

マイクロ波による非接触計測の生体信号に対する パラメトリックスペクトル推定

Parametric Spectrum Estimation for Contactless Vital-sign Measurement Using Microwave

○渋谷七海*, 佐藤宏明*, 恒川佳隆*, 本間尚樹*

○ Nanami Shibuya*, Hiroaki Satou*, Yoshitaka Tsunekawa*, Naoki Honma*

*岩手大学

*Iwate University

キーワード : 生体信号計測 (Vital-sign signal measurement), 無線計測 (wireless measurement),
自己回帰モデル推定 (auto-regressive model estimation), 最尤推定 (maximum
likelihood estimation), 共分散法 (covariance method)

連絡先 : 〒020-8551 岩手県盛岡市上田 4-3-5 岩手大学工学部 佐藤宏明

Tel/Fax.: (019) 621-6392, E-mail hsato@iwate-u.ac.jp

1. はじめに

近年, 高齢化に伴う孤独死の増加, 循環器疾患の発作による突然死などの問題がある. この対策として様々な方法での生体情報の長期計測の研究が進められている. 特に, 心拍と呼吸の情報は医療分野においても重要な役割を持つ. しかし, 現在の計測技術は測定対象に装置を取り付けるため, 長時間計測では大きなストレスとなる.

この問題に対し, マイクロ波での非接触計測法がある[1]. 心拍や呼吸により生体の表面は振動しており, マイクロ波を反射させると, その振動の影響により振幅や位相が変化する. この変化から, 生体情報を含んだ信号を

得ることができる.

筆者らの研究グループではこのマイクロ波による生体情報計測の応用として, 呼吸, 心拍の非接触計測に取り組んでいる[2-6]. これまでの研究から呼吸, 心拍の信号成分の存在を確認できており, それぞれの信号の抽出は成功している. しかしながら, 呼吸による胸部の収縮に比べて心拍の拍動の振幅が小さいことと, 心臓が体の内側に位置していることから心拍成分の信号レベルは微弱で, 呼吸成分や環境・計測システムの雑音により影響を受けてしまう. この場合, フーリエ変換に代表されるノンパラメトリック周波数解析では精度や周波数分解能において様々な

制限を受ける．そのため心拍成分の信号分離は困難であった．

そこで筆者らは，心臓が心筋に囲まれた球状の弾性体であるということから，心筋の振動が減衰正弦的な動きをしているという仮定のもと，減衰正弦波を表現する自己回帰モデルによる推定が可能であると考えた．

本研究では雑音による影響をできる限り少なくして心拍と呼吸のスペクトルを検出するために，信号の自己回帰モデルから最尤推定法に基づいた自己回帰モデル推定法より伝達関数のパラメータを推定する方法を提案する．そして，マイクロ波計測システムから得られた信号からパワースペクトル密度 (Power Spectral Density:PSD) 推定を試み，その結果を検討した．

2. 尤度関数と最尤推定法

推定量の求め方の一つに最尤推定法がある．これには推定量の性質として，漸近的 unbiased・漸近的有効性・一致性を少なくとも有する推定量を得られる．ここでは最尤推定法と，これに用いる尤度関数について述べる．

今，ある観測された N 個の標本 $\{y(0), y(1), \dots, y(N-1)\}$ が，確率密度関数 $p(y|\theta)$ で与えられる確率変数から得られた独立なデータであるとする． θ はこの確率密度関数を定めるための母数である．たとえば $p(y(i)|\theta)$ が正規分布である時 θ は母平均と母分散に対応する． N 個の標本データすべてにおいて，ちょうど $y(0), y(1), \dots, y(N-1)$ となるための同時確率密度関数 L は各データ $y(i)$ が現れる確率密度関数 $p(y(i)|\theta)$ の積で式(3.1)のように表される．

$$L = p(y(0)|\theta) \times p(y(1)|\theta) \times \dots \times p(y(N-1)|\theta) \quad (2.1)$$

ここで， N 個の観測データはすでに観測されているため決まっているので， L は N 個のデ

ータの関数ではなく θ の関数となる．

$$L = L(\theta) \quad (2.2)$$

$L(\theta)$ を今得られた N 個の標本データの尤度関数という．尤度関数とは，ガウス分布のような確率論的モデルを仮定しているときに，その観測データが得られる確率密度である．つまり，ある観測データに ある母数のもとで確率論的モデルが「どれくらいあてはまっているか」を確率で表す尺度である．

確率と尤度関数の違いは，確率においては確率密度関数 $p(y)$ とその母数 θ がすでに与えられていて，時刻 t のデータ $y(t)$ が得られる確率を $p(y(t))$ と表すことができるのに対して，尤度においては観測された N 個のデータ $\{y(0), y(1), \dots, y(N-1)\}$ とこのデータを起こした母集団の関数の形はわかっているが，母数 θ が定められておらず，その母数 θ を観測データから決めるというもので，確率を求めるときと逆の場合に用いる．なので，式(3.2)を N 次元ベクトル $\mathbf{y} = \{y(0), y(1), \dots, y(N-1)\}^T$ があるときの θ の関数であることを明示するために次式のように表せる．

$$L = L(\theta|\mathbf{y}) \quad (2.3)$$

この尤度関数 $L(\theta|\mathbf{y})$ を最大にする θ の値を $\hat{\theta}$ とすると次式を満たす $\hat{\theta}$ が存在する．

