
総 説

BPニューラルネットワークを用いたサーカディアンリズム源のシステム同定

長 篠 博 文¹⁾, 木 内 陽 介²⁾, 芥 川 正 武¹⁾, Youssouf Cisse^{2,3)}

¹⁾ 徳島大学医学部保健学科医用放射線科学講座

²⁾ 徳島大学工学部電気電子工学科

³⁾ ラヴァル大学医学部医学科

(平成15年11月18日受付)

(平成15年11月28日受理)

生体内に存在する信号源の活動は、生体恒常性に基づく機構により常時調節されているが、同時に絶えず外部環境の影響を受けて変動していると考えられる。

ここでは生体の代表的な概日(サーカディアン)リズムである睡眠-覚醒リズムに着目し、その変動の調整システムを誤差逆伝搬学習(BP)ニューラルネットワークで同定することを試みた。その結果、リズムの変動から規則性を抽出することができ、2日前までのデータによりほぼ表現できることが分かった。

また、ニューラルネットワークの内部表現を利用することによって、システムダイナミクスの経時的变化を捉えることができた。

この手法は各種生体信号時系列に適用することにより、その信号源の同定、医用診断への応用が期待される。

1. はじめに

生体はさまざまな周期的活動を行う。その典型的な例として概日(サーカディアン)リズムがある。サーカディアンリズムは地球の自転周期にほぼ同期するものであり、睡眠-覚醒、体温などのリズムがこれに当たる。そのリズム周期はさまざまな環境条件によって絶えず変動している。それにもかかわらずほぼ一定の範囲にリズム周期が保たれているのは、生体内部に周期を一定に保つように調節する機構が存在するためである。この性質は恒常性維持(ホメオスタシス)と呼ばれている。しかしながら、そのメカニズムはよく知られていない。このシステムに内在するダイナミクスの性質を理解することは、種々のリズム発生システムの障害の診断に役立つので、きわめて重要である^{1,2)}。

本研究の目的は、変動を含む睡眠-覚醒リズムのホメオスタシスに内在するダイナミクスの性質を同定することである。このリズム中枢は視交叉上核にあり、この部位がリズムの発生、リズムの同期の調節に関与していると考えられている³⁾。リズム源の活動は、日常生活の外乱によってゆらぎを呈しながらリズムを一定に維持するように調節されている⁴⁾。したがって、このリズム源は脳における内因的な自律的神経システムによって発生していると考えられる。

これまでダイナミカルシステムの同定には多くの手法が開発されており、線形移動平均(MA)モデル、自己回帰(AR)モデル、非線形自己回帰移動平均外因(NARMAX)モデルなどがよく用いられている⁵⁻⁷⁾。生体システムは非線形性を含んでいる。誤差逆伝搬学習(backpropagation, BP)時間的BP(BPTT)アルゴリズムを組み込んだニューラルネットワーク(NN)モデル⁸⁻⁹⁾は、非線形系の予測問題に容易に適用できる¹⁰⁾ため、システム同定に新しい枠組みをもたらした。

本研究では、MAモデルに基づいたBPNNを用いる。生体システムにおける非線形性を取り扱うのに有効であると考えられるからである¹¹⁾。

同定されたダイナミックな性質は被験者の行動を反映する。環境から強い外力を受けていない被験者、すなわち通常の日常生活を送っている被験者(会社員)のデータからは、大きな規則的成分が検出された。一方規則的成分の抽出が困難であった被験者(大学生)は、研究やアルバイトなどで不規則な生活あるいは強い外力を受けていた。

2. システム同定とニューラルネットワーク

あるシステムの出力が時系列 K, x_{-1}, x_0, x_1, K で与えられ,

$$x_t + \sum_{i=1}^m a_i x_{t-i} = e_t \tag{1}$$

と表される時、これを m 次の自己回帰 (auto-regressive, AR) 過程と呼ぶ。ここで e_t は平均値 0 のガウス性白色雑音系列である。また,

$$x_t = e_t + \sum_{i=1}^n b_i e_{t-i} \tag{2}$$

と表される時、これを n 次の移動平均 (moving average, MA) 過程と呼ぶ。これらを混合して

$$x_t + \sum_{i=1}^m a_i x_{t-i} = e_t + \sum_{i=1}^n b_i e_{t-i} \tag{3}$$

と表される時 m, n 次の自己回帰移動平均混合 (mixed auto-regressive moving average, ARMA) 過程と呼ぶ。システムが線形と見なせる場合は以上のようにシステムの振る舞いをモデル化し、システム同定は x_t の推定誤差を最小にするようにパラメータ a_i, b_i と次数 m, n を推定する問題に帰着できる。

