

Новоселов Илья Евгеньевич

аспирант Института прикладной математики и компьютерных наук, Томский государственный университет, город Томск; ведущий инженер-программист, ООО «Когнитив Роботикс», Москва. ORCID: 0009-0006-3920-0183

Электронный адрес: novoselov-ie@yandex.ru

Ца Е. Novoselov

Postgraduate, Institute of applied mathematics and computer science, Tomsk State University, Tomsk; Senior Software Engineer, Cognitive Robotics LLC, Moscow. ORCID: 0009-0006-3920-0183

E-mail address: novoselov-ie@yandex.ru

Бакланова Ольга Евгеньевна

кандидат физико-математических наук, доцент Института прикладной математики и компьютерных наук, Томский государственный университет, город Томск. ORCID: 0000-0001-8734-2596

Электронный адрес: oebaklanova@mail.ru

Olga E. Baklanova

Ph.D. of Physico-Mathematical Sciences, Associate Professor at the Institute of applied mathematics and computer science, Tomsk State University, Tomsk. ORCID: 0000-0001-8734-2596

E-mail address: oebaklanova@mail.ru

ПРОГРАММНАЯ РЕАЛИЗАЦИЯ МОДЕЛИ ГЛУБОКОГО ОБУЧЕНИЯ ДЛЯ ПРОГНОЗИРОВАНИЯ СВОЙСТВ ПОЧВЫ НА ОСНОВЕ ДАННЫХ СПЕКТРОСКОПИИ

Аннотация. В статье представлена разработка и программная реализация модели глубокого обучения для прогнозирования свойств почвы на основе данных спектроскопии в видимом и ближнем инфракрасном диапазонах. Актуальность исследования обусловлена потребностью современного сельского хозяйства в оперативном анализе почвенных характеристик для оптимизации ресурсов и повышения урожайности. Цель работы – создание эффективной модели, использующей архитектуру остаточных нейронных сетей с модулем внимания блочной свёртки и учётом кислотности почвы. Для обучения и тестирования применён набор данных LUCAS, включающий спектры и физико-химические свойства более 20 000 образцов почвы. Методы включают предварительную обработку данных (удаление выбросов, сглаживание, нормализацию, интерполяцию до 500 точек) и реализацию на языке Python с библиотекой PyTorch. Результаты демонстрируют высокую точность прогнозирования органического углерода, карбонатов кальция и азота (коэффициент детерминации выше 0,9) с улучшением предсказаний за счёт учёта кислотности в механизме внимания. Новизна заключается в интеграции кислотности в модель и адаптации к портативным спектрометрам. Практическая значимость заключается в возможности применения в системах точного земледелия и роботизированных платформах для мониторинга почвы.

Ключевые слова: точное земледелие, мониторинг почвы, глубокое обучение, остаточные нейронные сети, модуль внимания, прогнозирование свойств, спектроскопия.

Для цитирования: 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/RNU.V9I187.25.03.P.125

SOFTWARE IMPLEMENTATION OF A DEEP LEARNING MODEL FOR PREDICTING SOIL PROPERTIES BASED ON SPECTROSCOPY DATA

Abstract. The article presents the development and software implementation of a deep learning model for predicting soil properties based on visible and near-infrared spectroscopy data. The study's relevance stems from modern agriculture's need for rapid soil property analysis to optimize resource management and enhance crop yields. The objective is to create an efficient model utilizing the residual neural network architecture with a convolutional block attention module and soil acidity consideration. The LUCAS dataset, comprising spectra and physicochemical properties of over 20,000 soil samples, was used for training and testing. Methods involve data preprocessing (outlier removal, smoothing, normalization, interpolation to 500 points) and implementation in Python using the PyTorch library. The results show high accuracy in predicting organic carbon, calcium carbonates, and nitrogen (determination coefficient above 0.9), with improved predictions due to acidity integration into the attention mechanism. The novelty lies in incorporating acidity into the model and adapting it for portable spectrometers. Practical significance includes its potential application in precision agriculture systems and robotic platforms for soil monitoring.

Keywords: precision agriculture, soil monitoring, deep learning, residual neural networks, attention module, property prediction, spectroscopy.

For citation: Novoselov I.E., Baklanova O.E. (2025) Software implementation of a deep learning model for predicting soil properties based on spectroscopy data. *Vestnik of Russian New University. Series: Complex Systems: Models, analysis, management.* No. 3. Pp. 125 – 139. DOI: 10.18137/RNU.V9I87.25.03.P.125 (In Russian).

Введение

Современное сельское хозяйство требует точного и оперативного анализа почвенных свойств для оптимизации управления ресурсами и повышения урожайности. Спектроскопия в видимом и ближнем инфракрасном диапазонах (Vis-NIR) является перспективным методом, позволяющим быстро оценивать химический состав почвы без длительных лабораторных исследований [1]. Однако анализ спектральных данных осложняется шумами, перекрывающимися полосами поглощения и влиянием факторов, таких как кислотность почвы (далее – pH), которая существенно коррелирует с доступностью питательных элементов [2].

Традиционные методы, такие как частичная регрессия наименьших квадратов (PLSR) и метод опорных векторов (SVM), демонстрируют ограниченную эффективность при обработке больших объемов данных и сложных нелинейных зависимостей [3; 4]. В последние годы глубокое обучение, в частности, сверточные нейронные сети (CNN) с архитектурой ResNet, зарекомендовало себя как мощный инструмент для извлечения признаков из спектральных данных [5]. Добавление механизмов внимания, таких как СВМ (Convolutional Block Attention Module), позволяет модели фокусироваться на ключевых спектральных диапазонах, повышая точность прогнозирования [6]. Исследования также показывают, что на состав почвы сильно влияют значения влажности и pH, а их учет улучшает предсказательные способности моделей, поскольку они воздействуют на характеристики почвы [7–9].

