

В. А. ГОЛОВКО

Брестский государственный технический университет

E-mail: gva@bstu.by

НЕЙРОСЕТЕВЫЕ ТЕХНОЛОГИИ ОБРАБОТКИ ДАННЫХ ДЛЯ ОБНАРУЖЕНИЯ АНОМАЛИЙ В БИОМЕДИЦИНСКИХ СИГНАЛАХ

Аннотация

В данной лекции рассматриваются основные принципы построения нейроинтеллектуальных систем для обнаружения аномалий в биомедицинских данных с целью диагностирования заболеваний. В качестве аномалий здесь рассматриваются нарушения нормальной активности головного мозга, такие как эпилептиформная активность и транзиторные ишемические атаки (ТИА), которые могут привести к катастрофическим последствиям. Для таких процессов большое значение имеет оперативное обнаружение аномалий, чтобы помочь доктору поставить адекватный диагноз и предотвратить катастрофическое развитие ситуации. Задачи оперативного обнаружения эпилептиформной активности и транзиторных ишемических атак являются трудноформализуемыми, для которых невозможно или очень сложно формализовать процесс принятия решений. Основным подходом в медицинских учреждениях для диагностики таких заболеваний является визуальная инспекция электроэнцефалограмм в случае эпилептической активности или нейропсихологическое тестирование в случае ТИА, которые зависят от квалификации врача и очень часто приводят к неадекватному диагнозу. Поэтому эффективным средством для автоматической диагностики таких заболеваний являются нейросетевые методы для обработки биомедицинских данных, которые являются эффективным средством для решения трудноформализуемых задач, позволяют повысить качество диагностирования и соответственно помочь врачу поставить адекватный диагноз.

V. A. GOLOVKO

Brest State Technical University

E-mail: gva@bstu.by

NEURAL NETWORK TECHNIQUES OF DATA PROCESSING FOR ANOMALIES DETECTION IN BIOMEDICAL SIGNALS

Abstract

In this lecture the main principles of neurointelligent systems design for anomalies detection in biomedical data with the purpose of diseases diagnostics have been addressed. The disorders of normal activity of a brain, such as epileptic activity and transient ischemic attacks (TIA) which can lead to catastrophic consequences are considered as an anomalies. On-line anomalies detection in order to assist the doctor in making decision and to prevent catastrophic evolution of a situation is of great importance for such tasks. The problems of on-line detection of epileptic activity and transient ischemic attacks are hard formalizable for which it is very difficult to formalize the making decision process. The basic approach for diagnostics of such diseases in hospital are visual inspection of electroencephalogram (EEG) in a case of epileptic activity or neuropsychological testing in case of TIA. The quality of diagnosis depends on the doctor qualification and very often leads to the misdiagnosis. Therefore the neural network techniques are powerful tool for processing of biomedical data and for automating diagnostics of diseases. The use of neural networks permits to decide hard formalizable problems, to increase the quality of diagnosing and to assist the doctor in making decision accordingly.

Введение

В настоящее время все больше возрастает тенденция проектирования систем искусственного интеллекта на основе нейронных сетей, искусственных иммунных систем, эволюционного программирования и других, биологически инспирированных подходов. Это связано с различными аспектами в развитии искусственного интеллекта. Первый состоит в способности нейроинтеллектуальных систем к обучению и самоорганизации, что позволяет создавать на базе их различные системы, обладающие свойством

адаптации к внешней среде. Второй аспект этой проблемы характеризуется способностью нейроинтеллектуальных систем после обучения обобщать и прогнозировать результаты обучения. Такое обобщение осуществляется путем интеграции частных данных, в результате чего происходит определение закономерностей процесса. Третий аспект заключается в способности таких систем решать трудно-формализуемые задачи, для которых не существует эффективного математического алгоритма. Все это позволяет создавать на базе биологических подходов интеллектуальные системы в различных областях применения. Такие интеллектуальные системы способны к самоорганизации с целью адаптации к внешней среде.

Использование методов искусственного интеллекта широко применяется в медицине. Каждый год в журналах появляется более 500 академических публикаций по применению искусственных нейронных сетей в медицинских приложениях [1]. Согласно публикуемой литературе, искусственные нейронные сети являются эффективным средством для автоматической диагностики заболевания и помогают врачу принять адекватное решение. Медицинская диагностика является сложной задачей, которая зависит от квалификации доктора и поэтому во многих случаях очень субъективна. Поэтому автоматическая система поддержки принятия решений в медицинской диагностике может повысить качество диагностирования и избавить врача от рутинной работы.

В данной лекции рассматриваются основные принципы построения нейроинтеллектуальных систем для обнаружения аномалий в биомедицинских данных с целью диагностирования заболеваний. В качестве аномалий здесь рассматриваются нарушения нормальной активности головного мозга, такие как эпилептиформная активность и транзиторные ишемические атаки (ТИА), которые могут привести к катастрофическим последствиям [2, 3]. Для таких процессов большое значение имеет оперативное обнаружение заболеваний, чтобы помочь доктору поставить адекватный диагноз и предотвратить катастрофическое развитие ситуации. Задачи оперативного обнаружения эпилептиформной активности и транзиторных ишемических атак являются трудноформализуемыми, для которых невозможно или очень сложно формализовать процесс принятия решений. Основным подходом в медицинских учреждениях для диагностики таких заболеваний является визуальная инспекция электроэнцефалограмм в случае эпилептической активности или нейропсихологическое тестирование в случае ТИА, которые зависят от квалификации врача и очень часто приводят к неадекватному диагнозу.

Поэтому эффективным средством для автоматической диагностики таких заболеваний являются нейросетевые методы для обработки биомедицинских данных, которые являются эффективным средством для решения трудноформализуемых задач и, как будет показано ниже, позволяют повысить качество диагностирования и соответственно помочь врачу поставить адекватный диагноз.

