

寄贈	平成
島田 尊正 氏	年
	月
	日

DA

1547

1995

(HG)

ニューラルネットワークによる睡眠脳波特徴量の抽出とその医療応用

Extraction of Characteristics of Sleep EEG by Using Neural Networks and its Application to Clinical Medicine

1996年3月

島田 尊正

# 目次

第1章 序論	1
1.1 本研究の背景	1
1.2 本研究の目的	2
第2章 脳波診断の概要	6
2.1 脳波とは	6
2.2 脳波の計測	6
2.3 脳波形成の種類	13
2.3.1 正常脳波	17
2.3.2 睡眠脳波及び睡眠深度	19
2.4 脳波の診断方法	24
第3章 ニューラルネットワーク	28
3.1 ニューロン	28
3.2 バックプロパゲーション	31
3.3 多層ニューラルネットワーク	35
3.4 本研究で論ずる主なニューラルネットワークの構成	42
3.4.1 ACNN (all connecting neural network)	44
3.4.2 TDNN (time delay neural network)	44
3.4.3 SRNN (sleep stage recognition neural network)	49
第4章 脳波特徴波の検出	54
4.1 脳波特徴波検出に適したニューラルネットワークの条件	54
4.2 特徴波検出のための構成	54

4.2.1	SRNN による方法	56
4.2.2	TDNN による方法	61
4.2.3	ACNN による方法	63
4.3	テンプレートマッチング的手法	65
4.4	特徴波検出結果	65
4.4.1	解析データ	66
4.4.2	検出結果	66
4.5	考察	73
4.5.1	シフトインバリエント	73
4.5.2	孤立性の認識	78
4.5.3	特徴波持続時間の影響	87
4.5.4	まとめ	89
第5章 睡眠段階判定		90
5.1	医療応用としての睡眠段階判定	90
5.2	特徴波検出に基づく睡眠段階判定システム	90
5.2.1	特徴波検出部 (SRNN)	95
5.2.2	眠段階判定部 (SSNN)	100
5.3	平均パワースペクトルのみによる方法	104
5.4	睡眠段階判定結果	106
5.4.1	解析データ	106
5.4.2	本システムの場合	106
5.4.3	平均パワースペクトルによる結果	109
5.5	考察	113
5.6	まとめ	113
第6章 文脈的睡眠段階判定		115

6.1	文脈的睡眠段階判定の意義	115
6.2	文脈的睡眠段階判定システム	116
6.2.1	前段部 (SRNN+SSNN)	118
6.2.2	文脈的判定部 (CDNN)	118
6.3	目視による閾値設定による文脈的判定	122
6.4	文脈的判定結果	122
6.4.1	SRNNによる特徴波検出	122
6.4.2	SSNNによる睡眠段階判定	122
6.4.3	CDNNによる文脈的判定	123
6.5	考察	125
6.6	まとめ	130
第7章 結論		131
7.1	本研究のまとめ	131
7.2	今後の課題	133
謝辞		135
参考文献		137

# 第1章 序論

## 1.1 本研究の背景

人の脳波を最初に記録したのはドイツ・イエナ大学の Has Berger であり、1929年に論文が出された。当時彼は記録器として弦電流計を使用している。脳波は数  $10 \mu V$  という小さな電圧変動のため、本物かどうかということで、当時、この論文は重視されなかった。1943年イギリスのノーベル賞受賞者のケンブリッジ大学教授 Adian が追試論文を発表し、Berger の脳波研究が脚光を浴びた。人の脳機能の記録表示の良い方法が当時あまりなかったため、脳生理学に関係ある各方面の研究者が一齐に脳波の研究をはじめた。

一方、電子工学の急速な発達で、脳波記録は容易になり、真空管による増幅器、ペン記録器の開発で、1940年に入ってから間もなく臨床用脳波計が作られた。

脳波の基礎研究、臨床医学への応用も、Kornmüller, Schwab, Davis, Lennox, Jasper, Gibbs 夫妻, Walter, Gastaut, Brazier ら枚挙に暇がないほど多数の研究者によって優れた業績が紹介された。

わが国では1937年（昭12）に東北大学生理学教室で工学部の援助を得て最初に脳波が記録された。それに引き続き東大、北大へと研究の輪が広がっていったが、第2次世界大戦によって海外の情報から隔離され、わが国独自の研究開発が進んだ。戦後、世界への窓が開かれた時に、欧米では既に脳波は臨床検査の領域に入っておりその進歩に目を見張らざる得なかった。戦後わが国の脳波研究、臨床応用、脳波計の普及は非常に進んだ。1947年（昭22）に第1回の国際会議がロンドンで開かれ、1952年に日本脳波学会が結成されて、第1回大会が東京で開かれた。

現在わが国は世界有数の脳波国であり、脳波学会は筋電図学会と合併して日本脳波・筋

電図学会となり4年ごとの国際学会の出席者も極めて多い。

また電子工学の発展により脳波計はトランジスタ化され、小型軽量となり非常に安定したものができ、広く世界市場を持つようになった。また国内の普及は世界で最も高いと言われている。しかし、臨床検査としての脳波の正しい評価については必ずしも満足すべき状態には至っていない。

脳波の臨床への寄与という面から見て、目による判読は既に限界に達しており、言い換えれば、脳波についてその発生のメカニズムから臨床病理学的解釈に至るまでの中で未解決のまま残されている部分が多い。

一方、臨床への応用の限界の問題もある。したがって脳波に対する正しい評価と認識のもとに、それを十分に利用することが望ましい。

現在、脳波の数量的表示、分析表示などによって、視覚判読からさらに脳波の価値を拡大しようとする研究が進められている。

## 1.2 本研究の目的

睡眠状態の判定は、精神科での診断上極めて重要であり、睡眠脳波パターンを解析することにより行える。

脳波は、脳の活動状況をマクロに反映したものであり、様々な脳の疾患や精神状態に関する多くの情報を含んでいる。そのため、診断の手掛かりとして臨床に用いられている。また脳波は覚醒や睡眠状態の違いによっても変化し、それを客観的に把握するための重要な指標となる。このため、睡眠時の脳波を用いて、睡眠深度を段階づける試みは、1930年代に脳波が発見された当初からなされている。現在では、RechtschaffenとKalesらによりまとめられた6段階の分類<sup>(16)</sup>（Stage W（覚醒）、Stage 1（まどろみ）、Stage 2（浅い睡眠）、Stage 3（中程度睡眠）、Stage 4（深い睡眠）、Stage REM（レム睡眠））が基礎になっているが、さらにStage 1やStage 2を前半と後半に分けるより細かな分類法も用いられている<sup>(18) (19)</sup>。これらは、 $\alpha$ 波、睡眠紡錘波（spindle）、瘤波（hump）、徐波などの特徴波の出現や消失の状態を観察し、さらに眼球運動や筋電図を参考にして判

定するものである。

脳波診断の専門医は診断に際し、記録用紙のほぼ1ページ分の20秒間を1単位とし、1回の睡眠脳波の計測では、千ページにも及ぶ膨大なデータを視察により判読する。このように睡眠脳波の視察は、医師に多大な労力を強いることになる。さらに脳波波形は個人差が大きく、同一人でも微妙に変化するため、その認識には専門医としての熟練を必要とする。また、視察による波形認識に基づくため、診断基準が主観的、非定量的になりやすいという問題もある。一般に睡眠段階判定結果の医師間での一致率は約80%といわれている。このため、脳波診断における医師の労力の軽減、さらに診断の客観化や定量化を目的として、脳波診断の支援システムの開発が試みられている。

睡眠段階の自動判定の研究も、これまでも幾つかなされている。これらは、時間波形から直接特徴を抽出する方法<sup>(20)</sup>と、パワースペクトルの形状から特徴を得る方法<sup>(22)</sup><sup>(23)</sup><sup>(24)</sup><sup>(25)</sup>に大きく分けられる。大量のデータを効率よく処理するためには、波形の細かい違いに捕らわれずに、ある程度の情報の圧縮ができるパワースペクトルを用いる方法が適しているといえる。しかし、後者の方法の多くは比較的長い時間にわたる平均的なスペクトルを手掛かりとするものである。このため、持続性のある $\alpha$ 波などは適切に検出できても、humpのような、持続時間の短い突発的な特徴波を正確に抽出することは困難である。その結果、大まかな睡眠深度の判定しかできなかった。

また、一方で文献(25)のように短区間(2秒間)のスペクトルのみを用いた手法では、一定時間内でのスペクトルの時間推移が考慮されていない。そのため特定の脳波特徴波が持つ孤立性といった特徴をとらえて判定することはできない。

また、これらの方法では患者によって特徴波の周波数成分が変化し、事前に設定された検出周波数帯域がずれると、検出誤りが増大する。

一方、近年、ニューラルネットワークを用いた研究が様々な分野において行われており、その特性から数式的なモデル化が容易でないシステムの同定に適していると言われている<sup>(26)</sup><sup>(27)</sup><sup>(29)</sup>。

本論文において短区間スペクトルの時間推移パターンを、新たに提案したニューラルネットワーク SRNN (Sleep EEG Recognition Neural Network) により識別させることで、hump から  $\alpha$  波、徐波 (slow wave) まで、持続時間にかかわらず特徴波を検出できる

方法を提案する<sup>(2)(4)(5)(7)(8)</sup>。

特に文献(2)においては、最も一般的な全結合型の階層型ニューラルネットワーク（以下 ACNN（All Connecting Neural Network）と呼ぶ）<sup>(31)</sup>、Waibelらによって提案された音素認識用のニューラルネットワーク TDNN（Time Delay Neural Network）<sup>(33)</sup>、及びテンプレートマッチング手法の一つである、波形の線形予測係数に対する尤度比を用いた手法<sup>(22)</sup>との比較を行った。そして特に孤立性波形 hump に関する検出で、その優位性を示した。

本論文では、さらにこの手法を拡張し、ニューラルネットワークを用いて睡眠深度を判定するシステムについて述べ、睡眠脳波の処理によりその有効性を示している。本システムは、医師が睡眠段階を判定する過程に習い、特徴波の検出と状態分類という二つのプロセスからなる。前段は、睡眠脳波から特徴波検出を行う処理で、SRNNにより行われる。また、後段は前段の処理結果を受け SSNN（Sleep Stage Diagnosis Neural Network）と呼ぶニューラルネットワークにより、睡眠深度を判定する部分である。このような2つのプロセスは、実際の医師の用いる診断方法に従うもので、より正確な睡眠段階判定が可能となった。

しかしながら特徴波を考慮する睡眠段階判定の場合、その区間でたまたま特徴波が出現してなかった場合や、振幅が低く捕らえにくい場合などに正確な判定ができないといった問題点が残されていた。実際に、医師はこのような問題を解決する手法として、前後の段階からの流れによって矛盾のない判定を行っていることが知られている（文脈的判定）。

これまでいくつかの研究ではこの文脈的判定の規則を人為的に作成して行うことを試み、睡眠段階判定がより医師の判定に近いものになることが示されている<sup>(22)</sup>。しかしこの方法では規則作成という新たな作業が必要となる。また1つの規則のみでは医師間による文脈的判定方法の違いに対処できないといった問題がある。

本論文では特徴波のみによる睡眠段階の判定に対してさらに、文脈的判定用のニューラルネットワークを用いることにより、睡眠段階の持つ時間的な前後関係の規則の自動作成と、さらに医師間の文脈的規則の違いに対処可能である文脈的判定法を考察し、それについて実験・検討を行った。その結果正答率が向上し、これまで他の方法を用いたいくつかの研究でも示されていたように文脈的判定の有効性が示されると同時に、適切な長さの文



脈の考慮が重要であること、またニューラルネットワークを用いることによる汎化性や他の手法で要求される規則作成を省略できることによる労力の低減の効果なども示された。

本論文の第2章では睡眠診断の概要を、第3章で各種ニューラルネットワークの構造を示し、第4章では実際に脳波特徴波検出について述べる。さらに第5章では、第4章の特徴波検出の結果に基づいた睡眠段階判定法について示す。第6章では文脈的判定手法とその結果得られた各種知見について述べる。最後に第7章でまとめと今後の課題について示す。

## 第 2 章 脳波診断の概要

### 2.1 脳波とは

脳波とは脳の活動が頭皮上の電位変化として読み取れるものである。脳波の発生源は脳の皮質表層でのシナプス網で発生する電位（post-synaptic potential）によるものだと考えられている。振幅は～数十 $\mu$  V、周波数は～約 45Hz の信号である（実際の脳波を構成する波形については 2.3 において示す）。

大脳皮質では、神経細胞が 6 層をなして、グリア細胞の中に埋まっており、そのニューロン（神経細胞）は複雑なシナプス結合をしている。

皮質の中の電位変動の発生源としては

- ・ニューロンの軸索、樹状突起の活動電位
- ・細胞体の活動電位
- ・シナプスの電位
- ・シナプス後電位（興奮性：EPSP, 抑制性：IPSP）

脳波表層でシナプス網で発生する EPSP, IPSP が脳波の本体をなしているらしい。これは、視床からのコントロールでリズムを形成する。

### 2.2 脳波の計測

脳波計測には頭皮に電極を設置し、電位変化を脳波計で増幅して、記録する。

電極には皿電極、針電極、耳朶電極等がある。針は、痛みや感染の恐れがあるため、患者によっては使用しない。

電極配置には多くの方法があり、図 2-1 (a), (b) に 10/20 電極配置法を示す。これは電極の位置が頭皮上の特定距離の 10% と 20% の間隔になるように決められている。

基準点は、鼻根と頭蓋後頭部の中心点（後頭部隆起）である。電極の装着には電極と皮膚間には電極ペーストを塗り、接触インピーダンスが  $10k \Omega$  以下になるようにする。

脳波記録には単極（bipolar）導出（図 2-2）と双極（unipolar）導出（図 2-3）があり単極導出では基準電極部位に対して活性電極部位の脳波を捕らえる。

活性電極とは、脳波を記録するために頭皮上の目的とする部位につけた電極のことである。

一方双極導出は頭皮上の 2 箇所活性電極部位での脳波の電位差を記録する。

また、単極導出の場合の脳波測定装置の全体の構成を図 2-4 に示す。

脳波をコンピュータによる解析に使うときには、デジタル信号として記録を行うが、この時のサンプリング周波数は、一般の脳波計測では 200Hz 程度が用いられることが多い。この場合最大で 100Hz（ナイキスト周波数）までの信号が読みとれることになる。この周波数で、実際の脳波の周波数～45Hz 程度、さらに高周波である筋電なども読みとることができる。また、別の用途で ABR（短潜時聴覚誘発反応）や VER（視覚誘発反応）、AER（聴覚誘発反応）、SER（体性感覚誘発反応）などの誘発反応をとらえるときは、数 ms 単位での潜時の計測が求められるため、500Hz 程度のサンプリング周波数が用いられる。




图 2-1 (a) 国际基准 10 / 20 电极配置法




图 2-1 (b) 国际基准 10 / 20 电极配置法

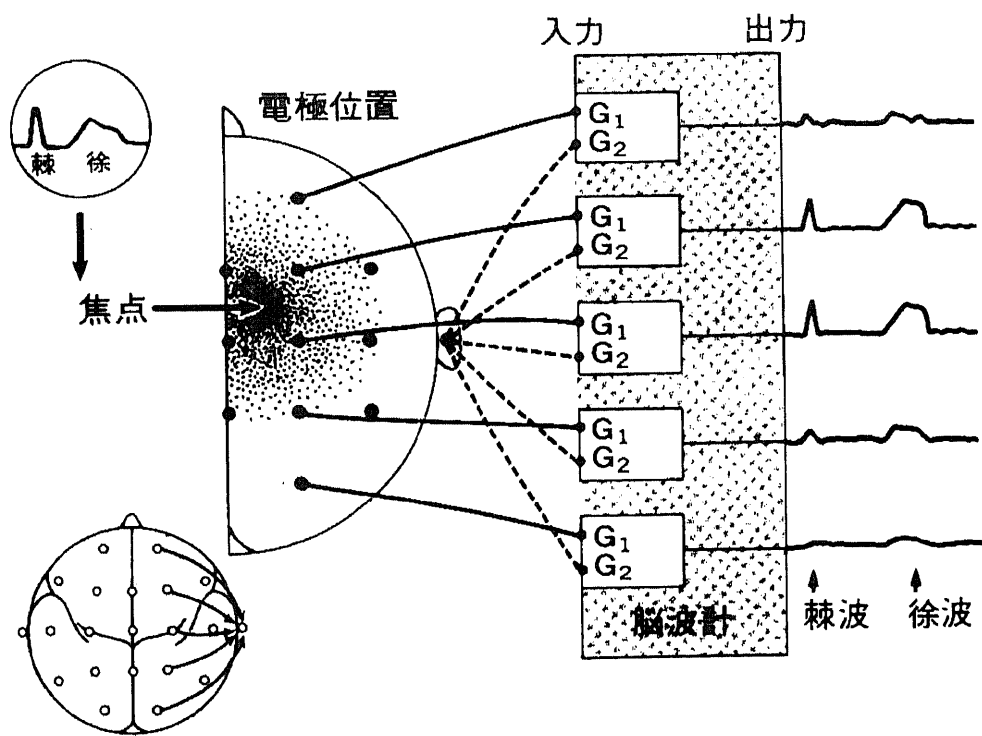


图 2-2 单極法




图 2-3 双極法




図 2-4 脳波測定装置の全体の構成（単極導出）



## 2.3 脳波形成の種類<sup>(13) (14) (15) (16) (17)</sup>

脳波の種類はその周波数により分類され、正常な波のタイプはギリシャ文字で命名されている（図 2-5）。

一般に振幅と周波数は逆の関係にある。このことは脳の活動が高まるとたくさんの神経細胞群が同期的に放電するよりもむしろ非同期的に活動するためと考えられる。

### (1) $\alpha$ 波 (alpha wave)

8 から 13Hz の間の周波数で平均振幅は  $50 \mu V$  である。この波は閉眼で覚醒安静状態の時、後頭葉に優位に見られる。開眼すると消失し、より高周波低振幅の波にとって代わる ( $\alpha$  波ブロッキング) (図 2-6)。この波は個人により差異があり、正常者の 10% は典型的な  $\alpha$  活動が記録されない。

### (2) $\beta$ 波 (beta wave)

13 から 30Hz の波で頭頂及び前頭葉に見られる。

### (3) $\gamma$ 波 (gamma wave)

30Hz 以上の波。

### (4) $\theta$ 波 (theta wave)

4 から 8Hz で成人の軽睡眠時や、子供にみられる。

### (5) $\delta$ 波 (delta wave)

4Hz 以下の波で成人の深睡眠時と未熟児と幼児に見られる。

また、 $\beta$  波と  $\gamma$  波を合わせて速波、 $\delta$  波と  $\theta$  波を合わせて徐波という呼び方もある。

この他にも棘波 (きょくは)、鋭波がある。背景となる波から急しゅんに抜き出た波で、幅が 80msec より小さいものを棘波 (spike)、大きいものを鋭波 (sharp wave) といい、振幅は様々で、棘波は異常波で、鋭波は正常と異常の場合がある (図 2-7)。




図 2-5 周波数の分類と帯域




図 2-6  $\alpha$  波のブロッキング




図 2-7 棘波と鋭波

### 2.3.1 正常脳波

ここでいう正常脳波とは、正常成人の覚醒、安静、閉眼状態の脳波を言う。正常脳波は10Hz前後の $\alpha$ 波が主体となり、小さな $\beta$ 波の混入があり、後頭（ $O_1, O_2$ ）、頭頂（ $P_3, P_4$ ）部で $\alpha$ 波が律動的で振幅も大きく（後頭優位）、前頭（ $FP_1, FP_2, F_3, F_4$ ）、中心（ $C_3, C_4$ ）、前側頭（ $F_7, F_8$ ）では後頭（ $O_1, O_2$ ）に比して振幅が低く、 $\beta$ 波が多い。また、左右の対称部位から記録した脳波の波形は、振幅、周期が大体同じで、同期している。しかし、これらの脳波波形には個人差がある（図2-8）。




図 2-8 成人・覚醒・安静・閉眼時の脳波（A, B, C, D の 4 人の被験者の脳波の例）

## 2.3.2 睡眠脳波及び睡眠深度

睡眠脳波は睡眠深度と関係があり、睡眠深度に応じて特徴的な波が出る（図 2-9）。

瘤波（hump）は高振幅鋭波で、中心、頭頂部付近で最大振幅を示し、両半球同期性に出現する。新生児には出現しないが、生後数か月で出現し、幼児期では振幅も大きく頻発する。学童期から成人に至るにつれて振幅を減らし、老人では出現しにくくなる。瘤波を頭頂鋭波（vertex sharp wave）ともいう。

紡錘波（spindle）は、14Hz を中心とし 11 から 15Hz の波で、出現部位は中心、頭頂部付近に著名で、両半球同期性に出現する。生後間もなくから出現し、14Hz より周波数の少ないこともしばしばある。この波は老年に至るまで出現し、睡眠脳波の良き指標となっている。この紡錘波を  $\sigma$  律動とも言う。

K 複合波は、瘤波の後に紡錘波が続くものを言い、全誘導に出現するが、中心-前頭部で振幅最大、両側同期性である。音などの外界からの刺激によって出やすいが、自発性にも現れる。また、K 複合に引き続いて覚醒することがある。

睡眠深度は、現在では APSS（association for the psychophysiological study of sleep）分類によるものが一般的である。

### （1）覚醒段階：stage w

$\alpha$  波と、低振幅で他の睡眠段階よりも周波数が速い種々の周波数が混じったパターンを示す。普通かなりの高振幅の持続性筋電図を伴い、急速眼球運動（REMs）や瞬目もしばしば出現。

### （2）入眠期と軽眠初期：stage1

この時期は眠気を覚えてうとうとした状態に当たる。脳波は振幅の低い 2～7Hz の徐波を中心とし、種々の周波数の混じったものとなる。覚醒からの移行では、次第に  $\alpha$  波の割合が減っていき、連続度が次第に悪くなり、最後に消失し、stage1 の脳波パターンへと変わる。 $\alpha$  波が記録の 50% 以下となったところで stage1 とする。これと同時に前頭部、中心部、頭頂部などに振幅の小さい  $\theta$  波や、20Hz 前後の低振幅速波が現れる。この段階は比

較的短く、1～7分程度である。この段階の後半では瘤波（hump）が出現する。

### （3）軽眠期：stage2

14Hzの紡錘波（spindle）、K複合波（K-complex）が出現する。しかしstage3や4で見られる高振幅徐波は存在しない。K複合波は、まず瘤波に続いて紡錘波が1～数秒間連続して現れる。後に睡眠が深くなると、瘤波が消失して紡錘波のみが安定して存在するようになる。紡錘波がこの睡眠段階の特徴であるため、紡錘波期とも呼ばれる。眠りがさらに深くなると、主に前頭部に10～12Hzの遅い紡錘波も出現する。これは左右の半球で独立に現れることも多い。背景には低振幅の $\theta$ 波、 $\delta$ 波などを含む不規則な脳波が見られる。

### （4）中度睡眠期：stage3

大きな徐波（2Hz以下で頂点間振幅が75 $\mu$ V以上）が出現し始める（20～50%）。紡錘波は混じっているが、頻度は少ない。この時期は10Hz前後の遅い紡錘波が多く、比較的脳の広い範囲にわたって左右同期的に出現することが多い。感覚刺激を与えても、よほど強い刺激でなければこれを知覚することはできない。

### （5）深眠期：stage4

大きな徐波（2Hz以下で頂点間振幅が75 $\mu$ V以上）が不規則に連続する（50%以上）。紡錘波は出現するときとしないときがある。睡眠段階は一晚で数回の周期を繰り返すが、このstage4は第1回の睡眠周期においてもっとも著明に出現する。

### （6）stage REM

stage4又はstage3に続いて、速い水平眼球運動（rapid eye movement）を伴うstage1に似た脳波を示す時期である。身体的特徴として姿勢を保つ抗重力筋の緊張が著しく低下し、頤（おとがい）筋の筋電図はほとんど平坦になる。また同時に各種の自律神経の変動が見られ、男子では陰茎、女子では陰核の勃起が見られる。REM段階はNREM（non-REM：REM段階以外の急速眼球運動のない睡眠段階）が現れた後に初めて現れ、以後約90分周期で比較的規則正しく出現し、一晚に約4～5回見られる。この時期に起こすと約80%



