

КЛАССИФИКАЦИЯ БОЛЬШИХ ПЛОЩАДЕЙ ЗЕМНОГО ПОКРОВА ПО РЕТРОСПЕКТИВНЫМ СПУТНИКОВЫМ ДАННЫМ

Аннотация. Задача картографирования больших территорий земного покрова представлена как задача автоматизированной обработки больших объемов геопространственных данных, которые могут содержать различные неопределенности. Для ее решения предложено использовать три различных парадигмы, а именно метод декомпозиции, метод активного обучения из сферы интеллектуальных вычислений и метод восстановления спутниковых снимков. Комплексное применение этих трех составляющих позволило минимизировать участие эксперта в решении задачи. При решении задачи классификации земного покрова проанализированы также три различных варианта слияния данных. Показана эффективность метода слияния данных, который сводится к решению задачи классификации на основе временных рядов данных. Благодаря разработанной автоматизированной методологии поставленная задача классификации и картографирования земного покрова была впервые решена для всей территории Украины за 1990, 2000 и 2010 гг. с 30-метровым пространственным разрешением.

Ключевые слова: классификация земного покрова, геопространственные данные, слияние данных, спутниковые данные, нейронные сети, обучающая и тестовая выборки.

ВВЕДЕНИЕ

Карты земного покрова или продукты обработки спутниковых данных традиционно строятся на основе снимков среднего разрешения, в частности MODIS или SPOT VEGETATION [1]. Последние годы характеризуются появлением в свободном доступе многолетних архивов спутниковых данных высокого разрешения, в частности данных спутников серии Landsat и продуктов их предварительной обработки. Это открывает новые возможности построения ретроспективных карт более высокого (30-метрового) разрешения для больших территорий, которые, в свою очередь, позволяют отслеживать изменения земного покрова и землепользования, а также решать задачи устойчивого развития [2–5].

Однако появление больших объемов данных высокого разрешения не только открывает новые возможности, но и порождает новые проблемы, связанные с обработкой снимков. Следует отметить, что методы классификации и формирования обучающей выборки, хорошо зарекомендовавшие себя при обработке одного снимка для небольшой территории, оказываются неприемлемыми для больших территорий. Основные проблемы связаны с большими объемами данных, малой площадью покрытия одним снимком, облачностью, необходимостью формирования общей карты на основе классификации разновременных снимков и т.п.

Очевидно, что решать эту задачу, обрабатывая каждый снимок в отдельности с помощью специализированного программного обеспечения, например ENVI, не представляется возможным. Поэтому необходимо минимизировать участие эксперта в решении задачи, автоматизировав все этапы ее решения, в том числе этап классификации спутниковых данных и слияния полученных результатов. Решение этой задачи изложено в настоящей статье.

Следует также отметить, что в процессе решения поставленной задачи для обработки и использования данных большого объема, а также последующего уточнения полученных ранее результатов на регулярной основе зачастую приме-

няются информационные системы [6]. Они могут быть основаны на технологиях Grid, Sensor Web [7–9], а также радарных данных [10].

ОБЩАЯ ПОСТАНОВКА ЗАДАЧИ КЛАССИФИКАЦИИ ЗЕМНОЙ ПОВЕРХНОСТИ ДЛЯ БОЛЬШИХ ТЕРРИТОРИЙ

Задача классификации территории всей страны или большого региона относится к задаче обработки «больших данных» и сводится к следующему. На основе имеющихся немаркированных многолетних спутниковых изображений и репрезентативных маркированных данных, которые получены либо путем наземных исследований, либо фотоинтерпретацией, необходимо построить карту классификации. Сложность решения данной задачи состоит в следующем:

- неравномерное покрытие спутниковыми изображениями целевой территории, что приводит к необходимости использования разных признаков для различных областей (регионов). На рис. 1 изображены отснятые спутником снимки территории Украины в 2010 году;
- необходимость учета локальных характеристик исследуемого региона (например, интенсивность и фазы развития сельскохозяйственных культур могут существенно видоизменяться в зависимости от агроклиматических зон);
- отсутствие данных ввиду облачности и теней на оптических изображениях;
- неопределенность (неточность) в маркированных данных, обусловленная их подготовкой на основе фотоинтерпретации (субъективность мнения эксперта).

Для решения поставленной задачи с учетом указанных ограничений в данной статье предлагается подход, основанный на использовании трех парадигм из разных областей компьютерных наук: принципа «разделяй и властвуй» (из теории алгоритмов) [4], метода активного обучения (из теории машинного обучения) [5] и метода восстановления изображений (из области компьютерной обработки цифровых изображений) [11].

