

## 確率的アプローチによる生体情報の変化検出法について

松 田 健<sup>†1</sup>

近年、ICT 技術を活用した遠隔医療を行うためのネットワークや技術の整備が進み、遠隔地に住む患者に取り付けられた装置から得られる生体情報を用いて医療が行えるようになってきている。しかしながら、これまでに提案されているシステムにはサーバの管理や、生体情報を扱うための医学的知識が必要であるため、これらの知識が無い場合でも利用可能なシステムを考えることは重要な問題である。本研究では、EMFIT 社の超高感度感圧センサーから得られる心拍データの特徴を確率モデルにより抽出し、医学的知識が無い人でも心拍データの異常検知が可能なオンラインアルゴリズムを提案する。

### Automatic Detection Model of SQL Injection Attacks and Prediction Error

TAKESHI MATSUDA<sup>†1</sup>

Nowadays, the telemedical system has been realized because of the technology improvement of the information technology. In this paper, we propose the extraction procedure on the feature of heartbeat data by using stochastic models, and show that our proposed method can detect the anomaly of heartbeat experimentally.

#### 1. はじめに

ICT 技術の発展は様々な分野に影響を与えており、センサーなどの装置を用いて遠隔地に住む患者から生体情報を取得し、それを用いて診断を行う遠隔医療にも影響を与えている<sup>1)2)3)4)5)6)7)8)9)10)</sup>。このような装置によって得られる心拍・呼吸波・歩行パターン・脳

内血流などの生体情報は、心不全や睡眠時無呼吸症候群などといった症状のモニタリングなどに利用されている<sup>5)</sup>。

従来研究で提案されている生体情報を遠隔地に送信するシステムでは、センサーから取得された生体情報はインターネットを利用してサーバ上のデータベースに蓄積され、そこから実際の医療現場に情報が送られるという仕組みがとられている。取得された生体情報はグラフ化されて医療現場などのクライアント側で視覚的に分かりやすい情報にするための加工が施されたり、生体情報を解析して生体情報から医療診断に必要な情報を抽出したりするシステムが考案されている<sup>5)</sup>。

さらに従来研究では、生体情報をグラフ化することで、グラフに現れるデータの周期性をもとにして生体情報の正常・異常を判別するシステムなども提案されている。これらの技術は遠隔医療だけでなく、一人住まいの高齢者の見守りシステムや工事現場の労働者の健康管理など実に様々な分野に応用されており、今後も重要な研究課題になるものと考えられる<sup>5)7)</sup>。生体情報を用いる従来研究において、データを取得してそれらの情報を有効に活用するための枠組みについては既に確立されていると考えられる。しかしながら、これらの従来研究では、生体情報を蓄積するデータベースの管理や、異常検知のための閾値の設定が必要となるため、実際の運用には様々なコストや医学的知識が必要である。

また、心拍データをグラフで表示すると周期性をもつグラフになることを用いてフーリエ解析や解析的な手法を用いて心拍データを解析する方法<sup>11)12)</sup>が提案されているが、心拍データは確率変数として扱うべきデータであり、その周期性はかなりばらつきがあるものとなっているなどの問題<sup>5)</sup>があるだけでなく、これらの手法は計算の手続きが若干複雑であるため、オンラインでの心拍データの異常検知には向いていないと考えられる。

そこで本研究では、確率モデルを用いて心拍データを分析する方法を提案する。統計的学習や推測の手法を応用することにより、確率モデルのもつパラメータに観測されたデータの情報を集約することができるため、これにより観測された心拍データを蓄積する必要がなくなる。さらに、心拍データの異常検知を行うためのアルゴリズムは基本的に四則演算のみで行えることから、オンラインでの異常検知を実現可能となることも本提案手法の特徴である。本研究では、フィンランドの EMFIT 社の DVM から取得した心拍データに、文献<sup>14)</sup>にある不整脈のデータを加えて人工的に異常時のパターンを含む心拍データを再現し、提案手法が心拍データの異常を検知できることを実験で確認した。

<sup>†1</sup>  
サイバー大学 IT 総合学部




図 1 実験用心拍データ (正常時)

