

ミリ波レーダと機械学習を用いた睡眠時無呼吸の非接触検出技術

Noncontact Detection of Sleep Apnea Events Using Millimeter-Wave Radar and Machine Learning

阪本 卓也¹ 香田 隆斗¹ 奥村 成皓² 瀧 宏文² 濱田 哲³ 陳 和夫³
Takuya Sakamoto Takato Koda Shigeaki Okumura Hirofumi Taki Satoshi Hamada Kazuo Chin

京都大学 大学院工学研究科¹ 株式会社マリ² 京都大学 大学院医学研究科³
Grad. School of Engineering, Kyoto University MaRI Co., Ltd. Graduate School of Medicine, Kyoto University

1 はじめに

現在、国内には 300 万人以上の睡眠時無呼吸症候群の治療対象者がいるといわれ、高血圧症や狭心症などの合併症を発症するリスクを緩和するためには早期の診断および治療開始が重要である。現在、睡眠時無呼吸 (sleep apnea: SA) の検査には睡眠ポリグラフ検査 (polysomnography: PSG) が標準的な検査機器として広く使われている。PSG は多数のセンサを身体に装着して睡眠中の多種の生体信号を取得する装置であり、得られたデータをもとに SA に関する診断が行なわれる。しかし、多数のセンサを装着していることによる心理的な影響は無視できないため、センサを装着しない非接触の睡眠モニタリング技術の実現が期待されている。本稿では、ミリ波レーダによる非接触計測と機械学習アルゴリズムの併用による SA の自動検出法について、我々の取り組みを紹介する [1]–[3]。

2 ミリ波レーダによる被験者の計測実験

本研究では中心周波数 24.2 GHz、帯域幅 180.0 MHz のミリ波レーダを使用し、E/H 面ビーム幅 20 度のアンテナを送受信に用いた。京都大学医学部附属病院において検査入院中の患者 2 名を被験者として同レーダにより計測した。図 1 に示すとおり、レーダをベッド横の木製ラック上部に設置した。PSG では脳波・眼球運動・心電図・筋電図・呼吸・いびき・酸素飽和度などの生体信号の記録を行う。検査技師により SA 等のイベントが手動抽出される。抽出されたイベントのうち、無呼吸と低呼吸を区別せず、以下では単に SA と呼ぶ。

両被験者とも、午後 10 時 45 分までには入眠し、SA などによる中途覚醒を除けば翌朝午前 6 時頃まで就寝していた。被験者 A と B では SA の種類が異なり、被験者 A は閉塞性 SA を示し、被験者 B は中枢性・混合性 SA を示す。被験者 2 名の詳細を表 1 に示す。表に示す通り、SA の種別による呼吸努力の有無がレーダ計測に影響を与えることが予想される。

| | 被験者 A | 被験者 B |
|----------------|-------------|-----------------------|
| 無呼吸・低呼吸イベントの回数 | 閉塞性 206 | 中枢性 157, 混合性 71, 他 52 |
| 主な無呼吸の種類 | 閉塞性 (気道の閉塞) | 中枢性・混合性 (呼吸調節の異常) |
| 無呼吸イベント中の呼吸努力 | ある | 無い/無呼吸当初は無く、その後出現 |

表 1 各被験者の詳細

3 レーダ信号処理および機械学習による無呼吸検出法

レーダ受信信号を時間 t と距離 r の複素関数 $s'(t, r)$ と表す。まず、静止クラッタを除去するために平均信号を $s_0(r) = (1/T) \int_0^T s'(t, r) dt$ により求め、受信信号から $s(t, r) = s'(t, r) - s_0(r)$ と減算し、時間変動を伴う成分のみを抽出する。その後、被験者の顕著な運動を示す距離 r_0 を $r_0 = \arg \max_r \int_0^T |s(t, r)|^2 dt$ により求め、さらに短時間フーリエ変換

$$S(t, \omega) = \left| \int_{-\infty}^{\infty} w(\tau) s(\tau - t, r_0) e^{-j\omega\tau} d\tau \right|^2 \quad (1)$$

によりスペクトログラムを生成する。ただし、ここで $w(t)$ は窓関数であり、幅 20 秒の Hann 窓とする。

次に、このスペクトログラムから機械学習に用いる画像 I_n ($n = 1, \dots, N$) を生成する。ここで、各画像 I_n は $S(t, \omega)$ を最大値で正規化したうえで -20 dB から 0 dB の範囲を dB 値で画像にしたもののうち、角周波数 ω は $0 \leq \omega \leq \pi$ rad/s の範囲、時間 t は $S(t, \omega)$ の $(n-1)\tau_0 \leq t \leq (n-1)\tau_0 + T_0$ の範囲に対応する。ただし、 $\tau_0 = 5$ s, $T_0 = 60$ s とする。その結果、7 時間のデータから $N = 4116$ 枚の画像が生成される。ただし、5 分毎のデータセットのうち最後の 1 分間は画像生成に使用しない。60 秒間の画像のピクセル数を減らすために時間および角周波数方向に間引き、最後に 256 階調グレースケールで 20×30 ピクセルの JPEG 形式の画像として保存する。機械学習による識別性能を評価するため、 $k = 12$ とした k -分割交差検証を行う。すなわち、学習およびテストに、それぞれ 3773 枚および 343 枚の画像を用いる。ただし、 k 分割する際に、学習データとテストデータの間に関連が生じないように選ぶ。

本研究では機械学習アルゴリズムとしてサポートベクターマシン (support vector machine: SVM) および畳み込みニューラルネットワーク (convolutional neural network: CNN) を選び、2 クラス分類器として無呼吸イベントの自動検出を試みる。SVM および CNN はいずれも教師あり学習アルゴリズムであるが、学習データの正解ラベルには検査技師が手動で検出した無呼吸イベントを正解ラベルとして与える。ただし、各画像は 60 s に相当するスペクトログラムであるため、各画像の中央の時間 $t = (n-1)\tau_0 + T_0/2$ において SA あるいは低呼吸が認められる場合には 1、それ以外は 0 のラベルを与える。

SVM では 2 次の多項式カーネルを用い、 20×30 ピクセルの各画像を 600 次元のベクトルに並べなおし、入



図1 呼吸器内科の病室内に設置されたレーダ [2]. レーダは斜め上から被験者の使用するベッドを見下ろす角度で設置されている. この写真中の人物は実際の被験者ではない.

