

УДК 528.854

СЕГМЕНТАЦИЯ ПРИРОДНЫХ И АНТРОПОГЕННЫХ ОБЪЕКТОВ ПО ПАНХРОМАТИЧЕСКИМ СПУТНИКОВЫМ ИЗОБРАЖЕНИЯМ С ИСПОЛЬЗОВАНИЕМ СТАТИСТИЧЕСКИХ ТЕКСТУРНЫХ ПРИЗНАКОВ

© Е. В. Дмитриев^{1,2}, Т. В. Кондранин², С. А. Зотов²

¹Институт вычислительной математики им. Г. И. Марчука РАН,
119333, Москва, ул. Губкина, 8

²Московский физико-технический институт,
141701, г. Долгопрудный Московской обл., Институтский переулок, 9
E-mail: yegor@mail.ru

Рассматривается задача сегментации природно-техногенных объектов по панхроматическим спутниковым изображениям сверхвысокого пространственного разрешения (< 1 м) с использованием текстурного анализа. Проводится анализ эффективности различных статистических методов извлечения текстурных признаков. На основе численных экспериментов выделены методы, которые позволяют с высокой точностью ($> 95\%$) сегментировать основные типы природных и антропогенных объектов, а также различные структуры растительного полога. Предложен метод TTSPCA, который даёт возможность совместно использовать наиболее информативные признаки, извлекаемые с помощью различных статистических методов. Результаты тестовых расчётов показывают, что данный метод имеет большую точность ($> 99\%$) при решении задачи текстурной сегментации по сравнению с рассмотренными стандартными подходами.

Ключевые слова: дистанционное зондирование, распознавание образов, текстурные признаки, тематическая обработка, классификация, сегментация.

DOI: 10.15372/AUT20220209

Введение. В настоящее время функционирует целый ряд космических систем дистанционного зондирования, которые позволяют одновременно получать изображения объектов подстилающей поверхности в видимом и ближнем инфракрасном диапазонах с высоким пространственным разрешением: 1–4 м для мультиспектральных изображений и менее 1 м для панхроматических. Высокая точность пространственного совмещения такого рода мультиспектральных и панхроматических изображений обусловила современную тенденцию развития методов тематического дешифрирования на основе совместного использования спектральной и текстурной информации [1, 2]. Существует ряд работ, в которых демонстрируются преимущества данного подхода при решении задач распознавания и сегментации природных объектов по сравнению с процедурами обработки на основе вегетационных индексов [3, 4]. Одним из примеров является снижение эффективности использования вегетационных индексов для классификации древостоев с высокой плотностью полога. В работе [5] демонстрируется значимое превосходство точности классификации видового состава древостоев на основе текстурной обработки панхроматических изображений WorldView-2 с разрешением $\sim 0,5$ м в подобных случаях над точностью попиксельной классификации как вегетационных индексов, так и непосредственно данных в спектральных каналах.

Результаты спектрально-текстурной обработки авиационных изображений с пространственным разрешением ~ 1 м, представленные в [6], показывают, что данный подход обеспечивает значимое (в ряде случаев более 10 %) увеличение точности классификации

породного состава и возрастных групп древостоев по сравнению с усреднёнными спектральными характеристиками. Сравнение различных схем спектральной и спектрально-текстурной классификаций [7] свидетельствует о том, что привлечение для анализа пространственной информации приводит к значительному повышению точности тематической обработки. В работе [8] демонстрируется повышение точности классификации видового состава влажных тропических лесов за счёт использования дополнительной текстурной информации. Подобные выводы можно сделать и по результатам спектрально-текстурной обработки изображений смешанных древостоев центральных регионов России [9]. Текстурный анализ изображений высокого пространственного разрешения также используется для определения структурных параметров древостоев, характеризующих разнообразие размеров и плотности крон, а также относительное положение отдельных деревьев [10].

Повышение эффективности тематической обработки аэрокосмических изображений высокого пространственного и спектрального разрешений имеет высокую востребованность в различных областях управления сельским и лесным хозяйством для мониторинга окружающей среды. Важно подчеркнуть, что точность текстурной обработки спутниковых изображений определяется не только качеством самих изображений и используемой геопривязанной наземной информации, но также существенным образом зависит от выбранного алгоритма извлечения признаков.

Целью данной работы является исследование возможности использования различных статистических методов измерения текстур для решения задачи сегментации природных и антропогенных объектов на спутниковых панхроматических изображениях сверхвысокого пространственного разрешения. Рассматривается проблема повышения точности сегментации за счёт совместного использования текстурных признаков, полученных разными методами. Одновременно решается практическая задача увеличения вычислительной эффективности рассматриваемых схем обработки и информативности текстурных признаков.

Методика извлечения текстурных признаков. Статистический подход к решению задачи текстурной обработки изображений в градациях серого предполагает, что яркости соответствующих пикселей образуют структурные элементы различной сложности, имеющие некоторое дискретное распределение. Функции вероятности представляются в виде матриц, поскольку соответствующие методы также называют «матричными». Обрабатываемое изображение должно содержать достаточно большое количество структурных элементов, чтобы получить надёжную оценку функции вероятности. Основным предположением является то, что различным текстурам соответствуют разные функции вероятности, характеризующие распределение структурных элементов. На основе функций вероятности рассчитываются статистические параметры, называемые текстурными признаками. Текстурные признаки, полученные на основе матричных методов, подразделяются на характеристики 1-го и 2-го порядков.

При построении текстурных характеристик 1-го порядка подразумевается, что структурными элементами являются отдельные пиксели исходного изображения [11]. В настоящее время для расчёта характеристик 1-го порядка используются два главных метода: GLM (Gray-Level Matrix) и GLDM (Gray-Level Difference Matrix), которые основаны на одномерных гистограммах частот появления уровней серого или модулей пространственных разностей уровней серого [12]. Поскольку в различных работах, в частности в [12], показана низкая эффективность данного класса методов для решения задач, здесь будут рассматриваться только характеристики 2-го порядка, описанные в [13]. Следует отметить, что некоторые из таких методов изложены в [13] лишь на качественном уровне. В связи с этим далее приводится их подробное описание.

Выделение текстурных характеристик 2-го порядка связано в первую очередь с построением двумерных распределений. Структурные элементы в этом случае состоят из

двух отдельных пикселей или двух групп пикселей. Матрица GLCM (Gray-Level Co-Occurrence Matrix) является одним из наиболее популярных статистических методов текстурного анализа [14]. Элементы матрицы GLCM представляют собой частоты совместной встречаемости яркостей монохромного изображения по заданному направлению (направление смежности).

