

# Data Science

## Кластеризация (Сеть Кохонена)



**MVP**



**DEDICATED  
TEAM**



**SUPPORT**

# Принцип самообучения

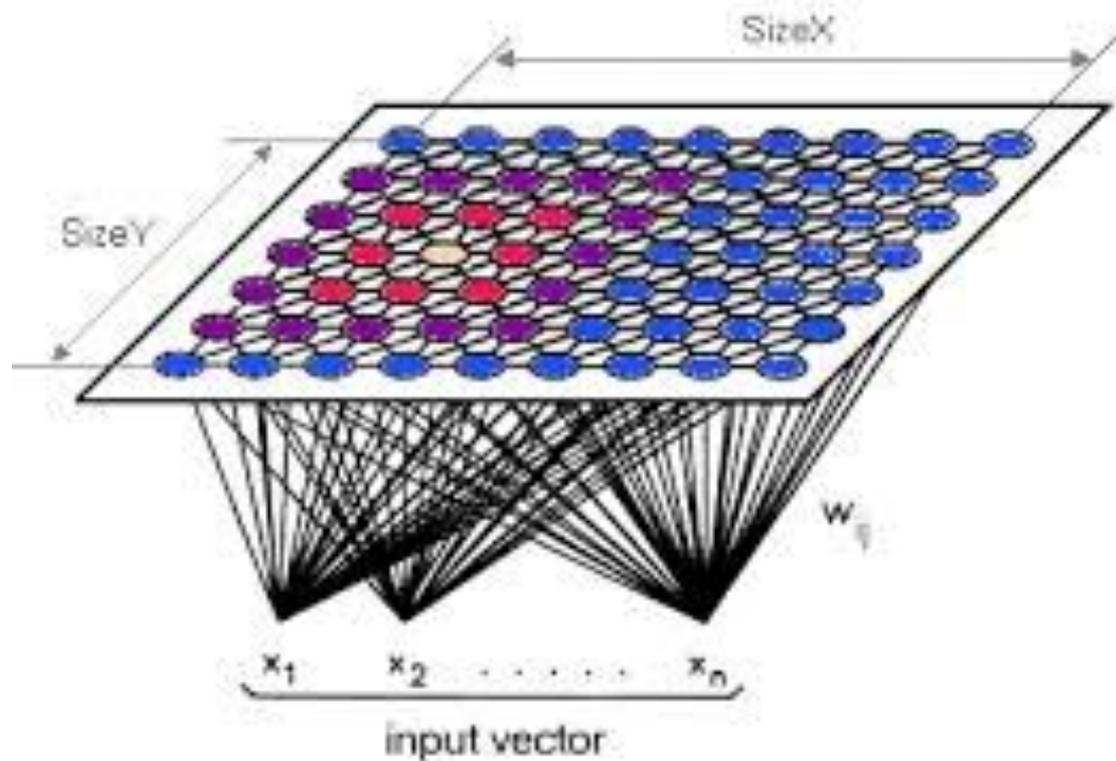
**Самообучение сети** заключается в **подстройке весов синапсов** на основании информации содержащейся в поданном входном векторе. Вид откликов на каждый класс входных событий заранее неизвестен и будет представлять собой произвольное сочетание состояний нейронов выходного слоя, обусловленное случайным распределением весов при инициализации сети.

**Общая идея алгоритмов обучения** заключается в том, что при самообучении путем коррекции весов усиливаются связи между возбужденными нейронами. Так происходит коррекция и закрепление образа, отвечающего конкретной части из всей группы рассматриваемых событий. В результате сеть способна **обобщать схожие образы** относя их к одному классу и этим выполнять **сжатие информации**.

**Архитектура слоя Кохонена и алгоритм его настройки** предполагает, что для каждого входного вектора будет активизирован лишь один **нейрон-победитель**. Для данного входного вектора только один нейрон Кохонена выдает логическую единицу, все остальные выдают ноль.

