

УДК 621.391:519.2

НЕПАРАМЕТРИЧЕСКИЙ МЕТОД ОПРЕДЕЛЕНИЯ ЧИСЛА КЛАССОВ В ЗАДАЧЕ СЕГМЕНТАЦИИ ИЗОБРАЖЕНИЙ

© Р. В. Подрезов¹, М. А. Райфельд²

¹АО «Научно-исследовательский институт электронных приборов»,
630005, г. Новосибирск, ул. Писарева, 53

²Новосибирский государственный технический университет,
630073, г. Новосибирск, просп. К. Маркса, 20
E-mail: podrezov@oaoiiep.ru
rajfeld@mail.ru

Важными в задачах автоматической пороговой сегментации изображений по яркости являются вопросы о количестве яркостных классов и, как следствие, необходимом числе порогов. Решение задачи оценивания количества классов на изображении часто базируется на представлении его распределения в виде смеси распределений яркостных классов. Известно, что данная задача (расщепление смеси) имеет решение лишь для некоторых видов распределений, а когда распределения яркостных классов неизвестны, возникают трудности его применения. В данной работе представлен непараметрический метод определения количества классов, основанный на ранговых гистограммах и использующий свойство локальной пространственной группировки элементов каждого яркостного класса на изображении. Сравнение предложенного метода с различными критериями оценки числа классов на изображениях показало эффективность рассматриваемого метода.

Ключевые слова: сегментация изображений, гистограмма рангов, ортогонализация Грамма — Шмидта, метод главных компонент.

DOI: 10.15372/AUT20200309

Введение. При решении задачи распознавания изображений первичная обработка, как правило, включает процедуру сегментации, т. е. разделение на области, однородные в смысле некоторого признака. Достаточно часто сегментация осуществляется по яркости. Одним из наиболее простых и распространённых методов яркостной сегментации изображений является пороговая обработка [1]. Несмотря на существование разнообразных методов сегментации, в ряде случаев, достаточно сложных и тонких, сохраняется большой интерес к исследованию пороговой сегментации изображений. Этот интерес часто вызван необходимостью обработки изображений в целях автоматического принятия решения в реальном масштабе времени в условиях ограниченности вычислительных ресурсов, поэтому используемые процедуры должны быть максимально просты и эффективны в вычислительном плане. Кроме этого, эффективность сегментации зависит от наличия априорной информации о сегментируемых изображениях и стабильности их вероятностных характеристик. Сложные, тонкие и высокоэффективные методы сегментации, как правило, не являются ни универсальными (поскольку ориентированы на вполне определённую модель изображения), ни робастными (поскольку достигаемая эффективность является следствием точного соответствия модели), и при незначительных отклонениях от модели процедура теряет работоспособность. Сравнительный анализ методов пороговой сегментации [2] показал, что важным фактором при выборе тех или иных алгоритмов сегментации является априорная информация о количестве классов на изображении. Так, метод Киттлера [3], основанный на модели распределения изображения в виде смеси нормальных классов и использующий динамический алгоритм кластеризации [4], подобный EM-алгоритму оценки

параметров смеси [5], может применяться только при известном числе классов. Очевидным способом решения проблемы оценки параметров смеси (расщепления и идентификации) в случае отсутствия информации о числе компонент является его оценивание по изображению. Необходимо отметить, что совместная идентификация смеси распределений и оценка количества классов сопряжены с общеизвестными проблемами. Так, например, равномерное распределение может быть представлено более чем одним способом в виде смеси двух равномерных распределений с различными параметрами. Таким образом, с помощью гистограммы не всегда можно однозначно различить компоненты смеси и оценить их параметры. Из-за этого становится проблематичной и оценка числа компонент смеси, когда вид распределений или их параметры для различных классов неизвестны. Другая проблема, часто встречающаяся при решении задачи оценки числа классов на изображении на основе максимально правдоподобного подхода, — смещение этой оценки в сторону больших значений этого параметра. В критериях, используемых при определении числа компонент смеси нормальных распределений, применяемых совместно с EM-алгоритмом, эта трудность преодолевается введением специального слагаемого, компенсирующего рост функции правдоподобия, которое приводит к появлению экстремума в зависимости от числа компонент. На этом подходе основаны критерий Акаике [6], байесовский информационный критерий (также известный как критерий Шварца) [7] и ряд других. Следует отметить, что непараметрическая априорная неопределённость является наиболее вероятной в реальных условиях использования алгоритмов сегментации, применяемых при обработке оптических и тепловизионных изображений в бортовой аппаратуре. В данной работе предлагается подход к решению задачи оценки количества классов на изображениях, основанный на рангах и ранговых статистиках. Основной целью является разработка алгоритма, эффективного в условиях априорной неопределённости относительно вида распределения отсчётов изображения. Разрабатываемый метод основывается на модели изображения, распределения яркости объектов которого характеризуются различными средними значениями (в общем случае неизвестными или изменяющимися от кадра к кадру). Алгоритм оценки количества классов должен обладать устойчивыми характеристиками качества, связанными с отклонением оцениваемого параметра от его истинного значения.