Нейросетевые методы обнаружения эпилептической активности

Эпилепсия является распространенным неврологическим заболеванием головного мозга, которое охватывает около 1% человечества [2]. 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 [5]. Распространенным подходом для обнаружения эпилептической активности нейронов головного мозга является анализ сигналов электроэнцефалограмм. Электроэнцефалограмма (EEG) представляет собой запись суммарной электрической активности нейронов головного мозга. Активность нейронов головного мозга при эпилептической активности отличается от нормального состояния, что проявляется в сигналах EEG. Однако обнаружение эпилептической активности в сигналах EEG 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 EEG 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 EEG. Это спектральный анализ на основе преобразования Фурье [6], вейвлет-анализ [7], нелинейный анализ [8–10], нейронные сети [11–15] и различные комбинации этих подходов [16]. Спектральный анализ на основе преобразования Фурье является линейным методом, где EEG-сигнал представляется в виде бесконечной суммы синусоид с различной амплитудой, частотой и фазой. Такое преобразование основывается на предположении, что EEG-сигнал является квази-

стационарным. Однако биоэлектрическая активность нейронов головного мозга характеризуется нелинейной и нестационарной природой, что ограничивает применение преобразования Фурье для анализа EEG-сигналов. Вейвлет-преобразование, в отличие от преобразования Фурье, отображает EEG-сигнал в частотно-временную область и может применяться для анализа нестационарных сигналов. В результате декомпозиции EEG-сигнала при помощи вейвлет-преобразования получаются вейвлет-коэффициенты, которые можно использовать как входной вектор признаков для дальнейшей классификации эпилептической или неэпилептической активности в сигналах EEG. В качестве классификаторов могут использоваться различные нейронные сети.

Распространенным подходом для анализа EEG сигналов является применение двух этапов анализа EEG:

- 1) выделение входных векторов признаков на основе Фурье- или вейвлет-преобразования;
- 2) построение классификатора.

В качестве классификатора может использоваться многослойный перцептрон [11, 12], нейро-нечеткая система [13], обучающийся векторный квантователь [14], машины опорных векторов [15] и т. д. Следует отметить, что качество функционирования классификатора зависит от входного пространства признаков, выделенного на первом этапе обработки EEG.

Исследования EEG-сигналов показали, что они являются нестационарными и хаотическими [9, 10]. Существует разница в динамических свойствах EEG-сигнала в нормальном и эпилептическом состоянии. Эпилептическое состояние характеризуется повышенной активностью отдельных нейронов головного мозга, что приводит к снижению сложности EEG-сигналов. Так «электроэнцефалограммы больных эпилепсией чрезмерно регулярны» [17]. Соответственно значения корреляционной размерности и старшего показателя Ляпунова [4] 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 [13].

Основным недостатком существующих подходов является обучение классификаторов с учителем, что приводит к неавтоматическому анализу EEG-сигналов, так как требует подготовки обучающей выборки с эпилептиче-

скими и нормальными векторами. Следующим недостатком является невозможность точного выделения временных сегментов с эпилептической и нормальной активностью в сигнале EEG.

В данном разделе рассматривается нейроинтеллектуальная система для определения эпилептической активности на основе анализа сигналов электроэнцефалограмм (EEG). Такая система обучается без учителя и позволяет выделять временные сегменты в сигналах EEG с эпилептической и нормальной активностью. Как уже отмечалось, при эпилептической активности происходит снижение старшего показателя Ляпунова в сигнале EEG. 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 EEG путем генерирования двумерной карты результатов диагностирования.

Нейросетевая диагностическая система

В данном разделе описывается нейросетевая диагностическая система для обнаружения эпилептической активности в сигналах EEG. 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 рис. 1 представлена нейросетевая система обнаружения эпилептической активности в сигналах EEG. На вход системы поступает набор сигналов EEG одной регистрации. Эти сигналы описывают динамику нелинейной хаотической системы, которая характеризует электрическую активность нейронов головного мозга. Каждый EEG 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 EEG-сигналов, чтобы отфильтровать их от различного рода артефактов и получить максимально независимые сигналы. Для такой обработки EEG-сигналов используется метод незави-

симых компонент (ICA — Independent Component Analysis) [18], который позволяет выделить независимые сигналы из их смеси. Результатом предобработки являются чистые сигналы EEG, содержащие электрическую активность нейронов головного мозга.



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 EEG.

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

где p — количество временных выделенных сегментов в сигнале EEG. 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 EEG выделяются временные сегменты с эпилептической и нормальной активностью.

Сегментация сигналов EEG

Как уже отмечалось, сегментация представляет собой разбиение каждого сигнала EEG 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 EEG-сигнал представляет собой хаотическую динамическую систему. Для максимальной предсказуемости хаотического процесса необходимо вначале осуществить псевдофазовую реконструкцию одномерных EEG сигналов [21]. *Псевдофазовая реконструкция* — это отображение, которое точке $x(t)$ временного ряда ставит в соответствие точку $(x(t), x(t + \tau), \dots, x(t + (m - 1)\tau)) \in \mathbb{R}^m$, где t — дискретное время ($t = ((m - 1)\tau + 1), N$), τ — временная задержка (в дискретах времени) и m — размерность пространства вложения.

Такенс [19] показал, что, используя только одну координату динамической системы можно реконструировать исходный аттрактор в пространстве точек с задержками $(x(t), x(t + \tau), \dots, x(t + (m - 1)\tau))$ 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 $m \geq [d + 1]$.

Таким образом, для прогнозирования EEG сигнала необходимо определить параметры вложения динамической системы, а именно подходящую временную задержку сигнала τ [4, 21–25] и размерность m [4, 21–25] 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 (рис. 2). Размерность пространства вложения сигналов EEG вычислялась при помощи метода ложных ближайших соседей. Эксперименты показали, что размерность пространства вложения EEG-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 EEG-сигнала на небольшие квазистационарные интервалы. Качество сегментации зависит от выбранной начальной длины сегментов. Известно, что промежуток времени, течение которого спектральные свойства EEG-сигнала могут рассматриваться как постоянные больше четырех секунд [20]. 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 с.

Затем выбирается первый сегмент сигнала EEG длиной 70 отсчетов и происходит обучение многослойного персептрона прогнозированию отсче-

тов данного сегмента в соответствии с методом скользящего окна:

$$x(t+i\tau) = F(x(t+(i-1)\tau), x(t+(i-2)\tau), \dots, x(t+(i-k)\tau)), i = \overline{k, n}. \quad (3)$$

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 получаются 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 $i = t+N, t+N+1, \dots$; здесь $\Delta x_{\max} = 0.1$ — 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 EEG разбивается на квазистационарные сегменты и для каждого сегмента формируется свой многослойный перцептрон, обученный на прогнозирование отсчетов соответствующего сегмента.

Расчет оценки старшего показателя Ляпунова

Старший показатель Ляпунова характеризует среднюю скорость экспоненциального разбегания двух близко лежащих траекторий [4, 21–27]. 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 учетом этих замечаний можно определить старший показатель Ляпунова соотношением:

$$\lambda = \underset{x(t_0) \in A}{E} \left\{ \lim_{\Delta t \rightarrow \infty} \frac{1}{\Delta t} \ln \frac{d(t)}{d(t_0)} \right\}, \quad (6)$$

$d(t) < \text{diam} A$

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 [4]. Он основывается на теореме Такенса [19] и алгоритме Бенеттина [21]. 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 [4]. 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.Оселедца [21], которая утверждает, что экспоненциальное расхождение двух случайно выбранных точек на аттракторе с единичной вероятностью характеризует старший показатель Ляпунова.

