

心拍数及び加速度情報を用いた機械学習によるヒトの覚醒予測

岩瀬 智矢[†]大野 佑介[‡]秦野 亮^{†‡}西山 裕之^{†‡}[†] 東京理科大学理工学部[‡] 東京理科大学理工学研究科

1 背景

医療現場での転倒・転落事故は医療事故全体の26%を占める。これらの事故によって残存障害が生じるケースは45%あり、そのうち重度なケースは24%、死亡にいたるケースも1%と報告されている[1]。転倒・転落事故を防ぐための離床行動予測を目的とした研究として間所ら[2]の研究がある。彼らは離床行動を識別した際に看護者に知らせることができるセンサーを開発した。しかし、離床行動を識別後に看護者に通知するため、看護者が到着する前に転倒・転落事故が発生する可能性がある。

本研究の目的はヒトの覚醒を機械学習により予測する手法の提案である。ヒトの覚醒予測が可能であれば、例えば医療現場にて、看護者は効率的な巡回ができるようになり、離床行動後に発生する転倒・転落事故を未然に防ぐことができる。

2 関連研究

覚醒時刻を予測するための特徴量を定めるために参考とした研究について述べる。Cajochenら[3]はノンレム睡眠からレム睡眠への移行の際に心拍数は急激に上昇することを確認した。このことから心拍数は睡眠の段階と関連していることがわかり、心拍数は特徴量として有用であると考えられる。神林ら[4]は「体動密度」という考えを導入し、時刻 t の体動密度は時刻 t の前後15分間に発生した体動の数と定義した。そしてこの体動密度は国際10-20法と呼ばれる方法で計測した脳波によって得られた睡眠状態の遷移と強い相関を示した。彼らの研究から体動も特徴量として有用であると考えられる。

3 提案手法

3.1 システムの概要

本研究では機械学習アルゴリズムの1つであるランダムフォレストを用いて覚醒時刻の予測を行う。関連研究[3, 4]で示したように心拍数や体動はヒトの覚醒予測において有用であると考えられるため、特徴量にはフィットネストラッカーと加速度センサーから取得した心拍数と加速度及び角速度を用いる。フィットネストラッカーにはFitbit Inc.のFitbit Alta HR[5]、加速度センサーにはライフラボラトリ株式会社のウェアラブルセンサー[6]を用いた。

3.2 特徴量とデータセットへのラベル付け

本研究では、 x, y, z の3軸加速度、角速度に対してデータを心拍数と揃えるために1分単位の平均をそれぞれ求めた。その後、加速度と角速度に対しローパスフィルタとハイパスフィルタを用いてノイズを低減した。最後に全てのデータに対し、ウィンドウの大きさを5分としたスライディングウィンドウを用いて心拍数と加速度、角速度の平均、分散、最大値、最小値を算出し合計28個の特徴量を生成した。体内リズムの1サイクルを60分の覚醒と30分の睡眠に分け、90分を1日の縮図と見立て、被験者に60分の覚醒と30分の睡眠を繰り返させ、生体のリズムの変化を観察する手法が過去に多くなされている[7, 8]。この手法の睡眠時間である30分は短時間ごとの睡眠の推移の評価に有用と考え、本研究ではラベルを以下の4つに設定した(表1)。

表1: 本研究でのラベル

c_1	覚醒までに91分以上
c_2	61~90以内に覚醒
c_3	31~60以内に覚醒
c_4	30分以内に覚醒

Prediction of Human's Awakening
Using Heart Rate and Acceleration Data
Based on Machine Learning

Tomoya Iwase[†], Yusuke Ono[‡], Ryo Hatano^{†‡}, Hiroyuki Nishiyama^{†‡}

[†] Faculty of Sci. and Tech. Tokyo University of Science

[‡] Graduate School of Sci. and Tech.

