ЭЛ №ФС77-57961
ISSN:2313-8459

«КОНТЕНАНТ»

ЭЛЕКТРОННЫЙ НАУЧНО-ТЕХНИЧЕСКИЙ ЖУРНАЛ

Том 24, №3, 2025

Журнал включен в Российский Индекс Научного Цитирования.
Входит в перечень ВАК с 20.03.2023.
Зарегистрирован в Научной Электронной Библиотеке.
Лицензионный договор №727-11/2014.

Учредитель и издатель – Общественная научно-техническая академия «Контенант»
Издается с 2019 года.

С О Д Е Р Ж А Н И Е

А.В. Мингалев, В.А. Овсянников, Я.В. Овсянников
Сравнение эффективности воздушной тепловизионной аппаратуры с автоматизированным и автоматическим дешифрованием изображений 2

С.Р. Кисленко
Проектирование (редизайн) микроболометра с размером чувствительного элемента 12 мкм: часть 1 29

Городничев В.А., Белов М.Л., Белов А.М., Назаров В.В.
Сравнительный анализ методов машинного обучения для классификации участков лесных массивов 41

В. А. Бабкин, Д. С. Андреев, М. И. Арцис, В. С. Белоусова
А.Е. Харлов, М.Н. Гулюкин
Квантовохимический расчёт некоторых молекул фуллеренов 51

Нгуен Минь Бач, Ю.В. Федотов, Н.В. Барышников, М.Л. Белов
Экспериментальные исследования спектров отражения пластиковых загрязнений в ближней ИК области 66

А.А. Шкарупило, М.Л. Белов, С.Е. Иванов, Н.В. Барышников
Исследование влияния числа исследуемых образцов и шумов измерения на возможности классификации пород деревьев в видимом и ближнем инфракрасном диапазоне 76

Выходит 4 раза в год
Журнал печатается при поддержке руководителей организаций и предприятий оптической промышленности и учебных заведений.

Редакционный совет:
Абдулкадыров Магомед Абдуразакович
Архипов Сергей Алексеевич
Бажанов Юрий Владимирович
Бездидько Сергей Николаевич
Белов Михаил Леонидович
Коротаев Валерий Викторович
Лукин Анатолий Васильевич
Сеник Богдан Николаевич
Соколов Андрей Леонидович
Торшина Ирина Павловна

Редакционная коллегия:
Барышников Николай Васильевич – главный редактор
Иванов Сергей Евгеньевич
Ильянок Юлия Михайловна
Семенов Александр Павлович

Мнения, высказанные в материалах журнала, не обязательно совпадают с точкой зрения редакции.
Ответственность за содержание статей несут авторы.
При полной или частичной перепечатке ссылка на журнал «Контенант» обязательна.

Рукописи и фотографии не возвращаются.

Подписано в печать 22.12.2025
Статьи, подготовленные к изданию, передаются редакции электронного научно-технического журнала в издательство по электронной почте nukrlm@bmstu.ru для последующего размещения на сайте Диссертационного рецензируемого научно-технического журнала «Контенант» с последующей передачей по договору №727-11/2014 в Российский Индекс Научного Цитирования Научной Электронной Библиотеки.

Редакционная коллегия Диссертационного рецензируемого журнала «Контенант»

УДК 621.384.32

СРАВНЕНИЕ ЭФФЕКТИВНОСТИ ВОЗДУШНОЙ ТЕПЛОВИЗИОННОЙ АППАРАТУРЫ С АВТОМАТИЗИРОВАННЫМ И АВТОМАТИЧЕСКИМ ДЕШИФРИРОВАНИЕМ ИЗОБРАЖЕНИЙ

А.В. Мингалев, В.А. Овсянников, Я.В. Овсянников
АО «НПО «Государственный институт прикладной оптики», г. Казань
E-mail: gipo@shvabe.com

Аннотация: Предложена математическая модель оценки интегрального показателя эффективности тепловизионной аппаратуры воздушного базирования, предназначенной для мониторинга подстилающей поверхности с целью поиска и вскрытия (обнаружения и/или распознавания) в режиме реального времени расположенных на ней объектов. В качестве данного показателя использована интенсивность поиска – среднее число объектов, вскрытых в единицу времени в начале поискового процесса, при обеспечении заданной результирующей вероятности вскрытия объектов, усредненной по углу обзора аппаратуры. Описана методика рационального выбора высоты и скорости полета носителя этой аппаратуры при автоматизированном и автоматическом дешифрировании тепловизионных изображений – в том числе с использованием сверточных нейронных сетей – и выполнена оценка и сравнение его эффективности.

Ключевые слова: воздушная тепловизионная аппаратура, дешифрирование изображений.

COMPARISON OF THE EFFICIENCY OF AERIAL THERMAL IMAGING EQUIPMENT WITH AUTOMATED AND AUTOMATIC IMAGE DECIPHERING

A.V. Mingalev, V.A. Ovsyannikov, Ya.V. Ovsyannikov
JSC "SPA "State Institute of Applied Optics", Kazan
E-mail: gipo@shvabe.com

Abstract: A mathematical model has been proposed for assessing the integral indicator of the efficiency of aerial thermal imaging equipment designed to monitor the underlying surface in order to search for and reveal (detect and/or recognize) objects located on it in real time. Search intensity – the average number of objects revealed per unit of time at the beginning of the search

process while ensuring a given resulting probability of objects acquisition averaged over the angle of view of the equipment – is used as such indicator. A method of rational selection of the altitude and flight speed of the carrier of this equipment in the automated and automatic deciphering of thermal imaging images has been described – including the use of convolutional neural networks – and an assessment and comparison of its effectiveness has been carried out.

Keywords: airborne thermal imaging equipment, image deciphering.

Введение

Одним из основных средств дистанционного зондирования земной поверхности является воздушная тепловизионная аппаратура (ВТА), предназначенная для оперативного поиска и вскрытия (обнаружения и/или распознавания) объектов местности, а также определения параметров и анализа динамики изменения их состояния. ВТА успешно используется для решения целого ряда военных и хозяйственных задач: инфракрасной разведки, исследования природных ресурсов, контроля состояния различных инженерных сооружений, земной поверхности и водной среды, обеспечения поисково-спасательных работ и т.д. Она, в отличие от аппаратуры космического базирования, обладает лучшим разрешением на местности, гарантирует более контролируемое, оперативное и активное обследование наземных объектов и имеет меньшую стоимость.

Далее под ВТА будем понимать сканирующую тепловизионную аппаратуру строчного типа с широким углом обзора, использующую субматричный фотоприемник, работающий в режиме временной задержки и накопления, благодаря чему достигается высокая пороговая чувствительность ВТА (способ сканирования whiskbroom – «подметание»). Топология современных субматриц обеспечивает фактическое отсутствие зазора между смежными чувствительными элементами в приемных линейках и сдвиг элементов фотоприемника на полпериода в соседних линейках, что удваивает число элементов изображения по кадру (в направлении полета носителя) [1]. Число выборок (отсчетов сигнала) на элемент фотоприемника по строке (в направлении сканирования) α подбирается так, чтобы сохранялась пространственная изотропность изображения, для чего требуется выполнение соотношения $\alpha = 2a/a_0$, где a, a_0 – размеры элементов фото-приемника по строке и кадру соответственно, мкм. Основное достоинство ВТА – высокая

производительность аэросъемки – обусловливает необходимость обработки большого объема видеоинформации, что человеку-оператору обеспечить в режиме реального времени невозможно. Постобработка же изображений в камеральных условиях недопустимо увеличивает время получения результатов, и эффективность авиационного мониторинга объектов местности снижается.

Следовательно, во многих случаях к традиционным требованиям достаточно полного, достоверного и точного дешифрирования изображений добавляется еще одно – его своевременность, особенно существенное, например, при ведении воздушной разведки. Однако наиболее достоверное и полное чисто визуальное дешифрирование изображений этому требованию не удовлетворяет. Огромный объем поступающей информации, малое время, отводимое на анализ изображения и принятие решения, наличие различного рода геометрических, яркостных искажений и шумов, быстро меняющийся масштаб и угол визирования на анализируемый фрагмент нередко приводят к необходимости создания автоматизированных или автоматических систем дешифрирования, как стационарных, так и бортовых, позволяющих решать в режиме реального времени поставленные задачи. При этом в автоматических системах дешифрирования осуществляется весь цикл обработки изображений, включая распознавание объектов, а в автоматизированных – лишь наиболее времязатратные операции – поиск и обнаружение объектов; решение более сложной задачи их распознавания здесь возлагается на оператора, так как считается, что только он, подготовленный во всех отношениях, творчески анализирующий и суммирующий, хотя и приближенно, но зато большое количество факторов одновременно, способен обеспечить максимально достоверное и полное дешифрирование изображений и адекватная замена его автоматическими классификаторами пока недостижима.

В связи с изложенным, нашей задачей является практическая оценка, с учетом современных достижений науки и техники, сравнительной эффективности ВТА, использующей автоматизированное и автоматическое дешифрирование изображений.

Методика решения задачи

В динамическом режиме работы при поиске и вскрытии наземных объектов посредством ВТА предполагается, что ее носитель находится на фиксированной высоте H, км, и перемещается равномерно и прямолинейно со скоростью V, км/с, обеспечивая

беспропускный просмотр подстилающей поверхности в угле обзора 2β, град. Поскольку возможное местоположение объектов обычно неизвестно, при поиске закон их распределения на местности принимается равновероятным. Это означает, что вероятность нахождения объекта в фиксированный момент времени в определенной области зависит только от геометрических характеристик этой области, но не от ее местоположения в зоне поиска объекта. Такое допущение обеспечивает минимальный субъективизм получаемых оценок эффективности ВТА в условиях неполноты исходных данных.

Наиболее адекватным интегральным показателем эффективности ВТА, синтезирующим отмеченные выше требования к дешифрированию изображений, является интенсивность поиска, под которой понимается математическое ожидание числа объектов, вскрытых в единицу времени в начале поискового процесса, когда эта интенсивность максимальна. Данный показатель, в отличие от среднего времени поиска объектов, обычно рекомендуемого в литературе для использования в этой ситуации, существует всегда и не зависит от кинематики поиска (траектории движения носителя) [2].

При вскрытии постоянно существующих объектов и автоматизированном дешифрировании изображений можно записать для интенсивности поиска N, с$^{-1}$, следующее выражение [2]:

$$N = SP_{\Sigma}n; \quad P_{\Sigma} = P_{\text{п}}P_{\text{о}}P_{\text{д}}P; \quad S = HV\psi; \quad \psi = 2\text{tg}\beta, \qquad (1)$$

где S – площадь, обследуемая ВТА в единицу времени, км^2/с; n – средняя пространственная плотность объектов на местности, км$^{-2}$; P_{Σ} – результирующая вероятность вскрытия объекта; $P_{\text{п}}$ – вероятность прямого видения – вероятность того, что линия визирования «ВТА-объект» не будет перекрыта облачностью (в ясную погоду и/или при полете носителя ниже облачности $P_{\text{п}}$ = 1); $P_{\text{о}}$ – вероятность отбора автоматом фрагментов изображения, содержащих объект, характеризующая полноту дешифрирования; $P_{\text{д}}$ – вероятность дешифрирования – вероятность того, что оператору, смотрящему на выделенный в результате поиска фрагмент изображения с объектом, времени его наблюдения будет достаточно для возможного распознавания объекта; P – статическая вероятность распознавания – вероятность того, что оператор, наблюдая изображение объекта неограниченно долго, распознает его, – показатель достоверности дешифрирования; ψ – ширина полосы захвата ВТА в долях высоты.

В соответствии с известной операциональной моделью NVTherm [1], статическая вероятность P вскрытия посредством ВТА наземного объекта, усредненная по углу обзора, может быть оценена по формуле [2]:

$$P = 1 - \exp\left[-0{,}7\left(h\gamma / 2CA\varsigma\right)^2\right]; \quad A = H\delta / 2x; \quad x = \nu\delta, \tag{2}$$

где h – критический размер объекта – корень квадратный из его видимой площади, м; A – разрешение ВТА на местности, м (полупериод разрешаемой эквивалентной тепловой миры); ν – угловая частота этой миры, мрад$^{-1}$; x – относительная частота миры; C – критерий Джонсона для решаемой задачи вскрытия, в среднем равный 1 при обнаружении (выделении из фоновых неоднородностей), 3 при классификации (распознавании класса) и 6 при идентификации (распознавании типа) объектов; γ = 0,65-1,5 – показатель квалификации оператора (от низкой до высокой соответственно); δ – эффективное значение элементарного поля зрения ВТА, определяемое всем ее информационным трактом, мрад; ς – поправочный коэффициент, учитывающий снижение вероятности вскрытия объектов, расположенных на краях полосы захвата ВТА, вследствие увеличения расстояния до них.

При этом, как показывает анализ результатов [2], для объемных объектов, видимая площадь которых от угла их визирования, отсчитываемого от надира, почти не зависит, и плоских объектов, для которых она пропорциональна косинусу угла визирования, значение коэффициента ς в (2) приближенно равно

$$\varsigma = \begin{cases} \exp(1{,}4\cdot 10^{-3}\cdot 2\beta) & \text{(объемный);} \\ \exp(2{,}5\cdot 10^{-3}\cdot 2\beta) & \text{(плоский).} \end{cases} \tag{3}$$

Вероятность прямого видения $P_{\text{п}}$ в (1) есть вероятность оптического контакта ВТА с объектом в условиях облачности, определяемая в результате обобщения существующих статистических данных наблюдений за облачностью в том или ином регионе Земли. Имеющиеся сведения о высотном распределении облачности позволяют найти значения $P_{\text{п}}$ в зависимости от высоты наблюдения H, приведенные для некоторых регионов на рисунке 1 [3].

Угловая частота миры ν в (2) является корнем уравнения

$$\left|\Delta T_R\right|\tau_{\text{а}} = \Delta T_{\text{раз}}(\nu), \tag{4}$$

где ΔT_R – средний радиационный контраст объектов – средняя разность радиационных температур объектов и фона, К; $\tau_{\text{а}}$ – коэффициент пропускания атмосферы на трассе до объектов в спектральном рабочем диапазоне ВТА; $\Delta T_{\text{раз}}(\nu)$ – температурно-частотная

характеристика ВТА – зависимость разрешаемой с вероятностью 0,5 разности радиационных температур полос миры и фона от ее угловой частоты.

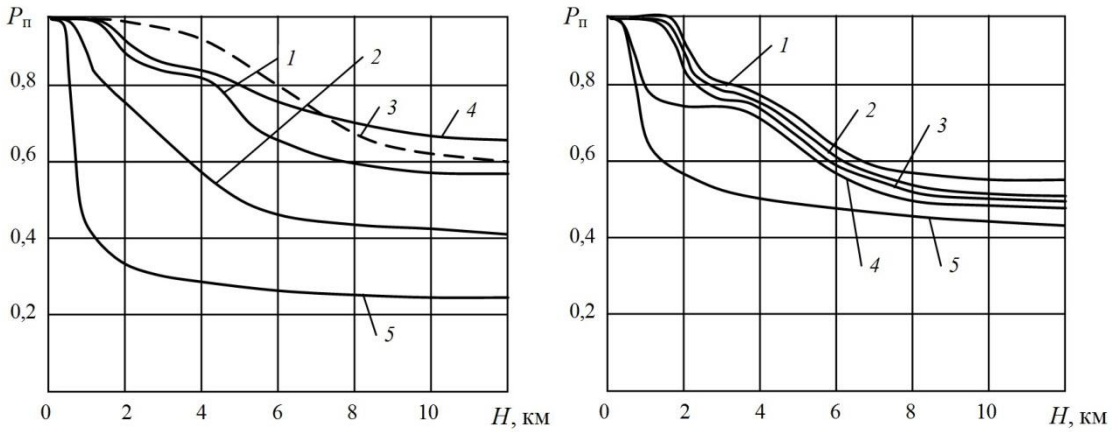

а *б*

Рисунок 1 – Зависимости вероятности прямого видения $P_п$ от высоты наблюдения: *а* – зимой; *б* – летом (*1* – Алтай, *2* – Подмосковье, *3* – Восточная Сибирь, *4* – Приморье, *5* – Центр. Европа)

Представленное в [2] общее выражение для эффективного значения элементарного поля зрения ВТА δ в данном случае имеет вид:

$$\delta = \delta_0 \vartheta; \quad \vartheta = \sqrt{0{,}7 + 0{,}25\theta^2}\ ;\ \theta = \sqrt{(0{,}84\, d_д / a_0)^2 + (d_a / a_0)^2}\ ;$$

$$d_д = 2{,}44\lambda_0/\omega;\ \delta_0 = a_0 / f\ , \qquad (5)$$

где $d_д$, d_a – диаметры дифракционного и аберрационного кружков рассеяния объектива соответственно с концентрацией энергии 85 %, мкм; λ_0 – средняя длина волны спектрального рабочего диапазона ВТА, мкм; f, ω – фокусное расстояние, мм, и относительное отверстие объектива соответственно; δ_0 – элементарное поле зрения ВТА по кадру, мрад.

Поскольку объекты поиска, как правило, локализованы на неоднородном фоне, а время их распознавания ограниченно, для эффективной работы ВТА требуется достаточно широкий диапазон регистрируемой разности температур $\Delta T_м$, К, необходимый для обеспечения вскрытия объектов с положительным или отрицательным радиационным контрастом, расположенных соответственно на горбах или впадинах температурных фоновых неоднородностей. При этом ВТА работает в контрастно-ограниченном режиме, характерном для современной высокочувствительной аппаратуры, эффективность которой лимитируется контрастной чувствительностью зрительного анализатора оператора, так

как видимый шум на изображении отсутствует (детальный анализ означенной ситуации дан в [4]), и указанный диапазон рекомендуется принимать равным

$$\Delta T_{\text{м}} = \Delta T_{\text{м0}} \tau_{\text{а}} , \qquad (6)$$

где $\Delta T_{\text{м0}}$ – максимально возможное значение $\Delta T_{\text{м}}$: $\Delta T_{\text{м0}}$ = 20 К (день, ясно) или 10 К (ночь, ясно).

Относительная частота x в (2) с учетом (4), (6) может быть найдена при использовании общей для всех образцов ВТА температурно-частотной характеристики в относительных единицах $E(x)$, которая описывается формулой [2, 4]:

$$E(x) = \frac{4K_{\text{м}}\Delta T_{\text{раз}}}{\pi \Delta T_{\text{м}}} = \frac{4K_{\text{м}}|\Delta T_R|}{\pi \Delta T_{\text{м0}}} = \mu \exp\left[\left(\left(\frac{305\xi\delta_0^2}{\Delta\delta'^2\delta^2}\right)+6\right)x^2\right];$$

$$K_{\text{м}} = (L'_2 - L'_1)/(L'_2 + L'_1) = 1 - L'_1/L'; \quad L' = (L'_2 + L'_1)/2,$$

где L'_1, L'_2, L' – минимальная, максимальная и средняя рабочие яркости изображения соответственно, кд/м^2 (можно принять [1]: L' = 100 кд/м^2 при дешифрировании изображения на свету, L' = 3-30 кд/м^2 – в полутьме, L' = 0,3-1 кд/м^2 – в темноте); $K_{\text{м}}$ – коэффициент сохранения контраста для протяженного объекта, обычно близкий к 0,95; $\Delta\delta'$ – размер элемента изображения, соответствующего δ_0 (далее принимаем оптимальное значение $\Delta\delta'$ = 0,95 мрад); μ, ξ – параметры аппроксимации так называемой функции порогового контраста, характеризующей контрастную чувствительность зрительного анализатора оператора (таблица 1).

Таблица 1 – Значения μ и ξ для различной средней яркости изображения L'

Задача вскрытия		L' = 0,6 кд/м^2	L' = 1 кд/м^2	L' = 3 кд/м^2	L' = 10 кд/м^2	L' = 30 кд/м^2	L' = 100 кд/м^2
Обнаружение	μ	0,090	0,075	0,053	0,036	0,026	0,021
	ξ	0,005	0,004	0,0025	0,0015	0,00096	0,0006
Классификация	μ	0,032	0,027	0,019	0,014	0,010	0,0084
	ξ	0,0062	0,0052	0,0036	0,0026	0,0018	0,0015
Идентификация	μ	0,019	0,016	0,012	0,008	0,0053	0,0042
	ξ	0,0075	0,0065	0,0049	0,0035	0,0028	0,0023

Отсюда получаем выражение для относительной частоты x:

$$x = \sqrt{\frac{\ln\left[1{,}3K_{\text{м}}|\Delta T_R|/\mu\Delta T_{\text{м0}}\right]}{6 + 340\xi/\vartheta^2}} . \qquad (7)$$

В автоматизированных системах распознавания для поиска и выделения обычно слабоконтрастных или размытых изображений объектов местности, которые затем предъявляются оператору-дешифровщику для их распознавания, может быть использован целый ряд алгоритмов, представленных, например, в [5]. Одной из наиболее простых и, вместе с тем, достаточно эффективных является следующая практически апробированная процедура [6]. Она использует цифровой пространственный фильтр, скользящий по изображению, состоящий из трех окон: центрального, внутреннего, форматом $k \times k$ пикселов, несколько меньшим минимального размера обнаруживаемого объекта; среднего, имеющего размеры $l \times l$, несколько большие максимального размера объекта; внешнего форматом $(2l+1) \times (2l+1)$ (рисунок 2).

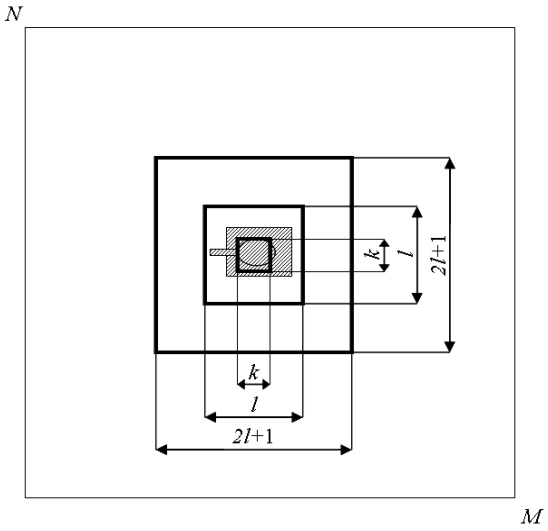

Рисунок 2 – Пространственный фильтр для реализации алгоритма обнаружения объекта

Поэтому при оптимальной локализации фильтра относительно объекта его границы находятся в среднем окне, центральное окно полностью заполнено объектом, а внешнее содержит только фон. Для центрального и внешнего окна вычисляются значения средней яркости изображения $L_0(p,q)$ и $L(p,q)$ в зависимости от пространственных координат p,q, среднеквадратические отклонения этой яркости $\sigma_0(p,q)$ и $\sigma(p,q)$ и соответствующая метрика $F(p,q)$:

$$F(p,q) = L_0(p,q) - L(p,q); \quad L_0(p,q) = \frac{1}{k^2}\left(\sum_{i=-(k-1)/2}^{(k-1)/2} \sum_{j=-(k-1)/2}^{(k-1)/2} L(p+i, q+j) \right);$$

$$L(p,q) = \frac{1}{(2l+1)^2 - l^2}\left(\sum_{i=-l}^{l} \sum_{j=-l}^{l} L(p+i, q+j) - \sum_{i=-(l-1)/2}^{(l-1)/2} \sum_{j=-(l-1)/2}^{(l-1)/2} L(p+i, q+j) \right);$$

$$\sigma_0(p,q) = \left[\frac{1}{k^2}\left(\sum_{i=-(k-1)/2}^{(k-1)/2} \sum_{j=-(k-1)/2}^{(k-1)/2} (L(p+i, q+j) - L_0(p,q))^2 \right) \right]^{1/2};$$

$$\sigma(p,q) = \left[\frac{1}{(2l+1)^2 - l^2}\left(\sum_{i=-l}^{l} \sum_{j=-l}^{l} \big(L(p+i, q+j) - L(p,q)\big)^2 - \right.\right.$$

$$\left.\left. - \sum_{i=-(l-1)/2}^{(l-1)/2} \sum_{j=-(l-1)/2}^{(l-1)/2} \big(L(p+i, q+j) - L(p,q)\big)^2 \right) \right]^{1/2}.$$

Решение о наличии объекта в центральном окне принимается, если решающая функция $G(p,q)$ превышает некоторый пороговый уровень $G_{\text{пор}}$:

$$G(p,q) = \frac{|F(p,q)|}{\sqrt{\sigma_0^2(p,q) + \sigma^2(p,q)}} > G_{\text{пор}}.$$

При ручной настройке данного алгоритма на тестовых изображениях объектов подбирают оптимальные значения k и l, а также порогового уровня $G_{\text{пор}}$. Основной объем вычислений здесь приходится на поэлементный перебор областей изображения размером $(2l+1) \times (2l+1)$, соответствующая скорость обработки составляет несколько сотен кадров, форматом 576 × 576 элементов, в секунду. Как показало имитационное моделирование, этот алгоритм обеспечивает вероятность $P_{\text{о}}$ отбора фрагментов с объектами, расположенными на локально квазиоднородных фонах (т.е. не вплотную к фоновым неоднородностям), близкую к 1.

В качестве примера на рисунке 3*а* приведено синтезированное на компьютере методом, описанном в [7], поле энергетической яркости местности с расположенным на ней малоконтрастным объектом-танком. Соответствующее выходное изображение поля, полученное после прохождения его через информационный тракт ВТА, развертываемое на мониторе, дано на рис. 3*б*. Выделенный фрагмент изображения местности, содержащий объект, представлен, после его увеличения и усиления контраста, в виде врезки в изображение, которая и предъявляется оператору для распознавания этого объекта.

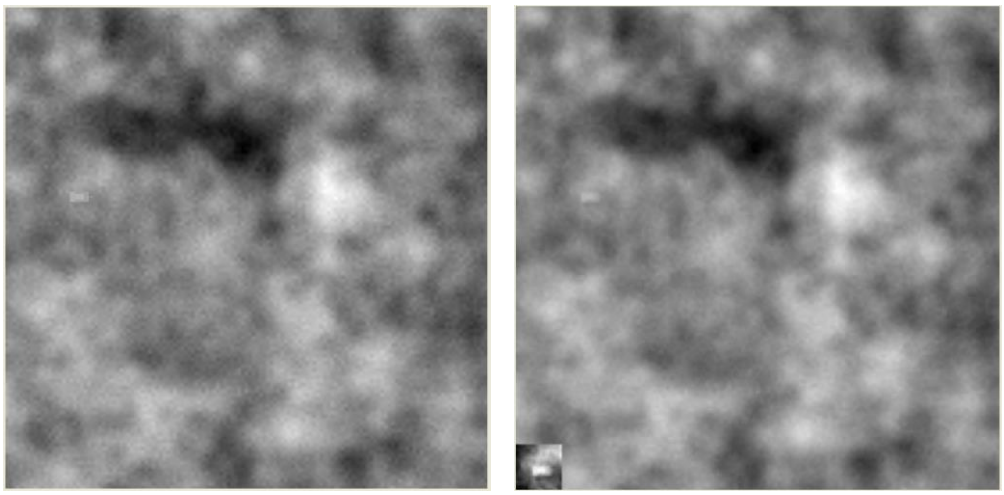

а *б*

Рисунок 3 – Синтезированное изображение: *а* – синтезированное поле энергетической яркости местности, *б* – выходное изображение ВТА с выделенным фрагментом с объектом

Хотя операция поиска и отбора отмеченных фрагментов изображения производится автоматом практически мгновенно, ресурс времени наблюдения оператором этого фрагмента изображения конечен и случаен, ибо по мере анализа изображений местности предъявляемые оператору фрагменты изображения с объектом будут заменяться в том же темпе все новыми и новыми. Поток этих фрагментов можно считать простейшим (стационарным пуассоновским).