На основе GLCM оцениваются значения двумерной функции вероятности

$$p(i, j) = \frac{\text{GLCM}(i, j)}{\sum_{i,j=1}^N \text{GLCM}(i, j)},$$

по значениям которой рассчитываются статистические моменты, известные как признаки Харалика. В данной работе рассмотрены следующие 19 признаков: Автокорреляция (Autocorrelation); Вышуклость кластера (Cluster Prominence); Тень кластера (Cluster Shade); Контраст (Contrast); Корреляция (Correlation); Энтропия разности (Difference Entropy); Дисперсия разности (Difference Variance); Неоднородность (Dissimilarity); Энергия (Energy); Энтропия (Entropy); Однородность (Homogeneity); Однородность 2 (Homogeneity 2); Первая информационная мера корреляции (Information Measure of Correlation 1); Вторая информационная мера корреляции (Information Measure of Correlation 2); Максимум вероятности (Maximum Probability); Среднее суммы (Sum Average); Энтропия суммы (Sum Entropy); Сумма квадратов (Sum Squares) и Дисперсия суммы (Sum Variance). Английские наименования признаков указаны в скобках, поскольку русские наименования не являются устоявшимися. Подробное описание вычисления признаков представлено в [9, 14].

При реализации метода GGCM (Gray-Level Gradient Co-Occurrence Matrix) [15] исходное изображение $I(x, y)$ преобразуется к изображению модуля градиента яркости $G(x, y)$, который, в свою очередь, оценивается с помощью оператора Собеля $S(x, y)$:

$$G(x, y) = \text{int} \left[\frac{S(x, y) - S_{\min}}{S_{\max} - S_{\min}} \right] N_{gl},$$

где N_{gl} — заданное число градаций модуля градиента. Метод GGCM представляет собой матрицу GLCM, построенную на основе $G(x, y)$. Текстурными признаками являются признаки Харалика, рассчитанные на основе GGCM. Применение градиентного преобразования позволяет выделить текстуры, представленные резкими перепадами яркости пикселей.

Метод GLRLM (Gray-Level Run-Length Matrix) представляет собой матрицу, которая содержит число линейных примитивов заданной длины с яркостью вдоль данного направления [16]. Направления определяются прямыми, проходящими под углами 0, 45, 90 и 135° по отношению к горизонтальной оси. Матрица имеет размер $G \times L$, где G — число градаций серого, а L — максимальная длина серии. Теоретически L в зависимости от угла составляет величину, равную горизонтальному, вертикальному или максимальному из них размеру изображения в пикселях. Однако на практике длина серий ограничивается гораздо меньшим числом.

На основе GLRLM оценивается функция вероятности

$$P(g, l) = \frac{\text{GLRLM}(g, l)}{N_{runs}}, \quad N_{runs} = \sum_{g=1}^G \sum_{l=1}^L \text{GLRLM}(g, l),$$

вводится N_p — число возможных серий размера 1 и производится расчёт текстурных признаков [17]:

1. Short-run emphasis (SRE) $\sum_{g=1}^G \sum_{l=1}^L \frac{P(g, l)}{l^2}$.
2. Run percentage (RP) $\frac{N_{runs}}{N_p}$.
3. Long-run emphasis (LRE) $\sum_{g=1}^G \sum_{l=1}^L P(g, l)l^2$.
4. Short-run low gray-level emphasis (SRLGE) $\sum_{g=1}^G \sum_{l=1}^L \frac{P(g, l)}{l^2 g^2}$.
5. Low gray-level run emphasis (LGRE) $\sum_{g=1}^G \sum_{l=1}^L \frac{P(g, l)}{g^2}$.
6. Long-run high gray-level emphasis (LRHGE) $\sum_{g=1}^G \sum_{l=1}^L P(g, l)l^2 g^2$.
7. High gray-level run emphasis (HGRE) $\sum_{g=1}^G \sum_{l=1}^L P(g, l)g^2$.
8. Short-run high gray-level emphasis (SRHGE) $\sum_{g=1}^G \sum_{l=1}^L \frac{P(g, l)g^2}{l^2}$.
9. Run-length nonuniformity (RLNU) $\sum_{l=1}^L \left[\sum_{g=1}^G P(g, l) \right]^2$.
10. Long-run low gray-level emphasis (LRLGE) $\sum_{g=1}^G \sum_{l=1}^L \frac{P(g, l)l^2}{g^2}$.
11. Gray-level nonuniformity (GLNU) $\sum_{g=1}^G \left[\sum_{l=1}^L P(g, l) \right]^2$.

Матрица SRDM (Surrounding Region Dependency Matrix) представляет собой двумерную гистограмму, показывающую количество пикселей исходного изображения, для которых во внутреннем ($R1$) и внешнем ($R2$) окружении яркость определённого количества пикселей строго меньше яркости центрального пикселя на заданную величину q [18]. Пусть окружение $R1$ состоит из m пикселей, а $R2$ — из n пикселей. Тогда SRDM будет иметь размер $(m + 1) \times (n + 1)$ и может быть представлена в виде

$$SRDM(q) = [\alpha(i, j)], \quad 0 \leq i \leq m, \quad 0 \leq j \leq n,$$

где $\alpha(i, j) = \# \{(x, y) \mid C_{R1}(x, y) = i \ \& \ C_{R2}(x, y) = j, (x, y) \in L_x \times L_y\}$; символ $\#$ означает количество элементов множества. Величины C_{R1} и C_{R2} определяются как

$$C_{R1}(x, y) = \# \{(k, l) \mid (k, l) \in R1 \ \& \ [I(x, y) - I(k, l)] > q\},$$

$$C_{R2}(x, y) = \# \{(k, l) \mid (k, l) \in R2 \ \& \ [I(x, y) - I(k, l)] > q\}.$$

При построении матрицы SRDM пробегаются все пиксели изображения. Для каждого текущего пикселя происходит приращение определённого элемента матрицы SRDM на единицу.

Выбор порогового значения q при вычислении C_{R1} и C_{R2} определяет чувствительность к малым градиентам яркости. При малых q усиливается случайный шум, а при больших происходит потеря тонких элементов текстуры. Для извлечения текстурных признаков на основе SRDM строится функция

$$r(i, j) = \begin{cases} 1/\alpha(i, j), & \alpha(i, j) > 0; \\ 0, & \alpha(i, j) \leq 0, \end{cases}$$

на основе которой вычисляются следующие параметры:

1. Horizontal Weighted Sum (HWS) $\frac{1}{N} \sum_{i=0}^m \sum_{j=0}^n j^2 r(i, j)$.
2. Vertical Weighted Sum (VWS) $\frac{1}{N} \sum_{i=0}^m \sum_{j=0}^n i^2 r(i, j)$.
3. Diagonal Weighted Sum (DWS) $\frac{1}{N} \sum_{k=0}^{m+n} k^2 \left(\sum_{i=0, i+j=k}^m \sum_{j=0}^n r(i, j) \right)$.
4. Grid Weighted Sum (GWS) $\frac{1}{N} \sum_{i=0}^m \sum_{j=0}^n ijr(i, j)$, где $N = \sum_{i=0}^m \sum_{j=0}^n \alpha(i, j)$.

