УДК 630*114.1 DOI: 10.18324/2077-5415-2026-3-218-225

Прототип информационной модели для бесконтактного определения влажности лесного почвогрунта

Е.Г. Хитров[1a], В.А. Лухминский[2b], Н.Д. Чалов[2c], А.А. Хохлов[3d], А.В. Андронов[2e], А.Ю. Жук[4f]

[1] Санкт-Петербургский политехнический университет Петра Великого, ул. Политехническая, 17, Санкт-Петербург, Россия
[2] Санкт-Петербургский государственный лесотехнический университет имени С.М. Кирова, пер. Институтский, 5У, Санкт-Петербург, Россия
[3] ООО «Строительное управление 8», пер. Большой Спасоглинищевский, д. 9/1 стр. 16, Москва, Россия
[4] Братский государственный университет, ул. Макаренко, 40, Братск, Россия
[a] hitrov_eg@spbstu.ru, [b] vladl1211@mail.ru, [c] chalov.nikitka@mail.ru, [d] t.igorevna123@yandex.ru,
[e] andronovalexandr@gmail.com, [f] ftslk@brstu.ru.
[a] https://orcid.org/0000-0003-4569-9508, [b] https://orcid.org/0009-0004-1695-2708,
[c] https://orcid.org/0009-0007-7255-8950, [d] https://orcid.org/0009-0008-3847-0872,
[e] https://orcid.org/0000-0002-1035-9231, [f] https://orcid.org/0000-0002-8307-6945.
Статья поступила 30.06.2026, принята 10.09.2026.

В статье проводится исследование двух типов моделей машинного обучения, классического – регрессии на основе метода опорных векторов, а также глубокого – на основе одномерной сверточной искусственной нейронной сети, которые в дальнейшем предполагается использовать для определения влажности лесной почвы бесконтактным способом, на основе данных наземной гиперспектральной съёмки. Основным методом исследования является вычислительный эксперимент. Для проведения исследования использован открытый набор данных, в котором присутствуют записи гиперспектральной яркости 679 образцов различных типов почвы с различной влажностью. Эксперимент выполнен при различном объёме обучающих данных с повторениями, что позволило не только определить среднюю абсолютную ошибку прогноза влажности, но и вариацию ошибки. Установлено, что при достаточном объёме обучающих данных модели показывают стабильные результаты прогноза влажности на валидации, поскольку стандартное отклонение средней абсолютной ошибки на порядок меньше её среднего значения (ориентировочно 0,1 % против 1 %). Отмечается, что сравнительно хуже модель на основе опорных векторов справляется с прогнозом влажности почвы свыше 35 %. Модель свёрточной искусственной нейронной сети показала более высокую точность прогноза влажности почвы практически во всём диапазоне уже при сравнительно небольшом наборе данных. Модели на настоящем этапе исследованы в простейших конфигурациях (линейное ядро у регрессии на основе метода опорных векторов и тривиальная структура свёрточной сети), в дальнейшем следует провести эксперименты с настройкой их гиперпараметров с целью полнее раскрыть потенциал семейств моделей при бесконтактном определении влажности почвы с учётом полученного опыта. На основе полученных результатов сделано заключение, что как классическая модель машинного обучения на основе опорных векторов, так и модель глубокого обучения на основе одномерной свёрточной сети перспективны с точки зрения разработки информационной модели бесконтактного определения влажности лесной почвы.

Ключевые слова: гиперспектральные данные; регрессия; метод опорных векторов; одномерная свёрточная сеть; обобщающая способность.

Prototype of an information model for contactless determination of forest soil moisture

E.G. Khitrov[1a], V.A. Lukhminsky[2b], N.D. Chalov[2c], A.A. Khokhlov[3d], A.V. Andronov[2e], A.Yu. Zhuk[3f]

1 Peter the Great St. Petersburg Polytechnic University, Polytechnicheskaya str., 17, St. Petersburg, Russia
2 S.M. Kirov Saint Petersburg State Forest Technical University, Institutskiy per., 5U, St. Petersburg, Russia
3 Building Management 8 LLC, Bolshoy Spasoglinishchevsky Lane, 9/1 bldg 16, Moscow, Russia
4 Bratsk State University, Makarenko str., 40, Bratsk, Russia
[a] hitrov_eg@spbstu.ru, [b] vladl1211@mail.ru, [c] chalov.nikitka@mail.ru, [d] t.igorevna123@yandex.ru,
[e] andronovalexandr@gmail.com, [f] ftslk@brstu.ru.
[a] https://orcid.org/0000-0003-4569-9508, [b] https://orcid.org/0009-0004-1695-2708,
[c] https://orcid.org/0009-0007-7255-8950, [d] https://orcid.org/0009-0008-3847-0872,
[e] https://orcid.org/0000-0002-1035-9231, [f] https://orcid.org/0000-0002-8307-6945.
Received 30.06.2026, accepted 10.09.2026.

The article studies two types of machine learning models – a classical one, support vector regression, and a deep one, based on a one-dimensional convolutional artificial neural network – which are subsequently intended to be used for contactless determination of

forest soil moisture based on ground-based hyperspectral survey data. The main research method is a computational experiment. An open dataset is used for the study, containing records of hyperspectral brightness of 679 samples of various soil types with different moisture content. The experiment is performed with different volumes of training data with repetitions, which makes it possible to determine not only the mean absolute error of moisture prediction but also the variation of the error. It is established that, with a sufficient volume of training data, the models show stable moisture prediction results on validation, since the standard deviation of the mean absolute error is an order of magnitude smaller than its mean value (approximately 0.1% versus 1%). It is noted that the support vector model copes comparatively worse with predicting soil moisture above 35%. The convolutional artificial neural network model shows higher accuracy in predicting soil moisture across almost the entire range even with a comparatively small dataset. At the present stage, the models have been studied in their simplest configurations (a linear kernel for support vector regression and a trivial structure of the convolutional network); in the future, experiments should be conducted with tuning their hyperparameters in order to more fully reveal the potential of these model families in the contactless determination of soil moisture, taking into account the experience gained. Based on the obtained results, it is concluded that both the classical machine learning model based on support vectors and the deep learning model based on a one-dimensional convolutional network are promising from the standpoint of developing an information model for the contactless determination of forest soil moisture.

