



Д.В. Вакуленко, А.Г. Кравец

## МОНИТОРИНГ СОСТОЯНИЯ СЕЛЬСКОХОЗЯЙСТВЕННЫХ ЗЕМЕЛЬ НА ОСНОВЕ СУПЕРПИКСЕЛЬНОЙ СЕГМЕНТАЦИИ ЦИФРОВЫХ ИЗОБРАЖЕНИЙ

(Волгоградский государственный технический университет)

**Аннотация.** Статья посвящена суперпиксельной сегментации изображений для решения задачи мониторинга состояния сельскохозяйственных земель по цифровым снимкам. Разделение цифрового изображения на несколько сегментов со схожими визуальными характеристиками достаточно широко применяется в обработке изображений. Приведенный подход демонстрирует возможность получения информации о плотности всходов растительности каждого из установленных классов на изображении и может быть отнесен к этапу предобработки для дальнейшего анализа и принятия решений в данной предметной области. Основное отличие предлагаемого подхода от аналогов заключается в работе с более содержательными, семантически наполненными сущностями изображения - суперпикселями, что позволяет на несколько порядков снизить число итераций кластеризации и, соответственно, достичь компромисса между скоростью работы и точностью результата алгоритма.

*Ключевые слова:* обработка цифровых изображений, предварительная сегментация, пиксельная карта, кластеризация, поле признаков сегмента.

### Введение

Охват новшеств нынешнего дня говорит в пользу внедрения космического сегмента в процесс пространственного исследования поверхности Земли в целом и возможности проводить эффективные наблюдения за состоянием зон произрастания растительных ареалов в частности. Управление системой агропромышленного производства требует достоверных методов обработки и анализа натуральных данных в режиме реального времени для возможности принятия взвешенного, обоснованного и своевременного решения, нацеленного на эффективное функционирование системы в целом и рост сельскохозяйственной продукции. В данной работе предложен алгоритм, работающий с пиксельной картой снимка на уровне выделения суперпикселей. Пространственная организация спектральной яркости пикселей носит случайный характер, что обуславливает целесообразность решения задачи разбиения изображения на непересекающиеся области в пространстве спектральных признаков, используя функционал похожести [6,7].

### Обзор существующих методик

Задача автоматического детектирования наземных объектов является одной из наиболее интересных задач современного компьютерного зрения,



решение которой неизбежно затрагивает поиск компромисса между компактностью представления и точностью выделения контуров объектов на снимке области интереса. Задача разрешима при использовании широкого спектра различных подходов. Среди них выделяются методы разрастания областей, поиска минимального остовного дерева на графах; метод водораздела, использующий абсолютную величину градиента яркости изображения, и многие другие [2,3]. Общая тенденция сводится к поиску баланса калибровки анализируемых параметров таким образом, чтобы согласованность дешифрованных объектов и их границ на снимке и реальных ареалах была как можно выше [7,9]. Трудность обработки дополняется высокой изменчивостью объектов внутри одного класса и высокой схожестью элементов объектов разных классов.

### **Алгоритм суперпиксельной сегментации**

Алгоритм, который исследуется в этой работе, базируется на единовременном выделении связных фрагментов изображения и параллельном вычислении их признаков за проходение одной итерации. Сильные стороны, говорящие в пользу алгоритма, заключаются в следующем:

- 1) пиксели со схожими метриками выступают в качестве согласованной единицы;
- 2) возможность установления связей между отдаленными друг от друга пикселями;
- 3) сравнительно низкая вычислительная сложность (вычислительная эффективность снижает время обработки и распознавания изображения).

Результатом обработки изображения является плотность всходов сельскохозяйственных культур в каждом из выделенных классов, оценка их площади и границ, выявление закономерностей формирования урожая в целом.