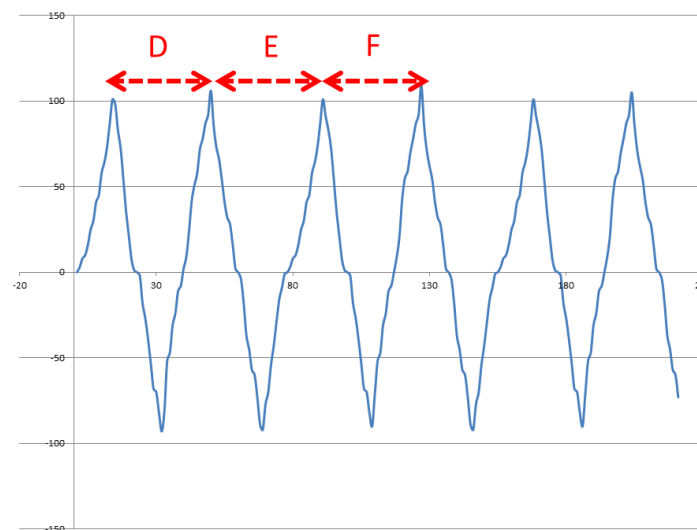


図 2 実験用心拍データ (不整脈時)

## 2. 心拍データの性質

本研究では、心拍データのもつ特徴を、確率モデルを用いて抽出する方法を提案する。そのために心拍データに関する一般的な医学的知識を紹介するだけでなく、具体的な心拍データの周期性に関する考察を行う。図 1 は DVM から取得された心拍データの波形グラフであり、本研究の実験で用いるものである。このグラフにおける時間軸は  $\frac{1}{80}$  秒間隔でとられており、以降この間隔を 1 として定義する。これにより、本論文において時間の間隔が 80 と書かれている場合、1 秒の時間が表現されることとなる。心拍データの波形は視覚的にも周期性があるように見えるが、実際に図 1 上にある区間 A, B, C の時間の間隔はそれぞれ 89, 89, 90 であり、若干のばらつきがあるものの心拍データは周期性があるデータと言えることが分かる。一方、図 3 は文献<sup>14)</sup>を参考にして再現した不整脈時の心拍データである。図 2 は明らかに図 1 と異なるものの、周期性をもつデータとしては正常時の心拍データと同じ性質であることが分かる。さらに、図 3 における区間 D, E, F の時間の間隔はそ

れぞれ 36, 44, 36 となっている。区間 A, B, C と区間 D, E, F の周期の幅を比較することで、この例においては正常と異常の区別がつけられるため、このような性質から心拍データの異常検知が可能であるとも考えられる。しかしながら、心拍データは個人差のある確率変数であることから、例え過去に区間 A, B, C と区間 D, E, F のような関係性をもったデータが観測されたことがなくとも、これらの関係をもたないデータが観測されないと言い切ることはできない。しかしながら、心拍データにおいては正常時と異常時では異なるタイプの性質をもつデータとなることは、揺るぎのない真実であると考えられる。図 1, 2 から考えられる心拍データに関する正常と異常の違いはグラフの横軸の大きさからも見て取ることができる。しかしながら、このようなデータも個人差のある確率変数であるため、確実性のあるデータというには少し問題があると言える。そこで本研究では、心拍データのグラフの極大値に着目し、そのパターンを抽出する数学的な枠組みを提案した上でそれを確率モデルで表現し、最尤学習による予測分布の変化を用いて心拍データの異常を検知する手法を構築する。

### 3. 確率モデルの適用

本研究は心拍データの特徴を数学的に捉え、それを確率モデルを用いて表現し、心拍データの異常を検知するためのアルゴリズムを提案する．具体的には心拍データの極大値のパターンの変化を捉えることで、心拍データの変化を捉える確率モデルを定義し、心拍データを予測分布の形で抽象化する．これにより、心拍データを蓄積するためのデータベースが不要になり、オンラインで心拍データの異常を検出することが可能となる．

