

オフィスワーカーの睡眠状況と労働衛生指標の関係性分析

福田 修之^{1,a)} 谷 優里¹ 松田 裕貴¹ 荒川 豊^{2,3} 安本 慶一¹

概要: 近年、企業に勤める労働者の行動変容を目的として、日々の行動や心理・生理状態を認識する研究が盛んに行われている。本論文では、一般企業 5 社に勤めるオフィスワーカー 60 人の 2～3 週間の生活データを基に、ウェアラブルデバイスから取得可能な日々の睡眠データから、起床時の DAMS 質問票により得られる抑うつ、肯定、不安気分を 2 分類で予測する汎用的な Balanced Random Forest モデルを構築した。Leave One Person Out 交差検証の結果、評価指標である F1 value を抑うつ気分：0.776、肯定気分：0.610、不安気分：0.756 の精度で推定可能であることを確認した。また、被験者ごとの推定精度のばらつきをヒゲ図で確認した結果、被験者ごとに推定精度のばらつきがあることが確認された。

キーワード: 睡眠、DAMS、ウェアラブルデバイス、労働衛生指標

1. はじめに

人間の心理・生理状態や環境状態は心身に様々な影響を与えるため、それらのデータを利用して人間のパフォーマンスや快適性向上に役立てる取り組みが広がっている。中でも、働き方改革により、オフィスワーカーの心身状態を把握し、サポートすることで行動変容を促し、いきいきと働ける職場を作るということは世界中の企業において喫緊の課題となっている。職場などの労働環境における心理状態の把握には、現在、質問票を用いたアンケートが一般的に用いられている。日本においても、平成 26 年 6 月の労働安全衛生法の改正により、50 名以上の従業員を抱えるすべての企業においてストレスヘルスの定期チェックが義務付けられ、労働時間の正確な管理やストレスチェックが広がっている。

このような背景から、企業に勤める労働者をとりまく環境状態や心理・生理状態がどのように労働者のパフォーマンスや快適性向上に影響するかを統計調査した研究が多数なされている。たとえば、Annina らは、被験者 154 人、それぞれ 4 日間を対象とし、睡眠の質を測定する Pittsburgh Sleep Diary 質問票の起床時の回答結果と、その日の職務中の回復状況を測る Recovery Experience Questionnaire 質問票 (REQ) の回答結果、1 日の職務時間の関係を、ロジスティック回帰分析により分析した [1]。その結果、1 日の職

務時間が長さと、起床時の睡眠の質の低下および REQ の回復状況の悪化の相関関係を報告している。

また一方で、Adam らは、米国で最も健康被害の大きい職種である Long-haul truck driving (LHTD) の職業に就いている 260 人を対象に、質問票により得られる職業性ストレスと睡眠の質、ワークライフバランスの関係をロジスティック回帰分析および構造化分析により調査した [2]。その結果、職業性ストレスがワークライフバランス低下の予測因子として有効であることを報告している。また、睡眠の質および時間の減少が職業性ストレスの増加につながることも分析結果より報告している。これらのことから、Adam らは、良質な睡眠の質および時間の確保が LHTD のワークライフバランス向上へとつながると提言している。

しかしながら、上記の研究は、質問票により回答された職務時間と睡眠の質やリカバリー経験がどのように関係するかを統計的に分析し、相関関係を報告しているのみにとどまっており、企業に勤める労働者一人ひとりの心身状態をモニタリングし、個々にあったサポートを行い、行動変容を促すことはできない。

一方で、個人のパフォーマンスや快適性向上を目指し、行動変容を促すことを目的とした研究も多数なされている [3], [4]。より良い行動に導くシステムを構築するためには、日々の行動パターンや心身状態をシステムが自動的に認識することが必要不可欠である。例として、雨森らはスマートデバイスを用いた HRQOL (Health-Related Quality of Life) の推定手法を提案している [5]。この手法ではスマートフォンとウェアラブルデバイスによるライフログと、QOL に関わるアンケートによる正解データを被

¹ 奈良先端科学技術大学院大学
Nara Institute of Science and Technology
² 九州大学, Kyushu University
³ JST さきがけ, JST Presto
a) fukuda.shuichi.fs5@is.naist.jp

