

ニューラルネットワークを用いた自律神経活動の状態分類

八木, 翔司 / YAGI, Shoji

(発行年 / Year)

2010-03-24

(学位授与年月日 / Date of Granted)

2010-03-24

(学位名 / Degree Name)

修士(工学)

(学位授与機関 / Degree Grantor)

法政大学 (Hosei University)

P377.5
1134
2009-29

2009年度 修士論文

ニューラルネットワークを用いた
自律神経活動の状態分類

指導教授 八名 和夫 教授

法政大学大学院
工学研究科 情報電子工学専攻
08R4134 八木 翔司



Abstract

This paper proposes a method to classify heart rate signal patterns depending on the state of autonomic nervous activities utilizing a neural network, a three layer perceptron has been applied to power spectra obtained from 14 normal subject with variety of conditions. The neural network receives characteristic features of the power spectrum of heart rate fluctuations for classifying them into four classes, i.e., control, parasympathetic, sympathetic and both blockade. Correct classification rate of 90% was achieved for the upright posture. For supine subjects, the rate was 70% utilizing relative spectra. The method is promising for automatic classification of the heart rate variability.

目次

概要	4
第1章 自律神経と心拍変動	5
1.1 自律神経	5
1.2 心拍変動	5
1.3 心電図波形	6
1.4 Berger 法	7
第2章 心拍変動のパワースペクトル	8
2.1 パワースペクトルへの変換	8
2.2 解析データ	8
2.3 スペクトルデータ	8
2.4 相対スペクトル	11
第3章 スペクトル解析に用いる指標定義	13
3.1 エントロピー帯域幅	13
3.2 活動推定指標	14
3.3 血圧変動に着目した指標	14
第4章 ニューラルネットワーク	16
4.1 ニューラルネットワークの構成	16
4.2 学習と評価	18
4.3 逆誤差伝播法	19
第5章 解析結果	21
5.1 解析内容	21
5.2 従来指標による結果	21
5.3 MFまたはWMFを用いた結果	25
5.4 相対スペクトルを用いた結果	31

第6章 考察	40
6.1 今回の解析の問題点	40
6.2 MFやWMFの導入による利点	40
6.3 相対スペクトルの場合の有効指標	41
おわりに	43
謝辞	44
参考文献	45

概要

生体における重要な神経の一つ、自律神経系は生体の内部環境を整えている神経系であり、生体の意思とは関係なく独立して働いている。この自律神経は交感神経と副交感神経という二つの互いに拮抗する働きを持ったシステムからなっており、近年ではこの自律神経のバランスが狂う自律神経失調症に陥る人が増えている。これはストレスなどの精神的要因、慢性疾患などの身体的要因等で、頭痛、めまい、吐き気等の症状が出るのだが、器質的な異常でなく、機能的に異常であるためこれとって決め手となる診断方法がない。そこで自律神経の支配を受けている器官に注目し、これらの変動から逆に自律神経の状態を推定する方法が考えられている。

その手法の一つとして心拍変動から自律神経の状態を推定する方法が挙げられる。近年では心拍変動はマンマシンインターフェースの設計やドライバーの緊張度評価といった生理指標を定量化する方法として知られている。心拍変動を用いた自律神経活動の推定には時間領域における解析と周波数領域における解析に大別される。周波数領域における心拍変動のスペクトル解析は自律神経の活動状態を無侵襲的に推定できる方法として広く用いられている。

スペクトル解析は従来、1981年 Akserlod らによって提案された LF 、 HF 等が指標として用いられる事が多い。[1] 本稿ではそれに加え、血圧変動が反映されたと思われる心拍スペクトルの変動成分に着目し、その領域を MF とした。また心拍を特徴づける手法として推定指標にエントロピー帯域を用いている。そして従来の LF 、 HF 指標と MF 指標、エントロピー帯域指標の違いを識別、及びその評価をするためニューラルネットワークを導入した。

第1章 自律神経と心拍変動

1.1 自律神経

神経系とは神経細胞の働きによって情報の伝達と処理を行う器官を指し、大きく二つに分類される。一つは中枢神経と呼ばれ、脳などの塊の神経からなる脊椎動物の中枢神経は脳や脊髄などで構成される。もう一つは抹消神経と呼ばれ、中枢神経から伸びる神経繊維が多数集まり束になって走っているもので、中枢神経と身体の各部位を結ぶ働きをする。

抹消神経は更に体性神経系と自律神経系に大別でき、体性神経系は目に見えるような身体動作もしくは随意運動に強く関与する。即ち生体の外界への反応を示す一方で、自律神経系は生体の内部環境を整えるものである。自律神経は心拍、呼吸、分泌などの調節を行っている。

自律神経は交感神経と副交感神経という互いに拮抗する働きを持ったシステムからなっている。交感神経は環境に対して生体が活発、積極的に機能を高める方向に働き、副交感神経は休養、疲労などの機能に関係する。例えば心臓に対して交感神経の活動は活動リズムを速め、かつ心拍数を増大させるが、副交感神経の活動は正反対のプラス効果をもたらす。消化器官に対しては交感神経の活動は胃腸管運動を抑制し、消化酵素や胆汁の分泌を低下させる一方で副交感神経の活動は正反対のプラスの効果をもたらす。

1.2 心拍変動

心臓は全身に血液を送り出すポンプの役割を担っている。心臓はまず上下に分けられ、上部は心房、下部は心室と呼ぶ。更に左右に分けられ全部で4つの部屋、即ち右心房、左心房、右心室、左心室である。右心房には洞結節と呼ばれる心臓の拍動リズムを決めるSAノードが存在し、この洞結節が周期的に刺激を発生させ、刺激伝導系である洞結節、房室結節、ヒ

ス束, 左脚と右脚, プルキンエ網, 心室作業心筋を伝わる事で心臓が1拍の拍動をする。

この洞結節は自律神経に支配されており, 自律神経の活動が介入, 周波数変動を起こし変動が起こる。運動等で交感神経が優位ならば洞結節の刺激の発生が早くなり, 睡眠時などで副交感神経が優位ならば遅くなる。このような揺らぎの事を心拍変動 (*HRV*) と呼ぶ。

現在, この *HRV* を解析して自律神経の活動を推定しており, 時間領域と周波数領域においての指標が存在している。 *HRV* の解析を行う際に洞結節のデータ取得が不可能な為, 実際は心電図を用いた解析を行う。

1.3 心電図波形

心電図とは心臓の電氣的な活動の様子をグラフの形に記録することで, 主に心臓の疾患における診断や治療に役立つものである。心電図は *P* 波, *QRS* 波, *T* 波の3つの波形で構成され, 心臓内の電気刺激が心臓全体に伝わっていく過程を記録している。その典型的な心電図波形を図 1.1 に示す。

この心電図で計測される電位の変化により心拍変動の測定を行う。理想としては心房の興奮が洞房結節から始まる *P* 波を利用し *PP* 間隔を解析に使うのがいいのだが, *P* 波は電位が小さく, 雑音の影響を受けやすいため, 代わりに *R* 波を検出して *RR* 間隔 (*RRI*) の時系列を記録するのが一般的とされている。

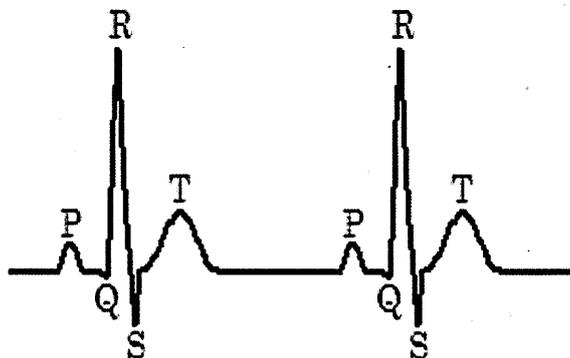


図 1.1: 心電図波形

1.4 Berger 法

心拍変動を時間領域でとらえると瞬時心拍数の時間的変化と考えられる。よってスペクトル解析を行うには観測される RR 間隔から各時刻における瞬時心拍数を推定することが第一である.[2] そのための推定方法として Berger 法である。

Berger 法は 1986 年 Berger らによって提案された手法である。 m 番目のサンプル点の HR を hr_m とし、これを求めるために m 番目のサンプル点を中心とした局所窓内の心拍数 h_m を求めなければならない。

