

Wi-Fi電波強度の変化を利用した無拘束な 睡眠時体動判定手法の提案

庵前 修¹ Korpela, Joseph¹ 前川 卓也¹

概要: 睡眠は健康な生活に不可欠な要素であるが、不眠や睡眠不足、十分な睡眠時間をとっているにも関わらず疲労が回復しないといった睡眠の量や質の低下に関する問題を抱えている人は多く存在する。睡眠に関する問題は集中力の低下などを引き起こすだけではなく、免疫力の低下や様々な病気の引き金となる。また子供の睡眠不足は脳や身体の発達の妨げになることが知られている。そのため、質の高い睡眠が十分に取られているかをモニタリングする手法の研究開発が数多く行われている。既存の睡眠モニタリング手法には、加速度センサを備えたリストバンドを装着するといった拘束性を伴う問題や、脳波計や筋電計のような高価で専門的な知識を必要とする測定機器を用いているなどといった問題がある。一方、先行研究により、睡眠時の体動と睡眠状態には相関があることが分かっている。そこで本研究では、Wi-Fi機能を備えたスマートフォンやタブレット端末といった身近なデバイスにより電波の変化を測定することで無拘束に睡眠時の体動を検出する手法を提案する。提案手法では睡眠時にユーザの身体の両横にWi-Fi機能を備えたデバイスを設置し、2台の間で継続的に通信を行うことで、電波の受信信号強度(RSSI)データを取得する。そのRSSIデータから体動時の電波強度変化をよく捉える特徴量を抽出し、機械学習を用いて、睡眠時の体動を認識するモデルの学習を行う。提案手法では隠れマルコフモデルを用いてユーザ非依存の体動判定モデルを構築し、認識時に最尤線形回帰適応を用いてユーザのテストデータにフィッティングするようモデル適応することにより、エンドユーザ側での学習データの取得を必要とせずにユーザに適したモデルを構築する。

キーワード: 睡眠モニタリング, 体動, Wi-Fi電波強度, 機械学習

Proposing a System for Unobtrusive Detection of Body Movements during Sleep Based on the Measurement of Wi-Fi RSSI

OSAMU AMMAE¹ JOSEPH KORPELA¹ TAKUYA MAEKAWA¹

Abstract: Although sleeping is essential for healthy life, many people have a problem related to insufficient or poor quality sleep. This problem causes not only loss of concentration but also a decline in immune function and various diseases. Also, children's lack of sleep is known for preventing mental and physical growth. Therefore, many researchers have developed sleep monitoring systems that permit us to measure the quality of sleep. However, because many existing sleep monitoring systems require a user to wear some device, e.g., wristband, the systems are more or less obtrusive to the users. In addition, several existing systems require an expensive special device and expert knowledge. On the other hand, previous research has found a correlation between body movements during sleep such as rolling over and sleep state. In this paper, we propose a method for unobtrusive detection of body movements during sleep based on the measurement of Wi-Fi Received Signal Strength Indication (RSSI) by using off-the-shelf Wi-Fi devices like smart phones or tablet computers. From the detected body movements, we can estimate a user's sleep state such as Rapid eye movement (REM) sleep or non-REM sleep. In our proposed system, we obtain RSSI data by placing two devices equipped with Wi-Fi modules on the left and right sides of a user's bed when sleeping. One device measures RSSI of the opposite device and we use the RSSI data to construct a body movement recognition model by employing machine learning approach. We construct a user independent recognition model based on the hidden Markov model, and employ maximum likelihood linear regression (MLLR) to adapt the user independent model to an end user. Therefore, our system is designed so that it does not require an end user's labeled training data.

Keywords: sleep monitoring, body movement, Wi-Fi RSSI, machine learning

1. はじめに

睡眠は健康な生活に不可欠な要素であるが、近年、不眠や睡眠不足、十分な睡眠時間をとっているにも関わらず疲労が回復しないなど睡眠に関する問題が増加している。睡眠に関する問題は、集中力の低下などを引き起こすだけでなく、免疫力の低下や発ガンのリスクの増加、肌の老化や肥満などと言った身体的な疾病に加え、慢性化することによりうつ病や自律神経失調症と言った精神疾病を引き起こす可能性がある。また子供の睡眠不足は成長ホルモンの分泌量が低下するため、知能の発達や身体の成長を妨げるという問題がある。そのため、質の高い睡眠が十分に取られているかをモニタリングする手法の研究開発が多く行われている。しかし、既存の睡眠モニタリング手法として広く用いられている睡眠ポリグラフィ (PSG: polysomnography)[1] は、脳波計や筋電計などを用いて専門家の指導の下に計測するものである。その他多くの既存研究においても、データの取得に拘束性を伴うデバイスを用いる必要があるという問題や、高価な専用のデバイスを用いるという問題がある。一方、先行研究から睡眠時の体動の出現頻度は睡眠段階と密接に関連しており、体動の出現頻度の順位は睡眠段階が深くなるほど少なくなることが報告されている [2]。一方近年、スマートフォンやタブレット端末の普及により、個人でスマートフォンとタブレット端末を両方所持するということが珍しくなくなってきた。

