



АҚПАРАТТЫҚ-КОММУНИКАЦИЯЛЫҚ ТЕХНОЛОГИЯЛАР
ИНФОРМАЦИОННО-КОММУНИКАЦИОННЫЕ ТЕХНОЛОГИИ
INFORMATION AND COMMUNICATION TECHNOLOGIES

DOI 10.51885/1561-4212_2023_2_187

MPHTI 20.19.21, 28.23.37, 89.57.35

М.А. Саденова¹, Н.А. Бейсекенов², Н.А. Куленова³, Т.Б. Ануарбеков⁴, А.М. Мамышева⁵, Л.В. Шушкевич⁶

Восточно-Казахстанский технический университет им. Д. Серикбаева,

г. Усть-Каменогорск, Казахстан

¹E-mail: MSadenova@ektu.kz*

²E-mail: BNail@ektu.kz

³E-mail: NKulenova@ektu.kz

⁴E-mail: turikanuarbekov@gmail.com

⁵E-mail: asel_mam@mail.ru

⁶E-mail: LShushkevich@ektu.kz

**ИСПОЛЬЗОВАНИЕ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ
ДЛЯ ПОВЫШЕНИЯ ТОЧНОСТИ РАЗРЕШЕНИЯ ИНФОРМАЦИИ ДИСТАНЦИОННОГО
ЗОНДИРОВАНИЯ НА ПРИМЕРЕ ВЫРАЩИВАНИЯ ЗЕРНОБОБОВЫХ КУЛЬТУР
В ВОСТОЧНОМ КАЗАХСТАНЕ**

**ШЫҒЫС ҚАЗАҚСТАНДА ДӘНДІ-БҰРШАҚТЫ DAҚЫЛДАРДЫ ӨСІРУ МЫСАЛЫНДА
ҚАШЫҚТЫҚТАН ЗОНДТАУ АҚПАРАТЫНЫҢ АЖЫРАТЫМДЫЛЫҒЫН АРТТЫРУ
ҮШІН ЖАСАНДЫ НЕЙРОНДЫҚ ЖЕЛІЛЕРДІ ПАЙДАЛАҢУ**

**THE USE OF ARTIFICIAL NEURAL NETWORKS TO IMPROVE THE RESOLUTION
ACCURACY OF REMOTE SENSING INFORMATION ON THE EXAMPLE OF LEGUME
CROP CULTIVATION IN EASTERN KAZAKHSTAN**

Аннотация. Инновационное развитие агропромышленного комплекса сегодня связано с внедрением данных дистанционного зондирования Земли (ДЗЗ). В данном исследовании представлена разработка математической модели использования искусственных нейронных сетей для повышения точности разрешения информации дистанционного зондирования на примере выращивания зернобобовой культуры (гороха) в условиях почвенно-климатической зоны востока Казахстана. Модель выполнена на базе искусственных нейронных сетей с использованием специализированных библиотек TensorFlow, Keras на основе расчетов коэффициентов корреляции между значениями спектральных индексов, полученных в результате обработки спутниковых снимков и данных беспилотных летательных аппаратов (БПЛА). Результаты демонстрируют потенциал использования данных ДЗЗ и искусственных нейронных сетей для повышения разрешения информации космических снимков при выращивании сельскохозяйственных культур, обеспечивая более точную и своевременную информацию для принятия решений в «умном» сельском хозяйстве.

Ключевые слова: ДЗЗ, БПЛА, математическая модель, нейронные сети, TensorFlow, Keras, спутниковые снимки, зернобобовая культура, агрохимический анализ почвы, фазы вегетации.

Аңдатпа. Агроөнеркәсіптік кешеннің инновациялық дамуы бүгінде Жерді қашықтықтан зондтау (ЖҚЗ) деректерін енгізумен байланысты. Бұл зерттеу Қазақстанның шығысындағы топырақ-климаттық аймақта бұршақ тұқымдас бұршақ өсіру мысалында қашықтан зондтау ақпаратының ажыратымдылығын арттыру үшін жасанды нейрондық желілерді пайдалана отырып, математикалық модельді әзірлеуді ұсынады. Модель жасанды нейрондық желілерге негізделген, мамандандырылған TensorFlow, Keras кітапханаларын пайдалана отырып, спутниктік суреттер мен ұиқысыз ұшу аппараттарынан алынған мәліметтерді өңдеу нәтижесінде алынған спектрлік индекстердің мәндері арасындағы корреляция коэффициент-

терін есептеуге негізделген. Нәтижелер қашықтан зондтау деректері мен жасанды нейрондық желілерді өсімдік шаруашылығында зарыштық түсірілімдер туралы ақпараттың ажыратымдылығын жақсарту үшін пайдалану әлеуетін көрсетеді, ақылды ауыл шаруашылығында шешім қабылдау үшін дәлірек және уақтылы ақпарат береді.

Түйін сөздер: ЖҚЗ, ҰАА, математикалық модель, нейрондық желілер, TensorFlow, Keras, спутниктік суреттер, бұршақ дақылдары, агрохимиялық топырақ талдауы, вегетация фазалары.

Abstract. Innovative development of agro-industrial complex today is associated with the implementation of Earth remote sensing (ERS) data. This study presents the development of a mathematical model using artificial neural networks to improve the accuracy of remote sensing information resolution on the example of growing grain legume crop peas in the soil and climatic zone of eastern Kazakhstan. The model is based on artificial neural networks using specialized libraries TensorFlow, Keras based on calculations of correlation coefficients between the values of spectral indices obtained from satellite imagery processing and unmanned aerial vehicle (UAV) data. The results demonstrate the potential of using ERS data and artificial neural networks to improve the resolution of space imagery information in crop cultivation, providing more accurate and timely information for decision-making in smart agriculture.

Keywords: ERS, UAV, neural networks, TensorFlow, Keras, satellite imagery, sunflower, agrochemical soil analysis, vegetation phases.

Введение. С наступлением информационного века создание высокоточных и недорогих цифровых карт изображений становится все более важным для многих сфер агропроизводства и землеустройства. По мнению авторов [1], объединение реальных изображений дистанционного зондирования с информатикой и технологиями для создания интуитивно понятных и четких цифровых карт изображений стало сегодня тенденцией в разработке геоинформационных систем (ГИС). В их работе предлагается новый метод, основанный на Google Earth и технологии ГИС, для разработки прикладной системы, которая включает в себя сбор географической информации (в соответствии с получением изображений дистанционного зондирования), хранение и управление географической информацией (с использованием технологии базы данных) и создание трех модулей цифровых карт. В основе системы лежит создание региональной географической модели, управление атрибутивными данными, создание информационной базы данных, а также запрос и анализ информации. В последние годы, с развитием крупномасштабных данных изображений и технологии компьютерного искусственного интеллекта, искусственные нейронные сети (ИНС) получили возможность обучаться и имитировать сложные явления, а то преимущество, что они могут объединять данные из различных источников в одну классификацию, позволяет широко использовать ИНС в моделировании землепользования [2].

