

системах подготовки и оптимизации входной информации для генераторов изображений микрочиповых установок.

СПИСОК ЦИТИРОВАННЫХ ИСТОЧНИКОВ

1. Ласло М. Вычислительная геометрия и компьютерная графика на C++ / Пер. с англ. М.: БИНОМ, 1997. 304 с.

2. Препарата Ф., Шеймос М. Вычислительная геометрия: Введение / Пер. с англ. М.: Мир, 1989. 478 с.

3. Фейнберг В.З. Геометрические задачи машинной графики больших интегральных схем // М.: Радио и связь 1987.-178 с.

4. Никулин Е.А. Компьютерная геометрия и алгоритмы машинной графики – СПб.: БХ-Петербург, 2005. – 576 с.

Материал поступил в редакцию 20.09.2008

BUTOV A.A. Method for set association of crossed contours

One of – An association for set of contours is considered in this paper. This classical problems of computing geometry has an application in the automated systems of input data preparation and optimisation for layout generators. The purpose of the work is to search for set of crossed contours B_1, B_2, \dots, B_n the output contour B^j and some set of so-called contours-cuts C_1, C_2, \dots, C_p representing those internal areas of contour B^j which points do not inhere any of united contours. Object of research is the set of contours, i. e. elements of layout patterns.

A method for set association of the crossed contours was developed. This method basis on such operations, as marking of end points of edges, transformation of edges to alternating pieces of straight lines and formation on their basis output contour and contours-cuts. The proposed method allows carry out analysis correctness of a covering for multiply connected polygons by rectangles at manufacturing of microcircuit.

УДК 004.8.032.26

Безобразова С.В., Головки В.А., Евстигнеев В.В.

ВСПОМОГАТЕЛЬНАЯ ДИАГНОСТИЧЕСКАЯ СИСТЕМА ДЛЯ АНАЛИЗА СИГНАЛОВ ЭЛЕКТРОЭНЦЕФАЛОГРАММЫ НЕЙРОСЕТЕВЫМИ МЕТОДАМИ

Введение. Электроэнцефалография, открытая австрийским психиатром и психофизиологом Хансом Бергером в 1924 году [1], и сегодня является основным методом исследования функциональной активности головного мозга человека. С развитием технологий появилось множество вспомогательных исследований, таких как компьютерная томография, магнитно-резонансная томография, позитронно-эмиссионная томография, которые позволяют производить уточнение диагноза эпилепсии. Заболевание эпилепсией носит внезапный характер появления припадков, что осложняет выявление и диагностику этого заболевания. Постановка точного диагноза является основой проведения успешного лечения.

Разработано множество методов для изучения и анализа сигналов электроэнцефалограммы (ЭЭГ) с целью выявления патологических изменений мозга во время эпилептических припадков [2]. Многие из этих методов уже используются в клиниках. Например, Фурье-анализ позволяет производить спектральный анализ сигнала, однако имеет ряд существенных недостатков. Фурье-анализ предназначен для работы с линейными процессами и при обработке нестационарного сигнала, когда происходит смена состояний в системе, дает усредненные показатели для всего анализируемого сигнала [3]. Использование Вейвлет-анализа позволяет решить проблему обработки нестационарных сигналов, однако требует применения методов распознавания образов, которые получаются в результате преобразования [3-5]. Результаты применения Вейвлет-анализа для исследования ЭЭГ сигналов показывают, что данный метод не позволяет отличить патологическую активность от артефактов (проявление мускульной и другой активности на ЭЭГ), а также не всегда обнаруживает аномалии в сигналах [5].

Не смотря на проведение широких исследований в области анализа ЭЭГ, самым эффективным считается метод визуальной оценки. При этом даже опытные врачи расходятся во мнении, принимая один и тот же паттерн за аномальную активность либо за артефакт. Также не существует единого мнения о том, где фиксировать начало появления эпилептиформной активности и где она завершается [6]. Все вышеописанное приводит к идее оценить ЭЭГ сигнал какой-то величиной, которая могла бы характеризовать изменения функциональной активности, то есть фиксировать появление аномалий из-

менением этой величины.

ЭЭГ описывает поведение сложной динамической системы, и характер нормальной активности ЭЭГ сигнала является хаотическим. При возникновении в ЭЭГ сигнале всплеск эпилептиформной активности отмечается снижение сложности сигнала, что приводит к снижению хаоса. Для оценки таких изменений возможно применение теории хаоса и нелинейной динамики. В качестве характеристических величин применимы корреляционная размерность восстановления аттрактора и старший показатель Ляпунова ($Lmax$) [7].

Следует отметить, что для обнаружения одиночных эпилептиформных активностей, длительность которых на ЭЭГ очень мала (от 20-100 мс), необходимо использовать методы, способные обрабатывать малые объемы данных. Именно поэтому в результате применения расчета $Lmax$ для больших фрагментов данных (2 - 10 сек) не получается выявить никаких изменений. Применяемый нами нейросетевой подход позволяет вычислять значение $Lmax$ для выборки малого объема за счет обобщающей способности искусственных нейронных сетей (ИНС) [8]. Для определения участков расчета, как условно-стационарных предлагается использовать адаптивную сегментацию при помощи прогнозирующей ИНС [9]. Данный метод сегментации позволяет выделять сегменты небольшой длительности, достаточные для выявления аномальных активностей.

Данная статья посвящена описанию вспомогательной диагностической системы для обнаружения эпилептиформной активности. В первом разделе представлена структура системы и описаны модули, на основании которых строится система, а также взаимодействие этих модулей. Приведены алгоритмы и методы, реализованные в каждом модуле, а также промежуточные результаты системы, наглядно отображающие работу модулей, для тестовых сигналов. Второй раздел содержит описание исходных данных, используемых для экспериментальных исследований системы. В третьем разделе приводятся результаты экспериментов, их анализ. Статья завершается выводами о проведенной научной работе.

1. Описание системы. Структура разработанной нами системы обнаружения эпилептиформной активности и вспомогательной диагностики эпилепсии представлена на рисунке 1.

