

Таблица 1 – Результаты распознавания типов атак до настройки порогов на обучающей выборке (3880 соединений), $MC = 5,05\%$

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23
DR	91,7	96,4	100	96,7	95	100	89,5	100	83,3	76,7	98,9	97,1	100	100	100	96,6	95	86,5	100	100	100	74	98
FAR	2,91					0,03		0,16				0,84			0,16	0,11	0,13	0,03				0,16	0,58
SE	11,2	3,6		3,3	5	0,03	10,5	0,16	6,7	23,3	1,1	3,74			0,16	3,51	5,13	13,5				26,2	2,6

Таблица 2 – Результаты распознавания типов атак после настройки порогов на обучающей выборке (3880 соединений), $MC = 3,87\%$

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23
DR	87,1	98,2	100	96,7	97,5	100	93,2	100	100	85,3	99,1	82,9	100	100	100	95,4	95	97	100	100	100	93,3	76
FAR	1,07					0,03	0,38			0,64		0,26			0,16	0,08	0,13	0,38				0,24	0,58
SE	14	1,8		3,3	2,5	0,03	7,18			15,3	0,9	17,4			0,16	4,68	5,13	3,4				6,94	24,6

Таблица 3 – Результаты распознавания типов атак после настройки порогов на тестовой выборке (505291 соединений), $MC = 1,92\%$

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23
DR	94,2	85,2	93,8	87,5	98,1	10,3	23,3	95,3	100	85,7	99,7	44,6	100	100	99,2	96,6	80	97,6	99,8	100	100	80,3	85
FAR	0,41	0,32		0,01	0,12		0,04		0,01		0,03	0,02				0,06	0,01	0,64				0,34	

Сравнивая результаты распознавания типов атак в первой и второй таблицах, можно сделать вывод, что на различных детекторах настройка порогов отражается по-разному: ухудшается качество распознавания (детекторы №№ 1, 12 и 23), остается на том же уровне или значительно улучшается (детекторы №№ 2, 5, 7 и, особенно, 10, 18 и 22). Это значит, что система пытается за счет проигрыша в небольшом количестве детекторов достичь выигрыша в большем количестве детекторов и в целом по системе.

Литература.

1. Giacinto, G. et al. Selection of image classifier // G. Giacinto, F. Roli, G. Fumera. – Electron. – №26(5), 2000. – P. 420-422.
2. Кочурко, П.А. Нейросетевой детектор аномалий / П.А.Кочурко // Известия Белорусской инженерной академии. – 2005. – № 1(19) – С. 78-81.
3. KDD Cup 1999 Data / The UCI KDD Archive, Information and Computer Science. – University of California, Irvine, 1999.

УДК 004.8.032.26

ОПТИМИЗАЦИЯ НЕЙРОСЕТЕВОЙ СИСТЕМЫ ДЛЯ АНАЛИЗА ЭЛЕКТРОЭНЦЕФАЛОГРАММ

Лаврентьева С.В.

УО «Брестский государственный технический университет», г. Брест

Введение

Автоматическое обнаружение эпилептиформной активности в сигналах электроэнцефалограмм (ЭЭГ) является актуальной задачей. Результаты исследования динамики значения старшего показателя Ляпунова для сигналов электроэнцефалограмм (ЭЭГ) показывают неточность обнаружения интервала, содержащего эпилептиформную активность, а также высокий процент ложных срабатываний алгоритма [1]. Причиной таких результатов работы метода является анализ нестационарного сигнала. Когда в обучающую выборку

попадает граница сегментов, при переходе которой меняются характеристические параметры сигнала, результаты расчета старшего показателя Ляпунова будут сильно зависеть от обучения нейронной сети. Обучение может привести к усреднению значения показателя на интервале обучения, также может быть рассчитано с большим влиянием одного из сегментов либо привести к резкому возрастанию показателя. Для устранения данного недостатка работы алгоритма предлагается до его использования проводить сегментацию сигнала на условно-стационарные сегменты и расчет старшего показателя Ляпунова производить отдельно на каждом сегменте. Такое решение позволит также точнее определять границы и длительность каждого сегмента, тем самым выделить участки с эпилептиформной активностью.

1. Нейросетевая система

Приведем алгоритм работы системы с кратким описанием используемых методов и результатов обработки сигнала ЭЭГ [2]:

1) Исходная группа сигналов обрабатывается при помощи метода независимых компонент (The Independent Component Analysis – ICA) [3]. Этот метод позволяет отфильтровать электрическую активность головного мозга от шумов и артефактов. В результате анализа выделяется один полезный ЭЭГ сигнал для последующей обработки.

2) Полученный на этапе 1) сигнал подвергается адаптивной сегментации при помощи прогнозирующей искусственной нейронной сети (ИНС). Так как сигналы ЭЭГ являются нестационарными, то данный подход позволяет получить последовательность сегментов, где в рамках каждого сегмента данные можно считать стационарными.

3) При помощи прогнозирующей ИНС производится расчет старшего показателя Ляпунова на каждом из сегментов. В результате получаем детерминированный ряд $\lambda(t) = (\lambda_1, \lambda_2, \dots, \lambda_N)$, где N – количество сегментов.

4) Согласно критерию (1) по значениям $\lambda(t)$ определяется наличие эпилептической активности в сигнале ЭЭГ:

$$\begin{cases} \lambda > 0, & \text{если } \lambda_i > 0; \\ \lambda \leq 0, & \text{иначе} \end{cases} \quad (1)$$

Такой подход позволяет работать с малыми объемами данных, однако зависит от эффективности смоделированной ИНС. По результатам наших предыдущих исследований [1,4] наилучшие результаты для рассматриваемой задачи получаются при использовании многослойного персептрона с сигмоидной функцией активации в скрытом слое.