В данной работе представлена программная реализация модели глубокого обучения на основе ResNet с интегрированным СВМ и учетом данных pH для прогнозирования

Программная реализация модели глубокого обучения для прогнозирования
свойств почвы на основе данных спектроскопии

свойств почвы по данным спектроскопии LUCAS, включающим спектры более 20 000 образцов. Проведена предварительная обработка: удаление выбросов, сглаживание спектров методом Савицкого – Голея, нормализация и интерполяция до 500 точек для адаптации к портативным спектрометрам. Реализация выполнена на Python с использованием PyTorch. Результаты сравнивались с традиционными методами по метрикам R^2 и RPD, демонстрируя преимущества предложенного подхода.

1. Теоретические основы метода

1.1. Основы ResNet

Архитектура ResNet (Residual Network) была разработана для решения проблемы деградации точности в глубоких нейронных сетях. В традиционных сетях увеличение числа слоев часто приводит к затуханию градиента, что затрудняет обучение. ResNet использует остаточные связи (residual connections), которые позволяют пропускать сигнал через один или несколько слоев, обеспечивая возможность эффективного обучения глубоких моделей [5].

Основной элемент ResNet – остаточный блок, который можно описать формулой

$$y = F(x, \{W_i\}) + x, \quad (1)$$

где x – входной сигнал блока;

$F(x)$ – остаточная функция, представляющая собой преобразование входа;

y – выход блока.

Такая структура позволяет сети обучать разницу между входом и выходом, упрощая оптимизацию и позволяя строить сети с сотнями слоев. В предложенной модели остаточные блоки адаптированы для обработки одномерных спектральных данных Vis-NIR, что делает их подходящими для анализа сложных спектральных зависимостей [10].

1.2. Механизм внимания СВМ

Модуль СВМ (Convolutional Block Attention Module) улучшает извлечение признаков за счет применения механизмов внимания к каналам и пространственным характеристикам входных данных [6]. СВМ состоит из двух последовательных подмодулей:

Канальное внимание (Channel Attention) определяет, какие каналы (спектральные диапазоны) наиболее значимы для задачи. Оно использует глобальные статистики карты признаков:

$$M_c(F) = \sigma(MLP(AvgPool(F)) + MLP(MaxPool(F))), \quad (2)$$

где F – входная карта признаков;

$AvgPool$ и $MaxPool$ – операции усреднения и взятия максимума по пространственным измерениям;

MLP – многослойный перцептрон;

σ – сигмоидальная функция.

Пространственное внимание (Spatial Attention) фокусируется на ключевых участках вдоль спектральной оси:

$$M_s(F) = \sigma(f^{k \times 1}([AvgPool_c(F); MaxPool_c(F)])), \quad (3)$$

где операции $AvgPool_c$ и $MaxPool_c$ усредняют/максимизируют по каналам, после чего результат свёрткой $f^{k \times 1}$ (ядро размера $k \times 1$) преобразуется в карту внимания.

1.3. Применимость к спектральным данным и учет данных pH

Спектральные данные Vis-NIR содержат сложные нелинейные зависимости и перекрывающиеся полосы поглощения, что затрудняет их анализ традиционными методами, такими как PLSR [11]. ResNet благодаря своей глубокой архитектуре способен извлекать иерархические признаки из спектральных данных, моделируя сложные взаимосвязи между длинами волн и свойствами почвы.

Механизм СВАМ дополняет ResNet, позволяя модели сосредоточиваться на наиболее информативных участках спектра. Например, для предсказания содержания органического вещества модель может выделять диапазоны, связанные с углеродными связями, игнорируя шумовые области [12]. Такая комбинация делает подход особенно эффективным для анализа высокомерных спектральных данных.

Кислотность почвы играет ключевую роль в формировании спектральных характеристик, влияя на доступность питательных веществ и химические связи. В предложенной модели pH учитывается на нескольких уровнях.

В канальном внимании значение pH добавляется как дополнительный канал к входным данным:

$$F_{pH} = \text{Concat}(F, e_{pH}), \quad e_{pH} \in R^{1 \times L}, \quad (4)$$

где e_{pH} – расширенный вдоль длины спектра вектор-отображение pH.

После этого к F_{pH} применяется та же схема MLP для расчёта M_c .

В реализованной модели в классе Channel Attention:

```
ph_embed = ph_value.unsqueeze(-1).expand(-1, -1, x.size(2))
x_with_ph = torch.cat((x, ph_embed), dim=1)
```

Это позволяет модулю внимания учитывать влияние pH при выделении значимых спектральных диапазонов.

В пространственном внимании pH включается в карту внимания через конкатенацию:

$$F_{pH} = \text{Concat}(\text{AvgPool}_C(F), \text{MaxPool}_C(F), e_{pH}). \quad (5)$$

Код реализованной модели в классе Spatial Attention:

```
ph_embed = ph_value.unsqueeze(-1).expand(-1, 1, x.size(2))
x_with_ph = torch.cat([avg_out, max_out, ph_embed], dim=1)
```

В итоговой модели pH кодируется через полносвязные слои и объединяется с признаками перед финальным предсказанием:

```
ph_encoded = self.ph_encoder(ph_value.view(-1, 1))
combined = torch.cat((x, ph_encoded), dim=1)
```

Такой подход обеспечивает адаптацию модели к вариациям pH, улучшая точность предсказаний для различных типов почв.

