

СЕГМЕНТАЦИЯ ВМЕЩАЮЩЕЙ СРЕДЫ В ГЕОФИЗИЧЕСКОЙ СИСТЕМЕ ПЕРЕДАЧИ ДАННЫХ

Проведено статистическое моделирование вмещающей среды методом кластерного анализа для геофизической телекоммуникационной системы. Дана классификация методов сегментации геоизображений. Создана упрощённая модель среды и проведён её анализ, позволяющий выявить структуру объектов.

Актуальность проблемы сегментации изображения

Совершенствование телекоммуникационных систем для геофизических исследований требует исследования возможности неискажённой передачи данных через различные среды – вода, буровой раствор и др. Проблема распространения сигнала по новому каналу связи – буровой трубе находится в начальной стадии решения и связана в первую очередь с моделированием влияния неоднородностей в канале связи на принимаемый сигнал. Моделирование включает в себя построение изображения среды, выделение неоднородностей и оценку затухания сигнала.

Недостатком существующих методов моделирования является то, что оценка влияния неоднородностей делается по обработанному изображению, а не по исходному сигналу и требует участия оператора. На это уходит много времени, так как фактически чёткого изображения объектов нет. Поэтому необходимо автоматизировать этот процесс, отказавшись от участия оператора в распознании объектов и расположения границ слоёв среды. Таким образом, существует потребность в разработке методов по оценке наличия объектов, основываясь на имеющейся информации: амплитуде и координатах отражённого сигнала. Для выделения границ объектов на изображении обычно используется сегментация изображения.

Сегментация изображения

Пример геоизображения представлен на рис. 1.

Каждому значению амплитуды соответствует своё значения яркости, а одинаковому цвету – одно значение диэлектрической проницаемости. По горизонтальной шкале отмечено расстояние, на котором находился антенный блок от начальной точки.

Анализ профиля представляет собой долгую и трудоёмкую работу, выполняемую оператором. Чтобы автоматизировать этот процесс, воспользуемся методами сегментации. Цель сегментации заключается в упрощении или изменении представления изображения, чтобы его было проще и легче анализировать [2].

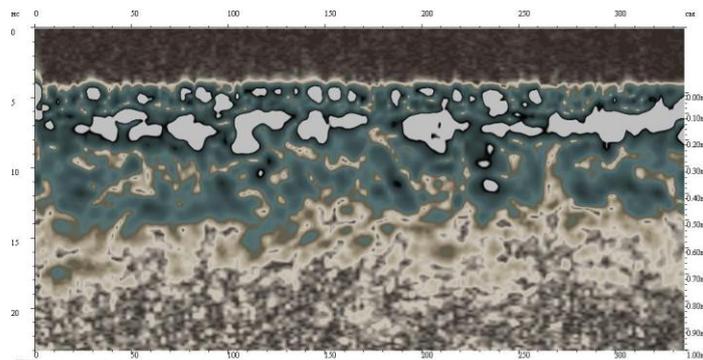


Рис. 1. Георадиолокационный профиль

Результатом является множество сегментов, которые вместе покрывают всё изображение, или множество контуров, выделенных из изображения. Все пиксели в сегменте похожи по некоторой характеристике или вычисленному свойству, например по цвету, яркости или текстуре. Соседние сегменты значительно отличаются по этой характеристике [3].

Для сегментации изображений было разработано несколько алгоритмов и методов.

Для того чтобы свести задачу сегментации к задаче кластеризации, достаточно задать отображение точек изображения в некоторое пространство признаков и ввести меру близости на этом пространстве признаков.

В качестве признаков точки изображения можно использовать представление ее цвета в некотором цветовом пространстве, примером метрики – меры близости может быть евклидово расстояние между векторами в пространстве признаков. Тогда результатом кластеризации будет квантование цвета для изображения. Задав отображение в пространство признаков, можно воспользоваться любыми методами кластерного анализа, например k-средних [5], EM алгоритмом [6].

Метод k-средних - это итеративный метод, который используется, чтобы разделить изображение на k кластеров. В качестве расстояния берётся сумма квадратов или абсолютных значений разностей между пикселем и центром кластера. Разность обычно основана на цвете, яркости, текстуре и местоположении пикселя, или на взвешенной сумме этих факторов [4, 7].

Методы с использованием гистограммы эффективны, когда сравниваются с другими методами сегментации изображений, потому что они требуют только один проход по пикселям. В этом методе гистограмма вычисляется по всем пикселям изображения и её минимумы и максимумы используются, чтобы найти кластеры на изображении [1]. Улучшение этого метода - рекурсивно применять его к кластерам на изображении для того, чтобы поделить их на более мелкие кластеры. Процесс повторяется с меньшими и меньшими кластерами до тех пор, когда перестанут появляться новые кластеры [2, 8].