При построении крестодиагональной текстурной матрицы CDTM (Cross-Diagonal Texture Matrix) [19] рассматриваются все возможные ячейки размера 3×3 на исходном изображении. В каждой ячейке выделяется центральный элемент и строится текстурный блок, который, в свою очередь, подразделяется на диагональный и крестовой текстурные блоки (diagonal-texture unit (DTU) и cross-texture unit (CTU) соответственно). Расчёт элементов текстурного блока производится по формуле

$$E_i = \begin{cases} 0, & V_i < V_0; \\ 1, & V_i = V_0; \\ 2, & V_i > V_0. \end{cases}$$

Для блоков CTU и DTU необходимо разместить три числа (0, 1 и 2) в четыре ячейки (всего 34 ячейки и 81 комбинация), т. е., по сути, указанным блокам ставится в соответствие четырёхзначное число в троичной системе счисления. Для представления данных чисел в десятичной системе используются формулы:

$$N_{DTU} = \sum_{i=1}^4 E_{D_i} 3^{i-1}, \quad N_{CTU} = \sum_{i=1}^4 E_{C_i} 3^{i-1}.$$

Обход осуществляется по часовой стрелке с четырёх начальных положений. Таким образом, для каждого текстурного блока имеем четыре набора чисел N_{CTU} и N_{DTU} , каждая пара которых образует матрицу-приращение Δ_{CDTM} . Матрица CDTM вычисляется как

$$CDTM = \sum \Delta_{CDTM},$$

где суммирование идёт по всем парам N_{CTU} и N_{DTU} и по всем положениям ячейки 3×3 . Матрица CDTM представляет собой распределение сочетаний значений диагонального и крестового блоков. Чтобы не учитывать возможный дисбаланс между крестовыми и диагональными блоками, рассматривается симметричная матрица $CDTM_S = CDTM + CDTM^T$. Расчёт текстурных признаков производится по формулам признаков Харалика. При этом в отличие от GLCM матрица CDTM не зависит от числа градаций серого и не требует выбора направления и расстояния смежности.

Методика текстурной сегментации панхроматических изображений. Входными данными процедуры сегментации является текстурный куб данных, представляющий собой трёхмерную стопку изображений текстурных признаков, для построения которых задаётся скользящее окно фиксированной ширины с центром, пробегающим все пиксели панхроматического изображения. Текстуры признаки вычисляются для части панхроматического изображения в пределах скользящего окна и ставятся в соответствие положению центра окна. Для обработки пикселей вблизи границы производится зеркальное отражение приграничных пикселей панхроматического изображения. Данный подход в дальнейшем будем называть стандартной моделью текстурной обработки панхроматических изображений.

При использовании стандартной модели возникает эффект пропуска шумов. Если исходное изображение содержит единичные структурные элементы, резко выделяющиеся на фоне основных текстур, то на изображениях текстурных признаков возникают выбросы, резко выделяющиеся по яркости макропиксели такого же размера, как и скользящее окно. Данная проблема в значительной степени устраняется с помощью гауссовской фильтрации. Параметр разброса гауссовского фильтра σ определяется пространственным разрешением исходного изображения и размером сегментируемых объектов. При слишком малых значениях параметра разброса фильтрация шумовых макропикселей происходит неэффективно. При чрезмерно больших значениях происходит существенное искажение границ объектов. Поэтому при выборе оптимального значения данного параметра необходимо предварительно установить допустимый уровень искажений.

Перебор всех пикселей панхроматического изображения приводит к неоправданным вычислительным затратам. Как показано в [9], для рассматриваемых задач оптимальный размер скользящего окна лежит в диапазоне 50–100 пикселей, таким образом, при перемещении скользящего окна на соседний пиксель анализируемые текстуры совпадают более чем на 90 %. При проведении совместной спектрально-текстурной обработки достаточно перемещать скользящее окно по координатам соответствующего привязанного мультиспектрального изображения, которое имеет меньшее пространственное разрешение. Так, например, при совместной обработке мультиспектральных и панхроматических изображений WorldView-2 достигается ускорение расчёта в 16 раз. В данном случае зона перекрытия соседних окон будет значительной, поэтому этот способ также относится к стандартной модели текстурной обработки.

Значительно более существенного ускорения вычислений можно достичь, если перемещать центр окна по сетке с шагом, равным его размеру, и последующей интерполяцией значений текстурных признаков. При этом использование нелинейных методов интерполяции, например бикубической интерполяции, как правило, приводит к появлению значительного количества выбросов. В этой связи предпочтительней использовать билинейную интерполяцию с последующей фильтрацией Гаусса, которая позволяет сгладить возникающие при этом характерные искажения в виде рёбер. Такой подход в дальнейшем будем называть сеточной моделью текстурной обработки.

Процедура сегментации состоит в применении обучаемой классификации к сформированному кубу текстурных данных и формировании изображения результатов попиксельной классификации. В качестве классификатора использовался ансамблевый алгоритм — метод самокорректирующихся кодов (ЕСОС) [20], позволяющий решать задачу многоклассовой классификации на основе проведения серии бинарных классификаций и последующего голосования. Общая схема метода состоит в следующем. Каждому классу ставится в соответствие уникальный код (вектор-строка), содержащий числа 1, -1 и 0. Коды классов имеют одну и ту же заданную длину и могут быть объединены в кодовую матрицу, строки которой соответствуют распознаваемым классам, а столбцы — различным способам

обучения некоторого бинарного классификатора. В предлагаемой работе была выбрана кодовая матрица, соответствующая стратегии OVO (каждый против каждого), а в качестве алгоритма бинарной классификации использовался метод опорных векторов с гауссовским ядром [21].

Для декодирования классов решаются задачи бинарной классификации, определяемые столбцами кодовой матрицы. Ответы бинарных классификаторов записываются в вектор-строку. Далее рассчитываются расстояния между полученной строкой и кодами классов в смысле некоторой заданной меры. Класс, соответствующий минимальному расстоянию, является ответом данного классификатора. Обоснование выбора такой модификации алгоритма ЕСОС представлено в [9].

Решение задачи обучаемой классификации в случае использования большого количества зависимых переменных сопряжено с наличием проблемы «проклятия размерности» [22]. Для эффективного сокращения размерности признакового пространства применялся регуляризованный метод последовательного отбора (РМПО) [23] и анализ главных компонент (РСА — Principal component analysis). Последовательность наиболее информативных признаков, устойчивую к малым изменениям обучающего ансамбля, позволяет получить РМПО. Анализ главных компонент даёт возможность спроецировать исходный куб данных в пространство с базисными векторами в направлениях максимальной изменчивости. Такие компоненты сортируются в порядке убывания дисперсии и разделяются на группы по информативности.

На основе РМПО и РСА реализован алгоритм, позволяющий повысить эффективность текстурной сегментации за счёт совместного использования текстурных признаков, извлекаемых с помощью рассмотренных статистических методов. Основные этапы алгоритма:

- 1) отбор методов извлечения текстурных признаков, обеспечивающих точность текстурной сегментации не хуже 90 %;
- 2) выделение последовательностей наиболее информативных признаков для каждого из методов, выбранных с помощью РМПО, и формирование на их основе текстурного куба данных;
- 3) расчёт главных компонент текстурного куба с использованием РСА;
- 4) выделение наиболее информативных главных компонент с помощью РМПО и формирование модифицированного текстурного куба, данные которого в дальнейшем используются в качестве входных в алгоритме классификации.