Метод оценивания количества классов на изображении, основанный на гистограммах рангов. При описании исходного изображения используется статистический подход. Распределение яркости $P_k(l_{ij})$ произвольного отсчёта изображения $l_{ij} = l(i, j)$, $i = \overline{1, M}$, $j = \overline{1, N}$, определяется меткой яркостного класса k , принимающего целочисленные значения от 1 до K , где K — неизвестное число классов, а M и N — размеры изображения. Отсчёты изображения в общем случае являются зависимыми. Относительно видов распределений классов выдвигаются предположения самого общего вида. Полагают, что распределения классов не перекрываются, т. е. распределение отсчётов каждого из классов, например k -го, определено на интервале яркостей $[c_{k-1}, c_k]$, $k = \overline{1, K}$, в который не попадают яркости других классов. Таким образом, все отсчёты класса k больше максимального элемента $(k - 1)$ -го класса и меньше минимального элемента $(k + 1)$ -го класса. Это свойство можно более точно сформулировать следующим образом:

$$F_{k-1}(c_{k-1}) = 1; \quad F_{k+1}(c_k) = 0, \quad (1)$$

где $F_k(\cdot)$ — функция распределения яркости k -го класса; c_0, \dots, c_K — неубывающая последовательность уровней яркости, для которой все наблюдения из некоторого класса k лежат в интервале между двумя соответствующими значениями $[c_{k-1}, c_k]$. Набор яркостных порогов c_0, \dots, c_K обеспечивает безошибочное разделение элементов различных классов. Отмечая пороговую разделимость классов, тем не менее нельзя считать, что задача их безошибочного разделения является гарантированно разрешимой в условиях априорной

неопределённости. Модель неперекрывающихся распределений (1) является искусственной, однако в дальнейшем она будет использована для синтеза непараметрического алгоритма оценивания количества классов. Другая модель яркости изображения, более близкая к реальности, предполагает, что распределения классов частично перекрываются. В этом случае можно утверждать, что наблюдения одного из классов (k -го) статистически более яркие, чем наблюдения $(k - 1)$ -го класса, и менее яркие, чем $(k + 1)$ -го. При этом $F_{k-1}(c) > F_k(c) > F_{k+1}(c) \quad \forall c$. Важное свойство реальных изображений, которое не учитывается в модели смеси, заключается в том, что отсчёты каждого класса группируются в некоторую локальную область на изображении. Формально это свойство может быть определено следующим образом. Пусть некоторый отсчёт изображения $l(i_0, j_0)$ принадлежит k -му классу ($k = \overline{1, K}$), тогда точки из некоторой окрестности $\Omega(i, j)$, в которую входит и $l(i_0, j_0)$, будут принадлежать тому же классу с вероятностью, существенно большей, чем $1/K$. Для изображения, удовлетворяющего модели (1), необходимо найти оценку количества яркостных классов (т. е. \hat{K}). Одним из возможных способов решения данной задачи является итеративная процедура, включающая предварительное задание количества классов, определение яркостных порогов, оценку качества сегментации изображения (при данном количестве классов) и удержание такого их количества, которое обеспечивает наилучшее качество сегментации. На этом пути возникает множество трудностей, среди которых можно отметить проблемы в управлении итеративной оптимизационной процедурой, выработке критерия для её останова, значительные вычислительные затраты, связанные с перебором или оценкой порогов сегментации в условиях априорной неопределённости. Таким образом, в автономных системах реального времени оценивание количества классов желательно выполнять с использованием прямого (неитеративного) алгоритма, не требующего процедуры оптимизации. Для решения задачи оценки количества классов применительно к описанным выше непараметрическим моделям предлагается использовать методы, основанные на ранговых статистиках. Предварительно отсчёты исходного изображения ранжируются. Каждой его точке l_{ij} ставится в соответствие ранг $r_{ij} = r(i, j)$, вычисленный на основе вариационного ряда, построенного из отсчётов всего изображения. Использование рангов наблюдений связано с необходимостью получения непараметрического свойства у разрабатываемого метода. Так, если распределения классов не перекрываются (1), то распределение рангов их отсчётов не зависит от распределения яркости наблюдений, а является равномерным с параметрами, зависящими от количества точек каждого класса g_k , $k = \overline{1, K}$, на всём изображении:

$$P_k(r) = \begin{cases} 1/g_k, & r_{k-1 \max} < r \leq r_{k \max}; \\ 0, & \text{иначе,} \end{cases} \quad (2)$$

