

показаны каскады для фильтров первого и второго порядка. Соединяя последовательно данные каскады можно получить фильтр любого порядка.

После фильтра следует основной усилительный каскад (рис 3). Коэффициент усиления равен 1000. Отношение $R_2/R_1=1000$. В качестве операционных усилителей можно использовать микросхемы ОРА2333 или ОРА4347, которые могут работать от однополярного питания.

В качестве АЦП лучше всего подойдет микросхема ADS1298. Эта микросхема специально предназначена для медицинских приложений, представляющая собой 24-битное дельта-сигма АЦП и имеет 8 каналов, считываемых одновременно. Также микросхема имеет программируемый интегрированный усилитель с коэффициентами усиления 1, 2, 3, 4, 6, 8 или 12. Для соединения с микропроцессорным устройством имеет SPI интерфейс.

В качестве блока управления и вычислений используется сигнальный процессор. Устройство должно иметь возможность сохранения данных во внешнюю память и передавать данные на персональный компьютер для визуализации результатов.

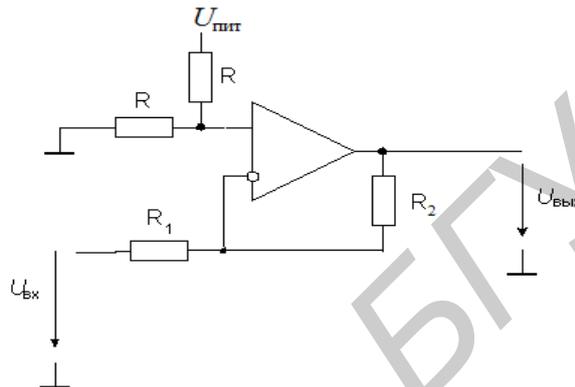


Рисунок 3 – Усилительный каскад на основе операционного усилителя

Разрабатываемая система должна контролировать активность мозга, детектировать эпилептические феномены и физиологические артефакты. Также система должна предусматривать добавление в будущем биологической обратной связи с пациентом.

Список использованных источников:

1. Киреев А.В., Ледаева В.С., Резниченко А.А., Принципы разработки усилителей биопотенциалов и метод обработки данных о реакции организма // Инженерный вестник Дона, 2012. - №4 (ч. 2)
2. Dong-Gyu Kim, Yong-Wan Roh, and Kwang-Seok Hong, A Portable EEG Signal Acquisition System// The Second International Symposium on Mechanical Science and Technology (ISMST 2011), December 20-21, 2011.
3. M. Teplan, "FUNDAMENTALS OF EEG MEASUREMENT", MEASUREMENT SCIENCE REVIEW, Volume 2, Section 2, 2002.

АЛГОРИТМ ФОРМИРОВАНИЯ ИНФОРМАТИВНЫХ ПРИЗНАКОВ ДЛЯ КЛАССИФИКАЦИИ ПАТТЕРНОВ В СИГНАЛАХ ЭЛЕКТРОЭНЦЕФАЛОГРАММ

*Белорусский государственный университет информатики и радиоэлектроники
г. Минск, Республика Беларусь*

Коржун В.В.

Давыдов М.В. – кандидат техн. наук, доцент

Электроэнцефалограмма является наиболее распространенным и важным методом анализа и диагностики биоэлектрической активности головного мозга человека. Проведение электроэнцефалограмм является очень эффективным методом для диагностики эпилептической активности, различных нарушений работы мозга, нарушений сна и др. Для повышения информативности электроэнцефалографии разрабатываются методики анализа сигналов, позволяющие выявлять эпилептическую активность в межприступном (интериктальном) периоде, в частности, определять неясную, скрытую пароксизмальную активность и дифференцировать сигналы эпилептической и неэпилептической природы.

