

# 第4章 独立成分解析を用いた大域信号除去

## 4.1 はじめに

本章では、前章で説明した大域信号除去において、大域信号の推定に独立成分解析を用いた場合について述べる。

## 4.2 独立成分解析 (ICA) の概要

パーティ会場のように、音楽や話し声など様々な物音が交錯する環境においても、人は周囲の雑音に煩わされることなく会話を楽しむことができる。また2人程度なら、同時に話をされても話の内容を聞き分けることもできる。人が持つこのような特定音声の抽出能力は**カクテルパーティ効果**と呼ばれており、古くから様々な分野において様々な観点から説明を与えることが試みられている。例えば、人が受け取る音声信号というのは、音の発生源から耳に届くまでの微妙な音響路の差によって、左右の耳でわずかながら異なる。このために、音響路の伝達特性を示す物理的なモデルを推測することによって、左右の音の差から原音を再現する信号処理の問題として取り扱うことができる。また、選択的注意とか言語処理といった脳の高次機能を考慮した心理学的なモデルにおいては、注意を持って聞こうとしている音や音声以外の信号を遮断するマスキング機構が考えられている。

カクテルパーティ効果の工学的な実現を目的としているのが、Blind Signal Separation (BSS)[9]であり、その中で最も中心的なものが、**独立成分解析 (Independent Component Analysis; ICA)**[10]-[12]である。独立成分解析は、信号の統計的な性質の違いを手掛かりに、観測された信号を互いに独立な成分へと分離することで、源信号を推定する。独立成分解析の考え方を、以下に簡潔に述べる。まず、互いに影響し合わない発生源からの信号は、互いに独立な性質を持つと考えられる。また、源信号が異なる複数のセンサに到達した場合、それらの観測信号には要因が同じ情報が含まれるため、観測信号は互いに独立ではなくなる。これを逆に考えると、互いに独立でない複数の観測信号に共通する信号をいくつか抽出し、それら抽出信号が互いに独立であれば、抽出信号は源信号を再現したものとなりうる。

独立成分解析が信号処理方法の手法としての特徴は、源信号の独立性を仮定するだけで、

それ以外の信号の信号伝送路の伝達特性などの情報は未知とすることである。このために、信号源が複数あり、他店計測されたデータの解析に有効とされている。その典型的な応用例としては、

- 複数話者の音声信号の分離
- 通信分野における混線信号 (crosstalk) の分離
- 多点計測されたレーダ・ソナー信号の前処理
- 生体計測信号の解析

等が存在する。本研究では、これを ELF 帯環境電磁波データの解析に応用する [26]-[28]。

### 4.3 問題の定式化

互いに独立な  $m$  個の信号源から発生する未知の時系列信号

$$\mathbf{s}(t) = [s_1(t), s_2(t), \dots, s_m(t)]^T \quad (4.1)$$

を考える。ここで、 $T$  は転置を表す。信号源は互いに影響を及ぼすことなく、各信号は互いに統計的に独立であるとする。この信号源から発生した信号を  $n$  個のセンサで計測した結果、得られる観測信号を

$$\mathbf{x}(t) = [x_1(t), x_2(t), \dots, x_n(t)]^T \quad (4.2)$$

と書くことにする。このとき、源信号と観測信号との関係は未知の混合行列  $\mathbf{A}$  を用いて

$$\mathbf{x}(t) = \mathbf{A}\mathbf{s}(t) \quad (4.3)$$

と表現されると仮定を置く。また、混合は時間によらず一定であると考え、混合行列  $\mathbf{A}$  は時不変であるとする。通常、信号源の数  $m$  と観測装置の数  $n$  は必ずしも一致しないが、 $m \leq n$  であれば、この問題を解くことが可能である。問題を定式化するにあたっては  $m$  と  $n$  が等しいことが望ましいため、以降は  $m = n$  の場合を考える。

$\mathbf{A}$  の逆行列  $\mathbf{A}^{-1}$  と観測信号  $\mathbf{x}(t)$  の積は

$$\mathbf{A}^{-1}\mathbf{x}(t) = \mathbf{A}^{-1}\mathbf{A}\mathbf{s}(t) = \mathbf{I}\mathbf{s}(t) = \mathbf{s}(t) \quad (4.4)$$