Программная реализация модели глубокого обучения для прогнозирования свойств почвы на основе данных спектроскопии

2. Датасет LUCAS и предварительная обработка данных

Для проведения исследований использовался датасет LUCAS (Land Use/Cover Area Frame Survey), который содержит спектры и физико-химические свойства более 20 000 образцов почвы, собранных по всей территории Европейского союза [13]. Спектры почвенного покрытия измерены в диапазоне 400...2500 нм с шагом 0,5 нм, что обеспечивает детализированное представление видимого и ближнего инфракрасного диапазона (Vis-NIR). Каждый образец включает данные о содержании органического углерода (OC), азота (N), карбонатов кальция (CaCO_3), а также гранулометрический состав (глина, ил, песок) и pH.

На Рисунке 1 представлены примеры спектров из датасета LUCAS, где видно, что спектры имеют сложную структуру с множеством пиков и провалов, связанных с поглощением света различными химическими компонентами почвы.

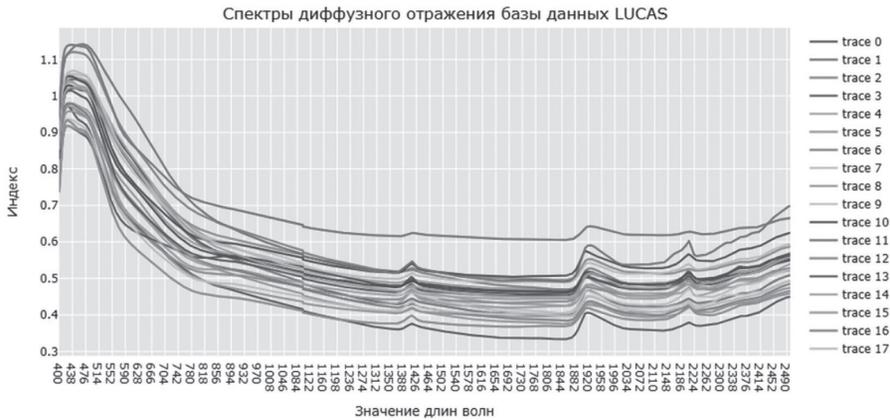


Рисунок 1. Примеры спектров из датасета LUCAS

Источник: здесь и далее рисунки выполнены авторами с использованием библиотек Python и данных спектроскопии LUCAS [13].

Для повышения качества анализа и улучшения производительности модели была проведена предварительная обработка данных, включающая следующие этапы.

2.1. Удаление выбросов

На начальном этапе были удалены экстремальные значения (выбросы) в данных. Для этого использовался анализ гистограмм распределения химических параметров (Рисунок 2). Выбросы могли быть вызваны ошибками измерения или нерепрезентативными образцами. Удаление таких данных позволяет улучшить стабильность модели и повысить точность прогнозирования.

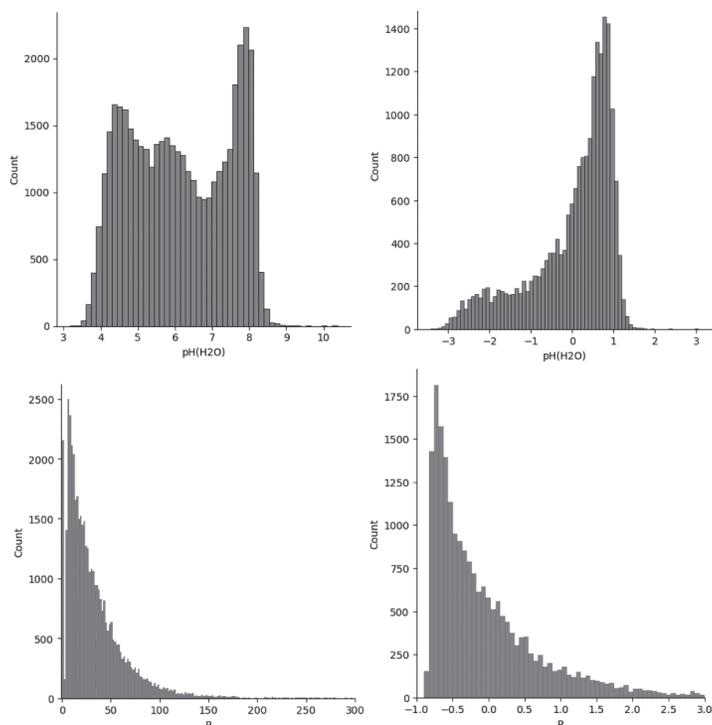


Рисунок 2. Гистограммы распределения содержания рН и Р почвы до (слева) и после (справа) удаления выбросов

2.2. Нормализация и стандартизация данных

Для приведения данных к единому масштабу и улучшения сходимости алгоритма обучения была применена нормализация спектров и стандартизация химических параметров.

Нормализация спектров выполнялась с использованием MinMaxScaler, который преобразует данные в диапазон $[0, 1]$, по формуле

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}}, \quad (6)$$

где X – исходное значение спектра;

X_{min} и X_{max} – минимальное и максимальное значения спектра.

Стандартизация химических параметров проводилась с помощью StandardScaler, который приводит данные к распределению с нулевым средним и единичной дисперсией:

$$X_{norm} = \frac{X - \mu}{\sigma}, \quad (7)$$

где μ – среднее значение;

σ – стандартное отклонение.

2.3. Интерполяция спектров

Для адаптации модели к портативным спектрометрам, которые имеют ограниченное количество точек измерения, была выполнена интерполяция спектров. Исходные спектры, содержащие 4200 точек, были сокращены до 500 точек с использованием кубической интерполяции. Это позволило уменьшить размерность данных без потери ключевых

Программная реализация модели глубокого обучения для прогнозирования
свойств почвы на основе данных спектроскопии

спектральных особенностей. Интерполяция проводилась по формуле

$$S_i(x) = a_i + b_i(x - x_i) + c_i(x - x_i)^2 + d_i(x - x_i)^3, \quad (8)$$

где a_i, b_i, c_i, d_i – коэффициенты сплайна, определяемые из условий непрерывности и гладкости.

