

マセマティカル・モルフォロジーを用いた  
脳波信号解析に関する研究

山口 朋成

# 目次

<b>1</b>	<b>序論</b>	<b>3</b>
<b>2</b>	<b>マセマティカル・モルフォロジーによる信号解析手法</b>	<b>8</b>
2.1	マセマティカル・モルフォロジー	9
2.1.1	順序統計フィルタ	9
2.1.2	基本演算	11
2.1.3	多値のモルフォロジー	11
2.1.4	モルフォロジカル・フィルタ	12
2.1.5	モルフォロジカルフィルタの特性	15
2.2	モルフォロジカル・パタンスペクトル	17
2.2.1	パタンスペクトル	17
2.2.2	時系列信号のパタンスペクトル	18
2.2.3	音声信号に対する適用	20
2.3	モルフォロジーを用いた時間周波数解析	23
2.3.1	多重解像度解析	23
2.3.2	モルフォロジカル・ハール・ウェーブレット	25
2.3.3	冗長性モルフォロジカル・ウェーブレットと局所パタンスペクトル	25
2.3.4	音声信号に対する適用	27
2.3.5	睡眠時脳波信号に対する適用	30
2.4	モルフォロジカルフィルタのフィルタ設計	33
2.4.1	超楕円型構造関数によるモルフォロジーマルチレベル分解	33
2.4.2	短時間モルフォロジカルフィルタ分離	37
2.5	フーリエ解析との対応関係	38
2.6	結言	40
<b>3</b>	<b>BCIシステムにおける脳波信号解析</b>	
	～特徴量抽出と変動解析～	<b>42</b>
3.1	脳波概説	42
3.1.1	脳波計測手法	42
3.1.2	事象関連電位	43
3.2	事象関連電位を利用したシステム	44
3.2.1	視覚性オドボール課題実験(1)	45
3.2.2	聴覚性オドボール課題実験(2)	48
3.2.3	事象関連電位を用いた文字入力システム(3)	50
3.3	動作想像時の脳波変動を利用したシステム	51

---

3.3.1	右手左手動作想像実験 ( 4 )	52
3.3.2	手足動作想像実験 ( 5 )	57
3.3.3	フェールセーフ機構を備えた BCI システム ( 6 )	62
3.4	光誘発電位を利用したシステム	69
3.4.1	SSVEP を利用した注視点検出システム ( 7 )	69
3.4.2	T-VEP を利用した単一光源注視パタン検出システム ( 8 )	72
3.4.3	T-VEP を利用した多光源注視パタン検出システム ( 9 )	75
3.5	結言	81
<b>4</b>	<b>結論</b>	<b>83</b>
	謝辞	<b>86</b>
<b>A</b>	<b>信号からの特徴抽出手法</b>	<b>94</b>
A.1	自己回帰モデルを用いたパタン識別手法	94
A.1.1	ベイズ判定法	94
A.1.2	自己回帰モデル	95
A.1.3	AR スペクトル	98
A.2	自己組織化マップ	98
A.3	独立成分分析	99
A.3.1	混合モデル	100
A.3.2	FastICA アルゴリズム	100
A.3.3	不定性問題の解決	101

# 1 序論

デジタル信号処理は、通信情報、計測制御、画像、ロボット、医療などの様々な分野で応用される基本的な技術である [1]. 特に、線形デジタル信号処理は、計算機の進歩とともに、デジタル信号処理の中心的な分野として確立されてきた。これは、数学的基礎を持つ理論体系を有していることと、理論の実装が容易であることなどが理由として挙げられる。これに対して、非線形デジタル信号処理は、理論的な複雑さや解析の難しさ、計算量の多さを理由として線形デジタル信号処理ほど広く利用されているものでないが、線形では表現できない特徴を抽出できるため、様々な手法が考えられてきている [2][3].

非線形デジタル信号処理として、最も有名なものの一つに Turkey によって提案されたメディアンフィルタがある [4]. これは、線形フィルタでは不可能であった信号のエッジ保存とパルス性雑音除去を同時に達成できるものであるが、細かに変動する成分を歪めてしまう問題や、ガウス性雑音の除去能力が乏しい問題がある。一方で、メディアンフィルタの一般型である順序統計フィルタを適切に設計すること、または拡張することでこのような弱点を防ぐことができる。たとえば、Brownrigg が提案した荷重メディアンフィルタは、重み付けられた細かな変動も保持することができ、線形フィルタとの組み合わせである  $\alpha$ -トリムド平均値フィルタは、パルス性雑音とガウス性雑音両方に対する雑音除去性能があることが知られている [5][6]. このように、非線形デジタル信号処理は、処理に特有の弱点を有するが、適切な調整を行うことで線形デジタル信号処理よりも有用なツールとして扱うことができる [7][8]. また、順序統計フィルタの一種である Matheron と Serra によって提案されたマセマティカル・モルフォロジーは、構造要素と呼ばれる集合と信号との非線形演算で信号から所望の形状を抽出・除去することができる非線形フィルタであり、線形手法であるフーリエ変換と類似した数学的枠組みを持っている [9][10][11][12][13][14]. 例えば、フーリエ級数展開はモルフォロジーのスケルトンに対応し、フーリエ変換は傾き変換に対応する [15].

本研究においては、雑音が混入されたデジタル信号から線形・非線形のデジタル信号処理手法を利用・応用して、その信号が有する特徴を抽出する手法の検討を行うことを目的とする。特に、近年活発に利用や実装に関して研究が行われているマセマティカル・モルフォロジーにより構成されるモルフォロジカルフィルタについて、そのフィルタ特性を決定する構造関数の設計方法について検討を行う [16].

構造関数の決定法としては、浅野らの雑音で劣化したデジタル画像に対して PGPC (Primitive, Grain, and Point Configuration) モデルに基づく評価関数を用いて構造関数の最適化を行う手法や、西田の脳波信号から認知活動に関する突発的な電位変化を抽出する目的で、構造関数を 2 次関数で設計する手法がある [17][18][19][20][21]. しかしながら、これらの手法は雑音の混入割合やデジタル信号・画像に含まれる特徴についてある程度の実験的知識が必要であり、情報が未知の信号から特徴を抽出するためには、別の解析手法が必要である。本研究においては、信号に対する情報が未知あるいは不足している時系列信号から本質的な情報を抽

出することを目指し、さまざまな解析手法やその枠組みを利用する。

例えば、定常的な特性を持たない時系列信号に対しては、自己回帰モデルに基づく同定やフーリエ解析のように信号の定常性を仮定した手法よりも短時間フーリエ変換 (short time Fourier Transform: STFT)、ウェーブレット変換 (Wavelet Transform: WT) のような時間周波数解析を用いる方が特徴抽出に適切である [22][23][24][25][26]。特に、WT は、信号が有する特徴を時間周波数領域において疎 (スパース) に表現するため、特徴の特定に有効な手法である。これは、短い区間において値を持つ一つの基底関数 (マザーウェーブレット) を用意し、それを拡大・平行移動したものと対象信号との内積によって得られる。また、信号に含まれるであろう特徴がある程度既知である場合、複数のマザーウェーブレットを用いて内積を求めらることで、より特徴をスパースに表現する修正ウェーブレット (Modified Wavelet Transforms) と呼ばれる方法もある [27]。

WT は、情報の冗長性が高く、計算時間も多いため、信号処理・画像処理への適用においては、WT を簡略化した離散ウェーブレット変換 (Discrete Wavelet Transform: DWT) が主に用いられている。DWT は、信号とマザーウェーブレットの内積処理によって得られる信号系列に対してダウンサンプリングを行い、この系列に対してあらかじめ定めた分解レベルまで処理を繰り返すことで得られ、これは分解系列の情報に冗長性が無いが、シフト不変性が失われる [28]。逆に、窓関数をアップサンプリングすることによって多重解像度解析を実現する定常性ウェーブレット (Stationary Discrete Wavelet Transform: SWT) は、信号情報に冗長性が生じるが信号の時間変化を詳細に解析することができる [29]。また、複素数型マザーウェーブレットを利用した展開を行うことで、入力信号の位相情報を保持する手法として複素ウェーブレットが提案されており、これもシフト不変性が保たれる [30]。信号に最も適合するマザーウェーブレットで信号を展開するマッチング追跡 (Matching Pursuits: MP) 法は、マザーウェーブレットが信号の有する特徴を表現するため、信号からの特徴抽出手法として有効に利用でき、生体信号に対する解析など様々な応用も行われている [31][32][33]。フーリエ解析と類似した枠組みを有するモルフォロジー解析も、同様に時間周波数解析へ拡張することができる。例えば、DWT のハールウェーブレット (Haar Wavelet: HW) に対応するものとして、モルフォロジカルハールウェーブレット (Morphological Haar Wavelet: MHW) が提案されている [34]。これは、多重解像度解析において画像に含まれる形態情報を歪めることが少ないため、画像からの形状検索や動画像圧縮などに用いられている [35][36][37]。また、パタンスペクトルは、フーリエ解析におけるパワースペクトルに相当する特徴抽出手法である [38]。

本研究においては、時系列信号からの特徴抽出として、パタンスペクトルの時間周波数領域への拡張と、フィルタ設計による信号分離手法からなる特徴抽出手法を提案する。これらの手法の特徴として、短時間パタンスペクトルは、スペクトル構造に非対称性があり、対象とする信号の振幅の極性も保持し、また、エッジやパルスなど線形手法では解析が困難であった特徴に関しても効果的に抽出が行うことができる。また、フィルタ設計による信号分離手法においては、設計において推定される構造関数が対象とする信号の形態成分を有すること

から，信号の構造を推定する一手法となることが示される [39][40][41]．

これらの手法の特性は，シミュレーションで確認するとともに，実環境で計測された時系列信号に対しても適用することで特性を確認する．使用する時系列信号は，音声信号と脳波信号の2種類とする．音声信号解析は，古くから研究されているテーマであり，様々な信号解手法がこの分野で提案されている [42][43][44]．脳波信号解析は，比較的歴史が浅いが，システムへの実装や利用に関して近年活発に研究が行われている．

音声信号解析は，1939年にベル研究所の Dudley が発明したボコーダをはじめに，印刷技術や録音技術の発達に伴い多くの研究がなされてきた．音声工学には主に音声波から言語情報を取り出す音声認識と，言語情報を入力として音声を作り出す音声合成とに分けられる [45][46]．さらに音声には，言語情報の他に個人性情報や，話し手の感情を表現する情報も含まれ，これらも研究の対象として扱われており，音声信号を分析してこれらの情報を表す種々の特徴パラメータを取り出し，それに基づいて合成や認識などを行うことを音声情報処理と呼ぶ．本研究においては，線形・非線形の信号解析手法の実システムへの実装を目的として，音声認識とりわけ言語情報の抽出に焦点を当てる．

音声情報処理は，聴覚器官である蝸牛が入力音声波の周波数に応じて神経細胞を発火させ脳へ情報伝達を行うことから，また，音声の生成過程が Kelly の声道モデルのようにいくつかデジタルフィルタの結合で上手く近似できることなどから，フーリエ変換，ウェーブレット変換，線形予測法 (Linear Predictive Coding: LPC)，ケプストラム法 (Cepstrum) など周波数解析を基礎とした手法が主流となっている [47] [48][49]．これらは，外部からのノイズの無い理想的な計測環境においては優良な認識を行うことができるが，実環境のようにパルス性雑音が入る環境においては周波数情報が埋もれる問題がある．また，母音情報を識別する上で重要な特徴量となるフォルマントに関する情報も，線形手法では，高調波成分が出現し誤認識を引き起こす危険性がある [50]．このような問題に対しては，前述の理由から非線形フィルタが特徴抽出に有用である可能性がある．本研究においては，音声の基本的性質，知覚過程について述べ，非線形手法を用いた雑音の除去や，信号に含まれる特徴の抽出方法などについて検討を行う．

脳波 (Electroencephalogram: EEG) が脳内の状態によって変化することは，脳波の発見者である Berger によって 1929年に報告され，1933年に Adrian によって追試・確認が行われて以来，病的疾患の診断のみならず，脳のメカニズムを解明する上で興味のある研究対象として，多くの研究者によって研究が行われている．例えば，光刺激や音刺激によって，人間の脳波には視覚誘発脳波や聴覚誘発脳波等の応答波形が出現することや，数種類の刺激を与え選択反応を義務付けることによって事象関連電位と呼ばれる電位変化が観測されることが知られている．また，手足を動かそうとする場合，脳波に運動準備電位やそれらに関連する事象関連電位が出現し，特に事象関連電位に関しては，実際に手足を動かさなくても意識するだけで出現することも知られている [51][52]．また，脳波，眼球運動 (Electro-oculogram: EOG)，筋電位図 (Electromyogram: EMG) からの情報をもとに，ヒトの睡眠状態を覚醒段階 (Stage W) と睡眠

段階 (Stage 1~4, REM) の 6 段階に分けることができる [53][54].

特に近年においては, 人間の認知過程, あるいは動作決定過程における脳内活動の変動状況に関する情報を抽出することにより, 人間が何をしようとしているのかを推測して, インターフェースとして利用する脳コンピュータインターフェース (Brain Computer Interface: BCI) に関する研究が世界的に進められている [55][56][57]. 既に, 脳内に埋め込まれた電極から得られる脳波 (Electrocorticogram: ECoG) を利用したインターフェースが, 実現されている [58]. 頭皮上へ貼られた電極から得られる脳波を利用した非侵襲型のものとしても, 右手・左手動作想像時の脳波変動を識別することによってディスプレイ上のカーソルを上下・左右へ制御できるシステムや, 認知活動に関連した事象関連電位を検出することによってディスプレイ上に表示した文字の選択を行うシステムの開発が行われている [59][60][61]. また, 点滅光の周波数に同期して出現する定常視覚誘発電位 (Steady State Visual Evoked Potentials: SSVEP) を用い, 画面上に表示された 4 つのチェッカーボードを刺激として画面内のコースに沿って車を走らせるシステムを開発されている [62]. 我々の研究グループにおいても, 種々の既存の信号処理手法や新たに独自に開発した解析手法を利用して, 脳波から人間の意思を推定し, BCI へ利用する研究を進めてきており, 右手・左手動作想像時の脳波変動を識別して SONY 製犬型ロボット (AIBO) を操作するシステムを構築し, 熟練した被験者が動作想像するだけで, AIBO を八の字状に操作できることを確認してきている [63][64][65][66][67].

BCI システムを実現する脳波の事象関連電位は, システムに応じて若干の違いが見られるが, 大きく分けて, 外因性成分, 内因性成分の 2 種類の要因と, 電位変化 (誘発電位変動), 周波数的変化 (周期的変動) の 2 種類の変動に分類できる. 外因性成分は, 視覚刺激・聴覚刺激などの外的刺激に応じて出現する応答成分であり, 内因性成分は, 動作想像や認知活動などの内的な心理変化に応じて出現する応答成分である. 制約条件の少ない BCI システムを実現するためには, 外的刺激を必要としないシステムが望ましい. しかしながら, 内因性の周期的変動として代表的な動作想像によって生じる事象関連脱同期・同期 (Event Related Desynchronization/Synchronization: ERD/ERS) を利用したシステムは, ユーザがシステムを利用できるまでに 10 日近くのトレーニングを必要とする問題がある. また, 内因性の電位変化である認知活動に伴う事象関連電位を利用した脳波タイプライタシステムにおいては, トレーニングは必要としないが, 認知活動時に表れる脳波波形の加算平均処理を行うため, 1 文字の入力に 10 [sec] 程度必要とする問題がある. 外因性の周期的変化を用いた BCI システムである SSVEP を用いた注視点検出システムにおいては, トレーニングを必要とせず, 検出速度は比較的早いものの, 高速点滅する光源 (視覚刺激) を凝視することにより不快感をユーザに与え, さらには光てんかんを引き起こす危険性がある [68]. 外因性の電位変化を利用したシステムとしては, 符号変調を利用した系列の光刺激により誘発される一過性の視覚誘発電位 (Transient Visual Evoked Potentials: T-VEP) の系列を利用した脳波タイプライタシステムが実現され, これはトレーニングを必要とせず, 検出速度も早く画期的な BCI システムであるが, 制約条件が多く拡張が難しい [69].

本研究においては、トレーニングを必要とせず、安全に使用でき、脳波入力時間の短いBCIシステムの構築を目的として、既存のBCIシステムに対する追従実験を行うとともに、独自に開発したBCIシステムとその際の脳波解析手法についてまとめる。はじめに、認知活動に関する脳波変動を利用した脳波タイプライタシステムについて、これの追従実験を行い、短時間の脳波入力から事象関連電位に関する脳波変動の抽出を試みる。また、このシステムは、光刺激または音刺激のオドボール課題実験を原型としており、これらの追従実験・解析も行う。次に、動作想像時脳波を用いたBCIシステムについて追従実験を行い、トレーニングによって変動する脳波の変動について調べる。また、右手・左手を動作想像とするシステムに対して、足動作想像を加えた3クラスの動作想像BCIシステムへの拡張を行う。さらに、ユーザがシステムの誤動作を認識した際に、事象関連電位の一種であるエラーポテンシャルが表れることが確認されており、この特徴を利用したフェールセーフ機能を伴うBCIシステムについて構築・検討を行う [70]。最後に、光誘発電位を利用したBCIシステムについて、SSVEPを利用したシステムに対する追従実験を行い、T-VEPを利用した新たなBCIシステムについて構築・検討を行う [71][72]。本研究においては、多光源のM-系列の刺激を入力刺激として用い、SSVEPにおける発振現象を抑え、ユーザの注視点の検出を試みるものとする [73]。最終的には、事象により変動する脳波について特徴抽出する手法についてまとめ、脳波から人間の意思を推定することを目指す [74][75]。

また、観測信号が様々な位置の原信号の混合成分であると仮定し、そのダイナミクスを推定することで原信号の情報を抽出する独立成分分析 (Independent Component Analysis: ICA) も、特徴抽出の前処理として有効に作用するため、これを用いた特徴抽出を試みる [76][77][78][79][80][81][82]。具体的に特徴を特定するための手法としては、自己回帰モデルやニューラルネットワーク (Neural network: NN) を拡張したOgdenの自己組織化マップ (Self-Organizing Maps: SOM) も有用であり、これらの信号処理手法も本研究の信号解析に導入する [83][84]。

本稿においては、2章で解析の中心となるマセマティカル・モルフォロジーのフレームワークとフーリエ解析との相違についてまとめ、3章でBCIシステムの利用と実装に関する研究についてまとめる。第4章では、本論文による成果を要約すると共に、今後の発展を図るための課題について言及し、本論文の結びとする。



## 2 マセマティカル・モルフォロジーによる信号解析手法

一般に, 実環境においてデジタル信号を計測する場合, その観測信号には, 目的とする信号成分の他に外部からのノイズやシステム固有のノイズが混入した状態で計測される. このような観測信号からノイズ成分を除去する目的で, FIR (Finite Impulse Response) フィルタや IIR (Infinite Impulse Response) フィルタなどの線形フィルタが, 多くの分野で導入されている [1]. フィルタリングは, 目的とする信号成分をできるだけ歪めず, ノイズ成分を除去できるように設計することが望ましい. しかしながら, 実環境において混入するノイズには, ガウスノイズやパルスノイズなど様々な特性を有したものがあり, 線形フィルタはガウスノイズの除去性能が高いが, パルスノイズに対しては上手く作用しない [7]. 特に, 線形フィルタを施した際に生じるインパルス応答成分は, 観測された信号成分に含まれていなかった成分を生じさせるため, この特性は信号からの特徴抽出に不都合となる.

パルス性のノイズの除去に優れるフィルタとしては, 非線形フィルタの一種であるメディアンフィルタ [4] がある. メディアンフィルタは, ガウスノイズの除去性能は線形フィルタより劣るが, 突発的に表れ特異な値を示すパルスノイズを効果的に除去することができる特性を有する. このように, ガウス性ノイズの除去には線形フィルタが適し, パルス性ノイズの除去には非線形フィルタが適している. また, メディアンフィルタは, フィルタ窓内の信号の振幅値の順序付けを行いその中央値を出力とするものであり, このような順序の情報を利用した非線形フィルタを一般に順序統計フィルタと呼ぶ [11][16].

順序統計フィルタを応用した非線形フィルタには, フィルタ窓に重みを付けて中央値を出力する荷重メディアンフィルタや, 最小・最大をとる振幅値成分を除き残りの信号成分で平均値をとる  $\alpha$ -トリムド平均値フィルタなど提案されている [5]. これらは, ガウス性ノイズとパルス性ノイズの両方のノイズ除去に上手く作用し, 観測信号に対する歪みも少ない. また, フィルタ窓に構造要素と呼ばれる重みを付けて観測信号との畳み込み演算を行い, その中の最大値・最小値を出力とするミンコフスキー演算があり, この組み合わせから構成されるモルフォロジカルフィルタは, 構造要素の設計次第で信号から所望の成分を分離・抽出することができる [13].

モルフォロジカルフィルタは, 2次元画像から鉱石の位置を特定する目的で考案されたものであり, モルフォロジカルフィルタから構成されるパタンスペクトルと呼ばれる形状分布は, 処理対象が有する特徴を直感的に理解する上で重要な情報となる. また, モルフォロジカルフィルタは, フーリエ解析と密接な関係があり, 例えばパタンスペクトルは, フーリエ解析におけるパワースペクトルに相当する特徴抽出手法であると言われている [15].

時系列信号から特徴抽出を行う上で重要な仮定の一つに, 信号の定常性がある. これは, 観測した時系列信号が時間によってその特性を変化させないことを仮定しており, この仮定が成り立つのであれば計測した信号すべてを用いて解析を行うことができる. しかしながら, 音

声信号や生体信号など現実的には時間によって変動する信号が数多く存在し、この仮定が成り立つ時系列信号は少ない。これに対して、短区間内においては信号が定常であることを仮定して、短区間ごとにスペクトル解析を行う手法として短時間フーリエ変換があり、これは、時間によって状態を変化させる時系列信号の特性を理解する重要な解析手法である。短時間スペクトルから特徴を推定するためには、時間分解能と周波数分解能高いことが望ましいが、これらの積を一定量以下にはできないという不確定性原理がある。ウェーブレット変換は、この原理を保ちつつ、高周波域では時間分解能を高くし、低周波域では周波数分解能を高くするように基底関数を伸縮させる手法であり、様々な分野で利用されている [23]。また、時間的に状態が変化する信号に対して、最も観測信号にマッチする基底関数を推定することで、信号が有する特徴を同定するマッチング追跡 (Matching Pursuit: MP) と呼ばれる手法がある [32]。

本章においては、モルフォロジカルフィルタのフィルタ設計を行い、観測信号からのノイズ除去や特徴抽出を試みる。はじめに、モルフォロジカルフィルタのフレームワークについて説明し、フィルタ特性について確認を行う。次に、モルフォロジカルフィルタから構成されるパタンスペクトルについて説明する。さらに、この手法を短時間スペクトル解析に拡張することを目的として、冗長性ウェーブレットとモルフォロジカル・ハール・ウェーブレットのフレームワークを利用した非線形短時間スペクトル抽出手法について提案を行う。これらの特徴抽出手法は、実環境で計測された音声信号や睡眠脳波信号などへの適用を行い特性を確認する。また、モルフォロジカルフィルタのフィルタ特性を決定する構造関数の設計手法の一手法を提案し、ガウスノイズやパルスノイズを含んだ信号からのノイズ除去特性について確認を行う。最後に、これらの非線形手法と線形手法であるフーリエ解析との対応関係についてまとめる。

## 2.1 マセマティカル・モルフォロジー

### 2.1.1 順序統計フィルタ

順序統計フィルタは、フィルタ窓内の信号の振幅値の順序関係の情報を利用したフィルタリング手法である (Fig. 2.1)。一般に、パルスノイズの振幅値は、フィルタ窓内において最大値・最小値をとるため、順序統計フィルタのフレームワークを取り入れたフィルタリング手法は、パルス性ノイズの除去性能に優れている。

1次元関数のサンプル値を  $f(i)$  とし、フィルタの窓領域  $B$  を  $[-M, M]$  とする ( $M$  は正の整数)。順序統計フィルタは、注目点  $i$  の近傍で窓領域に入る関数値  $f(i)$  を大きい値から順番に並べたとき、 $k$  番目に相当する関数値を出力する ( $k$  位順序統計フィルタ) [11]。

$$y(i) = [f(i - M), \dots, f(i), \dots, f(i + M)] \text{ の } k \text{ 位の値} \quad (2.1)$$

メディアンフィルタは、 $k = M + 1$  とした順序統計フィルタであり、信号や画像のエッジ情報を保存しつつパルスノイズのような細かな変動を取り除くのに効果のあるフィルタとして

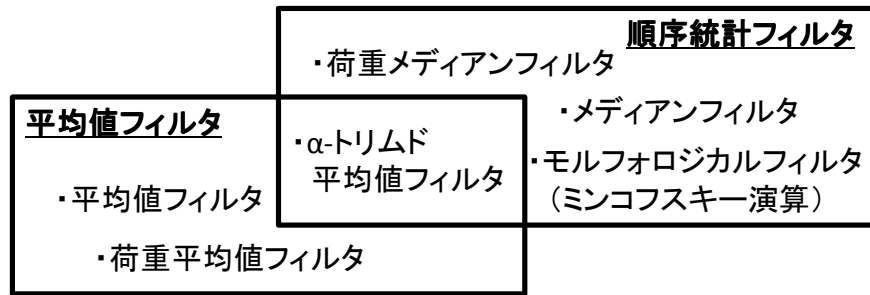


Fig. 2.1 順序統計フィルタの例

広く用いられている。

$$y(i) = [f(i - M), \dots, f(i), \dots, f(i + M)] \text{ の } M \text{ 位の値} \quad (2.2)$$

例えば、フィルタ窓内の信号として {3, 2, 4, 9, 6} が与えられたとすると、メディアンフィルタはこれを昇順に並べ替えて {2, 3, 4, 6, 9} として 4 を出力する。以降では、中央値フィルタの出力を  $\text{med}[\cdot]$  と書く。

荷重メディアンフィルタは、位置情報も考慮してフィルタ窓に重みを付与したメディアンフィルタであり、信号の劣化を抑えることができる [5][6][16]。入力ベクトルを  $\mathbf{x} = \{x_1, x_2, \dots, x_n\}$  で表し、これに対応する非負の整数からなる荷重ベクトルを  $\mathbf{w} = \{w_1, w_2, \dots, w_n\}$  とする。このとき、荷重メディアンフィルタの出力  $y$  は、次式で与えられる。

$$y = \text{med}[w_1 \diamond x_1, w_2 \diamond x_2, \dots, w_n \diamond x_n] \quad (2.3)$$

ここで、演算子  $\diamond$  は要素の複製個数を表している。例えば、フィルタ窓内の信号として {3, 2, 4, 9, 6} が、荷重ベクトルとして {1, 2, 3, 2, 1} が与えられたとする。これから拡張された数列 {3, 2, 2, 4, 4, 4, 9, 9, 6} が得られ、これを昇順に並べ替えて {2, 2, 3, 4, 4, 4, 6, 9, 9} として 4 を出力する。

$\alpha$ -トリムド平均値フィルタは、順序統計フィルタと平均値フィルタを組み合わせたフィルタリング手法で、ガウスノイズとパルスノイズの両方に対応可能なフィルタである [2]。パルスノイズは、信号値が極端に大きい小さいことが多く、 $N$  個の並べ替えにおいて 1 番目付近と  $N$  番目付近に集中すると考えられ、これらの信号を排除することで、パルスノイズの影響を受けていない信号が得られる。 $\alpha$ -トリムド平均値フィルタの出力は、位置  $i$  でのフィルタの窓内の信号を昇順に並べたものを  $x_{(k)}(i)$  として、次式で与えられる。

$$y(i) = \frac{1}{N(1 - 2\alpha)} \sum_{k=\alpha N+1}^{N-\alpha N} x_{(k)}(i) \quad (2.4)$$

ここで、 $0 \leq \alpha \leq (N - 1)/2N$  であり、 $\alpha N$  の値は整数値とする。例えば、フィルタの窓幅  $N$  を 5、 $\alpha$  の値を 0.2 としたとき、上式は次のようになる。

$$y(i) = \frac{1}{3} \sum_{k=2}^4 x_{(k)}(i) \quad (2.5)$$

入力信号 {3, 2, 9, 4, 5} が与えられたとすると, これを昇順に並べ替えて 2 と 9 を除外し, {3, 4, 5} 平均値を求めて 4 を出力する.

以上のように, 順序統計フィルタを用いることでパルスノイズを効果的に取り除くことができる. 特に, 順序統計フィルタを拡張させた荷重メディアンフィルタや  $\alpha$ -トリムド平均値フィルタは, 観測信号の歪みを抑えることができる. 次節で説明するモルフォロジカルフィルタも順序統計フィルタの拡張の一種であり, フィルタの特性を決定する構造関数の設計次第でこれらのフィルタリング手法よりもノイズ除去や特徴抽出に上手く作用する.

### 2.1.2 基本演算

モルフォロジーは, 対象集合と構造要素の集合演算とベクトル演算の組み合わせで構成され, 構造要素の形状に依存し, 対象集合の平滑化を行うことができる. モルフォロジーの基本演算は, Minkowski 集合論である Minkowski 和  $\oplus$  と Minkowski 差  $\ominus$  からなる.

$$A \oplus B = \{a + b | a \in A, b \in B\} = \bigcup_{b \in B} (A)_b \quad (2.6)$$

$$A \ominus B = \{a | a - b \in A, b \in B\} = \bigcap_{b \in B} (A)_b \quad (2.7)$$

ここで,  $(A)_b$  は,  $A$  を  $b$  だけ平行移動したもので, 次式のように定義される.

$$(A)_b = \{a + b | a \in A\} \quad (2.8)$$

モルフォロジカルフィルタは, これらの基本演算を組み合わせることで定義される.

$$\text{opening} : A_B = (A \ominus B^S) \oplus B \quad (2.9)$$

$$\text{closing} : A_B = (A \oplus B^S) \ominus B \quad (2.10)$$

ここで,  $B^S$  は,  $B$  の原点对称となる集合である.

opening 処理は, 対象集合を浸食させた後で膨張させる処理であり, 対象集合の外側に突き出した突起を削り滑らかにする一種の平滑化処理である. 対して closing 処理は, 対象集合を膨張させた後で浸食させる処理であり, 対象集合の入江のような部分や小さな穴がふさがれる効果がある (Fig. 2.2).

### 2.1.3 多値のモルフォロジー

多値関数を扱う場合は, モルフォロジー演算は関数の陰影に対して行われ, 出力はその表面変換からなる.  $\mathbf{x}$  を  $n$  次元ベクトルとし,  $n$  次元空間で定義される関数  $f(\mathbf{x})$  の陰影は,  $(n+1)$  次元空間で表現され,  $n$  次元が空間座標を表し,  $(n+1)$  次元目の軸が濃淡値を表す軸と考える. そのときの陰影とは次のようになる.

$$U[f] = \{(\mathbf{x}, y) : y \leq f(\mathbf{x})\} \quad (2.11)$$

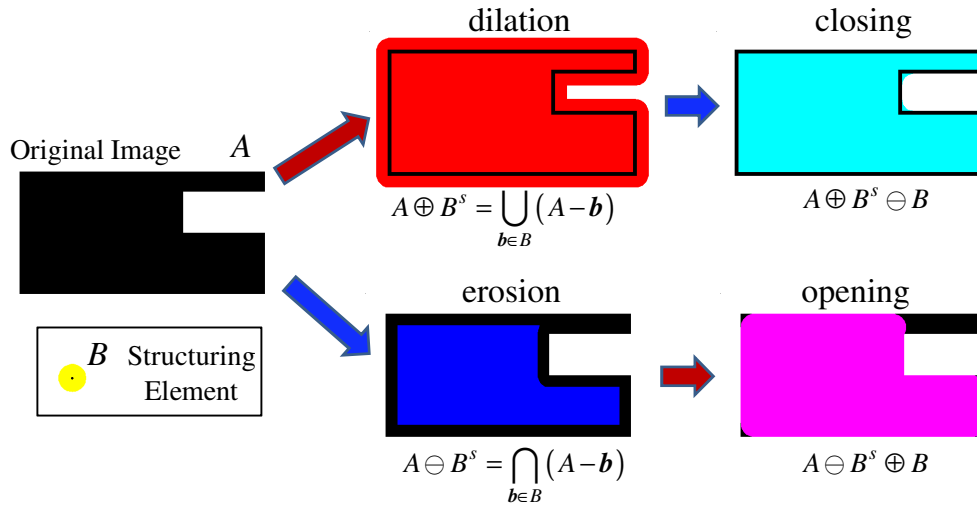


Fig. 2.2 2値集合のモルフォロジー

関数  $f$  が与えられれば, 上記の定義に基づいてその陰影が決まるが, 逆に陰影から元の関数  $f$  が次のように定まる.

$$f(\mathbf{x}) = \sup\{y \in R : (\mathbf{x}, y) \in U[f]\} \quad (2.12)$$

$\sup$  は, 上限 (supremum) を意味するが, 量子化が行われているデジタル信号を扱う場合には,  $\sup$  を  $\max$  で置き換える. 一般に, 集合の上限は表面 (top surface) と呼ばれる. Eq. (2.12) は, 関数  $f$  の陰影集合の表面が元の関数  $f$  を与えることを意味している. これを別の形で次のように表こととする.

$$f(\mathbf{x}) = T[U[f]] \quad (2.13)$$

ここで,  $T$  は表面変換を表す記号とし,  $T[U]$  は集合  $U$  の表面を意味する.

関数  $f$  と関数  $g$  の多値の Minkowski 演算は, 表面変換を用いて以下のようにできる (Fig. 2.3).

$$[f \oplus g](t) = T[U[f] \oplus U[g]] = \max_{\substack{t-u \in F \\ u \in G}} \{f(t-u) + g(u)\} \quad (2.14)$$

$$[f \ominus g](t) = T[U[f] \ominus \hat{U}[g]] = \min_{u \in G} \{f(t-u) - g(u)\} \quad (2.15)$$

ここで,  $F, G$  はそれぞれ関数  $f$  と  $g$  の定義域であり, 定義域外では  $-\infty$  をとるものとする.

