

# Применение интерфейса мозг-компьютер для распознавания маммограмм с патологиями

В.В. Сулимова<sup>1</sup>, О.В. Красоткина<sup>2</sup>, С. Бухонов<sup>3</sup>, В.В. Моттль<sup>4</sup>, Д. Уиндридж<sup>5</sup>

<sup>1</sup>Тулский государственный университет, Ленина 92, Тула, Россия, 300012

<sup>2</sup>Markov Processes International, Springfield Ave 475, Suite 401, Summit, NJ 07901

<sup>3</sup>МФТИ, Институтский пер. 9, Долгопрудный, Россия, 141701

<sup>4</sup>Вычислительный центр им. А.А. Дородницына ФИЦ ИУ РАН, Вавилова 44/2, Москва, Россия, 119333

<sup>5</sup>Middlesex University, London, UK

**Аннотация.** Несколько лет назад нашими партнерами из Великобритании была впервые предложена технология обнаружения маммограмм с патологиями, основанная на анализе мозговой активности эксперта в процессе просмотра быстро предъявляемых ему изображений маммограмм. Идея построения данной технологии основывается на факте, что сигналы, генерируемые головным мозгом при узнавании заданных объектов (в данном случае это маммограммы с патологиями) обычно содержат отклик, которого не наблюдается при просмотре других объектов. В этой работе мы улучшаем данную технологию, во-первых, применяя специальную предварительную обработку сигналов активности мозга, поступающих с 66 электродов, закрепленных на голове испытуемых, пока они просматривают изображения маммограмм, а во-вторых, применяя метод опорных векторов с двумя специальными видами регуляризации, учитывающими особенности рассматриваемой задачи, что позволяет значительно улучшить качество обнаружения маммограмм с отклонениями.

## 1. Введение


Построение интерфейса "мозг-компьютер" [1] основано на регистрации электрической активности различных участков головного мозга в виде электроэнцефалограмм (ЭЭГ) и последующем их анализе [2, 3]. Основным направлением применения данного интерфейса является реабилитационная медицина. На его основе ведутся разработки, позволяющие парализованным или утратившим конечности людям вернуть способность к движению.

Однако в последнее время появилась тенденция применения интерфейса "мозг-компьютер" в других областях [4], в том числе для обнаружения разнообразных целевых объектов на изображениях [5-7]. В частности, несколько лет назад нашими партнерами из Великобритании была впервые предложена технология обнаружения маммограмм с патологиями, основанная на анализе мозговой активности эксперта в процессе просмотра быстро предъявляемых ему изображений маммограмм [7].

Идея построения данной технологии основывается на факте, что сигналы, генерируемые головным мозгом при узнавании заданных объектов (в данном случае это маммограммы с патологиями) обычно содержат отклик, которого не наблюдается при просмотре других объектов [8]. Такая технология имеет высокую пропускную способность, которая в данном случае обусловлена быстротой работы человеческого мозга, способного за доли секунды узнать

заданный объект, и дает возможность существенно более эффективного использования уникального опыта высококвалифицированных экспертов [7]. Именно на это практическое приложение ориентирована данная работа.

На рисунке 1а показан процесс снятия электроэнцефалограмм в процессе просмотра изображений маммограмм, на рисунках 1б и 1в - примеры целевых и нецелевых изображений маммограмм, соответственно.



**Рисунок 1.** а) Процесс снятия электроэнцефалограмм, б) пример целевого объекта (маммограммы с патологией), в) пример нецелевого объекта (маммограммы без патологий).

Основная проблема применения данной технологии заключается в сложности распознавания на ЭЭГ сигналах откликов, соответствующих узнаванию заданных объектов. Решение данной проблемы требует привлечения эффективных методов обработки сигналов и машинного обучения и является областью активных исследований [9].

Одна из сложностей заключается в формировании подходящего признакового пространства, которое удовлетворяло бы гипотезе компактности [10], лежащей в основе любой техники машинного обучения. В некоторых работах пытаются извлечь полезные признаки, характеризующие особенности изменения ЭЭГ-сигнала во времени [11-13] [13]. Но в большинстве работ используются в качестве признаков используются отсчеты ЭЭГ-сигналов [14]. Это оказывается возможным, поскольку, согласно рассматриваемой технологии быстрого последовательного предъявления изображений, полный ЭЭГ-сигнал подразделяется на фрагменты одинаковой длины, соответствующие просмотру одного изображения.

Однако из-за большого количества отсчетов в каждом фрагменте (как правило, около 1000) и достаточно большого числа электродов (например, 66 в [7]) размерность признакового пространства оказывается слишком высокой, что приводит к переобучению (низкой обобщающей способности решающих правил распознавания). Для сокращения размерности признакового пространства используются различные методы, такие как метод главных компонент [15], независимый компонентный анализ [16], поиск оптимальной линейной комбинации данных с разных электродов [9] и другие [14]. Но все эти методики применяются до начала процесса обучения и, соответственно, не учитывают особенностей конкретной задачи обучения. Единственное исключение составляет применение специальной пространственной фильтрации сигналов [17], максимизирующей разницу между целевыми и нецелевыми сигналами, но и такой подход учитывает информацию о задаче не полностью и, соответственно, является менее предпочтительным по сравнению с отбором признаков непосредственно в процессе обучения.