局所窓とは各サンプル点ごと前後のサンプル点に囲まれた範囲の事でありこの範囲に R 波のピークがあるかないかで h_m の求め方が異なる。局所窓内に R 波ピークがある場合は (1.1) 式、ない場合は (1.2) 式で求められる。図 1.2 のように心電図と時間領域を見比べてみると分かりやすいかと思われる。

$$h_i = \frac{a}{I_k} + \frac{b}{I_{k+1}} \quad (1.1)$$

$$h_j = \frac{c}{I_{k+2}} \quad (1.2)$$

求めた局所窓内の心拍数を h_m と最終的なりサンプリング周波数 f_r から (1.3) 式でサンプル点の HR を求められる。

$$hr_m = h_m \cdot \frac{f_r}{2} \quad (1.3)$$

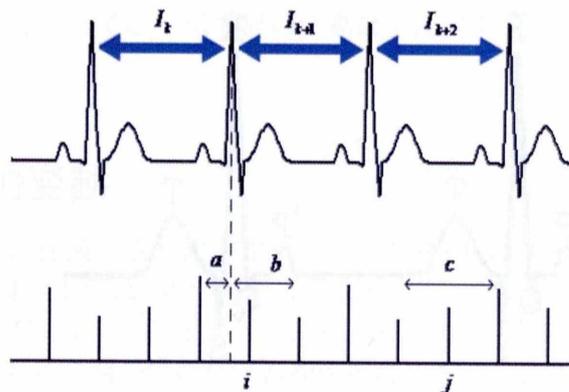


図 1.2: 心電図と時間領域

第2章 心拍変動のパワースペクトル

2.1 パワースペクトルへの変換

心電図の RR 間隔から HR を *Berger* 法により求める。その後、サンプリング周波数 3Hz でリサンプルした HR を解析の対象とする。

フーリエ変換の条件は

- 256 点ハミング窓
- ハーフオーバーラップ
- 加算回数 8 回程度

とし、パワースペクトルを算出した。

2.2 解析データ

14 名の 19 歳から 38 歳の成人男性を被験者とし、仰臥位 (*supine*)、立位 (*upright*) のコントロールデータを 5 分間の間隔をあけそれぞれ収集した。その後 *propranolol*, *atropine* といった薬物を使い、それぞれ交感神経あるいは副交感神経の活動を遮断し、仰臥位、立位それぞれ 5 分間隔をあけ 13 分間収集した。続いて前の薬物投与で *propranolol* を投与した際には *atropine* を、*atropine* を投与した際には *propranolol* を投与し、交感神経と副交感神経を同時に遮断した場合について、仰臥位、立位で 13 分間、5 分の間隔をあけてデータを収集した。以上の経緯を同一条件のもとで 2 回行った。

2.3 スペクトルデータ

図 2.1 から図 2.4 に導出した心拍変動の平均スペクトルを示す。各図の *supine* と *upright* は収集した 2 回分のデータのうち前半と後半の平均をとったものである。

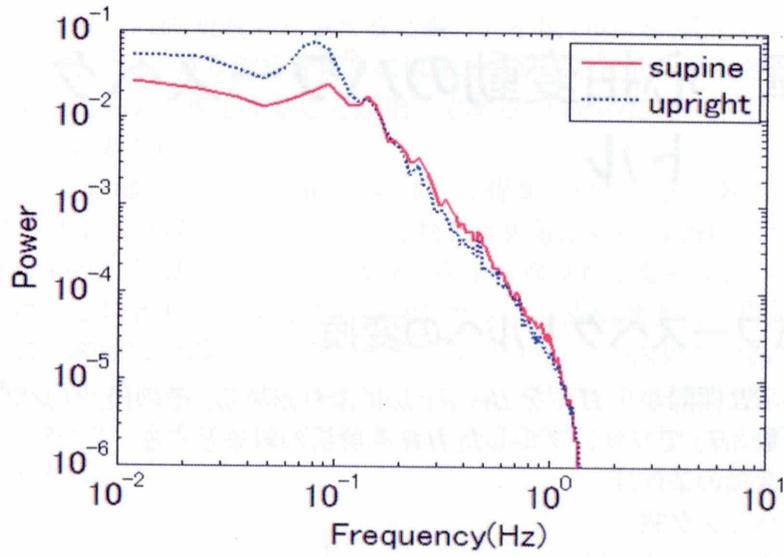


図 2.1: control 平均スペクトル

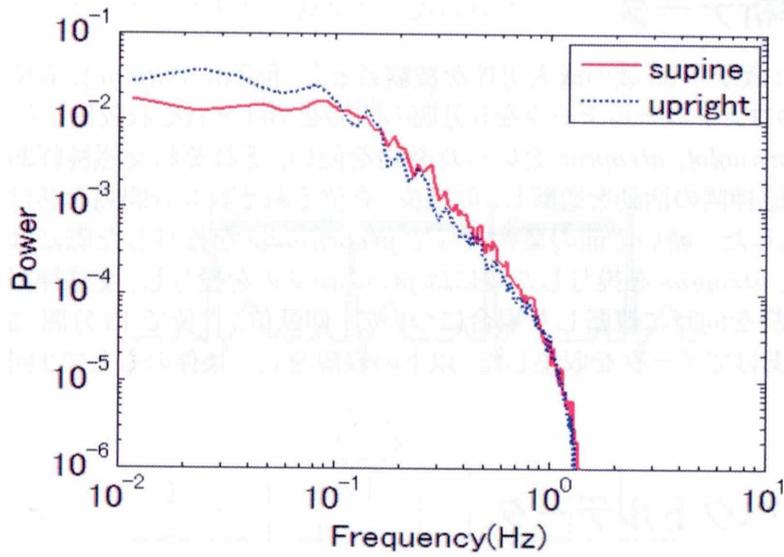


図 2.2: propranolol 平均スペクトル

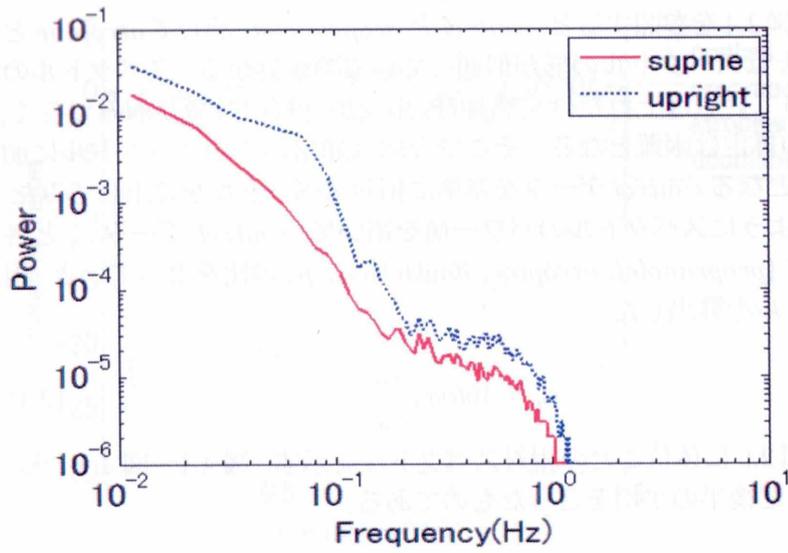


図 2.3: atropine 平均スペクトル

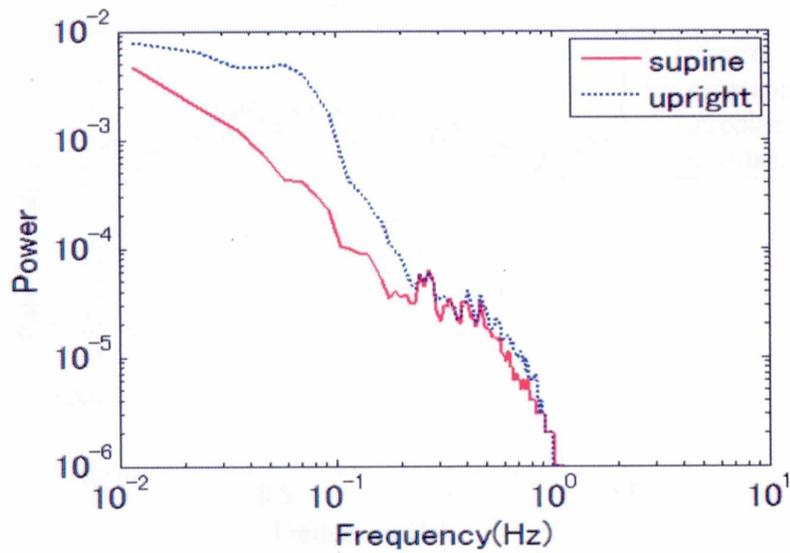


図 2.4: doubleblock 平均スペクトル

2.4 相対スペクトル

図 2.1～図 2.4 を参照すると, *control* と *propranolol*, そして *atropine* と *doubleblock* はスペクトルの形が似通っているのが分かる. スペクトルの形が似通っていればそれだけ交感神経, 副交感神経の特徴が掴みづらく, 自律神経の推定は困難となる. そこで今回は通常的心拍スペクトルに加えて, 基本となる *control* データを基準に相対スペクトルを算出してみた. 式 (2.1) のようにスペクトルのパワー値を用いて, *control* データ c_n と各状態データ (*propranolol*, *atropine*, *doubleblock*) p_n の比をとっていき, 相対スペクトルを算出した.

$$r_n = 10 \log_{10} \frac{p_n}{c_n} \quad (2.1)$$

図 2.5, 図 2.6 に体位ごとの相対スペクトルを示す. 図 4.1～図 4.4 同様, 各図は前半と後半の平均をとったものである.

