

腕時計型ウェアラブルデバイスの生体情報を用いた個人識別の評価 Evaluation of Individual Identification Using Bio-information of Wristwatch-type Wearable Device

吉田 豊[†] 金子 格[†] 湯田 恵美[†]

Yutaka Yoshida Itaru Kaneko Emi Yuda

1. はじめに

近年、バイオセンサーを備えたウェアラブルデバイスは急速に進歩し、人気が高まっている。市販の安価なウェアラブルデバイスでも、脈拍、生体加速度などの様々な生体情報を非侵襲的に取得できるようになった。これらの生体情報は通常、ユーザーが自身の健康管理のために利用する。しかし、これらの生体情報をデータベース化して共有すれば、公衆衛生の向上や医療に役立つ情報を得ることができるようになる。その際、プライバシーを考慮する必要がある。各国にはプライバシーの保護を目的とした法制度があり、その定義は国によって異なる。日本では、2017年に全面施行された改正個人情報保護法により、DNAや顔、虹彩など個人を識別できる生体情報が個人識別コードとみなされている。たとえば、歩行パターンや音声信号から個人識別できる可能性のある[1, 2]。心電図を利用した生体個人認証システムもある[3, 4]。血液型は個人を特定するものではないため、個人識別コードとはみなされない。同様に、体の姿勢や身体活動は生体加速度から推測できますが[5, 6]、これらは個人識別コードとはみなされていない。

現在、指紋や静脈など様々な生体認証を利用した個人認証システムの研究が進められている。一方、脈拍や生体加速度などの生体情報は常に変化しており、これらの瞬時値からでは個人の特定が困難である。しかし、脈拍や生体加速度の時間変化には個人特有のゆらぎや姿勢変化が含まれており、個人を特定できる可能性があります。ウェアラブルデバイスによる個人認証の可能性が解明されれば、将来的にウェアラブルデバイスの生体情報をデータベースとして収集、共有する際に有用な知見が得られる可能性もある。

そこで本研究では、腕時計型ウェアラブルデバイスから得られる脈拍、生体加速度、皮膚温度などの複数の生体情報を機械学習により解析し、個人を識別できるか否かを検証した。

2. 方法

2.1 測定デバイス

図 1 に実験で用いた腕時計型ウェアラブルデバイス (Silmeew22, TDK 社, 東京) を示す[7]。サイズは約 52mm × 24.5mm × 13.5mm, 重量は約 26g, 連続稼働時間は約 10 日である。本機は脈拍センサ, 3 軸加速度センサ, 紫外線センサ, 温度センサを搭載している。脈波検出では緑色

LED を使用し, サンプリング周波数 20Hz で容積脈波を測定する。3 軸加速度センサのサンプリング周波数は 20.5 Hz で, 最大 $\pm 4 \text{ G}$ まで測定可能。3 軸加速度の方向は直立姿勢の場合, 鉛直下向きが X 方向, 前方が Y 軸, ディスプレイ面に対して垂直方向が Z 軸と設定されている。紫外線センサはディスプレイに当たる紫外線量を測定し, UV 指数が算出される。温度センサはデジタル半導体温度センサを使用し, 手首の皮膚温度を $-10^{\circ}\text{C} \sim 45^{\circ}\text{C}$ の範囲で測定可能。また, ディスプレイに会話量センサも搭載されており, 人の声を検出して会話時間も測定される。

