

Применение теоретико-информационного подхода для сегментации изображений*

Д. М. Мурашов

d_murashov@mail.ru

ФИЦ «Информатика и управление» РАН, Россия, г. Москва, ул. Вавилова, 44/2

Рассматривается задача разработки метода обеспечения наилучшего качества сегментации цифровых изображений. Метод ориентирован на применение модифицированного суперпиксельного алгоритма сегментации. В известных работах для оценки качества сегментации использовался «взвешенный показатель достоверности», вычисляемый через значения нормализованной взаимной информации цветочных каналов входного и сегментированного изображений. Зависимость показателя достоверности от параметра алгоритма сегментации монотонна, что потребовало обучения алгоритма и разработки итерационной процедуры выбора параметра. В данной работе в качестве критерия для оптимизации качества сегментации предлагается применять меру избыточности информации. Такой критерий обеспечивает лучший результат с точки зрения визуального восприятия. Показано, что предложенный способ построения меры избыточности позволил получить экстремальные свойства. Эксперимент, проведенный на изображениях из базы Berkeley Segmentation Dataset, подтвердил, что сегментированное изображение, соответствующее минимуму меры избыточности, дает минимальное различие по теоретико-информационной мере при сравнении с исходным изображением. Кроме того, выбранный с помощью предложенного критерия вариант сегментации дает наибольшее сходство с эталонами, имеющимися в базе.

Ключевые слова: сегментация изображений; теоретико-информационная модель; мера избыточности; суперпиксельный алгоритм

DOI: 10.21469/22233792.2.2.08

1 Введение

Рассматривается задача разработки метода обеспечения наилучшего качества сегментации цифровых изображений и определения соответствующего параметра модифицированного суперпиксельного алгоритма SLIC (Simple Linear Iterative Clustering) [1, 2].

В работе [3] под сегментацией понимается процесс разделения изображения, представляемого как область Ω , на n непересекающихся связанных подобластей (сегментов) $\Omega_1, \Omega_2, \dots, \Omega_n$, элементы которых схожи по какому-либо признаку и отличаются от элементов соседних областей. Строгое определение сегментации дано в работе [4]. При сегментации изображений возникает проблема выбора параметров применяемых алгоритмов. Параметры выбираются исходя из наилучшего качества сегментации. При этом для разных задач анализа изображений выбирается свой критерий качества. Это может быть визуальная оценка эксперта или какой-либо количественный показатель. В исследованиях по сегментации результат обычно сравнивается с изображением, сегментированным экспертом и принятым в качестве эталона [5, 6]. Возможно наличие нескольких эталонов, принятых разными экспертами.

*Работа выполнена при финансовой поддержке РФФИ, проекты № 15-07-09324 и № 15-07-07516.




Рис. 1 Зависимость показателя недостоверности W от числа сегментов K , выделенных на изображении из базы BSDS500

Если операция сегментации рассматривается как процесс кластеризации пикселей, то применяются теоретико-множественные, статистические и теоретико-информационные меры [7], используемые для сравнения результатов кластеризации данных. Наиболее часто применяются меры хи-квадрат; индекс Рэнда (Rand Index) [8] и его варианты; мера Фаулкса–Мэллоуза (Fowlkes–Mallows) [9]; взаимная информация и варианты нормализованной взаимной информации [10]; вариация информации (variation of information) [11, 12]. Эти меры позволяют сравнить разные варианты разбиения изображений на непересекающиеся сегменты. В работе [5] отмечается, что стандартная методика для оценки эффективности алгоритмов сегментации еще не выработана.

В работе [13] предложен другой подход. При выборе параметров алгоритма оценивалось не сходство сегментированного изображения с эталоном, а сходство результата сегментации с исходным изображением. В качестве меры сходства исходного и сегментированного изображений предложено использовать «взвешенный показатель недостоверности» (weighted uncertainty index), вычисляемый через значения нормализованной взаимной информации соответствующих цветовых каналов входного и сегментированного изображений [10]. Авторы предлагают выбирать значения параметра, при которых получается наилучший с точки зрения визуального восприятия результат сегментации. Кривая зависимости показателя недостоверности от параметра i , соответственно, от числа выделенных подобластей (классов), построенная для одного изображения, не имеет экстремумов (см. [13] и рис. 1). Поэтому по экспертным оценкам результатов сегментации фрагментов серии изображений, выполненной при различных значениях параметра, на координатной плоскости с помощью классификатора, аналогичного SVM (support vector machine), выделены области «недосегментации», «пересегментации» и оптимальной сегментации. При сегментации изображений параметр алгоритма для каждой точки (x, y) обрабатываемого изображения выбирается с помощью итерационной процедуры на основе graph-cut алгоритма [14]. При этом сначала вычисляются значения показателя недостоверности для двух граничных значений параметра, а затем происходит итерационная корректировка параметра до попадания в область оптимальной сегментации. К недостаткам такого подхода следует отнести субъективность экспертных оценок, а также то, что обученный алгоритм будет давать приемлемые результаты только для тех классов изображений, которые использовались при обучении.

