

УДК 621.396

**Е.Н. КИСЕЛЬГОВ***Национальный аэрокосмический университет им. Н.Е. Жуковского «ХАИ», Украина***СТАТИСТИЧЕСКИЙ ПОДХОД К РЕШЕНИЮ ОБРАТНОЙ ЗАДАЧИ  
ЭЛЕКТРОЭНЦЕФАЛОГРАФИИ**

В статье рассмотрен способ модификации классического метода многошаговой дипольной локализации на основе статистического подхода с целью увеличения качества решения обратной задачи электроэнцефалографии и уменьшения временных затрат. Предложенный способ основан на применении разложения на статистически независимые составляющие и сведения поиска локализации источника к однопараметрической задаче за счет использования свойств дипольной модели.

**многошаговая дипольная локализация, электроэнцефалограмма, анализ независимых компонент, диполь, обратная задача**

**Введение**

С появлением компьютерных комплексов функциональной диагностики метод электроэнцефалографии (ЭЭГ) получил широкое распространение, так сказать, второе рождение после определенного периода застоя. Объясняется это, прежде всего, широкими возможностями в цифровой обработке сигнала, которые стали доступны после привлечения к этой цели компьютеров. Не последнюю роль в этом играет и относительная дешевизна этого метода по сравнению с аналогами. Однако результаты ЭЭГ обработки часто вызывают определенный скепсис у неврологов и нейрохирургов. Это связано с тем, что функционалист и невролог мыслят разными категориями: одни оперируют понятиями ритма, свойственными для описания ЭЭГ скальпа; другие – структурами и функциями мозга. «Пока потенциалы феноменов, регистрируемые на скальпе, не будут сведены к источникам и мозговым структурам их генерирующим, знания о ЭЭГ и ВП будут носить академический характер» – Хилльярд (1978). Именно решение задачи поиска и локализации источников ЭЭГ феноменов, называемое обратной задачей ЭЭГ (ОЗЭЭГ), и является тем мостиком, который связывает ЭЭГ обработку с накопленными знаниями в нейрофизиологии. ОЗЭЭГ – это сложная в матема-

тическом смысле задача, до сих пор существует устойчивое, хотя и не доказанное, мнение о неединственности ее решения. Базируется оно на недостаточности исходных данных для нахождения истинного решения, без применения каких либо упрощающих моделей. Исследованиями в данном направлении занимаются достаточно давно, но большинство из них дает хороший результат только в относительно простых случаях. И все обладают схожими проблемами, вытекающими из общего подхода к решению ОЗЭЭГ, связанного с применением метода многошаговой дипольной локализации (МДЛ) «в лоб». С другой стороны, начиная с 1995г. активно развивается направление статистического анализа ЭЭГ феноменов – «слепое» разложение сигнала на источники BSS (blind source separation) и его подкласс – анализ независимых компонент ICA (independent components analysis). Комбинирование ICA анализа и МДЛ позволяет значительно улучшить результаты решения ОЗЭЭГ, чему и посвящена данная статья.

**1. Многошаговая дипольная  
локализация (МДЛ)**

Основная идея метода МДЛ – использовать зарегистрированное распределение потенциального поля на скальпе для отыскания параметров дипольных

источников, его сформировавших. С этой целью решается оптимизационная задача, минимизирующая некую оценочную функцию, отражающую разность распределения потенциального поля по поверхности скальпа от текущих параметров дипольных источников (модель) и истинного распределения потенциалов в зарегистрированной ЭЭГ. Другими словами, обратная задача ЭЭГ решается при помощи *прямой задачи*. Варьируя теперь количеством дипольных источников и их параметрами, можно минимизировать разность этих распределений. Когда глобальный минимум будет найден – задача считается решенной.

