

## Лекция 4.

# Системы распознавания образов (идентификации)

---

- Перцептроны.
- Нейронные сети. История исследований, модель с обратным распространением ошибки.

# Перцептроны

Одним из методов решения задач обучения распознаванию образов основан на моделировании гипотетического механизма человеческого мозга.

Структура модели заранее постулируется. При таком подходе уровень биологических знаний или гипотез о биологических механизмах является исходной предпосылкой, на которой базируются модели этих механизмов.


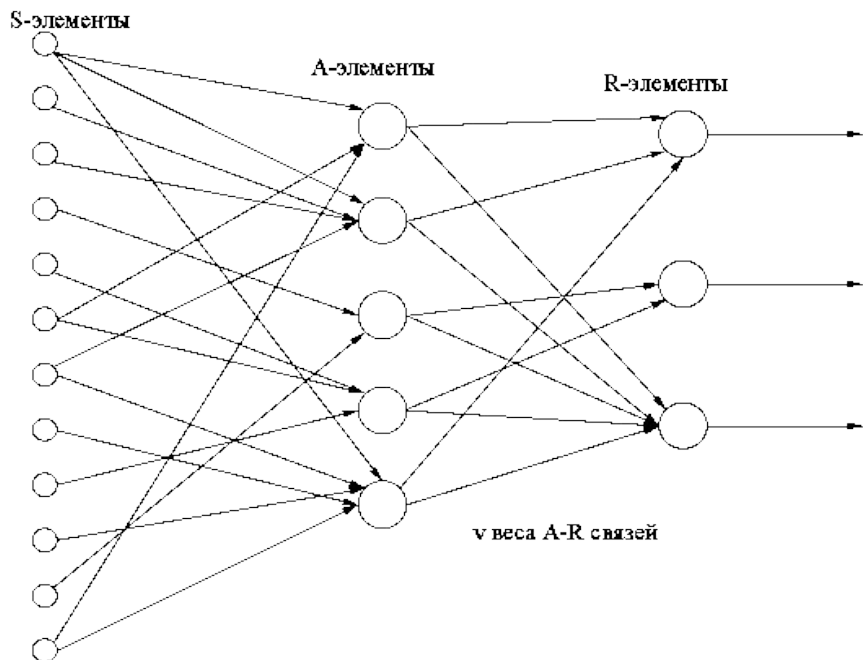


Рис. 1

# Перцептроны



□ совокупности сенсорных элементов S-элементов

□ S-элементы случайным образом связаны с совокупностью ассоциативных элементов A-элементов, выход которых отличается от нуля только тогда, когда возбуждено достаточно большое число S-элементов.

□ A-элементы соединены с реагирующими элементами R-элементами связями, коэффициенты усиления v которых переменны и изменяются в процессе обучения.

□ Взвешенные комбинации выходов R-элементов составляют реакцию системы, которая указывает на принадлежность распознаваемого объекта определенному образу.

# Перцептроны

---

Если распознаются только два образа, то в перцептроне устанавливается только один R-элемент, который обладает двумя реакциями — положительной и отрицательной.

Если образов больше двух, то для каждого образа устанавливают свой R-элемент, а выход каждого такого элемента представляет линейную комбинацию выходов A-элементов:

$$R_j = \Theta_j + \sum_{i=1}^n v_{ij} x_i \quad (1)$$

$R_j$  - реакция j-го R-элемента;

$x_i$  - реакция i-го A-элемента;

$\Theta_j$  - порог j-го R-элемента.

$v_{ij}$  - вес связи от i-го A-элемента к j-му R-элементу;

Аналогично записывается уравнение i-го A-элемента:

$$x_i = \Theta_i + \sum_{k=1}^S y_k \quad (2)$$

Сигнал  $y_k$  может быть непрерывным, но чаще всего он принимает только два значения: 0 или 1. Сигналы от S-элементов подаются на входы A-элементов с постоянными весами равными 1, но каждый A-элемент связан только с группой случайно выбранных S-элементов.

# Перцептроны

---

Предположим, что требуется обучить перцептрон различать два образа  $V1$  и  $V2$ .

Будем считать, что в перцептроне существует два  $R$ -элемента, один из которых предназначен образу  $V1$ , а другой — образу  $V2$ .

Перцептрон будет обучен правильно, если выход  $R1$  превышает  $R2$ , когда распознаваемый объект принадлежит образу  $V1$ , и наоборот.