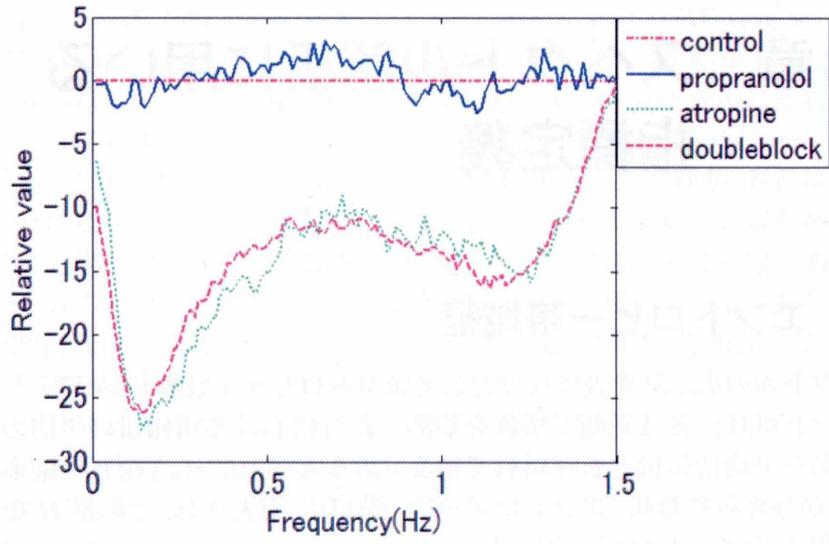


図 2.5: 相対スペクトル (supine)

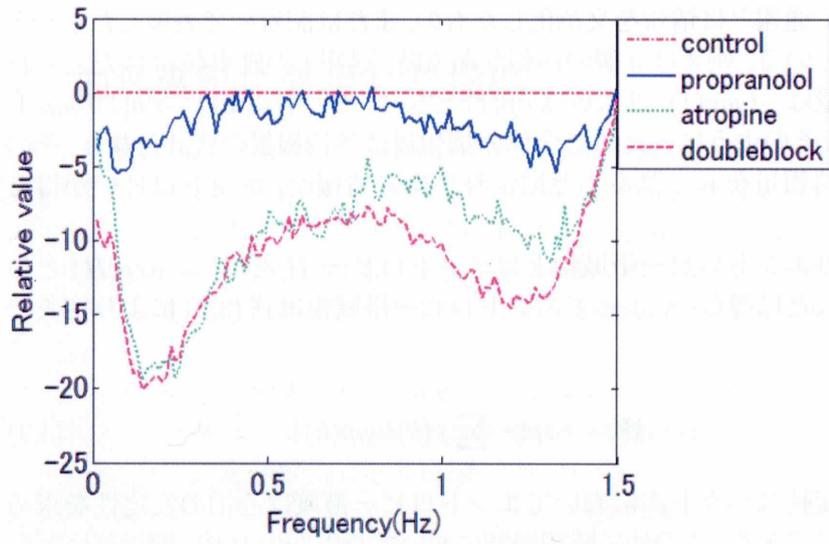


図 2.6: 相対スペクトル (upright)

第3章 スペクトル解析に用いる 指標定義

3.1 エントロピー帯域幅

スペクトルの広がりを表す尺度としてエントロピー帯域幅 W を導入した。エントロピーとは長期で情報を観測した時における情報量の平均のことであり平均情報量とも呼ばれている。ある確率分布 $p(x)$ をもつ確率変数 X が与えられた時、エントロピーは、式 (3.1) で表され、この量 H を確率変数 X のエントロピーという。

$$H(X) = -\sum p(x)\log p(x) \quad (3.1)$$

すなわち等確率分布に近い程、エントロピーは高い値を表す。この式は通報から考えられる情報量から容易に求めることができる。

ここで通報とは情報を文章化したもの、または記号列で表現したものと定義している。例えば n 個の通報がある時、通報1の確率が $p(1)$ だとすれば情報量は $-\log p(1)$ 、通報数は $np(1)$ となり、その情報量は $-np(1)\log p(1)$ となる。そのように考えると全体の情報量は各情報量の合計となり、その全体の情報量を n で割ることにより平均の情報量、エントロピーが得られる。

つまりエントロピー帯域幅とはエントロピー H を $W = \exp(H)$ として表すことに等しい。よってエントロピー帯域幅は式 (3.2) により定義できる。

$$W = \exp\left(-\sum_k p(k)\log p(k)\right) \quad (3.2)$$

心拍変動スペクトルにおいてエントロピー帯域は心拍の安定性を求めることができる。この他に時間領域において新生児の HRV 解析等にエントロピーが指標として用いられている研究もある。

3.2 活動推定指標

周波数領域における心拍変動スペクトル解析における指標は従来、1981年 Akserlodらによって導入された LF , HF , LF/HF の指標が主なものとして知られている。心拍変動スペクトルにおいて、 0.15Hz を境にそれより低周波を LF (Low Frequency), それより高周波を HF (High Frequency) と呼んでいる。 LF は交感神経と副交感神経、主に交感神経が、 HF は副交感神経に依存していることが分かっている。スペクトルにおいて HF が上昇していると副交感神経が有意に働く、つまりリラックスしている状態であることが分かり、 LF が上昇していると交感神経が有意に働く、つまり緊張している状態であることが分かる。しかし LF は副交感神経にも依存しており、 LF だけでは満足な交感神経の指標とは言いがたいため、 LF/HF を用いて交感神経の指標としている。よって LF は簡易の交感神経指標、 HF は副交感神経指標、 LF/HF は正確な交感神経指標とされている。

これに先のエントロピー帯域幅を適用したスペクトルのパターン判別による指標が2005年高本らによって提案された。[3] 本稿では LF , HF , LF/HF 指標から LF 部分を 0.15Hz 以下、 HF 部分を 0.15Hz 以上、全体部分を LF 部分と HF 部分の合計分の3つを対象としてエントロピー帯域幅の指標とした。 LF 部分、 HF 部分、全体部分のエントロピー帯域幅はそれぞれ WLF , WHF , W と表すこととする。

3.3 血圧変動に着目した指標

2章でも触れたが *control* と *propranolol* の心拍変動のスペクトルの形は似通っており、分類が難しい。だが図2.1と図2.2を見比べると *upright* 限定ではあるが、低周波領域で *control* にあって *propranolol* にはないパワー値の伸び(図3.1)が見られる。つまり交感神経の働きによって生じる変化ということになるため、血圧の変動によって影響された成分であると推測できる。

血圧と心拍は密接な関係にあり、運動等で血液をたくさん必要とする場合は自動的に心拍数が上がって心拍出量を増やし、睡眠時など血液が少なくてもいい場合は心拍数が下がるようになっている。このような心臓の変化は特に交感神経によって管理されている。また血管の収縮や拡張も管理しており、交感神経が緊張すると心拍出量が増加し、抹消血管は縮小することで血圧を上げる。逆に交感神経が弛緩すると心拍出量が減少し、血圧は下がるようになる。

このように交感神経は血圧の調整に深く関わっているため、この突出した変動成分も血圧変動による可能性が高いと思われる。今回はこの領域を目視で $0.04\text{Hz} \sim 0.11\text{Hz}$ と決め、血圧変動が反映された変動成分 *MWSA* (*Mayer Wave related Sinus Arrhythmia*) から活動推定指標 *MF* とした。またこれにエントロピー帯域幅を適用した指標を *WMF* と表すこととする。

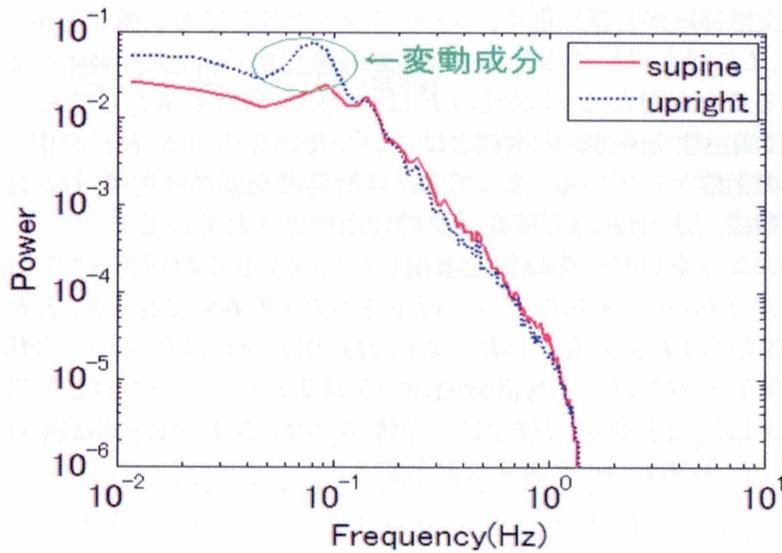


図 3.1: control における血圧変動が反映された変動成分

第4章 ニューラルネットワーク

4.1 ニューラルネットワークの構成

指標評価をするにあたり従来では検定による比較から状態分類を行う方法がある。だが検定法では各状態同士の分類を一度に行う事はできない。そのためそれらを一度に分類するための方法としてニューラルネットワークという概念を導入した。

