

## ВЫДЕЛЕНИЕ ТРЕХ УРОВНЕЙ ЯРКОСТИ НА ЗАШУМЛЕННОМ ИЗОБРАЖЕНИИ

А. В. Лихачев<sup>1</sup>

Предложен новый метод восстановления изображений, имеющих три неизвестные градации яркости. Для их определения используются фрагменты изображения, гистограммы которых согласуются с заданным распределением шума. Далее все пиксели распределяются по найденным уровням яркости посредством бинарной классификации. Выполнен вычислительный эксперимент, по результатам которого оказалось, что ошибка оценки исходных яркостей не превысила 3%. При относительно низком уровне шума доля неверно классифицированных пикселей от их общего числа составила менее 0.006.

**Ключевые слова:** восстановление изображений, проверка статистических гипотез, бинарная классификация.

**1. Введение.** В приложениях часто возникает задача выделения на зашумленном изображении множества пикселей, имеющих в отсутствие шума определенные яркости [1, 2]. Она является частным случаем классификации — бинарной, когда рассматривается одно значение яркости, или многоклассовой, если таких значений несколько. Первая из них к настоящему времени достаточно хорошо изучена [3, 4]. Наиболее простой является классификация по одному признаку. В настоящей статье таковым является яркость, которая определяется следующим образом. Сопоставим имеющемуся изображению функцию  $G(i, j)$ , заданную на сетке, каждый узел которой взаимно однозначно связан с некоторым пикселем. Пусть ее значение в узле с индексами  $i, j$  ( $1 \leq i \leq i_{\max}$ ,  $1 \leq j \leq j_{\max}$ ) равно  $x_{i,j}$ . Яркостью соответствующего пикселя назовем величину  $I(x_{i,j})$ , где  $I(x)$  — известное неубывающее преобразование, т.е.  $I(x_1) \leq I(x_2)$ , если  $x_1 < x_2$ .

На практике широко используются байесовские классификаторы (см., например, [5]). В частности, в [6] приводится описание такого классификатора для изображения, состоящего из объекта и фона с яркостями  $I(a)$  и  $I(b)$  соответственно. К объекту относятся те фрагменты, средняя яркость которых не меньше величины  $I(x_{th})$ . При этом значение порога  $x_{th}$  для нормально распределенного шума выражается как

$$x_{th} = \frac{\sigma^2}{a-b} \ln(\eta) + \frac{N}{2} (a+b). \quad (1)$$

Здесь  $\sigma^2$  — дисперсия шума;  $N$  — количество пикселей, составляющих фрагмент. Критерий отношения правдоподобия  $\eta$  имеет вид

$$\eta = \frac{P_{об} L_{2,1} - L_{2,2}}{P_{бк} L_{1,2} - L_{1,1}}, \quad (2)$$

где  $P_{об}$  и  $P_{бк}$  — вероятности того, что взятый фрагмент является частью объекта и фона соответственно. Второе отношение в (2) характеризует потери классификатора (подробности см. в [6]). Коэффициенты  $L_{p,q}$  находятся исходя из конкретных условий, часто с применением обучения.

Исходя из (1), можно заключить, что для реализации байесовского классификатора изображения требуется, чтобы были известны яркости выделяемых уровней. В противном случае необходимо получить их оценки. Решение этой задачи и является основной целью предлагаемой работы. Рассматривается изображение, имеющее три градации  $I_1, I_2$  и  $I_3$  (причем  $I_1 < I_2 < I_3$ ), на которое наложен аддитивный шум. При этом предполагается наличие следующей априорной информации: для каждого уровня яркости имеется оценка количества составляющих его пикселей; шум является некоррелированным, а функция его плотности известна с точностью до параметров.

