МЕТОДЫ СЕГМЕНТАЦИИ ALLSKY ИЗОБРАЖЕНИЙ ДЛЯ ЗАДАЧИ АНАЛИЗА ОБЛАЧНОСТИ

Афонасенко А.В[1]., Попова С.Д.[2], Шалеев А.В.[1]

[1]Институт оптики атмосферы им. В.Е. Зуева СО РАН, г. Томск, Россия

[2]Национальный исследовательский Томский государственный университет

e-mail: aav@iao.ru, sofia.popova20180520@gmail.com, sav@iao.ru

В работе рассматриваются подходы к сегментации Allsky изображений, с целью обнаружения облачности. Сравниваются методы на основе цветовых индексов, алгоритмы машинного обучения и нейросетевые модели. Цветовые пороговые методы, такие как cloud index, показали высокую чувствительность при простоте реализации, но низкую универсальность. Классические алгоритмы машинного обучения обеспечивают более гибкую адаптацию, но ограничены в учете пространственного контекста. Результаты нейросетевой сегментации оказались менее точными, что объясняется недостаточным объемом обучающей выборки. Сделан вывод о перспективности комбинированных решений, объединяющих простые эвристики, машинное обучение и глубокие нейросети для повышения точности и надежности анализа облачности.

В условиях стремительно изменяющегося климата и увеличения числа экстремальных погодных явлений возрастает необходимость в высокоточной и оперативной оценке атмосферных процессов. Мониторинг облачности важен для изучения изменений климата, так как облака влияют на баланс энергии в атмосфере, отражая солнечное излучение и влияя на парниковый эффект. Одним из простых и эффективных средств мониторинга состояния облачности является т.н. камера всего неба (AllSky камера), которая в самом простом исполнении представляет из себя ПЗС-камеру со сверширокоугольными объективами типа рыбий глаз [1.]. Применение подобных систем регистрации изображений, в сочетании с алгоритмами компьютерного зрения, позволяет осуществлять непрерывный контроль и анализ атмосферных условий, а также обнаруживать и классифицировать различные воздушные объекты, что актуально как для научных исследований, так и для оперативного наблюдения.

Задача сегментации изображения на два класса – «чистое небо» и «облачность» является одной из ключевых задач в области анализа атмосферных явлений, метеорологии и дистанционного зондирования Земли. Её важность обусловлена как научной значимостью, так и практическими приложениями. Сегментация позволяет точно определить границы облачности и её пространственное распределение. Это необходимо для изучения процессов формирования облаков, их динамики и влияния на климатическую систему. Автоматическая сегментация избавляет специалистов от рутинной работы по анализу больших объемов данных, позволяя сосредоточиться на интерпретации результатов. Сегментация AllSky изображений на два класса является базовой задачей, которая может быть использована как отправная точка для

более сложных задач, таких как классификация типов облаков или детекция атмосферных явлений.

Первыми методами сегментации были методы, основанные на анализе цвета и простых пороговых правилах. Эти методы, и разработанные на их основе алгоритмы, основаны на простом предположении, что дневное небо голубое, а облака – белые. В этом случае обычно говорят о вычислении индекса облачности (Cloud index), который рассчитывается на основе анализа соотношения яркостей или значений пикселей в разных цветовых каналах изображения. Например, в работе [3.] предложено оценивать отношение интенсивностей точки в красном и синем каналах. Значение этого отношения выше определённого порога указывает на принадлежность к классу облако. Другой подход, предложенный в работах по мониторингу облачности методом компьютерного зрения [2.], выглядит следующим образом:

$$Cloud\,index = \frac{B - R}{B + R},$$

где B – интенсивность синего канала, R – интенсивность красного канала.

В этом случае значения индекса облачности, близкие к 1 соответствуют областям чистого неба, а значения, близкие к 0 или отрицательные соответствуют облакам (рисунок 1).

