

## QoW マネジメントのための心的状態予測に用いる機械学習モデルの改良

Analysis of the relationship between biometric information and sense of fulfillment at work for improving QoW

北村 光輝 <sup>†</sup>	加藤 狩夢 <sup>‡</sup>	佐藤 章博 <sup>‡</sup>	小木曾 里樹 <sup>‡</sup>	一刈 良介 <sup>‡</sup>
Koki Kitamura	Karimu Kato	Akihiro Sato	Satoki Ogiso	Ryosuke Ichikari
森谷 隼介 <sup>†</sup>	中平 勝子 <sup>†</sup>	蔵田 武志 <sup>‡</sup>		
Shunsuke Moriya	Katsuko T. Nakahira	Takeshi Kurata		

## 1 はじめに

現代の職場において、「仕事」は所属する組織や社会の利益のために行われる人間の活動を指す。生産性はこれらの活動の効率を示す重要な指標であり、多くの関係者にとって非常に重要である。それと同時に、“働き方の質 (Quality of Working, QoW)” [1] という新しい概念も注目を集めている。一見対立するように見える生産性と QoW は、実は相互に関連し、互いに高め合う側面を持っている。この相互関係は、国連が提唱する持続可能な開発目標 (SDGs) のサブゴール「8. 働きがいも経済成長も」とも密接に関連している [9]。

先行研究において、生産性と働き方の質を同時に向上させることを目的とした「スマートワーク技術」を開発してきた [5]。

これらの技術には、作業環境やビジネスプロセスを再設計するためのツールや、人間の行動を測定する手法が含まれている。また、スキルを訓練するための仮想現実システムや、作業現場での情報支援用の拡張現実システムも含まれている。これらの技術の導入により、従業員の業務効率が苦情し、業務プロセスの最適化が進んだことが報告されている [5]。

上記のように計測技術をはじめとしたスマートワーク技術により生産性の向上が報告されている一方で働き方の質 (QoW) についての定量的な評価も重要な課題である。

QoW は、健康、働きやすさ、働きがいから成る概念である。

健康や働きやすさに関しては、安全保障や職場環境などの QoL 指標 [14, 15] によってある程度測定可能である。一方で、働きがいは達成や承認といった動機付け要因で構成されている。しかし、動機付け要因は欲求と捉えることもできるため、動機づけ、すなわち欲求に対する満足の程度を視覚化することで動機づけ要因の評価を実現することができるだろう。

そのため、満足を始めとした人の心身状態を表現する必要がある。

ある。

ここでは、心身状態を示す指標として感情を用いる。

感情の定量化の一手法として、Russell の円環モデル [11] が挙げられる。このモデルでは、満足を含めた 28 の感情が valence-arousal の二次元空間で表現される。したがって、満身に近い valence-arousal を持つ感情群を計測することで、仕事を行っている状況の満足の程度を把握し、欲求が満たされているかどうかを測ることが可能となる。これにより、欲求を満たそうとするモチベーションや、モチベーションが満たされた時のやりがいを予測することが可能になる。

しかし、労働中に、過度に個人の感情入力を求めることは労働そのものを阻害する可能性がある。そのため、労働中の感情を逐次自動取得するシステムが必要となる。

以上を踏まえ、この研究では最終的に、人の感情を反映するとされる生体情報を、スマートフォンやスマートウォッチに代表されるウェアラブルデバイスで取得し、これらの情報から労働者の感情を予測する AI の開発を目指す。本稿ではその第一段階として、労働時の感情を EMOSy による正解データと他の生体情報を用いた LSTM (Long-Short Term Memory) モデルによる推論を行う。また、データ拡張によるモデルのロバスト性向上、データの多様性確保を図り、更に新規モデル作成による精度向上を目指す。

