



паратами непосредственно в процессе выполнения этих задач, в результате чего становится возможной обработка заранее не запланированных событий.

### Литература

1. Каляев И.А. Модели и алгоритмы коллективного управления в группах роботов / И.А. Каляев, А.Р. Гайдук, С.Г. Капустян. – М.: ФИЗМАТЛИТ, 2009. – 280 с.
2. Соллогуб А. В. Мультиагентные технологии распределенного управления группировкой малоразмерных космических аппаратов дистанционного зондирования Земли / П. О. Скобелев, Е. В. Симонова, А. В. Царев, М. Е. Степанов, А.А. Жилиев // Информационное общество. – 2013. №1-2

О.П. Солдатова, А.М. Кузенная

## РАСПОЗНАВАНИЕ РУКОПИСНЫХ ЦИФР ПРИ ПОМОЩИ НЕЙРОННОЙ СЕТИ С ОДНИМ СКРЫТЫМ СЛОЕМ

(Самарский государственный аэрокосмический университет)

Целью данной научной работы является изучение возможностей нейронных сетей в распознавании рукописных цифр, проектирование и реализация системы распознавания рукописных цифр на основе многослойного персептрона с одним скрытым слоем для экспериментальной оценки работы данного вида сети, сравнение полученных результатов с результатами при другой структуре и настройке сети.

Реализованная сеть показала высокую эффективность при распознавании рукописных цифр. Все тесты велись с использованием базы рукописных цифр MNIST [1]. Система реализована на платформе C# в интегрированной среде разработки Microsoft Visual C# 2010.

Структура сети приведена на рисунке 1. Входные данные рассматриваемой задачи поделены на две части. Первая часть содержит эталонные представления букв, а вторая, тестовая, – те же буквы, но с искажениями. Эталонные буквы используются для обучения нейронной сети. Вторая часть используется для тестирования и оценки эффективности сформированной нейронной сети.

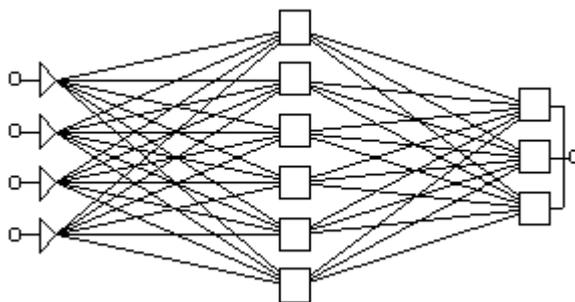


Рис. 1. Структура многослойного персептрона с одним скрытым слоем



Входной слой представляет собой вектор входных признаков изображения, который представляет собой вектор пикселей размером  $28*28$ . Каждый компонент входного вектора связан со всеми нейронами скрытого слоя. Скрытый и выходной слои образуют сигмоидальные нейроны. Число элементов в первом и втором слоях нейронной сети может варьироваться. В частности, в разработанной модели нейронной сети скрытый слой содержит 20, а выходной – 10 нейронов.

Обучающие и тестовые данные хранятся в виде картинок формата «.bmp». Сначала следует 8000 эталонных изображений, а затем 2000 тестовых. Программы обучения и распознавания работают с числовыми представлениями цифр. Каждая цифра – это изображение, состоящее из пикселей. В процессе обработки все изображения трансформируются в массив из целочисленных значений размера  $28*28$  с помощью разработанного в работе метода, преобразующего изображение с пороговой функцией цвета. При вычислении выходного сигнала нейрона используется сигмоидальная функция, возвращающая значение в диапазоне  $[-1, 1]$ . Число выходов нейронной сети равно числу цифр в обучающей выборке. В примере формируется нейронная сеть, способная распознавать 10 цифр. Значения выходных сигналов находятся в диапазоне  $[-1, 1]$ . После обработки сигнала выбирается выход с максимальным сигналом.

Сигнал, подаваемый на вход элемента нейронной сети слоя  $k$ , определяется, как взвешенная сумма его входных сигналов:

$$s_j^k = \sum_{i=1}^m x_i w_{ij}^k, j = 1, n_k, \text{ где } m - \text{число нейронов в слое } k - 1.$$

В случае входного слоя  $m = 28*28$ , а  $x_i$  – это входные сигналы;  $n_k$  – число элементов в слое  $k$ ;  $w_{ij}^k$  – соответствующий весовой коэффициент.

