

α 波構成要素の切出しと解析

石川 由羽^{1,a)} 高田 雅美¹ 城 和貴¹

受付日 2012年11月8日, 再受付日 2012年12月28日,
採録日 2013年1月29日

概要: α 波は1929年にBergerによって発見された脳波であり, 現在, 多くの研究者によって研究されている. 近年では, 主に α 波の振幅や位相に注目が集まっており, 様々な研究結果が報告されている. しかし, 今現在, α 波がどのように構成されているかを示す具体的なモデル化は行われていない. 本論文では α 波のモデル化を目指して, α 波の位相分析を行う. 前処理として, 脳波から α 波データを抽出し, そのデータを α 波構成波に分割する. α 波構成波の特徴から, 振幅と波形幅は時間遅延の相関があることが認められる.

キーワード: α 波, 信号処理, ICA, フーリエ記述子, クラスタリング, 位相分析

Extraction of Alpha Wave Constituent Waves and Its Phase Analysis

YU ISHIKAWA^{1,a)} MASAMI TAKATA¹ KAZUKI JOE¹

Received: November 8, 2012, Revised: December 28, 2012,
Accepted: January 29, 2013

Abstract: Alpha waves are electroencephalogram discovered by Hans Berger in 1929 and have been studied by many researchers. Recently the amplitude and the phase of alpha waves attract attention, and various studies are reported. So far the alpha waves are not concretely modeled to explain how they are constituted. In this paper, we analyze the phase of alpha waves for their future modeling. As pre-processing, we extract alpha wave data from EEGs and divide the data into alpha wave constituent waves. Analyzing the feature quantity of the alpha wave constituent waves, it turns out that the amplitude and the wavelength of alpha wave constituent waves are correlated possibly with some time delay.

Keywords: alpha waves, signal processing, ICA, Fourier descriptor, clustering, phase analysis

1. はじめに

近年, 脳波から思考状態を推定し, その推定をもとに機械を動かすBMI (Brain-Machine Interface) [1] と呼ばれる技術への関心が高まっている. BMI技術は, 手足が不自由な人の義肢や失明した人の義眼としてだけでなく, 健常者向けの玩具などにも利用されている. 脳波には α 波, β 波などの特定の事象生起に関係なくつねに発生している自発脳波と, 光や音などの外部刺激により出現する誘発脳波がある. その中でも, 記憶, 予測, 注意などの高次の処理過程により出現するものは事象関連電位と呼ばれる. 有

名なものでは1965年に発見された電位P300があり[2], 手がかり刺激が提示されてから300ms後に頭頂部に観察される脳波である. BMIには, 主にこのような事象関連電位が適用されている[3]. 今後BMIの可能性を広げるためには, 誘発脳波, 特に事象関連電位から精度の良い情報を得る必要がある. そこで, 自発脳波をモデル化することで, 脳波からの自発脳波の分離が可能となり, 事象関連電位の推定精度も向上すると考えられる. 我々は, 自発脳波の中で最も研究が進められている α 波に焦点を当ててモデル化を目指している.

α 波は1929年にBergerによって発見された脳波であり[4], 現在, 多くの研究者によって研究されている. Bergerは安静時に8–13Hzの安定した波形が出現すること, 開眼時には波形が消失することを指摘している. 1934年に

¹ 奈良女子大学
Nara Women's University, Nara 630-8263, Japan
^{a)} ishikawa-yu0804@ics.nara-wu.ac.jp

Adrian らは、 α 波が頭頂部、後頭部に優勢に出現し、特に後頭部において出現頻度、振幅ともに大きいこと、頭頂・後頭部付近で位相が逆転することから、 α 波の発生源が後頭葉にあるものと推定している [5]。しかし、 α 波がこの部位に優勢に出現する理由はまだはっきりと解明されておらず、1972 年には、鈴木が α 波の波形や刺激に対する反応性などから検討し、前頭部の α 帯域波は後頭部 α 波の単なる伝導性媒質内の物理的伝導によるのではなく、生理学的な伝達と相互作用によって発生するものと報告している [6]。1936 年に Davis らは、個人差の大きい α 波出現率の差を定量的に表現するため、 α 波百分率 (percent time alpha) を提唱している [7]。これは、正常成人の脳波を 4 型に分類し、被験者の性格との関係性を表現するものである。また、 α 波の振幅はつねに一定ではなく、多くの場合 1 秒ないし数秒の周期で漸増漸減を繰り返す。この現象は waxing and waning と呼ばれる。詳細は文献 [8] を参照されたい。 α 波のモデル化に関する研究もすでに行われており、現在では、neural mass model を用いた研究が注目されている [9]。このモデルは、脳波の発生メカニズムをもとにモデル化を行っており、自発脳波や事象関連電位などの様々な脳波現象を再現することができる。このように、 α 波に関する研究は数多く行われている。

本論文では、実測データから直接 α 波をモデル化することを目指して、 α 波の位相分析を行う。複数の信号処理を組み合わせることで α 波の詳細な解析を行う。まず、脳波から α 波データのみを抽出し、 α 波データを α 波の構成要素に分割する。次に、 α 波構成要素の特徴を抽出して、相互相関係数を用いた位相分析を行う。

以下、2 章では α 波の関連研究について紹介し、3 章で α 波構成要素の抽出手法、4 章では α 波構成要素の解析手法の提案を行う。最後に、5 章では 3、4 章で述べた提案手法の実験を行う。

2. 関連研究

α 波の発生源や発生メカニズムはいまだに明らかになっておらず、多方面から研究が進められている。 α 波の発生メカニズムを探る方法の 1 つに、外部からの刺激に対する α 波の応答を調べる方法がある。聴覚と脳波に関する研究は比較的古くから行われており、これまでに、音楽鑑賞にともなう脳波の変化は数多く報告されている [10]。ここでは音刺激時の α 波の変化を比較している研究を紹介する [11]。この論文では、音刺激を与えたときの快・不快の感情の変化と α 波の変化を、K.L 展開を用いて客観的かつ定量的に評価する方法を提案している。音刺激の種類にかかわらず各被験者の脳波パターンが安定していることから、個人の脳波パターンを K.L 展開を用いた座標系で表現できることを見い出している。さらに、快・不快による精神状態の違いも、定量的な数値の変化としてとらえられる

