Методика обработки данных авиационных мультиспектральных измерений для мониторинга состояния отдельных деревьев

А.А. Ломако

Институт прикладных физических проблем им. А. Н. Севченко БГУ Минск, 220045, Республика Беларусь E-mail: alekseylomako@gmail.com

На сегодняшний день существует большое количество исследований в области мониторинга состояния деревьев с целью выявления очагов усыханий. Тем не менее лишь в малой части таких работ ставится задача детектирования усыханий отдельных деревьев на ранней стадии. В настоящей статье приведён оригинальный подход к мониторингу состояния древостоев, основанный на проведении измерений с использованием мультиспектральной камеры, установленной на беспилотный летательный аппарат, и последующей обработке зарегистрированных данных специализированными новыми методами. Описывается новый способ географической привязки данных, использующий в качестве дополнительной информации рассчитываемые с использованием библиотеки компьютерного зрения пиксельные расстояния между близлежащими изображениями. Этот способ позволяет уменьшить средний радиус разброса значений географических координат изображений крон деревьев на 46 % по сравнению с прямым наложением кадров по координатам, сформированным на основе данных глобальных навигационных спутниковых систем, и на 15 % по сравнению со стандартным программным обеспечением. Также в работе описывается подход к семантической сегментации изображений на основе использования предварительно обученной модели нейросети Deep Forest и дополнительного анализа изображений специфических вегетационных индексов с помощью оригинального алгоритма. В результате применения такого способа удалось увеличить точность распознавания деревьев (F-score) с 75 до 92 %. В совокупности описанные методы и способы формируют методику обработки мультиспектральных изображений для мониторинга состояния хвойных насаждений, позволяющую анализировать спектральные отражательные характеристики отдельных деревьев по результатам мультивременных площадных съёмок.

Ключевые слова: БПЛА, изображения, геопривязка, ключевые точки, семантическая сегментация, нейросети, Deep Forest, вегетационные индексы

Одобрена к печати: 25.08.2023 DOI: 10.21046/2070-7401-2023-20-5-9-27

Введение

В современном мире использование беспилотных летательных аппаратов (БПЛА) для исследования объектов поверхности Земли с малых высот представляется одним из способов анализа последствий чрезвычайных ситуаций (Takhtkeshha et al., 2023), оценки состояния растительного покрова в пустынях (He et al., 2023), прогнозирования урожайности в сельском хозяйстве (Guo et al., 2022). Также БПЛА всё чаще применяются в лесном хозяйстве (Dainelli et al., 2021; Guimarães et al., 2020; Shamaoma et al., 2022).

Одно из важнейших направлений исследований на сегодняшний день — это дистанционный мониторинг состояния хвойных древостоев по причине большого экологического и экономического значения этих лесов (Катковский и др., 2022). В качестве съёмочной аппаратуры могут использоваться лидары (Guimarães et al., 2020), фотоспектральные (Lamaka et al., 2023), мультиспектральные (Awad, 2018) и гиперспектральные (Awad, 2018; Fassnacht et al., 2014) камеры. Часто встречаемым подходом для детектирования усыхания участков леса стал анализ спектральных отражательных характеристик объектов на поверхности Земли (Катковский и др., 2022; Awad, 2018; Fassnacht et al., 2014; Lamaka et al., 2023; Lausch et al., 2013).

В некоторых работах осуществляется поиск зон усыхания хвойных насаждений по единоразовым измерениям (Катковский и др., 2022), однако чаще указывается на необходимость получения мультивременных рядов данных (Ecke et al., 2022). Многие исследователи осуществляют детектирование отдельных деревьев на изображениях для последующего анализа (Керчев и др., 2021; Brandtberg, Walter, 1998; Chen et al., 2022; Mohan et al., 2017; Weinstein et al., 2019). При этом, несмотря на постоянно растущее количество исследований по данной тематике, достаточно мало внимания уделяется выявлению заболеваний хвойных насаждений на ранних стадиях (Torres et al., 2021).

Для идентификации отдельных деревьев на изображениях, зарегистрированных БПЛА, важно осуществлять географическую привязку кадров с высокой точностью. При использовании многоканальных двух- или трёхсистемных приёмников сигналов от глобальных навигационных спутниковых систем без подключения RTK-модулей (*англ.* Real Time Kinematic) летательные аппараты относят по точности к навигационному классу (точность определения координат порядка 1,5 м (Тимофеев, 2015)). Использование RTK-систем позволяет достигнуть точности позиционирования БПЛА до нескольких сантиметров, однако в таком случае повышается точность определения лишь положения центров кадров, зарегистрированных БПЛА, что не обеспечивает высокое качество совмещения пересекающихся изображений и последующую их геопривязку в случае съёмки лесных территорий с предельно малых высот (до 100 м). В то же время использование модулей RTK накладывает ряд ограничений: дополнительные экономические затраты; необходимость получения специального разрешения на использование радиочастоты; высокая вероятность помех при работе в индустриальных районах; установка верхнего предела дальности полёта, обусловленная ограниченной дальностью работы радиоканала (Тимофеев, 2015).

Целью данного исследования стала разработка методики обработки данных мультиспектральной камеры сверхвысокого пространственного разрешения, установленной на БПЛА, которая пригодна для мониторинга состояния отдельных деревьев при осуществлении регистрации изображений с предельно малых высот. Достигнуть поставленной цели было решено путём разработки адаптивного метода географической привязки данных с последующей семантической сегментацией изображений для выделения областей, соответствующих кронам деревьев. При этом ставилась задача обеспечения идентификации по географическим координатам отдельных деревьев в ряде независимых измерений без использования RTK-систем.

Методы и инструменты в исследовании

Приборы и их взаимодействие

В качестве носителя съёмочной аппаратуры использовался БПЛА DJI Phantom 4 Multispectral (https://www.dji.com/p4-multispectral), однако предлагаемая методика может работать с данными любого БПЛА мультироторного типа, если центры изображений имеют начальную геопривязку. Использованная в исследовании камера позволяет регистрировать RGB-изображения (R - англ. red, красный; G - англ. green, зелёный; B - англ. blue, синий), а также изображения в пяти спектральных каналах: синем (450 ± 16 нм), зелёном (560 ± 16 нм), красном (650 ± 16 нм), красном крае (*англ.* red edge — RE) (730 ± 16 нм) и ближнем инфракрасном (*англ.* near infrared — NIR) (840 ± 26 нм).

Для возможности сопоставления результатов измерений в различных условиях освещённости синхронно с лётными измерениями в районе полётов проводилась наземная регистрация спектров отражения солнечного излучения от молочного стекла MC-10 с использованием фотоспектрорадиометра ФСР-02 из состава аппаратно-программного комплекса (АПК) «Калибровка» (Катковский и др., 2017). Фотоспектрорадиометр ФСР-02 обладает спектральным разрешением 4 нм в диапазоне длин волн 350–900 нм. Данные спектрометра были пересчитаны в величины спектральной плотности энергетической яркости с учётом радиометрической калибровки, после чего была выполнена свёртка функций спектрального отклика в каналах мультиспектральной камеры и зарегистрированных спектров отражения (в качестве функций спектрального отклика использовались прямоугольные функции распределения):

$$B_{j} = \frac{\sum_{\lambda} I_{\lambda} R_{\lambda}^{j}}{\sum_{\lambda} R_{\lambda}^{j}},\tag{1}$$

где *j* — номер канала мультиспектральной камеры; I_{λ} — спектральная плотность энергетической яркости (СПЭЯ) в спектре ФСР-02 на длине волны λ ; R_{λ}^{j} — функция спектрального отклика *j*-го канала мультиспектральной камеры на длине волны λ ; B_{j} — пересчитанное с учётом спектрального отклика канала мультиспектральной камеры значение СПЭЯ.

В результате для каждого спектра ФСР-02 был получен вектор значений СПЭЯ, характеризующий текущее состояние небесной полусферы. После этого все значения интенсивности в каналах мультиспектральных изображений нормировались (с учётом радиометрической калибровки камеры) на соответствующие по времени величины вектора значений СПЭЯ, вычисленные по формуле (1). Таким образом, были получены нормированные значения яркости для всех каналов мультиспектральных изображений.

