

УДК 528.854.4

АЛГОРИТМ ПОВЫШЕНИЯ ТОЧНОСТИ КЛАССИФИКАЦИИ ОБЪЕКТОВ РАДИОЛОКАЦИОННЫХ ИЗОБРАЖЕНИЙ ПО КРИТЕРИЮ ПРИНАДЛЕЖНОСТИ К ВОДНОЙ ПОВЕРХНОСТИ ИЛИ СУШЕ С ИСПОЛЬЗОВАНИЕМ ЦИФРОВОЙ МОДЕЛИ РЕЛЬЕФА

Л. Л. Кузнецов, инженер 2-й категории НИИ «Фотон» РГРТУ, Рязань, Россия;
orcid.org/0009-0005-3888-8599; e-mail: kuznleo@gmail.com

В статье предлагается алгоритм, позволяющий повысить точность классификации объектов радиолокационных изображений по критерию принадлежности к водной поверхности или суше, основанный на объединении результатов первичной классификации с маской классов, сформированной по данным цифровой модели рельефа (ЦМР). Основной задачей является разработка алгоритма формирования маски классов на основе анализа относительных значений высот объектов местности. Актуальность данной работы обусловлена необходимостью создания и улучшения алгоритмов классификации объектов радиолокационных изображений для решения задач систем дистанционного зондирования Земли (ДЗЗ). Результаты применения предлагаемого алгоритма показали высокую степень устранения ложной классификации теневых склонов гор в класс водной поверхности и количественно представляют до 21,7 км² корректно классифицированной площади поверхности Земли.

Ключевые слова: дистанционное зондирование Земли, радиолокационные изображения, цифровая модель рельефа, классификация объектов, обнаружение водной поверхности.

DOI: 10.21667/1995-4565-2026-95-202-214

Введение

Задача классификации объектов на радиолокационных изображениях является востребованной при обработке информации от систем дистанционного зондирования Земли [1, 2]. Ее частный случай – классификация по признаку принадлежности к водной поверхности или суше – необходим при мониторинге стихийных бедствий, обнаружении паводков, определении береговой линии и т.д.

В большинстве случаев для адекватного решения этой задачи требуется применение дополнительных методов обработки изображений, например анализа поляриметрической информации (поляриметрическая классификация) или выполнения текстурного анализа. Так, в работе [3] мы показали возможность использования ряда текстурных признаков Харалика для выполнения классификации объектов по признаку принадлежности к водной поверхности или суше (далее по тексту – целевой классификации), а в работе [4] – пригодность алгоритма поляриметрической классификации Клода – Потье с использованием классификатора Уишарта [5] для решения той же задачи. При этом некоторые особенности отражения радиолокационных сигналов приводят к ошибкам в результатах классификации: асфальтированные дороги и теневые склоны гор имеют идентичное с водой отображение на радиолокационном изображении, вследствие чего возникает необходимость привлечения дополнительных источников информации для повышения точности классификации.

В настоящее время доступны цифровые модели рельефа [6], содержащие низкодетальные данные о высотах земной поверхности. В связи с этим при наличии геодезической привязки на радиолокационном изображении появляется возможность сопоставить изображение и фрагмент ЦМР, покрывающий соответствующий участок Земли. Так как некоторые объекты, такие как вода и холмы или горы, имеют характерные относительные значения высот, то результаты целевой классификации можно улучшить с помощью данных ЦМР [7, 8]. В данной работе предлагается алгоритм повышения точности целевой классификации с использованием ЦМР.

Постановка задачи и предлагаемое решение

Первым шагом предлагаемого алгоритма является определение классов объектов по значениям высот, хранящимся в ЦМР. При этом использование абсолютных высот для классификации по принципу «самые низкие значения соответствуют водным объектам» в большинстве случаев приведет к серьезным ошибкам в результатах классификации, так как данный подход не учитывает возможных изменений средних высот рельефа местности на протяжении маршрута съемки. Например, река, текущая вниз по склону холма, в своей наивысшей точке будет обладать большей высотой, чем поля, расположенные ниже по течению, так же горное озеро будет располагаться выше ближайших предгорий. Вследствие этого классификацию необходимо выполнять с помощью оконной обработки, основанной на анализе относительных значений высот определенного участка местности.

