

## 環境・バイタルセンサデータによる認知症における 行動・心理症状 (BPSD) の推定

南 泰浩<sup>†</sup> 常盤 直也<sup>‡</sup> 柴田 純一<sup>††</sup> 鈴木 利一<sup>††</sup> 柏木 岳彦<sup>†</sup> 田野 俊一<sup>†</sup>

<sup>†</sup> 電気通信大学 〒182-8585 東京都調布市調布ヶ丘 1 丁目 5-1

<sup>‡</sup> 株式会社ラクスパートナース 〒160-0022 東京都新宿区新宿 4-3-25 TOKYU REIT ビル 8F

<sup>††</sup> 株式会社 iD 〒040-0011 北海道函館市本町 6-10 五稜郭ビル 2F

E-mail: <sup>†</sup> minami.yasuhiro@is.uec.ac.jp, {t.kashiwagi, tano}@uec.ac.jp, <sup>‡</sup> ta003653@edu.cc.uec.ac.jp,

<sup>††</sup> {Shibata, t-suzuki}@intelligent-design.co.jp

**あらまし** 介護施設や家庭において、認知症の方が発症する行動・心理症状 (BPSD) は、家族・介護者に大きな負担を課しているだけでなく本人にも負の影響を与えている。本研究では、IOT の技術を用い複数の介護施設で環境センサ・バイタルセンサの情報を収集し、そのデータに基づき、機械学習の手法である勾配ブースティング木と DNN の一種 CNN を利用して BPSD の予測を行う。約 5 か月間のデータを用いて評価実験を行った結果、勾配ブースティングを使った手法において、BPSD 発症推定の可能性を示すことができた。

**キーワード** 認知症, BPSD, 勾配ブースティング決定木, CNN

## Estimation of Behavioral and Psychological Symptoms of Dementia (BPSD) using Environmental and Vital Sensor Data

Yasuhiro MINAMI<sup>†</sup> Naoya TOKIWA<sup>‡</sup> Junichi SHIBATA<sup>††</sup> Toshikazu SUZUKI<sup>††</sup>

Takehiko KASHIWAGI<sup>†</sup> and Tano SHUNICHI<sup>†</sup>

<sup>†</sup> The University of Electro-Communications 1-5-1 Chofugaoka, Chofu, Tokyo 182-8585, Japan

<sup>‡</sup> RAKUS Partners Co., Ltd. TOKYU REIT Bldg. 8F, 4-3-25 Shinjuku, Shinjuku-ku, Tokyo 160-0022, Japan

<sup>††</sup> iD corporation Goryokaku Bldg.2F, 6-10 Honcho, Hakodate, Hokkaido 040-0011, Japan

E-mail: <sup>†</sup> minami.yasuhiro@is.uec.ac.jp, {t.kashiwagi, tano}@uec.ac.jp, <sup>‡</sup> ta003653@edu.cc.uec.ac.jp,

<sup>††</sup> {Shibata, t-suzuki}@intelligent-design.co.jp

**Abstract** In nursing homes and homes, Behavioral and Psychological Symptoms of Dementia (BPSD) that developed by people with dementia not only impose a heavy burden on family members and caregivers but also give the individuals themselves negative impacts. In this study, we used IOT technology to collect data from environmental and vital sensors at multiple nursing homes, and based on the data, we estimated BPSD using gradient boosting decision trees (GBTD), a machine learning technique, and CNN, a type of DNN. As a result of evaluation experiments using approximately five months of data, we were able to demonstrate the possibility of estimating the onset of BPSD for the method using GBDT.

