

И. К. ВАСИЛЬЕВА, А. В. ПОПОВ*Национальный аэрокосмический университет им. Н. Е. Жуковского "ХАИ", Украина***МЕТОД СИНТЕЗА МНОГОКОМПОНЕНТНОЙ МОДЕЛИ
АТРИБУТИВНЫХ ПРИЗНАКОВ ОБЪЕКТОВ**

Предметом изучения в статье являются процессы формирования аналитических описаний атрибутивных признаков объектов для решения прикладных задач статистического распознавания образов объектов на многоканальных изображениях. *Целью* является разработка многокомпонентной математической модели для представления статистической информации о совокупности геометрических, цветовых и структурных параметров объектов наблюдения. *Задачи:* формализовать процедуру статистической сегментации изображения в условиях неполной априорной информации о классах объектов и неизвестных плотностях распределения классификационных признаков; построить эффективные алгоритмы выделения и связывания контурных точек; выбрать универсальную математическую модель для описания геометрической формы объекта и его структурных компонент и разработать робастный метод оценки параметров модели. *Используемыми методами* являются: статистические методы распознавания, методы теории вероятностей и математической статистики, методы контурного анализа, численные методы условной оптимизации. *Получены следующие результаты.* Предложена методика синтеза многокомпонентной модели для описания цветовых, геометрических и структурных атрибутов образов объектов на многоканальных изображениях. В терминах модели объект представляется иерархическим множеством вложенных контуров, для выделения которых используется информация о цветовых признаках статистически однородных областей изображения. Разработаны методы для детектирования и связывания контурных точек, позволяющие получить координаты круговой развертки границ как выпуклых, так и вогнутых геометрических объектов. В качестве универсального базиса для описания компонент модели принято S_V -распределение Джонсона, которое позволяет описывать практически любые унимодальные и широкий класс бимодальных распределений. Приведен метод нахождения оценок параметров распределения Джонсона по выборочным данным, основанный на методе моментов и использующий оптимизационные процедуры при нелинейной целевой функции с ограничениями. *Выводы.* Научная новизна полученных результатов состоит в следующем: получили дальнейшее развитие методы описания образов объектов в виде комбинации нескольких яркостно-геометрических элементов и структурных связей между ними, что позволяет комплексно учитывать атрибутивные признаки объектов в процедурах анализа и интерпретации изображений, автоматического обнаружения и локализации объектов с заданными характеристиками.

Ключевые слова: вероятностный фильтр, цветовая модель, детектирование контурных точек, текстура области, критерий расстояния, распределение Джонсона.

Введение

Выбор признаков объектов распознавания и способа описания признаков во многом определяют эффективность анализа и интерпретации изображений в системах искусственного интеллекта. Этот выбор связан с выделением атрибутов, которые выражают интересующую количественную информацию и являются основой классификации объектов [1–3]. Основными дешифровочными признаками, характеризующими свойства объекта на изображении, являются геометрические (форма, относительные размеры), яркостные (спектральная отражательная способность) и структурные признаки (текстура области, структура объекта). В тех случаях, когда интерес представляют внешние характеристики формы, для представления зрительных образов

используют описание границ областей, соответствующих образам объектов на изображениях. Такой подход обычно предполагает вычисление меры подобия (различия) геометрических форм образов объектов и эталонных фигур. Проблемы реализации робастных алгоритмов распознавания объектов на изображениях по их форме обусловлены искажениями, возникающими при формировании и обработке изображений. К числу основных факторов, влияющих на качество реальных изображений от датчиков и, соответственно, на вероятность обнаружения и распознавания объектов на этих изображениях относятся: шумы и помехи в приёмно-передающих трактах, шумы квантования при оцифровке изображений; эффекты изменения среды между сенсорами и объектами наблюдения (задымление, атмосферные осадки, пыль, искусственные помехи и др.); плохие

условия съемки, недостаточная освещенность или эффекты резкой смены освещения, блики, тени, особенно в динамически меняющихся сценах; искажающие оптические эффекты, ракурсные искажения и др.; сложный текстурированный фон, на котором должно происходить обнаружение объектов; разнообразие или изменчивость самих объектов обнаружения; эффекты заслонения одних объектов другими. Геометрические и проекционные искажения изображений приводят к значительным деформациям контуров образов объектов на снимке, их относительному смещению, перекрытию одних деталей объекта другими, изменениям относительных размеров отдельных деталей и т.п. При этом изменяется вид внешней границы образа объекта, уменьшается степень подобия геометрических форм образа и оригинала, и, соответственно, затрудняется процесс распознавания. Если процедура распознавания основывается на свойствах самой области, например, цвете и текстуре, то ее представляют внутренними характеристиками (т.е. совокупностью элементов изображения, составляющих эту область). На снимке структурные признаки представляют собой сочетание образов объектов и их частей определенной формы, размера и тона (цвета), дополняя его новым свойством – пространственным распределением элементов изображения, их размещением, повторяемостью. Несколько разных структур часто формируют довольно устойчивые сочетания, типичные для определенных объектов; в них находят отражение как природные особенности территории, так и пространственные взаимоотношения объектов антропогенного происхождения.

Таким образом, достоверность распознавания объектов на снимке в решающей степени обусловлена их спектральными свойствами, выраженностью границ, степенью изменчивости, а также наличием устойчивых взаимосвязей с другими объектами. Существенными факторами достоверности результатов являются также качество снимков и эффективность алгоритмов и методов, используемых на всех этапах обработки изображений. Дополнительные возможности для автоматизации обработки изображений и распознавания образов предоставляет их комплексная обработка; при этом для анализа и интерпретации необходимо использовать совместно цветовые, геометрические, текстурные и топологические атрибуты образов объектов на изображениях [4–7].

Целью работы является разработка методики построения CGT² модели (цвет – геометрия – текстура – топология), основанной на представлении образа объекта иерархическим множеством вложенных контуров, для выделения которых используется информация о цвете пикселей изображения.

1. Метод синтеза многокомпонентной модели

Как известно, основными этапами классификации графических объектов являются: сегментация изображения (т.е., выделение фигуры из общей сцены); построение замкнутой границы объекта на бинарном изображении «объект» – «фон»; определение меры подобия для контуров внешней границы объекта и эталона в соответствии с видом математического описания границы и способом использования этого описания в решающих правилах.

Для выделения объекта предлагается использовать метод вероятностной фильтрации [8, 9].

С учетом стохастической природы классификационных признаков \vec{z} , $\vec{z} \in \mathbb{R}^N$ информация о каждом классе объектов содержится в параметрах $\vec{\theta}$ совместных плотностей распределения вероятности (ПРВ) $f_M(\vec{z}; \vec{\theta})$; в предположении гауссова распределения компонент \vec{z}

$$f_M(\vec{z}; \vec{\theta}) = (2\pi)^{-\frac{N}{2}} \cdot (\det \mathbf{R})^{-\frac{1}{2}} \times \exp\{-0,5 \cdot (\vec{z} - \vec{m})^T \cdot \mathbf{R}^{-1} \cdot (\vec{z} - \vec{m})\}, \quad (1)$$

где N – размерность вектора признаков \vec{z} ;

\vec{m} – вектор математического ожидания;

\mathbf{R} – корреляционная матрица компонент \vec{z} .