となり、源信号  $\mathbf{s}(t)$  は観測信号  $\mathbf{x}(t)$  より分離できる。つまり、観測信号から源信号を分離するには、混合行列  $\mathbf{A}$  の逆行列を求めればよい。しかし、混合行列  $\mathbf{A}$  は未知であり、もちろん源信号  $\mathbf{s}(t)$  も未知であるため、逆行列  $\mathbf{A}^{-1}$  を算術的に求めることは不可能であり、何らかの方法で推定する必要がある。

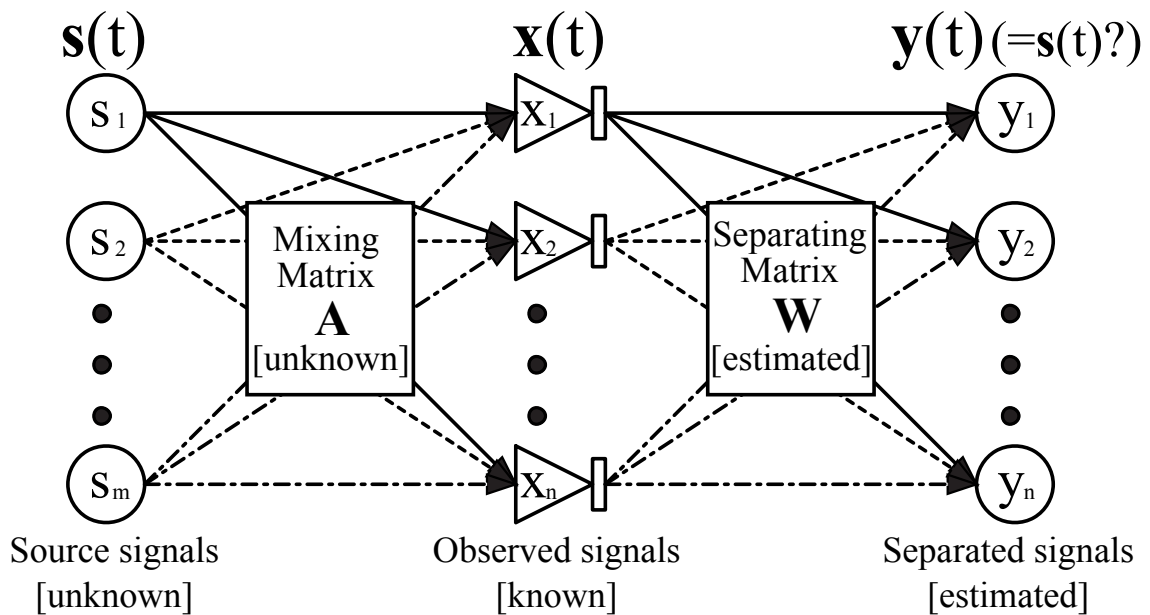


図 4.1: ICA における信号処理のモデル

ICA では、源信号  $\mathbf{s}(t)$  の各要素はそれぞれ互いに独立なものと仮定する。源信号が混ざり合った状態の観測信号  $\mathbf{x}(t)$  の各要素は独立性を失っており、逆に、観測信号を線形変換したものが互いに独立となれば、それは源信号へと分離されているというのが ICA の考え方である。つまり、観測信号  $\mathbf{x}(t)$  を互いに独立な成分へと変換する行列  $\mathbf{W}$  を求め、

$$\mathbf{y}(t) = \mathbf{W}\mathbf{x}(t) \quad (4.5)$$

で定まる信号  $\mathbf{y}(t)$  を源信号  $\mathbf{s}(t)$  として推定する (図 4.1)。

ICA によって観測信号  $\mathbf{x}(t)$  から分離行列  $\mathbf{W}$  を推定し、分離信号  $\mathbf{y}(t)$  が得られたとする。このとき、分離行列の逆行列と分離信号を用いて観測信号を再構成することができる。

$$\mathbf{W}^{-1}\mathbf{y}(t) = \mathbf{W}^{-1}\mathbf{W}\mathbf{x}(t) = \mathbf{I}\mathbf{x}(t) = \mathbf{x}(t) \quad (4.6)$$