Выход каждого элемента рассчитывается по следующей формуле:

$$y_j^k = f(s_j^k), \text{ где } f(x) = -0.5 + 1 / (1 + e^{-\alpha x}) \text{ (здесь } \alpha = 1.0).$$

Задача обучения нейронной сети состоит в нахождении весовых коэффициентов  $w_{ij}^k$ , обеспечивающих правильное распознавание цифр. Эта задача решается методом обратного распространения ошибки, при помощи следующего алгоритма:

1. Взять произвольную эталонную цифру.
2. Подать на вход сети ее числовое представление и рассчитать значения  $y_j$  выходных сигналов нейронной сети.
3. Вычислить параметр коррекции  $\delta_j$  каждого элемента нейронной сети  $\delta_j = (y_j - d_j) dy_j/ds_j$  (в случае выходных нейронов), где  $d_j$  – ожидаемое значение на  $j$ -м выходе, или  $\delta_j^k = [\sum_i \delta_i^{k+1} w_{ij}^{k+1}] dy_j/ds_j$  (для нейронов первого и второго слоев,  $k = 1$  или  $k = 2$ ).
4. Рассчитать величину коррекции весовых коэффициентов выходных элементов  $\Delta w_{ij}^k = -\eta \delta_j^k y_{ij}^{k-1}$  (в случае выходного слоя  $k = 3$ ). В программе  $\eta = 0.5$ .
5. Выполнить корректировку весовых коэффициентов элементов каждого слоя  $w_{ij}^k = w_{ij}^k + \Delta w_{ij}^k$ .
6. Повторить процедуру обучения, подавая на вход описание следующей эталонной буквы.



Приведенная процедура неоднократно повторяется для всего множества эталонных букв, образующих обучающую выборку. Процесс обучения завершается либо при получении весовых коэффициентов, обеспечивающих распознавание всех букв обучающей выборки, либо после превышения заданного порогового числа итераций. Начальные значения весовых коэффициентов всех нейронов, формируемые перед первой итерацией, задаются случайным образом в диапазоне [0.0, 1.0]. Обучающая выборка формируется из 8000 картинок базы MNIST [1].

На выходе сети, по известным, найденным в процессе обучения весовым коэффициентам вычисляется вектор  $y$  (размер вектора 10). Решение дает выходной нейрон с максимальным значением  $y_j$ : по номеру  $j$  этого нейрона предьявляется в качестве ответа цифра.

Были исследованы зависимости среднеквадратичного отклонения (СКО) от настроек сетей и обучения при следующих параметрах обучения: обучающая выборка – 8000 изображений, входной слой – 28\*28 нейронов, скрытый слой – 20, выходной – 10. Зависимость СКО от коэффициента наклона сигмоидальной функции представлена в таблице 1.

Таблица 1. Зависимость СКО от коэффициента наклона сигмоидальной функции

Коэффициент наклона сигмоидальной функции	Среднеквадратичная ошибка
1,0	0,0000035
0,8	0,0000140
0,6	0,0000700
0,5	0,0001110

Результаты исследований зависимости СКО от числа скрытых нейронов представлены в таблице 2.

Таблица 2 – Зависимость СКО от числа нейронов в скрытом слое

Число нейронов в скрытом слое	Среднеквадратичная ошибка
20	0,0000035
17	0,0004832
15	0,0000331

Для тестирования были взяты параметры сети, дающие наименьшее СКО при обучении: тестовая выборка – 8000 изображений, входной слой – 28\*28 нейронов, скрытый слой – 20, выходной – 10. На рисунке 2 в качестве примера приведено изображение цифры 0.

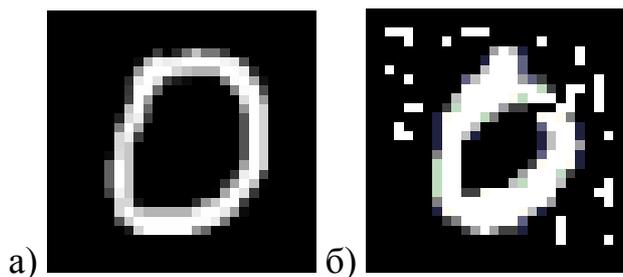


Рис. 2. а) случайная картинка из эталонной выборки;  
б) изображение той же цифры из тестовой выборки

Тестирование сети проведено на 2000 тестовых картинок, ошибка выявлена при распознавании 23 изображений. При указанных параметрах сеть неверно распознала цифры в 1,15% случаев.