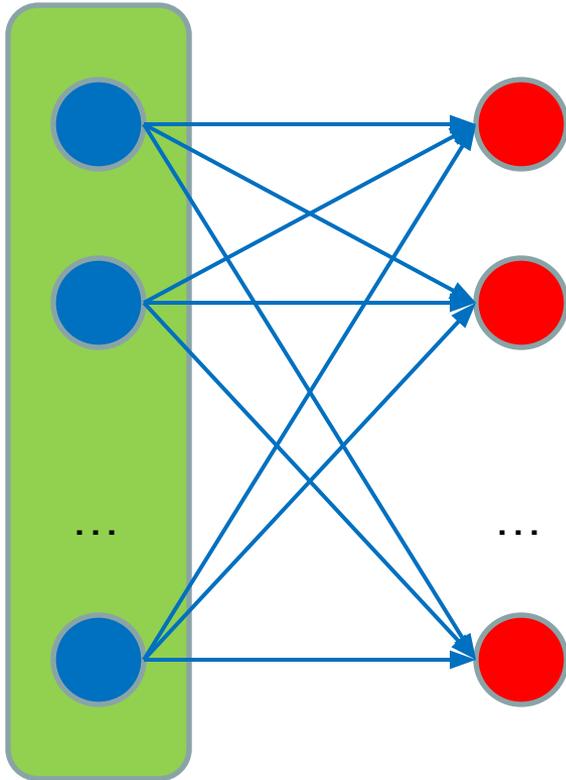
**Слой Кохонена классифицирует входные векторы** в группы схожих векторов. Это достигается с помощью такой подстройки весов, что **близкие входные векторы активизируют один и тот же нейрон**. В результате обучения слой получает способность разделять несхожие входные векторы.

# Сеть Кохонена



# Слой Кохонена

- классифицирует входные векторы в группы



Слой рецепторов  
(входной вектор)

Слой Кохонена  
(классификатор)

В простейшей форме  
реализуется модель «WTA»  
(«Победитель забирает всё»):

## Алгоритм Кохонена формирования карт признаков:

### Шаг 1. Инициализация сети:

Весовым коэффициентам сети присваиваются малые случайные значения. Общее число синаптических весов -  $M*N$  Начальная зона соседства показана на рис.

### Шаг 2. Предъявление сети нового входного сигнала.

### Шаг 3. Вычисление расстояния до всех нейронов сети:

Расстояния  $d_j$  от входного сигнала до каждого нейрона  $j$  определяется по формуле:

$$d_j = \sum_{i=0}^{n-1} (x_i(t) - w_{ij}(t))^2$$

Где  $x_i$  -  $i$ -ый элемент входного сигнала в момент времени  $t$ ,  
 $w_{ij}(t)$  - вес связи от  $i$ -го элемента входного сигнала к нейрону  $j$  в момент времени  $t$ .

### Шаг 4. Выбор нейрона с наименьшим расстоянием:

Выбирается нейрон  $j^*$ , для которого расстояние  $d_j$  наименьшее.

### Шаг 5. Настройка весов нейрона $j^*$ и его соседей:

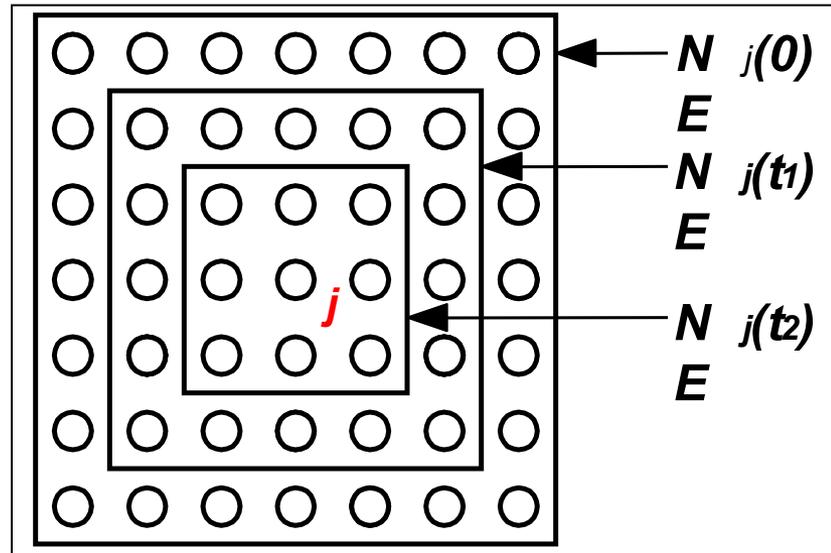
Производится подстройка весов для нейрона  $j^*$  и всех нейронов из его зоны соседства NE. Новые значения весов:

$$w_{ij}(t+1) = w_{ij}(t) + r(t) (x_i(t) - w_{ij}(t)),$$

где  $r(t)$  - шаг обучения, уменьшающийся с течением времени (положительное число, меньше единицы).

**Шаг 6. Возвращение к шагу 2 .**

## Зоны топологического соседства нейронов



$NE_j(t)$  – множество нейронов, которые являются соседями нейрона  $j$  в момент времени  $t$ .

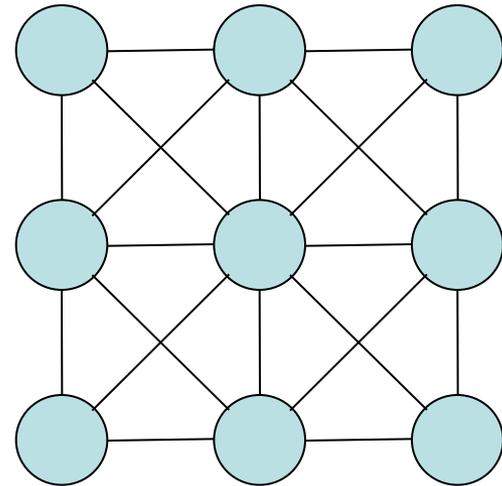
Окрестность - это несколько нейронов, окружающих выигравший нейрон.

# SOM (Карты Кохенена)

## Модель сетки

- Матрица узлов  $M^{KL} = (m_{kl})$
- Соседство - 4 или 8 СВЯЗНОСТЬ
- Каждому узлу соответствует точка в исходном пространстве