Литературный обзор. В настоящее время все более широкий размах приобретает применение сельскохозяйственных роботов. Так, в Японии различные их типы применяют для прополки рисовых полей и на чайных плантациях, для уборки такой крупногабаритной и тяжеловесной культуры как тыква, а также в виде автономных дронов для борьбы с вредителями. Автор N. Noguchi [3] провел исследования в области умного сельского хозяйства с использованием 5G и искусственного интеллекта (ИИ), а также роботов, работающих на сельскохозяйственных объектах. Ученые из Вьетнама [4] разработали метод классификации наземного растительного покрова, основанный на комбинации спутниковых снимков Sentinel 2 и Landsat 8 с разным разрешением. Полученные результаты показали, что данный метод повышает общую точность примерно на 5 % по сравнению с методом, использующим только данные Sentinel 2. Другие исследователи [5] предлагают точную классификацию сельскохозяйственных культур в аэроспектральных изображениях на основе многофункционального слияния и глубокого обучения. Множественная пространственная информация объединяется авторами с исходной спектральной информацией для получения результата классификации с использованием модели глубокой нейрон-

ной сети с условным случайным полем. Глубокая нейронная сеть – это модель глубокого распознавания, которая может извлекать особенности глубины и потенциальную информацию из данных. Условное случайное поле учитывает как пространственную, так и контекстную информацию, чтобы уменьшить шумы неправильной классификации при сохранении границ объекта.

Самые ранние методы извлечения информации о земном покрове с помощью спутникового дистанционного зондирования были основаны на визуальной интерпретации и компьютерных методах интерпретации изображений, которые основывались на характеристиках спутниковых изображений, таких как информация о цвете, текстуре и форме, в сочетании с естественной географией, геоморфологией и другими соответствующими профессиональными знаниями. Эти методы, как правило, имеют высокую точность картографирования, но отнимают много времени, трудоемки и имеют плохую воспроизводимость. С широким применением и быстрым развитием компьютерных технологий были разработаны многочисленные методы извлечения информации о земном покрове, основанные на машинном обучении и классификации, такие как алгоритм итеративных самоорганизующихся методов анализа данных, классификация по методу максимального правдоподобия, деревья классификации и регрессии, случайный лес, обратное распространение и объектно-ориентированная классификация с многомасштабной сегментацией. По мере развития дистанционного зондирования и компьютерных технологий появляются инновационные подходы к классификации, такие как нечеткие теории, экспертные системы и искусственные нейронные сети [6]. Динамичный технический прогресс способствовал развитию систем визуализации земной поверхности и методов интеллектуального анализа данных. Одним из таких примеров являются методы сверхвысокого разрешения, которые позволяют улучшить пространственное разрешение спутниковых снимков на основе изображения низкого разрешения и алгоритма с использованием глубоких нейронных сетей [7].

В последнее время глубокое обучение стало самой инновационной тенденцией для различных приложений дистанционного зондирования изображений с высоким пространственным разрешением. Достижения в области оптических датчиков и популярность беспилотных летательных аппаратов (БПЛА) ускорили разработку данных дистанционного зондирования с очень высоким пространственным разрешением. Наличие и доступность огромных объемов данных способствовали созданию мощных методов и продемонстрировали многообещающие результаты в широком диапазоне приложений, таких как картирование земного покрова, планирование реагирования на чрезвычайные ситуации и другое [8]. Анализ доступной литературы по применению машинного обучения показал, что группой признаков, наиболее часто используемых при прогнозировании урожайности, была информация о почве, которая состояла из таких переменных, как тип почвы, значение pH, емкость катионного обмена и карты почвы, которые предоставляют информацию о питательных веществах почвы, типе почвы, местоположении и другие характеристики. Ключевым фактором, влияющим на продуктивность сельскохозяйственных культур, является почва, которая является основным источником воды, а также микро- и макроэлементов. Поэтому знание физико-химических свойств почвы и включение их в качестве независимых переменных в прогноз урожайности может повысить точность прогноза [9].

В настоящей работе представлены результаты разработки архитектуры ИНС для расчета коэффициента корреляции между агрохимическими показателями почвы, данными ДЗЗ, метеоданными и корректировки математической модели прогнозирования урожайности зернобобовой культуры (гороха), выращиваемой в условиях 2-х различных поч-

венно-климатических зон востока Казахстана.

Материалы и методы исследования. В качестве исходных данных использовались данные по урожайности сельскохозяйственной зернобобовой культуры (гороха), агрохимические данные за предыдущий год, метеорологические данные для экспериментальных полигонов, результаты обработки данных дистанционного зондирования (аэрофотоматериалы с БПЛА и космических снимков). Для извлечения глубоких характеристик из гиперспектральных изображений использован метод трансферного обучения (метод машинного обучения) с помощью обученной свёрточной нейронной сети (CNN-Convolutional neural network) под названием AlexNet. Модель обучена на подмножестве большой базы данных ImageNet. Структура CNN (AlexNet) включала пять конволюционных слоев, три объединяющих слоя и два полностью связанных слоя. Всего через FC2 извлекалось 256 размерных векторов признаков в качестве глубоких признаков. Эксперимент проводился на основе фреймворка Pytorch в системе Windows. Данные дистанционного зондирования земли (ДЗЗ) были получены с веб-платформы Sentinel Hub EO Browser с помощью спутника Sentinel-2 L2A. Обработка спектральных индексов – нормализованного вегетационного (NDVI) и модифицированного корректированного почвенного (MSAVI) – проводилась с помощью программного обеспечения Agisoft Metashape Professional и DJI Terra (серийный номер лицензии 0f814ba0-b9d6-4192-814a-84d90d73ed53). Экспериментальная часть работы выполнена с помощью мультикоптера DJI Phantom 4 Pro Multispectral (производитель фирма DJI, Китай) (рис. 1, а) и БПЛА senseFly eBee X (производитель фирма senseFly, Швейцария) (рис. 1, б). Внешний вид использованных БПЛА представлен на рис. 1.

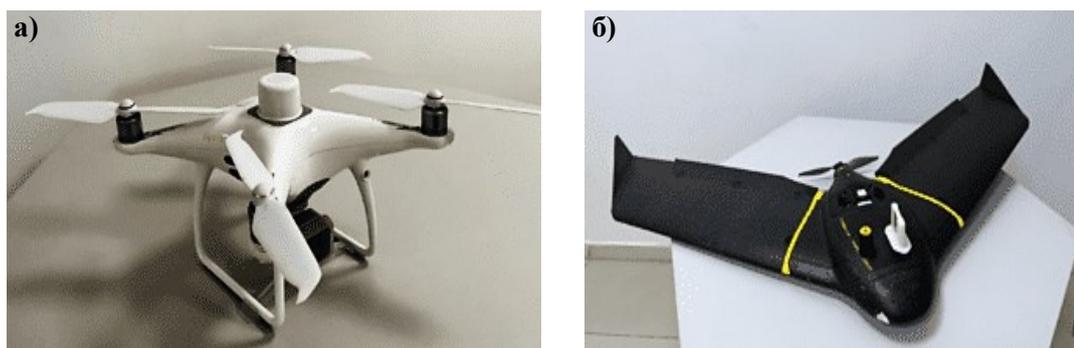


Рисунок 1. БПЛА, используемые в данном исследовании: а) БПЛА DJI P4M; б) senseFly eBee X

Для обработки полученных изображений использовалось лицензионное программное обеспечение Pix4DMapper 4.4.12 по методике, описанной автором [10]. Для подготовки полетного задания использована программа планирования полета eMotion компании senseFly версии 3.11.0 для создания горизонтального и 3D блока миссии. Отбор проб осуществлялся на расстоянии от земли 2,0 см для senseFly S.O.D.A 3D и 2,5 см для Aeria X, высота над уровнем моря соответственно составляла 88 и 118 метров. Для обеспечения оптимальных параметров полета поперечное перекрытие было установлено на 60 %, продольное перекрытие составляло от 60 % для Aeria X до 85 % для senseFly S.O.D.A. 3D, угол наклона был установлен по умолчанию на 30°. Все полеты проходили в автономном режиме. Геотеги изображений были скорректированы до абсолютной точности с помощью рабочего процесса РРК в программе eMotion Flight Data Manager.