Описываемые в работе алгоритмы получили реализацию в качестве составных частей программного обеспечения (ПО), разработанного с помощью фреймворка Qt на языках программирования C++ и Python с использованием библиотеки компьютерного зрения OpenCV. Конечная географическая привязка изображений осуществлена путём сохранения соответствий пиксельных и географических координат точек изображений в виде, соответствующем формату данных модуля географической привязки растровых изображений ПО QGIS (свободная географическая информационная система с открытым кодом, https://www.qgis.org/ru/ site/).

Особенности данных, зарегистрированных с предельно малых высот

Задача сшивки и геопривязки изображений, полученных при аэрофотосъёмке лесных территорий с предельно малых высот, вообще говоря, не имеет единственного решения. Это обусловлено существенным различием высоты объектов на регистрируемых изображениях, что приводит к фактическим различиям в линейном пространственном разрешении (L) на пиксель аэрофотосистем в разных зонах отдельных кадров (*рис. 1*) при одинаковой высоте съёмки относительно подстилающей поверхности (H). Таким образом, для географической привязки изображений требуется особый адаптивный подход, в основе которого будет лежать апостериорная информация об объектах в кадре.



Рис. 1. Различия в линейном пространственном разрешении при съемке разновысоких объектов

Адаптивный метод географической привязки данных

Для построения ортофотопланов используются различные подходы. Один из них основан на поиске на объединяемых изображениях специфических областей — особых точек, последующем их сопоставлении и определении относительного смещения изображений на основе полученной информации (Ломако, 2022). Такой подход хорошо работает при трассовой съёмке, однако при съёмке методом параллельного галсирования изображения, полученные на близлежащих галсах полёта БПЛА, могут быть смещены вследствие накопления ошибок, вызванных внешними факторами. Как следствие, становится невозможным мониторинг состояния отдельных деревьев по их кронам, так как крайне сложно становится сопоставить объекты из двух разновременных наборов изображений. Решением задачи, как правило, становится идентификация объектов по географическим координатам при достаточной их точности.

Наиболее частым вариантом начальной географической привязки данных БПЛА является фиксация GPS-координат (*англ*. Global Positioning System, система глобального позиционирования) центров отдельных кадров при съёмке. Для получения географической привязки всего кадра необходимо перевести географические координаты центров изображений в пиксельные координаты. Такой переход возможен, если известно угловое пространственное разрешение камеры БПЛА и высота, с которой осуществлялась съёмка подстилающей поверхности. В настоящей работе угловое пространственное разрешение съёмочной системы определялось по методике, аналогичной описанной в статьях (Ломако и др., 2023; Молчанов, 2018), и составило 0,0225 град/пиксель.

Для вычисления расстояния Δl (в метрах) между двумя точками с известными координатами использовалась формула гаверсинусов (Дубинин, 2006). На основе такого расстояния между двумя пересекающимися изображениями с известными географическими координатами центров для заданной высоты полёта относительно поверхности H (в метрах) при известном угловом разрешении на пиксель камеры θ (в градусах) можно определить пиксельное расстояние между центрами изображений:

 $\Delta r = \frac{\Delta l}{H \cdot \mathrm{tg}(\pi \theta / 180)}.$



Рис. 2. Определение координат изображений в пиксельной системе координат: *a* — преобразование систем координат при формировании объединённого изображения; *б* — смещения близлежащих изображений

Если выбрать центр первого изображения первого галса (галсы на *рис. 2* обозначены красным цветом) точкой отсчёта локальной системы координат (СК X0Y), можно осуществить перевод пиксельных координат центров изображений из СК WGS-84 (X'0Y') в СК финального изображения ($X_F0_FY_F$). При необходимости исключения отрицательных коорди-

нат в новой СК, связанной с финальным изображением, одновременно с поворотом осуществляется линейное смещение СК. Угол поворота СК WGS-84 относительно СК финального изображения α можно определить по отношению координат первого и последнего изображения галса полёта БПЛА в цикле съёмки (кадры 1 и 2 на *рис. 2a*). Таким образом, с помощью вышеописанных преобразований можно получить пиксельные координаты центра каждого изображения в финальном объединённом изображении.

Для уточнения пиксельных координат в настоящей работе предлагается помимо координат, определяемых на основе данных GPS-датчика, использовать также пиксельные расстояния между близлежащими изображениями, которые можно рассчитывать с использованием методов сопоставления изображений на основе детекторов особых точек (Кэлер, Брадски, 2017). Было принято решение использовать сочетание детектора ORB (*анел*. Oriented FAST and Rotated BRIEF) (Rublee et al., 2011) и дескриптора FREAK (*анел*. Fast Retina Keypoint) (Alahi et al., 2012) с сопоставлением дескрипторов особых точек полным перебором с метрикой сравнения Хэмминга (Кэлер, Брадски, 2017), так как для данных БПЛА такой вариант демонстрирует наилучшие показатели по качеству сшивки среди исследованных методов (Ломако, 2022). Перед проведением поиска особых точек для всего набора изображений необходимо выполнение коррекции искажений на изображениях, вызываемых эффектом дисторсии (Ломако, 2022).

Для каждого изображения на основе анализа по особым точкам рассчитывались пиксельные смещения по отношению к соседним изображениям (пресекающимся левому, верхнему, правому и нижнему). Эти смещения относительно соседних изображений для некоторого анализируемого кадра с начальными координатами $(x_0; y_0)$ показаны на *рис. 26*. В качестве примера на рисунке отображены смещения по оси *X* по отношению к изображению с координатами $(x_3; y_3)$ и по оси *Y* по отношению к изображению с координатами $(x_2; y_2)$. Они обозначены соответственно величинами Δx_3 и Δy_2 . Также на рисунке показано пиксельное расстояние Δr_4 между анализируемым изображением и изображением с координатами $(x_4; y_4)$, рассчитываемое по формуле:

$$\Delta r_i = \sqrt{(x_0 - x_i)^2 + (y_0 - y_i)^2}, \quad i = \overline{1, 4},$$
(2)

где *i* — номер изображения среди близлежащих изображений.

Для корректного определения географических координат пикселей изображений в работе использовался адаптивный подход, основанный на поиске коэффициентов масштабирования близлежащих изображений. Коэффициенты масштабирования определялись как соотношения пиксельных смещений между изображениями, вычисленных на основе данных приёмника сигналов глобальных навигационных спутниковых систем и на основе расстояния между особыми точками, детектированными с использованием алгоритмов библиотеки компьютерного зрения:

$$S = \frac{\Delta r_g}{\Delta r_p},\tag{3}$$

где Δr_g — пиксельное расстояние между центрами близлежащих кадров, рассчитанное по формуле (2) на основе базовой геопривязки аэрофотоснимков; Δr_p — пиксельное расстояние между центрами близлежащих кадров, рассчитанное по формуле (2) на основе координат особых точек в аэрофотоснимках.

Так как выбранные детекторы точек на изображениях лесного массива наиболее информативными принимают области, связанные с кронами деревьев, при таком подходе масштаб изображения будет изменяться в зависимости от высоты объектов в кадре. Следовательно, если бо́льшую часть кадра занимают области, соответствующие кронам деревьев, то коэффициент масштабирования будет изменяться таким образом, чтобы сшивка соседних изображений производилась «на высоте крон деревьев».

Фильтрация и учёт пиксельных смещений

Важно отметить, что при попытках сопоставления особых точек в изображениях лесных территорий, зарегистрированных с предельно малых высот, могут возникать ошибки, обусловленные геометрическими искажениями изображений объектов. Вследствие этого пиксельные расстояния, используемые в формуле (3), могут быть определены некорректно. В работе А. А. Ломако (2022) предложен способ фильтрации совпадений особых точек по особым признакам для сшивки изображений лесных территорий. В качестве одной из метрик сравнения используется длина отрезка, соединяющего центры совпадающих областей:

$$L = \sqrt{\left(x_2^k - x_1^k\right)^2 + \left(y_2^k - y_1^k\right)^2},$$
(4)

где $(x_2^k - x_1^k)$ — координаты центра *k*-й особой области во втором изображении; $(y_2^k - y_1^k)$ — координаты центра *k*-й особой области в первом изображении.