可能性を示唆している。聴覚だけでなく、視覚と α 波の関係性についても古くから研究がなされている [12]。脳波が外部からの周期的な光刺激によって引き込み現象 [13] を起こすことはよく知られている。周期的な閃光刺激の色の交替が脳波に与える影響に関する研究によると [14]、 α 波は刺激の色の組合せにかかわらず、刺激周波数にその周波数がシフトする引き込み現象を示すことが分かっている。特に、赤青の 2 色交互閃光刺激では後頭部と前頭部の振幅が他の部分よりも大きく、頭部前後の位相の反転が互いに小さくなる同相同期現象を示したことから、赤青刺激が α 波に特異的な影響を及ぼす可能性を示唆している。このように、聴覚、視覚などの感覚刺激によって変化する α 波から、発生メカニズムの解明が期待されている。

また、別の方面から α 波の発生源の解明に取り組んでいる研究報告もある [15]。この研究では、 α 波の信号源を等価電流ダイポールと仮定し、脳波を近似できるか検討している。16 電極で計測した α 波に対して、ニューラルネットワークを用いた等価電流ダイポール推定を行うことで、信号源の推定を行う。その結果、後頭葉の視覚野と辺縁葉、帯状回付近といった主に α 波が出現するといわれている場所に多く推定された。しかし、脳梁内などの信号源位置として不適当と思われる場所にも推定されており、誤差の検討が必要であると考えられる。

次に、 α 波形状の変化におけるメカニズム解明のために、 α 波モデルのパラメータ推定を行う方法を紹介する。近年、 α 波の位相と振幅に注目が集まっており、これらの推定には主にヒルベルト変換やウェーブレット変換が用いられている [16], [17]。しかし、これらの手法では単一試行での推定精度が悪く試行間平均をとる必要があるが、この場合、試行間で同期した活動しか抽出できない。そこで、推定精度を向上させることで単一試行のみで推定できるようにする。より精度の良い推定方法として、マルコフ確率場モデルを用いて α 波の位相および振幅の推定を行っている研究がある [18]。 α 波をマルコフ確率場モデルにより記述し、これを確率伝播法を用いて位相と振幅を推定し、周辺尤度を計算する手法を構築している。論文内では、脳波を模した人工データを使って推定精度を検証した結果、ヒルベルト変換よりも高い精度で推定できた。脳波の実データに適応することで、より精度の良い推定が可能になると考えられる。

このように α 波の研究は日本でも多く行われているが、 α 波のメカニズム解明につながる決定的な結論は出ていない。そのため、さらなる研究が必要である。

α 波が注目される以前から、脳波に関する研究は数多く行われている。脳波の解析には様々な手法が適用されており、ノイズが多く含まれている脳波から眼球運動などのアーチファクトを取り除くためには、主に独立成分分析 (Independent Component Analysis, ICA) が使われ

る [19]. しかし, ICA はアーチファクトだけでなく, 脳波成分を抽出することも報告されている. ICA を用いて P300 を抽出している研究では, P300 を含む脳波を ICA により複数の独立成分に分解し, その成分を時空間領域において解析することで, P300 に関係のある要素を容易に抽出できるとしている [20]. また, P300 だけでなく視覚誘発電位や睡眠脳波の抽出も可能であるとの研究報告もある [21], [22]. 本論文でも脳波から α 波データの抽出を行うために ICA を使用する.

3. α 波構成要素の切出し手法の提案

3.1 概要

本論文では, 実測データからの α 波モデル化を目指して解析を行うが, 被験者から得られた長時間の α 波データを直接モデル化することは非常に困難である. そのため, α 波データを基本構成要素に分割することで解析を行う.

本章では, 脳波から α 波含有時系列データを検出し, α 波データを抽出して, α 波構成波に切り出す方法を提案する. まず, α 波含有時系列データの検出を行うために, 脳波の計測を行う. 十分な時間計測された脳波から α 波が出現している時間帯のデータを検出するために, 時間周波数解析を行う. α 波成分が多く含まれている時間帯のデータを切り出すことで, α 波含有時系列データを生成する. α 波データの検出では, 様々なノイズが混合している α 波含有時系列データから純粋な α 波データのみを抽出する. まず, 大まかなノイズ除去を行うために, ケプストラム [23] を用いて補正を行う. ノイズ除去されたデータに ICA をかけることで複数の独立した波形を分離する. 分離された波形のパワースペクトルを求め, α 波データが分離されていることを確認する. 以上の処理から, ノイズを多く含む脳波から純粋な α 波データを抽出する. 抽出された α 波データを, α 波を構成している小波形に分割する. まず, α 波データをメディアンフィルタにかけることで, 分割を容易にする. 次に, メディアンフィルタ後の波形を最小単位の波形に分割する. この波形を α 波構成波と呼ぶ. 分割方法の最適解は木構造を走査するアルゴリズムを利用して得る.

3.2 α 波含有時系列データの検出

α 波の出現条件は閉眼, 安静, 覚醒時であるため, リラックスした状態での計測が必要となる. このような状態で計測したデータをオリジナルデータとして使用する. 本論文では脳波計測に 4 つの電極 (ch1-4) を持つ Enobio [24] を使用する. Enobio の電極は額に横 1 列に配置される. これは前頭葉にあたり, α 波が多く分布されている部分の 1 つである. また, Enobio のサンプリング周波数は 250 S/s (Samples/second) である. 本論文の α 波構成要素の切出しと位相分析の説明のために使用するデータは, 50 代男性




図 1 オリジナルデータ

Fig. 1 Original data.




図 2 STFT の結果

Fig. 2 STFT results.

の閉眼・安静・覚醒時の脳波を計測したもので, 計測時間は 10 分間である. 計測後のデータを図 1 に示す. フーリエ変換に高速フーリエ変換 (Fast Fourier Transform, FFT) を使用するため, データ数は 2 のべき乗でなければならない. そこで, 10 分間のデータから初めの 131,072 点 ($= 2^{17}$), つまり約 524 秒のデータに処理を行う.

