

事例研究 [論文]

COVID-19の脅威とメディア利用行動の変化 —消費者セグメントの遷移の把握—

猪狩 良介, 竹内 真登

1. はじめに

新型コロナウイルス感染症 (COVID-19) のまん延とそれに伴う行動自粛により, 消費者の生活様式は大きく様変わりしている. NHK オンライン [1] によると, 2020 年 1 月 15 日に日本国内で COVID-19 の感染者が初めて確認され, 同 2 月には国内で初の死者が出るなど, 本格的に国内で感染の広がりを見せた. 感染者は 3 月以降さらに増加し, 4 月には全国で緊急事態宣言が発出された. 緊急事態宣言の発出と外出自粛要請によって, 消費者の多くは自宅での生活を余儀なくされ, 生活や消費行動にも変化が起きた.

本研究では, COVID-19 のまん延する最中の消費者のメディア利用行動の変化に着目する. COVID-19 の感染拡大やそれに伴う緊急事態宣言により, 消費者は一時外出自粛を余儀なくされた. それに伴い, 持て余した時間を過ごすために, テレビやインターネット動画の視聴や SNS 利用などさまざまなメディア・サービスの利用時間が増加したと考えられる. 一方で, 2020 年 5 月末に緊急事態宣言が解除され, 消費者は自宅外での活動のある程度再開した. また, 夏秋には Go To トラベルなどの政府による政策 [2] もあいまって, 多くの消費者が日常生活へと舵を切った. 本研究では, COVID-19 のまん延や, まん延防止にむけた外出自粛などの行動に起因するメディアの利用行動の変化や閲覧・利用するジャンルの変化を分析する. コロナ前とコロナ禍でのメディア利用行動の変化と, 緊急事態宣言明けに利用時間が元に戻ったのか, もしくは宣言明けも元に戻らなかったのか, などを明らかにすること

は学術的に重要な研究課題である.

実際, 既存研究には行動変容と, その新しい行動の習慣化もしくは以前の習慣に戻るのかについて議論するものもあり, 特にソーシャルメディアやストーリーミングサービスは消費者行動を大きく変化させる可能性を秘めているという [3]. つまり, 未曾有のパンデミックの最中, 消費者がどのようにメディアの利用行動を変容させて, 新しい行動を習慣化させたか, それとも元の行動に戻っていったか, その詳細を記録すること自体に学術的な意義がある. こうした記録は, COVID-19 収束後に, 行動変容に関する経済的, 社会的な影響に関する観点はもちろんのこと, メディアの利用時間の増加が外出自粛に有効であったか, またそれはどのような消費者に対して有効だったのかなど, さまざまな角度から COVID-19 のパンデミックに関連した影響を検証し直す際の重要な資料になりえる. さらに社会的意義として, 将来において大規模な自然災害および類似のパンデミックが生じた際の消費者の行動を考える際の手助けにもなる.

COVID-19 が日本で本格的にまん延する前に総務省情報通信政策研究所が 2020 年 1 月に実施した調査 [4] では, 1 日当たりのテレビのリアルタイム視聴の平均時間は平日 161.2 分, 休日 215.9 分, インターネットの平均閲覧時間は平日 126.2 分, 休日 131.5 分である. 一方で, 同研究所が, COVID-19 のまん延後の 2021 年 1 月に実施した調査 [5] では, テレビのリアルタイム視聴の平均時間は平日 163.2 分, 休日 223.3 分と特に休日で約 7.4 分増加している. また, 2021 年 1 月のインターネット平均閲覧時間は平日 168.4 分, 休日 174.9 分と, いずれも大幅に増加していることがわかる. 一方で, 博報堂 DY メディアパートナーズが毎年実施しているメディア定点調査の時系列分析 [6] によると, 2020 年 1~2 月初旬の調査では 1 日当たり/週平均のテレビの平均視聴時間は 144.2 分, パソコンの平均利用時間は 64.9 分, 携帯電話/スマートフォンの平均利用時間は 121.2 分であった. 一方で, 2021 年同時

いがり りょうすけ

法政大学経営学部

〒 102-8160 東京都千代田区富士見 2-17-1

r-igari@hosei.ac.jp

たけうち まきと

東北学院大学経営学部

〒 980-8511 宮城県仙台市青葉区土樋 1-3-1

受付 22.4.18 採択 22.11.21

期の調査ではテレビの平均視聴時間は 150.0 分、パソコンの平均利用時間は 73.3 分、携帯電話/スマートフォンの平均利用時間は 139.2 分と、いずれの利用時間も増加していることがわかる。特に 2020 年から 2021 年ではメディア総利用時間は 411.7 分から 450.9 分と大きく増加している。このように、COVID-19 の国内での流行前後では、メディア利用時間が大きく変化していることがわかる。しかし、いずれも調査年度によって異なる対象者に調査を実施しており、メディア利用行動の変化を個人レベルで確認することは難しい。また、これらのデータはアンケートベースの質問からメディアの利用時間を取得しており、消費者の行動をログで記録したものではない。

本研究では、2019～2020 年の 2 年間にわたりメディア利用をログで記録しているシングルソースデータを用いて、個人レベルの複数メディア（テレビとインターネット）の利用時間の変化を捉える分析を行う。また、それぞれのメディア・ジャンルにおいて視聴・閲覧するジャンルは異なると考えられる。たとえば、テレビではドラマやスポーツだけを視聴し、インターネットでは動画サイトだけを閲覧する消費者もおり、ニュースやドラマなど、特定のジャンルの視聴/閲覧時間が増えていることも考えられることから、複数メディアのジャンル別の利用を扱う。また、メディア利用時間の変化を捉える場合、期間別に平均を比較する、またデータを週などで集計して時系列解析を用いて分析する方法などが考えられる。しかし、これらの集計モデルでは、利用時間の増減の検証のみにとどまり、実際に変化した消費者の特性や変化の要因などを解明することは難しい。本研究では、複数メディアの各ジャンルにおける週別の利用時間の傾向をセグメンテーションとして潜在的なグループレベルで捉え、セグメント別のメディア利用時間の変化と、セグメントの時間による遷移を捉えるモデルを提案する。潜在セグメントの時間変化は隠れマルコフモデル (Hidden Markov Model; HMM) によって表現し、セグメントの遷移に対する COVID-19 の感染拡大に起因する影響を捉える。