**Keywords** Dementia, BPSD, GBDT, CNN

### 1. はじめに

認知症は、病気や障害などの様々な要因により、脳の機能が損傷を受け、日常生活活動に影響が出る症状の疾患である[1]。厚生労働省の調査によると、認知症に関して以下の報告が示されている[1]。2020年時点で、日本での65歳以上の認知症の患者数は600万人に達している。また、2025年には、700万人に達すると予測されている。これに対し、2018年、厚生省は介

護人材の不足が2020年には26万人、2025年度までには、55万人に達すると予測していた[2]。この介護人材の不足は日本の社会が早急に対応すべき重要な問題であり、この問題によって引き起こされる介護士への負担の軽減は喫緊の課題である。

認知症の症状には、中核症状と、周辺症状に大別できるが、周辺症状である認知症の行動・心理症状 (Behavioral and Psychological Symptoms of Dementia; BPSD)が最近特に注目されている。BPSDは1996年に

国際老年精神医学会において、「認知症患者にしばしば生じる、知覚認識または思考内容または気分または行動の障害による症状」と定義されている[3,4,5]. このような症状として、徘徊、妄想、大声、不安、不眠などがあげられる。これらの症状は、周りで介護する介護士や家族にとって、大きな負担になるだけでなく、本人にとっても負担となっている。もし、BPSDがIoTの手法で、事前に予測でき、それに対する対処が可能であれば、介護士や家族の負担を軽減できる可能性がある。

本研究では、その可能性を探るため、様々な環境・バイタルセンサを各介護施設に設置し、そのセンサからの情報を使って、BPSDの推定手法について検討する。

これまで、このような研究では、ウェアラブル機材を使って、活動量、運動機能などの測定結果と、集団としての症状の関係を議論した研究がある[6-15]. 個別の対象者の状態を把握する研究として、リストバンドセンサを利用し、認知症対象者のストレス度を直接推定する手法が提案されている[16]. また、複数の音声やセンサの情報から、認知症対象者の興奮度を推定する手法も提案されている[17]. [18]では、ベッドセンサと湿潤センサと音声から、失禁と夜間の興奮を監視するシステムを提案している。今回の報告と同様に、マルチモーダルのセンサデータを利用して、認知症患者の動揺を検出するシステムの開発および、その問題点を指摘している研究もある[19,20]. この研究では、AUC0.89を達成している。[21]では、この研究をさらに発展させ、行動臨床記録ツールである Pittsburgh Agitation Scaleの結果との整合性を検証している。