Keywords: hyperspectral data; regression; support vector method; one-dimensional convolutional network; generalization ability.

Введение. Влажность почвогрунта является одной из ключевых характеристик, во многом определяющей его механические свойства [1–6]. Для реализации математических моделей, прогнозирующих проходимость лесной техники и экологические показатели воздействия движителей на почвогрунт, используются значения модуля общей деформации, несущей способности, сцепных свойств, являющиеся функциями фракционного состава, плотности и влажности [5, 6]. Известны лабораторные и полевые методики определения влажности почвогрунта, требующие физического отбора кернов [5, 6]. Известны методики, предполагающие использование контактных электронных влагомеров, сравнительно менее трудоёмкие [5, 6]. Однако, ввиду вариативности свойств и состояния лесного почвогрунта, представляют интерес методы определения влажности бесконтактными способами, позволяющими оперативно составлять картину его состояния даже в режиме реального времени. Подобная информация полезна не только с точки зрения реализации упомянутых моделей оценки проходимости и экологичности, но и в контексте разработки моделей технического зрения, предназначенных для поддержки навигации лесной техники, в том числе – беспилотной, что особенно актуально в настоящее время.

Представлены результаты [7–12], доказывающие возможность определения различных свойств почвы на основе анализа результатов гиперспектральной съёмки с точностью, приемлемой для практики (гиперспектральные данные представляют собой записи яркостей длин волн, отражённых объектом съёмки, в широком диапазоне – ориентировочно 400–1000 нм, что «перекрывает» классическую цветовую схему RGB). Методика и оборудование гиперспектральной съёмки допускает съёмку непосредственно с поверхности, на которой будет работать техника [7–12].

Однако, на настоящее время, в научной литературе не приводится систематизированная оценка применимости результатов анализа гиперспектральных данных для оперативного определения влажности лесного почвогрунта. Наиболее близкие исследования посвящены анализу гиперспектральных данных для определения влажности сельскохозяйственных почв, свойства которых в определённой мере передают свойства лесного почвогрунта [5, 6]. В работах [13–17] рассматриваются как модели классического машинного обучения, так и глубокого обучения в контексте определения влажности почвы (рассматривается решение задачи регрессии). Однако, ввиду ограниченного объёма экспериментальных данных, на настоящем этапе требуется более подробная оценка обобщающей способности моделей, т. е. их способность прогнозировать целевую функцию, в общем случае, для новых данных и в новых условиях, а в частности – при валидации. Детальная оценка позволит в дальнейшем оптимизировать разработку полноценной информационной модели, включающей в себя математическую модель, экспериментальные данные и программную реализацию, предназначенной для оперативного определения свойств лесного почвогрунта бесконтактным способом на основе анализа гиперспектральных данных.

Постановка задачи. В нашей работе проводится исследование двух типов моделей машинного обучения, классического – регрессии на основе метода опорных векторов (SVR), а также глубокого – на основе одномерной свёрточной искусственной нейронной сети (1D-CNN), которые в дальнейшем предполагается использовать для определения влажности лесной почвы. Выбор моделей для прототипа связан с их свойствами по структурам: устойчивостью по отношению к выбросам данных (робастностью) [18–22], что важно по причине ограниченного объёма экспериментальных данных, а также потенциально высокой обобщающей способностью [21, 22], что ценно с точки зрения дальнейшей разработки и тестирования полноценной информационной модели.

Материалы и методы решения задачи. Основным методом исследования является вычислительный эксперимент. Для проведения исследования использован открытый набор данных [23], в котором присутствуют записи гиперспектральной яркости 679 образцов различных типов почвы (объектов) с различной влажностью (гистограмма распределения целевой функции y – влажности W, представлена на рис. 1). Яркости записаны для 125 длин волн, таким образом, размерность исходного признакового пространства составляет $m = 125$ при объёме выборки $n = 679$.

Для наглядности проиллюстрируем признаки x (спектральные яркости соответствующих длин волн) для нескольких объектов из набора данных (рис. 2).

