

Impact Factor:	ISRA (India)	= 6.317	SIS (USA)	= 0.912	ICV (Poland)	= 6.630
	ISI (Dubai, UAE)	= 1.582	ПИИЦ (Russia)	= 0.191	PIF (India)	= 1.940
	GIF (Australia)	= 0.564	ESJI (KZ)	= 8.100	IBI (India)	= 4.260
	JIF	= 1.500	SJIF (Morocco)	= 7.184	OAJI (USA)	= 0.350

SOI: [1.1/TAS](#) DOI: [10.15863/TAS](#)
International Scientific Journal
Theoretical & Applied Science

p-ISSN: 2308-4944 (print) e-ISSN: 2409-0085 (online)
Year: 2025 Issue: 04 Volume: 144
Received: 04.04.2025
Accepted/Published: 30.04.2025 <https://T-Science.org>

Issue

Article



Zh. Ainakulov
S. Seifullin Kazakh Agrotechnical Research University
master

A. Iskakova
Al-Farabi Kazakh National University
master

G. Kurmankulova
Al-Farabi Kazakh National University
docent

MACHINE LEARNING METHODS IN PLANNING EXPERIMENTS AND DATA ANALYSIS IN THE AGRICULTURAL INDUSTRY

Abstract: The application of machine learning methods in the agro-industrial complex (AIC) is becoming increasingly relevant for solving complex problems related to the planning of experiments and data analysis. This paper reviews key machine learning approaches that improve the efficiency of agricultural research, including predictive modeling, optimization of experimental designs, and identification of significant factors influencing productivity and quality. Special attention is given to supervised and unsupervised learning methods, such as decision trees, random forests, neural networks, and clustering algorithms. The integration of these methods enables the processing of large volumes of agro-technological data, supports decision-making, and contributes to the development of precision agriculture. The paper also discusses practical examples of using machine learning in soil analysis, crop yield forecasting, and optimization of agrotechnical measures.

Key words: machine learning, agricultural experiment, planning, data analysis, yield, forecasting, precision agriculture.

Language: Russian

Citation: Ainakulov, Zh., Iskakova, A., & Kurmankulova, G. (2025). Machine learning methods in planning experiments and data analysis in the agricultural industry. *ISJ Theoretical & Applied Science*, 04 (144), 38-44.

Soi: <https://s-o-i.org/1.1/TAS-04-144-8> **Doi:**  <https://dx.doi.org/10.15863/TAS.2025.04.144.8>

Scopus ASCC: 1700.

МЕТОДЫ МАШИННОГО ОБУЧЕНИЯ В ПЛАНИРОВАНИИ ЭКСПЕРИМЕНТОВ И АНАЛИЗЕ ДАННЫХ В АПК

Аннотация: Применение методов машинного обучения в агропромышленном комплексе (АПК) становится все более актуальным для решения сложных задач, связанных с планированием экспериментов и анализом данных. В данной статье рассматриваются основные подходы машинного обучения, повышающие эффективность сельскохозяйственных исследований, включая предиктивное моделирование, оптимизацию экспериментальных планов и выявление значимых факторов, влияющих на производительность и качество. Особое внимание уделено контролируемым и неконтролируемым методам обучения, таким как деревья решений, случайные леса, нейронные сети и алгоритмы кластеризации. Интеграция этих методов позволяет обрабатывать большие объемы агротехнологических данных, поддерживает принятие решений и способствует развитию точного земледелия. В статье также рассматриваются практические примеры использования машинного обучения в анализе почв, прогнозировании урожайности и оптимизации агротехнических мероприятий.

Impact Factor:	ISRA (India)	= 6.317	SIS (USA)	= 0.912	ICV (Poland)	= 6.630
	ISI (Dubai, UAE)	= 1.582	РИИЦ (Russia)	= 0.191	PIF (India)	= 1.940
	GIF (Australia)	= 0.564	ESJI (KZ)	= 8.100	IBI (India)	= 4.260
	JIF	= 1.500	SJIF (Morocco)	= 7.184	OAJI (USA)	= 0.350

Ключевые слова: машинное обучение, агроэксперименты, планирование, анализ данных, урожайность, прогнозирование, точное земледелие.