Интерполяция спектров была выполнена с целью адаптации модели к данным, полученным с помощью портативных спектрометров, которые обычно имеют меньшее количество точек измерения (около 500). Это позволяет использовать модель в полевых условиях для оперативного анализа почвенных свойств.

3. Архитектура модели

Ниже представлена структура модели ResNet_CBAM, разработанной для прогнозирования свойств почвы на основе спектральных данных Vis-NIR с учетом pH. Модель реализована на Python с использованием библиотеки PyTorch. Таблица 1 описывает последовательность слоев и их параметры, включая входные и выходные размерности, а также роль pH в архитектуре.

Таблица 1

Структура модели ResNet_CBAM с учетом pH почвы

№	Модуль	Вход	Операция	Выход	Примечание
1	Input	(batch, C=4, L=500)	–	(batch, 4, 500)	4 канала спектра
2	Conv1 + MaxPool	(batch, 4, 500)	Conv1d(4→64, k=7, s=2, p=3) → BN → ReLU → MaxPool1d(k=3, s=2, p=1)	(batch, 64, 125)	Уменьшение разрешения в ×4
3	ResNet_CBAM_Block 1	(batch, 64, 125)	Два Conv1d(64→64, k=3, s=1, p=1) → BN → ReLU + CBAM(64, pH)	(batch, 64, 125)	Первый блок без down-sampling
4	ResNet_CBAM_Block 2	(batch, 64, 125)	Conv1d(64→128, k=3, s=2, p=1) → BN → ReLU Conv1d(128→128, k=3, s=1, p=1) → BN + CBAM(128, pH)	(batch, 128, 63)	Понижение длины ×2, channels→128
5	ResNet_CBAM_Block 3	(batch, 128, 63)	Аналогично блоку 2: 128→256, stride=2 + CBAM(256, pH)	(batch, 256, 32)	Дальнейшее уменьшение L×2, channels→256
6	ResNet_CBAM_Block 4	(batch, 256, 32)	Аналогично: 256→512, stride=2 + CBAM(512, pH)	(batch, 512, 16)	Последний ResNet_CBAM блок
7	Глобальный AvgPool	(batch, 512, 16)	AdaptiveAvgPool1d(output_size=1)	(batch, 512, 1)	Усреднение по длине
8	Flatten	(batch, 512, 1)	view(-1, 512)	(batch, 512)	Вектор признаков
9	pH-энкодер	(batch, 1)	Linear(1→64) → ReLU → Linear(64→128)	(batch, 128)	Кодирование дополнительного параметра pH

Продолжение таблицы 1

№	Модуль	Вход	Операция	Выход	Примечание
10	Конкатенация	(batch, 512) и (batch, 128)	<code>torch.cat([features, ph_encoded], dim=1)</code>	(batch, 640)	Объединение спектральных и рН признаков
11	Выходной линейный слой (FC)	(batch, 640)	<code>Linear(640→output_size)</code>	(batch, output_size)	output_size – число предсказываемых свойств

Источник: здесь и далее таблицы составлены авторами.

Пояснение

В – размер батча (batchsize).

Входные данные: спектральные данные размером (В, 4, 500), где 4 канала (исходный спектр, производная, вейвлет-преобразование и т. д.) и рН как скаляр (В, 1).

Каждый блок ResNet_CBAM_Block включает два сверточных слоя с нормализацией (BatchNorm) и активацией ReLU, а также модуль СВАМ, интегрирующий рН через канальное и пространственное внимание.

Модуль СВАМ состоит:

- из *канального внимания* – уменьшение числа каналов (ratio = 8) с учетом рН, добавленного как дополнительный канал (см. Рисунок 3);
- *пространственного внимания* – свертка с ядром 7 и учетом рН через конкатенацию.

Кодировщик рН преобразует скалярное значение рН в вектор признаков, который объединяется с результатами спектрального анализа перед финальным предсказанием (см. Рисунок 4).

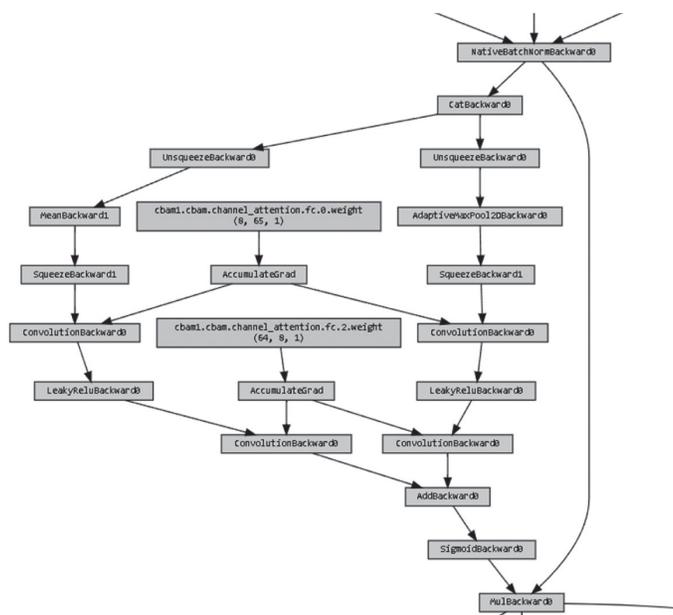


Рисунок 3. Схема блока СВАМ канального внимания

Программная реализация модели глубокого обучения для прогнозирования свойств почвы на основе данных спектроскопии