の人が夢を見ていると報告する。

以上のような睡眠深度は約 90 分の周期を持っており、終夜睡眠中に図 2-10 のように何度か繰り返す。


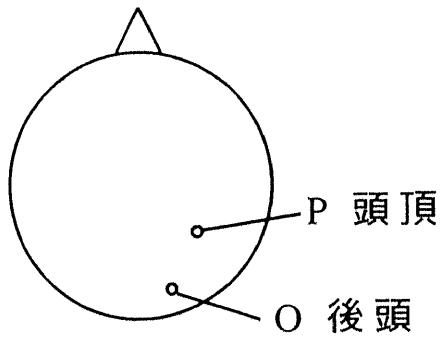
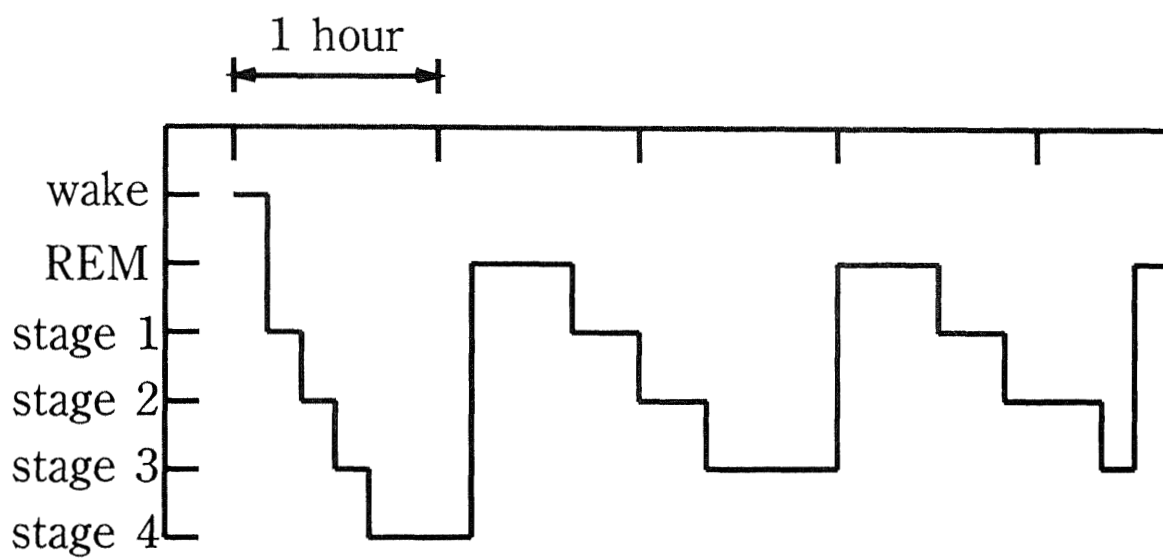


図 2-9 睡眠ステージと波形



The transition of sleep stage

図 2-10 終夜睡眠の流れ

## 2.4 脳波の診断方法<sup>(13) (14) (15) (16) (17)</sup>

現在脳波の解読は熟練した医師が行う。

脳波データは、例えば 16 導出のアナログ値を半時間程度かかって記録するのが普通である。

診断価値のある情報はどの導出でもほんの 1 秒程度のわずかな時間に現れるため、脳波の診断は時間浪費が多く、より容易な測定のためのデータ短縮の自動的方法を開発する努力がされてきた。

実験データの分析は、他の領域での応用ならば、その基礎にある物理的過程の知識に基づいてなされるが、脳波の場合、その基礎の部分が大部分未知であるため、不可能である。したがって、自動分析では、経験的な判読法をシミュレートするという試みがなされてきた。各導出について、短い時間内の周波数と振幅を分析し、また、これらのパラメータや位相を、異なる導出相互で比較するというやり方である。

脳波信号は、不規則な様式のものであり、統計学用語で記述される。ここで 2 種類の波形が問題となる。1 つは、観察された信号が統計的に規則性があるという特徴を持っていれば（例えば  $\alpha$  波や  $\beta$  波）、その信号は定常の確立分布と見なされる。第 2 のタイプとして、単発のパルスや複合的な群発波（例えば棘徐波）のように、特殊な過渡波が観察される。これらの過程を分析するための様々な技法が開発されてきた。

- [ 1 ] 脳波分析器と言われる帯域フィルタを使った周波数分析装置で基礎律動の定量化、客観化を行う。
- [ 2 ] 脳波誘発電位を平均加算専用計算機で検出する。
- [ 3 ] 専用計算機・汎用計算機を使って相関関数、パワースペクトル、高次モーメント、コヒーレンス関数等を計算して、脳波の統計的特徴を抽出する。
- [ 4 ] スクリーニングその他の目的の簡単な診断補助装置。
- [ 5 ] スクリーン上の質問に押しボタンで応答すると判定結果が出る半自動波形解読器。
- [ 6 ] パターン認識と医師の診断理論に基づく脳波自動解読。

人工パターンの読み取りは各方面で実用が進んでいるが、自然パターンは処理・認識アルゴリズムが完全に規定しにくく、誤解を避けるためにはますます大型計算機が要求され、実用化が難しくなる。脳波の判読もその困難さにおいて最たるものの1つで、波形自動判読は現状では研究段階である。

ここでこれまでに論文等で紹介されているいくつかの脳波の自動判定の手法について示す。

まず文献(21)で紹介されている堀田らの方法は、健康成人男子2例の終夜睡眠脳波の1ページ(20秒)ごとのスペクトルのパターン0~16Hzのデータを直接、ニューラルネットワークに入力し、睡眠段階と対応させて学習させることにより、睡眠段階を判定させる手法である。ニューラルネットワークの構成は入力層17ユニット、中間層5ユニット、判定結果出力層5ユニットの3層構造であり、パソコン上で構成されている。この実験の結果、学習データと判定データが同一被験者の場合約90%の正答率、異なる被験者の場合、学習事象の少ない睡眠段階を除いて約75%の正答率であった。ただしこの実験では医師が実際に睡眠段階判定を行う際に重要な指標としている特徴波を全く扱っていない点や、実際に扱った脳波データ長が分からない点、又、学習データと判定データで異なる被験者の場合、少ない事象の部分を除いて正答率が75%という点が研究の内容としては曖昧である。

次に文献(23)Jose C. Principeらの研究では、SAMICOSと呼ばれる睡眠段階解析のためのマイクロコンピュータ用のシステムを作っている。表2-1にこの手法で用いた周波数解析のためのFIRフィルタの式を示す。このシステムでは上記のシステムと異なり、睡眠特徴波を扱っているが、あくまでスペクトルのみに着目したもので、波形の孤立性といった時系列上での変化に関しては扱っていない。また、脳波特徴波の被験者間の違いなどについても扱っていないため、一人の被験者で設定したパラメータでは他の被験者へ適応できず、そのため再びシステムを作り替えるなどの手間が要求される。

次に文献(25)のNicolas Schaltenbrandらの方法では、睡眠脳波(EEG)、眼球運動(EOG)、筋電図(EMG)をニューラルネットワークに入力することで睡眠段階判定を行っているもので、1つの判定区間は128Hzサンプリングで2secとなっている。これからFFTによってパワースペクトルを求め、パワースペクトルのパターンを考慮して17種

類の特徴波を抽出する。これを1ページ30秒でまとめて、特徴波の検出データとする。次にこの特徴波のデータをニューラルネットワークに提示する。ニューラルネットワークの方式は、階層型の3層のネットワークである。学習はバックプロパゲーションによって行われる。各層の構成は、入力が17個のパワースペクトルの係数。隠れ1層目は10ユニットである。出力層は6ユニットで構成される。このニューラルネットワークの構造を図2-11に示す。このネットワークにより6段階の睡眠段階（wake, stage1, REM, stage2, stage3, stage4）に分類される。このシステムでは2secという短い時間での特徴波の検出を行っているが、やはり孤立性といった時系列上での変化に関しては扱っていない点や、脳波特徴波の被験者間の違いを扱っていないといった問題がある。

表 2-1 FIR EEG フィルタ

EEG waves	Passbands -3dB(Hz)	Implementation
$\Delta$	dc-3	$H_1(z)=(z^{-3}+1)(z^{-2}+1)(z^{-1}+1)(z^{-2}+z^{-1}+1)$
$\theta$	dc-9	$H(z)=H_1(z)$
$\alpha$	5-15	$H_2(z)=(z^{-6}-1)(z^{-2}+1)(z^{-2}+1.75z^{-1}+1)(z^{-2}-1)$
$\sigma$	8-25	$H(z)=H_2(z)$
$\beta$	11-40	$H(z)=H_2(z)$
LP	dc-7	$H_3(z)=(z^{-6}+1)(z^{-4}+1)(z^{-1}+1)$
EOG	dc-9	$H(z)=H_1(z)$

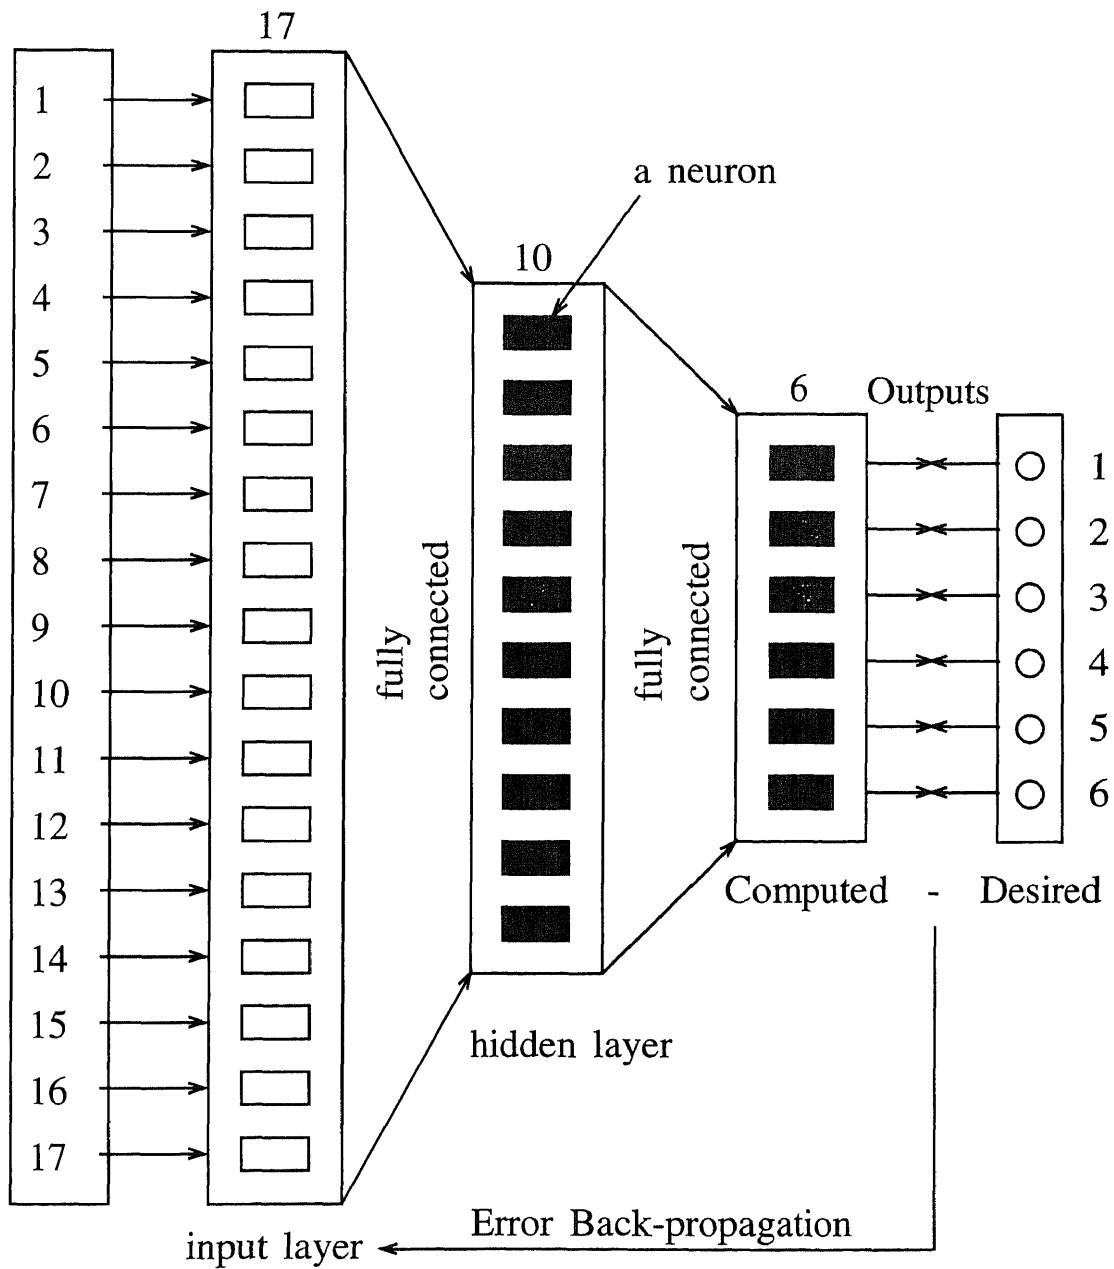


図 2-11 Nicolas Schaltenbrand らの睡眠段階判定用ニューラルネットワーク

## 第3章 ニューラルネットワーク

### 3.1 ニューロン <sup>(26)</sup> <sup>(27)</sup> <sup>(28)</sup> <sup>(29)</sup>

ニューラルネットワークの最小単位は、人間など生物の脳にある神経細胞を模した、ニューロンである（図 3-1）。

このニューロンの原理について簡単に示す。まずこの最小単位であるところのニューロン（仮に  $j$  とする）に、前段のニューロン  $i$  より  $y_i$  という信号が入力として入ってくる。

するとこのニューロンはその前段のニューロン  $i$  との結びつきを決める係数をこの入力  $y_i$  にかける。これを結合係数（又は結合荷重）  $w_{ji}$  という。

この入力には実際には今注目しているニューロン  $j$  にあらゆる方向のニューロンから入ってくると考えられるため、結局実際の入力はこれらのトータルとなる。

$$u = \sum_i y_i \times w_{ji} \quad (1)$$

ここで得られた入力値に対して、ニューロン内において、ある関数で変換されたものが、このニューロンの出力となる。これが次のニューロンへの入力として渡されるわけである。

ここでニューロン内における関数としてシグモイド関数がある。

$$f(u) = 1 / (1 + \exp(-u)) \quad (2)$$

バックプロパゲーション方式のニューラルネットワークにおいては、この出力と正しい出力（教師信号）との差を求め、それを  $w_{ji}$  の大きさの割合に応じて、 $w_{ji}$  を修正するとい




う方法をとる（デルタルール）。シグモイド関数の代わりにステップ関数を用いているのがパーセプトロンである。

ニューラルネットワークでの特徴の識別は、一つのニューロンで考えた場合、入力の数だけ次元のある空間を、それより次元の一つ少ない超平面により分割していることにより行われていると考えられる。なぜなら、出力は入力の総和の大小で決まるからである。以下の式はまさに平面の式である。

$$x_1+x_2+x_3+x_4+\dots+x_n=C \quad (3)$$

ここで $x$ は各次元の入力値を表し、 $C$ は定数を表す。

ただし、バックプロパゲーションの場合、この超平面はしっかりした板状（hard-limiting）のものではなく、その実体はシグモイド関数的に変化するものである。つまり超平面の両極で、値はシグモイド関数の出力である  $[0,1]$  の間で変化する。この値がまさにニューロンの出力  $[0,1]$  に対応する。



$$u = \sum_{i \neq j} y_i \times w_{ji}$$

$$f(u) = \frac{1}{1 + \exp(-u)}$$

図 3-1 ニューロン

## 3.2 バックプロパゲーション<sup>(26)(27)(28)(29)(30)(31)</sup>

バックプロパゲーション (back-propagation) は 1986 年ラメルハートとヒントンによって提案された、フィードバックのない層状回路で、与えられた入出力関係を満たすように神経回路を組織化させる 1 つの方法である (Rumelhart-Hinton, 1986)。入力層と出力層の間には細胞層は幾つあっても良い。出力細胞において実際の出力が教師入力を与える正解と食い違ったとき、いわゆる最急降下法に基づき、各層間の結合係数を修正すると、最終的に与えられた入出力関係を満たす神経回路網になるというものである。その修正の過程で、誤差を信号の流れと逆方向に伝搬させることから逆伝搬 (back-propagation) と呼ばれる。パーセプトロンで言うならば、連合層の最終層の特徴検出細胞が必要なものに育ってくることを意味し、パーセプトロンの最大の欠点を解消するものであるから画期的なものである。ただし、対象の性質を理解しないであらゆる問題にそのまま適用してもうまく動作するわけではない。

セイノフスキーとローゼンバーグ (C. R. Rosenberg) は英語のテキストを読むことをバックプロパゲーションによって神経回路網に学習させた (Sejnowski-Rosenberg, 1986)<sup>(35)</sup> (図 3-2)。NETtalk と名付けられたこのシステムでは、入力層に 203 個の細胞を置き、アルファベットの時系列を巧妙に空間パターンに変換して入力する。隠れユニット (hidden unit) と称する中間層の細胞を 80 個、出力細胞を 26 個持ち、出力細胞に発音記号を与えて学習させる。出力は発音記号の列となるから音声合成機に入れれば、機械が英文を読み上げることになる。この結果は魅力的で、バックプロパゲーションの名声を大いに高めることとなった。

次に実際のバックプロパゲーションの学習法について述べる。初めにパーセプトロンにおいて、ニューロンの出力値は

$$u_j = \sum_i w_{ji} y_i \quad (4)$$

となる。ここで  $j$  は着目する素子、他の素子  $i$  の出力を  $y_i$ 、結合荷重  $w_{ji}$  を掛けて加えた入力の総和を  $u_j$  とする。

出力は  $y_i$  は入力の総和に単調増加関数  $f$  を施したものである。

$$y_i = f(u_j) \tag{5}$$

ただし閾値は結合荷重の 1 つとして含まれているとする。

ここで、関数  $f$  がステップ関数

$$f(u) = 1(u) = \begin{cases} 0 & (u \leq 0) \\ 1 & (u > 0) \end{cases} \tag{6}$$

であれば、素子はパーセプトロンで用いたマッカローピッツ型の素子となる。ここでは関数  $f$  をシグモイド関数

$$f(u) = \frac{1}{1+e^{-u}} \tag{7}$$

とする。この関数はグラフで表すと図 3-3 のようになる。

次に、パターンの認識問題を、パーセプトロンは入力を  $0, 1$  のベクトルに対応させることであったが、以下ではパターン認識に限らず、一般に、1 つ 1 つの入力ベクトルに対して、何らかのスカラ値を（入力素子が複数であるならベクトルを）対応させる写像を神経回路に学習させることを考える。そして  $\hat{y}_{j,c}$  をある入力ベクトル（パターン）  $c$  に対して出力素子  $j$  が出すべき望ましい出力、 $y_{j,c}$  をその時の出力素子  $j$  の実際の出力としたとき、学習の評価として次のような誤差関数  $E$  を考える。

$$E = \frac{1}{2} \sum_{j,c} (y_{j,c} - \hat{y}_{j,c})^2 \tag{8}$$

このような形の誤差関数を最小にする手続きを一般に” 最小 2 乗誤差”（least mean square, LMS）法と言う。

各重みの値を軸としてできる空間を考え、誤差関数  $E$  によって定義される値を高さと考

えれば、Eは重み空間上の超平面として誤差曲面を与える。任意の重みの状態から、この誤差曲面の極小値に達するには

$$\Delta w_{ji} = -\varepsilon \frac{\partial E}{\partial w_{ji}} \quad (\varepsilon > 0) \quad (9)$$

ずつ変化させれば良い。

これは誤差曲面上を、最も急な傾斜方向に進んでいくことに相当し、この学習則を最急降下法 (gradient decent method) という。

ここで

$$\frac{\partial E}{\partial w_{i,c}} = \sum_c \frac{\partial E_c}{\partial w_{ji}} = \sum_c \frac{\partial E_c}{\partial y_{j,c}} \cdot \frac{dy_{j,c}}{du_{j,c}} \cdot \frac{\partial u_{j,c}}{\partial w_{ji}} \quad (10)$$

と展開され、

$$\frac{dy_j}{du_j} = f'(u_j) \quad (11)$$

$$\frac{\partial u_j}{\partial w_{ji}} = y_i \quad (12)$$

であるので、

$$\Delta w_{ji} = -\varepsilon \sum_c \frac{\partial E}{\partial y_j} f'(u_j) y_i \quad (13)$$

となる。ここで最終層のニューロン場合は

$$\frac{\partial E}{\partial y_j} = (y_j - \bar{y}_j) \quad (14)$$

ともとめられ、

$$\Delta w_{ji} = -\varepsilon \sum_c (y_j - \bar{y}_j) f'(u_j) y_i \quad (15)$$

となる。また  $f(u)$  がシグモイド関数の場合

$$f'(u) = y(1-y) \quad (16)$$

より

$$\Delta w_{ji} = -\varepsilon \sum_c (y_j - \bar{y}_j) (1 - y_j) y_i \quad (17)$$

となる。

最終層以外の場合は、 $\frac{\partial E}{\partial y_j}$  がすぐには定まらない。この微分値を出力層より逆向きに順

々に計算していき、誤差を前の層に伝えていくのがバックプロパゲーションのアイデアである。

その伝わり方を式で示すと

$$\begin{aligned} \Delta w_{ij} &= -\varepsilon \sum_c \frac{\partial E_c}{\partial y_{jc}} \cdot \frac{dy_{jc}}{du_{jc}} \cdot \frac{\partial u_{jc}}{\partial w_{ji}} \\ &= -\varepsilon \sum_c \left( \sum_k \frac{\partial E_k}{\partial y_k} \cdot \frac{dy_k}{du_k} \cdot \frac{\partial u_k}{\partial y_j} \right) \frac{dy_j}{du_j} \cdot \frac{\partial u_j}{\partial w_{ji}} \\ &= -\varepsilon \sum_c \sum_k \left( \sum_l \left( \frac{\partial E_l}{\partial y_l} \cdot \frac{dy_l}{du_l} \cdot \frac{\partial u_l}{\partial y_k} \right) \frac{dy_k}{du_k} \cdot \frac{\partial u_k}{\partial y_j} \right) \frac{dy_j}{du_j} \cdot \frac{\partial u_j}{\partial w_{ji}} \\ &= -\varepsilon \sum_c \left( \sum_k (\sum_l (y_l - \bar{y}_l) f'(u_l) w_{lk}) f'(u_k) w_{kj} \right) f'(u_j) y_i \end{aligned} \quad (18)$$

と伝わっていく。ここで

$$f'(u_k) = y_k(1-y_k) \quad (19)$$

であり、また最後の  $\frac{\partial u_j}{\partial w_{ji}}$  だけが  $w$  の変化するニューロンのオリジナルになる。

### 3.3 多層ニューラルネットワーク

ここでは、バックプロパゲーションなどで学習できるパーセプトロン型のニューラルネットワークの層数とその特徴領域分割能力について述べる。

多層パーセプトロンは入力と出力の間にいくつかの隠れ層が存在する feed-forward 型のネットワークである。図 3-4 に 3 層のパーセプトロンの例を示す。多層パーセプトロンによって 1 層のパーセプトロンの持ついくつかの制限を克服することができる。しかし以前は多層パーセプトロンが使用されることはなかった。これは以前は効果的な多層パーセプトロンの学習法がなかったためである。最近では学習アルゴリズムの発展によって多層パーセプトロンが一般的になった<sup>(31)</sup>。しかし、実際この多層パーセプトロンの学習に関しては実は 1 層の時のように確実に収束することは証明されていない。しかし各種領域での問題の適用でうまく学習できることが示されている。

この多層パーセプトロンの能力は、そのノードが非線形性を持っていることにより生じるものである。もし線形であれば、同様の計算が 1 層の場合でも可能である。なぜなら線形の場合、1 層では当然特徴空間のある方向に向かって値が漸増する出力しか得られない。さらに 2 層でこの 1 層で得られた出力を組み合わせ（幾つかあるある 1 層目のノードの出力それぞれにある値をかけて、足しあわせる）出力が得られるが、組み合わせた出力は結局はやはり特徴空間のある方向に漸増する値にしかならないためである。この後 3 層、4 層と増やしても同様のことの繰り返しにしかならない。これは 1 次元の例を考えるとすぐ分かる。これを図 3-5 に示す。2 つある 1 層目からの線形の出力の和が再び線形の出力となっていることが分かる。

