

# レーダを用いた非接触型血圧推定に関する研究

代表研究者	山本 幸平	慶應義塾大学大学院理工学研究科	後期博士課程 3年
共同研究者	石坂 秀壮	慶應義塾大学大学院理工学研究科	前期博士課程 2年
共同研究者	大槻 知明	慶應義塾大学理工学部情報工学科	教授

## 1 はじめに

血圧の上昇は脳心血管病を発症させる原因の一つであることが知られており [1]–[3], 日常生活の中で血圧を自己計測することが重要視されている. 代表的な血圧測定法として聴診法とオシロメトリック法がある. 聴診法は医師により行われる血圧測定法である. 上腕を帯状の腕帯 (カフ) で圧迫し, カフの圧力を変化させた際の血管音を聴くことで血圧を測定する. カフを減圧していくことで, 動脈が開いて血液が流れ始め, 血管音が聞こえ始める. さらにカフの減圧を進めていくことで血管音は聞こえなくなる. このとき, 血管音が聞こえ始めたときのカフの圧力が収縮期血圧 SBP (Systolic Blood Pressure), 血管音が聞こえなくなったときのカフの圧力が拡張期血圧 DBP (Diastolic Blood Pressure) に対応する. しかし, 聴診法は医師の技量次第で測定誤差が生じやすい. また, 腕の太さなどの体格によって血管音が聞こえにくいという問題もある. これに対し, オシロメトリック法は上腕をカフで圧迫し, カフの圧力を変化させた際の血管運動に起因する波形 (脈波) に基づき血圧を測定する. 腕を減圧すると脈波の振幅は急激に大きくなり, より減圧すると脈波の振幅は小さくって, 最終的に安定する. このとき, 脈波の振幅が急激に大きくなったときのカフの圧力が収縮期血圧 SBP, 脈波の振幅が安定したときのカフの圧力が拡張期血圧 DBP に対応する. オシロメトリック法医療分野で広く普及している血圧測定法であり, 家庭用血圧計にもこの手法が応用されている. しかし, オシロメトリック法は聴診法同様にカフを装着する必要がある, 例えば睡眠中の不快感やカフの装着位置に起因する測定誤差などが問題とされている.

そこで, カフを用いず非接触で血圧を推定する手法として, ドップラーレーダを用いた手法が検討されている [4]. ドップラーレーダは観測対象に電波を照射し, その反射波を受信する. 電波が動く対象に反射される際, ドップラー効果により電波の周波数は変化するため, 反射波を解析することで, 対象の動く向きや速さを観測することができる. この原理により, ドップラーレーダは心拍検出 [5]–[8] や呼吸検出 [9] – [12], 行動推定 [13]–[16], 人間検出 [17]–[19] への利用が検討されている. 従来法 [4] は, ドップラーレーダを用いて取得した心拍に起因する胸壁変位波形から, 血圧と関連のある PTT (Pulse Transit Time) を算出することで, 血圧を推定する. しかし, 心拍に起因する胸壁変位の雑音対電力比 SNR (Signal to Noise Ratio) は, 呼吸や体の揺らぎと比較して極めて低い. そのため, 心拍に起因する胸壁変位波形は, 呼吸や体の揺らぎにより容易に歪むため, こうした雑音が生じる環境下で PTT を算出することは難しい.

本研究では, ドップラーレーダを用いた血圧推定精度を改善するために, 雑音により歪んだ胸壁変位波形の特徴と血圧と関連のある綺麗な胸壁変位波形の特徴を深層学習により関連付けることで, 歪んだ胸壁変位波形から綺麗な胸壁変位波形を再構成する手法を提案する. 学習データを用意する際, 歪んだ胸壁変位波形を取得し, これに対応する綺麗な胸壁変位波形を取得することは不可能である. そこで, 本研究では綺麗な胸壁変位波形を定義し, この胸壁変位波形に対して雑音を付加することで学習データを生成する. そして, 実験を通して, 提案法が血圧と関連のある綺麗な胸壁変位波形を再構成できることを示す. また, 再構成した胸壁変位波形から血圧値を推定することで, 血圧の推定精度についても示す.

胸壁変位波形の再構成による血圧推定精度の改善に加えて, 本研究ではより雑音にロバストな血圧と関連のある特徴量についても検討する. 前述の通り, 胸壁変位波形は呼吸や体の揺らぎに起因する雑音の影響により歪みやすい. そこで, 雑音によりロバストな特徴量を検討することで, 血圧推定精度の改善を図る.

以下では, 2章でドップラーレーダの原理について説明し, 3章で関連研究について述べる. 4章では深層学習法を用いた胸壁変位波形の再構成に基づく血圧推定法について説明する. 続いて, 5章では雑音にロバストな血圧と関連のある特徴量について説明する. そして, 6章で深層学習法を用いた胸壁変位波形の再構成に基づく血圧推定法および雑音にロバストな血圧と関連のある特徴量について特性評価を行い, 6章で結論と展望を示す.

