

УДК 681.332:778.38

С. М. Борзов, В. И. Козик, О. И. Потатуркин

*(Новосибирск)***АДАПТИВНЫЙ МЕТОД РАСПОЗНАВАНИЯ
МАЛОРАЗМЕРНЫХ ИЗОБРАЖЕНИЙ С ИТЕРАЦИОННОЙ
ОБРАБОТКОЙ КОРРЕЛЯЦИОННЫХ ФУНКЦИЙ**

Предложен адаптивный метод распознавания малоразмерных изображений, основанный на итерационной процедуре определения параметров системы признаков. Рассматриваются системы с элементами нейронной сети для его реализации. В результате цифрового моделирования получено значительное повышение дискриминантных свойств формируемой системы признаков за счет использования в итерационном процессе как значений отсчетов, так и информации о структуре авто- и кросскорреляционных функций. Показана инвариантность метода к различным условиям освещенности и в значительной степени к ракурсным преобразованиям распознаваемых изображений.

Проблема распознавания образов является одной из наиболее актуальных и многоплановых в области создания искусственного интеллекта. К настоящему времени в общем виде она не решена, однако в конкретных прикладных задачах широкое распространение получили методы, основанные на применении корреляционного анализа [1] для определения меры близости распознаваемых и эталонных изображений (РИ и ЭИ соответственно). При этом с целью повышения дискриминантных свойств системы признаков предложено дополнительно осуществлять апостериорную обработку корреляционных функций с помощью локальных дифференциальных операторов и формировать таким образом модифицированную систему признаков [2, 3]. Данный подход позволяет повысить возможность выделения острых автокорреляционных пиков относительно более низкочастотных кросскорреляционных функций [4]. Тем не менее при распознавании близких изображений или изображений с небольшим числом элементов разрешения (менее 32×32) алгоритмы, основанные на корреляционном анализе, становятся малоэффективными. Дело в том, что при наличии даже малого шума максимальные значения авто- и кросскорреляционных функций могут незначительно отличаться друг от друга и увеличение их отношения за счет апостериорной обработки недостаточно для существенного повышения достоверности распознавания. Следовательно, актуальным становится исследование принципиально других подходов к этой проблеме.

Одними из наиболее перспективных в данной области являются нейросетевые методы обработки информации, значительно повышающие эффективность процесса распознавания за счет применения глобальных связей и итерационных процедур обучения и обработки.

В [5] предложен вариант двухслойной нейроподобной системы, где в каждом слое глобальные связи обеспечивают интегральные преобразования изображений, а в первом из них дополнительно имеется подслой с локальными

связями для дифференциальной апостериорной обработки. В процессе обработки после ряда итераций РИ преобразуется в наиболее близкое ЭИ, в результате чего определяется класс распознаваемого изображения. Однако, как показывает практика, применение в итерационном процессе только вторичной системы признаков и потеря в явном виде информации о корреляционной мере близости приводят в ряде случаев к ошибкам распознавания.

Дальнейшее увеличение дискриминантных свойств корреляционных методов распознавания изображений предлагается осуществить за счет совместного использования в итерационном процессе исходной $g_n(r)$ и модифицированной $\tilde{g}_n(r)$ систем признаков, где r — двумерные пространственные координаты, сопряженные с координатами входного поля наблюдения, n — номер итерации. Такой подход позволяет полнее использовать входную информацию, так как одновременно обеспечивает учет значений корреляционных функций РИ и ЭИ и их высокочастотных составляющих. При этом на каждой итерации пространство признаков является двумерным — $\{\tilde{g}_n(r), g_n(r)\}$, а область, соответствующая определенному классу РИ, формируется в процессе обучения нейронной сети.

В качестве одной из эффективных процедур предлагается итерационная обработка вида

$$g_{n+1}(r) = \alpha_n [g_n(r) - \beta_n \tilde{g}_n(r)] \tilde{g}_n(r), \quad (1)$$

где α_n и β_n — регулируемые коэффициенты на данной итерации; $g_1(r)$ — функция корреляции РИ и ЭИ; $\tilde{g}_1(r)$ — результат ее апостериорной обработки. При этом процесс обучения сводится к определению оптимальной последовательности коэффициентов $\{\alpha_n, \beta_n\}$. Отметим, что в дальнейшем для удобства изложения, за исключением особых случаев, обозначение аргумента функций будет опущено.