我々の研究では、より多くの環境・バイタルセンサと多くの実験参加者を用い、機械学習手法を利用してBPSD推定の可能性を検証する。

## 2. データ収集環境の概要

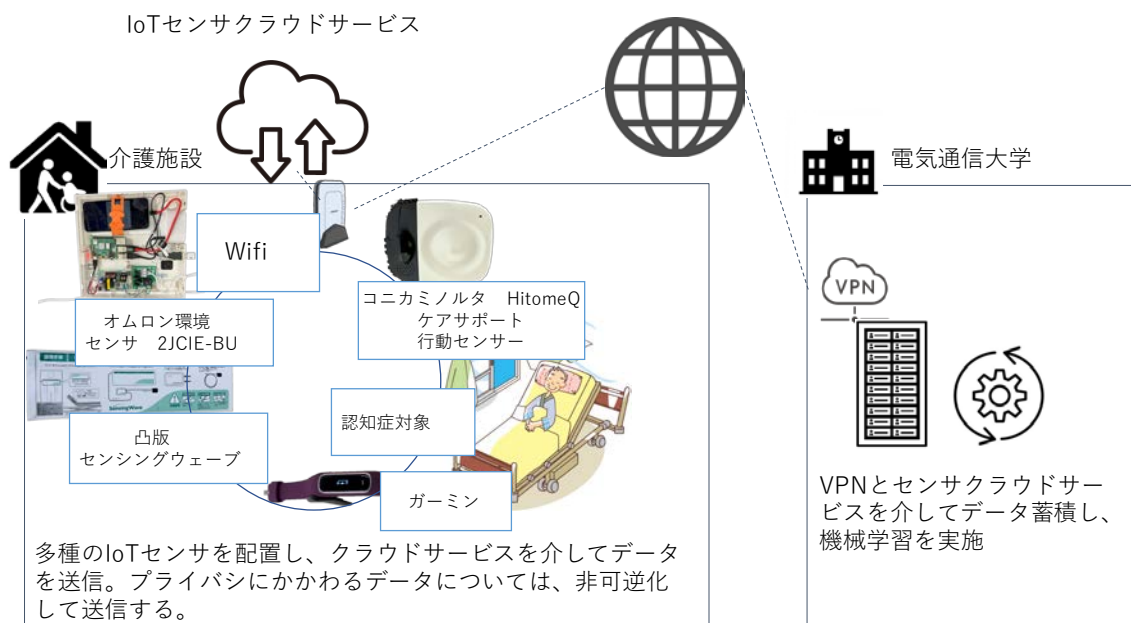
倫理審査実施後、複数の介護施設に依頼し、データの収集のため図1のシステムを構築した。また、入居者および家族に実験参加者への承諾を得た後、実験に参加してもらった。実験参加者の部屋には、オムロンの環境センサ(USB型)2JCIE-BU[22], TOPPANの非接触型センサのセンシングウェーブ[23], KONICA MINOLTAのHitomeQ ケアサポート行動分析センサ[24]を設置した。また、ウェアラブルセンサとしてGARMIN[25]を装着してもらった実験参加者もいる。クラウドサービスを介して、これらのセンサデータを電気通信大学へ送信している。ただし、プライバシーにかかわるデータについては、非可逆化して送信している。電気通信大学ではVPNとセンサクラウドサービスを介してデータを蓄積し、大学のネットワークからは切り離されたGPU搭載のコンピュータで機械学習を実施する。

## 3. 利用したセンサデータの種類

データを取得した時期、場所、実験参加者の人数、BPSDの総数などを表1に示す。

表1 データの諸元

データ取得期間	2022.08.01~2022.12.25
実施施設数	3施設
対象人数	58名
対象者基準	期間内4割以上のデータ取得
発症BPSD総数	1358



また、利用したデータの種類とその粒度を表2示す。今回の実験では、ガーミンと同種の情報を取得しているセンシングウェブのデータは使っていない。センサのデータ取得間隔は、センサによりまちまちであるが、機械学習ではそれらの粒度を揃える必要があるため、1分間隔以下の粒度のデータは1分で平均化して利用している。

#### 4. BPSD 推定手法

時系列の変化も時系列データの認識では重要な特徴量となるため、学習・テストデータを以下の方法で作成した。特徴量としては、センサ値  $s(t)$ 、1分前のセンサ値に対する変化量  $s(t) - s(t-1)$ 、1分前のセンサ値に対する変化率  $\{s(t) - s(t-1)\}/s(t-1)$  を利用した。また、予備実験で、BPSD 推定に照度が重要な役割を示す結果を得たが、これが、時刻の影響とも考えられるので、時刻情報を陽に学習に使用できる特徴量も加えた。具体的には、時間情報特徴量  $(\text{hour\_cos}, \text{hour\_sin}) = (\cos(\pi x / 12), \sin(\pi x / 12))$  を追加した。ただし、 $x = 0, 1, \dots, 23$  とする。この2次元の関数は、関数の連続性を保ちつつ24時間のそれぞれの時刻にユニークな値を付与

表2 本研究で利用するセンサー一覧

センサー名	データ	項目名	間隔
Garmin		心拍	15s
		スリープレベル	1s
		ストレス値	180s
OMRON社センサ		温度	1s
		相対湿度	1s
		照度	1s
		気圧	1s
		騒音	1s
		総揮発性有機化合物濃度	1s
		二酸化炭素濃度相当値	1s
		不快指数	1s
		熱中症危険度	1s
	PocketCO2		二酸化炭素濃度
コニカ ミノルタ社 センサ	behavior指 標	人矩形の重心座標 (x座標)	1s
		人矩形の重心座標 (y座標)	1s
	ドップ ラー指標	呼吸数	3s-3m
		覚醒睡眠不在フラグ	3s-3m
	時間ごと のbehavior 指標	行動量	1h
		移動距離	1h
		行動範囲面積	1h
		高頻度行動範囲面積	1h
		高頻度行動範囲面積割合	1h
		歩行速度	1h
		ふらつき度	1h
		総作業時間	1h
		立ち止まり時間	1h
		長時間立ち止まり回数	1h
		短時間立ち止まり回数	1h