## 2 ドップラーレーダの原理

本章では、ドップラーレーダの原理について説明する。図1にドップラーレーダを用いた血圧推定のシステムモデルを示す。まず、送信アンテナ  $T_x$  から被験者の胸壁に向けて電波  $T(t) = \cos(2\pi ft + \Phi(t))$  が照射される。ここで、 $f$  および  $\Phi(t)$  はそれぞれ搬送波周波数および位相雑音である。送信された電波は胸壁により反射され、電波の周波数が変化するドップラー効果が生じる。ドップラー効果による周波数シフトは、以下のように表される。

$$f_{\text{Doppler}} = \mp \frac{4\pi vt}{\lambda} \times \frac{1}{2\pi t} = \mp \frac{4v}{\lambda}. \quad (1)$$

ここで、 $\lambda$  は搬送波の波長、 $v$  は胸壁変位の速さである。胸壁がドップラーレーダから遠ざかる方向に動く場合、 $f_{\text{Doppler}}$  は負の値となり、近づく方向に動く場合、 $f_{\text{Doppler}}$  は正の値となる。ドップラー効果により周波数が変化した電波  $R(t)$  は受信アンテナ  $R_x$  により受信される。

$$R(t) = \cos\left(2\pi ft - \frac{4\pi d}{\lambda} - \frac{4\pi x(t)}{\lambda} + \Phi\left(t - \frac{2d}{c}\right)\right). \quad (2)$$

ここで、 $d$  は送受信アンテナと被験者の胸壁までの距離であり、 $x(t)$  は心拍や呼吸に起因する胸壁変位である。受信信号  $R(t)$  は LNA (Low Noise Amplifier) を通過し、ベースバンド信号  $B(t)$  にダウンコンバートされる。

$$B(t) = \cos\left(\theta + \frac{4\pi x(t)}{\lambda} + \Delta\Phi(t)\right). \quad (3)$$

ここで、 $\theta$  は  $d$  と  $f$  により決まる固有な位相シフトであり、 $\Delta\Phi(t)$  は残差位相雑音である。続いて、ベースバンド信号  $B(t)$  に直交ミキサを適用することで、位相差が  $2/\pi$  である2つの信号  $I(t)$  および  $Q(t)$  が生成され、OP-AMP (Operational Amplifier) によって振幅が調整される。

$$I(t) = \cos\left(\theta + \frac{\pi}{4} + \frac{4\pi x(t)}{\lambda} + \Delta\Phi(t)\right), \quad (4)$$

$$Q(t) = \cos\left(\theta - \frac{\pi}{4} + \frac{4\pi x(t)}{\lambda} + \Delta\Phi(t)\right). \quad (5)$$

ドップラーレーダを用いて電波を胸壁に照射する場合、電波の周波数は心臓の動きに起因する胸壁の変位により変化する。そのため、ドップラーレーダの受信信号  $I(t)$  および  $Q(t)$  には心臓の動きに起因する胸壁変位成分が含まれる。この原理に基づき、受信信号  $I(t)$  および  $Q(t)$  から心拍成分を抽出し、それらが生じるタイミングを検出することで、心拍間隔や心拍数を推定する信号処理法が多く検討されている。本研究では、心拍検出法を用いて心拍を検出した後に、 $I(t)$  および  $Q(t)$  に対して、信号処理法を適用することで血圧を推定する。

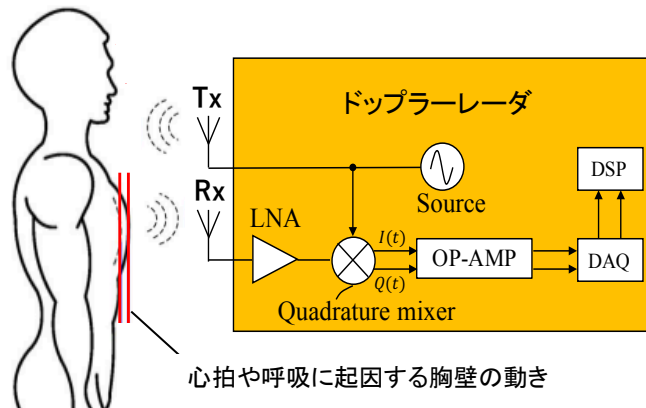


図1. ドップラーレーダを用いた血圧推定のシステムモデル

### 3 関連研究

本章では、関連研究について説明する。従来、カフを用いない血圧推定法として、PTT に基づく手法が検討されている [5]-[8]。PTT とはある点からある点へと脈波が伝播する時間であり、PTT と血圧の間には相関があることが知られている。PTT を取得する手法として、PPG (Photoplethysmography) センサと ECG (Electrocardiogram) センサを用いる手法 [20] や PPG センサと SCG (Seismocardiogram) センサ [21]、2つの ECG センサ [22]、2つの PPG センサを用いる手法 [20] がある。しかし、PPG センサおよび ECG センサ、SCG センサはいずれも接触型センサであり、特に長期的な血圧モニタリングにおいてはデバイス装着による不快感の課題がある。