#### 2.1.4 モルフォロジカル・フィルタ

これらを組み合わせた opening 処理, closing 処理は, 構造関数  $g(t)$  を対象信号  $f(t)$  の負方向あるいは, 正方向から押し当てたとき, 進入できる部分を残し, 進入できない部分を除去する特性がある. さらに, 正負の突起形状を除去するものとして, opening と closing を組み合わせた open-closing フィルタ, clos-opening フィルタを定義でき, これは構造関数に比べて小さな凸部を削る平滑化であり, 一種の非線形な低域通過フィルタである. これらは, 同じ  $g(t)$  を用




Fig. 2.3 多値のミンコフスキー演算

いた場合でも処理の順序で得られる軌跡が異なり、出力にそれぞれバイアスが生じる問題があるため、この対処法として、open-closing と clos-opening を組み合わせたフィルタ (LOCO: Linear combination of OC CO)[10] が提案されている。また、高域通過フィルタは、低域通過フィルタの出力結果を元の信号から引き去ることで構成される。

$$\text{low pass : } \psi_g(t) = \frac{1}{2} \left( (f_g)^g(t) + (f^g)_g(t) \right) \quad (2.16)$$

$$\text{high pass : } \omega_g(t) = f(t) - \psi_g(t) \quad (2.17)$$

さらに、異なる構造関数  $g_1, g_2$  を用いたフィルタ出力の差分をとることで、非線形な帯域通過フィルタ、帯域阻止フィルタも構成することができる (Fig. 2.4)。

$$\text{band pass : } p_{g_m, g_n}(t) = \psi_{g_m}(t) - \psi_{g_n}(t) \quad (2.18)$$

$$\text{band stop : } c_{g_m, g_n}(t) = f(t) - \psi_{g_m}(t) + \psi_{g_n}(t) \quad (2.19)$$

構造関数  $g_n$  は、 $g_m$  よりも大きなものを用いる。

モルフォロジカルフィルタのフィルタ特性は、構造関数の形状に依存して定まる。1次元の構造関数のパラメトリックなモデルとしては、楕円型、cos 関数型、ガウス型 [9]、多項式関数型 [21] などがある (Table 2.1)。本研究では、比較的導入の容易な Flat 型と、楕円型・超楕円型を構造関数のモデルに用いる (Fig. 2.5)。

時系列信号における Flat 型構造関数は、窓幅  $2n$  の 1 パラメータで一意に形状が定まる。

$$g(t) = \begin{cases} 0 & (-n \leq t \leq n) \\ -\infty & (\text{otherwise}) \end{cases} \quad (2.20)$$

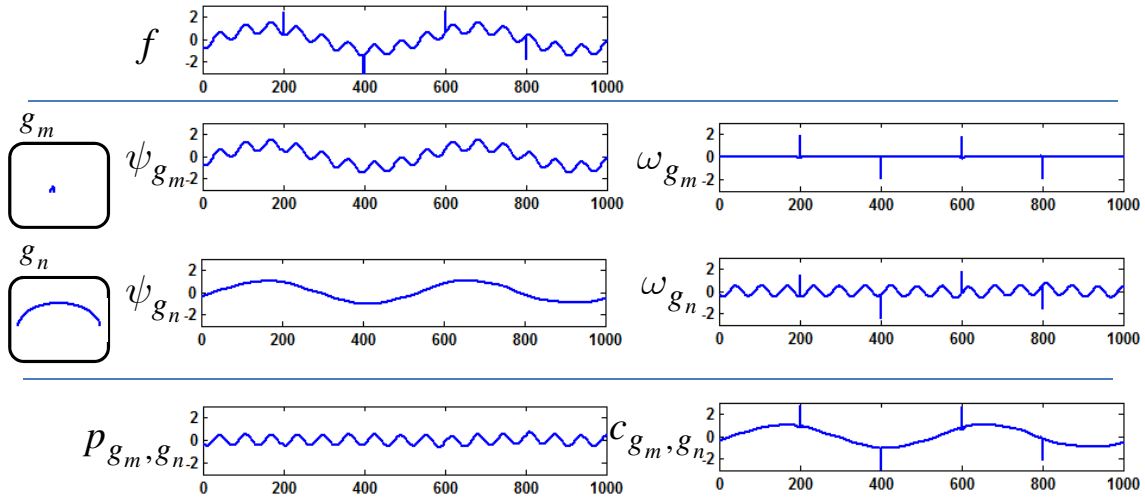


Fig. 2.4 モルフォロジカルフィルタ

Table 2.1 1次元構造関数モデル

Name	Representation	Structuring Function
Semiellipse	$\frac{x^2}{a^2} + \frac{y^2}{b^2} = 1$	$b \left[ 1 - \frac{x^2}{a^2} \right]^{1/2} - b$
Gaussian	$y = \frac{1}{\sqrt{2\pi}} e^{-x^2/2}$	$\frac{1}{\sqrt{2\pi}} e^{-x^2/2} - \frac{1}{\sqrt{2\pi}}$
Parabola	$x^2 = -4ay$	$-x^2/4a$
Semihyperbola	$\frac{y^2}{b^2} - \frac{x^2}{a^2} = 1$	$-b \left[ 1 + \frac{x^2}{a^2} \right]^{1/2} + b$
Sine	$y = a \sin(x)$	$a \sin(x) - a$
Cosine	$y = a \cos(x)$	$a \cos(x) - a$
polynomial (4)		$ax^4 + bx^3 + cx^2 + dx + e$
SuperEllipse	$\left  \frac{x}{a} \right ^p + \left  \frac{y}{b} \right ^p = 1$	$b \left( 1 - \left  \frac{x}{a} \right ^p \right)^{1/p}$
Flat		0

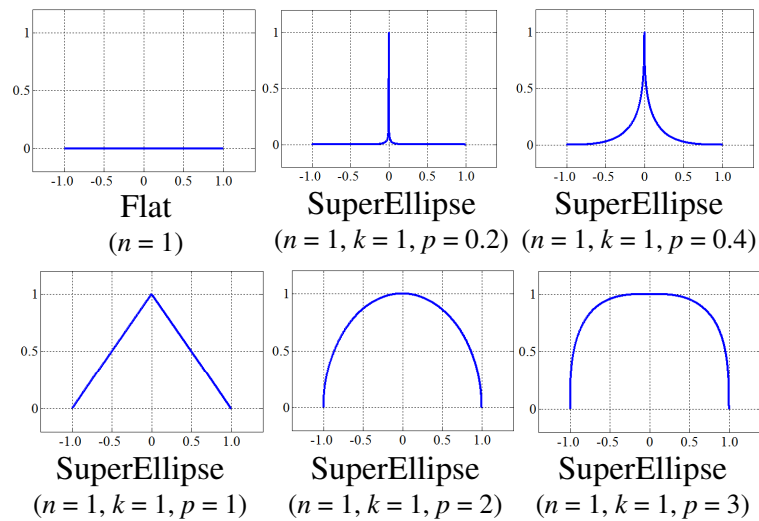


Fig. 2.5 超楕円型構造関数

超楕円構造関数の形状は、値軸  $k$ 、窓幅  $2n$  および  $p$  の 3 パラメータによって一意に定まる。

$$g(t) = \begin{cases} k \left(1 - \left|\frac{t}{n}\right|^p\right)^{\frac{1}{p}} & (-n \leq t \leq n) \\ -\infty & (\text{otherwise}) \end{cases} \quad (2.21)$$

これについて、 $p = 2$  とした場合は楕円型で、 $k = 0$  とした場合は Flat 型となる。

### 2.1.5 モルフォロジカルフィルタの特性

モルフォロジカルフィルタが、どのような形状成分を通過・遮断するかは、構造関数の形状によって定まる。ここでは、正弦波を入力としてフィルタの減衰特性を調べることでモルフォロジカルフィルタの周波数特性についてまとめる。特に注意が必要なことは、モルフォロジカルフィルタが入力信号のサンプリング周波数や振幅に依存して特性が変化することである。入力信号のサンプリング周波数の変化に対する影響については後に述べるものとして、ここでは、入力信号の振幅に関する情報を加味したフィルタの周波数特性を調べるものとする。

構造関数は、値軸  $k$ 、窓幅  $2n$  の 2 パラメータによって一意に形状が定まる楕円型構造関数を用いるものとする。入力信号は、単一周波数の時間遅れの無い正弦波とし、出力信号  $y(t)$  に対して最小 2 乗推定により減衰特性を調べる (Fig. 2.6)。

$$L = \sum_{t=1}^N (y(t) - b \sin(\omega t) - c \cos(\omega t))^2 \quad (2.22)$$

$$\begin{aligned} y(t) &= a \sin(\omega t + \phi) = a \sin(\omega t) \cos \phi + a \cos(\omega t) \sin \phi \\ &= b \sin(\omega t) - c \cos(\omega t) \quad (b = a \cos \phi, \quad c = a \sin \phi) \end{aligned}$$

上式に対して、 $\frac{\partial L}{\partial b} = 0$ ,  $\frac{\partial L}{\partial c} = 0$  となる  $b, c$  を求める。

$$\begin{pmatrix} b \\ c \end{pmatrix} = \begin{pmatrix} \sum_{t=1}^N \sin^2(\omega t) & \sum_{t=1}^N \sin(\omega t) \cos(\omega t) \\ \sum_{t=1}^N \sin(\omega t) \cos(\omega t) & \sum_{t=1}^N \cos^2(\omega t) \end{pmatrix}^{-1} \begin{pmatrix} \sum_{t=1}^N y(t) \sin(\omega t) \\ \sum_{t=1}^N y(t) \cos(\omega t) \end{pmatrix} \quad (2.23)$$

これにより、 $a = \sqrt{b^2 + c^2}$  が得られ、種々の周波数の正弦波を入力することで、1つのモルフォロジカルフィルタに対する特性が分かる。

また、モルフォロジカルフィルタは、入力信号の形状に対して平滑化をかけるフィルタであるため、入力信号の振幅に依存して除去できる周波数帯域が変化する。そのため、フィルタ設計の際には、入力信号の振幅値にも着目する必要がある。Fig. 2.7 は、ある構造関数を用いたモルフォロジカルフィルタに対し、入力周波数が同じであり、振幅値が異なる正弦波を入力した際の振幅特性を示す。この場合のサンプリング周波数は、128 [Hz] とする。入力振幅値に依存して、振幅特性が異なることが確認できる。そのため、Fig. 2.8 に示すように、周波数特性は、1つの構造関数に対して入力正弦波の振幅・周波数を変化させたものとして得られる。Fig. 2.9 に楕円形状である構造要素の長軸、短軸、および入力信号の振幅値をパラメータとして構成されるモルフォロジカルフィルタの周波数特性を示す。

以上のように、モルフォロジカルフィルタは、一般的な線形フィルタと異なり入力信号の振幅にも依存して周波数特性を変化させるため、線形フィルタと直接的な対応づけが難しい。



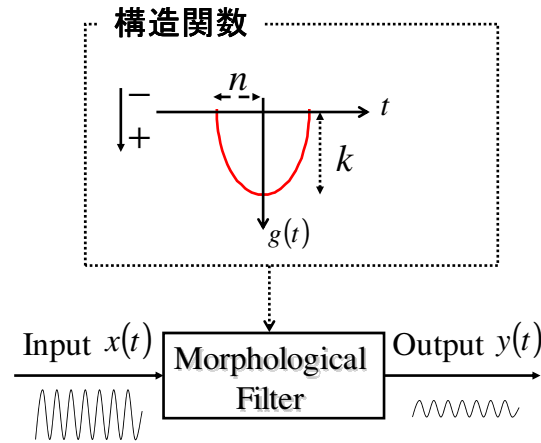


Fig. 2.6 モルフォロジカルフィルタの減衰特性

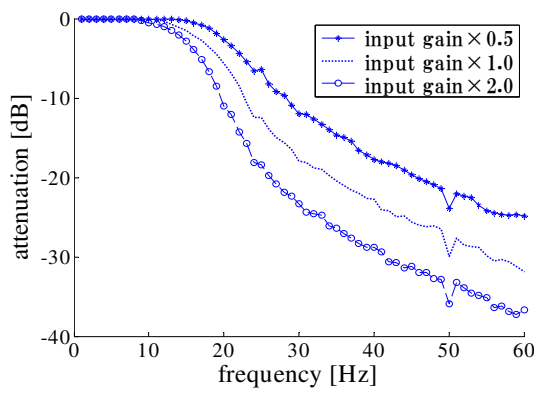


Fig. 2.7 入力信号の振幅を変化させた場合の周波数応答  
(SEGain (k): 0.25, SEProcLen (n): 13)

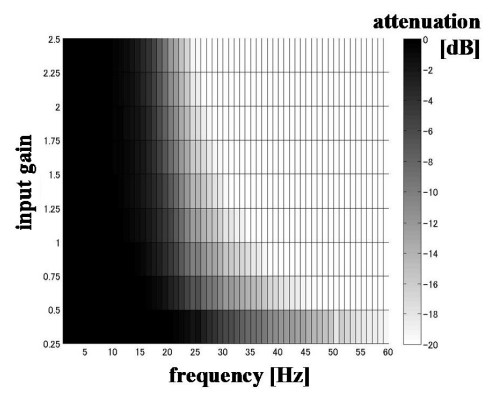


Fig. 2.8 周波数応答の例  
(SEGain (k): 0.25, SEProcLen (n): 13),  
(黒色: 通過帯域, 白色: 遮断帯域)




Fig. 2.9 モルフォロジカルフィルタ周波数応答リスト

## 2.2 モルフォロジカル・パタンスペクトル

### 2.2.1 パタンスペクトル

パタンスペクトル(サイズ分布)とは, 画像中の図形を構造要素の相似形に分解したとき, どのサイズの相似形がどれだけの面積を占めているかを表わしたものである [16][38]. opening 処理は, 対象集合を構造要素で浸食させた後で膨張させる処理であり, 対象集合の外側に突き出した突起を削り滑らかにする一種の平滑化処理である. 対して closing 処理は, 対象集合を膨張させた後で浸食させる処理であり, 対象集合の入江のような部分や小さな穴がふさがれる効果がある. すなわち, opening 処理は対象集合から構造要素よりも小さな成分を取り除いたものであり, closing 処理は対象集合から構造要素よりも小さな間隙を連結するものであるため, これらに対処集合内側からの平滑化, 外側からの平滑化とみなすことができる. これらの opening 処理, closing 処理がどのような成分を平滑化するかは, 構造要素の形状やサイズに依存する. そこで,  $B$  をある基本的な構造要素とし,  $B$  を順に大きくして, サイズ  $2, 3, \dots$  の構造要素  $2B, 3B, \dots$  を準備する. 最もよく知られた定義は,  $2B, 3B, \dots$  を凸図形の  $B$  の相似拡大によって定義するものである. ここで通常の離散的な画像  $X$  を考え, サイズも離散的であるとすると, これらの相似な構造要素はミンコフスキー集合和を使って次式で得られる.

$$nB = B \oplus B \oplus \dots \oplus B \quad ((n-1) \text{ 回の } \oplus) \quad (2.24)$$

これらの構造要素を用いた opening 処理, closing 処理には, 次式の大小関係が成り立つ.

$$\dots \supseteq X^{3B} \supseteq X^{2B} \supseteq X^B \supseteq X \supseteq X_B \supseteq X_{2B} \supseteq X_{3B} \supseteq \dots \quad (2.25)$$

すなわち, 様々なサイズの構造要素で opening 処理, closing 処理を行うことで,  $X$  から除かれる部分が次第に大きくなっている図形系列が得られる.

opening 処理, closing 処理によって生成される図形の系列について, 各図形の面積は単調減少となる.

$$\dots S(X^{3B}) \geq S(X^{2B}) \geq S(X^B) \geq S(X) \geq S(X_B) \geq S(X_{2B}) \geq S(X_{3B}) \geq \dots \quad (2.26)$$

また, 原図形の面積との比をとることで, これをサイズ分布関数と見なせる.

さらに, サイズ分布関数の差分は, そのサイズにおける構造要素固有の成分を表現する.

$$PS(n) = s(n) - s(n+1) \quad \begin{cases} s(n) = S(X^{nB}) & (n < 0) \\ s(n) = S(X) & (n = 0) \\ s(n) = S(X_{nB}) & (n > 0) \end{cases} \quad (2.27)$$

例えば,  $X_{2B}$  と  $X_{3B}$  の面積の差は,  $X_{2B}$  による opening 処理では除かれなかったが,  $X_{3B}$  による opening 処理で除かれた部分, すなわち, サイズがちょうど 2 である部分の面積となる. このようにして, 各サイズに対応する部分の面積を求めたものをパタンスペクトラム (Pattern

Spectrum: PS) と呼び、さらにそれを原図形の面積との比で表わしたものをサイズ密度関数という。サイズ分布関数やサイズ密度関数は、それぞれ確率分布関数、確率密度関数と同じような性質を持つため、このような名前が付けられている。

Fig. 2.10 は、ある 2 値画像に対して opening 処理, closing 処理を行い、その面積分布とパタンスペクトルを表したものである。異なるサイズの構造要素を用いた opening 処理を行うことで、そのサイズにおける構造要素固有の成分が抽出される。また、closing 処理を行うことで構造要素よりも小さな間隙が連結されるため、パタンスペクトルより要素間の距離に相当する情報が抽出される。

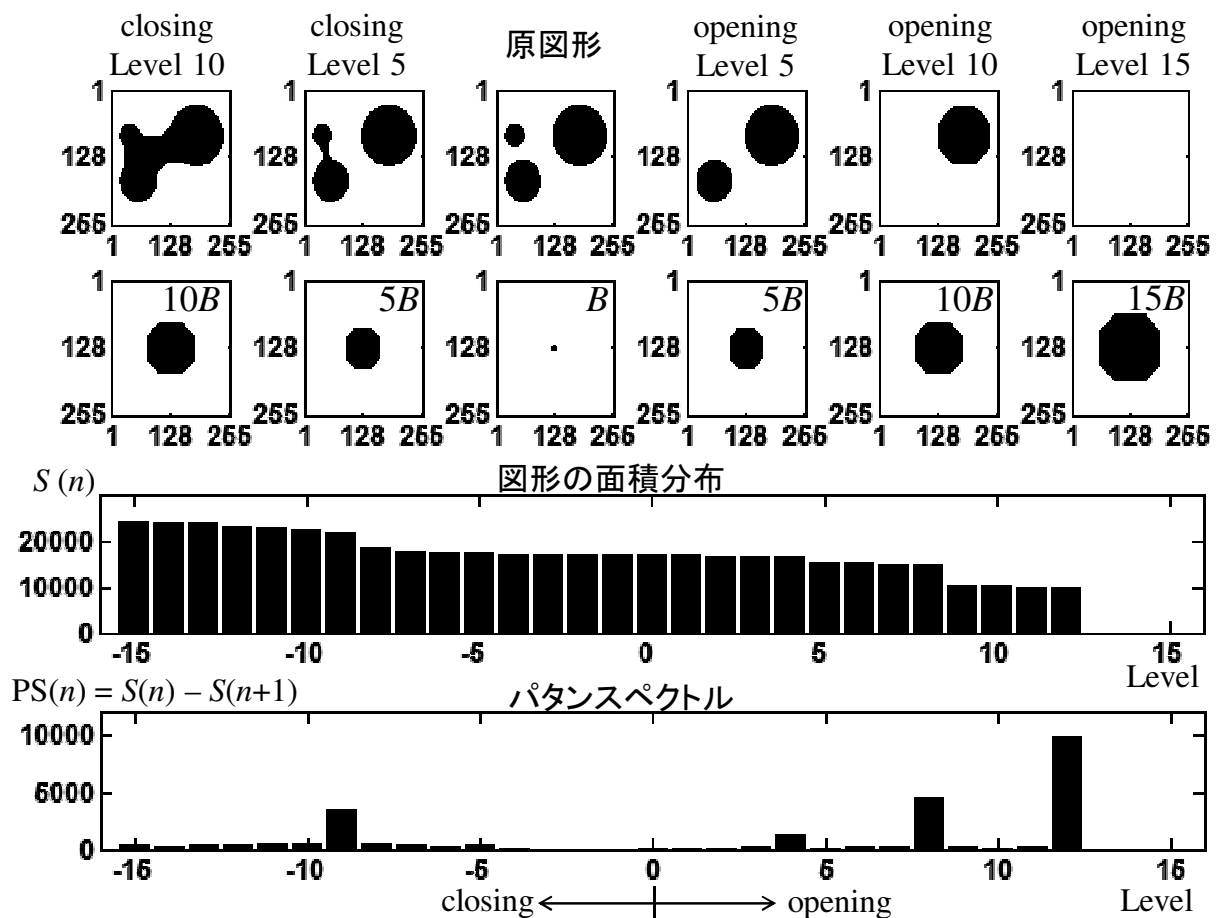


Fig. 2.10 離散空間における 2 値集合のパタンスペクトル

## 2.2.2 時系列信号のパタンスペクトル

時系列信号のパタンスペクトルは、時系列信号に対して陰影処理を施した後、2 値図形の場合と同様に様々な形状の構造関数を用いて opening 処理, closing 処理を行い、その面積分布の差分成分をパタンスペクトルとする。時系列信号  $f$  に対して、構造関数  $g$  で opening 処理, closing 処理を行った場合、その処理結果には次に示す大小関係が成り立つ。

$$\dots f^{3g} \geq f^{2g} \geq f^g \geq f \geq f_g \geq f_{2g} \geq f_{3g} \geq \dots \quad (2.28)$$

このとき、構造関数  $ng$  は、 $g$  の相似拡大から得られるものとする。

$$ng = g \oplus g \oplus \cdots \oplus g \quad ((n-1) \text{ 回の } \oplus) \quad (2.29)$$

パタンスペクトルは、各レベルの信号の振幅値を時間積分したのに対して、隣り合うレベルの差分を行うことで構成される。

$$PS(n) = s(n) - s(n+1) \quad \begin{cases} s(n) = \sum_t f^{ng}(t) & (n < 0) \\ s(n) = \sum_t f(t) & (n = 0) \\ s(n) = \sum_t f_{ng}(t) & (n > 0) \end{cases} \quad (2.30)$$

Fig. 2.11 は、5 [Hz] と 20 [Hz] の 2 種類の正弦波とパルス信号からなる信号であり、その opening 処理, closing 処理の結果とパタンスペクトルを表す。レベル 1 とレベル-1 でそれぞれ正負に突出したパルス成分が抽出され、残された波形の歪みも小さい。また、レベル  $\pm 15, \pm 35$  でそれぞれ 20 [Hz], 5 [Hz] 正弦波に相当する成分が抽出される。

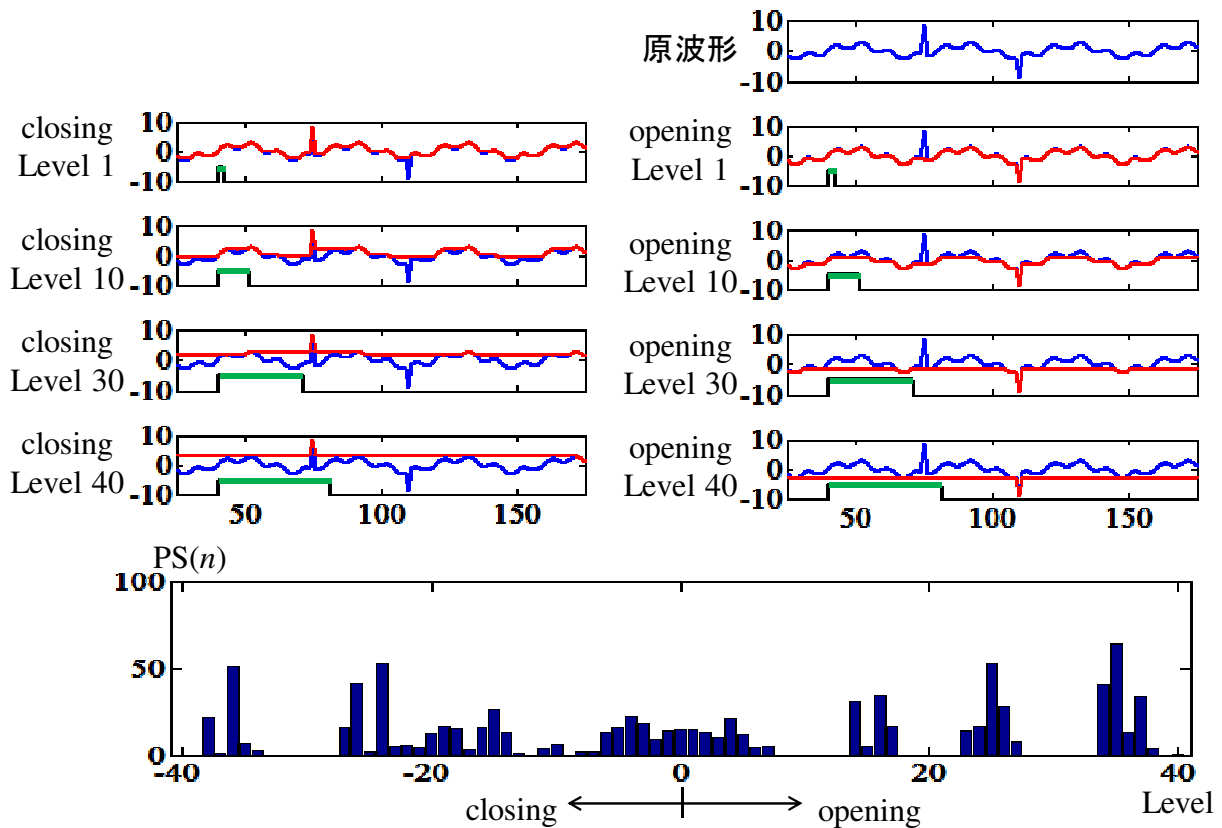


Fig. 2.11 時系列信号のパタンスペクトル

(青線: 原信号, 赤線: モルフォロジカルフィルタ結果, 緑線: 構造関数)

モルフォロジカル・パタンスペクトルにより、opening 処理で正のスペクトルが closing 処理で負のスペクトルがそれぞれ得られ、フーリエ・パワースペクトルと異なりこれらに対称性は無い。時系列信号の振幅の極性について情報が含まれているときには、この非対称性は重要な特徴量となる。一方で、振幅の極性に関する情報を抽出する必要がない場合、opening 処理

と closing 処理を同時に行う open-closing 処理でパタンスペクトルを求た方が安定してスペクトル抽出が行える場合がある. open-closing 処理においては, 出力信号の振幅値が正と負の両方をとるため, その絶対値を出力とする.

$$PS(n) = s(n) - s(n+1) \begin{cases} s(n) = \sum_t |(f_{ng})^{ng}(t)| & (n > 0) \\ s(n) = \sum_t |f(t)| & (n = 0) \end{cases} \quad (2.31)$$

### 2.2.3 音声信号に対する適用

音声情報処理は, 聴覚器官である蝸牛が入力音声波の周波数に応じて神経細胞を発火させ脳へ情報伝達を行うことから, また, 音声の生成過程が Kelly の声道モデル [47] のようにいくつかデジタルフィルタの結合で上手く近似できることなどから, フーリエ変換, 線形予測法 (Linear Predictive Coding: LPC), ケプストラム法 (Cepstrum) [49] など周波数解析を基礎とした手法が主流となっている. これらは, 外部からのノイズの無い理想的な計測環境においては優良な認識を行うことができるが, 実環境とくにパルス性雑音が混入する環境においては周波数情報が埋もれる問題がある. また, 母音情報を識別する上で重要な特徴量となるホルマント [50] に関する情報も, 線形手法では, 高調波成分が出現し誤認識を引き起こす危険性がある. このような問題に対しては, 前述の理由から非線形フィルタが特徴抽出に有用である可能性がある.

母音音声信号は, その周波数スペクトルの 2, 3 個のピーク周波数 (ホルマント周波数) の情報を用いることで判別することができる. ここでは, 実環境において計測された音声信号に対してパタンスペクトルを求め, 手法の有効性を確認する.

#### 2.2.3.1 実験データ

実験は, 実環境における連続音声計測された”日本語方言の地域差方言音声コーパス (GSR-JD)”に対して行う. この実験データは, 133 名の異なる地域の話者からなる音声データで, 16k [Hz] のサンプリング周波数, 16 [bit] の A/D 変換で計測している. /a i u e o/と連続発生した際の実験データを解析に用いる.

#### 2.2.3.2 解析方法

信号のモルフォロジカル・パタンスペクトルを用いることで, 音声信号からホルマントに相当する成分を抽出する. 母音音声は, 連続発声された音声信号から聞き取りによりそれぞれ 2000 [point] (0.125 [sec]) に切り分けられる. このデータに対して, LPC によるスペクトルとモルフォロジカルパタンスペクトルをそれぞれ求め, ピークピッキング法で 3 つのピーク周波数 (ホルマント周波数) を検出する [42].

ピークピッキング法とは, パワースペクトル包絡のホルマントに相当するピークをその包絡形状から抽出しようとするものである. これは, パワースペクトル  $P(f)$  について  $[P(f+\Delta f) - P(f)]$  の符号が正から負へ変わる周波数  $f_i$  を検出することで得られる. そのため, この手法は, 基となるスペクトル包絡の形, 言い換えればスペクトル  $P(f)$  の計算法に依存して結果が大きく変化する.

パタンスペクトルを求めるためのモルフォロジー演算には 音声信号の振幅の極性に本質的な意味がないことから, ここでは open-closing 処理を採用する. 構造関数は, Flat 型を用い, レベル 100 (窓幅 100) のモルフォロジー処理まで行い, その時間積分でスペクトルを導出する. なお, ピークピッキングの前処理として, 窓幅 15 の重み付き移動平均でパタンスペクトル波形の平滑化を行う. また, LPC の次数は, 25 とする.

LPC, パタンスペクトルでそれぞれ得られたホルマント成分は, その分布が正規分布に従うと仮定し, 次式のベイズ判別法で判別を行う.

$$k^* = \arg \max_k \Pr(\omega_k | \mathbf{s}) = \arg \min_k \left\{ \frac{1}{2} \ln |\Sigma_k| + \frac{1}{2} (\mathbf{s} - \mathbf{m}_k)^T \Sigma_k^{-1} (\mathbf{s} - \mathbf{m}_k) - \Pr(\omega_k) \right\} \quad (2.32)$$

$\mathbf{s}$  は, 3 つのホルマント周波数からなるベクトルである. また,  $\mathbf{m}_k, \Sigma_k$  は,  $\mathbf{s}$  の平均値ベクトル, 共分散行列である.

### 2.2.3.3 結果

ある母音/a/の音声信号について, フーリエスペクトル, LPC スペクトル, パタンスペクトルを求め, パタンスペクトルの顕著に特徴が表れた 3 レベル (5, 30, 55) についての処理の途中経過を示す (Fig. 2.12). この例では, open-closing 処理により, ノイズ成分と母音の情報を別々の帯域に分離でき, この分離系列の絶対値の時間積分をとることでパタンスペクトルが求められる.

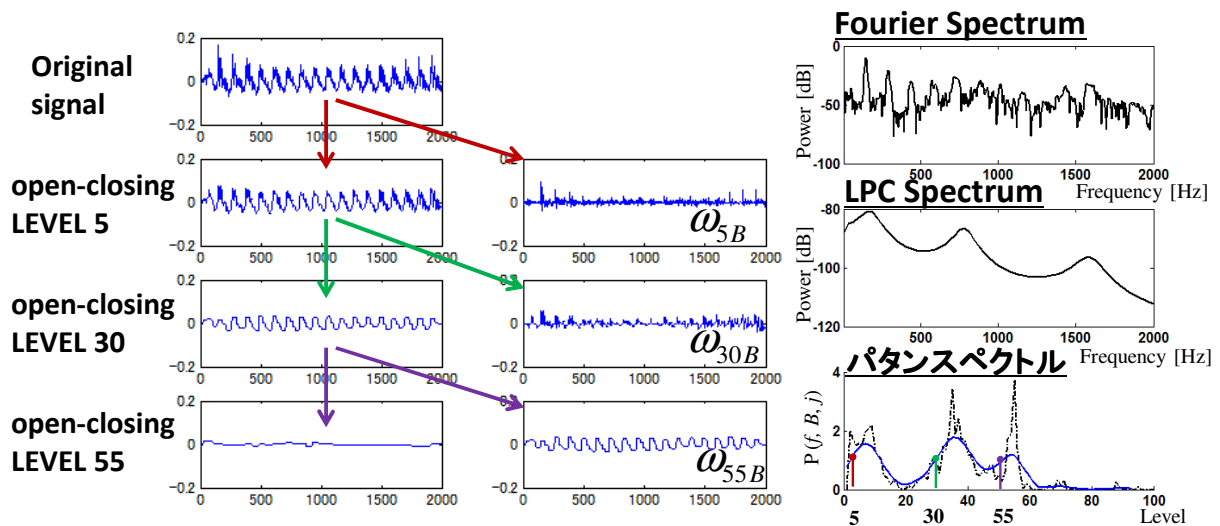


Fig. 2.12 母音信号のパタンスペクトル

Fig. 2.13 は, 5 つの母音/a/, /i/, /u/, /e/, /o/について, パタンスペクトルと LPC スペクトルをそれぞれ求め, ピークピッキングアルゴリズムでピーク検出を行った一例である. 音声解析分野において 3 種類あると言われているホルマント周波数について, パタンスペクトルにおいても 2 つあるいは 3 つのホルマント情報と考えられるピークレベルが検出される. 信号の元の成分にあるように, このデータの /i/, /u/, /e/ は 2 形状から, /a/, /o/ は 3 形状あるいは 3 形状以上から構成されているため, 一部でピーク数が少なく検出されることは正しいと考えられる.

一方で、ピークピッキングアルゴリズムでピーク情報を抽出した結果、このデータの*/i/*, */o/*音のように第2, 第3ピークについて誤検出するものも多く見られる。

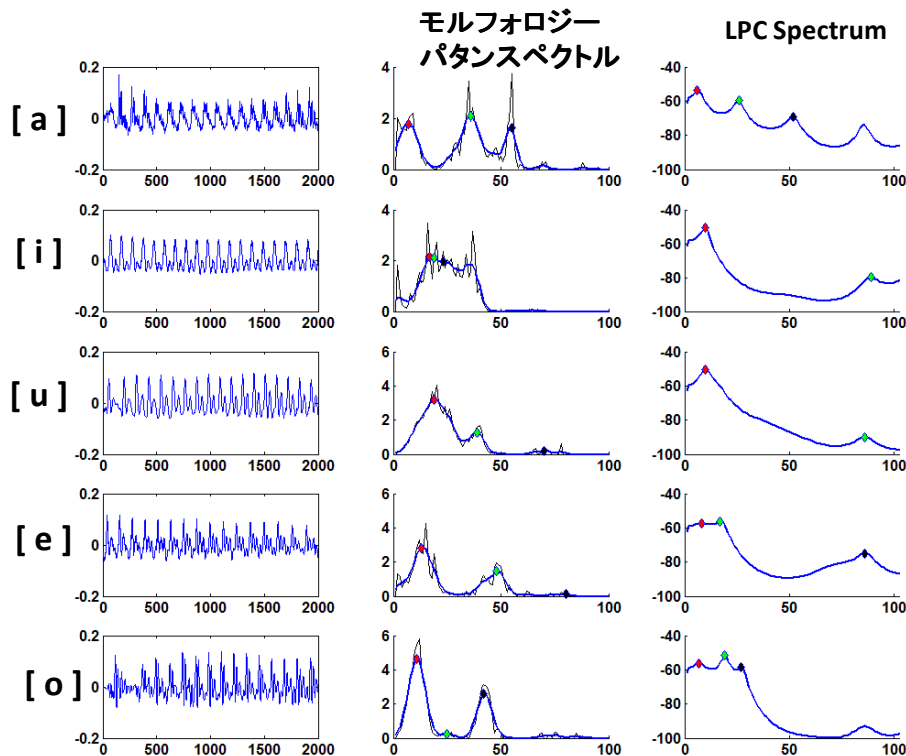


Fig. 2.13 ピークピッキング法によるスペクトルピーク検出

Fig. 2.14 は、LPC スペクトルとパタンスペクトルのピーク周波数とピークレベルを3次元プロットしたものである。例えば、*/a/*の音は、パタンスペクトルではひと固まりの分布を示すが、LPC の場合は分布が二つに分かれている。これは、本実験データが実環境において計測されたものであるため、雑音成分により LPC スペクトルに音声情報とは異なるピーク周波数が表れたためと考えられる。

パタンスペクトルについて、ピークレベルの軸を逆数で表したものが Fig. 2.14 の右図である。この傾向と LPC スペクトルによる傾向が類似していることから、2.1 で述べたように厳密に一致するものではないが、パタンスペクトルのレベルは周波数の逆数に相当しているものと考えられる。

次に、これらの分布が正規分布に従うと仮定したベイズ判定法を用いて、事後確率が最大となるクラスに割りつけるパタン識別を行った (Table 2.2)。評価は、トレーニングデータとテストデータの割合を5:5とした Cross Validation を10回行った平均とする。LPC を用いた場合、2ピークまでを用いた場合よりも、3ピークまで用いた方が認識精度が高くなった。対して、モルフォロジーの場合は、2ピークまでに留めた場合の方が認識精度が高くなった。

また、5クラスのデータから3クラスを抽出してパタン識別を行った結果、選んだ文字と手法によって認識精度が大きく変化した。特に、モルフォロジーの*/a u o/*クラスの判別の場合、85 [%] の認識精度が得られ、*/i u e/*クラスの場合は45 [%] しか得られなかった。LPC を用い

た場合は、これと逆の傾向を見せ、これは、LPC が*i u e*のような正弦波に類似した形状を抽出し、モルフォロジーが*a o*のような尖ったノイズに対して上手く作用したためであると考えられる。

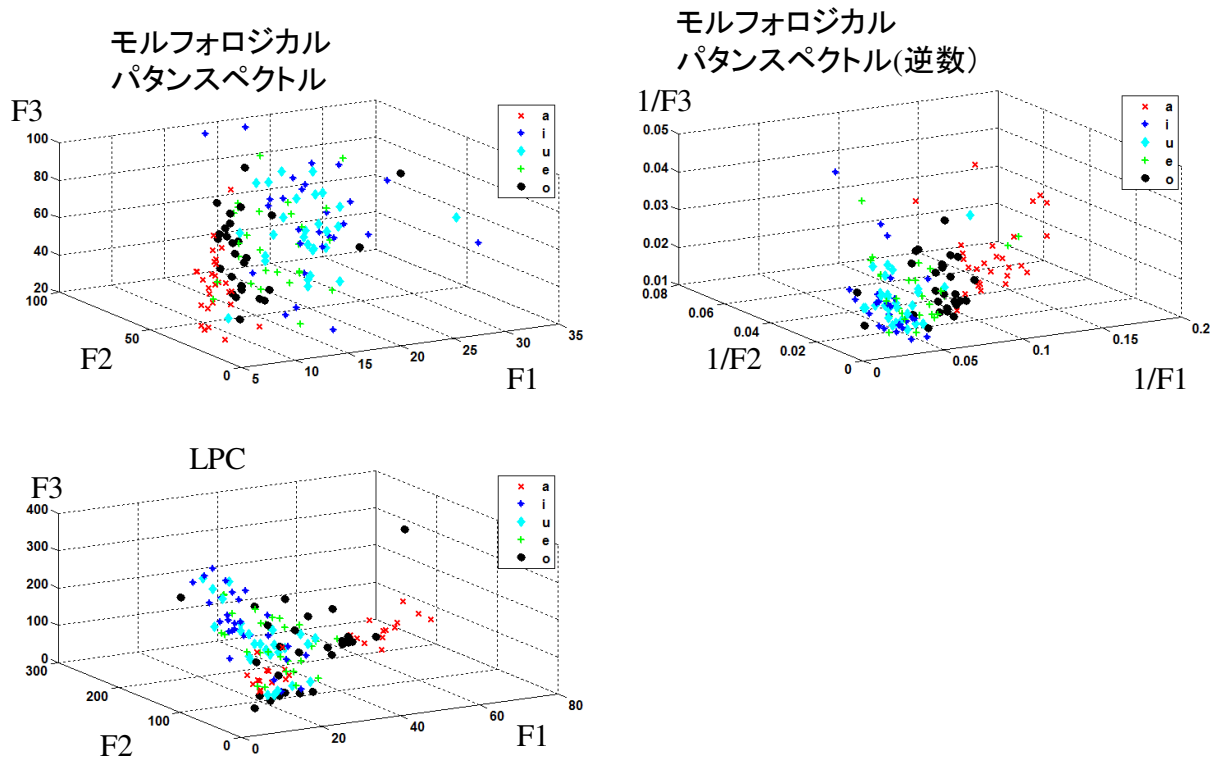


Fig. 2.14 ホルマント周波数の分布

Table 2.2 ピークレベルを特徴量とした場合のパターン識別結果

	5 class (/a i u e o/)		3 class (/a u o/)		3 class (/i u e/)	
	Granulometry	LPC	Granulometry	LPC	Granulometry	LPC
$\mathbf{s} = [F_1, F_2]^T$	57.0%	45.0%	85.0%	61.3%	45.0%	50.0%
$\mathbf{s} = [F_1, F_2, F_3]^T$	51.8%	47.0%	79.7%	69.7%	42.7%	48.3%

## 2.3 モルフォロジーを用いた時間周波数解析

### 2.3.1 多重解像度解析

時間によって周波数成分が変化しない周期的信号に対する解析においては、得られた信号全体を用いてフーリエ変換 (Fourier Transform: FT) や前述のパターンスペクトル (Pattern Spectrum: PS) などで特徴抽出を行うことができる。しかしながら、音声信号、脳波信号、地震波など、時間によって周波数成分が変化する非定常信号に対しては、周波数成分の時間変動も調べる必要があるため、信号をいくつかの短い区間に区切り、フレーム毎に特徴抽出を行う短時間スペクトルが有効になる。



短時間フーリエ変換 (Short Time Fourier Transform: STFT) は、フーリエ変換を短区間ごとに行う時間周波数解析手法であり、様々な分野で用いられている。しかしながら、短時間スペクトルから特徴を推定するためには、時間分解能と周波数分解能高いことが望ましく、これらの積を一定量以下にはできないという不確定性原理がある。ウェーブレット変換 (Wavelet Transform: WT) は、この原理を保ちつつ、高周波域では時間分解能を高くし、低周波域では周波数分解能を高くするように基底関数を伸縮させる手法である。このような短時間スペクトルは、信号が有する特徴を視覚化する上で重要なツールとなるが、情報の冗長性が高いため、多重解像度解析の枠組みを取り入れた離散ウェーブレット変換 (Discrete Wavelet Transform: DWT) もしばしば用いられている。これは、信号と基底関数であるマザーウェーブレットの畳み込み和で得られる低周波域の系列に対してダウンサンプリングを施し、その出力系列に対して繰り返し同等の処理を施すものであり、これによって得られる分解系列には情報の冗長性がない。これに対してさらに、高周波領域の系列に対して繰り返し処理を行う展開方法があり、前者を通常ウェーブレット展開 (Usual Wavelet)、後者を完全ウェーブレット展開 (Full Wavelet) と呼ぶ。

信号の集合を  $V_j, W_j$  とする。  $V_j$  はレベル  $j$  の低周波成分、  $W_j$  はレベル  $j$  の高周波成分である。  $V_j$  の要素を  $x_j$  で、  $W_j$  の要素を  $y_j$  で表す。モルフォロジカルフィルタを用いた信号分離において、Eq. (2.16) の低周波成分の抽出が、  $\psi^\uparrow : V_j \rightarrow V_{j+1}$  であるとする。入力信号  $x_0 \in V_0$  が与えられ、次の再帰的な分解スキームを考える。

### 1. 通常ウェーブレット展開

入力信号  $x^0 \in V_0$  に対して、次の再帰的な分解スキームが与えられる。

$$x^0 \rightarrow \{x_L^1, x_H^1\} \rightarrow \{x_{LL}^2, x_{LH}^2, x_H^1\} \rightarrow \dots$$

このスキームでは、低周波成分の出力を繰り返し解析される (Fig. 2.15(a)).

