

ワイヤレス人体センシングへの機械学習応用

阪本 卓也[†]

[†] 京都大学 大学院 工学研究科 電気工学専攻 〒615-8510 京都市西京区京都大学桂

あらまし 本稿では、我々のグループで進めているレーダによるワイヤレス人体センシング技術の研究のうち、機械学習を応用した例を2つ紹介する。一つ目は、レーダによる非接触ジェスチャ識別技術である。2.4 GHz帯の連続波レーダを用いて、6種類のジェスチャを行う10人の被験者の腕からの反射波を計測した。計測データから生成したI-Qプロット画像を畳み込みニューラルネットワークに入力し、レーダ受信信号のみを用いてジェスチャ識別を行い、識別精度を実験的に評価した。二つ目は、レーダによる非接触心拍計測技術である。79 GHz帯の超広帯域ミリ波アレーレーダを用いて7人の被験者の左肩からの反射波を計測した。計測したレーダ受信信号に静止クラッタ除去などを適用し、皮膚変位波形を推定し、それを並べ替えることで画像を生成した。生成画像を畳み込みニューラルネットワークに入力し、心電計のR波とS波の時間と同期した三角波を出力するように学習を行った。機械学習による心拍間隔の推定精度について評価し、従来法と比較した。

キーワード 人体センシング, レーダ, 信号処理, 機械学習

Application of Machine Learning Algorithms to Wireless Human Sensing

Takuya SAKAMOTO[†]

[†] Graduate School of Engineering, Kyoto University Kyotodaigaku-Katsura, Nishikyo-ku Kyoto, 615-8510, Japan

Abstract In this manuscript, we introduce two examples of application of machine learning to radar-based wireless human sensing. The first example is noncontact hand gesture identification using a 2.4-GHz continuous wave radar. The radar echoes from an arm of ten participants who were performing six types of gestures were measured. The I-Q plot images generated from the radar data were input to a convolutional neural network, achieving gesture identification, and the identification accuracy was evaluated experimentally. The second example is a noncontact heart rate measurement. The radar echoes from the left shoulder of seven participants were measured using a 79-GHz ultra-wideband array radar system. Images were generated by rearranging the skin displacement waveform estimated by applying phase-demodulation and static clutter removal. The generated images were input to a convolutional neural network, which was trained to output a triangular wave synchronized with the time of the R- and S-waves of the electrocardiograph. An experimental evaluation was performed on the estimation accuracy of the heartbeat interval.

Key words human sensing, radar, signal processing, machine learning

1. ま え が き

近年の機械学習を中心とした情報科学の計測分野への応用の発展は目覚ましく、そのレーダ信号処理への応用も例外ではない[1]~[7]。本稿ではレーダ信号処理の中でも特に、ワイヤレス人体センシングに注目し、非接触ジェスチャ識別と非接触心拍計測の2種類の応用についての我々の研究の一部を紹介する。

非接触ジェスチャ識別はGoogle Soliプロジェクト[8]に代表されるように、スマートフォンへの搭載を視野に盛んに研究が進められ、実用化が進められている。ジェスチャ識別にはウェアラブルデバイス[9]~[15]を使ったものや、RGBカメラ

や深度カメラ[16]~[19]を用いたものなどが提案されてきているが、前者は装着の手間や不快感、後者はプライバシー保護の観点から懸念が残る。こういった欠点を克服するのが電波を用いたレーダによるジェスチャ識別技術である。Google Soli[8]は60 GHzの超広帯域レーダを用い、2×4多入力多出力(MIMO: multiple-input multiple-output)アレーを利用するプロトタイプを開発した。Fan et al.[20]は受信2素子を有する連続波(CW: continuous wave)レーダを用いて、Molchanov et al.[21]は深度カメラと周波数変調連続波(FMCW: frequency-modulated CW)レーダを併用することで、それぞれジェスチャ識別に成功した。Kim et al.は機械学習の一種である畳み込みニューラル

ネットワーク (CNN: convolutional neural network) をレーダ信号の時間周波数領域表現であるスペクトログラム画像に適用し、マイクロドップラー情報を利用したジェスチャ識別を報告している [22]。スペクトログラム画像と機械学習を用いた方法は、レーダ目標識別を目的とした利用も報告されている [23], [24]。Kim et al. はインパルスラジオリレーダを用い、CNN をスペクトログラム画像ではなく時間領域の信号に適用し、ジェスチャ識別の精度 90% を達成した [25]。本稿で紹介する手法は、Kim et al. [25] と同様に時間領域信号に対して CNN を適用してジェスチャ識別を試みる。ただし、直交検波の I (in-phase) 成分と Q (quadrature) 成分を複素平面上に描画した I-Q プロットを画像と見なし、2次元画像を入力とする点が従来の報告と異なる。著者らの機械学習を用いた非接触ジェスチャ識別手法の詳細は [26], [27] を参照されたい。