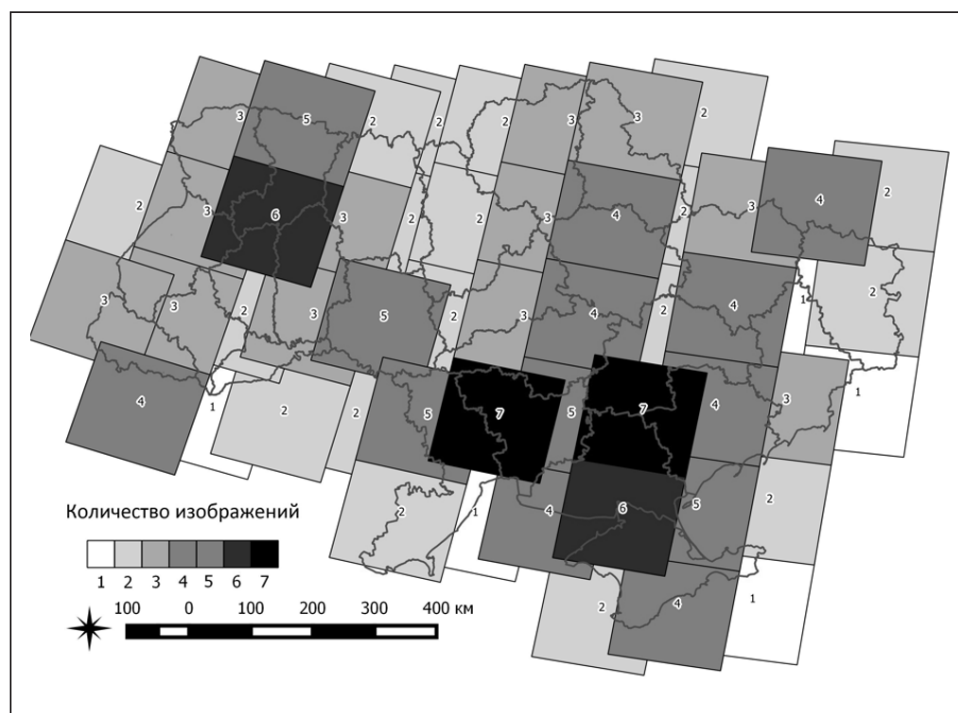


Рис. 1. Карта покрытия территории Украины сценами, используемыми для классификации на основе временного ряда 2010 г.

Для минимизации требований к вычислительным ресурсам системы при решении задачи обработки больших объемов данных территорию Украины предлагается разделить на непересекающиеся области (согласно принципу «разделяй и властвуй») и решать задачу классификации для каждой из них. В общем случае это можно осуществить двумя способами:

- разбиение на области одинакового размера с учетом покрытия спутниковыми данными [12];
- разбиение с учетом административных областей.

Второй способ не обеспечивает равной площади элементарных областей, однако он обладает преимуществом: позволяет использовать независимую информацию (например, официальные статистические данные, которые доступны административным областям Украины) для валидации полученных карт. Следует отметить, что именно такой подход был использован при создании карты классов поверхности Земли в программе CORINE, когда каждая страна проводила исследование своей собственной территории [13].

МЕТОД РЕШЕНИЯ И АЛГОРИТМ КЛАССИФИКАЦИИ СПУТНИКОВЫХ ИЗОБРАЖЕНИЙ

Рассмотрим общий подход к классификации земной поверхности для всей территории Украины на основе спутниковых данных высокого пространственного разрешения. Пусть P — множество границ полигонов, G — выборка для некоторой территории, состоящая из пар: «граница полигона» и класс земной поверхности, соответствующий данному полигону, $G = \{(p, k) \mid p \in P, k = \overline{1, K}\}$, где k — класс земной поверхности, K — общее количество классов. Выборку целесообразно хранить в векторном виде для возможности ее использования при классификации спутниковых изображений различного разрешения и размера. Без потери общности будем считать, что при наземных измерениях или в процессе фотоинтерпретации собранные данные представлены в виде геометрических полигонов. Количество полигонов в выборке (мощность множества) обозначим $|G|$. Выборку разделим на обучающую и тестовую примерно в равных пропорциях, как это принято при использовании индуктивного подхода. При этом

$$G = G_{\text{train}} \cup G_{\text{test}}, \quad (1)$$

$$G_{\text{train}} \cap G_{\text{test}} = \emptyset. \quad (2)$$

В качестве исходных данных в задаче классификации будем рассматривать многовременные спутниковые изображения, на которых пиксели, закрытые облачностью, восстановлены методом из работы [11]. На основе этих изображений для каждой точки выбранной территории формируется вектор

$$\mathbf{x} = (x_1, x_2, \dots, x_n) \in R^n, \quad (3)$$

$$n = i \cdot c,$$

где i — количество спутниковых изображений, покрывающих данную точку в течение года; c — количество спектральных каналов спутникового изображения.

Таким образом, на основе информации, поступающей из спектральных каналов спутникового изображения, можно сформировать множество пикселей выборки, где каждому пикселю, принадлежащему множеству полигонов G , сопоставлен соответствующий номер класса

$$T(G) = \{(\mathbf{x}_i, k_i), i = \overline{1, N}\}.$$

Здесь N — количество пикселей в выборке. Отметим, что мощность и состав данного множества зависит от набора полигонов G . В соответствии с разби-

нием множества полигонов G (1), (2) множество пикселей T также разбивается случайным образом на два независимых подмножества для обучения классификатора и его тестирования:

$$T = T_{\text{train}} \cup T_{\text{test}},$$

$$T_{\text{train}} \cap T_{\text{test}} = \emptyset.$$

Задача классификатора $f(x)$: для каждого входного пикселя (3) вычислить номер класса k_{out} , к которому относится данный пиксель.

В настоящей статье в качестве классификатора будем использовать многослойный перцептрон (multilayer perceptron — MLP), обучение которого и последующая классификация выполняются попиксельно [14–16]. Выбор конкретной модели классификатора обоснован наиболее высокой производительностью типа классификатора при решении аналогичных задач классификации спутниковых изображений [17].

