

(19) 日本国特許庁(JP)

(12) 特許公報(B2)

(11) 特許番号

特許第4978860号
(P4978860)

(45) 発行日 平成24年7月18日(2012.7.18)

(24) 登録日 平成24年4月27日(2012.4.27)

(51) Int.Cl.	F 1				
A 6 1 B	5/0476	(2006.01)	A 6 1 B	5/04	3 2 2
A 6 1 B	5/0484	(2006.01)	A 6 1 B	5/04	3 2 0 M
A 6 1 B	5/0408	(2006.01)	A 6 1 B	5/04	3 0 0 M
A 6 1 B	5/0478	(2006.01)	A 6 1 B	5/05	A
A 6 1 B	5/05	(2006.01)	A 6 1 B	10/00	E

請求項の数 12 (全 16 頁) 最終頁に続く

(21) 出願番号	特願2007-14220 (P2007-14220)	(73) 特許権者	393031586 株式会社国際電気通信基礎技術研究所
(22) 出願日	平成19年1月24日(2007.1.24)		京都府相楽郡精華町光台二丁目2番地2
(65) 公開番号	特開2008-178546 (P2008-178546A)	(74) 代理人	100078868 弁理士 河野 登夫
(43) 公開日	平成20年8月7日(2008.8.7)	(74) 代理人	100114557 弁理士 河野 英仁
審査請求日	平成21年11月24日(2009.11.24)	(72) 発明者	佐藤 雅昭 京都府相楽郡精華町光台二丁目2番地2 株式会社国際電気通信基礎技術研究所内
		(72) 発明者	山下 宙人 京都府相楽郡精華町光台二丁目2番地2 株式会社国際電気通信基礎技術研究所内

最終頁に続く

(54) 【発明の名称】 行動予測方法及び行動予測装置

(57) 【特許請求の範囲】

【請求項 1】

観測対象者の脳活動を時系列的に観測し、得られた観測データに基づいて前記観測対象者の行動を予測する行動予測方法において、

前記観測データを前記観測対象者の脳内の複数の電流源における時系列データに写像するフィルタを設定するステップと、設定したフィルタによって写像される時系列データの入力に対して前記観測対象者が特定の行動を起こす確率を出力する確率モデルを設定するステップと、新たに取得した観測データを前記フィルタにより前記電流源における時系列データに変換するステップと、変換した時系列データを設定した確率モデルに入力することにより前記確率を算出するステップとを有し、算出した確率に基づいて前記観測対象者の行動を予測することを特徴とする行動予測方法。

【請求項 2】

予測すべき行動の数だけ前記フィルタを設定し、各フィルタの前記確率への寄与度を算出するステップを更に有することを特徴とする請求項 1 に記載の行動予測方法。

【請求項 3】

前記確率モデルは、学習すべきパラメータを含み、前記観測対象者が前記特定の行動を実行した際に観測される観測データに基づいて前記パラメータを学習するステップを更に有することを特徴とする請求項 1 又は請求項 2 に記載の行動予測方法。

【請求項 4】

前記パラメータをベイズ推定法を用いて学習するステップを有することを特徴とする請

求項 3 に記載の行動予測方法。

【請求項 5】

前記確率モデルは、前記時系列データの入力に応じたスカラー値を出力する判別関数と、該判別関数の出力値に応じて所定値域の値を出力するロジスティック関数とにより記述されることを特徴とする請求項 1 乃至請求項 4 の何れか 1 つに記載の行動予測方法。

【請求項 6】

前記確率モデルは、スパースロジスティック回帰モデルであることを特徴とする請求項 1 乃至請求項 5 の何れか 1 つに記載の行動予測方法。

【請求項 7】

観測対象者の脳活動を時系列的に観測し、得られた観測データに基づいて前記観測対象者の行動を予測する行動予測装置において、

前記観測データを前記観測対象者の脳内の複数の電流源における時系列データに写像するフィルタを設定する手段と、設定したフィルタによって写像される時系列データの入力に対して前記観測対象者が特定の行動を起こす確率を出力する確率モデルを設定する手段と、新たに取得した観測データを前記フィルタにより前記電流源における時系列データに変換する手段と、変換した時系列データを設定した確率モデルに入力することにより前記確率を算出する手段とを備え、算出した確率に基づいて前記観測対象者の行動を予測するようにしてあることを特徴とする行動予測装置。

【請求項 8】

予測すべき行動の数だけ前記フィルタを設定し、各フィルタの前記確率への寄与度を算出する手段を更に備えることを特徴とする請求項 7 に記載の行動予測装置。

【請求項 9】

前記確率モデルは、学習すべきパラメータを含み、前記観測対象者が前記特定の行動を実行した際に観測される観測データに基づいて前記パラメータを学習する手段を更に備えることを特徴とする請求項 7 又は請求項 8 に記載の行動予測装置。

【請求項 10】

前記パラメータをベイズ推定法を用いて学習するようにしてあることを特徴とする請求項 9 に記載の行動予測装置。

【請求項 11】

前記確率モデルは、前記時系列データの入力に応じたスカラー値を出力する判別関数と、該判別関数の出力値に応じて所定値域の値を出力するロジスティック関数とにより記述されることを特徴とする請求項 7 乃至請求項 10 の何れか 1 つに記載の行動予測装置。

【請求項 12】

前記確率モデルは、スパースロジスティック回帰モデルであることを特徴とする請求項 7 乃至請求項 11 の何れか 1 つに記載の行動予測装置。

【発明の詳細な説明】

【技術分野】

【0001】

本発明は、脳活動の情報から行動を予測する行動予測方法及び行動予測装置に関する。

【背景技術】

【0002】

近年の生体計測技術の進歩はめざましく、従来では測定が困難で誤差も大きかった脳から発生する微弱電場（脳波）及び微弱磁場（脳磁波）の計測精度が年々向上している。

【0003】

脳活動を計測する目的としては、脳のどの部位が感覚、運動などの認知に関わるかを知らることが挙げられる。そのため、脳内の活動を高い空間分解能、また場合によっては高い時間分解能で観測することが求められている。非侵襲的に脳活動を計測する計測手段として、神経細胞脳電気活動由来の電気現象を計測する E E G (electroencephalogram) 及び M E G (magnetoencephalogram)、神経細胞発火後の二次的な現象として起こる脳血流又は代謝の変化を計測する f M R I (functional magnetic resonance imaging)、N I R

