

ПОСТРОЕНИЕ КАРТ СЕЛЬСКОХОЗЯЙСТВЕННЫХ ПОЛЕЙ ПО АЭРОФОТОСНИМКАМ РАЗЛИЧНОГО СПЕКТРАЛЬНОГО ДИАПАЗОНА ДЛЯ СИСТЕМ ТОЧНОГО ЗЕМЛЕДЕЛИЯ

В.В. Ганченко, А.А. Дудкин, Е.Е. Марушко
Объединенный институт проблем информатики НАН Беларуси, Минск

Рассмотрены информативные признаки состояния растительности. Определены алгоритм построения нечетких дескрипторов для составления карт посевов по многоспектральным изображениям, алгоритм обучения нейросетевой модели распознавания, алгоритм составления карт посевов. Представлены экспериментальные результаты применения предложенных алгоритмов.

Введение

Точное земледелие является одним из базовых элементов ресурсосберегающих технологий в сельском хозяйстве. Оно основано на применении геоинформационных технологий. Для их реализаций необходимы программно-технические системы, позволяющие выявить неоднородность поля (приборы дистанционного зондирования сельскохозяйственных посевов, программное обеспечение обработки данных и технические средства выполнения технологических операций) в соответствии с потребностями посевов.

Постоянный мониторинг состояния растительности невозможен без использования методов анализа состояния растительного покрова сельскохозяйственных полей по аэрофотоснимкам, которые являются основой для построения точных карт состояния растений и почв, автоматизированного выделения и идентификации различных типов сельскохозяйственных культур, оценки их развития и созревания, контроля возникновения и развития заболеваний растений.

Анализ состояния растительности базируется на решении двух основных задач: идентификации – выделения на исходных аэрофотоснимках однородных по некоторым признакам объектов, и классификации. Их решение осложняется нечеткостью признаков, а также наличием мешающего фона, влиянием облачности и теней. И в данном случае применение нейросетевых методов и методов нечеткой логики позволит повысить точность распознавания.

Дистанционные методы мониторинга сельскохозяйственных полей дают возможность оперативно выявить участки полей, пораженные болезнью. Выявление заболевания на ранних стадиях развития значительно сокращают затраты труда и средств [1].

1 Метод

Решение ряда задач, связанных с контролем состояния растительности сельскохозяйственного назначения, может основываться на совмещении различных информативных признаков состояния растительности.

1.1 Вегетационные индексы

Важными информативными признаками, используемыми для оценки состояния растительности на основе многоспектральных изображений, являются различные вегетационные индексы.

Нормализованный относительный индекс биомассы NDVI – показатель количества фотосинтетически активной биомассы на земной поверхности. Для расчета индекса используются значения спектральной яркости в красном и ближнем инфракрасном [2]. Индекс предназначен для обнаружения и оценки интенсивности вегетации растений. NDVI рассчитывается по снимкам высокого, среднего и низкого пространственного разрешения, имеющим спектральные каналы в красном (от 0,55 до 0,75 мкм) и ближнем инфракрасном диапазоне спектра (от 0,75 до 1 мкм). Индекс может принимать значения от -1 до 1. Для растительности индекс NDVI принимает положительные значения, чем больше объем фитомассы, тем выше значения индекса.

Усовершенствованный вегетационный индекс EVI – улучшенный индекс биомассы растений, представляющий собой модификацию нормализованного относительного индекса растительности NDVI, при оценке состояния растений имеет преимущества, поскольку влияние почвы и атмосферы в значениях данного индекса минимизировано [3].

Индекс листовой поверхности LAI – выраженная в квадратных сантиметрах (см^2) площадь освещенных листьев на каждый квадратный сантиметр поверхности почвы [4]. Индекс вычисляется на основе NDVI.

1.2 Цветовые информативные признаки

Помимо вегетативных индексов можно выделить и цветовые характеристики растительности: цветовые диапазоны и цветовые гистограммы для растительности в различном состоянии.

Различные состояния растительности характеризуются различным цветом (здоровая растительность – зеленая, пораженная – желтая или бурая), который может быть получен на основании анализа изображений. Для снижения влияния условий освещения следует использовать цветовое пространство HSV вместо RGB. При этом цвет растительности характеризуется параметрами Hue и Saturation.

1.3 Текстурные и фрактальные информативные признаки

Текстурные (признаки Харалика [5]) и фрактальные (размерность [6, 7]) характеристики позволяют, за счет построения оценок характеристик небольших участков изображений, оценить плотность растительности на том или ином участке поля.

