

Головко В.А., Лаврентьева С.В.

НЕЙРОСЕТЕВОЙ АНАЛИЗ ЭЛЕКТРОЭНЦЕФАЛОГРАММ ДЛЯ ОБНАРУЖЕНИЯ ЭПИЛЕПТИЧЕСКОЙ АКТИВНОСТИ

Введение. Эпилепсия является распространенным неврологическим заболеванием головного мозга, которое охватывает около 1% человечества [1]. Она приводит к эпилептическим припадкам, которые возникают в результате чрезмерных электрических разрядов соответствующих нейронов головного мозга. Эффективность лечения и прогноз эволюции эпилептической активности зависит от точности и оперативности обнаружения данного заболевания [2]. Распространенным подходом для обнаружения эпилептической активности нейронов головного мозга является анализ сигналов электроэнцефалограмм. Электроэнцефалограмма (ЭЭГ) представляет собой запись суммарной электрической активности нейронов головного мозга. Активность нейронов головного мозга при эпилептической активности отличается от нормального состояния, что проявляется в сигналах ЭЭГ. Однако обнаружение эпилептической активности в сигналах ЭЭГ является сложной задачей, так как до сих пор неизвестен точный механизм возникновения эпилептических припадков. Поэтому разработка точного и робастного метода для автоматического обнаружения эпилептической активности в сигналах ЭЭГ является важной задачей, решение которой поможет врачу применять эффективные методы лечения и снизить субъективность принимаемых решений.

В настоящее время существуют различные подходы для обнаружения эпилептической активности в сигналах ЭЭГ. Это спектральный анализ на основе преобразования Фурье [3], вейвлет-анализ [4], нелинейный анализ [5–7], нейронные сети [8–12] и различные комбинации этих подходов [13]. Спектральный анализ на основе преобразования Фурье является линейным методом, где ЭЭГ-сигнал представляется в виде бесконечной суммы синусоид с различной амплитудой, частотой и фазой. Такое преобразование основывается на предположении, что ЭЭГ-сигнал является квазистационарным. Однако биоэлектрическая активность нейронов головного мозга характеризуется нелинейной и нестационарной природой, что ограничивает применение преобразования Фурье для анализа ЭЭГ-сигналов. Вейвлет-преобразование, в отличие от преобразования Фурье, отображает ЭЭГ-сигнал в частотно-временную область и может применяться для анализа нестационарных сигналов. В результате декомпозиции ЭЭГ-сигнала при помощи вейвлет-преобразования получают вейвлет-коэффициенты, которые можно использовать как входной вектор признаков для дальнейшей классификации эпилептической или неэпилептической активности в сигналах ЭЭГ. В качестве классификаторов могут использоваться различные нейронные сети.

Распространенным подходом для анализа ЭЭГ-сигналов является применение двух этапов анализа ЭЭГ: 1) выделение входных векторов признаков на основе Фурье или вейвлет-преобразования; 2) построение классификатора. В качестве классификатора может использоваться многослойный перцептрон [8, 9], нейро-нечеткая система [10], обучающийся векторный квантователь [11], машины опорных векторов [12] и т.д. Следует отметить, что качество функционирования классификатора зависит от входного пространства признаков, выделенного на первом этапе обработки ЭЭГ.

Исследования ЭЭГ-сигналов показали, что они являются нестационарными и хаотическими [6,7,14]. Существует разница в динамических свойствах ЭЭГ-сигнала в нормальном и эпилептическом состоянии. Эпилептическое состояние характеризуется повышенной активностью отдельных нейронов головного мозга, что приводит к

снижению сложности ЭЭГ-сигналов. Так, «электроэнцефалограммы больных эпилепсией чрезмерно регулярны» [14]. Соответственно значения корреляционной размерности и старшего показателя Ляпунова [15] уменьшаются при эпилептической активности по сравнению с нормальным состоянием. Поэтому изменение данных показателей может использоваться в качестве теста для определения эпилептической активности. В ряде работ показатели Ляпунова используются совместно с вейвлет-коэффициентами в качестве входного вектора признаков для классификатора [10].

Основным недостатком существующих подходов является обучение классификаторов с учителем, что приводит к неавтоматическому анализу ЭЭГ-сигналов, так как требует подготовки обучающей выборки с эпилептическими и нормальными векторами. Следующим недостатком является невозможность точного выделения временных сегментов с эпилептической и нормальной активностью в сигнале ЭЭГ.

В данной статье рассматривается нейроинтеллектуальная система для определения эпилептической активности на основе анализа сигналов электроэнцефалограмм (ЭЭГ). Такая система обучается без учителя и позволяет выделять временные сегменты в сигналах ЭЭГ с эпилептической и нормальной активностью. Как уже отмечалось, при эпилептической активности происходит снижение старшего показателя Ляпунова в сигнале ЭЭГ. Поэтому в качестве критерия наличия эпилептической активности будем рассматривать значение старшего показателя Ляпунова. Такая система позволяет визуализировать сегменты (зоны) с эпилептической и нормальной активностью в сигналах ЭЭГ путем генерирования двумерной карты результатов диагностирования.

1. Нейросетевая диагностическая система. В данном разделе описывается нейросетевая диагностическая система для обнаружения эпилептической активности в сигналах ЭЭГ. В качестве диагностического критерия используется значение старшего показателя Ляпунова, которое снижается при наступлении эпилептических припадков. Старший показатель Ляпунова характеризует среднюю скорость экспоненциального расхождения двух близко лежащих траекторий. Наличие у системы положительной экспоненты Ляпунова свидетельствует о том, что любые две близкие траектории быстро расходятся с течением времени, то есть имеет место чувствительность к значениям начальных условий.