$$L(\hat{\theta}|\mathbf{y}) = \max_{\theta} L(\theta|\mathbf{y}) \quad (2.4)$$

この $\hat{\theta}$ を θ の最尤推定値という．そして，このように観測データから得られた $\hat{\theta}$ を θ の推定値と決定する方法を最尤推定法という．また，式(2.1)を自然対数をとって和の形にしたものを対数尤度といい，次式で示す．

$$l = \log L = \sum_{i=0}^{N-1} \log p(y(i)|\theta) \quad (2.5)$$

この対数尤度 l を最大にする θ を定めるために θ で偏微分して零と置く．

$$\frac{\partial l}{\partial \theta} = 0 \quad (2.6)$$

式(2.6)を尤度方程式といい，この式を満たす θ によって最尤推定値 $\hat{\theta}$ を定める．

3. 共分散法

ここでは最尤推定法に基づく自己回帰モデル(Auto-regression:ARモデル)のパラメータを推定する共分散法について述べる。

3.1 最尤推定法に基づく自己回帰モデル推定

まず AR モデルを想定するため、 M 次の全極形伝達系をガウス性白色雑音 $x(n)$ が駆動することによって、 N 個の観測信号 $y(0), y(1), \dots, y(N-1)$ が得られたものとする。AR モデルの線形予測係数を $\{a_i\}$ と置くと、 $y(n)$ は次式で記述できる。

$$y(n) = -\sum_{i=1}^M a_i y(n-i) + x(n) \quad (3.1)$$

入力信号 $x(n)$ が平均値零、分散 σ_x^2 の正規分布に従うと仮定すると、 $y(n)$ も平均値 μ_y が零の正規分布に従う。 N 次元確率変数ベクトル

$$\mathbf{y} = (y(0), y(1), \dots, y(N-1))^T \in \mathcal{N}(\mathbf{y}; \boldsymbol{\mu}_y, \boldsymbol{\Sigma}_y) \quad (3.2)$$

が、 N 次元平均値ベクトル $\boldsymbol{\mu}_y$ 、 $N \times N$ 共分散行列 $\boldsymbol{\Sigma}_y$ を持つ N 変量正規分布 $\mathcal{N}(\mathbf{y}; \boldsymbol{\mu}_y, \boldsymbol{\Sigma}_y)$ に従うとき、 \mathbf{y} の確率密度関数 $p(\mathbf{y})$ は

$$p(\mathbf{y}) = \frac{1}{\sqrt{(2\pi)^N |\boldsymbol{\Sigma}_y|}} \exp\left(-\frac{1}{2}(\mathbf{y} - \boldsymbol{\mu}_y)^T \boldsymbol{\Sigma}_y^{-1}(\mathbf{y} - \boldsymbol{\mu}_y)\right) \quad (3.3)$$

で与えられる。これを用いると、線形予測係数 $\{a_i\}$ と σ_x^2 が与えられたときに N 点長の自己回帰モデルが、 $\mathbf{y} = (y(0), \dots, y(N-1))^T$ となる同時生起確率を

$$p(\mathbf{y}|\mathbf{a}, \sigma_x^2) \quad (3.4)$$

と表せる。ここで、 \mathbf{a} は M 次元ベクトル $\mathbf{a} = (a_1, a_2, \dots, a_M)^T$ である。 N 点長の信号 \mathbf{y} を最初の $y(0)$ から M 次数点分の $y(0), y(1), \dots, y(M-1)$ からなる初期過渡応答区間 $[0, M-1]$ のベクトル \mathbf{y}_1 と、その後 $N-M$ の点分の $y(M), y(M+1), \dots, y(N-1)$ からなる定常区間 $[M, N-1]$ のベクトル \mathbf{y}_2 に分ける。 $\mathbf{y}_1 = (y(0), y(1), \dots, y(M-1))^T$ (3.5)

$$\mathbf{y}_2 = (y(M), y(M+1), \dots, y(N-1))^T \quad (3.6)$$

上記の全区間 $[0, N-1]$ の $p(\mathbf{y}|\mathbf{a}, \sigma_x^2)$ は、初期過渡応答区間 $[0, M-1]$ の信号 \mathbf{y}_1 部分が生起する同時確率密度関数 $p(\mathbf{y}_1|\mathbf{a}, \sigma_x^2)$ と、 \mathbf{y}_1 が与えられたときに定常区間 $[M, N-1]$ の信号 \mathbf{y}_2 の生起する条件付き確率密度関数 $p(\mathbf{y}_2|\mathbf{y}_1; \mathbf{a}, \sigma_x^2)$ との積で表すことができる。

$$p(\mathbf{y}|\mathbf{a}, \sigma_x^2) = p(\mathbf{y}_2|\mathbf{y}_1; \mathbf{a}, \sigma_x^2)p(\mathbf{y}_1|\mathbf{a}, \sigma_x^2) \rightarrow \text{最大化} \quad (3.7)$$

最尤推定法に基づけば、この同時確率密度関数 $p(\mathbf{y}|\mathbf{a}, \sigma_x^2)$ を尤度関数 $L(\mathbf{y}|\mathbf{a}, \sigma_x^2)$ とみなし、この尤度を最大にする \mathbf{a} と σ_x^2 を最尤推定値として決定することになる。