つまり、分離行列の逆行列  $\mathbf{W}^{-1}$  は分離信号の混合行列であり、分離信号が源信号を推定したものであることから、分離行列の逆行列  $\mathbf{W}^{-1}$  は混合行列  $\mathbf{A}$  を推定したもの ( $=\hat{\mathbf{A}}$ ) といえることができる。

ICA による推定結果において注意すべき点として、不定性がある。まず、源信号の順番と、対応する独立成分の順番は、必ずしも一致しない。信号モデルにおいて源信号に与えられていた順番は便宜上のものであり、独立成分の順番は任意である。次に、源信号の平均振幅と、対応する独立成分の平均振幅は、必ずしも一致しない。たとえば、ある源信号の平均振幅が実際には対応する独立成分の 2 倍であっても、混合の係数が実際の 1/2 倍であれば、観測信

号は同じである．よって結局，ICAは適当な対角行列  $\mathbf{D}$  と置換行列  $\mathbf{P}$  を用いて

$$\mathbf{W} = \mathbf{DPA}^{-1} \quad (4.7)$$

となるような分離行列  $\mathbf{W}$  を求めることとなる．

ICAは，分離された信号が統計的に互いに独立となるような分離行列を推定する．統計的な独立とは，ある確率変数の値を知っても他の確率変数の情報が得られないことである．具体的には，2つの確率変数  $x, y$  に対し，その同時確率分布  $p_{XY}(x, y)$  が周辺確率分布  $p_X(x), p_Y(y)$  の積

$$p_{XY}(x, y) = p_X(x) \cdot p_Y(y) \quad (4.8)$$

のように分解されるなら， $x, y$  はお互いに独立だといえる．これを一般化すると次の式となる．

$$p(\mathbf{x}) = \prod p_i(x_i) \quad (4.9)$$

連続データにおいて確率分布を求めることは困難であり，また，アルゴリズムに取り込むことも困難であることから，式(4.8)や式(4.9)が直接的に用いられることは少ない．代わりに，信号の非正規性を独立性とみなすことが多い．一般に，互いに独立に生起する信号を線形に混合していくにつれ，その確率分布は中心極限定理から正規分布に近づく．逆に，正規分布から遠ざける(非正規性を高める)ような処理を行うことで，混合前の互いに独立な信号に分離できるとも考えられる．非正規性の指標として，統計量の一種であるキュムラントを用いることができる．

キュムラントは，統計用の一種であるモーメントから導出される．ある確率変数  $x$  について， $x^r$  の期待値  $E[x^r]$  を  $r$  次モーメントという．全ての次数のモーメントを生成するモーメント母関数は， $t$  を用いて次の式で定義される．

$$M_X(t) = E[\exp\{tx\}] = \sum_{r=0}^{\infty} \frac{t^r}{r!} E[x^r] \quad (4.10)$$

ここで， $t^r$  の係数が  $x$  の  $r$  次モーメントに関係しており， $r$  次モーメントは導関数を用いて

$$M_X^{(r)}(0) = E[x^r] \quad (4.11)$$

のように取り出すことができる．あらかじめ確率変数  $x$  の平均を0としたときのモーメントを，「平均のまわりのモーメント」といい，多くの場合こちらを用いる．例えば分散は平均のまわりの2次のモーメントである．

式(4.10)の対数をとったものがキュムラント母関数であり，

$$K_X(t) = \log E[\exp\{tx\}] = \sum_{r=0}^{\infty} \frac{t^r}{r!} \kappa_r \quad (4.12)$$

と定義される．ここで  $t^r$  の係数  $\kappa_r$  が  $x$  の  $r$  次キュムラントであり，導関数を用いて

$$K_X^{(r)}(0) = \kappa_r \quad (4.13)$$

のようにモーメントの場合と同様に取り出すことができる．例えば1次キュムラントは，

$$\begin{aligned} K_X^{(1)}(t) &= \frac{M_X^{(1)}(t)}{M_X(t)} \\ K_X^{(1)}(0) &= E[x] \end{aligned} \quad (4.14)$$

