

ОБРАБОТКА СИГНАЛОВ DIGITAL PROCESSING OF SIGNALS

УДК 004.3:612.8

DOI: 10.17587/it.26.507-514

О. Г. Щербань, канд. техн. наук, доц., e-mail: shchero@mail.ru,
И. В. Щербань, д-р техн. наук, проф., e-mail: shcheri@mail.ru,
Южный федеральный университет, г. Ростов-на-Дону,
П. В. Лобзенко, канд. техн. наук, доц., e-mail: pasha.van@list.ru,
Московский технический университет связи и информатики

Метод поиска высокочастотных паттернов в составе зашумленных многомерных сигналов в реальном времени¹

Разработан метод поиска и локализации во времени высокочастотных паттернов в составе зашумленных выходных сигналов многомерных динамических объектов в реальном времени наблюдений. На основе аппарата многомерного сингулярного анализа синтезирован полосовой фильтр, адаптивный к вариациям характеристик наблюдаемого сигнала, применение которого к исходному сигналу обеспечивает требуемую чувствительность критериальной функции при поиске паттернов низкой интенсивности.

Ключевые слова: многомерный сингулярный спектральный анализ, адаптивный полосовой фильтр, метрика Хаусдорфа

Введение

Задачи анализа выходных сигналов технологических объектов, технических систем или иных динамических модулей получили широкое практическое распространение. Изменения режимов функционирования исследуемых объектов, всевозможные переходные процессы нередко находят отражение в регистрируемых выходных сигналах в виде различных структурных особенностей — всплесков, аномалий, коротких осцилляций различного частотного диапазона. Временная локализация и идентификация характеристик подобных частотно-временных паттернов обычно позволяет выполнять процедуры диагностирования объектов, или поиска и локализации неисправностей [1, 2], используется в процедурах неразрушающего контроля, в биомедицинских приложениях [3—5], позволяет понять особенности функционирования объектов в условиях возмущений [6], решать другие практические задачи.

¹ Работа выполнена при финансовой поддержке Министерства науки и высшего образования РФ в рамках Постановления №218 "Создание программного комплекса для управления человеческим капиталом на основе нейротехнологий для предприятий высокотехнологического сектора Российской Федерации" (Шифр: 2019-218-11-8185, внутренний номер ХД/19-22-НЙ).

Несмотря на то, что методы поиска таких паттернов в составе многомерных сигналов в настоящее время достаточно хорошо изучены [1, 6], проблемы в некоторых частных случаях все же существуют. Например, в условиях высокой априорной неопределенности частотных и временных характеристик паттернов, при маскировании их осцилляциями, вызванными неизвестными процессами, в условиях высокой зашумленности измеренных сигналов часто невозможно получить достаточную и подробную статистическую информацию об объекте. В работах [7, 8] рассмотрены методы поиска высокочастотных паттернов низкой интенсивности в составе зашумленных многомерных сигналов, работоспособные в условиях, когда характеристики паттернов близки к характеристикам шумовых составляющих сигналов, а точные границы частотных спектров паттернов априорно неизвестны. Общим недостатком представленных в работах [7, 8] методов является тот факт, что они могут быть использованы только лишь апостериорно. Однако известно, что во многих практических задачах поиск и временная локализация паттернов должны выполняться в реальном времени наблюдений динамического объекта [1, 6, 9, 10].

Таким образом, представляет научный и практический интерес излагаемый далее метод

поиска и временной локализации коротких высокочастотных паттернов низкой интенсивности в составе зашумленных выходных сигналов многомерных динамических объектов в реальном времени наблюдений этих сигналов.

1. Формализация задачи, ее декомпозиция, выбор инструментария для решения

Предполагается, что исследуемый динамический объект характеризуется измеряемым выходным многомерным сигналом

$$\mathbf{S}(t) = (s_1(t) \ s_2(t) \ \dots \ s_J(t))^T,$$

где J — число каналов наблюдений; $t \in [t_0; T]$ — независимая переменная (время); t_0 — начальный момент времени измерений, в общем случае равный нулю; T — текущий временной интервал измерений; T — знак транспонирования.

Соответственно, в момент времени T каждая j -я ($j = \overline{1, J}$) компонента $\mathbf{S}_j(T)$ многомерного сигнала \mathbf{S} представляется накапливаемым временным рядом $\mathbf{S}_j(T) = \{s_{j,k}\}_{k=1}^{N_k}$ объемом $N_k = T/\Delta t$ чисел, где Δt — шаг дискретизации. В составе наблюдаемого сигнала $\mathbf{S}(t)$ предполагается наличие периодических коротких высокочастотных осцилляций низкой интенсивности, отражающих какие-либо особенности функционирования исследуемого динамического объекта и существующих на коротких временных интервалах, существенно меньших интервала времени измерений T . Требуется найти положение по оси времени подобных паттернов при допустимости вариаций по каналам измерений форм паттернов.