### 2. 完全ウェーブレット展開

完全ウェーブレットスキームは、次の再帰的な分解スキームが与えられる。

$$x^0 \rightarrow \{x_L^1, x_H^1\} \rightarrow \{x_{LL}^2, x_{LH}^2, x_{HL}^2, x_{HH}^2\} \rightarrow \dots$$

このスキームでは、高周波成分・低周波成分の両方が繰り返し解析される (Fig. 2.15(b)).

また、信号系列のダウンサンプリングではなく、マザーウェーブレットのアップサンプリングにより多重解像度解析を構築する定常ウェーブレット (Stationary Discrete Wavelet Transforms: SWT) (Fig. 2.15(c)) は、信号系列の持つ情報が冗長になるが、シフト不変性などの性質を持ち、DWT より多くの情報を抽出することができる。

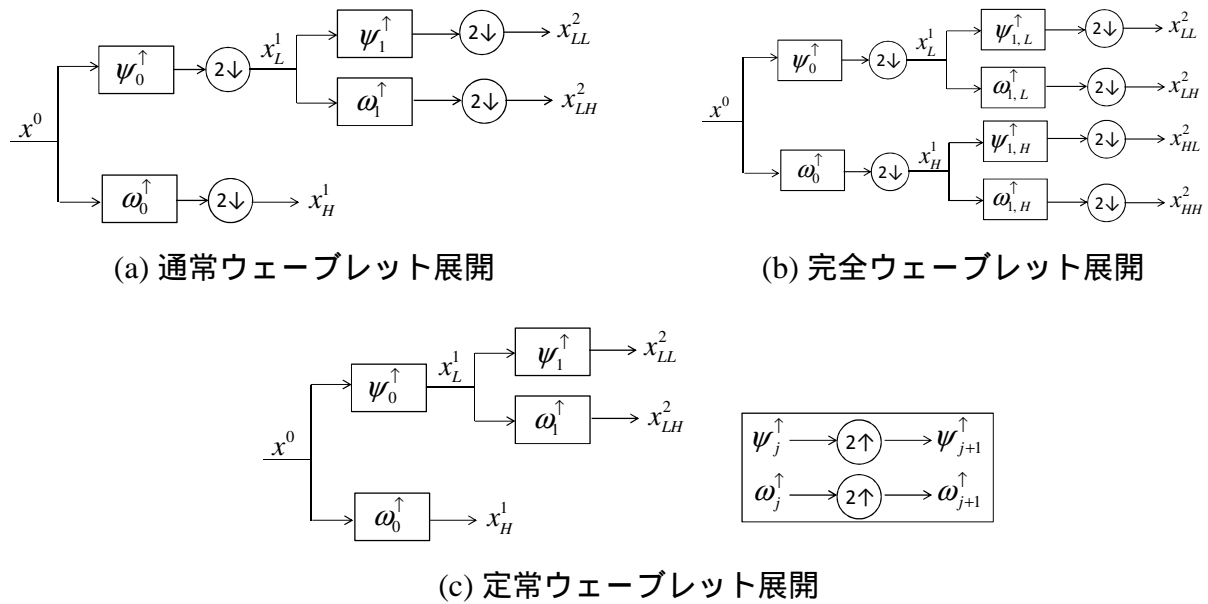


Fig. 2.15 信号分解スキーム

### 2.3.2 モルフォロジカル・ハール・ウェーブレット

ハール・ウェーブレット (Haar Wavelet: HW) は, DWT の枠組みの中で最も単純なマザーウェーブレットを用いて構成される.

$$x_{j+1}(t) = \frac{1}{2}(x_j(2t) + x_j(2t + 1)), \quad y_{j+1}(t) = x_j(2t + 1) - x_j(2t) \quad (2.33)$$

HW のモルフォロジー版であるモルフォロジカル・ハール・ウェーブレット (Morphological Haar Wavelet: MHW) は, 次式で定義される演算を行い多重解像度解析を構成するものである [34].

$$x_{j+1}(t) = \min(x_j(2t), x_j(2t + 1)), \quad y_{j+1}(t) = x_j(2t + 1) - x_j(2t) \quad (2.34)$$

2 値画像に対する HW と MHW 処理の一例を Fig. 2.16 に示す. それぞれ, レベル 3 まで分解を行っているが, レベル 3 の LL 成分に着目すると HW においては原図形には無かった灰色の成分が表れているが, MHW は原図形の白黒の成分のみで原図形を表現できている. このように, MHW はエッジやパルスなどの線形手法では除去が難しい処理を行うことができる. 一方で, ガウスノイズに対するノイズ除去能力が低いため, 適切な構造要素設計を行う必要もある.

### 2.3.3 冗長性モルフォロジカル・ウェーブレットと局所パタンスペクトル

冗長性モルフォロジカル・ハール・ウェーブレット (Redundant Morphological Haar Wavelet: R-MHW) は, MHW と SWT の枠組みを組み合わせた信号分解手法である. これは, MHW の多重解像度分解において分解系列のダウンサンプリングの代わりに, 構造関数の拡張を行うことで構成され, 分解された情報に冗長性が発生するが, シフト不変性の特徴を得る. ここでは, 計算コストを減らすため, 構造関数の拡張に Minkowski 演算の分配法則 (Eq. (2.29))

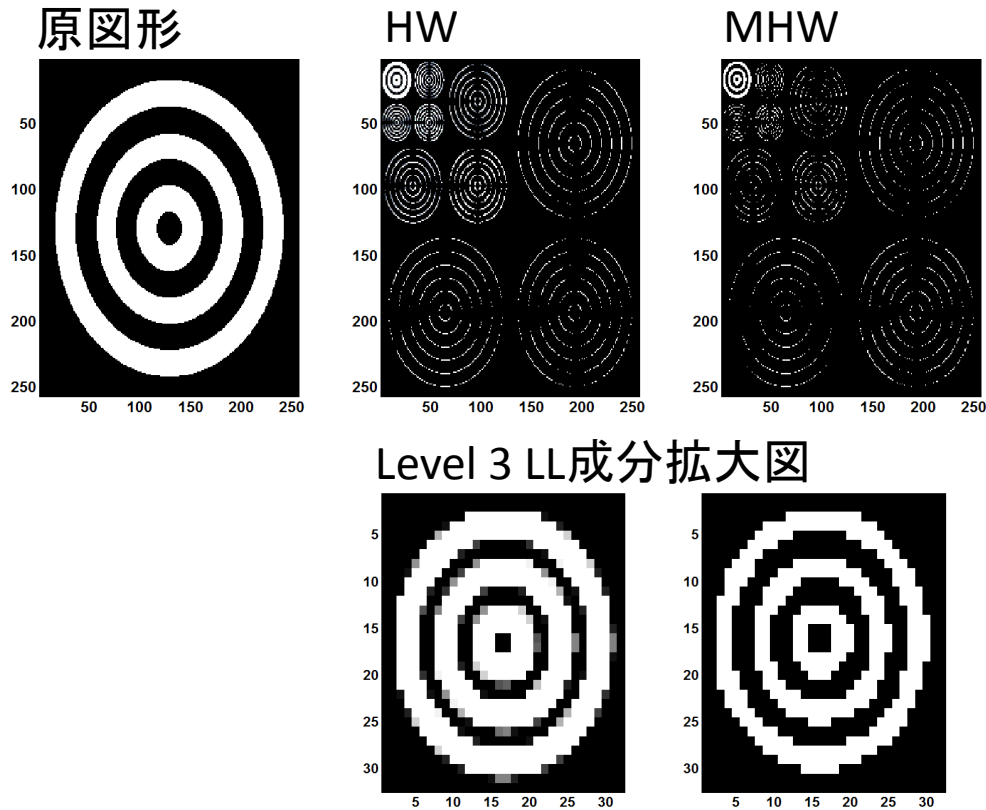


Fig. 2.16 2値画像に対するハール・ウェーブレットとモルフォロジカル・ハール・ウェーブレット

を利用する．また，高周波成分(詳細演算)の出力には，モルフォロジーの高周波通過フィルタを用いる．すなわち，分解レベル  $j$  (窓幅  $j$ ) における R-MHW の出力を次式で得る．

$$\begin{aligned}
 x_{j+1}(t) &= \epsilon_j(x_j)(t), & y_{j+1}(t) &= x_j(t) - x_{j+1}(t) & (2.35) \\
 \epsilon_j(f) &= \underbrace{(\epsilon \circ \epsilon \circ \dots \circ \epsilon)}_j(f), & \epsilon(f)(t) &= \min(f(t), f(t+1))
 \end{aligned}$$

ここで， $\epsilon$  は，窓幅が 2 で構造関数が 0 の値をとる erosion 演算であり， $\epsilon_j$  は， $j$  回の erosion 演算を意味し，処理の結果として窓幅  $j+1$  内の最小値が得られる．

上式の低周波成分(近似演算)の出力は，入力信号の底をたどる軌跡が得られる．ここで，近似演算が任意のモルフォロジー演算で置き換えられることから，ミンコフスキー差に対応する最小値演算を opening 処理, closing 処理で代用することで，信号の極性を加味したより細かな信号分解を行う．すなわち，R-MHW は，次式で置き換えられる．

$$\begin{aligned}
 & \begin{cases} x_{j+1}(t) = \delta_j(\epsilon_j(x_j))(t), & y_{j+1}(t) = x_j(t) - x_{j+1}(t) & j \geq 1 \\ x_{j+1}(t) = \epsilon_j(\delta_j(x_j))(t), & y_{j+1}(t) = x_{j+1}(t) - x_j(t) & j < 1 \end{cases} & (2.36) \\
 \epsilon_j(f) &= \underbrace{(\epsilon \circ \epsilon \circ \dots \circ \epsilon)}_j(f), & \epsilon(f)(t) &= \min(f(t), f(t+1)) \\
 \delta_j(f) &= \underbrace{(\delta \circ \delta \circ \dots \circ \delta)}_j(f), & \delta(f)(t) &= \max(f(t), f(t+1))
 \end{aligned}$$

ここで,  $\delta$  は, 窓幅が 2 で構造関数が 0 の値をとる dilation 演算であり,  $\delta_j$  は,  $j$  回の dilation 演算を意味し, 処理の結果として窓幅  $j + 1$  内の最大値が得られる. これは,  $j \geq 1$  で信号の正の方向成分に着目した信号分解を行い,  $j < 0$  で負の方向成分に着目した分解を行う.

また, 扱う信号の極性に重要な情報が含まれていない場合, 最小値演算を open-closing 処理で代用することもできる.

$$\begin{aligned} x_{j+1}(t) &= \epsilon_j(\delta_j(\delta_j(\epsilon_j(x_j))))(t), & y_{j+1}(t) &= x_j(t) - x_{j+1}(t) \\ \epsilon_j(f) &= \underbrace{(\epsilon \circ \epsilon \circ \dots \circ \epsilon)}_j(f), & \epsilon(f)(t) &= \min(f(t), f(t+1)) \\ \delta_j(f) &= \underbrace{(\delta \circ \delta \circ \dots \circ \delta)}_j(f), & \delta(f)(t) &= \max(f(t), f(t+1)) \end{aligned} \quad (2.37)$$

ここで, R-MHW で分解した系列は, 前節で説明した信号のパタンスペクトルの時間積分を行う前の状態と一致する. そのため, 時系列信号を短区間に区切り, 区間ごとにパタンスペクトルを求める処理は, 時系列信号を R-MHW で分解し, 各レベルについて短区間で時間積分をとることと等しくなる. すなわち, opening 処理と closing 処理を用いた R-MHW に対する局所的なパタンスペクトルは, 次式で得ることができる.

$$P(x_0, j, t_0) = \sum_{t=t_0}^{t_0+\Delta t} y_j(t) \quad (2.38)$$

open-closing 処理を用いた R-MHW に対する局所パタンスペクトルについては, 分解系列が正負の値をとるため, 値の絶対値をその区間のスペクトル値とする.

$$P(x_0, j, t_0) = \sum_{t=t_0}^{t_0+\Delta t} |y_j(t)| \quad (2.39)$$

### 2.3.4 音声信号に対する適用

ここでは, 実環境において計測された音声信号に対して短時間パタンスペクトルを求め, この手法の有効性を確認する.

#### 2.3.4.1 実験データ

実験データは, 2.2 で用いた実環境における連続音声”日本語方言の地域差方言音声コーパス (GSR-JD)”である. この実験データは, 133 名の異なる地域の話者からなる音声データで, 16k [Hz] のサンプリング周波数, 16 [bit] の A/D 変換で計測している. /a i u e o/と連続発生した際の実験データを解析に用いる.

#### 2.3.4.2 解析方法

音声信号を open-closing 処理に基づく R-MHW で展開し, 短区間ごとに振幅の絶対値の時間積分をとり短時間スペクトルを求める. この非線形手法と STFT, LPC の短時間スペクトル, 連続ウェーブレット (Continuous Wavelet Transform: CWT) 手法の比較を行う.

### 2.3.4.3 結果

Fig. 2.17 に、連続発声された/a/i/音に対するハールを基底とする DWT, SWT, MW, および open-closing 処理に基づく冗長性モーフォロジカルウェーブレットの展開系列を示す。冗長性ウェーブレットの枠組みとなる SWT と R-MHW の方が、非冗長手法よりも細かな解析を行うことができ、さらに、R-MHW は、信号に含まれる特徴を形状ごとに分離できていることが確認できる。

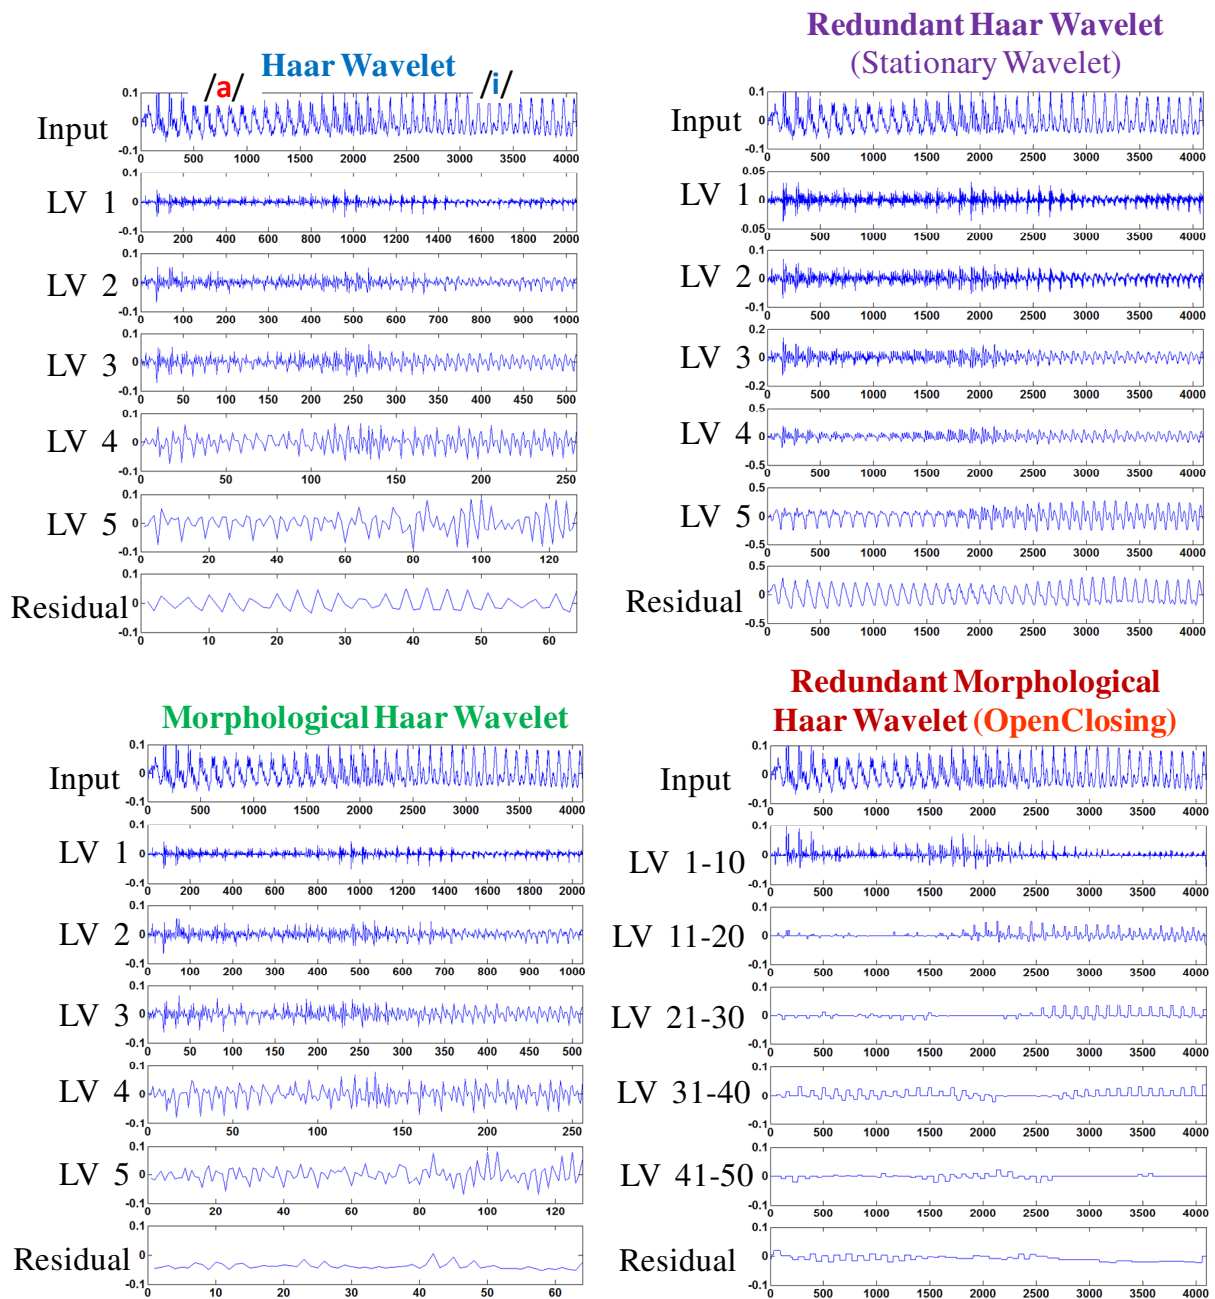


Fig. 2.17 多重解像度解析 (連続発声/a/ /i/)

局所パタンスペクトル導出のための展開レベルは、手動の区間検出の結果も加味して 70 とした。分離を行った結果、短時間で LPC や STFT, また、SWT が全周波数帯域に成分を表わしてしまうことに対して、モーフォロジー手法では、いくつかのピークに特徴をまとめるに留

める。これは、実環境データにパルス性雑音が混入し、周波数的手法であると全周波数帯域に成分が抽出されたためであると思われる。

より短い窓幅で解析を行った結果、モルフォロジカル手法が孤立的であるのに対して、特にLPCが上手く特徴が得られていない。これは、LPCスペクトル推定のための十分なデータが得られていないためであると考えられる。

ダウンサンプリングの結果からみても、これが分かる。元の信号の分布に比べて、一つおきにデータを間引いた結果、2つおき、4つ置き、8つおき、それぞれ比べた結果、信号のサンプリング周波数が下がるほど、モルフォロジーで表現できる領域が狭くなっている。

つまり、LPCなどの手法は、十分に解析するためには、十分長い実験時間（解析長）が必要であり、提案するモルフォロジー手法は、十分に細かいサンプリング周波数が必要である。

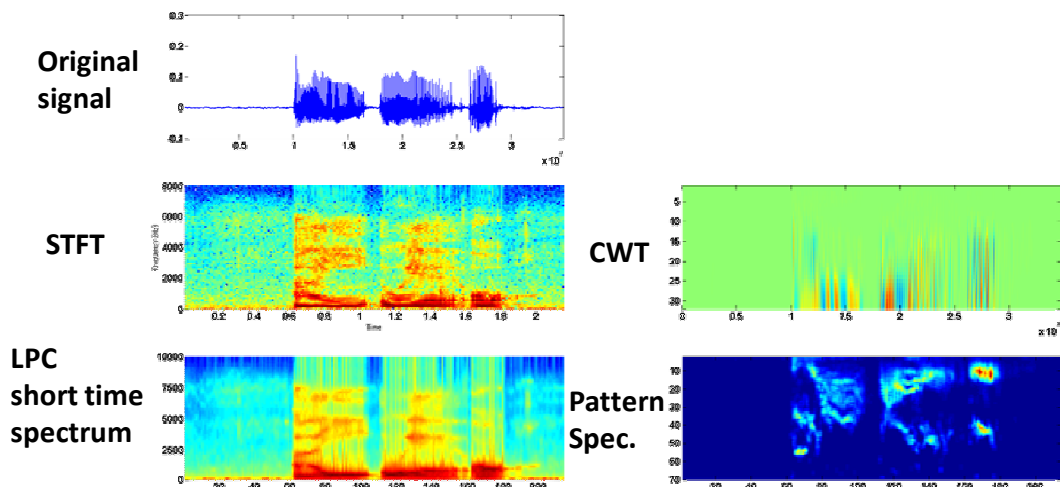


Fig. 2.18 時間周波数解析 (long data)

(analyzing step: 160 [pt] (10 [ms]), processing length: 400 [pt] (25 [ms]))

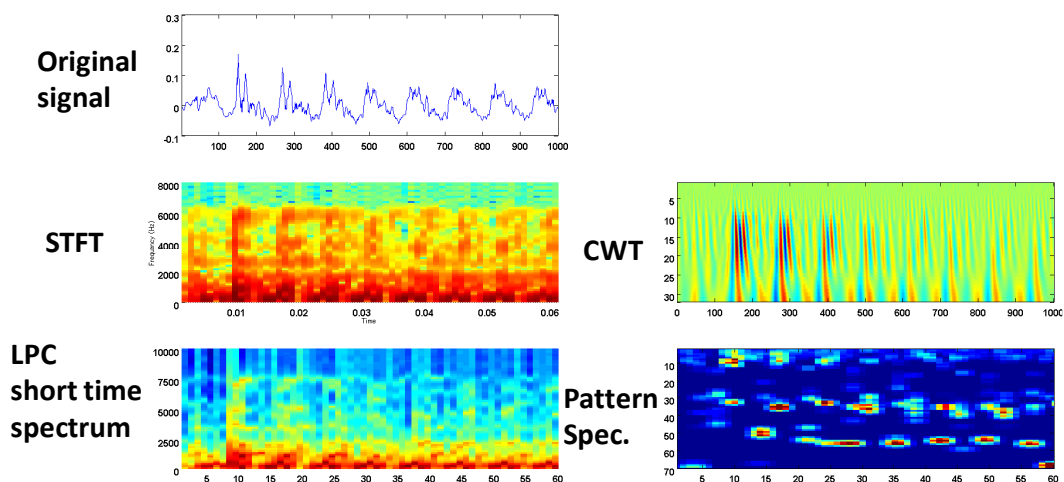


Fig. 2.19 時間周波数解析 (short data)

(analyzing step: 16 [pt] (1 [ms]), processing length: 40 [pt] (2.5 [ms]))

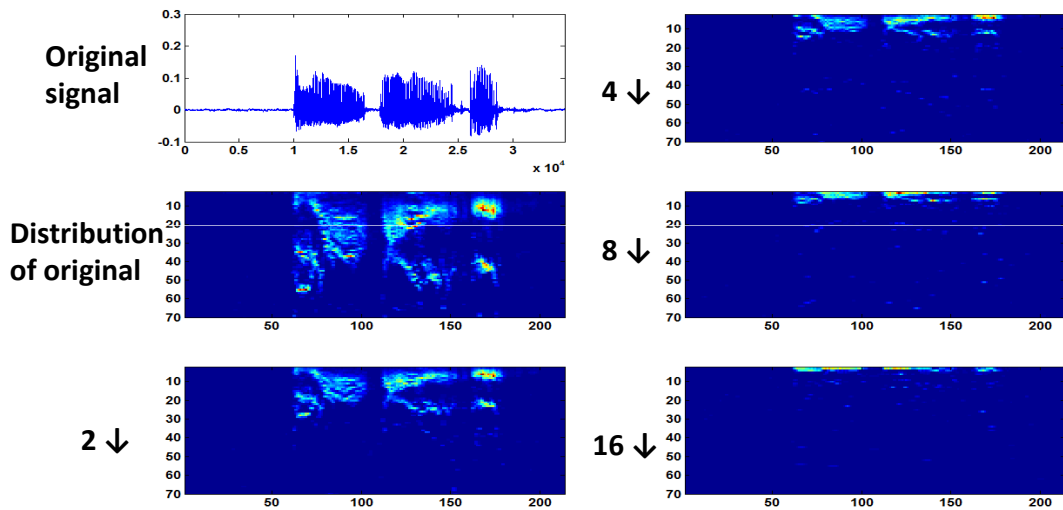


Fig. 2.20 ダウンサンプリングの影響

### 2.3.5 睡眠時脳波信号に対する適用

ここでは、終夜睡眠実験で得られた脳波信号に対してパタンスペクトル、短時間パタンスペクトルを求め、これらの手法の有効性を確認する。

脳波信号は非常に複雑な波形パターンを有しているが、正常安静時の脳波は比較的正しいリズムを有しており、 $\alpha$ 波、様々な周波数成分を含む低電位波 ( $L$ 波)、高振幅徐波などの背景脳波と、それに重畳して出現する睡眠紡錘波、 $K$ 複合波、頭頂部鋭波、運動覚醒波、鋸歯状波などがある。これらの波形パターのうち、 $\alpha$ 波、 $L$ 波、高振幅徐波、睡眠紡錘波、 $K$ 複合波の一例を Fig. 2.21 に示す。これらの脳波波形パターの出現率や出現系列と眼球運動図からの急速眼球運動 (Rapid Eye Movements: REMs) 情報、筋電図からの筋電位レベルをもとに、睡眠脳波ステージは定義され、一般に、覚醒段階 (Stage W) と睡眠段階 (Stage 1~4, Stage REM) の 6 段階に分けられている [53][54]。




Fig. 2.21 睡眠時脳波信号の波形パターン

### 2.3.5.1 実験データ

ここで用いる生体データは、日本睡眠学会 (Japanese Society of Sleep Research: JSSR) において行われた実験のものであり、判読医の視察判定で睡眠段階が確認されている。実験データ (JSSR009) は、4チャンネルの脳波データ (EEG) と眼電図 (EOG), 筋電位図 (EMG) が約8時間計測されている。その中で脳波は、C3-A2, C4-A2, O1-A2, O2-A2の単極導出により計測されている。サンプリング周波数は、500 [Hz] である。

### 2.3.5.2 解析方法

睡眠脳波ステージは、覚醒段階 (Stage W) と睡眠段階 (Stage 1~4, REM) の6段階に分けられている。特に、Stage 1では $\alpha$ 波が多く、Stage 4では高振幅徐波が多く表れる。そのため、モルフォロジーの短時間パタンスペクトルを用いてこれらの時間変化を解析するものとする。

### 2.3.5.3 結果

パタンスペクトル解析を行った結果を Fig. 2.22, Fig. 2.23, Fig. 2.24 に示す。Fig. 2.22, Fig. 2.23 は、20秒間のC3-A2脳波データの処理を行ったものであり、窓幅0.1 [sec], 解析ステップ幅0.05 [sec] である。例えば、Fig. 2.23の信号の1秒目に負の電位変化があるが、短時間スペクトルにおいてこの成分はclosing処理によってのみ表れるため、負のスペクトルで表わされる。このように、短時間パタンスペクトルは、信号の極性情報も保持したスペクトル情報を表すことができ、細かな波形の解析に用いることができると考えられる。

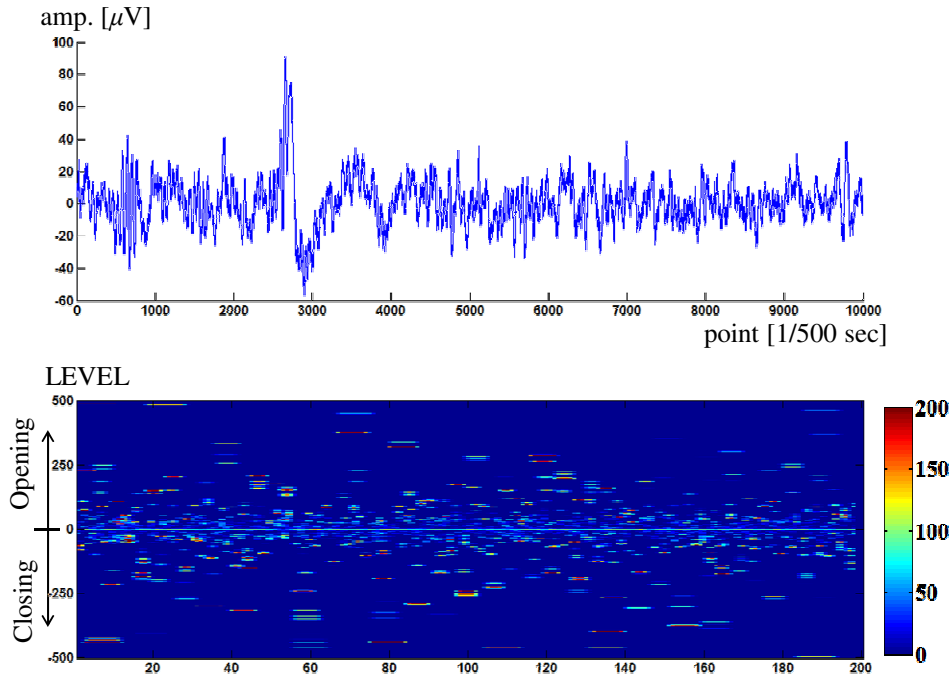


Fig. 2.22 睡眠時脳波信号のパタンスペクトル (20sec, Stage 1)

Fig. 2.24 上図は、窓幅を 20 [sec], ステップ幅を 20 [sec] とした一晩分 (8 時間) の処理結果であり、Fig. 2.24 下図は、判読医の視察判定結果である。寝返りなどの大きな体位変動である Stage MT は、短時間パタンスペクトルにおいては低レベルでまとめて表れ、高振幅徐波など



が表れる Stage 3, 4 においては, 信号成分は高レベルのスペクトルで表れる. このように, 睡眠ステージに応じてスペクトルのパワーが変動するため, ルフォロジー短時間スペクトルは, 特徴をより詳しく解析することで睡眠状態を判別できるツールになると考えられる.