験者 1 名を対象として 150 日分収集した後、計測したセンサデータから機械学習を行うための特徴量を計算し、推定モデルを構築することで HRQOL を推定している。しかしこの手法では一人の被験者から得られたデータのみを使用しているため、一般性については検証されておらず、汎用性に欠けるという問題点がある。また、ウェアラブルデバイスとして単価 20 万円程度の Empatica E4 wristband を使用しており、一人あたりのコストが高くなってしまふことも問題として挙げられる。

本研究では、企業に勤めるオフィスワーカーの心身状態を把握し、それぞれにあったサポートすることで行動変容を促し、人間のパフォーマンスや快適性向上を行うことを目的として、一般企業 5 社に勤めるオフィスワーカー 60 人の 2 ~ 3 週間の生活データを基に、ウェアラブルデバイスから取得可能な日々の睡眠データから、起床時の DAMS 質問票により得られる抑うつ、肯定、不安気分を、2 分類で予測する汎用的な Balanced Random Forest モデルを構築した。

Leave one Person Out 交差検証の結果、評価指標である F1 value を、抑うつ気分：0.776、肯定気分：0.610、不安気分：0.756 の精度で推定可能であることを確認した。また、混同行列の結果から、肯定気分の Low レベルの推定がうまく行えてないことがわかったが、抑うつ気分と不安気分に関しては、全体的にうまく推定できていることが確認できた。被験者ごとの推定精度のばらつきをヒゲ図により確認した結果、抑うつ気分の推定がばらつきが小さく、第一四分位数と第三四分位数の幅が 0.24 であった。しかし、抑うつ気分の推定においても被験者ごとのばらつきは 0.24 と大きめな値であることから、被験者によっては高い精度で推定することもあるが、場合によっては、低い精度で推定している場合もあることがあると言える。

汎用モデルの作成により、将来、オフィスワーカーはウェアラブルデバイスを身につけるだけで、日々の心身状態が自動的に認識され、それらに合わせたサポートが行われることが可能となる。

2. 関連研究

2.1 睡眠に関する統計分析研究

Annina らは、被験者 154 人、それぞれ 4 日間を対象とし、睡眠の質を測定する Pittsburgh Sleep Diary 質問票の起床時の回答結果と、その日の職務中の回復状況を測る Recovery Experience Questionnaire 質問票 (REQ) の回答結果、1 日の職務時間の関係を、ロジスティック回帰分析により分析した [1]。その結果、1 日の職務時間と、睡眠の質の低下および起床時の REQ の回復状況の悪化の相関関係を報告している。

Adam らは、米国で最も健康被害の大きい職種である Long-haul truck driving (LHTD) の職業についている 260

人を対象に、質問票により得られる職業性ストレスと睡眠の質、ワークライフバランスへの影響をロジスティック回帰分析および構造化分析により調査した [2]。その結果、職業性ストレスがワークライフバランスの低下の予測因子として有効であることを報告している。また、睡眠の質および時間の減少が職業性ストレスの増加につながることも分析結果より解明している。これらのことから、Adam らは、良質な睡眠の質および時間の確保が LHTD のワークライフバランス向上へとつながると提言している。

Kim らは、14 人の精神疾患患者を対象に、質問票により点数化される瞬間的な抗うつ状態と腕輪型ウェアラブルデバイスから得られる日常のアクティビティとの関係を調査した [6]。抑うつ気分スコアの変化と、同時に測定した自発運動の統計量をモデル化した結果、抑うつ気分の悪化原因として運動活動の欠如があると指摘している。Kim らの研究では、運動性の欠如による抑うつ気分の悪化を報告しているが、精神疾患患者を被験者としていて、本研究の対象とする健常なオフィスワーカーではないため、本研究の分析において運動性の欠如が抑うつ気分の悪化に影響する確証はない。

Hülshager らは、133 人の従業員を対象に 5 日間の就業日にわたって 1 日 4 回疲労評価を行い、疲労度の変化と睡眠の質との関係を成長曲線分析により調査した [7]。成長曲線分析の結果、平均して疲労は午前中に減少し、正午頃に最下点となり、その後就寝までの間増加することが明らかになった。また、それらの 1 日の疲労パターンと睡眠の質との関係性を分析した結果、睡眠の質が低い場合、翌日の疲労は起床時に高く正午に減少し、その後就寝するまで増加することが確認された。一方で、睡眠の質が高い場合、疲労は起床時も低く正午まで安定しており、仕事の終わりと就寝時間の間に増加することが確認された。

