Развитие концепции точного земледелия для культур озимой пшеницы: от мультиспектральных спутниковых данных к гиперспектральным эталонам

А. И. Новиков [1], О. И. Соколова [2], Т. П. Новикова [3]

[1] *Агрофизический научно-исследовательский институт*
Санкт-Петербург, 195220, Россия
E-mail: nvatdo@gmail.com

[2] *Ростовский государственный университет путей сообщения*
Ростов-на-Дону, 344038, Россия

[3] *Санкт-Петербургский государственный лесотехнический университет им. С. М. Кирова, Санкт-Петербург, 194021, Россия*
E-mail: novikova_tp.vglta@mail.ru

Повышение эффективности управления продукционным процессом озимой пшеницы представляется ключевой задачей для обеспечения продовольственной безопасности и устойчивого развития сельского хозяйства. В настоящей статье анализируется и развивается концепция интегрированной системы управления, сочетающая данные дистанционного зондирования Земли, климатические показатели, почвенные характеристики, гибкие алгоритмы оценивания параметров состояния и передовые методы машинного обучения для мониторинга роста и прогнозирования урожайности озимой пшеницы. На основе анализа современных исследований, включая модели IGWO-CNN (*англ.* Improved Gray Wolf Optimization — Convolutional Neural Network), LSTM (*англ.* Long Short-Term Memory), RF (*англ.* Random Forest), SVM (*англ.* Support Vector Machine), WOFOST (*англ.* WOrld FOod STudies) и др., рассмотрен комплексный подход, позволяющий осуществлять точное и своевременное прогнозирование урожая на региональном уровне. Особое внимание уделено проблеме интеграции гиперспектральных данных в качестве эталонных для калибровки и верификации спутниковых моделей. Представлен многоперспективный анализ эффективности различных сенсоров и методов, в том числе анализ на уровне сенсоров, методологий моделирования, предикторов и проблемных областей, что позволило определить наиболее эффективные подходы для интеграции с гиперспектральными эталонами. Предложено усовершенствование алгоритма оценивания состояния агроценоза на основе фильтра Калмана для расширенного вектора состояния, включающего параметры биомассы и почвенной среды. Результаты показывают, что интеграция мультиспектральных данных (особенно Sentinel-2 с красными краевыми каналами) и радарных данных (Sentinel-1) с гиперспектральными эталонами и интерпретируемыми моделями глубокого обучения значительно повышает надёжность прогнозов и будет способствовать принятию обоснованных решений в сельскохозяйственном производстве.

Ключевые слова: точное земледелие, озимая пшеница, дистанционное зондирование, гиперспектральные данные, машинное обучение, оценивание состояния, продукционный процесс, MODIS, LSTM, IGWO-CNN, Sentinel-2, интеграция данных, фильтр Калмана

Одобрена к печати: 25.05.2026
DOI: 10.21046/2070-7401-2026-23-4-27-48

Введение

Пшеница озимая (*Triticum aestivum* L.) — одна из важнейших зерновых культур в мире, которая обеспечивает значительную долю продовольственных ресурсов. В условиях роста глобального населения и увеличения частоты экстремальных погодных явлений точный и своевременный прогноз урожайности становится критически важным для формирования сельскохозяйственной политики, управления ресурсами и минимизации рисков (Chen et al., 2023; Fu et al., 2025). Традиционные методы прогнозирования урожайности, основанные на полевых обследованиях и статистических данных, требуют значительных трудозатрат и часто ограничены в масштабе (Han et al., 2020; Zhou et al., 2022). Развитие технологий дистанционного зондирования (ДЗ) и машинного обучения открыло новые возможности для мони-

торинга посевов и прогнозирования урожайности на больших территориях (Ali et al., 2023; Guo et al., 2006). Спутниковые данные, представленные в виде вегетационных индексов NDVI (*англ.* Normalized Difference Vegetation Index), EVI (*англ.* Enhanced Vegetation Index), GNDVI (*англ.* Green Normalized Difference Vegetation Index), п роизводных ключевых биофизических параметров, таких как индекс листовой поверхности LAI (*англ.* Leaf Area Index) и доля поглощённой фотосинтетически активной радиации FAPAR (*англ.* Fraction of Absorbed Photosynthetically Active Radiation), позволяют отслеживать состояние посевов в режиме, близком к реальному времени (Guanter et al., 2014; Huete et al., 2002). Гиперспектральные измерения, обеспечивающие непрерывную спектральную информацию в узких диапазонах, дают возможность детально характеризовать биофизические и биохимические свойства культур, которые не могут быть захвачены широкополосными мультиспектральными сенсорами (Lu et al., 2020).

В последние годы активно развиваются два основных подхода к прогнозированию урожайности: процессные модели роста растений (например, WOFOST (*англ.* WOrld FOod Studies)) и эмпирико-статистические модели, включая методы машинного обучения (Lobell, Burke, 2010; van Klompenburg et al., 2020). Процессные модели требуют большого количества входных данных и калибровки параметров для конкретных условий, что ограничивает их применение на больших площадях (Jones et al., 2003). В то же время машинное обучение, в частности глубокое обучение, демонстрирует высокую эффективность в выявлении сложных нелинейных взаимосвязей между урожайностью и предикторами (Cai et al., 2019; Khaki, Wang, 2019). Интеграция данных дистанционного зондирования в процессные модели, такая как ассимиляция данных о LAI в модель WOFOST, позволяет уточнить параметры модели и улучшить точность прогнозов на региональном уровне (Delécolle et al., 1992; Guérif, Duke, 2000). Однако для реализации такого подхода необходимо решить ряд задач, включая выбор оптимальных временных окон для прогнозирования, учёт пространственно-временной изменчивости и комбинирование данных из различных источников (Bolton, Friedl, 2013; Wang et al., 2020).

Несмотря на прогресс в развитии подходов, предложенных В. В. Галицким, А. С. Комаровым (1979) и И. М Михайленко (2005), ключевой проблемой остаётся калибровка и верификация спутниковых моделей.

Цель данного исследования — развитие концепции интегрированной системы управления продукционным процессом озимой пшеницы путём включения в неё анализа эффективности спутниковых методов для интеграции с гиперспектральными эталонными данными и усовершенствования алгоритма оценивания состояния культур озимой пшеницы.

Обзор исследований по управлению продукционным процессом озимой пшеницы

Базовые подходы к управлению системами точного земледелия

Для управления продукционным процессом культур озимой пшеницы существует необходимость оптимального выбора сроков посева, норм высева, доз удобрений, регулярного мониторинга состояния посевов, а также корректировки управляющих воздействий в реальном времени (Михайленко, Тимошин, 2025).

При этом дистанционное зондирование Земли (ДЗЗ) позволит оценивать биомассу с помощью дистанционных предикторов, получаемых на основе дифференцированного спектрального отражения листовыми пластинами и почвой фотосинтетически активной солнечной радиации в разных спектральных полосах. В качестве предикторов могут быть рассмотрены коэффициенты спектральной яркости или расчётные производные вегетационные индексы, которые коррелируют с фенологическими фазами развития культуры и продуктивностью.

В качестве практической реализации алгоритма оценивания, как правило, рассматриваются определение оптимальных сроков внесения удобрений и выбор момента уборки урожая

на основе данных о накопленной биомассе. Потенциал применения данных ДЗ в алгоритме оценивания предопределяется снижением рисков за счёт оперативного мониторинга, повышением рентабельности через оптимизацию использования ресурсов для проведения агроуходов. Существуют и некоторые риски применения данных ДЗЗ на базе UAV-платформы (*англ.* Unmanned Aerial Vehicle): необходимость в квалифицированных кадрах для интерпретации картограмм и ортофотопланов, зависимость от погодных условий и технических сбоев.

Дистанционное зондирование Земли позволит выявлять пространственную неоднородность полей, связанную с почвенными условиями, влажностью, поражением болезнями или вредителями. Наиболее информативными для оценки состояния культуры оказываются VNIR-диапазон длин электромагнитных волн (*англ.* visible and near infrared), полосы фотосинтетически активной солнечной радиации (400–700 нм) и NIR (*англ.* near infrared), особенно в окрестностях гидроксильного пика (около 970 нм) на спектрограмме.

Основные фокальные плоскости зарубежных поисковых исследований по управлению продукционным процессом озимой пшеницы с использованием ДЗЗ следующие:

1. Прогнозирование урожайности. Осуществляется, как правило, на основе данных ДЗЗ, в том числе UAV-данных, полученных системами захвата изображения на UAV-платформе различной аэродинамической схемы, что помогает автоматизировать процесс сбора данных.

2. Интеграция с машинным обучением. Предполагает интеграцию данных ДЗЗ с методами машинного обучения, такими как RFR (*англ.* Random Forest Regression), для создания моделей, которые могут с высокой степенью точности предсказывать урожайность на разных стадиях роста озимой пшеницы (Liu et al., 2025).

3. Оценка устойчивости к стрессорам засухи. Использование UAV для ДЗЗ позволяет оценить устойчивость сортов озимой пшеницы к засухе, что критически важно для повышения урожайности в условиях ограниченного доступа культур к водным ресурсам (Liu et al., 2025).

Предлагаемая в исследованиях система управления продукционным процессом включает следующие этапы:

1. Сбор и предварительная обработка данных: агрегация мультиспектральных или гиперспектральных данных ДЗЗ, климатических и почвенных показателей на платформах типа GEE (*англ.* Google Earth Engine). Нормализация данных и их приведение к единому пространственно-временному разрешению.

2. Картирование посевов и мониторинг фенологии: выделение площадей, занятых озимой пшеницей, с использованием классификации спутниковых снимков и данных о фенологических стадиях.

