

УДК 621.372:519.72

Распознавание изображений методом направленного перебора с применением редукции множества альтернатив¹.

Автоматическое распознавание изображений, распознавание образов без учителя, самообучение, критерий минимума информационного рассогласования.

А.В. Савченко

Государственный университет «Высшая школа экономики» - Нижегородский филиал

Ставится и решается задача автоматического распознавания изображений методом направленного перебора с редукцией множества альтернатив. Разработан алгоритм распознавания с самообучением. Представлены результаты его экспериментального исследования для распознавания полутонных изображений из большой базы данных.

Image Recognition by the Direct Search Method with Alternatives Set's Reduction

Automatic image recognition, pattern recognition, recognition with unsupervised training, self training, minimum of information mismatch criterion.

A. V. Savchenko

State University "High School of Economics", Nizhny Novgorod

The problem of automatic image recognition is put and solved the direct search method with alternatives set's reduction. The algorithm of recognition with unsupervised learning has been developed. The experimental results for half-tone image recognition from a large database have been produced.

Введение. Метод направленного перебора [1] альтернатив (МНП) является, как известно [2], эффективным средством решения широкого круга задач в области автоматического распознавания изображений (АРИ). Этот метод, основанный на теоретико-информационном подходе и отталкивающийся от метрических свойств решающей статистики минимального информационного рассогласования (МИР), позволяет учесть характерную особенность задачи АРИ – количество эталонов в реальных базах данных составляет сотни и тысячи единиц. Традиционный подход преодоления этой проблемы связан с редукцией множества альтернатив. Этот подход в соединении с принципом МИР получил свое дальнейшее развитие в информационной теории восприятия образов (ИТВО) [3], первоначально применявшейся для автоматического распознавания речи. Между тем, до настоящего времени практически не исследовалась возможность применения ИТВО к задачам АРИ.

¹ Работа выполнена при поддержке гранта ГУ-ВШЭ №09-03 от 04.06.2009

Исследованиям в этом актуальнейшем направлении и посвящена предлагаемая работа. В ней предлагается использования двухэтапного алгоритма АРИ: на первом этапе выполняется редукция множества альтернатив на основе ИТВО, а на втором для распознавания изображений применяется МНП. Полученные результаты и сделанные по ним выводы рассчитаны на широкий круг специалистов в области современной теории и практики распознавания образов.

Критерий минимума информационного рассогласования. Пусть задано множество из $L > 1$ полутоновых изображений $X_l = \left\| x_{uv}^l \right\|, l = \overline{1, L}, u = \overline{1, H}, v = \overline{1, W}$. Здесь H – высота изображения, W – его ширина; $x_{uv}^l \in \{1, 2, \dots, x_{\max}\}$ – интенсивность точки изображения с координатами (u, v) ; x_{\max} – максимальное значение интенсивности. Предположим, что множество всевозможных изображений \mathbf{X} , из которого взяты эталоны X_l , разбивается на R непересекающихся классов $\mathbf{X}_r, r = \overline{1, R}$ со свойствами

1. $\mathbf{X} = \bigcup_{r=1}^R \mathbf{X}_r$
2. $\mathbf{X}_{r_1} \cap \mathbf{X}_{r_2} = \emptyset$ при $r_1 \neq r_2$
3. $(\forall l)(\exists r) X_l \in \mathbf{X}_r$.

Каждый класс \mathbf{X}_r характеризуется тем, что принадлежащие ему объекты обладают некоторой общностью или сходством в характеристиках. То общее, что объединяет объекты в класс, и называют *образом*. Задача состоит в том, чтобы, во-первых, на основе множества изображений $\{X_l\}$ сформировать классы \mathbf{X}_r , и, во-вторых, отнести вновь поступающее (на вход) изображение $X = \left\| x_{uv} \right\|$ к одному из R таких классов. Первая подзадача представляет собой типичный пример задачи самообучения (обучение без учителя) [4]. Ее тривиальное решение основано на предположении о том, что каждый объект X_l задает свой собственный класс. Тогда $R=L, r \equiv l$ и $\mathbf{X}_r = \{X_r\}$. В этом случае интерес представляет только вторая подзадача – собственно распознавание образов для объектов нечисловой природы (ОНП) [5].

