

# スマートフォン依存患者の利用傾向の変化点検知と変化要因推定 Detecting Change Points and Estimating Factors of Change in Smartphone Addiction Patients' Usage Trends

杉山 孔亮<sup>\*1</sup>  
Kosuke Sugiyama

目黒 巧巳<sup>\*2</sup>  
Takumi Meguro

多屋 優人<sup>\*2</sup>  
Masato Taya

本庄 勝<sup>\*2</sup>  
Masaru Honjo

小林 七彩<sup>\*3</sup>  
Nanase Kobayashi

治徳 大介<sup>\*3</sup>  
Daisuke Jitoku

内田 真人<sup>\*1</sup>  
Masato Uchida

## 概要

スマートフォン（以下、スマホ）依存患者の診察において、医師が患者のスマホ利用状況を把握することは極めて重要である。しかし、問診から得られる客観的な情報には限界がある。この問題を解決するために、患者のスマホログデータを解析し、各時刻でのスマホ利用状態を推定する手法が提案されてきた。この手法により、患者のスマホ利用傾向を把握することが可能となったが、医師が推定結果を解釈する必要があり、これが医師の負担となっている。本論文では、スマホ利用状態の推定結果から患者のスマホ利用傾向の変化を検知し、具体的な変化内容を推定する新たな手法を提案する。我々のアプローチでは、推定されたスマホ利用状態を1週間ごとに集計し、多変量時系列データとしてオンライン変化点検知（OCPD）を適用することで、スマホ利用傾向の変化を捉える。さらに、単変量ごとにOCPDを適用した結果に基づいて多変量によるOCPD結果を近似する回帰分析を行い、変化要因を推定する手法を提案する。この手法の有効性を検証するために、実際の患者データを用いたケーススタディを実施した。その結果、我々の手法がスマホ利用傾向の変化点と具体的な変化内容を高精度で推定できることを確認した。本研究は、医師の負担を軽減し、スマートフォン依存患者の診察における新たな支援ツールとしての可能性を示している。

## 1 序論

スマートフォン（スマホ）の過度な使用により睡眠不足や精神的不調などの深刻な悪影響が生じる状態は、正式な医学的診断名ではないが、一般にはスマホ依存と呼ばれる[1, 2, 3]。スマホ依存患者の治療には、医師が各患者のスマホ利用傾向を正確に把握することが不可欠であるが、問診のみでは十分な情報を得ることは難しい。この課題に対して、古澤ら[4]は、患者のスマホのログデータから5分ごとのスマホ利用状態を推定する手法を提案した。これにより、患者のスマホ利用傾向を詳細に把握することが可能となった。この手法では、「無使用」、「短時間の使用」、「激しい使用」など7つのスマホ利用状態を定義し、スマホのログデータを観測変数、7つのスマホ利用状態を潜在変数とする隠れマルコフモデル（HMM）を最適化することで、各時刻のスマホ利用状態を推定する。

\*1 早稲田大学

Waseda University, Tokyo, Japan.

\*2 KDDI 総合研究所

KDDI Research, Inc., Tokyo, Japan.

\*3 東京医科歯科大学

Tokyo Medical and Dental University Hospital, Tokyo, Japan.

しかし、この手法の推定結果を診察に活用する際には、医師自らが推定結果を解釈しなければならないという課題が残る。例えば、スマホ利用傾向の変化を調べる場合、医師は数か月間の推定結果を目視で比較しなければならない。これは非常に手間がかかる。また、推定結果から診察に必要な情報を読み取るための技術を医師が習得する必要があり、負担が大きい。このような背景から、推定結果から自動的に診察に活用できる情報を抽出することが求められている。

そこで本研究では、HMMによるスマホ利用状態推定結果から患者のスマホ利用傾向の変化を検知する手法を提案する。まず、各患者について1週間ごとにHMMを用いて5分刻みのスマホ利用状態を推定し、その推定結果を1週間単位で集計する。これにより、1週間の1時点とする多変量時系列データを作成する。作成した多変量時系列データに対して、オンライン変化点検知（OCPD）手法の一つであるNEWMA[5]を適用することで、スマホ利用傾向の変化を検知する。この自動的な検知により、医師は推定結果を目視で調査する必要がなくなり、患者のスマホ利用傾向の変化の有無を把握することが可能となる。

しかし、具体的な変化内容まで把握するためには、該当期間のスマホ利用状態推定結果を確認する必要がある。そこで本研究では、スマホ利用傾向の変化点検知に加え、検知された変化点がどの特徴量を要因として生じたのかを推定する手法を提案する。変化要因を推定するために、多変量のOCPDと並行して各特徴量についての単変量のOCPDを実行する。提案手法では、多変量のOCPDで得られた変化点スコア、すなわち変化点であるかどうかを定量化した値の系列を、単変量のOCPDで得られた変化点スコアの系列の重み付き和で近似する回帰分析を行う。この回帰分析により、変化点においてどの特徴量が大きく影響したかを推定することができる。

