

超広帯域レーダによる歩行および着座の測定と畳み込みニューラルネットワークを用いた個人識別技術

阪本 卓也^{†,††a)}

Personal Identification Using a Convolutional Neural Network and Ultra-Wideband Radar Measurement of Walking and Sitting Motion

Takuya SAKAMOTO^{†,††a)}

あらまし 本論文では、超広帯域レーダを用いて人体の歩行及び着座運動を測定し、時間周波数解析により得られたスペクトログラム画像及び機械学習を用いて個人識別をおこなう。被験者 6 人の歩行及び着座運動を超広帯域レーダにより測定する。レーダ受信信号を時間周波数解析し、四肢の運動に伴うマイクロドップラー成分の含まれるスペクトログラムに変換し、画像を生成する。個人ラベルを付与されたスペクトログラム画像を 2 層畳み込みニューラルネットワークに入力して学習を行い、レーダによる個人識別を実現する。

キーワード 超広帯域レーダ, 時間周波数解析, マイクロドップラー, ニューラルネットワーク, 個人識別

1. ま え が き

近年、内閣府の戦略目標の一つである超スマート社会 (Society5.0) に代表される次世代センサ技術の応用に注目が集まっている。Society5.0 では「必要なモノやサービスを、必要な人に、必要なときに、必要なだけ提供」できるとされている [1]。これを実現するためには、センサ技術により人の位置、運動や生体信号などをモニタリングすることが求められるが、これらに加えて個人の自動識別技術も欠かせない。現在、主にカメラ画像による顔認識技術 [2], [3] が注目され、特に屋外や公共施設での防犯カメラの導入は急速に広がっている。また、屋内ではスマートスピーカーによる声紋照合による個人識別が普及している。これらの技術は安価かつ高精度であることから、広く普及しているものの、プライバシーの懸念も無視し得ない。カメラやマイクロホンからの情報漏洩は多く報道され、

社会的な不安は増している。

そのため、プライバシーに配慮した個人識別センサ技術が重要である。顔や体全体の撮影や声の録音を必要としない生体認証としては、指紋認証 [4], [5], 虹彩認証 [6], 静脈認証 [7]~[10], 眼球運動認証 [11] などの多くが既に実用化されている。更に、心電図 [12]~[14] や脳波 [15], [16] といった生体情報による個人識別の研究も進められている。例えば、Koike-Akino ら [17], 及び Louis ら [18] はいずれも心電図データから特徴量を抽出し、生体認証を試みている。Odinaka ら [19] のレビュー論文では、心電図を用いた個人識別技術が詳細に比較されている。これらの技術の多くは電極を体表面に装着したりセンサを体に近接させる必要があるなど、使用時の煩わしさがある。

レーダに代表される電波センシングは非接触かつ簡便に使用できるという点で期待が集まっている。Diederichs ら [20] はミリ波レーダを使って掌の皮下組織からの反射波を測定し、個人識別を実現している。この技術では非接触での個人識別を実現しているものの、ユーザは手をアンテナに近づける必要がある。Dwelly と Adams [21] は対象者をレーダで測定し、受信信号をニューラルネットワークで処理することで対象者の体勢を推定することに成功したが、個人識別は検討されていない。Rissacher と Galy [22] は 2.4 GHz

[†] 京都大学大学院工学研究科電気工学専攻システム創成論分野, 京都市 Graduate School of Engineering, Kyoto University, Kyotodaigaku-Katsura, Nishikyo-ku, Kyoto-shi, 615-8510 Japan

^{††} 科学技術振興機構さきがけ, 川口市

PRESTO, Japan Science and Technology Agency, 4-1-8 Honcho, Kawaguchi-shi, 332-0012 Japan

a) E-mail: sakamoto.takuya.8n@kyoto-u.ac.jp

帯のレーダを用いて心拍動を計測し、生体認証への応用可能性を検討している。Shi ら [23] は同じく 4 人の被験者の心拍動をレーダで測定し、91.3%の個人識別正解率を達成した。Rahman ら [24] は 2.4 GHz 帯のレーダを用いて 6 人の被験者の呼吸を測定し、95%の個人識別正解率を達成した。このように、心拍や呼吸などの生体信号のレーダによる計測及び個人識別は注目されているが、対象者がほぼ静止した安静状態である必要があるなど、適用シーンが制限される。更に、体調の変化などにより再現性が低くなるケースも報告されており、導入には慎重な検討が必要である。

こういった背景から、生体信号ではなく歩行等の四肢の運動のマイクロドップラー計測による個人識別が有望と考えられている。Garreau ら [25] はレーダではなく超音波ソナーを使ってセンサから 2.5 m 離れたトレッドミル上を歩行する 13 人の被験者を測定し、個人識別正解率 100%を報告している。彼らは速度や位置を制御できるトレッドミル上を歩行させたことで精度が高くなったと思われる。Kalganokar と Raj [26] はやはり超音波ソナーを使って 30 人の被験者の歩行を各 20 回測定し、混合ガウスモデルにより 91.7%の個人識別正解率を達成した。高分解能を有する高周波の超音波は空気中での減衰が大きく、ソナーによる人体計測は比較的近距离でのみ可能である。

