

# Обнаружение сигналов и их классификация с помощью распознавания образов

Бархатов В.А.

Сова приложила ухо к груди Буратино.  
– Пациент скорее мертв, чем жив, – прошептала она и отвернула голову назад на сто восемьдесят градусов.  
Жаба долго мяла влажной лапой Буратино.  
Раздумывая, глядела выпученными глазами сразу в разные стороны. Прошлепала большим ртом:  
– Пациент скорее жив, чем мертв...  
Народный лекарь Богомол сухими, как травинки, руками начал дотрагиваться до Буратино.  
– Одно из двух, – прошелестел он, – или пациент жив, или он умер...  
– Шшшшарлатанство, – сказала Сова, взмахнула мягкими крыльями и улетела на темный чердак.  
А.Толстой «Золотой ключик, или приключения Буратино»

В статье рассматривается концепция распознавания образов, основанная на объединении сигналов, близких к оригиналу. Предложен новый тип нейрона, который реализует элементарную операцию распознавания. Рассматриваются принципы работы некоторых детерминированных нейронных сетей. Приводятся примеры обнаружения и классификации сигналов при наличии искажений, шумов и помех.

В настоящее время задача распознавания несплошностей и принятие решения о годности изделий целиком возложена на дефектоскописта. Существуют характерные особенности формы сигнала от дефектов различного типа. Опытные специалисты часто используют эту информацию для принятия решения о браке - распознают сигналы прибора НК. Если бы удалось отнести дефект к какому-то типу анализируя форму сигнала, то тогда возможно установить индивидуальный уровень браковки для каждого типа дефектов. Например, для дефектов типа трещин устанавливается жесткий критерий браковки (низкая амплитуда сигнала), а для округлых дефектов - поры, шлаковые включения и т.п. - устанавливаются более мягкие нормы браковки. В итоге метод неразрушающего контроля обеспечил бы более высокую достоверность результатов.

Задачу распознавания образов традиционно решают с помощью нейронных сетей. На эту тему опубликовано огромное количество работ, например [1-4]. Автор тоже имеет опыт в создании и применении нейронных сетей [5]. Однако, до сих пор нейросетевые технологии не нашли широкого применения в технических устройствах.

Главная причина в том, что нейронные сети обладают свойством ненадежности. Это отмечают многие исследователи. Для обучения сетей используют различные варианты алгоритмов случайного поиска. Причем обучение проводят на ограниченном количестве позитивных и негативных сигналов. Естественно сеть дает хорошие результаты, если ей предъявляют сигналы, близкие к обучающим выборкам. Если же предъявить сильно отличающийся сигнал, то реакция сети будет непредсказуемой.

Во-вторых, проблема распознавания формулируется расплывчато. Обычно говорят о склонности нейронной сети к распознаванию, т.е. сеть выдает похожий результат, если «показать» ей сигнал, похожий на обучающий. В каких пределах происходит это «распознавание» заранее неизвестно. Качество обучения оценивается только с помощью большого количества тестов.

Существуют некоторые особенности представления сигналов в современных приборах НК. Данные получают в виде одномерных или двумерных дискретных массивов. Например, развертка типа «А» в ультразвуковом дефектоскопе, плотность потемнения на рентгеновском снимке и т.д. Кроме того, результаты дискретны по амплитуде, поскольку используются аналого-цифровые преобразователи.

Размер образа, который нужно обнаружить, как правило во много раз меньше, чем размер массива экспериментальных данных. Следовательно, процесс распознавания должен быть реализован в виде оконной операции, в которой алгоритм анализирует данные в ограниченной выборке из большого массива (в окне) и производится перемещение окна по массиву (сканирование). В результате распознавания должна быть получена информация о положении образа в массиве данных и его амплитуда.

Дискретный сигнал может быть представлен в виде вектора в многомерном пространстве, где каждый отсчет сигнала является проекцией вектора на ось координат. Размерность пространства равна количеству отсчетов в выборке. Будем называть такое пространство информационным, поскольку именно в нем проводится анализ данных.

Информационное пространство Эвклидово  $E^n$ , так как оно получается после дискретизации аналоговых сигналов из пространства Гильберта. Многие операции с сигналами в нем определяются точно также как операции с векторами в обычном трехмерном пространстве. Отличие состоит лишь в том, что информационное пространство имеет очень большую размерность. Ниже приведены правила вычисления различных параметров сигнала, которые понадобятся нам в дальнейшем.

$$W_S = \sum_{i=0}^N S_i^2 \quad \text{- энергия сигнала.} \quad (1)$$

$$A_S = \sqrt{W_S} \quad \text{- амплитуда сигнала (длина вектора).} \quad (2)$$

$$\vec{S} \cdot \vec{F} = \sum_{i=0}^N S_i F_i \quad \text{- свертка сигналов (скалярное произведение векторов).} \quad (3)$$

Уместно задать вопрос - что такое образ и что представляет собой процесс распознавания? На рисунке 1 представлены иллюстрации к обсуждению понятия образа. Пусть  $F_1$  – сигнал, который мы будем распознавать, т.е. образ. Сигналы  $F_2$  и  $F_3$  - это тот же самый образ, но с различной амплитудой, а сигналы  $F_4$ ,  $F_5$ ,  $F_6$  демонстрируют образ  $F_1$  с искажениями и шумами. Очевидно,  $F_1$  распознается во всех представленных сигналах. В информационном пространстве такие сигналы образуют множество, охватывающее исходный образ  $F_1$  (Рис. 1Г).

Иной читатель может поспорить, что скажем в сигнале  $F_6$ , образ  $F_1$  не присутствует. Тогда поступим иначе. Будем добавлять к образу  $F_1$  малые искажения. Присутствует ли  $F_1$  в получившемся сигнале? Конечно - да. А если добавить искажения? Образ  $F_1$  вроде бы распознается. А если еще исказить сигнал? Теперь уже точно образ  $F_1$  не распознается в нем.

Как распознается образ? Мы анализируем, насколько близок исследуемый сигнал к ожидаемому и находим отличия между ними. Кроме того, мы устанавливаем интуитивную границу отличий. Если разница между образом и исследуемым сигналом слишком большая, говорим, что образ не распознается. А если различия допустимы, ассоциируем исследуемый сигнал с образом, фактически приравниваем их друг к другу, отбрасывая различия.