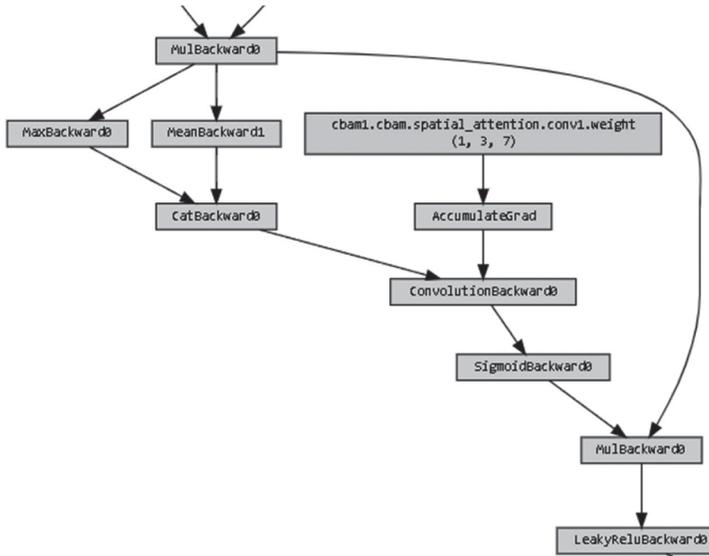


Рисунок 4. Схема блока СВМ пространственного внимания

3.1. Описание работы модели

Модель принимает спектральные данные размером (B, 4, 500) и значения pH (B, 1). Начальный сверточный слой и пулинг извлекают низкоуровневые признаки, уменьшая пространственную размерность. Последующие блоки ResNet_CBAM с остаточными связями и модулями внимания СВМ, учитывающими pH, постепенно увеличивают число каналов и извлекают высокоуровневые признаки. Глобальный пулинг формирует компактный вектор признаков, который объединяется с закодированным pH. Финальный полносвязный слой предсказывает шесть свойств почвы: органический углерод (OC), азот (N), карбонаты кальция (CaCO_3), фосфор (P), калий (K) и pH.

4. Оценка модели

В этом исследовании в качестве метрик оценки производительности используются: коэффициент детерминации (R^2), корень среднеквадратичной ошибки (RMSE) и относительное отклонение прогноза (RPD). R^2 используется для оценки соответствия между прогнозируемыми значениями модели и фактическими наблюдениями, при этом значения, приближающиеся к 1, указывают на большую точность модели. RMSE представляет собой среднее отклонение между прогнозируемыми и фактическими значениями, при этом более низкие значения означают более высокую производительность. RPD, рассчитанный как отношение стандартного отклонения к RMSE, используется для оценки точности модели, где значение больше 2 предполагает расширенные возможности прогнозирования. Их формулы расчета приведены в следующих уравнениях:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2}; \quad (9)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}; \quad (10)$$

$$RPD = \frac{SD}{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y}_i)^2} / \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}. \quad (11)$$

При прогнозной оценке моделей RPD является важным показателем для оценки точности модели. Чем выше значение RPD, тем лучше прогностическая способность модели (см. Таблицу 3). В частности, RPD больше 3 указывает на то, что модель является отличной моделью (ранг А); RPD от 2,5 до 3,0 – что модель является хорошей моделью (ранг В); RPD от 2,0 до 2,5 – что модель является приблизительной моделью (ранг С); RPD менее 2,0 – что модель неудовлетворительна (ранг D).

Таблица 2

Классификационные уровни относительного отклонения прогноза (RPD)

RPD	Значение	Показатель
RPD > 3	Отличная модель	А
2,5 < RPD < 3	Хорошая модель	В
2,0 < RPD < 2,5	Удовлетворительная модель	С
RPD < 2	Неудовлетворительная модель	Д

5. Результаты

В данном исследовании проведена оценка эффективности модели ResNet на двух наборах данных: оригинальных спектрах (4200 точек) и интерполированных спектрах (500 точек). Для оценки качества модели использовались метрики R^2 (коэффициент детерминации) и RPD (отношение прогноза к отклонению). Результаты показали, что интерполяция спектров не привела к значительной потере точности модели, что подтверждает возможность использования интерполированных данных для анализа с помощью портативных спектрометров.

На Рисунке 5 представлены точечные диаграммы, демонстрирующие корреляцию между измеренными и предсказанными значениями для ключевых параметров почвы: органического углерода (ОС), карбонатов кальция (CaCO_3), азота (N), фосфора (P) и калия (K). Видно, что модель демонстрирует высокую точность для ОС, CaCO_3 и N с коэффициентами детерминации (R^2) выше 0,9. Для P и K точность ниже (см. Рисунок 6), что может быть связано с меньшей выраженностью их спектральных характеристик.

На Рисунке 7 представлена полярная диаграмма, сравнивающая результаты модели на оригинальных и интерполированных данных. Верхний график показывает значения R^2 , а нижний – значения RPD. Видно, что для ОС, CaCO_3 и N значения R^2 и RPD остаются высокими как для оригинальных, так и для интерполированных данных. Для P и K наблюдается небольшое снижение точности, что, однако, не критично для практического применения.