Как видно из описания метода, важными для решения ОЗЭЭГ являются вопросы правильного решения прямой задачи и соответствия числа параметров источников количеству исходных данных. Из-за сложности процессов генерирования потенциального поля мозга, большого количества источников, множественных связей, неоднородностей тканей и т.п., не существует точного решения, которое удовлетворило бы всех исследователей. В настоящее время прямая задача приближенно описывается своими моделями, все они используют тезисы о наличии объемной проводимости в тканях мозга и окружающих его слоев и дипольного представления источников активности [1]:

– *Сферическая модель однородной изотропной бесконечной среды*. Эта модель использовалась на ранних этапах исследования и уже не применяется.

– *Сферическая многослойная модель*. Эта модель предполагает однородность и изотропность тканей, но учитывает различную их проводимость и толщины. Учитываются ткани мозга, окружающих слоев, черепа, кожи и т.п.

– *Эллиптическая модель* (модель реалистичной формы). К учету свойств тканей добавляется учет геометрической формы скальпа, за счет чего повышается точность в сагиттальных сечениях (во фронтальных сечениях высокая точность достигается уже

в сферических моделях).

– *Экспериментальная модель*. Для построения такой модели используется череп человека и электрические эквиваленты тканей мозга и скальпа. Размещая диполи-источники в разных точках мозга, регистрируются матрицы распределения потенциалов на скальпе. Такие модели наиболее точны, и их использование только начинается.

Согласно дипольному представлению источника его распределение потенциала (реальный источник – синхронно активированная группа нейронов, электрическая модель распространения потенциала которого – диполь), регистрируемое на поверхности скальпа, может быть смоделировано одним элементарным диполем, имеющим определенное направление (момент диполя, в базисе  $Px_i, Py_i, Pz_i$ ), локализацию  $(x_i, y_i, z_i)$  и сигнал  $s_i(t)$ ,  $i$  – индекс источника [1, 2]. При этом физическими размерами самого источника можно пренебречь, т.к. его величина считается значительно меньшей расстояния до точки на скальпе, где регистрируется потенциал его поля. Применение принципа суперпозиции для дипольной модели источников электрической активности головного мозга преобразуется в аддитивный закон смешивания, связывающий потенциал  $x_j(t)$ , регистрируемый в точке наложения электрода  $j$  ( $j \in [1..N]$ ,  $N$  – число электродов), с распределениями потенциалов от дипольных источников  $x_j^{s_i}(t)$  ( $i \in [1..M]$ ,  $M$  – кол-во источников), сформировавших его [1, стр. 89]:

$$x_j(t) = \sum_{i=1}^M x_j^{s_i}(t) = \sum_{i=1}^M Model(x_i, y_i, z_i, Px_i, Py_i, Pz_i, s_i(t)). \quad (1)$$

$Model(\ )$  – функционал выбранной модели проводимости, обеспечивающий переход от параметров дипольного источника к распределению его потенциалов на скальпе. Считается [1, уравнение Шерга,

стр. 89], что модель  $Model(\ )$  не является функцией времени (проводимость тканей – const, а источник не перемещается и не меняет своей ориентации, т.е.  $Px_i, Py_i, Pz_i$  и  $x_i, y_i, z_i$  не зависят от  $t$  [2]), а также не зависит от сигнала дипольного источника  $s_i(t)$ . Следовательно может быть заменена эквивалентной линейной моделью – набором коэффициентов  $a_{ij}$ , отражающих связь для каждой конкретной точки на поверхности скальпа между сигналом источника  $s_i(t)$  и потенциалом поля этого источника  $x_j^{s_i}(t)$  в точке установки электрода  $j$ :

$$x_j(t) = \sum_{i=1}^M a_{ij}(x_i, y_i, z_i, Px_i, Py_i, Pz_i) \cdot s_i(t). \quad (2)$$