Безобразова Светлана Владимировна, аспирант кафедры «Интеллектуальные информационные технологии» Брестского государственного технического университета.

Беларусь, БрГТУ, 224017, г. Брест, ул. Московская, 267.

Евстигнеев Виктор Владимирович, профессор, д.м.н., заслуженный деятель науки Республики Беларусь, профессор кафедры «Неврология и нейрохирургия» Белорусской медицинской академии последипломного образования.

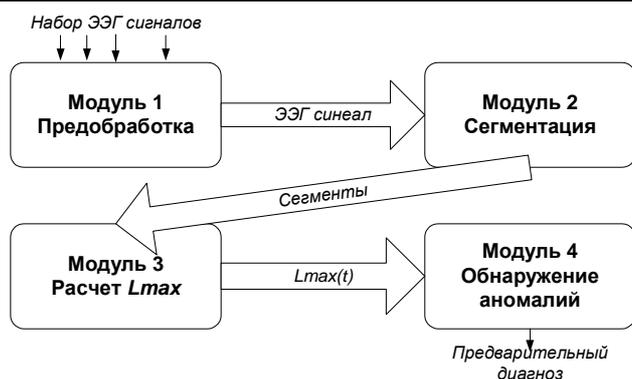


Рис. 1. Структура вспомогательной диагностической системы

Система состоит из четырех модулей. Входными данными для системы являются несколько ЭЭГ записей одной регистрации. Задача этапа предобработки отфильтровать из сигналов шумы и артефакты, помехи регистрационных приборов. В результате предобработки входных сигналов мы получаем один чистый сигнал, пригодный для последующей обработки. Далее ЭЭГ сигнал подвергается сегментации для выделения участков, которые можно считать условно-стационарными. На каждом из сегментов производится расчет значения L_{max} , таким образом, на выходе третьего модуля мы получаем временной ряд $L_{max}(t)$. Этот временной ряд используется для обнаружения аномалий, то есть в зависимости от значения L_{max} система фиксирует наличие аномалии в сегменте, либо нормальную активность.

Далее мы рассмотрим каждый модуль системы подробнее.

1.1. Предобработка. Как уже отмечалось, при регистрации ЭЭГ в сигналах содержится не только электрическая активность головного мозга, но и помехи, шумы, артефакты, которые могут повлиять на результаты работы системы. По таким сигналам мы не можем производить анализ функционального состояния, так как результаты расчета характеристических величин являются непредсказуемым.

Для фильтрации нежелательной информации из сигналов мы предлагаем использовать метод независимых компонент ICA (Independent Component Analysis). Данный метод позволяет из линейных смесей независимых сигналов от различных источников выделить исходные несмешанные сигналы [10]. То есть применение этого

метода базируется на предположении, что ЭЭГ сигналы представляют собой линейную смесь независимых сигналов от нескольких источников. Применимость данного метода подтверждается только экспериментально. На рисунке 2 изображены фрагменты трех сигналов ЭЭГ одной регистрации, на рисунке 3 вы можете видеть результат ICA, полученный при помощи пакета FastICA 2.5.

Из рисунка 3 видно, что второй и третий сигналы содержат отличную от исходных ЭЭГ динамику поведения. Изменения амплитуды второго сигнала носит периодический характер, что позволяет предположить о наличии в исходных сигналах составляющей в виде периодического шума. Первый сигнал имеет самые плавные изменения амплитуды и кажется наиболее похожим на ЭЭГ сигнал. Однако визуальная оценка не является объективной, попробуем экспериментально проверить необходимость применения ICA, а также какой из полученных после ICA сигналов следует использовать для последующего анализа. Для этого произведем эксперименты по обработке одного из исходных сигналов и трех сигналов, полученных после применения ICA в нашей системе. При описании очередного модуля будем приводить результаты экспериментов.

1.2. Сегментация. Существует ряд способов выполнения сегментации. Испытания, проводимые группой исследователей, по сегментации ЭЭГ сигналов [9] показывают необходимость применения адаптивной сегментации, которая предполагает определение значения характеристического параметра в движущемся по сигналу «окне». При этом при изменении значения этого параметра фиксируется смена сегментов исходного сигнала.

В нашем исследовании характеристическим параметром выступает старший показатель Ляпунова. Однако степень сходства можно определять путем прогнозирования фиксированного участка исходного сигнала. Суть метода заключается в том, что выборка будет прогнозироваться до тех пор, пока прогноз будет удовлетворять заданной точности, и далее на величину точного прогноза будет производиться смещение временного окна. Если прогноз с первой точки резко расходится со значениями исходного ряда, следовательно, обнаружена граница сегментов.

Для прогнозирования данных в нашем случае наиболее подходящим методом являются искусственные нейронные сети, так как они позволяют анализировать небольшие объемы данных [8]. В качестве базовой архитектуры для прогнозирования временных процессов в работе использован многослойный перцептрон (Multilayer Perceptron, MLP). Доказано, что данная нейронная сеть

