

С.В. БЕЗОБРАЗОВА, В.А. ГОЛОВКО

Брестский государственный технический университет, Республика Беларусь
svetilka@gmail.com, gva@bstu.by

НЕЙРОСЕТЕВАЯ МОДЕЛЬ СЕГМЕНТАЦИИ ЭЛЕКТРОЭНЦЕФАЛОГРАММ В ЗАДАЧЕ ОБНАРУЖЕНИЯ ЭПИЛЕПТИФОРМНОЙ АКТИВНОСТИ

Наше исследование хаотических процессов направлено на идентификацию уровня хаоса в них и тем самым обнаружение аномалий при его снижении. В частности, мы рассматриваем задачу диагностики эпилепсии. Для исследования и обнаружения эпилепсии широко используется электроэнцефалография, предметом изучения которой являются электрические явления в мозге человека. В данной статье рассматривается исследование сигналов электроэнцефалограмм при помощи теории хаоса и теории нейронных сетей. Произведен анализ эффективности использования сегментации сигнала в задаче обнаружения эпилептиформной активности.

Введение. Задача повышения точности идентификации хаотического процесса является одной из основных в нашей исследовательской работе [1]. Решение этой проблемы позволит обнаруживать не только участки проявления аномалий в сигналах, но и их длительность. В результате необходимости выделения участков сигнала с различными уровнями хаоса возникла задача сегментации, то есть разбиения исходного сигнала на участки, в пределах которых степень хаоса является одинаковой.

Для исследования и обнаружения эпилепсии широко используется электроэнцефалография, предметом изучения которой являются электрические явления в мозге человека. Исследования сигналов электроэнцефалограммы (ЭЭГ), направленные на изучение их структуры, показали возможность сегментирования ЭЭГ на относительно стационарные участки, длительностью около 0,1 ~ 0,2 с [2].

Электрическая активность головного мозга носит хаотический характер. Однако, при наступлении эпилептических приступов, либо обострения других нервно-психических заболеваний, вызывающих появление эпилептиформной активности на ЭЭГ, происходит снижение хаотичности сигнала.

В качестве меры хаоса может служить корреляционная размерность или старший показатель Ляпунова [3]. При эпилептических припадках наблюдается уменьшение корреляционной размерности и старшего показателя Ляпунова, что характеризует переход от хаоса к порядку.

В данной статье на основе экспериментальных исследований проводится анализ эффективности использования сегментации сигнала ЭЭГ при решении задачи обнаружению эпилептиформной активности. В первом разделе статьи описывается процедура сегментации сигналов. Во втором разделе приводится алгоритм расчета старшего показателя Ляпунова при помощи нейронных сетей. Третий раздел содержит описание нейросетевой методики сегментации сигналов. В четвертом разделе рассматривается выбор размера элементарного отрезка для прогнозирования. Пятый раздел посвящен испытанию предложенной методики на ЭЭГ сигналах.

1. Сегментация сигналов. Процедуру сегментации временного ряда на фрагменты по степени хаотичности можно разделить на четыре этапа [2], как представлено на рис. 1.

1. На первом этапе сигнал разбивается на элементарные участки.
2. Затем на каждом из этих участков производится расчет меры хаотичности, определяющей поведение сигнала на данном отрезке.
3. На третьем этапе элементарные участки классифицируются в соответствии с уровнем хаотичности сигнала, получая каждый свое классификационное наименование.
4. Наконец, на четвертом этапе "стираются" границы между одноименными элементарными участками, что превращает весь временной ряд в последовательность сегментов, в рамках которых уровень хаоса остается относительно постоянным.

Главной задачей является первый этап, то есть разбиение исходного сигнала на элементарные участки, для его реализации наиболее эффективной считается адаптивная сегментация. Такой подход к сегментации предполагает определение границы между сегментами при обнаружении изменения характеристических параметров [2]. Производится оценка степени сходства фиксированного участка исходного сигнала с последующим фрагментом этого сигнала, рассматриваемом в движущемся вдоль записи временном "окне". Очевидно, что как только в это окно попадет граница сегментов, контролируемая степень сходства резко уменьшится, и это будет формальным признаком перехода к следующему сегменту, участку с другой степенью хаотичности.

Однако этот метод порождает ряд сложностей, так как необходимо подобрать параметры, которые будут характеризовать каждый сегмент определенными значениями. В нашем исследовании характеристическим параметром выступает старший показатель Ляпунова, поэтому мы предлагаем степень сходства определять по точности прогноза при прогнозировании фиксированного участка исходного сигнала.