次に、心拍計測への機械学習応用を紹介する。レーダを用いた非接触生体計測は接触型センサと異なり、清潔かつ簡便で、レーダシステムから離れた被験者の呼吸や心拍を計測できるため、医療やヘルスケアなどの分野での応用が期待されている [28]–[39]。ところが、レーダにより心拍を高精度計測するためには皮膚表面の微小変位を高精度に計測することが求められ、これまでに様々な信号処理法が提案されてきたが、そのいずれも性能に限界があった。とくに、呼吸に代表される大きな体動が心拍成分と干渉し、計測精度が低下することは大きな課題である。本稿では、我々が開発してきた CNN を用いた非接触心拍計測技術を紹介し、呼吸の有無に依存しない高精度計測が可能であることを示す。なお、著者らの機械学習を用いた非接触心拍計測技術の詳細は [40], [41] を参照されたい。

2. 機械学習とレーダによるジェスチャ認識

2.1 ジェスチャ識別のためのレーダシステム

まず、レーダを用いた非接触ジェスチャ認識技術 [26], [27] を紹介する。測定には 2.4 GHz 帯の連続波 (CW: continuous wave) レーダを用いる。送信電力は 10.0 dBm である。単一のアンテナを送受両方に用いるモノスタティックレーダであり、送受信の信号はハイブリッド結合器により分離される。使用するアンテナは利得 8.0 dBi、垂直偏波、E 面と H 面のビーム幅はそれぞれ 60.0 度および 80.0 度である。受信信号は分配器で分離された後にミキサ入力され、直交検波により I (in-phase) 成分と Q (quadrature) 成分が出力される。両成分は低域通過フィルタに入力された後に DC カップリングにて A/D (analogue-to-digital) 変換されてデジタルデータとして保存される。サンプリング周波数は 1.0 kHz である。データに含まれる直流成分は信号処理により除去される。システムの構成を図 1 に示す。

2.2 ジェスチャ識別のための人体計測

10 人の被験者が参加するレーダ実験を行い、レーダ反射波のデータを得た。各対象者には電波暗室内において着座し、静止した状態で腕のみを動かすよう指示した。そのため、直流成分除去を行った受信信号には、主に腕の反射波のみが残っていたと考えられる。各被験者には、6 種類のジェスチャを各々 150 回繰り返し行わせ、各ジェスチャについて 2 秒間のレーダ

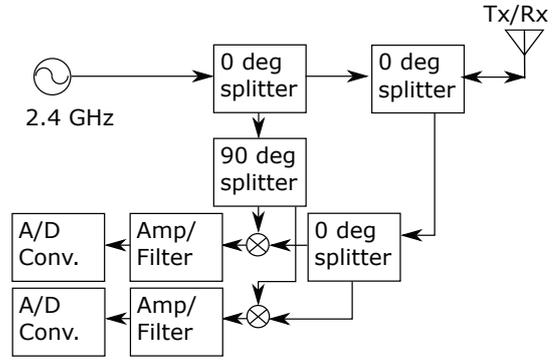


図 1 ジェスチャ識別に用いるレーダシステム [27]

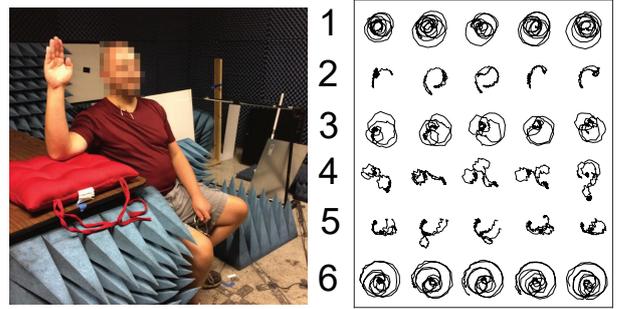


図 2 ジェスチャ識別のための実験環境と得られた I-Q プロットの例

測定を行った。被験者の腕はアンテナから約 1.2 m の距離に設定した。被験者番号 p ($p = 1, 2, \dots, N_p$) の i 番目のジェスチャ ($i = 1, 2, \dots, N_g$) の j 回目 ($j = 1, 2, \dots, N_0$) の測定データを $s_{(i,j)}^p(t)$ とする。ただし、本研究では $N_0 = 150$, $N_g = 6$, $N_p = 10$ とする。図 2 の左にジェスチャ識別のためのレーダ計測の様子を示す。

