

П.В.Бабаян, А.Б.Фельдман

РАСПОЗНАВАНИЕ ОБЪЕКТОВ НА ИЗОБРАЖЕНИЯХ ПРИ НАБЛЮДЕНИИ ИЗ КОСМОСА

Рассматриваются четыре алгоритма распознавания движущихся объектов на изображениях, полученных при наблюдении поверхности Земли из космоса. В представленных алгоритмах использован математический аппарат преобразования главных компонент для выделения информативных признаков и получения инвариантов бинарных изображений объектов относительно их поворота и смещения в кадре. Приведенные алгоритмы ориентированы на работу в реальном масштабе времени.

Ключевые слова: изображение, распознавание, классификация, нормализация, преобразование главных компонент.

ВВЕДЕНИЕ. Одной из актуальных задач, возникающих при обработке изображений, полученных с помощью космических средств наблюдения, является задача распознавания объектов. Под распознаванием [1, 2] понимается отнесение объекта к одному из заранее predetermined классов. Примерами характерных объектов могут служить самолёты, вертолёты, автотранспорт, суда, космические аппараты. Особый интерес представляет проблема создания систем распознавания объектов, работающих в реальном масштабе времени. Разработка таких систем может быть полезна для решения таких задач, как картография, поиск и спасение в чрезвычайных ситуациях, контроль наземного и воздушного движения, предотвращение аварийных ситуаций на транспорте.

Современная теория распознавания является хорошо развитой и сложившейся областью знания, оперирующей различными методологиями. Анализ источников [2-8] позволяет выделить четыре основных подхода к распознаванию.

Детерминированный подход предполагает, что в любой точке пространства признаков, используемых для распознавания, с ненулевой априорной вероятностью могут появляться реализации только одного класса объектов. В таком случае достаточно найти уравнения границ, разделяющих в пространстве образов области принадлежащие тому или иному классу [2, 3]. Если по каким-либо причинам невозможно найти эти границы, то классификацию можно осуществить путем оценки расстояния в пространстве признаков между распознаваемым образом и классами изображений. Следует отметить, что распознавание с использованием данного подхода обладает наглядной геометрической интерпретацией и для его реализации не требуется никаких дополнительных данных, кроме эталонов

изображений каждого класса. Вычислительные затраты для данного метода сравнительно невелики, что делает его применение оправданным в бортовых системах обработки информации.

Статистический подход, в отличие от детерминированного, предполагает, что в одной точке пространства образов с отличной от нуля априорной вероятностью могут наблюдаться реализации, относящиеся к различным классам. Это может быть связано с неизбежными случайными ошибками, присутствующими в детерминированных признаках, или использованием признаков, принципиально являющихся случайными величинами [4, 6]. Для данного подхода обычно считаются известными функции распределения вероятности, связанные с классами образов. Однако зачастую эти функции неизвестны и должны оцениваться по множеству обучающих образов. Если можно задаться каким-либо классом функций распределения вероятностей, например нормальным распределением, то задача оценки статистических свойств распознаваемых классов сводится к оценке параметров выбранного распределения (дисперсий, математического ожидания и т.п.). В таком случае речь идет о параметрических методах. Непараметрические методы должны оценивать не только параметры, но и общий вид функций распределения [2-4]. Непараметрические методы могут обеспечить лучшее качество распознавания, но требуют построения на порядок более сложных схем обучения и классификации, что критично применительно к бортовым системам распознавания.

Структурно-лингвистический (синтаксический) подход основан на описании геометрической структуры класса с помощью специализированного формального языка, алфа-

вит которого составляют производственные элементы и структуры, а также операции и композиции над ними, задаваемые грамматикой языка [7]. Такой подход предполагает, что структура и характер связей между элементами всех подлежащих распознаванию объектов подчиняются определенным, заранее известным закономерностям. Очевидно, что данная методика практически не подходит для реализации в бортовых информационных системах реального времени, т.к. приводит к сложной и операционно-емкой программной реализации.

