

Адаптация модели глубокого обучения на основе ResNet для прогнозирования химических свойств почв центральной России по данным спектроскопии

И. Е. Новоселов, О. Е. Бакланова

Томский государственный университет

Аннотация: В данной статье представлена адаптация модели глубокого обучения на основе остаточной нейронной сети ResNet с модулями внимания СВМ для прогнозирования содержания азота, фосфора и калия в почвах центральной России по данным спектроскопии в видимом и ближнем инфракрасном диапазонах. Модель, предобученная на глобальной библиотеке LUCAS, дообучена на локальной выборке из 100 образцов почв Воронежской, Курской, Ростовской областей и Краснодарского края. Применена стратегия частичной заморозки слоев. После дообучения достигнуты коэффициент детерминации 0,91 и относительное отклонение прогноза 3,01 для азота, для фосфора – 0,56 и 2,40 соответственно. Показана возможность использования портативных спектрометров в системах точного земледелия.

Ключевые слова: глубокое обучение, остаточные нейронные сети, внимание, дообучение, почва, спектроскопия.

Для цитирования: Новоселов И. Е., Бакланова О. Е. Адаптация модели глубокого обучения на основе ResNet для прогнозирования химических свойств почв центральной России по данным спектроскопии // Вестник СибГУТИ. 2026. Т. 20, № 2. С. 93–106. <https://doi.org/10.55648/1998-6920-2026-20-2-93-106>.



Контент доступен под лицензией
Creative Commons Attribution 4.0
License

© Новоселов И. Е., Бакланова О. Е., 2026

Статья поступила в редакцию 24.04.2026;
переработанный вариант – 30.04.2026;
принята к публикации 28.05.2026.

1. Введение

В современных агротехнологиях остро стоит вопрос оперативного получения достоверной информации о состоянии почвенного плодородия для рационального применения удобрений, увеличения продуктивности посевов и снижения негативного воздействия на окружающую среду. Классические лабораторные подходы к измерению концентраций азота (N), фосфора (P) и калия (K) отличаются высокой трудоемкостью, значительными финансовыми затратами и являются непригодными для массового экспресс-анализа непосредственно в поле. В этой связи все большее внимание привлекает метод спектроскопии в видимой и ближней инфракрасной области (Vis-NIR), позволяющий быстро, без разрушения образца и с относительно невысокой стоимостью получать спектральные характеристики почвы [1, 2].

Вместе с тем интерпретация спектральных данных связана с серьезными сложностями, обусловленными многомерностью исходных сигналов, наличием сложных нелинейных взаимосвязей и взаимным перекрытием полос поглощения разных химических соединений [3, 4]. Широко распространенные хемометрические алгоритмы – например, метод частичной регрессии на наименьшие квадраты (PLSR) и метод опорных

векторов (SVM) – несмотря на свою популярность, зачастую показывают ограниченную эффективность при работе с большими объемами данных и при моделировании нелинейных зависимостей [1, 5].

Глубокое обучение сегодня часто применяют для спектроскопического анализа почв. Особенно хорошо себя показывают сверточные нейронные сети (CNN), в частности архитектура с остаточными блоками ResNet – она эффективно выделяет иерархические признаки из спектров [6,7]. В работе He et al. [8] было показано, что остаточные связи позволяют тренировать очень глубокие сети без затухания градиента. Wartini Ng. et al. [9] сравнили несколько одномерных CNN – LeNet, AlexNet, VGG и ResNet – на наборе LUCAS. Оказалось, что ResNet дает высокое качество, для азота R^2 до 0,92, для органического углерода до 0,95, для pH до 0,89. Еще одно исследование Kattenborn et al. [7] подтвердило, что CNN можно использовать для одновременного предсказания нескольких почвенных свойств.

Улучшить работу моделей помогает интеграция механизмов внимания. Они заставляют модель концентрироваться на самых информативных участках спектра. Один из таких механизмов – модуль CBAM (Convolutional Block Attention Module) – был предложен Wartini Ng [9] и успешно применяется в анализе почвенных спектров. Интересно и многозадачное обучение, когда одна сеть прогнозирует сразу несколько связанных характеристик. Например, архитектура PS-MTL-LUCAS от Woo S. и др. [10] с частично разделяемыми слоями показала впечатляющие результаты на LUCAS, коэффициент детерминации равен $R^2 = 0,945$ для pH, 0,936 для N, 0,952 для органического углерода OC и 0,956 для карбонатов CaCO_3 . Кроме того, работы Wang, X и Zhong, L. [11, 12] тоже использовали глубокие сверточные сети для извлечения признаков и предсказания свойств почв по спектральной библиотеке LUCAS.

В нашей предыдущей работе [13] мы предоставили программную реализацию модели глубокого обучения – на базе ResNet, с модулем внимания CBAM и с учетом кислотности (pH). Та модель, обученная на LUCAS, хорошо предсказывала органический углерод ($R^2 = 0,94$), карбонаты кальция ($R^2 = 0,95$) и азот ($R^2 = 0,89$). Однако, как ни хороши глобальные библиотеки спектров, есть одна важная проблема, связанная с применением моделей на практике. Обученная на глобальных данных модель часто отказывается работать на других региональных данных. Почвы очень разные – и почвообразующие породы, и по климату, и по истории обработки [6, 11]. В итоге модель, которую натренировали на европейских образцах LUCAS, при попытке применить ее к почвам центральной России выдает совсем плохие результаты.

