

АНАЛИЗ И СИНТЕЗ СИГНАЛОВ И ИЗОБРАЖЕНИЙ

УДК 004.932

МОДИФИЦИРОВАННЫЙ МЕТОД ОБНАРУЖЕНИЯ
МЕЛКИХ СТРУКТУР НА ЗАШУМЛЁННЫХ ИЗОБРАЖЕНИЯХ

© А. В. Лихачев

*Институт автоматизи и электрометрии СО РАН,
630090, г. Новосибирск, просп. Академика Коптюга, 1
E-mail: ipm1@iae.nsk.su*

Предложен классификатор, ориентированный на работу с фрагментами изображения размером 1 пиксель. Разделение элементов на объект и фон проводится по апостериорным вероятностям, при расчёте которых используется гистограмма. Вычислительный эксперимент показал, что разработанный алгоритм осуществляет более точную классификацию по сравнению с разделением по порогу яркости, определяемому из условия минимальности взвешенной суммы ошибок первого и второго рода.

Ключевые слова: классификатор элементов изображения, апостериорные вероятности.

DOI: 10.15372/AUT20190607

Введение. Рассматривается задача поиска на полутоновых изображениях структур, имеющих малый размер. Если требуется только улучшить их визуальную различимость, используются разные фильтры. Ввиду практической значимости вопросы фильтрации широко освещены в литературе, например [1, 2]. В случае когда известны размеры элементов, видимость которых следует повысить, могут быть также применены методы кратномасштабного анализа на основе вейвлетных базисов [3, 4]. Однако, если целью ставится автоматическое обнаружение объектов определённого типа, в последовательность операций обработки должен быть включён классификатор. В данном контексте классификатор — это процедура, определяющая принадлежность рассматриваемого фрагмента изображения объекту интереса. Разработке и изучению классификаторов, а также методов фрагментации изображений посвящён ряд работ [5–8].

Самым простым, а при отсутствии дополнительной информации и наиболее естественным способом фрагментации является деление изображения на равные сегменты. При этом, если речь идёт об изучении тонкой структуры, сегменты следует брать достаточно малыми, в частности, они могут быть равны 1 пикселю. Разработка классификаторов, оперирующих мелкой фрагментацией изображения, осложняется тем, что признаки классов, связанные со статистическим усреднением, часто проявляются слабо. В связи с этим вероятность ошибки классификации оказывается весьма высокой.

Фрагменты полутоновых изображений, как правило, классифицируются по яркости. Под этой характеристикой здесь понимается следующее. Сопоставим с изображением функцию, заданную на сетке, каждый узел которой однозначно связан с определённым пикселем. Пусть её значение в узле, заданном индексами i и j , равно $x_{i,j}$. Яркостью определённого пикселя назовём величину $I(x_{i,j})$, где $I(x)$ — известное преобразование.

Предположим, что имеется изображение с двумя градациями яркости. Ему соответствует функция G , принимающая два значения, которые в дальнейшем будут обозначаться как a и b (причём $b < a$) и называться амплитудами объекта и фона. Пусть ξ — случайная

функция (шум) с непрерывным распределением значений. Сумма $G + \xi$ задаёт некоторое полутоновое изображение. Ставится задача восстановления по нему оригинального (бинарного) изображения с возможно большей точностью. В работе [9] приводится следующее её решение: к объекту относятся те фрагменты, суммарная яркость которых не меньше величины $I(x_0)$. При этом значение порога x_0 для нормального распределения шума выражается как

$$x_0 = \frac{\sigma^2}{a-b} \ln(\eta) + \frac{N}{2} (a+b). \quad (1)$$

Здесь σ^2 — дисперсия шума; N — количество пикселей, составляющих фрагмент. Критерий отношения правдоподобия

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

где P_{ob} и P_{bk} — вероятности того, что взятый фрагмент является частью объекта и фона соответственно. Второе отношение в (2) характеризует потери классификатора [9]. Значения коэффициентов $L_{i,j}$ находятся исходя из конкретных условий, часто с применением обучения.