Водные объекты естественного происхождения (озера, реки, моря и т.д.) располагаются в низинах, они также не подвержены резким перепадам высот, поэтому, анализируя характер рельефа обрабатываемого участка местности, можно сделать вывод, присутствует ли на нем водный объект. Подобную классификацию удобно выполнять путем сравнения средних значений высот целевого фрагмента изображения (для которого мы принимаем решение о его принадлежности классу воды целиком) и его некоторой окрестности (которая дает представление об относительном положении анализируемого участка рельефа) – в дальнейшем малого (размером $S \times S$) и большого (размером $L \times L$) окна обработки соответственно. Если средняя высота в малом окне меньше, чем в большом, ($H_s < H_l$) и при этом малое окно однородно (т.е. местность имеет постоянную высоту), то можно классифицировать данный фрагмент как водный объект.

Из-за того, что ЦМР содержит низкодетальные данные, плавные изменения в высоте, присущие водным объектам, в большинстве случаев представляются скачкообразно, с четкой линейной границей, что продемонстрировано на рисунке 1. В случае, если малое окно попадает на такую границу, условие однородности не будет выполняться, в результате чего произойдет ошибка классификации, вызванная особенностями формирования ЦМР. Для устранения данной ошибки вводится дополнительная проверка, позволяющая идентифицировать подобные случаи и выполнить корректную классификацию анализируемой области.




Рисунок 1 – Пример скачкообразного изменения высоты реки на ЦМР

Figure 1 – Example of a sharp elevation change of a river in a DEM

Суть данной проверки заключается в определении линейности границы между двумя уровнями высот. Для этого сначала извлекаются координаты всех граничных точек $\{(x_i, y_i)\}$, после чего вычисляется центр масс данной границы:

$$m_x = \frac{\sum x_i}{N}, \quad m_y = \frac{\sum y_i}{N},$$

где m_x, m_y – координаты центра масс, N – число граничных точек.

Дальнейшие вычисления производятся относительно координат центра масс, что позволяет устранить влияние положения границы внутри обрабатываемого окна. Рассчитываются

вторые центральные моменты инерции относительно осей X и Y S_{xx} и S_{yy} и центробежный момент S_{xy} :

$$S_{xx} = \frac{\sum (x_i - m_x)^2}{N}, S_{yy} = \frac{\sum (y_i - m_y)^2}{N}, S_{xy} = \frac{\sum (x_i - m_x)(y_i - m_y)}{N}.$$

Далее с помощью метода главных компонент вычисляется угол ориентации главной оси инерции $\theta = 0,5 \cdot \arctg\left(\frac{2S_{xy}}{S_{xx} - S_{yy}}\right)$ и производится поворот системы координат на угол θ , в результате чего ось X начинает совпадать с главной осью инерции. Последним шагом является вычисление ошибки $E_1 = \frac{\sum y_i'^2}{N}$, где y_i' – ордината координат граничных точек в новой системе координат.

Интерпретация значения ошибки E_1 позволяет принять решение о линейности границы. В случае идеально прямой линии $E_1 = 0$, однако с учетом погрешностей в вычислениях и в данных ЦМР такое значение практически недостижимо, в результате чего приходится вводить некоторый допуск на отклонение от линейной формы. В ходе ряда проведенных экспериментов было принято решение идентифицировать границу как линейную при $E_1 < 0,15$, что ставит достаточно жесткое требование к линейности формы границы.

Выбор размера окна обработки влияет на способность классифицировать относительно небольшие водные объекты. Чем больше окно, тем менее чувствителен алгоритм к локальным изменениям в рельефе местности. При этом в случае наличия на изображении крупных водных объектов (некоторые озера, моря, океаны) условие $H_s < H_l$ не позволит их корректно классифицировать, поскольку уже на расстоянии в 1-2 малых окна от берега средняя высота в обоих окнах станет одинаковой. Следовательно, условие классификации необходимо преобразовать к виду $H_s \leq H_l$.