Для оценки вероятности дешифрирования $P_д$ в (1) воспользуемся так называемой психометрической функцией $P_д(t)$ – зависимостью вероятности решения зрительной задачи от величины зрительного стимула, здесь – от времени t наблюдения фрагмента с объектом. Экспериментально установлено [8], что эта функция хорошо описывается выражением вида

$$P_д(t) = 1 - \exp(-\alpha_0^2 t^2),$$

где параметр α_0, $с^{-1}$, определяется из условия, что при t, равном среднему времени t_0 вскрытия объекта, значение $P_д(t) = 0{,}5$: $\alpha_0 = 0{,}83/t_0$.

Поэтому вероятность дешифрирования за время t, с, составляет

$$P_д(t) = 1 - \exp(-0{,}69 t^2 / t_0^2).$$

Анализ известных литературных данных позволяет рекомендовать для использования при решении задач вскрытия объектов следующие значения t_0, с:

$$t_0 = \begin{cases} 1/\gamma & \text{– при обнаружении;} \\ 2/\gamma & \text{– при классификации;} \\ 3/\gamma & \text{– при идентификации.} \end{cases} \qquad (8)$$

Для простейшего потока фрагментов интервал времени между ними, который и является временем наблюдения t, подчиняется показательному закону с плотностью вероятности [9]

$$w(t) = \lambda \exp(-\lambda t); \quad \lambda = nS,$$

где λ – средняя временная плотность потока, $с^{-1}$.

При этом под n понимается средняя суммарная плотность реальных и ложных объектов – объектоподобных элементов фона, фрагменты с которыми также отбираются автоматом.

Тогда средняя вероятность дешифрирования $P_д$ определится выражением:

$$P_д = \int_0^\infty P_д(t) w(t) dt = 1 - 1{,}07\lambda t_0 \exp(0{,}36\lambda^2 t_0^2)\left[1 - \Phi(0{,}85\lambda t_0)\right];$$

$$\Phi(z) = \frac{2}{\sqrt{2\pi}} \int_0^z \exp(-t^2/2) dt \approx \sqrt{1 - \exp(-0{,}63z^2)},$$

где $\Phi(z)$ – интеграл вероятности и его аппроксимация (для $z \geq 0$).

Расчетная зависимость $P_д = f(\lambda t_0)$ приведена ниже:

λt_0	0	0.2	0,5	1	1,5	2	3
$P_д$	1	0,78	0,60	0,39	0,28	0,19	0,11.

Эта зависимость хорошо аппроксимируется простой формулой: $P_д = \exp(-\lambda t_0)$.

Следовательно, выражение (1) для показателя эффективности N можно переписать так:

$$N = HVP_\Sigma \psi n; \quad P_\Sigma = P_п P \exp\left(-HV\psi n t_0\right). \qquad (9)$$

Установим значение $H_m V_m$ произведения высоты и скорости носителя HV, при котором величина N достигает максимума N_m. Из решения уравнения $dN/d(HV) = 0$ находим:

$$H_m V_m = 1/\psi n t_0 .$$

Подставляя это значение обратно в (9), получаем:

$$N_m = 0{,}37 P_п P / t_0 . \qquad (10)$$

Однако результирующая вероятность вскрытия объекта P_Σ в (9) при этом составляет лишь $P_{\Sigma m} = P_п P \exp(-1) = 0{,}37 P_п P$, т.е. никогда не превышает 0,37, в то время

как при использовании ВТА, как правило, требуется, чтобы значение P_Σ было не ниже некоторого минимума P_Σ^*, обычно 0,8. Тогда, принимая в (9) $P_\Sigma = P_\Sigma^*$, находим оптимальное для этого случая значение H^*V^* произведения высоты и скорости носителя, меньшее H_mV_m:

$$H^*V^* = \ln\left(P_\text{п}P/P_\Sigma^*\right)/\psi n t_0 , \qquad (11)$$

и соответствующую интенсивность поиска N^*:

$$N^* = P_\Sigma^* \ln\left(P_\text{п}P/P_\Sigma^*\right)/t_0 .$$

Видно, что при $P_\text{п}P > P_\Sigma^*$ (иначе величина P_Σ^* недостижима) величина N^* всегда меньше значения N_m, определяемого по (10), см. рисунок 4.

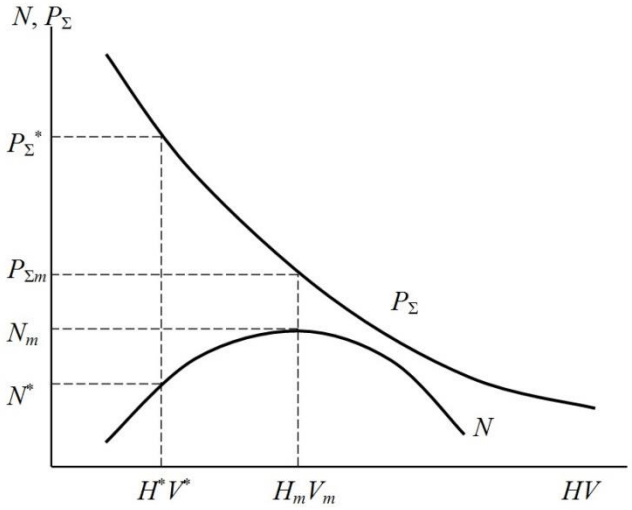

Рисунок 4 – Схематические зависимости $N = f(HV)$ и $P_\Sigma = f(HV)$

При этом для максимизации интенсивности поиска N^* высота носителя ВТА должна быть минимальной, чтобы произведение $P_\text{п}P$ было как можно ближе к 1. Следует, однако, учитывать, что параметры полета носителя H и V всегда подчинены определенным техническим и/или ситуационным ограничениям: $H_\text{min} \le H \le H_\text{max}$, $V_\text{min} \le V \le V_\text{max}$, причем величина V_max зависит в том числе от быстродействия автомата отбора фрагментов, характеризуемого числом элементов изображения n_0, с^{-1}, обработанных в единицу времени. Это означает, что скорость анализа изображений, составляющая

$$n_0 = \frac{V}{10^{-3} H\delta_0/2} \times \frac{17{,}45 \cdot 2\beta}{\delta_0/2} = \frac{70 \cdot 10^3 V \cdot 2\beta}{H\delta_0^2},$$

не должна превышать некоторое предельное значение n_max. Отсюда получаем:

$$V_\text{max} = 1{,}4 \cdot 10^{-5} n_\text{max} H\delta_0^2/2\beta .$$

Из изложенного вытекает, что при значениях высоты носителя H и соответствующей, согласно (9), скорости V, равных

$$H = H_{\min}; \quad V = \ln\left(P_{\text{п}} P / P_{\Sigma}^{*}\right) / \psi n t_0 H , \tag{12}$$

возможны следующие случаи:

1. $V < V_{\min}$. Тогда оптимальные значения высоты и скорости носителя составляют $H^{*} = H_{\min}$ и $V^{*} = V_{\min}$ (зависимость $V = f(H)$ № 1 и точка A на рис. 5). При этом, по (9), при $H = H^{*}$ и $V = V^{*}$ для результирующей вероятности вскрытия объекта P_{Σ} и интенсивности поиска N выполняются соотношения: $P_{\Sigma} < P_{\Sigma}^{*}$ и $N > N^{*}$ (требуемое значение P_{Σ}^{*} здесь недостижимо).

2. $V_{\min} \le V \le V_{\max}$. Тогда оптимальные значения высоты и скорости носителя составляют $H^{*} = H_{\min}$ и $V^{*} = V$ (зависимость $V = f(H)$ № 2 и точка B на рис. 5). При этом достигаются значения: $P_{\Sigma} = P_{\Sigma}^{*}$ и $N = N^{*}$.

3. $V > V_{\max}$. Тогда следует принять $V = V_{\max}$ и решить относительно искомой высоты H уравнение (12), например, методом подбора (в качестве первоначального значения H_1 высоты можно принять $H_1 = \ln(1/P_{\Sigma}^{*})/\psi n t_0 V$), для которой выполняется одно из следующих соотношений:

а) $H_{\min} \le H \le H_{\max}$. Тогда оптимальные значения высоты и скорости составляют $H^{*} = H$ и $V^{*} = V_{\max}$ (зависимость $V = f(H)$ № 3 и точка C на рисунок 5). При этом достигаются значения: $P_{\Sigma} = P_{\Sigma}^{*}$ и $N = N^{*}$;

б) $H > H_{\max}$. Тогда оптимальные значения высоты и скорости составляют $H^{*} = H_{\max}$ и $V^{*} = V_{\max}$ (зависимость $V = f(H)$ № 4 и точка D на рисунок 5). При этом выполняются соотношения: $P_{\Sigma} > P_{\Sigma}^{*}$ и $N < N^{*}$.

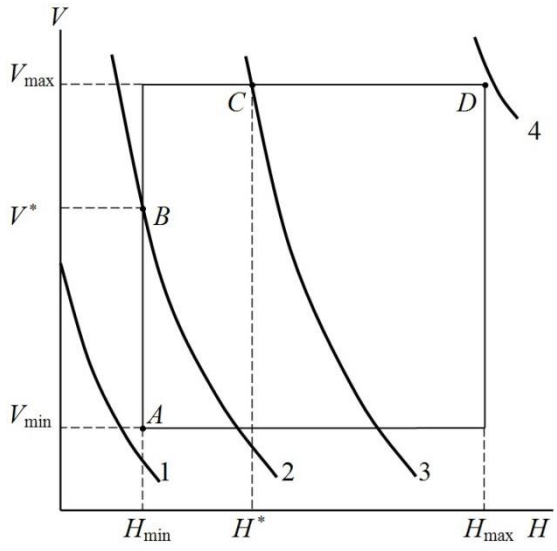

Рисунок 5 – К выбору оптимальных значений параметров полета носителя ВТА

При описании данного алгоритма оптимального выбора высоты и скорости носителя ВТА предполагается, что угловая скорость сканирования в ней может варьироваться, обеспечивая, при условии беспропускного просмотра местности, требуемые значения H и V. Если же эта скорость фиксирована, то выбор данных значений должен производиться по методике, аналогичной изложенной выше, при дополнительном ограничении $V/H = \rho = \text{const}$. Тогда, с учетом (11), находим соответствующие значения H и V:

$$H = \sqrt{\frac{\ln\left(P_{\text{п}} P / P_{\Sigma}^{*}\right)}{\rho \psi n t_0}}; \quad V = \rho H ,$$

и если эти значения удовлетворяют соотношениям $H_{\min} \le H \le H_{\max}$, $V_{\min} \le V \le V_{\max}$, то они и являются оптимальными: $H^{*} = H$ и $V^{*} = V$. Если же эти соотношения не выполняются, то выбираются соответствующие значения $H^{*} = H_{\min}$ или $H^{*} = H_{\max}$ и $V^{*} = \rho H^{*}$ или же $V^{*} = V_{\min}$ или $V^{*} = V_{\max}$ и $H^{*} = V^{*}/\rho$.

Отметим, что для несканирующей ВТА, использующей субматрицу с длинными приемными линейками, ориентированными перпендикулярно движению носителя (способ просмотра местности pushbroom – «загребание»), указанное дополнительное ограничение не возникает.

В автоматических системах дешифрирования для поиска и вскрытия объектов применяются алгоритмы распознавания, которые по методу подбора параметров фильтров и правил решения можно разделить на алгоритмы с ручной настройкой параметров (она имеет место и в автоматизированных системах дешифрирования) и алгоритмы на основе сверточных нейронных сетей (СНС).

Алгоритмы распознавания с ручной настройкой параметров используются в случаях, когда оператор может подобрать методы и способы обработки изображений для выявления демаскирующих признаков объектов и сформулировать правила для распознавания объектов по этим признакам. Здесь следует сформировать четкую математическую модель изображений объектов заданных классов, что часто представляет собой довольно сложную и времязатратную задачу. К основным достоинствам данных алгоритмов можно отнести высокую обозримость и качество дешифрирования при решении некоторых узкоспециализированных задач, отсутствие необходимости большого количества

изображений эталонных объектов. Однако их недостатком является трудоемкость поиска методов выделения характерных дешифровочных признаков изображений и низкое качество дешифрирования даже при незначительных отклонениях параметров этих изображений (размера, формы, поворота и др.) от расчетных и при вариациях условий картографирования. Существенным ограничением в их использовании также является чрезмерная чувствительность к изменению масштаба изображения, в связи с чем необходимо строго выдерживать требуемую высоту аэросъемки.

Важнейшим демаскирующим признаком объекта, используемым в системах технического зрения с ручной настройкой параметров, является его форма. Хотя математически строгое понятие формы объектов до сих пор отсутствует, отдельные стороны, признаки этой формы могут характеризоваться целым рядом метрик – дешифровочных признаков изображений [2]:

- отношение толщины (коэффициент формы) $T = 4\pi S_{об}/P_{пер}^2$, где $S_{об}$ – площадь объекта, ограниченная его периметром $P_{пер}$;

- отношение аспекта (вытянутость) $A = D_{max}/D_{min}$, где D_{max}, D_{min} – максимальный и минимальный диаметры вписанной и описанной окружностей соответственно;

- коэффициент симметрии $C = S_{пер}/S_о$, где $S_{пер}$, $S_о$ – площади пересечения и объединения объекта и его симметричного отображения относительно некоторой оси;

- коэффициент округлости (компактности) $O = 4S_{об}/\pi D^2_{min}$;

- коэффициент выпуклости $B = P_{min}/P_{пер}$, где P_{min} – минимальный периметр описанной окружности;

- коэффициент заполненности (сплошности) $З = 1 – S_{пус}/S_{об}$, где $S_{пус}$ – площадь «пустот» внутри периметра объекта.

Очевидно, значения этих метрик всегда находятся в пределах 0-1.

При автоматическом дешифрировании изображений вероятность дешифрирования $P_д$ в (1) близка к единице, однако статическая вероятность вскрытия P, напротив, обычно значительно меньше, чем при автоматизированном. Так, выполненное авторами [10] сравнение эффективности визуального и автоматического распознавания зашумленных изображений стилизованных объектов простой геометрической формы показало, что использование для автоматического дешифрирования набора метрик изображений объектов, состоящего из отношения толщины, коэффициента симметрии, отношения аспекта и коэффициента выпуклости, в сочетании с предварительной обработкой

изображений (увеличение + интерполяция) приближает вероятность автоматического распознавания этих объектов, равную 0,76, к вероятности визуального распознавания, составляющей 0,86. Это означает, что в случае автоматического распознавания подобных объектов при оценке величины *P* по (2) значения показателя γ не превышают $\gamma_{авт} = 1{,}25$ (по сравнению с величиной γ = 1,5 для высококвалифицированного оператора). Можно полагать, что при автоматическом дешифрировании изображений реальных объектов с использованием традиционных метрик это значение γ будет близко к $\gamma_{авт} = 1$, что отвечает оператору средней квалификации.

Алгоритмы распознавания на основе СНС особенно эффективны, когда имеется большой набор обучающих данных с изображениями объектов заданных классов в различных положениях на снимках и при разных уровнях их контраста. При этом строгая формализация математической модели изображений объектов не требуется, как не требуется и ручная настройка фильтров для выделения дешифровочных признаков изображений. Это связано с тем, что многослойная структура СНС подстраивается автоматически за счет изменения весовых коэффициентов в процессе обучения нейросетевой модели алгоритма. Для формирования больших наборов обучающих данных с изображениями объектов заданных классов часто прибегают к так называемой аугментации изображений – генерации новых изображений, подвергая имеющиеся в распоряжении изображения и их фрагменты различным преобразованиям гистограммы, геометрическим изменениям – таким, как растяжение, развороты и повороты; также выполняют объединение фрагментов из различных изображений в новое изображение и многие другие преобразования. Основные достоинства алгоритмов на основе СНС заключаются в их устойчивости к изменению размеров, формы, положения объектов, контраста изображения, отсутствии необходимости участия человека в подборе параметров алгоритмов, а также в достаточно высокой достоверности дешифрирования.

Этапы решения задачи вскрытия объектов с ручной настройкой параметров и с применением СНС приведены на рисунках 6 и 7 соответственно. Сравнительные характеристики этих алгоритмов представлены в таблице 2.

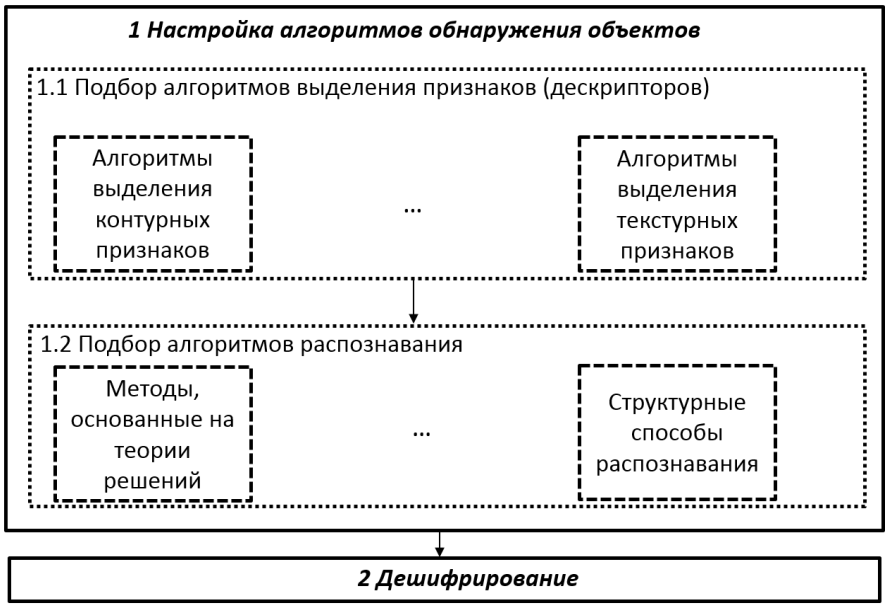

Рисунок 6 – Основные этапы решения задачи вскрытия объектов с ручной настройкой параметров

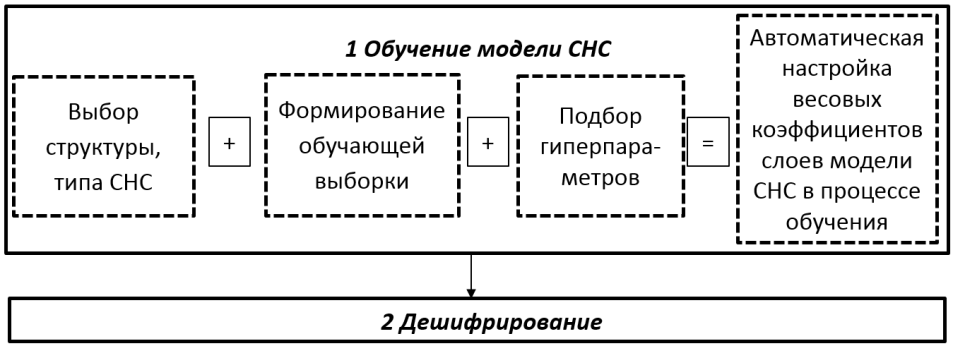

Рисунок 7 – Основные этапы решения задачи вскрытия объектов с применением СНС

Таблица 2 – Сравнительная оценка алгоритмов дешифрирования изображений объектов

Тип алгоритма	Участие человека в подборе параметров алгоритмов	Наличие большого набора обучающих данных	Устойчивость к изменению размеров объектов, контраста
С ручной настройкой	Да	Нет	Нет

На основе СНС	Нет	Да	Да

При решении задач, связанных с обнаружением точечных объектов, в системах дешифрирования на базе СНС, как правило, применяются детектирующие алгоритмы [11]. Для распознавания протяженных объектов используются алгоритмы семантической сегментации [12]. Принципы построения алгоритмов распознавания на основе СНС непрерывно совершенствуются с целью повышения качества дешифрирования и сокращения времени обработки изображений. Поэтому все эти алгоритмы имеют множество различных модификаций, однако в основе обоих типов алгоритмов лежит общий принцип – извлечение дешифровочных признаков из изображений с применением сверточных слоев [13], точнее – сверточной части нейронной сети (сверточной основы), которая состоит из нескольких следующих друг за другом сверточных блоков, включающих сами сверточные слои, слои подвыборки, нормализации и некоторые другие типы слоев, отвечающие за дополнительные преобразования.

Количество блоков от входного слоя до последнего может достигать нескольких десятков. При обработке изображения размер первого сверточного слоя первого блока соответствует размеру самого изображения. По мере прохождения от первого слоя вглубь сверточной сети значения ширины и высоты исходного изображения уменьшаются. На выходе каждого сверточного слоя формируется выходная карта признаков данного слоя, являющаяся результатом обработки карты признаков, поступившей с предыдущего слоя. Карта признаков представляет собой трехмерный массив (тензор) с соответствующими значениями высоты, ширины и количества каналов. Количество каналов определяет число цифровых фильтров – ядер свертки, входящих в состав сверточного слоя, и представляющих собой двумерные маски обычно размером 1 × 1, 3 × 3, 5 × 5 или 7 × 7 элементов. В каждом сверточном слое фильтры перемещаются по входной карте признаков с заданным шагом, формируя карту признаков (откликов на фильтр). Так, фильтры первого сверточного слоя перемещаются непосредственно по пикселам самого изображения, и на каждом шаге фильтра выполняется операция его свертки с соответствующими элементами изображения, в результате чего формируется карта признаков для следующих сверточных слоев.

Слои подвыборки уменьшают размеры (ширину и высоту) карты признаков за счет перемещения окна размером, например, 2 × 2 элемента по двумерной карте признаков с выбором одного из четырех элементов с максимальным его значением. Эта операция

позволяет сохранить наиболее важные признаки, уменьшить чувствительность к сдвигам и деформациям изображений объектов заданных классов, а также позволяет построить иерархию фильтров для просмотра более крупных окон с точки зрения долей исходных данных, которые они охватывают, и извлекать признаки различных частотных составляющих карт признаков.

Процесс обучения СНС, как детектирующих алгоритмов, так и алгоритмов семантической сегментации, можно представить в виде последовательных шагов, в результате которых веса фильтров – значения элементов масок – обновляются с применением алгоритма обратного распространения ошибки и оптимизационных методов, таких, как градиентный спуск. Для обучения СНС формируется обучающая выборка из изображений с заранее известными ответами в виде разметки, выполненной оператором-экспертом. Разметка осуществляется обрамлением границ объектов прямоугольной областью – для детектирующих алгоритмов, либо отнесением каждого пиксела изображения к одному из известных классов объектов – для алгоритмов семантической сегментации, с сохранением результатов разметки в отдельных файлах. На первом этапе обучения параметры фильтров инициализируются случайным образом. Обучение состоит из множества итераций. В процессе каждой итерации изображения из обучающей выборки проходят через фильтры сверточных слоев, вычисляются отклики на свертку и тем самым после каждого слоя создается карта признаков для следующего сверточного слоя. При прохождении всех слоев, включая специальные для каждого типа алгоритма, в СНС формируется ответ, который сравнивается с разметкой, выполненной оператором, и с учетом расчетного градиента функции потерь, вычисляемого на основе разности полученного ответа и истинного значения, изменяются параметры фильтров в обратном направлении от последнего слоя к первому. Процесс обучения повторяется до тех пор, пока модель СНС не достигнет приемлемого уровня точности ответов, либо не будет достигнуто заданное количество итераций.

Исследование возможности применения некоторых детектирующих нейросетевых алгоритмов выполнено в работе [11], где по результатам исследования в качестве наиболее универсального алгоритма определен алгоритм на основе нейронной сети YOLO v4 Tiny, продемонстрировавший в тестах наивысшие показатели скорости и достоверности. Примеры изображений с результатами вскрытия этим нейросетевым алгоритмом объектов класса «building (строение)», «car (автомобиль)» и «fence

(ограждение)» приведены на рисунке 8 (цифры на рисунке указывают на вероятность распознавания объектов).

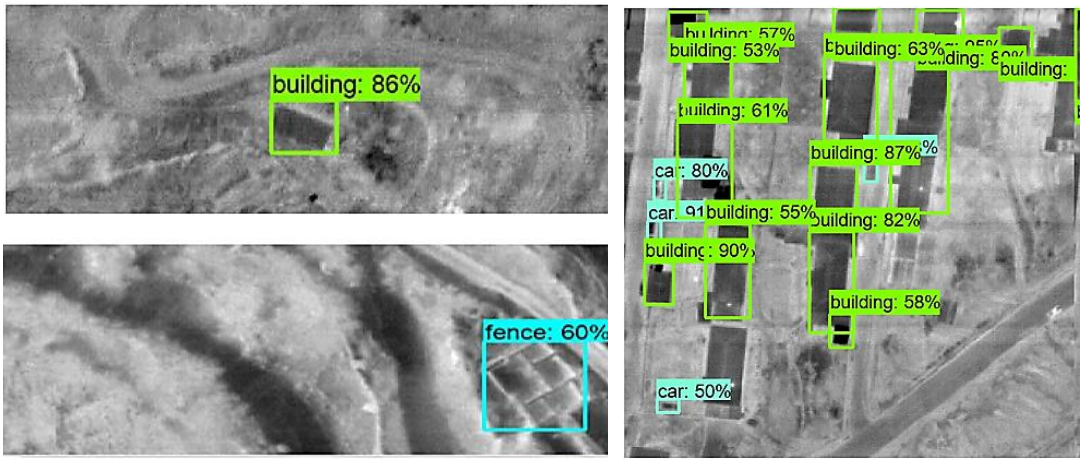

Рисунок 8 – Примеры вскрытия объектов с применением нейросетевого алгоритма YOLO v4 Tiny

При визуальной оценке человеком-оператором результатов обнаружения объектов вышеуказанных классов следует отметить, что в большинстве случаев данный нейросетевой алгоритм ложно выделял или ложно пропускал изображения объектов, которые имели форму более сложную по сравнению с типовой, представленной в обучающем наборе изображений, либо изображение объекта было близким по ключевым признакам к изображению объектов одного из трех заданных классов или же к изображениям фоновых неоднородностей.

На рисунке 9*а* представлено изображение двух близко расположенных объектов класса «строение», выделенных человеком-оператором как два объекта, в то время как нейросетевой алгоритм выделил их как один объект (рисунок 9*б*). На рисунке 9*б* также дан пример ложного выделения нейросетевым алгоритмом изображения объекта класса «ограждения».

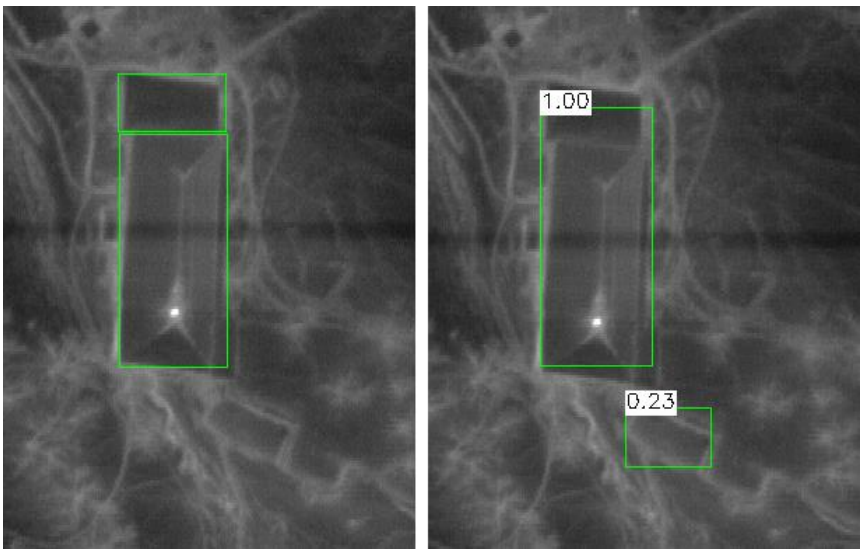

а *б*

Рисунок 9 – Изображение двух близко расположенных объектов: *а* – пример изображения объектов, выделенных оператором, *б* – пример изображения объектов, выделенных нейросетевым алгоритмом

В случае визуального просмотра несколькими операторами-экспертами ложно выделенных либо ложно пропущенных алгоритмом изображений объектов степень принадлежности изображений этих объектов к одному из данных классов также трактовалась разными операторами-экспертами по-разному. Один из алгоритмов семантической сегментации, DL_Xception_4, демонстрирующий достаточно высокое соотношение скорости обработки и качества распознавания, описан в работе [12]. При визуальной оценке результатов выполнения семантической сегментации этим алгоритмом объектов с резкими границами по сравнению с более точным, но существенно более медленным исходным алгоритмом DeepLabv3+, их различие не заметно, однако для объектов с нечеткими границами это различие выражено в виде менее плавных переходов и небольших разрывов контуров объектов, что не оказывает существенного влияния на качество распознавания при визуальной оценке результатов дешифрирования (рисунок 10).