На рисунке 1 представлена нейросетевая система обнаружения эпилептической активности в сигналах ЭЭГ. На вход системы поступает набор сигналов ЭЭГ одной регистрации. Эти сигналы описывают динамику нелинейной хаотической системы, которая характеризует электрическую активность нейронов головного мозга. Каждый ЭЭГ-сигнал снимается с определенного участка головного мозга, характеризует электрическую активность множества нейронов соответствующего участка головного мозга и содержит различные артефакты (помехи, появляющиеся на ЭЭГ в результате моргания, движения подбородком и т.п.). Поэтому на первом этапе необходимо осуществить предобработку ЭЭГ-сигналов, чтобы отфильтровать их от различного рода артефактов и получить максимально независимые сигналы. Для такой обработки ЭЭГ-сигналов используется метод независимых компонент (ICA – Independent Component Analysis) [16], который позволяет выделить независимые сигналы из их смеси. Результатом предобработки являются чистые сигналы ЭЭГ, содержащие электрическую активность нейронов головного мозга.

Головко Владимир Адамович, д.т.н., профессор, зав. кафедрой интеллектуальных информационных технологий Брестского государственного технического университета.

Лаврентьева Светлана Владимировна, доцент кафедры интеллектуальных информационных технологий Брестского государственного технического университета.

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

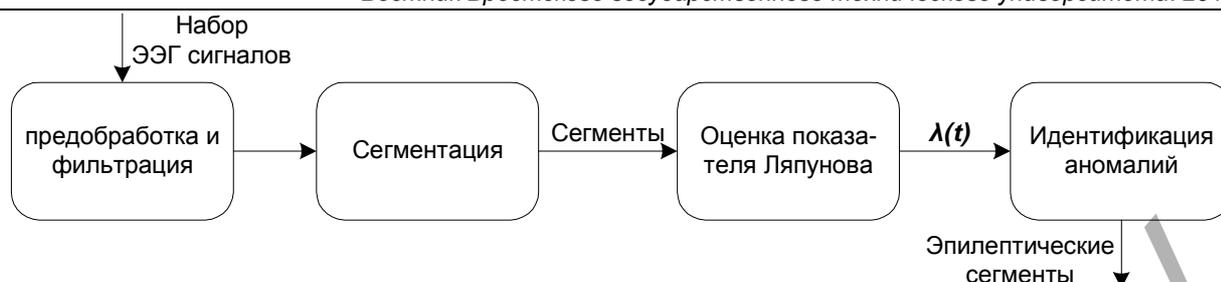


Рис. 1. Нейросетевая система обнаружения эпилептиформной активности. На вход системы подается набор сигналов электроэнцефалограмм; $\lambda(t)$ – ряд значений старшего показателя Ляпунова

Каждый сигнал, полученный после ICA-фильтрации, подвергается адаптивной сегментации при помощи многослойного персептрона (MLP). В результате сегментации происходит разбиение каждого сигнала на квазистационарные участки, где поведение сигнала не изменяется. Затем для каждого выделенного сегмента производится вычисление оценки старшего показателя Ляпунова. В результате получается детерминированный ряд показателей Ляпунова для каждого чистого сигнала ЭЭГ.

$$\lambda(t) = (\lambda_1, \lambda_2, \dots, \lambda_p), \quad (1)$$

где p – количество временных выделенных сегментов в сигнале ЭЭГ.

Если различные сегменты имеют одинаковые значения старшего показателя Ляпунова, то они объединяются в один сегмент. На заключительном этапе происходит идентификация эпилептической активности в соответствии со следующим критерием:

$$\begin{cases} \lambda > 0, & \text{нормальная активность;} \\ \lambda \leq 0, & \text{эпилептиформная активность.} \end{cases} \quad (2)$$

В результате выполнения данной процедуры для каждого сигнала ЭЭГ выделяются временные сегменты с эпилептической и нормальной активностью.

2. Сегментация сигналов ЭЭГ. Как уже отмечалось, сегментация представляет собой разбиение каждого сигнала ЭЭГ на квазистационарные участки, где поведение сигнала не изменяется с течением времени. Для этого используется метод адаптивной сегментации, который осуществляется при помощи прогнозирующего многослойного персептрона. В качестве критерия границы сегмента служит превышение ошибки прогнозирования выбранного порогового значения.

Как уже отмечалось, каждый ЭЭГ-сигнал представляет собой хаотическую динамическую систему. Для максимальной предсказуемости хаотического процесса необходимо вначале осуществить псевдофазовую реконструкцию одномерных ЭЭГ сигналов. Псевдофазовая реконструкция – это отображение, которое точке $x(t)$ временного ряда ставит в соответствие точку $(x(t), x(t+\tau), \dots, x(t+(m-1)\cdot\tau)) \in R^m$, где t – дискретное время ($t = ((m-1)\tau + 1), N$), τ – временная задержка (в дискретах времени) и m – размерность пространства вложения.

Такенс [17] показал, что, используя только одну координату динамической системы можно реконструировать исходный аттрактор в пространстве точек с задержками $(x(t), x(t+\tau), \dots, x(t+(m-1)\cdot\tau)) \in R^m$ таким образом, что он будет сохранять важнейшие динамические и топологические свойства оригинального аттрактора. Размерность m определяется по формуле $m \geq 2[d] + 1$, где d – фрактальная размерность аттрактора, $[d]$ – обозначает целую часть фрактальной размерности. В данном утверждении под фразой *важнейшие динамические свойства* следует понимать диссипативность и хаотичность системы, а под *важнейшими геометрическими свойствами* – топологические инварианты аттрактора такие, например, как фрактальная размерность. Выполнение неравенства $m \geq 2[d] + 1$ гарантирует

сохранение указанных свойств, однако эксперименты показывают, что данная оценка размерности пространства вложения является несколько завышенной. Для некоторых простых хаотических систем сохранение упомянутых свойств наблюдается даже при $m = [d + 1]$.

Таким образом, для прогнозирования ЭЭГ сигнала необходимо определить параметры вложения динамической системы, а именно – подходящую временную задержку сигнала τ [15, 18-22] и размерность m [15, 18-22] пространства вложения для псевдофазовой реконструкции. Тогда структура прогнозирующего многослойного персептрона будет состоять из $k \geq m - 1$ входных нейронов (m – размерность пространства вложения в соответствии с теоремой Такенса), p скрытых и одного выходного нейронного элемента (см. рисунок 2). Размерность пространства вложения сигналов ЭЭГ вычислялась при помощи метода ложных ближайших соседей. Эксперименты показали, что размерность пространства вложения ЭЭГ-сигналов меняется от 7 до 9. В качестве прогнозирующего многослойного персептрона в данной работе использовалась нейронная сеть, состоящая из семи входных нейронов, пяти нейронов скрытого слоя и одного выходного нейрона с линейной функцией активации. В качестве функции активации нейронов скрытого слоя использовалась сигмоидная функция.