<sup>1</sup> Институт автоматизации и электрометрии СО РАН (ИАЭ СО РАН), просп. Коптюга, 1, 630090, г. Новосибирск; ст. науч. сотр., e-mail: ipm1@iae.nsk.su

**2. Описание метода.** Пусть  $\hat{n}_1, \hat{n}_2, \hat{n}_3$  — оценки количества пикселей исходного изображения с яркостями  $I_1, I_2, I_3$ . Положим, что  $G(i, j)$  имеет три значения:  $x_1, x_2, x_3$  и  $I_1 = I(x_1), I_2 = I(x_2), I_3 = I(x_3)$ . Проведем разбиение на  $K$  прямоугольных фрагментов  $D_k$ . Предположим, что характер изображения таков, что часть из них имеет постоянную яркость. В дальнейшем такие фрагменты будут обозначаться через  $D_k^1, D_k^2$  и  $D_k^3$  в соответствии со значениями  $I_1, I_2, I_3$ . Наложение аддитивного шума означает, что в каждом узле к функции  $G(i, j)$  добавляется реализация случайной величины  $\xi$ , имеющей непрерывное распределение с функцией плотности  $f_\xi(t)$ . Будем считать, что математическое ожидание  $\xi$  равно нулю. Тогда нетрудно видеть, что значения  $x_{i,j} = G(i, j) + \xi_{i,j}$  в узлах сетки, связанных с пикселями фрагмента  $D_k^l$  ( $l = 1, 2, 3$ ), являются выборкой случайной величины с функцией плотности  $f_\xi(t - x_l)$ . В связи с этим для нахождения  $D_k^l$  предлагается для всех фрагментов провести проверку статистической гипотезы о принадлежности выборки заданному распределению.

Возьмем для определенности нормально распределенный шум. В этом случае

$$f_\xi(t - \mu) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{(t - \mu)^2}{2\sigma^2}\right). \tag{3}$$

Поскольку наличия информации о дисперсии шума не предполагается, неизвестными в (3) являются  $\mu$  и  $\sigma$ . В настоящей работе гипотезы проверялись по критерию Пирсона. Суть проверки, применительно к данному случаю, заключается в следующем [7]. Область значений величин  $x_{i,j}$  в рассматриваемом фрагменте разбивается на  $M$  интервалов. Пусть  $\nu_1, \dots, \nu_M$  — частоты попаданий в эти интервалы,  $\hat{P}_1, \dots, \hat{P}_M$  — оценки вероятностей попадания в те же интервалы, вычисленные по распределению (3), причем его параметры  $\mu$  и  $\sigma$  определяются по тем же  $x_{i,j}$ . Для этого здесь использовался метод максимального правдоподобия [7], который дает

$$\mu = \frac{1}{N} \sum_{D_k} x_{i,j}, \quad \sigma = \sqrt{\frac{1}{N} \sum_{D_k} (x_{i,j} - \mu)^2}. \tag{4}$$

В (4) суммирование ведется по узлам сетки, связанным с пикселями, составляющими фрагмент  $D_k$  (их число равно  $N$ ).

Далее вычисляется величина

$$Z = N \sum_{m=1}^M \frac{(\nu_m - \hat{P}_m)^2}{\hat{P}_m}.$$

Если выполняются определенные условия, то при  $n \rightarrow \infty$  величина  $Z$  имеет  $\chi^2$  распределение с  $M - 3$  степенями свободы. Чтобы использовать  $Z$  в качестве критерия, выбирается достаточно малая вероятность  $p$  и вычисляется соответствующий квантиль  $z_{th}(p)$ , принимаемый за пороговое значение, также называемое  $100p$ -процентным уровнем значимости отклонения выборки от распределения. При этом  $p$  является вероятностью события  $z_{th}(p) \leq Z$ :

$$P(z_{th}(p) \leq Z) = \int_{z_{th}(p)}^{\infty} f_{\chi^2}(t) dt = p. \tag{5}$$

Здесь  $f_{\chi^2}(t)$  — функция плотности распределения  $\chi^2$ . Если выполняется неравенство  $z_{th}(p) > Z$ , то гипотеза принимается. В противном случае она отклоняется.

Пусть гипотеза оказалась принятой для  $K_0 \geq 3$  фрагментов. Для каждого из них известно среднее значение  $\mu_k$ . Расположим эти  $\mu_k$  по возрастанию. Получившийся упорядоченный массив разделим на три части пропорционально числам  $\hat{n}_1, \hat{n}_2, \hat{n}_3$ . В частности, если  $\hat{n}_1 \approx \hat{n}_2 \approx \hat{n}_3$ , т.е., если все уровни яркости занимают на изображении примерно одинаковые площади, то к первой группе мы отнесем  $K_0/3$  начальных элементов массива, ко второй — следующие  $K_0/3$  элементов, остальные помещаются в третью группу. Обозначим средние значения  $\mu_k$  в каждой из групп через  $\bar{\mu}_1, \bar{\mu}_2$  и  $\bar{\mu}_3$ , а соответствующие им яркости примем за оценки неизвестных величин  $I_1, I_2, I_3$ . Таким образом решается первая часть задачи.