Напомним, что термин ОНП относится к элементам математического пространства, не являющегося линейным (векторным). Процедуры построения решающих правил для поставленной задачи в общем случае делятся на детерминированные и статистические [5]. В настоящее время наиболее часто используется первый, детерминистский, подход. В рамках такого подхода в пространстве ОНП определяется некое расстояние (мера

близости) между любыми парами объектов. Зачастую [5,6] для АРИ применяется критерий минимума l_1 - метрики

$$\rho_1(X / \mathbf{X}_r) = \frac{1}{W \cdot H} \sum_{u=1}^H \sum_{v=1}^W |x_{uv} - x_{uv}^r| \quad (1)$$

К сожалению, подобный подход не всегда позволяет получить удовлетворительные результаты. Это обстоятельство связано, во-первых, с известной [6] вариативностью зрительных образов, а, во-вторых, с наличием во входном изображении X помех, таких, как неопределенная заранее интенсивность источников освещения или просто случайное искажение некоторых точек изображения.

Указанные проблемы при детерминистском подходе обычно решаются путем добавления новых изображений к множеству эталонных изображений (МЭИ), что приводит, в свою очередь, к резкому увеличению его объема. Во всех перечисленных случаях на помощь приходит второй, статистический, подход [6]. В рамках данного подхода выполним нормировку интенсивности изображений из МЭИ, то есть перейдем к рассмотрению нормированных изображений $\bar{X}_r = \left\| \bar{x}_{uv}^r \right\|$, где

$$\bar{x}_{uv}^r = \frac{x_{uv}^r}{S_r}, u = \overline{1, H}, v = \overline{1, W}. \text{ Здесь введено обозначение } S_r = \sum_{u=1}^H \sum_{v=1}^W x_{uv}^r.$$

Аналогичная процедура нормировки выполняется и для входного изображения: $\bar{X} = \left\| \bar{x}_{uv} \right\|, \bar{x}_{uv} = \frac{x}{S}, S = \sum_{u=1}^H \sum_{v=1}^W x_{uv}$. Подобная нормировка

[7] издавна применяется в задаче АРИ во избежание указанной выше проблемы неизвестной интенсивности источника освещения.

Можно предположить, что нормированное изображение-эталон \bar{X}_r определяет собой распределение некой (гипотетической) двумерной дискретной случайной величины. Подобная интерпретация выглядит вполне обоснованной, если учесть, что для \bar{X}_r выполняются основные

свойства дискретного распределения: $\sum_{u=1}^H \sum_{v=1}^W \bar{x}_{uv}^r = 1$ (условие

нормировки) и $\bar{x}_{uv}^r > 0, u = \overline{1, H}, v = \overline{1, W}$ (условие регулярности [8]). Задача состоит, в таком случае, в проверке R гипотез о распределении $\mathbf{X}_r, r = \overline{1, R}$, сигнала изображения на входе X . Как показано в работе [8], оптимальное в байесовском смысле решение задачи проверки гипотез о распределении дискретной случайной величины дает принцип МИР и минимизация статистики

$$\rho_{KL}(X / X_r) = \sum_{u=1}^H \sum_{v=1}^W \left(\bar{x}_{uv} \ln \left(\frac{\bar{x}_{uv}}{\bar{x}_{uv}^r} \right) \right) \quad (2)$$

Статистика $\rho_{KL}(X / X_r)$ здесь определяет информационное рассогласование (ИР) по Кульбаку-Лейблеру [9] между наблюдаемым сигналом изображения X и r -м классом из МЭИ.

Таким образом, процедура АРИ в данном случае реализуется по схеме многоканальной обработки, в которой число каналов R определяется количеством изображений-эталонов L . Решение принимается по критерию минимума решающей статистики из выражения (1) – для традиционных методов решения задачи АРИ; или из выражения (2) – при использовании принципа МИР.