これらのことから、本研究では身近なデバイスとして、スマートフォンやタブレット端末を用いて睡眠時の体動を検出することを目指す。具体的には、このような Wi-Fi モジュールを搭載したデバイスにより、電波の変化を測定することで無拘束に睡眠時の体動を検出する手法を提案する。提案手法では睡眠時にユーザのベッドの左右それぞれに Wi-Fi 機能を備えたスマートフォンやタブレット端末といった身近なデバイスを設置することを想定する。そして、左右の端末間の Wi-Fi 電波強度の変化を測定することで、無拘束に体動を検出する。本研究では 2 台の端末を必要とするが、近年スマートフォンとタブレットの 2 台持ちをする人が増えているため、現実的な手法であると考えられる。また取得するセンサデータは Wi-Fi 受信信号強度 (RSSI: Received Signal Strength Indication) データのみであるため、無拘束性も確保されることが考えられる。

提案手法では、一方の端末が送信した電波の強度を他方の端末が観測し、その電波強度の時系列データから寝返りの際に発生する強度の変化を検出する。このとき、電波強度の変化量は非常に小さいため、データの移動分散と移動平均を計算し微小な変化を強調するよう前処理をした後、さら

にベイズ情報量基準 (BIC: Bayesian Information Criteria) を用いたトレンド変化点検出などを用いて、体動の際の電波強度変化を捉えた特徴抽出を行う。そして、体動の際に特有な特徴量の変化を隠れマルコフモデル (HMM: Hidden Markov Model) により学習し、そのモデルを用いて体動の認識を行う。このとき、他のユーザラベル付きデータにより学習されたユーザに非依存なモデルを最尤線形回帰 (MLLR: Maximum Likelihood Linear Regression) 適応 [3] と呼ばれるモデル適応手法を用いてエンドユーザに適応させることにより、エンドユーザがラベル付き学習データを用意する必要のない認識を行う。行動認識などの分野においてユーザ自身が用意した学習データを用いて学習したユーザに依存したモデルを用いた認識は、ユーザに非依存なモデルを用いた認識に比べて精度は高いことが一般的に知られているが、エンドユーザ自身がラベル付きデータを用意する必要がある。ユーザ自身がラベル付きデータを用意するのは実用の上では容易なことではなく、この方法はあまり現実的ではない。そこで本研究では MLLR 適応を用いることによって、ユーザに非依存なモデルを用いつつ、高い精度での認識を目指す。また本研究で用いる MLLR 適応は、音声認識の分野で使用されている回帰木を基に適応を行い、この回帰木を用いた MLLR 適応を用いることによって、テストデータの量に応じた過学習に強い適応を行うことができる。

以降では、2 章で関連研究について説明したあと、3 章で Wi-Fi 電波強度情報から睡眠時の体動を検出する手法について説明する。4 章で提案手法の評価実験について説明を行い、5 章で本研究のまとめを行う。

2. 関連研究

2.1 睡眠に関する研究

睡眠障害の問題は近代社会において重要なトピックの 1 つとなっている。睡眠は量だけではなく、質も重要とされており、この睡眠の質はいくつかの方法によって定義される。例えば、十分な睡眠をとっているか否か、日中の眠気、いくつかの睡眠を妨げる要因がある中で主観的睡眠感などが定義されている。質の低い睡眠は健康に多くの悪影響を与えるため、睡眠モニタリングの手法の研究開発は多く行われている。ここでは、本研究のアプローチである、睡眠段階と体動の関係についての研究を紹介したのち、睡眠のモニタリングに関する研究について紹介する。

2.1.1 睡眠段階と体動の関係

Wilde-Frenz らは、睡眠時の体動と睡眠段階には強い相関があることを示した [2]。この研究では、覚醒、レム睡眠、ノンレム睡眠 1, 2, 3, 4 の 6 段階に分けられた睡眠段階について、体動の発生頻度は覚醒、ノンレム睡眠 1, レム睡眠、ノンレム睡眠 2, ノンレム睡眠 3 + 4 の順に減少していくことがわかった。また、多量のデータを用いた場

¹ 大阪大学大学院情報科学研究科
Graduate School of Information Science and Technology, Osaka University, Suita, Osaka, Japan

合、体動頻度の分布はノンレム睡眠1, レム睡眠, ノンレム睡眠2, ノンレム睡眠3+4の4クラスにおいて、ほとんどオーバーラップがないことが示され、これらのことから、データ数が十分に存在する場合に、体動が睡眠段階を表す指標として信頼できると結論づけている。