На втором этапе разработанного метода проводится классификация пикселей — определяется их принадлежность какому-либо из найденных уровней. Сначала обрабатываются те  $K_0$  фрагментов, для которых подтвердилась гипотеза. Пусть рассматривается фрагмент, для которого  $\mu_k$  принадлежит первой группе. Являясь суммой нормально распределенных случайных величин,  $\mu_k$  тоже имеет нормальное распределение. Его дисперсия  $\sigma_\mu^2$  оценивается как  $\sigma^2/N$ , где  $\sigma$  вычисляется по формуле (4). За математическое ожидание примем  $\bar{\mu}_1$ . Тогда с большой вероятностью должно выполняться неравенство

$|\mu_k - \bar{\mu}_1| \leq 3\sigma_\mu$ . Если это действительно так, то полагается, что фрагмент принадлежит первому уровню. Поэтому всем его пикселям приписывается яркость  $I(\bar{\mu}_1)$ . В противном случае считается, что фрагмент отнесен к уровню ошибочно, и в дальнейшем он обрабатывается так же, как и те, для которых гипотеза не подтверждена. Для фрагментов из двух других групп проводятся аналогичные процедуры.

Чтобы разделить оставшиеся пиксели, используется подход, когда многоклассовая классификация сводится к бинарной [8]. Здесь этот подход был реализован следующим образом. Вычислялись два пороговых значения  $x_{th1}$  и  $x_{th2}$  (причем  $x_{th1} < x_{th2}$ ). Пиксели с яркостями из интервалов  $]-\infty; x_{th1}[$ ,  $]x_{th1}; x_{th2}[$ ,  $]x_{th2}; \infty[$ , относились к уровням  $I(\bar{\mu}_1)$ ,  $I(\bar{\mu}_2)$  и  $I(\bar{\mu}_3)$  соответственно.




Рис. 1. Модельное изображение без шума (а) и с шумом  $\sigma = 0.1$  (б)

Величины  $x_{th1}$  и  $x_{th2}$  определялись из условия минимальности суммы вероятностей ошибок первого и второго рода, как это было сделано ранее для бинарных изображений [9, 10]. Получающиеся при этом выражения для нормально распределенного шума являются частным случаем (1):

$$x_{th1} = \frac{\hat{\sigma}^2}{\bar{\mu}_2 - \bar{\mu}_1} \ln \left( \frac{1 - \hat{P}_2}{\hat{P}_2} \right) + \frac{1}{2} (\bar{\mu}_2 + \bar{\mu}_1),$$

$$x_{th2} = \frac{\hat{\sigma}^2}{\bar{\mu}_3 - \bar{\mu}_2} \ln \left( \frac{1 - \hat{P}_3}{\hat{P}_3} \right) + \frac{1}{2} (\bar{\mu}_3 + \bar{\mu}_2).$$

Здесь  $\hat{P}_2$  и  $\hat{P}_3$  — оценки вероятностей того, что произвольно взятый пиксель принадлежит второму и третьему яркостному уровню соответственно;  $\hat{\sigma}$  получается путем усреднения оценок (4) для  $K_0$  фрагментов, где была подтверждена гипотеза.

**3. Вычислительный эксперимент.** Разработанный алгоритм исследовался путем вычислительного эксперимента. Изучалось влияние дисперсии шума  $\sigma^2$  на точность оценок исходных яркостей и на качество классификации. Шум предполагался аддитивным, с равным нулю математическим ожиданием и имеющим в каждом пикселе нормальное распределение. Использовалось изображение с разрешением  $640 \times 490$ , которое представлено на рис. 1а. Значения функции  $G(i, j)$ , соответствующие уровням яркости, равны  $x_1 = 0$ ,  $x_2 = 1.0$ ,  $x_3 = 1.3$ . Число пикселей, составляющих каждый из уровней:  $n_1 = 112116$  (35.75%),  $n_2 = 101349$  (32.32%),  $n_3 = 100135$  (31.93%). В скобках указаны процентные отношения  $n_l / (n_1 + n_2 + n_3)$ ,  $l = 1, 2, 3$ . На рис. 1б приведено изображение с наложенным на него шумом, абсолютное значение стандартного отклонения которого  $\sigma$  равно 0.1.

