

ИССЛЕДОВАНИЕ ВЗАИМОЗАВИСИМОСТИ МЕЖДУ КЛАССАМИ В УСЛОВИЯХ ЗАДАЧИ РАСПОЗНАВАНИЯ ПЛОСКИХ СТАЦИОНАРНЫХ ОБЪЕКТОВ С БОЛЬШИМ КОЛИЧЕСТВОМ БИНАРНЫХ ПРИЗНАКОВ

Аннотация. Решается задача распознавания плоских стационарных объектов с большим количеством бинарных признаков с помощью нейронной сети типа когнитрон. В рамках этой задачи исследуется взаимозависимость между распознаваемыми классами, а также влияние параметров обучения на качество распознавания.

Ключевые слова: когнитрон, нейронная сеть, распознавание, матрица спутываний.

Вступление

В эпоху стремительного развития новых технологий процессам автоматизации отведено отдельное место, так как они помогают не только в вопросах сокращения времени выполнения рутинных операций, но и способствуют уменьшению ошибок, вызванных человеческим фактором. Процессы автоматизации занимают достаточно широкий круг применений – на технологических объектах, в медицине, социальной сфере и т.д.

Для поддержания львиной доли процессов автоматизации необходима качественная классификация, выполняемая программно-математическими средствами – классификаторами. Классификаторы должны обладать такими качествами как высокое быстродействие и точность, быстрая адаптация к изменениям входных образов, низкий уровень потребления ресурсов.

Анализ первоисточников

В качестве классификаторов часто используют нейронные сети, которые имеют ряд преимуществ, среди которых их использование в ситуациях, когда известны сопоставимый по точности прогноза метод решения, но критическое, например, время при получении результата, а обученная нейронная сеть решает задачу достаточно быстро [1].

Задачи, которые решают нейросети, сводятся к аппроксимации многомерных функций, то есть построения отображения вида [1]:

$$F: x \rightarrow y, \quad (1)$$

где $x \in \mathbb{R}^n$ – входной n -мерный вектор, $y \in \mathbb{R}$ – скаляр-результат.

Одной из самых популярных нейронных сетей для решений задач распознавания считают многослойный персепtron. Он однозначно имеет ряд преимуществ, среди которых возможность распознавания зашумленных образов с достаточно высоким уровнем пиксельного шума [2], но его основным недостатком есть то, что для каждого вида искажения его нужно переучивать, а этот процесс может занять часы, или даже дни.

Но персепtron далеко не единственная нейронная сеть, которая призвана решать задачу классификации. В процессе распознавания входных образов часто используется нейронная сеть типа когнитрон.

В основу функционирования когнитрона положена модель зрительной коры мозга человека [3,4]. Каждый слой мозга реализует различные уровни обобщения – входной слой чувствителен к простым образам, таким как линии различной ориентации в плоскости, в то время как другие слои позволяют формировать более сложные, абстрактные и независимые от положения образы. Каждый нейрон когнитрона связан только с локальной областью предыдущего слоя, причем области связей могут взаимопересекаться. Слоев в когнитроне обычно больше, чем в сетях других типов, таким образом достигается иерархическая организация. Высшие слои когнитрона реагируют на выделенные абстрактные признаки, поэтому на распознавание меньшей степени влияет зашумления исходного образа [3].

Архитектура когнитрона изображена на рисунке 1. Когнитрон конструируется в виде слоев нейронов, соединенных синапсами. Пресинаптический нейрон в одном слое связан с постсинаптическим нейроном в следующем слое. Есть два типа нейронов: возбуждающие узлы, которые стремятся вызвать возбуждение постсинаптического узла, и тормозящие узлы, которые тормозят это возбуждение. Возбуждение нейрона определяется взвешенной суммой его возбуждающих и тормозящих входов, однако в действительности механизм является более сложным, чем простое суммирование [4]. Алгоритм обучения и

математическая модель нейронной сети типа когнитрон представлена в работе [5].

Постановка задачи

В рамках вышесказанного ставится задача исследовать зависимости между распознаваемыми классами, и выяснить возможные причины таких зависимостей. Также выяснить, как влияет на процесс спутывания образов настройка входных параметров когнитрона.

Материалы исследования

Для решения этой задачи будет использоваться три вариации нейронной сети типа когнитрон с разными параметрами обучения.

Модели (SONNC self-organization neural network cognitron) будут представлять собой когнитрон со следующими параметрами:

- 1) Число слоев когнитрона (L).
- 2) Величина области связи (V_s).
- 3) Величина области конкуренции (V_c).
- 4) Величина области латерального торможения (L_t).
- 5) Величина значения коэффициента изменения весов при конкурентном обучении (q_1).
- 6) Величина значения коэффициента изменения весов неконкурентном обучении (q_2).
- 7) Количество проходов сети (I_c).

