

УДК 616-71

Компонентный анализ в задаче слепого разделения спонтанной электроэнцефалограммы

Захаров И.С., студент
*кафедра «Биомедицинские технические системы»,
Россия, 105005, г. Москва, МГТУ им. Н.Э. Баумана*

*Научный руководитель: Самородов А.В., к.т.н., доцент
Россия, 105005, г. Москва, МГТУ им. Н.Э. Баумана
bmt-1@bmstu.ru*

Введение

В отличие от различных техник визуализации метаболических изменений в участках мозга, позволяющих «напрямую» сравнивать изменения в гемодинамике, и работающих независимо от размера и формы мозга субъекта, электроэнцефалография (ЭЭГ), а также магнитоэнцефалография (МЭГ) далеко не всегда позволяют правильно и с достаточной точностью локализовать источники активности, наблюдаемой на ЭЭГ. Основная сложность заключается в том, что активность, регистрируемая в виде потенциалов на электродах на различных участках скальпа, является результирующей суммарной активностью электромагнитных полей различных источников, расположенных по всему объему мозга, а также за его пределами.

Непосредственно активность церебрального происхождения, регистрируемая на скальпе, обусловлена синхронным возникновением микрогенераторов под воздействием синаптических процессов на мембране нейронов и пассивным затеканием внеклеточных токов в области регистрации. Сигналы от подкорковых и глубинных источников могут распространяться в проводящей среде мозга, образованной электролитом – межклеточной средой, во всех направлениях и регистрироваться на поверхности головы [1].

Иными словами, «скальповые» потенциалы являются результатом объемного проведения и являются функцией расположения и ориентации источника и представляют собой сумму потенциалов ближнего и дальнего поля различного типа.

Подобное «сетевое» расположение источников в совокупности с некоторыми различиями в строении и функционировании головного мозга различных индивидуумов может привести к различной ориентации эквивалентных источников активности и, в свою очередь, к различным распределениям этой активности по поверхности скальпа. В связи с

этим сравнение активности, зарегистрированной на ЭЭГ, при одинаковом расположении электродов и одинаковых отведениях, но с разных индивидуумов, не может дать столь точного результата, как, например, сравнение гемодинамической активности в одних и тех же участках мозга при использовании МРТ.

Важным шагом в обработке ЭЭГ и МЭГ стала пространственная фильтрация сигналов, целью которой стало получение на выходе каждого пространственного фильтра данных, соотносимых с активностью в какой-либо конкретной области.

Сравнительно недавно появилась возможность проводить пространственную фильтрацию сигналов ЭЭГ, используя методы слепого разделения источников. Наибольшее применение в области электроэнцефалографии получил метод независимых компонент (МНК). Было показано, что МНК является полезным инструментом для декомпозиции ЭЭГ сигнала на максимально независимые паттерны активности, как правило, связанные с различными областями коры головного мозга или иными источниками сигналов.

Важной особенностью МНК является тот факт, что разделение на независимые компоненты (НК) происходит не с помощью прямой пространственной фильтрации, а с использованием информации, содержащейся непосредственно в регистрируемом наборе данных. В основе лежит обманчиво простое, но статистически и физиологически правдоподобное предположение о том, что источники активности находятся на некотором удалении друг от друга и функционируют независимо.

Таким образом, локально когерентные сигналы, исходящие от одного источника ЭЭГ, теоретически, будут сгруппированы вместе в одну НК, включающую в себя проекции на все каналы регистрации потенциалов со скальпа, в то время как все сигналы, не имеющие отношения к этому источнику, будут устранены и сгруппированы в другие НК. Иными словами, МНК позволяет трансформировать ЭЭГ в набор сигналов от церебральных и артефактных источников и анализировать эти отдельные составляющие ЭЭГ [2].

Метод независимых компонент, применяемый во время обработки ЭЭГ, производит линейную и обратимую декомпозицию данных. Иными словами, полученные НК являются «взвешенной» суммой сигналов, зарегистрированных со всех электродов на скальпе, а сигнал каждого канала, в свою очередь, является суммой всех НК, суммируемых в пропорциях, равных своим весам относительно данного канала.

На сегодняшний день известно более 100 алгоритмов МНК. Многие из них эффективны в решении конкретных вопросов. Использование МНК для анализа ЭЭГ нередко является тщетным в силу специфики ситуации и особенностей регистрируемых

данных. Выбор алгоритма, адекватного подобной задаче, является необходимым условием для получения осмысленного результата, от которого может зависеть точность нейрофизиологических исследований или, например, последующая классификация паттерна электроэнцефалографической активности в интерфейсе мозг-компьютер.