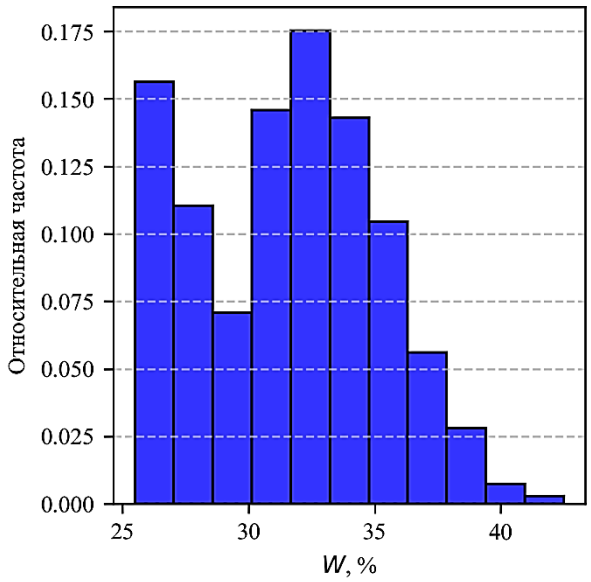

Рис. 1. Распределение образцов в наборе данных по влажности

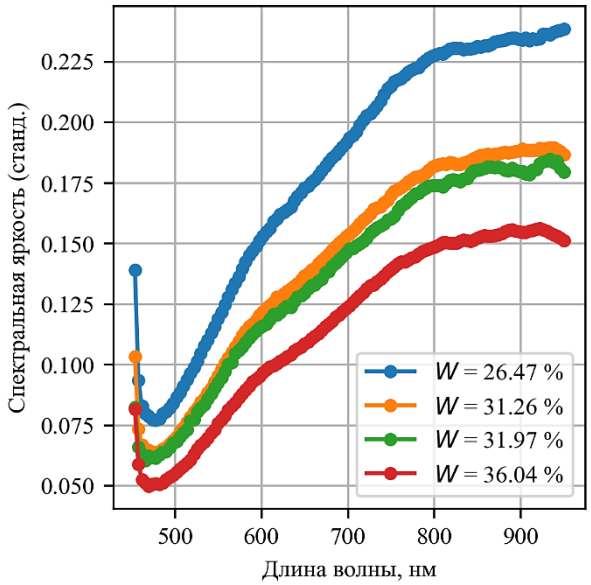

Рис. 2. Пример гиперспектральных данных для почвы при различной влажности

Вычисления реализуются с использованием стенда, основные сведения о программной и аппаратной части которого указаны в табл. 1.

Таблица 1. Программная и аппаратная часть стенда

Параметр	**Значение**
CPU	20x12th Gen Intel Core i7-12700KF
GPU	NVIDIA GeForce RTX 4060 Ti, версия CUDA 13.2
ОС	Linux KDE Neon 24.04
Реализация моделей	Python 3.13, Scikit-learn для модели SVR, Pytorch для модели 1D-CNN

Подготовка модели классического машинного обучения SVR проводится на обучающей выборке (Train), в которую случайным образом отбирается l объектов. Оставшиеся объекты образуют валидационную выборку (Val) объёмом $k = n - l$. Доля данных, использованных для обучения, варьируется от 0,05 до 0,8 с шагом 0,05. Эксперимент повторяется 100 раз при различных вариантах случайного выбора данных для обучения при каждом значении доли, что позволяет оценить вариацию метрик качества прогноза (метрики: среднее значение модуля абсолютной ошибки прогноза (MAE) и коэффициент детерминации R^2 раздельно для валидационной и обучающей выборки).

Поскольку часть признаков тесно коррелирована (рис. 2), что характерно для гиперспектральных данных, предусмотрим эксперимент с подготовкой модели после ортогонализации признакового пространства (отображение в пространство главных компонент). Для этого признаки в обучающей выборке центрируются [24]:

$$\tilde{x} = x - \mu, \tag{1}$$

где μ – среднее значение яркости волны соответствующей длины в обучающей выборке, а матрица ковариации центрированных по (1) признаков представляется сингулярным разложением [24]:

$$\Sigma = \frac{1}{l-1}\tilde{X}^T\tilde{X} = USV^T, \tag{2}$$

где U, V – соответственно матрицы левых и правых сингулярных векторов, S – матрица сингулярных чисел. Отображение в пространство главных компонент (PC) выполняется матричным умножением [24]:

$$Z = \tilde{X}R_d, \tag{3}$$

где R_d – матрица перехода (поворота), составленная из d-штук правых сингулярных векторов Σ, причем:

$$d = \min(l, m), \tag{4}$$

таким образом, преобразование выполняется не с целью снижения размерности пространства, что происходит вынужденно лишь при малых l, а с целью именно ортогонализации.

Преобразование признакового пространства валидационной выборки выполняется с использованием той же матрицы R_d, составленной на основе разложения матрицы ковариации обучающих данных.

В соответствии с постановкой задачи исследования, на настоящем этапе будем использовать самые простые структуры моделей – представителей двух «семейств». В связи с чем функцией-ядром SVR будет скалярное произведение. В общем виде прогноз линейной регрессионной модели задается формулой [18-20]:

$$f(x) = \langle w, x \rangle + b \tag{5}$$

где w – вектор весов модели (подлежит определению в процессе обучения модели, т. е. при минимизации функции потерь, вычисленной для данных обучающей выборки), x – вектор признаков объекта, b – смещение модели.

Для модели регрессии на основе опорных векторов решение для w, b (обучение модели) получается из решения задачи условной оптимизации [18–20]:

$$L = \frac{1}{2}\|w\|^2 + C\sum_{i=1}^{l}(\xi_i + \xi_i^*) \to \min_{w,b,\xi,\xi^*} \quad (6)$$

при ограничениях [18–20]:

$$\begin{gathered} y_i - \langle w, x_i\rangle - b \le \epsilon + \xi_i \\ \langle w, x_i\rangle + b - y_i \le \epsilon + \xi_i^* \\ \xi_i, \xi_i^* \ge 0 \end{gathered} \quad (7)$$

где $\frac{1}{2}\|w\|^2$ – слагаемое-регуляризатор, C – гиперпараметр модели (т. е. параметр, значение которого назначается до начала обучения, связанный со штрафом за ошибки (параметр принят $C = 100$ на основе предварительных поисковых экспериментов, значение можно интерпретировать как сравнительно «мягкую» регуляризацию по L_2-норме вектора w), ϵ – радиус, внутри которого ошибки модели не вносят вклад в суммарный штраф (гиперпараметр модели; принят $\epsilon = 0{,}1$ по умолчанию), ξ_i, ξ_i^* – ошибки для точек вне радиуса ϵ (так называемые слаковые переменные) [18–20]:

$$\begin{aligned} \xi_i &= \max(0, y_i - f(x_i) - \epsilon) \\ \xi_i^* &= \max(0, f(x_i) - y_i - \epsilon) \end{aligned} \quad (8)$$

В качестве альтернативы рассматривается модель глубокого обучения 1D-CNN, её архитектура схематично представлена на рис. 3.