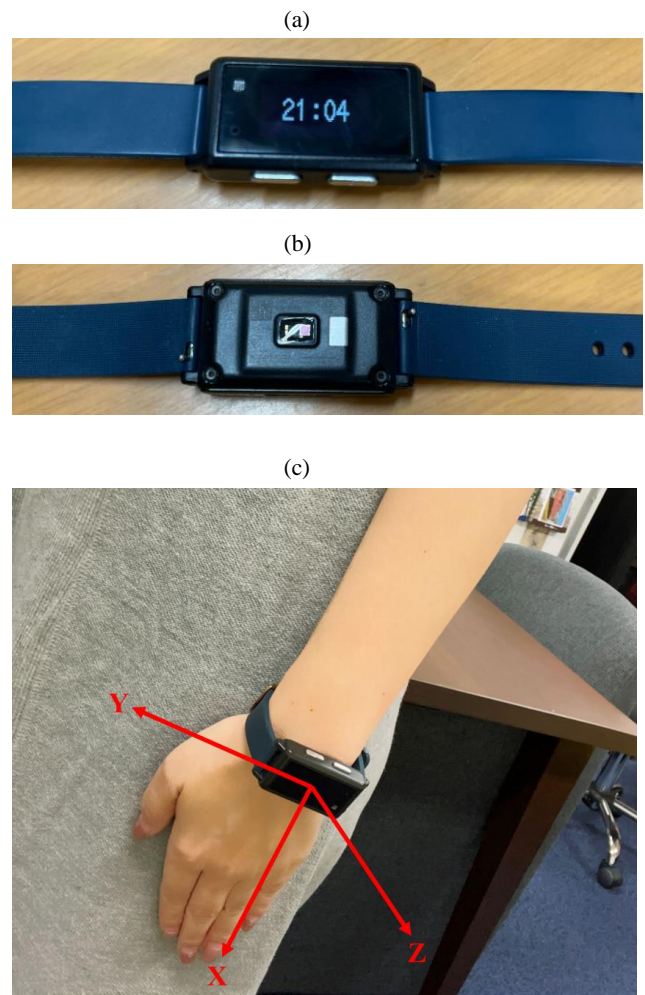


図 1. 腕時計型ウェアラブルデバイス (Silmeew22)
(a) ディスプレイ面, (b) センサー部, (c) 3 軸加速度の方向

[†] 東北大学大学院 情報科学研究科

〒980-8579 仙台市青葉区荒巻字青葉 6-3-09

Graduate School of Information Sciences, Tohoku University
6-3-09 Aoba, Aramaki-aza Aoba-ku, Sendai 980-8579

3.2 生体情報の測定

SilmeeW22 から取得される生体情報は、歩数 (Steps;ST[number of steps])、身体活動量 (Energy Expenditure;EE[kcal])、活動タイプ (Activity Type;AT[type])、体動変化 (Body Motion;BM[type])、睡眠状態 (Sleep State;SS[type])、皮膚温度 (Skin Temperature;SKT[°C])、平均脈拍数 (Pulse Rate;PR[bpm])、紫外線量指数 (UV Index;UV[level])、会話時間 (Conversation Time;CT[min])、脈拍間隔時間 (Pulse Rate Interval;PPI[ms])、X 軸加速度 (X-Acceleration;XA[G])、Y 軸加速度 (Y-Acceleration;YA[G])、Z 軸加速度 (Z-Acceleration;ZA[G])、3 軸合成加速度 (3-Axis Composite Acceleration;3ACA[G]) である。AT は安静、歩行、走行などの 5 段階評価、BM は体動変化の有無を 2 段階で評価、SS は睡眠の有無を 2 段階で評価される。3ACA は XA, XB, XZ の 2 乗和の平方根で算出される。これらの 14 種類の生体情報は 1 分ごとに算出される。

3.3 対象と実験プロトコル

対象は健康者 8 人(女性 1 人, 64±13 歳)で、実験前に本研究の趣旨を説明して、実験参加の同意を得た。本研究は、東北大学データ駆動科学・人工知能センター倫理委員会によって審査および承認され (No. 2021-4 2021 年 9 月 11 日承認, No.2022-4 2022 年 1 月 7 日承認)。

午前 9 時から午後 4 時の間で、連続 4 時間自由行動下で生体情報を測定した。この測定を 1 人につき 4 回 (4 日分) 行った。腕時計型ウェアラブルデバイスは左手首に装着した。測定のウォッシュアウト期間は 1 週間以上とした。

3.4 機械学習による分析

機械学習はオープンデータサイエンス プラットフォームの Anaconda から取得した Spyder(エディター, Ver 3.2.8)により Python (Ver 3.6.5) で実行した。機械学習ライブラリは scikit-learn を用いた[8]。機械学習に用いる分類器はランダムフォレスト(Random forest;RF)、サポートベクターマシン (Support-vector machine;SVM)、k 近傍法 (K-nearest neighbor algorithm;KNN)、k 平均法(K-means;K-M)、多層パーセプトロン(Multi-layer Perceptron;MLP)、AdaBoost(ADB)、二次判別分析(Quadratic Discriminant Analysis;QDA)、単純ベイズ(Naive Bayes;NAB)を用いた。

特徴量は 3.2 節で述べた 14 種類の生体情報である。実験で測定されたデータは 8 人分の 4 日間、すなわち 32 ケースである。1 ケースのデータ長は 240 分であるが、測定精度が保てなくデータに欠損値が生じたため、全てのケースのデータ長を 210 分に調整した。図 2 に 14 種類の生体情報時系列の 1 ケースを示す。1 ケース 210 分のデータを奇数分と偶数分に分けて、奇数分 105 個を学習データとし、偶数分 105 個をテストデータとした。従って、学習データのサンプル数は 8 名×4 日×105 の 3360 個であり、同様にテストデータのサンプル数も 3360 個となる。