Методы выращивания регионов основаны на следующей идее. Сначала по некоторому правилу выбираются центры регионов, к которым поэтапно присоединяются соседние точки, удовлетворяющих некоторому критерию. Процесс

выращивания регионов останавливается, когда ни одна точка изображения не может быть присоединена ни к одному региону.

В основном процедура выращивания региона используется для получения отдельных регионов, однако, применяя эту процедуру последовательно или одновременно для нескольких регионов, можно получить разбиение всего изображения [9–12].

В методе дробления-слияния [13, 14] дробление начинается с некоторого разбиения изображения, не обязательно на однородные области. Процесс дробления областей происходит до тех пор, пока не будет получено разбиение изображения (пересегментация), удовлетворяющее свойству однородности сегментов. Затем происходит объединение схожих соседних сегментов до тех пор, пока не будет получено разбиение изображения на однородные области максимального размера. Для получения пересегментации изображения используются алгоритмы k -средних [15], watershed [16], fuzzy expert systems [17, 18], на втором этапе используются алгоритмы k -средних [15], самоорганизующиеся карты Кохонена [14], fuzzy expert systems [11], и т. д. На этапе слияния регионов используются relaxation process [19], k -средних [15], SIDE-уравнения [9], самоорганизующиеся карты Кохонена [16] и т. д.

Случайное поле Маркова представляет собой вероятностную модель, заданную на решётке. Это есть набор случайных переменных, где каждая переменная соответствует определенному узлу в данной решетке. При таком задании возможны статистические корреляции между узлом решетки и его соседями. Эти локальные корреляции обеспечивают механизм для моделирования свойств изображения.

Решётка может быть представлена, как прямоугольная матрица, содержащая m строк и n столбцов. Каждый элемент такой матрицы соответствует пикселю на изображении. Решётка $m \times n$ записывается с помощью двойного или одинарного индексов по формуле:

$$S = \{(i, j), 1 \leq i \leq m, 1 \leq j \leq n\}, \text{ или } S = \{i | 1 \leq i \leq m \times n\}.$$

Конфигурация f случайного поля F задается определенными значениями случайных переменных F_i . Конфигурационное пространство F случайного поля – это набор всех возможных конфигураций.

Система N соседей определяет узлы на решетке, ближайшие к данному узлу. Система соседей первого порядка содержит 4 соседей: $N_{ij} = \{(i-1, j), (i, j-1), (i, j+1), (i+1, j)\}$ – для внутреннего пикселя (i, j) . Система соседей второго порядка включает соседей первого порядка плюс диагональные относительно заданного узла элементы (8 соседей).

На практике основной целью применения случайного поля Маркова является обнаружение наиболее вероятной конфигурации f^* случайного поля F :
$$f^* = \arg \max_f P(f).$$

Основные сложности, связанные с использованием данного метода, заключаются в правильном выборе параметров, контролирующих силу пространственного взаимодействия. Задание слишком сильной связи может привести к чрезмерно сглаженной сегментации при потере важных деталей в структуре. Несмотря

на это, метод широко используется для моделирования не только классов сегментации, но и неоднородностей в интенсивности, часто встречаемых на изображениях [20,21].

Методы выделения краёв основываются на алгоритмах, которые выделяют точки цифрового изображения, в которых резко изменяется яркость или есть другие виды неоднородностей.

В идеальном случае, результатом выделения границ является набор связанных кривых, обозначающих границы объектов, граней и оттисков на поверхности, а также кривые которые отображают изменения положения поверхностей. Таким образом, применение фильтра выделения границ к изображению может существенно уменьшить количество обрабатываемых данных, из-за того, что отфильтрованная часть изображения считается менее значимой, а наиболее важные структурные свойства изображения сохраняются.

Существует множество подходов к выделению границ, но практически все можно разделить на две категории: методы, основанные на поиске максимумов, и методы, основанные на поиске нулей. Методы, основанные на поиске максимумов, выделяют границы с помощью вычисления «силы края», обычно выражения первой производной, такого как величина градиента, и затем поиска локальных максимумов силы края, используя предполагаемое направление границы, обычно перпендикуляр к вектору градиента. Методы, основанные на поиске нулей, ищут пересечения оси абсцисс выражения второй производной, обычно нули Лапласиана или нули нелинейного дифференциального выражения. В качестве шага предобработки к выделению границ практически всегда применяется сглаживание изображения, обычно фильтром Гаусса [3].