次に1層、2層、3層の非線形パーセプトロンの能力を図3-6に示す。この場合は内部関数としてステップ関数を用いた hard-limiting な非線形性を持ったノードを考える。図から分かるように、1層のパーセプトロンは半平面の決定領域を形成する。2層のパーセプトロンは1層で分けられる空間を組み合わせて凸型の決定領域を形成することができる。ただし複数に分割した決定領域は形成できない。さらに3層の場合は、2層までの出力を組み合わせた決定領域が形成でき、凹型や複数に分割されたもの、穴のあいたものなども形成可能となる。

ここで、2層の時、1層目の  $N_1$  個のノードからの入力に掛ける結合荷重をすべて 1.0 とし、次にその2層目のノードの出力の閾値を  $N_1 - \epsilon$  とする。すると、2層目のノードの出力が 1.0 となるのは1層目からの入力がすべて 1.0 の場合である。この動作はちょうど論理 AND に相当する。決定領域は1層目のそれぞれのノードで形成された出力 1.0 となる半平面のすべてが交差する部分となる。よってこの決定領域は最大で1層目のノードの数と同じだけの辺をもつことになる。このことから、問題の複雑さに応じて、決定領域を適切に決められるだけの十分な数のノード数が必要であることが分かる。しかし、どれだけの結合荷重が必要かというのが学習データより評価できる場合は多い。

3層のパーセプトロンの場合、任意の複雑な決定領域を形成できる。これは mixture distributions や nearest-neighbor classifiers などの手法<sup>(32)</sup>を用いたのと同様の複雑さを扱える。このため、パーセプトロンライクな feed-forward ニューラルネットワークではこれ以上の層数は必要ないことが分かる。






图 3-2 NETtalk




図 3-3 シグモイド関数




図 3-4 3層パーセプトロン

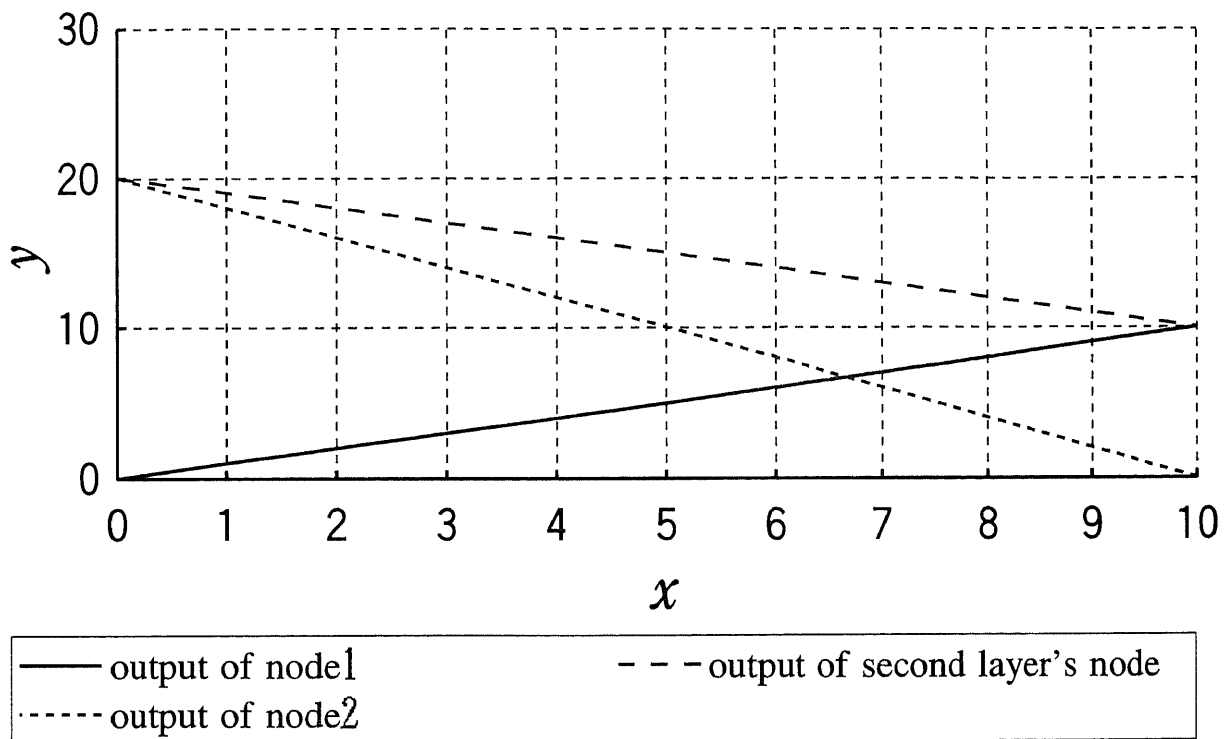


図 3-5 線形ノードを持つパーセプトロンの出力特性

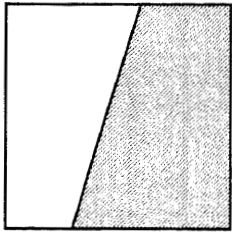
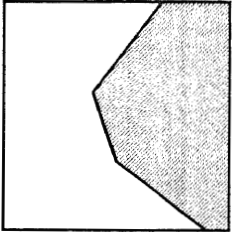
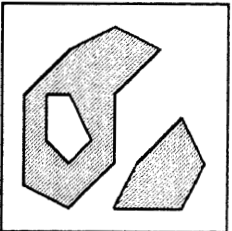
structure	Type of decision region	Shapes of decision region
single layer	Half plane bounded by hyperplane	
two layer	Convex open or closed region	
three layer	Arbitrary (Complexity limited by number of nodes)	

図 3-6 1層、2層、3層のパーセプトロンの能力

### 3.4 本研究で論ずる主なニューラルネットワークの構成

今回用いたニューラルネットワークの構成について述べる。

最も一般的な階層型のフィードフォワード（feed-forward）ニューラルネットワークである全結合型ネットワーク All Connecting Neural Network（ACNN）と、Waibelらによって考案された、音素判定に対して、時間方向の shift に強い判定の行える、Time-Delay Neural Network（TDNN）、それと今回脳波特徴波の判定に適したネットワークとして我々の提案する Sleep Stage Recognition Neural Network（以下 SRNN と呼ぶ）の 3 つを図 3-7（a）～（c）に示す。

以上 3 つのニューラルネットワークは学習方法にバックプロパゲーション法を用いている。

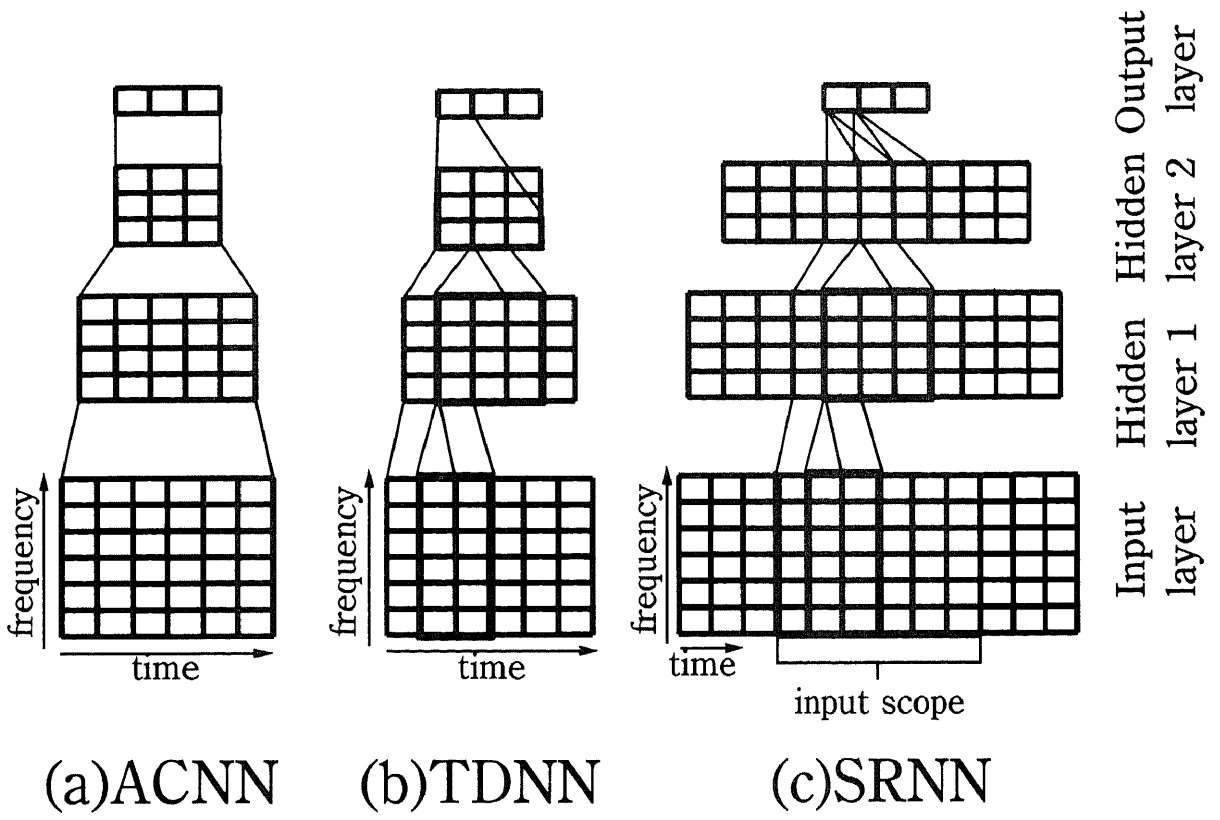


図 3-7 各種ニューラルネットワーク

### 3.4.1 ACNN (all connecting neural network)

各々の層のニューロンがその前の層及び後ろの層に存在するすべてのニューロンと結合しているモデルである。最も一般的なモデルである。

### 3.4.2 TDNN (time delay neural network) <sup>(33)</sup> <sup>(34)</sup>

Waibel らによると、音声認識のためのニューラルネットワークは、幾つかの性質を持たなければならない。

- 1) 複数の層を持ち、その間は、内部的に十分に結合されてなければならない。これは問題に対する複雑な非線形の決定様式を学習するためである。
- 2) 時間的に起こったイベント間の関係を表現する能力を持つこと。
- 3) ネットワークで学習された実質的な特徴、又は原理が時間的に変化しないこと。
- 4) 学習方法は学習の順番の厳密な並び方を要求しないようにすべきである。
- 5) 重みは学習データの大きさと十分細かく比較すべきで、これにより、ネットワークは、規則性を取り出し、入力データを符号化する。

上記のような条件を備えたニューラルネットワークとして、Waibel らは音素認識用のニューラルネットワーク TDNN を提案した。以下に音素認識のための TDNN のアーキテクチャを示す。

多数のニューラルネットワークで使われる基本的なユニットは、入力値に重みをかけた値の和をつくり、それを非線形の関数に渡すという計算を行う。この関数は大概閾値関数かシグモイド関数である。TDNN の基本的なユニットには図 3-8 のように、導入部の遅延  $D_1 \sim D_N$  が付く。そのようなユニットの  $J$  個の入力には遅延のあるものないものそれぞれに 1 つずつ重みが掛けられる。例えば  $N=2$ ,  $J=16$  の時、3 つの異なる時間位置と共に、16 の入力に対し重み付けの和を計算するのに 48 個の重みが必要である ( $3 \times 16=48$ )。このような方法により、TDNN は過去と現在のイベントの比較と関連付けが可能である。非線形な出力関数  $F$  については、その数学的な扱い安さからシグモイド関数を用いてい



る。この時間遅れ素子の詳細は次の SRNN の解説の中で述べる。

音素認識用に構築された 3 層のネットワークの全体的なアーキテクチャと、動作の典型例を、図 3-9 に示す。

一番低いレベルにおいて、16 個の正規化されたメルスケールのスペクトルが入力として与えられる。入力される音声は、12kHz でサンプリングされたもので、5ms ごとにハミングウィンドウをかけて 256 ポイントの FFT で処理された。

メルスケールの係数の値は、各々のメルスケールのエネルギーバンドの中で log エネルギーを計算するという方法で、パワースペクトルから計算された。ここでメルスケールは周波数に関してとなりあった係数が 1 つのスペクトルサンプルで重なりあっているため、その共通するサンプルは 50% 減衰することで平滑化された。時間的にとなりあった係数に関しては、10ms のフレーム全体でのより大きな減衰という形で減衰された。つまり、入力記号 (token) (ここでは手動でラベル付けされた母音の始まりを中心とした 15 フレームの発音) のすべての係数が正規化された。入力の全 15 フレームの係数のエネルギーより平均を計算して各々の係数から引き去り、これを -1 から +1 の範囲に正規化した。図 3-10 は入力 "DO" を表しており、正の値は黒の四角、負の値は灰色の四角で表している。

この入力層は 8 個の時間遅れ隠れユニットに完全に内部結合している ( $J=16$ ,  $N=2$ )。図 3-7 から分かるように、TDNN ではこの隠れ 1 層目と入力層との間の結合荷重の様子は、その左右のどの隠れ 1 層目から入力層の間の結合荷重とも同一であり、ネットワークで学習された実質的な特徴、又は原理が時間的に変化しない、入力パターンの横ズレに強い構造になっている。このため学習は、時間方向の平均を取って行われる。この関係は隠れ 1 層目と 2 層目の間においても成り立つ。第 2 の隠れ層は 3 つの TDNN ユニットのそれぞれが隠れ層 1 の 5 フレームのウィンドウに結合している ( $J=8$ ,  $N=4$ )。これは、より高次の層は、低時の層のよりローカルな原理の上に立って、時間的により幅広い処理をすべきであると考えたからである。最後に出力層はそれぞれの判定ユニットが時間全域にわたって隠れ層 2 の特定の横の列とのみ結合している。ここでの結合は、単純和となっており、その値がそのまま判定として出力される。

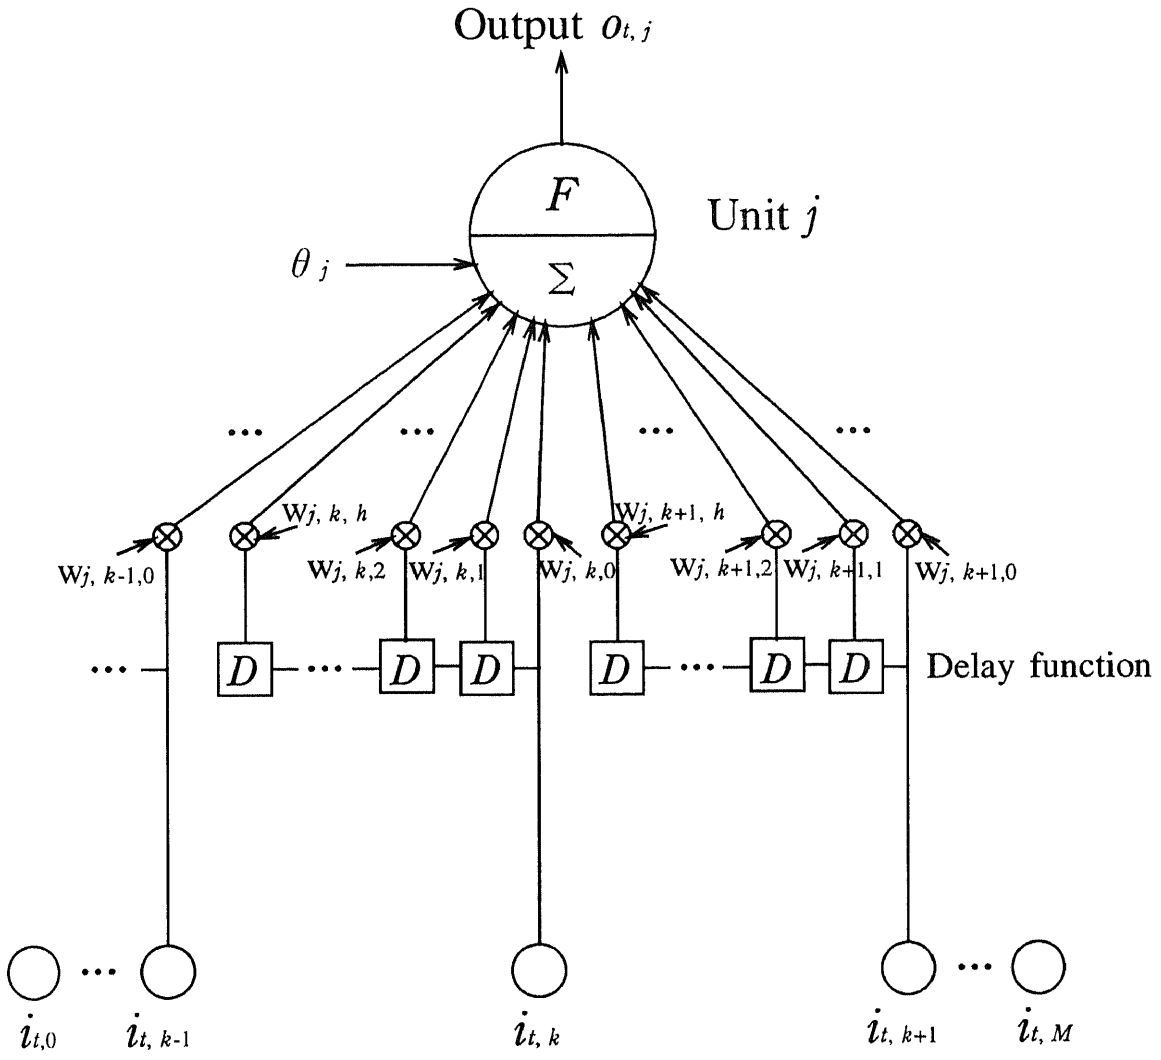


图 3-8 時間遅れ素子 Time Delay Unit

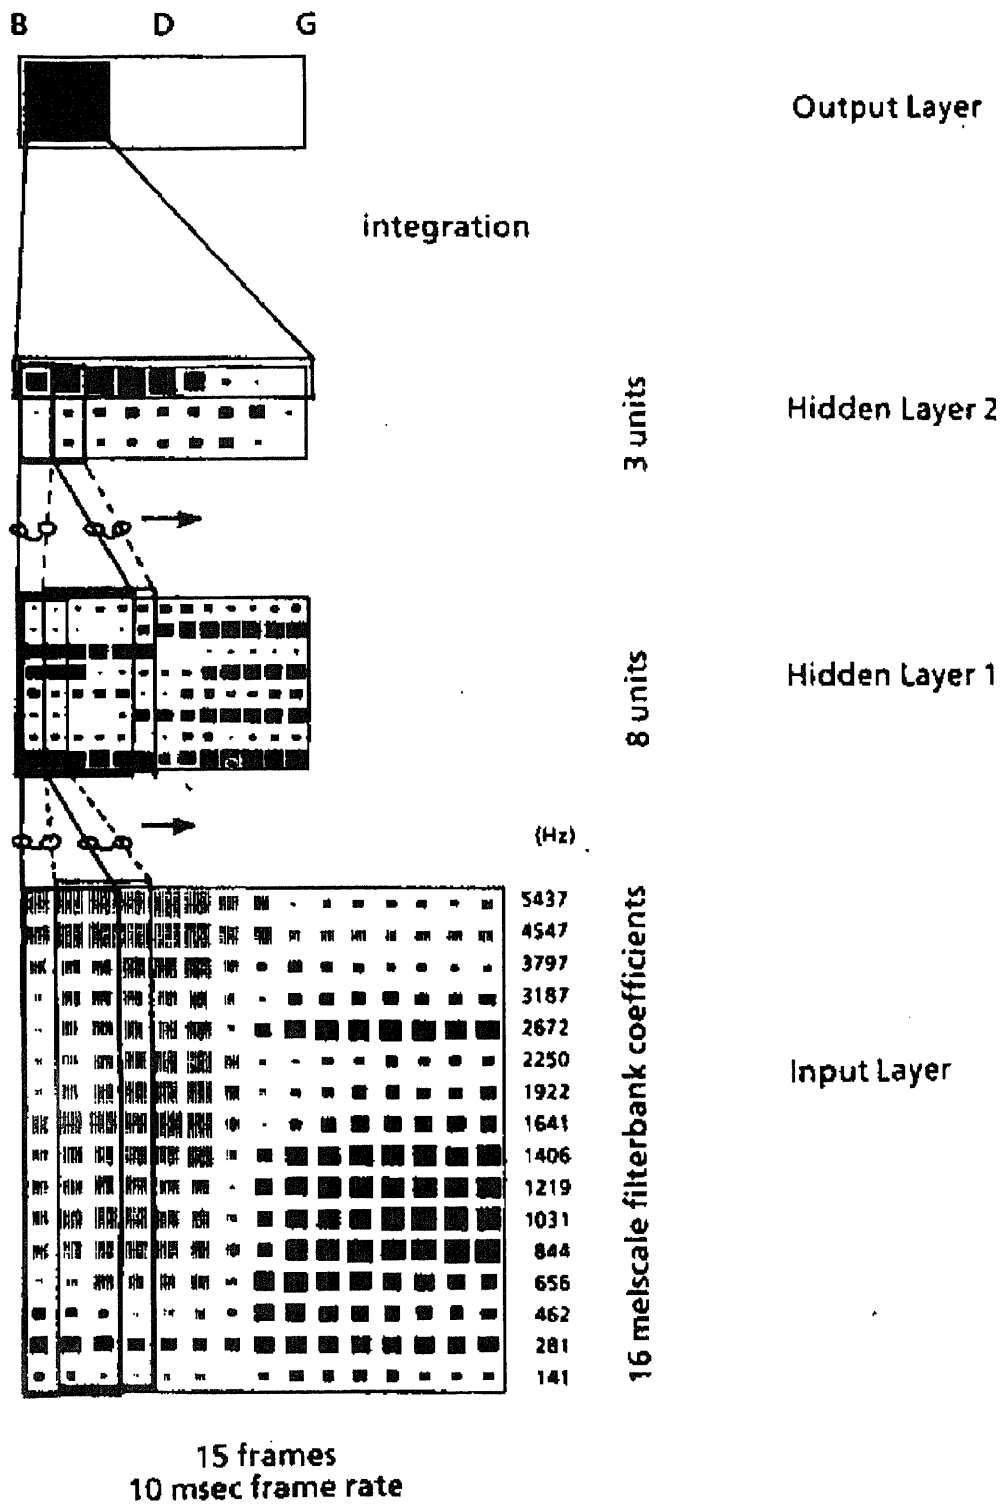


図 3-9 TDNN の動作例 (音素判定)

(Hz)




図 3-10 入力パターン” DO ”

### 3.4.3 SRNN (sleep stage recognition neural network) <sup>(2) (4) (5) (6) (7) (8)</sup>

睡眠脳波の特徴波を正確に検出するためのニューラルネットワークには、以下の3つの条件が重要であると考えられる。

#### 1) 特徴波持続時間に左右されない検出能力

睡眠脳波中の特徴波には持続時間が数秒以上に及ぶこともある $\alpha$ 波から、0.5秒にも満たない hump まで様々なものが存在する。また睡眠脳波のような大量のデータを処理するには、ある程度広い解析時間窓を用いる方が、処理時間の面から効率的であるが、この場合、様々な特徴波の持続時間に依存せずに安定した検出を行う必要がある。

#### 2) 孤立性の認識

一方で、特に持続時間の短い特徴波(突発波)の持つ性質である孤立性を正しく認識できなければならない。このとき孤立性のような時間推移パターンを認識するためにも、ある程度広い解析時間窓を用いる必要がある。また孤立性を持つ波形の判定には4.5.2で詳しく述べる波形のスペクトルパターンの時間方向における XOR 的処理が必要である。

#### 3) 時間軸方向に関するシフトインバリエント

そして、脳波データは解析時間窓をその窓幅だけ移動しながら処理されていく。これは窓を重なりを持たせて少しずつ移動される方式に比べてつなぎ目の部分を考慮する必要があるが、脳波の場合、特徴波の占める時間が背景波に比べて極めて少ないため、このようにしてもほとんど支障がない点、また、孤立性の認識には長い時間窓で見る必要がある点からこのような方式が適しており、TDNNによる音素識別とは異なる点である。しかし、この場合、入力パターンの時間シフトに完全に対応できるシフトインバリエントな能力を持つ構造でなければならない。