非接触で血圧を推定する手法として、ドップラーレーダを用いた手法がある [4][21]。従来法 [4][24] は、ドップラーレーダを用いて胸壁変位波形を取得し、血圧と相関のある特徴量を胸壁変位波形から取得することで血圧を推定する。図 2 にドップラーレーダを用いて取得した胸壁変位波形の一例を示す。具体的に、従来法 [4] では、胸壁変位波形の立ち上がりから最大ピーク直前のピークまでの時間を  $T_1$ 、胸壁変位波形の立ち上がりから最大ピーク直後の極小までの時間を  $ED$  として、以下のように  $PTT_{cf}$  を算出する。

$$PTT_{cf} = \frac{ED - T_1}{2}. \quad (6)$$

このとき、 $PTT_{cf}$  と血圧の間には負の相関があることが知られており、 $PTT_{cf}$  を算出することで、以下のように収縮期血圧 SBP を推定できる。

$$SBP = a \times PTT_{cf} + b. \quad (7)$$

ここで、 $a$  および  $b$  は線形回帰で得られるパラメータであり、実験を通して式(6)および式(7)を用いて血圧推定可能なことが示されている。

一方、従来法 [21] では、図 2 に示されるように、胸壁変異波形のピーク間隔を  $T$ 、胸壁変異波形のピークからその直後の谷となる点までの時間を  $\tau_f$ 、その谷となる点から胸壁変異波形のピークまでの時間を  $\tau_r$  として、以下のように血圧を推定できる。

$$DBP = DBP_0 \times e^{-\beta(\tau_f - \tau_{f0})}. \quad (8)$$

$$SBP = DBP + (SBP_0 - DBP_0) \times (\tau_f^2 / T) / (\tau_{f0}^2 / T).$$

ここで、 $DBP_0$ 、 $SBP_0$ 、 $\tau_{f0}$  はそれぞれ  $DBP$ 、 $SBP$ 、 $\tau_f$  の平均値であり、 $\beta$  は被験者ごとにチューニングされるパラメータである。実験を通してこれら従来法による推定血圧と真値血圧との間には相関があることが示されている。しかし、胸壁変位波形は呼吸や体の揺らぎにより容易に歪むため、こうした雑音が生じる環境下では  $PTT_{cf}$  の検出精度は劣化する。事実、従来法 [4] が血圧を推定する際、被験者は呼吸を止める必要がある。そのため、呼吸や体の揺らぎに起因する雑音が生じる環境下で、より高精度に血圧を推定できる手法が求められる。




図 2. ドップラーレーダを用いて取得した胸壁変位波形の一例

## 4 深層学習法を用いた胸壁変位波形の再構成に基づく血圧推定法

本章では、深層学習法を用いた胸壁変位波形の再構成に基づく血圧推定法のアルゴリズムおよび学習データの生成法について説明する。

### 4-1 アルゴリズム

提案法ではまず、呼吸や体の揺らぎに起因する雑音の影響を低減するために、ドップラーレーダの受信信号  $I(t)$  および  $Q(t)$  に対して BPF (Band Pass Filter) を適用する。ここで、カットオフ周波数は 0.7 Hz および 7.0 Hz とする。続いて、フィルタ後の  $I(t)$  および  $Q(t)$  から以下のように位相信号  $\phi(t)$  を算出する。

$$\phi(t) = \arctan\left(\frac{Q(t)}{I(t)}\right) \quad (9)$$

ここで、図 2 に示すような胸壁変位波形は位相信号  $\phi(t)$  において検出できる。提案法では、種々のドップラーレーダを用いた心拍検出アルゴリズムにより心拍を検出後、少なくとも 1 つの胸壁変位波形が含まれるように 0.8 秒ごとに胸壁変位波形を抽出する。そして、歪んだ胸壁変位波形を深層学習モデルに入力し、綺麗な胸壁変位波形へと再構成する。ここで、再構成される胸壁変位波形は従来法 [4] で定義される特徴量、つまり胸壁変位波形の立ち上がりから最大ピーク直前のピークまでの時間  $T_1$ 、胸壁変位波形の立ち上がりから最大ピーク直後の極小までの時間  $ED$  を抽出できるものである。深層学習モデルとしては、LSTM (Long Short Term Memory) を利用する。LSTM は時系列データの特徴を捉えるのに有用な深層学習法の一つであり [25]、信号分類 [26][27] や信号予測 [28] に広く用いられている。そのため、LSTM を用いることで歪んだ胸壁変位波形と綺麗な胸壁変位波形それぞれの特徴を関連づけることができると期待できる。具体的に、提案法で用いる深層学習モデルは、歪んだ胸壁変位波形を入力する入力層に続いて、隠れ層 64 の LSTM 層、ユニット数 1024 の全結合層、綺麗な胸壁変位波形を出力する出力層の 4 層構造である。ここで、隠れ層およびユニット数は予備実験を基に最適化した。学習データの多様性や学習データ数、入力データのサンプリング周波数などを考慮して、調整する必要がある。

深層学習モデルを通して胸壁変位波形を再構成後、式(6)を用いて  $PTT_{cf}$  を算出する。そして、 $PTT_{cf}$  と SBP の線形回帰を行うことで式(7)におけるパラメータ  $a$  および  $b$  を取得し SBP を推定する。しかし、再構成した脈波においても胸壁変位波形の立ち上がりから最大ピーク直前のピークまでの時間  $T_1$ 、胸壁変位波形の立ち上がりから最大ピーク直後の極小までの時間  $ED$  を算出できない場合がある。この場合、提案法では別の手法を用いて  $T_1$  および  $ED$  を算出する [26]。  $T_1$  を算出できない場合、胸壁変位波形を 2 回微分し、微分結果の最大ピーク直前において値が負から正の方向の切り替わる点を検出し、この点を用いて  $T_1$  を算出する。同様に、 $ED$  を算出できない場合、胸壁変位波形を 2 回微分し、微分結果の最大ピーク直後において値が負から正の方向の切り替わる点を検出し、この点を用いて  $ED$  を算出する。