Несмотря на то, что подобная классификация показывает достаточно высокую точность определения водных объектов на тестовых изображениях, о чем будет сказано в дальнейшем, можно лишь сделать *предположение* о принадлежности обнаруженных объектов к классу водной поверхности. Это связано с тем, что существуют и неводные объекты, которые имеют аналогичный характер относительных высот, удовлетворяющий критерию классификации. Примерами таких объектов может служить большое поле либо ровная долина между гор.

Тем не менее, знание о форме рельефа водных объектов позволяет выполнить другую классификацию, результаты которой в случае достоверности данных ЦМР также будут являться достоверными. Анализируя значения средних высот и проверяя однородность, можно определить, какие участки рельефа однозначно *не являются* водными объектами. Например, если средняя высота малого окна превышает среднюю высоту большого окна на некоторую величину δ , т.е. если $H_s > H_l + \delta$, то анализируемый фрагмент не является водным. Аналогично, если малое окно имеет сильную неоднородность, оно также однозначно не относится к водному классу. Кроме того, целесообразно оценивать величину наклона поверхности, поскольку ее большие значения обычно характерны для склонов холмов и гор.

Учитывая вышесказанное, по данным ЦМР можно сформировать маски объектов трех классов:

1) класса «вода», к которому относятся объекты изображения, во время анализа которых было выполнено условие $H_s \leq H_l$ и условие однородности;

2) класса «не вода», к которому относятся объекты изображения, во время анализа которых было выполнено условие $H_s > H_l + \delta$ или условие сильной неоднородности;

3) класса «не определено», к которому относятся объекты изображения, не удовлетворяющие критериям двух предыдущих классов.

Блок-схема алгоритма создания маски классов по данным ЦМР приведена на рисунке 2.