2.1.2 睡眠のモニタリングに関する研究

拘束性を伴った睡眠モニタリングの研究開発は多く行われている。例えば、既存の睡眠モニタリング手法の中で最も一般的であり広く用いられている PSG は、脳波計や筋電計などの測定装置を用いて脳波、眼球運動、オトガイ筋や下肢筋の筋電図、呼吸、心電図、動脈血酸素飽和度など様々な項目について専門家の指導の下に計測、評価するものである。また加速度センサを用いた睡眠モニタリング手法は多く存在する。近年では、Fitbit flex^{*1} や Jawbone UP^{*2} のようなウェアラブルセンサでも睡眠のモニタリングは行われている。しかし、これらは拘束性を伴い、また専用のデバイスを要する。

拘束性を伴わない製品もいくつか存在している。オムロン睡眠計 HSL-101^{*3} は電波を用いて睡眠状態をモニタリングする専用のデバイスである。また、拘束性を伴わない睡眠モニタリング手法の研究も多く行われている。例えば、Watanabe らはエアマットレス型の生体計測装置を用いることによって、睡眠のモニタリングを行った [4]。しかし、これについても専用のデバイスを要するという問題がある。

近年ではスマートフォンに搭載された加速度センサを用いた睡眠評価のアプリケーションも存在する。これは、枕元にスマートフォンを置くことで非拘束に睡眠時の体動の検出を行うが、間接的に加速度を取得するため精度があまり高くなく、またベッドの上に必ず置く必要があるため、睡眠中にベッドの下に落ちてしまう危険などがある。

スマートフォンに搭載された様々なセンサを用いた睡眠に関する研究も行われている。Chen らは、スマートフォンから得られる充電中、ロック中といったユーザの関与なしに得られる単純なデータのみを用いて、ユーザの睡眠時間の推定を試みた [5]。この研究では、平均 42 分の誤差で睡眠時間の推定を行っている。Min らは、スマートフォンをアラームとして使用する人の習慣を利用して、睡眠状態の調査を試みた [6]。この研究では、スマートフォンの7つのセンサデータ (加速度、音声、光センサ、スクリーン近接センサ、稼働中のプロセス、バッテリー状態、ディスプレイスクリーンの状態) を入力として、モデルの構築を行った。10 分間隔で睡眠しているか否かの分類については、93.6%の精度で分類を行っている。また、83.7%の精度で睡

眠の質が良かったか悪かったかの分類を行っている。この研究では、睡眠の質をピッツバーグ睡眠質問票 (Pittsburgh Sleep Quality Index) に基づいて評価している。これらのスマートフォンの加速度センサ以外の様々なセンサデータを用いた睡眠に関する研究では、睡眠時間などの推定は行えるが睡眠段階の評価までは行えていない。

2.2 デバイスフリー行動認識に関する研究

一般的な行動認識は、加速度センサなどを身体に装着することによって行う。しかし近年、センサデバイスを身体に装着することなく行動認識を行う、デバイスフリー行動認識に関する研究が多く行われている。ここではデバイスフリー行動認識の中でも特に、電波情報を用いた行動認識に関する研究について紹介する。Shi らは、USRP(Universal Software Radio Periphera)^{*4} と呼ばれる汎用信号処理ハードウェアを用いて FM ラジオ信号から生じる振幅に基づいた、82.5MHz の信号帯域の高周波信号特徴を 256kHz のサンプリングレートで抽出し、人がいない、横たわっている、立っている、歩行、走行、這うといった行動を認識することを試みている [7][8]。これらの6クラスの分類を、人がいないなどの静的行動と歩行などの動的行動に分類したのち、各クラスへの分類を SVM や決定木、k 近傍法などで行っているが、2段階の分類にすることにより、分類精度の向上があり、また静的行動については、全て 90% を大きく上回るような高い精度での認識ができているのに対し、動的行動については、67.5%-92.4%と分類精度にばらつきがみられた。一方で、静的行動と動的行動の分類については、99.4%と高い精度を達成している。このような、データの送受信機に依存した信号帯域の電波を用いて行動の認識を行う研究は多く存在するが、これらの認識手法には専用のデバイスが必要であるという問題がある。

一方、Wi-Fi 電波を用いたデバイスフリーの行動認識も行われている。Scholz らは、Wi-Fi 電波の RSSI データを使用し、ユーザが電波受信機を持つ、device-bound の行動認識とユーザが電波受信機を持たない、device-free の行動認識について、精度の比較を行った [9]。この研究では、歩行、静止などの6種類の行動について空間内に複数のデバイスを設置することで認識を試みている。device-bound である場合は 89.6%、device-free である場合は 89.4%と、どちらについても高い精度での認識を行い、Wi-Fi 電波を用いた行動認識が可能であることを示した。

また、スマートフォンを Wi-Fi 電波の受信機として行動認識を行う研究も存在する。一般に、スマートフォンからは平均した RSSI データしか取得できず約 1Hz のサンプリングレートでしか RSSI を取得できない。そのため、行動認識などは困難であったが、Sigg らは、スマートフォンを

*1 <http://www.fitbit.com/>

*2 <https://jawbone.com/>

*3 <http://www.healthcare.omron.co.jp/product/hsl/hsl-101.html>

*4 <http://www.ettus.com/>

モニターモードに変更し、tcpdump を用いることでこの問題を解決し、スマートフォンでの行動認識を行った [10].