### 4-2 学習データの生成法

提案法において、深層学習モデルの入力は呼吸や体の揺らぎにより歪んだ胸壁変位波形、出力は綺麗な胸壁変位波形である。しかし、歪んだ胸壁変位波形を取得後、これに対応する綺麗な胸壁変位波形を取得することは不可能である。そこで、本研究では綺麗な胸壁変位波形を定義し、この胸壁変位波形に対して雑音を付加することで学習データを生成する。具体的に、綺麗な胸壁変位波形を  $T_1$  および  $ED$  を算出でき、それらから取得可能な  $PTT_{cf}$  と血圧の間に -0.8 よりも高い相関がある波形と定義し、綺麗な胸壁変位波形を取得する。

付加する雑音を生成するため、予備実験を通して雑音統計量を確認した。まず、被験者ごとに綺麗な胸壁変位波形の平均振幅を算出し、続いて歪んだ胸壁変位波形の振幅から綺麗な胸壁変位波形の平均振幅を減算し雑音成分を取得した。図 3 に複数被験者から取得した雑音成分のヒストグラムを示す。この図より、雑音成分は平均 0 のガウス分布によく従うことがわかる。そのため、本研究では綺麗な胸壁変位波形に対して平均 0 のガウス分布に従う雑音を付加することで学習データを生成する。




図 3. 雑音成分のヒストグラム

## 5 雑音にロバストな血圧と相関のある特徴量

本章では、雑音にロバストな血圧と相関のある特徴量を提案する。こうした特徴量を抽出するために、まず呼吸や体の揺らぎの影響が低い高周波数帯の心拍成分を抽出する。具体的に、カットオフ周波数が 5 Hz および 30 Hz の BPF を  $I(t)$  および  $Q(t)$  に適用し [30]、複素信号  $S(t)$  を以下のように算出する。

$$S(t) = I(t) + jQ(t) \quad (10)$$

続いて、STFT (Short Time Fourier Transform) を  $S(t)$  に適用し、スペクトログラムを算出する。ここで、ウィンドウサイズおよびカットオフ周波数は 128 ms および 2 ms とする。図 4 に算出したスペクトログラムの一例を示す。この図より、帯状のパワーが生じていることがわかる。これらは心拍に起因するパワーである。提案法では、5 Hz から 30 Hz および -30 Hz から -5 Hz の周波数帯のスペクトルを積分し、スペクトル積分値を算出する。図 5 にスペクトル積分値の一例を示す。ここで、この図では ECG 信号も示されており、スペクトル積分値および ECG 信号の振幅値は比較しやすいように正規化されている。この図より、ECG の R ピークが生じる時間に、スペクトル積分値でも心拍成分が生じていることがわかる。各拍動に対応する心拍成分は心臓の収縮と拡張に起因するピークから構成され、図 5 で示されるように、ECG の R ピークに対してスペクトル積分値では主に 2 つのピークが生じている。心臓の収縮および拡張に関連する成分は、血圧推定に有益な情報となり得ることから、提案法では心臓の収縮および拡張を反映する特徴量をスペクトル積分値から抽出する。具体的に、スペクトル積分値に対してカットオフ周波数が 2 Hz の HPF (High Pass Filter) を適用し、心臓の収縮および拡張に関連する成分以外の周波数成分を除去する。続いて、ウィンドウサイズおよびステップサイズがそれぞれ 30 秒および 1 秒の STFT をフィルタ後のスペクトル積分値に適用してスペクトログラムを算出する。図 6(a) に算出したスペクトログラムを示す。この図より、3 Hz 付近に強いパワーが生じていることがわかる。このパワーは心臓の収縮および拡張に起因するピークの時間差に関連したものである。パワーが強く生じる支配的な周波数を抽出するため、各周波数におけるパワーを積分する。図 6(b) に積分して得られた周波数分布を示す。心臓の収縮および拡張に起因するピークの時間差に関連する周波数は、STFT のウィンドウサイズ 30 秒の中でも変化するため、提案法では周波数分布の最大ピークを中心とした 1 Hz のウィンドウを設定し、このウィンドウ内のピーク値を重みとして周波数の加重平均値を算出して、これを支配的な周波数として検出する。

心臓の収縮および拡張に起因するピークの時間差に関連する周波数に加えて、スペクトル積分値から心拍数を推定し、これも血圧推定の特徴量として利用する。心拍数を推定するために、スペクトル積分値に BPF を適用する。ここで、カットオフ周波数は約 40 bpm (beat per minute) および 120 bpm に対応する 0.8 Hz および 2 Hz とする。続いて、先ほどと同様にウィンドウサイズおよびステップサイズがそれぞれ 30 秒お

よび1秒の STFT をフィルタ後のスペクトル積分値に適用してスペクトログラムを算出する. 図 7(a)に算出したスペクトログラムを示す. ここで, 心拍数に対応する真値周波数は1.07 Hzである. 図 7(a)からわかるように, 真値周波数付近に強いパワーが生じていることがわかる. これは心拍数に起因するパワーであり, 支配的な周波数を抽出することで, 心拍数を推定できる. しかし, 前述したように, 心拍数に相当する周波数は, STFT のウィンドウサイズ30秒の中でも変化する. そこで, 心臓の収縮および拡張に起因するピークの時間差に関連する周波数を抽出する手法と同様に, 周波数ごとにスペクトルを積分し, 得られた周波数分布から周波数の加重平均値を算出して, これを心拍数に相当する支配的な周波数として検出する.