В данной работе лучшим вариантом сегментации считается тот, который дает приемлемое значение теоретико-информационной меры сходства при сравнении с исходным изображением, т. е. при сегментации не происходит потери значительной части информации. Принимается, что лучшее качество сегментации соответствует минимуму теоретико-информационной меры различия при сравнении с исходным изображением. Наилучшая сегментация содержит информацию только о наиболее важных деталях исходного изображения и, как и в [13], является лучшим с точки зрения визуального восприятия. В работе [15] предложена теоретико-информационная модель зрительной системы человека. В качестве основы модели использована гипотеза Барлоу [16] о минимизации избыточности информации на ранних стадиях обработки сигнала в зрительной системе человека. Предполагается, что на ранних стадиях зрительного восприятия происходит сокращение избыточности информации, поступающей от сетчатки через зрительный нерв. В данной работе, исходя из принципа минимизации избыточности информации [15], для определения наилучшего варианта сегментации изображений (и определения соответствующего параметра алгоритма) в качестве критерия предлагается применять меру избыточности информации. В предлагаемой работе установлено, что при определенном способе формирования теоретико-информационной модели системы сегментации мера избыточности обладает экстремальными свойствами. Сегментированное изображение, соответствующее минимуму меры избыточности, дает минимум меры различия при сравнении с исходным изображением. Эксперимент, проведенный на изображениях из базы Berkeley Segmentation Dataset BSDS500 [5], показал, что выбранный с помощью предложенного критерия вариант сегментации дает наибольшее сходство с эталонами.

2 Модификация алгоритма сегментации SLIC

Исследования по разработке метода выбора наилучшего варианта сегментации проводились на базе суперпиксельного алгоритма SLIC [1], дополненного предлагаемой ниже процедурой постобработки. Этот алгоритм простой и позволяет достаточно быстро получить серию сегментированных изображений при вариации параметра процедуры постобработки. В следующем подразделе дается краткое описание используемого суперпиксельного алгоритма.

2.1 Алгоритм сегментации SLIC

Основная идея алгоритма сегментации SLIC заключается в кластеризации пикселей в ограниченных областях, на которые регулярным образом разбивается анализируемое изображение. Каждая точка изображения характеризуется пятимерным вектором $\mathbf{p} = (c_1, c_2, c_3, x, y)^T$, где c_1, c_2 и c_3 — координаты точки в выбранном цветовом пространстве; x и y — пространственные координаты точки изображения. Авторы метода использовали цветовое пространство CIE Lab.

Алгоритм включает следующие шаги.

1. Изображение разбивается на K фрагментов размера $a \times a$, которые задают начальное приближение кластеров-суперпикселей. В качестве начальных центров суперпиксельных фрагментов выбираются их геометрические центры C_k .
2. Корректируются координаты центров фрагментов из условия минимального значения цветового градиента в 3×3 окрестности геометрического центра.
3. Формирование локальных кластеров в $2a \times 2a$ окрестности центров C_k аналогично методу k -средних. Расстояние D между центром и точками фрагмента вычисляется

как комбинация евклидовых расстояний по цветовой d_c и пространственной d_s составляющим описания точки \mathbf{p} :

$$d_c = \sqrt{(c_{j1} - c_{i1})^2 + (c_{j2} - c_{i2})^2 + (c_{j3} - c_{i3})^2}; \quad (1)$$

$$d_s = \sqrt{(x_j - x_i)^2 + (y_j - y_i)^2}; \quad (2)$$

$$D = \sqrt{d_c^2 + \left(\frac{d_s}{a}\right)^2 m^2}, \quad (3)$$

где m — параметр, задающий соотношение вкладов двух составляющих описания изображения в величину расстояния D ; i и j — номера точек, между которыми вычисляется расстояние.

4. Определение новых центров кластеров и вычисление смещений центров.
5. Повтор шагов 3 и 4 до тех пор, пока смещение центров между итерациями не станет меньше заданного значения.

Чтобы выделить однородные области, соответствующие объектам, зафиксированным на изображении, необходимо объединить отдельные суперпиксельные кластеры. Для этого предлагается процедура постобработки, описанная в следующем подразделе.