Для выделения объекта A на фоне других классов необходимо знать только параметры ПРВ класса объекта A , \vec{m}_A и \mathbf{R}_A . Статистические оценки этих параметров находят по классифицированной выборке на этапе обучения. Соответственно, вероятностное окно [8], настроенное на характеристики объекта A примет вид

$$w(\vec{z}) = \exp\{-0,5 \cdot (\vec{z} - \vec{m}_A)^T \cdot \mathbf{R}_A^{-1} \cdot (\vec{z} - \vec{m}_A)\}. \quad (2)$$

Сигнал $y = w(x)$, $y \in [0, 1]$ на выходе вероятностного фильтра, реализующего «вероятностное окно» (2), будет иметь плотность распределения, зависящую как от значения входного сигнала x , так и от степени согласованности параметров его распределения с параметрами фильтра.

Плотность распределения выходного сигнала вероятностного фильтра имеет вид [8]:

$$\rho(y) = \frac{\sigma_W}{\sqrt{2\pi\sigma_A y \sqrt{-2\ln(y)}}} \times \exp\left(-\frac{(m_A - m_W - \sigma_W \sqrt{-2\ln(y)})^2}{2\sigma_A^2}\right) + \frac{\sigma_W}{\sqrt{2\pi\sigma_A y \sqrt{-2\ln(y)}}} \times \exp\left(-\frac{(m_W - m_A + \sigma_W \sqrt{-2\ln(y)})^2}{2\sigma_A^2}\right),$$

где $\{m_A, \sigma_A\}, \{m_W, \sigma_W\}$ – параметры распределения признака объекта и фильтра, соответственно.

При точном согласовании фильтра с параметрами ПРВ признака объекта ($\Delta m = m_A - m_W = 0, \sigma = \sigma_A / \sigma_W = 1$) плотность распределения сигнала на выходе вероятностного фильтра будет иметь вид

$$\rho(y) |_{\Delta m=0, \sigma=1} = \frac{1}{\sqrt{-\pi \ln(y)}}.$$

Наиболее вероятными в этом случае являются максимальные значения выходного сигнала у.

При значительном рассогласовании параметров закон распределения выходного сигнала вырождается в экспоненциальный, и наиболее вероятными являются минимальные значения сигнала на выходе вероятностного фильтра.

При средних значениях рассогласования, например $\Delta m / \sigma = \pm(0.5..1)$, плотность распределения $\rho(y)$ имеет вид арксинуса.

Виды ПРВ $\rho(y)$ в зависимости от степени рассогласования фильтра (2) показаны на рис. 1.

Для измеряемых (первичных) и формируемых (вторичных) многомерных признаков реальных объектов наблюдения характерны негауссовы распределения и наличие взаимных корреляционных связей, поэтому для их математического описания целесообразно применять многопараметрические законы распределения, основанных на нелинейных преобразованиях нормальных случайных величин. За счет большого количества параметров (3...5) такие модели обладают высокой степенью универсальности, а использование нормального закона в качестве базового позволяет не выходить за рамки корреляционной теории.

К числу универсальных вероятностных моделей относится система распределений Джонсона $\{S_L, S_B, S_U\}$ [10].




Рис. 1. Плотность распределения выходного сигнала вероятностного фильтра при точной настройке (1), среднем (2) и сильном (3) рассогласовании

Система распределений Джонсона основана на нелинейных преобразованиях вида:

$$z = \gamma + \eta \cdot \tau(x, \varepsilon, \lambda),$$

обеспечивающих преобразование случайной величины x в случайную величину z с нормальным законом распределения. Преобразование Джонсона имеет два параметра формы (η и γ) и два параметра масштаба (ε и λ); функция $\tau(\bullet)$ определяется типом преобразования.

При $\tau(x, \varepsilon, \lambda) = \ln[(x - \varepsilon) / (\varepsilon - x + \lambda)]$, $\eta > 0$, $\gamma \in (-\infty, +\infty)$, $\lambda > 0$, $\varepsilon \in (-\infty, +\infty)$, $\varepsilon \leq x \leq \varepsilon + \lambda$ плотность распределения случайной величины x имеет вид:

$$f(x) = \frac{\eta \lambda}{\sqrt{2\pi}(x - \varepsilon)(\varepsilon + \lambda - x)} e^{-\frac{1}{2} \left(\gamma + \eta \ln \frac{x - \varepsilon}{\varepsilon + \lambda - x} \right)^2} \quad (3)$$

S_B -распределение Джонсона (3) позволяет аппроксимировать практически любые унимодальные и широкий спектр бимодальных распределений (см. рис. 2).

Для нахождения оценок компонент вектора параметров модели $\bar{\theta} = \{\varepsilon_i, \lambda_i, \eta_i, \gamma_i\}$ можно использовать метод моментов [11], который позволяет составить систему нелинейных интегральных уравнений, связывающих оцениваемые параметры с эмпирическими моментами:

$$\begin{cases} \int_{-\infty}^{\infty} x \cdot f(x; \varepsilon, \lambda, \eta, \gamma) dx = \bar{x}; \\ \int_{-\infty}^{\infty} (x - m_x)^2 f(x; \varepsilon, \lambda, \eta, \gamma) dx = \hat{\sigma}^2; \\ \int_{-\infty}^{\infty} (x - m_x)^3 f(x; \varepsilon, \lambda, \eta, \gamma) dx = \hat{a}; \\ \int_{-\infty}^{\infty} (x - m_x)^4 f(x; \varepsilon, \lambda, \eta, \gamma) dx = \hat{e}, \end{cases} \quad (4)$$

где \bar{x} , $\hat{\sigma}^2$, \hat{a} , \hat{e} – выборочные оценки моментов, которые находятся по экспериментальным данным.




Рис.2. Форма S_B -распределения Джонсона при различных значениях η и γ

Для оценки моментов (4) используют формулы:

$$\hat{m}_k = \frac{1}{N} \sum_{i=1}^N x_i^k; \quad (5)$$

$$\hat{\mu}_k = \frac{1}{N-1} \sum_{i=1}^N (x_i - \hat{m}_x)^k; \quad (6)$$

$$\hat{m}_x \equiv \hat{m}_1 = \bar{x}, \quad \hat{\mu}_2 = \hat{\sigma}^2, \quad \hat{\mu}_3 = \hat{a}, \quad \hat{\mu}_4 = \hat{e}.$$

Поскольку система уравнений (4) не содержит переменных пределов интегрирования, она может быть однозначно решена относительно искомым параметров $\varepsilon, \lambda, \eta, \gamma$ численными методами.