При сшивке изображений решение об относительном пиксельном смещении двух кадров принимается на основе распределения значений особого признака — выбираются совпадения точек, значения особых признаков которых попадают в заданный интервал (*puc. 3a*). Ошибки сопоставления особых точек возникают, когда мода распределения особой метрики является слабо выраженной или распределение становится многомодальным (*puc. 3б*). Для того чтобы исключить из анализа некорректно рассчитанные пиксельные расстояния, вводится параметр выраженности моды в распределении:

$$\omega_j = \frac{Q_M}{Q}, \quad j = \overline{1, N'}, \tag{5}$$

где ω_j — нормированный параметр качества определения пиксельного расстояния между *j*-й парой изображений по особым точкам; N' — общее количество пар близлежащих изображений по набору данных; Q_M — количество совпадений особых точек, попадающих в доверительный интервал в гистограмме распределения метрики, вычисленной по формуле (4); Q общее количество совпадений особых точек в гистограмме распределения метрики, вычисленной по формуле (4).



Puc. 3. Гистограмма распределения значений длины отрезка, соединяющего центры совпадающих областей: *a* — одномодальное распределение, ωⁿ > 0,9; *б* — многомодальное распределение, ωⁿ < 0,1

После определения по формуле (5) выраженности моды для всех пар изображений во входном наборе данных определяются минимальное и максимальное значения параметра ка-

чества определения пиксельного расстояния (ω_{min} и ω_{max} соответственно) и все значения нормируются по формуле:

$$\omega_j^n = \frac{\omega_j - \omega_{\min}}{\omega_{\max} - \omega_{\min}}.$$

В настоящей работе для пар изображений, где $\omega_j^n < 0,1$, пиксельное расстояние Δr_p считается вычисленным некорректно и принимается равным пиксельному расстоянию Δr_g . После такой фильтрации пиксельных смещений и определялись коэффициенты масштабирования для каждого кадра по формуле (3).

Следующим шагом стал расчёт дополнительного линейного смещения по осям изображения с целью компенсации неточности определения географических координат. Эти смещения рассчитывались для каждого изображения по следующим формулам:

$$\begin{cases} \Delta x^{k,l} = \frac{1}{2} \Big(\Delta x_g^{k+1,l} + \Delta x_g^{k-1,l} \Big) - \Big[\frac{1}{2} (S^{k+1,l} + S^{k,l}) \Delta x_p^{k+1,l} + \frac{1}{2} (S^{k-1,l} + S^{k,l}) \Delta x_p^{k-1,l} \Big], \\ \Delta y^{k,l} = \frac{1}{2} \Big(\Delta y_g^{k,l+1} + \Delta y_g^{k,l-1} \Big) - \Big[\frac{1}{2} (S^{k,l+1} + S^{k,l}) \Delta y_p^{k,l+1} + \frac{1}{2} (S^{k,l-1} + S^{k,l}) \Delta y_p^{k,l-1} \Big], \end{cases}$$

где k — номер, под которым изображение зарегистрировано в галсе, $k = \overline{1, K_l}$; l — номер галса, на котором зарегистрировано изображение $l = \overline{1, C}$; K_l — количество изображений в l-м галсе; C — количество галсов в трассовой съёмке; $\Delta x_g^{k\pm 1,l}$, $\Delta y_g^{k,l\pm 1}$ — пиксельные смещения, вычисленные на основе базовой геопривязки аэрофотоснимков для l-го кадра в k-м галсе по оси X (вычисляется при сопоставлении с l-м кадром в $(k\pm 1)$ -м галсе) и оси Y (вычисляется при сопоставлении с $(l\pm 1)$ -м кадром в k-м галсе) соответственно; $\Delta x_p^{k\pm 1,l}$, $\Delta y_p^{k,l\pm 1}$ — пиксельные смещения, вычисленные на основе детектирования особых точек для l-го кадра в k-м галсе по оси X (вычисляется при сопоставлении с l-м кадром в $(k\pm 1)$ -м галсе) и оси Y(вычисляется при сопоставлении с $(l\pm 1)$ -м кадром в k-м галсе) соответственно; $S^{k,l}$ — коэффициент масштабирования, вычисленный по формуле (3) для l-го кадра в k-м галсе.

Таким образом, для каждого изображения в серии измерений определяются координаты в СК итогового изображения. Обратными преобразованиями из пиксельных координат возможен пересчёт в географические координаты, что позволяет получать географически привязанное сшитое изображение, а также географическую привязку каждого отдельного кадра.

Семантическая сегментация изображений

Одним из основных подходов к последующей обработке данных для анализа состояния древостоев является сегментация изображений с выделением областей, соответствующих отдельным деревьям. В настоящее время существует множество различных подходов к такой сегментации: метод водораздела (Алешко и др., 2017); методы PCS (*англ.* Point Cloud Segmentation) и LSS (*англ.* Layer Stacking Segmentation), работающие на основе данных лидаров (Chen et al., 2022); обучаемые или предварительно обученные нейронные сети (Kislov et al., 2021; Korznikov et al., 2021; Weinstein et al., 2019). В случае учёта данных геопривязки, полученных в результате применения описанного выше адаптивного метода, после семантической сегментации появляется возможность осуществлять мониторинг состояния отдельно взятых деревьев. Такой мониторинг возможен на основе анализа по специфическим для хвойных пород спектральным характеристикам (Силюк и др., 2022).

В настоящей работе для распознавания крон деревьев на первом этапе была использована предварительно обученная модель нейросети Deep Forest (Weinstein et al., 2019). Точность работы данной нейросети в применении к задаче распознавания крон без дополнительного обучения выше, чем в методе водораздела и в методах PCS и LSS (Портнов и др., 2022). В результате работы алгоритма каждому RGB-изображению ставится в соответствие маска, где все кроны древостоев выделены прямоугольными рамками.

Для мониторинга состояния деревьев выделения прямоугольных областей недостаточно, так как в эти области, помимо крон, зачастую попадает затенённая подстилающая поверхность (*puc. 4a*). Кроме того, в некоторых случаях часть кроны дерева может не попадать в выделенный нейросетевым алгоритмом прямоугольный сегмент (*puc. 46*). Также стоит учитывать, что точность идентификации крон деревьев при использовании нейросети Deep Forest не является абсолютной, а значит, некоторые области могут быть ошибочно распознаны как изображения деревьев, а отдельные деревья могут быть не распознаны алгоритмом и не включены в маску сегментации. Решением в данном случае может стать уточнение маски крон деревьев за счёт использования рассчитанных значений вегетационных индексов.



Рис. 4. Ошибки сегментации: *а* — попадание лишних областей; *б* — исключение нужных областей

В настоящей работе для уточнения маски крон деревьев были использованы вегетационные индексы, которые можно рассчитать с использованием пяти каналов мультиспектральной камеры: MTVI (*англ*. Modified Triangular Vegetation Index — модифицированный треугольный индекс растительности) (Haboudane et al., 2004), TVI (*англ*. Transformed Vegetation Index — трансформированный индекс растительности) (Bannari et al., 1995), NDGI (*англ*. Normalized Difference Greenness Index — нормализованный разностный индекс зелени) (Bannari et al., 1995), GEMI (*англ*. Global Environment Monitoring Index — глобальный индекс мониторинга окружающей среды) (Bannari et al., 1995), CVI (*англ*. Chlorophyll Vegetation Index — вегетационный индекс хлорофилла) (Hunt et al., 2011), LCI (*англ*. Leaf Chlorophyll Index — индекс хлорофилла листьев) (Datt, 1999), а также некоторые простые соотношения каналов (*табл*. *1*). С помощью отдельных индексов также возможна оценка уровня стрессового состояния растений (Силюк и др., 2022; Bannari et al., 1995; Hunt et al., 2011). Помимо описанных выше индексов возможно использование комбинаций индексов, а также иных специфических индексов, например из электронных библиотек индексов, таких как IDB (*англ*. Index DataBase, https://www.indexdatabase.de).

