

УДК 004.93.12

ИНТЕРФЕЙС МОЗГ-КОМПЬЮТЕР НА ОСНОВЕ КОМПОНЕНТА P300: РАЗЛИЧНЫЕ ПОДХОДЫ КЛАССИФИКАЦИИ

Станкевич Ф.В., Пантюхин Е.И., Спицын В.Г.

ФГАОУ ВО «Национальный исследовательский Томский политехнический университет»,
Томск, e-mail: stankevichfv@tpu.ru

С момента изобретения электроэнцефалографии люди начали задумываться о возможности создания канала коммуникации, основанного на интерпретации сигналов мозговой активности. В последние десятилетия создание интерфейса мозг-компьютер (ИМК) ведется активными темпами во многих ведущих мировых лабораториях. Одним из направлений систем ИМК являются системы, основанные на компоненте P300. В данной работе рассматриваются различные подходы для детекции компонента P300 с целью построения системы ИМК для набора текста на экране монитора. Рассматриваются такие подходы, как анализ сырых данных, применение метода главных компонент, применение комитетных методов классификации с использованием машин опорных векторов и линейного дискриминантного анализа. По итогам работы была получена точность 100 и 98% для первого и второго субъекта соответственно на наборе данных с соревнования по ИМК (Берлин, 2003).

Ключевые слова: интерфейс мозг-компьютер, обработка сигналов, P300, извлечение признаков, комитетные методы классификации

TOWARDS P300 BASED BRAIN-COMPUTER INTERFACE: DIFFERENT APPROACHES OF CLASSIFICATION

Stankevich F.V., Pantyukhin E.I., Spitsyn V.G.

National Research Tomsk Polytechnic University, Tomsk, e-mail: stankevichfv@tpu.ru

Since the invention of electroencephalography (EEG) people have thought how to develop a new communication channel based on brain signal analysis. Over the last decades, the amount of brain-computer interface (BCI) research has significantly increased all over the world. P300 component is one of the most popular components for EEG-based BCI. In this work, we consider different approaches for P300 component detection to build a BCI speller. We have considered the classification of raw data, feature extraction based on principle component analysis using linear discriminant analysis (LDA) and support vector machine (SVM). Additionally, ensemble of classifiers has been used to improve recognition accuracy. Finally, the accuracies of 100 and 98% have been achieved, for subject A and B accordingly, using Data Set II from the BCI Competition III (Berlin, 2003).

Keywords: brain-computer interface, signal processing, P300, feature extraction, ensemble of classifiers

Термин «интерфейс мозг-компьютер» впервые был использован Jacques Vidal [13] для определения любой системы, содержащей компьютер и позволяющей получать информацию о функционировании мозга. На текущий момент можно дать более узкое определение данному понятию. В 1999 году на первой международной встрече по ИМК сформулировали, что ИМК не должен зависеть от состояния периферийных нервов, доставляющих информацию в мозг или несущих управляющие сигналы от него, а также мышц, управляющих движениями [15].

Спектр задач, на решение которых нацелен интерфейс мозг-компьютер, очень широк. В первую очередь можно выделить обеспечение альтернативных каналов коммуникации для людей с ограниченными возможностями. Например, написание слов посредством анализа электроэнцефалографической активности [4], выбор команд на экране монитора из нескольких альтернатив [13], управление протезом на основе интерпретации электроэнцефалографии (ЭЭГ) [11].

Также возможно применение ИМК для общего управления компьютером, что может быть полезно широкой аудитории пользователей, но пока существенных успехов в данной области достичь не удалось, так как для решения этой задачи требуется высокое выходное качество системы. Также в области ИМК можно выделить особую подзадачу – это управление в видеоиграх. Это направление в последнее время получило достаточное широкое распространение, обзор по этой теме может быть найден в [10]. Последней задачей по счету, но не по важности является задача управления техническими системами, например управление роботами и беспилотными летательными аппаратами [9] или создание умного дома [5].

