

**ПЕРСПЕКТИВЫ КОМПЛЕКСНОЙ ОЦЕНКИ ПОЧВЕННОГО
ПЛОДОРОДИЯ НА ОСНОВЕ ИНТЕРПРЕТАЦИИ ДАННЫХ
ДИСТАНЦИОННОГО ЗОНДИРОВАНИЯ ЗЕМЛИ****В.В. Якушев, чл.-корр. РАН,****Санкт-Петербургский Государственный аграрный университет (СПбГАУ)****Санкт-Петербург, Пушкин, Петербургское шоссе, 2, 196605, Российская Федерация****E-mail: mail@agrophys.com**

Показана актуальность развития дистанционных методов оценки состояния сельскохозяйственных угодий на основе спутниковых и аэрофотоснимков, полученных в различных спектральных диапазонах. Даны описание математического аппарата, используемого при обработке данных ретроспективного анализа доступных спутниковых снимков за несколько предшествующих лет, и выявление на их основе различных по плодородию участков. Приведены результаты кластеризации данных на примере пространственно-ориентированных карт продуктивности, полученных с помощью ретроспективного анализа снимков сельскохозяйственного поля в Краснодарском крае (Усть-Лабинский район).

Ключевые слова: плодородие, дистанционные методы оценки, точное земледелие, пространственно-ориентированные карты, ретроспективный анализ, статистическая обработка данных.

Для цитирования: Якушев В.В. Перспективы комплексной оценки почвенного плодородия на основе интерпретации данных дистанционного зондирования Земли // Плодородие. – 2024. – №5. – С. 5-8.

DOI: 10.25680/S19948603.2024.140.01.

Развитие дистанционных методов оценки состояния сельскохозяйственных посевов и методов математической обработки больших массивов данных на основе дистанционного зондирования Земли, получаемых с беспилотных летательных аппаратов (БПЛА) и космических аппаратов (КА), оснащенных мульти- и гиперспектральными камерами, а также сопряженных с ними наземных агрофизических, агрохимических и биологических измерений актуально для перехода сельского хозяйства на новый технологический уклад, важной составляющей которого является точное земледелие (ТЗ). Актуальность этого направления подтверждается результатами состоявшегося в 2023 г. форума "Сильные идеи для нового времени". В.В. Путин отметил, что "Цифровые платформы позволяют развивать беспилотные системы и начать широкое применение точного земледелия". Для сельского хозяйства важно "создание адаптивных систем земледелия и агротехнологий нового поколения на основе цифровизации". Актуально так же применение математического моделирования, методов статистического моделирования и анализа данных в медицине и сельском хозяйстве.

Методы и средства получения, обработки и интерпретации данных дистанционного зондирования (ДДЗ) обеспечивают сплошной и непрерывный мониторинг системы «посев – среда его обитания» с охватом одновременно значительных площадей сельскохозяйственных земель. Огромные размеры этих площадей в нашей стране, а также возрастающая доступность аэрокосмических средств предопределяют целесообразность более широкого использования ДДЗ в информационном обеспечении адаптивно-ландшафтных систем земледелия, включая производство растениеводческой продукции с использованием технологий точного земледелия [1, 2]. Один из основных элементов точного земледелия –

дифференцированное внесение минеральных удобрений, которое основано на данных агрохимического обследования сельскохозяйственных полей с геопространственной привязкой или ДДЗ, характеризующих состояние посева по обеспеченности азотом (обеспеченность калием и фосфором дистанционно пока определять не удастся). Однако при планировании агротехнических мероприятий по внесению минеральных удобрений не всегда имеются актуальные данные агрохимического обследования или аэрофотоснимки, или они могут быть не в цифровом виде и без привязки к координатам. Важным интегральным показателем плодородия почвы можно считать, на наш взгляд, карты урожайности, которые получают посредством систем картографирования, установленных на зерноуборочных комбайнах. Имея такие карты урожайности за несколько лет, можно с большой степенью вероятности определять зоны плодородия внутри сельскохозяйственного поля. Но и в этом компоненте оснащенность сельскохозяйственных предприятий России такими системами составляет пока еще не более 5% (рис. 1) [6].

В последнее время активно развиваются технологии ретроспективного анализа доступных спутниковых снимков за несколько предшествующих лет и выявление на их основе различных по плодородию участков поля. В нашем исследовании проведены оценка корреляции между картами урожайности и картами продуктивности, полученными на основе ретроспективного анализа спутниковых снимков, а также кластеризация поля на основе этих данных.

Цель исследования – расширить математический аппарат, применяемый для обработки данных дистанционного зондирования Земли, полученных при ретроспективном анализе снимков с космических аппаратов, а также оценить значимость полученных данных.




