

УДК 004.272.25, 004.622

Г.А. Прокопович

ПРИМЕНЕНИЕ ГЕТЕРОАССОЦИАТИВНЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ЗАПИСИ И ВОССТАНОВЛЕНИЯ ИНФОРМАЦИИ

Рассматривается проблема ассоциативного представления данных на примере рекуррентных искусственных нейронных сетей типа Хопфилда. Предложены: модификация сети «двунаправленная ассоциативная память», способ секционирования входных данных, основанный на их равномерном разбиении с дальнейшим последовательным отображением друг в друга, а также соответствующий метод их записи в гетероассоциативную память. Полученная нейросетевая архитектура способна сохранять, ассоциативно восстанавливать и распознавать большие объемы информации.

Введение

Одной из важнейших задач для современных вычислительных устройств является сохранение информации на носителе таким образом, чтобы впоследствии ее можно было извлечь, обладая лишь некоторым ключевым признаком этой информации. Как правило, предлагаются две различные формы сравнения входного ключа. С одной стороны, если среди совокупности данных требуется отыскать такие, которые на основе некоторой заданной меры близости соответствуют ключевой информации, то такая постановка задачи близка к постановке задачи распознавания образов. С другой стороны, задачи поиска информации по известному ключу, который сам содержит некоторую часть искомой информации, связаны с задачами оптимизации работы баз данных [1], а также способами ассоциативного представления данных [2].

Среди различных методов ассоциативной записи и восстановления информации можно выделить динамические нейросетевые архитектуры, обладающие обратной связью. К наиболее известным относятся однослойные сети Хопфилда [3–5] и рекуррентные многослойные перцептроны – сети Элмана [6]. Широкое практическое применение получили сети Элмана, которые используются для управления динамическими объектами [7, 8] и сжатия информации [9]. Однако для изучения принципов работы ассоциативной памяти чаще используются сети Хопфилда, которые демонстрируют, каким образом в принципе может быть организована устойчивая память, состоящая из коллектива недостаточно надежных нейроподобных элементов [9–11].

Характерной особенностью сетей Хопфилда является то, что процесс извлечения информации в таких сетях осуществляется по итеративному принципу и заключается в том, что на каждой новой итерации через обратные связи с элементами задержки Δt происходит обработка данных, полученных на предыдущем шаге. Для устойчивых сетей с обратными связями такая циркуляция информации происходит до тех пор, пока значения элементов сети не установятся в состояние равновесия, т. е. пока они не приобретут стационарные значения.

Для сети Хопфилда, в которой используется симметричная матрица весовых коэффициентов с нулевой главной диагональю, т. е. $w_{ij} = w_{ji}$ и $w_{ii} = 0$, такими стационарными значениями – аттракторами – являются устойчивые стационарные точки или устойчивые предельные циклы длины два [12]:

$$y_i(t+k) = y_i(t), \quad i = \overline{1, n}, \quad k = 1, 2. \quad (1)$$

Тем не менее сети Хопфилда обладают определенными недостатками, которые значительно ограничивают их практическое применение. Как известно, чтобы восстановить (извлечь) необходимый образ с помощью обученной сети Хопфилда, необходимо иметь ключевой образ, совпадающий по размеру с искомым. Это приводит к невозможности реализации ассоциативного процесса восстановления информации в полном смысле слова, т. е. по ее отдельному фрагменту. В результате недостающие участки входного вектора находятся в состоянии неопределенности. Например, в многочисленных источниках [10, 11, 13] часто приводится задача

восстановления графических образов при их частичном искажении (рис. 1, а). Если память сети Хопфилда не переполнена и количество наложенного шума не превышает некоторого определенного порога, то она восстановит исходный образ (рис. 1, б). Однако сеть не способна качественно восстановить образ по его некоторой известной части (рис. 1, в), так как ключевой образ (рис. 1, г) будет слабо коррелировать с исходным. В то же время человеческий мозг прекрасно справляется с поставленной задачей и способен вспомнить (восстановить) большие объемы информации лишь по малой части ключевой информации [2].




Рис. 1. Различные варианты входных образов

Рассмотрим бинарный вектор $\mathbf{L}_p = (l_1, l_2, \dots, l_p)$, состоящий из p элементов, с помощью которого можно зашифровать некоторую информацию. Чтобы записать указанный информационный вектор \mathbf{L}_p с помощью сети Хопфилда, она должна состоять из $n = p$ нейронов. Весовая матрица синаптических связей $W_{n \times n}$ представляет собой квадратную матрицу размером $n \times n$, где n – длина входного вектора. Тогда с ростом длины p входного вектора \mathbf{L}_p общий объем памяти, необходимый для моделирования сети Хопфилда, будет расти не линейно, а квадратично. Таким образом, имеет место ограничение сверху на объем памяти, необходимый для хранения весовой матрицы $W_{n \times n}$. В связи с этим может сложиться такая ситуация, когда размер вектора \mathbf{L}_p значительно превысит число нейронов n во входном слое сети. Следующим недостатком сети Хопфилда является то, что для восстановления информационного вектора \mathbf{L}_p потребуется ключевой вектор, длина которого совпадает с длиной искомого вектора.