となる．計算の簡便さや推定の頑健性からICAで用いられることの多い4次キュムラントは，平均を0とした場合，次のように表せる．

$$\kappa[x] = E[x^4] - 3\{E[x^2]\}^2 \quad (4.15)$$

標準正規分布は3次以上のキュムラントが0になるため，値が0から離れているほど非正規性が高いと言える．つまり，3次以上のキュムラントの絶対値が大きい分離信号であれば，独立性の高い信号に分離できていると考えられる．

## 4.4 推定アルゴリズム

ICAでは，信号の独立性の基準をもとにコスト関数を作り，分離行列  $\mathbf{W}$  を逐次推定によって求めるが，そのアルゴリズム自体も様々に提案されている [29]．ここでは，Natural Gradient - Frexible ICA (NG-FICA)[30][31] と Extended Infomax (ExInfomax)[32][33] について説明する．

### 4.4.1 Natural Gradient - Frexible ICA (NG-FICA)

NG-FICAは，独立性の指標に4次のキュムラントを，逐次推定に自然勾配法を用いたICAアルゴリズムである．

まず，基本となる勾配法について説明する．コスト関数  $L(\mathbf{W})$  が与えられたときに，これを最小にする  $\mathbf{W}$  を求めることを考える．その場合，適当な初期値  $\mathbf{W}$  を用意し， $L(\mathbf{W})$  が小さくなるように  $\mathbf{W}$  を少しずつ変化させていけば，収束した  $\mathbf{W}$  が目的のものとなりうる．このとき， $L(\mathbf{W})$  は下に凸な極値であることから， $L(\mathbf{W})$  を  $\mathbf{W}$  で偏微分した値，つまり勾配 (グラディエント)

$$\nabla L(\mathbf{W}) = \frac{\partial L(\mathbf{W})}{\partial \mathbf{W}} \quad (4.16)$$

の逆方向に向けて  $\mathbf{W}$  を変化させればよい。したがって  $\mathbf{W}$  を更新するには、適当な係数  $\eta$  を用いて

$$\mathbf{W} + \Delta\mathbf{W} = \mathbf{W} - \eta\nabla L(\mathbf{W}) \quad (4.17)$$

としてやればよい。

ICA におけるコスト関数は、実際には次のように表されることが多い。

$$L(\mathbf{W}) = -\log |\mathbf{W}| + E[f(\mathbf{y})] \quad (4.18)$$

ここで、 $\log |\mathbf{W}|$  を  $\mathbf{W}$  で偏微分すると、

$$\frac{\partial \log |\mathbf{W}|}{\partial \mathbf{W}} = \frac{\partial |\mathbf{W}|}{\partial \mathbf{W}} \frac{\partial \log |\mathbf{W}|}{\partial |\mathbf{W}|} = \frac{\partial |\mathbf{W}|}{\partial \mathbf{W}} |\mathbf{W}|^{-1} = |\mathbf{W}| \mathbf{W}^{-T} |\mathbf{W}|^{-1} = \mathbf{W}^{-T} \quad (4.19)$$

また、 $f(\mathbf{y})$  を  $\mathbf{W}$  で偏微分すると、

$$\frac{\partial f(\mathbf{y})}{\partial \mathbf{W}} = \frac{\partial \mathbf{y}^T}{\partial \mathbf{y}} \frac{\partial f(\mathbf{y})}{\partial \mathbf{W}} = \frac{\partial f(\mathbf{y})}{\partial \mathbf{y}} \left( \left( \frac{\partial}{\partial \mathbf{W}} \right)^T \mathbf{y} \right)^T = \frac{\partial f(\mathbf{y})}{\partial \mathbf{y}} \left( \frac{\partial \mathbf{W} \mathbf{x}}{\partial \mathbf{W}^T} \right)^T = \frac{\partial f(\mathbf{y})}{\partial \mathbf{y}} \mathbf{x}^T \quad (4.20)$$

