

# Потенциальные возможности дистанционного детектирования параметров плодородия пахотных почв на основе спектральной отражательной способности их поверхности и данных о её температуре

Е. Ю. Прудникова, И. Ю. Савин

Почвенный институт имени В. В. Докучаева, Москва, 119017, Россия  
E-mails: prudnikova\_eyu@esoil.ru, savin\_iyu@esoil.ru

Спутниковая оценка свойств пахотных почв основана на связи между ними и спектральной отражательной способностью их поверхности. Детектирование параметров плодородия пахотных почв по дистанционным данным осложняется тем, что не все из этих параметров оказывают непосредственное влияние на спектральную отражательную способность почв. Рассматривается информативность различных наборов спектральных параметров оптического и теплового диапазонов для детектирования параметров плодородия пахотных почв на примере тестового поля с выщелоченными чернозёмами, расположенного в Серебряно-Прудском р-не Московской обл. При этом анализируется как открытая поверхность почв, так и посевы. Наилучшие модели при применении наиболее часто используемых спектральных индексов и отношений, рассчитываемых на основе данных оптического диапазона ( $R_{cv}^2$  — коэффициент детерминации по результатам кросс-валидации и RPIQ (англ. Ratio of Performance to Interquartile Range) — отношение межквартильного размаха к среднеквадратической ошибке предсказания), были получены для содержания органического вещества в почвах ( $R_{cv}^2 = 0,50$ , RPIQ = 1,84) и для массовой доли соединений фосфора ( $R_{cv}^2 = 0,49$ , RPIQ = 1,16). При совместном использовании данных оптического и теплового диапазона в некоторых случаях были получены модели более высокой точности и предсказательной способности. Для содержания органического вещества  $R_{cv}^2$  увеличился до 0,64, RPIQ — до 2,23, а для массовой доли соединений фосфора  $R_{cv}^2$  увеличился до 0,53, RPIQ — до 1,33. Привлечение дополнительного набора параметров в оптическом диапазоне, включающего 102 варианта комбинаций, позволило получить модели для всех анализируемых свойств с  $R_{cv}^2$  лучших моделей в районе 0,72–0,87 и RPIQ в районе 1,52–3,34. Кроме того, для ряда свойств удалось получить достоверные модели с высокой предсказательной способностью только после привлечения дополнительного набора параметров. В целом спектральная отражательная способность открытой поверхности почв оказалась более информативной, чем спектральная отражательная способность посевов озимой пшеницы в стадии всходов.

**Ключевые слова:** параметры плодородия пахотных почв, спектральная отражательная способность, оптический диапазон, температура поверхности почв, Sentinel-2

Одобрена к печати: 15.05.2024

DOI: 10.21046/2070-7401-2024-21-3-131-144

## Введение

В качестве базовых показателей актуального плодородия почв обычно используют такие свойства их пахотного горизонта как содержание гумуса, водородный показатель рН (англ. *potentia hydrogenii*), содержание доступных форм азота, фосфора, калия, обменных форм кальция и магния (Методические..., 2003). Информацию о данных свойствах почв получают в результате полевого отбора образцов почв с их последующим лабораторным анализом. Данный подход достаточно трудоёмкий, затратный и не позволяет точно отразить пространственное варьирование этих свойств на поле (Wetterlind et al., 2010). В последние годы ведутся исследования в области разработки бесконтактных (в том числе дистанционных) методов детектирования и мониторинга основных показателей плодородия пахотных почв (Прудникова и др., 2023), но надёжные результаты до сих пор не получены.

В большинстве случаев в основе бесконтактной оценки свойств почв лежат связи между этими свойствами и спектральной отражательной способностью (СОС) почв (Орлов и др.,

2001; Савин, Виндекер, 2021; Bellinaso et al., 2010; Fang et al., 2018; Lesaignoux et al., 2011). С этой точки зрения свойства почв можно условно поделить на две группы: 1) параметры, оказывающие непосредственное влияние на СОС (например, содержание органического вещества, минералогический состав почв, их оструктуренность); 2) параметры, не оказывающие непосредственного влияния на СОС (рН, содержание нитратов, доступного калия и фосфора, обменных катионов и др.). Детектирование параметров второй группы в таком случае возможно опосредовано при наличии связи между ними и параметрами первой группы (Demattê et al., 2017; Kuang et al., 2012; Mouazen, Kuang, 2016; Stenberg et al., 2010). При отсутствии такой связи возможности моделирования параметров второй группы ограничены. Как правило получают модели с низкой предсказательной способностью. Кроме того, для свойств из первой группы также не всегда удаётся получить модели с хорошей предсказательной способностью (Viscarra Rossel et al., 2006).

При наличии влияния на СОС, детектирование свойств почв возможно путём поиска информативных длин волн, участков спектра, каналов и/или их комбинаций в виде спектральных индексов (Prudnikova, Savin, 2021).

Использование комбинаций разных спектральных диапазонов (например, дополнение оптического диапазона средним инфракрасным (ИК) или тепловым) в некоторых случаях может позволить увеличить предсказательную способность моделей (Грубина и др., 2020; Soriano-Disla et al., 2014).

Одним из вариантов повышения точности предсказательных моделей может быть применение более сложных методов моделирования, включая методы машинного обучения (Bulan, Sitorus, 2022; Trontelj ml., Chambers, 2021).

Ещё одним способом может быть преобразование или расширение исходного набора длин волн/каналов до моделирования (Gholizadeh et al., 2018). В данном случае преимуществом становится возможность выбора вариантов преобразований (например, различных методов фильтрации исходных данных) и вариантов расчёта комбинаций, т.е. состав каждой комбинации и характер преобразований известен. Однако высокая сложность рассчитываемых комбинаций или преобразований при использовании данного способа является ограничивающим фактором.

Всё сказанное выше применимо, когда речь идёт об открытой поверхности почвы. Однако поверхность пахотных почв большую часть времени покрыта растительностью (посевы сельскохозяйственных культур). Наличие посевов может негативно влиять на возможность дистанционного детектирования параметров плодородия пахотных почв. В то же время состояние посевов может быть косвенным индикатором для отдельных свойств почв, а соответственно, потенциально улучшать возможности их детектирования (Кириянова, Савин, 2013).

Целью работы было оценить возможность детектирования параметров плодородия пахотных почв тестового участка на основе спектральной отражательной способности почв и посевов в оптическом и тепловом диапазоне с применением различных наборов спектральных параметров.

## Объект и методы исследования

### Объект исследования

Объектом исследования выступает спектральная отражательная способность поверхности почв тестового поля площадью 148,3 га, расположенного в Серебряно-Прудском р-не Московской обл. (рисунки, см. с. 133). Почвы тестового поля представлены выщелоченными чернозёмами.



Географическое положение тестового поля

## **Методы исследования**

### **Полевые исследования**

Полевой выезд был совершён 25.09.2020. В момент проведения полевых исследований на поле находились всходы озимой пшеницы. В 35 точках, выбранных случайным образом, были проведены измерения спектральной отражательной способности и температуры поверхности почв и посевов, а также осуществлён отбор смешанных образцов поверхностного слоя почв (0–5 см).