本論文では、実際の患者データを用いたケーススタディを通じて、提案手法の有効性を検証した。まず、我々が作成した特徴量を用いてNEWMAを実行し、検知された変化点が実際の問診記録と対応していることを確認した。次に、提案する変化要因推定手法が変化点における変化の大きい特徴量を正確に特定できていることを確認した。これらの結果から、我々の提案手法により、1週間単位で患者のスマホ利用傾向の変化を自動的に検知し、さらにその変化要因を医師にフィードバックすることが可能であると期待される。

## 2 関連研究

### 2.1 スマホ利用状態推定

古澤ら[4]は、患者のスマホのログデータから、5分ごとの患者のスマホ利用状態を推定する手法を提案した。利用するログデータは、スクリーン状態とスクリーンの

タッチ回数, スマホの加速度である. 古澤らの手法では, 5分ごとのこれらのログデータを観測変数とし, 患者のスマホ利用状態を表す離散変数を潜在変数とした隠れマルコフモデル (HMM) を最適化することで, 5分ごとの患者のスマホ利用状態を推定する. スマホ利用状態の数は, AIC と BIC に基づいて, 7つと定められた. この最適化は, 次の 2 段階で行われる. 1 段階目では, 事前学習として, 複数の患者のデータを用いて HMM を最適化することで, 複数の患者で共通となるような 7 つのスマホ利用状態を定義する. 2 段階目では, 1 段階目で得られた HMM のパラメータを初期値とし, 各患者のデータのみを用いて患者ごとに HMM を再度最適化する. この方法により, 各状態の定義を保ちつつ, 状態ごとの観測変数の分布を各患者に合わせて, 各患者の特徴も考慮することができる.

古澤らは, HMM における各スマホ利用状態ごとの観測変数の分布から, それぞれの状態の意味付けを行った [4]. 7 つのスマホ利用状態はそれぞれ「無使用」, 「付けっぱなし」, 「移動中」, 「チェック行動/通知」, 「短時間の使用」, 「穏やかな使用」, 「激しい使用」として意味づけられた. この手法により, 各時刻の推定結果に対する直観的なスマホ利用状態の把握が可能となった. しかし, この推定結果から患者のスマホ利用傾向の変化を読み取るためには, 数か月間の推定結果の系列を観察する必要がある. 医師の負担が大きい. そこで, この推定結果から, 自動でスマホ利用傾向の変化を捉えることを考える.

## 2.2 オンライン変化点検知

オンライン変化点検知 (OCPD) とは, リアルタイムに発生する時系列データを逐次的に処理し, データの傾向が急激に変化したタイミングを検知する手法である [6]. 本研究では, OCPD を一定期間ごとに得られる患者のスマホ利用状態推定結果に適用することができる. しかし, 実際の診察に活用する場合, 医師は多くの患者に対応しなければならず, また現段階では十分な量の患者データが得られていないという課題がある. そのため, 計算量が少なく, 膨大なデータを必要としない OCPD 手法が求められる.

この要求を満たす手法の 1 つとして, NEWMA [5] に着目する. NEWMA は, 訓練データを必要とせず, 1 人の患者のデータがあれば実行できる. また, 最新のデータに対して変化点検知を行う際に, 過去のログデータや変化点スコアを保持する必要が無いため, 実際の活用場面でも計算資源の負担が少ない.

NEWMA のアルゴリズムを, アルゴリズム 1 に示す.  $\Psi$  にはカーネル関数が設定され,  $d$  次元の多変量時系列データを  $m(m \ll d)$  次元に射影することで次元削減が行われる.  $\lambda < \Lambda$  であるので,  $z_t'$  は  $t$  時点目に近い部分のみ大きい重みをもつため,  $t$  時点目に近い部分の傾向を捉えている. 一方で,  $z_t$  は,  $t$  時点目から離れた部分にも重みをもたせるため,  $t$  時点目までの比較的長い期間の時系列データの傾向を捉えている. NEWMA は, これらの差分を調べることで, 変化点検知を行う. この差分の大きさ  $\|z_t - z_t'\|$  を変化点スコアと呼び, 変化点スコアが閾値  $\tau$  を超えた場合に変化点が検知される. NEWMA の  $\lambda, \Lambda$  は, 新たなハイパーパラメータ  $B$  を導入し,  $B$  の値を元にヒューリスティックに決定される.  $B$  は, スライディングウィンドウを用いた OCPD 手法 [7] でのウィンドウサイズを意味している.

