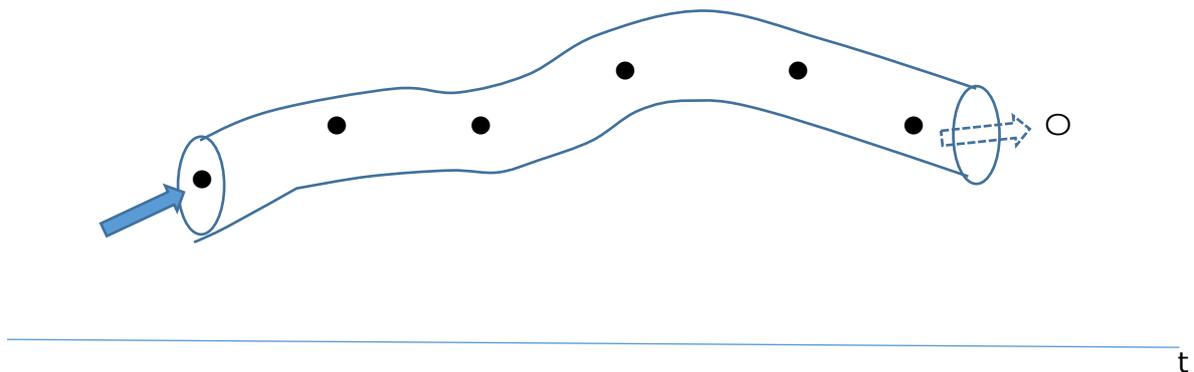
⁴ 我々の分析では、2次関数補間を用いている。

3-2.時系列モデルの特定化と予測(手順③・手順④)

時間の推移に伴って値が変化していくデータは、「時系列データ」(time series data)と呼ばれている。GDP、消費支出、設備投資など、経済データのほとんどは時間とともに変化するので、時系列データとして入手可能である。

ここで経済データの多くは公表までにある程度の時間がかかるため、その時々々の経済情勢に照らし合わせて、当該系列がどのような値をとっているのかを知ることができない。例えば本稿の問題意識からも分かるように、できるだけ足元の都道府県別の訪問率や訪日外客数の値を知っておくことは、観光戦略においてきわめて重要である。では利用可能な時系列データを用いて、公表されていない足元のデータを手入手するにはどのようにすればよいだろうか。直感的なイメージとしては、図表 3-2 のように時系列データ(●で表示)を覆うようにホースをかぶせ、ホースの左の端を押すことによって、足元のデータ(○で表示)を生成することができる。

図表 3-2 時系列モデルの特定化と足元データの生成



“時系列データを覆うようにホースをかぶせること”を、計量経済学の用語では「**時系列モデルを特定化する**」と呼ぶ⁵。また“ホースの先を押すことによって、足元のデータを生成すること”を、「**データを予測する**」と呼ぶ⁶。

⁵ 時系列モデルの具体的な特定化については、付録(2)で詳しい説明がなされている。

⁶ 予測(forecast)という言葉は、現時点よりも先の時点の値を予想する時に使われることが多い。例えば本稿執筆時点(2019年5月)において、2019年6月や7月の株価や為替レートの値を予想する場合、予測という言葉が使われる。しかし計量経済学では、推定モデルを用いて推定期間よりも先の値を計測する場合にも、「予測」という言葉を用いる。本稿では(後に詳説する)推定モデルの推定期間の終期は2018年12月であり、同モデルを

3-3. 時系列モデルの推計

時系列モデルの特定化は様々なタイプがあるが、本稿では**自己回帰和分移動平均モデル**(Auto Regressive Integrated Moving Average model : 略して **ARIMA モデル**)と呼ばれるモデルに基づいて特定化を行う。ARIMA モデルは、現実の時系列の短期的及び中長期的な動きをかなり丁寧に捉えることができ、多くの経済予測において用いられている。なお、時系列モデルの説明は本稿付録(2)に譲ることとして、ここでは具体的な時系列モデルの推計結果のみを示す。月次補間された訪問率のデータを用いて、関西 2 府 8 県と運輸局ベースの 5 地域(北海道、関東、中部、近畿(2 府 4 県)、九州)の訪問率を ARIMA モデルで推計した。ここでは、一例として近畿訪問率の推計結果を図表 3-3 に示した⁷。

図表 3-3 時系列モデルの推計結果(近畿訪問率(近畿運輸局ベース、2 府 4 県))

Dependent Variable: DLOG(MR_KNK)
Method: ARMA Maximum Likelihood (BFGS)
Date: 04/22/19 Time: 15:52
Sample: 2012M02 2018M12
Included observations: 83
Convergence achieved after 260 iterations
Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.004136	0.001439	2.874839	0.0053
AR(1)	-0.215118	0.139822	-1.538507	0.1282
SAR(12)	0.641447	0.117559	5.456404	0.0000
MA(1)	1.081934	20.67308	0.052335	0.9584
MA(2)	0.771999	33.46881	0.023066	0.9817
MA(3)	-1.020374	15.76983	-0.064704	0.9486
MA(4)	-1.044306	17.24592	-0.060554	0.9519
MA(5)	-0.789171	20.91637	-0.037730	0.9700
SIGMASQ	0.000439	0.021815	0.020136	0.9840
R-squared	0.860480	Mean dependent var		0.006251
Adjusted R-squared	0.845397	S.D. dependent var		0.056452
S.E. of regression	0.022197	Akaike info criterion		-4.438203
Sum squared resid	0.036459	Schwarz criterion		-4.175919
Log likelihood	193.1854	Hannan-Quinn criter.		-4.332832
F-statistic	57.04897	Durbin-Watson stat		2.015494
Prob(F-statistic)	0.000000			
Inverted AR Roots	.96	.83-.48i	.83+.48i	.48+.83i
	.48-.83i	.00+.96i	-.00-.96i	-.22
	-.48+.83i	-.48-.83i	-.83-.48i	-.83+.48i
	-.96			
Inverted MA Roots	1.00	-.45+.76i	-.45-.76i	-.59-.81i
	-.59+.81i			

用いて 2019 年 1 月、2 月、3 月の値を求めることを「予測する」と表現する。注意すべき点は、これら 3 か月の時期は、現時点(2019 年 5 月)よりも前の時点であるということである。

⁷ 推定結果のより詳細な説明は付録(2)においてなされている。

3-4. 訪問率の予測

手順③では、月次化された訪問率のデータを用いて、自動的に最適な ARIMA モデルを特定化する。最後の手順④では、計測した推定モデルを用いて、都道府県別訪問率の 6 カ月先を予測する。予測された訪問率を訪日外客数実績に乗じて、都道府県別の訪日外客数を予測する。訪問率の予測結果が、図表 3-4 に示されている⁸。ここでは、訪日外客数の利用可能性に合わせて、3 月までの訪問率の予測値が示されている。

図表 3-4 都道府県別訪問率の予測

訪問率	単位:%				
■府県ベース	2019/1	2019/2	2019/3	19Q1平均	18/Q4
福井県	0.20	0.22	0.24	0.22	0.19
三重県	0.68	0.71	0.68	0.69	0.69
滋賀県	0.78	0.78	0.71	0.76	0.71
京都府	28.82	27.90	27.16	27.96	27.32
大阪府	44.30	45.43	45.63	45.12	37.82
兵庫県	8.08	8.48	8.24	8.27	6.12
奈良県	9.80	10.03	10.42	10.08	9.54
和歌山県	1.41	1.29	1.17	1.29	1.30
鳥取県	0.28	0.25	0.24	0.26	0.42
徳島県	0.15	0.14	0.15	0.14	0.25

■運輸局ベース	2019/1	2019/2	2019/3	19Q1平均	18/Q4
北海道	5.97	7.18	8.94	7.36	6.83
関東	43.94	43.38	43.97	43.76	48.98
中部	9.12	8.98	9.48	9.19	11.80
近畿	45.03	44.23	43.20	44.15	41.09
九州	12.32	12.03	11.66	12.00	12.21