Нейрокомпьютерный подход является мощным инструментом для решения задач распознавания образов. В основе данного подхода лежит математическая модель абстрактного нейрона. Достоинства данного метода заключаются в возможности нелинейного разделения пространства образов и большой скорости вычислений, которая достигается благодаря параллельной организации структуры искусственной нейронной сети [8]. К недостаткам можно отнести то, что нейрокомпьютеры, как правило, являются специализированными системами, адаптированными для решения конкретной задачи. В рамках теории распознавания это означает, что нейронная сеть обучается распознаванию конкретных классов образов. При добавлении новых классов объектов может потребоваться реорганизация структуры нейрокомпьютера или, как минимум, его повторное обучение.

Методы статистического распознавания наиболее часто применяются в задачах дистанционного наблюдения за поверхностью Земли [6] в силу следующих причин:

- при наблюдении из космоса принимаемые изображения могут подвергаться различным случайным искажениям, маскирующим характерное различие между классами объектов. Статистический анализ позволяет учесть эти изменения, потенциально уменьшить их влияние на точность классификации;

- исследуемые классы могут перекрываться в исходном пространстве образов. В таком случае методы статистического распознавания позволяют осуществлять наиболее четкую классификацию.

Задача распознавания образов не сводится только к выбору метода классификации. Так, необходимо решить задачи получения значащей информации о распознаваемых объектах, нормализации относительно заданной группы преобразований, выделения наиболее информативных признаков. Структурная схема процесса распознавания представлена на рисунке 1.

В данной работе в качестве исходной информации используются бинарные изображения

классифицируемых объектов. Известные методы распознавания бинарных изображений можно условно разделить на три класса.

Первый класс методов основан на контурном описании объектов [9-11]. Отметим, что данное описание компактно, требует минимальных вычислительных затрат при выполнении аналитических преобразований. На основе контурного описания могут быть получены признаки, инвариантные к преобразованиям поворота, сдвига и масштабирования [12]. Отказ от использования методов контурного анализа в данной работе связан со спецификой процесса получения бинарных изображений объектов. Последние получают посредством сегментации на этапе выделения движения, и, учитывая сложность данной задачи, не следует ожидать, что полученный образ будет обладать характеристиками, необходимыми для получения устойчивого контура. Кроме того, процесс прослеживания контура является последовательным процессом, и ошибка, сделанная уже на первых шагах, может привести к непредсказуемым результатам [2].

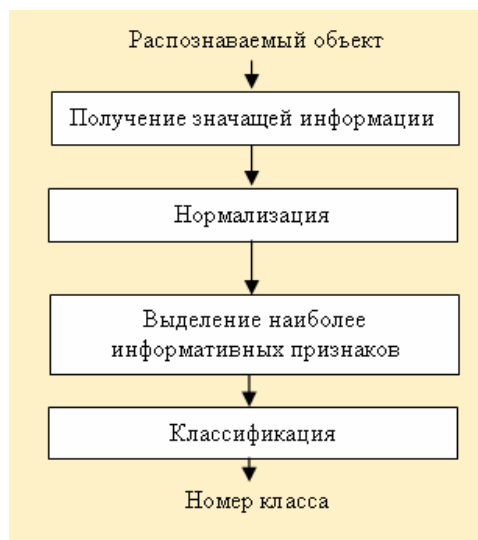


Рисунок 1 – Структурная схема процесса распознавания образов

Второй класс методов основан на «скелетизации» бинарных изображений, которая осуществляется либо с помощью аппарата математической морфологии [13], либо на основе геометрических построений [14]. Оба эти способа требуют, как известно, больших вычислительных затрат, и, учитывая характер наблюдаемых изображений, можно предполагать, что соответствующие им графы («скелеты») будут недостаточно разветвлены, что не позволит решить задачу классификации.

В силу указанных причин в данной работе решено было отказаться от специализированных видов описания бинарных изображений. Рассматриваемые ниже методы можно отнести к третьему классу методов – сопоставлению бинарных изображений [5]. Сущность методов данного класса состоит в том, что в качестве исходных данных для распознавания используются непосредственно матрицы бинарных изображений, т.е. признаками являются пространственные (геометрические) характеристики представленных на них объектов.

В настоящей работе будут рассмотрены четыре алгоритма классификации движущихся объектов в последовательности космических изображений, из которых три основаны на принципе минимума расстояния (детерминированный подход) и один – на основе оценки максимального правдоподобия (статистический подход).

