

Спутниковое картографирование растительного покрова России по данным спектрорадиометра MODIS

С. А. Барталев¹, В. А. Егоров¹, Д. В. Ершов², А. С. Исаев²,
Е. А. Лупян¹, Д. Е. Плотников¹, И. А. Уваров¹

¹ Институт космических исследований РАН,
117997 Москва, Профсоюзная 84/32
E-mail:smis@smis.iki.rssi.ru

² Центр по проблемам экологии и продуктивности лесов РАН,
117997 Москва, Профсоюзная 84/32
E-mail: ebch@cepl.rssi.ru

В работе представлен новый автоматизированный метод картографирования растительного покрова на основе данных спутниковых наблюдений спектрорадиометром MODIS. В основу метода положено использование предварительно очищенных от влияния облаков и других мешающих факторов многолетних временных серий данных спутниковых измерений спектрально-отражательных характеристик земного покрова с автоматическим распознаванием его типов на основе алгоритма локально-адаптивной классификации с обучением LAGMA. Созданная на основе разработанного метода новая карта, получившая название TerraNorte RLC, отражает пространственное распределение растительного покрова на территории России и имеет пространственное разрешение 250 м. Легенда карты содержит 22 тематических класса, из которых 18 соответствуют различным типам растительности. В сравнении с ранее созданными на основе спутниковых данных и содержательно близкими информационными продуктами новая карта демонстрирует качественно более высокий уровень картографической достоверности и детальности.

Ключевые слова: спутниковое картографирование растительного покрова, спектрорадиометр MODIS, алгоритм локально-адаптивной классификации LAGMA

Введение

Спутниковое картографирование растительности имеет широкое практическое использование и относится к числу интенсивно развивающихся научных направлений дистанционного зондирования Земли. При решении задач картографирования земного покрова на глобальном уровне, а также на уровне континентов или крупных стран, методам дистанционного зондирования в настоящее время не существует реальной альтернативы. При этом, несмотря на предпринимаемые с середины 1990-х годов и возрастающие в последние годы усилия, методические и технологические аспекты спутникового картографирования растительности больших территорий, на наш взгляд, все еще требуют существенного развития. Это объясняется концептуальной сложностью самой проблемы картографирования растительности при необходимости максимально полной автоматизации процессов обработки спутниковых данных с использованием алгоритмов, обеспечивающих высокую точность распознавания объектов земного покрова в условиях пространственной изменчивости их спектрально-отражательных характеристик.

Упомянутые обстоятельства, очевидно, могут служить объяснением того, что выполненные к настоящему времени крупные проекты по глобальному картографированию земного покрова (в англоязычных публикациях принят термин – land cover) рассматривают относительно небольшое число тематических классов легенд, а независимо выполнен-

ная валидация созданных карт свидетельствует об их относительно низкой точности. Так широко используемая при глобальном картографировании земного покрова легенда IGBP (International Geosphere-Biosphere Programme) содержит 17 тематических классов, тринадцать из которых характеризуют растительный покров (Belward, 1996). Использование указанной легенды, в частности, было положено в основу глобальных карт земного покрова, созданных на основе данных радиометра NOAA-AVHRR с пространственным разрешением около 1 км в рамках проектов IGBP-DIS (Loveland, 1999) и Университета штата Мэриленд США (Hansen, 2000). Экспертная валидация карты IGBP-DIS с использованием изображений Landsat-TM показала, что для различных классов точность распознавания варьирует в диапазоне 40-100% а в среднем составляет 59,4% (Scepan, 1999).

Несколько более высокая точность распознавания типов земного покрова достигнута при создании глобальной карты GLC2000 (Global Land Cover 2000) по спутниковым данным SPOT-VEGETATION с пространственным разрешением около 1 км (Bartholome and Belward, 2005). При этом легенда карты включала 22 класса, а средняя точность распознавания типов земного покрова составила 68,6% (Mayaux, 2006).

Другие, созданные на основе данных Terra-MODIS (Friedl, 2002) и Envisat-MERIS (Arino, 2008), глобальные карты земного покрова характеризуются тематической точностью, не превышающей в среднем величину 70%.

Создаваемые на основе спутниковых данных региональные карты земного покрова, как правило, отличаются несколько более высокой тематической точностью и детальностью легенды. В рамках проектов GLC2000 (Bartalev, 2003) и NELDA (Sulla-Menashe, 2011) созданы региональные карты земного покрова Северной Евразии, имеющие соответственно пространственное разрешение около 1 км и 500 м.

Как упоминалось выше, решение задач картографирования больших территорий требует учета фактора пространственной изменчивости спектрально-отражательных характеристик земного покрова, влияние которого, как правило, возрастает с увеличением географического охвата. В упомянутых выше примерах глобального и регионального спутникового картографирования учет данного фактора обеспечивался на основе различных подходов. Одним из широко используемых методических приемов, призванных снизить влияние фактора пространственной изменчивости спектрально-отражательных характеристик одноименных типов земного покрова, является стратификация территории с классификацией спутниковых данных в границах отдельных страт. В предельно простом случае, как в проекте IGBP-DIS, в качестве страт выступают отдельные континенты (Belward, 1996), а по мере усложнения подходов выделяются регионы, однородные по совокупности критериев, учитывающих меняющихся физико-географические, геоботанические и некоторые другие природные условия (Arino, 2008). Другой, используемый в ряде проектов по картографированию больших территорий, методический прием по снижению влияния географической изменчивости спектрально-отражательных характеристик одноименных типов земного покрова состоит в гиперклUSTERизации (Cihlar, 2000). Суть гиперклUSTERизации заключается в дробном разбиении пространства признаков распознавания для выделения однородных групп пикселов (клusterов), число которых в десятки раз превышает количество тематических классов легенды создаваемой карты.

Несмотря на то, что использование вышеуказанных методических приемов в ряде случаев является полезным и практически оправданным, они не способны, на наш взгляд, обеспечить универсальное и полное решение проблемы географической изменчивости спектрально-отражательных характеристик земного покрова. Более того, по нашему мне-

нию, именно отсутствие в используемых методах распознавания механизмов адекватного учета указанного фактора является фундаментальным ограничением дальнейшего качественного роста уровня достоверности при спутниковом картографировании земного покрова больших территорий.