3. Выявление ключевых предикторов: анализ корреляции между урожайностью и различными факторами (вегетационными индексами, климатическими переменными). Оценка важности признаков с помощью методов, таких как SHAP (*англ.* SHapley Additive exPlanations) (Chen et al., 2023). Например, в исследовании (Fu et al., 2025), выполненном по территории трёх ключевых зон возделывания озимой пшеницы Китая — Хуан-Хуай-Хай (*англ.* Huang-Huai-Hai), среднего и нижнего течения реки Янцзы (*англ.* Middle and Lower Yangtze River), Северо-Западного пшеничного региона (*англ.* Northwest Wheat Region); в пределах 58 городов провинций Хэнань (*англ.* Henan), Шаньдун (*англ.* Shandong), Аньхой (*англ.* Anhui) и Шэньси (*англ.* Shaanxi), наибольшую статистически значимую корреляцию с урожайностью (коэффициент корреляции Пирсона $r = 0{,}83$; уровень значимости $p < 0{,}001$) показал индекс GNDVI.

4. Прогнозирование урожайности: применение оптимальных моделей машинного и глубокого обучения (например, IGWO-CNN (*англ.* Improved Gray Wolf Optimization — Convolutional Neural Network), LSTM (*англ.* Long Short-Term Memory), RF (*англ.* Random Forest, случайный лес)) для прогнозирования урожайности на уровне округов или пикселей. Определение оптимального временного окна для прогноза (для условий Китая, по данным (Fu et al., 2025), апрель считается ключевым месяцем для раннего прогноза озимой пшеницы).

5. Верификация и оценка точности: использование методов перекрёстной проверки (например, LOYO (*англ.* leave-one-year-out)) и метрик качества (R^2 (коэффициент детерминации), RMSE (*англ.* Root Mean Square Error), MAE (*англ.* Mean Absolute Error), MAPE (*англ.* Mean Absolute Percentage Error)) для оценки моделей.

Таблица 1. Сравнительная эффективность моделей прогнозирования урожайности озимой пшеницы

Модель	Данные	Точность (R^2)	RMSE, кг/га	Ключевые преимущества	Источник
IGWO-CNN	MODIS (NDVI, GNDVI и др.), климат	0,7587	593,6	Высокая точность за счёт оптимизации гиперпараметров, устойчивость к переобучению	(Fu et al., 2025)
LSTM	Мультиспектральные, климат, почва, рельеф	0,71	~300 (0,30 т/га)	Учёт временных рядов, высокая точность в нормальные и экстремальные годы	(Chen et al., 2023)
RF	Климат, ДЗ (SIF, NDVI, EVI)	0,75–0,79	660–1040	Хорошая интерпретируемость, устойчивость к шуму, обработка нелинейностей	(Han et al., 2020; Zhou et al., 2022)
SVM (метод опорных векторов)	Климат, ДЗ	0,69–0,79	~750	Эффективность в высокоразмерных пространствах	(Han et al., 2020; Zhou et al., 2022)
LASSO	Климат, ДЗ	0,15–0,69	Зависит от зоны	Отбор признаков, простота	(Han et al., 2020)
WOFOST+ДЗЗ	Landsat (LAI), погода, почва	–	–	Физиологическая интерпретируемость, учёт процессов роста	(Guo et al., 2006)

Примечание: MODIS (*англ.* Moderate Resolution Imaging Spectroradiometer); SIF (*англ.* Solar-Induced chlorophyll Fluorescence); SVM (*англ.* Support Vector Machine); LASSO (*англ.* Least Absolute Shrinkage and Selection Operator).

Таблица 2. Важность предикторов в прогнозировании урожайности озимой пшеницы (на основе анализа SHAP и RF)

Предиктор	Категория	Относительная важность	Примечания
GNDVI	Вегетационный индекс	Наивысшая	Чувствителен к содержанию хлорофилла, наивысшая корреляция с урожайностью (0,83) (Fu et al., 2025)
EVI	Вегетационный индекс	Высокая	Меньше подвержен насыщению, чем NDVI, обеспечивает более точную оценку растительного покрова в условиях высокой биомассы (Han et al., 2020)
NDVI	Вегетационный индекс	Высокая	Стандартный индекс для оценки растительности, но подвержен насыщению (Fu et al., 2025; Han et al., 2020)
SIF	Флуоресценция	Высокая	Прямая связь с фотосинтезом, превосходит NDVI/EVI в некоторых сценариях (Han et al., 2020)
Осадки (PR)	Климатический	Высокая	Ключевой водный фактор, отрицательная корреляция в некоторых регионах (Fu et al., 2025; Han et al., 2020)
Минимальная температура (T_{MIN})	Климатический	Средне-высокая	Влияние на морозоустойчивость и процессы развития (Zhou et al., 2022)
Фактическая эвапотранспирация (AET)	Климатический	Средняя	Отражает водопотребление культуры (Fu et al., 2025)
Индекс засухи Палмера (PDSI)	Климатический	Средняя	Интегральный показатель засушливых условий (Fu et al., 2025)
Свойства почвы	Почвенный	Средняя	Влажность, содержание органического углерода, текстура (Ali et al., 2023; Chen et al., 2023)

Примечание: PR — осадки (*англ.* Precipitation); AET — фактическая эвапотранспирация (*англ.* Actual EvapoTranspiration); PDSI — индекс засухи Палмера (*англ.* Palmer Drought Severity Index).

На основе анализа представленных исследований были получены следующие ключевые результаты, демонстрирующие степень эффективности различных подходов к прогнозированию урожайности озимой пшеницы (*табл. 1* и *2*).

Анализ точности прогнозирования в зависимости от временного окна показал, что использование данных за весь вегетационный период (с октября по май) позволяет достичь наивысшей точности ($R^2 > 0{,}8$, ошибка <10 %) (Zhou et al., 2022). При этом для исследованных регионов Китая апрель, соответствующий фазе цветения озимой пшеницы, был идентифицирован как оптимальный срок для раннего прогноза (Fu et al., 2025).

Пространственный анализ ошибок прогнозирования показал, что модели имеют тенденцию к завышению урожайности в высокопродуктивных регионах и занижению в низкопродуктивных, что может быть связано с региональными различиями в агротехнике и сортах (Fu et al., 2025; Han et al., 2020).

Интеграция спутникового агромониторинга с гиперспектральными эталонными данными

Для интеграции гиперспектральных измерений в качестве эталона в разрабатываемую систему управления продукционным процессом озимой пшеницы необходимо провести анализ эффективности различных спутниковых подходов за период 2000–2025 гг.

Анализ на уровне сенсоров: спектральная и структурная комплементарность

Первый аналитический подход (Radočaj et al., 2026) исследует соответствие между характеристиками спутниковых сенсоров и возможностями гиперспектральных измерений. Мультиспектральные данные спутниковых миссий (в том числе MODIS), установленных на спутниковых платформах (среди которых Sentinel-2, Landsat), доминируют в литературе по прогнозированию урожайности благодаря их способности охватывать динамику растительности через спектральные индексы (Radočaj et al., 2026). Среди этих миссий Sentinel-2 приобрёл особое значение для интеграции с гиперспектральными данными благодаря наличию красных краевых каналов (*англ.* red-edge) в диапазоне 705–865 нм, которые демонстрируют высокую чувствительность к содержанию хлорофилла, азотному статусу и стрессовым состояниям культур (Segarra et al., 2020). Эти узкие каналы наиболее близко имитируют гиперспектральные измерения в критической области спектра, где происходят основные физиологические изменения.

Радарные сенсоры, установленные, например, на спутниках Sentinel-1, предоставляют данные, комплементарные по физической природе к гиперспектральным измерениям и существенно отличающиеся от них по типу регистрируемого сигнала. Если гиперспектральные измерения отражают биохимический состав тканей растения (содержание хлорофилла, каротиноидов, лигноцеллюлозы и др.) через регистрацию отражённого солнечного излучения в диапазоне 400–2500 нм, то радарное обратное рассеяние в С-диапазоне, на частоте около 5,405 ГГц и длине волны около 5,55 см, чувствительно преимущественно к диэлектрическим свойствам системы «почва–растение», а также геометрической архитектуре полога (Marais Sicre et al., 2020). Это принципиально важно для интеграции, поскольку позволяет объяснять вариабельность урожая, которую гиперспектр может фиксировать, но которая может быть недоступна для оптических спутниковых систем из-за облачности или сложной архитектуры полога (Jennewein et al., 2022).

Наиболее эффективной стратегией на уровне сенсоров становится мультисенсорная интеграция (*англ.* data fusion) оптических и радарных данных. Такой подход позволяет компенсировать недостатки каждого типа данных и создаёт многомерное пространство признаков, которое может быть калибровано по гиперспектральным эталонам. Исследования показывают, что комбинация данных Sentinel-2 и Sentinel-1 повышает устойчивость моделей

к облачности и обеспечивает более полное представление о состоянии посевов в критические фазы развития (Chahbi-Bellakanji et al., 2025). Для целей калибровки по гиперспектру это означает, что спутниковые модели могут быть обучены на гиперспектральных измерениях, а затем применены к комбинированным спутниковым данным с сохранением физической интерпретируемости.

Анализ методик моделирования: от эмпирики к гибридным системам

Второй аналитический подход фокусируется на вычислительных методах, которые обеспечивают наилучшую передачу от гиперспектральных эталонов к спутниковым данным. Эволюция методологий в области прогнозирования урожайности демонстрирует чёткий переход от простых регрессионных моделей к сложным архитектурам машинного и глубокого обучения (Radočaj et al., 2026).

Традиционные методы машинного обучения, такие как случайный лес RF и градиентный бустинг XGBoost, широко применяются благодаря их способности моделировать нелинейные зависимости между спутниковыми предикторами и урожайностью (Shahhosseini et al., 2021). При этом данные методы обладают ограниченной интерпретируемостью, что зачастую затрудняет понимание того, почему спутниковая модель расходится с гиперспектральными эталонами.

Методы глубокого обучения, особенно свёрточные нейронные сети (CNN) и сети долгой краткосрочной памяти (LSTM), демонстрируют высокую эффективность в обработке пространственно-временных рядов спутниковых данных (Muruganantham et al., 2022). Архитектуры LSTM способны захватывать фенологическую динамику и могут быть обучены на «идеальных» гиперспектральных временных рядах, а затем применены к спутниковым данным с временными пропусками или пониженным спектральным разрешением (Liu et al., 2023).