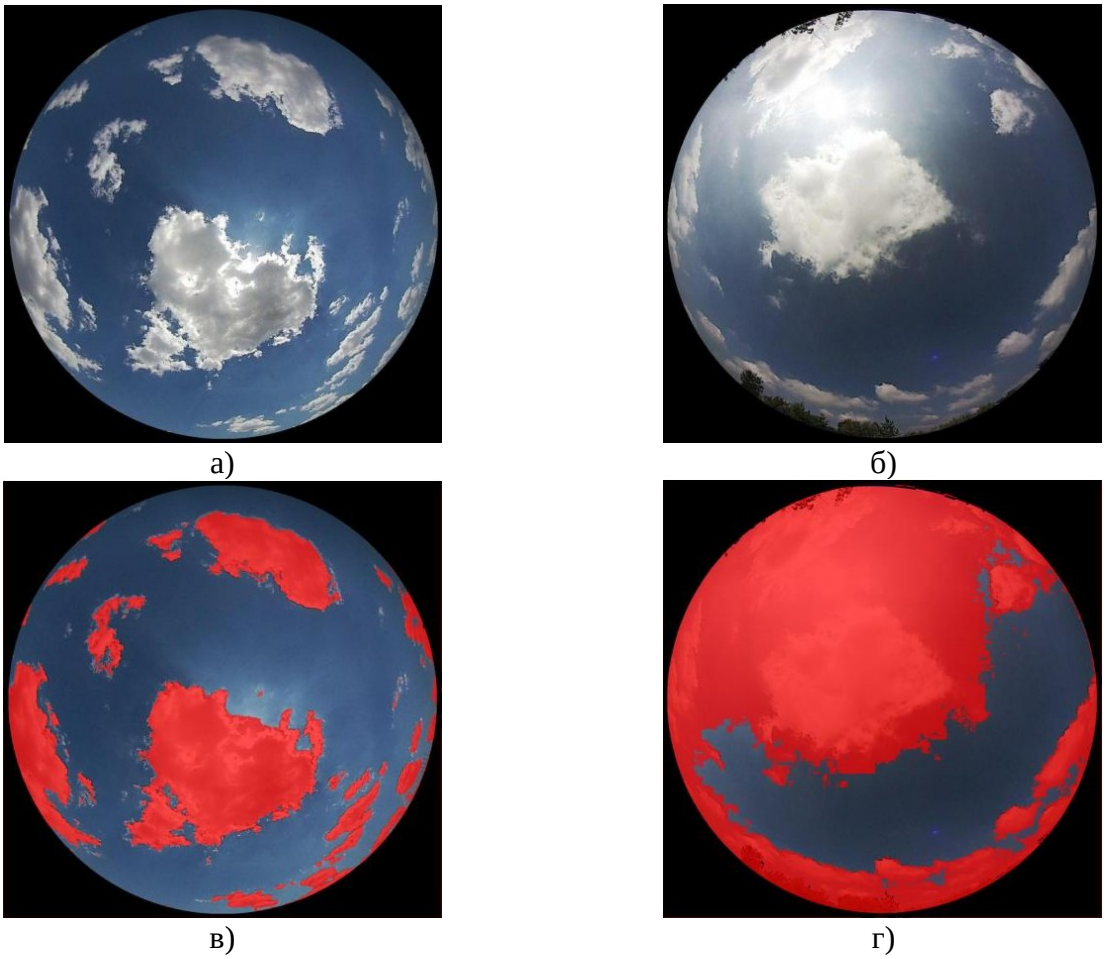

а) б) в) г)

Рисунок 1 – Пример сегментации изображений с помощью вычисления индекса облачности:

а), б) исходные изображения; в) пример «удачной» сегментации; г) пример неправильно подобранного порога

Иногда применяется модифицированная версия, использующая и зелёный канал:

$$Cloud\,index = \frac{B - \frac{R+G}{2}}{B + \frac{R+G}{2}}.$$

Это позволяет учитывать дополнительную информацию и повысить точность в отдельных условиях освещённости.