我々はこのような観点から睡眠脳波中の特徴波を認識する手法について検討し、図3-7に示すSRNNを提案する。このような時間シフトへの対応を考慮したものに、3.4.2で示

したように Waibel らにより音素認識用に提案された TDNN がある (図 3-7 参照)。しかし TDNN においては、SRNN と異なり出力層のニューロンは、隠れ 2 層目の出力のうちどれか 1 つの行とのみ結合している。このため XOR つまり孤立性を表現できず、孤立性を持つ hump の検出が困難であることを示した。この他文献 (2) においてその構造の詳細及び他の手法と比べたときの優位性、さらに内部の構造の解析について詳細に示した。以下に SRNN の構造を示す。

SRNN では横方向に時間、縦方向に周波数としたスペクトルの時間推移パターンをマトリクス状にして入力層に入力する。ただしこの入力層は、ネットワークへの入力値が配置される層であり、他の隠れ層や出力層と異なり、素子の部分にはリニアなニューロンが並んでいると考えられる層である。

また、入力パターンが横 (時間) 方向にズレても正しい判定が行えるよう、図 3-7 に示すように入力層、隠れ 1 層目、隠れ 2 層目の 3 つの層の間の結合の仕方に関しては、時間方向にそれぞれ  $h_1$  および  $h_2$  のせまい幅の結合単位で分割して処理を行い、それぞれ同一の時間遅れの構造をとっている。時間遅れの構造は次式で表される。

$$o_{i,j} = F\left(\sum_k \sum_l w_{i,k,l} D_l i_{i,k} - \theta_j\right) \quad (20)$$

ここで、< 入力層 → 隠れ 1 層目 > で考えた場合、 $i_{i,k}$  は、隠れ 1 層目の素子から見て時刻  $t$  での入力層の素子  $k$  からの入力値、また  $o_{i,j}$  は隠れ 1 層目の素子  $j$  がその入力値を (20) 式により処理した後の出力を示す。また  $D_l$  は、時間  $l$  だけの遅延関数、 $w_{i,k,l}$  は、 $l$  だけの時間遅れを持つ素子  $k$  と素子  $j$  との間の結合荷重、 $\theta_j$  は素子  $j$  の持つ閾値を示す。 $F$  はいわゆるシグモイド関数を表す。また < 隠れ 1 層目 → 隠れ 2 層目 > の結合では、隠れ 2 層目に並ぶ素子から見た場合  $i_{i,k}$  が隠れ 1 層目からの入力、 $o_{i,j}$  が隠れ 2 層目の素子の出力となり、同様の関係を満たす。この時間遅れ素子を図 3-8 に示す。

また最終層は次式で表されるような制限付きの全結合型とした。

$$y_m = F\left(\sum_k w_{m,k} i_k - \theta_m\right) \quad (21)$$

ここで、 $i_k$  は、出力層の素子から見て、隠れ2層目の素子  $k$  からの入力、 $y_m$  は出力層の素子  $m$  (判定ユニット) の出力、 $w_{m,k}$  は結合荷重、 $\theta_m$  は閾値を示す。また  $w_k$  は横(時間)方向には各行ごとに同一の値が並んでいる。すなわち、隠れ2層目の  $p$  行  $q$  列目の素子からの入力を  $i(p, q)$ 、これと出力層の素子  $m$  との間の結合荷重を  $w_m(p, q)$  と表すと式(21)は

$$y_m = F(\sum_p \sum_q w_m(p, q) i(p, q) - \theta_m) \quad (22)$$

のように書き表せ、結合荷重は次のような関係を満たしている。

$$w_m(0, q) = w_m(1, q) = \dots = w_m(p, q) \quad (23)$$

次に学習の仕方について述べる。学習にはバックプロパゲーションを用いた<sup>(26) (27)</sup>  
(28) (29)。

ここで用いた、バックプロパゲーションにおける結合荷重更新のアルゴリズムは

$$E = \frac{1}{2} \sum_j \sum_c (y_{jc} - \bar{y}_{jc})^2 \quad (24)$$

$$\Delta w_{j,i} = \varepsilon \frac{\partial E}{\partial w_{j,i}} \quad (\varepsilon > 0) \quad (25)$$

と表される。ここで  $y_{jc}$ 、 $\bar{y}_{jc}$  はそれぞれ入力データマトリクスのパターン  $c$  に対する、判定ユニット  $j$  の出力及び教師データを示す。また  $\varepsilon$  は荷重の更新係数、 $\Delta w_{j,i}$  は下位層の素子  $i$  と上位層の素子  $j$  間の結合荷重の更新量を表すが、実際にはさらに各行において横(時間)方向の平均値を結合荷重の更新量としている。すなわち、下位層の  $l$  行目において素子が時間方向に  $S$  列ならんでいる場合、 $l$  行目の素子と上位層の素子  $m$  との結合荷重

の更新量は次のようになる。

$$\Delta w_{m,l} = -\frac{\varepsilon}{S} \sum_{k=1}^w \frac{\partial E}{\partial w_m(k,l)} \quad (26)$$

この方式は、入力層から隠れ2層目間における各分割領域の、同一の対応関係を持つ入力-出力素子間に対してもあてはまり、この場合(26)式の $S$ はマトリクスの分割数を表す。

このようにすることですべての隠れ層においては、入力パターンが、解析時間窓に対して時間シフトを生じてても、安定した判定が可能となる。

また、処理効率の向上や孤立性の認識のためには、ある程度広い解析時間窓を用いる必要があることは、既に述べたが、この場合、解析窓内での検出感度が一様でなければならない。そのため、入力層や隠れ層の幅(時間方向の素子数)を、図3-7のように解析時間窓で決まる最小幅よりも拡張している。こうすることで入力層に提示されたパターンの端の方が中央部分に比較して結合回数が少なくなり検出感度が低下するのを防いでいる。このとき拡張する幅 $h_e$ は

$$h_e = 2 \times (h_1 - 1 + h_2 - 1) \quad (27)$$

と表される。ここで $h_1$ 、 $h_2$ はそれぞれ入力層のうち隠れ1層目へ結合する部分の横幅(時間方向の素子数)、および隠れ1層目のうち隠れ2層目への結合する部分の横幅である。この拡張された領域で下位層からの入力値のない部分については0の値が与えられた。

今回脳波特徴波検出に用いたSRNNは $h_1 = 3$ 、 $h_2 = 5$ となっている。また入力マトリクスは縦12行、横11列のrunning spectrumである。ここで、ネットワークを拡張しない場合、入力マトリクス上時間方向に11列並んでいるデータが、結合単位により処理される回数は、それぞれ左から $\langle 3, 5, 7, 8, 9, 9, 9, 8, 7, 5, 3 \rangle$ 回となっている。このことから、中心部分と端の部分で大きく処理回数が異なっており、端の方の検出感度が下がってしまうことがわかる。ここで、本論文で示したように拡張幅を設けると、処理回数はそれ



ぞれ左から

< 3, 5, 7, 8, 9, …, 9, …, 9, 8, 7, 5, 3 >  
15個

回となり、中心部分に同一処理回数が11列以上並んでいることがわかる。またここで、同一処理回数部分が15列あるのは、隠れ1層目と隠れ2層目の間も同様に、マトリクスの端の方と中心の部分で同一回数の処理を行う必要性からその分余計に同一処理回数部分が必要となるためである。このようにすることで、データ位置によらず安定した判定ができることが確かめられている。

また、文献(2)では、これらの特性により、SRNNを用いることで従来のニューラルネットワーク ACNN、TDNN やテンプレートマッチングの一種である線形予測係数に対する尤度比を用いた方法<sup>(22)</sup>などに比べ、持続時間の長い $\alpha$ 波から短い hump まで特徴波の持続時間によらずより高い正答率が達成できることを示した。

## 第 4 章 脳波特徴波の検出

### 4.1 脳波特徴波検出に適したニューラルネットワークの条件

3.4.3 で既に述べたが、脳波特徴波検出を行うニューラルネットワークに要求される条件として、以下の 3 つがあげられる。

- 1) 特徴波持続時間に左右されない検出能力
- 2) 孤立性の認識
- 3) 時間軸方向に関するシフトインバリエント

我々はこれらの条件を満たすニューラルネットワークとして SRNN (図 4-1) を提案した<sup>(2) (4) (5) (6) (7) (8)</sup>。

### 4.2 特徴波検出のための構成

SRNN を特徴波検出に用いる具体的な構成について示す。また、今回 SRNN との比較に用いたニューラルネットワーク ACNN と TDNN についても、その具体的な構成を示す。




図 4-1 SRNN の構造

### 4.2.1 SRNN による方法

特徴波検出に用いた SRNN のネットワークの構成は、その入力層は解析窓幅  $N_1=11$  に対し、横（時間方向） $N_1+2 \times (w_1-1+w_2-1)=23$ 、縦（周波数方向）12 であり、入力層の横  $w_1=3$  列分が隠れ 1 層目の 1 列へ入る。隠れ 1 層目は  $N_2=9$  に対し、横  $N_2+2 \times (w_1-1+w_2-1)=21$ 、縦 6 であり、隠れ 1 層目の横  $w_2=5$  列分が隠れ 2 層目の 1 列へ入る。また、隠れ 2 層目は横  $N_3+2 \times (w_1-1+w_2-1)=17$ 、縦 6 である。出力層のノード数は 3 とした。結合荷重数は  $(3 \times 12+1) \times 6+(5 \times 6+1) \times 6+(6+1) \times 3=429$  である。

ニューラルネットワークを用いて検出を行う場合、まず特徴波の学習データを入力に提示し、そのスペクトルパターンに対応して出力層の判定ユニットが発火するようネットワーク内の結合荷重の値を学習する。また、この論文で提案する SRNN は、特徴波の持つスペクトルの特徴に加え、その時間的推移パターンを認識する必要がある。このためデータの形式は前述のように横軸を時間、縦軸を周波数とし、スペクトルの振幅値に応じて正規化した値を並べた 2 次元のマトリクス状とした。

学習データの作成は、次のようにして行った。まず 200Hz でサンプリングされた睡眠脳波から、専門医の視察により各種の特徴波を含む部分を選び、0.64 秒間のハミング窓（128 ポイント）で切り出す。次にこれに FFT を施し、0 Hz から 17.1875Hz までの 12 ポイントの周波数、

$$f_k = k \Delta f \quad (k=0,1,2,\dots,11, \Delta f=1.5625 \text{ Hz}) \quad (28)$$

についてスペクトルを求めた。この周波数範囲に関しては、2.3.2 に示したように、睡眠段階判定に重要である大徐波（2Hz 以下）、 $\alpha$  波（8～12Hz）、spindle（14Hz 前後）、hump（5～14Hz）の周波数をカバーする周波数帯域を選んだ。

さらに、振幅の対数値  $P$  について、その全特徴波データの平均値  $m$ 、分散  $\sigma^2$  とすると、次式のように  $P$  の  $[m, m + 3\sigma]$  の範囲が  $[0,1]$  となるよう  $P$  の値を正規化し、スペクトルデータとする。

$$P'(f_k) = \begin{cases} 1 & (m + 3\sigma < P(f_k)) \\ (P(f_k) - m) / 3\sigma & (m \leq P(f_k) \leq m + 3\sigma) \\ 0 & (P(f_k) < m) \end{cases} \quad (29)$$

次に、窓を 0.32 秒移動して同様の処理を行い、マトリクスの中の列に相当するスペクトルデータとする。この様にして求めたスペクトルデータ列を 11 個ずつまとめて、全時間長 3.84 秒間、周波数 0 ~ 17.1875Hz に相当する 11 × 12 のマトリクス状の入力パターンを構成する。

学習用の教師データとして次の 5 種類の波形を用いた。

( I ) spindle

( II ) hump

( III )  $\alpha$  波

( IV ) hump を連続して並べたもの (以下 hump train と呼ぶ)

( V ) 背景波

学習データには 4.4.1 で示す 3 人の被験者 A, B, C の睡眠脳波から抽出した特徴波を使用した。これらの例を図 4-2 に示す。図でスペクトル振幅の大きさは黒い四角の面積で示されている。

学習に際し 5 つの特徴波のうち spindle, hump,  $\alpha$  波の 3 つについては各々に対応する判定ユニットが発火し、その他の特徴波についてはいずれの判定ユニットも発火しないよう行い、一定時間の睡眠脳波中に含まれる spindle, hump,  $\alpha$  波が検出できるようにする。ここで hump train は実際の睡眠脳波中には存在しないパターンである。しかし、局所的には似たような周波数成分が睡眠脳波の背景波に含まれることがあるため、hump を判定する場合の重要な手掛かりとなる”孤立性”を学習させ、hump と類似の周波数成分を持つ雑音成分と区別するために用いる。

学習はバックプロパゲーション法を用いた。すなわち学習データを順番にニューラルネットワークの入力層に提示し、出力層の判定ユニットの発火と正しい発火との 2 乗誤差から内部の結合荷重を変化させ、2 乗誤差の量がほぼ変化しなくなるまで学習データのセッ

トを繰り返し提示した。図 4-3 は、SRNN について学習回数と 2 乗誤差を示したもので、ほぼ 15,000 回で収束している。この場合、学習が収束するまでの時間はコンピュータ NEC の PC-9801RA を用いた場合約 5 時間程度であった。

学習したニューラルネットワークの検出能力を評価する被検査用のデータについても学習データと同様に構成した。これは被験者 A, B, C の 3 者についてそれぞれ 7～10 分程度の stage wake から stage2 までを含む睡眠脳波を用いた。


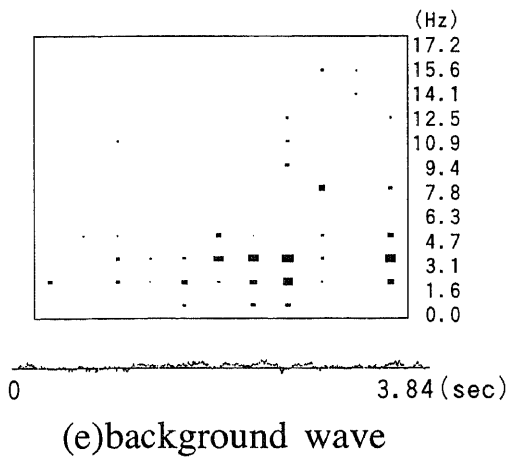
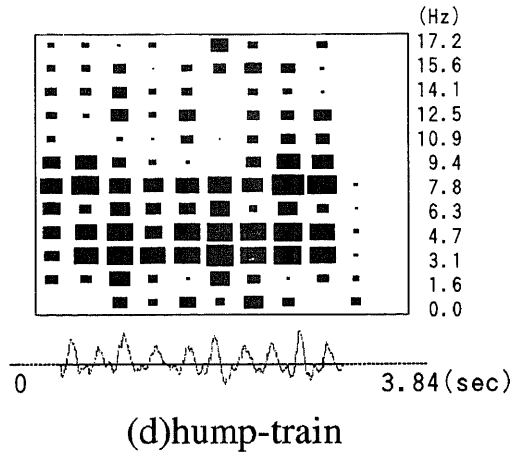
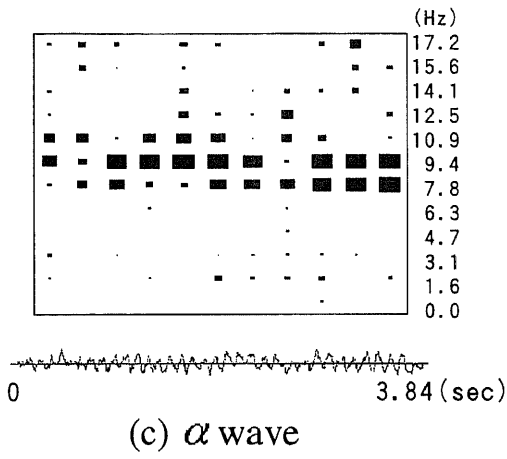
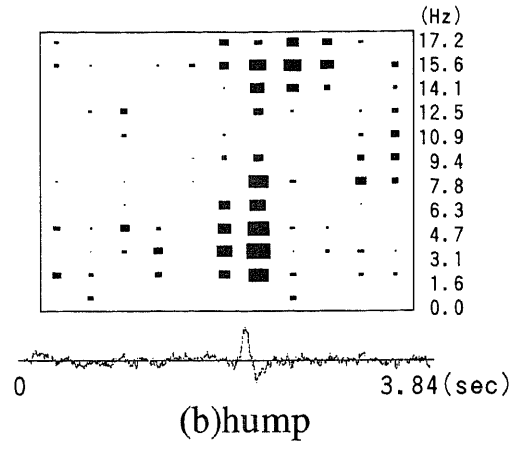



圖 4-2 各種特徵波




図 4-3 SRNN 学習時の学習回数と 2 乗誤差の推移



#### 4.2.2 TDNN による方法

睡眠脳波中の特徴波検出処理について、各種手法を適用し、SRNN による手法との比較を行った。

比較した手法の一つとして Waibel らによって考案された TDNN<sup>(33)(34)</sup> (図 4-4) を用いた。

TDNN では入力層の横を  $N_1=11$  で縦を 12、隠れ 1 層目の横を  $N_2=9$ 、縦を 17、隠れ 2 層目の横を  $N_3=5$ 、縦を 3 として SRNN と比較し結合荷重数が小さくならないようにしてある。用いた特徴波や、学習の方法等はすべて SRNN の場合と同一条件にして実験を行った。




図 4-4 TDNN の構造

### 4.2.3 ACNN による方法

今回最も一般的なニューラルネットワークとして、同じ3層の階層型ニューラルネットワークであるが層間のニューロンの結合を特に規定しない単純な全結合型ネットワーク ACNN (All Connecting Neural Network) (図 4-5) を比較に用いた。全結合型では、隠れ1層目のノードの数を6、隠れ2層目の数を10としてSRNNと比較して結合荷重が少なくなならないようにしてある。やはり用いた特徴波や学習の方法等はすべてSRNNの場合と同一条件にして実験を行った。




図 4-5 ACNN の構造

### 4.3 テンプレートマッチング的手法

いわゆるテンプレートマッチングによる手法の例として、波形の線形予測係数に基づく尤度比を用いた検出<sup>(22)</sup>を取り上げた。

尤度比による検出においては、まず検出する特徴波を含む時系列データをテンプレートとして用いるが、ここではこれを基準データと呼ぶことにする。次にこの基準データと被検査データとの間で、式(30)で定めるような線形予測係数間の尤度比 $D$ を求める。

$$D(P_x | P_y) = \log(a_y^T c_x a_y / a_x^T c_x a_x) + \log(a_x^T c_y a_x / a_y^T c_y a_y) \quad (30)$$

ここで、添え字 $x$ と $y$ はそれぞれ基準データ及び被検査データについての量であることを意味し、 $P_x, P_y$ は信号の最適自己回帰モデルを示す。また、 $a_x, a_y$ はそれぞれの線形予測ベクトル、 $c_x, c_y$ は自己相関行列である。この尤度比 $D$ は被検査データが基準データと一致する時に最小値0をとるので、適当に設定された閾値以下の場合にその特徴波であると認識される。

基準データ用の脳波中の特徴波は次の3つを対象とした。

- (I) spindle
- (II) hump
- (III)  $\alpha$ 波

基準データの長さは5.12秒(1024ポイント)とし、被検査データの長さはニューラルネットワークの場合に合わせて3.84秒(768ポイント)とした。基準データの作成は、学習データの特徴波のパワースペクトルをFFTで求め、その加算平均を逆FFTすることで求めた。線形予測係数は、試行により8次までを用いればそれ以上の次数を用いた場合と結果がほとんど変わらなかったため、次節の処理結果では8次の場合について示した。

### 4.4 特徴波検出結果

#### 4.4.1 解析データ

前章で述べた ACNN、TDNN、SRNN 及び尤度比による方法を用いて睡眠脳波中における特徴波の検出を試み、特性の比較を行った。解析には A、B、C の 3 人の被験者の脳波データを用いた。この 3 人の被験者の状態の詳細について表 4-1 に示す。A、B、C それぞれのデータのポイント数は 69,632、65,408、77,824 である。使用した学習データのポイント数は A、B、C それぞれの被験者から spindle で 11,520、7,680、13,824、hump で 10,752、102,912、6,912、 $\alpha$  波で 5,110、31,131、555 である。被験者 C のデータには  $\alpha$  波に関して stage wake と判定できる 1 判定区間に 50% 以上の持続時間を持つデータが無かったため、それより短いものをつなげることで学習データとした。また hump train に関しては 1 判定区間で 3 個以上の hump をランダムにつなげたものを学習データとした。背景波に関しては A、B、C のデータの特徴波がのっていない部分をつなげた 50,688 ポイントのデータを用いた。また、A、B、C それぞれの被験者のデータに含まれる特徴波の数は spindle で 22、26、49、hump で 24、15、19、 $\alpha$  波で 18、12、0 である。

#### 4.4.2 検出結果

特徴波の検出の結果を表 4-2、表 4-3、表 4-4、表 4-5 に示す。ここで正答率及び、過剰率は各種特徴波ごとに次式で定義される。表中の正答率は、過剰率が 30% を超えない範囲での最大の値を用いた。ここで正答率と過剰率は式 (31)、(32) のように定義される。

$$\text{正答率} = \frac{\text{ネットワークにより特徴波の存在が正しく検出された入力データ区間数}}{\text{実際に特徴波の存在する入力データ区間数}} \times 100\% \quad (31)$$

$$\text{過剰率} = \frac{\text{ネットワークにより特徴波が存在すると誤って検出された入力データ区間数}}{\text{実際に特徴波の存在する入力データ区間数}} \times 100\% \quad (32)$$

また、これらの表から、実験の open な場合と closed の場合で平均をグラフにしたものを図 4-6, 図 4-7 に示す。ここで open というのは、判定データが学習データ中に含まれていない場合、一方 closed は含まれている場合をいう。さらに open の場合の平均の正答率の上昇の値を表 4-6 に示す。

次に、この正答率に対して優位差の検定を試みた。検定に用いたデータは、各被験者において、別々の時刻において得た正答率である。検定手法は 2 つの手法間による正答率の平均に変化がないという帰無仮説 ( null hypothesis ) に対して有意水準 5% の t 検定を用いた。表 4-7 は、検定により仮説が棄却 ( reject ) された ( 有意差がみられた ) 部分に × 印を入れて示してある。この表より、SRNN は、TDNN や ACNN に比べ spindle 及び hump で有意差が見られるだけのより良い結果が得られていることが分かる。また線形予測係数に対する尤度比による結果と比較した場合、spindle、hump さらに  $\alpha$  波において有意差が見られるだけのよりよい結果が得られていることが分かる。

表 4-1 使用したデータの被験者の状態

	年齢	性別	医師の所見
A	35	女	正常
B	58	女	分裂病
C	21	女	正常

表 4-2 SRNN による特徴波検出正答率

学習 被験者	spindle			hump			$\alpha$ wave	
	A	B	C	A	B	C	A	B
A	86.4	100.0	95.9	95.8	93.3	89.5	100.0	100.0
B	81.8	100.0	91.8	75.0	80.0	63.2	100.0	100.0
C	86.4	96.2	95.9	62.5	80.0	73.7	100.0	100.0
AC	90.9	100.0	95.9	95.8	93.3	63.2	100.0	100.0
AB	86.4	96.2	95.9	91.7	73.3	78.9	100.0	100.0
BC	86.4	96.2	95.9	87.5	93.3	78.9	100.0	100.0
ABC	90.9	96.2	95.9	83.3	86.7	57.9	100.0	100.0

表 4-3 TDNN による特徴波検出正答率

学習 被験者	spindle			hump			$\alpha$ wave	
	A	B	C	A	B	C	A	B
A	54.5	88.5	93.9	87.5	60.0	57.9	100.0	100.0
B	63.6	100.0	91.8	75.0	80.0	47.4	100.0	100.0
C	68.2	96.2	93.9	79.2	100.0	57.9	100.0	100.0
AC	68.2	96.2	95.9	75.0	86.7	63.2	100.0	100.0
AB	54.5	92.3	91.8	79.2	86.7	57.9	100.0	100.0
BC	63.6	96.2	91.8	75.0	100.0	47.4	100.0	100.0
ABC	59.1	96.2	89.8	91.7	100.0	57.9	100.0	100.0