Задачу нахождения корней системы (4) можно сформулировать как оптимизационную. Поскольку в точке $(\varepsilon^*, \lambda^*, \eta^*, \gamma^*)$, соответствующей решению системы (4), правые части уравнений должны быть равны левым, то целевая функция, построенная по методу наименьших квадратов, имеет вид

$$Q(\varepsilon, \lambda, \eta, \gamma) = (m_x - \hat{x})^2 + (\sigma_x - \hat{\sigma})^2 + (a_x - \hat{a})^2 + (e_x - \hat{e})^2 \quad (7)$$

и должна быть минимальна в искомой точке пространства варьируемых переменных $(\varepsilon, \lambda, \eta, \gamma)$.

Для параметров распределения рассматриваемого закона имеется ряд ограничений, которые необходимо учесть в целевой функции (7). В частности, ограничения-неравенства $\lambda > 0, \eta > 0$, которые могут быть учтены с помощью штрафной функции:

$$\psi(\lambda, \eta) = \psi_\lambda(\lambda) + \psi_\eta(\eta), \quad (8)$$

где

$$\psi_\lambda(\lambda) = \begin{cases} 0, & \lambda > 0; \\ |\lambda| \cdot K_1 + K_0, & \lambda \leq 0, \end{cases}$$

$$\psi_\eta(\eta) = \begin{cases} 0, & \eta > 0; \\ |\eta| \cdot K_1 + K_0, & \eta \leq 0, \end{cases}$$

где K_0, K_1 – параметры штрафа.

Если варьируемый параметр находится в пределах области допустимых значений, то штрафная функция (8) равна нулю, иначе – принимает положительное значение и возрастает пропорционально отклонению за допустимые пределы, что определяется коэффициентом K_1 . Так как для параметров λ, η значение нуль также не разрешено, то в штрафную функцию вводится линейное смещение K_0 .

Результирующая целевая функция имеет вид:

$$Q(\varepsilon, \lambda, \eta, \gamma) = (m(\varepsilon, \lambda, \eta, \gamma) - \hat{x})^2 + (\sigma(\varepsilon, \lambda, \eta, \gamma) - \hat{\sigma})^2 + (a(\varepsilon, \lambda, \eta, \gamma) - \hat{a})^2 + (e(\varepsilon, \lambda, \eta, \gamma) - \hat{e})^2 + \psi(\lambda, \eta) \rightarrow \min. \quad (9)$$

Целевая функция (9) имеет овражный рельеф поверхности с изломами за счет ограничений на параметры λ, η (рис. 3). В связи с этим для решения оптимизационной задачи был выбран метод Ро-

зенброка [12], обеспечивающий минимизацию нелинейных унимодальных функций с разрывами производных.

Таким образом, по выборочным данным находят оценки значений $\hat{m}_x, \hat{\sigma}^2, \hat{a}, \hat{e}$ согласно (5), (6), которые используются в качестве начального приближения в целевой функции вида (9), минимум которой соответствует решению системы (4).

Графики ПРВ S_B -распределения Джонсона с тестовыми значениями параметров и их оценками по выборочным данным показаны на рис. 4.

Для более точной аппроксимации формы кривой плотности распределения необходимо уменьшить допустимое значение погрешности определения точки минимума функции (9). Так, например, при заданной точности нахождения оценок параметров $\varepsilon, \lambda, \eta, \gamma \cdot 10^{-3}$ потребуется 20...50 итераций; при этом достигается приемлемая адекватность описания признаков объектов статистическими моделями вида (3).

Модели N-мерных признаков должны описывать как ПРВ отдельных компонент вектора наблюдений, так и корреляционные связи между ними.




Рис. 3. Графическое представление целевой функции $Q(\eta, \gamma | \varepsilon = 0, \lambda = 10)$




Рис. 4. Закон распределения Джонсона: 1 – с тестовыми значениями параметров; 2 – с оценками параметров (при допустимой точности вычислений $\text{err} = 0,1$)

Многомерный вариант распределения (3) имеет вид [13]:

$$f(\vec{x}(t_j)|a) = (2\pi)^{-MN/2} \|\mathbf{R}\|^{-1/2} \times \prod_{j=1}^M \prod_{i=1}^N \left(\frac{\eta_i \lambda_i}{(x_i(t_j) - \varepsilon_i)(\varepsilon_i + \lambda_i - x_i(t_j))} \right) \times \exp \left[-\frac{1}{2} \sum_{j,k=1}^M \sum_{i,l=1}^N \mathbf{R}_{ijkl}^{-1} \left(\gamma_i + \eta_i \ln \frac{x_i(t_j) - \varepsilon_i}{\varepsilon_i + \lambda_i - x_i(t_j)} \right) \times \left(\gamma_l + \eta_l \ln \frac{x_l(t_k) - \varepsilon_l}{\varepsilon_l + \lambda_l - x_l(t_k)} \right) \right], \quad (10)$$

где N – размерность вектора признаков;

M – количество отсчетов;

\mathbf{R} – выборочная корреляционная матрица, элементы которой $\{R_{il}\}_{N \times N}$ определяются так:

$$\hat{R}_{il} = \frac{1}{M} \sum_{j=1}^M x_i(t_j) x_l(t_j).$$

Для выделения объекта в случае негауссова распределения его признака x можно использовать негауссово «вероятностное окно», согласованное по форме с формой ПРВ выделяемого объекта:

$$W(x) = \exp \left\{ -\frac{1}{2} \left[\gamma_W + \eta_W \ln \left(\frac{x - \varepsilon_W}{\lambda_W + \varepsilon_W - x} \right) \right]^2 \right\}, \quad (11)$$

где $\varepsilon_W, \lambda_W, \eta_W, \gamma_W$ – параметры фильтра.

Тогда сигнал y (выход фильтра (11))

$$y = \begin{cases} 0; & x \leq \varepsilon_W; \\ W(x|\varepsilon_W, \lambda_W, \eta_W, \gamma_W); & x \in]\varepsilon_W, \varepsilon_W + \lambda_W[; \\ 0; & x \geq \varepsilon_W + \lambda_W \end{cases}$$

будет иметь плотность распределения, зависящую как от статистических характеристик входного признака объекта, так и степени согласованности параметров его распределения с параметрами фильтра, при этом интервал значений $x \in]\varepsilon_W, \varepsilon_W + \lambda_W[$ образует полосу пропускания вероятностного фильтра, при попадании входного сигнала в которую выходной сигнал фильтра $y > 0$.

Если для описания признаков объектов используются многомерные модели вида (10), то негауссово «вероятностное окно», согласованное по форме с ПРВ выделяемого объекта, будет иметь вид

$$W(\vec{x}) = \exp \left\{ -\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \left[\left(\gamma_i + \eta_i \ln \left(\frac{x_i - \varepsilon_i}{\varepsilon_i - x_i + \lambda_i} \right) \right) \times \mathbf{R}_{ij}^{-1} \left[\gamma_j + \eta_j \ln \left(\frac{x_j - \varepsilon_j}{\varepsilon_j - x_j + \lambda_j} \right) \right] \right] \right\}. \quad (12)$$

В этом случае форма вероятностного фильтра $W(\vec{x})$ зависит не только от параметров ПРВ признаков \vec{x} выделяемого объекта, но и от корреляционной матрицы \mathbf{R} .