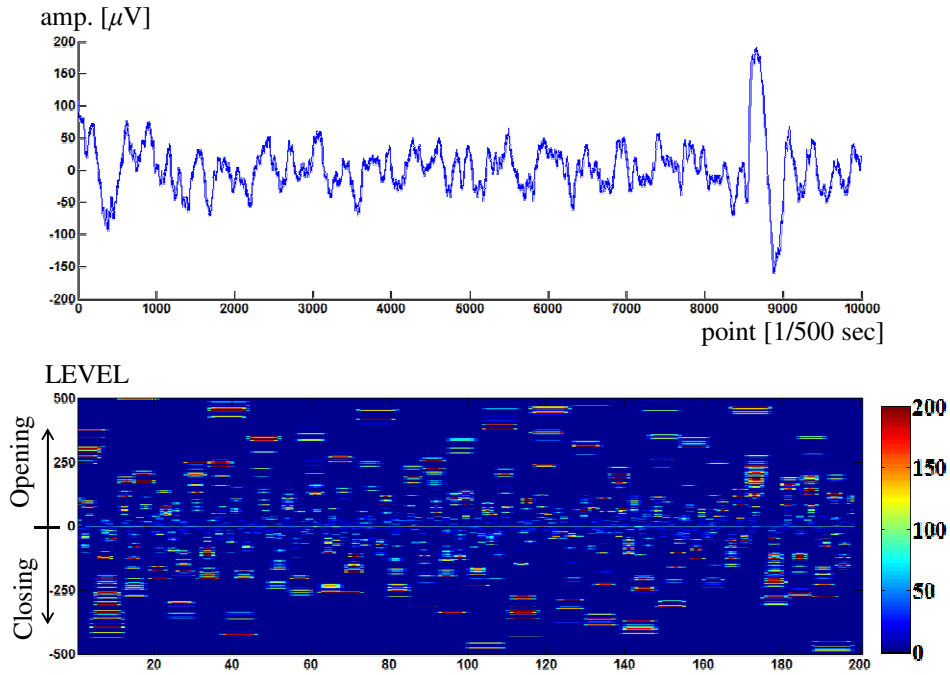


Fig. 2.23 睡眠時脳波信号のパターンスペクトル (20sec, Stage 4)

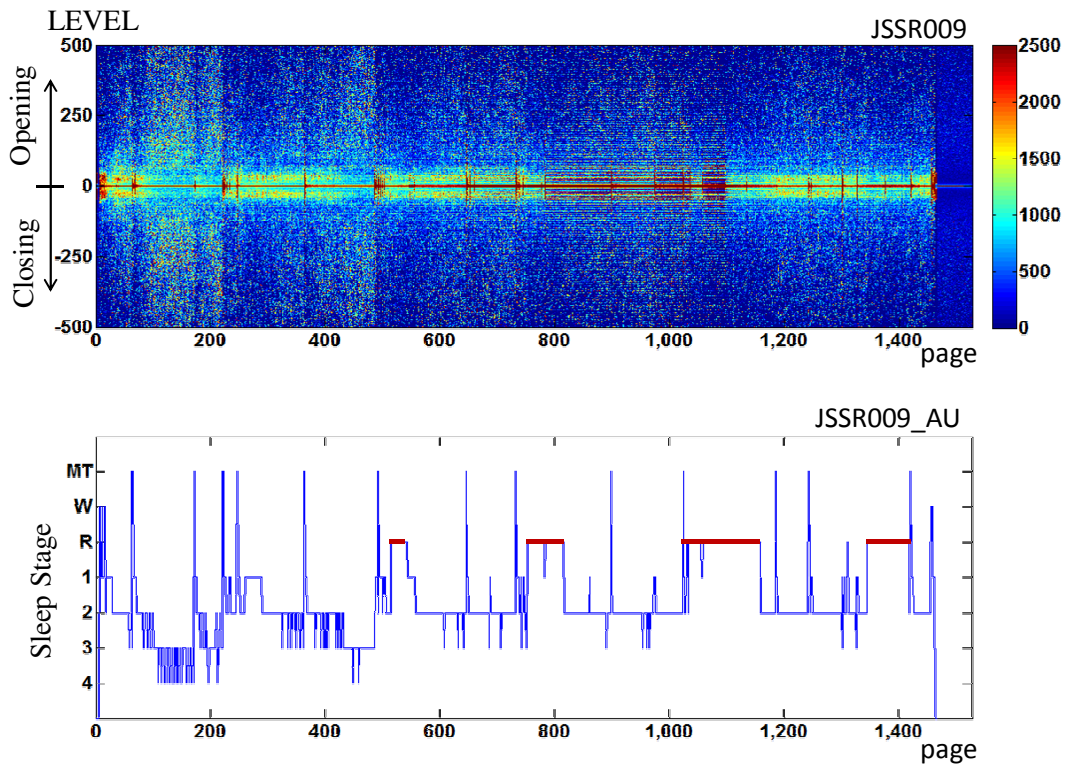


Fig. 2.24 睡眠時脳波信号のパターンスペクトル (all night)

## 2.4 モルフォロジカルフィルタのフィルタ設計

本節では、モルフォロジカルフィルタのフィルタ設計方法について述べる。2.1 節では、モルフォロジカルフィルタの周波数特性について述べ、そのフィルタ特性が構造関数の形状だけでなく入力信号の振幅にも影響を受けることを示した。すなわち、モルフォロジカルフィルタは、線形フィルタとは直感的に異なる特性を持ち、そのためフィルタを設計するための手法を考える必要がある。フィルタ設計についての関連研究としては、浅野らのPGPCモデルや西田の多項式関数近似手法があるが、これらは対象とする信号・画像が有する情報をあらかじめ知る必要がある [17][21]。

本節においては、扱う時系列信号が有する特徴が先見的に未知であるものとして、その信号が有する情報を別々の信号に自動的に分類する手法を考案する。単一の構造関数で設計されるモルフォロジカルフィルタは、一つの時系列信号に対してその高周波成分と低周波成分の2信号を出力させることができる。そのため、構造関数をパラメトリックなモデルで表し、出力する2信号間の距離関数を最大にする構造関数のパラメータを推定することで、一つの時系列信号に含まれる信号の情報を別々の信号に自動的に分解する。パラメトリックな構造関数として、超楕円型モデルを用い、信号の距離関数として結合エントロピーと周波数スペクトル分離手法を提案する。さらに、短区間ごとに分離を行う短時間モルフォロジカルフィルタ分離に関して、その枠組みと特性について述べる。

### 2.4.1 超楕円型構造関数によるモルフォロジーマルチレベル分解

時系列信号における超楕円構造関数の形状は、値軸  $k$ 、窓幅  $2n$  および  $p$  の3パラメータによって一意に定まる。

$$g(t) = \begin{cases} k \left(1 - \left|\frac{t}{n}\right|^p\right)^{\frac{1}{p}} & (-n \leq t \leq n) \\ -\infty & (\text{otherwise}) \end{cases} \quad (2.40)$$

信号構造を分離するモルフォロジカルフィルタ設計のために、これらのパラメータは、それぞれの分離信号  $x_L$  と  $x_H$  が異なる情報を持つようにランダム探索で最適化される。分離信号間の違いとして、2種類の評価法(結合エントロピー最大化, スペクトル分割)を利用し、これは入力信号依存に決まる。モルフォロジカルマルチ分解を構成するために、構造関数の形状は各レベルでそれぞれ異なるものを選択する。一つの構造関数によって得られる2つの出力(低周波成分, 高周波成分)は、同じアルゴリズムで得られる異なる構造関数を用いて、それぞれ分解処理が行われる。すなわち、完全ウェーブレットスキームが、このアルゴリズムに適用される。

信号構造を分離するモルフォロジカルフィルタ設計のために、これらのパラメータは、それぞれの分離信号  $x_L$  と  $x_H$  が異なる情報を持つようにランダム探索で最適化される。分離信号間の違いとして、2種類の評価法(結合エントロピー最大化, スペクトル分割)を利用し、これは入力信号依存に決まる。モルフォロジカルマルチ分解を構成するために、構造関数の形

状は各レベルでそれぞれ異なるものを選択する．一つの構造関数によって得られる2つの出力(低周波成分, 高周波成分)は, 同じアルゴリズムで得られる異なる構造関数を用いて, それぞれ分解処理が行われる．すなわち, 完全ウェーブレットスキームが, このアルゴリズムに適用される．

### 1. 結合エントロピー最大化手法

構造関数の形状を定めるパラメータは, 分離信号  $\mathbf{x}^j = \{x_L^j, x_H^j\}$  間の結合エントロピーを最大化するように選択される (Fig. 2.25)．このとき, 結合エントロピーが成分間の不確かさを意味するため, 分離信号間の関係は統計的独立に近づくものになる．結合エントロピーの密度関数には, 正規分布が仮定される．

$$\begin{aligned}
 H(\mathbf{x}) &= - \int p(\mathbf{x}) \log_2 p(\mathbf{x}) d\mathbf{x} \\
 &= - \int \frac{1}{(2\pi)^{n/2} |\Sigma|^{1/2}} \cdot \exp \left[ -\frac{1}{2} (\mathbf{x} - \mathbf{m})^T \Sigma^{-1} (\mathbf{x} - \mathbf{m}) \right] \\
 &\quad \cdot \left\{ \log_2 \frac{1}{(2\pi)^{n/2} |\Sigma|^{1/2}} + \log_2 \left( \exp \left[ -\frac{1}{2} (\mathbf{x} - \mathbf{m})^T \Sigma^{-1} (\mathbf{x} - \mathbf{m}) \right] \right) \right\} d\mathbf{x} \\
 &= - \log_2 \frac{1}{(2\pi)^{n/2} |\Sigma|^{1/2}} \cdot \int p(\mathbf{x}) d\mathbf{x} - \int p(\mathbf{x}) \frac{\log_e \left( \exp \left[ -\frac{1}{2} (\mathbf{x} - \mathbf{m})^T \Sigma^{-1} (\mathbf{x} - \mathbf{m}) \right] \right)}{\log_e 2} d\mathbf{x} \\
 &= - \log_2 \frac{1}{(2\pi)^{n/2} |\Sigma|^{1/2}} - \log_2 e \cdot E \left\{ -\frac{1}{2} (\mathbf{x} - \mathbf{m})^T \Sigma^{-1} (\mathbf{x} - \mathbf{m}) \right\} \\
 &= \log_2 (2\pi)^{n/2} |\Sigma|^{1/2} + \frac{1}{2} \log_2 e \cdot E \left\{ (\mathbf{x} - \mathbf{m})^T \Sigma^{-1} (\mathbf{x} - \mathbf{m}) \right\} \\
 &= \log_2 (2\pi)^{n/2} |\Sigma|^{1/2} + \frac{n}{2} \log_2 e = \log_2 \left[ (2\pi e)^{n/2} |\Sigma|^{1/2} \right] = \frac{1}{2} \log_2 \{ (2\pi e)^2 |\Sigma| \} \quad (2.41)
 \end{aligned}$$

$\mathbf{x}^j = \{x_L^j, x_H^j\}$  に対しては, 次式のように展開される．

$$\begin{aligned}
 H(\mathbf{x}^j) &= \frac{1}{2} \log_2 \{ (2\pi e)^2 |\Sigma| \} \\
 &= \frac{1}{2} \log_2 \left\{ \frac{(2\pi e)^2}{N-1} \left( \sum_{t=1}^N (x_L^j(t) - \bar{x}_L^j)^2 + \sum_{t=1}^N (x_H^j(t) - \bar{x}_H^j)^2 - 2 \sum_{t=1}^N (x_L^j(t) - \bar{x}_L^j)(x_H^j(t) - \bar{x}_H^j) \right) \right\} \\
 &\quad \left( \bar{x}_L^j = \frac{1}{N} \sum_{t=1}^N x_L^j(t), \bar{x}_H^j = \frac{1}{N} \sum_{t=1}^N x_H^j(t) \right)
 \end{aligned}$$

ここで,  $\Sigma$  は  $\mathbf{x}^j$  の共分散行列を示し,  $x_L^j(t)$  と  $x_H^j(t)$  は, 時刻  $t$  における  $x_L^j$  と  $x_H^j$  をそれぞれ示す．

### 2. スペクトル分離手法

構造関数の形状パラメータは, 信号の周波数成分が分かれるようにパラメータを最適化される．この手法では, 分離周波数としてパラメータ  $F_{sp}$ , ペナルティ項  $K_p$ , 評価する周波数区間として  $F_{min}$  と  $F_{max}$  を処理前に定める必要がある．

$$C(\mathbf{x}^j) = \frac{\int_{F_{min}}^{F_{sp}} (\hat{x}_L^j(f) - K_p \cdot \hat{x}_H^j(f)) \cdot \hat{x}^{j-1}(f) df}{F_{sp} - F_{min}} + \frac{\int_{F_{sp}}^{F_{max}} (\hat{x}_H^j(f) - K_p \cdot \hat{x}_L^j(f)) \cdot \hat{x}^{j-1}(f) df}{F_{max} - F_{sp}} \quad (2.42)$$

ここで、 $x^{j-1}$  は  $\mathbf{x}^j$  の原信号であり、 $\hat{\mathbf{x}}^j = \{\hat{x}_L^j, \hat{x}_H^j\}$  は  $\mathbf{x}^j$  のフーリエスペクトル (パワースペクトル) である。周波数成分を分離する構造関数の形状パラメータは、この評価関数を最大化することで得られる。

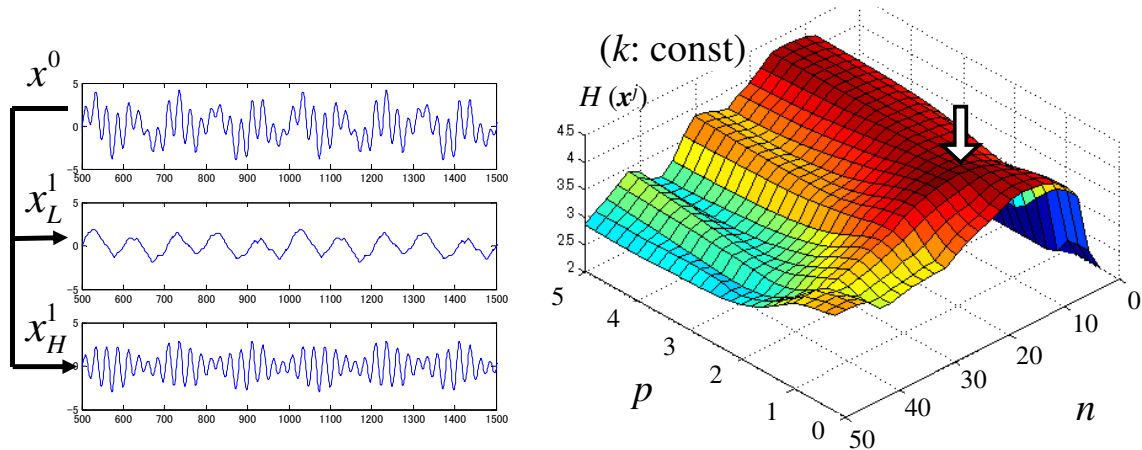


Fig. 2.25 評価量のマップ

#### 2.4.1.1 超楕円型構造関数の場合のシミュレーション

結合エントロピー最大化手法 (M-JET) の一つの結果を、Fig. 2.26 に示す。この例では、SNR を 10 [dB] としている。始めに、原信号は構造関数  $\psi_1^\dagger$  でのモルフォロジカルフィルタを用いて低周波・高周波成分に分解される。これらの信号は、互いに統計的に独立になるように分解される。抽出される成分が表れるレベルは、このアルゴリズムが評価関数の最大点を探索するため、唯一でない。たとえば、SNR が 10 [dB] の場合は、30 [Hz] の正弦波成分がレベル HL に抽出されるが、SNR が -1 [dB] の場合は、レベル LH に抽出される (Tables 2.3, 2.4)。出力となる低周波成分・高周波成分は、同じアルゴリズムが適用されるが、異なる形状の  $(\psi_{2,L}^\dagger, \psi_{2,H}^\dagger)$  構造関数が推定され、これを用いてそれぞれ分解される。原信号の正弦波成分は、十分な分解レベルで処理したとき、別々のレベルに抽出された (Table 2.3)。

スペクトル分割手法の一つの結果を、Fig. 2.27 に示す。この場合、先験的なパラメータは、例えば分離周波数  $F_{sp}$  を正弦波成分と白色成分の分離を行うために 20 [Hz] に設定している。このように、スペクトル分割手法は、原信号が有する情報を事前に知っておく必要がある。提案手法 (M-JET, M-SPD) の相関係数の値は、M-FLT 手法よりも向上している (sin (30 [Hz]): M-JET:0.71, M-FLT:0.60; sin (5 [Hz]): M-SPD: 0.90, M-FLT: 0.83)。

これらの結果より、実際の信号への適用には、構造関数の形状パラメータを自動決定するモルフォロジー解析がより信号からの特徴抽出に適していると言える。特に、結合エントロピー最大化手法は、事前に信号が有する情報を知る必要がないことなら、含まれている成分が未知の信号を解析するときにも有用である。

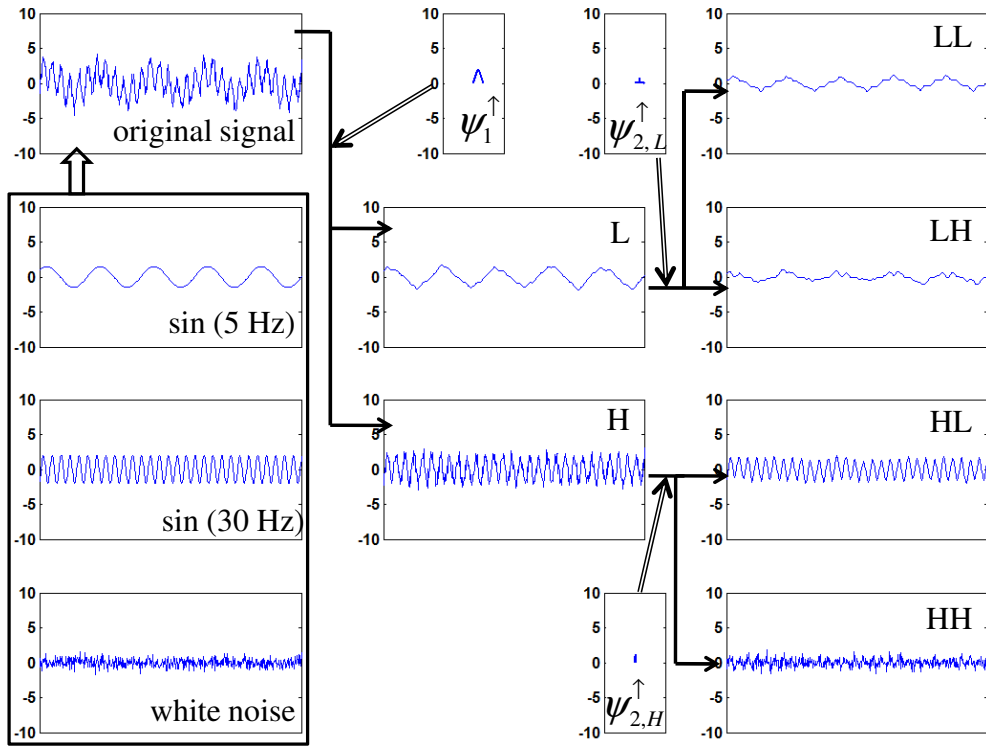


Fig. 2.26 白色ノイズの少ない正弦波信号に対する解析

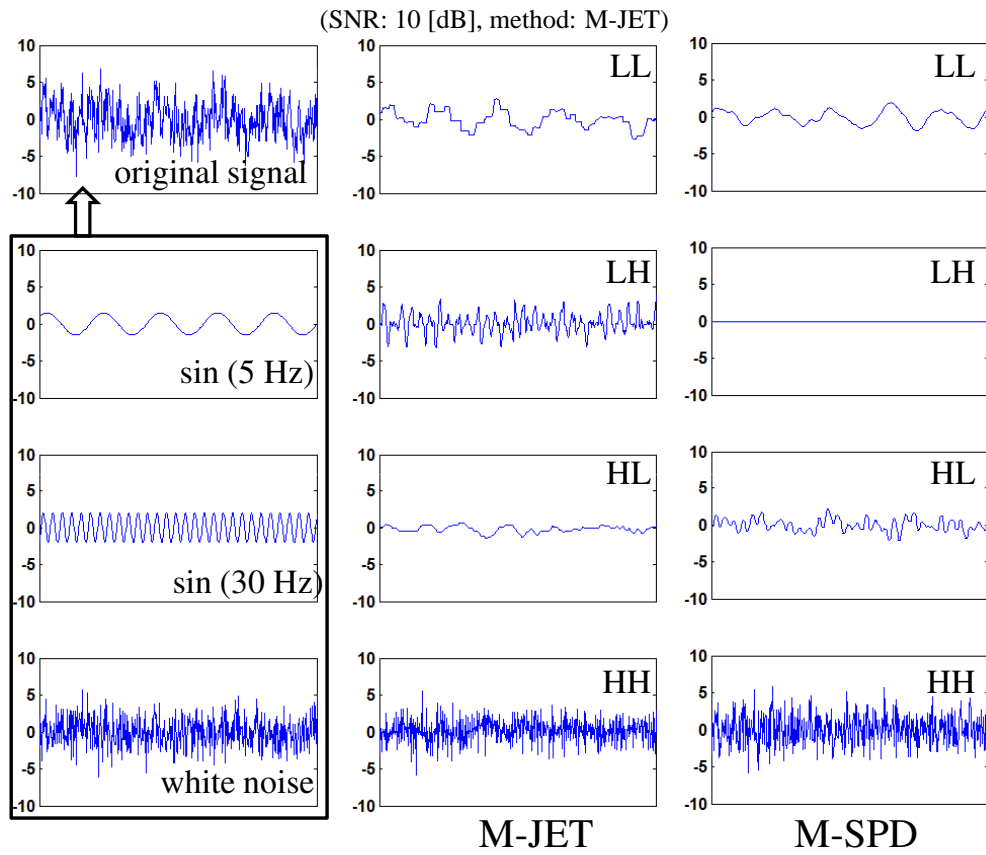


Fig. 2.27 M-JET手法とM-SPC手法の比較

(SNR: -1 [dB],  $K_p$  : 0.5,  $F_{\min}$  : 2,  $F_{\max}$  : 40,  $F_{\text{sep}}$  : 20, 3, 35 [Hz])

Table 2.3 原信号との相関係数 (白色ノイズ, SNR: 10 [dB])

	M-JET			M-SPD		
	sin	sin	white	sin	sin	white
	5 Hz	30 Hz		5 Hz	30 Hz	
LL	<u>0.96</u>	0.03	-0.05	<u>0.99</u>	0.04	-0.03
LH	<u>0.89</u>	0.121	0.00	0.00	0.00	0.00
HL	0.08	<u>0.97</u>	0.02	0.13	<u>0.94</u>	0.08
HH	0.03	<u>0.50</u>	<u>0.74</u>	0.01	<u>0.62</u>	<u>0.59</u>

M-JET: SuperEllipse (Joint entropy)

M-SPD: SuperEllipse (Spectrum dividing)

Table 2.4 原信号との相関係数 (白色ノイズ, SNR: -1 [dB])

	M-JET			M-SPD		
	sin	sin	white	sin	sin	white
	5 Hz	30 Hz		5 Hz	30 Hz	
LL	<u>0.81</u>	0.19	0.10	<u>0.90</u>	0.03	0.03
LH	-0.02	<u>0.71</u>	0.34	0.03	0.00	-0.06
HL	0.27	0.03	-0.02	0.15	<u>0.59</u>	0.16
HH	-0.05	0.06	<u>0.82</u>	0.01	0.38	<u>0.83</u>

M-JET: SuperEllipse (Joint entropy)

M-SPD: SuperEllipse (Spectrum dividing)

## 2.4.2 短時間モルフォロジカルフィルタ分離

前節のフィルタ設計手法については、時間的に信号の状態が変動しないモデルを仮定した。信号が有する特徴が先験的に既知であれば、対象区分に対する処理を行うことで特徴抽出ができるが、未知の場合は、短時間フーリエ変換のように、短時間に区切ったデータに対して、それぞれ処理を行うのが妥当である。Fig. 2.28 には、モルフォロジカルマルチレベル分解を短時間に区切った信号に対して施した結果であり、下部に、それぞれの区間で推定された構造関数を示す。構造関数推定には、結合エントロピー最大化を用いている。シミュレーション信号においては、尖った信号成分がある区間では尖った構造関数が推定され、丸みを有する特徴がある区間には、丸い構造関数が推定されている。このように、推定された構造関数を見ることで、信号が有する形状成分を抽出できることが確認できる。

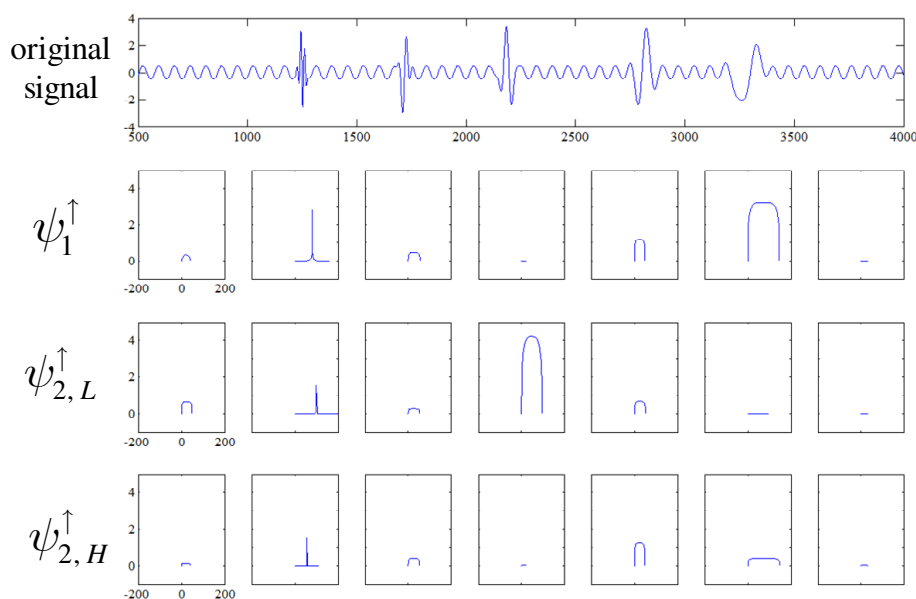


Fig. 2.28 短時間モルフォロジー分解

## 2.5 フーリエ解析との対応関係

これまでに述べたモルフォロジー解析とフーリエ解析には、いくつかの類似点がある。本節においては、その対応関係についてまとめる。

線形時不変システム  $\mathcal{L}$  は、入力信号  $x(t)$  に対して、重ね合わせの理と移動不変性が成り立つ。

$$\mathcal{L}\left[\sum_i a_i x_i(t)\right] = \sum_i \mathcal{L}[x_i(t)] \quad (2.43)$$

$$\mathcal{L}[x(t - t_0)] = [\mathcal{L}(x)](t - t_0) \quad (2.44)$$

次の単位パルス信号、

$$\delta(t) = \begin{cases} 1 & ; t = 0 \\ 0 & ; t \neq 0 \end{cases} \quad (2.45)$$

を線形時不変システムの入力として、その応答 (単位パルス応答) を、

$$\phi[\delta(t)] = h(t) \quad (2.46)$$

とする。このとき、任意の入力  $x(t)$  が単位インパルス信号を用いて、

$$x(t) = \sum_{m=-\infty}^{\infty} x(m)\delta(t - m) \quad (2.47)$$

と表せることを利用すれば、

$$y(t) = \sum_{m=-\infty}^{\infty} x(m)h(t - m) = \sum_{m=-\infty}^{\infty} h(m)x(t - m) \quad (2.48)$$

が成立する。この関係を畳み込みとよび、 $y(t) = x(t) * h(t)$  と表す。この関係は線形信号処理にとって基本的かつ重要な演算である。式 (2.48) からわかるように、線形時不変システムは単位パルス応答を定めれば記述できる。

線形時不変システムの入力として複素指数関数

$$x(t) = e^{j\omega t} \quad (2.49)$$

を考え、これを式 (2.48) に代入すれば、次式を得る。

$$y(t) = \sum_{m=-\infty}^{\infty} h(m)e^{j\omega(t-m)} = e^{j\omega t} \sum_{m=-\infty}^{\infty} h(m)e^{-j\omega m} \quad (2.50)$$

ここで、周波数特性 (応答) を

$$H(e^{j\omega}) = \sum_{m=-\infty}^{\infty} h(m)e^{-j\omega m} \quad (2.51)$$

と定義する．この式は， $\omega$  の複素関数であるので，その絶対値を  $|H(e^{j\omega})|$ ，偏角を  $\theta(\omega)$  とすれば，

$$H(e^{j\omega}) = |H(e^{j\omega})|e^{j\theta(\omega)} \quad (2.52)$$

と表すことができる．ここで， $|H(e^{j\omega})|$  を振幅特性 (応答)， $\theta(\omega)$  を位相特性 (応答) とよぶ．

式 (2.51) と式 (2.52) から，線形時不変システムの周波数特性はその伝達関数において， $z = e^{j\omega}$  とすれば求まることがわかる．また式 (2.51) は単位パルス応答の離散時間フーリエ変換でもある．よって，逆離散時間フーリエ変換を用いて，周波数特性と単位インパルス応答は

$$h(t) = \frac{1}{2\pi} \int_0^{2\pi} H(e^{j\omega}) e^{j\omega t} d\omega \quad (2.53)$$

として関連付けられる．

以上から単位パルス応答を指定すれば周波数特性を，逆に周波数特性を指定すれば単位パルス応答を求めることができる．すなわち，線形時不変システムを特徴づけるためには，周波数特性 (あるいは振幅と位相特性) を指定すれば十分である．さらに単位パルス応答の  $z$  変換から伝達関数が決まることを考えれば，単位パルス応答，伝達関数，周波数特性は，線形時不変システムの等価な表現となっている．表現の違いが存在するのは，それぞれの表現が得意とするものが異なり，使われ方が異なるためである．

一方で，構造関数  $g$  によるミンコフスキー和  $\delta_g$  も，入力信号  $x(t)$  に対して，分配律と移動不変性が成り立つ．

$$\delta_g(\vee_i f_i) = \vee_i \delta_g(f_i) \quad (2.54)$$

$$\delta_g(f_{\vee}) = \delta_{g_{\vee}}(f) = (\delta_g(f))_{\vee} \quad (2.55)$$

同様に，ミンコフスキー差  $\epsilon_g$  も，次式の関係が成り立つ．

$$\epsilon_g(\wedge_i f_i) = \wedge_i \epsilon_g(f_i) \quad (2.56)$$

$$\epsilon_g(f_{\wedge}) = \epsilon_{g_{\wedge}}(f) = (\epsilon_g(f))_{\wedge} \quad (2.57)$$

すなわち，線形時不変システムと非線形手法であるミンコフスキー演算には，システムとして類似性があり，関数の入出力関係についてみると，線形システムの掛け算と畳みこみ和が，非線形システムの加算減算と最大値最小値演算に相当することとなる．

$$\text{畳みこみ} : y(t) = \int f(t-\tau)g(\tau)d\tau \quad (2.58)$$

$$\text{Minkowski 和} : y(t) = \max_{t-\tau \in F, \tau \in G} \{f(t-\tau) + g(\tau)\} \quad (2.59)$$

$$\text{Minkowski 差} : y(t) = \min_{\tau \in G} \{f(t-\tau) - g(\tau)\} \quad (2.60)$$

また，前節で直観的ではあるが，パタンスペクトルにおけるレベルの逆数が，フーリエ変換のパワースペクトルにおける周波数に対応することを示した．そのため，パワースペクト



ルを区間ごとに求める短時間フーリエ変換は，短時間パタンスペクトルに対応することが同様に言える．さらに，基底関数を  $e^{j\omega t}$  とは別の関数としたウェーブレット変換は，Heijmans の提案するモルフォロジカルウェーブレットに対応し，モルフォロジ構造関数の自動決定手法は，信号から基底関数を自動決定するマッチング追跡に対応するものと考えられる．

この他にも，ミンコフスキー演算を用いて信号の傾きを検出する手法である傾き変換は，フーリエ解析におけるフーリエ変換に対応し [15]，原図形を様々なサイズの構造要素でのミンコフスキー差による軌跡で表現するモルフォロジカル・スケルトン [11] は，フーリエ展開に対応することが明らかとなっている．

Table 2.5 モルフォロジ解析とフーリエ解析の対応関係

モルフォロジ解析		フーリエ解析
Minkowski 和	↔	畳み込み
Minkowski 差	↔	畳み込み
パタンスペクトル	↔	パワースペクトル
短時間パタンスペクトル	↔	短時間フーリエ変換
モルフォロジカルウェーブレット	↔	ウェーブレット
モルフォロジ構造関数自動決定	↔	マッチング追跡
スケルトン	↔	フーリエ展開
傾き変換	↔	フーリエ変換

## 2.6 結言

本章では，非線形解析手法であるマセマティカル・モルフォロジについて，その特性について述べ，新たな解析手法について提案するとともに数学的枠組みを整備し，信号処理への適用に関して検討した結果を示した．

モルフォロジカルフィルタは，フーリエ解析と類似した枠組みを持つため，フーリエ解析を時間周波数領域に拡張した STFT や WT などの手法や，さらに DWT を拡張した MP 法や SWT などの手法の枠組みをモルフォロジ解析に取り入れて，冗長性モルフォロジカル・ハールウェーブレットについて提案した．また，パタンスペクトルの概念を取り入れた冗長性モルフォロジカル・ハールウェーブレットの局所スペクトルは，パルス性雑音に強く，高調波成分も出現しないため，時系列信号から STFT とは別の情報が抽出できることを音声信号や睡眠時脳波信号への適用を通じて示した．特に，この手法はフーリエ解析で見られるスペクトルの対称性という特徴が表れず，信号の振幅の極性に依存して非対象な構造を持つスペクトルを出力する．これは，睡眠時脳波信号のように，信号の振幅情報に重要な情報が含まれている場合に特に有効な信号解析ツールとなり得る．一方，音声信号のような信号の振幅情報に本質的な意味を持たない場合も，モルフォロジ演算の組み合わせである open-closing

演算を多重解像度解析の基本演算とすることで、フーリエ解析と同様の枠組みのスペクトルを出力することができる。

モルフォロジカルフィルタのフィルタ特性は、構造関数の形状によって定まり、フィルタの周波数特性は入力信号の振幅によっても可変であることを示した。これは、非線形フィルタであるモルフォロジカルフィルタが、線形フィルタと直感的に異なる性質を持つことを示したものであり、本章においてはまた、このフィルタ設計手法について提案を行った。単一の構造関数で設計されるモルフォロジカルフィルタは、一つの時系列信号に対してその高周波成分と低周波成分の2信号を出力させることができる。そのため、構造関数をパラメトリックなモデルで表し、出力する2信号間の距離関数を最大にする構造関数のパラメータを推定することで、一つの時系列信号に含まれる信号の情報を別々の信号に自動的に分解する枠組みを考案した。また、このときに推定される構造関数は、対象とする時系列信号が有する形状に類似したものが推定されるため、この手法は新たな特徴抽出の一手法としても利用できる可能性がある。

以上のように、マセマティカル・モルフォロジーを拡張した本章で述べた提案手法は、対象とする時系列信号から線形手法で得られる情報とは異なる特徴を抽出することができる。線形手法と直感的に異なる特性を示すことや計算コストなどの問題点もあるが、ここで示す提案手法は、扱う未知の信号からその信号が有する情報を抽出するための効果的な解析手法であると言える。

## 3 BCIシステムにおける脳波信号解析

### ～ 特徴量抽出と変動解析 ～

脳波 (Electroencephalogram: EEG) が脳内の状態によって変化することは、脳波の発見者である Berger によって 1929 年に報告され、1933 年に Adrian によって追試・確認が行われて以来、病的疾患の診断のみならず、脳のメカニズムを解明する上で興味のある研究対象として、多くの研究者によって研究が行われている。

また最近では、選択反応時の事象関連電位の変動や、外的光刺激の周波数に応じた脳波周波数変動、動作想像時の脳波変動を検出し、コンピュータや装置のインターフェースとして利用しようという脳コンピュータインターフェース (Brain Computer Interface: BCI) あるいは脳マシンインターフェース (Brain Machine Interface: BMI) と呼ばれる研究も盛んに行われている。これは、手足の不自由なハンディキャップユーザのための装置として、研究が進められているが、脳波マウスなど正常成人の通常使用を意識した研究も始まっている。

本章においては、これまでに行った BCI システムの実装と利用に関する研究について、その実験システムと解析方法をまとめる。まず、脳波に表れる特徴について概説し、選択反応時の事象関連電位変動を抽出するのに最も代表的であるオドボール課題実験について触れ、この変動導出のフレームワークを利用した文字入力システムを紹介し、追実験と解析方法について検討する。次に、動作想像時脳波を利用した手足動作想像識別実験について触れ、近年活発に研究がなされている光誘発電位を利用した注視点検出システムについてまとめる。

Table 3.1 は、本研究において 23 名の被験者に対して行った脳波計測実験についてにまとめたものである。なお、実験 2 の聴覚性オドボール課題実験の実験データについては、日本精神・神経センターで計測されたものを用いている。

### 3.1 脳波概説

#### 3.1.1 脳波計測手法

脳波記録装置、すなわち脳波計は、電極入力部、増幅部、記録部、電源部から構成されている (Fig. 3.1)。脳波計測実験においては、脳波以外の生体活動 (心電図、眼球運動、呼吸曲線、表面筋電図など) を脳波と同時記録することが多いので、1 チャンネル以上の万能アンプを備えた脳波計が良いとされる。通常は、循環器系の監視及び脳波に混入する R 波 (心室の電氣的興奮を反映する波) や脈波の識別に心電図が同時記録される。また、意識レベルなどの検査には眼球運動も同時記録することが望ましいとされる。電極には、通常は脳波検査では分極を起こしにくい銀・塩化銀を用いた皿状電極が使用され、電極用接着ペーストを用いて頭皮に固定する。電極の配置には、国際脳波学会の勧告による国際 10-20 電極法が一般的であり、これは頭皮 19 箇所と左右の耳朶電極 2 本とアース電極 (額に装着) 1 本の計 22 個の電極を使用する (Fig. 3.2)。ただし、目的によっては、必要最小限の電極を用いても良いとさ

Table 3.1 脳波計測実験 一覧

No.	実験名	被験者(実験日数)	クラス数	Sampling rate
1	視覚性オドボール課題実験	04y7 (6), 04f9 (3)	2	1000 [Hz]
2	聴覚性オドボール課題実験	172 例 (国立精神・神経センター)	2	1000 [Hz]
3	P300 タイプライタ	07s1 (3), 07y2 (3)	36	512 [Hz]
4	右手左手動作想像実験	05t1 (20), 05y2 (20), 05k3 (20), 06k4 (10), 06n5 (10), 06u6 (10)	2	128 or 500 [Hz]
5	手足動作想像実験	06s1 (10), 06c2 (11), 06o3 (10)	3	128 [Hz]
6	フェールセーフ機構を備えた BCI システム	07n1 (3), 07u2 (3), 07y3 (3)	4	512 [Hz]
7	SSVEP を利用した注視点検 出システム	09y4 (3), 09h5 (3), 09u6 (3)	9	512 [Hz]
8	T-VEP を利用した単一光源 注視パタン検出システム	08o1 (3), 08o2 (3), 08m3 (3)	2	512 [Hz]
9	T-VEP を利用した多光源注 視パタン検出システム	09k1 (2), 003sm (3), 004km (3), 022mm (3), 028sh (3), 034my (3)	4 or 9	512 [Hz]

れる。

本研究においては、脳波以外の生体信号は主に雑音源の特定のために利用する。たとえば、動作想像時脳波を計測する際には実際に動作を行っていないことを確認するために腕などの表面筋電図を記録する。生体信号計測には、デジタル脳波計の EEG-1100 (日本光電) および g.USBamp (g.tec 社) の 2 種類を用いた。電極配置箇所、サンプリング周波数、フィルタ条件などについては、目的とする実験に応じて変えていくため、これらに関してはその都度述べるものとする。

### 3.1.2 事象関連電位

脳波には、疾患の判断に用いられる特徴や、睡眠の深さを測るために利用する特徴など、さまざまな特徴があるが、ここでは、BCI に利用できる特徴についてまとめる。インターフェース構成については、様々な知見・アイデアがあるが、主に利用されている特徴は次の 8 種である。

1. 運動準備電位 (Bereitschafts Potential: BP)
2. 事象関連脱同期・同期 (Event Related Desynchronization/Synchronization: ERD/ERS)
3. 事象関連電位 (Event Related Potential: ERP)
4. 視覚誘発電位 (Transient Visual Evoked Potential: T-VEP)
5. 定常性視覚誘発電位 (Steady State Visual Evoked Potentials: SSVEP)
6. 聴性脳幹反応 (Auditory Brainstem Response: ABR)
7. 聴性定常反応 (Auditory Steady State Response: ASSR)
8. 緩変動電位 (Slow Cortical Potential: SCP)




Fig. 3.1 脳波計の概念




Fig. 3.2 国際 10-20 法に基づく電極配置図

本研究では特に, ERD/ERS, ERP, T-VEP, SSVEP を用いた BCI システムの構築と短時間脳波からの特徴抽出について試みる.