表 4-4 ACNN による特徴波検出正答率

学習 被験者	spindle			hump			$\alpha$ wave	
	A	B	C	A	B	C	A	B
A	45.5	96.2	89.8	58.3	86.7	36.8	100.0	100.0
B	81.8	96.2	93.9	50.0	73.3	31.6	100.0	83.3
C	63.6	88.5	87.8	37.5	53.3	21.1	100.0	100.0
AC	50.0	88.5	89.8	58.3	73.3	47.4	100.0	100.0
AB	40.9	100.0	93.9	45.8	60.0	47.4	100.0	91.7
BC	63.6	92.3	93.9	54.2	93.3	36.8	100.0	100.0
ABC	59.1	92.3	93.9	50.0	100.0	26.3	100.0	100.0



表 4-5 LRM による特徴波検出正答率

学習 被験者	spindle			hump			$\alpha$ wave	
	A	B	C	A	B	C	A	B
A	50.0	19.2	40.8	45.8	20.0	0.0	94.4	0.0
B	54.5	30.8	59.2	4.2	13.3	5.3	100.0	58.3
C	0.0	19.2	32.7	25.0	6.7	10.5	16.7	8.3
AC	36.4	26.9	32.7	37.5	0.0	0.0	94.4	25.0
AB	4.5	30.8	14.3	16.7	13.3	15.8	100.0	41.7
BC	31.8	19.2	34.7	25.0	13.3	10.5	100.0	58.3
ABC	9.1	23.1	32.7	0.0	6.7	15.8	100.0	41.7




図 4-6 特徴波検出の正答率 (open)




図 4-7 特徴波検出の正答率 (closed)

表 4-6 特徴波検出における SRNN を用いることによる平均の正答率の上昇 ( open )

	spindle	hump	$\alpha$ wave
TDNN	8.9	9.4	0.0
ACNN	8.3	28.1	0.0
LRM	63.7	69.4	59.0

表 4-7 特徴波検出における有意差検定

被験者 A closed

	spindle	hump	$\alpha$ wave
TDNN	×	×	
ACNN	×	×	
LRM	×	×	×

open

	spindle	hump	$\alpha$ wave
TDNN	×	×	
ACNN	×	×	
LRM	×	×	×

被験者 B closed

	spindle	hump	$\alpha$ wave
TDNN	×		
ACNN	×	×	×
LRM	×	×	×

open

	spindle	hump	$\alpha$ wave
TDNN	×	×	
ACNN	×	×	
LRM	×	×	×

被験者 C closed

	spindle	hump	$\alpha$ wave
TDNN	×	×	
ACNN	×	×	
LRM	×	×	×

open

	spindle	hump	$\alpha$ wave
TDNN	×	×	
ACNN	×	×	
LRM	×	×	×

## 4.5 考察

### 4.5.1 シフトインバリエント

まず SRNN と TDNN 及び ACNN の、入力パターンの横ずれへの対応能力を比較してみる。 $\alpha$  波においては共に良い結果が得られた。一方 hump においては SRNN の方が他の手法に比べ正答率が高いことが分かる。

hump のような持続時間の短い突発性の波形は、入力マトリクス内での特徴波の出現位置が予測できない。そのため hump の検出には、入力マトリクス内での特徴波の出現位置に依存しない均質な判定ができることが重要である。

TDNN では入力マトリクスの端の方に行くに従って、隠れ 1 層との結合回数が減少する。このためそれに伴う感度の減少が起こることが考えられる。また ACNN では SRNN や TDNN のような時間遅れ構造を持たないため、基本的にマトリクス内での均質な学習ができない。そのため、その均質性には学習時に学習データがどれだけ均質に入力マトリクスに提示されたかという不確実な要素に依存してしまうことになる。

ここでまず、ACNN と SRNN で hump の検出時の実際の出力を図 4-8 に示す。

図の横軸は判定する脳波データの記録時間を示し、縦軸は発火量を示している。またグラフの下には実際に hump が出現した時刻を示している。この図より、SRNN では hump の出現時刻と十分なレベルの出力が得られる時刻がほぼ対応しているのに対し、全結合型では 140 ~ 200(秒)の間で hump が出現する時刻でもほとんど出力がなく、その他の部分でも出力と出現時刻との対応関係が悪いのが分かる。

次に入力マトリクス内での特徴波の出現位置に依存しない均質な学習ができているかを調べるため、入力マトリクス上で hump の出現位置を左から右へ徐々にずらしたデータを SRNN, TDNN, ACNN に判定させた。hump の位置は 23 段階に分けてずらした(図 4-9)。また hump 以外の部分は睡眠深度の stage2 あたりの背景波を用いた。結果を図 4-10 に示す。グラフの横軸はマトリクス上の hump の出現位置に対応し、縦軸は発火の割合を示している。このグラフから TDNN ではその発火値は中央に行くほど大きく端に行くに従って次第に減少してしまっていることがわかる。また ACNN では hump の出現位置により発火値が不規則に大きく変化している。一方、SRNN では発火の割合が hump の出現位置に

依存せずに高い値を示し、マトリクス上の特徴波の位置に関して均質な学習ができていることが分かる。




図 4-8 ACNN と SRNN による特徴波 hump 検出時の出力




図 4-9 入力層での hump の横ずれ






図 4-10 hump の出現位置と対応する発火値

## 4.5.2 孤立性の認識

次に SRNN と TDNN を比較すると、隠れ 2 層目から出力層間の構造で SRNN は制限付きの全結合型であるが、一方 TDNN は出力層の特定の判定ユニットが隠れ 2 層目の時間軸方向の特定の行の単純和となっている。一般的にニューラルネットワークによる XOR 処理には 3 層構造が必要であることがわかっているが (3.3 節参照)、TDNN は完全な 3 層構造ではない。また特徴波検出の結果では、入力マトリクス内での全域的に出現する  $\alpha$  波において、共に良い結果が得られた。一方、孤立性のある hump においては SRNN の方が TDNN に比べ、良い結果が得られた。

これは、SRNN と TDNN では孤立性かつ突発性の波形を判定するのに必要な XOR 的処理の能力に差があるためと予想される。そこで SRNN と TDNN に AND, OR, XOR を学習させ、その能力について調べた。

図 4-11 はこのために用いたデータで、一番左の列は入力を示す。入力マトリクスの要素が 0 のみのものが [0 0]、入力マトリクスの一番左のみに 1 の入力のあるものが [1 0]、一番左から 2 番目のみに 1 の入力のあるものが [0 1]、どちらも 1 の入力のあるものが [1 1] という 2 入力に対応する (実際の実験ではこのパターンをマトリクス上ですずらしながら学習させたので、本来は 11 個の入力で考えなければならないが、ここではより理解しやすい形として 2 入力と対応させて示した)。これらの入力はそれぞれ hump とスペクトル的に重なりのない背景波、マトリクスの左側に存在する hump、マトリクスの右側に存在する hump、及び背景波のうち短区間でみると hump と同様なスペクトルを持つが全域的に出現する波 (hump train に相当) に対応する。

ここで XOR を実行すると、入力 [1 0]、[0 1] のみが出力 1 となり、hump の孤立性を認識することに対応することが分かる。これらの入力パターンをマトリクス上ですずらしながら学習させた。

AND, OR, XOR のそれぞれの学習結果を図 4-12, 図 4-13, 図 4-14 に示す。横軸が学習回数で縦軸が教師データとの自乗誤差を示している。AND, OR では SRNN、従来の TDNN とともに 100 から 300 回程度の学習で正しい値に収束しているのが分かる。一方、XOR では、SRNN は約 400 回で収束しているのに対し、従来の TDNN では 1,500 回を過ぎ

でも収束してない様子が示されている。このことから SRNNの方が TDNNに比べ、XOR的な能力に優れていることが分かる。

また、マトリクス上の2つの入力の大さをそれぞれ横軸と縦軸として2次元の平面上に表示し、対応する出力を TDNN と SRNN の場合で比較したものを図 4-15 に示す。図の黒いボックスの大きさが出力の大さを示している。正しく XOR が学習された場合には、2入力のうち、片方の入力のみが 0.5 以上の値をとったときに限り発火が起きる。この図より、SRNN では正しく XOR の領域分割ができているのに対し、TDNN では十分な領域分割が行われていないことが分かる。

一般にニューラルネットワークを用いて XOR 処理を行う場合、最低 3 層の構造が必要であると言われているが<sup>(29)</sup>、TDNN においては、出力層のニューロンは隠れ 2 層目の出力のうちどれか 1 つの行とのみ結合しているため XOR つまり孤立性を表現できず、そのため孤立性の判定が重要となる hump の検出において SRNN との差が出たと考えられる。

次に SRNN により hump、hump train、背景波について判定させた際のニューラルネットワークの内部状態について調べてみた。

図 4-16 の左が波形と入力層のマトリクスで、右が対応する出力である。図から、ネットワークは hump を入力したときのみ hump の判定ユニットが発火し、正しく学習がなされていることが分かる。

次に対応する隠れ 1 層目と 2 層目の出力を図 4-17 に示す。図 4-17 (a) から分かるように、hump と hump train を入力したときのみ、上から 2 段目の出力が大きくなっており、ここが hump のスペクトルに対応して発火をすることが分かる。

また図 4-17 (b) を見ると、まず 1 番上の段では、hump と hump train の入力に対し共に発火し、上から 2 段目では、hump train のときのみ発火していることが分かる。

hump と hump train の違いは、出現する孤立性の有無であることから 1 番上の段は hump のスペクトルパターンの出現位置に関して OR となる出力を、また上から 2 段目の段は出現位置に関して AND となる出力を示していると考えられる。また、hump の孤立性の判定には XOR 的な処理が必要であるが、一般に  $A \text{ XOR } B = (A \text{ OR } B) - (A \text{ AND } B)$  と表せるため、XOR を実行するには、OR に関して正の結合荷重、AND に関して負の結合荷重を持っていけば良いことになる。

図 4-18 は隠れ 2 層目と出力層の各判定ユニット間の結合荷重について示したものである。この図で右下に示されているのは閾値入力に対する結合荷重である。図で黒い四角の大きさが正の値の大きさを示しており、白い四角の大きさは負の値の大きさを示している。図 4-17 (b) と対応させて真ん中の hump の判定ユニットの結合荷重を見ると 1 番上の段に関しては OR と正の結合荷重を有し、上から 2 段目に関しては AND と負の結合荷重を有しており、上述のような XOR が実行されていることが分かる。




図 4-11 hump 検出と XOR 処理との対応




図 4-12 AND 学習時の誤差の推移




図 4-13 OR 学習時の誤差の推移






図 4-14 XOR 学習時の誤差の推移



(a)SRNN



(b)TDNN

図 4-15 XOR 処理における特徴空間の分割

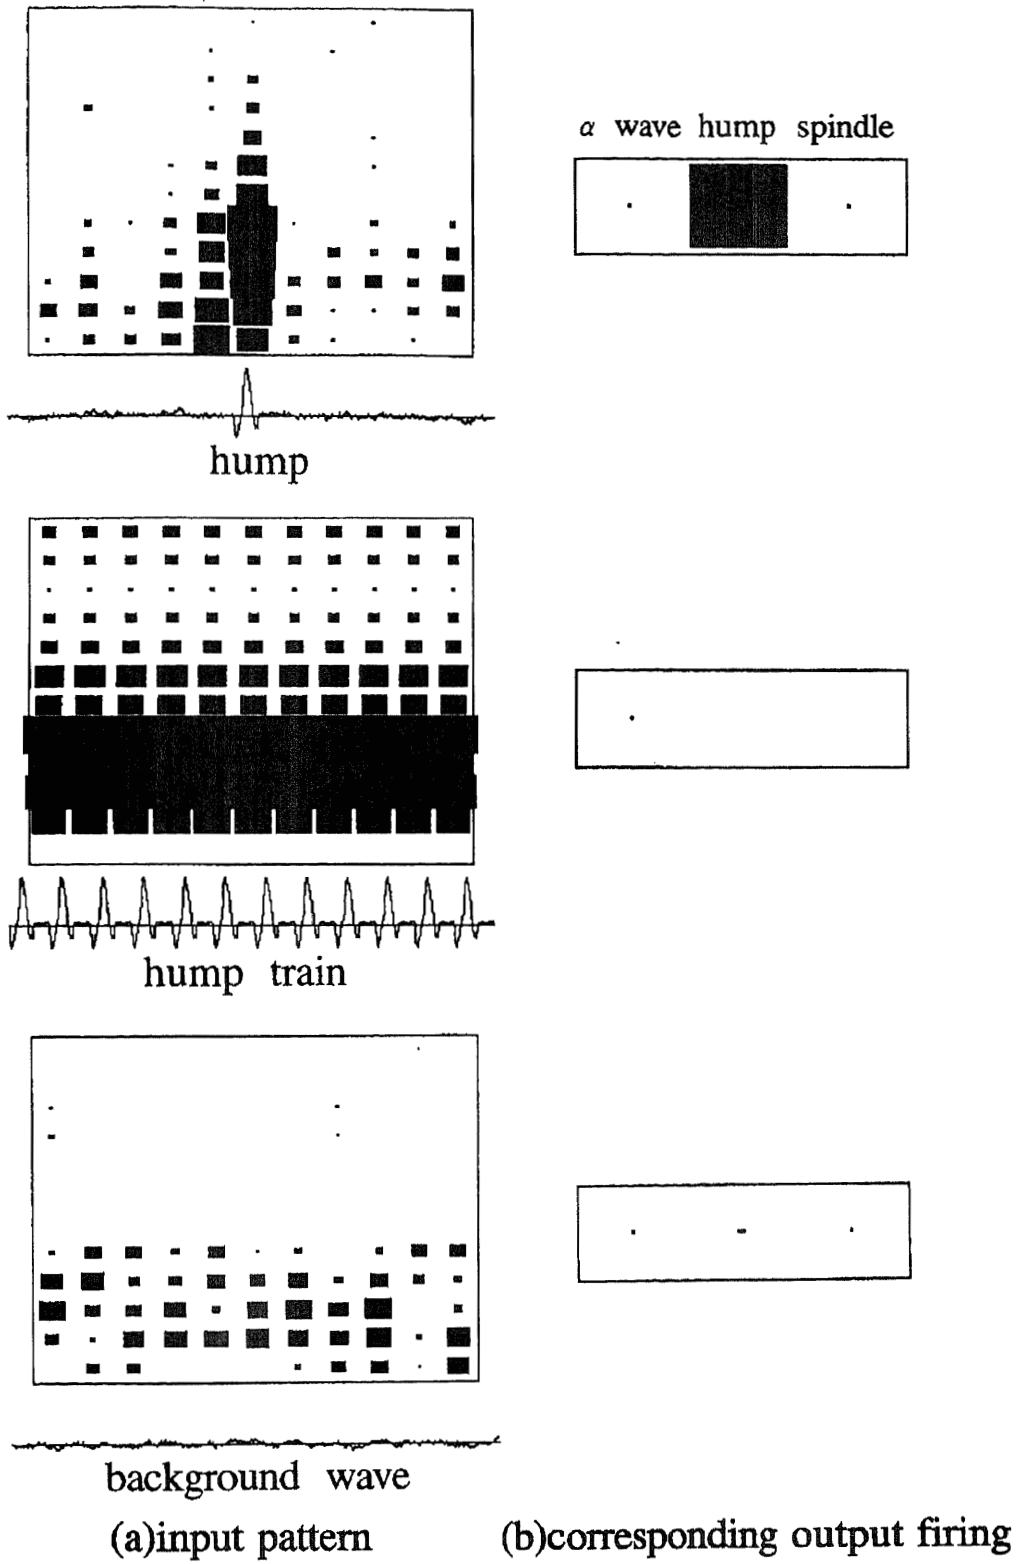




図 4-16 入力パターンと対応する SRNN の出力






hump




hump

OR




hump train




hump train

OR

AND



background wave




background wave

(a)hidden layer1

(b)hidden layer2

図 4-17 隠れ 1, 2 層における出力パターン



(a)  $\alpha$  wave      (b) hump      (c) spindle

図 4-18 SRNN の各判定ユニットにおける結合荷重

### 4.5.3 特徴波持続時間の影響

尤度比による検出では SRNN に比べ spindle、hump の正答率が低い。一方  $\alpha$  波においては良い結果が得られている。これらの結果から、尤度比による検出では解析時間窓に比較して特徴波の占める時間の割合が小さい場合に検出精度が悪くなることが考えられる。そこで特徴波の占める時間を変えながらその判定出力がいかに変わるかをシミュレートした。spindle のモデルとして、解析時間窓に占める 14Hz の正弦波の長さを変えたものを用い、残りの背景波部分に spindle モデルの  $2/5$  の最大振幅を持つランダム系列を与えた。図 4-19 はシミュレーションの結果であり、被検査用データの解析窓長に対する特徴波の占める時間の割合を横軸に、持続時間が解析窓長に等しい spindle をテンプレートとしたときの各割合に対する尤度比を縦軸にとってある。この図から、解析窓内における特徴波の占める割合が 100% より少なくなると尤度比が大きくなり、同一特徴波であることを判定することが難しくなることが分かる。同様の実験を SRNN で行ったのが図 4-20 であるがマトリクス内における特徴波の占める割合にかかわらず安定した出力が得られている。この尤度比のようなテンプレートマッチングによる手法は、一般に被検査データのばらつきが大きい場合は適さないが、このように解析窓内での時間シフトに対しても弱いといえる。さらに hump 検出の場合は孤立性の識別が重要であるがこの尤度比による方法では困難といえる。

また、表 4-5 の  $\alpha$  波の判定では被験者 A のものに比べ B の方が正答率が悪いことが分かる。これは B の方が波形に雑音が多く含まれていたためである。これに比べ他のニューラルネットによる手法は被験者 B に対しても A と同等の正答率を示しており、テンプレートマッチングの手法に比べパターンの劣化に強いことが分かる。




図 4-19 解析窓内に占める波形の時間的割合と尤度比




図 4-20 マトリクスに占める波形の時間的割合と発火量

#### 4.5.4 まとめ

睡眠状態の把握には、睡眠脳波の特徴波の検出において、孤立性や突発性を持つ波形を認識することが重要であると考え、特にその代表的な波形である hump を横ズレに強い形で認識できる方式のニューラルネットワークとして Sleep EEG Recognition Neural Network (SRNN) を提案した。

SRNN の動作特性を解析するため、ACNN、TDNN 及び、線形予測係数に対する尤度比を用いた検出法との特性の比較を行った。この結果 SRNN では ACNN、TDNN に比べ、孤立性かつ突発性のある波形に関して、より正確な検出がなされた。これは、マトリクス上の特徴波の出現位置に関してより均質な学習が行われるためであることを示した。

また、TDNN との比較に関しては、さらに、孤立性を持つ波形の判定には波形のスペクトルパターンの時間方向における XOR 的処理が必要であるが、TDNN では実現が不可能であること、一方で SRNN により実現されているためであることが分かった。

また線形予測係数による尤度比を用いた検出との比較では、尤度比による場合、解析窓中に占める特徴波の割合に検出結果が依存するのに対し、SRNN は出現位置や波形の持続時間に影響されにくいことが示された。また波形の劣化の影響を受けにくいことも確かめられた

## 第5章 睡眠段階判定

### 5.1 医療応用としての睡眠段階判定

前章で短区間スペクトルの時間推移パターンをニューラルネットワークにより識別させることで、humpから $\alpha$ 波まで、持続時間にかかわらず特徴波を検出できる方法を提案した<sup>(2) (4) (5) (6) (7) (8)</sup>。本章では、さらにこの手法を拡張し、ニューラルネットワークを用いて睡眠深度を判定するシステムについて述べ、睡眠脳波の処理によりその有効性を示す。以下で述べるシステムは、医師が睡眠段階を判定する過程に習い、特徴波の検出と状態分類という二つのプロセスからなる。前段は、睡眠脳波から特徴波検出を行う処理で、SRNN (Sleep EEG Recognition Neural Network) と名づけたニューラルネットワークで行われる。また、後段は前段の処理結果を受けSSNN (Sleep Stage Diagnosis Neural Network) と呼ぶニューラルネットワークにより、睡眠深度を判定する部分である。これらの基本構成及びデータの形式や学習については5.1で述べる。また、5.3においては、従来の長期間スペクトルのみを用いる手法として、全結合型のニューラルネットワークを用いた手法を示し、5.4ではこれらの手法による解析結果を示し、その比較・評価を行っている。

### 5.2 特徴波検出に基づく睡眠段階判定システム

従来の睡眠段階判定においては、主として睡眠脳波の長時間に渡る平均的スペクトルのみを用いて行われてきた。しかし自動的な睡眠段階判定を医師の行う判定の基準に沿ったものとするためには、医師が判定の手掛かりとしている脳波中の各種特徴波を用いる必要があると考えられる。このため図5-1のようにまずSRNN (図5-2) を用いて睡眠脳波

中から睡眠段階の判定に重要と考えられている特徴波を検出する。次にそこで検出された特徴波の出現パターンをもとにもう一つのニューラルネットワークにより睡眠段階を判定する2段階の手法により睡眠段階の自動判定を試みた。2つめのニューラルネットワークは、階層型の全結合型ネットワークを用い、以下ではこれを SSNN (Sleep Stage Diagnosis Neural Network)<sup>(3)(9)(10)(11)</sup> と呼ぶことにする (図 5-3)。