2. メディア利用行動のセグメンテーション

2.1 先行文献

セグメンテーションは、マーケティング分野では古くから用いられており、その方法論については Wedel and Kamakura [7] にまとめられている。セグメンテーションを統計分析により行うには、一般的には潜在クラスモデルが用いられている [8–10]。クラスター分析

と比較した潜在クラスモデルの利点は、回帰モデルやロジットモデルなどの消費者行動分析に利用される統計モデルの背後に潜在セグメントを仮定できる点にある。これにより、セグメントによる傾向（平均や分散など）の違いや、回帰係数のセグメントによる違いを見ることができる。しかし、潜在クラスモデルでは消費者のセグメントの所属は一定で、時間によってセグメントへの所属が動かないことを仮定している。COVID-19 の感染拡大や感染防止対策により消費者の生活は変化していると考えられ、セグメントの時間による変化を認めた分析が必要とされる。

そこで、セグメントへの所属を一定とするのではなく、時間による遷移を認めたモデルも提案されている。特に、HMM を用いて潜在的な状態（セグメント）の動的変化を捉える研究がマーケティング分野で多く提案されている [11–13]。HMM では、潜在的な状態にマルコフ過程を導入することで、潜在状態の時間変化を表現することができる。加えて、共変量を導入することで、潜在状態の遷移に影響を与える要因を考察することが可能になる。マーケティングにおける HMM の応用については、Netzer et al. [14] を参照されたい。

2.2 分析モデル

消費者 i ($= 1, \dots, n$)、時点 t ($= 1, \dots, T$)、メディア k ($= 1, \dots, K$)、メディア k におけるジャンル j_k ($= 1, \dots, J_k$) のメディア利用時間 y_{itkjk} を考える。ここで y_{itkjk} は利用していない場合は 0 を取り、利用している場合は 0 より大きい値を取る打ち切りデータである。 y_{itkjk} の潜在的な利用時間を y_{itkjk}^* とすると、 $y_{itkjk} = \max(0, y_{itkjk}^*)$ となる。

背後に観測されない潜在状態 m ($= 1, \dots, M$) を仮定した HMM を導入する。消費者 i の時点 t における状態を表すインディケータを z_{it} とすると、潜在状態 $z_{it} = m$ を所与とした潜在的なメディア利用時間を、

$$\mathbf{y}_{it}^* | z_{it} = m \sim MVN(\boldsymbol{\mu}_t^{(m)}, \boldsymbol{\Sigma}^{(m)}), \quad (1)$$

と表現する。ここで、 $\mathbf{y}_{it}^* = (y_{it11}^*, \dots, y_{itKJ_K}^*)^T$ 、 $\boldsymbol{\mu}_t^{(m)} = (\mu_{t11}^{(m)}, \dots, \mu_{tKJ_K}^{(m)})^T$ である。 $\mu_{tjk}^{(m)}$ は状態 m におけるメディア k のジャンル j_k の時点 t の平均、 $\boldsymbol{\Sigma}^{(m)}$ は分散共分散行列である。

また、平均 $\boldsymbol{\mu}_t^{(m)}$ は平均 $\bar{\boldsymbol{\mu}}^{(m)}$ 、分散共分散行列 $\boldsymbol{\Psi}^{(m)}$ をもつ多変量正規分布に従うと仮定する。

$$\boldsymbol{\mu}_t^{(m)} \sim MVN(\bar{\boldsymbol{\mu}}^{(m)}, \boldsymbol{\Psi}^{(m)}). \quad (2)$$

これにより、潜在セグメント別のメディア・ジャンルの利用時間の違いを把握することができる。

次に、HMMの潜在状態の時間変化を表現する。潜在状態 z_{it} は、一次のマルコフ過程に従うと仮定する。遷移確率行列は、

$$p(z_{it}|z_{it-1}) = \begin{bmatrix} p(z_{it}=1|z_{it-1}=1) \cdots p(z_{it}=M|z_{it-1}=1) \\ \vdots \quad \ddots \quad \vdots \\ p(z_{it}=1|z_{it-1}=M) \cdots p(z_{it}=M|z_{it-1}=M) \end{bmatrix}, \quad (3)$$

となる。ここで、 $\sum_{l=1}^M p(z_{it}=l|z_{it-1}=m') = 1, \forall m'$ である。

状態 m' から状態 m に遷移する確率は、多項ロジットモデルにより、

$$p(z_{it}=m|z_{it-1}=m') = \frac{\exp(v_{itm|m'})}{\sum_{l=1}^M \exp(v_{itl|m'})} \quad (4)$$

for $m' = 1, \dots, M,$

と表現する。 $v_{itm|m'}$ はロジットモデルの確定項である。

$$v_{itm|m'} = \mathbf{w}_t^T \boldsymbol{\lambda}_{m|m'} \quad \text{for } m' = 1, \dots, M. \quad (5)$$

ここで、 \mathbf{w} は潜在状態の推移を説明する共変量である。また、ロジットモデルの識別性のため $\boldsymbol{\lambda}_{m|m} = \mathbf{0}$ とする。