Разработано множество методов для изучения и анализа сигналов электроэнцефалограммы с целью выявления патологических изменений мозга. Наиболее распространенным в компьютерной электроэнцефалографии сегодня является кратковременный Фурье-анализ, но часто этот метод имеет недостаточную разрешающую способность по времени. Для решения этой проблемы используют вейвлет-анализ, который имеет много преимуществ. Однако результаты применения вейвлет-анализа для исследования ЭЭГ сигналов показывают, что данный метод не позволяет отличить эпилептическую

активность от артефактов (мышечной и другой природы), а также не всегда обнаруживает патологическую активность в сигналах [2, 3].

В данной работе предлагается алгоритм поиска оптимальных информативных признаков, способных обнаруживать различные паттерны в ЭЭГ сигнале. Рассматриваемый в данной работе алгоритм служит для определения характеристик и параметров отдельных участков в анализируемом ЭЭГ сигнале. Получаемая в результате работы алгоритма разметка сигнала может применяться для повышения эффективности работы систем детектирования эпилептических припадков, систем поиска артефактов и феноменов на длительных записях.

В данной работе делается попытка найти информативные признаки пригодные для классификации и детектирования различных феноменов, а также артефактов. Идея работы – найти уникальные признаки, которые были бы характерными только для конкретного феномена (например, острая волна, медленная волна и др.).

Алгоритм представляет собой селективный метод, суть которого из огромного набора параметров, признаков и характеристик выбрать наиболее значимые [1]. Алгоритм начинает с пустого множества и последовательно добавляет к нему наилучшие (для текущей итерации) информативные признаки.

На рисунке 1 изображена схема получения информативных признаков.