В данной статье распознавание сигналов, содержащих отклики на узнавание целевых изображений (целевых сигналов) осуществляется на основе метода опорных векторов (SVM) [18], который является удобным, эффективным и проверенным инструментом распознавания образов в линейных пространствах. Но для того, чтобы преодолеть указанную проблему переобучения, мы предлагаем использовать два специальных вида регуляризации, которые выражают априорные предпочтения в отношении решения, обусловленные особенностями решаемой задачи, и снабжают традиционный SVM возможностью автоматического выбора наиболее информационных признаков. Совместно со специальной предварительной обработкой сигналов ЭЭГ применение предлагаемых способов регуляризации позволяет повысить качество распознавания целевых и нецелевых сигналов.

## 2. Классификация ЭЭГ сигналов как двухклассовая задача распознавания

Поскольку просмотр экспертом целевых (с патологией) и нецелевых (без патологий) изображений маммограмм обычно приводит к разной мозговой активности, классификация зарегистрированных ЭЭГ-сигналов в данном случае заключается в обнаружении того, содержит ли некоторый фрагмент ЭЭГ отклик на целевое изображение или нет. С математической точки зрения такая задача является двухклассовой задачей распознавания образов.

Любой фрагмент ЭЭГ, полученный с некоторого электрода, представляет собой дискретный сигнал  $\mathbf{x} = [x_1, \dots, x_m] \in R^m$ . Для одновременного использования информации с двух или более электродов мы объединяем соответствующие сигналы, выполняя их конкатенацию, поэтому представление объекта остается вектором. В этой связи мы будем использовать одно и то же обозначение для сигналов с одного и нескольких электродов и давать пояснения о способе формировании сигнала в случае необходимости.

Поскольку все сигналы имеют одинаковую длину, его элементы можно рассматривать как признаки объектов.

Пусть  $(X, Y) = \{\mathbf{x}_j, y_j\}, j = 1, \dots, N$  - обучающая совокупность сигналов ЭЭГ  $\mathbf{x}_j \in R^m$ , каждый из которых снабжен меткой класса  $y_j \in \{+1; -1\}$ . При этом  $y_j = +1$  означает, что сигнал  $\mathbf{x}_j$  зарегистрирован при просмотре целевого изображения (маммограммы с патологией) и  $y_j = -1$ , соответственно, - не целевого (маммограммы без патологии).

Цель обучения состоит в том, чтобы построить решающее правило распознавания в виде некоторой функции  $\hat{y}(\mathbf{x})$ , такой, чтобы для любого нового сигнала  $\mathbf{x} \notin X$  она позволяла определить, содержит ли  $\mathbf{x}$  отклик на целевое изображение ( $\hat{y}(\mathbf{x}) = +1$ ) или нет ( $\hat{y}(\mathbf{x}) = -1$ ).

## 3. Методы двухклассового распознавания ЭЭГ сигналов

### 3.1. Традиционный метод опорных векторов (SVM)

Метод опорных векторов (SVM) [18] является одним из наиболее удобных, эффективных и проверенных инструментов для распознавания образов в линейном пространственном пространстве.

В этом случае решающее правило распознавания строится в виде оптимальной линейной разделяющей гиперплоскости

$$d(\mathbf{x}; \mathbf{a}, b) = \mathbf{a}^T \mathbf{x} + b \begin{cases} \geq 0 \Rightarrow \hat{y}(\mathbf{x}) = +1, \\ < 0 \Rightarrow \hat{y}(\mathbf{x}) = -1, \end{cases}$$

которая полностью определяется направляющим вектором  $\mathbf{a} = [a_1, \dots, a_m]^T$  и смещением вдоль него  $b$ . Оптимальная гиперплоскость призвана как можно лучше разделять объекты положительного и отрицательного классов, но может допускать ошибки классификации  $\delta_j$  для некоторых объектов обучения  $\mathbf{x}_j$ :

$$\begin{cases} \sum_{i=1}^m a_i^2 + \tilde{N} \sum_{j=1}^N \delta_j \rightarrow \min(\mathbf{a}, b, \delta), \\ y_j (\sum_{i=1}^m a_i x_{ij} - b) \geq 1 - \delta_j, \quad j = 1, \dots, N, \\ \delta_j \geq 0, \quad j = 1, \dots, N, \end{cases} \quad (1)$$

где параметр  $C$  определяет степень влияния ошибочных классификаций объектов обучения на положение разделяющей гиперплоскости.

### 3.2. Регуляризованный SVM с требованием гладкости решающего правила

Следует отметить, что, поскольку признаками ЭЭГ-сигналов в данном случае являются их отсчеты, то на них естественным образом оказывается задано отношение порядка.