В работах [21, 22, 25–27] 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. Схематично процедура вычисления старшего показателя Ляпунова представлена на рис. 3.

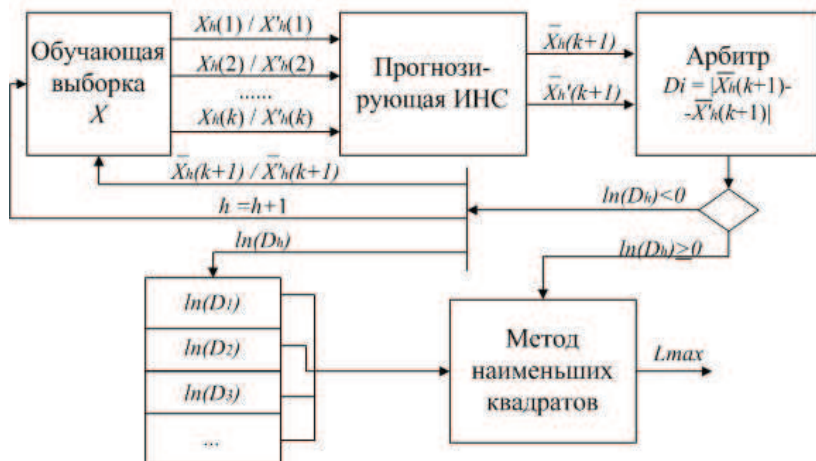


Рис. 3. Схема расчета старшего показателя Ляпунова

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 [21] 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 EEG 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 EEG 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 мно-

гошаговый прогноз:

$$x(t+i\tau) = F(x(t+(i-1)\tau), x(t+(i-2)\tau), \dots, x(t+(i-k)\tau)), \quad (7)$$

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 $\ln d < 0$.
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 EEG используются обученные нейронные сети, полученные на этапе сегментации. В результате получается набор сегментов для каждого сигнала EEG с соответствующими значениями старшего показателя Ляпунова. Если разные сегменты имеют одинаковые значения старшего показателя Ляпунова, то они объединяются в один сегмент.

Эксперименты

Рассмотрим результаты экспериментов по тестированию разработанной диагностической системы. В качестве исходных данных использовались как стандартные EEG данные, взятые из департамента эпилептологии Боннского университета [28] и данные, полученные из 5-й клинической больницы г. Минска.

Первый набор данных представляет собой очищенные от артефактов данные, которые состоят из множеств (А-Е) EEG сигналов [26]. Каждое множество состоит из 100 сигналов, и каждый сигнал содержит 4096 отсчетов продолжительностью 23,6 секунды. Множества А и В состоят из

EEG сигналов, полученных от здоровых пациентов с открытыми глазами (множество А) и закрытыми глазами (множество В) соответственно. Множества С and D включают EEG фрагменты больных эпилепсией во время отсутствия эпилептического состояния. Множество С состоит из EEG фрагментов, полученных из эпилептической зоны, а множество D состоит из фрагментов, полученных из противоположного полушария головного мозга. Множество Е содержит EEG фрагменты с эпилептической активностью. На рис. 4 представлены результаты экспериментов.




Рис. 4. Анализ EEG 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). **(с)** Пять сегментов с эпилептической активностью выделено (серый цвет) в фрагменте Е.

Как видно из рис. 4, 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 табл. 1 представлены общие результаты экспериментов для всех множеств. Интересно, что в множестве С, которое состоит из EEG сигналов, полученных с эпилептической зоны каждый раз выделялся один сегмент с эпилептической активностью (табл. 1; 6% обнаружения эпилептической активности). Следует отметить, что для множеств С и D, система

ТАБЛИЦА 1. Результаты классификации

Set	Класс 1: эпилептическая активность	Класс 2: нормальная активность
A	0 %	100 %
B	0 %	100 %
C	6 %	94 %
D	32 %	68 %
E	92 %	8 %

обнаруживает эпилептические события. Возможно, это происходит из-за скрытых эпилептических процессов. Если не брать в расчет множества C и D, то общая точность классификации составляет 97.7%, что соответствует лучшим результатам, полученных при анализе данных сигналов EEG.

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

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

В результате было получено 336 сигналов EEG. Каждый EEG 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 EEG одной регистрации разбиваются на наборы данных по три сигнала в каждом и подаются на 6 модулей ICA, как показано на рис. 6.

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

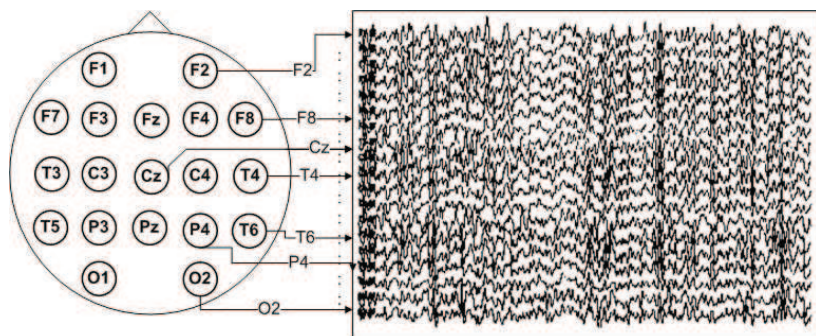


Рис. 5. Пример регистрации электроэнцефалограммы

Для оценки качества обнаружения эпилептической активности воспользуемся следующими характеристиками:

1. *FP (false positives)* — количество сегментов с нормальным состоянием, классифицированных как эпилептические. Они характеризуют ложные срабатывания.
2. *FN (false negatives)* — количество сегментов с эпилептической активностью, классифицированных как нормальные. Они характеризуют необнаружение эпилептической активности.
3. *TP (true positives)* — количество правильно классифицированных эпилептических сегментов.
4. *TN (true negatives)* — количество правильно классифицированных неэпилептических сегментов.