3.2 定常区間の駆動信号の確率表現

定常区間 $[M, N-1]$ の駆動信号列 $x(M), x(M+1), \dots, x(N-1)$ を、 $(N-M)$ 次元ベクトル \mathbf{x}_2 で表す。

$$\mathbf{x}_2 = (x(M), x(M+1), \dots, x(N-1))^T \quad (3.8)$$

\mathbf{x}_2 は、 $\mathbf{y}_1, \mathbf{y}_2, \mathbf{a}$ からなる $(N-M)$ 次元の関数 $\mathbf{g}(\cdot)$ で表すことができる。

$$\mathbf{x}_2 = \mathbf{g}(\mathbf{y}_2, \mathbf{a}) = (g_1(\mathbf{y}_2, \mathbf{a}), g_2(\mathbf{y}_2, \mathbf{a}), \dots, g_{N-M}(\mathbf{y}_2, \mathbf{a}))^T \quad (3.9)$$

\mathbf{x}_2 の各要素は、統計的に独立で正規分布 $\mathcal{N}(0, \sigma_x^2)$ に従うから、定常項 \mathbf{y}_2 の条件つき確率密度関数 $p(\mathbf{y}_2|\mathbf{y}_1; \mathbf{a}, \sigma_x^2)$ と、 \mathbf{x}_2 の同時確率密度関数 $p(\mathbf{x}_2)$ の関係は、次式で表される。

$$p(\mathbf{x}_2) = \frac{p(\mathbf{y}_2|\mathbf{y}_1; \mathbf{a}, \sigma_x^2)}{|J|} \quad (3.10)$$

ここで、 J は、 \mathbf{y}_2 から \mathbf{x}_2 への変換 $\frac{\partial \mathbf{x}_2}{\partial \mathbf{y}_2}$ のヤコビアンで次式のようにあらわされる。

$$J = \begin{pmatrix} \frac{\partial x(1)}{\partial y(M)} & \frac{\partial x(1)}{\partial y(M+1)} & \dots & \frac{\partial x(1)}{\partial y(N-1)} \\ \frac{\partial x(2)}{\partial y(M)} & \ddots & & \frac{\partial x(2)}{\partial y(N-1)} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial x(N-M)}{\partial y(M)} & \frac{\partial x(N-M)}{\partial y(M+1)} & \dots & \frac{\partial x(N-M)}{\partial y(N-1)} \end{pmatrix} \quad (3.11)$$

実際に、式(3.1)から、 $n = M, M + 1, \dots, N - 1$ の定常区間 $[M, N - 1]$ における駆動系列 $x(n)$ は次式のように表される。

$$x(n) = y(n) + \sum_{i=1}^M a_i y(n-i) \quad (n = M, M + 1, \dots, N - 1) \quad (3.12)$$

ここで、定常区間 $[M, N - 1]$ の $(N - M)$ 次元駆動ベクトル \mathbf{x}_2 、 \mathbf{x}_2 に対する応答信号 \mathbf{y}_2 、過渡応答区間 $[0, M - 1]$ での応答信号 $y(0), y(1), \dots, y(M - 1)$ を用いて推定した定常区間での $(N - M)$ 次元駆動信号ベクトル \mathbf{e}_2 、 \mathbf{y}_2 から \mathbf{x}_2 への変換のための $(N - M) \times (N - M)$ 行列 \mathbf{J} を次のように定義する。

$$\mathbf{x}_2 = (x(M), x(M + 1), \dots, x(N - 1))^T \quad (3.13)$$

$$\mathbf{y}_2 = (y(M), y(M + 1), \dots, y(N - 1))^T \quad (3.14)$$

$$\mathbf{e}_2 = (\sum_{i=1}^M a_i y(M - i), \sum_{i=2}^M a_i y(M + 1 - i), \dots, \sum_{i=M}^M a_i y(2M - 1 - i), 0, \dots, 0)^T \quad (3.15)$$

$$\mathbf{J} = \begin{pmatrix} 1 & 0 & \cdots & \cdots & \cdots & \cdots & 0 \\ a_1 & 1 & \ddots & \ddots & \ddots & \ddots & \vdots \\ \vdots & a_1 & \ddots & \ddots & \ddots & \ddots & \vdots \\ a_M & \ddots & \ddots & \ddots & \ddots & \ddots & \vdots \\ 0 & \ddots & \ddots & \ddots & \ddots & \ddots & \vdots \\ \vdots & \ddots & \ddots & \ddots & \ddots & \ddots & 0 \\ 0 & \cdots & 0 & a_M & \cdots & a_1 & 1 \end{pmatrix} \quad (3.16)$$