Конкретные значения коэффициентов α_n и β_n определяют область G_n^+ в пространстве $\{\tilde{g}_n, g_n\}$, где происходит усиление g_n , т. е. $g_{n+1} > g_n$. Ее граница находится из соотношения $\alpha_n(g_n - \beta_n \tilde{g}_n) \tilde{g}_n = g_n$ и имеет вид

$$g_n = \alpha_n \beta_n \tilde{g}_n^2 / (\alpha_n \tilde{g}_n - 1). \quad (2)$$

Соответственно в остальной области пространства признаков G_n^- происходит подавление g_n ($g_{n+1} < g_n$).

Вид функции $g_n(\tilde{g}_n)$ представлен на рис. 1. Прямые $\tilde{g}_n = 1/\alpha_n$ и $g_n = \beta_n \tilde{g}_n$ являются асимптотами этой функции, а ее минимум равен $(2/\alpha_n, 4\beta_n/\alpha_n)$. С увеличением α_n функция (2) приближается к асимптотам, а ее минимум — к началу координат вдоль прямой $g_n = 2\beta_n \tilde{g}_n$. Максимальные значения g_{n+1} принимает на прямой $g_n = 2\beta_n \tilde{g}_n$, где

$$g_{n+1} = \frac{\alpha_n}{4\beta_n} g_n^2.$$

Таким образом, выбор α_n определяет минимальные значения величин g_n и \tilde{g}_n , обеспечивающих режим усиления ($g_{n+1} > g_n$), а выбор β_n — такое соотношение между ними, при котором g_{n+1} максимально. Отметим, что при




Рис. 1




Рис. 2

$g_n = \text{const} = c_1$ и $\tilde{g}_n = \text{const} = c_2$ сечения g_{n+1} имеют соответственно следующий вид:

$$g_{n+1} = \frac{\alpha_n}{\beta_n} \left[\frac{c_1^2}{4} - \left(\frac{c_1}{2} - \beta_n \tilde{g}_n \right)^2 \right],$$

$$g_{n+1} = \alpha_n c_2 g_n - \alpha_n \beta_n c_2^2.$$

Рассмотрим последовательно процедуру обработки, выполняемой в соответствии с (1). На первой итерации определяется функция $g_2(r)$, которая, в свою очередь, используется на второй итерации. Ее апостериорная обработка позволяет получить новое пространство признаков $\{\tilde{g}_2, g_2\}$. Поскольку форма функции $g_2(r)$ отличается от формы $g_1(r)$, в результате итерации происходит не только усиление/подавление g_1 , но и изменение \tilde{g}_1 . Благодаря этому существенно увеличивается возможность разделения распознаваемых изображений на классы. При этом изменение \tilde{g}_1 зависит не от положения конкретной точки в пространстве признаков на преды-

дущей итерации (т. е. не от величины $\tilde{g}_1(r)$ и $g_1(r)$), а от окрестности $g_1(r \pm \Delta r)$ в корреляционном поле. Таким образом, на каждой последующей итерации расширяется вовлекаемая в обработку окрестность корреляционных отсчетов, размер которой определяется областью задания применяемых локальных операторов и количеством итераций. Следовательно, происходит более детальный многократный анализ структуры авто- и кросскорреляционных функций, за счет чего повышаются дискриминантные свойства итерационно формируемой системы признаков. Причем определяемый в результате обучения набор коэффициентов (α_n, β_n) обеспечивает адаптацию процесса обработки к особенностям входной информации.

Для иллюстрации предложенного метода синтезированы тестовые корреляционные функции различной формы $g_i^i(r)$, содержащие восемь одинаковых пиков $g_i^i = 50$ с соответствующими им равными высокочастотными составляющими $\tilde{g}_i^i = 20$ (для апостериорной обработки использован оператор Лапласа с областью задания 3×3 элемента), где i — номер корреляционной функции (расознаваемого объекта). Сечение функций $g_i^i(r)$ через центры пиков приведено на рис. 2, а. Поскольку признаки всех восьми объектов попадают в одну

Таблица 1

| n | α_n | β_n | g_n^1 | g_n^2 | g_n^3 | g_n^4 | g_n^5 | g_n^6 | g_n^7 | g_n^8 |
|-----|------------|-----------|-----------------|-----------------|-----------------|-----------------|-----------------|-----------------|-----------------|-----------------|
| | | | \tilde{g}_n^1 | \tilde{g}_n^2 | \tilde{g}_n^3 | \tilde{g}_n^4 | \tilde{g}_n^5 | \tilde{g}_n^6 | \tilde{g}_n^7 | \tilde{g}_n^8 |
| 1 | 0,1 | 1,225 | 50 20 | 50 20 | 50 20 | 50 20 | 50 20 | 50 20 | 50 20 | 50 20 |
| 2 | 0,08 | 0,9 | 50 34 | 50 36 | 50 45 | 50 45 | 50 50 | 50 45 | 50 45 | 50 45 |
| 3 | | | 50 47 | 47 44 | 30 30 | 30 30 | 19 19 | 30 30 | 30 30 | 30 30 |

