

ニューラルネットワークを用いた 指尖加速度脈波データの時系列モデリング

Modeling of Finger Acceleration Plenthysmogram by Artificial Neural Networks

経営システム工学専攻 若林 繁生
WAKABAYASHI Shigeo

1 はじめに

健康状態をはかるひとつの指標として指尖の加速度脈波(以下、指脈)がある。本研究では、指脈の時系列データに対する時系列モデリングについて検討した。

一般に指脈データは非線形性を有していると言われているが、どのような非線形モデルが適當かどうかについては明らかではない。ここでは、特定のモデルを特定しなくてもよい非線形モデルとして階層型ニューラルネットワークを用い、モデリングを行なう。

指脈データは強い周期性を持つが、振幅が変化したり周期がずれたりといった特徴を持っている。本研究では周期の変動を考慮に入れたモデリングを行うために、状態変数を取り入れたマルコフスイッチング・ニューラルネット(MS-NN)モデルを提案する。

2 研究方法

2.1 データセット

時系列データとして、PC用の測定システム「CHORUS」により実際に測定した脈波を用いた。本研究では、同じ24歳男性の指脈データの二本を対象とした。CHORUSで得られる1本の時系列の系列長は4000であるが、計算時間の短縮のため間引きを行なったデータに対し解析を行う。ラグ4以上では時系列の特徴が変化すると考えられるため、ここではラグ3で間引いた。間引き後のデータの系列長は1327である。間引き後のデータ1、2をそれぞれ図1、図2に示す。データ1およびデータ2の標本自己相関関数を図3、図4に示す。

図3、4は強い周期性を示している。最初に、差分によって周期性の除去が可能かどうかについて検討する。ラグdの差分演算子 ∇_d を

$$\nabla_d X_t = X_t - X_{t-d} \quad (1)$$

と定義する。




図1: 間引き後指脈時系列(データ1)




図2: 間引き後の指脈時系列(データ2)




図3: データ1の標本自己相関関数




図4: データ2の標本自己相関関数

X_t が周期 d の周期成分を含むとき、 $\nabla_d X_t$ からは周期 d の周期成分が除去される。標本自己相関関数より周期であると考えられるラグ $d = 44$ (データ 1)、 $d = 49$ (データ 2) として差分をとった系列は図 5、図 6 のようになる。




図 5: データ 1($d = 44$)




図 6: データ 2($d = 49$)

図 5、6においては、周期が除去できている部分とできていない部分がある。このことから、周期性は確定的なものではなく、その除去も困難であることがわかる。さらに、周期 d が一定とはみなせないことを示している。そこで本研究では、周期のずれを考慮に入れてモデリングを行う。

また、指脈のデータは非線形性を示していると考えられるので、若林・渡邊 [1] と同様ニューラルネットワークを基本となるモデルとして用いる。

2.2 ニューラルネットワークモデル

本研究で用いるニューラルネットワークは、入力層、中間層、出力層からなる階層型で、中間層の動作関数はシグモイド関数、出力層の動作関数は線形関数とした。階層型ニューラルネットは関数近似の能力を有しており、非線形時系列モデルとして用いることができる ([2] 参照)。入力層

のサイズが p であるようなニューラルネットを $NN(x_1, \dots, x_p)$ とおいたとき、次式の自己回帰型のモデルをあてはめる。

$$x_t = NN(x_{t-\ell_1}, x_{t-\ell_2}, \dots, x_{t-\ell_p}) + e_t \quad (2)$$

ここで ℓ_1, \dots, ℓ_p はラグで、 $\{e_t\}$ はホワイトノイズである。パラメータ数が増加すると、最適解ではなく局所解に落ちる可能性が大きくなる。そこでパラメータ数を減らすためにサブセット自己回帰モデルを用いる。

本研究では、与えられた系列に対してモデル (2) を最初にあてはめる。そして、これを基本モデルとして次節のモデルを推定するという手順をとる。モデル (2) における入力層、中間層については、標本自己相関数を参考にいくつかの組み合わせであてはめを行い決定した。また、パラメータの推定には Levenberg-Marquardt 法を用いた。一回の学習回数を 500 とし、これを 1000 回試行して平均二乗誤差を最小にするものを基本となる NN モデルとした。

