

マイクロ波を用いた遠隔・非接触な体動計測に基づく睡眠深度推定

Sleep Stage Estimation based on the Non-contact Remote Measure of Body Movements using Microwave Radio

山本 康平*¹ 橋 素子*¹ 前野 蔵人*¹ 北川 正嗣*² 岡田 志麻*²
 Kohei Yamamoto Motoko Tachibana Kurato Maeno Kitagawa Masashi Shima Okada

*¹沖電気工業株式会社
 Oki Electric Industry Co., Ltd.

*²近畿大学理工学部
 Department of Mechanical Engineering, Kindai University

Recently, not a few sleep stage estimation methods using wearable accelerators are proposed. However, these methods are necessary users to care such as daily attaching/detaching consciously. In this paper, we propose the new estimation method, using the machine learning technique, by measuring precious fractions of respiration movements remotely. We achieved around 85% on average to estimate sleep stages correctly.

1. はじめに

近年、超高齢化社会の到来による健康維持管理の重要性の拡大に伴い、睡眠の質に着目した健康状態のモニタリング技術が多数提案されている [高村 06, 大内 07]. ウェアラブルセンサを用いたものが多いが、これらは簡便に測定できる反面、日々の着脱の手間が課題となる。それは利用の継続性の面から、改善が望まれる。本稿では、マイクロ波を用いた非接触な体動計測により、この課題を解決する手法を提案する。

マイクロ波を人体に照射すると、その反射波にドップラー効果による呼吸の動きの影響が見られる [Li 13]. 呼吸は、体幹全体の大きな動きを伴うため、広い指向性を持つアンテナを使用しても、数メートルから十数メートルの範囲で十分な反応を得られる。また、呼吸の動きは睡眠深度と関係し、深度の変化に伴う自律神経活性度の変化が、呼吸の動きの安定性に影響する [岡田 07]. 本稿では、この特性に着目し、室内空間で人の場所を限定せずに睡眠深度を推定する手法を提案する。

マイクロ波による計測では、波長と検知対象の動きの大きさとの関係性や、ノイズの影響による問題があり、呼吸の動きに対しては、これらを十分に考慮する必要がある。2章では、従来手法の問題点を明らかにし、3章で、この問題を解決する呼吸動作の抽出と、それに基づく睡眠深度推定方式を説明する。4章は、提案方式の評価結果を示し、5章で本論文を総括する。

2. 従来手法

マイクロ波を用いたセンサ信号モデルは、以下の複素信号 $B(t)$ で表現することができる [Li 13].

$$B(t) = a(t)e^{j\left[-\frac{4\pi}{\lambda}(x(t)+d_0)+\phi_0\right]} + O + \varepsilon. \quad (1)$$

$a(t)$ は検知対象とセンサの距離関係や反射断面積等に依存する振幅項、 λ は照射するマイクロ波の波長、 $x(t)$ は検知対象の変位量、 d_0 は初距離、 ϕ_0 は初期位相、 O はクラッタによる直流成分項、 ε はノイズ項である。上記モデルの通り、 $B(t)$ は検知対象の変位 $x(t)$ に依存して複素平面上を回転する軌跡を描く信号となる。よって、複素信号 $B(t)$ の回転角を求めることで、検知対象の変位量を得ることができる。しかし、回転の