2.2 Процедура постобработки

В представляемой работе для сегментации цветного изображений предлагается применять алгоритм SLIC с двухступенчатой постобработкой. Целью постобработки является объединение полученных суперпикселей в однородные области, соответствующие объектам исходного изображения.

На первой ступени предлагается производить объединение соседних суперпиксельных областей. Для принятия решения об объединении используется пороговое решающее правило, разрешающее объединение, если выполняется неравенство:

$$d(C_i C_j) \leq \Delta_1; \quad (4)$$

$$d(C_i C_j) = \sqrt{(c_{1j} - c_{1i})^2 + (c_{2j} - c_{2i})^2 + (c_{3j} - c_{3i})^2}, \quad (5)$$

где $d(C_i C_j)$ — расстояние между центрами соседних суперпикселей с номерами i и j в выбранном цветовом пространстве; c_{1k} , c_{2k} и c_{3k} — координаты центра k ; Δ_1 — пороговое значение.

На второй ступени предлагается объединять суперпиксельные кластеры в пределах всего изображения. Для принятия решения об объединении, так же как и на первой ступени, используется пороговое решающее правило, разрешающее объединение, если выполняется неравенство:

$$d(C_i C_j) \leq \Delta_2, \quad (6)$$

где Δ_2 — пороговое значение.

Процедура включает следующие шаги: (а) просмотр массива центров суперпиксельных кластеров изображения и формирование матрицы объединения соседних суперпикселей по правилу (4)–(5); (б) объединение соседних суперпиксельных кластеров; (в) нахождение центров новых кластеров; (г) просмотр массива центров кластеров для формирования матрицы объединения суперпикселей по правилу (6); (д) объединение схожих суперпиксельных кластеров. Результаты сегментации изображения из базы BSDS500 показаны на рис. 2.

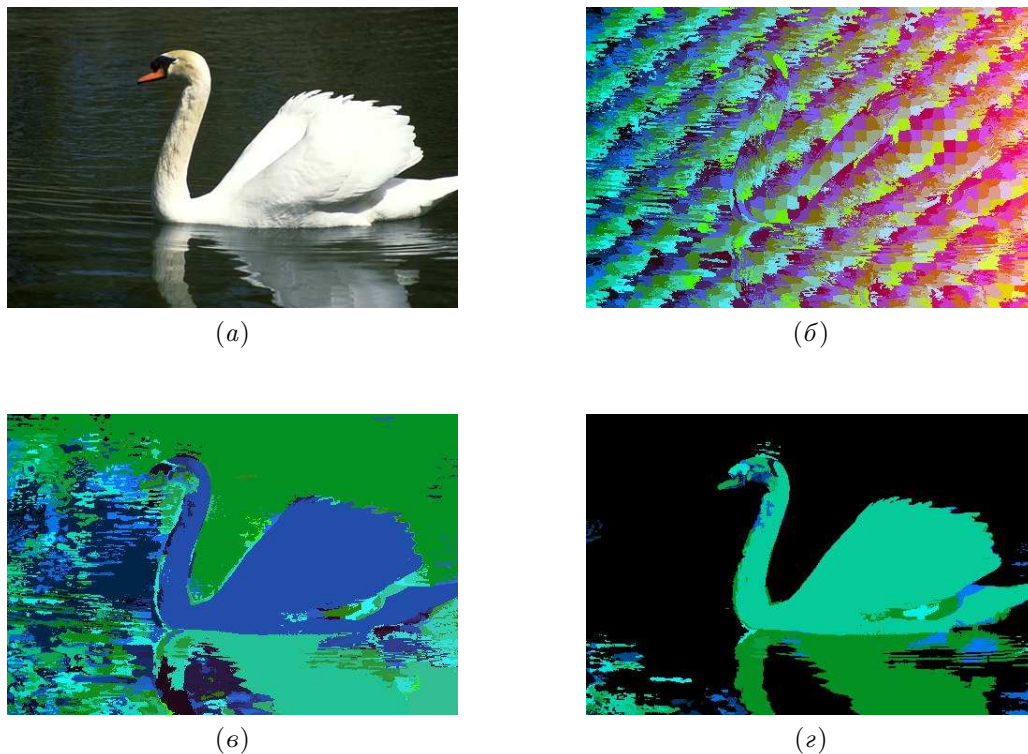


Рис. 2 Результат работы алгоритма сегментации с двухступенчатой постобработкой: (а) исходное изображение; (б) результат сегментации без постобработки; (в) и (г) изображения, полученные после первой и второй ступеней постобработки

Таким образом, предлагаемая процедура на базе алгоритма суперпиксельной сегментации SLIC содержит четыре параметра: начальная длина стороны суперпиксельной области a , параметр m , задающий соотношение вкладов цветовой и пространственной составляющих описания точек изображения в величину расстояния (1)–(3) и два пороговых значения Δ_1 и Δ_2 в решающих правилах (4)–(6).