生体システムは非線形性を無視できない。NN は生体の神経系の構造と機能の特徴である多層構造と学習特性を数学的にモデル化したもので、非線形システムの解析に威力を発揮する手法の一つである。ここではデータ系列を発生するシステムのダイナミクスを次のような MA-BPNN によって同定する。時系列データ x_t をこれに先立つ n 個のデータ $x_{t-n}, x_{t-2}, x_{t-1}$ から推定する。この推定を行うために、本研究では図 1 の多層構造フィードフォワード NN を用いる。この NN は n 個のデータに対応する入力 i_1, i_2, \dots, i_n を受けてそのまま出力する入力層, x_t を出力する 1 個の出力ニューロン, これらの間に位置する 2 層のニューロン群からなる隠れ層で構成される。隠れ層のニューロンの個数をそれぞれ l_1, l_2 とする。出力ニューロン及び隠れ層のニューロンは非線形出力特性をもつ。これらは複数の入力 u_i を

$$u = \sum_i w_i u_i \tag{4}$$

の形で荷重和し、単調増加飽和関数

$$y = \tanh(u) \tag{5}$$

によって得られる値 y を出力する。ここで、 w_i は入力 u_i についての結合荷重である。このシステムは n 次の MA モデルになっている。

N 個のデータ x_1, x_2, \dots, x_N から $(N-n)$ 個のデータパターン




図 1 ニューラルネットワークの構造

$$P_1(x_1, x_2, \dots, x_n | x_{n+1})$$

$$P_2(x_2, x_3, \dots, x_{n+1} | x_{n+2})$$

.....

$$P_{N-n}(x_{N-n}, x_{N-n+1}, \dots, x_{N-1} | x_N)$$

が得られる。

NN が訓練によりリズム源のダイナミクスを獲得すれば、データ $x_{t-n}, \dots, x_{t-2}, x_{t-1}$ が入力として NN に呈示されると x_t が出力として得られる。上記データパターンのうちの一部を NN の訓練パターンとして使い、残りを NN がダイナミクスを獲得できたかどうかを調べるテストパターンとして用いる。訓練過程では x_t を目標値とし、NN の出力 o_t が目標値 x_t に一致するように、NN における各結合荷重 w_i を最急降下法を用いて次のように修正する。誤差関数 F 及び誤差 ϵ_t を

$$F = \frac{1}{2} \sum_{t \in S_t} \epsilon_t^2 \tag{6}$$

$$\epsilon_t = o_t - x_t \tag{7}$$

と定義する。ここで、 S_t は訓練パターンの集合である。誤差関数を最小化するために荷重 w_i を

$$\Delta w_i = -\eta \frac{\partial F}{\partial w_i} \tag{8}$$

で与えられる修正量 Δw_i だけ逐次修正してゆく。ここで η は適当な大きさの正の定数である。

出力ニューロンの場合は $y = o$ であるから、式(4)~(8)より

$$\Delta w_i = -\eta(o_t - x_t) \frac{dy}{du} w_i \tag{9}$$

となる。

$$\delta = (o_t - x_t) \frac{dy}{du} \quad (10)$$

とおくと，

$$\Delta w_i = -\eta \delta_i w_i \quad (11)$$

と表せる。この δ を誤差信号と呼ぶ。

隠れ層のニューロンにおける結合荷重 w_i の修正量 Δw_i の計算にはBPアルゴリズム⁸⁾を用いる。隠れ層ニューロンに式(8)を適用すると，出力ニューロンの誤差を入力層の方向へ伝搬させていくことになる。対象の隠れ層ニューロンの出力を伝える相手方ニューロン k の誤差信号 δ_k を用いると，

$$\Delta w_i = -\eta \delta_i w_i \quad (12)$$

$$\delta_i = \sum_k \delta_k w_k \quad (13)$$

となる。図1のNNの場合には，まず隠れ層2のニューロンにおける入力との結合荷重の修正量には，出力ニューロンの誤差信号に対象ニューロンと出力ニューロンの結合係数を掛け合わせた値を，誤差信号 δ_i として用いることになる。隠れ層1のニューロンにおける入力との結合荷重の場合は，隠れ層2のニューロンのそれぞれの誤差信号に対象ニューロンとの結合荷重を掛け合わせ，すべての隠れ層2のニューロンについて総和をとった値が誤差信号 δ_i になり，修正量を式(12)で与えることになる。

十分誤差が小さくなるまで訓練ができた後，テストパターンに対する推定が可能か（これを搬化という）を調べる。これが十分小さい誤差で可能になっていれば，NNはシステムの内在大ダイナミクスを獲得したと言える。