В качестве примера на рис. 5 представлены по-

верхности $W(\vec{x})$ в двумерном признаковом пространстве $\vec{x} = \{x_1, x_2\}$ при фиксированных параметрах $\varepsilon_W = 1, \lambda_W = 1, \eta_W = 1, \gamma_W = 1$ и различных значениях коэффициента корреляции r_{12} .

Для статистической сегментации изображения используется решающее правило [8, 9], основанное на отношении правдоподобия:

$$w(\vec{z}^*) \geq 1/\pi. \quad (13)$$

Решающее правило (13) разбивает интервал возможных значений выходного сигнала вероятностного фильтра (7) $P = w(\vec{z}) \in [0, 1]$ на две области:

- $\Gamma_1 \in [1/\pi, 1]$ – область принятия решения о наличии класса объектов, параметры ПРВ которого совпадают с параметрами вероятностного фильтра;
- $\Gamma_2 \in [0, 1/\pi]$ – область принятия решения о наличии неизвестного класса объектов.





Рис. 5. Форма двумерного вероятностного фильтра при коэффициенте корреляции r_{12} компонент \vec{x} :
а – $r_{12} = 0$; б – $r_{12} = -0,8$

Таким образом, для каждого пикселя изображения с пространственными координатами (x_i, y_i) вычисляется значение $P_{i,j}$ – вероятность того, что данный пиксель принадлежит объекту A . После масштабирования диапазона $[0,1] \rightarrow [0,255]$ переходим к полутоновому изображению I_p , на котором «степень подобия» пикселей изображения заданному объекту A показана градациями яркости.

Достоверность идентификации объекта A по правилу (13) зависит от информативности (разделяющих качеств) выбранных признаков \vec{z} . Выбор в качестве вектора \vec{z} цветовых признаков (RGB, HSV и т.п.) позволяет учесть цветовую информацию об объекте и, тем самым, сформировать S -компоненту CGT² модели. При этом если объект характеризуется контрастным по отношению к фону цветом, то удобнее использовать канал цветового тона (H) при представлении изображений в пространстве HSV (hue-saturation-value). Этот канал характеризует цвет точки, но не зависит от ее яркости, и, следовательно, является инвариантным к разностям фотометрических характеристик изображений.

Результаты вероятностной фильтрации $\{P_{i,j}\}_{n_r \times n_c}$ (n_r, n_c – количество строк и столбцов изображения) являются исходными данными для двухэтапной процедуры выделения контурных точек объекта. На первом этапе получают бинарную маску M изображения:

$$M_{i,j} = \begin{cases} 1, & P_{i,j} = P\{(x_i, y_j) \in A\} \geq P_\alpha; \\ 0, & P_{i,j} < P_\alpha, \end{cases} \quad (14)$$

где P_α – заданный порог.

На втором этапе выполняется пороговая фильтрация сегментированного изображения $S = I_p \cdot M$:

$$1) \forall i \in 0..r, j \in 0..c: S_{i,j} = 100, \text{ если } \prod S_{k,l} \neq 0,$$

где (x_k, y_l) – ближайшие соседи пикселя (x_i, y_j) на изображении S ;

$$2) \forall i \in 0..r, j \in 0..c: \text{ если } S_{i,j} = 100, \text{ то } S_{i,j} = 0.$$

Для выделения точек внешнего контура (G -компоненты модели) разработан алгоритм формирования круговой развертки контура с равномерным шагом по углу α [14]. Процедура состоит в последовательном радиальном просмотре элементов бинарной маски M (квадратной $N \times N$ матрицы), центральный элемент которой $M_{N/2, N/2}$ соответствует взвешенному центру тяжести исследуемой фигуры (x_c, y_c) (весовой коэффициент каждого пикселя равен вероятности принадлежности его объекту). Величина N определяется максимальной длиной радиус-вектора круговой развертки

$$N = \lceil \sqrt{2} \cdot d_{\max} \rceil, \quad (15)$$

где $d_{\max} = \max\{d_{i,j}\}$ – наибольшее из расстояний от точки (x_c, y_c) до каждого пикселя выделенной области.

Если требуется построить эталонный контур для объекта на обучающем изображении размером $n_r \times n_c$ (n_r – количество строк, n_c – количество столбцов), значение N находят так:

$$N = 2 \lceil \max\{n_c, n_r\} / \sqrt{2} \rceil + 1. \quad (16)$$

После чего матрицу изображения приводят к квадратной матрице M : $N \times N$, дополняя ее нулевыми столбцами (или строками) симметрично относительно центрального элемента $M_{N/2, N/2}$. Просмотр элементов матрицы M осуществляется вдоль вектора $\vec{\Phi}$, направленного к точке (x_c, y_c) , и составляющего с осью абсцисс угол α . Приращения номеров строк и столбцов для элементов матрицы M определяют в цикле по переменным $\alpha \in 0..360$ и $\rho \in N/2 - 1..0$:

$$\begin{cases} \Delta x = \text{round}(\rho \cos(\alpha)); \\ \Delta y = \text{round}(\rho \sin(\alpha)). \end{cases} \quad (17)$$

При обнаружении первой точки, принадлежащей контуру ($M_{i,j} = 0$), поиск вдоль заданного направления прекращают, сохраняют координаты контурной точки и переходят к очередному значению угла наклона α .

Как показали результаты апробации алгоритма на тестовых геометрических объектах, погрешность восстановления границы значима только для вогнутых участков криволинейных контуров. Эта погрешность может быть скомпенсирована следующим образом.

Выполняют статистический анализ величины расстояний между соседними точками внешнего контура; наличие резких выбросов указывает на несвязные участки границ.

Для каждого k -го несвязного участка, определяемого парой точек $(x_i^{(k)}, y_i^{(k)})$, $(x_{i+1}^{(k)}, y_{i+1}^{(k)})$, рассчитывают K промежуточных точек ξ_k , $k = 1..K$ по координате x , $\xi_k \in [x_i^{(k)}, x_{i+1}^{(k)}]$ и определяют допустимый интервал значений по координате y , $D_y^{(k)} = [\delta y_i^{(k)}, \delta y_{i+1}^{(k)}]$. Из полного множества контурных точек (и внешних, и внутренних) выбирают L_k точек, ближайших к ξ_k (по критерию евклидова расстояния) и находящихся в пределах диапазона $D_y^{(k)}$; эти точки включают в состав множества точек внешнего контура, после чего переходят к следующему несвязному участку в цикле по k .

Изображения тестового объекта A_T и результатов детектирования точек его внешнего контура показаны на рис. 6. Тестовый объект состоит из четырех однородных по признаку «цвет» областей (структурных уровней). Как видно на рис. 6, а, выделенный внешний контур объекта 1-го уровня включает несвязные фрагменты, что обусловлено вогнутостью участков границы объекта.