レーダによる測定として、Cao ら [27] は 24 GHz 帯、帯域幅 250 MHz の K 帯レーダを用いて 24 人の被験者らの歩行を各 50 回測定し、スペクトログラム画像を用いて 5 層畳み込みニューラルネットワークの一種である AlexNet を用いて個人識別を実現した。彼らは被験者数 6 人及び 20 人の場合に個人識別正解率 90.9%及び 68.9%を達成した。Vandersmissen ら [28] は室内を自由に歩行する被験者 5 人を 77 GHz 帯の帯域幅 1.5 GHz のレーダにより測定し、スペクトログラム画像を 4 層畳み込みニューラルネットワークに入力して個人識別正解率 78.4%を達成した。Tahmoush と Silvius [29] は 8 人の被験者の歩行をレーダ測定し、マイクロドップラーから 2 次元の特徴量を手動抽出し、KNN (k -nearest neighbors) により 80%の個人識別正解率を達成した。このように、従来の研究の多くは、歩行運動を対象とした個人識別を検討している。それに対し、Yang ら [30] は通常の歩行に加え、シャドーボクシング動作をしながらの歩行・匍匐前進・忍び足歩行・跳躍・走行の 6 種類の運動について、15 人の被験者を 4.3 GHz 帯の超広帯域レーダで測定し、スペク

トログラム画像を用いた多層畳み込みニューラルネットワークにより、匍匐前進で 72.6%、歩行で 94.4%、走行で 95.2%の個人識別正解率を達成した。Seyfioğlu ら [31] は歩行を含む 12 種類の行動を行う 11 人の被験者を 4 GHz の CW レーダを用いて測定した。彼らは個人識別ではなく行動識別を対象とし、50 次元の特徴量を用いたサポートベクターマシンによる行動識別では 76.9%、オートエンコーダーでは 84.1%、畳み込みニューラルネットワークでは 90.1%、畳み込みオートエンコーダーでは 94.2%の行動識別正解率を達成した。

本論文では、歩行から着座に至る一連の運動のマイクロドップラーによる個人識別を試みる。着座運動のレーダ測定に注目した個人識別は著者の知る限りこれまでに報告例がない。本論文が想定するシナリオとしては、固定された椅子に向けてレーダの送信波を照射しておき、この椅子に近づき着席するユーザを識別するというものであり、多くの応用が期待できる。具体的な応用例としては、機密性の高い電子ファイルを保存した端末の座席に着席するユーザを特定したい場合や、安全保障上の理由で立ち入りを少数のスタッフに限定している施設内での不審な行動を検出したい場合などが挙げられる。実験では超広帯域レーダを用いて 6 人の被験者の歩行及び着座を測定し、受信信号から時間周波数分布を求め、畳み込みニューラルネットワークにより個人識別を行う。性能評価には歩行と着座の両方を含む 8 秒程度のデータを用い、個人識別の正解率等について、定量的に調べる。なお、本論文の予備的な検討の一部は [32] において口頭発表されている。

2. レーダによる人体の測定及びマイクロドップラー

運動中の人体からのレーダ反射波にはドップラー効果による周波数偏移が見られる。人体各部位の運動は一般に異なるため、各々の部位に対応する周波数偏移を示す反射波の重ね合わせが受信され、各々のドップラー偏移量は時間とともに変化する。人体全体の平均的な移動速度が古典的なレーダのドップラー成分に対応するのに対し、四肢の運動によるドップラー偏移はマイクロドップラーと呼ばれ、時間とともに変化する準周期関数である。

超広帯域レーダで測定される信号は時間 t とレンジ r の関数 $s_0(t, r)$ と表される。ただし、レンジ r は遅延時間 τ を用いて $r = c\tau/2$ と表される。ここで c は

空気中の電波伝搬速度である．本論文で使用するレーダは直交検波ではなく，受信信号を直接 A/D 変換しているため， $s_0(t, r)$ は実数値をとる．まず， $s_0(t, r)$ を次式のとおき解析信号 $s(t, r)$ に変換する．

$$s(t, r) = \frac{1}{2\pi} \int_{-\infty}^{\infty} U(k) e^{jkr} \int_{-\infty}^{\infty} s_0(t, r') e^{-jkr'} dr' dk \quad (1)$$

ただし， $U(k)$ は単位ステップ関数である．次に，短時間フーリエ変換 (STFT; Short-Time Fourier Transform) により時間周波数分布 (スペクトログラム) $S(t, v_d)$ を得る．

$$S(t, v_d) = \int_{r_1}^{r_2} \left| \int_{-\infty}^{\infty} w(t') s(t' - t, r) e^{-j2kv_d t'} dt' \right|^2 dr \quad (2)$$

ただし， k は波数， v_d はドップラー速度であり，窓関数 $w(\cdot)$ は次式で表される時間幅 $t_0 = 0.16$ s の Hann ウィンドウとする．

$$w(t) = \begin{cases} \frac{1}{2} \left(1 + \cos \left(\frac{2\pi t}{t_0} \right) \right) & |t| \leq t_0/2 \\ 0 & |t| > t_0/2 \end{cases} \quad (3)$$