В таком случае естественным представляется отдавать предпочтение таким положениям разделяющей гиперплоскости, для которых ее коэффициенты, соответствующие соседним

признакам, были бы близки друг к другу, т. е. выполнялось бы условие гладкости решающего правила. Введение такой априорной информации об искомой гиперплоскости позволяет построить более надежное решение, увеличивая его обобщающую способность.

Соответствующий тип регуляризации был впервые предложен нами в [19]. Для того, чтобы наделить SVM способностью выбирать сглаженное решающее правило, мы добавляем в критерий оптимизации (1) специальный регуляризующий член  $\sum_{i=2}^m (a_i - a_{i-1})^2$ . Таким образом, модифицированная задача SVM с соответствующей регуляризацией может принимать вид:

$$\begin{cases} \sum_{i=1}^m a_i^2 + \gamma \sum_{i=2}^m (a_i - a_{i-1})^2 + \tilde{N} \sum_{j=1}^N \delta_j \rightarrow \min(\mathbf{a}, b, \delta), \\ y_j (\sum_{i=1}^m a_i x_{ij} - b) \geq 1 - \delta_j, \quad j = 1, \dots, N, \\ \delta_j \geq 0, \quad j = 1, \dots, N, \end{cases} \quad (2)$$

где  $\gamma > 0$  - коэффициент гладкости решающего правила, определяющий степень влияния введенного регуляризующего члена.

Решение задачи (2) может быть легко найдено методом градиентного спуска.

Такой подход может быть наиболее полезен для распознавания ЭЭГ-сигналов, полученных с одного отдельного электрода.

### 3.3. Регуляризованный SVM с возможностью выбора наиболее информативных отсчетов ЭЭГ

Очевидно, что несколько электродов дают нам больше информации, чем один. С другой стороны, увеличение количества электродов приводит к увеличению количества признаков, усугублению проблемы переобучения и, соответственно, уменьшению обобщающей способности решающего правила. Но в то же время очевидно, что не вся информация с электродов может быть полезной для принятия решения о наличии или отсутствии отклика на узнавание целевого изображения. Таким образом, для того, чтобы повысить качество распознавания, необходим инструмент для автоматического выбора наиболее информативных признаков. Именно для этого мы вводим второй тип регуляризации SVM.

Предлагаемый тип регуляризации является частным случаем обобщенной вероятностной постановки SVM [20]. Он был впервые предложен нами в [21] и затем успешно применен для распознавания мембранных белков [22].

Изначально данный тип регуляризации был предложен для случая мультимодального распознавания, где каждая модальность представлена некоторой потенциальной функцией [21, 22]. В данной же работе мы переформулируем этот подход для случая распознавания в линейном признаковом пространстве. Полученный подход мы называем методом опорных векторов с контролируемой селективностью признаков (Selective Features Support Vector Machines, SFSVM).

Оптимизационная задача для нахождения оптимальной разделяющей гиперплоскости для данного типа регуляризации может быть записана в виде:

$$\begin{cases} J_{SFSVM}(a_1, \dots, a_m, b, \delta_1, \dots, \delta_N, C, \mu) = \\ \sum_{i=1}^m q(a_i | \mu) + C \sum_{j=1}^N \delta_j \rightarrow \min(\mathbf{a}, b, \delta), \\ q(a_i | \mu) = \begin{cases} 2\mu |a_i| & \text{if } |a_i| \leq \mu, \\ \mu^2 + a_i^2 & \text{if } |a_i| > \mu, \end{cases} \\ y_j (\mathbf{a}^T \mathbf{x}_j + b) \geq 1 - \delta_j, \quad \delta_j \geq 0, \quad j=1, \dots, N. \end{cases} \quad (3)$$

Таким образом, предлагаемый критерий обучения представляет собой обобщенный вариант классического SVM, который реализует принцип отбора информативных признаков.

Порог  $\mu$  называется здесь «селективностью», поскольку он регулирует способность критерия принимать решения по отбору признаков. Когда  $\mu=0$ , критерий эквивалентен классическому SVM (1) с минимальной возможностью отбора признаков. В то же время значения, намного превышающие 0, эквивалентны Lasso SVM [23] с возрастающей селективностью, которая растет до полного подавления всех признаков.

Решение задачи (3) эквивалентно решению  $(\hat{\xi}_i \geq 0, i \in I = \{1, \dots, m\}, \hat{\lambda}_j \geq 0$ , двойственной задачи

$$\begin{cases} L(\lambda_1, \dots, \lambda_N | C, \mu) = \sum_{j=1}^N \lambda_j - \sum_{i \in I} \xi_i / 2 \rightarrow \max(\lambda_1, \dots, \lambda_N), \\ \xi_i \geq 0, \xi_i \geq \sum_{j=1}^N \sum_{l=1}^N y_j y_l x_{ij} x_{il} \lambda_j \lambda_l - \mu^2, i \in I = \{1, \dots, m\}, \\ \sum_{j=1}^N y_j \lambda_j, 0 \leq \lambda_j \leq C/2, j = 1, \dots, N, \end{cases}$$