Данная работа посвящена созданию систем для ввода текста на экране монитора на основе компонента P300, а именно различным подходам к классификации сигнала для выявления присутствия/отсутствия компонента в сигнале. Существует множество работ, посвященных

задаче классификации компонента P300 для ИМК. Первой из них является работа Donchin и Farwell [6] в 1988 году, затем в 2000 году авторы улучшили скорость работы системы [4]. С 2000 г. было проведено множество исследований по классификации компонента P300 для создания систем ИМК для написания текста. В основном для этой задачи используются линейные методы классификации сигнала, результаты применения которых представлены в [12]. В 2003 году научной группой Berlin VCI было проведено 3-е соревнование по системам ИМК, одним из наборов данных для соревнования являлся набор с данными для классификации компонента P300 (Data Set II). В результате соревнования удалось достичь точности классификации 96 % [12].

В данной работе ставится задача сравнения различных методов извлечения признаков и способов линейной классификации сигнала для выявления присутствия компонента P300 для задачи написания текста на экране монитора.

Компонент P300

Рассмотрим подробнее компонент P300. Название компонента, как и в целом всех компонентов в нейронауках, состоит из двух частей: *P* означает *positive*, 300 означает момент во времени, в котором присутствует компонент. То есть P300 означает положительный пик в окрестности 300-й миллисекунды (может варьироваться от 250-й до 500-й мс). Схематическое изображение компонента P300 приведено на рис. 1.

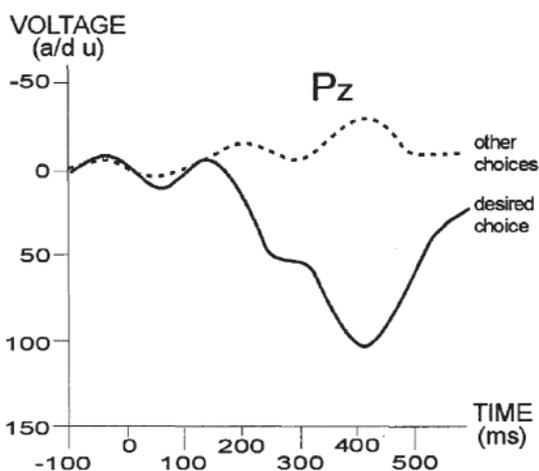


Рис. 1. Компонент P300 [15]

В целом сигнал ЭЭГ представляет собой одномерный сигнал с множества электродов (от 1 до 256), расположенных на поверхности головы. Частота дискретизации

сигнала варьируется от нескольких десятков до нескольких сот герц, обычно около 100 Гц. Амплитуда сигнала мозговой активности в спокойном состоянии, как правило, не превышает 100 мВ.

Для обнаружения компонента P300 целесообразно рассматривать сигнал окрестности 300 мс, в частности принято рассматривать сигнал в диапазоне от 0 мс (момент атаки внешнего стимула) до 600–800 мс, вплоть до 1 с. Таким образом, сигнал при частоте дискретизации 100 Гц и наличии 64 электродов и интервале в 1 с насчитывает 6 400 отсчетов по времени.

Набор данных

В данной работе мы использовали набор данных с соревнований по ИМК (VCI Competition III), организованных группой Berlin VCI. Данные для соревнования были предоставлены научной группой по ИМК университета г. Грац (Австрия).

Набор данных представляет собой сигналы ЭЭГ, записанные с применением системы VCI 2000 [2] и использованием 64 электродов при частоте дискретизации 240 Гц. Данные были предобработаны частотным фильтром с пропускающим диапазоном 0,1–60 Гц.

Набор данных был записан в ходе эксперимента по вводу текста на основе парадигмы P300 от двух пользователей. Рассмотрим подробнее процедуру эксперимента. Пользователю предъявлялась матрица символов размером 6×6 (рис. 2). Пользователь должен был фокусироваться на желаемой букве. Все строки и колонки матрицы поочередно вспыхивали в случайном порядке. Двум из 12 вспышек соответствовал желаемый символ (строка и колонка). В момент вспышки желаемых символов в электроэнцефалограмме пользователя регистрировался компонент P300.