また，人体は $r_1 \leq r \leq r_2$ の範囲に存在するとする．受信信号には，人体からの反射波以外に送受アンテナ間の直達波や室内の静止物体からの反射波などの不要成分であるクラッタが含まれるため， $r_1 \leq r \leq r_2$ の範囲のみのスペクトログラムを計算している．更に，あらかじめ測定しておいた無人状態の信号を，人体からの反射波を含む信号から減算することでクラッタの除去を行う．直流成分 $v_d = 0$ を除去する方法がとられることもあるが，その場合は低速あるいは静止状態の人体エコーが誤って除去されてしまう可能性があるため，本論文では採用しない．以降では $S(t, v_d)$ を画像として保存し，畳み込みニューラルネットワークの学習と性能評価に用いる．

3. 実験環境とニューラルネットワーク

3.1 レーダによる運動人体の測定

測定には中心周波数 4.2 GHz，帯域幅 2.2 GHz の超広帯域レーダ PulsON® 400 (Time Domain 社, Huntsville, AL, USA) を使用する．このレーダは 2 値擬似雑音系列 (M 系列) により位相変調された広

帯域信号を送信アンテナから送信し，別の受信アンテナで受信する．受信アンテナで得られた信号はパルス圧縮され，A/D 変換を経てデータとして保存される．帯域幅 2.2 GHz は距離分解能 6.8 cm に相当するため，大部分の不要波・静止クラッタは距離によって人体からの所望波と分離できる．ただし，一部の静止クラッタは時間周波数解析の後，直流成分として所望信号に重畳し，干渉の原因となる．送受信アンテナには超広帯域特性を有するダブルリッジ・ホーンアンテナを二つ使用し，両者を近接して設置することで近似的なモノスタティックレーダとする．

室内において 6 人の被験者 (A, B, C, D, E, F) が歩行及び着座を続けて行う．まず，各被験者は送受信アンテナから約 7.0 m の位置に立ち，測定開始の合図に合わせてアンテナへ向かって歩き始める．その後，アンテナから約 3.5 m の位置に設置したパイプ椅子の前方まで移動した後に着座する．これら一連の運動を行っている被験者をレーダにより測定する．測定緒元を表 1 に，測定風景の写真を図 1 に示す．

各測定時間長は約 8 秒間で，各被験者に対して同様

表 1 レーダシステム緒元

Antennas	Double ridged horns
Center frequency	4.2 GHz
10dB-Bandwidth	2.2 GHz
Range sampling interval	9.12 mm
Time sampling interval	5 ms
Beamwidth (E-plane)	32 degrees
Beamwidth (H-plane)	34 degrees
Modulation	Binary phase
Spreading code	M-sequence



図 1 超広帯域レーダによる被験者の測定風景




図 2 受信信号の各時間及びレンジにおける強度分布．左上から順に被験者 A, B, C, D, E, F.




図 3 受信信号の時間周波数分布．左上から順に被験者 A, B, C, D, E, F.

の測定を 100 回繰り返し行った．6 人の被験者に対する受信信号電力 $|s(t, r)|^2$ の一例を時間 t と距離（レンジ） r の関数として図 2 に示す．同図は最大値で正規化している．いずれの被験者も測定後約 4 秒後には椅子の前方に到達し，約 6 秒後には着座を完了していることがわかる．短時間フーリエ変換により得たスペクトログラム $S(t, v_d)$ を図 3 に示す．ただし，アンテナに近づく方向を正の速度としている．代表的な速度成

分の上下にスパイク状の時間変動成分が見られる．これは歩行時の四肢の運動により生じたマイクロドップラー成分である．また，着座時には負の速度成分が見られるが，これは頭部及び上半身がアンテナから遠ざかる方向へ運動したことに対応する．

3.2 ニューラルネットワークによる個人識別

使用する畳み込みニューラルネットワークの緒元を表 2 に，構成を図 4 に示す．入力データは 32×100 ピ




図 4 本論文で個人識別に使用する 2 層畳み込みニューラルネットワーク

表 2 使用するニューラルネットワークの緒元

Input layer size		32 × 100
Convolutional layer 1	# of filters	10
	Filter size	10 × 10
	Activation	ReLU
	Max pooling size	2 × 2
	Output size	10 × 22 × 45
Convolutional layer 2	# of filters	10
	Filter size	10 × 10 × 10
	Activation	ReLU
	Max pooling size	2 × 2
	Output size	10 × 12 × 17
Fully-connected layer		2,040 × 6
Output layer size		6