もしNNに平均値0のランダムデータ時系列を与えて訓練したならば，時系列にはシステムダイナミクスが含まれていないので，NNの出力は0になる。したがって，訓練したNNの出力は，訓練データに対してもテストデータに対しても対応する目標値には一致しない。

3. 睡眠 - 覚醒リズムデータ

2つのグループに分けた合計10名の被験者（平均年齢23歳）に3カ月間毎日の就寝時刻と目覚めた時刻を自己申告させた。第1のグループは会社員であり，第2のグループは大学生である。就寝や起床の時刻を被験者に強制してはならず，この間被験者は通常通りの生活を続けた。このデータはある程度誤差を含んでいるかも知れないが，研究の第1段階のデータとしては有用であると考え

えられる。

記録されたデータの簡単な解析から，これらのデータは2つに分類できることが観察された。すなわち規則性が見られるデータ（6名）と全く不規則なデータ（4名）である。本研究では規則的成分のダイナミクスを検出することに研究の主眼があるので，前者の規則的成分のデータについて考察した。ここではその代表例として2名の被験者A, B（ともに23歳，女性）のデータの解析結果を示す。

上記データを解析するため，3種類の時間すなわち睡眠時間 S ，覚醒時間 W ，および睡眠時間とそれに引き続く覚醒時間の和 SW を検討の対象とした。日付番号を t ，データ収録日数を N とすると

$$SW_t = S_t + W_t \quad , t = 1, 2, \dots, N \quad (14)$$

である。この3種類のデータとも変動の平均値は約2時間，平均値からの変動の最大値は， SW の場合平均値24時間から5.5時間， S の場合平均値6時間から3時間， S の場合平均値18時間から3.5時間であった。データはニューラルネットワークへの入力として適当な範囲（-1から1まで）に入るように，

$$x_t = (SW_t - 24)/h \quad , t = 1, 2, \dots, N \quad (15)$$

のように変換する。ここで $N = 91$ であり， $h = 6$ とした。

4. 方法及び結果

4.1 データの予備解析

統計的時系列データの解析を行うためには，データの厳密な予備解析が必要である。これにより多くの場合システムが線形か非線形か，決定論的かランダムか等が明らかになる。この目的のため時系列に対する近似エントロピー，自己相関，平均相互情報量などの尺度^{12, 14)}が計算される。ここではシステムが決定論的かランダムかを知ることが重要である。それは前者ならばモデル化や予測が容易であるからである。

睡眠 - 覚醒リズムデータが決定論的（規則的）かランダムかを調べるために，連続性の尺度としてはたらく Lipschitz 条件に基づく1つの方法¹⁵⁾を導入する。データの規則的成分が滑らかであることが知られているならば，連続性の評価はランダム性の指標として有用である。

図1における入力ベクトル (i_1, i_2, KK, i_n) を x で表し，出力 o を y で表す。入力ベクトルの組 x_1, x_2, \dots, x_{N-n} と対応する出力 y_1, y_2, KK, y_{N-n} がデータから得られたとする。もし x_i と x_j が非常によく似ていたならば，

規則的データならば y_i と y_j もよく似ているはずである。しかし、ランダムデータならば全く似ていないこともあり得る。そこで、ランダム性の尺度として各 x_i の近傍 Δ におけるすべての x_j に対応する y_j について差 $|y_i - y_j|$ を評価する。ランダム度 R を次のように定義する。

$$R = \frac{1}{\sum_i |\Delta_i|} \sum_{i=1}^{N-n} \sum_{j \in \Delta_i} f(z_{ji}) \quad (16)$$

ここで

$$\Delta = \left\{ j \mid \frac{|x_j - x_i|}{\sqrt{n} x_{rms}} \leq \beta, i \neq j \right\}, \text{ if } x_j \text{ exists} \quad (17)$$

$$\Delta = \left\{ j \mid \min_j \frac{|x_j - x_i|}{\sqrt{n} x_{rms}} \leq \beta, i \neq j \right\}, \text{ otherwise} \quad (18)$$

であり、 $|\Delta_i|$ は近傍 Δ_i における x_j の数を表す。 x_{rms} , y_{rms} はそれぞれデータ、出力の2乗平均値の平方根であり、 $\sqrt{n} x_{rms}$ は n 次元空間におけるベクトル x_i の平均長である。ここで

$$z_{ji} = \frac{|y_j - y_i|}{y_{rms}} \frac{|x_j - x_i|}{\sqrt{n} x_{rms}} \quad (19)$$

とし、関数 $f(z_{ji})$ を

$$f(z_{ji}) = 0, \text{ if } \frac{|x_j - x_i|}{\sqrt{n} x_{rms}} \text{ and } \frac{|y_j - y_i|}{y_{rms}} \leq \beta \quad (20)$$

$$f(z_{ji}) = 1 - (1 + \alpha z_{ji}) \exp(-\alpha z_{ji}), \text{ otherwise} \quad (21)$$

