

環境・バイタルセンサデータにより BPSD 予測性能向上のための BPSD 発症時期分析

新見龍之慎[†] 常盤 直也^{††} 柴田 純一^{†††} 鈴木 利一^{†††} 柏木 岳彦[†]
馬上 竜也^{††} 嘉村 魁人[†] 大沼飛宇多[†] 田野 俊一[†] 南 泰浩[†]

[†] 電気通信大学 〒182-8585 東京都調布市調布ヶ丘1丁目5-1
^{††} 株式会社ラクスパートナーズ 〒160-0022 東京都新宿区新宿4-3-25 TOKYU REIT ビル 8F
^{†††} 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: †{s2331080,k2331041,o2010123}@gl.cc.uec.ac.jp, ††{ta003653,ma004291}@edu.cc.uec.ac.jp,
†††{Shibata,t-suzuki}@intelligent-design.co.jp, ††††{t.kashiwagi,tano}@uec.ac.jp,
††††minami.yasuhiro@is.uec.ac.jp

あらまし 認知症患者が発症する行動・心理症状（BPSD）は、介護者の大きな負担となるだけでなく、患者本人の生活の質にも影響を与えている。BPSD を事前に予測し、症状へ対処が可能となれば介護者の負担を軽減できる。先行研究として複数の介護施設から収集した環境・バイタルセンサデータに基づき、機械学習を利用した BPSD 予測を行った。しかし未だ PR 曲線の Average Precision が低い。そこで本研究では、BPSD 予測の高精度化に向けてデータ解析を行なった。解析結果から特定の症状には 24 時間周期があることを確認した。この結果は、機械学習手法による BPSD 発症予測の可能性を示すものである。

キーワード 認知症, BPSD, 睡眠, 周期性, 機械学習

Analysis of BPSD onset time to improve BPSD prediction performance with environmental and vital sensor data

Tatsunoshin SHIMMI[†], Naoya TOKIWA^{††}, Junichi SHIBATA^{†††}, Toshikazu SUZUKI^{†††}, Takehiko KASHIWAGI[†], Tatsuya MOE^{††}, Kaito KAMURA[†], Hyuta ONUMA[†], Shunichi TANO[†], and Yasuhiro MINAMI[†]

[†] The University of Electro-Communications 1-5-1 Chofugaoka, Chofu, Tokyo 182-8585, Japan
^{††} RAKUS Partners Co., Ltd. TOKYU REIT Bldg. 8F, 4-3-25 Shinjuku, Shinjuku-ku, Tokyo 160-0022, Japan
^{†††} † iD corporation Goryokaku Bldg.2F, 6-10 Honcho, Hakodate, Hokkaido 040-0011, Japan
E-mail: †{s2331080,k2331041,o2010123}@gl.cc.uec.ac.jp, ††{ta003653,ma004291}@edu.cc.uec.ac.jp,
†††{Shibata,t-suzuki}@intelligent-design.co.jp, ††††{t.kashiwagi,tano}@uec.ac.jp,
††††minami.yasuhiro@is.uec.ac.jp

Abstract Behavioral and psychological symptoms of dementia (BPSD) that develop in patients with dementia not only impose a heavy burden on caregivers, but also affect the quality of life of the patients themselves. If BPSD can be predicted in advance and symptoms can be dealt with, the burden on caregivers can be reduced. In a preliminary experiment, we predicted BPSD using machine learning based on environmental and vital sensor data collected from multiple nursing homes. However, the Average Precision of the PR curve is still low. In this study, we analyzed data to improve the accuracy of BPSD prediction. The data analysis confirms that certain symptoms have a 24-hour cycle. The results show the possibility of predicting the onset of BPSD using machine learning methods.