Информационная теория восприятия образов. Рассмотрим наиболее актуальный и для теории, и для практики случай $R \gg 1$, когда решается задача АРИ с объемом МЭИ в сотни и даже тысячи изображений. В указанных условиях практическая реализация оптимального решающего правила (2) по схеме R -канальной обработки наталкивается на очевидную проблему его вычислительной сложности и даже практической реализуемости, особенно, если учитывать трудоемкую процедуру предварительной обработки изображений - их выравнивание по множеству параметров: размеру, цвету, ракурсу и т.п. В поиске путей решения указанной проблемы за счет отказа от сплошного перебора МЭИ и состоит центральная идея настоящей работы.

Заметим, что зачастую объем МЭИ L существенно превышает количество классов изображений R . Например, в базе данных может содержаться несколько фотографий одного и того же человека. В этом случае указанное выше тривиальное решение задачи самообучения уже не является приемлемым. Конечно, сходные изображения могут быть отобраны экспертом вручную. Однако для больших МЭИ такое решение является неприемлемым в силу своей трудоемкости. В этом случае целесообразно выполнить редукцию МЭИ, применяя известные алгоритмы классификации, такие как k -means или карты Кохонена [10]. Эти алгоритмы основаны на том, что число классов R заранее известно. Для большинства практических приложений задачи АРИ указанное предположение не выполняется, поэтому количество классов требуется определять, используя только информацию, содержащуюся в МЭИ $\{X_l\}$. Решение указанной задачи самообучения проведем на основе подхода ИТВО [3].

Прежде всего, отметим метрические свойства решающей статистики МИР $\rho_{KL}(X / X_l) \geq 0$ с равенством ее нулю лишь в идеальном случае совпадения входного и эталонного сигналов. Основываясь на этом, в

рамках ИТВО множество образов \mathbf{X} разбивается на R непересекающихся классов $\mathbf{X}_r = \{X_{r_i}, r_i \leq L\}$, таких, что либо \mathbf{X}_r состоит ровно из одного эталона X_{r_i} , либо

$$(\exists X_{r_j} \in \mathbf{X}_r, r_j \neq r_i) \rho_{KL}(X_{r_i} / X_{r_j}) < \rho_0 \quad (3)$$

Здесь $\rho_0 = const$ - порог для допустимой величины ИР на множестве одноименных изображений за счет известной их вариативности. Значение такого порога нетрудно установить опытным путем.

После этого на основе критерия минимума суммы ИР в пределах каждого r -го кластера ($X_k \in \mathbf{X}_r$)

$$\rho_{KL}^{(r)}(X_k) = \sum_{X_i \in \mathbf{X}_r} \rho_{KL}(X_k / X_i),$$

определяется (согласно ИТВО) его информационный центр-эталон (ИЦ) вида

$$X_r^* = \arg \min_k \rho_{KL}^{(r)}(X_k) \quad (4)$$

В эталоне X_r^* содержится существенная информация обо всем классе \mathbf{X}_r . Поэтому последний этап связан с редукцией всего множества эталонов $\{X_l\}, l = \overline{1, L}$ к множеству ИЦ $\{X_r^*\}, r = \overline{1, R}, R \leq L$.

После такого решения задачи самообучения второй этап – распознавание – производится на основе критерия МИР

$$W_v(X) : \rho_{KL}(X / X_v^*) \rightarrow \min \quad (5)$$

С учетом определения (3) класса \mathbf{X}_r последнюю формулу можно преобразовать к упрощенному (в ее практической реализации) виду [1,8]

$$W_v(X) : \rho_{KL}(X / X_v^*) < \rho_0 \quad (6)$$

По своей сути выражение (6) определяет условие останова при переборе альтернатив в рамках проверочной процедуры по критерию МИР (5).