Тогда параметры, характеризующие качество классификации определяются следующим образом:

1. *ACC (accuracy)* — точность классификации, характеризующая качество работы системы в целом:

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} = \frac{TP + TN}{P + N}, \quad (8)$$

2. *TPR (true positive rate)* — чувствительность, вероятность правильной классификации сегментов с эпилептической активностью:

$$TPR = \frac{TP}{TP + FN} = \frac{TP}{P}, \quad (9)$$

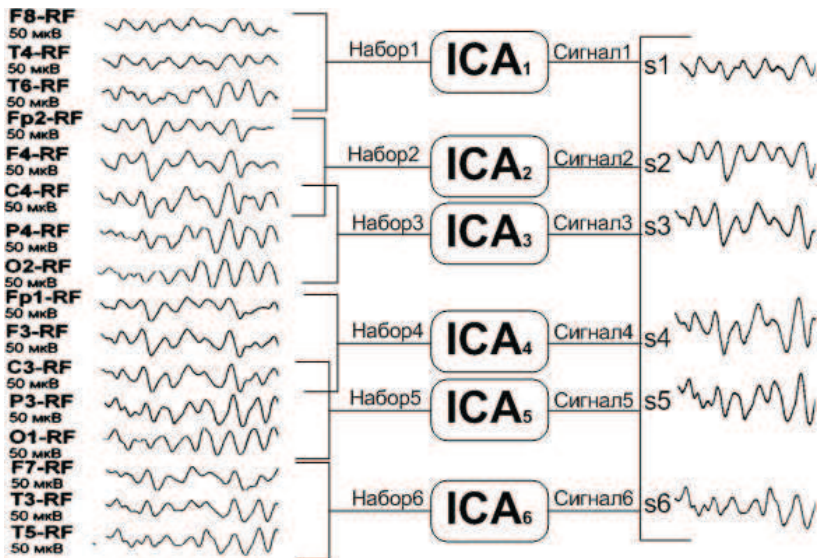


Рис. 6. Формирование шести наборов сигналов для ICA на основе одной регистрации EEG

3. *FNR (false negative rate)* – *ошибка первого рода*, характеризующая вероятность неправильной классификации сегментов с эпилептической активностью:

$$\alpha = FNR = 1 - TPR = \frac{FN}{P}, \quad (10)$$

4. *TNR (true negative rate)* – *специфичность*, характеризующая вероятность правильной классификации сегментов с неэпилептической активностью:

$$TNR = \frac{TN}{FP + TN} = \frac{TN}{N}, \quad (11)$$

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

$$\beta = FPR = \frac{FP}{TN + FP} = \frac{FP}{N}.$$

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

Таблица 3. Значения статистических параметров

Статистические параметры	Значения
Специфичность	99.7 %
Чувствительность	90.6 %
Общая точность классификации	99.6 %

Результаты обнаружения эпилептической активности в сигналах EEG приведены в табл. 2.

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

Как следует из табл. 3, ошибка второго рода $\beta = 0.3\%$, что характеризует очень малое значение ложных срабатываний. На рис. 7 изображен пример обнаружения эпилептической активности в виде вспышки в височной области правого полушария головного мозга для одной регистрации. На рис. 8 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 EEG 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 EEG временные сегменты с эпилептической и нормальной активностью.



Рис. 7. Обнаружение эпилептической активности в виде одной вспышки в височной области правого полушария головного мозга

Нейросетевые методы диагностики транзиторных ишемических атак

Основным подходом в медицинских учреждениях для первичной диагностики транзиторных ишемических атак (ТИА) является визуальная инспекция и нейропсихологическое тестирование, которые зависят от квалификации врача и очень часто приводят к неадекватному диагнозу. Так, например, диагностика транзиторных ишемических атак (ТИА) врачами первой помощи является корректной лишь в 30% случаев [29].




Рис. 8. Обнаружение вспышки эпилептической активности по всем зонам правого полушария головного мозга

Поэтому действенным средством для предварительной диагностики таких заболеваний являются нейросетевые методы, которые являются эффективным средством для решения трудноформализуемых задач, позволяют повысить качество диагностирования и соответственно помочь врачу поставить адекватный диагноз.

В настоящее время существует множество подходов для предварительной диагностики ТИА: нейрорепсихологическое тестирование (neuropsychological testing), статистические подходы, методы искусственного интеллекта [30–35]. В настоящее время нейрорепсихологическое тестирование часто используется для предварительной диагностики ТИА. Параметрами для диагностики являются тестирование речи (внезапное затруднение понимания речи), соматическая чувствительность, вегетативные нарушения (внезапное появление односторонней слабости мускулатуры лица или конечно-

стей) и т. д. Основным недостатком такого подхода является зависимость от квалификации врача и низкая точность первичной диагностики. Статистические подходы требуют наличия больших баз данных, что нередко является большим препятствием на пути создания системы диагностики. Один из статистических подходов для диагностики транзиторных ишемических атак описан в [29]. Авторы применили многомерную логистическую регрессию, используя ROC (receiver operating characteristic curves) анализ, для создания клинической системы диагностирования ТИА. Для этого была использована база данных из West Glasgow Stroke Registry, которая содержала информацию приблизительно о 225 000 пациентах. После регрессионного анализа были выделены 9 переменных с соответствующими коэффициентами регрессии: возраст, головные боли, двоение в глазах, обмороки, приступы, речевые нарушения, односторонняя слабость в конечностях, изменения на лице, история ТИА. Для вычисления критерия ТИА значения всех коэффициенты регрессии суммируются. При использовании ROC кривых ТИА идентифицировалась, если значение критерия превышало 6.1. Такая система правильно идентифицировала 85% пациентов с цереброваскулярными отклонениями и 54% с нецереброваскулярными. Основным недостатком такого подхода является необходимость иметь большую базу данных.

Нейронные сети в задаче диагностики ишемических заболеваний описываются в [33]. Предлагаемые модели были разработаны для быстрой диагностики ТИА в соответствии со следующими выходными значениями: нормальное состояние, ТИА в левой сонной артерии, правой сонной артерии и др. Исходными данными являлись анкеты пациентов, в 6 секциях которых содержались следующая информация: потеря или изменение речи, потеря зрения, зрительные двоения, нечувствительность или дрожь, паралич или слабость, головокружения или потеря равновесия. Каждый входной образ состоял из цифр 0 или 1 из анкеты. Для каждой секции анкеты использовался многослойный персептрон. Так, например, сеть для зрительных двоений состояла из 4 входных и 5 выходных нейронов. Три выхода соответствовали случаю «нет события» и оставшиеся два — удар (stroke) или ТИА.

В [34, 35] описывается пример применения генетического алгоритма для отбора признаков-предикторов с наиболее выраженным дифференциально-диагностическим потенциалом и последующей классификацией с помощью многослойного персептрона для прогнозирования тромбо-эмболических ударов. Архитектура нейронной сети состоит из 20 входных ней-

ронов, 10 скрытых и 10 выходных нейронов. В качестве входных данных были использованы следующие параметры: гипертония, диабет, миокардия, холестерин в крови и др. Выходные нейроны отображают различные категории заболеваний: ТИА, левая гемиплегия, афазия, правая гемипарезия, дисфагия и квадролегия. Точность прогнозирования составляет 78.52% на обучающей выборке и 90.61% — на тестовом множестве.

