

УДК 004.93

© А. В. Кучуганов, Д. Р. Касимов, В. Н. Кучуганов

МОДЕЛИРОВАНИЕ РАССУЖДЕНИЙ ПРИ ПОИСКЕ ОБЪЕКТОВ НА ИЗОБРАЖЕНИЯХ

Зрительные образы весьма вариативны. Например, рукописные буквы, объекты аэрокосмических наблюдений. Высокое разнообразие и большой объем неструктурированной информации приводят к необходимости сложных и ресурсоемких вычислений. В подходах к анализу изображений, опирающихся на онтологию предметной области, к сожалению, не оговаривается какой-либо способ автоматического подбора критериев (признаков) и правил принятия решений, а недостаточная структурированность прецедентов при большой вариативности изображений объектов приводит к быстрому росту базы прецедентов, что существенно снижает производительность системы поддержки принятия решений. В статье предлагается подход к структурному анализу изображений, заключающийся в последовательном уточнении признаков объектов и ослаблении правил интерпретации в ходе итерационного поиска фактов с использованием онтологии изображений, представленных в виде атрибутивных графов отношений между элементами объектов. Алгоритм рассуждений на графической информации состоит в последовательности задачных (функциональных) действий, необходимых для обработки и анализа изображения в соответствии с поставленной задачей, действий системы по подготовке условий для их выполнения, а также по организации и управлению процессом рассуждений.

Ключевые слова: изображение, информативный признак, атрибутивный граф, структурированный прецедент, онтология, рассуждатель, итерационная стратегия, сопоставление графов прецедентов.

DOI: [10.35634/vm200310](https://doi.org/10.35634/vm200310)

Введение

При решении задач структурного анализа и поиска фактов на изображениях обычно используют ранее накопленные знания: грамматики, эталоны, прецеденты. *Прецедент* — это участок изображения, содержащий несколько близко расположенных объектов или частей объекта, различающихся по признакам цвета и формы. Вывод на основе прецедентов позволяет сократить перебор вариантов при отнесении фигуры или нескольких соседних к некоторому классу возможных объектов.

В работе [1] предложен метод определения оптимальных параметров сегментации аэрокосмоснимков путем рассуждений на основе прецедентов. Прецедентами являются примеры изображений. С каждым изображением-прецедентом ассоциированы значения параметров сегментации, при которых изображение-прецедент сегментируется наилучшим образом; они определяются путем формирования всевозможных вариантов (комбинаций) значений, обработки изображения по каждому варианту, оценки качества получающегося в каждом случае результата и выбора того набора значений, при котором наблюдается наилучший результат. На основе информации, содержащейся в базе прецедентов, оптимальные параметры сегментации можно автоматически получить для новых изображений; для этого необходимо найти наиболее близкий (похожий) прецедент и заимствовать значения параметров, ассоциированные с ним. Поиск ближайшего прецедента основан на вычислении сходства гистограмм изображений и применении алгоритма кластеризации X-means.

В работе [2] с помощью рассуждений на основе прецедентов решается задача автоматической детекции оползней на аэрокосмоснимках. База прецедентов формируется с использованием набора размеченных изображений. Прецедентом является сегмент (область) изображения. В прецеденте содержится информация об атрибутах сегмента и метка целевого класса (оползень или прочий объект). Для определения оптимального набора атрибутов авторы применяют технику оптимизации на основе генетического алгоритма; в эксперименте из 366 возможных атрибутов генетический алгоритм выбрал 11 наиболее релевантных признаков, включая спектральные, текстурные, морфометрические атрибуты и параметры формы. Процесс детекции оползней на новом снимке включает выполнение сегментации изображения, вычисление атрибутов полученных сегментов, оценку сходства сегментов с прецедентами и присваивание класса, указанного в наиболее похожем прецеденте. Оценка сходства вычисляется по формуле, интегрирующей разницу значений отдельных атрибутов.

В работе [3] предлагается подход к проблеме классификации объектов на аэрокосмоснимках, в котором применяются нечеткие рассуждения на основе прецедентов и методы ансамблевого обучения. Авторы стремятся к тому, чтобы система, обученная на изображениях одного типа, была способна успешно классифицировать объекты на снимках другого типа, то есть снятых в другое время или относящихся к другой территории. Для этого с использованием набора размеченных снимков создается база прецедентов. Прецедентом выступает описание объекта изображения, полученного в результате сегментации изображения, в виде вектора значений 11-ти признаков (спектральные, текстурные, геометрические атрибуты и параметры пространственных отношений). В каждом прецеденте задан целевой класс в качестве решения. С помощью созданных прецедентов и алгоритма fuzzy k-NN производится оценка того, с какой вероятностью объекты из нового набора снимков относятся к каждому из целевых классов. Степень сходства объектов с прецедентами вычисляется как взвешенное евклидово расстояние в пространстве признаков. В результате прецедентного вывода для новых снимков формируются карты вероятности классификации. Эти карты используются для синтеза ансамблевого классификатора, адаптированного к новому набору изображений, с помощью алгоритма TrAdaBoost.

В работе [4] предлагается онтологический подход к представлению знаний GEOBIA-систем (Geographic Object-Based Image Analysis — объектный анализ географических изображений). На основе формализма дескриптивных логик описываются связи между целевыми категориями объектов и их образами на изображениях. Из этих логических описаний затем извлекаются правила отнесения объектов изображения, выделяемых с помощью процедуры сегментации, к желаемым категориям. Преимущество такого подхода в том, что знания экспертов передаются анализирующей системе в более систематизированном виде, нивелируется субъективность правил принятия решения, появляется возможность применения средств автоматической проверки согласованности базы знаний. Распознавание основывалось на спектральных и геометрических характеристиках отдельных объектов (индекс NDVI, признак прямоугольности и тому подобное). Авторы отметили, что автоматическая сегментация не всегда идеально очерчивала границы объектов, в том числе из-за присутствия теней и деревьев. В связи с этим для уточнения результатов сегментации применялась существующая свободная база картографических данных.

