

# 博士論文

## 容量性心電図実用化に向けた 波形変動認識手法の検討

城戸 孝士郎

奈良先端科学技術大学院大学  
先端科学技術研究  
情報理工プログラム

主指導教員 金谷 重彦教授  
計算システムズ生物学研究室(情報科学領域)

令和5年2月20日提出

本論文は奈良先端科学技術大学院大学 先端科学技術研究科に  
博士(工学)授与の要件として提出した博士論文である。

城戸 孝士郎

審査委員:

主査 金谷 重彦 (情報科学領域 教授)  
佐藤 嘉伸 (情報科学領域 教授)  
黄 銘 (情報科学領域 助教)  
小野 直亮 (情報科学領域 准教授)  
MD.ALTAf-UL-AMIN (情報科学領域 准教授)

## 容量性心電図実用化に向けた

### 波形変動認識手法の検討

城戸 孝士郎

#### 内容梗概

心疾患は国内の死因の第二位に位置していて、検査手段としては心電図や画像診断、カテーテルを用いるものなどがある。中でも心電図は心臓が全身に血液を送るときの収縮・拡張する際に発生する電位を測定したものであり、心臓の生理動態との関連が深く、また電極を貼るだけで測定ができる簡便さも兼ね備えている。疾患の早期発見のため長時間・常時測定に関心が集まっているが、電極を貼って長時間測定を行うと、アレルギーなどの皮膚の炎症を引き起こす。それを睡眠時であるが解決したのが容量結合心電計である。静電容量を介して心電位を測定するため寝具に組み込むと服を着て寝具で横になるだけで測定が可能である。このように測定された容量性心電図にはいくつかの問題点がある。それはノイズと姿勢変更による波形変動である。このような不安定な信号を実用化するために心臓が動く際の振動を測定した心弾図と組み合わせ、ノイズや姿勢変更に伴う波形変動の認識を目指す。本研究では容量性心電図と心弾図を同時に測定する実験環境を整え、実際に測定しデータを収集する。収集したデータに対して、1D-CNNを用いてノイズの強度の分類、睡眠時姿勢の分類を行った。ノイズの強度を分類することでノイズのない信号を96%抽出することができ、抽出した信号は診断等に用いることができる。また睡眠時姿勢の分類に関しては1D-CNNをベースとした多入力モデルを用いて、容量性心電図と心弾図を入力として睡眠時姿勢を分類した。ランダムにデータを分割し学習・検証を行った結果、約98%の精度で分類することができた。これらの分類器のよって測定部分と実際に診断等に應用するまでの間を埋めることができ、容量心電図の実用化に当たっての問題点の解決に寄与している。

キーワード

非接触心電図, 睡眠中モニタリング, 不整脈, 自動認識

---

\*奈良先端科学技術大学院大学 先端科学技術研究科 博士論文, 令和 5年 2月 20日.

# Estimation of Waveform Variability for Practical Application of Capacitive electrocardiogram

Koshiro Kido

## Abstract

Heart disease is the second leading cause of death in Japan. There are several ways to examine the heart, including electrocardiography, diagnostic imaging, and catheterization. Among these, the electrocardiogram measures the electrical potential generated when the heart contracts and expands to pump blood throughout the body, and is closely related to the physiological dynamics of the heart. There is a growing interest in long-term, constant measurement for early detection of diseases, but long-time measurement with electrodes on the skin causes skin irritation such as allergies. The capacitance coupled electrocardiograph is a solution to this problem, although it is used during sleep. Since it measures cardiac potential via capacitance, it can be incorporated into bedding, allowing measurement simply by lying down on the bedding with clothes on. This capacitive electrocardiogram (cECG) has several problems. One is the instability of the waveform due to noise and postural changes. In order to use such unstable signals, the analysis is performed by combining Ballistocardiograph (BCG), which measures the oscillation of the beating heart, and the aforementioned capacitive ECG. In this study, we prepared an experimental environment for measuring cECG and BCG, and actually measured and collected the data. For the collected data, we used 1D-CNN to classify the noise intensity and sleep posture. By classifying the noise intensity, 96% of noise-free signals can be extracted, and the extracted signals can be used for diagnosis and other purposes. For sleep posture classification, a multi-input model based on 1D-CNN was used to classify sleep posture using cECG and BCG as inputs. The results of training and validation by dividing the data at random showed that the classification accuracy was about 98%. These classifiers can bridge the gap between measurement and actual diagnosis, and contribute to solving problems in the practical application of cECG.

Keywords:

*Capacitive electrocardiogram, sleeping heart monitoring, ballistocardiography, autonomic detection*

---

\* Doctoral Dissertation, Graduate School of Science and Technology, Nara Institute of Science and Technology, February 20, 2023.

## 目次

<b>1. はじめに</b> .....	<b>1</b>
<b>1.1 心電図</b> .....	<b>4</b>
1.1.1 心電図の基本波形 .....	4
1.1.2 心電図誘導 .....	6
1.1.3 心電図検査の利点と問題点 .....	8
<b>1.2 容量性心電図</b> .....	<b>9</b>
1.2.1 容量結合心電計の構成 .....	9
1.2.2 容量性心電図の問題点 .....	10
1.2.3 容量性心電図に関する研究の現状 .....	12
<b>1.3 心弾図</b> .....	<b>14</b>
<b>1.4 容量性心電図と心弾図の違い</b> .....	<b>14</b>
<b>1.5 課題と本研究の目的</b> .....	<b>15</b>
1.5.1 課題 .....	15
1.5.2 目的 .....	15
<b>2. データ測定・前処理</b> .....	<b>17</b>
2.1 測定装置 .....	17
2.2 測定実験 .....	18
2.3 ラベル付け .....	19
2.4 前処理 .....	20
<b>3. 容量性心電図のみを用いた解析</b> .....	<b>21</b>
3.1 概要 .....	21
3.2 分類モデル .....	22
3.3 学習・検証 .....	24
3.4 結果 .....	27
3.5 考察 .....	29
<b>4. 容量性心電図と心弾図を組み合わせた解析</b> .....	<b>31</b>

4.1 概要.....	31
4.2 分類モデル.....	32
4.3 学習・検証.....	32
4.4 結果.....	35
4.5 考察.....	38
4.6 今後の展望.....	40
5. まとめ.....	41
6. 謝辞.....	42
7. 参考文献.....	43
8. 業績リスト.....	46



## 図目次

図 1	刺激電動系と心電図の関係[7]	5
図 2	心電図の基本波形	5
図 3	標準12誘導の概略 (bは[8]より引用)	7
図 4	容量結合心電計の電極配置	9
図 5	心電図ベクトルと誘導の関係	11
図 6	姿勢変更と波形の関係	11
図 7	本研究の対応部分	16
図 8	測定装置の構成	17
図 9	ノイズに関連するラベルの各波形	19
図 10	前処理の概要	20
図 11	処理の概要	21
図 12	分類モデルの概略	22
図 13	ノイズの判定に使う深層学習モデル構造	25
図 14	姿勢の判定に使う深層学習モデル構造	25
図 15	各分類結果に関する混合行列	28
図 16	中程度のノイズが含まれた信号 (M) の誤分類例	30
図 17	処理の流れ	31
図 18	多入力深層学習モデルの概略	33
図 19	多入力深層学習モデルの構造	34
図 20	各分類結果に関する混合行列	36
図 21	訓練データの被験者数に対する分類スコアの推移	37

## 表目次

表 1	標準12誘導	7
表 2	容量性心電図と心弾図の特徴	14
表 3	ノイズの判定に使うデータセット	24
表 4	睡眠時姿勢の判定に使うデータセット	24
表 5	学習条件	24
表 6	ノイズの強度の分類結果	27
表 7	睡眠時姿勢の分類結果	27
表 8	被験者単位でデータ分割した場合の睡眠時姿勢の分類結果	27
表 9	心弾図単体での分類結果	35
表 10	心弾図単体を被験者単位で分割した場合の分類結果	35
表 11	容量性心電図と心弾図を組み合わせた分類結果	35
表 12	容量性心電図と心弾図を被験者単位で分割した場合の分類結果	35

# 1. はじめに

令和2年時点で心疾患は悪性新生物に次いで日本国内における死因の第二位に位置している[1]。心疾患は様々な検査によって診断される。CTやMRIなどの画像診断や心電図による診断、カテーテルを挿入しての検査など様々な検査を組み合わせで診断される。

その中でも心電図検査は電極を貼ることで可能な簡易な検査手法である。心電図は心筋の電氣的な活動を電極から測定したものであり、心筋の虚血や不整脈の有無など、心疾患の兆候が表れる心臓の健康状態の評価指標として有用である。心電位の計測は心疾患診断に広く使われていて、画像診断やその他の検査手法と異なり心臓の活動の根本である電氣的活動が反映されるため医学的な解釈に適していて、また他の非電氣的な計測手段と異なる重要な生理学的な情報を含んでいる。

心電図検査は心臓の健康状態を評価する上で有用な検査方法ではあるが、異常心拍の出現頻度は疾患の種類や重症度によって様々である。そのため、短時間の心電図測定では心疾患の兆候を見逃す場合があり長時間の測定が必要になる場合もある。現在心電図を測定する手段としてはホルター心電計があり、これは電極を身体に貼り24時間心電図を測定し測定後医師が評価・診断するという形で運用されている。Barretらの実験ではホルター心電計による24時間の測定では61件の異常が検出されたのに対して、14日間の測定では96件の異常が検出されている。[2]また睡眠時のモニタリングは中～高リスクの不整脈検出に有用という報告もある[3]。このように長時間測定は重要であり、目的に応じた多様な個人用心電位測定デバイスの開発が必要である。また近年では心疾患もその他の疾患と同様に早期発見・早期治療への関心が高まっており、個人用の心電計も開発されている[4]。またスマートウォッチ等の一部ウェアラブルデバイスにも心電図測定機能が搭載されつつあり、常時測定に適したデバイスと、データ処理手法は日々進化している。

文献では小型のデバイスによって長時間心電図が測定できることが確認できているが、これらは導電性の物質を介した電氣的結合通して心電位を測定している。そのため測定の際に電極を被験者の身体に貼り付ける必要があり、長時間の電極貼り付けにはいくつかの問題点がある。

具体的な問題点として長時間の電極貼付による皮膚トラブルがあげられる。短時間の貼付であれば問題が発生する確率は低い、数時間を超える長時間測定ではかぶれや皮膚アレルギーを引き起こす恐れがある。また電極自体が身体にあることによるストレスも問題となる。電極が接触不良などのトラブルによって測定不能になるケースも多く、測定している間に常に注意を払う必要がある。また電極から線が出ていることで被験者の身体動作に制限がかかりこういった面でも被験者にストレスを与えている。