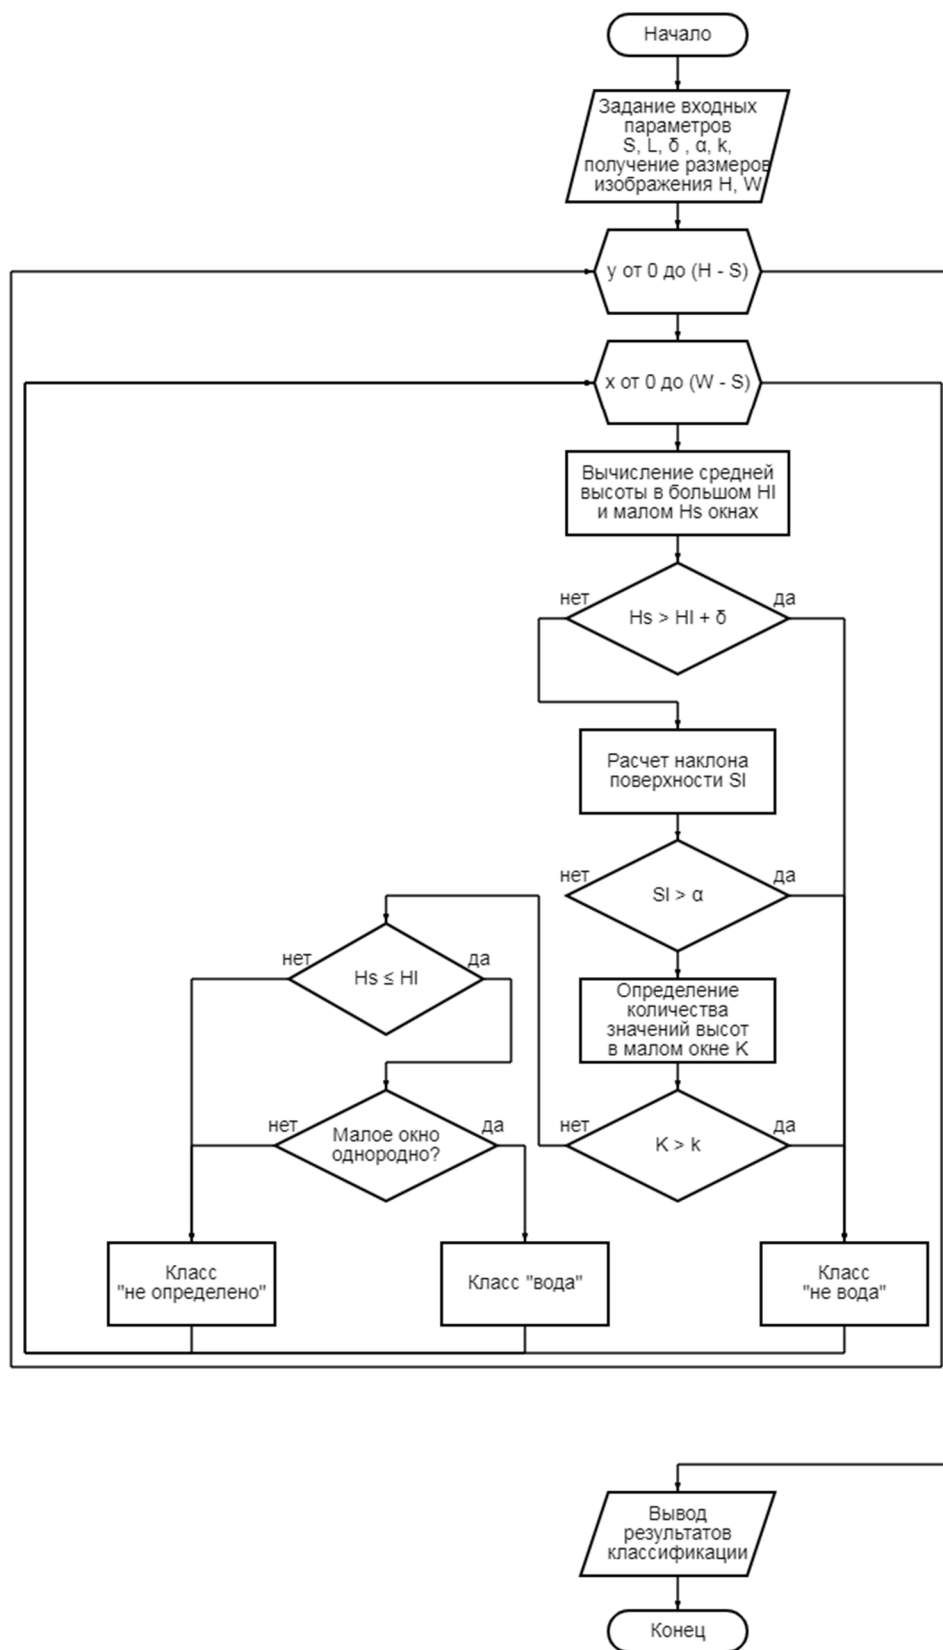


Рисунок 2 – Блок-схема алгоритма создания маски классов по данным ЦМР
Figure 2 – Example of river sharp elevation change in DEM

Второй шаг предлагаемого алгоритма предполагает объединение имеющихся результатов классификации или классификаций с маской классов, сформированной по ЦМР, следующим образом: объекты класса «не вода» сохраняются на выходном изображении без изменений, объекты класса «вода» добавляются как дополнительные данные для принятия решений об итоговом классе (наподобие того, как описано в нашей статье [9]), а объекты класса «не определено» не учитываются и соответственно не изменяют имеющихся результатов классификации.

Экспериментальная часть

Для анализа эффективности предлагаемого алгоритма в задаче повышения точности целевой классификации использовались натурные радиолокационные изображения от космического аппарата «RadarSat-2», приведенные на рисунках 3 и 4.




Рисунок 3 – Экспериментальное радиолокационное изображение № 1
Figure 3 – Experimental radar image № 1




Рисунок 4 – Экспериментальное радиолокационное изображение № 2
Figure 4 – Experimental radar image № 2

В первой серии опытов для экспериментальных изображений была выполнена целевая классификация на основе поляриметрической классификации Клода-Потье с использованием классификатора Уишарта. Примеры таких результатов классификации приведены на рисунках 5 и 6. Белым цветом обозначен класс водной поверхности, черным – класс суши.




Рисунок 5 – Целевая классификация изображения № 1 на основе поляриметрической классификации Клода – Потье (белым цветом обозначен класс водной поверхности, черным – класс суши)

Figure 5 – Targeted classification of image № 1 based on Cloude-Pottier polarimetric classification (white colour represents water surface class, black colour – land class)




Рисунок 6 – Целевая классификация изображения № 2 на основе поляриметрической классификации Клода – Потье (белым цветом обозначен класс водной поверхности, черным – класс суши)

Figure 6 – Targeted classification of image № 2 based on Cloude-Pottier polarimetric classification (white colour represents water surface class, black colour – land class)

Во второй серии опытов целевая классификация выполнялась на основе использования текстурного анализа. Примеры полученных результатов для текстурного признака гомогенности (обратного дифференциального момента) Харалика приведены на рисунках 7 и 8. Обозначение классов аналогично первой серии опытов.