2つの特徴量を検出後, これらを用いて重回帰分析により STFT のウィンドウサイズ30秒間の平均 SBP を推定する.




図 4. スペクトログラム




図 5. スペクトル積分値

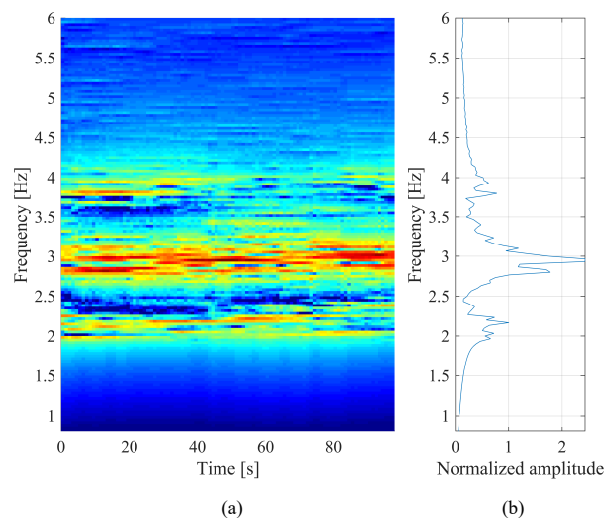


図 6. (a) ウィンドウサイズおよびステップサイズがそれぞれ30秒および1秒の STFT をスペクトル積分値に適用して得られたスペクトログラム. (b) スペクトログラム上の各周波数におけるスペクトルを積分した結果




図 7. (a) ウィンドウサイズおよびステップサイズがそれぞれ 30 秒および 1 秒の STFT をスペクトル積分値に適用して得られたスペクトログラム. (b) スペクトログラム上の各周波数におけるスペクトルを積分した結果

## 6 特性評価

### 6-1 深層学習法を用いた胸壁変位波形の再構成に基づく血圧推定法の特性評価

#### 6-1-1 実験諸元

提案法の血圧測定精度を評価するために、ドップラーレーダを用いて  $PTT_{cf}$  と収縮期血圧 SBP を測定する実験を行い、推定した  $PTT_{cf}$  と真値 SBP との間の相関係数を算出した。ここで、相関係数は 1 に近いほど強い正の相関を示し、-1 に近いほど強い負の相関を示す。 $PTT_{cf}$  と SBP の間には負の相関があるため、本実験においては負の相関が強いほど結果は良い。また、血圧推定精度を評価するために、推定 SBP と真値 SBP の間の MAE (Mean Absolute Error) を算出した。

使用したドップラーレーダの送信周波数は 24 GHz であり、サンプリング周波数および送信電力は 1000 Hz および 1 mW である。学習データとして、3 人の被験者から胸壁変位波形を取得した。ドップラーレーダと被験者間の距離は 0.5 m であり、胸部と同じ高さに設置した。学習データとして綺麗な胸壁変位波形を取得するために、被験者に呼吸を止めるよう指示し、無呼吸の時間に綺麗な胸壁変位波形を取得した。ここで、1 回の観測時間は 120 秒であり、被験者が呼吸を止めるタイミングは真値血圧値が出力される前後数十秒間である。また、真値血圧を取得する前後約 5 秒間で算出した  $PTT_{cf}$  の平均を真値血圧に対応する  $PTT_{cf}$  とした。綺麗な胸壁変位波形を取得後、胸壁変位波形の SNR を 5 dB から 40 dB の範囲で変化させながら、綺麗な胸壁変位波形に雑音を付加して学習データを生成した。一方、テストデータは学習データとは異なる 6 人の被験者から 4 つの場合に分けて取得した。(i) ドップラーレーダと被験者間の距離が 50 cm で、被験者が呼吸する場合、(ii) ドップラーレーダと被験者間の距離が 100 cm で、被験者が呼吸する場合、(iii) ドップラーレーダと被験者間の距離が 50 cm で、被験者が呼吸しない場合、(iv) ドップラーレーダと被験者間の距離が 100 cm で、被験者が呼吸しない場合。

また、深層学習モデルの学習では、損失関数として平均二乗誤差 MSE (Mean Squared Error) を使用し、バッチサイズおよびエポック数をそれぞれ 256 および 15 に設定した。

## 6-1-2 実験結果

図4に深層学習モデルの入力と出力の一例を示す。この図より、入力された胸壁変位波形からは最大ピーク直前のピークを検出できず、 $PTT_{cf}$  を算出することはできない一方、出力された胸壁変位波形では  $PTT_{cf}$  を算出できることがわかる。この結果は、呼吸や体の揺らぎによる雑音の影響で歪んだ胸壁変位波形と綺麗な胸壁変位波形の特徴を深層学習モデルにより関連づけられることを示している。表1に各条件における  $PTT_{cf}$  と真値 SBP の間の相関係数を示す。この表より、多くの場合において LSTM の入力胸壁変位波形から算出した  $PTT_{cf}$  よりも LSTM の出力胸壁変位波形から算出した  $PTT_{cf}$  の方が SBP との間に強い相関があることがわかる。これにより、提案法が歪んだ胸壁変位波形を血圧と相関のある綺麗な胸壁変位波形に再構成できることが確認できる。