また, NEWMA では閾値  $\tau$  は各時刻ごとに動的に推定される [5]. 具体的なアルゴリズムを, アルゴリズム 2 に示す. まず, 各時刻  $t$  において  $\|z_t' - z_t\|$  の分布に正

### アルゴリズム 1 NEWMA [5]

**Require:** Time series data  $x_t, t = 1, 2, \dots$ , function  $\Psi$ , forgetting factors:  $0 < \lambda < \Lambda < 1$ , threshold  $\tau > 0$ , initial value  $z_0 = z_0'$

```

for  $t = 1, 2, \dots$  do
   $z_t = (1 - \Lambda)z_{t-1} + \Lambda\Psi(x_t)$ 
   $z_t' = (1 - \lambda)z_{t-1}' + \lambda\Psi(x_t)$ 
  if  $\|z_t - z_t'\| \geq \tau$  then
    Detect  $t$  as a change-point
  end if
end for

```

### アルゴリズム 2 閾値の動的推定 [5]

**Require:** data  $\|z_t' - z_t\|, t \in \{1, 2, \dots\}$ , estimation factor  $0 < \kappa < 1$ , coefficient  $a$

Initialize  $\mu_0 = 0, \mu_0^{(2)} = 0$

```

for  $t = 1, 2, \dots$  do
   $\mu_t = (1 - \kappa)\mu_{t-1} + \kappa\|z_t' - z_t\|$ 
   $\mu_t^{(2)} = (1 - \kappa)\mu_{t-1}^{(2)} + \kappa\|z_t' - z_t\|^2$ 
   $\sigma_t = \sqrt{\mu_t^{(2)} - \mu_t^2}$ 
  Determine threshold  $\tau_t$  as  $\mu_t + a\sigma_t$ 
end for

```

規分布  $\mathcal{N}(\mu_t, \sigma_t^2)$  を仮定し,  $\mu_t, \sigma_t^2$  を推定する. そして,  $a \in \mathbb{R}^+$  を導入し,  $\mu_t + a\sigma_t$  を  $t$  時点目の閾値とする.

古澤らの手法 [4] は 5 分単位のスマホ利用状態を推定するため, この結果に NEWMA [5] を用いてスマホ利用傾向を捉えるには, 推定結果を加工し, スマホ利用傾向を捉えた時系列特徴量を作成する必要がある. 加えて, 診察補助に活用するためには, 変化点の検知だけでなく, 多変量の特徴量から変化内容を自動で見つけ出す必要がある. 3 節では, これらの課題に対応する方法を提案する.

## 3 提案手法

本節では, HMM によるスマホ利用状態推定結果を用いて, 患者のスマホ利用傾向の変化を捉え, かつ変化要因を推定する手法を提案する. 本提案手法は次の三段階で構成される. 1 段階目として, スマホのログデータに対し HMM によるスマホ利用状態推定 [4] を適用し, その推定結果を活用してスマホ利用傾向を捉えた多変量時系列データを作成する. 2 段階目では, 作成した多変量時系列データに対し, NEWMA [5] を適用し, スマホ利用傾向の変化を捉える. 3 段階目では, 検知したスマホ利用傾向の変化の要因となった特徴量を推定する. 3.1 節で 1 段階目を, 3.2 節で 3 段階目を説明する.

### 3.1 変化点検知のための多変量時系列データ

本節では, スマホのログデータに HMM によるスマホ利用状態推定 [4] を適用し, その推定結果を活用してスマホ利用傾向を捉えた多変量時系列データを作成する手順を説明する. 本節で作成する多変量時系列データは, スマホ利用状態分布と使用アプリカテゴリ分布と呼ばれる 2 種類の特徴量からなる. まず, 2 種類の特徴量に共

通する処理として、古澤らの手法 [4] を用いて、各患者の 1 週間ごとのログデータに対してそれぞれ HMM を最適化し、各時刻のスマホ利用状態を推定する。そしてこの 1 週間ごとに、5 分刻みで推定されたスマホ利用状態についての集計を行うことで、上記の 2 種類の特徴量を作成する。

次に、スマホ利用状態分布に関する特徴量を作成する。1 週間ごとに、各スマホ利用状態として推定された時間を集計し、総和が 1 になるように正規化することで、スマホ利用状態分布を表す特徴量を作成する。これらの特徴量には、ある 1 週間において「激しい使用」が全体の 30% を占めている、といった情報が含まれる。

続いて、使用アプリケーション分布に関する特徴量を作成する。この特徴量の作成では、新たに各時刻での使用アプリを記録したログデータを用いる。1 週間ごとに、各スマホ利用状態と推定された期間内におけるアプリケーション単位の使用時間を集計することで、スマホ利用状態ごとの使用アプリケーション分布を表す特徴量を作成する。これらの特徴量には、ある 1 週間において「激しい使用」状態として推定された時間帯の内、80% はゲームが占め、残り 20% は動画視聴が占めている、などの情報が含まれる。