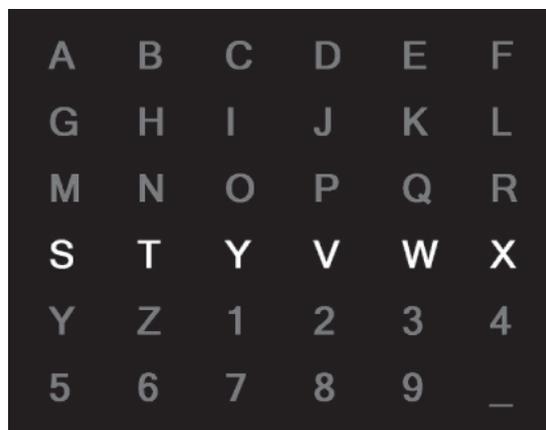


Рис. 2. Матрица символов для набора текста с использованием ИМК на основе P300

Подсветка строк и колонок производится согласно следующей процедуре. В начальный момент времени матрица отображалась без подсветки символов в течение 2,5 секунд. Затем каждая строка и колонка подсвечивалась в течение 100 мс. Интервал между вспышками – 75 мс. Такая процедура повторялась 15 раз для каждого символа. Пауза между символами – 2,5 секунды.

Набор данных содержит две выборки – обучающую и тестовую. Обучающая выборка состоит из 100 букв, тестовая – из 85. Таким образом, для каждого участника эксперимента было записано 185 букв.

Методы извлечения признаков

Использование исходного сигнала

Наиболее простым и очевидным методом анализа сигнала является использование его в исходном виде, но данный подход обладает рядом недостатков. Во-первых, если использовать исходный сигнал без предварительного извлечения признаков, то размерность пространства данных будет очень высока, что ухудшает работу классификаторов. Во-вторых, исходный сигнал содержит избыточную информацию, которая также ухудшает качество классификации. Избыточная информация содержится как во временном измерении, так и в пространстве электродов. В-третьих, часть исходного сигнала практически не содержит дискриминативной информации, что также приводит к ухудшению точности классификации. Это актуально как для временного пространства, так и для пространства электродов. Например, сигнал с 0–50 мс и с 800–1000 мс содержит меньше всего дискриминативной информации.

Усреднение сигнала

Альтернативой использования исходного сигнала является усреднение сигнала, то есть замена нескольких последовательных значений амплитуд сигнала их средним значением. Это позволяет сохранить форму сигнала, при этом устранив высокочастотные колебания и уменьшив количество значений амплитуд сигнала. В некоторых случаях, например при классификации представляемых движений, такой подход неприменим, так как в высокочастотных колебаниях содержится значимая для этой задачи информация. В случае компонента Р300 для детекции пика в районе 300 мс важна именно форма сигнала, поэтому усреднение дает положительные результаты.

Для усреднения сигнала применяется оконная функция, в рамках которой происходит нахождение среднего значения сигнала, затем исходный сигнал заменяет-

ся вычисленными средними значениями. Оконная функция может применяться как с шагом равным размеру окна, так и с произвольным шагом, например равным половине окна. Во втором случае окна перекрываются между собой, что позволяет сохранить больше информации в сигнале, добавив таким образом некоторую избыточность. Также возможен вариант не прямоугольной оконной функции, а взвешенной, например треугольной.

Метод главных компонент

Метод главных компонент (Principle Component Analysis, PCA) позволяет снизить размерность исходного вектора данных на основе проекции исходного пространства данных в пространство, составленное из собственных векторов, упорядоченных по соответствующим собственным числам. Первые n проекций представляют собой наиболее значимые компоненты, имеющие наибольшую дисперсию. Соответственно, снизить размерность исходного пространства можно используя первые n компонент. Математически это можно выразить следующим образом [7]:

Пусть \mathbf{X} – входной сигнал в виде матрицы размерности $n \times m$, где n – число измерений сигнала, m – число отсчетов по времени в каждом измерении. Пусть \mathbf{R} – ковариационная матрица размерности $m \times m$, определяемая выражением

$$\mathbf{R} = E[\mathbf{X}^T \mathbf{X}], \quad (1)$$

где E – математическое ожидание.