Решение сформулированной задачи предлагается осуществлять на основе последовательного выполнения следующих двух процедур. Вначале целесообразно выполнить фильтрацию исходного многомерного сигнала с целью выделить тот частотный диапазон, который примерно соответствует спектру частот искомым паттернов. Это, несомненно, повысит чувствительность критериальной функции, которую следует использовать далее, после фильтрации, в целях поиска паттернов уже в узкополосном многомерном сигнале.

Исходя из требования к реализации процесса поиска в реальном времени наблюдений необходимо предусмотреть возможность адаптации используемых процедур фильтрации к вариациям параметров регистрируемого сигнала $\mathbf{S}(t)$. Известно, что так называемый аппарат сингулярного спектрального анализа (*Singular*

Spectrum Analysis, SSA), в русскоязычном варианте именуемый "гусеница", фактически представляет собой набор из M линейных полосовых фильтров [11–14]. В отличие от традиционных фильтров, основанных на преобразовании Фурье [6, 15], дискретном или непрерывном вейвлет-разложениях сигналов [16], фильтры на основе *SSA* обладают адаптивностью к изменениям характеристик исходного сигнала и легко перестраиваются в реальном времени. Это позволяет разделять гармонические компоненты, даже пересекающиеся в частотно-временном пространстве (при определенных условиях). Таким образом, например, решены задачи удаления низкочастотных артефактов из электроэнцефалограмм (ЭЭГ) [17, 18], качественного подавления высокочастотного шума [19], высокоточной фильтрации сигналов [20]. В работе [17] синтезирован метод автоматического удаления низкочастотных артефактов в реальном времени регистрации сигналов ЭЭГ. Метод был разработан для обеспечения возможности технической реализации портативных носимых устройств, регистрирующих ЭЭГ мозга человека.

Последующий после фильтрации анализ сигналов можно осуществлять на основе сравнения двух текущих соседних неперекрывающихся временных выборок (окон), равных по объему и содержащих по $n < N_k$ одноименных отсчетов с каждого j -го ($j = \overline{1, J}$) канала измерений. Иными словами, если в текущем окне в составе многомерного сигнала присутствуют искомые паттерны — какие-либо структурные особенности, высокочастотные осцилляции, отличающие эту временную выборку от предыдущей временной выборки, — то этот факт должна отражать соответствующая критериальная функция. Таким образом, с дискретностью n отсчетов можно определить временные границы начала и окончания искомым паттернов в составе зашумленных выходных сигналов многомерных динамических объектов в реальном времени их наблюдений.

2. Метод и алгоритм поиска структурных особенностей в составе зашумленных многомерных сигналов в реальном времени измерений

Применительно к сигналу $\mathbf{S}(t)$ будем использовать многомерный *SSA (Multi-channel SSA, MSSA)* [14]. Для уменьшения влияния так называемых "граничных эффектов" аппарат

MSSA будем применять не отдельно к каждой временной выборке, а на всем текущем временном интервале наблюдений T , т. е. будем применять его ко всему накопленному J -мерному временному ряду из N_k отсчетов.

Согласно концепции *MSSA* [14] составим блочную траекторную матрицу

$$\mathbf{X}(T) = (\mathbf{X}_1 | \mathbf{X}_2 | \dots | \mathbf{X}_j | \dots | \mathbf{X}_J), \quad (1)$$

$$\text{где } X_j = \begin{pmatrix} s_{j,1} & s_{j,2} & \dots & s_{j,k} & \dots & s_{j,K} \\ s_{j,2} & s_{j,3} & \dots & s_{j,k+1} & \dots & s_{j,K+1} \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ s_{j,M} & s_{j,M+1} & \dots & s_{j,M+k} & \dots & s_{j,N_k} \end{pmatrix} -$$

ганкелева матрица размерности $\dim(X_j) = M \times K$, формируемая для каждой j -й составляющей ЭЭГ в отдельности; M — длина гусеницы (размерность вложения); $K = N_k - M + 1$. Сингулярное разложение усредненной выборочной корреляционной матрицы

$$\mathbf{C} = \frac{1}{K} \mathbf{X} \mathbf{X}^T$$

имеет вид

$$\mathbf{C} = \mathbf{V} \mathbf{\Lambda} \mathbf{V}^T,$$

где $\mathbf{\Lambda} = \text{diag}(\lambda_1 \lambda_2 \dots \lambda_{MJ})$ — диагональная матрица собственных чисел; $\mathbf{V} = (\mathbf{V}_1 \dots \mathbf{V}_i \dots \mathbf{V}_{MJ})$ — ортогональная матрица собственных векторов \mathbf{V}_i матрицы \mathbf{C} , $\dim(\mathbf{V}_i) = (MJ) \times 1$. Используя процедуру упорядочения собственных векторов \mathbf{V}_i по убыванию соответствующих собственных чисел $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_{MJ} \geq 0$ далее вычисляем матрицу нецентрированных главных компонент, а восстанавливаемую матрицу $\tilde{\mathbf{X}}(T)$ при этом рассчитываем как сумму