ニューラルネットワークは生物の神経系の特徴的な機能に着目してそのモデル化を行ったものである。生物の神経系は多数のニューロン (*neuron*) が複雑に結合され、それぞれが並列処理を行っている。各ニューロンの大まかな構造は入力端子である樹状突起 (*dendrite*)、出力端子である軸索 (*axon*)、ならびに本体の細胞体 (*soma*) から成り立っている。各ニューロンの端子はシナプス (*synapse*) を通しニューロン同士で電気信号のやり取りを行っている。シナプス結合の3種類のうち興奮性シナプスと呼ばれるものは、入力信号が加えられることによって細胞体内の電位の電位が上昇し、あるしきい値を超えるとニューロンが発火し軸索を通じてパルスが伝わり他のニューロンに刺激を及ぼす。

このようなニューロンの動作原理に基づき1943年、*McCulloch - Pitts* によってニューロンモデルが式 (4.1) で提案された。

$$y_i(m+1) = F\left[\sum_j w_{ij}y_j(m) - \theta_i\right] \quad (4.1)$$

ここでそれぞれ y_j はニューロン j からの信号、 w_{ij} はニューロン j からニューロン i への結合強度、いわゆる重み、 θ_i はニューロン i のしきい値、そして $F[X]$ は X が0以上に達すれば1、達しなければ0となる階段関数を表している。このモデル式は各ニューロンから伝わった電気信号の入力総和が一定のしきい値に達するとニューロンが興奮することを指す。この構図を図で表すと図4.1のようになる。

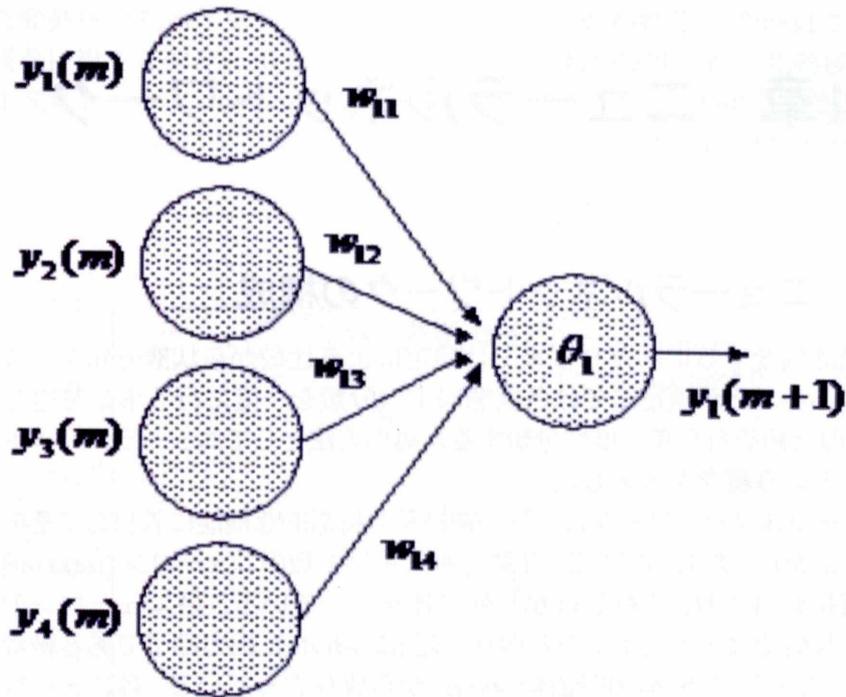


図 4.1: ニューロンモデル

$F[X]$ は過去には階段関数が用いられていたが最近では式(4.2)で表されるようなシグモイド関数が利用されることが多い。

$$F(x) = \frac{1}{1 + \exp(-x)} \quad (4.2)$$

ニューラルネットワークはこの人口ニューロンをいくつか結合することで作ることができる。入力ユニットから出力ユニットまで全て順方向のみに結合されている階層構造ニューラルネットワークモデル (*fully connected neural network model*), 図 4.2 の形が一般的に広く使われている。値のやり取りを実際に行っている中間層の数は任意で決めることができる。このモデルを用いて状態分類を行うには重み w_{ij} を適切な値に設定する必要がある。

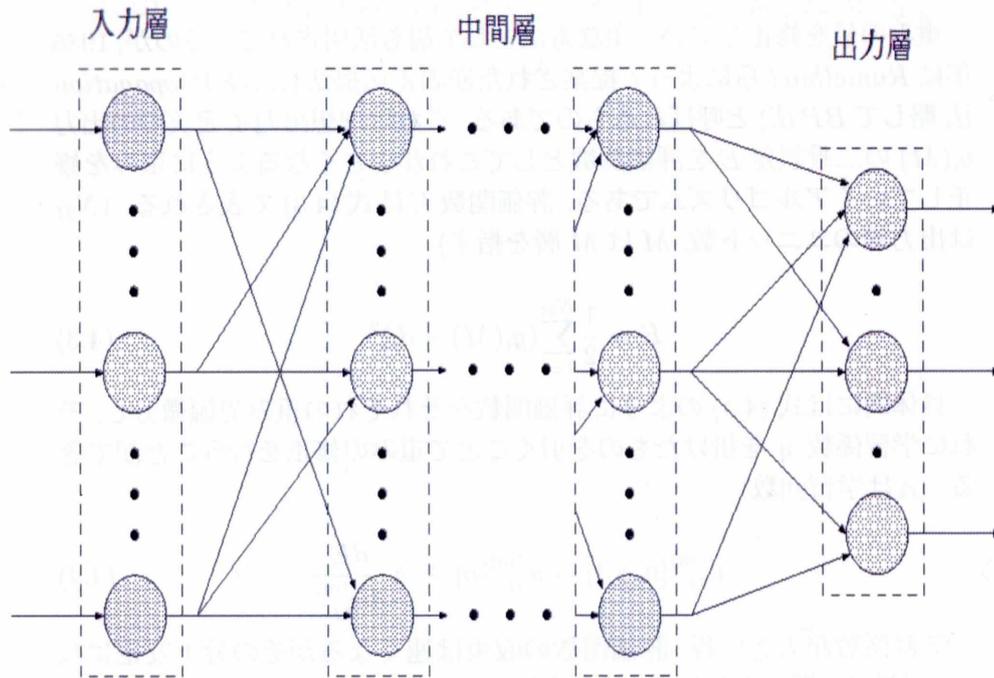


図 4.2: 階層型ネットワーク

4.2 学習と評価

ニューラルネットワークは学習によって知能を獲得し、正しい出力を出すことができる。ここでいう学習とは理想とする出力値を用意し、実際に出力される値と比較することでその差をできるだけ小さくするように重みの値を修正することで行うことができる。こういった学習方法を教師あり学習 (*supervised learning*) と呼ぶ。またこれとは別に評価基準をあらかじめ内蔵しておく教師なし学習 (*unsupervised learning*) のような学習方法もある。

この時、学習教材となる入力理想とする出力を出すに当たって適切なものであれば実際の出力との差はより小さくなるようにできている。よって各状態ごとの分類に適切な入力指標を探すことができるため、指標評価には適している。

4.3 逆誤差伝播法

重みの値を修正していく主な方法として最も活用されているのが、1986年に Rumelhart らによって提案された逆誤差伝播法 (*Back Propagation* 法 略して *BP* 法) と呼ばれるものである。これは理想出力 d_i と実際の出力 $y_i(M)$ の二乗誤差 E を評価関数としてこれが小さくなるように重みを修正していくアルゴリズムである。評価関数 E は式 (4.3) で表される。(N_M は出力層のユニット数, M は M 層を指す)

$$E = \frac{1}{2} \sum_{i=1}^{N_M} (y_i(M) - d_i)^2 \quad (4.3)$$

具体的には式 (4.4) のように評価関数をそれぞれの重みで偏微分し、それに学習係数 η を掛けたものを引くことで重みの修正を行うことができる。(n は学習回数)

$$w_{ij}^{(m)}[n+1] = w_{ij}^{(m)}[n] - \eta \frac{dE}{dw_{ij}^{(m)}} \quad (4.4)$$