Для обучения классификатора используется метод обратного распространения ошибки [18]. В процессе обучения классификатора происходит настройка весовых коэффициентов связей $w_{ij}^{(1)}$ между входом нейронной сети (3) и скрытым слоем нейронов, а также $w_{jk}^{(2)}$ между скрытым слоем и выходом нейронной сети k_{out} таким образом, чтобы максимизировать количество пикселей, для которых классификатор корректно определяет значение эталонного класса в соответствии с обучающей выборкой $k_{\text{out}} = k$. Блок-схема обработки информации при обучении классификатора с учетом специфики задачи приведена на рис. 2.

После настройки параметров классификатора выполняется попиксельная классификация изображения. В результате для всех пикселей из необходимой

области получаем карту классификации. Ее точность будем оценивать на независимой тестовой выборке, а также сопоставлением с данными официальной статистики.

Для оценки точности классификации на независимой выборке будем использовать следующие метрики.

Часть пикселей n_{ij} из тестовой выборки, реально принадлежащих классу i , но ошибочно отнесенных к классу j , обозначим n_{i+} :

$$n_{i+} = \sum_{j=1}^K n_{ij},$$

часть пикселей n_{ij} , реально принадлежащих классу j , но ошибочно отнесенных к классу i , обозначим n_{+j} :

$$n_{+j} = \sum_{i=1}^K n_{ij}.$$

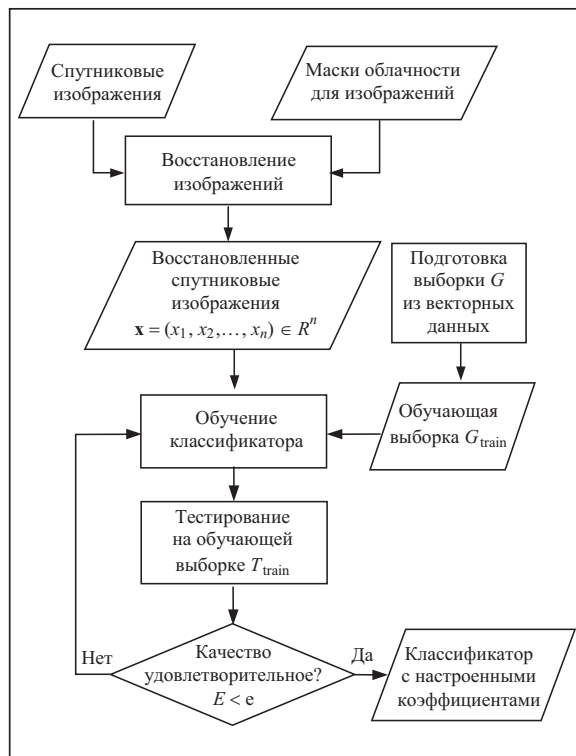


Рис. 2. Блок-схема обучения классификатора и настройки весовых коэффициентов с использованием MLP

Тогда общая точность карты классификации составляет

$$OA = \sum_{k=1}^K n_{kk} / N.$$

С учетом введенных обозначений можно вычислить ошибки первого и второго рода, т.е. точность «производителя» PA и точность «пользователя» UA , а также индекс Каппа K , иллюстрирующий уровень «случайности» классификации [19]:

$$PA = \frac{n_{jj}}{n_{+j}}, UA = \frac{n_{ii}}{n_{i+}}, K = \frac{N \cdot \sum_{i=1}^K n_{ii} - \sum_{i=1}^K n_{i+} \cdot n_{+i}}{N^2 - \sum_{i=1}^K n_{i+} \cdot n_{+i}}.$$

Нулевое значение индекса Каппа свидетельствует о том, что результат классификации согласуется с выборкой так же, как и случайным образом назначенные классы.

Если качество (точность классификации на независимой тестовой выборке) полученной карты удовлетворительно, она принимается как результирующая карта классификации. Если точность неудовлетворительна, то выполняется дообучение или выбор нового классификатора (активное обучение).

