

УДК 519.67

## ОБНАРУЖЕНИЕ И ОЦЕНКА ПАРАМЕТРОВ ПЕРЕПАДА ЯРКОСТИ В ЗАДАЧЕ КОНТУРНОГО АНАЛИЗА ОБЪЕКТОВ

А. А. Сирота, А. И. Соломатин

*Воронежский государственный университет,  
394006, г. Воронеж, Университетская площадь, 1  
E-mail: sai@cs.vsu.ru*

Синтезируются статистически оптимальный и нейросетевой алгоритмы совместного обнаружения и оценивания параметров перепада яркости в локальном окне наблюдения в интересах решения задачи выделения контура объектов на цифровых изображениях в присутствии шумов. Приводятся сравнительные результаты качества работы этих алгоритмов.

*Ключевые слова:* обработка изображений, идеальный перепад яркости, выделение границ объектов, нейронные сети.

**Введение.** При поиске границ объектов на изображениях, наблюдаемых в присутствии шумов, часто используются последовательные методы обхода контура. При этом общая задача нахождения контура объектов сводится к решению последовательности локальных задач анализа фрагмента границы в пределах небольшого окна (элементарного кадра круглой или квадратной формы) [1, 2], которое перемещается по изображению. Фактически в рамках каждого окна должна решаться задача принятия решения о наличии или отсутствии в нем границы объекта. В случае принятия решения о наличии границы требуется определить положение точек перехода фона в объект — перепад яркости, которым чаще всего и характеризуются границы объектов на изображениях. Для решения данной задачи могут использоваться различные подходы. Например, в [1, 2] форма границы в каждом локальном окне аппроксимируется прямой линией. Определение неизвестных параметров перепада происходит в рамках теории статистических решений на основе минимизации введенного функционала качества. При этом в известных статистических алгоритмах анализа изображений оценка параметров перепада яркости осуществляется в предположении наличия границы в окне анализа, что не всегда отвечает потребностям практики. Перспективным подходом к решению данной задачи представляется также использование нейросетевых алгоритмов обработки информации, которые, как показано в [3], часто обладают большей робастностью по сравнению со статистическими алгоритмами принятия решений.

Таким образом, целью данной работы является синтез и сравнительный анализ статистически оптимальных и нейросетевых алгоритмов совместного обнаружения и оценивания параметров перепада яркости для фрагментов изображений в локальных окнах наблюдения при умеренных и малых отношениях сигнал/шум.

**Модель перепада яркости для алгоритмов обнаружения и оценивания границы.** Нахождение граничных точек объекта возможно с использованием некоторой модели перепада яркости [1, 2]. Идея определения параметров модели перепада яркости, наилучшим образом аппроксимирующего исходное изображение в окрестности некоторой точки, принадлежит Хьюккелю [1]. В рамках данного подхода наблюдаемый участок изображения  $z(x, y)$  сопоставляется с заданной моделью  $S(x, y)$ , включающей перепад яркости.

Минимизируемая функция потерь определяется как

$$E = \int \int [z(x, y) - S(x, y)]^2 dx dy.$$

Будем рассматривать изображение в элементарном окне  $\Omega$ , задаваемом в виде участка квадратной формы размером  $M \times M$ . При этом будем считать, что начало системы координат совпадает с центром окна. Формально идеальный перепад яркости в локальном окне наблюдения  $\Omega$  определяется как

$$S(x, y) = \begin{cases} u, & x \cos \alpha + y \sin \alpha \leq d, \\ u + h, & x \cos \alpha + y \sin \alpha > d, \end{cases} \quad (1)$$

где  $\alpha$  (угол наклона перпендикуляра, проведенного к линии перепада яркости, относительно оси  $X$ ) и  $d$  (расстояние до линии перепада яркости) — величины, определяющие направление и положение перепада соответственно (рис. 1). Для параметров этой модели действуют следующие ограничения:  $\alpha \in [0; 2\pi)$ ,  $d \in [0; D_{\max}]$ , где  $D_{\max} = M/\sqrt{2}$ ,  $u \in [0; U_{\max}]$ ,  $h \in [0; U_{\max} - u]$ . Само наблюдаемое изображение и аппроксимирующая функция удовлетворяют условиям  $z(x, y) \in [0; U_{\max}]$  и  $S(x, y) \in [0; U_{\max}]$ . Угол наклона прямой  $\varphi$  (см. рис. 1) относительно  $\alpha$  выражается как

$$\varphi = \begin{cases} \alpha + \pi/2, & \text{если } \alpha \in [0; 3\pi/2), \\ \alpha - 3\pi/2, & \text{если } \alpha \in [3\pi/2; 2\pi). \end{cases}$$