Заметим, что если рассматривать самообучение как процесс адаптации [4], то нетрудно заметить эквивалентность выражений (3) и (6). Действительно, при адаптивном подходе классы формируются постепенно следующим образом. Вначале число классов $R=0$. далее для каждого изображения-эталона $X_l, l = \overline{1, L}$ ищется тот класс r , для которого выполняется условие (6), то есть решается обычная задача распознавания изображения $X = X_l$. Если такой класс v найден, то объект X_l добавляется в класс \mathbf{X}_v , а далее согласно (4) вычисляется его новый ИЦ. И

только если $(\forall v) \rho_{KL}(X_l / X_v^*) \geq \rho_0$, то создается новый, $(R+1)$ -й класс $X_{R+1} = \{X_l\}$, $X_{R+1}^* = X_l$.

В такой формулировке задача распознавания представляет собой основу адаптивной процедуры самообучения. Поэтому далее сосредоточимся на решении именно задачи распознавания (5),(6).

При принятии решения на основе принципа МИР (5) требуется просматривать не все ИЦ, а вычислять величину ИР лишь до тех пор, пока оно не будет меньше некоторого порогового уровня. Нетрудно понять, что само по себе указанное обстоятельство позволит сократить объем перебора МЭИ в среднем на 50%. Иными словами, благодаря использованию правила останова (6) удастся в два раза сократить объем выполняемых вычислений и этим существенно ослабить проблему практической реализуемости АРИ в режиме реального времени. В этом состоит принципиальное преимущество МИР по сравнению со всеми его наиболее известными статистическими аналогами, в которых применяются классические (байесовские) критерии: минимума среднего риска, максимума апостериорной вероятности и др. [6]. Между тем, как это выясняется ниже, рассмотренный выигрыш в вычислительной сложности и производительности далеко не исчерпывает всех преимуществ принципа МИР в задаче распознавания изображений.

Действительно, общая формулировка задачи (5) позволяет рассматривать ее как задачу оптимизации и применять алгоритмы поиска оптимального решения с заданным условием останова (6). В такой задаче на МЭИ $\{X_r^*\}$ требуется найти такой ИЦ-эталон X_v^* , который будет минимизировать статистику МИР (2). В этом случае метод, сводящийся к полному перебору МЭИ, является одним из множества известных методов оптимизации систем. Главным препятствием для применения в нашей задаче более эффективного оптимизационного метода является то, что, во-первых, задача относится к области дискретной математики и, во-вторых, в ней требуется найти глобальный минимум решающей статистики (2). По-видимому, наиболее обоснованным способом поиска глобального экстремума в указанных условиях можно считать методы случайного поиска, такие, как генетический алгоритм (ГА). К сожалению, известные классические методы оптимизации не учитывают информации о самих изображениях, рассогласованиях между ними. Более того, в большинстве дискретных алгоритмов оптимизации не существует четкого критерия останова поиска. На помощь снова приходит принцип МИР. Действительно, на основе того же выражения (6) мы можем сформулировать искомый критерий останова алгоритма оптимизации. В этом случае появляется гарантия того, что решение задачи, если оно существует (если входное изображение относится к одному из классов

$\{X_r\}$), будет найдено. Естественным развитием этой идеи может служить предложенный ниже метод направленного перебора МЭИ, в котором метрические свойства решающей статистики МИР (6) используются в наиболее полной степени.

Идея МНП. Следуя общей схеме вычислений (5),(6), сведем задачу АРИ X к проверке сначала N первых вариантов X_1^*, \dots, X_N^* из заданного R -множества альтернатив $\{X_r^*\}$ при условии $N \ll R$. Если, по крайней мере, одна из них, а именно: $X_{\nu}^*, \nu \leq N$, отвечает требованию останова (6), процесс поиска оптимального решения по критерию МИР (5) на ней и завершается. Однако в общем случае можно предположить, что ни одна из первых N альтернатив проверку (6) на первом шаге не проходит. В таком случае можно проверить вторую группу из N эталонных изображений в пределах множества $\{X_r^*\}$, потом третью группу и т.д. – до момента выполнения условия (6). Но есть и иной, более рациональный, вариант решения поставленной задачи.