В методах теории графов изображение представляется в виде взвешенного графа с вершинами в точках изображения. Вес ребра графа отражает сходство точек в некотором смысле (расстояние между точками по некоторой метрике). Разбиение изображения моделируется разрезами графа [3]. Обычно в методах теории графов вводится функционал «стоимости» разреза, отражающий качество полученной сегментации. Так задача разбиения изображения на однородные области сводится к оптимизационной задаче поиска разреза минимальной стоимости на графе.

Для поиска разреза минимальной стоимости применяются различные методы: нормализованные разрезы графов [13], случайное блуждание [6], минимальный разрез [14], изопериметрическое разделение [17] и сегментация с помощью минимального основного дерева [15].

Качество работы методов теории графов сильно зависит от выбора метрики. Поэтому для выбора оптимальной метрики в [22, 23] применяют машинное обучение.

Кластерный анализ

Наиболее подходящим методом сегментации геофизических данных является метод, основанный на кластеризации.

Этот выбор был обоснован следующими причинами:

- некоторая универсальность данного метода (не требует построения изображения разреза среды);

- относительная простота метода (простота алгоритма анализа и наглядность результатов);
- наличие программного пакета для анализа данным методом (Statistica).

Кластерный анализ подразумевает разделение объектов на группы по сходным свойствам. В нашем случае этим свойством является амплитуда отраженного сигнала и координаты профиля на местности, принятые радаром. Анализ кластеров по величине этой амплитуды и координатам даст возможность уменьшить объем обрабатываемых данных, разбив их на однородные группы со схожими свойствами, тем самым отделить объекты от среды.

Исследуемая поверхность покрывается регулярной сеткой соответствующей формуле:

$$F(f(t_1), f(t_2), \dots, f(t_M)) = F_{ij},$$

в каждой пространственной точке x_{ij} , $i=1, \dots, k_x$; $k_x \cdot k_y = N$, которой имеется отражённый сигнал, представляющий собой вектор размерности M , а $f(t_m)$ – значение отраженного сигнала в момент времени t_m ; $m=1, \dots, M$.

В пространстве Ω размерности M , образованном координатными осями t_1, t_2, \dots, t_M , такой вектор отобразится в точку с координатами $f(t_1), f(t_2), \dots, f(t_M)$. У нас всего N сигналов, поэтому в этом пространстве будет N точек.

Ясно, что если две точки будут находиться в пространстве $\Omega(M)$ близко друг к другу, то соответствующие сигналы будут похожи друг на друга [15]. Поэтому в нашем случае под структурой объекта надо понимать совокупность точек, удовлетворяющих следующим требованиям: функции в этих точках, во-первых, должны быть удалены от точек фона, а во-вторых, близки друг другу. Иными словами, при классификации точки, относящиеся к объекту, должны попасть в один класс.

Метод k -средних даст нам возможность уменьшить объем обрабатываемых данных, разбив их на однородные группы со схожими свойствами, тем самым отделить объекты от среды. Метод k -средних позволяет разбить исследуемую модель среды на непересекающиеся подмножества, называемые кластерами, так, чтобы каждый кластер состоял из объектов, близких по метрике, а объекты разных кластеров существенно отличались.

Группировка должна производиться по принципу высокая амплитуда – есть объект, низкая амплитуда – нет объекта, с учетом расстояние между точками отраженного сигнала, так как эти данные несут очень важную информацию об объектах. Таким образом, кластеры должны содержать объекты с близким значением амплитуды и координат.

Так как переменные x измерены в разных единицах измерения, то требуется их предварительная нормировка по формуле:

$$x_{норм} = \frac{x - \mu}{\sigma},$$

где μ – математическое ожидание; σ – дисперсия.

Значения нормированной переменной станут равными нулю, а дисперсии – единице.

Построение модели среды

Для удобства проведения статистического анализа была составлена копия реальных данных – модель, представляющая собой значения амплитуд и координат точек сигнала. Модель создана в программном пакете Statistica, содержит информацию о срезе, проходящем через геометрические центры объектов, а именно: амплитуду отраженного сигнала и координаты точки (переменные “X”, “Y”, “A”). Переменная X имеет диапазон от 0 до 40, переменная Y – от 0 до 50, переменная A эквивалентна амплитуде отраженного сигнала и распределена по экспоненциальному закону в диапазоне от 0 до 1000. Экспоненциальный закон близок к реальному распределению амплитуд отраженного сигнала. Плотность распределения для экспоненциального закона описывается уравнением:

$$f(x, \lambda) = \lambda \cdot e^{-\lambda \cdot x}$$

где λ – параметр распределения (интенсивность).

Модель должна содержать объекты, которые, как и в реальных данных, могут располагаться в любой области сканируемой среды и иметь различный размер и форму. Поместим три объекта в любую область модели и с помощью кластерного анализа попытаемся обнаружить их и определить расположение. Признаком наличия объекта будет скачок амплитуды в какой-либо области.