と定義する。式(20), (21)における α, β は正の定数である。

データ x_1, x_2, \dots, x_N が時間を変数とする決定論的な1価関数を標本化することによって得られたものとすると、式(20), (21)から $f(z_{ji}) = 0$ と期待される。なぜならば、任意の x_i の近傍 Δ_i (式(17))内に存在するすべての x_j に対して $y_i \cong y_j$ であるからである。ゆえにデータ数 N が十分大きい場合には R の値はほとんど0になる。データがランダムな値をとる関数から得られた場合は、 y_j は y_i とは独立であるから、 $f(z_{ji}) \cong 1$ である。したがって、大きなデータ数に対しては $R \cong 1$ である。ゆえに任意のデータに対する R は0と1の間の値をとる。すなわち R は規則性とランダム性の尺度を表す。 R の値が大きいほどランダム性が大きくて予測ができにくく、 R の値が小さいほどデータの特徴を捉えやすいことになる。

この手法は次のような利点と応用がある。

- (1) 簡単で予測システムに組み込みやすい。
- (2) 解析に大量のデータを必要としない。
- (3) NNの最適な構造を決定するのに有用であるので、生体リズムデータの解析のためのNNによるモデリングに適すると考えられる。

- (4) 臨床データの解析に有用である可能性がある。

4.2 最適なニューラルネットワーク

最適なNNを決定するための手法がこれまでに数多く提案されている^{16,17)}。それらの多くはデータをいくつかのカテゴリに分類する問題に関するものである^{18,19)}。ここでは我々は時系列の予測を対象にしている。図1のNNの構造は入力数、隠れ層の層数とニューロン数を決定すれば定まる。文献¹⁸⁾に報告されているように、時系列予測の性能はダイナミクスが決定論的であるかどうかにより依存する。そのため、データに規則成分とランダム成分がどのように含まれているかを知るため、 R の値を種々の入力数に対して4.1に記述した方法で計算した。

最初に2種類のデータを用意した。1つは-1と+1の間で一様分布をもつように発生させた乱数であり、もう1つは振幅1、周期 T の正弦波を間隔 $T/60.1$ で標本化した決定論的なデータである。これらのデータと我々のSleep+Wakeの測定データを比較した。

入力数 $n = 2, 3, KK, 7$ に対して R を計算するためのデータ集合として、1日ずつずらした45日分のデータから成る30個のデータグループ PS_1 から PS_{30} を次のように定義する。

$$PS_1 : x_1, x_2, \dots, x_{45}, \text{ with } R_1$$

$$PS_2 : x_2, x_3, \dots, x_{46}, \text{ with } R_2$$

.....

$$PS_{30} : x_{30}, x_{31}, \dots, x_{74}, \text{ with } R_{30}$$

R_1, \dots, R_{30} を計算した後、それらの平均値 R を求め、NNへの入力データ数との関係を図2に示す。ここでは式(20), (21)における α および β は、 $\alpha = 0.4, \beta = 0.01$ とした。

図2において、被験者AおよびB共に R の値は入力数 $n = 2$ のときランダムデータの場合よりもかなり小さい。 $n = 3$ でやや増加するが、それ以降 n の増加とともに R は単調に減少する。ランダムデータや正弦波の場合は一貫して n の増加とともに R は単調減少する。 $n = 5$ では被験者Aとランダムデータの R はほぼ等しい。これは被験者AのSleep+Wakeのデータはほとんどランダムであることを意味する。

Sleep+Wakeの R はほとんどランダムデータの R と正弦波の R の間に位置する。しかしながら生物学・生理学的観点から生体においては2~3日前以降の影響がより強いと考えられる。したがって、あまり多数の入力を加えても被験者の真のダイナミクスの性質を反映しな




図2 入力数とランダム性の指標の関係

いおそれがある。大きな n における規則性は被験者の環境からの外力の影響によってもたらされた可能性が高い。そこで、NN に対する入力数の最適値を 2 と決定する。

次に、隠れ層の数とそのニューロン数を決定する。隠れ層が 1 層の場合と 2 層の場合の NN についてそのニューロン数を変えて学習とテストを行った。その結果、2 層の場合の方が RMS 誤差（誤差の 2 乗平均値の平方根）が小さく、ニューロン数は 2 個あれば十分小さな RMS 誤差が得られることが分かった。表 1 および表 2 にそれぞれ被験者 A, B の場合について、この最適な構造（2 2 2 1）の NN において得られた RMS 誤差を示す。