Описанный метод будем называть TTSPCA (total texture statistics PCA). Для практического применения TTSPCA используется как стандартная, так и сеточная модель текстурной обработки.

Приведём также описание используемых характеристик качества сегментации. Базовой характеристикой считается матрица ошибок (СМ, Confusion Matrix), которая позволяет визуализировать сопоставление фактических классов и ответов классификатора. В представленном исследовании строки СМ соответствуют фактическим классам, а столбцы — предсказанным. Для количественной оценки качества сегментации каждого класса применяется понятие ошибок оmissии (ОЕ, Ommission error) и ошибок комисии (СЕ, Commission error). Ошибка оmissии определяется как вероятность ошибочной классификации реализации вектора признаков, соответствующей некоторому фактическому классу. Общая ошибка оmissии (ТОЕ) — среднее значение ОЕ по всем фактическим классам. Ошибка комисии определяется как вероятность ложной классификации для каждого предсказанного класса. Общая ошибка комисии (ТСЕ) — среднее значение СЕ по всем возможным ответам используемого классификатора. Полная вероятность ошибки классификации (ТЕ) определяется как количество неверно классифицированных реализаций по отношению к общему количеству реализаций. Для расчёта оценок ошибок используются

методы переклассификации (зависимая проверка), перекрёстной проверки (кроссвалидации) и независимой проверки. На основе сравнения оценок, полученных указанными методами, можно судить об обобщающей способности используемого алгоритма классификации после обучения.

Численные эксперименты. Для проведения тестовых расчётов с помощью вышеописанных методов текстурной обработки использовались панхроматические изображения WorldView-2 с пространственным разрешением 0,46 м двух тестовых участков — Константиновский (Константиновский карьер) и ГПЛ Дементьева (географические посадки лесничего Дементьева), расположенных на территории Савватьевского (Тверская обл.) и Бронницкого (Московская обл.) лесничеств соответственно. Первый участок содержит основные виды природных и техногенных объектов: водная поверхность, поле, зона застройки и сосновый древостой с однородным породным составом. Второй участок содержит характерные типы растительного полога: хвойный древостой (лесокультурные насаждения — ель, сосна) с плотным пологом, лиственный древостой (берёза) с плотным пологом, нормальный смешанный древостой, смешанный древостой с выраженной кластерной структурой верхней границы полога, лесокультуры лиственницы с регулярной структурой полога и луговая растительность.

Результаты текстурной классификации объектов тестового участка Константиновский представлены на рис. 1. Для обучения использовалась сбалансированная выборка, содержащая 1000 реализаций признаков для каждого класса. Рассматривалась модель, когда центр скользящего окна пробегает все пиксели соответствующего мультиспектрального изображения. Для метода SRDM размер скользящего окна был выбран равным 36, для остальных методов — 108. В данном случае гауссовская фильтрация текстурных признаков не осуществлялась. Для методов GLCM, GGCM, GLRLM и CDTM производился отбор наиболее информативных признаков. Для SRDM количество признаков невелико (четыре признака), поэтому задача классификации решалась в полном пространстве.

Сравнивая полученные результаты с экспертной картой, можно видеть, что все рас-

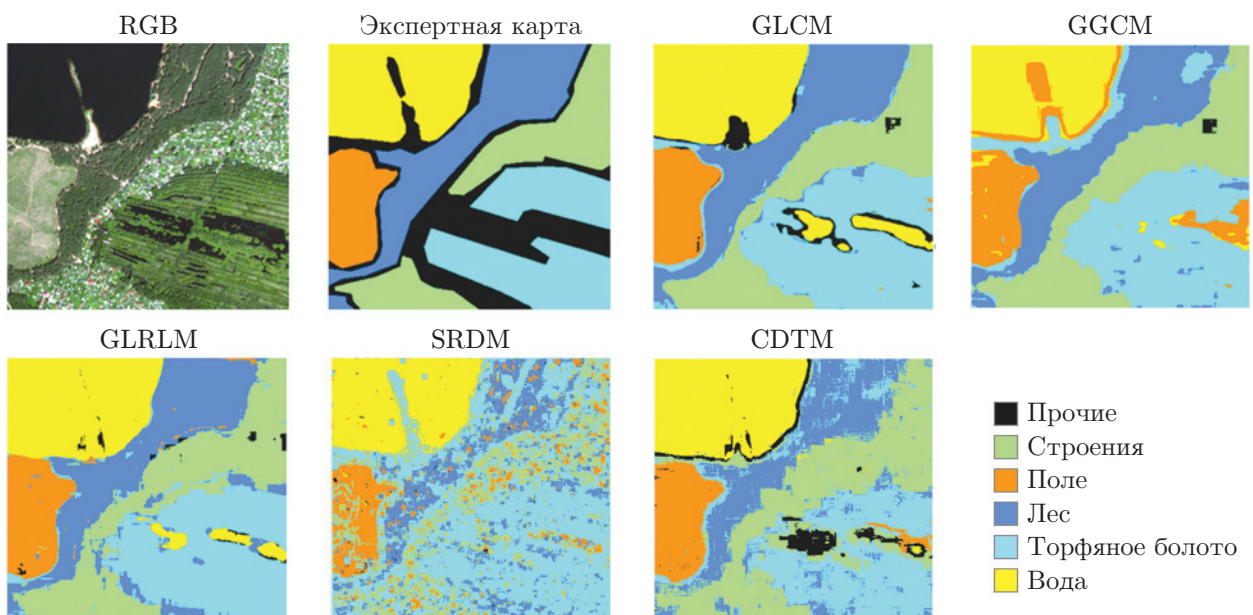


Рис. 1. Результаты сегментации природных и техногенных объектов по панхроматическому изображению тестового участка Константиновский с использованием различных статистических методов извлечения текстурных признаков

Таблица 1

Ошибки текстурной сегментации для объектов тестового участка Константиновский для различных статистических методов извлечения текстурных признаков

Методы	Ошибки	Строения	Поле	Лес	Торфяное болото	Вода
GLCM	OE	0,004	0,015	0,019	0,022	0
	CE	0,009	0,009	0,017	0,022	0
GGCM	OE	0,012	0,058	0,084	0,097	0,14
	CE	0,038	0,29	0,05	0,097	0,017
GLRLM	OE	0,021	0,014	0,06	0,098	0
	CE	0,103	0,039	0,056	0,02	0
SRDM	OE	0,54	0,33	0,47	0,23	0,08
	CE	0,4	0,33	0,36	0,44	0,03
CDTM	OE	0,08	0,008	0,18	0,12	0
	CE	0,08	0,026	0,15	0,14	0,0012

смотренные методы в целом несут полезную информацию для распознавания текстурных особенностей основных типов природно-техногенных объектов. Наиболее качественной представляется сегментация с использованием GLCM. Наихудшие результаты показали текстурные характеристики SRDM, а приемлемые результаты — методы GGCM, GLRLM и CDTM.