Стандартная модель метода независимых компонент

По определению, стандартный метод независимых компонент (Independent components analysis, ICA) – это метод обработки статистических данных, позволяющий выделить основные факторы (независимые компоненты), обладающие статистической независимостью и негауссовым распределением. Техника МНК (но не название метода) впервые была представлена в начале 1980-х [3]. В отличие от метода главных компонент (МГК), МНК не является методом снижения размерности данных (хотя понижение размерности, в принципе, возможно).

Для того чтобы дать определение МНК, необходимо представить следующую ситуацию: имеется n случайных векторов $x_1, \dots, x_n$, представляющих из себя линейные комбинации n случайных векторов $s_1, \dots, s_n$, каждый элемент которых, соответственно, равен:

$$x_{i,j} = a_{i,1}s_{1,j} + a_{i,2}s_{2,j} + \dots + a_{i,n}s_{n,j}, \quad (1)$$

где $i = 1, \dots, n$,

$a_{i,j}$ – действительные коэффициенты, $(i, j = 1, \dots, n)$.

По определению s_i статистически независимы друг от друга.

Иными словами, имеется набор наблюдаемых векторов (матрица $\mathbf{X}$), которые являются линейными комбинациями независимых компонент (матрица $\mathbf{S}$). Таким образом, модель МНК может быть записана:

$$\mathbf{X} = \mathbf{W}\mathbf{S}, \quad (2)$$

где $\mathbf{X}$ – матрица данных исходного пространства, $\mathbf{S}$ – матрица независимых компонент, $\mathbf{W}$ – матрица весов для перехода из пространства $\mathbf{S}$ в пространство $\mathbf{X}$.

Цель метода независимых компонент состоит в определении матрицы $\mathbf{W}^{-1}$, с помощью которой можно будет определить матрицу НК $\mathbf{S}$ по формуле:

$$\mathbf{S} = \mathbf{W}^{-1}\mathbf{X}. \quad (3)$$

Максимальное количество независимых компонент, для удобства вычислений, согласуется с размерностью входных данных. Т.е. для n различных зарегистрированных векторов мы получим m различных независимых компонент, где $m \leq n$. (Хотя существуют алгоритмы МНК, позволяющие получить $m > n$ независимых компонент).

В основе стандартного метода независимых компонент лежат следующие допущения:

- НК статистически независимы;
- НК должны иметь негауссово распределение;
- для упрощения предполагается что, матрица весов $\mathbf{W}$ – квадратная.

Впрочем, некоторые из НК могут иметь гауссово распределение. В данном случае такие НК не будут разделены друг от друга и будут выделены в одну НК, являющуюся их линейной комбинацией. В частном случае, если имеется только одна НК с гауссовым распределением, МНК полностью справится с декомпозицией.

Стандартная модель МНК подразумевает разделение смеси случайных переменных. Однако нередко данные представляют собой комбинацию не случайных значений, а временных сигналов, иными словами, переменные имеют строгий порядок, и располагать их любым удобным способом, не оказывая влияния на действительность модели, не представляется возможным.

Таким образом, стандартный МНК не способен разделить сигналы с гауссовым распределением и не учитывает временную структуру данных. Эти недостатки являются причиной существенных ошибок при применении подобных алгоритмов к ЭЭГ.

К стандартным МНК (не учитывающим временную структуру), например, можно отнести следующие алгоритмы: Infomax, JADE, FastICA, KernelICA, RADICAL, NICA [4].

Модель метода независимых компонент для временных рядов

Особенность временных последовательностей заключается в том, что значения часто зависимы, а во время анализа должен учитываться их временной порядок. Если речь идет о временных рядах, появляется возможность также использовать ковариации между значениями в разные моменты времени (автоковариации), использование которых применительно к независимым значениям не имеет смысла, т.к. они всегда равны нулю.

Модель МНК для временных рядов определяется следующим образом:

$$x_i(t) = \mathbf{A}s_i(t), \quad (4)$$

где $x_i(t)$, $s_i(t)$ – временные сигналы,
 t – временной отсчет.

Важной особенностью декомпозиции временных рядов является тот факт, что НК более не должны иметь негауссово распределение для получения результата. Для данной модели гауссовы независимые компоненты разделимы. Предполагается, что НК имеют различные ненулевые автоковариации.

Данный подход имеет существенный недостаток: в случае если некоторые из собственных чисел кроссковариационной матрицы равны, соответствующие НК разделены не будут. Для решения этой проблемы можно варьировать значение временного сдвига τ . Но в случае, если сигналы $s_i(t)$ имеют одинаковый спектр мощности, а значит одинаковые автоковариации, разделение на НК невозможно при любом τ .

К МНК, использующим временную структуру данных, можно отнести, например, следующие алгоритмы: AMUSE, TDSEP, SOBI [5].

Выбор алгоритма

Алгоритм МНК, применяемый к ЭЭГ, должен быть способен разделять сигналы по всем содержащимся в них признакам.