リラックス状態で計測したデータには必ずしも α 波が含まれているわけではないため, 長時間計測したオリジナルデータから, α 波含有時系列のみを特定して使用する必要がある. α 波含有時系列の検出には時間周波数解析を用いる. オリジナルデータに時間周波数解析を適用することで, パワースペクトルの時間的変化を得ることができる. この処理により, オリジナルデータの各時間におけるパワースペクトルを求め, データ全体から α 波の出現している時間帯を検出する. 時間周波数解析には, 主に, 短時間フーリエ変換 (Short-Time Fourier Transform, STFT) を使う. STFT は, 一定の大きさの窓関数を用いて信号を切り出し, その結果をフーリエ変換してスペクトルを計算する. 窓関数を順次ずらしていくことでスペクトルの時間変化が得られる. STFT は周波数の異なるものに対して同じ大きさの窓でしか見ることができないため, 低い周波数の場合周波数解像度が悪くなるという欠点がある. オリジナルデータに STFT を適用した結果を図 2 に示す. 窓関数には hanning 窓を用いる. 左上から順に ch1, ch2, ch3, ch4 となっている. 縦軸は周波数であり, 脳波の主成分が含まれている 1-40 Hz のみを表示している. 横軸は時間を


図 3 α 波含有時系列データとパワースペクトル

Fig. 3 Alpha wave containing time-series data and power spectrum.

表す. ch1 に 1 回, その他のチャンネルに 3 回見られる縦軸の線はパルスノイズである. また, 3 Hz 以下の周波数が多く見られるが 0.5–3 Hz には眼球運動が多く含まれているため [25], 本論文ではノイズと見なす. このグラフから, すべてのチャンネルで 10 Hz 付近にはっきりと α 波が確認できる.

次に, 全チャンネルで α 波帯域のスペクトル量が多い部分を, α 波含有時系列として切り出す. これにより, α 波の含まれているオリジナルデータが完成する. オリジナルデータの 90 秒から 120 秒の区間には位相分析に十分な α 波が含有されているとして, 90 秒から 8,192 点, つまり約 33 秒のデータを切り出して解析を行う. 図 3 の左図は切り出したデータ, つまり α 波含有時系列データである. オリジナルデータの各チャンネルにおける α 波量を計測するため, FFT を用いてパワースペクトルを求める. このデータのパワースペクトルを求めたグラフが図 3 の右図である. ここでは 1–40 Hz を表示している. 背景色が灰色の部分は α 波周波数帯域である 8–13 Hz を表している. このグラフから, すべてのチャンネルで α 波を含有していることが分かる. 以後, α 波含有時系列データのみ処理を行う.

3.3 α 波データの抽出

脳波計から得られたオリジナルデータには, 脳波に関係のない脳波計本体によるノイズが多く含まれている. 図 1 ではグラフ全体が右下がりになっていることが分かる. 今回切り出した α 波含有時系列データも例外ではなく, 多くのノイズが含まれていると考えられる. そのため, 前処理としてノイズ除去を行う必要がある. ノイズ除去にはケプストラムを利用する. ケプストラム分析は主に音声に適用される信号処理であり, 低次の要素からフォルマント情報, 高次の要素からピッチ情報が得られる. まず, データに逆フーリエ変換をかけ, 高次の要素を 0 にする. 次に, フーリエ変換をかけもとに戻すことでデータのスペクトル包絡を求めることができる. 本論文では, この手法を用いて α 波含有時系列データの包絡を求める. 得られた包絡は脳波計によるノイズであるため, 包絡の形状を 0 として α 波含有時系列データの補正を行う. 図 4 の左図に α 波含有時系列データの包絡, 右図に補正後のデータを示す. 左図




図 4 包絡と補正後のデータ

Fig. 4 Envelope and the resultant data.




図 5 ICA 後のデータとパワースペクトル

Fig. 5 ICA results and power spectrum.

で見られた緩やかな波形が除去されているため, 脳波計本体のノイズは取り除かれたと考えられる.

補正後のデータに ICA を適用する. ICA とは, 多変量の信号を複数の加法的な成分に分離するための分析手法である. この処理により, 脳波計から得られた 4 チャンネルのデータを 4 つの独立成分に分離することができる. 本論文では, ICA のアルゴリズムとして CuBICA3 [26] を採用する. CuBICA3 は, 観測信号からなる行列に, 3 次キュムラントの対角成分の和を最大にする回転角度を用いた回転行列を掛け合わせることで, 独立化した行列を得る手法である. これにより, 補正後の α 波含有時系列データから α 波の分離とノイズ除去が行われる. ICA 後の 4 つの独立成分 (I1–I4) が図 5 の左図である.

分離後の 4 つの波形から α 波が分離された波形を特定するために, 各波形のパワースペクトルを求める. パワースペクトルの算出には FFT を使用する. ICA 後のデータのパワースペクトルの結果を図 5 の右図に示す. 各波形の周波数成分を求め, α 波の周波数帯域である 8–13 Hz のパワースペクトルが最も多い波形を α 波データとする. 図 3 の右図と比べて, 4 つ目のデータに明らかな α 波量の集中が確認できる. これより, 4 つ目のデータに α 波データが分離された可能性が高いと考えられる.

3.4 α 波構成要素の切出し

α 波データは漸増漸減を繰り返すことから, 一定の長さを持った波形が繰り返されていると考えられる. そこで, α 波データの自己相関係数を求めて解析を行ったところ, 中央付近の値を除いたすべての値で相関が現れなかった. これは, α 波の波形幅が 8–13 Hz 内で変動するため, 振幅にずれが生じて重なりにくいことが原因だと思われる. α 波




図 6 アルゴリズムの概念図

Fig. 6 Algorithmic conception diagram.

は 8–13 Hz の周期を持つ波形であるため、これをもとに 1 波形ごとに分割する。本論文では、この波形を α 波構成波としている。 α 波データを α 波構成波ごとに分割することで、波形単位での解析が可能となる。

α 波データから直接 α 波構成要素ごとに波形切出しを行うのは困難である。そこで、メディアンフィルタを用いて α 波データの平滑化を行い、波形切出しを容易にする。

α 波構成波の切り出し方法について簡単に説明する。アルゴリズムの概念図を図 6 に示す。まず、Step1 では平滑化後の α 波データを下側の頂点ごとに分割し、頂点間の点の数を波形幅とする。次に、Step2 では、 α 波データから複数の大きな波形幅を検出する。Step2 で検出した波形幅を基準とし、Step3 では α 波データを複数の小区間ごとに分割する。Step1 で分割した波形の中には 8–13 Hz にあてはまらない小さな波形が多数含まれているため、これらの波形を組み合わせることで、8–13 Hz の波形幅を持つ波形を再構成する。Step4 では、小区間ごとの波形の最適な組合せを 2 分木を用いて探索し、決定する。最後に Step5 ですべての小区間を結合させることで、 α 波構成波は完成する。Step4 での最適な組合せとは、 α 波周波数成分の中央値の波形幅と各値の波形幅の差の合計が最小のものを指す。