Предположим, что структура исследуемого объекта такова, что её некоторые элементы отделены друг от друга расстоянием в 1 пиксель. Для того чтобы их различить, фрагмент также должен быть равен 1 пикселю. Описанный классификатор применим и в случае, если в формуле (1) положить $N = 1$. Однако из-за предельно малого размера фрагмента качество такой классификации может оказаться низким. В данной работе предлагается модифицированный классификатор, ориентированный на попиксельный анализ изображения. В нём помимо яркости для разделения пикселей по классам используется апостериорная вероятность. Обращаем внимание на то, что здесь не имеется в виду классификация на основании совокупности двух признаков. Как будет видно из дальнейшего изложения, в разработанном алгоритме часть пикселей классифицируется по яркости, а часть — в соответствии с апостериорной вероятностью.

Пусть яркость некоторого пикселя зашумлённого изображения лежит в интервале $\langle I \rangle$. Полная вероятность такого события

$$P(\langle I \rangle) = P_{ob}P(\langle I \rangle/ob) + P_{bk}P(\langle I \rangle/bk), \quad (3)$$

где $P(\langle I \rangle/ob)$ и $P(\langle I \rangle/bk)$ — условные вероятности того, что пиксель имеет значение яркости из $\langle I \rangle$, если он является частью объекта и фона соответственно. Вероятность того, что рассматриваемый пиксель принадлежит объекту при условии нахождения его яркости в интервале $\langle I \rangle$, называется апостериорной и определяется по формуле [10]

$$P(ob/\langle I \rangle) = P_{ob}P(\langle I \rangle/ob)/P(\langle I \rangle). \quad (4)$$

В разработанном методе предлагается оценивать $P(\langle I \rangle)$ по гистограмме. Тогда признак (4) будет вычисляться уже не по свойствам одного пикселя, поскольку гистограмма содержит информацию обо всём изображении.

Резюмируем сказанное выше: целью данного исследования является разработка классификатора для изображений, имеющих мелкомасштабную структуру, повышение точности которого обеспечивается за счёт использования апостериорных вероятностей (4).

Описание алгоритма. Поскольку распределение элементов объекта не предполагается равномерным по изображению, целесообразно разбить последнее на области и проводить анализ каждой из них в отдельности. На первом этапе разработки алгоритма исключаются области, предположительно занятые только фоном. Пусть \bar{I}_k — средняя яркость пикселей в k -й области. Обозначим через n_k количество пикселей в ней, а через $n_{k,ob}$ — число принадлежащих объекту. Если n_k достаточно велико, а математическое ожидание шума равно нулю, то

$$\bar{I}_k \approx (n_{k,ob}I(a) + (n_k - n_{k,ob})I(b))/n_k. \quad (5)$$

Здесь $I(a)$ и $I(b)$ — яркости объекта и фона соответственно. Из (5) получаем

$$\frac{n_{k,ob}}{n_k} \approx \frac{\bar{I}_k - I(b)}{I(a) - I(b)}. \quad (6)$$

Пусть n_{\min} — минимальный размер (в пикселях) участка объекта, значимый в контексте рассматриваемой задачи, в частности, может быть $n_{\min} = 1$. В дальнейшую обработку берутся те области, для которых правая часть (6) больше либо равна отношению n_{\min}/n_k . Само выражение (6) будем рассматривать как оценку вероятности того, что произвольный пиксель, взятый из k -й области, принадлежит объекту. Обозначим её через $\hat{P}_{k,ob}$.