Рассмотренные выше подходы отличаются друг от друга используемыми входными и выходными данными, а также базами данных пациентов. Поэтому трудно сравнивать эффективность различных подходов. В следующих разделах рассматривается нейросетевая диагностическая система для предварительной диагностики ТИА. Эффективность предлагаемой нейросетевой системы для диагностики транзиторных ишемических атак иллюстрируется результатами экспериментов.

Транзиторные ишемические атаки

Транзиторно-ишемическая атака (ТИА) на нормальное кровоснабжение головного мозга — это самостоятельная гетерогенная нозологическая единица, которая характеризует преинсультное состояние [36]. Основная задача состоит в раннем обнаружении ТИА, для того чтобы предупредить последующие серьезные нарушения мозгового кровообращения. В общем случае транзиторно-ишемические атаки можно разделить на три подтипа ТИА и класс НОРМА:

- 1) атеротромботический подтип (СубТИА1),
- 2) кардиоэмболический подтип (СубТИА2),
- 3) гипертензивный подтип (СубТИА3),
- 4) норма (НОРМА).

После эпизода ТИА риск развития инсульта существенно возрастает. Так, например, у 4–5% пациентов инсульт развивается в течение 2 дней, а у 11% — в течение 7 дней после эпизода ТИА. Поэтому пациенты после ТИА должны детально обследоваться в самые кратчайшие сроки (в течение 24 часов), чтобы предотвратить дальнейшее негативное развитие болезни, которое может привести к острому инсульту.

Таким образом, своевременное выявление ТИА позволяет предотвратить сложные и часто необратимые последствия заболевания.

Исходные данные для диагностики

Входные данные для обучения и тестирования нейронных сетей были предоставлены 5-й городской клинической больницей г. Минска. Они представляют собой набор из 38 медицинских показателей для 114 пациентов, у которых имелись симптомы ТИА. Таким образом, в качестве входных данных используется 38-мерный вектор, который характеризует исходные данные (признаки и симптомы) пациента, такие как возраст, хронический бронхит, диастолическое давление и т. д. [36]. В качестве выходных данных используется 4-мерный вектор, где 4 — это количество классов ТИА плюс нормальное состояние.

Эти показатели и величины их градаций представлены в табл. 4. Исходное множество данных содержало 28 образов первого подтипа (ТИА1), 25 образов второго подтипа (ТИА2), 27 образов третьего подтипа (ТИА3) и 34 образа нормального состояния (без ТИА).

Собранные данные о пациентах с различными заболеваниями ТИА образуют обучающую выборку для диагностической нейросетевой системы.

Нейросетевая диагностическая система

Рассмотрим нейросетевую систему распознавания транзиторных ишемических атак. Данная система основывается на двух различных нейронных сетях. В качестве входного вектора выступают описанные выше 38 параметров, содержащие данные о пациенте. Выходными данными нейросетевой системы является 4-мерный вектор, где 3 выхода соответствуют подтипам ТИА и один — нормальному состоянию. Обработка входных данных осуществляется в 2 этапа. Первый этап соответствует выделению наиболее информативных признаков (feature selection). Один из наиболее важных вопросов, касающихся входных данных, является следующий: какие входные параметры действительно полезны и оказывают наибольшее влияние на результат диагностики? Часто, в аналогичных системах для выделения наиболее информативных признаков используется генетический алгоритм [34]. В данной работе для выделения наиболее значимой информации из исходных данных и уменьшения размерности входных данных предлагается использовать нелинейный метод главных компонент (NPCA), с помощью которого входные 38-мерные векторы преобразуются в 12-мерные выходные векторы.

На втором этапе обработки данных производится классификация ТИА.

ТАБЛИЦА 4. Структура исходных данных

№	Наименование параметра	Величина градаций
1	Возраст	6
2	Пол	2
3	Место жительства	5
4	Образование	4
5	Профессия	4
6	Конфликты на работе	3
7	Смена места жительства за послед. 10 лет	5
8	Смена профессии за послед. 10 лет	7
9	Особенности ночного сна	4
10	Бессонница	3
11	Наследствен. по патологии сосудов мозга	3
12	Наследственность по другим заболеваниям	3
13	Артериальная гипертензия	4
14	Диастолическое давление	3
15	Аускультация сердца	5
16	Границы сердца	3
17	Изменения на ЭКГ	3
18	Боли в области сердца	4
19	Нарушения сердечного ритма	4
20	Хронический бронхит	3
21	Хронический гепатохолецистит	3
22	Хрон. гастрит, язв. болезнь желудка	4
23	Почечнокаменная болезнь	3
24	Остеохондроз шейный	4
25	Метеозависимость	5
26	Употребление алкоголя	3
27	Курение (количество)	3
28	Курение (возраст)	4
29	Работоспособность	3
30	Раздражительность повышенная	3
31	Снижение памяти (степень)	3
32	Снижение памяти (время появления)	3
33	Снижение остроты зрения (степень)	3
34	Снижение остроты зрения (время появления)	4
35	Зрительные нарушения	3
36	Головные боли	4
37	Головные боли (время появления)	4
38	Головокружение	4

Сжатые на предыдущем шаге данные, содержащие наиболее важную информацию из входного множества, используются как входная информация на втором этапе обработки информации. Для классификации ТИА используется многослойный персептрон (MLP). Многослойный персептрон обрабатывает сжатое пространство образов для определения класса ТИА или нормального состояния. Выходной слой включает 4 нейрона: 3 для каждого класса патологии и один для нормального состояния.

Таким образом, нейросетевая диагностическая система состоит из двух нейронных сетей: одна для реализации нелинейного метода главных компонент (для этих целей используется рециркуляционная нейронная сеть, RNN), вторая представляет собой многослойный персептрон (рис. 9).




Рис. 9. Обнаружение вспышки эпилептической активности по всем зонам правого полушария головного мозга

Перед подачей данных на вход NPCA они преобразуются в соответствии со следующими выражениями:

$$x_i^k = \frac{x_i^k - \mu(x_i)}{\sigma(x_i^k)}, \tag{12}$$

$$\mu(x_i) = \frac{1}{L} \sum_{k=1}^L x_i^k, \tag{13}$$

$$\sigma(x_i^k) = \frac{1}{L} \sum_{k=1}^L (x_i^k - \mu(x_i))^2, \tag{14}$$

где L – размерность обучающей выборки.

После обучения нейросетевая система способна распознавать транзиторные ишемические атаки на образах, не входивших в обучающую выборку.