4.3 ニューラルネットワークによるシステム同定

図 3 は最適構造（2 2 2 1）の NN に被験者 A のデータを学習させた結果を示す。横軸の 1 単位は一連の訓練データ全体の 1 回呈示に相当する。これより、訓練データ、テストデータに対する RMS 誤差はともに初期値から急激に減少しその後ほとんど一定の値を保つことが分かる。両者の RMS 誤差にそれほど差がないことから、NN はよい一般化特性を示している。この場合の RMS 誤差の収束値は約 0.04 で実時間に換算すると約 17 分に相当し、これはデータの変動よりも小さい。したがって、NN はリズム源のダイナミクスを捉えることができたと考えられる。

次に、4,000 回の学習を行った後の NN の出力と元のデータの残差の学習を行った。この場合、最初の学習で

は被験者 A の Sleep+Wake データを $N = 82$ として用いた。すなわち訓練パターンは P_1, \dots, P_{80} である。よって、訓練後の NN 出力は o_1, \dots, o_{80} と書ける。NN 出力と目標値の残差 $\mu_t (t = 1, \dots, N)$ は $\mu_t = x_t - o_t$ と表される。この残差は、NN のダイナミクス学習が完全であれば平均値 0 の雑音成分と見なせる。これらの μ_t を新しい訓練データとして用いて訓練パターン $P_{\mu 1}, \dots, P_{\mu 80}$ を作り NN を学習させた。その結果を図 4 に示す。NN 出力はほとんど 0 である。これはデータがランダムであることを示唆している。したがって、NN は最初の学習でダイナミクスを捉えていたことが分かる。これは図 4 および図 5 の場合についてランダム度 R を求めること




図3 学習に伴う誤差の変化

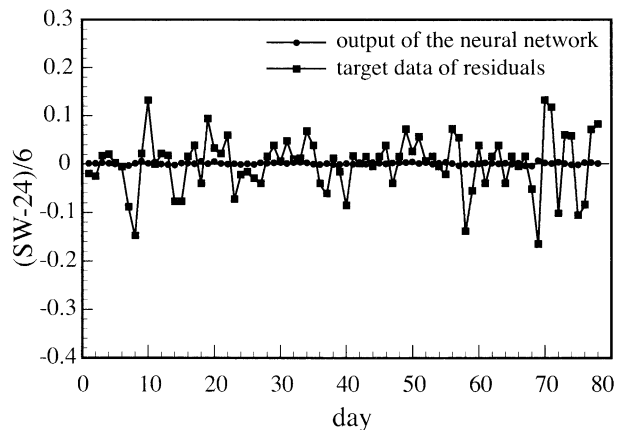




図4 ニューラルネットワークによる予測と目標データの残差の比較

Subject A


Subject B



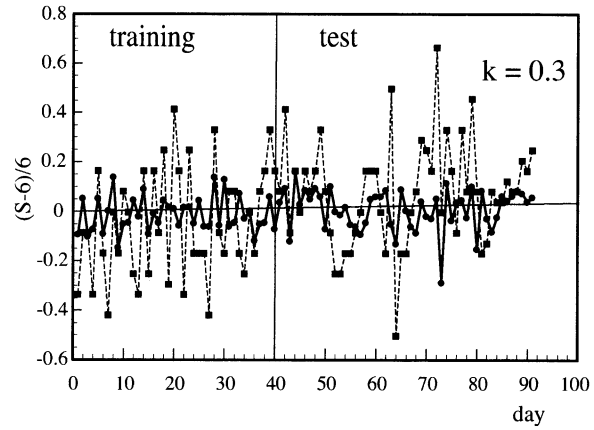
(a)




(d)




(b)



(e)



(c)



(f)

(a) wake-sleep data, (b) sleep data, (c) wake data (d) wake-sleep data, (e) sleep data, (f) wake data

---■--- : target data —●— : output of the neural network

図5 ニューラルネットワークによる予測と目標データの比較

により確認された。すなわち μ_t の R はランダムデータの R とほぼ同じ値であり、学習後の NN 出力の R は正弦波の R に近い。

しかしながら、表 1 および表 2 におけるデータを訓練に用いて NN は図 5 に示されるデータに含まれるダイナミクスを獲得した。ここでは、データ時系列のうち前半を訓練に用い、後半をテストに用いた。これより、被験者 A, B とともに NN 出力はデータの変化に追従しているが、Sleep+Wake データの場合と比較して Sleep データ、Wake データの場合は出力の変化は遅く小さいことが分かる。

表 1 ネットワークの学習結果 (被験者 A)