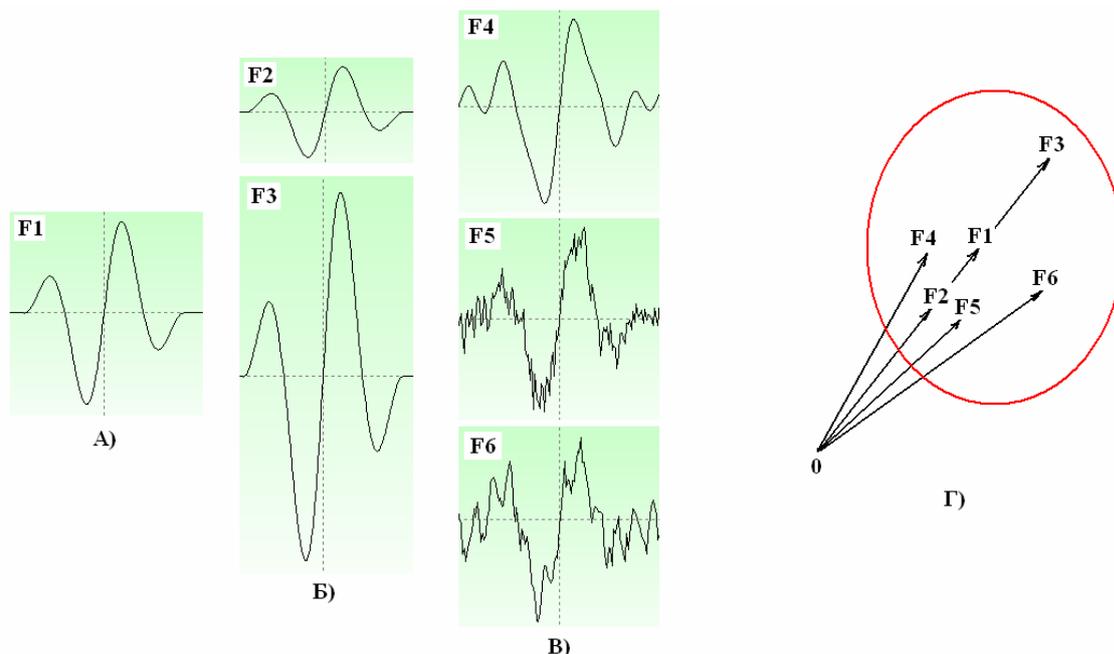


Рис.1 Иллюстрации к определению понятия «образ».

- А) Ожидаемый сигнал – образ.
- Б) Сигналы с различной амплитудой.
- В) Примеры сигнала с искажениями.
- Г) Множество сигналов в информационном пространстве, ассоциированных с образом.

Дадим теперь определение образа. Образ в информационном пространстве – это некоторый сигнал, вокруг которого сформировано плотное и односвязное множество, причем все сигналы множества ассоциируются с ним. Образ формируется путем обобщения всех сигналов, близких к нему.

Отметим, что в данной постановке термины «образ» и «обобщение» трактуются сильно упрощенно, как прямая ассоциация сигналов и как объединение сигналов во множество.

При таком определении образа проблема распознавания решается просто. Если исследуемый сигнал попадает в образ (в его множество), то говорим, что он обнаружен, если нет – это чужой образ.

Решим следующую задачу. Пусть имеется некоторый сигнал  $S$ . Определим, присутствует ли в нем образ  $F$ , и какова его амплитуда. Будем вычитать сигнал  $F$  из  $S$  с некоторой амплитудой  $A$  и найдем энергию остатка  $W$ . Очевидно, при полном вычитании оставшаяся энергия минимальна.

$$\sum_{i=0}^N (S_i - AF_i)^2 = W \rightarrow \min \quad (4)$$

Найдем амплитуду образа. Это вариационная задача. В точке минимума энергии частная производная по амплитуде равна нулю

$$\frac{\delta W}{dA} = 0. \quad (5)$$

Выполним дифференцирование и после простых преобразований получим

$$A = \frac{1}{W_F} \sum_{i=0}^N S_i F_i, \quad (6)$$

$$W_F = \sum_{i=0}^N F_i^2 . \quad (7)$$

Здесь  $W_F$  – энергия образа. Видно, что амплитуда сигнала  $F$ , присутствующего в  $S$ , вычисляется как свертка этих сигналов. Амплитуда является безразмерной величиной и представляет собой масштабный фактор присутствия образа  $F$  в сигнале  $S$ . В частности отметим, что операция обнаружения некоторого сигнала с помощью свертки (6) хорошо известна в технике обработки сигналов под названием оптимальный корреляционный фильтр [6].

Теперь необходимо установить границу множества сигналов, принадлежащих образу, и определить правило принятия решения «свой-чужой».

Вначале найдем энергию входного сигнала (8) и его амплитуду (9). В выражении (9) вычисляется относительная амплитуда входного сигнала, причем за единицу принята амплитуда образа  $F$ . Это нужно для дальнейшего сравнения амплитуд  $A$  и  $A_S$ .

$$W_S = \sum_{i=0}^N S_i^2 . \quad (8)$$

$$A_S = \sqrt{\frac{W_S}{W_F}} . \quad (9)$$

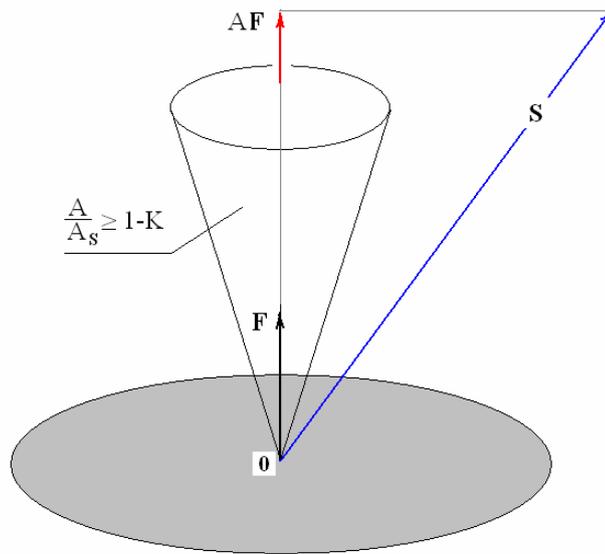


Рис.2. Условное графическое представление операции распознавания.  
Границы обобщения сигналов образа.

Условное графическое представление операции распознавания показано на Рис.2. Как ранее было отмечено, при распознавании нужно определить амплитуду образа. Если же принимается решение, что нет образа, в качестве отрицательного результата будем анализировать амплитуду входного сигнала. Установим, что информация выводится в данных YES и NO. Алгоритм принятия решения выглядит так

$$\frac{A}{A_S} \geq (1 - K) \begin{cases} \text{True} : \text{YES} = A, \text{NO} = 0 \\ \text{False} : \text{YES} = 0, \text{NO} = A_S \end{cases} . \quad (10)$$

Условие в выражении (10) определяет границу в информационном пространстве в виде многомерного конуса (Рис.2). Множество сигналов, расположенных внутри конуса обобщается в образ, а сам сигнал  $F$  является осью симметрии конуса.

Если входной сигнал попадает во внутренне пространство конуса, условие (10) выполняется (True), на выход YES передается амплитуда образа. В противном случае (False) на выходе NO устанавливается амплитуда входного сигнала.

Здесь,  $K$  – коэффициент обобщения. Он может принимать значения в интервале  $[0,1]$ . Если  $K = 0$ , обобщения отсутствуют. Малейшие отклонения входного сигнала от образа  $F$  приводят к выдаче отрицательного результата  $NO = A_S$ .

Другая крайность,  $K = 1$  – максимальное обобщение. Конус границ образа разворачивается в плоскость, которая делит все информационное пространство пополам. На основе численных экспериментов получено, что оптимальный коэффициент обобщения находится в пределах  $0,01-0,4$ .

Данный подход отражает простой факт, что чем больше амплитуда образа, тем больше могут быть допустимые искажения.