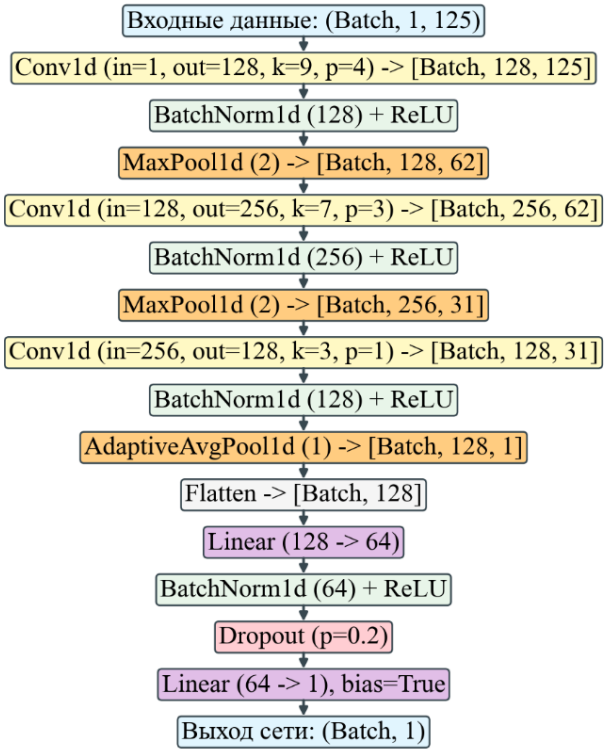

Рис. 3. Схема архитектуры модели глубокого обучения

Логика выбора архитектуры аналогична SVR: подбирается «представитель» семейства моделей наиболее простой, но включающий все характерные структурные элементы (слои свёртки Conv1d, полносвязные слои Linear, слои пулинга Pool, нормализация BatchNorm, регуляризатор Dropout [21, 22]). В конфигурации, проиллюстрированной на рис. 3, число весов составляет 338817.

Доля обучающих данных, как и для SVR-модели, варьируется по сетке с шагом 0,05 от 0,05 до 0,80 от всего объёма выборки. Число повторений каждого эксперимента составляет 10.

Реализация выполнена с полным перебором сочетаний гиперпараметров по табл. 2. Для обучения модели использован оптимизатор Adam с шагом обучения 0,0001 и лимитом числа обучения 10000 эпох (итераций); функция потерь представляет собой средний квадрат ошибки прогноза в обучающей выборке (MSE-loss [21, 22]), использовано условие ранней остановки обучения по критерию неулучшения метрики MAE в валидационной выборке в течение 100 эпох.

Основные результаты. На рис. 3 показаны результаты измерения метрик модели классического машинного обучения SVR, подготовленной в исходном признаковом пространстве (без ортогонализации), усреднённые по 100 повторениям при различных наборах обучающих и валидационных точек.

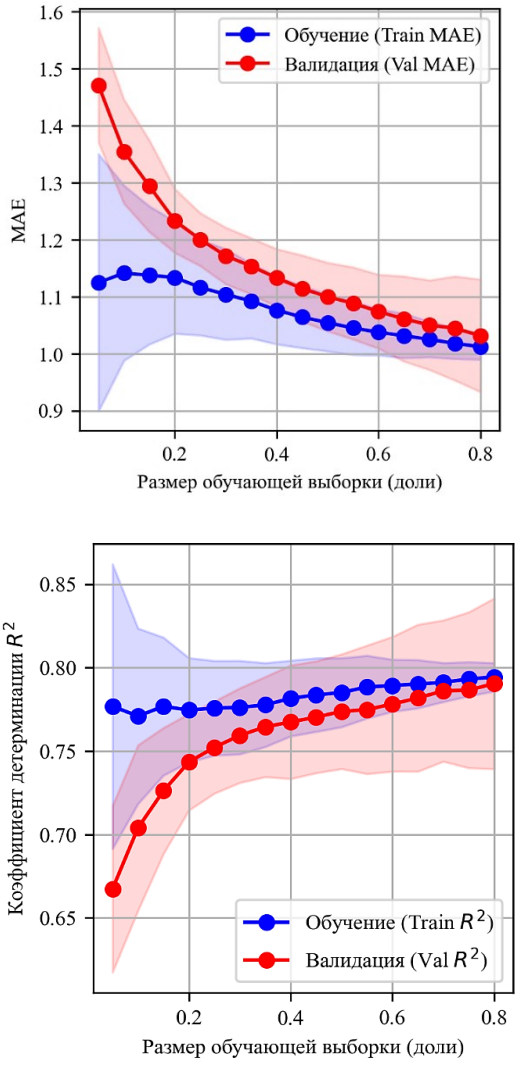

Рис. 3. Метрики модели SVR на основе обработки результатов эксперимента, обучение модели в исходном признаковом пространстве

Далее приведём результаты для модели SVR, обучение которой выполнено в пространстве главных компонент (формула (3) задаёт преобразование). Метрики модели проиллюстрированы на рис. 4.

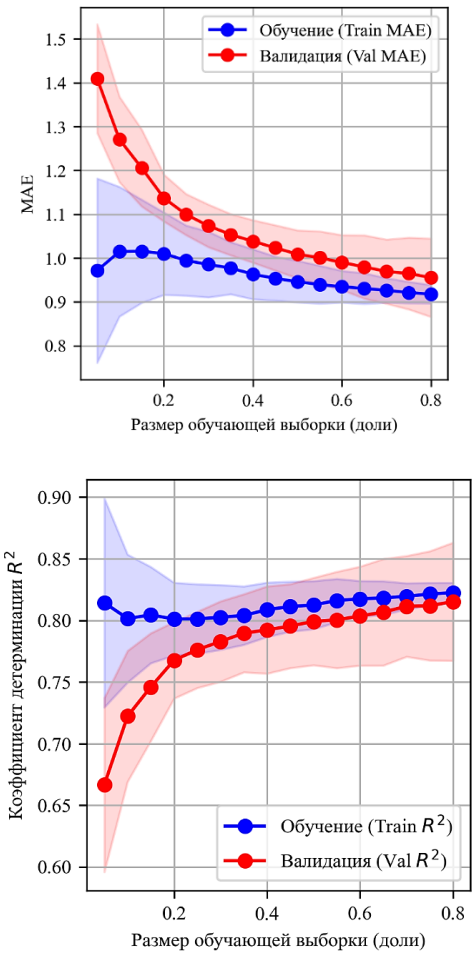

Рис. 4. Метрики модели SVR на основе обработки результатов эксперимента, обучение модели в ортогонализированном признаковом пространстве

Истинные значения влажности, известные из исходного набора данных, сопоставлены со значениями, предсказанными моделью SVR, на рис. 5, 6.