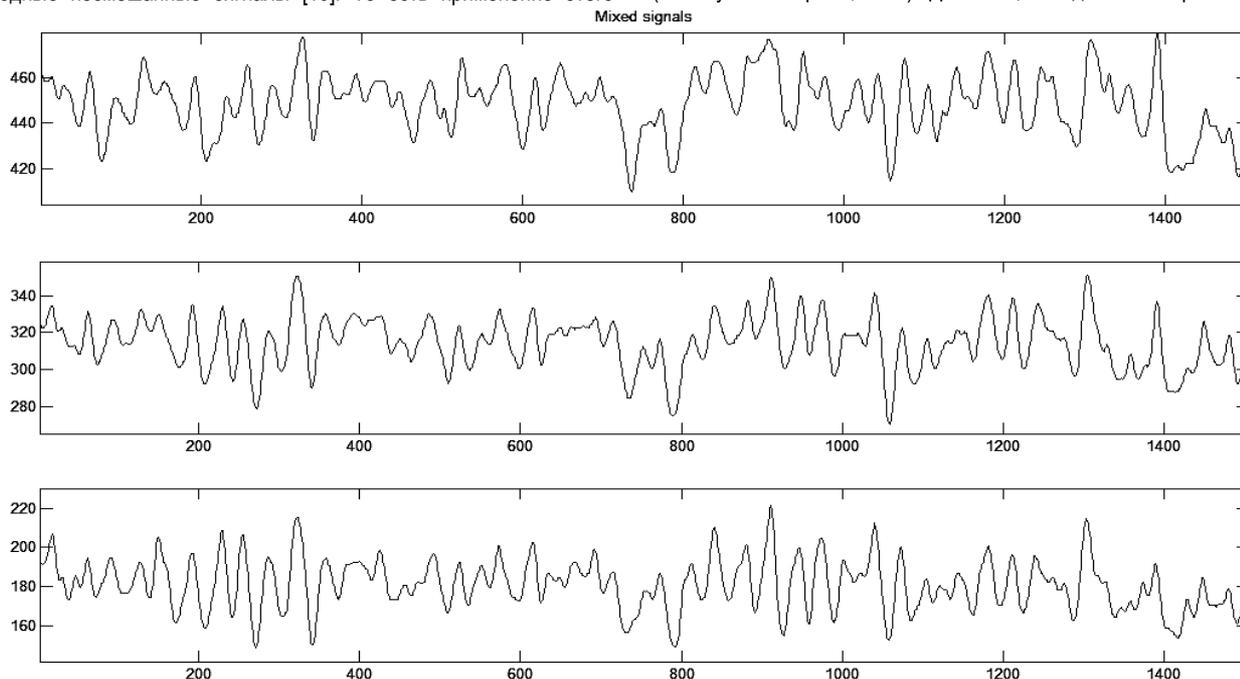


Рис. 2. Пример трех ЭЭГ сигналов одной регистрации

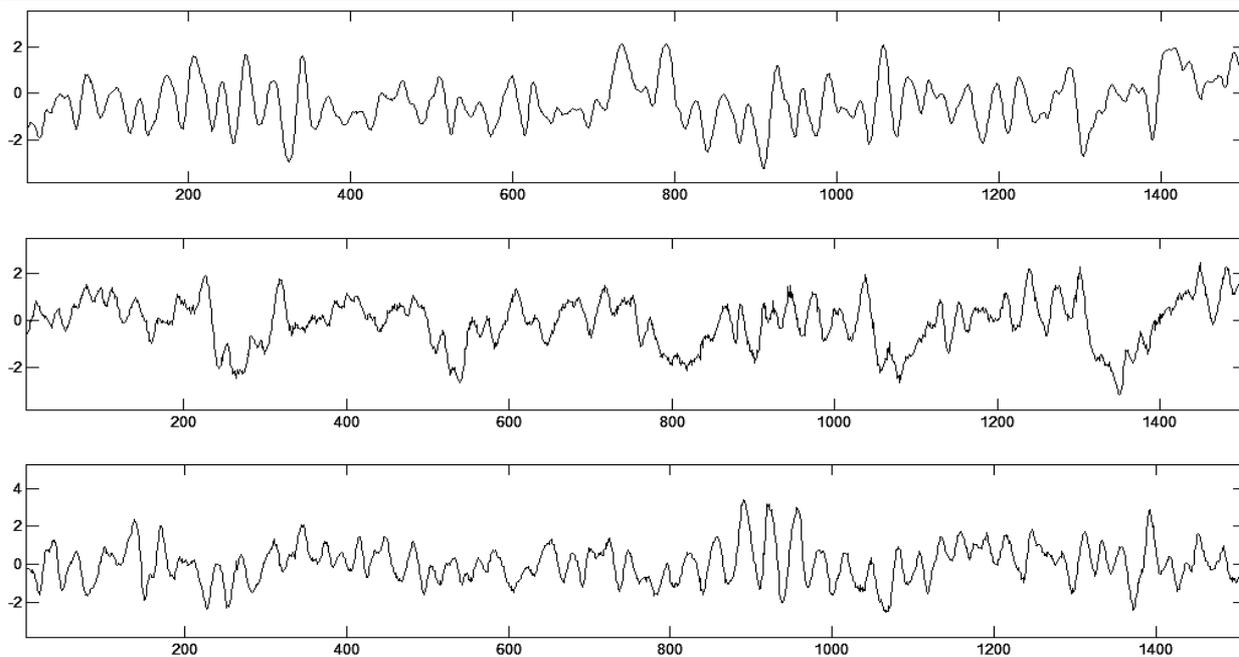


Рис. 3. Результаты метода независимых компонент для трех ЭЭГ сигналов одной регистрации