$$\tilde{\mathbf{X}}(T) = \sum_{m=1}^M \tilde{\mathbf{X}}_m(T) \quad (2)$$

блочных ганкелев матриц $\tilde{\mathbf{X}}_1 = (\tilde{\mathbf{X}}_{1,1} | \tilde{\mathbf{X}}_{1,2} | \dots | \tilde{\mathbf{X}}_{1,J})$, $\tilde{\mathbf{X}}_2 = (\tilde{\mathbf{X}}_{2,1} | \tilde{\mathbf{X}}_{2,2} | \dots | \tilde{\mathbf{X}}_{2,J})$, ..., $\tilde{\mathbf{X}}_M = (\tilde{\mathbf{X}}_{M,1} | \tilde{\mathbf{X}}_{M,2} | \dots | \tilde{\mathbf{X}}_{M,J})$, порожденных соответствующими собственными векторами \mathbf{V}_i матрицы \mathbf{C} . В ходе исследований было выяснено, что в дополнительных процедурах центрирования по столбцам и нормирования по среднеквадратическим отклонениям исходной траекторной матрицы \mathbf{X} (1) с последующим децентрированием и денормированием восстановленной матрицы $\tilde{\mathbf{X}}$ (2) [12, 14] необходимости нет.

Применение процедур антидиагонального усреднения к каждой из матриц $\tilde{\mathbf{X}}_1, \dots, \tilde{\mathbf{X}}_M$ (2)

позволяет сформировать M соответствующих узкополосных многомерных сигналов вида

$$\begin{aligned} \tilde{\mathbf{S}}_1(T) &= (\tilde{\mathbf{S}}_{1,1} \tilde{\mathbf{S}}_{1,2} \dots \tilde{\mathbf{S}}_{1,J}), \dots, \\ \dots \tilde{\mathbf{S}}_M(T) &= (\tilde{\mathbf{S}}_{M,1} \tilde{\mathbf{S}}_{M,2} \dots \tilde{\mathbf{S}}_{M,J}). \end{aligned} \quad (3)$$

При этом каждый m -й ($m = \overline{1, M}$) многомерный сигнал $\tilde{\mathbf{S}}_m(T)$ из соотношений (3) ограничен полосой частот $f_m \in [f_m^H, f_m^B]$, где f_m^H, f_m^B — верхняя и нижняя границы его частотного спектра. Иными словами, процедура *MSSA* представляет собой фильтрацию исходного сигнала набором из M линейных полосовых фильтров, посредством чего каждый j -й исходный временной ряд $\tilde{\mathbf{S}}_{1,j}(T), \dots, \tilde{\mathbf{S}}_{M,j}(T)$ разделяется на M временных рядов $\tilde{\mathbf{S}}_{1,j}(T), \dots, \tilde{\mathbf{S}}_{M,j}(T)$, частотные спектры которых

$$\begin{aligned} \Delta F_{1,j} &= f_{1,j}^B - f_{1,j}^H, \dots, \Delta F_{M,j} = f_{M,j}^B - f_{M,j}^H; \\ j &= \overline{1, J}, \end{aligned} \quad (4)$$

могут пересекаться, но верхние границы спектров упорядочены по возрастанию $f_{1,j}^B \leq f_{2,j}^B \leq \dots \leq f_{M,j}^B$, а $f_{M,j}^B = 0,5f_s$, где $f_s = 1/\Delta t$ — частота дискретизации. Таким образом, характеристики полосовых фильтров (ПФ) определяются размерностью вложения M . Задавая различные значения размерности вложения M и выбирая по определенному правилу из найденных M узкополосных многомерных сигналов лишь некоторые, можно реализовать фильтрацию измеренного сигнала $\mathbf{S}(T)$ [12, 17, 20].