10

20

30

40

50

S (Near Infrared Spectroscopy)、PET (positron emission tomography) 等が知られている。

【特許文献1】国際公開第03/057035号パンフレット

【発明の開示】

【発明が解決しようとする課題】

【0004】

しかしながら、前述したEEG、MEG計測は、時間分解能に優れており、神経活動に直接由来する電気現象を非侵襲的に観測することができるという利点を有している。しかしながら、その一方で、EEG、MEG計測は、計測地点が脳の内部ではなく頭蓋外部に配置したセンサにより計測しており、また、神経細胞の電気活動が物理法則に従って拡散した電場又は磁場を計測しているため、EEG、MEG計測のみから脳内の電気活動を推定するには空間分解能に関して原理的な制限が存在する。

10

【0005】

特に、外部から予期しない刺激が入力された場合、センサ空間における特徴量に対する外乱の影響を予測することは困難であるという問題点を有している。

【0006】

本発明は斯かる事情に鑑みてなされたものであり、観測データを観測対象者の脳内の複数の電流源における時系列データに写像するフィルタを設定し、設定したフィルタによって写像される時系列データの入力に対して観測対象者が特定の行動を起こす確率を出力する確率モデルを設定し、新たに取得した観測データを前記フィルタにより電流源における時系列データに変換し、変換した時系列データに基づいて特定の行動を起こす確率を算出する構成とすることにより、外部から予期せぬ外乱が入力された場合であっても、行動予測を高精度に実施することができる行動予測方法及び行動予測装置を提供することを目的とする。

20

【課題を解決するための手段】

【0007】

第1発明に係る行動予測方法は、観測対象者の脳活動を時系列的に観測し、得られた観測データに基づいて前記観測対象者の行動を予測する行動予測方法において、前記観測データを前記観測対象者の脳内の複数の電流源における時系列データに写像するフィルタを設定するステップと、設定したフィルタによって写像される時系列データの入力に対して前記観測対象者が特定の行動を起こす確率を出力する確率モデルを設定するステップと、新たに取得した観測データを前記フィルタにより前記電流源における時系列データに変換するステップと、変換した時系列データを設定した確率モデルに入力することにより前記確率を算出するステップとを有し、算出した確率に基づいて前記観測対象者の行動を予測することを特徴とする。

30

【0008】

第2発明に係る行動予測方法は、予測すべき行動の数だけ前記フィルタを設定し、各フィルタの前記確率への寄与度を算出するステップを更に有することを特徴とする。

【0009】

第3発明に係る行動予測方法は、前記確率モデルは、学習すべきパラメータを含み、前記観測対象者が前記特定の行動を実行した際に観測される観測データに基づいて前記パラメータを学習するステップを更に有することを特徴とする。

40

【0010】

第4発明に係る行動予測方法は、前記パラメータをベイズ推定法を用いて学習するステップを有することを特徴とする。

【0011】

第5発明に係る行動予測方法は、前記確率モデルは、前記時系列データの入力に応じたスカラー値を出力する判別関数と、該判別関数の出力値に応じて所定値域の値を出力するロジスティック関数とにより記述されることを特徴とする。

【0012】

50

第6発明に係る行動予測方法は、前記確率モデルは、スパースロジスティック回帰モデルであることを特徴とする。

【0013】

第7発明に係る行動予測装置は、観測対象者の脳活動を時系列的に観測し、得られた観測データに基づいて前記観測対象者の行動を予測する行動予測装置において、前記観測データを前記観測対象者の脳内の複数の電流源における時系列データに写像するフィルタを設定する手段と、設定したフィルタによって写像される時系列データの入力に対して前記観測対象者が特定の行動を起こす確率を出力する確率モデルを設定する手段と、新たに取得した観測データを前記フィルタにより前記電流源における時系列データに変換する手段と、変換した時系列データを設定した確率モデルに入力することにより前記確率を算出する手段とを備え、算出した確率に基づいて前記観測対象者の行動を予測するようにしてあることを特徴とする。

10

【0014】

第8発明に係る行動予測装置は、予測すべき行動の数だけ前記フィルタを設定し、各フィルタの前記確率への寄与度を算出する手段を更に備えることを特徴とする。

【0015】

第9発明に係る行動予測装置は、前記確率モデルは、学習すべきパラメータを含み、前記観測対象者が前記特定の行動を実行した際に観測される観測データに基づいて前記パラメータを学習する手段を更に備えることを特徴とする。

【0016】

20

第10発明に係る行動予測装置は、前記パラメータをベイズ推定法を用いて学習するようにしてあることを特徴とする。

【0017】

第11発明に係る行動予測装置は、前記確率モデルは、前記時系列データの入力に応じたスカラー値を出力する判別関数と、該判別関数の出力値に応じて所定値域の値を出力するロジスティック関数とにより記述されることを特徴とする。

【0018】

第12発明に係る行動予測装置は、前記確率モデルは、スパースロジスティック回帰モデルであることを特徴とする。

【0019】

30

第1発明及び第7発明にあつては、観測データを観測対象者の脳内の複数の電流源における時系列データに写像するフィルタを設定し、設定したフィルタによって写像される時系列データの入力に対して観測対象者が特定の行動を起こす確率を出力する確率モデルを設定し、新たに取得した観測データを前記フィルタにより電流源における時系列データに変換し、変換した時系列データに基づいて特定の行動を起こす確率を算出するようにしているため、EEGやMEGなどのセンサ空間における特徴量を利用した従来の予測手法と異なり、脳内電流源を推定した上で行動予測する本願手法では、外乱などのセンサノイズの影響が最小限に抑えられる。