次に、Step4 の木構造を用いた最適解の決定方法について説明する。例として、ある小区間内の Step3 時点での波形幅が 22, 10, 15, 25, 7, 7, 26 である場合を考える。また、波形幅はそれぞれの深さに対応している。全体図を図 7 に示す。まず初めに、1 つ目の波形幅を 2 分木のルートとする。次に、左の子には親の値に各深さの波形幅を足したものの、右の子には各深さの波形幅そのものを格納する。この処理を最後の波形幅まで繰り返す。ただし、左の子の値が α 波の低周波数 8 Hz の波形幅を超える場合、その枝は値を格納せずに終了とする。本論文では脳波計のサンプリング周波数が 250 Hz なので、すべての左の子は 31 点以下となる。図 7 は完成した 2 分木である。次に、経路の探索方法



図 7 2 分木の探索方法

Fig. 7 The binary tree search method.

を説明する。経路は最後の波形幅までたどり着いたもののみを使用する。経路の探索方法は、まず、1 つ目の波形幅から始め、右分岐時の波形幅のみ使用し、最後の波形幅まで探索する。つまり経路 1 では、22 → 25 → 25 → 14 → 26 の順番となる。次に α 波周波数成分の中央値の波形幅と各値の波形幅との差の合計を求める。 α 波周波数成分の中央値は今回のデータでは 11 Hz であるため、波形幅は 23 点となる。経路 1 から経路 4 までの差の合計はそれぞれ 17, 40, 36, 59 となる。差の合計が最小の経路が最適な組合せとなるので、22, 10, 15, 25, 7, 7, 26 の波形幅では、経路 1 の 22 → 25 → 25 → 14 → 26 が最適な組合せとなる。このようにして、最適な α 波構成波を生成することができる。

以下で詳細なアルゴリズムについて説明する。図 6 の各 Step のカッコ内の番号は以下のアルゴリズムの番号と一致する。

入力： α 波データ $S = \{s_0, s_1, \dots, s_N\}$ (N はデータ数)
出力： α 波構成波 $R = \{r_0, r_1, \dots, r_Z\}$ (Z は α 波構成波数)

アルゴリズム：

- 1 波形幅リスト $C = \text{NULL}$, 小区間リスト $A = \text{NULL}$, A 内の α 波構成波リスト $W = \text{NULL}$ を用意する。 α 波周波数成分の低周波数の波形幅を AD , α 波周波数成分の中央値の波形幅を AC とする。 α 波構成波を生成する 2 分木として、波形幅を格納する key , key と AC との差を表す $diff$, 左の子へのポインタ $*left$, 右の子へのポインタ $*right$ を持つ $node$ 型のデータ構造を用意する。
- 2 $j1 = 0$ とし, $j1$ を 1 から $N - 1$ まで 1 ずつ増やしながら, 3 を繰り返した後 4 に進む。
- 3 $s_{i1-1} > s_{i1}$ と $s_{i1} < s_{i1+1}$ を満たす s_{i1} を探索し, $b_{j1} = i1$ とし, $j1$ を 1 ずつ増やす。
- 4 $M = j1 - 1$ とし, $i2$ を 0 から $M - 1$ まで 1 ずつ増やしながら, 5 を繰り返した後 6 に進む。

```

5   $c_{j2} = b_{j2+1} - b_{j2}$ 
    $C = C + (c_{j2})$ 
6   $C$  の最大幅を  $c_{\max}$  として,  $V = (c_{\max} - h)$  を得る.  $h$ 
   は任意の定数.
7   $R = \text{NULL}$ 
    $i3 = 0$ 
8   $j3 = i3$ ,  $k = 0$  として  $j3$  と  $k$  を同時に 1 ずつ増やしな
   がら,  $c_{j3} \geq V$  または  $j3 < M$  の間, 9 を繰り返した後
   10 に進む.
9   $a_k = c_{j3}$ 
    $A = A + (a_k)$ 
10  $\text{Num} = k$ 
11 node 型の root を作成する.
12  $\text{root} = \text{tree}(0, 0, \text{Num})$  を実行する.
13  $\text{pre\_order}(0, \text{root}, \text{Num}, W)$  を実行する.
14  $R = R + W$ 
    $i3 = j3$ 
    $A = \text{NUL}$ 
15  $j3 < M$  の間, 8 へ戻る.

```

再帰関数: $\text{tree}(t, \text{val}, \text{Num})$

```

1   $t = \text{Num}$  のとき,  $\text{NULL}$  を返す.
2   $\text{val} \neq 0$  かつ  $(a_t + \text{val}) > \text{AD}$  のとき,  $\text{NULL}$  を返す.
3  node 型の  $\text{netree}$  を作成する.
4   $\text{newtree} \rightarrow \text{key} = a_t + \text{val}$ 
    $\text{newtree} \rightarrow \text{diff} = |\text{AC} - \text{newtree} \rightarrow \text{key}|$ 
5   $\text{newtree} \rightarrow \text{left} = \text{tree}(t + 1, \text{newtree} \rightarrow \text{key})$ 
    $\text{newtree} \rightarrow \text{right} = \text{tree}(t + 1, 0)$ 
6   $\text{newtree}$  を返す.

```

再帰関数: $\text{pre_order}(t, \text{newtree}, \text{Num}, W)$

```

1   $\text{newtree} = \text{NULL}$  のとき, 終了する.
2   $d_t = \text{newtree} \rightarrow \text{key}$ 
    $e_t = -1$ 
3   $\text{pre\_order}(t + 1, \text{newtree} \rightarrow \text{left})$ 
4   $e_t = \text{newtree} \rightarrow \text{diff}$ 
5   $\text{pre\_order}(t + 1, \text{newtree} \rightarrow \text{right})$ 
6   $\text{newtree} \rightarrow \text{left} \neq \text{NULL}$  または  $\text{newtree} \rightarrow \text{right} \neq$ 
    $\text{NULL}$  のとき, 11 に進む.
7   $\text{Sum} = 0$  とし,  $x1$  を 0 から  $\text{Num} - 1$  まで 1 ずつ増や
   しながら,  $\text{Sum}$  に  $e_{x1}$  を加える.
8   $x1 > 0$  かつ  $\min < \text{Sum}$  のとき, 11 へ進む. そうでな
   いなら,  $\min = \text{Sum}$  とする.
9   $W = \text{NULL}$ ,  $x2 = 0$  とし,  $y1$  を 1 から  $\text{Num} - 1$  まで
   1 ずつ増やしながら, 10 を繰り返す.
10  $e_{y1} \neq -1$  のとき,  $w_{x2} = d_{y1}$ ,  $W = W + (w_{x2})$  とし
   て,  $x2$  を 1 ずつ増やす.
11 終了する.

