

УДК 621.327:519.95

Г. Г. Фурсин

МОДЕЛИРОВАНИЕ ПРОЦЕССА ОБУЧЕНИЯ И РАСПОЗНАВАНИЯ В НЕЙРОННОЙ СЕТИ

(Московский физико-технический институт)

Настоящая статья касается двух таких научно-технических направлений, как, с одной стороны, нейронные сети и, с другой стороны, распознавание образов. Эти направления развиваются уже несколько десятилетий, испытывая то подъем, то спад.

Если начинают говорить об устройствах, которые в большей или меньшей степени используют принципы обработки информации, присущие живым системам, то обязательно упоминают несколько классических работ. В первой из них [1] Маккаллоу и Питтс проанализировали возможность построения вычислительных устройств на основе аналогов нервных сетей живых существ. Предложенный ими в качестве основного элемента таких устройств формальный нейрон позволяет реализовать фактически любую требуемую логическую функцию. Использовать свойства нейронов для моделирования функций мозга несколько позже предложил Хебб [2]. Согласно его взглядам, нервные клетки мозга соединены друг с другом большим количеством прямых и обратных связей и образуют нейронную сеть; он предложил правило обучения для нейронных сетей, основанное на увеличении силы связи (синаптического веса) между одновременно активными нейронами, что приводит к усилению часто используемых в сети связей, причем такое правило формирует симметричную матрицу связей. Увеличение их эффективности в процессе функционирования сети объясняет известное явление обучения путем повторения и привыкания.

Позднее Розенблатт описал результаты своей работы над перцептроном [3], в котором обучение символам с целью их последующего распознавания производилось изменением весовых коэффициентов. И хотя в дальнейшем мнения о перспективности такого устройства обработки информации разделились, до настоящего времени работы над перцептроном в той или иной степени продолжают-ся. Минский и Пайперт [4] отмечали, что недостатки простых пер-

септронное можно преодолеть как с помощью многослойных сетей, так и введением в сеть обратных связей, допускающих циркуляцию сигналов по замкнутым контурам.

В дальнейшем предпринимались многочисленные попытки (см., например, [5-18]) использовать эти принципы для решения различных практических задач "программно" и "аппаратно", на основе моделирования нейронов и нейросетей математически либо в виде электронных схем или совершенно различных физических сред, разрабатывалась архитектура соответствующих вычислительных устройств и ассоциативной памяти. Затем стали создаваться специальные кристаллы (микросхемы) - нейрочипы, и транспьютеры (многопроцессорные специализированные дополнения к существующим универсальным компьютерам), в том числе с использованием достижений бурно развивающейся микроэлектроники, но широкого распространения они пока все же не нашли, как и собственно нейрокompьютеры. Такие компьютеры и "отдельные" нейросети сегодня пытаются использовать уже не только для задач распознавания зрительных и речевых образов, хотя эта задача остается по-прежнему очень важной и актуальной, но и для решения других многочисленных статистических и трудноалгоритмизируемых задач, а также для применения в экспертных системах и системах искусственного интеллекта.

Новая волна интереса к искусственным нейросетям появилась после опубликования работы Хопфилда [19], который, исследуя спинозные стекла, провел аналогии между методами статистической физики и распознаванием и восстановлением образов в нейронных сетях. Ними разработан пакет программ, позволяющий моделировать различные варианты нейросетей как классических и модифицированных, так и принципиально новых [20]. В последней из цитированных работ впервые в отечественной и зарубежной литературе предложена концепция создания нового (шестого) поколения высоконадежных ЭВМ на основе недетерминированных нейронных сетей и нейропроцессоров, в качестве конструктивно-технологической базы которых используются нетрадиционные активные элементы и среды. Гипотетическая конструкция соответствующего нейрокompьютера как ЭВМ 6-го поколения с использованием новой логики обработки информации впервые опубликована в 1986 году на обложке работы [21] - здесь показан многокристальный модуль с оптическим вводом (с тыльной

стороны; за двумерной матрицей фотоприемников следует в виде случайным образом заштрихованных кубиков трехмерная нейронная сеть) и оптическим выводом (в виде "распознанных" и сформированных на плоском дисплее буквы "ОТЗ") информации. Настоящая же статья является первой в начатом нами цикле исследований и посвящена некоторым свойствам популярных дискретных (цифровых) нейросетей Хопфилда. Отметим сразу, что разработанные нами демонстрационная программа и базы данных (библиотеки образов, библиотеки подпрограмм, литературные ссылки с аннотациями и т.п.) студентами и аспирантами МЭИ применяются и распространяются бесплатно.

