

**Введение.** Существует ряд направлений исследования характеристик электроэнцефалограмм (ЭЭГ) для обнаружения эпилептической активности. На сегодняшний день уделяется большое внимание применению нелинейных методов обработки, из которых можно выделить применение вейвлет-анализа и применение теории хаоса для исследования ЭЭГ.

Для анализа ЭЭГ данных применяются различные алгоритмы вейвлет-преобразования [1, 2]. Способы применения также довольно многообразны. Вейвлет-преобразование делает возможным получение поддиапазонов сигнала ЭЭГ на подобии альфа, бета и других ритмов. При этом такой алгоритм преобразования не только заменяет Фурье-преобразование, но и решает проблему обработки нестационарных сигналов [2]. Также вейвлет-преобразование позволяет перейти от значений амплитуды к относительной разности амплитуд, частот и других показателей сигнала во времени, тем самым получая новую относительную характеристику сигнала, по которой можно судить о наличии аномалий в сигнале. Например, резкие перепады амплитуды с постоянной частотой могут свидетельствовать о начале эпилептического приступа либо его приближении [1]. 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 [1, 3].

В данной статье рассматривается анализ сигнала электроэнцефалограммы как хаотического ряда. Величиной, которая применима для оценки хаотичности временного ряда, является старший показатель Ляпунова  $L_{\max}$ . Эпилептическая активность имеет малую длительность на ЭЭГ и характеризуется малой выборкой данных, которые ее описывают. В связи с этим некоторым исследователям не удалось обнаружить характерных изменений данного показателя при анализе сигналов ЭЭГ [4]. В [5] рассмотрены различные оценки минимальной длительности фрагмента данных ЭЭГ, которой достаточно для обработки временного ряда. Требование использовать ряд длиной около 100000 отсчетов, что при частоте дискретизации 250 Гц составляет более 6 минут, является недопустимым в задаче обнаружения эпилептической активности, длительность которой на ЭЭГ может быть 20-200 мс [6]. Такое обстоятельство обосновывает необходимость применения таких методов расчета  $L_{\max}$ , которые способны производить вычисления на малых интервалах сигнала. В таком случае возможно применение нейросетевой технологии расчета показателя  $L_{\max}$  [7].

Нейронные сети позволяют анализировать небольшие участки данных [8] и тем самым производить обнаружение эпилептической активности малой длительности. В отличие от существующих методов автоматического обнаружения эпилептической активности, данный подход позволяет учитывать нелинейность сигнала и производить обнаружение патологических активностей разной формы, амплитуды, частоты.

Статья посвящена применению нейросетевых методов для обнаружения эпилептической активности в сигнале ЭЭГ как аномалии в динамической системе. В первом разделе описан нейросетевой алгоритм расчета старшего показателя Ляпунова. Во втором разделе представлена структура нейросетевого модуля, позволяющего ускорить расчет Старшего показателя Ляпунова. Третий раздел посвящен нейросетевому алгоритму для анализа сигнала ЭЭГ, позволяющему обнаруживать пароксизмальную активность по значению старшего показателя Ляпунова.

**1. Расчет старшего показателя Ляпунова.** Существует ряд методов для расчета старшего показателя Ляпунова  $L_{\max}$ , когда известна только эволюция одной координаты системы в виде временного ряда [9, 10]. Основной проблемой здесь является малая длина наблюдаемых ЭЭГ реализаций. Однако при малом объеме исходных данных затруднительно использовать стандартный подход для вычисления старшего показателя Ляпунова. Поэтому для решения данной задачи можно использовать нейросетевую технологию расчета [11], что позволяет использовать малый объем исходных данных для вычисления  $L_{\max}$  и соответственно снизить трудоемкость вычислений.

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 прогнозирующей искусственной нейронной сети (ИНС) [12]. Основной идеей данного метода является вычисление при помощи прогнозирующей ИНС расхождения двух близлежащих траекторий на  $n$  шагов вперед.