где $r_{k-1 \max}$ и $r_{k \max} = r_{k \max} + g_k$ — соответственно максимальные ранги элементов $(k - 1)$ -го и k -классов (номера классов упорядочены по яркости). Сформируем выборку Q_t , $t = \overline{1, T}$ (T — общее количество выборок) из n_t отсчётов изображения (общее число отсчётов $n = M \times N$). Геометрически элементы выборки могут располагаться в прямоугольном окне размером $n_t = M_t \times N_t$. Выборка может состоять из отсчётов различных классов. Распределение ранга отсчёта выборки Q_t представляет собой комбинацию равномерных распределений (2), взятых с весовыми коэффициентами, определяющимися количеством элементов каждого из классов g_{tk} , оказавшихся в выборке Q_t :

$$P(r; Q_t) = \frac{1}{n_t} \sum_{k=1}^K P_k(r) g_{tk}. \quad (3)$$

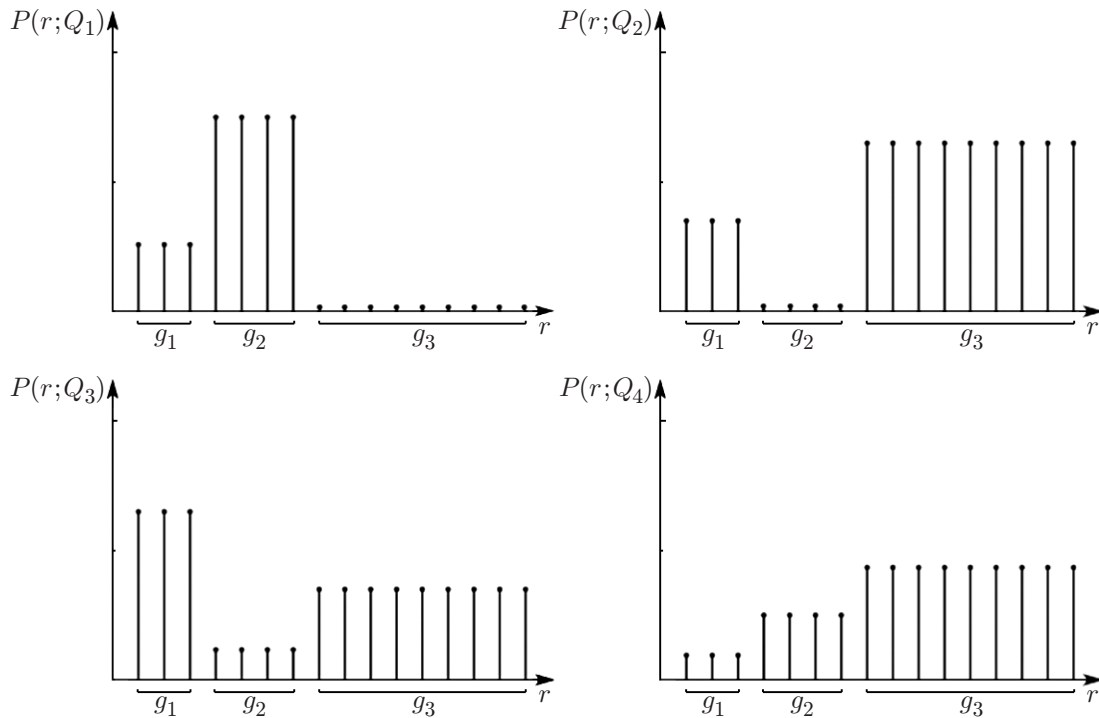


Рис. 1. Пример распределений ранга в выборках изображения

Пример такого распределения для случая трёх классов ($K = 3$) и четырёх выборок ($T = 4$), сформированных из отсчётов неперекрывающихся окон одинакового размера, приведён на рис. 1.