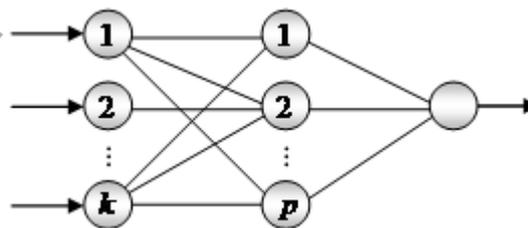


Рис. 2. Прогнозирующий многослойный персептрон

Начальным этапом процедуры сегментации является предварительное разбиение каждого ЭЭГ-сигнала на небольшие квазистационарные интервалы. Качество сегментации зависит от выбранной начальной длины сегментов. Известно, что промежуток времени, в течение которого спектральные свойства ЭЭГ-сигнала могут рассматриваться как постоянные, больше четырех секунд [23]. Однако если длина начального сегмента будет слишком большой, то уменьшается вероятность детектирования небольших по времени одиночных эпилептических событий. С другой стороны, при слишком малой длине сегмента объем обучающей выборки для многослойного персептрона может быть недостаточным для качественного обучения, так как размерность обучающей выборки должна быть больше количества настраиваемых параметров сети. Исходя из этих рассуждений и в результате проведения экспериментов, начальная длина сегментов была выбрана равной 70 отсчетам, что составляет приблизительно 0,5 секунды.

Затем выбирается первый сегмент сигнала ЭЭГ длиной 70 отсчетов и происходит обучение многослойного персептрона прогнозированию отсчетов данного сегмента в соответствии с методом скользящего окна:

$$x(t + i\tau) = F(x(t + (i-1)\tau)),$$

$$x(t + (i-2)\tau), \dots, x(t + (i-k)\tau), \quad i = \overline{k, n}, \quad (3)$$

Здесь $k \geq m-1$ – размер скользящего окна. После обучения многослойного персептрона определяется окончательная граница сегмента при помощи значения ошибки прогнозирования. Если значение ошибки прогнозирования в какой-либо точке превышает определенное пороговое значение, то данная точка является границей сегмента, и с нее начинается новый сегмент. Далее, начиная с этой точки, формируется новый сегмент длиной 70 отсчетов, генерируется следующий многослойный персептрон, который обучается прогнозированию на данном сегменте.

Алгоритм адаптивной сегментации состоит из следующих шагов:

1. Временной ряд разбивается на небольшие сегменты, каждый из которых состоит из $N = 70$ точек. Начальной точкой отсчета является $t = 1$.
2. Формируется обучающая выборка по методу скользящего окна: $\{x(t), x(t+1), \dots, x(t+N-1)\}$.
3. Происходит обучение многослойного персептрона в соответствии с методом скользящего окна.
4. Подается временной ряд на многослойный персептрон и он начинает прогнозировать точки сегмента. В результате получают следующие отсчеты $\{x'(t+N), x'(t+N+1), x'(t+N+2), \dots\}$.

Прогнозирование отсчетов временного ряда происходит до тех пор, пока не выполнится условие выражения (4):

$$|x'(i) - x(i)| > \Delta x_{\max}, \quad (4)$$

где $i = t + N, t + N + 1, \dots, \Delta x_{\max} = 0,1$ пороговое значение, определяемое экспериментальным путем.

5. Если при $i = t + N$ выражение (4) выполняется, то i считается точкой отсчета границы сегмента и генерируется другой многослойный персептрон, который обучается на выборке отсчетов длиной N , начиная с точки ряда $t = i$. В противном случае граница сегмента сдвигается на количество спрогнозированных точек, то есть $t = i - N$.

6. Процедура продолжается до тех пор, пока $t < m - N$, где m общая длина временного ряда.

В результате выполнения данного алгоритма каждый сигнал ЭЭГ разбивается на квазистационарные сегменты и для каждого сегмента формируется свой многослойный персептрон, обученный на прогнозирование отсчетов соответствующего сегмента.

4. Расчет оценки старшего показателя Ляпунова. Старший показатель Ляпунова характеризует среднюю скорость экспоненциального разбегания двух близко лежащих траекторий [15, 18-22]. Пусть $d(t_0)$ является начальным расстоянием между двумя точками траекторий, $d(t)$ – расстояние между этими точками через Δt шагов. Тогда старший показатель Ляпунова определяется следующим соотношением:

$$\lambda = \lim_{\Delta t \rightarrow \infty} \frac{1}{\Delta t} \ln \frac{d(t)}{d(t_0)}. \quad (5)$$

Для расчета показателя Ляпунова необходимо сделать следующие замечания:

- во-первых, в силу ограниченности аттрактора (а значит, ограниченности $d(t)$) Δt должно возрастать до тех пор, пока $d(t)$ существенно меньше размеров аттрактора. В противном случае значение λ будет равно нулю, при $\Delta t \rightarrow \infty$;

- во-вторых, вычисленное в соответствии с (5) значение λ следует рассматривать как усредненное по всем начальным точкам $x(t_0)$ аттрактора системы.

С учётом этих замечаний можно определить старший показатель Ляпунова соотношением:

$$\lambda = E_{x(t_0) \in A} \left\{ \lim_{\substack{\Delta t \rightarrow \infty \\ d(t) < \text{diam } A}} \frac{1}{\Delta t} \ln \frac{d(t)}{d(t_0)} \right\}, \quad (6)$$

где A – аттрактор системы, $\text{diam } A$ – его диаметр, а $E\{\cdot\}$ – математическое ожидание.

Старший показатель Ляпунова характеризует степень экспоненциального расхождения близких траекторий. Наличие у системы положительной экспоненты Ляпунова свидетельствует о том, что любые две близкие траектории быстро расходятся с течением времени, то есть имеет место чувствительность к значениям начальных условий. Для динамических систем наличие положительного значения старшего показателя Ляпунова является необходимым условием их хаотичности.