Первый объект, расположенный в среде, имеет координаты: X (15-18), Y (16-19), амплитуду A = 700, второй объект: X (23-27), Y (29-32), A = 450, третий объект: X 39 Y (40-43), A = 300. Часть таблицы модели нормированных данных представлена на рис. 2, где часть первого объекта выделена цветом.

5 Xnorm	6 Ynorm	7 amp-media	8 amp-object
-0,253	-1,290	1,413	1,394
-0,253	-1,223	1,352	1,333
-0,253	-1,155	1,084	1,066
-0,253	-1,087	1,061	1,043
-0,253	-1,019	1,045	1,027
-0,253	-0,951	1,008	0,990
-0,253	-0,883	0,925	0,907
-0,253	-0,815	0,872	0,855
-0,253	-0,747	0,752	0,734
-0,253	-0,679	0,678	0,661
-0,253	-0,611	0,657	1,130
-0,253	-0,543	0,429	1,130
-0,253	-0,475	0,396	1,130
-0,253	-0,408	0,364	1,130
-0,253	-0,340	0,271	0,255
-0,253	-0,272	0,211	0,195
-0,253	-0,204	0,148	0,132
-0,253	-0,136	0,116	0,100
-0,253	-0,068	-0,342	-0,357
-0,253	0,000	-0,348	-0,364
-0,253	0,068	-0,437	-0,452

Рис. 2. Часть таблицы с нормированными данными

Диаграмма рассеяния с помещёнными тремя объектами представлена на рис. 3.

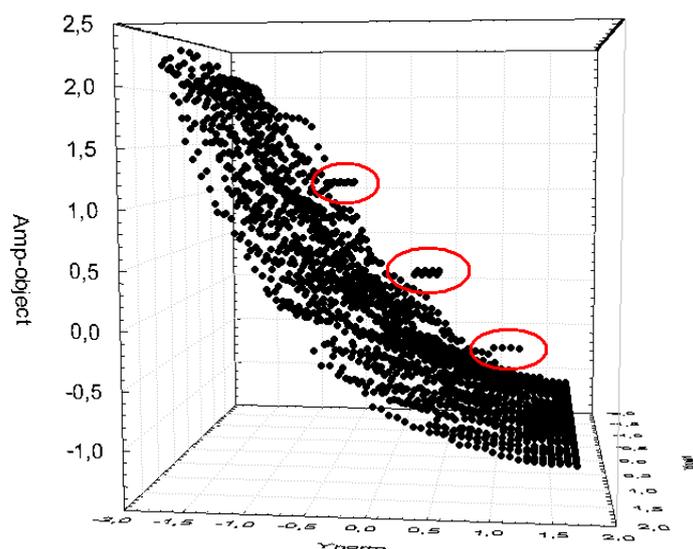


Рис. 3. Диаграмма рассеяния модели с тремя объектами

На диаграмме присутствуют три явно выраженные области, то есть три скачка амплитуд, которые моделируют объекты в среде.

Проведение кластерного анализа методом k-средних в программном пакете Statistica

В кластерном анализе методом k-средних число кластеров выбирает пользователь. Брать малое число кластеров не имеет смысла из-за большого объема данных. Разобьем таблицу сначала на 100, потом на 150 и 175 кластеров. Более успешным вариантом будет считаться тот, при котором каждый из объектов попадет в отдельный кластер, в котором не будут присутствовать посторонние точки, не являющиеся объектами.

Часть таблицы кластерного анализа при кластеризации на 100 кластеров представлена на рис. 4.

5	6	7	8	9	10	11
Xnorm	Ynorm	Amp-media	Amp-object	CASE_NO	CLUSTER	DISTANCE
-0,422	-0,951	0,984	0,966	777	49	0,12
-0,422	-0,883	0,842	0,825	778	49	0,11
-0,422	-0,815	0,825	0,807	779	49	0,11
-0,422	-0,747	0,648	0,631	780	49	0,20
-0,422	-0,679	0,613	0,596	781	49	0,22
-0,422	-0,611	0,553	1,130	782	49	0,16
-0,422	-0,543	0,445	1,130	783	49	0,19
-0,422	-0,475	0,364	1,130	784	49	0,22
-0,422	-0,408	0,362	1,130	785	49	0,25
-0,338	-1,087	1,048	1,030	826	49	0,18
-0,338	-1,019	1,035	1,017	827	49	0,14
-0,338	-0,951	0,919	0,901	828	49	0,10
-0,338	-0,883	0,791	0,773	829	49	0,12
-0,338	-0,815	0,696	0,678	830	49	0,16
-0,338	-0,747	0,571	0,554	831	49	0,23

Рис. 4. Результаты кластеризации на 100 кластеров

В первом и во втором столбцах (X_{norm} , Y_{norm}) – нормированные значения координат отраженного сигнала; в третьем столбце (Amp-media) – нормированные значения амплитуд; в четвертом столбце (Case_NO) – номер ячеек; в пятом столбце (CLUSTER) – номер кластера и в шестом столбце (DISTANCE) – расстояние объектов до центра каждого кластера.