Из выражения (3) следует, что закон распределений рангов выборок имеет вид дискретной кусочно-постоянной функции. Значения точек оси абсцисс, в которых происходит изменение уровня функции, и число таких точек одинаковы для распределений всех выборок. Они определяются соответственно количеством элементов каждого из классов на изображении и количеством классов. Подчёркнём, что такой характер ранговых распределений выборок имеет место, если распределения классов не перекрываются. В случае более общих моделей частично перекрывающихся классов форма распределения ранга зависит от степени этого перекрытия, но общая тенденция заключается в сглаживании скачков уровней распределений. Анализируя распределения рангов выборок для модели неперекрывающихся классов, можно отметить, что существует возможность представить эти кусочно-постоянные функции (распределения рангов) в пространстве меньшей размерности. Это можно сделать, например, применяя процедуру построения собственного базиса. Для рассматриваемой задачи размерность базиса определяется количеством классов на изображении. Поскольку распределения рангов выборок неизвестны, в качестве их несмещённых оценок можно использовать ранговые гистограммы $\Gamma(r; Q_t)$, $r = \overline{1, n}$, построенные по соответствующим выборкам Q_t ранжированного изображения. Они представляют собой случайные функции, при этом (в случае неперекрывающихся распределений яркости классов) их распределения не зависят от распределений яркости исходных наблюдений и являются в этом смысле непараметрическими оценками, характеристики которых (дисперсию и смещение) можно контролировать. Получим распределение отсчёта гистограммной оценки распределения рангов \tilde{p}_i , построенной для заданного интервала рангов Δ_i , $i = \overline{1, R}$, по выборке Q_1 (Δ_i — размер интервала, R — количество интервалов). Каждый из ранговых интервалов содержит элементы только одного класса изображения (например, k ,

поскольку согласно выражениям (2), (3) ранговые гистограммы классов не перекрываются). В соответствии с определением гистограммы её отсчёт, полученный по интервалу Δ_i , вычисляется следующим образом:

$$\tilde{p}_i = q_{1i}/(n_1 \Delta_i), \quad (4)$$

где q_{1i} — количество рангов выборки Q_1 , попавших в интервал Δ_i , $q_{1i} \leq \Delta_i$; \tilde{p}_i — оценка вероятности появления ранга из интервала Δ_i . Учитывая, что знаменатель в (4) является детерминированной величиной, распределение оценки \tilde{p}_i совпадает с распределением q_{1i} , которое вычисляется просто:

$$P(q_{1i}) = \binom{g_k - \Delta_i}{g_{1k} - q_{1i}} \binom{\Delta_i}{q_{1i}} \binom{g_k}{g_{1k}}^{-1}. \quad (5)$$

Очевидно, что количество рангов класса k в выборке равно $g_{1k} \geq q_{1i}$ и $g_k \geq g_{1k} + \Delta_i - q_{1i}$. Из полученного выражения следует, что распределение отсчёта гистограммы рангов не зависит от исходных функций распределений яркостей отсчётов изображения, т. е. обладает непараметрическим свойством. На основе выражений (4), (5) можно рассчитать математическое ожидание и дисперсию отсчёта гистограммы:

$$M[\tilde{p}_i] = \frac{g_{1k}}{g_k n_1}; \quad D[\tilde{p}_i] = \left(\frac{g_{1k}(g_{1k} - 1)(\Delta_i - 1)}{g_k(g_k - 1)n_1^2 \Delta_i} + \frac{g_{1k}}{g_k n_1^2 \Delta_i} \right) - \left(\frac{g_{1k}}{g_k n_1} \right)^2. \quad (6)$$

Анализ выражений (6) показывает, что минимальная дисперсия отсчёта гистограммы (равная нулю) получается в случае, если $g_{1k} = g_k$ (все точки k -го класса сосредоточены в данной выборке), либо $g_{1k} = 0$ (ни одного элемента этого класса нет в выборке). Дисперсия максимальна, если $g_{1k} = g_k/2$. Она в этом случае имеет вид $D_{\max} = 1/(4n_1^2 \Delta_i)$, т. е. определяется только параметрами алгоритма расчёта гистограммы.