```

h は α 波構成波を生成しやすいように, α 波データを複数の小区間に分割するための値である. ここでは $h = 5$ とする.

α 波データに本アルゴリズムを適用した結果, 8,192 点の α 波データは, 363 個の α 波構成波に分割された. また, このときの各 α 波構成波の振幅の平均は 2.7, 分散は 1.4, 波形幅の平均は 22.5, 分散は 11.3 である.

4. α 波構成要素の解析手法の提案

4.1 概要

本章では, 3 章で得られた α 波構成波を用いて α 波構成波特徴の位相分析を行う. まず, α 波構成波を k-means 法を用いてクラスタリングし, クラスタリング結果から α 波構成波の特徴を検討する. 次に, 相互相関係数から α 波構成波の特徴の時間的相関を算出することで, α 波構成要素の位相分析を行う.

4.2 α 波構成波特徴の抽出

3 章で得られた α 波構成波のクラスタリングを行う. クラスタリング手法の 1 つである k-means 法は, クラスタの中心と各データとの距離が最小になるようなクラスタ中心を逐次的に求めることで, クラスタリングを行う手法である. しかし, k-means 法には, クラスタリング結果がランダムに選択される初期のクラスタ中心に依存してしまうという問題がある. そこで, 近年最も注目されている k-means 法の初期値設定手法である k-means++ [27] を適用する. k-means++ は, 1 つ目の中心をランダムに選択し, 2 つ目以降の中心は, それまでに選択済みの中心と各個体の最小距離に基づく確率分布によって選択する手法である. 本論文では, クラスタリングの特徴量として最大エントロピー法 (Maximum Entropy Method, MEM) によるパワースペクトルを用いる. MEM はデータ数に関係なく周波数解像度を任意に設定できるため, 波形幅の異なる α 波構成波に適応しても同じ周波数解像度が得られる. 通常, k-means 法では, ユークリッド距離 $\sum (x_i - y_i)^2$ を用いてクラスタリングを行う. 本論文では, 付近の周波数を考慮するため, ユークリッド距離に重みづけを行う新たな距離を定義する. 式は以下のとおりである.

$$\sum \left(\sum_{l=-k}^k (x_i - f(l) * y_{i+l}) \right)$$

重みづけにはガウス関数 $f(l) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp(-\frac{l^2}{2\sigma^2})$ を使用する. これを用いてクラスタ数 5 でクラスタリングを行った結果を図 8 と図 9 に示す. このとき $k = 10$, $\sigma^2 = 0.18$ とする. 図 8 はクラスごとのオリジナルデータを並べてプロットしたものの一例である. 各クラスの振幅の平均と分散を表 1 に示す. Class1 には振幅の大きい波形が集まっており, Class3 には振幅の小さい波形が集まっている. こ




図 8 クラスタリング結果 (オリジナルデータ)

Fig. 8 Clustering result (original data).



図 9 クラスタリング結果 (パワースペクトル)

Fig. 9 Clustering result (power spectrum).

表 1 各クラスの振幅の平均と分散

Table 1 Average and dispersion of the amplitude of each class.

	振幅の平均	振幅の分散
Class1	4.891	1.134
Class2	2.757	0.532
Class3	1.538	0.110
Class4	3.303	0.262
Class5	2.213	0.204

これらの結果から、クラスごとに特徴あるといえる。したがって、オリジナルデータの振幅をもとにクラスタリングが行われていることが分かる。また、図 9 はクラスごとの 1–125 Hz のパワースペクトルを表示したものである。この結果から振幅だけでなく、クラスタリングには波形幅も考慮されていることが分かる。

以上のクラスタリング結果から、各 α 波構成波の主要な特徴として、振幅と波形幅があげられる。振幅は α 波構成波の最大値と最小値との差であり、波形幅は α 波構成波を構成する点の数にあたる。3.2 節で生成された 363 個の α 波構成波の振幅の時系列データと波形幅の時系列データを図 10 に示す。上の波形が振幅、下の波形が波形幅である。

振幅と波形幅の時系列データから位相分析を行うために、まず、それぞれの包絡を求める。包絡の算出にはフーリエ記述子を用いる。フーリエ記述子とは、曲線の様々な特徴量をフーリエ変換したものである。主に、形状認識の特徴量として用いられるが、曲線の包絡を算出する際にも使用




図 10 40 次の包絡と元データ

Fig. 10 Envelope by the fortieth order Fourier descriptor.

できる。最も一般的な手法は G 型フーリエ記述子 [28] である。G 型フーリエ記述子は、曲線を表す複素平面上の点列をそのままフーリエ変換したものであり、閉曲線に対しては優れた情報集約能力を発揮する。しかし、今回のような開曲線に適用した場合は情報集約能力が不十分である。そこで、本論文では開曲線において高い情報集約能力を持つ R 型フーリエ記述子 [29] を時系列データに適用する。R 型フーリエ記述子は、もとの開曲線にある回転子を乗じることで閉曲線を生成し、それをフーリエ変換したものである。この方法では、データ数を変化させずに開曲線から閉曲線に変換するので、計算量とデータ容量をあまり増加させることなく優れた情報集約能力を発揮する。また、R 型フーリエ記述子を逆フーリエ変換し、回転をもとに戻すことにより、開曲線が完全に再構成される。もとの閉曲線が十分に滑らかであれば、たとえば 1 次までのフーリエ記述子を逆フーリエ変換して再生される 1 次の閉曲線は、もとの閉曲線に近い値をとり、回転をもとに戻すことで、もとの開曲線に近い 1 次の開曲線が再構成できる。図 10 は 40 次の包絡ともとの時系列データである。それぞれ上の波形が振幅であり、下の波形は波形幅である