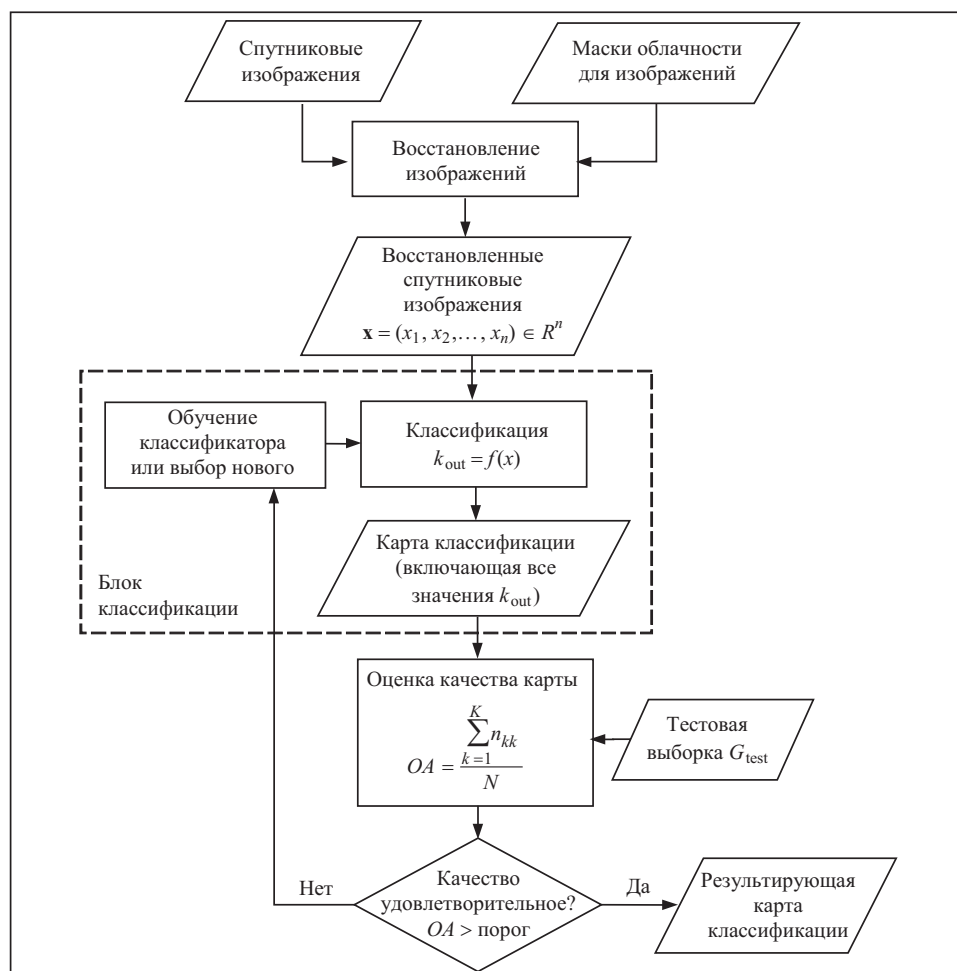


Рис. 3. Алгоритм активной классификации спутниковых изображений

На рис. 3 приведена обобщенная блок-схема работы классификатора с дообучением (активным обучением) в случае неудовлетворительной точности карты классификации на независимой тестовой выборке. Данный подход, включающий восстановление зашумленных пикселей и активное обучение, обеспечивает автоматическое построение карты классификации для каждой выбранной части территории (административной области Украины). Так решается задача классификации земного покрова для больших территорий.

ПРАКТИЧЕСКАЯ РЕАЛИЗАЦИЯ ПРЕДЛОЖЕННОГО ПОДХОДА

Описанный метод классификации использован для построения ретроспективных карт земного покрова для территории Украины. Классификация выполнялась с использованием выборок, построенных в соответствии с международной номенклатурой классов LUCAS [20]. В состав построенных выборок входят полигоны для шести основных классов (искусственные объекты, земли сельскохозяйственного назначения, лес, необрабатываемые земли, открытый грунт, вода). Более подробная информация о сформированных выборках и классах земной поверхности в 1990, 2000 и 2010 гг. представлена в табл. 1.

Таблица 1

| Класс земной поверхности | Количество полигонов в разные годы | | | Отношение количества исследуемых полигонов к общему количеству в разные годы (%) | | | Отношение площади исследуемых полигонов к общей площади в разные годы (%) | | |
|--|------------------------------------|-------|-------|--|--------|--------|---|--------|--------|
| | 2010 | 2000 | 1990 | 2010 | 2000 | 1990 | 2010 | 2000 | 1990 |
| Искусственные объекты | 29 | 14 | 38 | 0,22 | 0,12 | 0,32 | 0,04 | 0,03 | 0,07 |
| Земли сельскохозяйственного назначения | 6278 | 6000 | 5942 | 48,17 | 49,42 | 50,96 | 41,58 | 40,96 | 44,49 |
| Лес | 2338 | 2340 | 2332 | 17,94 | 19,27 | 20,00 | 17,28 | 18,00 | 20,83 |
| Необрабатываемые земли | 2471 | 2084 | 1801 | 18,96 | 17,16 | 15,44 | 10,14 | 7,87 | 7,67 |
| Открытый грунт | 315 | 180 | 156 | 2,42 | 1,48 | 1,34 | 1,06 | 1,47 | 0,96 |
| Вода | 1601 | 1524 | 1392 | 12,29 | 12,55 | 11,94 | 29,90 | 31,67 | 25,98 |
| Всего | 13032 | 12142 | 11661 | 100,00 | 100,00 | 100,00 | 100,00 | 100,00 | 100,00 |

Поскольку обучающая и тестовая выборки (рис. 4) формируются на основе фотоинтерпретации, то они не содержат абсолютно достоверной информации, поскольку сказывается влияние субъективного фактора. Поэтому классификацию необходимо выполнять итерационно, при необходимости редактируя и фильтруя выборки на каждом этапе. Обобщенную постановку задачи классификации с учетом фильтрации выборки сформулируем следующим образом: необходимо итеративно модифицировать множество G , чтобы выполнялись следующие условия:

$$E(T_{\text{train}}) \rightarrow \min, UA(G_{\text{test}}) \rightarrow \max, PA(G_{\text{test}}) \rightarrow \max, \quad (4)$$

$$|G| > g_{\text{critical}}, \quad (5)$$

где E — функция ошибки нейронной сети при условиях (1), (2), g_{critical} — минимальное количество полигонов, необходимое для удовлетворительного обучения нейронной сети [21, 22].