2.3 ニューラルネットワークによるジェスチャ認識

本研究では、ジェスチャ認識のために受信信号 $s_{(i,j)}^p(t)$ 複素平面上の信号点軌跡、すなわち I-Q プロットを画像として用いる。ただし、 $\max_{(t,i,j)} |s_{(i,j)}^p(t)| = 1$ となるように各被験者 p に対して振幅の正規化を行う。測定時間中に、反射信号は位相方向だけでなく振幅方向にも変化する。I-Q プロット画像は $N_s \times N_s$ ピクセルの低解像度 JPEG 形式に変換される。ただし、 $N_s = 30$ とする。各被験者に対して、各ジェスチャを N_0 回繰り返し、 $N_0 = 150$ 枚の JPEG 画像が生成される。図 3 には 6 種類のジェスチャに対応する I-Q プロットを各 3 枚ずつ例示する。図 2 の右に得られた 6 種類のジェスチャに対応する I-Q プロットの例を 5 例ずつ示す。測定の度に I-Q プロットは異なる軌跡を描いているが、類似した形状も見受けられる。

図 4 は本研究で用いた CNN のブロック図である。サイズ $N_s \times N_s = 30 \times 30$ ピクセルの入力画像は 40 種類の 5×5 フィルタと畳み込まれ、サイズ 22×22 の 40 枚の画像が生成される。これらの画像は活性化関数である正規化線形関数 (ReLU: rectified linear unit) に入力され、 2×2 ピクセルの非重複のマックスプーリング層に入力され、サイズ 11×11 の 40 枚の画像に変換される。2 層目の畳み込み層において、これらの画像は 30 種類の 5×5 フィルタと畳み込まれ、再び ReLU 関数およびマックスプーリング層を通り、最後に全結合層を通じて 6 個の

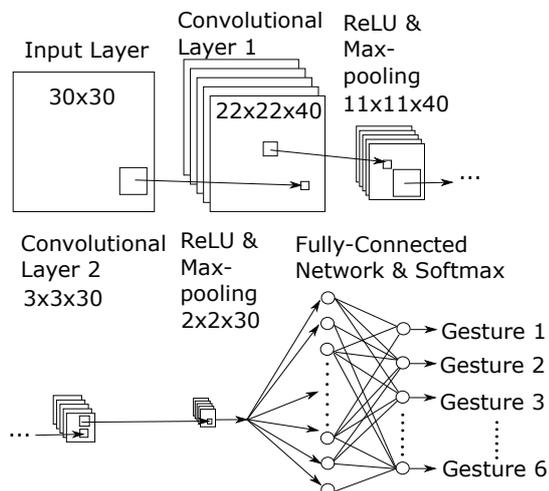


図3 ジェスチャ識別に用いる CNN の構成

出力ニューロンに至る。この全結合層の重みは慣性項付き確率的勾配降下法により、出力と学習ラベルの差が小さくなるように最適化される。図3にジェスチャ識別に用いる CNN の構成を示す。

2.4 ジェスチャ識別の性能評価

本節ではジェスチャ識別手法の性能評価を行う。まず最初に、被験者 10 人のうち 1 人のデータの一部を CNN に学習させ、同じ被験者の残りのデータを用いて性能評価を行う。学習に用いるデータと性能評価に用いるデータは重複しない。そのため、 $N_g N_{tr}$ 枚の画像を CNN の学習に用いる。ただし、 N_{tr} は各被験者・各ジェスチャに対して学習に用いるデータの枚数であり、残る $N_g(N_0 - N_{tr})$ 枚の画像が性能評価に用いられる。ここで $N_{tr}(\leq N_0)$ には 3 種類の値を設定して学習データサイズの性能への影響を評価する。学習過程では、確率的勾配降下法の反復回数は 300 とした。表 1 の 2-4 列目には提案法の CNN を、各被験者の全データのうちそれぞれ 10%, 50%, 90% を学習に用いて同じ被験者に対するジェスチャ識別を試みた場合の精度を示す。全データの 90% を学習に用いた場合、平均精度は 91.3% であった。また、学習データサイズによって精度が変化することも確認でき、より多くの学習データを用いることで精度が向上することがわかる。