Расставим изображения из нашей первой контрольной выборки X_1^*, \dots, X_N^* в порядке убывания их ИР $\rho_{KL}(X / X_n^*)$, $n = \overline{1, N}$. В результате будем иметь упорядоченную (ранжированную) последовательность эталонных изображений вида $\{X_{i_j}^*\} = \{X_{i_1}^*, X_{i_2}^* \dots X_{i_N}^*\}$, $i_j \leq N$. Соответствующая последовательность $\{\rho_j\}$ их ИР $\rho_j = \rho_{KL}(X / X_{i_j}^*)$, $i_j \leq N$, будет иметь характер монотонно убывающей зависимости.

Заметим, что ИР вида (2) представляет собой непрерывную функцию своих аргументов – относительных интенсивностей двух изображений. В этом случае можно предположить, что, если некоторый ИЦ-эталон из МЭИ X^* удовлетворяет условию $\rho_{KL}(X / X^*) < \rho_0 \ll 1$, то для произвольного образа X_i^* из МЭИ выполняется условие

$$\left| \rho_{KL}(X / X_i^*) - \rho_{KL}(X^* / X_i^*) \right| \ll 1.$$

Отсюда и вытекает главная идея МНП: использовать последний элемент $X_{i_N}^*$ из упорядоченной контрольной выборки $\{X_{i_j}^*\}$ как наилучшее приближение к искомому изображению X в роли точки отсчета для поиска наиболее подходящих «кандидатов» в очередную контрольную выборку. При этом ориентиром для определения максимально допустимых различий (в теоретико-информационном смысле) изображений-эталонных из будущей контрольной выборки по отношению к «точке отсчета» $X_{i_N}^*$ будет

служить рассогласование $\rho_{KL}(X / X_{i_N}^*)$. Проиллюстрируем сказанное с помощью диаграммы поисковой процедуры МНП на рис.1.

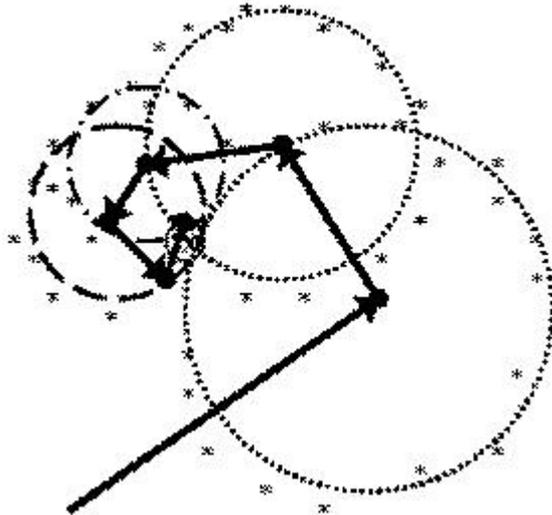


Рис.1. Поисковая процедура МНП

Здесь звездочками обозначены все имеющиеся изображения-эталоны, буквой X – входное изображение, а ромбиком – наиболее близкий к X эталон. Он и определяет искомое оптимальное решение задачи. Траектория поиска отображается на рис. 1 ломаной направленной линией. Жирными точками на ней обозначена последовательность наиболее близких к оптимуму изображений $X_{i_N}^*$ после нескольких подряд этапов вычислений. Окружностями здесь отмечены границы соответствующих контрольных точек-выборок X_1^*, \dots, X_N^* . Их радиусы определяются согласно ИР до входного изображения X . Хорошо видно, что траектория поиска имеет вид скручивающейся спирали.

Синтез алгоритма. Следуя определению ИР (2) составим $(R \times R)$ -матрицу $P = \|\rho_{ij}\|$ значений ИР $\rho_{ij} = \rho_{KL}(X_i / X_j)$. Эту весьма сложную в вычислительном отношении операцию требуется выполнить лишь раз: на предварительном этапе вычислений и для каждого конкретного МЭИ. Однако отметим, что в контексте решения задача самообучения (3) эта матрица все равно должна быть вычислена, так как объединение объектов в класс основывается на попарных расстояниях между ними. После этого, как было описано выше, зададимся в пределах имеющегося R -множества эталонов $\{X_r^*\}$ произвольной первой контрольной выборкой X_1^*, \dots, X_N^* некоторого фиксированного объема N , по ней получим ранжированный по критерию МИР (5) ряд данных $\{X_{i_j}^*\}$ и, наконец, найдем из него первый локальный оптимум $X_{i_N}^*$. На этом завершается первый этап вычислений.