При моделировании нейросетей широко используют понятие формального нейрона. Такой элемент имеет несколько входов и один выход; выходной сигнал получают путем "пропускания" суммарного уровня возбуждения S через нелинейную функцию F . В общем случае используют различные функции. В рассматриваемой нами задаче применяется биполярная функция (часто используют также бинарную и непрерывную сигмоидную функции); входные сигналы умножаются на их веса и складываются с соответствующими знаками; если результат превышает нуль, то $F = 1$, в противном случае $F = -1$.

Поскольку входы и выходы различных нейронов можно объединить огромным количеством способов, то при необходимости классификации среди архитектур нейронных сетей выделяют полносвязные, двунаправленные, многослойные и другие. В исследованной сети все нейроны попарно связаны. Сила связи между i -м и j -м нейронами характеризуется величиной T_{ij} . Величины всех синаптических связей T_{ij} составляют матрицу памяти. Она симметрична; диагональные элементы обнуляем с целью исключения отрицательного "самодействия" нейронов, общее число которых равно Q . Очевидно, что для квадратной матрицы это число равно квадрату числа строк (или столбцов) N .

Нелинейное преобразование исходного образа происходит по такому правилу:

$$X'_i = F \left(\sum_{j=1}^Q T_{ij} \cdot X_j \right), \quad (1)$$

где X_j - предыдущее (старое) состояние нейрона, а X'_i - последующее (новое). Матрица памяти вычисляется следующим образом:

$$T_{ij} = \sum_{s=1}^M V_i^s \cdot V_j^s, \quad (2)$$

где образы, которые необходимо запомнить (их число равно M), обозначены через V_s , $s=1 \dots M$, причем V_i^s есть состояние i -го нейрона в s -м образе.

Рассмотрим ситуацию, когда матрица памяти уже сформирована, и мы перешли к распознаванию образов. При предъявлении какого-либо входного образа, например V_i , результат преобразования определяется соотношением

$$V_i' = F\left(\sum_{j=1}^Q T_{ij} \cdot V_j'\right) = (Q-1) \cdot V_j' + \sum_{s=2}^M V_i^s \cdot \sum_{j=1}^Q V_j^s \cdot V_j'. \quad (3)$$

Если вектор предъявленного образа является собственным вектором матрицы T , то данный образ под действием указанного преобразования не изменится. Если же он не является собственным, то преобразование вектора образа приводит к его изменению.

В общем случае векторы V_s выбираются случайным образом и тогда для большого Q вышеприведенное произведение при $s=2 \dots M$ можно считать гауссовой случайной величиной со среднеквадратичным отклонением $\sqrt{Q-1}$. V_i близко к собственному вектору матрицы T в том случае, когда число M мало по сравнению с числом Q . Если в исходном векторе V_i окажется "испорченной" часть координат, то отношение первого слагаемого в (3), являющегося полезным сигналом, ко второму, являющемуся "шумом", уменьшится, но может остаться достаточно большим. Повторное применение преобразования (1) позволит восстановить образ памяти V_i . При сильном зашумлении образа данное преобразование следует применить несколько раз, но при этом истинный образ может и не восстановиться, а вместо него на "выходе" возникнет ложный образ.

Поскольку в литературе и в проанализированных нами зарубежных пакетах "нейропрограмм" отсутствуют приемлемые критерии сравнения и произвольной статистической обработки результатов процесса обучения и распознавания для различных библиотек образов и новых оригинальных нейросетей (в том числе использующих новый принцип действия), нами разработаны некоторые обобщенные процедуры. Одну из них проиллюстрируем следующим примером. При общеизвестных ограничениях рассматриваемая нейросеть неплохо

распознает символы, определяемые стандартом ASCII. Поэтому из библиотек образов возьмем одну, для которой мы отобрали 27 модифицированных ASC-символов с минимальной матрицей, соответствующих латинским и русским буквам приблизительно одного "размера", но различающихся написанием.

Программа запускает достаточно длинный цикл обработки образов, результаты которого автоматически записываются в файл. Его распечатка как простейший пример такого цикла показана в Таблице. Разумеется, для высокой точности и большей достоверности необходимо проводить очень большое число циклов обучения и распознавания, причем совершенно случайным образом, и только потом усреднять их количественные результаты (что обычно и делается). Ниже, однако, ограничимся для наглядности очень простым и компактным примером, который тем не менее в полной мере отражает основные свойства простейшей нейросети.

