

Алгоритм вычисления значений весов синапсов первого слоя нейронной сети на основе метрических методов распознавания. Часть 2¹

П. Ш. Гейдаров^а, канд. техн. наук, доцент, orcid.org/0000-0002-3881-0629, plbaku2010@gmail.com

^аИнститут систем управления Национальной академии наук Азербайджана, Бахтияр Вагабзаде ул., 9, Баку, Az 1141, Азербайджан

Введение: метрические методы распознавания позволяют предварительно и строго определять структуры нейронных сетей прямого распространения, а именно количество нейронов, слоев и связей на основе начальных параметров задачи распознавания. Они также дают возможность на основе метрических выражений близости аналитически вычислять веса синапсов нейронов сети. Процедура настройки для данных сетей включает в себя последовательное аналитическое вычисление значения каждого веса синапса в таблице весов для нейронов нулевого или первого слоя, что позволяет уже на начальном этапе без применения алгоритмов обучения получить работоспособную нейронную сеть прямого распространения. Затем нейронные сети прямого распространения могут дообучаться известными алгоритмами обучения, что в целом ускоряет процедуры их создания и обучения. **Цель:** определить, сколько времени требует процесс вычисления значений весов и, соответственно, насколько является оправданным предварительное вычисление значений весов нейронной сети прямого распространения. **Результаты:** предложен и реализован алгоритм автоматизированного вычисления всех значений таблиц весов синапсов для нулевого и первого слоя применительно к задаче распознавания черно-белых однотонных изображений символов. Описание предлагаемого алгоритма приведено в программной среде Builder C++. Рассмотрена возможность оптимизировать процесс вычисления весов синапсов в целях ускорения всего алгоритма. Выполнена оценка затрачиваемого времени на вычисление этих весов для разных конфигураций нейронных сетей на основе метрических методов распознавания. Приведены примеры создания таблиц весов синапсов согласно рассмотренному алгоритму. Результаты вычисления таблиц показывают, что на процедуру аналитического вычисления весов нейронной сети потрачены считанные секунды, минуты, что никак не сравнимо со временем, необходимым для обучения нейронной сети. **Практическая значимость:** аналитическое вычисление значений весов нейронной сети позволяет существенно ускорить процедуру создания и обучения нейронной сети прямого распространения. На основе предложенного алгоритма может быть также реализован и алгоритм вычисления трехмерных таблиц весов для более сложных, черно-белых и цветных полутоновых, изображений.

Ключевые слова – нейронные сети, весовые и пороговые значения, нейрокомпьютер, алгоритмы обучения, программирование нейронных сетей.

Для цитирования: Гейдаров П. Ш. Алгоритм вычисления значений весов синапсов первого слоя нейронной сети на основе метрических методов распознавания. Ч. 2. *Информационно-управляющие системы*, 2020, № 3, с. 25–38. doi:10.31799/1684-8853-2020-3-25-38

For citation: Geidarov P. Sh. Algorithm for calculating synapse weights of the first layer of a neural network on the base of metric recognition methods. Part 2. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2020, no. 3, pp. 25–38 (In Russian). doi:10.31799/1684-8853-2020-3-25-38

Оценка времени вычисления таблиц весов

С увеличением размерности таблицы весов синапсов количество связей нейрона первого слоя увеличивается. Оно равно количеству ячеек в таблице весов и определяется по выражению $n_{\text{связей}} = CR$, где C — количество столбцов; R — количество строк таблицы весов. При этом время вычислений также увеличивается. Для оценки времени вычисления значения весов синапсов использовалась встроенная в C++ функция $clock()$, которая выводит время в миллисекундах в начале функции $Izmeneniye_X0_Y0()$ и после завер-

шения вычисления таблицы весов. Результаты вычитаются, переводятся в секунды, и итоговое время вычисления таблицы весов выводится в статусную панель формы (см. рис. 4):

```
start = clock();
.....
.....
end = clock();
timework = end - start;
timework = timework/1000;
Form1->StatusBar1->SimpleText = "Время вычисления" + FloatToStr(timework) + "с";
```

Для таблиц весов, приведенных на рис. 8, было потрачено время, соответственно для каждого символа: $t_A = 0,078$ с и $t_C = 0,093$ с. Эти данные были получены на компьютере с использованием про-

¹ Окончание. Начало см. *Информационно-управляющие системы*, 2020, № 2, с. 20–30. doi:10.31799/1684-8853-2020-2-20-30

цессора со скоростью работы 2,8 ГГц и оперативной памятью 1 ГБ. При использовании более быстрых конфигураций время вычисления будет меньше.

Таблицы весов на рис. 8 являются таблицами весов синапсов нулевого слоя НС. Если в НС на основе метрического метода распознавания используется N эталонов, то понадобится в общем количестве N таблиц весов. Если реализуется НС без нулевого слоя, то поскольку для N эталонов требуется $n = N(N - 1)$ нейронов первого слоя (см. рис. 2), то столько же потребуется и таблиц весов, либо понадобится $n = N(N - 1)/2$ нейронов для сжатой схемы НС [26]. При этом одна таблица весов синапсов нейрона первого слоя $W_{i,j}^{(1)}$ определяется как разность двух таблиц весов нулевого слоя $W_i^{(0)}, W_j^{(0)}$:

$$W_{i,j}^{(1)} = W_i^{(0)} - W_j^{(0)}. \quad (16)$$

Например, если в выражении (16) i и j соответствуют символам «А» и «С», приведенным на рис. 8, то в НС без нулевого слоя таблица весов нейрона первого слоя $W_{A,C}^{(1)}$ будет выглядеть так, как показано на рис. 9.

Тогда время вычисления таблиц весов синапсов T для всех нейронов нулевого слоя определится как $T = n \times t_{cp}$, где n — количество нейронов первого или второго слоя; t_{cp} — среднее время вычисления одной таблицы весов синапсов. К примеру, если мы, исходя из рис. 8, определяем среднее время вычисления таблицы весов синапсов как $t_{cp} = (0,078 + 0,093)/2 = 0,0855$ с, то для задачи распознавания алфавитных символов с количеством распознаваемых образов, равным 30, в котором

	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
0	21	15	11	7	3	1	0	0	0	0	1	4	8	12	18	25
1	21	15	9	5	2	1	0	0	0	0	1	2	5	10	16	24
2	23	15	9	4	1	0	0	-1	-1	-1	-1	1	4	8	13	20
3	19	13	8	4	1	0	-1	-2	-4	-4	-2	0	2	5	10	17
4	17	10	5	2	0	-1	-2	-5	-7	-8	-5	-2	0	4	9	16
5	13	8	4	1	-1	-4	-5	-7	-11	-12	-8	-5	-1	3	8	12
6	10	5	2	0	-2	-5	-9	-11	-14	-17	-13	-8	-4	0	4	8
7	9	4	1	-1	-4	-8	-12	-16	-21	-24	-18	-13	-8	-4	0	3
8	8	4	1	-1	-4	-9	-15	-21	-30	-31	-25	-18	-13	-9	-7	-4
9	5	2	1	-1	-4	-8	-12	-19	-24	-24	-17	-13	-8	-5	-3	0
10	4	1	0	-1	-2	-5	-10	-13	-16	-16	-13	-8	-5	-2	0	1
11	2	1	0	0	-1	-4	-5	-8	-9	-9	-8	-5	-2	-1	0	1
12	1	0	0	0	0	0	-1	-3	-3	-3	-3	-1	-1	0	0	1
13	0	0	0	0	1	4	3	3	3	3	3	0	0	0	0	1
14	-1	-1	0	1	2	5	9	9	9	9	5	2	1	0	0	-1
15	-5	-2	-1	1	4	8	13	16	16	13	8	5	2	1	-1	-2

■ **Рис. 9.** Таблица весов синапсов для нейрона первого слоя сети без нулевого слоя, определенных для пары эталонных печатных символов «А» и «С» с размерностью 16×16

■ **Fig. 9.** Table of weights for a neuron of the first layer of a neural network without a zero layer, defined for a pair samples printed characters “A” and “C” with a dimension of 16×16

для каждого образа используется в среднем по три эталона (что в целом составляет 90 эталонов), понадобится время вычисления $T = 90 \times t_{cp} \approx 7$ с для НС с нулевым слоем, $T = 90 \times 89 \times t_{cp} \approx 6,23$ мин для архитектуры расширенной НС без нулевого слоя (см. рис. 2) и $T = 90 \times 89 \times t_{cp} / 2 \approx 3$ мин для сжатой схемы НС.