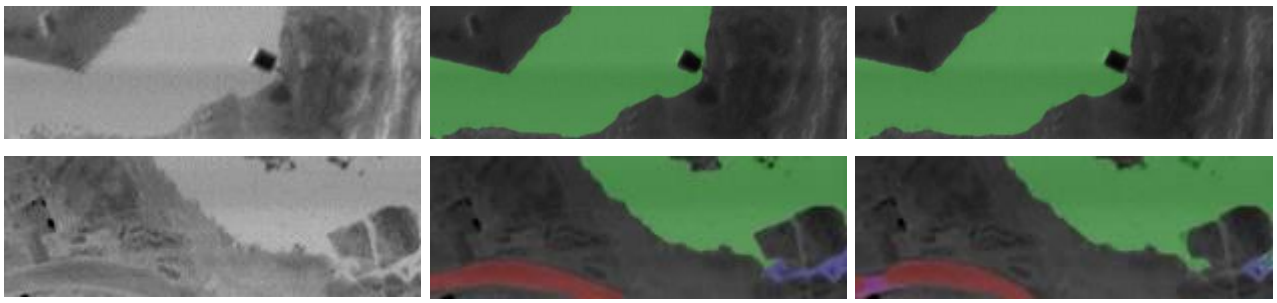

а *б* *в*

Рисунок 10 – Сегментация алгоритмами: *а* – исходные изображения, *б* – семантическая сегментация алгоритмом DeepLab, *в* – семантическая сегментация разработанным методом DL_Xception_4

Анализ результатов работ [11, 12] показывает, что означенные алгоритмы на основе СНС позволяют решать задачи автоматического дешифрирования изображений с эффективностью, соответствующей оператору повышенной квалификации ($\gamma_{авт}$ = 1,25). Эти алгоритмы настраивают на оптимальное соотношение ошибок первого и второго рода с целью установления баланса между количеством ложноположительных (ложное срабатывание, обнаружение несуществующего объекта) и ложноотрицательных ответов (пропуск искомого объекта, когда он остается нераспознанным).

При автоматическом дешифрировании изображений интенсивность поиска N и результирующая вероятность вскрытия P_Σ объектов определяются по (9) при $t_0 = 0$:

$$N = HVP_\Sigma \psi n; \quad P_\Sigma = P_п P\,. \tag{13}$$

Вполне очевидно, что оптимальное значение H^* высоты носителя здесь является корнем уравнения (2) при $P_\Sigma = P_\Sigma^*$:

$$H^* = \frac{h\gamma x}{1{,}2C\delta\varsigma\sqrt{-\ln(1-P_\Sigma^*)}}\,,$$

а его скорости $V^* = V_{max}$.

Примерное качественное соотношение эффективности автоматизированного и автоматического дешифрирования изображений схематически представлено на рис. 11 в виде зависимостей $P_\Sigma = f(V)$ результирующей вероятности вскрытия объектов от скорости носителя V для двух значений суммарной средней плотности объектов на местности n ($n_2 > n_1$).

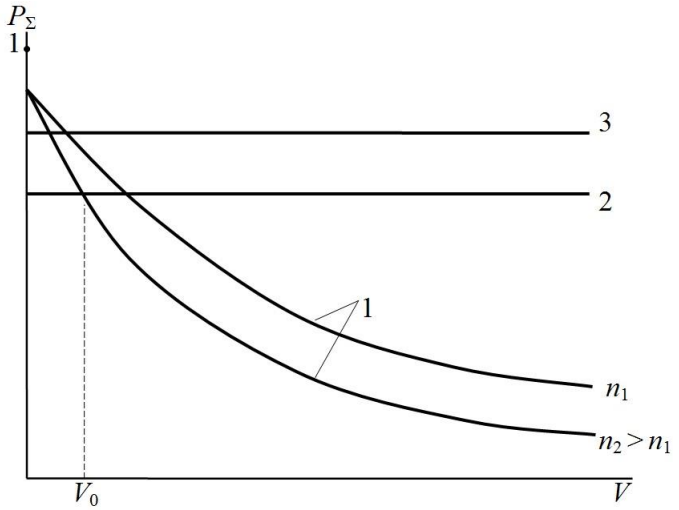

Рисунок 11 – Зависимости результирующей вероятности вскрытия объектов от скорости носителя ВТА при автоматизированном (*1*) и автоматическом дешифрировании с ручной настройкой параметров (*2*) и с использованием СНС (*3*)

Видно, что при малых скоростях носителя V, не превышающих некоторого порогового значения V_0, и фиксированной высоте носителя наибольшую результирующую вероятность вскрытия объектов обеспечивает автоматизированное дешифрирование изображений, а при более высоких скоростях – автоматическое. Это значение V_0, согласно (2), (9), определяется формулой (для $\gamma \geq \gamma_{авт}$):

$$V_0 = \frac{1}{H\psi n t_0} \ln\left[\frac{1-\exp[-(0{,}7(h\gamma / 2CA\mu)^2]}{1-\exp[-(0{,}7(h\gamma_{авт} / 2CA\mu)^2]}\right].$$

Следует подчеркнуть, что модель (2) для вероятности распознавания объектов при автоматизированном дешифрировании изображений предполагает учет лишь прямых демаскирующих признаков объектов – их формы и радиационного контраста. Между тем в сложных случаях вскрытия объектов на неоднородном фоне, особенно замаскированных, решающее значение может иметь контекст, знание свойств объектов, их окружения, возможных сцен и ситуаций, другими словами – косвенных демаскирующих признаков объектов, использование которых при визуальном дешифрировании может быть весьма продуктивным. Однако при автоматизированном дешифрировании изображений в режиме реального времени отмеченное обстоятельство обычно большого значения не имеет в связи с дефицитом времени наблюдения выделенных фрагментов изображения с объектами, составляющим в среднем $1/\lambda$, и сравнительно малыми размерами данных фрагментов, затрудняющими анализ окрестности объектов.

Пример расчета

Сравним эффективность вертолетной ВТА (спектральный рабочий диапазон 8-12 мкм, угол обзора $2\beta = 90^{o}$, размер элементов фотоприемника по кадру a = 20 мкм, фокусное расстояние объектива f = 200 мм, относительное отверстие ω = 1:2), использующей автоматизированное и автоматическое, с использованием СНС, дешифрирование изображений, при требуемой вероятности классификации $P_{\Sigma}^{*} = 0{,}8$ высококвалифицированным оператором объектов транспортной техники с критическим размером h = 3 м, средним радиационным контрастом ΔT_R = 2 К и средней суммарной пространственной плотностью объектов на местности $n = 5$ км$^{-2}$ при следующих ограничениях на высоту и скорость носителя ВТА: 1 км $\leq H \leq$ 5 км, 50 км/ч $\leq V \leq$ 200 км/ч. ВТА работает в темное время суток в ясную погоду, изображение наблюдается в полутьме. Расчеты производим в следующем порядке:

- устанавливаем по рисунку 1 для минимальной высоты H = 1 км вероятность прямого видения $P_{\text{п}} = 1$; рассчитываем по (3) коэффициент ς = 1,13 и по (5) для средней длины волны λ_0 = 10 мкм и типового соотношения $d_{\text{а}} = a$ коэффициент ϑ = 1,4 и эффективное значение элементарного поля зрения δ = 0,14 мрад;

- устанавливаем по (6) максимальный диапазон регистрируемой разности температур $\Delta T_{\text{м}0} = 10$ К; рассчитываем по (7) для типовой средней яркости изображения $L' = 10$ кд/м^2 и, согласно таблице 1, параметров μ = 0,014 и ξ = 0,0026 относительную частоту миры x = 0,65 и по (2) для показателя квалификации оператора γ = 1,5 и критерия Джонсона $C = 3$ статическую вероятность классификации $P = 1$;

- рассчитываем по (8) среднее время классификации объектов t_0 = 1,3 с и по (12) скорость носителя $V = 0{,}017$ км/с = 60 км/ч; так как выполняются соотношения 50 км/ч $\leq V \leq$ 200 км/ч, оптимальные значения высоты и скорости носителя составляют $H^{*} = H$ = 1 км, $V^{*} = V$ = 60 км/ч;

- рассчитываем по (9) результирующую вероятность вскрытия объекта $P_{\Sigma} = P_{\Sigma}^{*} = 0{,}8$ и интенсивность поиска при автоматизированном дешифрировании изображений $N = 0{,}14$ с$^{-1}$ (для сравнения отметим, что максимально возможная интенсивность поиска, согласно (10), здесь равна $N_m = 0{,}28$ с$^{-1}$);

- из уравнения $P = P_{\Sigma}^{*} = 0{,}8$ с использованием (2) находим для $\gamma = \gamma_{\text{авт}} = 1{,}25$ оптимальную высоту носителя $H^{*} = H$ = 3,4 км и по (13) для $V^{*} = V$ = 200 км/ч (0,055 км/с)

соответствующую интенсивность поиска при автоматическом дешифрировании изображений $N = 1{,}5\ с^{-1}$.

Таким образом, в данном случае автоматическое дешифрирование изображений ВТА предпочтительнее. Однако, как показывают аналогичные расчеты, при средней суммарной пространственной плотности объектов на местности $n < 0{,}2\ км^{-2}$ и прочих равных условиях интенсивность поиска будет выше при автоматизированном дешифрировании.

Заключение

1. При автоматизированном дешифрирования изображений, формируемых ВТА, когда поиск и отбор фрагментов изображений, содержащих объекты, производится автоматом, а решение по их распознаванию – оператором, и при автоматическом дешифрировании, когда все эти операции осуществляются без участия оператора, существуют оптимальные сочетания высоты и скорости движения носителя ВТА, свои для каждого способа дешифрирования, обеспечивающие, при определенных ограничениях на эти параметры, для заданной результирующей вероятности вскрытия объектов максимальную интенсивность их поиска.

2. В случае малой средней плотности распределения объектов на местности наиболее целесообразно использовать автоматизированное дешифрирование изображений, для которого статическая вероятность распознавания объектов высококвалифицированным оператором, особенно слабоконтрастных и замаскированных, больше, чем для автоматического, однако при высокой плотности объектов, когда решающее значение приобретает ограниченное время наблюдения выделенных фрагментов изображений, предпочтительнее их автоматическое дешифрирование.

3. При использовании традиционных метрик изображения объектов, связанных с их формой, статическая вероятность автоматического распознавания объектов соответствует эффективности их дешифрирования оператором со средней квалификацией, однако применение СНС увеличивает эту вероятность до уровня, отвечающего оператору повышенной квалификации.

Литература

1. Holst G. Electro-optical imaging system performance. 3 ed. USA: SPIE press, 2003. 442 p.
2. Балоев В.А., Ильин Г.И., Овсянников В.А., Филиппов В.Л. Эффективность, помехозащищенность и помехоустойчивость видовых оптико-электронных систем. Казань: Изд-во Казан. гос. техн. ун-та, 2015. 424 с.
3. Корниенко А.А., Мальцев Г.Н., Подрезов С.В. Вероятностные характеристики применения комплексов оптических информационных и измерительных систем в условиях облачности // Оптический журнал. 2000. № 7. С. 63-69.
4. Овсянников В.А., Овсянников Я.В. О разрешающей способности современных тепловизионных приборов // Контенант. 2025 (в печати).
5. Schachter B. Target-detection strategies // Optical Engineering. 2013. № 4. Pp. 041102-041108.
6. Овсянников В.А., Овсянников Я.В., Филиппов В.Л. Сравнение некоторых алгоритмов автоматизированного дешифрирования оптико-электронных изображений по эффективности и быстродействию // Оборонная техника. 2017. № 3. С. 54-65.
7. Овсянников В.А., Овсянников Я.В. Развитие компьютерной имитационной модели видовых оптико-электронных систем // Авиакосмическое приборостроение. 2024. № 7. С. 19-34.
8. Леонов Ю.П. Теория статистических решений и психофизика. М.: Наука, 1977. 227 с.
9. Абезгауз Г.Г., Тронь А.П., Копенкин Ю.Н., Коровина И.А. Справочник по вероятностным расчетам. М.: Воениздат, 1970. 536 с.
10. Меденников П.А., Павлов Н.И. Визуальное и автоматическое распознавание объектов по малопиксельным изображениям // Оптический журнал. 2003. Т. 70. № 2. С. 40-45.
11. Мингалев А.В., Белов А.В., Габдуллин И.М., Марданова Д.А., Агафонова Р.Р., Шушарин С.Н., Шлеймович М.П. Оценка и тестирование возможностей нейросетевых алгоритмов для обеспечения автоматизации дешифрирования графической информации в комплексах дистанционного зондирования Земли // Оптический журнал. 2022. Т. 89. № 10. С. 68-79.

12. Мингалев А.В. Метод и алгоритмы обработки сканерных тепловизионных изображений на основе сверточных нейронных сетей для автоматического обнаружения заданных типов объектов // Вестник Рязанского государственного радиотехнического университета. 2025. № 1. С. 158-167.
13. Шолле Ф. Глубокое обучение на Python. СПб: Питер, 2018. 400 с.

УДК 681.7.069.32

ПРОЕКТИРОВАНИЕ(РЕДИЗАЙН) МИКРОБОЛОМЕТРА С РАЗМЕРОМ ЧУВСТВИТЕЛЬНОГО ЭЛЕМЕНТА 12 МКМ: ЧАСТЬ 1

С.Р. Кисленко

E-mail: ki5le@yandex.ru

Аннотация: Представлена конструктивная модель микроболометра, на основе метода конечных элементов проиллюстрированы стационарные расчёты перегрузок, собственных частот, задач теплообмена.

Ключевые слова: микроболометр, ИК техника, моделирование.

REDISIGN OF A MICROBOLOMETER WITH A SENSITIVE ELEMENT SIZE 12 : PART 1

S.R. Kislenko

E-mail: ki5le@yandex.ru

Abstract: A structural model of a microbolometer is presented, and stationary calculations of overloads, natural frequencies, and heat transfer problems are illustrated based on finite element analysis.

Keywords: microbolometer, IR technology, modeling.

Введение

Микроболометр, как класс приёмников лучистой энергии, в текущих реалиях развития науки и техники, являются показателем эффективности работы учёных и инженеров, обеспечивается общим уровнем компетенций по ключевым отраслям микроэлектроники.

Основные тенденции развития микроболометров таковы [1]:

1. Переход на крупноформатные матрицы.
2. Разработка мультиспектральных устройств.

3. Использование альтернативных материалов и физических принципов (наиболее актуально).

Ещё одна тенденция – уменьшение размера чувствительной площадки и соответственно уменьшение уровня шумов. Однако при этом повышается требования к формирующей оптической системе, что с учётом специфики аберрационной коррекции тепловизионных систем лимитирует этот параметр.

На сегодняшний день на рынке широко представлены микроболометры с размером чувствительного элемента 12 мкм, продукция лидеров рынка (FLIR Teledyne, Sofradir ULIS) отличается топологией, хотя и характеризуется мостовой (консольной) конструкцией.

Предлагается серия статей, начиная от моделирования микроболометра, заканчивая технологическим, экономическим аспектом. В данной статье приводится конструкция чувствительного элемента, проводится механический и тепловой анализ.

Методика

Метод конечных элементов (МКЭ) наиболее популярен и эффективен на сегодняшний день, поскольку позволяет наглядно оценить и интерпретировать результат расчёта даже для нетривиальной геометрии. На рисунке 1 представлена упрощённая схема проектирования микроболометра. Кроме того, при проектировании микроболометра следует учитывать не только технологический аспект, но и экономический (издержки), поскольку усилия инженеров и технологов направлены на удешевление производства. Изготовление опытных образцов позволяет оценить адекватность модели. Несмотря на возможности моделирования, нужно отметить, что как правило, при проверке опытного образца возникают неучтённые физические эффекты, приводящие к ухудшению характеристик. С учётом этих замечаний проводилось проектирование.

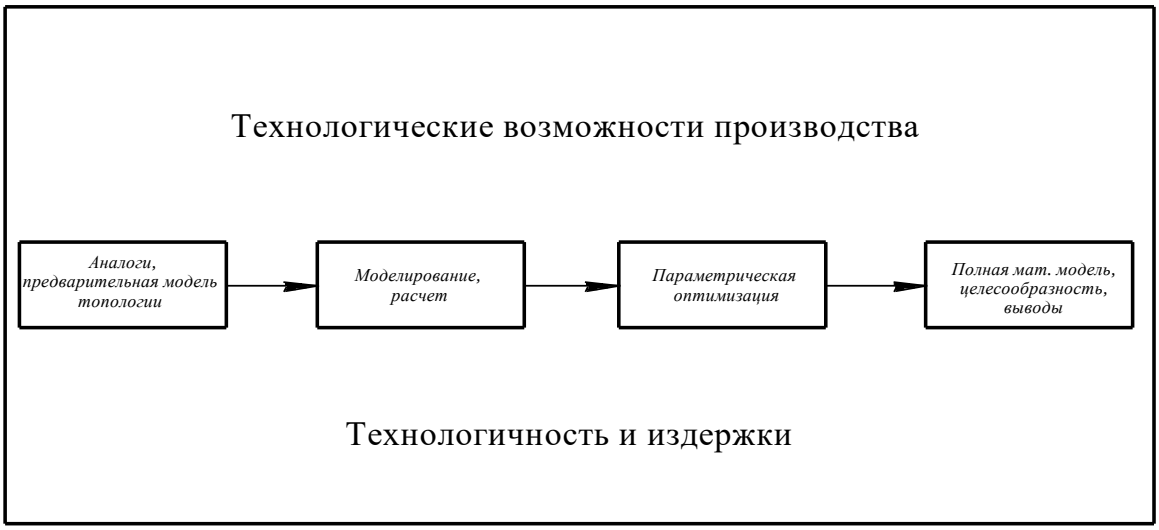

Рисунок 1 – Упрощённая схема проектирования микроболометра

Ожидаемые параметры

В таблице 1 представлены параметры микроболометрических модулей серии BOSON и BOSON+ компании FLIR Systems.

Таблица 1 – Параметры микроболометрических модулей компании FLIR Systems

Параметр	BOSON+	BOSON
Разрешение	VGA: 640x512 QVGA: 320x256	
Размер чувствительного элемента	12 мкм	
Спектральный диапазон	8–14 мкм	
Эквивалентная шуму разность температур (NeTD)	≤ 20 мК	≤ 40 мК
Постоянная времени (τ)	≤ 6 мс	≤ 25 мс
Диапазон рабочих температур	От $-40°C$ до $+80°C$	

В таблице 2 представлены параметры микроболометрического матричного детектора АСТРОН-64012 «ОКБ «Астрон», а на рис. 2 его габариты [2].

Таблица 2 – Параметры микроболометрического матричного детектора АСТРОН-64012

Технология	Оксид ванадия (VOx)
Спектральный диапазон, мкм	7-14
Формат матрицы	640 × 512
Шаг матрицы, мкм	12
Частота кадров, Гц	60
Эквивалентная шуму разность температур при 300 К, 25 Гц и F=1,0 (NeTD), мК	≤ 40
Постоянная времени, мс	10
Амплитуда выходного сигнала, В	1,0 ~ 2,6
Питание аналоговой части, В	3,3
Питание цифровой части, В	1,8
Потребляемая мощность, мВт	170
Корпус	Керамический
Диапазон рабочих температур, °С	-40 ... +85
Температура хранения, °С	-55 ... +85
Размеры, мм	22 × 22 × 3
Исполнение	32 вывода под поверхностный монтаж
Вес, гр	8

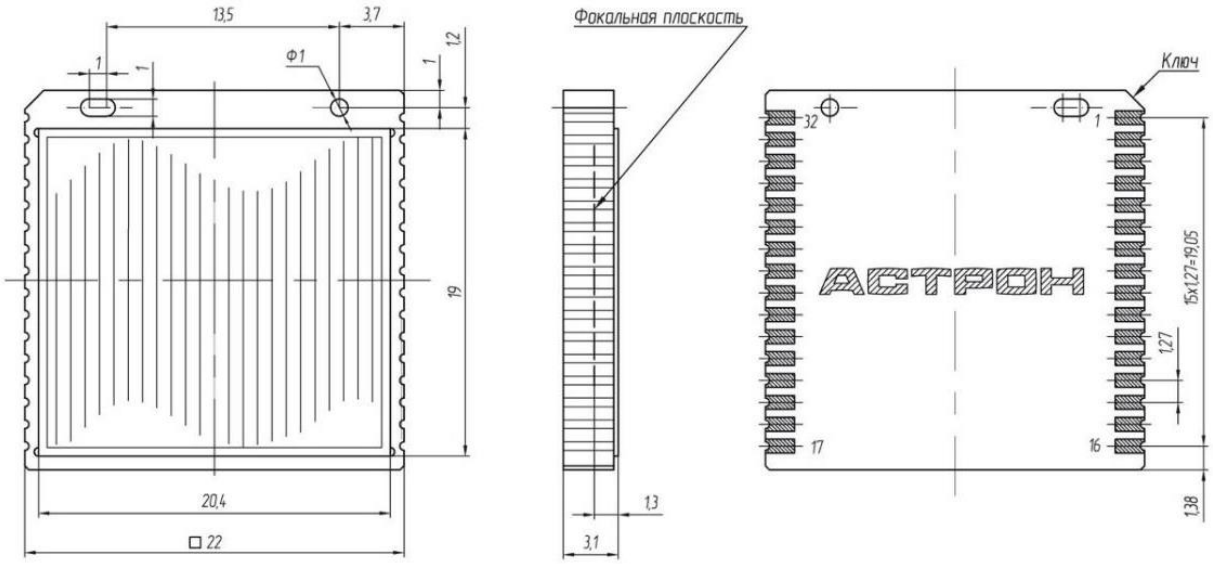

Рисунок 2 – Габариты микроболометрического матричного детектора АСТРОН-64012

Сравнивая микроболометрические модули, можно сделать вывод, отечественный сенсор имеет идентичные параметры, уступает зарубежному аналогу незначительно. Целью серии статей является приёмник с параметрами не хуже отечественного, поэтому в качестве ориентира используется именно он.

Моделирование

Необходимо спроектировать конструкцию пикселя и провести расчёты. На рисунке 3 представлена оригинальная конструкция чувствительного элемента микроболометра, используются следующие материалы [3]: VO_2, SiO_2 / Si_3N_4, $NiCr$.

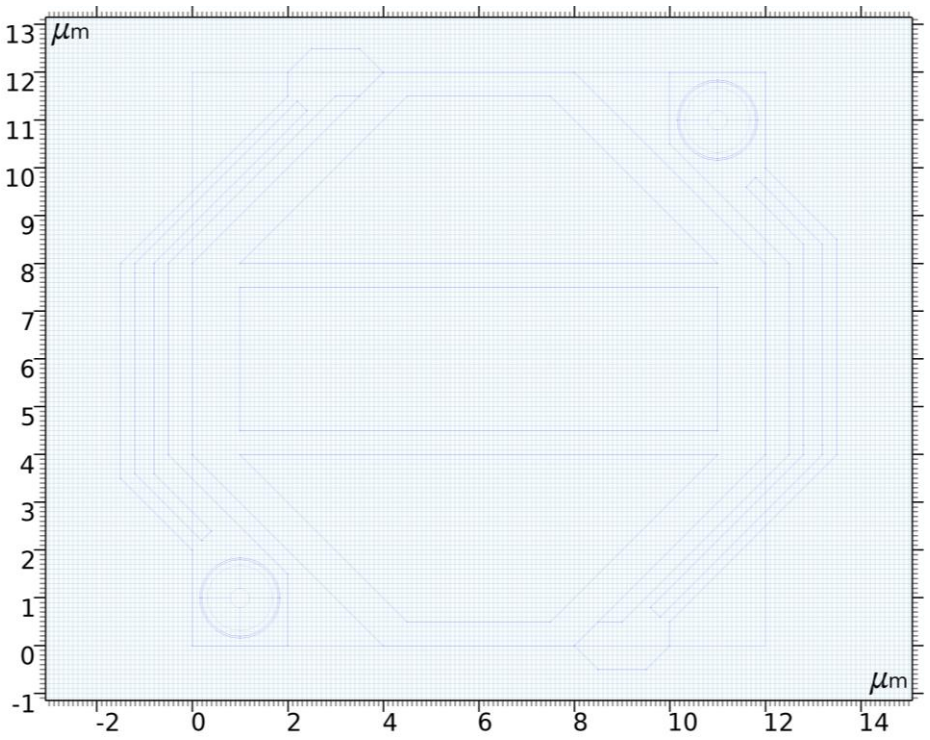

Рисунок 3 – Конструкция чувствительного элемента микроболометра

Помимо этой группы элементов в зарубежных статьях описаны и другие варианты. Так, в [4] дано описание таких материалов:

1. $Ni_{80}Cr_{20}$ для поглощающего слоя;
2. Ti для поддержек и контактов;
3. $Ge_{0.36}Si_{0.04}Sn_{11}O_{43}$ для чувствительного слоя.

В таблице 3 приведены физические свойства для VO_2, SiO_2 / Si_3N_4, $NiCr$.

Таблица 3 – Физические свойства материалов

Свойство	VO_2,	SiO_2 / Si_3N_4	$NiCr$
Плотность, $\rho[кг / м^3]$	4340	2200/2300	8500
Коэффициент Пуассона, μ	0,24	0,17/0,26	0,312
Модуль Юнга, $E[Па]$	80E10	70E9/300E9	200E10
Удельная теплоёмкость, $C[Дж/(кг \cdot K)]$	500	730/330	392
Теплопроводность, $\lambda[Bm/(м \cdot K)]$	50	1,4/20	400

На рисунке 4 представлен разрез микроболометра и его структрура.

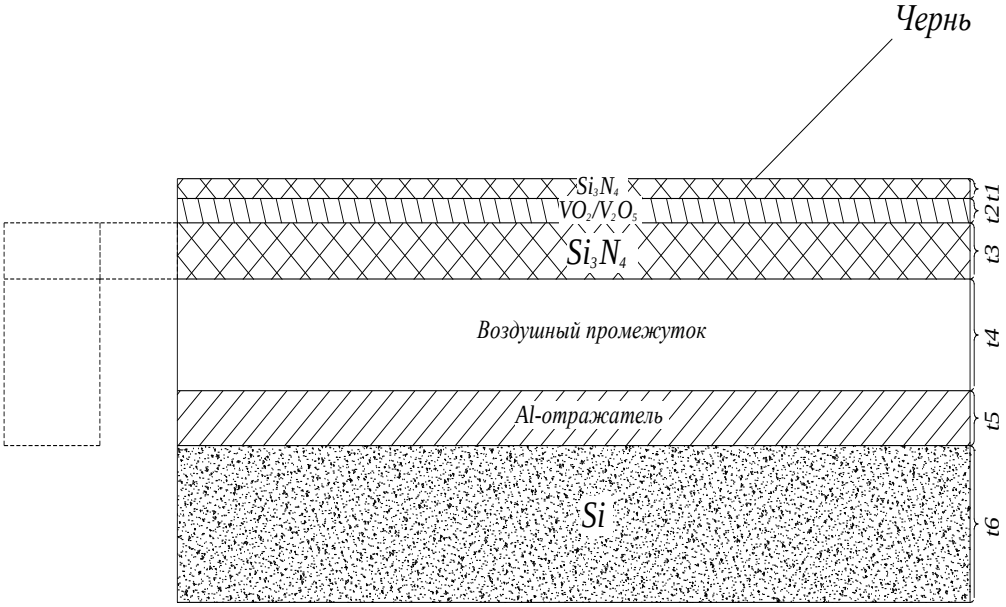

Рисунок 4 – Структура микроболометра

В таблице 4 приведены толщины слоёв для модельного описания.

