

УДК 004.932.2

АЛГОРИТМЫ ФОРМИРОВАНИЯ КАРТ СЕГМЕНТАЦИИ ИЗОБРАЖЕНИЙ ИЗ СУПЕРПИКСЕЛЕЙ НА ОСНОВЕ КОМБИНИРОВАННОЙ ИНФОРМАЦИОННОЙ МЕРЫ КАЧЕСТВА

© Д. М. Мурашов

*Федеральный исследовательский центр «Информатика и управление» РАН,
119333, Москва, ул. Вавилова, 40
E-mail: d_murashov@mail.ru*

Предлагаются новые алгоритмы объединения суперпикселей в сегменты с использованием «жадной» стратегии и комбинированной меры качества, которая включает две компоненты: меру информационной избыточности и вариацию информации. «Жадная» стратегия применялась автором ранее для ускорения сегментации изображений из условия минимума информационной избыточности, а двухкомпонентная информационная мера качества использовалась в задаче комбинирования различных карт сегментации. Совместное использование «жадной» стратегии и комбинированной меры качества в новых алгоритмах направлено на ускорение формирования карт сегментации и повышение их качества за счёт компромисса между требованиями минимизации количества выделенных информационно важных сегментов и минимизации информационного различия между оригинальными изображениями и сформированными разбиениями. Вычислительный эксперимент на тестовых изображениях показал, что предлагаемые алгоритмы позволяют ускорить процесс сегментации по сравнению с методом на основе минимизации информационной избыточности, применявшимся ранее автором, и улучшить информационные характеристики полученных карт сегментации.

Ключевые слова: сегментация изображений, информационная избыточность, вариация информации, комбинированная мера качества, выращивание сегментов, объединение суперпикселей.

DOI: 10.15372/AUT20240502

EDN: TSZLQQ

Введение. Предлагаемая работа посвящена задаче сегментации цифровых изображений, которая заключается в разбиении изображения на множество непересекающихся связанных сегментов, элементы которых схожи по какому-либо признаку и отличаются от элементов соседних сегментов. Один из подходов к решению этой задачи состоит из двух этапов. На первом этапе нужно получить пересегментированное изображение, т. е. разбить входное изображение на достаточно большое количество элементарных сегментов (суперпикселей), размеры которых меньше, чем видимые на изображении объекты. На втором этапе, исходя из условий сходства признаков описаний, полученные малые сегменты объединяются в более крупные, соответствующие объектам на оригинальном изображении. Результат сегментации при таком подходе зависит от выбора критериев объединения элементарных сегментов, порядка объединения и условия окончания процесса объединения.

В научной литературе предложено большое количество методов, реализующих указанный подход. Так, например, в [1] описаны алгоритмы объединения пикселей изображения в связанные области и объединения областей в сегменты по пороговым правилам для величины евклидова расстояния между точками, характеризующими соответствующие объекты изображения в цветовом пространстве HSI. В [2] представлен набор признаков для формирования суперпикселей и использованы предикаты однородности на основе максимальной и среднеквадратичной ошибок аппроксимации яркости пикселей изображения для укрупнения суперпикселей. В [3] разработаны статистические модели областей изображения и