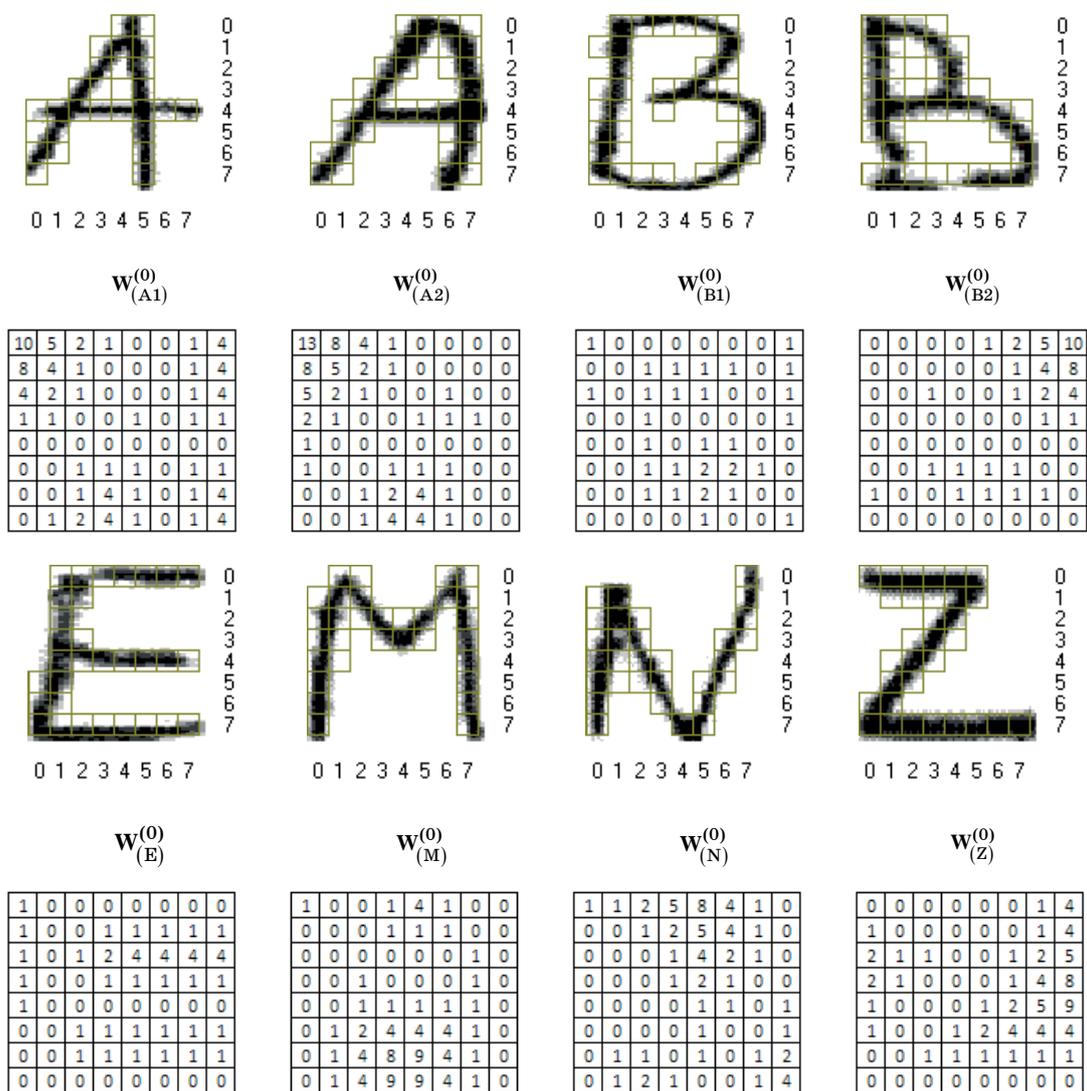
Нужно отметить, что при обучении НС классическими алгоритмами время требуется значительно большее, которое измеряется часами, а иногда и сутками. Таким образом, вычисление значения весов синапсов предлагаемым алгоритмом существенно выигрывает по времени, при этом создается уже работающая НС, которая может еще и доучаться классическими алгоритмами.

Примеры

Пример 1. Создание НС и применение вычисленных весовых значений синапсов для набора изображения букв

Приведем наглядный пример НС для задачи распознавания шести образов рукописных букв А, В, Е, М, N, Z (рис. 10). Для нашей задачи $N = 8$ (количество эталонов); образу символа «А» и «В» соответствует по два эталона, наименованные как А1, А2, В1, В2. Для наглядности и простоты примера будем также использовать схему НС с нулевым слоем (см. рис. 3).

Исходя из условия задачи количество нейронов нулевого слоя $n_0 = 8$; количество нейронов первого слоя $n_1 = 8 \times 7 = 56$; количество нейронов второго слоя равно количеству эталонов: $n_2 = 8$; количество нейронов третьего слоя равно количеству образов: $n_3 = 6$. Размерность таблицы весов синапсов примем равной 8×8 , и, таким образом, количество связей одного нейрона нулевого слоя будет равно 64. На рис. 10 приведены таблицы весов синапсов для каждого нейрона нулевого слоя, вычисленные описанным выше способом. Каждому нейрону нулевого слоя соответствует одна вычисленная таблица весов синапсов согласно их расположению на рис. 10, т. е. первому нейрону нулевого слоя соответствует таблица весов синапсов, определенная эталоном «А1», второму нейрону — эталоном «А2», третьему нейрону — эталоном «В1», четвертому нейрону — эталоном «В2», пятому нейрону — эталоном «Е», шестому нейрону — эталоном «М», седьмому нейрону — эталоном «N», восьмому нейрону — эталоном «Z». В этом же порядке определяются и выходы второго слоя. Выходы НС (выходы третьего слоя) определяются в следующем порядке: образу «А» соответствует 1-й выход, «В» — 2-й, «Е» — 3-й, «М» — 4-й, «N» — 5-й, «Z» — 6-й выход. В качестве входного тестируемого символа будем использовать значение рукописного символа



■ **Рис. 10.** Эталонные символы A1, A2, B1, B2, E, M, N, Z с размерностью матрицы разбиения изображений 8×8 и соответствующие им таблицы весов синапсов нейронов нулевого слоя
 ■ **Fig. 10.** Samples symbols A1, A2, B1, B2, E, M, N, Z with the dimension of the image partition matrix 8×8 and the corresponding tables of weights of neurons of the zero layer

ла «N», приведенного на рис. 11, а. Это означает, что в случае правильности узнавания входного символа НС 5-й выход НС должен активизироваться (стать равным 1), тогда как остальные выходы должны быть равны 0. На рис. 11, б приведена бинарная матрица входного тестируемого символа с рис. 11, а с размерностью также 8×8 . При применении тестируемого символа (см. рис. 11, а) определим формируемые значения состояний и активаций всех нейронов НС. На рис. 12 приведены таблицы умножений бинарной матрицы входного символа (см. рис. 11, а) на таблицы весов (см. рис. 10), а также значения состояния нейронов, определяемые как

$$Sw_i^{(0)} = \sum XW_i^{(0)}. \quad (17)$$

Здесь для нулевого слоя используются нейроны, у которых значения функции активации нейрона равны значению состояния нейрона:

$$f(Sw_i^{(0)}) = Sw_i^{(0)}. \quad (18)$$

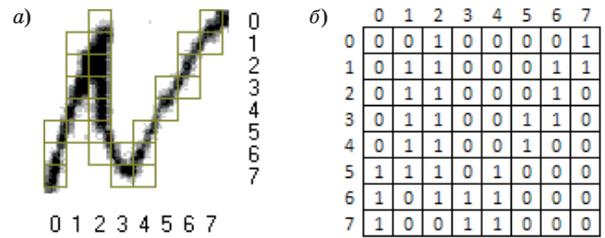
Значения функций состояний нейронов первого слоя определяются по выражению