В работе [5] представлен метод семантической классификации объектов изображения на основе управляемых знаниями семантических правил. Результаты, полученные авторами, показывают, что онтологический подход по сравнению с классификацией на основе дерева решений без использования онтологии дал некоторые статистические улучшения с точки зрения точности для использованных конкретных изображений.

В работе [6] предложен подход к классификации и интерпретации спутниковых изображений на основе онтологии. Экспертами разрабатывается онтология для представления

знаний, содержащихся в спутниковых снимках, таких как классы объектов, спектральные характеристики объектов, пространственные отношения между объектами, временные факторы (время года, атмосферные эффекты) и так далее. Знания представляются в виде иерархии концептов и отношений между ними. Создание базы знаний — это итеративный процесс, который продолжается до тех пор, пока не будут созданы характеристики и правила, дающие удовлетворительные результаты классификации на выборке тестовых изображений по оценке экспертов предметной области. Собственно классификация объектов на спутниковых изображениях также представляется как итеративный процесс пошагового уточнения результатов путем сравнения значений признаков анализируемых объектов с допустимыми диапазонами спектральных, пространственных и временных характеристик, связанных с концептами онтологии. Результатом классификации объектов на изображении является множество отображений вида «объект → концепт». После получения таких соответствий, аналитик может применять стандартные механизмы логического вывода (рассуждатель) на знаниях с целью поддержки принятия решений.

Проблема уменьшения пространства признаков в задаче классификации текстурных изображений рассматривается в работе [7]. Многоальтернативная классификация приводится к бинарной одномерной задаче, в которой допустимо использовать байесовский подход с одномерными оценками распределений. Параметры распределения оцениваются методом моментов. После оценки параметров осуществляется проверка гипотезы о распределении по критерию Пирсона. Экспериментально установлено, что модель бета-распределения в большинстве случаев применима к оценке распределений значений признаков. Сделан вывод о необходимости такой проверки для каждой обучающей выборки. В работе также предлагается по оценкам степени пересечений распределений классов оценивать эффективность признака и взаимную корреляцию выбранных признаков. Предлагается способ оценки информативности признаков, основанный на минимуме средней вероятности ошибки для одного признака и взаимной некоррелированности для системы признаков. Строится система признаков для каждой пары классов. Предложен алгоритм классификации, который объединяет результаты частных бинарных решений и принимает окончательное решение в задаче классификации.

Таким образом, можно сделать вывод о том, что в существующих реализациях GEOBIA технологий применяются относительно простые правила классификации, которые описывают логику визуальной интерпретации пользователя, но, практически, не учитывают контекст объекта. Объект рассматривается как целостный образ, характеризующийся набором признаков. Рассуждения на основе прецедентов выполняются по простой схеме: *Объект → Вектор признаков ↔ Прецедент → Класс*. Проблема сводится к поиску удовлетворительного набора признаков, в частности, нечетких. В ряде работ для этой цели применяются генетические алгоритмы. В условиях несовершенства автоматической сегментации изображения не всегда удается достичь высоких показателей эффективности. Недостаточная структурированность прецедентов при большой вариативности изображений объектов приводит к быстрому росту базы прецедентов, что существенно снижает производительность системы.

В статье предлагается подход к анализу изображений, заключающийся в последовательном уточнении признаков объектов и ослаблении правил интерпретации в ходе итерационного поиска фактов на изображениях, представленных в виде атрибутивных графов отношений между структурными элементами объектов.

§ 1. Онтология и дескриптивная логика изображений

Обычно при создании онтологий для изображений основное внимание уделяется таксономии свойств, описанию объектов и пространственных отношений, а также описанию

особенностей процессов, контролируемых с помощью видеоинформации, например, стихийных бедствий [8]. В нашей онтологии с целью повышения эффективности рассуждателя (reasoner) акцент ставится на описание прецедентов со сложной структурой, а также действий (методов) анализа и вывода в условиях большой вариативности решаемых ситуаций.

Модель онтологии изображений и действий *IAO* определим как набор, состоящий из множества концептов *C*, множества *Relation* отношений, множества Φ функций интерпретации на разделе описывающих данных (ABox) и изображениях:

$$IAO = \langle C, Relation, \Phi, Image \rangle,$$

где множество концептов с целью повышения наглядности терминологического раздела онтологии разбито на подмножества наблюдаемых объектов *Object*, признаков *Property*, действий (методов) анализа и вывода *Action*, функциональных ограничений *Restriction*, решающих правил *Rule*, и прецедентов *Precedent*:

$$C = Object \cup Property \cup Action \cup Restriction \cup Rule \cup Precedent.$$

То есть множество концептов — это: Объекты (наблюдаемые или искомые классы); Признаки (свойства объектов); Действия задачные и действия рассуждателя; Ограничения функциональные (пороговые величины); Решающие правила; Прецеденты (атрибутивные графы отношений между объектами).

Признаки объектов: контуры, цвет, границы цветовых сегментов, форма. Например, на спутниковых снимках урбанизированных территорий наблюдаемыми объектами могут быть: строения, асфальтированные площадки, тротуары, газоны, растительность, участки земли, дороги, река, озеро, берег, которые классифицируются по значениям признаков.

В данной работе используется дескриптивная логика *ALC* — *Attributive Language with Complement* [9, 10]. Описание прецедентов, представленных атрибутивными графами, аналогично работе [11], где логика *ALC* расширена на атрибутивные графы изображений *ARG* — *Attributed Relationship Graph*.