図 5 1 層目で用いた 10 種の 10 × 10 フィルタ

し、2 層目では、1 層目の出力をサイズ $10 \times 22 \times 45$ の 3 次元配列とみなし、図 6 に示す 10 種のサイズ $10 \times 10 \times 10$ のフィルタとの 3 次元畳み込みを適用する。2 層目から出力される画像は 10 枚の 12×17 ピクセルの画像となり、その総画素数は $N_{in} = 2,040$ である。この情報を用いて被験者数 N_{out} に応じた出力を得るための全結合層を用いる。入力ポート数 N_{in} 、出力ポート数 N_{out} との間全結合層から出力される N_{out} 個の値は Soft-max 処理後に $q_1, q_2, \dots, q_{N_{out}}$ として出力される。最大の出力に対応した番号

$$i_{est} = \arg \max_i q_i \quad (5)$$

により、被験者インデックス $i_{est} \in \{1, 2, \dots, N_{out}\}$ を最終的な識別結果として得る。本論文では、6 人の被験者を対象とするため、 $N_{out} = 6$ とし、被験者インデックス $1, 2, \dots, 6$ を被験者ラベル A, B, $\dots$, F に対応させる。

測定データから得られたスペクトログラム画像は、被験者ラベルが付与された N_{out} 個のクラスに分類される。各クラスの画像の枚数を N_s とすると、画像は計 $N_s N_{out}$ 枚あり、そのうち各クラスから無作為に N_l 枚選択して得られる計 $N_l N_{out}$ 枚を学習に、 $N_t N_{out} = N_s N_{out} - N_l N_{out}$ 枚を性能評価に使用する。つまり、学習に用いた画像は性能評価には用いない。ここで $N_t = N_s/k$ とし、 k -分割交差検証を用い

クセルの 8 ビットのグレースケール画像とする。入力画像は畳み込み層において 10 種のサイズ 10×10 のフィルタとの畳み込みを行う。畳み込み処理におけるストライド長は 1×2 とする。ここで用いた 10 種のフィルタを図 5 に示す。活性化関数として次式の $r(x)$ で表現される ReLU (Rectified Linear Unit) 関数を採用する。

$$r(x) = \begin{cases} x & (x \geq 0) \\ 0 & (x < 0) \end{cases} \quad (4)$$

その後、プーリングには最大値プーリングを採用する。プーリングサイズは 2×2 、ストライド長は 1×1 とする。1 層目の畳み込み・活性化・プーリング処理を経て 10 枚の 22×45 ピクセルの画像となる。続いて、2 層目において再び同様の処理をおこなう。ただ

る．具体的には $k = 10$ とし， $N_s = 100$ ， $N_l = 90$ ， $N_t = 10$ とする．

ネットワークの学習は，全結合層の重み $w_{i,j}$ ($i = 1, \dots, N_{in}$ ， $j = 1, \dots, N_{out}$) を最適化することで行う．本論文の適用例では $2,040 \times 6 = 12,240$ 次元の非線形最適化問題に相当する．この最適化には畳み込み




図6 2層目で用いた10種類の $10 \times 10 \times 10$ フィルタ．ブロックごとに上から1, 2, ..., 10種類目

ニューラルネットワークの学習に広く用いられる慣性つき確率的勾配降下法を用いる．その際の初期学習率 (learning rate) は経験的に 0.001 とした．

4. 個人識別精度の評価

ここでは前節で述べた畳み込みニューラルネットワークによる歩行・着座運動の測定データによる個人識別の精度を調べる．測定データのスペクトログラムのうち $0 \leq t \leq 8s$ 及び $-3.5 \text{ Hz} \leq f_v < 3.5 \text{ Hz}$ に対応する部分を画像に変換する．元のスペクトログラム画像サイズは 32×1600 ピクセルであるが，間引きによりピクセル数を減らし， 32×100 ピクセルの8ビットグレースケール画像とした．生成した画像を畳み込みニューラルネットワークに入力し，ネットワークの学習及び精度評価に用いる．本論文では教師あり学習を用いるため，実際の対象者ラベルを正答として与える．6人の被験者が各々100回の歩行・着座運動及びレーダ測定を繰り返すため，全部で600枚の画像が得られる．性能評価には10分割交差検証を用い，全600枚のうち，無作為に選んだ540枚を学習に，残りの60枚は性能評価に用いる．

本論文で使用した画像の一部を図7に示す．図3とは上下反転して表示している．図中のAからFは被験者のラベルである．各被験者の測定で得られた100枚の画像のうちの10枚を例示している．多数回の測定が必要であったため，一日に実施する測定は最大5回程度に留め，約1ヶ月にわたって間欠的に測定を続けた．図7のスペクトログラムを見ると，同じ被験者でも画像内のパターンが測定ごとに異なって見えるも




図7 被験者6人(A-F)の歩行及び着座運動のスペクトログラム画像各10枚の例

表 3 歩行運動（1 秒間）による個人識別の混同行列（％）．
平均正解率 93.3％，平均 F 値 93.6％

		Estimated Person					
		A	B	C	D	E	F
Actual Person	A	96.2	0.6	0.0	1.8	0.1	1.2
	B	0.6	89.2	3.2	1.8	2.6	2.3
	C	1.3	2.1	94.1	1.2	1.3	0.0
	D	1.1	1.8	1.4	93.0	1.7	0.9
	E	1.0	4.3	0.1	0.2	93.7	0.5
	F	1.3	1.3	1.7	0.3	0.7	93.7

のが存在することがわかる．また，被験者間のスペクトログラムの違いが明らかなものも存在するが，同一個人でも異なるパターンが生じている．これらのことから，手動での特徴量抽出による個人識別は困難であり，機械学習による特徴量の自動抽出が必要となる．