### 3.2 事象関連電位を利用したシステム

本節では, 事象関連電位 P300 を用いた文字入力インターフェースの実装と特徴抽出についてまとめる.

オドボール課題実験は, 頻度の異なる刺激に対して, 低頻度刺激時のみカウンティングやボタン押し行うなどのタスクを課した際に, 中心部 (Cz) 付近に認知活動に関連して出現する事象関連電位 P300 を取得するものである. 刺激としては, 通常, 光刺激または音刺激が利用され, 低頻度標的的刺激, 高頻度非標的的刺激の他に, 低頻度非標的的刺激を課する実験もある. 本節においては, まず, 視覚性オドボール課題実験を行い, その実験データを解析した結果と, 国立精神・神経センターの計測した聴覚性オドボール課題実験に対して解析を行った結果をまとめる.

この特徴を利用した脳波信号を入力とする文字入力システムが Guger らによって開発されている [60]. この研究においては, 脳波の加算平均的処理を施したものを入力とするため, 1 文字の判別に 30 [sec] 程度の脳波入力を必要とする. ここでは, その追実験を行い実現可能性について確認するとともに, 独立成分分析 (ICA) を用いた特徴抽出により短時間の脳波入力での文字入力ができるシステムについて検討する.

### 3.2.1 視覚性オドボール課題実験 ( 1 )

#### 3.2.1.1 実験データ

本実験は、認知課題タスクを被験者に課するものであり、その際に表れる事象関連電位を計測するものである。

実験は、外部からのノイズを遮断するため、銅線で覆ったシールドルームの中で行う。被験者は、呈示用モニタ前方約 100 [cm] の位置に設置したマッサージチェアに座る。

視覚刺激としては色刺激を用い、赤色と緑色を 3:7 (標的刺激:非標的刺激) の割合で呈示させ、その出現回数を被験者に頭の中でカウントするよう指示を与えるものである。刺激呈示は 750 [msec] で、刺激呈示間隔を 2000-4000 [msec] とする (Fig. 3.3)。

実験には、日本光電製のデジタル脳波計 (EEG-1100) と、視覚刺激呈示用 PC を用いる。デジタル脳波計でのサンプリング周波数は、1000 [Hz] である。

被験者は 2 名で、合わせて 9 日間の実験を行っている (被験者 (04y7) (6 [sessions]), 被験者 (04f9) (3 [sessions])). 計測した 20 チャンネルの脳波信号の電極配置を Fig. 3.4 に示す。刺激呈示時刻を正確に計測するため、視覚刺激用 PC に取りつけた照度計の出力も同時に記録している。




Fig. 3.3 視覚性オドボール課題実験 タイミングチャート




Fig. 3.4 実験 ( 1 ) 電極配置図

#### 3.2.1.2 解析方法

ここでは、モルフォロジーのマルチレベル分解を行い、特定のレベル帯域に P300 などの電位変化を抽出することを試みる。

分解に用いる構造関数は、Flat 型と楕円型の 2 種類とし、フィルタの窓幅である時間軸方向のパラメータを各レベルにおいて 2 のべき乗で幅を増やすものとする。また、分解レベル

は，Flat 型を 6 とし，楕円型を 8 とする (Table 3.2).

	$g_0$	$g_1$	$g_2$	$g_3$	$g_4$	$g_5$	$g_6$	$g_7$	$g_8$
Flat 型 窓幅 ( $2n+1$ )	3	5	9	17	33	65	129		
楕円型 窓幅 ( $2n+1$ )	3	5	9	17	33	65	129	257	513

楕円型構造関数の値軸方向のパラメータ  $k$  は，各レベルにおいて高周波成分  $\omega^k$  と低周波成分  $\psi^k$  の距離が最大になるものとする．

$$g(t) = \begin{cases} k \sqrt{1 - x^2/a^2} & -n \leq t \leq n \\ -\infty & t < -n, t > n \end{cases}$$

$$k = \arg \max_k \left\{ \sum_{t=t_1}^{t_2} (\psi^k(t) - \omega^k(t))^2 \right\}$$

$t_1, t_2$  は，クラス間の平均的距離が最大となる区間であり，各レベルごとに探索を行う．

$$t_1, t_2 = \arg \max_{t_1, t_2} \left\{ \frac{1}{t_2 - t_1} \sum_{t=t_1}^{t_2} (\psi^k(t) - \omega^k(t))^2 \right\} \quad (3.1)$$

また，この構造関数パラメータの推定による事象関連電位の分解特性を調べるため，次式の各レベル間の差分を調べる．

$$e_j = \sum_{t=t_1}^{t_2} (\omega_j(t) - \omega_{j-1}(t))$$

次に，標的刺激・非標的刺激間のパターン識別を，特定レベルの分離信号の和を取り再構成を行い，振幅の積分値を特徴量として行う．

$$s = \sum_{j=j_1}^{j_2} \sum_{t=t_1}^{t_2} \omega(j) \quad (3.2)$$

この特徴量の分布は，正規分布に従うものと仮定し，ベイズ判別法を用いて判別を行う．

### 3.2.1.3 結果

事象関連電位 P300 や刺激として用いる視覚刺激により誘発されて表れる視覚誘発電位電位 N100 は，電位変化の極性に生理学的意味を持つため，Flat 型構造関数を用いたモルフォロジーのマルチレベル分解について opening 処理からなる分解と closing 処理からなる分解，また open-closing 処理からなる分解をそれぞれ行う．

始めに，opening 処理に基づくマルチレベル分解で得られる標的刺激・非標的刺激時の脳波信号に対して行った分離結果を Fig. 3.5, Fig. 3.6 に示す．図の左側が低周波成分で，右側が高周波成分である．opening 処理は，信号の負方向からの平滑化処理であるため，正のピー

クを抽出に有用であり，標的刺激時脳波において，特定のレベルに P300 の成分の抽出を確認できる．

次に，closing の結果を Fig.3.7 に示す．処理チャンネルは，視覚刺激に対して特徴が表れやすい後頭部のチャンネル Oz である．Closing 処理は，信号の正方向からの平滑化処理であるため，負のピークを抽出に有用である．この場合，レベル 6 のみに N100 の成分が抽出されることを確認できる．

次に，正負両側からの平滑化処理である open-closing の結果を Fig. 3.8 に示す．標的刺激時脳波において，N100 の成分と P300 の成分が別のレベルに表れることを確認できる．このように，極性に意味がある信号からの特徴抽出には，モルフォロジー処理を用いることで所望の極性情報を持つ信号を抽出することができる．




Fig. 3.5 標的刺激時脳波の Opening 処理 (Channel Fz)




Fig. 3.7 Closing 処理 (Channel Oz)




Fig. 3.6 非標的刺激時脳波の Opening 処理 (Channel Fz)




Fig. 3.8 Open-Closing 処理 (Channel Fz)

次に，楕円型構造関数を用いたモルフォロジーのマルチレベル分解を行い，形状パラメータ推定とパターン識別を行った結果を示す．分解には，open-closing 処理を用いている．マルチレベル分解の一例を Fig. 3.9 に示す．楕円型関数を用いたモルフォロジーの場合，Flat 型構造関数を用いた分解よりも対象信号の波形を滑らかに分解していることが確認できる．

さらに，このマルチレベル分解による信号の分解性能を調べるため，各レベル間の差を求めた．その一例を Fig. 3.10 に示す．マルチレベル分解により片方向に突出したピークを抽出したため，特定のレベルで誤差の符号が反転することが確認できる．この符号が切り替わるレベルが，ピークの成分を含んだ帯域であると考えられる．



また、この差分情報の符号が反転するレベルに対してヒストグラムをとったものを Fig. 3.11 に示す。ここでは、標的刺激、非標的刺激において試行数が異なるため、各クラスの試行数で正規化を行っている。低頻度刺激時の分布に着目すると、レベル5～8に符号が切り替わるレベルが分布していることが確認できる。そのため、レベル5-8の分離データ ( $j_1 = 5$ ,  $j_2 = 8$ ) を用いて再構成を行い、標的刺激・非標的刺激間のパターン識別を行った。結果の一例を Fig. 3.12 に示す。特に中央部電極において、最大で80 [%] 程度の認識精度が得られることが確認できる。




Fig. 3.9 楕円型構造関数を用いた分離 (被験者 04f9, 低頻度刺激, channel: Fz)




Fig. 3.11 特徴が抽出されるレベルのヒストグラム (被験者 04f9)




Fig. 3.10 レベル間の差分 (被験者 04f9)




Fig. 3.12 楕円型構造関数で特徴を抽出した信号のパターン識別結果

## 3.2.2 聴覚性オドボール課題実験 (2)

### 3.2.2.1 実験データ

本実験は、音刺激に対して素早くキー押しをするように指示したときに表れる事象関連電位を計測するものである。

日本臨床神経生理学会のERP手順に準拠し、1000 [Hz] と 1500 [Hz] の純音を刺激として用いて行われたオドボール課題実験時の脳波を使用する。被験者には、1000 [Hz] の純音の際にキー押しのタスクを与えており、出現頻度は2:8とする。なお、信号はチャンネル Cz を用い、サンプリング周波数は 500 [Hz] で、バンドパスフィルタとしては通過帯域が 0.5 ~ 30 [Hz] のものを使用した。

### 3.2.2.2 解析方法

楕円型構造関数を用いた8レベルのモルフォロジカル多重解像度解析を用いて、脳波に含まれる聴覚誘発電位、事象関連電位、ノイズ成分の分離を試みる。

Table 3.3 構造要素のパラメータ

	$g_0$	$g_1$	$g_2$	$g_3$	$g_4$	$g_5$	$g_6$	$g_7$
SE Gain	1	1	1	1	1	1	1	1
SE ProcLen	5	7	11	25	35	47	61	77

### 3.2.2.3 結果

Table 3.3 の構造要素を用いた8レベルの分解結果を Fig. 3.13 に示す。原信号に電源ノイズが付加した波形を分解した場合、ノイズ成分がレベル1と2で抽出された (Fig. 3.13 左)。また、事象関連電位の形状に類似した信号がレベル4と5で抽出された (Fig. 3.13 右)。




Fig. 3.13 多レベル分解

(左：ノイズが混入された信号，中：高頻度刺激時，右：低頻度刺激時)

さらに、各レベルに分離された信号の中で、特定のレベルの信号を用いて再構成を試みた。ノイズの混入した信号に対して、レベル3～8の信号で再構成した信号を Fig. 3.14 に示す。また、レベル4と5の信号で再構成した信号を Fig. 3.15 に示す。これにより、原信号に含まれる識別に有用と思われる波形を抽出できることを確認した。

また、特定のレベルで再構成した信号を加算平均したものを Fig. 3.16 に示す。レベル3と4で再構成した信号の加算平均には、N100の形状が表れた。レベル6と7で再構成した信号の加算平均にはP300の形状が表れ、それよりも狭い形状であるN100は表れなかった。これにより、多重解像度解析的にモルフォロジカルフィルタを用いることで、単一試行脳波から異なる特徴形状をシステムティックに抽出できる可能性を確認した。




Fig. 3.14 レベル3から8を用いた再構成信号

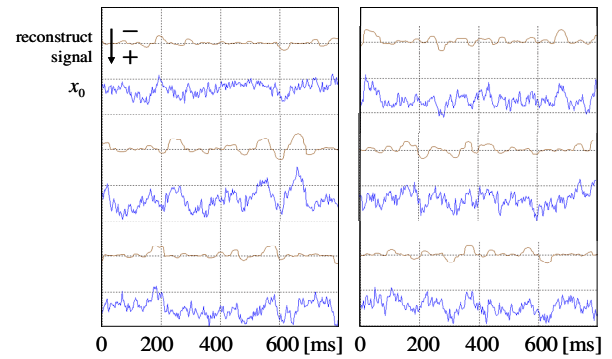


Fig. 3.15 レベル4,5を用いた再構成信号  
(左：高頻度刺激，右：低頻度刺激)




Fig. 3.16 再構成信号の平均信号 (低頻度刺激時)

### 3.2.3 事象関連電位を用いた文字入力システム (3)

#### 3.2.3.1 実験データ

本実験は、既存研究である事象関連電位を利用した文字入力システムについて追従実験を行うとともに、より短い脳波入力で文字入力を行うことを目指し、脳波信号から認知活動に関する情報抽出を試みるものである。

6行6列の文字盤を用意し、0.25秒ごとにひとつの行または列を無作為な順序で光らせる。被験者には、所望の文字が光った際にカウントを行うタスクを与えており、1文字の検出に9秒間の刺激呈示を行う (Fig. 3.17)。刺激呈示の後、行および列ごとに可算平均を行うことで、標的文字を含む要素からは、他の要素よりも大きな振幅の事象関連電位 P300 を観測することができ、最も大きな行と列が交差する点が求められる文字となる。

被験者は2名で、それぞれ3日間の実験を行っている (被験者 (07s1) (3 [sessions]), 被験者 (07y2) (3 [sessions])). サンプル周波数は 512 [Hz] で 20 [channels] の脳波を計測している。なお、本実験では確認の為、計測者が被験者に想像する文字をあらかじめ指示している。



Fig. 3.17 P300 を利用した文字入力システムの刺激装置

### 3.2.3.2 解析方法

事象関連電位は，信号の加算平均により抽出することができる．試行  $j$ , 時刻  $t$  の脳波信号  $y(j, t)$  の加算平均波形は，次式で与えられる．

$$\bar{y}(t) = \frac{1}{M} \sum_{j=1}^M y(j, t) \quad (3.3)$$

本節では，独立成分分析を用いて単一脳波から P300 成分の抽出を試みる．解析に用いる脳波信号は，Fz-A2, C3-A2, Cz-A2, C4-A2, Pz-A2, Oz-A2 の 6 チャンネルとする．

### 3.2.3.3 結果

Fig. 3.18 は，文字盤第 4 列の文字を標的文字とした場合の，各列ごとの脳波信号の加算平均波形を示す．第 4 列の標的文字注視時脳波において，P300 成分を確認できる．

このように事象関連電位 P300 は，数試行のデータを可算平均することによって得られるが，これに対して ICA を用いて単一試行脳波から P300 成分の抽出を試みた結果を Fig. 3.19 に示す．ICA のスケール復元を行う場合，分離信号の振幅の低いチャンネルは意味の無い情報であるとみなすことができる [79]．すなわち，有効な脳波成分は，第 1，第 3，第 5 チャンネルに抽出されたものと考えられる．特に，分離信号第 1 チャンネルにおいて P300 成分に類似した信号成分を確認できる．同様に，いくつかの試行において，P300 成分を有する可算平均波形と高い相関を持つ分離信号を確認した．

## 3.3 動作想像時の脳波変動を利用したシステム

本節では，動作想像時の脳波変動を利用した BCI システムに関する研究についてまとめる．

手や足の動作を行う際に，脳の特定の部位（運動野）で神経の発火が起こることが知られており，このとき局所的な部位の頭皮上脳波に  $\alpha$  (8-13 [Hz]),  $\beta$  (14-20 [Hz]) 帯域で周波数成分の変化が見られる．この周波数成分変化は，事象関連脱同期 (ERS)，事象関連同期 (ERD) と呼ばれ，実際に動作を行わなくても出現することが確認されている [51]．また，この動作想像時脳波信号を利用することで，コンピュータのカーソル移動や車いすの方向制御など様々




Fig. 3.18 加算平均波形




Fig. 3.19 独立成分分析

な応用がなされている [59] [61] . しかしながら, この動作想像時脳波を用いたシステムにおいては, ユーザが適切にシステムを扱えるようになるまで 10 日程度のトレーニングを必要とする欠点がある. 本項では, 右手左手動作想像時脳波信号を用いた BCI システムについて追従実験を行い, パタン識別を行うとともに, 右手左手・足動作想像時の脳波信号を用いた 3 クラス BCI システム, フェールセーフ機構を備えた BCI システムについてシステム構築を行う. また, 波の本質的な変動を調べ被験者のトレーニング期間短縮することを目指し, 自己組織化マップ (SOM), 独立成分分析 (ICA), 自己回帰モデル (AR-model), モルフォロジーなどを用いた解析を試みる.

### 3.3.1 右手左手動作想像実験 ( 4 )

#### 3.3.1.1 実験データ

動作想像タスク実験は, 指示方向の手を動かすイメージをするタスクを被験者に課するものであり, ここでは Pfurtscheller によって提案された実験フレームワークを利用した追従実験を行う.

実験は, タスク指示用モニタ前に被験者を椅子に座らせた状況で行う (Fig. 3.20) . 始めに,

モニタには被験者の注視点を整えるための十字線が引かれ、2秒目に実験開始予告のためのBEEP音を鳴らす。3秒目から1.25 [sec]の間、モニタには左右どちらかの矢印が示され、被験者はその方向の手の動作想像を始める。さらに、5秒目から8秒目まで、パターン識別結果は、被験者に視覚的にフィードバックされ、被験者はこの情報からよりコンピュータが認識しやすいイメージを学習する。この視覚的フィードバックは、AR-modelに基づくパターン識別法による各クラスの尤度の差分をバーで呈示したもので、0.25 [sec] 間隔で変動する。なお、識別器は、被験者の前回実験時の脳波信号から設計される。この8秒間を1試行 [trial]とし、1実験 [session] において180 [trials] (右手: 90, 左手: 90) 行った。左右の動作想像呈示は、ランダムな順序で行い、試行と試行の間には0.5~2.0 [sec] の休憩を挟む。

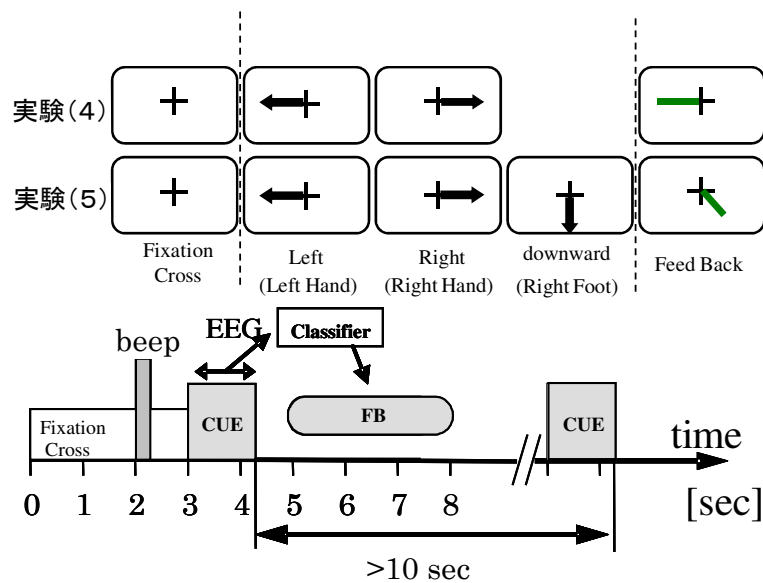


Fig. 3.20 動作想像課題実験 タイミングチャート

被験者は2種類行い、まずサンプリング周波数を128 [Hz]とした3名 (05t1, 05y2, 05k3) の右利きの健常者に対して、それぞれ20 [sessions] 別々の日に実験を行った。次に、脳波信号からより多くの特徴を抽出するために、サンプリング周波数を128 [Hz] から500 [Hz] に増やして右手左手動作想像実験を行った。被験者は、同じく3名 (06k4, 06n5, 06u6) でいずれも右利きの健常者であり、それぞれ10 [sessions] 行った。脳波信号は、Fig. 3.21 に示す15 [channels] である。

### 3.3.1.2 解析方法

本実験においては、AR-modelに基づくパターン識別を行い、被験者のシステムに対するトレーニングについて確認を行う。脳波データは、実験3.0 [sec] から8.0 [sec] まで0.25 [sec] 刻みで、0.5 [sec], 1.0 [sec], 1.5 [sec], 2.0 [sec] の112区間を切り出してパターン識別を行う。AR-modelのモデル次数は、次数が低く認識精度が安定する10次のものを利用した。また、判別の評価には、10 times 10 Cross Validation法を用いる。

脳波信号は、局所的な特徴を抽出することを目的として、Bipolar (BP), Small-Laplacian (SL) と呼ばれる空間的差分フィルタを利用する。例えばチャンネルC3の場合は、その前後左右の




Fig. 3.21 実験(4)電極配置図

チャンネル  $C3_F$ ,  $C3_R$ ,  $C3_B$ ,  $C3_L$  を利用して、次式のように導出される。

$$y_{C3}^{BP}(t) = y_{C3_F}(t) - y_{C3_B}(t) \quad (3.4)$$

$$y_{C3}^{SL}(t) = y_{C3}(t) - \frac{1}{4}(y_{C3_F}(t) + y_{C3_R}(t) + y_{C3_B}(t) + y_{C3_L}(t)) \quad (3.5)$$

後半のサンプリング周波数 500 [Hz] での実験については、AR-model に基づくパタン識別に加え、ICA により抽出された情報を用いたパタン識別も行う。ICA には、スケールの不定性問題と成分置換の問題があるが、近年においてはそれらの解決方法について検討がなされている。本研究においては、分離信号の分離行列の逆行列による分割信号が、原信号から同等の影響を受けるものと仮定したモデルを適用して分離信号のスケール復元を行う [78][81].

また、原信号数が混合信号数よりも多い場合、スケール復元された分離信号には、原信号の数の振幅が大きな信号成分が表れ、その他は振幅成分が低く表れることが確認されている [80]. そのため、動作想像時脳波のスケールが復元された分離信号について、振幅の大きな信号成分の数を特徴量とすることで、動作想像時の原信号数を知ることができると考えられる。具体的には、右手動作想像時に特徴が表れるとされるチャンネル C3 とその周囲 4 チャンネル、左手動作想像時に特徴が表れるとされるチャンネル C4 とその周囲 4 チャンネルについて、それぞれ 5 チャンネルで ICA とスケール回復を行い、閾値以上の振幅を持つ分離信号数を特徴量として傾向を調べる。また、分離信号について、動作想像時のみにパルス成分を抽出するチャンネルが出現していたため、分離信号に含まれるパルス数を特徴量としてパタン識別を行う。

### 3.3.1.3 結果

前半の実験について 20 [sessions] の AR-model に基づくパタン識別結果の推移を Fig. 3.22 に示す。3 被験者ともに識別率が向上し、特に被験者 (05k3) については 90 [%] 以上の認識精度を得ることができている。実験は、基本的には前回の実験から 2,3 日以内に行われており、これは、識別器に用いるパラメータが前回に計測した脳波から計測されるためであり、これにより被験者の学習を促しているものと考えられる。これを確認するために、Session 10 から Session 11 の間において、2 週間程の休みを設けた。その結果、被験者全員において識別精度が下がることが確認できる。被験者 (05y2) について見ると、Session 1 から Session 10

までは、識別精度が全体的に低く学習している傾向が見られないが、Session 11 から Session 20 においては、識別率の上昇傾向が見られる (Fig. 3.23)。これは、この実験システムにおいて、うまく学習ができなかった被験者は逆に実験間隔を空ける事で、学習の改善ができることを示唆している。

また、Fig. 3.24, Fig. 3.25, Fig. 3.26 に推定された AR パラメータのうち、最も Session 間で大きな変動を見せる  $\phi_1$  の推移を示す。被験者 (05y2) と、被験者 (05k3) においては、実験後半においてパラメータが収束していくことが見られ、これに応じて識別精度を向上させている。それに対して、被験者 (05t1) については、実験の最後までパラメータの収束が見られず、Session 18 まで識別精度の向上が見られない。これにより、AR パラメータ  $\phi_1$  を見ることで、学習の傾向が得られると考えられる。




Fig. 3.22 右手左手動作想像実験 1 の識別精度の推移







Fig. 3.23 被験者 (05y2) の実験日と学習傾向の関係

Fig. 3.27 は、脳波の観測信号を、Fig. 3.28 はその分離信号を示し、Fig. 3.29 は、分離行列の情報を利用したスケール回復後の分離信号を示す。処理長は、2 [sec] (1000 [point]) とする。スケール回復された分離信号について、振幅の大きな信号と振幅の小さな信号の 2 種類があることを確認できる。Fig. 3.30 は、スケール回復された脳波の中で大きな振幅を取ったものの数の平均値を示す。被験者 (06n5) において、対側性が C3 付近の分離信号、C4 付近の分離信号において見られる。トレーニングを重ねることによって、この差はだんだんと大きく



Fig. 3.24 被験者 (05y2) の AR パラメータ  $\phi_1$  の推移Fig. 3.25 被験者 (05t1) の AR パラメータ  $\phi_1$  の推移Fig. 3.26 被験者 (05k3) の AR パラメータ  $\phi_1$  の推移

なる傾向にあることが確認できる。

この特徴を用いて、被験者 (06n5) の右手動作想像・左手動作想像間のパタン識別を行った結果、90 [%] 近い判別精度を得ることができた (Fig. 3.31). しかしながら、他の被験者は、別の傾向を示している。被験者 (06u6) は、右手左手動作想像間に違いを見ることができ、これらの特徴は同側に表れる。被験者 (06k4) については、これらの特徴を見ることができなかった。

本実験において、スケール回復を行った信号のいくつかにパルス形状成分を含むものが出現した。Table 3.4, Table 3.5 に示すように、右手左手動作想像間のパルスに違いがみられる。特に動作想像を行っている時刻で、これらの差は明白である。パルス数を特徴量として、ベイズ判別法で右手左手動作想像判別を行った結果、被験者 (06n5) については、約 80 [%] の認識精度をえることができた (Fig. 3.32).

Fig. 3.33 に AR モデルに基づくパタン識別の認識精度を示す。また、FastICA アルゴリズムで分離した信号をスケール回復した信号に対し、高振幅の信号数、および分離信号に含ま

れるパルス数を特徴量としたときのパタン識別結果を Fig. 3.31, Fig. 3.32 に示す．これらの特徴を用いた場合の認識精度は，精度は低いが AR モデルの場合と同じ傾向を示した．これは，ICA により推定された信号に，判別に意味のある成分を抽出できたためであるとする．そのため，これらの方法は，AR 手法の弱点をカバーできる可能性がある．




Fig. 3.27 C4 周りの観測信号




Fig. 3.28 分離信号




Fig. 3.29 分離信号のスケール回復

### 3.3.2 手足動作想像実験 ( 5 )

#### 3.3.2.1 実験データ

本実験は，右手左手動作想像のパタン識別に加え，足動作想像識別も行う動作想像時脳波を用いた BCI システムの構築を試みたものである．実験タイミングチャートは，実験 4 と同じものであるが，動作想像指示に右矢印，左矢印に加え，下矢印もランダムな順序で出現する．右矢印呈示時には右手動作想像，左矢印呈示時には左手動作想像，下矢印呈示時には右足の動作想像をそれぞれ行う．実験は，1 [session] に各クラス 60 [trials] 行う．被験者は，3 名の健常者でそれぞれ 10 [sessions] もしくは 11 [sessions] の実験を行った ((06s1): 10 [sessions], (06c2): 11 [sessions], (06o3): 10 [sessions]) ．脳波計測のサンプリング周波数は，128 [Hz] とした．

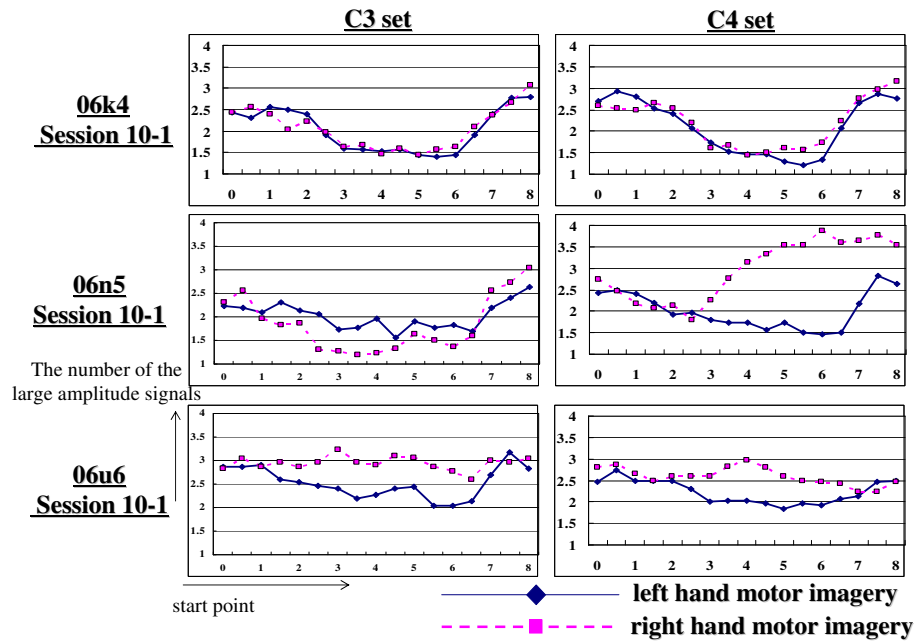


Fig. 3.30 高振幅信号の信号数

(3 subjects: ((06k4), (06n5), (06u6) from above))

Table 3.4 パルス数の推移 (平均)

(Subject: (06n5), Session: 10)

StartPoint	C3-L	C3-R	C4-L	C4-R
0	7.03	4.98	1.82	2.46
1	6.08	5.56	1.83	2.28
2	6.61	3.90	2.31	3.16
3	8.89	3.71	2.22	5.16
4	10.46	4.21	1.68	10.21
5	12.40	5.03	1.39	11.54
6	11.98	4.20	1.04	11.46
7	10.90	2.89	0.87	12.66
8	9.18	2.47	0.56	9.50

Table 3.5 パルス数の推移 (標準偏差)

(Subject: (06n5), Session: 10)

StartPoint	C3-L	C3-R	C4-L	C4-R
0	12.12	10.23	5.57	6.10
1	10.14	10.48	5.42	6.21
2	11.21	9.03	4.99	6.77
3	12.93	7.39	5.47	7.39
4	14.15	6.75	4.66	8.19
5	14.62	7.20	4.81	8.92
6	14.70	6.63	3.95	8.59
7	13.79	5.82	3.23	8.68
8	13.02	6.50	2.14	9.19

### 3.3.2.2 解析方法

AR-modelに基づくパタン識別に加え，ここでは，SOMにより抽出された情報を用いたパタン識別を行う。

SOMの入力ベクトルとしては，動作想像時脳波のAR-Spectrumを用いる．AR次数を20とし，6.0 [sec]~8.0 [sec]の脳波データを用いてスペクトル推定を行う．スペクトルは，128 [points]で離散化を行い，以下の帯域(入力ベクトル)用いてSOMの形成を行う。




Fig. 3.31 高振幅の分離信号数を特徴量としたパタン識別結果 (被験者: (06n5))




Fig. 3.32 分離信号のパルス数を特徴量としたパタン識別結果 (被験者: (06n5))




Fig. 3.33 AR-model に基づくパタン識別結果 (被験者: (06n5))




Fig. 3.34 学習傾向 (Subject: (06n5), C3 set)  
: 右手左手動作想像時の脳波原信号数の差  
(白色・黒色であるほど, 右手左手動作想像  
間の違いが大きい)




Fig. 3.35 学習傾向 (Subject: (06n5), C4 set)  
: 右手左手動作想像時の脳波原信号数の差




Fig. 3.36 実験 ( 5 ) 脳波波計測位置

1. 3 ~ 64 [Hz] (122 [points])
2. 4 ~ 7 [Hz] (8 [points])
3. 8 ~ 13 [Hz] (12 [points])
4. 14 ~ 30 [Hz] (34 [points])
5. 30 ~ 64 [Hz] (68 [points])

また, SOM 行列を  $10 \times 10$  の六角形型とし, 学習係数の初期値をそれぞれ,  $\alpha(0) = 0.5, \sigma(0) = 6$  とする. 学習のための入力データ数は, 180000 とする (3 クラス  $\times$  60 [trials]  $\times$  1000 [updates]).

また, SOM 形成時に使用されたクラスの回数をそれぞれのユニットにおいて記録を行うことにより, 新たにそのユニットに割り当てられるデータが, どのクラスに属するものが推定することができる. このように, SOM を用いることでパタン識別の識別器の形成を Fig. 3.37 のように試みる.

また, 入力とする信号は, 右手, 左手, 足動作想像時に特徴が表れるとされる C3, C4, Cz の 3 [channels] とし, 最終的な判別は, 各チャンネルの判別の多数決をとるものとする (Fig. 3.38).