В качестве экспериментальных участков было выбрано 2 полигона (рис. 2, а) с посевами гороха, расположенные в различных почвенно-климатических зонах. Местоположе-

ние полигона I в Глубоковском районе Восточно-Казахстанской области представлено на рис. 2, б, полигона II в Бородулихинском районе в Абайской области – на рис. 2, в. Согласно почвенной таксономии, тип черноземной почвы (чернозема) является доминирующей почвенной единицей на территории полигона I, в то время как полигон II имеет каштановый тип почвы.

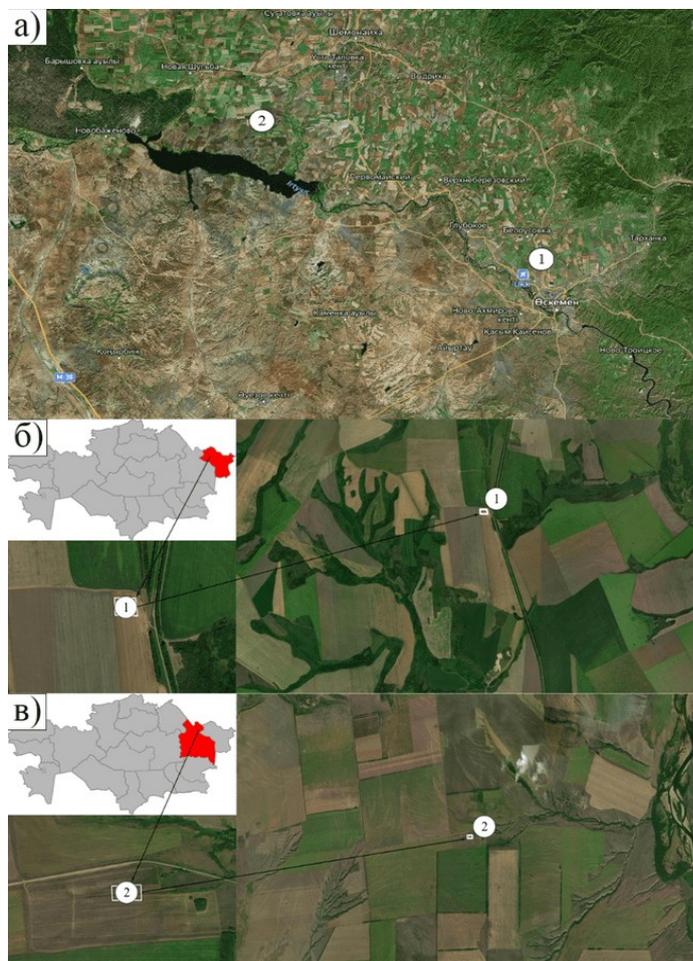


Рисунок 2. Экспериментальные полигоны I, II

Результаты и обсуждение. Для восточной части Казахстана характерен резко континентальный климат. Летом температура поднимается до 45 °С, зимой опускается до – 40 °С. Одним из недостатков спутниковых снимков является их зависимость от погодных условий. На рис. 3, а, б представлены значения индекса NDVI, рассчитанные на основе обработки спутниковых снимков Sentinel-2 L2A с платформы открытого доступа EO Browser за следующие даты: 01.07.22; 07.08.2022, и данные, полученные с помощью мультиспектрального БПЛА DJI Phantom4 RTK за аналогичные даты (рис. 4, а, б). Эффективность разрабатываемого подхода для уточнения изображений умеренного разрешения по снимкам БПЛА проведена на примере гороха. Установлено, что в зависимости от источника информации для I полигона за август месяц среднее значение индекса NDVI по космическим снимкам составило 0,25...0,35 (рис. 3, а), по II полигону за июль месяц – 0,35...0,45

(рис. 3, б).

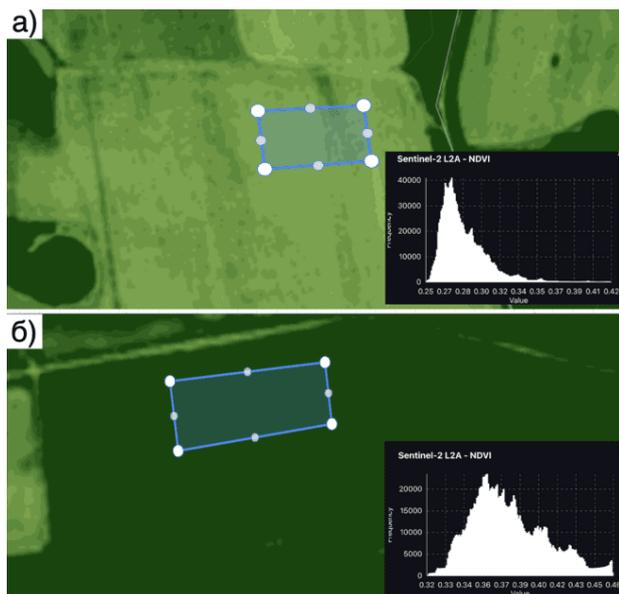


Рисунок 3. Обработанные космические снимки полигонов гороха на базе Sentinel-2 L2A:
a) I полигон (07.08.22); *б)* II полигон (01.07.22)

На основе анализа данных БПЛА среднее значение индекса NDVI для I полигона составило 0,23...0,30 (рис. 4, *a*), для II полигона – 0,38...0,42 (рис. 4, *б*) в соответствии с периодом развития растительности. В результате анализа данных БПЛА и спутниковых снимков был рассчитан коэффициент корреляции г-Пирсона, который составил 0,9464, что является высоким модулем.

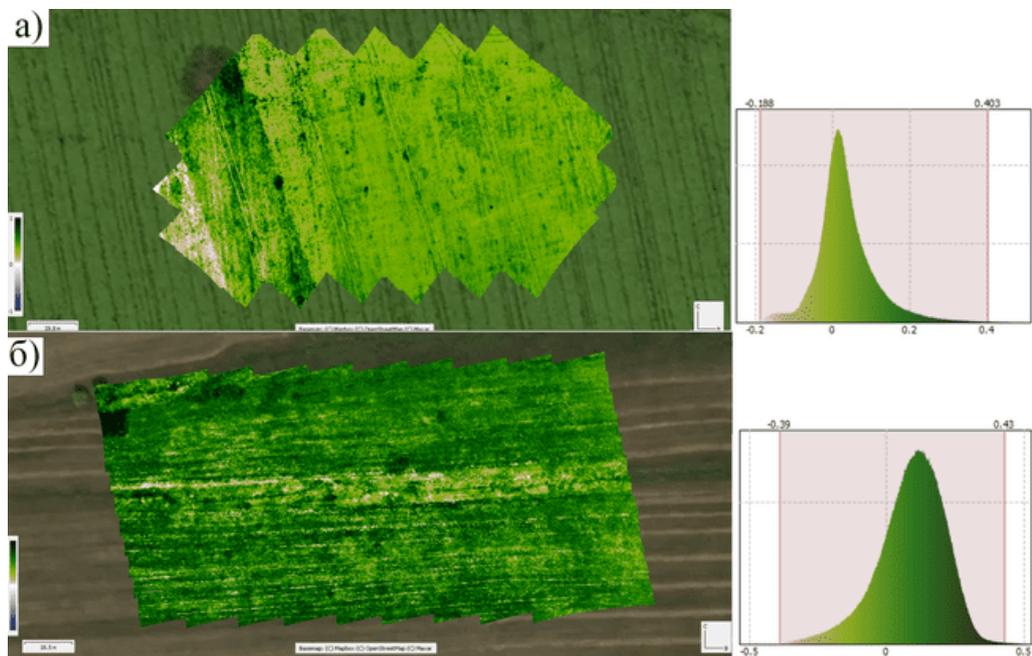


Рисунок 4. Обработанные снимки БПЛА полигонов гороха:

а) I полигон (02.08.22); б) II полигон (01.07.22)

Разработанная система для уточнения разрешения была реализована в среде TensorFlow и обучена на основе спутниковых данных и данных БПЛА 2022 года. Для проверки обученная система была использована для улучшения карты NDVI со спутниковой платформы, полученной в два разных временных периода (июль, август), и результаты сравнивались с более точными картами NDVI, полученными с БПЛА.