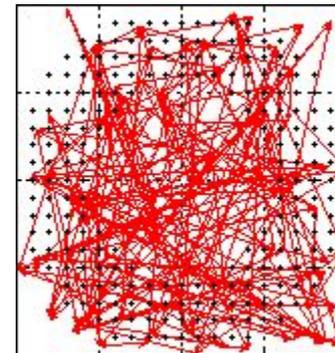
$$m_{kl} \in R^d$$



# SOM (Карты Кохенена)

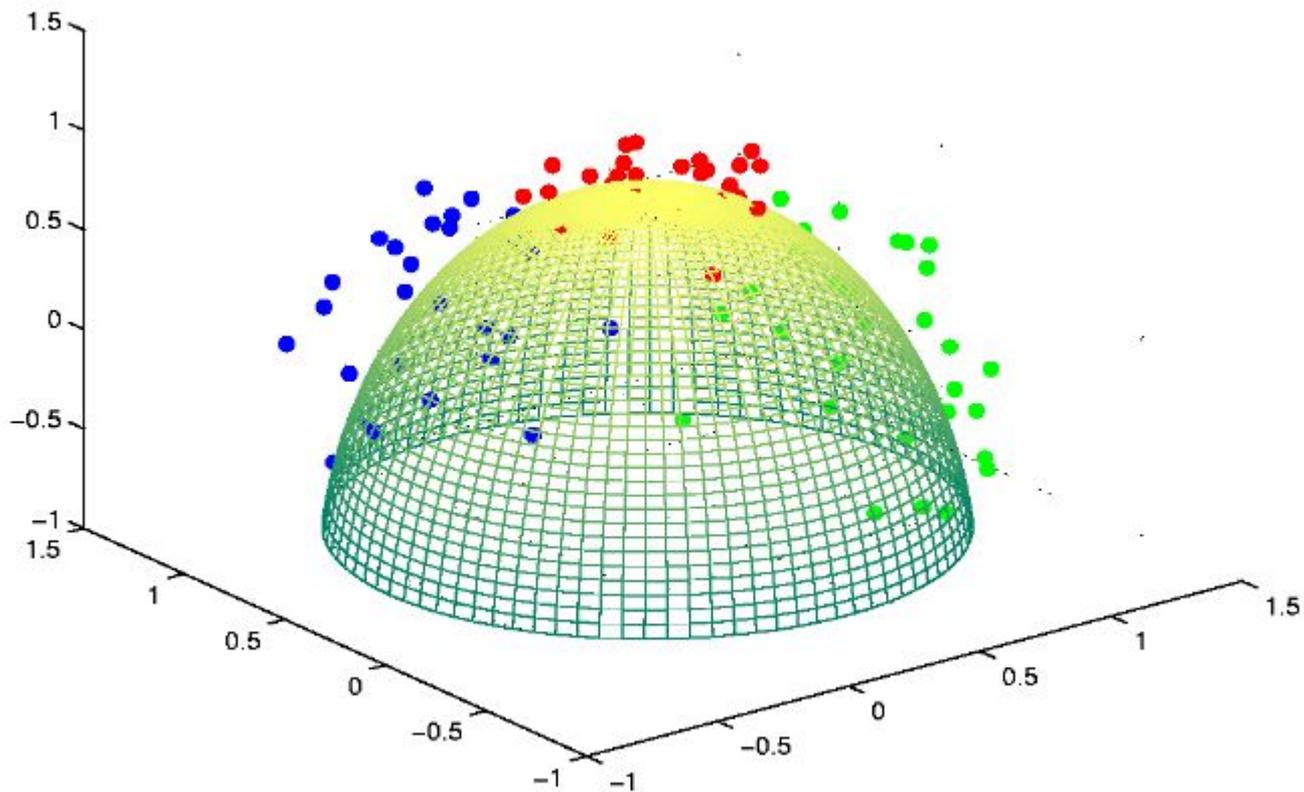
## Алгоритм построения

- Инициализируем  $(m_{ij})$  случайными значениями
- Далее, в случайном порядке будем предъявлять наблюдения и для каждого:
  - Вычисляем ближайший узел
  - Выберем множество соседей узла, такое что расстояние на сетке между ними меньше  $r$
  - Для некоторого множества соседей узла, включая сам узел, изменяем их положения согласно:  $m_{kl} \leftarrow m_{kl} + \alpha(x_i - m_{kl})$
  - Повторяем процедуру уменьшая  $r$  и  $\alpha$  пока сеть не стабилизируется



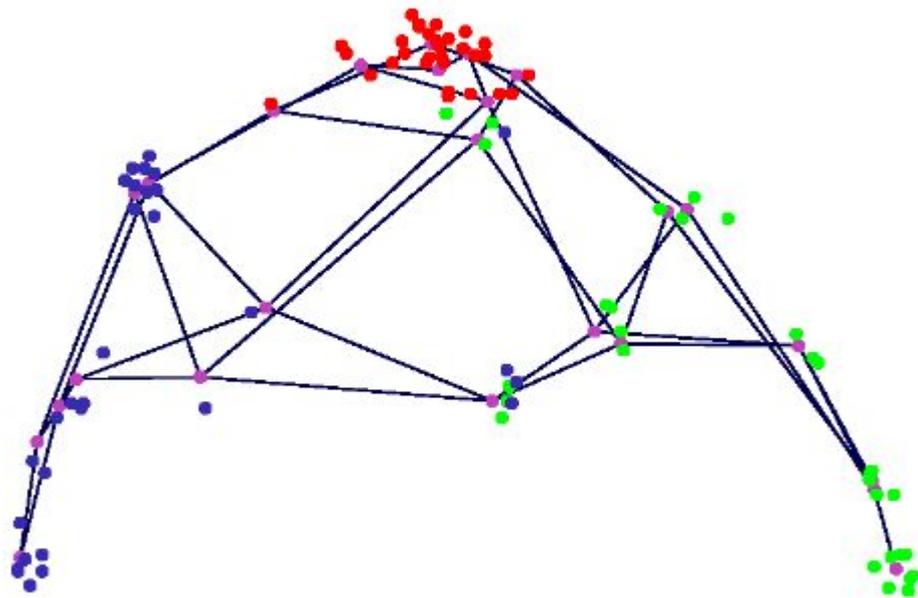
# SOM (Карты Кохенена)