## 3.2 変化要因推定

3.1 節で作成した特徴量の系列に対して、NEWMA [5] を適用することにより、スマホ利用傾向の変化点を検知できるが、診察においては具体的な変化内容も知る必要がある。しかし、多変量時系列データを扱う NEWMA のアルゴリズムは出力の解釈が難しく、どの特徴量が変化点に寄与したかは明らかではない。最も簡単な対応方法は、単変量ごとに OCPD を実行し、いずれかの特徴量で変化点を検知した場合にスマホ利用傾向が変化したと見なすことである。しかし、後述する図 3 で示す通り、この方法では非常に多くの時点を変化点と判定してしまうため、適切ではない。

そこで本節では、多変量データを扱う OCPD により検知された変化点が、どの特徴量を要因としているのかを推定する手法を提案する。具体的には、多変量の OCPD で得られた変化点スコアの系列を、単変量ごとの OCPD で得られた変化点スコアの系列で近似する回帰分析を行うことで、変化点の発生に大きく影響した特徴量を推定する。この手法は、多変量の OCPD で検知した変化点直前において、多変量の OCPD と要因となる特徴量での OCPD の変化点スコアの増加具合が類似するという仮説に基づいている。

本手法を実行するために、多変量の OCPD の実行と並行して、多変量の OCPD に用いた各特徴量について単変量の OCPD を実行する。全ての特徴量の個数を  $d$  とする。  $d$  個の特徴量を用いた多変量の OCPD で得られる変化点スコアの系列を  $f_M = [f_{M,1}, f_{M,2}, \dots]$  と表す。  $j \in \{1, \dots, d\}$  番目の特徴量を用いた単変量の OCPD で得られる変化点スコアの系列を  $f_j = [f_{j,1}, f_{j,2}, \dots]$  と表す。  $t \in \mathbb{N}_+$  時点目で多変量の OCPD により変化点を検知した場合を考える。このとき、以下の重み付きの Elastic Net [8] を実行する：

$$\hat{\beta}_t = \arg \min_{\beta \in \mathbb{R}^d} \sum_{s=1}^t w^{t-s} \left( f_{M,s} - \sum_{j=1}^d \beta_j f_{j,s} \right)^2 + \theta \left( \alpha \|\beta\|_1 + \frac{1}{2} (1 - \alpha) \|\beta\|_2^2 \right). \quad (1)$$

## アルゴリズム 3 提案手法

**Require:** Time series data  $\mathbf{x}_t = [x_{t,1}, \dots, x_{t,d}]$ ,  $t = 1, 2, \dots$ , function  $\Psi$ , forgetting factors:  $0 < \lambda < \Lambda < 1$ , initial value  $\mathbf{z}_0 = \mathbf{z}'_0$ ,  $\{\mathbf{z}_{j,0} = \mathbf{z}'_{j,0}\}_{j=1, \dots, d}$ , estimation factor  $0 < \kappa < 1$ , coefficient  $a$ , weight parameter  $w$ , causal threshold  $\eta$

```

for  $t = 1, 2, \dots$  do
   $\mathbf{z}_{M,t} = (1 - \Lambda)\mathbf{z}_{M,t-1} + \Lambda\Psi(\mathbf{x}_t)$ 
   $\mathbf{z}'_{M,t} = (1 - \lambda)\mathbf{z}'_{M,t-1} + \lambda\Psi(\mathbf{x}_t)$ 
   $f_{M,t} = \|\mathbf{z}_{M,t} - \mathbf{z}'_{M,t}\|$ 
  for  $j = 1, 2, \dots, d$  do
     $\mathbf{z}_{j,t} = (1 - \Lambda)\mathbf{z}_{j,t-1} + \Lambda\Psi(x_{j,t})$ 
     $\mathbf{z}'_{j,t} = (1 - \lambda)\mathbf{z}'_{j,t-1} + \lambda\Psi(x_{j,t})$ 
     $f_{j,t} = \|\mathbf{z}_{j,t} - \mathbf{z}'_{j,t}\|$ 
  end for
  Decide  $\tau_t$  using Algorithm 2 with  $\kappa, a$ 
  if  $\|\mathbf{z}_{M,t} - \mathbf{z}'_{M,t}\| \geq \tau_t$  then
    Detect  $t$  as a change-point
    Decide  $\theta, \alpha$  by executing Grid Search
    Obtain  $\hat{\beta}_t$  by executing Eq.(1)
    for  $j = 1, 2, \dots, d$  do
      if  $\hat{\beta}_{t,j} \geq \eta$  then
        Determine  $j$ -th feature as a causal factor at time  $t$ 
      end if
    end for
  end if
end for