近年は電極貼付式の心電位計測とは異なる方法で心臓をモニタリングする技術が開発されている。心弾図 (BCG)は心筋が血液を送り出す際の振動を加速度センサ等で測定し、その波形から心臓の健康状態を評価することが可能である[5]。またPhotoplethysmography (PPG)は光学的な測定技術であり、皮膚に赤外光を当ててヘモグロビンの濃度変化から血流を監視し、心機能を評価することができる[6]。これらの方法は電氣的ではない物理現象を用いて心臓の収縮・拡張の周期を推定し、大まかに心臓の生理状態を評価することができるが、心電位のように心筋の電氣的な活動が直接反映されるわけではないので、具体的な生理的・病理的な情報が欠けていて、病気の診断には不十分であるという懸念はある。

従来の心電図計測の電極貼付によるデメリットを排除しつつ、生理的・病理的な情報を維持できている測定機器が容量結合心電計である。容量結合心電計は皮膚と電極の間の容量性の結合を介して心電位を測定している。容量性の結合であるため、皮膚と電極の間に布があっても信号を測定することができる。そのため寝具に電極を配置することで、衣服を着用し、横になることで心電位を測定することができる。この時身体に直接電極を貼り付けていないため従来の心電計の電極貼付によるデメリットを回避できる。また測定された容量性心電図は電氣的な信号であるため、心電図と同様に生理的・病理的な情報を含んでいる。

容量結合心電計を実用化するにあたっては欠点があり、それは姿勢による波形の変化と、ノイズの多さである。本研究で扱う容量性心電図は寝具に組み込んでいるため、睡眠時の姿勢によって、電極が身体に当たる部位が異なり、波形も変動する。心電図は電極をつける位置によって医学的な解釈は異なるので、波形ともに電極位置の情報があることが望ましい。また電極を直接貼らないため、従来の電極を直接貼る心電計と比べてノイズが乗りやすいという欠点もある。ノイズが多い場合生理的・病理的な情報が読み取れず診断に使えない場合もある。これ

らの欠点から現状実用化が難しいという側面がある。

本研究では容量性心電図の実用化における課題を解決するために、信号処理・機械学習の手法を用いてノイズの程度・睡眠時姿勢の識別を行う。ノイズの少ない信号を抽出し、睡眠時姿勢を電極位置に対応させることで、電極を固定している従来心電図と同様の運用ができるようになる。また本研究では心弾図を組み合わせ解析を行う。心弾図は心臓の拍動の振動を測定したものであるが、心電図とは異なり機械運動を測定したものであり、睡眠時姿勢などの身体の状態・動きを反映しながら心臓の生理動態に関する情報も一部含んでいる。また容量性心電図と異なり、電氣的なノイズの影響を受けづらい。これらの二つの信号を解析し、ノイズの少ない信号の抽出と、睡眠時姿勢の把握を目指す。

## 1.1 心電図

心臓は全身の臓器や筋肉等に血液を送るポンプの役割を果たす臓器である。血液に含まれる酸素および栄養成分を送ることで臓器や筋肉は正常に機能する。一日で約10万回の収縮・拡張を繰り返し、約7000Lの血液を全身に送っている。心臓が正常に血液を循環させるためには規則正しい収縮・拡張が必要であり、この規則的に心筋を動かすための膜電位の変動が心電位である。この微弱な電位の変動を体表面にある電極から測定し、波形の形で表したものが心電図である。心電図の波形の各部分が心臓の各部位の状態に対応するため、心臓の状態を評価することができ、心電図検査は狭心症や心筋梗塞等の虚血性心疾患、心肥大、不整脈など様々な心疾患の診断材料となる。

### 1.1.1心電図の基本波形

心臓の全体に順に電気信号を伝えるための機構を刺激伝導系（図1）と呼び、その刺激電動系にそって発生する電位を測定しているのが心電図である。刺激電動系の始まりは右心房にある洞結節から始まり、この部位が心臓の拍動のリズムを作り出している。洞結節から発生した電気信号は心房全体に伝わり、それにより心房が収縮する。心房内電気信号の伝達を示すのがP波である。

心房を伝わった刺激は房室結節という部位に着く。この部位は心房から伝わってきた信号を心室に伝える役割を担っていて、心房と心室の収縮の時間差を生み出す部位でもある。時間差を生むことによって効率の良い血液運搬を行うことができる。房室結節からヒス束、プルキンエ線維、右脚・左脚等などの通り心室全体に刺激がいきわたり、心室が収縮する。心室が収縮する際にQRS波が発生する。QRS波の最初の下向きの波をQ波、その次の上向きの波をR波、その後の下向きの波をS波と呼ぶ。心室の心筋繊維の興奮がおさまると、心室が拡張する際の波形がT波である。それぞれの基本波形を（図2）に示す。




図1 刺激電動系と心電図の関係[7]




図2 心電図の基本波形

心電図の各基本波形は下記のような生理的・病理的な情報を含んでいる。

**P波**：小さい上向きの波形で心房の収縮を意味している。心房細動等の心房に関わる疾患と関連し波形が変化する。

**QRS波**：上下に振れる波で心室の収縮を示す。心室性期外収縮（PVC）や心室細動等では形状が変化する。正常な波形であれば一番振幅が大きくなる。

**T波**：心室の興奮がおさまりに拡張する際に起こる。虚血性心疾患等で特徴的な変化を起こし、心弾の指標となる。

**PQ間隔**：P波始端とQ波始端の間隔を示す。AVブロック等の疾患ではP波とQRSの間隔が広くなる。

### 1.1.2心電図誘導

心電図における誘導とは測定の際の電極の配置を中心とした測定形式である。以下に主な誘導の種類を示す。

#### ・四肢誘導

四肢に電極を取り付けて、複数の角度から心電位を測定する誘導法である。両腕間で起きた電位差をI誘導、右腕と足の間の電位差をII誘導、左腕と足の間の電位差をIII誘導とする（図3のa）。測定法としては、後述する標準12誘導より簡単であるが、心臓各部分の生理状態をある程度反映できる。

#### ・標準12誘導

健康診断等で一般的に用いられる誘導が標準12誘導である。この方法は四肢に4つ、胸に6つの計10個の電極を貼り、12個のチャンネル（四肢誘導6つ、胸部誘導6つ）で心電図を測定する。この誘導法は様々な部位で電位を測定することで各部位における心臓の立体的な電氣的活動を解釈することができる（図3）（表1）。

#### ・ホルター心電計

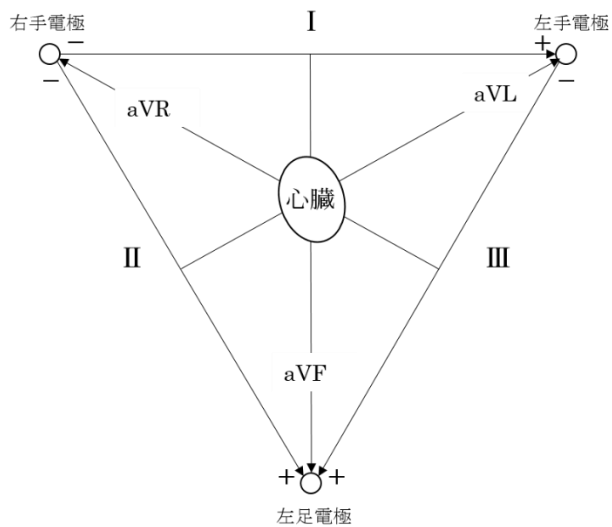
ホルター心電計は不整脈の検査に用いる小型の心電計であり、一般的に24時間、または48時間連続的に測定を行う。測定後に医師が診断を行うが、HR（1分当たりの心拍数）やSTレベルは自動解析結果がトレンドとして表示され、波形と

同時に見ながら診断を行う。一部の自動解析があるとはいえ、24時間の波形を医師が手動で診断するのは多大な労力を伴う。


誘導法に関しては、12誘導を測定できるものもあるが、一般的にはアースを含めた5つの電極から2つの双極誘導を測定している。誘導の種類にはいくつかあり、P波を識別しやすいNASA誘導やST変化を反映しやすいCM5誘導等がある。

表 1 標準12誘導

	誘導名	計測電位
標準四肢誘導 (双極誘導)	I	左手右手間の電位
	II	左足右手間の電位
	III	左足左手間の電位
単極肢誘導	aVR	右手の電位
	aVL	左手の電位
	aVF	左足の電位
単極胸部誘導	V1	第4肋間胸骨右縁の電位
	V2	第4肋間胸骨左縁の電位
	V3	V2とV4の中間部分の電位
	V4	第5肋間鎖骨中線上
	V5	第5肋間前腋窩線上
	V6	第5肋間中腋窩線上



a. 四肢誘導



b. 胸部誘導

図3 標準12誘導の概略 (bは[8]より引用)



### 1.1.3心電図検査の利点と問題点

心電図測定は電極を貼るだけで測定できるのでCTやMRIのような大掛かりな装置を使わずとも検査をすることができる。またカテーテル検査のように身体に負担をかけることなく測定することができる。このように手軽に検査できるため健康診断のようなスクリーニング的な用途にも適している。また簡易に検査できるにもかかわらず心筋の電氣的活動を測定するため、心臓の状態が信号に反映され、心疾患を診断するには非常に有用である。

このように心電図検査は測定も容易で利点も多い検査手段であるが、電極を貼ることによる欠点も存在する。心疾患の兆候が心電図に表れる頻度は疾患の種類・重症度に応じてさまざまである。そのため検査のために長時間の測定が必要になる場合もあり、その場合は前述したホルター心電計等が用いられる。長時間の測定においては電極貼付による問題が起こる。まずは電極を貼ることによる皮膚のトラブルがあげられる。長時間電極を肌に貼るとかぶれや皮膚アレルギーなどを引き起こす可能性がある。また電極を貼ることによる動作の制限等もあり、QoLを損なってしまう。このような欠点を解決したのが、本研究で用いる直接電極を貼る必要がない容量結合心電計である。

## 1.2 容量性心電図

容量性心電図は従来の心電図とは異なり電極皮膚間の容量性の結合を介して測定された心電図であり、測定装置を容量結合心電計と呼ぶ。本研究で用いる容量結合心電計では寝具に配置した電極と皮膚で布（衣類やシーツ等）を挟むことで形成された容量性の結合を介して心電位の交流成分を測定する。容量性の結合を介することで衣類に導電性を持たせる必要がなく電極と皮膚の間に衣類やシーツがあっても心電位の測定が可能である。しかし衣類や寝具等の布はコンデンサの誘電材料と比べると比誘電率が低く、静電容量も小さくなる。そのため結合部のインピーダンスが大きくなってしまうため、通常的心電計より入力インピーダンスを大きく設定する必要がある。本研究で使用装置では公称 $1000T\Omega$ の入力インピーダンスのICを用いている。また、皮膚に直接電極を貼らないため体動によって接触状態が変わりやすくノイズの影響を受けやすい。そのため体動等によるノイズを考慮した装置の設計、信号処理アルゴリズムの設計が必要となる。