することができる。学習・テストに使用した正解ラベルは、介護士が BPSD の発症を確認したのち記録した BPSD 発症時刻である。この記録は、アプリにより登録する。

本報告では、機械学習手法として勾配ブースティング決定木による手法と Deep Neural Network(DNN)による手法を用いて実験を行った。次節から、それぞれの説明を行い、最後に、評価方法について述べる。

##### 4.1 勾配ブースティング決定木による BPSD 推定

学習モデルには、勾配ブースティング決定木をベースとした LightGBM, CatBoost, XGBoost を使用する。BPSD 推定手法の構成を図2に示す。図に示すように、1分毎のセンサデータから得られる特徴量を入力とする。この入力に対して、複数の勾配ブースティング決定木による BPSD 判定器を時系列上に並べ、個々の判定器で将来の BPSD を予測し、その結果の平均をとって、BPSD の最終判定を行う（最後の BPSD 判定器は予測になっていないので、ここでは予測ではなく、推定という言葉を用いた）。すべての判定器には同じものを用いる。ここで、一つの BPSD 判定器が見ている入力特徴量の時系列上の長さを Window size とする。また、全体の BPSD 判定器が見ている特徴量の時系列上の長さを推定幅とする。

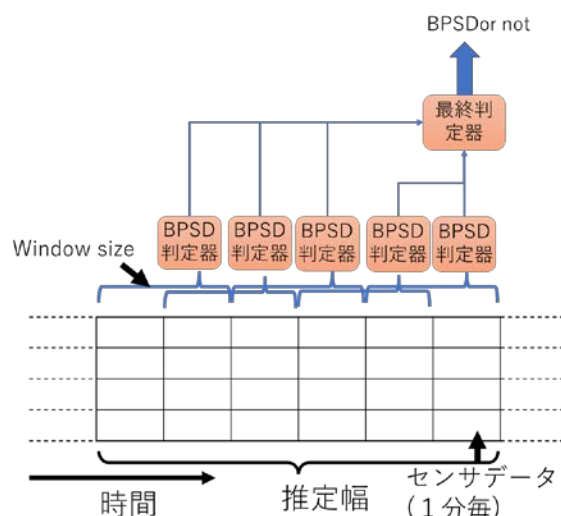


図2 決定木による BPSD 推定器の構成

##### 4.2 DNN による BPSD 推定

ここでは、BPSD 発症の推定を行うため、4.1 と同様の推定幅×特徴量の数を DNN モデルへの入力データとして使用する。図3にその入力例を示す。この場合の推定幅は120分である。