В следующем разделе предлагается метод, позволяющий выбрать наилучший вариант сегментации и определить соответствующее значение порога первой ступени процедуры постобработки.

3 Выбор наилучшего варианта сегментации и определение параметров алгоритма

Выбор параметров алгоритма осуществляется следующим образом. Начальный размер a суперпикселей задается по размеру наименьших деталей изображения, которые должны быть выделены. Параметр m специфичен для каждой решаемой задачи. Наибольший интерес представляет выбор порогов Δ_1 и Δ_2 правил (4)–(6) процедуры постобработки.

Для применения теоретико-информационного подхода необходима вероятностная модель связи между исходным и сегментированным изображениями. При оценивании качества сегментации будем использовать каналы цветового пространства CIE *Lab* (например, L).

Пусть исходное и сегментированное изображения являются входом и выходом стохастической информационной системы. Уровни светлоты L изображений описываются

непрерывными случайными переменными U и V с плотностями вероятности $p(u)$ и $p(v)$, где u и v — значения переменных U и V . Операция сегментации будет представлена моделью информационного канала:

$$V = F(U + \eta), \quad (7)$$

где U — сигнал на входе канала; V — выход канала; F — функция преобразования; η — шум канала. Предполагается, что шум является гауссовой случайной переменной с нулевым средним и дисперсией σ^2 ; переменные V и η независимы.

В качестве критерия качества сегментации изображений предлагается использовать меру избыточности канала, определяемую выражением [15]:

$$R = 1 - \frac{I(U; V)}{C(V)}, \quad (8)$$

где $I(U; V)$ — взаимная информация между входом и выходом; $C(V)$ — пропускная способность канала.

Положим $C(V) = H(V)$, где $H(V)$ — энтропия выхода. Тогда, учитывая, что $I(U; V) = H(V) - H(V|U)$, выражение (8) примет вид:

$$R = \frac{H(V|U)}{H(V)}, \quad (9)$$

где $H(V|U)$ — условная энтропия выхода канала при условии, что вход равен U .

Покажем, что величина меры избыточности системы сегментации, описываемой моделью (7)–(9), зависит от количества сегментов и имеет минимум.

В соответствии со способом представления сегментированного изображения плотность вероятности выхода системы может быть представлена суммой:

$$p(v) = \sum_{k=1}^K P(v_k) \delta(v - v_k), \quad (10)$$

где $P(v_k)$ — вероятность появления значения v_k ; $\delta(v - v_k)$ — дельта-функция; K — количество выделенных сегментов. В случае непрерывной модели (7) дифференциальная энтропия выхода системы с учетом (10) равна:

$$H(V) = - \int_{-\infty}^{+\infty} p(v) \log p(v) dv = - \sum_{k=1}^K P(v_k) \log P(v_k). \quad (11)$$

Пусть все значения V равновероятны: $P(v_k) = 1/K$. Тогда из (11) получим

$$H(V) = \log K. \quad (12)$$

Далее найдем значение условной дифференциальной энтропии $H(V|U)$. Условная энтропия $H(V|U)$ является мерой информации о шуме η сигнала, которая измеряется на выходе системы. В этом случае можно принять [17]:

$$H(V|U) = H(\eta). \quad (13)$$

Дифференциальная энтропия гауссова шума равна [17]:

$$H(\eta) = \frac{1}{2} [\log e + \log (2\sigma_\eta^2)], \quad (14)$$

где σ_η^2 — дисперсия шума системы. Тогда, подставляя (12)–(14) в (9), получим

$$R = \frac{\log e + \log (2\sigma_\eta^2)}{2 \log K}. \quad (15)$$

Таким образом, мера избыточности линейно зависит от логарифма дисперсии шума и обратно пропорциональна логарифму количества полученных сегментов. Функция $R(K)$ будет иметь минимум, например, если при малых значениях K дисперсия шума близка к нулю, а при увеличении K резко возрастает. Предложена модель дисперсии шума от количества сегментов на выходе системы сегментации, которая описывается полиномом шестой степени. Модель позволяет получить минимум функции (15) и согласуется с данными эксперимента на большинстве тестовых изображений.