Пусть λ – вектор размерности m , состоящий из собственных чисел матрицы \mathbf{R} , а \mathbf{Q} – матрица размерности $m \times m$, состоящая из собственных векторов матрицы \mathbf{R} , соответствующих собственным числам λ . Собственные вектора являются ортогональными, поэтому, выполнив проекцию исходных данных на пространство собственных векторов, получаем матрицу данных, компоненты которой являются некоррелированными:

$$\hat{\mathbf{X}} = \mathbf{X}\mathbf{Q}. \quad (2)$$

Тем самым мы осуществили переход в новое пространство собственных векторов матрицы \mathbf{R} , собственные же значения матрицы \mathbf{R} выражают дисперсии данных по соответствующим собственным векторам. Чем больше дисперсия, тем более значимым является собственный вектор. Упорядочив собственные значения λ по убыванию, так чтобы $\lambda_1 > \lambda_2 > \dots > \lambda_n$ и переупорядочив соответственно собственные вектора \mathbf{q}_i матрицы \mathbf{Q} , можно снизить размерность исходного пространства, выбрав первые l векторов, которые будут отражать наиболее

значимые компоненты данных. Это можно записать в виде

$$\hat{\mathbf{X}}_l = \mathbf{X}\mathbf{Q}_l, \quad (3)$$

где \mathbf{Q}_l – матрица из l собственных векторов ($l < n$), которые упорядочены по убыванию соответствующих собственных значений; $\hat{\mathbf{X}}_l$ – l главных компонент исходных данных \mathbf{X} .

Более подробное описание метода главных компонент приведено в [7].

Выбор электродов

Как известно, головной мозг делится на несколько зон в зависимости от функционального назначения. Поэтому целесообразно производить отбор электродов для регистрации данных при выполнении той или иной задачи. В частности, обработке визуальной информации соответствует затылочная часть коры головного мозга.

В данной работе мы используем именно визуальные стимулы, поэтому представляется целесообразным использование Fz, Pz, Cz, Oz, P3, C3, P4, C4, PO7 и PO8 электродов по классификации 10–20 [8].

Также уменьшение числа используемых электродов приводит к снижению размерности исходного пространства данных, что положительно сказывается на результатах классификации при условии сохранения значимой информации. Так как сигналы соседних электродов сильно коррелированы, то значительных потерь информации можно избежать при правильном выборе электродов.

Методы классификации сигнала

Машина опорных векторов

Машина опорных векторов – метод классификации, который разделяет классы посредством максимизации расстояния между разделяющей классы гиперплоскостью и объектами этих классов, с помощью построения так называемых линейных векторов, при этом образуется зазор между классами максимально возможной ширины. Метод был предложен Вапником и Червоненкисом [3].

Пусть имеются два линейно разделимых класса. Необходимо найти гиперплоскость, которая разделит эти два класса оптимально. Оптимальной гиперплоскостью будем считать ту гиперплоскость, которая максимизирует расстояние от нее до ближайшей точки обучающей выборки.

Разделяющая гиперплоскость имеет вид

$$\mathbf{w}\mathbf{x} - b = 0, \quad (4)$$

где \mathbf{w} – перпендикуляр к разделяющей гиперплоскости.

Параметр $\frac{b}{\|\mathbf{w}\|}$ равен расстоянию от гиперплоскости до начала координат [3]. Положим единичный зазор по обе стороны от разделяющей гиперплоскости, эти гиперплоскости будут параллельны разделяющей и иметь вид

$$\mathbf{w}\mathbf{x} - b = 1, \quad (5)$$

$$\mathbf{w}\mathbf{x} - b = -1. \quad (6)$$

Расстояние между ними будет равняться $\frac{2}{\|\mathbf{w}\|}$, такие гиперплоскости называются опорными. Ближайшие точки к опорным гиперплоскостям (или лежащие на них) называются опорными векторами.