Агрохимические показатели, такие как уровни азота (N), фосфора (P) и калия (K), играют решающую роль в росте и продуктивности сельскохозяйственных культур. Эти питательные вещества необходимы для роста растений, и их дефицит может привести к снижению урожайности и качества. Таким образом, мониторинг уровней этих агрохимических показателей важен для устойчивого управления сельским хозяйством.

Исследования показали, что значения NDVI растительности напрямую связаны с уровнями агрохимических показателей. Повышение уровней N, P и K может привести к увеличению значений NDVI, что указывает на улучшение здоровья и роста растительности. И наоборот, снижение уровней этих агрохимических показателей может привести к снижению значений NDVI, что указывает на ухудшение здоровья растительности. Взаимосвязь между агрохимическими показателями и NDVI растительности имеет решающее значение для понимания здоровья и продуктивности сельскохозяйственных земель. NDVI можно использовать для мониторинга уровней N, P, K и в результате получить представление о питательном статусе культур. Данная информация может быть использована для обоснования методов управления сельским хозяйством и повышения урожайности и качества сельскохозяйственных культур.

Исследования на примере полигона I показали, что содержание калия в почве в пределах 35...45 мг/100 г почвы (рис. 5, б), содержание фосфора в пределах 6 мг/100 г почвы (рис. 5, в), общего азота 10 (рис. 5, г), естественного гумуса в пределах 3,8...4,5 % (рис. 5, д). Картограммы содержания питательных веществ представлены на рис. 5.

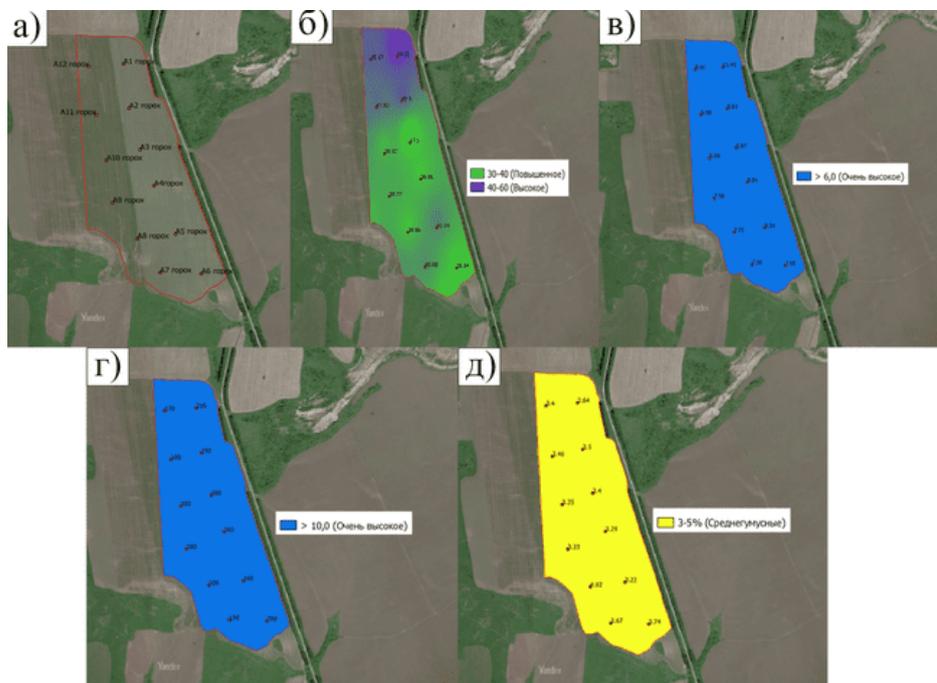


Рисунок 5. Агрохимический анализ экспериментального полигона I: а) контур полигона; б) K20

(мг/100 г почвы); в) P2O5 (мг/100 г почвы); з) содержание общего азота; д) состав гумуса почвы, %

Все собранные данные вегетационных индексов и результатов агрохимического анализа использовались в качестве входных данных математической модели нейронной сети. В разработке данной нейросетевой системы использованы коллекции дополнительных модульных компонентов кода на базе языка программирования Python, приспособленных под определенные задачи в области Data Science, такие как: Rasterio, Matplotlib, Numpy, Pandas, Tensorflow и Keras [11].

Исходный код модели выполнен в интерактивной среде разработки Jupyter Notebook, на языке программирования Python. По плану разрабатываемый модуль принимает данные индексов NDVI и MSAVI какого-либо снимка и проводит через обученную модель, повышая качество данных. Исследования работы [12] демонстрируют, что индекс NDVI эффективен для выражения состояния растительности и количественных характеристик растительности, а широкое использование и популярность делают его самым приоритетным индексом для выполнения поставленной задачи. Из-за способности быстро разграничивать растительность и вегетативный стресс NDVI имеет большую привлекательность в коммерческом сельском хозяйстве и исследованиях землепользования. Авторы работы [13] проанализировали отношение сигнал/шум для индекса MSAVI и выявили, что оно было выше, чем для других индексов растительности (включая оригинальную версию SAVI). Использование функций L не только увеличило динамические реакции растительности, но и дополнительно уменьшило колебания грунта. При более высоком растительном покрове L приближается к 0 и MSAVI ведет себя как NDVI, в то время как при низком растительном покрове L приближается к 1 и MSAVI вел себя как PVI или WDI. Благодаря этому индекс MSAVI дает более широкий спектр информации, чем остальные индексы, и поэтому был выбран для данного модуля.

Разрабатываемая система обучается на базе данных на основе обоих типов снимков. Обучение проходит через линейную регрессию (уравнение 1) и после получения результата повторяет этот цикл, начиная новую эпоху обучения.

$$Y = \beta x + a \quad (1)$$

Процессы, задействованные в модели, представлены на рис. 6.

После сбора данных начинается процесс обучения модели. Для этого использован модуль Keras библиотеки TensorFlow. Согласно данным из работы [14], главным преимуществом Tensorflow является существование множества реализованных архитектур для различных нейронных сетей. Keras является фреймворком, который работает поверх Tensorflow. Он используется для повышения скорости взаимодействия с нейронными сетями. В работе [15] описана реализация использования библиотек Tensorflow и Keras для многоэтапного предсказания индекса NDVI.

Следующим этапом импортируются инструменты Keras из библиотеки TensorFlow: функция `train_test_split` из библиотеки `sklearn`, с её помощью создаются 2 набора данных для тренировки модели и её тестирования.