Учитывая зависимость избыточности от количества сегментов, выбор наилучшего варианта сегментации производится следующим образом. Исследуемое изображение U сегментируется с помощью модифицированного алгоритма SLIC с различными значениями параметра Δ_1 условия (4) процедуры постобработки. В результате сегментации изображения получено множество из Q изображений $\mathfrak{V} = \{V_1, V_2, \dots, V_Q\}$. Далее сегментированные изображения $V_q, q = 1, 2, \dots, Q$, сравниваются с исходным изображением U и выбирается сегментация $V_q = V_{R_{\min}}$, при которой $R(V_q) = R_{\min}$. Выбранному изображению, состоящему из K_{\min} сегментов, соответствует значение параметра $\Delta_1 = \Delta_{1 \min}$.

4 Вычислительный эксперимент

В данной работе при выборе параметров использовались изображения из базы BSDS500 университета Беркли [5]. Каждое из исследуемых изображений сегментировалось с помощью модифицированного алгоритма SLIC с различными значениями параметра Δ_1 условия (4) процедуры постобработки. В результате сегментации изображения U получено множество из Q изображений $\mathfrak{V} = \{V_1, V_2, \dots, V_Q\}$. Далее сегментированные изображения сравнивались с исходным изображением U и с вариантами эталонной сегментации $V_t^{GT}, t = 1, 2, \dots, T$ из базы BSDS500. Для сравнения изображений применялась вариация информации (variation of information) — теоретико-информационная мера, предложенная в работах [11, 12]. Вариация информации является метрикой и обладает свойствами, полезными для сравнения результатов кластеризации данных. В рассматриваемом случае вариация информации характеризует различие (расстояние) между двумя версиями сегментации (или между исходным и сегментированным изображением) и определена следующим образом:

$$VI(S, S') = H(S) + H(S') - 2I(S; S'), \quad (16)$$

где $VI(S, S')$ — вариация информации; $H(S)$ и $H(S')$ — энтропии сравниваемых изображений S и S' ; $I(S; S')$ — взаимная информация сравниваемых изображений. С целью подтверждения того, что сегментированное изображение, обеспечивающее минимальное значение меры избыточности, является наилучшим в смысле сходства с входным изображением и сходства с эталонными вариантами сегментации, решались следующие задачи. Во-первых, для исходного изображения U и каждого из изображений $V_q, q = 1, 2, \dots, Q$,



Рис. 3 Изображение из базы BSDS500




Рис. 4 Результат работы алгоритма сегментации: (а) соотношение между значением порога Δ_1 и количеством сегментов K ; (б) зависимости меры избыточности R от числа сегментов K в каналах L (RL) и a (Ra) цветового пространства CIE Lab для изображения, показанного на рис. 3

полученных с помощью модифицированного алгоритма сегментации при различных значениях параметра, вычислены значения меры избыточности R . Затем среди изображений V_q находилось изображение $V_{R_{\min}}$, соответствующее глобальному минимуму R . Во-вторых, сравнивалось расстояние от входного изображения U до найденного варианта сегментации $V_{R_{\min}}$ по выбранной мере (9) с расстояниями до других изображений V_q . В-третьих, эталонные сегментации V_t^{GT} сравнивались с входным изображением U . В-четвертых, сравнивались расстояния между каждым из эталонов V_t^{GT} и вариантом сегментации $V_{R_{\min}}$ с расстояниями между эталонами и сегментациями V_q . В эксперименте использовалось 20 изображений. Сегментация изображений производилась в цветовом пространстве CIE Lab. Результаты эксперимента будут продемонстрированы на изображении 118035.jpg (рис. 3).

Получены следующие результаты. С помощью алгоритма SLIC с процедурой постобработки произведена сегментация изображений из базы при значениях порога Δ_1 в интервале $0 \leq \Delta_1 \leq 3,6$. Соответствие между значением порога и количеством сегментов на полученных изображениях показано на рис. 4, а.




Рис. 5 Результат работы алгоритма сегментации: (а) изменение вариации информации VI в каналах L , a и b при сравнении результатов сегментации с исходным изображением (см. рис. 3); (б) энтропия выхода $H(V)$, взаимная информация $I(U;V)$ и вариация информации $VI(U,V)$ в системе сегментации при разном количестве сегментов K

Для цветочных каналов исходного изображения U и каждого из полученных при сегментации изображений V_q , состоящих из K сегментов, вычислен показатель избыточности R . Полученные значения меры избыточности в каналах L и a представлены в виде графика на рис. 4, б. Минимум показателя избыточности достигается во всех цветочных каналах при $K = 28$, что соответствует $\Delta_1 = 2$.