Далее, в соответствии с МДЛ методом, задавшись определенными пространственными характеристиками дипольных источников, по выражению (2) определяется распределение потенциалов  $x_j(t)$  и сравнивается с исходным зарегистрированным распределением потенциалов  $x_j^u(t)$ . В качестве оценочной функции  $W$  в большинстве случаев выступает среднеквадратичное отклонение

$$W = \sum_{j=1}^N \left( x_j(t) - x_j^u(t) \right)^2. \quad (3)$$

Поскольку никаких предположений о законе сигнала  $s_i(t)$  дипольного источника в МДЛ не делается, а определить его без дополнительных упрощений невозможно, то в классическом МДЛ от него пытаются уйти. С этой целью, в качестве исходных данных для МДЛ метода выступает мгновенный временной срез (т.н. одномоментные сечения [1, стр. 74]). В этом случае  $s_i(t) = Const$  является масштабирующей константой, а, следовательно, не вносит искажений в форму оценочной функции и не влияет на поиск глобального минимума. Поэтому выражение (3) для одномоментного сечения и сам МДЛ метод можно записать в виде:

$$W = \sum_{j=1}^N \left( \sum_{i=1}^M a_{ij}(x_i, y_i, z_i, Px_i, Py_i, Pz_i) - x_j^u \right)^2, \quad (4)$$

$$\arg \min \left( \sum_{j=1}^N \left( \sum_{i=1}^M a_{ij}(x_i, y_i, z_i, Px_i, Py_i, Pz_i) - x_j^u \right)^2 \right). \quad (5)$$

$x, y, z \in X, Y, Z$   
 $Px, Py, Pz \in P$   
 $M \subset \Theta$

Причем  $\Theta$  – множество всех возможных источников, для заданного распределения, а минимизация с учетом  $M \subset \Theta$  означает перебор все возможных неповторяющихся элементов множества  $\Theta$ . В качестве алгоритма оптимизации в МДЛ обычно используются методы покоординатного или градиентного спусков, также существуют реализации и более сложных алгоритмов, например: использование «натурального» градиента Анри или «относительного» градиента Кордоса [3]. Следует отметить, что идея, применяемая в МДЛ, интересна и заслуживает внимания, но использование МДЛ на неподготовленных ЭЭГ, тем более по одномоментным сечениям, является ошибочным и выливается в следующие недостатки:

– *Максимальное число источников –  $N/6$ .* Для описания дипольного источника используется 6 параметров, величины которых ищутся из системы потенциалов на  $N$  электродах. Следовательно, чтобы система не была вырожденной и обладала единственным решением, необходимо, чтобы количество неизвестных (параметров, описывающих все источники) не превышало  $N$ , т.е. количество элементов множества  $\Theta$  (максимальное число источников) ограничено  $N/6$ . Т.е. для стандартной 16-ти канальной ЭЭГ можно найти только 2 источника на одном сечении, а для 19-ти канальной – 3!

– *Высокая величина ошибки в большинстве ЭЭГ.* ЭЭГ всегда содержит «шумовую» составляющую, т.е. помехи. Поэтому для ЭЭГ очень важно увеличить соотношение сигнал/шум, что достигается фильтрацией и обработкой «усредненных» за интервал данных. Использование же одномоментных се-

чений всегда приводит к ошибкам, зависящим от величины помехи, так как для них соотношение сигнал/шум – минимально.

– *Найденные диполи являются весьма грубым усреднением активности реальных источников.* Этот недостаток вытекает из первого – в большинстве случаев ЭЭГ (включая «ЭЭГ покоя») не может быть представлена 2 или 3 источниками, а описывается гораздо большим количеством. Ситуация осложняется наличием различного рода артефактов, каждый из которых также описывается своим источником. В результате даже для ярко выраженного на ЭЭГ феномена локализация источника оказывается сильно искаженной, так как содержит усреднение с другими источниками. Как следствие, можно говорить лишь о том, что распределение потенциального поля найденных источников представляет собой усреднение электрической активности нескольких источников, к тому же с неизвестными весовыми коэффициентами.