さらに、初期時点 ($t = 1$) の状態 z_{i1} は消費者のデモグラフィック属性 \mathbf{d} を説明変数とした多項ロジットモデルで表現する。

$$p(z_{i1}=m|\boldsymbol{\gamma}) = \frac{\exp(v_{i1m})}{\sum_{l=1}^M \exp(v_{i1l})}. \quad (6)$$

ここで、 v_{i1m} はロジットモデルの確定項であり、

$$v_{i1m} = \mathbf{d}_i^T \boldsymbol{\gamma}_m, \quad (7)$$

と表現する。また、識別性のため $\boldsymbol{\gamma}_M = \mathbf{0}$ とする。

本研究では、モデルはベイズ統計学の枠組みで表現し、母数の推定にはマルコフ連鎖モンテカルロ (Markov chain Monte Carlo; MCMC) 法を用いる。なお、各母数の事前分布としては、 $\Lambda_{m'} = (\boldsymbol{\lambda}_{1|m'}, \dots, \boldsymbol{\lambda}_{m'-1|m'}, \boldsymbol{\lambda}_{m'+1|m'}, \dots, \boldsymbol{\lambda}_{M|m'})^T$ 、 $\Gamma = (\boldsymbol{\gamma}_1^T, \dots, \boldsymbol{\gamma}_{M-1}^T)^T$ 、 $\bar{\boldsymbol{\mu}}^{(m)}$ には多変量正規分布を、 $\Sigma^{(m)}$ 、 $\Psi^{(m)}$ には逆ウィシャート分布をそれぞれ設定する。また、 $\boldsymbol{\mu}_t^{(m)}$ の事前分布は $MVN(\bar{\boldsymbol{\mu}}^{(m)}, \Psi^{(m)})$ となる。ベイズ統計学を用いた HMM の母数の推定については Scott [15] や Miglioretti [16] を参照されたい。

3. 実証分析

3.1 データ

分析には、株式会社ビデオリサーチが提供する VR CUBIC データ [17] を用いる¹。VR CUBIC は、消費者のメディア利用に焦点を当てたシングルソースデータであり、消費者の複数メディアの利用をログにより記録している。本研究では、テレビ視聴とインターネット利用の二つのメディアに焦点を当てる ($K = 2$)。インターネットはパソコン・タブレット端末・スマートフォンからの利用を対象としている²。

分析には、2019年1月から2020年12月までの2年間のデータを用いる。また、データは各消費者について週別のメディア利用時間を利用する ($T = 104$)。なお、104週のすべてにおいて、テレビとインターネットの双方のデータが取得できている人から200人を抽出して分析する ($n = 200$)。

テレビはリアルタイム視聴を対象とし、「報道」「教育・教養」「ドラマ」「娯楽」「その他」の5ジャンルを分析に用いる。一方で、インターネットはブラウザ利用を対象とし、「動画」「SNS」「その他」の3ジャンルを分析に用いる³。各メディア・ジャンルの要約統計量を表1に示す。なお、メディア利用時間は(分/週)を用い、分析時には $\log(\text{利用時間} + 1)$ と変換する。

メディア利用時間を週平均した時系列グラフを図1に

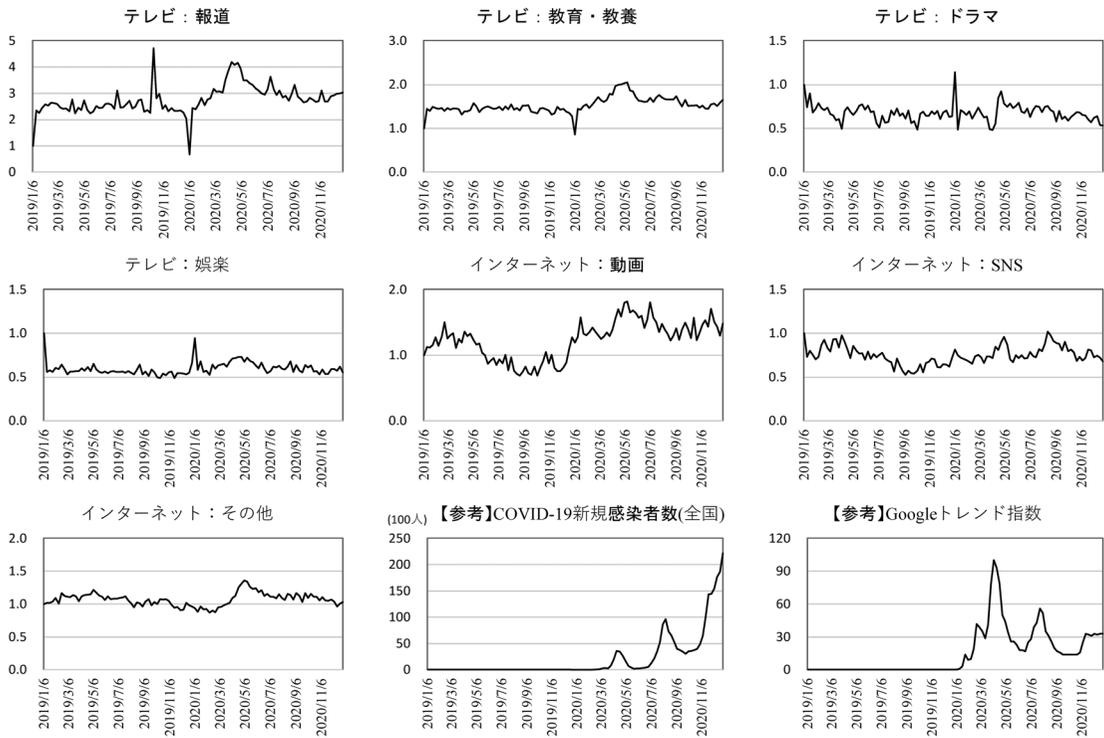
表1 メディア利用時間 (分/週)