### **Анализ почвенных образцов**

В отобранных почвенных образцах определялись следующие параметры плодородия пахотных почв: pH в водной и солевой вытяжке (ГОСТ 26423-85, ГОСТ 26483-85), содержание органического вещества (ГОСТ 26213-84), содержание подвижного фосфора (ГОСТ Р 54650-2011), содержание обменного калия (по Масловой) (ГОСТ 26210-91), обменных катионов по Шолленбергеру (кальций и магний) (Руководство..., 1990), массовая доля азота нитратов (ГОСТ 26951-86), общий азот (ГОСТ 26107-84, п. 4.1). Анализы проводились Испытательным лабораторным центром Почвенного института имени В. В. Докучаева.

### **Получение спектральных кривых**

Для определения спектральной отражательной способности использовался полевой спектрометр HandHeld-2, работающий в диапазоне 325–1075 нм. Съёмка проводилась в ясную погоду в дневное время. В каждой точке опробования измерения проводились в пятикратной повторности. Для съёмки спектров открытой поверхности почвы прибор располагался на высоте 10–15 см, для съёмки спектральной отражательной способности посевов — на высоте 1,5 м над посевами.

### Измерение температуры почв и посевов с помощью тепловизора

Одновременно с отбором образцов почв проводилась съёмка поверхности почвы, посевов и стерни с высоты 130–150 см в трёхкратной повторности с использованием тепловизора FLIR VUE 512, работающего в ИК-диапазоне 7,5–13,5 мкм и позволившего получить данные о температуре поверхности в виде изображения размером около 50×50 см (<https://www.flir.com/products/vue-pro/>).

### Предобработка данных о спектральной отражательной способности

Предобработка данных о спектральной отражательной способности заключалась в усреднении, удалении зашумлённых участков и сглаживании спектральных кривых. Для каждой точки полевого обследования на основе пяти повторностей рассчитывалась средняя спектральная кривая. При этом из-за зашумлённости для анализа использовался только участок 350–900 нм, который захватывает видимый и ближний инфракрасный участки спектра. Сглаживание спектральных кривых осуществлялось фильтром Савицкого – Голея в программе R с помощью функции *savitzkyGolay* пакета *prospectr* (<https://cran.r-project.org/web/packages/prospectr/index.html>).

После сглаживания спектральная отражательная способность, измеренная в поле, была пересчитана в каналы Sentinel-2 ([https://sentinel.esa.int/documents/247904/685211/Sentinel-2\\_User\\_Handbook](https://sentinel.esa.int/documents/247904/685211/Sentinel-2_User_Handbook)) в программе R помощью пакета *prospectr* и функции *resample*. Пересчёт в каналы данного сенсора был проведён потому, что именно его данные в последнее время чаще всего используются при сельскохозяйственном мониторинге. После этого были рассчитаны два набора параметров: *набор 1* и *набор 2*. Параметры рассчитывались отдельно для почв и посевов. В состав *набора 1* вошли спектральные индексы, которые предполагают наличие прямого влияния свойств почвы на её СОС: BI (*англ.* Brightness Index), CI (*англ.* Colour Index), HI (*англ.* Hue Index), SI (*англ.* Saturation Index), RI (*англ.* Redness Index), BSCI (*англ.* Bi-Seasonal Forest Index, бисезонный индекс леса), GSI (*англ.* Grain Size Index), Crust, AVI (*англ.* Advanced vegetation index), NDVI (*англ.* Normalized Difference Vegetation Index — нормализованный разностный вегетационный индекс), SAVI (*англ.* Soil-Adjusted Vegetation Index, индекс растительности с коррекцией по почве), EVI2 (*англ.* Enhanced Vegetation Index, усовершенствованный вегетационный индекс), NDWI (*англ.* Normalized Difference Water Index, нормализованный разностный водный индекс) (Prudnikova, Savin, 2021). *Набор 2* включал различные комбинации спектральных параметров от простых вида  $(X \pm X)/X$  до более сложных вида  $(X \times X \pm X \times X \pm X \times X)/(X \pm X)$ . Всего было рассчитано 102 варианта комбинаций параметров.

Расчёт параметров для *набора 2* проводился в программе R. Для каждого варианта после расчёта удалялись дублирующие параметры (имеющие одинаковые значения) и параметры, у которых стандартное отклонение равно 0 (т. е. значения параметра одинаковы для всех точек).

### Предварительная обработка данных, полученных с помощью тепловизора

Тепловые изображения были загружены в пакет прикладных программ ILWIS (*англ.* Integrated Land and Water Information System) (<https://www.itc.nl/ilwis/download/ilwis33/>), с использованием которого для каждого изображения проводилось количественное определение температуры поверхности почвы, посевов и стерни. Определялось среднее значение, минимальная и максимальная величина и стандартное отклонение для каждого изображения.

### Моделирование параметров плодородия пахотных почв на основе параметров из набора 1 и параметров теплового диапазона

До моделирования из набора 1 исключались параметры, которые сильно скоррелированы друг с другом. Для этого рассчитывались коэффициенты корреляции между ними. И далее, если коэффициент корреляции между параметрами превышал 0,6, то один из параметров исключался из дальнейшего анализа. В итоге в анализ включались только те параметры, коэффициент корреляции между которыми не превышал 0,6. Отбор проводился в программе R с помощью пакета *usdm* и функции *vifcor* (<https://cran.r-project.org/web/packages/usdm/index.html>).

Ввиду небольшого числа параметров теплового диапазона предварительного отбора параметров до моделирования не проводилось.

Моделирование осуществлялось методом множественной линейной регрессии с помощью функции *lm* пакета *stats* программы R (<https://stat.ethz.ch/R-manual/R-devel/library/stats/html/stats-package.html>). Моделирование проводилось отдельно для отобранных параметров из набора 1, для параметров теплового диапазона, а также для комбинации параметров теплового диапазона и отобранных из набора 1 параметров, т. е. в следующих вариантах: 1) набор 1; 2) параметры теплового диапазона; 3) набор 1 + тепловой диапазон. Сначала для каждого варианта в модель включались все отобранные параметры, далее последовательно проводилось исключение параметров с уровнем значимости более 0,05 до тех пор, пока в модели не оставались только статистически значимые параметры. Данная процедура повторялась отдельно для почв и отдельно для посевов.

### Моделирование параметров плодородия пахотных почв на основе параметров из набора 2

Для отбора параметров из набора 2 использовался пакет *bigstep* программы R (<https://cran.rstudio.com/web/packages/bigstep/index.html>). Перед проведением отбора параметры делились на несколько групп, включающих в себя не более 5 млн параметров (оптимально 3 млн). После отбора результаты для всех групп объединялись.

Для каждого анализируемого свойства повторялась следующая последовательность операций. С помощью функции *prepare\_data* создавался объект класса *big*. Затем с помощью функции *reduce\_matrix*, которая рассчитывает коэффициенты корреляции между анализируемым свойством и рассчитанными параметрами, все параметры сортировались в таблице с учётом уровня значимости коэффициента корреляции (начиная с параметров с наименьшим значением уровня значимости). На этом этапе количество параметров не изменялось, для чего устанавливалось  $minpv = 1$ . Затем для выбора параметров для дальнейшего анализа использовалась функция *fast\_forward*. В качестве критерия отбора параметров использовался байесовский информационный критерий.