Многослойный атрибутивный граф *MLAG* (*Multi Layer Attributive Graph*) изображения [11] содержит несколько информационных слоев, связанных пространственными отношениями, где каждый слой состоит из вершин и ребер со своим набором атрибутов:

$$MLAG = \langle v^0, G^{SEGM}, G^{EDGE}, G^{SKEL}, R \rangle,$$

где v^0 — корневая вершина с общими атрибутами изображения; G^{SEGM} — граф цветовых сегментов; G^{EDGE} — множество графов границ сегментов; G^{SKEL} — множество графов скелетов сегментов; R — множество отношений «предок-потомок» между слоями графа — отношений между вершиной или ребром из одного слоя и вершиной или ребром из другого слоя.

По аналогии с тематическими слоями в геоинформационных системах, многослойная организация облегчает анализ информации.

Прецедент представляется в виде лучевого графа (ЛГ), в котором корневой вершиной v^0 является область, отнесенная с достаточной уверенностью к одному из объектов целевого множества. Глубина лучевого графа $\rho = 1$ или $\rho = 2$.

§ 2. Итерационная стратегия поиска

Рассуждения на основе прецедентов — это поиск адекватных прецедентов, масштабирование и подстановка фактов к анализируемой ситуации.

Предлагаемый подход к анализу изображений заключается в последовательном уточнении признаков объектов и ослаблении правил интерпретации в ходе итерационного поиска фактов в онтологии изображений, представленных в виде атрибутивных графов отношений между элементами объектов и возможными действиями.

Действия рассуждателя на предметной онтологии разделим на две категории.

Задачные действия (предобработка изображения, выделение признаков, аппроксимация значений, перевод количественных значений в качественные, формирование графов и др.):

$$TaskAction \equiv Action \sqcap \exists hasMethod \sqcap \exists hasObject \sqcap \exists hasProperty \sqcap \exists hasRestriction,$$

где $Method \subset \Phi$.

Задачные действия выполняют преобразование данных. В результате образуются новые ситуации и появляются новые факты.

Предобработка заключается в фильтрации, сглаживании и других стандартных (в зависимости от предметной области) операциях обработки изображений.

Выделение информативных признаков осуществляется с помощью локальных дескрипторов — набора геометрических и логических функций.

Алгоритмы аппроксимации включают аппроксимацию цветовой палитры изображения путем кластерного анализа и аппроксимацию границ полученных цветowych областей — вначале сплайновыми кривыми, а затем круговыми дугами и прямыми. Более детально с ними можно ознакомиться в [12]. Аппроксимация границ дугами и прямыми позволяет относительно просто определять различные признаки формы, характерные для изображений искусственных объектов, и заменять количественные значения на более удобные для пользователей качественные значения типа большой — средний — маленький; острый — прямой — тупой и тому подобное.

Рассуждатель на графической информации служит для классификации (отнесения к одному из заданных классов) объектов изображения с релевантностью как можно более высокой при поддержке имеющейся онтологии знаний и умений.

Действия рассуждателя:

$$ReasonerAction \equiv Action \sqcap \exists hasMethod \sqcap \exists hasRule \sqcap \exists hasObject.$$

Действия рассуждателя включают:

- поиск ответов на запросы к базе знаний;
- выбор задачных действий и параметров их настройки;
- выбор функций извлечения признаков из изображения;
- выбор класса анализируемых объектов по приоритету, по признакам, по заданным отношениям (косвенным признакам);
- выбор решающих правил для анализа изображений объектов указанного класса — по приоритету, по степени достоверности, по интересующим признакам;
- организация дерева поиска и управление.

Сопоставление графов анализируемой ситуации и прецедента, оценка сходства.

В общем случае граф слоя (тематический атрибутивный граф) — это:

$$G = \langle V, E, AV, AE \rangle,$$

где V — множество вершин слоя — типовых опорных узлов (ТОУ) $v \in V$; в качестве таковых могут служить типовые (для предметной области) конфигурации или особенности; E — множество ребер $e \in E$, отображающих пространственные отношения между ТОУ; AV — множество атрибутов вершин — признаков $a \in AV$, принимающих количественные или качественные значения; AE — множество атрибутов ребер $a \in AE$.

Пусть в качестве v^0 лучевого графа (ЛГ) анализируемой ситуации взята область изображения, имеющая признак «не короткая прямая» и цвет, соответствующий Строению. Рядом могут быть: 1) другая часть Строения; 2) Площадка; 3) Дорога; 4) Газон; 5) Дерево. При этом (1) и (2) имеют сходные признаки. А рядом с Площадкой могут быть Газон и (или) Дорога. На Площадке могут быть Клумба, Дерево, Авто как вложенные объекты, отличающиеся цветом от Площадки.

Атрибуты вершин графа: 1) тип объекта; 2) признаки формы; 3) особенности формы; 4) цвет; 5) последовательность отрезков границы.

Атрибуты дуг лучевого графа указывают их пространственную ориентацию, например: «слева», «сверху» и так далее относительно очередного отрезка границы объекта v^0 .

Требуется: для анализируемой ситуации подобрать правдоподобные (релевантные) объекты из целевого множества.

Поиск прецедента, наиболее близкого к анализируемой ситуации, выполняется путем сопоставления графов прецедентов с подграфом, отображающим анализируемый участок изображения.

1. Сопоставление множеств вершин каждая с каждой. *Степень сходства*: $C1$ по количеству совпавших вершин графа анализируемой ситуации; $C2$ по относительной сумме баллов за каждый признак.
2. Если одна из оценок не удовлетворительна, то переход к следующему прецеденту.
3. Сопоставление по связям с помощью лучевых графов — корень (вершина) с атрибутами (1)–(4) и типы (1) ближайших соседей относительно отрезков границ. *Степень сходства* $C3$ по относительной сумме баллов за каждый признак каждой совпавшей вершины.