Hülshager の研究から、睡眠の質により、その日の疲労度の推移に変化が生じることが提言されているため、本研究においても、当日の睡眠が質問票により得られる労働衛生指標の推移に変化を及ぼす可能性が考えられる。この推移パターンを予測できた場合、労働衛生指標の推移予測に基づいた労働者一人ひとりにあったサポートとよりよい行動変容が行えると考えられる。

2.2 機械学習による質問票分析

Sano らは、学生被験者を対象として、アンケート質問票により得られる学生の学力 (GPA) や睡眠の質 (Pittsburgh Sleep Quality Index score)、メンタルヘルスの指標 (mental health composite score) を機械学習モデルにより推定する手法を提案している [8]。66 人の学生被験者に対してそれぞれ 30 日間、のべ 1980 日分のアンケート質問票を回答し得られるデータとウェアラブルセンサのスマートフォンの使用状況などから取得可能な 700 の特徴量を用いて、SVM

モデルを構築し、Leave One Person Out 交差検証法により評価した結果、80%を超える精度で推定することが報告されている。

Sano らの研究では、被験者として学生を対象としているため、本研究の目的である企業に勤めるオフィスワーカー一人ひとりの心身状態を把握し、それぞれにあったサポートすることはできない。

雨森らはスマートデバイスを用いた HRQOL の推定手法を提案している [5]。この手法ではスマートフォンとウェアラブルデバイスによるライフログと、QOL に関わるアンケートによる正解データを 150 日分収集した後、計測したセンサデータから機械学習を行うための特徴量を計算し、推定モデルを構築することで HRQOL を推定している。学習初期は全ての特徴量を使用して推定モデルの構築を行うが、データ計測日数を重ねるごとにモデルの再構築を行い、個人ごとに最適化されたモデルを構築する。学習の結果、推定において皮膚電気活動や心拍数、LF/HF 比などの心理状態に関連した特徴量に加え、一日の総移動量や最も離れた位置までの距離などの移動距離に関連した特徴量の重要度が高いことがわかった。これらの重要な特徴を選定して構築した推定モデルを用いて HRQOL の推定を行った結果、相関係数 0.646 で正解値を追従できることを確認した。この手法は、推定においてスマートフォンとリストバンド型のウェアラブルデバイスのみを使用するため、日常生活で被験者の動作を制限することなく HRQOL の簡易評価が可能である。

しかしこの手法では一人の学生被験者から得られたデータのみを使用しているため、一般性については検証されておらず、汎用性に欠けるという問題点がある。また、ウェアラブルデバイスとして単価 20 万円程度の Empatica E4 wristband を使用しており、一人あたりのコストが高くなってしまいうことも問題として挙げられる。

2.3 本研究の位置付け

上記の統計分析による研究では、質問票により得られる睡眠の質やリカバリー経験、疲労度、ストレスなどの指標を分析し、統計的な相関関係や因果関係を報告しているのみにとどまっている。よって、企業に勤める労働者一人ひとりの心身状態の認識およびその分析結果にあったサポートを行うことはできない。機械学習による質問票分析を行っている関連研究では、企業に勤めるオフィスワーカーを対象としていないことや、被験者数が少なく汎化性が乏しいことが問題点として挙げられる。

本研究では、企業に勤めるオフィスワーカー一人ひとりの心身状態を把握し、それぞれにあったサポートすることで行動変容を促し、人間のパフォーマンスや快適性向上を行うことを目的としている。本論では、企業に勤めるオフィスワーカー一人ひとりの心身状態を把握するために、個々の

オフィスワーカーの起床時の DAMS 質問表から得られる労働衛生指標 [9] を、前日の睡眠情報から機械学習を用いて推定し、その精度および被験者ごとのばらつきを検証する。

3. 提案手法

3.1 データ収集

本研究で機械学習モデル構築に使用するデータは、谷らが企業に勤めるオフィスワーカーを対象としたセンシングプロジェクトで収集したものを使用した [10], [11]。谷らの研究では、より手軽で汎用的なセンシング手法の構築を目的とし、独自に開発したスマートフォンアプリケーションを用いて一般企業 5 社のオフィスワーカー 60 人を対象に 2 ~ 3 週間のデータ計測を実施した。適切なデータ計測のために、データ計測期間の前に 6 日間の練習期間を設け、被験者の性別や年齢など静的特性に関する事前アンケートに回答している。被験者は実験中、睡眠状態を取得可能な Fitbit 生体センサを 1 日中携帯しながら生活するように指示されている。

