

СЕЛЬСКОХОЗЯЙСТВЕННЫЕ ИССЛЕДОВАНИЯ

AGRICULTURAL SCIENCES

DOI: 10.12731/2658-6649-2023-15-6-960

УДК 612.017.1:616.33-02.27



Научная статья

АГРОЭКОЛОГИЧЕСКАЯ ТИПИЗАЦИЯ СЕЛЬСКОХОЗЯЙСТВЕННЫХ ЗЕМЕЛЬ С ПРИМЕНЕНИЕМ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ, ГИС И ДДЗЗ

А.И. Павлова

Работа посвящена агроэкологической типизации сельскохозяйственных земель с применением современных методов геоинформационного анализа данных и машинного обучения.

Обоснование. *В литературе имеется небольшое количество работ, в которых освещены вопросы точности моделей машинного обучения (ММО) для агроэкологической типизации сельскохозяйственных земель. Для повышения точности классификации земель по космическим снимкам используют большое число растровых информационных слоев. Это существенно увеличивает время обучения и тестирования ММО, составления тематических карт классификации сельскохозяйственных земель. При таком подходе требуются существенные большие вычислительные ресурсы и значительный объем оперативной памяти компьютера. Растровые модели данных ГИС занимают значительно больший объем в сравнении с векторными моделями. В связи с этим исследования, посвященные автоматизированной агроэкологической (группировке, классификации) сельскохозяйственных земель с привлечением векторных моделей ГИС имеют практическую значимость.*

Целью исследования является применение методов ГИС, данных дистанционного зондирования Земли (ДДЗЗ) и методов машинного обучения для автоматической классификации сельскохозяйственных земель.

Материалы и методы. *В качестве материалов использованы синтезированные мультиспектральные снимки высокого пространственного*

разрешения Sentinel-2A, карты вегетационных индексов NDVI (Normalized Difference Vegetation Index), OSAVI (Optimized Soil Adjusted Vegetation Index), EVI2 (Enhanced Vegetation Index2), NDWI (Normalized Difference Water Index), SAVI, PVI, GDVI, MCARI, NDRE, TSAVI; топографическая карта, космические снимки ALOS DSM (30 м/пиксел) и ALOS PALSAR (12,5 м/пиксел), почвенная карта и результаты полевого обследования. Измерения на местности проводились с использованием спутникового геодезического приемника Trimble-2 и включали определение координат характерных точек границ земельных участков, элементов рельефа, почвенное обследование.

Создание цифровой пространственной модели землепользования осуществлялось помощью ГИС ArcGIS и QGIS, в процессе машинного обучения использованы инженерные библиотеки Python.

Результаты. Агроэкологическая группировка земель реализована на примере хозяйства АО «Зерно Сибири» Новосибирского района Новосибирской области с использованием методов машинного обучения: машина опорных векторов (Support Vector Machine, SVM), метод случайного леса (Random Forest, RF), деревья решений (Decision Tree, DT), метод ближайших соседей KNN (*k*-nearest neighbors). Лучшие показатели точности имеет модель машинного обучения RF. Точность модели в среднем составила 97,9% (при обучении 99,9%, тестировании 98,8%, кросс-валидации 95,0%). Величина Root Mean Square Error (RMSE) равна 0,006: для обучающей 0,001; тестовой 0,076; валидационной выборки 0,123 соответственно). Среднее значение коэффициента каппа равно 0,97 (для обучающей 1,00; тестовой 0,982; валидационной выборки 0,927).

Заключение. Предложенный способ агроэкологической группировки сельскохозяйственных земель с помощью ГИС, ДДЗЗ и методов машинного обучения позволил выделить информативные количественные показатели рельефа. Основная суть предложенного способа состоит в создании модели машинного обучения (ММО) на основе пространственного набора данных. Набор пространственных данных формируется с помощью методов геоинформационного анализа и включает: геоморфометрические карты, карты агрометеорологических параметров, почвенную карту, карту внутрихозяйственного землеустройства и операционно-территориальные единицы классификации земель. Применение векторной модели данных позволило осуществить агроэкологическую группировку сельскохозяйственных земель в автоматизированном режиме, ускорить трудоемкий процесс распознавания растровых данных, повысить объективность работ. Предложенный способ агроэкологической агроэкологической группировки земель позволяет с

помощью методов геоинформационного анализа, ДДЗЗ и машинного обучения учесть совокупность показателей рельефа и почвенно-экологических условий.

Ключевые слова: методы машинного обучения; географические (геоинформационные) системы; данные дистанционного зондирования Земли; агро-экологическая типизация; сельскохозяйственные земли; космические снимки

Для цитирования. Павлова А.И. Агроэкологическая типизации сельскохозяйственных земель с применением методов машинного обучения, ГИС и ДДЗЗ // Siberian Journal of Life Sciences and Agriculture. 2023. Т. 15, №6. С. 72-88. DOI: 10.12731/2658-6649-2023-15-6-960

Original article

AGRO-ECOLOGICAL CLASSIFICATION OF AGRICULTURAL LAND USING MACHINE LEARNING, GIS AND REMOTE SENSING DATA

A.I. Pavlova

The paper is devoted to agro-ecological classification of agricultural land using modern methods of geo-information data analysis and machine learning.