中心は直流成分 O に依存しているため、まずこれを除去し回転の中心を推定する必要がある。回転中心の推定に関しては従来研究があり、データを3分割して複数の方程式から円の中心を推定する方法や、最小二乗法による円の当てはめにより、中心を推定する方法がある [Zakrzewski 12]. しかし、これらの方法は検知対象の変位変化量が小さい場合では、中心の推定が難しい。また、本稿ではハードウェアの簡素化のためにセンサ出力信号にハイパスフィルタを適用する。この場合、検知対象の変位変化量の大小により、複素平面上の信号軌跡の形状が大きく変化する。信号軌跡の形状によっては、前記の従来手法で回転の中心を推定することは、ほぼ困難となる。一方で、軌跡の形状は変化するが、ビート信号の周波数の大きさが振幅の大きさに変換されるので、周期性の抽出は可能である。次章以降で述べる周期信号の抽出では、この信号軌跡の形状が重要となる。本稿と同様にハイパスフィルタを適用する従来研究として、[Yamamoto 13] の提案するモデルベースの手法がある。この手法では、呼吸の変位を表現した周期関数モデルをビート信号に対して当てはめることで、呼吸周期等のモデルパラメータを求めている。しかし、このモデルは、呼気と吸気動作それぞれに要する時間が等しいことを仮定しており、この仮定を満たさない呼吸に対して、精度が劣化する問題がある。また、フーリエ変換等の周波数分析法を用いて、センサ出力から直接的に呼吸の周期を求める方法がある [Li 13]. しかし、これらの手法は、入力信号を平均的に捉える性質を持ち、呼吸1回毎の周期及び振幅の変化を検出することができない。呼吸の動きの安定性は、呼吸1回毎の変化で評価する必要があり、この性質は問題となる。

3. 提案手法

3.1 射影変換による周期信号抽出

変位変化量が小さい場合のビート信号に対しては、複素平面上において特定方向に信号を射影することで、周期信号の抽出が可能である。そのような場合の信号は、複素平面上で図1(a)に実線で示す直線形状の軌跡を描く。この軌跡を分布として捉えると、ビート信号を分散が最大となる方向へ射影することで、呼吸の周期性を保持した信号が得られる。ここで、射影変換で得られる信号を射影信号 $s_p(t)$ とすると、 $s_p(t)$ は以下のように表現できる。

$$s_p(t) = \mathbf{p}^\top(t)\mathbf{b}(t). \quad (2)$$

連絡先: 山本 康平, 沖電気工業株式会社,

埼玉県蕨市中央1丁目16番8号 OKI システムセンター,
 yamamoto833@oki.com

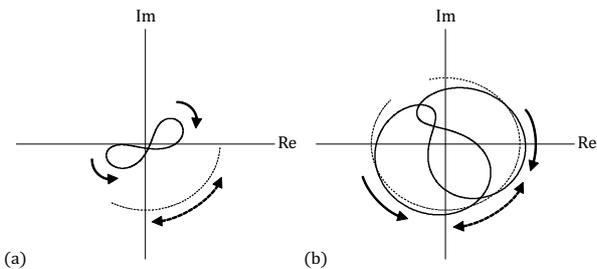


図 1: 変位変化量とビート信号の軌跡の関係 (a) 変位変化量が小さい場合のビート信号の軌跡 (実線). (b) 変位変化量大きい場合のビート信号の軌跡 (実線). 各破線は直流成分とノイズを含まない複素信号 $B(t)$ であり, 各矢印は回転の方向を示す.

ここで, $\mathbf{b}(t)$ は実部と虚部を 2 次元ベクトル表現としたビート信号, $\mathbf{p}(t)$ はビート信号の共分散行列に対する最大固有値に対応した固有ベクトルである.

一方で, 変位変化量大きい場合を含むビート信号は, 図 1(b) に実線で示す軌跡を描く. この場合, 軌跡が円形状となり, 分散が最大となる方向が意味を持たず, 射影信号に倍周期成分が含まれることになる. 倍周期成分は, 円弧上を半回転以上する軌跡の射影であり, 呼吸周期推定の障害となる. よって, 射影変換による周期信号抽出は, 変位変化量が小さい場合に適している.