Текстурные характеристики выражают разность значений интенсивности соседних пикселей изображения, при этом значения оценок этой разности отличаются для различных типов подстилающей

поверхности. Вычисление текстурных характеристик снимка выполняется в так называемом «скользящем окне». Размер «скользящего окна» – 4×4 пикселя.

Суть вычисления фрактальной сигнатуры состоит в том, что квантованные значения интенсивности двумерного сигнала должны располагаться между двумя функциями, называемыми верхней и нижней поверхностями. Вычисление их также выполняется для «скользящего окна».

1.4 Построение нечетких дескрипторов

Построение дескрипторов объектов основано на использовании комбинированных информативных признаков многоспектральных изображений представленных выше.

В данной работе представлен алгоритм построения карт посевов с предварительной экспертной разметкой обучающего набора данных, по которому производится формирование средних значений для классов объектов и обучения нейросетевой модели. Разметка набора данных заключается в назначении каждому пикселю изображения сельскохозяйственных полей идентификатора соответствующего классу объекта в данном пикселе.

Алгоритм построения нечетких дескрипторов для составления карт посевов состоит из следующих шагов.

Шаг 1. Вычисление нормализованного относительного индекса биомассы NDVI.

Шаг 2. Вычисление текстурных характеристик Харалика (Contrast, Entropy) для каждого из каналов мультиспектрального изображения поля.

Шаг 3. Вычисление значения фрактальной размерности для различного масштаба.

Шаг 4. Построение карты плотности биомассы для значений NDVI на основе диапазонов индекса.

Шаг 5. Построение карты плотности биомассы на основе текстурных характеристик Харалика.

Шаг 6. Построение карты плотности биомассы на основе фрактальных размерностей разного масштаба.

Шаг 7. Построение по полученным значениям карты посевов и объединение их операцией логического "ИЛИ".

Шаг 8. Вычисление среднего значения характеристик и информативных признаков для каждого класса по изображениям обучающего набора данных.

Шаг 9. Вычисление расстояния значений характеристик и признаков объектов до среднего значения каждого класса.

Шаг 10. Нормализация значения расстояний.

Карты нормализованных расстояний и являются нечеткими дескрипторами. В результате выполнения шагов алгоритма получена карта состояния посевов, где состояние описывается комбинацией индексов и интерпретируется в соответствии с задаваемыми интервалами значений индексов. В зависимости от требований конкретной решаемой задачи некоторые индексы, вычисляемые на шагах 1 - 5, могут быть исключены из карты состояния.

Комбинация информативных признаков и нечетких дескрипторов может использоваться для обучения нейронной сети (НС) с целью повышения точности построения карт полей.

Алгоритм обучения нейросетевой модели распознавания состоит из следующих шагов.

Шаг 1. Вычисление информационных признаков для каждого из каналов мультиспектрального изображений обучающего набора данных.

Шаг 2. Формирование нечетких дескрипторов.

Шаг 3. Формирование пар <входной вектор, идентификатор класса> для каждого пикселя изображений обучающего набора данных.

Шаг 4. Определение архитектуры НС.

Шаг 5. Обучение НС.

Обученная НС может использоваться для пиксельного распознавания изображений сельскохозяйственных полей. Дополнительно точность идентификации объектов может быть повышена с использованием ансамбля НС (АНС) [9-11].

В качестве нейросетевой модели выбрана многослойная НС с одним скрытым слоем с нелинейной функцией активации *гиперболический тангенс*.

Размер входного слоя N_I для НС определяется размерностью нечеткого дескриптора объекта и числом характеристик и информативных признаков.

Размер скрытого слоя N_H для НС определяется при проведении эксперимента с использованием следующей процедуры поиска субоптимального размера скрытого слоя одиночной НС.

Шаг 1. Определение интервала поиска размера скрытого слоя.

Шаг 2. Обучение 10 НС с размером скрытого слоя, равным текущему на интервале.

Шаг 3. Формирование из 10 НС АНС.

Шаг 4. Оценка эффективности АНС.

Шаг 5. Пока не конец интервала поиска, переход к следующему элементу интервала.

Шаг 6. Выбор АНС с лучшей эффективностью на интервале поиска, размер скрытого слоя элемента АНС будет подходящим решением.

Эффективность оценивается с использованием матрицы неточностей (confusion matrix). С ее помощью можно рассчитать такие метрики, как точность (*Precision*), полнота (*Recall*) и *F*-мера.