表2に各条件における推定 SBP と 真値 SBP の間の MAE を示す。結果より、各条件における LSTM 入力と出力の平均 MAE の差は条件 (i) から (iv) でそれぞれ、0.95 mmHg, 0.16 mmHg, 1.06 mmHg, 0.36 mmHg である。条件 (i) と (iii) を比較すると、条件 (i) における平均 MAE の差は条件 (iii) における値よりも小さく、呼吸の有無に関係なく提案法が血圧推定精度を改善することがわかる。また、条件 (ii) と (iv) における平均 MAE の差は、それぞれ条件 (i) と (iii) における差よりも小さい。これはドップラーレーダと被験者間の距離が長くなるほど、胸壁変位波形の SNR が劣化するためである。そのため、検出距離による心拍成分の SNR 劣化によりロバストな手法を検討する必要がある。




図4. 深層学習モデルの入力と出力の一例

表1. 各条件における  $PTT_{cf}$  と真値 SBP の間の相関係数



被験者	条件 (i)		条件 (ii)		条件 (iii)		条件 (iv)	
	LSTM 入力	LSTM 出力	LSTM 入力	LSTM 出力	LSTM 入力	LSTM 出力	LSTM 入力	LSTM 出力
1	-0.666	-0.792	0.191	-0.363	0.114	-0.796	0.405	-0.541
2	-0.413	-0.754	0.036	-0.227	0.557	0.483	-0.333	-0.405
3	-0.625	-0.632	0.585	0.031	-0.056	-0.228	-0.046	-0.233
4	0.228	-0.655	-0.296	-0.293	-0.176	-0.609	-0.673	-0.537
5	-0.214	-0.054	-0.089	0.154	-0.388	-0.738	-0.687	-0.724
6	0.127	-0.571	-0.039	-0.521	-0.186	-0.490	-0.161	-0.644
平均	-0.251	<u>-0.576</u>	0.039	<u>-0.203</u>	-0.023	<u>-0.396</u>	-0.318	<u>-0.514</u>

表 2. 各条件における推定 SBP と真値 SBP の間の MAE [mmHg]

被験者	条件 (i)		条件 (ii)		条件 (iii)		条件 (iv)	
	LSTM 入力	LSTM 出力	LSTM 入力	LSTM 出力	LSTM 入力	LSTM 出力	LSTM 入力	LSTM 出力
1	2.65	1.98	1.48	1.41	6.47	3.45	4.18	3.77
2	6.15	4.13	8.74	7.97	8.36	7.74	9.39	7.76
3	1.50	1.48	4.11	5.42	3.65	3.68	4.08	4.05
4	5.07	4.68	5.34	4.78	4.69	4.08	3.18	3.91
5	3.88	3.93	2.89	2.85	6.01	4.61	2.65	2.36
6	4.80	2.18	2.23	1.41	5.71	5.02	1.62	1.08
平均	4.01	<u>3.06</u>	4.13	<u>3.97</u>	5.82	<u>4.76</u>	4.18	<u>3.82</u>

## 6-2 雑音にロバストな血圧と相関のある特徴量の特性評価

### 6-2-1 実験諸元

提案した特徴量に基づく血圧推定の精度を評価するために、データベース [31] を利用した。このデータベースは 30 人の健常者（14 人の男性，16 人の女性）のデータから構成されている。しかし，血圧データの欠損により 4 人の被験者は利用できないため，26 人の被験者データを用いて評価した。被験者はベッドに仰向けに横たわっている状態で，観測時間は 600 秒である。ドップラーレーダの送信周波数は 24 GHz，サンプリング周波数は 2000 Hz である。ドップラーレーダと被験者の胸壁までの距離は 40 cm である。連続値血圧データはサンプリング周波数 200 Hz で取得されており，ドップラーレーダと連続値血圧データは同期している。評価指標としては，前の特性評価と同様に，特徴量と真値 SBP の間の相関係数，および推定 SBP と真値 SBP の間の MAE を算出した。

### 6-2-2 実験結果

まず，重回帰分析を被験者ごとに行う場合の特性について示す。特徴量として，心拍数のみを用いた場合，心臓の収縮および拡張に起因するピークの時間差に関する特徴量のみを用いた場合，両方を用いた場合の相

関係数はそれぞれ 0.36, 0.30, 0.41 となり, 2 つの特徴量を組み合わせることで, 最も高い相関係数を達成することを確認した. 加えて, 特徴量として, 心拍数のみを用いた場合, 心臓の収縮および拡張に起因するピークの時間差に関する特徴量のみを用いた場合, 両方を用いた場合の MAE はそれぞれ 2.99 mmHg, 2.68 mmHg, 2.58 mmHg となり, 相関係数同様に 2 つの特徴量を組み合わせることで, 最も小さい MAE を達成することを確認した. 今回のデータベースを用いた評価では, 血圧変化が小さい被験者に対しては, 相関係数が小さくなる一方で, MAE は小さくなる場合があることも確認した. また, 特徴量と真値 SBP の間に正の相関を確認できる被験者がいる一方で, 負の相関を確認できる被験者がいることも確認した. これは特徴量と真値 SBP の間の関係性は被験者ごとに異なることを示唆している.