表 1 に各分類器のハイパーパラメータを示す。RF の $n_estimators$, max_depth はそれぞれ決定木の数と決定木の深さの最大値である。KNN の $n_neighbors$ は k の値であり、 k の値は奇数とした。MLP の max_iter は反復最大回数、ADB の $n_estimators$ はブースティングが終了する推定器の最大数。K-M, QDA, NAB のハイパーパラメータはデフォルト値とした。ハイパーパラメータをグリッドサーチにより変更し、最適なハイパーパラメータにおける正答率 (Accuracy)、再現率(Recall)、適合率(precision) および F 値

(F-score)を算出した。これら 4 つの指標を識別精度とした。F-score は Recall と Precision の調和平均である。Accuracy, Recall, Precision, F-score は以下の(1)から(4)式で定義される。ここで、TP, TN, FP, FN はそれぞれ真陽性、真陰性、偽陽性、偽陰性である。

$$Accuracy = (TP + TN) / (TP + TN + FP + FN) \quad (1)$$

$$Recall = TP / (TP + FN) \quad (2)$$

$$Precision = TP / (TP + FP) \quad (3)$$

$$F\text{-score} = 2 * Recall * Precision / (Recall + Precision) \quad (4)$$

また、RF の識別において、特徴量どの程度寄与しているかを評価するために、scikit-learn の重要度関数 (importance function)を使用して特徴量の重要度を計算した。

表 1. 各分類器のハイパーパラメータ

Classifier	Hyperparameter	
RF	$n_estimators$	16, 32, 64, 128, 256, 512, 1024
	max_depth	16, 32, 64, 128, 256, 512, 1024
	$criterion$	gini
SVM	C	0.001, 0.01, 0.1, 1, 10, 100, 1000
	γ	0.001, 0.01, 0.1, 1, 10, 100, 1000
KNN	$n_neighbors$	3, 5, 7, 9, 11, 13, 15, 17, 19, 21
K-M	default	
MLP	α	0.001, 0.01, 0.1, 1
	max_iter	16, 32, 64, 128, 256, 512, 1024
ADB	$n_estimators$	16, 32, 64, 128, 256, 512, 1024
	$algorithm$	SAMME.R
QDA	default	
NAB	default	

3. 結果

表 2 に各分類器における識別精度を示す。識別精度が高い分類器順に並べた。Recall, Precision および F-score は 8 名の平均値と標準偏差である。8 つの分類器の中で RF の識別精度が最も高くなった。また、SVM と QDA 以外の分類器は Recall と Precision が大体同じ値になった。

表 3-10 に 8 種類の分類器から算出したハイパーパラメータが最適値における Confusion Matrix を示す。また、全対象の Recall と Precision も示した。行が真値、列が識別値である。TP を太文字で示した。従って、行で見た場合、TP 以外の値は FN、列で見た場合、TP 以外の値は FP となる。また、特定の対象者以外の TP は特定の対象者から見ると TN となる。従って、表 2 の Accuracy は各被験者の TP の