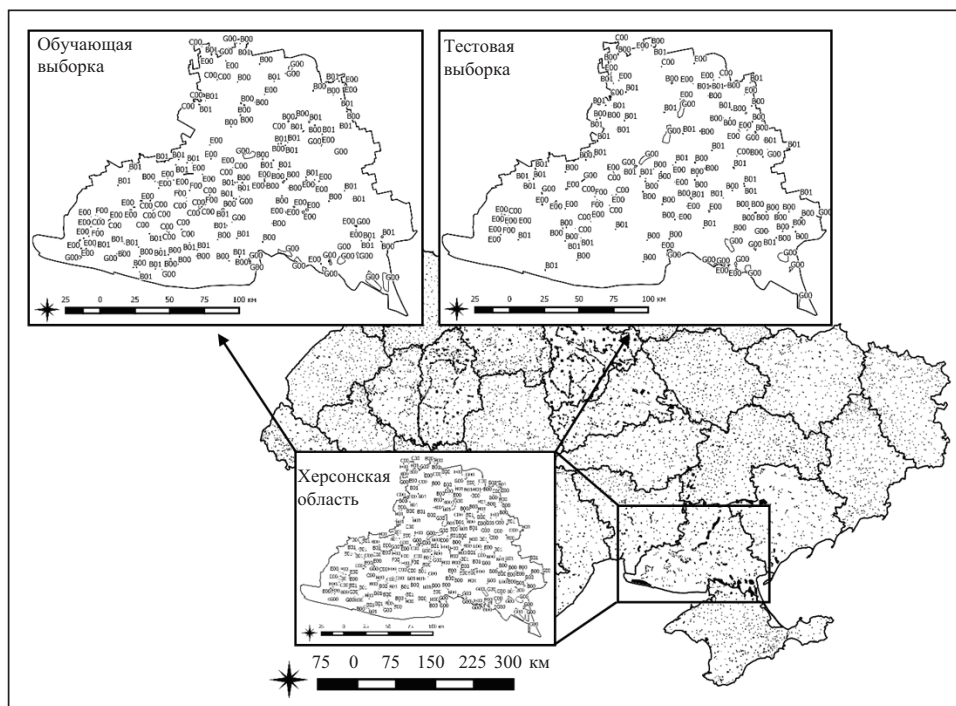


Рис. 4. Выборка для территории Украины за 2010 г. с вынесенной отдельно выборкой для Херсонской области

Таким образом, выборка итеративно модифицируется устранением ошибок (модификации границ полигонов и изменения маркировки) и добавлением новых полигонов до тех пор, пока качество классификации не станет удовлетворительным. При этом количество выбранных полигонов должно удовлетворять требованиям репрезентативности представления классов в исследуемой области и равномерного покрытия полигонами исследуемой территории.

Построение тематической карты необходимо сопоставить с текущей выборкой G и сформировать карту несоответствия результатов классификации и выборки. Поскольку такие несовпадения обусловлены различными причинами, в первую очередь, необходимо обеспечить выполнение условия (5), т.е. обеспечить равномерную распределенность обучающей выборки G_{train} по исследуемой территории для всех классов. Для качественной классификации также необходимо, чтобы классы в обучающей выборке были распределены пропорционально соответствующим площадям на рассматриваемой территории. Без учета этих требований хотя и будет получена высокая точность классификации на тестовой выборке $UA(G_{\text{test}})$, $PA(G_{\text{test}})$, однако результирующая карта классификации окажется неудовлетворительной.

Эксперт должен проанализировать результаты классификации данного поля, выборку G и временной ряд спутниковых изображений (3). Наиболее распространенными причинами несоответствия карты классификации тестовой выборке являются следующие артефакты выборки: перекрытие полигонов, относящихся к разным классам; сомнительные полигоны (эксперту сложно идентифицировать класс определенного полигона); «смешанные» полигоны (содержащие вкрапления других классов — небольшие озера или небольшие группы деревьев); нетипичные полигоны (полигон, отнесенный к какому-либо классу, существенно отличается от других представителей этого же класса), некоторые другие проблемы, связанные с качеством спутниковых изображений. Для обеспечения корректного обучения

нейронной сети сомнительные полигоны удаляются из выборки, неправильно классифицированные полигоны должны быть соотнесены с требуемым классом, нетипичные полигоны считаются исключениями из правил, т.е. выбросами, и удаляются. Итерационный процесс завершается после идентификации всех несоответствий в выборке. При этом полученную карту классификации можно рассматривать как окончательный результат.

МЕТОДЫ СЛИЯНИЯ ДАННЫХ

В связи с малой площадью, покрывающей территорию одним снимком, и наличием временных рядов снимков для каждой точки (см. рис. 1) возникает проблема слияния результатов классификации и построения результирующей карты для большой территории. Возможны два подхода к получению карты классификации: 1) классификация каждого снимка в отдельности последующим слиянием результатов классификации в общую карту для данной территории (слияние на уровне принятия решений); 2) классификация на основе данных всех спутниковых изображений (временного ряда изображений), покрывающих в течение года данную точку (слияние данных на уровне пикселей) (3) [23, 24].

В рамках первого подхода (слияние на уровне принятия решений) предлагается использовать два метода принятия решений. Первый состоит в принятии решения на основе вероятности принадлежности данного пикселя определенному классу на каждом изображении, покрывающем данный пиксель. Этот подход к получению классификации $Im_{res}(i, j)$ можно представить формулой

$$Im_{res}(i, j) = \begin{cases} Im_1(i, j), & P(Im_1(i, j)) > P(Im_2(i, j)), \\ Im_2(i, j), & P(Im_1(i, j)) \leq P(Im_2(i, j)), \end{cases}$$

где $Im_1(i, j)$, $Im_2(i, j)$ — результаты классификации пикселя (i, j) , $P(\cdot)$ — вероятность события.