3.2 回転角に基づく周期信号抽出

変位変化量大きい場合のビート信号に対しては, 回転中心からの角度 $\theta(t)$ の時間微分である角度変化量 $\theta'(t)$ に基づく信号抽出方法が有効である. そこで本稿では角度変化量に基づいた信号として, 以下の角速度信号 $s_a(t)$ を採用する.

$$s_a(t) = A(t)\theta'(t). \quad (3)$$

角速度信号 $s_a(t)$ は, ビート信号の振幅量 $A(t)$ と角度変化量との積算から求められる. 角度変化量に振幅量を積算する理由は, ハイパスフィルタの影響によりビート信号が原点に漸近した際に, 角度変化量が検知対象の動きに関係なく増大する現象を抑えるためである. 角速度信号は, 図 1(b) に実線で示すビート信号に対しては, 軌跡が円弧状であり, 角度変化量が安定的に求まるため, 射影信号と同様に, 呼吸の周期性を保持した信号を得ることができる. 一方で, 角速度信号は変位変化量が小さい場合のビート信号に対する周期信号抽出には適さない. これは, ビート信号の軌跡が直線形状に近くなることで, 角度変化量が安定的に得られないためである. 直線形状の状態ではノイズが重畳すると, 角度変化量の正負が不定となり, 角速度信号は呼吸周期を正しく表現できない. よって, 回転角に基づく周期信号抽出は, 射影変換による周期信号抽出とは逆に, 変位変化量大きい場合に適している.

3.3 周期信号の統合

前節から, 射影信号と角速度信号の間には, 検知対象の変位変化量に関するトレードオフの関係が存在する. 本稿では, 各信号を, 尤もらしさの評価に基づいて適応的に統合する. 具体的には, まず統合対象の信号に対して統合の基準となる特徴量を求め, 確率的識別モデルに入力し, 確率信号を得る. 次に, 統合の前処理として信号に位相補正を行う. 最後に, 確率信号を重みとして信号の荷重和を計算し, 周期信号の統合を行う.

3.3.1 特徴量と学習

統合の基準として, 2 種の特徴量を用いる. 1 つ目は, 各信号の瞬時周波数比 $x_1(t)$ であり, 以下で表現できる.

$$x_1(t) = \frac{1 + f_p(t)}{1 + f_a(t)}. \quad (4)$$

$f_p(t)$ は射影信号をヒルベルト変換し, 解析信号から求められる瞬時周波数であり, $f_a(t)$ は同様に得られる角速度信号の瞬時周波数である. この特徴量は, 射影信号と角速度信号の周波数が近い場合には 1.0 付近の値を取り, 射影信号に倍周期成分が含まれる場合には 1.0 より増加する性質を持つ.

2 つ目は, 角度変化量偏差 $x_2(t)$ であり, 以下で表現できる.

$$x_2(t) = \int_{t-L}^t (\theta'(u) - \mathbb{E}[\theta'(u)])^2 du. \quad (5)$$

ただし, L は任意の遅延時間, $\mathbb{E}[\cdot]$ は期待値である. この特徴量は, 検知対象の変位変化量によって角度変化量が異なる性質を狙ったものである. 以上 2 種の特徴量は検知対象とセンサとの距離関係の影響を受けない特徴量となる. 次に, これらの特徴量を用いて確率的識別モデルを学習する. 本稿では, 以下の尤度で与えられるロジスティック回帰によるモデル構築を行う.

$$p(\mathbf{y}|\mathbf{w}) = \prod_{n=1}^N \sigma(\mathbf{w}^\top \mathbf{x}_n)^{y_n} [1 - \sigma(\mathbf{w}^\top \mathbf{x}_n)]^{1-y_n}. \quad (6)$$

$\mathbf{y} = [y_1, y_2, \dots, y_N]^\top \in \{0, 1\}$ を教師データ, $\mathbf{w} = [w_0, w_1, w_2]^\top$ を学習パラメータ, $\sigma(\cdot)$ をシグモイド関数, $\mathbf{x}_n = [1, x_1(n), x_2(n)]^\top$ を特徴量とする.