Data	Network	Training	RMS error
Sleep +Wake	2 2 2 1	P1 - P44 P45 - P79	0.049 0.054
Wake	2 2 2 1	P1 - P44 P45 - P79	0.045 0.052
Sleep	2 2 2 1	P1 - P44 P45 - P79	0.043 0.059

表 2 ネットワークの学習結果 (被験者 B)

Data	Network	Training	RMS error
Sleep +Wake	2 2 2 1	P1 - P40 P41 - P91	0.060 0.065
Wake	2 2 2 1	P1 - P40 P41 - P91	0.063 0.069
Sleep	2 2 2 1	P1 - P40 P41 - P91	0.066 0.059

NN は訓練データにおいてもテストデータにおいてもデータの規則性を獲得している。しかし、NN 出力の変化はデータの変化に比べて幾分小さい。これはデータが規則成分とランダム成分から成ることを意味していると考えられる。このことを立証するため、我々は 4.1 の手法を提案した。しかし、ここではランダム度 R の変化とデータサイズの評価を評価しなければならない。

種々の場合の R の値を図 6 に示す。データ数が増加すると、ランダムデータの場合には R は次第に 1 に近づき、正弦波の場合は 0 に近づくことが分かる。データ数が小さい場合ランダムデータの R は小さくなる。これはランダム性を検出するのが難しいからである。Sleep+Wake データ、Sleep データ、Wake データの R はランダムデータの R と正弦波の R との間にある。したがって、これらのデータは規則成分とランダム成分の両方を含むことが分かる。NN は規則成分を獲得したので、学習後の NN 出力は対応するデータの値よりも小さいので

ある。

次に、ここで提案したシステムの能力を明らかにするために、ノイズに対する規則性の比を評価することは重要である。時系列 x_t は

$$x_t = o_t + \mu_t \tag{22}$$

と表される。ここで o_t は図 4 に示したような訓練後のネットワークシステムの出力であり、 μ_t は出力と目標値の残差から得られる平均値 0 のノイズ成分である。上式の両辺の 2 乗平均をとることにより

$$\overline{x_t^2} = \overline{o_t^2} + \overline{\mu_t^2} \tag{23}$$



$$\xi_x = \sqrt{\overline{o_t^2}} \text{ および } \xi_\mu = \sqrt{\overline{\mu_t^2}} \tag{24}$$

を得る。

規則性の尺度 D を

$$D = \xi_x / (\xi_x + \xi_\mu) \tag{25}$$

のように定義する。式(17)を用いて計算した結果、被験者



(a) subject A, (b) subject B

図 6 ランダム性の程度

A については Sleep+Wake データに対して $D=42\%$, Sleep データに対して $D=20\%$, Wake データに対して $D=30\%$ であり, 被験者 B については Sleep+Wake データに対して $D=45\%$, Sleep データに対して $D=28\%$, Wake データに対して $D=35\%$ であった。この結果から, 元のデータにノイズ成分が含まれている場合でも D の値はかなり高く, NN はデータに含まれるダイナミクスの性質を捉えることができると考えられる。

4.4 システム変動の検出

NN がデータからシステムダイナミクスの性質を捉えることができると考えられることが分かった。そこで, 次に各被験者に対する環境からの外力の影響の下で, システムダイナミクスが時間とともにどのように変化しているかを NN がより明確に示すことができるかどうかについて検討する。訓練された NN の性質はニューロン間の結合荷重によって表現される。これは NN の 1 種の内部表現である。ここでの最適構造の NN には 10 個の結合荷重がある。これをベクトル w で表す。生体システムのダイナミクスの性質は通常時間と共に適応的に変化する。この適応的变化をここでは荷重ベクトル w の変化で評価する。

この点を検討するため, 被験者 A のネットワークをデータパターングループ



$$MPG(t): P_t, P_{t+1}, \dots, P_{t+31}, t = 1, \dots, 45$$

を用いて訓練した。各グループは 44 個のパターンから成り, 上記のダイナミクスの性質を学習するのに十分である。学習により収束した荷重ベクトルを w_1, w_2, \dots, w_{45} と表す。得られたダイナミクスの適応的变化を w_1 からの荷重ベクトルの方向の変化によって評価する。ここでは

$$\cos \theta_t = \frac{w_t \cdot w_1}{\|w_t\| \|w_1\|}, t = 1, \dots, 45 \quad (26)$$

によって評価する。ここで, θ は 2 つのベクトルの成す角度である。

図 7 は被験者 A および B のデータに対する $\cos \theta_t$ の変化を示す。Sleep+Wake データについては $\cos \theta_t$ はほぼ 0.8 よりも大きく, ダイナミクスはあまり変化していないと見なせる。詳細に見ると, 一時ある程度の急な変化はあるものの, 20 日間程度はほぼ一定値に保たれている。Sleep データ, Wake データの場合はダイナミクスの変化は Sleep+Wake データの場合よりも大きい。しかし, 5 - 20 日間同様の特性を保つ期間もある。したがっ