В Таблице приведены численные результаты 14 последовательных попыток обучения нейросети возрастающему числу различных букв и последующего восстановления их образов. В каждой из попыток используется один и тот же набор ACEMNNORSUVWXZГЖЖКЛНТЧШЬЭЮЯ из 27 букв, который для удобства анализа многократно повторяется в Таблице под буквой R (Result of Recognition). Особо подчеркнем, что не следует путать форму (матрицу) букв, с которыми работает нейронная сеть, и написание букв, которое используется в тексте данной статьи (в последнем случае их гарнитура определяется принтером или загруженным в его ОЗУ новым шрифтом, а не нашей библиотекой образов: сравните буквы Ж, Л, Э в Таблице и на рисунке 2). В общем случае программа позволяет изменять размеры нейронной сети в широких пределах (ограничиваемых в основном быстродействием компьютера). В данном случае мы выбрали некоторый минимальный вариант: порядок квадратной матрицы №7 (Size of Array).

Обнуленную нейросеть поочередно обучаем одному, двум и так далее, включая M, символам (которые поступают на ее "вход"). Затем, после всех необходимых преобразований, начинаем в исходном порядке предъявлять сети для распознавания те же образы. Если запомненный символ (на "выходе") совпадает с предъявленным (в том числе после многократных циклов вычислений), то в файле статистики под соответствующим символом записывается единица, в

противном случае - нуль. Делается несколько предъявлений (в данном примере всего три, чтобы не загромождать публикуемому распечатку), отличающихся началом последовательности этих символов. Вычисляется величина A , равная среднему результату распознавания за указанное число предъявлений. Когда A равно нулю, то есть нейросеть не может распознать ни один символ, программа завершает запись в файл для текущей величины N .

Если образов немного, то числа запомненных и точно восстановленных образов приблизительно совпадают, а максимум соответствует оценке Хопфилда. Затем число запомненных образов падает, что видно также из рисунка 1. Проводить на нем аппроксимирующую кривую для малого числа статистических данных мы, естественно, не стали (но если ее все же провести, то результаты машинного моделирования удовлетворительно совпадают с результатами теоретических расчетов [19]).

Рассмотрим в заключение несколько иную ситуацию, когда предъявляемый образ по каким-либо причинам искажен ("зашумлен") по сравнению с исходным, что иллюстрируется рисунком 2. Он содержит три строки (для разных букв) и пять столбцов (для разных этапов работы рассматриваемой нейронной сети). В строках показаны предъявляемые нейросети (после ее обучения шести выбранным наугад русским буквам ЖЭКЛНТ) три буквы Ж, Л, Э. Программа позволяет не только импортировать образы из различных библиотек, но и изменять их - как автоматически, так и вручную; последнее сделано с буквами Л и Э. Результат редактирования приведен во втором слева столбце: букву Ж (первая строка) мы не изменили, букву Л (вторая строка) изменили слегка, а букву Э (третья строка) изменили достаточно сильно.

После проведения преобразований по приведенным выше формулам нейросеть восстановила буквы Ж и Л в первом же цикле (третий слева столбец), а для восстановления буквы Э ей потребовалось еще два цикла (четвертый и пятый столбцы). Продолжение процесса распознавания (т.е. навигных циклов вычислений) уже не изменит сформированные "выходные" образы (как истинные, что показано на обсуждаемом рисунке, так и возможные ложные). Данный пример убедительно демонстрирует ассоциативные свойства рассмотренной нейронной сети и ее устойчивость к "помехам" при восстановлении запомненных образов.

Таблица (начало)

N - Size of Array

M - Maximal Number of Symbols

C - Current Attempt

R - Result of Recognition

A - Average Result of Recognition

N	M	C	R	A
7	1		АСЕМНОRSUVWXZГЖЭКЛНТЧШЬЬЭЯ	
		1	1	
		2	1	
		3	1	1.0
7	2		АСЕМНОRSUVWXZГЖЭКЛНТЧШЬЬЭЯ	
		1	11	
		2	11	
		3	11	2.0
7	3		АСЕМНОRSUVWXZГЖЭКЛНТЧШЬЬЭЯ	
		1	111	
		2	111	
		3	100	2.3
7	4		АСЕМНОRSUVWXZГЖЭКЛНТЧШЬЬЭЯ	
		1	1111	
		2	1111	
		3	0011	3.3
7	5		АСЕМНОRSUVWXZГЖЭКЛНТЧШЬЬЭЯ	
		1	11100	
		2	11111	
		3	01101	3.7
7	6		АСЕМНОRSUVWXZГЖЭКЛНТЧШЬЬЭЯ	
		1	110011	
		2	111111	
		3	0000	3.3

Таблица (окончание)