Построение классификатора состоит в отыскании разделяющей гиперплоскости с учетом выполнения требования, чтобы все точки лежали по разные стороны опорных гиперплоскостей. Это может быть записано в виде

$$\begin{cases} \mathbf{w} \cdot \mathbf{x}_i - b \geq 1, c_i = 1; \\ \mathbf{w} \cdot \mathbf{x}_i - b \leq -1, c_i = -1 \end{cases} \quad (7)$$

или

$$c_i(\mathbf{w} \cdot \mathbf{x}_i - b) \geq 1; 1 < i < n, \quad (8)$$

где n – число объектов обучающей выборки.

Проблема построения разделяющей гиперплоскости сводится к минимизации $\|\mathbf{w}\|$ при условии (8):

$$\begin{cases} \|\mathbf{w}\|^2 \rightarrow \min; \\ c_i(\mathbf{w} \cdot \mathbf{x}_i - b) \geq 1, 1 < i < n. \end{cases} \quad (9)$$

Решение данной задачи может быть найдено при помощи методов квадратичной оптимизации. Более подробное описание изложенного метода приведено в [3].

Линейный дискриминантный анализ

Дискриминантный анализ проецирует пространство данных в пространство более низкой размерности с учетом минимизации дисперсии классов и максимизации межклассовых расстояний.

Математически это можно выразить следующим образом:

Пусть \mathbf{x} – вектор объектов; \mathbf{w} – разделяющая прямая, тогда результат линейной классификации может быть выражен как [1]:

$$y = \mathbf{w}^T \mathbf{x}. \quad (10)$$

Пусть \mathbf{m}_1 – центр масс первого класса; \mathbf{m}_2 – центр масс второго класса. Для максимизации расстояния между классами будем

проектировать классы на вектор, соединяющий центры масс:

$$\mathbf{w} \propto \mathbf{m}_2 - \mathbf{m}_1. \quad (11)$$

Выразим дисперсии внутри классов:

$$s_1^2 = \sum_{n \in C_1} (y_n - m_1), \quad (12)$$

$$s_2^2 = \sum_{n \in C_2} (y_n - m_2). \quad (13)$$

И потребуем минимизации дисперсии, что может быть выражено через максимизацию целевой функции Фишера:

$$J(\mathbf{w}) = \frac{(m_2 - m_1)^2}{s_1^2 + s_2^2}. \quad (14)$$

Числитель дроби максимизирует расстояние между классами, а знаменатель минимизирует дисперсию внутри классов. Выполнив оптимизацию $J(\mathbf{w})$, получаем искомую разделяющую прямую \mathbf{w} . Более подробное описание линейного дискриминантного анализа может быть найдено в [1].

Комитетные методы классификации

Комитетные методы классификации позволяют принимать решения о принадлежности объекта к тому или иному классу на основе использования нескольких классификаторов. Два основных способа построения таких комитетов (или ансамблей) классификаторов: бэггинг (bagging) и бустинг (boosting) [1].

Бэггинг заключается в обучении классификаторов на различных наборах данных, разбивая исходную обучающую выборку на несколько непересекающихся частей. Окончательное решение принимается путем усреднения ответов классификаторов, входящих в состав ансамбля.

В методе бустинга классификаторы обучаются последовательно. Обучение m -го классификатора зависит от результатов обучения $m - 1$ классификаторов. При обучении классификатора наибольшее внимание уделяется тем объектам в обучающей выборке, на которых предыдущие классификаторы допускали ошибки. После обучения ансамбля классификаторов окончательное решение принимается путем взвешенного голосования, причем вес классификаторов определяется на основе результатов обучения, то есть на основе степени доверия к классификатору.

Анализ результатов численных экспериментов

Исходный сигнал

В таблице представлены результаты классификации с использованием исходно-

го сигнала для полного и частичного набора электродов. Для получения более отчетливого отклика Р300 при тестировании результатов производилось усреднение сигнала по 15 попыткам для каждой буквы (см. описание набора данных). При обучении классификатора усреднение сигнала не производилось. Такой подход использовался для всех полученных результатов. Все последующие результаты представлены для первого субъекта в исходном наборе данных.