набор критериев объединения областей на основе теоретико-информационных мер, в частности, дивергенции Кульбака — Лейблера и коэффициента Бхаттачарья (Bhattacharyya coefficient). Результатом слияния областей является множество различных разбиений. Для ранжирования и выбора наилучших разбиений авторами введён индекс значимости. Метод слияния суперпикселей, который базируется на комбинированном условии объединения, представлен в [4]. Два соседних суперпикселя объединяются, если: *a*) они наиболее схожи по некоторому признаку среди всех пар суперпикселей в окрестности друг друга; *b*) они однородны (consistent). Условие однородности (*b*) фактически является критерием останова процесса сегментации. В [5] авторы предложили алгоритм выращивания суперпикселей и адаптивного слияния областей, исходя из соотношения величин площадей, значимости (saliency) областей, а также мер различия гистограмм (коэффициент Бхаттачарья), текстур и контурных характеристик. Количество сегментов в полученном разбиении регулируется задаваемыми порогами значимости областей и отношением длины общей границы суперпикселей к периметру меньшего суперпикселя. В работе [6] критерием их объединения является тест на унимодальность распределения признаков, извлекаемых из отдельных суперпикселей, и сегмента, полученного при их слиянии. При этом, кроме порога индикатора теста и уровня значимости, не требуется задавать никаких дополнительных параметров. Порядок объединения определяется степенью близости распределений признаков пар соседних суперпикселей. Процесс сегментации заканчивается, когда ни одна пара объединяемых областей не порождает новой области с унимодальным распределением признаков. Пороговый метод слияния суперпиксельных областей предложен в работе [7]. Порог выбирается, исходя из характеристик объединяемых областей. Порядок и условия слияния суперпикселей определяются средним значением градиента интенсивности внутри суперпикселей, показателями их однородности и соотношением длин перепадов интенсивности и общей границы между объединяемыми областями. Показатель однородности вычисляется как функция среднего значения интенсивности пикселей области. Уровень подробности полученных карт сегментации зависит от заданных величин параметров. В работах [8–10] представлены алгоритмы сегментации на основе метода информационного «бутылочного горлышка» (information bottleneck) [11]. Авторами предложены алгоритмы слияния (merge algorithms) областей изображения из условия минимизации потерь взаимной информации между входом и выходом (т. е. оригинальным и сегментированным изображениями). Так как взаимная информация убывает при слиянии сегментов, необходимо задать условие останова процесса объединения. Это условие формулируется как ограничение на величину нормированной взаимной информации или как минимальное количество сегментов получаемого разбиения. В задаче сегментации изображений дистанционного зондирования [12] с целью измерения степени сходства так называемых «примитивных сегментов» изображений применялась модель глубокого обучения. Объединение примитивных сегментов выполнялось на основе принципа минимума неоднородности. Сходство объединяемых областей оценивалось евклидовым расстоянием в пространстве признаков, в качестве которых использовались среднее значение и среднеквадратическое отклонение яркости пикселей сегмента в каждом спектральном диапазоне, среднее значение яркости по всем спектральным диапазонам, индикаторы компактности, формы и границы сегментов. Итерационный процесс объединения прекращается, когда евклидово расстояние между признаковыми описаниями всех оставшихся областей превышает заданный порог.

В [13, 14] предложен метод сегментации на основе принципа минимизации информационного функционала качества на картах сегментации, полученных с помощью суперпиксельного алгоритма SLIC [15] и процедуры объединения суперпикселей в сегменты при различных значениях параметра. Из множества разбиений оригинального изображения с разным числом сегментов выбиралось разбиение, которое минимизировало функционал качества. В работе [13] применялся функционал в виде меры информационной избыточно-

сти, а в [14, 19] использовался функционал, комбинирующий информационную избыточность и вариацию информации [16]. Такой функционал позволяет найти компромиссное решение между избыточностью и информационным различием между полученным разбиением и оригинальным изображением. Этот метод предоставляет возможность получить оптимальное в смысле информационного функционала качества разбиение, и для решения требуется задать только границы изменения и шаг параметра, определяющего мощность множества разбиений, из которых выбирается искомое. Вышеописанный алгоритм достаточно трудоёмкий, и возникает необходимость ускорить получение карт сегментации.

Целью представляемой работы является разработка ускоренных алгоритмов объединения суперпикселей в сегменты, которые представляют объекты, зафиксированные на изображении. Основная идея состоит в том, чтобы при объединении суперпиксельных областей, во-первых, использовалась «жадная» стратегия, и, во-вторых, мера качества не должна возрастать. Предлагаются три алгоритма на основе «жадной» стратегии, которые отличаются условиями принятия решения об объединении суперпикселей. Данные алгоритмы являются модификацией алгоритма, описанного в [13, 14].