		平均	中央値	標本 標準偏差
テレビ	報道	336.5	198.0	407.4
	教育・教養	562.7	353.0	653.2
	ドラマ	106.7	33.0	179.0
	娯楽	429.5	273.0	480.0
	その他	143.7	71.0	216.5
インター ネット	動画	78.7	0.0	276.5
	SNS	75.7	0.0	317.1
	その他	712.0	298.6	941.7

¹ 本研究では2019~2020年の2年間のデータを分析する。これは、2018年にデータ解析コンペティションで提供されたデータとは期間が異なる。また、VR CUBICの調査地区は関東1都6県(東京都・神奈川県・埼玉県・千葉県・茨城県・栃木県・群馬県)である。

² 本データはスマートフォンやタブレット端末によるアプリ利用のデータも取得しているが、アプリの利用時間を連続で取得できていないこと、また2年間のデータを取得している対象者が非常に少ないことから、分析対象から外している。

³ YouTubeは「動画」に、ブログやTikTokは「SNS」にそれぞれ含まれる。



※横軸の日付は週の最終日(日曜日)を表す。

図 1 平均利用時間の時系列プロット (初期時点を 1 とした比)

示す。なお、各メディア・ジャンルの条件を合わせるため、図 1 ではそれぞれ初期時点を 1 とした比をプロットする。横軸の日付は 1 週間のうちの最終日(日曜日)を表示している。また、参考までに COVID-19 の新規感染者数(全国)と「Googleトレンドのコロナの指数 [18]⁴」も一緒に図に示す。メディア利用時間には季節性が存在していることがわかるが、2019 年の変動と比較して、テレビの「報道」や「教育・教養」の視聴時間やインターネットの「動画」「その他」の利用時間が 2020 年以降大きく変動していることがわかる。

次に、初期時点のセグメントへの所属を説明するデモグラフィック属性 \mathbf{d}_i を定義する。 \mathbf{d}_i としては、「定数項」「年齢」「性別(男性=1)」「結婚(既婚=1)」を利用

⁴ キーワード「コロナ」でトレンドを確認している。1 未満の期間(COVID-19 流行前)は 0 とした。感染者数では捉えられない COVID-19 のインパクトの強さとして用いる。一見するとインターネット利用時間が増加すると Googleトレンド指標が高くなるという関係があると考えられる。しかし、Googleトレンドの指数は全体的な検索の集計値であり、個人レベルのインターネット利用時間との直接的な関係は小さいと考える。また、Googleトレンドのコロナの指数をメディア利用を説明する変数として直接用いていないのは、新規感染者数では捉えられない COVID-19 への消費者の関心がセグメントの遷移に与える影響を知りたいためである。

表 2 MSE および MSE 比

クラス数	MSE	MSE 比
クラス数 1	5.00	1.00
クラス数 2	4.62	0.92
クラス数 3	3.88	0.78
クラス数 4	4.92	0.98

する。年齢の平均は 48.3、性別の男性の割合は 0.66、既婚の割合は 0.67 であった。加えて、HMM の共変量 \mathbf{w} としては、COVID-19 の流行によるセグメントの変化を検証するために、日本の COVID-19 およびその影響に関連した週別の変数を利用する。具体的には、 \mathbf{w} として「定数項」「log(全国の COVID-19 の新規感染者数+1)」「Googleトレンドのコロナの指数 [18]」「緊急事態宣言ダミー」「2020 年ダミー」を利用する。なお、全国の COVID-19 の感染者数は NHK オンライン [19] より作成した。

3.2 セグメント数の決定

MCMC は全体で 15,000 回行い、うち最初の 10,000 回を burn-in とし、最後の 5,000 回のサンプリング値を用いて事後平均や事後標準偏差などを算出する。Geweke [20] の方法により MCMC の収束を確認

表3 セグメントの特徴 $\bar{\mu}^{(m)}$ (事後平均・95%信用区間)

	クラス1	クラス2	クラス3
構成比 (全期間平均)	38.0%	28.0%	34.0%
$\bar{\mu}^{(m)}$ TV (報道)	5.76 (5.70, 5.82)	5.69 (5.64, 5.74)	1.29 (1.17, 1.41)
TV (教育・教養)	6.41 (6.37, 6.45)	6.20 (6.16, 6.24)	2.08 (1.98, 2.18)
TV (ドラマ)	3.96 (3.88, 4.03)	3.83 (3.74, 3.91)	-1.53 (-1.70, -1.37)
TV (娯楽)	6.16 (6.12, 6.20)	5.94 (5.89, 5.99)	1.75 (1.64, 1.86)
TV (その他)	4.63 (4.56, 4.70)	4.59 (4.51, 4.67)	0.51 (0.35, 0.66)
インターネット (動画)	0.34 (0.21, 0.47)	-13.88 (-15.52, -12.44)	-1.54 (-1.78, -1.29)
インターネット (SNS)	1.30 (1.21, 1.40)	-7.60 (-8.27, -6.98)	-0.75 (-0.94, -0.58)
インターネット (その他)	6.70 (6.66, 6.73)	0.99 (0.85, 1.12)	4.92 (4.81, 5.02)

した。分析には、HMMを導入しないモデル(クラス数1)およびHMM(クラス数2~4)を計算した。クラス数の決定には平均二乗誤差(Mean Squared Error; MSE)⁵およびMSE比⁶を用いる。クラス数3が最良モデルという結果になった(表2)。以後、クラス数3の結果を解釈する。

3.3 結果(1)セグメントの特徴と利用時間の変化

全期間のセグメント構成比およびセグメント別のメディア・ジャンルの期間平均の母数 $\bar{\mu}^{(m)}$ の推定結果を表3に示す。 $\bar{\mu}^{(m)}$ は事後平均および95%ベイズ信用区間を示す。全期間平均のセグメント構成比は、クラス1が38.0%、クラス2が28.0%、クラス3が34.0%という結果となり、いずれのセグメントもある程度のボリュームがあることが窺える。