Подобрав адекватный прецедент, мы можем с некоторой степенью достоверности сказать, например, является ли v^0 анализируемой ситуации частью Строения и к каким классам следует отнести соседние области.

Возможно применение принципа *доказательства от противного*. Область, которая не распознана, принудительно получает, например, тип *Строение* и берется в качестве v^0 лучевого графа. Если не найден подходящий прецедент, то выдвигается предположение, что это есть Площадка, затем — часть Дороги и так далее, пока не будет найден адекватный прецедент.

Рассуждатель: итерационная стратегия поиска. Итерационный поиск фактов — это последовательное уточнение признаков искомых объектов и ослабление правил интерпретации в ходе итерационного поиска.

Уточнение значений признаков рассматривается как адаптация по контенту алгоритмов задачных действий с целью повышения точности.

Ослабление правил — это смягчение требований (ограничений) путем понижения критериев принятия решений или замена правил на более узконаправленные (от общих к частным). Ослабление правил, наоборот, снижает достоверность вывода.

Запрос на поиск объектов заданного класса по заданным признакам:

$SearchObject \sqcap \exists hasProperty.SearchProperty,$

где $SearchObject \sqsubseteq Object$, $SearchProperty \sqsubseteq Property$.

Решающие правила $ClassifyingRule$, с помощью которых устанавливается принадлежность объектов изображения искомым классам, записываются на языке логики предикатов первого порядка. Они добавляют новые факты в базу $GBox$, где находится атрибутивный граф изображения: $ClassifyingRule \sqsubseteq Rule \sqsubseteq Method$.

Например, правило $BuildingRule$, распознающее один из вариантов строений, выглядит следующим образом:

$(Цвет \neq Темный) \wedge (Цвет \neq Зеленый) \wedge (Величина > Средняя) \wedge (ПлощаднаяПрямоугольность \geq ОченьБольшая) \wedge (Имеет3СтороныПрямоугольника = Да) \wedge (Прямолинейность \geq Большая) \wedge (СредняяШирина \geq Большая)$.

Принцип итерационного уточнения признаков объектов заключается в следующем. В результате автоматической цветовой сегментации могут образовываться области, содержащие фрагменты двух или более объектов. Факты наличия у области характерных отростков, узких «перешейков», прямолинейных участков наряду с извилистыми явно свидетельствуют о том, что область покрывает объекты разных классов и ее следует разбить на части. С другой стороны, например, частный дом, имеющий многоскатную крышу, обычно представлен не одним цветовым сегментом, а несколькими областями, что сильно затрудняет процесс детекции, вызывает необходимость слияния областей. Итерационная стратегия поиска фактов и вывод на основе прецедентов позволяют получать области с более адекватными количественными и качественными характеристиками.

Алгоритм.

1. Предобработка изображения.
2. Аппроксимация контуров и границ.
3. Выделение информативных признаков. Перевод количественных значений в качественные.
4. Формирование атрибутивного графа изображения IG .
5. Цикл итерационного поиска фактов.
 - 5.1. Поиск объектов заданных классов в множестве V вершин графа IG на основе ДЛ описаний объектов.
 - 5.2. Цикл i по вершинам, отображающим нераспознанные объекты изображения.
 - 5.2.1. Уточнение признаков в зоне i -того объекта.
 - 5.2.2. Корректировка графа IG .
 - 5.2.3. Выбор *решающих правил*.
 - 5.2.4. Поиск объектов заданных классов в уточненной зоне (в соответствующем подмножестве вершин графа изображения).
 - 5.2.5. Поиск прецедентов путем *сопоставления лучевых графов*.
 - 5.2.6. Вычисление меры близости ситуации по отношению к известным классам объектов.
 - 5.2.7. Подстановка фактов из прецедента в анализируемую ситуацию.

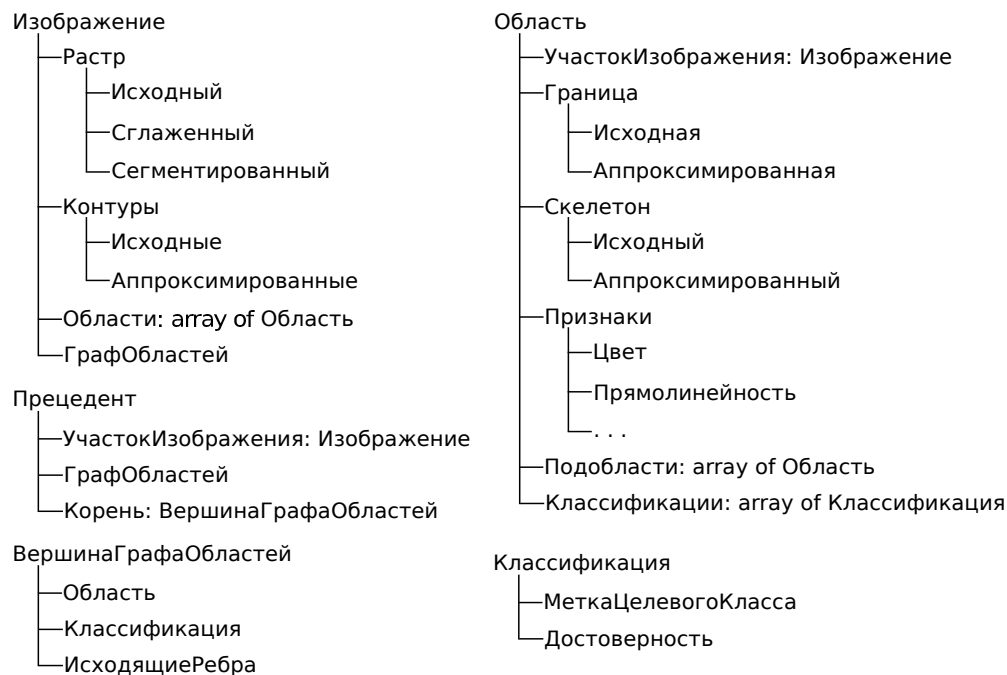


Рис. 1: Используемые структуры данных

§ 3. Эксперименты

На рис. 1 представлены структуры данных, используемые в предлагаемой системе анализа аэрокосмоснимков.