$$Sw_{i,j}^{(1)} = Sw_i^{(0)} - Sw_j^{(0)}, \quad (19)$$

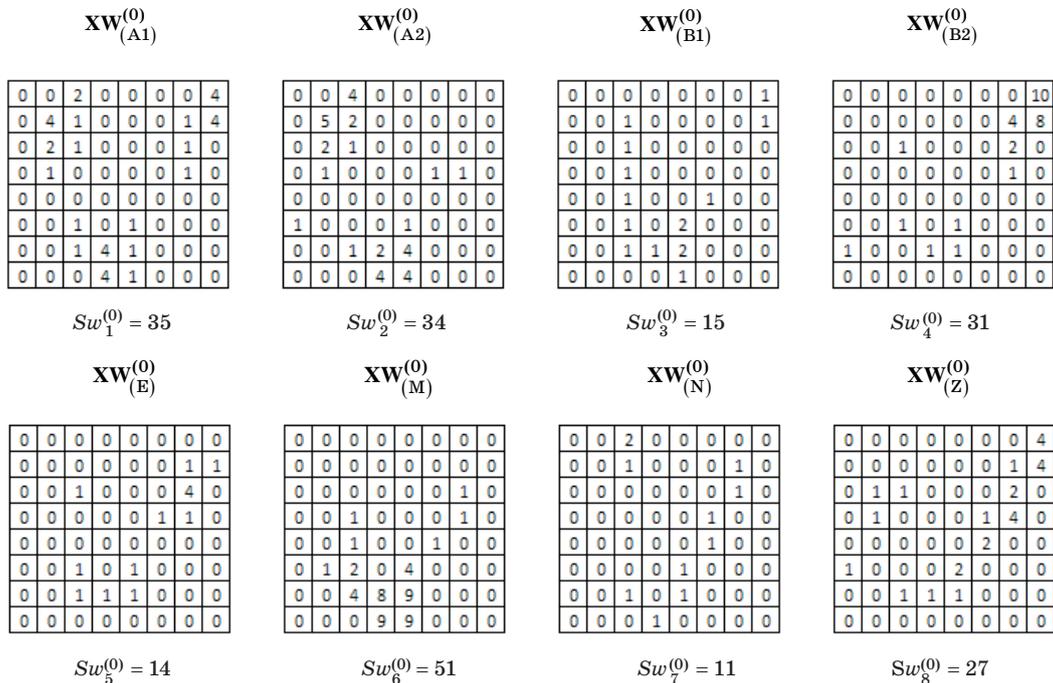
где i и j — порядковые номера попарно сравниваемых эталонов. В табл. 1 приведены значения функций состояний всех $8 \times 7 = 56$ нейронов первого слоя. Функции активации нейронов первого слоя $f(Sw_{i,j}^{(1)})$ определяются по выражению

$$\begin{cases} f(Sw_{i,j}^{(1)}) = 1, \text{ если } Sw_{i,j}^{(1)} < 0 \\ f(Sw_{i,j}^{(1)}) = 0, \text{ если } Sw_{i,j}^{(1)} \geq 0 \end{cases} \quad (20)$$

Значения всех выходов $f(Sw_{i,j}^{(1)})$ нейронов первого слоя приведены в табл. 2. Каждый нейрон второго слоя объединяет семь выходов нейронов первого слоя, в которых в выражении (19) индекс i соответствует одному и тому же эталону. Например, первый нейрон второго слоя соединен с семью нейронами первого слоя, где i в (19) и (20)



■ **Рис. 11.** Тестируемый рукописный символ «N» (а) и бинарная матрица X тестируемого символа (б)
 ■ **Fig. 11.** Test handwritten character “N” (a) and binary matrix of the test character X (b)



■ **Рис. 12.** Таблицы значений произведений бинарной матрицы X тестируемого (входного) символа с таблицами весов синапсов нейронов нулевого слоя W^0 и значения функций состояния $Sw_i^{(0)}$ нейронов нулевого слоя
 ■ **Fig. 12.** Tables of product values of the binary matrix X of the test (input) symbol with tables of weights of the zero layer neurons W^0 and values of the state functions $Sw_i^{(0)}$ of zero layer neurons

■ **Таблица 1.** Значения функций состояний $Sw_{i,j}^{(1)}$ (19) нейронов первого слоя
 ■ **Table 1.** Values of state functions $Sw_{i,j}^{(1)}$ (19) neurons of the first layer

Символ, i , $Sw_i^{(0)}$	Символ, j , $Sw_j^{(0)}$							
	A1, 1, 35	A2, 2, 34	B1, 3, 15	B2, 4, 31	E, 5, 14	M, 6, 51	N, 7, 11	Z, 8, 27
A1, 1, 35		1	20	4	21	-16	24	8
A2, 2, 34	-1		19	3	20	-17	23	7
B1, 3, 15	-20	-19		-16	1	-36	4	-12
B2, 4, 31	-4	-3	16		17	-20	20	4
E, 5, 14	-21	-20	-1	-17		-37	3	-13
M, 6, 51	16	17	36	20	37		40	24
N, 7, 11	-24	-23	-4	-20	-3	-40		-16
Z, 8, 27	-8	-7	12	-4	13	-24	16	

■ **Таблица 2.** Значения выходов нейронов первого, второго и третьего слоя
 ■ **Table 2.** The values of the outputs of the neurons of the first, second and third layer

Символ, <i>i</i>	Символ, <i>j</i>								Второй слой		Третий слой	
	A1, 1	A2, 2	B1, 3	B2, 4	E, 5	M, 6	N, 7	Z, 8	$Sw_k^{(2)}$	$f(Sw_k^{(2)})$	$Sw_{\text{ооп}}^{(3)}$	Y_{out}
	$f(Sw_{i,j}^{(1)})$											
A1, 1		1	20	4	21	-16	24	8	1	0	0 + 0 = 0	0
A2, 2	-1		19	3	20	-17	23	7	2	0		0
B1, 3	-20	-19		-16	1	-36	4	-12	5	0	0 + 0 = 0	0
B2, 4	-4	-3	16		17	-20	20	4	3	0		0
E, 5	-21	-20	-1	-17		-37	3	-13	6	0	0	0
M, 6	16	17	36	20	37		40	24	0	0	0	0
N, 7	-24	-23	-4	-20	-3	-40		-16	7	1	1	1
Z, 8	-8	-7	12	-4	13	-24	16		4	0	0	0

определяет эталон «A1»: $f(Sw_{A1,A2}^{(1)})$, $f(Sw_{A1,B1}^{(1)})$, $f(Sw_{A1,B2}^{(1)})$, $f(Sw_{A1,E}^{(1)})$, $f(Sw_{A1,M}^{(1)})$, $f(Sw_{A1,N}^{(1)})$, $f(Sw_{A1,Z}^{(1)})$. Соответственно, активный выход *i*-го нейрона второго слоя определяет схожесть входного распознаваемого элемента к эталону «A1». Аналогично и по другим нейронам второго слоя. Функции состояния нейрона второго слоя для расширенных схем рис. 2, 3 определяются следующим образом [26, 27]:

$$Sn_k^{(2)} = \alpha \sum_{j=1, j \neq k}^{N-1} f(Sn_{k,j}^{(1)}); \quad (21)$$

$$\begin{cases} f(Sn_k^{(2)}) = 1, \text{ если } Sn_k^{(2)} \geq \alpha(N-1) = H_k^{(2)} \\ f(Sn_k^{(2)}) = 0, \text{ если } Sn_k^{(2)} < \alpha(N-1) = H_k^{(2)} \end{cases}, \quad (22)$$

где *N* — количество эталонов; α — постоянная величина, определяющая значение веса $w_k^{(2)}$ входных связей нейронов второго слоя. В данном примере $\alpha = 1$; $H_k^{(2)} = \alpha(N - 1) = 7$ — порог нейрона второго слоя. Поскольку для данного примера количество эталонов равно восьми, то порог $H_k^{(2)} = 7$ для всех нейронов второго слоя. В табл. 2 показаны также значения функций состояний $Sw_k^{(2)}$ активации $f(Sw_k^{(2)})$ нейронов второго слоя согласно приведенным выражениям (21), (22). Можно видеть, что уже на этом этапе 7-й выход второго слоя, соответствующий эталону «N», является активным. В третьем слое НС выполняется объединение нейронов одного образа в одном нейроне. Для данного примера третий слой необходим для первого и второго образов «А» и «В», поскольку эти образы имеют по два эталона и их выходы объединяются в нейронах третьего слоя. Функции состояния $Sn_k^{(3)}$ и $f(Sn_k^{(3)})$ активации нейрона третьего слоя определяются следующим образом:

$$Sn_k^{(3)} = \sum_{j=1}^K (\alpha \times f(Sn_j^{(2)})); \quad (23)$$

$$\begin{cases} f(Sn_k^{(3)}) = 1, \text{ если } Sn_k^{(3)} > 0 \\ f(Sn_k^{(3)}) = 0, \text{ если } Sn_k^{(3)} \leq 0 \end{cases}, \quad (24)$$

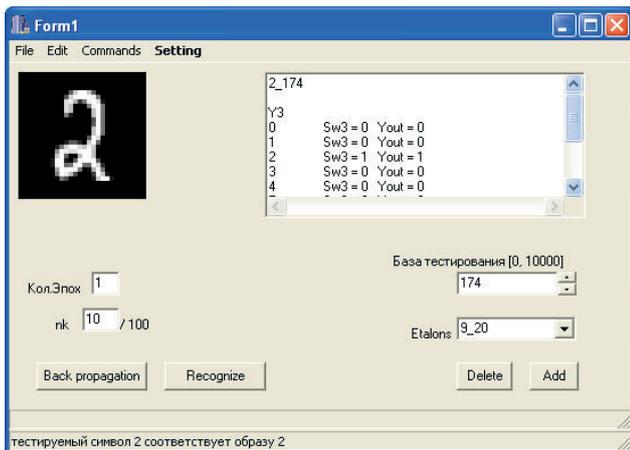
где *K* — количество эталонов в *k*-м образе; α — постоянное значение, определяющее значение веса связей нейронов третьего слоя $w_k^{(3)}$, для данного примера также $\alpha = 1$.