これらを用いると、式(3.12)は次式のように表せる。

$$\mathbf{x}_2 = \mathbf{x}_2(\mathbf{y}_2) \quad (3.17)$$

$$= \mathbf{J}\mathbf{y}_2 + \mathbf{e}_2 \quad (3.18)$$

ここで、式(3.17)は \mathbf{x}_2 が \mathbf{y}_2 の関数であることを示している。 \mathbf{y}_2 から \mathbf{x}_2 への変換のヤコビアン \mathbf{J} は、 \mathbf{J} の対角項がすべて 1 の下三角行列であることから、 $|\mathbf{J}| = 1$ である。したがって、式(3.10)の条件つき確率密度関数 $p(\mathbf{y}_2 | \mathbf{y}_1; \mathbf{a}, \sigma_x^2)$ は次式で与えられる。

$$p(\mathbf{y}_2 | \mathbf{y}_1; \mathbf{a}, \sigma_x^2)$$

$$= |\mathbf{J}| \cdot p(\mathbf{x}_2)$$

$$= p(\mathbf{x}_2)$$

$$= \prod_{n=M}^{N-1} \frac{1}{\sqrt{2\pi\sigma_x^2}} \exp\left\{-\frac{x(n)^2}{2\sigma_x^2}\right\}$$

$$= \frac{1}{(2\pi\sigma_x^2)^{(N-M)/2}} \exp\left\{-\frac{1}{2\sigma_x^2} \sum_{n=M}^{N-1} x(n)^2\right\}$$

$$= \frac{1}{(2\pi\sigma_x^2)^{(N-M)/2}} \exp\left\{-\frac{1}{2\sigma_x^2} S_2(\mathbf{a})\right\} \quad (3.19)$$

ここで、 σ_x^2 は $x(n)$ の平均パワーを表し、 $S_2(\mathbf{a})$ は次式で与えられる。

$$S_2(\mathbf{a}) = \sum_{n=M}^{N-1} x(n)^2 = \sum_{n=M}^{N-1} (y(n) + \sum_{i=1}^M a_i y(n-i))^2 \quad (3.20)$$

ARモデルのパラメータ a_i の推定としては最尤推定法より式(3.19)を最大させる a_i を選ぶのが妥当と考えられる。 $a_0 = 1$ と定めると $S_2(\mathbf{a})$ は次式となる。

$$S_2(\mathbf{a}) = \sum_{n=M}^{N-1} (\sum_{i=0}^M a_i y(n-i))^2 \quad (a_0 = 1) \quad (3.21)$$

ここで、式(3.21)内の $\sum_{i=0}^M a_i y(n-i)$ に注目する。この二乗値の時間区間 $[M, N - 1]$ における平均値を線形予測分析における予測残差パワー α とし、次式に示す。

$$\begin{aligned} \alpha &= \frac{1}{(N-1)-M+1} \sum_{n=M}^{N-1} (\sum_{i=0}^M a_i y(n-i))^2 \\ &= \sum_{i=0}^M \sum_{j=0}^M a_i a_j \left[\frac{1}{N-M} \sum_{n=M}^{N-1} y(n-i) \cdot y(n-j) \right] \end{aligned} \quad (3.22)$$

ここで大括弧内の部分を共分散 C_{ij} と表す。

$$C_{ij} = \frac{1}{N-M} \sum_{n=M}^{N-1} y(n-i) \cdot y(n-j) \quad (3.23)$$

すると残差パワー α は次式のようになる。

$$\alpha = \sum_{i=0}^M \sum_{j=0}^M a_i a_j C_{ij} \quad (3.24)$$

ここで $M \times M$ 行列 \mathbf{C} と M 次元ベクトル \mathbf{a}, \mathbf{c} をそれぞれ次のように定義する。

$$\mathbf{C} = \begin{pmatrix} C_{11} & C_{12} & \cdots & C_{1M} \\ C_{21} & C_{22} & \cdots & C_{2M} \\ \vdots & \vdots & \ddots & \vdots \\ C_{M1} & C_{M2} & \cdots & C_{MM} \end{pmatrix} \quad (3.25)$$

$$\mathbf{a} = (a_0 \ a_1 \ \cdots \ a_M)^T \quad (3.26)$$

$$\mathbf{c} = (C_{10} \ C_{20} \ \cdots \ C_{M0})^T \quad (3.27)$$

式(3.25)、式(3.26)、式(3.27)より、 α は次式のように表すことができる。

$$\alpha = \sum_{i=0}^M \sum_{j=0}^M a_i a_j C_{ij}$$

$$\begin{aligned}
&= C_{00} + \sum_{i=1}^M \sum_{j=1}^M a_i a_j C_{ij} \\
&\quad + \sum_{i=1}^M a_i C_{i0} + \sum_{j=1}^M a_j C_{0j} \\
&= C_{00} + \mathbf{a}^T \mathbf{C} \mathbf{a} + 2\mathbf{c}^T \mathbf{a} \\
&= C_{00} + \mathbf{a}^T (\mathbf{C} \mathbf{a} + \mathbf{c}) + \mathbf{c}^T \mathbf{a} \quad (3.28)
\end{aligned}$$

よって、式(3.21)は次式で表すことができる。

$$\begin{aligned}
S_2(\mathbf{a}) &= \sum_{n=M}^{N-1} (\sum_{i=0}^M a_i y(n-i))^2 \\
&= (N-M) \times \alpha \\
&= (N-M) \times (C_{00} + \mathbf{a}^T (\mathbf{C} \mathbf{a} + \mathbf{c}) + \mathbf{c}^T \mathbf{a}) \quad (3.29)
\end{aligned}$$