Введение

УДК 004.89:631

Современный агропромышленный комплекс (АПК) испытывает растущую потребность в интеллектуальных технологиях, позволяющих обрабатывать большие массивы данных, поступающих от сенсоров, БПЛА, спутниковых систем и других источников. Машинное обучение (ML) предоставляет инструменты, обеспечивающие извлечение полезной информации, прогнозирование и адаптивное управление агропроизводственными процессами. Это делает методы ML важным компонентом цифрового земледелия и точного сельского хозяйства.

Традиционные методы планирования экспериментов (например, метод полного факторного эксперимента) часто неэффективны при большом числе факторов. МО позволяет адаптивно выбирать оптимальные комбинации факторов, использовать исторические и реального времени данные, сокращать количество полевых испытаний при сохранении качества выводов. Например, *Bayesian Optimization* используется для оптимизации доз удобрений, а *Active Learning* применяется для адаптивного выбора наиболее информативных точек в экспериментах.

Анализ данных в АПК с применением машинного обучения используется для прогнозирования урожайности, определения оптимальных агротехнических приемов, построения моделей зависимости между климатом, почвой и урожайностью, обработки спутниковых изображений для оценки состояния растений (NDVI, EVI и др.), обнаружения аномалий в полевых данных (неисправности оборудования, засухи и др.), использование МО в обработке спутниковых данных и ДЗЗ:

- Использование **глубоких нейронных сетей (CNN, LSTM)** для обработки временных рядов NDVI.

- Классификация сельхозкультур по многоспектральным данным.

- Оценка биомассы и предсказание этапов развития растений.

- Использование **глубоких нейронных сетей (CNN, LSTM)** для обработки временных рядов NDVI.

- Классификация сельхозкультур по многоспектральным данным.

- Оценка биомассы и предсказание этапов развития растений.

Методы машинного обучения, применяемые в АПК

Таблица 1.

Метод	Применение в АПК
Random Forest	Предсказание урожайности, выявление значимых факторов (погода, агротехника)
Gradient Boosting	Повышение точности моделей продуктивности растений
Support Vector Machines (SVM)	Классификация типов почв, болезней растений
Neural Networks	Прогнозирование урожая по спутниковым и метео-данным
k-Means, DBSCAN	Кластеризация полей по производительности и типам почв
PCA / t-SNE	Снижение размерности и визуализация многомерных агроданных

В качестве примера рассмотрим *Kamilaris et al. (2018)*, где проведен обзор, в котором продемонстрировали успешное применение глубокого обучения для обработки данных ДЗЗ и точного земледелия.

Инструменты и платформы используемые при анализе данных, это Python библиотеки, scikit-learn, TensorFlow, XGBoost, LightGBM, PyTorch, Геоинформационные системы (ГИС): QGIS, Google Earth Engine, а также платформы для анализа АПК, такие как OneSoil, Climate FieldView, EOS Crop Monitoring

Преимуществом являются увеличение точности анализа, оптимизация затрат, возможность предиктивного управления.

Вызовы качество и полнота входных данных, необходимость экспертизы в АПК и МО одновременно, интерпретируемость моделей (особенно нейросетей).

Методы машинного обучения становятся важнейшим инструментом в научно-обоснованном принятии решений в АПК. Они позволяют не только проводить анализ, но и формировать *интеллектуальное планирование*

Impact Factor:	ISRA (India)	= 6.317	SIS (USA)	= 0.912	ICV (Poland)	= 6.630
	ISI (Dubai, UAE)	= 1.582	РИНЦ (Russia)	= 0.191	PIF (India)	= 1.940
	GIF (Australia)	= 0.564	ESJI (KZ)	= 8.100	IBI (India)	= 4.260
	JIF	= 1.500	SJIF (Morocco)	= 7.184	OAJI (USA)	= 0.350

экспериментов, особенно при ограниченных ресурсах и высокой стоимости полевых испытаний. Развитие в этом направлении предполагает всё большую интеграцию с IoT, БПЛА, спутниковыми системами и облачными платформами.

