

# 心拍変動を用いた時間依存睡眠段階遷移モデル

## Time-dependent Sleep Stage Transition Model Based on Heart Rate Variability

武田 十季<sup>♡</sup> 渡部 智樹<sup>♡</sup> 吉田 和広<sup>♡</sup>  
水野 理<sup>♡</sup>

Toki TAKEDA Tomoki WATANABE  
Kazuhiro YOSHIDA Osamu MIZUNO

本研究では、脳の中樞神経系の活動状態から定義される睡眠段階を、心拍変動から推定する睡眠段階分類器を新たに提案する。従来は、サポートベクタマシンなどの機械学習モデルを分類器として利用する際に有効な素性を抽出するための素性エンジニアリング研究が主であった。本研究では、従来研究の成果である有効素性を利用した上で、睡眠段階の出現分布と遷移確率が就床からの経過時間に依りて変動するという睡眠の性質に着目して生成モデルを構築し、ギブスサンプリングにより睡眠段階を推論する時間依存睡眠段階遷移モデルを新たに提案する。45名の健康者の覚醒・レム睡眠・ノンレム睡眠の三段階を分類する評価実験により、提案手法がサポートベクタマシンとナイーブベイズモデル、さらには、時間依存を考慮しない睡眠段階遷移モデルに比べて高い精度で分類できたことを示す。本研究は、ユーザの計測負担の低い心拍センサを用いた日常的な健康モニタリングの品質向上に貢献するものである。

**A new model is proposed to automatically classify sleep stages using heart rate variability (HRV). The generative model, based on the characteristics that the distribution and the transition probabilities of sleep stages depend on the elapsed time from the beginning of sleep, infers the sleep stage with a Gibbs sampler. Experiments were conducted using a public data set consisting of 45 healthy subjects and the model's classification accuracy was evaluated for three sleep stages: wake state, rapid eye movement (REM) sleep, and non-REM sleep. Experimental results demonstrated that the model provides more accurate sleep stage classification than conventional (naive Bayes and Support Vector Machine) models that do not take the above characteristics into account. Our study contributes to improve the quality of sleep monitoring in the daily life using easy-to-wear HRV sensors.**

♡ 日本電信電話株式会社 NTT サービスエボリューション研究所  
takeda.toki@lab.ntt.co.jp  
watanabe.tomoki@lab.ntt.co.jp  
yoshida.kazuhiro@lab.ntt.co.jp  
mizuno.o@lab.ntt.co.jp

### 1. はじめに

日本人の睡眠時間は過去 25 年間で男女共に減少傾向にある [1, 2]。OECD (経済協力開発機構) が 2014 年に発表した各国の 15 歳 ~ 64 歳までの男女の平均睡眠時間の国際比較調査によると、26 カ国平均が男性で 8 時間 15 分、女性で 8 時間 24 分であるのに比べ、日本人は男性が 7 時間 36 分、女性が 7 時間 46 分であり、男性・女性ともに睡眠時間が最も短い [3]。

睡眠の欠如は、認知機能や免疫機能を低下させ [4][5]、事故や病気のリスクを高める可能性がある [6]。睡眠を阻害する要因は様々あり、生活スタイルの変化や日々のストレス、寝室の照明や就床環境などがあげられる。日常生活において心身ともに健康で質の高い生活を送るためには、自分の睡眠の状態を把握して、睡眠や生活スタイルの改善に向けた行動を心がけることが重要である。

医療分野では睡眠の状態を診断するために睡眠ポリグラフ検査が行われる。この検査では、睡眠中に計測される脳波、眼球運動、顎筋電のデータを用いて、臨床検査技師が国際基準である R&K 法 [7] に基づいて、一定時間ごとの睡眠の状態を覚醒、レム睡眠、ノンレム睡眠 (ステージ 1 ~ 4) の 6 段階に分類する。それぞれの睡眠段階には異なる役割があり、例えば、レム睡眠は記憶の固定化や感情を整理する役割があり、ノンレム睡眠は身体の回復と関係があると言われている [8]。この検査技師により分類された睡眠段階の時系列データから、入眠までに要した時間や、各睡眠段階の割合、中途覚醒回数などの指標として変数を算出し、睡眠の質の定量的な評価が可能になるが、睡眠ポリグラフ検査による睡眠段階の判定はユーザへの拘束性が高く、装置が大規模であるため、日常生活での利用は困難である。

睡眠段階は脳の中樞神経系の活動状態に基づいて定義されるが、自律神経活動とも一定の相関があることが示されている [9]。自律神経活動は心拍変動に反映され、心拍変動 (Heart Rate Variability; HRV) は心電図の R 波ピークごとの間隔 (R-R Interval; RRI) を計算して求められる。近年では、ユーザへの負担を軽減させたウェアラブルセンサが普及し、日常生活での生体データ、特に心拍データを常時計測することが容易になっており [10]、心拍変動を用いた睡眠段階の推定に関する研究が注目を集めている。

従来の心拍変動を利用した睡眠段階推定は、Xiao らの研究 [11] に代表される様に、心拍変動からの特徴量抽出を行って、サポートベクタマシンやランダムフォレストなどの従来の機械学習モデルに適用する方法が主であった。これは脳波においても同様で [12]、最新の研究では、Långkvist らにより、deep belief nets (DBNs) を用いた深層学習による教師なしの特徴量抽出が行われている [13]。その一方で、睡眠自体の性質に着目した新たな推定モデルの構築はまだ未解決の課題として残っている。