Для определения архитектуры сети и порядка выбора данных в обучающую выборку необходимо учитывать, что временная задержка  $\tau$  определяет интервал между отсчетами временного ряда для

$$\begin{aligned}
 \begin{bmatrix} X_1 \\ X_2 \\ \dots \\ X_{N-k} \end{bmatrix} &= \begin{bmatrix} x(t+\tau) & x(t+2\tau) & \dots & x(t+k\tau) \\ x(t+2\tau) & x(t+3\tau) & \dots & x(t+(k+1)\tau) \\ \dots & \dots & \dots & \dots \\ x(t+(N-k)\tau) & x(t+(N-k+1)\tau) & \dots & x(t+(N-1)\tau) \end{bmatrix}, \\
 E &= \begin{bmatrix} E_1 \\ E_2 \\ \dots \\ E_{N-k} \end{bmatrix} = \begin{bmatrix} x(t+(k+1)\tau) \\ x(t+(k+2)\tau) \\ \dots \\ x(t+N\tau) \end{bmatrix}.
 \end{aligned} \tag{1}$$

**Лаврентьева Светлана Владимировна**, старший преподаватель кафедры интеллектуальных информационных технологий Брестского государственного технического университета.

**Головкин Владимир Адамович**, д.т.н., профессор, зав. кафедрой интеллектуальных информационных технологий 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.

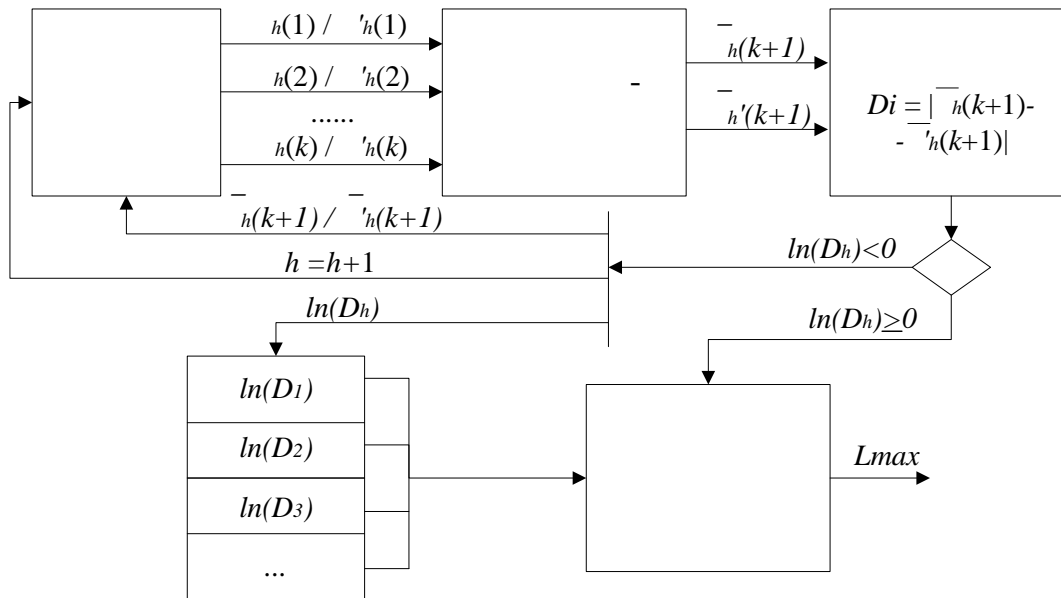


Рис. 1. Схема расчета старшего показателя Ляпунова

достижения наилучшей прогнозируемости данных. Использование временной задержки позволяет оптимальным образом формировать обучающую выборку для прогнозирующей ИНС. По значению размера пространства вложения  $m$  определяется размерность  $k$  входного слоя ИНС для увеличения скорости обучения и повышения качества прогноза.

Рассмотрим фрагмент временного ряда  $x$ , который состоит из  $N$  точек, взятых с учетом задержки  $\tau$ . Элементы фрагмента выбираются начиная с точки  $(t+\tau)$ . В результате фрагмент представляет собой следующий ряд  $\{x(t+\tau), x(t+2\tau), \dots, x(t+N\tau)\}$ . На основании выбранного фрагмента формируется обучающая выборка, состоящая из  $(N - k)$  входных векторов. Каждому вектору  $h$  из обучающей выборки ставится в соответствие эталонное выходное значение  $E_h$ , где  $h = \overline{1, N - k}$ :

Обозначим  $j$ -ый элемент  $h$ -ого вектора из обучающей выборки как  $X_h(j)$ . Обучение нейронной сети прогнозированию в соответствии с методом скользящего окна заключается в поиске наилучшего отображения  $F$  входных значений в выходные:

$$F: X_h \rightarrow E_h. \quad (2)$$

После обучения сети легко осуществить эволюцию двух точек на фазовой траектории системы, используя итерационный подход. Схематично процедура вычисления старшего показателя Ляпунова представлена на рис. 1.