Нелинейная рециркуляционная нейронная сеть

Рассмотрим нелинейную рециркуляционную нейронную сеть (RNN), которая является аналогом нелинейного метода главных компонент (рис. 10). Она представляет собой трехслойный персептрон, который осуществляет нелинейное сжатие данных. Как видно из рисунка нейронные элементы распределены по трем слоям. Скрытый слой осуществляет сжатие входных данных.




Рис. 10. Рециркуляционная нейронная сеть

При использовании метода главных компонент возникает вопрос, какое наименьшее число компонент выбрать, сохранив при этом максимум информативности. Для определения необходимого количества главных компонент используем эмпирический метод на основе критерия информативности:

$$I = \frac{\lambda_1 + \lambda_2 + \dots + \lambda_p}{\lambda_1 + \lambda_2 + \dots + \lambda_n} = \frac{\sum_{i=1}^p \lambda_i}{\sum_{i=1}^n \lambda_i}, \quad (15)$$

где n — размерность входного вектора, λ_i — собственные значения главных компонент, которые равняются их дисперсии.

Построив график зависимости информативности от числа главных компонент, можно определить подходящее количество главных компонент (рис. 11).

Как следует из рисунка количество главных компонент, необходимых для достаточной информативности сжатых данных равняется 12.




Рис. 11. График зависимости информативности от числа главных компонент

Рассмотрим зависимость выходных значений от входных данных для рециркуляционной нейронной сети. Значение j -го элемента скрытого слоя определяется в соответствии со следующим выражениями:

$$y_j = F(S_j), \quad (16)$$

$$S_j = \sum_{i=1}^{41} w_{ij} \cdot x_i, \quad (17)$$

где F — функция активации; S_j — взвешенная сумма j -го нейрона; w_{ij} — весовой коэффициент между i -м нейроном входного и j -м нейроном скрытого слоя; x_i — i -й входной элемент.

Значения нейронных элементов выходного слоя определяются следующим образом:

$$\bar{x}_i = F(S_i), \quad (18)$$

$$S_i = \sum_{j=1}^{12} w'_{ji} \cdot y_j, \quad (19)$$

где w_{ij} — весовой коэффициент между j -м нейроном скрытого и i -м нейроном выходного слоя; \bar{x}_i — i -й выходной элемент.

Для обучения нелинейной RNN использовался алгоритм обратного распространения ошибки с процедурой ортогонализации Грамма-Шмидта. В соответствии с ним весовые коэффициенты модифицируются по следующим выражениям:

$$w_{ij}(t+1) = w_{ij}(t) - \alpha \cdot \gamma_j \cdot F'(S_j) \cdot x_i, \quad (20)$$

$$w'_{ji}(t+1) = w'_{ji}(t) - \alpha \cdot (\bar{x}_i - x_i) \cdot F'(S_i) \cdot y_j, \quad (21)$$

где γ_j — ошибка j -го скрытого элемента:

$$\gamma_j = \sum_{i=1}^{38} (\bar{x}_i - x_i) \cdot F'(S_i) \cdot w'_{ji} \quad (22)$$

и $F'(S_j)$ — производная нелинейной функции активации по взвешенной сумме.

Весовые коэффициенты в скрытом слое ортонормируются в соответствии с процедурой Грамма-Шмидта:

1. Первый вектор вычисляется как:

$$w'_1 = \left[\frac{w_{11}}{|w_1|}, \frac{w_{21}}{|w_1|}, \dots, \frac{w_{n1}}{|w_1|} \right], \quad (23)$$

где

$$|w_1| = \sqrt{w_{11}^2 + w_{21}^2 + \dots + w_{n1}^2}. \quad (24)$$

2. Следующий весовой вектор определяется по следующим рекуррентным формулам:

$$w_i = w_i - \sum_{j=1}^{i-1} (w_i^T \cdot w'_j) \cdot w'_j, \quad (25)$$

$$|w_i| = \sqrt{w_{1i}^2 + w_{2i}^2 + \dots + w_{ni}^2}, \quad (26)$$

$$w'_i = \left[\frac{w_{1i}}{|w_i|}, \frac{w_{2i}}{|w_i|}, \dots, \frac{w_{ni}}{|w_i|} \right], \quad i = 2, \dots, 12. \quad (27)$$

После обучения нелинейная рециркуляционная нейронная сеть способна осуществить ортогональное сжатие входного множества данных.

Многослойный персептрон

Как уже упоминалось выше, архитектура нейронной сети для распознавания ТИА, используемая в данной лекции, представляет собой многослойный персептрон с 12 входными нейронами, 5 скрытыми и 4 выходными нейронными элементами. В качестве функции активации для каждого элемента скрытого и выходного слоя использовалась сигмоидная функция. Число входных элементов соответствует размерности сжатых данных, а число выходных нейронов соответствует числу классов ТИА и нормальному состоянию. Количество элементов в скрытом слое определялось экспериментальным путем. Для обучения многослойного персептрона использовался алгоритм обратного распространения ошибки. Выходными значениями многослойного персептрона являются числа в диапазоне от 0 до 1, которые характеризуют *вероятность развития соответствующего класса ТИА*.

Результаты экспериментов

Рассмотрим отображение входного пространства образов на плоскость двух первых главных компонент. На рис. 12 графически представлена классификационная картина разделения клинических случаев по подтипам ТИА с применением нелинейной RNN. Из рисунка видно, что данные, принадлежащие разным типам атак, распределены по разным областям.

Отображение входного пространства образов для нормального состояния и транзиторных ишемических атак в трехмерном пространстве показано на рис. 13.

Все пространство исходных образов было разделено на 2 группы: обучающую и тестовую выборки. Точность распознавания составляет до 100% на обучающей выборке и 78% на тестовых образах (табл. 5). Распределение вероятностей в зависимости от типа атаки для 10 пациентов, которые не входили в обучающую выборку, представлены в табл. 6.