【0020】

第2発明及び第8発明にあつては、予測すべき行動の数だけフィルタを設定し、各フィルタの確率への寄与度を算出するようにしているため、観測データ自体がある種のカテゴリに分けられる場合に当該モデルを使用することができる。

40

【0021】

第3発明及び第9発明にあつては、設定する確率モデルは、学習すべきパラメータを含み、観測対象者が特定の行動を実行した際に観測される観測データに基づいてパラメータを学習するようにしているため、事前学習によって得られるパラメータを用いて観測対象者が実行する行動の予測が可能となる。

【0022】

第4発明及び第10発明にあつては、パラメータをベイズ推定法を用いて学習する。パラメータの次元が高次である場合にはモンテカルロ法などの数値解析法は実用的ではない

50

ため、本発明では変分ベイズ推定法が用いられる。

【0023】

第5発明及び第11発明にあつては、確率モデルを時系列データの入力に応じたスカラー値を出力する判別関数と判別関数の出力値に応じて所定値域の値を出力するロジスティック関数とにより記述する。すなわち、本発明で用いる確率モデルは、複数のカテゴリに分類できるデータの観測過程をモデル化したものであり、このような回帰モデルを用いることにより、観測データが入力された場合、その観測データが複数のカテゴリのうち何れに属するかを判別することができる。

【0024】

第6発明及び第12発明にあつては、設定する確率モデルとしてスパースロジスティック回帰モデルを用いるため、確率モデルの解がスパースネスになるという性質が利用され、使用するデータの次元数が大幅に削減される。

【発明の効果】

【0025】

第1発明及び第7発明による場合は、観測データを観測対象者の脳内の複数の電流源における時系列データに写像するフィルタを設定し、設定したフィルタによって写像される時系列データの入力に対して観測対象者が特定の行動を起こす確率を出力する確率モデルを設定し、新たに取得した観測データを前記フィルタにより電流源における時系列データに変換し、変換した時系列データに基づいて特定の行動を起こす確率を算出するようにしている。したがって、EEGやMEGなどのセンサ空間における特徴量を利用した従来の予測手法と異なり、脳内電流源を推定した上で行動予測する本願手法では、外乱などのセンサノイズの影響を最小限に抑えることができ、行動予測を高精度に行うことができる。

【0026】

第2発明及び第8発明による場合は、予測すべき行動の数だけフィルタを設定し、各フィルタの確率への寄与度を算出するようにしている。したがって、観測データ自体がある種のカテゴリに分けられる場合に当該モデルを使用することができる。

【0027】

第3発明及び第9発明による場合は、設定する確率モデルは、学習すべきパラメータを含み、観測対象者が特定の行動を実行した際に観測される観測データに基づいてパラメータを学習するようにしている。したがって、事前学習によって得られるパラメータを用いて観測対象者が実行する行動を予測することができる。

【0028】

第4発明及び第10発明による場合は、パラメータをベイズ推定法を用いて学習する。パラメータの次元が高次である場合にはモンテカルロ法などの数値解析法は実用的ではないが、本発明では変分ベイズ推定法を用いて確率モデルに含まれるパラメータを求めることができる。

【0029】

第5発明及び第11発明による場合は、確率モデルを時系列データの入力に応じたスカラー値を出力する判別関数と判別関数の出力値に応じて所定値域の値を出力するロジスティック関数とにより記述する。すなわち、本発明で用いる確率モデルは、複数のカテゴリに分類できるデータの観測過程をモデル化したものであり、このような回帰モデルを用いることにより、観測データが入力された場合、その観測データが複数のカテゴリのうち何れに属するかを判別することができる。

【0030】

第6発明及び第12発明による場合は、設定する確率モデルとしてスパースロジスティック回帰モデルを用いている。したがって、確率モデルの解がスパースネスになるという性質が利用され、使用するデータの次元数を大幅に削減することができる。その結果、推定精度が劣化せずに済み、高精度に行動予測を行うことができる。

【発明を実施するための最良の形態】

【0031】

10

20

30

40

50

以下、本発明をその実施の形態を示す図面に基づいて具体的に説明する。

図1は脳活動を観測する観測手段としてのブレインキャップを示す模式図である。ブレインキャップ10は、人間の頭部を覆う帽子状のホルダ10Aに、第1センサ11及び第2センサ12を複数個(例えば、数十個~数百個)ずつ設けた構成をなしている。これらの第1センサ11及び第2センサ12は等ピッチ(例えば、数ミリメートル間隔)で配置されている。

【0032】

第1センサ11は、例えば、脳活動の際に生じる電気活動を非侵襲的に計測するための脳波計(EEG)センサである。ブレインキャップ10に配置された第1センサ11は、脳波計(EEG)を構成し、各センサ11, 11, ...が設置された位置にて脳活動に伴う脳磁場の経時的变化を計測して出力する。第1センサ11は時間分解能に優れており、ミリ秒単位での計測が可能である。

10

【0033】

第2センサ12は、例えば、NIRSの近赤外センサであって、比較的短い波長を持つ赤外光を出射する発光素子とその赤外光の反射光を受ける受光素子とが一組として構成されており、発光素子からの出射光の脳内での吸収量に基づいて脳血流の状態を非侵襲的に計測する。各センサ12, 12, ...は、自身が設置された各部位における脳血流を計測して出力する。第2センサ12は、電場又は磁場のように他の領域からの影響を受けないため空間分解能に優れており、数ミリメートル~数十ミリメートル単位での計測が可能である。

20

【0034】

このような第1センサ11及び第2センサ12は、小型の構成であっても脳活動を観測することができるため、前述したようなブレインキャップ10に簡単に取り付けることができ、大型の構成を必要としない。

【0035】

本実施の形態では、図1に示したブレインキャップ10を利用して被験者の脳活動を時系列的に観測し、得られた観測データに基づいて被験者の行動を予測する。なお、本明細書における行動とは、外観から観察可能な動作、反応、行為だけでなく、被験者の精神状態も含むものとする。