Рис. 6. Результаты выделения внешней границы тестового объекта:
 а – тестовое изображение; б – начальные массивы контурных точек 1-го структурного уровня;
 в – дополненные массивы контурных точек 1-го уровня; г – граница объекта 1-го уровня

Дополнение множества точек внешнего контура промежуточными контурными точками, расположенными в ближайшей окрестности несвязных участков (рис. 6, б), позволяет получить связную границу объекта (рис. 6, в).

На рис. 7, а – 7, в показаны границы объектов остальных структурных уровней, а на рис. 7, г – результирующая модель объекта.




Рис. 7. Результаты формирования CGT^2 модели тестового объекта:
 а – границы объектов 2-го уровня;
 б – границы объекта 3-го уровня;
 в – границы объектов 4-го уровня;
 г – результирующая модель

Другая причина фрагментированности линий границ и искажения их формы связана с ошибками статистической сегментации изображений, которые приводят к появлению ложных и отсутствию истинных границ (или их фрагментов). Для сглаживания таких искажений предлагается использовать одну из процедур связывания контурных точек, основанных на критерии расстояния между соседними точками контура. Первая процедура состоит в вычислении расстояния $d_{i,i+1}$ между элементами массива контурных точек (x_i, y_i) и (x_{i+1}, y_{i+1}) . Если $d_{i,i+1}$ превышает заданный порог d^* , то координаты точки (x_{i+1}, y_{i+1}) пересчитывают по формуле [14]

$$C'_{i+1} = (nC_{i+1} + C_i)/(n+1), \quad (18)$$

где $C \subseteq \{x, y\}$;

n – количество итераций, потребовавшихся для выполнения условия $d \leq d^*$.

Вторая процедура заключается в вычислении разности расстояний d_1 и d_2 между двумя соседними парами элементов: (x_i, y_i) , (x_{i-1}, y_{i-1}) и (x_i, y_i) , (x_{i+1}, y_{i+1}) массива контурных точек. Если величина $\Delta d = |d_1 - d_2|$ превышает порог, то новые координаты (x_{i+1}, y_{i+1}) находят по формуле [14]

$$C'_{i+1} = (w_2 C_{i+1} + w_1 C_i + w_0 C_{i-1}) / \sum_{j=0}^2 w_j. \quad (19)$$

На рис. 8, 9 представлены этапы построения модели образа объекта А, выделенного на реальном снимке методом вероятностной фильтрации изображения по цветовым признакам $\{H, S\}$.




Рис. 8. Результаты первого этапа формирования CGT^2 модели объекта А:
а – исходное изображение; б – контурные точки

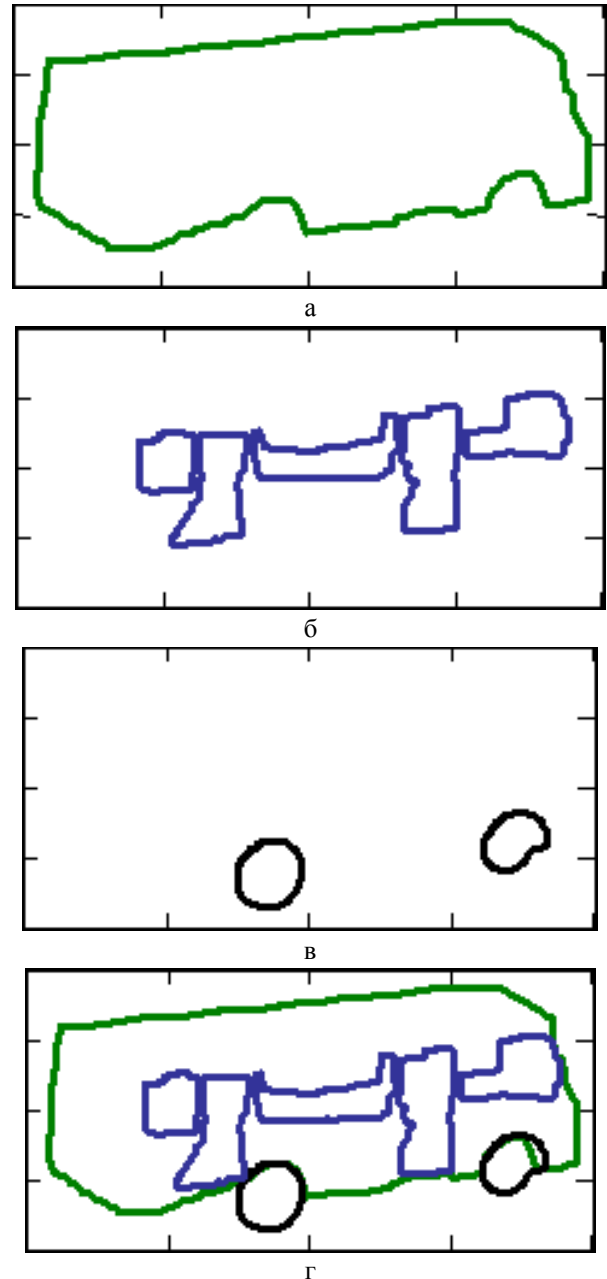


Рис. 9. Результаты последовательного формирования CGT^2 модели объекта А:
а – граница объекта 1-го уровня;
б – границы объектов 2-го уровня;
в – границы объектов 3-го уровня;
г – результирующая модель

В результате работы алгоритмов выделения и связывания контурных точек получают кортеж элементов $\langle \{x_i\}; \{y_i\} \rangle$ – разверток границы объекта по осям в инерциальной декартовой системе координат, помещенной в центр тяжести геометрической фигуры, соответствующей образу объекта.

Преимуществом разработанных алгоритмов является возможность векторизации в автоматическом режиме графических объектов, характеризующихся сложной двумерной формой, и получение

координат зв'язаних контурних точок с равномерной дискретизацией полярного угла $\alpha \in [0, 2\pi]$ при радиальном просмотре пикселей сегментированного изображения. Полученные в результате детектирования и связывания контурных точек данные $\langle\{x_i\}; \{y_i\}\rangle$ можно использовать для формирования параметрической математической модели геометрической формы объектов.

Таким образом, основываясь на информации о статистических характеристиках цветовых признаков объекта можно получить математическое описание внешней границы его образа (геометрической формы объекта) на верхнем уровне топологического представления:

$$M_0 = \{f_M(\bar{z}; \bar{\theta}); \dot{g}(x, y)\}.$$

Последовательное применение рассмотренной выше методики к внутренним элементам структуры образа позволяет сформировать иерархический ряд описаний текстуры для следующих уровней детализации топологии (T^2 -компоненты CGT^2 модели):

$$M_v = \{K_v; f_M^{(k)}(\bar{z}; \bar{\theta}); \dot{g}^{(k)}(x, y) | k = 1 \dots K_v\}, \quad (20)$$

где K_v – количество однородных областей (контуров) на v -м уровне.

2. Метод описания компонент модели

Рассмотрим способ описания геометрической составляющей многокомпонентной модели – внешней границы образа на определенном уровне топологического представления.