Оценки OE и комиссии CE для каждого из объектов тестового участка Константиновский, представленные в табл. 1, получены с использованием данных, не вошедших в обучающее множество (более 13000 реализаций на каждый класс) за исключением граничных пикселей. Видно, что для всех рассмотренных методов с наименьшими ошибками выделяется водная поверхность. Также с достаточно высокой точностью сегментируются зоны застройки. В целом наилучшую точность сегментации обеспечивают методы GLCM и GGCM, полная вероятность ошибки TE составляет величину в диапазоне 3–4 %. Метод GLRLM также демонстрирует хорошие результаты, ошибки классификации TE составляют около 5 %. Метод SRDM демонстрирует неприемлемо низкую точность: ошибки сегментации некоторых объектов находятся в районе 50 %, что соответствует признакам случайной классификации.

Существенного повышения точности сегментации удаётся достичь за счёт использования гауссовской фильтрации текстурных характеристик. Методы SRDM и CDTM наиболее подвержены проблеме возникновения шумов при движении скользящего окна. Влияние гауссовской фильтрации на результат сегментации для указанных методов представлено на рис. 2. Можно видеть, что при увеличении параметра разброса σ возрастает качество сегментации. Наилучших результатов удаётся достичь при значениях σ в 6–10 пикселей. Дальнейшее увеличение σ ведёт к видимому искажению границ.

В табл. 2 представлены ошибки классификации исходных текстурных признаков и после применения гауссовской фильтрации при разбросе в 10 пикселей для всех рассмотренных методов. Метод GLCM наименее подвержен проблеме возникновения шумов. При этом и для него виден явный положительный эффект от данной процедуры. Использование гауссовской фильтрации позволяет достичь общей точности сегментации около 99 % для методов GLCM, GGCM, GLRLM и CDTM, что соизмеримо с точностью построения экспертной тематической карты. Точность метода SRDM остаётся достаточно низкой.

На основании полученных результатов для реализации метода TTSPCA были использованы методы GLCM, GGCM, GLRLM и CDTM. Наиболее информативные текстурные признаки для указанных методов извлечения, полученные на основе регуляризованного

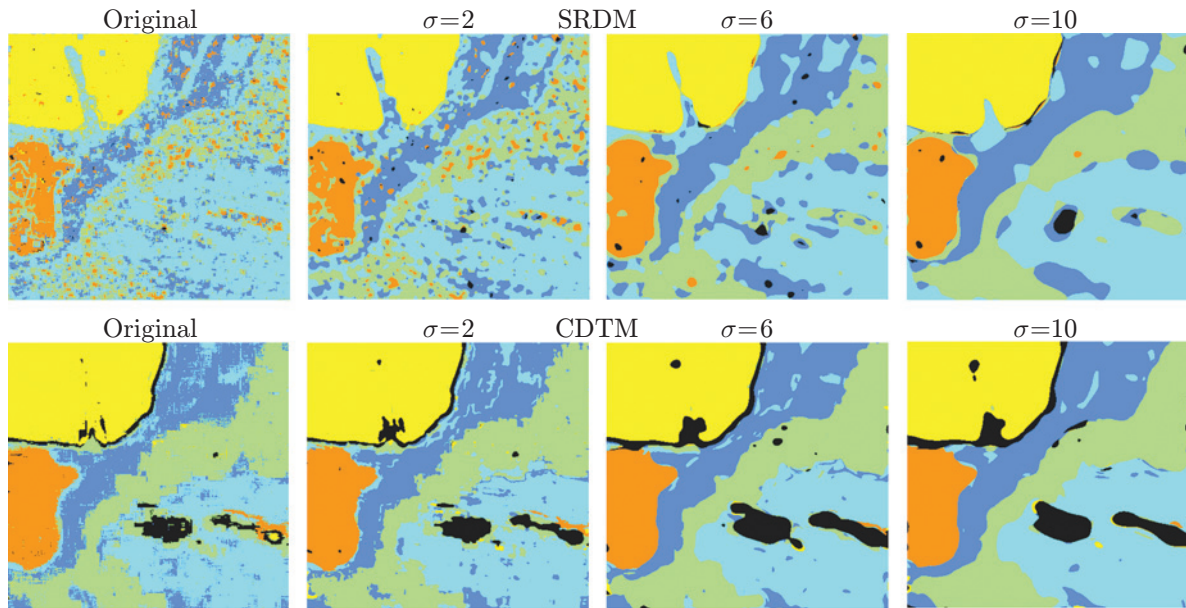


Рис. 2. Результаты сегментации с использованием гауссовской фильтрации текстурных признаков для методов SRDM и CDTM при различных значениях σ . Original означает обработку без использования гауссовской фильтрации. Тестовый участок — Константиновский, цветовое обозначение классов как на рис. 1

Таблица 2

Ошибки текстурной сегментации различными методами в рамках исходной модели и при использовании гауссовской фильтрации

Метод извлечения признаков	Без фильтрации		Фильтрация Гаусса ($\sigma = 10$)	
	Переклассификация	Независимая проверка	Переклассификация	Независимая проверка
GLCM	0,015	0,033	0,005	0,009
GGCM	0,023	0,043	0,006	0,01
GLRLM	0,039	0,046	0,007	0,011
SRDM	0,529	0,553	0,147	0,172
CDTM	0,06	0,09	0,002	0,009

прямого отбора, представлены в табл. 3. Необходимо отметить, что наборы, полученные для методов GLCM, GGCM и CDTM, существенно различаются. Далее для указанной совокупности признаков проводились расчёт главных компонент, их сортировка в порядке убывания изменчивости и оценка информативности. В результате для сегментации использовались 1-, 2-, 3-, 4-, 6- и 11-я главные компоненты, которые обеспечивали решение задачи сегментации с наиболее высокой точностью.

Результаты сегментации на основе TTSPCA и GLCM (наиболее точного из вышерассмотренных методов), а также соответствующие матрицы ошибок представлены на рис. 3. Рассматривались стандартная (TTSPCA и GLCM) и сеточная (TTSPCA grid и GLCM grid) модели извлечения признаков. Для сеточной модели предпочтительнее использовать меньший размер плавающего окна из оптимального диапазона значений. Таким образом, представленным далее расчётам соответствует размер окна в 54 пикселя, что обеспечи-

