

生体信号解析の新展開

New Developments in Biological Signal Analysis

辻 敏夫*¹, 福田 修*², ト 楠*¹

Toshio TSUJI, Osamu FUKUDA, Nan BU

Biological signals play an important role in exploring biological systems. To extract relevant information from biological signals, a variety of techniques and theories from mathematics, statistics, and applied physics have been applied. However, due to complex characteristics, non-linear components, and non-stationary processes involved in biological systems, the development of an accurate and efficient signal processing method is still one of major challenges in the field of biological signal analysis. This paper aims to present a brief review of some advanced/modern techniques in biological signal analysis to provide useful information to researchers in the fields of biological engineering.

Keywords: biological systems, biological signal analysis, biological engineering.

1 緒言

最近の電気電子工学, 機械工学, 情報工学などの目ざましい進歩は, 次々と革新的な装置を生み出し, 予想もしなかったような技術がいつのまにか生活環境をとりまわっている。各家庭に普及したインターネットや子供達までが持ち歩くようになった携帯電話は, 少し前までは未来世界を描いた映画や小説の中の話にすぎなかったが, いまやあたりまえのように生活空間に溶け込み, 日常生活を便利で豊かなものになっている。しかしながら, その一方では, テクノストレスやデジタルデバイドなどの問題も少なからず発生しており, これらを見過ごすことはできない。科学技術の進歩は, 人間と機械の関係をより複雑で緊密なものにするが, その中心にはいつも人間がいることを忘れてはならず, これからのエンジニアリングでは生体の特性を考慮したアプローチが必要であろう。

人間と機械をつなぐマン・マシン・インタフェース技術では, 人間の特性を十分に考慮した制御器や表示器の設計が求められる。このため最近では, その不具合や最適性を評価するために, 生体信号に基づく解析が実施されることが多い。これは, 安全確保やヒューマンエラーの防止にもつながる重要なプロセスである。一方, 精巧で複雑な生体の優れた特性は, 最先端の科学技術でも到底及ばず, 機械設計の際には学ぶべき点

連絡先: 辻 敏夫, 〒739-8527 東広島市鏡山1-4-1, 広島大学大学院工学研究科,

e-mail: tsuji@bsys.hiroshima-u.ac.jp

*¹ 広島大学 *² (独) 産業技術総合研究所




Fig. 1 Difficulties in biological signal analysis.

が多い。ここでも, 生体の特性を理解するために, 生体信号の解析がさかんに行われている。

以上のような背景から, 生体信号に関する解析技術は現代のエンジニアにとって必要不可欠なスキルとなってきた。人間にやさしい機械をつくるためには, まず人間の特性を理解する必要がある。本解説では, 生体信号の基本的な特性と解析の難しさを確認し, 最新の解析技術に関して「近年注目されている手法」, 「よく利用される手法」を概説する。そして, 具体的な研究事例として, 我々がこれまでに取り組んできた生体信号解析に基づく福祉機器開発を紹介する。

2 生体信号解析の難しさ

ここでは, 生体信号の基本的な特性について説明し, その取り扱いにおいて留意すべき点を確認しておく。生体信号解析を難しくする要因は多数あり, これらが作用し合って問題をより複雑化している (Fig. 1)。