Таблица 2

| n | α_n | β_n | $\begin{matrix} g_n^1 \\ \tilde{g}_n^1 \end{matrix}$ | $\begin{matrix} g_n^2 \\ \tilde{g}_n^2 \end{matrix}$ | $\begin{matrix} g_n^3 \\ \tilde{g}_n^3 \end{matrix}$ | $\begin{matrix} g_n^4 \\ \tilde{g}_n^4 \end{matrix}$ | $\begin{matrix} g_n^5 \\ \tilde{g}_n^5 \end{matrix}$ | $\begin{matrix} g_n^6 \\ \tilde{g}_n^6 \end{matrix}$ | $\begin{matrix} g_n^7 \\ \tilde{g}_n^7 \end{matrix}$ | $\begin{matrix} g_n^8 \\ \tilde{g}_n^8 \end{matrix}$ |
|-----|------------|-----------|--|--|--|--|--|--|--|--|
| 1 | 0,133 | 1,533 | 50 20 | 50 20 | 50 20 | 50 20 | 50 20 | 50 20 | 50 20 | 50 20 |
| 2 | 0,0465 | 0,581 | 48 33 | 48 33 | 48 43 | 48 43 | 48 48 | 48 43 | 48 43 | 48 43 |
| 3 | 0,0435 | 0,5 | 44 43 | 44 42 | 46 46 | 46 46 | 44 44 | 46 45 | 46 45 | 46 46 |
| 4 | 0,0435 | 0,5 | 42 42 | 42 42 | 46 46 | 46 46 | 42 42 | 45 45 | 45 45 | 46 46 |
| 5 | 0,0435 | 0,5 | 38 38 | 38 38 | 46 46 | 46 46 | 38 38 | 44 44 | 44 44 | 46 46 |
| 6 | 0,0444 | 0,5 | 31 31 | 31 31 | 46 46 | 46 46 | 31 31 | 42 42 | 42 42 | 46 46 |
| 7 | 0,0444 | 0,5 | 21 21 | 21 21 | 47 47 | 47 47 | 21 21 | 39 39 | 39 39 | 47 47 |
| 8 | 0,0444 | 0,5 | 9 9 | 9 9 | 49 49 | 49 49 | 9 9 | 33 33 | 33 33 | 49 49 |
| 9 | | | 1 1 | 1 1 | 53 53 | 53 53 | 1 1 | 24 24 | 24 24 | 53 53 |

точку пространства $\{\tilde{g}_1, g_1\}$, в результате преобразования (1) после первой итерации значения g_2^i для всех объектов остаются одинаковыми. Однако так как окрестности этих пиков различны, становятся различными значения \tilde{g}_2^i , поэтому при переходе к пространству признаков $\{\tilde{g}_2, g_2\}$ соответствующие точки распределяются по линии вдоль оси g_2 .

Рассмотрим пример такого преобразования с коэффициентами $\alpha_1 = 0,1$, $\beta_1 = 1,225$, значения которых выбраны так, чтобы исходная точка в пространстве признаков $\{\tilde{g}_1, g_1\}$ попала на границу раздела областей (2), т. е. после