Обучение с учителем (Supervised Learning) применяется при наличии размеченных данных. Используется в задачах прогнозирования урожайности, диагностики заболеваний, оценки эффективности агроприёмов. Наиболее распространёнными алгоритмами являются Линейная и полиномиальная регрессия; Метод опорных векторов (SVM); Случайные леса (Random Forest); Градиентный бустинг (XGBoost, LightGBM); Искусственные нейронные сети (ANN).

Обучение без учителя (Unsupervised Learning) используется для выявления скрытых закономерностей в неразмеченных данных. Позволяет проводить кластеризацию и сегментацию сельскохозяйственных объектов, таких как метод К-средних; Метод главных компонент (PCA); Самоорганизующиеся карты Кохонена; Автоэнкодеры.

Обучение с подкреплением (Reinforcement Learning) эффективно применяется для управления роботизированными системами, агроботами и автономными сельскохозяйственными машинами. Актуально также в задачах оптимизации расписаний полевых работ.

Методы планирования экспериментов с использованием ML В аграрных исследованиях машинное обучение используется для предварительного анализа данных и отбора информативных признаков, построения предсказательных моделей на основе данных полевых испытаний, при реализации байесовской оптимизации, позволяющей адаптивно планировать новые испытания на основе аппроксимации функции отклика и оценки неопределённости. ML-подходы также интегрируются с методами дизайн-экспериментов (DoE), повышая эффективность классических ПФЭ и ДФЭ.

Рассмотрим прогноз урожайности кукурузы с использованием случайного леса. В исследовании, проведённом на территории Центрального Казахстана, применялся алгоритм случайного леса для оценки урожайности кукурузы на основе климатических параметров, характеристик почвы и агротехнических приёмов. Модель достиг результата $R^2 = 0,87$, что позволяет рационализировать дозировку удобрений и минимизировать издержки на агрохимикаты.

Обучение модели случайного леса (Random Forest) — это процесс создания ансамбля деревьев решений, который используется для

классификации, регрессии и других задач анализа данных. Случайный лес состоит из множества решающих деревьев, каждое из которых обучается на случайной подвыборке исходных данных с применением случайности при выборе признаков для каждого узла дерева.

Основным шагом обучения модели случайного леса, состоит из выбора случайных подмножеств данных (Bootstrap). Для каждого дерева случайного леса случайным образом выбирается подмножество обучающих данных с возвращением (т.е., одно и то же наблюдение может попасть несколько раз в выборку).

Выбор случайных признаков заключается в том, что для каждого узла дерева случайным образом выбирается подмножество признаков. Подбор множества признаков помогает избежать переобучения и способствует созданию разнообразных деревьев.

Каждое дерево будет обучаться на своем подмножестве данных с использованием выбранных признаков. Деревья строятся с целью минимизации ошибки классификации или регрессии на обучающих данных.

После процесса обучения, выполняется прогноз, т.е. все деревья в случайном лесу дают свои прогнозы, а итоговый результат определяется путем голосования (для классификации) или усреднения (для регрессии) результатов всех деревьев.

Преимуществами случайного леса являются высокая точность благодаря ансамблевому подходу, устойчивость к переобучению на больших объемах данных. Он может работать с большим количеством признаков и сложными, нелинейными зависимостями.

Оценка важности признаков помогает выявлять ключевые факторы для принятия решений.

Случайный лес — это мощный инструмент для решения различных задач анализа данных в таких областях, как агрономия, медицина, финансовый анализ и т.д.