以上のことから、本研究では、身近なデバイスを用いて無拘束に睡眠状態の評価を行うことを実現するために、Wi-Fi 電波を用いて無拘束に睡眠時の体動を検出する手法の実現を目指す。

3. 提案手法

本研究では、図 1 のようにベッドの左右に Wi-Fi 機能をもつデバイスを配置する。




図 1 提案手法が想定する環境

本研究の実験で用いるデバイスは Raspberry Pi^{*5} という小型コンピュータであり、一方のデバイスは udp 通信の broadcast により約 350Hz で他方のデバイスにパケットの送信を行っている。他方のデバイスはモニターモードで tcpdump を起動させることで、パケット単位での RSSI 情報の取得を行う。本研究では、Raspberry Pi をデータの送受信機として使用したが、文献 [10] のようにスマートフォンを用いて tcpdump を起動させることが可能であるため、スマートフォンでも同様のことができる。図 2 は、実際に




図 2 実際に取得した生データの例

寝返りをしたときに得られた生データであるが、信号強度の変化が小さく、生データのままで寝返りの検知が難しいと考える。そこで本研究では、前処理として 1 秒幅、90%オーバーラップのスライディング時間窓を用いて移動平均と移動分散を計算する。この処理を図 2 のデータに適用した処理結果を図 3 と図 4 に示す。この結果から、移動平均については体動が発生することでトレンドの変化が生じ、移動分散については体動が発生することで値が一時的に増加することがわかる。このような特徴をもつデータから体動を検出する手法を以下に示す。

*5 <http://www.raspberrypi.org/>




図 3 体動発生時の移動平均の変化

図 4 体動発生時の移動分散の変化

3.1 概要

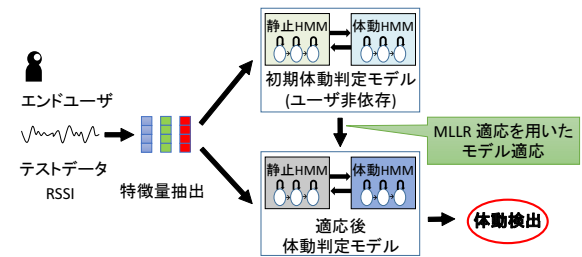


図 5 提案手法の概要

図 5 に提案手法の概要を示す。あるエンドユーザから得られた RSSI データの時系列に対して外れ値除去などの前処理を行った後、上述の移動平均と分散の計算を行い、これらの計算結果に対して上記のデータに見られたトレンド変化や一時的な値の増加を捉える特徴抽出を行う。その後、その時系列データを用いて、あらかじめ他のユーザの学習データから構築されたユーザ非依存な初期体動判定モデルを、そのエンドユーザに適用させる。最後に、そのユーザに適用したユーザに依存したモデルを用いて、そのユーザの時系列データを認識する。以降では、特徴抽出とユーザ非依存な HMM の学習、およびモデル適応に関して説明する。

3.2 特徴抽出

特徴抽出の概要を図 6 に示す。前処理としては、取得した RSSI データに対する外れ値の除去と電波状況が悪い場合に発生すると考えられる、サンプリングレートが極端に低くなっている部分に関するデータの処理を行う。具体的な処理方法としては、サンプリングレートが極端に低い場合は、データ数が一定数になるまで過去 10 秒間のデータからランダムに取り出し入力データとする。




図 6 特徴抽出の概要

また、本研究では移動平均と移動分散の時系列データから 100 サンプル幅、オーバーラップ 99% のスライディング

グ時間窓毎にそれぞれのデータ特徴に適した特徴抽出を行う。以降これらの特徴抽出について説明する。

3.2.1 移動平均のトレンド変化点の検出

移動平均時系列データにおける体動発生時のトレンド変化を反映した特徴抽出については以下の方法で行う。

BICセグメンテーション [11] とは、BICに基づく系列信号の分割点を発見する手法である。BICとは、モデル選択の基準であり、各モデル M_1, M_2, \dots, M_m に対して、データセット D_1, D_2, \dots, D_N が与えられたとき、モデル M_i のBIC値は以下のように定義される。

$$BIC(M_i) = \log P(D_1, D_2, \dots, D_N | M_i) - \frac{1}{2} \lambda \cdot d_i \log N$$