我々は、ウェアラブルセンサで取得可能な心拍データを利用して、健康者を対象とした睡眠段階の覚醒、レム睡眠、ノンレム睡眠の 3 分類の推定に取り組み、ユーザが日々の睡眠の状態を容易に把握できることを目指す。本研究では、我々が着目した睡眠の性質に基づいて以下の Research Question の解決に取り組み、

#### Research Question

就床からの経過時間に依存して睡眠段階の分布と遷移確率が変化する性質を考慮することで、睡眠段階の推定精度を向上できるか？

就床からの経過時間と睡眠段階の出現確率に着目した、時間依存睡眠段階遷移モデル (Time-dependent Sleep Stage Transition Model; TSST) を提案する。

本研究の構成は次のとおりである。2 章にて関連研究を示し、3 章で時間依存睡眠段階遷移モデルについて説明する。4 章にて評価実験の結果を示し、5 章にて結論を述べる。

## 2. 関連研究

本章では睡眠段階推定に関連する研究について示す。

**脳波による睡眠段階推定** 睡眠段階を検査技師の視察によって判定することは、多くの時間と労力を要することから、脳波のみを用いて睡眠段階を自動推定する研究が取り組まれている。Ebrahimiら[14]は脳波から特徴量を抽出し、多層パーセプトロンにより睡眠段階を推定している。Långkvistら[13]は deep belief nets により教師なしで脳波から特徴量を抽出し、隠れマルコフモデルにより睡眠段階を推定している。Senら[12]は、多数の特徴抽出・選択アルゴリズムと、ランダムフォレスト、サポートベクタマシンなど5種類の分類手法の比較実験を行っている。しかし、これらの技術は睡眠ポリグラフ検査と同様、睡眠時の脳波データを計測する必要があるため、日常生活で計測することは容易でない。

**加速度による覚醒・睡眠判定** ユーザへの負担が少ないセンサを利用した、睡眠段階の推定に関する研究は盛んに行われている。アクチグラフは、腕時計型の加速度センサで、睡眠中の体動を加速度データとして計測することができる[15]。従来研究では、このアクチグラフを用いて、覚醒と睡眠を高精度に分類できることを示している[16][17]。また、河本ら[18]は、アクチグラフの加速度データをスペクトル解析し呼吸によって生じる成分を抽出して、レム睡眠の判定を試みている。しかし、いずれの研究においても覚醒と睡眠の2分類にとどまっており、アクチグラフでレム睡眠とノンレム睡眠の分類を精度良く推定することは難しい。

**心拍変動による睡眠段階推定** 多くの研究において心拍変動と睡眠段階との間に関係があることが示されている。例えば、心拍数はノンレム睡眠時に減少し、覚醒やレム睡眠時に増加することが示されている[19][20]。また、心拍変動の低周波成分(LF, 0.04-0.15Hz)と高周波成分(HF, 0.15-0.4Hz)の割合、つまり、LF/HFの減少がノンレム睡眠と関係があり、LF/HFの増加がレム睡眠と関係があることが示されている[21]。

これらの研究を背景にして、心拍データを用いた睡眠段階推定の研究が近年進展している。Mendezら[22]は、心拍変動から時間領域・周波数領域の特徴量を抽出し、隠れマルコフモデルによってレム睡眠とノンレム睡眠の2分類を推定している。Xiaoら[11]は、心拍変動から時間領域、周波数領域、非線形素性を含む全41種類を素性としたランダムフォレストによって、覚醒、レム睡眠、ノンレム睡眠の3分類を推定している。なお、心拍変動を利用する場合も、正解データには睡眠ポリグラフ検査(R&K法)による睡眠段階が利用されている。

睡眠段階推定の従来研究では、上記の様に睡眠データから良い特徴量を抽出して従来の分類モデルを適用する研究が殆どで、経過時間と睡眠段階の出現頻度の関係性のように、睡眠の特性に着目した推定は取り組まれていない。

**スマートフォン・ウェアラブルデバイスによる睡眠段階推定** 近年のスマートフォンやウェアラブルデバイスの発展により日常的に利用可能になったセンサ情報を用いた睡眠段階推定の研究が進んでいる。市販されているJawbone Up[23]やFitbit[24]では、アクチグラフを利用した睡眠状態のモニタリングが可能である。Gu[25]らは、スマートフォンから取得される音と照度データと腕の加速度データ、ユーザの年齢と就床からの経過時間を入力として睡眠段階の4分類に取り組んでいる。各取得データから特徴量を算出して条件付き確率場(Conditional Random Field; CRF)によって分類している。ただし、Guらの研究では心拍変動は使われておらず推定精度が低いため、心拍変動とスマートフォンのデータとを統合する等、精度向上への課題がある。

**Subject-specific/independent** モデル ある被験者の睡眠段階を推定するにあたり、同じ被験者の睡眠データを用いて学習する場合(Subject-specific)と、異なる被験者の睡眠データを用いて学習する場合(Subject-independent)があり、一般的に Subject-




図 1: 睡眠経過図の例

dependentの方が Subject-independent に比べて精度が高くなる[26, 11]。しかし、睡眠ポリグラフ検査が容易に行えないことから、一人の被験者に対して複数日付の睡眠データが含まれる公開データセットは存在していない。本研究は Subject-independent モデルのみを扱う。