Наиболее перспективное направление для интеграции с гиперспектральными эталонами — интерпретируемое машинное обучение (XAI (*англ.* Explainable Artificial Intelligence)). Методы, такие как SHAP и графики частичной зависимости PDP (*англ.* Partial Dependence Plot), позволяют количественно оценить вклад каждого спутникового признака в итоговый прогноз (Elbeltagi et al., 2025; Lyu et al., 2024). Для интеграции с гиперспектром это создаёт уникальную возможность: сравнивать важность спутниковых индексов (например, NDVI по Sentinel-2 в фазу цветения) с важностью узких гиперспектральных полос. Такое сравнение напрямую указывает, какие спутниковые каналы или производные индексы нуждаются в калибровке по гиперспектральным эталонам. Перспективным дополнением к XAI является применение глубоких конволюционных нейронных сетей (Bernardes et al., 2022; Novikova et al., 2026) и алгоритмов нечёткой логики (Novikov et al., 2021) и методов PERT-планирования (Новикова и др., 2021) для организации проектных работ по агромониторингу, что создаёт предпосылки для прогнозирования спектральных характеристик формируемого агроценоза.

Гибридные модели, объединяющие процессные модели роста культур и машинное обучение, представляют собой наиболее физически обоснованный путь интеграции. Модели типа DSSAT (*англ.* Decision Support System for Agrotechnology Transfer), APSIM (*англ.* Agricultural Production Systems sIMulator), WOFOST описывают физиологические механизмы формирования урожая на основе погодных условий, свойств почвы и управления (Gavasso-Rita et al., 2024; Peng et al., 2020). Интеграция спутниковых и гиперспектральных данных в такие модели через ассимиляцию данных позволяет калибровать параметры моделей на локальном уровне. В этой парадигме гиперспектр выступает в роли учителя, предоставляя эталонные значения биофизических переменных (содержание хлорофилла, индекс листовой поверхности), которые затем используются для настройки спутниковых продуктов (Jin et al., 2020).

Анализ предикторов: фенологическая динамика в сопоставлении с точечными измерениями

Третий аналитический подход исследует, что́ важнее для точности прогнозирования и согласования с гиперспектральными эталонами — снимки в критические фазы развития или интегральные показатели динамики роста.

Фенологические метрики LSP (*англ.* Land Surface Phenology) приобретают всё большее значение в современной литературе (Radočaj et al., 2026). На основе временных рядов спутниковых вегетационных индексов рассчитываются такие показатели, как дата начала сезона, пик вегетации, продолжительность вегетационного периода и скорость нарастания биомассы (Liu et al., 2022; Ma et al., 2022). Эти метрики отражают интегральный эффект условий произрастания и сильно коррелируют с итоговой урожайностью. Для интеграции с гиперспектром фенологический подход предлагает важное преимущество: гиперспектральные измерения, выполненные в полевых условиях, могут быть привязаны к точным фенологическим фазам, определённым по спутниковым данным. Это позволяет создавать калибровочные кривые «спутниковый индекс – гиперспектральная характеристика» для каждой ключевой фазы развития.

Точечные измерения в критические фазы остаются важным компонентом, поскольку гиперспектральные съёмки часто проводятся именно в фазы цветения или налива зерна, когда растения наиболее чувствительны к стрессам (Pei et al., 2025). Спутниковые снимки в эти же периоды могут быть напрямую сопоставлены с гиперспектральными эталонами.

Наиболее эффективной стратегией представляется гибридный фенологический подход:

1. Использование плотных временных рядов спутниковых данных (Sentinel-2) для определения точных дат наступления критических фенологических фаз.
2. Проведение гиперспектральных измерений именно в эти фазы для максимизации информативности эталонных данных.
3. Сравнение спутниковых индексов и гиперспектральных характеристик в привязке к фенологическому календарю, что позволяет масштабировать точечные гиперспектральные эталоны на региональный уровень с учётом пространственно-временной вариабельности фенологии.

Анализ проблемных областей и направлений для интеграции

Четвёртый аналитический подход идентифицирует ключевые проблемы спутникового мониторинга, которые могут быть наиболее эффективно решены через интеграцию с гиперспектральными эталонными данными.

Проблема насыщения вегетационных индексов представляет собой фундаментальное ограничение мультиспектральных сенсоров. Традиционные индексы, такие как NDVI, перестают расти при высоких значениях биомассы (индекс листовой поверхности LAI > 3–4), теряя чувствительность к дальнейшему накоплению биомассы (Zhang et al., 2025). Гиперспектральные измерения свободны от этого ограничения, поскольку могут использовать узкие полосы в ближнем и среднем инфракрасном диапазонах, чувствительные к сухому веществу и содержанию воды. Интеграция гиперспектральных эталонов позволяет разрабатывать гибридные индексы насыщения на основе спутниковых данных Sentinel-2, калиброванные по гиперспектральным измерениям в зонах высокой биомассы (Radočaj et al., 2025a).

Проблема обобщаемости моделей (*англ.* model transferability) становится серьёзным ограничением для оперативного применения. Модели, обученные на данных одного региона или года, часто демонстрируют низкую точность при переносе на другие условия (Filippi et al., 2024; Jiang et al., 2022). Гиперспектральные измерения могут служить мостом для калибровки моделей под локальные условия, предоставляя эталонные спектральные сигнатуры, которые инвариантны к сенсору и могут быть использованы для нормализации спутниковых данных.

Специальные и мелкотоварные культуры (*англ.* specialty and minor crops) остаются значительно недоисследованными в литературе по сравнению с основными зерновыми (Radočaj et al., 2026). Для овощных культур, фруктов и технических культур точность спутниковых прогнозов часто не превышает $R^2 = 0{,}60...0{,}70$ из-за высокой гетерогенности поля, сложной архитектуры полога и коротких циклов вегетации (Cui et al., 2025; Dhaliwal, Williams et al., 2024; Lee et al., 2010).

Проблема пространственного разрешения и границ полей особенно актуальна для мозаичных ландшафтов и систем точного земледелия. Современные спутниковые миссии (Sentinel-2 с разрешением 10–20 м) могут не разрешать внутрипольную неоднородность, особенно при наличии узких полей или смешанных посевов (Trevisiol et al., 2024). Гиперспектральные измерения с беспилотных летательных аппаратов или наземных платформ обеспечивают эталонные данные на субпиксельном уровне, позволяя разрабатывать модели спектрального смешивания и методы субпиксельной декомпозиции для спутниковых данных (Ma et al., 2024).

Тенденции развития интегрированной системы управления продукционным процессом озимой пшеницы с использованием аэродистанционных данных

Предложения по совершенствованию концепции системы управления продукционным процессом озимой пшеницы

Рассмотрим особенности построения концепции системы управления продукционным процессом культур озимой пшеницы по ключевым элементам.

Эффективность моделей. Сравнительный анализ показал, что модели глубокого обучения (IGWO-CNN, LSTM) и ансамблевые методы (RF) превосходят традиционные модели машинного обучения (SVR, KNN) и линейные подходы (LASSO) по точности и устойчивости (Chen et al., 2023; Fu et al., 2025; Han et al., 2020; Zhou et al., 2022). Это связано с их способностью улавливать сложные нелинейные взаимосвязи и пространственно-временные паттерны в данных ДЗЗ. В частности, IGWO-CNN демонстрирует, как оптимизация гиперпараметров может существенно повысить производительность модели (Fu et al., 2025). В свою очередь, LSTM идеально подходит для учёта кумулятивного эффекта погодных условий и состояния посевов в течение сезона (Chen et al., 2023).

Важность интегрированных данных. Результаты подтверждают, что ни один источник данных не является достаточным для максимально точного прогноза. Климатические данные, особенно водные переменные (осадки, эвапотранспирация), несут критически важную информацию на протяжении всего вегетационного периода (Han et al., 2020). Данные ДЗЗ, прежде всего вегетационные индексы (GNDVI, EVI) и SIF, становятся наиболее информативными в критические фазы развития, такие как цветение и налив зерна. Для условий Китая, согласно работе (Fu et al., 2025), это апрель–май. Для фенологических периодов, выделенных при обследовании 1582 уездов в северной и южной зоне возделывания озимой пшеницы Китая (Zhou et al., 2022), — в пиковый и поздний период вегетации. Интеграция этих данных позволяет моделям компенсировать недостатки друг друга: климатические данные обеспечивают прогноз на ранних стадиях, а дистанционные — уточняют его по мере развития культуры (Han et al., 2020).

Практическая применимость в точном земледелии. Практическая значимость представленной разработки для точного земледелия заключается в реализации концепции перехода от унифицированного управления агроценозом к дифференцированному, основанному на прецизионных данных. Интеграция системы в производственный цикл обеспечивает непрерывный мониторинг посевов в реальном времени, позволяя детектировать пространственную неоднородность их состояния и своевременно идентифицировать зоны, подверженные водному или питательному стрессу, что создаёт основу для оперативной корректировки агротехнологических процессов.

Ключевое преимущество системы — возможность заблаговременного прогнозирования урожайности (за 1–2 мес. до уборки), что предоставляет сельхозтоваропроизводителям ценный временной ресурс для оптимизации логистических схем, планирования режимов хранения и маркетинговых стратегий сбыта зерна, а также для объективной оценки производственных рисков в рамках агрострахования. В конечном итоге, формируемые на основе прогнозных моделей и карт продуктивности данные служат основой для принятия решений о дифференцированном внесении удобрений, средств защиты растений и адаптации графиков орошения, что способствует существенной экономии материально-технических ресурсов и минимизации антропогенной нагрузки на окружающую среду.

Несмотря на представленные преимущества, имеются и некоторые недостатки. К ним относятся необходимость в данных сверхвысокого пространственного разрешения, учёт агротехнических практик (сорта, обработка почвы), а также «чёрный ящик» некоторых моделей глубокого обучения. Перспективными направлениями следует считать:

- совместное использование моделей — ассимиляция данных ДЗЗ в процессные модели роста культур (как в работе (Guo et al., 2006)) для сочетания физиологической интерпретируемости с точностью машинного обучения;
- использование новых источников данных — данные радара с синтезированной апертурой SAR (*англ.* Synthetic Aperture Radar) для мониторинга биомассы и влажности независимо от облачности, а также данные беспилотных летательных аппаратов для гиперлокального мониторинга;
- развитие XAI — применение методов, подобных SHAP, для объяснения прогнозов сложных моделей и получения агрономически ценных инсайтов (значимых представлений о скрытых закономерностях формирования урожая).