Второй метод слияния на уровне принятия решений сводится к следующему. Решение о принадлежности данного пикселя некоторому классу $Im_{res}(i, j)$ принимается с учетом качества покрывающих его снимков, т.е. маски восстановленных пикселей, так как результат классификации восстановленных пикселей не отличается высокой надежностью:

$$Im_{res}(i, j) = \begin{cases} Im_1(i, j), & Mask(Im_1) < Mask(Im_2), \\ Im_2(i, j), & Mask(Im_1) \geq Mask(Im_2), \end{cases}$$

где $Im_1(i, j)$, $Im_2(i, j)$ — результаты классификации пикселя (i, j) , $Mask(Im_i)$ — количество восстановленных пикселей на изображении, результатом классификации которого является Im_i , $i = \overline{1, 2}$.

АНАЛИЗ РЕЗУЛЬТАТОВ

Предложенный подход был использован для построения карт земного покрова территории Украины на основе данных Landsat для 1990, 2000 и 2010 годов. Сравнительный анализ результатов различных методов слияния данных при построении карт классификации показывает, что разброс точности пользователя и производителя для основных классов земного покрова (земли сельскохозяйственного назначения, лес, необрабатываемые земли и вода) достаточно велик. На рис. 5 и 6 показаны минимальные, средние и максимальные значения точности производителя и пользователя для четырех основных классов земного покрова при использовании трех методов слияния данных. Минимальные значения каждого класса обозначены светлыми символами, средние — черными, максимальные — серыми символами. На рисунках вертикальными штри-

ховыми линиями разграничены результаты для каждого класса. В каждой секции, соответствующей определенному классу земного покрова, представлены значения точности, обеспечиваемые тремя разными методами слияния данных. Слева направо показаны результаты слияния на основе вероятности, с учетом маски облачности и слияния данных на уровне пикселей (классификации по временному ряду изображений). Два первых результата для каждого класса (слева направо) соответствуют методам слияния на уровне принятия решений: на основе вероятности и с учетом маски облачности. Третий результат в каждой секции соответствует слиянию данных на уровне пикселей (классификации по временному ряду изображений).




Рис. 5. Разброс точности производителя для трех методов слияния данных при построении карт классификации за 2010 г.




Рис. 6. Разброс точности пользователя для трех методов слияния данных при построении карт классификации за 2010 г.




Рис. 7. Гистограмма общей точности классификации для каждой области

В дальнейшем для краткости необрабатываемые земли будем называть лугами.

Как видно из рис. 5, 6, метод слияния данных на уровне пикселей (классификации по временным рядам снимков) обеспечивает наилучшие результаты как для точности пользователя, так и для точности производителя. Наибольший разброс результатов наблюдается при классификации луга. Это объясняется схожестью спектральных характеристик различных типов растительности (на сельскохозяйственных и несельскохозяйственных территориях), а значит, сложностью отделения луга от сельскохозяйственных культур.

Ввиду преимущества метода классификации на основе временных рядов именно он был использован для построения результирующих карт классификации за 1990, 2000 и 2010 гг. Для каждой области общая точность классификации составляет не менее 88 % (в среднем 97 %) на независимой тестовой выборке. Минимальная точность классификации наблюдается в Днепропетровской (1990 г.) и Львовской (2010 г.) областях. Это связано с недостаточным количеством спутниковых данных в 1990 г. и с зашумленностью (облачным покровом) большинства снимков, покрывающих Львовскую область в 2010 г. Гистограмма общей точности классификации земного покрова для каждой области за 1990, 2000 и 2010 годы дана на рис. 7.

Полученные карты классификации земного покрова отличаются достаточно высокой точностью. Разброс точности пользователя и производителя по основным классам земного покрова для 1990, 2000, 2010 годов представлен на рис. 8, 9. Исследования показали, что наилучшие результаты классификации (наименьший разброс точности) достигаются для классов леса и воды. Наибольший разброс точности при построении карты земного покрова приходится на класс необрабатываемых земель, минимальное значение которого составляет порядка 66 %.

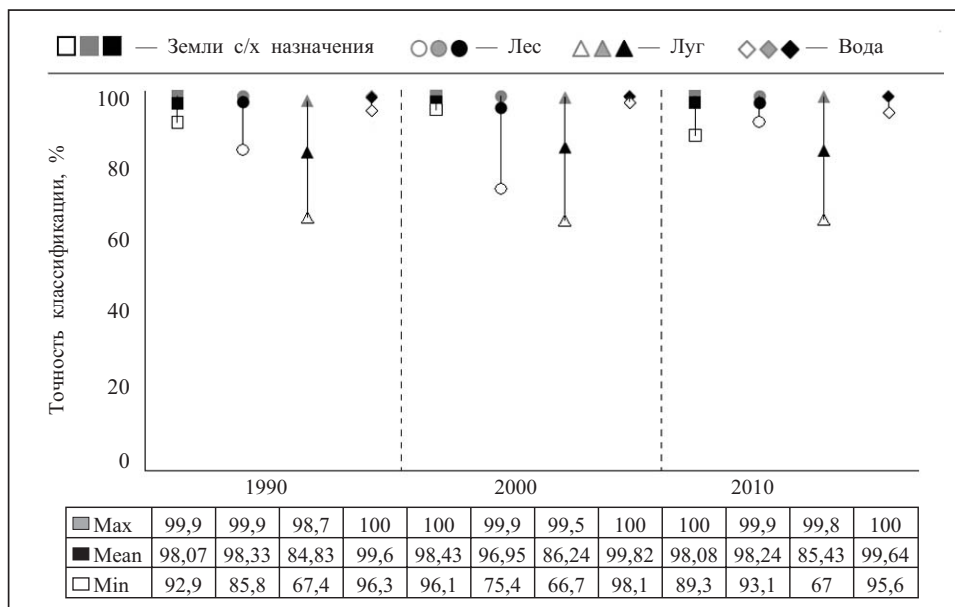


Рис. 8. Разброс точности пользователя для основных классов при классификации на основе временных рядов изображений