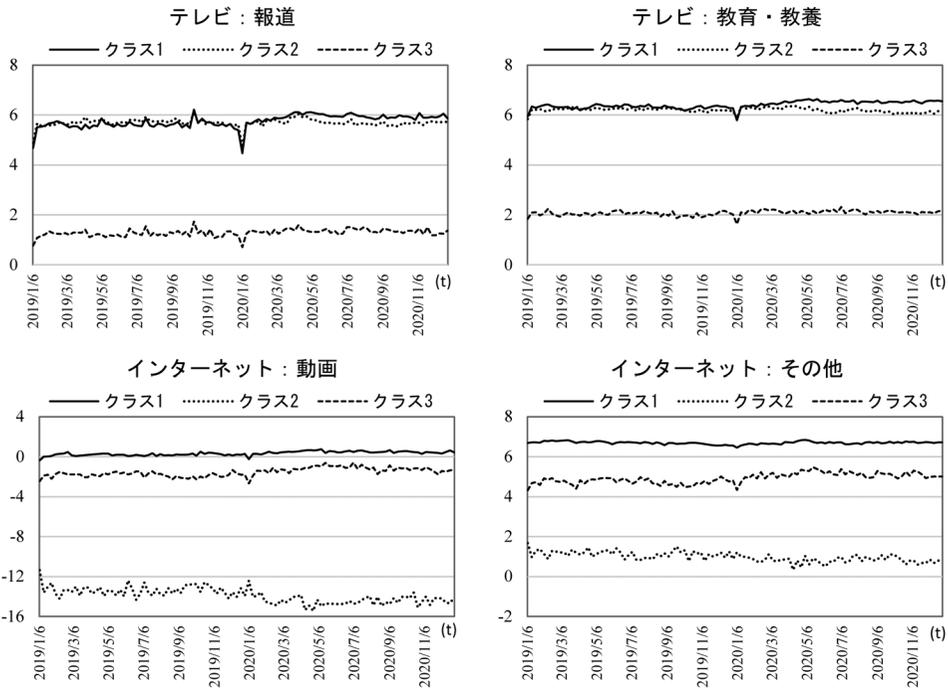
次に、セグメント別の期間平均の母数 $\bar{\mu}^{(m)}$ を解釈する。分析時に利用時間の対数変換を行っており、また潜在的な利用時間 y_{itkjk}^* を導入していることから、一部の推定結果はマイナスとなっている。まず、クラス1では、テレビ・インターネット双方の各ジャンルの平均が他のクラスより大きく、いずれのメディア・ジャンルも多く利用しているセグメントであることがわかる。一方でクラス2については、テレビの各ジャンルの平均はクラス1同様に高いが、インターネットの平均が低いことがわかる。つまり、TVのみの利用に特化しており、インターネットはほぼ利用しないセグメントであると解釈することができる。一方でクラス3はテレビの各ジャンルおよびインターネットの動画・SNSの平均はクラス1・2と比較してかなり低く、インターネット(その他)だけはクラス1ほどではないが平均がある程度高い。クラス3は、あまりテレビ

を視聴せず、またSNSやインターネット動画なども見ないセグメントである。インターネット(その他)はECサイトでの購入やメールの利用、検索エンジンの利用などが含まれることから、インターネットは娯楽としてではなく実用的に利用しているセグメントであると推察される。

次に、セグメント別の時間による平均値の変化を把握するため、母数 $\mu_t^{(m)}$ の解釈を行う。なお、 $\mu_t^{(m)}$ は対数変換をしているため利用時間の変動が図1と比べて小さくなっている点には注意されたい。ここでは、図1よりCOVID-19の流行前後で特徴的な動きをしていた、テレビ(報道)、テレビ(教育・教養)、インターネット(動画)、インターネット(その他)の四つを図2に示す。テレビ(報道)やテレビ(教育・教養)では、COVID-19の最初の流行がはじまった2020年3月頃までは $\mu_t^{(m)}$ はクラス1とクラス2でほぼ同じ水準で推移していたが、COVID-19が本格流行した2020年4月以降は、クラス1の方がクラス2よりも高い値となっていることがわかる。一方で、テレビ(報道)やテレビ(教育・教養)についてクラス3の $\mu_t^{(m)}$ はCOVID-19流行前後でも大きな違いがないことが見てとれる。また、インターネット(動画)やインターネット(その他)では、COVID-19流行後に特に実用的にインターネットを利用しているクラス3の $\mu_t^{(m)}$ が大きくなっていることがわかる。逆にクラス2のインターネット関連については、COVID-19本格流行後にはむしろ $\mu_t^{(m)}$ が小さくなっていることがわかる。なお、図2から、いわゆる第1波が落ち着いた2020年5月末以降でも、クラス1のテレビ(報道)やテレビ(教育・教養)の利用時間およびクラス3のインターネット(動画)とインターネット(その他)の利用時間は2019年の水準までは戻っていないことが見てとれる。このように、セグメントによって利用するメディアとジャンルが異なること、また観測されない消費者