## 3. 提案手法

本章では、提案する時間依存睡眠段階遷移モデルについて示す。まず本研究で用いる用語の定義を行い、それから提案モデルについて説明する。その後、提案モデルが用いる心拍特徴量の算出方法について示す。

### 3.1 用語定義

本研究で利用する用語の定義を以下に示す。

**定義 1 (時間ステップ)** 時間ステップ  $t$  は、1 から開始し、入床後から 30 秒毎に 1 ずつ増える値とする ( $t = 1, \dots, T$ )

**定義 2 (時間帯)** 時間帯  $c_t$  は、1 から開始し、就床から 30 分毎に 1 ずつ増える値とする。

**定義 3 (レム睡眠)** 急速眼球運動 (*Rapid Eye Movement; REM*) の見られる睡眠であり、身体が眠っているが脳が活動している状態である。

**定義 4 (ノンレム睡眠)** 急速眼球運動を伴わない睡眠 (*Non-Rapid Eye Movement; NREM*) であり、脳波の状態により 4 段階に細分化できる。本研究では、ノンレム睡眠を細分化せず 1 つの段階として扱う。

**定義 5 (睡眠段階)** 時間ステップ  $t$  における睡眠段階  $s_t$  は、覚醒、レム睡眠、ノンレム睡眠の 3 段階のいずれかとする。

**定義 6 (心拍特徴量)** 心拍特徴量  $\mathbf{h}_t = (h_{t1}, h_{t2}, \dots, h_{tK})$  は、被験者データごとに  $L$  レベルで正規化し離散化された  $K$  次元のベクトルである。 $h_{tk}$  は時間ステップ  $t$  における心拍特徴ベクトルの  $k$  番目の要素の値である。

**定義 7 (睡眠経過図)** 時間ステップ毎の睡眠段階の遷移を図示したものである。成人はノンレム睡眠のステージ 1 ~ レム睡眠の間を一夜に 4 ~ 5 回反復し、周期は 90 分程度である。睡眠の前半はノンレム睡眠が優性で、後半はレム睡眠が優性となり、早朝の 1 時間では 20% 以上をレム睡眠が占めるようになる (例: 図 1)。

### 3.2 時間依存睡眠段階遷移モデル

本節では、本研究で提案する時間依存睡眠段階遷移モデルを示す。まず、モデリングの背景となる睡眠段階と経過時間の関係について説明した後、就床からの経過時間に着目した睡眠段階の生成モデルである、時間依存睡眠段階遷移モデルを示す。その後、モデルの推論方法と、心拍特徴量の作成方法を示す。




図 2: 経過時間ごとの睡眠段階出現頻度

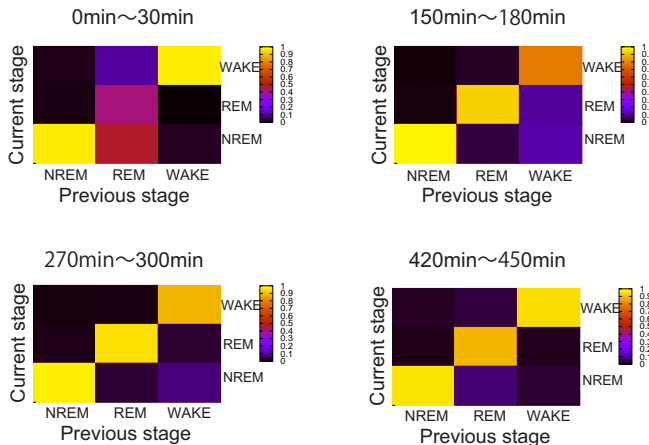


図 3: 経過時間ごとの睡眠段階の遷移確率

### 3.2.1 睡眠段階と経過時間の関係

Sleep Heart Rate and Stroke Volume Data Bank (SHRSV) [27] で公開されている、健康者 45 名 (16-61 歳, 男性 28 名) の検査技師によって分類された睡眠段階のデータを用いて、各時間帯 (30 分間) における睡眠段階と睡眠段階遷移パターンの出現頻度を表したものを図 2, 3 に示す。

図 2 から分かるように、レム睡眠の出現頻度は就床直後に比べて朝方の方が高く、ノンレム睡眠の出現頻度は朝方の方が低下している。図 3 からは、就床直後は、覚醒から覚醒への遷移、レム睡眠からノンレム睡眠への遷移の確率が高いことが分かる。また、就床から 3 時間以内の前半では、覚醒してもレム睡眠やノンレム睡眠に遷移しやすい傾向にあるのに比べて、後半では、1 度覚醒すると覚醒が持続しやすい傾向にあることが見て取れる。このように、睡眠段階の分布と遷移確率は、就床からの経過時間に依存して変化している。

以上の背景に基づき本研究では、下記 2 つの性質に着目した時間依存睡眠段階遷移モデルを提案する。

性質 1 (睡眠段階分布の時間依存性) 睡眠段階の分布は、就床からの経過時間に依存して変化する。

性質 2 (睡眠段階遷移の時間依存性) 睡眠段階の遷移確率は、就床からの経過時間に依存して変化する。

### 3.2.2 生成モデル

時間ステップ  $t$  における睡眠段階  $s_t$  の生起確率は、1 ステップ前の睡眠段階  $s_{t-1}$  と、就床からの経過時間、つまり現在の時間帯  $c_t$  と、心拍の特徴量の値  $\mathbf{h}_t$  に依存するとしてモデル化を行った。式 1 に睡眠段階  $s_t$  の条件付確率を、図 4 に提案モデルのグラフィカルモデルを示す。このとき、各  $h_{tk}$  は他の  $h_{t\ell} (h \neq g)$  と独立とする。

$$P(s_t = i | s_{t-1} = j, \mathbf{h}_t, c_t = m) \propto P(s_t | c_t)P(s_t | s_{t-1}, c_t) \prod_{k=1}^K P(h_{tk} | s_t)$$