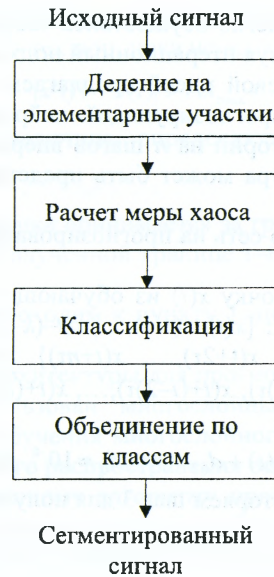


Рис. 1. Сегментация сигнала

2. Расчет меры хаоса. 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.

Рассмотрим определение старшего показателя Ляпунова на базе нейронной сети [4-6]. Ключевой идеей данного метода является вычисление при помощи прогнозирующей нейронной сети расхождения двух близлежащих траекторий на n шагов вперед.

Нейронная сеть будет состоять из $k \geq m - 1$ входных нейронов, p скрытых и одного выходного нейронного элемента. Здесь m – размерность пространства вложения.

Вначале необходимо обучить такую нейронную сеть прогнозированию в соответствии с методом скользящего окна:

$$x(t+i\tau) = F(x(t+(i-1)\tau), x(t+(i-2)\tau), \dots, x(t+(i-k)\tau)), \quad i = \overline{1, n}, \quad (1)$$

где τ – временная задержка.

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. Эта процедура может быть представлена следующим алгоритмом.

1. Обучаем нейронную сеть на прогнозирование по методу скользящего окна.

2. Выбираем любую точку $x(t)$ 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 $\{x(t+\tau), x(t+2\tau), \dots, x(t+n\tau)\}$ 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 $i = \overline{1, n}$, F – нелинейная функция.

4. Вычисляем $x'(t) = x(t) + d_0$, где $d_0 \approx 10^{-8}$ и, подавая на сеть $\{x'(t), x(t-\tau), \dots, x(t-(k-1)\tau)\}$, повторяем шаг 3 для получения $x'(t+i\tau)$, $i = \overline{1, n}$.

5. Оцениваем $\ln(d_n) = \ln |x'(t+i\tau) - x(t+i\tau)|$, $i = \overline{1, n}$ и выбираем только точки, где $\ln d < 0$.

6. Строим график зависимости $\ln(d_n)$ от n .

7. Строим прямую регрессии для выбранных точек и вычисляем её наклон, который равен наибольшему показателю Ляпунова.

Данный метод позволяет достаточно просто вычислить старший показатель Ляпунова при малом объеме экспериментальных данных.

3. Нейросетевой подход в сегментации. Для прогнозирования данных в нашем случае наиболее подходящим методом являются искусственные нейронные сети, так как они позволяют анализировать небольшие объемы данных [6].

Предположим, у нас есть временной ряд $X = \{x(1), x(2), \dots, x(m)\}$, где m – количество точек временного ряда, сформированного с учетом временной задержки τ согласно (1). Тогда деление на элементарные участки при помощи прогнозирующей нейронной сети будет осуществляться по 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)

$$|x'(i) - x(i)| > \Delta x_{\max}, \quad (2)$$

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

5. Если $i = 0$, то i -я точка принимается за границу сегментов и временное окно смещается к полученной границе $t=t+N$, иначе окно смещается на i точек $t=t+i$.

6. Если $t < m-N$, то переходим к пункту 1 иначе деление на элементарные участки завершено.

В качестве базовой архитектуры для прогнозирования временных процессов в работе использован многослойный перцептрон (Multilayer Perceptron, MLP). Для обучения многослойного перцептрона мы использовали алгоритм обратного распространения ошибки.

Согласно вышеописанному алгоритму произведем сегментацию смешанного ряда, изображенного на рис. 2, а. Ряд представляет собой набор из 420 отсчетов: 140 отсчетов выборки Энона, далее 70 отсчетов функции косинуса, еще 50 отсчетов выборки Энона и 50 отсчетов косинуса, завершает 110 отсчетов ряда Энона.




Рис. 2. Смешанный сигнал

Выборка Энона представляет собой значения x -координат, полученные по формулам (3).

$$\begin{cases} x_{t+1} = 1 - \alpha x_t^2 + y_t, \\ y_{t+1} = \beta x_t, \end{cases} \quad (3)$$

где $\alpha = 1.4$ и $\beta = 0.3$, t – номер отсчета.

Значение старшего показателя Ляпунова для этой выборки должно равняться 0.418. Функция косинуса (4) имеет значение экспоненты Ляпунова около нуля.

$$x_t = \cos(kt), \quad (4)$$

где $k = 0.1$, t – номер отсчета.