Рассмотрим алгоритм проведения эксперимента:

Шаг 1. Сбор и подготовка данных
Допустим, имеется CSV-файл corn_yield_data.csv со следующими признаками, с показателями:

- temperature — средняя температура (°C)
- precipitation — осадки (мм)
- soil_ph — pH почвы
- soil_type — тип почвы (категориальный)
- fertilizer_usage — количество удобрений (кг/га)
- irrigation — наличие орошения (0/1)
- plant_density — плотность посадки (растений на га)

Impact Factor:	ISRA (India)	= 6.317	SIS (USA)	= 0.912	ICV (Poland)	= 6.630
	ISI (Dubai, UAE)	= 1.582	ПИИЦ (Russia)	= 0.191	PIF (India)	= 1.940
	GIF (Australia)	= 0.564	ESJI (KZ)	= 8.100	IBI (India)	= 4.260
	JIF	= 1.500	SJIF (Morocco)	= 7.184	OAJI (USA)	= 0.350

– yield — урожайность кукурузы (ц/га) — целевая переменная

Шаг 2. Загрузка на языке python библиотек и загрузка данных

```
import pandas as pd
from sklearn.ensemble import
RandomForestRegressor
from sklearn.model_selection import
train_test_split
from sklearn.preprocessing import
OneHotEncoder
from sklearn.metrics import
mean_squared_error, r2_score
import matplotlib.pyplot as plt
import seaborn as sns
# Загрузка данных
data = pd.read_csv("corn_yield_data.csv")
# Быстрый просмотр
print(data.head())
```

Шаг 3. Осуществляется предобработка данных

```
# Кодирование категориальных переменных
data = pd.get_dummies(data,
columns=["soil_type"], drop_first=True)
# Разделение признаков и целевой
переменной
X = data.drop("yield", axis=1)
y = data["yield"]
# Деление на обучающую и тестовую
выборку
X_train, X_test, y_train, y_test =
train_test_split(X, y, test_size=0.2, random_state=42)
```

Шаг 4. Обучение модели случайного леса на python

```
# Инициализация и обучение модели
model =
RandomForestRegressor(n_estimators=100,
random_state=42)
model.fit(X_train, y_train)
```

Шаг 5. Для оценки модели используют Предсказания, Метрики качества

```
python
# Предсказания
y_pred = model.predict(X_test)
# Метрики качества
mse = mean_squared_error(y_test, y_pred)
r2 = r2_score(y_test, y_pred)
print(f'Mean Squared Error: {mse:.2f}')
print(f'R² Score: {r2:.2f}')
```

Шаг 6. Для анализ важности признаков необходимо визуализация важности признаков

```
python
# Визуализация важности признаков
```

```
feature_importances =
pd.Series(model.feature_importances_,
index=X.columns)
feature_importances.sort_values(ascending=True)
e).plot(kind='barh', figsize=(10,6))
plt.title("Feature Importances")
plt.xlabel("Importance")
plt.tight_layout()
plt.show()
```

Таким образом, случайный лес позволяет учитывать нелинейные зависимости между параметрами, автоматически обрабатывать взаимодействие между признаками, а также предоставит важную информацию о влиянии каждого признака.

Рассмотрим как адаптировать предыдущий код для оценки урожайности кукурузы в Центральном Казахстане с использованием реальных данных, куда входят климатические параметры, характеристики почвы, агротехнические приёмы и спутниковые данные, такие как NDVI, а также можно добавить визуализацию на основе карт для более наглядного представления результатов.

Шаг 1. Сбор и подготовка данных, где для проведения анализа потребуются следующие данные:

1. Климатические данные: среднемесячная температура, количество осадков и другие метеорологические показатели за вегетационный период. [MDPI](#)

2. Данные о почве: тип почвы, уровень pH, содержание органического вещества и другие характеристики.

3. Агротехнические данные: информация о применении удобрений, орошении, плотности посадки и других агротехнических приёмах.

4. Спутниковые данные (NDVI): нормализованный дифференциальный вегетационный индекс (NDVI) для оценки состояния растительности.

5. Данные об урожайности: фактические показатели урожайности кукурузы для соответствующих полей и периодов.

Источники данных, например, климатические данные можно получить из национальных метеорологических служб или глобальных климатических баз данных. Данные о почве доступны в национальных аграрных исследованиях или специализированных базах данных. NDVI получают со спутниковых снимков, где Sentinel-2 предоставляют данные с высоким разрешением и частотой обновления, которые подходят для мониторинга состояния растительности. Данные об урожайности можно собрать с помощью аграрных предприятий или государственных статистических служб.