ПОСТАНОВКА ЗАДАЧИ

Пусть имеются бинарные изображения различных классов движущихся объектов. Данные изображения могут быть получены одним из известных методов выделения движущихся объектов в последовательности изображений [15], полученных при наблюдении из космоса. Необходимо отнести объекты, найденные на этапе анализа движения, к одному из M предопределенных классов, каждый из которых представлен своими эталонными изображениями. Будем считать, что i -й класс объектов в пространстве образов подчиняется многомерному нормальному распределению с математическим ожиданием Ψ_i и матрицей ковариации C_i . Также будем полагать, что наблюдаемые образы объектов получаются из эталонных путем преобразований поворота и смещения. Преобразование поворота может быть описано матрицей преобразования. Например, повороту в плоскости XOY на угол α будет соответствовать матрица преобразования

$$W(\alpha) = \begin{pmatrix} \cos \alpha & -\sin \alpha \\ \sin \alpha & \cos \alpha \end{pmatrix}.$$

Также будем считать искажения, вносимые процессом сегментации в бинарный образ объекта, несущественными в данной задаче.

ПРЕОБРАЗОВАНИЕ ГЛАВНЫХ КОМПОНЕНТ

Математической основой представленных ниже подходов к распознаванию объектов является преобразование главных компонент (ПГК). Остановимся на основных свойствах данного преобразования.

Пусть X есть совокупность M реализаций случайного n -компонентного вектора X , т.е.

$$X = [x_1, x_2, \dots, x_n] = \begin{pmatrix} x_{11} & x_{12} & \dots & x_{1M} \\ x_{21} & x_{22} & \dots & x_{2M} \\ \dots & \dots & \dots & \dots \\ x_{n1} & x_{n2} & \dots & x_{nM} \end{pmatrix}. \quad (1)$$

Преобразованием главных компонент (ПГК) [8, 16, 17] для X называют выражение вида

$$Y = V^T (X - X_0), \quad (2)$$

где $X_0 = E\{X\}$, а V – это собственные векторы ковариационной матрицы

$$C = E\{(X - X_0)(X - X_0)^T\}.$$

Преобразование обладает рядом замечательных свойств.

1. Число собственных векторов матрицы C равно размерности исходного пространства. Ковариационная матрица в новом базисе диагонализуется, а ее собственные значения приобретают смысл дисперсий.
2. Из связи собственных векторов и собственных значений становится очевидным, что наибольшим собственным числам (дисперсиям сигнала) соответствуют собственные вектора, которые в исходном пространстве показывают направления наибольшей варибельности сигнала (главные оси).
3. Уже несколько первых главных компонент содержат большую часть информации о реализациях случайного вектора. Таким образом, отсортировав собственные числа в порядке убывания и выбрав соответствующие им собственные векторы, можно усилить редукцию пространства главных компонент по сравнению с исходным пространством. Максимальная ошибка представления набора данных с помощью главных компонент не превышает суммы отброшенных собственных чисел ковариационной матрицы, т.е.

$$e_{\max}(M) = \sum_{j=k-M}^k \lambda_j. \quad (3)$$

4. Так как система собственных векторов ортогональна и образует базис, то компоненты вектора Y оказываются не коррелированы между собой.

НОРМАЛИЗАЦИЯ БИНАРНЫХ ИЗОБРАЖЕНИЙ ОБЪЕКТОВ С ПОМОЩЬЮ ПГК.

Предположим, что наблюдаемый объект Y получается из некоторого эталонного X , посредством некоторого априори неизвестного преобразования S , принадлежащего группе поворотов, и смещения относительно центра изображения на вектор B , так