予測結果を見れば、2019 年 1-3 月期の運輸局ベースの訪問率は北海道と近畿では前期から上昇が予測されているが、関東、中部、九州では低下が予測されている。関西 2 府 8 県のうち、6 府県(福井県、滋賀県、京都府、大阪府、兵庫県、奈良県)では上昇が、4 県(三重県、和歌山県、鳥取県、徳島県)で低下が予測されている。

⁸ 各都道府県の訪問率には複数回答を含んでいることに注意。地方単位(運輸局等)で表示される訪問者数は、一地方内の複数都道府県を訪問した外客数の重複を除外しているため、都道府県の訪問者数を単純に合算した値とは異なる。例えば、大阪府 1-3 月期訪問率は 45.1%だが近畿の訪問率は 44.2%となっている。これは近畿を訪問した外国人はほとんど大阪府を訪問したことを意味する。

また、予測された訪問率に訪日外客数を乗じて都道府県別の訪日外客数が早期推計されている(図表 3-5)。1-3 月期の運輸局ベースの関東、近畿、九州の訪日外客数は前期より増加したが、北海道、中部の訪日外客数は前期より減少した。関西 2 府 8 県のうち、8 府県(福井県、三重県、滋賀県、京都府、大阪府、兵庫県、奈良県、和歌山県)では増加が、2 県(鳥取県、徳島県)で減少が予測されている。

図表 3-5 都道府県別訪日外客数の予測

訪日外客数				単位:人	
■府県ベース	2019/1	2019/2	2019/3	19Q1	18Q4
福井県	5,419	5,784	6,578	17,782	14,612
三重県	18,421	18,401	18,903	55,726	53,089
滋賀県	20,970	20,382	19,699	61,050	54,464
京都府	775,117	726,486	749,633	2,251,237	2,109,737
大阪府	1,191,456	1,183,049	1,259,517	3,634,021	2,921,060
兵庫県	217,325	220,776	227,478	665,580	472,378
奈良県	263,515	261,129	287,668	812,312	737,158
和歌山県	37,919	33,636	32,338	103,893	100,617
鳥取県	7,657	6,550	6,603	20,809	32,553
徳島県	3,937	3,588	4,018	11,543	19,462

■運輸局ベース	2019/1	2019/2	2019/3	19Q1	18Q4
北海道	160,496	186,889	246,857	594,241	662,116
関東	1,181,808	1,129,822	1,213,519	3,525,149	3,321,714
中部	245,246	233,959	261,664	740,869	823,905
近畿	1,210,986	1,152,009	1,192,248	3,555,244	2,521,460
九州	331,249	313,212	321,872	966,333	809,232

すでにみたように、JNTO により毎月、訪日外客数の前月の推計値、前々々月の暫定値が公表される。これと同時に、毎月、都道府県別訪日外客数の推計値、暫定値が更新される。1-3 月期の都道府県訪問率が発表されるのが 7 月であるから、4 月以降 6 月までは 12 月までのデータを用いた都道府県別訪問率の予測値が 1-3 月に引き続き用いられている。7 月の段階では 1-3 月期の訪問率のデータが入手可能となるので、1-3 月期の訪問率が月次化され、それらを加えた新たな標本で最適な時系列モデルが特定化され、新たに 4 月以降の 6 カ月について訪問率が予測される。これを用いて毎月の訪日外客数を乗ずることにより、4-6 月の都道府県別訪日外客数が予測・更新されることになる。以下、このルーティンが繰り返される。

おわりに

本稿では2つのオープンデータ(訪問率、訪日外客数)の重要性に注目し、まず訪問率の月次シリーズを作成した。このシリーズに時系列モデルによる特定化を行い、早期予測を行うことで2つのデータのタイムリーな利用可能性が実現した。結果、都道府県別の訪日外客数の月次推計がほぼリアルタイムで利用可能となった。

今後の展開としては、都道府県別の国籍・地域別訪日外客数の推計、それに基づく消費金額の推計が考えられる。KPIとして重要なのは訪日外客数のみならず、彼らの消費金額の推計が重要となる。オーバツーリズムが問題視される今日、訪日外客数の増加のみを追いかけるだけでなく、彼らの一人当たり消費の増加を重要な目標とし、全体として訪日外客の消費を増加させる戦略を意識すべきであろう。そのためにも、引き続き指標開発と分析を続けたい。

参考文献

有田帝馬(2012)『入門季節調整』東洋経済新報社。

アジア太平洋研究所(2019)、『「インバウンド先進地域としての関西+MICE」研究会報告書(2018年度)』2019年5月(近刊)。

稲田義久・下田充(2017)、「訪日外国人消費の経済効果 爆買いから新たな拡張局面へ：比較2013-16年」、APIR Trend Watch No.42、2017年8月4日。

稲田義久・松林洋一・木下祐輔(2018)、「「訪日外国人消費動向調査」個票データ分析から得られる関西インバウンド戦略へのインプリケーション(1)」、APIR Trend Watch No.47、2018年6月5日。

稲田義久・下田充(2018)、「訪日外国人消費の経済効果 新たな拡張局面は持続するか：比較2013-17年」、APIR Trend Watch No.48、2018年8月3日。

稲田義久・松林洋一・野村亮輔(2018)、「「訪日外国人消費動向調査」個票データ分析から得られる関西インバウンド戦略へのインプリケーション(2)-訪日外国人の移動パターン-」、APIR Trend Watch No.51、2019年1月11日。

稲田義久・野村亮輔(2019)、「持続可能なインバウンド戦略を目指して：オープンデータを利用した北陸地域の分析」、APIR Trend Watch No.53、2019年2月12日。

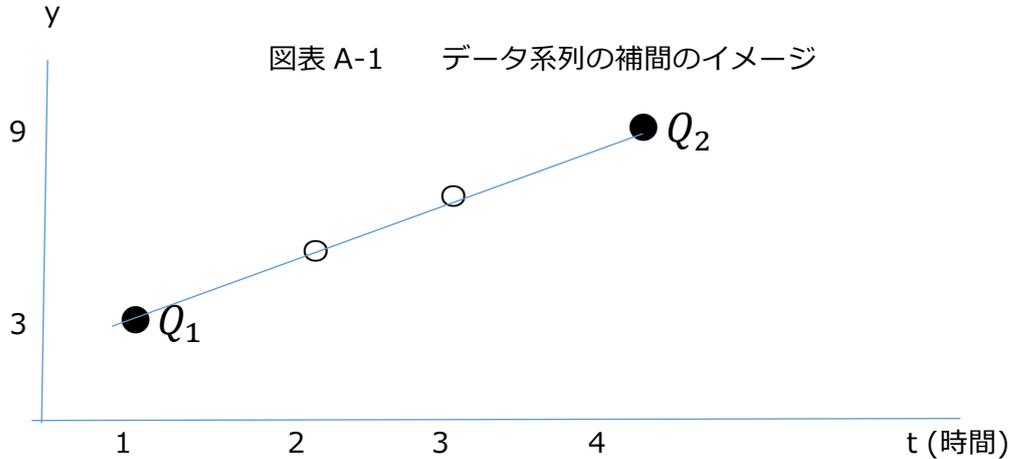
戸川隼人(1998)『科学技術計算ハンドブック』サイエンス社。

山澤成康(2004)『実戦計量経済学入門』日本評論社。

山本拓(1988)『経済の時系列分析』創文社。

付録(1) データの補間について

図表 A-1 では、四半期データを線形補間することによって月次化する手続きを図示している。以下では簡単な数値例によって同手続きのイメージを明らかにしておく。



2つの四半期データ($Q_1(1,3), Q_2(4,9)$)を取る直線は、

$$y = 2t + 1 \quad (\text{a-1})$$

として表せる。そこでその間の2か月分の値は、 $t = 2, t = 3$ を代入することによって、

$$y = 2 * 2 + 1 = 5$$

$$y = 2 * 3 + 1 = 7$$

という形で求めることができる。図表 A-1 には示していないが Q_2 と Q_3 の間にも線形補間を施せば(その際の一次式は(a-1)式の設定化とは異なる)、その間の月次データを求めることができる。