В качестве входных данных определим классифицируемое изображение как (1)

$$I = F(x, y) \in R^d, x \in [1, K], y \in [1, N] \quad (1)$$

$d$  - количество спектральных компонент изображения;

$K \times N$  - размер изображения

Описываемый подход к построению алгоритма сегментации включает в себя следующие этапы:

### **Предварительная сегментация**

Начало работы связано с выделением суперпикселей  $S_j, j = 1, \dots, J$ , на исходном изображении  $F(x, y)$  объединяющих пиксели, относительно близкие в пространстве признаков так, что на выходном изображении  $S(x, y)$  значению пикселя в точке  $x, y$  будет присвоен индекс соответствующего суперпикселя  $j$ . Диапазон вариации яркостей пикселей задается пользователем и служит мерой однородности для отнесения каждой области изображения к определенному фрагменту сегментации. Выбор подходящей меры однородности  $\delta$ , которая



позволит различать анализируемые структуры изображения друг от друга, выполняя поиск в соответствии со значением установленного порога. Чем выше значение параметра, тем более несхожие по цвету и отдаленные пиксели будут объединяться в один фрагмент, и тем, следовательно, выше вероятность объединения пикселей разных классов интереса. В противном случае, небольшое значение параметра разобьет изображение на мелкие фрагменты, включающие в себя незначительное количество элементов [4,9]. Цель подбора этого параметра – установить такое балансирующее значение, при котором будет достаточно точно определяться граница между объектами неоднородной структуры изображения при минимально возможном числе сегментируемых фрагментов.

Обозначим отклонение пикселя  $p$  от средней яркости фрагмента(2):

$$\forall p \in S \left| I(p) - \frac{1}{N} \sum_{q \in S} I(q) \right| < \delta \quad (2)$$

Введем обозначения:

$I(A)$  - яркость пикселя (отсчета)

$Cl_{avg}(B)$  - средняя яркость области, к которой принадлежит  $B$

Изображение подлежит построчному сканированию. Пусть отсчет  $A$  не является первым опорным пикселем  $\{A(x, y) : x \neq 1, y \neq 1\}$ , тогда итеративная процедура сканирования будет выполнять проверку условий и запускать соответствующие операции:

Создать новую область, присоединить к ней пиксель  $A$

$$\text{if } |I(A) - Cl_{avg}(B)| > \delta \text{ и } |I(A) - Cl_{avg}(C)| > \delta \quad (3)$$

Добавить  $A$  к одной из областей

$$\text{if } |I(A) - Cl_{avg}(B)| \leq \delta \text{ или } |I(A) - Cl_{avg}(C)| \leq \delta \quad (4)$$

$$\text{if } |I(A) - Cl_{avg}(B)| \leq \delta \text{ и } |I(A) - Cl_{avg}(C)| \leq \delta, \text{ то:} \quad (5)$$

Провести слияние области  $B$  и  $C$ , которые вместе не нарушают требования однородности (6):

$$|Cl_{avg}(B) - Cl_{avg}(C)| \leq \delta \quad (6)$$

Добавить пиксель  $A$  к тому классу, отклонение от которого минимально:

$$|Cl_{avg}(B) - Cl_{avg}(C)| > \delta \quad (7)$$

Продолжать итерации необходимо до тех пор, пока остаются регионы, которые можно объединить.



### Признаковое вычисление статистических метрик по сегментам

Целью данного этапа является переход от регулярной структуры изображения к множеству векторов-признаков

$f_j \in R^L$ ,  $L$  – количество признаков. В качестве признаков для суперпикселей рассчитать статистические характеристики каналов (среднее, дисперсия, максимальное по сегменту значение).

#### Создание обучающей выборки

Каждый выделенный суперпиксель должен быть сопоставлен с определенным классом состояния всходов изучаемого растительного сообщества, и такая принадлежность устанавливается с помощью маски классов состояния растительности.