В решаемой задаче в составе сигнала $\mathbf{S}(T)$ предполагается поиск относительно высокочастотных осцилляций. Поэтому для повышения чувствительности такого поиска необходим ПФ с полосой пропускания, максимально соответствующей частотному спектру искомым паттернов. Ясно, что ПФ, синтезируемый на основе *MSSA*, можно реализовать посредством восстановления сигнала не по всем M , а лишь по некоторым $M' < M$ узкополосным сигналам из соотношений (3) следующим образом:

$$\tilde{\mathbf{S}}'_\Sigma(M', T) = \sum_{m=m_H}^{m=m_B} \tilde{\mathbf{S}}_m(T); \quad M' = m_B - m_H + 1, \quad (5)$$

где m_H, m_B — номера, соответственно, самого низкочастотного и самого высокочастотного из учитываемых узкополосных сигналов $\tilde{\mathbf{S}}_m(T)$ (3). Усредненный спектр $\Delta F'$ суммар-

ного сигнала (5) также, естественно, является функцией учитываемых членов M' :

$$\Delta F' = \frac{1}{M'J} \sum_{m=m_H}^{m_B} \sum_{j=1}^J \Delta F_{m,j}. \quad (6)$$

Исходя из особенностей функционирования исследуемого динамического объекта можно отметить, что примерные границы частотного спектра искомых паттернов в каждом практическом случае априорно известны. Поэтому выбирать диапазон M' будем так, чтобы спектр $\Delta F'(M')$ (6) восстанавливаемого сигнала \tilde{S}'_{Σ} (5) гарантированно соответствовал бы спектру искомых паттернов ΔF_{Π} :

$$\Delta F' \approx \Delta F_{\Pi},$$

где $\Delta F_{\Pi} = f_{\Pi}^B - f_{\Pi}^H$; f_{Π}^H и f_{Π}^B — граничные значения расширенного частотного спектра искомых паттернов.

Следуя результатам работ [11–14, 17, 20], во-первых, на M можно наложить ограничение "сверху" $M_{\max} \leq 0,5N_k$. Во-вторых, для поиска оптимальных значений m_H и m_B можно воспользоваться известным условием оптимизации отношения функций спектральной плотности мощности (СПМ) в полосах "пропускания—подавления", часто используемым для синтеза адаптивных Фурье-фильтров [15]. В рассматриваемом случае подобная критериальная функция для выбора оптимального диапазона M'_{opt} будет иметь вид

$$M'_{opt}(m_H, m_B) = \arg \min_{\substack{m_H < m_B < M_{\max} \\ (m_H+1) < m_B}} \left\{ \frac{\sum_{f < f_{\Pi}^H} P'(f) + \sum_{f > f_{\Pi}^B} P'(f)}{\sum_{f \in [f_{\Pi}^H, f_{\Pi}^B]} P'(f)} \right\}, \quad (7)$$

где $P'(f)$ — усредненные по каналам измерений функции СПМ многомерного сигнала $\tilde{S}'_{\Sigma}(M'_{opt}, T)$ (5) в соответствующем диапазоне частот f . Спектр сигнала $\tilde{S}'_{\Sigma}(M'_{opt}, T)$ при этом будет максимально соответствовать диапазону частот $[f_{\Pi}^H, f_{\Pi}^B]$. Из работы [15] известно, что при таком подходе обеспечиваются и требуемые свойства адаптивности фильтрации к вариациям параметров исходного сигнала $S(t)$.

Для последующего поиска и временной локализации паттернов в восстановленном сигнале (5) необходимо также сформулировать критериальную функцию. Решение будем осуществлять на основе сравнения двух соседних неперекрывающихся временных выборок (окон), равных по объему n отсчетов. Каждое

такое временное окно представляет собой матрицу $J \times n$, иными словами, "изображение" объемом $J \times n$ пикселей. Каждое "изображение" принадлежит одномерному пространству признаков, на котором можно задать метрику, позволяющую оценить расстояние между двумя соседними "изображениями". В качестве подобной меры близости часто используют метрику Хаусдорфа (МХ) [21, 22], которую применительно к рассматриваемой задаче можно записать следующим образом:

$$d_H(A, B) = \max_{a \in A} \{ \min_{b \in B} \{ \|a, b\| \} \}, \quad (8)$$

где $\|a, b\|$ — евклидово расстояние между отсчетами (пикселями) a и b текущей и предыдущей временных выборок (окон) A и B . Если в какой-либо из соседних выборок присутствуют какие-то особенные частотные осцилляции, то критериальная функция d_H (8) принимает высокое значение. Таким образом, с дискретностью n отсчетов можно определить временные границы начала и окончания искомых паттернов.

Алгоритм применения разработанного метода временной локализации коротких высокочастотных паттернов низкой интенсивности в составе зашумленных выходных сигналов многомерных динамических объектов в реальном времени измерений представлен на рис. 1.



Рис. 1. Алгоритм разработанного метода

Размерности выборок для расчета МХ одинаковы и равны $n < N_k$. Свойства адаптивности синтезированного ПФ обеспечиваются за счет оптимального, основанного на характеристиках измеряемого сигнала, выбора (7). Целесообразно на каждой итерации цикла сдвигать границы временной выборки t_0 и t_k на n отсчетов — на ширину бегущего временного окна (рис. 1). В этом случае анализируемый интервал постоянен — $T = \text{const}$, и фильтр, можно так сказать, "забывает далекую историю", выделяя текущие особенности измеряемого сигнала.