Т а б л и ц а 4 – Толщины слоёв микроболометра

Материал	Толщина, мкм
Si_3N_4 (абсорбирующий слой)	$t1 = 0{,}02$
VO_2 / V_2O_5 (терморезистивный слой)	$t2 = 0{,}05$
Si_3N_4 (поддерживающий слой)	$t3 = 0{,}2$
Вакуум (моделирование выполнено в воздушной среде)	$t4 = 2$
Алюминиевый отражатель	$t5 = 0{,}4$
Кремниевая подложка	$t6 = 4$

Материалы и толщины слоёв будут уточнены при параметрической оптимизации.

Здесь и далее, граничное условие – жёсткое закрепление у основания, $g = 9{,}80665\ м/с^2, t = 22\ °C.$ На рисунке 5 представлена иллюстрация стационарного расчёта деформации при воздействии нагрузки (ударе) в осевом направлении (нормально к чувствительной площадке) 500 g ($a_f = -g$).

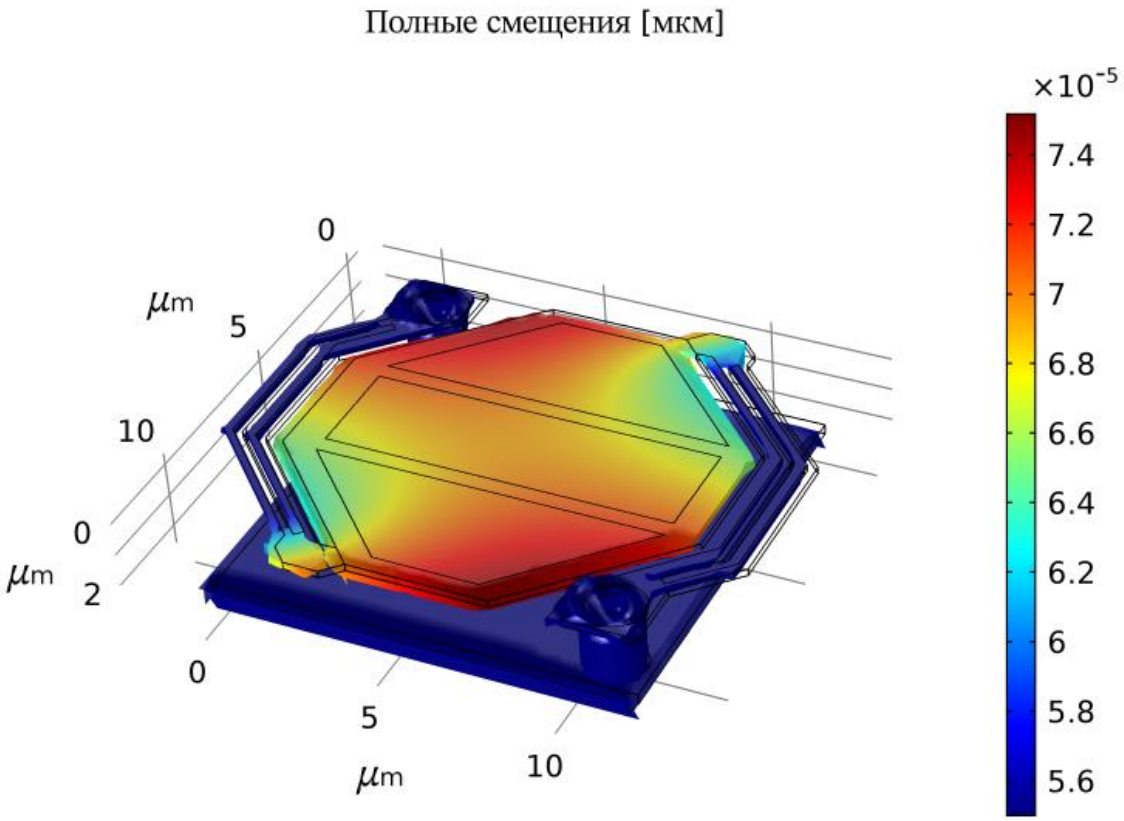

Рисунок 5 – Иллюстрация стационарного расчёта деформации при нагрузке 500 g

Наименьшие деформации возникают в ножках контактов – $5{,}5E-5$ мкм. Наибольшие деформации возникают в местах соединения с консолями и мембраной – $7{,}5E-5$ мкм. Необходимо усиление этих элементов.

Собственные частоты для первых трёх мод приведены на рисунке 6.

Наибольший интерес представляют задачи теплообмена. Относительное изменение сопротивления микроболометра $\Delta R/R$ при изменении его температуры на ΔT в случае, если $\Delta R << R$, можно представить следующим образом [5, с. 177]:

$$\Delta R/R = \beta_T \Delta T ,$$

где β_T – температурный коэффициент сопротивления болометра.

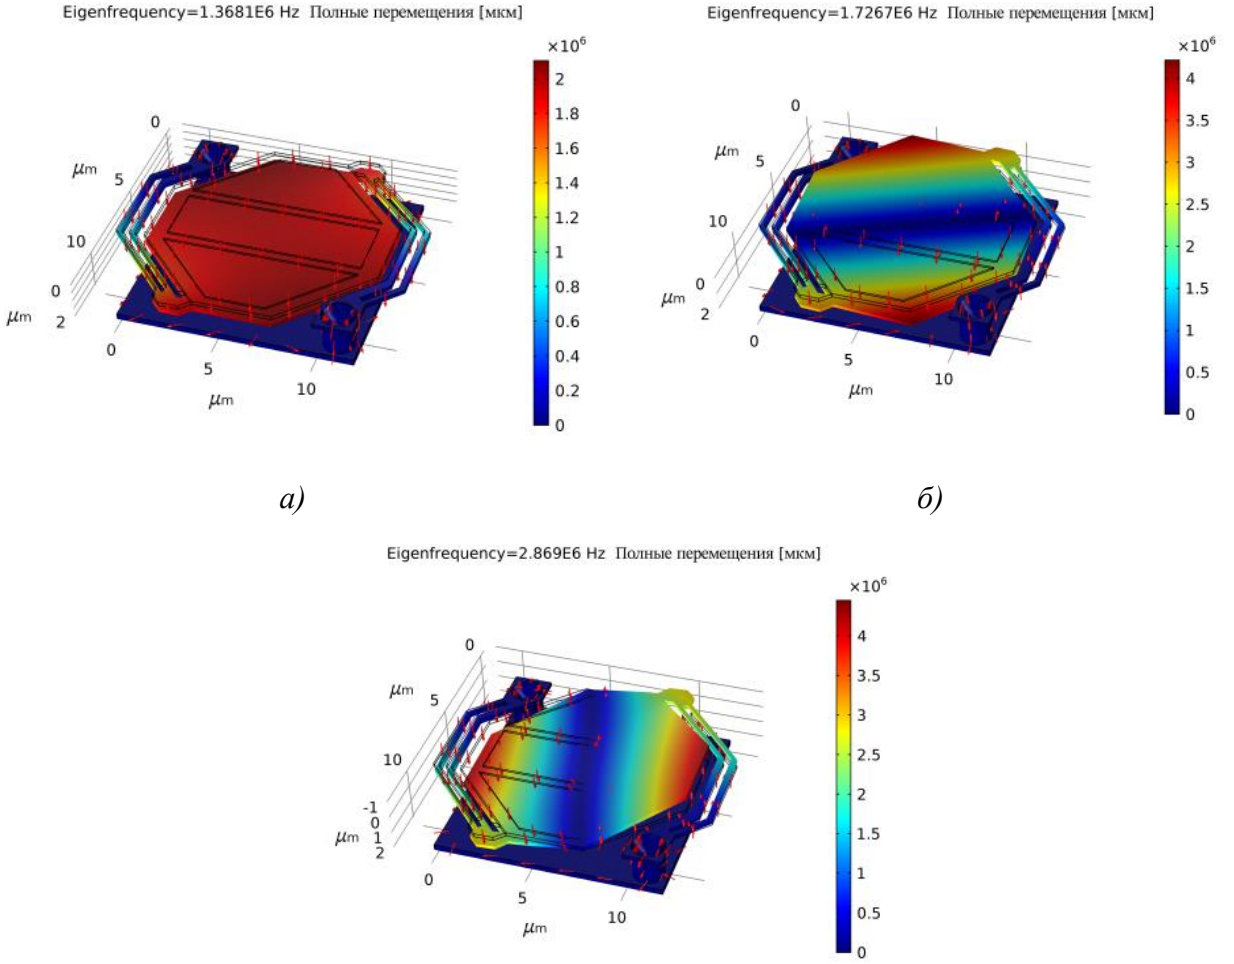

а) *б)*

в)

Рисунок 6 – Расчёт собственных частот для первых трёх мод (направления короблений показаны стрелками): *а* – первая мода $\nu_1 = 1{,}3681\,E6$ Гц, *б* – вторая мода $\nu_2 = 1{,}7267\,E6$ Гц, *в* – третья мода $\nu_3 = 2{,}869\,E6$ Гц

Для полупроводниковых микроболометров в ограниченном температурном диапазоне значение β_T обратно пропорционально квадрату температуры:

$$\beta_T = \frac{-3000}{T^2}.$$

Поэтому тепловой расчёт имеет особое значение при проектировании. Необходимо обеспечить теплоизоляцию площадки детектора от подложки и окружающей среды для обеспечения оптимального ОСШ (SNR).

Уравнение теплового баланса для микроболометра при поглощении излучения выглядит следующим образом [6]:

$$C\frac{\partial \Delta T}{\partial t} = \eta \cdot \Delta P - G \cdot \Delta T,$$

где C – теплоёмкость мембраны [Дж/К], ΔP – изменение мощности теплового излучения [Вт] в плоскости детектора, η – коэффициент поглощения ИК-излучения, а ΔT – изменение температуры между детектором и теплоотводом (подложкой) [К], G – теплопроводность консолей [Вт/К].

Случай теплообмена кремниевой подложки ($t = +30\,°C$, $W = 20$ $[Вт/(м^2 \cdot К)]$) с чувствительной площадкой (при нормальных климатических условиях) через 10 мс после начала теплообмена представлен на рисунке 7.

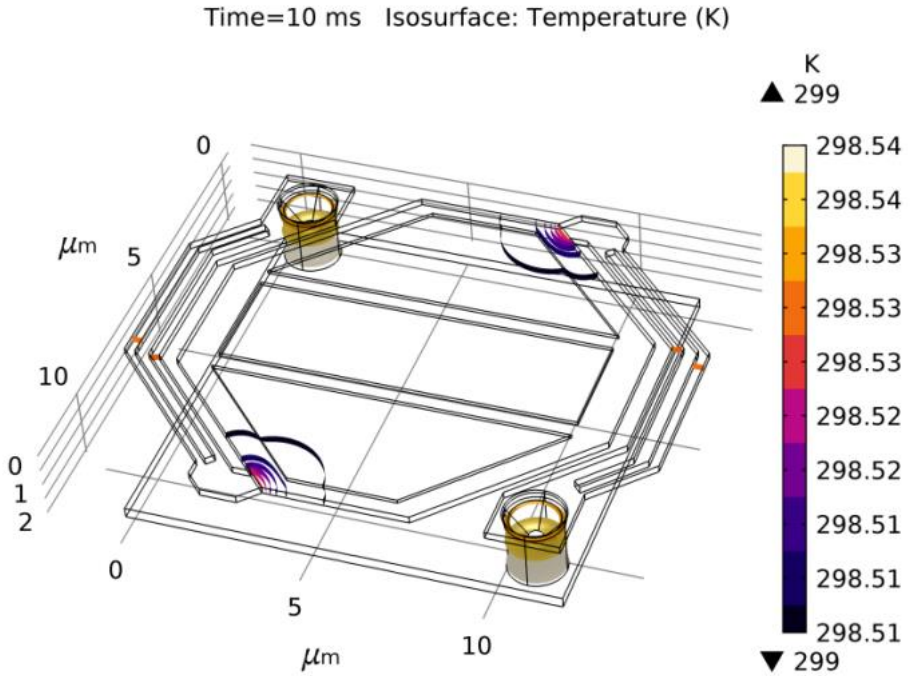

Рисунок 7 – Теплообмен подложки и чувствительного элемента

Стоит отметить неэффективный теплооообмен в представленной модели, разница между максимальной и минимальной температурой 0,03 $°C$.

Гексагональная компоновка чувствительных площадок представлена на рисунке 8. Размер пятна рассеяния центра поля (с учётом распределения энергии), для большинства тепловизионных систем вписывается в один элемент. Для края поля (в зависимости от степени аберрационной коррекции) пятно «растекается» минимум на 2 элемента.

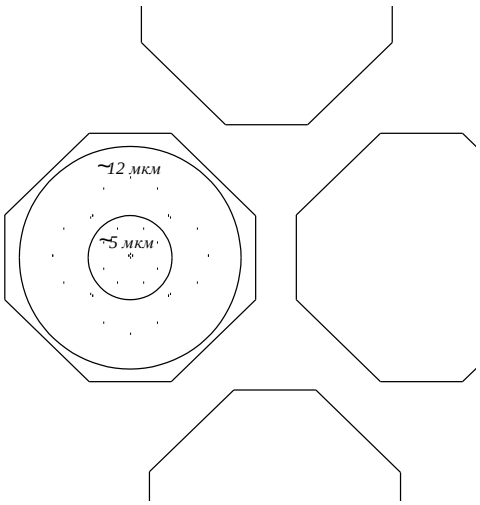

Рисунок 8 – Компоновка чувствительных площадок

Таким образом, принципиальная возможность реализации такой конструкции показана.

Заключение

Разработана потенциальная модель микроболометра, проведённые расчёты позволяют сделать вывод о допустимости продолжения проектирования, допускают, проведение дальнейших исследований: оптимизации, получения электрических характеристик, рассмотрения переходов в полупроводниковых структурах, NeTD, чувствительности.

Литература

1. Н.Кульчицкий, А. Наумов, В. Старцев – Рынок неохлаждаемых микроболометров для ИК-камер: тенденции и перспективы //Журнал «Электроника НТБ» -№1(00182) 2019, с. 1-7.

2. Официальный сайт «ОКБ «Астрон». Лыткарино. URL: https://astrohn.ru/product/astron-64012/ (дата обращения: 12.08.2025)

3. C. Chen, L. Zhang, Y. Zhou, X. Zheng, and J. Dong, “Analysis on vibrations and infrared absorption of uncooled microbolometer,” Journal of Vibroengineering, Vol. 17, No. 5, pp. 2733–2741, Aug. 2015.

4. Aponte, K.O.D.; Xu, Y.;Rana, M. Design and Simulation of Microbolometer with Dual Cavity for High Figure of Merits. Micromachines 2023, 14, 948. https://doi.org/10.3390/mi14050948.

5. Оптико-электронные узлы электронно-вычислительных средств, измерительных приборов и устройств автоматики [Электронный ресурс] : учебное пособие / Н. П. Захаров, С. П. Тимошенков, Ю. А. Крупнов. — 3-е изд. (эл.). — М. : БИНОМ. Лаборатория знаний, 2013. — 335 с. : ил.

6. Р.З. Хафизов, В.В. Старцев, В.Ю. Москвичев – Быстродействующие болометрические матричные детекторы//Журнал «Фотоника» том 15 №5 2021, с. 396-409, DOI:10.22184/1993-7296.

УДК 551.501

СРАВНИТЕЛЬНЫЙ АНАЛИЗ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ КЛАССИФИКАЦИИ УЧАСТКОВ ЛЕСНЫХ МАССИВОВ

Городничев В.А., Белов М.Л., Белов А.М., Назаров В.В.

Аннотация: Статья посвящена анализу возможностей методов машинного обучения для задачи картографирования лесных массивов (на основе классификации участков лесных массивов) при использовании гиперспектральных данных в спектральном интервале ~ 0,4-2,4 мкм. Исходной информацией для анализа являются данные измерений спектральных коэффициентов отражения разного вида участков лесных массивов в летний период - лиственных деревьев, хвойных деревьев, сухостоя, болот и гарей. Для классификации использовались следующие методы машинного обучения: k-ближайших соседей, случайный лес, сильно рандомизированные деревья, градиентный бустинг и метод опорных векторов. Показано, что для всех рассмотренных методов машинного обучения аддитивный шум мало влияет на результаты классификации. Наилучшие результаты классификации получаются при использовании метода опорных векторов (Support Vector Machine). При относительном среднеквадратическом значении шума измерения 10% метод опорных векторов позволяет получить оценки вероятностей правильной классификации болот, гарей, лиственных деревьев, сухостоя и хвойных деревьев в диапазоне ~ 0,9-1 при оценках вероятностей неправильной классификации в диапазоне ~ 0-0,05.

Ключевые слова: спектры отражения, видимый и ближний инфракрасный диапазоны, классификации участков лесных массивов, методы машинного обучения.

COMPARATIVE ANALYSIS OF MACHINE LEARNING METHODS FOR CLASSIFYING WOODLANDS

Gorodnichev V.A., Belov M.L., Belov A.M., Nazarov V.V.

Abstract: The article is devoted to the analysis of the possibilities of machine learning methods for the task of mapping forests (based on the classification of forest areas) using hyperspectral data in the spectral range of ~ 0.4-2.4 μm. The initial information for the analysis is data from

measurements of spectral reflection coefficients of various types of forest areas in the summer period - deciduous trees, coniferous trees, deadwood, swamps and harems. The following machine learning methods were used for classification: k-nearest neighbors, random forest, highly randomized trees, gradient boosting, and the support vector method. It is shown that for all the considered machine learning methods, additive noise has little effect on classification results. The best classification results are obtained using the support vector machine. With a relative RMS measurement noise of 10%, the support vector method allows us to obtain estimates of the probabilities of correct classification of swamps, hares, deciduous trees, deadwood and coniferous trees in the range of ~ 0.9-1, while estimating the probabilities of incorrect classification in the range of ~ 0-0.05.

Keywords: reflection spectra, visible and near-infrared ranges, classifications of forest areas, machine learning methods.

Введение

В настоящее время актуальным направлением дистанционного зондирования окружающей среды являются различные задачи мониторинга растительного покрова – оценка состояния лесных массивов, оценка продуктивности сельскохозяйственных культур; оценка влагосодержания почв и состояния экосистем; картирование лесных массивов, районов заболачивания, опустынивания, засухи др. [1-9].

Особенно актуальным представляется мониторинг таких сложных экологических систем как лесные массивы, которые характеризуется большим разнообразием участков, образующих эти массивы.

Отметим, что лесные массивы выполняют множество экологических (климатообразующих, водоохранных и т.д.), экономических, социальных и других важнейших функций [10,11].

На сегодняшний день в РФ основным методом контроля состояния леса является обход лесных участков. Однако, этот метод имеет большую трудоемкость. Наиболее перспективными методами мониторинга состояния лесных массивов являются дистанционные оптические аэрокосмические методы в видимом и ближнем инфракрасном спектральных диапазонах.

Использование мультиспектральных и гиперспектральных данных о лесных массивах в видимом и ближнем инфракрасном спектральных диапазонах дает возможность дистанционно решать многие задачи мониторинга лесных территорий (картирование лесных территорий, возрастной состав лесов, болезни, пожары, оценка запасов древесины и т.п.) (см., например, [12-19]).

В статье приведены результаты анализа возможностей методов машинного обучения для задачи картографирования лесных массивов (на основе классификации участков лесных массивов) при использовании гиперспектральных данных в видимом и инфракрасном спектральном интервале ~ 0,4-2,4 мкм.

Исходные данные для классификации участков лесных массивов

Исходной информацией для анализа являются данные измерений спектральных коэффициентов отражения разного вида участков лесных массивов в спектральном диапазоне 0,4-2,4 мкм.

Примеры спектральных зависимостей коэффициентов отражения разного вида участков лесных массивов в летний период года в спектральном интервале 0,4-2,4 мкм показаны на рисунках 1,2.

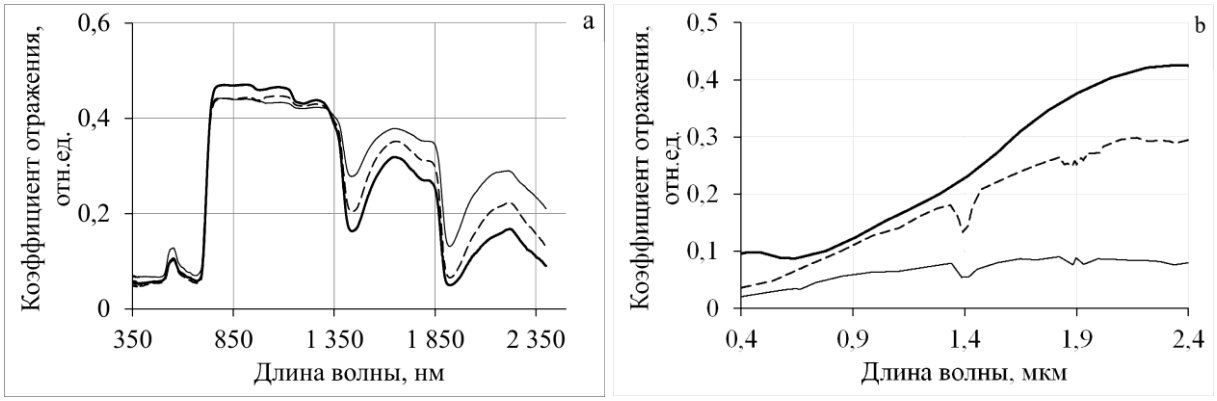

Рисунок 1 – Спектральные коэффициенты отражения: *a* – лиственных деревьев, *b* –гарей

На рисунке 1*a*: толстая сплошная линия – листья дуба, пунктирная линия – листья бука, тонкая сплошная линия – листья березы [20-22]. На рисунке 1*b*: примеры измерений коэффициентов отражения разных участков гарей [23,24].

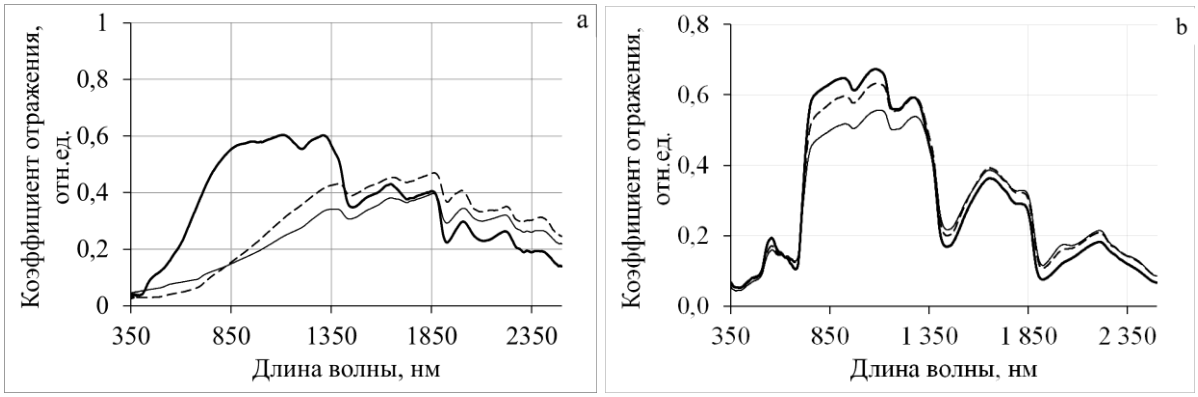

Рисунок 2 – Спектральные коэффициенты отражения: *a* – сухих хвойных деревьев, *b* – болот

На рисунке 2*a*: толстая сплошная линия – сухие иголки сосны; пунктирная линия – сухой лишайник, тонкая сплошная линия – кора сосны. На рисунке 2*b*: болота с проективных покрытием растительностью 95 % (толстая сплошная линия), 85 % (пунктирная линия), 80 % (тонкая сплошная линия).

Задача классификации участков лесных массивов решалась разными методами машинного обучения на основе данных о спектральных коэффициентах отражения в летний период лиственных деревьев, хвойных деревьев, сухостоя, болот и гарей в спектральном диапазоне 0,4-2,4 мкм.

В качестве исходных данных для классификации были взяты спектры отражения [20-24]:

- лиственных деревьев разных пород (осина, лох узколистый, орех, клен, береза, дуб, бук – 24 спектра);
- хвойных деревьев разных пород (сосна, ель, можжевельник, кедр, пихта – 27 спектров);
- сухого леса (сухие листья; сухие иголки хвойных деревьев; опавшие листья; сухой лишайник; сухая кора лиственных и хвойных деревьев – 32 спектр);
- болот (с разным процентом покрытия растительностью – 41 спектр);
- разных участков гарей (23 спектра).

Для классификации участков лесных массивов использовались следующие методы машинного обучения: k-ближайших соседей (k Nearest Neighbors); случайный лес (Random Forest); сильно рандомизированные деревья (Extremely Randomized Trees); градиентный бустинг (Gradient Boosting); метод опорных векторов (Support Vector Machine) (см., например, [25-28]).

Для обучения использовалась 66% спектров отражения каждого типа участков лесных массивов.

Остальные (34%) спектров отражения каждого типа участков лесных массивов использовались для проверки работы методов машинного обучения. Для этих спектров добавлялся аддитивный случайный шум, имитирующий шум приемного канала. Считалось, что шум распределен по нормальному закону с нулевым средним значением и относительным (по отношению к значению спектрального отсчета) среднеквадратическим отклонением δ=1–10 %.

Результаты классификации участков лесных массивов

Результаты статистического моделирования (моделирование проводилось по 1000 реализаций шумов регистрирующей аппаратуры) оценок вероятностей правильной классификации (P_d) и неправильной классификации (P_a) участков лесных массивов – болот, гарей, лиственных деревьев, сухостоя и хвойных деревьев приведены ниже для разных методов машинного обучения в таблицах 1-5.

Таблица 1 – Результаты статистического моделирования для метода k-ближайших соседей (k Nearest Neighbors)

Участок лесного массива	δ=1 %		δ=10 %	
	P_d	P_a	P_d	P_a
болота	0,79	0,11	0,79	0,11
гари	>0,99	0,02	0,89	0,02
лиственные зеленые деревья	0,78	0,05	0,78	0,04
сухие деревья	0,87	<0,01	0,91	0,03
хвойные зеленые деревья	0,80	0,02	0,80	0,02

Таблица 2 – Результаты статистического моделирования для метода случайный лес (Random Forest)

Участок лесного массива	δ=1 %		δ=10 %	
	P_d	P_a	P_d	P_a
болота	0,67	0,03	0,42	0,03
гари	0,98	0,02	0,88	0,02
лиственные зеленые деревья	0,56	0,05	0,56	0,03
сухие деревья	>0,99	<0,01	>0,99	0,03
хвойные зеленые деревья	>0,99	0,10	>0,99	0,18

Таблица 3 – Результаты статистического моделирования для метода сильно рандомизированные деревья (Extremely Randomized Trees)

Участок лесного массива	δ=1 %		δ=10 %	
	P_d	P_a	P_d	P_a
болота	0,79	0,03	0,79	0,03
гари	>0,99	0,02	>0,99	0,02
лиственные зеленые деревья	0,56	0,02	0,58	0,02
сухие деревья	>0,99	<0,01	0,99	<0,01
хвойные зеленые деревья	>0,99	0,10	>0,99	0,10

Таблица 4 – Результаты статистического моделирования для метода градиентного бустинга (Gradient Boosting)

Участок лесного массива	δ=1 %		δ=10 %	
	P_d	P_a	P_d	P_a
болота	0,64	0,03	0,64	0,05
гари	0,75	0,02	0,75	0,02
лиственные зеленые деревья	0,67	0,15	0,67	0,15
сухие деревья	0,92	0,03	0,92	0,03
хвойные зеленые деревья	0,80	0,07	0,77	0,07

Таблица 5 – Результаты статистического моделирования для метода опорных векторов (Support Vector Machine)

Участок лесного массива	δ=1 %		δ=10 %	
	P_d	P_a	P_d	P_a
болота	>0,99	0,05	>0,99	0,05
гари	>0,99	<0,01	>0,99	<0,01
лиственные зеленые деревья	0,89	<0,01	0,89	<0,01
сухие деревья	0,91	<0,01	0,91	<0,01
хвойные зеленые деревья	>0,99	<0,01	>0,99	<0,01

Результаты, приведенные в таблицах 1-5 показывают, что для всех рассмотренных методов машинного обучения аддитивный шум мало влияет на результаты классификации. Наилучшие результаты классификации получаются при использовании метода опорных векторов (Support Vector Machine).