На рис. 7 представлено как импортируется библиотека Keras и его инструментарий для построения слоев нейронных сетей Dense. Из библиотеки Scikit-learn импортируется функция `train_test_split`. Данные БПЛА и ДЗЗ задаются аргументами `x`, `y` и разделяются функцией `train_test_split` на тренировочные и тестовые выборки данных. Параметр `test_size` необходим для определения количества процента данных, который последовательно разделяется в тестовую выборку, параметр `random_state` выполняет функцию случайного порядка. Впоследствии разделения данных начинается обучение модели, создается модель многослойной последовательной нейронной сети с помощью класса

Sequential()).

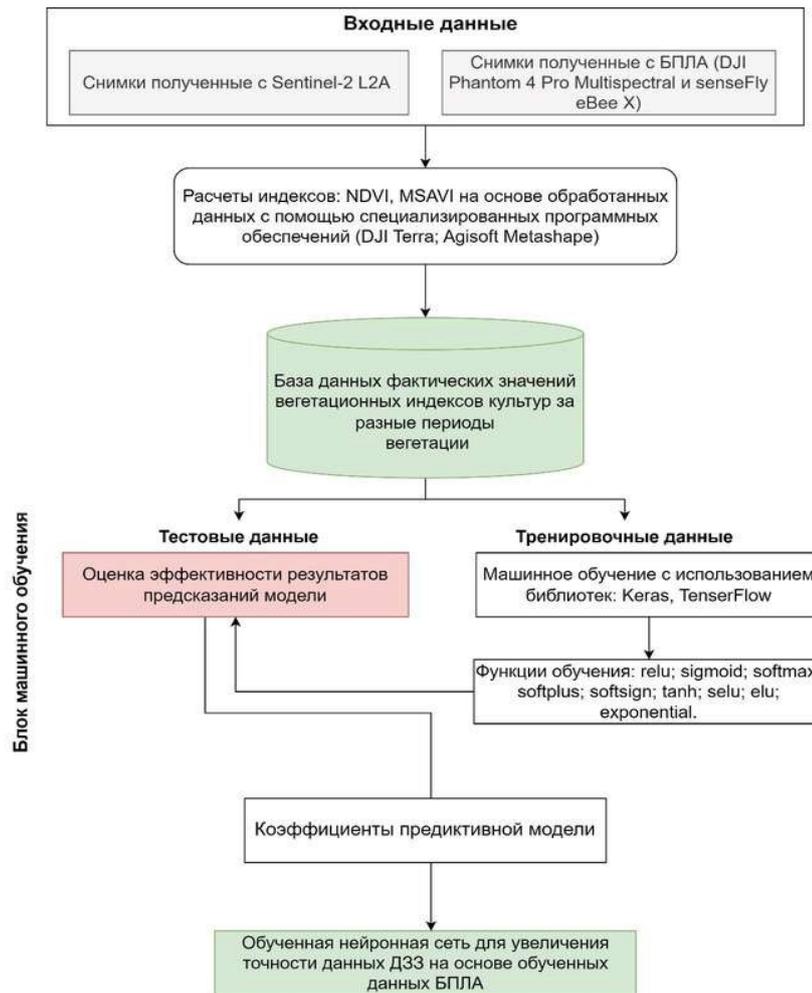


Рисунок 6. Диаграмма процессов модуля

```

from tensorflow import keras
from tensorflow.keras.layers import Dense
from sklearn.model_selection import train_test_split

x = df['Космо NDVI']
y = df['БПЛА NDVI']

X_train, X_test, y_train, y_test = train_test_split(x, y, test_size=0.1, random_state=10)

```

Рисунок 7. Разделение тренировочных и тестовых данных

Многослойная последовательная нейронная сеть (рис. 8) состоит из 3 слоев. Через входные слои поступают данные, которые умножаются на коэффициенты случайно сгенерированных весов и поступают в скрытые слои. Скрытые слои состоят из функции активации, где входные значения рассчитываются на основе алгоритмов и формул функций активации и умножаются на коэффициенты весов. После расчетов скрытых слоев данные поступают в выходной слой, где сравниваются с фактическими значениями. Затем веса нейронной сети корректируются и цикл начинается сначала.

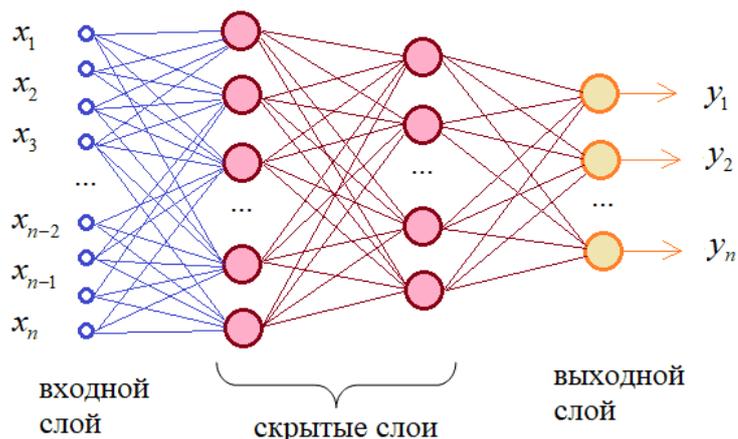


Рисунок 8. Многослойная последовательная нейронная сеть

Данная операция повторяется до тех пор, пока не будет достигнут наилучший результат предсказания. Добавляется скрытый слой, в котором хранится функция обучения, задаваемая атрибутом `activation`. Также задается количество эпох (циклы обучения модели) и запускается дальнейшее обучение модели (рис. 9). Чем больше модель имеет эпох, тем лучше натренирована сеть и выше точность ее результата. Эпохи увеличиваются с каждым разом, когда проходиться весь набор тренировочных сетов.

Для наблюдения за результатами обучения модели используется библиотека `Matplotlib` – библиотека графиков для языка программирования `Python` и его числового математического расширения `NumPy`. `Matplotlib` предоставляет объектно-ориентированный API для встраивания графиков в приложения с использованием универсальных инструментов графического интерфейса. Измерение точности предсказаний модели рассчитывается его средней квадратической ошибкой (MSE).

На рис. 9 представлено создание модели многослойной последовательной нейронной сети `Sequential()`. В данную модель функцией `model.add()` добавляется скрытый слой `Dense()`, в котором задается используемая функция активации с помощью параметра `activation`. Параметр `units` отвечает за размерность выходного пространства. В 3 строке кода функцией `model.compile()` задается метрика. Метрика является функцией, которая используется для оценки производительности модели. Параметр `loss` отвечает за функцию потерь, которым оценивается качество предсказания модели. Функция компиляции модели `Keras` задается параметром `optimizer`. Далее аргументом `history` задается функция `model.fit()`. Данная функция обучает модель используя ранее введенные параметры, принимая на вход тренировочные данные `X_train` и `y_train`. Параметром `epochs` задается количество циклов обучения, которые проходит модель во время обучения, параметр `verbose` необходим для отображения прогресса обучения каждой эпохи.

```
model = keras.Sequential()
model.add(Dense(units=1, activation='softmax'))
model.compile(loss='mean_squared_error', optimizer=keras.optimizers.Adam(0.1))
history = model.fit(X_train, y_train, epochs=200, verbose=0)
plt.plot(history.history['loss'])
plt.grid(True)
plt.show()
```

Рисунок 9. Код обучения модели

Путем анализа результатов настраивается оптимальное количество эпох обучения, затем подбирается одна из самых результативных и точных функций обучения модели. Всего рассматриваются 9 функций, которые имеются в библиотеке Keras. Для обучения нейронной сети использованы 9 функций активации (обучения слоя): relu; sigmoid; softmax; softplus; softsign; tanh; selu; elu; exponential. Оценив эффективность их предсказаний, выбраны самые оптимальные функции для обучения нейронной сети.