Далее анализировалась корреляция между отобранными параметрами и из набора исключались параметры, которые сильно скоррелированы друг с другом. Отбор проводился так же, как и в случае параметров из набора 1 с помощью функции *vifcor* пакета *usdm* в программе R. Пороговое значение коэффициента корреляции также устанавливалось равным 0,6.

Затем оставшиеся спектральные параметры включались в регрессионное моделирование в двух вариантах: без параметров теплового диапазона и с ними (набор, набор 2 + тепловой диапазон). Поскольку после отбора количество параметров для каждого свойства было в районе 40–50, то для подбора моделей использовалась функция *regsubsets* пакета *leaps* (<https://cran.r-project.org/web/packages/leaps/leaps.pdf>). Устанавливалось ограничение на максимальное количество параметров в модели, которое не могло превышать шести ( $nvmax = 6$ ).

Для каждого анализируемого свойства отдельно для почв и посевов получали набор регрессионных моделей, из которого выбиралась модель с наибольшим значением нормированного коэффициента детерминации.

### Оценка результатов моделирования

Для проверки полученных моделей проводилась процедура кросс-валидации. Выборка случайным образом делилась на 10 блоков, из которых один использовался для проверки, а остальные для обучения. Для устойчивости значений параметров оценки качества подобное деление повторялось 100 раз. Для кросс-валидации использовался пакет *caret* программы R (<https://cran.r-project.org/web/packages/caret/vignettes/caret.html>).

Основными параметрами для оценки качества моделей по результатам кросс-валидации стали следующие: коэффициент детерминации ( $R_{cv}^2$ ), среднеквадратическая ошибка предсказания (англ. Root Mean Squared Error of cross-validation —  $RMSE_{cv}$ ) и отношение межквартирного размаха (англ. Interquartile range — IQR) к среднеквадратической ошибке предсказания (англ. Ratio of Performance to InterQuartile distance — RPIQ).

### Результаты

Результаты лабораторного анализа образцов почв представлены в *табл. 1*. В отобранных образцах рН солевой вытяжки варьирует от 5,1 до 5,7, а рН водной вытяжки — от 6,3 до 6,9. Для данных свойств отмечается наименьший коэффициент вариации: 3,4 и 2,5 % соответственно. Содержание подвижного фосфора изменяется со 107,7 до 200,1 мг/кг с коэффициентом вариации 30,9 %. Содержание органического вещества изменяется в пределах от 4,1 до 6,9 %. Сильнее всего варьирует массовая доля азота нитратов — с 2 до 15,1 млн<sup>-1</sup> с коэффициентом вариации 42,8 %. Содержание обменного калия варьирует в пределах от 233,6 до 534,6 мг/кг с коэффициентом вариации 20,8 %. Содержание обменных катионов кальция изменяется от 22,1 до 54,5 ммоль/100 г с коэффициентом вариации 18,2 %, содержание обменных катионов магния — от 5,2 до 10,6 ммоль/100 г с коэффициентом вариации 17,6 %, а содержание общего азота — от 0,2 до 0,4 % с коэффициентом вариации 17,6 %.

Таблица 1. Параметры плодородия пахотных почв тестового поля

|                        | рН солевой вытяжки | Подвижный фосфор, мг/кг | Обменный калий, мг/кг | Органическое вещество, % | Обменные катионы по Шолленбергеру, ммоль/100 г |        | Массовая доля азота нитратов, млн <sup>-1</sup> | рН водной вытяжки | Общий азот, % |
|------------------------|--------------------|-------------------------|-----------------------|--------------------------|--|--------|---|-------------------|---------------|
|                        |                    |                         |                       |                          | кальций  | магний |   |                   |               |
| Среднее                | 5,4                | 200,1                   | 326,2                 | 5,6                      | 36,2   | 6,9    | 6,8   | 6,6               | 0,3           |
| Максимальное           | 5,7                | 343,4                   | 534,6                 | 6,9                      | 54,5   | 10,6   | 15,1  | 6,9               | 0,4           |
| Минимальное            | 5,1                | 107,7                   | 233,6                 | 4,1                      | 22,1   | 5,2    | 2,0   | 6,3               | 0,2           |
| Стандартное отклонение | 0,2                | 61,8                    | 67,8                  | 0,7                      | 6,6  | 1,2    | 2,9   | 0,2               | 0,1           |
| Коэффициент вариации   | 3,4                | 30,9                    | 20,8                  | 12,6                     | 18,2   | 17,6   | 42,8  | 2,5               | 17,6          |

При моделировании содержания подвижного фосфора использование данных *набора 1*, включающего только информацию о СОС почв в оптическом диапазоне, дало наихудший результат с  $R_{cv}^2 = 0,49$  и  $RPIQ = 1,16$  (*табл. 2*). Добавление к данному набору информации о температуре позволило немного повысить качество модели. При использовании параметров из *набора 2* существенно повысилась предсказательная способность модели. Применение *набора 2* на основе СОС посевов дало лучший результат, чем использование *набора 1*, но сработало хуже, чем совместное использование данного набора с информацией о температуре. Наилучший результат получен при использовании *набора 2* на основе СОС почв в оптическом диапазоне с  $R_{cv}^2 = 0,80$  и  $RPIQ = 2,09$ . Регрессионное уравнение для лучшей модели представлено ниже:

$$\begin{aligned}
 phosph = & 246,86 + 8,73 \frac{b_2 b_7 - b_1 b_7}{b_6 b_7 - b_5 b_{8a}} + 5,69 \frac{b_2 b_6 - b_1 b_7}{b_4 b_7 - b_3 b_{8a}} - 1,25 \frac{b_1 b_3 + b_2 b_5}{b_4^2 - b_1 b_7} + \\
 & + 0,37 \frac{b_6 - 2b_2}{b_4 b_5 - b_2 b_{8a}} + 0,02 \frac{b_5 - 2b_4}{b_6 b_2 - b_1 b_7} + 0,47 \frac{b_6 - 2b_2}{b_4^2 - b_1 b_{8a}},
 \end{aligned}$$

где *phosph* — содержание подвижного фосфора,  $b_1, \dots, b_{8a}$  — спектральная отражательная способность поверхности почвы, пересчитанная в соответствующие каналы Sentinel-2.

В случае рН солевой вытяжки использование информации о температуре поверхности дало наихудший результат с  $R_{cv}^2 = 0,43$  и RPIQ = 1,71 (табл. 2). Чуть лучше оказалось качество модели, полученное при использовании набора 1 на основе СОС посевов. Совместное использование набора 1 на основе СОС почв и информации о температуре позволило повысить  $R_{cv}^2$  модели до 0,50, но при этом также увеличилась среднеквадратическая ошибка предсказания по результатам кросс-валидации, что привело к снижению RPIQ до 0,08. В то же время применение набора 2 на основе СОС почв позволило увеличить  $R_{cv}^2$  модели до 0,75, а RPIQ до 1,9. При использовании набора 2 на основе СОС посевов результат получился чуть лучше за счёт снижения среднеквадратической ошибки предсказания по результатам кросс-валидации, таким образом, RPIQ увеличился до 2,6. Совместное применение набора 2 на основе СОС почв и информации о температуре позволило получить наилучшую модель с  $R_{cv}^2 = 0,81$  и RPIQ = 2,60. Регрессионное уравнение для лучшей модели представлено ниже:

$$\begin{aligned}
 pH_s = & 7,72 - 6,88 \cdot 10^{-6} \frac{3b_4}{b_3 b_7 - b_2 b_{8a}} + 0,002 \frac{b_6}{b_6^2 - b_4 b_8} + \\
 & + 0,001 \frac{b_5}{b_4^2 - b_1 b_7} - 0,001 \frac{b_2^2 + b_4 b_7 + b_3 b_4}{b_4^2 - b_1 b_{8a}} - 0,09 T_{sav},
 \end{aligned}$$

где  $pH_s$  — рН солевой вытяжки;  $T_{sav}$  — средняя температура открытой поверхности почвы.