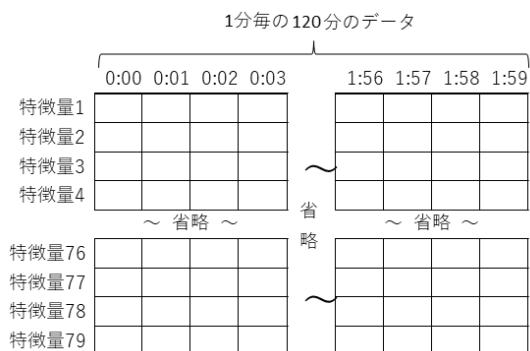


図3 DNN への入力例

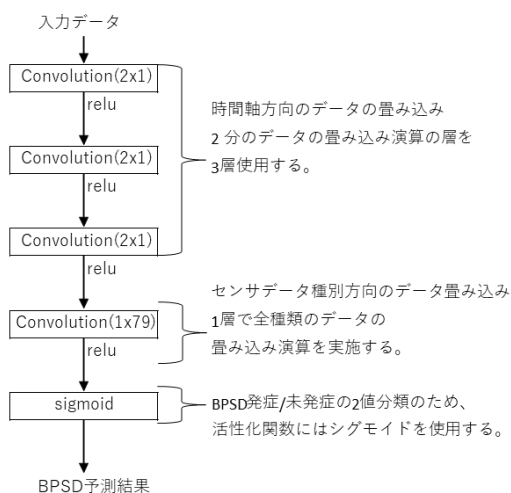


図4 用いる CNN の構造

DNN としては図4の構造のCNNを用いる。この構造では、4.1で述べた構造と同じような構造になるように、2分毎の特徴抽出器をカスケード状に配置し同じ特徴抽出器が短い範囲でデータを処理し、最後の層で結果を統合するようにした。

### 4.3 BPSD 推定の評価方法

精度検証には、これまでROC曲線によるAUCで評価することが見受けられる[19,20]。この評価は、TPR(真陽性率)とFPR(偽陽性率)をプロットした結果から求められ、評価として一定の意味をもつが、この他の評価も必要であると筆者らは考えている。真陽性率と偽陽性率は以下の式で計算される

$$\text{真陽性率} = \frac{\text{真陽性}}{\text{真陽性} + \text{偽陰性}} \quad (1)$$

$$\text{偽陽性率} = \frac{\text{偽陽性}}{\text{偽陽性} + \text{真陰性}} \quad (2)$$

しかし、偽陽性率は、陰性のサンプルの数が多の場合、少しの率で、多くの偽陽性を生成することになる。BPSDの場合では、偽陽性率が高いと偽のBPSD判定結果を生成するため、偽陽性率を相当低くしないと介護士に多くの負担を強いる可能性がある。このため、

ROC曲線から最適な閾値を見つけることが困難となる。

本報告では、このことを考慮し、ROC曲線だけでなく、真陽性率=Recall(再現率)とPrecision(適合率)をプロットするPR曲線を求め、精度確認を行う。ここで、適合率は、以下の式で表され、陽性と判定されたものうちのどれくらいが正しい陽性かを調べており、陰性数の影響を受けないので、介護現場の状況を考えてと有効な尺度となっている。

$$\text{適合率} = \frac{\text{真陽性}}{\text{偽陽性} + \text{真陽性}}$$

## 5. BPSD 推定実験

今回使用したデータセットは、BPSD発症時刻よりもBPSDを発症していない時刻の方が極端に多い不均衡データセットのため、学習時に多数派データを減少させるUnder samplingも実施した。また、モデルの汎化性能を評価できるように学習データとテストデータを6回入れ替えて交差検証を行った。

### 5.1 決定木によるBPSD推定実験

ここでは、推定幅は120分に設定した。Window size ([2分, 4分]), Under samplingの割合 ([1.0, 0.1, 0.01]), 学習に使用するモデル ([LightGBM, CatBoost, XGBoost])の組み合わせの中からAUCが最も高いものを選ぶ、Grid Searchを行うことで、精度の高い条件を求め、その結果のROC曲線と、PR曲線を求めた。最終的に選択されたものは、モデルがCatBoostであり、Window sizeが2であり、Under samplingの割合が1.0であった。図5に結果のROC曲線を示す。

この図から、ROCはかなり高い率を示していることがわかる。また、サンプルの取り方により、ROCのグ




図5 CatBoostによるROC曲線

ラフが変化することもわかる。これは、まだサンプルが少なくデータのばらつきがあるためだと考えられる。

図6にPR曲線を示す。PR曲線は右上に描かれるほど性能が良いことを示すが、図から6回の試行のうち3回はPR曲線がPrecision=0近辺から離れて描けていることがわかる。このことから、学習データの選び方によってBPSD推定が実現できる可能性があることがわかる。