1. Модель системы сегментации. В работах [13, 14] было предложено использовать для описания операции сегментации модель информационного канала. Предполагается, что оригинальное и сегментированное изображения являются входом и выходом стохастической информационной системы. Значения уровней яркости изображений описываются дискретными случайными переменными U и V . Тогда можно представить операцию сегментации следующей моделью:

$$V = F(U + \eta, t), \quad (1)$$

где U — сигнал на входе канала; V — выход канала; F — функция преобразования; t — параметр; η — шум канала, переменные U и η независимы. В [13, 14] задача сегментации сформулирована следующим образом. Пусть из заданного входного изображения U с помощью алгоритма сегментации (1) получен набор Q разбиений $\mathcal{V} = \{V^0, V^1, \dots, V^q, \dots, V^Q\}$ при различных значениях параметра алгоритма. Разбиение $V^q = \{S_1^q, S_2^q, \dots, S_{K^q}^q\}$ состоит из K_V^q сегментов. Требуется выбрать разбиение $V^{q \min}$, обеспечивающее минимум меры качества

$$M(U, V^{q \min}) = \arg \min_{V^q} [M(U, V^q)], \quad q = 1, 2, \dots, Q. \quad (2)$$

В [13] применялся функционал в виде меры информационной избыточности

$$R(U, V^q) = 1 - \frac{I(U; V^q)}{H(V^q)} = \frac{H(U, V^q) - H(U^q)}{H(V^q)} = \frac{H(V^q | U)}{H(V^q)}, \quad (3)$$

где $I(U; V^q)$ — средняя взаимная информация между входным изображением и картой сегментации V^q ; $H(U, V^q)$ — совместная энтропия; $H(U)$ и $H(V^q)$ — энтропии входа и выхода; $H(V^q | U)$ — условная энтропия выхода при условии, что вход равен U .

В работе [14] использовался функционал, комбинирующий информационную избыточность и вариацию информации:

$$M_c(U, V^q) = (1 - \gamma)R(U, V^q) + \gamma VI_n(U, V^q), \quad (4)$$

где γ — коэффициент, $0 \leq \gamma \leq 1$, а нормированная вариация информации [15] определена как

$$VI_n(U, V^q) = \frac{VI(U, V^q)}{H(U, V^q)} = \frac{2H(U, V) - H(U) - H(V^q)}{H(U, V^q)}. \quad (5)$$

1.1. Базовый алгоритм формирования карт сегментации. Рассмотрим алгоритм формирования разбиений V^q , применявшийся в работе [13]. Начальным приближением V^0 изображения V при формировании разбиений является суперпиксельное разбиение, полученное алгоритмом SLIC [15]:

$$V^0 = \bigcup_i S_i^{V^0}, \quad S_i^{V^0} \cap S_j^{V^0} = \emptyset, \quad i \neq j, \quad i = 1, 2, \dots, K_0, \quad j = 1, 2, \dots, K_0,$$

где $S_i^{V^0}, S_j^{V^0}$ — сегменты разбиения V^0 с номерами i и j , K_0 — число сегментов разбиения V^0 . Ниже будет рассмотрен базовый алгоритм объединения суперпикселей изображения V^0 для формирования карт сегментации V^q .

Базовый алгоритм объединения суперпикселей [13] включает следующие операции:

1. $q = 0, V = V^q$.

2. Для выбранного значения параметра t выполняется перебор центров $\mathbf{C}_i = (c_i^1, c_i^2, c_i^3)^\top$ всех суперпикселей изображения V и проверяется условие:

$$d_c(\mathbf{C}_i, \mathbf{C}_j) \leq ct, \quad (6)$$

где $\mathbf{C}_i, \mathbf{C}_j$ — векторы координат центров соседних суперпикселей в выбранном цветовом пространстве, $\partial S_i^V \cap S_j^V \neq \emptyset, \partial S_j^V \cap S_i^V \neq \emptyset$, где ∂S_i^V и ∂S_j^V — границы суперпикселей S_i^V, S_j^V ; c_i^{ch} — координаты центров; $ch = 1, 2, 3$ — номер компоненты используемого цветового пространства; $d_c(\mathbf{C}_i, \mathbf{C}_j)$ — евклидово расстояние между центрами суперпикселей S_i^V и S_j^V ; c — константа; t — параметр.

3. Формируется матрица сходства Px , элементы которой $Px_{ij} = 1$, если выполняется условие (6), и $Px_{ij} = 0$ в противном случае.

4. После завершения формирования матрицы Px выполняется объединение суперпикселей, которые соответствуют ненулевым элементам этой матрицы, в сегменты. Полученное разбиение V^{q+1} оригинального изображения сохраняется.

5. Выбирается новое значение параметра t , $V = V^{q+1}$, если $t < t_{\max}$, переход к шагу 2.