学習係数が大きい程、評価関数の収束は速くなるがその分不安定になる。偏微分 $\frac{dE}{dw_{ij}^{(m)}}$ は出力層から入力層へと上から求めていくアルゴリズムになっている。出力層の偏微分は式 (4.5) から式 (4.7)、中間層の偏微分は指揮 (4.8) から式 (4.10) にて求められる。[4]

$$\frac{dE}{dy_i^{(M)}} = y_i^{(M)} - d_i \quad (4.5)$$

$$\frac{dE}{dx_i^{(M)}} = \frac{dE}{dy_i^{(M)}} y_i^{(M)} (1 - y_i^{(M)}) \quad (4.6)$$

$$\frac{dE}{dw_{ij}^{(M)}} = \frac{dE}{dx_i^{(M)}} y_j^{(M-1)} \quad (4.7)$$

$$\frac{dE}{dy_j^{(m)}} = \sum_{i=1}^{N_{m+1}} w_{ij}^{(m+1)} \frac{dE}{dx_i^{(m+1)}} \quad (4.8)$$

$$\frac{dE}{dx_j^{(m)}} = \frac{dE}{dy_j^{(m)}} y_j^{(m)} (1 - y_j^{(m)}) \quad (4.9)$$

$$\frac{dE}{dw_{jk}^{(m)}} = \frac{dE}{dx_j^{(m)}} y_k^{(m-1)} \quad (4.10)$$

それぞれ添字に用いている i, j, k はそれぞれ出力層 (M 層), $M-1$ 層, $M-2$ 層のユニットを代表するものと考えerことで結合の把握が容易になる.

第5章 解析結果

5.1 解析内容

階層型ニューラルネットワークを用いて入力層に指標データを導出することで各指標の評価を行う。本稿では入力、中間、出力の3層からなるネットワークを用いて *supine*, *upright* ごとに *control*, *propranolol*, *atropine*, *doubleblock* の4状態の分類を行うことを目標とする。セオリーとしては学習に収集したデータの多くを用い、出力が理想出力に近づくようBP法を使用する。その後、残りのデータと修正した重みから出力を出し、正しく状態分類が出来てるかどうかで評価を行う。

出力数は各状態に対応するため4つとする。理想出力は理想とする状態に対応するものを1, それ以外を0とし、実際にニューラルネットワークを回した結果, 4つの中で最も1に近い値を出力した場所の状態を分類した状態とみなすこととする。一度の入力に用いる指標は, 各指標の効果を見るため毎回違う指標をいろんな組み合わせで使用することとする。中間数は従来より入力数の1倍よりは多く2倍未満とされているため, 入力数より2つ程多く設定することとする。学習回数は2万回程行い, 学習係数は0.4とした。

5.2 従来指標による結果

まずは従来の指標である LF , HF , LF/HF に加え, スペクトルの散らばり具合を見るため分散を入力指標とした。入力数が4つになるため中間数は6つとした。学習には収集したデータのうち被験者1番から被験者10番までの3/4程を用い, 評価には残りの1/4を使用した。その学習結果, 評価結果を体位ごとに表5.1~表5.4に示す。これ以降も同様だが各表は列が入力時の状態, 行が出力時の状態を表している。

表 5.1: supine における学習結果

入力: 分散, LF, HF, LF/HF				
学習3/4	con(su)	pro(su)	atr(su)	dou(su)
con(su)	100%	0.0%	0.0%	0.0%
pro(su)	100%	0.0%	0.0%	0.0%
atr(su)	0.0%	0.0%	50.0%	50.0%
dou(su)	11.1%	0.0%	22.2%	66.7%

表 5.2: supine における評価結果

入力: 分散, LF, HF, LF/HF				
学習3/4	con(su)	pro(su)	atr(su)	dou(su)
con(su)	100%	0.0%	0.0%	0.0%
pro(su)	100%	0.0%	0.0%	0.0%
atr(su)	0.0%	0.0%	0.0%	100%
dou(su)	0.0%	0.0%	25.0%	75.0%

表 5.3: upright における学習結果

入力: 分散, LF, HF, LF/HF				
学習3/4	con(up)	pro(up)	atr(up)	dou(up)
con(up)	84.2%	10.5%	0.0%	5.3%
pro(up)	25.0%	50.0%	0.0%	25.0%
atr(up)	0.0%	0.0%	14.3%	85.7%
dou(up)	0.0%	5.3%	10.5%	84.2%

表 5.4: upright における評価結果

入力: 分散, LF, HF, LF/HF				
学習3/4	con(up)	pro(up)	atr(up)	dou(up)
con(up)	100%	0.0%	0.0%	0.0%
pro(up)	60.0%	0.0%	0.0%	40.0%
atr(up)	0.0%	0.0%	0.0%	100%
dou(up)	0.0%	0.0%	0.0%	100%

評価結果を見ると *control* や *doubleblock* が分類できているが *propranolol* や *atropine* が全く分類できていない結果となった。学習結果でも決して満足のいく分類は出来ていないがそれと比べても非常に分類率が悪い。

2章で触れたが解析データは *control* や *doubleblock* に比べ、*propranolol* や *atropine* は実データの絶対数が少ない。よって学習量に差が生じていると思い、今度は4状態の学習データ量を調節して各々の結果を出してみた。そこで学習データには被験者1番から9番と11番、評価データには被験者10番と12番から14番を使用した。わざわざ10番を評価側に回したのは *atropine* が *propranolol* より更に実データが少ないため学習量を調節するためである。その際の結果を表5.5～表5.8に示す。

表 5.5: supine における学習結果

入力: 分散, LF, HF, LF/HF				
学習3/4	con(su)	pro(su)	atr(su)	dou(su)
con(su)	100%	0.0%	0.0%	0.0%
pro(su)	71.4%	28.6%	0.0%	0.0%
atr(su)	0.0%	0.0%	100%	0.0%
dou(su)	22.2%	0.0%	55.6%	22.2%

表 5.6: supine における評価結果

入力: 分散, LF, HF, LF/HF				
学習3/4	con(su)	pro(su)	atr(su)	dou(su)
con(su)	100%	0.0%	0.0%	0.0%
pro(su)	100%	0.0%	0.0%	0.0%
atr(su)	0.0%	0.0%	100%	0.0%
dou(su)	0.0%	37.5%	25.0%	37.5%

表 5.7: upright における学習結果

入力: 分散, LF, HF, LF/HF				
学習3/4	con(up)	pro(up)	atr(up)	dou(up)
con(up)	88.9%	11.1%	0.0%	0.0%
pro(up)	0.0%	100%	0.0%	0.0%
atr(up)	0.0%	0.0%	71.4%	28.6%
dou(up)	0.0%	22.2%	33.3%	44.4%

表 5.8: upright における評価結果

入力: 分散, LF, HF, LF/HF				
学習3/4	con(up)	pro(up)	atr(up)	dou(up)
con(up)	100%	0.0%	0.0%	0.0%
pro(up)	80.0%	20.0%	0.0%	0.0%
atr(up)	0.0%	0.0%	100%	0.0%
dou(up)	0.0%	0.0%	0.0%	100%

調節の結果, 評価結果を見るに *propranolol* の分類率は殆ど変わらなかったが, *atropine* の分類率が大きく上がった. 表 5.7 など学習結果では *propranolol* の分類率が高くても表 5.8 のように評価結果では大きく分類率が下がっているため *propranolol* を分類するには学習自体に問題があると考えられる. ともあれ *atropine* の分類はこなせるようになるため, これ以降も学習量を調節して結果を算出していくこととする.

5.3 MF または WMF を用いた結果

今回導入した *MF* と *WMF* を従来指標と様々な組み合わせで入力していく. *MF* と *WMF* は *upright* に限定した指標であるため, ここでの結果は *upright* において 4 状態分類が行えるかどうかを検討していく.