На это указывают и другие исследователи. Например, работа Shin S.K et al. [1] подчеркивает, чтобы спектроскопия работала в поле, модель нужно калибровать под конкретный регион. Российские ученые тоже пишут, что отражательная способность почв сильно различается от области к области, и нужны либо локальные модели, либо адаптация глобальных. Буряк и Гафуров [14] показали на почвах Татарстана: даже внутри одного региона спектральные характеристики статистически значимо различаются у разных типов почв. Горохова с коллегами [15] на примере Приволжской возвышенности выяснили, что один и тот же тип почвы может попадать в разные спектральные группы – из-за несовпадения свойств поверхности и глубоких горизонтов. Сироткин и др. [2] тоже считают, что локальные условия обязательно надо учитывать при полевых спектрометрических замерах.

Целью данной работы является исследование возможности адаптации предобученной на глобальном датасете LUCAS модели глубокого обучения на основе архитектуры ResNet с модулем внимания CBAM для прогнозирования содержания азота, фосфора и калия в почвах центральной части России путем дообучения (fine-tuning) на локальной выборке из 100 образцов с известными спектральными характеристиками и результатами химического анализа, что позволит повысить точность прогнозирования в реальных условиях применения.

2. Материалы и методы.

В работе использованы два набора данных: глобальная спектральная библиотека LUCAS для предобучения базовой модели и оригинальный набор спектров почв центральной части России для дообучения и тестирования.

2.1. Датасет LUCAS

Для предварительного обучения модели применен общедоступный набор данных LUCAS (Land Use/Cover Area Frame Survey), содержащий спектры диффузного отражения в диапазоне 400–2500 нм (шаг 0,5 нм) и результаты физико-химических анализов для более чем 20 000 образцов почвы, собранных на всей территории Европейского союза [6]. Для каждого образца доступны значения pH, содержания органического углерода (OC), общего азота (N), карбонатов кальция (CaCO_3), а также подвижных форм фосфора (P) и калия (K). На рисунке 1 приведены характерные спектры из библиотеки LUCAS, демонстрирующие их вариативность в зависимости от типа почвы.




Рис. 1. Примеры спектрограмм библиотеки LUCAS

2.2. Локальный датасет почв центральной России

Для адаптации модели к региональным условиям была сформирована собственная выборка из 100 образцов пахотного горизонта сельскохозяйственных почв (преимущественно черноземы типичные и выщелоченные). Образцы отобраны на территории Воронежской, Курской, Ростовской областей и Краснодарского края в период 2023–2024 гг.

Спектры диффузного отражения регистрировались с использованием портативных спектрометров [hamamatsu H16722 400-900nm и DLPNIRNANOEVМ, Mobile Spectrometer EVM: 900-1700nm] в диапазоне 450–1667 нм. Для каждого образца проводилось три измерения с последующим усреднением. Химический анализ выполнен в аккредитованной лаборатории по следующим методикам:

- 1) pH водной вытяжки – потенциометрически (ГОСТ 26423);
- 2) массовая доля подвижных соединений фосфора и калия – по методу Кирсанова в модификации ЦИНАО (ГОСТ Р 54650);
- 3) массовая доля общего азота – методом Кьельдаля (ГОСТ Р 58596, п. 7.2).

На рисунке 2 приведены исходные спектры (коэффициенты поглощения) из собранной локальной библиотеки почв центральной России до предварительной обработки.

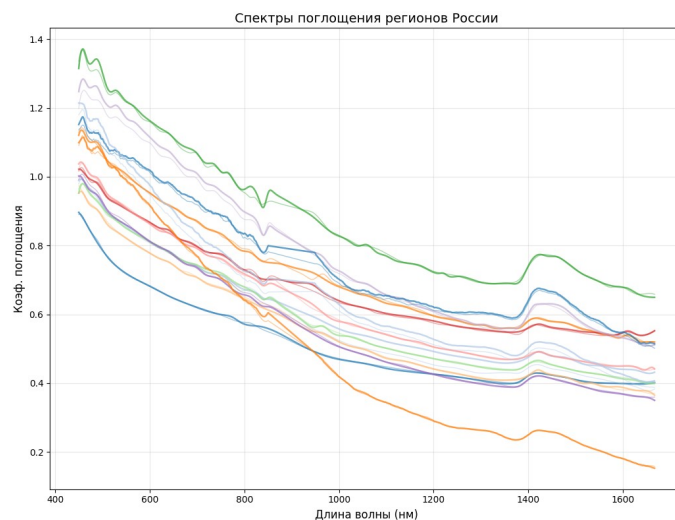


Рис. 2. Примеры спектрограмм локальной библиотеки центральной России

2.3. Предварительная обработка данных

Для обеспечения сопоставимости данных LUCAS и локальных образцов применен единый конвейер (pipeline) предобработки, реализованный на языке Python с использованием библиотек `numpy`, `scipy` и `scikit-learn`.

Приведение к единой длине волны. Спектры LUCAS имеют высокое разрешение (4200 точек), тогда как портативный спектрометр выдает меньшее число отсчетов. Для унификации размерности все спектры интерполированы на общий диапазон 450–1667 нм с постоянным шагом, что дает 500 точек. Интерполяция выполнена кубическими сплайнами (1):

$$S_i(x) = a_i + b_i(x - x_i) + c_i(x - x_i)^2 + d_i(x - x_i)^3, \quad (1)$$

где a_i , b_i , c_i , d_i – коэффициенты сплайна, определяемые из условий непрерывности первой и второй производных.