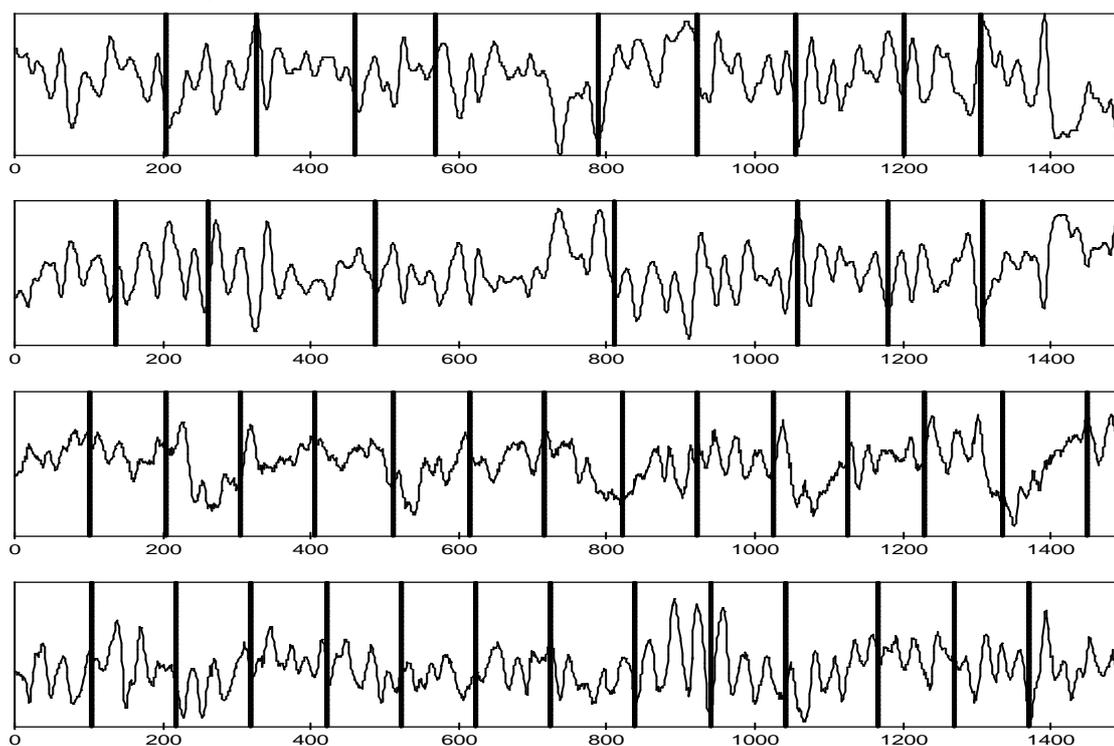


Рис. 4. Результаты сегментации: первый сигнал сверху - сигнал ЭЭГ без обработки, второй, третий и четвертый сигналы - сигналы, полученные после ICA преобразования

способна аппроксимировать любую непрерывную функцию со сколь угодно высокой точностью [11]. Для обучения многослойного перцептрона мы использовали алгоритм обратного распространения ошибки [12]. Предположим у нас есть временной ряд $X = \{x(1), x(2), \dots, x(m)\}$, где m – количество точек временного ряда. Сегментирование осуществляется согласно следующему алгоритму:

- 1) Определяется размер элементарного интервала N ; $t=1$ – начальная позиция временного окна;
- 2) Формируется обучающая выборка N точек, начиная с позиции t : $\{x(t), x(t+1), \dots, x(t+N-1)\}$;

- 3) Производится обучение нейронной сети на прогнозирование выбранных данных;
- 4) Осуществляется прогноз значений, получаем точки $x'(t+N)$, $x'(t+N+1)$, $x'(t+N+2)$... до тех пор, пока не выполнится условие (2)

$$|x'(i) - x(i)| > \Delta x_{\max}, \quad (1)$$

где $i = 0, 1, 2, \dots$ Δx_{\max} – величина, определяющая приемлемую точность прогноза.

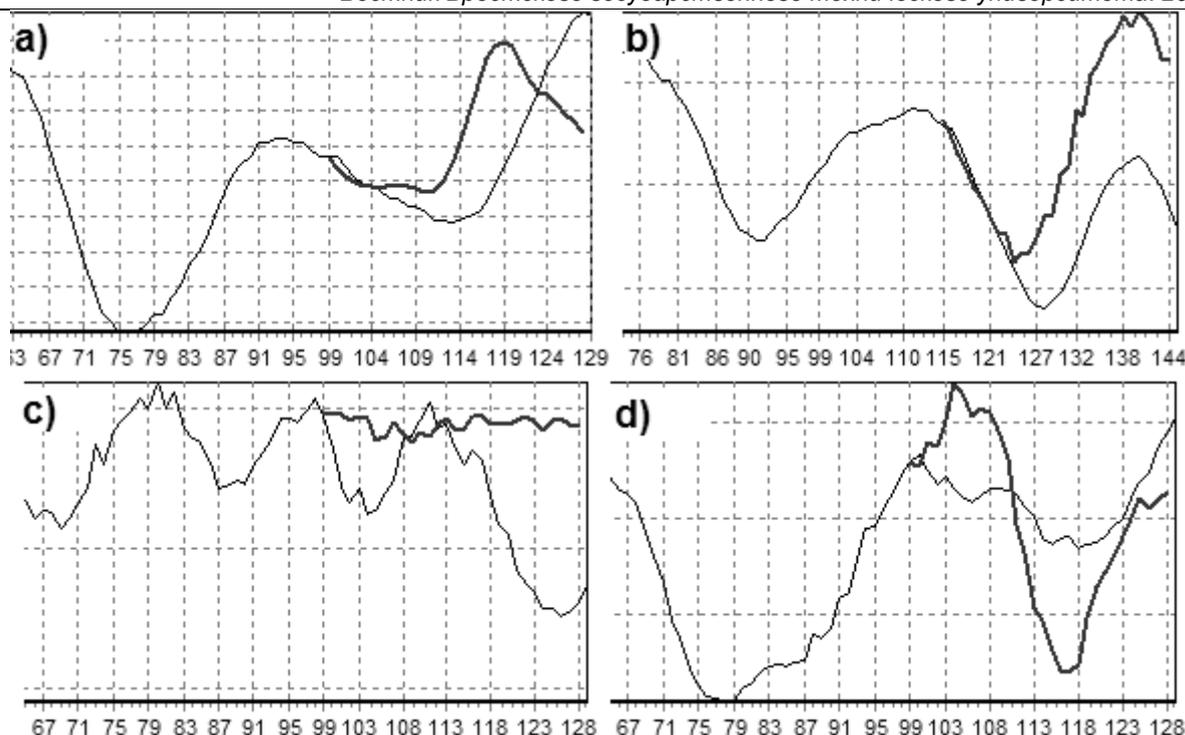


Рис. 5. Прогнозирование данных, исходный сигнал отображен тонкой черной линией, прогноз - жирной черной линией: а) сигнал ЭЭГ без обработки б), с), d) первый, второй, третий сигналы, полученные после ICA преобразования, соответственно

- 1) Если $i = 0$, то i -ая точка принимается за границу сегментов и временное окно смещается к полученной границе $t=t+N$, иначе окно смещается на i точек $t=t+i$.
- 2) Если $t < m-N$, то переходим к пункту 1) иначе сегментация завершена.

