



4. TensorFlow Hub – Magenta – arbitrary image stylization [Электронный ресурс]. URL: <https://tfhub.dev/google/lite-model/magenta/arbitrary-image-stylization-v1-256/fp16/prediction/1> (дата обращения: 02.04.2021)
5. tensorflow/tfjs: A WebGL accelerated JavaScript library for training and deploying ML models. [Электронный ресурс]. URL: <https://github.com/tensorflow/tfjs> (дата обращения: 02.04.2021)
6. Distilling the Knowledge in a Neural Network [Электронный ресурс]. URL: <https://arxiv.org/abs/1503.02531> (дата обращения: 02.04.2021)
7. Depthwise separable convolutions for machine learning [Электронный ресурс]. URL: <https://eli.thegreenplace.net/2018/depthwise-separable-convolutions-for-machine-learning/> (дата обращения: 15.04.2021)

Л.В. Болотникова, И.В. Лёзина

## АВТОМАТИЗИРОВАННАЯ СИСТЕМА РАСПОЗНАВАНИЯ РИМСКИХ ЦИФР ПРИ ПОМОЩИ НЕЙРОННОЙ СЕТИ КОХОНЕНА.

(Самарский университет)

Распознавание образов — научная дисциплина, целью которой является выявление объектов по нескольким критериям или классам. Теория распознавания объектов представляет собой раздел информатики, который основывается на разработке основ и методов идентификации предметов, явлений и сигналов. Потребность в таком распознавании возникает во многих областях, начиная с машинного зрения, символического распознавания, диагностики в медицине, распознавания речи и заканчивая узко специальными задачами [1].

Иногда подобное распознавание требуется для восстановления текстового документа. К примеру, для поврежденных литературных текстов часто требуется восстановить последовательность повествования для получения наиболее точного восприятия информации. Для этого необходимо распознавать римские цифры, которые часто используются в подобных текстах для нумерации глав, заголовков и страниц.

Для распознавания образов римских цифр была разработана автоматизированная система, основанная на нейронной сети Кохонена.

Она представляет собой двухслойную сеть, где каждый нейрон первого (распределительного) слоя соединен со всеми нейронами второго (выходного) слоя, которые расположены в виде двумерной решетки.

Нейроны выходного слоя называются кластерными элементами, их количество определяют максимальное количество групп, на которые система может разделить входные данные. Увеличивая количество нейронов второго слоя можно увеличивать детализацию результатов процесса кластеризации.

Для обучения сети Кохонена используется соревновательный метод [2]. На каждом шаге обучения из исходного набора данных случайно выбирается один вектор. Затем производится поиск нейрона выходного слоя, для которого



расстояние между его вектором весов и входным вектором - минимально. По определённому правилу производится корректировка весов для нейрона-победителя и нейронов из его окрестности, которая задаётся соответствующей функцией окрестности.

Алгоритм Кохонена относится к наиболее старым алгоритмам обучения сетей с самоорганизацией на основе конкуренции, и в настоящее время существуют различные его версии [3]. В одной из модификации алгоритма Кохонена используется, так называемое «гауссовское соседство», определяемое формулой [4]:

$$S(i, x) = \exp\left(-\frac{d^2(i, w)}{2\lambda^2}\right).$$

В другой модификации алгоритма Кохонена используется прямоугольное соседство, которое определяется формулой [4]:

$$S(i, x) = \begin{cases} 1, & \text{для } -K < d(i, w) < K \\ 0, & \text{иначе} \end{cases}$$

Была разработана автоматизированная система распознавания римских цифр при помощи нейронной сети Кохонена с возможностью выбора вида соседства для алгоритма обучения. Разработка системы производилась на языке программирования Java в среде разработки IntelliJ IDEA 2018.

В процессе проектирования была создана UML-модель системы. На рисунке 1 представлена диаграмма вариантов использования разработанной системы.

Перед началом обучения на вход сети подаются римские цифры: I, V, X, L, C, D, M.

Для тестирования данной системы был произведен ряд экспериментов, направленных на выявление оптимальных параметров обучения нейронной сети Кохонена.

В частности, исследовалась зависимость процента верных распознаваний от коэффициента обучения для двух типов соседства. Размер двумерной карты Кохонена для исследования был принят равным 15x15 нейронов.

Для обучения была сформирована выборка из 3500 «зашумленных» образов римских цифр. Длительность обучения была принята равной 30 эпохам.

Результаты распознавания тестовой выборки представлены в таблице 1.