ここで、 d_i はモデル M_i の自由パラメータ数であり、 P はデータセットに対するモデル M_i の尤度である。このとき、BIC値が最大になるものを適切なモデルとして選択する。BICセグメンテーションでは、ある入力区間 (N サンプル) に対して、それを1つのモデル $M_0 = N(\mu_0, \Sigma_0)$ で表した場合のBIC値 $BIC(M_0)$ と、ある点 $j (1 < j < N)$ を境界とした2つのモデル $M_{12} = M_1, M_2 = N(\mu_1, \Sigma_1), N(\mu_2, \Sigma_2)$ で分割して表した場合のBIC値 $BIC(M_{12})$ を比較することで、分割点が存在するか否かを判定する。 X に分割点が存在し、その分割点が適切に定められた場合、 X の M_{12} に対する尤度が大きくなる。モデル化にはガウス分布を用いるのが一般的であり、本研究でもガウス分布を用いている。この場合、入力特徴量系列を $X = x_1, \dots, x_N$ とすると、それぞれ、 $M_0 : X = x_1, \dots, x_N \sim N(\mu_0, \Sigma_0), M_{12} : x_1, \dots, x_j \sim N(\mu_1, \Sigma_1); x_{j+1}, \dots, x_N \sim N(\mu_2, \Sigma_2)$ となる。このとき、 $BIC(M_{12})$ と $BIC(M_0)$ の差分 $\Delta BIC(j)$ は次式のようになる。

$$\begin{aligned} \Delta BIC(j) &= BIC(M_{12}) - BIC(M_0) \\ &= \frac{1}{2} (N \log |\Sigma_0| - j \log |\Sigma_1| - (N - j) \log |\Sigma_2|) \\ &\quad - \frac{1}{2} \lambda (d + \frac{1}{2} d(d + 1)) \log N \end{aligned}$$

すなわち、分割点が j である場合に X の M_{12} に対する尤度が大きくなるため、 $\delta BIC(j)$ の値が大きくなる。本研究では、この ΔBIC が最大になる分割点 k を求め、そのときの $\Delta BIC(k)$ を特徴量として用いる。

3.2.2 移動分散の一時的増加の検出

移動分散時系列データにおける体動発生時の値の一時的な増加を反映した特徴抽出については外れ値検出手法を基に行う。各時刻における時間窓内の移動分散時系列データについて、窓内の最初のサンプルにおける分散値の、それ以外の値から求めた正規分布に対する対数尤度を求める。ある時刻 t における移動分散を v_t とし、 t を窓内の最初のサンプルの時刻、窓内のサンプル数を N をとしたとき、 $v_{t+1}, v_{t+2}, \dots, v_{t+N-1}$ の平均 μ 、分散 σ^2 をパラメータとする正規分布 $\mathcal{N}(\mu, \sigma^2)$ を求め、 v_t のその正規分布に対す

る尤度 $p(v_t | \mu, \sigma^2)$ を計算する。

時刻 t において抽出された上記の2つの特徴と、時刻 t の移動平均、分散を用いて時刻 t の4次元の特徴ベクトルを構築する。

3.3 ユーザ非依存なモデルの学習

ユーザ非依存な初期体動判定モデルの学習方法の概要を図7に示す。体動時と静止時のそれぞれについて、複数の他のユーザから得た学習データを用いてHMMを構築する。連続値の特徴ベクトルを出力として扱うため、連続分布型HMMを用いる。連続分布型HMMは各状態における出力分布が混合ガウス分布(GMM: Gaussian mixture model)で表現されている。本研究では、HMMの状態数は6、GMMの混合数は4とした。モデルパラメータはExpectation Maximization (EM) アルゴリズムを基にしたBaum-Welch アルゴリズム [12] によって推定する。

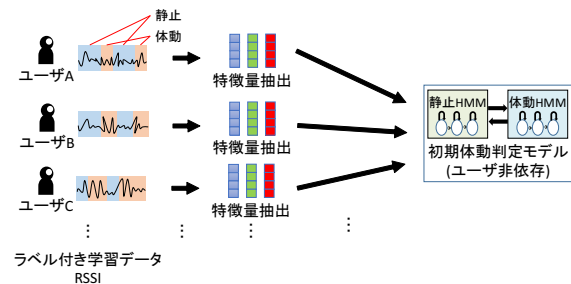


図7 ユーザ非依存なモデルの学習方法の概要

3.4 モデル適応

一般的に行動認識などの分野において、ユーザ自身が学習データを用意し、それを基に構築されたユーザに依存したモデルと、複数の他のユーザの学習データを基に構築されたユーザに非依存なモデルについて認識精度を比較した場合、ユーザに依存したモデルの精度がユーザに非依存なモデルの精度を大きく上回ることがわかっている。しかし、ユーザに依存したモデルを作成するためには、ユーザ自身が学習データを用意する必要がある。そこで本研究では、モデル適応と呼ばれる手法を用いて、モデルをユーザ毎に適応させることでエンドユーザが学習データを用意する必要がなく、また高い精度での認識が行えるようなモデルの構築を行う。本研究では、モデル適応手法として、回帰木を用いたMLLR適応 [3] を用いる。以降、まずMLLR適応について説明した後、回帰木を用いたMLLR適応について説明する。