Представленная схема функционирует согласно следующему алгоритму [11, 13]:

а) Дан временной ряд, состоящий из  $N$  точек, выбранных с учетом задержки  $\tau$ . Формируем обучающую выборку согласно (1) и обучаем нейронную сеть на прогнозирование по методу скользящего окна.

б) Выбираем начальный вектор прогнозирования из обучающей выборки (1):

$$h = \{h(1), h(2), \dots, h(k)\} = \{x(t+h\tau), x(t+(h+1)\tau), \dots, x(t+(h+k-1)\tau)\}, \quad (3)$$

где  $k$  – размер окна,  $h$  – любое целое значение из диапазона  $[1, N-k]$ .

в) Определяем вектор  $h'$  с небольшим отклонением  $d_0 \approx 10^{-8}$  от  $h$ :

$$h' = \{h'(1), h'(2), \dots, h'(k)\} = \{h(1), h(2), \dots, h(k) + d_0\}. \quad (4)$$

г) На вход нейронной сети поочередно подаются вектора  $X_h$  и  $X_{h'}$ , в результате на выходе сети получаем значения:

$$\begin{aligned} \overline{X}_h(k+1) &= F(X_h), \\ \overline{X}'_{h'}(k+1) &= F(X'_{h'}). \end{aligned} \quad (5)$$

д) Арбитр оценивает отклонение траектории  $\overline{X}_h$  и  $\overline{X}'_{h'}$ :

$$\ln D_h = \ln |\overline{X}'_{h'}(k+1) - \overline{X}_h(k+1)|. \quad (6)$$

е) Если  $\ln D_h > 0$ , тогда формируются новые вектора  $h_{h+1}$  и  $h'_{h+1}$  для следующего шага прогнозирования:

$$\begin{aligned} X_{h+1} &= \{X_h(2), X_h(3), \dots, X_h(k), \overline{X}_h(k+1)\}, \\ X'_{h+1} &= \{X'_{h'}(2), X'_{h'}(3), \dots, X'_{h'}(k), \overline{X}'_{h'}(k+1)\}. \end{aligned} \quad (7)$$

Увеличивается номер итерации  $h = h+1$  и выполняется переход к пункту г). В противном случае арбитр принимает решение о завершении прогнозирования.

Для полученной зависимости  $\ln D_h$  от  $h\tau$  производится поиск коэффициента  $\alpha$  прямой регрессии согласно методу наименьших квадратов. Старший показатель Ляпунова  $L_{max}$  определяется равным полученному коэффициенту.

## 2. Модификация алгоритма расчета старшего показателя Ляпунова.

Предлагается усовершенствовать алгоритм, рассмотренный в первом разделе данной статьи, для расчета старшего показателя Ляпунова путем модификации перцептрона с одним скрытым слоем на этапе функционирования. Целью модификации является ускорение расчета старшего показателя Ляпунова. После обучения, на этапе функционирования, можно трансформировать ИНС таким образом, что она сразу будет выполнять вычисления в), г) и д) этапов алгоритма, описанного в предыдущем разделе, при этом время выполнения этих этапов сократится. Пусть архитектура ИНС, обучаемой на прогнозирование, состоит из  $k$  входных,  $p$  скрытых и одного выходного нейронов (см. рис. 2).