Background. *There are few works in the literature, which cover the issues of accuracy of machine learning (MLL) models for agro-ecological grouping of agricultural land. A large number of raster information layers are used to improve the accuracy of land classification from satellite images. This considerably increases the time of training and testing MMOs, producing thematic maps of agricultural land classification. This approach requires considerably high computing resources and a considerable amount of computer RAM. Raster GIS data models occupy a much larger volume than vector models. In this regard, research on automated agro-ecological (grouping, classification) of agricultural land using vector GIS models is of practical importance.*

Purpose. *The aim of the study is to apply GIS methods, remote sensing (ERS) data and machine learning methods for agricultural land grouping.*

Materials and methods. *The materials used were synthesized multispectral high spatial resolution Sentinel-2A images, maps of vegetation indices NDVI (Normalized Difference Vegetation Index), OSAVI (Optimized Soil Adjusted Vegetation Index), EVI2 (Enhanced Vegetation Index2), NDWI (Normalized Difference Water Index), SAVI, PVI, GDVI, MCARI, NDRE, TSAVI; topographic map, ALOS DSM (30 m/pixel) and ALOS PALSAR (12.5 m/pixel) satellite images, soil map and field survey results. Field measurements were carried out using the Triumph-2*

satellite geodetic receiver and included determination of coordinates of characteristic points of land plot boundaries, relief elements, and soil survey.

Digital spatial model of land use was created using GIS ArcGIS and QGIS, Python engineering libraries were used in the machine learning process.

Results. Agro-ecological grouping of lands was realized by the example of the farm “Zerno Sibiri” of Novosibirsk region using the following machine learning methods: Random Forest (RF) method, Decision Tree (DT), k-nearest neighbours method (KNN). The best accuracy is the RF machine learning model. The accuracy of the model averaged 97.9% (with training 99.9%, testing 98.8%, and cross validation 95.0%). The Root Mean Square Error (RMSE) is 0.006: for training sample 0.001; test sample 0.076; validation sample 0.123 respectively). The mean kappa coefficient was 0.97 (1.00 for the training sample; 0.982 for the test sample, and 0.927 for the validation sample).

Conclusion. The offered method of agro-ecological grouping of agricultural lands by means of GIS, RS data and machine learning methods enabled to distinguish informative quantitative indicators of the relief. The main essence of the proposed method is to create a machine learning model (MLM) based on a spatial dataset. The spatial dataset is formed using geoinformation analysis methods and includes: geomorphometric maps, maps of agrometeorological parameters, soil map, on-farm land management map and operational-territorial units of land classification. The application of vector data model allowed for agro-ecological grouping of agricultural lands in automated mode, to accelerate labor-intensive process of raster data recognition, to increase objectivity of the work. The suggested method of agro-ecological agro-ecological grouping of lands allows taking into account the totality of relief and soil-ecological conditions indicators with the help of geoinformation analysis methods, remote sensing and machine learning.

Keywords: machine learning methods; geographic (geoinformation) systems; remote sensing data

For citation. Pavlova A.I. Agro-Ecological Classification of Agricultural Land using Machine Learning, GIS and Remote Sensing Data. Siberian Journal of Life Sciences and Agriculture, 2023, vol. 15, no. 6, pp. 72-88. DOI: 10.12731/2658-6649-2023-15-6-960

Введение

Для разработки адаптивно-ландшафтных систем земледелия, рационального размещения севооборотов необходима агроэкологическая типизация (классификация) сельскохозяйственных земель [7, 16]. В ходе агроэкологической оценки и типизации земель применяют метод визу-

ального анализа отдельных морфометрических показателей рельефа [5, 8, 12]. В работе [2] описаны косвенные признаки визуального метода дешифрирования переувлажненных земель, выделяемых по космическим аэрофотоснимкам без привлечения количественных показателей рельефа.

В зарубежной литературе используют количественные показатели рельефа (геоморфометрические параметры в различных целях: для комплексной оценки территории [20, 32], классификации земель по степени их пригодности [18], прогнозного почвенного картографирования [17, 23], оценки степени развития эрозионных процессов [22], классификации форм рельефа [27-28] и др. Развитие методов цифрового моделирования рельефа, доступность данных дистанционного зондирования среднего и высокого пространственного разрешения, совершенствование открытых геоинформационных систем (ГИС) способствует расширению перечня геоморфометрических величин для описания топографической поверхности и анализа геоморфологических условий сельскохозяйственных земель [17].

Особенности геоморфологических условий Западно-Сибирской равнины проанализированы в работах [1, 6, 10, 11]. В работах [4, 6] приводятся сведения о пространственном распределении морфометрических показателей (углов наклона рельефа, горизонтального и вертикального расчленения рельефа. А.Д. Орловым [13] выполнено эрозионное районирование Приобского плато Новосибирской области на основе анализа глубины вреза речных долин, углов наклона рельефа, длины склонов усредненных по отношению районов и подрайонов. Автор указывает на зависимость характера рисунка горизонталей и степени развития эрозионных процессов. В работе [15] выполнена автоматическая классификация форм и типов рельефа на примере Венгерского района Новосибирской области с привлечением морфометрических показателей рельефа в скользящем окне на основе анализа морфометрических карт рельефа. При этом выбор размера скользящего окна влияет на результаты классификации морфокомплексов рельефа. Актуальными являются исследования, посвященные разработке методических подходов автоматической классификации (типизации) сельскохозяйственных земель на основе комплексной геоморфологической оценки рельефа. Для решения проблемы автоматической классификации сельскохозяйственных земель необходимо применение методов геоморфометрии и машинного обучения.

