

Безобразова С.В., Головки В.А., Лаврентьев В.В.

АДАПТИВНАЯ СЕГМЕНТАЦИЯ СИГНАЛОВ ЭЛЕКТРОЭНЦЕФАЛОГРАММ НА ОСНОВЕ НЕЙРОННЫХ СЕТЕЙ

Введение. В настоящее время все более широкий интерес приобретает область исследования мозга человека. Одним из направлений изучения функционирования головного мозга является электроэнцефалография [1]. Анализ сигналов электроэнцефалограмм (ЭЭГ) направлен не только на определение психического и функционального состояния человека, но и на обнаружение патологических активностей.

Сигналы ЭЭГ отражают суммарную электрическую активность головного мозга и по своему характеру являются нестационарными [2]. Методы, используемые сегодня в клиниках для обнаружения патологий по ЭЭГ, имеют ряд недостатков и, главное, рассчитаны на анализ стационарных временных рядов [3].

Исследования сигналов ЭЭГ, направленные на изучение их структуры, показали возможность сегментирования ЭЭГ на стационарные участки, длительностью около 0,2 ~ 1 секунды [2]. По сути своей ЭЭГ является непрерывным сигналом, однако компьютерная регистрация и вычисления предполагают работу с детерминированными рядами (обычно регистрация производится с частотой 100 - 250 Гц) [1]. Применение существующих методов для анализа таких небольших участков, длительностью от 50 отсчетов, невозможно, так как они не предназначены для работы с такими малыми объемами данных. Применение нелинейных методов обработки данных, таких как искусственные нейронные сети, позволяет обойти это ограничение, и применять сегментацию для обнаружения аномалий в сигналах ЭЭГ, например эпилептиформную активность.

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, что отражается в смене стационарных сегментов с разной степенью хаотичности.

Для исследования сложных динамических систем применяют методы нелинейной динамики, позволяющие изучать поведение хаотических процессов во времени. В качестве меры хаоса для сигналов ЭЭГ можно применять следующие характеристические величины: корреляционная размерность, старший показатель Ляпунова [4,5]. При эпилептических припадках наблюдается уменьшение корреляционной размерности и старшего показателя Ляпунова, что характеризует переход от хаоса к порядку.

В данной статье рассматривается применение адаптивной сегментации на основе нейронных сетей для анализа ЭЭГ сигналов и по результатам экспериментальных исследований проводится анализ эффективности использования сегментации ЭЭГ при решении задачи обнаружения эпилептиформной активности. Первый раздел статьи посвящен рассмотрению различных методов сегментации сигналов. Во втором разделе приводится алгоритм расчета старшего показателя Ляпунова при помощи нейронных сетей. В третьем разделе описан нейросетевой алгоритм адаптивной сегментации. В четвертом разделе рассмотрена проблема выбора размера элементарного отрезка для прогнозирования. В пятом разделе производится испытание предложенного подхода на ЭЭГ сигналах.

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



Рис. 1. Сегментация сигнала

Главной задачей является первый этап, то есть разбиение исходного сигнала на элементарные участки.

Основной идеей сегментации методом фиксированных интервалов является разбиение исходного временного ряда на элементарные отрезки фиксированной длины и определение характеристических параметров на каждом из отрезков [2]. В рассматриваемой задаче идентификации хаотических процессов таким параметром является старший показатель Ляпунова [6]. Сегментация методом фиксированных интервалов имеет ряд недостатков:

1. При попадании в элементарный отрезок перехода от одного уровня хаотичности к другому не только невозможно обнаружить этот переход, но и результат расчета не обязательно будет соответствовать одному из вошедших в отрезок сегментов. Таким образом, в такой ситуации результат является непредсказуемым.
2. Погрешность определения точки перехода между сегментами равна размеру элементарного отрезка, что ставит задачу поиска оптимального временного масштаба (данная проблема подробно рассмотрена в разделе 4 данной статьи).

Применение адаптивной сегментации исключает первую проблему и частично решает вторую, так как данный подход 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.