Key words Dementia, BPSD, Sleep, Periodicity, Machine learning

1. はじめに

認知症は、認知機能の低下による日常生活全般に支障が出てくる症状の疾患であり、脳の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ることによって生じる [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]。2012 年時点で、日本における 65 歳以上の認知症の患者数は 462 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おり、認知症に向けた取組が今後さらに重要となる。これに対し、2019 年、厚生労働省は介護人材の不足が 2023 年度には 22 万人、2040 年度までには、69 万人に達すると予測していた [2]。高齢社会の日本において、この介護士の不足は速やかに取り組むべき重要な課題であり、この問題がもたらす介護士への負荷の軽減は喫緊の課題である。

認知症の症状は、中核症状と、周辺症状に大別できる。近年、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]~[5]。

このような症状として、徘徊、妄想、大声、失禁、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者の大きな負担となるだけでなく、患者本人の生活の質にも影響を与えている。もし、BPSD を事前に予測でき、その個別の症状に対し対処が可能となれば、周りで介護する介護者の負担を軽減できる可能性がある。

BPSD 予測モデル構築に際し、環境・バイタルセンサを用い収集したデータを使用し機械学習の手法である勾配ブースティング木を利用して BPSD を予測する実験を行った。しかし、現状の結果では不十分であり実用化に向けてさらに性能を向上させる必要がある。

そこで本研究では、BPSD 予測の性能向上の可能性を調査するため、BPSD 発症タグの情報を使用しデータ解析を行う。

これまで、類似研究にて、ウェアラブルデバイスを使用し、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]。対象者別の状態を把握する研究として、認知症患者のストレス度をリストバンドセンサを利用し、直接推定する手法が提案されている [16]。[17] 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。さらに [18] では、多くの環境・バイタルセンサデータと多くの実験参加者を用い、機械学習の手法である勾配ブースティング木を利用して BPSD 予測の可能性を示した。

これらの研究は、センサデータを用いた症状の推定・予測の可能性を示したが、実用化を考慮すると性能は未だ不十分である。

我々の研究では、BPSD 発症タグと時刻の関係性を明らかにし、機械学習手法を利用した BPSD 予測の高性能化の余地を検証する。

2. データ収集環境

倫理審査実施後、複数の介護施設に依頼し、図 1 に示すデータ収集システムを構築した。また、入居者だけでなくその家族に実験参加への承諾を得た後、入居者に実験に参加してもらった。

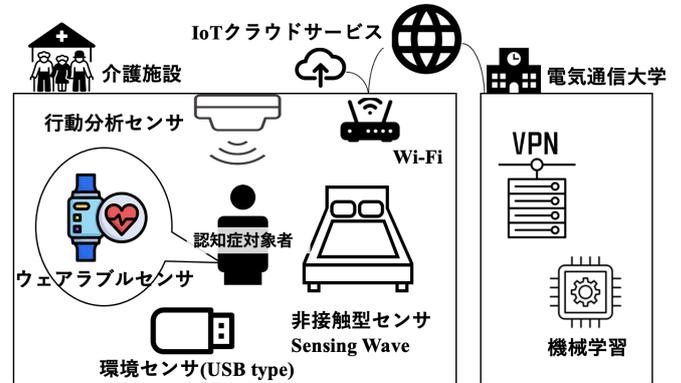


図 1 データ収集システム全体図

実験参加者の部屋には、オムロン社の環境センサ (USB 型) 2JCIE-BU [19]、TOPPAN の非接触型センサのセンシングウェーブ [20]、KONICAMINOLTA の HitomeQ ケアサポート行動分析センサ [21] を設置した。さらに、一部の実験参加者はウェアラブルセンサとして GARMIN [22] を装着した。これらのセンサデータはクラウドサービスを通じて電気通信大学に送信され、VPN とセンサクラウドサービスを介してデータが蓄積されている。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。

3. 使用したデータの詳細

データを取得した時期、施設、実験参加者の人数、および BPSD の総数を表 1 に示す。

表 1 データの詳細

データの取得期間	2022.08.01~2023.08.30
実施施設数	3 施設
対象者数	60 名
対象者基準	45 日以上データを取得できたユーザ
BPSD 発症総数	2258