図 4: 提案モデルのグラフィカルモデル。塗りつぶし円は観測変数、中抜き円は潜在変数、矢印は依存関係、方形は繰り返しを表す。

$$= \theta_{mi} \lambda_{mji} \prod_{k=1}^K \phi_{ihk} \quad (1)$$

$\theta_{mi}$  は時間ステップ  $t$  が含まれる  $m$  番目の時間帯 ( $c_t = m$ ) における睡眠段階の多項分布で、睡眠段階の分布が就床からの経過時間に依存して変化的こと (性質 1) に基づいている。 $\lambda_{mji}$  は  $c_t = m$  の時の、睡眠段階の遷移パターンの多項分布であり、睡眠段階の遷移確率が就床からの経過時間に依存して変化的こと (性質 2) に基づいている。

### 3.2.3 モデル推論

睡眠段階の系列全体の事後確率  $P(s | \mathbf{h}, \mathbf{c})$  を直接解析的に得ることは難しいため、ギブスサンプリング [28] を用いて、隠れ変数である各時間ステップの睡眠段階  $s_t$  を、式 1 の条件付確率に従って時間ステップ順にサンプリングすることを繰り返すことで推論する。ここで、 $s_1$  の睡眠段階は常に「覚醒」とする。

また、テストデータの各時間ステップにおける睡眠段階の推論時は各分布  $\theta, \lambda, \phi$  は既知であるとし、[27] の様な睡眠段階の正解付き学習データから下記のように推定した値を用いる。

$$\tilde{\theta}_{mi} = \frac{M_{mi}}{\sum_{i'} M_{mi'}} \quad (2)$$

$$\tilde{\lambda}_{mji} = \frac{M_{mji}}{\sum_{i'} M_{mji'}} \quad (3)$$

ここで、 $M_{mi}$  は学習データにおいて時間帯  $m$  で睡眠段階  $i$  となる個数、 $M_{mji}$  は時間帯  $m$  で睡眠段階  $j$  から  $i$  に遷移する個数である。 $\phi_{ihk}$  は、各睡眠段階  $i$  における  $\mathbf{h}_t$  の  $k$  番目の値の尤度関数であり、

$$\tilde{\phi}_{ihk} = \frac{M_{ihk}}{\sum_{i'} M_{i'k}} \quad (4)$$

と推定できる。 $M_{ihk}$  は睡眠段階  $i$  において観測される  $\mathbf{h}_t$  の  $k$  番目の値が  $h_{tk} = l_k$  を満たすカウントを表す。

### 3.3 心拍特徴量

本研究では、Xiao ら [11] による手順と同様に RRI から 12 種類の特徴量を作成した。本節では、RRI に対する事前処理、及び、特徴量算出について説明する。なお、Xiao らは 'stationary' とラベル付された正常データのみを用いているが、本研究ではより日常的な計測条件に近づけるため、'artifact' や 'non-stationary' とラベル付された非正常データも利用している。






図 5: RRI のパワースペクトル

### 3.3.1 RR の事前処理

各 RRI は、その RRI を中心とした前後 21 サンプルの平均値 ( $mRR$ ) と比較し、 $0.5 \times mRR$  未満、または、 $1.5 \times mRR$  を上回る場合は、異常値として  $mRR$  に置き換える。その後、30 秒ごとの睡眠段階の正解ラベルと対応づけて RRI を 30 秒ごとに分割する。

### 3.3.2 特徴量抽出

心拍特徴量は、時間領域解析と周波数領域解析 [29] によって算出する。

まず、時間領域解析では、各 30 秒区間の特徴量は、該当区間を中心とした 5 分間の事前処理済み RRI から、以下の特徴量を算出する。

- $mRR$ : RRI の平均値

$$mRR = \sum_{n=1}^N RRI_i$$

- $HR$ : 平均心拍数

$$HR = \frac{60000}{mRR}$$

- $SDNN$ : RRI の標準偏差

$$SDNN = \sqrt{\frac{1}{N-1} \sum_{n=1}^N (RRI_i - mRR)^2}$$

- $CVRR$ : RRI の変動係数

$$CVRR = \frac{SDNN}{mRR}$$

- $RMSDD$ : 連続した RRI の差の二乗平均平方根

$$RMSDD = \sqrt{\frac{1}{N} \sum_{n=1}^{N-1} (RRI_{i+1} - RRI_i)^2}$$

- $pNN50$ : 連続した RRI の差が 50ms 以上となる割合

$$pNN50 = \frac{\text{num}(RRI > 50)}{\text{num}(RRI)}$$

上記式において、 $\text{num}(\cdot)$  は述部の条件を満たすデータ数を示す。

次に、周波数領域解析は自律神経活動を評価する上で重要な解析法である [29]。RRI に対して FFT で周波数解析されたデータのうち、低周波数成分 (LF, 0.04-0.15Hz) には交感神経の活動が反映され、高周波数成分 (HF, 0.15-0.4Hz) には交感神経の活動が反映されている。また、中周波数成分 (MF, 0.1-0.15Hz) は血圧を制御する圧受容器反射機能と関連があることが知られている。本研究では、図 5 に示す各周波数帯、LF, MF, TLF, HF を対象として、各周波数帯のパワー積算の、全周波数帯 (TF) のパワー積算に対する割合を求める。さらに、異なる周波数帯同士の比率、LF/HF, MF/LF, TLF/LF を求める。