Конвейер спектральной обработки. Для уменьшения влияния шумов и вариаций базовой линии последовательно применялись:

- 1) удаление выбросов по правилу трех сигм;
- 2) сглаживание фильтром Савицкого–Голея (окно 11 точек, полином 2-го порядка);
- 3) вычисление первой производной (для подавления мультипликативных эффектов);
- 4) вейвлет-преобразование с использованием вейвлета Добеши (уровень 3) для дополнительного шумоподавления;
- 5) нормализация каждого спектра к единичной евклидовой норме.

Целевые переменные (содержание N, P, K) стандартизированы с помощью `StandardScaler` (нулевое среднее, единичная дисперсия). Все этапы конвейера сохранены и применены одинаково к обоим датасетам, что обеспечивает корректное сравнение.

2.4. Архитектура модели глубокого обучения.

В основе предлагаемого решения лежит одномерная сверточная нейронная сеть с остаточными связями (ResNet), адаптированная для обработки спектральных сигналов. Модель включает механизмы внимания СВМ (Convolutional Block Attention Module), интегрирующие значение кислотности почвы (pH) непосредственно в процесс выделения признаков. Архитектура ориентирована на многозадачную регрессию трех целевых переменных: массовой доли общего азота (N), подвижных соединений фосфора (P) и калия (K). На рисунке 3 представлена общая блок-схема модели.

Входные данные и начальная обработка. Модель принимает на вход два информационных потока:

- 1) Спектральный тензор размерности (B,C,L), где B – размер мини-батча, C=4 – число спектральных каналов (исходный спектр отражения, первая производная, аппроксимиру-

ющие и детализирующие коэффициенты вейвлет-преобразования Добеши), $L=500$ – длина спектра после интерполяции и даунсемплинга.

2) Скалярное значение pH для каждого образца, нормализованное к диапазону $[0,1]$ с использованием глобальной статистики обучающей выборки.

Начальный сверточный блок осуществляет повышение размерности каналов и пространственное прореживание (2):

$$h_0 = \text{MaxPool1d} \left(\text{LeakyReLU} \left(\text{BatchNorm} \left(\text{Conv1d}_{1 \rightarrow 64} (X, k=7, s=2, p=3) \right) \right) \right), \quad (2)$$

где X – входной спектральный тензор. Выходная размерность составляет $(B, 64, 125)$.

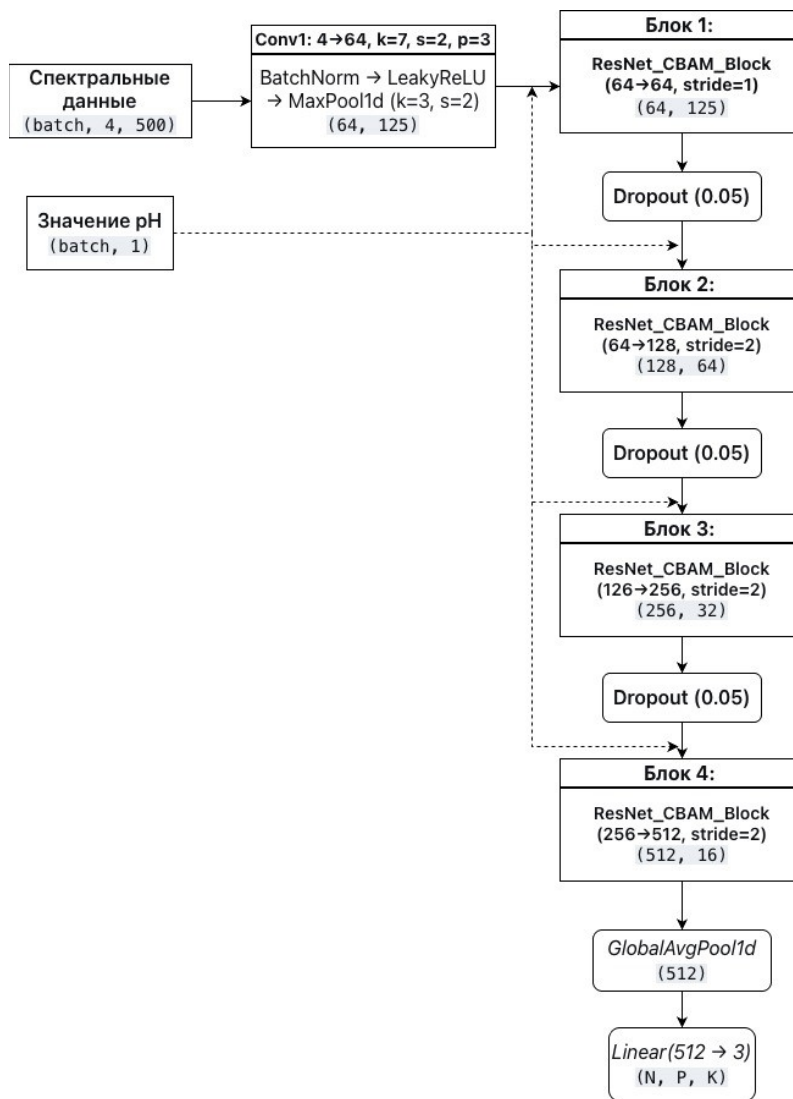


Рис. 3. Общая блок-схема модели ResNet101_CBAM

Остаточные блоки с модулями CBAM и учетом pH. Основу модели составляют четыре последовательных остаточных блока, каждый из которых содержит два сверточных слоя с пакетной нормализацией, функцией активации LeakyReLU ($\alpha=0.1$) и модуль CBAM, интегрирующий значение pH. Параметры блоков приведены в таблице 1.