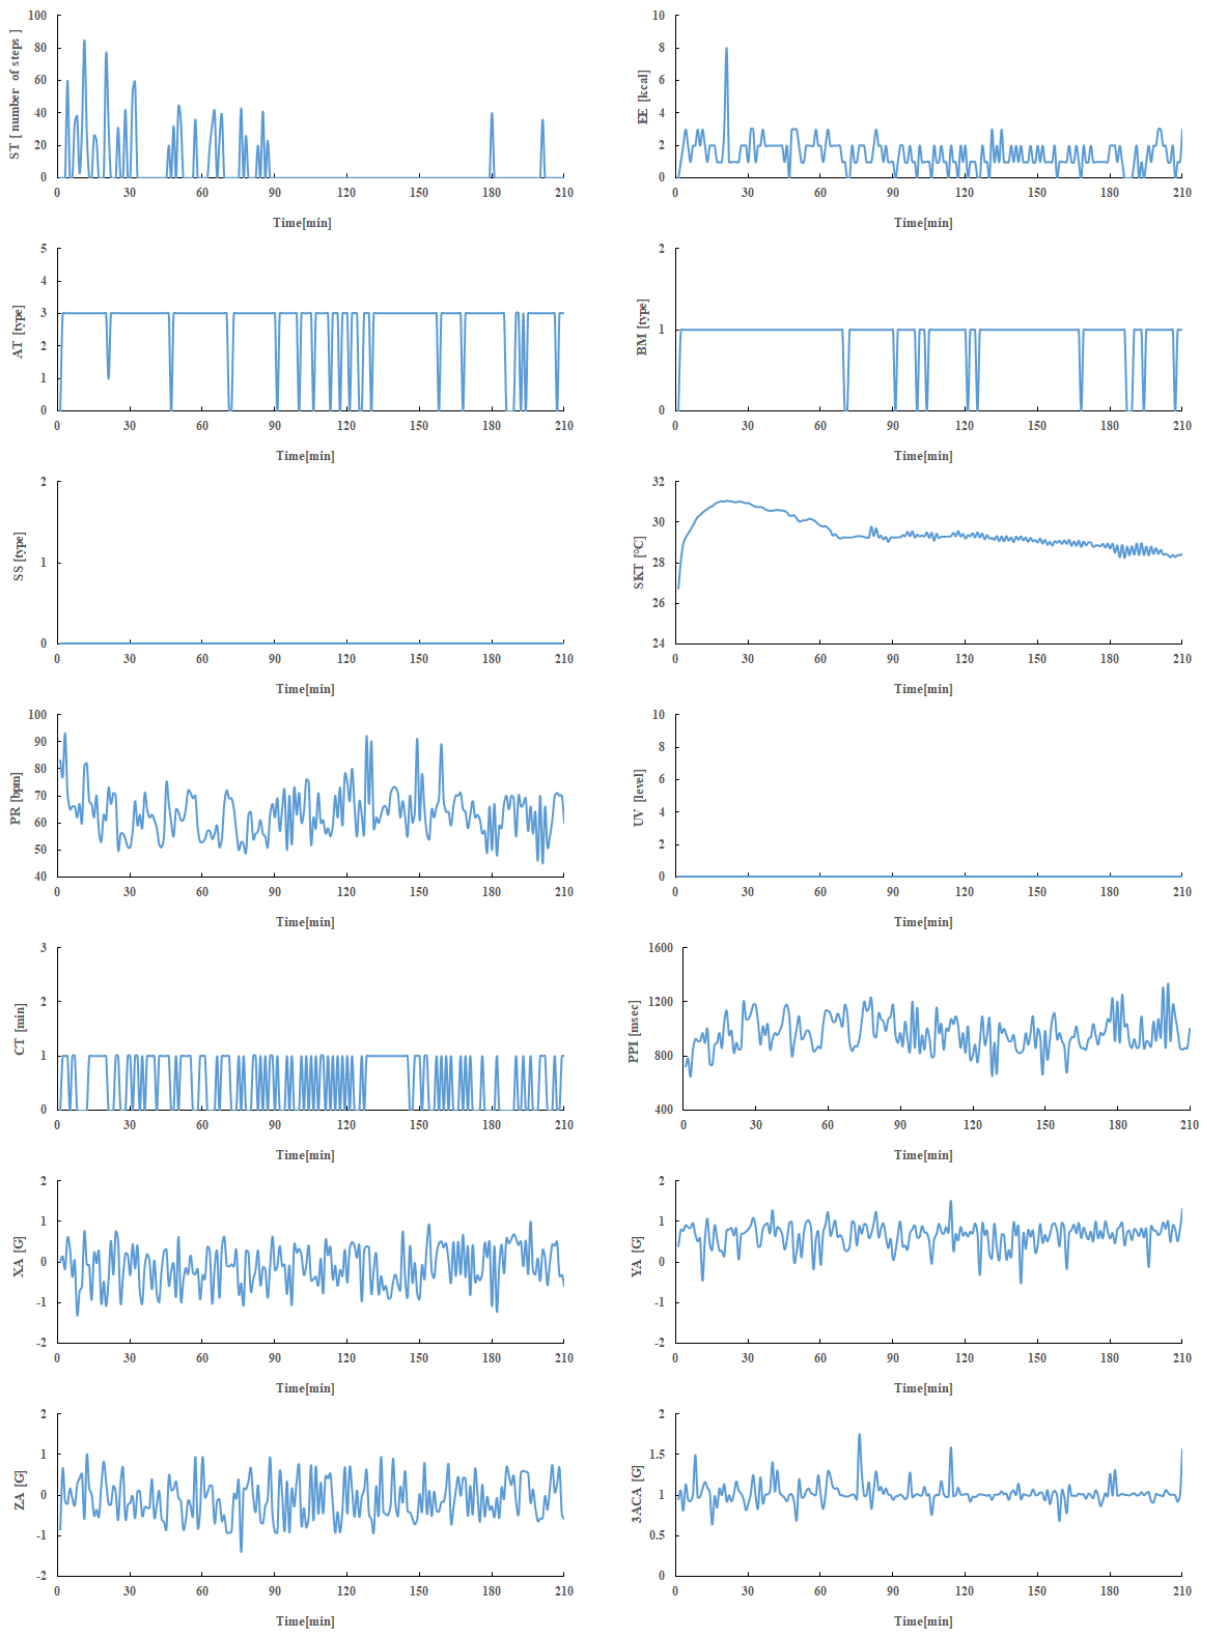


図 2. 腕時計型ウェアラブルデバイスから取得した生体情報時系列

表 2. 各分類器の識別精度

Classifier	Accuracy	Recall	Precision	F-Score
RF	0.684	0.684 ± 0.100	0.685 ± 0.082	0.684 ± 0.082
NAB	0.461	0.460 ± 0.196	0.471 ± 0.114	0.490 ± 0.162
KNN	0.382	0.382 ± 0.070	0.382 ± 0.019	0.382 ± 0.019
MLP	0.374	0.374 ± 0.134	0.369 ± 0.057	0.363 ± 0.065
ADB	0.320	0.320 ± 0.293	0.347 ± 0.124	0.202 ± 0.107
SVM	0.251	0.251 ± 0.254	0.524 ± 0.187	0.339 ± 0.187
K-M	0.181	0.181 ± 0.117	0.183 ± 0.049	0.120 ± 0.047
QDA	0.164	0.163 ± 0.164	0.232 ± 0.078	0.149 ± 0.108

表 6. MLP の Confusion Matrix

Subject	SubA	SubB	SubC	SubD	SubE	SubF	SubG	SubH	Recall
SubA	196	48	16	13	7	36	63	41	0.467
SubB	25	247	28	43	14	38	17	8	0.588
SubC	40	90	103	58	26	33	33	37	0.245
SubD	24	72	46	154	21	37	15	51	0.367
SubE	59	25	20	39	113	62	47	55	0.269
SubF	50	54	24	51	35	105	61	40	0.250
SubG	55	32	11	17	15	38	231	21	0.550
SubH	74	37	43	26	38	44	52	106	0.252
Precision	0.375	0.408	0.354	0.384	0.420	0.267	0.445	0.295	

表 3. RF の Confusion Matrix

Subject	SubA	SubB	SubC	SubD	SubE	SubF	SubG	SubH	Recall
SubA	305	2	11	0	8	15	45	34	0.726
SubB	0	359	12	35	6	3	0	5	0.855
SubC	3	12	281	23	47	25	2	27	0.669
SubD	0	60	10	315	21	7	0	7	0.750
SubE	4	7	12	22	283	51	8	33	0.674
SubF	15	20	27	32	46	243	10	27	0.579
SubG	40	1	5	2	21	22	301	28	0.717