個体差 生体信号の特性には, 性別, 年齢, 生活習慣, 環境などが影響し, 個体差が存在する。したがって, 個

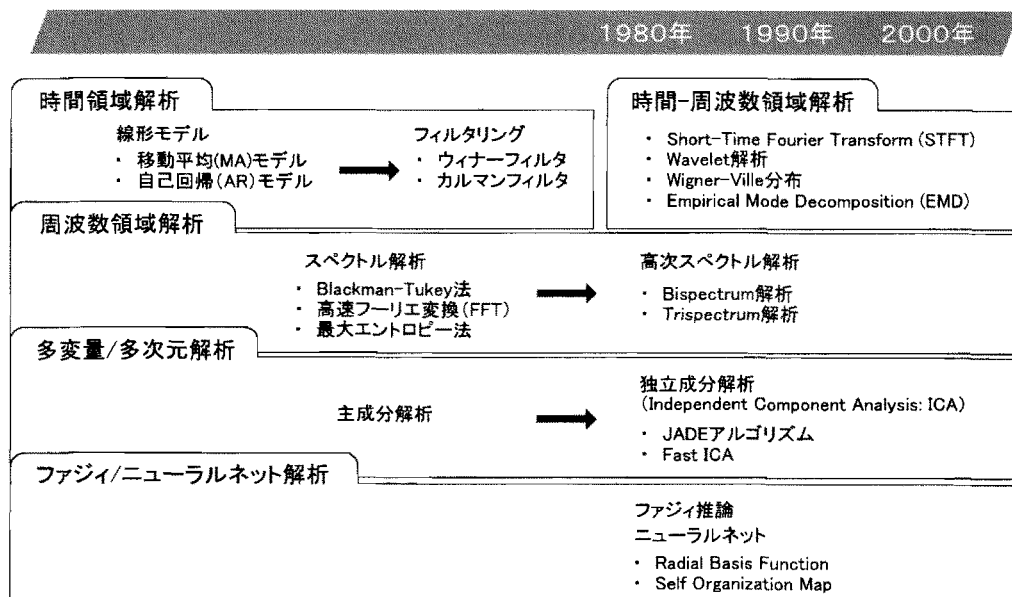


Fig. 2 Overview of the biological signal analysis.

体差に依存しない一般的な傾向を議論する際には、対象とする人間のプロフィールを明確にしたうえで、できるだけ多くの人間に共通する一般的な傾向を導き出す必要があり、慎重な実験計画を用意する必要がある。

非線形性 生体は、様々な器官や組織などが集まって全体を構成している。しかしながら、各要素は極めて複雑に影響し合っており、生体现象を個々の要素ごとに完全に分離して抽出することは不可能である。逆に、計測された個々の要素を足し合わせても、全体にはならない。神経ニューロンにおける情報伝達に代表されるように、生体には多くの非線形性が存在しており、生体信号解析においても線形解析の限界や適用範囲をよく見極めるとともに、非線形性を十分に考慮した解析を行う必要がある。

非定常性 生体信号の解析では、イベントに対する特性変化や異常波形の検出など、非定常な信号の変化に着目することが多い。また、心臓の拍動を例に取っても、同じ波形が計測されることは厳密には1拍としてなく、こうした生体信号の非定常性を抽出・解析する技術が求められる。

再現性 人間の恒常性は、自律神経系や内分泌系を統制し、日内変動や日差変動と呼ばれる「ゆらぎ」を発生している。午前や午後の時間帯によって、血圧などが若干異なるのもこのためである。その他にも、再現

性に影響を及ぼす要因として、その日の体調や疲労などがある。

また、生体信号解析の難しさは、計測した信号に含まれる情報量やノイズに大きく左右されるので、環境外乱の問題（温度、湿度、ノイズ）や、拘束性・侵襲性の問題（肉体的、精神的、時間的）にも十分気を配らなければならない。解析の目的を明確にした上で、上記の「難しさ」を十分に考慮し、実験計画をデザインすることが求められる。

3 生体信号解析の最新動向

生体信号解析の難しさには、前節で述べたような様々な要因がある。解析技術の従来研究では、このうちの非線形性、非定常性に関して議論されることが多い。いずれの研究でも、生体のメカニズムを積極的に考慮し、処理を効率よく実施する方法が提案されている。

Fig. 2は、生体信号解析に用いられる主な手法を分類したものである。これらには、時間領域解析、周波数領域解析、時間一周波数領域解析、多変量/多次元解析、ファジィ/ニューラルネット解析などがある。いずれも数学、統計学、制御工学、情報工学など様々なバックグラウンドを背景に発展してきた。