次に、提案法において、学習データと性能評価データが異なる被験者である場合の性能を評価する。ここでは、CNN を $N_p - 1$ 人の被験者、すなわち 1 人を除く全被験者のデータを用いて学習させ、学習から除外した被験者のデータを用いて性能評価を行う。この時、学習に用いる画像枚数は $(N_p - 1)N_g N_{tr} = 8100$ 枚となる。この場合の精度は表 1 の最も右の列に示す。この結果より、精度は 6 種類のジェスチャからランダムに選択した場合 ($1/6 = 16.7\%$) よりは高いものの、平均で 38.4% となり、同じ被験者のデータを用いて学習と性能評価を行った場合よりも低い精度となった。この結果より、同じジェスチャであっても、異なる被験者に対する I-Q プロットの画像は大きく異なり、CNN による正しいジェスチャ識別に必要な再現性が得られなかったということが示唆される。この理由として、被験者

表 1 CNN とレーダを用いたジェスチャ認識の精度 [27]

Training & testing	Accuracy of the proposed method (%)			
	Same subject			Different subjects
Training data size	$N_g N_{tr} = 90$ (10%)	$N_g N_{tr} = 450$ (50%)	$N_g N_{tr} = 810$ (90%)	$(N_p - 1)N_g N_{tr} = 8100$
Subj. 1	84.1	89.8	91.6	51.3
Subj. 2	83.7	89.6	90.4	39.0
Subj. 3	88.8	93.2	94.9	32.7
Subj. 4	77.9	85.7	88.2	36.5
Subj. 5	88.2	92.6	94.7	36.4
Subj. 6	94.7	97.6	98.6	43.6
Subj. 7	80.6	85.8	89.0	45.1
Subj. 8	82.5	90.0	93.1	40.7
Subj. 9	78.6	85.9	85.0	42.6
Subj. 10	73.7	83.2	87.1	16.8
Average	83.3	89.4	91.3	38.5

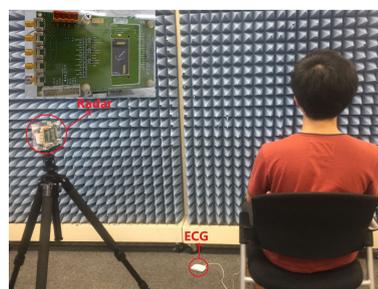


図4 ミリ波帯の超広帯域 MIMO レーダによる被験者の測定 [40].

が 6 種類のジェスチャについての指示を受けた際に、各々が異なる解釈をし、結果として被験者らが同じジェスチャを異なる方法で行っていた可能性が挙げられる。いずれにしても、提案手法は特定ユーザに特化したシステムでは十分に精度よくジェスチャ識別できるが、複数のユーザでシステムを共有する場合にはさらなる性能改善が求められる。

3. 機械学習とレーダによる非接触心拍計測

3.1 非接触心拍計測のためのレーダシステムと実験条件

別の機械学習の応用として、非接触心拍計測を紹介する [40], [41]。非接触心拍計測実験においては、79GHz 帯超広帯域レーダを用いる。帯域幅は 2.0 GHz であり、波長 $\lambda = 3.8$ mm である。多入力多出力 (MIMO; Multiple-Input Multiple-Output) アレイを用いる。アレイは素子間隔 4.6 mm (0.92 波長) で送信 4 素子、受信 4 素子の計 8 素子を有し、計 16 チャンネルのシステムである。レーダのサンプリング間隔は 0.24 ms であり、被験者の左肩から約 1.1 m の位置にアンテナを設置した。被験者には着座して通常の呼吸をするよう指示した。被験者にはあらかじめ心電計を装着しておく。心電計のサンプリング周波数は 500.0 Hz である。7 人の被験者に対し、各被験者をレーダおよび心電計により 300.0 s にわたり計測した。測定の様子を図 4 に示す。

16 チャンネルのレーダ受信信号 $s_0(t, r)$ は時間 t と距離 r の 16

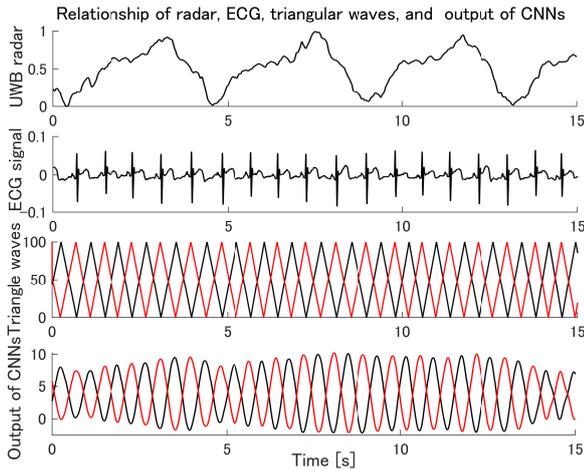


図5 心電の R 波と S 波の時間にピークを有する三角波を教師データとしたニューラルネットワークの出力波形 [40].