Научная новизна исследований состоит в автоматической классификации сельскохозяйственных земель на основе комплексной оценки геоморфологических условий сельскохозяйственных земель методами геоморфометрии.

Цель исследований – агроэкологическая классификация (типизация) сельскохозяйственных земель с применением алгоритмов машинного обучения, данных дистанционного зондирования Земли (ДДЗЗ) высокого пространственного разрешения.

Материалы и методы исследований

Исследования выполнены на примере хозяйства АО «Зерно Сибири» Новосибирского района Новосибирской области ($54^{\circ}51'03''$ с.ш., $82^{\circ}31'34''$ в.д.; $54^{\circ}59'55''$ с.ш., $82^{\circ}30'56''$ в.д.; $54^{\circ}59'33''$ с.ш., $82^{\circ}42'52''$ в.д.; $54^{\circ}52'16''$ с.ш., $82^{\circ}43'59''$ в.д.) (рис. 1). Территория исследований расположена вблизи г. Новосибирска, международного аэропорта Толмачево, с. Красноглинное. Основное направление деятельности хозяйства – зерновое и животноводческое. В геоморфологическом отношении изучаемая территория относится к плоской равнине со слаборасчлененным рельефом. Преобладающие абсолютные высоты местности составляют от 111 до 144 м. Углы наклона рельефа в среднем составляют от $0,5$ до $1,5^{\circ}$, вертикальное расчленение рельефа 5–20 м, горизонтальное расчленение незначительное до $0,5$ км/км².

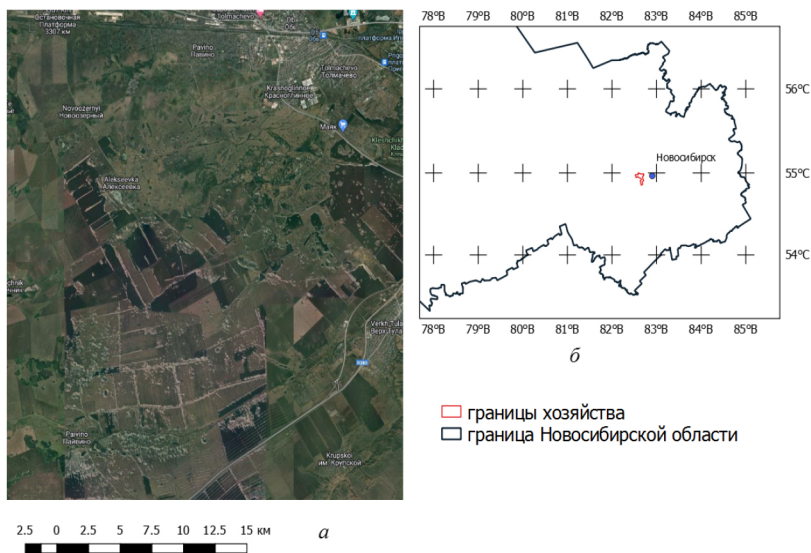


Рис. 1. Территория исследований АО «Зерно Сибири» Новосибирского района Новосибирской области: *a* – изображение территории на космических снимках Google; *б* – отображение территории исследований в административных границах Новосибирской области.

В качестве материалов использованы синтезированные мультиспектральные снимки высокого пространственного разрешения Sentinel-2A, карты вегетационных индексов NDVI (Normalized Difference Vegetation Index), OSAVI (Optimized Soil Adjusted Vegetation Index), EVI2 (Enhanced Vegetation Index2), NDWI (Normalized Difference Water Index), SAVI, PVI, GDVI, MCARI, NDRE, TSAVI; топографическая карта, космические снимки ALOS DSM (30 м/пиксел) и ALOS PALSAR (12.5 м/пиксел) [19], почвенная карта и результаты полевого обследования территории. Наземные измерения на местности проводились с использованием спутникового геодезического приемника Triump-2 и включали определение координат характерных точек границ земельных участков, элементов рельефа, корректировочные почвенные обследования.

Методы исследований: метод случайного леса (Random Forest, RF) [21], деревья решений (Decision Tree, DT) [3, 9, 26, 29], метод ближайших соседей KNN (k-nearest neighbors) [3, 9]. При создании модели машинного обучения (ММО) создан набор пространственных данных с помощью ГИС ArcGIS 10 и включает: геоморфометрические карты, почвенную карту, карту внутрихозяйственного землеустройства и операционно-территориальные единицы классификации земель. Совокупность операционно-территориальных единиц классификации земель представляется двумерной матрицей «объекты-признаки». Исходными признаками в модели машинного обучения служили геоморфометрические показатели рельефа (31 признак), почвенно-экологический индекс, уровень залегания грунтовых вод.

В проведенных исследованиях вычислены фундаментальные морфометрические показатели (параметры, величина, показатель), которые согласно теории дифференциальной геометрии и теории топографической поверхности представляются функцией двух переменных плановых координат точки на топографической поверхности, описывающей ее свойства [23, 24, 30].

Комбинированные морфометрические показатели включают локальные и нелокальные переменные, для описания геометрических особенностей территории и относительного положения некоторой точки на топографической поверхности [24, 30]. В работе использованы следующие морфометрические показатели:

- топографический индекс влажности (TWI Topographic Wetness Index);
- топографический индекс расчлененности (устойчивости местности) TRI (Topographic Ruggedness Index);

- индекс оценки степени эрозионных процессов LSF (Length Steepness Factor);
- топографический индекс отношения уклона и длины склонов Slope-Length;
- топографический индекс Mid-Slope Position;
- составной топографический индекс TCI (Topographic Compound index) [25].