Для сравнения эффективности работы реализованной сети в таблице 3 приведены результаты, показанные другими классификаторами на тестовом множестве базы MNIST (обучение проводилось на 60000 образцов, а тестирование – на 10000 образцов) [2]. В таблице 3 представлены результаты линейных классификаторов, нейронных сетей с одним и двумя скрытыми слоями, машин опорных векторов и свёрточных нейронных сетей семейства LeNet [3]. Из таблицы видно, что минимальная частота ошибок при обработке проверочного набора составляет 0,7% для сети Boosted LeNet-4.

Таблица 3. Процент неверно распознанных символов

Классификатор	Количество ошибок на тестовой выборке (%)
Linear	12
[deslant] Linear	8,4
Pairwise	7,6
K-NN Euclidean	5
[deslant] K-NN Euclidean	2,4
40 PCA + quadratic	3,3
1000 RBF + linear	3,6
[16x16] Tangent Distance	1,1
SVM poly 4	1,1
RS-SVM poly 5	1
[dist] V-SVM poly 9	0,8
28x28-300-10	4,7
[dist] 28x28-300-10	3,6
[deslant] 20x20-300-10	1,6
28x28-1000-10	4,5
[dist] 28x28-1000-10	3,8
28x28-300-100-10	3,05
[dist] 28x28-300-100-10	2,5
28x28-500-150-10	2,95
[dist] 28x28-500-150-10	2,45



[16x16] LeNet-1	1,7
LeNet-4	1,1
LeNet-4/Local	1,1
LeNet-4/K-NN	1,1
LeNet-5	0,95
[dist] LeNet-5	0,8
[dist] Boosted LeNet-4	0,7

Таким образом, реализованная в рамках данной работы нейронная сеть, при более простой по сравнению со свёрточной сетью структуре, показывает результаты распознавания, сопоставимые с сетями LeNet.

### Литература

1. LeCun, Y. The MNIST database of handwritten digits – <http://yann.lecun.com/exdb/mnist>.
2. Солдатова О.П., Гаршин А.А. Применение сверточной нейронной сети для распознавания рукописных цифр. Компьютерная оптика. – 2010. – Том 34, №2. – с. 252-260 – ISSN 0134-2452.
3. LeCun, Y. Gradient Based Learning Applied to Document Recognition / Y. LeCun, L. Bottou, P. Haffner – IEEE Press, 1998. – 46 pages.

О.П. Солдатова, Д.А. Панкратова

## АНАЛИЗ РЕЗУЛЬТАТОВ ПРОГНОЗИРОВАНИЯ УЧЕТНЫХ ЦЕН НА ДРАГОЦЕННЫЕ МЕТАЛЛЫ С ПОМОЩЬЮ НЕЧЕТКОЙ НЕЙРОННОЙ ПРОДУКЦИОННОЙ СЕТИ ВАНГА-МЕНДЕЛЯ

(Самарский государственный аэрокосмический университет)

Способности нейронной сети к прогнозированию напрямую следуют из её способности к обобщению и выделению скрытых зависимостей между входными и выходными данными. После обучения сеть способна предсказать будущее значение некой последовательности на основе нескольких предыдущих значений и (или) каких-то существующих в настоящий момент факторов. Следует отметить, что прогнозирование возможно только тогда, когда предыдущие изменения действительно в какой-то степени определяют будущее. Например, прогнозирование котировок акций на основе котировок за прошлую неделю может оказаться успешным (а может и не оказаться), тогда как прогнозирование результатов завтрашней лотереи на основе данных за последние 50 лет почти наверняка не даст никаких результатов [1].

Для прогнозирования учетных цен на драгоценные металлы была выбрана сеть Ванга-Менделя, поскольку только для этой сети существует эффективный и достаточно простой адаптивный алгоритм обучения, который позволяет автоматически организовать сеть. Данный алгоритм подбирает число нейронов