### 1.2.1 容量結合心電計の構成

本研究はUeno[9]らが開発した容量結合心電計を使用し、容量性心電図の測定を行った。電極の素材には導電性布を使用し、電極は図6のような配置としている。プラス極は仰臥位時に臀部の裏側に、マイナス極は肩甲骨の裏側に、アースは腰上部の裏側に位置するよう配置している。またプラス極に手指が触れてしまうとプラス極とマイナス極が等電位になり心電位が検出できなくなるため、手指が触れないようにプラスの電極は逆Vの字状の形にしている。

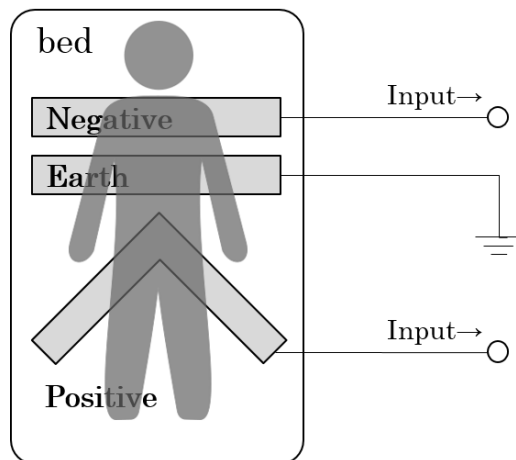



図4 容量結合心電計の電極配置

### 1.2.2容量性心電図の問題点

容量性心電図は非接触的な計測で、拘束のないモニタリングができるという利点がある一方、フレキシブルな計測による問題点もある。まず、電極を貼って測定する従来の心電計と異なり、睡眠姿勢によって電極の心臓に対する相対的な配置が変化する。図5で示しているように、四肢誘導では、刺激伝道系のベクトルモデル（灰色の矢印）が正三角形の各辺へ投影（黒い矢印）されていて、各誘導が心臓をどの角度から捉えて心電位を測定しているかが示されている。一方、容量性心電図では、姿勢の変更とともに、誘導部位が変化し、投影ベクトルの長さが変化していることがわかる。想定される睡眠時の姿勢としては仰臥位、右側臥位、左側臥位等がある。右側臥位の場合、電極はプラス極が右肩、マイナス極が右足に位置し第Ⅱ誘導に近い誘導となる（図5のb）。左側臥位ではプラス極が左肩、マイナス極が左足に位置し第Ⅲ誘導と等価になる（図5のb）。このように容量性心電図は測定する誘導（電極位置）が変化していく心電図と考えることもできる。通常、心電計では誘導が変わると波形も変わるため、図6のように姿勢によって容量性心電図の波形は変化する。最も顕著に変化するのはT波である。電極位置によって医学的な解釈は異なるため、前項にある通り心電図を測定する際、電極を貼る位置はいくつかの種類があるが規定が存在する。容量性心電図を実用化する場合は電極が身体に当たる位置を固定することは難しいため、最低限波形と電極位置（睡眠時姿勢）がセットになっていることが望ましい。

また姿勢による波形の変化とは別にノイズが乗りやすいという問題点もある。これは電極を貼らないことで、身体と電極の接触状況が変化しやすいことに起因する。これに関しては測定装置のハードウェアの部分で解決できる部分もあるが、どうしても体動の影響は受けてしまうため、信号処理のソフトウェアの部分で対応する必要がある。



a)標準四肢誘導      b)容量性結合と姿勢変化

図5 心電図ベクトルと誘導の関係




図6 姿勢変更と波形の関係

### 1.2.3容量性心電図に関する研究の現状

Uenoらは寝具に組み込んだ電極から、布越しに心電図を図る手法を提案し[10]、測定装置の改善を進みながら、この技術は心拍変動解析にまで応用されている[11]。またTakanoらによって容量性心電図とその接触信号、心弾図から仰臥位と側臥位をk-meansクラスタリングによって分類するシステムを構築した[12]。また同研究で容量性心電図の時間的精度も検証されている。これらの研究からノイズの少ない容量性心電図に対しては、従来の心電図と同様に医師による診断、自動分類手法への適用が可能であると期待される。ハード部分の改善によって、測定器の性能は向上しているが、前項で述べた容量性心電図の問題点である、睡眠時姿勢やノイズによって波形が変動する部分は解決されていない。

Wangらはノイズの少ない信号を取り出すのではなく、波形の変動の影響を受けないパラメータを抽出することで従来心電図と同様の運用を目指している[13]。またChoi[14]らは容量性心電図を測定するセンサを追加し、隣接するセンサの信号を適応フィルタの基準信号として利用し、ノイズの除去を試みている。適応センサによるノイズ除去はこれ以外にも盛んにおこなわれている[15]–[17]。しかし容量性心電図の場合ノイズを除去すれば診断に使える信号が取り出せる場合もあるが、電極を固定しないことによって身体が電極から離れている場合等において、心電位が含まれていない信号が存在する場合がある。そのため本研究ではノイズを除去するための手法ではなく、ノイズの少ない信号を選択する手法を提案する。

姿勢認識手法に関しては容量性心電図関連の分野では行われていないが、臨床分野では手術後の床ずれを防ぐ、睡眠時無呼吸症候群の兆候を見つける等の目的で需要があり、様々なセンサを用いた研究がおこなわれている。圧力センサをベッドに配置して、センサの信号から姿勢を推定する手法は盛んにおこなわれている[18]–[20]。圧電センサをベッドに配置する手法は身体にセンサを貼る必要がないという利点がある。またRF波など特定の波を照射し、反射した波を測定し、信号処理を行うことで姿勢を推定する手法もあり、YueらはRF波の反射波を測定し、機械学習アルゴリズムを介して睡眠時姿勢を予測した[21]。また可視光カメラ、赤外線カメラ、深度センシングカメラ等を用いた姿勢推定手法も存在する[22]–[24]。これは測定された映像から画像処理、機械学習アルゴリズム適用することで睡眠時姿勢を推定する。カメラを用いた手法も身体にセンサを貼る必要が

ないという利点を持つが、撮られることによるストレスやプライバシーの問題をはらんでいる。そして近年のウェアラブル端末の発達を受け、身体に装着したウェアラブル端末に搭載された加速度センサ・ジャイロセンサ等の信号から睡眠時姿勢を推定する手法も盛んに研究されている[25]–[29]。センサ信号に対して信号処理手法、機械学習アルゴリズムを適用し、睡眠時姿勢を推定している。これは身体にセンサを付ける必要はあるが、一般に普及しているウェアラブル端末を使って実現できる場合もあり、現実的に実用化しやすいという利点がある。

本研究で扱う容量性心電図では実用化のために睡眠時姿勢の検出をすることが望ましい。しかし、容量性心電図は姿勢による波形の変化傾向が個人の心臓の電気軸偏位の影響を受けることや、また信号自体もノイズ等の影響を受けやすく不安定な信号であるため、他のセンサと組み合わせる解析を行う。本研究では加速度センサの信号を容量性心電図と組み合わせる。具体的には心弾図と呼ばれる加速度センサから測定された心拍の情報を含んだ波形を解析する。この信号はベッドに取り付けた加速度センサから測定された信号であり、身体にセンサを貼る必要がない。心弾図を選んだ理由としてまずは身体にセンサを付ける必要がないことがあげられる。容量性心電図が身体にセンサを貼る必要がないことが利点の一つであるため、組み合わせるセンサでその利点をつぶさないよう心弾図を選択した。またカメラ等と違い、設備も簡易でプライバシーの問題等もないという利点もある。そして加速度センサ自体は姿勢推定に使われているセンサではあるため、装着場所は人体ではなくベッドにはなるが、睡眠時姿勢の推定に活用できるのではないかと考え採用している。次項で心弾図についての説明を行う。

### 1.3 心弾図

心弾図（または心弾動図）は心臓が拍動する際の振動・動きをベッド等に搭載した加速度センサで測定したものである。これは心臓を動かすための電氣的活動を測定した心電図と異なり、実際に動いた機械的な運動を測定したものである。心弾図は心臓の拍動が心電図から少し遅れて反映され、心電図ほど詳細ではないが心拍等の情報を得ることができる。また心電図との時間差によって心血管の状態の評価指標として有用である[30]。本研究では村田製作所のSCA11Hという一軸の加速度センサを用いる。

### 1.4 容量性心電図と心弾図の違い

容量性心電図と心弾図は双方身体に直接電極を貼らずとも測定することができる、また心臓の生理的・病的な情報を含んでいる。また心電図は電氣的活動、心弾図は機械的運動を測定しているため質の異なる情報を持つ。またノイズに対する耐性等も異なり違いを表2にまとめている。本研究ではノイズや体動に対して不安定である容量性心電図の欠点を補うため、同じく心臓の生理情報を含みながら、体動の情報も含む心弾図を組み合わせて解析を行う。

表2 容量性心電図と心弾図の特徴

	利点	欠点
容量性心電図	・心臓の生理状態の情報量が多い。（心疾患の分類に有用）	・体動以外にも静電気等の電氣的なノイズが乗りやすい。
心弾図	・振動を計測しているため電氣的ノイズの影響が少ない。（接触状態の影響が少ない）	・心拍のモニタリングはできるが、心臓の生理状態の情報量は少ない。

## 1.5 課題と本研究の目的

### 1.5.1 課題

容量性心電図を実用化するにあたっての課題は以下の二点である。

- ・睡眠時姿勢によって電極の身体から見た相対位置が変化し波形が変動する。
- ・体動などの影響を受けやすくノイズが乗りやすい。

### 1.5.2 目的

容量性心電図の測定装置は日々改善が進んでいる。またノイズの少ない心電図から自動で不整脈等を検出する手法も開発されている。本研究では容量性心電図の実用化における課題を解決するために、信号処理・機械学習の手法を用いてノイズの強度・睡眠時姿勢の識別を行う。それによって、容量性心電図の測定部分と医師による診断、または自動解析を行う応用部分の間を埋めることができる。ノイズの少ない信号を抽出し、睡眠時姿勢を電極位置に対応させることで、電極を固定している従来心電図と同様の運用ができるようになる。また本研究では心弾図を組み合わせて解析を行う。心弾図は心臓の拍動の振動を測定したものであるが、心電図とは異なり機械運動を測定したものであり、睡眠時姿勢などの身体の状態・動きを反映しながら心臓の生理動態に関する情報も一部含んでいる。また容量性心電図と異なり、電気的なノイズの影響を受けづらい。これらの二つの信号を解析し、ノイズの少ない信号の抽出と、睡眠時姿勢の把握を目指す。