Программная реализация модели глубокого обучения для прогнозирования свойств почвы на основе данных спектроскопии

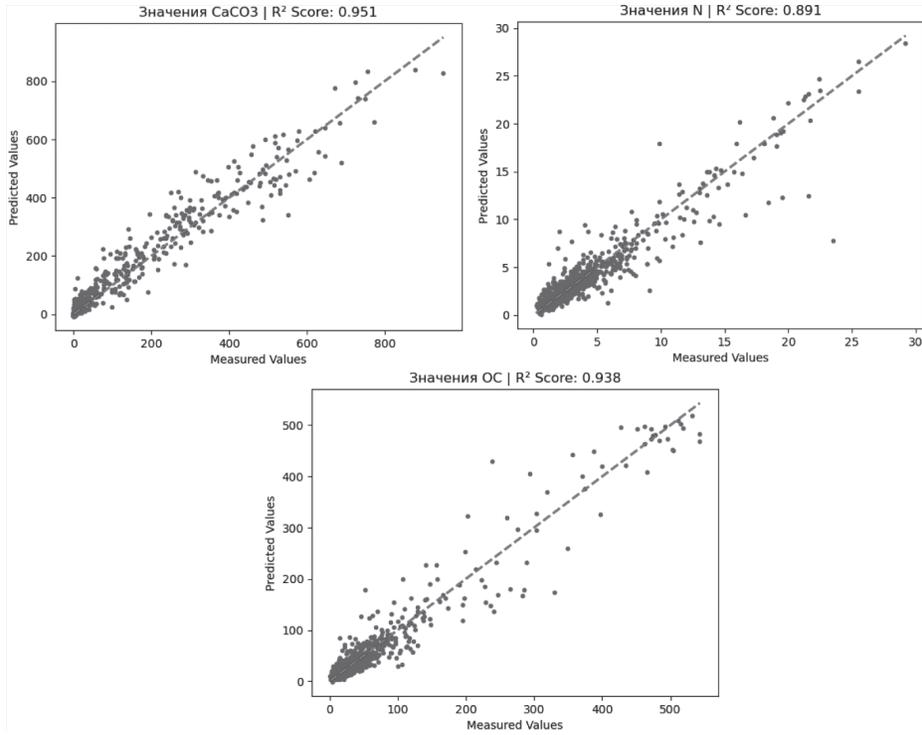


Рисунок 5. Точечные диаграммы сравнения измеренных и прогнозируемых значений некоторых свойств почвы с использованием модели ResNet_CBAM_pH с отличной производительностью оценки OC, CaCO₃, N

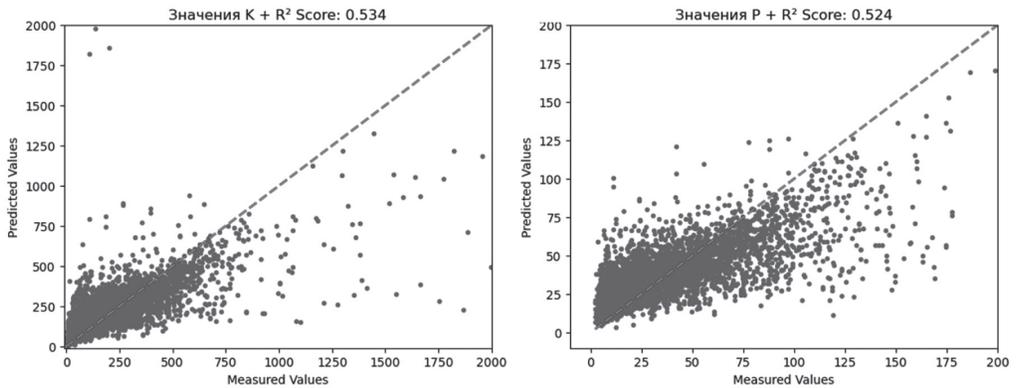


Рисунок 6. Точечные диаграммы между измеренными и прогнозируемыми значениями свойств почвы с неудовлетворительной оценочной производительностью

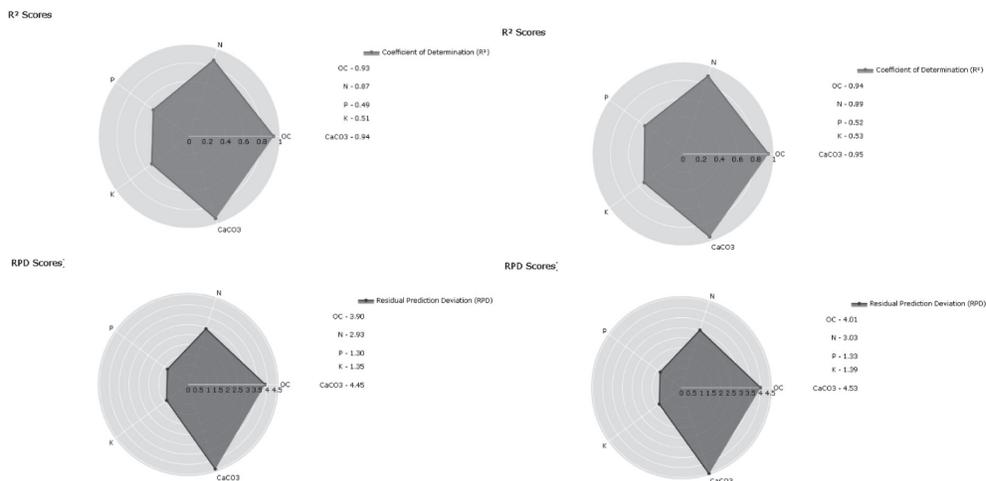


Рисунок 7. Полярная диаграмма сравнения моделей на оригинальных (справа) и интерполированных (слева) данных

Сравнение с другими исследованиями

Для оценки предложенной модели были проведены сравнения с результатами других исследований, использующих различные методы машинного обучения и глубокого обучения для прогнозирования химических свойств почвы. В Таблице 3 представлены результаты сравнения по ключевым параметрам: ОС, CaCO₃, N, P, K и рН.