SubH	32	20	45	12	65	23	12	211	0.502
Precision	0.764	0.746	0.697	0.714	0.569	0.625	0.796	0.567	

表 7. ADB の Confusion Matrix

Subject	SubA	SubB	SubC	SubD	SubE	SubF	SubG	SubH	Recall
SubA	335	3	0	1	0	2	76	3	0.798
SubB	0	295	13	94	9	5	1	3	0.702
SubC	227	10	31	50	4	8	49	41	0.074
SubD	23	107	11	228	12	9	5	25	0.543
SubE	232	7	3	57	22	10	74	15	0.052
SubF	225	29	12	50	5	18	55	26	0.043
SubG	297	2	0	3	0	2	105	11	0.250
SubH	209	22	18	47	8	8	66	42	0.100
Precision	0.216	0.621	0.352	0.430	0.367	0.290	0.244	0.253	

表 4. NAB の Confusion Matrix

Subject	SubA	SubB	SubC	SubD	SubE	SubF	SubG	SubH	Recall
SubA	174	3	9	0	30	22	175	7	0.414
SubB	0	234	39	98	27	22	0	0	0.557
SubC	18	8	206	54	51	55	16	12	0.490
SubD	2	51	48	236	64	11	0	8	0.562
SubE	7	9	21	15	245	63	56	4	0.583
SubF	35	14	49	41	70	113	92	6	0.269
SubG	35	2	3	0	47	18	310	5	0.738
SubH	20	20	50	30	105	41	127	27	0.064
Precision	0.598	0.686	0.485	0.498	0.383	0.328	0.399	0.391	

表 8. SVM の Confusion Matrix

Subject	SubA	SubB	SubC	SubD	SubE	SubF	SubG	SubH	Recall
SubA	127	3	3	3	246	9	11	18	0.302
SubB	2	60	4	9	318	17	2	8	0.143
SubC	2	20	22	10	354	6	3	3	0.052
SubD	5	9	3	72	302	12	5	12	0.171
SubE	3	3	0	4	378	16	7	9	0.900
SubF	6	5	3	5	319	62	10	10	0.148
SubG	4	4	3	3	309	15	65	17	0.155
SubH	5	1	1	3	335	10	9	56	0.133
Precision	0.825	0.571	0.564	0.661	0.148	0.422	0.580	0.421	