表 5.9: upright における学習結果 (入力:分散,LF,HF,MF,WMF)

入力:分散,LF,HF,MF,WMF				
学習3/4	con(up)	pro(up)	atr(up)	dou(up)
con(up)	77.8%	22.2%	0.0%	0.0%
pro(up)	25.0%	25.0%	0.0%	50.0%
atr(up)	0.0%	0.0%	14.3%	85.7%
dou(up)	0.0%	0.0%	0.0%	100%

表 5.10: upright における評価結果 (入力:分散,LF,HF,MF,WMF)

入力:分散,LF,HF,MF,WMF				
学習3/4	con(up)	pro(up)	atr(up)	dou(up)
con(up)	87.5%	12.5%	0.0%	0.0%
pro(up)	0.0%	100%	0.0%	0.0%
atr(up)	0.0%	0.0%	0.0%	100%
dou(up)	0.0%	12.5%	0.0%	87.5%

表 5.11: upright における学習結果 (入力:分散,LF,HF,LF/HF,WMF)

入力:LF,HF,LF/HF,WMF				
学習3/4	con(up)	pro(up)	atr(up)	dou(up)
con(up)	77.8%	22.2%	0.0%	0.0%
pro(up)	25.0%	62.5%	0.0%	12.5%
atr(up)	0.0%	0.0%	71.4%	28.6%
dou(up)	0.0%	11.1%	33.3%	55.6%

表 5.12: upright における評価結果 (入力:分散,LF,HF,LF/HF,WMF)

入力:LF,HF,LF/HF,WMF				
学習3/4	con(up)	pro(up)	atr(up)	dou(up)
con(up)	87.5%	12.5%	0.0%	0.0%
pro(up)	20.0%	80.0%	0.0%	0.0%
atr(up)	0.0%	0.0%	100%	0.0%
dou(up)	12.5%	25.0%	0.0%	62.5%

表 5.13: upright における学習結果 (入力:分散,WLF,WHF,WMF)

入力:分散,WLF,WHF,WMF				
学習3/4	con(up)	pro(up)	atr(up)	dou(up)
con(up)	77.8%	22.2%	0.0%	0.0%
pro(up)	25.0%	50.0%	0.0%	25.0%
atr(up)	14.3%	0.0%	42.9%	42.9%
dou(up)	0.0%	0.0%	22.2%	77.8%

表 5.14: upright における評価結果 (入力:分散,WLF,WHF,WMF)

入力: 分散,WLF,WHF,WMF				
学習3/4	con(up)	pro(up)	atr(up)	dou(up)
con(up)	87.5%	12.5%	0.0%	0.0%
pro(up)	0.0%	100%	0.0%	0.0%
atr(up)	0.0%	50.0%	0.0%	50.0%
dou(up)	0.0%	37.5%	12.5%	50.0%

表 5.15: upright における学習結果 (入力:分散,LF,HF,LF/HF,MF,WMF)

入力: 分散,LF,HF,LF/HF,MF,WMF				
学習3/4	con(up)	pro(up)	atr(up)	dou(up)
con(up)	77.8%	22.2%	0.0%	0.0%
pro(up)	0.0%	87.5%	0.0%	12.5%
atr(up)	0.0%	0.0%	71.4%	28.6%
dou(up)	0.0%	0.0%	22.2%	77.8%

表 5.16: upright における評価結果 (入力:分散,LF,HF,LF/HF,MF,WMF)

入力: 分散,LF,HF,LF/HF,MF,WMF				
学習3/4	con(up)	pro(up)	atr(up)	dou(up)
con(up)	100%	0.0%	0.0%	0.0%
pro(up)	20.0%	80.0%	0.0%	0.0%
atr(up)	0.0%	0.0%	0.0%	100%
dou(up)	12.5%	12.5%	0.0%	75.0%

表 5.17: upright における学習結果 (入力:LF,HF,LF/HF,MF)

入力:LF,HF,LF/HF,MF				
学習3/4	con(up)	pro(up)	atr(up)	dou(up)
con(up)	88.9%	11.1%	0.0%	0.0%
pro(up)	25.0%	50.0%	0.0%	25.0%
atr(up)	0.0%	14.3%	71.4%	14.3%
dou(up)	0.0%	22.2%	11.1%	66.7%

表 5.18: upright における評価結果 (入力:LF,HF,LF/HF,MF)

入力:LF,HF,LF/HF,MF				
学習3/4	con(up)	pro(up)	atr(up)	dou(up)
con(up)	100%	0.0%	0.0%	0.0%
pro(up)	80.0%	20.0%	0.0%	0.0%
atr(up)	0.0%	0.0%	100%	0.0%
dou(up)	12.5%	0.0%	12.5%	75.0%

表 5.19: upright における学習結果 (入力:分散,LF,HF,LF/HF,WMF)

入力:分散,LF,HF,LF/HF,WMF				
学習3/4	con(up)	pro(up)	atr(up)	dou(up)
con(up)	88.9%	11.1%	0.0%	0.0%
pro(up)	0.0%	87.5%	0.0%	12.5%
atr(up)	0.0%	0.0%	71.4%	28.6%
dou(up)	0.0%	0.0%	22.2%	77.8%

表 5.20: upright における評価結果 (入力:分散,LF,HF,LF/HF,WMF)

入力:分散,LF,HF,LF/HF,WMF				
学習3/4	con(up)	pro(up)	atr(up)	dou(up)
con(up)	100%	0.0%	0.0%	0.0%
pro(up)	20.0%	80.0%	0.0%	0.0%
atr(up)	0.0%	0.0%	50.0%	50.0%
dou(up)	12.5%	25.0%	0.0%	62.5%

表 5.21: upright における学習結果 (入力:LF,HF,WMF)

入力:LF,HF,WMF				
学習3/4	con(up)	pro(up)	atr(up)	dou(up)
con(up)	77.8%	22.2%	0.0%	0.0%
pro(up)	37.5%	37.5%	0.0%	25.0%
atr(up)	0.0%	0.0%	42.9%	57.1%
dou(up)	0.0%	0.0%	22.2%	77.8%

表 5.22: upright における評価結果 (入力:LF,HF,WMF)

入力:LF,HF,WMF				
学習3/4	con(up)	pro(up)	atr(up)	dou(up)
con(up)	87.5%	12.5%	0.0%	0.0%
pro(up)	60.0%	40.0%	0.0%	0.0%
atr(up)	0.0%	0.0%	0.0%	100%
dou(up)	0.0%	0.0%	12.5%	87.5%

表 5.23: upright における学習結果 (入力:HF,LF/HF,WMF)

入力:HF,LF/HF,WMF				
学習3/4	con(up)	pro(up)	atr(up)	dou(up)
con(up)	77.8%	22.2%	0.0%	0.0%
pro(up)	0.0%	87.5%	0.0%	12.5%
atr(up)	0.0%	0.0%	71.4%	28.6%
dou(up)	0.0%	0.0%	33.3%	66.7%

表 5.24: upright における評価結果 (入力:HF,LF/HF,WMF)

入力:HF,LF/HF,WMF				
学習3/4	con(up)	pro(up)	atr(up)	dou(up)
con(up)	62.5%	37.5%	0.0%	0.0%
pro(up)	0.0%	80.0%	0.0%	20.0%
atr(up)	0.0%	0.0%	100%	0.0%
dou(up)	12.5%	12.5%	0.0%	75.0%

表 5.25: upright における学習結果 (入力:分散,HF,LF/HF,WMF)

入力:分散,HF,LF/HF,WMF				
学習3/4	con(up)	pro(up)	atr(up)	dou(up)
con(up)	77.8%	22.2%	0.0%	0.0%
pro(up)	0.0%	87.5%	0.0%	12.5%
atr(up)	0.0%	0.0%	71.4%	28.6%
dou(up)	0.0%	0.0%	33.3%	66.7%

表 5.26: upright における評価結果 (入力:分散,HF,LF/HF,WMF)

入力:分散,HF,LF/HF,WMF				
学習3/4	con(up)	pro(up)	atr(up)	dou(up)
con(up)	87.5%	12.5%	0.0%	0.0%
pro(up)	0.0%	100%	0.0%	0.0%
atr(up)	0.0%	0.0%	100%	0.0%
dou(up)	0.0%	25.0%	0.0%	75.0%

5.4 相対スペクトルを用いた結果

図 2.5, 図 2.6 で示した相対スペクトルにおいて各指標を算出, 今まで同様ニューラルネットワークを用いて学習, 評価を行い相対スペクトルにおける有効指標を探し出す。

表 5.27: 相対スペクトル (supine) における学習結果 (入力:分散,LF,HF,LF/HF)

入力:分散,LF,HF,LF/HF				相対
学習3/4	con(su)	pro(su)	atr(su)	dou(su)
con(su)	100%	0.0%	0.0%	0.0%
pro(su)	57.1%	42.9%	0.0%	0.0%
atr(su)	0.0%	0.0%	100%	0.0%
dou(su)	11.1%	0.0%	88.9%	0.0%

表 5.28: 相対スペクトル (supine) における評価結果 (入力:分散,LF,HF,LF/HF)

入力:分散,LF,HF,LF/HF				相対
学習3/4	con(su)	pro(su)	atr(su)	dou(su)
con(su)	100%	0.0%	0.0%	0.0%
pro(su)	66.7%	0.0%	33.3%	0.0%
atr(su)	50.0%	0.0%	50.0%	50.0%
dou(su)	0.0%	0.0%	100%	0.0%

表 5.29: 相対スペクトル (upright) における学習結果 (入力:分散,LF,HF,LF/HF)

入力:分散,LF,HF,LF/HF				相対
学習3/4	con(up)	pro(up)	atr(up)	dou(up)
con(up)	100%	0.0%	0.0%	0.0%
pro(up)	25.0%	50.0%	0.0%	25.0%
atr(up)	0.0%	0.0%	28.6%	71.4%
dou(up)	0.0%	11.1%	11.1%	77.8%