Таблица 3

Сравнение результатов модели ResNet_CBAM_pH с другими методами машинного обучения и глубокого обучения

Модель / R ²	N	P	K	ОС	CaCO ₃
ResNet_CBAM_pH	0,89	0,52	0,53	0,94	0,95
1d_conv_cnn	0,91	0,37	0,43	0,93	0,89
SVM	0,81	0,25	0,36	0,82	0,81
PLSR	0,83	0,22	0,36	0,85	0,86
RF	0,85	0,23	0,31	0,89	0,84

Краткое описание источников

CNN (сверточные нейронные сети). В работе [14] использовалась глубокая сверточная нейронная сеть (CNN) для прогнозирования свойств почвы на основе данных спектроскопии Vis-NIR. Модель показала высокую точность для ОС ($R^2 = 0,93$) и рН ($R^2 = 0,93$), но уступала ResNet по точности для P ($R^2 = 0,37$), K ($R^2 = 0,43$) и CaCO₃ ($R^2 = 0,89$) [14].

SVM (метод опорных векторов). В исследовании [4] применялся метод SVM для прогнозирования свойств почвы. Модель показала умеренную точность для ОС ($R^2 = 0,81$) и рН ($R^2 = 0,89$), но уступает ResNet по точности для P ($R^2 = 0,25$), K ($R^2 = 0,36$) и CaCO₃ ($R^2 = 0,81$).

Программная реализация модели глубокого обучения для прогнозирования свойств почвы на основе данных спектроскопии

PLSR (частичная регрессия наименьших квадратов). В работе [3] использовался метод PLSR для анализа спектральных данных почвы. Модель показала хорошие результаты для ОС ($R^2 = 0.85$) и CaCO_3 ($R^2 = 0.86$), но уступала ResNet по точности для всех характеристик (N, P, K, ОС, CaCO_3).

RF (случайный лес). В исследовании [15] использовался метод случайного леса (RF) для прогнозирования свойств почвы. Модель показала высокую точность для ОС ($R^2 = 0,89$) и CaCO_3 ($R^2 = 0,84$), но уступала ResNet по точности для N ($R^2 = 0,85$) и других характеристик.

Заключение

Представлена разработанная модель глубокого обучения на основе архитектуры ResNet с модулем внимания CBAM для прогнозирования свойств почвы по данным спектроскопии Vis-NIR. Модель продемонстрировала высокую точность для органического углерода (ОС, $R^2 = 0,94$), карбонатов кальция (CaCO_3 , $R^2 = 0,95$) и азота (N, $R^2 = 0,89$), в то время как для P и K результаты оказались ниже из-за слабых спектральных сигналов этих элементов. Учет pH в механизмах внимания CBAM позволил улучшить предсказательную способность модели, адаптируя ее к различным типам почв.

Сравнение с традиционными методами (PLSR, SVM) и современными подходами (CNN, RF) подтвердило преимущество ResNet_CBAM_pH в точности и устойчивости прогнозов. Интерполяция спектров до 500 точек не привела к значительной потере качества, что делает модель применимой для портативных спектрометров. Это особенно важно для полевых исследований, где требуется оперативный анализ без потери точности.

Полученные результаты открывают перспективы для внедрения модели в системы точного земледелия, включая роботизированные платформы для мониторинга почвы. Дальнейшие исследования могут быть направлены на улучшение прогнозирования P и K, а также на интеграцию модели с другими методами анализа для повышения надежности оценок.

Литература

1. 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. EDN IWSIOP.
2. Федоров В.И., Ивацук О.А., Ужаринский А.Ю. Разработка модели оценки и прогнозирования состояния почв сельско-городских территорий на основе искусственной нейронной сети // Научный результат. Информационные технологии. 2017. Т. 2. № 4. С. 3–9. DOI: 10.18413/2518-1092-2017-2-4-3-9
3. Santasup N., Theanjumol P., Santasup C. Development of near-infrared spectroscopy (NIRS) for estimating organic matter, total carbon, and total nitrogen in agricultural soil // MethodsX. 2024. Vol. 13. Article no. 102798. DOI: 10.1016/j.mex.2024.102798
4. 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
5. 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: 10.1109/CVPR.2016.90

6. Woo S., Park J., Lee J.-Y., Kweon I.S. CBAM: Convolutional Block Attention Module // Ferrari V., Hebert M., Sminchisescu C., Weiss Y. (Eds) Computer Vision – ECCV 2018. ECCV 2018. Series: Lecture Notes in Computer Science. Vol. 11211. Springer, Cham. DOI: 10.1007/978-3-030-01234-2_1
7. Человечкова А.В., Комиссарова И.В., Мирошниченко Н.В. Прогнозирование почвенно-гидрологических параметров с помощью искусственного интеллекта // Известия Самарской государственной сельскохозяйственной академии. 2023. № 3. С. 28–36. DOI: 10.55170/19973225_2023_8_3_28. EDN WLTGSR.
8. Асадуллаев Р.Г., Ситникова М.А., Слетов А.А., Ситников А.В., Малых С.Б. Обзор методов искусственного интеллекта, применяемых в анализе данных функциональной спектроскопии в ближнем инфракрасном диапазоне // Российский психологический журнал. 2024. Т. 21. № 1. С. 67–86. DOI: 10.21702/рпж.2024.1.4. EDN KEFYLN.
9. Брындин Е.Г. Роботы с искусственным интеллектом и спектроскопическим зрением на высокотехнологичном рынке труда // Мягкие измерения и вычисления. 2019. № 9. С. 49–56. EDN WIUKLN.
10. Ng W., Minasny B., Montaner M., McBratney A. Convolutional neural network for simultaneous prediction of several soil properties using visible/near-infrared spectra // Geoderma. 2019. Vol. 352. P. 251–267. DOI: 10.1016/j.geoderma.2019.06.016
11. 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
12. Ben-Dor E., Banin A. Near-infrared analysis as a rapid method to simultaneously evaluate several soil properties // Soil Science Society of America Journal. 1995. Vol. 59. No. 2. P. 364–372. DOI: 10.2136/sssaj1995.03615995005900020014x
13. Tóth G., Jones A., Montanarella L. (Eds). LUCAS Topsoil Survey. Methodology, data and results. EUR26102. Luxembourg : Publications Office of the European Union, 2013. DOI: 10.2788/97922
14. 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. Article no. 115366. DOI: 10.1016/j.geoderma.2021.115366
15. Barra I., Haefele S.M., Sakrabani R., Kebede F. Soil spectroscopy with the use of chemometrics, machine learning and pre-processing techniques in soil diagnosis: Recent advances – A review // Trends in Analytical Chemistry. 2020. Vol. 135. Article no. 116166. DOI: 10.1016/j.trac.2020.116166