【0036】

30

図2はブレインキャップ10の観測データから被験者の行動を予測する行動予測装置の構成を示す模式図である。被験者の頭部に装着されるブレインキャップ10には、第1センサ11及び第2センサ12が出力する信号を集計する集計装置20が接続されている。集計装置20には、データ処理装置100と無線通信を行うための通信装置30が接続されている。本実施の形態では、ブレインキャップ10の第1センサ11及び第2センサ12が取得したデータを通信装置30を通じてデータ処理装置100へ送信し、データ処理装置100にて被験者の行動を予測する。

【0037】

データ処理装置100は、具体的には、パーソナルコンピュータ、ワークステーション等であり、ブレインキャップ10に接続された通信装置30から送信されるデータの解析を行う。データ処理装置100は、CPU101を備えており、このCPU101には、ROM103、RAM104、HDD105、通信IF106、入力IF107、出力IF108等のハードウェアがバス102を介して接続されている。CPU101には、ROM103に予め格納された制御プログラムをRAM104上にロードして実行することにより、前述のハードウェア各部を制御し、全体として本発明に係る行動予測装置として機能させる。

40

【0038】

HDD105は、磁気記録媒体を有する記憶装置であり、通信IF106にて受信したデータ、そのデータに基づく解析結果等を記憶する。入力IF107は、データ処理装置100の外部にキーボード、マウス等の入力デバイス110を接続するためのインタフェ

50

ースであり、解析開始指示、解析結果の出力指示等の操作を受付ける。出力 I F 1 0 8 は、液晶ディスプレイ装置、プリンタ装置等の出力デバイス 1 2 0 を接続するためのインタフェースであり、受信したデータ、解析結果等を出力する。

【 0 0 3 9 】

以下、データ処理装置 1 0 0 を用いて被験者の行動を予測する手法について具体的に説明する。本実施の形態では、通信 I F 1 0 6 を通じて取得する観測データを訓練データとして判別器（データ処理装置 1 0 0）の内部パラメータを決定し、新たな観測データ（テストデータ）が入力された場合、決定したパラメータを用いて設定される確率モデルにより、ある特定の行動が起きる確率を算出することによって行動予測を行う。

【 0 0 4 0 】

図 3 はデータ処理装置 1 0 0 が実行する処理の手順を示すフローチャートである。データ処理装置 1 0 0 は、まず、通信 I F 1 0 6 を通じて訓練データを取得する（ステップ S 1 1）。そして、訓練データを用いて階層ベイズ推定法により脳内電流源を特定する（ステップ S 1 2）。脳内電流源の特定は、本願発明者らが特願 2 0 0 5 - 1 0 7 9 5 2 明細書で開示している手法を用いることができる。すなわち、特願 2 0 0 5 - 1 0 7 9 5 2 明細書では、脳内に存する電流源の時空間分布を第 1 の分解能で推定する第 1 領域と第 1 の分解能より低い第 2 の分解能で推定する第 2 領域とを設定し、設定した第 1 及び第 2 領域での電流源の時空間分布を、対象者の頭蓋外部にて観測した電気現象に基づいて推定するようにしており、高精度に推定したい領域に重点的にパラメータを分配することによってパラメータの増大に伴う推定精度の劣化を防止することができる。

【 0 0 4 1 】

前述した推定手法では、最適逆フィルタ推定を行うことにより電流源の推定を行っているが、空間逆フィルタがデータ適合型フィルタであることから判別手法には何通りかのバリエーションが存在する。本実施の形態では、こういった条件別フィルタを用いた判別問題に対して混合モデルによる重み付き判別手法について説明する。

【 0 0 4 2 】

判別手法としてスパースロジスティック回帰モデルを用いる。ロジスティック回帰モデルは、2 カテゴリーカルのデータの観測過程をモデル化した確率モデルであり、特徴量ベクトル $\mathbf{x} \in \mathbb{R}^d$ の時に分類ラベル $y \in \{0, 1\}$ が観測される確率によってモデリングされる。複数のカテゴリーを分類する場合はマルチノミナルモデルを用いて以下の議論を拡張することができる。i 番目のサンプルを $\{y_i, \mathbf{x}_i\}$ で表し、N サンプル得られたとする。また、N サンプルまとめたラベル及び特徴量をそれぞれ $\mathbf{y} = \{y_1, \dots, y_N\}$ 、 $\mathbf{X} = \{\mathbf{x}_1, \dots, \mathbf{x}_N\}$ で表した場合、ロジスティック回帰モデルは次式で表すことができる。

【 0 0 4 3 】

【数 1】

$$P(\mathbf{y} | \mathbf{X}; \theta) = \prod_{i=1}^N p_i^{y_i} (1 - p_i)^{1-y_i}$$

$$p_i = \sigma(f(\mathbf{x}_i; \theta))$$

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

【 0 0 4 4 】

つまり、特徴量 \mathbf{x}_i がラベル 1 のカテゴリーに属すると判断される確率 p_i は、特徴量 \mathbf{x}_i をパラメータでモデリングされたスカラー値関数 $f(\mathbf{x}_i; \theta)$ によってマッピングし、さらに数式 (1) の $\sigma(u)$ によって値域 $(0, 1)$ に写像した値によってモデリングされる。数式 (1) の $\sigma(u)$ はロジスティック関数と呼ばれ、ロジスティック回帰と

10

20

30

40

50

呼ばれる由縁である。スカラー値関数 $f(x; \theta)$ は判別関数と呼ばれ、ラベルが分からない新しいデータ x が入ってきたときに、 $f(x; \theta)$ の値と 0 との大小によって、ラベル 1 に属するかラベル 0 に属するかを決定する際に使われる。実用上よく使われるものは線形判別関数であり、このとき、 $f(x; \theta) = x^t \theta$ で表される。本実施の形態では、線形判別関数のみを用いる。非線形関数モデルであるカーネル関数を用いた手法も基本的にはパラメータに関して線形であるので、以下同じ議論は可能である。