На втором этапе пиксели каждой из отобранных областей делятся по значению яркости на три группы. Для этого используются две пороговые величины: $I(x_{k,\min})$ и $I(x_{k,\max})$. Если яркость пикселя меньше $I(x_{k,\min})$, то он относится к фону, если же она больше $I(x_{k,\max})$, то к объекту. Пиксели третьей группы с яркостями из интервала от $I(x_{k,\min})$ до $I(x_{k,\max})$ классифицируются по апостериорной вероятности. Основания для такого деления заключаются в следующем. Пиксели объекта и фона с близкими вероятностями попадают в яркостный интервал $\langle I \rangle$, для которого близки $P(\langle I \rangle/ob)$ и $P(\langle I \rangle/bk)$. Поэтому подобрать величину порога (1) для классификации таких пикселей без обучения затруднительно. В этом случае имеет смысл использовать разделение по другому признаку. Яркости $I(x_{k,\min})$ и $I(x_{k,\max})$ можно рассматривать как границы, в которые укладывается интервал $\langle I \rangle$. Их введение необходимо, поскольку значения гистограммы при высоких и низких яркостях малы и, как правило, содержат существенные ошибки, что приводит к неверным оценкам апостериорных вероятностей.

Подобно тому, как это было сделано в [11], величины $x_{k,\min}$ и $x_{k,\max}$ определяются из условия минимальности взвешенной суммы вероятностей ошибок первого и второго рода: $P_{err1} + \alpha P_{err2}$. Здесь положительный коэффициент α характеризует относительную значимость ошибок второго рода. Пусть разделяющая яркость равна $I(x_{th})$. Рассмотрим некоторый пиксель из k -й области. Вероятность принадлежности пикселя объекту оцени-

вается как $\hat{P}_{k,ob}$, а то, что он будет отнесён к фону, равна $P_1 = \int_{-\infty}^{x_{th}} f_{\xi}(x - a) dx$, где $f_{\xi}(x)$ — плотность распределения шума. Таким образом, имеем $P_{err1} = \hat{P}_{k,ob}P_1$. Аналогично находим выражение для P_{err2} . В конечном итоге x_{th} получается путём минимизации функции

$$P_{err} = P_{err1} + \alpha P_{err2} = \hat{P}_{k,ob} \int_{-\infty}^{x_{th}} f_{\xi}(x - a) dx + \alpha(1 - \hat{P}_{k,ob}) \int_{x_{th}}^{+\infty} f_{\xi}(x - b) dx. \quad (7)$$

Для определённости будем считать, что шум имеет нормальное распределение. Приравняв производную по x_{th} от (7) к нулю, после простых преобразований имеем

$$x_{th} = \frac{\sigma^2}{a-b} \ln \left(\frac{\alpha(1 - \hat{P}_{k,ob})}{\hat{P}_{k,ob}} \right) + \frac{1}{2}(a+b). \quad (8)$$

Выражение (8) совпадает с (1), при этом отношение $(L_{2,1} - L_{2,2}) / (L_{1,2} - L_{1,1})$ равняется α — установленному весу ошибок второго рода. В разработанной реализации классификатора для вычисления $x_{k,\min}$ и $x_{k,\max}$ параметр α в (8) полагается равным $\hat{P}_{k,ob} / (1 - \hat{P}_{k,ob})$ и 1 соответственно. Поскольку обычно объект занимает на изображении меньше места, чем фон, предположим, что для всех областей $\hat{P}_{k,ob} < 0,5$. Тогда имеет место $x_{k,\min} < x_{k,\max}$ при любом k .

На заключительном этапе для анализа пикселей третьей группы строится гистограмма каждой области. Пусть $\langle I_{k,m} \rangle$ — m -й интервал гистограммы k -й области. Примем частоту попадания в $\langle I_{k,m} \rangle$ за оценку полной вероятности (3) и обозначим её как $\hat{P}_{k,m}$. Тогда оценка апостериорной вероятности принадлежать объекту для пикселя с яркостью из $\langle I_{k,m} \rangle$ будет иметь вид

$$\hat{P}(ob/m) = \hat{P}_{k,ob} P(m/ob) / \hat{P}_{k,m}, \quad (9)$$

где $P(m/ob)$ — условная вероятность того, что пиксель изображения имеет значение яркости из $\langle I_{k,m} \rangle$, если он принадлежит объекту. В выражении для вероятности $P(m/ob) = \int_{\langle x_{k,m} \rangle} f_{\xi}(x-a) dx$ интегрирование ведётся по интервалу значений референтной функции изображения, соответствующему яркостному интервалу $\langle I_{k,m} \rangle$.