最適化する前の全結合層の重みは，乱数により初期化される．更に，最適化に用いる慣性つき確率的勾配降下法でも乱数を用いる．そのため，乱数の初期値によって個人識別性能が変化する．この影響を考慮して性能評価するため，擬似乱数の初期値をさまざまに変化させ，平均的な性能を計算し，評価を行う．以下では初期値を 100 通り変化させ，歩行と着座運動の双方を含む 8 秒間のスペクトログラム画像を 2 層畳み込みニューラルネットワークにより学習し，個人識別の性能を評価する．各試行での学習 Epoch 数は経験的に 300 とする．各試行において学習を終えたネットワークに精度検証用の N_t 枚の画像を入力して識別精度を評価した．精度検証用の画像は学習に用いる画像とは重複しない．

実験により得られた個人識別結果を混同行列として表 3 に示す．この表の行ラベルが実際の被験者であり，列ラベルが推定された被験者である．混同行列の対角成分は，正しく個人識別された割合に相当する．平均正解率は 93.3％であった．サンプル数 100 から計算される正解率の不偏標準偏差は 2.7％であり，母数 100 の場合の信頼水準 95％の両側 t 値は 1.99 であるため，正解率の 95％信頼区間は 92.7％から 93.8％となった．従来技術で達成された正解率 90.9％ [26]，78.4％ [27]，80％ [28]，94.4％ [29] を超える，あるいは同程度の性能を実現できていることがわかる．平均適合率は 93.6％，平均再現率も 93.6％となり，これら適合率と再現率の調和平均である F 値も 93.6％となった．混同

行列をみると，被験者 B の正解率が 89.2％と比較的低いことがわかる．被験者 B のスペクトログラムは被験者 C，E，F と誤って推定される確率がいずれも 2％を超え，比較的高い．図 7 より，被験者 B や D のスペクトログラムは測定ごとに形状が異なり，あまり再現性が高くないことがわかる．こうしたことが，被験者 B や D の平均正解率を低下させた原因の一つと考えられる．

5. 考 察

5.1 個人識別の手法と機械学習

本論文で導入した 2 層畳み込みニューラルネットワークは基本的な構成とした．一方，個人識別に使える可能性のある手法としては最小 2 乗分類 [33]・サポートベクターマシン [34]・KNN [35]・決定木 [36]・ランダムフォレスト・単純ベイズ法など，多くの種類が存在する．また，ニューラルネットワークに限っても，多層化による深層学習 [37] や複素・四元数などを用いた高次元ニューラルネットワーク [38]～[40] など多くの種類が存在する．本論文で示した個人識別手法は機械学習適用の一例に過ぎない．

5.2 入力画像サイズ

ニューラルネットワークによる個人識別の性能はネットワークの構造や層数及び学習データ量及び学習の方法など，多くの要因に依存する．全結合層のパラメータ数とデータ量の大小を考慮すると，入力データの次元は必要最小限に留めることが学習時間の短縮や過学習を避ける意味でも有利である．そのためには入力画像サイズを小さく抑えることが有効である．本論文では 32×100 ピクセルの画像を入力として用いたが，Cao ら [27] は 256×256 ピクセルの画像を，Vandersmissen ら [28] は 45×256 ピクセルの画像を，Yang ら [30] は 100×100 ピクセルの画像を，それぞれ使っている．なお，画像サイズを小さくするには，測定時間・サンプリング周波数・目標の最大加速度で決まる時間分解能や周波数分解能を考慮し，ナイキスト条件を満たす範囲での間引きが必要であると同時に，ニューラルネットワークの全結合層の自由度と学習データ量の関係も考える必要がある．

本論文では以下のように入力画像サイズを定めた．測定時間を T_0 とし，サンプリング周波数を f_s とすると，時間方向のサンプル数は $M_s = T_0 \cdot f_s$ となる．本論文で使ったレーダのサンプリング周波数は $f_s = 200$ Hz であり，歩行及び着座という一連の行動の時間長を考

慮して $T_0 = 8.0\text{ s}$ としたため、 $M_s = 1,600$ となる。サンプリング周波数 $f_s = 200\text{ Hz}$ で定まるナイキスト速度は 3.6 m/s であり、図 3 からわかるように歩行及び着座においてナイキスト速度を超えるドップラー速度が生じる頻度は高くないため、サンプリング周波数を現状より高く設定する必要はない。短時間フーリエ変換に用いる窓関数 $w(t)$ の実効幅 $t_0/2$ に対し、周波数分解能はおよそ $\Delta f = 2/t_0$ となり、中心周波数を $f_0 = 4.2\text{ GHz}$ とするとドップラー速度分解能は $\Delta v = c/f_0 t_0$ で与えられる。例えば、 $t_0 = 0.16\text{ s}$ とすれば $\Delta v = 0.45\text{ m/s}$ となる。歩行及び着席における人体の加速度の最大値を例えば 3.0 m/s^2 と見積もれば、 $t_0 = 0.16\text{ s}$ の間の速度変化は最大 0.48 m/s となる。この値は $\Delta v = 0.45\text{ m/s}$ と同程度であるので、 t_0 をこれ以上長くする必要はない。よって、ドップラー速度方向のサンプル数は $f_s t_0 = 32$ 点と決まる。更に、時間方向のオーバーサンプリングを避けるため、短時間フーリエ変換の窓が半分だけ重複するサンプル間隔 $t_0/2$ を選べば、時間方向のサンプル数は $T_0/(t_0/2) = 100$ 点と決定される。以上より、本論文で畳み込みニューラルネットワークに入力した画像サイズ 32×100 が求まる。