Наблюдение полезного сигнала осуществляется в присутствии шума

$$z(x, y) = S(x, y) + N(x, y),$$

где  $N(x, y)$  — аддитивный гауссовский белый шум с нулевым математическим ожиданием и корреляционной функцией

$$\langle N(x_1, y_1)N(x_2, y_2) \rangle = \frac{N_0}{2} \delta(x_1 - x_2)\delta(y_1 - y_2)$$

( $N_0$  — односторонняя спектральная плотность белого шума).

При переходе от непрерывного к дискретному представлению задачи случайная величина  $N(x, y)$  будет подчиняться гауссовскому закону распределения с нулевым математическим ожиданием и дисперсией  $\sigma^2 = N_0/2$ .




Рис. 1. Модель ступенчатого идеального перепада яркости

**Постановка задачи совместного обнаружения и оценки параметров перепада яркости.** В рамках статистического подхода задача обнаружения границы фон/объект формулируется как задача выбора из двух альтернативных гипотез [4]:  $H_1$  — в окне наблюдения имеется перепад яркости и  $H_0$  — в окне наблюдения перепада яркости нет.

Определим формально, что считать наличием и отсутствием перепада яркости в окне наблюдения. Для обеих гипотез участок изображения рассматривается в рамках модели идеального перепада яркости (1). Отметим, что перепад яркости должен быть достаточным по уровню, чтобы его можно было считать существенным. Это означает, что фиксируемый перепад должен удовлетворять ограничению  $h \geq h_0$ , где  $h_0$  — некий минимально допустимый уровень перепада. Следующее ограничение касается параметра  $d$ . Допустим, что обнаружен перепад на краю элементарного окна. В этом случае фон (или объект) в окне представлен лишь небольшим участком, поэтому нельзя с уверенностью говорить о наличии границы фон/объект из-за отсутствия информации о перепаде вне рассматриваемого окна. Перепад яркости должен удовлетворять ограничению  $d \leq d_0$ , где  $d_0$  задает максимальное расстояние от центра кадра, на котором фиксируется перепад. Таким образом, под перепадом яркости в рамках модели (1) будем понимать перепад, для которого выполнены естественные ограничения решаемой задачи:  $h \geq h_0$  и  $d \leq d_0$ .

Обозначим все параметры рассматриваемой модели идеального перепада вектором  $\lambda = (u, h, d, \alpha)^T$ ,  $\lambda \in \Lambda = [0; U_{\max}] \times [0; U_{\max} - u] \times [0; D_{\max}] \times [0; 2\pi)$ . Здесь  $\Lambda$  — множество допустимых значений параметра  $\lambda$ . При этом если справедлива гипотеза  $H_1$ , то  $\lambda = \lambda_1 \in \Lambda_1 = [0; U_{\max} - h_0] \times [h_0; U_{\max} - u] \times [0; d_0] \times [0; 2\pi)$ , если же гипотеза  $H_0$ , то  $\lambda = \lambda_0 \in \Lambda_0 = \Lambda \setminus \Lambda_1$ . Примечателен частный случай гипотезы  $H_0$ , если  $h = 0$ , что соответствует однородному изображению в окне наблюдения.

Требуется на основе наблюдения  $z(x, y)$  принять решение в пользу одной из гипотез ( $H_1$  или  $H_0$ ) и определить вектор параметров перепада яркости  $\lambda = (u, h, d, \alpha)^T$ . При этом в нашей задаче значение вектора параметров  $\lambda$  имеет прикладной смысл только для гипотезы  $H_1$ .

Следуя подходу, описанному в [4], можно определить параметр состояния  $\theta$ , принадлежащий дискретному множеству значений  $\theta \in \{\theta_0, \theta_1\}$ . Параметр  $\theta = \theta_0$  в случае гипотезы  $H_0$  и  $\theta = \theta_1$  в случае  $H_1$ . При этом получаем, что составной дискретно-непрерывный вектор состояния  $\gamma = \|\theta, \lambda^T\|^T$ , а задачи различия гипотез и оценки параметров рассматриваются как совместная задача оценки составного вектора  $\gamma$  по наблюдению  $z(x, y)$ . Отметим, что при изменении значения дискретной компоненты  $\theta = \theta_i$  не меняется физический смысл непрерывной компоненты  $\lambda_i$ , меняется лишь область допустимых значений  $\lambda_i \in \Lambda_i$  ( $i \in \{0, 1\}$ ).