次元のベクトルであり、直流成分除去による静止クラッタ除去を行い、対象者のレンジ $r_0(t)$ を推定して $s_1(t) = s_1(t, r_0(t))$ を得る. 続いて円フィッティング法により精密な静止クラッタ除去を行い、 $s_2(t) = s_1(t) - s_{DC}$ を得る. 信号相関行列 $R = E[s_2 s_2^H]$ の最大固有値 σ_1 に対応する固有ベクトル v_1 で重み付け加算する最大比合成法を適用し、信号 $s(t) = v_1^H s_2(t)$ を得る. 信号 $s(t)$ の位相を変位量 $d(t) = (\lambda/4\pi)\angle s(t)$ に換算し、被験者の皮膚変位を推定する.

3.2 畳み込みニューラルネットワークによる心拍計測

前節の処理により得られた変位 $d(t)$ は $T_s = 2.4$ ms 間隔で標本化されている. そのうち 2,700 サンプル (6.5 s) を取り出し、 54×50 の行列に並べ替えて画像を生成する. サイズ 3×3 の 5 種類のフィルタとの畳み込みを行い、再びサイズ 3×3 の 5 種類のフィルタとの畳み込みを行った後に活性化関数として ReLU 関数を適用し、全結合層を通じて回帰層に至る. 本 CNN ではプーリング層は設けない. また、心電波形やこれから生成した三角波形を教師データとして、最も教師データに近い波形を出力させるように全結合層を最適化する.

教師データに用いた R 波と S 波に対応した時間にピークをもつ三角波を用いた場合の出力波形などを図 5 に示す. 同図の上から順に、レーダ変位波形 $d(t)$ 、心電波形、教師データである三角波、5,850 回の学習反復後のニューラルネットワーク出力波形である. ニューラルネットワーク出力波形は教師データである三角波に類似していることが確認され、提案手法が意図通りに動作していることがわかる.

3.3 機械学習による非接触心拍計測技術の性能評価

次に、機械学習による手法と従来のトポロジー法 [42] の性能を比較する. 機械学習による心拍計測では、100 秒間のデータを学習に使い、50 秒間のデータを使って精度評価する. 学習データと精度評価データは重複しないように選ぶ. 図 6 に被験者 A (60 代男性) の瞬時心拍間隔を示す. トポロジー法により高精度な心拍計測が実現できるケースも存在するが、ここで紹介する被験者については、大きな体動・呼吸および小さい心拍

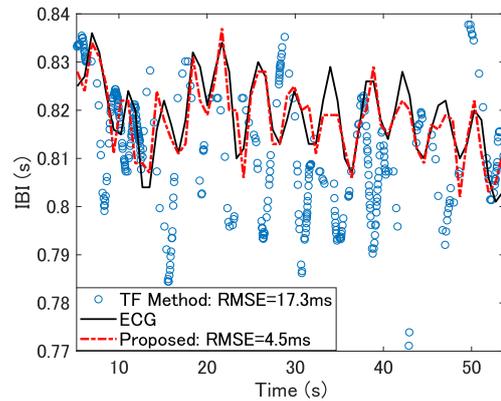


図6 心電計で計測された被験者 A の心拍間隔 (黒線)、トポロジー法 (青丸) および機械学習 (赤線) による推定心拍間隔 [40].

変位といった悪条件により、トポロジー法の推定精度が悪化している. 一方、機械学習による推定結果は心電計で計測された黒線とよく一致しており、機械学習による非接触心拍計測技術の有効性が確認される. トポロジー法および機械学習による推定心拍間隔の平均誤差はそれぞれ 17.3 ms および 4.5 ms であり、機械学習の導入により約 3.8 倍の精度改善が実現された. 同様に 7 名の被験者全てに対し、心拍推定精度の評価を行った. トポロジー法の平均誤差は 65.6 ms、提案する機械学習の平均誤差は 20.6 ms であり、約 3.2 倍の精度改善が実現された.