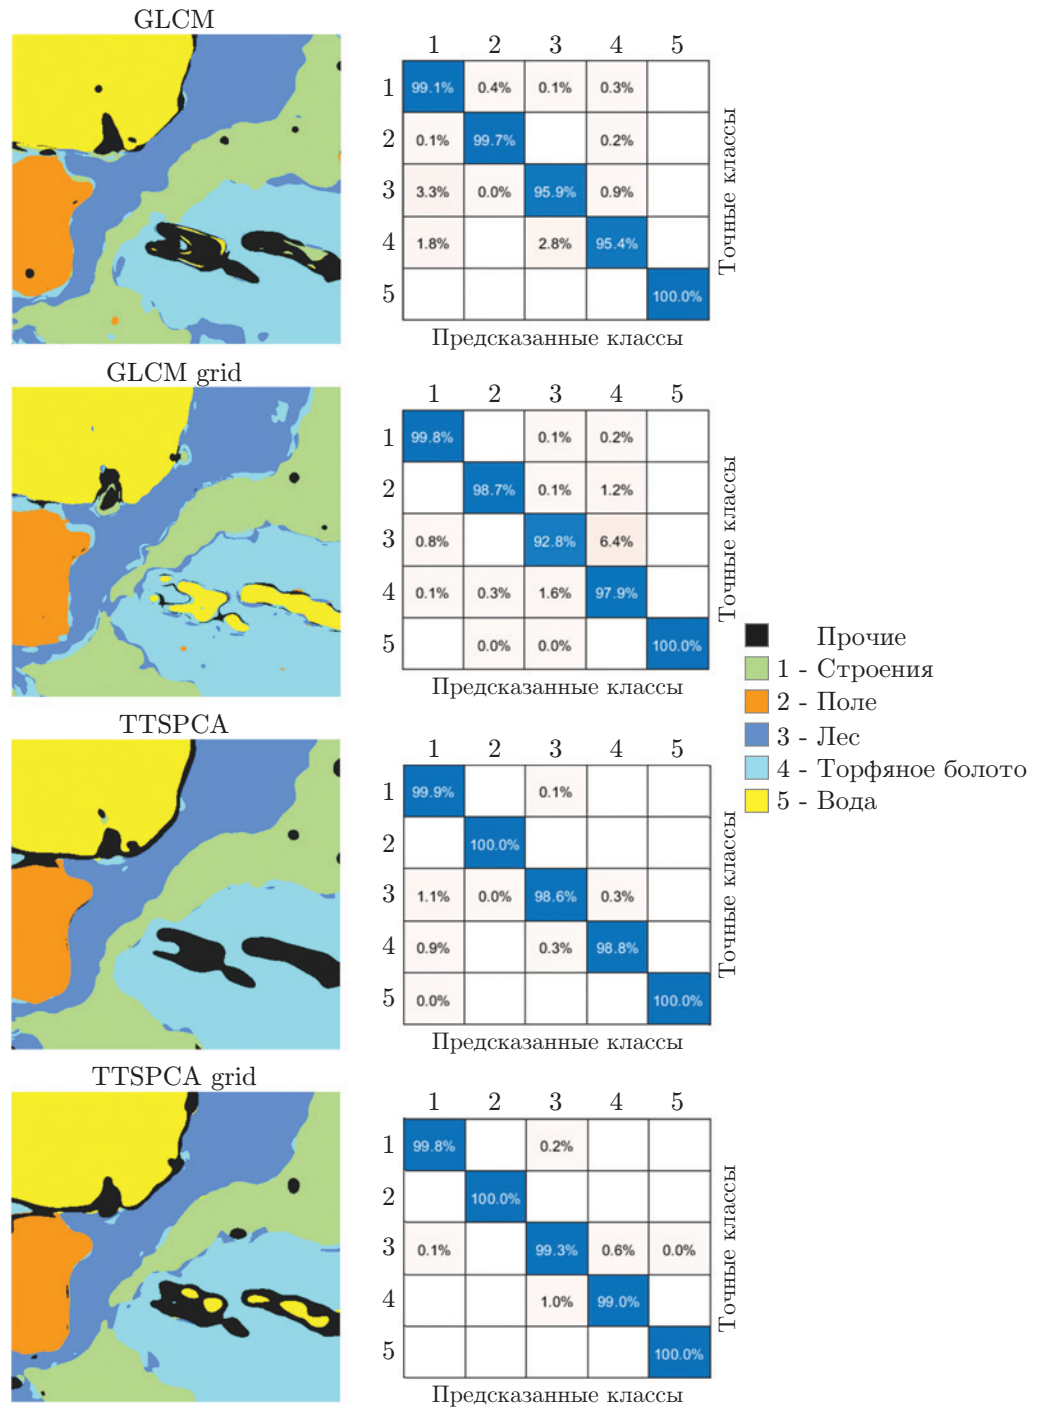


Рис. 3. Сегментация природных и техногенных объектов по панхроматическому изображению тестового участка Константиновский методами GLCM и TTSPCA (стандартная и сеточная модели)

Таблица 3

Оптимальные наборы признаков, используемые при реализации метода TTSPCA

Метод извлечения	Наиболее информативные признаки
GLCM	Автокорреляция, Первая информационная мера корреляции, Тень кластера, Однородность 2, Энергия
GGCM	Однородность, Однородность 2, Неоднородность, Энтропия разности
GLRLM	RP, GLNU, HGRE, LGRE, LRHGE
CDTM	Корреляция, Дисперсия разности, Энтропия, Однородность, Тень кластера

Таблица 4

Ошибки текстурной сегментации для объектов тестового участка Константиновский для методов GLCM и TTSPCA

Методы	Ошибки	Строения	Поле	Лес	Торфяное болото	Вода
GLCM	OE	0,009	0,003	0,041	0,046	0
	SE	0,058	0,01	0,031	0,012	0
GLCM grid	OE	0,002	0,013	0,072	0,021	0
	SE	0,011	0,007	0,02	0,063	0
TTSPCA	OE	0,001	0	0,014	0,012	0
	SE	0,024	0,001	0,005	0,003	0
TTSPCA grid	OE	0,002	0	0,007	0,01	0
	SE	0,001	0	0,012	0,005	0

вает хорошие результаты для обоих типов моделей. Параметр фильтрации Гаусса был выбран равным 7.

Анализируя данные на рис. 3, можно отметить, что использование значительно более быстрой сеточной модели обеспечивает получение достаточно близких результатов сегментации. Ошибка классификации, рассчитанная по результатам независимой валидации, составляет 2,4 % для обеих моделей. Ошибки, полученные по методам переклассификации и кроссвалидации, меньше и составляют соответственно 1,6 и 1,9 % при естественном разбросе значений, обусловленных случайным выбором обучающих реализаций в 0,3 %. Незначительное различие между оценками переклассификации и кроссвалидации свидетельствует о малой вероятности переобучения. При использовании метода TTSPCA полная вероятность ошибки снижается до значений около 0,6 %, при этом различие между ошибками стандартной и сеточной моделей составляет величину, не превышающую 0,2 %.

Независимые оценки ошибки оmissии и комиссии для каждого объекта приведены в табл. 4. Наибольшие ошибки соответствуют объектам Лес и Торфяное болото. По данным таблицы можно видеть снижение либо отсутствие значимых изменений ошибок сегментации для всех рассматриваемых объектов. Подобное заключение можно сделать и на основе матриц ошибок, представленных на рис. 3.