Таблица 3

| n | α_n | β_n | $\begin{matrix} g_n^1 \\ \tilde{g}_n^1 \end{matrix}$ | $\begin{matrix} g_n^2 \\ \tilde{g}_n^2 \end{matrix}$ | $\begin{matrix} g_n^3 \\ \tilde{g}_n^3 \end{matrix}$ | $\begin{matrix} g_n^4 \\ \tilde{g}_n^4 \end{matrix}$ | $\begin{matrix} g_n^5 \\ \tilde{g}_n^5 \end{matrix}$ | $\begin{matrix} g_n^6 \\ \tilde{g}_n^6 \end{matrix}$ | $\begin{matrix} g_n^7 \\ \tilde{g}_n^7 \end{matrix}$ | $\begin{matrix} g_n^8 \\ \tilde{g}_n^8 \end{matrix}$ |
|-----|------------|-----------|--|--|--|--|--|--|--|--|
| 3 | 0,0444 | 0,511 | 44 43 | 44 42 | 46 46 | 46 46 | 44 44 | 46 45 | 46 45 | 46 46 |
| 4 | 0,0435 | 0,5 | 42 42 | 42 42 | 45 45 | 45 45 | 42 42 | 46 46 | 46 46 | 45 45 |
| 5 | 0,0435 | 0,5 | 38 38 | 38 38 | 44 44 | 44 44 | 38 38 | 46 46 | 46 46 | 44 44 |
| 6 | 0,435 | 0,5 | 31 31 | 31 31 | 42 42 | 42 42 | 31 31 | 46 46 | 46 46 | 42 42 |
| 7 | 0,0444 | 0,5 | 20 20 | 20 20 | 38 38 | 38 38 | 20 20 | 46 46 | 46 46 | 38 38 |
| 8 | | 0,5 | 1 1 | 1 1 | 23 23 | 23 23 | 1 1 | 50 50 | 50 50 | 23 23 |




Рис. 3

преобразования (1) значение g_1^i не изменилось. На рис. 2, *b* представлено сечение функций g_2^i , а на рис. 2, *c* — результаты второй итерации, т. е. сечение функций g_3^i , с $\alpha_2 = 0,08$, $\beta_2 = 0,9$, которые заданы для выделения первого и второго объектов. Соответствующие данные представлены в табл. 1, где в верхнем ряду каждой строки приведены значения функций g_n^i , а в нижнем — \tilde{g}_n^i . Видно, что уже после двух итераций значения признаков первых двух объектов приблизительно в 1,5 раза превышают все остальные.

В процессе обучения последовательность коэффициентов (α_n, β_n) может быть настроена на корреляционные функции другой формы (при равенстве всех g_1^i и \tilde{g}_1^i). Тогда в результате итерационной обработки происходит усиление g_n^i соответствующих объектов. Например, последовательность $\alpha_1 = 0,133, \beta_1 = 1,533; \alpha_2 = 0,0465, \beta_2 = 0,581$ позволяет отобрать группу объектов 3, 4, 6, 7, 8 (вторая и третья строки табл. 2), которая при дальнейшей обработке может быть либо выделена целиком, либо частично (группы 3, 4, 8 или 6, 7). Наборы значений (α_n, β_n) и (g_n, \tilde{g}_n) дальнейших шести итераций для этих двух случаев представлены соответственно в табл. 2 и 3. Отсюда видно, что выбором (за счет обучения) коэффициентов (α_n, β_n) можно в широком диапазоне менять набор выделяемых объектов даже при равенстве соответствующих значений системы признаков на первой итерации.

Блок-схема нейроподобной системы, реализующей предложенный метод, приведена на рис. 3. Как и в [5], она состоит из двух слоев, однако каждый из них обладает другими функциями. В первом осуществляется корреляционная

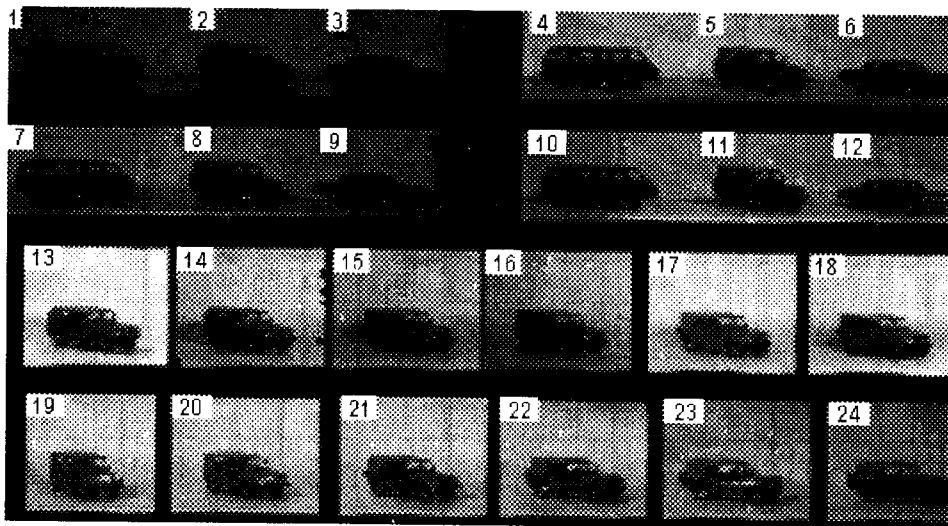


Рис. 4




Рис. 5

обработка для определения исходной системы признаков, а во втором, с элементами нейронной сети, многократно выполняется итерационная процедура (1) с коэффициентами, полученными в результате обучения.