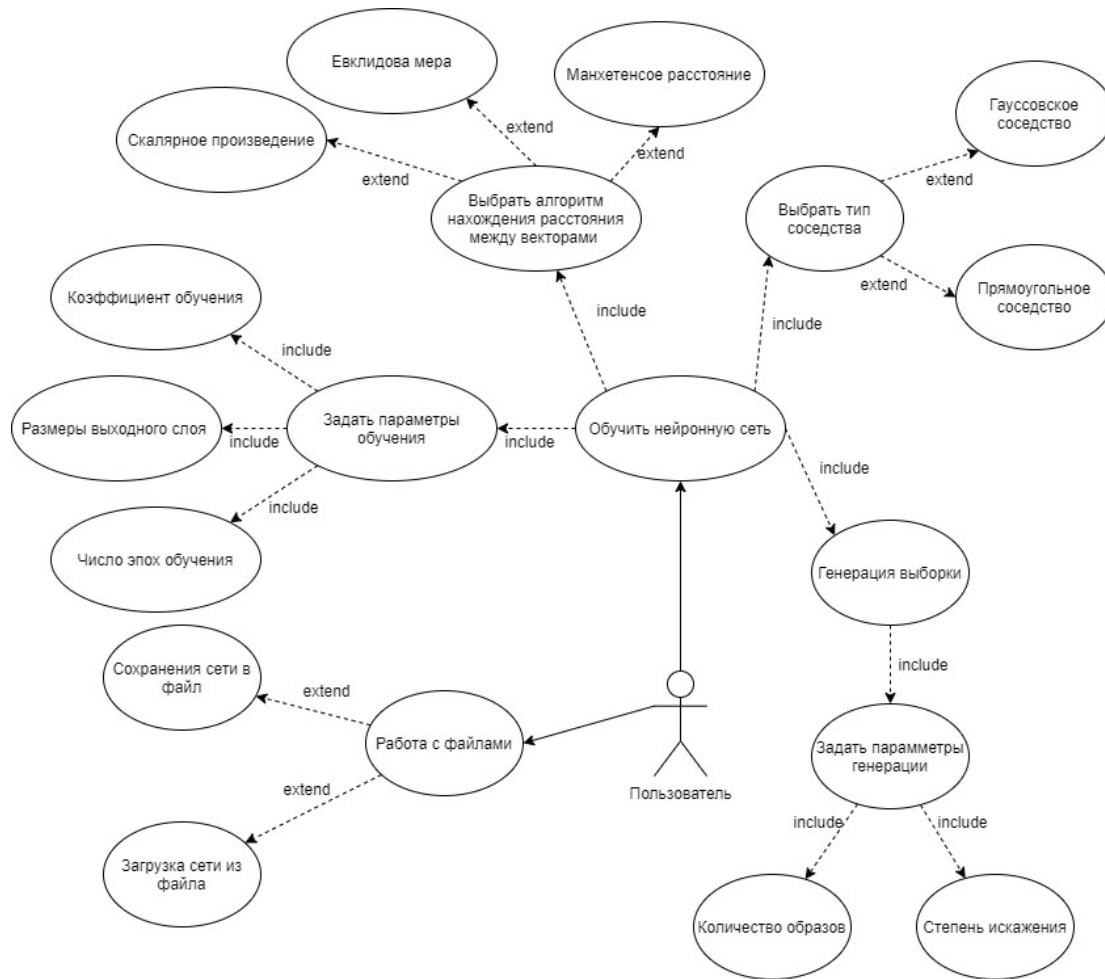


Рисунок 14 – Диаграмма вариантов использования разработанной системы

Таблица 1. Результаты проведённых экспериментов.

Кoeffициент обучения	Гауссово соседство	Прямоугольное соседство
0.2	97.57%	88.40%
0.25	97.60%	85.57%
0.3	97.00%	83.69%
0.35	93.11%	82.71%
0.4	91.34%	80.20%
0.45	87.80%	79.14%
0.5	86.66%	79.40%
0.55	86.26%	77.57%
0.6	82.89%	77.40%
0.65	81.69%	75.97%
0.7	80.89%	75.06%
0.75	79.66%	71.29%
0.8	77.57%	68.54%
0.85	77.00%	65.57%
0.9	74.14%	62.29%



Проанализировав результаты проведенных экспериментов, можно сделать вывод о том, что автоматизированная система распознавания римских цифр работает эффективно. Из результатов также видно, что процент верных распознаваний римских цифр с помощью нейронной сети Кохонена уменьшается с увеличением коэффициента обучения. Сравнивая результаты экспериментов, сделанных при помощи алгоритма Кохонена с разными типами соседства можно сделать вывод: при использовании алгоритма с Гауссовым соседством процент верных распознаваний, как правило, выше чем при использовании алгоритма с прямоугольным соседством.

### Литература

1. Барский, А. Б. Нейронные сети: распознавание, управление, принятие решений [Текст] / А.Б. Барский // М.: Финансы и статистика, 2004. — 176 с.
2. Борисов, Е. Кластеризатор на основе нейронной сети Кохонена [Электронный ресурс] режим доступа: <http://mechanoid.kiev.ua/neural-net-kohonen-clusterization.html>, свободный.
3. Осовский, С. Нейронные сети для обработки информации [Текст] / Осовский С.: Пер. с польского И.Д. Рудинского. – М.: Финансы и статистика, 2002. – 344 с..
4. Солдатова, О.П. Основы нейроинформатики [Текст] : учеб. пособие / О.П. Солдатова. – Самара: Изд-во Самар, гос. аэрокосм, ун-та, 2006. – 132 с. : ил.– ISBN 5-7883-0467-9.

С.С. Волков<sup>I, II</sup>, И.И. Курочкин<sup>III</sup>

## ПРИМЕНЕНИЕ ГЛУБОКИХ НЕЙРОННЫХ СЕТЕЙ, ОСНОВАННЫХ НА LSTM, ДЛЯ РЕШЕНИЯ ЗАДАЧ КЛАССИФИКАЦИИ<sup>I</sup>

(Российский университет дружбы народов<sup>I</sup>, ФИЦ ИУ РАН<sup>II</sup>, ИППИ РАН<sup>III</sup>)

### Введение

Машинное обучение – обширный подраздел научного направления искусственного интеллекта, отвечающий за изучение алгоритмов, способных обучаться на основе имеющихся данных. Наиболее часто методы машинного обучения применяются для решения задач классификации, кластеризации, прогнозирования и извлечения информации. Важной особенностью алгоритмов машинного обучения является то, что они способны хорошо работать с большими данными. В данной работе речь пойдет о задачах классификации. Этот класс задач относится к категории обучения с учителем. При обучении с учителем машина обучается на примерах. Оператор обеспечивает алгоритм машинного обучения набором известных данных, который содержит необходимые входные значения (признаки) и выходные. Задача заключается в установлении принципа

---

<sup>I</sup> Исследование выполнено при финансовой поддержке РФФИ в рамках научного проекта №18-29-03264.