Рис. 2. Архитектура прогнозирующей ИНС

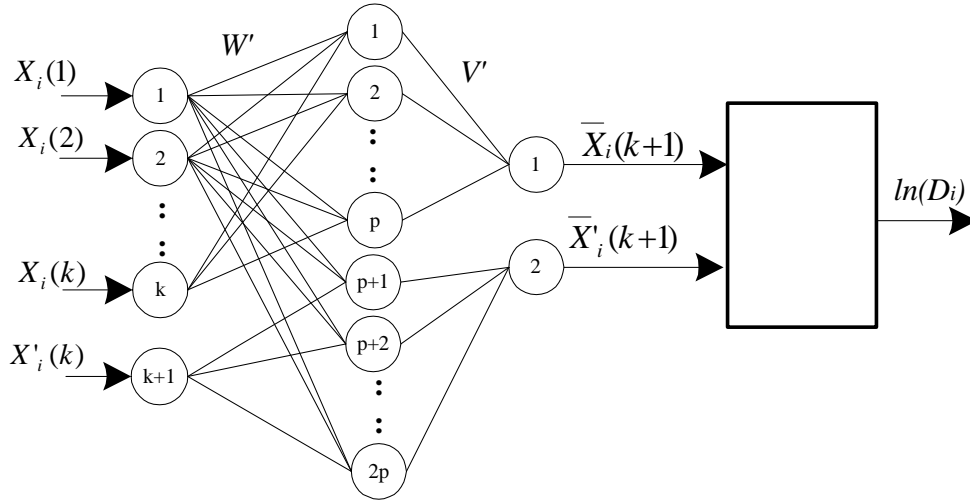


Рис. 3. Структура нейросетевого модуля для расчета старшего показателя Ляпунова

В процессе обучения выполняется настройка весовых коэффициентов  $w_{ij}$  и  $v_j$   $i = \overline{1, k}, j = \overline{1, p}$ . Определим матрицы весовых коэффициентов:

$$W = \begin{bmatrix} w_{11} & w_{12} & \dots & w_{1p} \\ w_{21} & w_{22} & \dots & w_{2p} \\ \dots & \dots & \dots & \dots \\ w_{k1} & w_{k2} & \dots & w_{kp} \end{bmatrix}, V = \begin{bmatrix} v_1 \\ v_2 \\ \dots \\ v_p \end{bmatrix}. \quad (8)$$

Архитектура ИНС на этапе функционирования формируется на основе архитектуры обученной ИНС путем добавления одного нейрона во входной слой, удваиванием нейронов в скрытом и выходном слоях (см. рис. 3).

Весовые коэффициенты рассматриваемой ИНС  $W'$  и  $V'$  формируются на базе матриц весовых коэффициентов  $W$  и  $V$ , путем добавления следующих весов:

$$\begin{aligned} w'_{ij} &= w'_{ip+j} = w_{ij}; \\ w'_{k+1p+j} &= w'_{kj} = w_{kj}; \\ w'_{k+1j} &= w'_{kj+p} = 0; \\ v'_{j1} &= v'_{j+p2} = v_j; \\ v'_{j+p1} &= v_{j2} = 0, \end{aligned} \quad (9)$$

где  $i = \overline{1, k-1}, j = \overline{1, p}$ .

В матричном виде:

$$W' = \begin{bmatrix} w'_{11} & w'_{12} & \dots & w'_{1p} & w'_{1p+1} & \dots & w'_{1,2p} \\ w'_{21} & w'_{22} & \dots & w'_{2p} & w'_{2p+1} & \dots & w'_{2,2p} \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ w'_{k-1,1} & w'_{k-1,2} & \dots & w'_{k-1,p} & w'_{k-1,p+1} & \dots & w'_{k-1,2p} \\ w'_{k1} & w'_{k2} & \dots & w'_{kp} & w'_{k,p+1} & \dots & w'_{k,2p} \\ w'_{k+1,2} & w'_{k+1,2} & \dots & w'_{k+1,p} & w'_{k+1,p+1} & \dots & w'_{k+1,2p} \end{bmatrix} = \begin{bmatrix} w_{11} & w_{12} & \dots & w_{1p} & w_{11} & \dots & w_{1p} \\ w_{21} & w_{22} & \dots & w_{2p} & w_{21} & \dots & w_{2p} \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ w_{k-1,1} & w_{k-1,2} & \dots & w_{k-1,p} & w_{k-1,1} & \dots & w_{k-1,p} \\ w_{k1} & w_{k2} & \dots & w_{kp} & 0 & \dots & 0 \\ 0 & 0 & \dots & 0 & w_{k1} & \dots & w_{kp} \end{bmatrix}; \quad (10)$$

$$V' = \begin{bmatrix} v'_{11} & v'_{12} \\ v'_{21} & v'_{22} \\ \dots & \dots \\ v'_{p1} & v'_{p1} \\ v'_{p+1,1} & v'_{p+1,2} \\ \dots & \dots \\ v'_{2p,1} & v'_{2p,2} \end{bmatrix} = \begin{bmatrix} v_1 & 0 \\ v_2 & 0 \\ \dots & \dots \\ v_p & 0 \\ 0 & v_1 \\ \dots & \dots \\ 0 & v_p \end{bmatrix}. \quad (11)$$