Одним из принципиальных отличий представленного в настоящей работе нового метода спутникового картографирования растительности больших территорий является использование алгоритма локально-адаптивной классификации LAGMA (Locally Adaptive Global Mapping Algorithm), обладающего внутренне присущим ему механизмом описания и учета пространственных вариаций спектрально-отражательных характеристик и других признаков распознавания типов земного покрова. Разработанный метод картографирования позволил получить на основе данных спектрорадиометра MODIS новую карту растительного покрова России с пространственным разрешением 250 м и легендой содержащей 22 тематических класса, из которых 18 соответствуют различным типам растительности.

Предварительная обработка спутниковых данных и формирование набора признаков распознавания

В основу разработанного метода картографирования растительного покрова положено использование спутниковых данных, получаемых спектрорадиометром MODIS на борту спутника Terra и распространяемых Геологической службой США (<http://lpdaac.usgs.gov/main.asp>). Сформированный в ИКИ РАН архив данных MODIS содержит многолетний (с 2000 года по настоящее время) и непрерывно пополняемый набор стандартных продуктов данных MOD09 (Vermote and Vermeulen, 1999). Метод предполагает использование данных ежедневных измерений коэффициента спектральной яркости (КСЯ) земной поверхности в красном (620-670 нм) и ближнем ИК (841-876 нм) каналах с пространственным разрешением 250 метров. В качестве дополнительной информации используются измерения КСЯ в голубом (459-479 нм) и среднем ИК (1628-1652 нм) диапазонах с пространственным разрешением 500 м, а также угловые характеристики Солнца и прибора в момент наблюдения.

К числу ключевых преимуществ спектрорадиометра MODIS при решении задач картографирования земного покрова можно отнести возможность формирования и использования временных рядов спутниковых данных. В частности, это открывает широкие возможности разработки информативных признаков распознавания типов растительного покрова, основанных на особенностях их сезонной динамики спектрально-отражательных характеристик (Bartalev et al., 2003). Было также показано, что полученные с использованием многолетних рядов спутниковых данных признаки распознавания позволяют достоверно выделять занятые сельскохозяйственной растительностью земли (Плотников и др., 2010). Поэтому одним из этапов разработанного метода является предварительная обработка многолетней временной серии данных MODIS с целью снижения влияния мешающих факторов, таких как облака и образуемые ими тени, сезонный снежный покров и аппаратные шумы. В настоящей работе для создания карты растительного покрова России были использованы данные MODIS, полученные в период 2005-2010 годов.

Предварительная обработка данных MODIS, призванная обеспечить максимально возможное снижение влияния мешающих факторов, предусматривает выполнение следующих последовательных этапов:

- исключение пикселов с превышающими некоторый порог значениями угловых характеристик освещения и наблюдения;
- исключение пикселов, испытывающих влияние снежного и облачного покрова;
- исключение пикселов, соответствующих участкам теней от облаков;
- статистическая фильтрация временных рядов данных;
- построение свободных от влияния мешающих факторов сезонных композитных изображений;
- построение и сглаживание многолетних временных рядов значений перпендикулярного вегетационного индекса PVI.

Для выбора наблюдений, пригодных для дальнейшей обработки по геометрическим условиям освещения и наблюдения используется совокупность пороговых критериев $VZA > 40^\circ$ и $SZA > 80^\circ$, где VZA – зенитный угол наблюдения, SZA – зенитный угол Солнца.

Детектирование участков с наличием облачного и снежного покрова выполняется с использованием данных измерений КСЯ в голубом $R3$ (459-479 нм) и среднем ИК $R6$ (1628-1652 нм) каналах MODIS. В основе алгоритма детектирования лежит использование нормализованного разностного индекса снега $NDSI$, определяемого по формуле (1), и априорных знаний об отражательных свойствах поверхности:

$$NDSI = \frac{R3 - R6}{R3 + R6} \quad (1)$$

Принимая, что каждый пиксель относится к одному из четырех классов (облачность, полупрозрачная облачность, снег, свободная от влияния облачности и снега «чистая поверхность»), разобьем пространство признаков $R3$ и $NDSI$ (рис.1) следующим образом:

«снег», если $R3 > 0,05$ и $NDSI > 0,1$;

«облачность», если $R3 > 0,05$ и $-0,2 < NDSI < 0,1$;

«полупрозрачная облачность», если $R3 > 0,05$ и $-0,35 < NDSI < -0,2$;

«чистая поверхность», во всех остальных случаях.

Пиксели, окружающие классы «облачности» и «полупрозрачной облачности», также относятся к этим классам, если их значения $R3$ не меньше значений крайних пикселов прилежащих к классу.



Рис.1. Пороговое разделение пикселов «чистой поверхности», облачности и снежного покрова в двумерном пространстве $R3$ - $NDSI$

Используя предполагаемое значение максимальной высоты облаков, на следующем шаге рассчитывается местоположение соответствующих им теней с использованием данных об углах наблюдения и положения Солнца (рис. 2).

Поскольку точные данные о высоте облаков отсутствуют, в качестве максимально возможной величины было выбрано значение $h = 12$ км, а алгоритм включил в себя построение зоны заведомо содержащей подлежащие выделению пиксели. Если ввести прямоугольную декартову систему координат с началом в данном соответствующем облаку пикселе с осью Ox направленной на север и осью Oy направленной на восток, тогда радиус-вектор смещения тени на изображении относительно облака высотой H задается в этой системе следующими координатами:

$$\begin{aligned} x &= H(\cos(\psi)\operatorname{tg}(\theta) - \cos(\beta)\operatorname{tg}(\delta)) \\ y &= H(\sin(\psi)\operatorname{tg}(\theta) - \sin(\beta)\operatorname{tg}(\delta)) \end{aligned} \quad (2)$$

где ψ – азимутальный угол наблюдения, θ – зенитный угол наблюдения, β – азимутальный угол Солнца, δ – зенитный угол Солнца.

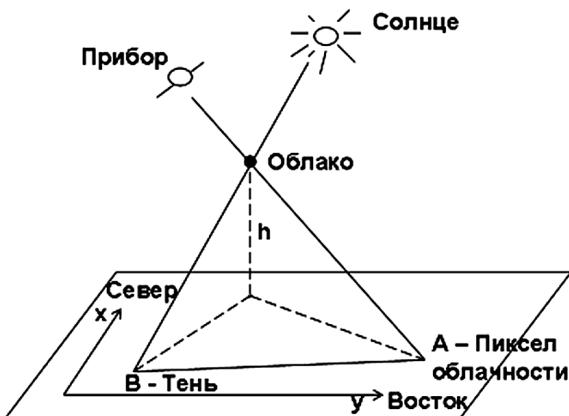


Рис 2. Геометрическое расположение линии тени от облака на наблюдаемой спутниковым прибором поверхности Земли

Как правило, геометрическая линия тени, описываемая формулой (2), захватывает не только теневые пиксели, но и чистую поверхность, что обуславливает необходимость дополнительного анализа пикселов, отнесенных к классу геометрической тени. Так, при рассмотрении линии тени можно определить реальную границу затененных участков по скачкообразному росту (рис.3) отражательной способности $R2$ в ближнем ИК канале (841-876 нм) MODIS.