6. Из полученного множества разбиений $\mathcal{V} = \{V^0, V^1, \dots, V^q, \dots, V^Q\}$, выбирается разбиение $V^{q \min}$, на котором функционал качества (2) достигает минимума.

1.2. Задача ускоренного выращивания сегментов из суперпикселей. Описанный в подразд. 1.1 алгоритм достаточно трудоёмкий, и возникает необходимость разработки более быстрых способов получения карт сегментации без значительных потерь качества в смысле функционала (4). Для этого предлагается реализовать «жадную» процедуру выращивания сегментов из суперпикселей непосредственно в процессе сканирования изображения V^0 . В задаче сегментации (1), (2) мера качества (4) применялась только на этапе выбора оптимального разбиения $V^{q \min}$ из множества разбиений $\mathcal{V}$. В представляемой работе предлагается: 1) выращивать каждый сегмент из соседних суперпикселей до тех пор, пока выполняются условия объединения; 2) использовать условие невозрастания меры $M_c(U, V^q)$ (4) при выращивании сегментов при формировании разбиения V^{q+1} из разбиения V^q .

Задача формулируется следующим образом. Пусть из изображения U получено суперпиксельное изображение V^0 . Методом выращивания сегментов из суперпикселей $S_k^{q+1} = S_k^{V^q} \cup S_l^{V^q}$, $V^{q+1} = \bigcup_k S_k^{V^{q+1}}$, $V^q = \bigcup_k S_k^{V^q}$ необходимо сформировать разбиение $V^{q \min}$ такое, что

$$M_c(U, V^{q \min}) \leq \dots \leq M_c(U, V^{q+1}) \leq M_c(U, V^q) \leq \dots \leq M_c(U, V^0).$$

2. Алгоритмы выращивания сегментов на основе «жадной» стратегии.

Предложим три варианта ускоренных алгоритмов получения карт сегментаций. В «жадных» модификациях вышеописанного базового алгоритма объединение суперпикселей выполняется непосредственно в процессе сканирования разбиения V^0 . Пусть Ω_k — множество суперпикселей, соседних с суперпикселем с центром $\mathbf{C}_k$, $\Omega_k = \{S_l^{V_m}\}$, $l = 1, 2, \dots, L$, $\partial S_k^{V_m} \cap S_l^{V_m} \neq \emptyset$, $\partial S_l^{V_m} \cap S_k^{V_m} \neq \emptyset$, где V_m — разбиение на шаге объединения m , $\partial S_k^{V_m}$ и $\partial S_l^{V_m}$ — границы суперпикселей $S_k^{V_m}$, $S_l^{V_m}$. Алгоритмы включают следующие операции:

1. Назначается начальное значение параметра $t = t_0$ и $V_m = V^0$, $m = 0$.
2. Выбирается суперпиксель $S_k^{V_m}$ изображения V_m с центром $\mathbf{C}_k$.
3. Проверяется условие объединения суперпикселя $S_k^{V_m}$ с центром $\mathbf{C}_k$ с соседним суперпикселем $S_l^{V_m} \subset \Omega_k$ с центром $\mathbf{C}_l$.
4. Если условие объединения выполняется, то суперпиксель $S_k^{V_m}$ объединяется с суперпикселем $S_l^{V_m} \subset \Omega_k$:

$$S_{kl} = S_k^{V_m} \bigcup S_l^{V_m}, \quad 1 \leq k \leq K_m, \quad 1 \leq l \leq L,$$

где $K_m = |V_m|$ — число суперпикселей разбиения V_m . Объединённому суперпикселю $S_{kl}^{V_m}$ присваивается номер k , $S_k^{V_m} = S_{kl}^{V_m}$, пересчитывается вектор координат центра $\mathbf{C}_k$.

5. $K_m = K_m - 1$, $l = l + 1$, $m = m + 1$.
6. Если условие объединения не выполняется и $l < L$, то $l = l + 1$, переход к операции 3.
7. Если $l > L$, то выбирается следующий суперпиксель $k = k + 1$, переход к операции 3.
8. Если $k > K_m$, то меняется параметр $t = t + \Delta t$, и выполняется переход к операции 3.

Алгоритм выполняется до достижения стабильности или минимально допустимого количества сегментов $K_m = 2$.

В представленных алгоритмах используются три различных условия объединения. В первом из предлагаемых «жадных» алгоритмов применяется условие (6), наложенное на расстояние в цветовом пространстве между центрами объединяемых объектов.