По результатам сравнения исходного изображения U с полученными при значениях порога $0 \leq \Delta_1 \leq 3,6$ сегментированными изображениями V_q построены графики в пространстве «число сегментов K — величина вариации информации VI в каналах L , a и b », показанные на рис. 5, а. На рисунке область $K < 12$ соответствует значениям $2,4 \leq \Delta_1 \leq 3,6$. В этой области при увеличении параметра Δ_1 K уменьшается, так как происходит интенсивное слияние сегментов, исчезают мелкие и даже относительно крупные детали изображения, образуются большие однородные сегменты. Значение вариации информации в этой области диаграммы достаточно велико, так как сегментированное изображение сильно упрощается и сходство с исходным изображением слабое. При уменьшении порога Δ_1 и увеличении числа сегментов наблюдается резкое падение значения вариации информации до минимума при $\Delta_1 = 2$ (что соответствует $K = 28$) и затем ее плавный рост до $K = 173$ (соответственно, $\Delta_1 = 0,4$). В этом интервале значений параметра не происходит значительных изменений сегментированного изображения, все основные детали изображения сохраняются, происходит слияние малых сегментов. Далее при $K > 173$, что соответствует уменьшению Δ_1 до 0, значение VI резко возрастает. Это связано с тем, что с уменьшением размера сегментов до $a \times a$ (см. подразд. 2.1) и появлением на сегментированном изображении большого количества мелких деталей, видимых на исходном изображении, рост энтропии выхода системы $H(V)$ существенно превосходит рост взаимной информации $I(U;V)$ между выходом и входом при постоянной энтропии входа $H(U)$ (рис. 5, б и определение вариации информации (16)). Таким образом, из рис. 4 и 5 следует, что наибольшее сходство между входным и сегментированным изображениями достигается при значении параметра (и, соответственно, количестве сегментов), обеспечивающих минимум показателя избыточности R .




Рис. 6 Результат работы алгоритма сегментации: (а) величина вариации информации VI , вычисленная в канале a пространства CIE Lab при сравнении исходного изображения, показанного на рис. 3, с эталонными сегментациями, состоящими из разного числа сегментов K ; (б) вариация информации VI , вычисленная при сравнении эталонных вариантов сегментации и результатов сегментации изображения, показанного на рис. 3, при различном количестве сегментов K



Рис. 7 Варианты сегментации изображения, показанного на рис. 3: (а) результат сегментации с постобработкой, соответствующий минимуму избыточности при $K = 28$; (б) эталонная сегментация, число сегментов $K = 12$

Далее для входного изображения и пяти эталонных (groundtruth) сегментаций, взятых из базы, вычислены значения вариации информации и построена кривая зависимости вариации информации числа сегментов, представленная на рис. 6, а. Из рисунка следует, что наименьшее значение меры различия соответствует эталонной сегментации с числом классов $K = 12$.

Следующая задача эксперимента заключалась в сравнении эталонных сегментаций исследуемого изображения и серии сегментированных изображений, полученных с помощью алгоритма суперпиксельной сегментации с процедурой постобработки. Результат сравнения в канале L показан на рис. 6, б. Все эталонные сегментации дают минимум расстояния по метрике (16) (наибольшее сходство) с изображением, полученным при $\Delta_1 = 2$ (28 сегментов), на котором достигается минимум меры избыточности R (см. рис. 4, б). Наблюдается наибольшее сходство указанного варианта сегментации с эталонным вариантом, состоящим из 12 сегментов (см. рис. 6, б). Сегментированное изображение с числом сегментов $K = 28$, соответствующее минимуму избыточности, и эталонное изображение с числом сегментов $K = 12$ показаны на рис. 7.

Таким образом, эксперимент показал, что из полученного множества сегментаций входного изображения, полученных при различных значениях параметра алгоритма, лучшим вариантом в смысле минимума меры различия входного и сегментированного изображений является изображение, обеспечивающее минимум меры избыточности информации для модели системы сегментации вида (7). Выбранный вариант сегментации наиболее близок к эталонным сегментированным изображениям базы BSDS500. Следует отметить, что приемлемыми результатами сегментации изображения, показанного на рис. 3, могут быть изображения с количеством сегментов от 28 до 173, соответствующие участку плавного роста меры различия (см. рис. 4, б).