Ниже на языке SDL (Strategy Description Language) [13] описан пример итерационной стратегии поиска строений на аэрокосмических снимках урбанизированных территорий. Язык SDL и программная среда SDL Solver относятся к категории инструментальных средств автоматизации программирования. На SDL удобно задавать различные стратегии выбора действий, ресурсов и ограничений для решения комбинаторных задач.

ГлавныйПлан ()

 ВыполнитьПодплан ОбщийАнализ ()

 ВыполнитьПодплан ЛокальныйАнализ ()

План ОбщийАнализ ()

 // Под режимом понимаются параметры, пороги.

 УстановитьРежимВыполненияДействий(Какой = Режим_общего_анализа)

 Размыть(Что = Исходный из Растр из Изображение,

 Метод = ГауссовскоеРазмытие,

 Результат = Сглаженный из Растр из Изображение)

 ВыделитьКонтур(Где = Сглаженный из Растр из Изображение,

 Метод = CannyEdgeDetector,

 Результат = Исходные из Контур из Изображение)

 Аппроксимировать(Что = Исходные из Контур из Изображение,

 Чем = Отрезками,

 Метод = RamerDouglasPeucker,

 Результат = Аппроксимированные из Контур из

Изображение)

 СегментироватьПоЦвету(Что = Сглаженный из Растр из Изображение,


```

        Метод = Метод_гистограммной_кластеризации_
                в_пространстве_HSV,
        Результат = Области из Изображение)
ВыполнитьДляКаждой(Что = Область$A из Области из Изображение)
    ВыделитьГраницы(Чего = УчастокИзображения из Область$A,
        Метод = Стандартный_метод_выделения_границ,
        Результат = Исходная из Граница из Область$A)
    Аппроксимировать(Что = Исходная из Граница из Область$A,
        Чем = Дугами_и_отрезками,
        Метод = Метод_рекурсивного_наращивания,
        Результат = Аппроксимированная из Граница из
Область$A)
    Скелетизировать(Что = Аппроксимированная из Граница из
Область$A,
        Метод = CGAL_Straight_skeleton,
        Результат = Исходный из Скелетон из Область$A)
    Аппроксимировать(Что = Исходный из Скелетон из Область$A,
        Чем = Отрезками,
        Метод = RamerDouglasPeucker,
        Результат = Аппроксимированный из Скелетон из
                Область$A)
    ВычислитьПризнаки(Чего = Область$A,
        Какие = (Цвет, Плотность_Контуров,
Значимые_линии,
                Прямолинейность, Доля_прямых_углов,
                Извилистость,
Площадная_прямоугольность,
                Средняя_ширина, Удлиненность,
                Нали-
чие_двух_параллельных_значимых_линий,
                Наличие_одной_значимой_линии),
        Результат = Признаки из Область$A)
    ВыполнитьДляКаждого(Что = $Reliability,
        Значения = (Высокая, Средняя, Низкая),
        Порядок = ПоследовательноСлеваНаправо)
    ВыполнитьДляКаждого(Что = $TargetClass,
        Значения =
(Тень, Зелень, Дорога, Площадка, Строение),
        Порядок = ПоследовательноСлеваНаправо)
    ВыполнитьДляКаждого(Что = ПравилоКлассификации$Rule,
        Какого = (МеткаЦелевогоКласса  $\subseteq$ 
$TargetClass,
                Достоверность  $\geq$  $Reliability))
    ВыполнитьДляКаждой(Что = Область$A из Области из
Изображение)
        Классифицировать(Что = Область$A,
            Правило = $Rule,
            Результат = Классификации из Область$A)
Подплан ЛокальныйАнализ( )

```

```

УстановитьРежимВыполненияДействий(Какой =
Режим_локального_анализа)
ВыполнитьДляКаждой(Что = Область$A из Области из Изображение,
Какой = (-Имеет(Что = Классификация,
Какую=(МеткаЦелевогоКласса⊆Строение,
Достоверность >=
Надежная)))
ВыделитьКонтуры(Где = Сглаженный из Растр из
УчастокИзображения из
Область$A,
Метод = CannyEdgeDetector,
Результат = Исходные из Контуры из
УчастокИзображения из Область$A)
Аппроксимировать(Что = Исходные из Контуры из
УчастокИзображения из
Область$A,
Чем = Отрезками,
Метод = RamerDouglasPeucker,
Результат = Аппроксимированные из Контуры из
УчастокИзображения из Область$A)
СегментироватьПоЦвету(Что = Сглаженный из Растр из
УчастокИзображения из Область$A,
Метод = Метод_гистограммной_кластеризации_
в_пространстве_HSV,
Результат = Области из УчастокИзображения
из
Область$A)
ВыполнитьДляКаждой(Что = Область$B из Области из
УчастокИзображения из Область$A)
ВыделитьГраницы(Чего = УчастокИзображения из Область$B,
Метод = Стандартный_метод_выделения_границ,
Результат = Исходная из Граница из Область$B)
Аппроксимировать(Что = Исходная из Граница из Область$B,
Чем = Дугами_и_отрезками,
Метод = Метод_рекурсивного_наращивания,
Результат=Аппроксимированная из Граница из
Область$B)
Создать(Что = ГрафОбластей из УчастокИзображения из Область$A)
ВыполнитьДляКаждого(Что = Прецедент$C из Прецеденты,
Какого = (МеткаЦелевогоКласса из
Классификация
из Корень ⊆ Строение))
ВыявитьВхождения(Чего = ГрафОбластей из Прецедент$C,
Где=ГрафОбластей из УчастокИзображения из
Область$A,
Метод = SubgraphMatching,
Результат = Вхождения$V)
ВыполнитьДляКаждого(Что = Вхождение$w из Вхождения$V,
Какого = (ОценкаСходства >=