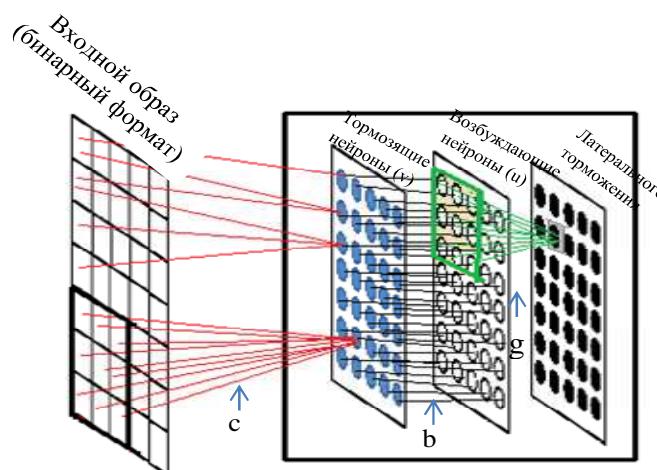


Рисунок 1 - Архитектура нейронной сети когнитрон
(связи возбуждающих нейронов с входным образом изображены не, однако эти связи идентичны как между слоем тормозных нейронов и входным образом)

Параметры для трёх вариаций нейронных сетей SONNC1, SONNC2 и SONNC3 представлены в таблице:

Таблица 1

	L	V_s	V_c	L_i	q_1	q_2	I_c
SONNC1	3	3	2	8	48	2	90
SONNC2	3	3	3	8	50	2	60
SONNC3	3	3	4	8	60	2	90

Нейронные сети будут обучаться на одинаковом наборе входных изображений вида, представленного на рисунке 2.



Рисунок 2 – Обучающая выборка

Результаты распознавания различных вариантов искажений (рис. 3) представлены в таблице 2 и проиллюстрированы на рисунке 4.

Таблица 2

Сравнение продуктивности альтернативных вариаций когнитрона

Пара- метры Сеть	Время обуче- ния	Чистые образы	Шум №1	Шум №2	Шум №3	Шум №4	Шум №5	Шум №6	Шум №7	Шум №8
SONNC1	20	100	96,2	69,2	73,1	69,2	46,2	11,5	46,2	46,2
SONNC2	14	92,3	84,6	76,9	76,9	76,9	34,6	11,5	46,2	50
SONNC3	21	100	34,6	84,6	69,2	69,2	7,69	100	11,5	15,4



Размытие (вид шума № 1)	Кубически й шум (вид шума № 2)	Размытие Гауса 1 (вид шума № 3)	Размытие Гауса 2 (вид шума № 4)	Размытие Гауса 3 (вид шума № 5)	Пиксельный шум (вид шума № 6)	Поворот фигуры влево (вид шума № 7)	Поворот фигуры вправо (вид шума № 8)
----------------------------	--------------------------------------	---------------------------------------	---------------------------------------	---------------------------------------	-------------------------------------	---	---

Рисунок 3 – Различные варианты искажений

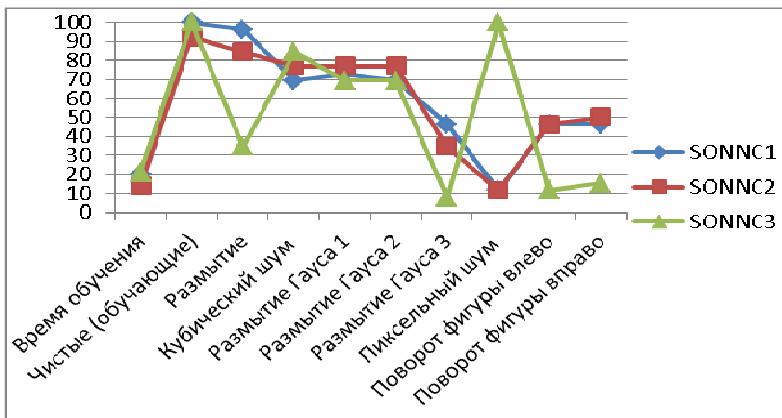


Рисунок 4 – Результат распознавания входных образов с разным типом искажений

Как видно по рисунку 4, очень большое влияние на когнитрон имеют параметры обучения. Также по рисунку 4 можно сделать вывод, что практически под любой вид искажений можно подобрать оптимальные параметры классификатора [5].

По результатам распознавания была построена матрица спутываний, которая показывает вероятность спутывания в соответствующих классах:

$$P_i = \frac{P_i}{\sum_{i=1}^{26} P_i}, \quad i = 1..26, \quad (2)$$

где индекс i соответствует номеру буквы в латинском алфавите.

Как видно по рисунку 5, наибольшая статистическая частота спутывания с буквой “B”. В то же время буква “B” распознается в 100 % случаев. Такая высокая частота спутывания связана с тем, что многие буквы имеют большое количество сходных бинарных признаков с буквой “B”.

Также большая статистическая частота спутываний существует для “круглых” букв. Буквы “O” и “Q” в 70 % случаев путаются с буквой “D”.