При кластеризации на 100 кластеров три объекта сгруппированы в отдельные кластеры. Первый объект попал в кластер под номером 32, второй объект в кластер под номером 49, третий в кластер под номером 14. Из таблицы видно, что в 49 кластер помимо объекта попали посторонние точки (рис. 5).

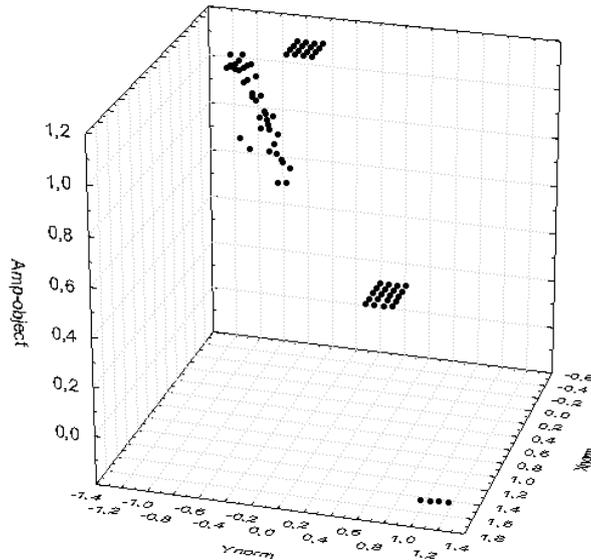


Рис. 5. Диаграмма рассеяния при 100 кластерах

На диаграмме отчётливо выделены четыре области, когда, на самом деле, они разбиты на три кластера. Это значит, что в один из кластеров попали посторонние точки, существенно отличающиеся по амплитуде и координатам. Значит, можно сделать вывод, что кластеризация на 100 кластеров не является подходящей для данной модели, так как невозможно четко отделить объекты от среды, в них попадают лишние точки, в нашем случае, не являющиеся объектами.

Результаты разбиения на 175 кластеров представлены в виде таблицы и диаграммы рассеяния на рис. 6 и 7.

5	6	7	8	9	10	11
xnorm	ynorm	amp-media	amp-object	CASE NO	CLUSTER	DISTANCE
-0,34	-1,56	2,01	1,99	819	120	0,08
-0,25	-1,70	2,17	2,15	868	120	0,06
-0,25	-1,63	2,15	2,13	869	120	0,03
-0,25	-1,56	2,14	2,11	870	120	0,04
-0,25	-1,49	2,11	2,09	871	120	0,08
-0,17	-1,70	2,27	2,25	919	120	0,12
-0,17	-1,63	2,15	2,13	920	120	0,08
-0,17	-1,56	2,15	2,13	921	120	0,08
-0,17	-1,49	2,14	2,12	922	120	0,10
1,61	1,02	-0,91	-0,15	2030	121	0,06
1,61	1,09	-1,02	-0,15	2031	121	0,02
1,61	1,15	-1,05	-0,15	2032	121	0,02
1,61	1,22	-1,07	-0,15	2033	121	0,06
0,34	-1,29	1,46	1,44	1231	122	0,05
0,34	-1,22	1,38	1,36	1232	122	0,09
0,42	-1,29	1,67	1,65	1282	122	0,09
0,42	-1,22	1,50	1,48	1283	122	0,03
0,51	-1,36	1,57	1,56	1332	122	0,08
1,52	-1,29	0,97	0,95	1945	123	0,05