На рисунке 4 изображены результаты сегментации первого сигнала, показанного на рисунке 2, и трех сигналов, полученных после обработки ICA, показанных на рисунке 3. Очевидно, что два нижних сигнала не прогнозируются, причиной этого может быть наличие постоянного шума в этих сигналах, который уносит случайную составляющую. Попробуем оценить насколько эффективно использование сегментации для данных сигналов на основе прогнозирующей ИНС. Действительно, проведя тест (см. рис. 5) на прогнозируемость данных для каждого исследуемого сигнала, мы убедились, что из сигналов, которые получены после ICA, только первый сигнал прогнозируется хорошо. Причем первый сигнал, полученный в результате ICA, имеет больший горизонт прогноза (10 точек), чем исходный ЭЭГ сигнал (6 точек) при одинаковой ошибке обучения прогнозирующей ИНС.

На каждом участке, полученном в результате сегментирования, производится расчет L_{max} . Методика расчета описана в следующем подразделе.

1.3. Расчет старшего показателя Ляпунова. Существует ряд методов для расчета L_{max} , когда известна только эволюция одной координаты системы в виде временного ряда [13]. Для решения нашей задачи наиболее подходящей является нейросетевая технология расчета [14], так как она позволяет производить вычисление L_{max} на небольших отрезках данных.

Расчет L_{max} должен производиться для каждого сегмента данных, поэтому необходимо производить обучение и настройку нейронной сети на каждом сегменте. Для определения архитектуры сети и порядка выбора данных в обучающую выборку необходимо рассчитать следующие параметры:

- Временная задержка τ определяет интервал между отсчетами временного ряда для достижения наилучшей прогнозируемости данных. Использование временной задержки позволяет оптимальным образом формировать обучающую выборку для прогнозирующей ИНС.

- Размер пространства вложения d рассчитывается по методу «ложных ближайших соседей» и позволяет определить размерность k входного слоя ИНС для увеличения скорости обучения и повышения качества прогноза:

$$k \geq d - 1. \quad (2)$$

Для определения значений вышеописанных параметров используется пакет Tesean 2.1.

В качестве прогнозирующей ИНС в нашей системе используется многослойный персептрон (см. рис. 6) с одним скрытым слоем, состоящем из p нейронов, и с одним выходным нейроном [14]. В скрытом слое ИНС активация нейронов производится сигмоидной функцией, в выходном слое - линейной. Данный вид прогнозирующей ИНС был выбран в результате сравнительных экспериментов трех архитектур [15]: многослойного персептрона, сети с радиально-базисной функцией активации и рекуррентной сети Элмана.

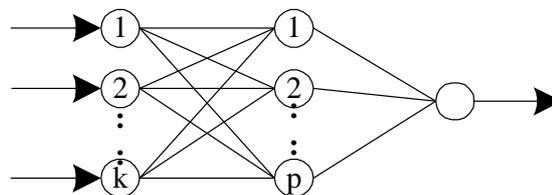


Рис. 6. Многослойный персептрон

Многослойный персептрон обучается на прогнозирование данных одного сегмента с учетом временной задержки τ . После достижения необходимой ошибки обучения производится прогнозирование исходного набора, а также прогнозирование с небольшим отклонением (10^{-8}). По экспоненциальной степени расхождения двух траекторий прогноза $\ln(D)$ оценивается значение L_{max} . Подробный алгоритм расчета приведен в [8, 16].

Проведем расчет L_{max} для тестовых сигналов (исходного сигнала ЭЭГ и первого сигнала после ICA разделения), результаты сегментации которых представлены на рисунке 4. На рисунке 7 можно видеть полученные значения расчета для каждого выделенного сегмента.

Оценка и анализ расчета L_{max} производится в модуле обнаружения аномалий.