Для повышения точности выделения крон деревьев выработан специальный алгоритм дополнительной обработки результатов сегментации нейросети Deep Forest, использующий, помимо RGB-изображений, данные, полученные в результате вычисления значений вегетационных индексов:

 Поиск на изображении областей, не идентифицированных нейросетевой моделью как деревья, но потенциально являющихся ими. Выполняется сегментацией методом сдвига среднего (Comaniciu, Meer, 1999) с последующей бинаризацией методом Оцу (Otsu, 1979), применённой к изображениям RGB-канала мультиспектральной камеры, и поиском контуров в бинарном изображении (Кэлер, Брэдски, 2017).

- 2. Вычисление усреднённых параметров гистограмм распределения значений вегетационных индексов для сегментов, выделенных нейросетевым алгоритмом Deep Forest.
- 3. Фильтрация сегментов, выделенных на 1-м этапе алгоритма, путём сравнения параметров распределения в гистограммах этих сегментов и усреднённых статистических параметров, полученных на 2-м этапе алгоритма.
- 4. Исключение ошибочно добавленных сегментов, соответствующих прогалинам в лесной местности, с помощью вычисления градиента значений вегетационных индексов в направлении от угла сегмента к его центру (некоторые области не отфильтровываются на 3-м этапе алгоритма вследствие схожести гистограмм распределения в сегментах, соответствующих кронам деревьев, и сегментах, где прогалины со всех сторон окружены кронами).
- 5. Исключение на всех выделенных сегментах областей с изображением подстилающей поверхности с помощью пороговой бинаризации методом Оцу, применённой к сегментам RGB-изображений, преобразованных с помощью сегментации методом сдвига среднего (при этом размер области для бинаризации принимается равным размеру исходного сегмента, увеличенному на 10 %, что позволяет включать части крон, ошибочно не добавленные в сегмент).
- 6. Применение сглаживающего фильтра с нормированным гауссовым ядром по окрестности 7×7 пикселей (Гонсалес, Вудс, 2012) к бинарным маскам изображений для удаления шумовых эффектов, проявляющихся на 5-м этапе алгоритма.

Название индекса	Аббревиатура	Формула для расчёта
Модифицированный треугольный индекс растительности	MTVI	1,2(1,2(NIR-GREEN)-2,5(RED-GREEN))
Трансформированный индекс растительности	TVI	$\sqrt{\frac{\text{NIR} - \text{RED}}{\text{NIR} + \text{RED}}} + 0.5$
Нормализованный разностный индекс зелени	NDGI	$\frac{\text{GREEN} - \text{RED}}{\text{GREEN} + \text{RED}}$
Глобальный индекс мониторинга окружающей среды	GEMI	$\left(\eta(1-0,25\eta) - \frac{\text{RED} - 0,125}{1 - \text{RED}}\right),$ $\eta = \frac{\left[2(\text{NIR}^2 - \text{RED}^2) + 1,5\text{NIR} + 0,5\text{RED}\right]}{(\text{NIR} + \text{RED} + 0,5)}$
Вегетационный индекс хлорофилла	CVI	$NIR \frac{RED}{GREEN^2}$
Индекс хлорофилла листьев	LCI	$\frac{\text{NIR} - \text{RE}}{\text{NIR} + \text{RED}}$
Простое соотношение красного и синего каналов	SRRB	RED BLUE
Простое соотношение красный – «красный край»	SRRRE	RED RE

Таблица 1. Вегетационные индексы для уточнения семантической сегментации изображений и анализа состояния хвойных деревьев

Примечание: BLUE — интенсивность в синем канале мультиспектральной камеры; GREEN — интенсивность в зелёном канале мультиспектральной камеры; RED — интенсивность в красном канале мультиспектральной камеры; RE — значения интенсивности в канале «красный край» мультиспектральной камеры; NIR — значения интенсивности в ближнем ИК-канале мультиспектральной камеры; SRRB — *англ.* Simple Ratio of Red and Blue; SRRRE — *англ.* Simple Ratio of Red and Red Edge. Каждое значение интенсивности нормируется на вычисленную по формуле (1) соответствующую составляющую *B*.

Экспериментальная проверка методики

Результаты применения адаптивного метода геопривязки

Для оценки качества работы адаптивного метода географической привязки 06.10.2022– 11.10.2022 на территории учебно-географической станции Белорусского государственного университета «Западная Березина» был проведён лётный эксперимент, в ходе которого пятикратно регистрировались изображения одной и той же территории (с различными полётными заданиями). Высота полёта над поверхностью земли составляла 100 м. В результате аэрофотосъёмки были получены по 100 изображений в каждой части эксперимента. Бо́льшую часть зарегистрированных объектов составляли древостои различных пород, определение географических координат которых стало приоритетной задачей.

В данной части работы для анализа использовались только RGB-изображения, регистрируемые мультиспектральной камерой. Геопривязка данных была проведена несколькими способами: прямым наложением изображений на координатную сетку в соответствии с исходными координатами центров кадров (с учётом поворота СК); разработанным в ходе исследования способом (с учётом изменения масштаба кадров); с помощью стандартного ПО для обработки данных, предоставляемого на платной основе производителем БПЛА (DJI Terra, https://www.dji.com/dji-terra). Для оценки качества работы различных методов на изображениях оператором ПО были выбраны 40 особых точек, географические координаты которых определялись независимо для каждого из трёх способов обработки. Точки выбирались на легко идентифицируемых частях крон деревьев.



Puc. 5. Средний разброс значений географических координат для выбранной точки в зависимости от метода обработки: *a* — изображение выбранной точки; *б* — разброс координат точки при прямом наложении; *в* — разброс координат точки при использовании разработанного способа; *г* — разброс координат точки при использовании ПО Тегга

Для каждой из отобранных точек устанавливались географические координаты. Математическое ожидание координат точек определялось на основе пяти независимых полётов БПЛА. После этого оценивалось смещение (в метрах) между математическим ожидани-

ем и координатами точки в каждом из наборов данных. Такое расстояние после усреднения по всем наборам данных представляет собой радиус разброса значений географических координат точек относительно их математического ожидания:

$$\overline{r} = \frac{1}{m} \sum_{i=0}^{m-1} \left(\frac{1}{n} \sum_{j=0}^{n-1} \Delta l_j^i \right),$$

где m — количество отобранных для анализа точек (в данном случае m = 40); n — количество проведённых измерений (в данном случае n = 5); Δl_j^i — расстояние (в метрах) между математическим ожиданием географических координат *i*-й точки и её координатами в *j*-м эксперименте.

Средний радиус разброса значений географических координат составил при прямом наложении изображений 2,48 м со среднеквадратическим отклонением 1,15 м; при использовании разработанного способа — 1,35 м со среднеквадратическим отклонением 0,57 м; при использовании стандартного ПО — 1,58 м со среднеквадратическим отклонением 1,03 м. Визуализация разброса значений представлена на *puc. 5* (см. с. 18) (радиусы центральных кругов на изображениях соответствуют радиусам разброса, радиусы периферийных кругов суммам радиусов разброса и соответствующих СКО).

Стоит отметить, что и разработанный программный модуль, и ПО Тегга позволяют осуществлять геопривязку изображений с достаточной точностью для работы с отдельными деревьями. В то же время качество сшивки в обоих программных продуктах для съёмки территории лесного массива с предельно малых высот довольно низкое. В настоящем исследовании измерения проводились на таких высотах с целью получения максимальной детализации изображений крон деревьев. В случаях, когда высокий уровень детализации не требуется или камера обладает существенно более высокой разрешающей способностью, рекомендуется проводить измерения с бо́льших высот.

Отбор вегетационных индексов для задач распознавания

Для выполнения всех этапов семантической сегментации по результатам визуального анализа тепловых карт, построенных на основе вычисления вегетационных индексов, были выбраны индексы и диапазоны их значений, позволяющие отделять кроны деревьев от подстилающей поверхности на изображениях (*puc. 6*, см. с. 20).