При относительном среднеквадратическом значении шума измерения 10% метод опорных векторов позволяет получить оценки вероятностей правильной классификации болот, гарей, лиственных деревьев, сухостоя и хвойных деревьев в диапазоне ~ 0,9-1 при оценках вероятностей неправильной классификации в диапазоне ~ 0-0,05.

Выводы

Проведен анализ возможностей методов машинного обучения для задачи картографирования лесных массивов (на основе классификации участков лесных массивов) при использовании гиперспектральных данных в спектральном интервале ~ 0,4-2,4 мкм. Исходной информацией для анализа являются данные измерений спектральных коэффициентов отражения разного вида участков лесных массивов в летний период - лиственных деревьев, хвойных деревьев, сухостоя, болот и гарей. Для классификации использовались следующие методы машинного обучения: k-ближайших соседей, случайный лес, сильно рандомизированные деревья, градиентный бустинг и метод опорных векторов. Показано, что для всех рассмотренных методов машинного обучения аддитивный шум мало влияет на результаты классификации. Наилучшие результаты классификации получаются при использовании метода опорных векторов (Support Vector Machine). При относительном среднеквадратическом значении шума измерения 10%

метод опорных векторов позволяет получить оценки вероятностей правильной классификации болот, гарей, лиственных деревьев, сухостоя и хвойных деревьев в диапазоне ~ 0,9-1 при оценках вероятностей неправильной классификации в диапазоне ~ 0-0,05.

Литература

1. Белов М.Л., Городничев В.А., Колючкин В.Я., Одиноков С.Б. Оптико-электронные системы мониторинга природной среды. М.: Из-во МГТУ, 2014, 76 с.
2. Токарева О.С. Обработка и интерпретация данных дистанционного зондирования Земли. Томск: Изд-во Томского политехнического университета, 2010.148 с.
3. Вегетационные индексы. Основы, формулы, практическое использование. Режим доступа: http://www.mapexpert.com.ua/index_ru.php?id=20&table=news (дата обращения 05.02.2016).
4. Zhang Y. Leaf chlorophyll content retrieval from airborne hyperspectral remote sensing imagery / Y. Zhang, J.M. Chen, J.R. Miller, T.L. Noland // Remote Sensing of Environment. - 2008. № 112. P. 3234-3247.
5. Черепанов А.С., Дружинина Е.Г. Спектральные свойства растительности и вегетационные индексы. Режим доступа: http://sovzond.ru/press-center/geomatics/2009-03/ (дата обращения 10.12.2016).
6. Кабонен А.В., Грязькин А.В., Гаврилова О.И. Оценка состояния лесных культур с использованием беспилотного летательного аппарата // Лесной вестник / Forestry Bulletin, 2024. Т. 28. № 3. С. 57–66. DOI: 10.18698/2542-1468-2024-3-57-66
7. Батырев Ю.П., Поярков Н.Г., Чумаченко С.И., Беляев М.Ю., Сармин Э.Э., Есаков А.М., Черемисин М.В. Особенности проведения космического эксперимента «Дубрава» с борта Российского сегмента МКС // Лесной вестник / Forestry Bulletin, 2022. Т. 26. № 1. С. 135–142. DOI: 10.18698/2542-1468-2022-1-135-142
8. Зотов С.А., Дмитриев Е.В., Шибанов С.Ю. Оценка информационных возможностей гиперспектрального космического комплекса НПО «Лептон» и МФТИ в задаче мониторинга лесных территорий России // Лесной вестник / Forestry Bulletin, 2020. Т. 24. № 3. С. 26–32. DOI: 10.18698/2542-1468-2020-3-26-32

9. Покоева М.В., Ярославцев А.М. Экологические исследования смешанных насаждений методами дистанционного зондирования // Лесной вестник / Forestry Bulletin, 2020. Т. 24. № 3. С. 33–38. DOI: 10.18698/2542-1468-2020-3-33-38.

10. Combating climate change – a role for UK forests. An assessment of the potential of the UK's trees and woodlands to mitigate and adapt to climate change / Ed. Read D.J., Freer-Smith P.H., Morison J.I.L., Hanley N., West C.C., Snowdon P. 2009. The Stationery Office, Edinburgh. 222 p.

11. Boreal Forests in the Face of Climate Change / Ed. Girona M.M.,·Morin H.,·Gauthier S., Bergeron Y. 2023. Springer. Geneva, Switzerland. 859 p.

12. Dmitriev E.V., Kozoderov V.V., Kondranin T.V., Sokolov A.A. Regional monitoring of forest vegetation using airborne hyperspectral remote sensing data. // Proc. of SPIE. 2014. V. 9263. P. 926330-1 - 926330-10.

13. Hycza T., Stereńczak K., Bałazy R. Potential use of hyperspectral data to classify forest tree species. // New Zealand Journal of Forestry Science. 2018. V.48 (18). P. 1- 13.

14. Kayet N. (2021). Forest Health Monitoring using Hyperspectral Remote Sensing Techniques. // Spatial Modeling in Forest Resources Management. Environmental Science and Engineering / Shit P.K., Pourghasemi H.R., Das, P., Bhunia G.S. 2021. Springer, Cham. P. 239–257.

15. Sampson P.H., Zarco-Tejada P.J., Mohammed G.H., Miller J.R., Noland T.L. Hyperspectral Remote Sensing of Forest Condition: Estimating Chlorophyll Content in Tolerant Hardwoods. // Forest Science. 2003. V.49(3). P. 381- 391.

16. Катаев М.Ю., Карташов Е.Ю. Метод компьютерного зрения для обнаружения лесных пожаров по RGB-изображениям, получаемым с помощью беспилотного моторного планёра. // Светотехника. 2021. № 2. С.15-20.

17. Белов М.Л., Белов А.М., Городничев В.А., Альков С.В. Многоспектральный оптический рефлектометрический метод мониторинга лесных ресурсов. // Светотехника. 2021. № 6. С.57-63.

18. Holzwarth S., Thonfeld F., Abdullahi S., Asam A., Da Ponte Canova E., Gessner U., Huth J., Kraus T., Leutner B., Kuenzer C. Earth Observation Based Monitoring of Forests in Germany: A Review. // Remote Sensing. 2020. V. 12. P.1-43.

19. Stoyanov A., Borisova D. Monitoring on forest ecosystems by using space-temporal analysis of different types aerospace data. // Ecological Engineering and Environment Protection. 2017. N.10. P. 31-37.

20. Meerdink S. K., Hook S. J., Abbott E.A., Roberts, D.A. ECOSTRESS Spectral Library - Version 1.0, http://speclib.jpl.nasa.gov/search-1 (2018).

21. Clark R. N., Swayze G. A., Wise R., Livo K. E., Hoefen T. M., Kokaly R. F., Sutley S. J. USGS Digital Spectral Library splib06a, U.S. Geological Survey, Data Series 231, 2007, http://speclab.cr.usgs.gov/spectral.lib06 (2007).

22. Johns Hopkins University Spectral Library [Электронный ресурс] URL: https://speclib.jpl.nasa.gov/documents/jhu_desc (дата обращения 12.08.2025).

23. Candra D.S. Deforestation detection using multitemporal satellite images // IOP Conf. Series: Earth and Environmental Science. 2020. V.500, 012037. P.1-13.

24. Yin C., He B., Quan X., Yebra M., Lai G. Remote Sensing of Burn Severity Using Coupled Radiative Transfer Model: A Case Study on Chinese Qinyuan Pine Fires // Remote Sens. 2020. V.12, 3590. P. 1-19.

25. Коэльо Л. П., Ричарт В. Построение систем машинного обучения на языке Python. М.: Изд-во ДМК Пресс, 2016. 304 с

26. Рашка С., Мирджалили В. Python и машинное обучение. М.: Изд-во Диалектика-Вильямс, 2021. 848 с.

27. Шолле Ф. Глубокое обучение на Python, С.-П.: Изд-во Питер, 2023. 576 с.

28. Флах П. Машинное обучение. М.: Изд-во ДМК пресс, 2015. 400 с.

УДК 621.315.592, 537.311.322

КВАНТОВОХИМИЧЕСКИЙ РАСЧЁТ НЕКОТОРЫХ МОЛЕКУЛ ФУЛЛЕРЕНОВ

В. А. Бабкин[1], Д. С. Андреев[1], М. И. Арцис[2], В. С. Белоусова[3]
А.Е. Харлов[4], М.Н. Гулюкин[5]
1 – Себряковский филиал Волгоградского государственного технического университета, г. Михайловка, Россия.
2 – Институт биохимической физики им. Н.М. Эмануэля РАН, г. Москва, Россия.
3 – Первый Московский государственный медицинский университет им. И.М. Сеченова Минздрава России (Сеченовский университет), г. Москва, Россия.
4 – Московский государственный университет им. М.В. Ломоносова
5 – Лыткаринский завод оптического стекла (ЛЗОС)

Аннотация: В настоящей статье представлены данные квантовохимического расчёта молекул фуллеренов, состоящих из различного количества гексагонов методами MNDO, AM1, PM3, DFT B3LYP и *ab initio* RHF 6-311G**. Получено оптимизированное геометрическое и электронное строение этих молекул. Рассчитаны значения энергии запрещённой зоны исследуемых фуллеренов, по анализу которых предложен наиболее подходящий метод DFT B3LYP для расчёта этой энергии.

Ключевые слова: фуллерен, квантовохимический расчёт, метод MNDO, AM1, PM3, DFT B3LYP, ab initio RHF, энергия запрещённой зоны.

QUANTUM CHEMICAL CALCULATION OF SOME FULLERENE MOLECULES

V. A. Babkin[1], D. S. Andreev[1], M. I. Artsis[2], V. S. Belousova[3], A.E. Kharlov[4]
1 – Sebryakovsky branch of Volgograd State Technical University, Mikhailovka, Russia.
2 – N.M. Emanuel Institute of Biochemical Physics of the Russian Academy of Sciences, Moscow, Russia.
3 – I.M. Sechenov First Moscow State Medical University of the Ministry of Health of the Russian Federation (Sechenov University), Moscow, Russia.
4 – Lomonosov Moscow State University
5 – Lytkarinsky Optical Glass Plant (LZOS)

Abstract: This article presents data on the quantum chemical calculation of fullerene molecules consisting of various amounts of hexagons by MNDO, AM1, PM3, DFT B3LYP and ab initio RHF 6-311G** methods. The optimized geometric and electronic structure of these molecules has been obtained. The values of the band gap energy of the studied fullerenes are calculated, according to the analysis of which the most suitable DFT B3LYP method for calculating this energy is proposed.

Keywords: fullerene, quantum chemical calculation, MNDO method, AM1, PM3, DFT B3LYP, ab initio RHF, band gap energy.

Фуллерены – это аллотропные формы углерода, молекулы которых имеют форму многогранников, состоящих из шести- (*N*) и пятиугольников (*M*) [1]. Фуллерены представляют собой уникальный класс углеродных наноматериалов, обладающих исключительными физическими и химическими свойствами. С момента их открытия в 1985 году изучение фуллеренов стало одной из самых активных областей исследований в области химии и материаловедения [1-3].

Фуллерены могут состоять из разного числа атомов углерода. Самый простой и распространенный фуллерен – C_{60}, известный также как бакминстерфуллерен. Он имеет форму икосаэдра, состоящего из 20 шестиугольников и 12 пятиугольников. Интересно отметить, что независимо от количества шестиугольников N пятиугольников M в фуллеренах всегда должно быть 12; то есть, это число для данных соединений является своеобразной константой. Теорема Эйлера описывает взаимосвязь между количеством вершин, ребер и граней многогранника. Она гласит, что V - E + F = 2, где V - количество вершин, E - количество ребер, а F - количество граней. Это означает, что количество вершин, ребер и граней этих объектов связано формулой V - E + F = 2.

Фуллерены обладают рядом уникальных свойств: они очень прочные и твердые, но при этом легкие и гибкие, обладают высокой электропроводностью и теплопроводностью и могут быть полупроводниками, проводниками или сверхпроводниками в зависимости от условий. Они могут вступать в различные химические реакции – образовывать связи с металлами, другими неметаллами и органическими молекулами, а также могут образовывать комплексные соединения с другими молекулами [1-3].

Фуллерены широко используются в различных областях науки и, в частности медицине, так как являются одними из лучших антиоксидантов известных на

сегодняшний день. В среднем они превосходят действия всех известных антиоксидантов в 100-1000 раз [4-5]. А также они применяются в технике, например, в качестве катализаторов, и в солнечных батареях, в качестве основы для новых материалов и т.д. Соединения фуллеренов являются перспективными материалами для создания новых электронных устройств, солнечных батарей, катализаторов и т.д. [6]. Также весьма интересны оптические свойства фуллеренов [7]. Спектр оптического поглощения фуллеренов характеризуется интенсивностью поглощения электромагнитного излучения в ультрафиолетовом, видимом и ближнем инфракрасном диапазонах. В формировании спектра участвуют переходы двух типов: разрешенные по симметрии — формируют полосы поглощения в коротковолновой области и запрещённые — определяют форму спектра в видимой и ближней инфракрасной области[8]. В настоящее время ведется активное исследование химических соединений фуллеренов, в том числе, методами квантовой химии [9-16]. Ученые изучают их свойства, разрабатывают новые способы их получения и применения. Важную роль в изучении играют квантово-химические методы расчёта. Они позволяют получить детальное представление об электронной структуре, энергетических уровнях, геометрии и свойствах фуллеренов. Эти методы позволяют исследовать поведение фуллеренов в различных условиях изучать их взаимодействие с другими молекулами и поверхностями. Несмотря на то, что фуллерены изучаются с 1985 г., до сих пор самый подходящий квантово-химический метод для расчета энергии запрещенной зоны не был предложен.

Методическая часть

В связи с вышесказанным, целью настоящей работы является квантово-химический расчет фуллеренов с количеством гексагонов 2-21 методами MNDO, AM1, PM3 и DFT B3LYP/6-311G** с оптимизацией геометрии по всем параметрам стандартным градиентным методом, встроенным в программу Firefly/GAMESS [17, 18] в приближении изолированной молекулы в газовой фазе и расчёт энергии запрещённой зоны. Для визуального представления модели молекулы использовалась программа MacMolPlt [19].

Результаты расчётов и их обсуждение

Оптимизированное геометрическое и электронное строение молекул фуллеренов из 2 гексагонов показано на рисунке 1 и в таблице 1, из 20 гексагона – на рисунке 2 и в

таблице 2. Значение длин связей находится в диапазоне 1,36-1,53 А для первой молекулы и в диапазоне 1,36-1,49 А – для второй. Значение зарядов для рассматриваемых молекул находится в диапазоне от -0,004 до 0,003 и от -0,052 до 0,054. Важно отметить, что закон сохранения заряда чётко выполнялся (суммы зарядов на атомах равны 0). Также были получены значения общей энергии.

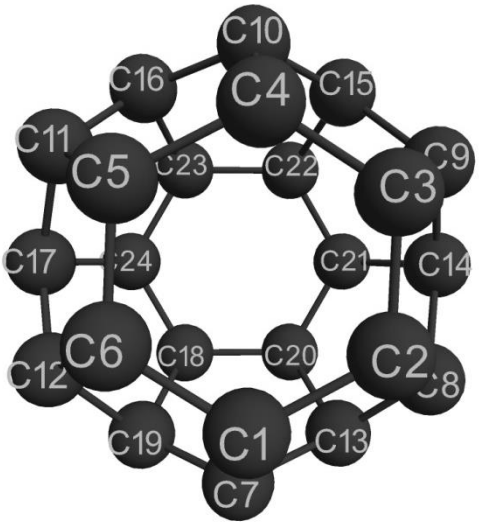

Рисунок 1 – Геометрическое и электронное строение молекулы C_{24}
(E_0= -2399329 кДж/моль)

Таблица 1 – Оптимизированные длины связей, валентные углы и заряды на атомах молекулы $C_{24,}$ полученные методом DFT B3LYP

Длины связей	R,A	Валентные углы	Град	Атом	Заряды на атомах молекулы
C(2)-C(1)	1,42	C(8)-C(2)-C(1)	107	C(1)	+0,002
C(2)-C(8)	1,53	C(5)-C(6)-C(1)	120	C(2)	+0,002
C(3)-C(2)	1,42	C(12)-C(6)-C(1)	106	C(3)	+0,002
C(3)-C(9)	1,53	C(13)-C(7)-C(1)	107	C(4)	+0,002
C(4)-C(3)	1,42	C(14)-C(8)-C(2)	107	C(5)	+0,002
C(4)-C(10)	1,53	C(9)-C(3)-C(2)	107	C(6)	+0,002
C(5)-C(4)	1,42	C(13)-C(8)-C(2)	109	C(7)	-0,002
C(5)-C(11)	1,53	C(1)-C(2)-C(3)	120	C(8)	-0,003
C(6)-C(5)	1,42	C(8)-C(2)-C(3)	106	C(9)	-0,002
C(6)-C(1)	1,42	C(15)-C(9)-C(3)	107	C(10)	-0,001
C(6)-C(12)	1,53	C(10)-C(4)-C(3)	107	C(11)	-0,003
C(7)-C(13)	1,46	C(14)-C(9)-C(3)	109	C(12)	-0,002
C(7)-C(1)	1,53	C(2)-C(3)-C(4)	120	C(13)	-0,002
C(8)-C(14)	1,46	C(9)-C(3)-C(4)	106	C(14)	-0,002

Длины связей	R,A	Валентные углы	Град	Атом	Заряды на атомах молекулы
C(9)-C(15)	1,46	C(16)-C(10)-C(4)	107	C(15)	-0,004
C(10)-C(16)	1,46	C(11)-C(5)-C(4)	107	C(16)	-0,002
C(11)-C(17)	1,46	C(15)-C(10)-C(4)	110	C(17)	-0,002
C(12)-C(19)	1,46	C(3)-C(4)-C(5)	120	C(18)	+0,001
C(13)-C(8)	1,36	C(10)-C(4)-C(5)	106	C(19)	-0,003
C(13)-C(20)	1,53	C(17)-C(11)-C(5)	107	C(20)	+0,002
C(14)-C(9)	1,36	C(12)-C(6)-C(5)	107	C(21)	+0,002
C(14)-C(21)	1,53	C(16)-C(11)-C(5)	109	C(22)	+0,003
C(15)-C(10)	1,36	C(4)-C(5)-C(6)	120	C(23)	+0,002
C(15)-C(22)	1,53	C(11)-C(5)-C(6)	106	C(24)	+0,003
C(16)-C(11)	1,36	C(2)-C(1)-C(6)	120		
C(16)-C(23)	1,53	C(19)-C(12)-C(6)	107		
C(17)-C(12)	1,36	C(17)-C(12)-C(6)	109		
C(17)-C(24)	1,53	C(8)-C(13)-C(7)	109		
C(18)-C(19)	1,53	C(20)-C(13)-C(7)	107		
C(19)-C(7)	1,36	C(2)-C(1)-C(7)	106		
C(20)-C(18)	1,42	C(9)-C(14)-C(8)	109		
C(21)-C(20)	1,42	C(21)-C(14)-C(8)	107		
C(22)-C(21)	1,42	C(20)-C(13)-C(8)	110		
C(23)-C(22)	1,42	C(10)-C(15)-C(9)	109		
C(23)-C(24)	1,42	C(22)-C(15)-C(9)	107		
C(24)-C(18)	1,42	C(21)-C(14)-C(9)	109		
		C(11)-C(16)-C(10)	109		
		C(23)-C(16)-C(10)	107		
		C(22)-C(15)-C(10)	109		
		C(12)-C(17)-C(11)	109		
		C(24)-C(17)-C(11)	107		
		C(23)-C(16)-C(11)	110		
		C(7)-C(19)-C(12)	109		
		C(24)-C(17)-C(12)	109		
		C(18)-C(19)-C(12)	107		
		C(14)-C(8)-C(13)	109		
		C(18)-C(20)-C(13)	106		
		C(21)-C(20)-C(13)	107		
		C(15)-C(9)-C(14)	109		
		C(20)-C(21)-C(14)	106		
		C(22)-C(21)-C(14)	107		
		C(16)-C(10)-C(15)	109		
		C(21)-C(22)-C(15)	106		

Длины связей	R,A	Валентные углы	Град	Атом	Заряды на атомах молекулы
		C(23)-C(22)-C(15)	107		
		C(17)-C(11)-C(16)	109		
		C(22)-C(23)-C(16)	106		
		C(24)-C(23)-C(16)	107		
		C(19)-C(12)-C(17)	109		
		C(18)-C(24)-C(17)	107		
		C(23)-C(24)-C(17)	106		
		C(7)-C(19)-C(18)	109		
		C(13)-C(7)-C(19)	109		
		C(1)-C(7)-C(19)	110		
		C(19)-C(18)-C(20)	107		
		C(24)-C(18)-C(20)	120		
		C(18)-C(20)-C(21)	120		
		C(20)-C(21)-C(22)	120		
		C(24)-C(23)-C(22)	120		
		C(21)-C(22)-C(23)	120		
		C(18)-C(24)-C(23)	120		
		C(19)-C(18)-C(24)	106		

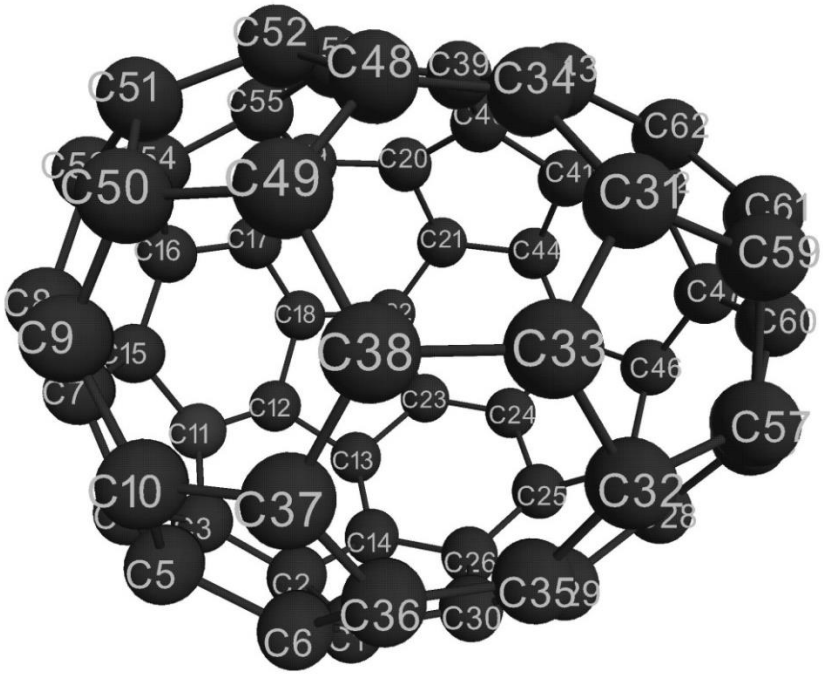

Рисунок 2 – Геометрическое и электронное строение молекулы C_{62}.

(E_0= -6202192 кДж/моль)

Таблица 2 – Оптимизированные длины связей, валентные углы и заряды на атомах молекулы $C_{62,}$ полученные методом DFT B3LYP

Длины связей	R,A	Валентные углы	Град	Атом	Заряды на атомах молекулы
C(2)-C(14)	1,44	C(14)-C(2)-C(1)	108	C(1)	+0,002
C(2)-C(1)	1,45	C(36)-C(6)-C(1)	119	C(2)	+0,001
C(3)-C(2)	1,39	C(29)-C(30)-C(1)	122	C(3)	-0,002
C(4)-C(3)	1,45	C(13)-C(14)-C(2)	120	C(4)	+0,005
C(4)-C(7)	1,46	C(26)-C(14)-C(2)	108	C(5)	-0,003
C(5)-C(4)	1,39	C(14)-C(2)-C(3)	120	C(6)	-0,003
C(5)-C(6)	1,45	C(1)-C(2)-C(3)	120	C(7)	-0,003
C(5)-C(10)	1,45	C(7)-C(4)-C(3)	108	C(8)	+0,011
C(6)-C(1)	1,39	C(2)-C(3)-C(4)	120	C(9)	+0,017
C(6)-C(36)	1,43	C(15)-C(7)-C(4)	107	C(10)	-0,007
C(7)-C(15)	1,46	C(11)-C(3)-C(4)	108	C(11)	0,00
C(8)-C(7)	1,38	C(6)-C(5)-C(4)	120	C(12)	+0,002
C(8)-C(53)	1,47	C(10)-C(5)-C(4)	120	C(13)	0,00
C(9)-C(8)	1,47	C(8)-C(7)-C(4)	121	C(14)	-0,002
C(10)-C(9)	1,42	C(3)-C(4)-C(5)	120	C(15)	+0,002
C(11)-C(3)	1,45	C(7)-C(4)-C(5)	120	C(16)	-0,001
C(12)-C(11)	1,39	C(1)-C(6)-C(5)	121	C(17)	-0,002
C(12)-C(18)	1,45	C(36)-C(6)-C(5)	109	C(18)	0,00
C(13)-C(12)	1,45	C(9)-C(10)-C(5)	120	C(19)	-0,003
C(13)-C(23)	1,45	C(37)-C(10)-C(5)	108	C(20)	-0,004
C(14)-C(13)	1,39	C(2)-C(1)-C(6)	120	C(21)	-0,001
C(14)-C(26)	1,45	C(35)-C(36)-C(6)	121	C(22)	-0,001
C(15)-C(11)	1,45	C(37)-C(36)-C(6)	107	C(23)	+0,003
C(16)-C(15)	1,40	C(10)-C(5)-C(6)	108	C(24)	+0,001
C(16)-C(54)	1,45	C(11)-C(15)-C(7)	108	C(25)	-0,001
C(17)-C(16)	1,44	C(53)-C(8)-C(7)	119	C(26)	-0,004
C(17)-C(19)	1,45	C(16)-C(15)-C(7)	120	C(27)	-0,006
C(18)-C(17)	1,39	C(15)-C(7)-C(8)	121	C(28)	+0,05
C(18)-C(22)	1,45	C(51)-C(53)-C(8)	107	C(29)	+0,019
C(19)-C(55)	1,45	C(54)-C(53)-C(8)	120	C(30)	-0,01
C(20)-C(19)	1,38	C(7)-C(8)-C(9)	120	C(31)	+0,003
C(20)-C(40)	1,45	C(53)-C(8)-C(9)	107	C(32)	+0,012
C(21)-C(20)	1,46	C(8)-C(9)-C(10)	119	C(33)	-0,026
C(22)-C(21)	1,40	C(50)-C(9)-C(10)	118	C(34)	+0,029
C(23)-C(22)	1,45	C(38)-C(37)-C(10)	121	C(35)	+0,037
C(24)-C(23)	1,39	C(2)-C(3)-C(11)	120	C(36)	-0,01
C(24)-C(25)	1,46	C(18)-C(12)-C(11)	120	C(37)	-0,001