(a) subject A, (b) subject B

図 7 内部表現の変化

て, このリズム源のダイナミクスはある環境の変化によって時折調整され, その後一定期間定常状態を保つと考えられる。

5. おわりに

われわれは, サーカディアンリズムの 1 つである睡眠 - 覚醒リズムのデータからそのダイナミクスの性質を, NN の手法を用いて同定した。データには規則的な成分に加えてランダムに変動する成分が含まれている。変動するデータから生物学的ダイナミクス, すなわち規則的性質を捉えるために MA-BP アルゴリズムモデルを用いた。MA モデルの次数は被験者の行動に依存するが, 最初の 2 つが支配的であり, 2 次のモデルでほとんど内部ダイナミクスの性質を捉えることができると見なせた。すなわち, 当日の睡眠時間, 覚醒時間, その合計はいずれも, 前日と前々日の値によってほぼ決まるといふ内部ダイナミクスが得られた。

ここで示した結果は会社員と大学生の被験者のうち、主として会社員のデータに基づいている。大学生のデータは外部環境あるいは日常の不規則な活動に強く影響を受けている。外力の周期的変化が強い影響を及ぼす場合は、その周期は5日から7日であり、MAモデルの次数が5から7となる。不規則性が強い場合はランダム度がきわめて高くなる。したがって、MA-BPアルゴリズムによって生体システムに内在する規則性成分をデータから抽出することは困難であった。

内部ダイナミクスが時折変化することをNNにおける結合荷重の変化を評価することにより見いだした。これは環境に対する一種の適応と考えられる。内部ダイナミクスはSleep+Wakeデータにおいて20日間以上、Seepデータ、Wakeデータにおいて5日から20日間持続する。

更に我々は、連続的なデータにおける規則性あるいはランダム性の程度を決定する方法を示した。この手法により種々のデータの解析のためのNNの構造を決定することができる見込みがある。

以上のような結果から本研究で開発した手法は、臨床医学に応用することによって、ヒトの睡眠-覚醒リズムなどのサーカディアンリズムに関連した障害の診断に寄与すると考えられる。本研究はMA-BPNNを用いた臨床医学における診断法の開発の第1歩として位置づけられる。

NNにおける非線形出力特性をもつニューロンを線形出力素子に置き換えて、線形モデルとしての同定も試みた。その結果、訓練データに対しては線形の場合でも非線形の場合と同程度のRMS誤差を得たが、テストデータに対しては非線形ニューロンの方が0.5から1ポイント低いRMS誤差が得られた。このことから、データは線形モデルにより近似することもある程度可能であると思われる。しかし、一般に生体システムは非線形性を含む。したがって、本研究では非線形モデルを用いた。

本研究のモデルの能力を向上させるには、被験者数を増やすこと、正常者とともサーカディアンリズムに関する障害をもつ患者のデータを解析することが必要である。本研究の手法を他の信号源システム同定、臨床医学における診断ツール、生物学などに応用することが今後の課題であり、現在手術中の脳波のモニタリングによる脳システムの変化の検出などへの応用を検討している²⁰⁾。

文 献

- 1) Haken, H. and Koepchen, H. P.: Rhythm in Physiological Systems, Proceedings of the International Symposium, Bavaria, 1990
- 2) Luce, G. G.: Biological clocks, Edward Arnold Ltd., London, 1979
- 3) Aschoff, J.: Handbook of Behavioral neurology, New York Press, New York, 1981
- 4) Vander, A. J., Sherman, J. H. and Luciano, D. S.: Human Physiology: The Mechanisms of Body Function, McGraw-Hill Press, Auckland, 1985
- 5) Davis, M. H. A. and Zheng, W. X.: A New Order Estimation Technique for Time series Modeling. IEEE Transactions on Automatic Control 42: 400-403, 1997
- 6) Tugnait, J.: Fitting MA models to Linear Non Gaussian Random field Using Higher order Cumulants. IEEE Transactions on Signal Processing 45: 1045-1050, 1997
- 7) Chow, T. W. S., Fei, G. and Cho, S. Y.: High order cumulants-based least squares for nonminimum-phase system Identification. IEEE Transactions on Industrial Electronics 44: 707-716, 1997
- 8) Rumelhart, D. E., Hinton, G. E. and Williams, R. J.: Learning internal representation by error propagation, In: Rumelhart, D. E., McClelland, J. L. and the PDP Research Group (Eds.): Parallel Distributed Processing, MIT Press, Cambridge, 1986, P. P. 318-362
- 9) Matsuba, I., Masui, H. and Hebishima, S.: Optimizing Multilayer Neural Networks Using Fractal Dimensions of Time series Data. Proceedings of IEEE International Joint Conference on Neural Networks, 1: 583-588, 1992
- 10) Doherty, S., Gomm, J. and Williams, D.: Experiment design Consideration for Nonlinear System Identification Using Neural Networks. Computers and Chemical Engineering 21: 327-346, 1997
- 11) Cisse, Y., Kinouchi, Y., Nagashino, H. and Akutagawa, M.: BP Neural Networks Approach for Identifying Biological Signal Source in Circadian Data Fluctuations. IEICE Transactions on Information and Systems, E85 D: 567-576, 2002