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

Головки Владимир Адамович, профессор, д.т.н., заведующий кафедрой «Интеллектуальные информационные технологии» БрГТУ. Беларусь, БрГТУ, 224017, г. Брест, ул. Московская, 267.

Лаврентьев Виктор Владимирович, инженер-программист СП, ООО «ВЭКНОБЕЛ».

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.

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 [7-9]. Ключевой идеей данного метода является вычисление при помощи прогнозирующей нейронной сети расхождения двух близлежащих траекторий на n шагов вперед.

Наиболее эффективной при решении задачи обнаружения эпилептиформной активности по нашим экспериментам является многослойный персептрон [10], изображенный на рисунке 2. Нейронная сеть состоит из $k \geq m - 1$ входных нейронов, p скрытых и одного выходного нейронного элемента. Здесь m – размерность пространства вложения.

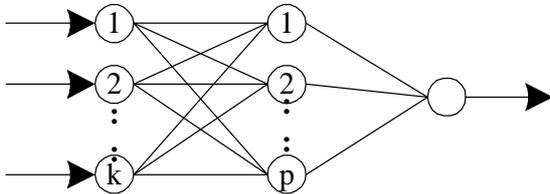


Рис. 2. Многослойный персептрон

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

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

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:

- Обучаем нейронную сеть на прогнозирование по методу скользящего окна.
- 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.
- 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 $i = 1, n, F$ – нелинейная функция.
- 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 $x'(t+i\tau), i = 1, n$.
- Оцениваем $\ln(d_n) = \ln|x'(t+i\tau) - x(t+i\tau)|, i = 1, n$ и выбираем только точки, где $\ln d < 0$.
- Строим график зависимости $\ln(d_n)$ от n .
- 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:

- Определяется размер элементарного интервала N ; $t=1$ – начальная позиция временного окна;
- Формируется обучающая выборка N точек, начиная с позиции t : $\{x(t), x(t+1), \dots, x(t+N-1)\}$;
- Производится обучение нейронной сети на прогнозирование выбранных данных;
- 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 $i = 0, 1, 2, \dots, \Delta x_{\max}$ – величина, определяющая приемлемую точность прогноза.

- 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 $t=t+i$.
- 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 персептрон (Multilayer Perceptron, MLP). Для обучения многослойного персептрона мы использовали алгоритм обратного распространения ошибки.

Согласно вышеописанному алгоритму произведем сегментацию смешанного ряда, изображенного на рисунке 3. 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.

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 рисунке 4.а при $N = 70$ и на рисунке 4.б при $N = 30$.

Из рисунка 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.