最も性能がいい場合、真陽性率が10%で、適合度が20%となっている。これは、10個のBPSDの内一個は補足でき、BPSDと判定されたもののうち2割は正解だということを示している。不正解の場合の介護士の負担が未知の現状では、1割のBPSDの通知が、介護

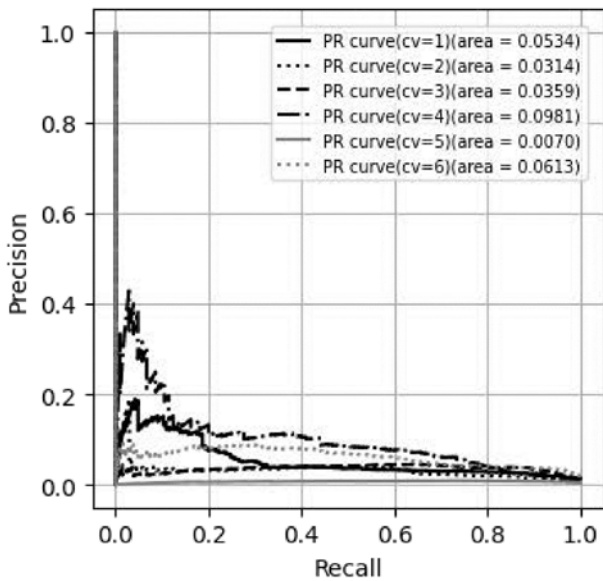


図6 CatBoostによるPR曲線

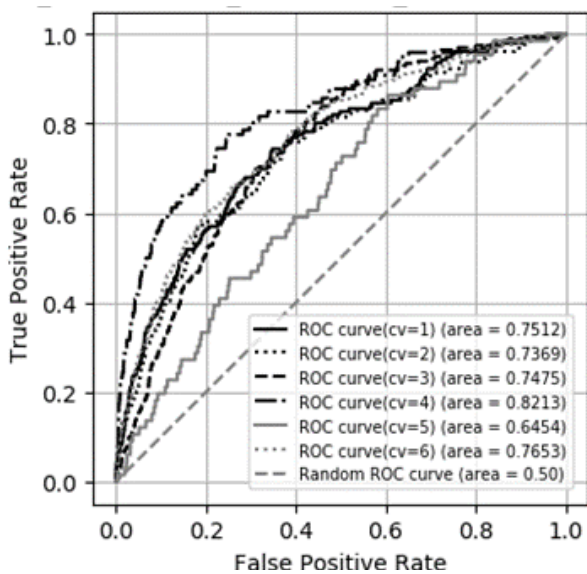


図7 CNNによるROC曲線

士の負担をどれだけ減らせるかは、評価できないが、負担軽減の可能性を示すことはできたと考えられる。

## 5.2 DNNによるBPSD推定実験

ここでは、DNNの一種CNNによるBPSDの実験を行った。推定幅は5.1と同じ120分である。ROCのグラフを図7に示す。この時の平均のAUCの値は0.74であった。この結果は、勾配ブースティング決定木の結果より悪い。原因はいくつか考えられるが、原因の一つは学習データの少なさであると考えられる。