Как можно видеть, наилучшая точность 71 % была получена при использовании LDA в качестве классификатора и 10 электродов.

Результат классификации исходного сигнала (точность, %)

Кол-во электродов	Классификатор	
	LDA	SVM
64	41	68
10	71	13

Метод главных компонент

На рис. 3 приведены результаты тестирования с использованием метода главных компонент для двух классификаторов и двух наборов электродов. Наилучший результат 89 % был получен при использовании 300 главных компонент, полного набора электродов и LDA классификатора.

Усреднение сигнала

На рис. 4 приведена зависимость точности распознавания от количества диапазонов, в рамках которых производилось усреднение сигнала. Из рисунка видно, что LDA значительно превосходит SVM, наилучшая точность 90 % была получена при использовании LDA классификатора и 14 диапазонов усреднения. Результаты представлены только для набора из 10 электродов, по причине низкой производительности классификаторов на большом числе признаков.

Комитетные методы классификации

Далее представлены результаты с использованием комитетных методов классификации и усреднения сигнала. На рис. 5 изображена зависимость точности распознавания от числа классификаторов в ансамбле. В ходе экспериментов было проанализировано использование различного числа диапазонов усреднения, на рис. 6 отражены лучшие результаты. Для LDA использовалось 20 диапазонов, SVM-14. Данные представлены для набора из 10 электродов.

Для построения ансамбля классификаторов мы использовали метод бэггинг. Так как тестовая выборка состояла из 85 букв, то все данные были разбиты на части по 1, 3, 5, 10, 15, 20, 25, 40 букв в каждой. Были

получены ансамбли, состоящие из 85, 29, 17, 9, 6, 5, 4, 3 классификаторов соответственно, каждый из них обучался на своей подвыборке, затем результат классификаторов усреднялся. В случае если общее число букв не делится на число классификаторов

нацело, то последний классификатор обучался на подвыборке меньшего размера, полученной как остаток от деления. Наилучшая точность 93% была получена при построении ансамбля из 9-ти LDA классификаторов.

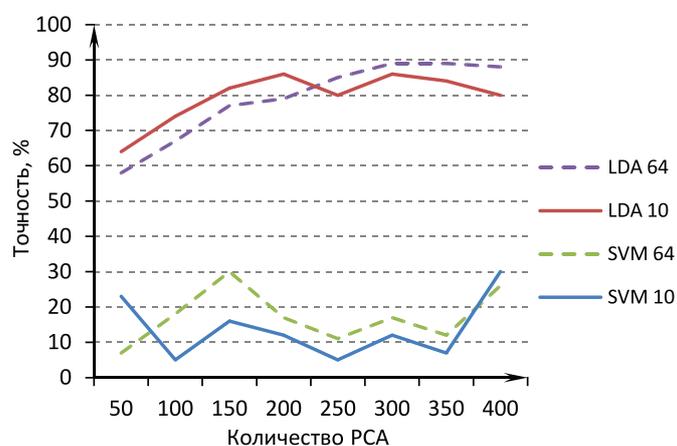


Рис. 3. Зависимость точности распознавания от количества главных компонент

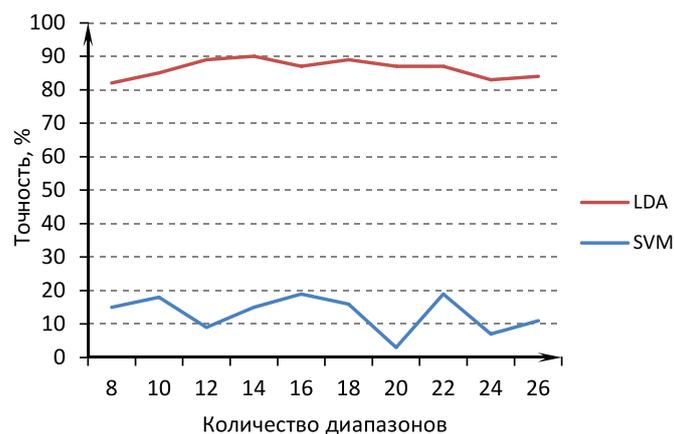


Рис. 4. Зависимость точности распознавания с применением усреднения сигнала (10 электродов)

