

勉強中における心拍数を用いた精神状態度合の推定

川崎 勇佑 (15817024)

ロペズ研究室

1. はじめに

作業効率および学習効果を高めるため、作業時および勉強時の集中はとても重要である。近年、ウェアラブルセンサの普及に伴い、生体情報を用いた集中状態の定量評価に関する研究が盛んである[1][2]。

本研究では心拍センサ搭載のスマートウォッチ・スマートバンドを用いて、勉強中のメンタル状態を連続的に推定し、短期的なアクションおよび長期的なフィードバックにより、パフォーマンス向上を支援するシステムを提案している（図1）。まず、スマートウォッチの心拍センサから心拍数関連の特徴量を用いて、集中、眠気、疲労の度合いが十分に検出可能かどうかを検証した。

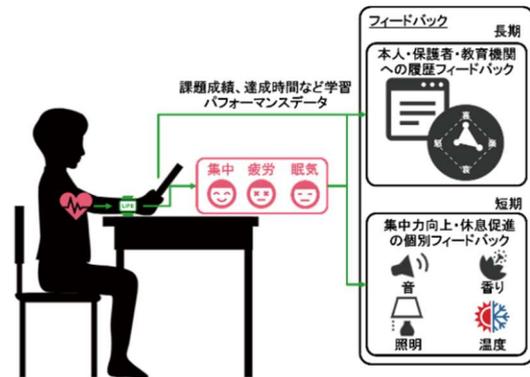


図1. 心拍数を用いた勉強中のメンタル状態推定とフィードバックシステムの概念図

表1 解析窓サイズによる精神状態度合ごとに収集した心拍とラベルデータ数

精神状態	解析窓(分)	精神状態度合		
		低	中	高
集中	3	1240	11568	5899
	5	800	7455	3816
	10	366	3399	1760
疲労	3	12766	4626	1315
	5	8221	2998	852
	10	3737	1387	401
眠気	3	9484	7966	1257
	5	6109	5149	813
	10	2776	2376	373

2. 心拍数を用いて精神状態を判別可能かの検証

心拍数のみを用いて、精神状態を判別するのは不十分とされており、まず心拍変動の特徴量のモデルで精神状態度合いを推定した結果と心拍の特徴量のモデルで精神状態度合いを推定した結果を比較した。比較の結果、心拍変動を用いたモデルの方が精度が高かったが、多くの精神状態度合では差が10%前後に収まっており、心拍数を用いたモデルでもある程度の精神状態度合が判別可能だということが示唆された。

3. 取得したデータのまとめ

実験参加者の心拍数を抽出するために左右いずれかの腕に、光電式容積脈波センサ搭載スマートウォッチ（FitBit versa2）を装着してもらった。集中、眠気、疲労のそれぞれの度合いを低・中・高の3段階に設定し、勉強開始時と勉強中にいずれかの精神状態ラベルの度合いが変わったときに記録した。

塾に通っている高校生男女5名に協力してもらい、

自宅学習の勉強中の連続心拍データと精神状態ラベルの度合いデータを取得した。

心拍の拍数の特徴量抽出窓とシフト時間として、3分窓20秒シフト、5分窓30秒シフト、10分窓60秒シフトとした。

精神状態度合ごとに収集した心拍とラベルデータ数を表1にまとめている。精神状態ごとのレコード数はほぼ同じ数取得できているが、全く制御されていない計測環境のため、精神状態度合い毎のアンバランスが生じた。

2020 年度（令和 2 年度）卒業論文要旨

3. 心拍数を用いた精神状態度の推定

3.1. 窓時間と学習モデルの評価

分析をするために心拍数データから次の七つの特徴量を抽出した：平均値，最大値，最小値，最大値 - 最小値，標準偏差，尖度，歪度．ランダムにデータセットの 75% を学習用に利用した．SVM, KNN, RF, GBRT の四つのモデルを学習残りの 25% のデータで精度評価した．そのプロセスを 10 回繰り返し，各精神状態度の F1 値 (%) と標準偏差を算出した．どの学習モデルにおいても，一番高い精度は 10 分の窓サイズにて一番高い精度を得た．また，RF モデルがどの精神状態度合においても，高い精度になった．