Разделение объектов на два образа можно провести и с помощью только одного  $R$ -элемента. Тогда объекту образа  $V1$  должна соответствовать положительная реакция  $R$ -элемента, а объектам образа  $V2$  — отрицательная.

# Перцептроны

---

Перцептрон обучается путем предъявления обучающей последовательности изображений объектов, принадлежащих образам  $V1$  и  $V2$ .

В процессе обучения изменяются веса  $v_i$   $A$ -элементов. В частности, если применяется система подкрепления с коррекцией ошибок, прежде всего учитывается правильность решения, принимаемого перцептроном.

Если решение правильно, то веса связей всех сработавших  $A$ -элементов, ведущих к  $R$ -элементу, выдавшему правильное решение, увеличиваются, а веса несработавших  $A$ -элементов остаются неизменными.

Можно оставлять неизменными веса сработавших  $A$ -элементов, но уменьшать веса несработавших. В некоторых случаях веса сработавших связей увеличивают, а несработавших — уменьшают.

После процесса обучения перцептрон сам, без учителя, начинает классифицировать новые объекты.

# Перцептроны

Если в перцептроне допускаются лишь связи, идущие от бинарных S-элементов к A-элементам и от A-элементов к единственному R-элементу, то такой перцептрон принято называть элементарным альфа-перцептроном.

Обычно классификация  $S(W)$  задается учителем. Перцептрон должен выработать в процессе обучения классификацию, задуманную учителем.




Рис. 2. Элементарный  $\alpha$ -перцептрон

# Перцептроны. Теоремы

---

О перцептронах было сформулировано и доказано несколько основополагающих теорем, две из которых, определяющие основные свойства перцептрона, приведены ниже.

**Теорема 1.** Класс элементарных альфа-перцептронов, для которых существует решение для любой задуманной классификации, не является пустым.

Эта теорема утверждает, что для любой классификации обучающей последовательности можно подобрать такой набор (из бесконечного набора)  $A$ -элементов, в котором будет осуществлено задуманное разделение обучающей последовательности при помощи линейного решающего правила ).



# Перцептроны. Теоремы

---

**Теорема 2.** Если для некоторой классификации  $S(W)$  решение существует, то в процессе обучения  $\alpha$ -перцептрона с коррекцией ошибок, начинающегося с произвольного исходного состояния, это решение будет достигнуто в течение конечного промежутка времени.

Смысл этой теоремы состоит в том, что если относительно задуманной классификации можно найти набор  $A$ -элементов, в котором существует решение, то в рамках этого набора оно будет достигнуто в конечный промежуток времени.

# Перцептроны. Теоремы

---

Обычно обсуждают свойства бесконечного перцептрона, т. е. перцептрона с бесконечным числом  $A$ -элементов со всевозможными связями с  $S$ -элементами (полный набор  $A$ -элементов).

В таких перцептронах решение всегда существует, а раз оно существует, то оно и достижимо в альфа-перцептронах с коррекцией ошибок.

Очень интересную область исследований представляют собой многослойные перцептроны и перцептроны с перекрестными связями, но теория этих систем практически еще не разработана.

# Нейронные сети

---

- История исследований в области нейронных сетей
- Модель нейронной сети с обратным распространением ошибки (back propagation)

# Нейронные сети. История исследований.

---

Способность нейронной сети к обучению впервые исследована **Дж. Маккалоком** и **У. Питтом**.

В 1943 году вышла их работа "Логическое исчисление идей, относящихся к нервной деятельности", в которой была построена модель нейрона, и сформулированы принципы построения искусственных нейронных сетей.

Крупный толчок развитию нейрокибернетики дал американский нейрофизиолог **Фрэнк Розенблатт**, предложивший в 1962 году свою модель нейронной сети — перцептрон.

В 1982 году американский биофизик **Дж. Хопфилд** предложил оригинальную модель нейронной сети, названную его именем. В последующие несколько лет было найдено множество эффективных алгоритмов:

- сеть встречного потока,
- двунаправленная ассоциативная память и др.

В киевском институте кибернетики с 70-х годов ведутся работы над стохастическими нейронными сетями.

# Модель нейронной сети с обратным распространением ошибки (back propagation)

---

В 1986 году Дж. Хинтон и его коллеги опубликовали статью с описанием модели нейронной сети и алгоритмом ее обучения, что дало новый толчок исследованиям в области искусственных нейронных сетей.

Нейронная сеть состоит из множества одинаковых элементов — нейронов, поэтому начнем с них рассмотрение работы искусственной нейронной сети.