и может быть выражена в виде

$$\begin{cases} \hat{a}_i = \sum_{j: \hat{\lambda}_j > 0} y_j \hat{\lambda}_j x_i(\omega_j), & i \in I^+ = \left\{ i \in I: \sum_{j=1}^N \sum_{l=1}^N y_j y_l x_{ij} x_{il} \hat{\lambda}_j \hat{\lambda}_l > \mu^2 \right\}, \\ \hat{a}_i = \hat{\eta}_i \sum_{j: \hat{\lambda}_j > 0} y_j \hat{\lambda}_j x_i(\omega_j), & i \in I^0 = \left\{ i \in I: \sum_{j=1}^N \sum_{l=1}^N y_j y_l x_{ij} x_{il} \hat{\lambda}_j \hat{\lambda}_l = \mu^2 \right\}, \\ \hat{a}_i = 0, & i \in I^- = \left\{ i \in I: \sum_{j=1}^N \sum_{l=1}^N y_j y_l x_{ij} x_{il} \hat{\lambda}_j \hat{\lambda}_l < \mu^2 \right\}, \end{cases}$$

где  $\{0 \leq \eta_i \leq 1, i \in I^0\}$  - дополнительно вычисляемые коэффициенты путем решения СЛАУ [21].

Следует отметить, что критерий (3), в отличие от других известных критериев отбора признаков [23, 24], явно разбивает весь набор признаков на два подмножества: опорные признаки  $I^+ \cup I^0$  (которые будут участвовать в результирующей разделяющей гиперплоскости) и признаки, которые будут исключены  $I^-$ .

В результате оптимальная разделяющая гиперплоскость, определяемая решением задачи обучения SFSVM (3), может быть выражена в виде

$$\sum_{j: \hat{\lambda}_j > 0} y_j \hat{\lambda}_j \left( \sum_{i \in I^+} x_{ij} x_i + \sum_{i \in I^0} \eta_i x_{ij} x_i \right) + b \geq 0,$$

где числовые параметры  $\{0 \leq \eta_i \leq 1, i \in I^0; b\}$  являются решениями задачи линейного программирования:

$$\begin{cases} 2\mu^2 \sum_{i \in I^0} \eta_i + C \sum_{j=1}^N \delta_j \rightarrow \min(\eta_i, i \in I^0; b; \delta_1, \dots, \delta_N), \\ \sum_{i \in I^0} \left( \sum_{l=1}^N y_j y_l x_{ij} x_{il} \lambda_l \right) \eta_i + y_j b + \delta_j \geq 1 - \sum_{i \in I^+} \left( \sum_{l=1}^N y_j y_l x_{ij} x_{il} \lambda_l \right), \\ \delta_j \geq 0, j = 1, \dots, N, 0 \leq \eta_i \leq 1, i \in I^0. \end{cases}$$

Таким образом, предлагаемый подход обладает существенным качественным преимуществом - он явно указывает на дискретное подмножество опорных признаков, в отличие от других методов, которые присваивают каждому признаку положительный вес (хотя, возможно, очень маленький). Соответственно, предлагаемый подход является более экономичным по памяти и, кроме того, параметр "селективность" позволяет осуществлять управление степенью жесткости при отборе признаков.

#### 4. Распознавание маммограмм с патологией

##### 4.1. Описание данных

В данной статье мы показываем, что предложенные методы регуляризации позволяют повысить качество распознавания целевых ЭЭГ, зарегистрированных при просмотре маммограмм с патологиями.

В этом исследовании мы используем те же данные, что и в [7], в котором содержится подробная информация о методологии сбора данных и проведения эксперимента.

В рамках данной работы используются фрагменты ЭЭГ одного эксперта по маммографии, зарегистрированные при помощи 66 электродов при просмотре им серии маммограмм.

Для каждого из 66 электродов вырезанные фрагменты имеют следующие характеристики:

1) длина фрагмента составляет 1100 отсчетов, что соответствует просмотру 11 маммограмм в течение 100 мс каждая,

2) для фрагментов, относящихся к нецелевому классу, ни одно из 11 изображений маммограмм не содержит признаков патологических изменений;

3) для фрагментов, относящихся к целевому классу, одно из 11 изображений маммограмм (случайное с 4 по 7) содержит признаки патологических изменений.

Сигналы, полученные с каждого из 66 электродов предварительно (перед нарезанием на фрагменты) были подвержены низкочастотной фильтрации с частотой среза 40Гц.

Всего по каждому электроду получено 755 фрагментов ЭЭГ. Эти фрагменты случайным образом разбиты на обучающее (98 целевых и 279 нецелевых объектов) и тестовое множество (98 целевых и 279 нецелевых объектов).

#### 4.2. Предварительная обработка сигналов

В рамках данной работы для повышения скорости и качества распознавания мы применяем 2 вида предварительной обработки фрагментов ЭЭГ: прореживание и сглаживание скользящим окном.

Пусть  $\mathbf{x} = (x_i \in R, i = 1, \dots, m)$ ,  $m = 1100$  - исходный фрагмент ЭЭГ.

