

Курочкин^{1,2} И.И., Богомолов¹ В.Ю., Кувшинов¹ М.Е.

¹Национальный исследовательский технологический университет МИСИС
119049, Москва, Ленинский проспект, д. 4, стр. 1

²Институт проблем передачи информации им. А.А. Харкевича РАН
127051, г. Москва, Большой Каретный переулок, д.19, стр. 1
E-mail: kurochkin@iitp.ru

Методы анализа снимков сельскохозяйственных полей

Методы машинного обучения применяются в различных отраслях, в том числе и в сельском хозяйстве. Данные методы применяются для решения различных задач: обнаружение болезней растений, классификация культур, идентификация сорняков, определение спелости и подсчет плодов, анализ водных ресурсов и почвы [1]. В тоже время, в сельском хозяйстве нашли свое применение беспилотные летательные аппараты (БПЛА) и спутниковые системы. Регулярный мониторинг с помощью спутниковых систем и аэрофотосъемки позволяет своевременно реагировать на изменения на сельскохозяйственных полях.

Спутниковые снимки позволяют эффективно производить мониторинг полей, следить за состоянием посевов, выявлять потенциальные угрозы. Особенностью данной технологии является то, что она позволяет в режиме реального времени наблюдать за состоянием посевов на большой территории или даже полях, находящихся на расстоянии, в разных областях, регионах, странах, на разных континентах, а также возможность формировать обширную статистическую базу для сравнений на основе исторических данных мониторинга. Преимуществами спутникового мониторинга являются: возможность мониторинга большой площади полей, возможность организации высокого уровня автоматизации наблюдения за посевами, а также автоматический анализ и интерпретация данных.

Использование снимков аэрофотосъемки с помощью БПЛА с низких высот 10-50 метров дает возможность анализировать данные, которые не видны на спутниковых снимках. Так на снимках с БПЛА можно увидеть отдельные растения и их листья. Такая информация дает возможность определять на ранних стадиях болезни растений и отклонения их развития.

После обработки исходных снимков помимо получения основных типов данных: ортофотоплан и карт отражений, можно еще получить и карты вегетационных индексов, таких как NDVI, SAVI, WI, NDWI, WDRVI, ARI, TCARI, MSAVI и др. Для вычисления вегетационных индексов необходимо производить съемку с помощью мультиспектральных камер. Мультиспектральные снимки позволяют получать больше информации о состоянии растительности, на основе ее отражательной способности в различных диапазонах. С помощью мультиспектральных изображений можно решать задачи идентификации типов растительности и их состояния - ведь различное состояние листовой поверхности (обезвоженность, недостаток элементов питания, вирусная деграция, поражённость от вредителей и заболевания и т.п.). Одним из самых популярных вегетационных индексов является NDVI [2]. NDVI (Normalized Difference Vegetation Index) – показатель количества фотосинтетической активной биомассы на земной поверхности (оценка интенсивности вегетации растений). Для расчёта индекса NDVI необходимы данные с двух каналов на мультиспектральной камере, улавливающих отраженный спектр в красном и ближнем инфракрасном диапазонах. Формула вычисления NDVI:

$$NDVI = \frac{(NIR - Red)}{(NIR + Red)}$$

где NIR – значение инфракрасного диапазона, Red – красного диапазона.

Использование вегетационных индексов для анализа состояния полей является достаточно популярным методом, но перед получением данных мониторинга полей для анализа требуется провести ряд этапов:

1. Планирование маршрута и организация полета БПЛА;
2. Обработка изображений с помощью дополнительных датчиков, в том числе проведение радиометрической коррекции;
3. Предобработка исходных изображений;

4. Создание ортофотоплана, путем склейки исходных изображений;
5. Сегментация изображения для отделения полей от прочих объектов;
6. Построение карты индексов с помощью мультиспектральных каналов камеры.

Исходные снимки плохо подходят для создания ортофотоплана, поскольку при склейке будут видны артефакты, а также достоверность значений во всех каналах изображения будет стоять под вопросом. К факторам, которые могут исказить исходные изображения, могут относиться:

- тени от облаков;
- погодные условия;
- температура;
- время дня и дата.

Влияние каждого фактора можно нивелировать с помощью алгоритмов и корректировкой организации съемки. К примеру, есть ряд алгоритмов для детекции и компенсации теней от объектов. Они делятся на пороговые методы и на методы классификации.

Методы, основанные на порогах, часто использовали либо предопределенные пороговые значения, либо адаптивные пороговые значения для пометки облаков на обработанных изображениях. Все пороговые методы имеют ряд недостатков – необходима точная настройка, так как пороги могут сильно меняться из-за локаций, камеры, и присутствует верхний порог по точности. Классификация изображений, основанная на извлечении признаков и методах машинного обучения, также является эффективным методом обнаружения облаков и их теней. Как правило, методы машинного обучения дают более точные результаты обнаружения облаков/теней, чем пороговые методы. Но следует учесть необходимость в обучении модели для конкретных условий съемки. В последние годы, часто встречается использование глубоких нейронных сетей, которые дают лучшие показатели точности классификации. На данный момент одним из лучших решений является многомасштабная глубокая нейронная сеть 3D-CNN [3], которая достигает около 96% точности для детекции облаков и около 96% точности для детекции теней облаков. Данная архитектура глубокой нейронной сети принимает на вход все мультиспектральные каналы изображения, что позволяет отличать облака от схожих объектов, таких как снег или белые здания.

Литература

1. Гатаулина Г. Г., Заренкова Н. В., Шитикова А. В. «О системном подходе к анализу формирования урожая зернобобовых культур» // Современное состояние и перспективы исследований сои. – 2020. – с. 119-131.
2. Hassan M. A. et al. A rapid monitoring of NDVI across the wheat growth cycle for grain yield prediction using a multi-spectral UAV platform // Plant science. – Vol. 282, 2019. pp. 95-103.
3. Chen Y. et al. Cloud and cloud shadow detection based on multiscale 3D-CNN for high resolution multispectral imagery // IEEE Access. – Vol. 8, 2020. pp. 16505-16516.