что $Y = S\{X\} + B$. Под нормализацией в контексте данной задачи будем понимать отыскание такого преобразования S^* , что

$$S^*\{S\{X\} - B\} = X, \quad \forall X, S, B. \quad (4)$$

Пусть в бинарном изображении размера $n \times m$ изображению объекта соответствуют $N < (n \times m)$ точек. Будем рассматривать эти точки как множество реализаций X случайного вектора $x = [i, j]^T$, где i - номер строки, соответствующей данной точке изображения объекта, j - номер столбца. Выполняя анализ главных компонент, найдем собственные векторы V и собственные числа Λ ковариационной матрицы $C = E\{(X - X_0)(X - X_0)^T\}$. В результате преобразования (2) объект повернется так, чтобы обеспечить статистическую независимость между номерами строк и столбцов пикселей, соответствующих объекту. Очевидно, что в таком случае направления главных осей объекта (собственных векторов), которые зависят только от формы объекта, станут совпадать с осями $i = \text{const}$ и $j = \text{const}$ соответственно. Для того чтобы обеспечить инвариантность изображения объекта к линейным смещениям его положения в кадре и изменению размера, достаточно выполнить совмещение его центра X_0 с геометрическим центром кадра и осуществить нелинейное масштабирование так, чтобы габариты объекта соответствовали размерам кадра. После чего весь кадр можно при необходимости привести к заданному размеру. Это необходимо для обеспечения работы алгоритмов распознавания. Пример получения нормализованного изображения с помощью преобразования (2) представлен на рисунках 2 и 3.



Рисунок 2 – Изображение самолета до нормализации



Рисунок 3 – Изображение самолета после нормализации

КЛАССИФИКАЦИЯ ПО МИНИМУМУ РАССТОЯНИЯ В ИСХОДНОМ ПРОСТРАНСТВЕ ОБРАЗОВ (I).

Пусть имеется обучающая выборка $\{\Gamma\} = \{\Gamma_1, \Gamma_2, \dots, \Gamma_M\}$, состоящая из M изображений объектов каждого из M классов, представленных в виде векторов размерностью $N = (n \times m)$. Будем полагать, что эталонное изображение Γ_i наилучшим образом представляет i -й класс изображений, т.е. оно сколь угодно близко к математическому ожиданию данного класса $\Gamma_i \rightarrow \Psi_i, i = \overline{1, M}$. В исходном N -мерном пространстве образов обычным способом введем евклидову меру расстояния

$$\|d\| = \|a - b\| = \sqrt{(a - b)^T (a - b)}. \quad (5)$$

Теперь, имея возможность оценить близость распознаваемого изображения Γ^* к эталонам $\Gamma_i, i = \overline{1, M}$, каждого из классов, можем сформулировать решающее правило в виде:

$$\text{Отнести объект к классу с номером } i, \quad \text{если } \|\Gamma^* - \Gamma_i\| < \|\Gamma^* - \Gamma_j\|, \quad \forall j \neq i. \quad (6)$$

Очевидно, что при увеличении размера обрабатываемых изображений будут увеличиваться вычислительные затраты, что критично для автономных информационных систем. Стоит отметить, данный метод может быть распространен на случай, когда каждому классу соответствует несколько изображений в обучающей выборке. В таком случае в качестве представительного эталона для каждого класса может использоваться математическое ожидание этого класса Ψ_i . В качестве альтернативы этому можно воспользоваться, например, схемой классификации по методу k -ближайших соседей [1,2].

КЛАССИФИКАЦИЯ ПО МИНИМУМУ РАССТОЯНИЯ С ЗАГРУБЛЕНИЕМ ИЗОБРАЖЕНИЙ (II).

Как известно, сложно построить алгоритм сегментации, который идеально выделял бы подвижный объект. Одним из методов, обеспечивающих робастность распознавания по отношению к алгоритму сегментации, является разбиение исходных изображе-

ний объектов на области. Данный подход широко применяется при распознавании текста и известен как метод зон (областей) [18]. В соответствии с данным подходом исходное бинарное изображение $I(i, j), i = \overline{1, N}, j = \overline{1, K}$, объекта разбивается на Q областей площадью $S = n \cdot m, n < N, m < K$ областей. Далее из этих областей формируется новое изображение меньшей размерности по следующему правилу: *если число пикселей, принадлежащих объекту в данной области, больше чем число пикселей, принадлежащих фону, то соответствующий элемент нового изображения имеет значение, равное 1, в противном случае – равное 0, т.е.*

$$I(i, j) \rightarrow G(p, k),$$

$$G(p, k) = \begin{cases} 1, & \text{if } \sum_{i=(p-1)n+1}^{pn} \left(\sum_{j=(k-1)m+1}^{km} I(i, j) \right) \geq \frac{S}{2}; \\ 0, & \text{otherwise.} \end{cases} \quad (7)$$