3. Вычислительный эксперимент

В ходе исследований воспользовались известной математической моделью ЭЭГ мозга, представленной в работах [23, 24]. Модель позволяет полноценно воспроизвести ЭЭГ-подобные сигналы и имитировать в их составе различные нелинейные явления, отражающие как спонтанную низкочастотную активность организма, так и высокочастотную биоэлектрическую активность. Как известно, низкочастотные осцилляции — артефакты — маскируют интересующую исследователей высокочастотную биоэлектрическую активность [5, 7–9]. К высокочастотной активности отно-

сят физиологические ритмы "гамма" в диапазоне от 30 до 150 Гц и выше [5]. В ходе биомедицинских исследований часто необходимо в реальном времени наблюдения сигналов ЭЭГ выделять временные границы именно биоэлектрической активности гамма-ритмов.

Модель включала $J = 8$ каналов ЭЭГ. По каналам задавались разные сигналы, отличающиеся характеристиками высокочастотных шумовых составляющих. В одном-двух каналах из 8 моделировались инвертированные сигналы ЭЭГ. На рис. 2 представлены временные выборки характерных модельных ЭЭГ по четырём каналам измерений.

Искомая периодическая гамма-активность имитировалась в полосе частот [50; 200] Гц во всех восьми каналах с вариациями форм по каналам. Длительность паттернов выбиралась равной 150...250 мс и была синхронизирована с фазой "вдоха". На рис. 3 показаны примеры паттернов гамма-активности по двум каналам, а также их спектр. В целях увеличения неопределенности граничные значения расширенного частотного спектра задавались с существенной ошибкой — смещенными относительно реального спектра модельных паттернов и равными $f_{\Pi}^H = 30$, $f_{\Pi}^B = 120$ Гц.

Моделировались гамма-ритмы с высокой и низкой амплитудой. Размах колебаний паттернов составлял при этом, соответственно, около 28 % и около 14 % от размаха колебаний фоновой ЭЭГ. Временная выборка, показанная на рис. 2, содержит пять участков гамма-активности, из которых 1 и 4 — участки с высокой интенсивностью гамма-активности, 2, 3, 5 — с низкой.

Ясно, что временные границы начала и окончания активности в области гамма-ритмов представлялись при моделировании "априорно неизвестными", а критериальная функция d_H (8) должна была наглядно отображать эти временные границы. График функции МХ d_H (8), рассчитанный на основе разработанного алгоритма (см. рис. 1), также показан




Рис. 2. Графики модельных ЭЭГ по четырём каналам и критериальной функции d_H (8)




Рис. 3. Примеры гамма-ритмов по двум каналам (а) и спектр модельной гамма-активности (б)

на рис. 2. Из графика видно, что критериальная функция обеспечивает правильную локализацию по оси времени как паттернов гамма-активности высокой интенсивности, так и низкоамплитудных паттернов. Погрешности определения временных границ паттернов при этом не превышали половины скользящего временного окна $0,5n$, что составляло 50 мс.

Временная выборка, показанная на рис. 4, содержит два низкочастотных артефакта на интервалах [1700; 1900] и [2600; 4400] отсчетов (мс), а также четыре участка гамма-активности, из которых 1 и 3 — участки с высокой интенсивностью, 2 и 4 — с низкой.

Видно, что критериальная функция d_H (8) снова позволила правильно определить временные границы всех четырех интервалов активности в области физиологических ритмов "гамма".

Значения m_H , m_B оптимального диапазона M'_{opt} , определяемые из критерия (7), менялись в зависимости от наличия или отсутствия в ЭЭГ низкочастотных артефактов,

что свидетельствует об адаптивных свойствах синтезированного ПФ. Следует отметить, что минимальные значения самой критериальной функции (7) как при наличии, так и в отсутствие артефактов были практически постоянными и равны примерно 1,30.

В целях сравнительного анализа вместо синтезированного адаптивного фильтра в алгоритме был также использован ПФ Баттерворта 6-го порядка [15] с теми же "смещенными" частотами среза — $f_n^H = 30$ и $f_n^B = 120$ Гц. Критериальная функция (7) при отсутствии низкочастотных артефактов в этом случае была равна 1,34, что, как видно, хуже в сравнении с синтезированным ПФ на основе *MSSA*. На рис. 5 показаны графики функций $Mx d_H$ (8) для временной выборки из рис. 2, рассчитанные после применения синтезированного ПФ на основе *MSSA* (сплошная линия на графике) и ПФ Баттерворта (пунктирная линия). Видно, что применение ПФ Баттерворта к исходному сигналу не обеспечивает требуемую для поиска гамма-активности чувстви-

тельность критериальной функции (8).