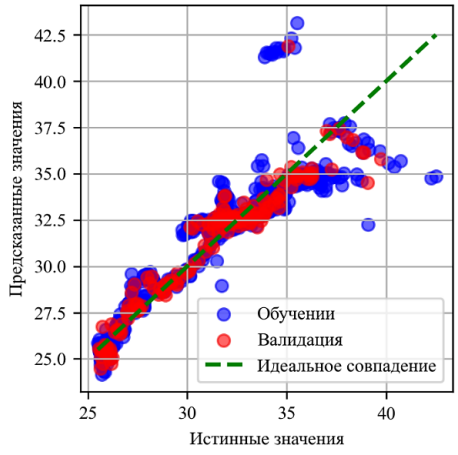

Рис. 5. Сравнение истинных и предсказанных значений, модель SVR, обучение в исходном признаковом пространстве, доля обучающих данных 0,8

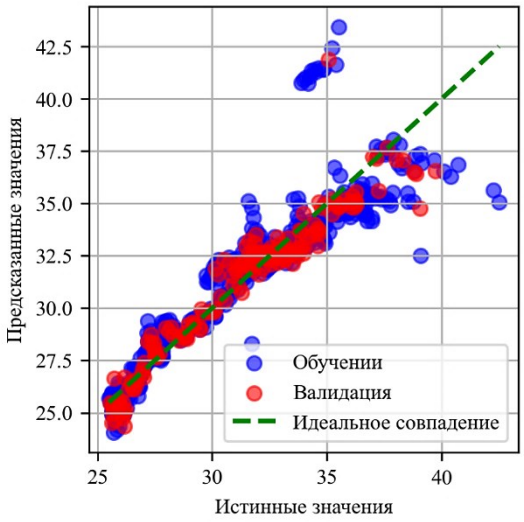

Рис. 6. Сравнение истинных и предсказанных значений, модель SVR, обучение модели в ортогонализированном признаковом пространстве, доля обучающих данных 0,8

Аналогично приведён функции метрик от объёма обучающих данных, полученных в эксперименте с 1D-CNN (рис. 7).

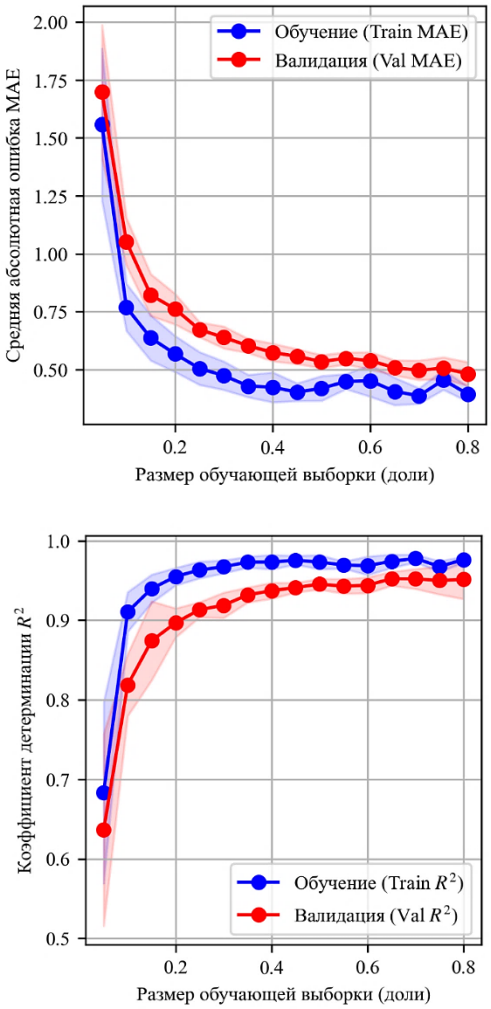

Рис. 7. Метрики модели 1D-CNN на основе обработки результатов эксперимента, данные в исходном признаковом пространстве переданы на обучение модели

Для наглядности сопоставим истинные значения влажности со значениями, предсказанными моделью 1D-CNN, на рис. 8.

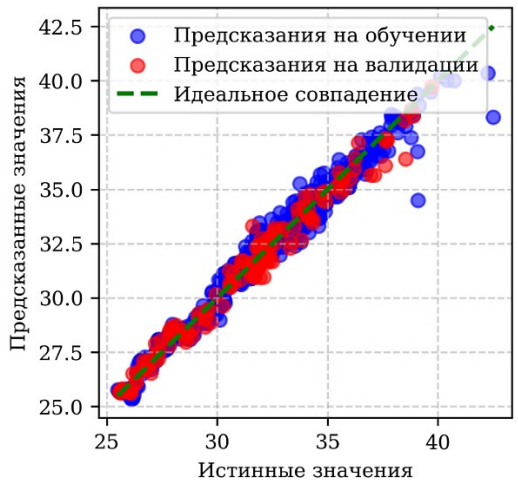

Рис. 8. Сравнение истинных и предсказанных значений, модель 1D-CNN, доля обучающих данных 0,8

В табл. 2 приведены сводные числовые данные, характеризующие вариацию метрики MAE для моделей SVR и 1D-CNN.