Impact Factor:	ISRA (India)	= 6.317	SIS (USA)	= 0.912	ICV (Poland)	= 6.630
	ISI (Dubai, UAE)	= 1.582	ПИИЦ (Russia)	= 0.191	PIF (India)	= 1.940
	GIF (Australia)	= 0.564	ESJI (KZ)	= 8.100	IBI (India)	= 4.260
	JIF	= 1.500	SJIF (Morocco)	= 7.184	OAJI (USA)	= 0.350

Шаг 2. Выполняет импорт библиотек и загрузку данных

```
python
import pandas as pd
import geopandas as gpd
import rasterio
from rasterio.plot import show
from sklearn.ensemble import RandomForestRegressor
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import StandardScaler
from sklearn.metrics import mean_squared_error, r2_score
import matplotlib.pyplot as plt
import seaborn as sns
import numpy as np
```

Шаг 3. Предобработка данных осуществляется путем объединения данных, объединяют все собранные данные в единый DataFrame, сопоставляя их по географическим расположениям и по временным меткам.

Для обработки пропущенных значений, необходимо удалить или заполнить пропущенные значения в данных. При нормализации данных, масштабируют числовые признаки для улучшения производительности модели. Кодирование категориальных переменных осуществляется путем преобразования категориальных переменных в числовой формат (например, с использованием one-hot кодирования).

Шаг 4. Обучение модели случайного леса начинают с разделения данных на признаки (X) и целевую переменную (y): и разделением на обучающую и тестовую выборки, далее осуществляют масштабирование признаков:

```
python
# Разделение данных на признаки (X) и целевую переменную (y)
X = data.drop(columns=['yield'])
y = data['yield']
# Разделение на обучающую и тестовую выборки
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)
# Масштабирование признаков
scaler = StandardScaler()
X_train_scaled = scaler.fit_transform(X_train)
X_test_scaled = scaler.transform(X_test)
# Инициализация и обучение модели
model = RandomForestRegressor(n_estimators=100, random_state=42)
model.fit(X_train_scaled, y_train)
```

Шаг 5. Оценка модели начинается с предсказания и указания метрики качества.

```
python
# Предсказания
y_pred = model.predict(X_test_scaled)
# Метрики качества
mse = mean_squared_error(y_test, y_pred)
r2 = r2_score(y_test, y_pred)
print(f'Mean Squared Error: {mse:.2f}')
print(f'R² Score: {r2:.2f}')
```

Шаг 6. Визуализация результатов на карте

Для визуализации результатов на карте можно использовать библиотеку geopandas и данные о географических границах полей, с указанием границы полей, далее выполняют добавление предсказанных значений урожайности к геоданным. В качестве визуализации представляют карту предсказанной урожайности кукурузы.

```
python
# Загрузка геоданных (например, границы полей)
gdf = gpd.read_file('fields_shapefile.shp')
# Добавление предсказанных значений урожайности к геоданным
gdf['predicted_yield'] = model.predict(scaler.transform(X))
# Визуализация
fig, ax = plt.subplots(1, 1, figsize=(12, 8))
gdf.plot(column='predicted_yield', ax=ax, legend=True,
         legend_kwds={'label': "Предсказанная урожайность (ц/га)",
                       'orientation': "horizontal"})
plt.title('Карта предсказанной урожайности кукурузы')
plt.show()
```

Шаг 7. Интеграция спутниковых данных (NDVI), где для интеграции NDVI в анализ необходим загрузка спутниковых данных, что осуществляется использованием библиотеки rasterio, который служит для чтения спутниковых изображений. NDVI рассчитывается как отношение разности между ближним инфракрасным (NIR) и красным (Red) каналами к их сумме:

```
python
with rasterio.open('NIR_band.tif') as nir_src:
    nir = nir_src.read(1)
with rasterio.open('Red_band.tif') as red_src:
    red = red_src.read(1)
ndvi = (nir - red) / (nir + red)
```

Для привязки NDVI к полям надо усреднить значения NDVI для каждого поля и добавить их в DataFrame в качестве дополнительного признака.