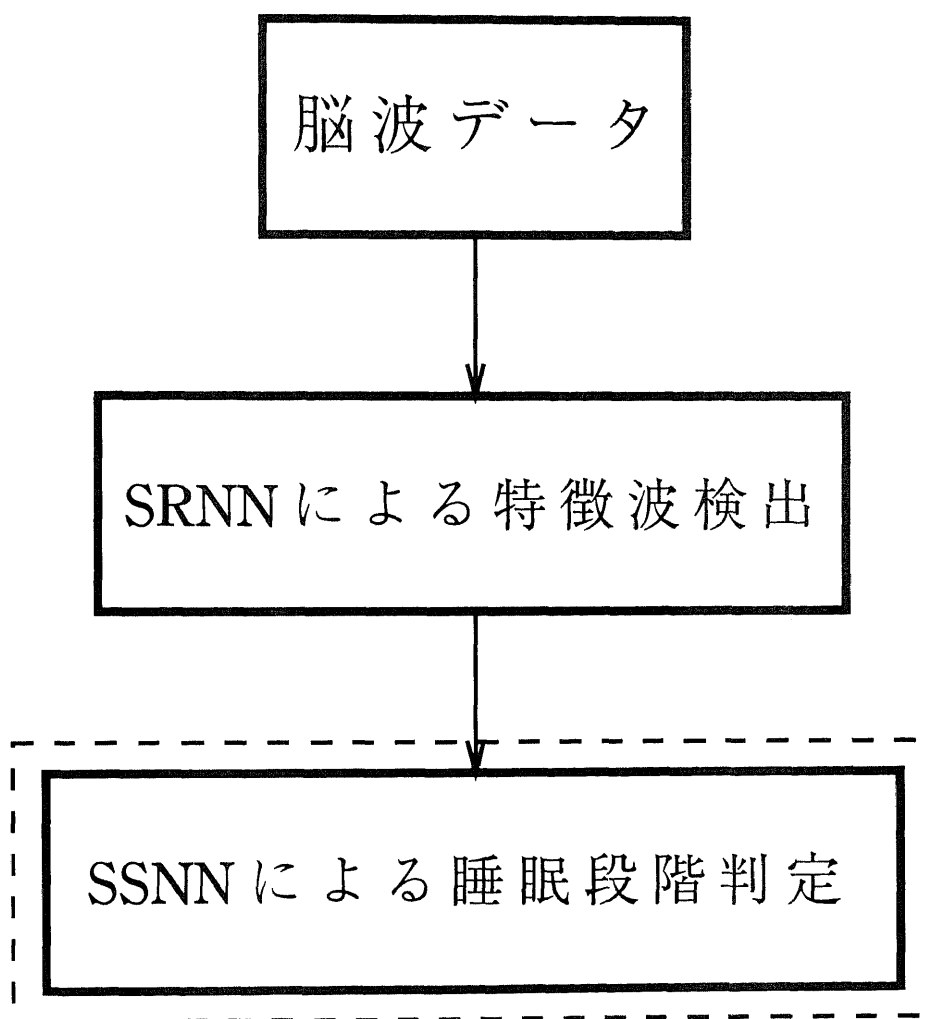


図 5-1 睡眠段階判定の流れ






図 5-2 SRNN の構造

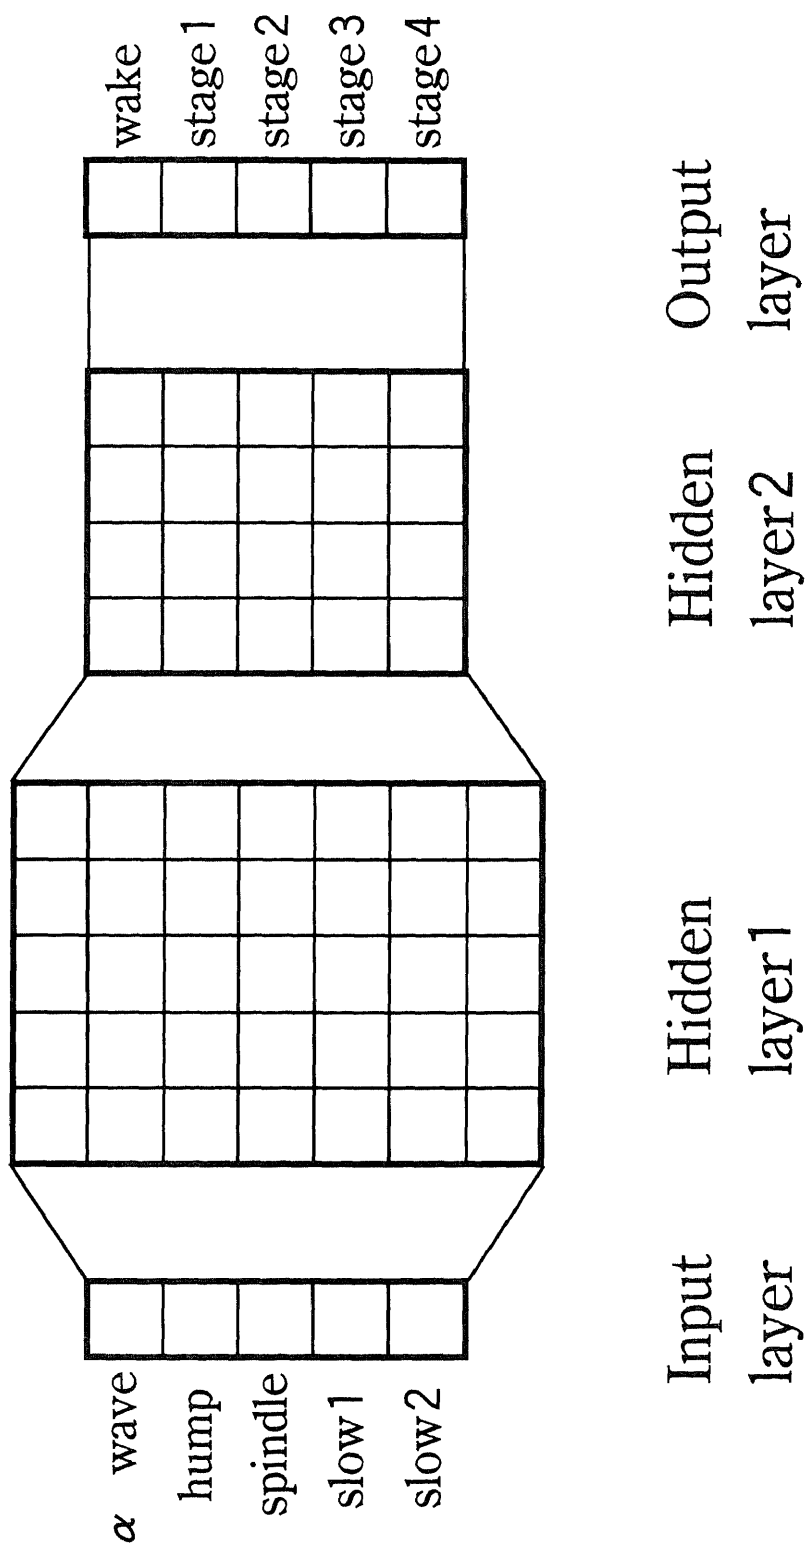


図 5-3 SSNN の構造

### 5.2.1 特徴波検出部 (SRNN)

睡眠段階判定システムの第一段階において、まず SRNN を用いて睡眠脳波中より睡眠段階判定に重要な特徴波を検出する。このため、図 5-2 に示すような構造の SRNN において 443 個のニューロン間の結合荷重に対して特徴波の学習データのスペクトルパターンを入力層に提示し、それに含まれる特徴波に対応して出力層の判定ユニットが発火するようネットワーク内の結合荷重の値を学習する。

学習データの作成は、前章で示した手法を用いた。

学習用の教師データとして前章で示した 5 つの特徴波を含めて次の 7 種類の波形を用いた。

- ( I ) spindle
- ( II ) hump
- ( III )  $\alpha$  波
- ( IV ) hump を連続して並べたもの (以下 hump train と呼ぶ)
- ( V ) slow1
- ( VI ) slow2
- ( VII ) 背景波

ここで slow1 と slow2 はそれぞれ一つの判定データ内 ( 3.84 秒 ) に徐波成分が時間的に 20 ~ 50 % のものとそれ以上存在するものとの分類してある。これは、徐波の割合が 20 ~ 50 % を stage 3、50 % 以上を stage 4 としている Rechtschaffen の診断基準<sup>(16)</sup>に沿って決めたものである。

slow1 と slow2 の入力パターンの例を図 5-4 に示す。学習に用いたデータの時間長は 25 分間である。

学習は hump train と背景波が入力されたときは出力層のどの判定ユニットも発火しないように学習し、またこれ以外の 5 種類の波形が入力された場合は出力層の 5 つの判定ユニットの内の対応するどれか 1 つが発火するように学習させた。この流れを以下に示す。また理想的な出力のパターンを図 5-5 に示す。

```

if pattern=<  $\alpha$  > OR <hump> OR <spindle>
    OR <slow1> OR <slow2>
    then corresponding output=1
        the others=0
else
    all output=0

```

またバックプロパゲーションによりパターン C に対するネットワークの出力  $y_{j,c}$  と教師信号  $\overline{y_{j,c}}$  との 2 乗誤差の変化が以下に示すように閾値以内になるまで繰り返した。

```

start:
    calculate  $y_{j,c}$  with the backpropagation method

```

$$E_n = \frac{1}{2} \sum_{j=1}^5 \sum_{c=1}^7 (y_{j,c} - \overline{y_{j,c}})^2$$

```

if  $|E_n - E_{n-1}| < \epsilon$ 

```

```

    then end

```

```

else

```

```

     $n = n + 1$ 

```

```

    go to start

```

ここで、SRNN による slow wave の検出能力を調べるため、マトリクス内に占めるの slow wave の時間の割合を 0 ~ 100% で変化させた場合の SRNN の発火値を調べた。入力データの内 slow wave 以外の部分には stage 2 の背景波を用いている。出力層には 3 つの判定ユニットを設け、その他の層のユニット数は今回特徴波判定に用いている SRNN と同一に合わせてある。それぞれの判定ユニットは、slow wave がマトリクス内に占める割合が 0%、20 ~ 40%、50 ~ 100% の時発火するように学習した。

結果を図 5-6 に示す。SRNN により slow wave の割合がほぼ正しく検出できていることが分かる。

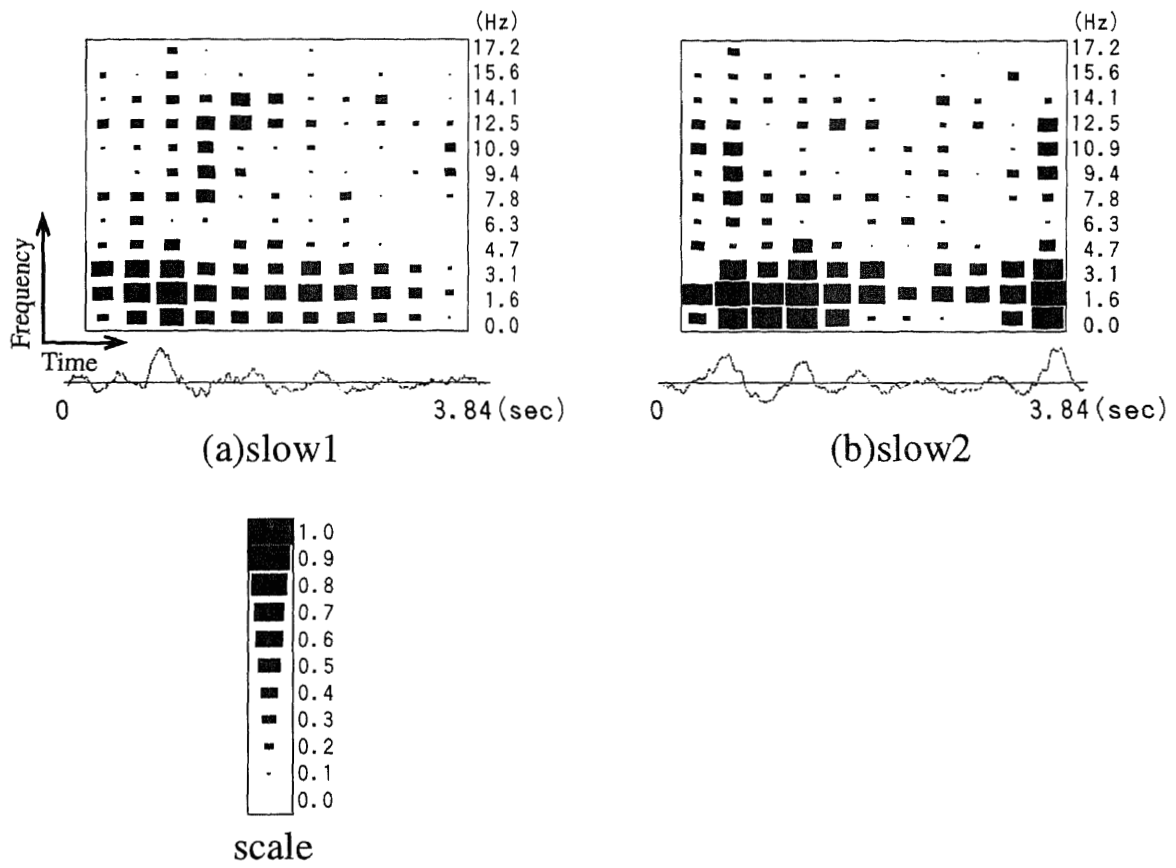


図 5-4 slow1 と slow2



$\alpha$  wave



hump



spindle



slow 1



slow 2



hump-train



background wave

図 5-5 SRNN の理想的な出力パターン




図 5-6 入力データマトリクスに占める slow wave の割合に対する SRNN の発火

## 5.2.2 眠段階判定部 (SSNN)

2 段目の SSNN は図 5-3 に示すように入力層が 5 ユニット、隠れ第 1 層と第 2 層がそれぞれ 35、20 ユニットで出力層が 5 ユニットの構造を持っており 1077 個の結合荷重に対して学習が行われた。第一段階で各睡眠段階の波形を入力して検出されたそれぞれ 5 種類の波形について、対応する判定ユニットの発火値  $y_{i,(k)}$  を 10 区間 (38.4 秒間) 分の和をとって得られる 5 つの係数

$$\mu_j = \sum_{k=1}^{10} y_{i,(k)} \quad (j=1, 2, \dots, 5) \quad (33)$$

を SSNN の学習データとした。ここで  $j$  は 5 つの特徴波を、 $k$  が判定区間のナンバーを示す。また判定区間の 38.4 秒間というのは、臨床医の多くが脳波記録用紙の見開きに相当する 20 秒以上の区間で睡眠段階の判定を行っていることを目安にしている。一般にあまり短い区間ではその中に含まれる特徴波の数が少なく正確な判定ができず、また逆に広くなった場合は判断の手掛かりが増えるが、広すぎると睡眠段階の細かな推移は捕らえ難くなるという問題が生じる。また脳波の性質は人によって特徴波の出現状況や睡眠段階の変化の仕方にかなり個人差があり、一意に最適な区間を定めるのは難しい。そのため医師が用いる区間の長さより大きく外れない範囲で、標本化周期 5msec と FFT に用いるサンプル数  $2^n$  との兼ね合いから 38.4 秒間とした。

学習では入力層に提示されたデータに対応する睡眠段階に応じ、出力層の各判定ユニットが発火するよう、バックプロパゲーションによって行われた。今回用いた睡眠段階は wake, stage 1, stage 2, stage 3, stage 4 の 5 段階で、SRNN と同様バックプロパゲーションにより、ネットワークの出力  $y_{j,c}$  と教師信号  $\overline{y_{j,c}}$  との 2 乗誤差の量がほぼ変化しなくなるまで繰り返して学習させた。それぞれの出力ユニットの理想的な発火パターンを図 5-7 に示す。学習データの長さは 668,160 ポイント (55 分 40.8 秒間) である。

学習時間は SRNN と SSNN のトータルで NEC の PC-9801RA を用いて約 7 時間程度かかった。



これらの睡眠段階判定システム全体のデータの流れを図 5-8 に示す。



wake



stage 1



stage 2



stage 3



stage 4

図 5-7 SSNN の理想的な出力パターン

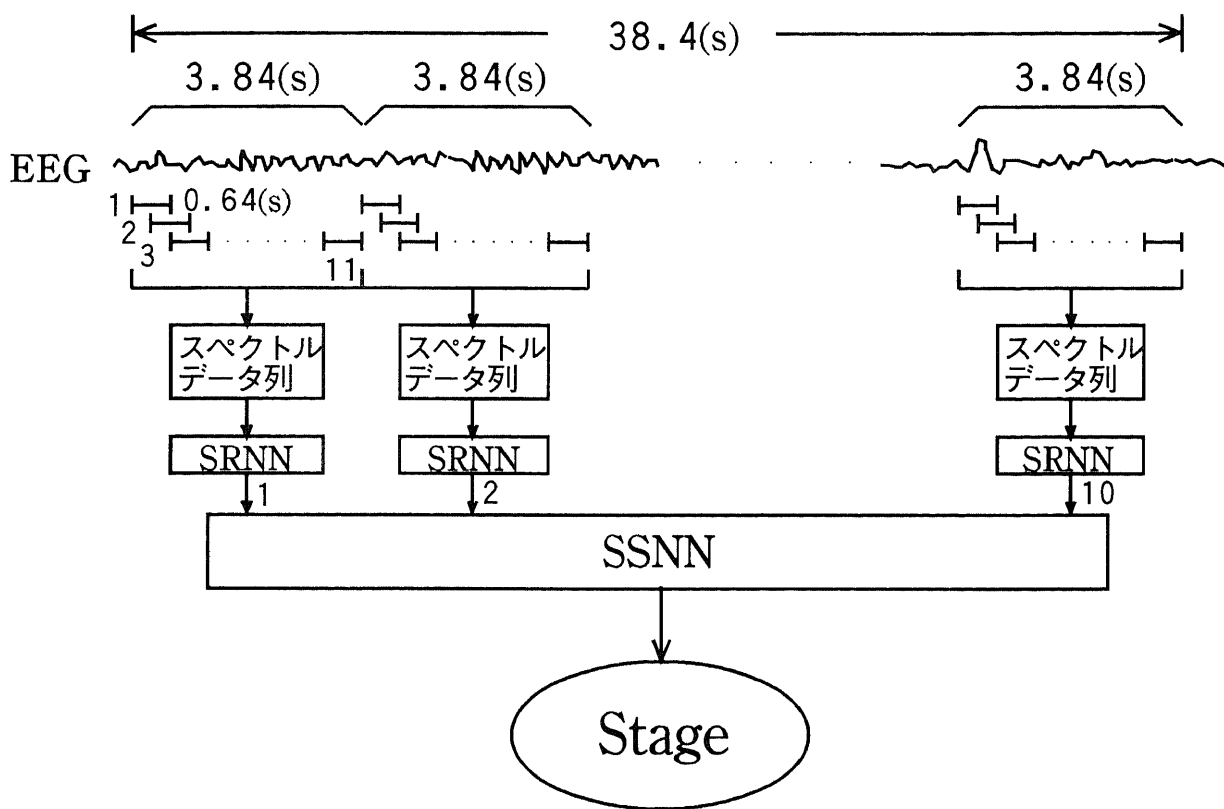


図 5-8 睡眠段階判定システムのデータの流れ

### 5.3 平均パワースペクトルのみによる方法

ここで提案したシステムとの比較のため、従来の長期間の平均的なスペクトル特徴量のみを手掛かりにした睡眠段階判定の方法についても実験を行った。スペクトルデータからの特徴抽出法には様々なものが考えられるがここでは、同じニューラルネットワークの学習を利用する方法と比較する。したがって本システムと同様、次式のように 10 区間に相当する 38.4 秒間のスペクトルデータ列 110 個につき各周波数で時間方向にとったすべての係数の和を入力データとする。

$$I_k = \sum_{t=0}^{109} C_{k,t} \quad (34)$$

ここで  $C_{k,t}$  はマトリクス上の係数、 $I_k$  は周波数  $f_k$  に対する入力データの値である。この入力データを図 5-9 に示すような階層型の全結合型のネットワーク（以下 ACNN（All Connecting Neural Network）と呼ぶ）に直接入力して睡眠段階判定を行った。この ACNN のユニット数は隠れ 1 層目に 37、2 層目に 32 で結合荷重数は SRNN と SSNN の結合荷重数の和と比較し小さくならないようにしてある。

データ作成において、38.4 秒間で平均を取ったのは、平均を取らない場合、入力層－隠れ第 1 層間のみで結合荷重数が我々の手法の場合を越えてしまう。また、これを無視して十分な荷重を与えたとしても、入力の係数が多いため学習時間が極端にかかり、また正しく学習が収束しない場合が多く実際的ではない。

学習の方法は我々の手法と同様に、入力として提示したデータに対応する睡眠段階を教師信号として与え、対応する判定ユニットが発火するようにバックプロパゲーション法で学習を行った。また、学習データは判定用データの前半 20% の部分を用いている。




図 5-9 ACNN の構造

## 5.4 睡眠段階判定結果

### 5.4.1 解析データ

本研究では、解析データに表 5-1 に示す D, E, F の 3 人の被験者のデータを用いた。

表 5-1 使用したデータの被験者の状態

	年齢	性別	医師の所見
D		男	正常
E	16	男	正常
F	28	女	正常

### 5.4.2 本システムの場合

初めに、5.2.1 で示した学習により調整された結合荷重を持つ SRNN を用いて睡眠脳波中から特徴波を検出した。判定用の睡眠脳波データは、学習データを作成したのと同じの被験者の 10/20 電極配置法における C<sub>3</sub> において計測したものである。2,595,840 ポイント（3 時間 36 分 19.2 秒）の脳波データを先頭から最後まで 768 ポイントずつに分割して 5.2.1 で示した方法でデータマトリクスに変換し、順に SRNN に入力して特徴波の検出を行った。図 5-10 は被験者 D のデータの解析で各特徴波に対する判定ユニットの発火値が一定以上となった時刻を示したものである。これを見ると、睡眠の開始から次第に睡眠段階が深くなるにつれて各段階に対応する特徴波が出現しているのが分かる。

次に 5.2.2 で示した方法で学習した SSNN を用いて睡眠段階の判定を行った。判定用データは学習データと同様、5.4.2 で述べた特徴波の検出に伴って得られる判定ユニットの発火値を、データの先頭から順に 10 区間ずつの和をとって求めた 5 つの係数である。これらの係数を SSNN に入力して睡眠段階の判定を行った。今回用いた D, E, F の 3 人の被験者の内、D の結果を図 5-11 (b) に示す。横軸は時間の経過、縦軸は睡眠段階を示しており、それぞれの記号は w (wake)、1 ~ 4 (stage 1 ~ stage 4) を表す。また図 5-11 (a) は医師による判定の結果である。

図 5-11 (a) の医師による判定と比較した場合の図 5-11 (b) の正答率  $\eta$  を次式により求め図 5-12 に示す。

$$\eta = \frac{\text{正しく判定された区間数}}{\text{ステージの全区間数}} \times 100[\%] \quad (35)$$




図 5-10 SRNN による特徴波検出の様子



### 5.4.3 平均パワースペクトルによる結果

図 5-11 (c) は比較に用いた ACNN によるスペクトルのみによる睡眠段階判定の結果である。正答率  $\eta$  を図 5-12 に示す。単純にパワースペクトルを用いた手法に比べ、本手法の方がすべての被験者のデータにおいて、より高い正答率が得られているのが分かる。


また、本手法と平均パワースペクトルによる手法とで、睡眠段階判定の正答率に関し、有意差の検定を行った。検定に使用したデータは、被験者 D について別々の時刻での 20 区間分の判定より得た正答率 (表 5-2) である。次に検定手法は 2 つの手法による正答率の平均に差がないという帰無仮説に対して有意水準 5% の t 検定を用いた。この結果を表 5-3 に示す。この結果より、正答率は SRNN+SSNN を用いた本手法の方が高い値が得られたが、有意水準 5% で仮説が棄却されるほどの有意差は見られなかった。

表 5-2 被験者 D の睡眠段階判定における別々の時刻での正答率


ACNN	SSNN
100.0	95.0
95.0	100.0
50.0	95.0
80.0	75.0
60.0	90.0
75.0	85.0
85.0	90.0
100.0	100.0
80.0	50.0
90.0	85.0
80.0	65.0
70.0	70.0
50.0	25.0
100.0	90.0
100.0	100.0
90.0	95.0

表 5-3 正答率の有意差検定の結果


	ACNN	SSNN
平均	81.6	81.9
分散	289.1	429.6
t	0.0466	
境界値	1.6991	
有意差	無し	



(a)



(b)



(c)

図 5-11 睡眠段階判定結果

(a) 医師による判定

(b) SRNN+SSNN による判定

(c) ACNN による判定




図 5-12 睡眠段階の正答率

## 5.5 考察

図 5-12 より、本論文で提案する方法は、長時間の平均的スペクトルを用いた従来のものに比べ誤りが少ないことが分かる。また図 5-11 を見ると、ここで示した方法では、従来の手法に比べ特に前半の部分で睡眠段階のより細かな変化に追従していることがわかる。これは、医師の睡眠段階判定の手順に従い本システムが、前段で SRNN を用いて各種特徴波の情報を抽出し、その出現パターンをもとに後段の SSNN により睡眠段階を判定するという構成をとることで、より実際に近い正確な判定が可能になったものと言える。しかし一方で、後半の比較的睡眠段階の変化が少ないところでは特徴波の細かな変化に影響されて医師による睡眠段階判定との差がでていいる。これは一般に医師による判定ではある時間区間の睡眠段階を判定する場合その区間の前後の睡眠段階も考慮することで前後に矛盾のない滑らかな睡眠段階づけが行われるが（文脈的判定<sup>(22)</sup>）、我々のシステムではまだそれらを考慮していないためと考えられる。この文脈的判定に関しては次章で示される。

## 5.6 まとめ

従来の自動睡眠段階判定の手法の多くは比較的長い時間についての平均的なスペクトルを用いて判定を行っていたが、実際の医師による判定ではそれぞれの睡眠段階における特徴波の有無を睡眠段階判定のための重要な指標にしている。このため本論文で提案したシステムは判定のための処理を 2 段階に分けている。

まず第一段階において判定する睡眠脳波中から医師が睡眠段階判定時に用いる各種特徴波を検出した。この検出処理には我々がこれまでに特徴波検出用のニューラルネットワークとして検討してきた SRNN を用いた。これによって、持続時間の長い特徴波からこれまで検出が難しかった持続時間の短い特徴波である hump まで検出が可能となった。

第二段階目では、第一段階目で検出された各種特徴波の有無の情報を用いてこれを SSNN によって実際の睡眠段階に対応させて判定を行った。これは脳波の比較的長時間の平均的なスペクトルを用いた従来の方法に比べ、個々の特徴波を判定に用いているという点でより医師の判定に近い方法であるといえる。我々のシステムと従来の方法とで睡眠段

階の判定結果を比較した結果、本システムを用いた方がより医師の判定に沿った正しい判定が行えることが確認できた。

また、我々の提案する方法では睡眠段階を判定するときに検出される特徴波の出現の様子から医師が直接目視による睡眠段階の判定や、疾患の診断などに役立てるなどの診断支援への応用が可能である。