かつての生体信号解析では、伝達関数や自己回帰 (AR) モデルなどの線形モデルが利用されていたため、定常・線形な特徴しか議論できなかつたが、近年の非線形解析技術の進歩によって、非定常過程を解析する

新しい展開がもたらされた。特に、90年代以降に大きな発展を遂げた時間-周波数領域解析、高次スペクトル解析、独立成分分析、ニューラルネット解析は、近年注目を集めており、よく利用されるようになってきた。以下では、これらの解析技術を研究事例とともに紹介する。

3.1 ウェーブレット解析

ウェーブレット解析は、近年の生体信号解析で頻繁に利用されるようになった解析手法の一つである。この手法は、周波数成分の変化を高い時間分解能で抽出することができ、特徴成分抽出、ノイズ除去、イベントの検出、データ圧縮、パターン識別などに利用できる [1-4]。着目すべき周波数成分が、あらかじめ臨床的に明らかになっている場合には特に有効である。

Englehart らは、筋電位信号をウェーブレット変換し、時間周波数領域における特徴量に基づいて前腕部の動作識別を試みている [2]。Adeli らは、癲癇性患者の脳波解析を行っている [3]。また、Gupta らは、超音波エコー画像のスペックルノイズを除去するのに、ウェーブレット変換を利用している [4]。

時系列信号 $x(t)$ のウェーブレット変換は、次のように定義される [1]。

$$(W_{\psi}f)(b, a) = \int_{-\infty}^{\infty} \frac{1}{\sqrt{|a|}} \psi^*\left(\frac{x-b}{a}\right) f(x) dx \quad (1)$$

ここで、 $\psi(x)$ は、マザーウェーブレットと呼ばれる基底関数であり、 $\psi^*(x)$ はその複素共役である。 a 、 b は、それぞれスケールパラメータ、トランスパラメータと呼ばれる。 a は、 $\psi(x)$ の時間方向スケールを拡大、縮小することができ、周波数領域の特徴量を抽出する。一方、 b は $\psi(x)$ の位相を変化させ、時間領域の特徴量を抽出する。ウェーブレット変換は、抽出する周波数成分をあらかじめ設定することができ、その際に時間分解能が高周波領域で狭く、低周波領域で広がるように自動調節されるという優れた特徴がある。

3.2 Empirical Mode Decomposition

ウェーブレット変換などの時間周波数解析手法のほとんどは、基底関数を用いて信号を分解するため、解析結果がこの基底関数の性質に大きく影響される。つまり、基底関数の選択が大きな問題と言える。そこで、Huang らは、基底関数を使用しない解析手法 Empirical Mode Decomposition (EMD) を提案した [5]。EMD 法は、対象とする信号自身から intrinsic mode function (IMF) と

呼ばれる構成成分を抽出し、この IMF に基づいて信号に埋め込まれた変動モードを忠実に反映した処理を実現する。

EMD 法は、これまで地震や波などの解析に利用されることが多く、生体信号への応用はまだ少ないのが現状である。しかしながら、脳波 [6]、心電図 [7]、血圧 [8] などの神経系、循環系の信号解析が最近試みられており、今後の展開が期待される。

EMD 法では、まず信号 $x(t)$ を、sifting process と呼ばれる手続きにしたがって一連の構成成分 IMF に分解する。次にヒルベルト変換を施し、時間-周波数領域のエネルギー分布を求める。この際、sifting process は、以下のようなステップで実施する [5]。

1. 信号 $x(t)$ を h_0 と設定し、 h_0 の全ての極大 (小) 値を検出する。そして、三次スプライン曲線により全極大値 (極小値) をフィットし、上下の包絡線を求める。
2. 次に、上下の包絡線から平均曲線 m を計算し、 $h = h_0 - m$ を求める。
3. IMF を検出する。
 - (a) h が IMF の条件を満たせば、IMF 成分として h を抽出し、残差 $r = x(t) - h$ を計算する。
 - (b) h が IMF の条件を満たさなければ、 h_0 を h と入れ替えて、ステップ 1 に戻る。
4. $x(t)$ を r と入れ替えて、IMF を抽出できなくなるまでステップ 1 からのプロセスを繰り返す。