Таблица 2. Средняя абсолютная ошибка прогноза влажности почвы при валидации моделей (в скобках указано стандартное отклонение метрики)

Доля Train	SVR	SVR (PC)	1D-CNN
0,05	1,47 (0,1007)	1,41 (0,1241)	1,70 (0,2881)
0,10	1,35 (0,0913)	1,27 (0,0975)	1,05 (0,1030)
0,15	1,29 (0,0803)	1,21 (0,0878)	0,82 (0,0903)
0,20	1,23 (0,0559)	1,14 (0,0534)	0,76 (0,0661)
0,25	1,20 (0,0464)	1,10 (0,0469)	0,67 (0,0323)
0,30	1,17 (0,0497)	1,07 (0,0486)	0,64 (0,0472)
0,35	1,15 (0,0492)	1,05 (0,0471)	0,60 (0,0303)
0,40	1,13 (0,0508)	1,04 (0,0485)	0,57 (0,0382)
0,45	1,11 (0,0581)	1,02 (0,0518)	0,56 (0,0318)
0,50	1,10 (0,0601)	1,01 (0,0546)	0,54 (0,0283)
0,55	1,09 (0,0633)	1,00 (0,0604)	0,55 (0,0260)
0,60	1,07 (0,0648)	0,99 (0,0626)	0,54 (0,0371)
0,65	1,06 (0,0746)	0,98 (0,0722)	0,51 (0,0327)
0,70	1,05 (0,0786)	0,97 (0,0733)	0,50 (0,0421)
0,75	1,04 (0,0913)	0,96 (0,0820)	0,51 (0,0469)
0,80	1,03 (0,0987)	0,96 (0,0895)	0,48 (0,0506)

Заключение. Результаты вычислительного эксперимента показали следующее:

Для исследованных моделей SVR и 1D-CNN ожидаемо отмечается снижение средней абсолютной ошибки (MAE) по мере увеличения доли данных, использованных для обучения. При достаточном объёме обучающих данных модели показывают стабильные результаты прогноза влажности на валидации, поскольку стандартное отклонение средней абсолютной ошибки на порядок меньше её среднего значения (ориентировочно 0,1 % против 1 %).

Ортогонализация признакового пространства несколько улучшила показатели модели SVR: модель, подготовленная в пространстве главных компонент, превосходит «базовый» вариант, подготовленный в исходном признаковом пространстве, при любых объёмах обучающей выборки. Переход к главным компонентам позволил снизить среднюю абсолютную ошибку на величину от 0,06 до 0,09 %, которая при доле обучающих данных 0,8 составила 0,96 %. Отметим, что сравнительно хуже модель SVR справляется с прогнозом влажности почвы свыше 35 %.

Модель свёрточной искусственной нейронной сети 1D-CNN показала более высокую точность прогноза влажности почвы практически во всём диапазоне уже при сравнительно небольшом наборе данных (679 образцов). Начиная с доли обучающей выборки 0,10 модель заметно опережает классический алгоритм SVR. Однако, при малом объёме обучающих данных (0,05) модель 1D-CNN продемонстрировала худший результат (ошибка в среднем 1,70 % при стандартном отклонении 0,2881), причём ошибка резко снижается уже при увеличении доли обучающей выборки до 0,10 (ошибка в среднем 1,05 % при стандартном отклонении 0,1030), что указывает на повышенную чувствительность сети к объёму обучающих данных на начальном этапе.

На основе полученных результатов можем заключить, что как классическая модель машинного обучения SVR, так и модель глубокого обучения 1D-CNN перспективны с точки зрения разработки информационной модели бесконтактного определения влажности лесной почвы, обладают потенциально высокой обобщающей способностью, что показали результаты валидации. Модели на настоящем этапе исследованы в простейших конфигурациях (линейное ядро у SVR и тривиальная структура 1D-CNN), в дальнейшем следует провести эксперименты с настройкой их гиперпараметров с целью полнее раскрыть потенциал семейств моделей при бесконтактном определении влажности почвы с учетом полученного опыта. Для тестирования моделей возможно предложить более сложный набор данных [25], доступный в открытых источниках.

Работа выполнена в рамках научной школы «Инновационные разработки в области лесозаготовительной промышленности и лесного хозяйства» Арктического государственного агротехнологического университета. Исследование выполнено за счёт гранта Российского научного фонда № 26-16-00047.

Литература

1. Шапиро В.Я., Рыжов Я.А., Григорьев И.В., Тихонов Е.А., Алексеева А.В., Кривоконева Е.Ю. Особенности разрушения оттаивающего почвогрунта на склоне в боковых полосах трасс движения лесных машин // Системы. Методы. Технологии. 2026. № 1 (69). С. 129–136.

2. Шапиро В.Я., Григорьев И.В., Сибиряткин Е.В., Тихонов Е.А., Перфильев П.Н. Моделирование процесса образования колеи при последовательном взаимодействии колес форвардера с твёрдыми препятствиями на трелёвоч-