今後はデータ作成時の各種パラメータの調整をすることなどにより、さらにより結果が得られる可能性がある。また睡眠段階判定の時の手掛かりとして stage REM の判定に不可欠な眼球運動を用いたり、筋電図を用いることが有効だと考えられる。また、従来の睡眠段階判定では背景波に含まれる周波数成分のみを用いることである程度の睡眠段階判定が可能なことから背景波中にもある程度の睡眠段階の情報が含まれているといえる。このためこれらの情報を用い特徴波データと組み合わせることにより正確な睡眠段階の判定を試みることが考えられる。さらに hump の検出結果を利用することで従来の判定方法では不可能であった stage 1a（抑制波期）,stage 1b（瘤波期）,stage 2a（瘤波・紡錘波期）,stage 2b（紡錘波期）等のより細かい睡眠段階の判定を行うことも考えられる<sup>(18)(19)</sup>。また睡眠段階の文脈的な判定に関して、さらに医師の持つ知識を利用することでより正確な判定が可能になると考えられるが、これらについても今後検討していきたい。

## 第6章 文脈的睡眠段階判定

### 6.1 文脈的睡眠段階判定の意義

これまでの提案されている睡眠段階の自動判定では主に脳波の長時間の平均パワースペクトルを用いている<sup>(22)(23)(24)(25)</sup>。一方、我々はこれまでにニューラルネットワークを用いて睡眠脳波中の特徴波を正確に検出する方法について検討し、持続時間の短い特徴波についても検出が行えるネットワークを提案してきた<sup>(2)(4)(5)(6)(7)(8)</sup>。この方法ではまず初めに睡眠特徴波判定ニューラルネットワークにより段階判定に必要な特徴波の検出を行い、次の第2段階で検出された特徴波を入力とするもう一つのニューラルネットワークにより睡眠段階判定を行っている。しかしながら特徴波を考慮する睡眠段階判定の場合、その区間でたまたま特徴波が出現しなかった場合や、振幅が低く捕らえにくい場合などに正確な判定ができないといった問題点が残されていた。実際に、医師は前後の段階からの流れによって矛盾のない判定を行っていることが知られている（文脈的判定）。

これまでいくつかの研究ではこの文脈的判定の規則を人為的に作成して行うことを試み、睡眠段階判定がより医師の判定に近いものになることが示されている<sup>(22)</sup>。しかしこの方法では規則作成という新たな作業が必要となる。また1つの規則のみでは医師間による文脈的判定方法の違いに対処できないといった問題がある。

本章ではこれまで我々が提案した特徴波のみによる睡眠段階の判定に対してさらに、文脈的判定用のニューラルネットワークを用いることにより前後関係の規則の作成作業の省略が可能であり、また医師間の違いにも対処できる文脈的判定法を考察し、それについて実験・検討した。その結果正答率が向上し、これまで他の方法を用いたいくつかの研究でも示されていたように文脈的判定の有効性が示されると同時に、適切な長さの文脈の考慮

が重要であること、またニューラルネットワークを用いることによる汎化性や他の手法で要求される規則作成を省略できることによる労力の低減の効果なども示された。

## 6.2 文脈的睡眠段階判定システム

一般に医師は、Rechtschaffen と Kales<sup>(1)(6)</sup>の示した、特徴波を手掛かりとする睡眠段階の判定基準に沿って診断を行っているが、我々のシステムでも、この判定基準に沿った診断を行うために、3段階に分かれた構成をとっている。図6-1にシステムの流れ図を示す。まず初めに前章までにおいて提案してきた特徴波検出ニューラルネットワーク SRNN (Sleep EEG Recognition Neural Network)<sup>(2)(4)(5)(6)(7)(8)</sup>を用いて脳波中から睡眠段階判定に必要な特徴波の検出を行う。次に第2段階において検出された特徴波を入力とする階層型の全結合型ニューラルネットワーク SSNN (Sleep Stage Diagnosis Neural Network)<sup>(3)(9)(10)(11)</sup>を用いて睡眠段階判定を行った。さらに本章ではこの特徴波のみによる判定結果に対して新たにニューラルネットワークを設けて、時間的に前と後の睡眠段階を考慮する文脈的判定を取り入れた。



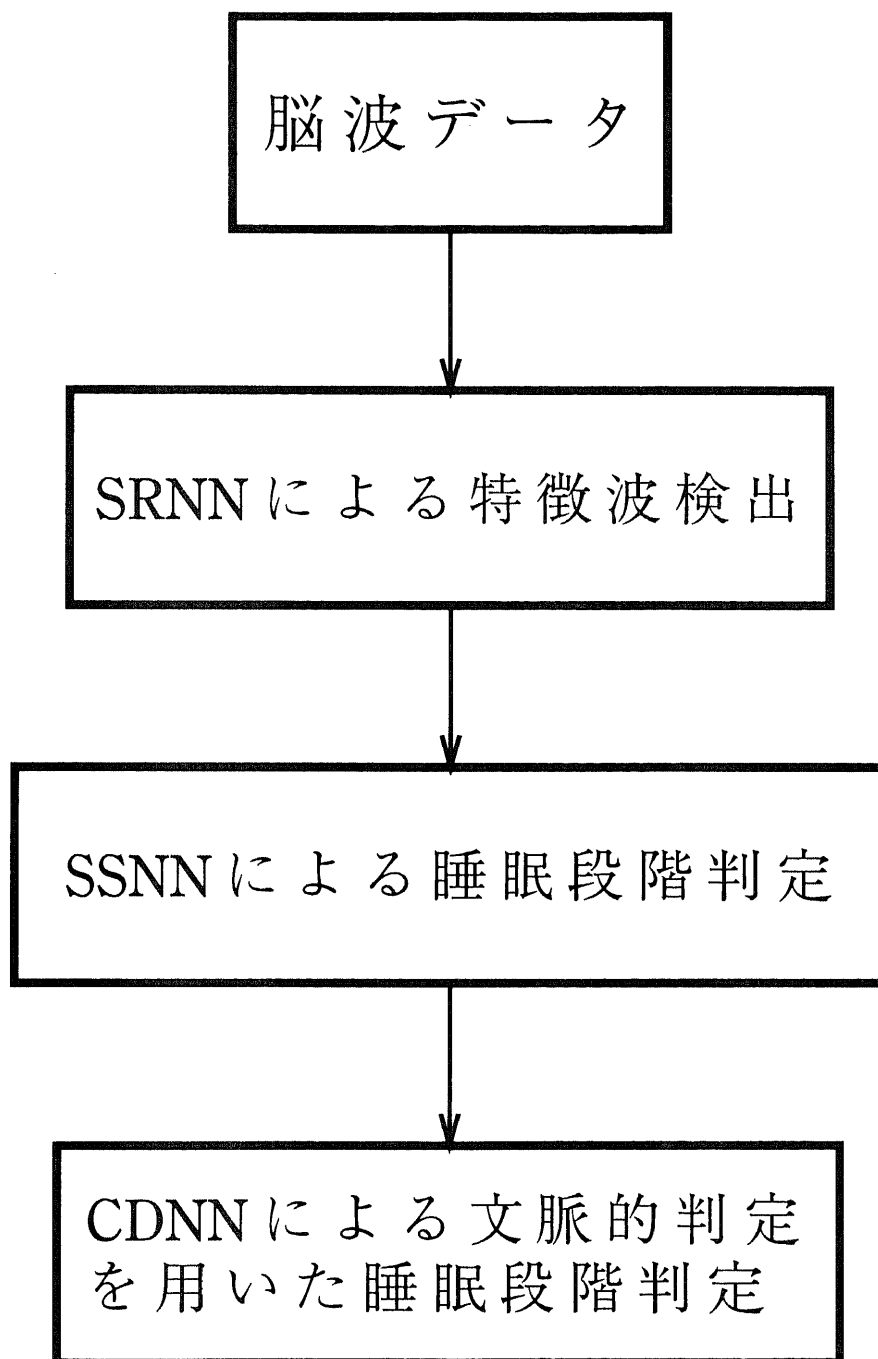


図 6-1 睡眠段階判定システムの流れ

### 6.2.1 前段部 (SRNN+SSNN)

睡眠脳波中の特徴波を検出するニューラルネットワークとして前章までで提案してきた SRNN を用いた。

次に第 2 段階目で睡眠段階判定に使用する SSNN は一般的な階層型の全結合型ニューラルネットワークをそのまま用いている。SRNN および SSNN の具体的な構成は前章で述べたとおりである。また、学習方法に関しても前章と同様の手法を用いており、特徴波検出を行う SRNN には hump の反例である hump train と背景波 background wave を加えた 7 種類の特徴波 (spindle, hump,  $\alpha$  波, slow1, slow2, hump train, background wave) を学習データとして与えた。学習に用いたデータの総時間長は 25 分間であり、判定用データと同一被験者のものを用いた。今回用いた被験者は前章で示した D, E, F の 3 人である。

ここで slow1 と slow2 はそれぞれ一つの入力データ内 (3.84 秒) に徐波成分が時間的に 20 ~ 50 % のものとそれ以上存在するものとで分類してある。これは、徐波の割合が 20 ~ 50 % を stage 3、50 % 以上を stage 4 としている Rechtschaffen の診断基準<sup>(16)</sup>に沿って決めたものである。

SRNN の学習は 5 種類の特徴波 (spindle, hump,  $\alpha$  波, slow1, slow2) が入力された場合にのみ出力層の 5 つの判定ユニットの内の対応するどれか 1 つが発火するように学習させた。

次に、睡眠段階判定の前処理を行う SSNN の学習では入力層に提示されたデータに対応する睡眠段階に応じ、出力層の各判定ユニットが発火するよう、バックプロパゲーションによって行われた。用いた睡眠段階は wake, stage 1, stage 2, stage 3, stage 4 の 5 段階である。学習データの長さは 200Hz サンプルングで 668,160 ポイント (55 分 40.8 秒間) である。これは判定用データの全ポイント数である 2,595,840 (3 時間 36 分 19.2 秒) の前半約 20% の部分に当たる。

### 6.2.2 文脈的判定部 (CDNN)<sup>(3) (12)</sup>

文脈的判定に用いたネットワークを図 6-2 に示す。以下ではこれを CDNN (Contextual

Diagnosis Neural Network) と呼ぶことにする。本研究で用いたネットワークは隠れ 1 層目と 2 層目に 10 ユニットずつを用いた階層型の全結合型ネットワークである。

入力層の横（時間）方向の長さは、判定する位置から前後に幾つ分の区間を考慮するかに応じて 3 ～ 15 の間で変化させた。また入力層の縦方向は睡眠段階に対応し、前段の SSNN による判定結果が入力として与えられる。

出力層は 5 つの判定ユニットのそれぞれが各睡眠段階に対応しており、判定ユニットのうち最も発火の大きいものをその時刻の睡眠段階とした。

入力データの形式は次の 2 つのものを用いた。

( I ) SSNN の判定ユニットの最も大きく発火している部分を 1、他を 0 とする方法

( II ) SSNN の出力値をそのまま入力する方法

( I ) の方法は特徴波による判定でいったん睡眠段階判定をした後、その睡眠段階の流れのみから前後関係の文脈を考慮する方法である。一方 ( II ) の方法は特徴波による睡眠段階判定法と文脈的判定の方法を完全に 1 つにして判定する方法である。この方法では、SSNN の出力の段階で判定があいまいなため発火値が小さかった場合なども考慮できることが考えられる。

学習の結合荷重の更新法にはバックプロパゲーション法を用いた。学習データは

( a ) 42 分 14.4 秒間

( b ) 1 時間 24 分 28.8 秒間

( c ) 3 時間 36 分 19.2 秒間

の 3 種類で変化させて行った。今回用いた睡眠脳波は全体で 3 時間 36 分 19.2 秒間であり、

( a )、( b ) はそれぞれ全データのはじめから約 20% と 40% を学習に用いた場合である。( c ) の場合は学習データと判定用データが一致した場合である。また、学習時の教師データには医師が目視によって行った睡眠段階判定結果を用いた。

全体を通しての学習時間 ( SRNN+SSNN+CDNN ) は、NEC のコンピュータ PC-9801RA を用いた場合約 7 ～ 9 時間であるが、判定にかかる時間は使用した 3 時間 36 分 19.2 秒間の脳波に対して約 2 分であった。

これらの睡眠段階判定システム全体のデータの流れを図 6-3 に示す。

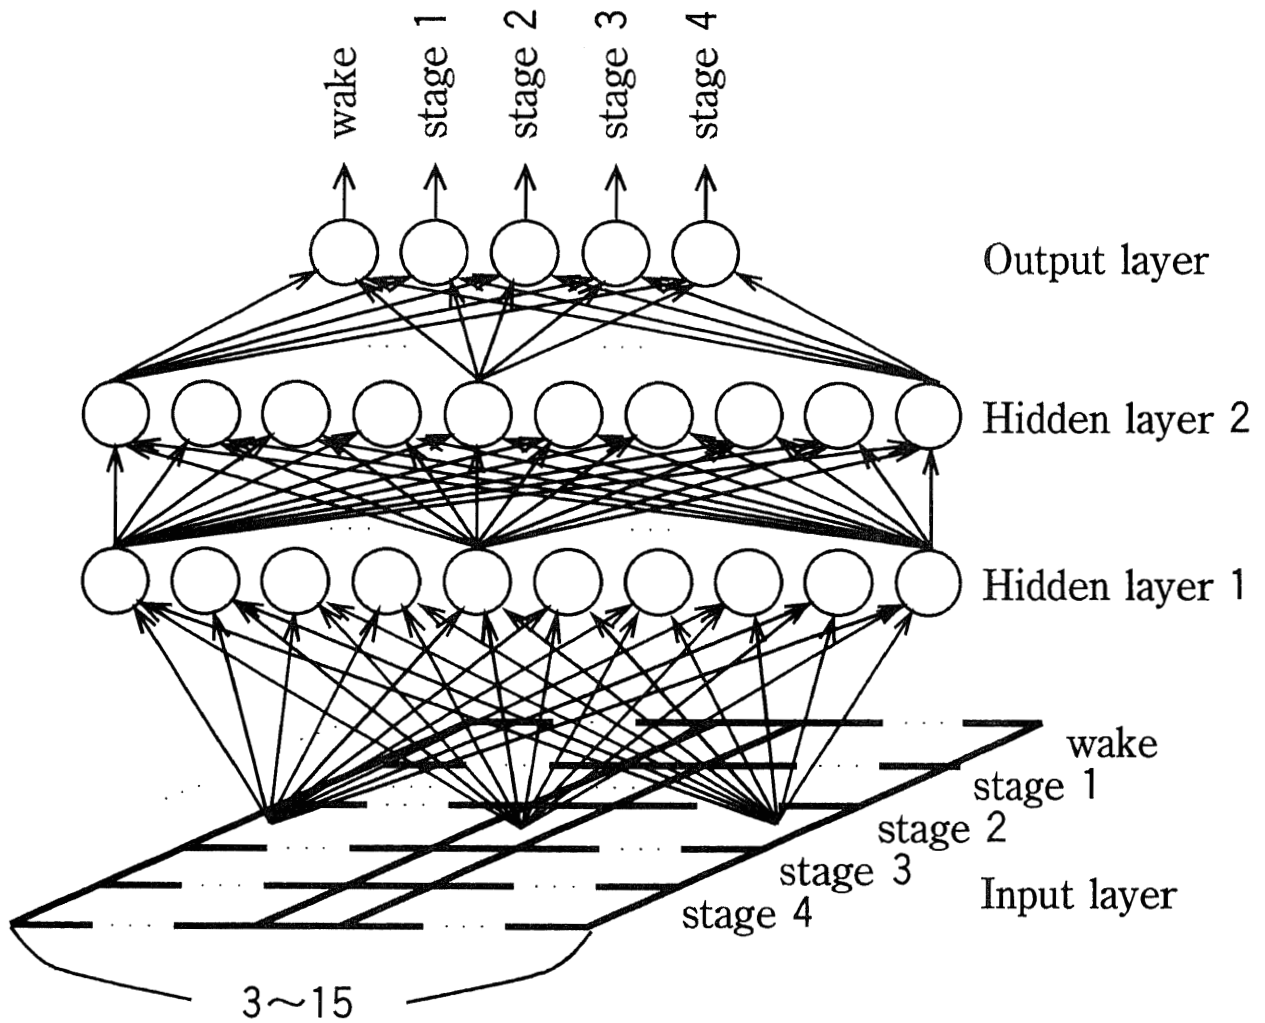


図 6-2 CDNN の構成

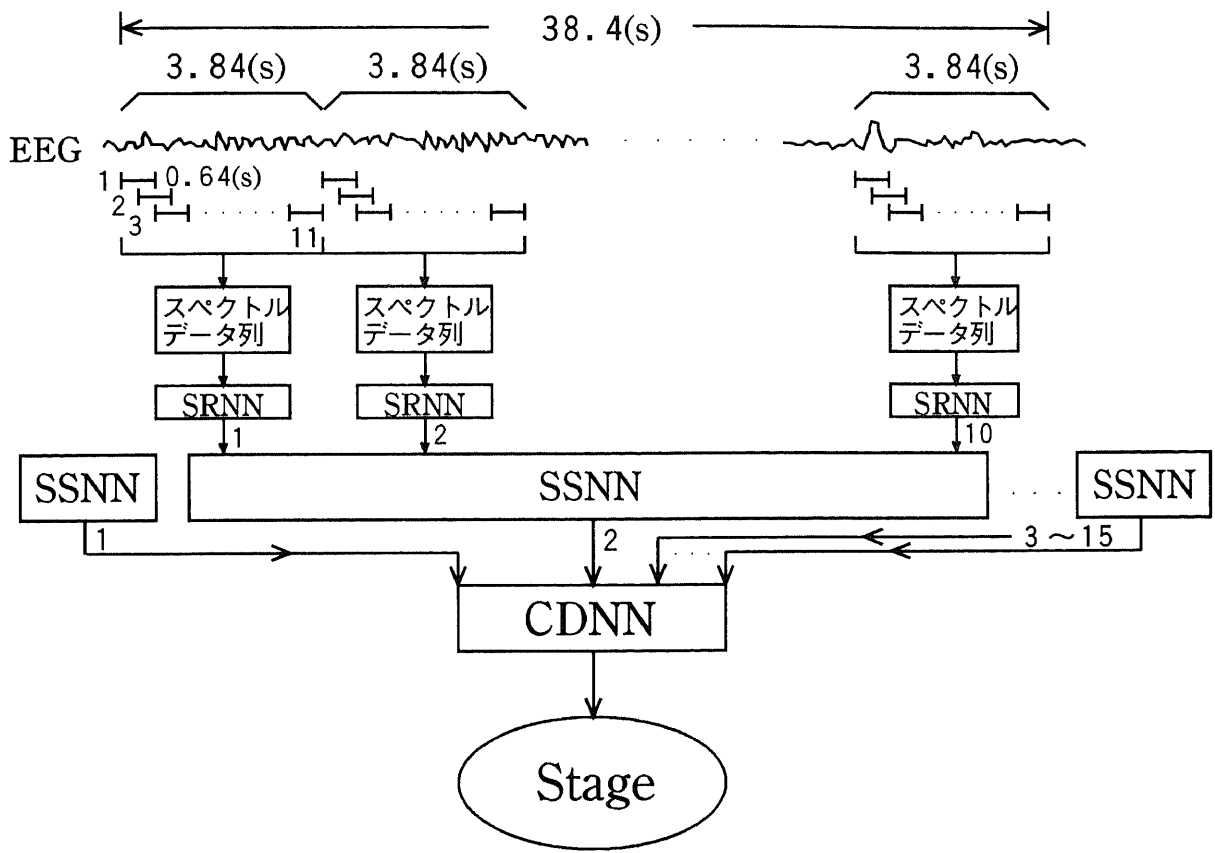


図 6-3 データ処理

## 6.3 目視による閾値設定による文脈的判定

比較のために次のような目視による文脈的判定の実験を行った。SSNNの5つの判定ユニットの発火値に対してそれぞれ閾値を設け、それより発火値が小さかった場合にはその前の睡眠段階と判断する、という極めて単純な前方向のみからの文脈的判定を、目視により少しずつ閾値の値を変化させながら全データでの睡眠段階の正答率を上げていくという方法で約3時間設定した。

## 6.4 文脈的判定結果

以下にSRNNによる特徴波検出結果、SSNNによる睡眠段階判定結果、及びCDNNによる文脈的判定結果について示す。

### 6.4.1 SRNNによる特徴波検出

6.2.1節で述べた学習のあと睡眠脳波中から特徴波を検出した。判定用データの長さは2,595,840ポイント（3時間36分19.2秒）である。

### 6.4.2 SSNNによる睡眠段階判定

6.2.1節で示した学習のあと、睡眠段階の判定を行った。結果を図6-4（b）に示す。横軸は時間の経過、縦軸は睡眠段階を示している。また図6-4（a）は医師による判定の結果である。この時の正答率は82.0%であった。なお正答率は次式で定義する。

$$\eta = \frac{\text{正しく判定された区間数}}{\text{ステージの全区間数}} \times 100(\%) \quad (36)$$

また、前章で示したACNNによる長時間の平均パワースペクトルのみを手掛かりに用い

た手法で得られた結果、及び目視による閾値の設定による文脈的判定の結果についてもそれぞれ図 6-4 (d) , (e) に示す。

### 6.4.3 CDNN による文脈的判定

文脈的判定の結果を図 6-5 に示す。横軸は文脈を考慮した区間数、縦軸は正答率を示す。また I -c で考慮する区間数が 11 の場合の睡眠段階の推移を図 6-4 (c) に示す。

また、CDNN を用いて文脈的判定を行った場合と、SSNN の出力でそのまま睡眠段階を判定した場合とで、結果の有意差の判定を行った。検定のためのデータには、被験者 D について別々の時刻での 20 区間分の判定より得た正答率を用いた。この正答率を表 6-1 に示す。検定手法には文脈的判定前後の正答率の平均に変化がないという帰無仮説に対し有意水準 5% の t 検定を用いた。有意差の検定結果を表 6-2 に示す。この結果から、CDNN を用いることにより、有意差 5% で仮説が棄却されるだけの良い正答率が得られていることが分かる。

表 6-1 被験者 D の睡眠段階判定における別々の時刻での正答率

SSNN	CDNN
95.0	100.0
100.0	100.0
95.0	100.0
75.0	100.0
90.0	100.0
85.0	100.0
90.0	100.0
100.0	100.0
50.0	100.0
85.0	100.0
65.0	100.0
70.0	95.0
25.0	55.0
90.0	100.0
100.0	100.0
95.0	95.0

表 6-2 正答率の有意差検定の結果

	SSNN	CDNN
平均	81.9	96.7
分散	429.6	125.7
t	2.4931	
境界値	1.7139	
有意差	有り	



## 6.5 考察

I -a や II -a などに比べ I -b、II -b さらに I -c、II -c と学習範囲が広くなるに従って正答率が上がっているのがわかる。これは学習データが多くなるほど、その中に含まれるより多くの文脈的判定のパターンを学習できるためであるといえる。また、学習データが短い場合、文脈的判定を行う以前の結果より悪くなってしまっているところもある。これは、ニューラルネットワークはその性質から、学習していないパターンに対しては学習した内で似ているパターンと結び付けて判定をする<sup>(26)</sup>。このため実際には未知の文脈パターンについても未知とは判断せず、既知の文脈パターンの中で最も似通ったものに無理に結び付けて判定してしまうためと考えられる。

また I の場合より II の場合の方が全般的に正答率が高い。また文脈的判定の区間数に従ったグラフの上昇の度合いも安定している。これは、例えばその判定区間にはっきりとした特徴波が現れていなかったり含まれる特徴波の数が少なかったりといった理由により SSNN の出力の段階で確実な段階判定ができず、発火値が小さかった場合など、それを考慮して前後関係を優先的に扱った判定ができるためであると考えられる。I の場合は十分な発火が得られた場合とそうでない場合を同一視してしまう。そのため、全般的に正答率が下がり、また、文脈を考慮する区間を広げた場合でも、そこで似たパターンがでてくることがあれば、正答率が下がりグラフの上昇も不安定になると考えられる。