5 Заключение

Рассмотрена задача получения наилучшего качества сегментации изображений. Предложена двухшаговая процедура постобработки для суперпиксельного алгоритма сегментации SLIC. Разработан метод выбора оптимального варианта сегментации и определения параметра процедуры на основе принципа минимума избыточности информации. В качестве критерия предложено применять меру избыточности информации, позволяющую получить наилучший с точки зрения визуального восприятия результат сегментации. Показано, что при предложенном способе формирования критерия он обладает экстремальными свойствами в отличие от известного критерия в виде взвешенного показателя недоверности. Результаты вычислительного эксперимента показали, что сегментированное изображение, соответствующее минимуму меры избыточности, дает минимум различия при сравнении с исходным изображением. Выбранный с помощью предложенного критерия вариант сегментации показал наибольшее сходство с эталонами.

Дальнейшие исследования будут направлены на изучение и уточнение модели дисперсии шума в теоретико-информационной модели сегментации, а также уточнению границ применимости метода.

Литература

- [1] Achanta R., Shaji A., Smith K., Lucchi A., Fua P., Susstrunk S. SLIC superpixels. Lausanne: TEPFL, 2010. Technical Report.
- [2] Achanta R., Shaji A., Smith K., Lucchi A., Fua P., Susstrunk S. SLIC superpixels compared to state-of-the-art superpixel methods // IEEE Trans. Pattern Anal., 2012. Vol. 34. No. 11. P. 2274–2282.
- [3] Haralick R. M., Shapiro L. G. Image segmentation techniques // Comput. Vision Graph., 1985. Vol. 29. No. 1. P. 100–132.
- [4] Gonzalez R. C., Woods R. E. Digital image processing. — 3rd ed. — Upper Saddle River, NJ, USA: Pearson Education Inc., 2008. 954 p.
- [5] Arbelaez P., Maire M., Fowlkes C., Malik J. Contour detection and hierarchical image segmentation // IEEE Trans. Pattern. Anal., 2011. Vol. 33. No. 5. P. 898–916.
- [6] Berkeley segmentation data set and benchmarks 500 (BSDS500). http://www.eecs.berkeley.edu/Research/Projects/CS/vision/grouping/BSR/BSR_bsds500.tgz.
- [7] Wagner S., Wagner D. Comparing clusterings — an overview. Universität Karlsruhe: TH, 2007. Technical Report 2006-04.
- [8] Rand W. M. Objective criteria for the evaluation of clustering methods // J. Am. Stat. Assoc., 1971. Vol. 66. No. 336. P. 846–850.

- [9] *Fowlkes E. B., Mallows C. L.* A method for comparing two hierarchical clusterings // *J. Am. Stat. Assoc.*, 1983. Vol. 78. No. 383. P. 553–569. doi: 10.2307/2288117.
- [10] *Ana L. N. F., Jain A. K.* Robust data clustering // *CVPR Proceedings*. — IEEE, 2003. P. 111–122.
- [11] *Meila M.* Comparing clusterings by the variation of information // *Learning theory and kernel machines* / Eds. B. Schoelkopf, M. Warmuth. — Lecture notes in artificial intelligence ser. — Berlin–Heidelberg: Springer-Verlag, 2003. Vol. 2777. P. 173–187.
- [12] *Meila M.* Comparing clusterings: An axiomatic view // *22nd Conference (International) on Machine Learning Proceedings*, 2005. P. 577–584.
- [13] *Frosio I., Ratner E. R.* Adaptive segmentation based on a learned quality metric // *VISAPP2015 Proceedings*. — INSTICC, 2015. Vol. 1. P. 283–291.
- [14] *Felzenszwalb P. F., Huttenlocher D. P.* Efficient graph-based image segmentation // *Int. J. Comput. Vision*, 2004. Vol. 59. No. 2. P. 167–181. doi: 10.1023/B:VISI.0000022288.19776.77.
- [15] *Atick J. J., Redlich A. N.* Towards a theory of early visual processing // *Neural Comput.*, 1990. Vol. 2. No. 3. P. 308–320. doi: 10.1162/neco.1990.2.3.308.
- [16] *Barlow H. B.* Possible principles underlying the transformations of sensory messages // *Sensory communication* / Ed. W. A. Rosenblith. — Cambridge: M.I.T. Press, 1961. P. 217–234.
- [17] *Haykin S.* *Neural networks: A comprehensive foundation*. — 2nd ed. — Upper Saddle River, NJ, USA: Prentice Hall Inc., 1999. 869 p.