Во втором алгоритме необходимо, чтобы в результате слияния суперпикселей не возрастала информационная мера качества (4):

$$\Delta M_c = M_c(U, V_{m+1}) - M_c(U, V_m) \leq 0, \quad (7)$$

где V_m — разбиение изображения U на шаге объединения m .

В третьем алгоритме условием слияния суперпикселей является комбинация (логическое «И») условий (6) и (7). Так как второй и третий алгоритмы обеспечивают невозрастание меры качества (4), то на их выходе будет получено разбиение с минимальным значением меры. При этом не требуется формировать большое число разбиений для всего диапазона значений параметра t , как в первом алгоритме. Указанное обстоятельство обусловило более высокое быстродействие второго и третьего алгоритмов.

Для проверки условий объединения, в которых используется мера (4), применяются следующие формулы вычисления её приращения:

$$\Delta M_c = (1 - \gamma) \Delta R + \gamma \Delta V I_n,$$

$$\Delta R = R(U, V_{m+1}) - R(U, V_m) = \frac{H(U, V_{m+1}) - H(U)}{H(V_{m+1})} - \frac{H(U, V_m) - H(U)}{H(V_m)},$$

$$\Delta V I_n = \frac{2H(U, V_{m+1}) - H(V_{m+1}) - H(U)}{H(U, V_{m+1})} - \frac{2H(U, V_m) - H(V_m) - H(U)}{H(U, V_m)}.$$

Прогнозируемые совместные и маргинальные энтропии на шаге $m + 1$ вычисляются по формулам:

$$H(U, V_{m+1}) = H(U, V_m) + \sum_{i=1}^{L_U} \frac{n_{ik}}{N} \log \frac{n_{ik}}{n_{ik} + n_{il}} + \sum_{i=1}^{L_U} \frac{n_{il}}{N} \log \frac{n_{il}}{n_{ik} + n_{il}},$$

$$H(V_{m+1}) = H(V_m) + \sum_{i=1}^{L_U} \frac{n_{ik}}{N} \log \left(\sum_{i=1}^{L_U} n_{ik} / \sum_{i=1}^{L_U} (n_{ik} + n_{il}) \right) +$$

$$+ \sum_{i=1}^{L_U} \frac{n_{il}}{N} \log \left(\sum_{i=1}^{L_U} n_{il} / \sum_{i=1}^{L_U} (n_{ik} + n_{il}) \right),$$

где N — количество пикселей в изображениях U , V_m и V_{m+1} ; L_U — количество уровней яркости изображения U ; k и l — метки сегментов разбиения V_m ; n_{ik} , n_{il} — частоты встречаемости пикселей с уровнем яркости i и метками сегментов k и l в двумерной гистограмме изображений U и V_m .

Предлагаемые алгоритмы на основе «жадной» стратегии позволяют найти разбиения, соответствующие локальному минимуму применяемой меры качества.

3. Вычислительный эксперимент. Опишем вычислительный эксперимент, подтверждающий эффективность предложенных алгоритмов. Вычислительный эксперимент проводился на наборе тестовых изображений из базы BSDS500 [17] с использованием персонального компьютера с процессором Intel Core i5-2410M, 2,3 ГГц, 4 ГБ оперативной памяти и операционной системой Windows. Эксперимент включал в себя три этапа. На первом этапе с помощью информационных мер оценивалось качество разбиений, порождаемых предложенными алгоритмами выращивания сегментов. Проведено сравнение полученных разбиений с разбиениями, образованными базовым алгоритмом [13]. На втором этапе оценивалось информационное различие разбиений, полученных разработанными алгоритмами, с эталонными разбиениями из базы BSDS500. На третьем этапе оценивалось быстроедействие предложенных алгоритмов.

Чтобы применить информационную меру (4) к цветным изображениям, значения меры избыточности R (3) и вариации информации $V I_n$ (5) для разных цветовых каналов взвешивались соответствующими энтропиями [18, 19].