Таким образом, несмотря на то что искусственные нейронные сети Хопфилда успешно демонстрируют ассоциативное восстановление, они не способны реализовывать ассоциативную обработку информации в той мере, какую демонстрируют нервные клетки головного мозга человека.

Описанная задача является типовой и востребована при реализации поиска в реляционных базах данных. Поэтому была поставлена задача разработать нейросетевую архитектуру, способную ассоциативно извлекать и обрабатывать информационные последовательности \mathbf{L}_p , размер которых значительно превышает число n нейронов входного слоя, т. е. $p \gg n$.

1. Способ декомпозиции входных данных и модификация сети ДАП

Рассмотрим искусственную нейронную сеть типа двунаправленной ассоциативной памяти (ДАП), разработанную Б. Коско [14, 15]. Сеть ДАП, как и широко известная сеть Хопфилда, способна к обобщению, вырабатывая правильные реакции даже на искаженные входы. Однако последняя является автоассоциативной. Это означает, что входной образ может быть завершен или исправлен, но не может быть ассоциирован с другим образом. Данный факт является результатом одноуровневой структуры ассоциативной памяти, в которой выходной вектор генерируется на тех же нейронах, на которые поступает входной вектор. В результате восстановленный образ, являющийся точечным аттрактором пространства состояний сети Хопфилда по (1), принципиально не может быть стимулом для генерации новой информации.

В противоположность этому в двухслойной сети ДАП входной вектор поступает на один набор нейронов $\mathbf{X}^{(n)} = (x_1, x_2, \dots, x_n)^T$, а соответствующий выходной вектор с помощью матри-

цы весов $W_{m \times n}$ вырабатывается на другом наборе $Y^{(m)} = (y_1, y_2, \dots, y_m)^T$. Таким образом, реализуется *гетероассоциативная память*. Поэтому обученная сеть на поступающий двоичный ключевой вектор, обладающий общими характерными признаками, вырабатывает на выходе один и тот же вектор-отклик, т. е. наблюдается процесс адресации памяти по ее содержанию. Процесс обучения сети ДАП реализуется в форме суммирования внешних произведений всех векторных пар обучающего набора согласно правилу Хебба [3].

Дополнительными преимуществами сетей данного типа являются: реализация распределенной памяти; быстрый безытерационный способ обучения; способность добавлять в память ограниченное число новых образов, не разрушая старые, и относительно простая архитектура для ее программно-аппаратной реализации [13, 16, 17].

Теоретически информационная емкость сети ДАП (количество образов, которые она может запомнить) в два раза меньше, чем у сети Хопфилда. Это связано со структурой сети ДАП, в процессе функционирования которой происходит не только извлечение вектор-отклика Y , но и восстановление самого вектор-стимула X (если он в допустимых пределах отличался от эталонного значения). Однако если стимул и отклик представить в виде двух составных частей одной информационной последовательности L_p , то ее максимальная длина $p = n + m$, а в случае, когда $n = m$, получаем, что $p = 2n$. Другими словами, размер запоминаемого образа в два раза превышает размер входного слоя нейронной сети.

Тем не менее результаты приведенных рассуждений недостаточно удовлетворяют условию поставленной задачи. Поэтому было решено изменить алгоритм работы и архитектуру сети ДАП таким образом, чтобы ее стационарные значения изменялись по формуле (1), в которой $k \geq 2$. С этой целью автором было предложено ввести в архитектуру сети ДАП дополнительную обратную связь t_B (рис. 2), а также новый способ секционирования входных данных.

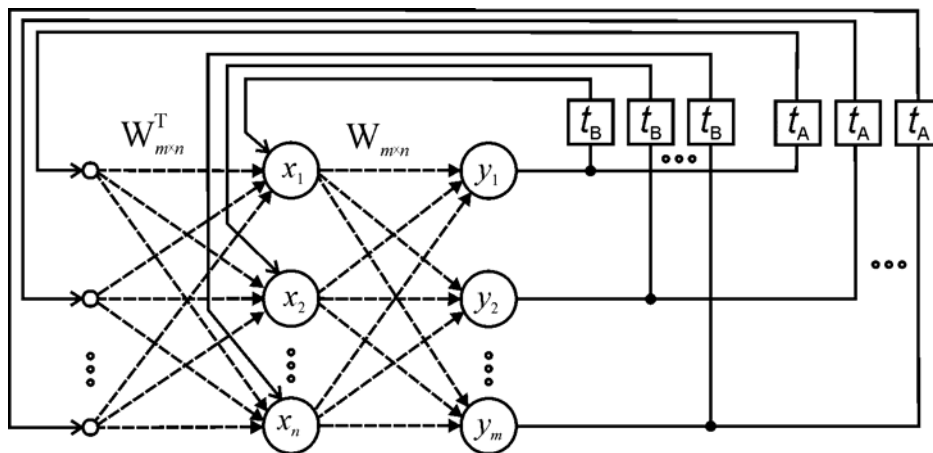


Рис. 2. Модифицированная сеть ДАП

Допустим, имеется бинарный вектор $X = (x_1, x_2, \dots, x_p)^T$, в котором содержится некая информационная последовательность L_p . Далее разделим вектор X на k векторов x_i одинаковой длины таким образом, чтобы выполнялись следующие условия:

$$\begin{cases} x_i \neq x_j, & i \neq j, \quad i, j = \overline{1, k}; \\ p \bmod k = 0. \end{cases} \quad (2)$$

Другими словами, исходный информационный вектор X представлен как строго определенная последовательность уникальных вектор-столбцов x_i меньшей, но одинаковой длины $X = [x_1; x_2; \dots; x_k]$ (рис. 3, а, б). Максимальное число k , на которое может быть разбит исходный вектор X , зависит от длины регулярных последовательностей нулей и единиц, встречаю-

щихся в исходном бинарном векторе. Далее запишем (закодируем) каждый из полученных векторов \mathbf{x}_i , которые здесь и далее будем называть информационными блоками, с помощью сети ДАП таким образом, чтобы его собственным ключом был предшествующий ему вектор \mathbf{x}_{i-1} . Таким образом, предложенный способ секционирования входных данных заключается в кодировании вектора $\mathbf{X} = [\mathbf{x}_1; \mathbf{x}_2; \dots; \mathbf{x}_k]$ как замкнутой последовательности пар уникальных векторов $\mathbf{x}_1 \Rightarrow \mathbf{x}_2, \mathbf{x}_2 \Rightarrow \mathbf{x}_3, \dots, \mathbf{x}_{k-1} \Rightarrow \mathbf{x}_k$ и $\mathbf{x}_k \Rightarrow \mathbf{x}_1$ (рис. 3, в). Другими словами, если входными данными для обучения сети ДАП служит набор $[\mathbf{x}_1; \mathbf{x}_2; \dots; \mathbf{x}_{k-1}; \mathbf{x}_k]$, то в качестве выходных данных требуется использовать набор $[\mathbf{x}_2; \mathbf{x}_3; \dots; \mathbf{x}_k; \mathbf{x}_1]$, т.е. обучающая выборка будет состоять из набора следующих векторов:

$$\begin{cases} \mathbf{X} = [\mathbf{x}_1; \mathbf{x}_2; \dots; \mathbf{x}_{k-1}; \mathbf{x}_k]; \\ \mathbf{Y} = [\mathbf{x}_2; \mathbf{x}_3; \dots; \mathbf{x}_k; \mathbf{x}_1]. \end{cases} \quad (3)$$




Рис. 3. Запись вектора \mathbf{X} по предложенному методу: а) и б) подготовка; в) запись

Предложенный алгоритм функционирования сети ДАП отличается от классического тем, что после стабилизации значений выходов нейронов обоих слоев добавляется вторая обратная связь t_B , которая идет от второго слоя к первому напрямую, не взаимодействуя с весовой квадратной матрицей $W_{n \times n}$. В результате предложенный алгоритм позволяет запоминать детерминированную последовательность \mathbf{L}_p , равную

$$p = k \cdot n \quad (4)$$

элементам, где k – число информационных блоков; n – длина входного и выходного слоев ДАП.

Следовательно, если число входных и выходных нейронов в сети ДАП $m = n = const$, а число информационных блоков может быть увеличено (если полученные новые подобразы не коррелируют между собой), то k тоже будет увеличиваться. Другими словами, будет расти объем запоминаемой информации \mathbf{L}_p . Стоит еще раз уточнить, что \mathbf{L}_p – это не объем общей памяти сети ДАП, а информационная последовательность нулей и единиц, состоящая из полученного набора подобразов. Под объемом памяти $V_{\text{ДАП}}$ сети ДАП понимается максимально возможное число запоминаемых образов, которое определяется выражением

$$V_{\text{ДАП}} \leq \frac{l}{4 \cdot \log_2 l}, \quad l = \min(n, m), \quad (5)$$

где l – количество нейронов в наименьшем слое. В рассматриваемом случае $l = m = n$, тогда $V_{\text{ДАП}}$ равняется объему сети Хопфилда [5].