Поскольку согласно теореме Котельникова [25] исходные сигналы являются избыточными, и могут быть прорежены вплоть до 12.5 раз без потери информации, то мы выполняем прореживание отсчетов каждого исходного фрагмента  $\mathbf{x}$  в  $step = 11$  раз, оставляя только 100 из 1100 отсчетов и получая таким образом новый сигнал  $\mathbf{x}' = (x'_i \in R, i = 1, \dots, m')$ ,  $m' = m / step = 1100 / 11 = 100$ . Прореживание позволяет сократить размерность признакового пространства, объем расходуемой памяти и количество вычислений.

Для уменьшения влияния шумовой составляющей мы осуществляем сглаживание скользящим окном ширины  $w = 11$ :

$$\begin{cases} x_i'' = \frac{1}{w} \sum_{k=i-\lfloor w/2 \rfloor}^{i+\lfloor w/2 \rfloor} x'_k, & i = \lfloor w/2 \rfloor + 1, \dots, m' - \lfloor w/2 \rfloor, \\ x_i'' = x'_{\lfloor w/2 \rfloor + 1}, & i < \lfloor w/2 \rfloor + 1, \quad x_i'' = x'_{m' - \lfloor w/2 \rfloor}, & i > m' - \lfloor w/2 \rfloor. \end{cases}$$

#### 4.3. Результаты экспериментального исследования

В первую очередь в ходе экспериментального исследования было проведено обучение распознаванию для каждого электрода в отдельности со сглаживанием и без сглаживания, а также с учетом требования гладкости решающего правила и без учета данного требования. Качество построенных решающих правил оценивалось значением площади под ROC-кривой (AUC), построенной по тестовой совокупности. При применении регуляризации первого типа, предъявляющей требование гладкости решающего правила, выбор коэффициента гладкости  $\gamma$  для каждого электрода осуществлялся автоматически по результатам скользящего контроля на обучающей совокупности. Полученные результаты приведены в таблице 1. Жирным выделен наилучший результат для каждого электрода.

Как видно из таблицы 1, в большинстве случаев наилучший результат достигается при одновременном применении сглаживания и регуляризации, учитывающей требование гладкости решающего правила, причем во многих случаях качество решающего правила оказывается существенно выше, чем в других рассматриваемых случаях. Кроме того, следует отметить, что для тех электродов, для которых наилучшим оказался вариант без сглаживания и(или) без регуляризации, качество решающего правила в основном является достаточно низким, т.е., как правило, это наблюдается для электродов, которые несут мало полезной информации для решения рассматриваемой задачи. В остальных случаях такой эффект может объясняться неподходящим значением ширины окна сглаживания, которая во всех случаях была принята равной 11 и не подбиралась для каждого электрода отдельно.

Помимо результатов для отдельных электродов таблица 1 содержит результаты для одновременного использования информации со всех 66 электродов. Из таблицы видно, что, как и ожидалось, качество решающего правила, построенного по всем электродам, оказывается хуже решающего правила, построенного по ряду отдельных электродов, что подтверждает наличие проблемы переобучения и необходимость сокращения размерности признакового пространства.

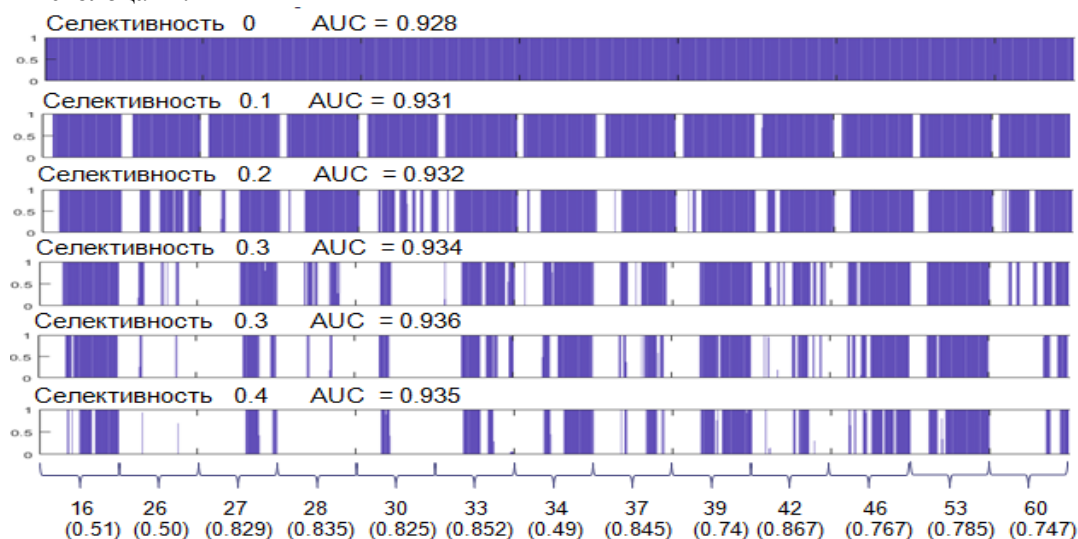
**Таблица 1.** Значения AUC для разных электродов с учетом и без учета сглаживания и требования гладкости решающего правила.