В задаче уточнения сегментации наибольший интерес представляют индексы GEMI (см. *рис. 66*), MTVI (см. *рис. 66*), NDGI (см. *рис. 62*), LCI (см. *рис. 60*) и TVI (см. *рис. 62*). Тепловая карта, построенная на основе значений индекса CVI, сильно коррелирует с тепловой картой на основе индекса LCI, возможно равнозначное использование одного из двух индексов. Оба индекса позволяют выделять границу крон деревьев. Карты на основе индексов TVI и SRRRE также схожи, но в данном случае выбор был сделан в пользу использования индекса TVI в силу его нормированности. На тепловой карте, основанной на значениях индекса SRRB, присутствует наибольшее количество шумов по сравнению со всеми другими использованными индексами, вследствие чего было принято решение не использовать его в задаче уточнения сегментации.

Дополнение результатов семантической сегментации

На следующем этапе исследования проводилась семантическая сегментация изображений для определения масок крон деревьев. Этапы сегментации на примере одного изображения представлены на *puc*. 7 (см. с. 21).

На этапе исключения из сегментов областей с изображением подстилающей поверхности и добавления недостающих частей крон деревьев (см. *рис. 7в*) в среднем состав сегмента изменялся на величину от 19 до 41 % (для набора из 500 сегментов, соответствующих кронам).



Рис. 6. Пример исходного изображения (*a*) и тепловые карты, построенные на основе вычисления индексов GEMI (*b*), MTVI (*b*), NDGI (*c*), LCI (*d*) и TVI (*e*)

Такой процент изменения области для спектрального анализа в среднем изменяет значения отражательных коэффициентов в сегментах на величину от 9 до 22 %, что можно считать существенным при мониторинге состояния деревьев, поэтому дополнительное выделение границ внутри сегментов становится обязательным в данной методике. При этом предлагается принимать для независимого анализа при мониторинге состояния древостоев и полные прямоугольные сегменты, и оконтуренные области.

Оценка точности работы всех этапов сегментации проводилась на наборе из 100 изображений участка лесного массива. Точность распознавания крон деревьев определялась по общепринятым формулам (Портнов и др., 2022; Sokolova et al., 2006), а также с использованием новой метрики точности для обучения, которая увеличивает вес ошибочно детектированных деревьев (*табл. 2*). Новая метрика введена в качестве оценки возможности использования разработанного алгоритма для дополнительного обучения нейросети.



Рис. 7. Этапы семантической сегментации изображения: *а* — фрагмент исходного кадра; *б* — изображение с маской крон деревьев, вычисленной с использованием модели Deep Forest, и наложенными масками после дополнительного поиска сегментов (результаты поиска выделены синим); *в* — изображение после оконтуривания крон деревьев

Название параметра	Формула для расчёта	Нейросетевая модель Deep Forest	Разработанный алгоритм
Точность (<i>анел</i> . precision)	$\varepsilon_p = \frac{1}{K} \sum_{j=0}^{K} \frac{\mathrm{TP}_j}{\mathrm{TP}_j + \mathrm{FP}_j}$	0,979	0,970
Отклик (<i>англ</i> . recall)	$\varepsilon_r = \frac{1}{K} \sum_{j=0}^{K} \frac{\mathrm{TP}_j}{\mathrm{TP}_j + \mathrm{FN}_j}$	0,612	0,873
Статистическая оценка (F-score)	$F = \frac{2\varepsilon_r \varepsilon_p}{(\varepsilon_r + \varepsilon_p)}$	0,753	0,919
Точность для обучения (<i>англ</i> . training)	$\varepsilon_t = \frac{1}{K} \sum_{j=0}^{K} \frac{\mathrm{TP}_j - \mathrm{FP}_j}{\mathrm{TP}_j + \mathrm{FN}_j}$	0,598	0,840

Таблица 2. Оценка точности сегментации

П р и м е ч а н и е: K — количество изображений в выборке для оценки точности; TP_{j} — количество корректно распознанных крон деревьев на *j*-м изображении (*англ*. true positive); FP_{j} — количество ошибочно распознанных крон деревьев на *j*-м изображении (*англ*. false positive); FN_{j} — количество нераспознанных крон деревьев на *j*-м изображении (*англ*. false positive); FN_{j} — количество нераспознанных крон деревьев на *j*-м изображении (*англ*. false positive); FN_{j} — количество нераспознанных крон деревьев на *j*-м изображении (*англ*. false negative).

Полученные значения статистической оценки точности распознавания нейросети Deep Forest сопоставимы с проведёнными ранее исследованиями (например, в работе А. М. Портнова с соавторами (Портнов и др., 2022)). Это говорит о том, что оценку увеличения точности за счёт применения разработанного алгоритма можно считать корректной. В некоторых исследованиях статистическая точность распознавания крон превышает полученную в настоящей работе (например, в исследовании К.А. Корзникова с соавторами (Korznikov et al., 2021)), однако в данном случае прямое сравнение будет некорректным ввиду различий входных данных (в работе (Korznikov et al., 2021) кроны на изображениях были существенно удалены друг от друга, пространственное разрешение было более низким).

По новой метрике оценки точности для обучения разработанный алгоритм показывает точность 84 %, чего может быть достаточно для формирования выборки для дополнительного обучения нейросетевой модели. При этом сегменты, отсеянные на 3-м и 4-м этапах разработанного алгоритма, можно использовать в качестве примеров сегментов, не являющихся деревьями, при формировании обучающей выборки.

Заключение

В настоящей работе разработан адаптивный метод географической привязки изображений сверхвысокого пространственного разрешения, зарегистрированных с борта БПЛА без использования RTK-систем. Метод использует апостериорную информацию об объектах в кадрах, что позволяет уменьшить средний радиус разброса значений географических координат деревьев относительно их математического ожидания на 46 % по сравнению с прямым наложением и на 15 % по сравнению с алгоритмом, использованным в ПО производителя БПЛА.

Наилучшие различия крон деревьев и подстилающей поверхности определяются с использованием индексов MTVI и GEMI. В работе представлены наиболее информативные диапазоны значений этих и других вегетационных индексов, которые могут быть использованы для задачи распознавания крон, а также при мониторинге состояния древостоев.

Разработан алгоритм автоматического уточнения результатов сегментации нейросетью Deep Forest, основанный на вычислении значений вегетационных индексов по мультиспектральному изображению с последующим анализом. Статистическая точность разработанного алгоритма (F-score) составила 91,9 %, что больше точности для нейросети Deep Forest на 16,6 %. Кроме того, алгоритм обладает высоким значением точности для обучения — 84 %, что выше, чем у нейросети Deep Forest на 24,2 %. В силу того, что алгоритм основан на гистограммном анализе изображения, область его применения ограничена ситуациями, когда деревья занимают существенную часть изображения.

Таким образом, была разработана методика обработки данных для мониторинга состояния отдельных деревьев на основе мультиспектральных изображений сверхвысокого пространственного разрешения, зарегистрированных с борта БПЛА с предельно малых высот.

Выражаю благодарность доктору физико-математических наук, профессору Катковскому Леониду Владимировичу, доктору физико-математических наук, профессору Беляеву Борису Илларионовичу, а также научному сотруднику Красовской Ольге Олеговне за научные консультации и критические замечания по теме исследования.

Литература

- 1. Алешко Р.А., Алексеева А.А., Шошина К.В. и др. Разработка методики актуализации информации о лесном участке с использованием снимков со спутников и малых БПЛА // Современные проблемы дистанционного зондирования Земли из космоса. 2017. Т. 14. № 5. С. 87–99. DOI: 10.21046/2070-7401-2017-14-5-87-99.
- 2. *Гонсалес Р., Вудс Р.* Цифровая обработка изображений: пер. с англ.; 3-е изд., испр. и дополн.; пер. Л. И. Рубанова, П.А. Чочиа; ред. П.А. Чочиа. М.: Техносфера, 2012. 1104 с.
- 3. *Дубинин М.* Вычисление расстояния и начального азимута между двумя точками на сфере / Географ. информац. системы и дистанц. зондирование. 2006. https://gis-lab.info/qa/great-circles.html.
- 4. Катковский Л. В., Беляев Б. И., Сосенко В. А., Абламейко С. В. Аппаратно-программный комплекс «Калибровка» для наземного спектрометрирования подстилающей поверхности и атмосферы // 7-й Белорусский космич. конгресс: материалы конгресса. В 2 т. Минск: ОИПИ НАН Беларуси, 2017. Т. 2. С. 36–40.
- 5. *Катковский Л. В., Силюк О. О., Беляев Б. И. и др.* Обнаружение усыханий хвойных лесов по авиакосмическим данным // Современные проблемы дистанционного зондирования Земли из космоса. 2022. Т. 19. № 3. С. 88–102. DOI: 10.21046/2070-7401-2022-19-3-88-102.