Биологический нейрон моделируется как устройство, имеющее несколько входов (дендриты), и один выход (аксон).

Каждому входу ставится в соответствие некоторый весовой коэффициент  $w$ , характеризующий пропускную способность канала и оценивающий степень влияния сигнала с этого входа на сигнал на выходе.

# Модель нейронной сети с обратным распространением ошибки (back propagation)

---

В зависимости от конкретной реализации, обрабатываемые нейроном сигналы могут быть аналоговыми или цифровыми (1 или 0).

В теле нейрона происходит взвешенное суммирование входных возбуждений, и далее это значение является аргументом активационной функции нейрона, один из возможных вариантов которой представлен на Рис. 3.

# Модель нейронной сети с обратным распространением ошибки (back propagation)

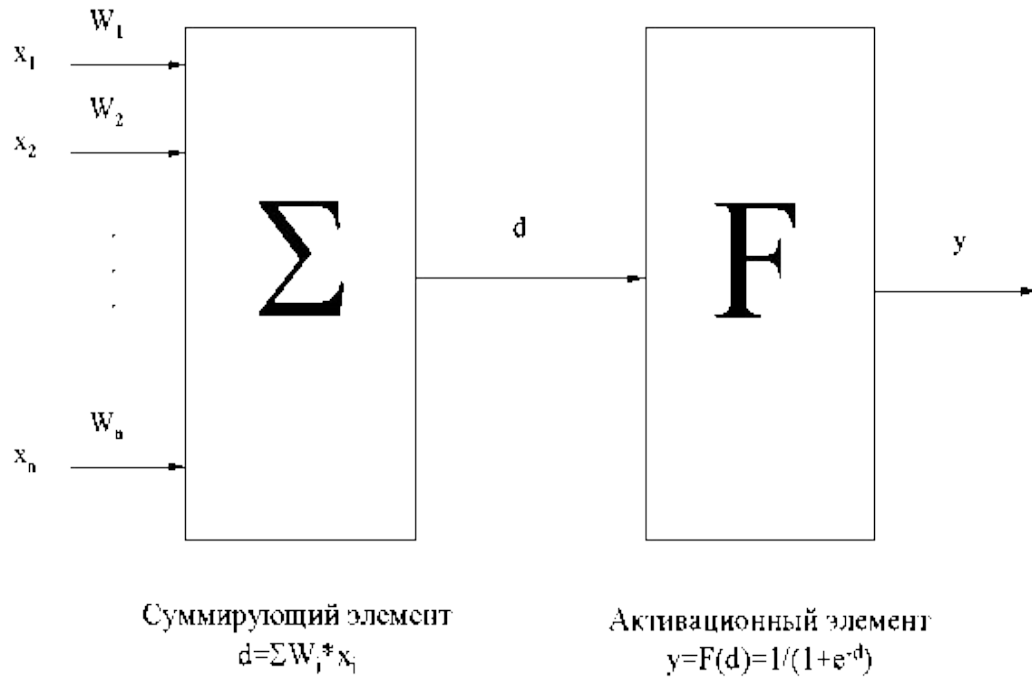


Рис. 3. Искусственный нейрон

Будучи соединенными определенным образом, нейроны образуют нейронную сеть. Работа сети разделяется на обучение и адаптацию.

Под обучением понимается процесс адаптации сети к предъявляемым эталонным образцам путем модификации (в соответствии с тем или иным алгоритмом) весовых коэффициентов связей между нейронами.

Заметим, что этот процесс является результатом алгоритма функционирования сети, а не предварительно заложенных в нее знаний человека, как это часто бывает в системах искусственного интеллекта.

# Модель нейронной сети с обратным распространением ошибки (back propagation)

---

Среди различных структур нейронных сетей (НС) одной из наиболее известных является многослойная структура, в которой каждый нейрон произвольного слоя связан со всеми аксонами нейронов предыдущего слоя или, в случае первого слоя, со всеми входами НС.

Такие НС называются **полносвязными**.

Когда в сети только один слой, алгоритм ее обучения с учителем довольно очевиден, так как правильные выходные состояния нейронов единственного слоя заведомо известны, и подстройка синаптических связей идет в направлении, минимизирующем ошибку на выходе сети.

По этому принципу строится, например, алгоритм обучения однослойного перцептрона.



# Модель нейронной сети с обратным распространением ошибки (back propagation)

---

В многослойных же сетях оптимальные выходные значения нейронов всех слоев, кроме последнего, как правило, не известны, и двух- или более слойный перцептрон уже невозможно обучить, руководствуясь только величинами ошибок на выходах НС.