Имея разбиения распознаваемого изображения G^* и разбиения эталонов для каждого класса $G_i, i = \overline{1, M}$, решающее правило можем сформулировать в виде, аналогичном (6):

Отнести объект к классу с номером i ,

$$\text{если } \|G^* - \Gamma_i\| < \|G^* - G_j\|, \quad \forall j \neq i. \quad (8)$$

КЛАССИФИКАЦИЯ ПО МИНИМУМУ РАССТОЯНИЯ С ВЫДЕЛЕНИЕМ ИНФОРМАТИВНЫХ ПРИЗНАКОВ (III). Пусть изображения, хранящиеся в БД, представлены в виде векторов $\Gamma_i, i = \overline{1, M}$, размером $n \times m$. Тогда множество изображений объектов в БД можно представить в виде множества реализаций $\{\Gamma\}$ случайного вектора Γ_i . Пусть среднее изображение по базе

$$\Psi = \frac{1}{M} \sum_{i=1}^M \Gamma_i. \quad (9)$$

Отличие каждого изображения в выборке от среднего

$$\Phi_i = \Gamma_i - \Psi, \quad i = \overline{1, M}. \quad (10)$$

Таким образом, обучающая выборка преобразуется к виду $A = [\Phi_1, \Phi_2, \dots, \Phi_M]$, где $\Phi_i, i = \overline{1, M}$, есть вектор размерностью $k = m \times n$, представляющий соответствующее исходное изображение Γ_i .

Ковариационная матрица для обучающей выборки:

$$C = \frac{1}{M} \sum_{i=1}^M (\Gamma_i - \Psi)(\Gamma_i - \Psi)^T =$$

$$= \sum_{i=1}^M \Phi_i \Phi_i^T = A A^T. \quad (11)$$

Решая задачу на собственные значения непосредственно для матрицы C , получаем k собственных k -компонентных векторов, диагонализующих C :

$$A A^T U = U \Lambda. \quad (12)$$

Совокупность собственных векторов U определяет новый базис, в котором значение i -го компонента случайного вектора статистически не зависит от значения j -го компонента. Следует отметить, что данное преобразование сопряжено с большими вычислительными затратами и задачу на собственные значения для КВМ C можно решить более удобным способом.

Введем матрицу $B = A^T = [\Phi_1, \Phi_2, \dots, \Phi_M]^T$, тогда новая ковариационная матрица:

$$L = B B^T = A^T A. \quad (13)$$

Очевидно, что матрица L отражает статистическую зависимость различных изображений эталона, в то время как матрица C отражает статистическую зависимость между пикселями с различными индексами в данной обучающей выборке. Решая задачу на собственные значения для матрицы L , находим M M -компонентных собственных векторов $V = [v_1, v_2, \dots, v_M]$, диагонализующих L , и M собственных чисел $\mu_i, i = \overline{1, M}$:

$$A^T A V = V N. \quad (14)$$

Здесь $N = \begin{pmatrix} \mu_1 & 0 & \dots & 0 \\ 0 & \mu_1 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \mu_M \end{pmatrix}.$

Найдем связь между собственными векторами матриц L и C . Для этого обе части (14) домножим слева на A . В результате получим:

$$A A^T (A V) = (A V) N. \quad (15)$$

Проводя аналогию с (12), отметим, что M собственных значений матрицы L определяют M собственных значений, а произведение $A V$ - M собственных векторов матрицы C , т.е.:

$$u_i = A v_i, \quad \lambda_i = \mu_i, \quad i = \overline{1, M}. \quad (16)$$

Возникает вопрос, может ли $M \ll k$ собственных значений и собственных векторов отразить в достаточном объеме структуру обу-

чающей выборки? Как показано в [4, 16, 17], на практике уже несколько первых компонентов разложения содержат более 90% информации о статистическом ансамбле.