3.3.2 位相補正と統合

学習したモデルの出力である確率信号を用いて, 荷重和による信号統合を行う前に, 各信号に対して位相補正を行う必要がある. 位相補正では, まず各信号を解析信号化した上で, 以下のように位相差情報を含む複素信号 $m(t)$ を抽出する.

$$m(t) = e^{j(\omega_a t + \phi_a)} e^{-j(\omega_p t + \phi_p)} = e^{j(\Delta\omega t + \Delta\phi)}. \quad (7)$$

ω_a, ϕ_a は角速度信号の周波数と位相を表現し, ω_p, ϕ_p は射影信号の周波数と位相を表現している. 各信号の周波数が十分に近い場合には, $\Delta\omega \approx 0$ と近似できる. この時, $m(t)$ は位相差の情報のみを持つので, 角速度信号に対して複素共役積を計算すると, 位相補正された角速度信号 $s_m(t)$ が得られる.

$$s_m(t) = \text{Re} \left[e^{j(\omega_a t + \phi_a)} e^{-j\Delta\phi} \right] = \text{Re} \left[e^{j(\omega_a t + \phi_p)} \right]. \quad (8)$$

$\text{Re}[\cdot]$ は複素信号の実部の抽出を示す. 次に, 統合信号 $g(t)$ を以下のように定義する.

$$g(t) = \sigma(\mathbf{w}^\top \mathbf{x}_t) s_p(t) + [1 - \sigma(\mathbf{w}^\top \mathbf{x}_t)] s_m(t). \quad (9)$$

統合信号は確率信号を重みとする射影信号と, 位相補正された角速度信号の荷重和で表現されている. また, 実際に式 (9) を計算する場合には, $s_p(t)$ と $s_m(t)$ の振幅量が異なるので, 各信号に対して正規化処理を行う必要がある. 以上の特徴量が統合対象の信号に対する優位性条件として機能し, 学習した確率的識別モデルが良い分離性能を有しているならば, 統合信号は検知対象の変位変化量に依存し難い周期信号となる.

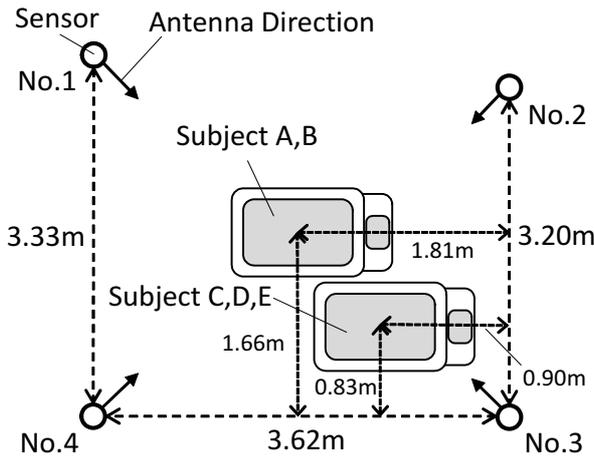


図 2: センサ配置図

3.4 統合信号に対する周期・振幅推定

前節の統合信号に対して、相互相関分析に基づいた呼吸の周期推定を行う。この方法では、1時刻前の推定周期から計算されるラグ量の範囲で、余弦波との相互相関係数を計算する。相互相関係数が最大となる時刻を求めると、呼吸1回毎に時刻に関する分布が得られ、その分布のモードと前回の呼吸のモードとの時間間隔を呼吸周期の推定量とする。また、モードとなる時刻の射影信号の振幅量を、呼吸振幅の推定量とする。呼吸振幅は、呼気と吸気発生時の動きの大きさの指標となる。