第2章ではデータ測定環境と測定実験、第3章では容量性心電図のみで解析を行い、第4章では心弾図と組み合わせて解析を行う。



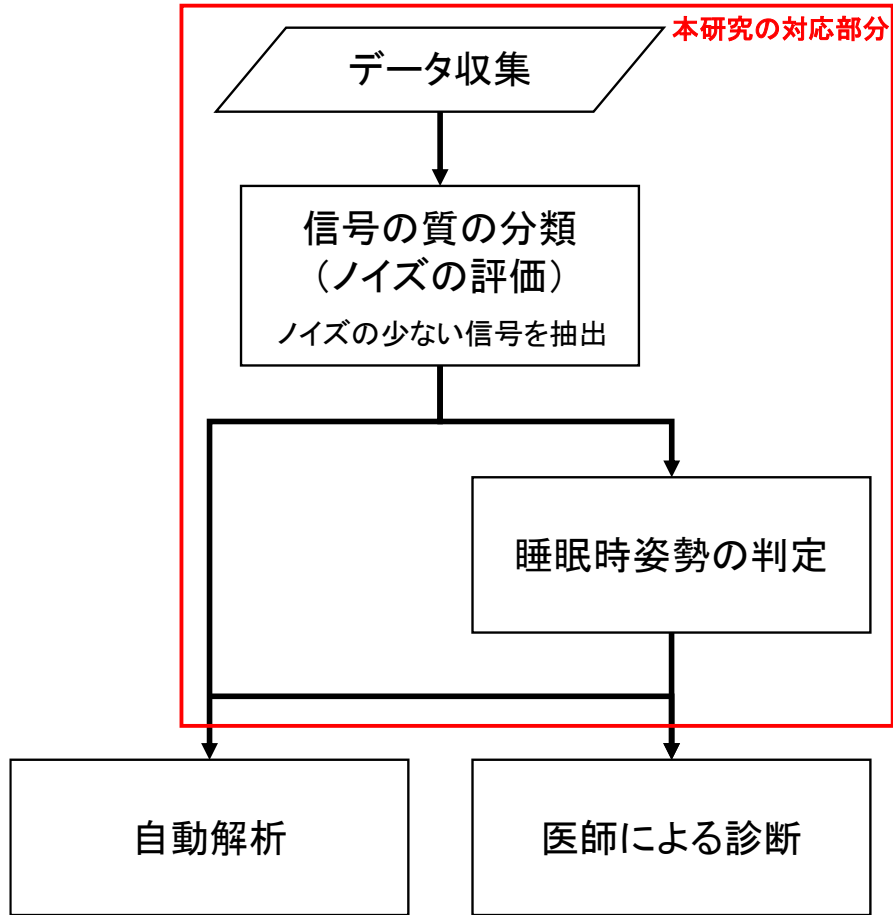


図7 本研究の対応部分

## 2. データ測定・前処理

### 2.1 測定装置

本研究では寝具に電極を配置した容量結合心電計を用いる。測定装置の概要を図7に示す。装置構成としては容量結合心電計（T13-2701, コスミックエムイー）の電極を寝具に配置している。基本的には肩甲骨付近に当たる電極と臀部にあたる電極の間の電位を測定している。測定自体は服を着たまま行い、電極 - 服 - 皮膚で形成される容量性の結合を介して測定を行う。通常的心電計と異なり服を介することで接触部のインピーダンスが高くなるため、容量結合心電計の入力インピーダンスは $1000T\Omega$ と通常的心電計より高い値となっている。また容量結合心電計に加えて、心弾図測定のための1軸の加速度センサ（SCA11H, 村田製作所）をベッドの側面に固定している。この加速度センサによって心弾図が測定でき、体動などの被験者の運動情報もこのセンサの測定信号に反映される。これら二つの測定装置を使うことで心臓の電氣的な活動・機械的な活動を測定することが可能となる。また容量性心電図は体動の影響を受け、加速度センサも体動等の影響が波形に表れるため、ベッド身体の状態を反映する信号を測定することも可能である。容量結合心電計のサンプリング周波数は300Hz、加速度センサのサンプリング周波数は公称で1000Hzとなっている。

また測定信号に睡眠時姿勢等のラベルをつけるために実験中の映像を記録するためのカメラもベッド付近に配置している。

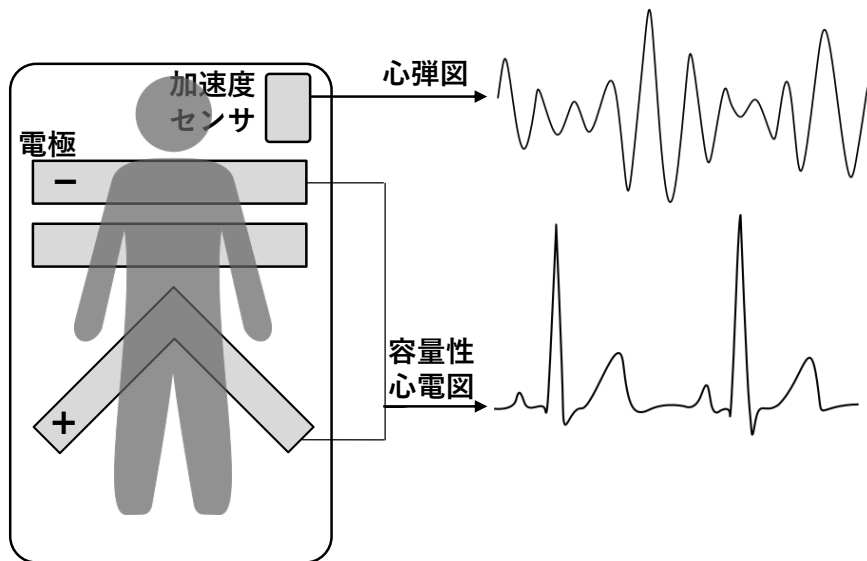


図8 測定装置の構成

## 2.2 測定実験

本研究では被験者を募って測定実験を行った。基本的には被験者はベッドに横になり、容量性心電図と心弾図を各センサから測定する。基本的な睡眠時の動きを把握するために各睡眠時姿勢で測定を行う。姿勢としては仰臥位、右側臥位、左側臥位をそれぞれ20分前後測定した。14人の被験者からデータ測定を行った。被験者は23～26歳の健康な男性であり、詳細を表 3に示す。ラベルを付けるためにカメラによる映像を同時に記録する。

表 3 被験者の年齢の分布

ID	年齢	ID	年齢
A	24	H	26
B	25	I	23
C	23	J	23
D	24	K	23
E	26	L	23
F	23	M	23
G	23	N	23

## 2.3 ラベル付け

前項の測定したデータに対して、ノイズの程度、睡眠時姿勢に関するラベルを手動で付与した。ノイズに関するラベルはS (Signal、きれいな信号)、M (Mid、ノイズが混じった信号)、N (Noise、ノイズしかない) の3クラスのラベルを付与している。ラベルSに関しては前項に示す心電図の基本波形P, Q, R, S, T波がすべて視認できる場合の波形に付与している。ラベルMはR波が視認できる場合に付与している。Nはすべての基本波形が見えない信号に対して付与される。ノイズに関する各ラベルの波形の一例を図に示す。

睡眠時姿勢に関するラベルはカメラの映像と照らし合わせて手動で付与している。具体的にはS (仰臥位)、R (右側臥位)、L (左側臥位) の3種類を付与している。




図9 ノイズに関連するラベルの各波形

## 2.4 前処理

後述する分類モデルに適用するために測定したデータを加工する必要がある。前処理としてはリサンプリングとフィルタによるノイズ除去、データの分割を行っている。前処理の流れを図 10に示す。

リサンプリングは容量性心電図と心弾図のサンプリング周波数を揃えるために心弾図側を1000Hzから300Hzにリサンプリングを行う。この際ただ間引くとエイリアシングが起こり、ノイズが乗るため、ローパスフィルタも同時に適用する。

ノイズ除去にはフィルタ処理を行っており、心電図データには0.1~40Hzの、心弾図データには0.1~100Hzの二次のバンドパスフィルタを適用している。心電図自体は0.05Hz~100Hzの範囲に心臓の生理状態に関する情報を含んでいるが、今回測定した容量性心電図に関してはノイズが多く、特にコンセント等から発生する商用交流電流由来の60Hz前後のノイズが多く乗っているため、周波数の上限を60Hzよりも低い40Hzとしている。

データ分割に関しては測定した信号（容量性心電図と心弾図）を4秒の区間で区切って分割する。区間として4秒としているのは複数の心拍が区切ったデータの中に含まれるようにするためである。正常であれば1分当たりの心臓の拍動回数は60~80回程度であり、1秒1回程度は心拍が発生する。個人差や健康かどうかによって回数は上下するので余裕をもって4秒としている。




図 10 前処理の概要

### 3. 容量性心電図のみを用いた解析

#### 3.1 概要

本章では前項に示したように容量性心電図からノイズの強度、睡眠時姿勢を検出する。データとしては前項で示した通り容量性心電図のデータを4秒間に分割したのを使い、1次元の畳み込みニューラルネットワーク（1D-CNN）を用いて各タスクの分類を行う。ノイズ強度に関しては前項に示した通り、3段階のラベルに分類する。

1D-CNNは従来心電図の不整脈の自動分類手法として頻繁に使われていて、90%を超える精度での分類を実現している[31]–[35]。また信号処理の領域では従来ウェーブレット変換など、特定のフィルタを畳み込んで、特徴を抽出する方法が使われていて、心電図の解析にも活用されている[36]。1D-CNNはウェーブレット変換等で畳み込むフィルタ形状を学習させている手法と表現することもでき、本研究では各種分類モデルに用いる。

1D-CNNノイズの強度の分類と睡眠時姿勢の分類には深さは異なるが基本的には同じ構造のモデルを用いる。処理の概要を図に示す。測定されたデータをモデルの学習用と検証用に分け、学習用データセットを用いてモデルを訓練し、検証用モデルの分類結果で評価を行う。

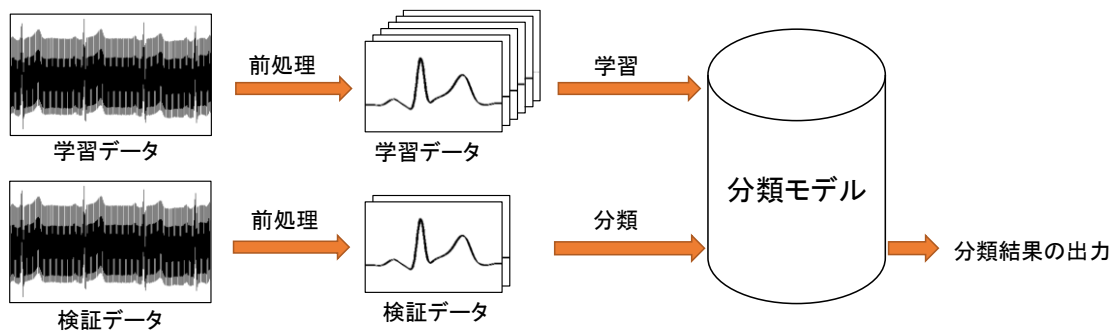


図 11 処理の概要

## 3.2 分類モデル

本研究では1D-CNNを分類モデルとして用いる。1D-CNNは基本的に畳み込み層とプーリング層で構成されたニューラルネットワークである。ネットワークの各層で入力配列を特定の長さのフィルタを畳み込むことで特定の特徴を活性化する。この際の畳み込むフィルタの係数を学習していき分類モデルが訓練される。構造の概要を図に示す。入力データのサイズはサンプリング周波数が300の信号を4秒に分割しているため $1200 \times 1$ となる。入力されたデータに対して畳み込みとプーリング処理を繰り返し、最終的に全結合層から出力層につながり出力された分布と元々ラベル付けしていた教師ラベルを表す真の分布との差を小さくするように学習する。各層についていかに説明をしていく。