Рисунок 7 – Целевая классификация изображения № 1 на основе текстурной классификации по признаку гомогенности (белым цветом обозначен класс водной поверхности, черным – класс суши)

Figure 7 – Targeted classification of image № 1 based on texture classification of homogeneity feature (white colour represents water surface class, black colour – land class)



Рисунок 8 – Целевая классификация изображения № 2 на основе текстурной классификации по признаку гомогенности (белым цветом обозначен класс водной поверхности, черным – класс суши)

Figure 8 – Targeted classification of image № 2 based on texture classification of homogeneity feature (white colour represents water surface class, black colour – land class)

Для создания маски классов объектов по ЦМР необходимо задать некоторые входные значения для работы алгоритма. В проведенных экспериментах размер малого окна обработки соответствовал площади поверхности $60 \times 60 \text{ м}^2$, размер большого окна обработки – в два раза больше размеров малого окна, что позволяет адекватно оценить окрестность. Выбор размера малого окна по минимальной площади поверхности обнаруживаемого водного объекта, во-первых, позволяет регулировать чувствительность алгоритма, во-вторых, «привязывает» алгоритм к конкретному маршруту съемки, не допуская абстрактности обработки.

Следует отметить, что уменьшение размеров малого окна наряду с повышением чувствительности алгоритма к водным объектам, также повышает количество ложных классификаций поверхности суши, как воды.

Формирование класса «не вода» требует задания трех входных параметров: порога превышения средней высоты малого окна над средней высотой большого окна δ , предельно допустимого значения наклона поверхности $\alpha = \Delta h / d$ (Δh – изменение высоты на противоположных границах малого окна, d – ширина/высота малого окна в метрах) и количества различных значений высоты в пределах малого окна, которое характеризует данное окно как «сильно неоднородное» k . Для работы алгоритма были выбраны следующие значения: $\delta = 1 м$, $\alpha = 0,05$, $k = 0,2 \cdot w \cdot h$ (w – ширина малого окна, h – высота малого окна в пикселях). Аналогично с размерами окон, ужесточение данных пороговых значений позволяет снизить число ложных классификаций поверхности суши в класс воды, при этом уменьшая размер класса «не вода» и увеличивая размер класса «не определено». При задании значений этих параметров следует исходить из конкретных потребностей в том, насколько полной должна быть классификация объектов по ЦМР, и тем самым определять, насколько большой вклад ЦМР должна оказывать на результат целевой классификации. Предложенные значения позволяют сохранить адекватный баланс между наполненностью классов «вода» и «не вода» и достоверностью получаемых результатов.

Результаты формирования маски классов по данным ЦМР для исследуемых изображений приведены на рисунках 9 и 10. На них белым цветом обозначен класс «вода», черным – класс «не вода» и серым – класс «не определено».



Рисунок 9 – Сформированная по данным ЦМР маска классов изображения № 1 (белый цвет – класс «вода», черный цвет – класс «не вода», серый цвет – класс «не определено»)
Figure 9 – Class mask for image №1 formed on DEM data
(white colour – class «water», black colour – class «non-water», gray colour – class «undefined»)

Далее выполнялось объединение исходных данных классификации с маской классов по ЦМР так, как было описано ранее: класс «не вода» сохраняется в неизменном виде, класс «не определено» не учитывается, а класс «вода» используется в качестве дополнительного источника для принятия решения об итоговом классе объектов. В данном случае для принятия решения использовалось правило строгого согласия: если оба источника данных (исходная классификация и маска классов) классифицируют объект принадлежащим водной поверхности, то на результирующем изображении он принадлежит водной поверхности; в остальных случаях объект классифицируется как суша. Изображения из первой серии опытов с результатами целевой классификации после применения алгоритма повышения точности приведены на рисунках 11 и 12, а изображения из второй серии опытов – на рисунках 13 и 14.