При наличии низкочастотных артефактов разница в значениях критериальной функции (7) существенно увеличивалась для исследуемых фильтров. Если для ПФ на основе *MSSA* она оставалась прежней — около 1,30, то для ПФ Баттерворта эта величина повышалась уже до значения 1,51. При задании, например, нижней частоты среза ПФ Баттерворта без ошибки равной $f_n^H = 50$ Гц значение критериальной функции (7) улучшалось и было равно 1,42. Из представленных результатов следует, что синтезированный ПФ действительно обладает свойством адаптации к изменениям параметров исходного сигнала в области низких частот и может быть реализован в реальном времени наблюдений ЭЭГ, в то время как ПФ на основе Баттерворта требует точной подстройки частот среза, без чего, ясно, адаптивностью не обладает.




Рис. 4. Графики модельных ЭЭГ по четырем каналам при наличии низкочастотных артефактов, а также критериальной функции d_H (8)




Рис. 5. Графики функций $Mx d_H$ (8) при использовании синтезированного ПФ (сплошная линия) и ПФ Баттерворта (пунктирная линия)

Также следует отметить тот факт, что временные границы моделированной гамма-активности низкой интенсивности найти визуально в составе многомерной ЭЭГ принципиально невозможно.

Заключение

Разработанный ПФ на основе *MSSA* обладает свойством адаптивности к вариациям характеристик наблюдаемого многомерного сигнала и легко перестраивается в реальном времени. Его применение к исходному сигналу обеспечивает, в итоге, требуемую чувствительность критериальной функции поиска высокочастотных паттернов низкой интенсивности в составе зашумленных выходных сигналов многомерных динамических объектов. Это, в итоге, позволяет правильно найти положение по оси времени границ паттернов. И, окончательно, алгоритм, построенный на основе разработанного метода, реализуем в реальном времени измерений выходных сигналов многомерных динамических объектов.

Список литературы

1. Мироновский Л. А. Функциональное диагностирование динамических систем (обзор) // Автоматика и телемеханика. 1980. № 8. С. 96–121.
2. Мисриханов А. М. Применение методов вейвлет-преобразования в электроэнергетике // Автоматика и телемеханика. 2006. № 5. С. 5–23.
3. Гнездицкий В. В. Обратная задача ЭЭГ и клиническая электроэнцефалография (картирование и локализация источников электрической активности мозга). М.: МЕД-пресс-информ, 2004. 624 с.
4. Basar E., Schurmann M., Demiralp T., Basar-Eroglu C., Ademoglu A. Event-related Oscillations are 'Real Brain Responses'—Wavelet-Analysis and New Strategies // Int. J. Psychophysiol. 2001. N. 39. P. 91–127.
5. Rangayyan R. M. Biomedical Signal Analysis: A Case-Study Approach. Wiley-IEEE Press, 2007. 440 p.
6. Справочник по теории автоматического управления / Под ред. А. А. Красовского. М.: Наука, 1987. 712 с.
7. Щербань И. В., Кириленко Н. Е., Щербань О. Г. Эффективные критериальные функции спектральной энтропии для поиска высокочастотных паттернов в составе зашум-

ленных электрограмм // Информационно-управляющие системы. 2018. № 2. С. 8–17.

8. Щербань И. В., Кириленко Н. Е., Красников С. О. Метод временной локализации неизвестных высокочастотных осцилляторов в составе зашумленных сигналов на основе непрерывного вейвлет-преобразования // Автоматика и телемеханика. 2019. № 7. С. 122–133.

9. Горшков А. А., Осадчий А. Е., Фрадков А. Л. Регуляризация обратной задачи ЭЭГ/МЭГ локальным кортикальным волновым паттерном // Информационно-управляющие системы. 2017. № 5. С. 12–20.

10. Гуляев С. А., Архипенко И. В. Артефакты электроэнцефалографического исследования: их выявление и дифференциальный диагноз // Русский медицинский журнал. 2013. № 10. С. 486–491.

11. Elsner J. B., Tsonis A. A. Singular Spectrum Analysis: A New Tool in Time Series Analysis. New York and London: Plenum Press, 1996. 164 p.

12. Данилов Д. Л., Жиглявский А. А. Главные компоненты временных рядов: метод "Гусеница". СПб.: Пресском, 1997. 308 с.

13. Golyandina N., Nekrutkin V., Zhigljavsky A. Analysis of Time Series Structure: SSA and Related Techniques. London: Chapman&Hall/CRC, 2001. 305 p.