### ・畳み込み層

畳み込み層に関しては指定した長さのフィルタ（カーネル）をデータの一部に対して畳み込み処理を行い、このフィルタをデータ上でスライドしながら繰り返し、畳み込み処理されたデータが出力される。各畳み込み層において複数のフィルタを畳み込みそれぞれの結果が出力される。畳み込み層の出力は活性化関数に接続される。畳み込み層の出力 $C$ は以下の式で表せる

$$C_i = \sigma \left( b + \sum_m w_m I_{i+m} \right)$$

$I$ が入力で $w$ が畳み込まれるフィルタ係数、 $b$ がバイアスとなる。処理としてはフィルタ係数 $w$ （ウェイト）を畳み込み、バイアス $b$ を足し、活性化関数 $\sigma$ が適用される。 $w$ と $b$ が処理を重ねるごとに更新される。

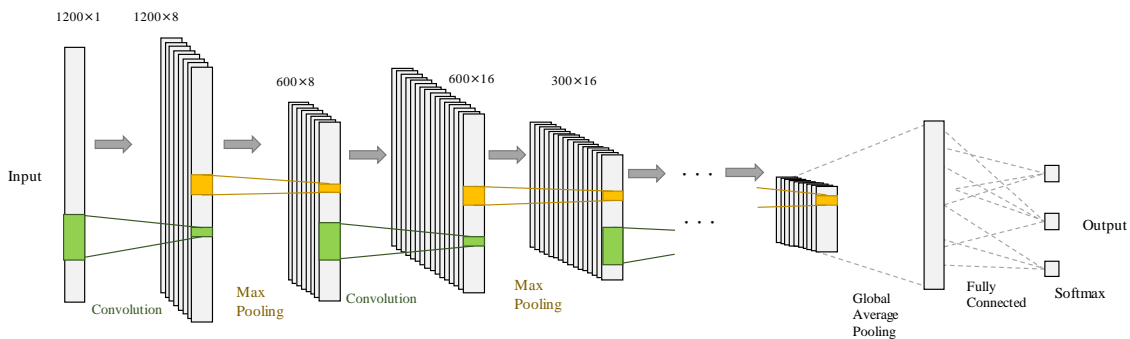


図 12 分類モデルの概略

活性化関数  $\sigma$  としてはReLU関数を使っている。Relu関数は以下のような式で表され、0より大きい入力はそのままだ出力し、0以下の入力は0にする。

$$\sigma(x) = \begin{cases} 1, & x > 0 \\ 0, & x < 0 \end{cases}$$

#### ・プーリング層

プーリング層に関しては、本研究で用いるモデルにおいてはMax poolingが適用される。これはカーネルが適用された範囲の最大値を出力に返すものであり。今回はカーネルサイズを2とし出力サイズは入力サイズの半分となる。前述した畳み込み層とプーリング層を繰り返すことで特徴は抽象化されていき、データの位置ずれ等に対して堅牢になり、抽象度を高めることによって過学習を防ぐという意味合いもある。

#### ・出力層

畳み込みとプーリングを繰り返した後、出力につなげるためにGlobal Average Poolingという処理を挟む。この処理は各チャンネルの平均を出力するもので、前段階までの時系列データを畳み込んだ特徴マップを、そのチャンネルの時系列ごとに平均を取る。この処理によって出力層は前段階までのチャンネル数のノードになり、ここから出力層の3つのノードに全結合によってつながりソフトマックス関数が適用され、出力となる。ソフトマックスはノードの合計の値を1、範囲を0~1とする関数である。これを適用した出力と (0,1,0) のような形式で数値化された教師ラベルとの分布の差を小さくするよう各層のパラメータを更新していく。分布の差はクロスエントロピーという尺度で表され、以下のような式で表される。pが真の分布、qが推定された確率分布である。

$$H = - \sum_i p_i \log q_i$$



### 3.3 学習・検証

今回はノイズの判定と睡眠時姿勢の判定を行う。各分類タスクに使うデータセットを以下に示す。学習用のデータと検証のデータをラベルの比率が変わらないようランダムに8：2に分割している。また睡眠時姿勢による容量性心電図の波形変化は個人の心臓の電気軸変位の影響を受け、個人差も大きい。そのため、睡眠時姿勢の分類に関しては汎化性能を測るため、14人の被験者を2人ずつ7グループに分け、1グループを検証用データとし、6グループを学習用データとして学習・検証を行う処理を7回繰り返す。この被験者単位でのデータ分割での学習・検証を睡眠時姿勢の分類に関しては適用する。この方法で8：2に分けた際より分類精度が大きく低下するようであれば、未知の患者に対応できないモデルであることになる。

深層学習モデルの層の深さはノイズ判定用のモデルは畳み込み層、プーリング層が5層ずつ、姿勢判定モデルは4層ずつの構成となっている。それぞれの詳細な構成については図 13、図 14に示す。学習条件は表 6に示す。

表 4 ノイズの判定に使うデータセット

	S(Signal)	M(Mid)	N(Noise)
train	2502	2368	2637
test	626	592	659

表 5 睡眠時姿勢の判定に使うデータセット

	S(仰向け)	R(右向き)	L(左向き)
train	3994	3569	2825
test	999	892	707

表 6 学習条件

項目	設定値
Epoch	50
Batch Size	32
Optimizer	Adagrad

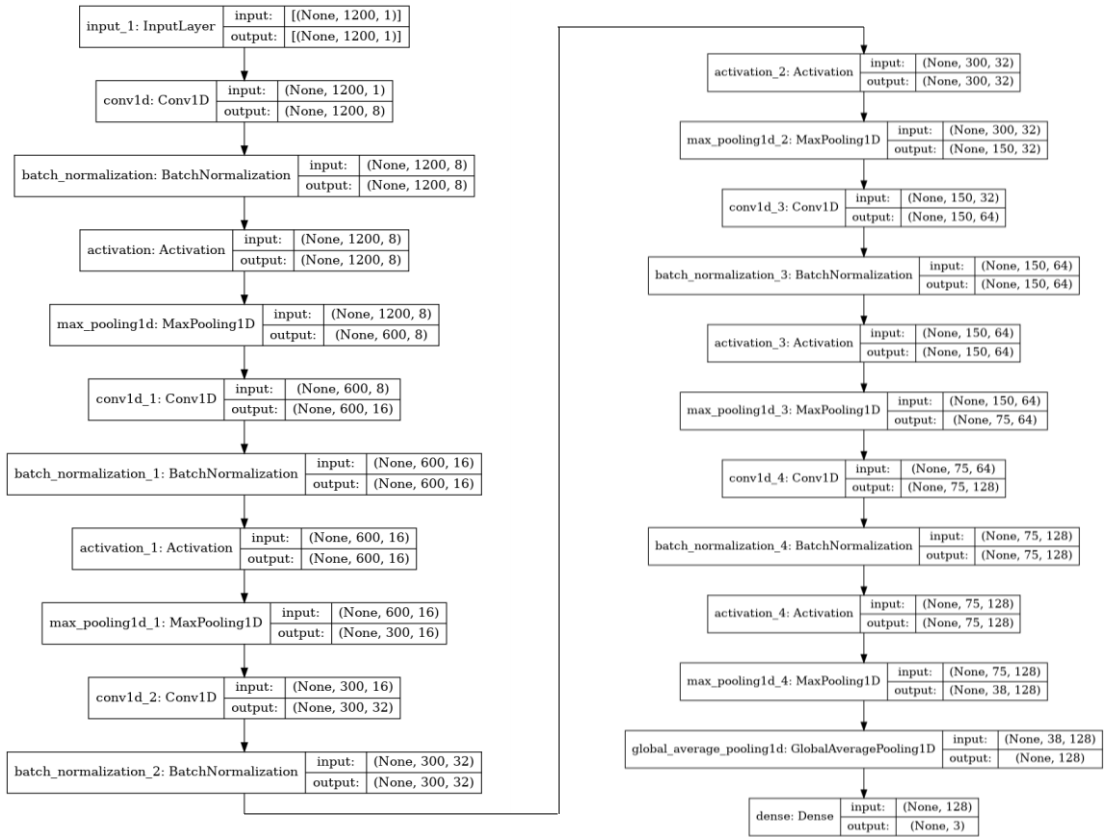


図 13 ノイズの判定に使う深層学習モデル構造

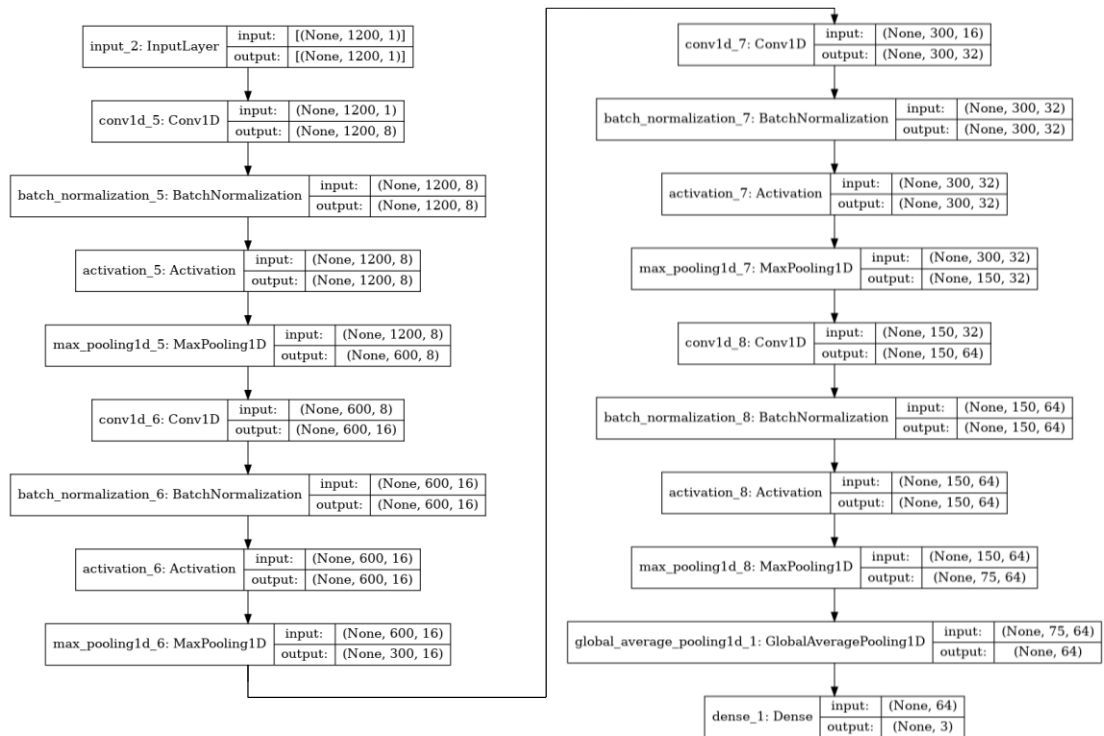


図 14 姿勢の判定に使う深層学習モデル構造

評価指標にはAccuracy, Recall, Precision, F1 scoreを用いる。Accuracyは全体の正答率を示す。Recallは特定のラベルであることをどの程度予測できているかを示す。Precisionは特定のラベルであると予測した時、予測したものの中でどの程度が正答していたかを示す。RecallとPrecisionの調和平均をとったF1 scoreも産出する。それぞれの指標に関しては以下に示す。