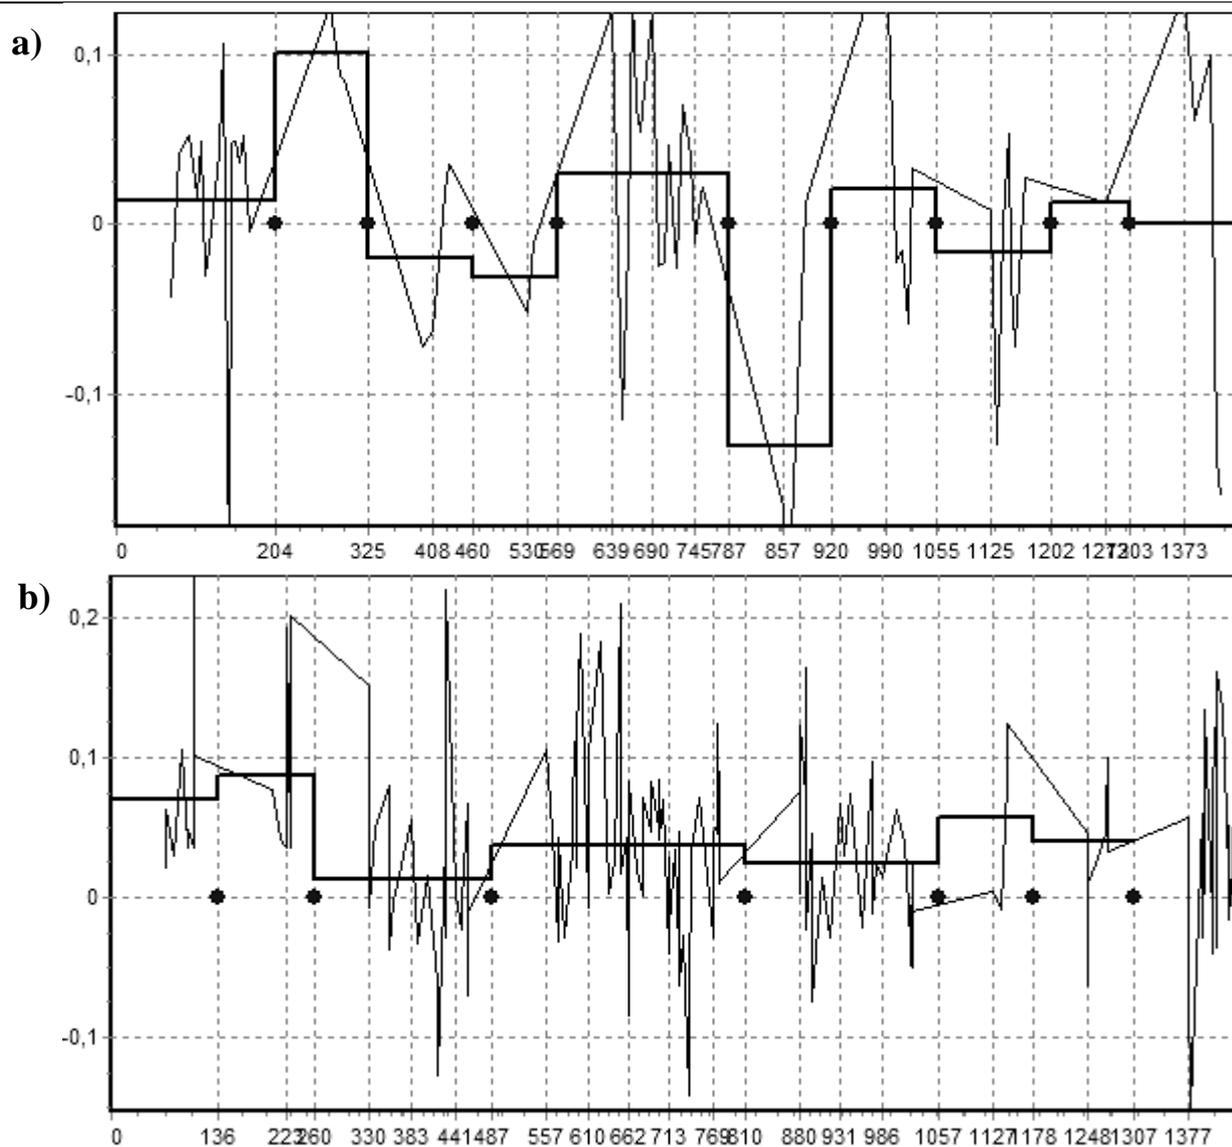


Рис. 7. Расчет L_{max} для сегментированных сигналов. Черные круги отображают границы сегментов, черной тонкой линией показаны значения L_{max} , черной жирной линией - среднее значение для сегмента. а) исходный ЭЭГ сигнал, б) ЭЭГ сигнал, полученный в результате ICA

1.4. Обнаружение аномалий. В результате вычисления L_{max} для каждого сегмента мы получаем временной ряд:

$$L_{max}(t) = (L_{max_1}, L_{max_2}, L_{max_3}, \dots, L_{max_M}), \quad (3)$$

где M - количество выделенных сегментов, то есть каждое значение ряда соответствует одному сегменту, при этом является средним из набора вычисленных в сегменте значений.

Полученные значения будут использоваться для оценки сегментов на наличие аномальной активности в сигнале по следующему критерию:

$$\begin{cases} L_{max} > 0, \text{ нормальная активность;} \\ L_{max} \leq 0, \text{ эпилептиформная активность.} \end{cases} \quad (4)$$

При обнаружении аномальной активности система выдает участки (сегменты), на которых эта активность обнаружена. Это свидетельствует о необходимости детального изучения и исследования этих участков. При отсутствии аномальной активности система свидетельствует, что на ЭЭГ эпилептиформных активностей не выявлено. Рассмотрим с точки зрения критерия 4 результаты расчета L_{max} , показанные на рисунке 7. Из рисунка 7.а следует, что в сигнале ЭЭГ присутствует множество аномальных активностей, хотя данная ЭЭГ их не содержит. На рисунке 7.б отсутствуют сегменты с

отрицательным средним значением L_{max} , следовательно согласно критерию (4) аномальные активности отсутствуют. Можно сделать вывод, что шумы и артефакты, которые могут присутствовать в ЭЭГ сигналах, приводят к ложным обнаружениям. В результате удаления шумовой составляющей мы получаем сигналы, которые можно использовать для автоматического обнаружения эпилептиформных активностей.

Если анализировать таким образом несколько наборов одной регистрации, то система выдает двумерную карту, на которой можно просмотреть зоны, где происходят эпилептиформные вспышки. Такие карты будут представлены вашему вниманию в третьем разделе данной статьи.

2. Исходные данные. Данные для исследований предоставлены Пятой клинической больницей г. Минска. Одна регистрация ЭЭГ сигналов представляет собой группу из 16 сигналов длительностью 8 секунд каждый. Исходные сигналы разбиваются на наборы по три сигнала в каждом, как показано на рисунке 7, и проходят предобработку. После фильтрации сигналов методом ICA мы получаем 6 сигналов, которые используются для анализа в системе по вышеописанной схеме (см. рис. 1).