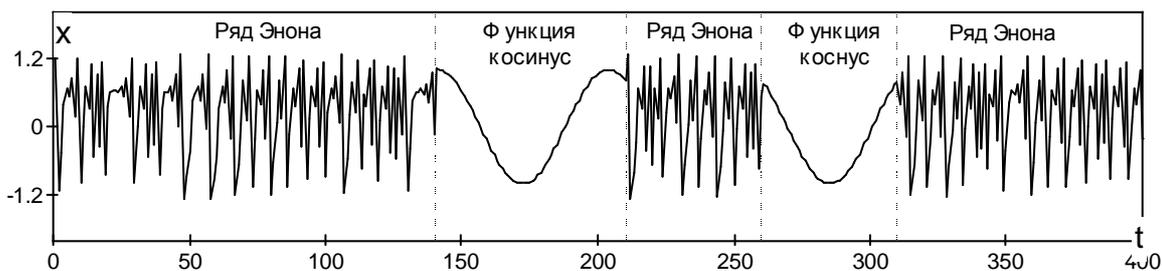


Рис. 3. Смешанный сигнал

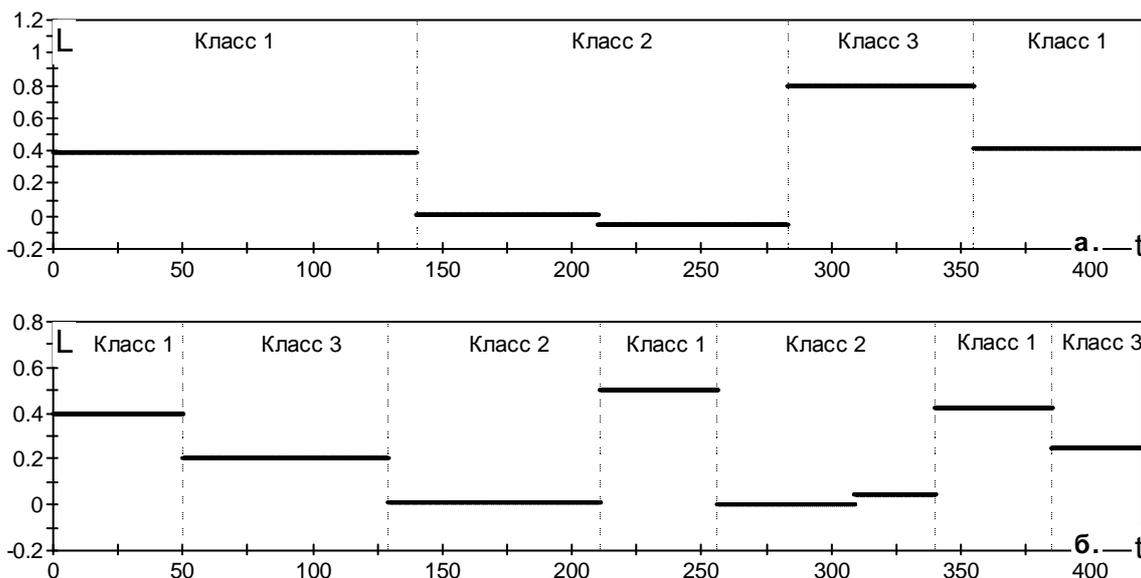


Рис. 4. Адаптивная сегментация при помощи нейронных сетей
а.) при $N = 70$; б.) при $N = 30$; L – значение старшего показателя Ляпунова

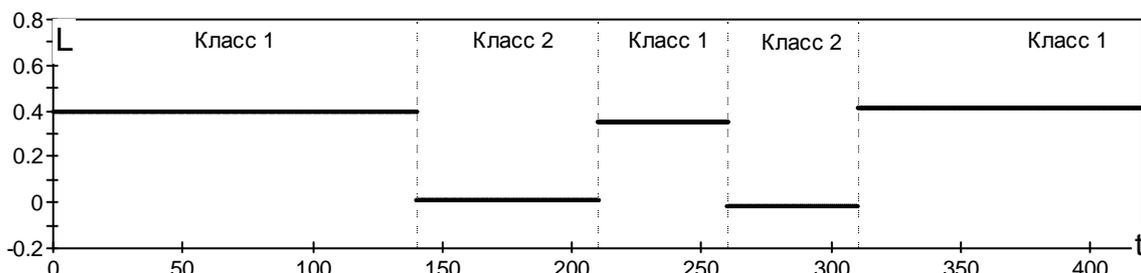


Рис. 5. Сегментация при элементарном отрезке $N = 50$ отсчетов; L – значение старшего показателя Ляпунова

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 рисунке 4, 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 рисунке 2, минимальная длина сегмента составляет 50 отсчетов, тогда результаты расчета, представленные на рисунке 5, гораздо точнее.

Из рисунка 5 видно, что качество идентификации переходов очень высокое: сегментация произведена с точностью до трех отсче-

тов, 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 [11], сведем данные об их длительности в таблицу.

Из таблицы 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.