```

Elastic Net のハイパーパラメータである  $\theta \in [0, 1]$  と  $\alpha \in [0, \infty)$  は、複数の値の候補で式 (1) を実行し、得られる回帰モデルの決定係数  $R^2$  が最も大きくなるものを選ぶ。変化要因を判定するためのハイパーパラメータ  $\eta \in \mathbb{R}_+$  を導入し、得られた偏回帰係数  $\hat{\beta}_{t,j}$  が  $\hat{\beta}_{t,j} \geq \eta$  を満たす  $j$  番目の特徴量を  $t$  時点目の変化点の要因とみなす。本手法では、変化要因を限定することを目的として、L1 ノルムによる正則化を含む Elastic Net を採用した。

$w \in (0, 1]$  は、 $t$  時点目から過去の時点に対して指数的に減少する重みを付加するための重みパラメータである。 $w$  による重みづけは、変化点スコアの類似度を式 (1) を通して調べる際に、変化点に近い範囲を重視させることを目的としている。

我々の提案手法をアルゴリズム 3 にまとめる。アルゴリズム 3 で用いるデータ  $\{\mathbf{x}_t\}_{t=1,2,\dots}$  は、3.1 節で作成した 1 週間を 1 時点とする多変量時系列データとする。我々の手法は 1 週間単位で変化点を検知し、その要因を推定するため、スマホ依存患者の問診において最新の情報を提供することができる。加えて、我々の提案手法を実行する際には、過去のログデータを保持する必要はなく、過去の変化点スコアとその閾値のみを保持すればよいため、実運用時の計算資源の負担は少ないと考えられる。

## 4 ケーススタディ

本節では、我々の提案手法をスマホ依存患者のデータに適用することで、変化点検知と変化要因推定の有効性

を評価する。4.1 節では、データセットの概要を述べる。4.2 節では、我々の作成した多変量時系列データを用いた変化点検知の有効性を評価する。4.3 節では、提案する変化要因推定手法の有効性を評価する。

#### 4.1 データセット

本論文では、東京医科歯科大学のネット依存外来を受診した 43 名の患者から同意を得て収集したスマホのログデータを使用する。このログデータは、KDDI 総合研究所が開発したアプリである「U-Logger」を用いて収集された。本論文では、スマホ利用状態推定のための HMM の事前学習として、4 名の患者のデータを用いた。そして、特に長期間データを取得できている 2 名の患者 A, B に対し、我々の提案手法を適用した。

#### 4.2 変化点検知の検証

本節では、3.1 節で作成した多変量時系列データに NEWMA [5] を適用することで、スマホ利用傾向の変化が検知できているかを調べる。しかし、いつスマホ利用傾向の変化が生じたかは未知であり、正確に評価できない。そこで、生活の大きな変化などが記録された問診記録と照合することで、変化点検知の有効性を評価する。本実験で使用する NEWMA のハイパーパラメータは  $B = 5$  とする。NEWMA で用いるカーネルには、ガウシアンカーネルを含む平行移動不変なカーネルを設定し、Random Fourier Features によりカーネル関数を近似計算する [5, 9]。閾値の動的推定のためのパラメータは、 $\kappa = 0.05, a = \lambda$  とした。ただし、 $\lambda$  は  $B$  の値に応じて決定される [5]。

3.1 節で作成した患者 A, B のデータに OCPD 手法である NEWMA [5] を適用した結果を、それぞれ図 1, 2 に示す。青色の線がスマホ利用状態分布のみを使用した場合 (State)、緑色の線が使用アプリカテゴリ分布のみを使用した場合 (Category)、赤色の線がこれらを両方用いた場合 (All) である。実線が変化点スコアを表し、点線が変化点の閾値を表す。縦線が引かれた箇所は検知された変化点を表す。薄い色でハイライトされた期間は、問診記録から生活の大きな変化があった期間である。

図 1, 2 より、患者 A, B のそれぞれのハイライトされた期間において、State, Category, All のいずれかで変化点が検知されたことがわかる。加えて、それ以外の期間では過度に変化点が検知されている傾向がないことがわかる。患者 B の Week16~19 では、問診記録には特徴的な記載は無い一方で、3 種類の OCPD 全てで変化点を検知している。紙面の都合上記載は省略するが、この期間では状態 3, 6, 7 などのログデータで大きく傾向が変化していることが確認されている。よって、問診からは知ることができなかったスマホ利用傾向の変化を検知することができたと考えられる。したがって、我々が作成した多変量時系列データを用いた OCPD は、問診以上に、2 名の患者のスマホ利用傾向の変化を適切に捉えられたと考えられる。