## 2 使用データ・収集データ

本稿では、名神高速道路吹田サービスエリアにて各種計測を行った [16, 4, 17] 計測対象者は、高速道路上り線の飲食・物品販売サービスの従業員で、計測場所は上下線商業施設全体とした。計測期間は 2022 年 7 月 4 日 16:00 7 月 14 日 16:00, 2023 年 1 月 16 日 16:00~1 月 26 日 16:00 の夏冬の計測期間で延べ 90 名を対象とした。

従業員の心身状態モニタリングは、以下の通りとし、入力データとして用いた。

- 1 分ごとの心拍数 [BPM]: 身体的な活動やストレスと関連している、個人の身体的な状態や興奮度などの情報

<sup>†</sup> 長岡技術科学大学

Nagaoka University of Technology

<sup>‡</sup> 産業技術総合研究所

National Institute of Advanced Industrial Science and Technology (AIST)

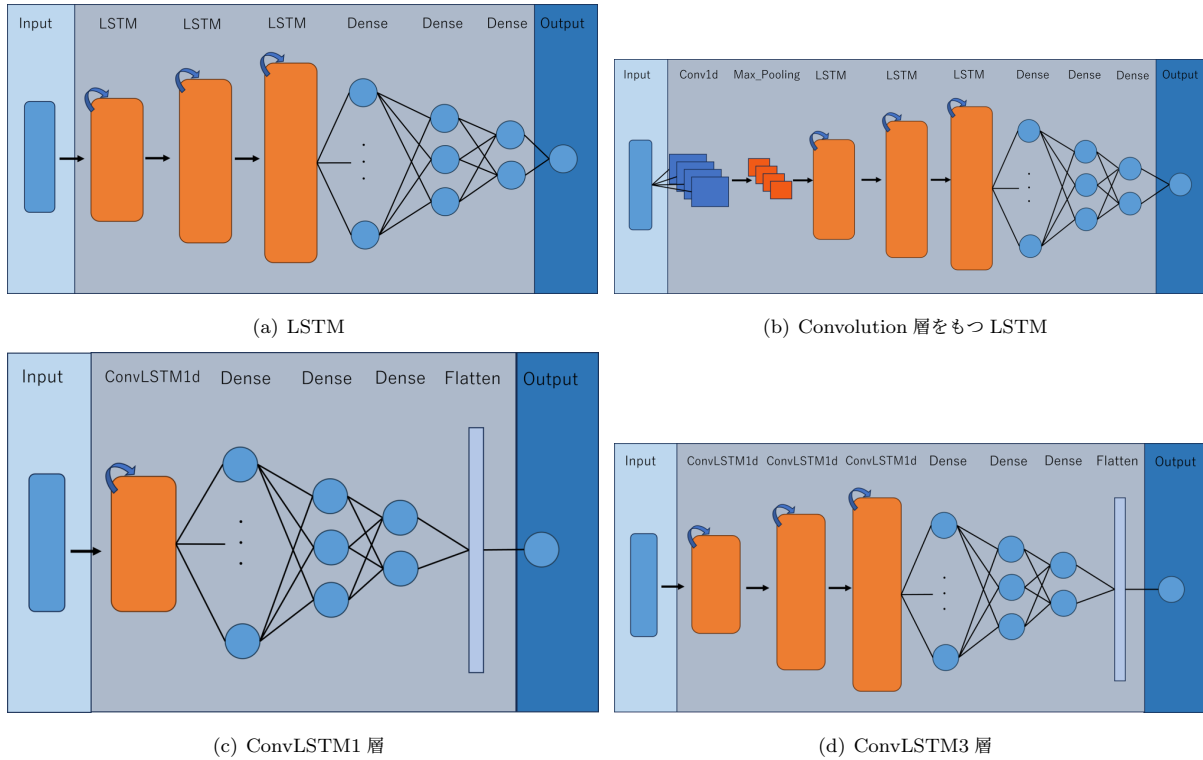


図 1 今回採用したモデル.