На первом этапе эксперимента из семи тестовых изображений U_i , $i = 1, 2, \dots, 7$ получены разбиения $V_i^j(\gamma)$, $j = 1, 2, \dots, 4$ с использованием четырёх алгоритмов формирования сегментов (базового алгоритма и трёх его «жадных» модификаций, описанных в разд. 2) при пяти различных значениях параметра γ меры качества (4). Для каждого разбиения вычислено значение меры $M_c(U_i, V_i^j(\gamma))$ и её составляющих $R(U_i, V_i^j(\gamma))$ и $V I_n(U_i, V_i^j(\gamma))$. Далее определены средние значения этих мер для семи разбиений, полученных алгоритмом j при заданных значениях γ . Результаты первого этапа эксперимента на тестовых




Рис. 1. Графики зависимости среднего значения комбинированной меры качества сегментации $M_c(U, V)$ для базового и трёх «жадных» алгоритмов от параметра γ . Обозначения: кривая 1 — Mean M_c , info; кривая 2 — Mean M_c , color; кривая 3 — Mean M_c , info+color; кривая 4 — Mean M_c , Basic

изображениях приведены на рис. 1 и 2, на которых показаны графики зависимостей средних значений комбинированной меры качества сегментации $M_c(U, V)$ и её составляющих $R(U, V)$ и $VI_n(U, V)$. На рисунках введены следующие обозначения: Mean M_c — среднее значение меры $M_c(U, V)$; Mean R — среднее значение избыточности $R(U, V)$; Mean VI — среднее значение вариации информации $VI_n(U, V)$. Средние значения мер для разбиений тестовых изображений, полученных базовым алгоритмом, имеют метку «Basic», алгоритмом с условием слияния суперпикселей (6) помечены как «color», алгоритмом с условием (7) — «info», а алгоритмом с комбинированным условием — «info+color». Из рис. 1 и 2, а следует, что объединение суперпикселей с помощью «жадной» стратегии позволило в среднем уменьшить по сравнению с разработанным ранее базовым алгоритмом [13] величины информационной избыточности и комбинированной меры качества (4) при большем информационном отличии (т. е. вариации информации $VI_n(U, V)$) разбиений от оригинальных изображений (рис. 2, б) при $\gamma \leq 0,5$. С ростом параметра γ число сегментов в разбиениях увеличивается для всех алгоритмов, а значение вариации информации убывает.

На втором этапе эксперимента сравнение полученных разбиений с эталонами из базы BSDS500 показало, что наибольшее сходство с эталоном (соответственно, меньшее значение вариации информации) достигается «жадными» алгоритмами объединения суперпикселей при значении параметра меры качества (4) $0,25 \leq \gamma \leq 0,6$ (рис. 3). Однако результаты сегментации «жадными» алгоритмами в большей степени отличаются от эталонов, чем разбиения, сформированные базовым алгоритмом. Эксперимент также показал, что «жадные» алгоритмы, в которых условия объединения включают условие (7), при малых значениях параметра γ позволяют получить приемлемые карты сегментации не для всех тестовых изображений. Поэтому для этих алгоритмов необходимо задавать подходящее значение параметра γ .

Примеры формирования карт сегментаций из суперпиксельного изображения с помощью базового и предложенных «жадных» алгоритмов при двух значениях параметра комбинированной информационной меры качества (4) представлены на рис. 4–6. На рис. 4 показаны тестовое изображение, суперпиксельное изображение, полученное алгоритмом




Рис. 2. Графики зависимостей средней меры избыточности $R(U, V)$ (a) и средней нормированной вариации информации $VI_n(U, V)$ (b) для разбиений тестовых изображений, полученных базовым алгоритмом и тремя «жадными» алгоритмами, от параметра γ . Обозначения на рис. 2, a: кривая 1 — Mean R , info; кривая 2 — Mean R , color; кривая 3 — Mean R , info+color; кривая 4 — Mean R , Basic. Обозначения на рис. 2, b: кривая 1 — Mean VI , info; кривая 2 — Mean VI , color; кривая 3 — Mean VI , info+color; кривая 4 — Mean VI , Basic




Рис. 3. Графики зависимости среднего значения информационного различия (средней нормированной вариации информации) $VI_n(V, V^{GT})$ между эталонными разбиениями и разбиениями тестовых изображений, полученных базовым и тремя «жадными» алгоритмами, от параметра γ . Обозначения: кривая 1 — Mean VI , Basic; кривая 2 — Mean VI , color; кривая 3 — Mean VI , info; кривая 4 — Mean VI , info+color