以上のステップにより、信号 $x(t)$ は、

$$x(t) = \sum_{i=1}^n h_i + r \quad (2)$$

と記述され、 n 個の IMF 成分と残差に分解できる。

このように、EMD 法はデータ駆動型の信号処理であり、信号の局所的な特性に従って信号を分解するので、基底関数選択の必要がなく、対象とする信号に特有な時間周波数特性を忠実に反映した処理ができる。

3.3 高次スペクトル解析

一般的なスペクトル解析が、周波数成分の独立性を仮定するのに対し、高次スペクトル解析は、周波数成分間の関係を抽出できる利点がある。各周波数成分の位相情報を利用できるのも特徴である。信号の高次キュムラント (cumulant) の周波数分布を表現し、信号の非線形特性の解析に適する [9]。

高次スペクトル解析として広く利用されている手法には、バイスペクトル解析 (Bispectrum analysis) があり、医学系の研究報告が数多くなされている。例えば、手術中の麻酔深度、鎮静深度のモニタリングを目的として、脳波データの Bispectral Index Scale (BIS) 計算が試みられている [10-11]。Patwardhan らは心室細動 (VF) 時の心電図データの周波数成分の位相結合 (phase coupling) を解析している [12]。また、ラットの脳波のバイスペクトル解析に基づく、脳障害の判別事例なども報告されている [13]。

ある確率過程 $x(t)$ のバイスペクトルは、以下の式で記述される [9]。

$$B(f_1, f_2) = \langle X(f_1)X(f_2)X^*(f_1 + f_2) \rangle \quad (3)$$

ここで、 $\langle \cdot \rangle$ は期待値を表し、 $X(f)$ は信号 $x(t)$ のフーリエ変換を示す。 $X^*(f)$ はその複素共役である。 $B(f_1, f_2)$ は2つの周波数成分、 f_1 と f_2 の関数であり、周波数成分やその相互作用を示す。この、 $B(f_1, f_2)$ を解析することにより、周波数成分 f_1 と f_2 の間の位相関係を調べることができる。

3.4 独立成分分析

独立成分分析 (Independent Component Analysis: ICA) は、複数の情報が混在する生体信号から、特定の成分を分離する際に利用される [14]。この手法は、1980年代から盛んに研究されるようになった多変量解析の一種であり、理論的には統計学における主成分分析とも密接な関係がある。ICA では、観測される信号は、統計的に独立した信号の線形な重ね合わせと仮定され、観測信号から元の信号成分を分離することができる。

生体信号解析における ICA の応用としては、独立信号 (源) の推定やノイズ、アーチファクトの除去がある。例えば、Nakamura らは、筋電位信号からモーターユニットの活動電圧 (MUAP) の推定に成功している [15]。Vigário は、ICA を利用して脳波データからアーチファクトの除去を行った [16]。McKeown らは、ファンクショナル MRI データに適用し、活動ポイントを高精度に推定している [17]。また、Ehlers らは、実環境における音声信号から特定音源の分離を実現している [18]。

ICA の原理を簡単に紹介する [14]。 K 個の信号源から信号

$$s(t) = (s_1(t), s_2(t), \dots, s_K(t))^T \quad (4)$$

が出力されたとする。各成分の平均は 0 で、各成分は互いに独立であるとする。この時、 M 個のセンサで元の信号が混合した信号

$$x(t) = (x_1(t), x_2(t), \dots, x_M(t))^T \quad (5)$$

を計測する。センサの次元 M と信号源の次元 K は必ずしも一致しない。ここで、 $s(t)$ と $x(t)$ との間に

$$x(t) = As(t) \quad (6)$$

という線形関係を仮定する。 A は $M \times K$ の実数行列である。ICA の目的は、 $s(t)$ の独立性の仮定から、 A に関する知識を持たずに $x(t)$ を K 個の独立な成分に分解することである。この問題は、 $s(t)$ と A が共に分からない状況で推定を行うことから Blind Source Separation (BSS) とも呼ばれる。解法についてはこれまでに幾つかのアプローチが提案されているが、誌面の都合により、ここでは省略させて頂く。文献 [14] などをご参照頂きたい。

