



И.В. Кузьмин, О.П. Солдатова

## ИССЛЕДОВАНИЕ ЭФФЕКТИВНОСТИ РЕШЕНИЯ ЗАДАЧИ КЛАССИФИКАЦИИ НЕЙРОННЫМИ СЕТЯМИ ПЕРСЕПТРОННОГО ТИПА

(Самарский университет)

Целью данной работы является сравнение эффективности двух нейронных сетей персептронного типа. В сравнении были использованы многослойный персептрон и многослойный персептрон с дополнительным нечеткий слоем  $C$  – средних.

Нечеткий слой  $C$  – средних определяет степень принадлежности входного сигнала к одному из заранее заданных кластеров с помощью нечеткого алгоритма  $C$  – средних. Использование данного слоя в дополнение к персептрону позволяет получить корректное распределение входных данных в кластеры, а также однозначно определять данные на их границах.

Данный алгоритм основан на минимизации целевой функции вида:

$$J_m = \sum_{i=1}^N \sum_{j=1}^C u_{ij}^m \|x_i - c_j\|^2, 1 \leq m < \infty$$

Где  $m$  – любое вещественное число больше 1,  $u_{ij}$  – степень принадлежности  $x_i$  в кластере  $j$ ,  $x_i$  – элемент входных данных,  $c_j$  – центроид кластера [1]. На каждой итерации алгоритма происходит оптимизация вышеописанной функции применяя к  $u_{ij}$  следующую схему вычисления:

$$u_{ij} = \frac{1}{\sum_{k=1}^C \left( \frac{\|x_i - c_j\|}{\|x_i - c_k\|} \right)^{\frac{2}{m-1}}}$$
$$c_j = \frac{\sum_{i=1}^N u_{ij}^m \cdot x_i}{\sum_{i=1}^N u_{ij}^m}$$

Остановка оптимизации произойдет если выполнится условие:

$$\max_{ij} \left\{ \left| u_{ij}^{(k+1)} - u_{ij}^{(k)} \right| \right\} < \varepsilon, 0 < \varepsilon < 1$$

где  $\varepsilon$  – критерий остановки оптимизации и  $k$  – шаг итерации.

В качестве входных данных были использованы коэффициенты разложения PSF размерности 15x206, в качестве выходных данных были использованы коэффициенты поля  $F$  параметров глаза человека с прибора OCULIZER аналогичной размерности.

В качестве алгоритма обучения многослойного персептрона использован алгоритм обучения учителем. Для корректировки весов персептрона использован метод обратного распространения ошибки [2]. Для активации нейронов использована сигмоидальная функция. Исходные данные были поделены на обучающую и контрольную выборку в соотношении 4:1



В качестве сравнения эффективности были использованы показатели среднеквадратичного отклонения (СКО) для обучающей и контрольной выборки (таблицы 1 и 2), а также на рисунках 1 и 2 приведены графики зависимостей входных данных от выходных данных в сравнении с контрольными данными.

Таблица 1. СКО для обучающей выборки

Эпоха обучения	СКО для обучающей выборки многослойного персептрона	СКО для обучающей выборки многослойного персептрона с дополнительным нечетким слоем
100	0.02970	0.01164
200	0.02723	0.00815
300	0.02640	0.00709
400	0.02597	0.00637
500	0.02571	0.00603
600	0.02553	0.00584
700	0.02540	0.00571

Таблица 2. СКО для тестируемой выборки

Тестируемый массив	СКО для контрольной выборки многослойного персептрона	СКО для контрольной выборки многослойного персептрона с дополнительным нечетким слоем
	0.00021	0.00020
2	0.00014	0.00014
3	0.00003	0.00004
4	0.00007	0.00003
5	0.00008	0.00004
6	0.00004	0.00001
7	0.00008	0.00002
8	0.00018	0.00003

Полученные результаты позволяют сделать вывод о том, что дополнительный нечеткий слой повышает точность классификации многослойного персептрона. Однако, стоит заметить, что данные преимущества нечеткого слоя могут отличаться в зависимости от входных данных нейронной сети. Также уменьшается скорость обучения нейронной сети в связи с дополнительными вычислениями для кластеризации данных.