3.5 睡眠深度推定

睡眠深度として、覚醒、レム睡眠、ノンレム睡眠の3状態を判別する。推定に使用する特徴量は、呼吸周期と呼吸振幅に加えて、寝返り等の大きな体動成分が存在する周波数帯域を抽出したビート信号の振幅量 $A(t)$ の3種から計算する。また本稿は、国際的な睡眠深度判定基準である R&K 法 [Rechtschaffen 68] に則り、エポックと呼ばれる30秒区間毎に推定を行う。まず、呼吸周期は、30秒区間で平均を取り、エポック単位の特徴量とする。エポック間差分の2乗を計算し、過去10エポックで平均したものを特徴量 v_1 とする。この特徴量は、エポック単位での呼吸周期の変動の大きさを表現している。呼吸振幅は、標本分散を標本平均で除した値である変動係数を30秒区間で計算し、エポック単位の特徴量とする。呼吸周期の場合と同様に、過去10エポックで平均したものを特徴量 v_2 とする。この特徴量は、エポック単位での呼吸振幅のばらつきの変化度を表現している。振幅量に関する特徴量は、1秒間隔で差分量を計算し、それを30秒区間で平均を取ることで、エポック単位の特徴量 v_3 と定義する。

本稿では、以上3つの特徴量を用いた睡眠深度推定法を以下の線形方程式で定義する。

$$\mathbf{h} = M\mathbf{v}. \quad (10)$$

ただし、 $\mathbf{h} = [h_1, h_2, h_3, h_4]^T$ を判別ベクトル、 $\mathbf{v} = [1, v_1, v_2, v_3]^T$ を特徴ベクトル、

$$M = \begin{pmatrix} -2.10 & 0 & 11.27 & 3.04 \\ 6.29 & 0 & 20.0 & 9.81 \\ -0.92 & 10.27 & 0 & 3.00 \\ -1.01 & 26.13 & 0 & 1.79 \end{pmatrix}$$