References

1. Sirotkin V.V., Vasyukov S.V., Usmanov B.M. (2020) Study of soil parameters based on field spectrometric data. *Bulletin of Udmurt University. Series Biology. Earth Sciences*. Vol. 30. No. 1. Pp. 71–82. DOI: 10.35634/2412-9518-2020-30-1-71-82 (In Russian).
2. Fedorov V.I., Ivashchuk O.A., Uzharskiy A.Yu. (2017) Development of a model of estimation and forecasting of the state of soils of rural-urban territory on the basis of the artificial neural network. *Research Result. Information Technologies*. Vol. 2. No. 4. Pp. 3–9. (In Russian). DOI: 10.18413/2518-1092-2017-2-4-3-9.
3. Santasup N., Theanjumol P., Santasup C. (2024) Development of near-infrared spectroscopy (NIRS) for estimating organic matter, total carbon, and total nitrogen in agricultural soil. *MethodsX*. Vol. 13. Article no. 102798. DOI: 10.1016/j.mex.2024.102798.

Программная реализация модели глубокого обучения для прогнозирования свойств почвы на основе данных спектроскопии

4. Chen S., Li S., Ma W., et al. (2019) Rapid determination of soil classes in soil profiles using vis–NIR spectroscopy and multiple objectives mixed support vector classification. *European Journal of Soil Science*. Vol. 70. No. 1. Pp. 42–53. DOI: 10.1111/ejss.12715.
5. He K., Zhang X., Ren S., Sun J. (2016) Deep Residual Learning for Image Recognition. In: *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA, 2016*. Pp. 770–778. DOI: 10.1109/CVPR.2016.90
6. Woo S., Park J., Lee J.-Y., Kweon I.S. (2018) CBAM: Convolutional Block Attention Module. In: Ferrari V., Hebert M., Sminchisescu C., Weiss Y. (Eds) *Computer Vision – ECCV 2018*. ECCV 2018. Series: Lecture Notes in Computer Science. Vol. 11211. Springer, Cham. DOI: 10.1007/978-3-030-01234-2_1
7. Chelovechkova A.V., Komissarova I.V., Miroshnichenko N.V. (2023) Forecasting of soil-hydrological parameters with the help of artificial intelligence. *Bulletin Samara State Agricultural Academy*. No. 3. Pp. 28–36. DOI: 10.55170/19973225_2023_8_3_28 (In Russian).
8. Asadullaev R.G., Sitnikova M.A., Sletov A.A., Sitnikov A.V., Malykh S.B. (2024) Review of artificial intelligence methods used in the analysis of functional near-infrared spectroscopy data. *Russian psychological journal*. Vol. 21. No. 1. Pp. 67–86. DOI: 10.21702/rpj.2024.1.4 (In Russian).
9. Bryndin E.G. (2019) Robots with artificial intelligence and spectroscopic vision in the high-tech labor market. *Soft Measurement and Computing*. No. 9. Pp. 49–56. (In Russian). EDN WIUKLN.
10. Ng W., Minasny B., Montaner M., McBratney A. (2019) Convolutional neural network for simultaneous prediction of several soil properties using visible/near-infrared spectra. *Geoderma*. Vol. 352. Pp. 251–267. DOI: 10.1016/j.geoderma.2019.06.016
11. Viscarra Rossel R.A., Behrens T. (2010) Using data mining to model and interpret soil diffuse reflectance spectra. *Geoderma*. Vol. 158. No. 1-2. P. 46–54. DOI: 10.1016/j.geoderma.2009.12.025.
12. Ben-Dor E., Banin A. (1995) Near-infrared analysis as a rapid method to simultaneously evaluate several soil properties. *Soil Science Society of America Journal*. Vol. 59. No. 2. Pp. 364–372. DOI: 10.2136/sssaj1995.03615995005900020014x
13. Tóth G., Jones A., Montanarella L. (Eds.) (2013) *LUCAS Topsoil Survey. Methodology, data and results*. EUR26102. Luxembourg : Publications Office of the European Union. DOI: 10.2788/97922
14. Zhong L., Guo X., Xu Z., Ding M. (2021) Soil properties: Their prediction and feature extraction from the LUCAS spectral library using deep convolutional neural networks. *Geoderma*. Vol. 402. Article no. 115366. DOI: 10.1016/j.geoderma.2021.115366
15. Barra I., Haefele S.M., Sakrabani R., Kebede F. (2020) Soil spectroscopy with the use of chemometrics, machine learning and pre-processing techniques in soil diagnosis: recent advances – A review. *Trends in Analytical Chemistry*. Vol. 135. Article no. 116166. DOI: 10.1016/j.trac.2020.116166.

Поступила в редакцию: 06.05.2025

Received: 06.05.2025

Поступила после рецензирования: 21.07.2025

Revised: 21.07.2025

Принята к публикации: 07.08.2025

Accepted: 07.08.2025