Таблица 2. Результаты моделирования параметров плодородия пахотных почв тестового поля

| Используемые данные                  | $R_{cv}^2$ | RMSE <sub>cv</sub> | RPIQ |
|--------------------------------------|------------|--------------------|------|
| <i>Содержание подвижного фосфора</i> |            |                    |      |
| Набор 1 почвы                        | 0,49       | 58,80              | 1,16 |
| Набор 1 почвы + температура          | 0,53       | 51,50              | 1,33 |
| Набор 2 почвы                        | 0,80       | 32,80              | 2,09 |
| Набор 2 посевы                       | 0,68       | 46,740             | 1,46 |
| Набор 2 посевы + температура         | 0,75       | 33,20              | 2,06 |
| <i>рН солевой вытяжки</i>            |            |                    |      |
| Набор 1 посевы                       | 0,45       | 0,170              | 1,71 |
| Температура                          | 0,43       | 0,170              | 1,71 |
| Набор 1 почвы + температура          | 0,50       | 3,750              | 0,08 |
| Набор 2 почвы                        | 0,75       | 0,150              | 1,90 |
| Набор 2 почвы + температура          | 0,81       | 0,110              | 2,60 |
| Набор 2 посевы                       | 0,75       | 0,110              | 2,60 |
| <i>Органическое вещество</i>         |            |                    |      |
| Набор 1 почвы                        | 0,50       | 0,580              | 1,84 |
| Температура                          | 0,59       | 0,520              | 2,06 |
| Набор 1 почвы + температура          | 0,64       | 0,480              | 2,23 |
| Набор 2 почвы                        | 0,79       | 0,350              | 3,06 |
| Набор 2 почвы + температура          | 0,87       | 0,320              | 3,34 |

Окончание табл. 2

| Используемые данные                 | $R_{cv}^2$ | RMSE <sub>cv</sub> | RPIQ |
|-------------------------------------|------------|--------------------|------|
| Набор 2 посевы                      | 0,79       | 0,360              | 2,97 |
| Набор 2 посевы + температура        | 0,79       | 0,360              | 2,97 |
| <i>pH водной вытяжки</i>            |            |                    |      |
| Набор 1 почвы                       | 0,48       | 0,970              | 0,19 |
| Набор 1 посевы                      | 0,48       | 0,140              | 1,32 |
| Температура                         | 0,51       | 0,150              | 1,23 |
| Набор 1 почвы + температура         | 0,53       | 2,120              | 0,09 |
| Набор 2 почвы                       | 0,72       | 0,100              | 1,80 |
| Набор 2 посевы                      | 0,70       | 0,160              | 1,16 |
| <i>Массовая доля азота нитратов</i> |            |                    |      |
| Набор 2 почвы                       | 0,74       | 1,780              | 2,16 |
| Набор 2 посевы                      | 0,67       | 2,020              | 1,91 |
| Набор 2 посевы + температура        | 0,72       | 1,780              | 2,16 |
| <i>Обменный калий</i>               |            |                    |      |
| Набор 2 почвы                       | 0,73       | 40,95              | 1,52 |
| Набор 2 посевы                      | 0,71       | 42,46              | 1,46 |
| <i>Обменные катионы кальция</i>     |            |                    |      |
| Набор 2 почвы                       | 0,77       | 3,660              | 2,63 |
| Набор 2 посевы                      | 0,66       | 4,840              | 2,00 |
| <i>Обменные катионы магния</i>      |            |                    |      |
| Температура                         | 0,54       | 1,000              | 1,67 |
| Набор 2 почвы                       | 0,82       | 0,610              | 2,70 |
| Набор 2 посевы                      | 0,66       | 1,000              | 1,67 |
| <i>Общий азот</i>                   |            |                    |      |
| Набор 2 почвы                       | 0,76       | 0,028              | 2,14 |
| Набор 2 посевы                      | 0,64       | 0,036              | 1,67 |

Что касается органического вещества, при использовании набора 1 на основе СОС почв получилась модель с самым низким  $R_{cv}^2$  (0,50) и RPIQ (1,84) (табл. 2). Моделирование только на основе информации о температуре дало лучший результат с  $R_{cv}^2 = 0,59$  и RPIQ = 2,06. Совместное использование информации о температуре и набора 1 на основе СОС почв позволило увеличить  $R_{cv}^2$  до 0,64 и RPIQ — до 2,23. При применении набора 2 на основе СОС почв  $R_{cv}^2$  увеличился до 0,79, RPIQ — до 3,06. Близкий результат даёт использование набора 2 на основе СОС посевов отдельно и совместно с информацией о температуре. Наилучшая же модель получается при совместном использовании набора 2 на основе СОС почв и информации о температуре с  $R_{cv}^2 = 0,87$  и RPIQ = 3,34. Регрессионное уравнение для лучшей модели представлено ниже:

$$om = 8,73 - 0,002 \frac{b_4 b_5 - b_1 b_7}{b_2 \times b_6 - b_1 b_8} - 0,1 \frac{b_3 (b_8 - b_7)}{b_2 b_6 - b_1 b_7} - 1,13 \frac{b_2 b_{8a} - b_2 + b_1}{b_3 - b_4} - 0,004 \frac{b_7 - b_1 - b_3}{b_4^2 - b_2 b_7} + 0,0001 \frac{b_4 - 2b_{8a}}{b_3 b_5 - b_2 b_6} - 0,82 T_{sdev},$$

где  $om$  — содержание органического вещества (в %);  $T_{sdev}$  — стандартное отклонение температуры открытой поверхности почвы.