Введем новую качественную характеристику – информационную эффективность сети I , с помощью которой можно оценить предложенный гетероассоциативный метод представления

информации. Следуя [18, 19], определим I как количество бит информации, приходящейся на один синапс, т. е.

$$I = \frac{L}{n^2}, \quad (6)$$

где L – информация, извлекаемая из сети; n^2 – общее количество элементов сети, способных к модификации (синаптические связи). Вычислим информационную эффективность при записи одного образа, т. е. при фиксированном размере матрицы весов $W_{n \times n}$, с помощью сети Хопфилда: $I_{\text{Хопф}} = \frac{L}{n^2} = \frac{n}{n^2} = \frac{1}{n}$ и с помощью модифицированной ДАП: $I_{\text{ДАП}} = \frac{p}{n^2} = \frac{k \cdot n}{n^2} = \frac{k}{n}$, где n – число нейронов во входном слое; k – число подобразов, на которые разбивается исследуемый образ. Таким образом, если ставится задача сохранить один образ с помощью ассоциативной нейронной сети, то $I_{\text{ДАП}} = k \cdot I_{\text{Хопф}}$.

В результате использования предложенных способ секционирования входных данных и модифицированного алгоритма функционирования сети ДАП последняя способна реализовывать отображение специального вида: $\mathbf{x}_{i+1} = F(\mathbf{x}_i)$, причем $\mathbf{x}_1 = F(\mathbf{x}_k)$, где k – количество информационных блоков, на которые был разбит первоначальный вектор \mathbf{X} . После проведенного процесса обучения сеть ДАП способна восстанавливать и идентифицировать запомненный на этапе обучения вектор \mathbf{X} по любому известному ключевому вектору \mathbf{x}_i . Поэтому процессы записи и извлечения информации, закодированной в виде последовательности уникальных векторов \mathbf{x}_i , являются возможными только в процессе динамического режима работы сети.

Так как итерационный процесс извлечения информации является циклическим, значения выходов описанной системы, попав на аттрактор, будут бесконечно изменяться согласно формуле (1). Поэтому предложенный метод регламентирует и правило останова. Процесс распознавания (извлечения) считается успешно завершенным, если за конечное число итераций на выходе сети ДАП появится вектор, идентичный ключевому, который послужил стимулом к возникновению данного динамического режима. Если описанное правило не выполняется, т. е. значения выходов сети ДАП находятся в хаотическом режиме, то считается, что искомый образ не был записан в память либо ключевой вектор не обладает достаточным количеством начальной информации.

2. Извлечение и идентификация данных

С помощью модифицированной сети ДАП, а также предложенных способа секционирования и метода записи входных данных появляется возможность реализовать устройства, способные выполнять одну из следующих функций: извлечение либо идентификацию данных, представленных информационной последовательностью \mathbf{L}_p . Основой подобных устройств, к числу которых относятся устройства извлечения и идентификации данных, может служить не только описанная выше модифицированная сеть ДАП, но и любая другая реализация гетероассоциативной памяти.

На рис. 4, а изображена блок-схема алгоритма работы устройства, предназначенного для ассоциативного извлечения (восстановления) по любой известной части заранее сохраненной информационной последовательности \mathbf{L}_p , в качестве которой, например, могут выступать как графические изображения, так и текстовые файлы, предварительно закодированные в бинарный вид. Одним из главных требований для записи указанной информации \mathbf{L}_p является описанный выше этап предобработки, цель которого заключается в ее декомпозиции на некоторое число информационных блоков, соответствующих условию (2). Полученные информационные блоки должны быть записаны в модифицированную сеть ДАП по предложенному методу (3).

Процесс извлечения информации \mathbf{L}_p должен начинаться с ввода любого из известных информационных блоков, представленного вектором $\mathbf{x}_{\text{нач}}$. Затем значения данного вектора

присваиваются временному вектору x , который записывается в результирующий массив X и с помощью сети ДАП извлекает первый вектор-отклик y . На следующей итерации значения полученного вектор-отклика y присваиваются значениям нового вектор-стимула x , который извлекает из сети ДАП очередной информационный блок. Таким образом, пока выполняется условие $x_{нач} \neq y$, из сети ДАП последовательно извлекаются информационные блоки, принадлежащие искомой информационной последовательности L_p . После того как будет извлечен ключевой вектор $x_{нач}$, следует этап проверки на адекватность работы устройства. В данном случае используется проверка на наличие числа k информационных блоков. Для этого была введена дополнительная переменная-счетчик c . В качестве альтернативы можно предложить, чтобы k -й информационный блок содержал некую наперед заданную последовательность символов, являющуюся признаком конца информационной последовательности L_p .

На рис. 4, б изображена блок-схема алгоритма работы устройства, предназначенного для регистрации в потоке сенсорных данных определенного класса образов, которые могут описывать критические значения некоторых физических процессов. Подобными сенсорными данными могут быть графические изображения, акустические сигналы, данные химических анализаторов и т. д. Таким образом, задачей устройства является причисление входного вектора к одному из двух классов (например, штатный и нештатный режимы), причем близость либо корреляция между образами каждого из классов может полностью отсутствовать, т. е. сигналы могут быть различной природы. Главное, чтобы их информационные блоки отвечали условиям (2).