Рис.1. Оценка внедрения элементов точного земледелия в России

Методика. Исследования проводились с использованием пространственно-ориентированных карт продуктивности, полученных с помощью ретроспективного анализа снимков сельскохозяйственного поля в Краснодарском крае (Усть-Лабинский район). Почва – чернозём обыкновенный. Для построения карт продуктивности использовались ДДЗ, полученные с космического спутника Sentinel-2. Анализ проводили за четыре года путем построения зависимостей от сочетания нескольких индексов вегетации и индексов влажности. Расчет производили для элементарного участка поля (10×10 м). Спектральные данные для анализа взяты с Sentinel-hub.

Для решения задачи кластеризации использовали подход на основе разделения смеси вероятностных распределений, в котором отдельные компоненты моделируются нормальными распределениями с различными параметрами. При этом математическое ожидание соответствует средней продуктивности с участка внутри зоны однородности. Веса компонент указывают относительный размер соответствующего кластера (правильнее - относительную долю участков, отнесенных к данной компоненте смеси).

Таким образом, общая математическая модель смеси распределений, характеризующая урожайность на поле, имеет вид:

$$f(x) = \sum_{j=1}^k p_j f(x, \theta_j),$$

где k – число кластеров (зон однородности); p_j – удельный вес зоны однородности (относительная доля наблюдений из данной зоны по отношению к общему числу наблюдений); $f(x, \theta_j)$ – плотность нормального распределения (описывает закон распределения

урожайности x внутри зоны однородности с номером j); $\theta_j = (a_j, \sigma_j^2)$ – неизвестные параметры (математическое ожидание и дисперсия) распределения компоненты с номером j [3].

В статистической литературе имеются разнообразные алгоритмы решения задачи разделения смеси распределений, в целом можно сказать, что это довольно трудная статистическая задача, связанная с решением сложных вычислительных задач. Нами был выбран алгоритм адаптивного вероятностного обучения, представляющий собой некоторую модификацию алгоритма SEM [4]. Важным достоинством данной методики кластеризации поля является отсутствие каких – либо априорных предположений о числе однородных зон (задается лишь верхняя граница числа однородных зон) и их локализации на поле. Мы выбираем заведомо максимальное количество зон и не делаем никаких предположений о том, где они могут находиться на поле. В результате объективного анализа продуктивности отдельных участков удастся определить количество зон и их локализацию. Для реализации алгоритма использовался язык программирования R, созданный специально для статистического анализа данных. Для работы с геопространственными данными нами использовалась Quantum GIS – свободная кроссплатформенная геоинформационная система.

Результаты и их обсуждение. В результате ретроспективного анализа спутниковых снимков за 4 года была получена карта поля, площадью 83 га, где были выделены зоны с различной продуктивностью по биомассе (рис. 2).

Используя алгоритм адаптивного вероятностного обучения, были обработаны данные по продуктивности поля.

Типичная конечномерная модель смеси представляет собой модель, состоящую из следующих компонентов:

- n случайных величин, каждая из которых распределена в соответствии со смесью из k компонентов, причем компоненты принадлежат к одному и тому же параметрическому семейству распределений, но с разными параметрами;
- набор из k весов смеси, которые представляют собой вероятности, в сумме равные 1;
- набор из g параметров, каждый из которых определяет параметр соответствующего компонента смеси.

Во многих случаях каждый "параметр" на самом деле представляет собой набор параметров. Например, если компоненты смеси представляют собой нормальное распределение, для каждого компонента будут среднее и дисперсия [5].

Далее анализируем параметр BIC (Schwarz's Bayesian criterion), показатель качества модели (табл.).

Выбираем модель с наименьшим значением BIC:

$$BIC = m \ln n - 2 \times \log \text{Likelihood} (X_1, \dots, X_n, k, p_1, \dots, p_{k-1}, a_1, \dots, a_k, \sigma_1, \dots, \sigma_k).$$




Рис.2. Карта продуктивности поля

| Показатели качества моделей кластеризации | | | | | | |
|---|---|----------|----------|-------------|-----------------------------------|--------------------|
| Число кластеров | Значение логарифма функции правдоподобия log-likelihood | BIC | ICL | Вероятность | Число элементов в каждом кластере | Границы интервалов |
| 5 | 5757.921 | 11390.14 | 3863.255 | 0,09721271 | 611 | мин до 0,51 |
| | | | | 0,33350695 | 2024 | 0,52 до 0,72 |
| | | | | 0,21625408 | 2066 | 0,73 до 0,79 |
| | | | | 0,16848754 | 1805 | 0,80 до 0,84 |
| | | | | 0,18453872 | 1425 | 0,85 до Макс |
| 4 | 5754.461 | 11410.16 | 4216.436 | 0,09712437 | 612 | Мин до 0,51 |
| | | | | 0,36555685 | 2291 | 0,52 до 0,74 |
| | | | | 0,30563046 | 2986 | 0,75 до 0,82 |
| | | | | 0,23168832 | 2042 | 0,83 до Макс |
| 3 | 5751.89 | 11431.95 | 6967.266 | 0,3812673 | 600 | мин до 0,51 |
| | | | | 0,7138074 | 2279 | 0,52 до 0,73 |
| | | | | 0,8138560 | 5052 | 0,74 до макс |

В результате обработки данных видно, что в рассматриваемом случае оптимально использовать 5 кластеров

продуктивности. Графически результаты кластеризации представлены на рисунках 3 и 4.