Изображение разбивалось на  $64 \times 49$  квадратных фрагментов по 100 пикселей в каждом. Вероятность  $p$  при проверке статистической гипотезы о принадлежности выборки распределению бралась равной 0.05. Исходя из соотношений чисел  $n_1$ ,  $n_2$  и  $n_3$ , вероятности для произвольного пикселя принадлежать заданному яркостному уровню полагались равными, т.е.  $\hat{P}_1 = \hat{P}_2 = \hat{P}_3 = 1/3$ . Ошибки оценок значений  $x_1$ ,  $x_2$  и  $x_3$  вычислялись по формулам  $\delta_l = |x_l - \bar{\mu}_l| / x_2$ ,  $l = 1, 2, 3$ . Таким образом, нормировка проводилась на значение, соответствующее второму уровню. Точность восстановления  $l$ -го уровня определялась нормированными ошибками первого и второго рода:

$$\Delta_{1,l} = \frac{1}{n_l} \sum_{(i,j) \in S_l} \gamma_l(i, j), \quad \Delta_{2,l} = \frac{1}{n_l} \sum_{(i,j) \in S_l} \gamma_l^*(i, j). \quad (6)$$

В (6) для ошибки  $\Delta_{1,l}$  суммирование ведется по пикселям, принадлежащим на модельном изображении уровню с яркостью  $I(x_l)$ , а для  $\Delta_{2,l}$  — по пикселям, не принадлежащим ему. Функция  $\gamma_l(i, j)$  принимает значение 0, если  $\hat{G}(i, j) = \bar{\mu}_l$ , и 1 в противном случае. Напротив,  $\gamma_l^*(i, j) = 1$ , если  $\hat{G}(i, j) = \bar{\mu}_l$ , и  $\gamma_l^*(i, j) = 0$ , если  $\hat{G}(i, j) \neq \bar{\mu}_l$ . Здесь  $\hat{G}(i, j)$  — функция, связанная с изображением, полученным в результате классификации пикселей по яркости (она может быть равна  $\bar{\mu}_1, \bar{\mu}_2$  или  $\bar{\mu}_3$ ). Ошибка  $\Delta_{1,l}$  показывает относительное количество пикселей, первоначально имеющих яркость  $I(x_l)$ , которые не были идентифицированы. Ошибка  $\Delta_{2,l}$  выражает отношение числа пикселей, которым была неверно, приписана яркость  $I(\bar{\mu}_l)$  к числу  $n_l$ .

На рис. 2 приведены зависимости ошибок  $\delta_l$  от значения  $\sigma$ , выраженного в абсолютных единицах (таким образом, в частности,  $\sigma = 1.3$  равно максимальному значению функции  $G(i, j)$ ). Кривые 1, 2, 3 показывают поведение  $\delta_1, \delta_2, \delta_3$  соответственно. Из рисунка, в первую очередь, видно, что полученные оценки амплитуд уровней  $\bar{\mu}_l$  близки к их истинным значениям  $x_l$ . Ошибка не превосходит трех процентов от величины  $x_2$ . Кроме того, можно заключить, что в рассмотренном интервале, относящемся к области слабого и умеренного шума, ошибки практически не зависят от его дисперсии. Это связано с тем, что при данных условиях гипотеза о принадлежности распределению выполняется более чем для двух тысяч двухсот фрагментов. Поэтому  $\bar{\mu}_l$  являются средними достаточно больших выборок, из-за чего шум оказывает слабое влияние на их значения. Осцилляции кривых вызваны случайными причинами, в том числе индивидуальными свойствами модельного изображения.