– *Высокие временные затраты.* Для решения уравнения (5) необходимо осуществить перебор всех сочетаний элементов множества  $\Theta \supset (1, 2, \dots, M)$ . Количество таких сочетаний (необходимое и достаточное число итераций алгоритма):

$$c_u = \sum_{i=1}^M C_M^i = \sum_{i=1}^M \frac{M!}{(M-i)!i!} = \frac{M!}{(M-1)!} \cdot \left[ 2 \frac{2^{(M-1)}}{M} - \frac{1}{M} \right].$$

На каждой итерации необходимо провести поиск локального минимума  $W_u$  градиентным методом и из всех итераций выбрать ту, которая дает минимальное значение  $W = \min(W_u)_{u \in (u_1, u_2, \dots, u_M)}$ . Так как минимизация градиентным методом на каждом этапе будет проходить одновременно по 6 параметрам  $(x, y, z, P_x, P_y, P_z)$ , то сложность одной итерации –  $O(N^6)$ , где  $O(N)$  – сложность однопараметрического градиентного метода. С учетом необходимого количества итераций сложность метода можно оценить как

$$c_{МДЛ} = \frac{M!}{(M-1)!} \cdot \left[ 2 \frac{2^{(M-1)}}{M} - \frac{1}{M} \right] \cdot O(N^6). \quad (6)$$

Таким образом, для 19 канальной ЭЭГ, максимальное число источников достигает 3, а сложность их отыскания –  $c_{МДЛ}^{19} = 7 \cdot O(N^6)$ .

Чтобы повысить точность разложения (количество источников), можно попытаться использовать несколько временных сечений. Но это не дает желаемого результата, так как каждое новое сечение содержит в себе уже найденные на предыдущих этапах источники, и в результате мы получаем новое «усреднение». Вычитать же из него по выражению (2) уже найденные источники нельзя, так как определены они слишком «грубо» и содержат в себе шумовую составляющую и сигналы еще не определенных источников (по второму и третьему недостаткам). Перечисленные проблемы могут быть легко решены, если убрать причины, из-за которых они проявляются. А именно – метод МДЛ не должен заниматься обнаружением количества источников, поиск локализации источников должен проводиться на подготовленных данных, где соотношение сигнал/шум – максимально, а так же полезна избыточность  $N > M$ . С этой целью полезно скомбинировать МДЛ и ИСА.

## 2. Анализ независимых компонент (ИСА)

Анализ независимых компонент рассматривает исходный сигнал (ЭЭГ) как результат линейного смешивания источников активности. Распределение поля источника, регистрируемое сенсорами (электродами), связано с сигналом источника через весовые коэффициенты  $a_{ij}^u$ , определяющее распространения возмущения от источника в заданной системе. Линейная смесь этих источников, т.е. их весовых коэффициентов  $a_{ij}^u$ , образует так называемую матрицу смешивания  $\mathbf{A}$ , модель смешивания записывается в матричном виде [4]:

$$\mathbf{X} = \mathbf{A} \cdot \mathbf{S};$$

$$x_j(t) = \sum_{i=1}^M a_{ij}^u \cdot s_i(t), \quad (7)$$

где  $\mathbf{X}$  – матрица исходных данных  $\mathbf{X} = [x_1(t), x_2(t) \dots x_N(t)]^T$ ;  $\mathbf{S}$  – матрица источников  $\mathbf{S} = [s_1(t), s_2(t) \dots s_M(t)]^T$ ;  $\mathbf{A}$  – матрица смешивания, коэффициенты для одного источника  $s_i(t)$  находятся в  $i$ -м столбце матрицы;  $a_{ij}^u$  – весовой коэффициент, с которым  $i$ -й источник входит в  $j$ -й электрод, индекс  $u$  обозначает связь этого коэффициента с точкой локализации электрода. Источники обладают свойством статистической независимости:

$$\rho(\mathbf{S}) = \prod_{i=1}^M \rho(s_i(t)), \text{ т.е. все их несовместные моменты (кумулянты) высших порядков равны нулю.}$$