Каждая точка (x_k^*, y_k^*) внешнего контура i -го объекта j -го структурного уровня в полярной системе координат описывается длиной радиус-вектора d_k и величиной полярного угла α_k , $\alpha \in [0, 2\pi]$. При этом предполагается, что центр системы координат находится в точке (x_0, y_0) – взвешенном центре тяжести выделенной на изображении области (с учетом вероятности $P_{i,j}$ принадлежности пикселя (x_i, y_i) образу объекта).

Для описания геометрической формы объекта предлагается способ, основанный на статистическом представлении меры отклонения точек внешнего контура от окружности как наиболее сгруппированного объекта на плоскости в евклидовом пространстве. Радиус окружности с центром (x_0, y_0) , описывающей геометрический образ объекта, определяется как $\rho = d_{\max}$, где d_{\max} – максимальное из расстояний от центра до каждого пикселя объекта.

Тогда после нормировки значений

$$\tilde{d}_k = d_k / \max\{d\}, \quad \tilde{d}_k \in (0, 1]$$

можно рассчитать критерий отклонения k -й точки контура от единичной окружности

$$J(k|\alpha_k) = 1 - \tilde{d}_k; \quad \alpha_k \in [0, 2\pi].$$

Конкретные значения критерия $\{J_k\}$ предлагается рассматривать как реализации непрерывной случайной величины $J \in [0, 1]$ (рис. 10).

На рис. 11 – 14 показаны контуры объектов и соответствующие гистограммы критерия J .




Рис. 10. График реализаций критерия J объекта А





Рис. 11. Граница объекта А – «автобус» и гистограмма H_A признака $J(i)|A$





Рис. 12. Граница эталонного объекта Е – «эллипс» и гистограмма H_E признака $J(i)|E$




Рис. 13. Граница эталона R – «прямоугольник» и гистограмма H_R признака $J(i)|R$




Рис. 14. Граница эталона T – «треугольник» и гистограмма H_T признака $J(i)|T$

Степень подобия форм геометрических объектов можно определить по статистическим оценкам коэффициентов асимметрии и эксцесса эмпирического распределения критерия J; это позволит сформировать на их основе вероятностные модели для решения задач распознавания образов. Другим подходом к математическому описанию формы объекта на ν -м структурном уровне является нахождение теоретической плотности распределения вероятности, наилучшим образом аппроксимирующей эмпирическое распределение (гистограмму) критерия J; при этом ПРВ должна быть достаточно универсальной, чтобы адекватно описывать различные виды гистограмм случайной величины J (см. рис. 11 – 14).

Как было показано ранее, для этой цели удобно использовать S_B -распределение Джонсона вида (3). Поскольку минимальное значение критерия J определяет параметр масштаба, то $\varepsilon = 0$ и оцениванию

подлежат три параметра распределения (3); оценки параметров для ряда объектов даны в табл. 1, где приняты обозначения: A – «автобус», T – «треугольник», R – «прямоугольник», E – «эллипс».

Таблица 1

Параметры модели (3) для критерия J

Оценки параметров	A	T	R	E
λ	0,689	0,797	0,598	0,553
η	0,569	0,702	0,407	0,347
γ	-0,399	-0,243	0,285	-0,199

На рис. 15 показаны гистограммы критерия J и аппроксимирующие их статистические модели (3).

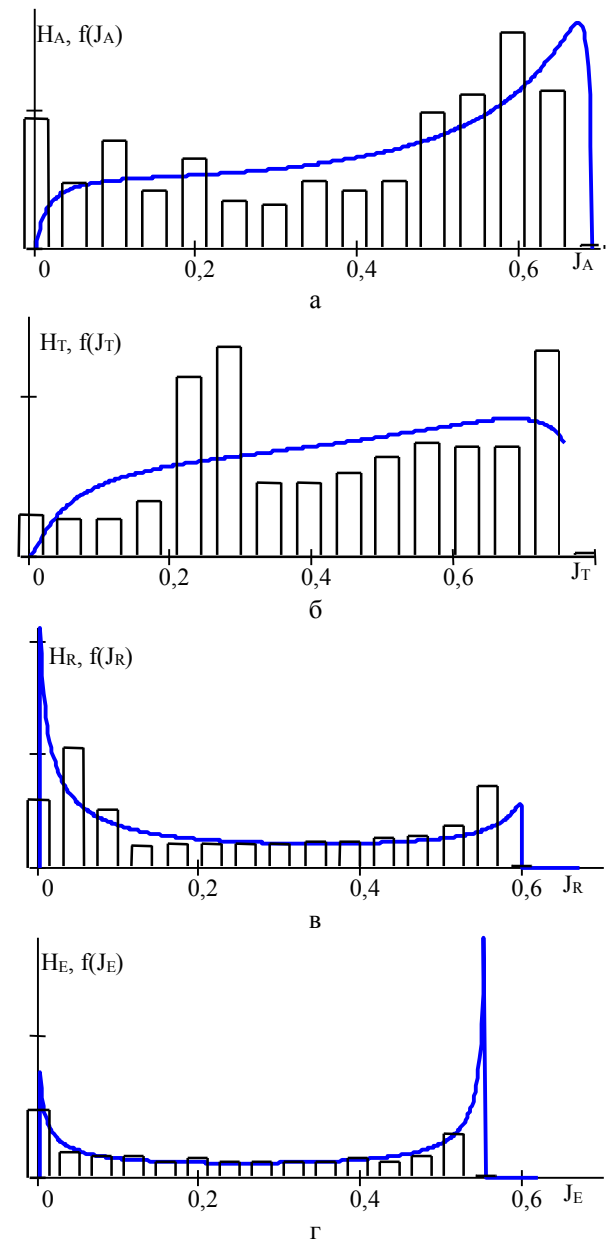


Рис. 15. Гистограммы критерия J и модели (3): а – «автобус», б – «треугольник», в – «прямоугольник», г – «эллипс»

Таким образом, на базе S_V -распределения Джонсона могут быть получены математические описания не только цветовых компонент CGT^2 модели, но и геометрических признаков, описывающих форму статистически однородных по цвету областей на каждом структурном уровне представления образа объекта.

В этом случае в CGT^2 модели (20) вид функции $f_M^{(k)}(\bar{z}; \bar{\theta})$ определяется выражением (3), где $z \equiv J$, $\bar{\theta} = \{\varepsilon_k, \lambda_k, \eta_k, \gamma_k\}$ – вектор оценок параметров S_V -распределения Джонсона, описывающего вероятные значения критерия J для k -го контура объекта на v -м уровне топологии, $k = 1 \dots K_v$.

Разработанные методы описания образов объектов в виде комбинации нескольких яркостно-геометрических элементов и структурных связей между ними позволяют, применительно к конкретной предметной области, решать не только задачи распознавания путем явного или неявного сравнения данного вектора признаков с аналогичными векторами признаков других объектов известных классов, но и такие специфические задачи, как фильтрация, сжатие и сегментация данных, а также задачу автоматического обнаружения и локализации объектов с заданными атрибутивными характеристиками непосредственно в ходе низкоуровневого анализа растровых данных.