Tokyo University of Science

4 評価実験

4.1 実験環境と評価指標

実験は基本的に夜に行った。外部からの影響を受けずらい環境を想定しているため、外光が入らず、睡眠を妨げるような騒音が少ない部屋で実験を行った。実験参加者は20代の男性3名、実験期間は10月～12月であった。生成したランダムフォレストのモデルの性能を評価する指標として、正確度、適合率、再現率、 F 値を用いた。ただし適合率、再現率、 F 値の値はマクロ平均である。

4.2 交差検証による評価

データセットに対し、10分割交差検証をもとにグリッドサーチを行い、パラメータを調整した後の評価結果を表2に示す。

表2: 評価結果

評価指標	値 (%)
正確度	86.45
適合率	89.70
再現率	81.11
F 値	84.60

全ての指標において80%以上の精度となった。

4.3 モデルの汎化性能の評価

本研究では他人のデータを学習に用いて、覚醒の予測が可能であるかどうかを検証した。まずベースラインとして被験者Aのデータを学習させ、被験者A自身の覚醒を予測した結果を表3に示し、汎化性能を評価するため被験者Bのデータを学習させ、被験者Aの覚醒を予測した結果を表4に示す。

表3: 被験者Aのモデルで被験者A自身の覚醒予測

評価指標	値 (%)
正確度	84.38
適合率	86.52
再現率	80.22
F 値	82.54

被験者Bのデータを学習させ被験者Aの覚醒予測を行うと、精度が非常に低下していることが表3、表4から確認できる。このことから覚醒前の心拍数や加速度情報に個人差が生じていることが考えられる。そのため実際にシステムを導入するには事前にシステム利用者の睡眠データ及び加速度情報が必要であることがわかった。

表4: 被験者Bのモデルで被験者Aの覚醒予測

評価指標	値 (%)
正確度	40.87
適合率	29.62
再現率	25.88
F 値	16.71

5 結論

心拍数と3軸の加速度、角速度を取得した。そのデータをもとに、合計28個の特徴量を生成し、機械学習を行った。生成したランダムフォレストのモデルは正確度、適合率、再現率、 F 値全ての指標において80%以上の精度であった。

今後の展望として、本研究では被験者の年齢に偏りがあるため、今後はより多くの被験者を集め実験を行う。また他人のデータを学習に用いても精度が下がらないような汎用性の高いモデルの構築も行っていく予定である。

参考文献

- [1] 財団法人日本医療機能評価機構 医療事故情報収集等事業第49回報告書.(2017). http://www.med-safe.jp/pdf/report_49.pdf 2018年10月13日アクセス。
- [2] 間所洋和, 下井信浩, 佐藤和人, & 徐粒. (2015). 離床行動予測を目的としたベッド上での動作パターン識別. 計測自動制御学会論文集, 51(8), 528-534.
- [3] Cajochen, C., Pischke, J., Aeschbach, D., & Borbély, A. A. (1994). Heart rate dynamics during human sleep. *Physiology & behavior*, 55(4), 769-774.
- [4] 神林優太, & 萩原啓. (2012). 体動の出現頻度を用いた睡眠周期推定の試み. 生体医工学, 50(1), 99-104.
- [5] Fitbit Alta HR. <https://www.fitbit.com/jp/altahr> 2018年10月15日アクセス
- [6] LifeAnalyzer 説明資料. http://www.meidenshoji.co.jp/news/_icsFiles/afieldfile/2018/08/23/LifeAnalyzer_171113.pdf 2018年10月15日アクセス
- [7] Carskadon, M. A., & Dement, W. C. (1977). Sleepiness and sleep state on a 90-min schedule. *Psychophysiology*, 14(2), 127-133.
- [8] Duncan, W. C., Barbato, G., Fagioli, I., Garcia-Borreguero, D., & Wehr, T. A. (2009). A biphasic daily pattern of slow wave activity during a two-day 90 minute sleep wake schedule. *Archives italiennes de biologie*, 147(4), 117-130.