В выражении (7) ICA описывает проблему разложения источников без учета наличия аддитивного шума. Но за счет выбора относительно большого временного интервала, где соотношение сигнал/шум увеличивается, наличием шума можно пренебречь, тем более что для ЭЭГ шум имеет нормальное распределение, а некоторые ICA алгоритмы, основанные на применении эксцессов (кумулянтов или моментов 4-го порядка), устойчивы к нему, так как эксцесс для нормального закона равен нулю. Выражение (7) полностью совпадает с принятой моделью (2), а значит, ICA может быть применен для поиска сигналов источников и матрицы смешивания – весовых коэффициентов модели (2) [10 – 11]. Т.е. результат ICA разложения ЭЭГ на источники снимает с метода МДЛ ту часть задачи, с которой он справляется хуже всего – поиск источников активности, и предоставляет для каждого найденного источника  $s_i(t)$  весовые коэффициенты  $a_{ij}^u$ , которые могут быть использованы в МДЛ для поиска пространственных характеристик источника (см. след. раздел). Вопрос выбора конкретного метода решения ICA (Infomax ICA [5], Extended ICA [6], FastICA [7],

JADE [8], JADETD, CuBICA [9]) рассматривать здесь не будем, это обширная тема для отдельной статьи. Замечу только, что для подавляющего большинства существующих ICA алгоритмов остается открытым вопрос количества искомым источников. Так многие авторы предлагают использовать равенство  $M = N$ , а после разложения провести какой-либо анализ на основе априорных знаний о природе источника, чтобы откинуть лишние шумовые компоненты (при условии, что в реальности  $M < N$ ), но насколько это оправдано? Действительно для условия  $M > N$  какого-либо однозначного трактования результата не существует, так как в системе (7) недостаточно данных для определения всех источников, и избежать «смешивания/усреднения» нескольких источников в одном не получится, можно только минимизировать ошибку, применяя последовательные алгоритмы, такие как FastICA [7] или рекурсивный пакетный ICA [13]. Что же касается варианта  $M \leq N$ , то для этого случая можно достаточно точно предсказать исходное количество источников в смеси, не проводя при этом полного разложения, а ориентируясь только по моментам второго порядка (ковариационная матрица). Выполним следующие преобразования для исходных данных  $X$ , где  $\mathfrak{R}_x$  – ковариационная матрица, а  $eig(\mathfrak{R}_x)$  – её разложение на вектор собственных значений:

$$\mathfrak{R}_x = \langle \dot{\mathbf{X}} \rangle;$$

$$\omega_x = 10 \cdot \log_{10} (eig(\mathfrak{R}_x)). \quad (8)$$

Это преобразование не что иное, как диагонализация ковариационной матрицы вектора наблюдений. Так как источники статистически независимы, то они и не коррелированы, т.е. их совместные моменты второго порядка (ковариация, а, следовательно, и корреляция) должны быть равны нулю, что и отражает операция их диагонализации. Если матрица  $\mathbf{X}$  построена с избытком, т.е.  $M < N$ , то несколько собственных значений, число которых  $D_\lambda = N - M$ , должно значительно отличаться от группы основ-

ных собственных значений по величине, и при этом мало отличаться друг от друга, указывая на зависимость своих псевдоисточников – шумовая составляющая (вытекает из смысла диагональности матрицы моментов независимых величин). Если в процессе разложения на собственные значения полученная диагональная матрица имеет отсортированные значения главной диагонали, то группы выделяются явно: первая группа (начиная от максимального собственного значения) – группа источников, вторая – шумовая составляющая. Для разделения групп по их значениям Крадосо в [8] предложил эмпирическое значение в 5dB (в качестве примера см. рис. 1).