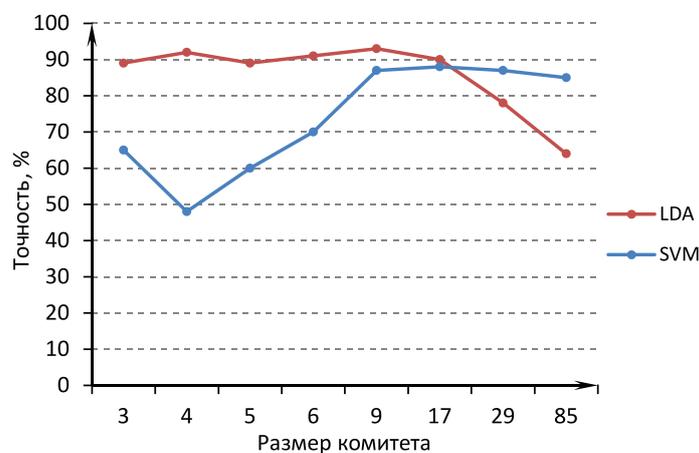


Рис. 5. Зависимость точности распознавания от размера комитета

По результатам экспериментов наилучшая точность и устойчивость была получена при использовании комбинации методов предобработки. Метод главных компонент был применен к пространству 64 электродов, тем самым снижая размерность исходного пространства, затем мы применили усреднение сигнала во времени с использованием 20 диапазонов и шагом перекрытия 3. Также мы использовали комитетный метод с 9 классификаторами. Лучшая точность 100% была получена при использовании LDA и 40 главных компонент. На рис. 4 представлена зависимость точности классификации от количества используемых главных компонент. Для сравнения показаны результаты с использованием SVM.

Во-вторых, использование методов снижения размерности, таких как метод главных компонент или усреднение сигнала, повышает точность, в лучшем случае до 90%.

В-третьих, использование LDA классификатора позволяет получить более высокую точность в сравнении с SVM. Также LDA лучше справляется с пространствами более высокой размерности в данной задаче, нежели SVM.

В-четвертых, использование комитетных методов классификации также повышает точность распознавания. В лучшем случае удалось достичь точности 93% при использовании 9-ти LDA классификаторов, 20 диапазонов усреднения и 10 электродов.

По итогам экспериментов наилучшая

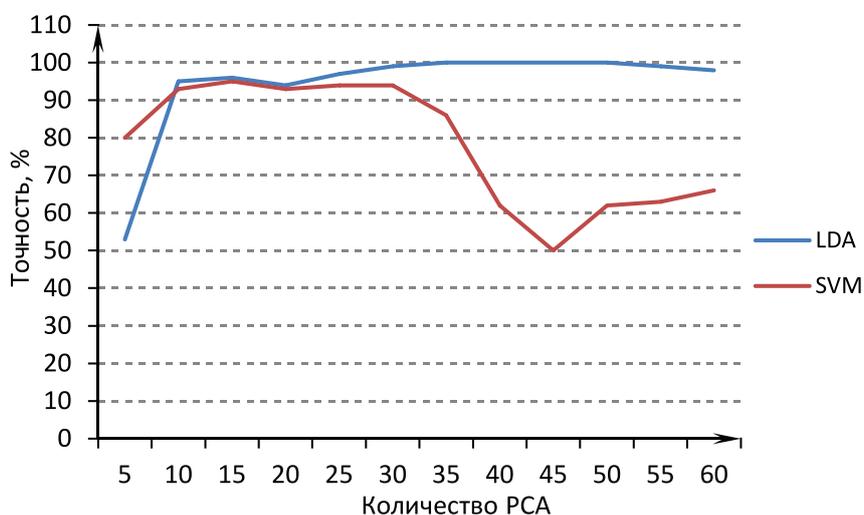


Рис. 6. Зависимость точности распознавания от количества PCA с применением усреднения сигнала

Разработанный метод с данными параметрами был применен также и для второго субъекта в наборе данных, для него была достигнута точность распознавания 98%.