$i$  を自然数とし、 $t_i$  で時刻  $i$ 、つまり  $i$  番目に取得したデータとする．また、 $f(t_i)$  でそのときの心拍データの大きさを表す．心拍データにおける極大値は  $i \geq 2$  において

$$f(t_{i-1}) < f(t_i), f(t_i) > f(t_{i+1})$$

を満足する  $f(t_i)$  である．いま、ある正の実数  $\alpha$  と与えられたデータに対して  $f(t_i) \geq \alpha$  を満足する極大値

$$f(t_{I_1}), f(t_{I_2}), f(t_{I_3}), \dots$$

が得られたとする．ただし、 $t_{I_1} < t_{I_2} < t_{I_3} < \dots$  である．図 5 は  $\alpha = 50$  としたときの極大値  $f(t_{I_1}), f(t_{I_2}), f(t_{I_3}), \dots$  の値である．このとき、 $f(t_{I_{j_1}}) > f(t_{I_{j_1+1}})$  となる最小の自然数  $j_1$  を探し、次に  $f(t_{I_{j_2}}) > f(t_{I_{j_2+1}})$  となる自然数  $j_2$  を探す．同様に、 $f(t_{I_{j_k}}) > f(t_{I_{j_k+1}})$  を満足する自然数  $k$  を探すことにより数列

$$\{j_1, j_2, j_3, \dots, j_k, \dots\}$$

が得られる．こうすることで、心拍データのグラフがもつある周期の中に含まれる、正の実数  $\alpha$  以上の極大値から最大の極大値までの差

$$x_1 = f(t_{I_{j_2-1}}) - f(t_{I_{j_1}}), x_2 = f(t_{I_{j_3-1}}) - f(t_{I_{j_2}}), x_3 = f(t_{I_{j_4-1}}) - f(t_{I_{j_3}}), \dots$$

が求められる．変数  $x_1, x_2, \dots$  は心拍データから得られるデータであり確率変数である．確率変数  $x_1, x_2, \dots$  の特徴を抽出するため、平均  $\mu$ 、分散  $\sigma^2$  である正規分布

$$p(x|\mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

を考える．ここで正規分布を利用した理由は、確率変数に関する大数の法則や中心極限定理を考えるためのものでなく、単純に心拍データの情報を確率モデルである正規分布に反映させるためである．まず正常時の心拍データ  $D^{(n)} = \{d_1, d_2, \dots, d_n\}$  を用意して、確率モデル  $p(x|\mu, \sigma^2)$  の最尤推定量




図 3  $\alpha = 50$  としたときの心拍データの極大点の取得の様子

$$\mu_{mle} = \frac{1}{n} \sum_{i=1}^n d_i$$

$$\sigma_{mle}^2 = \frac{1}{n} \sum_{i=1}^n (d_i - \mu_{mle})^2$$

を求め、予測分布を  $p(x|\mu_{mle}, \sigma_{mle}^2)$  と定義する．心拍データの予測分布が得られたのち、観測された心拍データ  $\{x_1, x_2, x_3, \dots\}$  から確率変数のペア  $X^{(l)} = \{x_l, x_{l+1}, \dots, x_{l+m-1}\}$  ( $l, m$  は自然数) を作り、これらの観測値から得られる最尤推定量

$$\mu_l = \frac{1}{m} \sum_{i=1}^m x_i$$

$$\sigma_l^2 = \frac{1}{m} \sum_{i=1}^m (x_i - \mu_l)^2$$

を  $l$  毎に計算し、確率モデル  $p(x|\mu_l, \sigma_l^2)$  がどの程度予測分布  $p(x|\mu_{mle}, \sigma_{mle}^2)$  からずれているかを計算する。確率分布  $p(x|\mu_l, \sigma_l^2)$  と予測分布  $p(x|\mu_{mle}, \sigma_{mle}^2)$  の誤差をカルバックライブラ情報量

$$\begin{aligned} KL(p(x|\mu_l, \sigma_l^2)|p(x|\mu_{mle}, \sigma_{mle}^2)) &= \int_{-\infty}^{\infty} p(x|\mu_l, \sigma_l^2) \log \frac{p(x|\mu_l, \sigma_l^2)}{p(x|\mu_{mle}, \sigma_{mle}^2)} dx \\ &= \log \frac{\sigma_{mle}}{\sigma_l} + \frac{\sigma_l^2}{2\sigma_{mle}^2} - \frac{1}{2} + \frac{(\mu_l - \mu_{mle})^2}{2\sigma_{mle}^2} \end{aligned}$$