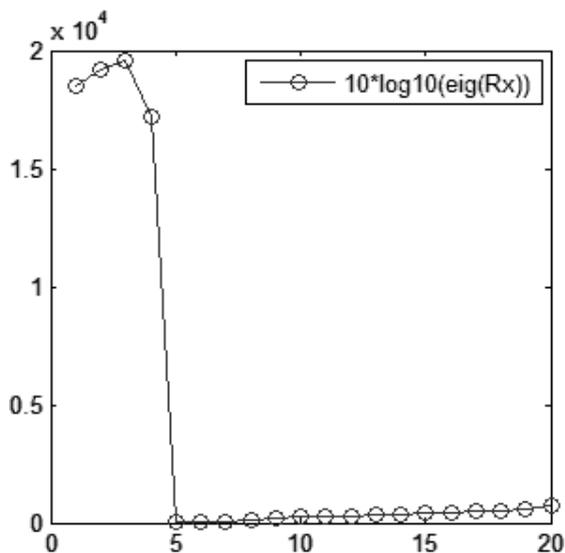


Рис. 1. График  $\omega_x$  экспериментальной матрицы  $X$  размером в 20 отведений, сформированных из 16 источников. Отчетливо видны две группы собственных значений из 4 и 16 элементов, отстающих друг от друга на три порядка

### 3. Решение ОЗЭЭГ для источников ИСА разложения МДЛ методом

Благодаря ИСА разложению и выражению (8), сигналы источников  $s_i(t)$ , их количество  $M$  и коэффициенты  $a_{ij}^u$  уже найдены. Поскольку коэффициенты  $a_{ij}^u$  позволяют вычислить  $x_j^{s_i}(t)$  для каждого  $i$ -го источника, то локализацию удобно проводить для каждого из них в отдельности. В действительности,

$x_j^{s_i}(t)$  нам не нужен, т.к. его пространственное распределение по скальпу с точности до Const в каждый момент времени уже задано в  $a_{ij}^u$ , так как модель смешивания не является функцией времени. Для этого, как и в классическом МДЛ, будем использовать модель, описывающую электрическую проводимость тканей мозга и алгоритм оптимизации оценочной функции  $W_i$  для  $i$ -го источника:

$$\arg \min_i \left( \sum_{j=1}^N \left( a_{ij}(x_i, y_i, z_i, Px_i, Py_i, Pz_i) - a_{ij}^u \right)^2 \right). \quad (9)$$

$x, y, z \in X, Y, Z$   
 $Px, Py, Pz \in P$

Но, учитывая дипольное представление источника, можно значительно ускорить алгоритм, задав ограничение в виде однопараметрического поиска вдоль линии вектора дипольного момента, на которой должна располагаться точка его локализации. Так как распределение поля дипольного источника по любой эллиптической поверхности, описывающей его, дает так называемую «дипольную карту» источника, то точки пересечения этой поверхности с линией дипольного момента на «карте» будут представлены глобальными минимумом и максимумом. Воспользовавшись оптимизированной под нашу цель сферической сплайн интерполяцией, описанной в [2], можно по коэффициентам  $a_{ij}^u$  найти эти точки  $(x_1, y_1, z_1), (x_2, y_2, z_2)$  и соответствующие им  $a_{\max}(x_1, y_1, z_1)$  и  $a_{\min}(x_2, y_2, z_2)$ . Линию вектора дипольного момента источника, проходящую через заданные точки, можно записать в параметрическом виде:

$$\left. \begin{aligned} x &= x_1 + (x_2 - x_1) \cdot t \\ y &= y_1 + (y_2 - y_1) \cdot t \\ z &= z_1 + (z_2 - z_1) \cdot t \end{aligned} \right\}, t \in [0 \dots 1] \quad (10)$$

Длина вектора дипольного момента  $Px_i, Py_i, Pz_i$  в ОЗЭЭГ не важна с точки зрения практического применения, главное – определить его направление и локализацию. Направление нам уже известно, те-