## Иллюстрация: исходные данные



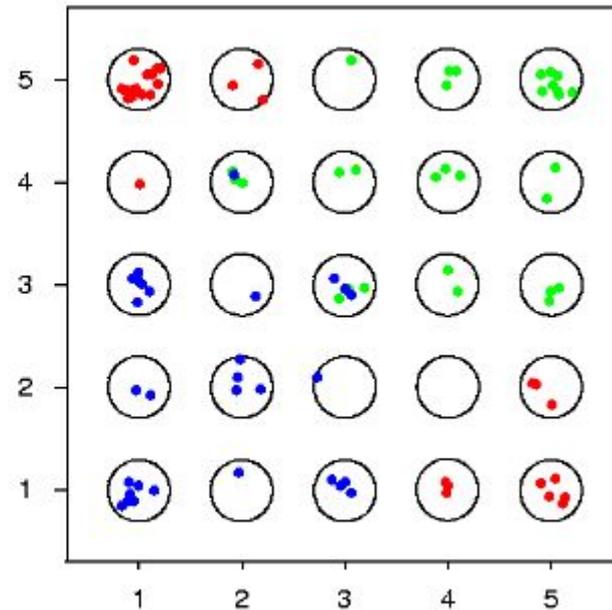
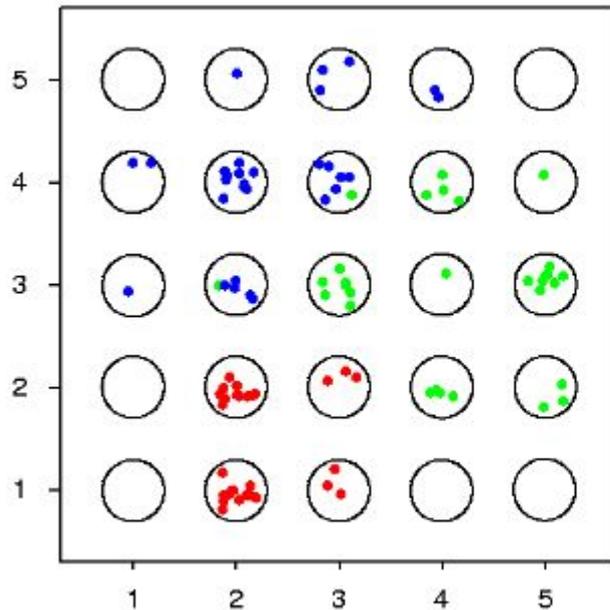
# SOM (Карты Кохенена)

Иллюстрация: сетка



# SOM (Карты Кохенена)

Иллюстрация: проекции на матрицу



# Интерпретация работы слоя

## Кохонена

**Вид откликов на каждый класс** входных образов не известен заранее и **будет представлять собой произвольное сочетание состояний нейронов выходного слоя**, обусловленное случайным распределением весов на стадии инициализации. Вместе с тем, сеть способна обобщать схожие образы, относя их к одному классу.

Для **приведения откликов обученной сети к удобному представлению** сеть дополняется одним слоем, который по алгоритму обучения однослойного перцептрона **необходимо заставить отображать выходные реакции сети в требуемые образы**.

# SOM (Карты Кохенена)

## Практическое использование

- Данные представляют некоторую поверхность, требуется сократить размерность
- Хорошо подходят для последующей кластеризации
- Могут работать «online»
- В случае слишком сложных данных не информативны