Этап статистической фильтрации временных рядов направлен на выявление неверно выделенных теней, возникающих за счет имеющего место ошибочного отнесения участков снега с недостаточно высоким значением индекса NDSI к классу облачности. Ложной тенью считается пикセル, не попадавший ни разу в класс «чистая поверхность» в течение двадцати дней (десять дней до даты начала интервала и десять дней после) при условии выполнения следующего условия для пикселов геометрической тени:

$$R1(\Theta^*, t) > M_{R1}(\Theta^*, t) + \sigma_{R1}(\Theta^*, t) \quad (3)$$

где $\sigma_{R1}(\Theta^*, t)$ – стандартное отклонение от среднего значения $M_{R1}(\Theta^*, t)$.

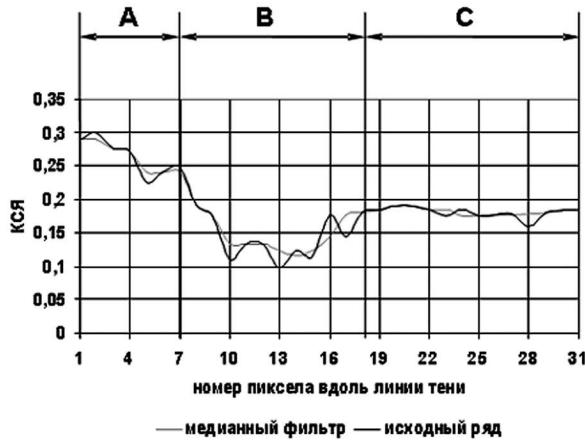


Рис 3. Профиль значений КСЯ в ближнем ИК канале MODIS по линии тени от облака: А – зона остаточной облачности, Б – область тени, В – область избыточного выделения тени

Фильтрация остаточного влияния мешающих факторов и детектирование сбойных пикселов осуществляется на основе анализа временных рядов данных MODIS за указанный выше двадцатидневный интервал времени. Отделение «зашумленных» пикселей происходит по критерию превышения удвоенного стандартного отклонения $\sigma_{R6}(\Theta^*, t)$ от среднего значения $M_{R6}(\Theta^*, t)$:

$$|R6(\Theta^*, t) - M_{R6}(\Theta^*, t)| \geq 2 \cdot \sigma_{R6}(\Theta^*, t) \quad (4)$$

В результате выполнения перечисленных выше шагов формируется набор «масок» с указанием статуса каждого пикселя, используемых для последующего осреднения очищенных данных за заданные интервалы времени.

Предварительная обработка ежедневных данных MODIS позволяет в значительной мере скомпенсировать влияние мешающих факторов и дает возможность построения композитных изображений за различные промежутки времени с редуцированным влиянием облаков, сезонного снежного покрова и аппаратных шумов. В работе были сформированы двухмесячные композитные изображения чистой поверхности за весенний, летний и осенний период 2010 года, включающие значения КСЯ в каналах R1, R2 и R6. Также по данным MODIS за период с 1 ноября 2009 года по 31 марта 2010 года было сформировано зимнее композитное изображение, полученное путем осреднения значения КСЯ в каналах R1 и R2 для пикселов с выявлением присутствием снежного покрова. Совокупность описанных выше четырех композитных изображений позволяет достаточно хорошо охарактеризовать сезонную динамику спектрально-отражательных характеристик большинства типов земного покрова и используется в дальнейшей классификации в качестве основных признаков их распознавания.

Вместе с тем, как уже было отмечено выше, для выявления сельскохозяйственных земель целесообразно использование признаков распознавания, полученных на основе многолетних временных рядов данных MODIS. Решение этой задачи достигается с использованием еженедельных композитных изображений значений КСЯ и полученных по ним значений перпендикулярного вегетационного индекса PVI. Будучи почвенно-адаптивным индексом PVI в значительной мере независим от яркости почвенного по-

кровя и тесно коррелирует с объемом зеленой биомассы и концентрацией хлорофилла в растениях. Значение PVI рассчитывается в двумерном пространстве значений КСЯ красного и ближнего ИК диапазонов как евклидово расстояние от данной точки до линии почв. С использованием уравнения для линии почв (Плотников и др., 2010) PVI вычисляется по формуле

$$PVI(R_1 R_2) = -0,74R_1 + 0,67R_2 - 0,034 \quad (5)$$

где R_1 и R_2 соответствуют измерениям КСЯ в красном и ближнем ИК каналах. На основе рассчитанных значений PVI формируются временные серии данных с последующим сглаживанием временных рядов на основе скользящих статистических фильтров для снижения влияния случайного шума и заполнения пропусков данных.

Временной ряд еженедельных значений PVI за период 2005-2010 годов составил основу для формирования набора специализированных признаков распознавания пахотных земель, основе из которых включают в себя:

- индекс кратчайшего сезона вегетации $L_{1/2}$, рассчитываемый как минимальный для ряда лет период, в котором значения PVI превышают порог, определяемый половиной максимального значения индекса в текущем году;
- индекс весеннего развития растительности MSI , определяемого, как минимальная многолетняя сумма значений PVI в границах временного окна, охватывающего период с 1 января по 15 июня каждого года наблюдений;
- индекс сезонного снижения фитомассы $NSMI$, определяемого как нормированная сумма многолетних сезонных минимумов PVI в период 15 мая – 15 сентября каждого года наблюдений.

Детальное описание и результаты оценки информативности упомянутых выше признаков распознавания сельскохозяйственных земель приведены в ряде ранее опубликованных работ (Плотников и др., 2010; Барталев и др., 2011).

Метод распознавания типов растительного покрова по спутниковым данным

Распознавание типов растительного покрова осуществляется с использованием совокупности, полученных по данным MODIS и описанных выше признаков, на основе алгоритма локально-адаптивной классификации с обучением LAGMA (Уваров и Барталев, 2010).

Использование методов обучаемой классификации предполагают построение статистических описаний (сигнатур) классов в пространстве признаков на основе репрезентативной выборки характерных эталонов. Статистический подход к классификации в данной работе исходит из предположения нормального распределения значений признаков, а сигнатура каждого k -го класса включает в себя параметры вектора их средних значений U_k и ковариационной матрицы Σ_k .