Предлагается отнести к объекту определённое количество пикселей, имеющих наибольшие оценки вероятностей (9). Пусть n_{k3} — число пикселей третьей группы в k -й области, определяемое непосредственно по изображению после того, как будут найдены яркости $I(x_{k,\min})$ и $I(x_{k,\max})$. Обозначим через $\hat{n}_{k3,ob}$ и $\hat{n}_{k3,bk}$ оценки ожидаемых чисел пикселей третьей группы, принадлежащих объекту и фону. Очевидно, что $n_{k3} = \hat{n}_{k3,ob} + \hat{n}_{k3,bk}$, откуда $\hat{n}_{k3,ob} = n_{k3} / (1 + \hat{n}_{k3,bk} / \hat{n}_{k3,ob})$. Положим, что отношение $\hat{n}_{k3,bk} / \hat{n}_{k3,ob}$ равно отношению вероятностей для пикселя из третьей группы в k -й области принадлежать фону и объекту. Они выражаются как $(1 - \hat{P}_{k,ob}) P(k3/bk)$ и $\hat{P}_{k,ob} P(k3/ob)$. Здесь $P(k3/bk)$ и $P(k3/ob)$ — соответствующие условные вероятности того, что пиксель имеет значение яркости из интервала $[I(x_{k,\min}); I(x_{k,\max})]$. Тогда в предположении, что шум имеет нормальное распределение, $\hat{n}_{k3,ob}$ вычисляется по следующей формуле:

$$\hat{n}_{k3,ob} = n_{k3} \frac{\hat{P}_{k,ob} \int_{x_{k,\min}}^{x_{k,\max}} \exp \left(-\frac{(x-a)^2}{2\sigma^2} \right) dx}{\hat{P}_{k,ob} \int_{x_{k,\min}}^{x_{k,\max}} \exp \left(-\frac{(x-a)^2}{2\sigma^2} \right) dx + (1 - \hat{P}_{k,ob}) \int_{x_{k,\min}}^{x_{k,\max}} \exp \left(-\frac{(x-b)^2}{2\sigma^2} \right) dx}. \quad (10)$$

Если гистограмма состоит из M интервалов, то существует M оценок (9). Расположим их в порядке убывания. Будем считать принадлежащими объекту те пиксели, для которых $\hat{P}(ob/m)$ не меньше j_k -го члена полученного ряда. Пусть $n(j_k)$ — количество таких