また文脈的判定を考慮する区間数を見た場合、全般的に区間数が大きくなるに従って正答率が上がっているのがわかる。これは区間数が大きくなるに従ってより複雑な文脈パターンについても学習できるようになるためであると考えられる。しかし一方で、区間数が大きくなればなるほど上昇の度合いが緩やかになっているのが読み取れる。このことから睡眠段階に含まれる文脈的關係は時間的に離れた部分になるほど次第に弱まっていくことがわかる。さらに区間数が大きくなるとそれに従ってニューラルネットワークの学習にかかる時間が長くなるという欠点もある。今回の実験では中間層のユニット数は固定としたが、この場合でも結合荷重数は、区間数が 3 の場合の 325 に対し区間数が 15 の場合 925 となり、それだけ学習時間が多くかかることになる。

また文脈的判定前の正答率が 82.0% であることから、これより良い正答率を文脈的判定

によって得るためには、十分な長さの学習データと適切な長さの判定区間数の決定、及び適切なデータ形式が重要であることがわかる。

また本手法の特徴としてニューラルネットワークを用いて文脈的判定のための規則の自動生成を行ったことが上げられる。目視による文脈的判定では約3時間かかって86.1%の結果が得られた。しかし無数にある閾値の値から最適な組み合わせを見つけるのは容易でなく、かなりの労力と時間が要求される。また後ろ向きの文脈的判定を考慮するなど処理が複雑になった場合や、より長い脳波データについて処理を行う場合などはさらにその設定は難しくなる。またあらゆる可能性の中から最適な文脈的判定のための規則の発見は容易ではない。

さらに医師によっても脳波の文脈的な見方は変わるためそのたびに新たな規則を見いださなければならない。一方、本手法では同様にSSNNの出力を直接使い、学習には全データを用いたII-cにおいて、最も悪い結果でも約20分程の学習時間で89.9%の正答率が得られている。

さらに、この文脈的判定の方式Iに関しては、SRNNによる特徴波検出やSSNNによる睡眠段階判定に比べ、振幅等の変化に左右されないため、他の被験者のデータにも比較的容易に適応できる可能性がある。そこで学習結果を他の被験者に適応した場合についても調べた。実験にはD, E, Fの三人の被験者のデータを用いた。また、学習データに含まれる被験者の数を一人の場合、二人の場合、三人の場合の3通りで変化させた。ここで用いた文脈的判定の方式はIで、学習には学習用データとして設定された被験者の全データを用い、文脈を考慮する区間数が11の場合である。結果を表6-3に示す。

表6-3から分かるように、学習データと判定用データの被験者が異なる場合、正答率は低いことが分かる。一方で、学習データに含まれる被験者が複数になった場合でも、学習した被験者に関してはかなり高い正答率が得られており、本人の学習データのみの場合に比べ正答率がさほど下がっていないことから、今後より多くの被験者が含まれる学習データを用いることにより、一つの学習結果から、未学習の被験者のデータに対しても適応できる可能性がある。

表 6-3 学習データと判定用データの被験者の数を変化させた場合の正答率

Subject of learning data	Correct rate(%)		
	Subject of test data		
	D	E	F
D	96.3	61.4	52.2
E	50.0	100.0	60.9
F	70.1	72.7	100.0
D,E	95.1	100.0	54.4
E,F	46.3	100.0	100.0
D,F	95.4	61.4	97.8
D,E,F	93.3	97.7	100.0
before contextual diagnosis	82.0	79.6	75.0

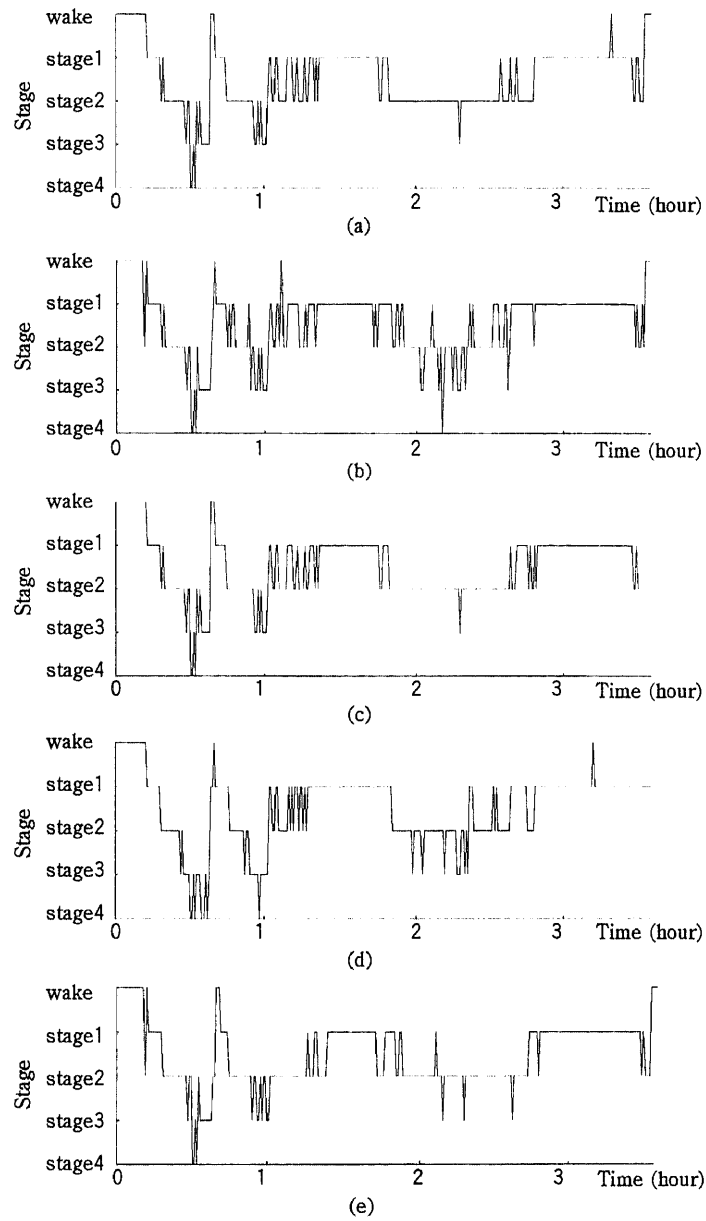


図 6-4 睡眠段階判定の結果

- (a) 専門医による判定結果
- (b) SRNN と SSNN を用いた段階での判定結果
- (c) CDNN を用いた文脈的判定を適用した判定結果
- (d) スペクトルのみを手掛かりにした睡眠段階判定結果
- (e) 目視による文脈的判定を適用した判定結果




図 6-5 文脈的判定の結果

(I) 入力値に SSNN の最大値を 1、他を 0 とした 2 値データを用いた場合

(II) 入力値に SSNN のアナログ出力値を用いた場合

## 6.6 まとめ

従来の自動睡眠段階判定手法の多くは比較的長い時間についての平均的なスペクトルを用いて判定を行っている。一方、本論文では前章までに提案したシステムで睡眠段階における特徴波の有無を睡眠段階判定のための重要な指標にすることでより高い正答率を実現した。さらに本章ではより正確な睡眠段階判定には前後の睡眠段階の流れから睡眠段階を判定する文脈的判定が重要であることを提案し、実験・検討を行い、その効果を示した。

本章で示したシステムでは、新たなニューラルネットワーク CDNN を設けることで文脈的判定を行った。その結果文脈的判定の性質として、学習時には十分な長さの学習データを用いる必要性和、判定時には適切な長さの区間数と適切なデータ形式でデータを与えることが重要であることがわかった。またニューラルネットワークを用いることで他の手法で要求される閾値の設定や規則作成における労力の低減が可能となり、さらに様々な医師の文脈的な見方に対する汎化性の効果も示唆された。

## 第7章 結論

### 7.1 本研究のまとめ

従来の自動睡眠段階判定の手法の多くは比較的長い時間についての平均的なスペクトルを用いて判定を行っている<sup>(22)(23)(24)(25)</sup>。一方、本論文で提案したシステムは睡眠段階における特徴波の有無を睡眠段階判定のための重要な指標にしている。またより正確な睡眠段階判定には特徴波の出現状況に加えて前後の睡眠段階の流れから判断する文脈的判定が重要である<sup>(22)</sup>。

本システムでは、睡眠段階判定の手法を3段階に分けて行うことで、より医師の判定と近い結果が得られることが確かめられた。

まず第1段階として、睡眠脳波中からの特徴波の検出を行った。この時特徴波検出用のニューラルネットワークとして、入力パターンに対する完全なシフトインバリエントと、孤立性の認識が可能であるSRNN (Sleep EEG Recognition Neural Network)<sup>(2)(4)(5)(6)(7)(8)</sup>を用いた。この手法により、従来一般的であった脳波の長期のスペクトルパターンを用いる手法や、音素判定において高い正答率の得られるTDNNを用いた方法、また線形予測係数に対する尤度比による検出手法などに比べ、特にtransientな波形(spindleやhump)に関してより高い正答率が得られた(有意水準5%のt検定で有意差が見られた)。また、本論文では、孤立性のある波形の検出にはXOR的な能力が必要と推測したが、このことについて、実際にSRNNの内部の結合荷重を解析することで、実際にXOR的な内部動作が行われていることも示した。また、従来のテンプレートマッチング手法が波形の継続時間に大きく影響されてしまうことなどについてもシミュレーション結果により明ら

かにされた。

次に第2段階目において、第1段階目で検出された睡眠脳波中の特徴波を用いて睡眠段階判定を行う方法について示した。この手法では、医師の手法を参考にして、一般的に睡眠段階判定に適したある程度の長さを持つ時間長での特徴波の出現状況を統合し、その係数を新たに設けた階層型の3層の全結合型ニューラルネットワーク SSNN (Sleep Stage Recognition Neural Network)<sup>(3)(9)(10)(11)</sup>に入力し、出力として対応する睡眠段階を得る手法について示した。従来一般的であった長期のスペクトルパターンのみを用いた手法と比較した場合、正答率に関して5%の有意水準で有意差が確かめられるほどの大きな正答率の改善は見られなかったが、用いた3人の被験者の脳波データに対し確実に従来の方法より高い正答率を得ることが確かめられた。

次に第3段階目として、より医師に近いインテリジェントな睡眠段階判定手法として、医師が行う文脈的な睡眠段階の判定手法をニューラルネットワークに取り込んで行うことを試みた。この文脈的判定の手法は実際に Rechtschaffen と Kales の示した睡眠段階判定の基準<sup>(16)</sup>に示されているものではないが、実際の医師の判定ではこの文脈的な考え方により、例えばその判定区間においてたまたまその段階を特徴づけるための特徴波が出現していなかった場合や、出ている振幅が非常に小さく見逃しが起こりやすい場合などに、これをカバーするために行われていると考えられる手法である。本論文では、第2段階目までに得られた睡眠段階の結果を、さらに新たに設けた階層型の3層の全結合型のニューラルネットワーク CDNN (Contextual Diagnosis Neural Network)<sup>(3)(12)</sup>に入力し、実際の医師の睡眠段階判定結果を教師信号として与えてやることで、医師の持つ文脈的な知識をニューラルネットワークに学習させることを試みた。この実験の結果、被験者の脳波の一部を学習させた場合でも、全体の脳波での判定結果は、文脈的判定を行わなかった場合に比べより高い正答率が得られることが確かめられ、文脈的判定の効果が示された。また実験の結果から、文脈的判定に関しては、十分な長さの学習データと、学習時間との兼ね合いを考えた適切な長さの判定区間数の決定、さらに適切なデータ形式が重要であることを示した。また本手法との比較として目視による単純な前方向からのみの文脈的手法を試み



たが、3時間かかって設定した閾値においても提案する本手法の結果に及ばず、本手法による文脈的判定のための規則作成のための労力の低減の効果も示された。また本手法で用いたニューラルネットワークには学習能力があるため、医師間の文脈的な見方の違いに対しても、学習を仕直すことにより簡単に対処できる。

## 7.2 今後の課題

今後の課題として、以下のような項目があげられる。

まず SRNN による特徴波の検出に関しては、学習方法の最適な手法の検討。特にバックプロパゲーションのニューラルネットワークの問題点として、学習が local minimum に陥ってしまうといったことの回避。またユニット数の最適な数を予測したり、学習に従って削除・付加することにより、適切なネットワーク構成を求め、実際の臨床の現場で問題となるであろう学習時間の短縮を行うこと。また、本論文で提案したシステムでは生体の解析で要求されるであろう突発波の出現時刻の正確な計測が不可能であること。実際の時系列波形での位相的な情報がパワースペクトルを用いることにより失われていることから、疾患の診断に要求される波形の positive、negative といった情報が捕らえられないことなどがある。そのため今後は入力データとして時系列のデータを用いる方法についての検討なども行いたい。また、単なるパワースペクトルを用いるのではなく、最近各方面で注目を集めている wavelet を用いた周波数解析により求めたパワースペクトルを用いることも考えられる。この wavelet による解析では周波数分解能が下がる代わりに時間分解能が上がるといった特性があり、transient な性質を持つ hump や spindle、さらにはてんかん波などの波を捕らえるのに有利である可能性がある。また、その他の大きなファクターとして特徴波の周りに存在する雑音成分 background wave の問題がある。この雑音成分のフロントエンド処理による除去手法の一つとして、現在、線形予測による定常成分の除去などを検討している。

また SSNN による睡眠段階判定に関しては、やはり睡眠段階を判定するためのより適切な判定区間長の設定の問題があるだろう。これはその判定区間で、睡眠段階を正確に判定

するための特徴波が存在しているように設定することが要求される。同時にこの問題は CDNN による文脈的判定との関連が考えられ、SSNN における判定と、その判定の誤りをカバーするための CDNN における考慮する文脈の適切な長さが重要である。

また CDNN では、この他に、必要とされる学習データ長や、様々な入力データ形式の検討などがある。

また本システムでの各段階での実験に共通して言えるのは、使用データ数が少ないということ、本論文中ではそれをカバーするため、システムの能力を示すシミュレーションや論理的考察を幾つか示してきたが、やはり今後データが集まり次第、より多数の被験者のデータにおいてある程度統計的な性質についても示すといった研究が考えられる。

さらに今後のアイデアとして、本システムで示した SRNN を用いて、特徴波を正確に捕らえることによる、感情の自動判定や、誘発電位と関連付けた脳における音声の認識機構の分析の研究などを考えている。

## 謝辞

本研究は椎名毅助教授のもと大学院の5年間において行われたものです。椎名先生には本研究を進めるにあたり信号処理の基礎から脳波解析の実際、さらには論文誌への論文の執筆に際してまで、公私共々様々な局面で、数多くの御指導、御助言を頂きました。ここに心より感謝の意を表するとともに厚くお礼申し上げます。

また、脳波計量解析研究所の斎藤陽一先生には研究者さらには医師の立場から臨床的見地に立って様々な御指導、御助言を頂きました。ここに心より感謝を表するとともにお礼申し上げます。

また、筑波大学の板橋秀一教授、並びに東京農工大学の伊東正安教授にはゼミ等での各種貴重な御意見や博士論文の執筆等においても様々な御指導を頂きました。心より感謝の意を表しお礼申し上げます。

さらに筑波大学の平井有三教授には、ブレインサイエンスセミナー等の数々の機会において、ニューラルネットワークの最新動向等について御教授頂き厚く感謝いたします。

筑波大学の寅市和男教授には今後脳波解析でも重要となるであろう Wavelet に関し、ゼミにおいて理論的見地から様々な事柄をご教授頂きました。ここに感謝の意を表します。

通商産業省工業技術院電子技術総合研究所の葛西直子主任研究官には Squid を用いた脳磁計測やその応用であるダイポール推定について詳しくご教授頂きました。また博士論文執筆に当たってはデータ採取のための脳波計をお貸しして頂いたり、様々なサポートを頂きました。以上の御指導に関し心より感謝の意を表するとともに、今後も脳波の研究を続けるに当たり、これまで同様に御指導ご鞭撻頂きますようよろしくお願い申し上げます。

また筑波大学の永井啓之亮教授には信号処理の専門家という観点から幅広く数々の有意義な御助言を頂いたことに対し、ここに感謝の意を表します。

筑波大学の佐々木公男助教授には、本論文に対して有意義な御助言を頂きました。ここに感謝いたします。

さらに脳波計量解析研究所の石川淑郎先生、石川史人先生、報徳会宇都宮病院臨床検査センターの阿久津恭一先生、(株)日本光電の原田元先生らには脳波データの提供を含め研究の様々な面でサポートを頂きました。ここに厚くお礼申し上げます。

また、法政大学の八名和夫教授、並びに東海大学の濱本和彦講師には 1995 年のカナダでの IEEE 大会において大変お世話になりました。ここに感謝の意を表します。

徳島大学の片山貴文助手には自ら考案した独自のニューラルネットワークを用いた脳波解析法について詳しく御教授頂くことで、新たな脳波解析法の動向を知ることができました。ここに感謝いたします。

最後に、研究に協力してくださった東京農工大学の竹村淳君、横山幸生君、並びに筑波大学の深見忠典君、今西なお美さんらの研究室の皆さんにも心より厚くお礼申し上げます。

## 参考文献

- (1) 横山 幸生, 島田 尊正, 竹村 淳, 椎名 毅, 斎藤 陽一, "睡眠脳波の主成分分析とニューラルネットワークによる特徴波検出", 電子情報通信学会論文誌 A, Vol. J76-A No.8, pp. 1050-1058, 1993
- (2) 島田 尊正, 椎名 毅, 斎藤陽一: 「ニューラルネットワークを用いた睡眠脳波のスペクトル時間推移パターン認識による特徴波の検出」, ME誌, 32, 3, 196 ~ 205 (1994)
- (3) 島田 尊正, 椎名 毅, 斎藤 陽一, "ニューラルネットワークによる睡眠段階の文脈的特徴を考慮した判定", 電気学会論文誌, Vol.115-C, 12, pp.1452-1459, 1995
- (4) T. SHIMADA and T. SHIINA: "Detection of characteristic waves, by neural network analysis of time-spectra pattern of sleep EEG", Proceeding of the 1994 ISNCR, 199 ~ 204 (1994)
- (5) T. SHIMADA and T. SHIINA, "Sleep Stage Recognition by Neural Network Analysis of Sleep EEG", Abstracts of the World Congress on Medical Physics and Biomedical Engineering, 8, 1994
- (6) T. SHIMADA and T. SHIINA: "Detection of Characteristic waves of sleep EEG by neural network analysis", in Proc. IEEE Int. Conf. Biomed. Eng., No. 00823 (1995)
- (7) 島田 尊正, 竹村 淳, 横山 幸生, 椎名 毅, 斎藤 陽一: 「ニューラルネットを用いた睡眠脳波の状態判定」, 信学会秋季大会論文集, D-83 (1992)
- (8) 島田 尊正, 竹村 淳, 横山 幸生, 椎名 毅, 斎藤 陽一, "ニューラルネットを用いた睡眠脳波の状態判定", 第6回日本ME学会秋季大会論文集, 2-H-4, 1992
- (9) 島田 尊正, 竹村 淳, 横山 幸生, 椎名 毅, 斎藤 陽一: 「ニューラルネットを用いた睡眠脳波の状態判定(第2報)」, 日本ME学会「MEにおけるニューロ情報処理技術研究会(第3回)」報告集, 21 ~ 24 (1993)
- (10) 島田 尊正, 椎名 毅, 斎藤 陽一, "脳波のニューラルネット解析による睡眠深度の推定", 日本ME学会専門別研究会「MEにおけるニューロ情報処理技術研究会」, 第7回日本ME学会秋季大会論文集, 1-2-9, 1993
- (11) 島田 尊正, 椎名 毅, "睡眠脳波の時間一周波数パターンによる特徴波の検出", 電気学会医用・生体工学研究会, MBE-93-29, pp. 11-16, 1993
- (12) 島田 尊正, 椎名 毅, 斎藤 陽一, "ニューラルネットによる脳波特徴波検出と睡眠


段階の判定", 日本ME学会春季大会, 030, 1995

- (13) 江部 充, 本間 伊佐子: 「図解脳波テキスト」, 7 ~ 35, 文光堂 (1989)
- (14) 斎藤 正男, 鈴木 宏哉監訳, "クリニカル エンジニアリング<上巻>", コロナ社
- (15) 大熊 輝男, 松岡 洋夫, 上埜 高志, "脳波判読 step by step 入門編", 医学書院
- (16) A. Rechtschaffen and A. Kales (清野茂訳): 「睡眠脳波アトラス」, 医歯薬出版 (1972)
- (17) 瓜谷 富三, "分かりやすいME", 産報出版
- (18) 塩月正雄, 市野義夫: 「睡眠と脳波 (第1報) 終夜自然睡眠の脳波」, 日本外科学会雑誌, 55, 322 ~ 331 (1954)
- (19) 塩月正雄, 市野義夫: 「睡眠と脳波 (第2報) 脳波による終夜睡眠の型」, 日本外科学会雑誌, 55, 348 ~ 353 (1954)
- (20) 藤森: 「脳波の臨床的簡易分析法としてのヒストグラム法とその臨床応用、脳波分析とその応用」, 医学書院 (1957)
- (21) 堀田 素志, 松浦 弘毅, 金 英道, "ニューラルネットワークによる睡眠段階判定の試み", 第20回日本脳波・筋電図学会学術大会予稿集, 378, p221, 1990
- (22) 星宮 望, 石井 直宏, 塚田 稔, 井出 英人: 「生体情報工学」, 91 ~ 131, 森北出版株式会社 (1988)
- (23) J. C. Principe and J. R. Smith: "SAMICOS—A Sleep analyzing microcomputer system", IEEE Trans. Biomed. Eng., BME-33, 10, 935 ~ 941 (1986)
- (24) J. C. Principe, S. K. Gala and T. G. Chang: "Sleep staging automaton based on the theory of evidence", IEEE Trans. Biomed. Eng., BME-36, 5, 503 ~ 509 (1989)
- (25) N. Schaltenbrand, R. Lengelle, and J. P. Macher, "Neural Network Model: Application to Automatic Analysis of Human Sleep", Computers and Biomedical Research 26, pp.157-171 (1993)
- (26) 中野 馨: 「ニューロコンピュータの基礎」, 66 ~ 76, コロナ社 (1990)
- (27) (社) 日本工業技術振興協会ニューロコンピュータ研究部会編, "ニューロコンピューティングの基礎理論", 海文堂
- (28) F. Rosenblatt, "Principles of Neurodynamics", Washington, D.C., Spartan, 1961
- (29) Richard. P. Lippmann: "An introduction to computing with neural nets", IEEE ASSP Mag., 4 ~ 22, Apr. (1987)

- (30)Lodewyk F. A. Wessels, E. Barnard, "Avoiding False Local Minima by Proper Initialization of Connections", *IEEE Trans. neural networks*, vol. 3, pp. 899–905, November 1992
- (31)D. E. Rumelhart, G. E. Hinton and R. J. Williams, "Learning internal representation by error propagation", *Parallel distributed processing*, D. E. Rumelhart, J. L. McClelland and the PDP Research Group ed., 318 ~ 362, MIT Press ( 1986 )
- (32)R. O. Duda and P. E. Hart, "Pattern Classification and Scene Analysis", John Wiley & Sons, New York (1973)
- (33)A. Waibel, T. Hanazawa, G. Hinton, K. Shikano, & K. Lang : Phoneme recognition using time–delay neural networks, *IEEE Trans. Acoust., Speech, Signal Processing*, 37, 328/339 (1989)
- (34)A. Waibel, H. Sawai, K. Shikano, "Modularity and Scaling in Large Phonemic Neural Networks", *IEEE Trans. signal processing*, vol. 37, pp.1888–1898, December 1989
- (35)T. J. Sejnowski and C. R. Rosenberg "Parallel networks that learn to pronounce English text," *Complex Systems*, 1, 145–168, 1987
- (36)E. McDermott, S. Ktagiri, "LVQ–Based Shift–Tolerant Phoneme Recognition", *IEEE Trans. signal processing*, vol. 39, pp. 1398–1411 , June 1991
- (37)George R. Doddington, "Speech recognition:turning theory to practice", *IEEE spectrum*, pp. 26–32, September 1981
- (38)Nassim N. Chit,John S.Mason, "Complex Chebyshev Approximation for FIR Digital Filter", *IEEE Trans. signal processing*, vol. 39, pp. 49–54, January 1991

# 著者紹介

島田 尊正 (Takamasa SHIMADA)



1996年筑波大学大学院博士課程工学研究科電子・情報工学専攻修了。本書はそのときの学位論文。工博。医用電子工学の分野において、主に脳波の解析手法とその医療応用の研究に従事。他にニューラルネットワークを専門とする。電子情報通信学会、日本ME学会、IEEE等の会員。