В основу алгоритма LAGMA положен подход, предполагающий на первом этапе формирование для рассматриваемой территории пространственного распределения сигналов на основе репрезентативной совокупности эталонных объектов (обучающей выборки) с известной принадлежностью к одному из классов заданного множества. Пространственное

распределение локализованных сигнатур описывается их значениями в узлах $G(p; q)$ регулярной прямоугольной сети с шагом d , где p и q – порядковые номера узлов по осям x и y соответственно. Обучение классификатора, включающее в себя два описанных ниже логических этапа, направлено на оценку в узлах $G(p; q)$ параметров локализованных сигнатур $U_k(p; q)$ и $\sum_k(p; q)$ для каждого k -го класса.

Первоначально для каждого узла $G(p; q)$ на основе расположенных в границах соответствующей клетки эталонных пикселов вычисляются величины:

$S_k^i(p; q)$ – сумма значений i -го признака k -го класса;

$C_k^{i,j}(p; q)$ – сумма произведений значений i -го и j -го признаков k -го класса;

$N_k(p; q)$ – количество эталонных пикселов k -го класса.

Указанные величины используются для оценки элементов $Cov_k^{i,j}(p; q)$ ковариационной матрицы $\Sigma_k(p; q)$ на основе следующего выражения:

$$Cov_k^{i,j}(p; q) = \frac{C_k^{i,j}(p; q)}{N_k(p; q)} - \frac{S_k^i(p; q)}{N_k(p; q)} \frac{S_k^j(p; q)}{N_k(p; q)} \quad (6)$$

Оценка элементов $Cov_k^{i,j}(p; q)$ ковариационной матрицы и средних значений признаков на основе $S_k^i(p; q)$ и $N_k(p; q)$ позволяет получить параметры сигнатур $U_k(p; q)$ и $\sum_k(p; q)$.

Обучающая выборка эталонных пикселов, как правило, имеет пространственно неравномерное распределение. При этом в случае отсутствия эталонных пикселов k -го класса в окрестности узла $G(p_0; q_0)$ вычисление параметров $U_k(p_0; q_0)$ и $\sum_k(p_0; q_0)$ оказывается невозможным. Для учета этого фактора метод предусматривает задание порога репрезентативности T , характеризующего минимально допустимое количество эталонных пикселов для оценки локальных сигнатур классов. Это приводит к появлению узлов не обеспеченных значениями параметров сигнатур некоторых классов и, как следствие, к необходимости проведения второго этапа обучения классификатора.

На втором этапе для каждого не преодолевшего порог репрезентативности ($N_k(p_0; q_0) < T$) узла $G(p_0; q_0)$ проводится обработка данных соседних клеток. Количество используемых соседних клеток зависит от величины T , числа эталонных пикселов в клетке $N_k(p_0; q_0)$ и соседних клетках $N_k(p_0 + \Delta p; q_0 + \Delta q)$. Кроме того, методом предусмотрено задание параметров L_{min} и L_{max} , ограничивающих число используемых соседних клеток снизу и сверху соответственно. Число используемых соседних клеток итеративно увеличивается, начиная с L_{min} до величины, соответствующей достижению порога репрезентативности T . Если порог T не был преодолен при достижении числа ближайших клеток значения L_{max} , то сингнтура узла $G(p_0; q_0)$ для класса k считается несуществующей.

Расширение анализируемой для оценки параметров локальной сингнтуры класса окрестности осуществляется дискретно путем последовательного включения соседних клеток, находящихся на одинаковом удалении от узла $G(p_0; q_0)$, и обобщения полученных на первом этапе обучения величин $S_k^i(p_0 + \Delta p; q_0 + \Delta q)$, $C_k^{i,j}(p_0 + \Delta p; q_0 + \Delta q)$ и $N_k(p_0 + \Delta p; q_0 + \Delta q)$. При этом новые характеристики узла $S_k^{i*}(p_0; q_0)$, $C_k^{i,j*}(p_0; q_0)$ и $N_k^{*}(p_0; q_0)$ вычисляются как суммы соответствующих величин, полученных для соседних узлов на первом этапе обучения.

По результатам второго этапа обучения, для класса k в узлах, для которых справедливо выражение $N_k^{*}(p_0; q_0) \geq T$, определяются с использованием выражения аналогичного (6) параметры сингнтур $U_k^{*}(p_0; q_0)$ и $\sum_k^{*}(p_0; q_0)$ для последующей обучаемой классификации.

В соответствии с решающим правилом максимума правдоподобия, пиксел $P(x;y)$ относится к множеству ω_l пикселов класса l в том случае, если для всех $k=1, 2\dots m$ выполняется условие:

$$p(\omega_l)p(P(x;y) | \omega_l) \geq p(\omega_k)p(P(x;y) | \omega_k) \quad (7)$$

где: $p(\omega_l)$ и $p(\omega_k)$ – априорные вероятности классов l и k ;

$p(P(x;y) | \omega_l)$ и $p(P(x;y) | \omega_k)$ – плотности вероятности отнесения пикселя $P(x;y)$ к множеству пикселов класса l и множеству пикселов класса k .

В свою очередь, плотность вероятности определяется по формуле:

$$p(P(x;y) | \omega_k) = \frac{\exp\left(-\frac{1}{2}(B(x;y) - U_k^*(p; q))^T \Sigma_k^*(p; q)^{-1} (B(x;y) - U_k^*(p; q))\right)}{(2\pi)^{\frac{n}{2}} |\Sigma_k^*(p, q)|^{\frac{1}{2}}}, \quad (8)$$

где: $B(x;y)$ – вектор признаков пикселя $P(x;y)$; n – число признаков.

При классификации используются параметры $U_k^*(p; q)$ и $\Sigma_k^*(p; q)$ локализованных сигнатур, вычисленных на втором этапе обучения. Для классификации пикселя $P(x;y)$ используются сигнатуры ближайшего узла $G(p; q)$, порядковые номера которого в строках и столбцах регулярной сетки с шагом d определяются по формулам $p=x/d$ и $q=y/d$.

Наряду с сигнатурами, характеризующими локализованные значения признаков, при классификации используются априорные вероятности, полученные на основе данных об ареалах распространения различных типов земного покрова в пределах рассматриваемой территории. В решающем правиле (7) априорная вероятность класса используется в качестве коэффициента, определяемого в виде дробной величины в диапазоне от 0 до 1 для каждого класса и каждого пикселя территории. Априорные вероятности могут быть получены в результате обобщения обучающей выборки таким образом, что в окрестности эталонных пикселов заданного класса ее значения максимальны и снижаются по эмпирически подобранным правилам по мере удаления.