Функция Relu [16] применяет функцию активации выпрямленного линейного блока. При значении по умолчанию возвращается стандартная активация ReLU. Максимум 0 по элементам во входной тензор. Изменение параметров по умолчанию позволяет использовать ненулевые пороговые значения, изменять максимальное значение активации и использовать ненулевое кратное входных данных для значений ниже порогового значения. Уравнение функции Relu:

$$f(x) = \begin{cases} 0 & x < 0 \\ x & x \geq 0 \end{cases} . \quad (2)$$

Функция Sigmoid [17] применяет функцию активации сигмовидной части. Для малых значений (<-5) возвращает значение близкое к нулю, а для больших значений (>5) результат функции приближается к 1. Sigmoid эквивалентен 2-элементному Softmax, где второй элемент считается равным нулю. Сигмовидная функция всегда возвращает значение от 0 до 1. Уравнение функции Sigmoid:

$$f(x) = \frac{1}{1+e^{-x}} . \quad (3)$$

График поведения функции Sigmoid представлен на рис. 10.

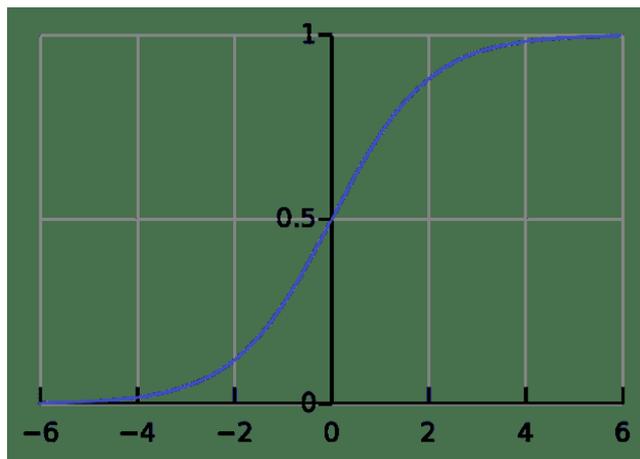


Рисунок 10. График поведения функции Sigmoid

Функция Softmax [18] преобразует вектор значений в распределение вероятностей. Элементы выходного вектора находятся в диапазоне (0, 1) и суммируются до 1. Каждый вектор обрабатывается независимо. Аргумент задает, вдоль какой оси входных данных применяется функция axis. Softmax часто используется в качестве активации для последнего слоя классификационной сети, потому что результат может быть интерпретирован как распределение вероятностей. Входные значения являются логарифмическими коэффициентами результирующей вероятности. Уравнение функции Softmax:

$$f_i(x) = \frac{\exp(x_i)}{\sum_j \exp(x_j)} . \quad (4)$$

Функция активации Selu [19] – SELU умножается (> 1) с выходом функции `tf.keras.activations.elu`, чтобы обеспечить наклон больше единицы для положительных входов `.scale` [20]. Значения выбираются таким образом, чтобы средняя и дисперсия входных данных сохранялись между двумя последовательными слоями до тех пор, пока веса инициализированы правильно (см. `tf.keras.initializers.LecunNormal initializer`) и количество входных единиц являлись «достаточно большими». Уравнение функции Selu :

$$\begin{aligned} f(x) &= \lambda x \text{ if } x \geq 0 \\ f(x) &= \lambda \alpha (\exp(x) - 1) \text{ if } x < 0. \end{aligned} \quad (5)$$

Функция Elu [21] – Экспоненциальная линейная единица (ELU) с $\alpha > 0$, если $x > 0$, и $\alpha * (\exp(x) - 1)$, если $x < 0$. Гиперпараметр α управляет значением, до которого ELU насыщается отрицательными чистыми входами. ELU уменьшают эффект исчезающего градиента. ELU имеют отрицательные значения, которые подталкивают среднее значение активаций ближе к нулю. Средние активации, которые ближе к нулю, обеспечивают более быстрое обучение, поскольку они приближают градиент к естественному градиенту. ELU насыщаются отрицательным значением, когда аргумент становится меньше. Насыщенность означает небольшую производную, которая уменьшает вариацию и информацию, и распространяется на следующий слой.

Для оценки точности выходных данных модели оценивается ошибка расчетов предсказания. Ошибка расчетов предсказания – это процентная величина, отражающая расхождение между ожидаемым и полученным ответами. Ошибка формируется каждую эпоху и должна идти на спад. Во многих исследованиях используется среднеквадратичная ошибка (MSE) и ее корневой вариант (RMSE) или средняя абсолютная ошибка (MAE) и ее процентный вариант (MAPE). Несмотря на свою полезность, данные коэффициенты имеют общий недостаток: поскольку их значения могут варьироваться от нуля до бесконечности, одно их значение мало что говорит о производительности регрессии в отношении распределения основных элементов истинности. Согласно исследованиям авторов работы [22], широко распространённым методом является семейство мер, которое оценивает качество подгонки с точки зрения расстояния регрессора до фактических точек обучения. Двумя основными членами такого семейства являются средняя погрешность (MAE) [23] и средняя квадратичная ошибка (MSE) [24], отличие которой заключается в оценочной метрике, соответственно линейной L_1 или квадратичной L_2 . Опять же, имеющиеся ссылки многочисленны, связанные как с теоретическими [25], так и с прикладными аспектами [26]. В качестве естественного вывода был принят квадратный корень из среднеквадратичной ошибки (RMSE) [27] для стандартизации единиц измерения.

Для вычисления ошибки рассматривались следующие пути: Mean Squared Error (MSE), Root MSE, Mean Absolute Error, Mean absolute percentage error, Symmetric mean absolute percentage error и Arctan. Уравнения подсчета ошибок представлены ниже:

$$MSE = \frac{(i_1 - a_1)^2 + (i_2 - a_2)^2 + \dots + (i_n - a_n)^2}{n}, \quad (6)$$

$$MSE = 1/m * \sum_{i=1}^m (X_i - Y_i)^2. \quad (7)$$

MSE используется в случае наличия выбросов, которые необходимо обнаружить. MSE отлично подходит для присвоения больших весов таким точкам, как L_2 : очевидно, что, если модель в конечном итоге выдает плохой прогноз, возведение в квадрат части функции увеличивает ошибку.

$$RMSE = \sqrt{\frac{(i_1 - a_1)^2 + (i_2 - a_2)^2 + \dots + (i_n - a_n)^2}{n}}, \quad (8)$$

$$RMSE = \sqrt{1/m * \sum_{i=1}^m (X_i - Y_i)^2} . \quad (9)$$

Две величины MSE и RMSE монотонно связаны (через квадратный корень). Порядок регрессионных моделей, основанных на MSE, будет идентичен порядку моделей, основанных на RMSE.

$$MAE = 1/m * \sum_{i=1}^m |X_i - Y_i| \quad (10)$$

Метрика средней абсолютной ошибки (MAE) используется в случаях, когда выбросы в данных считаются испорченными. Метрика MAE не накладывает существенного штрафа на выбросы в процессе обучения (норма L1 сглаживает все ошибки возможных выбросов), обеспечивая таким образом общую и ограниченную меру производительности для модели. С другой стороны, если тестовый набор имеет большое количество выбросов, производительность модели будет посредственной. Результаты предсказания функций активации продемонстрированы в табл. 1.

Обучение модели происходит итеративно путем подачи пакета данных определенного размера в сеть системы и обновления параметров небольшими шагами, которые определяются скоростью обучения η , используя градиент выбранной функции потерь. По результатам математического моделирования на основе машинного обучения TensorFlow было получено увеличение точности и разрешения космических снимков на 90 % и более. Исследование продолжается в направлении последующей интеграции данной модели в разрабатываемый геоинформационный портал «умного» сельского хозяйства.