- 6. *Керчев И.А., Маслов К.А., Марков Н. Г., Токарева О.С.* Семантическая сегментация повреждённых деревьев пихты на снимках с беспилотных летательных аппаратов // Современные проблемы дистанционного зондирования Земли из космоса. 2021. Т. 18. № 1. С. 116–126. DOI: 10.21046/2070-7401-2021-18-1-116-126.
- Кэлер А., Брэдски Г. Анализ изображений. Гистограммы и шаблоны. Контуры. Особые точки и дескрипторы // Изучаем OpenCV 3: пер. с англ.; пер. А.А. Слинкин; ред. Д. Мовчан. М.: ДМК Пресс, 2017. Гл. 12–14, 16. С. 310–375, 418–495.
- 8. Ломако А.А. Метод формирования панорамных изображений по мультиспектральным данным беспилотного летательного аппарата, учитывающий дисторсию камеры // Журн. Белорусского гос. ун-та. Физика. 2022. № 2. С. 60–69. DOI: 10.33581/2520-2243-2022-2-60-69.
- 9. Ломако А.А., Ивуть П.В., Гуторов А.В., Щербаков Н.Г. Определение пространственного разрешения аэрофотосистем в летном эксперименте // Прикладные проблемы оптики, информатики, радиофизики и физики конденсированного состояния: материалы 7-й Международ. научно-практич. конф. 18–19 мая 2023, Минск / М-во образования Республики Беларусь; Ин-т прикладных физ. проблем им. А. Н. Севченко Белорусского гос. ун-та. Минск, 2023. С. 425–427.
- 10. *Молчанов А. С.* Методика оценки линейного разрешения на пиксель аэрофотосистем военного назначения при проведении летных испытаний // Изв. высш. учеб. заведений. Геодезия и аэрофотосъемка. 2018. Т. 62. № 4. С. 390–396. DOI: 10.30533/0536-101X-2018-62-4-390-396.
- 11. Портнов А. М., Иванова Н. В., Шашков М. П. Опыт использования нейронной сети DeepForest для детектирования деревьев в широколиственном лесу // Докл. Международ. конф. «Математическая биология и биоинформатика» / под ред. В.Д. Лахно. Пущино: ИМПБ РАН, 2022. Т. 9. Ст. № е45. 6 с. DOI: 10.17537/icmbb22.12.
- 12. Силюк О. О., Литвинович Г. С., Бручковский И. И. и др. Классификация стрессовых состояний ели обыкновенной по спектральным характеристикам при дистанционных измерениях // Современные проблемы дистанционного зондирования Земли из космоса. 2022. Т. 19. № 5. С. 125–135. DOI: 10.21046/2070-7401-2022-19-5-125-135.
- 13. Тимофеев М. В. RTK-режим системы глобального позиционирования при топографической съемке линейных объектов / Огарёв-Online. 2015. № 24(65). https://cyberleninka.ru/article/n/ rtk-rezhim-sistemy-globalnogo-pozitsionirovaniya-pri-topograficheskoy-semke-lineynyh-obektov.
- 14. *Alahi A.*, *Ortiz R.*, *Vandergheynst P.* FREAK: Fast Retina Keypoint // IEEE Conf. Computer Vision and Pattern Recognition. 2012. P. 510–517. DOI: 10.1109/CVPR.2012.6247715.
- 15. *Awad M*. Forest mapping: a comparison between hyperspectral and multispectral images and technologies // J. Forestry Research. 2018. V. 29. No. 5. P. 1395–1405. DOI: 10.1007/s11676-017-0528-y.
- Bannari A., Morin D., Bonn F., Huete A. R. A review of vegetation indices // Remote Sensing Reviews. 1995. V. 13. No. 1. P. 95–120.
- 17. *Brandtberg T., Walter F.* Automated delineation of individual tree crowns in high spatial resolution aerial images by multiple-scale analysis // Machine Vision and Applications. 1998. No. 11. P. 64–73. DOI: 10.1007/s001380050091.
- Chen Q., Gao T., Zhu J. et al. Individual Tree Segmentation and Tree Height Estimation Using Leaf-Off and Leaf-On UAV-LiDAR Data in Dense Deciduous Forests // Remote Sensing. 2022. V. 14. Article 2787. DOI: 10.3390/rs14122787.
- 19. *Comaniciu D.*, *Meer P.* Mean Shift Analysis and Applications // IEEE Intern. Conf. Computer Vision. 1999. V. 2. Article 1197.
- Dainelli R., Toscano P., Di Gennaro S. F., Matese A. Recent Advances in Unmanned Aerial Vehicle Forest Remote Sensing — A Systematic Review. Pt. I: A General Framework // Forests. 2021. V. 12. Article 327. DOI: 10.3390/f12030327.
- 21. *Datt B.* A new reflectance index for remote sensing of chlorophyll content in higher plants: tests using Eucalyptus leaves // J. Plant Physiology. 1999. No. 154. P. 30–36. DOI: 10.1016/S0176-1617(99)80314-9.
- 22. *Ecke S., Dempewolf J., Frey J. et al.* UAV-Based Forest Health Monitoring: A Systematic Review // Remote Sensing. 2022. V. 14. Article 3205. DOI: 10.3390/rs14133205.
- 23. *Fassnacht F., Latifi H., Ghosh A. et al.* Assessing the potential of hyperspectral imagery to map bark beetle-induced tree mortality // Remote Sensing of Environment. 2014. V. 140. P. 533–548. DOI: 10.1016/j. rse.2013.09.014.
- 24. *Guimarães N., Pádua L., Marques P. et al.* Forestry Remote Sensing from Unmanned Aerial Vehicles: A Review Focusing on the Data, Processing and Potentialities // Remote Sensing. 2020. V. 12. Article 1046. DOI: 10.3390/rs12061046.
- 25. *Guo Y., Zhang X., Chen S. et al.* Integrated UAV-Based Multi-Source Data for Predicting Maize Grain Yield Using Machine Learning Approaches // Remote Sensing. 2022. V. 14. Article 6290. DOI: 10.3390/rs14246290.
- 26. *Haboudane D., Miller J. R., Pattey E. et al.* Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture // Remote Sensing of Environment. 2004. V. 90. Iss. 3. P. 337–352. DOI: 10.1016/j.rse.2003.12.013.