4. 結 論

本稿では、機械学習を応用したワイヤレス人体センシング技術を 2 つ紹介した. 前半で紹介した非接触ジェスチャ識別技術では、計測データから生成した I-Q プロット画像を CNN に、後半で紹介した非接触心拍計測技術では、計測データから生成した皮膚変位波形を並べなおした画像を CNN に、それぞれ入力した. 前者においては、受信信号に一切の前処理を行わず、直接得られる画像を機械学習の入力に用いたのに対し、後者においては、受信信号にクラッタ除去・位相復調・フィルタリングなど多くの処理を経て得られた画像を機械学習の入力に用いた. このように、用途に応じてほぼ生データを機械学習に入力するのか、信号処理を適用したデータを機械学習に入力するのか、同じ機械学習応用でもシステムの構成には自由度がある. 一方、非接触ジェスチャ識別技術では CNN を分類のために、非接触心拍計測技術では CNN を回帰のために、それぞれ用いた. このように、信号の性質や目的に応じて同じ CNN であっても様々な使い方があり、システム全体の処理速度・演算量・信号の性質などを多面的に考慮したうえで最終的な方式を決定する必要がある. 今後、こうした設計を体系化・自動化することができれば、同分野への機械学習応用が飛躍的に効率化すると予想される.

謝 辞

本研究の一部は JSPS 19H02155, JST JPMJPR1873, JST COI JPMJCE1307 の助成により実施された.