Рис. 2. Зависимости ошибки оценки яркости уровней от стандартного отклонения шума

На рис. 3 показаны зависимости ошибок первого и второго рода, см. (6), от  $\sigma$ . Рис. 3а–3с относятся к пикселям с исходными яркостями  $I(x_1), I(x_2), I(x_3)$  соответственно. Кривые 1 и 2 являются графиками функций  $\Delta_{1,l}$  и  $\Delta_{2,l}$ ,  $l = 1, 2, 3$ . Наблюдается естественный рост ошибок с увеличением дисперсии шума.




Рис. 3. Зависимости ошибок первого и второго рода от стандартного отклонения шума при определении областей первого (а) второго (б) и третьего (в) уровней яркости

При этом  $\Delta_{1,1}$  и  $\Delta_{2,1}$  оказались в среднем почти на два порядка ниже, чем остальные ошибки. Причина состоит в том, что разность  $x_2 - x_1$  значительно больше, чем  $x_3 - x_2$ . Поэтому вероятность правильной классификации пикселей, принадлежащих первому уровню, выше.

Влияние вероятности  $p$  (см. формулу (5)) на точность оценки величин  $x_1, x_2, x_3$  иллюстрирует рис. 4. Стандартное отклонение шума составляет 0.1. На приведенном графике по оси ординат откладывается ошибка  $\delta$ , которая вычисляется для используемых на практике значений  $p$ , равных 0.1, 0.05, 0.025, 0.01, 0.005 и 0.001. Кривые 1, 2, 3 соответствуют зависимостям  $\delta_1(p), \delta_2(p), \delta_3(p)$ . Согласно рис. 4, при всех  $p$  ошибка по-прежнему не превосходит трех процентов от величины  $x_2$ . Таким образом, для вычислений может быть использовано любое из приведенных выше значений.

На рис. 5а и 5б представлены изображения, восстановленные предлагаемым методом. Для рис. 5а величина  $\sigma$  равна 0.1, т.е. реконструкция проводится из зашумленного изображения, показанного на рис. 1б. Для рис. 5б стандартное отклонение шума вдвое больше:  $\sigma = 0.2$ . По этим рисункам видно, что при умеренном шуме качество восстановления достаточно высокое. В частности, различимы все малоразмерные элементы, присутствующие на модельном изображении.

**4. Заключение.** В настоящей статье предложен метод восстановления изображений, имеющих три уровня яркости, после наложения на них аддитивного шума. При этом предполагается, что исходные яркости неизвестны. Чтобы их найти, изображение разбивается на фрагменты и для каждого проверяется гипотеза о принадлежности яркостей составляющих его пикселей к сдвинутому распределению шума. Неизвестные значения определяются путем усреднения по тем фрагментам, для которых гипотеза подтверждается. Далее, с применением двух бинарных классификаторов, все пиксели разделяются на три группы и, в соответствии с принадлежностью к определенной группе, каждому приписывается одна из найденных яркостей.

Был выполнен вычислительный эксперимент, показавший, что при умеренно интенсивном шуме ошибка оценок яркостей уровней не превосходит 3%. Проведенная классификация пикселей по уровням так же дала хороший результат. В частности, для шума со стандартным отклонением  $\sigma \leq 0.05$  (что приблизительно соответствует 3.5% от максимальной яркости исходного изображения) число ошибочно классифицированных пикселей было менее пятисот при общем их количестве более чем 310 тысяч.




Рис. 5. Результаты восстановления модельного изображения:  $\sigma = 0.1$  (а);  $\sigma = 0.2$  (б)