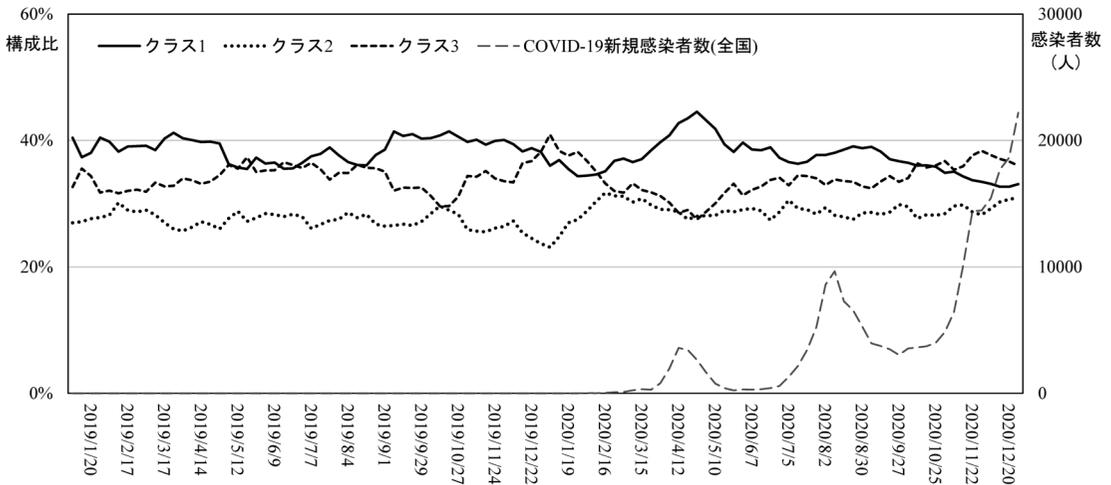
⁵ z_{it} を所与として $\mu_t^{(m)}$ を個人の予測値として、観測されたメディア利用時間との誤差を計算した。

⁶ クラス数1のMSEを1とした比を計算する。MSE比が1未満の場合はクラス数1より良い結果であると解釈する。



※横軸の日付は週の最終日(日曜日)を表す。

図2 メディア利用時間の母数 $\mu_t^{(m)}$ の時間変化 (事後平均)



※横軸の日付は週の最終日(日曜日)を表す。

図3 セグメント構成比の時間変化と COVID-19 全国新規感染者数

セグメント別のメディア利用時間の変化を把握することができる点が、本手法を用いる利点である。

3.4 結果 (2) セグメント構成比の時間変化

図3に、セグメント構成比の時間変化および参考情報として COVID-19 の全国新規感染者数を示す。2019年と2020年のセグメントの構成比の時間による変化を比較すると、異なる動きをしていることがよく

わかる。

2020年のセグメントの構成比を見ると、COVID-19 の新規感染者が最初に増えたいわゆる第1波の時期(2020年3月後半~5月中旬)に、クラス1の構成比が増えていることがわかる。第1波では2020年4月7日~5月31日に1回目の緊急事態宣言が発出されており、多くの消費者は外出自粛を余儀なくさ

れた時期である。クラス1はテレビ・インターネットすべての利用時間が多いセグメントであり、この時期にメディアを多く利用するクラス1にスイッチした消費者が増えていることがわかる。一方で、同時期にはクラス2・クラス3の構成比が下がっている。クラス2はテレビのみに特化したセグメント、クラス3はインターネット（その他）に特化したセグメントである。普段はテレビのみを見る人や、インターネットの実用的な使用（ECサイトやメールなど）をしていると思われる人が第1波の自粛期間に時間を持て余したことで、構成比が減ったと推察される。COVID-19の新規感染者は5月以降一度落ち着き、緊急事態宣言は5月末に解除された。それに連動して、クラス1の構成比が減少していることがわかる。

その後、2020年7月以降にいわゆる第2波が到来したが、その間にセグメントの構成比には大きな動きは見られなかった。しかし、第2波が落ち着いた10月以降、クラス3の割合が上昇していることがわかる。この頃は、首都圏の大学では一部の対面授業を再開したり、Go to トラベルが本格化するなど、多くの経済活動が本格的に再開した時期でもある。その中で、これまでは主に自宅で時間を過ごしていた消費者が経済活動を行うことで、自宅で過ごす時間が減り、メディアを多く利用するクラス1の構成比が減少し、実用的なインターネットのみを利用するクラス3の構成比が上昇したと推察される。2020年11月以降には感染者が再度増加し、いわゆる第3波が到来したが、クラス3の構成比は高いままで、クラス1の構成比が再び増えることはなかった。構成比の時間変化を見ると、2020年の第1波は、新型コロナウイルスという未知のウイルスに対する恐怖もあり、第2波以降に比べるとCOVID-19の新規感染者数はそこまで多くないにもかかわらず、消費者のメディア利用に対する影響は絶大であったことが窺える。しかし、感染者がより増えた第2波以降では、徐々にCOVID-19に関する情報が蓄積されていたこともあり、消費者のメディア利用への影響は第1波ほどではなかったと考えられる。

3.5 結果 (3) 共変量の効果

最後に、状態遷移に影響する共変量 w の効果 $\lambda_{m|m'}$ の推定結果（事後平均・95%ベイズ信用区間）を表4に示す。表の「*」は95%信用区間が0を含まなかったものである。なお、同じクラス間の遷移（たとえばクラス1→クラス1）の係数は0である点に注意されたい。COVID-19の全国新規感染者数やGoogleトレンド、緊急事態宣言ダミーなどが、一部のクラス間の遷移に

影響を与えていることがわかるが、セグメント構成比の時間変化の図3を見てもわかるように、COVID-19の新規感染者が増えることでメディアを多く利用するクラス1へのスイッチが起こるという明確な結果を得ることはできなかった。前述のように、2020年の第1波は、第2波以降に比べるとCOVID-19の感染者数は多くないにもかかわらず、消費者への影響は絶大であったため、COVID-19の感染者数がクラス間の遷移にあまり影響しなかったと推察される。一方でクラス2→クラス1のGoogleトレンドの係数がプラスに効いており、また信用区間が0を含むものの、クラス3→クラス1の係数もプラスの結果となっている。Googleトレンド指数は第1波の時期に最も値が高くなっていることもあり（図1参照）、メディアを多く利用するクラス1へのスイッチにGoogleトレンド指数がプラスに効いていると考えられる。