を判別行列とする。式(10)による睡眠深度推定では、以下の判別順序ルールを用いて2段階で睡眠クラスを決定する。

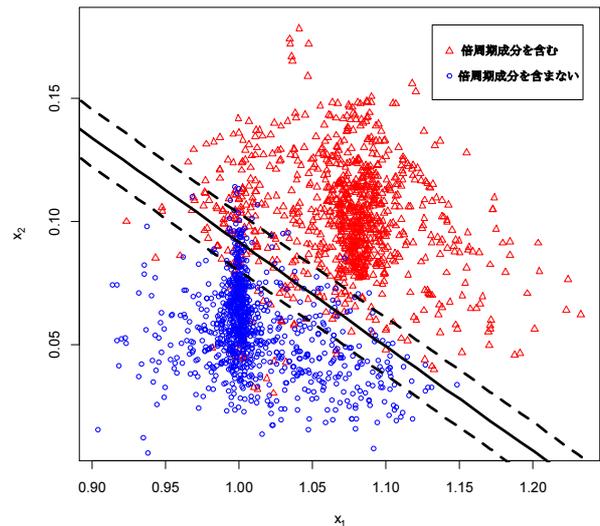


図 3: 統合に利用する特徴分布と学習モデルによる識別境界

1. 覚醒/睡眠判定

$h_1 > h_2$ を満たす場合は覚醒と判定する。条件を満たさない場合は睡眠状態として2へ

2. レム睡眠/ノンレム睡眠判定

$h_3 > h_4$ を満たす場合はレム睡眠と判定し、条件を満たさない場合はノンレム睡眠と判定する。

以上の手続きにより、睡眠深度が推定される。

4. 評価実験

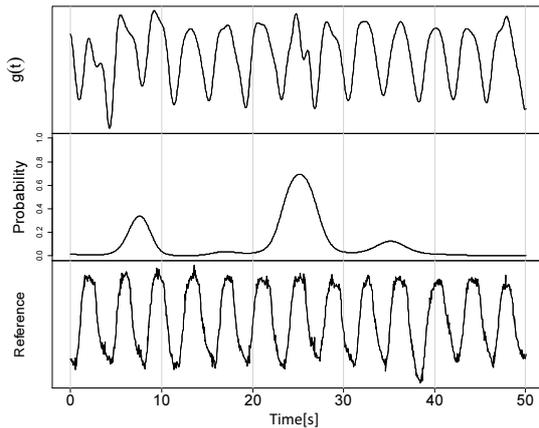
4.1 評価方法

健康成人男性及び女性の計5名の被験者(A~E)に対し、評価実験を実施した。1名の被験者に対して4台のセンサ(No.1~4)で同時計測を行い、各センサの出力毎に提案手法を適用した。また、室内の多様な位置関係を評価するために、被験者の位置を2パターン、センサの配置を4箇所とした(図2)。ただし、センサは天井付近に設置されており、各センサ(No.1~4)の高さはそれぞれ2.20, 2.24, 2.21, 2.20[m]とした。この時、センサと全被験者との直線距離は2.6~4.3[m]の範囲となる。睡眠深度の精度確認のために、一般的な睡眠検査法であるPSG(Polysomnography)法による計測を同時実施した。PSG法による計測では、被験者は脳波、眼球運動、頰筋筋電図、心電図、呼吸や心拍等を計測可能なセンサ類を装着した状態で睡眠を実施する。本実験では、PSG法の計測結果からR&Kに基づく睡眠深度の判定を計3名に依頼し、内2名で判定した睡眠深度に関して、結果が一致しない箇所に対してはもう1名の意見を採用し、誤判定の確率を下げ、睡眠深度の正解値となるデータを生成した。

4.2 結果

4.2.1 周期信号の統合結果

信号統合に用いられる特徴分布の例(50秒間分)と、学習したモデルの識別境界を図3に示す。図3は、横軸が瞬時周波数比 $x_1(t)$ を、縦軸が角度変化量偏差 $x_2(t)$ を示す。赤三角形は、射影信号が倍周期成分を含む特徴分布であり、青円は倍周期成分を含まない特徴分布である。図3における実線は、確率的識別モデルの出力確率が0.5(識別境界)、破線がそれぞれ0.25または0.75の場合を表現している。各特徴分布の識別境界を見ると、倍周期成分の発生有無の判定が可能であることが

図 4: 倍周期成分発生時の統合信号 $g(t)$ の出力例

示唆される。角度変化量偏差が 0.05 以下の場合には、倍周期成分を含まない信号の瞬時周波数比は、広く分布していることが読み取れる。この理由は、検知対象の変位変化量が小さくなると、角度変化量がノイズの重畳により正負不定となることから、角速度信号の周期性が異常な値となったと考えられる。図 4 に、射影信号が倍周期成分を含む場合の統合信号 $g(t)$ 、確率信号、参照信号の腹部バンドセンサの出力 (50 秒間分) の例を示す。確率信号は 0.0 に近いほど角速度信号を重視し、1.0 に近いほど射影信号を重視する。図 4 では主に角速度信号が重視されていることがわかり、参照信号とのピーク位置の類似が確認できる。

4.2.2 睡眠深度推定精度

表 1 に各被験者 5 名 (A~E)、各センサ (No.1~4) に対して求められた PSG 判定結果に基づく精度を示す。2 段階の推定法のため、覚醒 (WAKE) と睡眠 (SLEEP) の判定、レム睡眠 (REM) とノンレム睡眠 (non-REM) の判定の 2 つの精度について求めている。太字は各判定における最高精度である。検知対象との直線距離が最も小さい場合と最も大きい場合 (被験者 C,D,E における No.1 と No.3) である 6 パターンの精度差に着目すると、その差は最大で 6.9% (レム睡眠/ノンレム睡眠判定における被験者 D) であった。この結果から、本手法は距離関係に対して頑健性を持つことが示唆される。評価全体の結果として、全被験者及び全センサデータを結合して精度を求めると、覚醒/睡眠判定の精度が 84.5%、レム睡眠/ノンレム睡眠判定の精度が 78.2% となった。