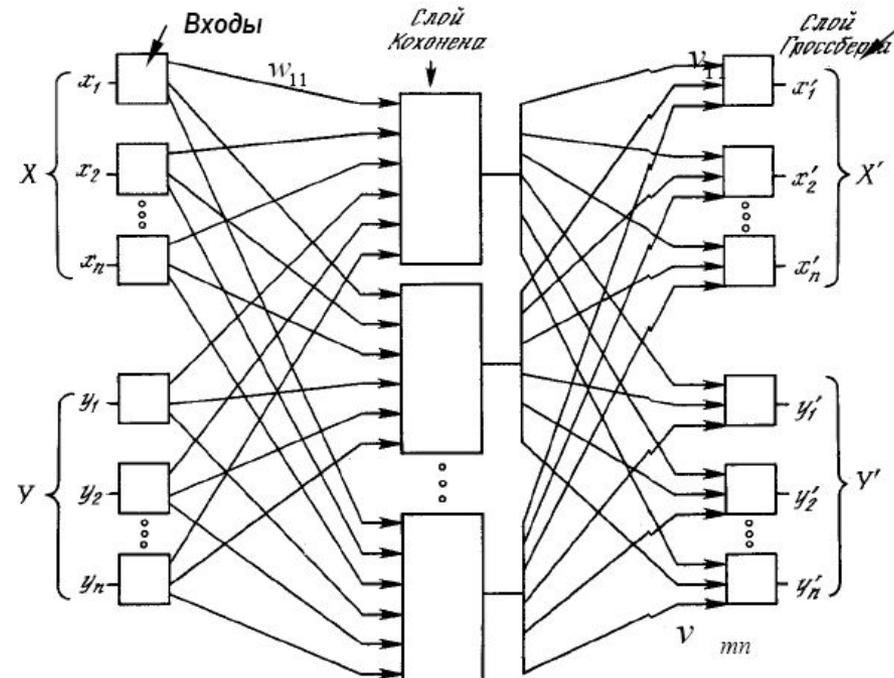
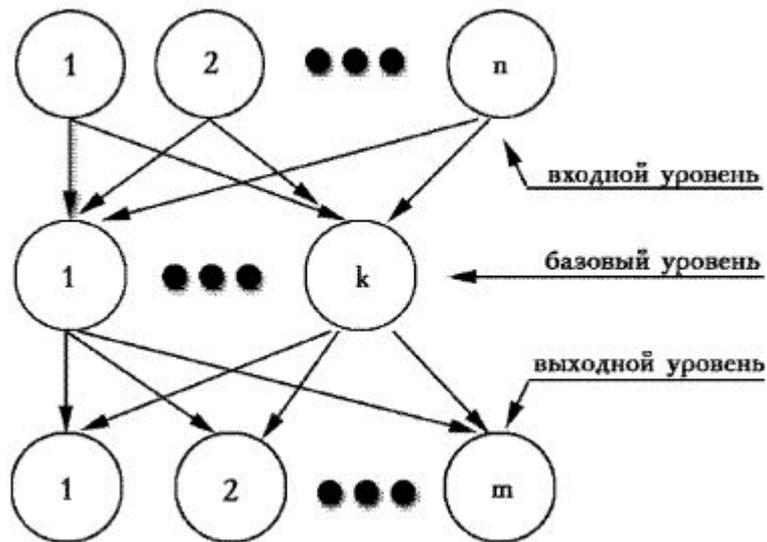
# Монохромные (бинарные) изображения

2 цвета (черный и  
белый)

Изображение  
представляется в  
виде раstra (таблицы)  
со значениями  
яркости 0 (черный) и 1  
(белый)



# Нейронная сеть Цао-Ена (Гроссберга-Кохонена)



# Отличия сети Цао-Ена от многослойного персептрона

Функция состояния

Персептрон

$$s = \sum_{i=0}^n x_i \cdot w_i$$

Сеть Цао-Ена

$$s = \sum_{i=1}^n w_{ij} x_i$$

Функция активации

Персептрон

$$f(s) = \begin{cases} 0, & s < 0; \\ 1, & s \geq 0 \end{cases}$$

$$f(s) = \frac{1}{1 + e^{-s}}$$

Сеть Цао-Ена

$$f(s) = s$$

На первый взгляд разница между сетями несущественна, но при рассмотрении процесса обучения будут видны принципиальные преимущества

# Классификация изображений.

## 1 этап сжатия

Задача классификации заключается в разбиении объектов на классы (формирующиеся динамически), причем основой разбиения служит вектор параметров объекта.