Таблица 1. Результаты обучения нейронной модели

Функции обучения слоя	Определение	Точность предсказаний (%) через кол-во эпох обучения			
		25	50	100	200
relu	$\max(x, 0)$	94,2	92,5	94,9	95
sigmoid	$\text{sigmoid}(x) = 1 / (1 + \exp(-x))$	87	93	96,2	94,8
softmax	$\exp(x) / \text{tf.reduce_sum}(\exp(x))$	24,6	24,6	24,6	24,6
softplus	$\text{softplus}(x) = \log(\exp(x) + 1)$	93	93,3	96,5	95,2
softsign	$\text{softsign}(x) = x / (\text{abs}(x) + 1)$	98,4	94,3	98,7	95,9
tanh	$\text{tanh}(x) = \sinh(x) / \cosh(x) = ((\exp(x) - \exp(-x)) / (\exp(x) + \exp(-x)))$	91,8	94,6	95	94,8
selu	if $x > 0$: return scale * x if $x < 0$: return scale * alpha * ($\exp(x) - 1$)	94,5	92,7	98,8	96,8
elu	$\text{xx} > 0 \text{alpha} * (\exp(x) - 1) x < 0$	86,3	89,7	97,9	95
exponential	$\exp(x)$	57	67	98	98,8

Заключение. Спутниковые снимки низкого и среднего разрешения демонстрируют некоторые ограничения в конкретных сельскохозяйственных приложениях, например, когда культуры выращиваются в рядах, что приводит к смещенному радиометрическому отражению, которое не позволяет достоверно описать состояние растительности. Предлагаемая новая система уточнения и повышения разрешения спутниковых изображений, основанная на методах машинного обучения и нейронных сетях TensorFlow, использует информацию из мультиспектральных изображений, полученных с помощью БПЛА с высоким разрешением, и мультиспектральных спутниковых изображений. Установлено, что

для обучения нейронной сети следует использовать два набора данных дистанционного зондирования и это позволяет успешно реализовать предлагаемый простой и экономически эффективный подход. В качестве примера для тестирования были выбраны полигоны выращивания зернобобовой культуры (гороха) в двух крестьянских хозяйствах востока Казахстана. Уточненные вегетационные индексы NDVI, полученные в два разных вегетационных периода роста и развития гороха, по данным корреляционного анализа г-Пирсона демонстрируют высокий модуль, который составил 0,9464. Получено, что текущая улучшенная точность разрешения информации космического снимка при использовании функции «Exponential» составила 98 %. Таким образом, предложенная система уточнения и повышения разрешения спутниковых снимков с использованием методов машинного обучения и нейронных сетей TensorFlow показала свою простоту, экономическую эффективность и высокую точность. Полученные результаты свидетельствуют, что данный подход может быть полезен для повышения точности и надежности спутниковых снимков в сельскохозяйственных приложениях.

Благодарности. Данное исследование выполнено в рамках реализации проекта BR10865102 «Развитие технологий дистанционного зондирования земли (ДЗЗ) для улучшения управления сельским хозяйством», финансируемого Министерством сельского хозяйства Республики Казахстан.

Список литературы

1. Lei R., Yang W., Yang S. System Development of Making an Image Map Based on Google Earth // IOP Conference Series: Earth and Environmental Science. – IOP Publishing, 2021. – Т. 697. – №. 1. – С. 012004.
2. Hu Y. et al. A deep convolution neural network method for land cover mapping: A case study of Qinhuangdao, China // Remote Sensing. – 2018. – Т. 10. – №. 12. – С. 2053.
3. Supporting the future of foods: Japan's smart agriculture [Электронный ресурс]. – 2022. – URL: <https://nexttrendsasia.org/supporting-the-future-of-foods-japans-smart-agriculture/#COUNTRIES> (дата обращения 14.02.2023).
4. Hung T. L., Sinh M. D., Zablotskii V. R. The urban areas classification methodology according to multi-zone images of sentinel 2 and landsat 8 (On the example of the city of thanh hoa, vietnam) // Geodezia i Kartografia. – 2020. – Т. 956. – №. 2. – С. 40-49.
5. Wei L. et al. Crops fine classification in airborne hyperspectral imagery based on multi-feature fusion and deep learning // Remote Sensing. – 2021. – Т. 13. – №. 15. – С. 2917.
6. Mary S. R. et al. Deep Learning Model for the Image Fusion and Accurate Classification of Remote Sensing Images // Computational Intelligence and Neuroscience. – 2022. – Т. 2022.
7. Deng J. et al. Improving the spatial resolution of solar images using generative adversarial network and self-attention mechanism // The Astrophysical Journal. – 2021. – Т. 923. – №. 1. – С. 76.
8. Gao H. et al. Classification of very-high-spatial-resolution aerial images based on multiscale features with limited semantic information // Remote Sensing. – 2021. – Т. 13. – №. 3. – С. 364.
9. Hara P., Piekutowska M., Niedbała G. Selection of independent variables for crop yield prediction using artificial neural network models with remote sensing data // Land. – 2021. – Т. 10. – №. 6. – С. 609.
10. Sun G, Wang X, Yang H, Zhang X. A canopy information measurement method for modern standardized apple orchards based on UAV multimodal information // Sensors (Switzerland). –2020; 20(10):2985.
11. Beisekenov N. A. et al. Development of a preliminary version of a model for machine learning in predicting yield on the example of wheat in the conditions of East Kazakhstan //16th International Conference on Electronics Computer and Computation (ICECCO). – IEEE. – 2022. – С. 1-6.
12. Sadenova M. A. et al. Digitalization of Crop Production for Transition to Climate-optimized Agriculture Using Spring Wheat in East Kazakhstan as an Example // Chemical Engineering Transactions. – 2022. – №. 96. – С. 415-420
13. Huang S. et al. A commentary review on the use of normalized difference vegetation index (NDVI) in the era of popular remote sensing // Journal of Forestry Research. – 2021. – Т. 32. – №. 1. – С. 1-6.
14. Chung, Jeehun, et al. Correlation analysis between air temperature and MODIS land surface temperature and prediction of air temperature using TensorFlow long short-term memory for the period of occurrence of cold and heat waves // Remote Sensing 12.19 – 2022. – С. 3231.
15. Omar M. S., Kawamukai H. Evaluation of Stochastic and Artificial Neural Network Models for Multi-step