Согласно первому этапу будем производить прогнозирование элементарных отрезков по N отсчетов. Далее на каждом отрезке произведем вычисление старшего показателя Ляпунова, определяющего хаотичность сигнала. Согласно построению сигнала результат классификации должен делить наш сигнал на два класса – это выборка Энона и функция косинус, однако присутствует элемент непредсказуемости, когда элементарный отрезок включает в себя переход от одного класса к другому. Исходя из сказанного, введем третий класс, который будет включать сегменты с тем уровнем хаоса, что не входит в предполагаемые диапазоны. Таким образом, к первому классу отнесем отрезки со значениями ≈ 0.4 , ко второму – со значениями около нуля, и к третьему – все остальные отрезки. Элементарные отрезки, которые принадлежат одному классу, объединяются. Результат адаптивной сегментации при помощи нейронных сетей показан на рис. 3, а при $N = 70$ и на рис. 3, б при $N = 30$.

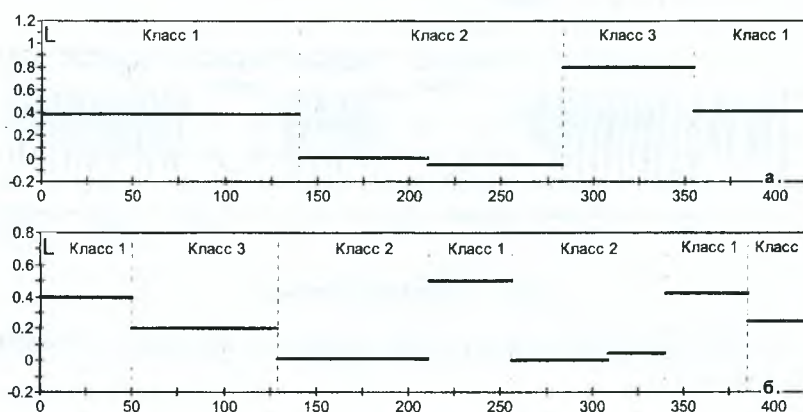


Рис. 3. Адаптивная сегментация при помощи нейронных сетей
а.) при $N = 70$; б.) при $N = 30$; L – значение старшего показателя Ляпунова

Из рис. 3 видно, что важно правильно выбрать временной масштаб. Очевидно, что при $N = 70$ не все переходы обнаруживаются, а при $N = 30$ недостаточно данных для точного расчета старшего показателя Ляпунова. Отсюда возникает задача выбора временного масштаба, которая подробно рассматривается в следующем разделе статьи.

4. Выбор временного масштаба. Остается определить размер обучающей выборки, либо элементарного интервала. Если она будет достаточно большой, то мы наверняка обнаружим присутствие аномалии, однако не сможем определить количество переходов, а также точную длительность сегментов каждого класса. С другой стороны маленький размер выборки может привести к ложному определению из-за недостаточного количества данных для расчета старшего показателя Ляпунова. Как же определить этот средний оптимальный размер?

Исходя из примера, показанного на рис. 3, можно предположить, что ответ на вопрос следует искать не в самих методах, а в анализируемых данных. Важным аспектом является знание возможной наименьшей длительности сегмента, тогда ее можно принять за длительность элементарного отрезка.

Предположим нам известно, что в смешанном сигнале изображенном на рис. 2 минимальная длина сегмента составляет 50 отсчетов, тогда результаты расчета представленные на рис. 4 гораздо точнее.




Рис. 4. Сегментация при элементарном отрезке $N = 50$ отсчетов;
 L – значение старшего показателя Ляпунова

Из рис. 4 видно, что качество идентификации переходов очень высокое: сегментация произведена с точностью до трех отсчетов, все сегменты идентифицированы правильно, отсутствуют неопределенные сегменты.

Учитывая, что рассматриваемая методика направлена на обнаружение эпилепсии при анализе сигнала ЭЭГ, тогда необходимо выяснить, сколько длятся эпилептиформные активности на ЭЭГ, и какой самый маленький

период их повторения. Зная это минимальное значение T_{min} , размер обучающей выборки N определим по формуле:

$$N \leq \frac{T_{min}}{\tau \cdot \Delta t}, \quad (5)$$

где Δt – интервал, через который сняты данные ЭЭГ, τ – временная задержка.

Проанализировав различные формы проявления эпилептической активности [7], сведем данные об их длительности в табл. 1.