## 4. 評価

本章では、提案手法に対する評価方法とその結果について説明する。

### 4.1 評価方法

提案手法である時間依存睡眠段階遷移モデル (Time-dependent Sleep Stage Transition Model; TSST) を評価するため、Sleep Heart Rate and Stroke Volume Data Bank (SHRSV) [27] のデータベース (45 名) を利用して評価実験を行った。推定対象の時刻ステップ数の全被験者の合計は、NREM が 27718 (69.4%)、REM が 5970 (14.9%)、Wake が 6248 (15.6%) である。心拍特徴量は節に示す方法にて抽出した。

比較手法には、ナイーブベイズ (NB) とサポートベクターマシン (SVM) と提案手法から時間依存性を除いた睡眠段階遷移モデル (Sleep Stage Transition Model; SST) を用いた。NB は、提案モデルから性質 1 と性質 2 の考慮を外したものと考えられ、睡眠段階  $s_t$  を下記の式にて推定する。

$$P(s_t | \mathbf{h}_t) \propto P(s_t) \prod_{k=1}^K P(h_{tk} | s_t) \quad (5)$$

SST は、睡眠段階の分布と遷移確率は、就床からの経過時間に依存して変化しないと考えられ、睡眠段階  $s_t$  を下記の式にて推定する。

$$P(s_t | s_{t-1}, \mathbf{h}_t) \propto P(s_t) P(s_t | s_{t-1}) \prod_{k=1}^K P(h_{tk} | s_t) \quad (6)$$

SVM 以外の手法は、心拍の特徴量の値を 6 段階 ( $L = 6$ ) に離散化し、SVM は正規化された値をそのまま利用した。評価は、45 人のうち 44 人を学習データ、1 人をテストデータとした 45-fold クロスバリデーションで行った。

### 4.2 評価尺度

本実験では、一般的な正解率による評価に加えて、下記の 2 つの評価尺度を用いる。

#### 4.2.1 Cohen の Kappa 係数

評価データに睡眠段階の偏りが見られるため、偶然に推定結果が一致する確率を除外して、睡眠段階の正解データに対する推定結果の一致性を評価するため、以下の式で計算される Cohen の Kappa 係数 [30] を用いる。

$$k = \frac{P_o - P_c}{1 - P_c} \quad (7)$$

ここで、 $P_o$  は睡眠段階の正解データと推定結果の一致率、 $P_c$  は睡眠段階の正解データと推定結果が偶然により一致する確率である。なお、本研究で使用したデータセットにおいては、 $P_c = 0.5285$  である。

#### 4.2.2 マクロ平均 F 値

全ての睡眠段階に対して精度の良い推定が行えているかを評価するため、各睡眠段階  $i$  ごとに適合率 (Precision) と再現率 (Recall) を算出して F 値を算出し、平均を取ったマクロ平均 F 値を利用する。

$$\text{Macro F-measure} = \frac{1}{3} \sum_{i=1}^3 \frac{2 \cdot \text{Recall}_i \cdot \text{Precision}_i}{\text{Recall}_i + \text{Precision}_i} \quad (8)$$

### 4.3 評価結果

各手法による評価結果を表 1 に示す。提案手法 TSST は、正解率で 0.760 を実現し、SVM に比べて 0.039、SST に比べて 0.018、ナイーブベイズに比べて 0.094 の改善となった。また、マクロ平均 F 値では 0.569 を実現し、SVM に比べて 0.101、SST に比べて 0.061、ナイーブベイズに比べて 0.052 の改善であった。また、Kappa 係数については、Fleiss による分類 [31] では 0.4 未満が 'poor' (一致率が低い) とされるが、提案手法のみが 0.418 と 0.4 を超え、SVM は 0.236 に留まった。

次に、図 6 と図 7 に、それぞれ異なる被験者データをテストデータとした場合の推定結果を示す。緑の点線が睡眠段階の正解

表 1: 45-fold クロスバリデーションによるナイーブベイズ (NB), サポートベクタマシン (SVM), 提案手法 (TSST) の推定結果 .

モデル	正解率	Kappa 係数	F 値 (マクロ平均)	F 値 (NREM)	F 値 (REM)	F 値 (Wake)
NB	0.676	0.329	0.517	0.805	0.332	0.414
SVM	0.721	0.236	0.450	0.836	0.189	0.326
SST	0.742	0.357	0.527	0.843	0.229	0.509
TSST	0.760	0.418	0.569	0.855	0.258	0.596

を示し, 赤線が各手法による推定結果を示す. 提案手法は時間依存性を考慮するため, 特に就床してから入眠までの時間や, 起床時のタイミングに対しての精度が良くなっている. 睡眠時間や入眠に要する時間は, 睡眠の質を評価する上で重要な変数の 1 つであるため, 提案手法による精度向上は意義が大きいと考える. また, 今回利用したデータセットにおいて, レム睡眠は最も出現回数が少ない. このため, SVM ではレム睡眠を誤って覚醒と推定している場合が多かったが, 提案手法では, レム睡眠と覚醒の分類精度が向上している. 睡眠時に覚醒する回数が多いほど, 睡眠が中断された可能性が示唆されることから, 睡眠の質を評価する上で, 睡眠途中における覚醒の誤分類を減らすことは非常に重要である.