よって、コスト関数  $L$  の勾配  $\nabla L$  は次のようになる。

$$\nabla L = -\mathbf{W}^{-T} + E \left[ \varphi(\mathbf{y}) \mathbf{x}^T \right], \quad \varphi(\mathbf{y}) = \frac{\partial f(\mathbf{y})}{\partial \mathbf{y}} \quad (4.21)$$

したがって、 $\mathbf{W}$  の変化分は次のようになる。

$$\Delta\mathbf{W} = \eta \left( \mathbf{W}^{-T} - E \left[ \varphi(\mathbf{y}) \mathbf{x}^T \right] \right) \quad (4.22)$$

ある関数の座標系がユークリッド空間の正規直交系であれば、その関数が最も急激に変化する方向 (最急変化方向) は勾配である。しかし一般的には空間は曲がっており、勾配が必ずしも最急変化方向とは限らないため、勾配法をそのまま用いることができない。曲がった空間における最急変化方向は自然勾配 [12] と呼ばれ、リーマン空間において正則な行列  $\mathbf{W}$  を系とした場合、先ほどのコスト関数  $L(\mathbf{W})$  の自然勾配は次のようになる。

$$\tilde{\nabla} L = \nabla L \mathbf{W}^T \mathbf{W} \quad (4.23)$$

よって、これをもとに  $\mathbf{W}$  を変化させればよい。つまり変化分は次のようになる。

$$\Delta\mathbf{W} = \eta \left( \mathbf{I} - E \left[ \varphi(\mathbf{y}) \mathbf{y}^T \right] \right) \mathbf{W} \quad (4.24)$$

さてここで、変化方向を決める関数  $\varphi(\mathbf{y})$  を考える。これはもともと、コスト関数の内部にある  $f(\mathbf{y})$  を  $\mathbf{y}$  で偏微分したものである。コスト関数としてキュムラントを用いるには、

$$f(\mathbf{y}) = \frac{1}{4} \sum y_i^4 \quad (4.25)$$

などとすればよい。上式は4次キュムラントを簡単にしたものである。このとき  $\varphi(\mathbf{y})$  の各要素は  $\varphi_i(y_i) = y_i^3$  となるが、 $\mathbf{y}$  の各要素が互いに独立である場合、 $E[\mathbf{y}^3 \mathbf{y}^T]$  の  $i, j$  要素は  $i \neq j$  のとき0となる。つまり対角行列である。このように、自然勾配法を用いたICAアルゴリズムは、成分の分離が成功した場合に  $E[\varphi(\mathbf{y}) \mathbf{y}^T]$  が対角行列となるよう設計する。それは  $\mathbf{W}$  が収束する条件からも理解できる。

NG-FICAは、次の式(4.26)で表される主成分解析(Principal Component Analysis; PCA)を逐次推定の前に行うことで、入力信号  $\mathbf{x}(t)$  を互いに無相関な信号  $\mathbf{z}(t)$  へと線形に変換する。

$$\mathbf{z}(t) = \mathbf{Q} \mathbf{x}(t), \quad \mathbf{Q} = E[\mathbf{x}(t) \mathbf{x}^T(t)]^{-1/2} \quad (4.26)$$

この処理は白色化(球状化)と呼ばれ、多くのICAアルゴリズムで前処理として行われる。 $\mathbf{z}(t)$  を新たな入力信号として、次の式(4.27)で逐次推定を行う。

$$\Delta \mathbf{W} = \eta \left( \mathbf{I} - E \left[ \mathbf{y}(t) \mathbf{y}^T(t) - \{ \varphi(t) \mathbf{y}^T(t) + \mathbf{y}(t) \varphi^T(t) \} \right] \right) \mathbf{W} \quad (4.27)$$

$$\varphi_i(t) = |y_i(t)|^{\alpha_i - 1} \text{sgn}(y_i(t)) \quad (i = 1, 2, \dots, n) \quad (4.28)$$