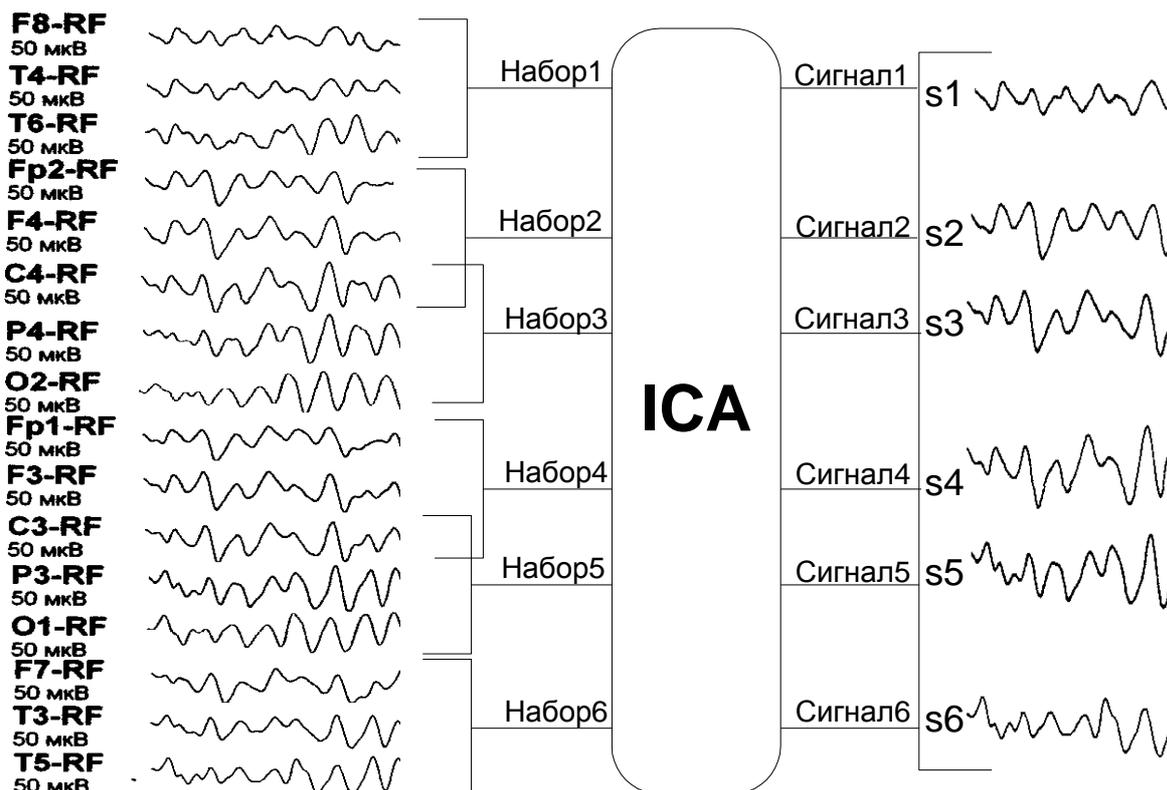


Рис. 8. Формирование наборов для ICA разделения из одной регистрации ЭЭГ

Для проведения экспериментов было использовано пять ЭЭГ регистраций, описание которых приведено в таблице 1.

Таблица 1. Описание ЭЭГ регистраций, используемых в качестве исходных данных для экспериментов

№ п.п.	Возраст пациента	Тип эпилептиформной активности
1	22	Одиночные острые волны
2	23	-
3	24	Одиночная острая волна
4	25	Единичный комплекс спайк-волна
5	25	-

3. Результаты экспериментов. Эксперименты проводились на всех тестовых данных, описанных в таблице 1. Следует отметить, что при анализе сигналов, не содержащих эпилептиформных активностей, обнаружений не было выявлено, кроме небольшого снижения значения L_{max} к нулю для второго тестового сигнала, что может свидетельствовать о наличии в нем небольшой дезорганизации по причине нарушения работы мозга либо по причине плохо отфильтрованных помех, которые могли остаться в сигнале. Наиболее интересные результаты получены для сигналов 1 и 4, они представлены на рисунке 9.

Из рисунка 9.а следует, что на исследуемой ЭЭГ присутствует две вспышки эпилептиформной активности, при этом видно, что есть области, в которых происходит аномальный всплеск раньше, чем в других. На рисунке 9.б наблюдается одна вспышка эпилептиформной активности и в нижнем сигнале небольшой всплеск между 1-й и 2-й секундой регистрации является ложным обнаружением.

Выводы. В статье представлена вспомогательная диагностическая система, рассмотрены все основные этапы функционирования этой системы. Произведено тестирование системы и оценка целесообразности применения методов анализа ЭЭГ сигналов. По результатам проведенных исследований и экспериментов можно сделать следующие выводы:

1. Применение ICA как метода предобработки и фильтрации ЭЭГ сигналов оказалось весьма эффективным, так как повысило прогнозируемость временного ряда. Нерешенной осталась задача определения, какой сигнал после ICA является сигналом ЭЭГ, а какие содержат помехи и артефакты. При тестировании оценка производилась визуально по динамике сигнала и по схожести на исходные ЭЭГ данные.
2. Адаптивная сегментация на основе нейронных сетей позволяет выделять сегменты малой длительности, что сделало возможным не только обнаруживать одиночные эпилептиформные активности, такие как спайки и одиночные волны, но и выделить четкие границы участков с аномальной активностью, при этом можно определить в каких сигналах раньше других появляется дезорганизация.
3. Тестирование на реальных данных показало работоспособность предложенной системы. Полученные результаты анализа ЭЭГ демонстрируют дополнительный способ отображения и локализации очагов эпилептиформных активностей. Не смотря на то, что существует вероятность ложного обнаружения, по исходным сигналам ЭЭГ всегда визуально можно оценить достоверность полученной информации.

Исследования проводятся в соответствии с ГКПНИ «Инфотех» Республики Беларусь по теме «Методы математического моделирования процессов самоорганизации в активных средах» (№ госрегистрации 20063567) под руководством профессора, д.т.н. Головки Владимира Адамовича.

СПИСОК ЦИТИРОВАННЫХ ИСТОЧНИКОВ

1. Berger H. Uber das Elektroencephalogramm des Menschen. Archiv fur Psychiatrie und Nervenkrankheiten, 1929, Berlin, Vol.87: 527-570.
2. К.Ю. Мухин, А.С. Петрухин, Л.Ю. Глухова. Эпилепсия. Атлас электроклинической диагностики. – М.: Альварес Паблишинг, 2004. – 440 с.