На втором этапе для выделенного изображения-эталона $X_{i_N}^*$ по матрице P найдем множество из $M < R$ изображений $X^{(M)} = \{X_{i_{N+1}}^*, \dots, X_{i_{N+M}}^*\} \ i_j \leq R$, находящихся от изображения $X_{i_N}^*$ на «расстоянии» (2), не превышающем порогового значения $\rho_N = \rho_{KL}(X / X_{i_N}^*)$:

$$\left(\forall X_i \notin X^{(M)} \right) \left(\forall X_j \in X^{(M)} \right) \Delta \rho(X_i) \geq \Delta \rho(X_j) \quad (7)$$

Здесь $\Delta \rho(X_i) = \left| \rho_{KL}(X_i / X_{i_N}^*) - \rho_N \right|$ - отклонение ИР между входным изображением X и локальным оптимумом $X_{i_N}^*$ относительно ИР между парой изображений X_i и $X_{i_N}^*$. На рис.1 каждое такое множество ограничивается соответствующей окружностью с центром в точке $X_{i_N}^*$.

Добавим к этому множеству еще один, $(M+1)$ -й элемент $X_{i_{N+M+1}}^*$ из числа не попавших в состав контрольной выборки по результатам предыдущего этапа вычислений. Этим мы вносим в поисковую процедуру определенный элемент случайности как способ достижения глобального оптимума за конечное число шагов оптимизации (этапов вычислений). В результате получаем вторую контрольную выборку изображений-эталонов $\{X_{i_N}^*, \dots, X_{i_{N+M+1}}^*\} \ i_j \leq R$, для анализа. Далее все вычисления первого этапа циклически повторяются до тех пор, пока на некотором K -м этапе для элемента $X_{i_N}^*$ не будет выполнено условие останова (3), т.е. при условии

$$\rho_{KL}(X / X_{i_N}^*) < \rho_0 \quad (8)$$

На рис.1 в такой момент входное изображение оказывается в пределах границ множества контрольных точек последнего этапа вычислений. Решение здесь принимается в пользу наиболее близкого образа X^* . Или, в худшем случае, после перебора всех альтернатив из множества $\{X_r^*\}$, но в отсутствие решения из (8), делается вывод о том, что входное изображение X нельзя отнести ни к одному классу из МЭИ, и необходимо задействовать режим переспроса. В общем же случае, суммарное число $C = N + (M + 1) \cdot K \leq R$ выполняемых согласно (8) проверок может существенно выигрывать по сравнению с объемом используемого МЭИ L . Этот выигрыш обусловлен, в частности, тем обстоятельством, что для рассогласования Кульбака-Лейблера (как, впрочем, и для многих других расстояний, в частности, метрики l_1)

вероятность p того, что искомый эталон X^* принадлежит множеству $X^{(M)}$, как правило, существенно превышает вероятность того, что X^* будет одним из M наудачу выбранных эталонов:

$$p = P\{X^* \in X^{(M)}\} \gg p_0 = \frac{M}{R} \quad (9)$$

В этом и состоит эффект направленного перебора. А отличия в количестве этапов K алгоритма для разных экспериментов объясняются тем, что вероятность p зависит не только от свойств используемой метрики, но и от свойств входного изображения и МЭИ.

Таким образом, система выражений (5)...(9) и определяет, в конечном итоге, предлагаемый МНП в задаче АРИ.