4. まとめ

本研究では、2019年から2年間のメディアの利用をログで記録しているシングルソースデータを用いて、COVID-19の感染者の拡大とそれに伴う外出自粛による消費者のメディア利用の変化を分析した。COVID-19がまん延する環境下における消費者のメディア利用時間の傾向を潜在的なセグメントで捉え、その動的変化をHMMによって分析した。

分析結果として、テレビ・インターネットいずれのメディア・ジャンルも多く利用しているセグメント、TVのみに利用に特化したセグメント、実用的なインターネットのみを利用するセグメントの三つが確認された。また、各セグメントによって利用するメディアやジャンルが異なること、COVID-19流行前後において、メディア利用時間が増加したセグメントや、変化しない、または減少したセグメントなどを把握することができた。さらに、セグメントの構成比は、第1波（2020年3月後半～5月中旬）の時期に、いずれのメディアも多く利用するセグメントの構成比が増え、同時期の他のセグメントの構成比が減っていることが確認された。また、第2波が落ち着いた2020年10月以降、実用的なインターネットのみを利用するセグメントの割合が上昇していることが確認された。加えて、メディアを多く利用するクラス1へのスイッチにGoogleトレンド指数がプラスに効いていることが明らかになった。

このように、HMMを用いることで、期間別の平均の比較や、集計データの時系列解析では捉えることのできない、観測されないセグメント別のメディア利用

表4 セグメント推移への影響 $\lambda_{m|m'}$ (事後平均・95%信用区間)

	事後平均	95% 信用区間	事後平均	95% 信用区間
	クラス1→クラス2		クラス1→クラス3	
定数項	-4.947	(-5.421, -4.501) *	-3.343	(-3.529, -3.163) *
COVID-19 全国感染者数	-0.081	(-0.203, 0.035)	-0.095	(-0.200, 0.007)
Google トレンド	-0.011	(-0.037, 0.009)	-0.014	(-0.033, 0.004)
緊急事態宣言ダミー	-0.609	(-2.196, 0.618)	0.977	(0.341, 1.628) *
2020年ダミー	1.372	(0.462, 2.160) *	0.271	(-0.36, 0.878)
	クラス2→クラス1		クラス2→クラス3	
定数項	-4.466	(-4.848, -4.04) *	-3.372	(-3.594, -3.173) *
COVID-19 全国感染者数	-0.146	(-0.326, 0.040)	-0.051	(-0.142, 0.047)
Google トレンド	0.019	(0.003, 0.033) *	-0.002	(-0.018, 0.010)
緊急事態宣言ダミー	0.110	(-0.807, 0.853)	-0.456	(-1.308, 0.242)
2020年ダミー	0.368	(-0.882, 1.520)	0.464	(-0.277, 1.168)
	クラス3→クラス1		クラス3→クラス2	
定数項	-3.251	(-3.466, -3.051) *	-3.591	(-3.896, -3.346) *
COVID-19 全国感染者数	-0.141	(-0.243, -0.038) *	-0.093	(-0.191, 0.00)
Google トレンド	0.012	(-0.001, 0.024)	0.002	(-0.013, 0.014)
緊急事態宣言ダミー	0.428	(-0.336, 1.160)	-0.005	(-0.646, 0.602)
2020年ダミー	-0.029	(-0.709, 0.570)	0.667	(0.015, 1.334) *

※「*」は95%信用区間が0を含まなかった結果を表す。

時間の変化や、セグメントの時間による遷移の要因などを捉えることができた。このような消費者行動の背後にあるメカニズムを解明できる点が、パネルデータとHMMを用いる利点であり、本研究はマネジメントサイエンスの観点からも非常に重要である。

本研究は、COVID-19がまん延する最中の消費者行動に焦点を当てており、異常事態が起きた際の消費者のメディア利用の変化を捉えた研究として、学術的、社会的な意義がある。まず学術的な意義として、本研究ではセグメント別のメディア利用時間の変化を捉えており、コロナ禍のさまざまな行動制限や自粛が要請される中で、メディア利用に関する行動の実態を示した知見自体に価値を見出すことができる。さらに、社会生活の正常化の後に、行動変容に関する経済的、社会的な影響などの検証を行う際の情報として参考になる可能性もある。加えて、社会的な意義として、将来の自然災害および類似のパンデミックが起こった場合、消費者の行動を予想する一助となりえる。本研究ではCOVID-19関連の変数を用いて潜在セグメントの遷移を捉えており、異常事態が起きた際のインパクトなどを変数化することによって、消費者セグメントがどのように遷移していくのかを予想する参考になる。また、類似の異常事態が生じた場合に、たとえば消費者が集中することが予想されるメディアに積極的に行政が広報する、また企業のプロモーションを集中させるといっ

た施策を考える際の参考にもなりえる。

本研究の限界として、スマートフォンやタブレット端末からのアプリ利用を考慮することができなかった点があげられる。近年、消費者の多くはスマートフォンやタブレット端末からアプリを利用してSNS利用や動画視聴を行っているが、本研究で用いたデータはアプリの利用時間を連続で取得しておらず、同じ枠組みで分析することができなかった。加えて、本研究では長期間のメディア利用をシングルソースで取得したデータが必要であり、アプリ利用を加えると分析に十分なサンプルサイズを確保することができなかったことも、アプリを分析に利用できなかった理由である。また、本研究では2019~2020年の2年間のデータを利用したが、2021年以降のデータを含めた分析も重要な課題である。2021年以降もCOVID-19は猛威を振るい、2021年には2回目以降の緊急事態宣言やまん延防止等重点措置も発出・適用されている。この時期になると、特に飲食店の利用が大きく制限されたこともあり、消費者のメディア利用行動もさらに変化した可能性がある。この時期のメディア利用行動を記録したデータが入手できれば、追加の分析を実施する予定である。