Индекс оценки степени эрозионных процессов LSF (Length Steepness Factor) входит в качестве основного показателя универсального уравнения потерь почвы USLE (Universal Soil Loss Equation) и более современной версии для оценки RUSLE (Revised Universal Soil Loss Equation) и модифицированную версию MUSLE (Modified Universal Soil Loss Equation).

Формирование набора обучающих данных осуществлялось случайным образом, таким образом, чтобы обучающие примеры (OTE) размещались на разных участках хозяйства. При построении модели машинного обучения (ММО) выполнялись процедуры проверки пропущенных значений. Нормализация данных выполнена с целью приведения набора пространственных данных к единому масштабу и повышения точности модели машинного обучения. Для этого использован способ мин-макс нормализации.

В процессе классификации сельскохозяйственных земель набор пространственных данных был использован для обучения, тестирования и валидационной оценки: обучающая (70% от общего количества примеров), тестовая (15%) и кросс-валидационная выборки данных (15%). Подбор размера выборок для обучения, тестирования и кросс-валидации осуществлялся эмпирическим путем путем сравнения анализа результатов точности моделей машинного обучения.

Классификация сельскохозяйственных земель выполнена с применением подхода машинного обучения с учителем, в соответствии с которым заданы классы объектов.

Результаты исследований

С помощью метода Random Forest (количество деревьев решений принятой равным 100) выполнена агроэкологическая типизация сельскохозяйственных земель. В процессе машинного обучения использованы следующие классы объектов (агроэкологические типы земель): 1 – плакорные (зональные) земли, 2 – слабоэрозионные земли, 3 – гидроморфные (переувлажненные) земли, 4 – полугидроморфные (среднепереувлажненные) земли, 5 – солонцовые земли.

Набор пространственных данных, использованный в работе состоял из 555490 примеров. Распределение примеров по классам неравномерное. К плакорным землям отнесены 120084 ОТЕ, к слабоэрозионным – 2329, к гидроморфным землям – 51913 ОТЕ, к полугидроморфным землям – 102886 ОТЕ и к солонцовым землям – 22788 ОТЕ. Такое неравномерное распределение по классам объектов связано с территориальным распределением земель по группам. Например, слабоэрозионные земли, распространены на незначительной части территории (менее 1% от площади) хозяйства по вершинам увалов.

Результаты группировки сельскохозяйственных земель, полученные с помощью метода RF, представлены на рис. 1.

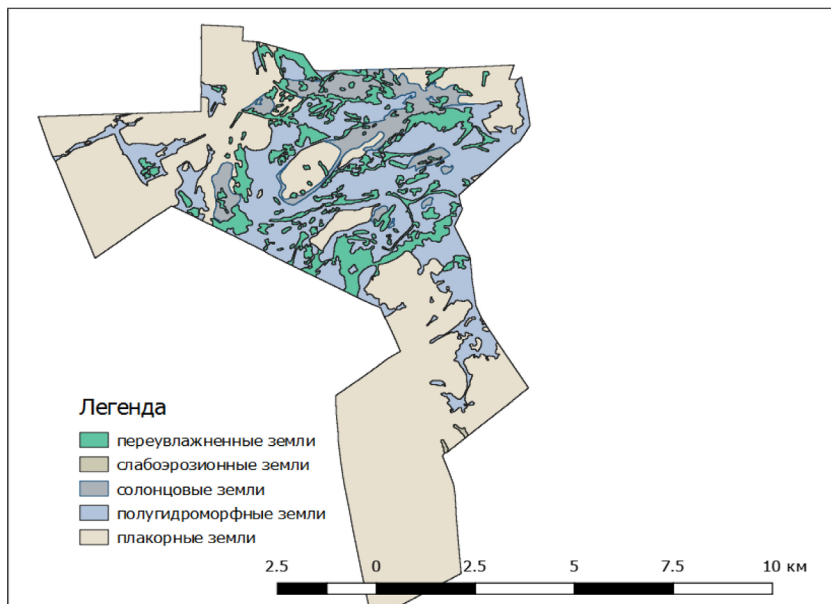


Рис. 1. Карта агроэкологических типов сельскохозяйственных земель АО «Зерно Сибири» Новосибирского района Новосибирской области

Результаты классификации различными алгоритмами приведены в табл. 1. Модель машинного обучения, построенная на основе RF имеет более высокие значения показателей точности в сравнении с остальными моделями. Значение точности модели в среднем составляет 97,9%. При этом точность классификации, вычисленная на валидационной выборке в сравнении с обучающей выборкой отличается в меньшую сторону на 4,9%. Коэффициент

каппа в среднем составляет 97,0%. Средняя квадратическая ошибка классификации для валидационной выборки составила 0,123. Метод RF имеет более высокую скорость обучения в сравнении с методом KNN в 3,5 раза быстрее.

Среднее значение точности модели DT, рассчитанное для обучающего набора данных высокое и составило 99,9%. Однако различия в точности проявляются на тестовых и валидационных данных. Точность классификации для валидационной выборки в сравнении с методом RF меньше на 5,9%, а коэффициент каппа на 8,4%.

Метод KNN обладает высокой скоростью машинного обучения и классификации данных. Точность обучения составила 89,9%, однако точность классификации, вычисленная для тестовой и валидационной выборок уменьшается на 2,3% и на 8,6% соответственно. Коэффициент каппа существенно отличается на разных выборках данных: на 3,3% для тестовой и 12,7% для валидационной.