Как было показано выше, распределения рангов неперекрывающихся яркостных классов являются кусочно-постоянными функциями, которые могут быть представлены в виде линейной комбинации базисных индикаторных функций:

$$P(r; Q_t) = \sum_{k=1}^K c_{tk} 1(r; a_k, b_k). \quad (7)$$

Здесь $1(r; a_k, b_k) = \begin{cases} 1, & a_k \leq r \leq b_k; \\ 0 & \text{иначе} \end{cases}$ — индикаторная функция, имеющая вид единичного прямоугольника, координаты левой и правой границы которого задаются числами a_k и b_k соответственно; $c_{tk} = g_{tk}/(g_k n_t)$ — весовой коэффициент, а границы классов определяются следующим образом: $a_k = \sum_{j=1}^{k-1} g_j + 1$ и $b_k = \sum_{j=1}^k g_j$, $k = \overline{1, K}$. Размерность такого

базиса K на единицу меньше количества скачков функции $P(r; Q)$, т. е. количества классов. Не производя сегментации, оценить размерность базиса (и, как следствие, оценить число классов) можно, применяя в качестве базисных функций ранговые гистограммы, построенные по выборкам Q_t ранжированного изображения. Важно, чтобы количество выборочных ранговых гистограмм было не меньше, чем ожидаемое число классов на изображении. Это гарантирует достаточное количество выборок $T \geq K$. Построение базиса на основе выборочных гистограмм осуществляют с использованием известных процедур ортогонализации. Хотя ранговые гистограммы являются случайными функциями, однако

параметры их распределения, как было показано выше, не зависят от исходных распределений яркости классов. Функции можно представить в следующем виде:

$$\Gamma(r; Q) = P(r; Q) + \eta(r), \quad (8)$$

где $\eta(r)$ — отклонение гистограммной оценки от вероятности ранга, которое рассматривается как шум, связанный со случайным распределением элементов классов в выборках изображения. Этот шум не является стационарным, поскольку его дисперсия для рангов различных классов в выборке будет различаться, что связано с разными значениями отношения g_{tk}/g_k для каждого класса в данной выборке (6). Все гистограммы, построенные по T выборкам изображения, обычно оказываются множеством линейно-независимых векторов, и их ортогонализация не приводит к построению базиса размерности меньшей, чем общее их число (т. е. T). Ошибка представления снижается при добавлении нового базисного вектора, но не становится равной нулю (за исключением представления последней T -й выборочной гистограммы — это следует из того, что сумма всех выборочных ранговых гистограмм даёт постоянную в диапазоне $[0, n]$ функцию с уровнем $1/n$). Тем не менее существует некоторое количество значимых векторов, образующих базис размерностью $\Theta \leq T$, дальнейшее добавление элементов в который не приводит к существенному снижению ошибки представления. Размерностью этого базиса и будем определять количество классов. Таким образом, процедура ортогонализации может быть модифицирована включением в неё условной операции добавления нового вектора в базис, только в том случае, если его метрика оказывается выше заданного порога C . Рассмотрим, как выглядит использование в данной задаче процедуры Грамма — Шмидта. В этой процедуре первый вектор нового базиса определяется нормированием первого вектора какой-либо выборочной гистограммы рангов:

$$\mathbf{e}_1 = \Gamma(r; Q_1) / \|\Gamma(r; Q_1)\|, \quad r = \overline{1, n}, \quad (9)$$

где $\|\Gamma(r; Q_1)\|$ — евклидова метрика гистограммы рангов, построенная по первой выборке. Последующие операции создания нового базиса проводятся в виде итеративной процедуры, состоящей из вычисления разложения вектора по базису, построенному к текущему шагу, и добавления вектора при соблюдении условия в соответствии с выражениями

$$\boldsymbol{\varepsilon}_{t+1} = \Gamma(r; Q_{t+1}) - \sum_{j=1}^t \mathbf{e}_j \langle \mathbf{e}_j, \Gamma(r; Q_{t+1}) \rangle; \quad \mathbf{e}_{t+1} = \frac{\boldsymbol{\varepsilon}_{t+1}}{\|\boldsymbol{\varepsilon}_{t+1}\|}, \quad \text{если } \|\boldsymbol{\varepsilon}_{t+1}\| \geq C. \quad (10)$$

Ошибка $\|\boldsymbol{\varepsilon}_t\|$ (10) является случайной величиной с распределением, не зависящим от исходного распределения яркости изображения. Необходимо отметить, что распределение координат векторов гистограмм выборок отличается от гауссовского (5), кроме того, их дисперсия не постоянна (6) и зависит от доли отсчётов каждого из классов (по отношению к общему количеству его отсчётов на изображении) в данной выборке. Поэтому точный расчёт распределения $\|\boldsymbol{\varepsilon}_t\|$ оказывается достаточно сложным. В первом приближении для выборок большого размера можно воспользоваться аппроксимацией нормальным законом и ориентироваться на наихудший случай, т. е. считать, что дисперсия каждой координаты гистограммы максимальна и равна D_{\max} , и на этом основании рассчитывать порог C . За оценку количества классов принимается количество базисных векторов Θ , оставшихся после обработки всех T выборок. Возможным подходом к определению размерности базиса ранговых гистограмм является метод главных компонент [5, 8, 9], заключающийся в линейном преобразовании ранговых гистограмм (векторов с размерностью n) для их представления в новой системе координат:

$$\mathbf{Z} = \Gamma(r; Q)\mathbf{L}, \quad (11)$$

где $\Gamma(r; Q) = \{\Gamma(r; Q_1), \Gamma(r; Q_2), \dots, \Gamma(r; Q_T, \dots)\}^\top$ — матрица, составленная из векторов-столбцов гистограмм и имеющая размерность $n \times T$; \mathbf{Z} — матрица векторов проекций в новую систему координат; \mathbf{L} — линейный оператор преобразования координат (матрица, составленная из собственных векторов корреляционной матрицы выборочных гистограмм). Метод главных компонент предполагает упорядочение по величине дисперсий проекций λ_i векторов гистограмм в ортогональном базисе. Первой главной компонентой в этом случае является линейная комбинация исходных векторов, которая обладает наибольшей дисперсией λ_1 . Поскольку векторы ранговых гистограмм линейно независимы, то размерность пространства равна количеству выборок, т. е. T . Кроме того, имеется небольшое количество (Θ) значимых компонент ($\Theta \leq T$), в которых сосредоточена основная мощность. Для оценки количества главных компонент традиционно используется эвристическое правило Кайзера [10] или правило сломанной трости. С учётом того, что дисперсия отсчётов гистограмм однородного изображения зависит от размеров выборок, размера изображения и выбранного интервала, можно предложить более простое пороговое правило для выбора значимых главных компонент в результате их сравнения с некоторым порогом λ_ξ , определяемым по распределению собственных чисел [9, 11].

Рассмотрим ряд вопросов, связанных с применением вышеописанного алгоритма оценки количества яркостных классов на реальных изображениях. Поскольку алгоритм предполагалось применять в задаче распознавания тепловизионных изображений, то и исследование проблем, связанных с его использованием, базируется на изображениях данного типа. Главная проблема применения данного алгоритма (как, впрочем, и всех правил, основанных на ранговых статистиках) заключается в потере им непараметрического свойства при работе с зависимыми (коррелированными) наблюдениями, какими являются отсчёты тепловизионных изображений. В качестве модели сигнала строки тепловизионного изображения можно принять следующее выражение: $y_i = \delta_k + s_{ki} + \xi_i$, $i = \overline{1, N}$, $k = \overline{1, K}$. Здесь δ_k — неизвестное математическое ожидание отсчёта строки изображения, задаваемое меткой яркостного класса (например, k -го); s_{ki} — отсчёт гауссовского случайного процесса с нулевым средним и корреляционной матрицей, определяемой меткой того же класса, что и δ ; ξ_i — отсчёт независимого гауссовского шума. Зависимость наблюдений в строке определяется корреляционной матрицей процесса s_k . Поскольку сегментация осуществляется по признаку средней яркости, то процесс s_k , имеющий нулевое математическое ожидание, является помехой. Его оценка \hat{s}_{ki} может быть получена на основе предыдущих отсчётов (используется модель линейного предсказания [12]) и далее вычтена из y_i для обеспечения декорреляции сигнала. Весовые коэффициенты фильтра $\mathbf{a} = \{a_1, a_2, \dots, a_p\}$ могут находиться с использованием адаптивного метода наименьших квадратов [12] по выборке y . Поскольку математическое ожидание отсчётов δ является неизвестным, его приходится оценивать обычным способом по выборке наблюдений y . При этом математическое ожидание k -го класса необходимо вычислять на основе наблюдений именно данного класса, для чего требуется возможность исключить из выборки, по которой производится оценивание, точек других классов, отличных от k -го. Такого результата можно достичь, контролируя невязку γ , рассчитываемую для i -го отсчёта в строке выражением: $\gamma = y_i - (\hat{s}_{ki} + \hat{\delta}_k)$. В том случае, если невязка не превышает порогового значения, точка y_i считается принадлежащей к тому же классу, что и все предыдущие, а оценки $\hat{\delta}$ и $\hat{\mathbf{a}}$ уточняются с учётом новой точки, иначе фильтры, оценивающие математическое ожидание и коэффициенты линейного предсказания, начинают свою работу с новой выборки, содержащей только i -й отсчёт. Более сложная стратегия полагает, что в i -й точке сигнал k -го класса искажён импульсной помехой. Тогда оценки $\hat{\mathbf{a}}$ и $\hat{\delta}$ «замораживаются» и далее проверяется невязка для $(i + 1)$ -го отсчёта. Если порог превышает для некоторого числа подряд идущих