また、今回はセグメントの時間変化に影響を与える変数 w_t は、COVID-19およびその影響に関連した変数のみを利用し、消費者に関する変数を利用することができなかった。たとえば、消費者の在宅時間やテレ

ワークなどの有無の情報を週別のデータとして利用できれば、これらとメディア利用時間やセグメント遷移の関係などを分析することも可能になる。さらに、本研究では消費者のデモグラフィック属性 d_i は初期時点のセグメントの所属を説明する情報として用いた。対象期間の2年で年齢は変化し、それ以外の属性（未婚など）も変化している可能性があるが、本研究ではデモグラフィック属性の時間による変化は考慮していない。なぜなら、本研究のようなパネルデータの分析では一般的に、年齢は開始時点の情報を利用して固定変数として扱うためである（たとえば、文献 [21]）。加えて、利用したデータでは初期時点のデモグラフィック属性のみ記録しており、たとえば未婚の変化などは今回のデータでは取得できていない。そのため、ライフステージの変化によるセグメント所属の変化を捉えることができていない点は本研究の限界である。COVID-19のまん延、もしくはそのまん延防止にむけた外出自粛などといった行動に起因するメディアの利用時間の変化とライフステージの変化の双方を捉えた研究も今後の課題としてあげられる。

謝辞 論文の改稿において2名の匿名の査読者から有益なコメントをいただきました。また、本研究の実施に当たり、株式会社ビデオリサーチから大変貴重なデータを提供いただきました。この場を借りて御礼申し上げます。また、本研究は科学研究費(20K13624/20H01545)による助成を受けています。

参考文献

[1] NHK オンライン, 「新型コロナウイルス特設サイト」, <https://www3.nhk.or.jp/news/special/coronavirus/> (2022年4月15日閲覧)

[2] 観光庁, 「Go To トラベル事業関連情報」, <https://www.mlit.go.jp/kankocho/page01-000637.html> (2022年4月15日閲覧)

[3] J. Sheth, “Impact of Covid-19 on consumer behavior: Will the old habits return or die?” *Journal of Business Research*, **117**, pp. 280–283, 2020.

[4] 総務省情報通信政策研究所, 「令和元年度 情報通信メディアの利用時間と情報行動に関する調査」, https://www.soumu.go.jp/main_content/000708016.pdf (2022年1月27日閲覧)

[5] 総務省情報通信政策研究所, 「令和2年度情報通信メディアの利用時間と情報行動に関する調査報告書」, https://www.soumu.go.jp/main_content/000765258.pdf (2022年1月27日閲覧)

[6] 博報堂 DY メディアパートナーズ, 「「メディア定点調査2021」時系列分析」, <https://mekanken.com/news/1623/> (2022年2月10日閲覧)

[7] M. Wedel and W. A. Kamakura, *Market Segmentation: Conceptual and Methodological Foundations*, Kluwer Academic Publishers, 2000.

[8] W. A. Kamakura and G. J. Russell, “A probabilistic choice model for market segmentation and elasticity structure,” *Journal of Marketing Research*, **26**, pp. 379–390, 1989.

[9] S. Gupta and P. K. Chintagunta, “On using demographic variables to determine segment membership in logit mixture models.” *Journal of Marketing Research*, **31**, pp. 128–136, 1994.

[10] 猪狩良介, 星野崇宏, “Online-Offline チャネルにおける消費者の購買間隔と購買金額の同時モデリング,” *オペレーションズ・リサーチ: 経営の科学*, **61**, pp. 589–599, 2016.

[11] A. L. Montgomery, Li. Shibo, K. Srinivasan and J. C. Liechty, “Modeling online browsing and path analysis using clickstream data,” *Marketing Science*, **23**, pp. 579–595, 2004.

[12] O. Netzer, J. M. Lattin and V. Srinivasan, “A hidden Markov model of customer relationship dynamics,” *Marketing Science*, **27**, pp. 185–204, 2008.

[13] S. Moon, W. A. Kamakura and J. Ledolter, “Estimating promotion response when competitive promotions are unobservable,” *Journal of Marketing Research*, **44**, pp. 503–515, 2007.

[14] O. Netzer, P. Ebbes and T. H. A. Bijmolt, “Hidden Markov models in marketing,” *Advanced Methods for Modeling Markets*, P. S. H. Leeftang, J. E. Wieringa, T. H. A. Bijmolt and K. H. Pauwels (eds.), Springer, pp. 405–449, 2017.

[15] S. L. Scott, “Bayesian methods for hidden Markov models: Recursive computing in the 21st century,” *Journal of the American Statistical Association*, **97**, pp. 337–351, 2002.

[16] D. L. Miglioretti, “Latent transition regression for mixed outcomes,” *Biometrics*, **59**, pp. 710–720, 2003.

[17] 坂上潤, “VR CUBIC データの活用事例とコンペティションへの提供,” *オペレーションズ・リサーチ: 経営の科学*, **65**, pp. 71–75, 2020.

[18] Google トレンド, <https://trends.google.co.jp/trends/> (2021年10月11日閲覧)

[19] NHK オンライン, 「日本国内の感染者数」, <https://www3.nhk.or.jp/news/special/coronavirus/data-all/> (2022年2月18日閲覧)

[20] J. Geweke, “Evaluating the accuracy of sampling based approaches to the calculation of posterior moments,” *Bayesian Statistics 4*, J. M. Bernardo, J. O. Berger, A. P. Dawid and A. F. M. Smith (eds.), Oxford University Press, pp. 169–193, 1992.

[21] 中村剛, 「Cox 比例ハザードモデル」, 朝倉書店, 2001.