5.3 学習データ量

例えば、Yang ら [30] は本論文よりも高い識別正解率を達成しているが、学習に用いた画像数は本論文と異なる。本論文では計 600 枚の画像を使ったのに対し、彼らの識別には 22,500 枚の画像が使われている。一般に、学習データ量が増えるに従って性能が向上する。本論文で想定する応用では、ユーザに同じ行動を多数回にわたって繰り返させることはあまり現実的ではない。そのため、実用上の学習データ量は制限される。このような場合、データの水増し法 (data augmentation) では学習データへの雑音の加算やコントラスト変換により実効的な学習データ量を増加させることができる。更に、オートエンコーダーによる事前学習、転移学習や GAN (generative adversarial networks) の導入も性能改善につながる可能性がある。こうした様々な手法の導入検討も今後の重要な課題となる。

6. む す び

家庭や職場などの複数人が共有する場所での個人識別技術は今後ますます重要になり、プライバシーの懸念が少ないレーダによる個人識別技術は特に重要である。これまで呼吸・心拍といった生体情報を用いた

個人識別や、主に歩行人体のマイクロドップラーを用いた個人識別が報告されてきた。本論文では椅子に座る人体を対象とし、歩行から着座に至る運動を超広帯域レーダで測定し、時間周波数解析で得られるマイクロドップラー情報を用いた個人識別を検討した。対象者の運動を超広帯域レーダで測定し、時間周波数解析によりスペクトログラムに変換し、更に低解像度のグレースケール画像に変換した上で 2 層畳み込みニューラルネットワークによる識別を行った。被験者 6 人の参加する実験により個人識別の平均正解率 93.3% を達成した。

謝辞 本研究を実施する上でご協力くださいました元兵庫県立大学末政菜奈氏、日下部響土氏並びに実験に参加くださいました被験者の皆様に感謝申し上げます。また、本研究の一部は科学技術振興機構平成 30 年度戦略的創造研究推進事業 (さきがけ) No. JP-MJPR1873, JST COI JPMJCE1307, JSPS 科研費 19H02155, 15K18077, 15KK0243 の助成を受けたものです。関係各位に心より感謝申し上げます。

文 献

- [1] 内閣府, “総合科学技術・イノベーション会議,” <https://www8.cao.go.jp/cstp/>, 参照 Dec. 2, 2019.
- [2] S. Tan, X. Sun, W. Chan, L. Qu, and L. Shao, “Robust face recognition with kernelized locality-sensitive group sparsity representation,” *IEEE Trans. Image Process.*, vol.26, no.10, pp.4661–4668, 2017. DOI:10.1109/TIP.2017.2716180.
- [3] J. Lu, G. Wang, and J. Zhou, “Simultaneous feature and dictionary learning for image set based face recognition,” *IEEE Trans. Image Process.*, vol.26, no.8, pp.4042–4054, 2017. DOI:10.1109/TIP.2017.2713940.
- [4] C. Kauba and A. Uhl, “Fingerprint recognition under the influence of image sensor ageing,” *IET Biometrics*, vol.6, no.4, pp.245–255, 2017.
- [5] R.D. Labati, A. Genovese, V. Piuri, and F. Scotti, “Toward unconstrained fingerprint recognition: a fully touchless 3-D system based on two views on the move,” *IEEE Trans. Syst., Man, Cybern. Syst.*, vol.46, no.2, pp.202–219, 2016.
- [6] F. Jiu, K. Noronha, and D. Jayaswal, “Biometric identification through detection of retinal vasculature,” *Proc. 2016 IEEE 1st International Conference on Power Electronics, Intelligent Control and Energy Systems*, 2016. DOI:10.1109/ICPEICES.2016.7853731.
- [7] J. Wang and G. Wang, “Quality-specific hand vein recognition system,” *IEEE Trans. Inf. Forensics Security*, vol.12, no.11, pp.2599–2610, 2017. DOI:10.1109/TIFS.2017.2713340.