Таблица 1

Длительность эпилептических форм активности

№	Наименование	Длительность в мс
1.	Спайк	20-70
2.	Острая волна	70-200
3.	Комплекс спайк-волна	160-250 (период)
4.	Комплекс острая волна-медленная волна	500-1300 (период)

Из табл. 1 видно, что $T_{min} = 20$ мс. Однако, если известен тип эпилептиформной активности, который содержится в анализируемом ЭЭГ сигнале, тогда минимальное значение T_{min} будет выбираться как минимальная длительность для соответствующего типа активности.

Таким образом, размер элементарного отрезка необходимо выбирать с учетом анализируемых данных и тех свойств, которые о них известны.

5. Применение сегментации к сигналам электроэнцефалограмм. Рассмотрим предложенный подход на примере ЭЭГ сигнала, где аномалией являются эпилептиформные активности, вызывающие снижение уровня хаоса в сигнале [8].

На рис. 5, а изображен исследуемый сигнал ЭЭГ с двумя спайками (островершинные высокоамплитудные волны, появившиеся в сигнале в результате эпилептического приступа). Данные взяты с интервалом $\Delta t = 0.5$ мс. Рассчитано, что $\tau = 1$, тогда для $T_{min} = 20$ мс согласно (5) размер обучающей выборки $N = 40$. На рисунке 5.б показаны результаты сегментации этого сигнала согласно предложенному алгоритму: к классу I отнесены сегменты с положительным значением старшего показателя Ляпунова (нормальная активность), к классу II – с отрицательным (эпилептиформная активность). Из рис. 4 видно, что адаптивная сегментация при

помощи нейронных сетей позволила обнаружить все эпилептиформные активности в анализируемом сигнале и определить их длительность.

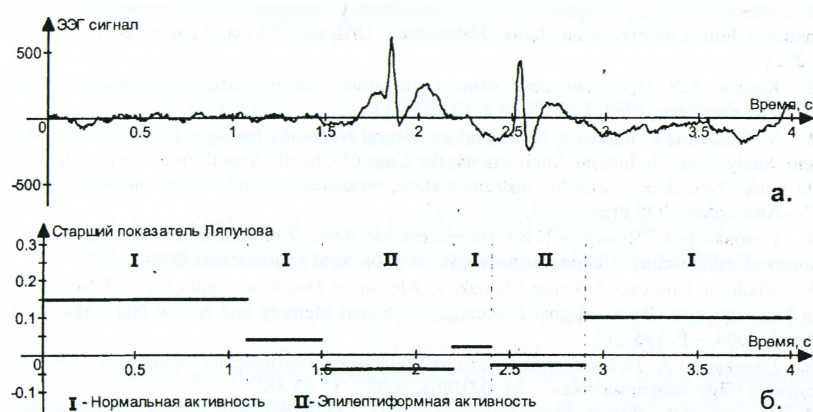


Рис. 4. Сигнал ЭЭГ (а);
адаптивная сегментация сигнала ЭЭГ при помощи нейронных сетей (б)

Выводы.

1. Разработан нейросетевой подход к сегментации сигналов. Сегменты идентифицируются по уровню хаоса на участке сигнала.
2. Рассмотрен способ решения проблемы выбора временного масштаба при помощи исследования сегментируемых рядов и выделения возможного наименьшего размера сегмента.
3. Предложенный подход позволяет повысить точность обнаружения эпилептиформной активности в сигнале ЭЭГ, так как применение сегментации предполагает определение длительности соответствующего сегмента.

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

Список литературы

1. 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.
2. Каплан А.Я. Проблема сегментного описания электроэнцефалограммы человека // Физиология человека, 1999, Том 25, № 1, С. 125-133.
3. 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, P. 119-143.
4. Головки В.А., Чумерин Н.Ю. Нейросетевые методы определения спектра Ляпунова хаотических процессов // Нейрокомпьютеры: разработка и применение, 2004. – №1.
5. Vladimir Golovko, Nikolay Maniakov, Alexander Doudkin. Application of Neural Networks Techniques to Chaotic Signal Processing // Optical Memory and Neural Networks, vol.13, Number 4, 2004, – P. 195-215.
6. Головки В.А. Нейросетевые методы обработки хаотических процессов // В книге «Лекции по Нейроинформатике». – М.: МИФИ, 2005. – С. 43-88.
7. Зенкова Л.Р. «Клиническая эпилептология». - Медицинское информационное агентство, 2002, – 416с.
8. Sackellares J.Ch, Iasemidis L.D, Shiau D. Epilepsy when chaos fail. Singapore: Word Scientific, 1990.