抽出された特徴に対する解析として, SOM においてクラスごとに最も更新されるユニットは, そのクラスにおける特徴を有していると考え, 各クラス最も更新されたユニットに対して, クラス間距離を特徴量として周波数毎に差を求める (Fig. 3.39).

$$\begin{aligned}
 d &= \frac{S_B}{S_W} = \frac{\sum_{k=1}^3 \Pr(C_k)(m_k - m)^2}{\sum_{i=k}^3 \Pr(C_k)\sigma_k} = \frac{\sum_{k=1}^3 \left(m_k - \frac{1}{3} \sum_{i=1}^3 m_i\right)^2}{\sum_{k=1}^3 \sigma_k^2} \\
 &= \frac{(m_1 - m_2)^2 + (m_2 - m_3)^2 + (m_3 - m_1)^2}{\sigma_1^2 + \sigma_2^2 + \sigma_3^2} \\
 &= \frac{(m_1 - m_2)^2}{\sigma_1^2 + \sigma_2^2 + \sigma_3^2} + \frac{(m_2 - m_3)^2}{\sigma_1^2 + \sigma_2^2 + \sigma_3^2} + \frac{(m_3 - m_1)^2}{\sigma_1^2 + \sigma_2^2 + \sigma_3^2}
 \end{aligned}$$

ここで、特定クラスの分散が極端に大きい場合に他のクラス間の関係が考慮されなくなることを防ぐ目的で、ここでは3クラス間の距離を次式で評価する。

$$d = \frac{(m_L - m_R)^2}{\sigma_L^2 + \sigma_R^2} + \frac{(m_R - m_F)^2}{\sigma_R^2 + \sigma_F^2} + \frac{(m_F - m_L)^2}{\sigma_F^2 + \sigma_L^2}$$

ただし、 $m_L, m_R, m_F, \sigma_L^2, \sigma_R^2, \sigma_F^2$  は、各クラス(右手動作想像, 左手動作想像, 足動作想像)におけるスペクトルの平均と分散である。

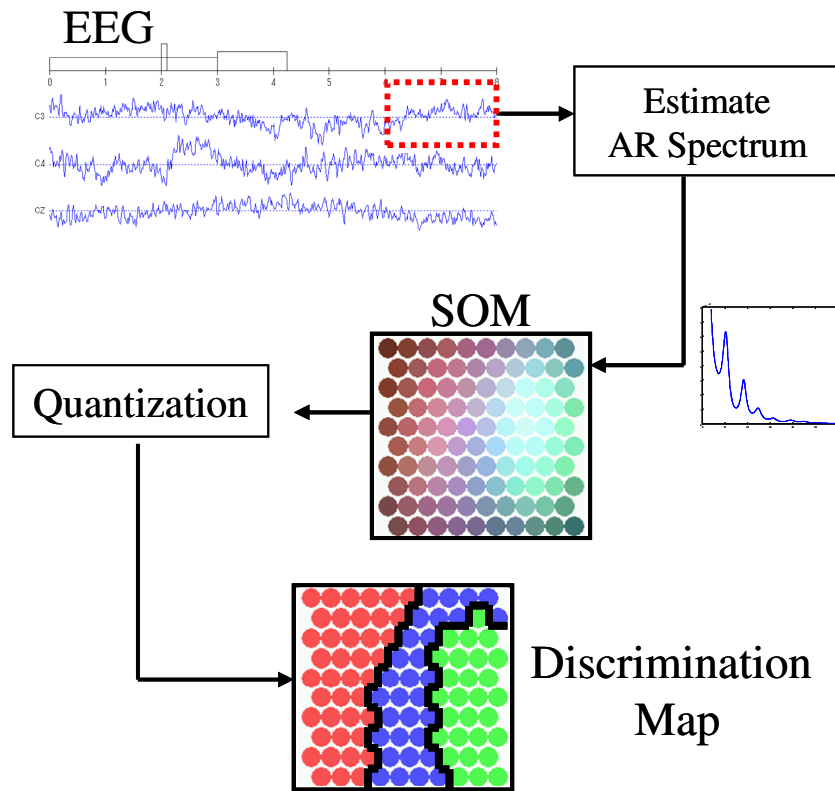


Fig. 3.37 SOMを用いたパターン分類

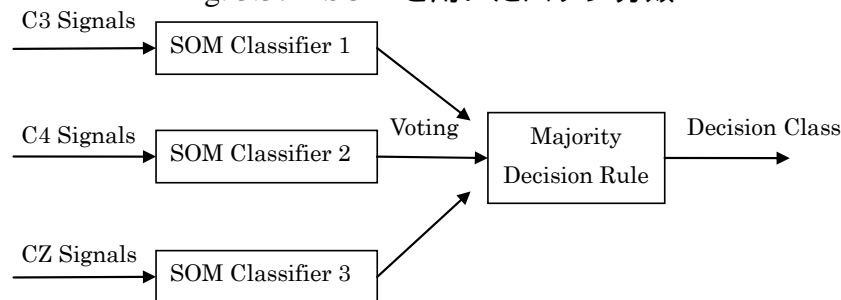


Fig. 3.38 多数決判別システム

### 3.3.2.3 結果

AR-modelを用いたパターン識別を行った結果を Fig. 3.40 に示す。3名ともに高い識別精度を得ることができなかった。特に、被験者(06s1), (06o3)については、被験者の学習傾向も得ることができなかった。これは、足動作想像時脳波からは、右手左手に比べ特徴がとりづらいことと、3クラスの識別になったことによる動作想像の複雑化が原因と考えられ、また、

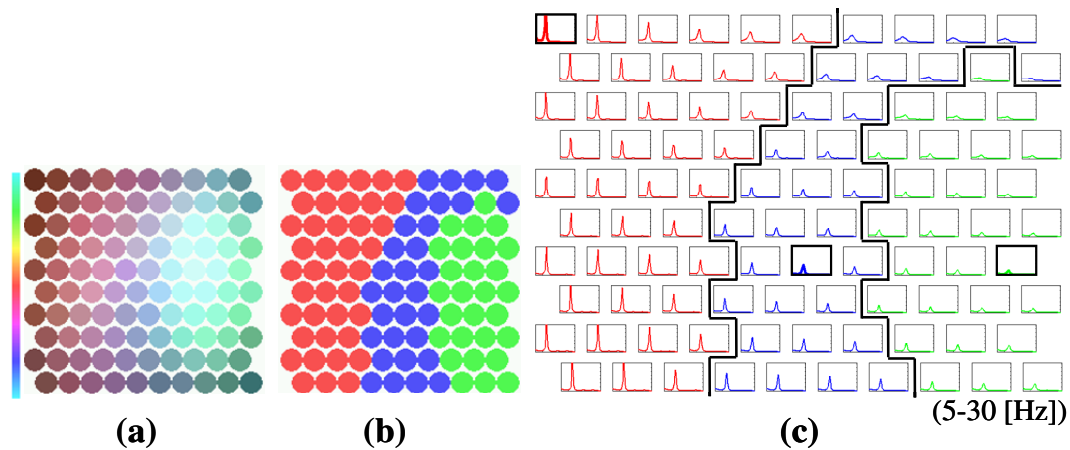


Fig. 3.39 SOM 行列 (被験者 06c2)

(a) クラスの更新回数特徴量としたカラーマップ (RGB (X, Y, Z): X, Y, Z は、それぞれ右手・左手・足動作想像クラス的数据が割り当てられた個数を示す) . (b) 更新回数により形成された判別マップ (c) 特徴ベクトルによる表現 (5~30 [Hz]) と最も更新されたユニット

視覚的フィードバックの呈示方法についても検討の必要がある．被験者 (06c2) についても，Session 6 までは識別率を向上させたが，Session 7 から Session 10 までは，学習をうまく行えず，逆に識別精度を低下させている．これに対して，Session 6 の脳波を用いて推定したパラメータを使って，Session 11 の実験を行ったところ，識別率の回復を確認できた．本実験の AR パラメータ  $\phi_1$  の傾向を Fig. 3.41 に示す．実験 (4) のときと同様に，うまく学習できない際には，パラメータ  $\phi_1$  が大きく変動する傾向を確認できる．

SOM を用いたパターン識別を行った場合，すべての被験者について 5 割から 6 割程度の識別率しか得られなかったが，被験者 (06c2) において統計的な手法に比べて良いときで約 15 [%] の向上させた (Fig. 3.42) ．

各被験者最終 Session の結果を Fig. 3.43，Fig. 3.45，Fig. 3.47 に示す．これにより，いくつかのバンドで特徴的なピークが表れることを確認できる．さらに，入力ベクトルの周波数を制限した上で ( $\theta$ : 4-7 [Hz],  $\alpha$ : 8-13 [Hz],  $\beta$ : 14-30 [Hz],  $\gamma$ : 30-64 [Hz]) SOM を用いたパターン識別を行った．そのいくつかの結果に，クラス間距離にピークが表れる周波数帯域で，パターン識別でも高い識別率が表れた (Fig. 3.44，Fig. 3.46，Fig. 3.48) ．これは，SOM が動作想像時脳波の特徴を視覚化できることを意味する．

### 3.3.3 フェールセーフ機構を備えた BCI システム (6)

#### 3.3.3.1 実験データ

動作想像タスク実験は，指示方向の手を動かすイメージをするタスクを被験者に課し，識別結果は，被験者に視覚的にフィードバックされ，被験者はこの情報からよりコンピュータが認識しやすいイメージを学習するものである．本実験ではさらに，低確率で視覚的フィードバックを想像方向と反対方向に呈示することにより，意図しない結果をシステムが出力したときの被験者の反応を取得するものである．これにより，BCI システムにフェールセーフ




Fig. 3.40 実験(5)の識別結果

Fig. 3.41 実験(5)におけるARパラメータ $\phi_1$ の推移

機能を付加できることが期待される．False出力とTrue出力の割合を2:8とする．被験者は3名でそれぞれ3日間の実験を行った(被験者: (07n1), (07u2), (07y3))．20 [channels] の脳波信号を512 [Hz] のサンプリング周波数で計測している．






Fig. 3.42 自己組織化マップを用いたパターン識別結果




Fig. 3.43 自己組織化マップで抽出されるクラス間距離: 06c2

Fig. 3.44 入力の周波数帯域を制限した場合の識別率: 06c2

	accuracy [%]				
	4-7 [Hz]	8-13 [Hz]	14-30 [Hz]	30-64 [Hz]	3-64 [Hz]
Channel C3	47.2	55.6	45.0	47.2	52.2
Channel C4	44.4	58.3	50.0	49.4	56.7
Channel Cz	51.1	47.8	56.1	48.3	46.1

### 3.3.3.2 解析方法

モルフォロジー処理は、Flat 型構造関数を用いたマルチレベル分解と、超楕円型構造関数の形状パラメータを結合エントロピー最大化手法 (M-JET) で最適化したマルチレベル分解を行う。分解されたそれぞれの信号に対して、動作想像に関する特徴と認知活動に関する特徴を抽出する。認知活動に関する特徴は、特定の振幅潜時で表れる正の電位変化とされるため、振幅の積分値を特徴量として、分布が正規分布に従うベイズ判別を行う。




Fig. 3.45 自己組織化マップで抽出されるクラス間距離: 06s1

Fig. 3.46 入力の周波数帯域を制限した場合の識別率: 06s1

	accuracy [%]				
	4-7 [Hz]	8-13 [Hz]	14-30 [Hz]	30-64 [Hz]	3-64 [Hz]
Channel C3	45.6	47.8	47.2	41.7	45.6
Channel C4	50.0	46.1	52.8	47.8	47.8
Channel Cz	49.4	45.0	49.4	48.9	51.1




Fig. 3.47 自己組織化マップで抽出されるクラス間距離: 06o3

Fig. 3.48 入力の周波数帯域を制限した場合の識別率: 06o3

	accuracy [%]				
	4-7 [Hz]	8-13 [Hz]	14-30 [Hz]	30-64 [Hz]	3-64 [Hz]
Channel C3	44.4	45.0	49.4	45.6	44.4
Channel C4	50.0	46.1	46.7	45.0	42.2
Channel Cz	44.4	45.6	47.8	43.3	45.6

$$\begin{aligned}
k^* &= \arg \max_k \Pr(\omega_k | s) = \arg \max_k \frac{p(s/\omega_k) \Pr(\omega_k)}{p(s)} \\
&= \arg \min_k \left\{ -\ln \left( \frac{1}{\sqrt{2\pi}\sigma_k} \exp\left(-\frac{(s-m_k)^2}{2\sigma_k^2}\right) \cdot \Pr(\omega_k) \right) \right\} \\
&= \arg \min_k \left\{ \ln \sigma_k + \frac{(s-m_k)^2}{2\sigma_k^2} - \ln \Pr(\omega_k) \right\} \tag{3.6}
\end{aligned}$$

特徴量  $s$  は次式のようにとる .

$$s = \sum_{t=1}^N \{H(\tilde{y}(t)) \cdot \tilde{y}(t)\}, \quad H(\tilde{y}) = \begin{cases} 1, & \tilde{y}(t) \geq 0 \\ 0, & \tilde{y}(t) < 0 \end{cases}$$

ここで,  $m_k, \sigma_k$  は  $s$  の平均, 分散である .

ERD/ERS の変化は動作想像の前後で表れるとされる . そのため, 右手・左手動作想像の判別は, Intertrial Variance 値を特徴量として行う . この特徴量は, 正規分布に従うものとし, 次式の判別を行う .

$$\begin{aligned}
k^* &= \arg \max_k \Pr(\omega_k | \tilde{y}) \\
&= \arg \min_k \left[ \frac{1}{2} \sum_{t=1}^N \ln \sigma_{k,t}^2 + \frac{1}{2} \sum_{t=1}^N \left\{ \frac{1}{\sigma_{k,t}^2} (\tilde{y}(t) - \tilde{y})^2 \right\} - \ln \Pr(\omega_k) \right] \tag{3.7}
\end{aligned}$$

ここで,


$$\tilde{y}_k(t) = \sum_{j=1}^M \tilde{y}_k^j(t), \quad \sigma_{k,t}^2 = \frac{1}{2} \sum_{j=1}^M (y_k^j(t) - \tilde{y}_k(t))^2 \quad (M : \text{block number})$$

である .

### 3.3.3.3 結果


Flat 型構造関数を用いたモルフォロジーマルチレベル分解 (M-FLT) で EEG 信号を分離するために, 7 レベルの分解を必要とした . また, 比較の為に適用した離散ウェーブレット変換 (DWT) も, 同様に 7 レベルの分解を行った . DWT は, Daubechies 6 をマザーウェーブレットとする (WT-D6). 判別の為のデータを, 時刻 5000 [msec] から 8000 [msec] までのチャンネル C3, C4 and Cz のデータとした . この時刻は, 被験者が動作想像を行っている区間で, 特に 5000 [msec] では視覚的フィードバックが行われる . 判別結果を, Fig. 3.49 に示す .

被験者 (07n1) は, 動作想像についての判定精度が高いのは, 低いレベル帯域であった . 特に, モルフォロジカル手法の場合は, この特徴を狭いレベル帯域に抽出できている . この結果は, モルフォロジカル手法を用いることで, 動作想像に関する特徴を見つけやすくなることを示唆する . 反対に, DWT の結果は, 特徴的な帯域を特定することができない . これは, 脳波信号に含まれる高振幅で高周波数成分の成分が, 広いレベルに影響を及ぼしたためである . モルフォロジカル手法は集合演算とベクトル演算で構成するため, この成分が



(a) (被験者: (07n1), session no: 1, CH: C4, Cz, data: 5.0 ~ 5.5 [sec])

(左: M-FLT, 右: WT-D6)



(b) (被験者: (07y3), session no: 2, CH: C4, Cz, data: 5.0 ~ 5.5 [sec])

(左: M-FLT, 右: WT-D6)

Fig. 3.49 モルフォロジーとウェーブレットを用いた分離

広いレベルに影響を及ぼさない。さらに、インパルス成分による歪みが少ないため、認知活動に関する高い認識精度が、高い方のレベルで得られた。この減少は、特に被験者 (07y3) で見られた。

次に、EEG 信号を結合エントロピー最大化手法 (M-JET) で分離を行った。単一試行の EEG 信号に対し、2 レベルのモルフォロジーマルチレベル分解を行った。視覚的フィードバックのバーが呈示された直後に、正方向のピーク (P300 成分) が特定のレベルで出現することが確認できる。動作想像 (右手と左手) と Error Potential (Correct クラスと Error クラス) に関するパターン識別結果を Fig. 3.50 に示す。認識精度は、両方のケースで 10 [%] 程度向上していることが確認できる。これは、モルフォロジカル手法が、動作想像に関する高周波高振幅を抽出できたためであると考えられる。また、緩やかな変化をとる認知活動に関する成分 (P300) は、構造関数を設計することで明瞭に抽出されたためであると考えられる。

さらに、推定された構造関数は、元の信号の情報を有している。Fig. 3.51 は、単一試行の短時間で推定される構造関数の推移を示す。たとえば、時刻 2000 [msec] と 5000 [msec] の後

に，丸型構造関数の組み合わせが推定される．この構造関数は，聴覚反応 (N100) と認知活動 (P300) に関する特徴を抽出しているものである．同様に，動作想像時である 7000 [msec] 付近において，尖った構造関数の組み合わせが推定されている．これらは，動作想像に関する特徴であると考えられる．

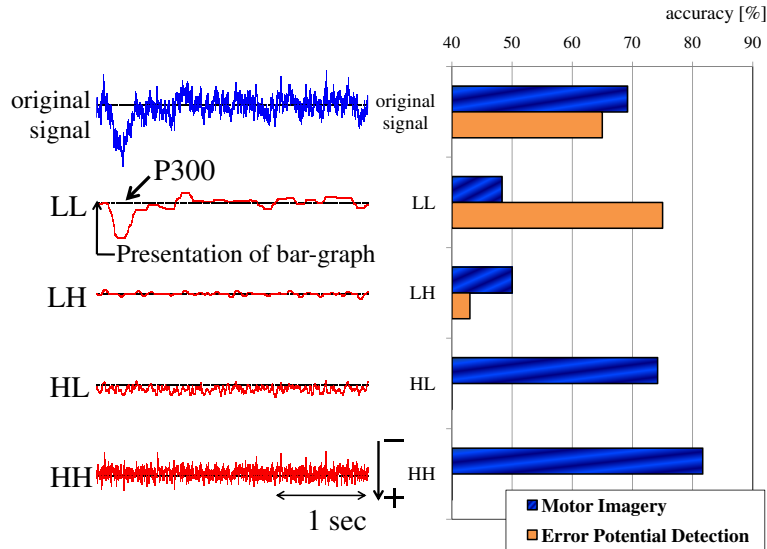


Fig. 3.50 結合エントロピー最大化手法を用いた場合のパターン識別結果

(左: モルフォロジーによる分解 (被験者: (07n1), session no: 1, CH: C4, data: 5.0 ~ 8.0 [sec], method: M-JET),

右: パターン識別結果 (subject: (07n1), session no: 1, CH: C4, data: 5.0 ~ 5.5 [sec], method: M-JET)




Fig. 3.51 推定される構造関数

(被験者: (07y3), session no: 1, CH: C4, method: M-JET )

500 [msec] の窓幅で 3 レベルの構造関数の推定を行う．

### 3.4 光誘発電位を利用したシステム

本節では，光誘発電位 (Visual Evoked Potentials: VEP) を利用した注視点検出に関する研究についてまとめる．

視覚誘発電位 (VEP) は，視覚刺激を被験者に与えるもので，脳後頭部付近 (O1, O2, Oz) で観測される脳波に，刺激後約 100 [ms] で負の電位変化 N100 が出現することが知られている．一般的に，視覚誘発電位の成分は，加算平均によって抽出される．

視覚刺激により視覚誘発電位が刺激後 100 [ms] 程で出現することが知られている．特に，10 [Hz] 以上の周期で連続的に視覚刺激を繰り返すことで，これらの特徴は同期現象として出現する．一般的に，この定常性視覚誘発電位 (SSVEP: steady state visual evoked potentials) は，フーリエ変換によって周波数領域で成分の有無を調べられる．

#### 3.4.1 SSVEP を利用した注視点検出システム (7)

##### 3.4.1.1 実験データ

3行3列の文字盤を用意し，行・列ごとに異なる周波数で文字を点滅させる．被験者には，所望の文字を注視するタスクを与えており，行と列のパタンの組み合わせで注視文字を推定する．行・列は，それぞれ 5, 8, 11 [Hz] の周期で点滅させる．実験は，3人の被験者 ((09y4), (09h5), (09u6)) に対してそれぞれ 2 [session] 行った．サンプリング周波数は，512 [Hz] で 14 [channels] の脳波信号を計測した．

##### 3.4.1.2 解析方法

EEG 信号は，2種類の空間フィルタを用いて導出される．一つは，monopolar で EEG 信号の一般的な導出方法である．もう一方は，ラプラシアン信号で，局所的な変動を抽出できる．たとえば，チャンネル  $O_z$  は次のように構成される．

$$\begin{aligned} \text{monopolar} : y_{O_z}^M &= y_{O_z} - y_{A_2} \\ \text{laplacian} : y_{O_z}^L &= y_{O_z}^M - (y_{O_1}^M + y_{O_2}^M)/2 \end{aligned}$$

視覚刺激周波数と同じ周波数成分を脳波が有するため，脳波のフーリエスペクトルの分布が正規分布に従うものと仮定し，ベイズ判別手法でパターン識別を行う．

$$\begin{aligned} k^* &= \arg \max_k \Pr(\omega_k | \mathbf{x}) \\ &= \arg \min_k \left\{ \frac{1}{2} \ln |\Sigma_k| + \frac{1}{2} (\mathbf{x} - \mathbf{m}_k)^T \Sigma_k^{-1} (\mathbf{x} - \mathbf{m}_k) - \Pr(\omega_k) \right\} \\ &\quad \left( \mathbf{x} = [x_1^1, x_2^1, x_3^1]^T, x_j^1 = \sum_{f=d_j^1-w}^{d_j^1+w} S(f) \right) \end{aligned} \tag{3.8}$$

$S(\cdot)$  は EEG 信号  $\mathbf{x}$  のフーリエスペクトルを示し， $\mathbf{m}_k$ ， $\Sigma_k$  は， $\mathbf{x}$  の平均・分散を示す．また， $d_j^1$  は入力刺激の周波数 (5, 8 and 11 Hz) で， $w$  は積分を行う窓である．さらに， $\mathbf{x}$  に表れる倍

周波成分として、次の成分も特徴量として用いることとする。

$$f + 2f : \mathbf{x} = [x_1^1, x_2^1, x_3^1, x_1^2, x_2^2, x_3^2]^T$$

$$f + 2f + 3f : \mathbf{x} = [x_1^1, x_2^1, x_3^1, x_1^2, x_2^2, x_3^2, x_1^3, x_2^3, x_3^3]^T$$

$d_j^2, d_j^3$  は、倍周波の周波数である (10, 16, 22, 15, 24, 33 [Hz]).

また、スペクトル近似波形として、AR-spectrum も用いる。

### 3.4.1.3 結果

EEG 信号に対してフーリエスペクトルを求めた結果を、Fig. 3.52, Fig. 3.53 に示す。視覚刺激の周波数とその倍周波成分において、高い周波数成分が得られている。これらの特徴は、特にラプラシアンフィルタを用いた場合に明確に表れる。

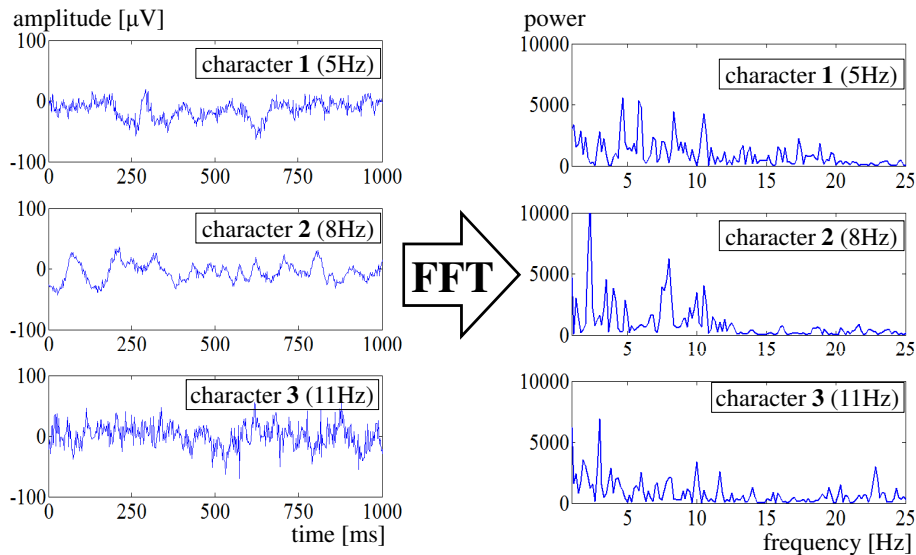


Fig. 3.52 フーリエスペクトル (monopolar)




Fig. 3.53 フーリエスペクトル (laplacian) Fourier spectrum  
(subj.: (09y4), session: 1, trial no: 24, ch.: Oz, filter: laplacian)

Eq. (3.8) で用いたフーリエスペクトルの積分値を, Fig. 3.54 に示す. クラスごとの差が大きく表れることが, 確認できる. Fig. 3.55 と Fig. 3.56 にこの判別結果を示す. ラプラシアンは, 近傍の EEG チャンルを使用するため, monopolar よりも表示数が少ない. すべての被験者において, 後頭部で判別精度が高くなることが確認できる. 特に, monopolar 信号の被験者 (09h5) では, 80 [%] の認識精度が得られた. その他の被験者は, laplacian フィルタを用いることで, 認識精度が向上した.




Fig. 3.54 特徴量の分布

(subj.: (09y4), session: 1, ch.: Oz, filter: laplacian)




Fig. 3.55 認識精度の空間分布

(Pattern recognition method: Fourier method)




Fig. 3.56 チャンネル Oz のパターン識別結果

(filter: laplacian, channel: Oz)

倍周波成分も特徴量として導入した場合と, AR 手法を用いた場合についての判別結果を Fig. 3.57, Fig. 3.58 に示す. AR 手法の場合は, 計算の簡略化の為に 128 [Hz] ヘダウンサンプリングしている. また, AR モデルの次数を 40 とした. AR 手法の認識精度は, 被験者 (09y4) の 1 [session] でフーリエ手法の場合に比べて向上したが, ほとんどのケースで認識精度が低くなった. これは, Fig. 3.59 に見られるように, AR スペクトルは, モデル次数に依存してスペクトルにピークを出現させるため, 対象の成分のみを抽出するのに向かないものと考えられる.

このように, SSVEP の特徴を用いた文字入力装置の特徴は, 入力刺激の基本周波数と倍周波数成分のフーリエスペクトルの積分値を特徴量とすることで, 主に後頭部の脳波信号を用いて抽出できることを確認した.






Fig. 3.57 高調波成分も利用したパターン識別の識別結果  
(filter: laplacian, channel: Oz)




Fig. 3.58 認識結果の空間分布  
(Pattern recognition method: AR method)




Fig. 3.59 AR スペクトル  
(subject: (09y4), session: 1, channel: Oz, filter: laplacian)

### 3.4.2 T-VEP を利用した単一光源注視パターン検出システム ( 8 )

#### 3.4.2.1 実験データ

M-sequence VEP システムは、ランダムな順序で光刺激を与えたときの視覚誘発電位を取得し、被験者の注視パターンを推定するものである。特に本実験では、他光源からの光刺激の漏れの影響を避けるため、光源数を 1 とし、2 種類のパターンを別の時間に出力した (Fig. 3.60)。被験者は、刺激呈示用モニタから、100 [cm] 離れたマッサージチェアに座るものとする。

光刺激パターンとしては、刺激がランダムとなるように、点灯・消灯の組み合わせに 2 種類の M-系列 [73] を採用した。パターン A, B は、それぞれ 7 [bits], 15 [bits] の周期の M-系列パターンである。刺激は、1 単位 100 [msec] とし、点灯時は、50 [msec] 間の光刺激を行う。

サンプリング周波数は、512 [Hz] で 20 [ch] の脳波信号を計測している。実験は、1 [session] に 1 時間程度行い、3 人の被験者に対してそれぞれ 3 [sessions] 行った (08o1, 08o2, 08m3)。




Fig. 3.60 刺激装置




Fig. 3.61 タイミングチャート

### 3.4.2.2 解析方法

相互情報量最大化手法を用いた2レベルのモルフォロジー分解を行い、分解された信号の振幅値の区間積分を特徴量としたパタン識別を行う。

視覚誘発電位は、視覚刺激後75 [msec], 100 [msec] に表れる電位変化であり、それぞれP75, N100と呼ばれている。解析は、入力信号に対してモルフォロジーによる多レベル分解を行い、各分離波形に対して、次式の電位変化の時間積分値を特徴量としたパタン識別を行うものとする。

$$\begin{aligned}
 k^* &= \arg \max_k \Pr(\omega_k | \mathbf{s}) \\
 &= \arg \min_k \left\{ \frac{1}{2} \ln |\Sigma_k| + \frac{1}{2} (\mathbf{s} - \mathbf{m}_k)^T \Sigma_k^{-1} (\mathbf{s} - \mathbf{m}_k) - \Pr(\omega_k) \right\} \\
 &\quad \left( \begin{array}{l} \mathbf{s} = [s_1, s_2]^T, \\ s_1 = \sum_{t=d-w}^{d+w} \{y(t+500) + y(t+1000)\}, \\ s_2 = \sum_{t=d-w}^{d+w} \{y(t+400) + y(t+600)\} \end{array} \right)
 \end{aligned} \tag{3.9}$$

ここで、 $y$  はモルフォロジカルフィルタの出力で、 $\mathbf{m}_k$  と  $\Sigma_k$  は  $\mathbf{s}$  の平均と分散を表す。また、 $d$  は、P75 と N100 の振幅潜時で、 $w$  は処理ウィンドウ長である。

### 3.4.2.3 結果

Fig. 3.62 にモルフォロジーによる多レベル分解の一例を示す。この際の構造関数は、1000回の乱数探索によって推定されている。

刺激パターンAの場合、第5刺激目の100 [ms]後に負のピークがレベルLHに表れる。同様に、パターンBにおいても、第4刺激に関して負のピークが抽出されていることを確認できる。1 [session]におけるこれらのピーク潜時とその振幅値の分布をFig. 3.63に示す。図に示すように、刺激時には約20 [points]の範囲内に振幅潜時が収まることが確認できる。

Eq. (3.9)における $w$ を5とし、特徴量 $\mathbf{s}$ は、Fig. 3.64のように分布する。パタン識別は、トレーニングデータとテストデータのデータ比を4:1とするCross Validationを用いて評価を行う。

Fig. 3.65, Fig. 3.66は、P75とN100の特徴量を用いたパタン識別結果である。モルフォロジー手法を用いることで、情報の損失の無い分離を行うことができ、特にP75成分を用いた




Fig. 3.62 単一施行 EEG のモルフォロジー分解

EEG 信号は 3 種の構造関数を用いて 2 レベルに分解される．刺激パターンに依存して，N100 成分が対応する振幅潜時で抽出される．




Fig. 3.63 負値ピークの振幅・時間分布

(Level: LH, stimulus no: 5, subject: (08o1), session no: 1)

Eq. (3.8) におけるパラメータ  $d$ ,  $w$  は，この分布から決められる．

分類で認識精度の改善を見せている．一方で，DWT を用いた場合，識別のための特徴的な情報はいろいろなレベルに分割されている．そのため，このモルフォロジー手法は VEP の主要成分を効率よく抽出するための手法になると考えられる．

また，推定された構造関数を Fig. 3.67 に示す．被験者 (08o1) の場合，尖った形状の構造関数が形成され，高い認識精度がレベル LH, HL, HH で観測される．反対に被験者 (08o2), (08m3) のように，丸い構造関数が推定されたとき，高い認識精度はレベル LL, LH, HL で観測された．この現象は，最適な構造関数が信号構造の特性を有していることを示す．これらの特徴は，信号からの特性検出に利用できる可能性がある．




Fig. 3.64 特徴量の分布

(Subj.: (08o2), Session no: 2, channel: Oz, feature: N100)




Fig. 3.65 モルフォロジカル多レベル分解を用いた場合のパタン分類結果

(Session no: 2, channel: Oz)

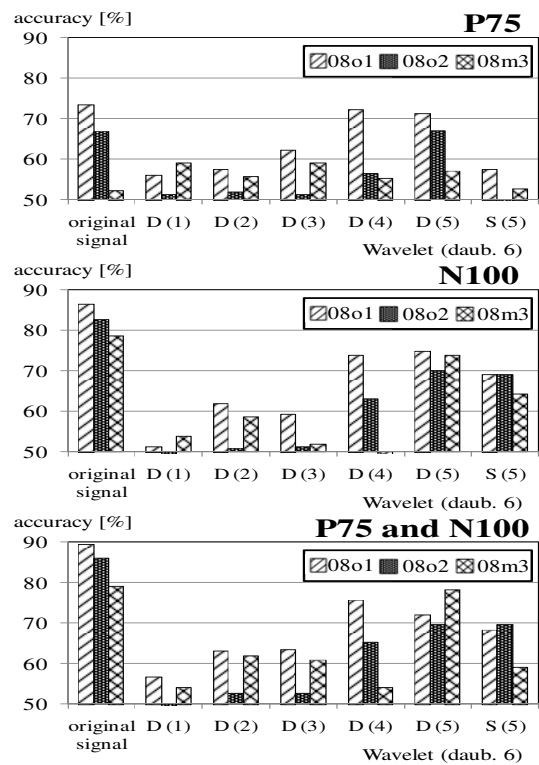


Fig. 3.66 DWT を用いた場合のパタン分類結果

(Session no: 2, channel: Oz)

### 3.4.3 T-VEP を利用した多光源注視パタン検出システム ( 9 )

#### 3.4.3.1 実験データ

実験は、異なるパタン系列で光る4つの注視点のうちの1つを注視させるタスクを被験者に課するものである。光刺激に伴い表れるVEP成分を脳波信号から抽出することで、被験者の注視点の推定を行う。実験は、外部からの電氣的ノイズを遮断するシールドルーム内で行う。被験者は、視覚刺激用モニタ (ProLite E2607WS, iiyama) から60 [cm] 程度離れた場所

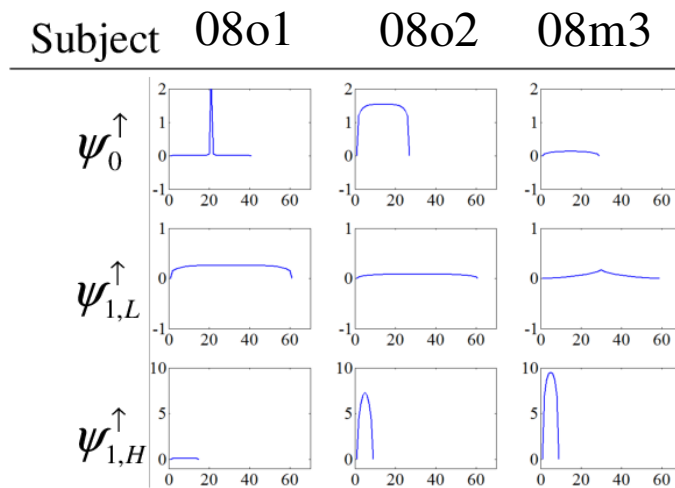


Fig. 3.67 推定された構造関数

(Session no: 2, channel: Oz)

にあるマッサージチェアに座って実験を行う。

モニタには、4種の文字(A, B, C, D)が配置されており、それぞれ異なる刺激パターンで点滅する (Fig. 3.68)。刺激パターンは、刺激を1, 非刺激を0とし15刺激 (bit) 周期で60回繰り返す。刺激時の刺激時間を50 [ms]とし、刺激間隔を100 [ms]とする。このような実験を、1日に2回、5人の被験者 ((003sm), (004km), (022mm), (028sh), (034my)) に対してそれぞれ3日間行った。また、他光源からの影響を調べるための対照実験として、注視点の文字以外は点滅を行わない実験も併せて行っている。脳波信号は、後頭部を主とする17箇所にて電極を配置し (Fig. 3.69), g.USBamp (g.tec 社) を用いた24 bit A/D で計測される。サンプリング周波数は、512 [Hz] である。




Fig. 3.68 刺激パターン

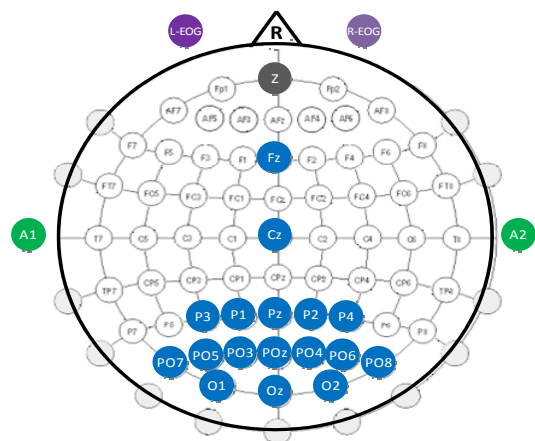


Fig. 3.69 電極配置図

### 3.4.3.2 解析方法

本実験については、加算平均で表れる特徴とその問題点を述べ、注視点以外の他の光源からの影響を独立成分分析で抽出し、さらにモルフォロジカルフィルタでVEP成分の抽出を

試みるものである．なお，脳波信号は，2-50 [Hz] のバンドパスフィルタ (FIR，100 次) が前処理として施されている．

脳波の加算平均波形とは，トリガー時刻から一定時間の脳波を抽出し，加算平均したものを指す．脳波信号  $\mathbf{x}^m = [x(m, 1), x(m, 2), \dots, x(m, N)]^T$  の  $M$  試行の加算平均は，次式で得られる．

$$\bar{x}(t) = \frac{1}{M} \sum_{m=1}^M x(m, t), \quad (t = 1, 2, \dots, N) \quad (3.10)$$

注視点以外に光源がある場合，光源の位置と対側の視覚野で最も顕著に VEP 成分が表れる．例えば，注視点の右側に光源がある場合は，後頭部対側のチャンネル PO7-Pz もしくは O1-Pz 付近で最も電位変化が大きくなる．本実験においては，観測信号である脳波信号が，様々な位置の光源からなる応答の混合波形であると仮定し，PO7-Pz, O1-Pz, Oz-Pz, O2-Pz, PO8-Pz の 5 チャンネルについて独立成分分析を行う．分離行列の推定は，刺激パタン 1 周期 (15 [bits]) に相当する 1.5 [sec] 毎に行う．また，同日に計測した単一光源時の脳波波形の加算平均波形との相関係数を求め，次式に示すスコアが最も高いチャンネルを視覚刺激時応答脳波のチャンネルとする．

$$r(i) = \sum_{j=1}^4 \sum_{k=1}^{15} e_j(k) \cdot \text{cor}(\mathbf{x}(i, j, k), \mathbf{x}_{\text{TEMP}})$$

$$(i^* = \arg \max_i \{|r(i)|\}) \quad (i = 1, 2, \dots, 5) \quad (3.11)$$

ここで， $\mathbf{x}(i, j, k)$  は，分離チャンネル  $i$ , 注視点パターン  $j$  の  $k$  [bit] 目の分離信号であり， $\mathbf{x}_{\text{TEMP}}$  は，単一光源の脳波 Oz-Pz の加算平均波形を示し， $\text{cor}(\mathbf{a}, \mathbf{b})$  はベクトル  $\mathbf{a}, \mathbf{b}$  の相関係数を示す．それぞれデータ長を 120 [points] (約 0.23 [sec]) とする． $e_j(k)$  は，注視点文字  $j$  の光刺激パタンであり，刺激時は 1，非刺激時には -1 とする．また，極性を統一するため，選ばれた分離信号について  $\text{sign}(r(i))$  をかけている．

脳波信号から，より効果的に VEP 成分を抽出するために，モルフォロジカル帯域阻止フィルタを施す．フィルタの遮断帯域を決定する 2 種類の構造関数は，次式の評価関数を最大にする組み合わせを GA で探索する．

$$u(\theta) = \sum_{j=1}^4 \sum_{k=1}^{15} e_j(k) \cdot (c_{g_1, g_2}, \mathbf{x}_{\text{TEMP}})$$

$$\theta^* = \arg \max_{m, n} \{u(\theta)\} \quad (3.12)$$

ここで， $\theta = [k_1, n_1, p_1, k_2, n_2, p_2]^T$  である．GA への適用のために，構造関数のパラメータは，それぞれ 16 [bit] で 2 値化される．Table 3.6 に GA の条件を示す．

注視点文字を判別するための特徴量として，単一光源時の脳波の加算平均波形と脳波信号の相関係数を利用した刺激パタン類似度を採用する．

$$s_j = \sum_{k=1}^{15} e_j(k) \cdot \text{cor}(\mathbf{y}(k), \mathbf{x}_{\text{TEMP}}), \quad (\mathbf{s} = [s_1, s_2, s_3, s_4]^T) \quad (3.13)$$

Table 3.6 GAのパラメータ

項目	条件	項目	条件
個体数	200	2 値化法	BinaryCode
世代数	5	量子化 bit 数	16
交叉法	一様交叉	探索幅 (値軸)	0-10
交叉率	0.96	探索幅 (時間軸)	1-100
選択法	トーナメント方式	探索幅 (曲率)	1.5-2.5
PLAYER 数	5		

ここで、 $y(k)$  は、観測される脳波信号、ICA の分離信号、もしくは、モルフォロジカルフィルタの出力についての、 $k$  [bit] 目の信号である。 $e_j(k)$  は、注視文字  $j$  の光刺激パターンであり、Eq. (3.11) と同様に、刺激時は 1、非刺激時には -1 とした。