4.3 α 波構成波特徴の位相分析

α 波構成波の位相分析のために、振幅と波形幅の相互相関解析を行う。相互相関解析とは 2 つの時系列信号の類似度を評価する手法であり、相互相関係数 [30] を用いて表される。時系列データ $X = \{x_0, x_1, \dots, x_T\}$, $Y = \{y_0, y_1, \dots, y_T\}$ (T はデータ数) の時間遅延 k の相互相関係数 r_{xy} は以下のように定義される。

$$r_{xy}(k) = \frac{\sum_{t=k+1}^T (x_t - \bar{x})(y_{t-k} - \bar{y})}{\sqrt{\sum_{t=k+1}^T (x_t - \bar{x})^2} \sqrt{\sum_{t=k+1}^T (y_{t-k} - \bar{y})^2}}$$

$\bar{x}$, $\bar{y}$ はそれぞれ時系列データ X , Y の平均である。 r_{xy} が 1 に近いときは正の相関、 -1 に近いときは負の相関があり、0 に近いときは相関が弱いとされる。本論文では、各 α 波構成波の振幅と波形幅が 2 組の時系列データ、 T は α 波構成波の個数にあたる。 k の範囲は $-T/2 \leq k \leq T/2$ (ただし k は整数) とする。

振幅と波形幅の相互相関係数を図 11 に示す。縦軸は相




図 11 振幅と波形幅の時間的相関
Fig. 11 Time-delay correlation.

関係数の絶対値、横軸は振幅データの開始位置を表している。丸印で囲まれている部分が相関のある部分である。本論文では、相関係数の絶対値が0.25以上の場合、相関があると看做する。この波形から、約60周期で相関が強くなっていることが分かる。つまり、 α 波構成波の振幅と波形幅は約60波形分の時間差で相関があるといえる。波形幅の平均が22.5、Enobioのサンプリング周波数が250 S/sであるため、1波形分の時間は0.09秒になる。したがって、60波形分の時間差では5.4秒差になる。

5. 実験

5.1 実験方法

3-4章で提案した α 波構成要素の切り出し手法と解析方法を用いて実験を行う。被験者は20-22歳の健康な女性10人である。計測回数は合計122回である。検証に使用するデータは閉眼・安静・覚醒時の α 波が出やすい状態で脳波を計測したもので、1回の計測時間は10分間である。脳波計にはEnobioを使用する。まず、これらのデータを用いて3章で行った α 波構成要素の切り出しを試みる。しかし、多数の計測データを処理するにあたり、STFTの結果から目視で α 波含有時系列データを見つけ出して切り出すには膨大な時間がかかるため、 α 波含有時系列データの切り出し部分の処理を自動で行えるように以下の手法を適用する。まず、切り出すデータは64秒に固定し、1秒ずつずらしながらICA処理後の4つの独立成分の全周波数帯域(0-125 Hz)における α 波含有率を求める。最も α 波含有率の多い成分が全成分の α 波含有率に占める割合を求める。この割合が最大の時系列データを α 波含有時系列データとし、そのとき最も α 波含有率の多い独立成分を α 波データとする。また、 α 波データに十分な α 波量が確認できない場合は α 波が含まれていないデータとして除外する。基準として、 α 波データの4-30 Hz内での α 波含有率が32%以上のとき α 波が十分含まれていると見なす。ここでの4-30 Hzとは、自発脳波である θ 波・ α 波・ β 波全体の周波数帯域であり、32%の閾値は α 波データの α 波含有率の結果から目視により決定したものである。次に、4章




図 12 α 波データの α 波構成波数
Fig. 12 The number of alpha wave constituent waves.




図 13 α 波データの α 波含有率
Fig. 13 Alpha wave containing rates.

に基づいて、 α 波構成波の特徴である振幅と波形幅から相互相関係数を求めて位相分析を行う。本論文では、相互相関係数の絶対値が0.25以上の場合、相関があると看做する。

5.2 α 波構成波切り出しの実験結果

122回の計測データから α 波含有率が32%以上の α 波データは37個得られた。最も α 波データが得られた人では、5回の計測すべてで32%以上の α 波含有率が得られたが、10人のうち3人は最大で12回の計測を行ったが1度も32%を超える α 波含有率は現れなかった。また、計測回数を重ねるうちに α 波含有率が増加する人もいた。

α 波データを得られた37データについていくつかの情報を提示する。図12は α 波データの α 波構成波数である。例外はあるものの、多くのデータは600個台後半である。図13は α 波データの α 波含有率を3種類示している。1つ目は全周波数帯域(0-125 Hz)における α 波周波数帯域(8-13 Hz)の含有率、2つ目は自発脳波の周波数帯域(4-30 Hz)における α 波周波数帯域の含有率、3つ目は α 波と β 波の周波数帯域(8-30 Hz)における α 波周波数帯域の α 波含有率を求めたものである。1つ目の含有率はほとんどのデータが10%未満を示しているが、これは0-4 Hzの周波数を持つ筋電位や眼球運動などのアーチファクトが大半を占めていることが原因と考えられる。2つ目の含有


図 14 α 波データの波形幅の平均と分散

Fig. 14 Average and distribution of alpha wave length.


図 15 α 波データの振幅の平均と分散

Fig. 15 Average and distribution of alpha wave amplitude.

率は α 波データの抽出時に基準とした含有率である。3 つ目の含有率は α 波データの半数が 50% を超えており、十分 α 波が含まれていることを示している。

次に、 α 波構成波の特徴について示す。図 14 は波形幅の平均と分散である。3.4 節で説明した α 波構成要素抽出のアルゴリズムを用いて α 波構成波に分割したため、波形幅の平均は最適な波形幅である 23 点付近 (約 11 Hz) に多く見られる。また、図 15 は振幅の平均と分散を示しており、波形幅に比べていくらかのばらつきが見られた。

5.3 α 波解析の実験結果

5.2 節で提示した α 波構成波の特徴から相互相関係数を用いて解析を行う。 α 波の解析を行ううえで、個人によるデータの影響が大きくなるのを防ぐため、実験に使用するデータは 1 人あたりのデータ数を一致させる必要がある。 α 波データを得られた 7 人の中で複数のデータを得られたのは 6 人であった。また、6 人の中で最も少なかったデータ数は 3 であるため、実験に使用するデータは、 α 波データの取得に成功したデータのうち 1 回目から 3 回目の 1 人あたり 3 データの計 18 データとする。

α 波データの相互相関係数を求めた例を図 16 に示す。中央の縦線が時間差 0 の地点での相互相関係数である。各




図 16 相互相関係数の一例

Fig. 16 Example of cross-correlation coefficient.