文 献

- [1] C. Waldschmidt, J. Hasch and W. Menzel, "Automotive Radar — From First Efforts to Future Systems," *IEEE Journal of Microwaves*, vol. 1, no. 1, pp. 135–148, 2021, doi: 10.1109/JMW.2020.3033616.
- [2] Q. Cheng, A. A. Ihalage, Y. Liu and Y. Hao, "Compressive Sensing Radar Imaging With Convolutional Neural Networks," *IEEE Access*, vol. 8, pp. 212917–212926, 2020, doi: 10.1109/ACCESS.2020.3040498.
- [3] S. Skaria, A. Al-Hourani and R. J. Evans, "Deep-Learning Methods for Hand-Gesture Recognition Using Ultra-Wideband Radar," *IEEE Access*, vol. 8, pp. 203580–203590, 2020, doi: 10.1109/ACCESS.2020.3037062.
- [4] X. Yang, P. Chen, M. Wang, S. Guo, C. Jia and G. Cui, "Human Motion Serialization Recognition With Through-the-Wall Radar," *IEEE Access*, vol. 8, pp. 186879–186889, 2020, doi: 10.1109/ACCESS.2020.3029247.
- [5] J. Kim, S. Lee, Y. -H. Kim and S. -C. Kim, "Classification of Interference Signal for Automotive Radar Systems With Convolutional Neural Network," *IEEE Access*, vol. 8, pp. 176717–176727, 2020, doi: 10.1109/ACCESS.2020.3026749.
- [6] H. -S. Lim, J. Jung, J. -E. Lee, H. -M. Park and S. Lee, "DNN-Based Human Face Classification Using 61 GHz FMCW Radar Sensor," *IEEE Sensors Journal*, vol. 20, no. 20, pp. 12217–12224, 15 Oct. 15, 2020, doi: 10.1109/JSEN.2020.2999548.
- [7] A. P. Sligar, "Machine Learning-Based Radar Perception for Autonomous Vehicles Using Full Physics Simulation," *IEEE Access*, vol. 8, pp. 51470–51476, 2020, doi: 10.1109/ACCESS.2020.2977922.
- [8] J. Lien, N. Gillian, M. E. Karagozler, P. Amihoud, C. Schwesig, E. Olson, H. Raja, and I. Poupyrev, "Soli: ubiquitous gesture sensing with millimeter wave radar," *Proc. The 43rd Int'l Conference and Exhibition on Computer Graphics & Interactive Techniques*, vol. 35, no. 4, article no. 142, 2016.
- [9] Z. Lu, X. Chen, Q. Li, X. Zhang, and P. Zhou, "A hand gesture recognition framework and wearable gesture-based interaction prototype for mobile devices," *IEEE Transactions on Human-Machine Systems*, vol. 44, no. 2, pp. 293–299, 2014.
- [10] A. Nelson, G. Singh, R. Robucci, C. Patel, and N. Banerjee, "Adaptive and personalized gesture recognition using textile capacitive sensor arrays," *IEEE Transactions on Multi-Scale Computing Systems*, vol. 1, no. 2, pp. 62–75, 2015.
- [11] P. G. Jung, G. Lim, S. Kim, and K. Kong, "A wearable gesture recognition device for detecting muscular activities based on air-pressure sensors," *IEEE Transactions on Industrial Informatics*, vol. 11, no. 2, pp. 485–494, 2015.
- [12] P. Pflawiak, T. Sośnicki, M. Niedźwiecki, Z. Tabor, and K. Rzecki, "Hand body language gesture recognition based on signals from specialized glove and machine learning algorithms," *IEEE Transactions on Industrial Informatics*, vol. 12, no. 3, pp. 1104–1113, 2016.
- [13] H. P. Gupta, H. S. Chudgar, S. Mukherjee, T. Dutta, and K. Sharma, "A continuous hand gestures recognition technique for human-machine interaction using accelerometer and gyroscope sensors," *IEEE Sensors Journal*, vol. 16, no. 16, pp. 6425–6432, 2016.
- [14] Y. Wu, K. Chen, and C. Fu, "Natural gesture modeling and recognition approach based on joint movements and arm orientations," *IEEE Sensors Journal*, vol. 16, no. 21, pp. 7753–7761, 2016.
- [15] K. Van Volkinburg and G. Washington, "Development of a wearable controller for gesture-recognition-based applications using polyvinylidene fluoride," *IEEE Transactions on Biomedical Circuits and Systems*, vol. 11, no. 4, pp. 900–909, 2017.
- [16] H. Cheng, L. Yang, and Z. Liu, "Survey on 3D hand gesture recognition," *IEEE Transactions on Circuits and Systems for Video Technology*, vol. 26, no. 9, pp. 1659–1673, 2016.
- [17] N. Rossol, I. Cheng, and A. Basu, "A multisensor technique for gesture recognition through intelligent skeletal pose analysis," *IEEE Transactions on Human-Machine Systems*, vol. 46, no. 3, pp. 350–359, 2016.
- [18] D. Wu, L. Pigou, P. J. Kindermans, N. D. H. Le, L. Shao, J. Dambre, and J. M. Odobez, "Deep dynamic neural networks for multimodal gesture segmentation and recognition," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 38, no. 8, pp. 1583–1597, 2016.
- [19] G. Zhu, L. Zhang, P. Shen, and J. Song, "Multimodal gesture recognition using 3-D convolution and convolutional LSTM," *IEEE Access*, vol. 5, pp. 4517–4524, 2017.
- [20] T. Fan, C. Ma, Z. Gu, Q. Lv, J. Chen, D. Ye, J. Huangfu, Y. Sun, C. Li, and L. Ran, "Wireless hand gesture recognition based on continuous-wave Doppler radar sensors," *IEEE Transactions on Microwave Theory and Techniques*, vol. 64, no. 11, pp. 4012–4020, 2016.
- [21] P. Molchanov, S. Gupta, K. Kim, and K. Pulli, "Short-range FMCW monopulse radar for hand-gesture sensing," *IEEE Radar Conf.*, pp. 1491–1496, 2015.
- [22] Y. Kim and B. Toomajian, "Hand gesture recognition using micro-Doppler signatures with convolutional neural network," *IEEE Access*, vol. 4, pp. 7125–7130, 2016.
- [23] Y. Kim and H. Ling, "Human activity classification based on micro-Doppler signatures using a support vector machine," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 47, no. 5, pp. 1328–1337, 2009.
- [24] Y. Lang, C. Hou, Y. Yang, D. Huang, and Y. He, "Convolutional neural network for human micro-Doppler classification," *Proc. European Microwave Conference*, 2017.
- [25] S. Y. Kim, H. G. Han, J. W. Kim, S. Lee, and T. W. Kim, "A hand gesture recognition sensor using reflected impulses," *IEEE Sensors Journal*, vol. 17, no. 10, pp. 2975–2976, 2017.
- [26] T. Sakamoto, X. Gao, E. Yavari, A. Rahman, O. Boric-Lubecke, and V. Lubecke, "Radar-based hand gesture recognition using I-Q echo plot and convolutional neural network," *Proc. 2017 IEEE Conference on Antenna Measurements & Applications*, doi: 10.1109/CAMA.2017.8273461, 2017.
- [27] T. Sakamoto, X. Gao, E. Yavari, A. Rahman, O. Boric-Lubecke, and V. M. Lubecke, "Hand gesture recognition using a radar echo I-Q plot and convolutional neural network," *IEEE Sensors Letters*, vol. 2, no. 3, doi:10.1109/LESENS.2018.2866371, Sep. 2018.
- [28] G. Vinci, S. Lindner, F. Barbon, S. Mann, M. Hofmann, A. Duda, R. Weigel, and A. Koelpin, "Six-port radar sensor for remote respiration rate and heartbeat vital-sign monitoring," *IEEE Trans. Microw. Theory Tech.*, vol. 61, no. 5, pp. 2093–2100, 2013.
- [29] J. C. Y. Lai, Y. Xu, E. Gunawan, E. C.-P. Chua, A. Maskooki, Y. L. Guan, K.-S. Low, C. B. Soh, and C.-L. Poh, "Wireless sensing of human respiratory parameters by low-power ultrawideband impulse radio radar," *IEEE Trans. Instrum. Meas.*, vol. 60, no. 3, pp. 928–938, 2011.
- [30] W. Hu, Z. Zhao, Y. Wang, H. Zhang, and F. Lin, "Noncontact accurate measurement of cardiopulmonary activity using a compact quadrature Doppler radar sensor," *IEEE Trans. Biomed. Eng.*, vol. 61, no. 3, pp. 725–735, 2014.
- [31] A. Rahman, V. M. Lubecke, O. Boric-Lubecke, J. H. Prins, and T. Sakamoto, "Doppler radar techniques for accurate respiration characterization and subject identification," *IEEE J. Emerg. Sel. Topics Circuits Syst.*, vol. 8, no. 2, pp. 350–359, 2018.
- [32] H.-S. Cho and Y.-J. Park, "Detection of heart rate through a wall using UWB impulse radar," *J. Healthc. Eng.*, vol. 2018, pp. 1–7, 2018.
- [33] L. Ren, Y. S. Koo, H. Wang, Y. Wang, Q. Liu, and A. E. Fathy, "Non-contact multiple heartbeats detection and subject localization using UWB impulse Doppler radar," *IEEE Microw. Wirel. Compon. Lett.*, vol. 25, no. 10, pp. 690–692, 2015.
- [34] K. Naishadham, J. E. Piou, L. Ren, and A. E. Fathy, "Estimation of cardiopulmonary parameters from ultra wideband radar measurements using the state space method," *IEEE Trans. Biomed. Circuits Syst.*, vol. 10, no. 6, pp. 1037–1046, 2016.
- [35] L. Ren et al. L. Ren, H. Wang, K. Naishadham, O. Kilic, and A. E. Fathy, "Phase-based methods for heart rate detection using UWB impulse Doppler radar," *IEEE Trans. Microw. Theory Techn.*, vol. 64, no. 10, pp. 3319–3331, 2016.
- [36] W.-P. Hung, C.-H. Chang, and T.-H. Lee, "Real-time and noncontact