Рисунок 10 – Сформированная по данным ЦМР маска классов изображения № 2 (белый цвет – класс «вода», черный цвет – класс «не вода», серый цвет – класс «не определено»)
 Figure 10 – Class mask for image №2 formed on DEM data (white colour – class «water», black colour – class «non-water», gray colour – class «undefined»)



Рисунок 11 – Результат применения алгоритма повышения точности для поляриметрически классифицированного изображения № 1
 Figure 11 – The result of accuracy improvement algorithm usage on polarimetrically classified image № 1

При визуальном сравнении изменений в результатах классификации можно увидеть, что ложная классификация горных склонов в класс водной поверхности либо практически полностью устранилась, либо стала заметно меньше, однако обнаруженные русла рек стали намного уже, чем были изначально.

В качестве меры оценки точности классификации использовалась средняя точность классификации $Acc_{cp} = (Acc_w + Acc_c) / 2$, где $Acc_w = P_w / N_w$, $Acc_c = P_c / N_c$ – точность классификации воды и суши соответственно (P_w , P_c – число корректно классифицированных пикселей воды и суши, определенное по соответствию вручную сформированной эталонной маске классов; N_w , N_c – число пикселей воды и суши, также определенное по эталонной маске).




Рисунок 12 – Результат применения алгоритма повышения точности для поляриметрически классифицированного изображения № 2
 Figure 12 – The result of accuracy improvement algorithm usage on polarimetrically classified image № 2



Рисунок 13 – Результат применения алгоритма повышения точности для текстурно классифицированного изображения № 1
 Figure 13 – The result of accuracy improvement algorithm usage on texturally classified image № 1

Результаты проведенных экспериментов первой серии опытов приведены в таблице 1. Для каждого изображения выполнялась поляриметрическая классификация с разным числом итераций k -средних (столбец « I_k »), проводимых для переобучения классификатора Уишарта, а также замерялось примерное время выполнения двух основных этапов: первичной целевой классификации $t_{кл}$ и алгоритма повышения точности $t_{нов}$. В столбце « Acc_{cp} , %» приведены значения точности поляриметрической классификации, в столбце « Acc_{cp} с ЦМР, %» приведены значения точности после применения предлагаемого алгоритма, а в столбце « ΔAcc_{cp} , %» приведен прирост в точности. Также для каждого эксперимента повышение точности бы-

ло оценено в количестве корректно классифицированной площади земной поверхности $\Delta S = N_{\text{пикс}} S_{\text{пикс}} \Delta Acc_{\text{ср}}$, где $N_{\text{пикс}}$ – количество пикселей анализируемого изображения, $S_{\text{пикс}}$ – площадь поверхности, соответствующая одному пикселю.



Рисунок 14 – Результат применения алгоритма повышения точности для текстурно классифицированного изображения № 2

Figure 14 – The result of accuracy improvement algorithm usage on texturally classified image № 2

Таблица 1 – Результаты оценки повышения точности классификации благодаря применению предлагаемого алгоритма к поляриметрически классифицированным изображениям

Table 1 – The result of accuracy improvement algorithm usage on texturally classified image № 2

№ изображения	I_k	$t_{\text{кл}}, \text{с}$	$t_{\text{нов}}, \text{с}$	$Acc_{\text{ср}}, \%$	$Acc_{\text{ср}} \text{ с ЦМР}, \%$	$\Delta Acc_{\text{ср}}, \%$	$N_{\text{пикс}}$	$S_{\text{пикс}}, \text{м}^2$	$\Delta S, \text{км}^2$
1	25	44,89	58,27	90,94	92,74	1,80	23 353 988	38,953	16,4
	50	80,52	57,47	91,94	92,93	0,99			9,0
	62	98,96	59,22	92,05	92,95	0,90			8,2
2	25	30,99	45,44	90,82	93,53	2,71	19 638 584	40,844	21,7
	50	57,70	45,04	93,79	95,49	1,70			13,6
	62	70,80	45,09	95,59	96,73	1,14			9,1

В таблице 2 приведены результаты второй серии опытов. Для каждого изображения выполнялась классификация на основе расчета текстурного признака гомогенности по Харалику, после чего применялся алгоритм повышения точности.