Рассмотрим ситуацию, когда уравнения эволюции системы неизвестны и известна только одна фазовая координата системы. В таких случаях для оценки старшего показателя Ляпунова хаотической системы используют методы, основанные на обработке измерений одной координаты рассматриваемой системы. Такой метод был впервые предложен Вольфом [15]. Он основывается на теореме Такенса [17] и алгоритме Бенеттина [18]. В соответствии с данным методом необходимо вначале осуществить псевдофазовую реконструкцию одномерного временного ряда, вычисляя размерность пространства вложения m и временную задержку τ . Затем, оперируя m – мерными точками ряда, рассматриваем их эволюцию на реконструированном аттракторе до тех пор, пока расстояние между ними не превысит заданную величину [15]. Повторив данную процедуру много раз, старший показатель Ляпунова оценивается как среднее арифметическое показателей Ляпунова, полученных на каждом шаге алгоритма. Такой подход базируется на эргодической теореме В.И. Оселедеца [18], которая утверждает, что экспоненциальное расхождение двух случайно выбранных точек на аттракторе с единичной вероятностью характеризует старший показатель Ляпунова.

В работах [18, 19, 22-25] для оценки старшего показателя Ляпунова был предложен подход, базирующийся на применении прогнозирующей нейронной сети. Для этого необходимо вначале определить временную задержку τ и размерность пространства вложения m . В качестве нейронной сети используется многослойный персептрон, который состоит из $k \geq m-1$ входных нейронов, p скрытых и одного выходного нейронного элемента. Вначале необходимо обучить такую нейронную сеть прогнозированию в соответствии с методом скользящего окна (3), как было показано в предыдущем разделе. После обучения сети легко осуществить эволюцию двух точек на фазовой траектории, используя итерационный подход. Таким образом, ключевой идеей предлагаемого метода является вычисление при помощи прогнозирующей нейронной сети расхождения двух близлежащих траекторий на n шагов вперед, используя итерационный подход.

Основным преимуществом данного подхода является возможность произвести оценку старшего показателя Ляпунова при малом объеме исходных данных за счет прогнозирования расхождения двух близлежащих траекторий. Как было показано в работе [18], для временного ряда Энона по координате X было получено значение старшего показателя Ляпунова $\hat{\lambda} = 0,43$, что близко к ожидаемому значению 0,419. При этом объем исходного ряда составил 70 отсчетов. Для оценки старшего показателя Ляпунова для сегмента ЭЭГ вычисляются показатели Ляпунова для каждой точки сегмента, и результирующая оценка получается как среднее арифметическое показателей Ляпунова, полученных в каждой точке сегмента.

Процедура оценки старшего показателя Ляпунова для сегмента ЭЭГ состоит из следующих шагов:

1. Обучаем нейронную сеть на прогнозирование по методу скользящего окна.
2. Выбираем первую точку $x(t)$, $t = 1$ из обучающей выборки и формируем следующий набор данных: $\{x(t), x(t+\tau), \dots, x(t+(k-1)\tau)\}$, где k – размер окна.
3. Вычисляем $\{x(t+k\tau), x(t+(k+1)\tau), \dots, x(t+n\tau)\}$ используя многошаговый прогноз $x(t+i\tau) = F(x(t+(i-1)\tau), x(t+(i-2)\tau), \dots, x(t+(i-k)\tau))$, где $i = \overline{k, n}$, F – нелинейная функция.
4. Вычисляем, $x'(t) = x(t) + d_0$, где $d_0 = 10^{-8}$, и, подавая на сеть $\{x'(t), x(t+\tau), \dots, x(t+(k-1)\tau)\}$, повторяем шаг 3 для получения $x'(t+i\tau)$, $i = \overline{k, n}$.
5. Оцениваем $\ln d_i = \ln |x'(t+i\tau) - x(t+i\tau)|$, $i = \overline{1, n}$ и выбираем только точки, где $\ln d_i < 0$.
6. Строим график $\ln(d_n)$ от n .
7. Строим прямую регрессии для выбранных точек и вычисляем её наклон, который равен наибольшему показателю Ляпунова. В результате получаем оценку значения показателя Ляпунова для $t = 1$.
8. Изменяем момент времени $t = t + 1$ и повторяем процедуру, начиная с пункта 2 для всех отсчетов данного сегмента.
9. Производится оценка старшего показателя Ляпунова как среднее арифметическое показателей Ляпунова, полученных на каждом шаге алгоритма.

Следует отметить, что для расчета старшего показателя Ляпунова в каждом сегменте ЭЭГ используются обученные нейронные сети, полученные на этапе сегментации. В результате получается набор сегментов для каждого сигнала ЭЭГ с соответствующими значениями старшего показателя Ляпунова. Если разные сегменты имеют одинаковые значения старшего показателя Ляпунова, то они объединяются в один сегмент.

5. Эксперименты. Рассмотрим результаты экспериментов по тестированию разработанной диагностической системы. В качестве исходных данных использовались как стандартные ЭЭГ-данные, взятые из департамента эпилептологии Боннского университета [26], и данные, полученные из 5-ой клинической больницы г. Минска.

Первый набор данных представляет собой очищенные от артефактов данные, которые состоят из множеств (А-Е) ЭЭГ-сигналов [26]. Каждое множество состоит из 100 сигналов, и каждый сигнал содержит 4096 отсчетов продолжительностью 23,6 секунды. Множества А и В состоят из ЭЭГ-сигналов, полученных от здоровых пациентов с открытыми глазами (множество А) и закрытыми глазами (множество В) соответственно. Множества С and D включают ЭЭГ-фрагменты больных эпилепсией во время отсутствия эпилептического состояния. Множество С состоит из ЭЭГ фрагментов, полученных из эпилептической зоны, а множество D состоит из фрагментов, полученных из противоположного полушария головного мозга. Множество Е содержит ЭЭГ-фрагменты с эпилептической активностью. На рисунке 3 представлены результаты экспериментов.