パターン識別は、特徴量  $s$  の分布が正規分布に従うと仮定し、事後確率が最大となるクラスに割り付ける。

$$\begin{aligned}
 i^* &= \arg \max_i \Pr(\omega_i | \mathbf{s}) \\
 &= \arg \min_i \left\{ \frac{1}{2} \ln |\Sigma_i| - \Pr(\omega_i) + \frac{1}{2} (\mathbf{s} - \mathbf{m}_i)^T \Sigma_i^{-1} (\mathbf{s} - \mathbf{m}_i) \right\} \quad (3.14)
 \end{aligned}$$

ここで、 $\mathbf{m}_i, \Sigma_i$  は、クラス  $i$  の平均ベクトル、共分散行列を示す。1 [session] の実験で得られる 120 [blocks] の実験データについて、20 [blocks] をモルフォロジーの構造関数設計に用い、残り 100 [blocks] で Cross Varidation 評価を行う。

### 3.4.3.3 結果

単一光源の場合、視覚刺激後約 75 [ms], 100 [ms], 145 [ms] の振幅潜時で、それぞれ P75, N100, P145 と呼ばれる電位変化が起こる。多光源の場合は、注視している光源以外の影響が表れるため、刺激・非刺激間の判別が困難となる。Fig. 3.70 にチャンネル Oz-Fz の 600 [trials] の加算平均波形を示す。特に、N100 成分において、他光源からの影響を受けていることが確認できる。

ICA の分離結果の一例を Fig. 3.71 に示す。このときの注視文字は 'B' であり、注視文字の左側の光源 (文字 'A') の影響が、特に右脳側のチャンネル O2-Pz, PO8-Pz に表れている。分離の結果として、注視点以外の影響が分離チャンネル 1 に抽出され、分離チャンネル 3 に刺激パターン 'B' に対応する VEP 成分が抽出されている。

次に、各抽出手法の効果の傾向を調べるために、それぞれの手法の結果に対して、加算平均を求めた。Fig. 3.72 に結果の一例を示す。ICA の結果、原波形に VEP の成分が顕著に表れない被験者 S4 の場合でも、視覚刺激後 100 [ms] 付近で VEP と見られる成分が抽出されることが確認できる。

モルフォロジカルフィルタは、VEP 成分確認できる際にはある程度の高周波成分除去が行えているが、Fig. 3.72 左 2 段目のように、上手く VEP を抽出できない場合もある。一方、全

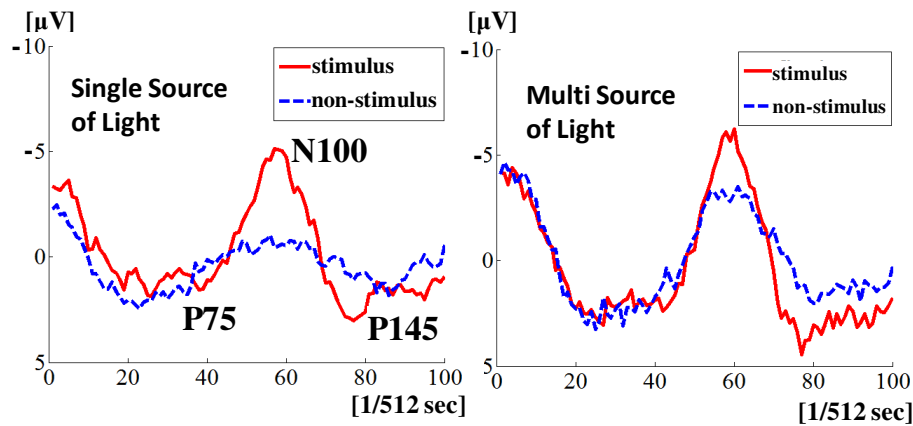


Fig. 3.70 視覚刺激時脳波の加算平均波形

(left: 単一光源, right: 多光源)

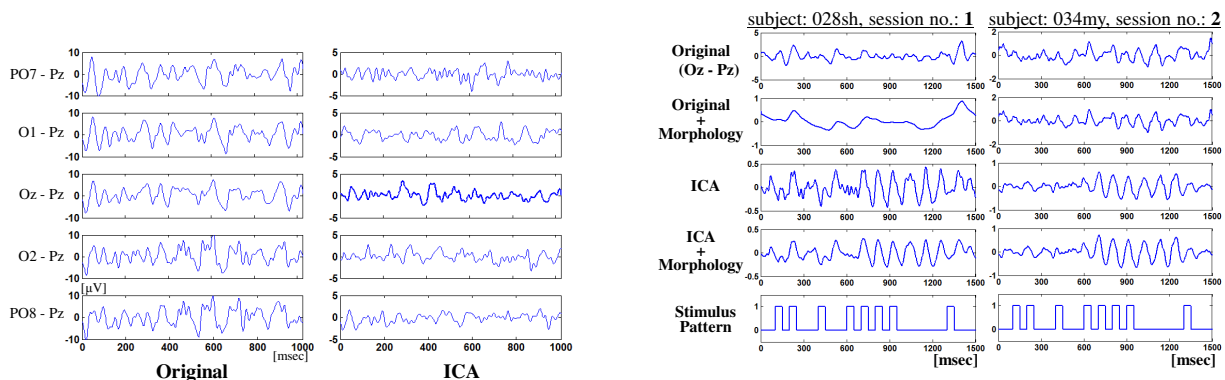


Fig. 3.71 独立成分分析による信号分離

(subj.: (028sh), session no: 1, class: B, block no.: 10)

Fig. 3.72 加算平均波形

(class: B, num. of addition: 120, subject: (028sh) and (034my))

ての被験者について、注視文字 'B' の 7 [bit] 目 (600 [ms]) 以降で、視覚刺激が 4 波であるにもかかわらず、応答脳波が 5 波から 7 波出現した。余分に表れる区間は、他の光源からの刺激も無いため (Fig. 3.68 参照)、視覚刺激による外因的な応答ではなく、SSVEP に類似する内因的な成分であると考えられる。

Eq. 3.13 で求められる特徴量について、さらに同系列の加算平均を行った場合 (1 [block] (1.5 [sec]), 3 [blocks] (4.5 [sec]), 5 [blocks] (7.5 [sec])) の分布を Fig. 3.73 に示す。加算平均は、3 [blocks] の場合であると、'1+2+3', '2+3+4', '3+4+5', のように 1 [block] ずつシフトさせながら加算したため、データ個数は加算数に関わらず同一であるが、外れ値の影響を大きく受ける危険性がある。

また、特徴量の次元が 4 であるため、ここでは  $s_1$  と  $s_2$  についてのみ表示している。1 [block] の原波形の場合は、分布がほとんど重なっているが、長時間の加算平均を行うか、ICA やモルフォロジー処理を行うことで、分布間距離が広がることを確認できる。Eq. 3.14 のパタン識別について、同系列の加算平均を行った場合の認識精度の推移を Fig. 3.74 に示す。

全ての被験者について、加算数を増やすに従って認識精度が向上することが確認できる。



これらは、多くのケースで収束せずに向上を続けたが、加算数 20 [blocks] (30 [sec]) 以上は、実用的とは言えない。Fig. 3.75 に 1 [block] のデータを用いたパターン識別結果を示す。原波形の認識精度は、被験者 (028sh) 以外はほとんど判別できておらず、原波形に対するモルフォロジーの結果も大きな改善を示さない。しかしながら、ICA で修正された信号に対するモルフォロジーを用いた場合、ほとんどのケースで認識精度の向上が見られる。

本実験では、VEP を利用した脳波タイプライタシステムの構築を目指し、多光源の中からユーザの注視点を検出する手法について検討を行った。多光源視覚刺激時の VEP は、注視点以外からの影響を大きく受けるため、特徴抽出が難しくなるが、ICA を用いることでこれらの影響を抑えることができることを確認した。また、ICA 後の信号を利用したモルフォロジカルフィルタ設計により、VEP 成分を効果的に抽出できることを確認した。これらの特徴を用いた 4 クラスのパタン分類では、1.5 [sec] の脳波入力で平均 40 [%] 最大 48 [%]、4.5 [sec] の脳波入力で平均 58 [%] 最大 78 [%] の認識精度を得ることができた。また、4 波の連続した視覚刺激を与えることで、脳の内部状態が変化することが確認できた。認識精度や判別できるクラス数では、既存の事象関連電位 P300 を用いた脳波タイプライタシステムを上回るものではないが、視覚誘発電位を利用した BCI システムの構築についての一つの指針を得たと考えられる。

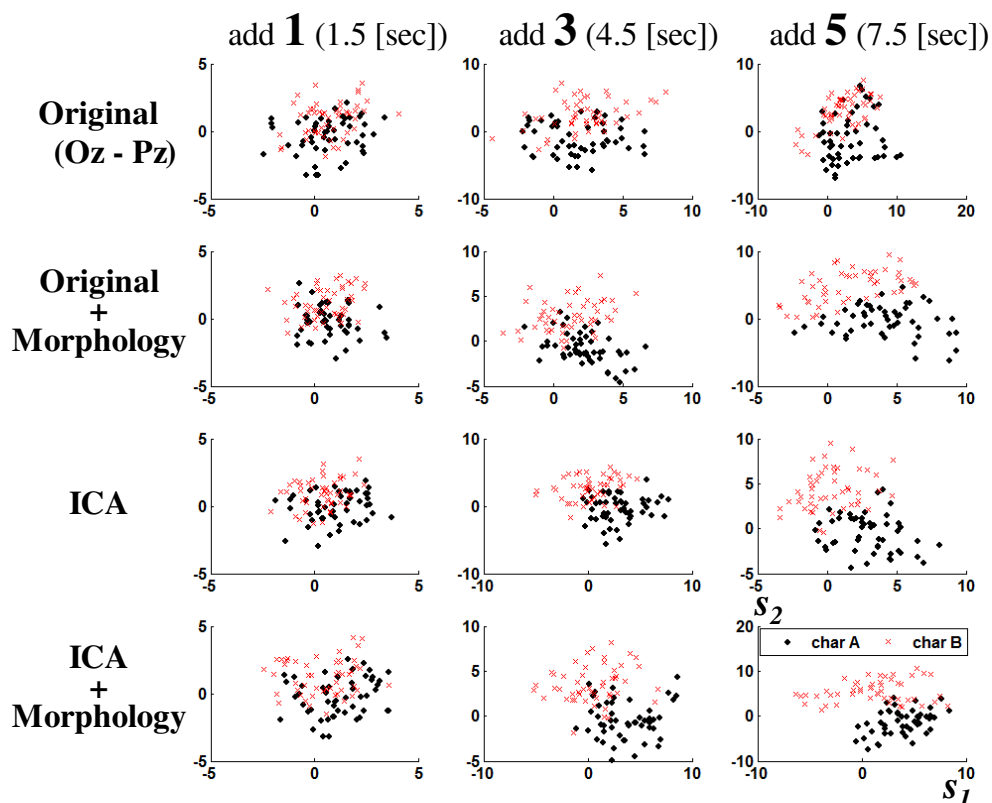


Fig. 3.73 特徴量  $s$  の分布

(subj.: (028sh), session no: 1, class and feature: A and B)

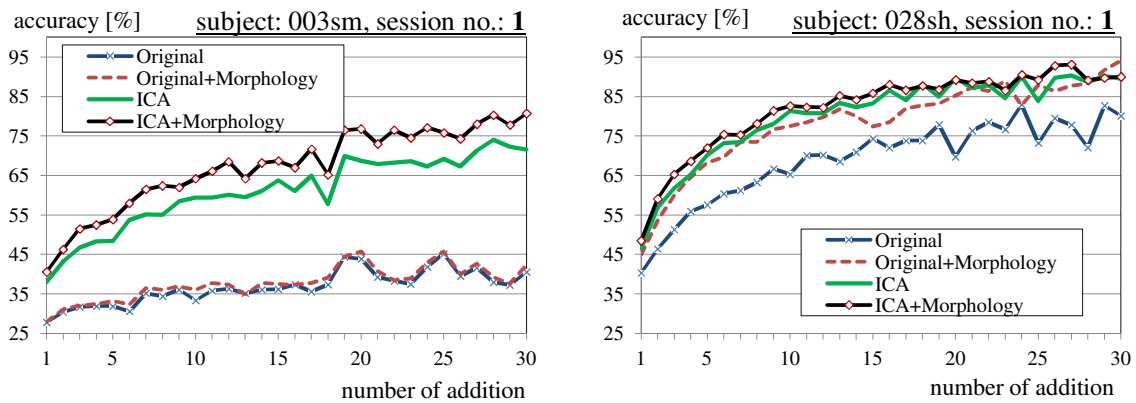


Fig. 3.74 加算回数による認識精度の変動

(subj.: (003sm) and (028sh), session no: 1)




Fig. 3.75 パタン識別結果

### 3.5 結言

本章では、脳コンピュータインターフェースの実装と利用を目指し、事象関連電位、事象関連同期・脱同期、視覚誘発電位の特徴を利用したBCIシステムを構築し、さらに計測した脳波信号から識別に有用な特徴を抽出するために、線形・非線形手法を適用した。

事象関連電位を用いたBCIシステムについては、モルフォロジー手法を用いることで、ノイズ成分と誘発電位成分、事象関連電位 P300 成分を別々の信号に分離できることを確認した。また、スケール復元も伴うICAを行うことで P300 成分を含む特徴を単一試行脳波から抽出できることを確認し、さらに、その信号は、テンプレート波形との相関情報を用いることで選択できることを確認した。検出した特徴を用いてパタン識別に組み込むことにより、より利用しやすい文字入力システムが構築できるものと考えられる。

事象関連同期・脱同期の特徴を用いた手足動作想像パタン識別に基づくBCIシステムについては、実験の結果としてこのシステムには被験者のトレーニングが必要であり、おおよそ10日のトレーニングが必要であることを確認した。また、トレーニングが上手いかわからない

被験者については、実験日間隔を開けたり、学習を促すための視覚的フィードバックのパラメータを調整することで改善ができる。さらに、学習傾向は、AR-model のモデルパラメータ  $\phi_1$  の傾向を調べることで大まかな検討がつけられることを確認した。解析としては、ICA、SOM、モルフォロジーを用いて、動作想像時脳波に含まれる突発的な変動や、パルス成分の抽出を行った。特に、サンプリング周波数を 128 [Hz] から 500[Hz] 以上に上げることによって、観測脳波に含まれる原信号数の変動や含まれる成分に違いが表れることを確認した。すなわち、一般に動作想像に関する特徴は、 $\beta$  帯域までであると言われていたが、動作想像に本質的に関わる周波数帯域は更に上の周波数帯域にあるものと考えられる。

視覚誘発電位を利用したシステムについては、特徴の抽出が容易である SSVEP を用いた注視点検出と、特徴の抽出が難しい反面で利用に関してメリットのある Transient-VEP を用いた注視点検出について、それぞれシステムを構築し、特徴の抽出を試みた。SSVEP を用いた場合、フーリエ解析を行うことで比較的容易に注視文字を判別することができる。しかしながら、これは視覚刺激装置の刺激周波数に重なりを認めないため、システムの拡張性が難しく、また、高い視覚周波数刺激は被験者の負担を導く。T-VEP を用いた場合、非周期的刺激の視覚刺激を用いた注視点検出装置について、単一光源の場合と多光源の場合とでそれぞれ構築し、比較を行った。その結果、単一光源時にはモルフォロジーを用いることで、光誘発電位 P75, N100 として現れる特徴を抽出することができることを確認した。しかしながら、多光源時には、脳波に多光源刺激の影響が表れ、判別が難しくなる問題が生じる。これに対して、独立成分分析を用いてこの混合信号から原信号に相当する成分を抽出し、パターン識別を行った結果、認識精度を大幅に回復させることができ、また、モルフォロジカルフィルタ設計による特徴抽出を行うことで、視覚誘発に関するより本質的な情報を抽出できることが確認された。システム出力に必要とする脳波入力時間は、これらの手法を利用することで短くすることができると考えられる。また、4 波の連続した視覚刺激を与えることで、脳の内部状態が変化することが確認された。認識精度や判別できるクラス数では、既存の事象関連電位 P300 を用いた脳波タイプライタシステムを上回るものではないが、視覚誘発電位を利用した BCI システムの構築についての一つの指針を得たと考えられる。

以上のように、本章では、実現に関して幾つかの問題を有する BCI システムについて、これらの追従実験や独自に開発したシステムの提案、および解析を通じて問題の解決を図った。結果として、トレーニングを必要とせず、安全性があり、短い脳波入力で指令を入力できる実用可能なシステムの開発には至らないものの、より本質的な脳波変動を抽出するための解析手法をいくつか提案できたものと考えられる。

## 4 結論

本研究では、非定常な時系列信号を解析するためのモルフォロジー解析の時間周波数領域への拡張方法や、対象信号を有意な特徴を持つ信号系列に自動分離する変換核の設計方法について検討を行い、新たな手法の提案を行うとともに、これらの手法を実環境で計測された音声信号や睡眠脳波信号へ適用して、信号の正負非対称性の評価などの新たな特徴抽出法としての可能性があることなど、その有効性を確認した。また、脳波信号からヒトの意思に関する情報を抽出しコンピュータの入力とするブレイン・コンピュータ・インターフェース(BCI)について、独自のシステムを構築して実験を行い、特徴抽出と変動識別に関して検討を行って、線形手法では分離が困難な突発的変動の安定した信号分離が可能であるなどの有効性を示した。

モルフォロジカルフィルタは、パルスノイズなどの正弦波を基底関数とするフーリエ解析では表現し難い特徴について上手く作用することができ、また、形状分布であるモルフォロジカル・パタンベクトルを時間周波数領域に拡張することで、非定常な信号の挙動を捉える事ができる。これらの手法は、フーリエ解析と類似した枠組みを持ち、モルフォロジーの基本演算であるミンコフスキー演算は、畳みこみ演算に対応し、パタンベクトルは、フーリエ・パワースペクトルに対応、さらにこれを時間周波数領域に拡張した局所スペクトルは、短時間フーリエ変換に対応する。また、モルフォロジカルフィルタ自動設計手法は、ウェーブレット解析手法のマッチング追跡に対応し、フィルタ自動設計により推定される構造関数の形状は、マッチング追跡で得られるマザーウェーブレットと同様に、もとの信号が有する形状成分を表していることが確認された。

これらのモルフォロジー手法の特性の確認として、音声信号と睡眠時脳波に対する適用を行った結果、音声信号解析においては、一般的に用いられているLPCスペクトルを用いたパタン識別手法と同程度の認識精度を抽出し、さらに、LPCで抽出しやすいクラスとパタンベクトルで抽出しやすいクラスが別であったため、既存のシステムに加えたさらなる特徴抽出ツールとなりえることが示された。また、睡眠時脳波解析においては、睡眠時脳波に表れる特殊形状を短時間パタンベクトルで表現し、睡眠脳波判読医によって判断された睡眠状態の推移とパタンベクトルの推移に相関があることを確認した。

この手法は、フーリエに基づく手法の周波数分解能が入力データの時間長に依存することに比べて、モルフォロジーの短時間スペクトルのレベル分解能は入力信号のサンプリング周波数に依存する特性がある。これは、例えば音声信号においては、8k [Hz] のサンプリング周波数で解析が行えるLPCに比べ、明瞭な解析におよそ5倍のサンプリング周波数を要求するため、長時間の音声信号解析には向かないというデメリットがあるが、より短い音声信号入力で解析が行えるという点は、既存の手法では難しい子音解析などに利用できるため、重要なツールになりえるものといえる。また、フーリエスペクトルが対称性を持つことに対し、パタンベクトルは対象信号の振幅の極性に依存して非対象のスペクトル構造を持つため、睡眠時

脳波信号のように対象とする信号の振幅の極性に重要な意味がある場合、より詳細な解析が期待できる。

このように、本研究で提案された手法は、非線形手法であるマセマティカル・モルフォロジー手法を体系的に整備したものであり、フィルタ特性を規定する構造関数の自動決定法や、パタンスペクトルを利用した信号の時間・周波数解析手法は、従来の線形手法では抽出できなかった形状に着目した新たな情報の抽出が可能となるものである。

BCIの実装と利用を目的とした実験については、オドボール課題実験や、これを応用したP300文字入力システム、動作想像時脳波の特徴を利用したBCIシステム、VEPを利用した注視文字検出について、既存システムに対する追従実験と新たなシステムの提案を行い、脳波信号解析を行った。

オドボール課題実験とP300文字入力システムにおいては、特徴抽出手法として信号の加算平均によるノイズ除去が主に用いられているが、独立成分分析やモルフォロジー手法を用いることでノイズや突発的な電位変化を効果的に抽出または除去することができることを確認した。

動作想像時脳波を用いたBCIシステムについては、ユーザがシステムを利用できるまでに10日前後のトレーニングを必要とすることを確認したが、これについては、トレーニング状態が自己回帰モデルのモデルパラメータに表れたため、これによる効率的なシステムに対するトレーニングを実行することができた。また、動作想像時に表れる脳波の本質的な変動を調べるために独立成分分析と自己組織化マップを用いた結果、独立成分分析においては、観測信号を構成する原信号の数が動作想像によって変動することが確認され、さらにこの変動の主な成分である秒間20発程度の頻度で出現するパルス性の信号をパタン識別の特徴量とした場合、自己回帰モデルと同等の認識精度を得ることができた。自己組織化マップについては、各動作想像クラスで最も更新されたユニットの情報を用いることで、入力ベクトルであるLPCスペクトルの周波数に違いが表れることを確認した。また、動作想像時脳波を用いたBCIシステムに対してフェールセーフ機能を持たせることを目的として、システムの誤判別を視覚的にフィードバックさせるシステムを構築し、モルフォロジー手法を用いて、動作想像に関する信号成分と、システム誤判別の出力時に脳波に表れるエラーポテンシャルと呼ばれる突発的な電位変動である事象関連電位成分を別々の信号に分離できることを確認した。

VEPを用いた注視文字検出システムについては、ユーザに負担を与えるが脳波信号から変動抽出が容易であるSSVEPを用いたシステムについて、これを構築し、効果的な特徴量抽出について検討を行った結果、適切な脳波信号導出法と特徴量抽出を行うことで、システムに対するトレーニングを必要とせず高い認識精度でユーザの注視文字が判別できることを確認した。また、他光源の影響を受けやすいT-VEPについて、これを用いた注視文字検出システムを構築し、独立成分分析とモルフォロジー手法を用いた特徴抽出を試みた結果、注視文字のみに関する特徴を抽出でき、SSVEPを用いたシステムよりも精度が下がるが、システムに対するトレーニングを必要とせずある程度の認識精度で判別できることを確認した。

以上のように、本研究では、非線形手法の一手法を提案するとともに、これを利用した BCI システムの構築を行った。本研究における BCI システムは、トレーニングを必要とせず、安全性があり、短い脳波入力で指令を入力できる実用可能なシステムであるとは言い難いが、より本質的な脳波変動を抽出するための解析手法をいくつか提案できたものとする。

本研究には、多重解像度解析における基底構造関数の決定方法や、抽出された特徴のより効果的な解析手法などの課題も残るが、非線形解析手法であるモルフォロジカルフィルタが音声信号や脳波信号などの信号解析に有用であることを明らかにした。この研究を更に進めることで、例えば音声信号では、子音などの短い時間における変動なども効果的に解析でき、脳波信号ではユーザの意思に関する情報を抽出することができると考えられる。また、この手法は、音声信号や脳波信号に限らず、情報が未知で、周期的な振る舞いを見せない非定常な信号の解析に利用することができると考えられる。

## 謝辞

本論文をまとめるにあたり，終始懇切なご指導とご鞭撻とを賜りました九州工業大学情報工学部 井上勝裕教授に甚深なる感謝の意を表します．また，九州工業大学情報工学部の熊丸耕介教授，藤尾光彦准教授，前田誠助教授には終始多大な御教示と懇篤なる御指導を頂きました，心より感謝申し上げます．

本研究は，Graz 工科大学の Pfurtscheller 教授が考案された動作想像時脳波を用いたマンマシンインターフェースに関する研究について，実験データとなる脳波信号データを頂き，さらに本学で研究を進めたものであります．脳波変動に関する重要な基礎研究データを国立精神・神経センターの白川修一郎室長より頂き，さらに脳波計測実験に関する御指導を賜りました．また，考案した信号処理手法の特性を確認するために，筑波大学板橋秀一教授より日本語音声コーパスを頂きました．ここに謹んで諸先生方に対して，感謝の意を表します．

さらに，本研究を遂行するにあたり，石橋孝昭先輩を始めとする多くの同大学井上研究室・藤尾研究室，近畿大学五反田研究室の先輩，同輩，後輩らから御指導・御協力を頂きました，深く感謝致します．

## 参考文献

- [1] 樋口龍雄. デジタル信号処理の基礎. 昭晃堂, 1986.
- [2] 棟安実治, 田口亮, 雛元孝夫. 非線形デジタル信号処理. 朝倉書店, 1999.
- [3] Ioannis Pitas and Anastasios N. Venetsanopoulos. *Nonlinear Digital Filters: Principles and Applications*. Springer US, 1990.
- [4] J. W. Tukey. Nonlinear (nonsuperposable) methods for smoothing data. *Cong. Rec. EAS-CON'74*, pages 837–855, 1974.
- [5] D. R. K. Brownrigg. The weighted median filter. *Communication of the ACM*, 27(8):807–818, 1984.
- [6] L. Yin, R. Yang, M. Gabbouj, and Y. Neuvo. Weighted median filters: A tutorial. *IEEE Trans. on Circuits Syst. II*, 43(3):157–192, 1996.
- [7] Ayyaz Hussain et al. Random-valued impulse noise removal using fuzzy logic. *International Journal of Innovative Computing, Information and Control*, 6(10):4723–4288, 2010.
- [8] Chao-Ho (Thou-Ho) Chen et al. Intelligent adaptive subband-based multi-state median filter in lowly-corrupted images. *International Journal of Innovative Computing, Information and Control*, 5(9):2917–2926, 2009.
- [9] Frank Y Shih. *Image Processing and Mathematical Morphology Fundamentals and Applications*. Taylor & Francis, 2009.
- [10] M.A. Schulze and J.A. Pearce. Linear combinations of morphological operators: the midrange, pseudomedian, and loco filters. *1993 IEEE International Conference on Acoustics, Speech, and Signal Processing*, 5:57–60, 1993.
- [11] H. Kobatake. "Morphology". *CORONA PUBLISHING CO., LTD.*, 1996.
- [12] G. Matheron and J. Serra. The birth of mathematical morphology. *Proc. 6th International Symposium on Mathematical Morphology*, pages 1–16, 2002.
- [13] J. Serra. *Image analysis and mathematical morphology Volume 2: Technical advances*. Academic Press, 1982.
- [14] H. J. A. M. Heijmans. *Morphological Image Operations*. Academic Press, Soston, 1994.
- [15] Petros Maragos. Slope transforms: Theory and application to nonlinear signal processing. *IEEE Transaction on Signal Processing*, 43(4):864–877, 1995.



- 
- [16] 浅野晃, 浅野千恵, 木森義隆, 棟安 実治, 延原 肇, 藤尾 光彦. 非線形画像・信号処理 (モルフォロジーの基礎と応用). 丸善株式会社, 2010.
- [17] A. Asano, Y. Kobayashi, C. Murai, and M. Muneyasu. Optimization of gray scale morphological opening for noise removal in texture images. *Proc. 2004 IEEE international Midwest Symposium on Circuits and Systems*, 1:I313–I316, 2011.
- [18] 奥野裕之, 花田良子, 棟安実治, 浅野晃. 劣化画像のみを用いた雑音除去のための  $ga$  による最適構造要素の推定法の検討. 電子情報通信学会技術研究報, *SIS2008-76*, pages 25–30, 2009.
- [19] D.E. Goldberg. Genetic algorithms in search optimization and machine learning. *Addison-Wesley*, 1989.
- [20] 佐藤, 小野, 小林. 遺伝的アルゴリズムにおける世代交代モデルの提案と評価. 人工知能学会誌, 12(5):734–743, 1996.
- [21] 西田茂人, 中村政俊, 諏訪園秀吾. 単一試行誘発電位の波形特徴抽出のためのモルフォロジカルフィルタ設計. 医用電子と生体工学, 34(3):255–263, 1996.
- [22] R.L. Kashyap. "Optimal feature selection and decision rules in classification problems with time series". *IEEE Trans. Information Theory*, IT-24:281–288, 1978.
- [23] 榊原進. ウェーブレット ビギナーズガイド. 東京電機大学出版局, 1995.
- [24] 戸田浩, 章忠, 川畑洋昭. 最新ウェーブレット実践講座 入門と応用. ソフトバンク クリエイティブ株式会社, 2005.
- [25] Charles K. Chui 著, 桜井 明, 新井 勉 訳. ウェーブレット応用 信号解析のための数学的手法. 東京電機大学出版局, 1997.
- [26] R. Todd Ogden. "Essential Wavelets for Statistical Applications and Data Analysis". *Boston: Birkhäuser*, 1997.
- [27] K. Inoue, A. Takajo, M. Maeda, and S. Matsuoka. Tuning method of modified wavelet transform in human sleep eeg analysis. *International Conference on Control, Automation and Systems, 2007*, pages 2784 – 2789, 2007.
- [28] 新井朝雄. ヒルベルト空間と量子力学. 共立出版株式会社, 1997.
- [29] G.P. Nason and B.W. Silverman. The stationary wavelet transform and some statistical applications. *Lecture Notes in Statistics*, 103:281–299, 1995.

- 
- [30] Zhong Zhang, Hiroshi Toda, and Hiroaki Kawabata. "RI-Spline Wavelet and Its Application for Unsteady Signal Analysis-2nd Report, Complex Multi-Resolution Analysis with RI-Spline Wavelet". *Transactions of the Society of Instrument and Control Engineers*, 39(7):615–623, 2003.
- [31] S. G. Mallat. "Zero-crossings of a wavelet transform". *IEEE Transaction on Information Theory*, 37-4:1019–1033, 1991.
- [32] S.G. Mallat and Zhifeng Zhang. Matching pursuits with time-frequency dictionaries. *IEEE Transactions on Signal Processing*, 41:3397 – 3415, 1993.
- [33] Christian G. Bénar, Théodore Papadopoulo, Bruno Torr sani, and Maureen Clerc. Consensus matching pursuit for multi-trial eeg signals. *Journal of Neuroscience Methods*, 180:161–170, 2009.
- [34] Henk J. A. M. Heijmans and John Goutsias. "Nonlinear Multiresolution Signal Decomposition Schemes-Part II: Morphological Wavelets". *IEEE Trans. on Image Processing*, 9(11):1897–1913, 2000.
- [35] Chang'an Wei and Shouda Jiang. Small target detection in flir imagery using multi-scale morphological filter and kernel density estimation. *International Journal of Innovative Computing, Information and Control*, 5(7):1811–1817, 2009.
- [36] H. Nobuhara et al. Max-plus algebra-based wavelet transforms and their fpga implementation for image coding. *Information Sciences*, 180:3232–3247, 2010.
- [37] Bin Yang and Shutao Li. Multi-focus image fusion using watershed transform and morphological wavelet clarity measure. *International Journal of Innovative Computing, Information and Control*, 7(5A):2503–2514, 2011.
- [38] P. Maragos. Pattern spectrum and multiscale shape representation. *IEEE Trans. on PAMI*, 11(7):701–716, 1989.
- [39] Tomonari Yamaguchi, Mitsuhiko Fujio, and Katsuhiko Inoue. Design method of morphological structuring function for pattern recognition of eeg signals during motor imagery and cognition. *International Journal of Innovative Computing, Information and Control*, 7(8):4989–5002, 2011.
- [40] 井上勝裕, 藤尾光彦, 前田誠, 山口朋成. ウェーブレット手法の脳波解析への応用. システム制御情報学会誌, 53(1):34–40, 2009.
- [41] Tomonari Yamaguchi, Kouji Seita, Mitsuhiko Fujio, and Katsuhiko Inoue. Morphological redundant wavelet analysis of vocal signal. *ICIC Express Letters*, 6(4), 2011.

- 
- [42] L. R. Rabiner and R. W. Schafer. *Digital Processing of Speech Signals*. Prentice-Hall, 1978.
- [43] ピーター B. デニッシュ, エリオット N. ピンソン 著, 切替一郎・藤村靖監訳, 神山五郎・戸塚元吉共訳. 話ことばの科学. 東京大学出版社, 1966.
- [44] J. L. Flanagan. *Speech Analysis, Synthesis and Perception*. Springer Verlag, 1965.
- [45] 古井貞熙. 新音響・音声工学. 近代科学社, 2006.
- [46] 板橋秀一. 音声工学. 森北出版, 2005.
- [47] J. L. Kelly and C. Lochbaum. Speech synthesis. *Proc. Speech Communication Seminar, Stockholm*, 1962.
- [48] Jing Dong et al. Pitch detection using circular average magnitude difference function based on wavelet transform. *International Journal of Innovative Computing, Information and Control*, 5(9):2717–2724, 2009.
- [49] M. Cooke, S. Beet, and M. Crawford. *Visual Representations of Speech Signal*. John Wiley & Sons, 1993.
- [50] Hideki Kasuya, Hisayoshi Suzuki, and Keniti Kido. Changes in pitch and first three formant frequencies of five Japanese vowels with age and sex of speakers. *Acoustical Society of Japan*, 24(6):355–364, 1968.
- [51] E. Niedermeyer and F. L. Da Silva. "Electroencephalography: Basic Principles, Clinical Applications, and Related Fields". *Williams & Wilkins*, 1999.
- [52] 佐藤光源, 松岡洋夫. 最新臨床脳波学. 朝倉書店, 1993.
- [53] T. Hori, Y. Sugita, and et al. Proposed supplements and amendments to 'techniques and scoring system for sleep stages of human subjects', the Rechtschaffen & Kales (1968) standard. *Psychiatry and Clinical Neurosciences*, 55(3):305–310, 2001.
- [54] A. Rechtschaffen and A. Kales. *A manual of standardized terminology, techniques and scoring system for sleep stages of human subject*. Public Health Service U.S. Government Printing Office, Washington D.C., 1968.
- [55] J. J. Vidal. "Toward direct brain computer communication". *Annual Rev. Biophysics Bio-engineering*, pages 157–180, 1973.
- [56] J. Wolpaw and D. McFarland. "Multichannel EEG based brain computer communications". *Electroencephalography and clinical Neuro-physiology*, 90:444–449, 1997.

- 
- [57] Dennis J. McFarland, Lynn M. McCane, Stephen V. David, and Jonathan R. Wolpaw. Spatial filter selection for eeg-based communication. *Electroencephalography and clinical Neurophysiology*, 103(3):386–394, 1997.
- [58] J. C. Sanchez, P. R. Carney A. Gunduz, and J. C. Principe. "Extraction and localization of mesoscopic motor control signals for human ECoG neuroprosthetics". *Journal of Neuroscience Methods*, 167:63–81, 2008.
- [59] J. Wolpaw, N. Birbaumer, D. J. McFarland, G. Pfurtscheller, and Theresa M. Vaughan. "Brain-computer interfaces for communication and control". *Clinical Neurophysiology*, 113:767–79, 2002.
- [60] Christoph Guger, Shahab Daban, Eric Sellers, Clemens Holzner, Gunther Krausz, Roberta Carabalona, Furio Gramatica, and Guenter Edlinger. "How many people are able to control a P300-based brain-computer interface (BCI)?". *Neuroscience Letters*, 462:94–98, 2009.
- [61] G. Pfurtscheller, C. Brunner, A. Schlögl, and F.H. Lopes da Silva. "Mu rhythm (de)synchronization and EEG single-trial classification of different motor imagery tasks". *NeuroImage*, 31-1:153–159, 2006.
- [62] P. Martinez, H. Bakardjian, and A. Cichocki. Fully-online multi-command brain computer interface with visual neurofeedback using ssvep paradigm. *Computational Intelligence and Neuroscience*, 2007(94561):9, 2007.
- [63] K. Inoue, K. Kumamaru, and G. Pfurtscheller. "Robot Operation based on Pattern Recognition of EEG Signals". *Proc. of the 3rd International Brain-Computer Interface Workshop and Training Course 2006*, pages 116–117, 2006.
- [64] Tomonari Yamaguchi, Miyo Taniguchi, Koichi Nagata, Makoto Mihara, Pham Quang Truong, Katsuhiko Inoue, Mitsuhiko Fujio, Kousuke Kumamaru, and Gert Pfurtscheller. Pattern recognition of eeg signals during hand and foot motor imagery. *The 38th ISICIE International Symposium on Stochastic Systems Theory and Its Applications*, pages 88–93, 2006.
- [65] K. Inoue, D. Mori, G. Pfurtscheller, and K. Kumamaru. "Pattern Recognition of EEG Signals During Right and Left Motor Imagery Learning Effects of the Subjects". *edited by J.L Wu, K. Ito, S. Tobimatsu, T. Nishida, and H. Fukayama, Complex Medical Engineering, Springer*, pages 251–261, 2007.
- [66] K. Inoue, M. Fujio, T. Yamaguchi, and G. Pfurtscheller. "Mathematical Morphological Multi-resolution Analysis of EEG Signals during Misoperation of BCI System". *Proc.of the 4th International Brain-Computer Interface Workshop and Training Course 2008*, pages 74–79, 2008.