Результаты экспериментальных исследований. Для проведения эксперимента воспользуемся реальной базой данных фотографий людей¹. В качестве их предварительной обработки для выделения лиц использовалась библиотека OpenCV². Из 6500 фотографий 400 различных людей с помощью алгоритма самообучения (4),(5) на основе метрики Кульбака-Лейблера (2) были отобраны в качестве эталонов $R=1225$ наиболее различающиеся изображения. Для алгоритма самообучения без использования МНП количество вычислений расстояний (2) составило чуть более 3 млн. Если же наряду с (4),(5) использовался МНП (6)-(8), то общий объем вычислений упал на 60% и составил чуть более 1млн вычисления ИР (2). Параметры МНП при этом были выбраны следующим образом: $N=2$, $M=20$. В этом случае вероятность из (9) $p_0 = \frac{20}{1225} \approx 0,016$.

Порог $\rho_0 = 0,09$ был подобран экспериментально. При этом вероятность того, что в один класс X_r попали изображения разных людей, составила всего лишь 0,6%.

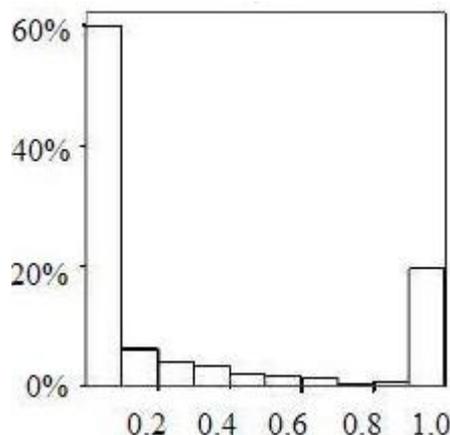


Рис.2. Гистограммы количества проверок C изображений для МНП

¹ Essex Faces database <http://cswww.essex.ac.uk/mv/allfaces/index.html>

² <http://opencv.willowgarage.com/wiki/>

После этого для тестирования собственно распознавания были взяты другие 1200 фотографий тех же людей. В результате, в 96% случаев было получено точное решение $X^* = X_r^*$. Гистограмма количества проведенных проверок C согласно алгоритму (2)...(9) показана на рис.2. Здесь среднее количество проверок составило примерно 29% от объема МЭИ. Для 22,5% тестовых изображений условие (6) не было выполнено ни для одного эталона из МЭИ, и были проверены все R альтернатив. В этом эксперименте вероятность того, что искомый эталон X^* принадлежит множеству $X^{(M)}$, составила $p=0,56$. Если же для указанной задачи применять только случайный ГА-поиск (без использования МНП) на основе критерия останова (6), то в среднем проверяются 55,3% эталонов. Гистограмма количества проверок C в этом случае показана на рис.3. Как видно, здесь наблюдается практически равномерное распределение величины C (конечно, с учетом «хвоста» в 22,5% обязательных проверок).

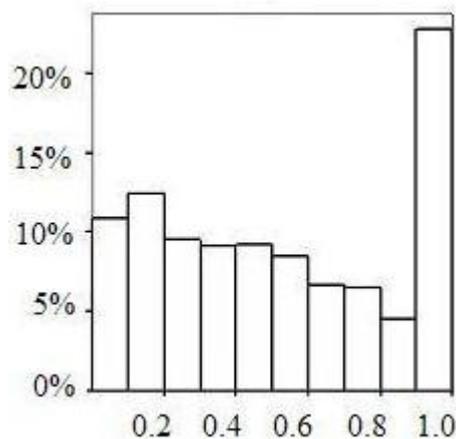


Рис.3. Гистограмма количества проверок C изображений для случайного поиска.