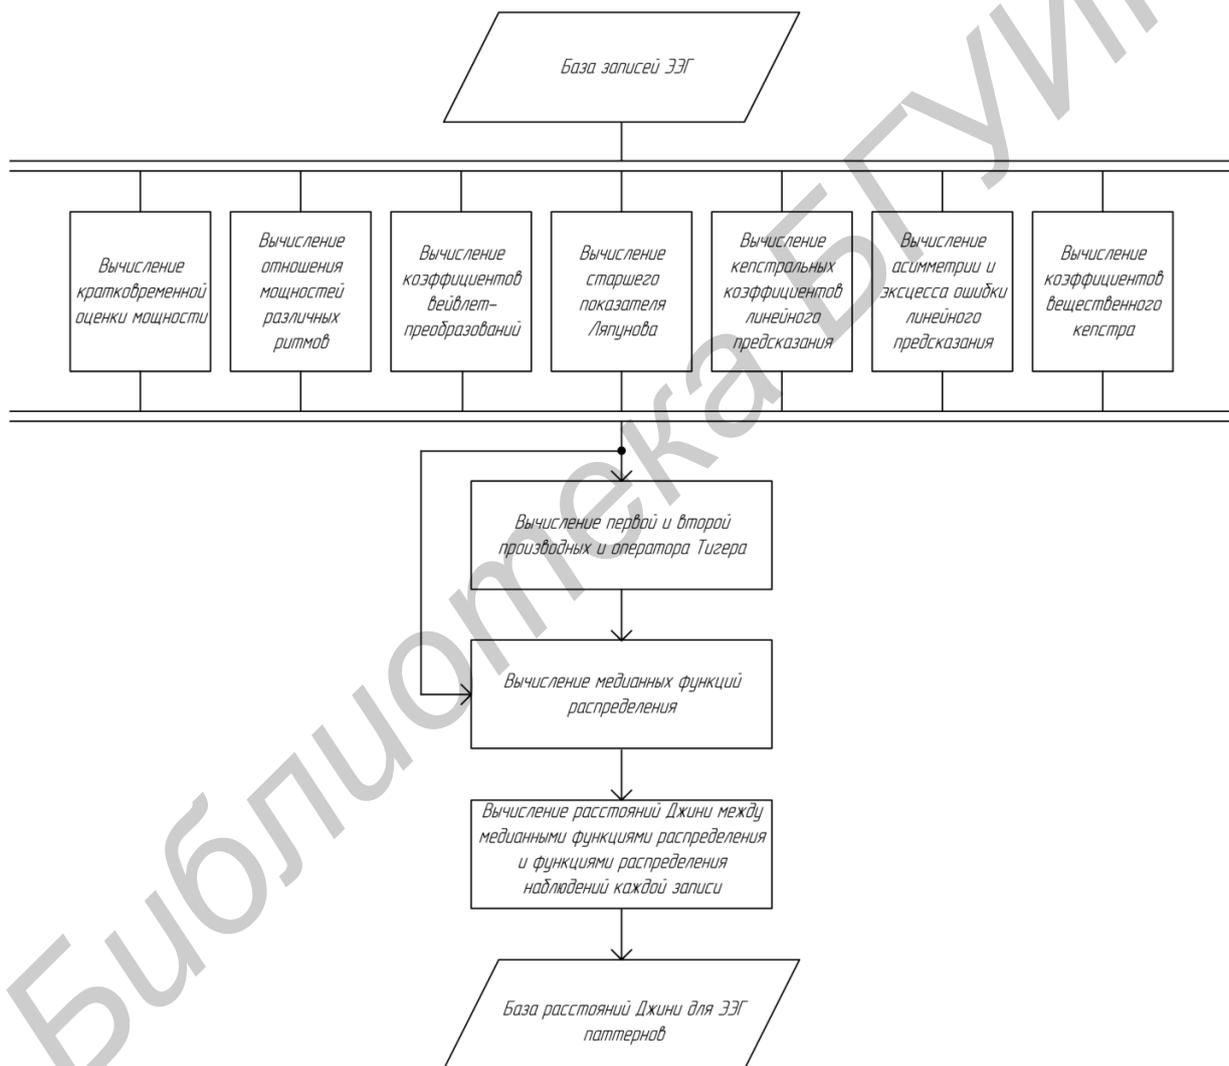


Рисунок 1 – Получение коллекции информативных признаков

Прежде всего, из баз ЭЭГ формируется основные характеристики такие как оценка мощности, отношение мощностей в различных частотных полосах, кепстральные коэффициенты линейного предсказания, эксцесс и асимметрия ошибки линейного предсказания, старший показатель Ляпунова [2], коэффициенты различных вейвлет преобразований (симлеты, койфлеты, Добеши, Хаара и др.), коэффициенты вещественного кепстра. На основании основных характеристик вычисляются дополнительные, такие как первая и вторая производные, оператор Тигера [4].

По всем основным и дополнительным характеристикам строятся их функции распределения для всех записей исследуемых классов, по которым далее вычисляется медианные функции распределения классов по всем выше перечисленным характеристикам. Теперь формируется база расстояний Джини [5], как

интеграл модуля разности функции распределения каждой записи и медианной функции распределения. Вычисление медианных функций распределения показано на рисунке 2.

Когда набор информативных признаков сформирован, начинается процедура обучения и тестирования классификатора. Для этого используется метод K-fold cross-validation или метод перекрестной проверки [8]. Суть данного метода заключается в разделении базы на K примерно равных частей. K-1 частей используются для обучения, а одна часть для тестирования. Данная процедура повторяется K раз и каждый раз для тестирования используются разные части.

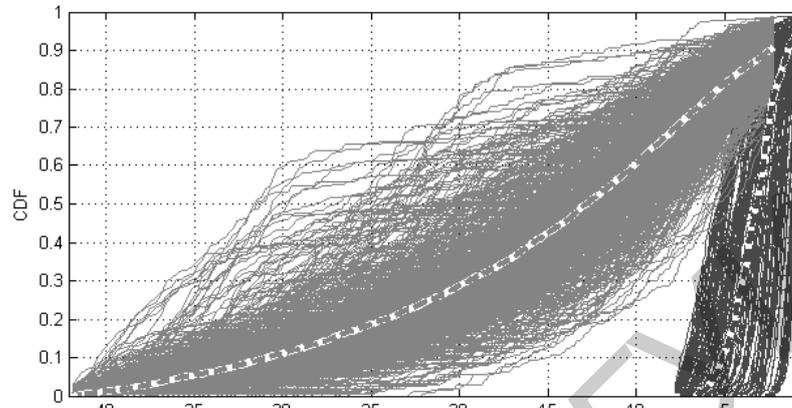


Рисунок 2 – Вычисление медианных функций распределения для двух классов по одному из признаков