ном волоке с учётом влажности почвогрунта // Лесотехнический журнал. 2026. Т. 16, № 2 (62). С. 234–246.
3. Шапиро В.Я., Григорьев И.В., Рыжов Я.А., Тихонов Е.А., Перфильев П.Н. Оценка работоспособности трелёвочного волока на склоне с учётом армирующего влияния насыщенного корнями слоя почвогрунта при взаимодействии колесной лесной машины // Лесотехнический журнал. 2026. Т. 16, № 2 (62). С. 247–257.
4. Шапиро В.Я., Григорьев И.В., Савченко С.И., Тихонов Е.А., Ревяко С.И., Перфильев П.Н. Влияние маневрирования движителя колесной лесной машины на ее проходимость в сложных геотехнических условиях // Лесотехнический журнал. 2025. Т. 15, № 3 (59). С. 228–244.
5. Grigorev I., Kunickaya O., Burgonutdinov A. et al. Theoretical studies of dynamic soil compaction // Diagnostyka. 2020. Vol. 21, no. 4. P. 3–13. DOI: 10.29354/diag/127650.
6. Grigorev I., Kunickaya O., Burgonutdinov A. et al. Dynamic impact of wheeled skidders on forest soil // Journal of Terramechanics. 2022. Vol. 102. P. 21–31.
7. Ali I., Greifeneder F., Stamenkovic J., Neumann M., Notarnicola C. Review of Machine Learning Approaches for Biomass and Soil Moisture Retrievals from Remote Sensing Data // Remote Sensing. 2015. Vol. 7, no. 12. P. 16398–16421.
8. Colini L., Spinetti C., Amici S., Buongiorno M., Caltabiano T., Doumaz F., Favalli M., Giammanco S., Isola I., La Spina A. Hyperspectral spaceborne, airborne and ground measurements campaign on Mt. Etna: Multi data acquisitions in the frame of Prisma Mission (ASI-AGI Project n. I/016/11/0) // Quaderni di Geofisica. 2014. Vol. 119. P. 1–51.
9. Treitz P.M., Howarth P.J. Hyperspectral remote sensing for estimating biophysical parameters of forest ecosystems // Progress in Physical Geography: Earth and Environment. 1999. Vol. 23, no. 3. P. 359–390.
10. Gislason P.O., Benediktsson J.A., Sveinsson J.R. Random forests for land cover classification // Pattern Recognition Letters. 2006. Vol. 27, no. 4. P. 294–300.
11. Camps-Valls G., Tuia D., Gómez-Chova L., Jiménez S., Malo J. Remote sensing image processing // Synthesis Lectures on Image, Video, and Multimedia Processing. 2011. Vol. 5, no. 1. P. 1–192.
12. Shen Q., Xia K., Zhang S., Kong C., Hu Q., Yang S. Hyperspectral indirect inversion of heavy-metal copper in reclaimed soil of iron ore area // Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy. 2019. Vol. 222. Art. no. 117191.
13. Keller S., Riese F. M., Stötzer J., Maier P. M., Hinz S. Developing a machine learning framework for estimating soil moisture with VNIR hyperspectral data // ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences. 2018. Vol. IV-1. P. 101–108.
14. Riese F.M., Keller S. Introducing a Framework of Self-Organizing Maps for Regression of Soil Moisture with Hyperspectral Data // Proceedings of the 2018 IEEE International Geoscience and Remote Sensing Symposium. 2018. P. 6151–6154.
15. Fabre S., Briottet X., Lesaignoux A. Estimation of soil moisture content from the spectral reflectance of bare soils in the 0.4-2.5 μm domain // Sensors. 2015. Vol. 15, no. 2. P. 3262–3281.
16. Vahidi M., Shafian S., Frame W. H. Precision Soil Moisture Monitoring Through Drone-Based Hyperspectral Imaging and PCA-Driven Machine Learning // Sensors. 2025. Vol. 25, no. 3. Art. no. 782.
17. Rasheed M.W., Tang J., Sarwar A., Shah S., Saddique N., Khan M. U., Imran Khan M., Nawaz S., Shamshiri R. R., Aziz M. Soil Moisture Measuring Techniques and Factors Affecting the Moisture Dynamics: A Comprehensive Review // Sustainability. 2022. Vol. 14, no. 18. Art. no. 11538.
18. Smola A.J., Schölkopf B. A tutorial on support vector regression // Statistics and Computing. 2004. Vol. 14, no. 3. P. 199–222.
19. Drucker H., Burges C.J.C., Kaufman L., Smola A. J., Vapnik V.N. Support vector regression machines // Advances in Neural Information Processing Systems (NIPS 1996). 1997. Vol. 9. P. 155–161.
20. Vapnik V.N., Golowich S.E., Smola A.J. Support vector method for function approximation, regression estimation, and signal processing // Advances in Neural Information Processing Systems (NIPS 1996). 1997. Vol. 9. P. 281–287.
21. Kiranyaz S., Avci O., Abdeljaber O., Ince T., Gabbouj M. 1D convolutional neural networks and applications: A survey // Mechanical Systems and Signal Processing. 2021. Vol. 151. Art. no. 107398.
22. Kiranyaz S., Ince T., Gabbouj M. Real-time patient-specific ECG classification by 1-D convolutional neural networks // IEEE Transactions on Biomedical Engineering. 2016. Vol. 63, no. 3. P. 664–675.
23. Riese F.M., Keller S. Hyperspectral benchmark dataset on soil moisture // Zenodo. 2018. DOI: 10.5281/zenodo.1227837
24. Jolliffe I.T., Cadima J. Principal component analysis: a review and recent developments // Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences. 2016. Vol. 374, no. 2061. Art. no. 20150202.
25. HydReSGeo: Field experiment dataset of surface-sub-surface infiltration dynamics acquired by hydrological, remote sensing, and geophysical measurement techniques [Electronic resource] / S. Keller, F.M. Riese, N. Allroggen, C. Jackisch. Электрон. дан. Potsdam : GFZ Data Services, 2020. DOI: 10.5880/fidgeo.2020.015.