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN}$$

$$\text{Recall} = \frac{TP}{TP + FN}$$

$$\text{Precision} = \frac{TP}{TP + FP}$$

$$\text{F1 score} = \frac{2TP}{2TP + FP + FN}$$

TP: True Positive, FP: False Positive,

TN: True Negative, FN: False Negative

### 3.4 結果

ノイズの強度の分類結果を表 7に示す。Accuracyは0.932を示している、M（中程度のノイズ）の分類結果が他のクラスと比べスコアが劣る結果となっている。

睡眠時姿勢の分類結果を表 8に示す。Accuracyは0.869を示している、R（右側臥位）の結果が他のクラスと比べスコアが劣る結果となっている。

被験者単位でデータ分割した場合の睡眠時姿勢の分類結果を表 9に示す。Accuracyは0.54となっている。ランダムに分割した場合の結果から全体的にスコアが低くなっている。

表 7 ノイズの強度の分類結果


	S(Signal)	M(Mid)	N(Noise)
F1 score	0.966	0.890	0.937
Recall	0.963	0.853	0.974
Precision	0.968	0.930	0.903
Accuracy		0.932	

表 8 睡眠時姿勢の分類結果


	S(仰臥位)	R(右側臥位)	L(左側臥位)
F1 score	0.883	0.838	0.886
Recall	0.892	0.807	0.914
Precision	0.874	0.972	0.859
Accuracy		0.869	

表 9 被験者単位でデータ分割した場合の睡眠時姿勢の分類結果


	S(仰臥位)	R(右側臥位)	L(左側臥位)
F1 score	0.494	0.516	0.630
Recall	0.432	0.581	0.642
Precision	0.577	0.464	0.619
Accuracy		0.540	



a) ノイズの強度の分類結果



b) 睡眠時姿勢の分類結果



c) 被験者単位でデータ分割した場合の睡眠時姿勢の分類結果


図 15 各分類結果に関する混合行列

### 3.5 考察


まずノイズ強度の分類結果（表 7、図 15のa）を見るとAccuracyは0.932となっていて、特に抽出したいきれいな信号（S）のF1 scoreは0.966となっている。混合行列を参照するとノイズ（N）がきれいな信号として誤分類されている数は0となっていて、本来の目的であるきれいな信号とノイズを分離したいという性能がある程度実現できているように見える。誤分類の傾向を見ると中程度のノイズが乗った信号（M）はN側へ誤分類される場合が多く、NはMにしか誤分類されていない。そのためMとNの間で誤分類が多くなっているが、きれいな信号（S）はある程度分離できている、という性能になっている。またMの信号に関しては、他クラスと比べRecallが低い。これはラベル付けの精度の影響も受けていると考えられる。MがNに誤分類された例を図 16に示す。正しく分類された例では心拍が確認できる信号となっているが、誤分類された例では心拍を確認するのは難しくノイズのような波形となっている。Mクラスの定義は心拍（R波）は確認できる信号となっているが、誤分類された波形がこの条件を満たしていると言い切るとは難しく、このような波形がラベルを付ける際のエラーを生み、MクラスのRecallの低下を引き起こしていると考えられる。容量性心電図を実用化する場合、SとMクラスの信号には使用用途が存在する。きれいな信号（S）は電極位置（睡眠時姿勢）さえわかれば通常的心電図と同じように運用することができる。実際に医師が信号と睡眠時姿勢から病気に診断に使うこともでき、また、日々研究が進んでいる自動診断手法を適用することもできる。また心拍のみが判断できるMクラスもRR間隔のみであれば判断できるため、疾患によっては診断の一助になる。そのためMクラスのスコアのさらなる改善ができれば望ましい。

データセットをランダムに分割した際の睡眠時姿勢の分類結果（表 8、図 15のb）を見るとAccuracyは0.869となっている。右側臥位（R）がF1 scoreが他と比べて低いスコアとなっている。混合行列を見ると仰向け（S）と右側臥位（R）の間で誤分類が相対的に多く発生していることがわかる。SとRの波形の違いはLと他の波形を比べた場合と比べて小さく、その波形の違いの傾向が誤分類の傾向に表れていると考えられる。また被験者単位でデータ分割した場合の結果（表 9、図 15のc）を見るとその後分類の傾向はさらに強くなる。またスコア全体を見ても、Accuracyは0.869から0.540に下がっていてこのモデルには汎化性能がないことがわかる。睡眠時姿勢による波形の変化の傾向は個人差があり、具体的には個人の心臓の電気軸の偏位度合い（心臓の傾きの程度等に対応する）の影響を受け

る。そのため今回の実験で用いた14人分のデータだとパターンを網羅できておらず、未知の患者に対応できない汎化性能の低いモデルになってしまったと考えられる。実際に汎化性能のない状態で運用するのであれば、使用者が使う前に各姿勢を一定時間とることでキャリブレーションを取るなどの手段で使うこともできるが、改善は必要である。次項では心弾図を組み合わせることで改善を図る。



a) 正しく分類された例



b) ノイズ (N) に誤分類された例

図 16 中程度のノイズが含まれた信号 (M) の誤分類例

## 4. 容量性心電図と心弾図を組み合わせた解析

### 4.1 概要

本章では容量性心電図と心弾図を組み合わせて睡眠時姿勢の分類を行う。前項において容量性心電図のみで分類を行ったが、汎化性能が低い結果となった。これを改善するために本章では心弾図を新たに分類に用いる。心弾図は前述したとおり、加速度センサである。感度の高い加速度センサから測定された信号には心臓の振動が反映され、身体の動き・状態も反映される。基本的に心臓の生理状態以外の情報も含んでいるため、容量性心電図よりも心臓の個人差の影響が少ないと考え、採用している。

本章での処理の流れを図 17 に示す。容量性心電図と心弾図を入力として、睡眠時姿勢を出力する多入力モデルを構築する。比較のために心弾図単体を用いた分類モデルも構築する。他入力モデルを用いて、前章と同様の条件で学習・分類を行い、容量性心電図単体と、心弾図を組み合わせた場合での性能の変化を検証する。

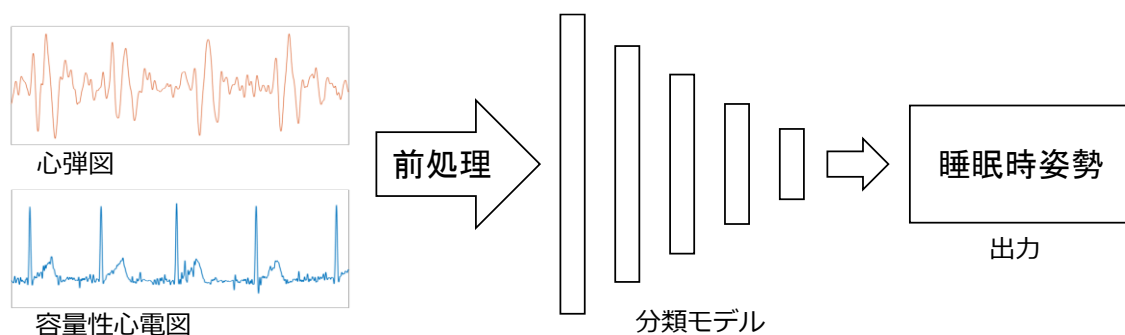


図 17 処理の流れ



## 4.2 分類モデル

本章では容量性心電図と心弾図の多入力モデルを用いる。複数種類のデータを入力する利点として、以下のようなものがあげられる[37]。

- ・ 同じ現象を観察する複数種類のデータがあると予測が堅牢になる
- ・ 複数種類のデータから補完的な情報を抽出できる。
- ・ 一部のデータの質が悪くても（もしくは欠落しても）対応できる。

本研究では不安定な信号である容量性心電図を用いているため、異なる測定原理でありながら、共通する情報も含む心弾図を学習に組み込むことでより堅牢なモデルの構築を目指す。

具体的な構造としては、容量性心電図のみで学習した際に用いた1D-CNNをベースとして、二つの1D-CNNを出力付近で情報を結合し出力層に接続する図 18。詳細な構造を図 19に示す。今回出力付近でモデルを結合しているのは、片方のデータの質が悪くても対応できるようにするためである。

## 4.3 学習・検証

基本的には容量性心電図のみで学習を行った際と同じ条件で行う。データ分割も学習用と検証用で8：2にランダムに分割し、学習・検証を行う。この際比較のため心弾図単体での学習・検証も行う。心弾図単体で学習する際は容量性心電図と同様のモデルを用いる。

また汎化性能の評価のために前章と同様に、被験者2人ずつの7グループに分けそれぞれのグループが検証用、それ以外が学習用となるよう7回処理を行った。これによって汎化性能を評価する。また学習にデータの被験者数2～12人まで2人刻みで変化させ、データ数と精度の関連を調べた。




図 18 多入力深層学習モデルの概略



図 19 多入力深層学習モデルの構造

## 4.4 結果

心弾図のみを用いた分類結果を表 10と表 11に示す。データをランダムに分割した場合、各スコアが0.9を超えている。被験者単位で分割した場合はRecallが仰臥位 (S) が他クラスより高い傾向になっている。容量性心電図と心弾図を組み合わせで分類した結果を表12に示す。Accuracyは0.978となっていて、各クラスのF1 scoreも0.97以上となっている。心弾図のみの場合と同じくクラスごとの明確なスコアの差はない。被験者単位でデータ分割した場合の分類結果を表 13に示す。Accuracyは0.832とランダム分割した場合より0.15程度下がっている。クラス間の差を見ると右側臥位 (R) のスコアが他のクラスと比べて低くなっている。

表 10 心弾図単体での分類結果

	S(仰臥位)	R(右側臥位)	L(左側臥位)
F1 score	0.933	0.943	0.937
Recall	0.942	0.942	0.974
Precision	0.924	0.945	0.903
Accuracy	0.935		

表 11 心弾図単体を被験者単位で分割した場合の分類結果


	S(仰臥位)	R(右側臥位)	L(左側臥位)
F1 score	0.795	0.807	0.785
Recall	0.850	0.770	0.755
Precision	0.747	0.849	0.818
Accuracy	0.797		

表 12 容量性心電図と心弾図を組み合わせで分類結果


	S(仰臥位)	R(右側臥位)	L(左側臥位)
F1 score	0.981	0.982	0.971
Recall	0.971	0.983	0.983
Precision	0.991	0.981	0.959
Accuracy	0.978		