- impulse radio radar system for μm movement accuracy and vital-sign monitoring applications," *IEEE Sen. J.*, vol. 17, no. 8, pp. 2349–2358, 2017.
- [37] S. Nahar, T. Phan, F. Quaiyum, L. Ren, A. E. Fathy, and O. Kilic, "An electromagnetic model of human vital signs detection and its experimental validation," *IEEE J. Emerg. Sel. Topics Circuits Syst.*, vol. 8, no. 2, pp. 338–349, 2018.
- [38] E. Schires, P. Georgiou, and T. S. Lande, "Vital sign monitoring through the back using an UWB impulse radar with body coupled antennas," *IEEE Trans. Biomed. Circuits Syst.*, vol. 12, no. 2, pp. 292–302, 2018.
- [39] K.-K. Shyu, L.-J. Chiu, P.-L. Lee, T.-H. Tung, and S.-H. Yang, "Detection of breathing and heart rates in UWB radar sensor data using FVPIEF based two-layer EEMD," *IEEE Sens. J.*, vol. 19, no. 2, pp. 774–784, 2018.
- [40] S. Wu, T. Sakamoto, K. Oishi, T. Sato, K. Inoue, T. Fukuda, K. Mizutani, and H. Sakai, "Person-specific heart rate estimation with ultra-wideband radar using convolutional neural networks," *IEEE Access*, vol. 7, no. 1, pp. 168484–168494, doi:10.1109/ACCESS.2019.2954294, Dec. 2019.
- [41] 阪本卓也, 武 淑瓊, 佐藤 亨, "機械学習と超広帯域レーダによる非接触心拍計測," 電子情報通信学会総合大会, BT-1-4, 広島大学 東広島キャンパス (東広島市), March 2020.
- [42] T. Sakamoto, R. Imasaka, H. Taki, T. Sato, M. Yoshioka, K. Inoue, T. Fukuda, and H. Sakai, "Feature-based correlation and topological similarity for interbeat interval estimation using ultra-wideband radar," *IEEE Trans. Biomed. Eng.*, vol. 63, no. 4, pp. 747–757, 2016.