Для метрики l_1 из выражения (1) результаты применения МНП оказались несколько лучше. Так, вероятность ошибки распознавания составила 2,5%, при этом в среднем МНП проверял 24% эталонов в МЭИ. Однако не будем забывать, что метрика l_1 в формулировке (1) использует условное предположение о том, что все входные изображения освещены так же, как и эталоны из МЭИ. Для подтверждения немного изменим наш предыдущий эксперимент. Выполним искусственное затемнение тестовых изображений и проведем процедуру АРИ еще раз. В этом случае для метрики Кульбака-Лейблера (2) и МНП с параметрами N , M и ρ_0 из предыдущего эксперимента получаем среднее количество проверок 31% от объема МЭИ при вероятности ошибки 6%. Таким образом, результаты использования рассогласования Кульбака-Лейблера (2) ухудшились не существенно по сравнению с предыдущим экспериментом без искажений

тестовых изображений. Однако при использовании метрики l_1 из выражения (1) и алгоритма МНП с порогом $\rho_0 = 15$ результаты получаются значительно хуже. Так, вероятность ошибки повысилась до 16%, при этом среднее число проверок составило 88% от объема МЭИ. В 84% случаев условие (6) не было выполнено ни для одного эталона.

Заключение. Вопрос о повышении скорости вычислений без потери качества распознавания образов вызывает повышенный интерес среди специалистов как в области теории, так и практики АРИ. Этот вопрос обычно решается применением некоторых алгоритмов кластеризации для объединения сходных объектов в один класс. В настоящей работе показано, что принцип МИР и ИТВО, применявшиеся раньше в задачах распознавания речи, могут быть с успехом использованы для выполнения адаптивного самообучения и в задачах АРИ. Однако самообучение представляет собой только первый этап на пути к повышению скорости вычислений. Применение критерия останова (6) позволяет, с одной стороны, выполнить отбраковку сомнительных с точки зрения надежности решений, с другой, - сократить объем вычислений в среднем в 2 раза даже в самом невыгодном, переборном, варианте своей реализации. При использовании же предложенного метода в формулировке (5)...(9) количество вычислений и вовсе составляет 30% по сравнению с методом сплошного перебора. При применении же двухэтапной процедуры «редукция МЭИ-распознавание» выполняется лишь 6% вычислений. При этом не утрачивается (по сравнению со сплошным перебором МЭИ) и качество достигаемого решения. Более того, проведенные эксперименты наглядно показывают, что МНП может давать хорошие результаты на основе не только информационной метрики Кульбака-Лейблера (2), но и традиционной метрики l_1 (1). А условие (9) позволяет в таком случае сделать обоснованный выбор в пользу одной из метрик для проверки гипотез по МНП при учете особенностей применяемого МЭИ.

Таким образом, благодаря проведенному исследованию предложен новый метод для решения задачи АРИ без учителя на основе принципа МИР, обладающий широкими функциональными возможностями и высокими эксплуатационными свойствами.

Библиографический список

1. Савченко А.В. Метод направленного перебора словаря в задаче автоматического распознавания речи на основе принципа минимума информационного рассогласования. // Системы управления и информационные технологии. 2009. №1 (35). С.83-91.
2. Савченко А.В. Метод направленного перебора альтернатив в задаче распознавания полутонных изображений. // Автометрия. 2009. №3 (45). С. 90-98.

3. Савченко В.В. Информационная теория восприятия речи. // Известия вузов России. Радиоэлектроника. 2007. Вып.6. С.3-9.
4. Цыпкин Я.З. Адаптация и обучение в автоматических системах, М., 1968, 400 с.
5. Орлов А.И. Математические методы исследования и диагностика материалов //Заводская лаборатория. 2003. Т.69. №.3. С.53-64.
6. Горелик А.Л., Гуревич И.Б., Скрипкин В.А. Современное состояние проблемы распознавания: некоторые аспекты. М.: Радио и связь, 1985. - 160с.
7. Phill Kyu Rhee, InJa Jeon, and EunSung Jeong, “Adaptive normalization based highly efficient face recognition under uneven environments”, Lecture Notes in Computer Science, vol. 3611, 2005
8. Савченко В.В., Савченко А.В. Принцип минимального информационного рассогласования в задаче распознавания дискретных объектов // Известия вузов России. Радиоэлектроника. 2005. Вып.3. С.10-18.
9. Кульбак С. Теория информации и статистика. М.: Наука, 1967.- 408 с.
10. Kohonen, T.: Self Organizing Maps. Springer, Berlin Heidelberg New York (1995)