3.4.1 MLLR 適応

MLLR 適応は連続分布型HMMの各状態における出力分布であるGMMに対して、適応データの尤度を最大にする平均ベクトルを推定するような変換行列 W を求め、初

期のモデルセットと適応データの間には存在する差異を減少させるように変換する手法である。変換行列を用いると、平均ベクトルの推定値 $\hat{\mu}$ は次式で与えられる。

$$\hat{\mu} = W\xi$$

ここで、 W は $n \times (n+1)$ の行列であり、 n はデータの次元数である。また、 ξ は拡張平均ベクトルであり、次式で与えられる。

$$\xi = [w \ \mu_1 \ \mu_2 \ \cdots \ \mu_n]^T$$

w はバイアスオフセット値を表し、通常 1 を用いる。変換行列 W は EM アルゴリズムを用いて計算する。

3.4.2 回帰木を用いた MLLR 適応

MLLR 適応は 3.4.1 で述べたように連続分布型 HMM の各状態における出力分布である GMM に対して、テストデータに応じて平均パラメータを適切にフィッティングする手法である。しかし、MLLR 適応を用いた場合に、初期のユーザ非依存なモデルを用いた認識結果には誤りが存在する可能性がある。また MLLR 適応は、状態毎に対して適応を行うため、ある状態に認識されたテストデータの量が少ない場合、過学習 [13] の問題が生じてしまう。通常の MLLR 適応は、これらの要因によって認識精度が低下する恐れがある。

そこで本研究では、テストデータの量に応じてより柔軟なモデル適応を行うために、音声認識に関する分野で使われている回帰木を用いた MLLR 適応を用いる [14]。この手法では、テストデータの量に応じて MLLR 適応で用いる変換行列の数を自動で決定する。回帰木の例を図 8 に示す。




図 8 回帰木の例

図 8 では、根ノード G_1 に HMM における全ての状態の GMM が含まれている。ユークリッド距離を用いた分割手法により、 G_1 に含まれる GMM を G_1 の子ノード G_2 と G_3 の 2 つのグループに分割する。以下これを全ての GMM が分割されるまで繰り返す。これによって、似た GMM は回帰木の中で同じ祖先を持つようになる。例えば、 G_2 を祖先として持つ G_5 、 G_8 、 G_9 に含まれる GMM は、類似していると考えられる。このように、異なった HMM の状態に属している似た GMM を結び付けておくことによって、認識の誤りが存在する場合においても HMM の状態には無関係な GMM の結び付きによって、認識の誤りに対して頑

健な適応を行うことができる。例えば、いくつかの特徴ベクトルについて G_8 の状態に属するべきであるにもかかわらず、 G_9 と誤って認識されていた場合、これらの共通の祖先である G_4 に焦点を当て、 G_8 と G_9 をまとめた G_4 について変換行列を求めることによって、認識の誤りの影響を軽減することができると考えられる。

また回帰木を用いることによって、テストデータの量に応じた柔軟な変換が行える。例えば、少量のテストデータしか得られなかった場合、根ノード G_1 について実行されるグローバルな変換を行う。しかしそうでない場合には、より下のノードに対して個別の変換を行う。つまり、テストデータの量に応じて変換を行うノードを変更することができる。ある葉ノードに存在する GMM に属するテストデータが少ない場合、例えば、図 8 において、 G_6 に存在する GMM に属するテストデータが少ない場合、 G_6 と G_7 に含まれる GMM に対して、親ノードに遡り、 G_3 に対して変換行列を求めて MLLR 適応を行う。これによって、過学習の問題を軽減することができると考えられる。

テストデータの認識時には、Viterbi アルゴリズムを用いることで、観測された事象系列を結果として生じる最も尤度の高い状態遷移 (体動と静止) を求める [15]。

4. 評価実験

4.1 データセット

本実験では、図 1 に示すような条件で意図的に 5 回体動を行った 5 分間のデータを 1 セッションとするデータを収集した。3 名からそれぞれ 10 セッションずつ取得し、合計 30 セッションのデータを取得した。

4.2 評価方法

評価方法としては、まず Leave-One-Session out 交差検定を用いて、特徴量抽出の有効性を評価する。Leave-One-Session out 交差検定とはユーザ毎に 1 つテストデータを定め、それ以外をトレーニングデータとする手法である。次に、Leave-One-User out 交差検定を用いて、MLLR 適応の有効性を評価する。Leave-One-User out 交差検定とは 1 人のユーザのデータをテストデータ、それ以外のユーザのデータをトレーニングデータとする手法である。また、評価は適合率 (precision)、再現率 (recall) と呼ばれる 2 つの指標とそれらから計算される F 値 (F-measure) を用いて行った。F 値とは、正確性を表す適合率と、網羅性を表す再現率の調和平均であり、

$$F\text{-measure} = \frac{2 \cdot \text{precision} \cdot \text{recall}}{\text{precision} + \text{recall}}$$