Показатели точности Precision, Recall F1 score, рассчитанные для обучающей, тестовой и валидационной выборок для метода RF оказались более высокими (97%) в сравнении с другими методами. Для метода DT данные показатели ниже на 2%, метода KNN меньше на 12%.

Таблица 1.

Результаты точности моделей машинного обучения

Алгоритм	Time, сек	Acc train	Acc test	Acc val	RMSE train	RMSE test	RMSE val	Kappa train	Kappa test	Kappa val
RF	4,5	0,999	0,988	0,950	0,001	0,076	0,123	1,000	0,982	0,927
DT	14,4	0,999	0,973	0,891	0,003	0,103	0,419	1,000	0,957	0,843
KNN	15,7	0,899	0,876	0,813	0,424	0,522	0,779	0,849	0,816	0,722

Продолжение таблицы 1.

Результаты точности моделей машинного обучения

Алгоритм	Precision weighted		Recall weighted		F1-score weighted	
	test	val	test	val	test	val
RF	0,99	0,95	0,99	0,95	0,99	0,95
DT	0,98	0,92	0,97	0,92	0,97	0,92
KNN	0,88	0,88	0,81	0,81	0,88	0,82

Примечание. В строках: алгоритмы машинного обучения KNN – метод ближайших соседей, DT – метод деревьев решений, RF – метод случайного леса. В столбцах: Acc (Accuracy) – точность модели машинного обучения; Prec (Precision, %) – точность классификации по классам, %; Recall – полнота (%); F1-score – мера, или гармоническое среднее между точностью и полнотой; RMSE (Root Mean Square Error) – средняя квадратическая ошибка; kappa – коэффициент Cohen's kappa statistic.

На территории хозяйства наибольшее распространение получили плакорные (зональные) земли 4273 га, занимающие чуть больше половины площади хозяйства (56,4%). Плакорные земли залегают на плоских элементарных поверхностях рельефа по вершинам пологих увалов и плоских горизонтальных поверхностях водоразделов. Плакорные земли представлены автоморфными почвами черноземами обыкновенными и выщелоченными среднетощими среднетугумусными тяжелосуглинистыми и среднесуглинистыми, а также включениями темно-серых лесных и серых лесных почв тяжелосуглинистыми и среднесуглинистыми.

Слабоэрозийные земли занимают незначительную часть территории хозяйства 7 га (0,09% от площади хозяйства). Земли данной группы занимают повышенные участки равнин по пологим склонам увалов. Для земель данной группы ограничивающим фактором возделывания сельскохозяйственных культур является водная эрозия почв. Земли данной группы представлены черноземами выщелоченными среднетощими малотугумусными слабосмытыми.

Переувлажненные земли занимают значительную часть территории хозяйства (11,2% от общей площади), получили распространение преимущественно в северной части на площади 847 га. Земли данной группы приурочены к депрессиям в рельефа – замкнутые понижения в виде озерных западин круглой или вытянутой формы). Земли залегают на участках пониженной плоской равнины. Ограничивающим фактором ведения сельского хозяйства является постоянное переувлажнение почв, поэтому земли требуют проведения специальных агротехнических мероприятий.

Солонцовые земли распространены на площади 419 га (5,53% от площади хозяйства) залегают в понижениях рельефа по окраинам болот и блюдцеобразных понижений плоских и вогнутых участков равнины. Почвенный покров представлен солонцами черноземно-луговыми мелкими и солонцами черноземно-луговыми солончаковыми корковыми.

Полугидроморфные (среднепереувлажненные) земли занимают большую часть территории (26,8% от площади хозяйства) 2026 га. Почвенный покров земель данной контрастный и представлен полугидроморфными почвами лугово-черноземными, луговыми обычными среднетощими среднетугумусными, луговыми осолоделыми среднетощими среднетугумусными, луговыми карбонатными среднетощими среднетугумусными, луговыми солонцеватыми среднетощими среднетугумусными, луговыми солончаковыми среднетощими малотугумусными, а также лугово-черноземными обычными и выщелоченными среднетощими среднетугумусными, лугово-черноземными осолоделыми, лугово-черноземными

карбонатными, лугово-чернозменными солончаковыми среднемощными среднегугусными. Земли данной залегают в мезопонижениях рельефа на пониженных вогнутых участках равнин.

Заключение

Предложенный способ агроэкологической типизации сельскохозяйственных земель с помощью ГИС, ДДЗЗ и методов машинного обучения позволил выделить информативные количественные показатели рельефа. Основная суть предложенного способа состоит в создании модели машинного обучения (ММО) на основе пространственного набора данных. Набор пространственных данных формируется с помощью методов геоинформационного анализа и включает: геоморфометрические карты, карты агрометеорологических параметров, почвенную карту, карту внутрихозяйственного землеустройства и операционно-территориальные единицы классификации земель. Применение векторной модели данных позволило осуществить агроэкологическую группировку сельскохозяйственных земель в автоматизированном режиме, ускорить трудоемкий процесс распознавания растровых данных, повысить объективность работ. Предложенный способ агроэкологической агроэкологической типизации земель позволяет с помощью методов геоинформационного анализа, ДДЗЗ и машинного обучения учесть совокупность показателей рельефа и почвенно-экологических условий.

