#### Лекция 4.

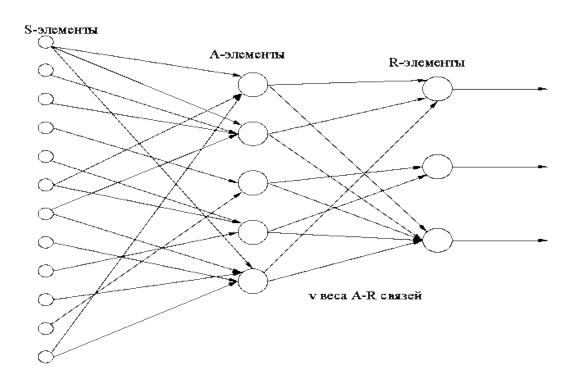
### Системы распознавания образов (идентификации)

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

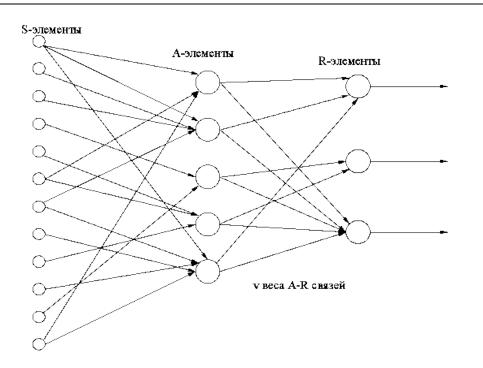


Одним из методов решения задач обучения распознаванию образов основан на моделировании гипотетического механизма человеческого мозга.

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







- □ совокупности <u>сенсорных</u> элементов **S-элементов**
- □ S-элементы случайным образом связаны с совокупностью ассоциативных элементов А-элементов, выход которых отличается от нуля только тогда, когда возбуждено достаточно большое число S-элементов.
- □ <u>А-элементы</u> соединены с <u>реагирующими элементами</u> <u>**R-элементами**</u> связями, <u>коэффициенты усиления</u> <u>v</u> которых переменны и <u>изменяются в процессе обучения</u>.
- □ Взвешенные комбинации выходов <u>R-элементов</u> составляют <u>реакцию</u> <u>системы</u>, которая указывает на <u>принадлежность</u> распознаваемого <u>объекта</u> <u>определенному образу</u>.



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

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

$$R_{j}=\Theta_{j}+\sum_{i=1}^{n}v_{ij}x_{i}$$
 (1)  $R_{j}$  - реакция j-го  $R$ - реакция i-го  $A$ - элемента; элемента;  $\Theta_{j}$  - порог j-го  $R$ -элемента. - вес связи от i-го  $A$ -элемента к j-му  $R$ -  $V_{ij}$  элементу;

Аналогично записывается уравнение і-го А-элемента:

$$x_i = \Theta_i + \sum_{k=1}^{S} y_k \tag{2}$$

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

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 <u>обучен правильно</u>, если выход *R1* <u>превышает</u> *R2*, когда распознаваемый <u>объект принадлежит образу</u> *V1*, и наоборот.

<u>Разделение объектов</u> 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.



Перцептрон <u>обучается</u> путем предъявления обучающей последовательности изображений объектов, принадлежащих образам *V1* и *V2*.

<u>В процессе обучения</u> изменяются <u>веса</u> *vi А-элементов*. В частности, если применяется система подкрепления с <u>коррекцией ошибок</u>, прежде всего учитывается правильность решения, принимаемого перцептроном.

Если решение <u>правильно</u>, то веса связей всех сработавших *А*-элементов, ведущих к *R*-элементу, выдавшему правильное решение, <u>увеличиваются</u>, а веса <u>несработавших</u> *А*-элементов остаются <u>неизменными</u>.

Можно оставлять <u>неизменными</u> веса сработавших *А*-элементов, но <u>уменьшать</u> веса <u>несработавших</u>. В некоторых случаях веса сработавших связей <u>увеличивают</u>, а несработавших — <u>уменьшают</u>.

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



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

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

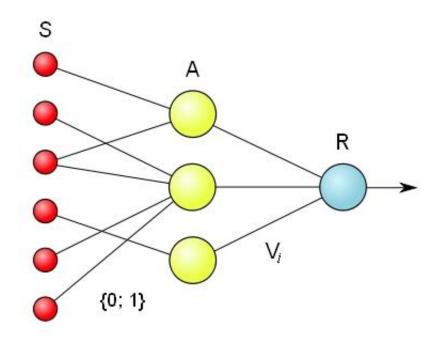


Рис. 2. Элементарный lpha-перцептрон



#### Перцептроны. Теоремы

О перцептронах было сформулировано и доказано несколько основополагающих теорем, две из которых, определяющие <u>основные</u> <u>свойства</u> 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) А-элементов, в котором будет осуществлено задуманное разделение обучающей последовательности при помощи линейного решающего правила ).



#### Перцептроны. Теоремы

**Теорема 2**. Если для некоторой классификации C(W) решение существует, то в процессе обучения а -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 А-элементов, в котором существует решение, то в рамках этого набора оно будет достигнуто в конечный промежуток времени.