Из табл. 2 можно видеть, что в итоге для входного символа на рис. 11, *a* активизируется 5-й выход НС, соответствующий образу «N».

Пример 2. Создание и обучение НС на основе базы цифр MNIST

В данном примере НС создается и далее обучается на базе MNIST (рис. 13). Набор эталонов набирается из базы MNIST, размерность таблицы весов синапсов определяется также на основе размерности матрицы изображений базы MNIST, превышая ее в два раза (28 × 56). Дальнейшее дообучение сети выполняется также на базе MNIST. Для оценки эффективности полученной сети обучение той же НС выполняется и классическим способом со случайной инициализацией всех весов НС. Результаты сравниваются.

Напомним, что база MNIST состоит из обучающей базы, в которую входят 60 000 изображений рукописных цифр, и контрольной (тестовой) базы, состоящей из 10 000 образцов изображений цифр. Каждой базе также прилагается своя база наименований цифр, порядок расположения которых такой же, как и порядок расположения изображений цифр в обучающей и контрольной базах. Изображения цифр в базах описаны в виде матрицы цифр размерностью 28 × 28. Каждая

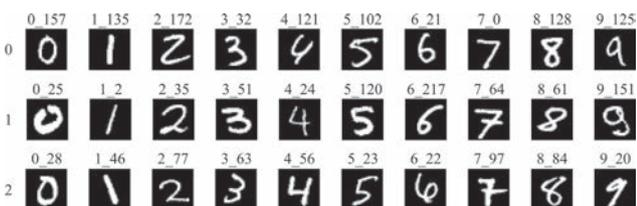


■ **Рис. 13.** Программный модуль для распознавания и обучения изображений базы MNIST, реализованный в среде Builder C++

■ **Fig. 13.** Software module for recognition and training of images of the MNIST base, implemented in the Builder C++ environment

цифра матрицы определяет значение тональности одного пикселя изображения цифры в диапазоне [0, 255].

В качестве эталонов было выбрано по три образца изображений цифр от каждого образа. Итого использовалось 30 эталонов (рис. 14). Эталоны были выбраны интуитивно из первых 250 изображений цифр контрольной базы MNIST. Над каждым выбранным эталоном приведено наименование изображения, например 2_35, в котором первая цифра 2 указывает образ, которому принадлежит изображение цифры, число 35 указывает порядковый номер данного изображения цифры в базе MNIST. Поскольку количество эталонов равно 30, то в соответствии с архитектурой НС, реализующих метрические методы распознавания, количество нейронов второго слоя будет равно также 30. Эталоны в рассматриваемой задаче расположены в такой же последовательности, как на рис. 14. Сначала столбец с изображениями цифры «0», потом цифры «1» и т. д. В соответствии с этим схема сети на рис. 2



■ **Рис. 14.** Выбранные эталоны из контрольной базы MNIST

■ **Fig. 14.** Selected samples from the MNIST control base

определяет и выходы второго слоя. Количество нейронов третьего слоя равно количеству распознаваемых образов цифр: $n^{(3)} = 10$. Каждый i -й выход третьего слоя определяет принадлежность распознаваемого элемента к i -му образу цифры. Порядок образов цифр определен последовательно от 0 до 9.

Количество нейронов первого слоя $n^{(1)} = 30 \times 29 = 870$. В процессе распознавания или обучения для каждого входного распознаваемого изображения составляется бинарная матрица, которая, в отличие от первого примера на рис. 11, б, будет состоять из двух частей. В первой части бинарной матрицы единицы определяют светлые пиксели изображения, значения которых >150 , и наоборот, нули определяют затемненные пиксели изображения, значения которых <150 . Другая часть матрицы зеркально противоположна, определяет активными ($= 1$) темные пиксели изображений (<150) и неактивными ($= 0$) светлые пиксели изображений (>150). Соответственно, размерность бинарной матрицы равна 28×56 . Каждая таблица весов синапсов нулевого слоя соразмерна с бинарной матрицей и состоит также из двух частей (рис. 15, а и б).

Соответственно, таблица весов синапсов первого слоя определяется на основе выражения (19).

Прежде чем начать обучение НС (см. рис. 2) алгоритмом *back propagation*, необходимо провести некоторые преобразования в сети. Поскольку значения весов синапсов первого слоя получаются большими, в основном располагаются в диапазоне [0, 100], что не рекомендуется для алгоритма *back propagation*, то каждое значение веса синапсов первого слоя делится на 100, что не меняет результативность полученной сети. На рис. 16, а и б приведен пример таблицы весов синапсов первого слоя, вычисленных для пары эталонов 2_172 и 5_102. Таким образом, для каждого нейрона первого слоя вычисляется 870 таблиц весов синапсов. При этом нужно отметить, что в данном примере при обучении НС нейроны нулевого слоя не используются, рассматриваться будет только полученная трехслойная сеть (см. рис. 2).

Нейронная сеть на рис. 2 является сетью прямого распространения, но при этом второй и третий слой не являются полносвязными. В работе [5] были приведены обобщенный алгоритм создания полносвязной НС и вычисления значений весов синапсов второго и третьего слоя, при которых сохраняется первоначальная логика работы сети. Но в простейшем случае из схемы на рис. 2 полносвязную НС можно получить добавлением всех недостающих связей второго и третьего слоя, значения весов синапсов которых будут приравнены к нулю. В этом случае логика работы сети на рис. 2 также не изменится. На рис. 17, а и б приведены значения весов связей нейронов второго и треть-



100	85	72	61	52	45	40	37	34	29	25	20	17	16	16	16	16	16	16	16	17	20	25	32	41	50	61			
89	74	61	50	41	34	29	26	25	20	17	13	10	9	9	9	9	9	9	9	9	10	13	18	25	32	41	52		
80	65	52	41	32	25	20	17	16	13	10	8	5	4	4	4	4	4	4	4	4	4	5	8	13	18	25	34	45	
73	58	45	34	25	18	13	10	9	8	5	4	2	1	1	1	1	1	1	1	1	1	2	5	8	13	20	29	40	
68	53	40	29	20	13	8	5	4	2	1	1	0	0	0	0	0	0	0	0	0	0	1	2	5	10	17	26	37	
65	50	37	26	17	10	5	2	1	1	1	0	0	0	0	0	0	0	0	0	0	0	0	1	4	9	16	25	36	
64	49	36	25	16	9	4	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	4	9	16	25	36	
64	49	36	25	16	9	4	1	0	0	0	0	1	1	1	1	1	1	0	0	0	0	1	4	9	16	25	36		
65	50	37	26	17	10	5	2	1	1	1	1	2	4	4	2	1	0	0	0	0	0	1	2	5	10	17	26	37	
68	53	40	29	20	13	8	5	4	4	4	4	3	2	1	0	0	0	0	0	0	1	2	5	8	13	20	29	40	
73	58	45	34	25	18	13	10	9	8	5	2	1	0	0	0	0	0	0	0	0	1	2	5	8	13	18	25	34	45
80	65	52	41	32	25	20	17	16	13	8	5	2	1	0	0	0	1	1	2	5	8	13	18	25	32	41	52		
85	72	61	50	41	32	25	18	13	8	5	2	1	0	0	0	1	2	4	5	8	13	18	25	32	36	37	40		
72	61	50	41	32	25	18	13	8	5	2	1	0	0	0	1	2	5	8	13	18	20	17	16	13	10	9	9	10	13
61	50	41	32	25	18	13	8	5	2	1	0	0	0	1	2	5	8	13	17	20	25	20	17	16	16	17	20		
52	41	32	25	18	13	8	5	2	1	0	0	0	1	2	5	8	13	18	20	17	16	13	10	9	9	10	13		
45	34	25	18	13	8	5	2	1	0	0	0	1	2	5	8	13	16	13	10	9	8	5	4	4	5	8			
40	29	20	13	8	5	2	1	0	0	0	1	2	5	8	13	10	9	8	5	4	4	2	1	1	2	5			
37	26	17	10	5	2	1	0	0	0	1	2	5	8	9	8	5	4	4	2	1	1	1	0	0	0	1	4		
36	25	16	9	4	1	0	0	0	1	2	5	4	4	4	4	2	1	1	1	0	0	0	0	1	2	5			
36	25	16	9	4	1	0	0	0	1	4	2	1	1	1	1	0	0	0	0	0	0	0	1	1	2	5	8		
36	25	16	9	4	1	0	0	0	1	1	1	0	0	0	0	0	0	0	1	1	1	2	4	5	8	13			
37	26	17	10	5	2	1	0	0	0	0	0	0	0	0	0	1	1	2	4	4	5	8	10	13	18				
40	29	20	13	8	5	2	1	0	0	0	0	1	1	1	2	4	4	5	8	9	10	13	17	20	25				
45	34	25	18	13	8	5	4	2	1	1	1	2	4	4	5	8	9	10	13	16	17	20	25	29	34				
52	41	32	25	18	13	10	8	5	4	4	4	5	8	9	10	13	16	17	20	25	26	29	34	40	45				
61	50	41	32	25	17	13	10	9	8	9	9	10	13	16	17	20	25	26	29	34	37	40	45	52	58				
72	61	50	41	34	29	25	20	17	16	16	16	17	20	25	26	29	34	37	40	45	50	55	58	65	73				