一方, 重回帰分析を全被験者で行う場合, 相関係数および MAE は重回帰分析を被験者ごとに行う場合と比較して劣化した. 一般的に, 特徴量と真値 SBP の間の関係性は非線形であり, 先に述べたように被験者ごとに異なる. 加えて, ドップラーレーダを用いた血圧推定においては, 胸壁の厚さといった個人特有の特徴も考慮する必要がある.

## 7 結論と展望

本研究では, 日常的な血圧自己測定を目的として, ドップラーレーダを用いた血圧推定法について検討, 提案した. ドップラーレーダを用いて取得可能な胸壁変位波形は, 血圧と相関のある特徴量を有することが知られているが, 呼吸や体の揺らぎに起因する雑音の影響により, この波形は歪みやすい. そのため, 日常生活の中で血圧を推定する上で, 血圧と相関のある特徴量の抽出は容易でない. そこで, 歪んだ胸壁変位波形を血圧と相関のある胸壁変位波形に再構成する深層学習モデルを構築した. 実験の結果, 歪んだ胸壁変位波形を再構成することで, 呼吸の影響が低減され血圧推定精度が改善することを確認した.

また, 本研究では雑音によりロバストな特徴量を用いた血圧推定についても検討した. 具体的に, 特徴量として, 心拍数および心臓の拡張, 収縮に起因する成分を抽出し, パブリックデータベースを用いてそれら特徴量と血圧の間に相関があることを確認した.

今後は, 深層学習モデルの構造および損失関数, 入出力データを変更することで, 胸壁変異波形の再構成精度をさらに改善することを検討する. その上で, 同一のデータベースを用いてこれら 2 つの手法を比較評価する. そして, 雑音や検出距離による SNR 劣化に対し, よりロバストな特徴量を選定し, それらを組み合わせることで血圧を推定することを検討する. また, 特徴量を抽出する際には, 本研究で検討した深層学習に基づく波形の再構成技術を利用し, より正確な特徴量抽出を検討する.

## 【参考文献】

- [1] Prospective Studies Collaboration, "Age-specific relevance of usual blood pressure to vascular mortality: A meta-analysis of individual data for one million adults in 61 prospective studies," *The Lancet*, vol. 360, no. 9349, pp. 1903-1913, Dec. 2002.
- [2] Prospective Studies Collaboration, "Blood cholesterol and vascular mortality by age, sex, and blood pressure: a meta-analysis of individual data from 61 prospective studies with 55000 vascular deaths," *The Lancet*, vol. 370, pp. 1829-1839, Dec. 2007.
- [3] V. Perkovic, R. Huxley, Y. Wu, D. Prabhakaran, S. MacMahon, "The burden of blood pressure-related disease: a neglected priority for global health," *Hypertension* vol. 50 pp. 991-997, Oct. 2007.
- [4] H. Zhao, X. Gu, H. Hong, Y. Li, X. Zhu and C. Li, "Non-contact Beat-to-beat Blood Pressure Measurement Using Continuous Wave Doppler Radar," *Int. Conf. IEEE Microw. Symp. Dig.*, pp. 1413-1415, June 2018.
- [5] M. Li and J. Lin, "Wavelet-Transform-Based Data-Length-Variation Technique for Fast Heart Rate Detection Using 5.8-GHz CW Doppler Radar," *IEEE Trans Microwave Theory and Techniques*, vol. 66, pp. 568-576, Jan. 2018.