При моделировании рН водной вытяжки использование *набора 1* на основе СОС почв и на основе СОС посевов дало близкий результат по величине  $R_{cv}^2$  (0,48), однако по величине среднеквадратической ошибки предсказания по результатам кросс-валидации *набор 1* на основе СОС показал лучший результат (табл. 2). Моделирование на основе информации о температуре позволило получить модель чуть лучшего качества по величине  $R_{cv}^2$  (0,51), однако данная модель оказалась хуже по величине  $RMSE_{cv}$  и RPIQ по сравнению с моделью, построенной на *наборе 1* на основе СОС посевов. Совместное использование информации о температуре и *набора 1* на основе СОС почв привело к незначительному увеличению  $R_{cv}^2$  (до 0,53) и к существенному увеличению  $RMSE_{cv}$  (до 2,12) и снижению RPIQ (до 0,09). Применение *набора 2* на основе СОС посевов позволило улучшить результат моделирования, увеличив  $R_{cv}^2$  до 0,70, при этом  $RMSE_{cv}$  оказалась выше, а RPIQ, соответственно, ниже, чем при использовании только информации о температуре или *набора 1* на основе СОС посевов. Наилучший результат получен при применении *набора 2* на основе СОС почв с  $R_{cv}^2 = 0,72$  и RPIQ = 1,80. Регрессионное уравнение для лучшей модели представлено ниже:

$$\begin{aligned} pH_w = & 5,50 + 0,005 \frac{b_1 - b_8 + b_4}{b_7 - b_3 - b_1} - 0,06 \frac{b_5 b_6 - b_3 b_{8a}}{b_3 b_5 - b_1 b_7} - 0,02 \frac{b_6^2 - b_4 b_{8a}}{b_4 b_5 - b_1 b_{8a}} + \\ & + 0,38 \frac{b_{8a}^2 - b_6 b_8}{b_8^2 - b_7 b_8} + 0,001 \frac{b_6 - 2b_2}{b_6^2 - b_4 b_{8a}} + 0,0005 \frac{b_2 b_3 + b_3^2 + b_1 b_2}{b_6^2 - b_4 b_{8a}}, \end{aligned}$$

где  $pH_w$  — рН водной вытяжки.

В случае массовой доли азота нитратов наихудшая модель получена при использовании *набора 2* на основе СОС посевов с  $R_{cv}^2 = 0,67$  и RPIQ = 1,91. Добавление к данному набору информации о температуре позволило увеличить  $R_{cv}^2$  модели до 0,72, а RPIQ — до 2,16. Наилучшая модель получена при применении *набора 2* на основе СОС почв с  $R_{cv}^2 = 0,74$  и RPIQ = 2,16. Применение параметров *набора 1* и на основе СОС почв и на основе СОС посевов как отдельно, так и совместно с информацией о температуре не позволило получить статистически достоверные модели для данного параметра. Регрессионное уравнение для лучшей модели представлено ниже:

$$\begin{aligned} nitr = & 8,59 - 0,86 \frac{b_3 b_4 - b_1 b_6}{b_5^2 - b_3 b_7} + 0,13 \frac{b_3 b_4 - b_1 b_7}{b_3^2 - b_1 b_5} - \\ & - 0,80 \frac{b_3 b_4 - b_1 b_7}{b_2 b_5 - b_4 b_1} + 0,14 \frac{b_3 b_5 - b_1 b_7}{b_5 b_7 - b_4 b_8}, \end{aligned}$$

где  $nitr$  — массовая доля азота нитратов.

Для обменного калия были получены только две статистически достоверные модели. Наилучшая модель получена при использовании *набора 2* на основе СОС почв с  $R_{cv}^2 = 0,73$  и RPIQ = 1,52. Чуть хуже оказалась модель, полученная при использовании *набора 2* на основе СОС посевов с  $R_{cv}^2 = 0,71$  и RPIQ = 1,46. Регрессионное уравнение для лучшей модели представлено ниже:

$$\begin{aligned} K = & 324,77 + 63,07 \frac{b_3^2 - b_1 b_5}{b_6 b_2 - b_1 b_8} + 17,62 \frac{b_2 b_5 - b_1 b_6}{b_6^2 - b_4 b_{8a}} - 3,5 \frac{b_1 + b_2 - b_6}{b_2 - b_8 + b_4} + \\ & + 14,2 \frac{b_2 b_6 - b_1 b_7}{b_5^2 - b_2 b_{8a}} - 1,85 \frac{b_6^2 - b_5 b_7}{b_3^2 - b_1 b_5} - 14,06 \frac{b_4^2 - b_2 b_7}{b_6^2 - b_4 b_{8a}}, \end{aligned}$$

где  $K$  — содержание обменного калия.

Похожая ситуация отмечается для обменных катионов кальция:  $R_{cv}^2$  модели, полученной при использовании *набора 2* на основе СОС почв, составил 0,77, а RPIQ — 2,63. В случае применения *набора 2* на основе СОС посевов  $R_{cv}^2$  составил 0,66, RPIQ — 2,00. Регрессионное уравнение для лучшей модели представлено ниже:

$$\begin{aligned} \text{Ca} = & 30,68 + 3,21 \frac{b_3^2 - b_1 b_5}{b_3 b_7 - b_2 b_{8a}} + 2 \frac{b_1 b_2 - b_1^2}{b_4 b_5 - b_3 b_6} + 0,27 \frac{b_2 b_3 - b_1 b_4}{b_2 b_4 - b_1 b_5} - \\ & - 0,21 \frac{b_3 b_7 - b_1 b_7}{b_4^2 - b_3 b_6} + 0,04 \frac{b_1 b_8 + 2b_8}{b_5} + 0,034 \frac{b_8 - b_1 - b_5}{b_3 b_6 - b_1 b_{8a}}, \end{aligned}$$

где Ca — содержание обменных катионов кальция.

Что касается обменных катионов магния, наихудшая модель с  $R_{cv}^2 = 0,54$  и  $RPIQ = 1,67$  была получена при использовании информации о температуре. Применение набора 2 на основе СОС посевов позволило повысить  $R_{cv}^2$  до 0,66, при этом  $RMSE_{cv}$  и  $RPIQ$  остались не изменились. Наилучшая модель с  $R_{cv}^2 = 0,82$  и  $RPIQ = 2,70$  получена при использовании набора 2 на основе СОС почв. Регрессионное уравнение для лучшей модели представлено ниже:

$$\begin{aligned} \text{Mg} = & 4,87 - 0,29 \frac{b_2 + b_4 - b_{8a}}{2b_3 - b_{8a}} + 0,55 \frac{b_3^2 - b_1 b_5}{b_4 b_5 - b_2 b_{8a}} + 0,12 \frac{b_{8a}^2 - b_1 b_6}{b_8^2 - b_7 b_{8a}} - \\ & - 0,17 \frac{b_2^2 - b_1 b_3}{b_4 b_5 - b_3 b_7} - 0,0005 \frac{b_{8a}^2 - b_1}{b_4^2 - b_1 b_8} + 0,07 \frac{b_3 b_6 - b_2 b_8}{b_2 b_4 - b_1 b_5}, \end{aligned}$$

где Mg — содержание обменных катионов магния.

В случае общего азота, также как и в случае обменного калия и обменных катионов кальция, были получены только две статистически достоверные модели. Наилучшая модель построена при использовании набора 2 на основе СОС почв с  $R_{cv}^2 = 0,76$  и  $RPIQ = 2,16$ . Чуть хуже оказалась модель, полученная при использовании набора 2 на основе СОС посевов с  $R_{cv}^2 = 0,64$  и  $RPIQ = 1,67$ . Регрессионное уравнение для лучшей модели представлено ниже:

$$\begin{aligned} N_{tot} = & -2,83 + 0,16 \frac{b_5 b_{8a} - b_1 b_7}{b_3 b_{8a} - b_2 b_8} + 0,004 \frac{b_7^2 - b_6 b_8}{b_4^2 - b_2 b_7} - 1,22 \frac{b_8 b_3 + 2b_8}{b_{8a} - b_7 - b_8} - \\ & - 0,0002 \frac{b_5 b_3 - b_{8a} + b_2}{b_3 - b_1 - b_6} + 0,0002 \frac{b_7 - b_1 - b_2}{b_3 b_5 - b_2 b_7} + 0,0001 \frac{b_{8a} - b_5 - b_1}{b_2 b_5 - b_1 b_6}, \end{aligned}$$

где  $N_{tot}$  — содержание общего азота.