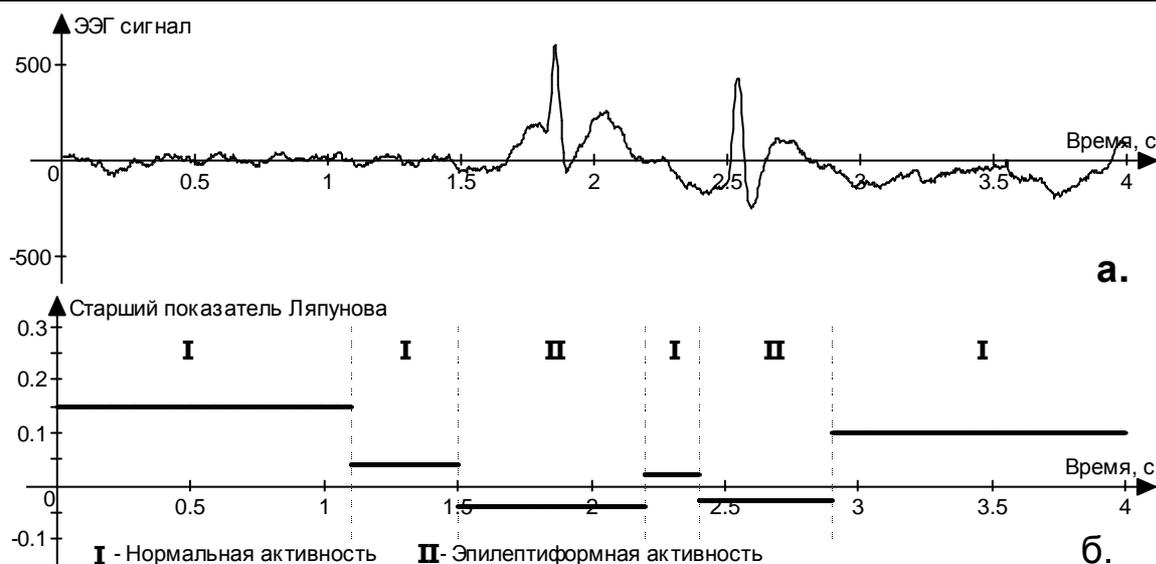


Рис. 6: а.) сигнал ЭЭГ; б.) адаптивная сегментация сигнала ЭЭГ при помощи нейронных сетей

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)

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 [12].

На рисунке 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 рисунка 5 видно, что адаптивная сегментация при помощи нейронных сетей позволила обнаружить все эпилептиформные активности в анализируемом сигнале и определить их длительность.

Применение адаптивной сегментации позволяет решить множество проблем, связанных с обнаружением патологических активностей в сигналах ЭЭГ. Точное определение момента возникновения эпилептиформных активностей даст возможность анализировать сразу набор ЭЭГ сигналов одной регистрации и выявлять области головного мозга, где аномалии регистрируются раньше. Все это позволит создать вспомогательную диагностическую систему.

Выводы

1. Проведен анализ существующих методов сегментирования данных.
2. Предложен нейросетевой подход к сегментации сигналов. Сегменты идентифицируются по уровню хаоса на участке сигнала.
3. Рассмотрен способ решения проблемы выбора временного масштаба при помощи исследования сегментируемых рядов и выделения возможного наименьшего размера сегмента.
4. Адаптивная сегментация на основе нейронных сетей позволяет повысить точность обнаружения эпилептиформной активности в сигнале ЭЭГ, так как применение сегментации предполагает определение длительности соответствующего сегмента.
5. Дальнейшее исследование будет направлено на тестирование данного подхода на реальных данных ЭЭГ и сравнение с результатами, полученными в наших ранних исследованиях.

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. К.Ю. Мухин, А.С. Петрухин, Л.Ю. Глухова. Эпилепсия. Атлас электро-клинической диагностики. – М.: Альварес Паблишинг, 2004. – 440 с.
2. Каплан А.Я. Проблема сегментного описания электроэнцефалограммы человека // Физиология человека, 1999, Том 25, № 1, С. 125-133.
3. Гнездицкий В.В. Обратная задача ЭЭГ и клиническая электроэнцефалография (картирование и локализация источников электрической активности мозга). – М.: МЕДпресс-информ, 2004. – 624 с.
4. 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.
5. 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.
6. Moser H., Weber B., Wieser H. Electroencephalograms in epilepsy: analysis and seizure prediction within the framework of Lyapunov theory. Physiol. D, 1999, - P. 130, 291-305.
7. Головка В.А., Чумерин Н.Ю. Нейросетевые методы определения спектра Ляпунова хаотических процессов // Нейрокомпьютеры: разработка и применение, 2004. – №1.
8. 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.
9. Головка В.А. Нейросетевые методы обработки хаотических процессов // В книге «Лекции по Нейроинформатике». – М.: МИФИ, 2005. – С. 43-88.
10. 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. – P. 202 – 207.
11. Зенкова Л.Р. «Клиническая эпилептология». – Медицинское информационное агентство, 2002, – 416с.
12. Sackellares J.Ch, Iasemidis L.D, Shiau D. Epilepsy when chaos fail. Singapore: Word Scientific, 1990.