3.5 ニューラルネット解析

最近の情報工学の発展にともない、非線形モデルを学習的に獲得可能なニューラルネットの研究が注目を集めるようになった。ニューラルネットによる信号処理は、仮定や条件、モデル等の先験情報には大きく頼らず、データそのものから学習的にモデルのパラメータを推定する点が特徴的である。フレキシブルなモデリング手法として、生体信号解析の分野においても盛んに利用が試みられている。そもそもニューラルネットの理論的枠組みは、脳神経における情報伝達モデルに基づいており、生体の優れた特性にインスパイアされた手法でもある。

生体信号解析へのニューラルネットの応用に関しては、アーチファクト処理、データ圧縮、信号源推定、パターン識別などの例が多数報告されている。Grieve らは多層パーセプトロンによる適応ノイズキャンセルフィルタを提案し、脳波信号のアーチファクト除去を試みている [19]。従来の線形 FIR 型フィルタでは、パラメータ数が次数の二乗に比例して増加する問題があるが、この適応ノイズキャンセルフィルタは、学習によりこれを解決することができる。脳波信号の解析に関しては、文献 [20] にもニューラルネットを利用した方法が紹介されている。

ニューラルネットを利用した生体信号解析では、特徴パターンの識別処理に関する研究も活発である。脳波




Fig. 3 An example of the EMG signal.

を利用したインタフェースに挑戦した Brain Computer Interface (BCI) や、脳波による癲癇、麻酔深度、覚醒度判断などの自動診断が報告されている。Bortolan らは、ニューラルネットを利用した心電図パターン識別を試みている [21]。

4 応用事例の紹介

我々の研究グループでは、これまでに生体信号を利用したマン・マシン・インタフェースの研究に取り組んできた [22-26]。これらの研究では、生体信号解析に適した構造を有するオリジナルのニューラルネットを開発し、脳波信号や筋電位信号などのパターン識別を実施した。そして、従来法では得られなかった識別精度を実現し、この成果を障害者のための福祉機器に導入した。ここでは、応用事例として、我々の開発したシステムの1つを紹介する。

紹介するシステムは、前腕切断者が筋電位信号を利用して電動義手を制御するためのインタフェースに関するものである。切断者の残存筋から計測可能な筋電位信号は、運動意図に関する様々な情報を含んでいることから、これらを精度良く識別することができれば、失った腕と近い制御感覚を実現できる可能性がある。

筋電位信号の生波形を Fig. 3 に示す。この図のように、筋電位信号には高周波成分が多く含まれるため、適切な特徴抽出処理、特に低域通過フィルタによる平滑化処理が必要となる。また、障害者の筋電位信号には大きな個人差が存在することが多いため、信号の識別には、学習能力を備えたニューラルネットが有効と考えられる。しかしながら、低域通過フィルタやニューラルネットを利用した従来手法は、それらに含まれる全てのパラメータを同時に最適化するのが非常に困難であり、これらの信号処理をトータルに最適化する手法が求められた。

我々は、従来手法では独立した2つのプロセスとして


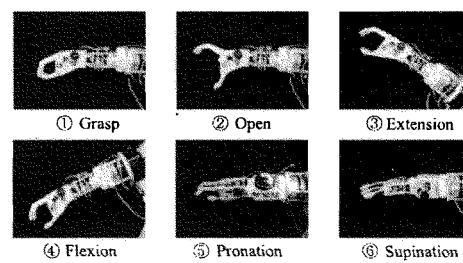


Fig. 4 An example of the prosthetic control.