3.3 過渡応答区間の扱いと尤度の最大化

一方、最初の過渡応答区間の信号からなるベクトルの生起確率 $p(\mathbf{y}_1 | \mathbf{a}, \sigma_x^2)$ は、 \mathbf{y}_1 の共分散行列を含んだ複雑な形式となることが知られている[7]。信号長が次数よりも十分に長く、かつ極が平面上で単位円から十分内側に入っている場合、伝達系のインパルス応答が短いので、過渡応答区間で駆動された応答の定常区間への寄与は小さいとみなせる。したがって、区間全体における自己回帰モデルの生起確率の評価である式(3.7)の初期過渡応答区間の同時確率密度関数を無視できる。よって次式を区間全体における尤度関数とみなせる。

$$\begin{aligned}
L(\mathbf{y} | \mathbf{a}, \sigma_x^2) &= p(\mathbf{y} | \mathbf{a}, \sigma_x^2) \\
&\approx p(\mathbf{y}_2 | \mathbf{y}_1; \mathbf{a}, \sigma_x^2) \rightarrow \text{最大化} \quad (3.30)
\end{aligned}$$

これを最大にすることで AR モデル \mathbf{y} の生起確率を最大にするパラメータ $\{a_i\}$ と σ_x^2 の最尤推定値を近似的に決定できる。

式(3.30)の両辺の自然対数を取り、対数尤度 $l(\mathbf{y} | \mathbf{a}, \sigma_x^2)$ を求めると次式になる。

$$\begin{aligned}
l(\mathbf{y} | \mathbf{a}, \sigma_x^2) \\
&= -\frac{N-M}{2} \log 2\pi - \frac{N-M}{2} \log \sigma_x^2 - \frac{1}{2\sigma_x^2} S_2(\mathbf{a}) \\
&\quad \rightarrow \text{最大化} \quad (3.31)
\end{aligned}$$

最大化のため、式(3.31)を \mathbf{a} について偏微分して零と置く。

$$\frac{\partial l(\mathbf{y} | \mathbf{a}, \sigma_x^2)}{\partial \mathbf{a}} = -\frac{1}{2\sigma_x^2} \frac{\partial S_2(\mathbf{a})}{\partial \mathbf{a}} = 0 \quad (3.32)$$

これに式(3.29)を代入すると次式を得る

$$\frac{\partial l(\mathbf{y} | \mathbf{a}, \sigma_x^2)}{\partial \mathbf{a}} = \sum_{j=0}^M a_j C_{ij} = 0 \quad (i = 1, 2, \dots, M) \quad (3.33)$$

このとき $a_0 = 1$ であるため、 a_0 が係数の項を整理すると、

$$\sum_{j=1}^M a_j C_{ij} = -C_{i0} \quad (i = 1, 2, \dots, M) \quad (3.34)$$

となる。これをベクトルと行列で記述すると次式になる。

$$\begin{pmatrix} C_{11} & C_{12} & \cdots & C_{1M} \\ C_{21} & C_{22} & \cdots & C_{2M} \\ \vdots & \vdots & \ddots & \vdots \\ C_{M1} & C_{M2} & \cdots & C_{MM} \end{pmatrix} \begin{pmatrix} a_1 \\ a_2 \\ \vdots \\ a_M \end{pmatrix} = - \begin{pmatrix} C_{10} \\ C_{20} \\ \vdots \\ C_{M0} \end{pmatrix} \quad (3.35)$$

式(3.35)をユールウォーカー方程式という。

また、式(3.25)、式(3.26)、式(3.27)からユールウォーカー方程式は次式で表される。

$$\mathbf{C} \mathbf{a} = -\mathbf{c} \quad (3.36)$$

これより、行列 \mathbf{C} が正則であれば \mathbf{a} の推定値 $\hat{\mathbf{a}}$ を決定できる。

$$\hat{\mathbf{a}} = -\mathbf{C}^{-1} \mathbf{c} \quad (3.37)$$

また、式(3.19)より、 $S_2(\mathbf{a})$ を最小にすれば $p(\mathbf{y}_2 | \mathbf{y}_1; \mathbf{a}, \sigma_x^2)$ が \mathbf{a} に関して最大になるので、式(3.36)を式(3.29)に代入して最小値 $S_2(\hat{\mathbf{a}})$ は次式で求められる。

$$S_2(\hat{\mathbf{a}}) = (N-M) \times (C_{00} + \mathbf{c}^T \hat{\mathbf{a}}) \quad (3.38)$$

一方 σ_x^2 の最尤推定値 $\hat{\sigma}_x^2$ を求めるために、式(3.31)を σ_x^2 について偏微分して零と置く。

$$\frac{\partial l(\mathbf{y} | \mathbf{a}, \sigma_x^2)}{\partial (\sigma_x^2)} = -\frac{N-M}{2\sigma_x^2} + \frac{S_2(\mathbf{a})}{2(\sigma_x^2)^2} = 0 \quad (3.39)$$