2. 1 分ごとの歩数 [歩] 及び移動距離 [km]: 労働者の活動量に関する情報
3. 上がった階数 [3m 上がるごとに + 1]: 活動やエネルギー消費に関連している
4. 消費カロリー [kcal]: 労働者の活動状態に関する情報
5. emosity 入力時の情報: 労働者の感情や、心理状態など、主観的な情報が得られ、教師データとして用いる
6. 被験者の役職, 持ち場: 労働者の職務に関連するストレスや負荷の度合い, 業務のパターンなどを学習することが期待される
7. SA 各店舗の売上個数 (注文数): 労働者の業績や仕事量の変動を学習することが期待される
8. 測定日の曜日: 週の中での特定のパターンや傾向を示す可能性がある
9. 軌跡データ: 労働者の行動パターンや場所による感情の変化を学習することが期待される

また、労働者の感情や心理状態については、経験サンプリング法 (ESM: Experience Sampling Method) の一種である EMOSy (EMOtionaL States measurement sYstem) [18, 7, 6] を用いて収集を行った (図 2). 調査では図の 12 種類の絵文字を収集した.

icon	emoji	Valence	Arousal	emosy_label
16	😄😄😄	7.69	7.37	12
10	😄😄😄	7.75	7.03	11
13	😄😄😄	6.87	6.21	10
9	😄😄😄	6.54	5.68	9
11	😄😄😄	6.02	4.73	8
54	😄😄😄	5.18	5.52	7
30	😄😄😄	4.22	4.62	6
59	😄😄😄	4.45	4.36	5
61	😄😄😄	3.56	5.58	4
43	😄😄😄	3.52	5.5	3
57	😄😄😄	2.88	6.53	2
41	😄😄😄	2.09	7.53	1

図 2 調査で使用された絵文字



図 3 EMOSy 入力例




図 4 74 種絵文字の分布

### 3 モデル

本稿では予測モデルに LSTM(Long Short-Term Memory)[2] を用いた。LSTM は、時系列データを処理するためのモデルであり、従来の RNN(Recurrent Neural Network) の勾配消失問題を解消したニューラルネットワーク層の一つである。前章のデータは期間内で収集した時系列データであり、データポイントが時間的に依存する特徴がある [3]。このことから、本稿では、LSTM をモデルとして用いている。

また、前節で述べた学習に用いるデータが大量にあるためその特徴を LSTM 層だけでは十分に学習できない可能性があると考えた。そこで、LSTM をベースに以下の 4 つのモデルを作成した。

- LSTM(Long Short-Term Memory) : 図 1(a)。系列データ処理 LSTM 層を 3 層にして層を深くすることでより多くの特徴を捉えることを目的に作成。データ間の短い相関関係、長い相関関係を各レイヤーで学習できるとされている。
- CNN-LSTM(Convolution 層 (畳み込み層)) を持つ LSTM[8] : 図 1(b)。畳み込み層が静的な特徴を抽出し、LSTM が時系列データを処理する構造となっている。入力データの特徴を Conv 層で抽出し、LSTM で学習させることを目的としている。
- ConvLSTM1 層 (Convolutional LSTM)[12] : 図 1(c)。内部に畳み込み層を持つ LSTM 畳み込みによって特徴量の空間的な関係を考慮しながら、LSTM によって時系列の依存関係を捉えることができる。後述するほかの ConvLSTM モデルよりも計算コストが軽く、過学習になりづらいメリットがある
- ConvLSTM3 層 (Convolutional LSTM) : 図 1(d)。積み重ねることにより複雑な依存関係を捉えることを目的に作成。計算コストが高いこと、モデルが複雑で過学習になりやすいデメリットがある