Разработка легенды карты растительного покрова России

Рассматривая методические вопросы спутникового картографирования растительного покрова нельзя не отметить важность наличия формализованных критериев определения классов легенды, основанных на общих для создаваемых карт принципах и не допускающих неоднозначностей содержательной интерпретации. Это позволяет обеспечить принципиальную возможность сопоставления полученных в разное время разнородных карт и оценки на их основе динамики растительного покрова. Принципиально новым шагом к унификации подходов к тематическому описанию классов явилась разработанная ФАО ООН система классификации земного покрова LCCS (Land Cover Classification System) (Di Gregorio, 2005), ставшая «де-факто» стандартом и эффективным инструментом формирования легенд глобальных спутниковых карт лесов.

Согласно LCCS при разработке легенды карты учитывались такие признаки растительности, как ее жизненные формы (древесная, кустарниковая, травяная, мохово-

лишайниковая), типы вегетативных органов (хвойные, лиственные) и типы фенологической динамики (вечнозеленые, листопадные).

Разработанная легенда созданной карты растительного покрова России, получившей название TerraNorte RLC, включает в себя 22 тематических класса, образующих шесть различных групп земного покрова, а именно:

1) Леса

– *Темнохвойные вечнозеленые насаждения*, в пологе которых не менее 80% площади крон составляют теневыносливые виды хвойных деревьев, включая ель, пихту и сибирскую сосну (кедр);

– *Светлохвойные вечнозеленые насаждения*, в пологе которых не менее 80% площади крон составляют деревья сосны обыкновенной;

– *Лиственные насаждения*, в пологе которых не менее 80% площади занимают кроны березы и осины, а также широколиственных пород, включая дуб, липу, ясень, клен, вяз и некоторые другие виды;

– *Смешанные насаждения с преобладанием хвойных пород*, в которых кроны хвойных деревьев занимают от 60 до 80%, а лиственных от 20% до 40% площади полога;

– *Смешанные насаждения*, в которых площади крон хвойных и лиственных пород деревьев представлены примерно в равных пропорциях (40-60 %) в пологе;

– *Смешанные насаждения с преобладанием лиственных пород*, в которых кроны лиственных пород деревьев занимают от 60 до 80%, а хвойных от 20% до 40% площади полога;

– *Хвойные листопадные (лиственничные) насаждения*, в пологе насаждений которых кроны деревьев лиственницы занимают более 80% площади;

– *Редины хвойные листопадные (лиственничные)*, представляющие собой участки, занятые отдельно стоящими деревьями или разреженными насаждениями лиственницы с проективным покрытием крон менее 20%;

2) Травяно-кустарниковая растительность

– *Луга* – травяная растительность с продолжительностью вегетационного сезона более 5 месяцев, видовой состав которой характеризуется господством многолетних трав, главным образом злаков и осоковых, в условиях достаточного увлажнения. Площадь проекции крон деревьев и кустарников на земную поверхность составляет менее 20%;

– *Степи* – травяной покров образован преимущественно засухоустойчивыми многолетними дерновинными злаками (ковыль, типчак, полынь, житняк и др.). Встречается большое разнообразие видов степных кустарников и полукустарников, а также короткоцветущих эфемероидов и эфемеров;

– *Хвойные вечнозеленые кустарники* – кустарниковые заросли или низкоствольные леса из кедрового стланика;

3) Тундра

– *Кустарниковая тундра* – сухая тундра с редкой фрагментарной растительностью, среди которой доминирует виды альпоарктических кустарниковых сообществ высотой менее 15 см. Распространены также мохово-лишайниковый покров и разнотравье;

– *Травянистая тундра* представлена главным образом различными видами трав и мхов, произрастающими на сырых почвах и образующими сплошной растительный покров. Часто встречаются кустарнички высотой до 40 см;

– *Кустарниковая тундра* с доминированием кустарников (карликовая береза и различные виды ивы) высотой более 40 см, иногда с примесью можжевельника, ольхи или кедрового стланика;

4) Водно-болотные комплексы

– *Болота* – территории, характеризующиеся избыточным увлажнением с преобладанием растительного покрова изо мхов, лишайников, тростника, осоки и некоторых других видов. Часто встречаются участки с наличием редкого (< 20%) древесного полога;

– *Прибрежная растительность* – гидрофильная травяная и древесно-кустарниковая растительность по берегам водоемов, часто периодически затопляемая;

5) Другие типы растительного покрова

– *Свежие гари* – лесные гари, произошедшие в течение последних пяти лет. Могут содержать погибшие деревья и некоторое присутствие вторичной растительности;

– *Пахотные земли* – регулярно обрабатываемые в течение последних пяти лет земли сельскохозяйственного назначения;

6) Не покрытые растительностью земли

– Вечные снега и льды – земли, покрытые снегами и льдами в течение всего года;

– Открытые грунты и выходы горных пород – земли, суммарное проективное покрытие которых растительностью всех видов не превышает 20%;

– Урбанизированные территории – населенные пункты, дороги и другие образования антропогенного происхождения;

– Водные объекты – речные и озерные внутренние водоемы, а также прибрежные участки открытой воды.

Формирование обучающей выборки и классификация типов земного покрова

Метод локально-адаптивной классификации с обучением LAGMA предусматривает использование репрезентативной выборки опорных данных, обеспечивающих оценку признаков распознаваемых классов земного покрова на всей картографируемой территории. В качестве возможных источников данных для формирования обучающей выборки могут использоваться, в частности, существующие тематические карты. Однако при использовании существующих карт для этой цели необходимо учитывать, что получаемая на их основе обучающая выборка, как правило, требует предварительной фильтрации в силу таких причин, как:

- возможные ошибки картографирования;
- изменения земного покрова, произошедшие с момента создания опорной карты;
- различия величин пространственного разрешения опорной карты и используемых спутниковых данных.

В качестве опорной карты для формирования обучающей выборки в настоящей работе использовалась карта наземных экосистем Северной Евразии, созданная на основе, полученных в 2000 году, спутниковых данных SPOT-Vegetation, имеющих пространственное разрешение около 1 км (Bartalev, 2003). При формировании обучающей выборки был использован итерационный подход, предусматривающий ее коррекцию по результатам многократного использования процедуры классификации и экспертной оценки получаемых результатов. При этом, формирование начальной обучающей выборки предусматривало несколько этапов фильтрации пикселов опорной карты с целью исключения макроскопических ошибок.