Список литературы

1. Архипов С.А., Вдовин В.В., Мизеров Б.В., Николаев В.А. Этап формирования современного рельефа. Четвертичный период // Западно-Сибирская равнина. История развития рельефа Сибири и Дальнего востока. М.: Наука, 1970. С. 66-204.
2. Ахтырцев А.Б. Принципы и методика картографирования переувлажненных земель лесостепи // Вестник Воронежского гос. ун-та. 2002. Т.42. № 3. С.53-60.
3. Вьюгин В.В. Математические основы теории машинного обучения и прогнозирования. М. МЦМНО. 2013. 387 с.
4. Гриценко, А.Г. Карта густоты расчленения рельефа юга Западно-Сибирской равнины // Геоморфологические формации Сибири. Новосибирск: Ин-т геологии и геофизики СО АН СССР, 1978. С. 126-132.
5. Ирмулатов Б.Р., Алманова Ж.С. Опыт агроэкологической оценки земель и проектирования адаптивно-ландшафтных систем земледелия в Северном Казахстане на примере Павлодарской области // Сельскохозяйственные науки. 2017. Вып. 5 (59). С. 199-203.
6. Зятькова Л.К. Структурная геоморфология Западной Сибири. Новосибирск, 1979. 200 с.

7. Каличкин В.К., Павлова А.И. Агрономические геоинформационные системы. Новосибирск: СФНЦА РАН, 2018. 347 с.
8. Макаренко Е.Л. Агроэкологическая оценка и картографирование земель Верхнего Приангарья // География и природные ресурсы. 2019. № 1. С. 146-155.
9. Миронов А. Машинное обучение. М.: Макс-пресс. 2018. 100 с.
10. Николаев В.А. Геоморфологические системы Сибири // Проблемы системно-формационного подхода к познанию рельефа / В.А. Николаев. Новосибирск: Наука, 1982. С. 108-123.
11. Николаевская Е.М. Морфометрический анализ Западно-Сибирской равнины / Е.М. Николаевская // Геоморфология. 1970. № 4. С. 41-51.
12. Онищук В.С. Результаты агроэкологической оценки земель равнинных ландшафтов Приамурья для проектирования адаптивно-ландшафтной системы земледелия по ГИС-технологии // Адаптивные технологии в растениеводстве Амурской области: Сб. науч. трудов. Благовещенск: Изд-во Дальневост. аграр. ун-та, 2015. С. 68-73.
13. Орлов А.Д. Водная эрозия почв Новосибирского Приобья. Новосибирск: Наука, 1971. 175 с.
14. Павлова А.И. Анализ методов интерполирования для создания цифровых моделей рельефа // Автометрия. 2017. Т. 53. № 2. С. 86–94.
15. Чупина Д.А., Зольников И.Д. Геоинформационное картографирование форм и типов рельефа на основе морфометрического анализа // Геодезия и картография. 2016. № 6. С. 35-43.
16. Чурсин А.И., Крючкова Н.А. Агроэкологическая оценка земель в системе рационального природопользования. Пенза: ПГУАС, 2016. 192 с.
17. Abdi A.M. Land cover and land use classification performance of machine learning algorithms in a boreal landscape using Sentinel-2 data // GIScience and Remote Sensing, 2020, vol. 57, is. 1, pp. 1-20. <https://doi.org/10.1080/15481603.2019.1650447>
18. Aleksis D.E., Bathrellos G., Skilodimou H.D., Gmvroula D.E. Land Suitability Mapping Using Geochemical and Spatial Analysis Methods // *Applied Sciences*, 2021, vol. 11, no. 12, 5404. <https://doi.org/10.3390/app11125404>
19. ALOS PALSAR-2. 2023. URL: <https://www.eorc.jaxa.jp/ALOS-2/en/about/palsar2.htm> (дата обращения 10.05.2023).
20. Amelia V., Sinaga S., Bhermana A. Agroecological management at sloping land areas using land resources evaluation approach to achieve sustainable agricultural development (a case study of Gunung Mas Regency, Central Kalimantan Province, Indonesia) // IOP Conf. Series: Earth and Environmental Science. 2021. vol. 782. article 032061. URL: <https://iopscience.iop.org/article/10.1088/1755-1315/782/3/032061/pdf> (дата обращения 16.03.2023).