Материал поступил в редакцию 13.02.08

Existence methods of the data segmentation are analyzed. The neural network approach for the signals segmentation is proposed. Segments are identified by a level of chaos on an interval of the signal. We consider a solution of the time scaling problem by the initial signals examination and the minimum size estimation of a segment. The segmentation applying calculates a length of segments; therefore the adaptive segmentation based on neural networks allows accuracy of epileptiform activity detection in EEG signal increased.

УДК 681.324

Савицкий Ю.В.

АНАЛИЗ ХАОТИЧЕСКИХ СИГНАЛОВ НА БАЗЕ МНОГОСЛОЙНЫХ НЕЙРОННЫХ СЕТЕЙ С РАЗЛИЧНОЙ КОНФИГУРАЦИЕЙ РЕКУРРЕНТНЫХ СВЯЗЕЙ

Введение. Анализ и исследование хаотических систем сегодня приобретает все большую практическую значимость в самых разных сферах человеческой деятельности, дает ключ к более глубокому пониманию природы динамических систем в технических и естественных науках [1-9]. При этом *нейросетевые методы* анализа хаотических сигналов находят все большее применение в различных областях благодаря ряду преимуществ по сравнению с традиционными методами: возможностью исследования систем, математическая модель которых неизвестна (неизвестны математические соотношения, характеризующие поведение динамической системы); использованием для исследований выборки данных ограниченного объема и соответственно относительно малой вычислительной сложностью алгоритмов [1]. Традиционно данные методы базируются, как правило, на модели многослойного персептрона с сигмоидальными функциями активации скрытых нейронных элементов.

В то же время использование рекуррентных синаптических связей с задержкой сигнала между выходными нейронами сети и нейронами скрытого слоя (модель Джордана), либо нейронами распределительного слоя (модель Элмана), либо связями обоих типов (мультирекуррентная модель Джордана-Элмана) предоставляет дополнительные возможности по улучшению характеристик рассматриваемых методов. Это обусловлено тем, что наличие рекуррентных связей с задержкой сигнала позволяет при обучении и функционировании сети учитывать не только текущие данные, подаваемые на сеть, но и все предыдущие данные и состояния нейронной сети (рис. 1).

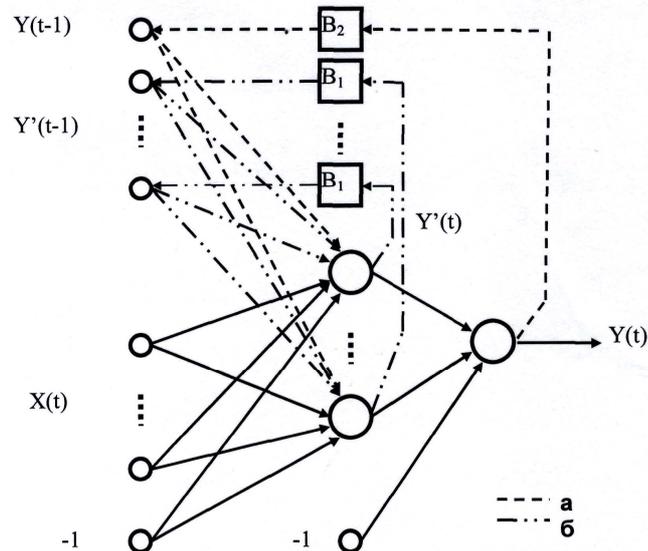


Рис. 1. Варианты архитектур рекуррентной нейронной сети: а) с рекуррентными связями от выходного слоя (сети Джордана); б) с рекуррентными связями от скрытого слоя (сети Элмана); $X(t)$ – вектор входного сигнала временного процесса X ; V_1, V_2 – элементы задержки на 1 такт функционирования сети; $Y'(t-1)$ – сигналы рекуррентных связей от нейронов скрытого слоя; $Y(t-1)$ – сигнал рекуррентной связи от линейного нейрона выходного слоя