Таким образом, выражение для собственных векторов (16) в матричном виде

$$U = AV. \quad (17)$$

Теперь проекция произвольного изображения Γ в пространство главных компонент может быть найдена с помощью операции:

$$\Omega = U^T (\Gamma - \Psi). \quad (18)$$

Зная проекции изображений БД в пространство образов $\Omega_i, i = 1, M$, и распознаваемого изображения Ω^* , можно сформулировать решающее правило:

Отнести объект к классу с номером i , если

$$\|\Omega^* - \Omega_i\| < \|\Omega^* - \Omega_j\|, \quad \forall j \neq i. \quad (19)$$

На рисунке 4 показаны проекции изображений БД (точки) и распознаваемого изображения (звездочки) на два первых собственных вектора главных компонент для входного изображения соответствующего рисунку 1.




Рисунок 4 – Представление пространства главных компонент в процессе распознавания

КЛАССИФИКАЦИЯ В ПРОСТРАНСТВЕ ГК ПО ПРАВИЛУ МАКСИМАЛЬНОГО ПРАВДОПОДОБИЯ (IV). Если внести в обучающую базу данных более одного объекта для каждого из распознаваемых классов, то очевидно, что проекции изображений обучающей выборки в пространстве главных компонент будут образовывать кластеры [1]. В таком случае положение кластера для каждого класса объектов может быть описано многомерной функцией плотности распределения вероятности. Примем в качестве такой функции многомерную гауссову функцию распределения

$$p_i(\Omega | \omega_i) = \frac{\exp\left[-\frac{1}{2}(\Omega - \bar{\Omega}_i)^T C_i^{-1}(\Omega - \bar{\Omega}_i)\right]}{(2\pi)^{N/2} |C_i|^{1/2}}, \quad (20)$$

$$i = \overline{1, N}$$

где N - количество различных классов изображений, $\bar{\Omega}_i$ - математическое ожидание, а C_i - ковариационная матрица класса ω_i , Ω - вектор-образ в пространстве главных компонент. Как видно, для однозначного определения функции (20) необходимо знать два параметра – математическое ожидание и ковариационную матрицу для проекций изображений каждого класса в пространство главных компонент. После оценки этих параметров можем сформулировать решающее правило в виде:

Отнести объект к классу с номером i , если $p(\Omega | \omega_i) > p(\Omega | \omega_j), \quad \forall j \neq i. \quad (21)$

Параметры функции плотности распределения несложно оценить, зная координаты проекций изображений соответствующего класса в пространство главных компонент. После оценки параметров распределения можно построить границы доверительного интервала, эллипса или эллипсоида рассеяния заданного уровня значимости. Из курса теории вероятностей [19] известно: чтобы построить эллипс (эллипсоид) рассеяния в случае нормального распределения, достаточно знать величину СКО по каждой из компонент случайного вектора, которая естественным образом связана с КВМ набора данных. Таким образом, когда уравнение эллипса (эллипсоида) ищется в системе координат, центр которой совмещен с центром набора данных, а оси совпадают с осями рассеяния (осями эллипса), то величины i -й полуоси находятся в виде $k\sigma_i$, где k – коэффициент, определяемый заданной степенью достоверности.

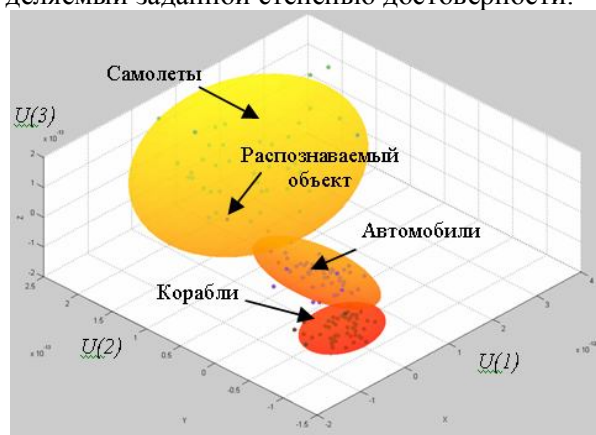


Рисунок 5 – Кластеры изображений БД в пространстве главных компонент

На рисунке 5 представлены проекции классов изображений объектов «Самолет», «Корабль» и «Автомобиль» в пространстве главных компонент с построенными для них эллипсоидом рассеяния.