ここで、 $\eta$  はステップ幅(通常は0.07)、 $\mathbf{y}(t)$  は暫定的な分離信号(=  $\mathbf{W} \mathbf{z}(t)$ )である。 $\alpha_i$  は  $y_i(t)$  の4次キュムラント  $\kappa_i = \frac{E[y_i^4(t)]}{\{E[y_i^2(t)]\}^2} - 3$  の値によって次のように値を変える。

$$\alpha_i = \begin{cases} 0.8 & (\kappa_i > 20) \\ 1 & (0 < \kappa_i \leq 20) \\ 4 & (\kappa_i \geq 0) \end{cases} \quad (4.29)$$

また、 $\text{sgn}(y_i(t))$  は

$$\text{sgn}(y_i(t)) = \begin{cases} 1 & (y_i(t) > 0) \\ 0 & (y_i(t) = 0) \\ -1 & (y_i(t) < 0) \end{cases} \quad (4.30)$$

という符号関数である。

NG-FICAは、 $\mathbf{W}$  を単位行列  $\mathbf{I}$  で初期化し、式(4.27)による更新を値が十分収束するまで繰り返す。

NG-FICAにおいて、入力信号  $\mathbf{x}(t)$  と出力信号  $\mathbf{y}(t)$  の最終的な関係は

$$\mathbf{y}(t) = \mathbf{W} \mathbf{Q} \mathbf{x}(t) \quad (4.31)$$

となる。したがって、最終的な分離行列は  $\mathbf{W} \mathbf{Q}$  となる。

### 4.4.2 Extended Infomax (ExInfomax)

Extended Infomax (ExInfomax) アルゴリズム [32] は, Infomax アルゴリズム [33] の一種である. ExInfomax は, 確率分布の形状が異なるような信号分離を行うことで, 源信号を推定する. 更新式は以下のようになる.

$$\Delta \mathbf{W} = \eta \left[ \mathbf{I} - \mathbf{K} \tanh(\mathbf{y}(t)) \mathbf{y}^T(t) - \mathbf{y}(t) \mathbf{y}^T(t) \right] \mathbf{W} \quad (4.32)$$

ここで,  $N$ 次元の対角行列  $\mathbf{K}$  の  $(i,i)$  要素  $K_{ii}$  は次の通りである.

$$K_{ii} = \text{sgn} \left( E[y_i^4(t)] / E[y_i^2(t)]^2 - 3 \right) \quad (4.33)$$

## 4.5 大域信号除去への組み込み

ICA では源信号数  $m$  を観測信号数  $n$  以下と仮定しているが, 現実において, 信号の発生源は無数に存在する. エネルギーがごく小さい信号に関しては, 観測雑音に埋もれてしまうため, 大域信号などエネルギーの大きな信号の推定にさほど影響を与えない. しかし, エネルギーの大きな源信号を多く含む観測信号をいくつか解析の対象に含んだ場合, 源信号の数が通常の信号分離手法で分離可能な数を超えてしまう可能性がある. その場合, いくつかの源信号が混ざり合った状態, つまり精度の低い源信号を推定してしまう危険がある. よって, 解析対象として適切でない観測信号を避ける必要がある.

ここで, 本研究では大域信号という特定の信号を推定の対象としており, また, これまでの研究から大域信号に関する様々な知見が得られている. そこで, 大域信号の推定に適した, 大域信号以外の源信号をほとんど含んでいない観測信号をあらかじめ選択しておき, それを解析することによって, 大域信号を高い精度で推定することを試みる.

### 4.5.1 使用観測点の選択

本研究において, 大域信号の推定に適した観測信号を選択する基準には, 推定された源信号から大域信号成分を特定する場合と同様の基準を用いる. 具体的には, 前章でも述べた観測信号の概形  $\tilde{x}(t)$

$$\tilde{x}(t) = \frac{1}{n} \sum_i \frac{x_i(t) - E[x_i(t)]}{\sqrt{E[(x_i(t) - E[x_i(t)])^2]}} = \frac{1}{n} \sum_i \frac{x_i(t) - \mu_{x_i}}{\sigma_{x_i}} \quad (4.34)$$

と  $i$  番目の観測信号  $x_i(t)$  との相関係数

$$r_{\tilde{x}x_i} = \frac{E[(\tilde{x}(t) - \bar{\tilde{x}})(x_i(t) - \bar{x}_i)]}{\sqrt{E[(\tilde{x}(t) - \bar{\tilde{x}})^2]} \sqrt{E[(x_i(t) - \bar{x}_i)^2]}} \quad (4.35)$$

を計算し,  $r_{\tilde{x}x_i}$  の大きな観測信号を解析の対象とする.