Таблица 1. Конфигурация остаточных блоков

Блок	Входные каналы	Выходные каналы	Шаг (stride)	Выходная размерность
1	64	64	1	$(B, 64, 125)$
2	64	128	2	$(B, 128, 64)$
3	128	256	2	$(B, 256, 32)$
4	256	512	2	$(B, 512, 16)$

Каждый блок выполняет преобразование (3):

$$h_k = \text{LeakyReLU}\left(\text{CBAM}\left(F_{\text{conv}}(h_{k-1}), pH\right)\right) + s(h_{k-1}), \quad (3)$$

где F_{conv} – последовательность двух сверток с пакетной нормализацией и активацией, а $s(\cdot)$ – остаточное соединение (shortcut).

При совпадении размерностей входного и выходного тензоров s является тождественным отображением; в противном случае реализуется свертка 1×1 с соответствующим шагом.

После каждого блока (кроме последнего) применяется слой Dropout с вероятностью отключения 0.05 для регуляризации.

Структура модуля СВМ

Модуль СВМ состоит из двух подмодулей: канального внимания и пространственного внимания. В отличие от классической реализации, в данном решении значение pH интегрируется в оба подмодуля.

Канальное внимание. Входная карта признаков дополняется $F \in \mathbb{R}^{C \times L}$ дополнительным каналом, полученным расширением скалярного pH на всю пространственную размерность. Затем вычисляются глобальный средний и глобальный максимальный пулинг, результаты которого суммируются и пропускаются через двухслойный сверточный блок с ядром 1×1 и коэффициентом сжатия 8. Полученные веса каналов нормируются сигмодой (4):

$$M_c = \sigma\left(\text{MLP}\left(\text{AvgPool}(\tilde{F}) + \text{MaxPool}(\tilde{F})\right)\right), \quad (4)$$

где \tilde{F} – карта признаков, дополненная каналом pH. Выходные веса M_c поэлементно умножаются на исходную карту F .

Пространственное внимание. На вход подается карта признаков после канального внимания. Вычисляются среднее и максимальное значения по каналам, к которым конкатенируется расширенное значение pH, формируя трехканальный тензор. Свертка 1×7 с одним выходным каналом и последующая сигмоида дают пространственные веса:

$$M_s = \sigma\left(\text{Conv1d}_{3 \rightarrow 1}(S, k=7)\right).$$

Итоговый тензор получается умножением карты признаков на M_s . Таким образом, pH участвует в формировании как канальных, так и пространственных весов внимания на каждом остаточном блоке.

После прохождения четырех остаточных блоков выполняется глобальный усредняющий пулинг, преобразующий карту признаков размерности (B,512,16) в вектор (B,512). Полученный вектор подается на полносвязный слой без скрытых слоев:

$$\hat{y} = Wz + b, \quad \hat{y} \in \mathbb{R}^{B \times 3},$$

где $W \in \mathbb{R}^{3 \times 512}$, $b \in \mathbb{R}^3$ – обучаемые параметры.

Выходные значения соответствуют прогнозам нормализованных содержаний N, P, K. Для получения абсолютных величин применяется обратное преобразование с использованием сохраненного на этапе обучения StandardScaler.

В процессе обучения используется среднеквадратичная ошибка (MSE), суммированная по трем целевым переменным (5):

$$L = \frac{1}{B} \sum_{i=1}^B \sum_{j \in \{N, P, K\}} \left(y_{i,j} - \hat{y}_{i,j}\right)^2. \quad (5)$$

Оптимизация выполняется алгоритмом Adam с начальной скоростью обучения 1×10^{-3} и L2-регуляризацией 5×10^{-5} .

2.5. Дообучение на локальных данных

Предобученная на глобальном датасете LUCAS модель демонстрирует высокие показатели точности при прогнозировании свойств европейских почв. Однако при переносе на образцы, отобранные в центральной части России, происходит значительное снижение качества предсказаний. Основная причина заключается в различиях минералогического состава, гранулометрических характеристик и спектральных свойств почв, обусловленных разными

почвообразующими породами и климатическими условиями. Для преодоления этого эффекта применяется стратегия дообучения (fine-tuning) на локальной выборке, насчитывающей 100 образцов с известными спектральными характеристиками и результатами химического анализа. На рисунке 4 представлена схема предлагаемого процесса дообучения.



Рис. 4. Схема процесса дообучения (fine-tuning) на локальных данных

Подготовка данных и стратегия заморозки слоев. Все локальные образцы проходят единый конвейер предобработки (раздел 1.2). Выборка стратифицированно разделяется на обучающую (70 образцов), валидационную (15) и тестовую (15) подмножества. Целевые переменные (N, P, K) стандартизируются с использованием параметров, полученных из дата-сета LUCAS, что сохраняет единое масштабное пространство.

Полная модель содержит более 10 млн параметров, и прямое дообучение всех слоев на 70 образцах приводит к переобучению. Поэтому применяется частичная заморозка: первые два остаточных блока и начальный сверточный слой остаются неизменными, а третий и четвертый остаточные блоки, модули СВМ внутри них и выходной полносвязный слой дообучаются. Такая стратегия сохраняет универсальные низкоуровневые спектральные признаки и адаптирует только высокоуровневые представления.