На первом этапе для фильтрации обучающей выборки использовался алгоритм гистограммной фильтрации. Данный алгоритм предусматривает исключение из обучающей выборки пикселов некоторого класса, по своим спектрально-отражательным характеристикам имеющих большую степень сходства с другими классами. Применение гистограммной фильтрации оправдано при условии, что большинство пикселов опорой карты не претерпело изменений и не содержит ошибок распознавания, а ошибочно распознанные пиксели в действительности принадлежат к одному из классов ближайшего окружения. В основе алгоритма лежит построение на основе обучающей выборки многомерных гистограмм значений признаков для множества, представленных в скользящем окне (20x20 км) классов. Для обеспечения сопоставимости гистограмм они нормализуются на общее количество пикселов заданного класса в пределах скользящего окна. Из значений гистограммы одного класса вычитаются значения гистограмм всех остальных классов в пределах скользящего окна, а отрицательные значения в модифицированных гистограммах исключаются. Области пересечения гистограмм классов в пространстве признаков в результате такого преобразования разделяются на соответствующие отдельным классам части.

Одновременно, на начальном этапе фильтрации обучающей выборки к пикселям опорной карты применялась следующая совокупность критериев:

1. Пиксел исключается из обучающей выборки, если хотя бы один из его ближайших соседей принадлежит к другому классу. Целью применения условия является отбор пикселов, расположенных внутри областей одного типа земного покрова исходя из предположения, что смешанные пиксели с большей вероятностью расположены на их границах;
2. Пиксели различных классов леса исключаются из опорной выборки, если его яркость на композитном изображении зимнего периода превышает эмпирически установленную пороговую величину;
3. Пиксел классов луга или открытая почва исключается, если соответствующее ему значение индекса NDVI выходит за границы эмпирически установленного диапазона.

Созданная с использованием разработанного метода новая карта растительного покрова России TerraNorte RLC представлена на рисунке 4, а полученные на ее основе оценки площади различных типов земного покрова приводятся в таблице 1. Также в таблице представлен объем сформированной опорной выборки для различных типов растительности.

Качественное сравнение полученной карты TerraNorte RLC с ранее разработанными содержательно близкими глобальными и региональными информационными продуктами позволяет сделать заключение о существенных преимуществах новой карты по уровню достоверности представления данных о пространственном распределении типов растительного покрова на территории России. Сравнительный экспертный анализ новой карты TerraNorte RLC проводился в сравнении со следующими информационными продуктами:

- Карта наземных экосистем Северной Евразии, полученная в рамках проекта GLC2000 по данным SPOT-Vegetation, с пространственным разрешением 1 км (Bartalev, 2003);
- Глобальная карта земного покрова, полученная в рамках проекта Globcover по данным Envisat-MERIS с пространственным разрешением 300м (Arino, 2008);
- Карта земного покрова Северной Евразии, полученная в рамках проекта NELDA по данным MODIS с пространственным разрешением 500 м (Sulla-Menashe, 2011).

Выборочные фрагменты включенных в сравнение карт растительного покрова представлены на рисунке 5.

Таблица 1. Характеристика опорной выборки и оценка площади различных типов земного покрова

| Тип растительности | Опорная выборка | | Результат картографирования | |
|---|---------------------------|---|---------------------------------|-----------------|
| | Число пикселей (тыс. шт.) | % площади выборки от площади классов на опорной карте | Площадь (тыс. км ²) | % общей площади |
| Леса | | | | |
| Темнохвойные вечнозеленые | 4741,0 | 29,8 | 840,8 | 4,9 |
| Светлохвойные вечнозеленые | 2767,5 | 15,0 | 978,1 | 5,7 |
| Лиственные | 6465,0 | 32,4 | 1056,1 | 6,2 |
| Смешанные с преобладанием хвойных | 349,7 | 3,8 | 490,9 | 2,9 |
| Смешанные | 126,7 | 1,7 | 391,6 | 2,3 |
| Смешанные с преобладанием хвойных | 576,6 | 7,2 | 421,2 | 2,5 |
| Хвойные листопадные | 25807,2 | 45,1 | 3030,0 | 17,7 |
| Редины хвойные листопадные | 1690,0 | 14,7 | 607,6 | 3,6 |
| Общая площадь лесов | 42523,6 | 28,8 | 7816,3 | 45,8 |
| Травяно-кустарниковая растительность | | | | |
| Луга | 9209,8 | 27,2 | 1793,2 | 10,5 |
| Степи | 3009,5 | 54,5 | 291,9 | 1,7 |
| Хвойные вечнозеленые кустарники | 1259,0 | 12,7 | 522,9 | 3,1 |
| Тундра | | | | |
| Кустарничковая | 1364,8 | 11,0 | 654,2 | 3,8 |
| Травянистая | 5300,6 | 27,0 | 1037,3 | 6,1 |
| Кустарниковая | 3472,6 | 20,2 | 908,0 | 5,3 |
| Водно-болотные комплексы | | | | |
| Болота | 7028,4 | 24,2 | 1533,5 | 9,0 |
| Прибрежная растительность | 423,4 | 25,3 | 88,5 | 0,5 |
| Не покрытые растительностью земли | | | | |
| Вечные снега и льды | - | - | 73,4 | 0,4 |
| Грунты и выходы горных пород | - | - | 1142,5 | 6,7 |
| Урбанизированные территории | - | - | 17,3 | 0,1 |
| Водные объекты | - | - | 409,1 | 2,4 |
| Другие типы растительного покрова | | | | |
| Свежие гари | 597,4 | 45,4 | 69,6 | 0,4 |
| Пахотные земли | - | - | 719,5 | 4,2 |
| Общая площадь | 80397,0 | 24,9 | 17077,3 | 100,0 |

Заключение

Представленный в настоящей работе новый метод картографирования растительного покрова на основе спутниковых данных дистанционного зондирования Земли принципиально отличается от ранее опубликованных в научной литературе подходов. Основное

отличие предложенного метода состоит в генетически присущем ему механизме учета пространственной изменчивости спектрально-отражательных характеристик (или любых других признаков распознавания) одноименных типов земного покрова за счет использования алгоритма локально-адаптивной классификации спутниковых изображений. Это обеспечивает возможность унифицированного картографирования растительного покрова больших территорий без необходимости предварительной стратификации. Указанная особенность предложенного метода открывает потенциальную возможность его эффективного использования для создания карт растительного покрова любого, вплоть до глобального, географического охвата.