Одна из попыток объединить базовую модель МНК и методы, использующие временную структуру сигнала, например, была основана на информационно-теоретической концепции меры сложности Колмогорова. Алгоритм, основанный на данной методике, часто именуется Complexity Pursuit [6].

А, например, алгоритм JADETD, использующий и пространственные и временные свойства данных, является не чем иным, как объединением алгоритмов JADE и TDSEP.

Как правило, подобные алгоритмы выдают лучший результат во время обработки стационарных временных рядов, чем стандартные МНК или МНК, использующие только временные зависимости. Но ЭЭГ является нестационарным сигналом, различные выборки которого могут иметь одинаковые спектры мощности, но разную природу. Подобные выборки, как было указано выше, подобными методами разделить невозможно.

Для решения подобной проблемы предлагается использовать стандартный МНК применительно к коэффициентам Фурье исследуемого сигнала. Подобный алгоритм включает в себя предварительное использование преобразования Фурье к отдельным участкам сигнала длиной около 1-3 секунд, после которого к полученному набору данных

применяется комплексный МНК. Подобный метод позволяет разделять сигналы, учитывая не только амплитуды, но и фазы. При этом разделение также возможно и при одинаковых автоковариациях для различных сигналов, так как сигналы с одинаковыми спектральными характеристиками разделяются по амплитудным модуляциям осцилляций.

Алгоритм МНК для анализа ЭЭГ

Таким образом, для анализа сигнала ЭЭГ предлагается использовать комплексный МНК после оконного преобразования Фурье. Окна при преобразовании не перекрываются. Полученные спектральные участки из комплексных величин выстраиваются в том же порядке, что и временные, и объединяются.

Модель предложенного алгоритма имеет вид:

$$\hat{x}_{c,tf} = \sum_{p=1}^P \hat{a}_{c,p} \hat{s}_{p,tf}, \quad (5)$$

где a – весовые коэффициенты НК,

s – независимые компоненты,

x – сигнал ЭЭГ на канале c ,

t – окно Фурье анализа,

f – коэффициенты Фурье анализируемого окна,

p – кол-во НК (можно задать меньшим, чем c). Обозначением $\hat{}$ отмечены комплексные величины [7].

Экспериментальная часть

В ходе экспериментальной части были сравнены стандартный алгоритм МНК (FastICA) и предложенный алгоритм МНК, включающий в себя применение FastICA к коэффициентам Фурье анализа. Тестовый 10-канальный сигнал, представленный на Рисунке 1, был получен как набор линейных комбинаций различных модулированных синусоид (в том числе модулированных синусоид с фазовыми сдвигами) с добавлением шума, резких скачков и 50 Гц синфазной помехи. Результаты применения двух алгоритмом представлены на Рисунках 2 и 3.




Рис. 1. Тестовый 10-канальный сигнал для разложения





Рис. 2. Исходные сигналы (слева) и результат разложения тестового сигнала на компоненты предложенным алгоритмом (справа). Четвертая сверху компонента – распознанные (и объединенные в одну НК с учетом сдвига фазы) пятый и шестой сигналы. Первая компонента не представлена в исходных сигналах в явном виде и может считаться артефактом. Распознаны все 10 компонент (включая шум)



Распознано 5 компонент (включая шум)

Анализ результатов

Качественное сравнение методов показывает явное преимущество предложенного алгоритма. В ходе эксперимента была успешно распознана компонента с фазовым сдвигом, выделены и значительно лучше отфильтрованы от шума все исходные сигналы. (В случае стандартного алгоритма только 5, включая шум).

При проверке на тестовом сигнале предложенный алгоритм показал близкую к 100 % эффективность против 50 % компонент, распознанных стандартным методом.

Список литературы

1. В.В. Гнездицкий «Обратная задача ЭЭГ и клиническая электроэнцефалография», Москва, «МЕДпресс-информ», 2004 г., стр 31, 35,36,54
2. Julie Onton Scott Makeig « Information-based modeling of event-related brain dynamics» For a volume in the Elsevier Progress in Brain Research book series, Eds. Neuper & Klimesch February, 2006
3. J.H'erault and B.Ans. Circuits neuronaux `a synapses modifiables: d'ecodage de messages composites par apprentissage non supervis'e. C.-R. de l'Acad'emie des Sciences, 299(III-13):525–528, 1984.
4. P. Pajunen. Blind source separation using algorithmic information theory. Neurocomputing, 22:35–48, 1998.
5. Aapo Hyv'tirinen «Independent Component Analysis», A Wiley-Interscience Publication JOHN WILEY & SONS, INC, 2001.
6. Hyv"arinen and E. Oja. A fast fixed-point algorithm for independent component analysis. Neural Computation, 9(7):1483–1492, 1997.
7. Aapo Hyv'tirinen, Pavan Ramkumar, «Independent component analysis of short-time Fourier transforms for spontaneous EEG/MEG analysis», NeuroImage 49 (2010) 257-271.