また, 提案手法は, 睡眠段階の分布が就床からの経過時間に依存して変化すること (性質 1) と, 睡眠段階の遷移確率が就床からの経過時間に依存して変化すること (性質 2) の考慮をナイーブベイズモデルに加えたものとみなすことができ, 正解率, Kappa 係数, マクロ平均 F 値の全てで提案手法は有意 (paired Wilcoxon test;  $p < .001$ ) にナイーブベイズと SVM を上回り, SST に対して提案手法は, 有意な傾向 ( $p < .01$ ) で正解率が上回り, Kappa 係数とマイクロ平均 F 値では有意 ( $p < .005$ ) に上回った. これらの結果から, 本研究により Research Question を解決できたと結論付ける.

## 5. おわりに

本研究では, 脳の中樞神経系の活動状態から定義される睡眠段階を, 心拍変動から推定する睡眠段階分類器を提案した. 提案した時間依存睡眠段階遷移モデル (Temporal-dependent Sleep Stage Transition Model; TSST) は, 睡眠段階の出現分布と遷移確率が就床からの経過時間に依存して変化することに着目して睡眠段階を分類する点に新規性がある. 45 名の健常者の公開データセットを用いた評価実験では, 覚醒・レム睡眠・ノンレム睡眠の三段階を 76% で正解できた. また, Kappa 係数は 0.418 となり, サポートベクタマシンの 0.236 に比べて大きな精度向上を実現した. 特に, 就床してから入眠までの時間や, 起床時のタイミングに対しての推定精度が向上し, 睡眠中におけるレム睡眠と覚醒の誤判定が低減している. 提案手法は, 従来取り組まれてきた心拍変動からの有効素性抽出 (素性エンジニアリング) の研究成果を活用することができ, 日々の睡眠の状態を容易に, かつ, 精度良くモニタリングする技術の発展に貢献するものである.

今後の課題は 2 点ある. 1 点目は, 個人適応による睡眠段階の精度向上である. 同一被験者内で学習・テストを行う Subject-specific モデルによる睡眠段階分類は, データの準備の難しさから研究が進展していないが, 日常的な健康モニタリングにおいては重要な課題である. 2 点目は, 他のセンサデータとの統合である. 手首の加速度データには, 睡眠中の寝返り等の体動情報が反映されており, また, スマートフォン等のマイクを用いると寝息の音を取得できる. これらは睡眠段階を推定する上で重要な情報になり得る. これらのセンサデータと心拍データの統合によって睡眠段階推定の精度向上が期待できる.

## 【文献】

- [1] 宮崎総一郎, 佐藤尚武, "睡眠と健康", NHK 出版, 2013.
- [2] 総務省. 平成 23 年社会生活基本調査 生活時間に関する結果結果の概要. 2012.
- [3] Organization for Economic Co-operation and Development. Balancing paid work, unpaid work and leisure. 2014. <http://www.oecd.org/gender/data/balancingpaidworkunpaidworkandleisure.html>
- [4] M. Thomas, H. Sing, G. Belenky, H. Holcomb, H. Mayberg, R. Dannals, H. Wagner, D. Thorne, K. Popp, L. Rowland, A. Welsh, S. Balwinski, and D. Redmond. Neural basis of alertness and cognitive performance impairments during sleepiness. I. Effects of 24 h of sleep deprivation on waking human regional brain activity. *Journal of Sleep Research* Volume 9, Issue 4, pp. 335-352, 2000.
- [5] CA. Everson. Clinical assessment of blood leukocytes, serum cytokines, and serum immunoglobulins as responses to sleep deprivation in laboratory rats. *Am J Physiol Regul Integr Comp Physiol* 289, pp. 1054-1063, 2005.
- [6] JS. Durmer, and DF. Dinges. Neurocognitive Consequences of Sleep Deprivation. *Semin Neurol*. pp. 117-29, 2005.
- [7] A. Rechtschaffen, and A. Kales. A Manual of Standardized Terminology, Techniques and Scoring System for Sleep Stages of Human Subject. US Government Printing Office, National Institute of Health Publication, Washington DC, 1968.
- [8] A Publication of the National Sleep Foundation All content was reviewed by the NSF appointed expert panel. THE SLEEP DISORDERS.
- [9] A. Baharav, S. Kotagal, V. Gibbons, B. K. Rubin, G. Pratt, REEGT, J. Karin, and S. Akselrod. Fluctuations in autonomic nervous activity during sleep displayed by power spectrum analysis of heart rate variability. *Neurology*, vol. 45, pp. 1183-1187, 1995.
- [10] NTT 技術ジャーナル, 2014.11, p16-20.
- [11] M. Xiao, H. Yan, J. Song, Y. Yang, and X. Yang. Sleep stages classification based on heart rate variability and randomforest. *Biomedical Signal Processing and Control*, 8, pp.624-633, 2013.
- [12] Baha Sen, Musa Peker, Abdullah Çavusoglu, Fatih V. Celebi. A Comparative Study on Classification of Sleep Stage Based on EEG Signals Using Feature Selection and Classification Algorithms. *Journal of Medical Systems* 38(3), pp. 1-21, 2014.
- [13] M. Långkvist, L. Karlsson, and A. Loutfi. Sleep Stage Classification Using Unsupervised Feature Learning. *Advances in Artificial Neural System*, 2012.
- [14] F. Ebrahimi, M. Mikaeili, E. Estrada, and H. Nazeran. Automatic Sleep Stage Classification Based on EEG Signals by Using Neural Networks and Wavelet Packet Coefficients. *IEEE EMBS Conference*, 1151-4, 2008.
- [15] S. A. Israel, R. Cole, C. Alessi, M. Chambers, W. Moorcroft, C. P. Pollak. The role of actigraphy in the study of sleep and circadian rhythms. *Sleep*, 26(3), pp. 342-359, 2003.
- [16] L. D. Souza, A. A. Benedito-Silva, M. L. Nogueira Pires, D. Poyares, S. Tufik, and H. M. Calil. Further validation of actigraphy for sleep studies. *Sleep*, vol. 26, no. 1, pp. 81-85, 2003.
- [17] J. Paquet, A. Kawinska, and J. Carrier. Wake detection capacity of actigraphy during sleep. *Sleep*, vol. 30, no. 10, pp. 1362-1369, 2007.