Перекрестная проверка – это метод формирования обучающего и тестового множеств для обучения аналитической модели в условиях недостаточности исходных данных или неравномерного представления классов. Перекрестная проверка имеет два основных преимущества перед применением одного множества для обучения и одного для тестирования модели. Во-первых, распределение классов оказывается более равномерным, что улучшает качество обучения. Во-вторых, если при каждом проходе оценить выходную ошибку модели и усреднить ее по всем проходам, то полученная ее оценка будет более достоверной.

Добавление признаков в список происходит согласно алгоритму sequential forward feature selection (SFFS) [5,6]. После тестирования в список добавляется признак с наибольшей эффективностью разделения для данной итерации. За каждым проходом к списку признаков будет добавляться по одному признаку, но обучение и тестирование будет проходить уже в комбинации с признаками из списка. Алгоритм работает по правилу +5 -3, т.е. сначала последовательно отыскиваются и добавляются в список наиболее 5 информативных признаков, а затем последовательно удаляются 3 наихудших из списка. Данный цикл будет повторяться до тех пор, пока количество признаков не достигнет заданного предела.

После получения набора оптимальных признаков необходимо проверить эффективность классификации. Для этого строится график эффективности в зависимости от количества взятых признаков. Также работоспособность классификатора должна оцениваться на случайных данных. Для этой характеристики все полученные из записей признаки заменяются случайными данными. Если результаты классификации на случайных данных будут значительно ниже, то можно будет говорить о корректности результата.

Список использованных источников:

1. Давыдов А.Г., Киселёв В.В., Чочетков Д.С., Ткачя А.В. Выбор оптимального набора информативных признаков для классификации эмоционального состояния диктора по голосу // Компьютерная лингвистика и интеллектуальные технологии: материалы ежегодной Международной конференции «Диалог» (Бекасово, 30 мая - 3 июня 2012г.). Вып. 11 (18). – М.: Изд-во РГГУ, 2012., стр 122
2. Лаврентьева С.В, Кистень О.В., Головкин В.А., Евстигнеев В.В. Диагностическая экспериментальная система для анализа эпилептической активности по данным электроэнцефалограмм// Новости медико-биологических наук, 2010. - №1. –
3. Куравский, Л.С. Нейросетевая технология диагностики патологических состояний по аномалиям электроэнцефалограмм / Л.С. Куравский [и др.] // Нейрокомпьютеры: разработка и применение. – 2007. – №4 – С. 4-14.
4. Teager, H. and Teager, S., Evidence for nonlinear production mechanisms in the vocal tract. *Speech Production and Speech Modelling*, Nato Advanced Institute, 1990 - pp. 241–261.
5. Кобзарь, А.И. Прикладная математическая статистика. Для инженеров и научных работников/ А.И. Кобзарь. - ФИЗМАТЛИТ, 2006. – 816 с.
6. Pudil, P., Novovicova, J., Kittler, J. (1994) Floating search methods in feature selection. *Pattern Recognition Lett.* 15,
7. Stearns, S.D. On selecting features for pattern classifiers. // *Third Internat. Conf. on Pattern Recognition*, Coronado, CA, 1976 - С. 71-75.
8. Kohavi, R. A study of cross-validation and bootstrap for accuracy estimation and model selection // *Fourteenth International Joint Conference on Artificial Intelligence*, 1995 – С. 1137 – 1143
9. Добеши, И. "Десять лекций по вейвлетам". Москва, РХД, 2001.
10. Хайкин, С., Нейронные сети : полный курс, 2-е издание. : Пер. с англ. – М. : Издательский дом «Вильямс», 2006
11. Jongseo Sohn, Nam Soo Kim, Wonyong Sung. A statistical model-based voice activity detection. - *IEEE signal processing letters*, vol. 6, №. 1, 1999
12. Метод опорных векторов [Электронный ресурс]. – Электронные данные. – Режим доступа : <http://www.machinelearning.ru>