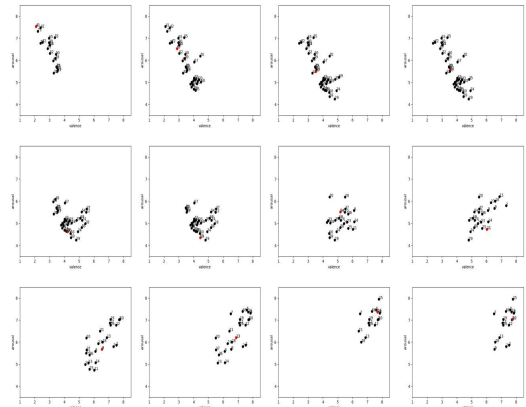


図 5 Enter Caption

### 4 データ拡張

吹田サービスエリア (SA) における絵文字データ収集において、作業環境やユーザビリティの制約が存在したため、香澤ら [13] の基準に基づき、74 種の絵文字 [7](図 4) から Valence と Arousal それぞれの標準偏差が低い絵文字を 2 個ずつ選定し、計 12 種類の絵文字を被験者に入力させた。これにより、被験者は 12 種類の絵文字から選択することとなったが、今回選定されなかった絵文字の中に被験者の感情をより適切に表現する絵文字が含まれていた可能性がある。

本研究では、学習データにおいて、選定された 12 種類の絵文字の周辺に分布する他の絵文字を活用する手法を提案する。具体的には、各説明変数と選定された絵文字を目的変数とするデータに加え、その絵文字を中心とする分布に含まれる他の絵文字を目的変数とするデータを作成し、拡張を行う。このようにして、各説明変数に対して、複数の目的変数を持つデータセットを作成する。絵文字の選定に関しては、香澤ら [7, 6] の調査で得られた標準偏差内の範囲を基準とし、対象の絵文字に追加を行う。

対象の調査絵文字と追加したデータとの対応分布は図 5 のようになっている。それぞれ縦軸が絵文字の Arousal の値、横軸が絵文字の Valence の値となっている。

データを追加した結果学習データ数は追加前 857 から追加後 22800 まで増加した。図 6 は、データ拡張前後の学習データの各絵文字の個数である。赤い点はデータ拡張前の学習データ、青い棒グラフはデータ拡張後の学習データを示す。絵文字のそれぞれ横軸が絵文字の持つ Valence, Arousal の値で上の値が Valence, 下の値が Arousal である。縦軸が個数となっている。拡張前と比べて拡張後はデータの種類、合計量が大幅に増えていることが確認できる。

### 5 感情推定

3 章で紹介した 4 つのモデルを用いて先行研究 [7] によって調査された絵文字の持つ Valence, Arousal それぞれの値




図 6 データ拡張前後学習絵文字データの分布. 点はデータ拡張前, 棒グラフはデータ拡張後. 縦軸は頻度, 横軸は (valence-arousal) のセット.

表 1 各モデルの Valence および Arousal の RMSE

	Valence		Arousal	
	拡張前	拡張後	拡張前	拡張後
LSTM	0.266	0.229	0.289	0.281
CNN-LSTM	0.248	0.243	0.275	0.279
ConvLSTM1 層	0.245	0.237	0.288	0.289
ConvLSTM3 層	0.254	0.314	0.299	0.280

を回帰予測する. どのモデルに置いても, エポックサイズによって RMSE が変わるため, 本稿ではエポックサイズを 128 と 1024 の 2 通りを各モデルで実行した. CNN-LSTM モデルの Convolution 層のフィルターサイズについては 4~128, ConvLSTM モデルの ConvLSTM 層のフィルターサイズについては実行時間の制約で 4~16 でそれぞれ検証した. 検証にはホールドアウト法 [10] を用いた.

RMSE は予測結果と真値との誤差の平均的な大きさを示す指標であり, 値が小さいほど予測の正確性が高いことを示す. 表 1 に, 各モデルの目的変数拡張前, 目的変数拡張後の Valence, Arousal それぞれの RMSE を示す. 表 1 について, LSTM モデルでは拡張前と比べて 13.9% RMSE の減少が確認された. CNN-LSTM モデルでは拡張前と比べて RMSE の値が 2.0% 減少した. ConvLSTM1 層モデルでは拡張前と比べて RMSE の値が 3.2% 減少した. ConvLSTM3 層モデルでは拡張前と比べて RMSE の値が 23.6% 増加した.