表 13 容量性心電図と心弾図を被験者単位で分割した場合の分類結果


	S(仰臥位)	R(右側臥位)	L(左側臥位)
F1 score	0.838	0.798	0.867
Recall	0.848	0.798	0.854
Precision	0.829	0.799	0.880
Accuracy	0.832		



a) 被験者単位でデータ分割した場合の心弾図のみの分類結果




b) 多入力モデルの分類結果




c) 被験者単位でデータ分割した場合の多入力モデルの分類結果


図 20 各分類結果に関する混合行列



a) Accuracy



b) Recall



c) Precision

図 21 訓練データの被験者数に対する分類スコアの推移

## 4.5 考察

心弾図単体の分類結果（表 10、表 11、図 20のa）を見ると、Accuracyは0.935となり0.9を超えている。また混合行列によると仰臥位（S）は右側臥位（R）と左側臥位（L）に均等に誤分類されている。また被験者単位でデータを分割した場合はAccuracyが0.797となっていてランダムにデータ分割した場合よりAccuracyが下がっている。下がり幅は前章で検証した容量性心電図よりも小さく容量性心電図よりも今回のデータ数においては汎化性能が高いことがわかる。またRecallのタイは仰臥位（S）が最も高くなっていて（0.85）、誤分類の傾向としては右側臥位（R）、左側臥位（L）がそれぞれ仰臥位に多く誤分類されている。前章で容量性心電図のみで学習・分類した場合はSとRの間で誤分類が多く起こっていたため、姿勢毎の誤分類の傾向は容量性心電図とは異なることがわかる。そのため心弾図と容量性心電図は異なる性質を持っていて、同時に学習させる相互作用にも期待できる。

容量性心電図と心弾図を組み合わせて分類した結果（表12、表13、図 20のb）を見ると、Accuracyは0.978となっていて、各スコアが心弾図単体、容量性心電図単体での分類と比べて高い値となっている。また混合行列をみても容量性心電図単体での分類結果見られた左右の誤分類の偏りも見られない。これは心弾図を組み合わせることで、ある程度分類結果の偏りが是正されたと考えられる。

この他入力モデルを汎化性能評価のために被験者単位でデータ分割を行い分類した結果を表 13、図 20のcに示す。この結果を見ると容量性心電図のみでの解析と同じく、ランダムにデータを分割した場合と比べてスコアは全体的に低下している。しかし容量性心電図のみで分類を行うとAccuracyが0.54しかないのに対し、心弾図も組み合わせることでAccuracyが0.832程度に向上している。そのため心弾図と比べて汎化性能は上がっていると判断することができる。クラスごとの差を混合行列から見ると、仰臥位（S）と右側臥位（R）の間で誤分類が多く起こっている。この傾向は容量性心電図の性質の影響を受けており、心弾図を組み合わせても、完全には補完できていないことがわかる。

学習データに用いる被験者の数を2～12人に変化させたときのスコアの推移を図 21に示す。Accuracyに関しては学習させる被験者の数を2人から12人に増加させることで0.65から0.83に向上する。Precision に関しても同様の傾向であるが、

Recallに関しては仰臥位（S）が0.8前後を一様に保っていて、他のクラスが被験者を増やすごとに向上するという傾向となっている。これは仰臥位（S）のRecallが高くなる心弾図の性質が反映されていると考えられる。また学習データの被験者数に関して今回2～12人で行ったが、改善の余地がある。実際12人まで増やした場合0.83までAccuracyが上昇したが、被験者数を増やすことでさらなるAccuracyの上昇が期待できる。従来心電図の不整脈検出等の研究で頻繁に使われるMIT-BIH Arrhythmia Database[38]は47人の被験者のデータを含む。また290人のデータを含むPTB Diagnostic ECG Database[39]もあり、これらのデータが心電図を用いた不整脈検出の先行研究[40]に使われていることを考えると、50～100人程度まで被験者を増やせるとさらなる改善も期待できる。

このように容量性心電図単体を使う場合と比べて、性能は向上することができ、汎化性能も向上することができたが、被験者ごとにデータを分割するとAccuracyが0.15ほど低下しているため、改善の余地はある。本研究ではモデルの出力付近で情報を結合しているため、結合部分以前のモデルの構造は置き換えが可能であり、異なる構造を使うことや、別のデータ（例えば通常の心電図等）で事前に学習したモデルを接続することなど、改善の余地は多分にある。モデルの改善とデータの拡充を行えば、汎化性能の高い分類器の構築も可能であると考えられる。

汎化性能の問題に関しては運用方法によって解決できる場合もある。ランダムにデータを分割した場合は同一被験者のデータが学習側・検証側に存在するため、精度が高くなっていると考えられる。そのため、初めて使用者が測定機器を使う場合に、一定時間各姿勢をとるなどのキャリブレーションを運用過程に組み込むことで、解決できると考えられる。この手法の場合ノイズの影響を受けやすい容量性心電図のみではキャリブレーションがうまくいかない場合も考えられるがノイズの影響を受けにくい心弾図であればキャリブレーションにも適している。



## 4.6 今後の展望

前項にあるように、データの拡充とモデルの改善によって、分類タスクの精度が改善されていくことで容量性心電図が心臓のモニタリング手段としての実用化に近づく。また心弾図も同時に測定しているため、心電図よりも多くの情報量を取り出すことも期待される。現状では心電図との時間差によって心血管の状態を評価できる[30]という報告もあり、心臓の状態のモニタリング手段としてさらなる発展が期待される。本研究では正常心電図を使っているため、今後は各心疾患の波形を集めることができれば、容量性心電図と心弾図から心疾患に関わる特徴量を取り出すモデルを作ることでもできると考えられる。

また本研究では容量性心電図と心弾図という身体の状態・動きが反映される信号を使用している。そのため容量性心電図と心弾図から体動の程度を評価できると期待される。体動から睡眠状態を評価する研究はウェアラブルデバイスの発展と共に進んでいる[41]。そのため容量性心電図と心弾図は睡眠状態と心臓の生理動態を同時にモニタリングできることが期待できる。

このように容量性心電図と心弾図を同時計測することは心臓自体の動きと、身体全体の動きの両方の情報を含んでいて、それらのデータ、解析手法を整えることで睡眠状態・心臓生理動態の両方をモニタリングし、健康管理のための非常に有用な手段になりうる。

## 5. まとめ

本研究では容量性心電図と心弾図の測定環境を整え、ノイズ強度の分類と睡眠時姿勢の分類を行った。ノイズ強度の分類に関しては最もきれいな信号を96%抽出することができ、またノイズをきれいな信号として誤分類されることがないモデルとなった。この結果はノイズの少ない信号を抽出するという当初の目的をおおむね達成している。ノイズが中程度の信号 (M) の分類精度に関しては改善の余地がある。

睡眠時姿勢の分類に関しては心弾図と容量性心電図を併用することで、ランダムにサンプルを分割した場合はAccuracyが0.978となっている。しかし、被験者ごとに分割した場合はAccuracyが0.832となっている。そのため、汎化性能の面では改善の余地があり、モデルの改善や運用方法によって今後実用化に近づける必要がある。本研究によって測定から実際にデータを診断に使うまでの過程を埋めることで容量性心電図の実用化へ近づけることができた。

また本研究では容量性心電図を実用にするために心弾図を補助として使用したが、心弾図自体は心拍などの情報を含んでいて、心電図と併用することで心血管機能の評価指標となる。そのため今後は容量性心電図と心弾図の両方から心疾患等と関連する心臓の生理動態を認識するような応用も期待できる。

## 6. 謝辞

本研究は多くの方々からのご指導、ご協力によって進めることができました。卓越した御指導と研究環境を与えてくださった奈良先端科学技術大学院大学情報科学領域計算システムズ生物学研究室 金谷 重彦 教授に深く感謝致します。研究室のゼミでは卓越した御意見を頂きました、同研究室Md. Altaf-Ul-Amin 准教授、小野 直亮准教授に深く感謝致します。ゼミナールの際に貴重なご意見をくださいました奈良先端科学技術大学院大学情報科学研究科生体医用画像研究室 佐藤 嘉伸 教授に深く感謝致します。日頃より研究に関して多大なご助言をいただき、また研究のみならず学生に気を配ってくださいました情報科学領域 黄 銘 助教に、深く感謝致します。同研究室の皆様とは同じ研究室で互いに助け合い刺激を受けながら研究を行うことができました。ここに深く感謝致します。

最後に大学院生活をこれまで支えてくれ、おそらくこれからも支えてくださるであろう家族に心から感謝致します。

## 7. 参考文献

- [1] 厚生労働省, “令和2年(2020)人口動態統計月報年計(概数) の概況.” [Online]. Available: <https://www.mhlw.go.jp/toukei/saikin/hw/jinkou/geppo/nengai20/index.html>
- [2] P. M. Barrett *et al.*, “Comparison of 24-hour Holter monitoring with 14-day novel adhesive patch electrocardiographic monitoring,” *American Journal of Medicine*, vol. 127, no. 1, pp. 95.e11-95.e17, 2014, doi: 10.1016/J.AMJMED.2013.10.003.
- [3] L. J. Gula, A. D. Krahn, A. C. Skanes, R. Yee, and G. J. Klein, “Clinical relevance of arrhythmias during sleep: guidance for clinicians,” *Heart*, vol. 90, no. 3, pp. 347–352, Mar. 2004, doi: 10.1136/HRT.2003.019323.
- [4] E. H. Chung and K. D. Guise, “QTC intervals can be assessed with the AliveCor heart monitor in patients on dofetilide for atrial fibrillation,” *J Electrocardiol*, vol. 48, no. 1, pp. 8–9, Jan. 2015, doi: 10.1016/J.JELECTROCARD.2014.10.005.
- [5] E. Pinheiro, O. Postolache, and P. Girão, “Theory and Developments in an Unobtrusive Cardiovascular System Representation: Ballistocardiography,” *Open Biomed Eng J*, vol. 4, pp. 201–216, 2010.
- [6] L. Krivoshei *et al.*, “Smart detection of atrial fibrillation †”, doi: 10.1093/europace/euw125.
- [7] 小沢友紀雄, 齋藤穎, and 平山篤志, これだけは知っておきたい やさしい心電図の見方～おもな心疾患と治療のポイント～. 株式会社 医薬ジャーナル社, 2013.
- [8] 石原謙, 臨床工学講座 生体計測装置学 第1版. 医歯薬出版株式会社, 2010.
- [9] A. Ueno, Y. Shiogai, and Y. Ishiyama, “A Primary Study of Indirect ECG Monitor Embedded in a Bed for Home Health Care,” 2007.
- [10] A. Ueno, Y. Akabane, T. Kato, H. Hoshino, S. Kataoka, and Y. Ishiyama, “Capacitive sensing of electrocardiographic potential through cloth from the dorsal surface of the body in a supine position: A preliminary study,” *IEEE Trans Biomed Eng*, vol. 54, no. 4, pp. 759–766, Apr. 2007, doi: 10.1109/TBME.2006.889201.
- [11] H. J. Lee, S. H. Hwang, H. N. Yoon, W. K. Lee, and K. S. Park, “Heart rate variability monitoring during sleep based on capacitively coupled textile electrodes on a bed,” *Sensors (Switzerland)*, vol. 15, no. 5, pp. 11295–11311, May 2015, doi: 10.3390/s150511295.
- [12] M. Takano and A. Ueno, “Noncontact In-Bed Measurements of Physiological and Behavioral Signals Using an Integrated Fabric-Sheet Sensing Scheme,” *IEEE J Biomed Health Inform*, vol. 23, no. 2, pp. 618–630, Mar. 2019, doi: 10.1109/JBHI.2018.2825020.
- [13] K. Wang, Y. Yao, R. Lin, A. Cheng, Y. Xu, and L. Xu, “A Capacitive Electrocardiography System With Dedicated Noise-Cancellation Algorithms for Morphological Analysis,” *IEEE Trans Biomed Eng*, 2022, doi: 10.1109/TBME.2022.3209325.
- [14] M. Choi, J. J. Jeong, S. H. Kim, and S. W. Kim, “Reduction of Motion Artifacts and Improvement of R Peak Detecting Accuracy Using Adjacent Non-Intrusive ECG Sensors,” *Sensors 2016, Vol. 16, Page 715*, vol. 16, no. 5, p. 715, May 2016, doi: 10.3390/S16050715.
- [15] I. D. Castro, R. Morariu, T. Torfs, C. van Hoof, and R. Puers, “Robust wireless capacitive ECG system with adaptive signal quality and motion artifact reduction,” in *2016 IEEE International Symposium on Medical Measurements and Applications (MeMeA)*, May 2016, pp. 1–6. doi: 10.1109/MeMeA.2016.7533802.