Выводы

В данной статье была рассмотрена задача обнаружения компонента P300 в ЭЭГ сигнале. Были проанализированы различные способы извлечения признаков сигнала, возможность выбора электродов и применения разных классификаторов. По итогам проведенных экспериментов можно сделать следующие выводы:

Во-первых, из полученных результатов видно, что использование исходного сигнала без снижения размерности дает невысокую точность. Лучшая точность равная 71% достигается при использовании LDA и 10 электродов.

точность была достигнута на 64 электродах при использовании комбинации методов: главных компонент (примененного к пространству электродов), усреднения с перекрытием диапазонов и комитета из LDA классификаторов. Точность классификации составила 100 и 98% для первого и для второго субъекта соответственно.

Список литературы/ References

1. Bishop C.M. Pattern Recognition and Machine Learning / C.M. Bishop. – Springer, 2006.
2. Blankertz B. et al The BCI competition 2003: Progress and perspectives in detection and discrimination of EEG single trials // IEEE Transactions on Biomedical Engineering. – 2004. – № 6 (51). – P. 1044–1051.
3. Cortes C., Vapnik V. Support-vector networks // Machine learning. – 1995. – № 3 (20). – P. 273–297.

4. Donchin E., Spencer K.M., Wijesinghe R. The mental prosthesis: Assessing the speed of a P300-based brain-computer interface // IEEE Transactions on Rehabilitation Engineering. – 2000. – № 2 (8). – P. 174–179.
5. Edlinger G. et al Brain-computer interfaces for goal oriented control of a virtual smart home environment // 2009 4th International IEEE/EMBS Conference on Neural Engineering, NER '09. – 2009. – P. 463–465.
6. Farwell L.A., Donchin E. Talking off the top of your head: toward a mental prosthesis utilizing event-related brain potentials // Electroencephalography and Clinical Neurophysiology. – 1988. – № 6 (70). – P. 510–523.
7. Haykin, S. «Neural networks: A comprehensive approach», IEEE Computer Society Press, 1999.
8. Jasper H. Report of the committee on methods of clinical examination in electroencephalography // Electroencephalography and Clinical Neurophysiology. – 1958. – № 10. – P. 370–375.
9. LaFleur K. et al Quadcopter control in three-dimensional space using a noninvasive motor imagery-based brain-computer interface. // Journal of neural engineering. – 2013. – № 4 (10). – P. 046003.
10. Marshall D. et al Games, gameplay, and BCI: The state of the art // IEEE Transactions on Computational Intelligence and AI in Games. – 2013. – № 2 (5). – P. 82–99.
11. Müller-Putz G. R., Pfurtscheller G. Control of an electrical prosthesis with an SSVEP-based BCI // Biomedical Engineering, IEEE Transactions on. – 2008. – T. 55. – №. 1. – P. 361–364.
12. Rakotomamonjy A., Guigue V. BCI competition III: dataset II-ensemble of SVMs for BCI P300 speller. // IEEE transactions on biomedical engineering. – 2008. – № 3 (55). – P. 1147–54.
13. Riechmann H., Finke A., Ritter H. Hierarchical Codebook Visually Evoked Potentials for fast and flexible BCIs 2013. // Engineering in Medicine and Biology Society (EMBC), 2013 35th Annual International Conference of the IEEE. – IEEE, 2013. – P. 2776–2779.
14. Vidal J.J. Toward direct brain-computer communication. // Ann. rev. of biophysics and bioeng. – 1973. – P. 157–80.
15. Wolpaw J.R. et al Brain-computer interfaces for communication and control. // Clinical neurophysiology: official journal of the International Federation of Clinical Neurophysiology. – 2002. – № 6 (113). – P. 767–91.