```

Удовлетворительная)

Классифицировать (Что=Область\$E из Корень из Подграф2 из Вхождение\$w,

ЦелевойКласс=МеткаЦелевогоКласса из Классификация

из Корень из Подграф1 из Вхождение\$w,

Вхождение\$w, Достоверность = ОценкаСходства из

Результат = Классификации из Область\$E)

Приведенная стратегия состоит из двух этапов – подпланов: «Общий анализ» и «Локальный анализ». В том и другом подплане вначале осуществляется установка режимов выполнения действий.

На этапе общего анализа задаются режимы точности действий из наборов: *Низкая, Средняя, Высокая*. В общем случае эти режимы поочередно меняются для каждого из действий и весь этап повторяется заново. В данном случае для удобства восприятия стратегии сразу устанавливаются режимы средней точности, подобранные в ходе предварительных экспериментов. После действия «Вычислить признаки» для всех цветowych областей изображения начинается итерационная классификация. При этом последовательно ослабляются требования, устанавливаемые правилами, которые рассортированы в заданном порядке выявления целевых классов и по уровню требований к значениям признаков.

На этапе локального анализа осуществляется вывод на основе прецедентов. Здесь также вначале устанавливаются режимы точности действий. Затем для каждой области, которая на предыдущем этапе не была классифицирована с достаточной степенью достоверности, локально и с повышенной чувствительностью выделяются контуры и выполняется цветовая сегментация. Далее строится атрибутивный граф подобластей и отыскивается прецедент, граф которого имеет наибольшее вхождение в граф анализируемой области. Вычисляется мера сходства, на основании которой делается вывод о принадлежности этой области соответствующему целевому классу.

В эксперименте ставилась задача автоматического обнаружения всех объектов класса «строение» на аэрокосмоснимках урбанизированных территорий. Тестовые изображения были взяты из общедоступного набора данных Inria Aerial Image Labeling [14], содержащего снимки европейских и североамериканских городов. Данные изображения имеют сверхвысокое пространственное разрешение (30 см на пиксель) и содержат большое число всевозможных деталей, типов объектов и их сочетаний, что сильно затрудняет процесс автоматической семантической классификации. На рис. 2 представлен пример одного из использованных в эксперименте изображений и соответствующая ему эталонная пиксельная разметка строений, с помощью которой можно объективно оценить качество автоматической классификации. Отметим, что только на одном этом изображении присутствует свыше 500 строений.

На рис. 3 показан пример результатов автоматического обнаружения строений на аэрокосмоснимке.

Всего в эксперименте было использовано 15 изображений, каждое размером 5000×5000 .

Путем попиксельного сравнения результатов автоматической семантической классификации с эталонными маркировками были получены следующие количественные показатели эффективности:

$$Recall_{px} = \frac{|A \cap G|}{|G|} = 65,57, \quad Precision_{px} = \frac{|A \cap G|}{|A|} = 72,78,$$




Рис. 2: Один из элементов набора данных: а) исходный аэрокосмоснимок; б) эталонная пиксельная разметка строений




Рис. 3: Пример автоматического выделения строений на изображении: а) фрагмент исходного изображения; б) результаты семантической классификации (красные пиксели — верно классифицированные, зеленые — неверно классифицированные, белые — пропущенные пиксели строений)

где $Recall_{px}$ — пиксельная полнота, показывающая, какую долю пикселей целевых строений системе удалось захватить; $Precision_{px}$ — пиксельная точность, говорящая о том, сколько пикселей из тех, что были отнесены системой к строениям, являются верными; A — пиксели строений в результате работы системы; G — пиксели строений в эталонной маркировке.

Полученные оценки говорят о высокой эффективности представленного подхода, учитывая высокую сложность решаемой задачи.

На снижение показателей немного повлияло наличие некоторого процента ошибок в эталонных маркировках (строение присутствует на изображении, но отсутствует в разметке, и наоборот; на рис. 3 внимательный читатель может найти пару таких случаев).

Кроме того, следует учитывать, что пиксельные показатели сильно зависят от того, с какой точностью система определяет границы объектов. На наш взгляд, обнаружение даже небольшого фрагмента целевого объекта является весьма весомым фактом, поскольку удалось «зацепиться» за объект. Далее можно в целенаправленном режиме проанализировать область расположения объекта и уточнить его границы.

Заключение

Таким образом, алгоритм проблемно ориентированного рассуждателя на графической информации состоит в последовательности действий, необходимых для обработки и анализа изображения в соответствии с поставленной задачей, действий рассуждателя по подготовке условий для их выполнения, а также в организации и управлении процессом рассуждений.

Представление прецедентов ситуаций в виде атрибутивных графов отношений делает их более удобными для структурного анализа с целью заимствования решений. Стратегии локального уточнения перспективных/сомнительных объектов позволяют повысить показатели релевантности ГЕОБИА технологий.

Далее предполагается исследовать вопросы адаптации структурированных прецедентов к локальным ситуациям и минимизации их количества для машинного обучения с учителем.

Финансирование. Работа выполнена за счет гранта Российского научного фонда — РФФ (проект № 18-71-00109).