ЭКСПЕРИМЕНТАЛЬНЫЕ ИССЛЕДОВАНИЯ. Для статистического исследования представленных алгоритмов классификации использовались реальные изображения, полученные с искусственного спутника Земли «Ресурс-ДК1». Решено было ограничиться тремя классами объектов: классом автомобилей, самолетов и кораблей. Для исследования алгоритмов (I)-(III) была создана обучающая БД, в которую было внесено по одному изображению для каждого класса размером 30 на 50 пикселей. Изображения были получены следующим образом. На космическом снимке вручную находились движущиеся объекты – корабли, самолеты и автомобили. Далее участки, содержащие по одному объекту, вырезались из основного изображения и подвергались пороговой сегментации. Полученные таким образом бинарные образы вносились в базу данных. Кроме того, часть эталонных изображений была синтезирована искусственно таким образом, чтобы учитывать характерные черты соответствующих классов объектов. Изображения, используемые для создания БД, представлены на рисунке 6.



Рисунок 6 – Образцы корабля (а) автомобиля (б), самолета (в), используемые для создания базы данных эталонов

На рисунке 7 (а, б, в) показаны три объекта, с помощью которых проводилось исследование алгоритмов классификации. В ходе эксперимента образцы подвергались пороговой сегментации и всевозможным поворотам вокруг центра изображения. Результаты тестирования алгоритма распознавания с использованием и без использования ППК сведены в таблицы 1-3.



Рисунок 7 – Образцы корабля (а), автомобиля (б), самолета (в), используемые для тестирования алгоритмов

Таблица 1 – Результаты тестирования для объекта «Самолет» (алгоритмы I и III)

Параметр	Алгоритм I	Алгоритм III		
		3	2	1
Количество используемых главных компонент	–	3	2	1
Число опытов	1000	1000	1000	1000
Количество ошибок	0	0	0	0
Относительная ошибка распознавания, %	0	0	0	0

Таблица 2 – Результаты тестирования для объекта «Корабль» (I и III)

Параметр	Алгоритм I	Алгоритм III		
		3	2	1
Количество используемых главных компонент	–	3	2	1
Число опытов	1000	1000	1000	1000
Количество ошибок	0	0	49	323
Относительная ошибка распознавания, %	0	0	4,9	32,3

Таблица 3 – Результаты тестирования для объекта «Автомобиль» (алгоритмы I и III)

Параметр	Алгоритм I	Алгоритм III		
		3	2	1
Количество используемых главных компонент	–	3	2	1
Число опытов	1000	1000	1000	1000
Количество ошибок	98	241	284	0
Относительная ошибка распознавания, %	9,8	24,1	28,4	0

Результаты тестирования алгоритма с загроулением изображений объектов представлены в таблицах 4-6.

Таблица 4 – Результаты тестирования алгоритма II для объекта «Самолет»

Размер области [строки столбцов]	[3 5]	[6 10]	[10 10]	[6 5]
Число опытов	1000	1000	1000	1000
Количество ошибок	0	0	0	0
Относительная ошибка распознавания, %	0	0	0	0

Таблица 5 – Результаты тестирования алгоритма II для объекта «Корабль»

Размер области [строки столбцов]	[3 5]	[6 10]	[10 10]	[6 5]
Число опытов	1000	1000	1000	1000
Количество ошибок	11	6	15	9
Относительная ошибка распознавания, %	1,1	0,6	1,5	0,9

Таблица 6 – Результаты тестирования алгоритма II для объекта «Автомобиль»

Размер области [строки столбцов]	[3 5]	[6 10]	[10 10]	[6 5]
Число опытов	1000	1000	1000	1000
Количество ошибок	149	9,4	105	127
Относительная ошибка распознавания, %	14,9	9,4	10,5	12,7

Для тестирования алгоритма IV была создана обучающая база данных, в которую вошли по 30 объектов для каждого класса изображений, полученные из образцов (рисунок 6) с помощью тех моделей искажений, что использовались для проверки алгоритма. Результаты работы алгоритма сведены в таблицу 7.