На основе проведённого анализа может быть предложена интегрированная стратегия использования гиперспектральных данных в качестве эталона для спутникового агромониторинга.

Уровень 1: сенсорная архитектура. Базовая платформа должна включать синхронизированные временные ряды Sentinel-2 (мультиспектральный оптический сенсор с красными краевыми каналами) и Sentinel-1 (радарный SAR). Спутник Sentinel-2 обеспечивает максимальную спектральную близость к гиперспектральным измерениям, а Sentinel-1 предоставляет комплементарную структурную информацию, устойчивую к облачности (Radočaj et al., 2025b).

Уровень 2: калибровочная сеть. Гиперспектральные измерения должны проводиться в стратифицированных репрезентативных точках, охватывающих основные типы почв, сорта культур и градиенты продуктивности. Временная привязка гиперспектральных съёмок должна соответствовать ключевым фенологическим фазам, определяемым по спутниковым временным рядам (Pei et al., 2025).

Уровень 3: методологический каркас. Рекомендуется использование интерпретируемых моделей машинного обучения (XAI) с применением SHAP-анализа для количественного сравнения важности спутниковых и гиперспектральных признаков (Elbeltagi et al., 2025). Для учёта временной динамики предпочтительны архитектуры LSTM, способные обучаться на гиперспектральных временных рядах и переносить знания на спутниковые данные с пониженным спектральным разрешением (Liu et al., 2023).

Уровень 4: целевые направления. Приоритетными направлениями для интеграции должны стать: 1) преодоление эффекта насыщения NDVI в зонах высокой биомассы через калибровку гибридных индексов по гиперспектральным измерениям; 2) разработка моделей для специальных (овощных, плодовых, технических) культур с использованием гиперспектральных библиотек спектральных сигнатур; 3) создание регионально-адаптивных моделей через трансферное обучение с гиперспектральных эталонов на спутниковые данные.

Фильтр Калмана в задачах управления продукционным процессом озимой пшеницы

Фильтр Калмана и его роль в интегрированных системах управления продукционным процессом озимой пшеницы

Фильтр Калмана представляет собой рекурсивный алгоритм оптимальной оценки состояния динамической системы. Его современные модификации основаны на адаптивной стохастической фильтрации с оцениванием ковариационной матрицы шумов измерений по нерегулярным высокоточным наблюдениям (Sokolov et al., 2021), в том числе с учётом терминальной фильтрации (Sokolov et al., 2023), алгоритмах, устойчивых к постоянным возмущениям параметров наблюдаемого объекта (Manin et al., 2022), и методах адаптации к возмущениям параметров наблюдателя (Manin et al., 2021). В задачах навигации беспилотных летательных аппаратов эффективность такого подхода подтверждена результатами адаптивного оценивания навигационных параметров по нерегулярным инерциально-спутниковым измерениям (Sokolov, Novikov, 2021).

Фильтр Калмана для задачи оценивания состояния параметров агрокультуры (Михайленко, Тимошин, 2025) имеет вид:

$$\mathbf{X}^*(t) = \mathbf{X}^*(t-1) + \mathbf{P}(t)\mathbf{H}(t)[\mathbf{Z}(\mathrm{t}) - \mathbf{H}(t)\mathbf{X}^*(t-1)], \quad (1)$$

$$\mathbf{P}(t) = [\mathbf{I} - \mathbf{K}(t)\mathbf{H}(t)]\mathbf{P}(t-1), \quad (2)$$

$$\mathbf{K}(t) = \mathbf{P}(t-1)\mathbf{H}^T(t)[\mathbf{H}(t)\mathbf{P}(t-1)\mathbf{H}^T(t) + \mathbf{R}(t)]^{-1}, \quad (3)$$

где $\mathbf{X}^*(t)$ — оценка вектора параметров состояния $\mathbf{X}(t)$ биомассы культуры; $\mathbf{P}(t)$ — матрица ошибок оценивания; $\mathbf{K}(t)$ — матричный коэффициент усиления фильтра; $\mathbf{H}(t)$ — транспонированная матрица наблюдений (верхний индекс T обозначает операцию транспонирования); $\mathbf{Z}(t)$ — вектор измеряемых параметров; $\mathbf{R}(t)$ — матрица ошибок измерений; $\mathbf{I}$ — единичная матрица (*англ.* Identity matrix).

В контексте управления продукционным процессом озимой пшеницы данный алгоритм решает фундаментальную задачу: как получить наилучшее оценивание текущего состояния агроценоза (биомасса, индекс листовой поверхности, содержание хлорофилла, влажность почвы и др.), располагая, с одной стороны, несовершенной математической моделью динамики развития культуры, а с другой — зашумлёнными и неполными данными дистанционного зондирования, поступающими с различных сенсорных платформ.

Принцип действия фильтра Калмана базируется на двух чередующихся этапах — предсказании и коррекции, что обеспечивает его рекуррентную природу и вычислительную эффективность. На этапе предсказания алгоритм использует априорную информацию о динамике системы, заложенную в модели роста, чтобы экстраполировать вектор состояния на следующий момент времени. Полное математическое описание этой динамики даётся уравнением $\mathbf{X}(t) = \mathbf{A}\cdot\mathbf{X}(t-1) + \mathbf{B}\cdot u(t) + w(t)$, где матрица $\mathbf{A}$ описывает естественную эволюцию параметров (например, закономерности накопления биомассы озимой пшеницы в зависимости от фенологической фазы), матрица $\mathbf{B}$ отражает влияние управляющих воздействий $u(t)$ (внесение удобрений, орошение), а $w(t)$ символизирует шум процесса, т. е. ту неопределённость, которая присуща любой математической модели и обусловлена неполнотой наших знаний о сложных биологических и почвенных процессах. Однако вычислить конкретную реализацию шума $w(t)$ в будущий момент времени невозможно, поэтому на практике алгоритм принимает его равным нулю и формирует предварительный прогноз (априорную оценку) по формуле $\mathbf{X}^*(t) = \mathbf{A}\cdot\mathbf{X}(t-1) + \mathbf{B}\cdot u(t)$. Именно эта величина $\mathbf{X}^*(t)$ и представляет собой прогнозируемое состояние системы в момент t. Одновременно с прогнозом состояния фильтр вычисляет априорную ковариационную матрицу ошибки $\mathbf{P}(t)$, количественно выражающую степень доверия к полученному прогнозу, — с учётом того, что опущенный шум $w(t)$ продолжает вносить свой вклад в неопределённость. Чем меньше элементы этой матрицы, тем выше уверенность в том, что модель адекватно описывает реальные процессы, происходящие в посевах озимой пшеницы.

На этапе коррекции в алгоритм поступают новые измерительные данные $\mathbf{Z}(t)$, полученные в результате дистанционного зондирования, — это могут быть коэффициенты спектральной яркости, зарегистрированные мультиспектральной камерой беспилотного летательного аппарата; вегетационные индексы, рассчитанные по спутниковым снимкам Sentinel-2; или же эталонные гиперспектральные измерения, выполненные в ключевые фенологические фазы развития культуры. Ключевым элементом этого этапа выступает вычисление так называемой инновации или невязки — разности между фактически измеренными значениями и теми значениями, которые ожидалось получить согласно предсказанию модели, что формально записывается как $[\mathbf{Z}(t) - \mathbf{H}(t)\mathbf{X}^*(t-1)]$, где матрица наблюдений $\mathbf{H}(t)$ устанавливает связь между вектором состояния и вектором измерений, т. е. определяет, какие именно комбинации параметров состояния доступны для непосредственного наблюдения с помощью имеющихся сенсоров.

Центральную роль в алгоритме играет коэффициент усиления Калмана $\mathbf{K}(t)$, вычисляемый по формуле $\mathbf{K}(t) = \mathbf{P}(t-1)\mathbf{H}^T(t)[\mathbf{H}(t)\mathbf{P}(t-1)\mathbf{H}^T(t) + \mathbf{R}(t)]^{-1}$, где $\mathbf{R}(t)$ представляет собой ковариационную матрицу ошибок измерений, характеризующую точность используемых средств дистанционного зондирования. Физический смысл коэффициента усиления заключается в том, что он определяет оптимальный баланс между доверием к прогнозу модели и доверием к поступающим измерениям — в ситуации, когда измерительная аппаратура обладает высокой точностью (малые значения элементов матрицы $\mathbf{R}(t)$), коэффициент усиления принимает большие значения и фильтр существенно корректирует прогноз в сторону наблюдений, тогда как в случае значительной зашумлённости данных или временных пропусков в спутниковой съёмке, обусловленных, например, облачностью, доверие к измерениям падает и алгоритм в большей степени опирается на модельные представления о динамике развития культуры. Финальная оценка состояния $\mathbf{X}(t)$ формируется как взвешенная сумма прогноза и инновации $\mathbf{X}(t) = \mathbf{X}^*(t-1) + \mathbf{K}(t)[\mathbf{Z}(t) - \mathbf{H}(t)\mathbf{X}^*(t-1)]$, после чего обновляется и ковариационная матрица ошибки $\mathbf{P}(t)$ в соответствии с выражением $\mathbf{P}(t) = [\mathbf{I} - \mathbf{K}(t)\mathbf{H}(t)]\mathbf{P}(t-1)$, что подготавливает фильтр к следующему циклу обработки данных.