Интеграция различных источников данных, включая климатические показатели, характеристики почвы, агротехнические приёмы и

Impact Factor:	ISRA (India)	= 6.317	SIS (USA)	= 0.912	ICV (Poland)	= 6.630
	ISI (Dubai, UAE)	= 1.582	РИНЦ (Russia)	= 0.191	PIF (India)	= 1.940
	GIF (Australia)	= 0.564	ESJI (KZ)	= 8.100	IBI (India)	= 4.260
	JIF	= 1.500	SJIF (Morocco)	= 7.184	OAJI (USA)	= 0.350

спутниковые данные, позволяет более точно описывать состояние исследуемых объектов.

Таблица 2.

Научный аспект	Применение
Прогноз урожайности	Использование Random Forest, нейросетей и XGBoost для оценки урожайности по климату, NDVI и агрофакторам
Оптимизация удобрений	Байесовская оптимизация, активное обучение
Обработка спутниковых данных	NDVI, EVI, Sentinel-2
Геопространственный анализ	GeoDataFrame, QGIS, Google Earth Engine
Классификация и кластеризация	SVM, k-Means, DBSCAN – типы почв, группы участков

Параллельно с машинным обучением используются обученная сверточная нейросеть (CNN), прогностическая модель на основе алгоритма градиентного бустинга,

Определение зон стресса растений по снимкам с БПЛА

Обученная сверточная нейросеть (CNN) на основе изображений NDVI и RGB, полученных с беспилотников, классифицировала участки поля по уровню стресса растений. Это позволило проводить прецизионное орошение и локальное внесение средств защиты растений.

Интеллектуальное планирование севооборота

Прогностическая модель на основе алгоритма градиентного бустинга учитывала агрохимические свойства почв, погодные сценарии и данные прошлых урожаев. Результатом стало автоматизированное составление плана севооборота, адаптированного к изменениям климата и структуре рынка.

Предиктивное обслуживание сельхозтехники

Система предиктивной диагностики на базе рекуррентных нейросетей (LSTM) анализировала данные с датчиков вибрации и температуры на тракторах и зерноуборочных комбайнах. Модель предсказывала вероятность отказа узлов техники за 7–10 дней, позволяя планировать сервисное обслуживание без простоев.

Машинное обучение становится ключевым инструментом в анализе аграрных данных и планировании экспериментов в АПК. Применение ML позволяет существенно сократить длительность полевых испытаний, повысить точность прогнозов и адаптировать агротехнологии к конкретным условиям. Перспективными направлениями являются интеграция моделей с цифровыми двойниками полей, разработка облачных сервисов анализа и внедрение автоматизированных рекомендаций для агроспециалистов.

References:

1. Kamilaris, A., Kartakoullis, A., & Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. *Computers and Electronics in Agriculture*.
2. Liakos, K. G., et al. (2018). Machine learning in agriculture: A review. *Sensors*.
3. Wolfert, S., et al. (2017). Big Data in Smart Farming – A review. *Agricultural Systems*.
4. Ainakulov, Z., Pirmanov, I., Koshekov, K., Astapenko, N., Fedorov, I., Zuev, D. & Kurmankulova, G. (2022). Risk Assessment of the Operation of Aviation Maintenance Personnel Trained on Virtual Reality Simulators. *Transport and Telecommunication Journal*, 23(4) 320-333. <https://doi.org/10.2478/ttj-2022-0026>
5. Kotenko, D.I., Kotenko, I.V., Sayenko, I.B. (2013). Modelirovaniye atak v bol'shikh komp'yuternykh setyakh // *Tekhnicheskiye nauki - ot teorii k praktike*. 2013. № 17-1. pp. 12-16.
6. Yin, X., et al. (2020). Deep learning to evaluate plant growth. *Plant Methods*, 2020.
7. Ainakulov, Z., Koshekov, K., Savostin, A., Anayatova, R., Seidakhmetov, B., & Kurmankulova, G. (2023). Development of an advanced AI-based model for human psychoemotional state analysis. *Eastern-European Journal of Enterprise Technologies*,