В итоге, процесс распознавания содержит вычисления по формулам (6-10). Устройство или алгоритм, реализующей процедуру распознавания, по традиции назовем нейроном.

Автором проведено исследование эффективности работы нейронов-распознавателей и сетей, построенных на их основе. Для этой цели создано программное обеспечение, которое позволяет генерировать тест-сигналы, формировать нейроны и нейронные сети, а также анализировать результаты распознавания. В программах используется представление сигналов во времени, хотя это не принципиально. В тестах данной статьи везде установлена частота дискретизации 100МГц.

Посмотрим, как работает нейрон - Рис.3. В качестве примера выбран образ высокочастотного сигнала, близкого к эхосигналу ультразвукового дефектоскопа. Частота заполнения 5 МГц. Количество отсчетов сигнала в окне 120, коэффициент обобщения 0,25. На вход нейрона подается массив данных, содержащий тот же самый образ (Рис.3А).

Внутренние сигналы нейрона, полученные в процессе сканирования окна, показаны на Рис. 3Б. Корреляционная характеристика (амплитуда образа) красного цвета и амплитуда входного сигнала синего цвета. Видно, что условие (10) выполняется только вблизи пика корреляционной характеристики. Поэтому на выходе нейрона YES формируется короткий положительный импульс (Рис. 3В). В данном случае нейрон производит выделение своего образа, из таких же сигналов, но представленных со сдвигом в окне.

Множество сигналов нейрона включает в себя суммы образа с любым произвольным сигналом, если конечно их общая амплитуда не превышает заданной границы. Кроме того, множество содержит сигналы, похожие на образ. В примере Рис.3, при коэффициенте обобщения 0,25, нейрон выдает положительную реакцию на сигналы с частотой модуляции 4,3-5,6МГц, а также при изменении фазы модулирующего сигнала  $\pm 40$  градусов.

Обратите внимание, что все выходные сигналы (Рис. 3Б, 3В) приведены к нулевому отсчету окна (к началу окна). Поэтому они расположены перед исследуемым сигналом. Это сделано намеренно здесь и во всех тестах данной работы, чтобы можно было показать на одном графике входной сигнал и реакцию устройства распознавания.

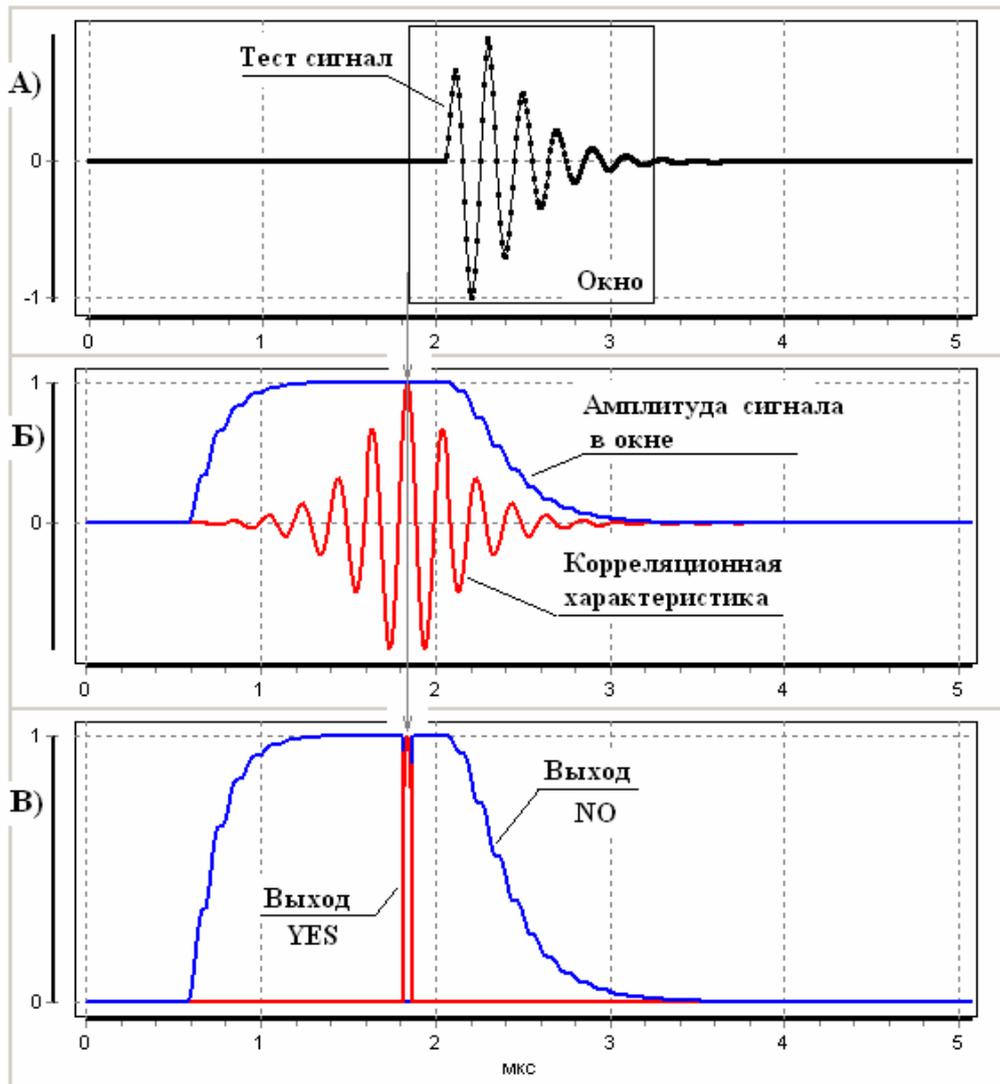


Рис.3. Принцип работы нейрона.  
 А) Входной сигнал.  
 Б) Корреляционная характеристика.  
 В) Сигналы на выходах нейрона YES и NO.

Способность нейрона находить сигнал в шумах и помехах демонстрирует Рис.4. Здесь использован образ предыдущего теста Рис.3А. Обнаружение полезного сигнала при высоком уровне помех связано с тем, что установлен довольно большой коэффициент обобщения ( $K=0,25$ ). Причем образ надежно выявляется при многократных тестах с использованием случайных сигналов. Дальнейшее увеличение уровня помех дает отрицательный результат распознавания, сигнал на выходе нейрона YES=0.

Если увеличить коэффициент обобщения, например до 0,5, будут наблюдаться ложные акты распознавания. Это и понятно, множество сигналов нейрона стало слишком большим и в него теперь попадают сигналы сильно отличающиеся от образа. С другой стороны, если уменьшить коэффициент обобщения, скажем до 0,1, надежное распознавание будет производиться при меньшем уровне помех.