図8にこのときの、PR曲線も示しておく。図のように、この設定では、PR曲線が右上の方に描ける可能性を示すことができなかった。

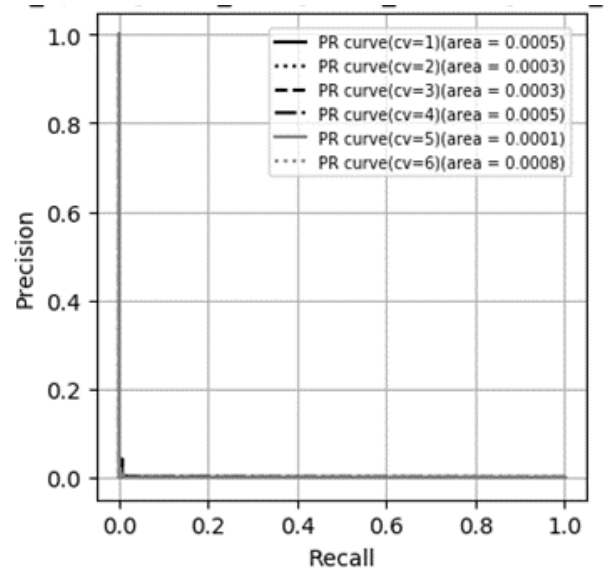


図8 CNNによるPR曲線

## 6. まとめ

本研究では、介護施設での認知症の方の環境をセンシングし記録したデータとバイタル情報をセンシングし記録したデータに基づき、認知症の方が発症する行動・心理症状(BPSD)を、機械学習手法で、推定する手法を提案し評価した。本研究では機械学習として、勾配ブースティング決定木を時系列上に複数使い、その結果を平均化する手法を提案した。本手法を用いて、実際に収集したデータで評価した結果、BPSDを推定できる可能性があることが分かった。また、CNNでもBPSDの判定器を構成し、実験を行った結果、勾配ブースティングよりも推定精度が低いことが分かった。これは、データ量が少ないことが影響していると考えられる。今後、データ量を増加させ、さらに分析を進めていく。