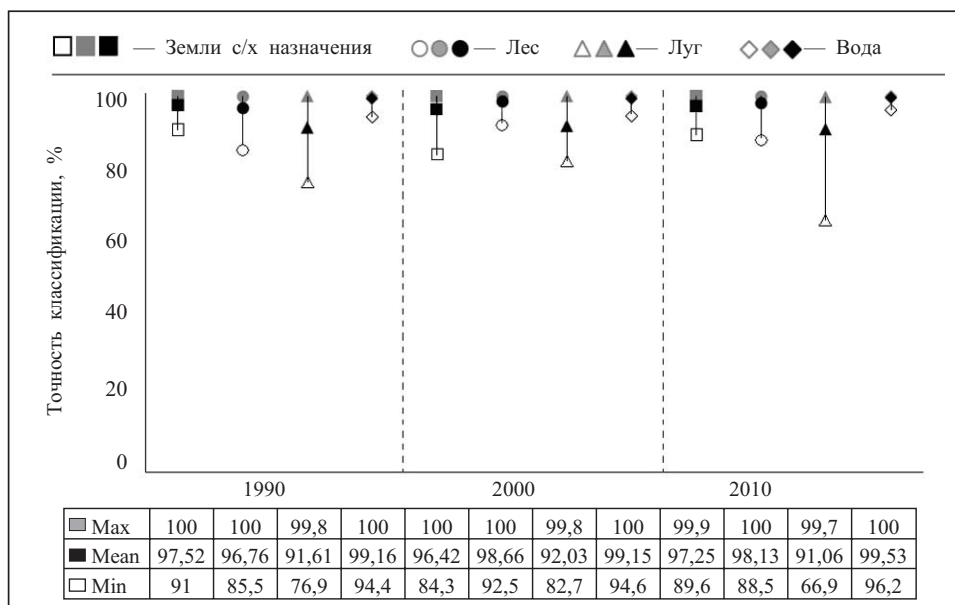


Рис. 9. Разброс точности производителя для основных классов при классификации на основе временных рядов изображений

ЗАКЛЮЧЕНИЕ

В настоящей статье задача картографирования больших территорий земного покрова на основе ретроспективных данных высокого разрешения рассмотрена как задача автоматизированной обработки больших объемов геопространственных данных, которые могут содержать неопределенности (например, области, скрытые облачным покровом). Для решения задачи предложено использовать три парадигмы компьютерных наук, а именно метод декомпозиции («разделяй и властвуй») из теории алгоритмов, метод активного обучения из сферы ин-

теллектуальных вычислений и метод восстановления спутниковых снимков из области компьютерной обработки цифровых изображений. Комплексное применение этих трех составляющих позволяет минимизировать участие эксперта в решении задачи. Проанализированы три варианта слияния данных в задаче классификации земного покрова: два варианта на уровне принятия решений и один — на уровне пикселей. Показана эффективность последнего метода слияния данных, который сводится к решению задачи классификации на основе временных рядов данных. Благодаря разработанной автоматизированной методологии впервые удалось решить задачу классификации и картографирования земного покрова всей территории Украины за 1990, 2000 и 2010 годы с 30-метровым разрешением. Общая точность классификации по областям составляет не менее 88 % и в среднем 97 % на независимой тестовой выборке.

Результаты, полученные при решении задачи картографирования, можно использовать для оценки рисков, а также решения других важных прикладных задач [25, 26].