補間する際に二次関数を用いる場合には、二次関数の形状を決めるパラメータの数が少し多くなるので、計算する際に多少工夫する必要があるが、基本的イメージは線形補間と同じである⁹。

付録(2) 時系列モデルの概念と諸類型について

時系列モデルの基本は、当該変数の今期の値を、自分自身の過去の変数によって特定化するものである。代表的な特定化は以下に説明する4タイプであり、本稿で用いているARIMAモデルは、

⁹ 様々な補間方法の詳細については戸川(1998)が丁寧な解説を行っている。

最も精緻な特定化がなされているものである。以下ではそれぞれの特定化の概要を説明していくことにする¹⁰。

A-1 時系列モデルの特定化(1)

(1) AR モデル

まず時系列モデルの基本形とも言うべき、**自己回帰モデル**(Auto Regressive model : 略して **AR モデル**)を紹介する。AR モデルの最もシンプルな形は(a-2)式で示される。

$$y_t = \alpha_1 y_{t-1} + u_t \quad (\text{a-2})$$

$$E(u_t) = 0$$

$$\text{var}(u_t) = \sigma^2$$

$$\text{cov}(u_t, u_s) = 0, \quad t \neq s$$

(a-1)式は、一階の自己回帰過程モデル(Auto Regressive model of order one: 略して AR(1)モデル)と呼ばれている。AR(1)モデルは、今期の y_t は、一期前の y_{t-1} を α_1 の割合で引きずるとともに、今期の確率的なノイズ(u_t)の影響を受けるという形になっている。

(2) MA モデル

次に**移動平均モデル**(Moving Average model : 略して **MA モデル**)と呼ばれる時系列モデルを紹介する。MA モデルの基本形は、(a-3)式で示される。

$$y_t = u_t + \theta u_{t-1} \quad (\text{a-3})$$

$$E(u_t) = 0$$

$$\text{var}(u_t) = \sigma^2$$

$$\text{cov}(u_t, u_s) = 0, \quad t \neq s$$

(a-3)式は MA モデルの最もシンプルな形であり、MA(1)モデルと呼ばれている。MA(1)モデルは、今期の y_t は、一期前の確率的なノイズ(u_{t-1})を θ の割合で引きずるとともに、今期のノイズ(u_t)の影響をストレートに受けるという形になっている。

¹⁰ 時系列モデルの理論的解説は、山本(1988)が丁寧である。なお直感的な理解を得るには山澤(2004)が平易で分かりやすい。

MAモデルの特定化は一見するわかりにくい気がするが、先に説明したARモデルと密接な関係がある。たとえば(a-3)式を一期後方にずらすと、(a-4)式となる。

$$y_{t-1} = \alpha_1 y_{t-2} + u_{t-1} \quad (\text{a-4})$$

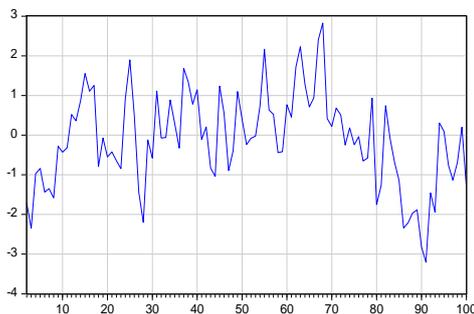
この(a-4)式を(a-2)式に再度代入すると(a-5)式となる。

$$y_t = u_t + \alpha_1 u_{t-1} + \alpha_1^2 y_{t-2} \quad (\text{a-5})$$

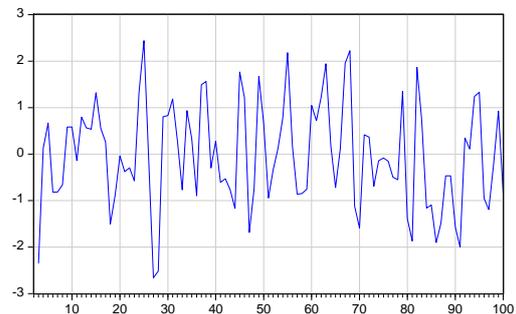
(a-5)式は、ほぼ(a-3)式と形が同じであることがわかる。上記の逐次代入からも想像できるように、ARモデルによって生成される時系列は、過去から現在までの確率的ノイズの集積になっており、この特徴を陽表的に表しているのが、MAモデルであると考えられる。

図表 A-2 AR(1)モデルと MA(1)のシミュレーション

(a) $y_t = 0.8y_{t-1} + u_t$



(b) $y_t = u_t + 0.8u_{t-1}$



ARモデルがMAモデルで表されることは、先の演算からも分かるが、実はそれ以外の時系列モデルの多くが、MAモデルに書き換えられることが知られている。そして時系列モデルの様々な理論的考察は、このMAモデルをベースとして行うことが可能となる。表現を変えれば、MAモデルの存在意義は「時系列モデルの理論的考察を行う際の基本形」にあると言える。

ここで、ARモデルとMAモデルの特徴をより鮮明にするために、以下の式のシミュレーションを行い、その様子を描いてみることにする。

AR(1)モデル

$$y_t = 0.8y_{t-1} + u_t \quad (\text{a-6})$$

MA(1)モデル

$$y_t = u_t + 0.8u_{t-1} \quad (\text{a-7})$$

(a-6)式と(a-7)式は、確率的なノイズに乱数を発生させることによって、 y_t の系列の人工値を作り出すことができる。図表 A-2 にはその結果が示されている。AR(1)モデル、MA(1)モデルともにジグザグとした形状を示しており、MA(1)モデルでは、平均値が0近傍にある点が特徴的である。

A-2 時系列モデルの特定化(2)

(1)ARMA モデル

前節では、AR モデルと MA モデルという時系列モデルの基本形を紹介した。本節ではこれらの基本形を拡張した、2つのモデルを紹介する。最初は**自己回帰移動平均モデル**(Auto Regressive Moving Average model : 略して **ARMA モデル**)と呼ばれるものである。ARMA モデルの基本形は、(a-8)式のように表される。

$$y_t = \alpha_1 y_{t-1} + u_t + \theta u_{t-1} \quad (\text{a-8})$$

(a-8)式は、AR(1)モデル((a-1)式)と、MA(1)モデル((a-2)式)が融合した形になっており、今期の y_t は、前期の自分自身の値と、今期および前期の確率的ノイズによって表される。(a-8)式をより一般的に描写すると、(a-9)式のように表現できる。

$$y_t = \alpha_1 y_{t-1} + \dots + \alpha_p y_{t-p} + u_t + \theta_1 u_{t-1} + \dots + \theta_q u_{t-q} \quad (\text{a-9})$$

(a-9)式は、 p 次の AR 項と、 q 次の MA 項から構成されており、ARMA(p,q)モデルと呼ばれている。したがって(a-9)式は、ARMA(1,1)モデルとなる。

この ARMA モデルの存在意義はどこにあるのだろうか。図表 A-1 からわかるように、AR モデルは大きなジグザグを、MA モデルではより細かなギザギザ感を捉えることができる。したがって両モデルを合体した ARMA モデルでは、より複雑な形状を捉えることができる(後にシミュレーション結果を示す)。つまり ARMA モデルの意義は「現実の時系列データに対して、時系列モデルを特定化する際の基本形」という点にある。表現を変えれば、ARMA モデルによる特定化は、時系列データに対してモデルを当てはめるといふ、現実的な要請に基づいた考察の際の、第一歩と言える。

(2)ARIMA モデル

2番目は、**自己回帰和分移動平均モデル**(Auto Regressive Integrated Moving Average model : 略して **ARIMA モデル**)を紹介する。ARIMA モデルの基本形は(a-10)式、(a-11)式で表すことができる。

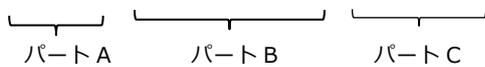
$$\Delta y_t = y_t - y_{t-1} \tag{a-10}$$

$$\Delta y_t = \alpha_1 \Delta y_{t-1} + u_t + \theta u_{t-1} \tag{a-11}$$

ARIMA モデルの特徴は、これまでの3つの時系列モデルとは異なり、まず元の系列(y_t)の階差をとり((a-10)式)、その階差系列(Δy_t)について、ARMA モデルを当てはめる((a-11)式)という2段階の手続きを踏んでいる点である¹¹。