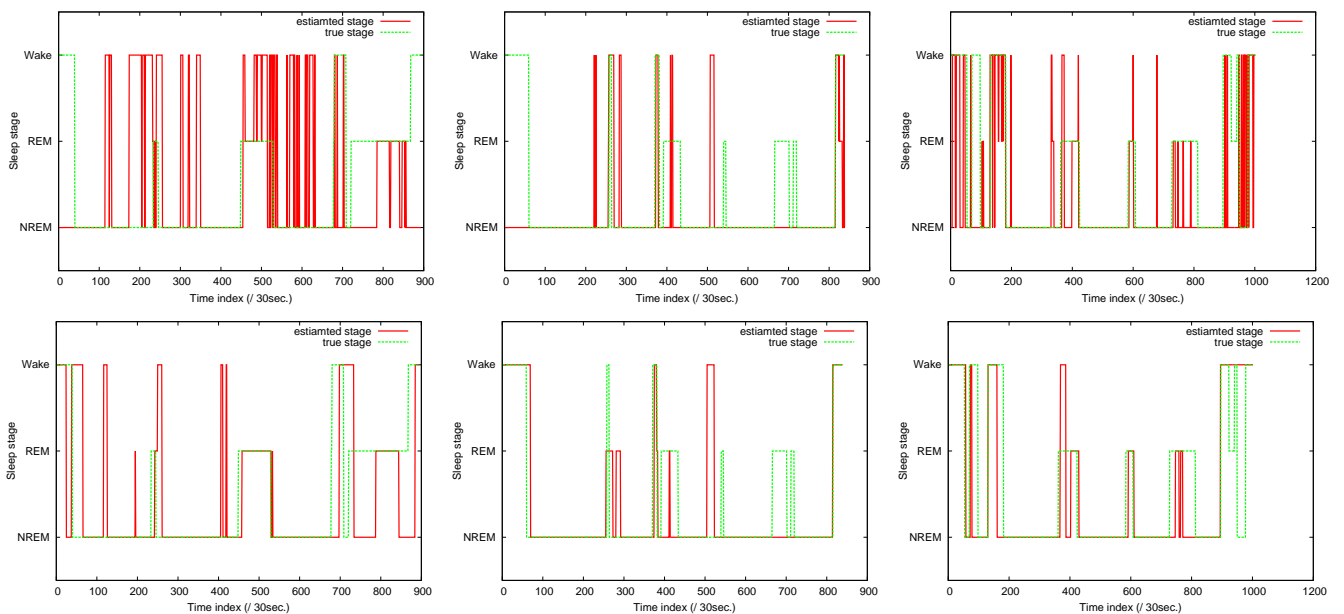


図 6: 上段: 被験者 A, B, C のデータの SVM による睡眠段階の推定結果 . 下段: 被験者 A, B, C のデータの提案手法 TSST による睡眠段階の推定結果 .