#### 4.3 変化要因推定の検証

本節では、3.2 節で述べた提案手法が、検知された変化点の要因をどれだけ良く推定できているのかを、患者 A のデータを用いて評価する。本実験で使用する NEWMA のハイパーパラメータは 4.2 節と同じ値に設定する。変化要因推定手法のハイパーパラメータ  $\theta, \alpha$  の探索範囲は、それぞれ  $[0.0001, 10], [0.2, 1.0]$  とした。また、その他のハイパーパラメータは  $w = 0.5, \eta = 0.05$  に設定した。

患者 A について、スマホ利用状態分布を用いた多変量の OCPD と、スマホ利用状態分布に含まれる各特徴量での単変量の OCPD の結果を図 3 に示す。縦線が引かれた箇所が、各 OCPD で変化点が検知された箇所である。また、多変量の OCPD で変化点を検知した期間を、過去から順に青色、赤色、緑色でハイライトした。ただし、計測の初期段階では変化点を正しく検知できないと考えられるため、評価から除外している。

図 3 で示す多変量の OCPD で検知された変化点において、式 (1) を用いて各特徴量の偏回帰係数を推定した結果を表 1 に示す。表 1 の  $R^2$  は、表示している偏回帰係数を持つ線形回帰モデルの決定係数を表す。本論文では、 $\eta = 0.05$  とし、偏回帰係数が 0.05 以上であるものを変化要因とみなした。表 1 では、変化要因と判定されたときの偏回帰係数を太字で記載した。

まず、図 3 の青色の期間 (Week 15, 16) に着目する。表 1 より、青色の期間で偏回帰係数が大きい特徴量は状態 7, 6 である。図 3 より、単変量の OCPD で青色の期間に変化点を検知したのは状態 7 のみであり、状態 6 は該当期間の直前に変化点が検知されている。加えて、他の状態のログデータから大きな変化は見られない。よって、この期間では変化要因を正しく推定できていると考えられる。

次に、図 3 の赤色の期間 (Week 32) に着目する。表 1 より、赤色の期間で偏回帰係数が大きい特徴量は順に状態 2, 3, 6, 5 である。図 3 より、単変量の OCPD で赤色の期間に変化点を検知したのは状態 2 と状態 5 である。状態 6 は、変化点スコアがわずかに閾値に達していないが、閾値や変化点スコアの変動を考慮すると、変化点である可能性は十分あると考えられる。状態 3 では、Week32 前後でログデータが減少傾向から増加傾向に変化しており、変化点検知に寄与した可能性はあると考えられる。よって、変化点とは言い切れない状態を含みつつも、この期間では変化要因を含めた特徴量集合を提示できていると考えられる。

最後に、図 3 の緑色の期間 (Week 36~43) に着目する。表 1 より、緑色の期間で偏回帰係数が大きい特徴量は状態 2, 3, 6, 7 である。図 3 より、単変量の OCPD で緑色の期間に変化点を多く検知したのは、状態 2, 3, 6, 7 であり、ログデータからも明確な変化が確認できる。そのため、これらの状態は緑色の期間の変化要因と考えられ、提案手法は良く推定できていると考えられる。

以上より、提案する変化要因推定手法は、患者 A について、変化要因であると考えられる特徴量を自動的に抽出することができていると考えられる。患者 B については紙面の都合上省略するが、患者 A と同様に変化要因を良く推定することができた。特に、多変量の OCPD で変化点を検知した期間において、ある特徴量の OCPD では変化点が検知されていなくても、直前の時系列傾向を考慮して、その特徴量が変化要因であると推定できていると考えられる。これは、多変量の OCPD と同時点で、単変量の OCPD で変化点が検知された特徴量を列挙する単純な手法では達成できない。そのため、直前の時系列傾向も考慮した変化要因推定が我々の提案手法の強みであると考えられる。

## 5 結論

スマホ依存患者の診察補助のために、スマホのログデータから 5 分ごとのスマホ利用状態を推定する手法が提案されていたが、結果を解釈するための医師の負担が大きいという課題があった。本研究では、スマホ利用状態の推定結果から、患者スマホ利用傾向の変化を捉え、




図1 患者Aに対するOPCD結果




図2 患者Bに対するOPCD結果

変化要因を推定する手法を提案した。そして、我々の提案手法をスマホ依存患者のデータに適用することで、提案手法の有効性を評価した。提案手法は1週間単位でスマホ利用傾向の変化を捉えられるため、医師へのスマホ利用傾向についての簡潔な情報の共有や、患者への同様の情報のフィードバックなどに活用できると期待される。