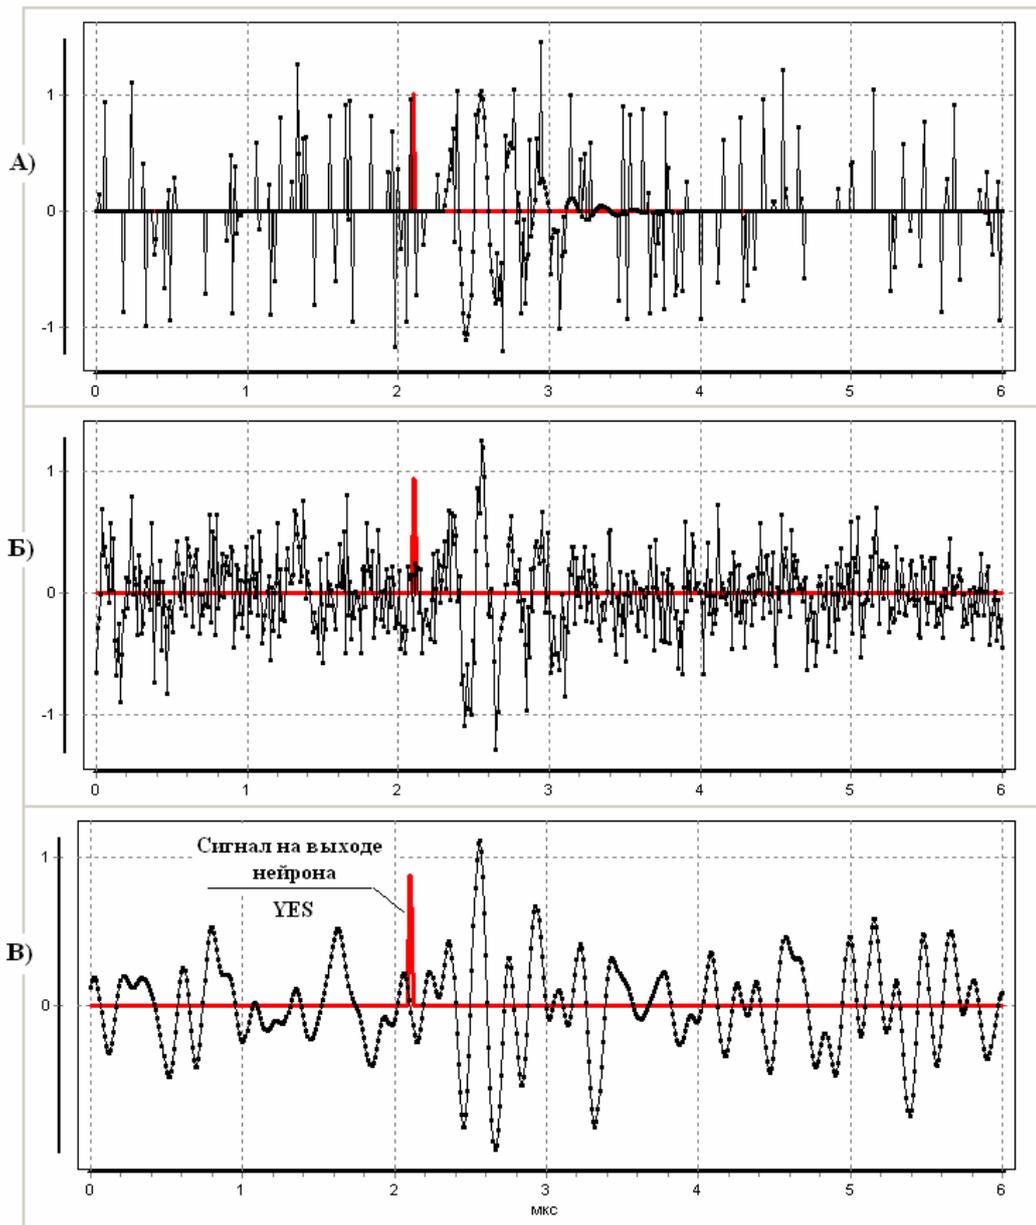


Рис.4. Обнаружение сигнала вблизи границ распознавания в различных ситуациях.

Реакция нейрона показана на графике красного цвета.

Коэффициент обобщения нейрона  $K=0,25$ .

А) Импульсные помехи.

Б) Белый шум.

В) Полосовой шум в диапазоне частот 1-7 МГц.

Предлагаемый нейрон может использоваться для поиска графических образов. В данном случае образ и анализируемое изображение представлены двумерными массивами яркости. Сканирование проводится по двум координатам. Алгоритм принятия решения такой же (10). Автором создана небольшая программа, которая реализует операции распознавания образов на изображениях.

На рис.5. показаны примеры распознавания символов. Изображения фрагментов текста получены с помощью USB видекамеры. Здесь решается задача обнаружения темного символа на светлом фоне.

Видеоданные имеют цветовую кодировку R,G,B (красный, зеленый, синий). Символы должны распознаваться независимо от их цвета. Поэтому изображения предварительно переводились в градации серого. Использовалось известное соотношение

$$S = 0,3R + 0,59G + 0,11B , \quad (11)$$

которое отражает цветовое восприятие человека. Дополнительно диапазон яркости нормировался в пределах [0,1]. Причем значение  $S=0$  соответствует белому цвету, а  $S=1$  - черному.

Программа обеспечивает выполнение следующих действий. Вначале выделяется графический образ. Устанавливается коэффициент обобщения. Затем проводится сканирование изображения. При обнаружении символа ( $YES>0$ ) программа выводит на изображение «галочку» красного цвета (Рис.5).

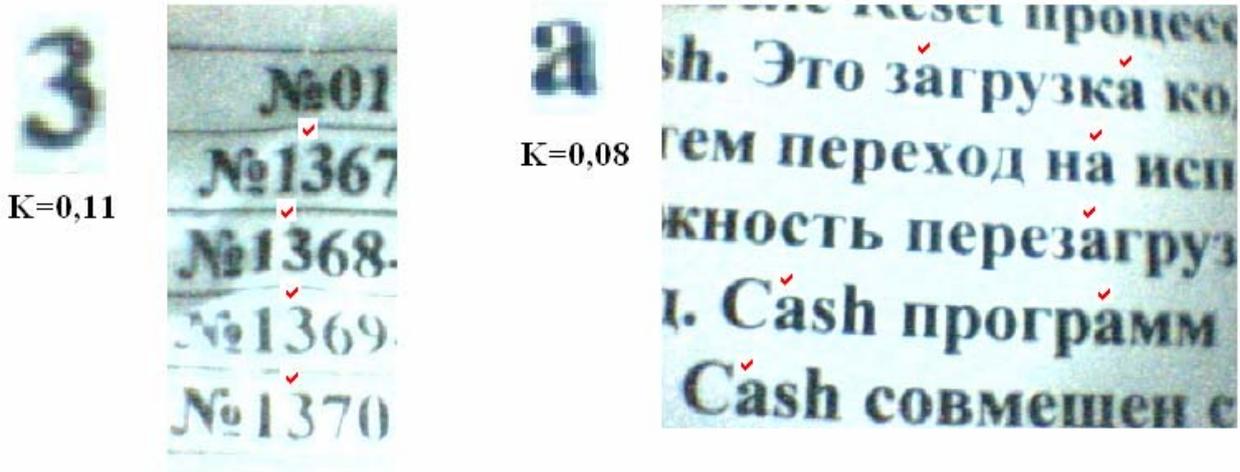


Рис.5. Примеры распознавания символов на изображениях. Образы показаны с увеличением 2,5:1.