Рис. 6. Результаты кластеризации на 175 кластеров

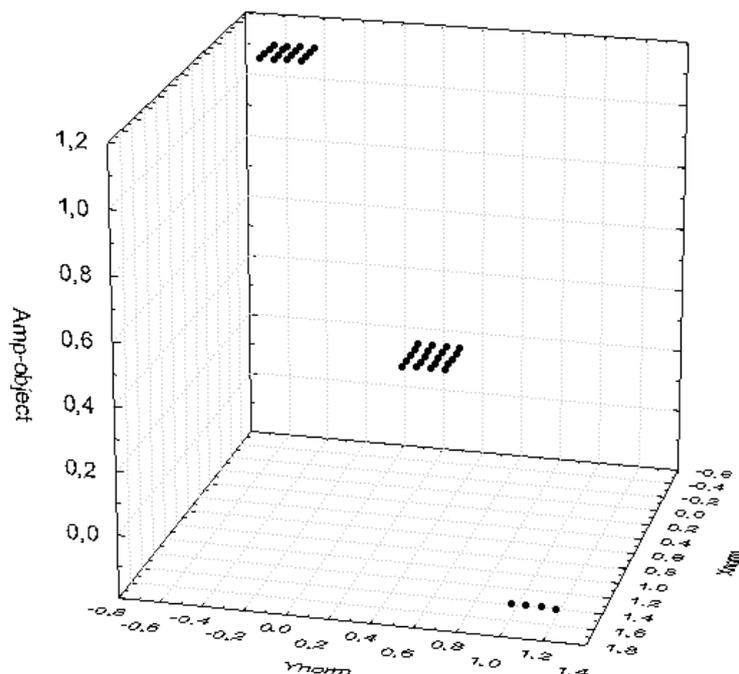


Рис. 7. Диаграмма рассеяния для кластеров 121, 146, 151

На рис. 6 выделенный цветом кластер является одним из искомым объектов. На рис. 7 можно увидеть расположение трех кластеров в пространстве, в которые входят точки с одинаковой амплитудой без каких-либо посторонних точек и ни один из объектов не разбит на два кластера. По диаграмме можно сделать вывод о наличии трёх объектов и то, что они четко отделены от всей среды.

Выбор оптимального количества кластеров

Решение задач выявления границ слоёв и объектов в среде методом кластерного анализа напрямую связано с определением количества кластеров. От правильного выбора числа кластеров будет зависеть успех обнаружения объектов.

Выполнив кластерный анализ для модели методом k-средних с разбиением на разное количество кластеров, и сравнив результаты кластеризации, можно сделать вывод, что для данной модели оптимальным числом кластеров является 175. В этом случае каждый объект попадает в отдельный кластер. Дальнейший статистический анализ будем проводить для модели, разделенной на 175 кластеров, в которой искомые объекты расположены в отдельных кластерах. Первый объект занимает кластер под номером 146, второй объект кластер под номером 151, третий объект – 121 кластер.

Проведенный статистический анализ позволил отделить объекты от среды в отдельные кластеры. Решим задачу обнаружения, учитывая, что в реальности координаты объектов не будут известны.

Задача может быть решена выполнением древовидной кластеризации данных, полученных после кластерного анализа методом k-средних, то есть данных, представляющих собой 175 непересекающихся подмножеств – кластеров, а значит, будем использовать средние значения амплитуды и координат каждого кластера.

Отделить кластеры с объектами от всех остальных кластеров, не представляющих интереса, можно при помощи древовидной кластеризации и иерархического алгоритма статьи [25]. Древовидная кластеризация использовалась после построения гистограммы данных и позволила отделить границы объектов от общего фона. В нашем случае целесообразно применять древовидную кластеризацию данных, сгруппированных надлежащим образом при помощи метода k-средних, чтобы получить искомые кластеры.

Наиболее информативным результатом является горизонтальная дендрограмма, которая изображена на рис. 8.