**Статистический алгоритм выбора гипотез и оценки параметров перепада.** Следуя методике [2], используем первоначально непрерывное описание наблюдаемого в окне  $\Omega$  изображения

$$z(x, y) = u + hI(x, y) + N(x, y), \tag{2}$$

$$\text{где } (u, h, d, \alpha)^T = \lambda \in \Lambda; I(x, y) = \begin{cases} 0, & x \cos \alpha + y \sin \alpha \leq d, \\ 1, & x \cos \alpha + y \sin \alpha > d. \end{cases}$$

Для решения задачи проверки гипотезы  $H_1$  против альтернативы  $H_0$  будем использовать метод максимального правдоподобия [4, 5]. Решение в пользу одной из гипотез принимается на основе сравнения логарифма функционала отношения правдоподобия (ФОР) с порогом  $c_0$ , определяемым выбранным критерием оптимальности

$$L(z; \lambda_0, \lambda_1) = \ln \Lambda[H_1 | H_0] \underset{H_0}{\overset{H_1}{\geq}} c_0. \tag{3}$$

В [4] приведены выражения для ФОП в случаях, когда при одной из гипотез наблюдаемое поле представляет собой реализацию гауссовского белого шума. Введем вспомогательную гипотезу  $H$ , при которой  $z(x, y) = N(x, y)$ . Очевидно, что ФОП при проверке гипотезы  $H_1$  против альтернативы  $H_0$  есть отношение ФОП при проверке гипотез  $H_1$  и  $H_0$  против простой альтернативы  $H$ , т. е.  $\Lambda[H_1 | H_0] = \Lambda[H_1 | H] / \Lambda[H_0 | H]$ . Следовательно, логарифм ФОП можно представить в виде

$$L(z; \lambda_0, \lambda_1) = \ln \Lambda[H_1 | H] - \ln \Lambda[H_0 | H] = L_1(z; \lambda_1) - L_0(z; \lambda_0), \quad (4)$$

где  $L_i(z; \lambda_i) = \ln \Lambda[H_i | H]$  — логарифм отношения правдоподобия гипотезы  $H_i$  по отношению к вспомогательной гипотезе  $H$  для  $i \in \{0, 1\}$ .

Так как истинные значения параметров  $\lambda_0, \lambda_1$  при выборе гипотез неизвестны, необходимо одновременно производить их оценку. Заменяя значения неизвестных параметров их оценками  $\tilde{\lambda}_0, \tilde{\lambda}_1$  максимального правдоподобия (МП), получаем обобщенный алгоритм МП [4]. При этом необходимо производить максимизацию логарифмов отношения правдоподобия (4) по неизвестным параметрам  $\lambda_0$  и  $\lambda_1$ .

Таким образом, в общем виде алгоритм оценки составного вектора  $\gamma$  запишем как

$$\tilde{\lambda}_i = \arg \sup_{\lambda_i \in \Lambda_i} L_i(z; \lambda_i), \quad i \in \{0, 1\}; \quad \tilde{\theta} = \begin{cases} \theta_1, & L(z; \tilde{\lambda}_0, \tilde{\lambda}_1) \geq c_0, \\ \theta_0, & L(z; \tilde{\lambda}_0, \tilde{\lambda}_1) < c_0. \end{cases} \quad (5)$$

Подставляя выражение (2) для  $z(x, y)$  в соотношение для логарифма ФОП [4], получаем

$$L_i(z; \lambda) = L(z; \lambda) = \frac{1}{2\sigma^2} \left( \int_{\Omega} z^2(x, y) dx dy - \int_{\Omega} (z(x, y) - u - I(x, y, d, \alpha)h)^2 dx dy \right). \quad (6)$$

Примем

$$G(z, \lambda) = \int_{\Omega} (z(x, y) - u - I(x, y, d, \alpha)h)^2 dx dy. \quad (7)$$

Тогда

$$L(z; \lambda_0, \lambda_1) = \frac{1}{2\sigma^2} (G(z, \lambda_0) - G(z, \lambda_1)).$$

Функции  $G(z, \lambda_i)$  являются функциями ошибок аппроксимации наблюдаемого участка изображения моделью перепада с соответствующими параметрами.