表 5.30: 相対スペクトル (upright) における評価結果 (入力:分散,LF,HF,LF/HF)

入力:分散,LF,HF,LF/HF				相対
学習3/4	con(up)	pro(up)	atr(up)	dou(up)
con(up)	100%	0.0%	0.0%	0.0%
pro(up)	20.0%	60.0%	0.0%	20.0%
atr(up)	0.0%	0.0%	0.0%	100%
dou(up)	0.0%	0.0%	0.0%	100%

表 5.31: 相対スペクトル (upright) における学習結果 (入力:分散, HF, LF/HF, WMF)

入力: 分散, HF, LF/HF, WMF				相対
学習3/4	con(up)	pro(up)	atr(up)	dou(up)
con(up)	100%	0.0%	0.0%	0.0%
pro(up)	37.5%	50.0%	0.0%	12.5%
atr(up)	0.0%	14.3%	14.3%	71.4%
dou(up)	11.1%	11.1%	22.2%	55.6%

表 5.32: 相対スペクトル (upright) における評価結果 (入力:分散, HF, LF/HF, WMF)

入力: 分散, HF, LF/HF, WMF				相対
学習3/4	con(up)	pro(up)	atr(up)	dou(up)
con(up)	100%	0.0%	0.0%	0.0%
pro(up)	40.0%	40.0%	0.0%	20.0%
atr(up)	0.0%	50.0%	0.0%	50.0%
dou(up)	12.5%	12.5%	0.0%	75.0%

表 5.33: 相対スペクトル (upright) における学習結果 (入力:分散, LF, HF, LF/HF, WMF)

入力: 分散, LF, HF, LF/HF, WMF				相対
学習3/4	con(up)	pro(up)	atr(up)	dou(up)
con(up)	100%	0.0%	0.0%	0.0%
pro(up)	25.0%	50.0%	12.5%	12.5%
atr(up)	0.0%	14.3%	28.6%	57.1%
dou(up)	0.0%	11.1%	0.0%	88.9%

表 5.34: 相対スペクトル (upright) における評価結果 (入力:分散,LF,HF,LF/HF,WMF)

入力: 分散,LF,HF,LF/HF,WMF				相対
学習3/4	con(up)	pro(up)	atr(up)	dou(up)
con(up)	100%	0.0%	0.0%	0.0%
pro(up)	40.0%	60.0%	0.0%	0.0%
atr(up)	0.0%	50.0%	0.0%	50.0%
dou(up)	0.0%	0.0%	0.0%	100%

表 5.35: 相対スペクトル (supine) における学習結果 (入力:分散,W,WLF,WHF)

入力: 分散,W,WLF,WHF				相対
学習3/4	con(su)	pro(su)	atr(su)	dou(su)
con(su)	100%	0.0%	0.0%	0.0%
pro(su)	28.6%	71.4%	0.0%	0.0%
atr(su)	0.0%	0.0%	100%	0.0%
dou(su)	0.0%	11.1%	44.4%	44.4%

表 5.36: 相対スペクトル (supine) における評価結果 (入力:分散,W,WLF,WHF)

入力: 分散,W,WLF,WHF				相対
学習3/4	con(su)	pro(su)	atr(su)	dou(su)
con(su)	100%	0.0%	0.0%	0.0%
pro(su)	33.3%	66.7%	0.0%	0.0%
atr(su)	0.0%	0.0%	50.0%	50.0%
dou(su)	0.0%	0.0%	25.0%	75.0%

表 5.37: 相対スペクトル (upright) における学習結果 (入力:分散,W,WLF,WHF)

入力:分散,W,WLF,WHF				相対
学習3/4	con(up)	pro(up)	atr(up)	dou(up)
con(up)	100%	0.0%	0.0%	0.0%
pro(up)	12.5%	87.5%	0.0%	0.0%
atr(up)	0.0%	0.0%	57.1%	42.9%
dou(up)	0.0%	11.1%	22.2%	66.7%

表 5.38: 相対スペクトル (upright) における評価結果 (入力:分散,W,WLF,WHF)

入力:分散,W,WLF,WHF				相対
学習3/4	con(up)	pro(up)	atr(up)	dou(up)
con(up)	100%	0.0%	0.0%	0.0%
pro(up)	20.0%	80.0%	0.0%	0.0%
atr(up)	0.0%	0.0%	100%	0.0%
dou(up)	12.5%	0.0%	12.5%	75.0%

表 5.39: 相対スペクトル (supine) における学習結果 (入力:分散,LF,HF,WLF,WHF)

入力:分散,LF,HF,WLF,WHF				相対
学習3/4	con(su)	pro(su)	atr(su)	dou(su)
con(su)	100%	0.0%	0.0%	0.0%
pro(su)	42.9%	57.1%	0.0%	0.0%
atr(su)	10.0%	0.0%	80.0%	10.0%
dou(su)	0.0%	0.0%	55.6%	44.4%

表 5.40: 相対スペクトル (supine) における評価結果 (入力:分散,LF,HF,WLF,WHF)

入力:分散,LF,HF,WLF,WHF				相対
学習3/4	con(su)	pro(su)	atr(su)	dou(su)
con(su)	100%	0.0%	0.0%	0.0%
pro(su)	33.3%	50.0%	0.0%	16.7%
atr(su)	0.0%	0.0%	100%	0.0%
dou(su)	0.0%	0.0%	75.0%	25.0%

表 5.41: 相対スペクトル (upright) における学習結果 (入力:分散,LF,HF,WLF,WHF)

入力:分散,LF,HF,WLF,WHF				相対
学習3/4	con(up)	pro(up)	atr(up)	dou(up)
con(up)	100%	0.0%	0.0%	0.0%
pro(up)	37.5%	62.5%	0.0%	0.0%
atr(up)	0.0%	0.0%	57.1%	42.9%
dou(up)	0.0%	0.0%	0.0%	100%

表 5.42: 相対スペクトル (upright) における評価結果 (入力:分散,LF,HF,WLF,WHF)

入力:分散,LF,HF,WLF,WHF				相対
学習3/4	con(up)	pro(up)	atr(up)	dou(up)
con(up)	100%	0.0%	0.0%	0.0%
pro(up)	20.0%	80.0%	0.0%	0.0%
atr(up)	0.0%	0.0%	50.0%	50.0%
dou(up)	0.0%	0.0%	0.0%	100%

表 5.43: 相対スペクトル (supine) における学習結果 (入力:分散,WLF,WHF,WLF/HF)

入力:分散,WLF,WHF,WLF/HF				相対
学習3/4	con(su)	pro(su)	atr(su)	dou(su)
con(su)	100%	0.0%	0.0%	0.0%
pro(su)	28.6%	71.4%	0.0%	0.0%
atr(su)	0.0%	0.0%	70.0%	30.0%
dou(su)	0.0%	11.1%	22.2%	66.7%

表 5.44: 相対スペクトル (supine) における評価結果 (入力:分散,WLF,WHF,WLF/HF)

入力:分散,WLF,WHF,WLF/HF				相対
学習3/4	con(su)	pro(su)	atr(su)	dou(su)
con(su)	100%	0.0%	0.0%	0.0%
pro(su)	50.0%	50.0%	0.0%	0.0%
atr(su)	0.0%	0.0%	100%	0.0%
dou(su)	0.0%	0.0%	0.0%	100%

表 5.45: 相対スペクトル (upright) における学習結果 (入力:分散,WLF,WHF,WLF/HF)

入力: 分散,WLF,WHF,WLF/HF				相対
学習3/4	con(up)	pro(up)	atr(up)	dou(up)
con(up)	100%	0.0%	0.0%	0.0%
pro(up)	37.5%	62.5%	0.0%	0.0%
atr(up)	0.0%	0.0%	42.9%	57.1%
dou(up)	0.0%	11.1%	11.1%	77.8%

表 5.46: 相対スペクトル (upright) における評価結果 (入力:分散,WLF,WHF,WLF/HF)

入力: 分散,WLF,WHF,WLF/HF				相対
学習3/4	con(up)	pro(up)	atr(up)	dou(up)
con(up)	100%	0.0%	0.0%	0.0%
pro(up)	20.0%	60.0%	0.0%	20.0%
atr(up)	0.0%	0.0%	0.0%	100%
dou(up)	0.0%	25.0%	0.0%	75.0%

表 5.47: 相対スペクトル (supine) における学習結果 (入力:分散,HF,W,WHF)

入力: 分散,HF,W,WHF				相対
学習3/4	con(su)	pro(su)	atr(su)	dou(su)
con(su)	100%	0.0%	0.0%	0.0%
pro(su)	28.6%	71.4%	0.0%	0.0%
atr(su)	0.0%	0.0%	100%	0.0%
dou(su)	0.0%	0.0%	44.4%	55.6%

表 5.48: 相対スペクトル (supine) における評価結果 (入力:分散, HF, W, WHF)