Как видно из рисунка, система не имеет ложных обнаружений на множестве А. Такие же результаты были показаны на множестве В. Таким образом, для здоровых пациентов диагностическая система не имеет ложных обнаружений. В таблице 1 представлены общие результаты экспериментов для всех множеств. Интересно, что в множестве С, которое состоит из ЭЭГ-сигналов, полученных с эпилептической зоны, каждый раз выделялся один сегмент с эпилептической активностью (таблица 1, 6% обнаружения эпилептической активности). Следует отметить, что для множеств С и D система обнаруживает эпилептические события. Возможно, это происходит из-за скрытых эпилептических процессов. Если не брать в расчет

множества С и D, то общая точность классификации составляет 97,7%, что соответствует лучшим результатам, полученным при анализе данных сигналов ЭЭГ.

Преимуществом данной системы является то, что она способна не только определять эпилептическую активность в сигналах ЭЭГ, но также выделять временные сегменты, где эта активность имеется.

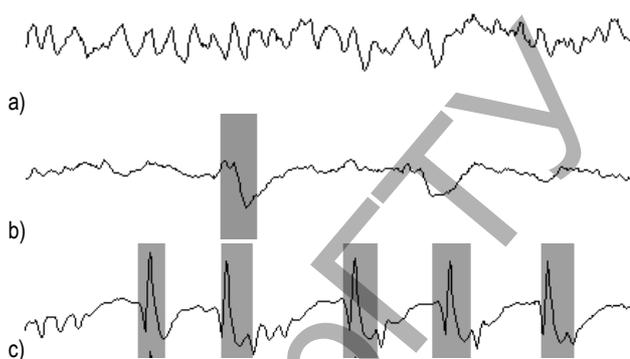


Рис. 3. Анализ ЭЭГ фрагментов множества А, С and Е: а) во фрагменте множества А не выявлено эпилептической активности; б) фрагмент множества С имеет один сегмент с эпилептической активностью (выделено серым цветом); в) пять сегментов с эпилептической активностью выделено (серый цвет) в фрагменте Е

Таблица 1. Результаты классификации

Множество	Класс 1: эпилептическая активность	Класс 2: нормальная активность
А	0 %	100 %
В	0 %	100 %
С	6 %	94 %
Д	32 %	68 %
Е	92 %	8 %

Следующие эксперименты были осуществлены с использованием ЭЭГ сигналов, полученных из 5-ой клинической больницы г. Минска. ЭЭГ сигналы представляют набор данных, которые содержат 21 регистрацию для 8 взрослых пациентов. Каждая регистрация состоит из 16 сигналов ЭЭГ (см. рисунок 4).

В результате было получено 336 сигналов ЭЭГ. Каждый ЭЭГ-сигнал представляет собой временной ряд, состоящий из 2000 отсчетов.

Представленные данные, в отличие от предыдущего эксперимента, являются необработанными, то есть содержат различные артефакты, являющиеся результатом моргания глаз, сердечной активности и т.п. Поэтому здесь необходимо использовать метод независимых компонент ICA, который позволяет из линейных смесей независимых сигналов от различных источников выделить исходные несмешанные сигналы. Для этого сигналы ЭЭГ одной регистрации разбиваются на наборы данных по три сигнала в каждом и подаются на 6 модулей ICA, как показано на рисунке 5.

В результате, после ICA фильтрации получается 6 сигналов ЭЭГ, которые подвергаются сегментации и анализу диагностической системой.

Для оценки качества обнаружения эпилептической активности воспользуемся следующими характеристиками:

- FP (false positives) – количество сегментов с нормальным состоянием, классифицированных как эпилептические. Они характеризуют ложные срабатывания;
- FN (false negatives) – количество сегментов с эпилептической активностью, классифицированных как нормальные. Они характеризуют необнаружение эпилептической активности;
- TP (true positives) – количество правильно классифицированных эпилептических сегментов;
- TN (true negatives) – количество правильно классифицированных неэпилептических сегментов.