Назовём *прототипом* класса объект, наиболее типичный для своего класса. Один из самых простых подходов к классификации состоит в том, чтобы предложить существование определённого числа классов и произвольным образом выбрать координаты прототипов.

В качестве меры близости двух векторов обычно выбирается евклидово расстояние:

$$d(x, y) = \sum (x_i - y_i)^2 .$$

# Алгоритм обучения сети Цао-Ена.

## Шаги инициализации

Шаг 1. Нормализация входов

Единичная нормировка всех векторов  $(X, Y)$  обучающего множества

Шаг 2. Инициализация весов и нормализация столбцов матрицы весов

Весовым коэффициентам сети  $W_{ij}, V_{ji}$ ,  $i=1, n$ ,  $j=1, m$  присвоить случайные значения и произвести единичную нормировку матриц  $W, V$  по столбцам

Инициализация констант  $\alpha$  и  $\beta$

# Алгоритм обучения сети Цао-Ена. Обучение слоя Кохонена

При обучении сети самоорганизация происходит следующим образом. Для каждого  $j$ -го нейрона определяется расстояние от него до вектора  $X$ :

$$d_j = \sum_{i=1}^n (x_i - w_{ij})^2$$

Далее выбирается нейрон с номером  $k$  для которого это расстояние минимально (то есть сеть отнесла входной вектор к классу с номером  $k$ ).

На текущем шаге обучения  $N$  будут модифицироваться только веса нейронов и окрестности нейрона  $k$ :

$$w_{ij}^{N+1} = w_{ij}^N + \alpha_N (x_i - w_{ij}^N).$$

# Замечание по обучению

Проведем предварительную единичную нормировку входных векторов:

$$x_i' = \frac{x_i}{\sqrt{x_1^2 + x_2^2 + \dots + x_n^2}}$$

В таком случае, вычисление расстояния будет выглядеть как вычисление скалярного произведения:

$$d_j = \sum_{i=1}^n (x_i - w_{ij}^N)^2 = \sum_{i=1}^n x_i^2 - 2 \sum_{i=1}^n x_i w_{ij}^N + \sum_{i=1}^n w_{ij}^2 = 2 - 2 \sum_{i=1}^n x_i w_{ij}^N.$$

Таким образом, наименьшим будет расстояние до того нейрона, скалярное произведение с весами которого у входного вектора максимально.

# Обучение слоя Гроссберга.

## 2 этап сжатия

### Шаг 4

Корректировка весов нейрона

$$v_{kj}^{N+1} = v_{kj}^N + \beta_N (z_i - v_{kj}^N)$$

(k-номер выигравшего нейрона,

весовой вектор которого  
даёт максимальное

скалярное произведение с входным вектором)

# Алгоритм обучения сети Цао-Ена. Итерации

## Шаг 5

Уменьшение значений  $\alpha_N$ ,  $\beta_N$

## Шаг 6

Повтор шагов 3-5

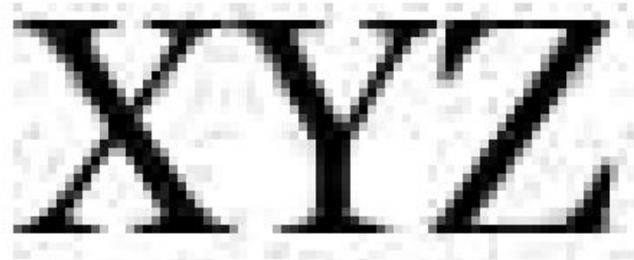
Общее количество итераций должно быть достаточно большим. Все образы обучающей выборки желательно предъявить сети несколько десятков или даже сотен раз.