【0045】

パラメータ θ は、最尤推定法によって N 個の $\{y_i, x_i\}$ のサンプルから、数式(1)に示される $P(y | X; \theta)$ のトータルの観測確率が最大となるように推定される。

【0046】

【数2】

$$\hat{\theta} = \arg \max \log P(\mathbf{y} | \mathbf{X}; \theta)$$

【0047】

実際の判別問題では、特徴量とラベルが既知の訓練データとから、パラメータ θ を最尤法により推定値 $\hat{\theta}$ を計算し、ラベルが分かっていないテストデータ x_{test} に対して、

【0048】

【数3】

$$f(x_{test}; \hat{\theta}) = x_{test}^t \hat{\theta} < 0 \quad \text{のとき、ラベル0}$$

$$f(x_{test}; \hat{\theta}) = x_{test}^t \hat{\theta} > 0 \quad \text{のとき、ラベル1}$$

【0049】

と判別する。また、ラベルが 1 であるという確率は、次式で与えられ、判別の確信度をこの確率を用いて表すことができる。

【0050】

【数4】

$$p_{test} = \sigma(x_{test}^t \hat{\theta})$$

【0051】

スパースロジスティック回帰モデルは、ベイズ推定版のロジスティック回帰モデルであり、数式(1)に加えて、パラメータ θ の各成分 θ_j の事前分布として平均 0、分散 σ_j^2 の正規分布を仮定し、さらに、逆分散 σ_j^2 も無情報事前分布によってモデル化する。 σ_j^2 は対応するパラメータ θ_j がどれだけ推定に重要であるかを決定する変数であり、 σ_j^2 が小さいほど重要度が高くなる。

【0052】

スパースロジスティック回帰モデルを数式でまとめた場合、以下の式で表すことができる。

【0053】

10

20

30

40

【数5】

$$P(\mathbf{y} | \mathbf{X}; \boldsymbol{\theta}) = \prod_{n=1}^N p_i^{y_i} (1 - p_i)^{1 - y_i} \quad (p_i = \sigma(x_i^t \boldsymbol{\theta}))$$

$$P(\theta_i | \alpha_i) = N(0, \alpha_i^{-1}) \quad \text{for } i = 1, \dots, N$$

$$P_0(\alpha_i) = \alpha_i^{-1} \quad \text{for } i = 1, \dots, N$$

10

【0054】

パラメータ及びハイパーパラメータ $\{\alpha_1, \dots, \alpha_D\}$ は、以下の式で表されるベイズ事後確率が最大をとる値として計算される。

【0055】

【数6】

$$P(\boldsymbol{\theta} | \mathbf{y}, \mathbf{X}) = \int d\boldsymbol{\alpha} p(\boldsymbol{\theta}, \boldsymbol{\alpha} | \mathbf{y}, \mathbf{X})$$

$$P(\boldsymbol{\alpha} | \mathbf{y}, \mathbf{X}) = \int d\boldsymbol{\theta} p(\boldsymbol{\theta}, \boldsymbol{\alpha} | \mathbf{y}, \mathbf{X})$$

$$(P(\boldsymbol{\theta}, \boldsymbol{\alpha} | \mathbf{y}, \mathbf{X}) \propto P(\mathbf{y} | \mathbf{X}, \boldsymbol{\theta}) P(\boldsymbol{\theta} | \boldsymbol{\alpha}) P_0(\boldsymbol{\alpha}))$$

20

【0056】

しかし、数式(6)の右辺の積分は解析的に行うことが困難であり、モンテカルロ法などの数値解析法、又は変分ベイズ法などの近似解法が必要となる。パラメータの次元が高次のときモンテカルロ法は実用的ではないため、本実施の形態では変分ベイズ法に基づいた推定アルゴリズムを用いる。

【0057】

この推定アルゴリズムをパラメータが収束するまで適用して得られる推定値ハットは、判別に有効な要素以外の多くが0となるスパースな解をもつ。これは数式(5)で与えられるベイズ事前分布を α_i で周辺化した事前分布 $P(\alpha_i) = \alpha_i^{-1}$ (ただし、 $i = 1, \dots, D$) の形から分かるように $\alpha_i \rightarrow 0$ の極限で無限の確率をとるような事前分布となっているためである。つまり、この事前分布は尤度関数 $P(\mathbf{y} | \mathbf{X}; \boldsymbol{\theta})$ に対して0の値に高い確率を持つような正規化の役割を果たす。

30

【0058】

スパースロジスティック回帰モデルの解がスパースネスになるという応用上、非常に重要な情報を与える。EEGやMEGデータのように膨大な計測データが入力データとなる場合、そもそもどの特徴量を使ったら良いか分かっていることは稀である。しかも多くの場合、判別精度は適切な特徴量の選択に依存する。線形判別関数 $f(\mathbf{x}; \boldsymbol{\theta}) = \mathbf{x}^t \boldsymbol{\theta} = \sum_i \theta_i x_i$ におけるスパースなパラメータ推定は、その形をみて分かるように、推定値0に対応する特徴量を使わないことを意味する。すなわち、スパースロジスティック回帰では、パラメータの推定結果として特徴量ベクトル \mathbf{x} の中から自動的に判別に効果的な特徴量だけを抜き出しているわけである。したがって、初めにラフに大きな次元の初期特徴量ベクトルを入力し、スパースロジスティック回帰によって学習すればよいことになる。その結果、構成される判別器は判別に有効な特徴量だけを用いたものとなる。

40

【0059】

次に、混合スパースロジスティック回帰モデルについて説明する。混合スパースロジスティックモデルは、複数のスパースロジスティック回帰モデルの混合比による重み付きで判別するモデルである。このモデルは、後述する電流源空間での判別の例のように、特徴

50

量自体がある種のカテゴリに分けられ、各モデルの混合比が計算できるときに有用である。

【 0 0 6 0 】

以下では混合分布を K 個とし、サンプル i についての混合比を $g_i^{(1)}, \dots, g_i^{(K)}$ とした場合、混合スパースロジスティック回帰モデル（確率モデル）を以下の式により設定する（ステップ S 1 3）。