#### 参考文献

- [1] Soheli Ahmed, Nikita Pokhrel, Swastik Roy, and Asir John Samuel. Impact of nomophobia: A non-drug addiction among students of physiotherapy course using an online cross-sectional survey. *Indian journal of psychiatry*, 61(1):77–80, 2019.
- [2] Qing-Qi Liu, Zong-Kui Zhou, Xiu-Juan Yang, Fan-Chang Kong, Geng-Feng Niu, and Cui-Ying Fan. Mobile phone addiction and sleep quality among chinese adolescents: A moderated mediation model. *Computers in Human Behavior*, 72:108–114, 2017.
- [3] Jon D. Elhai, Jason C. Levine, Robert D. Dvorak, and Brian J. Hall. Non-social features of smartphone use are most related to depression, anxiety and problematic smartphone use. *Computers in Human Behavior*, 69:75–82, 2017.
- [4] 古澤, 浜村, 米山, 本庄, 小林, 治徳, and 内田. 隠れ

マルコフモデルによるスマートフォン依存患者の利用状態推定. *情報処理学会第85回全国大会講演論文集*, 2023(1):315–316, 2023.

- [5] Nicolas Keriven, Damien Garreau, and Iacopo Poli. Newma: A new method for scalable model-free online change-point detection. *IEEE Transactions on Signal Processing*, 68:3515–3528, 2020.
- [6] Samaneh Aminikhanghahi and Diane J Cook. A survey of methods for time series change point detection. *Knowledge and information systems*, 51(2):339–367, 2017.
- [7] Daniel Kifer, Shai Ben-David, and Johannes Gehrke. Detecting change in data streams. In *VLDB*, volume 4, pages 180–191. Toronto, Canada, 2004.
- [8] Trevor Hastie, Robert Tibshirani, Jerome H Friedman, and Jerome H Friedman. *The elements of statistical learning: data mining, inference, and prediction*, volume 2. Springer, 2009.
- [9] Ali Rahimi and Benjamin Recht. Random features for large-scale kernel machines. In J. Platt, D. Koller, Y. Singer, and S. Roweis, editors, *Advances in Neural Information Processing Systems*, volume 20. Curran Associates, Inc., 2007.