表 5. KNN の Confusion Matrix

Subject	SubA	SubB	SubC	SubD	SubE	SubF	SubG	SubH	Recall
SubA	202	41	34	13	28	32	33	37	0.481
SubB	43	209	75	25	16	33	8	11	0.498
SubC	33	92	147	52	45	17	20	14	0.350
SubD	37	57	53	172	25	31	17	28	0.410
SubE	35	22	25	47	157	39	45	50	0.374
SubF	29	54	29	53	51	133	45	26	0.317
SubG	50	46	23	29	49	48	142	33	0.338
SubH	59	36	27	45	53	34	44	122	0.290
Precision	0.414	0.375	0.356	0.394	0.370	0.362	0.401	0.380	

表 9. K-M の Confusion Matrix

Subject	SubA	SubB	SubC	SubD	SubE	SubF	SubG	SubH	Recall
SubA	72	39	121	63	56	2	64	3	0.171
SubB	20	136	172	11	61	7	1	12	0.324
SubC	60	107	153	22	20	5	50	3	0.364
SubD	72	98	69	48	26	7	95	5	0.114
SubE	128	0	28	39	75	13	128	9	0.179
SubF	120	42	51	77	65	13	46	6	0.031
SubG	86	28	34	83	74	12	100	3	0.238
SubH	91	55	36	54	38	10	126	10	0.024
Precision	0.111	0.269	0.230	0.121	0.181	0.188	0.164	0.196	

合計を全体のデータ数で除して算出した。図3にRFを用いた識別における特徴量の重要度の結果を示した。影響度が最も高かった特徴量はSKTで影響度が39.8%、次に高かった特徴量はPRで15.6%となった。これ以降はYA(13.5%)、PPI(10.1%)、XA(10.3%)、ZA(9.5%)となり、これらの特徴量が全体の約81.8%を占めた。

4. 考察

本研究では、腕時計型ウェアラブルデバイスから得られる生体情報へ機械学習を用いて個人識別が可能か否かを検証した。

SVMはすべての対象者をSubEと誤識別される割合が多くなった。また、QDAもすべての対象者をSubGやSubHと誤識別される割合が多くなり、特にSVMはPrecisionに比べてRecallが大幅に減少して識別に偏りが生じた。一方、最も精度が高かったRFはすべての対象者でRecallとPrecisionが0.5以上あり、SVMやQDAのように極端な識別の偏りはなかった。RFにおいてSubBは、Recallが0.855、Precisionが0.746であるため、8名の対象者の中で最も識別されやすいと考えられる。この実験では8名の識別となり、偶然識別される確率が12.5%であるため、RFのAccuracy(0.684)は偶然に対して約5.5倍の識別力となる。

表10. QDAのConfusion Matrix

Subject	SubA	SubB	SubC	SubD	SubE	SubF	SubG	SubH	Recall
SubA	84	42	0	0	34	2	81	177	0.200
SubB	28	34	1	2	35	2	79	239	0.081
SubC	47	49	5	2	20	3	114	180	0.012
SubD	29	36	3	6	16	2	110	218	0.014
SubE	47	31	3	1	53	6	116	163	0.126
SubF	60	36	2	1	30	10	68	213	0.024
SubG	30	18	1	3	21	0	156	191	0.371
SubH	34	23	0	4	29	7	123	200	0.476
Precision	0.234	0.126	0.333	0.316	0.223	0.313	0.184	0.127	