Рис. 4. Блок-схемы алгоритмов функционирования предлагаемых устройств

Принцип работы предлагаемого устройства идентификации сенсорных данных заключается в подсчете количества ассоциируемых пар информационных блоков исследуемого вектора X . Если информационные блоки принадлежат к известному образу, то, начиная с первого, они будут последовательно отображаться друг в друга и счетчик c будет равен $(k - 1)$. В данном случае считается, что исследуемый вектор X соответствует одному из известных эталонов, при этом устройство выдаст сигнал о его распознавании.

3. Примеры и эксперименты по записи и извлечению информации

На типовых примерах записи и извлечения информации рассмотрим преимущества модифицированной сети ДАП. Для начала проанализируем пример записи и восстановления бинарного вектора с помощью предложенного модифицированного способа. Допустим, у нас имеется 16-битный вектор-столбец $\mathbf{X} = (1 \ 1 \ 0 \ 0 \ 1 \ 1 \ 1 \ 1 \ 1 \ 0 \ 0 \ 1 \ 1 \ 0 \ 1 \ 0)^T$, т. е. его длина $p = 16$. Максимально допустимым числом частей k , на которое его можно разделить согласно условию (3), является четыре. Это объясняется тем, что исходный вектор \mathbf{X} нельзя разделить на 3-битные векторы без остатка, а при разделении его на 2-битные среди них окажутся одинаковые. Таким образом, получим следующие четыре вектора: $\mathbf{x}_1 = (1 \ 1 \ 0 \ 0)^T$, $\mathbf{x}_2 = (1 \ 1 \ 1 \ 1)^T$, $\mathbf{x}_3 = (1 \ 0 \ 0 \ 1)^T$ и $\mathbf{x}_4 = (1 \ 0 \ 1 \ 0)^T$.

Чтобы записать полученную последовательность $\mathbf{X} = [\mathbf{x}_1; \mathbf{x}_2; \mathbf{x}_3; \mathbf{x}_4]$ с помощью предложенного метода, реализуем двухслойную сеть ДАП, в каждом слое которой будет находиться по четыре нейрона. Воспользуемся обобщенной формулой генерации матрицы синаптических связей $W_{m \times n}$ по следующей формуле [5–7]:

$$W_{m \times n} = \sum_{i=1}^k (2 \cdot \mathbf{Y}_i^{(m)} - 1) \otimes (2 \cdot \mathbf{X}_i^{(n)} - 1)^T, \quad (7)$$

где k – число пар обучаемой выборки $\{\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_k\}$ и $\{\mathbf{Y}_1, \mathbf{Y}_2, \dots, \mathbf{Y}_k\}$; n и m – число входных и выходных нейронов соответственно; операция в скобках необходима для перевода бинарных векторов в биполярные.

Учитывая, что $m = n = 4$, $k = 4$, $\mathbf{X} = [\mathbf{x}_1; \mathbf{x}_2; \mathbf{x}_3; \mathbf{x}_4]$ и $\mathbf{Y} = [\mathbf{x}_2; \mathbf{x}_3; \mathbf{x}_4; \mathbf{x}_1]$, получим

$$\begin{aligned} W_{4 \times 4} &= \left(\begin{bmatrix} 1 \\ 1 \\ 1 \\ 1 \end{bmatrix} \otimes [1 \ 1 \ -1 \ -1] + \begin{bmatrix} 1 \\ -1 \\ -1 \\ 1 \end{bmatrix} \otimes [1 \ 1 \ 1 \ 1] + \begin{bmatrix} 1 \\ -1 \\ 1 \\ -1 \end{bmatrix} \otimes [1 \ -1 \ -1 \ 1] + \begin{bmatrix} 1 \\ 1 \\ -1 \\ -1 \end{bmatrix} \otimes [1 \ -1 \ 1 \ -1] \right) = \\ &= \left(\begin{bmatrix} 1 & 1 & -1 & -1 \\ 1 & 1 & -1 & -1 \\ 1 & 1 & -1 & -1 \\ 1 & 1 & -1 & -1 \end{bmatrix} + \begin{bmatrix} 1 & 1 & 1 & 1 \\ -1 & -1 & -1 & -1 \\ -1 & -1 & -1 & -1 \\ 1 & 1 & 1 & 1 \end{bmatrix} + \begin{bmatrix} 1 & -1 & -1 & 1 \\ -1 & 1 & 1 & -1 \\ 1 & -1 & -1 & 1 \\ -1 & 1 & 1 & -1 \end{bmatrix} + \begin{bmatrix} 1 & -1 & 1 & -1 \\ -1 & 1 & -1 & 1 \\ -1 & 1 & -1 & 1 \\ -1 & 1 & -1 & 1 \end{bmatrix} \right) = \\ &= \begin{bmatrix} 4 & 0 & 0 & 0 \\ 0 & 0 & 0 & -4 \\ 0 & 0 & -4 & 0 \\ 0 & 4 & 0 & 0 \end{bmatrix}. \end{aligned}$$