Длины связей	R,A	Валентные углы	Град	Атом	Заряды на атомах молекулы
C(24)-C(45)	1,44	C(3)-C(11)-C(12)	120	C(38)	+0,054
C(25)-C(27)	1,45	C(17)-C(18)-C(12)	119	C(39)	+0,024
C(26)-C(25)	1,38	C(22)-C(18)-C(12)	108	C(40)	-0,006
C(26)-C(30)	1,46	C(15)-C(11)-C(12)	120	C(41)	-0,011
C(27)-C(28)	1,43	C(23)-C(13)-C(12)	108	C(42)	+0,01
C(28)-C(58)	1,43	C(11)-C(12)-C(13)	120	C(43)	+0,04
C(28)-C(29)	1,48	C(18)-C(12)-C(13)	108	C(44)	-0,002
C(29)-C(35)	1,47	C(22)-C(23)-C(13)	108	C(45)	-0,004
C(30)-C(29)	1,41	C(26)-C(14)-C(13)	120	C(46)	-0,006
C(30)-C(1)	1,44	C(24)-C(23)-C(13)	120	C(47)	+0,003
C(31)-C(34)	1,45	C(12)-C(13)-C(14)	120	C(48)	-0,015
C(32)-C(33)	1,48	C(23)-C(13)-C(14)	120	C(49)	-0,009
C(33)-C(31)	1,42	C(25)-C(26)-C(14)	120	C(50)	-0,038
C(34)-C(43)	1,49	C(30)-C(26)-C(14)	109	C(51)	-0,036
C(35)-C(32)	1,45	C(3)-C(11)-C(15)	108	C(52)	0,00
C(36)-C(35)	1,40	C(54)-C(16)-C(15)	120	C(53)	0,00
C(36)-C(37)	1,49	C(11)-C(15)-C(16)	120	C(54)	-0,003
C(37)-C(10)	1,41	C(53)-C(54)-C(16)	120	C(55)	-0,007
C(37)-C(38)	1,43	C(19)-C(17)-C(16)	107	C(56)	+0,037
C(38)-C(33)	1,40	C(55)-C(54)-C(16)	108	C(57)	-0,052
C(38)-C(49)	1,43	C(15)-C(16)-C(17)	120	C(58)	+0,006
C(39)-C(56)	1,47	C(54)-C(16)-C(17)	108	C(59)	-0,041
C(40)-C(39)	1,42	C(55)-C(19)-C(17)	109	C(60)	-0,047
C(41)-C(40)	1,44	C(22)-C(18)-C(17)	120	C(61)	+0,018
C(41)-C(44)	1,46	C(20)-C(19)-C(17)	120	C(62)	-0,018
C(42)-C(41)	1,38	C(16)-C(17)-C(18)	121		
C(42)-C(47)	1,48	C(19)-C(17)-C(18)	119		
C(42)-C(62)	1,44	C(21)-C(22)-C(18)	120		
C(43)-C(39)	1,47	C(23)-C(22)-C(18)	108		
C(44)-C(21)	1,44	C(54)-C(55)-C(19)	107		
C(45)-C(44)	1,40	C(40)-C(20)-C(19)	120		
C(45)-C(46)	1,45	C(56)-C(55)-C(19)	121		
C(46)-C(27)	1,44	C(55)-C(19)-C(20)	120		
C(47)-C(46)	1,40	C(39)-C(40)-C(20)	122		
C(48)-C(34)	1,40	C(41)-C(40)-C(20)	107		
C(48)-C(49)	1,45	C(19)-C(20)-C(21)	120		
C(48)-C(52)	1,46	C(40)-C(20)-C(21)	108		
C(49)-C(50)	1,41	C(20)-C(21)-C(22)	119		
C(50)-C(9)	1,40	C(44)-C(21)-C(22)	121		

Длины связей	R,A	Валентные углы	Град	Атом	Заряды на атомах молекулы
C(51)-C(50)	1,46	C(21)-C(22)-C(23)	119		
C(52)-C(51)	1,40	C(25)-C(24)-C(23)	120		
C(52)-C(56)	1,43	C(45)-C(24)-C(23)	121		
C(53)-C(51)	1,41	C(22)-C(23)-C(24)	120		
C(54)-C(53)	1,39	C(27)-C(25)-C(24)	109		
C(55)-C(54)	1,45	C(44)-C(45)-C(24)	119		
C(56)-C(55)	1,43	C(46)-C(45)-C(24)	108		
C(57)-C(32)	1,37	C(26)-C(25)-C(24)	120		
C(57)-C(58)	1,45	C(28)-C(27)-C(25)	121		
C(57)-C(59)	1,47	C(45)-C(24)-C(25)	107		
C(58)-C(60)	1,42	C(30)-C(26)-C(25)	120		
C(59)-C(31)	1,43	C(46)-C(27)-C(25)	107		
C(60)-C(47)	1,40	C(27)-C(25)-C(26)	120		
C(60)-C(61)	1,48	C(29)-C(30)-C(26)	122		
C(61)-C(59)	1,36	C(1)-C(30)-C(26)	107		
C(61)-C(62)	1,45	C(58)-C(28)-C(27)	116		
C(62)-C(43)	1,42	C(29)-C(28)-C(27)	118		
		C(60)-C(58)-C(28)	120		
		C(35)-C(29)-C(28)	119		
		C(30)-C(29)-C(28)	118		
		C(57)-C(58)-C(28)	120		
		C(32)-C(35)-C(29)	118		
		C(58)-C(28)-C(29)	119		
		C(36)-C(35)-C(29)	120		
		C(35)-C(29)-C(30)	117		
		C(2)-C(1)-C(30)	109		
		C(43)-C(34)-C(31)	119		
		C(48)-C(34)-C(31)	115		
		C(31)-C(33)-C(32)	107		
		C(38)-C(33)-C(32)	122		
		C(58)-C(57)-C(32)	121		
		C(59)-C(57)-C(32)	107		
		C(34)-C(31)-C(33)	119		
		C(59)-C(31)-C(33)	106		
		C(49)-C(38)-C(33)	116		
		C(39)-C(43)-C(34)	119		
		C(62)-C(43)-C(34)	117		
		C(49)-C(48)-C(34)	121		
		C(52)-C(48)-C(34)	122		

Длины связей	R,A	Валентные углы	Град	Атом	Заряды на атомах молекулы
		C(33)-C(32)-C(35)	119		
		C(57)-C(32)-C(35)	121		
		C(37)-C(36)-C(35)	122		
		C(32)-C(35)-C(36)	116		
		C(10)-C(37)-C(36)	108		
		C(38)-C(37)-C(36)	120		
		C(9)-C(10)-C(37)	120		
		C(33)-C(38)-C(37)	118		
		C(49)-C(38)-C(37)	118		
		C(31)-C(33)-C(38)	121		
		C(50)-C(49)-C(38)	119		
		C(48)-C(49)-C(38)	119		
		C(55)-C(56)-C(39)	120		
		C(52)-C(56)-C(39)	118		
		C(56)-C(39)-C(40)	117		
		C(43)-C(39)-C(40)	118		
		C(44)-C(41)-C(40)	109		
		C(39)-C(40)-C(41)	122		
		C(21)-C(44)-C(41)	107		
		C(47)-C(42)-C(41)	119		
		C(62)-C(42)-C(41)	120		
		C(45)-C(44)-C(41)	119		
		C(40)-C(41)-C(42)	120		
		C(44)-C(41)-C(42)	121		
		C(46)-C(47)-C(42)	119		
		C(43)-C(62)-C(42)	122		
		C(60)-C(47)-C(42)	108		
		C(61)-C(62)-C(42)	105		
		C(56)-C(39)-C(43)	120		
		C(20)-C(21)-C(44)	108		
		C(46)-C(45)-C(44)	120		
		C(21)-C(44)-C(45)	120		
		C(27)-C(46)-C(45)	108		
		C(47)-C(46)-C(45)	120		
		C(28)-C(27)-C(46)	122		
		C(27)-C(46)-C(47)	119		
		C(62)-C(42)-C(47)	109		
		C(61)-C(60)-C(47)	107		
		C(43)-C(34)-C(48)	119		

Длины связей	R,A	Валентные углы	Град	Атом	Заряды на атомах молекулы
		C(50)-C(49)-C(48)	107		
		C(51)-C(52)-C(48)	107		
		C(56)-C(52)-C(48)	120		
		C(9)-C(50)-C(49)	122		
		C(52)-C(48)-C(49)	108		
		C(51)-C(50)-C(49)	109		
		C(8)-C(9)-C(50)	108		
		C(9)-C(50)-C(51)	109		
		C(56)-C(52)-C(51)	121		
		C(50)-C(51)-C(52)	108		
		C(55)-C(56)-C(52)	116		
		C(53)-C(51)-C(52)	122		
		C(50)-C(51)-C(53)	109		
		C(51)-C(53)-C(54)	118		
		C(53)-C(54)-C(55)	120		
		C(54)-C(55)-C(56)	122		
		C(33)-C(32)-C(57)	109		
		C(60)-C(58)-C(57)	106		
		C(31)-C(59)-C(57)	109		
		C(61)-C(59)-C(57)	107		
		C(47)-C(60)-C(58)	122		
		C(61)-C(60)-C(58)	107		
		C(59)-C(57)-C(58)	108		
		C(34)-C(31)-C(59)	120		
		C(62)-C(61)-C(59)	123		
		C(46)-C(47)-C(60)	119		
		C(59)-C(61)-C(60)	110		
		C(62)-C(61)-C(60)	109		
		C(31)-C(59)-C(61)	119		
		C(43)-C(62)-C(61)	120		
		C(39)-C(43)-C(62)	118		

В таблице 3 приведено сравнение энергии запрещённой зоны в зависимости от количества гексагонов, полученных квантовохимическими методами MNDO, AM1, PM3, DFT B3LYP и *ab initio* RHF 6-311G**.

Таблица 3 – Значения энергии запрещённой зоны E_H (эВ), полученные квантовохимическими методами MNDO, AM1, PM3, DFT B3LYP и *ab initio* RHF 6-311G**, где N – количество шестиугольников в молекуле фуллерена, а M для всех соединений равно 12

N, шт.	E_H, эВ				
	MNDO	AM1	PM3	DFT B3LYP 6-311G**	*ab initio* RHF 6-311G**
2	5,52	5,04	5,11	1,82	6,54
3	5,94	5,80	5,72	1,65	7,00
4	5,51	5,93	5,78	1,59	6,69
5	5,73	5,58	5,47	1,35	6,19
6	5,86	5,63	5,54	2,03	6,65
7	5,29	4,82	4,81	1,45	5,77
8	5,17	5,01	4,89	1,34	6,25
9	5,08	4,94	4,82	1,26	5,30
10	5,79	5,71	5,60	1,52	6,35
11	5,13	4,94	4,86	1,20	5,53
12	5,64	5,59	5,51	1,65	6,24
13	5,36	5,21	5,16	1,41	5,86
14	5,32	5,11	5,07	1,74	5,88
15	4,89	4,62	4,55	1,50	5,30
16	5,50	5,45	5,36	1,74	6,16
17	4,97	4,79	4,71	0,96	5,21
18	5,24	5,12	5,07	1,47	5,83
19	4,75	4,45	4,47	0,91	5,03
20	6,56	6,69	6,58	2,73	7,33

Из приведённых данных видно, что чёткой зависимости между величиной энергии запрещённой зоны и количеством гексагонов в фуллерене нет. Однако, исходя из полученных данных, метод DFT/B3LYP 6-311G** является наиболее подходящим для дальнейших исследований, потому что даёт значения энергии запрещённой зоны в диапазоне 0,91-2,73 эВ, что соответствует известным литературным данным [20], и относят фуллерены к классу полупроводников согласно классической зонной теории [21], в то время, как методы MNDO, AM1, PM3 и в том числе *ab initio* RHF 6-311G** эти значения завышают.

Полученные данные квантово-химических расчетов фуллеренов могут способствовать объяснению различных физико-химических свойств фуллеренов и в частности оптических.

Литература

1. Елецкий А. В., Смирнов Б. М. Фуллерены и структуры углерода // Успехи физических наук. - 1995. -№ 9, с. 977–1009.
2. Сидоров Л.Н., Юровская М.А. и др. Фуллерены: учебное пособие // М.: Экзамен, 2005. - 690 с.
3. Шпилевский Э. Фуллерены — новые молекулы для новых материалов // Наука и инновации. - 2006. - №5 (39), с.32-38.
4. Сабиров Д. Ш., Булгаков Р. Г., Хурсан С. Л. Оценка реакционной способности фуллеренов методами квантовой химии // Вестник Башкирск. ун-та. 2009. №3. с.734-742.
5. Сабиров Д. Ш., Булгаков Р. Г., Хурсан С. Л. Квантовохимическое моделирование фуллеренильных радикалов CNF (n = 20, 24, 30, 36, 40, 60, 70, 76) // Вестник Башкирского университета. – 2010. – Т. 15, № 1. – С. 15-17.
6. Schmidt M. W., Baldridge K. K., Boatz J. A., Elbert S. T., Gordon M. S., Jensen J. H., Koseki S., Matsunaga N., Nguyen K. A., Su S. J., Windus T. L., Dupuis M., Montgomery J. A. General Atomic and Molecular Electronic Structure System // Journal of Computational Chemistry. 1993. Vol.14. PP.1347 – 1363.
7. Granovsky A.A. Firefly version 8: [Электронный ресурс] // Firefly computational chemistry program. 2013. URL: http://classic.chem.msu.su/gran/firefly/index.html (дата обращения: 15.01.2024).

8. Bode B.M., Gordon M.S. MacMolPlt: A Graphical User Interface for GAMESS // Journal of Molecular Graphics and Modelling. 1998. №16. PP. 133 – 138.

9. Макарова Т.Л. Электрические и оптические свойства мономерных и полимеризованных фуллеренов // Физика и техника полупроводников, 2001, том 35, вып. 3, с.257-293.

10. Шалимова К.В. Физика полупроводников. // М .:. Энергоатомиздат, - 1985. – 392 с.

11. А. В. Елецкий, Б. М. Смирнов, “Фуллерены”, УФН, 163:2 (1993), 33–60; Phys. Usp., 36:2 (1993), 202–224

12. Л.Н. Сидоров, М.А. Юровская, А.Я. Борщевский, И.В. Трушков, И.Н. Иоффе Фуллерены Учебное пособие М: Издательство "Экзамен", 2005. — 688 с. (Серия "Учебное пособие для вузов") ISBN 5-472-00294-X

13. Фуллерен // Википедия URL: https://ru.wikipedia.org/wiki/Фуллерен (дата обращения: 15.05.2025).

14. Вуль А. Я. Фуллерены как материал для электронной техники // «Материалы электронной техники. Известия вузов»,1999, №3 стр.4

15. Лобанов Б. В. Энергетический спектр и спектры оптического поглощения фуллеренов и эндоэдральных наночастиц на их основе: дис. канд. ф.-м. наук 01.04.07 / Лобанов Б. В. — Томск, 2018. - 133 с.

16. Салем М.А., Гришаков К.С., Гимальдинова М.А.Квантово-химическое исследование структурного дефекта стоуна-уэльса в функционализированном фуллерене C20 // Краткие сообщения по физике ФИАН. 2018. Т. 45. № 8. С. 3-7.

17. Кадыргулов М.В. Фуллерены: особенности строения, получение, свойства // Наука через призму времени. 2022. № 6 (63). С. 25-27.

18. Терещенко В.И., Семакина Н.В. Квантово-химическое моделирование эндоэдральных комплексов фуллеренов с неметаллами // Химическая физика и мезоскопия. 2023. Т. 25. № 3. С. 362-374.

19. Жанхаева Я.С., Султанова Л.М. Исследование фуллеренов с применением ик спектроскопии // Colloquium-Journal. 2020. № 14-1 (66). С. 39-42.

20. Лобанов Б.В., Мурзашев А.И. Электронные и оптические свойства фуллерена C70 в рамках концепции сильно коррелированного состояния // Физика твердого тела. 2017. Т. 59. № 2. С. 409-413.

21. Васильев М.М., Костюкова Л.О. Анализ взаимодействия фуллерена С60 с органическими растворителями методами квантовой механики // Актуальные вопросы биологической физики и химии. 2019. Т. 4. № 4. С. 523-526.

УДК 504.064

ЭКСПЕРИМЕНТАЛЬНЫЕ ИССЛЕДОВАНИЯ СПЕКТРОВ ОТРАЖЕНИЯ ПЛАСТИКОВЫХ ЗАГРЯЗНЕНИЙ В БЛИЖНЕЙ ИК ОБЛАСТИ

Нгуен Минь Бач, Ю.В. Федотов, Н.В. Барышников, М.Л. Белов

Аннотация: Статья посвящена экспериментальным исследованиям спектров отражения различных пластиковых загрязнений земной поверхности в ближней инфракрасной области спектра. Показано, что в спектрах отражения различных видов пластика в ближней инфракрасной ИК спектра существуют спектральные провалы (в разной степени выраженные), характерные для почв, загрязненных нефтью и нефтепродуктами, и вызванные поглощением излучения углеводородами. Такие пластиковые загрязнения могут создавать ложные тревоги для дистанционных систем обнаружения утечек нефтепродуктов в ближней инфракрасной области спектра. Пластиковые загрязнения могут давать большую вероятность ложных тревог (более 82%) для задачи обнаружения разливов нефтепродуктов на земной поверхности (в случае, когда разливов нет, но присутствуют пластиковые загрязнения).

Ключевые слова: ближний ИК диапазон, обнаружение утечек нефтепродуктов, земная поверхность, пла-стиковые загрязнения.

EXPERIMENTAL STUDIES OF THE REFLECTION SPECTRA OF PLASTIC CONTAMINANTS IN THE NEAR-INFRARED REGION

Bach Nguyen Minh, Yu.V. Fedotov, N.V. Baryshnikov, M.L. Belov

Abstract: The article is devoted to experimental studies of the reflection spectra of various plastic pollutants of the Earth's surface in the near-infrared region of the spectrum. It is shown that there are spectral dips in the reflection spectra of various types of plastics in the near-infrared IR spectrum, which are characteristic of soils contaminated with oil and petroleum products and caused by the absorption of radiation by hydrocarbons. Such plastic contamination can create false alarms for remote oil leak detection systems in the near-infrared region of the spectrum. Plastic pollution can give a high probability of false alarms (more than 82%) for the task of detecting oil spills on the earth's surface (in the case when there are no spills, but plastic pollution is present).

Keywords: near IR range, detection of oil pollution, earth's surface.

Введение

На сегодняшний день актуальной является задача оперативного обнаружения разливов нефтепродуктов на земной поверхности (см., например, [1-4]).

Одним из наиболее перспективных методов оперативного мониторинга (например, с беспилотного летательного аппарата) разливов нефтепродуктов является метод, использующий измерение спектров отражения загрязненной нефтепродуктами земной поверхности в ближней инфракрасной (ИК) области спектра (см., например, [5-9]).

Физической основой этого метода является появление особенностей в форме спектров отражения при наличии на земной поверхности углеводородов.

Постановка задачи

Задача создания оптических методов и приборов для обнаружения утечек нефтепроводов и нефтяных загрязнений на земной поверхности является сложной из-за трудности обнаружения нефтяных загрязнений на фоне разноообразных элементов земного ландшафта и антропогенных загрязнений земной поверхности, некоторые из которых содержат химические структуры с углеродом и водородом (характерные для нефтяных загрязнений).

Наиболее перспективным для обнаружения утечек нефтепроводов и нефтяных загрязнений на земной поверхности (для метода, использующего измерение спектров отражения) является спектральный диапазон 1,6-2,5 мкм.

К настоящему времени в этом спектральном диапазоне проведены экспериментальные исследования спектров отражения разных нефтепродуктов, разлитых на разных почвах (см., например, [5-11]).

Однако, работ посвященных экспериментальным исследованиям спектров пластиковых загрязнений земной поверхности (которые потенциально являются мешающими факторами для задачи мониторинга утечек нефтепродуктов) в спектральном диапазоне 1,6-2,4 мкм в настоящее время мало (см., например, [12-15]).

Ниже в статье приводятся результаты экспериментальных исследований спектров отражения в ближнем ИК диапазоне некоторых пластиковых загрязнений на земной поверхности, которые могут служить источниками ложных тревог для

оптических систем обнаружения утечек нефтепроводов и нефтяных загрязнений на земной поверхности в ближней ИК области спектра.

Описание экспериментальной установки

Измерения спектров отражения различных видов пластиковых загрязнений на земной поверхности проводились на созданной лабораторной установке.

Основным блоком лабораторной установки является спектрометр OPTOSKY ATP8000 ближнего инфракрасного диапазона [16]. Спектрометр OPTOSKY ATP8000 обеспечивает регистрацию сигнала в спектральном диапазоне в диапазоне 0,9-2,5 мкм со спектральным разрешением ~ 10 нм.

На экспериментальной установке измерялся коэффициент яркости: отношение яркости, регистрируемой приемной системой в направлении близком к вертикальному, к яркости, регистрируемой приемной системой от эталонного отражателя.

Подробно лабораторная установка для измерения спектров отражения описана в [17].

На лабораторной установке в спектральном диапазоне 1,6-2,4 мкм измерены спектры отражения: различных типов почв; разных нефтепродуктов (товарная нефть, дизельное топлива, машинное масло, бензин), разлитых на различных типах почв; разных видов пластика.

Результаты экспериментальных исследований спектров отражения

На рисунке 1 для примера приведены спектры отражения в ближнем инфракрасном диапазоне: почвы, загрязненной товарной нефтью Рязанского нефтеперерабатывающего завода (НПЗ), – см. рисунок 1а и почвы, загрязненной отработанным моторным маслом – см. рисунок 1б. Наличие углеводородов на почве проявляется (для спектральной области 1,6-2,4 мкм) в поглощении излучения в спектральных интервалах около длин волн 1,73 и 2,3 мкм.

На всех рисунках (на рисунке 1 и на приведенных ниже рисунках 5-7) приведены средние (по 30 изменениям) коэффициенты яркости, соответствующих образцов загрязненной нефтепродуктами почвы или пластиковых загрязнений.

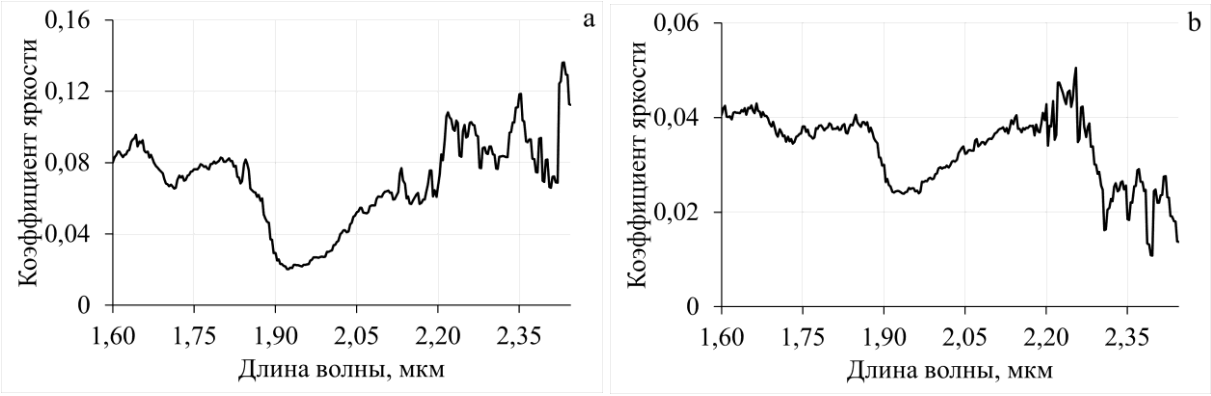

Рисунок 1 – Загрязненная почва: *а* – почва, загрязненная нефтью Рязанского НПЗ; *b* – отработанным моторным маслом

На лабораторной установке проводились измерения спектров отражения различных видов пластика.

Для пластика измерялись спектры отражения образцов, изготовленные из соответствующих материалов. На рисунках 2-4 приведены фотографии некоторых образцов, которые использовались для измерения спектров отражения.

Здесь: рисунок 2*а* - лист для упаковки голубого цвета из пенополиэтилена $(C_2H_4)_n$; рисунок 2*б* – пластиковый плинтус из поливинилхлорида $(C_2H_3Cl)_n$; рисунок 3*а* – материал тента для грузовиков из тканевой синтетической основы и поливинилхлорида; рисунок 3*б* – крышка для стеклянных банок из полиэтилена высокой плотности $(C_2H_4)_n$; рисунок 4*а* - фурнитура для электрической розетки из полипропилена $(C_3H_6)_n$; рисунок 4*б* – белый пакет из полиэтилена низкой плотности $(C_2H_4)_n$.

а *б*

Рисунок 2 – Фотографии некоторых образцов: *а* – пенополиэтилен для упаковки голубого цвета, б – пластиковый плинтус

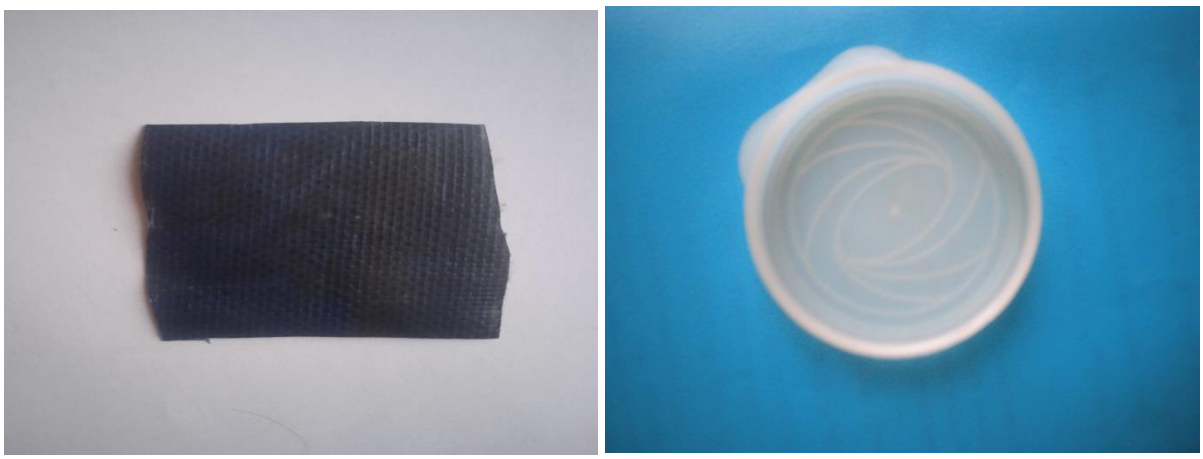

а *б*

Рисунок 3 – Фотографии некоторых образцов: *а* – материал тента для грузовиков, *б* – крышка для стеклянных банок

а *б*

Рисунок 4 – Фотографии некоторых образцов: *а* – фурнитура для электрической розетки, *б* – пакет полиэтиленовый

Результаты измерения спектров отражения в ближней ИК области спектра пластиков, фотографии которых показаны на рисунках 2-4, приведены на рисунках 5-7.