ここで(a-10)式と(a-11)式によって表される ARIMA モデルの特徴をより鮮明にしておく。(a-11)式は、階差の表現(Δ)を外すと、(a-12)式のように書き直すことができる。

$$y_t = y_{t-1} + \alpha_1(y_{t-1} - y_{t-2}) + u_t + \theta u_{t-1} \tag{a-12}$$



パート A は、前期の y_{t-1} が、今期の y_t に対してストレートに影響を及ぼすため、時系列の大きな動きをとらえている。パート B では、原系列の前期と前々期の差であるから、ある程度ジグザグした動きを捉えている。そしてパート C は、図表 A-2(b)で見たように、かなりギザギザとした細かな波動を捉えている。

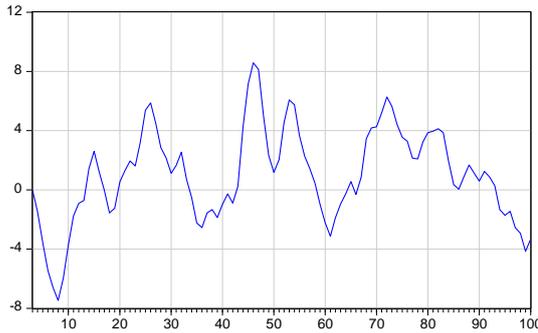
このように(a-12)式は、これらの3つの特徴をもった特定化を融合する形となっていることがわかる。つまり ARIMA モデルを構築する意義は、「現実の複雑な時系列データを特定化する際の一般モデル」ということになり、極めて現実的有用性の高いモデルであると言える¹²。

図表 A-3 ARMA(1,1)モデルと ARIMA(1,1,1)のシミュレーション

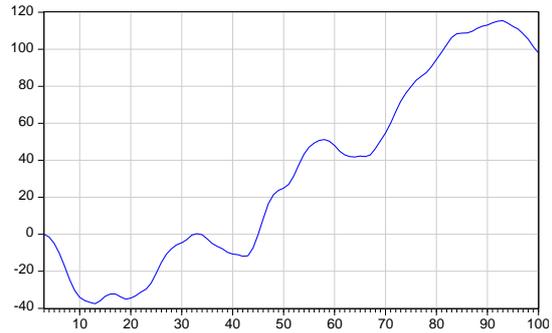
¹¹ 原系列が発散過程(AR モデルにおける自己回帰係数(y_{t-1} の係数)が 1 より大きい場合)では、推定モデルが不安定となり、後に行う予測が安定的な値をとり得ないケースが多い。そこで(a-10)式のように原系列に対して予め階差をとり、この階差系列に対して、(a-11)式のように ARMA モデルを特定化するという手続きをとる。

¹² ARMA モデルと同様に、AR 項の次数(p)、MA 項の次数(q)、さらに何回階差をとるのか(階差の回数=d)によって、ARIMA(p,q,d)モデルという形で一般化が可能である。したがって(a-10)式と(a-11)式によって表される ARIMA モデルは、ARIMA(1,1,1)となる。なお、たとえば月次や四半期の経済時系列データでは、顕著な季節性が観察されるケースが多く、この季節性を調整するために「季節調整」という操作が行われることがある。季節調整では、諸手続きの一貫として ARIMA モデルが使われることが多い(ARIMA モデルの詳細な解説を含め、季節調整全般については有田(2012)が詳しい)。

(a) $y_t = 0.8y_{t-1} + u_t + 0.8u_{t-1}$



(b) $y_t = y_{t-1} + 0.8(y_{t-1} - y_{t-2}) + u_t + 0.8u_{t-1}$



最後に ARMA モデルと ARIMA モデルのイメージを鮮明にするために、式のシミュレーションを行い、その様子を描いてみることにする。

ARMA(1,1)モデル

$$y_t = 0.8y_{t-1} + u_t + 0.8u_{t-1} \tag{a-13}$$

ARIMA(1,1,1)モデル

$$y_t = y_{t-1} + 0.8(y_{t-1} - y_{t-2}) + u_t + 0.8u_{t-1} \tag{a-14}$$

ARIMA モデルは、ARMA モデルよりも、大きな趨勢的な動きも捉えている様子が見て取れる。また図表 A-3(b)を拡大してみれば、(a-12)式のパート B、パート C で捉えている細かな波動も観察されるはずである。

A-3 ARIMA モデルの実践

以下ではすでに説明した ARIMA モデルを用いて、月次化した都道府県別の訪問率を、ARIMA モデルで推定し、同モデルを用いて予測を行うことにする。われわれは計量経済ソフト「Eviews Ver.9.5」を用いて ARIMA モデルを特定化し推定を行った。同ソフトでは ARIMA(p,q,d)モデルにおける p,q,d の次数の選択は、情報量基準(Akaike Information Criteria: 略して AIC)を用いて自動的に決定される。

われわれは、d については 1 次、p, q については、滋賀県、大阪府、近畿の場合、最大 6 次を想定した。その他府県・地域については最大 12 次を想定して次数を決定した。なお季節性を丁寧に調整するため、季節ごとに(例えば毎 12 月ごとに)通常の AR 項、MA 項とは別途に、季節 AR 項 (Seasonal AR)、季節 MA 項(Seasonal MA)も付加している(どの月に季節項を入れるのかも、AIC によって自動的に設定される)。

図表 3-3(再掲) ARIMA モデルの推定結果

Dependent Variable: DLOG(MR_KNK)
Method: ARMA Maximum Likelihood (BFGS)
Date: 05/07/19 Time: 17:48
Sample: 2012M02 2018M12
Included observations: 83
Convergence achieved after 260 iterations
Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.004136	0.001439	2.874839	0.0053
AR(1)	-0.215118	0.139822	-1.538507	0.1282
SAR(12)	0.641447	0.117559	5.456404	0.0000
MA(1)	1.081934	20.67308	0.052335	0.9584
MA(2)	0.771999	33.46881	0.023066	0.9817
MA(3)	-1.020374	15.76983	-0.064704	0.9486
MA(4)	-1.044306	17.24592	-0.060554	0.9519
MA(5)	-0.789171	20.91637	-0.037730	0.9700
SIGMASQ	0.000439	0.021815	0.020136	0.9840
R-squared	0.860480	Mean dependent var		0.006251
Adjusted R-squared	0.845397	S.D. dependent var		0.056452
S.E. of regression	0.022197	Akaike info criterion		-4.438203
Sum squared resid	0.036459	Schwarz criterion		-4.175919
Log likelihood	193.1854	Hannan-Quinn criter.		-4.332832
F-statistic	57.04897	Durbin-Watson stat		2.015494
Prob(F-statistic)	0.000000			
Inverted AR Roots	.96	.83-.48i	.83+.48i	.48+.83i
	.48-.83i	.00+.96i	-.00-.96i	-.22
	-.48+.83i	-.48-.83i	-.83-.48i	-.83+.48i
	-.96			
Inverted MA Roots	1.00	-.45+.76i	-.45-.76i	-.59-.81i
	-.59+.81i			

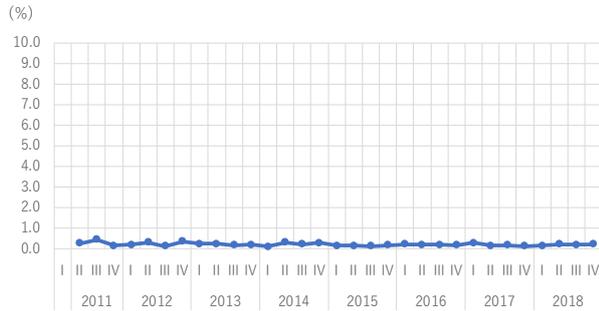
図表 3-3 には、2012 年 2 月から 2018 年 12 月までの関西(近畿運輸局ベース、2 府 4 県)の月次データを用いた ARIMA モデルの推定結果(ARIMA(1,5,1))が掲載されている。AIC 基準により、原系列に対して(対数を施したうえで)一階の階差を取った系列((a-11)式)に対して ARMA モデル((a-12)式)が特定化されている。推定方法は最尤法であり、260 回の繰り返し計算の後、推定結果が得られている。説明変数としては、1 次の AR 項(AR(1)で表示)、5 次まで MA 項(MA(1)から MA(5)で表示)、12 次の季節 AR 項(SAR(12)で表示)、残差の分散(SIGMASQ で表示)が表示されている。