Расширение вектора состояния как базовое усовершенствование для агромониторинга

В контексте рассматриваемой интегрированной системы управления продукционным процессом озимой пшеницы классическая постановка задачи фильтрации сталкивается с принципиальным ограничением: вектор состояния $\mathbf{X}(t)$, ограниченный только параметрами самой культуры (биомассой надземной части, индексом листовой поверхности, содержанием пигментов), не позволяет в полной мере учесть влияние почвенных условий, которые выступают ключевым фактором, лимитирующим продуктивность. Именно это обстоятельство послужило основанием для предложенного в работе Михайленко и В. Н. Тимошина (2025) перехода к оцениванию расширенного вектора $(\mathbf{X}, \mathbf{V})$, где $\mathbf{V}$ представляет собой вектор параметров состояния почвенной среды, включающий такие значимые характеристики, как влажность различных почвенных горизонтов, содержание доступных форм азота, фосфора и калия, гранулометрический состав и содержание органического вещества.

Принципиальное преимущество такого подхода заключается в возможности одновременной ассимиляции данных, характеризующих как состояние самой культуры, так и среду её произрастания, что открывает путь к построению более адекватных моделей продукционного процесса, учитывающих двунаправленные связи в системе почва–растение. С математической точки зрения переход к расширенному вектору состояния требует соответствующего увеличения размерности ковариационных матриц $\mathbf{P}(t)$ и $\mathbf{R}(t)$, однако использование современных вычислительных средств делает это увеличение вычислительной сложности некритичным, особенно в сравнении с тем выигрышем в точности и быстродействии оценивания, который достигается за счёт совместной обработки разнородных данных.

Практическая реализация расширенного подхода предполагает, что матрица наблюдений $\mathbf{H}(t)$ должна быть соответствующим образом модифицирована для отражения связей между

измеряемыми величинами и компонентами расширенного вектора состояния. Особый интерес в этом контексте представляют возможности гиперспектральных измерений, которые при соответствующей калибровке способны предоставлять информацию не только о состоянии фотосинтетического аппарата растений (содержание хлорофилла, каротиноидов, антоцианов), но и о характеристиках почвенной поверхности, включая содержание органического углерода, влажность и даже гранулометрический состав в поверхностном слое. Таким образом, гиперспектральные данные, выступая в роли эталонных измерений высокой точности, позволяют осуществлять калибровку и валидацию как компонентов вектора **X**, так и компонентов вектора **V**, что существенно повышает общую надёжность системы оценивания.

Ансамблевый фильтр Калмана для работы с нелинейными моделями роста

Классическая формулировка фильтра Калмана, представленная уравнениями (1)–(3), предполагает линейность модели динамики системы и гауссовский характер распределения ошибок — предположения, которые далеко не всегда выполняются в задачах агромониторинга. Модели роста сельскохозяйственных культур, такие как WOFOST, DSSAT или APSIM, описывают сложные нелинейные процессы, включающие фенологические стадии развития, влияние температурных стрессов, водного дефицита и минерального питания, причём характер этих нелинейностей может существенно меняться в зависимости от фазы вегетации и погодных условий конкретного года. В этих условиях применение классического фильтра Калмана может приводить к существенным ошибкам оценивания или даже к расходимости вычислительного процесса.

Альтернативой, получившей широкое распространение в задачах ассимиляции данных дистанционного зондирования в агрометеорологические модели, выступает ансамблевый фильтр Калмана EnKF (*англ.* Ensemble Kalman Filter), принципиальное отличие которого заключается в том, что вместо одной детерминированной оценки вектора состояния формируется ансамбль из множества реализаций, каждая из которых эволюционирует согласно нелинейной модели, но с различными начальными условиями и разными реализациями шумов процесса. Ковариационные матрицы, необходимые для вычисления коэффициента усиления, при этом оцениваются непосредственно по ансамблю, что позволяет корректно учитывать нелинейный характер динамики без необходимости линеаризации уравнений модели. В контексте управления продукционным процессом озимой пшеницы ансамблевый подход предоставляет дополнительное важное преимущество: распределение ансамбля в каждый момент времени даёт не только точечную оценку состояния, но и полную картину неопределённости прогноза, что критически важно для принятия решений в условиях риска, связанных с изменчивостью погодных условий и возможными потерями урожая.

Адаптивные модификации фильтра для работы с переменным качеством данных

Существенным ограничением классической формулировки фильтра Калмана применительно к задачам спутникового агромониторинга является априорное задание ковариационных матриц шумов процесса $\mathbf{Q}(t)$ и измерений $\mathbf{R}(t)$, которые в реальных условиях не остаются постоянными, а существенно изменяются во времени под влиянием множества факторов. Точность спутниковых измерений может варьировать в зависимости от угла съёмки, состояния атмосферы, наличия облачности и даже от типа подстилающей поверхности, например, ошибки определения вегетационных индексов возрастают в условиях разреженного растительного покрова ранней весной или в период созревания, когда происходит пожелтение и усыхание листового аппарата. Аналогичным образом меняется и точность модельных представлений: модель может достаточно точно описывать рост в оптимальных условиях, но существенно ошибаться в экстремальные годы с засухами или возвратными заморозками.

Адаптивные фильтры Калмана предлагают решение этой проблемы посредством динамической оценки ковариационных матриц непосредственно в процессе фильтрации на основе анализа инновационной последовательности. Идея заключается в том, что если модель адекватна и матрицы **Q** и **R** заданы корректно, то инновации (невязки между прогнозом и измерениями) должны представлять собой последовательность некоррелированных случайных величин с нулевым средним и известной ковариацией. Отклонения от этого поведения (например, появление систематических смещений или автокорреляции) служат индикатором того, что априорные предположения о точности модели или измерений нуждаются в корректировке. В агромониторинге адаптивный подход приобретает особую значимость при интеграции данных различных сенсоров: когда поступает высокоточное гиперспектральное измерение, фильтр может автоматически снизить доверие к менее точным спутниковым данным, и наоборот, в периоды между гиперспектральными съёмками опираться преимущественно на спутниковые временные ряды, но с учётом их переменной точности, зависящей от условий съёмки.

Пространственно-временная фильтрация и учёт неоднородности полей

Классическая постановка задачи фильтрации предполагает обработку временных рядов для каждой пространственной ячейки (пикселя) независимо, что игнорирует фундаментальное свойство сельскохозяйственных полей — их пространственную коррелированность, обусловленную как природными факторами (почвенными разностями, микрорельефом), так и технологическими (неравномерностью внесения удобрений, особенностями полива). Пространственно-временной фильтр Калмана (*англ.* Spatio-Temporal Kalman Filter) учитывает эту корреляцию включением в модель не только временной динамики каждого пикселя, но и связей между соседними элементами пространственной сетки.

Математически это достигается модификацией матрицы перехода **A** таким образом, чтобы она включала не только диагональные элементы, отвечающие за эволюцию каждого пикселя во времени, но и недиагональные блоки, описывающие пространственные взаимодействия. В контексте точного земледелия такой подход открывает новые возможности: фильтр может использовать высокоточные гиперспектральные измерения, выполненные в ограниченном числе репрезентативных точек, для коррекции оценок состояния на всей площади поля, опираясь на предположение о пространственной ковариации, которая может быть оценена по данным спутниковой съёмки высокого разрешения. Особенно важно это при работе с данными Sentinel-2, имеющими пространственное разрешение 10–20 м, которое часто оказывается недостаточным для разрешения внутрипольной неоднородности, характерной для систем точного земледелия.

Гибридные архитектуры: интеграция фильтра Калмана с глубокими нейронными сетями

Дальнейшим развитием методологии фильтрации в задачах агромониторинга выступает создание гибридных архитектур, объединяющих достоинства фильтра Калмана (строгую вероятностную основу, учёт неопределённости, рекуррентную природу) и глубоких нейронных сетей (способность аппроксимировать сложные нелинейные зависимости, автоматическое выделение признаков из больших массивов данных). В таких гибридных схемах нейросетевые компоненты могут выполнять различные функции: аппроксимировать нелинейную динамику системы, которую сложно описать аналитически (заменяя или дополняя матрицу **A**); моделировать связь между состоянием системы и измерениями (заменяя матрицу наблюдений **H**); или даже непосредственно предсказывать ковариационные матрицы шумов, обеспечивая адаптивность фильтра.

Особый интерес представляет интеграция фильтра Калмана с сетями долгой краткосрочной памяти LSTM, которые продемонстрировали высокую эффективность в моделировании временных рядов вегетационных индексов и прогнозировании урожайности. В такой гибридной архитектуре LSTM может использоваться для формирования априорного прогноза состояния, учитывающего долговременные зависимости и фенологические закономерности, в то время как фильтр Калмана осуществляет ассимиляцию текущих измерений и поддержание согласованной оценки неопределённости. При этом методы интерпретируемого искусственного интеллекта, такие как SHAP-анализ, позволяют объяснять решения фильтра, отвечая на принципиально важные для агронома вопросы: почему именно сейчас и именно в этой части поля потребовалась коррекция прогноза и какие именно измерения (гиперспектральные, спутниковые, метеорологические) внесли наибольший вклад в уточнение оценки.

Перспективы развития фильтрационных методов в контексте гиперспектральной калибровки

Интеграция гиперспектральных измерений в качестве эталонных данных открывает новые горизонты для совершенствования фильтрационных алгоритмов, позволяя реализовать многоуровневую схему калибровки и валидации. На нижнем уровне гиперспектральные данные, характеризующиеся высокой спектральной детализацией, но ограниченным пространственным охватом, используются для калибровки более простых мультиспектральных индексов, получаемых со спутниковых платформ, например, построением регрессионных зависимостей между узкими гиперспектральными полосами и широкими каналами Sentinel-2, что позволяет скорректировать систематические ошибки спутниковых измерений и привести их к единому эталонному базису.

На среднем уровне откалиброванные таким образом спутниковые данные ассимилируются в фильтр Калмана, работающий на уровне отдельных полей или даже пикселей, что обеспечивает пространственно детализированную оценку состояния посевов с временным разрешением, определяемым периодичностью спутниковой съёмки. Наконец, на верхнем уровне результаты фильтрации могут использоваться для калибровки параметров самих моделей роста, реализуя так называемую обратную связь: если фильтр систематически корректирует прогноз в определённом направлении, это служит индикатором того, что модельные параметры (например, коэффициенты использования фотосинтетически активной радиации или эффективность применения влаги) нуждаются в уточнении для данных конкретных условий.