Системы подобной конфигурации могут быть созданы различными способами. Так, в качестве первого слоя, где процесс обработки ведется со скоростью поступления входной информации, т. е., как правило, в телевизионном темпе с числом глобальных связей $(1000 \times 32)^2$ и более без их оперативного (потактового) изменения, целесообразно использовать высокопроизводительные оптико-электронные корреляторы на принципах дифракционной оптики в частично-когерентном свете [6, 7]. Такие гибридные процессоры обеспечивают большую полосу пропускания, инвариантность в широких пределах к про-

Таблица 4

| n | α_n | β_n | ε_n^1 $\bar{\varepsilon}_n^1$ | ε_n^2 $\bar{\varepsilon}_n^2$ | ε_n^3 $\bar{\varepsilon}_n^3$ | ε_n^4 $\bar{\varepsilon}_n^4$ | ε_n^5 $\bar{\varepsilon}_n^5$ | ε_n^6 $\bar{\varepsilon}_n^6$ | ε_n^7 $\bar{\varepsilon}_n^7$ | ε_n^8 $\bar{\varepsilon}_n^8$ | ε_n^9 $\bar{\varepsilon}_n^9$ | ε_n^{10} $\bar{\varepsilon}_n^{10}$ | ε_n^{11} $\bar{\varepsilon}_n^{11}$ | ε_n^{12} $\bar{\varepsilon}_n^{12}$ |
|-----|------------|-----------|--|--|--|--|--|--|--|--|--|--|--|--|
| 1 | 0,105 | 1,079 | 40 19 | 29 11 | 42 20 | 38 19 | 34 12 | 47 21 | 29 13 | 31 10 | 38 15 | 41 15 | 33 7 | 51 26 |
| 2 | 0,133 | 1,0 | 39 31 | 19 16 | 42 31 | 35 27 | 26 21 | 53 43 | 20 16 | 21 16 | 34 20 | 39 31 | 18 14 | 62 50 |
| 3 | 0,071 | 0,661 | 33 27 | 6 5 | 45 36 | 28 22 | 14 12 | 57 46 | 8 6 | 10 8 | 37 28 | 33 27 | 8 6 | 63 49 |
| 4 | 0,065 | 0,597 | 29 25 | 0 0 | 54 47 | 21 18 | 5 4 | 63 50 | 1 0 | 2 1 | 37 31 | 29 25 | 1 1 | 63 49 |
| 5 | 0,067 | 0,583 | 22 20 | 0 0 | 63 58 | 11 10 | 0 0 | 63 51 | 0 0 | 0 0 | 37 33 | 22 21 | 0 0 | 63 47 |
| 6 | 0,08 | 0,5 | 13 13 | 0 0 | 63 61 | 3 3 | 0 0 | 63 51 | 0 0 | 0 0 | 39 38 | 13 13 | 0 0 | 63 55 |
| 7 | | | 6 6 | 0 0 | 63 63 | 0 0 | 0 0 | 63 51 | 0 0 | 0 0 | 57 57 | 6 6 | 0 0 | 63 55 |