Рис. 3. Кластеризация данных




Рис. 4. Кластеризация продуктивности по полю

Полученные результаты мы сравнили с картой урожайности по этому же полю, полученную в предшествующий период. С помощью коэффициента корреляции Пирсона, вычисленного между уровнем урожайности и уровнем продуктивности, выявлена прямая линейная зависимость между этими двумя важными показателями. Значимость коэффициента корреляции проверена с использованием теста Стьюдента. При заданном уровне значимости 0,95 $p\text{-value} < 2,2 \cdot 10^{-16}$, что подтверждает предположение о высоком уровне значимости коэффициента корреляции и позволяет, на наш взгляд, использовать показатель продуктивности для сравнительной оценки различных участков поля по уровню плодородия почвы.

Выводы. Результат обработки данных ретроанализа представлен на рисунок 3. Поле разбито на 5 кластеров продуктивности, которая с некоторой вероятностью характеризует плодородие почвы на каждом элементарном участке поля (размер участка 10 x 10 м). Эти данные могут быть использованы для оптимизации создания карт-заданий на дифференцированное внесение минеральных удобрений дополняя информацию, полученную при агрохимическом обследовании поля. Представленный подход базируется на анализе оптических измерений посева (спутниковых и аэрофотоснимках), то есть на анализе растений. Но если почву можно рассматривать как функцию, то растение – его производная, а по

производной можно судить и о самой функции. Безусловно данный подход требует дополнительных исследований и уточнений, но тем не менее он имеет, как нам кажется, перспективу практического применения при внедрении технологий дифференцированного внесения агрохимикатов и как дополнительный показатель внутрипольной вариативности плодородия почвы.

Литература

1. Chlingaryan A., Sukkarieh S., Whelan B. Machine learning approaches for crop yield prediction and nitrogen status estimation in precision agriculture: A review // *Computers and Electronics in Agriculture*. 2018. V. 151. P. 61–69. <https://doi.org/10.1016/j.compag.2018.05.012>.
2. Якушев В.П., Якушев В.В., Блохина С.Ю., Блохин Ю.И., Петрушин А.Ф., Матвеев Д.А. Перспективы использования гиперспектральной информации в задачах управления азотным режимом посевов зерновых культур // *Современные проблемы дистанционного зондирования Земли из космоса*. 2024. Т. 21. № 3. С. 188–203. DOI: 10.21046/2070-7401-2024-21-3-188-203
3. Якушев В.В. Точное земледелие: теория и практика. СПб.: АФИ, 2016. 364 с.
4. Сидорова В.А., Красильников П.В. Почвенно-географическая интерпретация пространственной вариативности химических и физических свойств поверхностных горизонтов почв степной зоны // *Почвоведение*. 2007. № 4. С. 1–11.
5. Айвазян С.А. и др. Прикладная статистика. Классификация и снижение размерности: справочное издание. М.: Финансы и статистика, 1989.
6. Труфляк Е.В., Курченко Н.Ю., Оценка готовности регионов к внедрению цифровых технологий в сельское хозяйство, *Вестник Самарского государственного экономического университета*. 2019. № 10 (180). С. 22–26.

PROSPECTS FOR A COMPREHENSIVE ASSESSMENT OF SOIL FERTILITY BASED ON THE INTERPRETATION OF REMOTE SENSING DATA

Yakushev V.V.

Saint Petersburg State Agrarian University (SPbSAU) Saint Petersburg,
Pushkin, Peterburgskoe shosse 2, 196605, Russian Federation, E-mail: mail@agrophys.com

The article shows the relevance of the development of remote methods for assessing the condition of agricultural land based on satellite and aerial photographs obtained in various spectral ranges. The description of the mathematical apparatus used in the processing of data from a retrospective analysis of available satellite images for several previous years and the identification of different fertility sites based on them is given. The results of data clustering are presented using the example of spatially oriented productivity maps obtained using a retrospective analysis of images of an agricultural field in the Krasnodar Territory, Ust-Labinsk district.

Keywords: agricultural land, interpretation, clustering of data, spectral ranges.