В литературе, посвященной проблеме распознавания образов, используется понятие класс образов или класс сигналов. Естественно, разные авторы трактуют термин «класс» по собственному усмотрению. В контексте данной работы определим класс как множество сигналов от объектов определенного типа, например эхосигналы от угловых отражателей, магнитное поле рассеяния трещин и т.п. Класс состоит из образов. Само понятие класс необходимо для того, чтобы сопоставить конкретный сигнал аппаратуры неразрушающего контроля с типом объекта (дефекта).

Очевидно, все сигналы (образы) класса, формируемые однотипными объектами, должны отличаться от сигналов получаемых от других объектов. В противном случае идентификация невозможна. В конечном итоге возможность классификации дефектов определяется параметрами прибора неразрушающего контроля.

Предъявим еще одно требование к сигналам класса – они должны создавать плотное множество. Интуитивно это требование понятно, однако его доказательство требует рассмотрения физических основ формирования сигнала в методе НК – это выходит за рамки данной статьи.

Плотное множество сигналов класса не обязательно односвязное, оно может состоять из нескольких изолированных подмножеств.

Предложенный нейрон выделяет плотное множество сигналов вблизи образца, т.е. является элементарным устройством распознавания. Из таких нейронов можно создать сеть, которая будет выполнять более сложные алгоритмы распознавания.

Рассмотрим однослойную нейронную сеть Рис.6. Здесь нейроны #1,#2...#m содержат различные экземпляры образов класса. Причем используются нормированные образы, их энергия равна единице. Каждый нейрон имеет свой коэффициент обобщения.

Теперь необходимо установить правила объединения множеств. На выходе класса YES должен формироваться сигнал, если хотя бы один из нейронов произвел распознавание. Значит, выходы нейронов YES нужно объединить с помощью некоторой операции «ИЛИ».

Воспользуемся приемом из теории нечеткой логики. Операция «ИЛИ» над набором нечетких сигналов может быть реализована как определение максимального сигнала и передача его на выход. Действительно, если какой-либо нейрон выдаст сигнал  $YES > 0$ , он будет передаваться на выход YES класса. В информационном пространстве это соответствует объединению множеств сигналов нейронов. Кроме того, имеется дополнительный выход Num, на который выводится номер нейрона с максимальным сигналом YES. Выход Num используется для анализа работы сети.

Сформируем сигнал класса NO с помощью операции нечеткого «И». Это операция нахождения минимального сигнала. Сигнал на выходе NO будет только в том случае, когда все нейроны выдадут отрицательный результат.

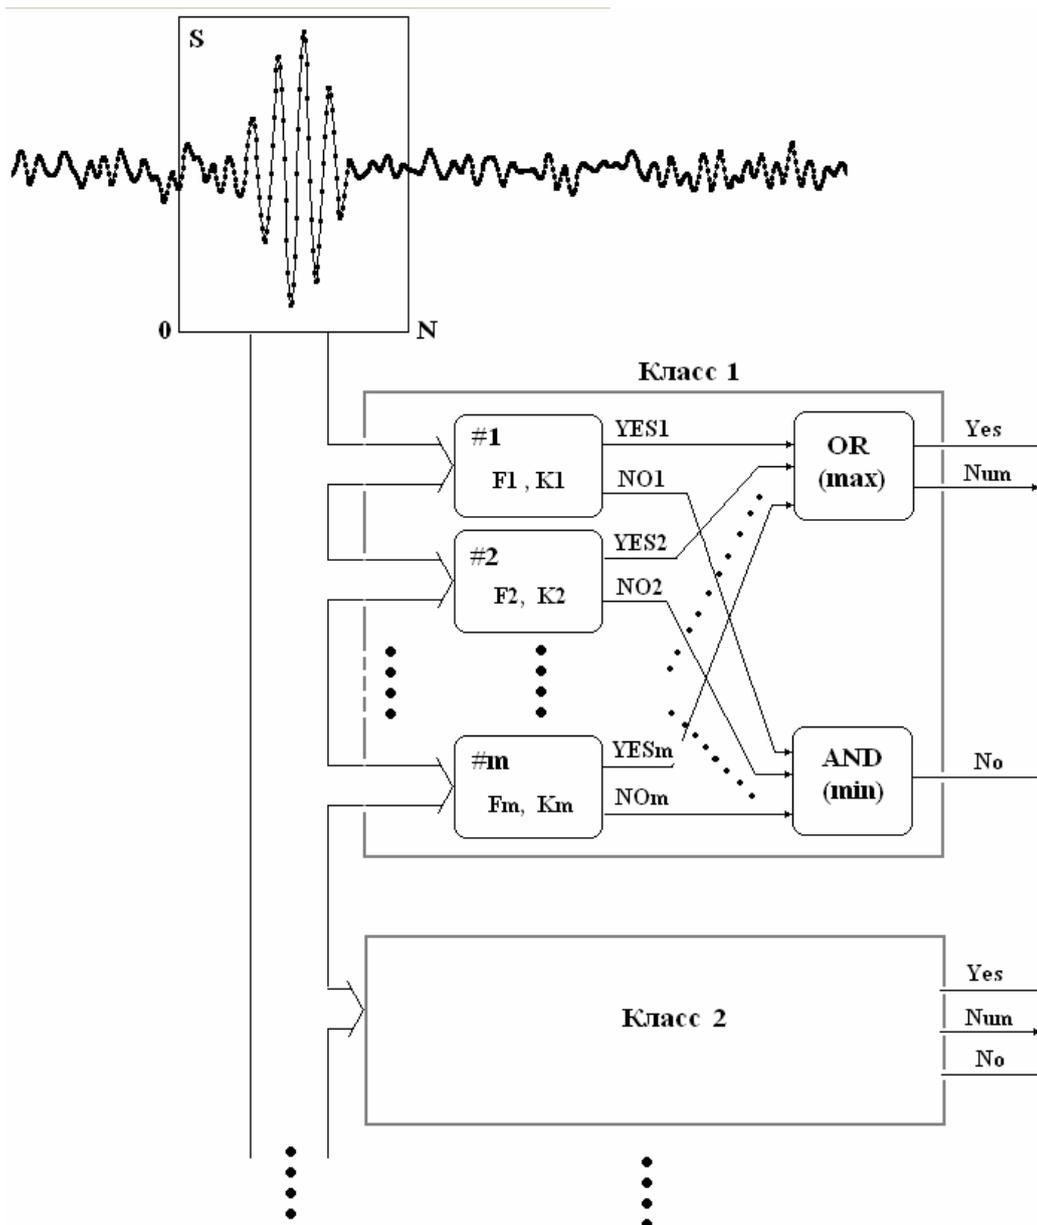


Рис.6. Блок-схема детерминированной нейронной сети, основанной на обобщении библиотеки образов.

Рассмотрим пример распознавания двух классов. Пусть один класс состоит из прямоугольных видеопульсов длительностью 0,5-1 мкс, а второй класс содержит импульсы с Гауссовской характеристикой в том же интервале длительностей (нормальные

видеоимпульсы). В частности длительность нормального импульса определяется на уровне 0,5 от максимума.

Для решения этой задачи используем нейронную сеть Рис.6. В каждом классе установим по 5 нейронов с образами видеоимпульсов. Длительность сигналов установлена от 0,5мкс до 0,9мкс с шагом 0,1мкс.