перь, воспользовавшись (9) и (10), решаем одномерную задачу поиска глобального минимума оценочной функции, которую можно записать через выражение:

$$\arg \min_i \left( \sum_{\substack{j=1 \\ t \in [0 \dots 1]}}^N \left( a_{ij} \begin{pmatrix} x_1 + (x_2 - x_1) \cdot t, \\ y_1 + (y_2 - y_1) \cdot t, \\ z_1 + (z_2 - z_1) \cdot t \end{pmatrix} - a_{ij}^u \right)^2 \right); \quad (11)$$

$$\arg \min_i \left( \sum_{t \in [0 \dots 1]} (a_i(t) - a_i^u)^2 \right), a_i^u \in [a_{\min}, a_{\max}].$$

Легко увидеть, что сложность описанного метода можно оценить как:  $c_{ICA-МДЛ} = M \cdot O(N)$ , что значительно меньше, чем для классического МДЛ.

Сформируем теперь алгоритм решения ОЗЭЭГ с использованием анализа независимых компонент по методу МДЛ, назовем эту комбинацию ICA-МДЛ:

1. Центрирование:  $\mathbf{X} = \mathbf{X} - \langle \mathbf{X} \rangle$ .
2. Выбеливание:  $\mathbf{X} = \text{eigvect}(\mathfrak{R}_x)^{-1} \cdot \mathbf{X}$ .
3. Поиск количества источников  $M$  по формуле (8).
3. ICA разложение (поиск матрицы  $\mathbf{A}$ ).
4. Выбор колонки коэффициентов  $a_{ij}^u$  для  $i$ -го источника.
5. Сферическая сплайн интерполяция коэффициентов  $a_{ij}^u$  (описана в [2]).
6. Поиск точек максимума и минимума и коэффициентов  $a_{\max}(x_1, y_1, z_1)$  и  $a_{\min}(x_2, y_2, z_2)$  на поверхности скальпа.
7. Поиск глобального минимума оценочной функции по выражению (11) градиентным методом или любым однопараметрическим методом.
8. Переход к следующему источнику (шаг 4) или конец.

Описанный алгоритм следовало бы добавить анализом дипольности распределения источника (на шаге 4), так как его применение к недипольным источникам, которые могут быть найдены после шага 3, является некорректным.

## Выводы

Сравнение данного алгоритма с другими методами решения ОЗЭЭГ можно увидеть в табл. 1. Для сравнения использовалась ЭЭГ зрительные ВП (16 каналов, 8 источников), в которую при помощи генератора источников, реализованного в NeuroCom, был добавлен дипольный источник. Каждой из программ, реализующей свой метод, была представлена полученная ЭЭГ, измерялось время поиска (разложение+локализация), количество найденных источников  $M$ , и сравнивалось СКО от найденного положения с изначально заданным.

Таблица 1

Сравнение методов

Метод	$M$	$t$ , сек.	СКО
NeuroLab 2000 (МДЛ)	2	8	0,3572
NeuroCom (ICA-МДЛ)	9	10	0,018004
BESA 2.2 (PCA-МДЛ для многих источников)	16	18	0,15201
BESA 3 + MatLab (ICA-МДЛ)	16	25	0,0131

Как видно из таблицы, классический МДЛ метод справился хуже всех, хотя и затратил при этом меньшее время (из-за малого количества найденных источников). Метод PCA-МДЛ, аналогичный описанному здесь, но с разложением на некоррелированные компоненты (PCA анализ) обнаружил излишнее количество источников (так как не содержит анализа  $M$ ), показал худшую точность (из-за недостаточности критерия независимости разложения), при этом затратил излишнее время, так как обобщен и не учитывает дипольности источников. Метод ICA-МДЛ (представлен двумя программами NeuroCom и BESA 3 + Matlab) справился лучше всех, однако BESA 3 + Matlab затратил излишнее время, так как ICA разложение, не реализованное в BESA 3, велось интерпретатором Matlab и обнаружил излишнее количество источников. NeuroCom незначительно уступил BESA 3 по качеству локализации, но точно определил количество источников и затратил на их поиск меньшее время.