で表される。この式の導出は付録で行う。

$KL = KL(p(x|\mu_l, \sigma_l^2)|p(x|\mu_{mle}, \sigma_{mle}^2))$  の値が大きくなることは、2つの確率分布  $p(x|\mu_l, \sigma_l^2)$  と予測分布  $p(x|\mu_{mle}, \sigma_{mle}^2)$  のズレが大きくなることを表す。そのため、各  $l$  に対して  $KL$  の値を計算し、その値をもとに心拍データのパターンの変化を読み取ることが可能となる。具体的には、最尤推定量  $\mu_l, \sigma_l^2$  を用いて  $KL$  の値を計検知算することを  $KL(l)$  で表すと、 $DIF(l) = |KL(l+1) - KL(l)|$  の数値を計算し、これを基にして心拍データが異常な状態にある危険度を表示するなどのシステムを構築することができる。この考え方は心拍データのモニターを見たり、心拍データの周期性からある閾値を設定して異常を検知する方法とあまり変わらないように思えるかもしれないが、本研究で提案する手法は  $DIF(l)$  の値が高ければ異常がある可能性が高いことを意味しており、このデータのみで医学的な知識を持ち合わせてなくとも異常検知ができるところが従来研究との相違点となっている。

#### 4. 実 験

本章では、3章で紹介した心拍データ（図1:正常時、図2:異常時）を用いて人工的に異常時のパターンを再現し、4章で提案したアルゴリズムを適用する。図6は作成した人工データをグラフで表したものである。本研究の提案アルゴリズムを適用するには、

- 取得する極大値の値の設定 (正の実数  $\alpha$  の設定)
- 正常時の心拍データパターンの取得 ( $D^{(n)}$  の取得)
- 観測データから作る  $m$  個のデータの設定 (自然数  $m$  の設定)

が必要となる。そのため本実験では、図1と図2を作成するために使用した DVM による心拍データから1分間分のデータをサンプリングし、 $\alpha = 50$  としたときの極大値に関する




図4 異常時のパターンを含む心拍データ

る正常時のデータ  $D^{(n)}$  から得られる最尤推定量  $\mu_{mle}, \sigma_{mle}^2$  を求め、 $m = 3$  としたときの  $DIF(l)$  の値の計算を行う。なお、データ  $D^{(n)}$  から計算される最尤推定量  $\mu_{mle}, \sigma_{mle}^2$  はそれぞれ

$$\mu_{mle} = 125.20$$

$$\sigma_{mle}^2 = 164.56$$

となった。本実験で利用する心拍の異常データを含むサンプルから、 $\alpha = 50$  以上の値をとる極大点は以下のように得ることができる。表1のデータに提案アルゴリズムを適用することで、表2のデータが得られる。図3に示した心拍データから異常を検出するために、正常時のパターン  $D^{(n)}$  の特徴を抽出するために計算した確率モデル

$$p(x|\mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

の最尤推定量  $\mu_{mle}, \sigma_{mle}^2$  を用いて定義される予測分布  $p(x|\mu_{mle}, \sigma_{mle}^2)$  と、表2で得られた観測データの  $m$  個の組  $X^{(l)} = \{x_l, x_{l+1}, \dots, x_{l+m-1}\}$  に関する  $p(x|\mu, \sigma^2)$  の最尤推定量