Гиперпараметры и процесс дообучения. Дообучение выполняется с использованием следующих гиперпараметров:

- 1) оптимизатор Adam с начальной скоростью обучения $\eta=1 \times 10^{-4}$;
- 2) размер мини-батча = 8;
- 3) L2-регуляризация 5×10^{-5} ;
- 4) планировщик ReduceLROnPlateau (фактор 0.5, терпение 5 эпох);
- 5) ранняя остановка при отсутствии улучшения RMSE на валидации в течение 20 эпох.

эпох.

Процесс дообучения описывается стандартным правилом обновления параметров (6):

$$\theta^{(t+1)} = \theta^{(t)} - \eta \cdot \frac{m_t}{\sqrt{v_t + \varepsilon}}, \quad (6)$$

где для замороженных параметров θ_{frozen} градиенты не вычисляются:

$$\frac{\partial L}{\partial \theta_k} = 0 \quad \forall \theta_k \in \theta_{\text{frozen}}$$

Оценка эффективности. Для количественного анализа сравниваются три сценария: исходная предобученная модель (без адаптации), модель после дообучения и традиционные методы (PLSR, случайный лес), обученные только на локальных данных. Оценка выполняется по метрикам R^2 , RMSE и RPD. Ожидается, что дообученная модель существенно превзойдет исходную и, благодаря трансферу знаний, покажет лучшую обобщающую способность, чем методы, обученные с нуля на малой выборке.

3. Анализ результатов

Для количественной оценки качества прогнозирования в работе используются две стандартные метрики регрессионных задач спектроскопического анализа почв. Коэффициент детерминации R^2 показывает долю дисперсии целевой переменной, объясненную моделью (7):

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2}, \quad (7)$$

где y_i – измеренное значение, \hat{y}_i – предсказанное моделью, \bar{y}_i – среднее арифметическое.

Относительное отклонение прогноза RPD (Ratio of Performance to Deviation). Он показывает, во сколько раз разброс данных превышает ошибку модели (8):

$$RPD = \frac{SD}{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y}_i)^2} \bigg/ \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (8)$$

Принято интерпретировать значения RPD согласно классификации, приведенной в таблице 2.

Таблица 2. Классификационные уровни относительного отклонения прогноза (RPD).

RPD	Оценка	Показатель
$RPD > 3$	Отличная модель	A
$2.5 < RPD < 3$	Хорошая модель	B
$2.0 < RPD < 2.5$	Удовлетворительная модель	C
$RPD < 2$	Неудовлетворительная модель	D

Значения R^2 интерпретируются просто, чем ближе к единице, тем точнее модель воспроизводит изменчивость целевого параметра. RPD же показывает, во сколько раз размах данных превышает ошибку прогноза. Вместе эти метрики дают полное представление о качестве регрессии. Именно поэтому в спектроскопии почв принято приводить обе.

Для оценки эффективности предложенного подхода проведена серия экспериментов.

Первый этап. Мы обучили модель на глобальном наборе LUCAS и проверили ее на интерполированных спектрах (450–1667 нм, 500 точек). На тестовой части LUCAS модель неплохо предсказала азот – $R^2=0,82$, $RPD=2,33$ (это категория «удовлетворительно» по таблице 2). А вот для фосфора и калия метрики оказались низкими: для P – $R^2=0,27$, $RPD=1,16$;

для К – $R^2=0,25$, $RPD=1,15$ (категория D, неудовлетворительно). Это говорит о том, что используемый спектральный диапазон слабо чувствителен к фосфору и калию, а глобальная библиотека LUCAS не очень информативна для этих элементов.

Второй этап. Ту же самую предобученную модель (без всякой адаптации) мы применили локальной выборке из 100 образцов – Воронежская, Курская, Ростовская области, Краснодарский край. На тестовом подмножестве (15 образцов) точность оказалась крайне неудовлетворительной. Для азота R^2 упал до 0,21 ($RPD=1,14$), для фосфора – до 0,07 ($RPD=0,25$), для калия – до 0,02 ($RPD=0,18$). Все три показателя RPD попали в категорию D (неудовлетворительно). Причина такого резкого падения – разница в минералогии, гранулометрии и спектрах почв центральной России по сравнению с теми, что были в обучающем наборе LUCAS.

Третий этап. Мы дообучили (fine-tuning) предобученную модель на локальной обучающей выборке (70 образцов). И применили стратегию: заморозили первые два остаточных блока и начальный сверточный слой, а третий и четвертый блоки, а также выходной слой обучали. Гиперпараметры дообучения: скорость обучения 1×10^{-4} , батч-размер 8, L2-регуляризация 5×10^{-5} , ранняя остановка (20 эпох без улучшения валидационной ошибки). После дообучения модель снова протестировали на тех же 15 локальных образцах.

Результаты (таблица 3) значительно улучшились. Для азота достигнуто отличное качество: $R^2=0,91$, $RPD=3,01$ (категория A). Для фосфора – удовлетворительная: $R^2=0,56$, $RPD=2,4$ (категория C, почти B). Для калия оценка остается неудовлетворительная: $R^2=0,41$, $RPD=1,56$ (категория D). Значит, дообучение помогло модели подстроиться под региональные особенности почвы и сделать модель применимым к использованию в полевых условиях с портативным спектрометром – особенно для оценки азота.