14. Golyandina N., Stepanov D. SSA-based approaches to analysis and forecast of multidimensional time series // Proc. 5th St. Petersburg Workshop on Simulation. St. Petersburg, Russian Federation, 2005. P. 293–298.

15. Тихонов В. И. Оптимальный прием сигналов. М.: Радио и связь, 1983. 320 с.

16. Смоленцев Н. К. Основы теории вейвлетов. Вейвлеты в MATLAB. М.: ДМК Пресс, 2005. 305 с.

17. Hu H., Guo S., Liu R., Wang P. An adaptive singular spectrum analysis method for extracting brain rhythms of electroencephalography // PeerJ. 2017. N. 6, e3474.

18. Sanctis S., Malloni W. M., Kremer W., Tomé A. M., Lang E. W., Neidig K. P., Kalbitzer H. R. Singular spectrum analysis for an automated solvent artifact removal and baseline correction of 1D NMR spectra // Journal of Magnetic Resonance. 2011. N. 210. P. 177–183.

19. Ghaderi F., Mohseni H. R., Sanei S. Localizing heart sounds in respiratory signals using singular spectrum analysis // IEEE Transactions on Biomedical Engineering. 2011. N. 58. P. 3360–3367.

20. Maddirala A. K., Shaik R. A. Motion artifact removal from single channel electroencephalogram signals using singular spectrum analysis // Biomedical Signal Processing and Control. 2016. N. 30. P. 79–85.

21. Герман В., Пахомов А., Никитов С., Потапов А. Новейшие методы обработки изображений / Под ред. А. А. Потапова. М.: ФИЗМАТЛИТ, 2008. 496 с.

22. Михайлов И. А. Распознавание изображений с помощью метода радиальных окрестностей // Компьютерная оптика. 2010. № 3. С. 399–407.

23. Bai O., Nakamura M., Ikeda A., Shibasaki H. Nonlinear Markov Process Amplitude EEG Model for Nonlinear Coupling Interaction of Spontaneous EEG // IEEE Transactions On Biomedicine Engineering. 2000. Vol. 47, N. 9. P. 1141–1146.

24. Bai O., Nakamura M., Nishida S., Ikeda A., Shibasaki H. Markov Process Amplitude EEG Model for Spontaneous Background Activity // Journal of Clinical Neurophysiology. 2001. N. 18(3). P. 283–290.

O. G. Shcherban, Assistant Professor, e-mail: shchero@mail.ru,

I. V. Shcherban, Professor, e-mail: shcheri@mail.ru,

Southern Federal University, Rostov-on-Don,

P. V. Lobzenko, Assistant Professor, e-mail: pasha.van@list.ru,

Moscow Technical University of Communications and Informatics

The Real-Time Method for the Temporal Localization of the High-Frequency Patterns in Noised Multichannel Signals

The problems of the real-time searching and temporal localization of the short-time patterns in the multichannel signals are important in many practical cases. The desired patterns can be masked by the high-frequency noise and low-frequency artifacts. The known approaches of the high precision searching for the low-intensity patterns can be used during an a posteriori analysis of the signals. The real-time method for the searching and temporal localization for the short-time low intensity patterns in multidimensional dynamic objects noised output signals has been considered. We synthesized an adaptive multichannel singular spectrum analysis (MSSA) band-pass filter (BPF). Based on the power spectral density of the signal amplitude the grouping rule determines adaptively the MSSA reconstructed components as low-frequency artifacts or high-frequency noise and removes them. The grouping rule thus enables BPF to be adaptive to the output signals containing different levels of the low-frequency artifacts or high-frequency noise. This provides the required sensitivity of the criterial function for the real-time searching and temporal localization for the low intensity patterns. The distance Hausdorff metric was used to measure the similarity of the two current neighboring non-overlapping time samples from the multichannel output signals. A computational experiment results illustrating the efficiency of the use of the method developed has been given. The eight channel electroencephalography (EEG) signal based on the Markov Process Amplitude EEG model were used to verify the developed method. Results showed a better performance in the real-time searching of the low intensity patterns, compared with the method, based on the Butterworth bandpass Fourier filter.

Keywords: real-time searching, short-time patterns, output signals, multidimensional dynamic objects, multichannel singular spectrum analysis, adaptive bandpass filter, the Hausdorff metric