【 0 0 6 1 】

【数 7】

$$P(\mathbf{y} | \mathbf{X}; \theta) = \prod_{i=1}^N \left(\sum_{k=1}^K g_i^{(k)} P(y_i | \mathbf{X}^{(k)}; \theta^{(k)}) \right) \quad 10$$

【 0 0 6 2 】

ここで、 $P(y | \mathbf{X}^{(k)}; \theta^{(k)})$ は入力特徴量の値を $\mathbf{X}^{(k)}$ とするスパースロジスティック回帰モデル（数式（5）を参照）である。

【 0 0 6 3 】

以下にコンポーネントの数が K 個の場合のアルゴリズムについて説明する。

【 0 0 6 4 】

初期パラメータを $\alpha_i^{(k)} = 0, \beta_i^{(k)} = 1$ （ただし、 $i = 1, \dots, D, k = 1, \dots, K$ ）とする。事前混合比 $g_i^{(1)}, \dots, g_i^{(K)}$ は、条件ごとに空間フィルタを考える場合、データを再構成したときのフィッティングの良さの割合で評価して設定すればよい。

【 0 0 6 5 】

次いで、データ処理装置 1 0 0 はパラメータの推定を行う（ステップ S 1 4）。このとき、事後混合比は次式により与えられる。

【 0 0 6 6 】

【数 8】

$$\bar{z}_i^{(k)} = E[z_i^{(k)} | y_i, \theta, \alpha] = \frac{g_i^{(k)} P(y_i | \mathbf{X}^{(k)}, \theta^{(k)}, \alpha^{(k)})}{\sum_{j=1}^K g_i^{(j)} P(y_i | \mathbf{X}^{(j)}, \theta^{(j)}, \alpha^{(j)})} \quad 30$$

【 0 0 6 7 】

また、推定値 $\hat{\theta}$ は次式により与えられる。

【 0 0 6 8 】

【数 9】

$$\hat{\theta} = \arg \max_{\theta} \sum_{k=1}^K \left(\sum_{i=1}^N \bar{z}_i^{(k)} \left\{ y_i \log \sigma(\mathbf{x}_i^{(k)t} \theta^{(k)}) + (1 - y_i) \log(1 - \sigma(\mathbf{x}_i^{(k)t} \theta^{(k)})) \right\} - \frac{1}{2} \theta^{(k)t} A^{(k)} \theta^{(k)} \right) \quad 40$$

ただし、 $A^{(k)} = \text{diag}(\alpha_1^{(k)}, \dots, \alpha_D^{(k)})$

【 0 0 6 9 】

最大化は各コンポーネントごとに、勾配とヘシアン行列とを用いてニュートン法によって行う。ここで、勾配 $g^{(k)}$ 、ヘシアン行列 $H^{(k)}$ 、最大値における事後分散 $S^{(k)}$ は次

式で与えられる。

【 0 0 7 0 】

【 数 1 0 】

$$g^{(k)} = \sum_{i=1}^N \bar{z}_i^{(k)} \left\{ y_i - \sigma(\mathbf{x}_i^{(k)t} \boldsymbol{\theta}^{(k)}) \right\} \mathbf{x}_i^{(k)} - \mathbf{A}^{(k)} \boldsymbol{\theta}^{(k)}$$

$$H^{(k)} = -\mathbf{X}^{(k)} B^{(k)} \mathbf{X}^{(k)t} - A^{(k)}$$

$$S^{(k)} = \left(\mathbf{X}^{(k)} B^{(k)} \mathbf{X}^{(k)t} + A^{(k)} \right)^{-1}$$

10

ただし、

$$B^{(k)} = \text{diag} \left(\bar{z}_1^{(k)} (1 - \sigma(\mathbf{x}_1^{(k)t} \boldsymbol{\theta}^{(k)})) \sigma(\mathbf{x}_1^{(k)t} \boldsymbol{\theta}^{(k)}), \dots, \bar{z}_N^{(k)} (1 - \sigma(\mathbf{x}_N^{(k)t} \boldsymbol{\theta}^{(k)})) \sigma(\mathbf{x}_N^{(k)t} \boldsymbol{\theta}^{(k)}) \right)$$

【 0 0 7 1 】

次いで、データ処理装置 1 0 0 は分散の推定を行う（ステップ S 1 5）。逆分散 を以下の式により推定する。

20

【 0 0 7 2 】

【 数 1 1 】

$$\alpha_i^{(k)} = \frac{1 - \alpha_i^{(K)} S_{ii}^{(k)}}{\left(\theta_i^{(k)} \right)^2}$$

【 0 0 7 3 】

次いで、データ処理装置 1 0 0 はパラメータが収束したか否かを判断し（ステップ S 1 6）、パラメータが収束していないと判断した場合（S 1 6：NO）、処理をステップ S 1 4 へ戻し、パラメータの値が収束するまで、パラメータの推定（S 1 4）及び分散の推定（S 1 5）を行う。

30

【 0 0 7 4 】

パラメータが収束したと判断した場合（S 1 6：YES）、行動予測のためにデータ処理装置 1 0 0 は脳活動の観測データ（テストデータ）を通信 I F 1 0 6 を通じて取得し（ステップ S 1 7）、前述のステップ S 1 1 ~ S 1 6 の処理により得られる確率モデルによりトータル確率を算出する（ステップ S 1 8）。そして、算出結果に基づいて行動の予測を行う（ステップ S 1 9）。

【 0 0 7 5 】

40

次に、MEG データへの適用例について説明する。図 4 は実験手法を説明する説明図である。1750 ミリ秒間の実験で、プレキュー時間（250 ミリ秒）、キュー期間（1000 ミリ秒）、刺激期間（500 ミリ秒）からなる。プレキュー期間では、被験者は特に何もせずにスクリーン上の固定点（例えば、黒い小さなサークル）を見続ける。その後、注意を向けるキューとして、黒いサークルがカラー（C）又は動き（M）に変化し、被験者は指示された対象に注意を向ける。実際の実験では、1つのセッションでは常に同じキューを表示するようにしているため、キューは被験者が注意を向けるタイミングの指示として使われると理解できる。1000 ミリ秒のキュー期間の後、色（赤または青）のついたランダムドットが外向き又は内向きに500 ミリ秒だけ動く。被験者は指示によって、注意を向けていた属性について反応する。すなわち、色注意なら赤又は青ということにな