Перспективным направлением выступает также разработка фильтров, учитывающих специфику различных типов сельскохозяйственных культур и региональных условий возделывания. Как показано в обзоре (Radočaj et al., 2026), модели, обученные на данных одного региона, часто демонстрируют низкую точность при переносе на другие условия, что связано с различиями в сортах, агротехнике, почвенно-климатических условиях. Адаптивные фильтры, способные перенастраиваться в процессе работы на основе поступающих измерений (включая гиперспектральные эталоны), представляют собой один из наиболее перспективных путей решения проблемы обобщаемости моделей и создания универсальных систем мониторинга, сохраняющих работоспособность в широком диапазоне условий без необходимости трудоёмкой повторной калибровки.

Таким образом, фильтр Калмана в его современных модификациях выступает не просто как вычислительный алгоритм, но как концептуальная основа для построения интегрированных систем управления продукционным процессом, обеспечивающая оптимальное сочетание теоретических знаний о физиологии растений, данных дистанционного зондирования различного пространственного и спектрального разрешения и эталонных гиперспектральных измерений. Предложенное в работе расширение вектора состояния до включения почвенных параметров представляет собой важный шаг в этом направлении, открывающий путь к созданию действительно комплексных систем поддержки принятия решений в точном земледелии, способных учитывать всю сложность и многообразие факторов, определяющих формирование урожая озимой пшеницы.

Заключение

1. Рассмотрена и развита концепция интегрированной системы управления продукционным процессом озимой пшеницы, основанная на синтезе данных дистанционного зондирования, климатических и почвенных показателей, а также современных алгоритмах машинного и глубокого обучения. Система позволит осуществлять точный мониторинг состояния посевов и прогнозировать урожайность с высокой точностью (R^2 до 0,79) на региональном уровне. Модели глубокого обучения (IGWO-CNN, LSTM) и ансамблевые методы (RF) демонстрируют наивысшую эффективность по сравнению с традиционными подходами. Ключевыми предикторами урожайности являются вегетационные индексы (GNDVI, EVI), флуоресценция хлорофилла SIF и водно-климатические факторы.

2. Следует подчеркнуть, что календарные сроки оптимального раннего прогноза урожайности озимой пшеницы по данным ДЗЗ существенно варьируют в зависимости от агроклиматической зоны. Если для условий ключевых зон возделывания озимой пшеницы Китая оптимум приходится на апрель (Fu et al., 2025), то для основных зернопроизводящих регионов Российской Федерации он может смещаться на май – июнь (Южный федеральный округ, Центральное Черноземье, Поволжье), а для Северо-Западного региона (Ленинградская область), где фаза цветения наступает только в конце июня – начале июля, — на июль. Предложенная в настоящей работе концепция адаптивного оценивания на основе фильтра Калмана с расширенным вектором состояния (**X**, **V**) и калибровки по локальным гиперспектральным эталонам позволит настраивать оптимальное временное окно прогнозирования под конкретные региональные условия, что является ключевым преимуществом при масштабировании на различные агроклиматические зоны.

3. Впервые в концепцию интегрированной системы управления включён многоперспективный анализ для интеграции гиперспектральных данных в качестве эталонных. На основе систематического анализа современных публикаций определены наиболее эффективные подходы:

- на уровне сенсоров — мультисенсорная интеграция данных Sentinel-2 (красные краевые каналы) и Sentinel-1 (SAR);
- на уровне методологий — интерпретируемое машинное обучение (SHAP-анализ) и архитектуры LSTM для учёта временной динамики;
- на уровне предикторов — гибридный фенологический подход, привязывающий гиперспектральные измерения к фазам развития, определённым по спутниковым данным.

Методологическая концепция (гиперспектральная калибровка, интерпретируемое машинное обучение, адаптивная фильтрация), использующая озимую пшеницу в качестве модельной культуры, принципиально масштабируема. Она позволяет не только решать общие для спутникового агромониторинга проблемы — насыщение вегетационных индексов и ограниченную обобщаемость моделей, — но и достигать повышенной точности для специальных (овощных, плодовых и технических) культур за счёт отдельной калибровки их специфичных спектральных сигнатур и параметров архитектоники полога.

4. Ключевым методологическим результатом работы выступает обоснование и развитие фильтрационных методов оценивания состояния агроценоза, адаптированных к специфике задач агромониторинга. Показано, что фильтр Калмана выполняет функцию интеллектуального моста между тремя информационными потоками: физиологически обоснованными моделями роста (WOFOST), регулярными, но менее точными спутниковыми данными (Sentinel-2, Sentinel-1) и редкими, но эталонными гиперспектральными измерениями. Предложенное усовершенствование алгоритма оценивания на основе фильтра Калмана для расширенного вектора (**X**, **V**), включающего параметры биомассы и почвенной среды, позволяет одновременно ассимилировать данные о состоянии культуры и среде её произрастания, что повышает быстродействие и точность управления.

Дальнейшее развитие фильтрационных методов в контексте интегрированной системы может осуществляться по следующим направлениям:

- применение ансамблевого фильтра Калмана EnKF для корректной работы с нелинейными моделями роста и получения полных распределений неопределённости прогноза;
- использование адаптивных модификаций, автоматически оценивающих переменную точность спутниковых данных в зависимости от условий съёмки (облачность, угол, атмосферные искажения);
- разработка пространственно-временных фильтров, учитывающих пространственную корреляцию между пикселями и позволяющих масштабировать точечные гиперспектральные эталоны на всю площадь поля;
- создание гибридных архитектур, объединяющих фильтр Калмана с LSTM-сетями, где нейросетевые компоненты моделируют нелинейную динамику, а фильтр обеспечивает вероятностно обоснованную ассимиляцию данных и интерпретируемость результатов с помощью SHAP-анализа.

5. Практическая значимость системы заключается в её способности обеспечивать информационную поддержку решений в рамках точного земледелия, включая оптимизацию применения ресурсов, управление рисками и повышение общей устойчивости агропроизводства. Фильтрационные методы в этом контексте выступают не просто как вычислительный инструмент, но как концептуальная основа для создания самообучающихся систем, способных адаптироваться к изменяющимся условиям и накапливать знания о региональных особенностях продукционного процесса озимой пшеницы. Дальнейшее развитие системы связано с интеграцией новых источников данных, совместным использованием процессных и статистических моделей, а также повышением интерпретируемости прогнозов для конечных пользователей — агрономов и специалистов сельскохозяйственных предприятий.

Литература

1. *Галицкий В. В.*, *Комаров А. С.* О моделировании роста растений // Изв. Акад. наук СССР. Сер. биол. 1979. № 5. С. 714–723.
2. *Михайленко И. М.* Управление системами точного земледелия. СПб.: Изд-во Санкт-Петербургского гос. ун-та, 2005. 234 с.
3. *Михайленко И. М.*, *Тимошин В. Н.* Оценивание параметров состояния биомассы корнеплодных культур по данным дистанционного зондирования Земли // Современные проблемы дистанционного зондирования Земли из космоса. 2025. Т. 22. № 3. С. 161–170. DOI: 10.21046/2070-7401-2025-22-3-161-170.
4. *Новикова Т. П.*, *Евдокимова С. А.*, *Новиков А. И.* Разработка и исследование базовой модели PERT для планирования работ по проекту // Моделирование систем и процессов. 2021. Т. 14. № 4. С. 75–81. DOI: 10.12737/2219-0767-2021-14-4-75-81.
5. *Ali A.*, *Hussain T.*, *Tantashutikun N. et al.* Application of smart techniques, internet of things and data mining for resource use efficient and sustainable crop production // Agriculture. 2023. V. 13. No. 2. Article 397. DOI: 10.3390/agriculture13020397.
6. *Bernardes R. C.*, *De Medeiros A.*, *da Silva L. et al.* Deep-learning approach for *Fusarium* head blight detection in wheat seeds using low-cost imaging technology // Agriculture. 2022. V. 12. No. 11. Article 1801. DOI: 10.3390/agriculture12111801.
7. *Bolton D. K.*, *Friedl M. A.* Forecasting crop yield using remotely sensed vegetation indices and crop phenology metrics // Agricultural and Forest Meteorology. 2013. V. 173. P. 74–84. DOI: 10.1016/j.agrformet.2013.01.007.
8. *Cai Y.*, *Guan K.*, *Lobell D. et al.* Integrating satellite and climate data to predict wheat yield in Australia using machine learning approaches // Agricultural and Forest Meteorology. 2019. V. 274. P. 144–159. DOI: 10.1016/j.agrformet.2019.03.010.
9. *Chahbi-Bellakanji A.*, *Shil E.*, *Khlif M. et al.* Early cereal yield prediction using machine learning and Sentinel-1 and Sentinel-2 satellite data // European J. Remote Sensing. 2025. V. 58. No. 1. Article 2558614. DOI: 10.1080/22797254.2025.2558614.
10. *Chen P.*, *Li Y.*, *Liu X. et al.* Improving yield prediction based on spatio-temporal deep learning approaches for winter wheat: A case study in Jiangsu Province, China // Computers and Electronics in Agriculture. 2023. V. 213. Article 108201. DOI: 10.1016/j.compag.2023.108201.