■ **Рис. 15.** Таблица весов синапсов нулевого слоя НС для эталона 2_172: *a* — для части бинарной таблицы, в которой светлым пикселям (>150) изображения соответствует 1; *b* — для части бинарной таблицы, в которой затемненными пикселям (<150) соответствует 1

■ **Fig. 15.** Table of weights of the neural network zero layer for sample 2_172: *a* — for the part of the binary table in which light pixels (>150) of the image correspond to 1; *b* — for the part of the binary table in which the darkened pixels (<150) correspond 1

го слоя, расположенных горизонтально в строках. Например, на рис. 17, *b* количество последовательных единиц в строке определяется количеством эталонов, принадлежащих одному образу цифры. В данном примере это значение одинаково для всех образов и равно трем (см. рис. 14). Над каждой строкой также приведены пороговые значения нейронов, представленные в качестве веса синапса, противоположного по знаку пороговому значению нейронов: $Wh2 = -H_k^{(2)} = -29$.

В качестве функции активации нейронов использовалась сигмоидная функция активации

$$f(Sw) = \frac{1}{1 + e^{-Sw}}. \quad (25)$$

Поскольку для схемы сети на рис. 2 все весовые значения синапсов нейронов второго и третьего слоя являются положительными, то и все выходы нейронов третьего слоя, вычисленные с сигмоидной функцией активации (25), больше 0,5. Это можно наблюдать в табл. 3, где приведены выходы третьего слоя при распознавании изображения 2_174 (см. рис. 13). Из табл. 3 можно также видеть, что выход, соответствующий правильному образу цифры (3-й выход с номером 2), имеет наибольшее значение >0,51. Исходя из этого в качестве правила сравнения на выходе

НС было использовано значение не 0,5, а 0,51. Другой используемый в данном примере способ определения активности выхода нейрона третьего слоя — по наибольшему значению выхода Y_i НС. Например, как показано в табл. 3, наибольшее значение принадлежит третьему выходу с номером 2, соответствующему образу цифры «2».

В итоге на весь процесс создания НС и вычисления всех весов синапсов (в том числе и весов синапсов нулевого слоя) в программном модуле рис. 13 было зафиксировано общее потраченное время $t_{созд} = 0,5469$ с. Это значительно меньше, чем приведенные предыдущие оценки, даже с учетом большей размерности таблицы весов синапсов (28 × 64). Связано это, видимо, с самим форматом представления изображений в базе MNIST, поскольку изображения базы MNIST представлены уже в виде текста со значениями пикселей, т. е. для изображений базы MNIST не требуется выполнять попиксельное сканирование ячеек изображений, как это делалось в предыдущем примере.

В табл. 4 приведены результаты распознавания контрольной базы MNIST (10 000 изображений) на основе полученной НС с вычисленными весами синапсов с использованием как пороговой, так и сигмоидной функции активации. Также приведены количество и процент правиль-

■ **Таблица 3.** Выходы третьего слоя НС с пороговой и сигмоидной функцией активации при распознавании символа 2_174 (см. рис. 13) из контрольной базы MNIST

■ **Table 3.** Outputs of the third layer of a neural network with a threshold and sigmoidal activation function upon recognition of the 2_174 symbol (see Fig. 13) from the MNIST control base

Функция активации					
пороговая			сигмоидная		
Выход	$Sw3$	Y_{out}	Выход	$Sw3$	Y_{out}
0	0	0	0	0,000270242677595017	0,500067560668988
1	0	0	1	3,43951083407716E-6	0,500000859877708
2	1	1	2	0,0526576299057448	0,513161366435398
3	0	0	3	0,0109778057331013	0,502744423871947
4	0	0	4	9,28464982946175E-6	0,500002321162457
5	0	0	5	0,000934588149375769	0,500233647020337
6	0	0	6	0,000250751415905857	0,500062687853648
7	0	0	7	1,20144980966343E-7	0,500000030036245
8	0	0	8	0,014626235919069	0,503656493794839
9	0	0	9	0,00149247436075622	0,50037311852093

■ **Таблица 4.** Результаты распознавания контрольной базы MNIST (10 000 символов) без обучения

■ **Table 4.** MNIST control base recognition results (10 000 characters) without learning

Функция активации					
пороговая			сигмоидная		
s	i	$p, \%$	s	i	$p, \%$
$s_0 = 834$	$i_0 = 980$	$p_0 = 85$	$s_0 = 962$	$i_0 = 980$	$p_0 = 98$
$s_1 = 968$	$i_1 = 1135$	$p_1 = 85$	$s_1 = 872$	$i_1 = 1135$	$p_1 = 76$
$s_2 = 530$	$i_2 = 1032$	$p_2 = 51$	$s_2 = 530$	$i_2 = 1032$	$p_2 = 51$
$s_3 = 454$	$i_3 = 1010$	$p_3 = 44$	$s_3 = 420$	$i_3 = 1010$	$p_3 = 41$
$s_4 = 410$	$i_4 = 982$	$p_4 = 41$	$s_4 = 487$	$i_4 = 982$	$p_4 = 49$
$s_5 = 411$	$i_5 = 892$	$p_5 = 46$	$s_5 = 421$	$i_5 = 892$	$p_5 = 47$
$s_6 = 586$	$i_6 = 958$	$p_6 = 61$	$s_6 = 151$	$i_6 = 958$	$p_6 = 15$
$s_7 = 556$	$i_7 = 1028$	$p_7 = 54$	$s_7 = 499$	$i_7 = 1028$	$p_7 = 48$
$s_8 = 773$	$i_8 = 974$	$p_8 = 79$	$s_8 = 298$	$i_8 = 974$	$p_8 = 30$
$s_9 = 750$	$i_9 = 1009$	$p_9 = 74$	$s_9 = 227$	$i_9 = 1009$	$p_9 = 22$
Итого: $s = 6272, i = 10\ 000, p = 62 \%$			Итого: $s = 4867, i = 10\ 000, p = 48 \%$		

но идентифицированных объектов контрольной базы MNIST отдельно для каждого образа цифры (s_j, p_j , где j — наименование образа), а также приводится общее количество изображений i_j для каждого j -образа в контрольной базе MNIST.

По данным табл. 4 можно видеть, что общее количество правильно идентифицированных изображений MNIST составило 62 % для НС с пороговой функцией активации и 48 % с сигмоидной

функцией активации. Падение до 48 % объясняется тем, что установленное правило проверки на выходе ($>0,51$) в некоторых случаях приводит к ошибкам активации одновременно нескольких выходов третьего слоя, а в некоторых случаях, наоборот, к тому, что на выходе НС нет активных выходов, в результате чего итоговое количество правильно узанных изображений уменьшается на 14 %. В действительности потенциал вычис-

ленных значений весов синапсов сохраняется и с сигмоидной функцией активации, что подтверждается также распознаванием контрольной базы MNIST НС с сигмоидной функцией активации и с проверкой на выходе НС по наибольшему значению выхода Y_i . В этом случае результат НС с сигмоидной функцией активации идентичен результату НС с пороговой функцией активации и равен также 62 %.

Обучение НС выполнялось стохастическим алгоритмом обратного распространения (*back propagation*) с использованием обучающей выборки MNIST, состоящей из 60 000 изображений. Поправки вносились после каждого представления нового объекта на входы сети и только в случае наличия ошибки распознавания на выходе НС. При обучении активность выхода оценивалась по правилу $>0,51$. Для каждого эксперимента обучения НС использовались три эпохи, из которых первые две обучались со скоростью $nk = 0,1$, а последняя со скоростью $nk = 0,02$. Ошибка обучения вычислялась для каждой эпохи по формуле

$$S_{err} = \frac{1}{2} \sum_{i=0}^P \sum_{k=0}^{N_{обп}} \left(y_k^{(corr)} - f(Sn_k^{(3)}) \right), \quad (26)$$

где $y_k^{(corr)}$ — принятое правильное значение k -го выхода третьего слоя, для активного выхода $y_k^{(corr)} = 0,7$, для неактивного $y_k^{(corr)} = 0,2$; P — количество неправильно идентифицированных изображений обучающей базы MNIST, для которых в процессе эпохи делались правки весов синапсов алгоритмом обратного распространения ошибки.