50

り、動き注意なら外向き又は内向きということになる。

【0076】

解析では、瞬きなどのアーティファクトの入っているトライアルの除去、正常に働いていないセンサの除去、100Hzのデジタルローパスフィルタによる前処理を行った。実際に解析したデータはセンサ数186、トライアル数136（色注意のトライアル数を65、動き注意のトライアル数を71）、被験者が注意を向けているキュー期間は1000ミリ秒である。

【0077】

時刻 t に M 個のセンサにおいて計測したMEGデータを $b_t = (b_{t,1}, \dots, b_{t,M})^t$ とする。センサ空間における判別では、 M 個のセンサ全部又は一部を選択し、その時系列を加工して特徴量をつくる。一方、脳皮質における判別では、電流源推定問題を解くことによって得られるセンサ空間から皮質空間への写像（空間フィルタ）をまず適用し、写像した空間における時系列データを用いる。階層ベイズ法では空間フィルタは線形となり、それを表す行列を F とした場合、 $j_t = F B_t$ によって得られる脳活動電流源の時系列データ $j_t = (j_{t,1}, \dots, j_{t,L})^t$ が得られる。このデータから興味ある脳部位を特定し、時系列データの一部を特徴量として用いる。

10

【0078】

次に、センサ空間における判別と電流源空間における判別との比較を行う。センサ空間における判別に用いる特徴量として、後頭に位置する22のチャンネルにおける次数10の移動平均フィルタで平滑化した後、100Hzにダウンサンプリングしたデータ点を用いた。特徴量が $[1, -1]$ の範囲に収まるように訓練データの平均を引き、最大値で割ることによって正規化を行った。

20

【0079】

脳皮質上の特徴量として、例えば、前述した手法により同定された6つの興味ある領域（V4-Left, V4-Right, MT-Left, MT-Right, SMG-Left, Parietal-Right）において、ピーク強度を持つ皮質頂点を選択した。選ばれた皮質点の電流時系列データは、推定によるばらつきを考慮するために事後分布の平方根で割り、センサ空間における判別と同じく、時間方向には次数10の移動平均フィルタで平滑化した後100Hzにダウンサンプリングした。また、特徴量の値が $[1, -1]$ の範囲に収まるように訓練データの平均を引き、絶対値の最大値で割ることによって正規化を行った。

30

【0080】

階層ベイズ法では空間フィルタは各条件ごとに F_{color} 、 F_{motion} のように計算されるため、電流源に写像した時点ですでにラベルの情報が含まれる。実際の判別では、ラベルの情報は分かっていないので、どちらの空間フィルタを適用するかそれ自体が問題である。そのため、判別問題を解くときは、判別されるべきMEGデータに F_{color} 、 F_{motion} をそれぞれ適用した結果である電流源それぞれをダウンサンプリングした特徴量を用いる必要がある。そして、それらを用いた判別方法として、混合分布を用いた方法（混合分布法という）、各条件からの電流特徴量を合わせて1つの特徴量として判別する方法（結合法という）が考えられる。

40

【0081】

ここで、空間フィルタを用いた判別問題における注意点を2つ述べる。1つ目は、空間フィルタの構成には訓練データのみから作る点である。クロスバリデーションでは訓練データをさらに、訓練データとテストデータとに分けるが、空間フィルタも分割された訓練データからのみ構成されたフィルタでない場合には公正なバリデーションができないので注意が必要である。空間フィルタの構成に計算量がかかるときには、空間フィルタを作るためのデータを計測するのも1つの手段である。これは、独立成分分析、主成分分析などの空間フィルタを用いる方法すべてに共通するポイントである。2つ目は、階層ベイズ法のように条件別フィルタを計算する場合、空間フィルタ自体にラベルの情報が含まれるので、判別特徴量を作るときはそれぞれのフィルタを適用した結果それぞれを何らかの形で

50

特徴量として用いなければならないという点である。

【 0 0 8 2 】

以下に、センサ空間における判別、電流源空間における判別（混合分布法）、電流源空間における判別（結合法）の結果を示す。図 5 は判別結果をまとめた図表である。136 個のトライアル（サンプル）を 109 個の訓練データと、27 個のテストデータとにランダムに分け、訓練データで判別器のパラメータをスパースロジスティック回帰又はその混合モデルで学習し、テストデータを用いて判別精度を評価した。訓練・テストデータの分け方の影響を少なくするために、10 通りの分け方を行い、それぞれについて判別精度を評価した。また、学習後に 0 でないパラメータ推定値をもつ特徴量の次元を、学習後の特徴量次元として表示している。

10

【 0 0 8 3 】

判別精度では電流源空間において混合モデルを用いた方法が平均 89 % の判別精度を有し、最も精度が高い。センサ空間における判別では平均 81 % であり、電流源空間における判別でも結合法では、センサ空間と同程度の判別精度（81 %）であった。学習後の特徴量次元は、どの手法でも 20 前後であり、学習前の 2200 次元（すなわち、200 個のセンサ×時間方向のデータ 11 個）に比べて、判別に有効でない多くの次元が除去されていることが分かる。このようにスパースロジスティック回帰では、データから自動的に有効なパラメータのみを推定する。

【 0 0 8 4 】

このようにセンサ空間と電流源空間における判別精度の比較を行った結果、電流源空間における判別の方法が、信号の生理学的意味から考えて精度が高くなるという予想を支持する結論が得られた。