Исходя из (6) ФОП  $L_i(z; \lambda_i)$  в (5) достигают своего максимума при условии минимума соответствующих функций ошибок аппроксимации  $G(z, \lambda_i)$ . Поэтому при реализации обобщенного алгоритма МП получаем

$$\tilde{\lambda}_i = \arg \inf_{\lambda_i \in \Lambda_i} G_i(z, \lambda_i), \quad i \in \{0, 1\},$$

$$L(z; \tilde{\lambda}_0, \tilde{\lambda}_1) = L_1(z; \tilde{\lambda}_1) - L_0(z; \tilde{\lambda}_0) = \frac{1}{2\sigma^2} (G(z, \tilde{\lambda}_0) - G(z, \tilde{\lambda}_1)).$$

Обратим внимание на то, что граничные точки пространства значений параметра  $\lambda$  для областей  $\Lambda_0$  и  $\Lambda_1$  (при которых  $h = h_0$  и  $d = d_0$ ) принадлежат области  $\Lambda_1$ . Дополним также множество  $\Lambda_0$  этими точками ( $h = h_0$  и  $d = d_0$ ) и обозначим такое множество

$\bar{\Lambda}_0$ . Функция  $G(z, \lambda)$  содержит в своем составе ступенчатую функцию, которая, вообще говоря, является разрывной и не дифференцируемой непосредственно по параметру  $\lambda$ , однако далее для поиска минимума этой функции будем пользоваться ее непрерывным и дифференцируемым приближением. Тогда полагаем, что функция  $G(z, \lambda)$  непрерывна. В частности, добавление граничных точек к множеству  $\Lambda_0$  не меняет минимума на этом множестве, т. е.

$$\inf_{\lambda_0 \in \Lambda_0} G(z, \lambda_0) = \inf_{\lambda_0 \in \bar{\Lambda}_0} G(z, \lambda_0).$$

Минимумы функций  $G(z, \lambda_i)$  будем искать среди локальных минимумов внутри областей  $\bar{\Lambda}_0$  и  $\Lambda_1$ , а также на их границе (т. е. среди локальных минимумов при  $h = h_0$  и  $d = d_0$ ). Под локальными минимумами понимаются точки, в которых равны нулю производные по всем неизвестным компонентам составного параметра  $\lambda$ .

Для поиска локальных минимумов функции  $G$  внутри областей  $\bar{\Lambda}_0$  и  $\Lambda_1$  введем сигнальную функцию

$$S(x, y) = u + hI(x, y, d, \alpha).$$

Как уже отмечалось,  $G$  содержит ступенчатую функцию, и поэтому невозможно использовать методы дифференцирования для поиска минимума непосредственно  $G$ . Воспользуемся по аналогии с [1, 2] представлением функций  $S$  и  $z$  в виде разложения по усеченному ортонормированному базису  $\Psi_p$  ( $p = \overline{0, 5}$ ):

$$\Psi_0 = 1, \quad \Psi_1 = x, \quad \Psi_2 = y, \quad \Psi_3 = 0,5[x^2 + y^2] - 1, \quad \Psi_4 = 0,5[x^2 - y^2], \quad \Psi_5 = xy.$$

В итоге сигнальную функцию запишем в виде

$$S(x, y) = \sum_{p=0}^5 S_p \Psi_p(x, y). \tag{8}$$

Заданное разложение по ортогональным функциям на окне конечных размеров имеет свои особенности, так как вне окна наблюдения  $S(x, y) = 0$ . Этот факт предполагает необходимость достаточно быстрого спада функции разложения при удалении от центра окна. Для обеспечения этого дополнительно применяется взвешивание функции ошибки, т. е. рассматривается функционал [2]

$$G = \int_{\Omega} Q^2(x, y)(z(x, y) - S(x, y))^2 dx dy,$$

где в качестве весовой функции  $Q$  может быть использована функция вида

$$Q(x, y) = \frac{1}{\sqrt{2\pi}} \exp \left\{ \frac{-(x^2 + y^2)}{4} \right\}.$$