Для оценки эффективности вышеописанной схемы TTSPCA при решении задачи текстурной сегментации растительного покрова использовались панхроматические изображения тестового участка ГПЛ Дементьева. Выбор данного участка обусловлен наличием лесных выделов правильной формы, соответствующих древостоям с различной структурой полога. Древостои тестового участка отличаются по полноте, породному составу и

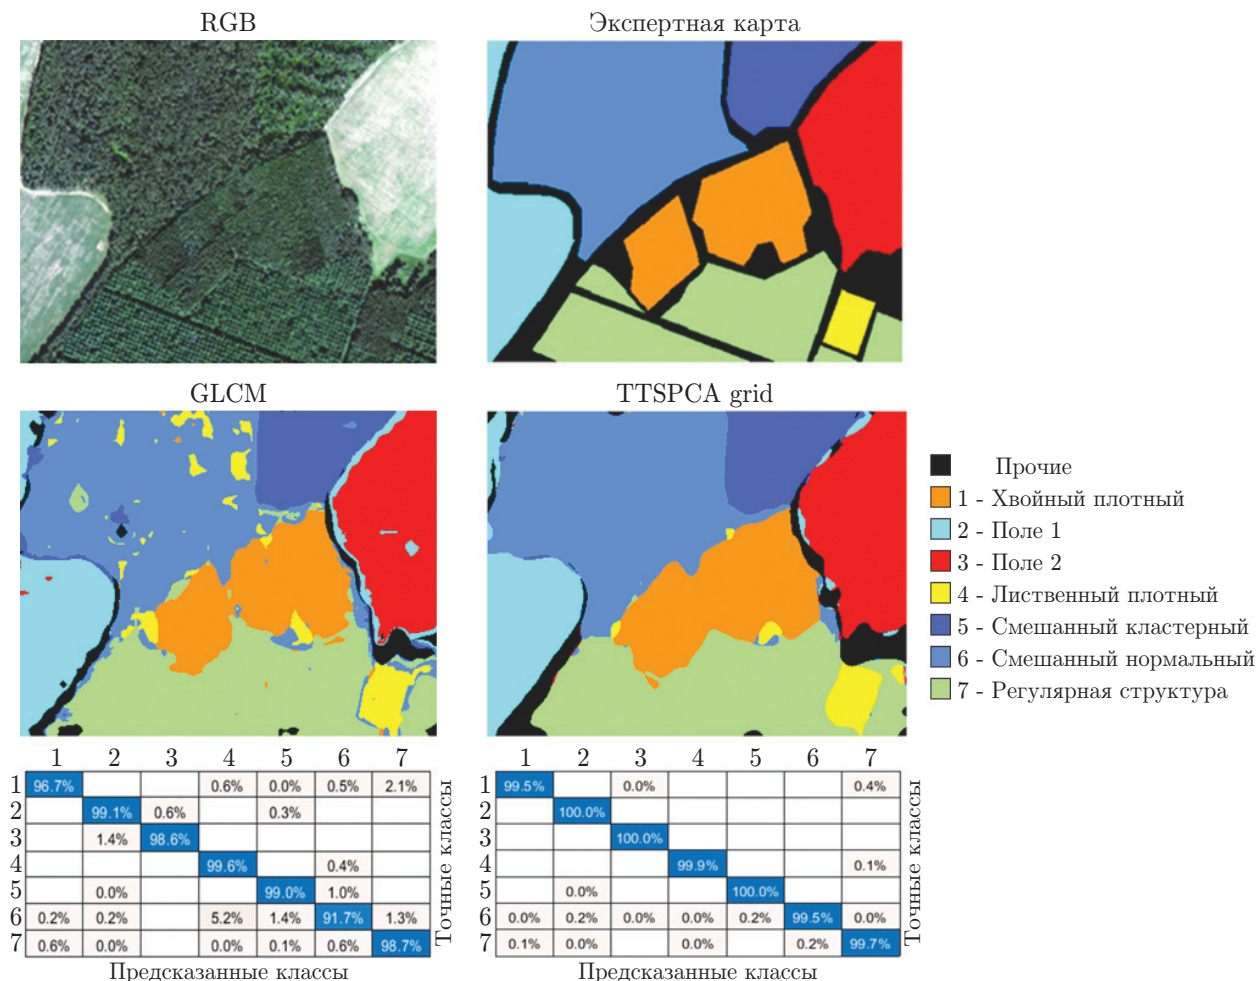


Рис. 4. Сегментация объектов растительного полого по панхроматическому изображению тестового участка ГПЛ Дементьева методами GLCM и TTSPCA grid

регулярности расположения деревьев. Луговая растительность, соответствующая объектам Поле 1 и Поле 2, также имеет видимые текстурные различия, возникающие вследствие наличия открытых почв и особенностей механической обработки данных участков. Результаты текстурной обработки и соответствующие матрицы ошибок для участка ГПЛ Дементьева представлены на рис. 4.

Сравнивая результаты сегментации с экспертной тематической картой, можно видеть, что оба метода GLCM и TTSPCA позволяют с хорошим качеством выделить характерные текстуры растительного покрова. При этом для некоторых объектов сегментация методом GLCM всё же содержит артефакты вне граничных зон. Полная вероятность ошибки сегментации растительного полого методом GLCM составляет 3,9 %. Согласно с данными табл. 5 наибольшие ошибки соответствуют лиственному древостою с плотным пологом. Для такого объекта возникают большие ошибки комиссии, что подтверждается наличием артефактов в зоне смешанного нормального древостоя (см. рис. 4). Также достаточно большая ошибка комиссии возникает при сегментации древостоя с кластерной структурой. Наиболее точно сегментируется луговая растительность и лиственные древостои с регулярной структурой полого (лесокультурные насаждения ели и сосны).

При использовании сеточной модели TTSPCA полная вероятность ошибки сегментации снижается до 0,3 %. Все незначительные артефакты, видимые на рис. 4, соответ-

Таблица 5

**Ошибки текстурной сегментации объектов тестового участка ГПЛ Дементьева
для методов GLCM и TTSPCA**

Методы	Ошибки	Хвойный плот- ный	Поле 1	Поле 2	Листвен- ный плот- ный	Смешанный клас- терный	Смешан- ный нормаль- ный	Регуляр- ная струк- тура
GLCM	OE	0,033	0,009	0,014	0,004	0,01	0,083	0,013
	SE	0,015	0,031	0,0039	0,68	0,072	0,008	0,034
TTSPCA grid	OE	0,005	0	0	0,0013	0	0,005	0,003
	SE	0,001	0,009	0,001	0,013	0,01	0,001	0,003

ствуют граничным зонам. Наибольшие ошибки, возникающие при сегментации хвойного древостоя с плотным пологом и смешанного нормального древостоя, не превышают 1 %. Таким образом, на основе представленного анализа можно заключить, что предлагаемый сеточный метод TTSPCA позволяет повысить точность текстурной сегментации природных и антропогенных объектов по панхроматическим спутниковым изображениям сверхвысокого пространственного разрешения.