- 12) Pincus, S. M., Gladstone, I. M. and Ehrenkranz, R. A. : A Regularity Statistic for Medical Data Analysis. *Journal of Clinical Monitoring* ,7 : 335-345 ,1991
- 13) Bendat, J. S. and Piersol, A. G. : *Random Data Analysis and Measurement Procedures*, John Wiley and Sons, New York ,1971
- 14) Kulkarni, D. R., Parikh, J. C. and Pandya, A. S. : Dynamic Predictions from Time Series Data : An Artificial Neural Network Approach. *International Journal of Modern Physics C* 8 : 1345-1360 ,1997
- 15) Morgan, F. : What is a surface, *American Mathematics Monthly* ,103 : 369-376 ,1996
- 16) Kulkarni, D. R., Pandya, A. S. and Parikh, J. C. : Modeling and Predicting Sunspots Activity-State Space Reconstruction + Artificial Neural Network Methods. *Geophysical Research Letters* 25 : 457-460 ,1998
- 17) Fogel, D. B. : An Information Criterion for Optimal Neural Network Selection. *IEEE Transactions on Neural Networks* 2 : 490-497 ,1991
- 18) Park, Y. R., Murray, T. J. and Chen, C. : Predicting Sun Spots Using a Layered Perceptron Neural Network. *IEEE Transactions on Neural Networks* ,7 : 501-505 ,1996
- 19) Faraway, J. and Chatfield, C. : Time series Forecasting with Neural Network : A comparative Study Using the Airline Data. *Applied Statistics Journal of The Royal Statistical Society Series* 47 : 231-250 ,1988
- 20) Kawano, T., Akutagawa, M., Zhang, Q., Nagashino, H. *et al.* : System identification of the brain dynamics by EEG analysis using neural networks, V. Palade, R. J. Howlett and L. C. Jain(Eds.) : *Knowledge-Based Intelligent Information and Engineering Systems. (Proceedings of Seventh International Conference on Knowledge-Based Intelligent Information and Engineering Systems, Oxford, UK, Sept. 3-5, 2003)* Springer-Verlag, Berlin, Heidelberg, II ,2003 P. P. 807-813

BP neural networks approach for identifying biological rhythm source in circadian data fluctuations

Hirofumi Nagashino¹⁾, Yohsuke Kinouchi²⁾, Masatake Akutagawa¹⁾, and Youssouf Cisse^{2,3)}

¹⁾*Department of Radiologic Science and Engineering, School of Health Sciences, ²⁾Department of Electrical and Electronic Engineering, Faculty of Engineering, The University of Tokushima, Tokushima, Japan ; and ³⁾Department of Medicine, Faculty of Medicine, Laval University, Quebec, Canada*

SUMMARY

Almost all land animals coordinate their behavior with circadian rhythms, matching their functions to the daily cycles of lightness and darkness that result from the rotation of the earth corresponding to 24 hours. Through external stimuli, such as dairy life activities or other sources from our environment may influence the internal rhythmicity of sleep and waking properties. However, the rhythms are regulated to keep their activity constant by homeostasis while fluctuating by incessant influences of external forces. A modeling study has been developed to identify homeostatic dynamics properties underlying a circadian rhythm activity of sleep and wake data measured from normal subjects, using an MA (Moving Average) model associated with backpropagation (BP) algorithm. As a result, we found out that the neural network can capture the regularity and irregularity components included in the data. The order of MA neural network model depends on subject's behavior. The last two data are usually dominant in the case without strong external forces. The adaptive changes of the dynamics are evaluated by the change of weight vectors, a kind of internal representation of the trained network. The dynamics is kept in a steady state for more than 20 days. Identified properties reflect the subject's behavior, and hence may be useful for medical diagnoses of disorders related to circadian rhythms.

Key words : circadian rhythms, sleep-wake rhythm, system identification, neural network, moving average process