Коэффициенты разложения  $S_p$  по данному базису в (8) имеют следующий вид [2]:

$$\begin{aligned} S_0 &= u + g(h, d), \quad S_1 = \nu \cos \alpha, \quad S_2 = \nu \sin \alpha, \\ S_3 &= \nu d/2, \quad S_4 = \nu d \cos(2\alpha)/2, \quad S_5 = \nu d \sin(2\alpha)/2, \\ \nu &= \frac{h}{\sqrt{2\pi}} \exp \left( -\frac{d^2}{2} \right), \quad g(h, d) = \frac{h}{\sqrt{2\pi}} \int_d^{\infty} \exp \left( -\frac{d^2}{2} \right) dt. \end{aligned}$$

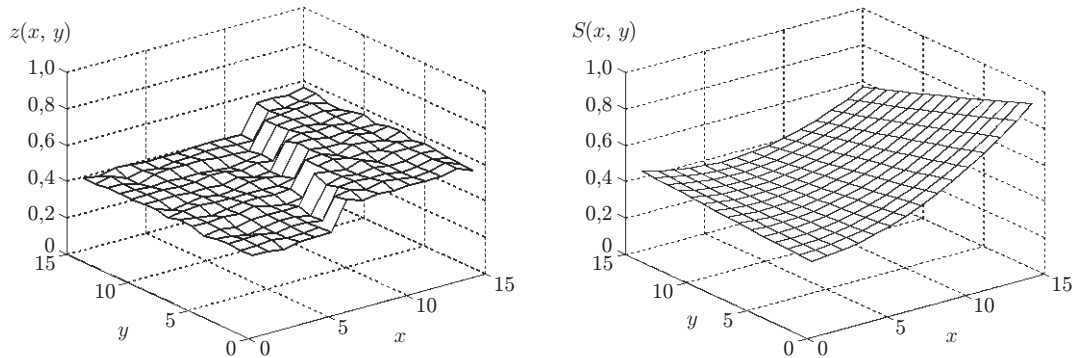


Рис. 2. Ступенчатый перепад яркости и его аппроксимация ( $M = 7,5$ ,  $N = 15$ )

Наблюдаемое поле  $z(x, y)$  также можно представить в виде разложения с коэффициентами

$$Z_p = \int_{\Omega} Q^2(x, y) \Psi_p(x, y) z(x, y) dx dy. \quad (9)$$

При обработке дискретных изображений с шагом дискретизации  $m_0$  соотношение (9) преобразуется к виду

$$Z_p = \sum_{i=1}^N \sum_{j=1}^N I_p(i, j) z(i, j), \quad p = \overline{0, 5}, \quad N = M/m_0,$$

где значения  $I_p(i, j) = \int_{\Omega(i, j)} Q^2(x, y) \Psi_p(x, y) dx dy$  для каждого пиксела  $(i, j)$  в участке изображения  $\Omega(i, j)$  вычисляются заранее и хранятся в виде массива данных, т. е. при переходе от непрерывного представления к дискретному получается участок изображения размером  $N \times N$  пикселей, при этом параметр  $m_0$  выбирается исходя из размеров окна  $\Omega$ . На рис. 2 представлены пример перепада яркости и функция, которая получается при его аппроксимации на основе (8) в виде непрерывной функции относительно параметров  $u, h, d, \alpha$  при  $N = 15$ .

После решения уравнений, полученных путем приравнивания к нулю частных производных функции ошибки по всем параметрам, будем иметь выражения для оптимальных оценок  $u, h, d$  в явном виде [2]:

$$\nu = Z_1 \cos(\alpha) + Z_2 \sin(\alpha), \quad d = (Z_3 + Z_4 \cos(2\alpha) + Z_5 \sin(2\alpha))/\nu,$$

$$h = \sqrt{2\pi} \frac{\nu}{\exp(-d^2/2)}, \quad u = Z_0 - g(h, d).$$

При этом угол  $\alpha$  находится из уравнения 4-й степени вида

$$(4A^2 + C^2) \sin^4(2\alpha) + 2(2AB + CD) \sin^3(2\alpha) + (B^2 - C^2 - 4A^2 + D^2) \sin^2(2\alpha) - 2(AB + CD) \sin(2\alpha) + A^2 - D^2 = 0,$$

где

$$A = 2Z_4Z_5; \quad B = Z_1^2 - Z_2^2 + 2Z_3Z_4; \quad C = 2(Z_4^2 - Z_5^2); \quad D = -2(Z_1Z_2 - Z_3Z_5).$$

Таким образом, алгоритм поиска локальных минимумов  $G$  на всей области определения параметра  $\lambda \in \Lambda$  состоит в вычислении по наблюдаемому фрагменту  $z$  параметров  $Z_p$ ,  $p = \overline{0, 5}$ , и расчете на их основе оценок  $u, h, d, \alpha$ . Уравнение для нахождения  $\alpha$  решается численными методами. В случае если это уравнение имеет несколько решений на интервале  $[0; 2\pi)$ , функция  $G$  имеет несколько локальных минимумов в области  $\Lambda$ .