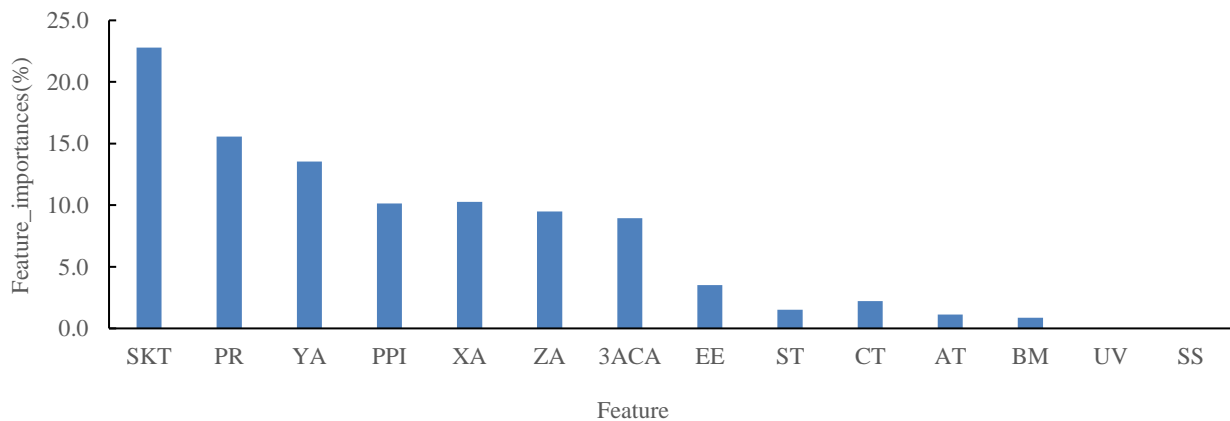


図3. RFの識別における特徴量の重要度

表3より、識別精度が最も高いRFでも誤識別があり、SubAとSubG、SubBとSubDは互いに誤識別が多かった。Recallの低いSubFとSubHは特定の対象者のみならず、複数の対象者に対して誤識別が多かった。RFで識別する際、SKT、PR、YA、PPI、XA、ZAの6つの生体情報が約81.8%影響を与える。これらの生体情報の中で最も影響度が高かったものがSKT(39.8%)であり、個人識別するための有力な生体情報である。また、3軸加速度は合成するよりも各軸を用いた方が識別に影響を与える。3軸の中でY軸加速度の影響度が高いため、自由行動下において対象者それぞれY軸の加速度に特徴的な変化があると考えられる。従って、生体情報の時間変化が類似した対象者同士は互いに誤識別される可能性があり、また、生体情報の個人内変動が大きい対象者は複数の対象者と誤識別されることが示唆される。本研究では、名前、年齢、性別などを含まない健常者を対象としたが、ここに心疾患が入ればその人を特定できる可能性は高くなる。何故なら、心疾患は徐脈、頻脈、期外収縮などが生じ、健常者とは異なる変動を示すからである。すなわち、特有な生体情報を持つ人は個人を特定できる可能性が高くなる。

個人情報をデータベースとして管理する場合、通常、データベースは何らかの識別子によって構造化される。この識別子に個人が関連付けられていれば、それは個人情報である。識別子が個人に関連付けられていなくても、別のデータベースと照合することで名前をたどることができる場合、これも個人情報である可能性が高い(容易照合性)。エンコードされた生体情報が個人情報を構成するかどうかを検討する際、識別子自体の性質を調べる必要があるため、汎用性や個人への到達可能性の観点から検討の方がよいと思われる。エンコードされた生体情報とは、主に遺伝情報、顔情報、指紋情報を指す。これらは、個人固有の身体的または行動的特徴であり、アプリケーションやその他のネットワークリソースにアクセスするために個人を認証するための生体認証技術として使用されている。しかし、心電図や脈波などの生体情報は、加齢や病気により時間の経過とともに波形が次々に変化することに留意する必要がある。

これまでの研究では、心電図、脳波、および生体加速度などの単一モダリティの生体情報を用いて個人識別を行うアプローチが多く見られた[9-17]。これらの研究はそれぞれの情報特性を活かし、高い識別精度を実現しているが、単一の生体情報に依存する方法であり、その情報が持つ特有の制約やノイズの影響を受けやすい問題がある。一方で、マルチモーダルな情報解析に関する研究では、音声や顔画像を用いた識別が主流となっている[18-25]。これらの先行研究のアプローチは、異なるモダリティの情報を統合することで識別精度を向上させる技術である。本研究は、これらの既存の研究とは異なり、ウェアラブルセンサから得られるマルチモーダルな生体情報を解析する点において新規性がある。

5. 結論

本研究では、腕時計型ウェアラブルデバイスから取得された生体情報が公開されて使用される場合のプライバシーリスクの不明点を明らかにするために、生体情報から個人を識別できる可能性を検証した。8種類の機械学習で識別精度を比較した結果、RFが最適であることがわかった。最適の場合でも、測定時における生体情報の時間変化が個人と他人で異なれば識別可能であり、類似していれば個人を特定し難い。また、特有な生体情報を持つ人は個人を特定する可能性もあると考えられる。本研究の結果は、生体情報の公開に必要な措置の検討、健康、および医療に貢献することが期待される。