- [8] D. Huang, Y. Tang, Y. Wang, L. Chen, and Y. Wang, "Hand-dorsa vein recognition by matching local features of multisource keypoints," *IEEE Trans. Cybern.*, vol.45, no.9, pp.1823–1837, 2015. DOI:10.1109/TCYB.2014.2360894.
- [9] W. Kang and Q. Wu, "Contactless palm vein recognition using a mutual foreground-based local binary pattern," *IEEE Trans. Inf. Forensics Security*, vol.9, no.11, pp.1974–1985, 2014. DOI:10.1109/TIFS.2014.2361020.
- [10] S. Veluchamy and L.R. Karlmarx, "System for multimodal biometric recognition based on finger knuckle and finger vein using feature-level fusion and k-support vector machine classifier," *IET Biometrics*, vol.6, no.3, pp.232–242, 2017. DOI:10.1049/iet-bmt.2016.0112.
- [11] A.V. Lyamin and E.N. Cherepovskaya, "An approach to biometric identification by using low-frequency eye tracker," *IEEE Trans. Inf. Forensics Security*, vol.12, no.4, pp.881–891, 2017. DOI:10.1109/TIFS.2016.2639342.
- [12] B.M. Galloway, G. Niezen, G.P. Hancke, and B.J. Silva, "Multimodal biometric authentication in wireless sensor networks," *Proc. IEEE 14th International Conference on Industrial Informatics*, 2016. DOI:10.1109/INDIN.2016.7819308.
- [13] R. Tan and M. Perkowski, "ECG biometric identification using wavelet analysis coupled with probabilistic random forest," *Proc. 2016 15th IEEE International Conference on Machine Learning and Applications*, pp.182–187, 2016. DOI:10.1109/ICMLA.2016.0038.
- [14] Q. Zhang, D. Zhou, and X. Zeng, "HeartID: a multiresolution convolutional neural network for ECG-based biometric human identification in smart health applications," *IEEE Access*, vol.5, pp.11805–11816, 2017. DOI:10.1109/ACCESS.2017.2707460.
- [15] K.P. Thomas and A.P. Vinod, "Biometric identification of persons using sample entropy features of EEG during rest state," *Proc. 2016 IEEE International Conference on Syst., Man, Cybern. Syst.*, pp.3487–3492, 2016. DOI:10.1109/SMC.2016.7844773.
- [16] M.K. Bashar, I. Chiaki, and H. Yoshida, "Human identification from brain EEG signals using advanced machine learning method EEG-based biometrics," *Proc. 2016 IEEE EMBS Conference on Biomedical Engineering and Sciences*, pp.475–479, 2016. DOI:10.1109/IECBES.2016.7843496.
- [17] T. Koike-Akino, R. Mahajan, T.K. Marks, Y. Wang, S. Watanabe, O. Tuzel, and P. Orlik, "High-accuracy user identification using EEG biometrics," *Proc. 38th Annual International Conf. the IEEE Engineering in Medicine and Biology Society*, pp.854–858, 2016. DOI:10.1109/EMBC.2016.7590835.
- [18] W. Louis, M. Komeili, and D. Hatzinakos, "Continuous authentication using one-dimensional multiresolution local binary patterns (1DMRLBP) in ECG biometrics," *IEEE Trans. Inf. Forensics Security*, vol.11, no.12, pp.2818–2832, 2016. DOI:10.1109/TIFS.2016.2599270.
- [19] I. Odinaka, P.-H. Lai, A.D. Kaplan, J.A. O'Sullivan, E.J. Sirevaag, and J.W. Rohrbaugh, "ECG biometric recognition: a comparative analysis," *IEEE Trans. Inf. Forensics Security*, vol.7, no.6, pp.1812–1824, 2012.
- [20] K. Diederichs, A. Qiu, and G. Shaker, "Wireless biometric individual identification utilizing millimeter waves," *IEEE Sensors Letters*, vol.1, no.1, Article Sequence Number: 3500104, 2017. DOI:10.1109/LSENS.2017.2673551.
- [21] W.H. Dwelly and V.N. Adams, "Biometric radar system and method for identifying persons and positional states of persons," *United States Patent*, US 8,026,840 B2, 2011.
- [22] D. Rissacher and D. Galy, "Cardiac radar for biometric identification using nearest neighbour of continuous wavelet transform peaks," *Proc. IEEE Int'l Conf. Identity, Security and Behavior Analysis*, 2015. DOI:10.1109/ISBA.2015.7126356.
- [23] K. Shi, C. Will, R. Weigel, and A. Koelpin, "Contactless person identification using cardiac radar signals," *Proc. 2018 IEEE International Instrumentation and Measurement Technology Conference*, 2018. DOI:10.1109/I2MTC.2018.8409645.
- [24] A. Rahman, V. Lubecke, O. Boric-Lubecke, J. Prins, and T. Sakamoto, "Doppler radar techniques for accurate respiration characterization and subject identification," *IEEE Journal on Emerging and Selected Topics in Circuits and Systems*, vol.8, no.2, pp.350–359, June 2018.
- [25] G. Garreau, C.M. Andreou, A.G. Andreou, J. Georgiou, S. Dura-Bernal, T. Wennekers, and S. Denham, "Gait-based person and gender recognition using micro-Doppler signatures," *Proc. IEEE Biomed. Circuits Syst. Conf. (BioCAS)*, pp.444–447, Nov. 2011.
- [26] K. Kalgaonkar and B. Raj, "Acoustic Doppler sonar for gait recognition," *Proc. IEEE Conf. Adv. Video Signal Based Surveill.*, pp.27–32, Sept. 2007.
- [27] P. Cao, W. Xia, M. Ye, J. Zhang, and J. Zhou, "Radar-ID: human identification based on radar micro-Doppler signatures using deep convolutional neural networks," *IET Radar, Sonar & Navigation*, vol.12, no.7, pp.729–734, July 2018.
- [28] B. Vandersmissen, N. Knudde, A. Jalalvand, I. Couckuyt, A. Bourdoux, W. De Neve, and T. Dhaene, "Indoor person identification using a low-power FMCW radar," *IEEE Trans. Geoscience and Remote Sensing*, vol.56, no.7, July 2018.
- [29] D. Tahmoush and J. Silvius, "Radar micro-Doppler for long range front-view gait recognition," *Proc.*