また, Arousal について, LSTM モデルでは拡張前と比べて RMSE の値が 2.7% 減少した. CNN-LSTM モデルでは拡張前と比べて RMSE の値が 1.4% 増加した. ConvLSTM1 層モデルでは拡張前と比べて RMSE の値が 0.3% 増加した. ConvLSTM3 層モデルでは拡張前と比べて RMSE の値が 6.3% 減少した.

図 7 はフィルターサイズを横軸, RMSE を縦軸として, Arousal 及び Valence の結果を示したものである. 図 7(a)(b) それぞれで上のグラフが Arousal, 下のグラフが Valence を表

している. 図 7(a) はフィルターサイズ 40 までにおける各モデルの性能が示されている. 図 7(b) では, フィルターサイズ 120 までにおける結果を示している.

## 6 感情推定におけるモデルとデータ拡張の影響に対する考察

### (1) データ拡張の視点からの考察:

データ拡張は, 予測モデルの性能向上に重要な影響を与える要因である. 本稿では, LSTM モデルが Valence および Arousal の予測精度で明確な向上を示したことから, データ拡張がこのモデルに対して効果的であることが示された. 一方で, CNN-LSTM や ConvLSTM といった他のモデルでは, データ拡張の効果がモデルの構造によって異なる結果を示した. 特に, ConvLSTM の 3 層モデルでは Valence において精度が著しく低下することが観察され, これはモデルの複雑さが過学習を引き起こしやすくなることを示唆している.

また, 一部のモデルで RMSE が増加したことについては, データ拡張手法の問題もあると考えられる. 図 6 において, 学習に用いられた絵文字に偏りが見られる. そのため, 偏った学習データが精度に悪影響を及ぼした可能性も考えられる. さらに, 本稿で採用した拡張手法では, 調査で使用された 12 種類の絵文字のうち, Valence や Arousal の値が近い絵文字同士の大小関係が学習において重要な要素である場合, 拡張によってこの大小関係が逆転する事による影響の可能性もある.

### (2) モデル構造の違いの視点からの考察:

モデルの構造が予測精度に与える影響は著しく, 特に異なる層数や組み合わせが性能にどう影響するかが重要である. 図 7(a) から分かるように, CNN-LSTM の 128 エポックのモデルが Valence と Arousal の両方で安定した性能を発揮している一方で, 他のモデルでは性能の安定性に差異が見られる. 例えば, 層数が増えると ConvLSTM モデルの Valence における性能が著しく低下する傾向が見られたことから, 適切なモデル構造の選択が予測精度に直接的な影響を与えるということが考えられる.

## 7 まとめと今後の展望

本稿では, QoW の構成要素の 1 つであるやりがいの定量化に資するための基礎研究として, 吹田 SA で行った従業員の常時モニタリングで得られたデータを使用し, LSTM をベースとした 4 つのモデルを用いた感情推定を行った. 収集時の制約により収集できなかった絵文字を追加することによる適切な感情表現を学習できる機械学習モデル作成を目標とした. 結果として作成した一部の感情推定モデルで精度向上を確認することができた.

本稿では絵文字を文献 [7] の調査で得られた絵文字の持つ Valence, Arousal の値 (図の標準偏差を基に追加した. しかしながら 6 章で述べたように学習に用いられた絵文字に偏りが