2 Проведение эксперимента

2.1 Входные данные

В качестве тестовых данных использовался набор мультиспектральных изображений «Assessing crops (multispectral/eBee SQ)» [8]. Изображения были собраны в Швейцарии беспилотным летательным аппаратом «eBee SQ» с камерой Sequoia.

Технические данные:

- разрешение 0,1213 м;
- охват 2,57 км²;
- система координат WGS84;
- высота полета 120 м.

Набор данных включает 5260 изображений в формате tiff. Размер 13 ГиБ. Включает зелёный канал, красный канал, ближний инфракрасный канал, канал «красного края». Каждое мультиспектральное изображение представлено в виде изображений отдельных каналов.

Ближний инфракрасный, видимый красный и видимые зелёный каналы при отображении соответственно на красную, зелёную и синюю области RGB-изображения представляют псевдоцветное изображение, которое называется стандартным цветным инфракрасным композитом. В данном представлении разделение растительности представляется наиболее наглядным.

В изображении композита области воды очень темные, а зеленая растительность выглядит красной. Цветной инфракрасный композит представлен на рисунке 1а.



Рисунок 1 – Входные данные: а) стандартный цветной инфракрасный композит, б) размеченные данные для классов «здоровая растительность» и «слабая растительность»

Размеченные данные для классов «здоровая растительность» и «слабая растительность» представлены на рисунке 1б. Наиболее значимым индексом является NDVI, который представлен на рисунке 2.



Рисунок 2 – NDVI исходного изображения
 На основе совместных характеристик строилась карта нечеткой принадлежности к классу «здо-

ровая растительность». Карта нечеткой принадлежности представлена на рисунке 3. Как видно из рисунка, кроме сельскохозяйственной растительности, также отмечаются растительность лесная.

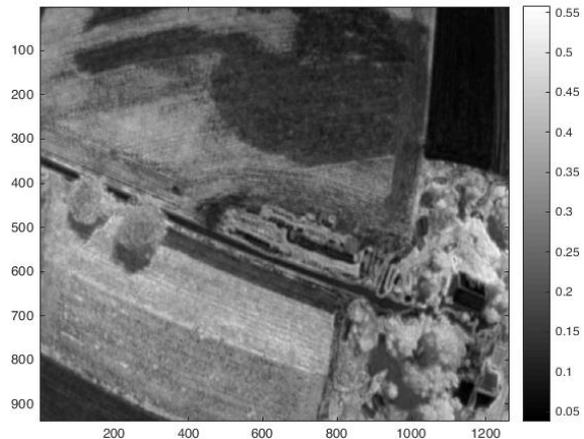


Рисунок 3 – Карта нечеткой принадлежности к классу «здоровая растительность»

Данная карта совместно с вегетационными индексами и характеристиками вариативности обрабатывалась нейросетевой моделью, которая выдает четкое решение принадлежности к классам «здоровая растительность», «слабая растительность» и «другие объекты». Размер скрытого слоя N_H для НС был равен 400 нейронов.

Результат работы модели представлен на рисунке 4.

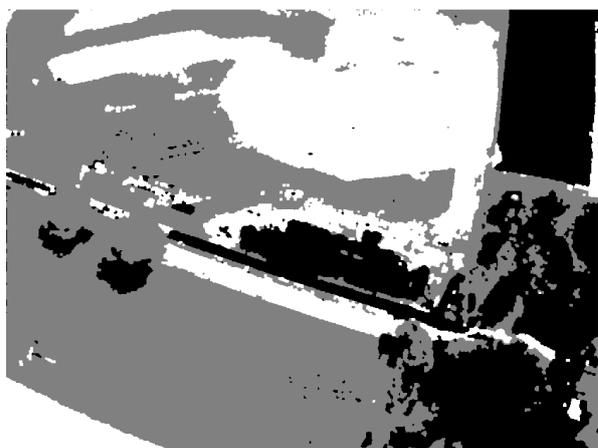


Рисунок 4 – Результат работы модели

Для определения точности распознавания полей использовался коэффициент Жаккара, который вычисляется по следующей формуле:

$$J(A, B) = \frac{|A \cup B|}{|A| + |B| + |A \cap B|}, \quad (1)$$

где A – множество точек класса из размеченного изображения;

B – множество точек класса из сформированного моделью изображения.

Результаты представлены в таблице 1.