Сглаживание		-	-	+	+	Сглаживание		-	-	+	+
Требование гладкости	Требование гладкости	-	+	-	+	Требование гладкости	Требование гладкости	-	+	-	+
		1	0,6858	0,6855	0,657			<b>0,6985</b>	34	0,5012	<b>0,5036</b>
2	0,6431	0,6192	0,6009	<b>0,6611</b>	35	0,5012	<b>0,576</b>	0,5493	0,5558		
3	0,6644	0,6758	0,6308	<b>0,6901</b>	36	0,6348	0,6711	0,63	<b>0,6985</b>		
4	0,6683	0,6473	0,6411	<b>0,689</b>	37	0,7203	0,8257	0,7364	<b>0,8451</b>		
5	<b>0,6582</b>	0,6174	0,6124	0,6167	38	0,6085	0,696	0,6259	<b>0,6997</b>		
6	0,6425	0,6791	0,6292	<b>0,6806</b>	39	0,7062	0,6931	0,6811	<b>0,7431</b>		
7	<b>0,6091</b>	0,5954	0,5827	0,5816	40	<b>0,5897</b>	0,5857	0,5464	0,547		
8	0,6766	0,6778	0,6242	<b>0,6873</b>	41	0,6088	0,655	0,6291	<b>0,6742</b>		
9	0,5714	0,6161	0,5782	<b>0,6267</b>	42	0,7708	0,8584	0,7815	<b>0,8672</b>		
10	<b>0,6053</b>	0,555	0,5384	0,5746	43	<b>0,5378</b>	0,5366	0,5268	0,5518		
11	0,5509	0,5613	0,5724	<b>0,576</b>	44	0,545	0,5642	0,5664	<b>0,5735</b>		
12	<b>0,5929</b>	0,5478	0,5504	0,5593	45	0,5924	0,6715	0,6281	<b>0,6961</b>		
13	0,5368	0,5254	0,5541	<b>0,5589</b>	46	0,6428	0,7447	0,6951	<b>0,7671</b>		
14	0,5295	<b>0,5405</b>	0,5226	0,5397	47	0,5491	<b>0,6056</b>	0,5669	0,5759		
15	0,5595	0,6175	0,5876	<b>0,5891</b>	48	0,5628	<b>0,6101</b>	0,5775	0,5869		
16	<b>0,5191</b>	0,5157	0,5171	0,5119	49	0,5713	<b>0,5866</b>	0,5371	0,5455		
17	0,5756	0,5609	0,563	<b>0,5891</b>	50	0,4918	<b>0,5419</b>	0,5268	0,5388		
18	0,5844	0,5601	0,5798	<b>0,6629</b>	51	0,5852	<b>0,603</b>	0,575	0,6005		
19	0,6222	0,5994	0,5969	<b>0,6692</b>	52	0,5622	0,5515	0,5829	<b>0,5787</b>		
20	0,5214	0,6301	0,5672	<b>0,6316</b>	53	0,6943	0,7688	0,7287	<b>0,7855</b>		
21	0,6377	0,6699	0,6202	<b>0,6944</b>	54	0,5702	<b>0,6184</b>	0,5608	0,5666		
22	0,5103	0,508	<b>0,5191</b>	0,5108	55	0,5238	<b>0,5485</b>	0,5354	0,5248		
23	0,5471	0,5877	0,5473	<b>0,5952</b>	56	0,6548	0,6617	0,6275	<b>0,6805</b>		
24	0,616	0,6358	0,585	<b>0,6594</b>	57	0,6458	<b>0,6638</b>	0,6382	0,6146		
25	0,488	0,4853	<b>0,5191</b>	0,5177	58	<b>0,7606</b>	0,7137	0,6748	0,7351		
26	0,4931	0,4864	<b>0,5142</b>	0,5072	59	<b>0,7382</b>	0,7115	0,6733	0,6547		
27	0,748	0,8083	0,7277	<b>0,8289</b>	60	<b>0,7493</b>	0,7234	0,6854	0,7472		
28	0,7385	0,8305	0,7112	<b>0,8351</b>	61	<b>0,5537</b>	0,5049	0,5399	0,5127		
29	0,6363	<b>0,6808</b>	0,6716	0,663	62	0,6219	<b>0,6625</b>	0,5983	0,6011		
30	0,7717	0,8177	0,7439	<b>0,8252</b>	63	0,7336	<b>0,7465</b>	0,7009	0,7453		
31	0,5568	<b>0,5786</b>	0,5422	0,5428	64	<b>0,6066</b>	0,6001	0,5831	0,5783		
32	0,6661	0,6812	0,644	<b>0,7248</b>	65	0,4933	0,4814	<b>0,5129</b>	0,5021		
33	0,7652	0,8308	0,7312	<b>0,8518</b>	66	0,6191	<b>0,6232</b>	0,5492	0,5475		
<b>все</b>	0,764	0,805	<b>0,815</b>	0,811							

Для следующего эксперимента мы отобрали 7 электродов, которые по отдельности обеспечивают наиболее высокое качество распознавания по результатам скользящего контроля на обучающей совокупности - это электроды с номерами 27, 28, 30, 33, 37, 42 и 53. При совместном обучении только по указанным электродам с применением предварительной обработки и регуляризации с требованием гладкости решающего правила, значение AUC для тестовой совокупности оказалось равно 0,9026, что превышает результат, полученный при обучении по всем электродам и по каждому электроду в отдельности, что еще раз подтверждает наличие переобучения и его снижение при уменьшении числа электродов и, соответственно, размерности признакового пространства.