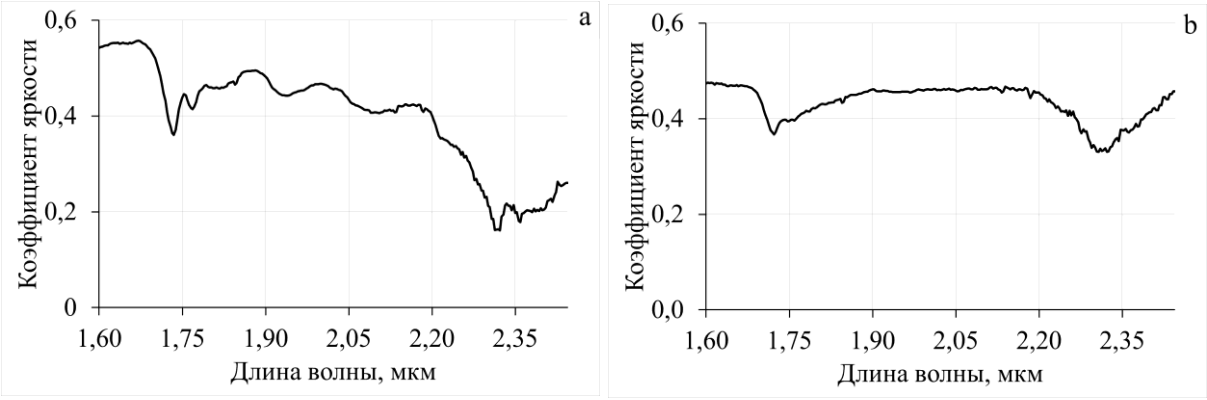

Рисунок 5 – Спектры отражения: *a* – пенополиэтилена для упаковки, *b* – пластикового плинтуса

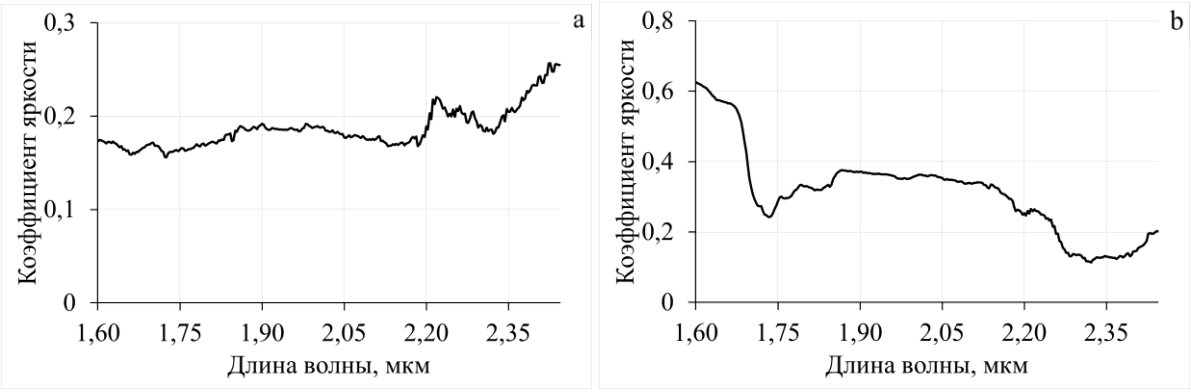

Рисунок 6 – Спектры отражения: *a* – материала тента для грузовиков, *b* – крышки для банок

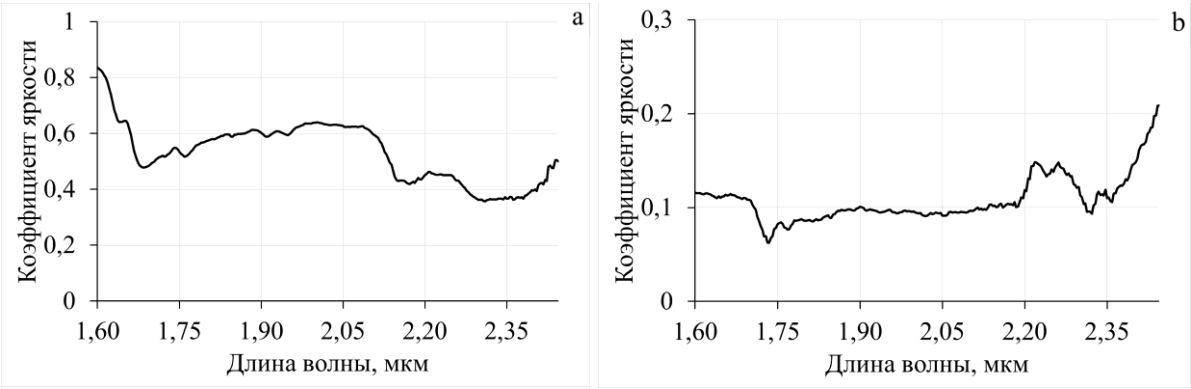

Рисунок 7 – Спектры отражения: a – электрической розетки, b – полиэтиленового пакета

Анализ полученных результатов

Рисунки 5-7 показывают, что в спектрах отражения различных видов пластика существуют в разной степени выраженные спектральные провалы (около длин волн

1,73 и 2,3 мкм), характерные для почв, загрязненных нефтью и нефтепродуктами, и вызванные поглощением излучения углеводородами.

Для количественной оценки ложных тревог, вызванных пластиковыми загрязнениями, для метода мониторинга нефтяных загрязнений, основанного на гиперспектральной съемки в ближней ИК области, проводился анализ результатов работы разработанной нейронной сети, использующей наши данные измерений.

Входными данными для нейронной сети являлись измеренные (для незагрязненных почв и почв, загрязненных нефтепродуктами; для различного вида пластиковых загрязнений) коэффициенты яркости в спектральных диапазонах 1600 - 1800 нм и 2100-2400 нм. Выбор этих спектральных диапазонов обусловлен тем, что здесь находятся окна прозрачности земной атмосферы (см., например, [18]).

Для работы нейронной сети были использованы измеренные на лабораторной установке спектры отражения в диапазоне 1,6 – 2,4 мкм: разные типы почв и песка с нефтяными загрязнениями (разные типы нефтепродуктов – товарная нефть, дизельное топлива, машинное масло, бензин) – 485 спектров; пластиковые загрязнения (разные виды пластика – полиэтилена низкой и высокой плотности, полипропилена, поливинилхлорида разного цвета, пенополиэтилена) – 180 спектров.

Половина измеренных спектров отражения (для разных типов почв и песка с разными нефтяными загрязнениями) была использована для обучения нейронной сети для задачи обнаружения разливов нефтепродуктов на поверхности почвы. Другая половина спектров отражения была использована для оценки вероятности правильного обнаружения нефтепродуктов. Спектры отражения пластиковых загрязнений были использованы для оценки вероятности ложных тревог (для задачи обнаружения разливов нефтепродуктов на земной поверхности).

Результаты работы нейронной сети показаны в таблице 1.

В таблице 1 величина N1 – оценка вероятности правильного обнаружения нефтепродуктов (процент количества спектров для образцов, загрязненных нефтепродуктами, которые нейронная сеть после обучения правильно определила как спектры образцов, загрязненных нефтепродуктами) и величина N2 – оценка вероятности ложных тревог (процент количества спектров для образцов, незагрязненных нефтепродуктами, которые нейронная сеть после обучения неправильно определила как спектры образцов, загрязненных нефтепродуктами).

В таблице 1 приведены результаты работы нейронной сети (величины N1, N2) для трех вариантов входных данных:

- 20 спектральных каналов с шириной 10 нм в диапазоне 1600 – 1800 нм и 29 спектральных каналов с шириной 10 нм в диапазоне 2100 - 2390 нм (вариант 1);
- 20 спектральных каналов с шириной 10 нм в диапазоне 1600-1800 нм (вариант 2);
- 3 спектральных канала с шириной 50 нм и центральными длинами волн: 1696, 1734, 1775 нм (вариант 3).

Таблица 1 – Оценки вероятности обнаружения нефтепродуктов и ложных тревог для разных вариантов входных данных для нейронной сети

Условия измерения и результат работы нейронной сети	Вариант 1	Вариант 2	Вариант 3
Разлив нефтепродуктов на почве N1, %	>99	>99	99
Почва незагрязненная нефтепродуктами N2, %	<1	<1	1
Разные виды пластика N2, %	98	82	82

Результаты, приведенные в Таблице 1, показывают, что пластиковые загрязнения могут давать большую вероятность ложных тревог (более 82%) для задачи обнаружения разливов нефтепродуктов на земной поверхности (в случае, когда разливов нет, но присутствуют пластиковые загрязнения).

Таким образом, такие пластиковые загрязнения будут создавать большие ложные тревоги для дистанционных систем обнаружения утечек нефтепродуктов и нефтяных загрязнений, которые работают в ближней инфракрасной области спектра.

Отметим, что полученные экспериментальные результаты представляют практический интерес для создания дистанционных систем мониторинга загрязнений земной поверхности пластиком.

Выводы

Таким образом, проведены экспериментальные исследования спектров отражения различных пластиковых загрязнений земной поверхности в ближней инфракрасной ИК спектра. Показано, что в спектрах отражения различных видов пластика существуют спектральные провалы (в разной степени выраженные), характерные для почв, загрязненных нефтью и нефтепродуктами, и вызванные поглощением излучения углеводородами. Такие пластиковые загрязнения могут создавать ложные тревоги для дистанционных систем обнаружения утечек нефтепродуктов в ближней ИК области спектра. Пластиковые загрязнения могут давать большую вероятность ложных тревог (более 82%) для задачи обнаружения разливов

нефтепродуктов на земной поверхности (в случае, когда разливов нет, но присутствуют пластиковые загрязнения).

Литература

1. Komene G.L., Remi C.O. Oil pollution crisis and relationship marketing approach of oil firms in Niger delta. // British Journal of Management and Marketing Studies. 2022. V.5. N 1. P. 39-78.
2. Huettel M. Oil pollution of beaches. // Current Opinion in Chemical Engineering. 2022. V. 36. 100803. P. 1-10.
3. Adegboye M.A., Fung W.-K., Karnik A. Recent advances in pipeline monitoring and oil leakage detection technologies: Principles and approaches. // Sensors. 2019. V. 19. № 2548. P. 1–36.
4. Paul Arellano , Kevin Tansey, Heiko Balzter , Doreen S. Boyd. Detecting the effects of hydrocarbon pollution in the Amazon forest using hyperspectral satellite images. // Environmental Pollution. 2015. 205. P. 225-239
5. Achard V., Foucher P.Y., Dubucq D. Hydrocarbon Pollution Detection and Mapping Based on the Combination of Various Hyperspectral Imaging Processing Tools. // Remote Sensing. 2021. V.13 (5). 1020. P. 1-28.
6. Brum J., Schlegel C., Chappell C.,·Burke M.,·Krekeler M.P.S. Refective spectra of gasoline, diesel, and jet fuel A on sand substrates under ambient and cold conditions: Implications for detection using hyperspectral remote sensing and development of age estimation models. // Environmental Earth Sciences. 2020. V.79. 463. P.1-14.
7. Pelta R., Ben-Dor E. An Exploratory Study on the Effect of Petroleum Hydrocarbon on Soils Using Hyperspectral Longwave Infrared Imagery. // Remote Sensing. 2019. V.11(569). P. 1-15.
8. Del'Papa R., Scafutto M., de Souza Filho C.R., de Oliveira. W.J. Hyperspectral remote sensing detection of petroleum hydrocarbons in mixtures with mineral substrates: Implications for onshore exploration and monitoring. // ISPRS Journal of Photogrammetry and Remote Sensing. 2017. V.128. P.146–157.
9. Keskin G., Teutsch C.D., Lenz A., Middelmann W. Concept of an advanced hyperspectral remote sensing system for pipeline monitoring. // Proc. SPIE. 2015. V.9644. P. 96440H-1 - 96440H-9.

10. Allen C.S., Satterwhite M.B. Reflectance spectra of three liquid hydrocarbons on a common sand type. // Proc. SPIE. 2006. V. 6233. P. 62331M-1 - 62331M-12.

11. Allen C.S., Krekeler M.P.S. Reflectance spectra of crude oils and refined petroleum products on a variety of common substrates. // Proc. SPIE. 2010. V.7687. P. 76870L-1 - 76870L-13.

12. Hamed Masoumi, Seyed Mohsen Safavi, and Zahra Khani. Identification and Classification of Plastic Resins using Near Infrared Reflectance Spectroscopy. // International Journal of Mechanical and Industrial Engineering. 2012. V.6. P. 213-220.

13. Bonifazi, G.; Fiore, L.; Gasbarrone, R.; Hennebert, P.; Serranti, S. Detection of Brominated Plastics from E-Waste by Short-Wave. // Infrared Spectroscopy. 2021, V. 6. 54. P.1-21.

14. Kühn F., Oppermann K., Hörig B. Hydrocarbon Index – an algorithm for hyperspectral detection of hydrocarbons. // International Journal of Remote Sensing. 2004. 25(12). P. 2467-2473.

15. Hörig B., Kühn F. HyMap hyperspectral remote sensing to detect hydrocarbons. // Int. J. remote sensing. 2001, V. 22. N. 8. P. 1413–1422.

16. Cooled -20℃ NIR512-2.5 Spectrometer [Electronic resource]. Access mode: URL: https://www.optosky.net/atp8000.html. Language English (accessed 17/09/2025).

17. Федотов Ю.В., Иванов С.Е., Белов М.Л., Городничев В.А., Чумаченко С.И. Лабораторные измерения спектров отражения лесной растительности Европейской части России в диапазоне 1–2,4 мкм // Оптический журнал. 2024. Т. 91. № 10. С. 15–24.

18. Fenn R. W., Mill J.D., Clough S.A., Rothman L.S., Gallery W.O., Shettle E.P., Good R.E., Volz F.E., Kneizys F.X. Handbook of geophysics and the space environment. ed. A.S. Jursa. 1985. 18. P.18-1–18-80.

УДК 551.501

ИССЛЕДОВАНИЕ ВЛИЯНИЯ ЧИСЛА ИССЛЕДУЕМЫХ ОБРАЗЦОВ И ШУМОВ ИЗМЕРЕНИЯ НА ВОЗМОЖНОСТИ КЛАССИФИКАЦИИ ПОРОД ДЕРЕВЬЕВ В ВИДИМОМ И БЛИЖНЕМ ИНФРАКРАСНОМ ДИАПАЗОНЕ

А.А. Шкарупило, М.Л. Белов, С.Е. Иванов, Н.В. Барышников

Аннотация: Статья посвящена экспериментальным исследованиям возможности классификации пород деревьев в видимом и ближнем инфракрасном диапазоне. Приведены примеры результатов экспериментальных исследований спектров отражения 20 пород деревьев в период начала лета (вторая половина мая – вторая половина июня). Проведен анализ возможности классификации 20 пород деревьев по их спектрам в диапазоне 0,4-1 мкм. Показано, что как модель шума измерения слабо влияет на результаты, так и сами шумы измерения не сильно влияют на результаты классификации пород деревьев. Существенное влияние на результаты классификации оказывает количество измеренных спектров для пород деревьев. Чем больше количество измеренных спектров, тем лучше результаты классификации. При 150 измеренных спектров отражения для каждой породы деревьев и относительном среднеквадратическом значении шума 1% можно обеспечить оценку средней вероятности правильного обнаружения 20 пород деревьев более 91 %.

Ключевые слова: спектры отражения, экспериментальные исследования, сверточная нейронная сеть, древесная растительность, классификация пород деревьев.

STUDY OF THE EFFECT OF THE NUMBER OF SAMPLES STUDIED AND THE NOISE MEASURED ON THE POSSIBILITY OF CLASSIFICATION OF TREE SPECIES IN VISIBLE AND NEAR-INFRARED RANGE

A.A. Shkarupilo, M.L. Belov, S.E. Ivanov, N.V. Baryshnikov

Abstract: The article is devoted to experimental studies on the possibility of classification of tree species in visible and near infrared. Examples are given of experimental studies on the spectra of 20 tree species in early summer (second half of May - second half of June). The possibility of classifying 20 tree species by their spectra in the range 0.4-1 μm has been analysed. It is shown that as the noise measurement model has little effect on the results, so

the noise measurements themselves do not have much effect on the results of tree species classification. The number of measured spectra for tree species has a significant influence on classification results. The more spectra measured, the better the classification results. With 150 measured reflection spectra for each tree species and a relative standard noise value of 1%, 20 tree species have a probability of correct detection of more than 91%.

Keywords: reflectance spectra, experimental studies, convolutional neural network, wood vegetation, tree classification.

Введение

Лес является одним из важных природных ресурсов экономики страны, предметом экспорта и выполняет важную экологическую роль.

Для оценки лесов с точки зрения экономических и экологических задач важно знать состав пород деревьев, их возраст, состояние и т.п. Такие задачи наиболее эффективно решаются методами аэрокосмического оптического мониторинга (см., например, [1-8]).

В настоящее время является актуальной работа по созданию аппаратного и программного обеспечения для получения объективных данных о лесных массивах в РФ в видимом и ближнем инфракрасном диапазонах спектра. Первым этапом этой работы является создание банка данных спектральной отражательной способности пород деревьев (характерных для лесных массивов РФ) и проведение исследований возможности классификации пород деревьев по информации, содержащейся в таком банке данных.

На сегодняшний день есть публикации по этому вопросу (см., например, [9-19]) для древесной растительности характерной для лесных массивов РФ. Однако, в этих работах приводятся спектры отражения и рассматривается задача классификации пород деревьев для не широкого (не более 7) списка пород деревьев.

При анализе возможности классификации большого числа пород деревьев по их спектру отражения в видимом и ближнем инфракрасном диапазоне возникает ряд вопросов, которые ранее систематически не были исследованы. Это прежде всего вопросы о влиянии числа исследуемых образцов и шумов измерения на возможности классификации пород деревьев.

В статье приведены результаты экспериментальных исследований спектров отражения 20 пород деревьев (береза, осина, тополь черный, тополь бальзамический,

липа, клен, клен американский (ясенелистный), дуб, ясень, ива, каштан, сосна, ель, лиственница, туя, ель голубая, рябина, лещина, черемуха, сирень) в период начала лета (вторая половина мая – вторая половина июня) и проводится анализ возможности классификации 20 пород деревьев по их спектрам отражения в спектральном диапазоне 0,4-1 мкм.

Измерение спектров отражения образцов древесной растительности

Измерение спектров отражения листьев и хвои деревьев проводилось на лабораторной установке. Основным блоком установки для измерения спектров отражения листьев и хвои деревьев являлся спектрометр OPTOSKY ATP2000P, который регистрировал спектр отражения образцов в диапазоне 200-1100 нм с разрешением ~ 2 нм [20]. В качестве источника излучения использовалась галогеновая лампа. При измерениях образцы помещались на подложку, которая была покрашена черной краской с коэффициентом отражения в диапазоне 0,4-1 мкм, не превышающим 0,07.

На лабораторной установке измерялся коэффициент яркости образцов - отношение яркости, регистрируемой от измеряемого образца, к яркости, регистрируемой от эталонного отражателя (использовался эталон диффузного отражения Edmund Optics Spectralon). Подробно лабораторная установка описана в [17]. Для каждой породы дерева получено 150 спектров отражения. Измерения одной породы деревьев проводились для образцов с разных деревьев, с разных веток одного дерева и в разных точках образца листьев или хвои. Измерения проводились в период начала лета (вторая половина мая – вторая половина июня).

На рисунках 1-3 показаны примеры спектров отражения листьев и хвои деревьев. Толстые линии (сплошные или пунктирные) на рисунках – средние (по всем спектрам данной породы) значения спектров отражения, тонкие линии (сплошные или пунктирные) – средние значения спектров + - среднеквадратические отклонения значений спектров.

На рисунке 1*а* показаны спектры отражения березы (сплошные линии) и ясеня (пунктирные линии), на рисунке 1*б* - спектры отражения бальзамического тополя (сплошные линии) и сосны (пунктирные линии), на рисунке 2*а* - спектры отражения орешника (сплошные линии) и американского клена (пунктирные линии), на рисунке 2*б* - спектры отражения каштана (сплошные линии) и клена (пунктирные линии), на

рисунке 3а - спектры отражения черного тополя (сплошные линии) и дуба (пунктирные линии), на рисунке 3б - спектры отражения рябины (сплошные линии) и липы (пунктирные линии).

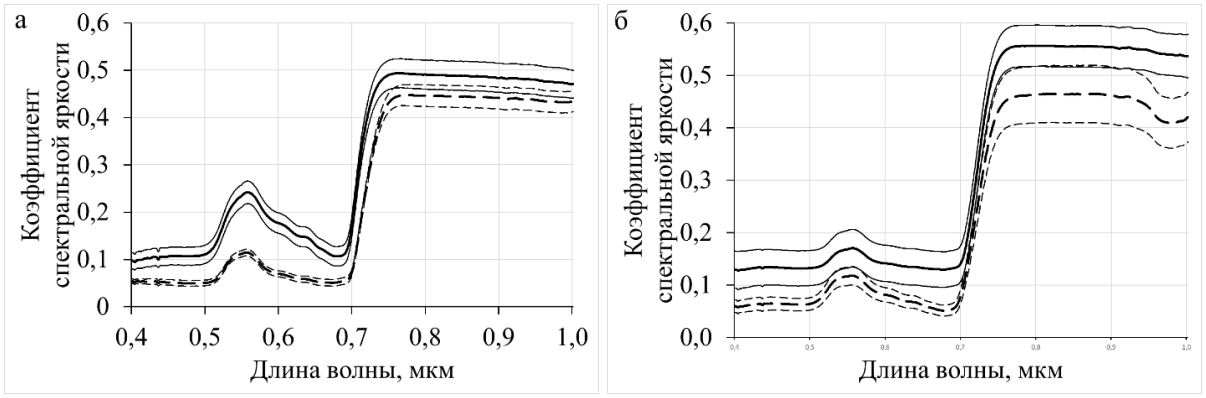

Рисунок 1 – Спектры отражения: *а* – березы и ясеня, *б* – бальзамического тополя и сосны

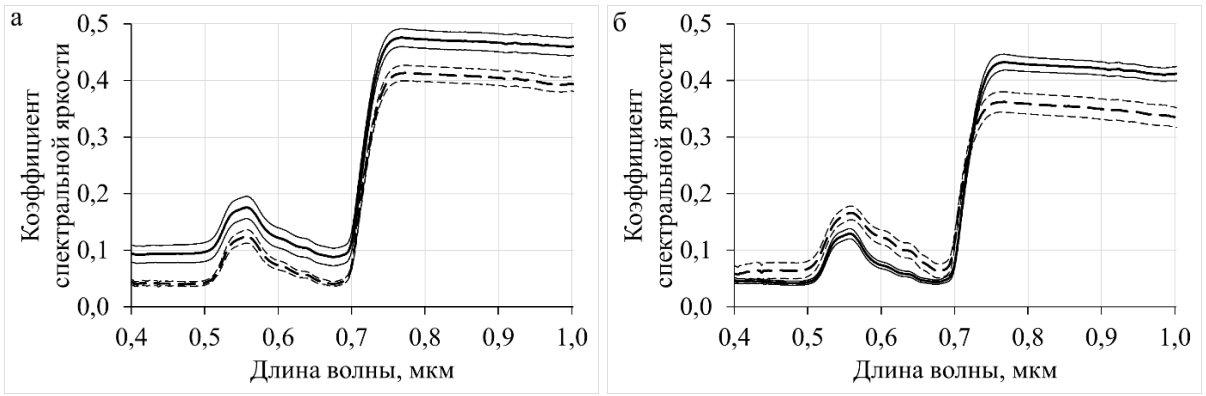

Рисунок 2 – Спектры отражения: *а* – орешника и американского клена, *б* – каштана и клена

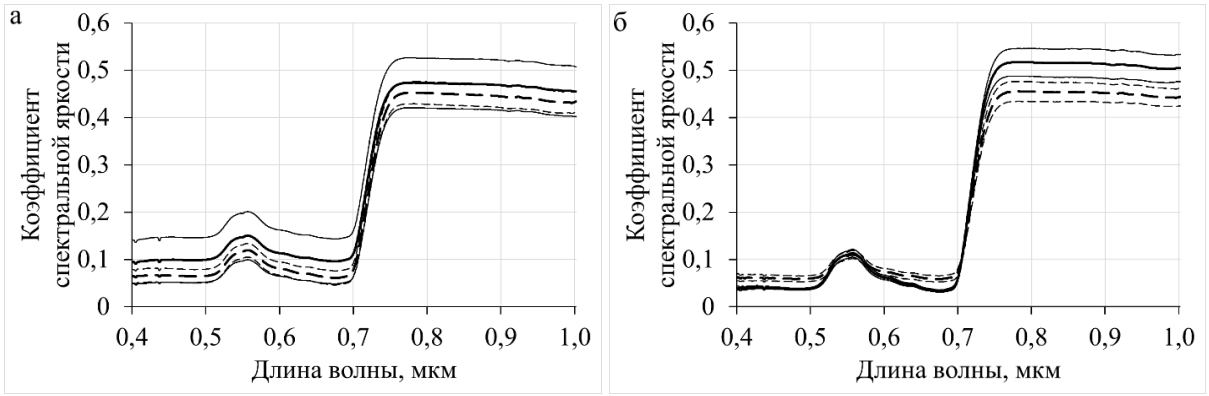

Рисунок 3 – Спектры отражения: *а* – черного тополя и дуба, *б* – рябины и липы

Из рисунков 1-3 видно, что спектры отражения пород деревьев в большинстве случаев существенно отличаются между собой. При этом, разброс значений коэффициента спектральной яркости для большинства пород деревьев небольшой. Это позволяет надеяться на хорошие результаты классификации пород деревьев.

Для количественной оценки возможностей классификации пород деревьев проводилось математическое моделирование работы алгоритма классификации, основанного на использовании сверточной нейронной сети.

Оценка эффективности классификации пород деревьев по спектрам отражения

Для классификации пород деревьев по спектрам отражения были использованы были использованы 150 спектров отражения каждой пород (береза Б, дуб Д, ель Е, ель голубая ЕГ, ива И, каштан К, клен КЛ, клен американский КА, лещина ЛЕ, липа Л, лиственница ЛИ, осина О, рябина Р, сирень С, сосна СО, тополь бальзамический ТБ, тополь черный ТЧ, туя Т, черемуха Ч, ясень Я) и алгоритм классификации на основе сверточной нейронной сети 1D-AlexNet.

При обучении нейронной сети для каждой породы использовался оптимизатор модели Adam и 80% экспериментально измеренных спектров отражения. Остальные 20% измеренных спектров были использованы для тестирования работы нейронной сети.

При тестирования работы нейронной сети для оценки эффективности классификации пород деревьев по спектрам отражения на вход нейронной сети подавались данные измерений коэффициентов спектральной яркости, к которым добавлялся шум, имитирующего возможные погрешности измерений и шумы приемной аппаратуры.

Использовалось две модели шума измерения. Для обеих моделей шум приемной аппаратуры полагался гауссовским с нулевым средним значением. Для первой модели (М1) шум для каждого спектрального отсчета в тестовой выборке характеризовался среднеквадратическим отклонением δ относительно среднего для каждой породы деревьев коэффициента спектральной яркости. Для второй модели (М2) шум для каждого спектрального отсчета в тестовой выборке характеризовался среднеквадратическим отклонением δ относительно значения каждого спектрального отсчета.

Различие моделей показано на рисунке 4. Здесь приведен спектр отражения липы для моделей М1 (рисунок 4а) и М2 (рисунок 4б) в диапазоне 0,4-1 мкм при δ=5%. На рисунках толстой линией показан спектр отражения листьев липы без шумов, а тонкой линией - спектр отражения с шумом

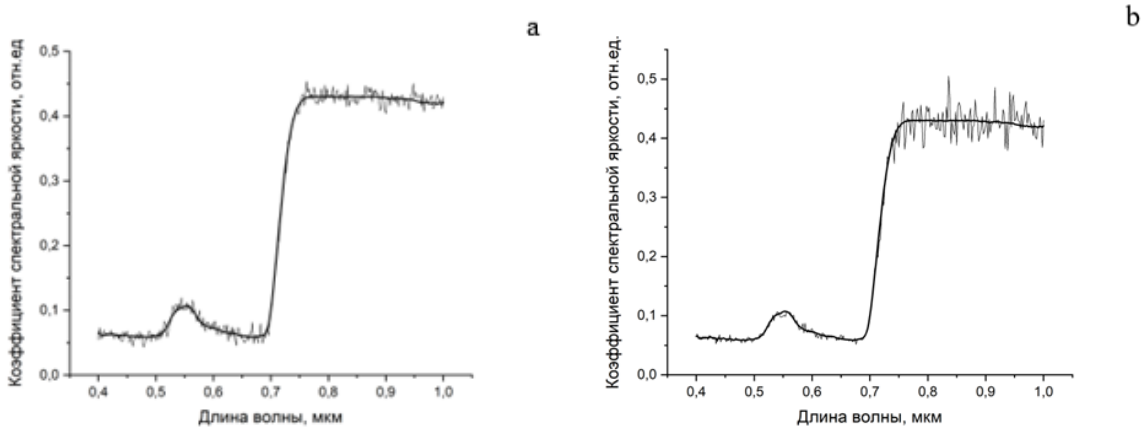

Рисунок 4 – Спектр отражения листьев липы без шумов и с шумом: *а* – по модели М1, *б* – М2

Из рисунка 4 видно, что потенциально аддитивный шум для модели М2 должен сильнее влиять для задачи классификации пород деревьев.

В результате работы нейронной сети для количественной оценки эффективности классификации формировалась матрица значений оценок вероятностей правильной и неправильной классификации пород деревьев.

В таблицах 1,2,5,6 и 3,4,7,8 показаны матрицы средних значений (по 1000 реализаций шума измерения) оценок вероятностей правильной и неправильной классификации 20 пород деревьев (характерных для Европейской части РФ) для случаев δ=1%, 5% для модели аддитивного шума, соответственно, М1 и М2.