- [6] V. L. Petrovic, M. M. Jankovic, A. V. Lupsic, V. R. Mihajlovic, and J. S. Popovic-Bozovic, "High-accuracy real-time monitoring of heart rate variability using 24 GHz continuous-wave Doppler radar" *IEEE Access*, vol. 7, pp. 74721-74733, June 2019.
- [7] J. Tu and J. Lin, "Fast acquisition of heart rate in noncontact vital sign radar measurement using time-window-variation technique," *IEEE Trans. Instrumentation and Measurement*, vol. 65, pp. 112-122, Jan. 2016.
- [8] 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. Biomedical Engineering*, vol. 61, no. 3, pp. 725-735, Nov. 2013.
- [9] Y. S. Lee, P. N. Pathirana, C. L. Steinfort, and T. Caelli, "Monitoring and analysis of respiratory patterns using microwave doppler radar," *IEEE journal of translational engineering in health and medicine*, vol. 2, pp. 1-12, Feb. 2014.
- [10] N. T. P. Van, L. Tang, A. Singh, N. D. Minh, S. C. Mukhopadhyay, and S. F. Hasan, "Self-identification respiratory disorder based on continuous wave radar sensor system," *IEEE Access*, vol. 7, pp. 40019-40026, 2019.
- [11] H. Zhao, H. Hong, D. Miao, Y. Li, H. Zhang, Y. Zhang, and X. Zhu, X, "A noncontact breathing disorder recognition system using 2.4-GHz digital-IF Doppler radar," *IEEE journal of biomedical and health informatics*, vol. 23, pp. 208-217, Jan. 2018.
- [12] 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 Journal on Emerging and Selected Topics in Circuits and Systems*, vol. 8, pp. 350-359, Mar. 2018.
- [13] B. Y. Su, and K. C. Ho, M. ZJ. Rantz, and M. Skubic, "Doppler radar fall activity detection using the wavelet transform," *IEEE Transactions on Biomedical Engineering*, vol. 62, pp. 865-875, Mar. 2015.
- [14] M. G. Amin, Y. D. Zhang, F. Ahmad,, and K. D. Ho, "Radar signal processing for elderly fall detection: The future for in-home monitoring," *IEEE Signal Processing Magazine*, vol. 33, pp. 71-80, Feb. 2016.
- [15] S. Z. Gurbuz and M. G. Amin, "Radar-based human-motion recognition with deep learning: Promising applications for indoor monitoring," *IEEE Signal Processing Magazine*, vol. 36, pp. 16-28, Apr. 2019.
- [16] Y. Kim and T. Moon, "Human detection and activity classification based on micro-Doppler signatures using deep convolutional neural networks," *IEEE geoscience and remote sensing letters*, vol. 13, pp. 8-12, Jan. 2016.
- [17] Y. Kim, S. Ha, and J. Kwon, "Human detection using Doppler radar based on physical characteristics of targets. *IEEE Geoscience and Remote Sensing Letters*," vol. 1, pp. 289-293, 2014.
- [18] J. Kwon and N. Kwak, N, "Human detection by neural networks using a low-cost short-range Doppler radar sensor," *Int. Conf. IEEE Radar Conference (RadarConf)*, pp. 0755-0760, May 2017.
- [19] Y. Kim and T. Moon, "Human detection and activity classification based on micro-Doppler signatures using deep convolutional neural networks," *IEEE geoscience and remote sensing letters*, vol. 13, pp. 8-12, 2015.
- [20] B. Mishra and N. Thakkar, "Cuffless blood pressure monitoring using PTT and PWV methods," *Int. Conf. IEEE Recent Innovations in Signal processing and Embedded Systems (RISE)* pp. 395-401, Oct. 2017.
- [21] J. Sola, M. Proenca, D. Ferrario, J. A. Porchet, A. Falhi, O. Grossenbacher, and C. Sartori, "Noninvasive and nonocclusive blood pressure estimation via a chest sensor," *IEEE Trans. on Biomedical Engineering*, vol. 60, pp. 3505-3513, Nov. 2013.
- [22] K. Soerensen, A. K., Verma, A. Blaber, J. Zanetti, S. E. Schmidt, J. J. Struijk, and K. Tavakolian, "Challenges in using seismocardiography for blood pressure monitoring," *Int. Conf. Computing in Cardiology (CinC)* pp. 1-4, Sep. 2017.

- [23] T. H. Huynh, R. Jafari, and W. Y. Chung, "Noninvasive cuffless blood pressure estimation using pulse transit time and impedance plethysmography," *IEEE Trans. on Biomedical Engineering*, vol. 66, pp. 967-976, Apr. 2018.
- [24] T. Ohata, K. Ishibashi, and G. Sun, "Non-Contact Blood Pressure Measurement Scheme Using Doppler Radar," *Int. Conf. Engineering in Medicine and Biology Society (EMBC)*, pp. 778-781, July 2019.
- [25] S. Hochreiter and J. Schmidhuber, "Long Short-Term Memory," *Neural Comput.*, vol. 9, no. 8, pp. 1735-1780, 1997.
- [26] O. Yildirim, "A novel wavelet sequence based on deep bidirectional LSTM network model for ECG signal classification," *Computers in biology and medicine*, vol. 96, pp. 189-202, 2018.
- [27] P. Wang, A. Jiang, X. Liu, J. Shang, and L. Zhang, "LSTM-based EEG classification in motor imagery tasks," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 26, pp. 2086-2095, Nov. 2018.
- [28] R. Wang, X. Liang, X. Zhu, and Y. Xie, "A feasibility of respiration prediction based on deep Bi-LSTM for real-time tumor tracking," *IEEE Access*, vol. 6, pp. 51262-51268, 2018.
- [29] A. Qasem and A. Avolio, "Determination of Aortic Pulse Wave Velocity From Waveform Decomposition of the Central Aortic Pressure Pulse," *Hypertension*, vol. 51, no. 2, pp. 1188-1195, Jan. 2008.
- [30] K. Yamamoto, K. Toyoda, and T. Ohtsuki, "Spectrogram-based Non-contact RRI Estimation by Accurate Peak Detection Algorithm," *IEEE Access*, vol. 6, pp. 60369-60379, Oct. 2018.
- [31] S. Schellenberger, K. Shi, T. Steigleder, A. Malessa, F. Michler, L. Hameyer, and A. Koelpin, "A dataset of clinically recorded radar vital signs with synchronised reference sensor signals," *Scientific data*, vol. 7, pp. 1-11, Sep. 2020.

### 〈発 表 資 料〉

題 名	掲載誌・学会名等	発表年月
Non-contact Blood Pressure Measurement using Doppler Radar based on Waveform Analysis by LSTM	IEEE International Conference on Communications 2021 (ICC2021)	2021.6
LSTM による波形再構成に基づく非接触血圧測定法の精度改善	電子情報通信学会総合大会	2021.3
LSTM による波形解析に基づくドップラーレーダを用いた非接触血圧測定	電子情報通信学会ヘルスケア・医療情報通信技術研究会 (MICT)	2020.11