На следующем этапе мы исследуем возможности предложенной регуляризации второго типа по интеллектуальному сокращению размерности признакового пространства непосредственно в процессе обучения.

В этом эксперименте участвовало 13 электродов, имеющих как низкие, так и очень высокие проценты ошибок по результатам скользящего контроля на обучающей совокупности. Для этого набора электродов обучение по методу SFSVM (раздел 3.3) было произведено несколько раз для разных значений селективности. На рисунке 2 для каждого значения селективности приведено полученное значение AUC, а оставшиеся в результате обучения признаки показаны синими столбцами.



**Рисунок 2.** Результат отбора информативных признаков методом SFSVM для разных значений селективности.

Из рисунка 2 видно, что при увеличении значения селективности в первую очередь отбрасываются признаки, находящиеся в начале и конце сигналов, соответствующих отдельным электродам, что очень естественно, поскольку начальные и конечные фрагменты оказываются малоинформативными из-за особенностей сглаживания скользящим окном. Кроме того, при увеличении селективности до некоторого предела наблюдается рост значения AUC, которое достигает максимума (в данном случае) при значении селективности 0.3, после чего начинает снижаться.

Наилучшее качество распознавания в данном случае составляет 0.936, что дополнительно улучшает результаты, полученные в ходе предыдущих экспериментов. Кроме того, результаты для обоих типов регуляризации существенно превышают наилучший результат, полученный в [7] при совместном обучении по множеству электродов, который для данного эксперта составляет 0.88.

### 5. Заключение

В данной статье предложен способ предварительной обработки и два типа регуляризации для метода опорных векторов для повышения качества распознавания маммограмм с патологиями с применением интерфейса "мозг-компьютер".

Проведенное экспериментальное исследование показало, что каждый из предложенных типов регуляризации позволяет повысить качество распознавания маммограмм с отклонениями, но наиболее ощутимого эффекта позволяет достичь применение регуляризации второго типа, которая обеспечивает возможность осуществления интеллектуального отбора наиболее информативных признаков непосредственно в процессе обучения.



## 6. Литература

- [1] Wolpaw, J.R. An EEG-based brain-computer interface for cursor control / J.R. Wolpaw, D.J. McFarland, G.W. Neat, C.A. Forneris // *Electroencephalography & Clinical Neurophysiology*. – 1991. – Vol 78(3). – P. 252-259.
- [2] Zenkov, L.R. *Clinical electroencephalography*. – Moscow: MEDpress-inform, 2004. – 368 p.
- [3] Teplan, M. Fundamentals of EEG measurement // *Measurement Sc. Review*. – 2002. – Vol. 2(2). – P. 1-11.
- [4] Eizagirre, A. *EEG/ERP Analysis: Methods and Applications* / A. Eizagirre, A. Vall, 2014.
- [5] Poolman, P. A single-trial analytic framework for eeg analysis and its application to target detection and classification / P. Poolman, R.M. Frank, P. Luu, S.M. Pederson, D.M. Tucker // *NeuroImage*. – 2008. – Vol. 42. – P. 787-798.
- [6] Sajda, P. Evoked neural responses to events in video // *IEEE J. Sel. Top. Signal Process*. – 2014. – Vol. 8. – P. 358-365.
- [7] Hope, C. High Throughput Screening for Mammography using a Human-Computer Interface with Rapid Serial Visual Presentation (RSVP) / C. Hope, A. Sterr, P.E. Langovan, N. Geades, D. Windridge, K. Young, K. Wells. // *Proc. SPIE Medical Imaging: Image Perception, Observer Performance, and Technology Assessment*. – 2013. – Vol. 8673. – P. 867303. DOI:10.1117/12.2007557.
- [8] Sur, S. Event-related potential: An overview / S. Sur, V. Sinha // *Industrial Psychiatry Journal*. – 2009. – Vol. 18(1). – P. 70.
- [9] Cecotti, H. Single-trial classification of event-related potentials in rapid serial visual presentation tasks using supervised spatial filtering / H. Cecotti, M.P. Eckstein, B. Giesbrecht // *IEEE Trans. Neural Netw. Learn. Syst*. – 2014. – Vol. 25. – P. 2030-2042.
- [10] Braverman, E.M. Experiments on training a machine for pattern recognition // PhD Thesis. – Moscow, 1961.
- [11] Abootalebi, V. A new approach for EEG feature extraction in P300-based lie detection / V. Abootalebi, M.H. Moradi, M.A. Khalilzadeh // *Comp. Methods Progr. Biomed*. – 2009. – Vol. 94(1). – P. 48-57.
- [12] Amini, Z. Comparison of performance of different feature extraction methods in detection of P300 / Z. Amini, V. Abootalebi, M.T. Sadeghi // *Biocybernetics and Biomedical Engineering*. – 2013. – Vol. 33(1). – P. 3-20.
- [13] Tran, L. EEG Features for the Detection of Event-Related Potentials Evoked Using Rapid Serial Visual Presentation // PhD Thesis, 2014. – 63 p.
- [14] Lees, S. A review of rapid serial visual presentation-based brain-computer interfaces / S. Lees, N. Dayan, H. Cecotti, P. McCullagh, L. Maguire, F. Lotte, D. Coyle // *J Neural Eng*. – 2018. – Vol. 15(2). – P. 021001. DOI: 10.1088/1741-2552/aa9817.
- [15] Spatiotemporal representations of rapid visual target detection: a single-trial EEG classification algorithm / G.F. Alpert, R. Manor, A.B. Spanier, L.Y. Deouel, A.B. Geva // *IEEE Trans. Biomed. Eng*. – 2014. – Vol. 61. – P. 2290-2303.
- [16] Kumar, S. Brain computer interface for interactive and intelligent image search and retrieval / S. Kumar, F. Sahin // *High Capacity Optical Networks and Emerging/Enabling Technologies*, 2013. – P. 136-140.
- [17] Rivet, B. xDAWN algorithm to enhance evoked potentials: application to brain-computer interface // *IEEE Trans. Biomed. Eng*. – 2009. – Vol. 56. – P. 2035-2043.
- [18] Vapnik, V.N. *Statistical Learning Theory*. – Wiley-Interscience, 1998. – 768 p.
- [19] Mottl, V.V. Pattern recognition learning taking into account the criterion of smoothness of the decision rule / V.V. Mottl, S.D. Dvoenko, O.S. Seredin, O.V. Krasotkina // *Control and Information: proc. of the chair of automation and remote control of TSU*, 2000.
- [20] Tatarchuk, A. Selectivity supervision in combining pattern-recognition modalities by feature- and kernel-selective Support Vector Machines / A. Tatarchuk, V. Mottl, A. Eliseyev, D. Windridge // *Proc. ICPR*, 2008.
- [21] Tatarchuk, A. A support kernel machine for supervised selective combining of diverse pattern-recognition modalities / A. Tatarchuk, E. Urlov, V. Mottl, D. Windridge // *MCS*, 2010.