力する. SVM の最適化アルゴリズムとしては逐次最小問題最適化法を用いる. CNN では, 20×30 ピクセルの画像をそのまま入力データとし, 4 層の畳み込み層でのフィルタサイズはそれぞれ $5 \times 5 \times 20$, $3 \times 3 \times 30$, $3 \times 3 \times 30$, $3 \times 3 \times 30$ とし, Pool サイズ 2×2 の Max プーリング層を経て 1500×2 の全結合層に至る. 活性化関数には rectified linear unit (ReLU) を用い, エポック数およびバッチサイズはそれぞれ 100 および 128 とした. 最終的に Softmax 層を経て 2 値 (SA イベントの有無に対応) の出力を行う. 全結合層の各重みの最適化には慣性項付き確率的勾配降下法を用いる.

4 レーダおよび機械学習による無呼吸検出の性能評価

図 2 に被験者 A のレーダ計測から生成されたスペクトログラム画像の例を示す. 図中の左の画像は SA イベントが認められる場合, 右の画像は認められない場合に相当する. 同じく, 被験者 B についても同様の画像を図 3 に示す. これらの図より, 被験者 B については SA の有無によりスペクトログラムの特徴が大きく異なることがわかる. 各被験者のデータを SVM および CNN で学習し, SA の検出性能を評価した. 結果を表 2 に示す.

SVM を用いた場合, 被験者 A について平均正解率 79.2%, 再現率 36.1%, 適合率 40.8% となった. 同じ SVM により, 被験者 B について平均正解率 79.5%, 再現率 63.3%, 適合率 71.2% となり, いずれの指標でも被験者 A よりも高い値となった. 続いて, CNN を用いた場合, 被験者 A について平均正解率 79.6%, 再現率 22.6%, 適合率 38.2% と SVM を用いた場合よりも性能が低下している. 同じく CNN を用いた場合, 被験者 B について平均正解率 81.7%, 再現率 66.7%, 適合率 74.9% となり, SVM を用いた場合よりも性能が改善していることが確認された.

結論として, 機械学習アルゴリズムによる検出性能は, SA の種別により異なる可能性があり, 少なくとも今回のケースでは中枢性・混合性無呼吸を示す患者については CNN による無呼吸イベント検出が有効であった. 本稿では 2 名の被験者についてのみ検討を行ったが, 今後, より多くの被験者データについて詳細な検討を進める予定である.

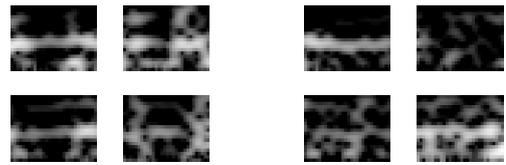


図 2 スペクトログラム画像の例 (被験者 A)

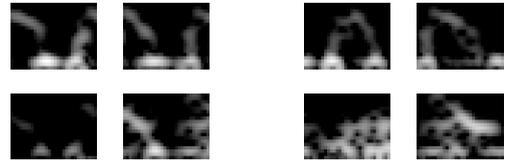


図 3 スペクトログラム画像の例 (被験者 B)

5 まとめ

本稿では, ミリ波レーダと機械学習アルゴリズムを用いた SA の非接触検出技術について, 我々の取り組みを紹介した. SA の種別によって精度が大きく影響を受けることが示された. また, 機械学習アルゴリズムとして SVM および CNN の 2 種類の適用を行った. 中枢性・混合性 SA のような中枢性成分の多い異常呼吸を示す患者については CNN の性能が上回ったが, 閉塞性 SA を示す患者については検出精度は十分でなかった. 中枢性・混合性 SA を示す患者について, CNN を用いた場合には平均正解率 81.7%, 再現率 66.7%, 適合率 74.9% であり, F 値は 70.6% となった. 今後, SA に種別に応じた適切な機械学習アルゴリズムの選択および計測条件の変更によりさらなる性能向上を目指す. 特に, 本稿では無呼吸と低呼吸に同じラベルを付したが, 今後の研究では無呼吸と低呼吸に異なるラベルを付し, 識別性能の向上を試みる予定である.

謝辞

本研究の一部は日本学術振興会科研費 19H02155, JST さきがけ JPMJPR1873, JST COI JPMJCE1307 の助成により実施された.

参考文献

- [1] 阪本, 杉田, 奥村, 瀧, 濱田, 陳, 信学総大, B-19-10, Mar. 2020.
- [2] 香田, 阪本, 奥村, 瀧, 濱田, 陳, 信学ソ大, B-2-15, Sep. 2020.
- [3] T. Koda, *et al.*, *Proc. 2020 International Symposium on Antennas and Propagation (ISAP2020)*, Jan. 2021.

| 手法 | 被験者 | 平均正解率 | 再現率 | 適合率 |
|-----|-----|-------|-------|-------|
| SVM | A | 79.2% | 36.1% | 40.8% |
| | B | 79.5% | 63.3% | 71.2% |
| CNN | A | 79.6% | 22.6% | 38.2% |
| | B | 81.7% | 66.7% | 74.9% |

表 2 レーダによる睡眠時無呼吸の検出性能