5. おわりに

本稿では、マイクロ波を用いて呼吸周期と呼吸振幅を推定し、さらに睡眠深度を推定する方法を提案した。呼吸周期と呼吸振幅の推定には、ビート信号から呼吸の周期性を保持した信号を生成する必要があった。しかし、ビート信号には検知対象の変位変化量に依存する問題があり、単一の方法では周期信号の生成が困難であった。この問題に対する対策として、トレードオフ関係のある 2 つの周期信号を機械学習を用いて適応的に統合し、単一の周期信号を生成した。睡眠深度は、呼吸周期と呼吸振幅、寝返り等の大きな体動情報の 3 種から求められる特徴量を利用し、定義した判別ルールに基づいて推定された。評価実験は、5 名の被験者を対象とし、検知対象とセンサ間の直線距離が 2.6~4.3[m] の実験環境で実施された。その結果から、本稿の提案手法は、覚醒と睡眠の判定において 84.5%、レム睡眠とノンレム睡眠の判定において 78.2% の精度を有して

表 1: 睡眠深度推定結果

Decision Step	Subject	Accuracy[%]			
		No.1	No.2	No.3	No.4
WAKE/SLEEP	A	92.8	89.1	92.3	87.5
	B	88.5	77.6	84.3	87.5
	C	82.3	85.8	87.3	88.3
	D	82.9	78.2	84.8	82.2
	E	73.8	78.2	75.0	80.2
REM/non-REM	A	87.0	81.9	80.2	83.2
	B	76.4	83.0	85.6	73.6
	C	64.3	72.9	67.2	63.2
	D	85.7	92.6	92.6	93.5
	E	71.2	71.8	68.8	72.9

いると結論付けた。

今後の課題としては、周期信号を統合する方法の最適化である。本稿で用いたロジスティック回帰による線形分離は、特徴量分布の形状に対して最適でなく、非線形分離を行った方が精度が向上する可能性があり、さらなる検討が必要である。

参考文献

- [Li 13] Li, C. and Lin, J.: *Microwave Noncontact Motion Sensing and Analysis*, Wiley Series in Microwave and Optical Engineering (2013)
- [Rechtschaffen 68] Rechtschaffen, A. and Kales, A.: *A Manual of Standardized Terminology, Techniques and Scoring System for Sleep Stage of Human Subjects*, Washington Public Health Service U.S. Government Printing Office, Washington, D.C. (1968)
- [Yamamoto 13] Yamamoto, K., Maeno, K., and Kamakura, T.: Dynamic respiratory modeling for non-contact live monitoring by particle filter approach, in *Computational Intelligence and Informatics (CINTI), 2013 IEEE 14th International Symposium on*, pp. 25–30 (2013)
- [Zakrzewski 12] Zakrzewski, M., Raittinen, H., and Vanhala, J.: Comparison of Center Estimation Algorithms for Heart and Respiration Monitoring With Microwave Doppler Radar, *Sensors Journal, IEEE*, Vol. 12, No. 3, pp. 627–634 (2012)
- [岡田 07] 岡田 志麻, 藤原 義久, 安田 昌司, 牧川 方昭, 飯田 健夫: 呼吸波形を用いた徐波睡眠期の推定 (日本感性工学会研究論文集), 感性工学研究論文集, Vol. 7, No. 1, pp. 145–151 (2007)
- [高村 06] 高村 昇, 青柳 潔, 白水 重憲, 豊村 広平, 片山 宗哲, 山下 俊一: 姿勢・体動・皮膚温度測定による睡眠と生活行動モニタリング, *I Tヘルスケア誌*, Vol. 1, No. 1, pp. 14–23 (2006)
- [大内 07] 大内 一成, 鈴木 琢治, 森屋 彰久, 亀山 研一: ウェアラブル機器を用いたヘルスケアサービス (MBL-UBI 合同セッション 1), 情報処理学会研究報告. UBI, [ユビキタスコンピューティングシステム], Vol. 2007, No. 14, pp. 29–36 (2007)