#### Перцептроны. Теоремы

Обычно обсуждают свойства <u>бесконечного перцептрона</u>, т. е. перцептрона с <u>бесконечным числом А-элементов</u> со <u>всевозможными связями с S-элементами</u> (полный набор *А*-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.

<u>Способность</u> нейронной сети к <u>обучению</u> впервые исследована **Дж. Маккалоком** и **У. Питтом**.

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

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

В <u>1982</u> году американский биофизик **Дж. Хопфилд** предложил оригинальную <u>модель нейронной сети</u>, 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.



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

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

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

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



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

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



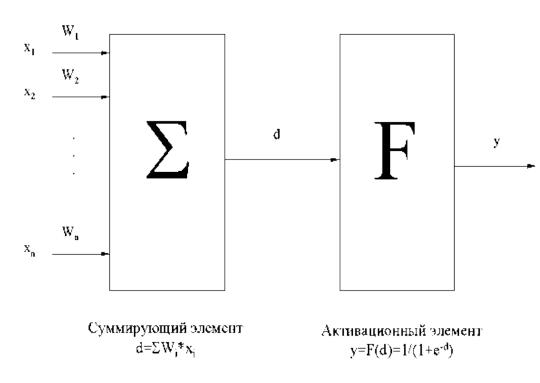


Рис. 3. Искусственный нейрон

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

Под <u>обучением</u> 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.



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

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



В <u>многослойных</u> же <u>сетях</u> 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.

<u>Приемлемый вариант решения</u> – 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.



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

$$E(w) = \frac{1}{2} \sum_{j,p} (y_{j,p}^{(N)} - d_{j,p})^2$$
(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 <u>градиентного спуска</u>, что означает <u>подстройку</u> весовых коэффициентов следующим образом:

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

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

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

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

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

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



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

$$\frac{dy}{ds} = 1 - s^2 \tag{6}$$

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



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

$$\frac{\partial E}{\partial y_i} = \sum_{k} \frac{\partial E}{\partial y_k} \cdot \frac{dy_k}{ds_k} \cdot \frac{\partial s_k}{\partial y_i} = \sum_{k} \frac{\partial E}{\partial y_k} \cdot \frac{dy_k}{ds_k} \cdot w_{jk}^{(n+1)}$$
(7)

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

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

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

$$\delta_{j}^{(n)} = \left[\sum_{k} \delta_{k}^{(n+1)} \cdot w_{jk}^{(n+1)}\right] \cdot \frac{dy_{j}}{ds_{j}} \tag{9}$$

Для выходного же слоя:

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



Теперь мы можем записать (4) в раскрытом виде:

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

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

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

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



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

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

$$y_i^{(n)} = f(s_i^{(n)})$$
 где  $f()$  – сигмоид (14)

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

где  ${\rm I}_q - q$ -ая компонента вектора входного образа.

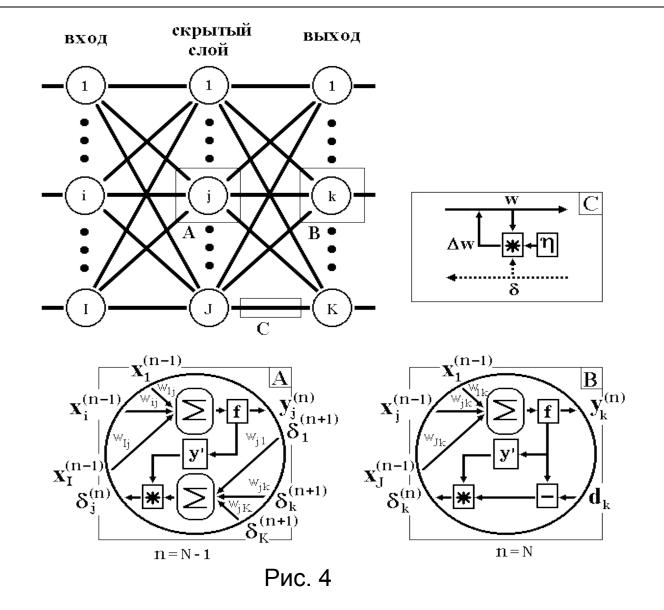


- 2. Рассчитать  $\delta^{(N)}$  для выходного слоя по формуле (10).
  - Рассчитать по формуле (11) или (12) изменения весов  $\Delta w^{(N)}$  слоя N.
- 3. Рассчитать по формулам (9) и (11) (или (9) и (12)) соответственно  $\delta^{(n)}$ и  $\Delta w^{(n)}$  для всех остальных слоев, n = N-1, ..., 1 .
- 4. Скорректировать все веса в НС

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

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







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 уі(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:

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



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 Сd оценивается так:

$$\frac{N_w}{N_v} < C_d < \frac{N_w}{N_v} \log(\frac{N_w}{N_v}) \tag{18}$$

где Nw – число подстраиваемых весов, Ny – число нейронов в выходном слое.

Следует отметить, что данное выражение получено с учетом некоторых ограничений. Во-первых, число входов Nx и нейронов в скрытом слое Nh должно удовлетворять неравенству Nx+Nh>Ny.

Во-вторых, *Nw/Ny* > 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.