СПИСОК ЛИТЕРАТУРЫ

1. Cheriguene R. S., Djerriri K. Case-based reasoning for object-based remotely sensed image classification // 37th EARSeL Symposium: Smart Future with Remote Sensing. 2017. <https://www.researchgate.net/publication/318108617>
2. Dou J., Chang K.-T., Chen S., Yunus A. P., Liu J.-K., Xia H., Zhu Z. Automatic case-based reasoning approach for landslide detection: Integration of object-oriented image analysis and a genetic algorithm // Remote Sensing. 2015. Vol. 7. Issue 4. P. 4318–4342. <https://doi.org/10.3390/rs70404318>
3. Liu Y., Li X. Domain adaptation for land use classification: A spatio-temporal knowledge reusing method // ISPRS Journal of Photogrammetry and Remote Sensing. 2014. Vol. 98. P. 133–144. <https://doi.org/10.1016/j.isprsjprs.2014.09.013>
4. Belgiu M., Hofer B., Hofmann P. Coupling formalized knowledge bases with object-based image analysis // Remote Sensing Letters. 2014. Vol. 5. Issue 6. P. 530–538. <https://doi.org/10.1080/2150704X.2014.930563>
5. Gu H., Li H., Yan L., Liu Z., Blaschke T., Soergel U. An object-based semantic classification method for high resolution remote sensing imagery using ontology // Remote Sensing. 2017. Vol. 9. Issue 4. Article 329. <https://doi.org/10.3390/rs9040329>

6. Abburu S., Golla S.B. A generic framework for multiple and multilevel classification and semantic interpretation of satellite images // World Engineering and Applied Sciences Journal. 2016. Vol. 7. No. 2. P. 107–113.
7. Милич В. Н., Сметанин В. А. Использование бета-распределения в задачах анализа информативности признаков и повышения эффективности решающего правила при распознавании текстурных изображений // Вестник Удмуртского университета. Математика. Механика. Компьютерные науки. 2014. Вып. 3. С. 134–141. <https://doi.org/10.20537/vm140312>
8. Alirezaie M., Kiselev A., Längkvist M., Klügl F., Loutfi A. An ontology-based reasoning framework for querying satellite images for disaster monitoring // Sensors. 2017. Vol. 17. Issue 11. Article 2545. <https://doi.org/10.3390/s17112545>
9. Baader F., Nutt W. Basic description logics // The description logic handbook: theory, implementation, and applications / Baader F., Calvanese D., McGuinness D., Nardi D., Patel-Schneider P.F. (Eds). Cambridge University Press, 2003. P. 43–95.
10. Золин Е. Е. Дескрипционная логика (лекции). <http://lpcs.math.msu.su/~zolin/dl/>
11. Кучуганов М. В., Кучуганов А. В. Дескрипционная логика на графах изображений // Вестник Удмуртского университета. Математика. Механика. Компьютерные науки. 2018. Т. 28. Вып. 4. С. 582–594. <https://doi.org/10.20537/vm180410>
12. Kasimov D. R., Kuchuganov A. V., Kuchuganov V. N., Oskolkov P. P. Approximation of color images based on the clusterization of the color palette and smoothing boundaries by splines and arcs // Programming and Computer Software. 2018. Vol. 44. No. 5. P. 295–302. <https://doi.org/10.1134/S0361768818050043>
13. Kuchuganov V., Kasimov D. An intelligent environment for learning techniques and strategies of solving combinatorial problems // Proceedings of the III International Scientific Conference «Information Technologies in Science, Management, Social Sphere and Medicine» (ITSMSSM 2016). Atlantis Press, 2016. P. 204–207. <https://doi.org/10.2991/itsmssm-16.2016.47>
14. Maggiori E., Tarabalka Y., Charpiat G., Alliez P. Can semantic labeling methods generalize to any city? The Inria aerial image labeling benchmark // 2017 IEEE International Geoscience and Remote Sensing Symposium (IGARSS). 2017. <https://doi.org/10.1109/IGARSS.2017.8127684>

Поступила в редакцию 20.05.2020

Кучуганов Александр Валерьевич, д. т. н., профессор, кафедра «Автоматизированные системы обработки информации и управления», ФГБОУ ВО «Ижевский государственный технический университет имени М.Т. Калашникова», 426069, Россия, г. Ижевск, ул. Студенческая, 7.

E-mail: Aleks_KAV@udm.ru

Касимов Денис Рашидович, к. т. н., доцент, кафедра «Автоматизированные системы обработки информации и управления», ФГБОУ ВО «Ижевский государственный технический университет имени М.Т. Калашникова», 426069, Россия, г. Ижевск, ул. Студенческая, 7.

E-mail: kasden@mail.ru

Кучуганов Валерий Никонорович, д. т. н., профессор, кафедра «Автоматизированные системы обработки информации и управления», ФГБОУ ВО «Ижевский государственный технический университет имени М.Т. Калашникова», 426069, Россия, г. Ижевск, ул. Студенческая, 7.

E-mail: kuchuganov@istu.ru

Цитирование: А. В. Кучуганов, Д. Р. Касимов, В. Н. Кучуганов. Моделирование рассуждений при поиске объектов на изображениях // Вестник Удмуртского университета. Математика. Механика. Компьютерные науки. 2020. Т. 30. Вып. 3. С. 497–512.

A. V. Kuchuganov, D. R. Kasimov, V. N. Kuchuganov

Modeling of reasoning when searching for objects in images

Keywords: image, informative feature, attributed graph, structured case, ontology, reasoner, iterative strategy, case graph matching.

MSC2010: 03B70, 68T10

DOI: [10.35634/vm200310](https://doi.org/10.35634/vm200310)

Visual patterns, for example, handwritten letters or objects of aerospace observations, are highly variable. The high variety and large volume of unstructured information lead to the need for complex and resource-intensive calculations. Unfortunately, image analysis approaches based on the domain ontology do not specify any method for automatic selection of criteria (features) and decision-making rules. Insufficient structuredness of cases and a large variability of object images lead to a rapid growth of the case base, which significantly reduces the performance of the decision support system. The article proposes an approach to the structural analysis of images, which consists in sequential refinement of objects' features and weakening of interpretation rules during an iterative search of facts using the ontology of images represented as attributed graphs of relationships between elements of objects. The algorithm of reasoning on graphic information consists in the sequence of task (functional) actions necessary for processing and analyzing the image in accordance with the task, the actions of the system to prepare conditions for their implementation, as well as to organize and manage the reasoning process.