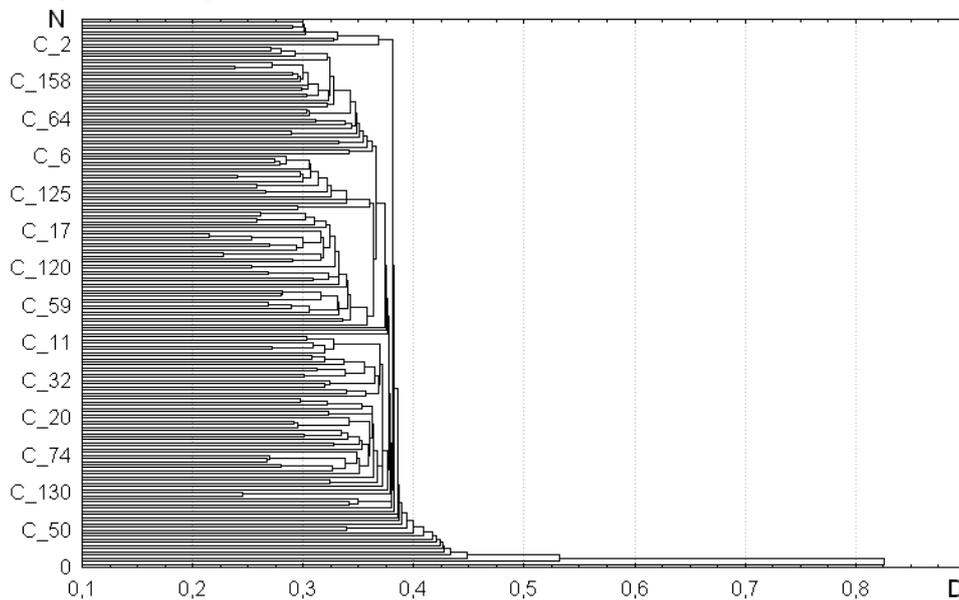


Рис. 8. Дендрограмма

На горизонтальной оси дендрограммы откладываются расстояния между начальными объектами кластеризации и кластерами, на вертикальной оси – номера кластеров N. Таким образом, вертикальные отрезки дендрограммы проводятся на уровнях, соответствующих пороговым значениям расстояний, выбираемым для данного шага кластеризации. Кластерный анализ одиночной связи (ближайшего соседа) приводит к образованию одного кластера.

На рисунке можно выделить три кластера у основания с максимальными пороговыми значениями по сравнению с другими. Это результирующий кластер и два кластера, следующие за ним. Их можно выделить из общей массы и предположить, что эти кластеры являются кластерами с объектами. Проверить это возможно, построив дендрограмму, отражающую номера кластеров. Часть такой дендрограммы представлена на рис. 9.

Amalgamation Schedule (средн 1)															
Single Linkage															
Euclidean distances															
linkage distance	Obj. No. 161	Obj. No. 162	Obj. No. 163	Obj. No. 164	Obj. No. 165	Obj. No. 166	Obj. No. 167	Obj. No. 168	Obj. No. 169	Obj. No. 170	Obj. No. 171	Obj. No. 172	Obj. No. 173	Obj. No. 174	Obj. No. 175
,3713111															
,3717432															
,3743530															
,3757349															
,3762656															
,3765204															
,3778702															
,3783946															
,3801911															
,3802356															
,3805846															
,3822718															
,3859445															
,3862480															
,3866172	C_89														
,3894682	C_89	C_13													
,3942964	C_89	C_13	C_46	C_50											
,3991734	C_89	C_13	C_46	C_50	C_113										
,4090240	C_89	C_13	C_46	C_50	C_113	C_5									
,4165704	C_89	C_13	C_46	C_50	C_113	C_5	C_53								
,4201708	C_89	C_13	C_46	C_50	C_113	C_5	C_53	C_91							
,4238184	C_89	C_13	C_46	C_50	C_113	C_5	C_53	C_91	C_15						
,4258631	C_89	C_13	C_46	C_50	C_113	C_5	C_53	C_91	C_15	C_18					
,4270709	C_89	C_13	C_46	C_50	C_113	C_5	C_53	C_91	C_15	C_18	C_136				
,4336464	C_89	C_13	C_46	C_50	C_113	C_5	C_53	C_91	C_15	C_18	C_136	C_61			
,4483621	C_89	C_13	C_46	C_50	C_113	C_5	C_53	C_91	C_15	C_18	C_136	C_61	C_146		
,5321475	C_89	C_13	C_46	C_50	C_113	C_5	C_53	C_91	C_15	C_18	C_136	C_61	C_146	C_151	
,8256705	C_89	C_13	C_46	C_50	C_113	C_5	C_53	C_91	C_15	C_18	C_136	C_61	C_146	C_151	C_121

Рис. 9. Часть дендрограммы с номерами кластеров

Из рис. 9 видно, что результирующими кластерами древовидной кластеризации являются кластеры под номером 121, 151, 146. Искомые кластеры, содержащие объекты, можно отделить от среды.

Заключение

Задача распознавания объектов очень актуальна и широко применима в различных областях деятельности человека, в том числе в области телекоммуникаций. Решение задач осуществляется различными методами сегментации изображения.

В данной работе в программном пакете Statistica была создана модель среды данных с тремя объектами, представляющая собой значения амплитуд отраженного сигнала и координат профиля на местности. Необходимость модели обоснована тем, что реальные данные имеют большой объём и посторонние шумы.

Для модели среды был проведен кластерный анализ методом k-средних, который позволил выделить объекты в отдельные кластеры. Затем, для полученных данных была проведена древовидная кластеризация, с помощью которой кластеры с объектами были отделены от среды. Были представлены наглядные графики, подтверждающие успешные результаты.

Список литературы

1. Гринев А. Ю. Вопросы подповерхностной радиолокации / А.Ю. Гринев – М. : Радиотехника, 2005. – 416 с.
2. Shapiro L.G. Computer Vision / L.G. Shapiro, G.C. Stockman // Prentice-Hall, New Jersey. – 2007. – P. 279–325.