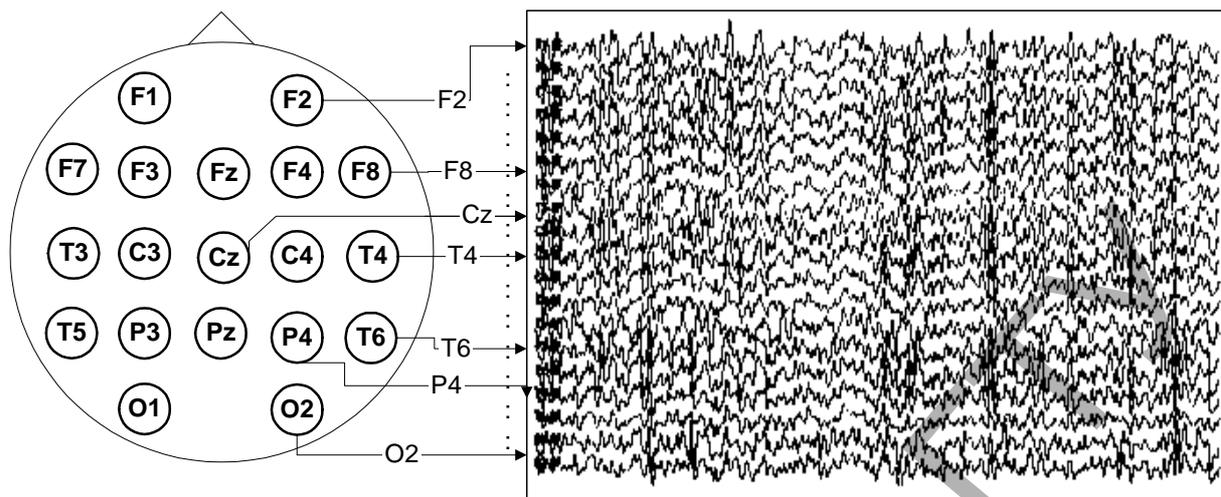


Рис. 4. Пример регистрации электроэнцефалограммы

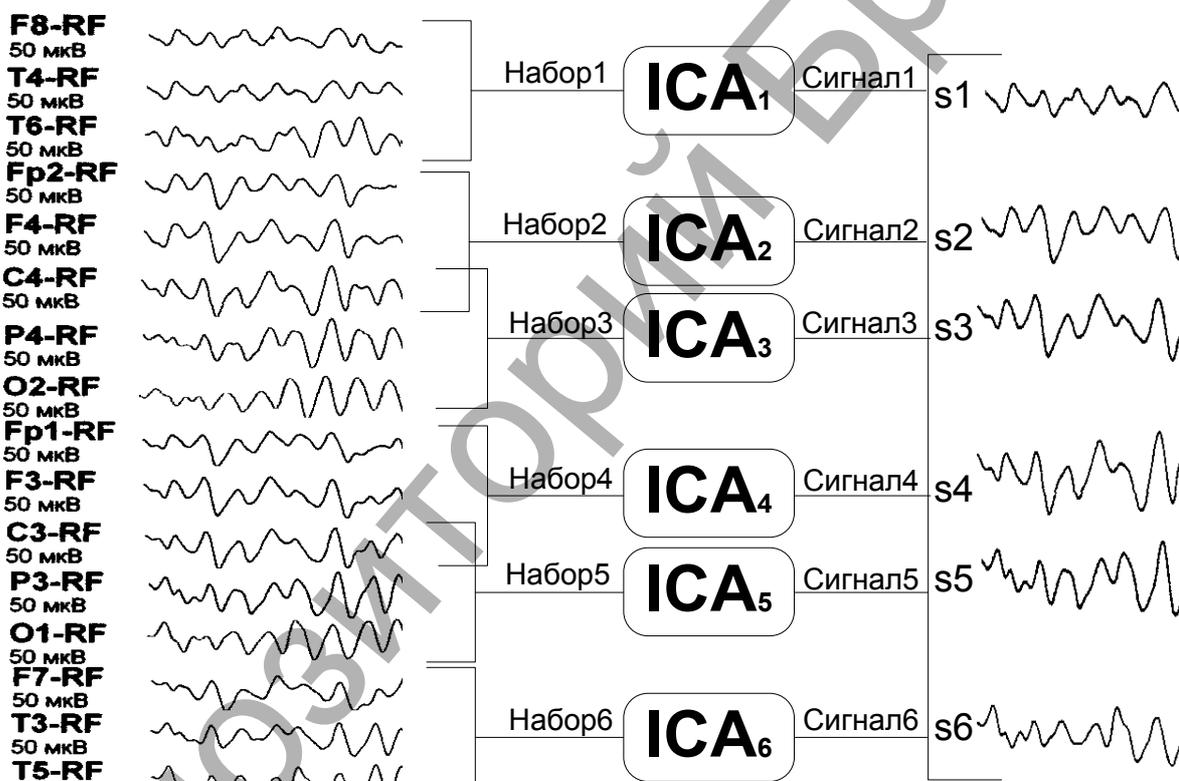


Рис. 5. Формирование шести наборов сигналов для ICA на основе одной регистрации ЭЭГ

Тогда параметры, характеризующие качество классификации, определяются следующим образом:

- ACC (accuracy) – точность классификации, характеризующая качество работы системы в целом:

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} = \frac{TP + TN}{P + N}, \quad (7)$$

- TPR (true positive rate) – чувствительность, вероятность правильной классификации сегментов с эпилептической активностью:

$$TPR = \frac{TP}{TP + FN} = \frac{TP}{P}, \quad (8)$$

- FNR (false negative rate) – ошибка первого рода или уровень значимости, характеризующая вероятность неправильной классификации сегментов с эпилептической активностью:

$$\alpha = FNR = 1 - TPR = \frac{FN}{P}, \quad (9)$$

- TNR (true negative rate) – специфичность (мощность критерия), характеризующая вероятность правильной классификации сегментов с неэпилептической активностью:

$$TNR = \frac{TN}{FP + TN} = \frac{TN}{N}, \quad (10)$$

- FPR (false positive rate) – ошибка второго рода, характеризующая вероятность классификации сегментов с нормальной активностью как эпилептические (вероятность ложных срабатываний):

$$\beta = FPR = 1 - TNR = \frac{FP}{TN + FP} = \frac{FP}{N}. \quad (11)$$

Результаты обнаружения эпилептической активности в сигналах ЭЭГ приведены в таблице 2.



Рис. 6. Обнаружение epileptической активности в виде одной вспышки в височной области правого полушария головного мозга (L – значение старшего показателя Ляпунова)



Рис. 7. Обнаружение вспышки epileptической активности по всем зонам правого полушария головного мозга (L – значение старшего показателя Ляпунова)

Таблица 2. Результаты классификации

Сегменты	Количество сегментов	Результаты классификации	
		Класс 1: эпилептическая активность	Класс 2: нормальная активность
Эпилептические	32	29	3
Нормальные	1743	4	1739

Значения статистических параметров, которые характеризуют качество классификации, показаны в таблице 3.

Как следует из таблицы, ошибка второго рода $\beta = 0,3\%$, что характеризует очень малое значение ложных срабатываний. На рисунке 6 изображен пример обнаружения эпилептической активности в виде вспышки в височной области правого полушария головного мозга для одной регистрации. На рисунке 7 изображен пример обнаружения вспышки эпилептической активности по всем зонам правого полушария головного мозга. Как видно из рисунков, разработанная система позволяет выделять временные сегменты в сигналах ЭЭГ с эпилептической активностью и определять зоны появления эпилептической активности. Основными преимуществами предложенной методологии определения эпилептической активности является высокая точность классификации 99,6% при малой вероятности ложных срабатываний, равной 0,003, и отсутствие необходимости обучения на эталонных наборах, а также способность выделять в сигналах ЭЭГ временные сегменты с эпилептической и нормальной активностью.