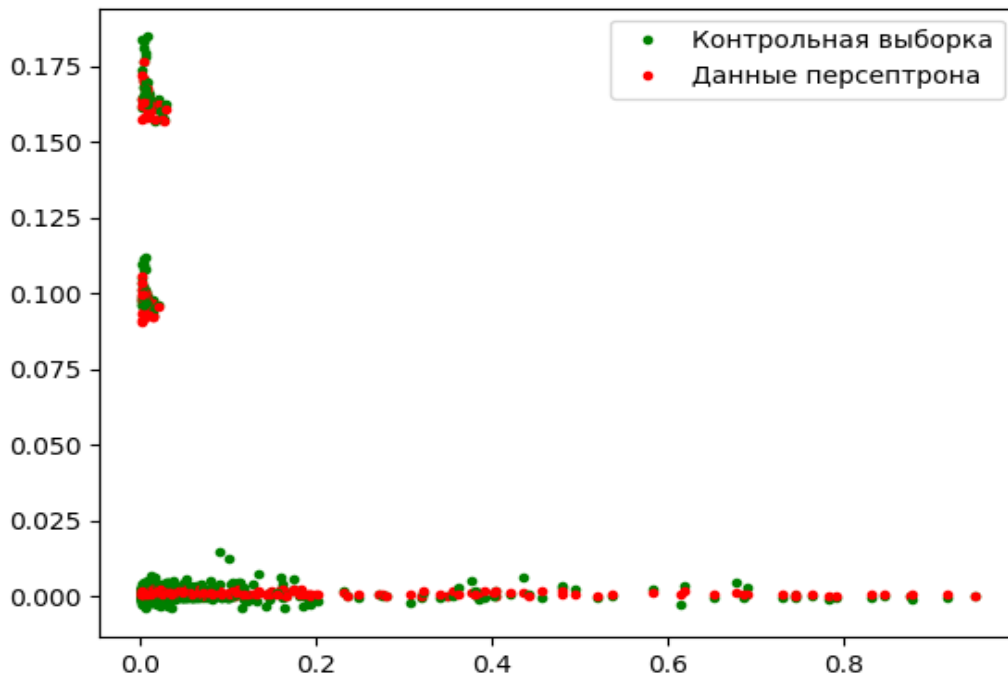


Рис. 1. Результаты классификации многослойного персептрона с дополнительным нечетким слоем и контрольная выборка