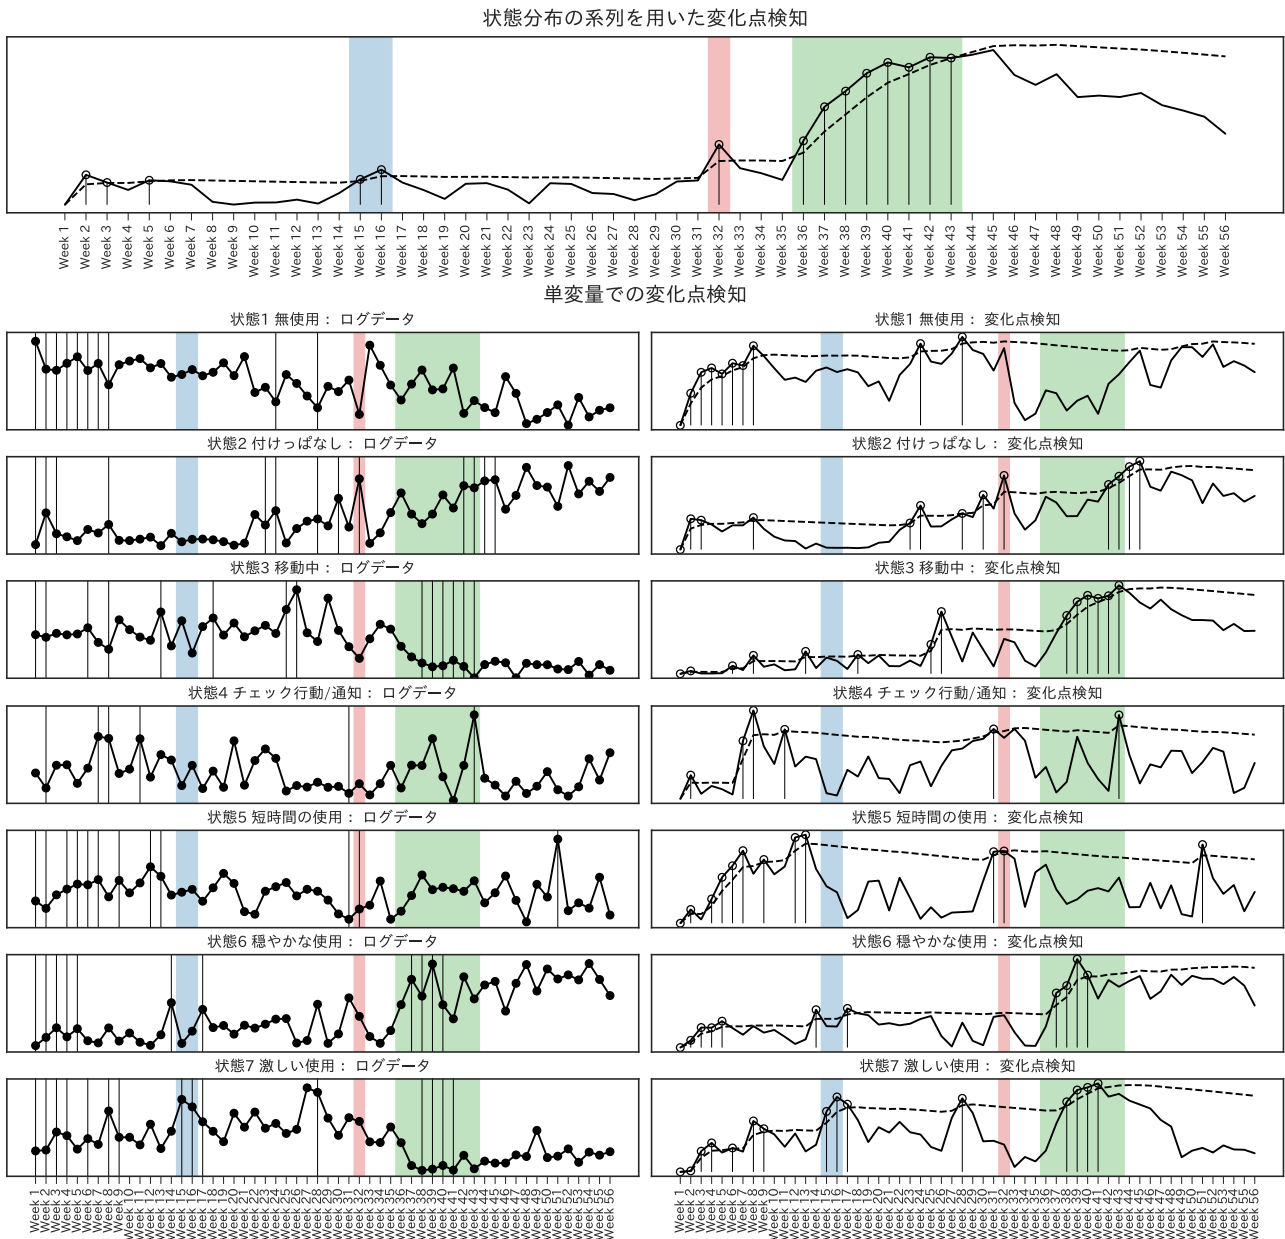


図3 患者Aに対する多変量と単変量の OCPD 結果

表1 患者Aについて、式(1)により推定された各特徴量の偏回帰係数  $\hat{\beta}$

変化点	状態1	状態2	状態3	状態4	状態5	状態6	状態7	$R^2$
Week 5	<b>0.15</b>	<b>0.42</b>	0.00	0.00	<b>0.12</b>	<b>0.32</b>	-0.55	0.98
Week 15	-0.00	-0.05	0.00	-0.21	-0.16	<b>0.08</b>	<b>0.09</b>	0.97
Week 16	-0.23	-0.02	0.00	-0.09	-0.09	<b>0.19</b>	<b>0.32</b>	0.99
Week 32	0.00	<b>0.50</b>	<b>0.37</b>	-0.13	<b>0.25</b>	<b>0.26</b>	-0.00	1.00
Week 36	-0.68	<b>1.08</b>	<b>0.30</b>	-0.14	-0.36	<b>0.81</b>	<b>0.09</b>	0.99
Week 37	-0.54	<b>1.11</b>	<b>0.18</b>	-0.07	-0.31	<b>0.62</b>	0.00	0.99
Week 38	-0.52	<b>0.88</b>	<b>0.30</b>	-0.05	-0.13	<b>0.50</b>	<b>0.22</b>	0.99
Week 39	-0.32	<b>0.59</b>	<b>0.33</b>	-0.10	-0.06	<b>0.50</b>	<b>0.22</b>	0.99
Week 40	-0.15	<b>0.49</b>	<b>0.48</b>	-0.12	-0.00	<b>0.33</b>	<b>0.31</b>	0.99
Week 41	-0.03	<b>0.36</b>	<b>0.45</b>	-0.12	0.00	<b>0.23</b>	<b>0.42</b>	0.99
Week 42	0.00	<b>0.35</b>	<b>0.51</b>	-0.15	-0.00	<b>0.23</b>	<b>0.37</b>	0.99
Week 43	0.00	<b>0.36</b>	<b>0.51</b>	-0.12	-0.00	<b>0.22</b>	<b>0.36</b>	0.99