Использование предложенного метода позволило создать на основе данных спутникового спектрорадиометра MODIS новую карту растительного покрова России TerraNorte RLC. Будучи преимущественно основанной на данных спутниковых наблюдений 2010 года с пространственным разрешением 250 м созданная карта в настоящее время не имеет аналогов и является наиболее современным, объективным и детальным источником информации о пространственном распределении растительного покрова по территории России. Легенда карты включает в себя 22 тематических класса, 18 из которых характеризуют различные типы растительности, выделенные с учетом их жизненных форм, типов вегетативных органов и фенологической динамики.

Проведенный экспертный анализ позволяет на качественном уровне сделать заключение о существенно более высоком уровне тематической достоверности новой карты растительного покрова России по сравнению содержательно близкими глобальными и региональными информационными продуктами, созданными ранее на основе спутниковых данных. Дальнейшие исследования должны быть направлены на проведение валидации разработанной карты с использованием репрезентативных опорных данных для получения количественных оценок ее достоверности.

Разработанный метод и созданная карта TerraNorte RLC составляют основу дальнейшего развития методологии спутникового картографирования растительного покрова. В частности, указанные разработки позволяют создать автоматическую технологию динамического картографирования растительного покрова по данным MODIS и сформировать на ее основе временную серию ежегодных карт за период с 2000 года по настоящее время.

Ближайшие перспективы развития предложенной нами методологии спутникового картографирования растительного покрова, на наш взгляд, связаны со следующими основными приоритетами:

- создание автоматической технологии динамического (ежегодного) картографирования растительного покрова больших территорий;
- расширение географического охвата картографируемой территории с уровня России на континентальный (Северная Евразия), циркумполярный (boreальный пояс планеты) и глобальный уровни;
- повышение тематической детальности (расширение легенды) спутниковых карт растительного покрова за счет более полного использования возможностей временных серий спутниковых данных;
- повышение пространственной детальности карт растительного покрова за счет использования открытых источников спутниковых данных высокого пространственного разрешения (включая Landsat-TM/ETM+ и Sentinel-2).



Рис 4. Карта растительного покрова России TerraNorte RLC, полученная по данным MODIS

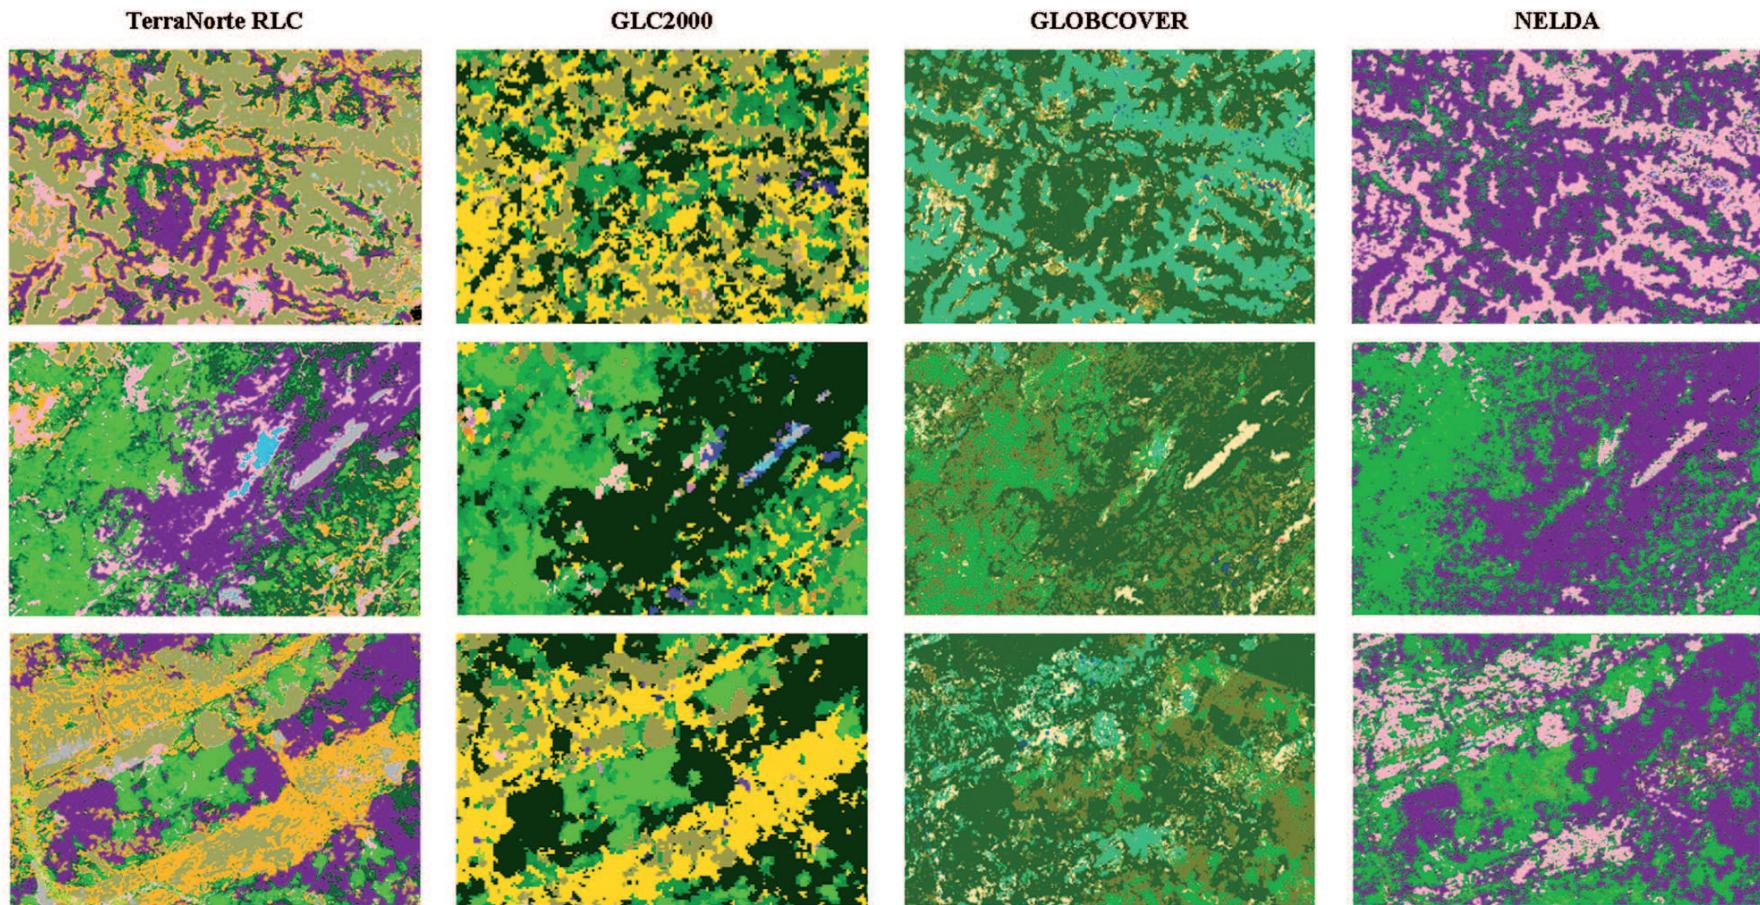


Рис 5. Выборочные фрагменты включенных в сравнение различных карт растительного покрова