В табл. 5 приведены результаты обучений полученной НС как с предварительно вычисленными значениями весов синапсов НС, так и классическим образом — со случайной инициализацией весов синапсов. В табл. 5 можно видеть, что для случая обучения с предварительно вычисленными весами результаты по всем параметрам и на всех трех эпохах лучше по сравнению с результатами обучения НС со случайной инициализацией весов синапсов. При этом общее время, потраченное на обучение НС с предварительно вычисленными весами синапсов, на 2 ч 50 мин (499 – 329 = 170 мин) меньше.

В табл. 6 приведены результаты проверки полученной НС после каждой эпохи обучения на контрольной базе MNIST (10 000 изображений). Проверка выполнялась как по правилу $>0,51$

■ **Таблица 5.** Сравнение результатов обучения НС по обучающей выборке MNIST (60 000 изображений) для каждой эпохи обучения

■ **Table 5.** Comparison of the results of training the neural network in the training set MNIST (60 000 images) for each epoch of training

№ эпохи	Скорость обучения в эпохе	Обучение НС с предварительно вычисленными весами				Обучение НС со случайной инициализацией весов в диапазоне $[-0,5; 0,5]$			
		Количество узнанных изображений	% узнанных изображений	S_{err}	Время, мин	Количество узнанных изображений	% узнанных изображений	S_{err}	Время, мин
1	0,1	43 932	73	1199	159	35 370	59	1935	256
2	0,1	49 748	83	737	98	46 033	76	1051	139
3	0,02	52 285	87	545	72	49 195	82	784	104
Общее время обучения					329	Общее время обучения			499

■ **Таблица 6.** Сравнение результатов обучения НС с проверкой на контрольной выборке MNIST (10 000 изображений) для каждой эпохи обучения

■ **Table 6.** Comparison of the results of training a neural network with testing on a control sample MNIST (10 000 images) for each era of training

№ эпохи	Скорость обучения в эпохе	Обучение НС с предварительно вычисленными весами		Обучение НС со случайной инициализацией весов	
		Количество узнанных изображений по правилу $>0,51$	Количество узнанных изображений по наибольшему значению	Количество узнанных изображений по правилу $>0,51$	Количество узнанных изображений по наибольшему значению
1	0,1	8140	9145	7506	8894
2	0,1	8557	9282	8022	9116
3	0,02	8764	9449	8194	9256

на выходе третьего слоя, так и по наибольшему значению выхода третьего слоя. В табл. 6 также можно видеть, что на всех эпохах количество узнанных изображений контрольной базы MNIST больше для случая обучения НС с предварительно вычисленными весами. Наибольшее количество узнанных изображений было достигнуто после третьей эпохи обучения НС с предварительно вычисленными весами синапсов и с проверкой по наибольшему значению выходов третьего слоя, что составило 9449 изображений, 94 %. Результаты табл. 5 и 6 можно объяснить тем, что алгоритм обучения отталкивается от тех начальных результатов, которые НС уже имеет. То есть можно сказать, что чем больше начальная результативность НС, тем больше у алгоритма обучения возможности и времени для того, чтобы добраться до более лучших результатов обучений за одну эпоху. По этой же причине с лучшими начальными результатами (с вычисленными весами синапсов) алгоритму обучения требуется меньше времени на обучение сети. При этом можно также сказать, что с большим количеством выбранных эталонов (больше чем три на один образ) начальная результативность сети была бы также больше (>62 %), соответственно, и результаты, приведенные в табл. 5 и 6, могли быть еще более выраженными.

Выводы

Таким образом, процесс вычисления таблиц весов синапсов НС на основе метрических методов распознавания при помощи существующих вычислительных средств позволяет существенно ускорить процедуры создания и обучения НС. В зависимости от параметров эталонных изображений: размеров изображений, количества

пикселей, — а также в зависимости от размерности таблицы весов и общего количества эталонов время вычисления весов исчисляется считанными долями секунд и минут. Это означает, что процедура вычисления значений весов синапсов НС позволяет выполнить существенный скачок по времени в процессе создания и обучения НС. Наименьшее время вычисления значений весов будет свойственно для архитектуры НС с нулевым слоем (см. рис. 3), поскольку для этой архитектуры количество таблиц весов будет минимально и равно количеству используемых эталонов.

Нужно также отметить, что в качестве объектов распознавания могут использоваться не только однотонные черно-белые изображения, но и более сложные объекты, например, полутонные черно-белые и цветные изображения. В этих случаях используемые метрические меры близости могут быть более сложными. Для данного случая, как один из вариантов, таблицы весов для полутонных черно-белых изображений будут трехмерными, а для цветных изображений, помимо трехмерности таблиц, один образец-эталон цветного изображения может быть представлен несколькими черно-белыми эталонами в соответствии с количеством цветовой гаммы цветного изображения (RGB, CMYK и т. д.). В качестве выражения меры близости может быть, например, использовано выражение среднеквадратичной разности в трехмерном пространстве. При этом в рассмотренном выше алгоритме ячейки трехмерной таблицы весов будут перебираться не только по оси X , Y , но еще и по оси Z . Соответственно, для более сложных задач потребуются и больше эталонов и большая размерность таблиц весов синапсов. С увеличением этих параметров результативность НС будет также увеличиваться, но при этом будут увеличиваться и количество нейронов, и количество связей НС.

Литература

1. Азаров И. С., Петровский А. А. Формирование персональной модели голоса диктора с универсальным фонетическим пространством признаков на основе искусственной нейронной сети. *Труды СПИИРАН*, 2014, № 5, с. 12–15. <https://doi.org/10.15622/sp.36.8>
2. Будко Р. Ю., Старченко И. Б. Создание классификатора мимических движений на основе анализа электромиограммы. *Труды СПИИРАН*, 2016, № 3 (46), с. 76–89. <https://doi.org/10.15622/sp.46.7>
3. Осипов В. Ю., Никифоров В. В. Возможности рекуррентных нейронных сетей с управляемыми элементами по восстановлению потоков кадров. *Информационно-управляющие системы*, 2019, № 5, с. 10–17. doi.org/10.31799/1684-8853-2019-5-10-17
4. Ле Т. Ч. Сравнение нейронной сети СМАС и многослойной нейронной сети в задаче обнаружения DoS-атак. *Нейрокомпьютеры: разработка, применение*, 2016, № 7, с. 65–69.
5. Катасев А. С., Катасева Д. В., Кирпичников А. П. Распознавание рукописных символов на базе искусственной нейронной сети. *Вестник технологического университета*, 2018, т. 18, № 11, с. 173–176.
6. Дрокин И. С. Об одном алгоритме последовательной инициализации весов глубоких нейронных сетей и обучении ансамбля нейронных сетей. *Вестник Санкт-Петербургского университета. Прикладная математика. Информатика. Процессы управления*, 2016, № 4, с. 66–74.
7. Лещенко Ю. Е. Ассоциативно-вербальные сети и искусственные нейронные сети как метод моделирования ментального лексикона индивида. *Гло-*