また、利用したデータの種類とその粒度を表 2 示す。センサのデータ取得間隔はセンサにより異なるため、モデルの学習時を考慮し、1 分間隔以下の粒度のデータは 1 分で平均化している。

4. BPSD 予測

先行研究において行なった BPSD 予測の学習・テストデータは以下の方法で作成した。特徴量として、センサ値 $s(t, j)$ 、すべてのセンサにおける短期・長期特徴量 $\frac{1}{n} \sum_{k=0}^n s(t-k, j)$ 。また、時間情報特徴量 ($hour_{cos}, hour_{sin}$) = ($\cos(\pi x/12), \sin(\pi x/12)$) を追加した。ただし、 $x = 0, 1, \dots, 23$ とする。センサ値には環

表2 データの種類

センサ名	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 社環境センサ		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
Pocket CO ₂		二酸化炭素濃度	1s
コニカミノルタ社 行動分析 センサ	behavioral 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 behavioral 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
TOPPAN 社 非接触型センサ		ストレス値	5s
		心拍	5s
		呼吸数	5s
		体動	5s
		入床フラグ	5s
		離床フラグ	5s
		入眠フラグ	5s
		覚醒フラグ	5s
		睡眠波形値	5s
	寝返りフラグ	5s	

境・バイタルデータだけでなく非接触型センサで収集した睡眠データも含んでいる。そして、モデルは勾配ブースティング決定木をベースとした CatBoost を使用した。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 発症時刻を使用した。また、モデルの汎化性能を評価するために、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。最も精度が高かった PR 曲線の結果を図2に示す。この研究結果の詳細は First IEEE International Conference on AIMHC にて発表された大沼ら著の論文[18]に記載されている。

最も精度が高い PR 曲線の Average Precision が 0.3961 であり、この BPSD 予測モデルでは性能が不十分である。また、CatBoost の PredictionValuesChange 指標を用い特徴量重要度を調査した。結果から BPSD 発症予測には睡眠と長期間蓄積データが関係していることを示した。そこで性能を上げるための基礎検討として BPSD 発症タグを用い解析を行う。

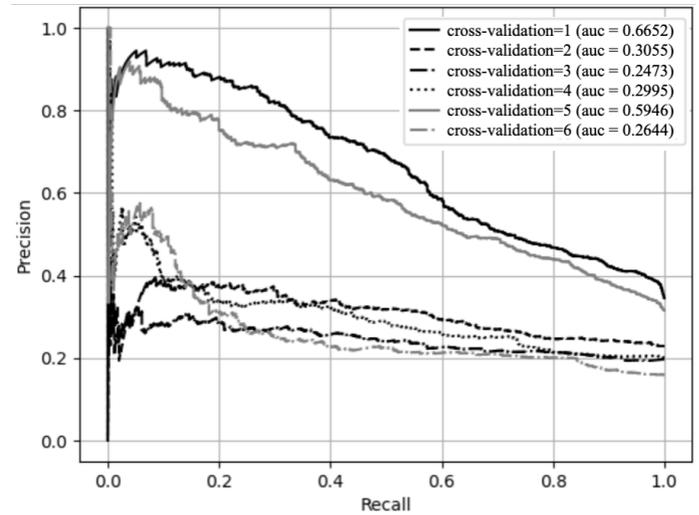


図2 先行研究における最も正確なモデルの PR 曲線

5. データの解析

先行研究[18]において、BPSD 発症予測には睡眠と長期間蓄積データが関係していることを示した。つまり時刻に関するデータが BPSD 発症予測には重要であると考えられる。そこで、今回は先行実験にて学習・テストの正解ラベルとして使用した、介護士が BPSD 発症を確認したのちに BPSD 発症時刻を記録した BPSD タグを用いた。このタグは、先行実験の学習・テストの正解ラベルとして使用したものである。時刻と BPSD 発症の関係性を明らかにするため、時刻における BPSD 発症数と BPSD 発症の周期を調査した。