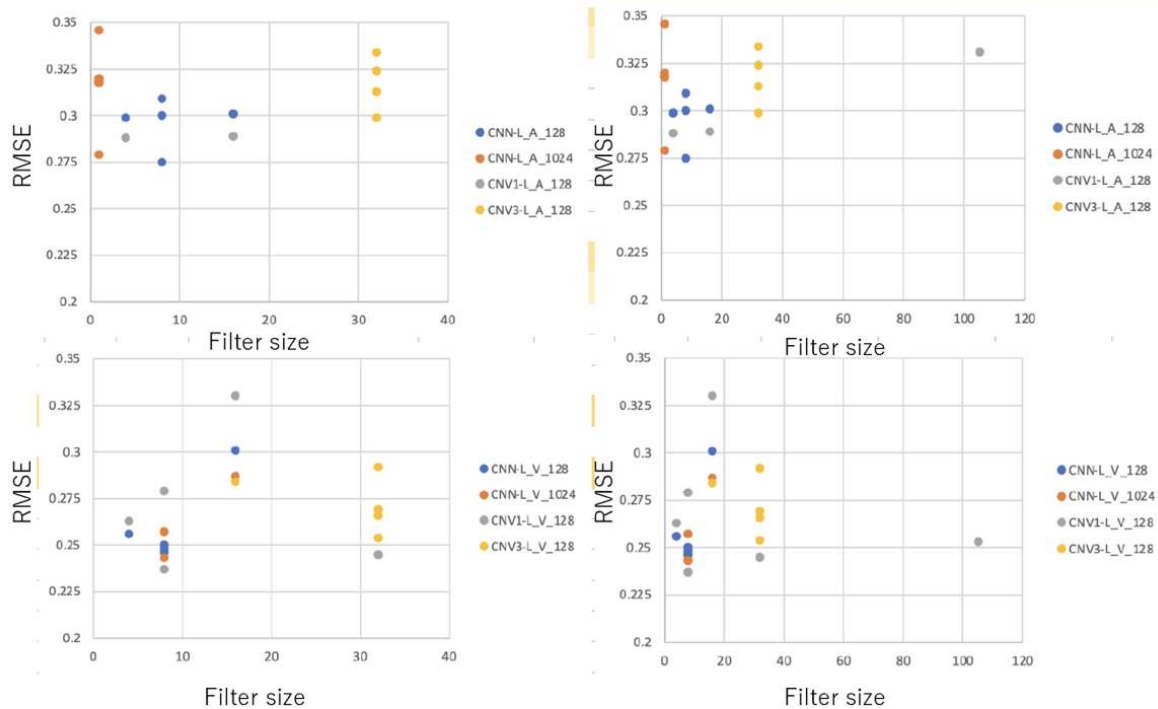


図7 フィルターサイズごとの RMSE

見られたこと、絵文字の大小関係が逆転することによる影響が挙げられる。そこで、今後の展望としてデータ拡張で追加する絵文字の適切な選別方法や選択範囲の調査を行う予定である。データ拡張で追加する絵文字の選別方法として追加する 74 種の絵文字から吹田 SA で収集した 12 種類の各絵文字に対して、ユークリッド距離に近いほど高い確率でランダムに選択し、追加するという手法を試す予定である。

また、精度評価についても拡張前絵文字の分布境界に従った誤差補正による RMSE 算出やクロスバリデーションを用いた評価も今後行う予定である。

## 謝辞

本研究は、国立研究開発法人新エネルギー・産業技術総合開発機構 (NEDO) の委託業務 (JPNP21004)、および、令和 4 年度産業技術総合研究所・立命館大学融合シーズ・スプラウト・プログラムの一環で行われたものです。また、実証実験に関わられたがんこフードサービス株式会社の皆様には多大なご協力を頂きました。関係者の皆様に感謝致します。

## 参考文献

- [1] 産業競争力懇談会 COCN. 【「人」が主役となる新たなものづくり】～活力ある高齢化社会に向けて. <http://www.cocn.jp/report/thema91-L.pdf>, accessed 2024.6.3.
- [2] Sepp Hochreiter and Jürgen Schmidhuber. Long short-

term memory. *Neural Computation*, Vol. 9, No. 8, pp. 1735–1780, 1997.