処理されていた筋電位信号の特徴抽出処理とパターン識別処理を1つのニューラルネットを実現し、両処理に関するパラメータを同時に最適化する方法を提案した。この処理には、我々が提案したりカレントニューラルネットワークである Recurrent Log-Linearized Gaussian Mixture Network (以下、R-LLGMN と略記) [25] を利用する。R-LLGMN は、動的確率モデルの一つである隠れマルコフモデルに基づいた構造を有しており、筋電位信号に含まれる時系列特性をこのモデルに従って学習できる。これにより、生の筋電位信号から動作識別を実現することが可能になり、操作者の筋電位信号発生に対する識別処理の応答特性が向上した。

Fig. 4 に電動義手の制御例を示す。操作者は、切断者の男性 (44 才) で、約3年前に事故のため手首から3cm程の部位で右前腕部を切断している。電極は切断した右前腕部に5ch、右上腕部に1chを装着した。Fig.

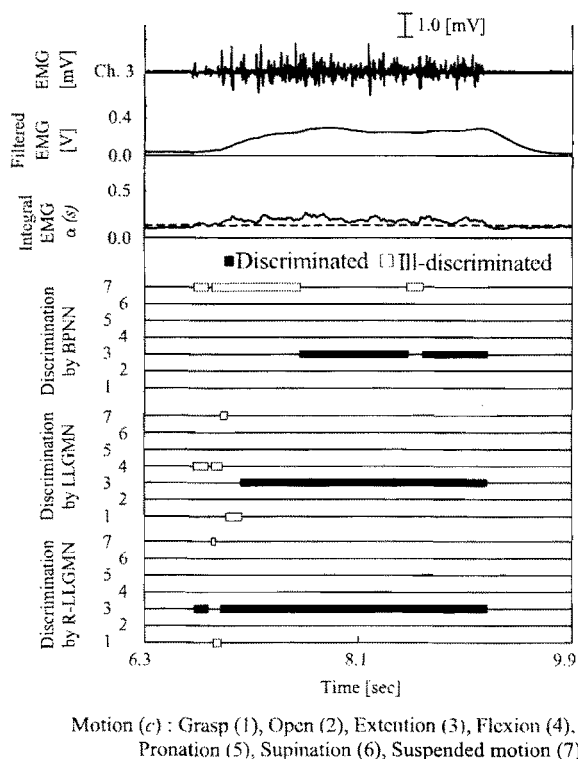


Fig. 5 Changes of the discrimination results by three types of neural networks.

4は、上から電動義手の動作写真（握り、開き、背屈、掌屈、回内、回外）、筋電位信号の生波形、積分筋電位レベル $\alpha(s)$ 、R-LLGMNの出力から計算したエントロピー $H(s)$ 、識別結果を表している。図中のグレーで示したエリアは、積分筋電位レベル $\alpha(s)$ が設定した閾値を越えないために無動作と判別されたことを示す。写真の番号は識別結果の番号と一致している。図より、若干のばらつきが見られるものの良好な識別結果が得られていることが分かる。エントロピーは識別の確からしさを示す指標 [26] となるが、この値も比較的低位安定している。識別率はトータルで95.5%であった。

次に、入力信号に対する識別の応答性について調べた。ここでは、比較のために筋電位信号のパターン識別に良く用いられる誤差逆伝播型ニューラルネットワーク（以下、BPNNと略記）と、我々が統計モデルに基づいて開発したLog-Linearized Gaussian Mixture Network（以下、LLGMNと略記）[24]についても結果を示す。これらの手法はいずれもリカレント構造を有さず、信号の時系列的な特性は考慮できない。

Fig. 5は、Fig. 4の6.3[sec]~9.9[sec]までの信号を拡大した図である。上から、筋電位信号の生波形（チャ

ンネル3）、全波整流した筋電位信号にデジタルローパスフィルタ（特性：Butterworth、次数：2、カットオフ周波数：1.0[Hz]）を施した整流平滑筋電位信号、積分筋電位レベル $\alpha(s)$ 、整流平滑筋電位信号を入力としたBPNN、LLGMNの識別結果、生の筋電位信号を入力としたR-LLGMNの識別結果を表している。動作は背屈で、チャンネル3はこの動作時に最も筋電位が発生したチャンネルである。図より、整流平滑筋電位信号を入力としたBPNNやLLGMNは、識別開始に時間遅れが生じており、誤識別も多いことが分かる。一方、生の筋電位信号を入力とした本手法の場合は、筋電位信号発生とほぼ同時刻から正しい識別が行われており、位相遅れが極めて小さいことが分かる。