### 4.5.2 大域信号に対する係数ベクトルの推定

全ての観測信号を解析対象とした場合、大域信号に対する観測点の感度ベクトル  $\hat{\mathbf{b}}$  は、分離信号  $y_j(t)$  を大域信号としたとき、 $\hat{\mathbf{A}}$  の  $j$  番目の列ベクトル  $[\hat{\mathbf{a}}_j = \hat{a}_{1j}, \hat{a}_{2j}, \dots, \hat{a}_{nj}]^T$  となる。しかし、解析する観測信号を減らした場合、分離信号から観測信号を再構成することは不可能であり、分離信号の混合行列が得られない。そこで、大域信号に対する感度ベクトルは、何らかの方法で近似する必要がある。

推定された局所信号には大域信号が混入していないことが理想である。局所信号と大域信号は発生源が異なり、さらに発生源の関連がない。このことから、大域信号と無相関になるような局所信号が得られれば、大域信号除去に成功していると考えることができる。すなわち、各観測点における大域信号に対する感度は、大域信号と局所信号の共分散が0となるように定めればよい。

$i$  番目の局所信号  $l_i(t)$  と大域信号  $y_j(t)$  の共分散は

$$\begin{aligned} & E[(l_i(t) - \bar{l}_i)(y_j(t) - \bar{y}_j)] \\ &= E[\{(x_i(t) - b_i y_j(t)) - (\bar{x}_i - b_i \bar{y}_j)\}(y_j(t) - \bar{y}_j)] \\ &= E[(x_i(t) - \bar{x}_i)(y_j(t) - \bar{y}_j)] - b_i E[(y_j(t) - \bar{y}_j)^2] \end{aligned} \quad (4.36)$$

である。これが0となるような  $b_i$  は、

$$b_i = \frac{E[(x_i(t) - \bar{x}_i)(y_j(t) - \bar{y}_j)]}{E[(y_j(t) - \bar{y}_j)^2]} \quad (4.37)$$

である。この  $b_i$  を要素とするベクトルを大域信号に対する感度ベクトル  $\hat{\mathbf{b}}$  とすることで、大域信号と無相関な局所信号を得る。

## 4.6 シミュレーション実験

ICAを用いた大域信号除去が可能であることを確認するため、ELF帯環境電磁波データを模した擬似信号に対し、大域信号除去の実験を行う。具体的には第3章で用いた擬似信号を再び用いるが、ここで改めて説明する。

まず、図4.2に示す4個の源信号  $\mathbf{s}(t) = [s_1(t), \dots, s_4(t)]^T$  ( $t = 1, 2, \dots, 43200$ ) を生成した。図の縦軸は信号の振幅を、横軸は時系列に相当する  $t$  を表す。また、混合行列  $\mathbf{A}$  は

$$\mathbf{A} = \begin{bmatrix} 1.0151 & 0.0555 & 0.0000 & 0.2294 \\ 1.1204 & 0.0000 & 0.0000 & 0.1043 \\ 1.0185 & 0.0000 & 0.0019 & 0.0000 \\ 1.1892 & 1.3968 & 0.0039 & 0.5161 \\ 1.0895 & 0.0000 & 0.0015 & 0.0000 \\ 1.0228 & 0.0098 & 0.0972 & 0.9991 \\ 1.2059 & 0.0067 & 1.3036 & 0.1044 \\ 1.0489 & 0.7501 & 0.0154 & 0.0000 \\ 1.0164 & 0.0092 & 0.0000 & 0.7375 \\ 1.0028 & 0.0000 & 0.0000 & 0.6062 \\ 1.0130 & 0.1012 & 0.0005 & 0.0152 \\ 1.0069 & 0.0029 & 0.0000 & 0.0177 \end{bmatrix} \quad (4.38)$$