Рис. 4. Тестовое изображение из базы BSDS500 (a), суперпиксельное изображение (b) и эталонное разбиение (c)



Рис. 5. Карты сегментации, полученные различными алгоритмами слияния суперпикселей при $\gamma = 0$: a — базовым алгоритмом; b — «жадным» алгоритмом с условием минимизации расстояния в цветовом пространстве; c — «жадным» алгоритмом с условием минимизации информационной меры; d — «жадным» алгоритмом с условием минимизации комбинации расстояния в цветовом пространстве и информационной меры



Рис. 6. Карты сегментации, полученные различными алгоритмами слияния суперпикселей при $\gamma = 0,5$: a — базовым алгоритмом; b — «жадным» алгоритмом с условием минимизации расстояния в цветовом пространстве; c — «жадным» алгоритмом с условием минимизации информационной меры; d — «жадным» алгоритмом с условием минимизации комбинации расстояния в цветовом пространстве и информационной меры

SLIC, и одно из эталонных разбиений из базы BSDS500. На рис. 5 представлены результаты работы четырёх алгоритмов при значении параметра $\gamma = 0$, а на рис. 6 — при $\gamma = 0,5$. На рис. 5 и 6 показано, что с ростом параметра γ число сегментов в разбиениях возрастает. При $\gamma = 0,5$ карты сегментации, полученные «жадными» алгоритмами, имеют большее сходство с эталоном, представленным на рис. 4, c, что соответствует графикам вариации информации на рис. 3.

На третьем этапе получены экспериментальные оценки затрат времени разными алгоритмами. При $\gamma = 0$ базовым алгоритмом затрачено на формирование разбиения 34,97 с, «жадным» алгоритмом с условием объединения (6) — 27,78 с, алгоритмом с условием (7) — 2,81 с, а алгоритмом с комбинированным условием — 22,59 с. Из результатов эксперимен-

та следует, что информационные характеристики разбиений тестовых изображений, полученные алгоритмом с условием объединения суперпикселей (7), близки к характеристикам разбиений, полученных алгоритмом с комбинированным условием (6), (7) (см. рис. 1–3) при меньших затратах времени.

Заключение. Предложены новые алгоритмы объединения суперпикселей с использованием «жадной» стратегии и комбинированной информационной меры качества в задаче сегментации изображений. Применяемая мера позволяет получить разбиение изображения, обеспечивающее компромисс между условиями минимизации количества выделенных информационно важных сегментов и минимизации информационного различия между оригинальным изображением и полученным разбиением. Предлагаемые алгоритмы позволяют значительно ускорить процесс сегментации по сравнению с применявшимся ранее базовым алгоритмом и улучшить информационные характеристики полученных разбиений. Наибольшее быстроедействие обеспечивается алгоритмом с информационным условием объединения суперпикселей.

Результаты вычислительного эксперимента позволили сформулировать рекомендации по выбору параметра γ комбинированной меры качества. Из анализа результатов следует, что целесообразно выбирать параметр в диапазоне $0,25 \leq \gamma \leq 0,6$. При таких значениях параметра, во-первых, карты сегментации, полученные всеми алгоритмами, имеют наибольшее сходство с эталонными разбиениями; во-вторых, информационная избыточность возрастает незначительно; в-третьих, информационное различие карт сегментации и оригинальных изображений уменьшается. При меньших значениях параметра «жадные» алгоритмы с информационным условием объединения суперпикселей могут сформировать неприемлемые карты сегментации. При $\gamma > 0,6$ количество сегментов в разбиениях возрастает, что может приводить к пересегментации и существенному увеличению избыточности.