入力: 分散, HF, W, WHF				相対
学習3/4	con(su)	pro(su)	atr(su)	dou(su)
con(su)	100%	0.0%	0.0%	0.0%
pro(su)	33.3%	66.7%	0.0%	0.0%
atr(su)	0.0%	0.0%	100%	0.0%
dou(su)	0.0%	0.0%	25.0%	75.0%

表 5.49: 相対スペクトル (upright) における学習結果 (入力:分散, HF, W, WHF)

入力: 分散, HF, W, WHF				相対
学習3/4	con(up)	pro(up)	atr(up)	dou(up)
con(up)	100%	0.0%	0.0%	0.0%
pro(up)	25.0%	75.0%	0.0%	0.0%
atr(up)	0.0%	0.0%	71.4%	28.6%
dou(up)	0.0%	0.0%	0.0%	100%

表 5.50: 相対スペクトル (upright) における評価結果 (入力:分散, HF, W, WHF)

入力: 分散, HF, W, WHF				相対
学習3/4	con(up)	pro(up)	atr(up)	dou(up)
con(up)	100%	0.0%	0.0%	0.0%
pro(up)	20.0%	80.0%	0.0%	0.0%
atr(up)	0.0%	0.0%	0.0%	100%
dou(up)	0.0%	0.0%	0.0%	100%

第6章 考察

6.1 今回の解析の問題点

表 5.5 から表 5.8 を参照するに従来の指標 LF , HF , LF/HF だけでは *propranolol* の分類は困難であることが分かる。そこで MF や WMF を導入し従来指標と複数の組み合わせで入力していった訳だが、結果によっては学習結果の方が評価結果よりも分類率が低いものが見受けられる。例えば表 5.9 と表 5.10 などである。特に *propranolol* において学習では 25 % であるのに対し評価では 100 % という結果になっている。いふなれば練習で 25 点だったのに本番で 100 点だったという話だ。要するに学習で用いたデータは今回入力した指標の組み合わせでは不適格で評価に用いたデータの方が適格だったということなる。しかしそうなるとどの被験者を学習データにするかで結果が変わってくることになる。

またもう一つの可能性として学習データに不良データが混じっていたことも考えられる。どちらにせよ今回の結果には多少の不手際がある可能性は否めないであろう。

6.2 MF や WMF の導入による利点

表 5.10, 表 5.12, 表 5.14, 表 5.16 など MF や WMF を入力することで *propranolol* の分類率が高くなることが分かる。特に表 5.12 は表 5.8 の従来指標入力結果に WMF を追加しただけだが、表 5.8 に比べて明らかに *propranolol* の分類率が高くなっている。

しかし *propranolol* の分類率は高くなっているものの、多くの結果で *atropine* の分類率が大きく下がっているものが見られる。表 5.10, 表 5.14, 表 5.16 等がそれにあたる。つまり MF や WMF 両方、もしくはいずれかに *atropine* の分類率を下げる要因がある可能性が考えられる。そこで MF と WMF をそれぞれ単体で評価する必要が出てくる。その比較するための結果が表 5.12 と表 5.18 になる。見ての通りこの二表で入力して

指標は LF , HF , LF/HF に加え, 表 5.12 では WMF , 表 5.18 では MF となっている. その結果 MF を加えた表 5.18 では *propranolol* が 20 % しか分類できていないのに対し, WMF を加えた表 5.12 では 80 % 分類できている. *control* や *doubleblock* において多少の分類率の落ちはあるものの *propranolol* を分類するには MF より WMF の方が適していることが分かる. 更に表 5.10 や表 5.16 など MF や WMF を同時に用いると *atropine* の分類率が大幅に落ちる傾向にあるため, 特に MF を用いる利点は今回は見当たらなかった.

表 5.19 からは MF は用いず WMF のみを従来指標と組み合わせてより分類率の高いものを探している. 表 5.20 は先の表 5.16 から MF を外したもののだが *atropine* の分類率が表 5.16 より上昇した. ここでこの中から交感神経に作用する指標をもう一度考えてみる. LF , LF/HF , WMF が交感神経指標, HF が副交感神経指標である. 交感神経指標を使いすぎるのではないかと考え, 簡易の交感神経指標である LF を外してみた. その結果が表 5.26 となる. 全体で約 90 % が分類できた結果となった. これから分散を外した表 5.24 は多少精度が落ちたため, *upright* においては表 5.26 で入力した指標, 分散, HF , LF/HF , WMF の組み合わせが最も精度の高い結果となった. また WMF を *upright* 限定であるものの, 交感神経指標として定義することができた.

6.3 相対スペクトルの場合の有効指標

相対スペクトルを用いた場合の結果を参照するに心拍スペクトルの時の結果とはかなり結果が異なるものが多いことが分かる. 例えば表 5.32 は前の考察で有効な指標の組み合わせとされた分散, HF , LF/HF , WMF を用いているが表 5.26 とは異なりかなり精度の悪い結果となった. つまり相対スペクトルで自律神経活動の分類を行うならば心拍スペクトルの時とは異なる視点が必要ではないかと考えられる. 従来指標における結果, 表 5.28, 表 5.30 を見ても分かる通り, こちらの精度もあまり良いものではない.

だが表 5.36, 表 5.38 等の結果を参照すると入力情報にエントロピー帯域を用いた場合, その精度が上がっていることが確認できた. 特に *upright* では分類率が高く全体で約 90 % 近くの分類を行えている. *supine* ではそれには劣るものの 70 % 以上の分類率をとれており, *upright* より分類の難しい *supine* ではまずまずといえる. 続く表 5.40, 表 5.42 でもエントロピー帯域を用いているがそう悪くない精度を出している. だが全体精度

としては表 5.36, 表 5.38 の方が良いため LF , HF の影響というよりはエントロピー帯域の指標が有効であると考えられる。だからこそ全領域におけるエントロピー帯域を入力情報とした表 5.36, 表 5.38 の分類結果が精度の高いものになったと考えられる。

全体を参照するに *supine*, *upright* 共に精度が良いのは表 5.36, 表 5.38 で用いた指標, 分散, WLF , WHF , W の組み合わせである。だが *supine*, *upright* 単体で見れば更に精度の高いものが見られた。*supine* 単体で見ると表 5.44 において約 90 % 程分類できている。だが *upright* では大きく精度が落ちているというあまり見られない結果となった。図 2.5, 図 2.6 を見ても相対スペクトルでは *supine* よりも *upright* の方が状態ごとのスペクトル形状が捉え易いように見える。だがこの表では WLF/HF というあまり検討したことのない指標を用いているため, はっきりとした答えを出すことは出来ないだろう。それ以外にも心拍スペクトル時の指標と同様の組み合わせで逐一試してみたが特に目立った結果を出すことはなかった。結論をいえば相対スペクトルの場合は帯域指標が有効であるといえる。

おわりに

WMF や相対スペクトルの導入で *propranolol* の分類がしやすくなった。だが *upright* に比べるとまだ *supine* の分類精度は不十分であるといえる。よって更にスペクトルの形状に着目し、違いを認識しやすい領域を指標とすることが重要ではないかと思われる。また体位ごとの4状態分類をこなすことが出来るようになった後は、体位も含めた8状態分類も行っていきたい。

またBP法には大域的な最小値を見つけにくい、要するに評価関数が極小値に陥ってしまいやすいといった欠点も多い。[5] その辺りの改良を進めることでより正確な分類結果が得られれば理想的だと思う。

謝辞

本研究を進めるにあたり、様々な面で多くの方々に御協力頂きました。特に御指導、御鞭撻頂いた八名和夫教授に深く感謝の意を表したいと思えます。また本研究は、城西大学の水田博士氏をはじめ、小川浩良氏、西山澄人氏、紫竹弘之氏ならび諸先輩方に敬意を表すと共に、研究を進めるにあたり数多くの助言をして頂いた八名研究室所属の皆様に心から感謝致します。

参考文献

- [1] Solange Akselrod, David Gordon, F.AndrewUbel, Dabid C.Shannon, A.Clifford Borrger, and Richard J.Cohen. Power spectrum analysis of heart rate fluctuation: A quantitative probe of beat-to-beat cardiovascular control. Science, vol.213,pp.220-222, July 1981.
- [2] 水田博久, 八名和夫, "心拍ゆらぎの1/fスペクトル推定," BME, vol.8, No.10, pp.13-16, 1994.
- [3] 高本淳, 小川浩良, 水田博久, 八名和夫, "エントロピーを用いた心拍スペクトルのパターン判別," 電子情報通信学会研究報告, vol.105, No.456, pp.33-36, Dec.2005
- [4] 八名和夫, 鈴木義武著, "ニューロ情報処理技術," pp.42-48, 1992
- [5] 馬場則夫著, "ニューラルネットの基礎と応用," pp.4-19, 1994