Особенность решаемой задачи состоит в том, что требуется также анализировать минимумы  $G$  на границе множеств  $\bar{\Lambda}_0$  и  $\Lambda_1$ . Для этого найдем минимум функции  $G$  при  $h = h_0$ . В этом случае приравниваются к нулю производные по остальным параметрам  $u, d, \alpha$ . После решения уравнений получаем

$$u = Z_0 - g(h_0, d), \quad d = d(\alpha) = \frac{Z_2 \cos \alpha - Z_1 \sin \alpha}{Z_4 \sin 2\alpha - Z_5 \cos 2\alpha},$$

где  $\alpha$  находится численным методом (например, методом деления отрезка пополам) из уравнения

$$Z_3 + Z_4 \cos 2\alpha + Z_5 \sin 2\alpha - \frac{h_0}{\sqrt{2\pi}} e^{-(d^2/2)} d = 0,$$

в которое вместо  $d$  при решении подставляется выражение  $d(\alpha)$ .

Для поиска минимума функции  $G$  при  $d = d_0$  приравниваем к нулю производные по  $u, h, \alpha$  и получаем

$$u = Z_0 - g(h_0, d), \quad d = d(\alpha) = \frac{Z_2 \cos \alpha - Z_1 \sin \alpha}{Z_4 \sin 2\alpha - Z_5 \cos 2\alpha},$$

где  $\alpha$  находится численным методом из уравнения

$$Z_1 \cos \alpha + Z_2 \sin \alpha - \frac{h_0}{\sqrt{2\pi}} e^{-(d^2/2)} \left(1 + \frac{d^2}{2}\right) + Z_3 \frac{d}{2} + Z_4 \cos 2\alpha \frac{d}{2} - Z_5 \sin 2\alpha \frac{d}{2} = 0,$$

в которое вместо  $d$  при решении подставляется выражение  $d(\alpha)$ .

Для поиска  $\inf G(z, \lambda_0)$  при  $\lambda_0 \in \bar{\Lambda}_0$  нужно выбрать минимальное значение функции  $G$  из всех локальных минимумов в области  $\bar{\Lambda}_0$  и минимумов при  $h = h_0$  и  $d = d_0$ . Обозначим параметр, при котором достигается этот минимум, как  $\tilde{\lambda}_0$ . Аналогичным образом выбирается значение  $\tilde{\lambda}_1 \in \Lambda_1$ , при котором достигается  $\inf G(z, \lambda_1)$ . Далее полученные обобщенным МП оценки  $\tilde{\lambda}_0$  и  $\tilde{\lambda}_1$  подставляем в выражение для  $L(z; \tilde{\lambda}_0, \tilde{\lambda}_1)$  (5) и после сравнения с порогом  $c_0$  выбираем значение  $\tilde{\theta}$ , принимая решение в пользу одной из гипотез. В случае выбора гипотезы  $H_1$ , т. е. обнаружения перепада, уже имеем оценку параметров перепада в виде  $\tilde{\lambda}_1$ . Таким образом, получен алгоритм совместного обнаружения и оценки параметров перепада яркости, основанный на реализации обобщенного метода МП [4].

**Нейросетевой алгоритм выбора гипотез и оценки параметров перепада.** Для решения поставленной задачи с помощью нейронной сети была рассмотрена аналогичная модель входных данных. Для реализации выбрана нейронная сеть в виде многослойного персептрона. Архитектура сети задавалась из следующих соображений. На вход нейронной сети подается развернутое в вектор изображение окна наблюдения размером  $N \times N$  пикселей ( $N = 15$ ). В окне наблюдения содержится идеальный перепад яркости в рамках модели (1), при этом параметр  $\lambda$  перепада принимает значения и из области  $\Lambda_1$  и из области  $\Lambda_0$ , и в зависимости от этого обучающий пример либо содержит перепад яркости (справедлива гипотеза  $H_1$ ), либо нет (справедлива гипотеза  $H_0$ ). Действует аддитивный

гауссовский шум с указанными характеристиками. На выходе нейронной сети должны получить составной вектор параметров  $\gamma = (\theta, u, h, d, \alpha)^T$ , где  $\theta \in \{0, 1\}$  — номер выбираемой гипотезы;  $u, h, d, \alpha$  — основные параметры модели (1). Используемая нейронная сеть содержала два слоя. В первом слое было двадцать нейронов, во втором — пять. Все искусственные нейроны использовали логистическую функцию активации.