## 7. 謝辞

本研究は、大学研究者による事業提案制度「AIとIoTにより認知症高齢者問題を多面的に解決する東京アプローチの確立」を通じて東京都の支援を受けたもので



ある。また、この制度に参加し、データ収集に尽力をしていただいたメンバーの方たちにも感謝いたします。

## 文 献

- [1] 厚生労働省, "みんなのメンタルヘルス", [https://www.mhlw.go.jp/kokoro/known/disease\\_recog.html](https://www.mhlw.go.jp/kokoro/known/disease_recog.html).
- [2] 厚生労働省, "第7期介護保険事業計画に基づく介護人材の必要数について", <https://www.mhlw.go.jp/stf/houdou/0000207323.html>.
- [3] 山口晴保, "BPSD の定義, その症状と発症要因", 認知症ケア研究誌, vol.2, pp. 1-16 2018.
- [4] S. I. Finkel, J. C. e Silva, G. Cohen, S. Miller and N. Sartorius, "Behavioral and psychological signs and symptoms of dementia: A consensus statement on current knowledge and implications for research and treatment", *International psychogeriatrics*, vol.8, no.5, pp. 497-500 1997.
- [5] 国際老年精神医学会, "認知症の行動と心理症状 BPSD". アルタ出版, 2013.
- [6] 山上徹也, 山口晴保, "情報通信技術を活用した bpsd 予防・予測システム開発の現状と課題", 認知症ケア研究誌, vol.5, pp. 8-15 2021.
- [7] A. Bankole et al., "Validation of noninvasive body sensor network technology in the detection of agitation in dementia," *American Journal of Alzheimer's Disease & Other Dementias*, vol. 27, no. 5, pp. 346-354, 2012.
- [8] L. Etcher, A. Whall, R. Kumar, D. Devanand, and V. Yeragani, "Nonlinear indices of circadian changes in individuals with dementia and aggression," *Psychiatry research*, vol. 199, no. 1, pp. 77-78, 2012.
- [9] L. M. Ghali, R. W. Hopkins, and P. Rindlisbacher, "Temporal shifts in peak daily activity in Alzheimer's disease," *International journal of geriatric psychiatry*, vol. 10, no. 6, pp. 517-521, 1995.
- [10] A. Knuff, R. H. Leung, D. P. Seitz, L. Pallaveshi, and A. M. Burhan, "Use of actigraphy to measure symptoms of agitation in dementia," *The American Journal of Geriatric Psychiatry*, vol. 27, no. 8, pp. 865-869, 2019.
- [11] G. Nagels, S. Engelborghs, E. Vloeberghs, D. Van Dam, B. A. Pickut, and P. P. De Deyn, "Actigraphic measurement of agitated behaviour in dementia," *International journal of geriatric psychiatry*, vol. 21, no. 4, pp. 388-393, 2006.
- [12] L. Valembois, C. Oasi, S. Pariel, W. Jarzebowski, C. Lafuente-Lafuente, and J. Belmin, "Wrist actigraphy: a simple way to record motor activity in elderly patients with dementia and apathy or aberrant motor behavior," *The journal of nutrition, health & aging*, vol. 19, pp. 759-764, 2015.
- [13] T. Fleiner, P. Haussermann, S. Mellone and W. Zijlstra, "Sensor-based assessment of mobility-related behavior in dementia: Feasibility and relevance in a hospital context", *International psychogeriatrics*, vol.28, no.10, pp. 1687-1694 2016.
- [14] J. Merilahti, P. Viramo and I. Korhonen, "Wearable monitoring of physical functioning and disability changes, circadian rhythms and sleep patterns in nursing home residents", *IEEE journal of biomedical and health informatics*, vol.20, no.3, pp. 856-864 2015.
- [15] H. Zhou, H. Lee, J. Lee, M. Schwenk and B. Najafi, "Motor planning error: Toward measuring cognitive frailty in older adults using wearables", *Sensors*, vol.18, no.3, pp. 926 2018.
- [16] B. Kikhia, T. G. Stavropoulos, S. Andreadis, N. Karvonen, I. Kompatsiaris, S. Sävenstedt, M. Pijl and C. Melander, "Utilizing a wristband sensor to measure the stress level for people with dementia", *Sensors*, vol.16, no.12, pp. 1989 2016.
- [17] C. Nesbitt, A. Gupta, S. Jain, K. Maly and H. R. Okhravi, "Reliability of wearable sensors to detect agitation in patients with dementia: A pilot study", in *Proceedings of the 2018 10th International Conference on Bioinformatics and Biomedical Technology*, pp. 73-77, 2018.
- [18] J. Gong, K. M. Rose, I. A. Emi, J. P. Specht, E. Hoque, D. Fan, S. R. Dandu, R. F. Dickerson, Y. Perkhounkova and J. Lach, "Home wireless sensing system for monitoring nighttime agitation and incontinence in patients with alzheimer's disease", in *Proceedings of the conference on Wireless Health*, pp. 1-8, 2015.
- [19] S. S. Khan, T. Zhu, B. Ye, A. Mihailidis, A. Iaboni, K. Newman, A. H. Wang and L. S. Martin, "Daad: A framework for detecting agitation and aggression in people living with dementia using a novel multimodal sensor network", in *2017 IEEE International Conference on Data Mining Workshops (ICDMW)*, pp. 703-710, IEEE, 2017.
- [20] S. S. Khan, S. Spasojevic, J. Nogas, B. Ye, A. Mihailidis, A. Iaboni, A. Wang, L. S. Martin and K. Newman, "Agitation detection in people living with dementia using multimodal sensors", in *2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pp. 3588-3591, IEEE, 2019.
- [21] S. S. Khan, T. Sooriyakumaran, R. K. Brewer, S. Spasojevic, B. Ye, K. Newman, A. Iaboni and A. Mihailidis, "Tracking agitation in people living with dementia in a care environment", in *Canadian Conference on AI*, 2021.
- [22] オムロン, "環境センサ (USB 型) 2JCIE-BU", <https://www.fa.omron.co.jp/products/family/3724/>.
- [23] TOPPAN, "非接触型センサ センシングウェーブ", <https://forest.toppan.co.jp/products/sensingwave.html>.
- [24] KONICA MINOLTA, "HitomeQ", <https://www.konicaminolta.com/jp-ja/care-support/index.html>.
- [25] 日本 GARMIN, "GARMIN", <https://www.garmin.co.jp/>.