5.1 時刻における BPSD 発症数

時刻における BPSD 発症数は、ある時刻における BPSD 発症数の総数である。例えば、20:00 の発症総数は 20:00~20:59 までの各患者の発症数の和である。時刻における BPSD 発症数の結果を図3に示す。図より 9:00~11:00 が他の時間帯に比べ発症数が多いことがわかる。これは、睡眠不足等による体内時計の乱れなどの前日の要因が翌日の BPSD に関係している可能性

を示した。

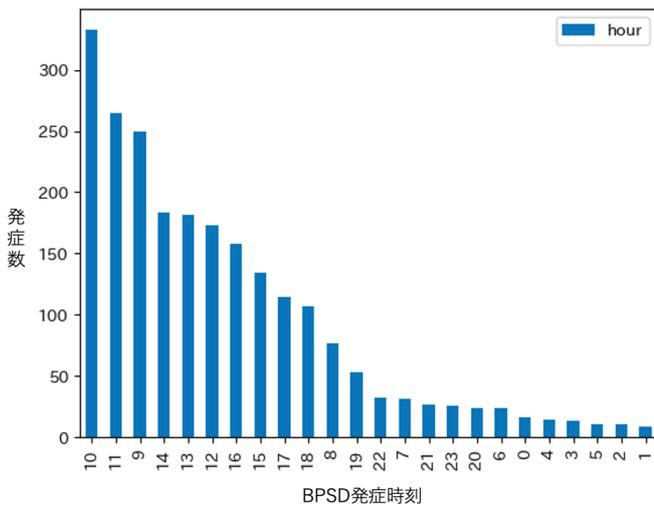


図3 時刻における BPSD 発症数

5.2 BPSD 発症の周期性

BPSD 発症の周期は、各患者のある BPSD 発症から次の発症までの時刻の差を時間 (hour) に直したものである。ただし、小数点以下は python の `round()` 関数を用いて丸め込みをした。

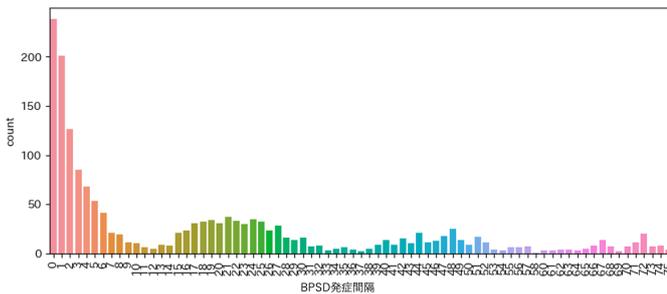


図4 全ての BPSD 発症間隔

5.2.1 全症状の発症間隔

BPSD の全症状の結果を図4に示す。図より、穏やかな24時間の周期があることが分かる。これは、BPSD 発症の要因が時刻や照度等の周期的に起こるものと関係している可能性が高いことを示している。

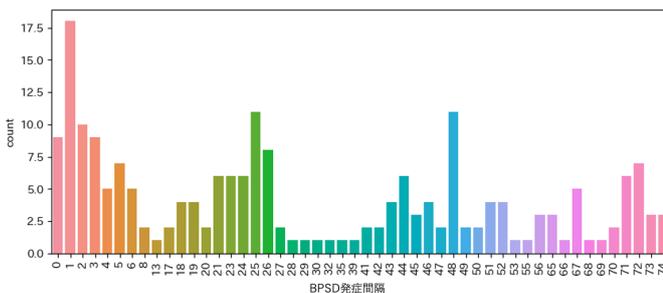


図5 個別症状の発症間隔：傾眠傾向

5.2.2 個別症状の発症間隔：周期あり

個別症状の発症間隔に周期性が見られた傾眠傾向と大声の症状の結果を図5, 6に示す。図からある特定の症状は発症が周期的であることが分かる。この結果より、介護士が記録を行う時間などのバイアスが含まれる可能性もあるが、BPSD の個別症状においても周期性がある可能性を示すことができた。