Заключение

Выбор признаков для распознавания связан с выделением атрибутов, которые выражают интересующую количественную информацию и являются основой классификации объектов. При разработке эффективных алгоритмов распознавания объектов видеонаблюдения существенную роль играют геометрические, цветовые и структурные характеристики. Для представления характеристик геометрической формы объекта используют описание границы области, соответствующей образу объекта на изображении. Выделение области, соответствующей объекту наблюдения, предлагается выполнять по результатам сегментации изображения с применением вероятностного фильтра, согласованного с параметрами распределения цветовых характеристик данного объекта.

Разработаны методы для детектирования и связывания контурных точек, позволяющие получить координаты круговой развертки границ как выпуклых, так и вогнутых геометрических объектов. Результаты работы алгоритмов можно использовать для формирования параметрических математических моделей геометрических форм самого объекта

и элементов его структуры (текстуры) методами аппроксимации дискретных значений разверток внешнего и внутренних контуров по координатным осям.

Предлагаемый подход позволяет синтезировать многокомпонентные модели атрибутивных признаков объектов в виде иерархической последовательности математических описаний цветовых, геометрических и текстурных признаков для каждого уровня детализации структуры области, соответствующей образу объекта на снимке; при этом показано, что универсальной вероятностной моделью для описания случайных признаков объектов является S_V -распределение Джонсона. Описан метод оценивания параметров распределения Джонсона по выборочным данным, основанный на методе моментов и использующий оптимизационную процедуру для нелинейной целевой функции с ограничениями.

Приведенная методика синтеза многокомпонентной модели позволяет комплексно учитывать цветовые, геометрические и структурные характеристики образов объектов в процедурах анализа и интерпретации изображений.

Литература

1. Sonka, M. *Image Processing, Analysis, and Machine Vision [Text]* / M. Sonka, V. Hlavac, R. Boyle. – CL Engineering, 2014. – 920 p.
2. Bishop, Ch. M. *Pattern Recognition and Machine Learning [Text]* / Ch. M. Bishop. – Springer, 2010. – 738 p.
3. Zheng, N. *Statistical Learning and Pattern Analysis for Image and Video Processing [Text]* / N. Zheng, J. Xue. – Springer, 2009. – 365 p.
4. Nixon, M. *Feature Extraction and Image Processing for Computer Vision [Text]* / M. Nixon. – Academic Press, 2012. – 632 p.
5. Rosenfeld, A. *Digital Picture Processing [Text]* / A. Rosenfeld. – Elsevier, 2014. – 349 p.
6. Sandeep, V. M. *Level sets for real-world object segmentation [Text]* / V. M. Sandeep // *Signal and Information Processing (IConSIP) : Proc. Internat. Conf., Vishnupuri, India, 6-8 Oct. 2016.* – Vishnupuri, 2016. – P. 260 – 265.
7. *Fast Multiregion Image Segmentation Using Statistical Active Contours [Text]* / G. Gao, Ch. Wen, H. Wang, L. Xu // *IEEE Signal Processing Letters.* – 2017. – Vol. 24, Iss. 4. – P. 417 – 421. doi: 10.1109/LSP.2017.2664659.
8. Popov, A. V. *Radar target recognition by probabilistic filtering [Text]* / A. V. Popov, O. Pogrebnyak // *Earth Observing Systems IX : Proc. SPIE.* – 2004. – Vol. 5542. – P. 459 – 467. doi: 10.1117/12.558627.
9. Попов, А. В. *Метод принятия решений при распознавании объектов в условиях существенной априорной неопределенности [Текст]* / А. В. Попов

// *Радиоэлектронні і комп'ютерні системи*. – 2015. – № 3. – С. 53 – 60.

10. Хан, Г. *Статистические модели в инженерных задачах [Текст] / Г. Хан, С. Шапиро – М. : Мир, 1969. – 369 с.*

11. Bendat, J. S. *Random Data: Analysis and Measurement Procedures [Text] / J. S. Bendat, A. G. Piersol. – John Wiley & Sons, 2011. – 640 p.*

12. Шуп, Т. *Решение инженерных задач на ЭВМ: практическое руководство [Текст] / Т. Шуп. – М. : Мир, 1982. – 238 с.*

13. Бабаков, М. Ф. *Об одном способе аппроксимации распределений многомерных поляриметрических характеристик [Текст] / М. Ф. Бабаков // Автоматизированные системы управления : сб. науч. тр. Харьк. авиац. ин-та им. Н. Е. Жуковского. – Вып. 3. – 1981. – С. 166 – 167.*

14. Васильева, И. К. *Выделение внешних контуров объектов распознавания на многоканальных изображениях [Текст] / И. К. Васильева, А. В. Попов // Радиоэлектронні і комп'ютерні системи. – 2017. – № 2 (82). – С. 17 – 23.*

References

1. Sonka, M., Hlavac, V., Boyle, R. *Image Processing, Analysis, and Machine Vision*. CL Engineering, 2014. 920 p.

2. Bishop, Ch. M. *Pattern Recognition and Machine Learning*. Springer, 2010. 738 p.

3. Zheng, N., Xue, J. *Statistical Learning and Pattern Analysis for Image and Video Processing*. Springer, 2009. 365 p.

4. Nixon, M. *Feature Extraction and Image Processing for Computer Vision*. Academic Press, 2012. 632 p.

5. Rosenfeld, A. *Digital Picture Processing*. Elsevier, 2014. 349 p.

6. Sandeep, V. M. *Level sets for real-world object segmentation*. Proc. Internat. Conf. on Signal and Information Processing (IconSIP), Vishnupuri, India, 6-

8 Oct. 2016, pp. 260 – 265.

7. Gao, G., Wen, Ch., Wang, H., Xu, L. *Fast Multiregion Image Segmentation Using Statistical Active Contours*. IEEE Signal Processing Letters, 2017, vol. 24, iss. 4, pp. 417 – 421. doi: 10.1109/LSP.2017.2664659.

8. Popov, A. V., Pogrebnyak, O. *Radar target recognition by probabilistic filtering*. Earth Observing Systems IX, Proc. SPIE, 2004, vol. 5542, pp. 459 – 467. doi: 10.1117/12.558627.

9. Popov, A. V. *Metod prinyatiya reshenii pri raspoznavanii ob"ektov v usloviyakh sushchestvennoy apriorno neopredelennosti [A Decision-Making Method at Recognizing Objects in Conditions of Essential Prior Uncertainty]*. *Radioelektronni i komp'yuterni systemy – Radioelectronic and computer systems*, 2015, no. 3, pp. 53 – 60. (In Russian).

10. Khan, G., Shapiro, S. *Statisticheskie modeli v inzhenernykh zadachakh [Statistical models in engineering problems]*. Moscow, Mir Publ., 1969. 369 p.