Коэффициенты обобщения нейронов подбирались экспериментально. С одной стороны множество сигналов нейрона должно охватывать соседний образ. Например, нейрон с прямоугольным импульсом 0,7мкс должен реагировать на такие же импульсы длительностью 0,6 и 0,8мкс. Тогда множество класса будет односвязным. С другой стороны множества классов не должны перекрываться, иначе не будет распознавания. Коэффициенты обобщения нейронов выбирались с учетом данного компромисса. В итоге получено: коэффициент обобщения класса прямоугольных импульсов 0,09, а для нормальных импульсов - 0,07.

На рисунке 7 показаны результаты тестирования. Видно, что сеть справляется с поставленной задачей в условиях довольно больших искажений и помех.

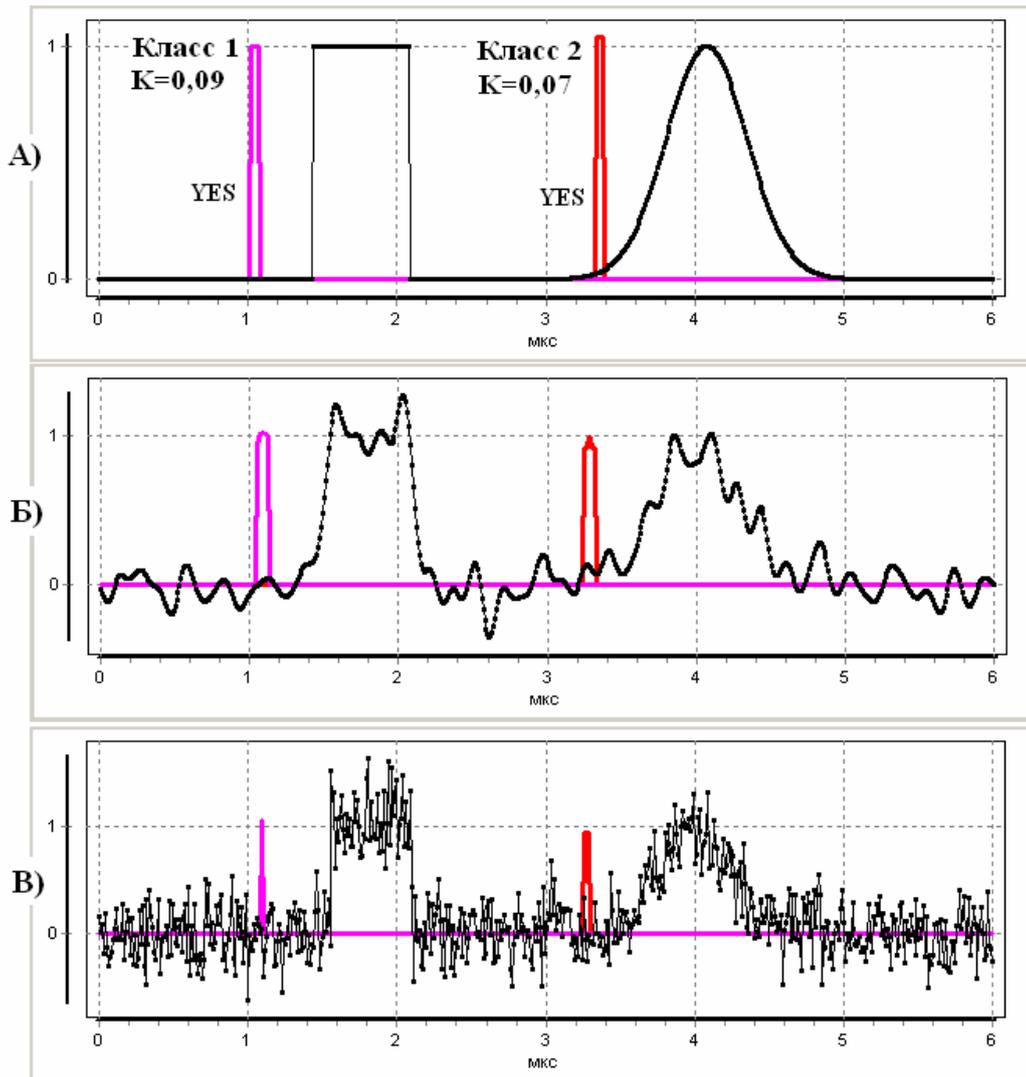


Рис.7. Распознавание классов прямоугольных и нормальных видеоимпульсов.

А) Сигналы длительностью 0,75 мкс

Б) Сигналы длительностью 0,75 мкс. Наложение белого шума с последующей фильтрацией в диапазоне частот 0,05-7 МГц.

В) Длительность сигналов 0,55мкс, наложение белого шума.

Другой пример демонстрирует возможности сети в задаче распознавания букв (Рис.8). Здесь созданы классы изображений букв «У», «Т» и «А». В процессе сканирования тестового изображения (Рис.8 справа) обнаруженные символы помечаются индивидуальными

пиктограммами. В этом примере, для буквы «Т» и буквы «А» множество сигналов класса состоит из набора изолированных множеств нейронов.

Класс 1,  $K=0,11$

УуУуУу

Класс 2,  $K=0,09$

ТТТ

Класс 3,  $K=0,09$

а а а

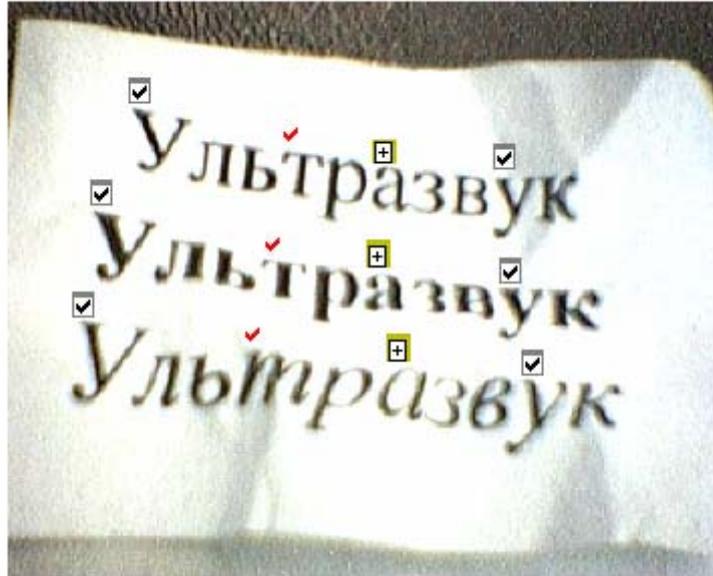


Рис.8. Распознавание символов в тесте с помощью детерминированной нейронной сети. Масштабы образов и тестового изображения совпадают.

В сущности, сеть Рис.6 производит распознавание сигналов на основе обобщения библиотеки образов. В отличие от типичных нейронных сетей предлагаемая сеть полностью адекватна. В ней четко определено множество сигналов класса. За каждую область сигналов отвечает свой нейрон.

Сеть легко модифицируется. В нее можно добавлять нейроны и удалять их. При этом не разрушается общая способность к распознаванию.