Заключение. Статистические методы извлечения текстурных признаков могут быть эффективно использованы для решения задачи сегментации природных и техногенных объектов сложной структуры по панхроматическим спутниковым изображениям сверхвысокого пространственного разрешения. На ряде тестовых примеров показано, что методы GLCM, GGCM, GLRLM и CDTM при использовании гауссовской фильтрации обеспечивают точность сегментации, близкую к 99 %. Точность метода SRDM не превышает 85 %, что соответствует точности текстурной сегментации с использованием характеристик 1-го порядка [12]. Методы CDTM и SRDM наиболее подвержены влиянию шумов, возникающих при движении скользящего окна. Проведено сравнение стандартной и сеточной моделей текстурной обработки. Показано, что точности указанных моделей совпадают, при этом сеточная модель имеет гораздо большую вычислительную эффективность. Таким образом, использование сеточной модели является предпочтительным при проведении массовой обработки панхроматических изображений. Предложен метод TTSPCA, позволяющий совместно использовать наиболее информативные признаки, извлекаемые с помощью различных методов. На основе численных экспериментов продемонстрировано, что данный метод имеет бóльшую точность по сравнению со стандартными статистическими методами. В дальнейшем TTSPCA может быть использован для усовершенствования совместной спектрально-текстурной тематической обработки мультиспектральных и панхроматических изображений высокого пространственного разрешения.

Финансирование. Работа выполнена при поддержке Российского фонда фундаментальных исследований (проект № 20-07-00370) «Фундаментальные проблемы повышения информативности обработки данных оптоэлектронных авиакосмических устройств высокого пространственного и спектрального разрешения».

СПИСОК ЛИТЕРАТУРЫ

1. Wang F., Yi Q., Hu J. et al. Combining spectral and textural information in UAV hyperspectral images to estimate rice grain yield // Intern. Journ. Appl. Earth Observ. and Geoinform. 2021. 102. 102397. P. 1–10.

2. **Tuominen S., Pekkarinen A.** Performance of different spectral and textural aerial photograph features in multi-source forest inventory // *Remote Sens. Environ.* 2005. **94**, Iss. 2. P. 256–268.
3. **Барталев С. А., Лупян Е. А.** Исследования и разработки ИКИ РАН по развитию методов спутникового мониторинга растительного покрова // *Современные проблемы дистанционного зондирования Земли из космоса.* 2013. **10**, № 1. С. 197–214.
4. **Jia K., Liang S., Zhang L. et al.** Forest cover classification using Landsat ETM+ data and time series MODIS NDVI data // *Intern. Journ. Appl. Earth Observ. and Geoinform.* 2014. **33**, Iss. 1. P. 32–38.
5. **Sibiya B., Lottering R., Odindi J.** Discriminating commercial forest species using image texture computed from a worldview-2 pan-sharpened image and partial least squares discriminant analysis // *Remote Sens. Appl.: Soc. and Environ.* 2021. **23**. 100605. P. 1–10.
6. **Рылов С. А., Мельников П. В., Пестунов И. А.** Спектрально-текстурная классификация гиперспектральных изображений высокого пространственного разрешения // *Интерэкспо Гео-Сибирь.* 2016. **4**, № 1. С. 78–84.
7. **Melnikov P. V., Pestunov I. A., Rylov S. A.** Comparison of spectral-spatial classification methods for hyperspectral images of high spatial resolution // *Journ. Siberian Federal University. Engineering & Technologies.* 2017. **10**, Iss. 6. P. 805–811.
8. **Ferreira M. P., Wagner F. H., Aragão L. E. et al.** Tree species classification in tropical forests using visible to shortwave infrared WorldView-3 images and texture analysis // *ISPRS Journ. Photogramm. and Remote Sens.* 2019. **149**. P. 119–131.
9. **Dmitriev E. V., Sokolov A. A., Kozoderov V. V. et al.** Spectral texture classification of high-resolution satellite images for the state forest inventory in Russia // *Proc. of SPIE.* 2019. **11149**. 111491J.
10. **Beguet B., Guyon D., Boukir S., Chehata N.** Automated retrieval of forest structure variables based on multi-scale texture analysis of VHR satellite imagery // *ISPRS Journ. Photogramm. Remote Sens.* 2014. **96**. P. 164–178.
11. **Weszka J. S., Dyer C. R., Rosenfeld A.** A comparative study of texture measures for terrain classification // *IEEE Trans. Syst., Man, and Cybern.* 1976. N 4. P. 269–285.
12. **Dmitriev E. V., Kondranin T. V., Melnik P. G., Donskoy S. A.** Statistical texture analysis of forest areas from very high spatial resolution satellite images // *Proc. of the CEUR Workshop Proceedings. Spatial Data Processing for Monitoring of Natural and Anthropogenic Processes.* Novosibirsk, Russia, 24–27 Aug., 2021. P. 56–66.
13. **Chaki J., Dey N.** *Texture Feature Extraction Techniques for Image Recognition.* Singapore: Springer, 2020. 100 p.
14. **Haralick R. M., Shanmugam K., Dinstein I. H.** Textural features for image classification // *IEEE Trans. Systems, Man, and Cybern.* 1973. N 6. P. 610–621.
15. **Chen S., Wu C., Chen D., Tan W.** Scene classification based on gray level-gradient co-occurrence matrix in the neighborhood of interest points // *Proc. of the IEEE Intern. Conf. on Intelligent Computing and Intelligent Systems.* Shanghai, China, 20–22 Nov., 2009. P. 482–485.
16. **Galloway M. M.** Texture analysis using gray level run lengths // *Comp. Graph. and Image Process.* 1975. **4**, Iss. 2. P. 172–179.
17. **Barry B., Buch K., Soto J. A. et al.** Quantifying liver fibrosis through the application of texture analysis to diffusion weighted imaging // *Magnetic Resonance Imaging.* 2014. **32**, Iss. 1. P. 84–90.
18. **Kim J. K., Park H. W.** Statistical textural features for detection of microcalcifications in digitized mammograms // *IEEE Trans. Med. Imaging.* 1999. **18**, Iss. 3. P. 231–238.

19. **Al-Janobi A.** Performance evaluation of cross-diagonal texture matrix method of texture analysis // Pattern Recogn. 2001. **34**, Iss. 1. P. 171–180.
20. **Dietterich T. G., Bakiri G.** Solving multiclass learning problems via error-correcting output codes // Journ. Artif. Intell. Res. 1995. **2**. P. 263–286.
21. **Hastie T., Tibshirani R., Friedman J.** The Elements of Statistical Learning: Data Mining, Inference, and Prediction. Springer Series in Statistics. 2nd ed. 2008. 745 p.
22. **Bellman R. E.** Adaptive Control Processes. Princeton: Princeton University Press, 1961. 276 p.
23. **Дмитриев Е. В.** Классификация лесного покрова Тверской области на основе гиперспектральных аэроизображений // Исследование Земли из космоса. 2013. № 3. С. 22–32.

Поступила в редакцию 17.02.2022

После доработки 09.03.2022

Принята к публикации 11.03.2022