Таблица 3. Значения статистических параметров

Статистические параметры	Значения
Специфичность	99,7 %
Чувствительность	90,6 %
Общая точность классификации	99,6 %

Заключение. В данной статье разработана нейроинтеллектуальная система для определения эпилептической активности на основе анализа сигналов электроэнцефалограмм (ЭЭГ). Такая система обучается без учителя и позволяет выделять временные сегменты в сигналах ЭЭГ с эпилептической и нормальной активностью. При эпилептической активности происходит снижение старшего показателя Ляпунова в сигнале ЭЭГ. Поэтому в качестве критерия наличия эпилептической активности рассматривается значение старшего показателя Ляпунова. Такая система позволяет визуализировать сегменты (зоны) с эпилептической и нормальной активностью в сигналах ЭЭГ путем генерирования двумерной карты результатов диагностирования. Основными преимуществами предложенной методологии определения эпилептической активности является высокая точность классификации 99,6% при малой вероятности ложных срабатываний, равной $\beta = 0,3\%$.

Исследования проводятся в соответствии с ГПНИ «Информатика и космос» Республики Беларусь по теме «Нейроинтеллектуальные технологии обработки информации для построения самоорганизующихся систем» под руководством д.т.н., профессора Головки Владимира Адамовича.

СПИСОК ЦИТИРОВАННЫХ ИСТОЧНИКОВ

- Guo, L. Epileptic seizure detection using multiwavelet transform based approximate entropy and artificial neural networks / L. Guo, D. Rivero, A. Pazos // J of Neuroscience Methods. – 2010. – Vol. 193. – P. 156–163.
- Iasemidis, L.D. Measurement and quantification of spatiotemporal dynamics of human epileptic seizures / L.D. Iasemidis, J.C. Principe, J.C. Sackellares // Nonlinear signal processing in medicine. – NY: IEEE Press, 2000. – Vol. 2. – P. 1-27.
- Polat, K. Classification of epileptiform EEG using a hybrid system based on decision tree classifier and fast Fourier transform / K. Polat, S. Gunes // Applied Mathematics and Computation. – 2007. – Vol. 187. – P. 1017–1026.
- Automatic epileptic seizure detection in EEGs based on line length feature and artificial neural networks / L. Guo [et al.] // J of Neuroscience Methods. – 2010. – Vol. 191. – P. 101–109.
- Nonlinear features of surface EEG showing systematic brain signal adaptations with muscle force and fatigue / B. Yoa [et al.] // Brain research. – 2009. – Vol. 1272. – P. 89–98.
- Sarbadhikari, S.N. Chaos in the brain: a short review alluding to epilepsy, depression, exercise and lateralization / S.N. Sarbadhikari, K. Chakrabarty // Medical Engineering & Physics. – 2001. – Vol. 23. – P. 445–455.
- Research on the relation of EEG signal chaos characteristics with high-level intelligence activity of human brain / X. Wang [et al.] // Nonlinear Biomedical Physics. – 2010. – Chap. 4.
- Nigam, V.P. A neural-network-based detection of epilepsy / V.P. Nigam, D. Graupe // Neurological Research. – 2004. – Vol. 26. – P. 55–60.
- Patnaika, L.M. Epileptic EEG detection using neural networks and post-classification / L.M. Patnaika, O.K. Manyam // Computer methods and programs in biomedicine. – 2008. – Vol. 91. – P. 100–109.
- Subasi, A. Application of adaptive neuro-fuzzy inference system for epileptic seizure detection using wavelet feature extraction / A. Subasi // Computers in Biology and Medicine. – 2007. – Vol. 37. – P. 227–244.
- Subasi, A. Automatic detection of epileptic seizure using dynamic fuzzy neural networks / A. Subasi // Expert Systems with Applications. – 2006. – Vol. 31. – P. 320–328.
- Ocak, H. Optimal classification of epileptic seizures in EEG using wavelet analysis and genetic algorithm / H. Ocak // Signal Processing. – 2008. – Vol. 88. – P. 1858–1867.
- Hsu, K-Ch. Detection of seizures in EEG using subband nonlinear parameters and genetic algorithm / K-Ch. Hsu, S-N. Yu // Computers in Biology and Medicine. – 2010. – Vol. 40. – P. 823–830.
- Пригожин, И. Время, хаос, квант: к решению парадокса времени / И. Пригожин, И. Стенгер. – Москва: URSS, 2008. – 300с.
- Determining Lyapunov exponents from a time series / A. Wolf [et al.] // Physica D. – 1985. – Vol. 16. – P. 285–292.
- Hyvaerinen, A. Independent component analysis: algorithms and applications / A. Hyvaerinen, E. Oja // Neural Networks. – Elsevier, 2000. – Vol. 13. – P. 411-430.
- Takens, F. Detecting strange attractors in turbulence / F. Takens // Mathematics: Lecture Notes. – Berlin: Springer-Verlag, 1980. – Vol. 898. – P. 366-381.
- Головки, В.А. Нейросетевые методы обработки хаотических процессов / В.А. Головки // Лекции по Нейроинформатике. – М.: МИФИ, 2005. – С. 43-88.
- Golovko, V. Application of Neural Networks Techniques to Chaotic Signal Processing / V. Golovko, A. Doudkin, N. Maniakov, // Optical Memory and Neural Networks. – Elsevier, 2004. – V. 13(4). – P. 195-215.
- Rosenstein, M.T. A practical method for calculating largest Lyapunov exponents from small data sets / M.T. Rosenstein, J.J. Collins, C.J. De Luca // Physica D. – 1993. – Vol. 65. – P. 117-134.
- Kantz, H. A robust method to estimate the maximal Lyapunov exponent of a time series / H. Kantz // Physics Letters A. – 1994. – Vol. 185. – P. 77–87.
- Golovko, V. From Neural Networks to Intelligent Systems: Selected Aspects of Training, Application and Evolution / V. Golovko // Limitations and Future Trends in Neural Computation: NATO book. – Amsterdam: IOS Press, 2003. – Chap. 12. – P. 219–243.
- Lopes da Silva, F. EEG analysis: theory and practice / F. Lopes da Silva // Electroencephalography: basic principles, clinical applications, an related fields / ed. E. Niedermeyer, F. Lopes da Silva editors. – Baltimore: Lippincott, Williams and Wilkins, 1998. – 4th ed. – P. 1153-1163.
- Golovko, V. Neural Networks for Signal Processing in Measurement Analysis and Industrial Applications: the Case of Chaotic Signal Processing / V. Golovko, Y. Savitsky, N. Maniakov // Neural networks for instrumentation, measurement and related industrial applications: NATO book. – Amsterdam: IOS Press, 2003. – Chap. 6. – P. 119-143.
- Головки, В.А. Нейросетевые методы определения спектра Ляпунова хаотических процессов / В.А. Головки, Н.Ю. Чумерин // Нейрокомпьютеры: разработка и применение. – М.: Радиотехника, 2004. – №1. – С. 129–136.
- EEG time series // Dept. of Epileptology University of Bonn [Electronic resource]. – Mode of access: <http://www.meb.uni-bonn.de/epileptologie/science/physik/eegdata.html>. – Date of access: 25 May 2011.