Сеть позволяет выявить конфликты между классами и выяснить, какие нейроны из разных классов имеют общие области сигналов. Данная информация используется для целенаправленного редактирования сети. Проводят корректировку коэффициентов обобщения, удаление или добавление нейронов для более точного разграничения классов.

Все указанные свойства сети делают ее удобной в эксплуатации.

Есть и недостатки. Если в выше приведенном примере (Рис.7) предложить сети распознать сигнал, состоящий из суммы прямоугольного и нормального импульсов, то сеть не выдает положительного результата. Каждый класс обнаружит, что в сигнале присутствует нужный образ, но амплитуда входного сигнала сильно отличается от амплитуды образа, поэтому оба класса выдадут отрицательный результат «NO». Для того, чтобы сеть распознавала суммы сигналов, нужно организовать третий класс, в котором представлены образы сумм.

Второй недостаток связан с тем, что для описания класса может потребоваться большое количество образов. Их трудно редактировать с помощью тестов. Кроме того, сеть будет медленно работать на компьютере.

Видимо детерминированная нейронная сеть Рис.6 может найти применение в достаточно простых задачах распознавания.

Рассмотрим другой подход формирования сигналов класса. Предположим, что любой сигнал  $F$ , принадлежащий классу, можно представить в виде линейной комбинации некоторых простых сигналов  $X^k$  – назовем их деталями.

$$F_i = \sum_{k=1}^L A^k X_i^k \quad (12)$$

Определим, какой сигнал из класса  $\mathbf{F}$  содержится в исследуемом сигнале  $\mathbf{S}$ . Попытаемся вычитать различные образцы  $\mathbf{F}$  из входного сигнала  $\mathbf{S}$  и оценим энергию остатка  $W$ . Будем считать, что в сигнале  $\mathbf{S}$  присутствует такой экземпляр  $\mathbf{F}$ , который минимизирует энергию

$$\sum_{i=0}^N \left( S_i - \sum_{k=1}^L A^k X_i^k \right)^2 = W \rightarrow \min \quad (13)$$

В точке минимума энергии все частные производные по амплитудам деталей равны нулю.

$$\frac{\delta W}{dA^k} = 0, k = [1, L]. \quad (14)$$

Данная задача сводится к системе линейных уравнений

$$\sum_{k=1}^L A^k N^{jk} = P^j, j = [1, L], \quad (15)$$

Здесь введены обозначения

$$N^{jk} = \sum_{i=0}^N X_i^j X_i^k - \text{матрица сверток сигналов деталей.} \quad (16)$$

$$P^j = \sum_{i=0}^N S_i X_i^j - \text{свертки входного сигнала с сигналами деталей.} \quad (17)$$

Система уравнений (15) имеет единственное решение, если детали  $\mathbf{X}^k$  линейно независимы, т.е. ни один из сигналов  $\mathbf{X}^k$  нельзя выразить в виде линейной комбинации других деталей. Это единственное требование к разложению сигналов класса на детали.

Итак, решив систему уравнений (15), находим амплитуды деталей  $A^k$ . Определим теперь энергию образа  $\mathbf{F}$ . Очевидно

$$W_F = \sum_{i=0}^N \left( \sum_{k=0}^L A^k X_i^k \right)^2. \quad (18)$$

Найдем амплитуды сигналов

$$A_F = \sqrt{W_F}, A_S = \sqrt{W_S}. \quad (19)$$

Далее нужно разработать алгоритм распознавания. Во-первых, введем ограничение на различие амплитуд  $A_F$  и  $A_S$ , как это было сделано у простого нейрона. Во-вторых, класс может состоять не из всех сигналов типа (12). Есть возможность выделить классы в подпространстве деталей. Тогда границы множества класса следует проверять по соотношению амплитуд деталей. Обозначим эту проверку в общем виде как логическую функцию  $Class(A^k)$  и запишем

$$\left( \frac{A_F}{A_S} \geq (1 - K) \right) \text{and} (Class(A^k) = True) \begin{cases} \text{True : YES} = A_F, \text{ NO} = 0 \\ \text{False : YES} = 0, \text{ NO} = A_S \end{cases} \quad (20)$$

Процесс распознавания состоит в следующем. Вначале из входного сигнала  $\mathbf{S}$  выделяется образ  $\mathbf{F}$ , который находится в подпространстве деталей  $\mathbf{X}^k$ . Сигнал  $\mathbf{F}$  представлен в виде набора амплитуд деталей  $A^k$ . Затем проводится анализ - формула (20). Входной сигнал  $\mathbf{S}$  должен попадать во множество образа  $\mathbf{F}$  и, дополнительно, образ  $\mathbf{F}$  должен принадлежать

классу. Тогда образ обнаружен  $YES=A_F$ . В противном случае выдается отрицательный результат  $NO=A_S$ .

Примеры распознавания класса сигналов, состоящих из деталей, представлены на рисунках 9-11. В данном случае класс образуется из двух деталей - прямоугольный видеоимпульс  $X1$  и радиоимпульс  $X2$ . Здесь установлены ограничения амплитуд деталей  $A1 > 0$  и  $A2 > 0$ , иначе говоря, образы класса не содержат инвертированных сигналов  $X1$  и  $X2$ . Коэффициент обобщения равен 0,1. Тесты на рисунках 10,11 дают наглядное представление о свойствах классификатора, основанного на анализе деталей.

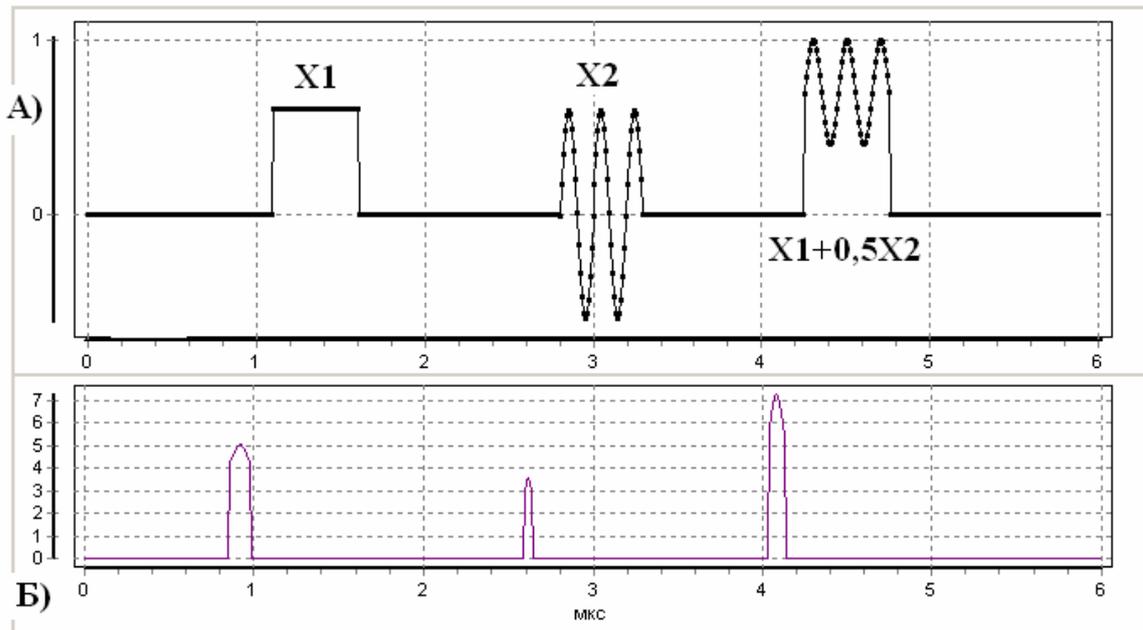


Рис.9. Распознавание класса сигналов, состоящих из суммы прямоугольного видеоимпульса и радиоимпульса.