この式より、最尤推定値 $\hat{\sigma}_x^2$ は次式のように決定できる。

$$\hat{\sigma}_x^2 = \frac{1}{N-M} S_2(\mathbf{a}) \quad (3.40)$$

これに式(3.38)を代入すると次式となる。

$$\hat{\sigma}_x^2 = C_{00} + \mathbf{c}^T \hat{\mathbf{a}} \quad (3.41)$$

以上より、 \mathbf{a} と σ_x^2 に関する最尤推定値が得られた。この方法を共分散法という。

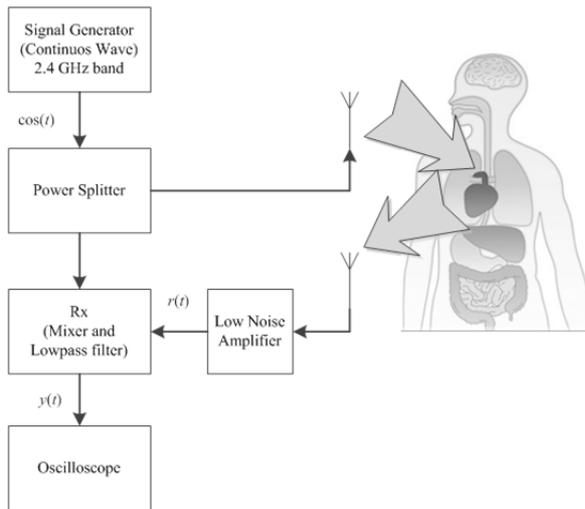


Fig.1 マイクロ波計測システム

4. マイクロ波計測システム

アンテナでマイクロ波信号を送受信すると、信号が通ったアンテナ間の伝搬経路の環境によって受信信号が変化する。この伝搬経路内に人などの生体があると、呼吸や心拍などの生体表面の振動による反射点の変動に対応し伝搬チャンネルが変化する。伝搬チャンネルの変化が受信信号に現れてくるため生体信号を検出することができる。使用した計測システム[2]を図1に示す。送信信号として無変調連続波を使用する。

5. 共分散法での処理結果・考察

5.1 信号の前処理

上記のマイクロ波計測システムから得た出力信号を、オシロスコープを用いてA/D変換し、記録する。この時の測定条件を表1に示す。得られたデータを式(3.37), (3.41)に示した方法にてARモデルを推定する。まず得られたデータをさらに表2のようにダウンサンプリングし図2のような信号を得た。図2の301ポイント目から以降の64サンプルを選び、連続した少数データを用いてPSD推定を行った。

Table.1 測定条件

Frequency range	2 GHz band
Antenna type	Patch
Height	1.15 m
Distance	30 cm
Sampling rate	1 kHz
Data length	100 k
Measurement time	100 s

Table.2 ダウンサンプリング後のデータ

Sampling rate	10 Hz
Data length	1 k
Measurement time	100 s

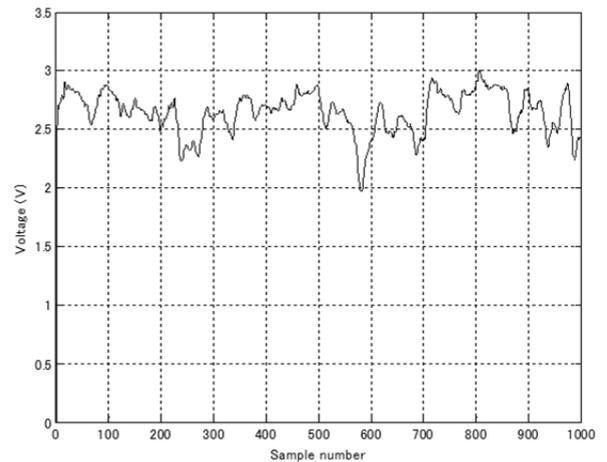


Fig.2 ダウンサンプリング後の信号データ

5.2 処理結果

共分散法ではARモデルの次数 M を設定する必要があるが、この次数決定については以下のように行った。測定時に本システム計測とは別に心電計を用いて心拍の測定を行っていたので、使用した区間での心拍の複数のピーク間のデータ数を求め、そのピーク間の平均データ個数を計算する。すると、その区間の心拍の平均周波数を求められる。今回の場合は心拍の周波数が約1.29Hz、さらに測定中の呼吸の周期はおよそ3秒に1回を意識して行っていたので呼吸の周波数が約0.3Hz