- бальный научный потенциал, 2014, № 10 (43), с. 154–156.
8. Гафуров Д. О., Гафуров О. М., Конторович В. А. Интерпретация данных геофизических исследований Талаканского нефтегазоконденсатного месторождения обучаемыми нейронными сетями, прогноз строения Осинского горизонта. *Технологии сейсморазведки*, 2014, № 4, с. 85–92.
 9. Владимирова Д. Б., Кокшарова А. А. Прогнозирование финансовых рынков искусственными нейронными сетями. *Наука и бизнес: пути развития*, 2014, № 3 (33), с. 42–46.
 10. Синчук О. Н., Бойко С. Н. Нейронные сети и управление процессом управления электроснабжением объектов от комбинированных электрических сетей. *Технічна електродинаміка*, 2014, № 5, с. 53–55.
 11. Шведов В. А., Ильин Е. С. Распознавания дорожных знаков сверточными нейронными сетями различной структуры, с применением графических процессоров CUDA. *Транспортная инфраструктура Сибирского региона: материалы Шестой международной научно-практической конференции*, Иркутск, 30 сентября–03 октября 2015 г., 2015, т. 2, с. 282–286.
 12. Туровский Я. А., Кургалин С. Д., Адаменко А. А. Сравнительный анализ программных пакетов для работы с искусственными нейронными сетями. *Вестник Воронежского государственного университета. Серия: Системный анализ и информационные технологии*, 2016, № 1, с. 161–168.
 13. Лукина А. С., Некрасов М. В., Пакман Д. Н. Обработка телеметрической информации космического аппарата нейронными сетями на основе теории фильтров Калмана. *Тенденции развития науки и образования*, 2016, № 13-1, с. 43–45.
 14. Стасюк В. В. Прогнозирование чувствительности к удару взрывчатых веществ нейронными сетями с предварительной группировкой данных. *Фундаментальные исследования*, 2015, № 12–6, с. 1139–1143.
 15. Хусаинов А. Т. Оценка прогнозируемости системы поддержания пластового давления нейронными сетями на нефтяных месторождениях. *Академический журнал Западной Сибири*, 2016, т. 12, № 3 (64), с. 48.
 16. Бондарко В. М., Бондарко Д. В., Солнушкин С. Д., Чихман В. Н. Моделирование результатов психофизических экспериментов нейронными сетями. *Нейрокомпьютеры: разработка, применение*, 2018, № 5, с. 31–33.
 17. Sedov V. A., Sedova N. A. Modelling collision avoidance actions in closest approach zones by means of neural networks. *Asia-Pacific Journal of Marine Science & Education*, 2014, vol. 4, no. 2, pp. 104–111.
 18. Peng Shi, Fanbiao Li, Ligang Wu. Neural network-based passive filtering for delayed neutral-type semi-Markovian jump systems. *IEEE Transactions on Neural Networks and Learning Systems*, 2017, vol. 28, iss. 9, pp. 2101–2114.
 19. Chenggang Yan, Hongtao Xie, Dongbao Yang, Jian Yin, Yongdong Zhang, Qionghai Dai. Supervised hash coding with deep neural network for environment perception of intelligent vehicles. *IEEE Transactions on Intelligent Transportation Systems*, 2018, vol. 19, iss. 1, pp. 284–295.
 20. Anusha N., Gregory K., Ronald S. F., Sergey Levine. Neural network dynamics for model-based deep reinforcement learning with model-free fine-tuning. *2018 IEEE International Conference on Robotics and Automation (ICRA)*, Brisbane, Australia, 2018, pp. 156–162.
 21. Wei He, Yuhao Chen, Zhao Yin. Adaptive neural network control of an uncertain robot with full-state constraints. *IEEE Transactions on Cybernetics*, 2016, vol. 46, iss. 3, pp. 620–629.
 22. Song Han, Xingyu Liu, Huizi Mao, Jing Pu, Arda van Pedram, Mark A. H., William J. Efficient inference engine on compressed deep neural network. *2016 ACM/IEEE 43rd Annual International Symposium on Computer Architecture (ISCA)*, Seoul, South Korea, 2016, pp. 304–309.
 23. William Chan, Navdeep Jaitly, Quoc Le, Oriol Vinyals. Listen, attend and spell: A neural network for large vocabulary conversational speech recognition. *2016 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, Shanghai, China, 2016, pp. 107–115.
 24. Andre Esteva, Brett Kuprel, Roberto A. Novoa, Justin Ko, Susan M. Swetter, Helen M. Blau, Sebastian Thrun. Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 2017, vol. 542, pp. 115–118.
 25. Круглов В. В., Борисов В. В. *Искусственные нейронные сети. Теория и практика*. М., Горячая линия–Телеком, 2001. 328 с.
 26. Geidarov P. Sh. Neural networks on the basis of the sample method. *Automatic Control and Computer Sciences*, 2009, vol. 43, pp. 203–210. <https://doi.org/10.3103/S0146411609040063>
 27. Гейдаров П. Ш. Алгоритм реализации метода ближайшего соседа в многослойном перцептроне. *Труды СПИИРАН*, 2017, т. 51, с. 123–151. <https://doi.org/10.15622/sp.51.6>
 28. Биргрет И. А. *Техническая диагностика*. М., Машиностроение, 1978. 240 с.

UDC 007.519.7

doi:10.31799/1684-8853-2020-3-25-38

Algorithm for calculating synapse weights of the first layer of a neural network on the base of metric recognition methods. Part 2P. Sh. Geidarov^a, PhD, Tech., Associate Professor, orcid.org/0000-0002-3881-0629, plbaku2010@gmail.com^aAzerbaijan National Academy of Sciences Institute of Control Systems, 9, Bahtijar Vagabzade St., Az 1141, Baku, Azerbaijan

Introduction: Metric recognition methods make it possible to preliminarily and strictly determine the structures of feed-forward neural networks, namely, the number of neurons, layers, and connections based on the initial parameters of the recognition problem. They also make it possible to analytically calculate the synapse weights of network neurons based on metric expressions. The setup procedure for these networks includes a sequential analytical calculation of the values of each synapse weight in the weight table for neurons of the zero or first layer, which allows us to obtain a working feed-forward neural network at the initial stage without the use of training algorithms. Then feed-forward neural networks can be trained by well-known learning algorithms, which generally speeds up the process of their creation and training. **Purpose:** To determine how much time the process of calculating the values of weights requires and, accordingly, how reasonable it is to preliminarily calculate the weights of a feed-forward neural network. **Results:** An algorithm is proposed and implemented for the automated calculation of all values of synapse weight tables for the zero and first layers as applied to the task of recognizing black-and-white monochrome symbol images. The proposed algorithm is described in the Builder C++ software environment. The possibility of optimizing the process of calculating the weights of synapses in order to accelerate the entire algorithm is considered. The time spent on calculating these weights for different configurations of neural networks based on metric recognition methods is estimated. Examples of creating and calculating synapse weight tables according to the considered algorithm are given. According to them, the analytical calculation of the weights of a neural network takes just seconds or minutes, being in no way comparable to the time necessary for training a neural network. **Practical relevance:** Analytical calculation of the weights of a neural network can significantly accelerate the process of creating and training a feed-forward neural network. Based on the proposed algorithm, we can implement one for calculating three-dimensional weight tables for more complex images, either black-and-white or color grayscale ones.

Keywords — neural networks, weight and threshold values, neurocomputer, learning algorithms, programming of neural networks.

For citation: Geidarov P. Sh. Algorithm for calculating synapse weights of the first layer of a neural network on the base of metric recognition methods. Part 2. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2020, no. 3, pp. 25–38 (In Russian). doi:10.31799/1684-8853-2020-3-25-38

References

- Azarov I. S., Petrovskij A. A. Training personal voice model of a speaker with unified phonetic space of features using artificial neural network. *SPIIRAS Proceedings*, 2014, no. 5, pp. 128–15 (In Russian). <https://doi.org/10.15622/sp.36.8>
- Budko R. Yu., Starchenko I. B. Creation of the facial gestures dlassifier based on the electromyogram analysis. *SPIIRAS Proceedings*, 2016, no. 3 (46), pp. 76–89 (In Russian). <https://doi.org/10.15622/sp.46.7>
- Osipov V. Yu., Nikiiforov V. V. Recurrent neural networks with controlled elements in restoring frame flows. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2019, no. 5, pp. 10–17 (In Russian). <https://doi.org/10.31799/1684-8853-2019-5-10-17>
- Le T. Ch. The comparison of neural network CMAC and multilayer neural network in the task of detection of DoS attacks. *Neurokomputers*, 2016, no. 7, pp. 65–69 (In Russian).
- Katasev A. S., Kataseva D. V., Kirpichnikov A. P. Handwritten character recognition based on artificial neural network. *Vestnik tehnologicheskogo universiteta*, 2018, vol. 18, no. 11, pp. 173–176 (In Russian).
- Drokin I. S. About an algorithm for consistent weights initialization of deep neural networks and neural networks ensemble learning. *Vestnik of Saint Petersburg University Applied Mathematics. Computer Science. Control Processes*, 2016, no. 4, pp. 66–74 (In Russian).
- Leshhenko Ju. E. Associative-verbal networks and artificial neural networks as a method of mental lexicon modeling. *Global Scientific Potential*, 2014, no. 10 (43), pp. 154–156 (In Russian).
- Gafurov D. O., Gafurov O. M., Kontorovich V. A. Interpretation of data from geophysical studies of the Talakan oil and gas condensate field by trained neural networks, forecast of the structure of the Osinsky horizon. *Seismic Technologies*, 2014, no. 4, pp. 85–92 (In Russian).
- Vladimirova D. B., Koksharova A. A. Financial Markets Forecasting Using Artificial Neural Networks. *Science and Business: Ways of Development*, 2014, no. 3 (33), pp. 42–46 (In Russian).
- Sinchuk O. N., Bojko S. N. Neural networks and process control of power supply of objects from combined electric networks. *Tehnichna elektrodinamika*, 2014, no. 5, pp. 53–55 (In Russian).
- Shvedov V. A., Il'in E. S. Recognition of road signs by convolutional neural networks of various structures, using cuda GPUs. *Materialy Shestoy mezhdunarodnoy nauchno-prakticheskoy konferentsii "Transportnaja infrastruktura Sibirskogo regiona"* [Proc. 6th Int. Sump. "Transport infrastructure of the Siberian region"], 2015, vol. 2, pp. 282–286 (In Russian).
- Turovskij Ya. A., Kurgalin S. D., Adamenko A. A. Comparative analysis of software packages for working with artificial neural networks. *Vestnik Voronezhskogo gosudarstvennogo universiteta. Seriya: Sistemnyj analiz i informacionnye tekhnologii*, 2016, no. 1, pp. 161–168 (In Russian).
- Lukina A. S., Nekrasov M. V., Pakman D. N. Processing telemetric information of a spacecraft by neural networks based on the theory of Kalman filters. *Tendencii razvitiya nauki i obrazovaniya*, 2016, no. 13-1, pp. 43–45 (In Russian).
- Stasjuk V. V. Prediction of the explosives impact sensitivity by neural networks with preliminary grouping data. *Fundamental Research*, 2015, no. 12-6, pp. 1139–1143 (In Russian).
- Husainov A. T. Predictability assessment of a reservoir pressure maintenance system by neural networks in oil fields. *Academic Journal of West Siberia*, 2016, vol. 12, no. 3 (64), p. 48 (In Russian).
- Bondarko V. M., Bondarko D. V., Solnushkin S. D., Chihman V. N. Modeling the results of psychophysical experiments by neural networks. *Neurokomputers*, 2018, no. 5, pp. 31–33 (In Russian).
- Sedov V. A., Sedova N. A. Modelling collision avoidance actions in closest approach zones by means of neural networks. *Asia-Pacific Journal of Marine Science & Education*, 2014, vol. 4, no. 2, pp. 104–111.
- Peng Shi, Fanbiao Li, Ligang Wu. Neural network-based passive filtering for delayed neutral-type semi-Markovian jump systems. *IEEE Transactions on Neural Networks and Learning Systems*, 2017, vol. 28, iss. 9, pp. 2101–2114.
- Chenggang Yan, Hongtao Xie, Dongbao Yang, Jian Yin, Yongdong Zhang, Qionghai Dai. Supervised hash coding with deep neural network for environment perception of intelligent vehicles. *IEEE Transactions on Intelligent Transportation Systems*, 2018, vol. 19, iss. 1, pp. 284–295.