Приемлемый вариант решения – распространение сигналов ошибки от выходов НС к ее входам, в направлении, обратном прямому распространению сигналов в обычном режиме работы.

Этот алгоритм обучения НС получил название процедуры обратного распространения. Именно он будет рассмотрен в дальнейшем.

# Модель нейронной сети с обратным распространением ошибки (back propagation)

---

Согласно методу наименьших квадратов, минимизируемой целевой функцией ошибки НС является величина:

$$E(w) = \frac{1}{2} \sum_{j,p} (y_{j,p}^{(N)} - d_{j,p})^2 \quad (3)$$

где  $y_{j,p}^{(N)}$  – реальное выходное состояние нейрона  $j$  выходного слоя  $N$  нейронной сети при подаче на ее входы  $p$ -го образа;  $d_{jp}$  – идеальное (желаемое) выходное состояние этого нейрона.

Суммирование ведется по всем нейронам выходного слоя и по всем обрабатываемым сетью образам.

Минимизация ведется методом градиентного спуска, что означает подстройку весовых коэффициентов следующим образом:

$$\Delta w_{ij}^{(n)} = -\eta \cdot \frac{\partial E}{\partial w_{ij}} \quad (4)$$

здесь  $w_{ij}$  – весовой коэффициент синаптической связи, соединяющей  $i$ -ый нейрон слоя  $n-1$  с  $j$ -ым нейроном слоя  $n$ ;  $\eta$  – коэффициент скорости обучения,  $0 < \eta < 1$ .

# Модель нейронной сети с обратным распространением ошибки (back propagation)

---

Как показано в [Розенблатт Ф. Принципы нейродинамики (перцептрон и теория механизмов мозга).]

$$\frac{\partial E}{\partial w_{ij}} = \frac{\partial E}{\partial y_j} \cdot \frac{dy_j}{ds_j} \cdot \frac{\partial s_j}{\partial w_{ij}} \quad (5)$$

Здесь под  $y_j$ , как и раньше, подразумевается выход нейрона  $j$ , а под  $s_j$  – взвешенная сумма его входных сигналов, то есть аргумент активационной функции.

Так как множитель  $\frac{dy_j}{ds_j}$  является производной этой функции по ее аргументу, из этого следует, что производная активационной функции должна быть определена на всей оси абсцисс.

# Модель нейронной сети с обратным распространением ошибки (back propagation)

---

В связи с этим функция единичного скачка и прочие активационные функции с неоднородностями не подходят для рассматриваемых НС.

В них применяются такие гладкие функции, как гиперболический тангенс или классический сигмоид с экспонентой. В случае гиперболического тангенса

$$\frac{dy}{ds} = 1 - s^2 \quad (6)$$

Третий множитель  $\frac{\partial s_j}{\partial w_{ij}}$  очевидно, равен выходу нейрона предыдущего слоя  $y_i^{(n-1)}$

# Модель нейронной сети с обратным распространением ошибки (back propagation)

---

Что касается первого множителя в (5), он легко раскладывается следующим образом:

$$\frac{\partial E}{\partial y_j} = \sum_k \frac{\partial E}{\partial y_k} \cdot \frac{dy_k}{ds_k} \cdot \frac{\partial s_k}{\partial y_j} = \sum_k \frac{\partial E}{\partial y_k} \cdot \frac{dy_k}{ds_k} \cdot w_{jk}^{(n+1)} \quad (7)$$

Здесь суммирование по  $k$  выполняется среди нейронов слоя  $n+1$ .  
Введя новую переменную:

$$\delta_j^{(n)} = \frac{\partial E}{\partial y_j} \cdot \frac{dy_j}{ds_j} \quad (8)$$

мы получим рекурсивную формулу для расчетов величин  $\delta_j^{(n)}$  слоя  $n$  из величин  $\delta_j^{(n+1)}$  более старшего слоя  $n+1$ .

$$\delta_j^{(n)} = \left[ \sum_k \delta_k^{(n+1)} \cdot w_{jk}^{(n+1)} \right] \cdot \frac{dy_j}{ds_j} \quad (9)$$

Для выходного же слоя:

$$\delta_l^{(N)} = (y_l^{(N)} - d_l) \cdot \frac{dy_l}{ds_l} \quad (10)$$

# Модель нейронной сети с обратным распространением ошибки (back propagation)

---

Теперь мы можем записать (4) в раскрытом виде:

$$\Delta w_{ij}^{(n)} = -\eta \cdot \delta_j^{(n)} \cdot y_i^{(n-1)} \quad (11)$$