- 27. *He J., Lyu D., He L. et al.* Combining Object-Oriented and Deep Learning Methods to Estimate Photosynthetic and Non-Photosynthetic Vegetation Cover in the Desert from Unmanned Aerial Vehicle Images with Consideration of Shadows // Remote Sensing. 2023. V. 15. Article 105. DOI: 10.3390/ rs15010105.
- 28. *Hunt Jr. E. R., Daughtry C. S. T., Eitel J. U. H., Long D. S.* Remote Sensing Leaf Chlorophyll Content Using a Visible Band Index // Agronomy J. 2011. V. 103. P. 1090–1099. DOI: 10.2134/agronj2010.0395.
- 29. *Kislov D. E., Korznikov K.A., Altman J. et al.* Extending deep learning approaches for forest disturbance segmentation on very high-resolution satellite images // Remote Sensing in Ecology and Conservation. 2021. V. 7. No. 3. P. 355–368. DOI: 10.1002/rse2.194.
- Korznikov K.A., Kislov D. E., Altman J. et al. Using U-Net-Like Deep Convolutional Neural Networks for Precise Tree Recognition in Very High Resolution RGB (Red, Green, Blue) Satellite Images // Forests. 2021. V. 12. Article 66. DOI: 10.3390/f12010066.
- 31. *Lamaka A.A.*, *Gutarau A.V.*, *Shcherbakou N.G.*, *Ivuts P.V.* Photospectral Data Obtaining with the Unmanned Aerial Spectrometry Vehicle // Devices and Methods of Measurements. 2023. V. 14. No. 1. P. 7–17. DOI: 10.21122/2220-9506-2023-14-1-7-17.
- 32. Lausch A., Heurich M., Gordalla D. et al. Forecasting potential bark beetle outbreaks based on spruce forest vitality using hyperspectral remote-sensing techniques at different scales // Forest Ecology and Management. 2013. V. 308. P. 76–89. DOI: 10.1016/j.foreco.2013.07.043.
- 33. *Mohan M., Silva C.A., Klauberg C. et al.* Individual Tree Detection from Unmanned Aerial Vehicle (UAV) Derived Canopy Height Model in an Open Canopy Mixed Conifer Forest // Forests. 2017. V. 8. Article 340. DOI: 10.3390/f8090340.
- 34. *Otsu N.A.* Threshold Selection Method from Gray-Level Histograms // IEEE Trans. Systems, Man, and Cybernetics. 1979. V. 9. No. 1. P. 62–66.
- 35. *Rublee E., Rabaud V., Konolige K., Bradski G.* ORB: An efficient alternative to SIFT or SURF // 2011 Intern. Conf. Computer Vision. 2011. P. 2564–2571. DOI: 10.1109/ICCV.2011.6126544.
- 36. *Shamaoma H., Chirwa P.W., Ramoelo A. et al.* The Application of UASs in Forest Management and Monitoring: Challenges and Opportunities for Use in the Miombo Woodland // Forests. 2022. V. 13. Article 1812. DOI: 10.3390/f13111812.
- Sokolova M., Japkowicz N., Szpakowicz S. Beyond accuracy, F-score and ROC: A family of discriminant measures for performance evaluation // AI 2006: Advances in Artificial Intelligence. Lecture Notes in Computer Science / eds. Sattar A., Kang B. Berlin; Heidelberg: Springer, 2006. V. 4304. P. 1015–1021. DOI: 10.1007/11941439_1.
- 38. *Takhtkeshha N., Mohammadzadeh A., Salehi B.* A Rapid Self-Supervised Deep-Learning-Based Method for Post-Earthquake Damage Detection Using UAV Data (Case Study: Sarpol-e Zahab, Iran) // Remote Sensing. 2023. V. 15. Article 123. DOI: 10.3390/rs15010123.
- 39. *Torres P., Rodes-Blanco M., Viana-Soto A. et al.* The Role of Remote Sensing for the Assessment and Monitoring of Forest Health: A Systematic Evidence Synthesis // Forests. 2021. V. 12. Article 1134. DOI: 10.3390/f12081134.
- 40. Weinstein B. G., Marconi S., Bohlman S. et al. Individual Tree-Crown Detection in RGB Imagery Using Semi-Supervised Deep Learning Neural Networks // Remote Sensing. 2019. V. 11. Article 1309. DOI: 10.3390/rs11111309.

Methodology of data processing for individual trees monitoring based on UAV multispectral measurements

A.A. Lamaka

A. N. Sevchenko Institute of Applied Physical Problems of Belarusian State University Minsk 220045, Belarus E-mail: alekseylomako@gmail.com

To date, there is a large number of studies in the field of trees condition monitoring to identify their illness. However, only in a small part of such works researchers set the task of detecting the drying of individual trees at an early stage. This article describes an original approach to monitoring the state of trees based on UAV multispectral camera measurements and subsequent processing of recorded

data with specialized new methods. The article describes a new method of geographic data binding using pixel distances between nearby images calculated with the OpenCV library as additional information. This method makes it possible to reduce the average radius of the tree crowns images geographical coordinates spread by 46 % compared with the direct overlay of frames on coordinates formed on the basis of data from global navigation satellite systems, and by 15 % compared with standard software. The paper also describes an approach to semantic image segmentation based on the use of a pre-trained Deep Forest neural network model and additional image analysis of specific vegetation indices using an original algorithm. As a result of this method, the accuracy of tree recognition (F-score) was increased from 75 to 92 %. Together, the described methods form a technique for multispectral images processing for monitoring coniferous plantations condition. This technique allows to analyze the spectral reflectance characteristics of individual trees on the basis of the results of multi-temporal areal measurements.

Keywords: UAV, images, geotagging, key points, semantic segmentation, neural networks, Deep Forest, vegetation indexes

Accepted: 25.08.2023 DOI: 10.21046/2070-7401-2023-20-5-9-27

References

- 1. Aleshko R.A., Alekseeva A.A., Shoshina K.V. et al., Development of the methodology to update the information on a forest area using satellite imagery and small UAVs, *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2017, Vol. 14, No. 5, pp. 87–99 (in Russian), DOI: 10.21046/2070-7401-2017-14-5-87-99.
- 2. Gonzalez R. C., Woods R. E., Digital Image Processing, 3rd ed., Prentice Hall, 2008, 976 p.
- 3. Dubinin M., Calculating the distance and initial azimuth between two points on a sphere, *Geographic Information Systems and Remote Sensing*, 2006 (in Russian), https://gis-lab.info/qa/great-circles.html.
- 4. Katkouski L.V., Hardware-software system "Calibrovka" for ground-based spectrometry of the underlying surface and atmosphere, *7-i Belorusskii kosmicheskii congress* (7th Belarussian Space Congress, Proc.), Minsk, 2017, Vol. 2, pp. 36–40 (in Russian).
- 5. Katkovsky L. V., Siliuk V. A., Belyaev B. I. et al., Detection of drying coniferous forests from aerospace data, *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2022, Vol. 19, No. 3, pp. 88–102 (in Russian), DOI: 10.21046/2070-7401-2022-19-3-88-102.
- Kerchev I.A., Maslov K.A., Markov N.G., Tokareva O.S., Semantic segmentation of damaged fir trees in unmanned aerial vehicle images, *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2021, Vol. 18, No. 1, pp. 116–126 (in Russia), DOI: 10.21046/2070-7401-2021-18-1-116-126.
- Kaehler A., Bradski G., *Learning OpenCV 3*, Sebastopol, CA: O'Reilly Media, Inc., 2016, Ch. 12–14, 16, pp. 360–445, 493–586.
- Lamaka A. A., Considering camera distortion panoramic images forming method for unmanned aerial vehicle multispectral data, *J. Belarusian State University. Physics*, 2022, Vol. 2, pp. 60–69 (in Russian), DOI: 10.33581/2520-2243-2022-2-60-69.
- Lamaka A.A., Ivuts P.V., Gutarau A.V., Shcharbakou M.G., Determination of the spatial resolution of aerial photo systems in a flight experiment, *Prikladnye problemy optiki*, *informatiki*, *radiofiziki i fiziki kondensirovannogo sostoyaniya* (Applied problems of optics, computer science, radiophysics and condensed matter physics), Proc. 7th Intern. Scientific and Practical Conf., Minsk, 2023, pp. 425–427 (in Russian).
- Molchanov A. S., Methodology of evaluation of linear permit per pixel of aerophotosystems of military purpose when conducting flight tests, *Izvestiya vuzov. Geodesy and Aerophotosurveying*, 2018, Vol. 62, No. 4, pp. 390–396 (in Russian), DOI: 10.30533/0536-101X-2018-62-4-390-396.
- 11. Portnov A. M., Ivanova N. V., Shashkov M. P., Experience of using the DeepForest neural network to detect trees in a broad-leaved forest, *Matematicheskaya biologiya i bioinformatika* (Mathematical Biology and Bioinformatics), Proc. Intern. Conf., V. D. Lakhno (ed.), Pushchino: IMPB RAS, 2022, Vol. 9, Paper No. e45, 6 p. (in Russian), DOI: 10.17537/icmbb22.12.
- Siliuk V. A., Litvinovich H. S., Bruchkousky I. I. et al., Pícea ábies stress levels classification by spectral features of remote sensing data, *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2022, Vol. 19, No. 5, pp. 125–135 (in Russian), DOI: 10.21046/2070-7401-2022-19-5-125-135.
- 13. Timofeev M. V., RTK-global positioning system mode for topographic survey of linear objects, *Ogarev-Online*, 2015, Vol. 65, No. 4 (in Russian), https://cyberleninka.ru/article/n/ rtk-rezhim-sistemy-globalnogo-pozitsionirovaniya-pri-topograficheskoy-semke-lineynyh-obektov.