- Lead Forecasting of NDVI // IOP Conference Series: Earth and Environmental Science. – IOP Publishing, 2022. – T. 1008. – №. 1. – C. 012014.
16. Schmidt-Hieber J. Nonparametric regression using deep neural networks with ReLU activation function // The Annals of Statistics. – 2020. – T. 48. – №. 4. – C. 1875-1897.
 17. Pratiwi H. et al. Sigmoid activation function in selecting the best model of artificial neural networks // Journal of Physics: Conference Series. – IOP Publishing, 2020. – T. 1471. – №. 1. – C. 012010.
 18. Rottmann, Matthias, et al. Prediction error meta classification in semantic segmentation: Detection via aggregated dispersion measures of softmax probabilities // 2020 International Joint Conference on Neural Networks (IJCNN). – IEEE. – 2020.
 19. Sakketou F., Ampazis N. On the invariance of the selu activation function on algorithm and hyperparameter selection in neural network recommenders // IFIP International Conference on Artificial Intelligence Applications and Innovations. – Springer, Cham, 2019. – C. 673-685.
 20. Chicco D., Warrens M.J., Jurman G. The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation // PeerJ Computer Science. – 2021. – T. 7. – C. e623.
 21. Karunasingha D. S. K. Root mean square error or mean absolute error? Use their ratio as well // Information Sciences. – 2022. – T. 585. – C. 609-629.
 22. Ngoc T. T., Le Van Dai C. M. T., Thuyen C. M. Support vector regression based on grid search method of hyperparameters for load forecasting // Acta Polytechnica Hungarica. – 2021. – T. 18. – №. 2. – C. 143-158.
 23. Bisong E. Matplotlib and seaborn // Building machine learning and deep learning models on google cloud platform. – Apress, Berkeley, CA, 2019. – C. 151-165.
 24. Sadenova M. A. et al. Forecasting Crop Yields Based on Earth Remote Sensing Methods // Chemical Engineering Transactions. – 2022. – №. 92. – C. 691-696.
 25. Sadenova M. A. et al. Modelling of Alfalfa Yield Forecasting Based on Earth Remote Sensing (ERS) Data and Remote Sensing Methods // Chemical Engineering Transactions. – 2022. – №. 94. – C. 697-702.
 26. Čalasan, Martin, et. al On the root mean square error (RMSE) calculation for parameter estimation of photovoltaic models: A novel exact analytical solution based on Lambert W function // Energy conversion and management. – 2020. – №. 210 – C. 112716.
 27. Karunasingha D. S. K. Root mean square error or mean absolute error? Use their ratio as well // Information Sciences. – 2022. – T. 585. – C. 609-629.

References

1. Lei R., Yang W., Yang S. System Development of Making an Image Map Based on Google Earth // IOP Conference Series: Earth and Environmental Science. – IOP Publishing, 2021. – T. 697. – №. 1. – C. 012004.
2. Hu Y. et al. A deep convolution neural network method for land cover mapping: A case study of Qinhuangdao, China // Remote Sensing. – 2018. – T. 10. – №. 12. – C. 2053.
3. Supporting the future of foods: Japan's smart agriculture [Electronic resource]. – 2022. – URL: <https://nexttrendsasia.org/supporting-the-future-of-foods-japans-smart-agriculture/#COUNTRIES> (circulation date 14.02.2023).
4. Hung T. L., Sinh M. D., Zablotskii V. R. The urban areas classification methodology according to multi-zone images of sentinel 2 and landsat 8 (On the example of the city of thanh hoa, vietnam) // Geodezia i Kartografia. – 2020. – T. 956. – №. 2. – C. 40-49.
5. Wei L. et al. Crops fine classification in airborne hyperspectral imagery based on multi-feature fusion and deep learning // Remote Sensing. – 2021. – T. 13. – №. 15. – C. 2917.
6. Mary S. R. et al. Deep Learning Model for the Image Fusion and Accurate Classification of Remote Sensing Images // Computational Intelligence and Neuroscience. – 2022. – T. 2022.
7. Deng J. et al. Improving the spatial resolution of solar images using generative adversarial network and self-attention mechanism // The Astrophysical Journal. – 2021. – T. 923. – №. 1. – C. 76.
8. Gao H. et al. Classification of very-high-spatial-resolution aerial images based on multiscale features with limited semantic information // Remote Sensing. – 2021. – T. 13. – №. 3. – C. 364.
9. Hara P., Piekutowska M., Niedbała G. Selection of independent variables for crop yield prediction using artificial neural network models with remote sensing data // Land. – 2021. – T. 10. – №. 6. – C. 609.
10. Sun G, Wang X, Yang H, Zhang X. A canopy information measurement method for modern standardized apple orchards based on UAV multimodal information // Sensors (Switzerland). – 2020; 20(10):2985.
11. Beisekenov N. A., et al. Development of a preliminary version of a model for machine learning in predicting yield on the example of wheat in the conditions of East Kazakhstan //16th International Conference on Electronics Computer and Computation (ICECCO). – IEEE. – 2022. – C. 1-6.
12. Sadenova M. A., et al. Digitalization of Crop Production for Transition to Climate-optimized Agriculture Us-

- ing Spring Wheat in East Kazakhstan as an Example // *Chemical Engineering Transactions*. – 2022. – №. 96. – С. 415-420
13. Huang S. et al. A commentary review on the use of normalized difference vegetation index (NDVI) in the era of popular remote sensing // *Journal of Forestry Research*. – 2021. – Т. 32. – №. 1. – С. 1-6.
 14. Chung, Jeehun, et al. Correlation analysis between air temperature and MODIS land surface temperature and prediction of air temperature using TensorFlow long short-term memory for the period of occurrence of cold and heat waves // *Remote Sensing* 12.19. – 2022. – С. 3231.
 15. Omar M. S., Kawamukai H. Evaluation of Stochastic and Artificial Neural Network Models for Multi-step Lead Forecasting of NDVI // *IOP Conference Series: Earth and Environmental Science*. – IOP Publishing, 2022. – Т. 1008. – №. 1. – С. 012014.
 16. Schmidt-Hieber J. Nonparametric regression using deep neural networks with ReLU activation function // *The Annals of Statistics*. – 2020. – Т. 48. – №. 4. – С. 1875-1897.
 17. Pratiwi H. et al. Sigmoid activation function in selecting the best model of artificial neural networks // *Journal of Physics: Conference Series*. – IOP Publishing, 2020. – Т. 1471. – №. 1. – С. 012010.
 18. Rottmann, Matthias, et al. Prediction error meta classification in semantic segmentation: Detection via aggregated dispersion measures of softmax probabilities // *2020 International Joint Conference on Neural Networks (IJCNN)*. – IEEE, – 2020.
 19. Sakketou F., Ampazis N. On the invariance of the selu activation function on algorithm and hyperparameter selection in neural network recommenders // *IFIP International Conference on Artificial Intelligence Applications and Innovations*. – Springer, Cham, 2019. – С. 673-685.
 20. Chicco D., Warrens M. J., Jurman G. The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation // *PeerJ Computer Science*. – 2021. – Т. 7. – С. e623.
 21. Karunasingha D. S. K. Root mean square error or mean absolute error? Use their ratio as well // *Information Sciences*. – 2022. – Т. 585. – С. 609-629.
 22. Ngoc T. T., Le Van Dai C. M. T., Thuyen C. M. Support vector regression based on grid search method of hyperparameters for load forecasting // *Acta Polytechnica Hungarica*. – 2021. – Т. 18. – №. 2. – С. 143-158.
 23. Bisong E. Matplotlib and seaborn // *Building machine learning and deep learning models on google cloud platform*. – Apress, Berkeley, CA, 2019. – С. 151-165.
 24. Sadenova M. A. et al. Forecasting Crop Yields Based on Earth Remote Sensing Methods // *Chemical Engineering Transactions*. – 2022. – №. 92. – С. 691-696.
 25. Sadenova M. A., et al. Modelling of Alfalfa Yield Forecasting Based on Earth Remote Sensing (ERS) Data and Remote Sensing Methods // *Chemical Engineering Transactions*. – 2022. – №. 94. – С. 697-702.
 26. Calasan, Martin, et. al On the root mean square error (RMSE) calculation for parameter estimation of photovoltaic models: A novel exact analytical solution based on Lambert W function // *Energy conversion and management*. – 2020. – №. 210 – С. 112716.
 27. Karunasingha D. S. K. Root mean square error or mean absolute error? Use their ratio as well // *Information Sciences*. – 2022. – Т. 585. – С. 609-629.
-
-