Impact Factor:	ISRA (India)	= 6.317	SIS (USA)	= 0.912	ICV (Poland)	= 6.630
	ISI (Dubai, UAE)	= 1.582	ПИИЦ (Russia)	= 0.191	PIF (India)	= 1.940
	GIF (Australia)	= 0.564	ESJI (KZ)	= 8.100	IBI (India)	= 4.260
	JIF	= 1.500	SJIF (Morocco)	= 7.184	OAJI (USA)	= 0.350

- 6(4(126)), 39-49. <https://doi.org/10.15587/1729-4061.2023.293011>
8. Ainakulov, Z., Kurmankulova, G., Ospanov, S., Ainakulova, Z., Schüle, H., & Akhmetov, K. (2024). *Developing a comprehensive solution for collecting and managing data from machines by different manufacturers*. In Proceedings of the 2nd International Interdisciplinary Scientific Conference “Digitalization and Sustainability for Development Management: Economic, Social, and Environmental Aspects” (AIP Conf. Proc. 3033, 020013). AIP Publishing. <https://doi.org/10.1063/5.0188481>
 9. Ainakulov, Z., Koshekov, K., Astapenko, N., & Pirmanov, I. (2023). The experience of introducing digital twins into the educational process on the example of training in the repair of aircraft equipment units. *Journal of Theoretical and Applied Information Technology*. 30th June 2023 - Vol. 101. No. 12 – 2023.
 10. Mohanty, S. P., Hughes, D. P., & Salathé, M. (2016). Using deep learning for image-based plant disease detection. *Frontiers in Plant Science*.
 11. Zhaksylykova, A., Ainakulov, Zh., & Kurmankulova, G. (2023). Modeling the process of implementation of attacks and estimation of its probabilistic parameters. *ISJ Theoretical & Applied Science*, 02 (118), 539-544. So: <http://s-o-i.org/1.1/TAS-02-118-47>
 12. Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. — Springer, 2006. — 738 p.
 13. Shapiro, B. I., Schimmelpfennig, D., & Griffin, T. (2019). Precision agriculture: an opportunity for machine learning and data analytics. *AI in Agriculture*. — 2019. — Vol. 1. pp. 45–54.
 14. Titov, S.V., & Ivanova, E.A. (2022). Primenenie metodov mashinnogo obucheniya v zadachah prognozirovaniya urozhajnosti. *Agronauka*. — 2022. — № 4. pp. 22-30.
 15. Ainakulov, Zh.Zh., Razakova, M.G., Kuzmin, A.G., Fedorov, I.O., & Yergaliev, R.K. (2020). Development of hardware and software architecture for analysis and processing of the field data, *Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci.*, XLIII-B2-2020, 1253-1258 (SCOPUS, WOS), <https://doi.org/10.5194/isprs-archives-XLIII-B2-2020-1253-2020>
 16. Ainakulov, Z., Koshekov, K., Savostin, A., Anayatova, R., Seidakhmetov, B., & Kurmankulova, G. (2023). Development of an advanced AI-based model for human psychoemotional state analysis. *Eastern-European Journal of Enterprise Technologies*, 6(4(126)), 39-49. <https://doi.org/10.15587/1729-4061.2023.293011>
 17. Koval`chuk, V.M. (2023). Mashinnoe obuchenie v agroinzhenerii: perspektivy i vyzovy. *Vestnik agrarnoy nauki*. — 2023. — № 3. pp. 60-68.
 18. (n.d.). *Scikit-learn: Machine Learning in Python*. — [Jelektronnyj resurs]. Retrieved from <https://scikit-learn.org/>
 19. (n.d.). *TensorFlow: Open-source ML platform*. — [Jelektronnyj resurs]. Retrieved from <https://www.tensorflow.org/>