Таблица 7 – Результаты тестирования алгоритма IV

Класс объектов	«Самолет»	«Корабль»	«Автомобиль»
Число опытов	1000	1000	1000
Количество ошибок	17	1	19
Относительная ошибка распознавания, %	1,7	0,1	1,9

ВЫВОД. По результатам экспериментальных исследований может быть сделан вывод, что наилучшим качеством распознавания обладает алгоритм (IV). Как видно из таблицы 7, максимальная относительная ошибка распознавания для данного метода не превосходит 2%. Кроме того, обладая способностью к обучению, он после дальнейшей доработки может быть адаптирован к работе в бортовой системе конкретного спутника совместно с выбранным алгоритмом сегментации.

Исследования выполнены при поддержке гранта Президента РФ № МК-2815.2007.9.

Библиографический список

1. Коршунов Ю.М. Математические основы кибернетики – 3-е изд. М.: Энергоатомиздат, 1987 – 495 с.
2. Дуда Р., Харт П. Распознавание образов и анализ сцен : пер. с англ. – М.: Мир, 1976. – 511 с.
3. Ту Дж., Гонсалес Р. Принципы распознавания образов : пер. с англ. – М.: Мир, 1978. – 414 с.
4. Фукунага К. Введение в статистическую теорию распознавания образов : пер. с англ. – М.: Наука, 1979. – 368 с.
5. Гонсалес Р. Цифровая обработка изображений / Р.Гонсалес, Р. Вудс. – М.: Техносфера, 2005. – 1072 с.
6. Кашкин В.Б., Сухинин А.И. Дистанционное зондирование Земли из космоса // Цифровая обработка изображений: учеб. пособие. – М.: Логос, 2001. – 264 с.
7. Фу К. Структурные методы распознавания образов: пер. с англ. – М.: Мир, 1977. – 318 с.
8. Хайкин С. Нейронные сети: полный курс – 2-е изд. – М.: Вильямс, 2006. – 1104 с.
9. David Cyganski, John A. Orr. Object Identification and Orientation Estimation from Countours based on an Affine Invariant Curvature // Proceedings of SPIE. Vol. 0848. Jan. 1987.– P. 34-40.
10. Hong-Chih Liu and M.D. Srinath. Recognition of Partially Occluded Shapes Using Boundary Matching in Distance Image // Proceedings of SPIE. Vol. 1192. Mar. 1990. P. 87-97.
11. David Cyganski and Richard F. Vaz. A linear signal decomposition approach to affine invariant contour identification // Proceedings of SPIE. Vol. 1607. Feb. 1992. P.98-109.
12. Введение в контурный анализ; приложения к обработке изображений и сигналов/ Я.А. Фурман и др.; под ред. Я.А. Фурмана – М.: ФИЗМАТЛИТ, 2003. – 592 с.
13. Sanjay Sengupta and Hyun S. Yang. Morphological Shape Representation and Recognition of Binary Images // Proceedings of SPIE. Vol. 0848. Jan. 1987, P.51-56.
14. Рейер И., Петровцева М. Язык гранично-скелетного представления бинарных изображений // Доклады международной конференции Graphicon.– М., – 2003.
15. Алпатов Б.А., Бабаян П.В. Методы обработки и анализа изображений в бортовых системах обнаружения и сопровождения объектов // Цифровая обработка сигналов. – 2006. – №2. – С. 45-51.
16. Прикладная статистика: классификация и снижение размерности: Справ. изд. / С.А. Айвазян, В.М. Бухштабер, И.С. Енюков, Л.Д. Мешалкин; под ред. С.А. Айвазяна. – М.: Финансы и статистика, 1989. – 607 с.
17. Pearson K. On lines and planes of closest fit to systems of points in space // Philosophical Magazine. Vol. 2, 1901 <http://pbil.univ-lyon1.fr/R/pearson1901.pdf>
18. Бондаренко А.В. Исследование подходов к построению систем автоматического считывания символьной информации // А.В. Бондаренко и др. — Институт прикладной математики имени М.В.Келдыша. – М., 2003.
19. Вентцель Е.С. Теория вероятностей. – 4-е изд. – М.: Наука, 1969. – 564 с.