DOI: 10.17587/it.26.507-514

References

1. **Mironovskii L. A.** Functional diagnosis of dynamic systems, *Avtomat. i Telemekh.*, 1980, no. 8, pp. 96–121 (in Russian).
2. **Misrikhanov A. M.** Wavelet Transform Methods: Application in Electroenergetics, *Autom. Remote Control*, 2006, vol. 67, no. 5, pp. 682–697.
3. **Gnezdickij V. V.** Reverse EEG challenge and clinical electroencephalography, Moscow, MEDpress-inform Publ., 2004, 624 p. (in Russian).
4. **Basar E., Schurmann M., Demiralp T., Basar-Eroglu C., Ademoglu A.** Event-related Oscillations are ‘Real Brain Responses’ – Wavelet-Analysis and New Strategies, *Int. J. Psychophysiol.*, 2001, no. 39, pp. 91–127.
5. **Rangayyan R. M.** Biomedical Signal Analysis: A Case-Study Approach, Wiley-IEEE Press, 2007, 440 p.
6. **Krasovskij A. A.** eds. The Theory Of Automatic Control, Moscow, Nauka, 1987, 720 p. (in Russian).
7. **Shcherban I. V., Kirilenko N. E., Shcherban O. G.** Effective cost functions for spectrum entropy to search for high-frequency event-related patterns in electrograms with noise, *Informatsionno-Upravliaiushchie Sistemy*, 2018, vol. 2018, no. 2, pp. 8–17 (in Russian).
8. **Shcherban I. V., Kirilenko N. E., Krasnikov S. O.** A Search Method for Unknown High-Frequency Oscillators in Noisy Signals Based on the Continuous Wavelet Transform, *Autom. Remote Control*, 2019, vol. 80, no. 7, pp. 1279–1287.
9. **Gorshkov A. A., Osadchi A. E., Fradkov A. L.** Regularization of EEG/MEG Inverse Problem with a Local Cortical Wave Pattern, *Informatsionno-Upravliaiushchie Sistemy*, 2017, no. 5, pp. 12–20 (in Russian).
10. **Gulyaev S. A., Arhipenko I. V.** Electroencephalographic investigation artifacts: their identification and differential diagnosis, *Russian Medical Journal*, 2013, no. 10, pp. 486–491 (in Russian).
11. **Elsner J. B., Tsonis A. A.** Singular Spectrum Analysis: A New Tool in Time Series Analysis, New York and London, Plenum Press, 1996, 164 p.
12. **Danilov D. L., Zhiglyavskij A. A.** Principal components of time series structure: SSA, St. Petersburg, Presskom Publ., 1997, 308 p. (in Russian).
13. **Golyandina N., Nekrutkin V., Zhigljavsky A.** Analysis of Time Series Structure: SSA and Related Techniques, London, Chapman&Hall/CRC, 2001, 305 p.
14. **Golyandina N., Stepanov D.** SSA-based approaches to analysis and forecast of multidimensional time series, *Proc. 5th St. Petersburg Workshop on Simulation*, St. Petersburg, Russian Federation, 2005, pp. 293–298 (in Russian).
15. **Tihonov V. I.** Optimal radio reception, Moscow, Radio and communication Publ., 1983, 320 p. (in Russian).
16. **Smolencev N. K.** Fundamentals of the theory of wavelets. Wavelets in MATLAB, Moscow, DMK Publ., 2005, 305 p. (in Russian).
17. **Hu H., Guo S., Liu R., Wang P.** An adaptive singular spectrum analysis method for extracting brain rhythms of electroencephalography, *PeerJ*, 2017, no. 6, e3474.
18. **Sanctis S., Malloni W. M., Kremer W., Tomé A. M., Lang E. W., Neidig K. P., Kalbitzer H. R.** Singular spectrum analysis for an automated solvent artifact removal and baseline correction of 1D NMR spectra, *Journal of Magnetic Resonance*, 2011, no. 210, pp. 177–183.
19. **Ghaderi F., Mohseni H. R., Sanei S.** Localizing heart sounds in respiratory signals using singular spectrum analysis, *IEEE Transactions on Biomedical Engineering*, 2011, no. 58, pp. 3360–3367.
20. **Maddiral A. K., Shaik R. A.** Motion artifact removal from single channel electroencephalogram signals using singular spectrum analysis, *Biomedical Signal Processing and Control*, 2016, no. 30, pp. 79–85.
21. **German V., Pahomov A., Nikitov S., Potapov A.** The newest image processing techniques, Moscow, FIZMATLIT Publ., 2008. 496 p. (in Russian).
22. **Mikhaylov I. A.** Image recognition using a radial neighborhood method. *Computer Optics*, 2010, vol. 34, no. 3, pp. 399–407.
23. **Bai O., Nakamura M., Ikeda A., Shibasaki H.** Nonlinear Markov Process Amplitude EEG Model for Nonlinear Coupling Interaction of Spontaneous EEG, *IEEE Transactions On Biomedicine Engineering*, 2000, vol. 47, no. 9, pp. 1141–1146.
24. **Bai O., Nakamura M., Nishida S., Ikeda A., Shibasaki H.** Markov Process Amplitude EEG Model for Spontaneous Background Activity, *Journal of Clinical Neurophysiology*, 2001, no. 18(3), pp. 283–290.