# Сравнение с JPEG

Исходное изображение



Сжатие JPEG



Сжатие Цао-Ена



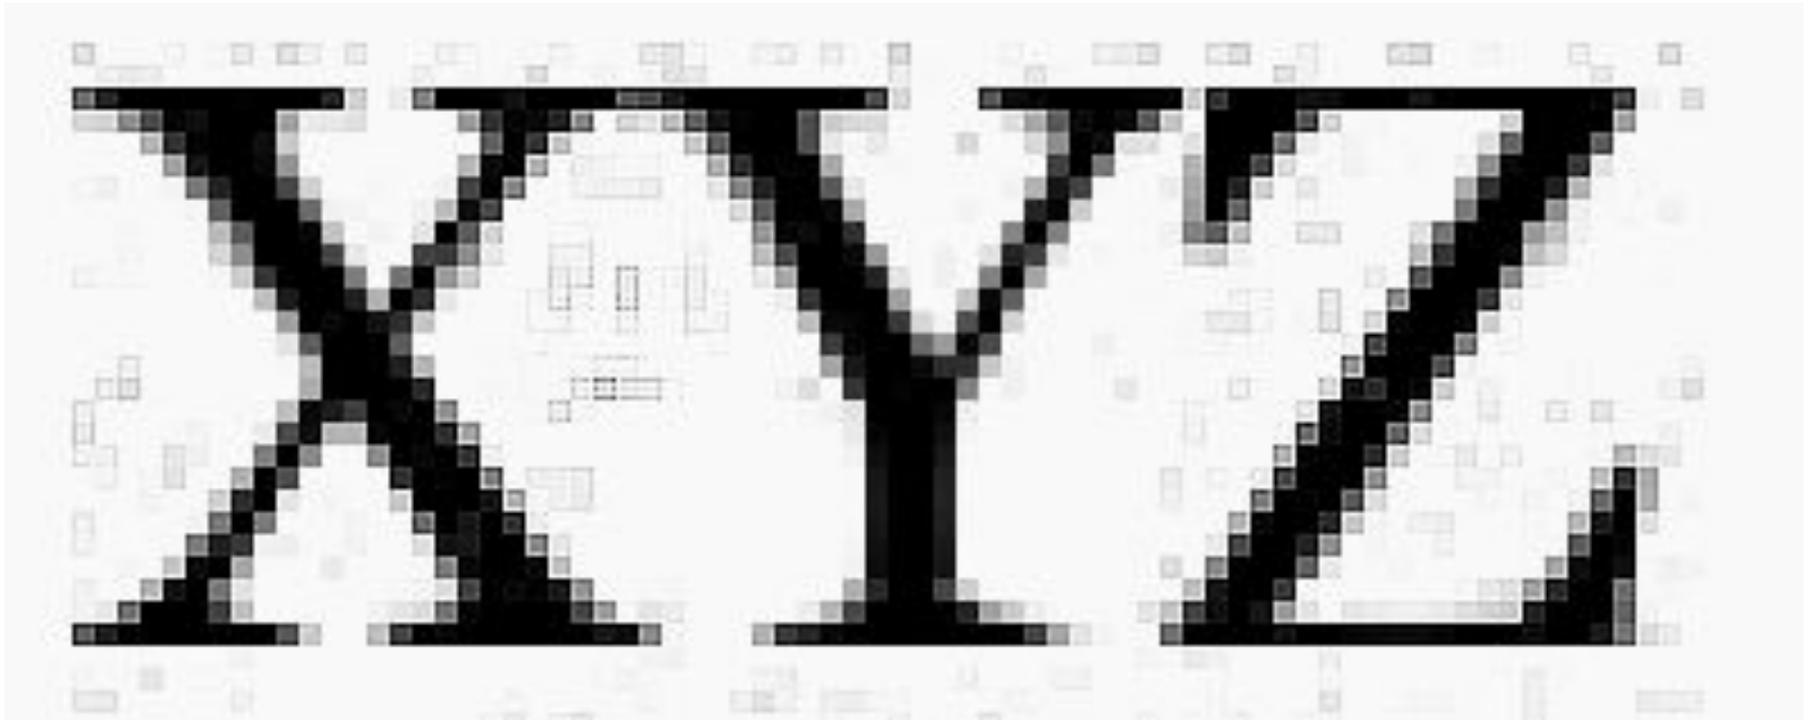
# Крупный масштаб

Исходное изображение



# Крупный масштаб

Сжатие JPEG



# Крупный масштаб

Сжатие Цао-Ена



СПАСИБО)

ВОПРОСЫ