なお、後掲の参考図表には関西 2 府 8 県及び地域(運輸局ベース)の訪問率時系列モデルの推計結果が示されている。

参考図表

訪問率：2府8県

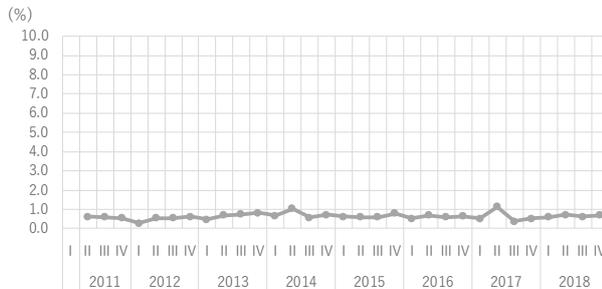
福井県 訪問率推移



三重県 訪問率推移



滋賀県 訪問率推移



京都府 訪問率推移



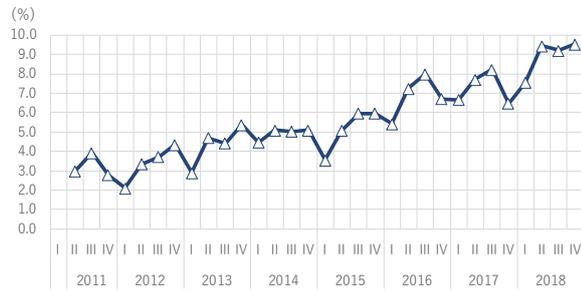
大阪府 訪問率推移



兵庫県 訪問率推移



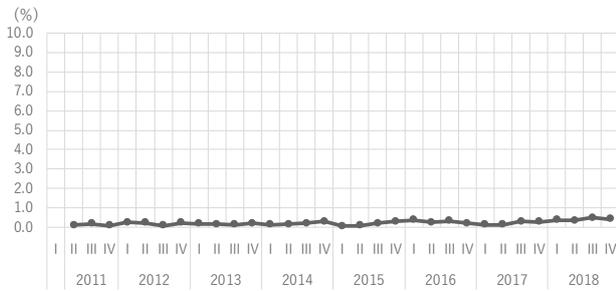
奈良県 訪問率推移



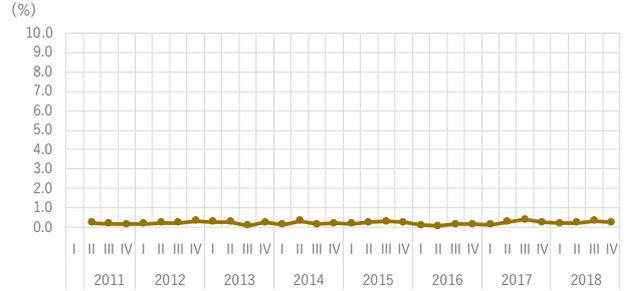
和歌山県 訪問率推移



鳥取県 訪問率推移



徳島県 訪問率推移



訪問率時系列モデル推計結果：2府8県、北海道、関東、中部、近畿、九州

■福井県

Dependent Variable: LOG(MR_FKI)
Method: ARMA Maximum Likelihood (BFGS)
Date: 05/07/19 Time: 16:47
Sample: 2012M01 2018M12
Included observations: 84
Convergence achieved after 248 iterations
Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-1.788007	0.005076	-352.2796	0.0000
AR(1)	2.036076	0.118026	17.25106	0.0000
AR(2)	-1.005473	0.243913	-4.122261	0.0001
AR(3)	-0.815995	0.298562	-2.733079	0.0079
AR(4)	1.274469	0.230629	5.526062	0.0000
AR(5)	-0.545392	0.098348	-5.545538	0.0000
MA(1)	-0.772689	268.7861	-0.002875	0.9977
MA(2)	-0.655244	299.8640	-0.002185	0.9983
MA(3)	-0.364981	184.9070	-0.001974	0.9984
MA(4)	0.796027	754.9506	0.001054	0.9992
SIGMASQ	0.021344	2.265500	0.009421	0.9925
R-squared	0.879388	Mean dependent var	-1.768431	
Adjusted R-squared	0.862866	S.D. dependent var	0.423202	
S.E. of regression	0.156718	Akaike info criterion	-0.565423	
Sum squared resid	1.792930	Schwarz criterion	-0.247102	
Log likelihood	34.74776	Hannan-Quinn criter.	-0.437460	
F-statistic	53.22464	Durbin-Watson stat	2.044057	
Prob(F-statistic)	0.000000			
Inverted AR Roots	.95-.21i	.95+.21i	.50+.65i	.50-.65i
Inverted MA Roots	-1.00+.03i	1.00-.03i	-.61-.65i	-.61+.65i

■三重県

Dependent Variable: LOG(MR_MIE)
Method: ARMA Maximum Likelihood (BFGS)
Date: 05/07/19 Time: 16:50
Sample: 2012M01 2018M12
Included observations: 84
Convergence achieved after 97 iterations
Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.427943	0.095483	-4.481864	0.0000
AR(12)	-0.249850	0.135036	-1.850251	0.0681
MA(1)	1.562668	505.0137	0.003094	0.9975
MA(2)	1.671323	1126.373	0.001484	0.9988
MA(3)	0.684250	747.4014	0.000916	0.9993
MA(4)	0.318484	458.9450	0.000694	0.9994
SIGMASQ	0.018784	4.292746	0.004376	0.9965
R-squared	0.865258	Mean dependent var	-0.422952	
Adjusted R-squared	0.854759	S.D. dependent var	0.375613	
S.E. of regression	0.143148	Akaike info criterion	-0.854851	
Sum squared resid	1.577840	Schwarz criterion	-0.652283	
Log likelihood	42.90376	Hannan-Quinn criter.	-0.773421	
F-statistic	82.41046	Durbin-Watson stat	1.949099	
Prob(F-statistic)	0.000000			
Inverted AR Roots	.86+.23i	.86-.23i	.63-.63i	.63+.63i
Inverted MA Roots	-.23-.86i	.23+.86i	-.23+.86i	-.23-.86i
	-.63-.63i	-.63-.63i	-.86-.23i	-.86+.23i
	-.14+.55i	-.14-.55i	-.64-.76i	-.64+.76i

■滋賀県

Dependent Variable: LOG(MR_SHG)
Method: ARMA Maximum Likelihood (BFGS)
Date: 05/07/19 Time: 17:27
Sample: 2012M01 2018M12
Included observations: 84
Convergence achieved after 472 iterations
Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.528476	0.103324	-5.114729	0.0000
AR(1)	0.534306	0.090579	5.898813	0.0000
AR(2)	0.008391	0.000152	55.04724	0.0000
AR(3)	-0.942009	0.056818	-16.57937	0.0000
AR(4)	0.583905	0.095120	6.138640	0.0000
MA(1)	1.291014	1.447698	0.891770	0.3754
MA(2)	1.310698	1.767620	0.741504	0.4608
MA(3)	1.310369	1.518603	0.862878	0.3910
MA(4)	1.291334	1.844914	0.699943	0.4862
MA(5)	0.999548	2.601236	0.384259	0.7019
SIGMASQ	0.008050	0.012961	0.621051	0.5365
R-squared	0.890148	Mean dependent var	-0.493289	
Adjusted R-squared	0.875100	S.D. dependent var	0.272323	
S.E. of regression	0.096242	Akaike info criterion	-1.515812	
Sum squared resid	0.676168	Schwarz criterion	-1.197491	
Log likelihood	74.66412	Hannan-Quinn criter.	-1.387850	
F-statistic	59.15300	Durbin-Watson stat	2.366492	
Prob(F-statistic)	0.000000			
Inverted AR Roots	.61	.46+.86i	.46-.86i	-1.00
Inverted MA Roots	.43-.90i	.43+.90i	-.57-.82i	-.57+.82i
	-1.00			