21. Breiman L. Random Forests // *Machine Learning*, 2001, vol. 45, no.1, pp. 5–32. <https://doi.org/10.1023/a:1010933404324>
22. Emmanuel F., Solomon G. Tesfamichael, Fethi A. A combination of Sentinel-1 RADAR and Sentinel-2 multispectral data improves classification of morphologically similar savanna woody plants // *European Journal of Remote Sensing*, 2022, vol. 55, no. 1, pp. 372-387.
23. Florinsky I. V. *Digital Terrain Analysis in Soil Science and Geology*. 2nd ed. Amsterdam: Elsevier Academic Press, 2016. 486 p.
24. Florinsky I. Geomorphometry on the surface of a triaxial ellipsoid: Towards the solution of the problem // *International Journal of Geographical Information Science*. 2018, vol. 32, no. 8, pp. 1558-1571. <https://doi.org/10.1080/13658816.2018.1461220>
25. Galin E., Guerin E., Peytavie A., Cordonnier G., Cani M.P., Benes P, Gain J. A Review of Digital Terrain Modeling. 2019. URL: <https://hal.science/hal-02097510/file/A%20Review%20of%20Digital%20Terrain%20Modeling.pdf> (дата обращения 12.03.2023).
26. Jenhani I., Amor N.B., Elouedi Z. Decision trees as possibility classifiers // *International Journal of Approximate Reasoning*, 2008, vol. 48, pp. 784 -807.
27. Lin S., Chen N., He Z. Automatic Landform Recognition from the Perspective of Watershed Spatial Structure Based on Digital Elevation Models // *Remote Sensing*, 2021, vol. 13, no. 19, article 3926. <https://doi.org/10.3390/rs13193926> (дата обращения 25.02.2023).
28. Mashimbye Z.E., Loggenberg K. A Scoping Review of Landform Classification Using Geospatial Methods // *Geomatics*, 2023, no. 3, pp. 93-114.
29. Mendonca L.F., Vieira S.M., Sousa J.M.C. Decision tree search methods in fuzzy modeling and classification// *International Journal of Approximate Reasoning*, 2007, vol. 44, is. 2, pp. 106-123.
30. Shary P. A., Sharaya L. S., Mitusov A. V. Fundamental quantitative methods of land surface analysis // *Geoderma*, 2002, no. 107, pp. 1-32.
31. Xiong L., Li S., Tang G., Strobl J. Geomorphometry and terrain analysis: data, methods, platforms and applications // *Earth-Science Reviews*, 2022, vol. 233, article 104191. <https://doi.org/10.1016/j.earscirev.2022.104191>
32. Xue J., Su B. Significant Remote Sensing Vegetation Indices: a review of developments and applications // *Journal of Sensors*, 2017, Article 1353691. <https://doi.org/10.1155/2017/1353691>

References

1. Arkhipov S.A., Vdovin V.V., Mizerov B.V., Nikolaev V.A. Etap formirovaniya sovremennogo relefa. [The stage of formation of modern relief. Quaternary pe-

- riod]. *In the book West Siberian Plain. History of Relief Development in Siberia and the Far East*. Moscow: Nauka, 1970, pp. 66-204.
2. Akhtyrtev A.B. Principy i metodika kartografirovaniya pereuvlazhnennyh zemel le-sostep [Principles and methods of mapping of overmoistened lands of forest-steppe]. *Bulletin of Voronezh State University*, 2002, vol. 42, no. 3, pp. 53-60.
 3. Vyugin V.V. Matematicheskie osnovy teorii mashinnogo obucheniya i prognoz-irvoaniya [Mathematical Bases of the Theory of Machine Learning and Fore-casting]. M.: ICMNE, 2013, 387 p.
 4. Gritsenko, A.G. Karta gustoty raschleneniya rel'efa yuga Zapadno-Sibirskoj ravniny [Map of relief dissection density in the south of the West Siberian Plain]. *Geomorphological formations of Siberia*. Novosibirsk: Institute of Geology & Geophysics, SB AS USSR, 1978, pp. 126-132.
 5. Irmulatov B.R., Almanova Zh. S. Opyt agroekologicheskoy ocenki zemel' i proektirovaniya adaptivno-landshaftnyh sistem zemledeliya v Severnom Ka-zakhstane na primere Pavlodarskoj oblasti [Experience of agro-ecological assess-ment of lands and design of adaptive-landscape farming systems in Northern Kazakhstan by the example of Pavlodar region]. *Agricultural Sciences*, 2017, is. 5 (59), pp. 199-203.
 6. Zyatkova L.K. *Strukturnaya geomorfologiya Zapadnoj Sibiri* [Structural geo-morphology of Western Siberia]. Novosibirsk, 1979, 200 p.
 7. Kalichkin V.K., Pavlova A.I. *Agronomicheskie geoinformacionnye sistemy* [Agro-nomic geoinformation systems]. Novosibirsk: SFNCA RAS, 2018, 347 p.
 8. Makarenko E.L. Agroekologicheskaya ocenka i kartografirovanie zemel Verhnego Priangar'ya [Agroecological assessment and land mapping of Upper Priangarye]. *Geography and natural resource*, 2019, no. 1, pp. 146-155.
 9. Mironov A. *Mashinnoe obuchenie* [Machine learning]. Moscow: Max-Press, 2018, 100 p.
 10. Nikolaev V.A. Geomorfologicheskie sistemy Sibiri [Geomorphological systems of Siberia]. *Problems of system-formational approach to cognition of relief*. No-vo-sibirsk: Nauka, 1982, pp. 108-123.
 11. Nikolaevskaya E.M. Morfometricheskij analiz Zapadno-Sibirskoj ravniny [Mor-phometric Analysis of West Siberian Plain]. *Geomorphology*, 1970, no. 4, pp. 41-51.
 12. Onishchuk V.S. Rezul'taty agroekologicheskoy ocenki zemel ravninnyh land-shaftov Priamur'ya dlya proektirovaniya adaptivno-landshaftnoj sistemy zem-ledeliya po GIS-tehnologii [Results of agro-ecological assessment of the plains landscapes of Priamurye for designing adaptive landscape farming system using GIS-technology]. *Adaptive technologies in crop farming in the Amur Region:*