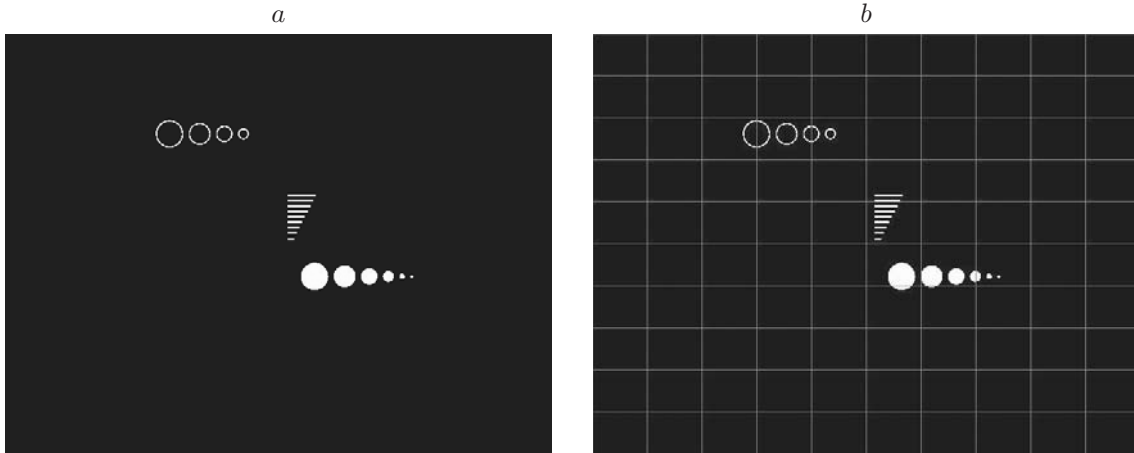


Рис. 1. Модельное изображение: общий вид (a) и его разбиение на области (b)

пикселей, т. е. сумма пикселей, попавших в интервалы, соответствующие членам ряда с первого по j_k -й включительно. При этом есть оценка (10) для числа пикселей из k -й области, относящихся к объекту. Чтобы согласовать эти две оценки, определим номер j_k как минимальное число, для которого выполняется неравенство $n(j_k) \geq \hat{n}_{k3,ob}$. Таким образом, число пикселей, отнесённых классификатором к объекту, будет превосходить оценку $\hat{n}_{k3,ob}$ меньше чем на число пикселей, попавших в интервал гистограммы, соответствующий j_k -му члену упорядоченного ряда.

Вычислительный эксперимент. Предлагаемый классификатор изучался в процессе вычислительного эксперимента. Модельное изображение представлено на рис. 1, a. Исследуемый объект моделируется структурой, состоящей из четырёх колец, девяти прямоугольников и шести кругов. Разность между амплитудами объекта и фона составляет $a - b = 0,1$. В качестве наименьшего значимого элемента структуры рассматривается самый маленький круг, занимающий $n_{\min} = 8$ пикселей, при разрешении рисунка 640×490 пикселей. В первой серии экспериментов изображение разбивалось на 10×10 одинаковых прямоугольных областей, как это показано на рис. 1, b. Каждая из них содержит $n_k = 3136$ пикселей. Таким образом, отношение n_{\min}/n_k в этом случае равняется $8/3136 \approx 0,0026$.

Для оценки качества классификации использовались нормированные ошибки первого Δ_1 и второго рода Δ_2 , вычисляемые по формулам

$$\Delta_1 = \frac{1}{n_{ob}} \sum_{(i_{ob}, j_{ob})} (x(i_{ob}, j_{ob}) - a); \quad \Delta_2 = \frac{1}{n_{bk}} \sum_{(i_{bk}, j_{bk})} (x(i_{bk}, j_{bk}) - b), \quad (11)$$

где суммирование проводится по пикселям, принадлежащим на модельном изображении объекту (для ошибки Δ_1) и фону (для ошибки Δ_2); n_{ob} и n_{bk} — количества этих пикселей; $x(i, j)$ — значения функции, соответствующей изображению, полученному в результате обработки (они могут быть равны либо a , либо b).

Определены зависимости характеристик Δ_1 и Δ_2 от уровня аддитивного шума, имеющего нормальное распределение с дисперсией σ^2 и математическим ожиданием, равным нулю. На рис. 2, a, b приведены зависимости $\Delta_1(\sigma)$ и $\Delta_2(\sigma)$. Стандартное отклонение шума σ выражается в абсолютных единицах. Таким образом, значение $\sigma = 0,1$ составляет величину превышения объекта над фоном. Для кривых 1 ошибки вычисляются по изображениям, полученным предлагаемым алгоритмом; для кривых 2 — по изображениям, в которых пиксель из k -й области считается принадлежащим объекту (фону), если его яркость больше (не больше) $I(x_{k,\min})$; для кривых 3 — по изображениям, в которых деление




Рис. 2. Зависимости от уровня шума нормированных ошибок: первого (а) и второго (б) рода (кривые 1 — предлагаемый алгоритм, кривые 2 — порог $I(x_{k,\min})$, кривые 3 — порог $I(x_{k,\max})$)

на объект и фон проводится по пороговым яркостям $I(x_{k,\max})$. Обратим внимание на то, что кривая 2 на рис. 2, б показывает не саму ошибку Δ_2 , а ее величину, в пять раз меньшую, т. е. $\Delta_2/5$. Это сделано для того, чтобы демонстрируемые данные имели сравнимый порядок величины.