Процесс обучения сети производился в среде Matlab [6]. При обучении каждое изображение, представленное в виде вектора-столбца  $225 \times 1$ , подавалось на вход сети. Яркость элементов изображения нормировалась к диапазону относительных значений от 0 до 1. При этом в качестве целевого вектора принимался составной вектор параметров  $\gamma = (1, u, h, d, \alpha)^T$  для  $H_1$  и  $\gamma = (0, 0, 0, 0, 0)^T$  для  $H_0$ , каждый элемент которого приводился к диапазону  $[0, 1; 0, 9]$ .

Для проведения процедуры обучения было разработано приложение, которое формировало обучающую выборку по определенным диапазонам изменения параметров и шагу перебора значений каждого диапазона, образуя все возможные комбинации заданных значений параметров для каждой из гипотез. На все обучающие изображения добавлялся аддитивный гауссовский шум. Дисперсия шума  $\sigma^2$  принимала значения из множества  $\{(ih/10)^2\}$ , где  $i \in \{1, 2, 3\}$ ,  $h$  — уровень перепада яркости обучающего примера. При формировании целевого вектора для каждого обучающего примера принималось, что пороговые значения различия гипотез равны  $h_0 = 0,1$  и  $d_0 = 0,5N/3 = 2,5$ . Общее количество обучающих выборок составило 54540 образцов. Требуемым значением среднеквадратической ошибки (СКО) было принято 0,001. На ЭВМ с процессором Celeron CPU 2,40 ГГц и 512 Мбайт оперативной памяти продолжительность процедуры обучения составила 12 ч.

**Исследование эффективности работы и примеры обработки реальных изображений статистическим и нейросетевым алгоритмами.** Для сравнения представленных алгоритмов было проведено моделирование их работы. При этом использовались участки изображения размером  $15 \times 15$  пикселей ( $N = 15$ ). Проверка робастности алгоритмов происходила в зависимости от уровня аддитивного шума, а именно от отношения  $h/\sigma$ , которое изменялось в пределах от 0 до 10. Параметры перепада  $u, h, d, \alpha$  выбирались каждый раз случайным образом из области допустимых значений. Для параметров предельных значений фиксации перепада в окне наблюдения задавались  $h_0 = 0,1$  и  $d_0 = 2,5$  (именно для этих значений происходило обучение нейронной сети). При работе




Рис. 3. Зависимости вероятности ошибки в выборе гипотезы  $p$  от отношения  $h/\sigma$  (сплошная линия на графике соответствует статистическому алгоритму, пунктирная — нейросетевому)



статистического алгоритма пороговое значение  $c_0 = 0$ , что соответствует равенству нулю логарифма отношения правдоподобия двух гипотез.

При тестировании вычислялись следующие параметры:  $p$  — вероятность ошибки в выборе гипотезы;  $\varepsilon_u^2, \varepsilon_h^2, \varepsilon_d^2, \varepsilon_\alpha^2$  — СКО определения параметров  $u, h, d$  и  $\alpha$  для гипотезы  $H_1$ . Графики зависимостей этих параметров, полученные в ходе моделирования, приведены на рис. 3 и 4.

По полученным результатам можно сделать вывод, что нейросетевой алгоритм при решении поставленной задачи показывает лучшие результаты по сравнению со статистическим при малых отношениях сигнал/шум. Проигрыш статистического алгоритма в данном случае объясняется использованием приближенной аппроксимации функции  $G$  (7), при которой теряется часть информации, содержащейся в участке изображения. Именно недостаточно точным приближением разложения функций по усеченному ортонормированному базису объясняются большие СКО статистического алгоритма при определении параметров  $u, h, d$  по сравнению с нейросетевым. При решении задачи оценивания наблюдается аналогичная тенденция, однако при оценке углового положения перепада  $\alpha$  имеется выигрыш при применении статистического алгоритма, свидетельствующий о том, что угол поворота при использовании данной аппроксимации перепада достаточно точно