ТАБЛИЦА 5. Точность распознавания

Число образов в обучающей выборке	Число образов в тестовой выборке	Точность распознавания на обучающей выборке	Точность распознавания на тестовой выборке
90	24	100%	78%

ТАБЛИЦА 6. Распределение вероятностей

Пациент	ТИА 1	ТИА 2	ТИА 3	Норма
1	18.1%	0.1%	13.6%	68.2%
2	6.4%	0%	93.6%	0%
3	5.1%	12.1%	64.5%	18.3%
4	3.6%	72.6%	23.8%	0%
5	1.1%	96.0%	2.8%	0.1%
6	94.4%	0.6%	4.2%	0.8%
7	9.6%	16.8%	0.1%	73.4%
8	15.2%	1.6%	1.5%	81.7%
9	20.8%	10.0%	0%	69.2%
10	8.7%	0.4%	24.1%	66.7%




Рис. 12. Данные обработанные нелинейной RNN

Значительное расхождение точности распознавания на двух выборках (обучающей и тестовой), получается, из-за того, что объем обучающей выборки является недостаточным для качественного обучения нейросетевой системы. Поэтому возникает дилемма, как при малом объеме обучающей выборки обучить нейросетевую систему качественной классификации транзиторных ишемических атак. Для этого необходимо искусственно генерировать новые образы в обучающую выборку для увеличения ее размерности. Предлагается следующий алгоритм для увеличения размерности обучающей выборки:

1. Рециркуляционная нейронная сеть обучается на исходных образах.
2. В наименее информативную составляющую полученного в скрытом слое сжатого вектора (12-я компонента) вносится случайная погрешность в пределах 30%.
3. После внесения погрешности производится восстановление соответствующих образов.
4. Новые образы сопоставляются с одним из классов ТИА при помощи обученного на исходных данных многослойного персептрона. При этом сгенерированные образы, которые не имеют четкой принадлеж-




Рис. 13. Данные обработанные нелинейной RNN

ности к какому-либо классу, удаляются.

5. Затем сгенерированные образы помещаются в обучающую выборку, а исходные данные — в тестовую.
6. Нейронные сети обучаются на сгенерированных образах и проверяются на исходном множестве (тестовом множестве).

Схематично данная процедура изображена на рис. 14.

При помощи данной процедуры было сгенерировано 1000 новых образов, которые относятся к различным типам ТИА. Результаты тестирования системы с использованием сгенерированных образов представлены в табл. 7.

Как следует из таблицы, точность распознавания транзиторных ишемических атак значительно возросла. Разработанная система диагностики позволяет осуществлять предварительный анализ состояния пациента, ба-

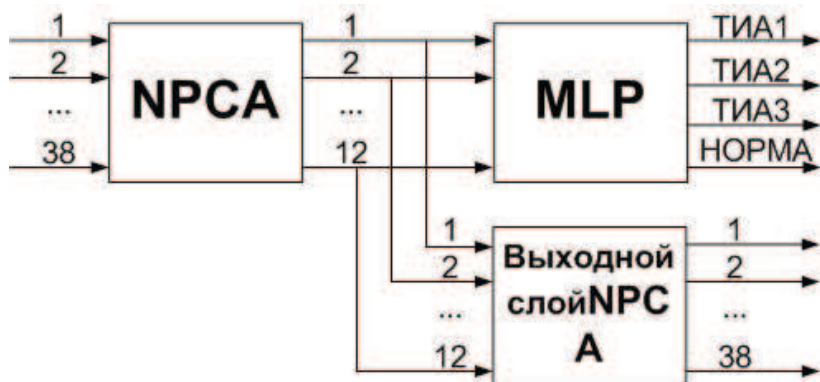


Рис. 14. Генерация новых образов

Таблица 7. Результаты распознавания с использованием сгенерированных образов

Число образов в обучающей выборке	Число образов в тестовой выборке	Точность распознавания на обучающей выборке	Точность распознавания на тестовой выборке
1000	114	98%	92.2%

зирующийся на легкодоступных анамнестических данных, получение которых не требует дорогих и значительного времени исследований. Система способна оперативно определить наиболее вероятный вектор развития патологии, что очень важно для выбранных заболеваний. Предварительный диагноз дает возможность доктору понять симптоматику пациента уже при первом обследовании, уменьшая временной интервал между началом обследования пациента и назначением лечебно-профилактических действий.

Заключение

В данной лекции рассмотрены основные принципы построения нейроинтеллектуальных систем для обнаружения аномалий в биомедицинских данных с целью диагностирования заболеваний. В качестве аномалий здесь рассматриваются нарушения нормальной активности головного мозга, такие как эпилептиформная активность и транзиторные ишемические атаки (ТИА), которые могут привести к катастрофическим последствиям. Для таких процессов большое значение имеет оперативное обнаружение аномалий, чтобы помочь доктору поставить адекватный диагноз и предотвратить катастрофическое развитие ситуации. Задачи оперативного обнаружения эпилептиформной активности и транзиторных ишемических атак являются трудноформализуемыми, для которых невозможно или очень сложно найти аналитический алгоритм принятия решений.

В лекции представлена нейросетевая система обнаружения эпилептической активности на основе анализа сигналов EEG и нейросетевая система предварительной диагностики транзиторных ишемических атак. Основными преимуществами предложенной диагностической системы определения эпилептической активности является высокая точность классификации 99.6% при малой вероятности ложных срабатываний равной 0.003 и отсутствие предварительного обучения на эталонных данных. Нейросетевая система для диагностики транзиторных ишемических атак способна распознавать новые атаки, неиспользуемые в обучающей выборке.

Результаты, приведенные в данной лекции, получены в результате сотрудничества кафедры «Интеллектуальные информационные технологии» Брестского государственного технического университета и кафедры «Неврология и нейрохирургия» Белорусской медицинской академии последипломного образования. Автор благодарит проф. Евстигнеева В. В., Мастыкина А. С., Лаврентьеву С. В., Дунца А. П., Войцеховича Г. Ю., Кистень О. В., Апанель Е. Н. за помощь в подготовке данной лекции.

Литература

1. *Lisba P.J., Taktak A.* The use of artificial neural networks in decision support in cancer: A systematic review // *Neural Networks*. – 2006, **19**:408–415.
2. *Guo L., Rivero D., Pazos A.* Epileptic seizure detection using multiwavelet transform based approximate entropy and artificial neural networks // *J. of Neuroscience Methods*. – 2010, **193**:156–163.