11. Bendat, J. S., Piersol, A. G. *Random Data: Analysis and Measurement Procedures*. John Wiley & Sons, 2011. 640 p.

12. Shup, T. *Reshenie inzhenernykh zadach na EVM: prakticheskoe rukovodstvo [Solution of engineering tasks on a computer: a practical guide]*. Moscow, Mir Publ., 1982. 238 p.

13. Babakov, M. F. *Ob odnom sposobe ap-proksimatsii raspredeleniy mnogomernykh polyarimetricheskikh kharakteristik [About one method of multidimensional polarimetric characteristics distributions approximation]*. *Trudy KhAI «Avtomatizirovannye sistemy upravleniya» [Proc. of the KhAI “Automated control systems”]*, 1981, no. 3, pp. 166–167. (In Russian).

14. Vasil'eva, I. K., Popov, A. V. *Vydelenie vneshnikh konturov ob"ektov raspoznavaniya na mnogokanal'nykh izobrazheniyakh [Selection of recognition objects' external contours on multi-channel images]*. *Radioelektronni i komp'yuterni systemy – Radioelectronic and computer systems*, 2017, no. 2 (82), pp. 17 – 23. (In Russian).

Поступила в редакцию 3.05.2018, рассмотрена на редколлегии 16.05.2018

МЕТОД СИНТЕЗУ БАГАТОКОМПОНЕНТНОЇ МОДЕЛІ АТРИБУТИВНИХ ОЗНАК ОБ'ЄКТІВ

І. К. Васильєва, А. В. Попов

Предметом вивчення в статті є процеси формування аналітичних описів атрибутивних ознак об'єктів для вирішення прикладних завдань статистичного розпізнавання образів об'єктів на багатоканальних зображеннях. **Метою** є розробка багатоконпонентної математичної моделі для подання статистичної інформації про сукупності геометричних, колірних і структурних параметрів об'єктів спостереження. **Завдання:** формалізувати процедуру статистичної сегментації зображення в умовах неповної апіорної інформації про класи об'єктів і невідомих щільностей розподілу класифікаційних ознак; побудувати ефективні алгоритми виділення та зв'язування контурних точок; вибрати універсальну математичну модель для опису геометричної форми об'єкта і його структурних компонент і розробити робастний метод оцінки параметрів моделі. Використовуваними **методами** є: статистичні методи розпізнавання, методи теорії ймовірностей і математичної статистики, методи контурного аналізу, чисельні методи умовної оптимізації. Отримані наступні **результати**. Запропоновано методіку синтезу багатоконпонентної моделі для опису колірних, геометричних і структурних атрибутів образів об'єктів на багатоканальних зображеннях. У термінах моделі об'єкт представляється ієрархічною множиною вкладених контурів, для визначення яких використовується інформація про колі-

рні ознаки статистично однорідних областей зображення. Розроблено методи для детектування і зв'язування контурних точок, що дозволяють отримати координати кругової розгортки границь як опуклих, так і увігнутих геометричних об'єктів. В якості універсального базису для опису компонент моделі прийнято S_B -розподіл Джонсона, який дозволяє описувати практично будь-які унімодальні та широкий клас бімодальних розподілів. Наведено метод знаходження оцінок параметрів розподілу Джонсона за вибірковими даними, заснований на методі моментів, що використовує оптимізаційні процедури за нелінійної цільової функції з обмеженнями. **Висновки.** Наукова новизна отриманих результатів полягає в наступному: отримали подальший розвиток методи опису образів об'єктів у вигляді комбінації декількох яскравісно-геометричних елементів і структурних зв'язків між ними, що дозволяє комплексно враховувати атрибутивні ознаки об'єктів в процедурах аналізу та інтерпретації зображень, автоматичного виявлення і локалізації об'єктів із заданими характеристиками.

Ключові слова: імовірнісний фільтр, колірна модель, детектування контурних точок, текстура області, критерій відстані, розподіл Джонсона.

METHOD OF ATTRIBUTE OBJECT SIGNATURES' MULTICOMPONENT MODEL SYNTHESIS

I. K. Vasilyeva, A. V. Popov

The **subject matter** of the article are the processes of forming of objects' attribute features analytical descriptions for solving applied problems of statistical recognition of objects' images on multi-channel images. The **goal** is to develop a multicomponent mathematical model for representing statistical information about the summation of geometric, colour and structural parameters of observational objects. The **tasks** to be solved are: to formalize the procedure of statistical image segmentation in conditions of incomplete a priori information about objects classes and unknown distribution densities of classification characteristics; to build effective algorithms for detection and linking contour points; to choose a universal mathematical model for describing the geometric shape of both the object and its structural components and to develop a robust method for estimating the model parameters. The **methods** used are: statistical methods of pattern recognition, methods of probability theory and mathematical statistics, methods of contour analysis, numerical methods for conditional optimization. The following **results** were obtained. The method of multicomponent model synthesis for describing colour, geometric and structural attributes of object images on multichannel images is proposed. In the model terms, the object is represented by a hierarchical set of nested contours, for the selection of which information about the colour characteristics of statistically homogeneous regions of the image is used. Methods for detecting and linking contour points have been developed, which make it possible to obtain the coordinates of the boundaries circular sweep for both convex and concave geometric objects. As a universal basis for describing the model components, the Johnson S_B distribution is adopted, which allows us to describe practically any unimodal and wide class of bimodal distributions. A method for Johnson distribution parameters' estimation from sample data, based on the method of moments and using optimization procedures for a non-linear objective function with constraints is given. **Conclusions.** The scientific novelty of the results obtained is as follows: the methods for describing the objects' images in the form of a combination of several bright-geometric elements and structural connections between them have been further developed, which makes it possible to comprehensively take into account the attribute features of objects in the procedures for analyzing and interpreting images, automatically detecting and locating objects with specified characteristics.

Key words: probabilistic filter, colour model, contour point detection, area texture, distance criterion, Johnson distribution.

Васильєва Ирина Карловна – канд. техн. наук, доцент, доцент кафедри інформаційно-комунікаційних технологій ім. А. А. Зеленського, Національний аерокосмічний університет ім. Н. Е. Жуковського «Харьківський авіаційний інститут», Харків, Україна, e-mail: i.vasilieva@khai.edu.

Попов Анатолій Владиславович – канд. техн. наук, доцент, доцент кафедри радіоелектронних і біомедицинських комп'ютеризованих засобів і технологій, Національний аерокосмічний університет ім. Н. Е. Жуковського «Харьківський авіаційний інститут», Харків, Україна, e-mail: a.v.popov@khai.edu.

Vasilieva Irina – PhD, docent, associate professor of the Department of Information-Communication Technologies named after O. O. Zelensky, National Aerospace University "Kharkiv Aviation Institute", Kharkiv, Ukraine, e-mail: i.vasilieva@khai.edu.

Popov Anatolii – PhD, docent, associate professor of the Department of Radio-Electronic and Biomedical Computerized Means and Technologies, National Aerospace University "Kharkiv Aviation Institute", Kharkiv, Ukraine, e-mail: a.v.popov@khai.edu.