によって求められる。提案手法ではそれぞれの時間窓毎に静止または体動と分類するため時間窓毎の分類結果からこれらの指標を算出する。また比較手法として、移動平均と移動分散のみを用いて HMM により学習、認識を行う単純

な手法を用意した。

4.3 結果

4.3.1 Leave-One-Session out 交差検定

提案手法と比較手法として用いた単純な手法の結果を表1に示す。提案手法は適合率、再現率、F値全てにおいて比較手法を大きく上回った。比較手法はF値が0.6程度しかなく、体動による小さなセンサデータの変化をうまく捉えられていないことが分かる。一方、提案手法では約0.85のF値を達成しており、提案手法の特徴抽出の有効性を確認できた。

表1 Leave-One-Session out 交差検定の結果

	適合率	再現率	F値
単純な手法	59.2%	60.7%	0.597
提案手法	81.3%	89.2%	0.843

4.3.2 Leave-One-User out 交差検定

提案手法とMLLR適応を行わない手法(MLLR適応なし)の結果を表2に示す。ただし、ある参加者のあるセッションを評価するとき、それ以外のセッションを適応データとして用いた。提案手法は適合率、再現率、F値全てにおいてMLLR適応を行わない手法を上回った。MLLR適応を行うことで、0.8以上の高いF値を達成していた。また、単純な手法の結果も表2に示しているが、F値が非常に低かった。

表2 Leave-One-User out 交差検定の結果

	適合率	再現率	F値
単純な手法	55.3%	57.1%	0.553
提案手法	79.0%	87.3%	0.819
MLLR適応なし	76.9%	84.5%	0.795

また、被験者(ユーザ)毎のF値を表3に示す。ただし、“ユーザ依存”はユーザ自身のラベル付けされたデータを学習に用いた場合の結果を、“ユーザ非依存”は他のユーザのラベル付けされたデータを学習に用いた場合の結果を示す。MLLR適応を行うことにより、ユーザ自身のラベル付けされたデータを用いた場合とほぼ同等の精度を達成していることが分かる。また、全てのユーザにおいて高い認識精度を達成していた。

表3 各参加者の認識精度(F値)

	ユーザ非依存 MLLR適応なし	提案手法 (ユーザ非依存)	ユーザ依存
A	0.875	0.877	0.880
B	0.701	0.747	0.789
C	0.788	0.810	0.836

4.3.3 実際の睡眠時における体動検出

実際の睡眠時に得られたデータに対して提案手法を適用し、その性能を検証する。ある1名の被験者から取得した1晩の5.5時間のデータをテストデータとして用いた。データを取得する際、Microsoft Kinectによる赤外線映像も同時に撮影し、提案手法の性能評価に用いる。また被験者はリストバンド型加速度センサであるJawbone UP24も装着し、それによる結果と提案手法の結果を比較する。評価方法としては、本手法によって体動と認識された部分のうち、一回の体動が T_{th} 秒以上であるとされた体動について、赤外線映像と比較することによって目視で適合率の計算を行った。再現率については、5.5時間の映像を全て目視で正解データを作るのが困難であるため評価していないが、前述の実験結果では再現率が適合率より約10%高くなっている。




図9 Jawboneによる睡眠モニタリング結果と本手法による体動検出の結果

図9は、Jawbone UP24により検出された浅い睡眠、深い睡眠の時間帯および、提案手法によって検出された体動を示している。この結果から、浅い睡眠の時間帯において、体動が多く検出されていることが分かる。またKinectの赤外線映像との比較の結果、 T_{th} が10秒のときの適合率は63.5%であった。前の実験に比べて低い値となったが、図9から、体動の誤検知の多くは短い体動時間と認識された体動にあることがわかる。ここで、 T_{th} を変化させた場合における、適合率と、正解データ数の変化を図10と表4に示す。




図10 閾値の変化による適合率の変化

図10と表4の結果、 T_{th} を適切に調節することによって、より精度の高い体動検出が可能であると考えられる。

表 4 閾値の変化による体動検出数と正解数の変化

T_{th}	体動検出数	正解数	適合率 (%)
10	52	33	63.5
11	42	33	78.6
12	39	32	82.1
13	34	30	88.2
14	27	25	92.6
15	26	24	92.3

4.4 デバイス設置位置に関する検証

計測の際に配置するデバイスの位置の検証を行った。本実験では、ベッドサイドの棚に Wi-Fi モジュール搭載端末を置くことを想定したデータの取得を行った。一方で、日本を含む多くのアジア圏の国々では、床に布団を置いて就寝することがあるため、様々な場所に端末が置かれる可能性がある。そこで、端末を下半身の横に設置してデータを取得した。そのデータから計算された移動平均と移動分散の時系列データを図 11 と図 12 に示す。図 11 と図 12 から、デバイスの設置場所を変更しても、移動平均と移動分散に変化がみられることがわかった。