Иногда для придания процессу коррекции весов некоторой инерционности, сглаживающей резкие скачки при перемещении по поверхности целевой функции, (11) дополняется значением изменения веса на предыдущей итерации

$$\Delta w_{ij}^{(n)}(t) = -\eta \cdot (\mu \cdot \Delta w_{ij}^{(n)}(t-1) + (1 - \mu) \cdot \delta_j^{(n)} \cdot y_i^{(n-1)}) \quad (12)$$

где  $\mu$  – коэффициент инерционности,  $t$  – номер текущей итерации.

# Модель нейронной сети с обратным распространением ошибки (back propagation)

---

Таким образом, полный алгоритм обучения НС с помощью процедуры обратного распространения ошибки строится так:

1. Подать на входы сети один из возможных образов и в режиме обычного функционирования НС, когда сигналы распространяются от входов к выходам, рассчитать значения последних. Напомним, что

$$s_j^{(n)} = \sum_{i=0}^M y_i^{(n-1)} \cdot w_{ij}^{(n)} \quad (13)$$

где  $M$  – число нейронов в слое  $n-1$  с учетом нейрона с постоянным выходным состоянием  $+1$ , задающего смещение;

$y_i^{(n-1)} = x_{ij}^{(n)}$  –  $i$ -ый вход нейрона  $j$  слоя  $n$ .

$$y_j^{(n)} = f(s_j^{(n)}) \quad \text{где } f() \text{ – сигмоид} \quad (14)$$

$$y_q^{(0)} = I_q \quad (15)$$

где  $I_q$  –  $q$ -ая компонента вектора входного образа.

# Модель нейронной сети с обратным распространением ошибки (back propagation)

---

2. Рассчитать  $\delta^{(N)}$  для выходного слоя по формуле (10).

Рассчитать по формуле (11) или (12) изменения весов  $\Delta w^{(N)}$  слоя  $N$ .

3. Рассчитать по формулам (9) и (11) (или (9) и (12)) соответственно  $\delta^{(n)}$  и  $\Delta w^{(n)}$  для всех остальных слоев,  $n = N-1, \dots, 1$ .

4. Скорректировать все веса в НС

$$w_{ij}^{(n)}(t) = w_{ij}^{(n)}(t-1) + \Delta w_{ij}^{(n)}(t) \quad (16)$$

5. Если ошибка сети существенна, перейти на шаг 1. В противном случае – конец.