В большинстве случаев конечный результат сегментации очень сильно зависит от выбранного порогового значения, который в первую очередь будет зависеть от условий регистрации изображений. В некоторых работах пороги подбираются адаптивно, путем выбора глобального порога по гистограмме яркости изображения и делении пикселей изображения на два класса, с учетом максимизации межклассовой дисперсии [4.].

Следующим этапом развития методов сегментации стало применение методов классического машинного обучения, которые учитывают больше признаков изображения и способны обучаться на размеченных данных. Вместо ручного подбора порога стали использоваться алгоритмы классификации пикселей, методы кластеризации и обучения с учителем. Один из простых подходов – метод *k*-средних, он автоматически группирующий пиксели по схожести, например, цветовых характеристик. Можно, например, кластеризовать (сегментировать) изображение на 2 кластера по цветовым признакам RGB, а затем кластер с большей яркостью или определённым цветовым тоном интерпретировать как «облака», а второй – как «чистое небо». Такой подход избавляет от необходимости вручную задавать пороги. Однако результат сегментации всё еще будет зависеть от правильности выбранных признаков. Поэтому предпочтительнее использовать более мощные инструменты, которые обучаются на размеченных человеком изображениях различать облака и небо. К таким относятся, например, метод опорных векторов (SVM) [5.] и метод случайного леса (Random Forest) [6.]. В этих методах выбираются информативные признаки для каждого пикселя. Помимо базовых значений RGB интенсивности, можно использовать значения насыщенности, контраста, текстурные признаки и т.д. На основе обучающей выборки пикселей (размеченных как «облако» или «небо») алгоритм строит модель, способную классифицировать новые изображения. Однако и у них есть ограничения. Во-первых, им по-прежнему требуются явно заданные признаки. Набор цветовых и статистических параметров, подобранный для одной сцены, может оказаться недостаточным для другой. Во-вторых, эти подходы имеют

ограниченную способность учитывать контекст – они чаще оперируют значениями отдельных пикселей или небольших окрестностей.

Больших успехов в сегментации изображений достигли сверточные нейронные сети. Сильная сторона глубокого обучения в том, что сеть самостоятельно находит отличительные черты облаков на разных масштабах. Внутренние слои сети формируют иерархию признаков от простых границ до сложных текстур и форм облачных структур. Благодаря этому современные нейросетевые модели успешно сегментируют даже сложные случаи – разорванную облачность, тонкие перистые облака, облака на фоне бликующего моря и т.д. Исходное изображение проходит через серию сверточных слоев, которые выделяют всё более сложные признаки, после чего восстанавливается разметка пикселей. Результаты сегментации изображения с помощью методов машинного обучения представлены на рисунке 2.

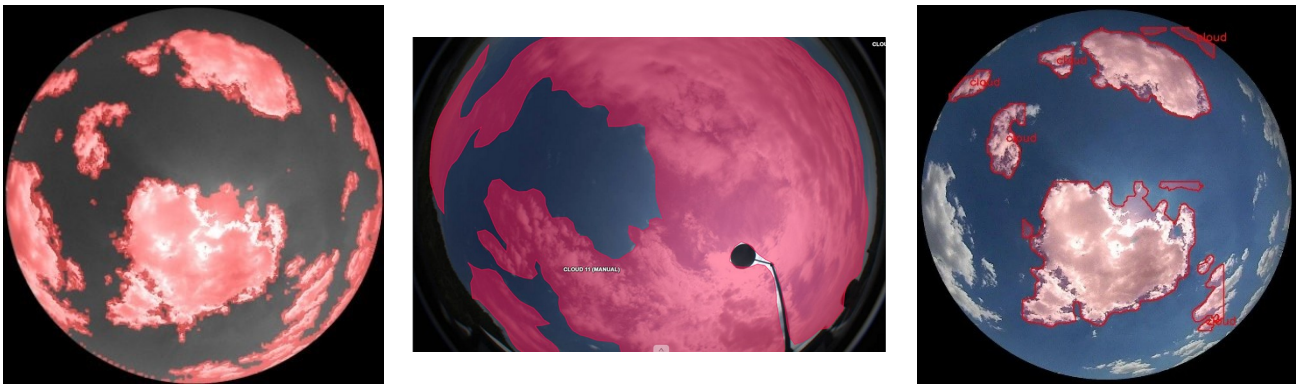

а) б) в)