3.2 アンケートデータの事前処理

本研究で使用する労働衛生指標には、DAMS (Depression and Anxiety Mood Scale) [9] を使用した。DAMS は抑うつ気分と肯定的気分、および不安気分の程度を測定するための質問票であり、「はつらつとした」、「暗い」、「気がかりな」といった気分を表現する言葉について、今の自分の気分への程度当てはまっているかを 7 段階で選択するようになっている。抑うつ気分得点の算出方法は、「暗い」「沈んだ」「嫌な」の質問項目の 7 段階評価の合計であり、0 - 18 の範囲の値を取りうる。同様に、肯定気分得点は、「楽しい」「嬉しい」「はつらつとした」の、不安気分得点は、「不安な」「心配な」「気がかりな」の合計点数である。

本研究の機械学習の正解データのラベリング手法は、先行研究でアンケート質問票により得られるメンタル指標などの推定を行っている Sano らと同様の手法である。Sano らの正解データの作成手法は、アンケート項目によって得られたメンタル指標の点数に対して、その上位 20% と下位 20% をそれぞれ High, Low の 2 値に設定している。なお、中間の 60% のデータに関しては、アンケート回答における曖昧性が多分に含まれるため破棄している。本研究では、DAMS 質問票により得られた抑うつ気分と肯定的気分、および不安気分得点について、それぞれの上位 20% と下位 20% をそれぞれ High, Low の 2 値に設定し、2 分類問題として扱う。抑うつ気分と肯定的気分、および不安気分得点の点数分布と上位下位 20% の範囲を図 1, 図 2, 図 3 に示す。抑うつ気分と肯定的気分、および不安気分得点の上位下位 20% の点数の閾値は、抑うつ気分：上位 20% 点数 9 点、下位 20% 点数 0 点、肯定気分：上位 20% 点数 9 点、下位 20% 点数 3 点、不安気分：上位 20% 点数 12 点、

表 1 特徴量一覧

Feature Names		
1	Total Sleep Minutes	睡眠時間
2	Total Wake Minutes	ベッドで起きていた時間
3	Light Sleep Minutes	浅い眠りの時間
4	Rem Sleep Minutes	レム睡眠の時間
5	Deep Sleep Minutes	深い眠りの時間
6	Total Wake Time Ratio	ベッドで起きていた 時間割合
7	Light Sleep Time Ratio	浅い眠りの時間割合
8	Rem Sleep Time Ratio	レム睡眠の時間割合
9	Deep Sleep Time Ratio	深い眠りの時間割合
10	Number of Wake	ベッドで起きていた時間 の出現頻度
11	Number of Light Sleep	浅い眠りの出現頻度
12	Number of Rem Sleep	レム睡眠の出現頻度
13	Number of Deep Sleep	深い眠りの出現頻度

下位 20% 点数 3 点であった。全体のアンケート回答総数は、685 件であり、正解データのラベリング後のデータ総数は、274 件であった。

3.3 特徴量抽出

労働衛生指標を推定するモデルの入力となる睡眠に関する特徴量一覧を表 1 に示す。本研究では、被験者の睡眠状況を Fitbit Charge 3 [12] により取得した。Fitbit Charge 3 では、自動検出される入眠・起床時刻や睡眠時間だけでなく、睡眠時の浅い睡眠、レム睡眠、深い睡眠などを 4 段階でを計測することが可能である。本研究では、それらの 4 段階の睡眠時間とその割合も特徴量として追加した。睡眠の特徴量として用いるのは、起床時の DAMS 質問票の回答を行う直前の日付の睡眠である。特徴量は総計 13 項目である。

3.4 モデル構築

推定モデルには、Balanced Random Forest (以後、BRF と称す) モデル [13], [14] を使用した。グリットサーチ法により調整した抑うつ気分、肯定気分、不安気分を推定する BRF モデルのパラメータを表 2 に示す。

4. 結果および考察

4.1 評価方法

本研究では、上述した DAMS 質問票分析により得られる抑うつ気分、肯定気分、不安気分得点を 2 段階に分けてラベリングした正解データと睡眠に関する特徴量を用いて、Leave One Person Out 交差検証法により、モデルの汎用性評価を行った。Leave One Person Out 交差検証法とは、機械学習のモデル構築に使用するデータセットを被験者ごとに分割し、データセットから被験者一人分のデー