# Модель нейронной сети с обратным распространением ошибки (back propagation)

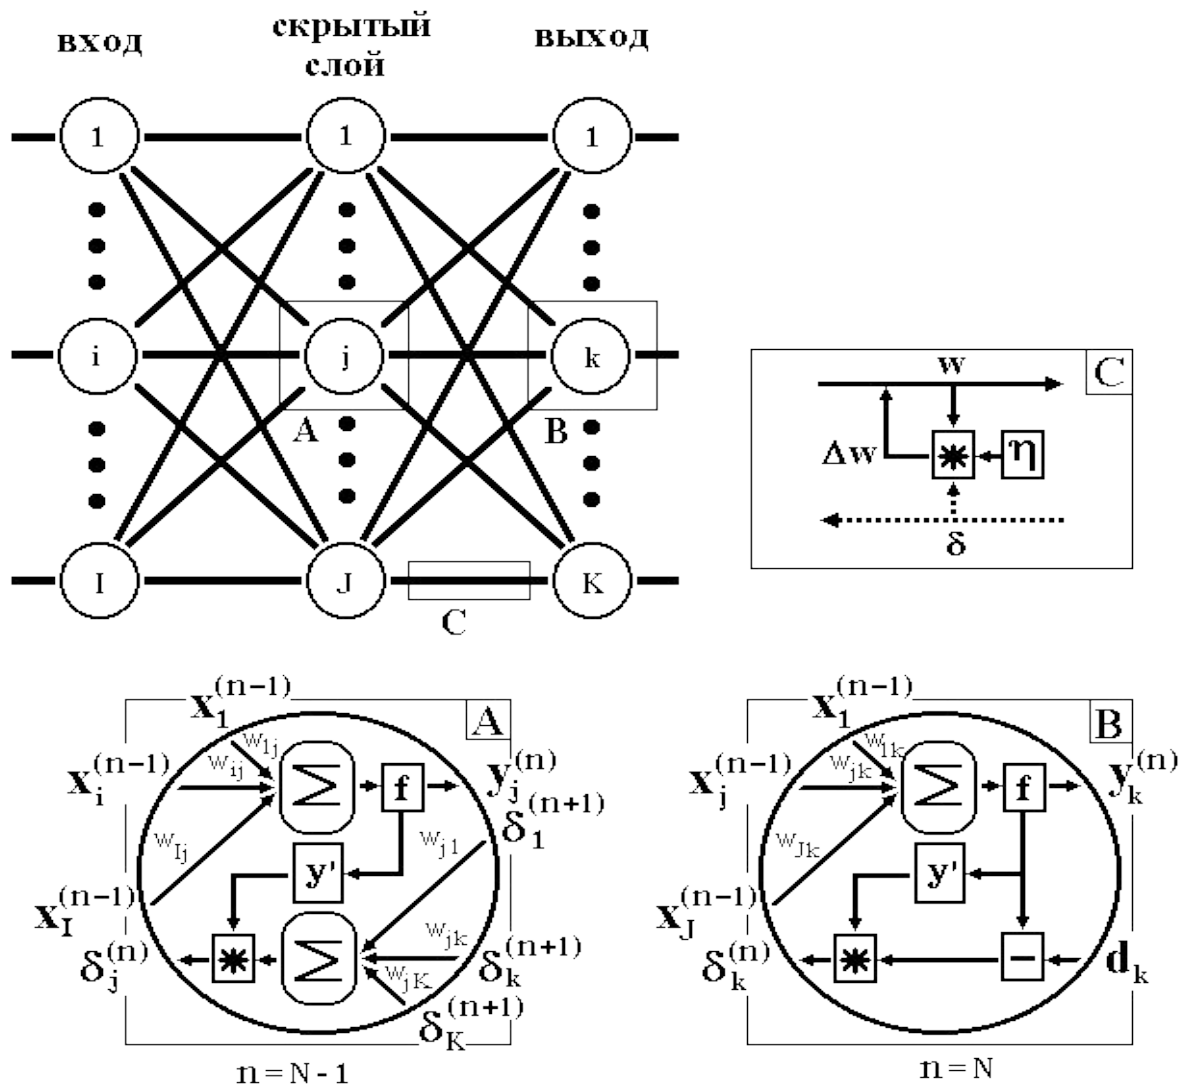


Рис. 4

# Модель нейронной сети с обратным распространением ошибки (back propagation)

---

Сети на шаге 1 попеременно в случайном порядке предъявляются все тренировочные образы, чтобы сеть, образно говоря, не забывала одни по мере запоминания других. Алгоритм иллюстрируется Рис. 4

Из выражения (11) следует, что когда выходное значение  $y_i(n-1)$  стремится к нулю, эффективность обучения заметно снижается. При двоичных входных векторах в среднем половина весовых коэффициентов не будет корректироваться [3], поэтому область возможных значений выходов нейронов  $[0, 1]$  желательно сдвинуть в пределы  $[-0.5, +0.5]$ , что достигается простыми модификациями логистических функций. Например, сигмоид с экспонентой преобразуется к виду:

$$f(x) = -0.5 + \frac{1}{1 + e^{-\alpha \cdot x}} \quad (17)$$

# Модель нейронной сети с обратным распространением ошибки (back propagation)

---

Теперь коснемся вопроса ёмкости НС, то есть числа образов, предъявляемых на ее входы, которые она способна научиться распознавать. Для сетей с числом слоев больше двух, он остается открытым. Как показано в [4], для НС с двумя слоями, то есть выходным и одним скрытым слоем, детерминистская емкость сети  $C_d$  оценивается так:

$$\frac{N_w}{N_y} < C_d < \frac{N_w}{N_y} \log\left(\frac{N_w}{N_y}\right) \quad (18)$$

где  $N_w$  – число подстраиваемых весов,  $N_y$  – число нейронов в выходном слое.

Следует отметить, что данное выражение получено с учетом некоторых ограничений. Во-первых, число входов  $N_x$  и нейронов в скрытом слое  $N_h$  должно удовлетворять неравенству  $N_x + N_h > N_y$ .

Во-вторых,  $N_w/N_y > 1000$ . Однако вышеприведенная оценка выполнялась для сетей с активационными функциями нейронов в виде порога, а емкость сетей с гладкими активационными функциями, например – (17), обычно больше.