■京都府

Dependent Variable: DLOG(MR_KYT)
Method: ARMA Maximum Likelihood (BFGS)
Date: 05/07/19 Time: 16:46
Sample: 2012M02 2018M12
Included observations: 83
Convergence achieved after 111 iterations
Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.007428	0.008270	0.898153	0.3721
AR(1)	-0.423538	0.534551	-0.792325	0.4308
SAR(12)	0.678474	0.163767	5.364165	0.0000
MA(1)	1.254420	34.19458	0.036685	0.9708
MA(2)	0.956364	60.46176	0.015818	0.9874
MA(3)	-0.751914	17.06081	-0.044073	0.9650
MA(4)	-0.919338	52.42298	-0.017537	0.9861
MA(5)	-0.650092	53.58366	-0.012132	0.9904
MA(6)	0.015596	1.435144	0.010867	0.9914
SMA(12)	-0.481288	0.378082	-1.272973	0.2071
SIGMASQ	0.001010	0.043164	0.023398	0.9814
R-squared	0.854806	Mean dependent var	0.009890	
Adjusted R-squared	0.834641	S.D. dependent var	0.083908	
S.E. of regression	0.034121	Akaike info criterion	-3.547771	
Sum squared resid	0.083824	Schwarz criterion	-3.227202	
Log likelihood	158.2325	Hannan-Quinn criter.	-3.418984	
F-statistic	42.38893	Durbin-Watson stat	1.947126	
Prob(F-statistic)	0.000000			
Inverted AR Roots	.99	.86-.49i	.86+.49i	.49-.86i
	.49+.86i	.00+.99i	-.00-.99i	-.42
	-.49+.86i	-.49-.86i	-.86+.49i	-.86-.49i
	.99			
Inverted MA Roots	.94	.89	.81-.47i	.81+.47i
	.47-.81i	.47+.81i	.02	.00+.94i
	.00-.94i	-.47+.81i	-.47-.81i	-.52+.70i
	-.52-.70i	-.57+.82i	-.57-.82i	-.81+.47i
	-.81-.47i	-.94		

■大阪府

Dependent Variable: DLOG(MR_OSQ)
Method: ARMA Maximum Likelihood (BFGS)
Date: 05/07/19 Time: 17:29
Sample: 2012M02 2018M12
Included observations: 83
Convergence achieved after 174 iterations
Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.007457	0.002447	3.047658	0.0032
AR(1)	-0.232929	0.146285	-1.592292	0.1157
AR(2)	0.270611	0.170290	1.589122	0.1164
AR(3)	0.443862	0.175166	2.533952	0.0135
SAR(12)	0.569312	0.123851	4.596745	0.0000
MA(1)	1.195279	364.9408	0.003275	0.9974
MA(2)	0.981497	257.3539	0.003814	0.9970
MA(3)	-0.981502	544.8322	-0.001801	0.9986
MA(4)	-1.195279	603.0075	-0.001982	0.9984
MA(5)	-0.999995	810.0076	-0.001235	0.9990
SIGMASQ	0.000325	0.024111	0.013473	0.9893
R-squared	0.811145	Mean dependent var	0.007551	
Adjusted R-squared	0.784915	S.D. dependent var	0.041726	
S.E. of regression	0.019351	Akaike info criterion	-4.702971	
Sum squared resid	0.026962	Schwarz criterion	-4.382402	
Log likelihood	206.1733	Hannan-Quinn criter.	-4.574184	
F-statistic	30.92447	Durbin-Watson stat	1.935713	
Prob(F-statistic)	0.000000			
Inverted AR Roots	.95	.83+ .48i	.83- .48i	.80
	.48+ .83i	.48- .83i	.00+ .95i	-.00- .95i
	-.48+ .83i	-.48- .83i	-.52+ .54i	-.52- .54i
	-.83+ .48i	-.83- .48i	-.95	
Inverted MA Roots	1.00	-.47- .89i	-.47+ .89i	-.63+ .77i
	-.63- .77i			

■兵庫県

Dependent Variable: LOG(MR_HYG)
Method: ARMA Maximum Likelihood (BFGS)
Date: 05/07/19 Time: 16:45
Sample: 2012M01 2018M12
Included observations: 84
Convergence achieved after 289 iterations
Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	1.812835	0.009728	186.3607	0.0000
AR(1)	1.891976	0.145156	13.03405	0.0000
AR(2)	-0.856527	0.390161	-2.195316	0.0315
AR(3)	-0.566443	0.366239	-1.546649	0.1265
AR(4)	0.978930	0.259739	3.768904	0.0003
AR(5)	-0.509703	0.399738	-1.275093	0.2065
AR(6)	-0.547961	0.351841	-1.557412	0.1239
AR(7)	1.117629	0.226197	4.940963	0.0000
AR(8)	-0.553298	0.122700	-4.509349	0.0000
SAR(12)	0.559657	0.136827	4.090243	0.0001
MA(1)	-0.076697	87.72974	-0.000874	0.9993
MA(2)	0.027306	95.40716	0.000286	0.9998
MA(3)	-0.950593	235.6640	-0.004034	0.9968
SIGMASQ	0.000440	0.042440	0.010366	0.9918
R-squared	0.950101	Mean dependent var	1.793486	
Adjusted R-squared	0.940834	S.D. dependent var	0.094460	
S.E. of regression	0.022977	Akaike info criterion	-4.345788	
Sum squared resid	0.036954	Schwarz criterion	-3.940652	
Log likelihood	196.5231	Hannan-Quinn criter.	-4.182927	
F-statistic	102.5257	Durbin-Watson stat	1.937106	
Prob(F-statistic)	0.000000			
Inverted AR Roots	.96- .14i	.96+ .14i	.95	.83+ .48i
	.83- .48i	.74- .53i	.74+ .53i	.48+ .83i
	.48- .83i	.09+ .91i	.09- .91i	.00+ .95i
	-.00- .95i	-.48+ .83i	-.48- .83i	-.83+ .48i
	-.83- .48i	-.84+ .36i	-.84- .36i	-.95
Inverted MA Roots	1.00	-.46+ .86i	-.46- .86i	

■奈良県

Dependent Variable: DLOG(MR_NRA)
Method: ARMA Maximum Likelihood (BFGS)
Date: 05/07/19 Time: 17:30
Sample: 2012M02 2018M12
Included observations: 83
Convergence achieved after 107 iterations
Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.028038	0.020984	1.336168	0.1856
AR(1)	-0.110959	0.081905	-1.354726	0.1796
AR(2)	0.001183	0.163311	0.007246	0.9942
AR(3)	-0.446933	0.109084	-4.097131	0.0001
SAR(12)	0.709869	0.302482	2.346813	0.0216
MA(1)	1.129809	259.9164	0.004347	0.9965
MA(2)	0.999996	460.0708	0.002174	0.9983
SMA(12)	-0.385348	0.386291	-0.997558	0.3217
SIGMASQ	0.002576	0.589292	0.004371	0.9965
R-squared	0.754451	Mean dependent var	0.022156	
Adjusted R-squared	0.727905	S.D. dependent var	0.103039	
S.E. of regression	0.053748	Akaike info criterion	-2.758205	
Sum squared resid	0.213775	Schwarz criterion	-2.495921	
Log likelihood	123.4655	Hannan-Quinn criter.	-2.652834	
F-statistic	28.42061	Durbin-Watson stat	2.051161	
Prob(F-statistic)	0.000000			
Inverted AR Roots	.97	.84- .49i	.84+ .49i	.49- .84i
	.49+ .84i	.35+ .66i	.35- .66i	.00- .97i
	-.00+ .97i	-.49+ .84i	-.49- .84i	-.80
	-.84+ .49i	-.84- .49i	-.97	
Inverted MA Roots	.92	.80+ .46i	.80- .46i	.46- .80i
	.46+ .80i	.00+ .92i	-.00- .92i	-.46- .80i
	-.46+ .80i	-.56- .83i	-.56+ .83i	-.80- .46i
	-.80+ .46i	-.92		