- [3] Robin John Hyndman and George Athanasopoulos. *Forecasting: Principles and Practice*. OTexts, Australia, 2nd edition, 2018.
- [4] T. Kurata, K. Ogata, S. Kanazawa, Y. Imamura, A. Sato, S. Ogiso, Y. Kobayashi, R. Ichikari, S. Nakae, M. Tada, T. Aoyama, H. Shimizu, H. Kuzuoka, T. Nakamura, T. Koshihara, M. Kuroda, H. Sorimachi, and F. Naruse. Project progress on xr-ai platform for tele-rehab and health guidance. In *2024 IEEE Conference on Virtual Reality and 3D User Interfaces Abstracts and Workshops (VRW)*, pp. 244–251, Los Alamitos, CA, USA, mar 2024. IEEE Computer Society.
- [5] Takeshi Kurata. *Geospatial Intelligence for Health and Productivity Management in Japanese Restaurants and Other Industries*, pp. 206–214. 08 2021.
- [6] Gaku Kutsuzawa, Hiroyuki Umemura, Koichiro Eto, and Yoshiyuki Kobayashi. Age differences in the interpretation of facial emojis: Classification on the arousal-valence space. *Frontiers in Psychology*, Vol. 13, p. 915550, 07 2022.
- [7] Gaku Kutsuzawa, Hiroyuki Umemura, Koichiro Eto,

- and Yoshiyuki Kobayashi. Classification of 74 facial emoji' s emotional states on the valence-arousal axes. *Scientific Reports*, Vol. 12, , 01 2022.
- [8] Wenjie Lu, Jiazheng Li, Yifan Li, Aijun Sun, and Jingyang Wang. A cnn-lstm-based model to forecast stock prices. *Complexity*, Vol. 2020, pp. 1–10, 11 2020.
- [9] United Nations. The 17 goals. <https://sdgs.un.org/goals>, accessed 2024.6.10.
- [10] Sebastian Raschka and Vahid Mirjalili. *Python Machine Learning, 2nd Ed.* Packt Publishing, Birmingham, UK, 2017.
- [11] James Russell. A circumplex model of affect. *Journal of Personality and Social Psychology*, Vol. 39, pp. 1161–1178, 12 1980.
- [12] Xingjian Shi, Zhoung Chen, Hao Wang, Dit-Yan Yeung, Wai-kin Wong, and Wang-chun Woo. Convolutional lstm network: a machine learning approach for precipitation nowcasting. In *Proceedings of the 28th International Conference on Neural Information Processing Systems - Volume 1*, NIPS'15, p. 802–810, Cambridge, MA, USA, 2015. MIT Press.
- [13] 沓澤岳, 小林吉之. IoT× 絵文字による 感情変動測定システム “EMOSy” の開発. 計測自動制御学会 ライフエンジニアリング部門シンポジウム 2022.
- [14] 厚生労働省. 総論参考資料. [https://www.mhlw.go.jp/www1/topics/kenko21\\_11/s1.html](https://www.mhlw.go.jp/www1/topics/kenko21_11/s1.html).
- [15] 厚生労働省. 令和元年版 労働経済の分析 – 人手不足の下での「働き方」をめぐる課題について –. <https://www.mhlw.go.jp/stf/wp/hakusyo/roudou/19/19-1.html>.
- [16] 佐藤章博, 小木曾里樹, 一刈良介, 沓澤岳, 小林吉之, 新村猛, 野中朋美, 蔵田武志. 健康経営支援のための高速道路 SA 従業員の心身状態常時モニタリング. HCG シンポジウム, No. B-2-4, 2022.
- [17] 佐藤章博, 小木曾里樹, 一刈良介, 蔵田武志. 複雑な決定境界に対応するためのスタッキングアンサンブル学習器による高速道路 SA 就業者の感情推定における不均衡データ対策手法の比較. Technical Report 358, jan 2024.
- [18] 小林吉之, 沓澤岳, 藤本雅大, 中嶋香奈子, 稲井卓真, 工藤将馬. AIST 歩行属性判定システム HOLMES と, 感情測定システム EMOSy による日常生活行動計測, 2021. [https://unit.aist.go.jp/harc/symposium/HARCS2021/poster\\_contents/23\\_Kobayashi.pdf](https://unit.aist.go.jp/harc/symposium/HARCS2021/poster_contents/23_Kobayashi.pdf), accessed 2024.6.14.