表 2 BRF モデルのパラメータ

	抑うつ気分	肯定気分	不安気分
bootstrap	True	True	True
class_weight	balanced	balanced	balanced
criterion	gini	gini	gini
max_depth	None	3	3
max_features	3	3	5
max_leaf_nodes	1	1	1
min_samples_leaf	2	2	2
min_samples_split	2	2	2
min_weight_fraction_leaf	0	0	0
n_estimators	100	100	30
n_jobs	-1	-1	-1
oob_score	False	False	False
random_state	1	1	1
sampling_strategy	all	all	all
verbose	0	0	0

タを評価用、そのほかの被験者全員のデータを学習用データセットとして学習およびモデル評価を行う。それを被験者ごとに繰り返し、モデルの被験者間における汎化性能を評価する手法である。評価指標には、Accuracy, Precision, Recall, F1 Value を使用した。

4.2 被験者ごとの交差検証結果

被験者ごとの交差検証の結果を表 3 に示す。抑うつ気分、肯定気分、不安気分の F1 Value の値は、抑うつ気分が最も高く、0.732 であった。また、その時の Accuracy, Precision, Recall, F1 Value の被験者ごとののばらつきを図 4, 5, 6 に示す。

本研究で使用した Sano らが提案する正解データのラベリング手法では、上位・下位 20% の回答結果のみを抽出した際、60 人二週間のデータは、4 割に減少し、被験者によってその中に含まれるデータ件数にバラツキが生じる。それにより、Leave One Person Out 交差検証を行った時の F1 Value の平均値には、データ数の少ない被験者の結果も含まれてしまう。そこで、データ件数が一週間未満の被験者のデータを除き、Accuracy, Precision, Recall, F1 Value を再計算したものを表 4 に示す。正解データラベリング後の抑うつ気分、肯定気分、不安気分の被験者数はそれぞれ 42 名、44 名、42 名であった。また、それらに対して、データ件数が一週間未満の被験者を除いた後の抑うつ気分、肯定気分、不安気分の交差検証における被験者数は 20 名、19 名、21 名であった。表 4 から、抑うつ気分の推定精度が最も高く、0.776 であった。一方で、肯定気分の推定精度が悪く、0.610 であった。

被験者ごとの推定のばらつきに関しては、図 4, 5, 6 から、被験者ごとにばらつきがあることが確認できる。被験者ごとばらつきは、抑うつ気分の推定が最も小さく、第一四分位数と第三四分位数の幅が、0.24 であった。一方で、




図 1 抑うつ気分得点の分布

図 2 肯定気分得点の分布

図 3 不安気分得点の分布

表 3 被験者ごとの交差検証における精度評価

	抑うつ気分	肯定気分	不安気分
Accuracy	0.639	0.640	0.565
Precision	0.917	0.902	0.704
Recall	0.639	0.640	0.565
F1 Value	0.732	0.696	0.600

表 4 一週間分以上データのある被験者の推定精度

	抑うつ気分	肯定気分	不安気分
F1 Value	0.776	0.610	0.756

表 5 抑うつ気分推定における特徴量の寄与率

	特徴量	寄与率
1	Light Sleep Time Ratio	0.146339
2	Rem Sleep Minutes	0.117653
3	Rem Sleep Time Ratio	0.117653
4	Number of Rem Sleep	0.098994
5	Total Wake Minutes	0.071501
6	Deep Sleep Time Ratio	0.070383
7	Deep Sleep Minutes	0.068154
8	Light Sleep Minutes	0.066242
9	Total Sleep Minutes	0.065598
10	Total Wake Time Ratio	0.063514
11	Number of Wake	0.049613
12	Number of Light Sleep	0.044701
13	Number of Deep Sleep	0.026987

表 6 肯定気分推定における特徴量の寄与率

	特徴量	寄与率
1	Light Sleep Time Ratio	0.125438
2	Rem Sleep Time Ratio	0.124797
3	Rem Sleep Minutes	0.116199
4	Total Sleep Minutes	0.098601
5	Deep Sleep Minutes	0.088327
6	Light Sleep Minutes	0.084920
7	Number of Rem Sleep	0.065996
8	Total Wake time Ratio	0.064743
9	Total Wake Minutes	0.056930
10	Deep Sleep time Ratio	0.053145
11	Number of Wake	0.046709
12	Number of Deep Sleep	0.040319
13	Number of Light Sleep	0.033874