Для формирования маски классов на исходном изображении  $F(x, y)$  выделим  $i = 1, \dots, I$  областей на множествах координат пикселей:

$$Z_i = \{(x, y) : Z(x, y) = i\} \quad (8)$$

Чтобы сформировать обучающую выборку  $V$  переопределим суперпиксели как  $S_g$ ,  $g = 1, \dots, G_i$ , предполагая, что имеет место пересечение данного однородного фрагмента с пикселями  $Z_i$  класса  $i$ , и упорядочим по убыванию фрагментарные области с наибольшей площадью пересечения с множеством пикселей  $Z_i$  (9):

$$V = \left\{ S_g \cap Z_i \mid = \max, Z_i \cap Y_i \neq \emptyset \right\} \quad (9)$$

Обучающая выборка должна представлять собой множество номеров суперпикселей  $S_g$  которым поставлены в соответствие векторы признаков фрагментарных областей  $f_g$ , отнесенных к соответствующему сегментируемому фрагменту на предыдущем шаге технологии.

#### Инициализация количества кластеров

На данном шаге производится кластеризация векторов признаков  $f_j$  всего изображения. За этим расслоением стоит разметка скелета суперпикселей, упорядоченных согласно минимуму евклидова расстояния между значениями цветовых компонент однородной фрагментарной области и центром кластеров.

Результатом семантической кластеризации изображения является изображение-карта разметки индексов кластеров исходного изображения. Все пиксели, сгруппированные в суперпикселе  $S_j$ ,  $j = 1, \dots, J$ , должны попасть в один кластер и соотноситься с одним классом состояния растительности, который, в свою очередь, согласуется с определенным вектором признаков  $f_j$ .

#### Расчет плотности полученных информационных классов

Выходными данными предлагаемой технологии является размеченное на кластеры изображение с плотностью всходов  $p(i, x, y)$  растительных классов



$i = 1, \dots, I$ , выделенных на изображении. Плотность можно оценить как количество точек, попавших в окрестность с определенным радиусом.

$$p(i, x, y) = \frac{|P_i(x, y)|}{|P(x, y)|} \quad (10)$$

$P_i(x, y)$  - количество пикселей класса  $i$  во фрагменте  $P(x, y)$

$P(x, y)$  - общее количество пикселей в окрестности.

### Оценка качества проведенной кластеризации

Итерационный процесс кластеризации гарантированно сходится, но он может не привести к оптимальному решению. Качество кластеризации определяется четко выделенными однородными областями, распознаванием их правильного положения и достоверных размеров. Сегментация вправе считаться успешно проведенной в случае нахождения компромисса между компактностью представления и точностью выделения контуров объектов. При подборе неподходящих параметров согласованность границ кластеров с границами объектов, присутствующих на изображении, может не сохранить свою информативность, и разбить изображение на множество мелких фрагментов. Избыточная или недостаточная сегментация усложняет получение приемлемого решения задачи, противоречит основной цели сегментации и приводит к ошибочным результатам [1,8,9,10]. В качестве оценочного критерия может выступать параметр регулирования цветовой компактности кластера с учетом цветовых характеристик и образующих текстур изображения.

Цель подбора параметра детализации сегментации  $P_s$  заключается в оптимальном выборе значения, при котором будет достаточно точно определяться граница и содержание кластеров при их минимально возможном числе. В целом необходимо решить задачу вида (11):

$$(da^2 + db^2 + dc^2) * P_s + dx^2 + dy^2 \leq \delta \quad (11)$$

$da, db, dc$  - расстояние между пикселями по компонентам цвета;

$P_s$  - параметр, задающий детальность сегментации;

$dx, dy$  - разность координат сравниваемых пикселей;

$\delta$  - параметр, задающий максимальное расстояние между пикселями, при котором их можно объединить в один кластер.

Регулируемые параметры зависят от конкретного цветового и координатного положения пикселей, а также степени текстурной изменчивости исследуемого изображения и опираются на следующие особенности:

- цветовая схожесть пикселей;
- пространственное (координатное) положение пикселей;
- размер искомых детектируемых объектов;
- гладкость текстуры изображения.