Таким образом, в значениях полученной весовой матрицы $W_{4 \times 4}$ синаптических связей нейронов содержится информация об искомом векторе \mathbf{X} . Далее, учитывая функцию генерации вектор-отклика сети ДАП [5–7]

$$\mathbf{Y}^{(m)} = f(W_{m \times n} \cdot \mathbf{X}^{(n)} - \mathbf{B}^{(m)}), \quad (8)$$

где $f(x)$ – функция активации (например, знаковая функция сигнум); $\mathbf{B}^{(m)}$ – вектор смещения (как правило, равный нулю), восстановим всю последовательность, начиная с ввода третьего участка $\mathbf{x}_3 = (1 \ 0 \ 0 \ 1)^T$:

$$\mathbf{x}'_4 = \operatorname{sgn} \begin{pmatrix} 4 & 0 & 0 & 0 \\ 0 & 0 & 0 & -4 \\ 0 & 0 & -4 & 0 \\ 0 & 4 & 0 & 0 \end{pmatrix} \cdot \begin{pmatrix} 1 \\ 0 \\ 0 \\ 1 \end{pmatrix} = \operatorname{sgn} \begin{pmatrix} 4 \\ 0 \\ 4 \\ 0 \end{pmatrix} = \begin{pmatrix} 1 \\ 0 \\ 1 \\ 0 \end{pmatrix} = \mathbf{x}_4;$$

$$\mathbf{x}'_1 = \operatorname{sgn} \begin{pmatrix} 4 & 0 & 0 & 0 \\ 0 & 0 & 0 & -4 \\ 0 & 0 & -4 & 0 \\ 0 & 4 & 0 & 0 \end{pmatrix} \cdot \begin{pmatrix} 1 \\ 0 \\ 1 \\ 0 \end{pmatrix} = \operatorname{sgn} \begin{pmatrix} 4 \\ 4 \\ 0 \\ 0 \end{pmatrix} = \begin{pmatrix} 1 \\ 1 \\ 0 \\ 0 \end{pmatrix} = \mathbf{x}_1;$$

$$\mathbf{x}'_2 = \operatorname{sgn} \begin{pmatrix} 4 & 0 & 0 & 0 \\ 0 & 0 & 0 & -4 \\ 0 & 0 & -4 & 0 \\ 0 & 4 & 0 & 0 \end{pmatrix} \cdot \begin{pmatrix} 1 \\ 1 \\ 0 \\ 0 \end{pmatrix} = \operatorname{sgn} \begin{pmatrix} 4 \\ 4 \\ 4 \\ 4 \end{pmatrix} = \begin{pmatrix} 1 \\ 1 \\ 1 \\ 1 \end{pmatrix} = \mathbf{x}_2,$$

и, наконец, проверим ключевой образ

$$\mathbf{x}'_3 = \operatorname{sgn} \begin{pmatrix} 4 & 0 & 0 & 0 \\ 0 & 0 & 0 & -4 \\ 0 & 0 & -4 & 0 \\ 0 & 4 & 0 & 0 \end{pmatrix} \cdot \begin{pmatrix} 1 \\ 1 \\ 1 \\ 1 \end{pmatrix} = \operatorname{sgn} \begin{pmatrix} 4 \\ 0 \\ 0 \\ 4 \end{pmatrix} = \begin{pmatrix} 1 \\ 0 \\ 0 \\ 1 \end{pmatrix} = \mathbf{x}_3.$$

В результате восстановлена вся искомая последовательность $\mathbf{X}=[\mathbf{x}_1; \mathbf{x}_2; \mathbf{x}_3; \mathbf{x}_4]$, причем восстановление можно было начинать с любой известной части.

Рассмотрим второй пример, в котором требуется разработать устройство ассоциативного хранения несжатой графической информации – монохромных изображений. При этом существуют аппаратные ограничения на число параллельных каналов ввода-вывода и объем используемой памяти – 8 Мб. Таким образом, если на один элемент весовой матрицы W выделить по 8 бит, то максимальный ее размер составит 1024×1024 элементов.

С помощью современных аппаратных средств можно реализовать сеть Хопфилда, которая будет в состоянии запоминать монохромные изображения размером 32×32 (рис. 5, а). Точно такого же размера можно реализовать сеть ДАП, которая тоже будет способна запоминать и восстанавливать монохромные изображения размером 32×32 . Однако благодаря предложенному методу гетероассоциативной записи и извлечения последовательности образов изображения, показанные на рис. 5, б–д, можно закодировать как подобразы одного большого образа. В результате обученная по предложенному методу сеть ДАП способна при вводе одного из известных подобразов 5, б–д восстановить искомый образ, размеры которого будут уже 64×64 (рис. 5, е). Таким образом, в приведенном примере сеть ДАП способна хранить и восстанавливать (при наличии любой из четырех составных частей) монохромное изображение 5, е, которое в четыре раза превышает по размеру изображение 5, а.