20

【 0 0 8 5 】

なお、本実施の形態では、第 1 センサ 11 及び第 2 センサ 12 が出力するデータを用いて脳内の電流源を推定する構成としたが、例えば、第 1 センサとして脳磁計（MEG）センサを用いることもできる。また、第 2 センサを同時計測するのではなく、事前に fMRI を用いて計測しても良い。更に fMRI などの装置により得られる磁気共鳴画像により電流源の推定を事前に行う構成としてもよい。fMRI による手法では、タスク実行時と安静時との磁気共鳴画像を比較し、磁気共鳴信号の変化を統計分析することにより、脳の活動部位を推定することができる。

30

【図面の簡単な説明】

【 0 0 8 6 】

【図 1】脳活動を観測する観測手段としてのブレインキャップを示す模式図である。

【図 2】ブレインキャップの観測データから被験者の行動を予測する行動予測装置の構成を示す模式図である。

【図 3】データ処理装置が実行する処理の手順を示すフローチャートである。

【図 4】実験手法を説明する説明図である。

【図 5】判別結果をまとめた図表である。

【符号の説明】

【 0 0 8 7 】

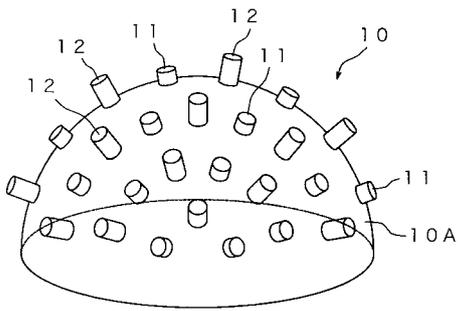
- 10 ブレインキャップ
- 20 集計装置
- 30 通信装置
- 100 データ処理装置
- 101 CPU
- 102 バス
- 103 ROM
- 104 RAM
- 105 HDD
- 106 通信 I F

40

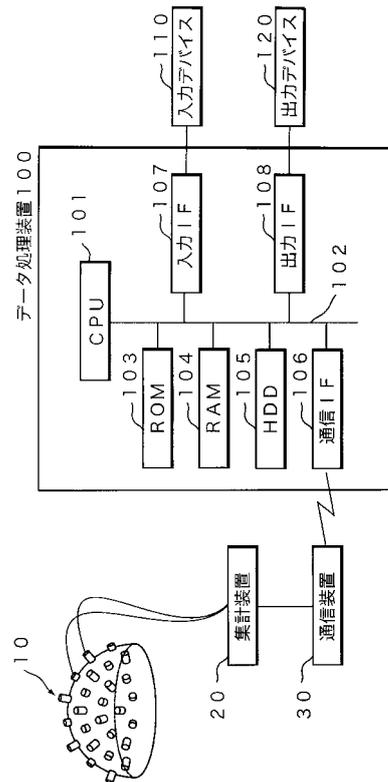
50

- 107 入力IF
- 108 出力IF
- 110 入力デバイス
- 120 出力デバイス

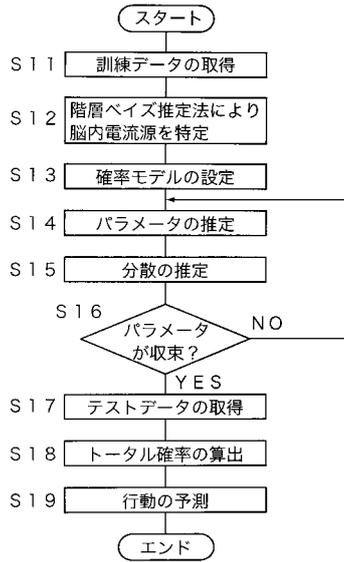
【図1】



【図2】

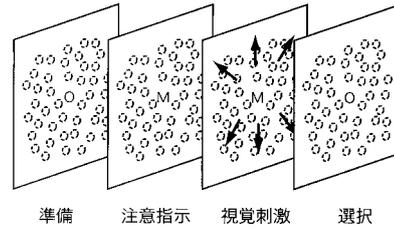


【図3】

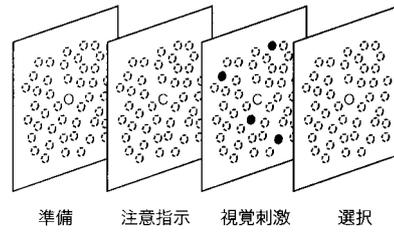


【図4】

(a) 動きへの注意指示



(b) カラーへの注意指示



【図5】

手法	学習前の特徴量の次元	学習後の特徴量次元 (10テストデータ分)	正答率 (10テストデータ分)
センサ空間	2200	18, 25, 24, 23, 21 22, 17, 24, 18, 23	89%, 74%, 78%, 81%, 81%, 85%, 85%, 74%, 85% Total : 81±5 %
電流源空間 (結合法)	1800~2400	19, 12, 20, 22, 21 22, 25, 19, 20, 22	78%, 67%, 81%, 85%, 85%, 81%, 81%, 81%, 93% Total : 81±7 %
電流源空間 (混合法)	1800~2400	19, 18, 19, 25, 21 22, 19, 25, 27, 23	74%, 89%, 85%, 93%, 89%, 93%, 89%, 96%, 93% Total : 89±6 %

フロントページの続き

(51)Int.Cl. F I
A 6 1 B 10/00 (2006.01)

(72)発明者 吉岡 琢
京都府相楽郡精華町光台二丁目2番地2 株式会社国際電気通信基礎技術研究所内

審査官 門田 宏

(56)参考文献 特開2006-305334(JP,A)
特開2006-280806(JP,A)
特表2002-526189(JP,A)
特開2006-263460(JP,A)
川脇大 外5名, fMRI/MEG統合解析による心的な指標運動追跡に関わる皮質電流源の推定, 電子情報通信学会技術研究報告, 日本, 社団法人電子情報通信学会, 2006年10月4日, Vol. 106, No.279, pp.19-24

(58)調査した分野(Int.Cl., DB名)

A 6 1 B 5 / 0 4 - 5 / 0 5

A 6 1 B 5 / 1 4 5

A 6 1 B 1 0 / 0 0

J S T P l u s / J M E D P l u s / J S T 7 5 8 0 (J D r e a m I I)