- IEEE 3rd Intl. Conf. Biometrics, Theory, Appl. Syst., pp.1–6, Sept. 2009.
- [30] Y. Yang, C. Hou, Y. Lang, G. Yue, Y. He, and W. Xiang, “Person identification using micro-Doppler signatures of human motions and UWB radar,” *IEEE Microwave and Wireless Components Letters*, vol.29, no.5, May 2019.
- [31] M.S. Seyfioglu, A.M. Özbayoglu, and S.Z. Gürbüz, “Deep convolutional autoencoder for radar-based classification of similar aided and unaided human activities,” *IEEE Trans. Aerospace and Electronic Systems*, vol.54, no.4, pp.1709–1723, Aug. 2018. DOI:10.1109/TAES.2018.2799758.
- [32] 阪本卓也, 末政菜奈, “多層畳込みニューラルネットワークを用いた UWB レーダによる着座時のマイクロドップラー測定と個人識別,” 電子情報通信学会総合大会講演論文集, CS-2-6, March 2019.
- [33] D. Sasakawa, N. Honma, T. Nakayama, and S. Iizuka, “Human activity identification by height and Doppler RCS information detected by MIMO radar,” *IEICE Trans. Commun.*, vol.E102-B, no.7, July 2019.
- [34] J. Hong and T. Ohtsuki, “State classification with array sensor using support vector machine for wireless monitoring systems,” *IEICE Trans. Commun.*, vol.E95-B, no.10, pp.3088–3095, Oct. 2012.
- [35] K. Saho, T. Sakamoto, T. Sato, K. Inoue, and T. Fukuda, “Accurate and real-time pedestrian classification based on UWB Doppler radar images and their radial velocity features,” *IEICE Trans. Commun.*, vol.E96-B, no.10, pp.2563–2572, Oct. 2013.
- [36] S. Lan, Z. He, W. Chen, and K. Yao, “A low cost solution of hand gesture recognition using a three-dimensional radar array,” *IEICE Trans. Commun.*, vol.E102-B, no.2, pp.233–240, Feb. 2019.
- [37] J. Sonoda and T. Kimoto, “Object identification from GPR images by deep learning,” *Proc. 2018 Asia-Pacific Microwave Conference (APMC)*. DOI:10.23919/APMC.2018.8617556.
- [38] Y. Sunaga, R. Natsuaki, and A. Hirose, “Land form classification and similar land-shape discovery by using complex-valued convolutional neural networks,” *IEEE Trans. Geoscience and Remote Sensing*, vol.57, no.10, pp.7907–7917, Oct. 2019.
- [39] K. Oyama and A. Hirose, “Phasor quaternion neural networks for singular point compensation in polarimetric-interferometric synthetic aperture radar,” *IEEE Trans. Geoscience and Remote Sensing*, vol.57, no.5, pp.2510–2519, May 2019.
- [40] N. Matsui, T. Isokawa, H. Kusamichi, F. Peper, and H. Nishimura, “Quaternion neural network with geometrical operators,” *Journal of Intelligent & Fuzzy Systems: Applications in Engineering and Technology*, vol.15, no.3, 4, pp.149–164, Dec. 2004.

(2019 年 12 月 13 日受付, 2020 年 2 月 12 日再受付,
6 月 11 日公開)



阪本 卓也 (正員)

平 12 京大・工・電気電子卒. 平 17 同大学院情報学研究科通信情報システム専攻博士課程了. 同大学院にて日本学術振興会特別研究員 PD を経て, 平 18 同大学院情報学研究科通信情報システム専攻助手, 平 19 より同助教. 平 23 から平 25 まで日本学術振興会海外特別研究員としてオランダ王国デルフト工科大学客員研究員兼任. 平 27 から平 31 まで兵庫県立大学大学院工学研究科電子情報工学専攻准教授, 平 29 米国ハワイ大学マノア校客員研究員兼任. 平 30 から科学技術振興機構さきがけ研究者兼任, 平 31 より京都大学大学院工学研究科電気工学専攻准教授, 現在に至る. レーダ画像化及びレーダ信号処理の研究に従事. アンテナ伝播国際シンポジウム最優秀論文賞 (平 24), 電子情報通信学会通信ソサイエティ活動功労賞 (平 27 及び平 31), 堀場雅夫賞 (平 28), 電子情報通信学会エレクトロニクスソサイエティ活動功労賞 (平 31) 各受賞. IEEE シニア会員. 電気学会正員. 京都大学博士 (情報学).