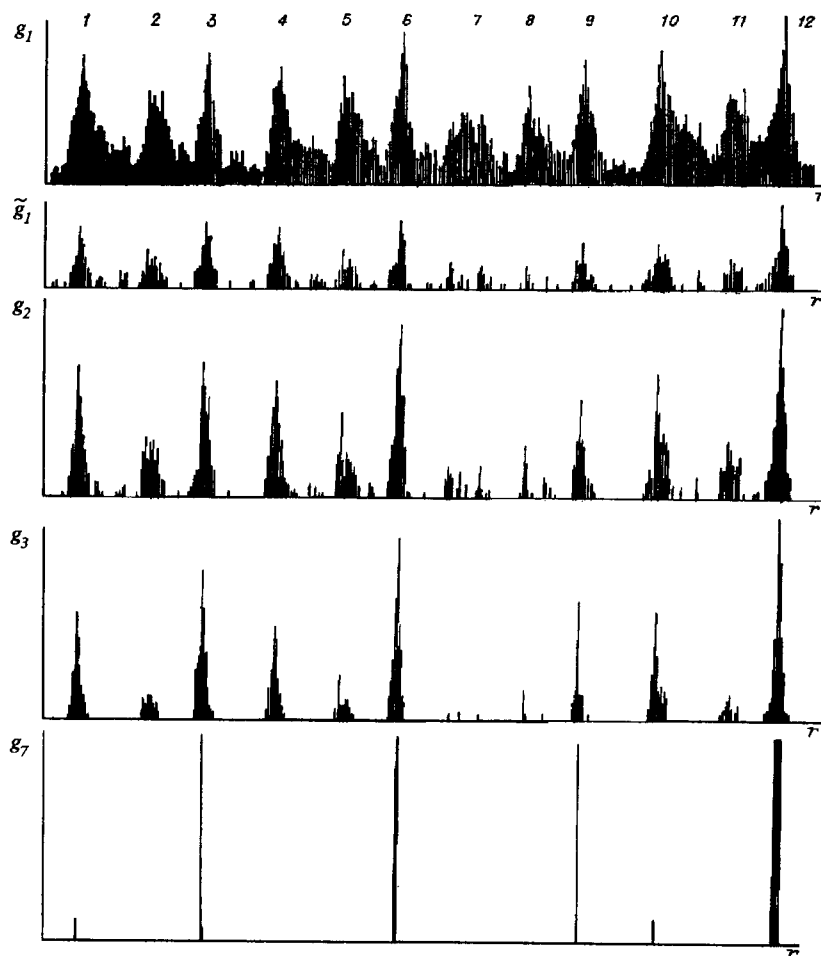


Рис. 6

дольным и поперечным сдвигам оптических элементов и высокие эксплуатационные характеристики [8, 9]. Альтернативные варианты заключаются в применении различного рода цифровых вычислительных систем, в первую очередь параллельных вычислительных сред с сигнально-транспьютерными компонентами [10]. Второй же слой, где выполняются локальная дифференциальная и поточечная нелинейная обработки с коэффициентами (α_n, β_n) , оперативно изменяемыми при необходимости на каждой итерации, наиболее адекватно реализуется цифровыми электронными средствами.

Исследование эффективности предложенного адаптивного метода распознавания проведено путем цифрового моделирования, включая процедуру обучения (определение последовательности коэффициентов α_n, β_n), в режиме обработки малоразмерных изображений реальных объектов трех классов. При этом РИ вводились в компьютер сканирующей камерой на базе фотодиодной линейки при различных условиях освещения и ракурсах. Угол места составлял $\sim 6^\circ$, а дискретность изменения азимутального угла $\sim 12^\circ$. Количество элементов разрешения на один объект не превышало 32×32 .

Для формирования ЭИ использовались четыре изображения каждого класса, зарегистрированные при различных условиях освещения. Они оконтуривались модифицированным оператором Собела [11] с последующей адаптивной пороговой обработкой. Полученные четыре бинарных контура

Таблица 5

| n | α_n | β_n | ε_n^1 $\tilde{\varepsilon}_n^1$ | ε_n^2 $\tilde{\varepsilon}_n^2$ | ε_n^3 $\tilde{\varepsilon}_n^3$ | ε_n^4 $\tilde{\varepsilon}_n^4$ | ε_n^5 $\tilde{\varepsilon}_n^5$ | ε_n^6 $\tilde{\varepsilon}_n^6$ | ε_n^7 $\tilde{\varepsilon}_n^7$ | ε_n^8 $\tilde{\varepsilon}_n^8$ | ε_n^9 $\tilde{\varepsilon}_n^9$ | ε_n^{10} $\tilde{\varepsilon}_n^{10}$ | ε_n^{11} $\tilde{\varepsilon}_n^{11}$ | ε_n^{12} $\tilde{\varepsilon}_n^{12}$ |
|-----|------------|-----------|--|--|--|--|--|--|--|--|--|--|--|--|
| 1 | 0,2 | 1,65 | 33 12 | 38 17 | 21 8 | 32 8 | 35 4 | 24 8 | 37 16 | 34 12 | 21 6 | 34 13 | 44 20 | 27 8 |
| 2 | 0,077 | 0,635 | 31 24 | 33 26 | 13 9 | 30 23 | 36 24 | 17 14 | 33 25 | 34 28 | 13 10 | 32 24 | 44 35 | 22 17 |
| 3 | 0,071 | 0,554 | 29 25 | 33 28 | 5 4 | 27 21 | 38 32 | 8 7 | 32 25 | 34 30 | 5 4 | 30 23 | 58 49 | 14 12 |
| 4 | 0,064 | 0,532 | 27 24 | 35 31 | 0 0 | 23 19 | 46 42 | 2 2 | 32 27 | 37 33 | 0 0 | 28 22 | 63 52 | 6 5 |
| 5 | 0,061 | 0,5 | 22 20 | 37 35 | 0 0 | 15 12 | 63 60 | 0 0 | 30 27 | 41 38 | 0 0 | 23 19 | 63 53 | 1 1 |
| 6 | 0,057 | 0,5 | 14 13 | 41 40 | 0 0 | 6 5 | 63 61 | 0 0 | 27 26 | 50 48 | 0 0 | 15 14 | 63 54 | 0 0 |
| 7 | 0,057 | 0,5 | 5 5 | 48 48 | 0 0 | 1 0 | 63 63 | 0 0 | 20 20 | 63 62 | 0 0 | 6 6 | 63 55 | 0 0 |
| 8 | 0,04 | 0,5 | 0 0 | 63 63 | 0 0 | 0 0 | 63 63 | 0 0 | 11 11 | 63 63 | 0 0 | 1 1 | 63 55 | 0 0 |
| 9 | | | 0 0 | 63 63 | 0 0 | 0 0 | 63 63 | 0 0 | 2 2 | 63 63 | 0 0 | 0 0 | 63 55 | 0 0 |