11. *Cui X.*, *Guan Z.*, *Farnsworth D.* Advancing specialty crop management: A review of recent developments in robotics, remote sensing, and machine learning systems // Intern. Food and Agribusiness Management Review. 2025. V. 28. No. 2. P. 423–440. DOI: 10.22434/IFAMR1104.
12. *Delécolle R.*, *Maas S.J.*, *Guérif M.*, *Baret F.* Remote sensing and crop production models: present trends // ISPRS J. Photogrammetry and Remote Sensing. 1992. V. 47. P. 145–161. DOI: 10.1016/0924-2716(92)90030-D.
13. *Dhaliwal D.S.*, *Williams M.M.*, *II.* Sweet corn yield prediction using machine learning models and field-level data // Precision Agriculture. 2024. V. 25. P. 51–64. DOI: 10.1007/s11119-023-10057-1.
14. *Elbeltagi A.*, *Srivastava A.*, *Cao X. et al.* An interpretable machine learning approach based on SHAP, Sobol and LIME values for precise estimation of daily soybean crop coefficients // Scientific Reports. 2025. V. 15. Article 36594. DOI: 10.1038/s41598-025-20386-y.
15. *Filippi P.*, *Han S.Y.*, *Bishop T.F.A.* On crop yield modelling, predicting, and forecasting and addressing the common issues in published studies // Precision Agriculture. 2024. V. 26. Article 8. DOI: 10.1007/s11119-024-10212-2.
16. *Fu H.*, *Lu J.*, *Li J. et al.* Winter wheat yield prediction using satellite remote sensing data and deep learning models // Agronomy. 2025. V. 15. No. 1. Article 205. DOI: 10.3390/agronomy15010205.
17. *Gavasso-Rita Y.L.*, *Papalexiou S.M.*, *Li Y. et al.* Crop models and their use in assessing crop production and food security: A review // Food and Energy Security. 2024. V. 13. No. 1. Article e503. DOI: 10.1002/fes3.503.
18. *Guanter L.*, *Zhang Y.*, *Jung M. et al.* Global and time-resolved monitoring of crop photosynthesis with chlorophyll fluorescence // PNAS. 2014. V. 111. No. 14. P. E1327–E1333. DOI: 10.1073/pnas.1320008111.
19. *Guérif M.*, *Duke C.L.* Adjustment procedures of a crop model to the site-specific characteristics of soil and crop using remote sensing data assimilation // Agriculture, Ecosystems and Environment. 2000. V. 81. P. 57–69. DOI: 10.1016/S0167-8809(00)00168-7.
20. *Guo J.*, *Lu W.*, *Zhang G. et al.* Incorporating remote sensing data in crop model to monitor crop growth and predict yield in regional area // Proc. SPIE. 2006. V. 6411. Article 64111C. DOI: 10.1117/12.692756.
21. *Han J.*, *Zhang Z.*, *Cao J. et al.* Prediction of winter wheat yield based on multi-source data and machine learning in China // Remote Sensing. 2020. V. 12. No. 2. Article 236. DOI: 10.3390/rs12020236.
22. *Huete A.*, *Didan K.*, *Miura T. et al.* Overview of the radiometric and biophysical performance of the MODIS vegetation indices // Remote Sensing of Environment. 2002. V. 83. P. 195–213. DOI: 10.1016/S0034-4257(02)00096-2.
23. *Jennewein J.S.*, *Lamb B.T.*, *Hively W.D. et al.* Integration of satellite-based optical and synthetic aperture radar imagery to estimate winter cover crop performance in cereal grasses // Remote Sensing. 2022. V. 14. No. 9. Article 2077. DOI: 10.3390/rs14092077.
24. *Jiang J.*, *Shu Y.*, *Wang J.*, *Long M.* Transferability in deep learning: A survey // https://arxiv.org/. arXiv:2201.05867. 2022. 64 p. https://arxiv.org/abs/2201.05867.
25. *Jin X.*, *Li Z.*, *Feng H. et al.* Estimation of maize yield by assimilating biomass and canopy cover derived from hyperspectral data into the AquaCrop model // Agricultural Water Management. 2020. V. 227. Article 105846. DOI: 10.1016/j.agwat.2019.105846.
26. *Jones J.W.*, *Hoogenboom G.*, *Porter C.H. et al.* The DSSAT cropping system model // European J. Agronomy. 2003. V. 18. P. 235–265. DOI: 10.1016/S1161-0301(02)00107-7.
27. *Khaki S.*, *Wang L.* Crop yield prediction using deep neural networks // Frontiers in Plant Science. 2019. V. 10. Article 621. 10 p. DOI: 10.3389/fpls.2019.00621.
28. *Lee W.S.*, *Alchanatis V.*, *Yang C. et al.* Sensing technologies for precision specialty crop production // Computers and Electronics in Agriculture. 2010. V. 74. No. 1. P. 2–33. DOI: 10.1016/j.compag.2010.08.005.
29. *Liu L.*, *Cao R.*, *Chen J. et al.* Detecting crop phenology from vegetation index time-series data by improved shape model fitting in each phenological stage // Remote Sensing of Environment. 2022. V. 277. Article 113060. DOI: 10.1016/j.rse.2022.113060.
30. *Liu F.*, *Jiang X.*, *Wu Z. et al.* Attention mechanism-combined LSTM for grain yield prediction in China using multi-source satellite imagery // Sustainability. 2023. V. 15. No. 12. Article 9210. DOI: 10.3390/su15129210.
31. *Liu X.*, *Yang H.*, *Ata-Ul-Karim S.T. et al.* Screening drought-resistant and water-saving winter wheat varieties by predicting yields with multi-source UAV remote sensing data // Computers and Electronics in Agriculture. 2025. V. 234. Article 110213. DOI: 10.1016/j.compag.2025.110213.
32. *Lobell D.B.*, *Burke M.B.* On the use of statistical models to predict crop yield responses to climate change // Agricultural and Forest Meteorology. 2010. V. 150. P. 1443–1452. DOI: 10.1016/j.agrformet.2010.07.008.
33. *Lu B.*, *Dao P.D.*, *Liu J. et al.* Recent advances of hyperspectral imaging technology and applications in agriculture // Remote Sensing. 2020. V. 12. No. 16. Article 2659. DOI: 10.3390/rs12162659.
34. *Lyu Y.*, *Wang P.*, *Bai X. et al.* Machine learning techniques and interpretability for maize yield estimation using time-series images of MODIS and multi-source data // Computers and Electronics in Agriculture. 2024. V. 222. Article 109063. DOI: 10.1016/j.compag.2024.109063.

35. *Ma X.*, *Zhu X.*, *Xie Q. et al.* Monitoring nature's calendar from space: Emerging topics in land surface phenology and associated opportunities for science applications // Global Change Biology. 2022. V. 28. No. 24. P. 7186–7204. DOI: 10.1111/gcb.16436.
36. *Ma Y.*, *Liang S.-Z.*, *Myers D. B. et al.* Subfield-level crop yield mapping without ground truth data: A scale transfer framework // Remote Sensing of Environment. 2024. V. 315. Article 114427. DOI: 10.1016/j.rse.2024.114427.
37. *Manin A. A.*, *Sokolov S. V.*, *Novikov A. I. et al.* Kalman filter adaptation to disturbances of the observer's parameters // Inventions. 2021. V. 6. No. 4. Article 80. DOI: 10.3390/inventions6040080.
38. *Manin A. A.*, *Sukhanov A. V.*, *Sokolov S. V. et al.* Kalman filter adaptive to constant perturbations of the observable object parameters // Proc. 5th Intern. Scientific Conf. "Intelligent Information Technologies for Industry" (IITI'21). Lecture Notes in Networks and Systems. 2022. V. 330. P. 527–538. DOI: 10.1007/978-3-030-87178-9_52.
39. *Marais Sicre C.*, *Fieuzal R.*, *Baup F.* Contribution of multispectral (optical and radar) satellite images to the classification of agricultural surfaces // Intern. J. Applied Earth Observation and Geoinformation. 2020. V. 84. Article 101972. DOI: 10.1016/j.jag.2019.101972.
40. *Muruganantham P.*, *Wibowo S.*, *Grandhi S. et al.* A systematic literature review on crop yield prediction with deep learning and remote sensing // Remote Sensing. 2022. V. 14. No. 9. Article 1990. DOI: 10.3390/rs14091990.
41. *Novikov A. I.*, *Vovchenko N. G.*, *Sokolov S. V. et al.* Improving the quality of automated VIS-grading of Scots pine seeds using fuzzy logic algorithm // IOP Conf. Ser.: Earth and Environmental Science. 2021. V. 875. Article 012032. DOI: 10.1088/1755-1315/875/1/012032.
42. *Novikova T. P.*, *Tylek P.*, *Petrishchev E. P.*, *Novikov A. I.* Higher plant seed container germination success predicted by smart farming optical RGB approach // Scientific Reports. 2026. V. 16. Article 13021. DOI: 10.1038/s41598-026-42258-9.
43. *Pei J.*, *Tan S.*, *Zou Y. et al.* The role of phenology in crop yield prediction: Comparison of ground-based phenology and remotely sensed phenology // Agricultural and Forest Meteorology. 2025. V. 361. Article 110340. DOI: 10.1016/j.agrformet.2024.110340.
44. *Peng B.*, *Guan K.*, *Tang J. et al.* Towards a multiscale crop modelling framework for climate change adaptation assessment // Nature Plants. 2020. V. 6. No. 4. P. 338–348. DOI: 10.1038/s41477-020-0625-3.
45. *Radočaj D.*, *Plaščak I.*, *Jurišić M.* (2025a) Fusion of Sentinel-2 phenology metrics and saturation-resistant vegetation indices for improved correlation with maize yield maps // Agronomy. 2025. V. 15. No. 6. Article 1329. DOI: 10.3390/agronomy15061329.
46. *Radočaj D.*, *Plaščak I.*, *Jurišić M.* (2025b) A comparative assessment of regular and spatial cross-validation in subfield machine learning prediction of maize yield from Sentinel-2 phenology // Eng. 2025. V. 6. No. 10. Article 270. DOI: 10.3390/eng6100270.
47. *Radočaj D.*, *Jurišić M.*, *Plaščak I.*, *Galić L.* Satellite remote sensing for crop yield prediction: A review // Agriculture. 2026. V. 16. No. 4. Article 417. DOI: 10.3390/agriculture16040417.
48. *Segarra J.*, *Buchaillot M. L.*, *Araus J. L.*, *Kefauver S. C.* Remote sensing for precision agriculture: Sentinel-2 improved features and applications // Agronomy. 2020. V. 10. No. 5. Article 641. DOI: 10.3390/agronomy10050641.
49. *Shahhosseini M.*, *Hu G.*, *Huber I.*, *Archontoulis S. V.* Coupling machine learning and crop modeling improves crop yield prediction in the US Corn Belt // Scientific Reports. 2021. V. 11. No. 1. Article 1606. DOI: 10.1038/s41598-020-80820-1.
50. *Sokolov S. V.*, *Novikov A. I.* Adaptive estimation of UVs navigation parameters by irregular inertial-satellite measurements // Intern. J. Intelligent Unmanned Systems. 2021. V. 9. No. 4. P. 274–282. DOI: 10.1108/IJIUS-10-2019-0056.
51. *Sokolov S.*, *Novikov A.*, *Polyakova M.* Adaptive stochastic filtration based on the estimation of the covariance matrix of measurement noises using irregular accurate observations // Inventions. 2021. V. 6. No. 1. Article 10. DOI: 10.3390/inventions6010010.
52. *Sokolov S.*, *Khatlamadzhiyan A.*, *Novikov A. et al.* Terminal stochastic filtering of nonlinear dynamic processes: The case of invariant immersion // Proc. 6th Intern. Scientific Conf. "Intelligent Information Technologies for Industry" (IITI'22). Lecture Notes in Networks and Systems. 2023. V. 566. P. 369–379. DOI: 10.1007/978-3-031-19620-1_35.
53. *Trevisiol F.*, *Mandanici E.*, *Pagliarani A.*, *Bitelli G.* Evaluation of Landsat-9 interoperability with Sentinel-2 and Landsat-8 over Europe and local comparison with field surveys // ISPRS J. Photogrammetry and Remote Sensing. 2024. V. 210. P. 55–68. DOI: 10.1016/j.isprsjprs.2024.02.021.
54. *van Klompenburg T.*, *Kassahun A.*, *Catal C.* Crop yield prediction using machine learning: A systematic literature review // Computers and Electronics in Agriculture. 2020. V. 177. Article 105709. DOI: 10.1016/j.compag.2020.105709.
55. *Wang X.*, *Huang J.*, *Feng Q.*, *Yin D.* Winter wheat yield prediction at county level and uncertainty analysis in main wheat-producing regions of China with deep learning approaches // Remote Sensing. 2020. V. 12. No. 11. Article 1744. DOI: 10.3390/rs12111744.