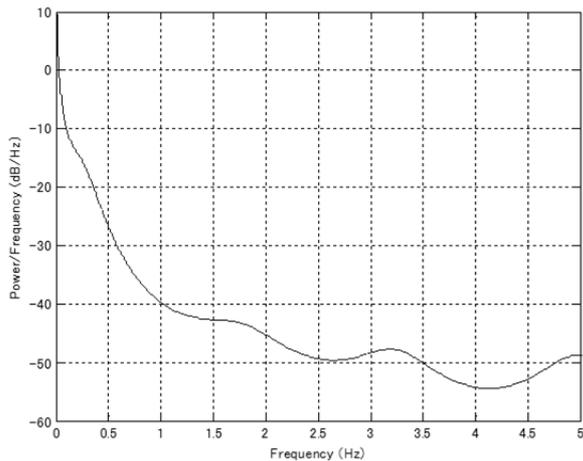


Fig.3 $M = 8$ の提案法による PSD 推定

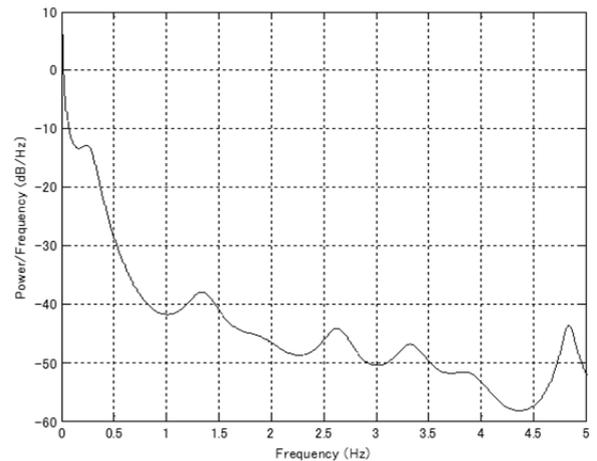


Fig.5 $M = 16$ の提案法による PSD 推定

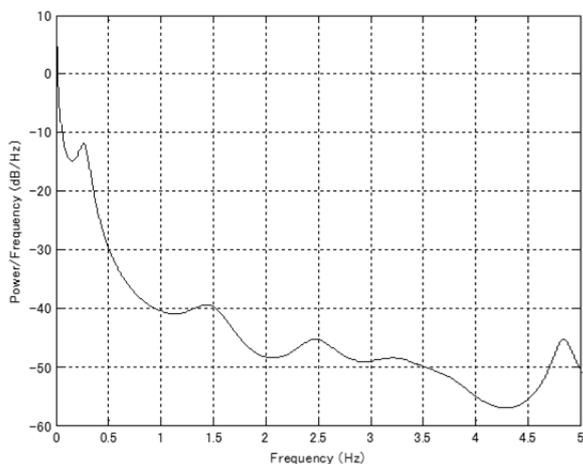


Fig.4 $M = 14$ の提案法による PSD 推定

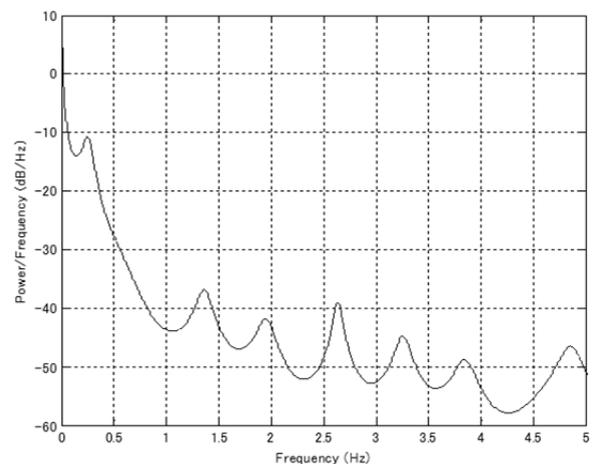


Fig.6 $M = 18$ の提案法による PSD 推定

となる。これらの周波数に対応したピークがはっきりみられる次数 M について調べ、最適なものを求める。共分散法での PSD 推定をあらゆる次数で行った結果を図 3~6 に示す。

(i) 次数 $M = 8$ 以下の場合(図 3 は $M = 8$)
スペクトルピークがはっきりと確認できないものとなった。

(ii) 次数 $M = 10 \sim 14$ の場合(図 4 は $M = 14$)
次数を 8 より大きくしていくと、徐々にピークが明確に見えてくるようになり、呼吸と思われるピークは約 0.3Hz に確認できるが、心

拍と思われるピークが約 1.5Hz に立っているのがわかる。一方、心拍の周波数(約 1.29Hz)とは僅かにズレがある。これは、この次数での AR モデルの表現が不十分で、推定された別の極によってピークが引っ張られた結果、このような PSD になったと考えられる。

(iii) 次数 $M = 16$ の場合(図 5 に示す)
心拍と思われるピークが約 1.32Hz に確認できるようになった。

(iv) 次数 $M = 18$ の場合(図 6 に示す)
これまでの呼吸・心拍と思われるピークとは

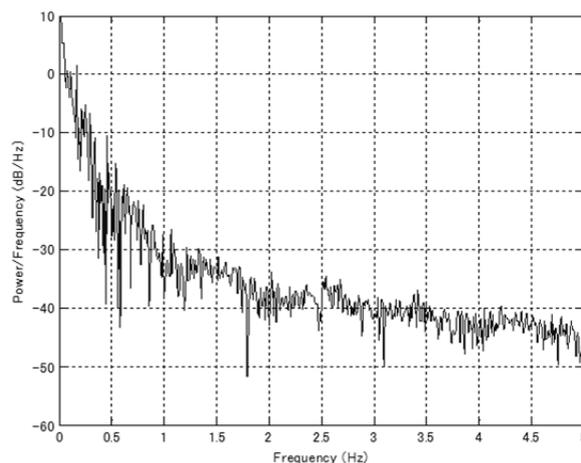
別にスペクトルピークが増える。これは生体信号の基本周波数に対する高調波による、または雑音に影響され始めたことによるピークであると思われる。

このように、次数が $M \leq 14$ の場合ではスペクトルピークを十分に確認できない、期待する位置にピークが得られないといった結果になった。次数 M を18よりさらに大きくするとやはり検知に必要なスペクトルピークも増えていき、結果、生体信号のピークが明確に得られないものになってしまう。