каждого класса совмещались по центрам масс, после чего элементы ЭИ определялись по совпадению, как минимум, трех соответствующих точек.

В качестве РИ использовалась матрица изображений, приведенная на рис. 4, где два верхних ряда содержат по две тройки объектов каждого класса, третий ряд — шесть изображений второго класса при различных условиях освещенности (одного ракурса), а нижний ряд — шесть изображений того же класса в различных ракурсах (при одинаковых условиях освещения). Все они также оконтуривались модифицированным оператором Собела с последую-

Таблица 6

| n | α_n | β_n | ε_n^{13} $\tilde{\varepsilon}_n^{13}$ | ε_n^{14} $\tilde{\varepsilon}_n^{14}$ | ε_n^{15} $\tilde{\varepsilon}_n^{15}$ | ε_n^{16} $\tilde{\varepsilon}_n^{16}$ | ε_n^{17} $\tilde{\varepsilon}_n^{17}$ | ε_n^{18} $\tilde{\varepsilon}_n^{18}$ | ε_n^{19} $\tilde{\varepsilon}_n^{19}$ | ε_n^{20} $\tilde{\varepsilon}_n^{20}$ | ε_n^{21} $\tilde{\varepsilon}_n^{21}$ | ε_n^{22} $\tilde{\varepsilon}_n^{22}$ | ε_n^{23} $\tilde{\varepsilon}_n^{23}$ | ε_n^{24} $\tilde{\varepsilon}_n^{24}$ |
|-----|------------|-----------|--|--|--|--|--|--|--|--|--|--|--|--|
| 1 | 0,2 | 1,65 | 58 30 | 57 34 | 51 26 | 48 25 | 50 24 | 50 23 | 35 11 | 39 12 | 52 26 | 38 11 | 35 11 | 33 8 |
| 2 | 0,077 | 0,635 | 51 39 | 43 38 | 49 38 | 40 32 | 53 43 | 56 45 | 37 27 | 46 33 | 48 37 | 43 33 | 37 29 | 31 22 |
| 3 | 0,071 | 0,554 | 63 47 | 55 51 | 63 51 | 48 41 | 63 51 | 63 51 | 41 35 | 63 52 | 63 50 | 55 45 | 41 36 | 28 24 |
| 4 | 0,064 | 0,532 | 63 52 | 63 59 | 63 49 | 63 58 | 63 52 | 63 52 | 54 50 | 63 54 | 63 50 | 63 51 | 54 52 | 25 24 |
| 5 | 0,061 | 0,5 | 63 53 | 63 60 | 63 54 | 63 59 | 63 54 | 63 53 | 63 61 | 63 55 | 63 49 | 63 47 | 63 63 | 18 18 |
| 6 | | | 63 54 | 63 62 | 63 55 | 63 61 | 63 55 | 63 55 | 63 62 | 63 55 | 63 55 | 63 55 | 63 63 | 9 9 |

щей бинаризацией адаптивным порогом. Результат предобработки представлен на рис. 5.