■和歌山県

Dependent Variable: LOG(MR_WAK)
Method: ARMA Maximum Likelihood (BFGS)
Date: 05/07/19 Time: 17:30
Sample: 2012M01 2018M12
Included observations: 84
Convergence achieved after 119 iterations
Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.107527	0.113592	0.946610	0.3468
AR(12)	0.771656	0.259810	2.970082	0.0040
MA(1)	1.784650	64.38631	0.027718	0.9780
MA(2)	2.239291	156.6346	0.014296	0.9886
MA(3)	1.247945	126.2135	0.009888	0.9921
MA(4)	0.570315	77.46925	0.007362	0.9941
SMA(12)	-0.428451	0.347549	-1.232779	0.2215
SIGMASQ	0.005924	0.124453	0.047596	0.9622
R-squared	0.902771	Mean dependent var	0.153820	
Adjusted R-squared	0.893815	S.D. dependent var	0.248308	
S.E. of regression	0.080914	Akaike info criterion	-1.916057	
Sum squared resid	0.497574	Schwarz criterion	-1.684550	
Log likelihood	88.47438	Hannan-Quinn criter.	-1.822993	
F-statistic	100.8081	Durbin-Watson stat	2.161363	
Prob(F-statistic)	0.000000			
Inverted AR Roots	.98	.85+ .49i	.85- .49i	.49+ .85i
	.49- .85i	-.00- .98i	-.00+ .98i	-.49- .85i
	-.49+ .85i	-.85+ .49i	-.85- .49i	-.98
Inverted MA Roots	.93	.81+ .47i	.81- .47i	.47+ .81i
	.47- .81i	-.00- .93i	-.00+ .93i	-.27+ .71i
	-.27- .71i	-.47+ .81i	-.47- .81i	-.62- .78i
	-.62+ .78i	-.81- .47i	-.81+ .47i	-.93

■鳥取県

Dependent Variable: LOG(MR_TOT)
Method: ARMA Maximum Likelihood (BFGS)
Date: 05/07/19 Time: 17:31
Sample: 2012M01 2018M12
Included observations: 84
Convergence achieved after 16 iterations
Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-1.523139	0.293030	-5.197899	0.0000
AR(1)	0.678001	0.147989	4.581442	0.0000
SAR(12)	0.763925	0.398551	1.916756	0.0590
MA(1)	0.803280	0.146419	5.486191	0.0000
MA(2)	0.622127	0.083866	7.418146	0.0000
SMA(12)	-0.593417	0.510514	-1.162391	0.2487
SIGMASQ	0.037592	0.005680	6.618575	0.0000

R-squared	0.883043	Mean dependent var	-1.559203
Adjusted R-squared	0.873929	S.D. dependent var	0.570339
S.E. of regression	0.202507	Akaike info criterion	-0.225539
Sum squared resid	3.157698	Schwarz criterion	-0.022971
Log likelihood	16.47265	Hannan-Quinn criter.	-0.144109
F-statistic	96.89356	Durbin-Watson stat	1.994231
Prob(F-statistic)	0.000000		

Inverted AR Roots	.98	.85+ .49i	.85- .49i	.68
	.49- .85i	.49+ .85i	.00+ .98i	-.00- .98i
	-.49- .85i	-.49+ .85i	-.85- .49i	-.85+ .49i
	-.98			
Inverted MA Roots	.96	.83- .48i	.83+ .48i	.48+ .83i
	.48- .83i	.00+ .96i	-.00- .96i	-.40- .68i
	-.40+ .68i	-.48+ .83i	-.48- .83i	-.83- .48i
	-.83+ .48i	-.96		

■徳島県

Dependent Variable: LOG(MR_TOK)
Method: ARMA Maximum Likelihood (BFGS)
Date: 05/07/19 Time: 17:31
Sample: 2012M01 2018M12
Included observations: 84
Convergence achieved after 233 iterations
Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-1.567160	0.041288	-37.95722	0.0000
AR(1)	0.857746	0.135245	6.342168	0.0000
SAR(12)	0.735636	0.340815	2.158463	0.0341
MA(1)	0.572616	123.8220	0.004625	0.9963
MA(2)	0.196476	128.6670	0.001527	0.9988
MA(3)	-0.843712	242.2290	-0.003483	0.9972
MA(4)	-0.495925	212.5961	-0.002333	0.9981
MA(5)	-0.429452	258.3164	-0.001663	0.9987
SMA(12)	-0.522168	0.465443	-1.121872	0.2655
SIGMASQ	0.025261	1.241968	0.020339	0.9838

R-squared	0.857093	Mean dependent var	-1.545321
Adjusted R-squared	0.839712	S.D. dependent var	0.422956
S.E. of regression	0.169334	Akaike info criterion	-0.518043
Sum squared resid	2.121888	Schwarz criterion	-0.228661
Log likelihood	31.75783	Hannan-Quinn criter.	-0.401714
F-statistic	49.31317	Durbin-Watson stat	1.973348
Prob(F-statistic)	0.000000		

Inverted AR Roots	.97	.86	.84+ .49i	.84- .49i
	.49+ .84i	.49- .84i	-.00- .97i	-.00+ .97i
	-.49- .84i	-.49+ .84i	-.84+ .49i	-.84- .49i
	-.97			
Inverted MA Roots	1.00	.95	.82+ .47i	.82- .47i
	.47+ .82i	.47- .82i	.00+ .95i	-.00- .95i
	-.17- .70i	-.17+ .70i	-.47+ .82i	-.47- .82i
	-.61+ .67i	-.61- .67i	-.82+ .47i	-.82- .47i
	-.95			

■北海道運輸局

Dependent Variable: DLOG(MR_HKD)
Method: ARMA Maximum Likelihood (BFGS)
Date: 05/07/19 Time: 17:32
Sample: 2012M02 2018M12
Included observations: 83
Convergence achieved after 150 iterations
Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.000525	0.000602	-0.872643	0.3858
AR(1)	2.191789	0.123750	17.71139	0.0000
AR(2)	-1.872535	0.277022	-6.759526	0.0000
AR(3)	0.153003	0.329815	0.463904	0.6442
AR(4)	1.382687	0.215629	6.412351	0.0000
AR(5)	-1.507009	0.273045	-5.519269	0.0000
AR(6)	0.802784	0.273216	2.938273	0.0045
AR(7)	-0.273081	0.121769	-2.242609	0.0281
SAR(12)	0.780857	0.174818	4.466674	0.0000
MA(1)	-1.999585	0.502937	-3.975814	0.0002
MA(2)	0.999992	0.487678	2.050516	0.0441
SMA(12)	-0.170681	0.349575	-0.488253	0.6269
SIGMASQ	0.003566	0.011890	0.299931	0.7651

R-squared	0.926735	Mean dependent var	-0.010484
Adjusted R-squared	0.914175	S.D. dependent var	0.221970
S.E. of regression	0.065028	Akaike info criterion	-2.245948
Sum squared resid	0.296004	Schwarz criterion	-1.867093
Log likelihood	106.2068	Hannan-Quinn criter.	-2.093745
F-statistic	73.78636	Durbin-Watson stat	1.846555
Prob(F-statistic)	0.000000		

Inverted AR Roots	.98	.93+ .25i	.93- .25i	.85+ .49i
	.85- .49i	.49- .85i	.49+ .85i	.47+ .75i
	.47- .75i	.17+ .61i	.17- .61i	.00+ .98i
	-.00- .98i	-.49- .85i	-.49+ .85i	-.85- .49i
	-.85+ .49i	-.93	-.98	
Inverted MA Roots	1.00- .02i	1.00+ .02i	.86	.75+ .43i
	.75- .43i	.43+ .75i	.43- .75i	.00- .86i
	-.00+ .86i	-.43+ .75i	-.43- .75i	-.75+ .43i
	-.75- .43i	-.86		