以上のように、我々の提案した手法では、筋電位信号の特徴抽出処理とパターン識別処理の2つの処理を、1つのニューラルネットワークで実現し、両処理に関するパラメータをトータルに最適化した。これにより、識別の応答特性の向上に成功した。

5 結言

本解説では、人間にやさしい機械を開発するためには、生体を深く理解することが必要不可欠であるとの観点から、生体信号解析技術が現代のエンジニアにとって必須のスキルであると論じた。そして、これから生体信号の解析技術に触れようとするエンジニアのために生体信号の基本的特性を概説するとともに、解析の難しさを説明した。最新の解析技術に関しては、できる限り広範に「近年注目されている手法」、「よく利用される手法」を具体的な研究事例を交えて示すとともに、具体的な応用例として、我々がこれまでに取り組んできた生体信号解析技術の一端を紹介した。

科学技術の進歩は、新しい人間と機械との関係を次々に創造していくが、その中心には人間がいることを忘れてはならない。少しでも多くの工学者が、神が創造したと言われる生体の優れた機能や特性に学びながら、新しい時代のエンジニアリングを開拓していくことを願っている。

参考文献

- [1] 榊原, ウェーブレット ビギナーズガイド, 東京電機大学出版, 1995.
- [2] K. Englehart, B. Hudgins, P. A. Parker, and M. Stevenson, Classification of the myoelectric signal using time-frequency based representations, *Medical Engineering & Physics*, Vol.21, No.6-7, pp.431-438, 1999.