В процессе функционирования на выходе нейронной сети параллельно вычисляются значения точек двух ближайших траекторий, которые необходимы для оценки старшего показателя Ляпунова. Арбитр вычисляет логарифмическую разность и принимает решение о завершении функционирования нейронной сети (см. рис. 3). На основе предложенной модели ИНС алгоритм расчета старшего показателя Ляпунова будет иметь следующий вид:

- а) Дан временной ряд, состоящий из  $N$  точек, выбранных с учетом задержки  $\tau$ . Формируем обучающую выборку согласно (1) и обучаем нейронную сеть на прогнозирование по методу скользящего окна.
- б) Выбираем начальный вектор прогнозирования из обучающей выборки (1):

$$h = \{ h(1), h(2), \dots, h(k), h'(k) \} = \{ x(t+h\tau), x(t+(h+1)\tau), \dots, x(t+(h+k-1)\tau), x(t+(h+k-1)\tau) + d_0 \}, \quad (12)$$

где  $h$  – любое целое значение из диапазона  $[1, N-k]$ ,  $k$  – размер окна,  $d_0 \approx 10^{-8}$  – начальное отклонение траектории  $X'$  от  $X$ .

- в) На вход нейронной сети подается вектор  $h'$ , в результате на выходе сети получаем значения  $\overline{X}_h(k+1), \overline{X}'_h(k+1)$ .

- г) Арбитр оценивает  $\ln D_h$  согласно (6).

- д) Если  $\ln D_h > 0$ , тогда формируется новый вектор  $X'_{h+1}$  для следующего шага прогнозирования:

$$X'_{h+1} = \{ X_h(2), X_h(3), \dots, X_h(k), \overline{X}_h(k+1), \overline{X}'_h(k+1) \}. \quad (13)$$

Увеличивается номер итерации  $h = h+1$  и выполняется переход к пункту в). Иначе арбитр принимает решение о завершении прогнозирования.

- е) Для полученной зависимости  $\ln D_h$  от  $h\tau$  производится поиск коэффициента  $a$  прямой регрессии согласно методу наименьших квадратов. Старший показатель Ляпунова определяется равным полученному коэффициенту  $a$ .

Описанный алгоритм за счет предложенной модели ИНС для расчета старшего показателя Ляпунова позволяет ускорить процедуру вычислений, так как за одну итерацию работы ИНС вычисляется прогноз сразу двух близких траекторий временного ряда. В рас-

смотренном ранее алгоритме для расчета двух близких траекторий требовалось две итерации вычисления нейронной сети. Однако добавление дополнительных нейронных элементов в ИНС приводит к тому, что время расчета сокращается не вдвое, а приблизительно на 10%. Результат ускорения является существенным, так как алгоритм расчета старшего показателя Ляпунова является основой алгоритма анализа сигналов ЭЭГ.

**3. Обнаружение эпилептической активности.** Для обнаружения эпилептической активности предлагается использовать значение старшего показателя Ляпунова  $L_{\max}$ . Значение  $L_{\max}$  будет вычисляться согласно алгоритму, представленному во втором разделе. В качестве прогнозирующей нейронной сети будет применяться модель многослойного персептрона.

Основываясь на том, что наступление эпилептической активности влечет снижение хаоса в сигналах ЭЭГ, составим критерий:

$$\begin{cases} L_{\max} > e, \\ L_{\max} \leq e, \end{cases} \quad ; \quad (14)$$

где  $L_{\max}$  – значение старшего показателя Ляпунова,  $e$  – пороговое значение  $L_{\max}$ , заданное как константа. Определение порогового значения  $e$  будет рассматриваться в третьей главе данной работы.