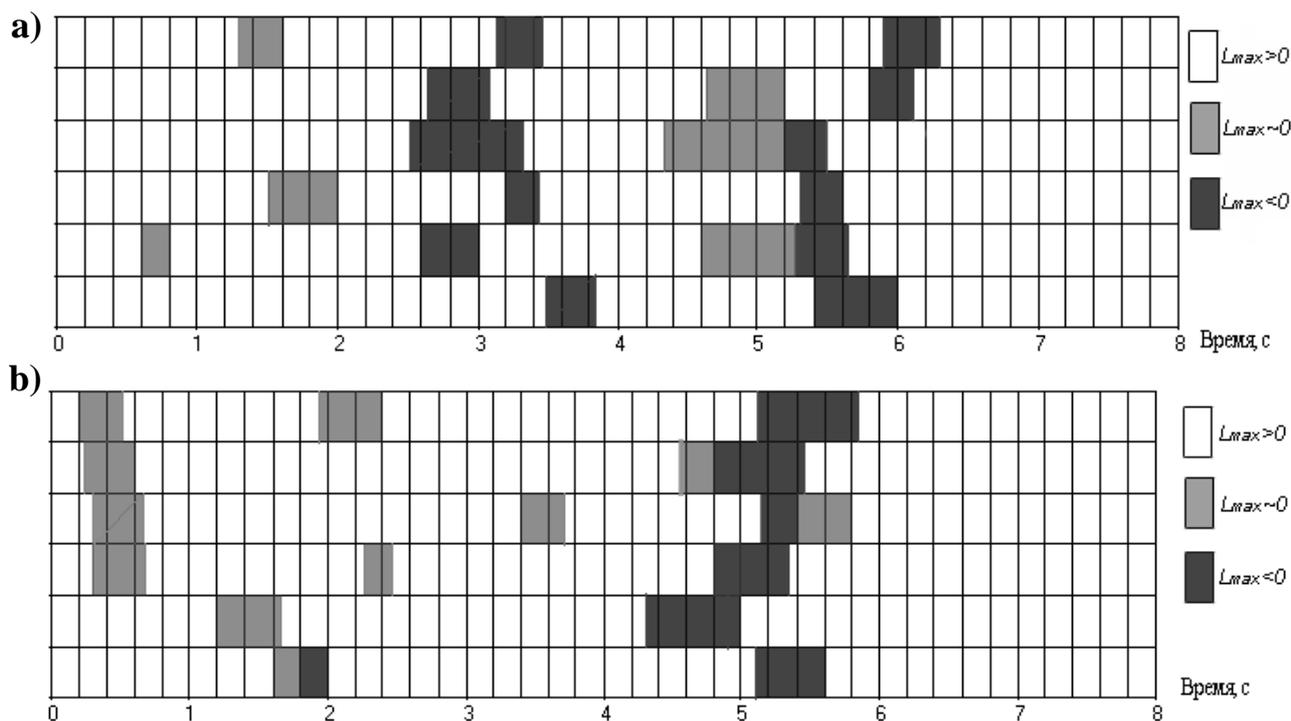


Рис. 9. Карты обнаружения эпилептиформной активности, где белая область согласно критерию соответствует нормальной активности, светло-серая область означает снижение показателя, то есть является неопределенной (требуется детального исследования), темно-серая область - наличие эпилептиформной активности

3. Воробьев В.И., Грибунин В.Г. Теория и практика вейвлет-преобразования. Санкт-Петербург: издательство Военного университета связи, 1999. – 204 с.
4. Добеши И. Десять лекций по вейвлетам. - Москва, Ижевск: НИЦ «Регулярная и хаотическая динамика». – 2001. – 464 с.
5. Куравский Л. С., Баранов С. Н., Буланова О. Е., Кравчук Т. Е. Нейросетевая технология диагностики патологических состояний по аномалиям электроэнцефалограмм. - «Нейрокомпьютеры». - №4, 2007.
6. Крамаренко А.В. Электроэнцефалограмма. Анализ с точки зрения теории информации. – Интернет-журнал – 2002. – Available from: <http://www.dx-telemedicine.com/rus/publications/analise_eeg.htm>.
7. Меклер А.А. Применение аппарата нелинейного анализа динамических систем для обработки сигналов ЭЭГ. // В: сб. Актуальные проблемы современной математики: ученые записки. Т. 13 (вып. 2). п/ред. проф. Калашникова Е.В., изд. ЛГУ им. А.С. Пушкина, С-Пб., 2004 г., 153 стр., стр. 112-140.
8. Головкин В.А. Нейросетевые методы обработки хаотических процессов // В книге «Лекции по Нейроинформатике». – М.: МИФИ, 2005. – С. 43-88.
9. Каплан А.Я. Проблема сегментного описания электроэнцефалограммы человека // Физиология человека, 1999. – Т. 25. - № 1. - С. 125-133.
10. Nyvaerinen A., Oja E. Independent component analysis: algorithms and applications // Neural Networks. - №13, 2000. - P. 411-430.
11. Hornik K., Stinchcombe M., White H. Multilayer feedforward networks are universal approximators // Neural Networks. - 1989. - N. 2. - P. 359 - 366.
12. В.А. Головкин. Нейронные сети: обучение, организация и применение. Кн. 10: Учеб. пособие для вузов / Общая ред. А. И. Галушкина. - М.: ИПРЖР, 2000. –187с.
13. Wolf A., Swift J., Swinney H., Vastano J. Determining Lyapunov exponents from a time series // Physica D. – 1985. – No. 16. – pp. 285-301.
14. V. Golovko, Y. Savitsky, N. Maniakov. Neural Networks for Signal Processing in Measurement Analysis and Industrial Applications: the Case of Chaotic Signal Processing // chapter of NATO book “Neural networks for instrumentation, measurement and related industrial applications”. - Amsterdam: IOS Press, 2003. - pp. 119-143.
15. Bezobrazova, S., Golovko, V. Comparative Analysis of Forecasting Neural Networks in the Application for Epilepsy Detection // Proceedings of the 4 IEEE Workshop on Intelligent Data Acquisition and Advanced Computer Systems: Technology and Application IDAACS'2007, Dortmund, Germany, September 6-9, 2007. – Dortmund, 2007. – pp. 202-207.
16. V. Golovko, S. Bezobrazova, S. Bezobrazov and U. Rubanau. Application of Neural Networks to the Electroencephalogram Analysis for Epilepsy Detection // Proceedings of The 2007 International Joint Conference on Neural Networks. – Orlando, Florida, August 12-17, 2007. – P. 2707-2711.

Материал поступил в редакцию 06.10.2008

BEZOBRAZOVA S.V., GOLOVKO V.A., EVSTIGNEEV V.V. The assistant diagnostic system for EEG analysis by neural-network methods

Paper covers description of the assistant diagnostic system for epileptiform activity detection. The structure of the system is presented. There is a review of all units and their intercommunication on which the system is based. Algorithms and methods realized in each unit are introduced. We also include in paper intermediate results for test signals that express each unit work clearly. The system functionality on the real electroencephalogram data is analyzed.