СПИСОК ЛИТЕРАТУРЫ

1. Friedl M.A., McIver D.K., Hodges J.C.F., Zhang X.Y., Muchoney D., Strahler A.H., Woodcock C.E., Gopal S., Schneider A., Cooper A., Baccini A., Gao F., Schaaf C. Global land cover mapping from MODIS: algorithms and early results // *Remote Sensing of Environment*. — 2002. — **83**, N 2. — P. 287–302.
2. Gallego J., Kussul N., Skakun S., Kravchenko O., Shelestov A., Kussul O. Efficiency assessment of using satellite data for crop area estimation in Ukraine // *International Journal of Applied Earth Observation and Geoinformation*. — 2014. — **29**. — P. 22–30.
3. Kussul N., Skakun S., Shelestov A., Kravchenko O., Gallego J.F., Kussul O. Crop area estimation in Ukraine using satellite data within the MARS project 2012 // *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 2012. — P. 3756–3759.
4. Cormen T.H., Leiserson C.E., Rivest R.L., Stein C. Introduction to algorithms. — 3rd edition. — Cambridge; Massachusetts: The MIT Press, 2009. — 1312 p.
5. Tuia D., Ratle F., Pacifici F., Kanevski M.F., Emery W.J. Active learning methods for remote sensing image classification // *IEEE Transactions on Geoscience and Remote Sensing*. — 2009. — **47**, N 7. — P. 2218–2232.
6. Shelestov A.Yu., Kravchenko A.N., Skakun S.V., Voloshin S.V., Kussul N.N. Geospatial information system for agricultural monitoring // *Cybernetics and Systems Analysis*. — 2013. — **49**, N 1. — P. 124–132.
7. Kussul N., Skakun S., Shelestov A., Kussul O., Yailymov B. Resilience aspects in the sensor Web infrastructure for natural disaster monitoring and risk assessment based on Earth observation data // *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. — 2014. — **7**, N 9 — P. 3826–3832.
8. Kussul N., Mandl D., Moe K., Mund J.P., Post J., Shelestov A., Skakun S., Szarzynski J., Van Langenhove G., Handy M. Interoperable infrastructure for flood monitoring: sensor Web, Grid and cloud // *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. — 2012. — **5**, N 6. — P. 1740–1745.
9. Kussul N., Shelestov A., Skakun S. Grid and sensor Web technologies for environmental monitoring // *Earth Science Informatics*. — 2009. — **2**, N 1–2. — P. 37–51.
10. Kussul N., Shelestov A., Skakun S. Flood monitoring from SAR data // *NATO Science for Peace and Security Series C: Environmental Security*. — 2011. — P. 19–29. — DOI: 10.1007/978-90-481-9618-0_3.
11. Skakun S.V., Basarab R.M. Reconstruction of missing data in time-series of optical satellite images using self-organizing Kohonen maps // *Journal of Automation and Information Sciences*. — 2014. — **46**, N 12. — P. 19–26.

12. Hansen M.C., Egorov A., Roy D.P., Potapov P., Ju J., Turubanova S., Kommareddy I., Loveland T.R. Continuous fields of land cover for the conterminous United States using Landsat data: first results from the Web-Enabled Landsat Data (WELD) project // *Remote Sensing Letters*. — 2011. — **2**, N 4. — P. 279–288.
13. Büttner G., Feranec J., Jaffrain G., Mari L., Maucha G., Soukup T. The CORINE land cover 2000 project // *EARSel eProceedings*. — 2004. — **3**, N 3. — P. 331–346.
14. Kussul N., Skakun S., Shelestov A., Kussul O. The use of satellite SAR imagery to crop classification in Ukraine within JECAM project // *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 2014. — P. 1497–1500.
15. Kussul N., Skakun S., Shelestov A., Kravchenko O., Kussul O. Crop classification in Ukraine using satellite optical and SAR images // *Models&Analyses*. — 2013. — **2**, N 2. — P. 118–128.
16. Gallego J., Kravchenko A.N., Kussul N.N., Skakun S.V., Shelestov A.Yu., Grypych Yu. A. Efficiency assessment of different approaches to crop classification based on satellite and ground observations // *Journal of Automation and Information Sciences*. — 2012. — **44**, N 5. — P. 67–80.
17. Chen Jun, Chen Jin, Liao A., Cao X., Chen L., Chen X., He C., Han G., Peng S., Lu M., Zhang W., Tong X., Mills J. Global land cover mapping at 30m resolution: A POK-based operational approach // *ISPRS Journal of Photogrammetry and Remote Sensing*. — 2015. — **103**. — P. 7–27..
18. Haykin S. *Neural networks and learning machines* (3rd edition). — Upper Saddle River (New Jersey): Prentice Hall, 2008. — 938 p.
19. Sim J., Wright C.C. The Kappa statistic in reliability studies: Use, interpretation, and sample size requirements // *Physical Therapy*. — 2005. — **85**, N 3. — P. 257–268.
20. LUCAS, 2009. Land use and cover area frame survey. — http://ec.europa.eu/eurostat/documents/205002/208938/LUCAS2009_C1-Instructions_Revised20130925.pdf/.
21. Olofsson P., Foody G.M., Herold M., Stehman S.V., Woodcock C.E., Wulder M.A. Good practices for estimating area and assessing accuracy of land change // *Remote Sensing of Environment*. — 2014. — **148**. — P. 42–57.
22. Foody G.M. Status of land cover classification accuracy assessment // *Remote Sensing of Environment*. — 2002. — **80**, N 1. — P. 185–201.
23. Kussul N., Skakun S., Shelestov A., Kussul O. The use of satellite SAR imagery to crop classification in Ukraine within JECAM project // *Geoscience and Remote Sensing Symposium (IGARSS) // IEEE International, Quebec City, QC, Canada, 2014*. — P. 1497–1500. — DOI: 10.1109/IGARSS.2014.6946721.
24. Lavreniuk V., Kussul N., Skakun S., Shelestov A., Yailymov B. Regional retrospective high resolution land cover for Ukraine: Methodology and results // *International Geoscience and Remote Sensing Symposium (IGARSS 2015)*, 2015.
25. Kussul N.N., Sokolov B.V., Zelyk Ya.I., Skakun S.V., Shelestov A.Yu. Disaster risk assessment based on heterogeneous geospatial information // *Journal of Automation and Information Sciences*. — 2010. — **42**, N 12. — P. 32–45.
26. Skakun S., Kussul N., Shelestov A., Kussul O. Flood hazard and flood risk assessment using a time series of satellite images: A case study in Namibia // *Risk Analysis*. — 2014. — **34**, N 8. — P. 1521–1537.

Поступила 09.04.2015