- [22] Tatarchuk, A. Supervised Selective Kernel Fusion for Membrane Protein Prediction / A. Tatarchuk, V. Sulimova, V. Mottl, D. Windridge // Pattern Recognition in Bioinformatics, Lecture Notes in Computer Science. – 2014. – Vol. 8626. – P. 98-109.
- [23] Bradley, P. Feature selection via concave minimization and support vector machines / P. Bradley, O. Mangasarian // International Conference on Machine Learning, 1998.
- [24] Wang, L. The doubly regularized support vector machine / L. Wang, J. Zhu, H. Zou // Statistica Sinica. – 2006. – Vol. 16. – P. 589-615.
- [25] Бураченко, Д.Л. Общая теория связи / Д.Л. Бураченко, Н.Н. Клюев, В.И. Коржик, Л.М. Финк. – Л.: ВАС, 1970. – 412 с.

### Благодарности

Работа выполнена при поддержке РФФИ, гранты 15-07-08967, 18-07-01087.

## The Brain-Computer Interface for Recognition Mammograms with Pathology

V.V. Sulimova<sup>1</sup>, O.V. Krasotkina<sup>2</sup>, S. Bukhonov<sup>3</sup>, V.V. Mottl<sup>4</sup>, D. Windridge<sup>4</sup>

<sup>1</sup>Tula State University, Lenin Ave. 92, Tula, Russia, 300012

<sup>2</sup>Markov Processes International, Springfield Ave 475, Suite 401, Summit, NJ 07901,

<sup>3</sup>MIPT, Institutskiy 9, Dolgoprudniy, Russia, 141701

<sup>4</sup>Computing Center A.A. Dorodnitsyna of the RAS, Vavilova 44/2, Moscow, Russia, 119333

<sup>5</sup>Middlesex University, London, UK

**Abstract.** Last few years a trend of using brain-computer interfaces (BCIs) for identifying targets within different image types has emerged. Particularly, some years ago our colleagues from Great Britain first proposed to use BCI as a novel high throughput screening technology for mammography. This technology is based on rapid serial visual presentation of mammograms images to experts end recognition of its brain activity that corresponds to seeing mammograms with pathologies. High performance is provided by the advanced computing power of the human visual system, which has been found to be able to identify and classify the image content as target or non-target with a frequency of more than 10 Hz. In this paper, we improve this technology by, firstly, applying special pre-processing of brain activity signals coming from 66 electrodes fixed on the head of the test persons while they are viewing mammogram images and, secondly, by applying the support vector machines method with two kinds regularization, taking into account the peculiarities of the considered problem, which makes it possible to significantly improve the quality of detection of abnormal mammograms.