Таблица 2 – Результаты оценки повышения точности классификации благодаря применению предлагаемого алгоритма к текстурно классифицированным изображениям

Table 2 – The results of classification accuracy improvement estimation due to utilization of the proposed algorithm to texturally classified images

№ изображения	$t_{\text{кл}}, \text{с}$	$t_{\text{нов}}, \text{с}$	$Acc_{\text{ср}}, \%$	$Acc_{\text{ср}} \text{ с ЦМР}, \%$	$\Delta Acc_{\text{ср}}, \%$	$N_{\text{пикс}}$	$S_{\text{пикс}}, \text{м}^2$	$\Delta S, \text{км}^2$
1	47,27	60,77	94,12	94,65	0,53	23 353 988	38,953	4,8
2	41,11	46,55	98,32	98,37	0,05	19 638 584	40,844	0,4

Исходя из результатов проведенных экспериментов можно сделать несколько выводов. Во-первых, эффективность работы предлагаемого алгоритма в значительной степени зависит от сюжета анализируемого изображения. Поскольку основная коррекция результатов подразумевает уменьшение ложной классификации склонов холмов и гор в класс водной поверх-

ности, то чем более гористая местность на изображении, тем выше эффективность работы алгоритма. Во-вторых, чем точнее первоначальная целевая классификация, тем меньше влияния оказывает предлагаемый алгоритм. В проведенных экспериментах точность целевой классификации с помощью текстурного анализа оказалась на несколько процентов выше точности поляриметрической классификации, соответственно прирост от применения алгоритма повышения точности в первом случае был значительно меньше. В-третьих, время работы алгоритма зависит только от размеров анализируемого изображения, что позволяет прогнозировать временные затраты и оптимизировать их (например, при обработке серии изображений с одного или нескольких смежных), что важно для систем оперативного мониторинга.

Заключение

В статье предложен алгоритм повышения точности классификации объектов радиолокационных изображений по критерию принадлежности к водной поверхности или суше, основанный на формировании маски классов по данным высот местности цифровой модели рельефа. На основе данных ЦМР формируются классы «вода», «не вода» и «не определено», которые позволяют уточнить результаты целевой классификации.

Результаты применения предложенного алгоритма на натуральных радиолокационных изображениях показали прирост в точности классификации до 21,7 км² корректно классифицированной площади, что является достаточно большой величиной для одного маршрута съемки в режиме Stripmap. Наибольший вклад данный алгоритм внес в уменьшение ложной классификации теневых склонов гор в класс водной поверхности, вызванной схожими свойствами отражения радиолокационных сигналов от таких поверхностей. Полученные результаты позволяют сделать вывод о пригодности использования предложенного алгоритма в системах ДЗЗ.

Библиографический список

1. **Чандра А.М., Гош С.К.** Дистанционное зондирование и географические информационные системы: М.: Техносфера, 2008. 312 с.
2. **Шовенгердт Р.А.** Дистанционное зондирование. Модели и методы обработки изображений: М.: Техносфера, 2010. 560 с.
3. **Гусев С.И., Кузнецов Л.Л.** Классификация объектов радиолокационных изображений по признаку принадлежности к водной поверхности на основе текстурного анализа в системах дистанционного зондирования Земли // Научные технологии в космических исследованиях Земли. 2025. Т. 17. № 3. С. 22-28.
4. **Гусев С.И., Кузнецов Л.Л., Ушенкин В.А.** Обнаружение водной поверхности на полнополяризационных радиолокационных изображениях // Современные технологии в науке и образовании СТНО-2025. Сборник статей. 2025. Т. 6. С. 58-61.
5. **Lee J.S., Pottier E.** Polarimetric Radar Imaging: from Basic to Applications: Boca Raton, London, New York: CRC Press, 2009. 398 p.
6. **Хромых В.В., Хромых О.В.** Цифровые модели рельефа: учеб. пособие. Томск, 2007.
7. **Sun D., Gao G., Huang L., Liu Y., Liu D.** Extraction of water bodies from high-resolution remote sensing imagery based on a deep semantic segmentation network // Sci Rep, Vol. 14, no. 14604, 2024.
8. **Guo Zh., Wu L., Huang Y., Guo Zh., Zhao J. Li N.** Water-Body Segmentation for SAR Images: Past, Current, and Future // Remote Sens, Vol. 14, no. 7, 2022.
9. **Гусев С.И., Кузнецов Л.Л.** Принятие решений о классе пикселей многоканального радиолокационного изображения по результатам классификации пикселей отдельных каналов в системах дистанционного зондирования Земли // Перспективы науки. 2025. № 7 (190). С. 15-19.