Визуальное сравнение трех сценариев представлено на полярных диаграммах. Рисунок 5 отображает значения коэффициента детерминации R^2 и значения RPD для N, P и K.

Таблица 3. Сравнение метрик модели на разных этапах

Параметр	N (азот)	P (фосфор)	K (калий)
На тестовой выборке LUCAS (после интерполяции)			
R^2	0,82	0,27	0,25
RPD	2,33	1,16	1,15
На локальной выборке (без дообучения)			
R^2	0,21	0,07	0,02
RPD	1,14	0,25	0,18
На локальной выборке (после дообучения)			
R^2	0,91	0,56	0,41
RPD	3,01	2,40	1,56

На графике хорошо видно, что после дообучения радиальная координата значительно увеличивается, особенно для азота и фосфора. Дополнительно на рисунке 6 приведены точечные диаграммы «предсказание – истина» для N, P и K после дообучения. Точки плотно ложатся на диагональ, что подтверждает высокую точность прогнозов для азота и приемлемую – для фосфора.



Рис. 5. Полярная диаграмма сравнения значение коэффициента детерминации R^2 и относительного отклонения прогноза (RPD)

В итоге обсуждая проблему переносимости моделей спектроскопии почв, можно предварительно решить через fine-tuning даже на небольшой локальной выборке (70 образцов). По калию точность остается низкой ($RPD=1,56$) – вероятно, из-за короткого диапазона прибора (450–1667 нм) и слабой спектральной выраженности калия в этой области. В будущем стоит расширить диапазон до коротковолнового ИК (2500 нм) или добавить в модель другие параметры (органическое вещество, карбонаты и др.) – они могут быть косвенными маркерами калия. А для азота и фосфора предложенная адаптированная модель пригодна для точного земледелия с портативными спектрометрами ($RPD > 2,4$ для фосфора и > 3 для азота).




Рис. 6. Точечные диаграммы «предсказание – истина» для содержания N, P и K на тестовой выборке локальных образцов после дообучения

Заключение

В представленной работе рассмотрена возможность адаптации модели глубокого обучения, предварительно обученной на глобальной спектральной библиотеке LUCAS, для прогнозирования содержания азота, фосфора и калия в почвах центральной России по данным спектроскопии в видимом и ближнем инфракрасном диапазонах. Исследование показало, что прямое применение модели, обученной на европейских образцах, к почвам Воронежской, Курской, Ростовской областей и Краснодарского края сопровождается существенным снижением точности прогнозов. Для преодоления указанного эффекта предложена стратегия частичного дообучения (fine-tuning) с заморозкой первых двух остаточных блоков и началь-

ного сверточного слоя, что позволило сохранить универсальные спектральные признаки, извлеченные из больших данных, и адаптировать высокоуровневые представления под региональную специфику.

Эксперименты показали, что после дообучения на локальной выборке из 70 образцов достигается значительное улучшение метрик. Для азота коэффициент детерминации возрос с 0,21 до 0,91, а относительное отклонение прогноза – с 1,14 до 3,01, что соответствует отличной прогностической способности. Для фосфора зафиксирован рост R^2 с 0,07 до 0,56, RPD – с 0,25 до 2,40 (удовлетворительная модель, близкая к хорошей). По калию улучшение менее выражено: R^2 увеличился с 0,02 до 0,41, RPD – с 0,18 до 1,56, что указывает на сохраняющиеся ограничения. Полученные результаты позволяют предположить, что предложенный подход может быть использован для оперативной полевой оценки азота и, в определенной степени, фосфора с применением портативных спектрометров.

Вместе с тем, недостаточно высокая точность прогнозирования калия, вероятно, связана с ограниченным спектральным диапазоном использованного прибора (450–1667 нм) и слабой спектральной выраженностью данного элемента в указанной области. Дальнейшие исследования могут быть направлены на расширение спектрального окна в коротковолновую инфракрасную область, включение в модель дополнительных почвенных параметров (органическое вещество, карбонаты), а также на апробацию метода на других типах почв центральной России. Разработанная программная реализация на базе PyTorch представляет интерес для интеграции в системы точного земледелия и роботизированные платформы мониторинга почвы.

Литература

1. *Shin S. K., Lee S. J., Park J. H.* Prediction of Soil Properties Using Vis-NIR Spectroscopy Combined with Machine Learning: A Review // *Sensors*. 2025. Vol. 25. 5045. DOI: 10.3390/s25165045.
2. *Сироткин В. В., Васюков С. В., Усманов Б. М.* Изучение почвенных параметров на основе полевых спектрометрических данных // *Вестник Удмуртского университета. Серия: Биология. Науки о Земле*. 2020. Т. 30, № 1. С. 71–82. DOI: 10.35634/2412-9518-2020-30-1-71-82.
3. *Viscarra Rossel R. A., Behrens T.* Using data mining to model and interpret soil diffuse reflectance spectra // *Geoderma*. 2010. Vol. 158, no. 1–2. P. 46–54. DOI: 10.1016/j.geoderma.2009.12.025.
4. *de Santana F. B., de Souza A. M., Poppi R. J.* Visible and near Infrared Spectroscopy Coupled to Random Forest to Quantify Some Soil Quality Parameters // *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy*. 2018. Vol. 191. P. 454–462. DOI: 10.1016/j.saa.2017.10.052.
5. *Chen S., Li S., Ma W. et al.* Rapid determination of soil classes in soil profiles using vis–NIR spectroscopy and multiple objectives mixed support vector classification // *European Journal of Soil Science*. 2019. Vol. 70, no. 1. P. 42–53. DOI: 10.1111/ejss.12715.
6. *Tóth G., Jones A., Montanarella L. (eds.)*. LUCAS Topsoil Survey. Methodology, data and results. Luxembourg: Publications Office of the European Union, 2013. 141 p. (EUR 26102). DOI: 10.2788/97922.
7. *Kattenborn T., Leitloff J., Schiefer F., Hinz S.* Review on Convolutional Neural Networks (CNN) in Vegetation Remote Sensing // *ISPRS Journal of Photogrammetry and Remote Sensing*. 2021. Vol. 173. P. 24–49. DOI: 10.1016/j.isprsjprs.2020.12.010.
8. *He K., Zhang X., Ren S., Sun J.* Deep Residual Learning for Image Recognition // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA, 2016. P. 770–778. DOI: 10.48550/arXiv.1512.03385.