- [67] T. Yamaguchi, M. Fujio, K. Inoue, and G. Pfurtscheller. "Wavelet analysis of EEG signals during motor imagery". *International Conference on Wavelet Analysis and Pattern Recognition, 2008.*, 1:454–459, 2008.
- [68] 吉村 奈津江, 板倉 直明. Transient 型 Vep を用いた脳波入力インタフェースの研究. *JSMBE*, 46(2):202–211, 2008.
- [69] Guangyu Bin, Xiaorong Gao, Yijin Wand, Yun Li, and Bo Hong. A high-speed bci based on code modulation vep. *Journal of Neural Engineering*, 8(2), 2011.
- [70] G. Schalk, J. R. Wolpaw, D. J. McFarland, and G. Pfurtscheller. "EEG-Based communication: presence of an error potential". *Clinical Neurophysiology*, 111:2138–2144, 2000.
- [71] Tomonari Yamaguchi, Kana Ohmori, Jun Irie, and Katsuhiko Inoue. Feature extraction from eeg signals in ssvep spelling system. *SICE Annual Conference 2010*, pages 58–62, 2010.
- [72] K. Inoue, T. Yamaguchi, T.Mizoguchi, M. Fujio, and M. Maeda. A transient-vep based spelling system by using ica and adaptive morphological filter. *Proceedings of the 5th International Brain-Computer Interface Conference 2011*, pages 76–79, 2011.
- [73] 柏木潤. *M* 系列とその応用. 昭晃堂, 1996.
- [74] 井上勝裕, 山口朋成, 前田誠, 藤尾光彦. 脳波によるヒトの状態推定のためのウェーブレット手法の応用. 平成 23 年度数学・数理科学と諸科学・産業との連携研究ワークショップ ウェーブレット理論と工学への応用 プロシーディングス, pages 131–149, 2011.
- [75] Tomonari Yamaguchi, Mitsuhiko Fujio, Katsuhiko Inoue, and Gert Pfurtscheller. Feature extraction of eeg during motor imagery and cognition by using morphological mra. *ICCAS-SICE 2009*, pages 843–848, 2009.
- [76] Aapo Hyvärinen, Juha Karhunen, and Erkki Ojya. 詳解 独立成分分析 (根元幾, 川勝真喜 訳). 東京電機大学出版局, 2005.
- [77] A. Hyvärinen and E. Oja. Independent component analysis algorithms and applications. *Neural Networks*, 13(4):411–430, 2000.
- [78] Shiro Ikeda and Noboru Murata. A method of ica in time-frequency domain. *in Proc. ICA*, pages 365–371, 1999.
- [79] T. Ishibashi, M. Sugahara, S. Tamatsuka, K. Inoue, H. Gotanda, and K. Kumamaru. "Estimation of the Number of Unknown Source Signals and Its Application to EEG Analysis". *The 38th ISCIE International Symposium on Stochastic System Theory and Its Applications*, pages 100–105, 2006.

- 
- [80] T. Ishibashi, S. Tamatsuka, M. Sugahara, K. Inoue, H. Gotanda, and K. Kumamaru. Separation performance of ica algorithms dependent on the source number. *The 38th ISCIE International Symposium on Stochastic System Theory and Its Applications*, pages 318–323, 2006.
- [81] Noboru Murata, Shiro Ikeda, and Andreas Ziehe. An approach to blind source separation based on temporal structure of speech signals. *Neurocomputing*, 41:1–24, 1998.
- [82] 村田昇. 入門 独立成分分析. 東京電機大学出版局, 2004.
- [83] T. コホネン著, 徳高平蔵, 岸田悟, 藤村喜久郎 訳. *Self-Organizing Map*. シュプリンガー・フェアラーク東京, 1996.
- [84] Tomonari Yamaguchi, Koichi Nagata, Pham Quang Truong, Mitsuhiko Fujio, Gert Pfurtscheller, and Katsuhiko Inoue. Pattern recognition of eeg signal during motor imagery by using som. *International Journal of Innovative Computing, Information and Control*, 4(10):2617–2630, 2008.

## A 信号からの特徴抽出手法

計測した信号からその信号が有する特徴を抽出するために、様々な手法が研究されている。ここでは、自己回帰モデルを用いたパターン識別、自己組織化マップ、独立成分分析の3手法について紹介する。

### A.1 自己回帰モデルを用いたパターン識別手法

自己回帰モデル (Auto-Regressive Model: AR-Model) は、現在の出力サンプル値がそれ以前のサンプル値の線形結合によって予測されるものとするモデルであり、定常な振る舞いを見せる信号の同定によく用いられている。ここでは、自己回帰モデルからなる確率密度関数をベイズ判定法に導入し、クラス判別を行う手法について紹介し [22]、また、AR-Model の予測係数から推定されるスペクトル包絡 (AR-Spectrum) の手法について説明する。これは、モデル次数の設定に依存してフーリエ・スペクトルよりも誤差が小さく、滑らかな包絡線が得られるものである。

#### A.1.1 ベイズ判定法

ベイズ判定法は、データ (特徴ベクトル) が属するクラスを、事後確率が最大となるクラスとする判別器において、ベイズ則を用いて判別器を既知情報から構成できるものに変形する手法である。特徴ベクトル  $\mathbf{x}$  をクラス  $\omega_k$  に割りつける判別器は、次式のように表わされる。

$$k^* = \arg \max_k \Pr(\omega_k | \mathbf{x}) \quad (\text{A.1})$$

ベイズ判定法においては、事後確率  $\Pr(\omega_k | \mathbf{x})$  を、事前確率  $\Pr(\mathbf{x} | \omega_k)$  と、先験確率  $\Pr(\omega_k)$  を用いて次式のように展開する。

$$\begin{aligned} k^* &= \arg \max_k \Pr(\omega_k | \mathbf{x}) = \arg \max_k \frac{p(\omega_k, \mathbf{x})}{p(\mathbf{x})} = \arg \max_k \left\{ \frac{p(\omega_k, \mathbf{x})}{\Pr(\omega_k)} \cdot \frac{\Pr(\omega_k)}{p(\mathbf{x})} \right\} \\ &= \arg \max_k \left\{ \frac{p(\mathbf{x} | \omega_k) \Pr(\omega_k)}{p(\mathbf{x})} \right\} = \arg \max_k \{ p(\mathbf{x} | \omega_k) \Pr(\omega_k) \} = \arg \max_k \{ \ln [p(\mathbf{x} | \omega_k) \Pr(\omega_k)] \} \\ &= \arg \min_k \{ -\ln p(\mathbf{x} | \omega_k) - \ln \Pr(\omega_k) \} \end{aligned} \quad (\text{A.2})$$

ただし、扱う事前確率  $\Pr(\mathbf{x} | \omega_k)$  は連続量のため、これを確率密度関数  $p(\mathbf{x} | \omega_k)$  で表記している。ここで、システムを決定するパラメータ  $\theta$  は、各クラスにおいて一定であると仮定する (SIMPLE CLASS の仮定)。すなわち、 $p(\theta | \omega_k) = \delta(\theta - \theta_k)$  とすると、 $p(\mathbf{x} | \omega_k)$  は次式で表される。

$$\begin{aligned} p(\mathbf{x} | \omega_k) &= \int_{-\infty}^{\infty} p(\mathbf{x}, \theta | \omega_k) d\theta = \int_{-\infty}^{\infty} p(\mathbf{x} | \theta, \omega_k) p(\theta | \omega_k) d\theta \\ &= \int_{-\infty}^{\infty} p(\mathbf{x} | \theta, \omega_k) \delta(\theta - \theta_k) d\theta = p(\mathbf{x} | \theta_k, \omega_k) = p(\mathbf{x} | \theta_k) \end{aligned} \quad (\text{A.3})$$

ただし,  $p(\theta_k, \omega_k) = p(\theta_k)p(\omega_k)$  である. Eq. (A.3) より, 判別式は, 次のようにシステムパラメータ  $\theta_k$  で表現された判別式に変形できる.

$$k^* = \arg \min_k \{p(\mathbf{x}|\theta_k) \Pr(\omega_k)\} \quad (\text{A.4})$$

ここで,  $i$  番目の系列を  $\mathbf{x}^{(i)}$  として, 特徴ベクトルの分布が正規分布に従うものと仮定した場合, 確率密度関数は次式のように表される.

$$p(\mathbf{x}|\omega_k) = \frac{1}{(2\pi)^{n/2} |\Sigma_k|^{1/2}} \exp \left[ -\frac{1}{2} (\mathbf{x} - \mathbf{m}_k)^T \Sigma_k^{-1} (\mathbf{x} - \mathbf{m}_k) \right] \quad (\text{A.5})$$

$$\left( \mathbf{m}_k = \frac{1}{N} \sum_{i=1}^N \mathbf{x}^{(i)}, \quad \Sigma_k = \frac{1}{N-1} \sum_{i=1}^N (\mathbf{x}^{(i)} - \mathbf{m}_k)(\mathbf{x}^{(i)} - \mathbf{m}_k)^T \right)$$

これにより, 判別式は次式のように変形できる.

$$\begin{aligned} k^* &= \arg \min_k \left\{ -\ln \left( \frac{1}{(2\pi)^{n/2} |\Sigma_k|^{1/2}} \exp \left[ -\frac{1}{2} (\mathbf{x} - \mathbf{m}_k)^T \Sigma_k^{-1} (\mathbf{x} - \mathbf{m}_k) \right] \right) - \ln \Pr(\omega_k) \right\} \\ &= \arg \min_k \left\{ \frac{n}{2} \ln(2\pi) + \frac{1}{2} (\mathbf{x} - \mathbf{m}_k)^T \Sigma_k^{-1} (\mathbf{x} - \mathbf{m}_k) + \frac{1}{2} \ln |\Sigma_k| - \ln \Pr(\omega_k) \right\} \\ &= \arg \min_k \left\{ \frac{1}{2} (\mathbf{x} - \mathbf{m}_k)^T \Sigma_k^{-1} (\mathbf{x} - \mathbf{m}_k) + \frac{1}{2} \ln |\Sigma_k| - \ln \Pr(\omega_k) \right\} \end{aligned} \quad (\text{A.6})$$

### A.1.2 自己回帰モデル

自己回帰モデルは, 信号を過去の系列の線形結合と雑音の和で表現する線形モデルであり, 以下のように表される.

$$y_t = \sum_{j=1}^m \phi_j y_{t-j} + v_t = \Phi^T z_{t-1} + v_t, \quad v_t \sim N[0, \rho^2], \quad m+1 \leq t \leq N \quad (\text{A.7})$$

ここで,  $m$  はモデル次数,  $N$  は 1 系列のデータ長,  $\Phi = [\phi_1, \phi_2, \dots, \phi_m]^T$  は係数ベクトル,  $z_{t-1} = [y_{t-1}, y_{t-2}, \dots, y_{t-m}]^T$  は回帰ベクトルを意味する. また, 以下では  $z_N = [y_N, y_{N-1}, \dots, y_1]^T$  を観測値ベクトルとして用いる. 自己回帰モデルに対するベイズ判別法は, 特徴ベクトルを  $z_N$ , システムパラメータを  $\theta_k = [\Phi_k^T, \rho_k]^T$  として, 次式で表す.

$$k^* = \arg \max_k \{p(z_N|\theta_k) \Pr(\omega_k)\} \quad (\text{A.8})$$

ここで,  $p(z_N|\theta_k)$  について, 次式のように表すことができる.

$$\begin{aligned} p(z_N|\theta_k) &= p(y_N, y_{N-1}, \dots, y_1|\theta_k) \\ &= \frac{p(y_N, y_{N-1}, \dots, y_1, \theta_k)}{\Pr(\theta_k)} \cdot \frac{p(y_{N-1}, y_{N-2}, \dots, y_1, \theta_k)}{p(y_{N-1}, y_{N-2}, \dots, y_1, \theta_k)} \cdots \frac{p(y_m, y_{m-1}, \dots, y_1, \theta_k)}{p(y_m, y_{m-1}, \dots, y_1, \theta_k)} \\ &= p(y_N|y_{N-1}, y_{N-2}, \dots, y_1, \theta_k) \cdot p(y_{N-1}|y_{N-2}, y_{N-3}, \dots, y_1, \theta_k) \cdots \frac{p(y_m, y_{m-1}, \dots, y_1, \theta_k)}{\Pr(\theta_k)} \\ &= p(y_m, y_{m-1}, \dots, y_1|\theta_k) \prod_{t=m+1}^N p(y_t|y_{t-1}, y_{t-2}, \dots, y_1, \theta_k) \end{aligned} \quad (\text{A.9})$$



そのため，判別式は次式で表される．

$$k^* = \arg \max_k \left\{ p(y_m, y_{m-1}, \dots, y_1 | \theta_k) \left( \prod_{t=m+1}^N p(y_t | y_{t-1}, y_{t-2}, \dots, y_1, \theta_k) \right) \Pr(\omega_k) \right\} \quad (\text{A.10})$$

ここで，Eq. (A.7) の  $v_t$  が正規分布であることから， $p(y_t | y_{t-1}, y_{t-2}, \dots, y_1, \theta_k)$  も正規分布になる．これにより， $p(y_t | y_{t-1}, y_{t-2}, \dots, y_1, \theta_k)$  の平均値及び分散値を計算すると，次式となる．

$$\begin{aligned} E[y_t | y_{t-1}, y_{t-2}, \dots, y_1, \theta_k] &= E[\Phi_k^T z_{t-1} + v_t | y_{t-1}, y_{t-2}, \dots, y_1, \theta_k] \\ &= E[\Phi_k^T z_{t-1} | y_{t-1}, y_{t-2}, \dots, y_1, \theta_k] + E[v_t | y_{t-1}, y_{t-2}, \dots, y_1, \theta_k] \\ &= E[\Phi_k^T z_{t-1} | y_{t-1}, y_{t-2}, \dots, y_1, \theta_k] \\ &= \Phi_k^T z_{t-1} \end{aligned} \quad (\text{A.11})$$

$$\begin{aligned} V[y_t | y_{t-1}, y_{t-2}, \dots, y_1, \theta_k] &= E\left[\left(y_t - \Phi_k^T z_{t-1}\right)^2 \middle| y_{t-1}, y_{t-2}, \dots, y_1, \theta_k\right] \\ &= E\left[\left(\left(\Phi_k^T z_{t-1} + v_t\right) - \Phi_k^T z_{t-1}\right)^2 \middle| y_{t-1}, y_{t-2}, \dots, y_1, \theta_k\right] \\ &= E\left[v_t^2 \middle| y_{t-1}, y_{t-2}, \dots, y_1, \theta_k\right] \\ &= \rho_k \end{aligned} \quad (\text{A.12})$$

これにより，確率密度関数  $p(y_t | y_{t-1}, y_{t-2}, \dots, y_1, \theta_k)$  は，次式となる．

$$p(y_t | y_{t-1}, y_{t-2}, \dots, y_1, \theta_k) = \frac{1}{\sqrt{2\pi\rho_k}} \exp\left(-\frac{1}{2\rho_k} \left(y_t - \Phi_k^T z_{t-1}\right)^2\right) \quad (\text{A.13})$$

この結果を Eq. (A.9) に代入して  $p(z_N | \theta_k)$  を求めると，次式となる．

$$\begin{aligned} p(z_N | \theta_k) &= \frac{p(y_t | y_m, y_{m-1}, \dots, y_1, \theta_k)}{p(\theta_k)} \prod_{t=m+1}^N \frac{1}{\sqrt{2\pi\rho_k}} \exp\left(-\frac{1}{2\rho_k} \left(y_t - \Phi_k^T z_{t-1}\right)^2\right) \\ &= \frac{p(y_t | y_m, y_{m-1}, \dots, y_1, \theta_k)}{p(\theta_k)} \left(\frac{1}{2\pi\rho_k}\right)^{\frac{N-m}{2}} \exp\left(-\frac{1}{2\rho_k} \sum_{t=m+1}^N \left(y_t - \Phi_k^T z_{t-1}\right)^2\right) \end{aligned} \quad (\text{A.14})$$

ここで， $p(y_m, y_{m-1}, \dots, y_1, \theta_k) / p(\theta_k)$  を初期観測値として用い，また，初期観測値はクラスに依存しないと仮定すると Eq. (A.14) は次式で表される．

$$\begin{aligned} p(z_N | \theta_k) &= p(y_m, y_{m-1}, \dots, y_1) \left(\frac{1}{2\pi\rho_k}\right)^{\frac{N-m}{2}} \exp\left(-\frac{1}{2\rho_k} \sum_{t=m+1}^N \left(y_t - \Phi_k^T z_{t-1}\right)^2\right) \\ (p(y_m, y_{m-1}, \dots, y_1, \theta_k) &= p(y_m, y_{m-1}, \dots, y_1) p(\theta_k)) \end{aligned} \quad (\text{A.15})$$

パラメータ推定に関しては，次式の尤度関数を用いて最尤推定を行う．

$$L = \sum_{j=1}^{N_p} \ln p(z_N^j | \theta_k) \quad (\text{A.16})$$

ここで， $N_p$  は，パラメータ推定に用いるデータ数を表し， $z_N^j$  は  $j$  試行目の観測値ベクトルを表す．また， $j$  試行目の時刻  $t$  における信号値を  $y_t^j$  とする．最尤推定では，この尤度関数が最大

になる  $\Phi_k^T, \rho_k$  をそれぞれ求める. Eq. (A.15) より,  $p(z_N|\theta_k)$  を Eq. (A.16) に代入して, 次式が得られる.

$$\begin{aligned} L &= \sum_{j=1}^{N_p} \ln \left[ p(y_m^j, y_{m-1}^j, \dots, y_1^j, \theta_k) \left( \frac{1}{2\pi\rho_k} \right)^{\frac{N-m}{2}} \exp \left( -\frac{1}{2\rho_k} \sum_{t=m+1}^N (y_t^j - \Phi_k^T z_{t-1}^j)^2 \right) \right] \\ &= \sum_{j=1}^{N_p} \left[ \ln p(y_1^j, y_2^j, \dots, y_m^j, \theta_k) - \frac{N-m}{2} \ln(2\pi) - \frac{N-m}{2} \ln \rho_k - \frac{1}{2\rho_k} \sum_{t=m+1}^N (y_t^j - (z_{t-1}^j)^T \Phi_k)^2 \right] \end{aligned} \quad (\text{A.17})$$

パラメータの推定値  $\hat{\theta} = [\hat{\Phi}_k^T, \hat{\rho}_k^T]^T$  を求めるため, Eq. (A.17) において  $L$  を  $\Phi_k, \rho_k$  で偏微分し,  $\frac{\partial L}{\partial \Phi_k} = 0, \frac{\partial L}{\partial \rho_k} = 0$  となる  $\hat{\Phi}_k, \hat{\rho}_k$  を求める.

$$\begin{aligned} \frac{\partial L}{\partial \Phi_k} &= \sum_{j=1}^{N_p} \left[ \left( -\frac{1}{2\rho_k} \right) \sum_{t=m+1}^N \frac{\partial}{\partial \Phi_k} (y_t^j - (z_{t-1}^j)^T \Phi_k)^2 \right] \\ &= \sum_{j=1}^{N_p} \left[ \left( -\frac{1}{2\rho_k} \right) \sum_{t=m+1}^N \left( -2(z_{t-1}^j)^T y_t^j + 2(z_{t-1}^j)(z_{t-1}^j)^T \Phi_k \right) \right] \end{aligned} \quad (\text{A.18})$$

$$\begin{aligned} \frac{\partial L}{\partial \rho_k} &= \sum_{j=1}^{N_p} \left[ -\frac{N-m}{2} \frac{\partial}{\partial \rho_k} \ln \rho_k - \frac{\partial}{\partial \rho_k} \frac{1}{2\rho_k} \sum_{t=m+1}^N (y_t^j - (z_{t-1}^j)^T \Phi_k)^2 \right] \\ &= \sum_{j=1}^{N_p} \left[ -\frac{N-m}{2\rho_k} + \frac{1}{2\rho_k^2} \sum_{t=m+1}^N (y_t^j - (z_{t-1}^j)^T \Phi_k)^2 \right] \end{aligned} \quad (\text{A.19})$$

$\frac{\partial L}{\partial \Phi_k} = 0, \frac{\partial L}{\partial \rho_k} = 0$  において,  $\hat{\Phi}_k, \hat{\rho}_k$  をそれぞれ求めると, 次式の推定値が得られる.

$$\hat{\Phi}_k = \left( \sum_{j=1}^{N_p} \sum_{t=m+1}^N (z_{t-1}^j)(z_{t-1}^j)^T \right)^{-1} \left( \sum_{j=1}^{N_p} \sum_{t=m+1}^N y_t^j (z_{t-1}^j) \right) \quad (\text{A.20})$$

$$\hat{\rho}_k = \frac{1}{N_p(N-m)} \sum_{j=1}^{N_p} \sum_{t=m+1}^N (y_t^j - (z_{t-1}^j)^T \hat{\Phi}_k)^2 \quad (\text{A.21})$$

Eq. (A.8) に式 Eq. (A.15), Eq. (A.20), Eq. (A.21) を代入し整理すると, 次式の判別則が得られる.

$$\begin{aligned} k^* &= \arg \max_k \left\{ p(y_m, y_{m-1}, \dots, y_1) \left( \frac{1}{2\pi\hat{\rho}_k} \right)^{\frac{N-m}{2}} \exp \left( -\frac{1}{2\hat{\rho}_k} \sum_{t=m+1}^N (y_t - \hat{\Phi}_k^T z_{t-1})^2 \right) \Pr(\omega_k) \right\} \\ &= \arg \max_k \left[ \ln \left\{ \left( \frac{1}{2\pi\hat{\rho}_k} \right)^{\frac{N-m}{2}} \exp \left( -\frac{1}{2\hat{\rho}_k} \sum_{t=m+1}^N (y_t - \hat{\Phi}_k^T z_{t-1})^2 \right) \Pr(\omega_k) \right\} \right] \\ &= \arg \max_k \left\{ -\frac{N-m}{2} \ln(2\pi\hat{\rho}_k) - \frac{1}{2\hat{\rho}_k} \sum_{t=m+1}^N (y_t - \hat{\Phi}_k^T z_{t-1})^2 + \ln \Pr(\omega_k) \right\} \end{aligned} \quad (\text{A.22})$$

### A.1.3 AR スペクトル

自己回帰モデルによるスペクトル推定は、推定されたモデル係数から計算される。まず、自己回帰モデルの  $z$  変換は、予測誤差の  $z$  変換を  $V(z)$  として次式で得られる。

$$Y(z) = \left( \sum_k \phi_k z^{-k} \right) Y(z) + V(z) \quad (\text{A.23})$$

スペクトルは、モデル伝達関数のパワーから得られる。

$$\begin{aligned} H(z) &= \frac{1}{Y(z)} = \frac{V(z)}{1 - \sum_k \phi_k z^{-k}} \\ |H(z)|^2 &= \frac{|V(z)|^2}{|1 - \sum_k \phi_k z^{-k}|} \\ |H(e^{j\omega})| &= \frac{\rho^2}{|1 - \sum_k \phi_k e^{-j\omega k}|} \end{aligned} \quad (\text{A.24})$$

## A.2 自己組織化マップ

自己組織化マップ (Self-Organizing Maps: SOM) は、Kohonen が提案した教師なし学習によって入力データ群をそのデータ間の関係に保ったまま、任意の次元へと写像することができる、大脳皮質の視覚野をモデル化した人工ニューラルネットワーク (Artificial Neural Network: ANN) の一種である [83]。SOM は、複数の SOM を木構造にした木構造 SOM (Tree Structured SOM: TS-SOM) や、競合層を階層状に構成する階層的 SOM (Hierarchical Self-Organizing Map) などのモデルがあるが、本研究においては、入力層と出力層 (競合層) からなる 2 層構造の SOM について取り扱う。

入力ベクトル  $\mathbf{x}$  は  $k$  次元ベクトルで与えられ、出力層は、 $N \times M$  個のユニットが配置されており、各ユニットはそれぞれ  $k$  次元のベクトル (参照ベクトル) で構成される。SOM は、下記の手順で出力層の学習を行う (Fig. A.1)。

- Step 1: 入力ベクトル  $\mathbf{x} = [x_1, x_2, \dots, x_k]^T$  を提示する。
- Step 2: 各ユニットの参照ベクトル  $\mathbf{m}_i = [m_{i1}, m_{i2}, \dots, m_{ik}]^T$  と入力ベクトル  $\mathbf{x}$  との間でユークリッド距離を計算する。

$$d(\mathbf{x}, \mathbf{m}_i) = \|\mathbf{x} - \mathbf{m}_i\| = \sqrt{(x_1 - m_{i1})^2 + (x_2 - m_{i2})^2 + \dots + (x_k - m_{ik})^2} \quad (\text{A.25})$$

- Step 3: ユークリッド距離が最も短いユニットを勝者ユニット  $c$  とする。

$$c^* = \arg \min_i \{d(\mathbf{x}, \mathbf{m}_i)\} \quad (\text{A.26})$$

- Step 4: 勝者ユニット  $c$  と、その他の全ユニットを以下の更新式を用いて更新する。

$$\mathbf{m}_i(t+1) = \mathbf{m}_i(t) + h_{ci}(\mathbf{x}(t) - \mathbf{m}_i(t)) \quad (\text{A.27})$$

$$h_{ci} = \alpha(t) \exp \left\{ \frac{\|r_c - r_i\|^2}{2\sigma^2(t)} \right\} \quad (\text{A.28})$$

ここで,  $r_c, r_i$  は, 勝者ユニットの位置, 更新するユニットの位置であり,  $\sigma(t)$  は近傍半径,  $\alpha(t)$  は学習率係数を表わす.

- Step 5: マップが収束するまでステップ 1 から 4 を繰り返す.




Fig. A.1 自己組織化マップの構造

SOM の大きな特徴のひとつに近傍の概念があり, これには正方形型や六角形型などが提案されている (Fig. A.2). 学習では, 近傍に含まれるすべてのユニットを更新して学習を行うが, 近傍半径  $\sigma$  は学習回数が増加するにつれて単調減少させ, 学習が終了するまでに  $\sigma = 0$  へ収束させる. 学習係数  $\alpha$  ( $0 < \alpha < 1$ ) も同様に, 学習回数が増加するにつれて減少させる. 近傍半径と学習係数の更新式の代表的な例として, 次式のように線形的に単調減少させる方法がある.

$$\sigma(t) = \sigma(0) \left(1 - \frac{t}{T}\right), \quad \alpha(t) = \alpha(0) \left(1 - \frac{t}{T}\right) \quad (\text{A.29})$$

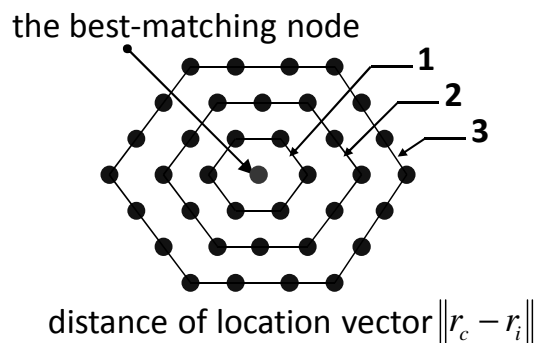


Fig. A.2 自己組織化マップにおける近傍 (六角形型の例)

### A.3 独立成分分析

独立成分分析 (Independent Component Analysis: ICA) とは, 観測される信号が, それぞれ統計的に独立な原信号の線形結合で表されると仮定し, 線形結合の係数で構成される混合行

列の逆行列を推定することで、原信号に相当する信号成分を推定するブラインドソースセパレーションの一手法である [76][77]. ここでは、ICA モデルと代表的な分離アルゴリズムである FastICA について説明した後、ICA 手法のスケール不定性問題の解決手法について紹介する [78][81].

### A.3.1 混合モデル

観測信号  $\mathbf{x} = [x_1, \dots, x_M]^T$  は、それぞれが独立な未知の原信号  $\mathbf{s} = [s_1, \dots, s_N]^T$  と混合行列  $A$  との線形結合で表される混合信号であると仮定する.

$$\mathbf{x} = A\mathbf{s} \quad (\text{A.30})$$

ICA は、分離信号  $\mathbf{u} = [u_1, \dots, u_N]^T$  が、それぞれ統計的に独立になるように分離行列  $W$  を推定する.

$$\mathbf{u} = W\mathbf{x} \quad (\text{A.31})$$

もし、 $WA = I$  となる分離行列が推定できれば、分離信号  $\mathbf{u}$  と原信号  $\mathbf{x}$  は完全に一致し、原信号が正確に推定できたことになる. ただし、 $\mathbf{u}$  の成分の順番を入れ替えても独立性は保たれ、各成分の大きさも独立性には影響しないことから、 $WA = PD$  ( $P$  は、各行に 1 つだけ 1 を持つ  $N \times N$  の置換行列、 $D$  は、 $N \times N$  の対角行列) となれば良いとする. これが、ICA における成分置換の問題と、スケール不定性問題の要因となる.

### A.3.2 FastICA アルゴリズム

ICA における代表的な分離アルゴリズムの一つに、FastICA がある. FastICA アルゴリズムは、分離信号間の非ガウス性の最大点を探索する不動点反復法を利用した推定手法である. 白色化された観測信号  $\tilde{\mathbf{x}}$  に対して、FastICA は、次式のように逐次計算を行い、分離行列を推定する.

$$\begin{aligned} \mathbf{w}_i^+ &= E[\tilde{\mathbf{x}}g(\mathbf{w}_i^T \tilde{\mathbf{x}})] - E[g'(\mathbf{w}_i^T \tilde{\mathbf{x}})] \mathbf{w}_i \\ \mathbf{w}_{i+1} &= \mathbf{w}_i^+ / \|\mathbf{w}_i^+\| \end{aligned} \quad (\text{A.32})$$

ここで、 $\mathbf{w}_i$  は、分離荷重で、 $W = [\mathbf{w}_1, \dots, \mathbf{w}_M]^T$  であり、 $g$  と  $g'$  は、非 2 次関数である.  $g$  の代表的なものとしては、 $g_1(y) = \tanh(a_1 y)$ 、 $g_2(y) = y \exp(-y^2/2)$ 、 $g_3(y) = y^3$  などがあるが、本研究では  $\tanh$  関数を利用するものとする. また、複数個の独立成分を推定するアルゴリズムとして、グラムシュミットの直交化法を利用した逐次直交化を用いている.

$$\mathbf{w}_p \leftarrow \mathbf{w}_p - \sum_{j=1}^p (\mathbf{w}_p^T \mathbf{w}_j) \mathbf{w}_j \quad (\text{A.33})$$

### A.3.3 不定性問題の解決

ここでは、分離行列の逆行列の情報を用いてスケール不定性問題を解決する手法について述べる。

1つの分離信号が有する原信号の成分  $\mathbf{v}_n = [v_{n1}, \dots, v_{nM}]^T$  を次式のように定義する。

$$\mathbf{v}_n = W^{-1}[0, \dots, 0, u_n, 0, \dots, 0]^T \quad (\text{A.34})$$

また、これらの和は観測信号と等しくなり、これは、 $\mathbf{v}_n$  のスケールが観測信号のスケールと等しいところまで戻されたことを意味する。

$$\mathbf{x} = \sum_{n=1}^N \mathbf{v}_n \quad (\text{A.35})$$

成分置換がなく、スケールの不定性が生じた場合について述べる。混合過程と分離過程は、次式のように表される。

$$\mathbf{x} = \mathbf{A}\mathbf{s}$$

$$\mathbf{u} = \mathbf{W}\mathbf{x} = \mathbf{W}\mathbf{A}\mathbf{s}$$

上式において  $\mathbf{W}\mathbf{A} = \mathbf{I}$  であれば  $\mathbf{u} = \mathbf{s}$  となり原信号を完全に推定したと言えるが、実際は  $\mathbf{W}\mathbf{A} = \mathbf{D}$  となる。  $\mathbf{D} = \text{diag}[d_1, \dots, d_N]$  であり、これは分離信号  $\mathbf{u}$  のスケールに影響をもたらす対角行列である。このとき、分離信号  $\mathbf{u}$  は、次式のように表される。

$$\mathbf{u} = \mathbf{W}\mathbf{x} = \mathbf{D}\mathbf{s} = [d_1 s_1, d_2 s_2, \dots, d_N s_N]^T \quad (\text{A.36})$$

つまり、分離信号  $u_n$  は、それぞれ原信号を  $d_n$  倍したものとなり、 $u_n$  における  $\mathbf{v}_n$  は、次式のよ

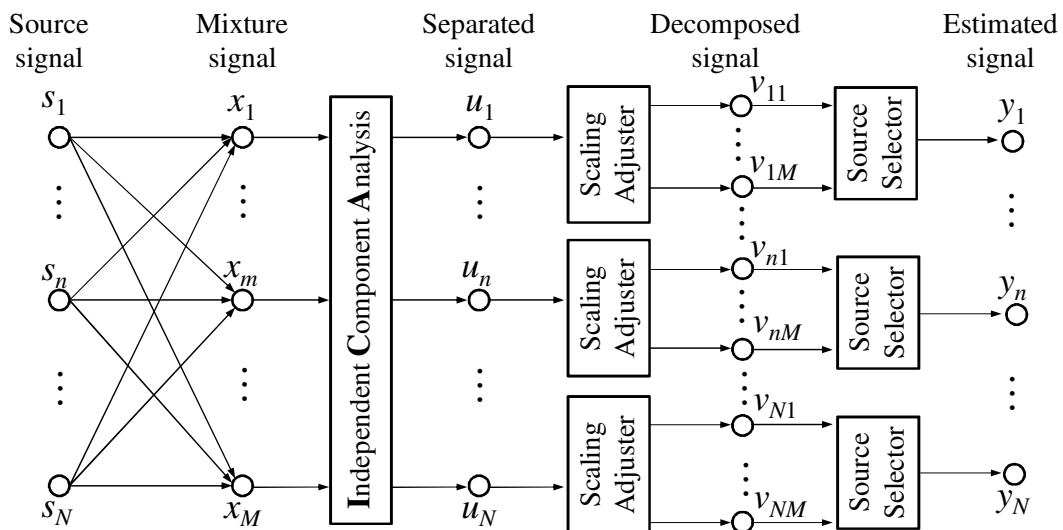


Fig. A.3 ICA モデル

うに原信号と伝達関数の積として表される.

$$\begin{aligned}
 \mathbf{v}_n &= W^{-1} [0, \dots, 0, u_n, 0, \dots, 0]^T \\
 &= AD^{-1} [0, \dots, 0, u_n, 0, \dots, 0]^T \\
 &= \frac{1}{d_n} [a_{1n}u_n, a_{2n}u_n, \dots, a_{Nn}u_n]^T \\
 &= [a_{1n}s_n, a_{2n}s_n, \dots, a_{Nn}s_n]^T
 \end{aligned}$$

次に, 成分置換とスケールの不定性の両方がある場合 ( $WA = PD$ ) について, 簡単のため 2 次元の場合を例にとって述べる. この場合, 分離信号  $\mathbf{u}$  は,  $\mathbf{u} = W\mathbf{x} = WAs = PDs$  により, 最終的に次式のように表される.

$$\mathbf{u} = \begin{bmatrix} u_1 \\ u_2 \end{bmatrix} = \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix} \begin{bmatrix} d_1 & 0 \\ 0 & d_2 \end{bmatrix} \begin{bmatrix} s_1 \\ s_2 \end{bmatrix} = \begin{bmatrix} d_2 s_2 \\ d_1 s_1 \end{bmatrix} \quad (\text{A.37})$$

つまり, 分離信号  $u_1$  と  $u_2$  は, 対応する原信号が  $s_2$  と  $s_1$  に入れ替わって, それぞれ  $d_2$  倍と  $d_1$  倍されたものとなる. このときの分割信号  $\mathbf{v}_1, \mathbf{v}_2$  は,

$$\mathbf{v}_1 = \begin{bmatrix} v_{11} \\ v_{12} \end{bmatrix} = W^{-1} \begin{bmatrix} u_1 \\ 0 \end{bmatrix} = AD^{-1}P \begin{bmatrix} u_1 \\ 0 \end{bmatrix} = \frac{1}{d_2} \begin{bmatrix} a_{12}u_1 \\ a_{22}u_1 \end{bmatrix} = \begin{bmatrix} a_{12}s_2 \\ a_{22}s_2 \end{bmatrix} \quad (\text{A.38})$$

$$\mathbf{v}_2 = \begin{bmatrix} v_{21} \\ v_{22} \end{bmatrix} = W^{-1} \begin{bmatrix} 0 \\ u_2 \end{bmatrix} = AD^{-1}P \begin{bmatrix} 0 \\ u_2 \end{bmatrix} = \frac{1}{d_1} \begin{bmatrix} a_{11}u_2 \\ a_{21}u_2 \end{bmatrix} = \begin{bmatrix} a_{11}s_1 \\ a_{21}s_1 \end{bmatrix} \quad (\text{A.39})$$

このように, 分割信号  $v_{nm}$  は原信号  $s_n$  と, 伝達関数  $a_{mn}$  の積で表現でき, その組み合わせは排他的一意に決定される.

ICA を用いて信号分離を行う場合, 原信号数は完全に未知であるため, 一般に原信号数は観測信号数と等しいと仮定して解くことが多い. このとき, 分割信号  $\mathbf{v}_n$  は原信号  $s_n$  と伝達関数  $a_{mn}$  の積として与えられ,  $n$  番目の原信号  $s_n$  が  $n$  番目のセンサで観測されたときの値である. 原信号数と観測信号数が異なる場合の影響については, 石橋らによって確認がなされている [80].

また, 最終的な推定信号  $y_n$  は, 各分割信号が原信号から同等の影響を受けるものと仮定して, 次式のように各成分の平均値として表す [78][81].

$$u_n(t) = \frac{1}{M} \sum_{m=1}^M v_{nm}(t) \quad (\text{A.40})$$