UDC 528.854.4

ALGORITHM TO IMPROVE ACCURACY OF RADAR IMAGE OBJECTS CLASSIFICATION BY CRITERION OF BELONGING TO WATER SURFACE OR LAND USING DIGITAL ELEVATION MODEL

L. L. Kuznetsov, 2nd category engineer at the Research Institute «Photon», RSREU, Ryazan, Russia; orcid.org/0009-0005-3888-8599; e-mail: kuznleo@gmail.com

The article suggests an algorithm that allows to improve accuracy of radar image objects classification by criterion of belonging to water surface or land based on combining the results of primary classification with a class mask generated from digital elevation model (DEM) data. The main task is to create an algorithm that generates a class mask by analyzing relative height of surface objects. This work is relevant due to the need to create and improve radar image objects classification algorithms to solve the tasks of Earth remote sensing (ERS) systems. The results of the proposed algorithm utilization showed a high degree of elimination of false shadow mountain slopes classification into water surface class and are quantified at up to 21,7 square kilometers of correctly classified Earth surface area.

Keywords: Earth remote sensing, radar images, digital elevation model, objects classification, water surface detection.

DOI: 10.21667/1995-4565-2026-95-202-214

References

1. **Chandra A.M., Gosh S.K.** *Distancionnoe zondirovanie i geograficheskie informacionnye sistemy* (Remote sensing and geographic information systems). Moscow: Tehnosfera. 2008, 312 p. (in Russian).
2. **Shovengerdt R.A.** *Distancionnoe zondirovanie. Modeli i metody obrabotki izobrazhenij* (Remote Sensing. Image Processing Models and Methods). Moscow: Tehnosfera, 2010, 560 p. (in Russian).
3. **Gusev S.I., Kuznetsov L.L.** Klassifikacia objektov radiolokacionnyh izobrazhenij po priznaku prinadlezhnosti k vodnoj poverhnosti na osnove teksturnogo analiza v sistemah distancionnogo zondirovaniya Zemli. *Naukojomiye tehnologii v kosmicheskikh issledovaniyah Zemli*. 2025, vol. 17, no. 3, pp. 22-28 (in Russian).
4. **Gusev S.I., Kuznetsov L.L., Ushenkin V.A.** Obnaruzhenije vodnoj poverhnosti na polnopoljarizacionnyh radiolokacionnyh izobrazhenijah. *Sovremennyye tehnologii v nauke i obrazovanii STNO-2025. Sbornik statej*. 2025, vol. 6, pp. 58-61 (in Russian).
5. **Lee J.S., Pottier E.** *Polarimetric Radar Imaging: from Basic to Applications*. Boca Raton, London, New York: CRC Press, 2009. 398 p.
6. **Hromykh V.V., Hromykh O.V.** *Cifrovyye modeli rel'jefa* (Digital elevation models). Tomsk, 2007. (in Russian).
7. **Sun D., Gao G., Huang L., Liu Y., Liu D.** Extraction of water bodies from high-resolution remote sensing imagery based on a deep semantic segmentation network. *Sci Rep*, 2024, vol. 14, no. 14604.
8. **Guo Zh., Wu L., Huang Y., Guo Zh., Zhao J. Li N.** Water-Body Segmentation for SAR Images: Past, Current, and Future. *Remote Sens*. 2022, vol. 14, no. 7, 2022.
9. **Gusev S.I., Kuznetsov L.L.** Prinjatije reshenij o klasse pikselej mnogokanal'nogo radiolokacionnogo izobrazhenija po rezul'tatam klassifikacii pikselej otdel'nyh kanalov v sistemah distancionnogo zondirovaniya Zemli. *Perspektivy nauki*. 2025, no. 7(190), pp. 15-19 (in Russian).