СПИСОК ЛИТЕРАТУРЫ

1. Ikonomatakis N., Plataniotis K. N., Zervakis M., Venetsanopoulos A. N. Region growing and region merging image segmentation // Proc. of the 13th Int. Conf. on Digital Signal Processing. Santorini, Greece, 2–4 July, 1997. Vol. 1. P. 299–302. DOI: 10.1109/ICDSP.1997.628077.
2. Егорова А. А., Сергеев В. В. Система признаков для расширенного суперпиксельного представления изображений // Компьютерная оптика. 2021. **45**, № 4. С. 562–574. DOI: 10.18287/2412-6179-CO-876.
3. Calderero F., Marques F. Region Merging Techniques Using Information Theory Statistical Measures // IEEE Trans. Image Processing. 2010. **19**, Iss. 6. P. 1567–1586. DOI: 10.1109/TIP.2010.2043008.
4. Peng B., Zhang L., Zhang D. Automatic image segmentation by dynamic region merging // IEEE Trans. Image Processing. 2011. **20**, Iss. 12. P. 3592–3605. DOI: 10.1109/TIP.2011.2157512.
5. Ko H.-Y., Ding J.-J. Adaptive growing and merging algorithm for image segmentation // Proc. of the Asia-Pacific Signal and Information Processing Association Annual Summit and Conf. (APSIPA). Jeju, South Korea, 13–16 Dec., 2016. DOI: 10.1109/APSIPA.2016.7820762.
6. Chamalis T., Likas A. Region merging for image segmentation based on unimodality tests // Proc. of the 3rd Int. Conf. on Control, Automation and Robotics (ICCAR). Nagoya, Japan, 24–26 April, 2017. P. 381–384. DOI: 10.1109/ICCAR.2017.7942722.
7. Tang R., Song W., Guan X. et al. Dam Burst: A region-merging-based image segmentation method // ArXiv. 2020. DOI: 10.48550/arXiv.2003.04797.

8. **Rigau J., Feixas M., Sbert S. et al.** An information theoretic framework for image segmentation // Proc. of the Int. Conf. on Image Processing (ICIP). Singapore, 24–27 Oct., 2004. Vol. 2. P. 1193–1196. DOI: 10.1109/ICIP.2004.1419518.
9. **Bardera A., Rigau J., Boada I. et al.** Image Segmentation Using Information Bottleneck Method // IEEE Trans. Image Processing. 2009. **18**, Iss. 7. P. 1601–1612. DOI: 10.1109/TIP.2009.2017823.
10. **Mirsadeghi S. E., Royat A., Rezatofghi H.** Unsupervised Image Segmentation by Mutual Information Maximization and Adversarial Regularization // IEEE Robot. and Automat. Lett. 2021. **6**, Iss. 4. P. 6931–6938. DOI: 10.1109/LRA.2021.3095311.
11. **Tishby N., Pereira F. C., Bialek W.** The information bottleneck method // Proc. of the 37th Ann. Allerton Conf. on Communication, Control and Computing. 1999. P. 368–377.
12. **Lv X., Persello C., Li W. et al.** DeepMerge: Deep-Learning-Based Region-Merging for Image Segmentation // ArXiv Preprint. 2023. DOI: 10.48550/arXiv.2305.19787.
13. **Murashov D.** Theoretical-information quality model for image segmentation // Procedia Engineering. 2017. **201**. P. 239–248.
14. **Murashov D. M.** A New Quality Measure for Image Segmentation Based on Combination of Information Redundancy and Variation of Information // Patt. Recogn. and Image Anal. 2022. **32**, Iss. 3. P. 600–606. DOI: 10.1134/S1054661822030257.
15. **Achanta R., Shaji A., Smith K. et al.** SLIC Superpixels Compared to State-of-the-Art Superpixel Methods // IEEE Trans. Pattern Analysis and Machine Intell. 2012. **34**, Iss. 11. P. 2274–2282. DOI: 10.1109/TPAMI.2012.120.
16. **Meilă M.** Comparing Clusterings — An Axiomatic View // Proc. of the 22nd Int. Conf. on Machine Learning. Bonn, Germany, 7–11 Aug., 2005. P. 577–584.
17. **Arbeláez P., Maire M., Fowlkes C., Malik J.** Contour Detection and Hierarchical Image Segmentation // IEEE Trans. Pattern Analysis and Machine Intell. 2010. P. 898–916.
18. **Murashov D. M.** An Information Model for Digital Image Segmentation // Patt. Recogn. and Image Anal. 2021. **31**, Iss. 4. P. 632–645.
19. **Мурашов Д. М.** Метод комбинирования карт сегментации изображений на основе минимизации информационной избыточности и вариации информации // Автометрия. 2022. **58**, № 5. С. 34–42. DOI: 10.15372/AUT20220504.

Поступила в редакцию 05.07.2024

После доработки 18.07.2024

Принята к публикации 24.07.2024