Таким образом, почти во всех случаях при использовании параметров из набора 1 качество модели улучшается при добавлении в неё информации о температуре. В то же время лучшие модели получаются при использовании параметров из набора 2 на основе СОС почв (большая часть моделируемых параметров плодородия) или при совместном использовании параметров из набора 2 на основе СОС почв и информации о температуре открытой поверхности почвы (органическое вещество и рН солевой вытяжки). Для органического вещества информативным оказалось стандартное отклонение температуры открытой поверхности почвы в пределах анализируемого изображения тепловизора. Это может объясняться тем, что при высоком содержании органического вещества (от 6 %) в случае температуры поверхности происходит такой же эффект, как и в случае СОС в видимом диапазоне: она практически не изменяется при дальнейшем повышении содержания органического вещества. В случае рН солевой вытяжки информативной была средняя температура открытой поверхности почвы, что, скорее всего, указывает на то, что анализируемый параметр в данном случае лучше детектируется косвенно. Вероятнее всего, это происходит через связь с содержанием органического вещества.

В результате многочисленных исследований было установлено, что температура поверхности почвы тесно связана с её свойствами: гранулометрическим составом, влажностью, минералогическим составом, содержанием и типом органического вещества и микробиоты (Курганова, Типе, 2003; Орлов и др., 1997). Данные свойства, в свою очередь, во многом и определяют динамику параметров плодородия почв. При этом температура поверхности пахотных почв, по-видимому, имеет более тесные связи с отдельными параметрами пло-

дородия, чем её оптические свойства. Приведём в качестве примера такое свойство как влажность почвы, от которой зависит скорость трансформации питательных веществ в пахотном горизонте почв и специфика формирования гумуса. По оптическим свойствам поверхности почва часто может диагностироваться как сухая, но содержание влаги в самом пахотном горизонте может быть высоким (Савин и Виндекер, 2021), что влияет на температуру поверхности почвы. Таким образом, температура поверхности почвы более тесно связана с влажностью пахотного горизонта почв, чем её оптические свойства, что и предопределяет установленный эффект повышения качества построенных предсказательных моделей.

В целом для детектирования изучаемых параметров плодородия задействуются все анализируемые каналы Sentinel-2, т. е. спектральные параметры набора 2 более эффективно используют информацию из СОС открытой поверхности почв в оптическом диапазоне. Лучше всего детектируются такие параметры, как содержание органического вещества, рН солевой вытяжки и обменные катионы магния, а хуже всего — рН водной вытяжки и обменный калий.

## Заключение

Полученные результаты показали, что потенциально многие параметры плодородия пахотных почв могут быть успешно отдетектированы по спутниковым данным Sentinel-2 или по данным полевого спектрометрирования в диапазонах спектра, соответствующих каналам этого сенсора. Использование стандартных спектральных индексов не всегда позволяет получать достоверные модели с хорошей предсказательной способностью. На тестовом поле подобные достоверные модели были получены лишь для содержания органического вещества. Более качественные модели могут быть получены при использовании специальных индексов, созданных для конкретных параметров плодородия, на основе спектральных каналов видимого диапазона. Такие модели для тестового поля были получены практически для всех проанализированных параметров плодородия тестового поля кроме обменного калия и рН водной вытяжки. Привлечение информации о температуре поверхности почв и посевах позволило повысить качество предсказательных моделей для содержания подвижного фосфора, рН водной и солевой вытяжки, содержания органического вещества и массовой доли азота нитратов. Применение предложенных спектральных индексов на других полях требует дополнительного тестирования.

Работа выполнена в рамках реализации важнейшего инновационного проекта государственного значения «Разработка системы наземного и дистанционного мониторинга пулов углерода и потоков парниковых газов на территории Российской Федерации, обеспечение создания системы учёта данных о потоках климатически активных веществ и бюджете углерода в лесах и других наземных экологических системах» (рег. № 123030300031-6).

## Литература

1. ГОСТ 26423-85. Почвы. Методы определения удельной электрической проводимости, рН и плотного остатка водной вытяжки. М.: Стандартинформ, 2011. 4 с.
2. ГОСТ 26483-85. Почвы. Приготовление солевой вытяжки и определение ее рН по методу ЦИНАО. М.: Изд-во стандартов, 1985. 5 с.
3. ГОСТ 26213-84. Почвы. Методы определения органического вещества. М.: Изд-во стандартов, 1992. 6 с.
4. ГОСТ Р 54650-2011. Почвы. Определение подвижных соединений фосфора и калия по методу Кирсанова в модификации ЦИНАО. М.: Стандартинформ, 2013. 7 с.
5. ГОСТ 26210-91. Почвы. Определение обменного калия по методу Масловой. М.: Изд-во стандартов, 1992. 4 с.
6. ГОСТ 26951-86. Почвы. Определение нитратов ионометрическим методом. М.: Изд-во стандартов, 1986. 7 с.
7. ГОСТ 26107-84, п. 4.1. Почвы. Методы определения общего азота. М.: Изд-во стандартов, 1984. 8 с.