9. Ng W., Minasny B. Convolutional neural network for simultaneous prediction of several soil properties using visible/near-infrared, mid-infrared, and their combined spectra // *Geoderma*. 2019. Vol. 352. P. 251–267. DOI: 10.1016/j.geoderma.2019.06.016.
10. Woo S., Park J., Lee J.-Y., Kweon I. S. CBAM: Convolutional Block Attention Module // *arXiv*. 2018. 1807.06521. DOI: 10.48550/arXiv.1807.06521.
11. Wang X., Zhang M.-W., Zhou Y.-N. et al. Simultaneous estimation of multiple soil properties from vis-NIR spectra using a multi-gate mixture-of-experts with data augmentation // *Geoderma*. 2024. Vol. 445. 116888. DOI: 10.1016/j.geoderma.2024.117127.
12. Zhong L., Guo X., Xu Z., Ding M. Soil properties: Their prediction and feature extraction from the LUCAS spectral library using deep convolutional neural networks // *Geoderma*. 2021. Vol. 402. 115366. DOI: 10.1016/j.geoderma.2021.115366.
13. Новоселов И. Е., Бакланова О. Е. Программная реализация модели глубокого обучения для прогнозирования свойств почвы на основе данных спектроскопии // *Вестник Российского нового университета. Серия: Сложные системы: модели, анализ, управление*. 2025. № 3. С. 125–139. DOI: 10.18137/RNUV9187.25.03.P.125.
14. Буряк Ж. А., Гафуров А. М. Оценка спектрально-отражательных свойств эродированных агропочв Республики Татарстан // *Региональные геосистемы*. 2025. Т. 49, № 3. С. 517–532. DOI: 10.52575/2712-7443-2025-49-3-517-532.
15. Горохова И. Н., Хитров Н. Б. Распознавание каменистых, песчаных и карбонатных с поверхности почв на юге Приволжской возвышенности (Волгоградская область) по космическим снимкам // *Почвоведение*. 2023. № 11. С. 1340–1356. DOI: 10.31857/S0032180X23600609.

Новоселов Илья Евгеньевич

ведущий инженер-программист, ООО «Когнитив Роботикс» (Россия г. Москва, 3-Я Рыбинская ул., д. 17), e-mail: novoselov-ie@yandex.ru. ORCID: 0009-0006-3920-0183.

Бакланова Ольга Евгеньевна

канд. физ.-мат. наук, доцент института прикладной математики и компьютерных наук, ФГАОУ ВО ТГУ (Россия, 634050, г. Томск, пр. Ленина, дом 36), e-mail: oebaklanova@mail.ru. ORCID: 0000-0001-8734-2596

Авторы прочитали и одобрили окончательный вариант рукописи.

Авторы заявляют об отсутствии конфликта интересов.

Вклад соавторов: Каждый автор внес равную долю участия как во все этапы проводимого теоретического исследования, так и при написании разделов данной статьи.

Adaptation of a ResNet-based deep learning model for predicting chemical properties of soils in central Russia using spectroscopy data

Ilya Novoselov, Olga Baklanova

National Research Tomsk State University, Russia, 634050, Tomsk, Lenin Ave., 36.

Abstract: The paper presents adaptation of a deep learning model based on residual neural network ResNet with CBAM attention modules for predicting nitrogen, phosphorus and potassium content in soils of central Russia using visible and near-infrared spectroscopy. The model pre-trained on the global LUCAS library was fine-tuned on a local sample of 100 soil samples from Voronezh, Kursk, Rostov regions and Krasnodar Krai. A partial layer freezing strategy was applied. After fine-tuning, the coefficient of determination of 0.91 and the ratio of performance to deviation of 3.01 were achieved for nitrogen, and 0.56 and 2.40 for phosphorus, respectively. The possibility of using portable spectrometers in precision farming systems is shown.

Keywords: deep learning, residual neural networks, attention, fine-tuning, soil, spectroscopy.

For citation: Novoselov I., Baklanova O. Adaptation of a ResNet-based deep learning model for predicting chemical properties of soils in central Russia using spectroscopy data *Vestnik SibGUTI*, 2026, vol. 20, no. 2, pp. 93-106. <https://doi.org/10.55648/1998-6920-2026-20-2-93-106>.