参考文献

- [1] Takeda, T., Kuramoto, K., Kobashi, S., Hata, Y. Biometrics Personal Identification by Wearable Pressure Sensor. ICETET 2012: 120-123.
- [2] Fedorov, E., Utkina, T., Nechyporenko, O., Korpan, Y. Method of Speech Signal Structuring and Transforming for Biometric Personality Identification. DSMP, 307-322, 2020.
- [3] Rabhi, E., Lachiri, Z. Biometric Personal Identification System using the ECG Signal. CinC, 507-510, 2013. <https://www.cinc.org/archives/2013/pdf/0507.pdf>
- Jae-Neung, L., Yeong-Hyeon, B., Sung-Bum, P., Keun-Chang, K. An EigenECG Network Approach Based on PCANet for Personal Identification from ECG Signal. Sensors (Basel), 18(11):4024, 2018.
- [5] Yoshida, Y., Yuda, E., Yamamoto, K., Miura, Y., Hayano, J. Machine-Learning Estimation of Body Posture and Physical Activity by Wearable Acceleration and Heartbeat Sensors. Signal & Image Processing: An International Journal, 10(3), 1-9, 2019
- [6] Yoshida, Y., Yuda, E. Workout Detection by Wearable Device Data Using Machine Learning. Applied Sciences, 13(7), 4280-4280, 2023.
- [7] TDK, Silmee W22. Available online: https://product.tdk.com/ja/products/biosensor/biosensor/silmee_w22/index.html (accessed on 1 June 2024).
- [8] 鶴英雄, 中村紗里 他. Python による機械学習入門, オーム社, 第1版第1刷, 2016年11月30日
- [9] Abdullah, B., Aleksandar, J. ECG bio-identification using Fréchet classifiers: A proposed methodology based on modeling the dynamic change of the ECG features. Biomed. Signal Process. Control., 82, 104575, 2023.
- [10] Victor Rincon, M., Mariko Nakano, M., Oswaldo Juarez, S., Jesus Olivares, M., Jairo Moreno, S., Gibran Benitez, G. Deep Learning Algorithm for the People Identification Using their ECG Signals as a Biometric Parameter. TSP 2023, 154-159, 2022
- [11] Mohamed, B., Lotfi, M., Nicholas, C., Meryem, R. ECG based biometric identification using one-dimensional local difference pattern. Biomed. Signal Process. Control., 64, 102226, 2021.
- [12] Yefei, Z., Zhidong, Z., Yanjun, D., Xiaohong, Z., Yu, Z. Human identification driven by deep CNN and transfer learning based on multiview feature representations of ECG. Biomed. Signal Process. Control., 68, 102689, 2021.
- [13] Emna, R., Zied, L. Biometric Personal Identification System using the ECG Signal. CinC, 507-510, 2013.
- [14] Hung-Tsai, W., Yi-Ting, W., Wen-Whei, C. Biometric Identification Using JPEG2000 Compressed ECG Signals. IEICE Trans. Inf. Syst., 98-D(10), 1829-1837, 2015.
- [15] Ahmet Burak, T. Biometric identification system using EEG signals. Neural Comput. Appl., 35(1), 1009-1023, 2023.
- [16] Su, Y., Farzin, D. Novel HHT-Based Features for Biometric Identification Using EEG Signals. ICPR 2014, 1922-1927.
- [17] Arnab, M., Dulal, M., Iti Saha, M. A simple proposition for heart sound signal de-noising for effective components identification in normal and abnormal cases. Biomed. Signal Process. Control., 71, 103264, 2022
- [18] Suncheng, X., Hao, C., Wei, R., Zefang, Y., Ting, L., Dahong, Q., Yuzhuo, F. Deep multimodal representation learning for generalizable person re-identification. Mach. Learn., 113(4), 1921-1939, 2024.
- [19] Jyothi J., Chitra, R. Multimodal biometric identification based on overlapped fingerprints, palm prints, and finger knuckles using BM-KMA and CS-RBFNN techniques in forensic applications. Vis. Comput., 40(5), 3217-3231, 2024.
- [20] Tae-Ho, H., Jingyao, S., Kangyoon, L. Enhancing Privacy-Preserving Personal Identification Through Federated Learning With Multimodal Vital Signs Data. IEEE Access 11, 121556-121566, 2023.
- [21] Chahreddine, M., Freha, M., Abdellatif, R., Christophe, C. Identification based on feature fusion of multimodal biometrics and deep learning. Int. J. Biom., 15(3/4), 521-538, 2023.
- [22] Hava, C., Valeriya, S., Michele, P., Bianca, D., et al. StressID: a Multimodal Dataset for Stress Identification. NeurIPS, 2023.
- [23] Satya Chandrashekhar, A., Bogdan, I., Mircea, T., Dan, I. A Multimodal Deep Learning Approach to Emotion Detection and Identification. SACI, 135-142, 2022.
- [24] Goutam, S., Swagata, G. Biometric-based unimodal and multimodal person identification with CNN using optimal filter set. Innov. Syst. Softw. Eng., 17(2), 157-166, 2021.
- [25] Priti, S., Yogesh, D. Multimodal biometric identification system with deep learning based feature level fusion using maximum orthogonal method. Int. J. Knowl. Based Intell. Eng. Syst., 25(4), 429-437, 2021.