N	M	C	R	A
7	7		АСЕМNDRSUUVWXZГЖЭКЛНТЧШЬЪЭЯ	
		1	10111100	
		2	11111100	
		3	0000 000	3.0
N	M	C	R	A
7	8		АСЕМNDRSUUVWXZГЖЭКЛНТЧШЬЪЭЯ	
		1	00110001	
		2	01110000	
		3	010001 00	2.7
N	M	C	R	A
7	9		АСЕМNDRSUUVWXZГЖЭКЛНТЧШЬЪЭЯ	
		1	00100001	
		2	010000000	
		3	00000000 0	1.0
N	M	C	R	A
7	10		АСЕМNDRSUUVWXZГЖЭКЛНТЧШЬЪЭЯ	
		1	0001000100	
		2	0 100000000	
		3	0100000001	1.7
N	M	C	R	A
7	11		АСЕМNDRSUUVWXZГЖЭКЛНТЧШЬЪЭЯ	
		1	10000000000	
		2	000 00000000	
		3	10000100001	1.3
N	M	C	R	A
7	12		АСЕМNDRSUUVWXZГЖЭКЛНТЧШЬЪЭЯ	
		1	000000000000	
		2	00000 0000000	
		3	000000000100	0.3
N	M	C	R	A
7	13		АСЕМNDRSUUVWXZГЖЭКЛНТЧШЬЪЭЯ	
		1	0000001000000	
		2	0000000 000000	
		3	00000000010000	0.7
N	M	C	R	A
7	14		АСЕМNDRSUUVWXZГЖЭКЛНТЧШЬЪЭЯ	
		1	0000000000000	
		2	000000000 00000	
		3	00000000000000	0.0




Рис. I




Рис. 2

Список литературы

1. McCulloch W.S., Pitts W. A logical calculus of the ideas immanent in nervous activity. В. М. Biophys., 1943, v. 5, p. 115-133.
2. Hebb D.O. The organisation of behaviour. - N.Y., 1949. - 335 p.
3. Розенблат Ф. Принципы нейродинамики (перцептроны и теория механизмов мозга). - М.: Мир, 1965. - 480 с.
4. Минский М., Лейперт С. Перцептроны. - М.: Мир, 1971. - 263 с.
5. Галушкин А.И. Синтез многослойных систем распознавания образов. - М.: Энергия, 1974. - 368 с.
6. Дунин-Барковский В.Л. Информационные процессы в нейронных структурах. - М.: Наука, 1978. - 166 с.
7. Микаэлян А.Л. Оптические методы в информатике. Запись, обработка и передача информации. - М.: Наука, 1970. - 232 с.
8. Rambidi., Maximuchev A.V., Usatov A.V. Nonlinear Dynamics in a Nondiscrete Molecular System for Neural Pattern Recognition Devices. - Opt. Mem. and Neural Networks, 1992, v. 1, No. 3, p. 177-187.
9. Стафеев В.И., Комаровских К.Ф., Фурсин Г.И. Нейристорные и др. функциональные схемы с объемной связью. - М.: Р. и св., 1981. - 112 с.
10. Фролов А.А., Муравьев И.П. Нейронные модели ассоциативной памяти. - М.: Наука, 1987. - 160 с.
11. Anderson J.A. Cognitive and psychological computation with neural models. - IEEE Tr. S., M., and Cyb., 1983, v. 13, p. 799-813.
12. Fukushima K. Cognitron: a selforganizing multilayered neural network. - Biological Cybernetics, 1975, v. 20, No. 3/4, p. 121-136.
13. Grossberg S. Studies of mind and brains: Neural principles of learning, development, cognition and motor control. - Boston: Reidel, 1982. - 662 p.
14. Hecht-Nielsen R. Neurocomputing: picking the human brain. - IEEE Spectrum, 1988, v. 25, No. 3, p. 36-41.
15. Kohonen T. Self-Organisation and Associative Memory. - Berlin etc.: Springer (Third Edition), 1989. - 225 p.
16. Palm G. Neural assemblies: An alternative approach to artificial intelligence. - Berlin etc.: Springer, 1982. - 224 p.
17. Personnaz L., Guyon I., Drayfus G. High-order neural networks: inf. storage without errors. - Europh. Let., 1987, v. 4, No. 8, p. 863-867.
18. Piret P. Analysis of a modified Hebbian Rule. - IEEE Tr. Inform. Theory, 1990, v. IT-36, No. 6, p. 1391-1397.
19. Hopfield J.J. Neural networks and physical systems with emergent collective computational abilities. - Proc. Nat. Acad. (USA), 1982, v. 79, No. 8, p. 2554-2558.
20. Фурсин Г.И. Функциональная микроселектроника: Учебное пособие. - М.: изд. МФТИ, 1985. - 112 с.
21. Фурсин Г.И. Основы твердотельной электроники: Учебное пособие. - М.: изд. МФТИ, 1986. - 92 с.

Поступила в редколлегию 16.03.95
в редакцию 04.09.95