На основе критерия (14) предлагается следующий алгоритм обнаружения эпилептической активности [14]:

а) Строится модель прогнозирующей ИНС в соответствии с характеристическими величинами входных данных: значение временной задержки  $\tau$  и размер пространства вложения  $m$  [11]. Количество нейронов входного слоя больше либо равно  $m$ . 1.

б) Сигнал ЭЭГ разбивается на последовательные фрагменты длиной  $N$ , при этом  $N$  может быть как фиксированной, так и

переменной величиной. Пусть сформировано  $L$  фрагментов, тогда

для каждого  $l$ -го фрагмента ( $l = \overline{1, L}$ ) выполняется следующее:

в) Из  $l$ -го фрагмента формируется обучающая выборка (1), состоящая из  $N-k$  образов размерностью  $k$ .

г) ИНС обучается и выполняет расчет старшего показателя Ляпунова согласно алгоритму, описанному в разделе 2 данной статьи. При этом значения старшего показателя Ляпунова рассчитываются для каждой точки обучающей выборки, и в результате получается фрагмент детерминированного ряда:

$$L_{\max}(l) = (L_{\max 1}, L_{\max 2}, \dots, L_{\max N}), \quad (15)$$

д) После того, как весь ряд ЭЭГ данных обработан, то результаты расчетов объединяются в общий ряд данных, где каждый элемент является характеристикой степени хаотичности исходного ряда в заданной точке:

$$\begin{aligned} L_{\max}(t) &= \{L_{\max}(1), L_{\max}(2), \dots, L_{\max}(L)\} = \\ &= (L_{\max 1}, L_{\max 2}, \dots, L_{\max NL}), \end{aligned} \quad (16)$$

е) Производится усреднение  $L_{\max}(t)$  в скользящем окне  $r=10$  точек (значение подобрано экспериментально) на основе сглаживающего фильтра, в результате получаем новый ряд  $\overline{L_{\max}}(t)$  элементы которого вычисляются следующим образом:

$$\overline{L_{\max}}_{i+[r/2]} = \frac{L_{\max i} + L_{\max i+1} + \dots + L_{\max i+r-1}}{r}, \quad (17)$$

где  $i = \overline{1, LN - r + 1}$ ,  $r$  – окно, в котором производится усреднение значений.