図 17 各 α 波データの閾値を超えた割合

Fig. 17 The ratio of cross-correlation coefficients that exceed the threshold.


図 18 α 波データの相関出現回数

Fig. 18 The number of effective cross-correlation coefficients for each alpha wave data.

相互相関係数の値は絶対値で表している。図 16 のデータでは 10 回にわたり 0.25 の閾値を超える相関係数が見られた。次に、 α 波データの相互相関係数が閾値を超えた割合を図 17 に示す。閾値は 0.20 から 0.50 まで 0.05 ずつ変化させる。閾値が 0.25 のときにすべてのデータから相関が確認されていることから、 α 波構成波の振幅と波形幅には時間遅延の相互相関があるといえる。

最後に、 α 波構成波の特徴である振幅と波形幅の相互相関係数の規則性について分析する。まず、時間差 0 の地点での相関係数をカウントしたところ、18 データ中 9 データに 0.25 以上の相関が見られた。次に、各データの 0.25 以上の相関が見られた部分をカウントしたところ、図 18 で示す結果となった。横軸の 1-9 は時間差 0 の地点で相関が見




図 19 α波データの相関出現回数の左右差

Fig. 19 Comparison of valid cross-correlation coefficients found in forward and backward time direction.

られたデータであり、10-18 は相関が見られなかったデータである。時間差 0 での相関があるデータは比較的相関がある部分の回数が多く見られた。また、相関が現れた回数の左右差を調べた結果を図 19 に示す。横軸は図 18 の横軸と一致する。左側の相関が多い場合はマイナスの値、右側の相関が多い場合はプラスの値、左右差がない場合は 0 とする。この結果からは相互相関係数と左右差の関係は認められない。しかし、本論文で提案した手法をより長時間の α 波データに適用して解析することで、時間遅延に関する相互相関出現の規則性を見い出すことも可能であると考えられる。

5.4 考察

5.3 節では、α 波構成波の振幅と波形幅には時間遅延の相関があることが分かった。これは、振幅の変動にともない、数秒後の波形幅が同様に変動することを意味している。今回の実験では、各 α 波データから複数回の相関出現回数が得られたが、すべてのデータが図 11 のような周期的な頻度で相関が得られるわけではなかった。そのため、振幅と波形幅の時間遅延相関の周期変動をモデル化するには至らなかった。しかし、本論文で提案した手法を用いてより多くのデータを解析することで、この時間遅延をモデル化することが可能になると期待される。時間遅延のモデル式が求まると、α 波構成波をモデル化することも可能となる。また、1 章で述べたように、α 波の既存モデルとしては neural mass model などの脳波の発生メカニズムからモデル化しているものがある。我々の手法では実測データからのモデル化を目指しているため、将来的には既存モデルとの比較を行うことで、脳波発生のより詳細なメカニズムの解明につながるものと思われる。そのためにも、まず、振幅と波形幅との時間遅延相関の周期変動をモデル化する必要があると考えられる。

6. おわりに

本論文では、脳波から α 波データを切り出し、そのデータを α 波構成波に分割することで、α 波構成波の特徴量か

ら位相分析を行う手法を提案した。まず Enobio で測定された脳波に前処理を施した後、STFT を適用して α 波成分を多く含む時系列データを特定し、当該データを ICA で独立成分に分離後、α 波含有時系列データを得た。次に α 波含有時系列データから α 波を構成すると推定される α 波構成波にする分割アルゴリズムを提案・適用して α 波構成波を得た。得られた α 波構成波をクラスタリングすることで、α 波構成波の主要な特徴量は振幅と波形幅だということが判明した。また、各特徴量のフーリエ記述子の相関係数から、振幅と波形幅には時間遅延の相関があることが分かった。

今後の課題は多数ならびに長時間の計測脳波データから具体的な α 波のモデル化を行うことである。また、そのモデルを拡張して、自発脳波のモデル化を行い、計測された脳波から自発脳波を除去することで、精度の良い誘発脳波を得て、BMI などの研究に発展させたい。

謝辞 Enobio に関する質問に答えていただいた StarLab 社の羽田昌代氏に感謝します。また ICA の適用について助言いただいた富士通研究所の石川千里氏に感謝します。α 波のモデル化のヒントをいただいたお茶の水女子大学の吉田裕亮教授に感謝します。脳波計測の被験者になっていただいた本学域研究室の学生の皆様に感謝します。

参考文献

- [1] Lebedev, M.A. and Nicolelis, M.A.: Brain Machine Interfaces: Past, Present and Future, *TRENDS in Neurosciences*, Vol.29, pp.536-546 (2006).
- [2] Sutton, S., Braren, M., Zubin, J. and John, E.: Evoked-Potential Correlates of Stimulus Uncertainty, *Science*, Vol.150, pp.1187-1188 (1965).
- [3] Farwell, L.A. and Donchin, E.: Talking off the Top of Your Head: Toward a Mental Prosthesis Utilizing Event-related Brain Potentials, *Electroencephalography and Clinical Neurophysiology*, Vol.70, pp.510-523 (1988).
- [4] Hans, B.: Über das Electroencephalogramm des Menschen, *Archiv für Psychiatrie und Nervenkrankheiten*, Vol.87, pp.527-570 (1929).
- [5] Edgar, D. and M.B.H.C.: The Berger rhythm; Potential Changes from the Occipital Lobes in Man, *Brain*, Vol.57, pp.355-385 (1934).
- [6] Suzuki, H.: Phase relationships of alpha rhythm in man, *The Japanese Journal of Physiology*, Vol.24, pp.569-586 (1974).
- [7] Davis, H. and Davis, P.: Action Potentials of the Brain of Normal Persons and in Normal States of Cerebral Activity, *Arch. Neurol. and Psychiatry*, Vol.36, pp.249-279 (1936).
- [8] 大熊輝雄：臨床脳波学，第 5 編，医学書院 (1999)。
- [9] Naruse, Y., Matani, A., Miyawaki, Y. and Okada, M.: Influence of Coherence Between Multiple Cortical Columns on Alpha Rhythm: A Computational Modeling Study, *Human Brain Mapping*, Vol.31, pp.703-715 (2010).
- [10] 田崎新二, 伊賀崎伴彦, 村山伸樹, 古賀広昭：音楽鑑賞時におけるヒトの感性と生体信号の関連性, 電気学会論文誌 C, 電子・情報・システム部門誌, pp.1632-1638 (2002)。