のように定義した。 $s_1(t)$ を大域信号と想定したため、 $\mathbf{A}_1$ は他と比較して大きな値であり、かつ、ほぼ一様にした。 $s_2(t) \sim s_4(t)$ は、少数のいくつかの観測点でのみ有効値で観測可能な異常電磁波を想定したものである。

次に、12個の観測信号  $\mathbf{x}(t)$  を

$$\mathbf{x}(t) = \mathbf{A}\mathbf{s}(t) + \mathbf{e}(t) \quad (4.39)$$

のように作成した。ここで、 $\mathbf{e}(t)$ はガウス雑音の絶対値であり、個々の観測点に依存する雑音あるいは観測点近隣でのみ観測可能な電磁波による信号を想定したものである。作成した観測信号を図4.3に示す。全ての観測信号が、3サイクルの波を持っている。この形は、大域信号である  $s_1(t)$  の影響である。理想的な局所信号、つまり  $\mathbf{x}(t)$  から  $s_1(t)$  を完全に取り除いた信号は、図4.4となる。

全ての観測信号から NG-FICA によって推定された源信号を図4.5に示す。 $y_1(t)$  から  $y_4(t)$  は、波形の上下や推定の順序が違うものの、真の源信号によく似ている。ただし、 $y_1(t)$  と  $y_2(t)$  には  $s_4(t)$  による成分が含まれている。 $y_1(t)$  は大域信号である  $s_1$  を推定したものと断定できるため、これを除去の対象とする。 $y_5(t)$  以降は、ほとんどガウス雑音のような信号である。推定された局所信号を図4.6に示す。観測信号に見られた3サイクルの波が見られなくなっていることが分かる。

選択した観測信号から NG-FICA によって推定された源信号を図4.7に示す。選択数  $r$  は4とした。 $y_1(t)$  は大域信号である  $s_1$  を推定したものと断定できるため、これを除去の対象と




図 4.2: 作成した源信号

表 4.1: 推定された局所信号の SN 比および  $GIC$ 

データ	SNR[dB]	$GIC$
観測信号	-5.073	1.002
推定された局所信号		
理想	—	0.041
平均的な観測信号	6.471	0.120
NG-FICA (全ての観測信号を解析)	7.911	0.278
NG-FICA (選択した観測信号を解析)	13.400	0.061
ExInfomax(全ての観測信号を解析)	4.076	0.191
ExInfomax(選択した観測信号を解析)	13.900	0.058

する.  $y_2(t)$  と  $y_4(t)$  は, それぞれ真の源信号  $s_4(t)$  と  $s_3(t)$  に似た特徴を持っているが, 全ての観測信号を解析した場合よりも, その特徴が薄れている.  $y_3(t)$  は, どの源信号とも対応付けができなかった. 推定された局所信号を図 4.8 に示す. 全ての観測信号を解析した場合とほぼ同様に, 観測信号に見られた 3 サイクルの波が見られなくなっていることが分かる.

推定された局所信号の精度を, SN 比および  $GIC$  に基づいて評価する (表 4.1). 表より, 推定された局所信号の SN 比はどちらも 10[dB] 以上改善しており,  $GIC$  も小さくなっている. また, 解析する観測信号を選択した場合の方が, より改善できている. これらの結果から, 全ての観測信号を解析した場合は様々な源信号を推定できる可能性があるものの, 大域信号のみを精度よく推定したい場合には, 選択した観測信号を解析した方が良いと言える.








図 4.5: NG-FICA によって推定された源信号 (全ての観測信号を解析)




図 4.6: NG-FICA を用いて推定された局所信号 (全ての観測信号を解析)




図 4.7: NG-FICA によって推定された源信号 (選択した観測信号を解析)






図 4.8: NG-FICA を用いて推定された局所信号 (選択した観測信号を解析)




図 4.9: ExInfomax によって推定された源信号 (全ての観測信号を解析)




図 4.10: ExInfomax を用いて推定された局所信号 (全ての観測信号を解析)




図 4.11: ExInfomax によって推定された源信号 (選択した観測信号を解析)




図 4.12: ExInfomax を用いて推定された局所信号 (選択した観測信号を解析)