- [16] B. Eilebrecht, T. Wartzek, J. Willkomm, A. Schommartz, M. Walter, and S. Leonhardt, "Motion Artifact Removal from Capacitive ECG Measurements by Means of Adaptive Filtering," 2011, pp. 902–905. doi: 10.1007/978-3-642-23508-5\_234.
- [17] V. Ravichandran *et al.*, "Deep Network for Capacitive ECG Denoising," *Medical Measurements and Applications, MeMeA 2019 - Symposium Proceedings*, Jun. 2019, doi: 10.1109/MEMEA.2019.8802155.
- [18] C. C. Hsia, K. J. Liou, A. P. W. Aung, V. Foo, W. Huang, and J. Biswas, "Analysis and comparison of sleeping posture classification methods using pressure sensitive bed system," in *2009 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, Sep. 2009, pp. 6131–6134. doi: 10.1109/IEMBS.2009.5334694.
- [19] M. B. Pouyan, J. Birjandtalab, M. Heydarzadeh, M. Nourani, and S. Ostadabbas, "A pressure map dataset for posture and subject analytics," in *2017 IEEE EMBS International Conference on Biomedical & Health Informatics (BHI)*, 2017, pp. 65–68. doi: 10.1109/BHI.2017.7897206.
- [20] K. Tang, A. Kumar, M. Nadeem, and I. Maaz, "CNN-Based Smart Sleep Posture Recognition System," *IoT*, vol. 2, no. 1, pp. 119–139, Feb. 2021, doi: 10.3390/iot2010007.
- [21] S. Yue, Y. Yang, H. Wang, H. Rahul, and D. Katabi, "BodyCompass: Monitoring Sleep Posture with Wireless Signals," *Proc ACM Interact Mob Wearable Ubiquitous Technol*, vol. 4, no. 2, pp. 1–25, Jun. 2020, doi: 10.1145/3397311.
- [22] A. Y.-C. Tam *et al.*, "Depth-Camera-Based Under-Blanket Sleep Posture Classification Using Anatomical Landmark-Guided Deep Learning Model," *Int J Environ Res Public Health*, vol. 19, no. 20, p. 13491, Oct. 2022, doi: 10.3390/ijerph192013491.
- [23] T. Khan, "An Intelligent Baby Monitor with Automatic Sleeping Posture Detection and Notification," *AI*, vol. 2, no. 2, pp. 290–306, Jun. 2021, doi: 10.3390/ai2020018.
- [24] S. M. Mohammadi, M. Alnowami, S. Khan, D.-J. Dijk, A. Hilton, and K. Wells, "Sleep Posture Classification using a Convolutional Neural Network," in *2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, Jul. 2018, pp. 1–4. doi: 10.1109/EMBC.2018.8513009.
- [25] R. M. Kwasnicki *et al.*, "A lightweight sensing platform for monitoring sleep quality and posture: a simulated validation study," *Eur J Med Res*, vol. 23, no. 1, p. 28, Dec. 2018, doi: 10.1186/s40001-018-0326-9.
- [26] S. Fallmann, R. van Veen, L. Chen, D. Walker, F. Chen, and C. Pan, "Wearable accelerometer based extended sleep position recognition," in *2017 IEEE 19th International Conference on e-Health Networking, Applications and Services (Healthcom)*, Oct. 2017, pp. 1–6. doi: 10.1109/HealthCom.2017.8210806.
- [27] R. S. Abdulsadig, S. Singh, Z. Patel, and E. Rodriguez-Villegas, "Sleep Posture Detection Using an Accelerometer Placed on the Neck," in *2022 44th Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, Jul. 2022, pp. 2430–2433. doi: 10.1109/EMBC48229.2022.9871300.
- [28] J. Gupta, N. Gupta, M. Kumar, R. Duggal, and J. J. P. C. Rodrigues, "Collection and Classification of Human Posture Data using Wearable Sensors," in *2021 IEEE Global Communications Conference (GLOBECOM)*, Dec. 2021, pp. 1–6. doi: 10.1109/GLOBECOM46510.2021.9685755.
- [29] E. P. Doheny, M. M. Lowery, A. Russell, and S. Ryan, "Estimation of respiration rate and sleeping position using a wearable accelerometer," in *2020 42nd Annual*

- International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, Jul. 2020, pp. 4668–4671. doi: 10.1109/EMBC44109.2020.9176573.
- [30] R. Casanella, J. Gomez-Clapers, and R. Pallas-Areny, “On time interval measurements using BCG,” *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, pp. 5034–5037, 2012, doi: 10.1109/EMBC.2012.6347124.
- [31] S. Kiranyaz, T. Ince, and M. Gabbouj, “Real-Time Patient-Specific ECG Classification by 1-D Convolutional Neural Networks,” *IEEE Trans Biomed Eng*, vol. 63, no. 3, pp. 664–675, Mar. 2016, doi: 10.1109/TBME.2015.2468589.
- [32] U. R. Acharya, H. Fujita, O. S. Lih, Y. Hagiwara, J. H. Tan, and M. Adam, “Automated detection of arrhythmias using different intervals of tachycardia ECG segments with convolutional neural network,” *Inf Sci (N Y)*, vol. 405, pp. 81–90, Sep. 2017, doi: 10.1016/j.ins.2017.04.012.
- [33] S. L. Oh *et al.*, “A Deep Convolutional Neural Network Model to Classify Heartbeats Diagnosing heart disorders based on ECG signals View project Btp project View project U Rajendra Acharya A Deep Convolutional Neural Network Model to Classify Heartbeats,” *Article in Computers in Biology and Medicine*, 2017, doi: 10.1016/j.combiomed.2017.08.022.
- [34] Ö. Yildirim, P. Pławiak, R. S. Tan, and U. R. Acharya, “Arrhythmia detection using deep convolutional neural network with long duration ECG signals,” *Comput Biol Med*, vol. 102, pp. 411–420, Nov. 2018, doi: 10.1016/J.COMPBIOMED.2018.09.009.
- [35] U. B. Baloglu, M. Talo, O. Yildirim, R. S. Tan, and U. R. Acharya, “Classification of myocardial infarction with multi-lead ECG signals and deep CNN,” *Pattern Recognit Lett*, vol. 122, pp. 23–30, May 2019, doi: 10.1016/J.PATREC.2019.02.016.
- [36] R. J. Martis, C. Chakraborty, and A. K. Ray, “Wavelet-based machine learning techniques for ECG signal analysis,” *Intelligent Systems Reference Library*, vol. 56, pp. 25–45, 2014, doi: 10.1007/978-3-642-40017-9\_2.
- [37] T. Baltrusaitis, C. Ahuja, and L. P. Morency, “Multimodal Machine Learning: A Survey and Taxonomy,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 41, no. 2. IEEE Computer Society, pp. 423–443, Feb. 01, 2019. doi: 10.1109/TPAMI.2018.2798607.
- [38] G. B. Moody and R. G. Mark, “The impact of the MIT-BIH arrhythmia database,” *IEEE Engineering in Medicine and Biology Magazine*, vol. 20, no. 3, pp. 45–50, 2001, doi: 10.1109/51.932724.
- [39] R. Boussejot, D. Kreiseler, and A. Schnabel, “Nutzung der EKG-Signaldatenbank CARDIODAT der PTB über das Internet,” *Biomed Tech (Berl)*, vol. 40, no. s1, pp. 317–318, Jan. 1995, doi: 10.1515/bmte.1995.40.s1.317.
- [40] X. Liu, H. Wang, Z. Li, and L. Qin, “Deep learning in ECG diagnosis: A review,” *Knowl Based Syst*, vol. 227, Sep. 2021, doi: 10.1016/j.knosys.2021.107187.
- [41] D. Fekedulegn, M. E. Andrew, M. Shi, J. M. Violanti, S. Knox, and K. E. Innes, “Actigraphy-Based Assessment of Sleep Parameters,” *Ann Work Expo Health*, vol. 64, no. 4, pp. 350–367, Apr. 2020, doi: 10.1093/ANNWEH/WXAA007.

## 8. 業績リスト

### 国際会議

- ・ 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (2018) Poster presentation on “Validation of the Temporal Information of a Capacitive Electrocardiogram”
- ・ 41th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (2018) Poster presentation on “The possibility of Arrhythmias detection from a capacitive ECG measurement using convolutional neural network”

### 投稿論文

- ・ Koshiro Kido, Toshiyo Tamura, Naoaki Ono, MD.ALTAf-UL-AMIN, Masaki Sekine, Shigehiko Kanaya and Ming Huang. (2019). A Novel CNN-Based Framework for Classification of Signal Quality and Sleep Position from a Capacitive ECG Measurement. Sensors. 19. 1731. 10.3390/s19071731.
- ・ Koshiro Kido, Zheng Chen, Ming Huang, Toshiyo Tamura Wei Chen, Naoaki Ono, Masachika Takeuchi, MD.ALTAf-UL-AMIN and Shigehiko Kanaya. (2021). Discussion of Cuffless Blood Pressure Prediction Using Plethysmograph Based on a Longitudinal Experiment: Is the Individual Model Necessary?. Life. 12. 11. 10.3390/life12010011.

### その他

- ・ JSPS 研究助成事業 特別研究員奨励費 2020年4月～2022年3月

非接触センシングに基づく睡眠生理動態モニタリングのためのAI技術の研究開発