2.3 MS-NN モデル

本研究では周期のずれを取り込むために以下のマルコフ連鎖を応用したモデルを提案する。今、新たな確率過程 $\{s_t\}$ を式 (6) に加え、

$$x_t = NN(x_{t-\ell_1+s_t}, x_{t-\ell_2+s_t}, \dots, x_{t-\ell_p+s_t}) + e_t \quad (3)$$

を考える。確率過程 s_t は周期のずれに対応したもので、本研究では、時間的一様なマルコフ連鎖であるものと仮定する。 s_t のとる値の集合を q とする。 q は整数値からなる集合であり、ここでは $q = \{-1, 0, 1\}$ とする。ただし、 $s_t = -1$ のとき $\ell_1 + s_t = 0$ となる可能性がでてくるので、 $\ell_1 = 1$, $\ell_2 = 2$ と固定した上で (3) を次のように修正する。

$$x_t = NN(x_{t-1}, x_{t-2}, x_{t-\ell_3+s_t}, \dots, x_{t-\ell_p+s_t}) + e_t \quad (4)$$

ただし、 $p > 2$, $\ell_3 > 3$ とする。本稿ではモデル (4) を MS-NN モデルと呼ぶ。

周期のずれをあらわす状態変数 s_t の推移確率を

$$P_{ij} = Pr(s_{t+1} = j | s_t = i) \text{ for } i, j \in q \quad (5)$$

とおく。 P_{ij} は t に依存しない。

2.4 モデリング

ここでは MS-NN モデルの具体的なモデリング方法を示す。基本となる NN モデルは得られているものとする。マルコフスイッチングモデルについては、最尤法を適用することができ、最尤法においては EM アルゴリズムなどがよく用いられる。しかし、非線形性の強い時系列データの場合、数値的最適化の計算が簡単ではなく、次数やラグが明らかでない場合は計算上の困難が少なくない。本研究では、数値計算を容易にする簡便法を提案する。

モデリングの手順は以下の通りである。

Step 1. 基本 NN モデルを暫定モデルとする。

Step 2. 暫定モデルを用い、各時点 $t - 1$ における x_t の予測値 $\hat{x}_{t|t-1}(k) = \text{NN}(k)$ ($k = -1, 0, 1$) を求める。ただし $\text{NN}(k)$ は、モデルにおけるラグを、(4)において $s_t = k$ としたラグで置き換えたものである。

Step 3. 次式によって予測誤差 $m_t(k)$ を求め、最小値を与える k を s_t の推定値 \hat{s}_t とする。

$$m_t(k) = (x_t - \hat{x}_{t|t-1}(k))^2 \quad (k = -1, 0, 1) \quad (6)$$

Step 4. 推定値 $\{\hat{s}_t\}$ から推移確率行列

$$P = \begin{bmatrix} P_{-1,-1} & P_{-1,0} & P_{-1,1} \\ P_{0,-1} & P_{0,0} & P_{0,1} \\ P_{1,-1} & P_{1,0} & P_{1,1} \end{bmatrix} \quad (7)$$

を求める。

Step 5. それぞれの時点 t における x_{t+1} の予測値 $\hat{x}_{t+1|t}$ を次式より求める。

$$\hat{x}_{t+1|t} = (P_{\hat{s}_t, -1} \ P_{\hat{s}_t, 0} \ P_{\hat{s}_t, 1}) \cdot \begin{pmatrix} \hat{x}_{t+1|t}(-1) \\ \hat{x}_{t+1|t}(0) \\ \hat{x}_{t+1|t}(1) \end{pmatrix} \quad (8)$$

Step 6. 系列全体に対する平均 2 乗誤差 $\frac{1}{T-L} \sum_{t=L}^{T-1} (x_{t+1} - \hat{x}_{t+1|t})^2$ を求める。 T は系列長、 L は推定において初期値として用いる長さである。

Step 7. $k = -1, 0, 1$ に対し、 $\hat{s}_t = k$ となるデータのみを用いてそれぞれの k に対するニューラルネットワークの再推定を行う。

Step 8. Step 7 の MS-NN モデルを暫定モデルとして Step 2～Step 7 を適当な回数繰り返す。

3 解析

本研究では系列長 1327 のデータの $110 \leq t \leq 1200$ の値をモデリングに用い ($T = 1200$, $L = 110$)、残りの $1201 \leq t \leq 1327$ を評価のためのテストデータとして用いた。