8. Грубина П. Г., Савин И. Ю., Прудникова Е. Ю. Возможности использования данных тепловой съемки для детектирования основных параметров плодородия пахотных почв // Бюл. Почвенного ин-та имени В. В. Докучаева. 2020. № 105. С. 146–172. <https://doi.org/10.19047/0136-1694-2020-105-146-172>.
9. Кирьянова Е. Ю., Савин И. Ю. Неоднородность посевов, определяемая по спутниковым данным MODIS, как индикатор контрастности почвенного покрова // Докл. Российской акад. с.-х. наук. 2013. № 3. С. 36–39.
10. Курганова И. Н., Тине Р. Влияние процессов замерзания-оттаивания на дыхательную активность почв // Почвоведение. 2003. № 9. С. 1095–1105.
11. Методические указания по проведению комплексного мониторинга плодородия почв земель сельскохозяйственного назначения. М.: ФГНУ «Росинформагротех», 2003. 240 с.
12. Орлов Д. С., Бирюкова О. Н., Рыжова И. М. Зависимость запасов гумуса от продолжительности периода биологической активности почв // Почвоведение. 1997. № 7. С. 818–822.
13. Орлов Д. С., Суханова Н. И., Розанова М. С. Спектральная отражательная способность почв и их компонентов. М.: Изд-во МГУ, 2001. 176 с.
14. Прудникова Е. Ю., Савин И. Ю., Грубина П. Г. Спутниковая оценка агрономически важных свойств пахотных почв с учетом состояния их поверхности // Бюл. Почв. ин-та им. В. В. Докучаева. 2023. № 115 С. 129–159. DOI: 10.19047/0136-1694-2023-115-129-159.
15. Руководство по лабораторным методам исследования ионно-солевого состава нейтральных и щелочных минеральных почв / Под ред. Н. Б. Хитрова, А. А. Понизовского. М.: Почв. ин-т им. В. В. Докучаева, 1990. 235 с.
16. Савин И. Ю., Виндекер Г. В. Некоторые особенности использования оптических свойств поверхности почв для определения их влажности // Почвоведение. 2021. № 7. С. 806–814. DOI: 10.31857/S0032180X21070121.
17. Bellinaso H., Demattê J. A. M., Romeiro S. A. Soil spectral library and its use in soil classification // Revista Brasileira de Ciência do Solo. 2010. V. 34. P. 861–870. DOI: 10.1590/S0100-06832010000300027.
18. Bulan R., Sitorus A. Vis-NIR spectra combined with machine learning for predicting soil nutrients in crop-land from Aceh Province, Indonesia // Case Studies in Chemical and Environmental Engineering. 2022. V. 6. Article 100268. DOI: 10.1016/j.cscee.2022.100268.
19. Demattê J. A., Ramirez-Lopez L., Marques K. P. P., Rodella A. A. Chemometric soil analysis on the determination of specific bands for the detection of magnesium and potassium by spectroscopy // Geoderma. 2017. V. 288. P. 8–22. <https://doi.org/10.1016/j.geoderma.2016.11.013>.
20. Fang Q., Hong H., Zhao L. et al. Visible and near-infrared reflectance spectroscopy for investigating soil mineralogy: A review // J. Spectroscopy. 2018. V. 2018. P. 1–14. DOI: 10.1155/2018/3168974.
21. Gholizadeh A., Saberioon M., Carmon N. et al. Examining the performance of PARACUDA-II data-mining engine versus selected techniques to model soil carbon from reflectance spectra // Remote Sensing. 2018. V. 10(8). Article 1172. DOI: 10.3390/rs10081172.
22. Kuang B., Mahmood H. S., Quraishi M. Z. et al. Sensing soil properties in the laboratory, *in situ*, and on-line: a review // Advances in Agriculture. 2012. V. 114. P. 155–223. DOI: 10.1016/B978-0-12-394275-3.00003-1.
23. Lesaignoux A., Fabre S., Briottet X., Olioso A., Belin E. Influence of surface soil moisture on spectral reflectance of bare soil in the 0.4–15  $\mu\text{m}$  domain // Geosciences and Remote Sensing Letters. 2011. V. 8(1). P. 143–147.
24. Mouazen A. M., Kuang B. On-line visible and near infrared spectroscopy for in-field phosphorous management // Soil and Tillage Research. 2016. V. 155. P. 471–477. DOI: 10.1016/j.still.2015.04.003.
25. Prudnikova E., Savin I. Some peculiarities of arable soil organic matter detection using optical remote sensing data // Remote Sensing. 2021. V. 13(12). Article 2313. DOI: 10.3390/rs13122313.
26. Soriano-Disla J. M., Janik L. J., Rossel R. A. V. et al. The Performance of Visible, Near-, and Mid-Infrared Reflectance Spectroscopy for Prediction of Soil Physical, Chemical, and Biological Properties // Applied Spectroscopy Reviews. 2014. V. 49. P. 139–186. DOI: 10.1080/05704928.2013.811081.
27. Stenberg B., Viscarra Rossel R. A., Mouazen A. M., Wetterlind J. Visible and near-infrared spectroscopy in soils // Advances in Agriculture. 2010. V. 107. P. 163–215. DOI: 10.1016/S0065-2113(10)07005-7.
28. Trontelj ml. J., Chambers O. Machine learning strategy for soil nutrients prediction using spectroscopic method // Sensors. 2021. V. 21(12). Article 4208. DOI: 10.3390/s21124208.
29. Viscarra Rossel R. A., Walvoort D. J. J., McBratney A. B. et al. Visible, near infrared, mid infrared or combined diffuse reflectance spectroscopy for simultaneous assessment of various soil properties // Geoderma. 2006. V. 131. P. 59–75. DOI: 10.1016/j.geoderma.2005.03.007.
30. Wetterlind J., Stenberg B., Söderström M. Increased sample point density in farm soil mapping by local calibration of visible and near infrared prediction models // Geoderma. 2010. V. 156(3–4). P. 152–160.

## Potential possibilities for remote detection of fertility parameters of arable soils based on spectral reflectance of their surface and data on its temperature

E. Yu. Prudnikova, I. Yu. Savin

V. V. Dokuchaev Soil Science Institute, Moscow 119017, Russia

E-mails: prudnikova\_eyu@esoil.ru, savin\_iuy@esoil.ru

Remote assessment of the properties of arable soils is based on the relationship between these properties and soil spectral reflectance. The detection of fertility parameters of arable soils from remote data is complicated by the fact that not all of these parameters have a direct effect on soil spectral reflectance. The article discusses the information content of various sets of spectral parameters of optical and thermal ranges for detecting fertility parameters of arable soils on the example of a test field with leached chernozems located in Serebryano-Prudsky District of Moscow Region. At the same time, both the open surface of soils and crops were analyzed. The best models using the most common spectral indices and ratios calculated from optical data were obtained for organic matter ( $R_{cv}^2$  (cross-validated coefficient of determination) = 0.50, RPIQ (ratio of performance to interquartile distance) = 1.84) and the mass fraction of phosphorus compounds ( $R_{cv}^2 = 0.49$ , RPIQ = 1.16). With the combined use of optical and thermal data, models of higher accuracy and predictive power were obtained in some cases. For the content of organic matter  $R_{cv}^2$  increased to 0.64, RPIQ to 2.23, for the mass fraction of phosphorus compounds  $R_{cv}^2$  increased to 0.53, RPIQ to 1.33. Using an additional set of parameters in the optical range, including 102 combinations, made it possible to obtain models for all analyzed properties with  $R_{cv}^2$  of the best models in the region of 0.72–0.87 and RPIQ in the region of 1.52–3.34. In addition, for a number of properties, it was possible to obtain reliable models with high predictive ability only after using an additional set of parameters. In general, the spectral reflectance of the open soil surface turned out to be more informative than the spectral reflectance of winter wheat crops at the germination stage.