Рисунок 2 – Результаты сегментации allsky изображений: а) метод k-средних; б), в) результаты, полученные с использованием различных моделей нейронных сетей.

Анализ результатов показывает, что каждый из подходов имеет свои преимущества и недостатки. Простые пороговые алгоритмы подходят для элементарных случаев и требуют минимум ресурсов; алгоритмы машинного обучения учитывают множество факторов и хорошо работают при должной настройке. Глубокие нейросети обеспечивают хорошую точность и способность адаптироваться к изменению условий, но при этом результаты существенно зависят от качества обучения.

Следует отметить, что не до конца решена задача сегментации в сложных условиях – при низком уровне освещения, особенно в ночное время, при наличии редких типов облаков или в условиях плохой видимости. В этих случаях целесообразно использовать, например мультиспектральный подход, когда алгоритм учитываются данные видимых, инфракрасных и, возможно, радиолокационных наблюдений для надёжного определения облачности в любых условиях. Комбинация моделей глубокого обучения с физическими моделями атмосферы и облачности могут объединить адаптивность нейросетей с интерпретируемостью физических

моделей. Так же, один из вероятных путей развития – гибридный подход, объединяющий сильные стороны всех поколений методов. Простые алгоритмы могут служить быстрым фильтром или маской областей интереса для последующей сегментации, а тщательно подобранные признаки классических методов машинного обучения позволят дополнить абстракции нейронных сетей. Такие комплексные решения способны обеспечить высокую надёжность и универсальность сегментации в самых разных географических и погодных условиях.

Исследования выполнены в рамках государственного задания ИОА СО РАН.

1. Галилейский В.П., Елизаров А.И., Кокарев Д.В., Матвиенко Г.Г., Морозов А.М. Программно-техническая система мониторинга и контроля оптико-физического состояния атмосферы. Часть 1. Панорамно-оптическая станция // Оптика атмосферы и океана. Физика атмосферы: Сборник докладов XXVII Международного симпозиума. [Электронный ресурс]. ISBN 978-5-94458-187-7. - Томск: Изд-во ИОА СО РАН, 2021. С. F5-F9.

2. Kalisch J. Estimation of the total cloud cover with high temporal resolution and parametrization of short-term fluctuations of sea surface insolation / Kalisch J., Macke A. // Meteorologische Zeitschrift – 2008. – Т. 17 – № 5 – С. 603–611.

3. Long C.N. Retrieving Cloud Characteristics from Ground-Based Daytime Color All-Sky Images / Long C.N., Sabburg J.M., Calbó J., Pagès D. // Journal of Atmospheric and Oceanic Technology – 2006. – Т. 23 – № 5 – С. 633–652.

4. Xie W. et al. SegCloud: A novel cloud image segmentation model using a deep convolutional neural network for ground-based all-sky-view camera observation //Atmospheric Measurement Techniques. – 2020. – Т. 13. – №. 4. – С. 1953-1961.

5. Latry C., Panem C., Dejean P. Cloud detection with SVM technique //2007 IEEE International Geoscience and Remote Sensing Symposium. – IEEE, 2007. – С. 448-451.

6. Wei J. et al. Cloud detection for Landsat imagery by combining the random forest and superpixels extracted via energy-driven sampling segmentation approaches //Remote Sensing of Environment. – 2020. – Т. 248. – С. 112005.