Рис. 5. Восстановление графических изображений сетями Хопфилда и модифицированной ДАП

На следующем примере рассмотрим обратную задачу. Имеется монохромное изображение размером 120×160 , требуется определить минимальный размер весовой матрицы $W_{n \times n}$, способной к восстановлению указанного изображения с помощью предложенного метода по любой его известной части. Для этого необходимо провести ряд экспериментов, заключающихся в делении монохромного изображения (рис. 6, а) на k одинаковых по размеру участков. Ниже приведены 15 возможных способов деления, причем на рис. 6, б указан седьмой способ, т. е. 2×4 :

- | | | | | |
|-----------------------|-----------------------|------------------------|-------------------------|-------------------------|
| 1) $1 \times 1 = 1$; | 4) $2 \times 2 = 4$; | 7) $2 \times 4 = 8$; | 10) $3 \times 5 = 15$; | 13) $6 \times 4 = 24$; |
| 2) $1 \times 2 = 2$; | 5) $1 \times 5 = 5$; | 8) $2 \times 5 = 10$; | 11) $4 \times 4 = 16$; | 14) $5 \times 5 = 25$; |
| 3) $3 \times 1 = 3$; | 6) $3 \times 2 = 6$; | 9) $3 \times 4 = 12$; | 12) $4 \times 5 = 20$; | 15) $6 \times 5 = 30$. |

Затем полученные подобразы записываются по предложенному методу в сеть ДАП.




Рис. 6. Пример записи и распознавания монохромного изображения

На графике (рис. 7) отчетливо видна зависимость качества распознавания отдельных подобразов от длины n входного вектора сети ДАП ($n = p/k$, $p = const$ – длина информационной последовательности). Из формулы (5) видно, что от числа n зависит максимально возможное число подобразов. Сплошной линией на графике указана относительная погрешность распознавания δ_k при различных способах разбиения исходного изображения:

$$\delta_k = \frac{1}{n} \sum_{i=1}^k h(x_i, \tilde{x}_i) \cdot 100\%, \quad (9)$$

где $h(x_i, \tilde{x}_i)$ – расстояние Хемминга между эталонными x_i подобразами из обучающей выборки и соответствующими подобразами \tilde{x}_i , полученными в результате распознавания. Деление на n необходимо для устранения влияния размера входного слоя на значение погрешности.




Рис. 7. Экспериментальные данные различных способов записи монохромного изображения

Эксперименты на конкретном изображении (см. рис. 6, *a*) показали, что из-за сильной корреляции между подобразами с ростом числа k пропорционально растет и относительная погрешность набора подобразов δ_k . Это в конечном счете приводит к разрушению первоначального образа, т. е. образ полностью не восстанавливается. На рис. 6, *b* изображен пример, когда исходное изображение было поделено на восемь одинаковых по размеру частей и было восстановлено с ошибкой в 5%. Хотя, судя по графику, при $k=5$ максимально возможным числом подобразов, которое можно записать в ДАП, является 50.

Благодаря своей нейросетевой архитектуре предложенная модель памяти способна добавлять новые и удалять старые образы. Это свойство достигается благодаря безытерационному способу обучения ДАП [16, 17]. Например, из памяти обученной сети ДАП с весовой матрицей $W_{n \times n}$ требуется удалить информационный блок \mathbf{x}_i , тогда необходимо разорвать ассоциативную связь между последовательными блоками $\mathbf{x}_{i-1} \Rightarrow \mathbf{x}_i$ и $\mathbf{x}_i \Rightarrow \mathbf{x}_{i+1}$ и создать новую ассоциативную пару $\mathbf{x}_{i-1} \Rightarrow \mathbf{x}_{i+1}$:

$$W'_{n \times n} = W_{n \times n} - \mathbf{x}_i \otimes \mathbf{x}_{i-1}^T - \mathbf{x}_{i+1} \otimes \mathbf{x}_i^T + \mathbf{x}_{i+1} \otimes \mathbf{x}_{i-1}^T. \quad (10)$$

Для добавления в сеть ДАП после i -го участка нового информационного блока \mathbf{x}_j необходимо воспользоваться следующей формулой:

$$W''_{n \times n} = W_{n \times n} - \mathbf{x}_{i+1} \otimes \mathbf{x}_i^T + \mathbf{x}_j \otimes \mathbf{x}_i^T + \mathbf{x}_{i+1} \otimes \mathbf{x}_j^T. \quad (11)$$

В результате для выполнения операций над определенным информационным блоком в предложенном методе организации памяти не требуется искать его расположение среди других блоков (представленных в виде списка), необходимо только создать новую или удалить старую ассоциативную связь.

Заключение

Предложена модификация нейронной сети ДАП, а также способ секционирования и записи входных данных, позволяющие не только ассоциативно идентифицировать (распознавать) ранее запомненные образы, но и извлекать (восстанавливать) из памяти определенные последовательности соответствующих ассоциативных пар. Описываемая итерационная модель нейросетевой гетероассоциативной памяти способна эффективно оперировать большими объемами информации. Так, количество элементов информационной последовательности L_p , состоящей из нулей и единиц, при фиксированном размере весовой матрицы синаптических связей $W_{n \times n}$ может достигать длины $p = k \cdot n$, где n – размер входного слоя нейронной сети ДАП, а k – количество уникальных информационных блоков запоминаемого образа.