Поступила в редакцию 01.09.2016

Application of information-theoretical approach for image segmentation*

D. M. Murashov

d_murashov@mail.ru

Federal Research Center “Computer Science and Control” of RAS,

44/2 Vavilova Str., Moscow, Russia

A problem of segmentation quality of digital images is considered. The developed technique is based on the information-theoretical approach and applied to a modified superpixel segmentation algorithm. In one of the conventional techniques, the weighted uncertainty index is used for measuring segmentation quality. The index is calculated using normalized mutual information of color channels in given and segmented images. The uncertainty index varies monotonously depending on the parameter of the segmentation algorithm. This caused application of learning technique and iterative procedure for choosing parameter value. In this work, information redundancy measure is proposed as a criterion for optimizing segmentation quality. This criterion provides the best result in terms of visual perception. It is shown that proposed method of constructing the redundancy measure provides it with extremal properties. The experiment was conducted using the images from the database Berkeley Segmentation Dataset. The experiment confirmed that the segmented image corresponding to a minimum of redundancy measure produces the minimum difference in the information-theoretical dissimilarity measure when compared with the original image. In addition, the segmented image that was selected using the proposed criteria, gives the highest similarity with the groundtruth segmentations, available in the database.

*The research was supported by the Russian Foundation for Basic Research (grants 15-07-09324 and 15-07-07516).

Keywords: *image segmentation; information-theoretical model; redundancy measure; super-pixel algorithm*

DOI: 10.21469/22233792.2.2.08

References

- [1] Achanta, R., A. Shaji, K. Smith, A. Lucchi, P. Fua, and S. Susstrunk. 2010. SLIC superpixels. Lausanne: TEPFL. Technical Report.
- [2] Achanta, R., A. Shaji, K. Smith, A. Lucchi, P. Fua, and S. Susstrunk. 2012. SLIC superpixels compared to state-of-the-art superpixel methods. *IEEE Trans. Pattern Anal.* 34(11):2274–2282.
- [3] Haralick, R. M., and L. G. Shapiro. 1985. Image segmentation techniques. *Comput. Vision Graph.* 29(1):100–132.
- [4] Gonzale, R. C., and R. E. Woods. 2008. *Digital image processing*. 3rd ed. Upper Saddle River, NJ: Pearson Education Inc. 954 p.
- [5] Arbelaez, P., M. Maire, C. Fowlkes, and J. Malik. 2011. Contour detection and hierarchical image segmentation. *IEEE Trans. Pattern Anal.* 33(5):898–916.
- [6] Berkeley segmentation data set and benchmarks 500 (BSDS500). Available at: http://www.eecs.berkeley.edu/Research/Projects/CS/vision/grouping/BSR/BSR_bsds500.tgz (accessed August 30, 2016).
- [7] Wagner, S., and D. Wagner. 2007. *Comparing clusterings — an overview*. Universität Karlsruhe: TH. Technical Report 2006-04.
- [8] Rand, W. M. 1971. Objective criteria for the evaluation of clustering methods. *J. Am. Stat. Assoc.* 66(336):846–850.
- [9] Fowlkes, E. B., and C. L. Mallows. 1983. A method for comparing two hierarchical clusterings. *J. Am. Stat. Assoc.* 78(383):553–569. doi: 10.2307/2288117.
- [10] Ana, L. N. F., and A. K. Jain. 2003. Robust data clustering. *CVPR Proceedings*. IEEE, 2003. 111–122.
- [11] Meila, M.. 2003. Comparing clusterings by the variation of information. *Learning theory and kernel machines*. Eds. B. Schoelkopf and M. Warmuth. Lecture notes in artificial intelligence ser. Berlin–Heidelberg: Springer-Verlag. 2777:173–187.
- [12] Meila, M. 2005. Comparing clusterings: An axiomatic view. *22nd Conference (International) on Machine Learning Proceedings*. 577–584.
- [13] Frosio, I., and E. R. Ratner. 2015. Adaptive segmentation based on a learned quality metric. *VISAPP2015 Proceedings*. INSTICC. 1:283–291.
- [14] Felzenszwalb, P. F., and D. P. Huttenlocher. 2004. Efficient graph-based image segmentation. *Int. J. Comput. Vision* 59(2):167–181. doi: 10.1023/B:VISI.0000022288.19776.77.
- [15] Atick, J. J., and A. N. Redlich. 1990. Towards a theory of early visual processing. *Neural Comput.* 2(3):308–320. doi: 10.1162/neco.1990.2.3.308.
- [16] Barlow, H. B. 1961. Possible principles underlying the transformations of sensory messages. *Sensory communication*. Ed. W. A. Rosenblith. Cambridge: M.I.T. Press. 217–234.
- [17] Haykin, S. 1999. *Neural networks: A comprehensive foundation*. 2nd ed. Upper Saddle River, NJ: Prentice Hall Inc. 869 p.

Received September 1, 2016