На основе можно определить следующие рекомендации для определения интервала выбора значений параметра сегментации:

- чем больше значение параметра, тем выше окажется схожесть цветов в кластере и тем детальнее осуществится разбиение;



- чем меньше размер искомых объектов, тем больше необходимость увеличения значения параметра;
- чем слабее изменчивость текстуры, тем менее жесткие требования предъявляются к искомому параметру и целесообразнее выбор его меньшего значения.

Изменчивость текстуры можно описать как среднюю разность по цвету между всеми парами соседних пикселей, имеющих общую сторону:

$$HContrast = \frac{1}{K * (N - 1)} \sum_{i=1}^K \sum_{j=1}^{N-1} dist(I_{i,j}, I_{i,j+1}) \quad (12)$$

$$VContrast = \frac{1}{(K - 1) * N} \sum_{j=1}^N \sum_{i=1}^{K-1} dist(I_{i,j}, I_{i+1,j}) \quad (13)$$

$K, N$  - высота и ширина изображения в пикселях;

$I_{i,j}$  - цвет пикселя в позиции  $i, j$

$$Texture = HContrast + VContrast \quad (14)$$

Проверка обозначенных зависимостей будет раскрыта в будущем исследовании, эксперименты на реальных данных покажут устойчивость алгоритма при варьировании различных показателей эффективности. Комплексная оценка качества сегментации осуществляется по выделению показателей, сгруппированных в табл.1. Это позволит перейти от адаптации отдельного параметра к настройке комплексной системы эффективной работы всего алгоритма [1,4].

Таблица 1. Показатели оценки качества алгоритма

Наименование показателя	Критерий качества процесса сегментации	
Показатели точности	процент обнаруженных границ	→ max
	избыточность сегментации	→ min
	максимально достижимая точность результирующей сегментации	→ max
Показатели компактности	среднеквадратичное отклонение размеров фрагментов	→ min
	изодиаметрический и изопериметрический коэффициенты (отношение площади фрагмента к площади круга с аналогичными диаметром и периметром)	→ max
Показатели устойчивости	устойчивость к шумам: степень зависимости от доли искаженных пикселей изображения, рассчитываемая для границ суперпикселей	→ max
Показатель быстродействия	время работы алгоритма	→ min



### Заключение

Предлагаемый подход заключается в кластеризации пространства спектральных каналов, классификации сегментов изображения, полученных на основе кластеров и вычислении итоговой плотности всходов на основе доли пикселей определенного класса внутри сегмента. Подход ориентирован на мультиспектральные данные дистанционного зондирования Земли и служит в качестве способа экспертизы качества созревания растений в сфере агропромышленного возделывания культур. Каждая технология обработки релевантна тому диапазону условий, для которых создана, поэтому описанный алгоритм ограничивается своим классическим наполнением и обладает возможностями для модификации: на основе идейного направления возможно создание конгломерата нескольких подходов, когда недостатки каждого по отдельности при грамотной комбинации могут обернуться преимуществом. Поскольку работа над проектом продолжается, адекватность принятых теоретических решений будет проверена путем тестирования на коллекции аэрофотоснимков видимого и инфракрасного диапазонов.