В таблицах 1-4 приведены результаты классификации для случая 150 измеренных спектров для каждой породы деревьев.

В таблицах 5-8 приведены те же результаты, но для случая 30 измеренных спектров для каждой породы деревьев.

Сравнение таблиц 1-4 и таблиц 5-8 показывает, что при уменьшении числа измеренных спектров (которые используются нейронной сетью для классификации пород) для каждой породы деревьев со 150 до 30 оценки вероятностей правильной и неправильной классификации 20 пород деревьев резко ухудшаются.

Таблица 1 – Матрица значений оценок вероятностей правильной и неправильной классификации для модели шума М1 и δ=1%

с\д	Б	Д	Е	ЕГ	И	К	КЛ	КА	ЛЕ	Л	ЛИ	О	Р	С	СО	ТБ	ТЧ	Т	Ч	Я
Б	>0,99	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
Д	<0,01	0,76	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,03	<0,01	0,05	<0,01	<0,01	<0,01	0,01	0,09	<0,01	<0,01	0,05
Е	<0,01	<0,01	0,93	<0,01	<0,01	<0,01	<0,01	0,03	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,03	<0,01	<0,01	<0,01	<0,01	<0,01
ЕГ	0,03	<0,01	<0,01	0,97	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
И	<0,01	0,03	<0,01	<0,01	0,90	<0,01	<0,01	<0,01	0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,07
К	<0,01	<0,01	<0,01	<0,01	<0,01	>0,99	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
КЛ	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	>0,99	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
КА	<0,01	<0,01	<0,01	<0,01	<0,01	0,03	<0,01	0,93	<0,01	<0,01	<0,01	0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,02
ЛЕ	<0,01	<0,01	<0,01	<0,01	0,14	<0,01	<0,01	<0,01	0,78	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,05	<0,01	0,03	<0,01
Л	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,90	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,10
ЛИ	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,96	0,04	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
О	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,01	<0,01	<0,01	<0,01	0,82	0,06	<0,01	<0,01	<0,01	<0,01	<0,01	0,10	<0,01
Р	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	>0,99	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
С	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,96	<0,01	0,03	<0,01	<0,01	<0,01	<0,01
СО	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,05	<0,01	<0,01	<0,01	0,95	<0,01	<0,01	<0,01	<0,01	<0,01
ТБ	<0,01	0,03	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,02	<0,01	<0,01	<0,01	<0,01	<0,01	0,94	<0,01	<0,01	<0,01	<0,01
ТЧ	<0,01	0,02	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,10	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,88	<0,01	<0,01	<0,01
Т	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	>0,99	<0,01	<0,01
Ч	<0,01	<0,01	<0,01	<0,01	<0,01	0,03	<0,01	0,05	<0,01	<0,01	<0,01	0,18	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,70	0,03
Я	<0,01	<0,01	<0,01	<0,01	<0,01	0,04	<0,01	<0,01	<0,01	0,03	0,00	0,02	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,90

Т а б л и ц а 2 – Матрица значений оценок вероятностей правильной и неправильной классификации для модели шума М1 и δ=5%.

с\д	Б	Д	Е	ЕГ	И	К	КЛ	КА	ЛЕ	Л	ЛИ	О	Р	С	СО	ТБ	ТЧ	Т	Ч	Я
Б	>0,99	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
Д	<0,01	0,69	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,06	0,02	0,05	<0,01	<0,01	<0,01	0,03	0,09	<0,01	<0,01	0,06
Е	<0,01	<0,01	0,93	<0,01	<0,01	<0,01	<0,01	0,03	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,03	<0,01	<0,01	<0,01	<0,01	<0,01
ЕГ	0,02	<0,01	<0,01	0,97	<0,01	<0,01	0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
И	<0,01	0,02	<0,01	<0,01	0,87	<0,01	<0,01	<0,01	0,04	0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,06
К	<0,01	<0,01	<0,01	<0,01	<0,01	0,88	<0,01	0,05	<0,01	<0,01	<0,01	<0,01	<0,01	0,06	<0,01	<0,01	<0,01	<0,01	<0,01	0,01
КЛ	0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,99	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
КА	<0,01	<0,01	<0,01	<0,01	<0,01	0,10	<0,01	0,78	<0,01	<0,01	<0,01	0,05	<0,01	0,02	<0,01	<0,01	<0,01	<0,01	<0,01	0,05
ЛЕ	<0,01	0,01	<0,01	0,01	0,21	<0,01	<0,01	<0,01	0,71	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,04	<0,01	0,02	<0,01
Л	<0,01	0,02	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,86	<0,01	<0,01	<0,01	<0,01	<0,01	0,01	0,01	<0,01	<0,01	0,10
ЛИ	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,94	0,03	0,01	0,01	0,01	<0,01	<0,01	<0,01	<0,01	<0,01
О	<0,01	0,01	<0,01	<0,01	<0,01	0,04	<0,01	0,03	<0,01	<0,01	<0,01	0,70	0,06	0,03	<0,01	<0,01	0,01	<0,01	0,08	0,04
Р	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,97	0,02	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
С	<0,01	<0,01	<0,01	<0,01	<0,01	0,02	<0,01	<0,01	<0,01	0,01	<0,01	<0,01	0,02	0,91	<0,01	0,03	<0,01	<0,01	<0,01	0,01
СО	<0,01	<0,01	0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,05	<0,01	<0,01	<0,01	0,94	<0,01	<0,01	<0,01	<0,01	<0,01
ТБ	<0,01	0,03	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,02	<0,01	<0,01	<0,01	<0,01	<0,01	0,94	0,01	<0,01	<0,01	<0,01
ТЧ	<0,01	0,07	<0,01	<0,01	0,02	<0,01	<0,01	<0,01	<0,01	0,11	<0,01	<0,01	<0,01	<0,01	<0,01	0,02	0,77	<0,01	<0,01	0,01
Т	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,01	<0,01	<0,01	<0,01	0,99	<0,01	<0,01
Ч	<0,01	0,03	<0,01	<0,01	<0,01	0,04	<0,01	0,05	0,01	<0,01	<0,01	0,15	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,69	0,03
Я	<0,01	<0,01	<0,01	<0,01	<0,01	0,05	<0,01	<0,01	<0,01	0,05	<0,01	0,07	<0,01	0,04	<0,01	<0,01	0,02	<0,01	<0,01	0,77

Т а б л и ц а 3 – Матрица значений оценок вероятностей правильной и неправильной классификации для модели шума М2 и δ=1%.

с\д	Б	Д	Е	ЕГ	И	К	КЛ	КА	ЛЕ	Л	ЛИ	О	Р	С	СО	ТБ	ТЧ	Т	Ч	Я
Б	>0,99	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
Д	<0,01	0,77	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,03	<0,01	0,05	<0,01	<0,01	<0,01	0,01	0,09	<0,01	<0,01	0,05
Е	<0,01	<0,01	0,93	<0,01	<0,01	<0,01	<0,01	0,03	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,03	<0,01	<0,01	<0,01	<0,01	<0,01
ЕГ	0,03	<0,01	<0,01	0,97	<0,01	<0,01	0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
И	<0,01	0,03	<0,01	<0,01	0,90	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,07
К	<0,01	<0,01	<0,01	<0,01	<0,01	>0,99	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
КЛ	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	>0,99	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
КА	<0,01	<0,01	<0,01	<0,01	<0,01	0,03	<0,01	0,93	<0,01	<0,01	<0,01	0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,02
ЛЕ	<0,01	<0,01	<0,01	<0,01	0,13	<0,01	<0,01	<0,01	0,78	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,05	<0,01	0,03	<0,01
Л	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,90	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,10
ЛИ	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,97	0,03	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
О	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,83	0,07	<0,01	<0,01	<0,01	<0,01	<0,01	<0,10	<0,01
Р	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	>0,99	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
С	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,97	<0,01	0,03	<0,01	<0,01	<0,01	<0,01
СО	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,05	<0,01	<0,01	<0,01	0,95	<0,01	<0,01	<0,01	<0,01	<0,01
ТБ	<0,01	0,03	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,03	<0,01	<0,01	<0,01	<0,01	<0,01	0,94	<0,01	<0,01	<0,01	<0,01
ТЧ	<0,01	0,02	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,10	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,88	<0,01	<0,01	<0,01
Т	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	>0,99	<0,01	<0,01
Ч	<0,01	<0,01	<0,01	<0,01	<0,01	0,03	<0,01	0,06	<0,01	<0,01	<0,01	0,18	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,69	0,03
Я	<0,01	<0,01	<0,01	<0,01	<0,01	0,04	<0,01	<0,01	<0,01	0,03	<0,01	0,02	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,91

Т а б л и ц а 4 – Матрица значений оценок вероятностей правильной и неправильной классификации для модели шума М2 и δ=5%.

с\д	Б	Д	Е	ЕГ	И	К	КЛ	КА	ЛЕ	Л	ЛИ	О	Р	С	СО	ТБ	ТЧ	Т	Ч	Я
Б	0,99	<0,01	<0,01	<0,01	0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
Д	<0,01	0,71	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,05	0,03	0,05	<0,01	<0,01	<0,01	0,02	0,09	<0,01	<0,01	0,05
Е	<0,01	<0,01	0,94	<0,01	<0,01	<0,01	<0,01	0,02	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,03	<0,01	<0,01	<0,01	<0,01	<0,01
ЕГ	0,02	<0,01	<0,01	0,97	<0,01	<0,01	0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
И	0,01	0,03	<0,01	<0,01	0,85	<0,01	<0,01	<0,01	0,04	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,06
К	<0,01	<0,01	<0,01	<0,01	<0,01	0,87	<0,01	0,10	<0,01	<0,01	<0,01	<0,01	<0,01	0,02	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
КЛ	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	>0,99	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
КА	<0,01	<0,01	<0,01	<0,01	<0,01	0,09	<0,01	0,85	<0,01	<0,01	<0,01	0,01	<0,01	0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,04
ЛЕ	<0,01	0,01	<0,01	0,01	0,18	<0,01	<0,01	<0,01	0,74	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,04	<0,01	0,02	<0,01
Л	<0,01	0,02	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,88	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,01	<0,01	<0,01	0,08
ЛИ	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,96	0,03	<0,01	<0,01	0,01	<0,01	<0,01	<0,01	<0,01	<0,01
О	<0,01	0,01	<0,01	<0,01	<0,01	0,01	<0,01	0,02	<0,01	<0,01	0,01	0,76	0,05	0,01	<0,01	<0,01	0,01	<0,01	0,08	0,03
Р	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,99	0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
С	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,02	0,93	<0,01	0,03	<0,01	<0,01	<0,01	0,01
СО	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,05	<0,01	<0,01	<0,01	0,95	<0,01	<0,01	<0,01	<0,01	<0,01
ТБ	<0,01	0,04	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,95	0,01	<0,01	<0,01	<0,01
ТЧ	<0,01	0,08	<0,01	<0,01	0,01	<0,01	<0,01	<0,01	<0,01	0,10	<0,01	<0,01	<0,01	<0,01	<0,01	0,02	0,79	<0,01	<0,01	<0,01
Т	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,01	<0,01	<0,01	<0,01	0,99	<0,01	<0,01
Ч	<0,01	0,02	<0,01	<0,01	<0,01	0,03	<0,01	0,06	0,01	<0,01	<0,01	0,18	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,66	0,03
Я	<0,01	<0,01	<0,01	<0,01	<0,01	0,04	<0,01	0,01	<0,01	0,05	<0,01	0,09	<0,01	0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,80

Таблица 5 – Матрица значений оценок вероятностей правильной и неправильной классификации для модели шума М1 и δ=1%.

с\д	Б	Д	Е	ЕГ	И	К	КЛ	КА	ЛЕ	Л	ЛИ	О	Р	С	СО	ТБ	ТЧ	Т	Ч	Я
Б	0,83	<0,01	<0,01	<0,01	<0,01	<0,01	0,17	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
Д	<0,01	0,17	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,16	<0,01	<0,01	<0,01	<0,01	0,17	<0,01	<0,01	<0,01	0,17	0,33
Е	<0,01	<0,01	0,63	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,37	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
ЕГ	<0,01	<0,01	<0,01	>0,99	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
И	<0,01	<0,01	<0,01	<0,01	0,50	<0,01	<0,01	<0,01	0,50	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
К	<0,01	<0,01	0,16	<0,01	<0,01	0,34	<0,01	0,50	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
КЛ	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	>0,99	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
КА	<0,01	<0,01	0,64	<0,01	<0,01	<0,01	<0,01	0,17	<0,01	<0,01	<0,01	0,02	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,17	<0,01
ЛЕ	<0,01	<0,01	<0,01	<0,01	0,17	<0,01	<0,01	<0,01	0,83	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
Л	<0,01	0,17	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,67	0,16	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
ЛИ	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,81	0,03	0,16	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
О	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,17	0,40	<0,01	0,09	<0,01	<0,01	<0,01	<0,01	0,33	0,01
Р	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	>0,99	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
С	<0,01	<0,01	0,33	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,17	0,50	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
СО	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,35	<0,01	<0,01	<0,01	<0,01	0,48	<0,01	<0,01	<0,01	0,17	<0,01
ТБ	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,14	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,69	0,17	<0,01	<0,01	<0,01
ТЧ	<0,01	0,15	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,19	0,27	<0,01	<0,01	<0,01	0,02	<0,01	0,37	<0,01	<0,01	<0,01
Т	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	>0,99	<0,01	<0,01
Ч	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,14	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,67	0,19
Я	<0,01	0,17	0,02	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,16	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,65

Таблица 6 – Матрица значений оценок вероятностей правильной и неправильной классификации для модели шума М1 и δ=5%.

с\д	Б	Д	Е	ЕГ	И	К	КЛ	КА	ЛЕ	Л	ЛИ	О	Р	С	СО	ТБ	ТЧ	Т	Ч	Я
Б	0,83	<0,01	<0,01	<0,01	<0,01	<0,01	0,17	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
Д	<0,01	0,17	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,11	0,01	0,01	<0,01	<0,01	0,17	0,05	<0,01	<0,01	0,16	0,31
Е	<0,01	<0,01	0,61	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,02	<0,01	0,37	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
ЕГ	<0,01	<0,01	<0,01	>0,99	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
И	<0,01	<0,01	<0,01	<0,01	0,48	<0,01	<0,01	<0,01	0,52	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
К	<0,01	<0,01	0,15	<0,01	<0,01	0,44	<0,01	0,39	<0,01	<0,01	<0,01	0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
КЛ	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	>0,99	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
КА	<0,01	<0,01	0,48	<0,01	<0,01	<0,01	<0,01	0,17	<0,01	<0,01	<0,01	0,14	<0,01	0,02	<0,01	<0,01	<0,01	<0,01	0,16	0,02
ЛЕ	<0,01	<0,01	<0,01	<0,01	0,17	<0,01	<0,01	<0,01	0,83	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
Л	<0,01	0,14	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,63	0,10	<0,01	<0,01	<0,01	0,05	0,06	<0,01	<0,01	0,02	0,01
ЛИ	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,75	0,06	0,18	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
О	<0,01	<0,01	<0,01	<0,01	<0,01	0,01	<0,01	<0,01	<0,01	<0,01	0,22	0,30	0,03	0,06	<0,01	<0,01	<0,01	<0,01	0,32	0,07
Р	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,09	<0,01	0,90	0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
С	<0,01	<0,01	0,36	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,01	<0,01	0,13	0,50	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
СО	<0,01	0,06	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,30	0,03	<0,01	<0,01	<0,01	0,45	<0,01	<0,01	<0,01	0,16	<0,01
ТБ	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,10	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,72	0,17	<0,01	<0,01	<0,01
ТЧ	<0,01	0,10	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,23	0,23	<0,01	<0,01	<0,01	0,07	0,01	0,34	<0,01	<0,01	0,02
Т	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	>0,99	<0,01	<0,01
Ч	<0,01	0,11	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,04	<0,01	<0,01	0,08	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,57	0,19
Я	<0,01	0,13	0,06	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,05	0,01	0,12	<0,01	<0,01	0,03	<0,01	<0,01	<0,01	<0,01	0,61

Т а б л и ц а 7 – Матрица значений оценок вероятностей правильной и неправильной классификации для модели шума М2 и δ=1%.

с\д	Б	Д	Е	ЕГ	И	К	КЛ	КА	ЛЕ	Л	ЛИ	О	Р	С	СО	ТБ	ТЧ	Т	Ч	Я
Б	0,83	<0,01	<0,01	<0,01	<0,01	<0,01	0,17	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
Д	<0,01	0,17	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,16	<0,01	<0,01	<0,01	<0,01	0,17	<0,01	<0,01	<0,01	0,17	0,33
Е	<0,01	<0,01	0,64	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,36	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
ЕГ	<0,01	<0,01	<0,01	>0,99	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
И	<0,01	<0,01	<0,01	<0,01	0,50	<0,01	<0,01	<0,01	0,50	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
К	<0,01	<0,01	0,17	<0,01	<0,01	0,33	<0,01	0,50	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
КЛ	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	>0,99	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
КА	<0,01	<0,01	0,66	<0,01	<0,01	<0,01	<0,01	0,17	<0,01	<0,01	<0,01	0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,17	<0,01
ЛЕ	<0,01	<0,01	<0,01	<0,01	0,17	<0,01	<0,01	<0,01	0,83	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
Л	<0,01	0,17	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,67	0,16	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
ЛИ	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,83	<0,01	0,17	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
О	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,17	0,40	<0,01	0,10	<0,01	<0,01	<0,01	<0,01	0,33	<0,01
Р	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	>0,99	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
С	<0,01	<0,01	0,33	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,17	0,50	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
СО	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,34	<0,01	<0,01	<0,01	<0,01	0,50	<0,01	<0,01	<0,01	0,16	<0,01
ТБ	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,15	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,69	0,16	<0,01	<0,01	<0,01
ТЧ	<0,01	0,16	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,17	0,30	<0,01	<0,01	<0,01	0,01	<0,01	0,36	<0,01	<0,01	<0,01
Т	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	>0,99	<0,01	<0,01
Ч	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,16	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,67	0,17
Я	<0,01	0,17	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,17	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,66

Т а б л и ц а 8 – Матрица значений оценок вероятностей правильной и неправильной классификации для модели шума М2 и δ=5%.

с\д	Б	Д	Е	ЕГ	И	К	КЛ	КА	ЛЕ	Л	ЛИ	О	Р	С	СО	ТБ	ТЧ	Т	Ч	Я
Б	0,83	<0,01	<0,01	<0,01	<0,01	<0,01	0,17	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
Д	<0,01	0,18	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,10	<0,01	<0,01	<0,01	<0,01	0,17	0,06	<0,01	<0,01	0,16	0,33
Е	<0,01	<0,01	0,56	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,01	<0,01	0,43	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
ЕГ	<0,01	<0,01	<0,01	>0,99	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
И	<0,01	<0,01	<0,01	<0,01	0,49	<0,01	<0,01	<0,01	0,51	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
К	<0,01	<0,01	0,16	<0,01	<0,01	0,45	<0,01	0,38	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
КЛ	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	>0,99	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
КА	<0,01	<0,01	0,51	<0,01	<0,01	<0,01	<0,01	0,17	<0,01	<0,01	<0,01	0,14	<0,01	0,01	<0,01	<0,01	<0,01	<0,01	0,17	<0,01
ЛЕ	<0,01	<0,01	<0,01	<0,01	0,17	<0,01	<0,01	<0,01	0,83	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
Л	<0,01	0,16	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,64	0,11	<0,01	<0,01	<0,01	0,03	0,06	<0,01	<0,01	<0,01	<0,01
ЛИ	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,83	0,04	0,13	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
О	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,24	0,32	0,01	0,06	<0,01	<0,01	<0,01	<0,01	0,33	0,05
Р	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,04	<0,01	0,96	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
С	<0,01	<0,01	0,34	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,16	0,50	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
СО	<0,01	0,03	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,32	0,01	<0,01	<0,01	<0,01	0,48	<0,01	<0,01	<0,01	0,16	<0,01
ТБ	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,09	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,74	0,17	<0,01	<0,01	<0,01
ТЧ	<0,01	0,08	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,22	0,26	<0,01	<0,01	<0,01	0,08	<0,01	0,35	<0,01	<0,01	<0,01
Т	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	>0,99	<0,01	<0,01
Ч	<0,01	0,09	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,02	<0,01	<0,01	0,10	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,58	0,21
Я	<0,01	0,12	0,04	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,04	<0,01	0,16	<0,01	<0,01	0,02	<0,01	<0,01	<0,01	<0,01	0,61

Средние (по реализациям шума и по породам деревьев) оценки вероятностей правильной классификации следующие: 91,46% (таблица 1), 84,24% (таблица 2), 91,24% (таблица 3), 87,97% (таблица 4), 64,06% (таблица 5), 59,11% (таблица 6), 64,08% (таблица 7), 61,89% (таблица 8).

Во всех таблицах по диагонали матриц стоят полученные оценки вероятностей правильной классификации пород деревьев по их спектрам отражения в диапазоне 0,4-1 мкм (условные обозначения пород деревьев приведены выше в статье).

Внедиагональные элементы матриц показывают оценки неправильной классификации, когда вместо действительной породы дерева (указанной в крайнем правом столбце таблицы) классификатор (по спектру отражения) неправильно определяет другую породу дерева (указанную в верхней строке таблицы).

Из результатов, приведенных в таблицах 1-8, видно, что как модель шума измерения слабо влияет на результаты, так и сами шумы измерения не сильно влияют на результаты классификации пород деревьев.

Существенное влияние на результаты классификации оказывает количество измеренных спектров для пород деревьев. Чем больше количество измеренных спектров, тем лучше результаты классификации.

Таким образом, приведены примеры результатов экспериментальных исследований спектров отражения 20 пород деревьев (береза, осина, тополь черный, тополь бальзамический, липа, клен, клен американский (ясенелистный), дуб, ясень, ива, каштан, сосна, ель, лиственница, туя, ель голубая, рябина, лещина, черемуха, сирень) в период начала лета (вторая половина мая – вторая половина июня). Проведен анализ возможности классификации 20 пород деревьев по их спектру отражения в спектральном диапазоне 0,4-1 мкм. Показано, что как модель шума измерения слабо влияет на результаты, так и сами шумы измерения не сильно влияют на результаты классификации пород деревьев. Существенное влияние на результаты классификации оказывает количество измеренных спектров для пород деревьев. Чем больше количество измеренных спектров, тем лучше результаты классификации. При 150 измеренных спектров отражения для каждой породы деревьев и относительном среднеквадратическом значении шума 1% можно обеспечить оценку средней вероятности правильного обнаружения 20 пород деревьев более 91 %.

Литература

1. Dmitriev E.V., Kozoderov V.V., Kondranin T.V., Sokolov A.A. Regional monitoring of forest vegetation using airborne hyperspectral remote sensing data. // Proc. of SPIE. 2014. V. 9263. P. 926330-1 - 926330-10.
2. Stoyanov A., Borisova D. Monitoring on forest ecosystems by using space-temporal analysis of different types aerospace data. // Ecological Engineering and Environment Protection. 2017. N.10. P. 31-37.
3. Holzwarth S., Thonfeld F., Abdullahi S., Asam A., Da Ponte Canova E., Gessner U., Huth J., Kraus T., Leutner B., Kuenzer C. Earth Observation Based Monitoring of Forests in Germany: A Review. // Remote Sens. 2020. V. 12. P.1-43.
4. John E., Bunting P., Hardy A., Silayo D.S., Masunga E. A. Forest Monitoring System for Tanzania. // Remote Sens. 2021. V.13. P.1-29.
5. Zhang Y., Chen J.M., Miller J.R., Noland T.L. Leaf chlorophyll content retrieval from airborne hyperspectral remote sensing imagery // Remote Sensing of Environment. - 2008. № 112. P. 3234-3247.
6. White J.C., Coops N.C., Wulder M.A., Vastaranta M., Hilker T., Tompalski P. Remote Sensing Technologies for Enhancing Forest Inventories : A Review. // Can. J. Remote Sens. 2016. V.42. P. 619–640.
7. Immitzer M., Vuolo F., Atzberger C. First Experience with Sentinel-2 Data for Crop and Tree Species Classifications in Central Europe. // Remote Sensing. 2016. V.8. P. 1–27.
8. Lister A.J., Andersen H., Frescino T., Gatziolis D., Healey S., Heath L.S., Liknes G.C., McRoberts R., Moisen G.G., Nelson M., Riemann R., Schleeweis K., Schroeder T.A., Westfall J., Wilson B.T. Use of Remote Sensing Data to Improve the Efficiency of National Forest Inventories: A Case Study from the United States National Forest Inventory. // Forests. 2020. V.11. P.1-41.
9. Козодеров В.В., Егоров В.Д. Распознавание типов лесной растительности по гиперспектральным самолетным и многоканальным спутниковым данным высокого пространственного разрешения. Сравнение результатов и оценка их точности // Исследование Земли из космоса. 2019. № 6. С. 89−102.
10. Мамелин Ю.В., Копытов Г.Ф., Бузько В.Ю. Дискриминация хвойных и лиственных листьев деревьев и кустарников от декоративно-искусственных материалов методом оптической спектроскопии диффузного отражения света // Оптика и спектроскопия. 2020. Т. 128. Вып. 2. С. 290−294.

11. Козодеров В.В. Егоров В.Д. Распознавание растительности по данным гиперспектрального аэрозондирования // Исследование земли из космоса. 2011. № 3. С. 40–48.

12. Зимин М.В., Тутубалина О.В., Голубева Е.И., Рис Г.У. Методика наземного спектрометрирования растений Арктики для дешифрирования космических снимков // Вестник Московского университета. Серия 5. География. 2014. № 4. С. 34−41.

13. Касимов Н.С., Голубева Е.И., Лурье И.К., Зимин М.В., Самсонов Т.Е., Тутубалина О.В., Рис У.Г., Михеева А.И., Аляутдинов А.Р. Библиотека спектральных характеристик географических объектов в структуре геопортала МГУ им. М.В. Ломоносова // Вестник Московского университета. Серия 5. География. 2015. № 5. С. 3−8.

14. Голубева Е.И., Зимин М.В., Рис У.Г., Тутубалина О.В., Тимохина Ю.И. Дистанционные методы изучения состояния растительности севера (на примере Кольского полуострова) // Проблемы окружающей среды и природных ресурсов. 2020. № 5. С. 47−51.

15. Чабан Л.Н., Березина К.В. Анализ информативности спектральных и текстурных признаков при классификации растительности по гиперспектральным аэроснимкам. // Изв. вузов «Геодезия и аэрофотосъемка». 2018. Т. 62. № 1. С. 85–95.

16. Зотов С.А., Дмитриев Е.В., Шибанов С.Ю. Оценка информационных возможностей гиперспектрального космического комплекса НПО «Лептон» и МФТИ в задаче мониторинга лесных территорий России. // Лесной вестник. 2020. Т. 24. № 3. С. 26–32.

17. Федотов Ю.В., Иванов С.Е., Белов М.Л., Белов А.М., Городничев В.А., Чумаченко С.И., Шкарупило А.А. Исследование возможностей классификации пород деревьев в спектральном диапазоне 0,4–1 мкм // Светотехника. 2024. № 2. С. 62-67.

18. Иванов С.Е., Федотов Ю.В., Белов М.Л., Белов А.М., Городничев В.А., Чумаченко С.И. Шкарупило А.А. Исследование спектров отражения и возможностей классификации пород лесной растительности Европейской части РФ в диапазоне 0,4–1 мкм в осенний период // Светотехника, 2025. № 2. С. 77-81.

19. Шкарупило А.А., Белов М.Л., Иванов С.Е., Федотов Ю.В., Барышников Н.В. Исследование спектров отражения пород деревьев Европейской части РФ в видимом и ближнем инфракрасном спектральных диапазонах в период начала лета // Контенант. 2025. Т. 24, № 2. С. 87-97.

20. Popular UV-Vis vs USB2000+. URL: https://www.optosky.net/atp2000p.html.