表 1 心拍データの極大点の抽出

$t_{I_k}$	時刻	$f(t_{I_k})$
$t_{I_1}$	3	64
$t_{I_2}$	48	90
$t_{I_3}$	66	211
$t_{I_4}$	99	60
$t_{I_5}$	123	81
$t_{I_6}$	155	186
$t_{I_7}$	169	52
$t_{I_8}$	187	65
$t_{I_9}$	226	91
$t_{I_{10}}$	245	173
$t_{I_{11}}$	317	83
$t_{I_{12}}$	336	184
$t_{I_{13}}$	373	53
$t_{I_{14}}$	406	95
$t_{I_{15}}$	424	180
$t_{I_{16}}$	458	66
$t_{I_{17}}$	494	101
$t_{I_{18}}$	530	106
$t_{I_{19}}$	571	101
$t_{I_{20}}$	607	109

表 2 観測データ

$x_k$	値
$x_1$	146
$x_2$	126
$x_3$	121
$x_4$	106
$x_5$	127
$x_6$	40
$x_7$	8
$x_8$	4
$x_9$	4

$\mu_i, \sigma_i^2$  で定義される  $p(x|\mu_i, \sigma_i^2)$  とをカルバックライブラ情報量  $KL$  を用いて測り,  $KL$  の大きさを求めて心拍データのパターン変化を捉える. 表 3 は  $m = 3$  の  $DIF(l)$  の値である.

表 3 において  $DIF(l)$  の値が急激に増加する部分において心拍データのパターンに変化があることが確認できる. これにより, 例えば  $DIF(l)$  の値を何らかの端末で表示させるこ

表 3  $m = 3$  の場合の  $DIF(l)$  の値

$l$	$DIF(l)$
1	23.44
2	4.97
3	1149.68
4	3384.06
5	7049.568
6	2735.85

とにより,  $DIF(l)$  の値をみることで医学的な知識がなくとも心拍データに何らかの異変が起こっていることを伝えることが可能である. さらに, 提案アルゴリズムの一連の計算は加減乗除の四則演算のみで処理が出来るため, オンラインでの情報処理が容易に実行できるという特徴を持っていることが分かる.

## 5. 考 察

本章では前章の実験に関する考察を行う. 本研究は確率モデルを用いて心拍データの異常値を検出する方法を提案するものであるが, 前章の表 2 を見るだけでも心拍データの異常検出ができるとも考えられる. しかし, 表 2 から異常検知を行うには閾値を定める必要がある. 閾値を定めるためには, 心拍データの性質を調べるためにデータをグラフ化するなどの作業が必要となるだけでなく, 心拍データは個人によってパターンが異なるため, 個人に合わせた閾値が必要になるものと考えられる. 本研究で提案する手法ではこのような閾値を定める必要がないため, この点が従来研究の手法と本研究の相違点となっている. また, 本研究の提案手法を用いることで医学的知識がない人でも, 心拍データの異常検出ができることも本研究の大きな特徴である.

また本研究で提案している異常検知について, 前章では, 正常時の心拍データの確率モデル  $p(\mu, \sigma^2)$  に対する最尤推定量  $\mu_{mle}, \sigma_{mle}^2$  を求めることで, 予測分布  $p(\mu_{mle}, \sigma_{mle}^2)$  として正常時の心拍データを抽象的に表現し, 観測データ  $X^{(l)}$  に関する最尤推定量  $\mu_l, \sigma_l^2$  で定義される確率分布  $p(\mu_l, \sigma_l^2)$  との違い  $DIF(l)$  を比較することで心拍データの異常検知が可能なることを実験により示した. 本研究では, 隣り合う 3 つのデータ ( $m = 3$  のとき) の場合  $DIF(l)$  を計算し, その結果を表 3 にまとめた. その結果, 心拍データのパターンが変化するときから  $DIF(l)$  の値が急激に大きくなることが分かった. 観測データのペアの取り方

を変えたときの  $DIF(l)$  の値の変化を理論的に調べることは今後の重要な課題である。

また本研究では、心拍データの特徴をグラフの極大値から抽出する方法について議論してきたが、提案方法に極大値以外の心拍データ、例えば極小値や時刻の情報などグラフから得られる他の情報を活用して心拍データの異常検知を行うことも可能であると考えられる。また、本研究では取得する極大値の値を  $\alpha = 50$  と設定したが、最適な  $\alpha$  の値を定めるためのアルゴリズムを考えることも今後の課題である。