■関東運輸局

Dependent Variable: DLOG(MR_KNT)
Method: ARMA Maximum Likelihood (BFGS)
Date: 05/07/19 Time: 17:32
Sample: 2012M02 2018M12
Included observations: 83
Convergence achieved after 31 iterations
Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.002692	0.001851	-1.453810	0.1502
AR(1)	0.884506	0.071454	12.37874	0.0000
SAR(12)	0.999994	0.000114	8764.329	0.0000
MA(1)	0.003726	15.05036	0.000248	0.9998
MA(2)	-0.003877	15.42532	-0.000251	0.9998
MA(3)	-0.999814	99.41779	-0.010057	0.9920
SMA(12)	-0.996805	0.003776	-263.9798	0.0000
SIGMASQ	7.46E-05	0.001391	0.053640	0.9574

R-squared	0.780380	Mean dependent var	-0.002997
Adjusted R-squared	0.759882	S.D. dependent var	0.018547
S.E. of regression	0.009088	Akaike info criterion	-6.149979
Sum squared resid	0.006195	Schwarz criterion	-5.916838
Log likelihood	263.2241	Hannan-Quinn criter.	-6.056316
F-statistic	38.07134	Durbin-Watson stat	1.976454
Prob(F-statistic)	0.000000		

Inverted AR Roots	1.00	.88	.87- .50i	.87+ .50i
	.50+ .87i	.50- .87i	.00+ 1.00i	-.00- 1.00i
	-.50+ .87i	-.50- .87i	-.87- .50i	-.87+ .50i
	1.00			
Inverted MA Roots	1.00	1.00	.87+ .50i	.87- .50i
	.50+ .87i	.50- .87i	.00+ 1.00i	-.00- 1.00i
	-.50+ .87i	-.50- .87i	-.50- .86i	-.50+ .86i
	-.87- .50i	-.87+ .50i	1.00	

■ 中部運輸局

Dependent Variable: LOG(MR_TYU)
Method: ARMA Maximum Likelihood (BFGS)
Date: 05/07/19 Time: 17:33
Sample: 2012M01 2018M12
Included observations: 84
Convergence achieved after 50 iterations
Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	2.569038	0.041170	62.40010	0.0000
AR(1)	1.121765	0.401342	2.795038	0.0066
AR(2)	0.572149	0.753389	0.759433	0.4501
AR(3)	-0.907260	0.298107	-3.043403	0.0033
AR(4)	0.171331	0.321391	0.533092	0.5956
AR(5)	0.014219	0.213951	0.066457	0.9472
SAR(12)	0.731691	0.084036	8.706835	0.0000
MA(1)	0.824952	43.14249	0.019122	0.9848
MA(2)	-0.016014	45.22703	-0.000354	0.9997
MA(3)	-1.050328	98.17383	-0.010699	0.9915
MA(4)	-0.758611	107.9721	-0.007026	0.9944
SIGMASQ	0.000936	0.073912	0.012659	0.9899
R-squared	0.956383	Mean dependent var	2.606713	
Adjusted R-squared	0.949720	S.D. dependent var	0.147342	
S.E. of regression	0.033039	Akaike info criterion	-3.631917	
Sum squared resid	0.078592	Schwarz criterion	-3.284657	
Log likelihood	164.5405	Hannan-Quinn criter.	-3.492321	
F-statistic	143.5222	Durbin-Watson stat	2.231145	
Prob(F-statistic)	0.000000			
Inverted AR Roots	.97 .84-.49i -.00-.97i -.49+.84i	.86+.05i .49+.84i -.00+.97i -.84+.49i	.86-.05i .49-.84i -.06 -.84-.49i	.84+.49i .34 -.49-.84i -.89
Inverted MA Roots	1.00	-.53+.85i	-.53-.85i	-.76

■ 近畿運輸局(図表3-3再掲)

Dependent Variable: DLOG(MR_KNK)
Method: ARMA Maximum Likelihood (BFGS)
Date: 05/07/19 Time: 17:48
Sample: 2012M02 2018M12
Included observations: 83
Convergence achieved after 260 iterations
Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.004136	0.001439	2.874839	0.0053
AR(1)	-0.215118	0.139822	-1.538507	0.1282
SAR(12)	0.641447	0.117559	5.456404	0.0000
MA(1)	1.081934	20.67308	0.052335	0.9584
MA(2)	0.771999	33.46881	0.023066	0.9817
MA(3)	-1.020374	15.76983	-0.064704	0.9486
MA(4)	-1.044306	17.24592	-0.060554	0.9519
MA(5)	-0.789171	20.91637	-0.037730	0.9700
SIGMASQ	0.000439	0.021815	0.020136	0.9840
R-squared	0.860480	Mean dependent var	0.006251	
Adjusted R-squared	0.845397	S.D. dependent var	0.056452	
S.E. of regression	0.022197	Akaike info criterion	-4.438203	
Sum squared resid	0.036459	Schwarz criterion	-4.175919	
Log likelihood	193.1854	Hannan-Quinn criter.	-4.332832	
F-statistic	57.04897	Durbin-Watson stat	2.015494	
Prob(F-statistic)	0.000000			
Inverted AR Roots	.96 .48-.83i -.48+.83i -.96	.83-.48i .00+.96i -.48-.83i -.83-.48i	.83+.48i -.00-.96i -.83-.48i -.83+.48i	.48+.83i -.22 -.83+.48i -.83+.48i
Inverted MA Roots	1.00	-.45+.76i	-.45-.76i	-.59-.81i
		-.59+.81i		

■ 九州運輸局

Dependent Variable: LOG(MR_KYU)
Method: ARMA Maximum Likelihood (BFGS)
Date: 05/07/19 Time: 17:59
Sample: 2012M01 2018M12
Included observations: 84
Convergence achieved after 164 iterations
Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	2.426873	0.013586	178.6272	0.0000
AR(1)	0.910044	0.107183	8.490577	0.0000
SAR(12)	0.857511	0.166528	5.149365	0.0000
MA(1)	0.914729	42.34000	0.021604	0.9828
MA(2)	1.008124	78.02391	0.012921	0.9897
MA(3)	-0.476523	29.81830	-0.015981	0.9873
MA(4)	-0.379712	23.45797	-0.016187	0.9871
MA(5)	-0.597169	16.67085	-0.035821	0.9715
MA(6)	-0.475367	45.53756	-0.010439	0.9917
MA(7)	-0.539938	61.36138	-0.008799	0.9930
MA(8)	-0.453962	63.37619	-0.007163	0.9943
SMA(12)	-0.499638	0.320195	-1.560418	0.1231
SIGMASQ	0.000361	0.028102	0.012853	0.9898
R-squared	0.970821	Mean dependent var	2.430763	
Adjusted R-squared	0.965890	S.D. dependent var	0.111930	
S.E. of regression	0.020672	Akaike info criterion	-4.493414	
Sum squared resid	0.030341	Schwarz criterion	-4.117216	
Log likelihood	201.7234	Hannan-Quinn criter.	-4.342186	
F-statistic	196.8560	Durbin-Watson stat	1.903015	
Prob(F-statistic)	0.000000			
Inverted AR Roots	.99 .49-.86i -.49-.86i -.99	.91 .49+.86i -.49+.86i -.99	.86-.49i .00+.99i -.86+.49i -.86-.49i	.86+.49i -.00-.99i -.86-.49i -.86+.49i
Inverted MA Roots	1.00 .47-.82i .00+.94i -.47+.82i -.71	.94 .47+.82i .00-.94i -.47-.82i -.82+.47i	.82-.47i .38+.70i -.40+.91i -.58-.81i -.82-.47i	.82+.47i .38-.70i -.40-.91i -.58+.81i -.94

<APIR 研究統括/数量経済分析センター長 稲田 義久、主席研究員 松林 洋一、研究推進部員
野村亮輔、contact@apir.or.jp, 06-6485-7690>

- ・本レポートは、執筆者の見解に基づき作成されたものであり、当研究所の見解を示すものではありません。
- ・本レポートは信頼できると思われる各種データに基づいて作成されていますが、その正確性、完全性を保証するものではありません。また、記載された内容は、今後予告なしに変更されることがあります。