**Keywords:** fertility parameters of arable soils, spectral reflectance, optical range, thermal range, Sentinel-2

Accepted: 15.05.2024

DOI: 10.21046/2070-7401-2024-21-3-131-144

### References

1. GOST 26423-85. Pochvy. Metody opredeleniya udel'noi elektricheskoi provodimosti, pH i plotnogo ostatka vodnoi vytyazhki (Soils. Methods for determination of specific electric conductivity, pH and solid residue of water extract), Moscow: Standartinform, 2011, 4 p. (in Russian).
2. GOST 26483-85. Pochvy. Prigotovlenie solevoi vytyazhki i opredelenie ee pH po metodu TsINAO (Soils. Preparation of salt extract and determination of its pH by CINAO method), Moscow: Standards Publ. House, 1985, 5 p. (in Russian).
3. GOST 26213-84. Pochvy. Metody opredeleniya organicheskogo veshchestva (Soils. Methods for determination of organic matter), Moscow: Standards Publ. House, 1992, 6 p. (in Russian).
4. GOST R 54650-2011. Pochvy. Opredelenie podvizhnykh soedinenii fosfora i kaliya po metodu Kirsanova v modifikatsii TsINAO (Soils. Determination of mobile phosphorus and potassium compounds by Kirsanova method modified by CINAO), Moscow: Standards Publ. House, 1992, 4 p. (in Russian).
5. GOST 26210-91. Pochvy. Opredelenie obmennogo kaliya po metodu Maslovoi (Soils. Determination of exchangeable potassium by Maslova method), Moscow: Standartinform, 2013, 7 p. (in Russian).
6. GOST 26951-86. Pochvy. Opredelenie nitratov ionometricheskim metodom (Soils. Determination of nitrates by ionometric method), Moscow: Standards Publ. House, 1986, 7 p. (in Russian).
7. GOST 26107-84, p. 4.1. Pochvy. Metody opredeleniya obshchego azota (Soils. Methods for determination of total nitrogen, p. 4.1), Moscow: Standards Publ. House, 1984, 8 p. (in Russian).
8. Grubina P. G., Savin I. Yu., Prudnikova E. Yu., The possibilities of using thermal infrared imaging data for detecting the main parameters of arable soil fertility, *Dokuchaev Soil Bull.*, 2020, No. 105, pp. 146–172 (in Russian), DOI: 10.19047/0136-1694-2020-105-146-172.
9. Kir'yanova E. Yu., Savin I. Yu., Crop canopy heterogeneity detected based on MODIS satellite data as an indicator of contrast in soil patterns, *Russian Agricultural Sciences*, 2013, Vol. 4, pp. 342–345.

10. Kurganova I. N., Tipe R., The effect of freezing-thawing processes on soil respiration activity, *Pochvovedenie*, 2003, Vol. 36, No. 9, pp. 976–985.
11. *Metodicheskie ukazaniya po provedeniyu kompleksnogo monitoringa plodorodiya pochv zemel' sel'skokhozyaistvennogo naznacheniya* (Guidelines for conducting comprehensive monitoring of soil fertility in agricultural lands), Moscow: FGNU "Rosinformagrotech", 2003, 240 p. (in Russian).
12. Orlov D. S., Biryukova O. N., Ryzhova I. M., Dependence of humus reserves on the duration of the period of biological activity of soils, *Pochvovedenie*, 1997, No. 7, pp. 818–822.
13. Orlov D. S., Sukhanova N. I., Rozanova M. S., *Spektral'naya otrazhatel'naya sposobnost' pochv i ikh komponentov* (Spectral reflectivity of soils and their components), Moscow: MSU Publ. House, 2001, 176 p. (in Russian).
14. Prudnikova E. Yu., Savin I. Yu., Grubina P. G., Satellite based assessment of agronomically important properties of agricultural soils with consideration of their surface state. *Dokuchaev Soil Bull.* 2023, No. 115, pp. 129–159 (in Russian), DOI: 10.19047/0136-1694-2023-115-129-159.
15. *Rukovodstvo po laboratornym metodam issledovaniya ionno-solevogo sostava neutral'nykh i shchelochnykh mineral'nykh pochv* (Guidelines for Laboratory Methods for Studying the Ion-Salt Composition of Neutral and Alkaline Mineral Soils), N. B. Khitrov, A. A. Ponizovskii (eds.), Moscow: V. V. Dokuchaev Soil Science Institute, 1990, 235 p. (in Russian).
16. Savin I. Yu., Vindeker G. V., Some specifics in using optical properties of soil surface for moisture detection, *Eurasian Soil Science*, 2021, Vol. 54, No. 7, pp. 1019–1027, DOI: 10.1134/S1064229321070127.
17. Bellinaso H., Demattê J. A. M., Romeiro S. A., Soil spectral library and its use in soil classification, *Revista Brasileira de Ciência do Solo*, 2010, Vol. 34, pp. 861–870, DOI: 10.1590/S0100-06832010000300027.
18. Bulan R., Sitorus A., Vis-NIR spectra combined with machine learning for predicting soil nutrients in cropland from Aceh Province, Indonesia, *Case Studies in Chemical and Environmental Engineering*, 2022, Vol. 6, Article 100268, DOI: 10.1016/j.cscee.2022.100268.
19. Demattê J. A., Ramirez-Lopez L., Marques K. P. P., Rodella A. A., Chemometric soil analysis on the determination of specific bands for the detection of magnesium and potassium by spectroscopy, *Geoderma*, 2017, Vol. 288, pp. 8–22, <https://doi.org/10.1016/j.geoderma.2016.11.013>.
20. Fang Q., Hong H., Zhao L. et al., Visible and near-infrared reflectance spectroscopy for investigating soil mineralogy: A review, *J. Spectroscopy*, 2018, Vol. 2018, pp. 1–14, DOI: 10.1155/2018/3168974.
21. Gholizadeh A., Saberioon M., Carmon N. et al., Examining the performance of PARACUDA-II data-mining engine versus selected techniques to model soil carbon from reflectance spectra, *Remote Sensing*, 2018, Vol. 10(8), Article 1172, DOI: 10.3390/rs10081172.
22. Kuang B., Mahmood H. S., Quraishi M. Z. et al., Sensing soil properties in the laboratory, *in situ*, and on-line: a review, *Advances in Agriculture*, 2012, Vol. 114, pp. 155–223, DOI: 10.1016/B978-0-12-394275-3.00003-1.
23. Lesaignoux A., Fabre S., Briottet X., Oliosio A., Belin E., Influence of surface soil moisture on spectral reflectance of bare soil in the 0.4–15 µm domain, *Geosciences and Remote Sensing Letters*, 2011, Vol. 8(1), pp. 143–147.
24. Mouazen A. M., Kuang B., On-line visible and near infrared spectroscopy for in-field phosphorous management, *Soil and Tillage Research*, 2016, Vol. 155, pp. 471–477, DOI: 10.1016/j.still.2015.04.003.
25. Prudnikova E., Savin I., Some peculiarities of arable soil organic matter detection using optical remote sensing data, *Remote Sensing*, 2021, Vol. 13(12), Article 2313, DOI: 10.3390/rs13122313.
26. Soriano-Disla J. M., Janik L. J., Rossel R. A. V. et al., The Performance of Visible, Near-, and Mid-Infrared Reflectance Spectroscopy for Prediction of Soil Physical, Chemical, and Biological Properties, *Applied Spectroscopy Reviews*, 2014, Vol. 49, pp. 139–186, DOI: 10.1080/05704928.2013.811081.
27. Stenberg B., Viscarra Rossel R. A., Mouazen A. M., Wetterlind J., Visible and near-infrared spectroscopy in soil science, *Advances in Agriculture*, 2010, Vol. 107, pp. 163–215, DOI: 10.1016/S0065-2113(10)07005-7.
28. Trontelj ml. J., Chambers O., Machine learning strategy for soil nutrients prediction using spectroscopic method, *Sensors*, 2021, Vol. 21(12), Article 4208, DOI: 10.3390/s21124208.
29. Viscarra Rossel R. A., Walvoort D. J. J., McBratney A. B. et al., Visible, near infrared, mid infrared or combined diffuse reflectance spectroscopy for simultaneous assessment of various soil properties, *Geoderma*, 2006, Vol. 131, pp. 59–75, DOI: 10.1016/j.geoderma.2005.03.007.
30. Wetterlind J., Stenberg B., Söderström M., Increased sample point density in farm soil mapping by local calibration of visible and near infrared prediction models, *Geoderma*, 2010, Vol. 156(3–4), pp. 152–60, DOI: 10.1016/j.geoderma.2010.02.012.