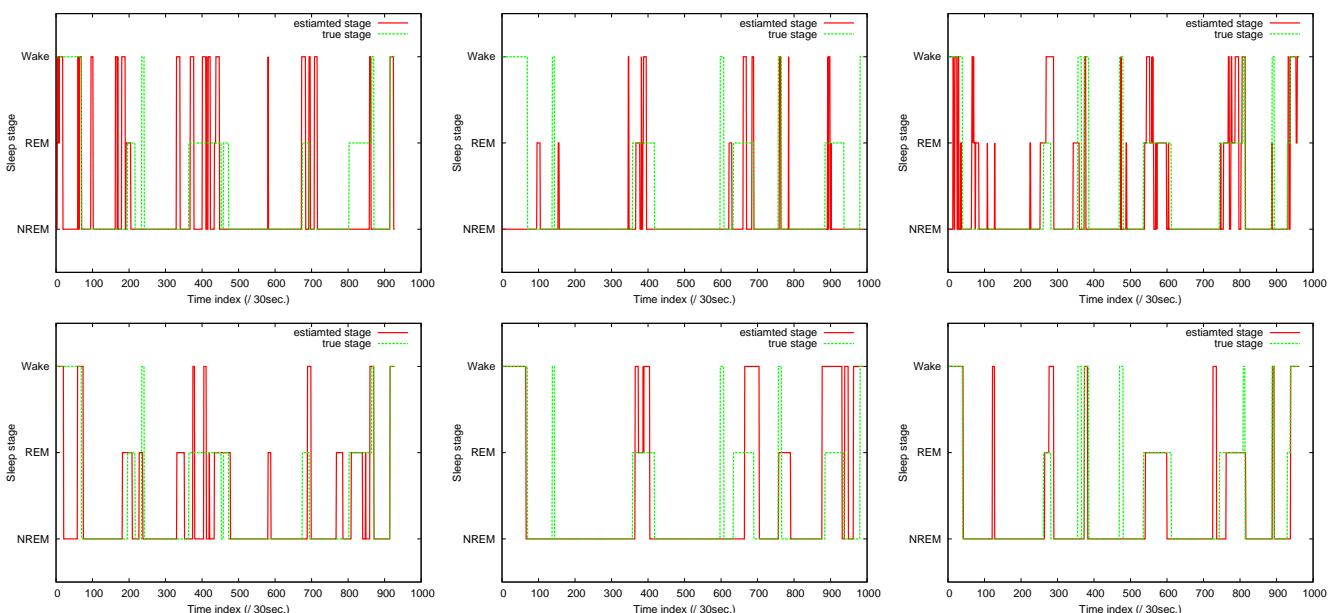


図 7: 上段: 被験者 D, E, F のデータの SVM による睡眠段階の推定結果 . 下段: 被験者 D, E, F のデータの提案手法 TSST による睡眠段階の推定結果 .

- [18] K. Kawamoto, H. Kuriyama, and S. Tajima. Actigraphic Detection of REM Sleep Based on Respiratory Rate Estimation. *Journal of Medical and Bioengineering* vol. 2, no. 1, pp.20-25, 2013.
- [19] P.P. Busek, J. Vankova, J.J. Opavsky, J. Salinger, and S. Nevsimalova. Spectral analysis of heart rate variability in sleep, *Physiological Research*, pp. 369-376, 2005.
- [20] A. Gundel, D. Jurgen, A.S. Yuri, and V.P. Valery. Heart period and heart period variability during sleep on the MIR space station. *Journal of Sleep Research*, pp. 37-43, 1999.
- [21] U.J. Scholz, A.M. Bianchi, S. Cerutti, and S. Kubicki. Vegetative background of sleep:spectral analysis of the heart rate variability. *Physiology and Behavior*, 62, pp. 1037-1043, 1997.
- [22] M.O. Mendez, M. Matteucci, V. Castronovo, L.F. Strambi, V. Castronovo, S.Cerutti, and A.M. Bianchi. Sleep staging from heart rate variability: time-varying spectral features and hidden Markov models. *International Journal of Biomedical Engineering and Technology*, 3, pp. 246-263, 2010.
- [23] Jawbone Up. <https://jawbone.com/up>.
- [24] Fitbit. <http://www.fitbit.com/>.
- [25] W. Gu, Z. Yang, L.Shanguan, W. Sun, K. jin, and Y. Liu. Intelligent Sleep Stage Mining Service with Smartphones. *ubicomp*, pp. 13-17. 2014.
- [26] S. J. Redmond, C. Heneghan. Cardiorespiratory-based sleep staging in subjects with obstructive sleep apnea. *IEEE Trans. Biomed. Engineering* 53(3), pp. 485-496, 2006.
- [27] Institute of Psychophysiology and Rehabilitation, Kaunas University of Medicine: Sleep Heart Rate and Stroke Volume Data Bank, <http://www.pri.kmu.lt/datbank/index.php>.
- [28] T. L. Griffiths, and M. Steyvers. Finding Scientific Topics. *PNAS*, Vol. 101, pp. 5228-5235, 2004.
- [29] Task Force of The European Society of Cardiology and The North American Society of Pacing and Electrophysiology. Heart rate variability: standards of measurement, physiological interpretation, and clinical use, *European Heart Journal*, pp. 354-381, 1996.
- [30] K. L.Gwet. *Handbook of Inter-Rater Reliability*. 2012.
- [31] J.L. Fleiss. *Statistical methods for rates and proportions* (2nd ed.). John Wiley & Sons Ltd, 1981.

### 武田 十季 Toki TAKEDA

日本電信電話株式会社 NTT サービスエボリューション研究所所属。2009年九州大学芸術工学部卒業。2011年同大学院修士課程修了。同年日本電信電話株式会社に入社。以来、ライフログ、生体信号処理の研究開発に従事。情報処理学会会員。

### 渡部 智樹 Tomoki WATANABE

1992年横浜国立大学工学部卒業。同年、日本電信電話株式会社入社。主に、家電制御技術、生体状態計測・推定技術の研究開発に従事。現在 NTT サービスエボリューション研究所主任研究員。博士(工学)。電子情報通信学会、情報処理学会、各会員。

### 吉田 和広 Kazuhiro YOSHIDA

日本電信電話株式会社 NTT サービスエボリューション研究所所属。1996年東京工業大学情報理工学研究所計算工学専攻修了。センシング活用技術の研究開発に従事。

### 水野 理 Osamu MIZUNO

1994年早稲田大学理工電気工学科大学院修了。同年、日本電信電話株式会社入社。現在、NTT サービスエボリューション研究所勤務。日本音響学会、言語処理学会各会員。