データ 1 に対する基本 NN モデルとして、中間層ニューロン数が 12 である次式が得られた。

$$x_t = \text{NN}(x_{t-1}, x_{t-2}, x_{t-17}, x_{t-43}, x_{t-44}, x_{t-87}, x_{t-88}) \quad (9)$$

データ 2 に対しては中間層ニューロン数が 18 である次式が得られた。

$$x_t = \text{NN}(x_{t-1}, x_{t-2}, x_{t-18}, x_{t-48}, x_{t-49}, x_{t-96}, x_{t-97}) \quad (10)$$

これらの基本 NN モデルについての $101 \leq t \leq 1200$ における平均 2 乗誤差（残差）、および $1201 \leq t \leq 1327$ における平均 2 乗誤差（予測誤差）を表 1 に示す。また、予測値のグラフを図 7、図 8 として示す。次に s_t の加える項を

	残差	予測誤差
データ 1	0.001449	0.002178
データ 2	0.0009791	0.01167

表 1: 残差と予測誤差




図 7: 予測値 (データ 1)




図 8: 予測値 (データ 2)

$p > 3$ とした MS-NN モデルによる結果を表 2、表 3 に示す。また、 $p > 2$ とした場合の結果を表 4、表 5 に示すただし、Step 2～7 の繰り返しはデータ 1 に対しては 5 回、データ 2 に対しては 6 回行なった。

4 考察

繰り返し回数	残差	予測誤差
1	0.001687	0.001839
2	0.002638	0.001732
3	0.003437	0.00206
4	0.010800	0.002087
5	0.010342	0.002744

表 2: MS-NN モデル結果 ($p > 3$, データ 1)

繰り返し回数	残差誤差	予測誤差
1	0.0011647	0.008153
2	0.001579	0.011834
3	0.001852	0.009767
4	0.001962	0.007016
5	0.002036	0.005606
6	0.002141	0.008045

表 3: MS-NN モデル結果 ($p > 3$, データ 2)

繰り返し回数	残差誤差	予測誤差
1	0.001780	0.002813
2	0.003622	0.003457
3	0.003446	0.003113
4	0.009699	0.005075
5	0.040764	0.018499

表 4: MS-NN モデル結果 ($p > 2$, データ 1)

繰り返し回数	残差誤差	予測誤差
1	0.001201	0.008164
2	0.001938	0.013347
3	0.00243	0.016925
4	0.002713	0.01646
5	0.004309	0.032185
6	0.004466	0.011318

表 5: MS-NN モデル結果 ($p > 2$, データ 2)

ここで対象とした指脈データに対しては、サブセット自己回帰型のニューラルネットワークによつて周期的特徴がうまくとらえられており、ニューラルネットワークが非線形モデルとして有効であることがわかった。

さらに提案した $p > 3$ の MS-NN モデルについては、データ 1 に対しては繰り返しが 2 回目のとき、データ 2 に対しては 5 回目のときに予測誤差が最少のモデルが得られている。

$p > 2$ の MS-NN モデルについては、データ 1 に対しては NN モデルより有効なモデルがなく、データ 2 に対しては 6 回目のときに予測誤差が最少のモデルが得られている。したがって、状態変数 s_t を加えるラグの決定が重要であると考えられる。また、実際のモデリングにおいては予測誤差の情報は得られない。残差が最小となる繰り返し回数は異なった値となっている。

現実的なモデリング法としては、繰り返し数を 2 または 3 と固定することが考えられる。なお、ここで提案したモデリング法は簡便法であり、最尤法などを適用することによりモデリングの精度をあげるとともに、予測誤差をさらに減少することが可能であると予想される。しかし、本研究の結果は、簡便法であっても提案した MS-NN モデルによって予測精度を向上させることが可能であることを示している。

本研究では、指脈に関する医学的な知識を前提にしないで時系列モデリングの立場からニューラルネットワークの非線形モデルとしての有効性について検討した。データ 1, 2 は同一人物についての指脈データであるが、異なるモデルが得られている。これは、時間帯や体調によって脈波が変化するためである。医学的な見地からは、データ 1, 2 に対するモデル間の関係についても検討する必要があると思われるが、この点については今後の課題である。

参考文献

- [1] 若林繁生、渡邊則生”ニューラルネットワークを用いた指尖脈波の時系列モデリング” 第 73 回日本統計学会 2005
- [2] 渡邊則生著「ソフトコンピューティングと時系列解析」 シーエーピー出版 2003