## 6. ま と め

本論文では、確率モデルを用いて心拍データの異常を検知する方法を提案した。本研究では確率モデルの最尤推定量を用いて異常検知を行う方法を提案したが、ベイズ推定<sup>15)</sup>などの他の推定法を用いて異常検知を行ったり、他の生体情報に本研究の異常検知法を応用することなどが今後の課題である。

謝辞 本研究で使用したデータを提供して頂きました、ユーロ・プロテック社の電子医療機器コンサルタントである堀田信一氏に心より感謝申し上げます。

## 参 考 文 献

- 1) 山越 憲一, 本井 幸介, 非侵襲生体情報センシング技術の新展開: 理学療法への応用に向けて, 理学療法学 38(8), pp.555-559, 2011.
- 2) 中川原実, 山越憲一, 胸部電流分布計測に基づいた電気的インピーダンス心拍出量計測用スポット電極配置, 医用電子と生体工学 JJME 38(3), pp.238-245, 2000.
- 3) 福島遼介, 高山潤也, 蜂屋弘之, 空中超音波を用いた人ターゲットの呼吸・心拍の非接触計測, 電子情報通信学会, 信学技報, Vol. 110 No. 366, pp. 59-64, 2011.
- 4) 三林 浩二, 新しい生体計測のためのバイオ/化学センサ (アナログ, アナデジ混載, RF 及びセンサインタフェース回路), 映像情報メディア学会技術報告 33(39), pp.63-68, 2009.
- 5) 板生 清, 渡辺 小絵, ウェアラブルセンサの開発と介護予防 (特集 生活機能と介護予防の運動), 杏林書院, 体育の科学 60(10), 692-699, 2010.
- 6) 桑原 教彰, 野間 春生, 鉄谷 信二, 萩田 紀博, 小暮 潔, 伊関 洋, ウェアラブルセンサによる看護業務の自動行動計測手法 (ウェアラブル/ユビキタス・コンピューティング)(特集「インタラクション:理論, 技術, 応用, 評価」), 情報処理学会論文誌 44(11), pp.2638-2648, 2003.
- 7) 田中稔彦, フィンランド製, 超高感度感圧センサによる生体信号モニタリング技術の独居老人対応遠隔監視の活用事例, 日本遠隔医療学会雑誌, Vol.3, No.2, pp.231-233, 2007.
- 8) K. Tavakolian, B. Ngai, A. Akhbardeh, B. Kaminska and A. Blaber *Comparative*

- Analysis of Infrasonic Cardiac Signals*, Computers in Cardiology, pp.757-760, 2009.
- 9) 八坂 貴宏, 離島を含めた地域医療連携ネットワーク: あじさいネットワークの利用価値 (特集 遠隔医療の今), 地域医療振興協会, 月刊地域医学 26(8), pp.734-738, 2012.
  - 10) 郡 隆之, 石田 智之, 矢内 正男 他, 沼田保健医療圏における ICT 利活用事業: 利根沼田遠隔医療ネットワーク, 日本遠隔医療学会雑誌 8(1), pp.37-39, 2012.
  - 11) 田口 俊章, 胎児新生児心拍数基線細変動の周期性の高速フーリエ解析による検討, 日本産科婦人科学会雑誌 35(1), pp.53-60, 1983.
  - 12) 富田 豊, 心拍変動の新しい解析法の提案, 電子情報通信学会技術研究報告. MBE, ME とバイオサイバネティクス 108(219), pp.37-40, 2008.
  - 13) 村越政之, 吉澤誠, 杉田典大, 阿部誠, 田中明, 山家智之, 仁田新一, 低周波数サンプリングでの瞬時心拍数の推定方法, 計測自動制御学会第 251 回研究集会, pp1-7, 2009.
  - 14) 立川 洋一, モニター心電図の見方, [online] <http://www.coara.or.jp/tatchi/MonitorECG/MonitorECG.html>
  - 15) 松田健, 渡辺澄夫, 重み付きブローアップの混合多項分布への応用, 電子情報通信学会論文誌. A, 基礎・境界 J93-A(4), pp.300-308, 2010.