20. Anusha Nagabandi, Gregory Kahn, Ronald S. Fearing, Sergey Levine. Neural network dynamics for model-based deep reinforcement learning with model-free fine-tuning. *2018 IEEE International Conference on Robotics and Automation (ICRA)*, Brisbane, Australia, 2018, pp. 156–162.
21. Wei He, Yuhao Chen, Zhao Yin. Adaptive neural network control of an uncertain robot with full-state constraints. *IEEE Transactions on Cybernetics*, 2016, vol. 46, iss. 3, pp. 620–629.
22. Song Han, Xingyu Liu, Huizi Mao, Jing Pu, Ardavan Pedram, Mark A. Horowitz, William J. Efficient inference engine on compressed deep neural network. *2016 ACM/IEEE 43rd Annual International Symposium on Computer Architecture (ISCA)*, Seoul, South Korea, 2016, pp. 304–309.
23. William Chan, Navdeep Jaitl, Quoc Le, Oriol Vinyals. Listen, attend and spell: A neural network for large vocabulary conversational speech recognition. *2016 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, Shanghai, China, 2016, pp. 107–115.
24. Andre Esteva, Brett Kuprel, Roberto A. Novoa, Justin Ko, Susan M. Swetter, Helen M. Blau, Sebastian Thrun. Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 2017, vol. 542, pp. 115–118.
25. Kruglov V. V., Borisov V. V. *Iskusstvennye neyronnye seti. Teoriya i praktika* [Artificial neural networks. Theory and practice]. Moscow, Goriachaia liniia–Telekom Publ., 2001. 328 p. (In Russian).
26. Geidarov P. Sh. Neural networks on the basis of the sample method. *Automatic Control and Computer Sciences*, 2009, vol. 43, pp. 203–210. <https://doi.org/10.3103/S0146411609040063>
27. Geidarov P. Sh. An algorithm implementing the method of the nearest neighbor in a multi-layer perceptron. *SPIIRAS Proceedings*, 2017, vol. 51, pp. 123–151 (In Russian).
28. Birger I. A. *Tekhnicheskaya diagnostika* [Technical diagnostics]. Moscow, Mashinostroenie Publ., 1978. 240 p. (In Russian).

Уважаемые авторы!

При подготовке рукописей статей необходимо руководствоваться следующими рекомендациями.

Статьи должны содержать изложение новых научных результатов. Название статьи должно быть кратким, но информативным. В названии недопустимо использование сокращений, кроме самых общепринятых (РАН, РФ, САПР и т. п.).

Объем статьи (текст, таблицы, иллюстрации и библиография) не должен превышать эквивалента в 20 страниц, напечатанных на бумаге формата А4 на одной стороне через 1,5 интервала Word шрифтом Times New Roman размером 13, поля не менее двух сантиметров.

Обязательными элементами оформления статьи являются: индекс УДК, заглавие, инициалы и фамилия автора (авторов), ученая степень, звание (при отсутствии — должность), полное название организации, аннотация и ключевые слова на русском и английском языках, ORCID и электронный адрес одного из авторов. При написании аннотации не используйте аббревиатур и не делайте ссылок на источники в списке литературы. Предоставляйте подписанные копии и названия таблиц на русском и английском языках.

Статьи авторов, не имеющих ученой степени, рекомендуется публиковать в соавторстве с научным руководителем, наличие подписи научного руководителя на рукописи обязательно; в случае самостоятельной публикации обязательно предоставляйте заверенную по месту работы рекомендацию научного руководителя с указанием его фамилии, имени, отчества, места работы, должности, ученого звания, ученой степени.

Формулы набирайте в Word, не используя формульный редактор (Mathtype или Equation), при необходимости можно использовать формульный редактор; для набора одной формулы не используйте два редактора; при наборе формул в формульном редакторе знаки препинания, ограничивающие формулу, набирайте вместе с формулой; для установки размера шрифта никогда не пользуйтесь вкладкой Other..., используйте заводские установки редактора, не подгоняйте размер символов в формулах под размер шрифта в тексте статьи, не растягивайте и не сжимайте мышью формулы, вставленные в текст; в формулах не отделяйте пробелами знаки: + = -.

Для набора формул в Word никогда не используйте Конструктор (на верхней панели: «Работа с формулами» — «Конструктор»), так как этот ресурс предназначен только для внутреннего использования в Word и не поддерживается программами, предназначенными для изготовления оригинал-макета журнала.

При наборе символов в тексте помните, что символы, обозначаемые латинскими буквами, набираются светлым курсивом, русскими и греческими — светлым прямым, векторы и матрицы — прямым полужирным шрифтом.

Иллюстрации предоставляются отдельными исходными файлами, поддающимися редактированию:

— рисунки, графики, диаграммы, блок-схемы предоставляйте в виде отдельных исходных файлов, поддающихся редактированию, используя векторные программы: Visio (*.vsd, *.vsdx); Coreldraw (*.cdr); Excel (*.xls); Word (*.docx); Adobe Illustrator (*.ai); AutoCad (*.dxf); Matlab (*.ps, *.pdf или экспорт в формат *.ai);

— если редактор, в котором Вы изготавливаете рисунок, не позволяет сохранить в векторном формате, используйте функцию экспорта (только по отношению к исходному рисунку), например, в формат *.ai, *.esp, *.wmf, *.emf, *.svg;

— фото и растровые — в формате *.tif, *.png с максимальным разрешением (не менее 300 pixels/inch).

Наличие подписанных копий и названий таблиц на русском и английском языках обязательно (желательно не повторяющих дословно комментарии к рисункам в тексте статьи).

В редакцию предоставляются:

— сведения об авторе (фамилия, имя, отчество, место работы, должность, ученое звание, учебное заведение и год его окончания, ученая степень и год защиты диссертации, область научных интересов, количество научных публикаций, домашний и служебный адреса и телефоны, e-mail), фото авторов: анфас, в темной одежде на белом фоне, должны быть видны плечи и грудь, высокая степень четкости изображения без теней и отблесков на лице, фото можно представить в электронном виде в формате *.tif, *.png с максимальным разрешением — не менее 300 pixels/inch при минимальном размере фото 40×55 мм;

— экспертное заключение.

Список литературы составляется по порядку ссылок в тексте и оформляется следующим образом:

— для книг и сборников — фамилия и инициалы авторов, полное название книги (сборника), город, издательство, год, общее количество страниц, doi;

— для журнальных статей — фамилия и инициалы авторов, полное название статьи, название журнала, год издания, номер журнала, номера страниц, doi;

— ссылки на иностранную литературу следует давать на языке оригинала без сокращений;

— при использовании web-материалов указывайте адрес сайта и дату обращения.

Список литературы оформляйте двумя отдельными блоками по образцам lit.dot на сайте журнала (<http://i-us.ru/paperrules/>): Литература и References.

Более подробно правила подготовки текста с образцами изложены на нашем сайте в разделе «Правила для авторов».

Контакты

Куда: 190000, Санкт-Петербург,
Б. Морская ул., д. 67, ГУАП, РИЦ

Кому: Редакция журнала «Информационно-управляющие системы»

Тел.: (812) 494-70-02

Эл. почта: ius.spb@gmail.com

Сайт: www.i-us.ru