Рис. 4. Зависимости СКО определения параметров от отношения  $h/\sigma$ : параметра  $u$  (a),  $h$  (b),  $d$  (c),  $\alpha$  (d) (сплошная линия на графиках соответствует статистическому алгоритму, пунктирная — нейросетевому)




Рис. 5. Примеры обнаружения перепадов яркости на изображении объекта «эритроцит»: *a* — изображение в присутствии слабых шумов; *b* — результат работы статистического алгоритма в условиях слабых шумов; *c* — результат работы нейросетевого алгоритма в условиях слабых шумов; *d* — изображение в присутствии сильных шумов; *e* — результат работы статистического алгоритма в условиях сильных шумов; *f* — результат работы нейросетевого алгоритма в условиях сильных шумов

выявляется на основе идеальной модели.

Для сравнения результатов работы алгоритмов по реальным изображениям рассматривались изображения объектов микробиологии. В частности, анализировалось изображение эритроцита с различным уровнем шума (рис. 5). При этом изображение обрабатывалось скользящим окном наблюдения размером  $7 \times 7$  пикселей, в рамках которого решался вопрос о наличии или отсутствии перепада яркости. Параметры предельных значений фиксации перепада в окне наблюдения принимались следующими:  $h_0 = 0,2$  и  $d_0 = 0,5N/3 = 1,16$ . В случае наличия перепада в месте его обнаружения рисовалась небольшая черта длиной 3 пиксела. В итоге получалось бинарное изображение перепадов яркости. Какой-либо дополнительной вторичной обработки полученных бинарных изображений не проводилось.

На рис. 5, *b, c* приведены результаты работы алгоритмов для случая слабых шумов ( $h/\sigma = 6,0$ ), на рис. 5, *e, f* — для случая сильных шумов ( $h/\sigma = 1,4$ ), присутствующих на изображении объекта. Для предложенного нейросетевого алгоритма с использованием того же принципа были получены результаты обработки предварительно зашумленного тестового изображения «Лена» (рис. 6).



Рис. 6. Пример работы нейросетевого алгоритма при поиске перепадов яркости на реальном изображении: *a* — обрабатываемое зашумленное изображение, *b* — обнаруженные перепады яркости

**Заключение.** В представленной работе рассмотрены два подхода к решению задачи совместного обнаружения и оценивания параметров перепада яркости применительно к задаче контурного анализа изображений, основанные на реализации статистически оптимальных и нейросетевых алгоритмов. С точки зрения достоверности обнаружения границы и точности оценивания ее параметров в локальных фрагментах изображений оба подхода к решению задачи показали примерно одинаковые результаты. Использование синтезированного статистически оптимального алгоритма оказалось весьма затратным с точки зрения потребляемого времени обработки. Нейросетевой алгоритм более эффективен в применении. К его достоинствам можно отнести высокую скорость работы по сравнению со статистическим алгоритмом при достаточно эффективном функционировании в условиях малых по уровню шумов. К недостаткам нейросетевого алгоритма обработки информации следует отнести необходимость долгого предварительного обучения при фиксированных параметрах задачи, например такого, как размер анализируемого участка изображения.

### СПИСОК ЛИТЕРАТУРЫ

1. **Хюккель М.** Оператор нахождения контуров на кодированных изображениях // Интегральные роботы. М.: Мир, 1973.
2. **Перов А. И., Соколов Г. Г.** Алгоритм последовательного выделения контура объекта на двумерных цифровых изображениях // Радиотехника. 1998. № 7.
3. **Сирота А. А., Кирсанов Э. А., Маслов О. В.** Нейросетевые и статистически оптимальные алгоритмы принятия решений в задачах высокоточной координатометрии и обработки изображений // Тр. III Междунар. конф. «Идентификация систем и задач управления». М.: ИПУ РАН, 2004.
4. **Трифонов А. П., Шинаков Ю. С.** Совместное различение сигналов и оценка их параметров на фоне помех. М.: Радио и связь, 1986. 264 с.
5. **Крянев А. В., Лукин Г. В.** Математические методы обработки неопределенных данных. М.: ФИЗМАТЛИТ, 2003. 216 с.
6. **Осовский С.** Нейронные сети для обработки информации: Пер. с пол. М.: Финансы и статистика, 2002. 344 с.

*Поступила в редакцию 30 января 2009 г.*

---