Как указано в предыдущем разделе, данный метод нуждается в дополнительной проработке с целью введения в алгоритм анализа дипольности распределения источника, так как для недипольных источников применять выражение (11) нельзя. В этом случае поиск должен осуществляться по обобщенному алгоритму из выражения (10). После введения такого анализа шаг 11. станет таким: Если распределения коэффициентов  $a_{ij}^u$  по поверхности скальпа носит дипольный характер, то – поиск глобального минимума оценочной функции по выражению (11) градиентным методом или любым специализированным однопараметрическим методом; иначе поиск глобального минимума оценочной функции по выражению (10) градиентным методом.

### Литература

1. Гнездицкий. В.В. Обратная задача ЭЭГ и клиническая электроэнцефалография. – Таганрог: ТГРУ. – 2000. – 640 с.
2. Кисельгов Е.Н. Приближенное решение проблемы референтного электрода в ЭЭГ анализе // Радиоэлектронные и компьютерные системы. – 2006. – №1(13). – С. 115-123.
3. Cardoso J.-F., Laheld B. Equivariant adaptive source separation // IEEE Trans. on Sig. Proc. – 1996. – No. 44. – P. 3017-3030.
4. Jutten C., Herault. J. Blind separation of sources. An adaptive algorithm based on neuromimetic architecture // Signal Processing. – 1991. – No. 24(1). – P. 156-166.
5. Lee Te-Won, Girolami M., Bell A.J., Sejnowski T.J. A Unifying Information-Theoretic Framework for Independent Component Analysis // Computers & mathematics with application. – 2000. – No. 39. – P. 181-202.
6. Lee Te-Won, Girolami M., Sejnowski T.J. Independent Component Analysis using an extended infomax algorithm for mixed sub-gaussian and super-gaussian sources // Neural Computation. – 1998. – No. 11. – P. 609-233.
7. Hyvarinen A. Fast and Robust Fixed-Point Algorithms for Independent Component Analysis // IEEE Transactions on Neural Networks. – 1999. – Vol.3, No. 10. – P. 624-634.
8. Cardoso Jean-Francois. High-Order Contrasts for Independent Component Analysis // Neural Computation. – 1999. – Vol. 11, No. 1. – P. 157-192.
9. Blaschke Tobias, Wiskott Laurenz. CuBICA: Independent Component Analysis by Simultaneous Third- and Fourth-Order Cumulant Diagonalization, Inst. Theoretical Biology // Computer Science Preprint Server (CSPS): Computational Intelligence / 0304002. – 2003. – [Электрон. ресурс]. – Режим доступа: <http://www.compscipreprints.com/comp/Preprint/blaschke/20030409/1/>.
10. Кисельгов Е.Н. Независимый компонентный анализ и его применение к задачам выделения статистически независимых сигналов // Технология приборостроения. – Х.: Харьковский нац. автомобильно-дорожный ун-т. – 2002. – №1-2. – С. 142-147.
11. Gharhremant D., Makeigo S., Hung T.-P., Bell A.J., Sejnowski T.J. Independent Component Analysis of Simulated EEG Using Three-Shell Spherical Head Model // Institute of Neural Computation. – Technical Report. – No. INC-9601.
12. Сергеев В.Г., Кисельгов Е.Н. Новые методы в исследовании ЭЭГ феноменов // Вестник эпилептологии. – К.: ЛДНЦ «Эпилепсия». – 2003. – № 2. – С. 52-59.
13. Кисельгов Е.Н. Рекурсивный пакетный ИСА для неизвестного количества источников // Интегрированные компьютерные технологии в машиностроении ИКТМ'2003. – Х.: Нац. аэрокосм. ун-т «ХАИ», 2003. – № 2. – С. 201-202.

Поступила в редакцию 4.09.2006

**Рецензент:** д-р техн. наук, проф. В.К. Волосюк, Национальный аэрокосмический университет им. Н.Е. Жуковского «ХАИ», Харьков.