- [3] H. Adeli, Z. Zhou, and N. Dadmehr, Analysis of EEG records in an epileptic patient using wavelet transform, *Journal of Neuroscience Methods*, Vol.123, pp.69-87, 2003.
- [4] S. Gupta, R.C. Chauhan, and S.C. Sexana, Wavelet-based statistical approach for speckle reduction in medical ultrasound images, *Medical & Biological Engineering & Computing*, Vol.42, pp.189-192, 2004.
- [5] N.E. Huang, Z. Shen, S.R. Long, M.C. Wu, E.H. Shih, Q. Zheng, C.C. Tung, and H.H. Liu, The empirical mode decomposition and the Hilbert spectrum for nonlinear and nonstationary time series analysis, *Proceedings of the Royal Society of London, A*, Vol.454, pp.903-995, 1998.
- [6] H. Liang, S.L. Bressler, R. Desimone, and P. Fries, Empirical mode decomposition: a method for analyzing neural data, *Neurocomputing*, Vol.65-66, pp.801-807, 2005.
- [7] R. Balocchi, D. Menicucci, E. Santarcangelo, L. Sebastiani, A. Gemignani, B. Ghelarducci, and M. Varanini, Deriving the respiratory sinus arrhythmia from the heartbeat time series using empirical mode decomposition, *Chaos, Solitons and Fractals*, Vol.20, pp.171-177, 2004.
- [8] W. Huang, Z. Shen, N.E. Huang, and Y.C. Fung, Engineering analysis of biological variables: An example of blood pressure over 1 day, *Proceedings of the National Academy of Sciences of the United States of America*, Vol.95, No.9, pp.4816-4821, 1998.
- [9] W.B. Collis, P.R. White, and J.K. Hammond, Higher-order Spectra: The Bispectrum and Trispectrum, *Mechanical Systems and Signals Processing*, Vol.12, No.3, pp.375-394, 1998.
- [10] J.W. Johansen, P.S. Sebel, Development and Clinical Application of Electroencephalographic Bispectrum Monitoring, *Anesthesiology*, Vol.93, No.5, pp.1336-1344, 2000.
- [11] 萩平, 脳波の Bispectral Analysis と BIS, *Life Support and Anesthesia*, Vol.8, No.10, pp.904-909, 2001.
- [12] A. Patwardhan, K. Wang, S. Moghe, and F. Leonelli, Bispectral Energies within Electrocardiograms During Ventricular Fibrillation are Correlated with Defibrillation Shock Outcome, *Annals of Biomedical Engineering*, Vol.27, No.2, pp.171-179, 1999.
- [13] J.W. Zhang, C.X. Zheng, and A. Xie, Bispectrum Analysis of Focal Ischemic Cerebral EEG Signal Using Third-Order Recursion Method, *IEEE Trans. on Biomedical Engineering*, Vol.47, No.3, pp.352-359, 1999.
- [14] 池田, 独立成分解析, *日本神経回路学会誌*, Vol.9, No.2, pp.181-189, 2002.
- [15] H. Nakamura, M. Yoshida, M. Kotani, K. Akazawa, T. Moritani, The application of independent component analysis to the multi-channel surface electromyographic signals for separation of motor unit action potential trains: part II-modelling interpretation, *Journal of Electromyography and Kinesiology*, Vol.14, pp.433-441, 2004.
- [16] R.N. Vigário, Extraction of ocular artefacts from EEG using independent component analysis, *Electroencephalography and Clinical Neurophysiology*, Vol.103, No.3, pp.395-404, 1997.
- [17] M.J. McKeown, S. Makeig, G.G. Brown, T.P. Jung, S.S. Kindermann, A.J. Bell, and T.J. Sejnowski, Analysis of fMRI data by blind separation into independent spatial components, *Human Brain Mapping*, Vol.6, pp.160-188, 1998.
- [18] F. Ehlers and H. Schuster, Blind separation of convolutive mixtures and an application in automatic speech recognition in noisy environment, *IEEE Trans. on Signal Processing*, Vol.45, No.10, pp.2608-2609, 1997.
- [19] R. Grieve, P.A. Parker, B. Hudgins, and K. Englehart, Nonlinear Adaptive Filtering of Stimulus Artifact, *IEEE Trans. on Biomedical Engineering*, Vol.47, No.3, pp.389-395, 2000.
- [20] C. Robert, J.F. Gaudy, and A. Limoge, Electroencephalogram processing using neural networks, *Clinical Neurophysiology*, Vol.113, No.5, pp.694-701, 2002.
- [21] G. Bortolan, C. Brohet, and S. Fusaro, Possibilities of using neural networks for ECG classification, *Journal of Electrocardiology*, Vol.1, Supp.1, pp.10-16, 1996.
- [22] 辻, 森, 伊藤, 統計構造を組み込んだニューラルネットによる EMG 動作識別法, *電気学会論文誌 C*, Vol.112-C, No.8, pp.465-473, 1992.
- [23] 辻, 市延, 伊藤, 長町, エントロピーを用いた誤差逆伝搬型ニューラルネットによる EMG からの前腕動作の識別, *計測自動制御学会論文集*, Vol.29, No.10, pp.1213-1220, 1993.
- [24] T. Tsuji, O. Fukuda, H. Ichinobe and M. Kaneko, A log-linearized Gaussian mixture network and its application to EEG pattern classification, *IEEE Trans. on Systems, Man, and Cybernetics-Part C: Applications and Reviews*, Vol.29, No.1, pp.60-72, 1999.
- [25] T. Tsuji, N. Bu, O. Fukuda, and M. Kaneko, A Recurrent Log-Linearized Gaussian Mixture Network, *IEEE Trans. on Neural Networks*, Vol.14, No.2, pp.304-316, 2003.
- [26] O. Fukuda, T. Tsuji, M. Kaneko and A. Otsuka, A Human-Assisting Manipulator Teleoperated by EMG Signals and Arm Motions, *IEEE Trans. on Robotics and Automation*, Vol.19, No.2, pp.210-222, 2003.