図 11 体動発生時の移動平均の変化




図 12 体動発生時の移動分散の変化

5. おわりに

本研究では身近な Wi-Fi 機能を備えたデバイスにより電波の変化を測定することで、無拘束に睡眠時の体動を検出する手法を提案した。提案手法では、まず学習段階として他の複数のユーザから得たラベル付き学習データを用いてユーザに非依存な体動検知モデルを隠れマルコフモデルによって構築する。認識段階ではこのユーザに非依存なモデルに対しエンドユーザ毎に MLLR 適応を行うことでモデルをユーザに適応させ、エンドユーザに応じたモデルを用いた体動の検知を行う。このような認識方法を用いることによって、エンドユーザが学習データを用意する必要がないようなモデルの構築を行った。

評価実験では、提案手法が約 80% の高い精度で体動の検知を行えることを確認し、またユーザに依存したモデルと遜色ない精度で体動の検知が行えることを確認した。また実際の睡眠時における体動の検知も行えることを確認し、デバイス設置位置をある程度変えた場合にも電波に同様の変化がみられることを確認した。

今後の課題として、精度を高めていくために特徴量の工夫とさらなるデータ収集を行う予定である。

参考文献

- [1] 野田明子, 古池保雄, “終夜睡眠ポリグラフィ (< 解説特集> 睡眠の生体計測技術),” 生体医工学: 日本エム・イー学会誌, vol.46, no.2, pp.134–143, 2008.
- [2] J. Wilde-Frenz, and H. Schulz, “Rate and distribution of body movements during sleep in humans,” *Perceptual and motor skills*, vol.56, no.1, pp.275–283, 1983.
- [3] C.J. Leggetter, and P.C. Woodland, “Maximum likelihood linear regression for speaker adaptation of continuous density hidden markov models,” *Computer Speech & Language*, vol.9, no.2, pp.171–185, 1995.
- [4] T. Watanabe, and K. Watanabe, “Estimation of the sleep stages by the non-restrictive air mattress sensor (japanese title: 無拘束エアマットレス型生体センサーによる睡眠段階の推定),” *Transactions of the Society of Instrument and Control Engineers*, vol.37, pp.821–828, 2001.
- [5] Z. Chen, M. Lin, F. Chen, N.D. Lane, G. Cardone, R. Wang, T. Li, Y. Chen, T. Choudhury, and A.T. Campbell, “Unobtrusive sleep monitoring using smartphones,” *International Conference on Pervasive Computing Technologies for Healthcare (PervasiveHealth 2013)*, pp.145–152, 2013.
- [6] J.K. Min, A. Doryab, J. Wiese, S. Amini, J. Zimmerman, and J.I. Hong, “Toss’n’turn: smartphone as sleep and sleep quality detector,” *Proceedings of the 32nd annual ACM conference on Human factors in computing systems*, pp.477–486, 2014.
- [7] S. Shi, S. Sigg, and Y. Ji, “Activity recognition from radio frequency data: Multi-stage recognition and features,” *Vehicular Technology Conference (VTC Fall)*, 2012, pp.1–6, 2012.
- [8] S. Shi, S. Sigg, and Y. Ji, “Passive detection of situations from ambient fm-radio signals,” *Proceedings of the 2012 ACM Conference on Ubiquitous Computing*, pp.1049–1053, 2012.
- [9] M. Scholz, T. Riedel, M. Hock, and M. Beigl, “Device-free and device-bound activity recognition using radio signal strength,” *Proceedings of the 4th Augmented Human International Conference*, pp.100–107, 2013.
- [10] S. Sigg, U. Blanke, and G. Troster, “The telepathic phone: Frictionless activity recognition from wifi-rssi,” *PerCom 2014*, pp.148–155, 2014.
- [11] 河原達也, 須見康平, 緒方淳, 後藤真孝, “音声会話コンテンツにおける聴衆の反応に基づく音響イベントとホットスポットの検出,” *情報処理学会論文誌*, vol.52, no.12, pp.3363–3373, 2011.
- [12] L.R. Welch, “Hidden markov models and the baum-welch algorithm,” *IEEE Information Theory Society Newsletter*, vol.53, no.4, pp.10–13, 2003.
- [13] D.M. Hawkins, “The problem of overfitting,” *Journal of chemical information and computer sciences*, vol.44, no.1, pp.1–12, 2004.
- [14] T. Maekawa, and S. Watanabe, “Unsupervised activity recognition with user’s physical characteristics data,” *International Symposium on Wearable Computers (ISWC2011)*, pp.89–96, 2011.
- [15] L. Rabiner, “A tutorial on hidden Markov models and selected applications in speech recognition,” *Proceedings of the IEEE*, vol.77, no.2, pp.257–286, 1989.