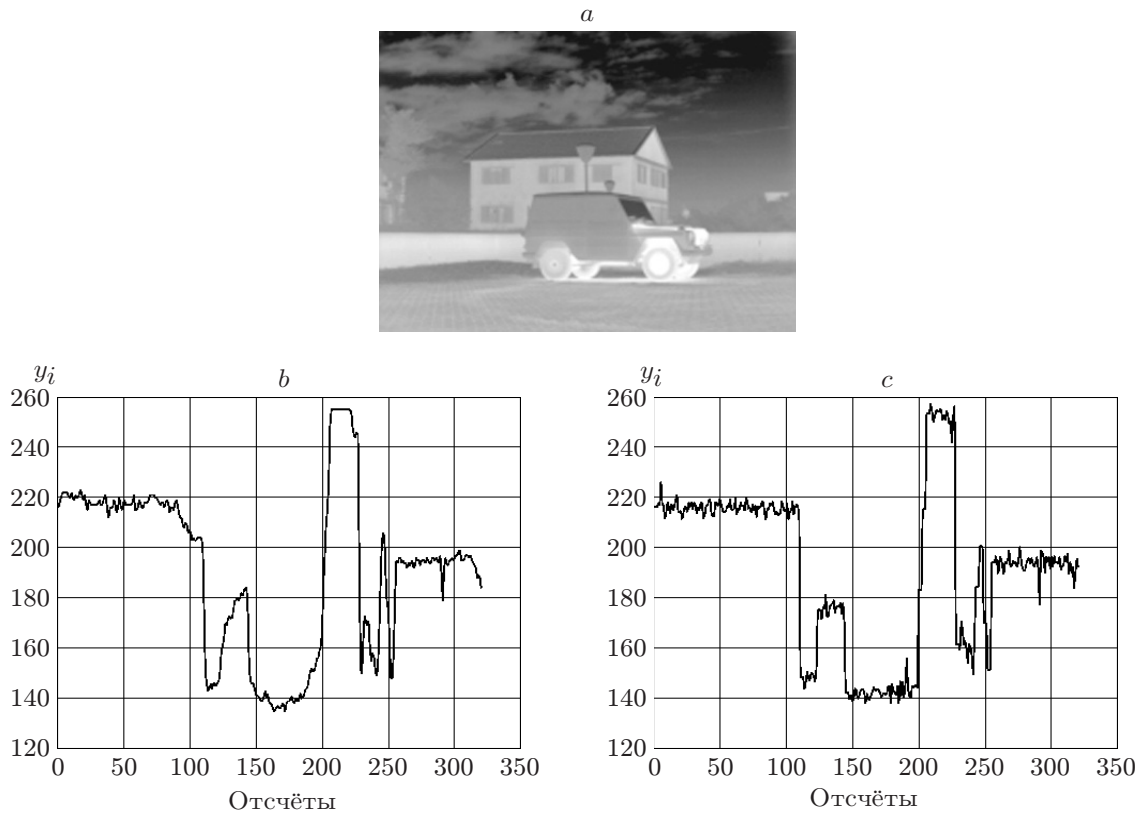


Рис. 2. Результаты обработки тепловизионного изображения адаптивным фильтром: исходное тепловизионное изображение (*a*), его 172-я строка (*b*) и результат фильтрации (*c*)




Рис. 3. Формирование искусственного модельного изображения: исходное искусственное изображение (*a*); результат искажения шумом (*b*)

Таблица 1

Результаты статистического эксперимента
по определению количества яркостных классов на изображении

Количество классов	Метод	Вероятности оценок					
		1	2	3	4	5	6
1	AIC	0,98	0,02	0	0	0	0
	BIC	1	0	0	0	0	0
	ГШФП	0,98	0,02	0	0	0	0
	МГК-правило сломанной трости	0,99	0,01	0	0	0	0
	МГКСП	1	0	0	0	0	0
2	AIC	0	0,33	0,43	0,21	0,03	0
	BIC	0	0,63	0,31	0,06	0	0
	ГШФП	0	0,83	0,15	0,02	0	0
	МГК-правило сломанной трости	0	1,00	0	0	0	0
	МГКСП	0	1,00	0	0	0	0
3	AIC	0	0	0,04	0,37	0,41	0,18
	BIC	0	0	0,18	0,57	0,24	0,01
	ГШФП	0	0	0,72	0,24	0,04	0
	МГК-правило сломанной трости	0	1,00	0	0	0	0
	МГКСП	0	0	1,00	0	0	0
4	AIC	0	0	0	0,07	0,26	0,67
	BIC	0	0	0,01	0,10	0,29	0,60
	ГШФП	0	0	0	0,12	0,48	0,4
	МГК-правило сломанной трости	0	0	0	1,00	0	0
	МГКСП	0	0	0	0	1,00	0

отсчётов, то полученная к данному моменту выборка полностью обновляется. Подобные процедуры можно проводить по строкам и столбцам изображения. Результаты подобной фильтрации для строк тепловизионного изображения приведены на рис. 2.