Среди основных положительных свойств полученной модели памяти можно выделить реализацию поиска информации по ее содержанию и хранение информации в виде структурированных последовательностей. Также можно отметить, что процесс выборки информации представляет собой динамический процесс, подобный процессам, протекающим в различных физических системах непрерывного действия. Недостатком предложенной модели памяти является ее небольшая емкость, связанная с ограниченной способностью сети ДАП.

Благодаря итерационному методу записи и извлечения, а также распределенному методу хранения информации на множестве взаимодействующих нейроподобных элементов рассматриваемая модель обладает сложной нелинейной динамикой, свойства которой еще предстоит изучить.

Список литературы

1. Кузнецов, С.Д. Основы баз данных : учебное пособие / С.Д. Кузнецов. – 2-е изд., испр. – М. : Интернет-университет информационных технологий; БИНОМ. Лаборатория знаний, 2007. – 484 с.

2. Кохонен, Т. Ассоциативные запоминающие устройства / Т. Кохонен. – М. : Мир, 1982. – 384 с.
3. Hopfield, J. Neural networks and physical systems with emergent collective computational abilities / J. Hopfield // Proc. of National Academy of Sciences. – 1982. – Vol. 79, № 8. – P. 2554–2558.
4. Hopfield, J.J. Computing with neural circuits / J.J. Hopfield, D.W. Tank // A model. Science. – 1986. – Vol. 233. – P. 625–633.
5. The capacity of the Hopfield associative memory / R.J. McEliece [et al.] // IEEE Transactions on Information Theory. – 1987. – Vol. 33, № 4. – P. 461–482.
6. Elman, J.L. Finding structure in time / J.L. Elman // Cognitive Science. – 1990. – Vol. 14. – P. 179–211.
7. Narendra, K.S. Identification and control of dynamical systems using neural networks / K.S. Narendra, K. Parthasarathy // IEEE Trans. Neural Networks. – 1990. – Vol. 1. – P. 4–27.
8. Improved Elman networks and applications for controlling ultrasonic motors / X.H. Shi [et al.] // Applied Artificial Intelligence: An International Journal. – 2004. – Iss. 7, vol. 18. – P. 603–629.
9. Хайкин, С. Нейронные сети: полный курс / С. Хайкин. – 2-е изд., пер. с англ. – М. : Вильямс, 2006. – 1104 с.
10. Фролов, А.А. Нейронные модели ассоциативной памяти / А.А. Фролов, И.П. Муравьев. – М. : Наука, 1987. – 160 с.
11. Ежов, А.А. Нейрокомпьютинг и его применения в экономике и бизнесе / А.А. Ежов, С.А. Шумский. – М. : МИФИ, 1998. – 223 с.
12. Меламед, И.И. Нейронные сети и комбинаторная оптимизация / И.И. Меламед // Автоматика и телемеханика. – 1994. – № 11. – С. 3–40.
13. Уоссермен, Ф. Нейрокомпьютерная техника: теория и практика / Ф. Уоссермен. – М. : Мир, 1990. – 240 с.
14. Kosko, B. Constructing an associative memory / B. Kosko // Byte. – 1987. – Vol. 12. – P. 137–144.
15. Kosko, B. Bi-directional associative memories / B. Kosko // IEEE Transactions on Systems, Man and Cybernetics. – 1988. – Vol. 18, № 1. – P. 49–60.
16. Прокопович, Г.А. Адаптивный нейросетевой классификатор / Г.А. Прокопович // Информатика. – 2009. – № 23. – С. 68–81.
17. Прокопович, Г.А. Нейросетевой блок памяти для адаптивной работы сложных технических систем в динамической среде / Г.А. Прокопович // Информатика. – 2010. – № 26. – С. 54–65.
18. Palm, G. On the information storage capacity of local learning rules / G. Palm // Neural Comp. – 1992. – Vol. 4. – P. 703–711.
19. Sommer, F.T. Improved bidirectional retrieval of sparse patterns stored by Hebbian learning / F.T. Sommer, G. Palm // Neural Networks. – 1999. – Vol. 12 (2). – P. 281–297.

Поступила 17.02.12

*Объединенный институт проблем
информатики НАН Беларуси,
Минск, Сурганова, 6
e-mail: bigznich@tut.by*

R.A. Prakupovich

**HETEROASSOCIATIVE NEURAL NETWORKS APPLICATION
FOR DATA RECORDING AND RECOVERY**

The problem of an associative representation of the data is considered on an example of recurrent neural networks of Hopfield type. An original heteroassociative input data representing method is proposed, which is based on data splitting into equal parts, followed by sequential mapping of these parts into each other. The obtained neural network architecture is able for recording and associative recovery of large volumes of information.