Материал поступил в редакцию 11.12.12

GOLOVKO V.A., LAURENTSYEVA S.V. The neural-net analysis of electroencephalogram for epileptic activity detection

The paper presents a neural-net system for epileptic activity detection on the base of EEG signals analysis. The designed system allows to allocate time segments with epileptic activity in the EEG signals and to determine the occurrence of epileptic activity zone. The main advantages of the proposed diagnostic system for the epileptic activity detection are a high classification accuracy equal 99,6% for the low probability of false positives equal to 0,003 and the lack of prior training on the etalon data. Experimental results showing the effectiveness of the developed approach are presented.

УДК 004.896

Дёмин В.В., Дунец И.П., Михняев А.Л.

СОЗДАНИЕ ПЛАТФОРМЫ РОБОТА-ГИДА И АЛГОРИТМЫ ЕГО НАВИГАЦИИ В ДИНАМИЧЕСКОЙ СРЕДЕ

Введение. В настоящее время в мире проекты робота-гида разрабатывают различные крупнейшие корпорации (Sony, Hitachi, Toshiba, General Motors, Siemens и другие [1–3]). Эти устройства с успехом были применены в кинотеатрах (ED Corporation [4]), в Сеульском национальном историческом музее, в Мадридском офисе Santander's Group City [5], региональном археологическом музее Agrigento, Штутгартском институте мануфактуры инженерии и автоматки, форумах и корпоративных офисах (Kaikan Exhibition Hall в Toyota City [6]). Главной сложностью применения таких систем является высокая стоимость и закрытые исходные коды. Это делает экономически непривлекательным использование любой из существующих платформ для создания автоматизированных выставок в небольших экспозициях и музеях. В 2014 году в Республике Беларусь будет проводиться чемпионат мира по хоккею. Событие такого масштаба будет способствовать многократному увеличению туристов, посещающих нашу страну. Для увеличения числа посетителей выставки будут нуждаться в технических новшествах. Такими ноу-хау могут стать автоматизированные выставки, где экскурсоводами выступают роботизированные гиды. Идея создания робота-гида получила поддержку Министерства образования Республики Беларусь в виде гранта «Разработка прототипа интеллектуальной роботизированной платформы для создания робота-гида», и в настоящий момент ведется разработка макета и программной системы управления роботом.

Главной особенностью робота-гида является взаимодействие с людьми на выставках в закрытом пространстве. В помещении располагается определенное число экспонатов (рисунок 1). У робота есть информация о карте помещения, координатах экспонатов и координатах начала движения. Для управления выбором экскурсий используется сенсорный экран. Каждый посетитель может выбрать интересующий его маршрут. После определения маршрута прокладывается путь к экспонатам. В процессе движения воспроизводится мультимедийная развлекательная информация о выставке и по прибытии на место – об экспонатах.

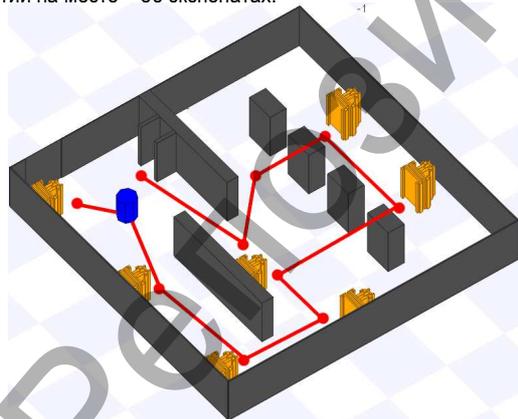


Рис. 1. Модель комнаты-выставки для робота-гида

В настоящий момент изготовлен макет робота-гида и осуществляется разработка программной системы управления роботом. Для разработки и отладки алгоритмов использована система компьютер-

ного моделирования Player/Stage.

Для уменьшения затрат в проекте используются только сенсоры низшего ценового диапазона. Такие сенсоры обладают достаточной точностью, но требуют дополнительной обработки получаемых данных. Для определения препятствий в проекте применяются ультразвуковые и инфракрасные датчики, алгоритмы обработки данных от которых разработаны опираясь на предыдущие исследования, проведенные в СНИЛ «Робототехника» БрГТУ.

1. Платформа робота. Роботизированная платформа разрабатывается в СНИЛ «Робототехника» Брестского государственного технического университета. Внешний вид компьютерной модели робота показан на рисунке 2а. На сегодняшний день также разработан макет робота-гида, приведенный на рисунке 2б. Макет имеет диаметр 46 см, оснащен одометрами, гироскопом, ультразвуковыми датчиками, инфракрасными датчиками и двумя wi-fi-камерами. Для передвижения платформа макета оборудована четырьмя колесами, два из которых свободно вращаются на 360 градусов относительно своей оси, а два оборудованы электроприводами. Каждое из приводных колес оснащено оптическим одометром, позволяющим отсчитывать 64 деления за оборот колеса. Для управления движением роботом используется дифференциальная схема управления, при которой поворот платформы осуществляется за счет разницы скоростей вращения колес. Максимальная скорость движения робота 1,5 м/с.



а)

Демин В.В., магистрант кафедры интеллектуальных информационных технологий Брестского государственного технического университета.

Дунец И.П., аспирант кафедры интеллектуальных информационных технологий Брестского государственного технического университета.

Михняев А.Л., ассистент кафедрой интеллектуальных информационных технологий Брестского государственного технического университета.

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

Физика, математика, информатика