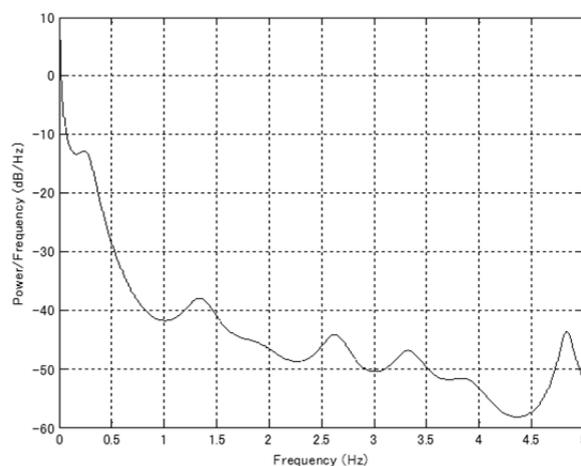
さらに共分散法による推定 PSD($M = 16, 18$)とノンパラメトリックな方法(DFT)での推定 PSD の比較を図7に示す。そもそも、ノンパラメトリック推定ではデータの信号を含まれる雑音も併せてフーリエ変換するため、PSDの解像度を上げてても雑音の不規則性が強調されるだけであるのに対して、パラメトリック推定は任意に次数を設定し、推定パラメータから極を得ることで PSD を求めているため、比較的雑音に影響されにくい結果が得られる。実際に図7で比較すると、両者のスペクトル包絡がよく似ている。

また、共分散法での PSD がノンパラメトリック推定のものより比較的雑音に影響されずに生体情報のピークを表している。したがって、提案法では比較的妥当な結果を得られたと考えられる。

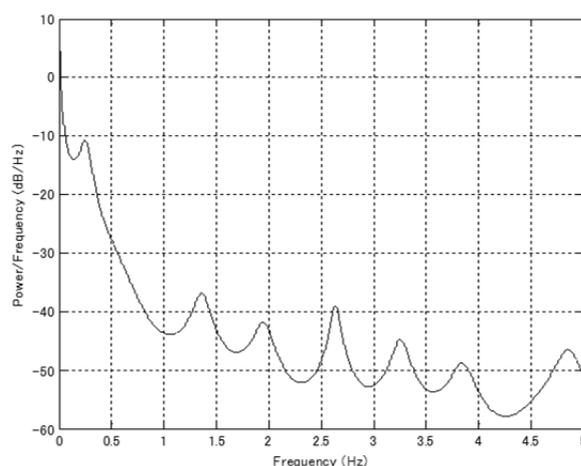
次に、次数 $M = 18$ の場合も包絡線が似ているように見えるが、本稿では生体信号の基本周波数が見えれば十分と考えた。また、図6の約2.6Hzのピークを心拍の高調波と考えると、基本周波数のピークと比べて振幅の差があまりなく、減衰振動系においてこの結果は不適當であると考えられる。よって、この場合の次数 $M = 16$ と決定する。



(a) ノンパラメトリック PSD 推定



(b) $M = 16$ の提案法での PSD 推定



(c) $M = 18$ の提案法での PSD 推定

Fig.7 ノンパラメトリック推定と提案する推定法の比較

6. まとめ

本稿では、呼吸や心拍による生体信号を非接触・無拘束で計測することを目的とした。そのためにまずアンテナとマイクロ波を用いて生体情報を計測するシステムを提案した。そして、観測信号が自己回帰モデルから得られたものであると仮定し、最尤推定法に基づいた自己回帰モデルの推定を行うことで生体情報を PSD から求めた。提案法から得られた PSD では望ましいスペクトル包絡を得られていることをノンパラメトリック推定法と比較することで確認した。そして、次数の設定により、生体情報であろうスペクトルピークを確認することができた。

今後の課題として、まずは用いるデータ数をいくつにするかということが挙げられる。今回は求めたい情報が最低2周期以上入っていることを条件に好ましい PSD が得られるよう 64 個のデータを用いたが、このデータ数の合理的な決定方法もまだ明らかではない。

次に提案法では共分散法を用いて PSD を求めたが、その次数の決定方法についても今後の課題である。

したがって、今後はこの二つの決定方法を検討していく。そして、もっと明確な生体情報を得ることをめざし、PSD の推定法をさらに検討していく。

参考文献

- [1] 西山恵介, 間瀬淳, 近木祐一郎, “マイクロ波アクティブセンサによる生体情報計測”, 電気学会研究会資料 PST. 2005 (37), pp. 41-44, (2005).
- [2] 南湖 政輝, 本間 尚樹, 西森健太郎, “MIMO チャンネル時変動特性を用いた呼吸検出法,” 電子情報通信学会総合大会, B-1-207, (2011)

- [3] 南湖 政輝, 本間 尚樹, 西森健太郎, “MIMO チャンネル時変動特性を用いた非接触呼吸検出法”, 信学技報, AP2011-49, pp. 1-6, (2011)
- [4] 佐藤宏明, 今日向, 南湖政輝, 本間尚樹他, “MIMO チャンネルを用いたヒト心臓拍動の検出”, 2011 年電通学会ソサエティ大会, BS-2-3, (2011)
- [5] 今日向, 今日向, 佐藤宏明他, “MIMO センサを用いた呼吸・心拍の計測法”, 計測自動制御学会東北支部, 272-11, (2012)
- [6] Masaki Nango, Naoki Honma, Kentaro Nishimori, Hiroaki Sato: Biological activity detection method using MIMO system, IEICE Communications Express, Vol. 2, No. 2, pp. 36-41, Feb. 2013
- [7] 金井 浩, “音・振動のスペクトル解析”, コロナ社, (1999)