Это создает предпосылки к тому, что рекуррентная нейросете-

вая модель в процессе обучения глубже учитывает и обобщает динамические свойства исследуемого процесса и, следовательно, позволит решать задачи анализа и прогнозирования на более высоком уровне качества [10].

Исследование нейросетевых методов расчета старшего показателя Ляпунова на базе рекуррентных нейронных сетей вышеуказанных конфигураций. В качестве базовой архитектуры использована трехслойная нейронная сеть с сигмоидной функцией активации нейронов скрытого слоя и линейной функцией активации выходного нейронного элемента. За основу был взят алгоритм расчета старшего показателя Ляпунова для одного измерения хаотического сигнала, описанный в работе [1]. Суть алгоритма заключается в следующем. После того, как нейронная сеть была обучена на данных выборки до требуемой ошибки, начиная с некоторого измерения сигнала, осуществляется многошаговое прогнозирование по методу скользящего окна; результаты прогнозирования фиксируются. Следующим этапом является внесение в это измерение смещения достаточно малого размера, после чего при помощи нейронной сети заново выполняется многошаговый прогноз. Затем, на основании разницы между нейросетевым прогнозом, полученным на основе оригинальных данных выборки, и прогнозом, рассчитанным с учетом внесенного смещения, рассчитывается старший показатель Ляпунова.

Однако, поскольку вместо многослойного персептрона, который при вычислении текущей выходной активности никак не учитывает свои предыдущие состояния, используется рекуррентная нейронная сеть, то на данном этапе алгоритма внесены следующие изменения: при осуществлении прогнозов на вход нейронной сети должны быть предварительно поданы элементы выборки данных, начиная с первого. Это позволяет к моменту расчета старшего показателя Ляпунова сформировать соответствующее состояние рекуррентной нейронной сети. (Необходимость этого обусловлена тем, что текущее состояние нейронов рекуррентной сети формируется на основе предыдущего их состояния, которое, в свою очередь, было сформировано на основе всех предыдущих состояний).

Для тестирования моделей были использованы данные хаотических процессов Энона и Лоренца с известными параметрами вложения и задержки, а также данные измерений данных EEG (<http://kdd.ics.uci.edu/databases/eeg/>), для которых соответствующие параметры вложения и задержки найдены с использованием пакета Tisean. С целью анализа чувствительности моделей к фрагментам детерминированных сигналов дополнительно были проведены эксперименты по расчету старшего показателя Ляпунова для смешанных сигналов (процессов Энона, Лоренца и данных EEG, в состав которых включены участки детерминированных сигналов). Результаты применения нейронных сетей Джордана и Джордана-Элмана продемонстрировали как достаточно высокую скорость сходимости алгоритма обучения к требуемой ошибке, так и удовлетворительные оценки старшего показателя Ляпунова. Так, для достижения среднеквадратичной ошибки обучения для процесса Энона (объем выборки - 500), равной $E=2 \cdot 10^{-4}$, потребовалось 194 итерации для сети Джордана, 265 – для сети Джордана-Элмана (192 – для многослойного персептрона). Аналогично, для процесса Лоренца (объем выборки - 800) для достижения ошибки $E=9 \cdot 10^{-4}$ выполнено 386 итерации для сети Джордана, 442 – для сети Джордана-Элмана (329 – для многослойного персептрона). С целью расчета старшего показателя Ляпу-

Савицкий Юрий Викторович, кандидат технических наук, доцент кафедры «Интеллектуальные информационные технологии» Брестского государственного технического университета.

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