肯定気分、不安気分の推定のばらつきは、第一四分位数と第三四分位数の幅がそれぞれ 0.53, 0.57 であった。このことから、本論で作成した汎用モデルは、被験者によっては、高い精度で推定できることもあるが、一方で低くなる可能性も多分に含まれていると言える。しかし、このモデルをベースとして使用者ごとに学習データを与え、パーソナライズ化することで推定精度が向上する可能性があると考えられる。

4.3 推定全体の評価

抑うつ気分、肯定気分、不安気分のそれぞれの推定結果全体の混同行列を図 7, 8, 9 に示す。混同行列の結果から、抑うつ気分、不安気分に関しては、全体的にうまく推定を行っているが、肯定気分に関しては、肯定気分の低い状態の推定で 58% と High と誤って予測しており、うまく行うことができていない。これは、起床時の DAMS の肯定気分の質問項目「楽しい」「うれしい」「はつらつとした」というポジティブな内容あまり当てはまらなく回答しなかったからだと考えられる。

抑うつ、肯定、不安気分推定における全体の特徴量の寄与率を表 5, 6, 7 に示す。それぞれの推定において寄与率の上位 5 つの項目に、レム睡眠に関する特徴量が入っていることが確認できる。また、同様に浅い睡眠の時間割合の特徴量 (Light Sleep Time Ratio) も上位 5 つに入っている。これらのことから、起床時の抑うつ、肯定、不安気分の推定において、深い睡眠の特徴量よりも、レム睡眠や浅い睡眠の時間割合の特徴量が推定において有効であると考えられる。

5. おわりに

本論では、一般企業 5 社に勤めるオフィスワーカー 60 人の 2 ~ 3 週間の生活データを基に、ウェアラブルデバイスから取得可能な日々の睡眠データから、起床時の DAMS 質問票により得られる抑うつ、肯定、不安気分を、2 分類で予測する汎用的な Balanced Random Forest モデルを構築した。Leave one Person Out 交差検証の結果、評価指標である F1 value を、抑うつ気分 : 0.776, 肯定気分 : 0.610, 不安気分 : 0.756 の精度で推定可能であることを確認した。




図 4 抑うつ気分推定のヒゲ図




図 5 肯定気分推定のヒゲ図




図 6 不安気分推定のヒゲ図




図 7 抑うつ気分推定の混同行列




図 8 肯定気分推定の混同行列

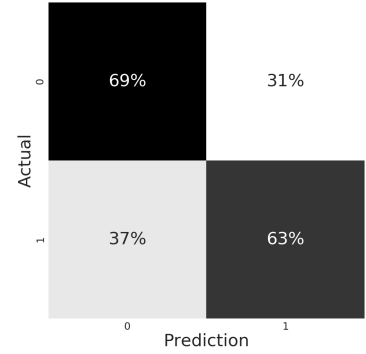


図 9 不安気分推定の混同行列

表 7 不安気分推定における特徴量の寄与率

	特徴量	寄与率
1	Rem Sleep Time Ratio	0.109272
2	Rem Sleep Minutes	0.100533
3	Light Sleep Time Ratio	0.094728
4	Deep Sleep Time Ratio	0.083043
5	Total Wake Time Ratio	0.082017
6	Total Sleep Minutes	0.077754
7	Light Sleep Minutes	0.077330
8	Number of Wake	0.074166
9	Deep Sleep Minutes	0.067463
10	Number of Rem Sleep	0.066891
11	Number of Light Sleep	0.062715
12	Total Wake Minutes	0.062314
13	Number of Deep Sleep	0.041775

また、混同行列の結果から、肯定気分の Low レベルの推定がうまく行えてないことがわかったが、抑うつ気分と不安気分に関しては、全体的にうまく推定できていることが確認できた。被験者ごとの推定精度のばらつきをヒゲ図により確認した結果、抑うつ気分の推定がばらつきが小さく、第一四分位数と第三四分位数の幅が 0.24 であった。しかし、抑うつ気分の推定においても被験者ごとのばらつきは 0.24 と大きめな値であることから、被験者によっては高い精度で推定することもあるが、場合によっては、低い精度で推定している場合もあることがあると言える。