Funding. This work is supported by the Russian Science Foundation under grant No. 18-71-00109.

REFERENCES

1. Cheriguene R. S., Djerriri K. Case-based reasoning for object-based remotely sensed image classification, *37th EARSeL Symposium: Smart Future with Remote Sensing*, 2017. <https://www.researchgate.net/publication/318108617>
2. Dou J., Chang K.-T., Chen S., Yunus A. P., Liu J.-K., Xia H., Zhu Z. Automatic case-based reasoning approach for landslide detection: integration of object-oriented image analysis and a genetic algorithm, *Remote Sensing*, 2015, vol. 7, issue 4, pp. 4318–4342. <https://doi.org/10.3390/rs70404318>
3. Liu Y., Li X. Domain adaptation for land use classification: A spatio-temporal knowledge reusing method, *ISPRS Journal of Photogrammetry and Remote Sensing*, 2014, vol. 98, pp. 133–144. <https://doi.org/10.1016/j.isprsjprs.2014.09.013>
4. Belgiu M., Hofer B., Hofmann P. Coupling formalized knowledge bases with object-based image analysis, *Remote Sensing Letters*, 2014, vol. 5, issue 6, pp. 530–538. <https://doi.org/10.1080/2150704X.2014.930563>
5. Gu H., Li H., Yan L., Liu Z., Blaschke T., Soergel U. An object-based semantic classification method for high resolution remote sensing imagery using ontology, *Remote Sensing*, 2017, vol. 9, issue 4, article 329. <https://doi.org/10.3390/rs9040329>
6. Abburu S., Golla S. B. A generic framework for multiple and multilevel classification and semantic interpretation of satellite images, *World Engineering and Applied Sciences Journal*, 2016, vol. 7, no. 2, pp. 107–113.
7. Milich V. N., Smetanin V. A. Using the beta distribution for the analysis of informative value of features and for improving the efficiency of decision rule for texture images recognition, *Vestnik Udmurtskogo Universiteta. Matematika. Mekhanika. Komp'yuternye Nauki*, 2014, issue 3, pp. 134–141 (in Russian). <https://doi.org/10.20537/vm140312>
8. Alirezaie M., Kiselev A., Längkvist M., Klügl F., Loutfi A. An ontology-based reasoning framework for querying satellite images for disaster monitoring, *Sensors*, 2017, vol. 17, issue 11, article 2545. <https://doi.org/10.3390/s17112545>

9. Baader F., Nutt W. Basic description logics, *The description logic handbook: theory, implementation, and applications*, Eds.: Baader F., Calvanese D., McGuinness D., Nardi D., Patel-Schneider P.F. Cambridge University Press, 2003, pp. 43–95.
10. Zolin E.E. Description logic (lectures) (in Russian).
<http://lpcs.math.msu.su/~zolin/dl/>
11. Kuchuganov M.V., Kuchuganov A.V. Description logic on image graphs, *Vestnik Udmurtskogo Universiteta. Matematika. Mekhanika. Komp'yuternye Nauki*, 2018, vol. 28, issue 4, pp. 582–594 (in Russian). <https://doi.org/10.20537/vm180410>
12. Kasimov D.R., Kuchuganov A.V., Kuchuganov V.N., Oskolkov P.P. Approximation of color images based on the clusterization of the color palette and smoothing boundaries by splines and arcs, *Programming and Computer Software*, 2018, vol. 44, no. 5, pp. 295–302.
<https://doi.org/10.1134/S0361768818050043>
13. Kuchuganov V., Kasimov D. An intelligent environment for learning techniques and strategies of solving combinatorial problems, *Proceedings of the III International Scientific Conference "Information Technologies in Science, Management, Social Sphere and Medicine" (ITSMSSM 2016)*, Atlantis Press, 2016, pp. 204–207. <https://doi.org/10.2991/itsmssm-16.2016.47>
14. Maggiori E., Tarabalka Y., Charpiat G., Alliez P. Can semantic labeling methods generalize to any city? The Inria aerial image labeling benchmark, *IEEE International Geo-science and Remote Sensing Symposium (IGARSS)*, 2017. <https://doi.org/10.1109/IGARSS.2017.8127684>

Received 20.05.2020

Kuchuganov Aleksandr Valeryevich, Doctor of Engineering, Professor, Department of Automated Data Processing and Control Systems, Kalashnikov Izhevsk State Technical University, ul. Stencheskaya, 7, Izhevsk, 426069, Russia.

E-mail: Aleks_KAV@udm.ru

Kasimov Denis Rashidovich, Candidate of Engineering, Associate Professor, Department of Automated Data Processing and Control Systems, Kalashnikov Izhevsk State Technical University, ul. Stencheskaya, 7, Izhevsk, 426069, Russia.

E-mail: kasden@mail.ru

Kuchuganov Valeriy Nikonorovich, Doctor of Engineering, Professor, Department of Automated Data Processing and Control Systems, Kalashnikov Izhevsk State Technical University, ul. Stencheskaya, 7, Izhevsk, 426069, Russia.

E-mail: kuchuganov@istu.ru

Citation: A.V. Kuchuganov, D.R. Kasimov, V.N. Kuchuganov. Modeling of reasoning when searching for objects in images, *Vestnik Udmurtskogo Universiteta. Matematika. Mekhanika. Komp'yuternye Nauki*, 2020, vol. 30, issue 3, pp. 497–512.