References

1. Shapiro V.Y., Ryzhov Y.A., Grigorev I.V., Tikhonov E.A., Alekseeva A.V., Krivokoneva E.Y. Features of Destruction of Thawing Soil on a Slope in the Side Lanes of Forest Machine Movement Tracks // Sistemy. Metody. Tekhnologii. 2026. no. 1 (69). Pp. 129–136.
2. Shapiro V.Y., Grigorev I.V., Sibiryatkin E.V., Tikhonov E.A., Perfiliev P.N. Modeling the Process of Rut Formation During Successive Interaction of Forwarder Wheels with Solid Obstacles on a Skid Trail Taking Into Account Soil Moisture // Lesotekhnicheskii Zhurnal. 2026. Vol. 16, no. 2 (62). Pp. 234–246.
3. Shapiro V.Y., Grigorev I.V., Ryzhov Y.A., Tikhonov E.A., Perfiliev P.N. Performance Evaluation of a Skid Trail on a Slope Taking Into Account the Reinforcing Influence of a Root-Saturated Soil Layer Under Interaction of a Wheeled Forest Machine // Lesotekhnicheskii Zhurnal. 2026. Vol. 16, no. 2 (62). Pp. 247–257.
4. Shapiro V.Y., Grigorev I.V., Savchenko S.I., Tikhonov E.A., Revyako S.I., Perfiliev P.N. The Influence of Wheeled Forest Machine Propulsor Maneuvering on its Trafficability in Difficult Geotechnical Conditions // Lesotekhnicheskii Zhurnal. 2025. Vol. 15, no. 3 (59). Pp. 228–244
5. Grigorev I., Kunickaya O., Burgonutdinov A. et al. Theoretical studies of dynamic soil compaction // Diagnostyka. – 2020. – Vol. 21, no. 4. – P. 3–13. – DOI: 10.29354/diag/127650.
6. Grigorev I., Kunickaya O., Burgonutdinov A. et al. Theoretical studies of dynamic soil compaction // Diagnostyka. 2020. Vol. 21, no. 4. P. 3–13. DOI: 10.29354/diag/127650.
7. Grigorev I., Kunickaya O., Burgonutdinov A. et al. Dynamic impact of wheeled skidders on forest soil // Journal of Terramechanics. 2022. Vol. 102. P. 21–31.
8. Ali I., Greifeneder F., Stamenkovic J., Neumann M., Notarnicola C. Review of Machine Learning Approaches for Biomass and Soil Moisture Retrievals from Remote Sensing Data // Remote Sensing. 2015. Vol. 7, no. 12. P. 16398–16421.
9. Colini L., Spinetti C., Amici S., Buongiorno M., Caltabiano T., Doumaz F., Favalli M., Giammanco S., Isola I., La Spina A. Hyperspectral spaceborne, airborne and ground measurements campaign on Mt. Etna: Multi data acquisitions in the frame of

Prisma Mission (ASI-AGI Project n. I/016/11/0) // Quaderni di Geofisica. 2014. Vol. 119. P. 1–51.
10. Treitz P.M., Howarth P.J. Hyperspectral remote sensing for estimating biophysical parameters of forest ecosystems // Progress in Physical Geography: Earth and Environment. 1999. Vol. 23, no. 3. P. 359–390.
11. Gislason P.O., Benediktsson J.A., Sveinsson J.R. Random forests for land cover classification // Pattern Recognition Letters. 2006. Vol. 27, no. 4. P. 294–300.
12. Camps-Valls G., Tuia D., Gómez-Chova L., Jiménez S., Malo J. Remote sensing image processing // Synthesis Lectures on Image, Video, and Multimedia Processing. 2011. Vol. 5, no. 1. P. 1–192.
13. Shen Q., Xia K., Zhang S., Kong C., Hu Q., Yang S. Hyperspectral indirect inversion of heavy-metal copper in reclaimed soil of iron ore area // Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy. 2019. Vol. 222. Art. no. 117191.
14. Keller S., Riese F. M., Stötzer J., Maier P. M., Hinz S. Developing a machine learning framework for estimating soil moisture with VNIR hyperspectral data // ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences. 2018. Vol. IV-1. P. 101–108.
15. Riese F.M., Keller S. Introducing a Framework of Self-Organizing Maps for Regression of Soil Moisture with Hyperspectral Data // Proceedings of the 2018 IEEE International Geoscience and Remote Sensing Symposium. 2018. P. 6151–6154.
16. Fabre S., Briottet X., Lesaignoux A. Estimation of soil moisture content from the spectral reflectance of bare soils in the 0.4-2.5 μm domain // Sensors. 2015. Vol. 15, no. 2. P. 3262–3281.
17. Vahidi M., Shafian S., Frame W. H. Precision Soil Moisture Monitoring Through Drone-Based Hyperspectral Imaging and PCA-Driven Machine Learning // Sensors. 2025. Vol. 25, no. 3. Art. no. 782.
18. Rasheed M.W., Tang J., Sarwar A., Shah S., Saddique N., Khan M.U., Imran Khan M., Nawaz S., Shamshiri R.R., Aziz M. Soil Moisture Measuring Techniques and Factors Affecting the Moisture Dynamics: A Comprehensive Review // Sustainability. 2022. Vol. 14, no. 18. Art. no. 11538.
19. Smola A. J., Schölkopf B. A tutorial on support vector regression // Statistics and Computing. 2004. Vol. 14, no. 3. P. 199–222.
20. Drucker H., Burges C. J. C., Kaufman L., Smola A. J., Vapnik V.N. Support vector regression machines // Advances in Neural Information Processing Systems (NIPS 1996). 1997. Vol. 9. P. 155–161.
21. Vapnik V.N., Golowich S.E., Smola A.J. Support vector method for function approximation, regression estimation, and signal processing // Advances in Neural Information Processing Systems (NIPS 1996). 1997. Vol. 9. P. 281–287.
22. Kiranyaz S., Avci O., Abdeljaber O., Ince T., Gabbouj M. 1D convolutional neural networks and applications: A survey // Mechanical Systems and Signal Processing. 2021. Vol. 151. Art. no. 107398.
23. Kiranyaz S., Ince T., Gabbouj M. Real-time patient-specific ECG classification by 1-D convolutional neural networks // IEEE Transactions on Biomedical Engineering. 2016. Vol. 63, no. 3. P. 664–675.
24. Riese F.M., Keller S. Hyperspectral benchmark dataset on soil moisture // Zenodo. 2018. DOI: 10.5281/zenodo.1227837
25. Jolliffe I.T., Cadima J. Principal component analysis: a review and recent developments // Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences. 2016. Vol. 374, no. 2061. Art. no. 20150202.
26. HydReSGeo: Field experiment dataset of surface-sub-surface infiltration dynamics acquired by hydrological, remote sensing, and geophysical measurement techniques [Electronic resource] / S. Keller, F.M. Riese, N. Allroggen, C. Jackisch. Электрон. дан. Potsdam : GFZ Data Services, 2020. DOI: 10.5880/fidgeo.2020.015.