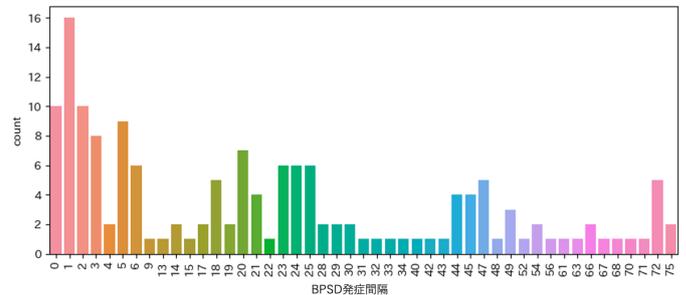


図6 個別症状の発症間隔：大声

5.2.3 個別症状の発症間隔：周期なし

個別症状の発症間隔に周期性が見られない暴行の症状の結果を図7に示す。

図から周期性と無関係と予見できる症状については、BPSD の発症に周期が見られないことが分かる。ただし、BPSD 発症総数は 2258 件であり症状別に解析するにはデータが不十分なため、今後より多くのデータを用いた解析が必要である。

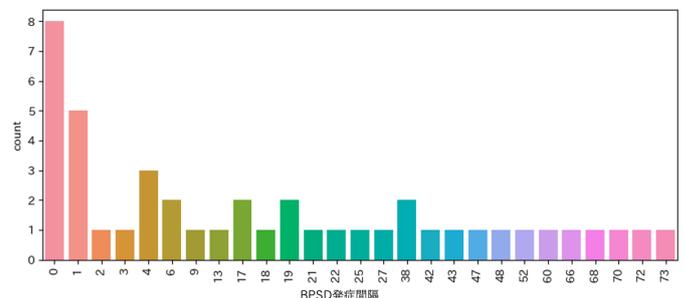


図7 個別症状の発症時間間隔：暴行

6. まとめ

本研究では、介護施設で収集した環境・バイタル情報データに基づき、認知症の方が発症する行動・心理症状 (BPSD) を予測するモデルの性能向上を踏まえて、BPSD 発症の周期性の解析を行なった。結果としては、BPSD 発症には 24 時間の周期があり、24 時間のうちで 9:00~11:00 での発症が多く見られた。この結果から、より高精度な BPSD 予測モデル作成の可能性を示せた。今後は BPSD の症状別のより正確な周期の分析を行うとともに、BPSD 発症周期と発症時刻を考慮した BPSD 予測モデルの構築を進めていく。

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.
- [2] 厚生労働省, "第8期介護保険事業計画に基づく介護職員の必要数について", <https://www.mhlw.go.jp/content/12004000/000804129.pdf>.
- [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.S3, 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, "Non-linear 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. Valembos, 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 mobilityrelated 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. Kompatiaris, 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] 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.
- [18] H. Onuma, N. Tokiwa, J. Shibata, T. Suzuki, T. Kashiwagi, T. Moe, K. Kamura, T. Shinmi, S. Tano and Y. Minami, "Prediction of BPSD using environmental and vital sensor data", in *Proceedings of 2024 IEEE First International Conference on ARTIFICIAL INTELLIGENCE MEDICINE, HEALTH, and CARE*, pp.52-59, 2024.
- [19] オムロン, "環境センサ (USB 型) 2JCIE-BU", <https://www.fa.omron.co.jp/products/family/3724/>.
- [20] TOPPAN, "非接触型センサ センシングウェブ", <https://forest.toppa.co.jp/products/sensingwave.html>.
- [21] KONICA MINOLTA, "HitomeQ", <https://www.konicaminolta.com/jp-ja/caresupport/index.html>.
- [22] 日本 GARMIN, "GARMIN", <https://www.garmin.co.jp/>.