Как и следовало ожидать, для метода разделения по яркости $I(x_{k,\min})$ количество ошибок первого рода несколько меньше, чем для других методов. Однако это преимущество полностью теряется из-за высокого уровня ошибок второго рода. Как видно на рис. 2, б, с учётом масштабирования кривой 2 при использовании порога $I(x_{k,\min})$ значение Δ_2 при $\sigma = 0,1$ достигает 0,15, т. е. 15 % пикселей фона классифицируется неверно. Для предлагаемого подхода Δ_2 при таком σ меньше в 23,4 раза. Что касается выбора порога равным $I(x_{k,\max})$, то в этом случае ошибка первого рода максимальна. Ошибка же второго рода меньше, чем для предлагаемого метода, в среднем в 2–4 раза, но, как показало визуальное сравнение изображений, эта разница не имеет решающего значения.

На рис. 3, а приведено модельное изображение, содержащее шум с $\sigma = 0,05$. Результаты обработки с помощью полученного классификатора представлены на рис. 3, б. Видно, что при умеренном шуме (σ составляет 50 % от величины разности амплитуд объекта и фона) обнаружены все элементы объекта, включая самый маленький круг. При этом количество ошибок второго рода остаётся относительно низким. Наибольшая плотность неверно классифицированных пикселей фона наблюдается вблизи крупных элементов объекта. На рис. 3, с, d показаны изображения, полученные посредством разделения по пороговым яркостям $I(x_{k,\min})$ и $I(x_{k,\max})$ соответственно. Сравнивая их с рис. 3, б, можно видеть преимущества предлагаемого метода. На рис. 3, с велико количество ошибок второго рода, из-за чего, в частности, невозможно различить самый мелкий элемент объекта. На рис. 3, d, напротив, много ошибок первого рода, что приводит к более значительному искажению структур объекта в сравнении с рис. 3, б.

Во второй серии экспериментов изучалось влияние количества элементов разбиения (и соответственно их размера) на точность классификации. Как и ранее, были получены зависимости ошибок (11) от стандартного отклонения шума. Результаты представлены на рис. 4, а (ошибка первого рода) и рис. 4, б (ошибка второго рода). Из проведённых расчётов следует, что с уменьшением области ошибка Δ_1 несколько снижается, в то время как ошибка Δ_2 растёт. Первое объясняется тем, что применение областей относительно небольшого размера позволяет лучше локализовать элементы объекта, второе, по-видимому, уменьшением объёма выборки для получения оценок статистических характеристик, в частности,




Рис. 3. Исходное изображение и результаты его обработки: модель с наложенным шумом (a), предлагаемый алгоритм (b), разделение по пороговым яркостям $I(x_{k,\min})$ (c) и $I(x_{k,\max})$ (d)




Рис. 4. Зависимости ошибок от уровня шума: нормированных ошибок первого (a) и второго (b) рода (кривые 1—5 — разбиение изображения на 5×5 , 8×7 , 10×10 , 16×14 , 20×35 областей соответственно)

априорных вероятностей $\hat{P}_{k,ob}$. Из исследования был сделан вывод, что в рассмотренных условиях для получения изображения наиболее высокого качества, пригодного для визуального анализа, размер области должен быть приблизительно от 1000 до 5000 пикселей.