Первоначально определялась корреляционная мера близости РИ всех классов (первые две строки на рис. 4) с каждым из трех ЭИ. Этого оказалось достаточно, чтобы распознать изображения первого класса. Однако ни исходная, ни модифицированная системы признаков по отдельности не позволили однозначно распознать все РИ. В качестве примера в верхнем ряду табл. 4 представлены максимальные значения авто- (объекты 3, 6, 9, 12) и кросскорреляционных (остальные объекты) отсчетов и их высокочастотных составляющих для всех 12 изображений с ЭИ третьего класса. Видно, что, пользуясь такими признаками, девятое РИ выделить относительно изображений других классов не удастся. Однако уже после второй итерации происходит разделение сигналов по величине (вторая и третья строки табл. 4), а после шестой кросскорреляционные функции подавляются практически полностью, тогда как автокорреляционные достигают максимума (динамический диапазон составляет 64). Эта же информация в графическом виде (сечения функций $g_1, \tilde{g}_1, g_2, g_3, g_7$ через их условные центры) представлена на рис. 6. В табл. 5 приведены аналогичные данные для ЭИ второго класса, которому соответствуют объекты 2, 5, 8 и 11. В этом случае также не удастся распознать по исходной или модифицированной системам признаков восьмое РИ, однако после восьми итераций осуществляется полное выделение изображений второго класса.

Определенный в процессе обучения (по двум верхним строкам РИ) набор коэффициентов (α_n, β_n) второго класса использовался также при итерационной обработке изображений, представленных в двух нижних строках матрицы (см. рис. 4), согласно процедуре (1). Для РИ различной освещенности (объекты 13—18) это должно привести к выравниванию значений системы признаков и, следовательно, обеспечить инвариантность распознавания изображений к этому фактору. Согласно табл. 6, такой эффект достигнут уже после проведения пяти итераций. Естественно, что для РИ различных ракурсов (объекты 19—24) этого добиться в полной мере не удалось и выравнивание (с усилением) значений системы признаков происходило лишь в определенном угловом диапазоне РИ при их подавлении вне его. Полученные данные (см. табл. 6) позволили определить для заданного угла места и размерности РИ такой диапазон ($\pm 24^\circ$ по азимуту), тогда как после первой итерации он не превышал $\pm 12^\circ$.

Таким образом, в работе предложен адаптивный метод распознавания малоразмерных изображений, основанный на итерационной процедуре определения параметров системы признаков с оперативно перестраиваемыми коэффициентами, полученными в результате обучения. Их выбор позволяет в широком диапазоне менять набор выделяемых объектов даже при равенстве соответствующих значений системы признаков на первой итерации. С помощью цифрового моделирования продемонстрировано значительное повышение дискриминантных свойств формируемой системы признаков за счет более полного использования как значений отсчетов, так и информации о структуре авто- и кросскорреляционных функций. Показана инвариантность метода к различным условиям освещенности распознаваемых изображений. Для конкретного случая определена степень инвариантности процесса распознавания к ракурсным преобразованиям РИ.

СПИСОК ЛИТЕРАТУРЫ

1. Василенко Г. И. Голографическое опознавание образов. М.: Сов. радио, 1977.
2. Гофман М. А., Козик В. И., Потатуркин О. И., Фельдбуш В. И. Распознавание изображений в гибридной оптико-электронной системе с оперативным вводом // Оптико-электронные методы обработки изображений / Под ред. С. Б. Гуревича. Л.: Наука, 1982.
3. Mercle F., Lorch T. Hybrid optical-digital pattern recognition // Appl. Opt. 1984. 23. P. 1509.
4. Потатуркин О. И., Худик В. Н. Апостериорная дифференциальная обработка корреляционной функции // Оптическая и цифровая обработка изображений. Л.: Наука, 1988.

5. Kozik V. I., Potaturkin O. I. Image recognition by means of two-layer holographic neural network // Proc. SPIE. 1994. 2430. P. 27.
6. Василенко Г. И., Цибульский Л. М. Голографические распознающие устройства. М.: Радио и связь, 1985.
7. Potaturkin O. I. Incoherent diffraction correlator with a holographic filter // Appl. Opt. 1979. 18. P. 4203.
8. Козик В. И., Потатуркин О. И. Исследование влияния продольных сдвигов голографического фильтра на взаимный масштаб коррелируемых изображений // Автометрия. 1987. № 2.
9. Козик В. И., Опарин А. Н., Потатуркин О. И. Исследование характеристик голографического коррелятора, сопряженного с видеопроцессором // Автометрия. 1988. № 6.
10. Васьков С. Т., Вьюхин В. Н., Коршевер И. И. Открытые системы реального времени // Информатика и вычислительная техника. 1995. Вып. 1, 2.
11. Прэйт У. Цифровая обработка изображений. М.: Мир, 1982. Т. 2.

Поступила в редакцию 5 декабря 1995 г.