- 14. Alahi A., Ortiz R., Vandergheynst P., FREAK: Fast Retina Keypoint, *IEEE Conf. Computer Vision and Pattern Recognition*, 2012, pp. 510–517, DOI: 10.1109/CVPR.2012.6247715.
- 15. Awad M., Forest mapping: a comparison between hyperspectral and multispectral images and technologies, *J. Forestry Research*, 2018, No. 29, pp. 1395–1405, DOI: 10.1007/s11676-017-0528-y.
- 16. Bannari A., Morin D., Bonn F., Huete A. R., A review of vegetation indices, *Remote Sensing Reviews*, 1995, Vol. 13, No. 13, pp. 95–120.
- Brandtberg T., Walter F., Automated delineation of individual tree crowns in high spatial resolution aerial images by multiple-scale analysis, *Machine Vision and Applications*, 1998, No. 11, pp. 64–73, DOI: 10.1007/ s001380050091.
- Chen Q., Gao T., Zhu J. et al., Individual Tree Segmentation and Tree Height Estimation Using Leaf-Off and Leaf-On UAV-LiDAR Data in Dense Deciduous Forests, *Remote Sensing*, 2022, Vol. 14, Article 2787, DOI: 10.3390/rs14122787.
- 19. Comaniciu D., Meer P., Mean Shift Analysis and Applications, *IEEE Intern. Conf. Computer Vision*, 1999, Vol. 2, Article 1197.
- Dainelli R., Toscano P., Di Gennaro S. F., Matese A., Recent Advances in Unmanned Aerial Vehicle Forest Remote Sensing – A Systematic Review. Pt. I: A General Framework, *Forests*, 2021, No. 12, Article 327, DOI: 10.3390/f12030327.
- 21. Datt B., A new reflectance index for remote sensing of chlorophyll content in higher plants: tests using Eucalyptus leaves, *J. Plant Physiology*, 1999, No. 154, pp. 30–36, DOI: 10.1016/S0176-1617(99)80314-9.
- 22. Ecke S., Dempewolf J., Frey J. et al., UAV-Based Forest Health Monitoring: A Systematic Review, *Remote Sensing*, 2022, Vol. 14, Article 3205, DOI: 10.3390/rs14133205.
- 23. Fassnacht F., Latifi H., Ghosh A. et al., Assessing the potential of hyperspectral imagery to map bark beetle-induced tree mortality, *Remote Sensing of Environment*, 2014, Vol. 140, pp. 533–548, DOI: 10.1016/j. rse.2013.09.014.
- 24. Guimarães N., Pádua L., Marques P. et al., Forestry Remote Sensing from Unmanned Aerial Vehicles: A Review Focusing on the Data, Processing and Potentialities, *Remote Sensing*, 2020, Vol. 12, Article 1046, DOI: 10.3390/rs12061046.
- Guo Y., Zhang X., Chen S. et al., Integrated UAV-Based Multi-Source Data for Predicting Maize Grain Yield Using Machine Learning Approaches, *Remote Sensing*, 2022, Vol. 14, Article 6290, DOI: 10.3390/ rs14246290.
- 26. Haboudane D., Miller J. R., Pattey E. et al., Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture, *Remote Sensing of Environment*, 2004, Vol. 90, Issue 3, pp. 337–352, DOI: 10.1016/j.rse.2003.12.013.
- 27. He J., Lyu D., He L. et al., Combining Object-Oriented and Deep Learning Methods to Estimate Photosynthetic and Non-Photosynthetic Vegetation Cover in the Desert from Unmanned Aerial Vehicle Images with Consideration of Shadows, *Remote Sensing*, 2023, Vol. 15, Article 105, DOI: 10.3390/rs15010105.
- 28. Hunt Jr. E. R., Daughtry C. S. T., Eitel J. U. H., Long D. S., Remote Sensing Leaf Chlorophyll Content Using a Visible Band Index, *Agronomy J.*, 2011, Vol. 103, pp. 1090–1099, DOI: 10.2134/agronj2010.0395.
- 29. Kislov D. E., Korznikov K. A., Altman J. et al., Extending deep learning approaches for forest disturbance segmentation on very high-resolution satellite images, *Remote Sensing in Ecology and Conservation*, 2021, Vol. 7, No. 3, pp. 355–368, DOI: 10.1002/rse2.194.
- Korznikov K.A., Kislov D.E., Altman J. et al., Using U-Net-Like Deep Convolutional Neural Networks for Precise Tree Recognition in Very High Resolution RGB (Red, Green, Blue) Satellite Images, *Forests*, 2021, Vol. 12, Article 66, DOI: 10.3390/f12010066.
- 31. Lamaka A.A., Gutarau A.V., Shcherbakou N.G., Ivuts P.V., Photospectral Data Obtaining with the Unmanned Aerial Spectrometry Vehicle, *Devices and Methods of Measurements*, 2023, Vol. 14, No. 1, pp. 7–17, DOI: 10.21122/2220-9506-2023-14-1-7-17.
- 32. Lausch A., Heurich M., Gordalla D. et al., Forecasting potential bark beetle outbreaks based on spruce forest vitality using hyperspectral remote-sensing techniques at different scales, *Forest Ecology and Management*, 2013, Vol. 308, pp. 76–89, DOI: 10.1016/j.foreco.2013.07.043.
- Mohan M., Silva C.A., Klauberg C. et al., Individual Tree Detection from Unmanned Aerial Vehicle (UAV) Derived Canopy Height Model in an Open Canopy Mixed Conifer Forest, *Forests*, 2017, Vol. 8, Article 340, DOI: 10.3390/f8090340.
- 34. Otsu N.A., Threshold Selection Method from Gray-Level Histograms, *IEEE Trans. Systems, Man, and Cybernetics*, 1979, Vol. 9, No. 1, pp. 62–66.
- 35. Rublee E., Rabaud V., Konolige K., Bradski G., ORB: An efficient alternative to SIFT or SURF, *Intern. Conf. Computer Vision*, 2011, pp. 2564–2571, DOI: 10.1109/ICCV.2011.6126544.
- 36. Shamaoma H., Chirwa P.W., Ramoelo A. et al., The Application of UASs in Forest Management and Monitoring: Challenges and Opportunities for Use in the Miombo Woodland, *Forests*, 2022, Vol. 13, Article 1812, DOI: 10.3390/f13111812.

- Sokolova M., Japkowicz N., Szpakowicz S., Beyond accuracy, F-score and ROC: A family of discriminant measures for performance evaluation, *AI 2006: Advances in Artificial Intelligence. Lecture Notes in Computer Science*, Sattar A., Kang B (eds.), Berlin; Heidelberg: Springer, 2006, Vol. 4304, pp. 1015–1021, DOI: 10.1007/11941439_1.
- 38. Takhtkeshha N., Mohammadzadeh A., Salehi B., A Rapid Self-Supervised Deep-Learning-Based Method for Post-Earthquake Damage Detection Using UAV Data (Case Study: Sarpol-e Zahab, Iran), *Remote Sensing*, 2023, Vol. 15, Article 123, DOI: 10.3390/rs15010123.
- 39. Torres P., Rodes-Blanco M., Viana-Soto A. et al. The Role of Remote Sensing for the Assessment and Monitoring of Forest Health: A Systematic Evidence Synthesis, *Forests*, 2021, Vol. 12, Article 1134, DOI: 10.3390/f12081134.
- 40. Weinstein B.G., Marconi S., Bohlman S. et al., Individual Tree-Crown Detection in RGB Imagery Using Semi-Supervised Deep Learning Neural Networks, *Remote Sensing*, 2019, Vol. 11, Article 1309, DOI: 10.3390/rs11111309.