Заключение. В данной работе предложен модифицированный классификатор, предназначенный для попиксельного анализа зашумлённого изображения, являющегося в отсутствие шума бинарным. При этом часть пикселей классифицируется с учётом условной вероятности принадлежать объекту, имея определённую яркость, без явного вычисления величины разделяющего яркостного порога (заметим, что последний может быть установлен в случае унимодального распределения шума, которое почти всегда имеет место на практике). Указанная вероятность оценивается с привлечением гистограммы заданной области, к которой относится рассматриваемый пиксель. Таким способом учитываются статистические характеристики изображения.

Разработанная алгоритмическая реализация не предусматривает обучения, что, с одной стороны, можно рассматривать как недостаток, а с другой стороны, в этом есть и определённое преимущество. Широкое множество видеосигналов может обрабатываться без предварительной настройки алгоритма. Это обстоятельство очень важно, например, для приложений, где в режиме реального времени анализируется поток изображений, различающихся по своим свойствам. Кроме того, предлагаемый классификатор допускает обучение. Например, его можно использовать при нахождении яркостей $I(x_{k,\min})$ и $I(x_{k,\max})$.

Выполнен вычислительный эксперимент. Чтобы учесть неоднородность статистических свойств изображения, обусловленных присутствием элементов объекта, оно разбивалось на области, каждая из которых обрабатывалась отдельно. Вычислялись ошибки первого и второго рода, а также проводилась визуальная оценка получаемых результатов. Показано, что алгоритм осуществляет более точную классификацию по сравнению с разделением по порогу яркости, определяемому из условия минимальности взвешенной суммы ошибок первого и второго рода.

Путём вычислительного эксперимента также исследовалось влияние размера областей разбиения изображения. В проведённых вычислениях он варьировался в пределах от 448 до 12 544 пикселей. Оказалось, что с уменьшением области ошибка первого рода также уменьшается, а ошибка второго рода увеличивается. Исходя из этих результатов был сделан вывод, что в рассмотренных условиях размер области следует выбирать в диапазоне от 1000 до 5000 пикселей.

СПИСОК ЛИТЕРАТУРЫ

1. Гонсалес Р., Вудс Р. Цифровая обработка изображений. М.: Техносфера, 2005. 1072 с.
2. Сергиенко А. Б. Цифровая обработка сигналов. С.-Пб.: Питер, 2007. 751 с.
3. Лихачев А. В. Новый алгоритм повышения контраста мелкомасштабных деталей изображения на основе разложения по вейвлетам // Цифровая обработка сигналов. 2018. № 3. С. 44–48.
4. Воскобойников Ю. Е. Оценивание оптимальных параметров мультипликативного алгоритма вейвлет-фильтрации изображений // Автометрия. 2017. 53, № 4. С. 112–119.
5. Коулмен Г. Б., Эндрюс Х. С. Сегментация изображений при помощи автоматической классификации // Тр. ин-та инженеров по электротехнике и радиоэлектронике. 1979. № 5. С. 82–97.
6. Хорн Б. К. П. Зрение роботов. М.: Мир, 1989. 487 с.
7. Шлезингер М., Главач В. Десять лекций по статистическому и структурному распознаванию. Киев: Наукова думка, 2004. 545 с.

8. **Дмитриев Е. В., Козодеров В. В., Дементьев А. О., Сафонова А. Н.** Комплексирование классификаторов в задаче тематической обработки гиперспектральных аэрокосмических изображений // Автометрия. 2018. **54**, № 3. С. 3–13.
9. **Грузман И. С., Киричук В. С., Косых В. П. и др.** Цифровая обработка изображений в информационных системах. Новосибирск: Изд-во НГТУ, 2002. 352 с.
10. **Гнеденко Б. В.** Курс теории вероятностей. М.: Едиториал УРСС, 2005. 448 с.
11. **Лихачев А. В.** Томографическая реконструкция области, имеющей заданное значение плотности // Вычислительные методы и программирование. 2018. **19**, № 4. С. 516–521.

Поступила в редакцию 24.04.2019

После доработки 24.07.2019

Принята к публикации 07.08.2019