3. Dawson J. a.o. A recognition tool for transient ischemic attack // *Q. J. Med.*, 2009, **192**:43–49.
4. Wolf A., Swift J., Swinney H., Vastano J. Determining Lyapunov exponents from a time series // *Physica D.* – 1985, **16**:285–292.
5. Iasemidis L. D., Principe J. C., Sackellares J. C. Measurement and quantification of spatiotemporal dynamics of human epileptic seizures // *Nonlinear Signal Processing in Medicine.* – 2000, **2**:1–27.
6. Polat K., Gunes S. Classification of epileptiform EEG using a hybrid system based on decision tree classifier and fast Fourier transform // *Applied Mathematics and Computation.* – 2007, **187**:1017–1026.
7. Guo L., Rivero D., Dorado J. a.o. Automatic epileptic seizure detection in EEGs based on line length feature and artificial neural networks // *J. of Neuroscience Methods.* – 2010, **191**:101–109.
8. Yasa B., Liu J. Z., Brown R. W. a.o. Nonlinear features of surface EEG showing systematic brain signal adaptations with muscle force and fatigue // *Brain Research.* – 2009, **1272**:89–98.
9. Sarbadhikari S. N., Chakrabarty K. Chaos in the brain: a short review alluding to epilepsy, depression, exercise and lateralization // *Medical Engineering and Physics.* – 2001 **23**:445–455.
10. Wang X., Meng J., Tan G., Zou T. Research on the relation of EEG signal chaos characteristics with high-level intelligence activity of human brain // *Nonlinear Biomedical Physics.* – 2010, doi:10.1186/1753-4631-4-2.
11. Nigam V. P., Graupe D. A neural-network-based detection of epilepsy // *Neurological Research.* – 2004, **26**:55–60.
12. Patnaik L. M., Manyam O. K. Epileptic EEG detection using neural networks and post-classification // *Computer Methods and Programs in Biomedicine.* – 2008, **91**:100–109.
13. Subasi A. Application of adaptive neuro-fuzzy inference system for epileptic seizure detection using wavelet feature extraction // *Computers in Biology and Medicine.* – 2007, **37**:227–244.
14. Subasi A. Automatic detection of epileptic seizure using dynamic fuzzy neural networks // *Expert Systems with Applications.* – 2006, **31**:320–328.
15. Ocak H. Optimal classification of epileptic seizures in EEG using wavelet analysis and genetic algorithm // *Signal Processing.* – 2008, **88**:1858–1867.
16. Hsu K.-Ch., Yu S.-N. Detection of seizures in EEG using subband nonlinear parameters and genetic algorithm // *Computers in Biology and Medicine.* – 2010, **40**:823–830.

17. *Пригожин И., Стенгерс И.* Время, хаос, квант: К решению парадокса времени. Москва: URSS, 2008. – 300с.
18. *Hyvaerinen A., Oja E.* Independent component analysis: algorithms and applications // *Neural Networks*. – 2000, **13**:411–430.
19. *Takens F.* Detecting strange attractors in turbulence, Lecture Notes in Mathematics, Vol.898, Springer-Verlag, Berlin, 1980, pp. 366–381; and in *Dynamical System in Turbulence*, Warlock, 1980, eds. D.Rand and L.S.Young.
20. *Lopes da Silva F.* EEG analysis: theory and practice. In: Niedermeyer E., Lopes da Silva F. editors. Electroencephalography: Basic principles, clinical applications, an related fields. 4th ed. CityplaceBaltimore: Lippincott, Williams and Wilkins. – 1998, 1153–1163.
21. *Головко В. А.* Нейросетевые методы обработки хаотических процессов // Лекции по нейроинформатике. – М.: МИФИ, 2005. – с. 43–88.
22. *Golovko V., Doudkin A., Maniakov N.* Application of Neural Networks Techniques to Chaotic Signal Processing // *Optical Memory and Neural Networks*. – 2004, **13**:195–215.
23. *Rosenstein M. T., Collins J. J., De Luca C. J.* A practical method for calculating largest Lyapunov exponents from small data sets // *Physica D*. – 1993, **65**:117–134.
24. *Kantz H.* A robust method to estimate the maximal Lyapunov exponent of a time series // *Physics Letters A*. – 1994, **185**:77–87.
25. *Golovko V.* From Neural Networks to Intelligent Systems: Selected Aspects of Training, Application and Evolution. Limitations and Future Trends in Neural Computation: NATO book. IOS Press, Amsterdam, 2003, 219–243.
26. *Golovko V., Savitsky Y., Maniakov N.* Neural Networks for Signal Processing in Measurement Analysis and Industrial Applications: the Case of Chaotic Signal Processing // chapter of NATO book “Neural networks for instrumentation, measurement and related industrial applications”. – Amsterdam: IOS Press, 2003, pp. 119–143.
27. *Головко В., Чумерин Ю.* Нейросетевые методы определения спектра Ляпунова хаотических процессов // *Нейрокомпьютеры: разработка и применение*, 2004. – № 1.
28. EEG time series.
URL: <http://www.meb.uni-bonn.de/epileptologie/science/physik/eegdata.html>
Accessed 25 May 2011.
29. *McNeill A.* How Accurate Are Primary Care Referral Letters For Presumed Acute Stroke? // *Scottish Medical Journal*. – 2008. – v. 53, No. 4. – pp. 11–12.

30. *Easton J.D. a.o.* Definition and evaluation of transient ischemic attack // *Stroke* (Journal of the American Heart Associations), 2009.
31. *Dawson J. a.o.* A recognition tool for transient ischemic attack // *Q. J. Med.* – 2009. – 192, pp. 43–49.
32. *Lisba P.* A review of evidence of health benefit from artificial neural networks in medical intervention // *Neural Networks.* – 2002. – 15. – pp. 11–39.
33. *Barnes R., Toole J., Nelson J., Howard V.* Neural networks for ischemic stroke // *Journal of Stroke and Cerebrovascular Diseases.* – 2006. – Vol.15, No. 5, pp. 223–227.
34. *Shanthi D., Sahoo D., Saravanan D.* Input feature selection using hybrid neuro-genetic approach in the diagnosis of stroke disease // *IJCSNS International Journal of Computer Science and Network Security.* – Vol. 8, No. 12, December 2008. – pp. 99–107.
35. *Shanthi D., Sahoo D., Saravanan D.* Designing an artificial neural network model for the prediction of thrombo-embolic stroke // *International Journal of Biometric and Bioinformatics.* – 2008. – Vol. 8, No. 1. – pp. 10–18.
36. *Мастыкин А. С., Евстигнеев В. В., Головкин В. А., Апанель Е. Н., Войцехович Г. Ю.* Нейросетевой подход к решению проблемы предотвращения атак на нормальное кровоснабжение мозга // Доклады Академии наук Беларуси. – 2010. – Т. 54 – № 5. – с. 81–90.

Владимир Адамович ГОЛОВКО, доктор технических наук, профессор, заведующий кафедрой «Интеллектуальные информационные технологии» и научно-исследовательской лабораторией «Искусственные нейронные сети» Брестского государственного технического университета. Область научных интересов — искусственный интеллект, нейронные сети, искусственные иммунные системы, хаотические процессы, обработка биомедицинских сигналов, обнаружение и распознавание атак и вирусов на компьютерные системы, автономное управление мобильными роботами, прогнозирование. Рецензент журналов *IEEE Transaction on Neural Networks, Neurocomputing and Knowledge-Based Systems*. Организатор международной конференции в Беларуси *International Conference on Neural Networks and Artificial Intelligence (ICNNAI)*. Автор трех монографий, пяти глав в книгах и более 250 научных публикаций.