- Collection of scientific papers*. Blagoveshchensk: Far Eastern Agrarian University Press, 2015, pp. 68-73.
13. Orlov A.D. *Vodnaya eroziya pochv Novosibirskogo Priobya* [Water erosion of soils of Novosibirsk Priobye]. Novosibirsk: Nauka, 1971, 175 p.
 14. Pavlova A.I. Analysis of interpolation methods for creating digital elevation models. *Autometry*, 2017, vol. 53, no. 2, pp. 86-94.
 15. Chupina D.A., Zolnikov I.D. Geoinformacionnoe kartografirovanie form i tipov rel'efa na osnove morfometricheskogo analiza [Geoinformation mapping of landforms and relief types based on morphometric analysis]. *Geodesy and Cartography*, 2016, no. 6, pp. 35-43.
 16. Chursin A.I., Kryuchkova N.A. *Agroekologicheskaya ocenka zemel v sisteme racional'nogo prirodopolzovaniya* [Agroecological assessment of lands in the system of rational nature management]. Penza: PSUAS, 2016, 192 p.
 17. Abdi A.M. Land cover and land use classification performance of machine learning algorithms in a boreal landscape using Sentinel-2 data. *GIScience and Remote Sensing*, 2020, vol. 57, is. 1, pp.1-20. <https://doi.org/10.1080/15481603.2019.1650447>
 18. Aleksis D.E., Bathrellos G., Skilodimou H.D., Gmvroula D.E. Land Suitability Mapping Using Geochemical and Spatial Analysis Methods. *Applied Sciences*, 2021, vol. 11, no. 12, 5404. <https://doi.org/10.3390/app11125404>
 19. ALOS PALSAR-2. 2023. URL: <https://www.eorc.jaxa.jp/ALOS-2/en/about/palsar2.htm> (accessed 10.05.2023)
 20. Amelia V., Sinaga S., Bhermana A. Agroecological management at sloping land areas using land resources evaluation approach to achieve sustainable agricultural development (a case study of Gunung Mas Regency, Central Kalimantan Province, Indonesia). *IOP Conf. Series: Earth and Environmental Science*. 2021, vol. 782, article 032061. <https://iopscience.iop.org/article/10.1088/1755-1315/782/3/032061/pdf> (accessed 16.03.2023).
 21. Breiman L. Random Forests. *Machine Learning*, 2001, vol. 45, no.1, pp. 5–32. <https://doi.org/10.1023/a:1010933404324>
 22. Emmanuel F., Solomon G. Tesfamichael, Fethi A. A combination of Sentinel-1 RADAR and Sentinel-2 multispectral data improves classification of morphologically similar savanna woody plants. *European Journal of Remote Sensing*, 2022, vol. 55, no. 1, pp. 372-387.
 23. Florinsky I. V. *Digital Terrain Analysis in Soil Science and Geology*. 2nd ed. Amsterdam: Elsevier Academic Press, 2016, 486 p.
 24. Florinsky I. Geomorphometry on the surface of a triaxial ellipsoid: Towards the solution of the problem. *International Journal of Geographical Information Science*, 2018, vol. 32, no. 8, pp. 1558-1571. <https://doi.org/10.1080/13658816.2018.1461220>

25. Galin E., Guerin E., Peytavie A., Cordonnier G., Cani M.P., Benes P, Gain J. A Review of Digital Terrain Modeling. 2019. <https://hal.science/hal-02097510/file/A%20Review%20of%20Digital%20Terrain%20Modeling.pdf> (accessed 12.03.2023).
26. Jenhani I., Amor N.B., Elouedi Z. Decision trees as possibility classifiers. *International Journal of Approximate Reasoning*, 2008, vol. 48, pp. 784-807.
27. Lin S., Chen N., He Z. Automatic Landform Recognition from the Perspective of Watershed Spatial Structure Based on Digital Elevation Models. *Remote Sensing*, 2021, vol. 13, no. 19, article 3926 <https://doi.org/10.3390/rs13193926>
28. Mashimbye Z.E., Loggenberg K. A Scoping Review of Landform Classification Using Geospatial Methods. *Geomatics*, 2023, no. 3, pp. 93–114.
29. Mendonca L.F., Vieira S.M., Sousa J.M.C. Decision tree search methods in fuzzy modeling and classification. *International Journal of Approximate Reasoning*, 2007, vol.44, is. 2, pp. 106-123.
30. Shary P. A., Sharaya L. S., Mitusov A. V. Fundamental quantitative methods of land surface analysis. *Geoderma*, 2002, no. 107, pp. 1-32.
31. Xiong L., Li S., Tang G., Strobl J. Geomorphometry and terrain analysis: data, methods, platforms and applications. *Earth-Science Reviews*, 2022, vol. 233, article 104191. <https://doi.org/10.1016/j.earscirev.2022.104191>
32. Xue J., Su B. Significant Remote Sensing Vegetation Indices: a review of developments and applications. *Journal of Sensors*, 2017, Article 1353691. <https://doi.org/10.1155/2017/1353691>

ДААННЫЕ ОБ АВТОРЕ

Павлова Анна Илларионовна, кандидат технических наук, доцент

*Новосибирский государственный университет экономики и управления
ул. Каменская, 56, г. Новосибирск, 630039, Российская Федерация
annstab@mail.ru*

DATA ABOUT THE AUTHOR

Anna I. Pavlova, PhD (technical sciences), Associate Professor

*Novosibirsk State University of Economics and Management
56, Kamenskaya Str., Novosibirsk, 630039, Russian Federation
annstab@mail.ru*

SPIN-code: 8714-1140

ORCID: <https://orcid.org/0000-0001-6159-1439>

Поступила 25.04.2023

После рецензирования 23.05.2023

Принята 08.06.2023

Received 25.04.2023

Revised 23.05.2023

Accepted 08.06.2023