### Литература

1. Абакумов, В.Г. Повышение эффективности обработки образной информации в автоматизированных системах [Текст] / В.Г Абакумов, В.Н. Крылов, С.Г. Антощук // Электроника и связь: Темат. вып. «Проблемы электроники». – 2005. – Ч. 1. – С. 100 – 105.
2. Егорова, Е.А. Анализ методов сегментации изображений [Текст] // Восточно-Европейский журнал передовых технологий. – 2006, №5/2 (23).– С.67-71.
3. Калинин, П.В. Графовый подход к пересегментации иерархического изображения [Текст]/ П.В. Калинин, А.А. Сирота // Компьютерное зрение и образ Понимание. - 2015. - Т.130. - С. 80-86.
4. Левашкина, А.О. Исследование супервизорных критериев оценки качества сегментации изображений [Текст] /А.О. Левашкина, С.В. Поршневу// Известия Томского политехнического университета. – 2008. Т. 313, №5. - С.28-33
5. Малик, Дж. Нормализованные срезы и сегментация изображения [Текст]/ Дж. Малик, Дж. Ши // IEEE транзакции по анализу паттернов и машинному интеллекту. -2000. - №8, Т. 22. - С. 888-905.
6. Разбиение изображения на области, однородные относительно заранее выбранных критериев [Электронный ресурс]; ред. Цао Чэнь.– Режим доступа: [http:// niclifmo.ru/publications/ articles/ Maior Read2009/MREAD2009 Zao Chen.pdf](http://niclifmo.ru/publications/articles/Maior_Read2009/MREAD2009_ZaoChen.pdf).
7. Способы представления воксельного ландшафта при проектировании систем виртуальной реальности [Электронный ресурс] / Моделирование, оптимизация и информационные технологии; ред. В.Д. Шакаев, А.Г. Кравец; Научный сетевой журнал. - 2019. - Т. 7, № 1 (24). - С. 309-327. – Режим доступа: [https://moit.vivt.ru/wp-content/uploads/2019/04/Issue\\_1\(24\)\\_2019.pdf](https://moit.vivt.ru/wp-content/uploads/2019/04/Issue_1(24)_2019.pdf).



8. Patents Images Retrieval and Convolutional Neural Network Training Dataset Quality Improvement [Электронный ресурс] / Proceedings of the IV International research conference «Information technologies in Science, Management, Social sphere and Medicine» (ITSMSSM 2017); ed. by O.G. Berestneva, A.G Kravets, N. Lebedev, M. Legenchenko; [Published by Atlantis Press], 2017. – P. 287-293. – (Ser. Advances in Computer Science Research (ACSR) ; Vol. 72). – URL: <https://www.atlantis-press.com/proceedings/itsmssm-17>.

9. The Study of Neural Networks Effective Architectures for Patents Images Processing [Text]: Creativity in Intelligent Technologies and Data Science (CIT&DS 2019) : Third Conference (Volgograd, Russia, September 16–19, 2019 : Proceedings. Part II / [Editors: A. Kravets, P. Groumpos, M. Shcherbakov, M. Kultsova].– Volgograd State Technical University [et al.]. – Cham (Switzerland) : Springer Nature Switzerland AG, 2019. – P. 27-41. – (Ser. Communications in Computer and Information Science (CCIS) ; Volume 1084).

10. The Berkeley Segmentation Dataset and Benchmark / University of California, Berkeley. – Режим доступа: <https://www2.eecs.berkeley.edu/Research/Projects/CS/vision/bsds/>.

А.В. Головастикова, К.Е. Климентьев

## ЗАДАЧА МОДЕЛИРОВАНИЯ «УМНОГО» КОМПЬЮТЕРНОГО КОНТРАГЕНТА

(Самарский университет)

**Введение.** В Самарском университете силами преподавателей и студентов продолжается разработка, отладка и тестирование инструментальной среды, предназначенной для имитационного моделирования процессов размножения и взаимодействия популяций самовоспроизводящихся сущностей, таких как компьютерные вирусы и черви, болезнетворные микроорганизмы, пожары и т.п. – см. работу [1]. Моделью отдельной сущности при этом является «агент» – автономный программный модуль, обладающий набором свойств (атрибутов) и алгоритмов поведения (методов, протоколов). Эти свойства и алгоритмы могут быть не только жестко фиксированными на этапе разработки, но и самообучаемыми под конкретную ситуацию в процессе имитации. Это возможно благодаря внутренней организации инструментальной среды, состоящей из: 1) исполняющей среды («движка»); 2) библиотеки агентов; 2) генератора «мира», в котором «живут» агенты (см. рис. 1).

При этом «агенты» могут быть оформлены в виде довольно сложных программных модулей, использующих методы искусственного интеллекта – генетические алгоритмы, искусственные нейронные сети, системы продукций и прочее.