今後の課題として、年齢や性別などの特徴量を追加することやモデルごとの精度比較を行い、推定精度の向上を目指す予定である。また、実用化を目的として、本モデルをベースとして、被験者ごとにパーソナライズした場合、被験者のデータをどの程度与えれば、精度が向上するのか

などの確認を行う。

謝辞

本研究の一部は JST さきがけの支援のもと実施されている。また本実験は、株式会社 NTT データ経営研究所が事務局を務める「応用脳科学コンソーシアム (CAN)」の産学連携研究会「IoT-NA 研究会」の参画企業と連携して実施したものである

参考文献

- [1] Annina Ropponen, Mikko Härmä, Barbara Bergbom, Jouko Nätti, and Mikael Sallinen. The vicious circle of working hours, sleep, and recovery in expert work. *International journal of environmental research and public health*, Vol. 15, No. 7, p. 1361, 2018.
- [2] Adam Hege, Michael K Lemke, Yorghos Apostolopoulos, Brian Whitaker, and Sevil Sönmez. Work-life conflict among us long-haul truck drivers: Influences of work organization, perceived job stress, sleep, and organizational support. *International journal of environmental research and public health*, Vol. 16, No. 6, p. 984, 2019.
- [3] Yutaka Arakawa. [invited paper] sensing and changing human behavior for workplace wellness. *Journal of Information Processing*, Vol. 27, pp. 614–623, 2019.
- [4] Zhihua Zhang, Yuta Takahashi, Manato Fujimoto, Yutaka Arakawa, and Keiichi Yasumoto. Investigating effects of interactive signage-based stimulation for promoting behavior change. *Computational Intelligence*, Vol. 35, No. 3, pp. 643–668, 2019.
- [5] Chishu Amenomori, Teruhiro Mizumoto, Hirohiko Suwa, Yutaka Arakawa, and Keiichi Yasumoto. A method for simplified hrqol measurement by smart devices. In *Wireless Mobile Communication and Healthcare*, 2018.
- [6] Jinhyuk Kim, Toru Nakamura, Hiroe Kikuchi, Kazuhiro Yoshiuchi, and Yoshiharu Yamamoto. Co-variation of

- depressive mood and spontaneous physical activity evaluated by ecological momentary assessment in major depressive disorder. In *2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pp. 6635–6638. IEEE, 2014.
- [7] Ute R Hülshager. From dawn till dusk: Shedding light on the recovery process by investigating daily change patterns in fatigue. *Journal of Applied Psychology*, Vol. 101, No. 6, p. 905, 2016.
- [8] Akane Sano, Andrew J Phillips, Z Yu Amy, Andrew W McHill, Sara Taylor, Natasha Jaques, Charles A Czeisler, Elizabeth B Klerman, and Rosalind W Picard. Recognizing academic performance, sleep quality, stress level, and mental health using personality traits, wearable sensors and mobile phones. In *2015 IEEE 12th International Conference on Wearable and Implantable Body Sensor Networks (BSN)*, pp. 1–6. IEEE, 2015.
- [9] Lee Anna Clark. *The anxiety and depressive disorders: Descriptive psychopathology and differential diagnosis*. 1989.
- [10] 谷優里, 松田裕貴, 河中祥吾, 大坪敦, 平野陽大, 荒川豊, 安本慶一ほか. オフィスワーカーの心身と環境センシングのためのアプリケーションの開発と評価. 研究報告モバイルコンピューティングとパーベイシブシステム (MBL), Vol. 2019, No. 34, pp. 1–7, 2019.
- [11] 谷優里, 松田裕貴, 荒川豊, 井上創造. 労働衛生に関するアンケートとモバイルセンサデータの統合的・継続的な収集. マルチメディア, 分散, 協調とモバイルシンポジウム 2019 論文集, pp. 1027–1034, 2019.
- [12] Fitbit Inc. : Fitbit charge 3. available from <https://www.fitbit.com/jp/charge3> (accessed 2019-10-20).
- [13] Mohammed Khalilia, Sounak Chakraborty, and Mihail Popescu. Predicting disease risks from highly imbalanced data using random forest. *BMC medical informatics and decision making*, Vol. 11, No. 1, p. 51, 2011.
- [14] Yaya Xie, Xiu Li, EWT Ngai, and Weiyun Ying. Customer churn prediction using improved balanced random forests. *Expert Systems with Applications*, Vol. 36, No. 3, pp. 5445–5449, 2009.