С изменением параметров обучения наблюдалось небольшое изменение в матрице спутываний. В SONNC1 и SONNC3 чистые образы распознаются безошибочно. Самые частые спутывания наблюдаются с классами изображений “B” и “D”. Но поскольку каждый вид сети настроен под конкретный вид искажений, то большая доля спутываний происходит именно на виде искажений, к которому сеть неустойчива.

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26
	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T	U	V	W	X	Y	Z
1 A	0,778	0,111	0	0	0	0	0	0,111	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2 B	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
3 C	0,111	0,111	0,667	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0,111
4 D	0	0,222	0	0,778	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
5 E	0	0,889	0	0,111	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
6 F	0	0,111	0	0	0,778	0	0	0	0	0	0	0	0	0	0	0	0	0,111	0	0	0	0	0	0	0	0
7 G	0	0,667	0	0	0	0,222	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
8 H	0	0,222	0	0	0	0	0	0,667	0	0	0	0	0,111	0	0	0	0	0	0	0	0	0	0	0	0	0
9 I	0	0,111	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
10 J	0	0,111	0	0	0	0	0	0	0	0	0,111	0,778	0,111	0	0	0	0	0	0	0	0	0	0	0	0	0
11 K	0	0,111	0	0	0	0	0	0	0	0	0	0	0	0,667	0	0	0,111	0	0	0	0	0	0	0	0	0
12 L	0	0,111	0	0	0	0	0	0	0	0	0	0	0	0	0,778	0	0	0	0	0	0	0	0	0	0	0
13 M	0,111	0,333	0	0	0	0	0	0	0	0	0	0	0	0	0	0,556	0	0	0	0	0	0	0	0	0	0
14 N	0	0,111	0	0	0	0	0	0	0	0	0	0	0	0	0	0,889	0	0	0	0	0	0	0	0	0	0
15 O	0	0,111	0,111	0,667	0	0	0	0	0	0	0	0	0	0	0	0	0,111	0	0	0	0	0	0	0	0	0
16 P	0	0,111	0	0	0	0	0,111	0	0	0	0	0	0	0	0	0	0,778	0	0	0	0	0	0	0	0	0
17 Q	0	0,111	0	0,667	0	0	0	0	0	0	0	0	0	0	0	0	0,111	0	0	0	0	0	0	0	0	0
18 R	0	0,222	0	0	0	0	0	0,111	0	0	0	0	0	0	0	0	0	0,667	0	0	0	0	0	0	0	0,556
19 S	0,222	0,778	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
20 T	0	0,111	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
21 U	0,222	0,111	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0,111	0	0	0	0	0	0	0	0,778	0
22 V	0	0,111	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0,111	0	0	0	0	0	0	0	0,333
23 W	0	0,222	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
24 X	0	0,111	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0,111	0	0	0	0	0	0	0	0,778
25 Y	0	0,111	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
26 Z	0	0,111	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0,111	0	0	0	0	0	0	0	0,778

Рисунок 5 – Матрица спутываний для модели когнитрона SONNC2

Выводы

Нейронная сеть типа когнитрон способна справляться с достаточно высоким уровнем пиксельного шума. Она быстро обучается (меньше 1 минуты), и показывает высокую точность в классификации входных образов (практически для каждого вида искажений, кроме поворотов и масштабирования, можно добиться точности распознавания выше 95 %).

Как показало исследование, для каждого вида искажений когнитрон требует переобучения с подборкой соответствующих параметров. Также показано, что есть классы изображений, которые практически не распознаются. К таким классам относятся буквы “E”, “G”, “O”, “Q”, “S”. Буквы “E”, “G”, “S” более чем в 65 % случаев спутывались с классом “B”. А буквы “O” и “Q” в 67 % спутывались с классом “D”. Связано это прежде всего с тем, что данные буквы имеют достаточно много схожих бинарных признаков. Что касается распознавания изображений с поворотом, когнитрон не показал высокой эффективности, так как подстройкой параметров обучения не удалось достичь эффективности свыше 55 %.

ЛИТЕРАТУРА

1. Gerald H. L. C. Approximation with neural networks activated by ramp sigmoids / H. L. C. Gerald // Journal of Approximation Theory. – 2010. – Volume 162, Issue 8. – P. 1450 – 1465.
2. Romanuke V. V. An attempt for 2-layer perceptron high performance in classifying shifted monochrome 60-by-80-images via training with pixel-distorted shifted images on the pattern of 26 alphabet letters / V. V. Romanuke // Радіоелектроніка, інформатика, управління. – 2013. – № 2. – С. 112 – 118.
3. Fukushima K. A self-organizing multilayered neural network: Cognitron / K. Fukushima // Biological Cybernetic. – 1975, vol 20. – P. 121–136.
4. Уоссермен Ф. Нейрокомпьютерная техника: Теория и практика / Уоссермен Ф. – М. : Мир, 1992. – 240 с.
5. Молчанова М. О. Дослідження впливів параметрів навчання когнітрону на якість розпізнавання вихідних образів / М. О. Молчанова, М. В. Протасов // Вісник Хмельницького національного університету. Технічні науки. – 2014. – № 5. – С. 240 – 246