3. Обзор методов сегментации и триангуляции данных МРТ [Электронный ресурс]. – Режим доступа: <http://www.ihna.ru/files/verkhyutov/mriseg2005.zip>. – Загл. с экрана.
4. Вежневек А. Методы сегментации изображений: автоматическая сегментация / А. Вежневек, О. Баринава // Компьютерная Графика и Мультимедиа [Электронный ресурс]. - 2006. - Режим доступа: <http://cgm.computergraphics.ru/content/view/147>. – Загл. с экрана.
5. Bishop C.M. Neural Networks for Pattern Recognition / C.M. Bishop // Oxford University Press. - Oxford, 1995. – P. 567-573.
6. Lucchese L. Color Image Segmentation: A State-of-the-Art Survey / L. Lucchese, S.K. Mitra. – New York, 2001. – P. 1243-1247.
7. Вуколов Э.А. Основы статистического анализа. Практикум по статистическим методам и исследованию операция с использованием пакетов STATISTICA и EXCEL: Учебное пособие / Э.А. Вуколов. – М.: ФОРУМ: ИНФРА-М, 2004. – 464 с. – (Профессиональное образование).
8. Ohlander R. Picture Segmentation Using a Recursive Region Splitting Method / R. Ohlander, K. Price, D.R. Reddy // Computer Graphics and Image Processing, volume 8. – 1978. – P. 313–333.
9. Tremeau A. Region growing and Merging Algorithm to color segmentation / A. Tremeau, A. Borel // Pattern Recognition. – 1997. – P. 246–251.
10. Kanai Y. Image Segmentation Using Intensity and Color Information / Y. Kanai // SPIE – Visual Communications and Image Processing. – New York, 1998. – P. 1347–1354.
11. Cramariuc B. Clustering Based Region Growing Algorithm for Color Image Segmentation / B. Cramariuc, M. Gabbouj, J. Astola // Int. Conf. on Digital signal Processing. – New York, 1997. – P. 456–495.
12. Deng Y. Color Image Segmentation / Y. Deng, B.S. Manjunath, H. Shin // CVPR. – 1999. – P. 457–478.
13. Jain R. Machine Vision / R. Jain, R. Kasturi, B.G. Schunck. – New York, 1995. – P. 1752–1770.
14. Bow S.T. Pattern Recognition and Image Preprocessing / S.T. Bow // Marcel Dekker, Inc. – New York, 1992. – P. 1256–1274.
15. Celenk M. Hierarchical Color Clustering for Segmentation of Textured Images // Proc. of the 29th Southeastern Symposium on system Theory / M. Celenk. – New York, 1997. – P. 657–683.
16. Digabel H. Iterative Algorithms / H. Digabel, C. Lantujoul // Proc. of the 2nd European Symp. on Quantitative Analysis of Microstructures in Material Science, Biology and Medicine. – 1977. – P. 2136–2194.
17. Shafarenko L. Automatic Watershed segmentation of Randomly Textured Color Images / L. Shafarenko, M. Petrov, J. Kittler // IEEE Trans. on Image Processing. – New York, 1997. – P. 456–562.
18. Barni M. Fuzzy Expert System for Low Level Image Segmentation / M. Barni, S. Rossi, A. Mecocci // EUSIPCO. – New York, 1996. – P. 1359–1387.

19. Pal N.R. A Review on Image Segmentation Techniques / N.R. Pal, S.K. Pal // Pattern Recognition, Vol. 26, No 9. – New York, 1993. – P. 1204–1263.
20. Wu Z. An Optimal Graph Theoretic Approach to Data Clustering. Theory and Its Application to Image Segmentation / Z. Wu, R. Leahy // IEEE Transactions on Pattern Analysis and Machine Intelligence. – 1993. – N 15(11). – P. 1101–1143.
21. Matula D.W., Graph Theoretic Techniques for Cluster Analysis Algorithms / Matula D.W., // Classification and Clustering.- New York, 1977. - Academic Press. - P. 95-129.
22. Fowlkes C. Learning Affinity Functions for Image Segmentation / C. Fowlkes, D. Martin, J. Malik // Combining Patch-based and Gradient-based Approaches. – New York, 2003. – P. 1318–1346.
23. Hertz T. Boosting Margin Based Distance Functions for Clustering / T. Hertz, A. Bar-Hillel – 2004. – P. 761–794.
24. Haralick R.M. Image Segmentation Techniques / R.M. Haralick, L.G. Shapiro // Computer Vision, Graphics, and Image Processing. – Vol 29. –No 1. – New York, 1985. – P. 621–667.
25. Arifin A.Z. Image Segmentation by Histogram Thresholding Using Hierarchical Cluster Analysis / A.Z. Arifin, A. Asano // Pattern Recognition Letters 27. – 2006. – P. 1515– 1521.