ж) Эпилептическая активность в сигнале ЭЭГ определяется по сни-

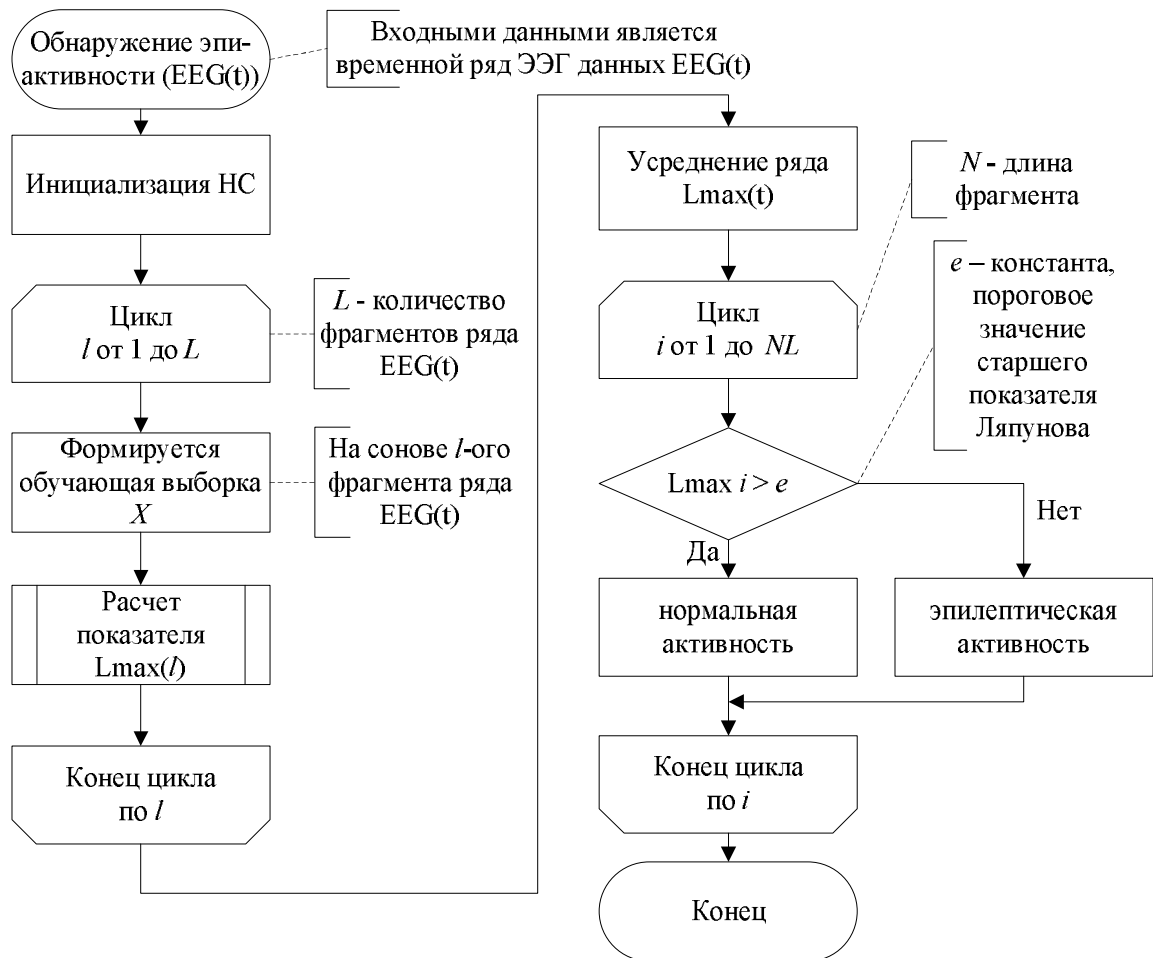


Рис. 4. Схема алгоритма обнаружения эпилептической активности

жению значения  $L_{\max i}$  в ряду  $L_{\max}(t)$  ниже порогового значения старшего показателя Ляпунова  $\epsilon$  согласно критерию (14).

На рис. 4 представлена схема алгоритма обнаружения эпилептической активности.

Усреднение сигнала при помощи сглаживающего фильтра выполняется с целью устранения излишней «скачкообразности» результатов расчета старшего показателя Ляпунова [15]. Используя зависимость  $L_{\max}(t)$ , сложно производить обнаружение аномалий, так как она очень нестабильна. Для уточнения результатов производится усреднение  $L_{\max}(t)$  на  $r$  точек, что позволяет избежать ложного обнаружения патологических признаков, характерных для эпилепсии. В качестве фильтра полученных значений  $L_{\max}(t)$  можно также применить медианную фильтрацию, алгоритм которой описан в разделе 1 данной работы. Однако эксперименты показывают, что медианная фильтрация приводит к снижению вероятности обнаружения одиночных вспышек эпилептической активности [16]. Поэтому предлагается использовать сглаживающий фильтр.

**Заключение.** В статье представлен нейросетевой подход для анализа сигналов электроэнцефалограмм по значению старшего показателя Ляпунова с целью обнаружения эпилептической активности. По результатам проведенных теоретических исследований можно сделать следующие выводы:

1. Разработан алгоритм обнаружения эпилептической активности в сигнале ЭЭГ, который базируется на расчете старшего показателя Ляпунова при помощи нейронной сети. Основной функцией данного алгоритма является классификация в автоматическом режиме фрагментов ЭЭГ данных на два состояния: нормальная и эпилептическая активность. Данный алгоритм позволяет определять как одиночные вспышки активности, так и целый ряд следующих один за другим эпилептических событий.
2. Разработана структура нейросетевого модуля для расчета старшего показателя Ляпунова сигналов ЭЭГ. Модуль состоит из многослойного слабосвязанного перцептрона с одним скрытым слоем и арбитра, что позволяет параллельно осуществить эволюцию двух точек на фазовой траектории и соответственно ускорить на 10% расчет старшего показателя Ляпунова, который применяется для определения степени хаотичности сегментов электроэнцефалограммы.