- [11] 住谷正夫, 安久正紘: K.L 展開を用いた聴覚ストレス時の α 波パターンの特徴抽出について, 電子情報通信学会論文誌 D-II, 情報・システム, II-情報処理, pp.2556-2564 (1997).
- [12] Eberlin, P. and Yager, D.: Alpha Blocking During Visual After-images, *Electroencephalography and Clinical Neurophysiology*, Vol.25, pp.23-28 (1968).
- [13] Walter, W.G.: The Convergence and Interaction of Visual, Auditory, and Tactile Responses in Human Non-specific Cortex, *Annals of the New York Academy of Sciences*, Vol.112, pp.320-361 (1964).
- [14] 西藤聖二, 大門弘典, 田中正吾: 閃光刺激の色の交替が α 波の応答に及ぼす影響について, 電子情報通信学会論文誌 A, 基礎・境界, pp.480-489 (2005).
- [15] 鴻野浩一郎, 芥川正武, 榎本嵩宏, 長篠博文, 小中信典, 加治芳雄, 七條文雄, 古川和彦, 木内陽介: ニューラルネットワークを用いた α 波発生源の検討, 電子情報通信学会技術研究報告, MBE, ME とバイオサイバネティクス, pp.25-29 (2011).
- [16] Nikulin, V.V. and Brismar, T.: Phase Synchronization between Alpha and Beta Oscillations in the Human Electroencephalogram, *The Journal of Neuroscience*, Vol.137, pp.647-657 (2006).
- [17] Palva, M.J., Palva, S. and Kaila, K.: Phase Synchrony among Neuronal Oscillations in the Human Cortex, *The Journal of Neuroscience*, Vol.25, pp.3962-3972 (2005).
- [18] Naruse, Y., Takiyama, K., Okada, M. and Murata, T.: Inference in Alpha Rhythm Phase and Amplitude Modeled on Markov Random Field Using Belief Propagation from Electroencephalograms, *PHYSICAL REVIEW E*, Vol.82, p.011912 (2010).
- [19] Vigario, R.N.: Extraction of Ocular Artefacts from EEG Using Independent Component Analysis, *Electroencephalography and Clinical Neurophysiology*, Vol.103, pp.395-404 (1997).
- [20] Xu, N., Gao, X., Hong, B., Miao, X., Gao, S. and Yang, F.: BCI Competition 2003 — Data Set IIb: Enhancing P300 Wave Detection Using ICA-Based Subspace Projections for BCI Applications, *IEEE Trans. Biomedical Engineering*, Vol.51, pp.1067-1072 (2004).
- [21] Fusheng, Y., Yingfu, P., Qugyu, T., Kui, C. and Yanmei, T.: Single-trial Estimation and Analysis of PVEP Based on Independent Component Analysis, *Tsinghua Science and Technology*, Vol.6, pp.503-508 (2001).
- [22] Ventouras, E.M., Ktonas, P.Y., Tsekou, H., Paparrigopoulos, T., Kalatzis, I. and Soldatos, C.R.: Independent Component Analysis for Source Localization of EEG Sleep Spindle Components, *Computational Intelligence and Neuroscience*, Vol.2010, p.15 (2010).
- [23] Childers, D.G., Skinner, D.P. and Kemerait, R.C.: The Cepstrum: A Guide to Processing, *Proc. IEEE*, Vol.65, pp.1428-1443 (1977).
- [24] Starlab: Starlab Living Science (online), available from <http://starlab.es/products/enobio> (accessed 2011).
- [25] Manoilov, P.: EEG Eye-Blinking Artefacts Power Spectrum Analysis, *CompSysTech'06*, pp.IIIA.3-1-III.A.3-5 (2006).
- [26] Blaschke, T. and Wiskott, L.: CuBICA: Independent Component Analysis by Simultaneous Third- and Fourth-Order Cumulant Diagonalization, *IEEE Signal Processing Society*, Vol.52, pp.1250-1256 (2004).
- [27] Arthur, D. and Vassilvitskii, S.: k-means++: the advantages of careful seeding, *Proc. 18th Annual ACM-SIAM Symposium on Discrete Algorithms*, pp.1027-1035 (2007).

- [28] Persoon, E. and King-Sun, F.: Shape discrimination using Fourier descriptors, *IEEE Trans. Syst. Man Cybern.*, Vol.7, pp.170-179 (1977).
- [29] 長谷川哲平, 飯國洋二: 開曲線のための回転型フーリエ記述子, 電子情報通信学会論文誌 D, 情報・システム, Vol.J92-D, No.12, pp.2217-2224 (2009).
- [30] 人文・社会科学の統計学(編): 人文・社会科学の統計学, 東京大学出版会 (2003).



石川 由羽 (学生会員)

2012 年奈良女子大学理学部情報科学科卒業, 同年同大学院人間文化研究科博士前期課程情報科学専攻入学, 現在に至る. 信号処理に関する研究に従事.



高田 雅美 (正会員)

1977 年生. 2004 年奈良女子大学大学院人間文化研究科複合領域科学専攻修了. 博士(理学)を同大学より取得. 2004 年独立行政法人 JST 戦略的創造研究推進事業において, 京都大学大学院情報科学研究科にて委嘱研究員. 2006

年奈良女子大学大学院人間文化研究科助手. 2007 年奈良女子大学大学院人間文化研究科助教. 2013 年奈良女子大学理学部講師. 数値計算ライブラリの開発, 分散メモリ環境を対象とする並列プログラムの開発に関する研究に従事.



城 和貴 (正会員)

大阪大学理学部数学科卒業. 日本 DEC, ATR 視聴覚研究所(日本 DEC より出向), (株)クボタ・コンピュータ事業推進室で勤務の後, 1993 年奈良先端科学技術大学院大学情報科学研究科博士前期課程入学, 1996 年同研究科後期課程修了, 同年同研究科助手. 1997 年和歌山大学システム工学部講師, 1998 年同助教授. 1999 年奈良女子大学理学部情報科学科教授, 現在に至る, 博士(工学博士). 情報処理学会論文誌数理モデル化と応用編集委員長.