2. Описание экспериментальных данных

Различные эпилептиформные активности, которые могут присутствовать на ЭЭГ, характеризуются амплитудой, частотой сигнала, длительностью участка. Наиболее важным свойством для автоматического обнаружения участка эпилептиформной активности при помощи предложенного алгоритма является длительность аномальной активности на ЭЭГ. Согласно этой длительности можно определить размер минимального сегмента, который предполагается выделять на ЭЭГ и при этом корректно идентифицировать его принадлежность к классу нормальной либо аномальной активности. Если проанализировать возможную длительность эпилептиформной активности и минимальный период повторения (T_{\min}) таких активностей в случае образования комплексов на ЭЭГ, тогда размерность сегмента N ограничится исходя из неравенства (6) [2].

$$N \leq \frac{T_{\min} \cdot F}{\tau}, \quad (2)$$

где F – частота дискретизации сигнала, τ – временная задержка.

Для проведения исследований была сформирована база тестовых образов, состоящая из 60 фрагментов ЭЭГ сигналов с частотой дискретизации 250 Гц. При этом 30 фрагментов содержат в себе различные формы эпилептической активности и 30 представляют собой фрагменты ЭЭГ, характеризующиеся только нормальной активностью головного мозга.

При помощи программного продукта TESEAN 2.1 для экспериментальных данных была рассчитана величина $\tau = 1$. Таким образом, согласно условию (2) получим $N \leq 50$ при минимальном периоде повторения эпилептических вспышек в комплексах на ЭЭГ $T_{\min} = 0.2$ секунды [2]. С увеличением размерности обучающей выборки возрастает и время обучения до желаемой ошибки, при этом приемлемым можно принять интервал $N = [50, \dots 70]$.

3. Экспериментальное исследование

Необходимо определить граничное значение старшего показателя Ляпунова, согласно которому мы будем классифицировать сегмент как нормальную или аномальную активность. Рассмотрим вариации значения минимального сегмента в интервале $N = [50, \dots 70]$ и рассчитаем значение показателя для каждого образа тестовой базы и определим диапазон изменения данной величины $[\min, \max]$ для образов с нормальной активностью и для образов с аномальной активностью отдельно. Результаты анализа сведены в таблицу 1.

Таблица 1 – Результаты расчета старшего показателя Ляпунова при различных размерах обучающей выборки

N	Значение старшего показателя Ляпунова			
	Эпилептиформная активность		Нормальная активность	
	min	max	min	max
50	-0.12	-0.01	-0.04	0.13
55	-0.20	0.01	-0.02	0.17
60	-0.21	0.01	-0.01	0.16
65	-0.25	0.00	0.00	0.18
70	-0.31	-0.01	0.01	0.21

Результаты экспериментальных расчетов, приведенные в таблице 1, показывают, что при $N = 70$ диапазоны значений показателя не пересекаются, а следовательно, можно определить граничное значение $\epsilon = 0$ (среднее значение между \max для эпилептиформной активности и \min для нормальной активности сигнала).

Для $N = 70$ рассчитаем относительную величину K_r , характеризующую точность выполненной классификации:

$$K_r = \frac{C_r}{C_p} \cdot 100\%, \quad (3)$$

где C_r – количество правильно классифицированных образов, $C_p = 60$ – общее количество тестовых образов.

Результаты предложенного экспериментального анализа представлены на рисунке 1.

Как показано на рисунке 1, наилучший результат достигается при достижении ошибки обучения $E_w = 0.01$, так как все образы классифицируются правильно и при этом снижение данного значения приведет к нежелательному увеличению времени обучения.




Рисунок 1 – Зависимость точности классификации исходных образов от значения достигаемой ошибки обучения нейронной сети E_w

Выводы

Представлено описание нейросетевой системы для анализа электроэнцефалограмм с целью обнаружения и выделения длительности эпилептиформной активности.

Проведены экспериментальные исследования для настройки параметров предложенного алгоритма с целями оптимизации его работы и повышения точности выделения участков и классификации их.

Исследования проводятся по заданию Министерства образования Республики Беларусь в соответствии с темой «Нейросетевая система анализа электроэнцефалограмм для обнаружения и распознавания эпилептиформной активности» (№ госрегистрации 20090433).

Литература

1. Golovko, V.A. Neural networks for chaotic signal processing: application to the electroencephalogram analysis for epilepsy detection / V.A. Golovko, S.V. Bezobrazova // Proceedings of the 4th International Conference on Neural Networks and Artificial Intelligence (ICNNAI'2006) / BrSTU. – Brest, 2006. – P.136-139.

2. Laurentsyeva, S. Electroencephalogram Analysis Based on Artificial Neural Network and Adaptive Segmentation / S. Laurentsyeva, V. Golovko, V. Evstigneev // Proceedings of the Tenth International Conference of Pattern Recognition And Information Processing (PRIP'2009), Minsk, Belarus, 19 – 21 May, – Minsk, 2009 – P. 327–331.

3. Hyvaerinen A., Oja E. Independent component analysis: algorithms and applications // Neural Networks. – 2000. – № 13. - P. 411-430.

4. Bezobrazova S. Forecasting neural networks and chaos theory in the application for epilepsy detection // IX International PhD Workshop OWD'2007: Conference Archives PTETiS. – 2007. – Vol. 23.