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

#### СПИСОК ЦИТИРОВАННЫХ ИСТОЧНИКОВ

1. Osorio, I. Real-Time Automated Detection and Quantitative Analysis of Seizures and Short-Time Prediction of Clinical Onset / I. Osorio, M.G. Frei, S.B. Wilkinson // *Epilepsia*. – Philadelphia: Lippincott-Raven, 1998. – Vol. 39. – P. 615–627.
2. Adeli, H. A wavelet-chaos methodology for analysis of EEGs and EEG subbands to detect seizure and epilepsy / H. Adeli, S. Ghosh-Dastidar, N. Dadmehr // *Biomedical Engineering: IEEE Transactions*. – NY: IEEE, 2007. – Vol. 54. – P. 205–211.

3. Нейросетевая технология диагностики патологических состояний по аномалиям электроэнцефалограмм / Л.С. Куравский [и др.] // *Нейрокомпьютеры: разработка и применение*. – М.: Радиотехника, 2007. – № 4. – С. 4–14.
4. Iasemides, D. Chaos theory and epilepsy / D. Iasemides, J.C. Sackellares // *The Neuroscientist*. – US: Sage Publications, 1996. – Vol.2. – P. 118–126.
5. Меклер, А.А. Применение аппарата нелинейного анализа динамических систем для обработки сигналов ЭЭГ / А.А. Меклер // *Актуальные проблемы современной математики: ученые записки*; под ред. Калашникова Е.В. – СПб.: ЛГУ им. А.С. Пушкина, 2004. – Т. 13 (вып. 2). – С. 112–140.
6. Зенкова, Л.П. Клиническая эпилептология / Л.П. Зенкова. – Мн.: Медицинское информационное агентство, 2002. – 416 с.
7. Golovko, V. Modeling Nonlinear Dynamics Using Multilayer Neural Networks / V. Golovko, Y. Savitsky, N. Maniakov // *Intelligent Data Acquisition and Advanced Computing Systems (IDAACS'2001): Proceedings of the International Workshop, July 1–4, 2001, Foros, Ukraine*. – Ternopil: Lileya, 2001. – P. 197–202.
8. Hornik, K. Multilayer feedforward networks are universal approximators / K. Hornik, M. Stinchcombe, H. White // *Neural Networks*. – 1989. – Vol.2. – P. 359–366.
9. Kugiumtzis, D. State Space Reconstruction in the Prediction of Chaotic Time Series with Neural Nets / D. Kugiumtzis // *Norwegian Neural Network Symposium [Electronic resource]: Proceedings*. – 1994. Mode of access: <http://users.auth.gr/dkugiu/PDFs/NNpaper.pdf> – Date of access: 17.11.2009.
10. Liapunov exponents from time series / J.-P. Eckmann [et al.] // *Physical Review A*. – APS, 1986. – Vol. 34(6). – P. 4971–4979.
11. 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.
12. Головки, В.А. Нейросетевые методы обработки хаотических процессов / В.А. Головки // *Лекции по Нейроинформатике*. – М.: МИФИ, 2005. – С. 43–88.
13. 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.
14. Головки, В.А. Нейросетевой подход к детектированию эпилепсии / В.А. Головки, С.В. Безобразова // *Вестник БрГТУ. Серия: Физика, математика, информатика*. – 2005. – № 5(39). – С. 58–61.
15. Golovko, V.A. Neural networks for chaotic signal processing: application to the electroencephalogram analysis for epilepsy detection / V.A. Golovko, S.V. Bezobrazova // *International Conference on Neural Networks and Artificial Intelligence (ICNNAI'2006): Proceedings of the 4th International Conference / BrSTU*. – Brest, 2006. – P. 136–139.
16. Blumenfeld, H. Cellular and Network Mechanisms of Spike-Wave Seizures / H. Blumenfeld // *Epilepsia*. – Malden: Blackwell, 2005. – Vol. 46. – P. 21–33.

11.11.10

#### LAURENTSYEVA S.V., GOLOVKO V.A., EVSTIGNEEV V.V. The neural-net algorithm for an epileptic activity detection

The neural-net approach for seizure detection on the base of the largest Lyapunov's exponent computing is considered. The structure of the neural network module is developed that allows expediting the calculation of the largest Lyapunov's exponent. The neural network algorithm for epileptic activity detection in EEG signals by the largest Lyapunov's exponent is designed.