Таблица 1 – Оценка точности построения карты сельскохозяйственных полей

Метод	Коэффициент Жаккара
Построение на основе NDVI	0,66
Построение на основе NDVI + текстурные и фрактальные характеристики	0,67
Предложенная модель	0,86

Как видно из таблицы, наибольшую информативность относительно наличия растительного покрова показывает индекс NDVI на основе близкого инфракрасного спектрального диапазона. Текстурные и фрактальные характеристики не показали значительного улучшения при совмещении с NDVI.

Использование нейросетевой модели и нечетких дескрипторов позволяет более точно формировать контуры распознаваемых объектов.

Заключение

Метод комбинирования информативных признаков многоспектральных изображений для оценки состояния сельскохозяйственной растительности строится на совместном использовании данных видимого диапазона и ряда вегетационных индексов, вычисляемых по изображениям в видимой и инфракрасной областях спектра, а также цветовых и текстурных характеристик.

Алгоритмы построения комбинированных информативных признаков многоспектральных изображений, основанные на совместном использовании ряда вегетационных индексов, вычисляемых на базе видимого спектра и ближнего инфракрасного спектра, цветовых и текстурных характеристик изображений предназначены для оценки состояния сельскохозяйственной растительности и подготовки различных тематических карт для задач точного земледелия.

Алгоритм построения дескрипторов объектов, характеризующихся вариативностью информационных признаков может использоваться для сегментации и распознавания изображений в системах мониторинга состояния и прогнозирования урожайности сельскохозяйственной растительности.

Использование нейросетевой модели и нечетких дескрипторов позволяет повысить точность дистанционных методов мониторинга сельскохозяйственных полей по сравнению с методами на основе только вегетационных индексов и характеристик вариативности.

Список литературы

- 1 Беляев, Б.И. Оптическое дистанционное зондирование / Б.И. Беляев, Л.В. Катковский. – Минск: БГУ, 2006. – 455 с.
- 2 Rouse, J.W. Monitoring vegetation systems in the Great Plains with ERTS / J.W. Rouse [at al.] // In 3rd ERTS Symposium, NASA SP-351 I. – 1973. – PP. 309–317.
- 3 Huete, A. R. A comparison of vegetation indices over a global set of TM images for EOS-MODIS / A. R. Huete [at al.] // Remote Sensing of Environment. – 59. – P. 440 – 451.
- 4 Sang-II, Na. Estimating Leaf Area Index of Paddy Rice from RapidEye Imagery to Assess Evapotranspiration in Korean Paddy Fields / Na, Sang-II [at al.] // Korean Journal of Soil Science and Fertilizer. – Volume 46, Issue 4. – 2013. – PP.245-252.

5 Haralick R.M. Textural Features for Image Classification / R.M. Haralick, K. Shanmugam, I. Dinstein // IEEE Transactions on Systems, Man and Cybernetics. – 1973. – № 6. – P. 610-621.

6 Потапов, А.А. Фракталы в радиофизике и радиолокации / А.А. Потапов. – М.: Логос, 2002. – 664 с.

7 Нигматуллин, Р.Р. Фракталы, дробные операторы и дробная кинетика в диэлектрической спектроскопии и волновых процессах / Р.Р. Нигматуллин, А.А. Потапов // Физика волновых процессов и радиотехнические системы. – 2007. – Т. 10, № 3. – С. 30–49.

8 Sensefly Datasets [Электронный ресурс]. – Режим доступа: <https://www.sensefly.com/education/datasets/>. – Дата доступа: 04.01.2018.

9 Parikh, D. An ensemble-based incremental learning approach to data fusion / D. Parikh, R. Polikar // IEEE Transactions on Systems, Man and Cybernetics – Part B: Cybernetics. – 2007. – Vol. 37. – Iss. 2. – P. 437–450.

10 Marushko, Y. Using Ensembles of Neural Networks with Different Scales of Input Data for the Analysis of Telemetry Data / Y. Marushko // Proc. of the XV Intern. PhD Workshop OWD 2013 (Wisla, 19–22 Oct. 2013). – Gliwice: Silesian University of Technology, 2013. – P. 386–391.

11 Neural network ensemble operators for time series forecasting / Nikolaos Kourentzes [et al.] // Expert Systems with Applications. – July 2014. – Vol.41, Iss. 9. – ISSN: 0957-4174. – P. 4235–4244.

Исследование выполнено при финансовой поддержке БРФФИ (проект № Ф16МС-012).