А) Образцы сигналов. Б) Выход YES.

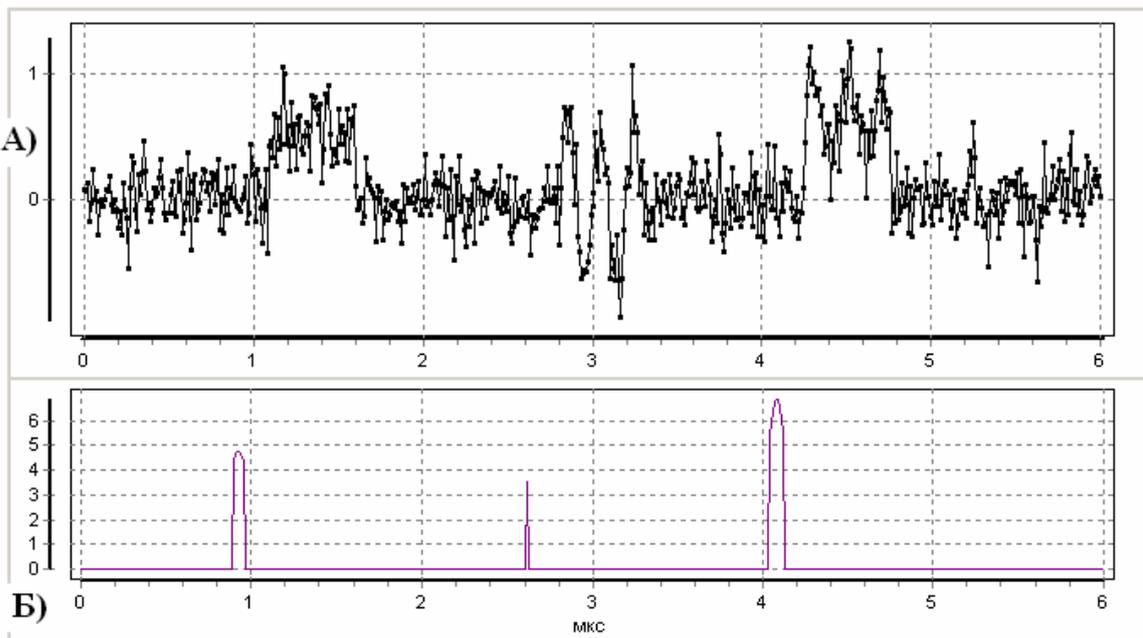


Рис.10. Тест с наложением белого шума.

А) Входной сигнал. Б) Выход YES.

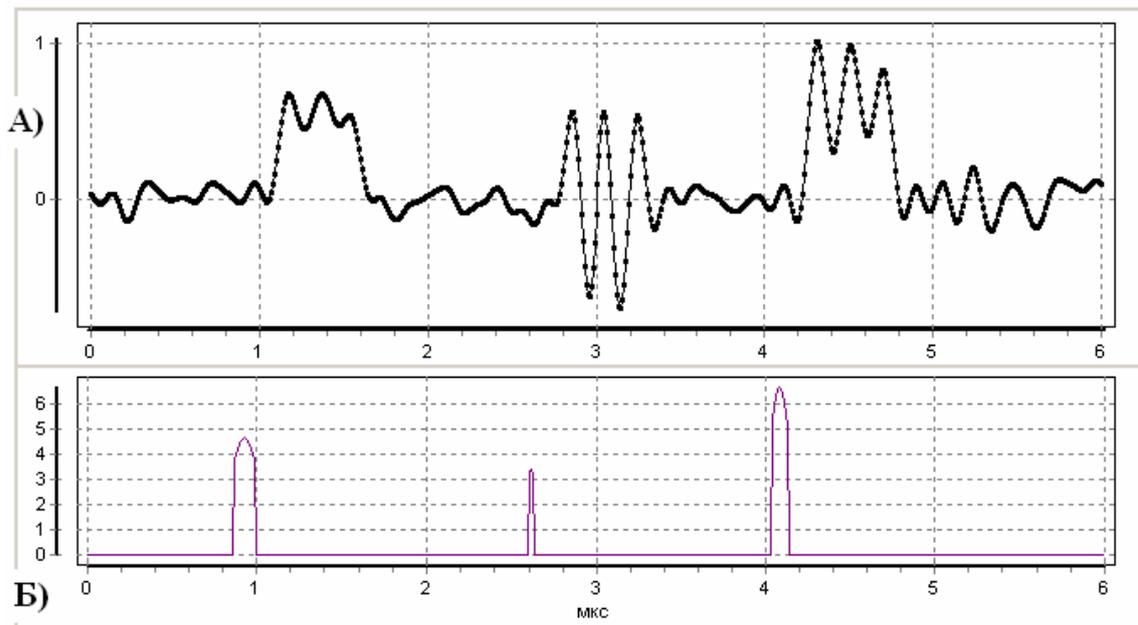


Рис.11. Тест с наложением белого шума и последующей фильтрацией в диапазоне частот 0,5-6 МГц.  
А) Входной сигнал. Б) Выход YES.

Подведем итоги. Главная идея состоит в самом понимании образа как сигнала с охватывающим его множеством. На этом построена концепция устройств распознавания. Присутствие ожидаемого образа в исследуемом сигнале определяется посредством корреляции, а распознавание осуществляется путем проверки, попадает ли исследуемый сигнал во множество образа. Конечно, существует еще много вариантов ограничения множества образа и разграничения множеств нескольких образов или классов.

В предлагаемом подходе в отличие от нейронных сетей нет процедур обучения основанных на алгоритмах случайного поиска и, следовательно, нет непредсказуемых реакций устройства распознавания. В данном случае процесс обучения заменяется конструированием.

По мнению автора наиболее перспективным является алгоритм распознавания, основанный на анализе деталей. Рациональное разложение класса сигналов на детали позволит создать сложные и многогранные устройства распознавания.

### Список литературы

1. Ф.Уоссермен, Нейрокомпьютерная техника, М.,Мир, 1992.
2. Artificial Neural Networks: Concepts and Theory, IEEE Computer Society Press, 1992.
3. Наука и обучение. Информация по нейронным сетям. URL: <http://www.91.ru/Education/>
4. Осовский С. Нейронные сети для обработки информации. /Пер. с польского – М: Финансы и статистика, 2004. – 344с.
5. В. А. Бархатов Распознавание дефектов с помощью искусственной нейронной сети специального типа. - Дефектоскопия, №2, 2006, с. 28-39.
6. Макс Ж. Методы и техника обработки сигналов при физических измерениях: В 2-х томах, Пер. с франц.- М.: Мир 1983.