その組み合わせの詳細評価結果を表 2 にまとめている．集中，眠気，疲労のいずれの精神状態を 73% 以上の平均精度で推定できた．精神状態の度合いに関して，60% を下回る項目はあったものの，各状態度合のデータ数と照らし合わせると，400 レコード程度の低集中，高疲労と，高眠気がそれぞれ一番低い精度となり，レコード数の多かった中集中，低疲労と，低眠気はそれぞれ約 85% を超える高い精度となった．そのことから，更なるデータを収集し，ラベルごとのアンバランスを縮小すれば，精度の向上が期待できると考えられる．

3.2. 未知のユーザに対するロバスト性評価

次に，前述の 10 分窓の心拍数特徴量と RF 学習モデルを用いて，未知のユーザデータに対する精度評価を行った．前述 6 名のデータのうち，一名のデータを順番に除いてモデルの学習を行ったうえで，除いたユーザのデータでテストを行った．評価方法として合致率，適合率，再現率，F1 値を導き出した．

その結果を表 3 に示している．明らかに 1 つ目の結果と比べて精度が落ちていることがわかる．ほとんど 60% を超えていたラベルが，10% を下回る結果になり，80% を超えていたラベルも大幅に精度を落としている．

4. 推定精度向上への施策

3.1 の窓時間と学習モデルの評価で作成したモデルの精度向上のために，データの前処理，特徴量エンジニアリング，モデルの最適化の 3 つを行った．結果い

表 2 10 分窓と 1 分シフトのデータセット特徴量を用いて，RF での学習精度のまとめ

	低	中	高	平均
集中	66.7±5	86.6±1	74.0±2	75.8
疲労	89.2±1	70.4±1	59.7±6	73.1
眠気	84.9±1	81.7±1	64.8±3	77.1

表 3 未知のユーザに対する学習精度の評価結果

	合致率	適合率			再現率			F1 値		
		低	中	高	低	中	高	低	中	高
集中	49.2	5.5	60.6	34.1	1.1	61.1	40.9	1.8	60.8	37.2
疲労	32.4	79.6	16.6	35	29.2	82.6	1.9	65.4	16.2	3.7
眠気	43.6	32.6	56.5	2.8	41.7	51.3	1.6	36.6	53.8	2.0

ずれも明らかに精度が上がったものはなかったが，モデルの最適化はレコード数が少ないラベルが主に精度が上がったことから，探索するハイパーパラメータを増やすことにより，精度が上がるのではないかと考えられる．

5. まとめと展望

本研究では心拍数のみを用いて勉強中の集中，眠気，疲労の度合を 3 段階で予測するモデルを作成し，その精度を検証した．10 分窓のデータセットで RF モデルがどの精神状態の度合推定においても，一番優れた結果を得て，平均 73% 以上の精度であったことから，心拍数のみでもある程度の精神状態の度合い予測ができることが示唆された．

一方，汎用モデルは未知のデータに対しての予測は全く機能しないことも示された．各学習ラベルのデータ数がまだ少なく，ラベル間のアンバランスが顕著であるが，このような結果になった一因だと考える．

今後の展望として，データをより多く集めることや，学習モデルの最適化，特徴量エンジニアリングの実施などをすることなどをして改善を進めていく．

参考文献

- [1] 大久保雅史，藤村安耶：加速度センサを利用した集中度合い推定システムの提案，WISS 2008.
- [2] 趙丹俊，松田香菜，片山喜規，伊良皆啓治：脳波・NIRS・心電図による集中状態の評価，電子情報通信学会技術研究報告，111(423):117-20 (2012).