Экспериментальное исследование метода гистограмм рангов. С использованием метода статистического моделирования был испытан ряд алгоритмов определения количества классов на изображении. Модельное изображение (рис. 3) имеет размер 320×240 пикселей.

Выборки формируются из отсчётов прямоугольных фрагментов изображения размером 32×40 пикселей (всего 60 выборок). Сравнение проводилось среди методов ранговых гистограмм с ортогонализацией Грамма — Шмидта с фиксированным порогом (ГШФП), метода главных компонент (МГК) с помощью правил: Кайзера [10], сломанной трости и статистического порога (МГКСП). Эти методы сравнивались с критерием Акаике (AIC), байесовским информационным критерием (BIC), информационным классификационным критерием (ICLBIC). В параметрических методах использовался EM-алгоритм оценки параметров смесей нормальных распределений. Классы на изображении моделировались нормальным законом с равной дисперсией $\sigma^2 = 0,5$ и равномерно возрастающим математическим ожиданием от класса к классу $m_{k+1} = m_k + 1$. Все результаты сведены в таблицу 1.

Заключение. В данной работе представлен новый метод оценки количества яркостных классов на изображениях, основанный на определении эффективной размерности пространства выборочных ранговых гистограмм. Метод обладает непараметрическим свойством, его рабочие характеристики не зависят от вида распределения отсчётов изображения, поэтому он является устойчивым. Эффективность предлагаемого подхода связана с привлечением дополнительной информации, содержащейся в пространственной неодно-

родности обрабатываемого изображения, и локализацией классов в определённых его областях. Областью применения развиваемого подхода является автоматическая обработка тепловизионных изображений, в частности их сегментация. Предложенный алгоритм не требует предварительной настройки и представляется простым в вычислительном плане, поэтому он может быть использован для оценки числа классов на изображении и соответствующего числа порогов сегментации в реальном масштабе времени.

СПИСОК ЛИТЕРАТУРЫ

1. **Чочиа П. А.** Сегментация изображений на основе анализа расстояний в пространстве признаков // Автометрия. 2014. **50**, № 6. С. 97–110.
2. **Sezgin M., Sankur B.** Survey over image thresholding techniques and quantitative performance evaluation // Journ. Electron. Imaging. 2004. **13**, N 1. P. 146–168.
3. **Kittler J., Illingworth J.** Minimum error thresholding // Patt. Recogn. 1986. **19**, N 1. P. 41–47.
4. **Devijver P. A.** Pattern Recognition: A Statistical Approach / P. A. Devijver, J. Kittler. Englewood Cliffs: Prentice Hall, 1982. 448 p.
5. **Айвазян С. А.** Прикладная статистика: классификация и снижение размерности / С. А. Айвазян, В. М. Бухштабер, И. С. Енюков, Л. Д. Мешалкин. М.: Финансы и статистика, 1989. 607 с.
6. **Akaike H.** A new look at the statistical model identification // IEEE Transactions on Automatic Control. 1974. N 6. P. 716–723. DOI: 10.1109/TAC.1974.1100705.
7. **Schwarz G.** Estimating the dimension of a model // Ann. Stat. 1978. **6**. P. 461–464.
8. **Уилкс С.** Математическая статистика. М.: Наука, 1967. 632 с.
9. **Андрукович П. Ф.** Применение метода главных компонент в практических исследованиях. М.: Издво МГУ, 1973. Вып. 36. 126 с.
10. **Ким Дж.-О.** Факторный, дискриминантный и кластерный анализ. М.: Финансы и статистика, 1989. 215 с.
11. **James A. T.** The distribution of the latent roots of the covariance matrix // Ann. Math. Statist. 1960. N 1. P. 151–158.
12. **Уидроу Б.** Адаптивная обработка сигналов / Б. Уидроу, С. Стирнз. М.: Радио и связь, 1989. 440 с.

Поступила в редакцию 17.12.2019

После доработки 17.01.2020

Принята к публикации 21.01.2020