Литература

1. Барталев С.А., Егоров В.А., Лупян Е.А., Плотников Д.Е., Уваров И.А. Распознавание пахотных земель на основе многолетних спутниковых данных спектрорадиометра MODIS и локально-адаптивной классификации // Компьютерная оптика, Том 35, №1 – Самара: ИСОИ РАН, 2011 – С.103-116.
2. Плотников Д.Е., Барталев С.А., Лупян Е.А. Признаки распознавания пахотных земель на основе многолетних рядов данных спутникового спектрорадиометра MODIS // Современные проблемы дистанционного зондирования Земли из космоса, 2010. – Т.7. № 1. – С.330-341.
3. Уваров И.А., Барталев С.А. Алгоритм и программный комплекс распознавания типов земного покрова на основе локально-адаптивной обучаемой классификации спутниковых изображений // Современные проблемы дистанционного зондирования Земли из космоса, 2010. – Т.7, № 1. – С.353-365.
4. Arino O., Bicheron P., Achard F., Latham J., Witt R. and Weber J.L. GlobCover: the most detailed portrait of Earth // ESA Bulletin-European Space Agency. 2008. № 136, P. 24-31.
5. Bartalev, S.A., A.S. Belward, D.V. Erchov, and A.S. Isaev. A new SPOT4-VEGETATION derived land cover map of Northern Eurasia // Int. J. Remote Sens. 2003. V. 24. 9. P. 1977-1982
6. Bartholome, E. and Belward, A.S. GLC2000: a new approach to global land cover mapping from Earth observation data // Int. J. Remote Sens. 2005. V. 26, P. 1959–1977
7. Belward, A.S., ed., 1996, The IGBP-DIS global 1 km land cover data set (DISCover) -proposal and implementation plans: IGBP-DIS Working Paper No. 13, Toulouse, France, 61 pp.
8. Cihlar, J. Land-cover mapping of large areas from satellites: Status and research priorities. // International Journal of Remote Sensing. 2000. V. 21, 1093–1114.
9. Di Gregorio A. UN Land Cover Classification System (LCCS) - Classification Concepts and User Manual for software version 2 // United Nations Food and Agricultural Organization. 2005. Available online at: www.glcn-lccs.org
10. Friedl, M. A., D. K. McIver, J. C. F. Hedges, X. Y. Zhang, D. Muchoney, A. H. Strahler, C. E. Woodcock, S. Gopal, A. Schneider, A. Cooper, A. Baccini, F. Gao and Schaaf C. Global land cover mapping from MODIS: Algorithms and early results // Remote Sensing of Environment. 2002. V. 83. P. 287-302
11. Hansen, M., DeFries, R., Townshend, J. R. G. and Sohlberg, R. Global land cover classification at 1 km resolution using a decision tree classifier // Int. J. Remote Sens. 2000. V.21. № 6-7. P. 1331-1365
12. Loveland, T. R., Zhu, Z., Ohlen, D. O., Brown, J. F., Reed, B. C., and Yang, L. An analysis of the IGBP Global Land-Cover Characterization Process // Photogramm. Eng. Rem. S. 1999. V. 65. № 9. P. 1021-1032
13. Mayaux, P., Eva H., Gallego J., Strahler A., Herold M., Shefali A., Naumov S., de Miranda E., di Bella C., Johansson D., Ordoyne C., Kopin I. and Belward A. Validation of the Global Land Cover 2000 Map // IEEE Transactions on Geoscience and Remote Sensing. 2006. V. 44. № 7-1. P. 1728-1739
14. Scepan J. Thematic Validation of High-Resolution Global Land-Cover Data Sets // Photogramm. Eng. Rem. S. 1999. V. 65. № 9. P. 1051-1060
15. Sulla-Menashe, D; Friedl, MA; Kruskina, ON; Baccini, A; Woodcock, CE; Sibley, A; Sun, GQ; Kharuk, V; Elsakov, V. Hierarchical mapping of Northern Eurasian land cover using MODIS data. // Remote Sensing of Environment. 2011. V. 115(2). P. 392-403.
16. Vermote, E. F., Vermeulen, A. Atmospheric correction algorithm: spectral reflectances (MOD09). Algorithm Theoretical Background Document. 1999. 107 pp. (http://modis.gsfc.nasa.gov/data/atbd/atbd_mod08.pdf)

Mapping of Russia's vegetation cover using MODIS satellite spectroradiometer data

**S. A. Bartalev¹, V. A. Egorov¹, D. V. Ershov², A. S. Isaev²,
E. A. Loupian¹, D. E. Plotnikov¹, I. A. Uvarov¹**

¹ *Space Research Institute, Russian Academy of Sciences
117997, 84/32 Profsoyuznaya str., Moscow, Russia
E-mail: smis@smis.iki.rssi.ru*

² *Centre for Forest Ecology and Productivity, Russian Academy of Sciences
117997, 84/32 Profsoyuznaya str., Moscow, Russia
E-mail: ebch@cepl.rssi.ru*

The paper describes new automated method for vegetation cover mapping based on satellite observation data by spectroradiometer MODIS. The method involves preliminarily cleaned from impact of cloud and other contaminating factors multi-annual time-series of spectral reflectance satellite measurements along with automated land cover types recognition based on a locally-adaptive classification algorithm LAGMA. New vegetation map of Russia developed with mentioned above method has spatial resolution 250 m. The map legend consist 22 thematic classes, including 18 various vegetation types. New map demonstrates higher level of thematic reliability and details in comparison to earlier published satellite data derived land cover maps.

Keywords: vegetation cover mapping, satellite spectroradiometer MODIS, locally-adaptive classification algorithm LAGMA