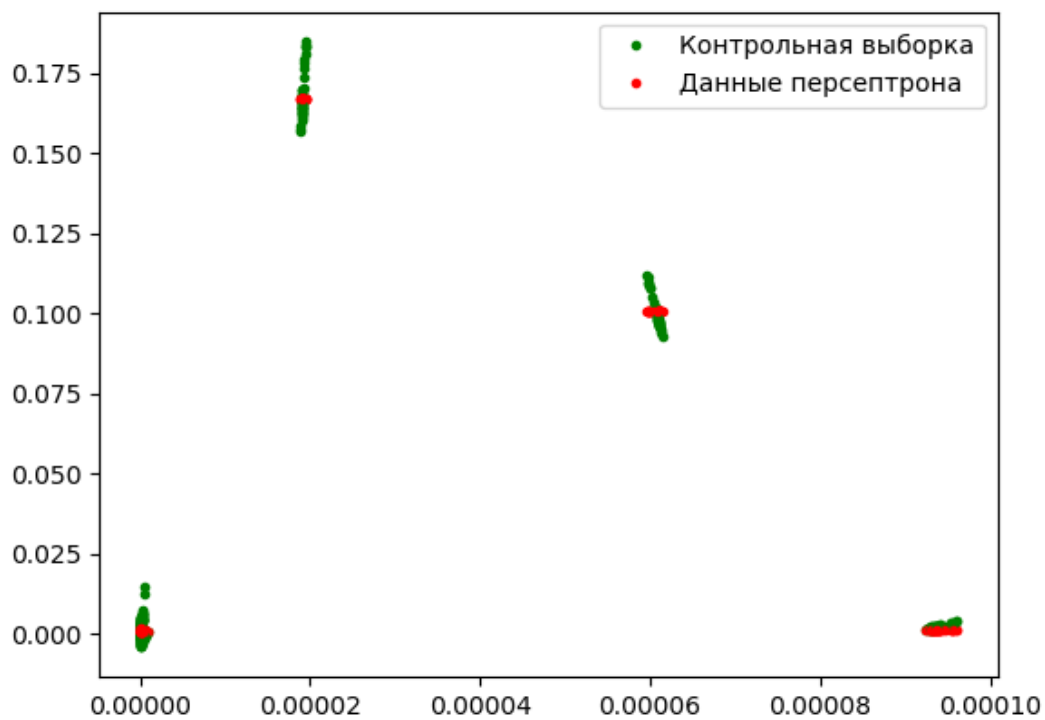


Рис. 2. Результаты классификации многослойного персептрона и контрольная выборка



### Литература

1. Bezdek J. C., Pattern Recognition with Fuzzy Objective Function Algorithms [Текст] / J. C. Bezdek// Plenum Press, – 1981.
2. Осовский, С. Нейронные сети для обработки информации [Текст] / С.Осовский – М.: Финансы и статистика, 2002 – 344 с.

А.В. Лагарникова, И.А. Сюсин

## КОНЦЕПЦИЯ КОНСТРУКТОРА ПОСТРОЕНИЯ АВТОМАТИЗИРОВАННЫХ ТЕСТОВ ДЛЯ МОБИЛЬНЫХ ПРИЛОЖЕНИЙ НА УРОВНЕ ПОЛЬЗОВАТЕЛЬСКОГО ИНТЕРФЕЙСА

(Самарский университет)

Тестирование приложений – это важный этап в процессе разработки программных систем. На сегодняшний день существует большое количество методов тестирования, каждый из которых имеет ряд достоинств и недостатков, а также зависит от конкретных целей и не всегда может быть применим. Существуют два основных вида тестирования: ручное и автоматизированное. Как правило, ручное тестирование используется для проверки функциональности приложения с точки зрения пользователя, а автоматизированное - для проверки внутренней функциональности приложения [1, 2].

Условно тестирование мобильных приложений можно разбить на 3 уровня [3]:

1) Unit Tests Layer – уровень автоматизированных модульных тестов, написанных разработчиками.

2) Functional Tests Layer (Non-UI) – уровень тестирования бизнес-логики приложения с выполнением функциональных тестов.

3) GUI Tests Layer – уровень тестирования пользовательского интерфейса приложения с возможностью тестирования функционального уровня, выполняя операции, использующие бизнес-логику приложения.

В данной статье будет рассмотрен уровень GUI Tests Layer, а также возможность применения методов его автоматизации.

Автоматизированное тестирование не может в полной мере покрыть требования к пользовательскому интерфейсу [4]. Данная проблема является наиболее актуальной для тестирования мобильных приложений. В автоматизированном тестировании нет возможности исследовательского тестирования, которая есть в ручном тестировании. Целью исследовательского ручного тестирования является проверка сложных возможностей приложения, а именно поведение приложения при мультитач – взаимодействиях (тактильные особенности приложения), при всплывающих уведомлениях (баннеры, action-меню, системные уведомления), а также при открытии другого приложения поверх тестируемого, поведение приложения при заблокированном – разблокированном экране [5, 6]. Важно, что используются не заранее составленные тест-кейсы, как