Рис. 4. Зависимости ошибки оценки яркости уровней от вероятности  $p$

## СПИСОК ЛИТЕРАТУРЫ

1. Потатов А.А., Пахомов А.А., Никитов С.А., Гуляев Ю.В. Новейшие методы обработки изображений. М.: Физматлит, 2008.
2. Дабагов А.Р., Малютина И.А., Филлист С.А. Системы искусственного интеллекта для рентгенологических исследований в цифровой медицине. Курск: Университетская книга, 2019.
3. Голубков А.М. Бинарная классификация изображений на примере задачи распознавания лиц // Известия СПбГЭТУ ЛЭТИ. 2018. № 7. 26–30.
4. Румянцев А.А., Миняев Р.Ш., Дыганов С.А., Голованов Р.А., Перухин М.Ю. Оценка влияния размера архитектуры нейросети на скорость обучения в задаче бинарной классификации // Вестник Технологического университета. 2018. **21**, №8. 124–127.
5. Айвазян С.А., Бухштабер В.М., Енюков И.С., Мешалкин Л.Д. Прикладная статистика: классификация и снижение размерности. М.: Финансы и статистика, 1989.
6. Грузман И.С., Киричук В.С., Косых В.П., Перетягин Г.И., Спектор А.А. Цифровая обработка изображений в информационных системах. Новосибирск: Изд-во НГТУ, 2002.
7. Пугачев В.С. Теория вероятностей и математическая статистика. М.: Физматлит, 2002.
8. Карасиков М.Е., Максимов Ю.В. Поиск эффективных методов снижения размерности при решении задач многоклассовой классификации путем ее сведения к решению бинарных задач // Машинное обучение и анализ данных. 2014. **1**, № 9. 1273–1290.
9. Лихачев А.В. Томографическая реконструкция области, имеющей заданное значение плотности // Вычислительные методы и программирование. 2018. **19**, № 4. 516–521.
10. Лихачев А.В. Модифицированный метод обнаружения мелких структур на зашумленных изображениях // Автометрия. 2019. **55**, № 6. 55–63.

Поступила в редакцию  
2 марта 2020

---

### Allocation of Three Brightness Levels on a Noisy Image

A. V. Likhachov<sup>1</sup>

<sup>1</sup>*Institute of Automation and Electrometry, Siberian Branch of Russian Academy of Sciences; Koptuyug prospekt 1, Novosibirsk, 630090, Russia; Dr. Sci., Senior Scientist, e-mail: ipm1@iae.nsk.su*

Received March 2, 2020

**Abstract:** A new recovery method for images with three unknown brightness levels is proposed. In order to determine these levels, we use the image fragments whose histograms correspond to a given noise distribution. All pixels are distributed over the found brightness levels by a binary classification. The numerical results show the error in the estimate of the original brightnesses is no more than 3%. When the noise level is relatively low, the fraction of wrong classified pixels in their total amount is less than 0.006.

**Keywords:** image reconstruction, verification of statistical hypotheses, binary classification.

### References

1. A. A. Potapov, A. A. Pakhomov, S. A. Nikitov, and Yu. V. Gulyaev, *Novel Methods of Image Processing* (Fizmatlit, Moscow, 2008) [in Russian].
2. A. R. Dabagov, I. A. Malyutina, and S. A. Filist, *Artificial Intelligence Systems for X-Ray Examinations in Digital Medicine* (Universitetskaya Kniga, Kursk, 2019).
3. A. M. Golubkov, “Face Recognition Using Images Binary Classification Methods,” *Izv. Saint Petersburg Elettrotekh. Univ.*, No. 7, 26–30 (2018).

4. A. Rumyantsev, R. Minyazev, S. Dyganov, et al., "Assessment of the Influence of the Neural Network Architecture Size on the Training Rate in the Problem of Binary Classification," *Vestn. Tekhnol. Univ.* **21** (8), 124–127 (2018).
5. S. A. Aivazian, V. M. Buchstaber, I. S. Yenyukov, and L. D. Meshalkin, *Applied Statistics. Vol. 3: Classification and Reduction of Dimensionality* (Financy i Statistika, Moscow, 1989) [in Russian].
6. I. S. Gruzman, V. S. Kirichuk, V. P. Kosykh, et al., *Digital Processing of Images in Information Systems* (Novosibirsk Gos. Tekh. Univ., Novosibirsk, 2002) [in Russian].
7. V. S. Pugachev, *Theory of Probability and Mathematical Statistics* (Nauka, Moscow, 2002) [in Russian].
8. M. E. Karasikov and Y. V. Maximov, "Dimensionality Reduction for Multi-Class Learning Problems Reduced to Multiple Binary Problems," *Mashinnoe Obuchenie Analiz Danykh* **1** (9), 1273–1290 (2014).
9. A. V. Likhachov, "Tomographic Reconstruction of a Region with a Given Density Value," *Vychisl. Metody Programm.* **19**, 516–521 (2018).
10. A. V. Likhachev, "Modified Method for Detecting Small Structures in Noisy Images," *Avtometriya* **55** (6), 55–63 (2019) [*Optoelectr., Instrum. Data Process.* **55** (6), 580–586 (2019)].