Content is available under the license
Creative Commons Attribution 4.0
License

© Novoselov I., Baklanova O., 2026

The article was submitted: 24.04.2026;
revised version: 30.04.2026;
accepted for publication 28.05.2026.

References

1. Shin S. K., Lee S. J., Park J. H. Prediction of Soil Properties Using Vis-NIR Spectroscopy Combined with Machine Learning: A Review. *Sensors*, 2025, vol. 25, 5045. DOI: 10.3390/s25165045.
2. Sirotkin V. V., Vasyukov S. V., Usmanov B. M. Izuchenie pochvennykh parametrov na osnove polevykh spektrometricheskikh dannykh [Study of soil parameters based on field spectrometric data]. *Vestnik Udmurtskogo universiteta. Seriya: Biologiya. Nauki o Zemle*, 2020, vol. 30, no. 1, pp. 71-82. DOI: 10.35634/2412-9518-2020-30-1-71-82.
3. Viscarra Rossel R. A., Behrens T. Using data mining to model and interpret soil diffuse reflectance spectra. *Geoderma*, 2010, vol. 158, no. 1-2, pp. 46–54. DOI: 10.1016/j.geoderma.2009.12.025.
4. de Santana F. B., de Souza A. M., Poppi R. J. Visible and near Infrared Spectroscopy Coupled to Random Forest to Quantify Some Soil Quality Parameters. *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy*, 2018, vol. 191, pp. 454-462. DOI: 10.1016/j.saa.2017.10.052.
5. Chen S., Li S., Ma W., et al. Rapid determination of soil classes in soil profiles using vis-NIR spectroscopy and multiple objectives mixed support vector classification. *European Journal of Soil Science*, 2019, vol. 70, no. 1, pp. 42-53. DOI: 10.1111/ejss.12715.
6. Tóth G., Jones A., Montanarella L., eds. *LUCAS Topsoil Survey. Methodology, Data and Results*. Luxembourg, Publications Office of the European Union, 2013. 141 p. (EUR 26102). DOI: 10.2788/97922.
7. Kattenborn T., Leitloff J., Schiefer F., Hinz S. Review on Convolutional Neural Networks (CNN) in Vegetation Remote Sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2021, vol. 173, pp. 24-49. DOI: 10.1016/j.isprsjprs.2020.12.010.
8. He K., Zhang X., Ren S., Sun J. Deep Residual Learning for Image Recognition. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA, 2016, pp. 770-778. DOI: 10.48550/arXiv.1512.03385.
9. Ng W., Minasny B. Convolutional neural network for simultaneous prediction of several soil properties using visible/near-infrared, mid-infrared, and their combined spectra. *Geoderma*, 2019, vol. 352, pp. 251-267. DOI: 10.1016/j.geoderma.2019.06.016.
10. Woo S., Park J., Lee J.-Y., Kweon I. S. CBAM: Convolutional Block Attention Module. *arXiv*, 2018, 1807.06521. DOI: 10.48550/arXiv.1807.06521.
11. Wang X., Zhang M.-W., Zhou Y.-N., et al. Simultaneous estimation of multiple soil properties from vis-NIR spectra using a multi-gate mixture-of-experts with data augmentation. *Geoderma*, 2024, vol. 445, 116888. DOI: 10.1016/j.geoderma.2024.117127.
12. Zhong L., Guo X., Xu Z., Ding M. Soil properties: Their prediction and feature extraction from the LUCAS spectral library using deep convolutional neural networks. *Geoderma*, 2021, vol. 402, 115366. DOI: 10.1016/j.geoderma.2021.115366.
13. Novoselov I. E., Baklanova O. E. Programmynaya realizatsiya modeli glubokogo obucheniya dlya prognozirovaniya svoystv pochvy na osnove dannykh spektroskopii [Software implementation of a deep learning model for predicting soil properties based on spectroscopy data]. *Vestnik Rossiyskogo novogo universiteta. Seriya: Slozhnye sistemy: modeli, analiz, upravlenie*, 2025, no. 3, pp. 125-139. DOI: 10.18137/RNUV9187.25.03.P.125.
14. Buryak Zh. A., Gafurov A. M. Otsenka spektral'no-otrazhatel'nykh svoystv erodirovannykh agropochv Respubliki Tatarstan [Assessment of spectral-reflective properties of eroded agricultural soils of the

- Republic of Tatarstan]. *Regional'nye geosistemy*, 2025, vol. 49, no. 3, pp. 517-532. DOI: 10.52575/2712-7443-2025-49-3-517-532.
15. Gorokhova I. N., Khitrov N. B. Raspoznavanie kamenistykh, peschanykh i karbonatnykh s poverkhnosti pochv na yuge Privolzhskoy vozvyshennosti (Volgogradskaya oblast') po kosmicheskim snimkam [Recognition of stony, sandy, and calcareous surface soils in the south of the Volga Upland (Volgograd region) from satellite images]. *Pochvovedenie*, 2023, no. 11, pp. 1340-1356. DOI: 10.31857/S0032180X23600609.

Ilya Novoselov

Senior Software Engineer, Cognitive Robotics LLC, (Russia, Moscow, 3rd Rybinskaya St., 17),
e-mail: novoselov-ie@yandex.ru

Olga Baklanova

Cand. of Sci. (Physics and Mathematics), Associate professor at the Institute of Applied Mathematics and Computer Science, Tomsk State University, (Russia, 634050, Tomsk, Lenin Ave., 36),
e-mail: oebaklanova@mail.ru.