56. *Zhang Z.*, *Yang J.*, *Sun H. et al.* MCVI-SANet: A lightweight semi-supervised model for LAI and SPAD estimation of winter wheat under vegetation index saturation // https://arxiv.org/. arXiv:2512.18344. 2025. 33 p. https://arxiv.org/abs/2512.18344.
57. *Zhou W.*, *Liu Y.*, *Ata-Ul-Karim S. T. et al.* Integrating climate and satellite remote sensing data for predicting county-level wheat yield in China using machine learning methods // Intern. J. Applied Earth Observation and Geoinformation. 2022. V. 111. Article 102861. DOI: 10.1016/j.jag.2022.102861.

Development of the precision farming concept for winter wheat crops: from multispectral satellite data to hyperspectral standards

A. I. Novikov [1], O. I. Sokolova [2], T. P. Novikova [3]

[1] *Agrophysical Research Institute*, *Saint Petersburg 195220*, *Russia*
E-mail: nvatdo@gmail.com
[2] *Rostov State Transport University*, *Rostov-on-Don 344038*, *Russia*
[3] *Saint Petersburg State Forest Technical University*, *Saint Petersburg 194021*, *Russia*
E-mail: novikova_tp.vglta@mail.ru

Improving the efficiency of managing the production process of winter wheat is a key task for ensuring food security and sustainable agricultural development. The article analyzes and develops the concept of an integrated management system combining Earth remote sensing data, climatic indicators, soil characteristics, flexible algorithms for estimating state parameters, and advanced machine learning methods for monitoring the growth and predicting the yield of winter wheat. On the basis of analysis of modern research, including IGWO-CNN (Improved Gray Wolf Optimization — Convolutional Neural Network), LSTM (Long Short-Term Memory), RF (Random Forest), SVM (Support Vector Machine), WOFOST (WOrld FOod STudies) and other models, an integrated approach is considered that allows for accurate and timely yield forecasting at the regional level. Special attention is paid to the problem of integrating hyperspectral data as a reference for calibration and verification of satellite models. A multi-perspective analysis of the effectiveness of various sensors and methods is presented, including analysis at the sensor level, modeling methodologies, predictors, and problem areas, which made it possible to identify the most effective approaches for integration with hyperspectral standards. An improvement of the algorithm for estimating the state of an agrocenosis based on the Kalman filter for an extended state vector, including parameters of biomass and the soil environment, is proposed. The results show that the integration of multispectral data (especially Sentinel-2 with red-edge channels) and radar data (Sentinel-1) with hyperspectral standards and interpretable deep learning models significantly increases the reliability of forecasts and will facilitate informed decision-making in agricultural production.

Keywords: precision farming, winter wheat, remote sensing, hyperspectral data, machine learning, state estimation, production process, MODIS, LSTM, IGWO-CNN, Sentinel-2, data integration, Kalman filter

Accepted: 25.05.2026
DOI: 10.21046/2070-7401-2026-23-4-27-48

References

1. Galitsky V. V., Komarov A. S., On modeling plant growth, *Izvestiya Akademii Nauk SSSR. Ser. biologicheskaya*, 1979, No. 5, pp. 714–723 (in Russian).
2. Mikhailenko I. M., *Upravlenie sistemami tochnogo zemledeliya* (Management of precision farming systems), Saint Petersburg: Saint Petersburg University Press, 2005, 234 p. (in Russian).
3. Mikhailenko I. M., Timoshin V. N., Estimation of the parameters of the state of biomass of root crops using remote sensing data, *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2025, V. 22, No. 3, pp. 161–170 (in Russian), DOI: 10.21046/2070-7401-2025-22-3-161-170.

4. Novikova T. P., Evdokimova S. A., Novikov A. I., R&D of the pert basic model for project planning, *Modeling of systems and processes*, 2021, V. 14, No. 4, pp. 75–81 (in Russian), DOI: 10.12737/2219-0767-2021-14-4-75-81.
5. Ali A., Hussain T., Tantashutikun N. et al., Application of smart techniques, internet of things and data mining for resource use efficient and sustainable crop production, *Agriculture*, 2023, V. 13, No. 2, Article 397, DOI: 10.3390/agriculture13020397.
6. Bernardes R. C., De Medeiros A., da Silva L. et al., Deep-learning approach for *Fusarium* head blight detection in wheat seeds using low-cost imaging technology, *Agriculture*, 2022, V. 12, No. 11, Article 1801, DOI: 10.3390/agriculture12111801.
7. Bolton D. K., Friedl M. A., Forecasting crop yield using remotely sensed vegetation indices and crop phenology metrics, *Agricultural and Forest Meteorology*, 2013, V. 173, pp. 74–84, DOI: 10.1016/j.agrformet.2013.01.007.
8. Cai Y., Guan K., Lobell D. et al., Integrating satellite and climate data to predict wheat yield in Australia using machine learning approaches, *Agricultural and Forest Meteorology*, 2019, V. 274, pp. 144–159, DOI: 10.1016/j.agrformet.2019.03.010.
9. Chahbi-Bellakanji A., Shil E., Khlif M. et al., Early cereal yield prediction using machine learning and Sentinel-1 and Sentinel-2 satellite data, *European J. Remote Sensing*, 2025, V. 58, No. 1, Article 2558614, DOI: 10.1080/22797254.2025.2558614.
10. Chen P., Li Y., Liu X. et al., Improving yield prediction based on spatio-temporal deep learning approaches for winter wheat: A case study in Jiangsu Province, China, *Computers and Electronics in Agriculture*, 2023, V. 213, Article 108201, DOI: 10.1016/j.compag.2023.108201.
11. Cui X., Guan Z., Farnsworth D., Advancing specialty crop management: A review of recent developments in robotics, remote sensing, and machine learning systems, *Intern. Food and Agribusiness Management Review*, 2025, V. 28, No. 2, pp. 423–440, DOI: 10.22434/IFAMR1104.
12. Delécolle R., Maas S. J., Guérif M., Baret F., Remote sensing and crop production models: present trends, *ISPRS J. Photogrammetry and Remote Sensing*, 1992, V. 47, pp. 145–161, DOI: 10.1016/0924-2716(92)90030-D.
13. Dhaliwal D. S., Williams M. M., II, Sweet corn yield prediction using machine learning models and field-level data, *Precision Agriculture*, 2024, V. 25, pp. 51–64, DOI: 10.1007/s11119-023-10057-1.
14. Elbeltagi A., Srivastava A., Cao X. et al., An interpretable machine learning approach based on SHAP, Sobol and LIME values for precise estimation of daily soybean crop coefficients, *Scientific Reports*, 2025, V. 15, Article 36594, DOI: 10.1038/s41598-025-20386-y.
15. Filippi P., Han S. Y., Bishop T. F. A., On crop yield modelling, predicting, and forecasting and addressing the common issues in published studies, *Precision Agriculture*, 2024, V. 26, Article 8, DOI: 10.1007/s11119-024-10212-2.
16. Fu H., Lu J., Li J. et al., Winter wheat yield prediction using satellite remote sensing data and deep learning models, *Agronomy*, 2025, V. 15, No. 1, Article 205, DOI: 10.3390/agronomy15010205.
17. Gavasso-Rita Y. L., Papalexiou S. M., Li Y. et al., Crop models and their use in assessing crop production and food security: A review, *Food and Energy Security*, 2024, V. 13, No. 1, Article e503, DOI: 10.1002/fes3.503.
18. Guanter L., Zhang Y., Jung M. et al., Global and time-resolved monitoring of crop photosynthesis with chlorophyll fluorescence, *PNAS*, 2014, V. 111, No. 14, pp. E1327–E1333, DOI: 10.1073/pnas.1320008111.
19. Guérif M., Duke C. L., Adjustment procedures of a crop model to the site-specific characteristics of soil and crop using remote sensing data assimilation, *Agriculture*, *Ecosystems and Environment*, 2000, V. 81, pp. 57–69, DOI: 10.1016/S0167-8809(00)00168-7.
20. Guo J., Lu W., Zhang G. et al., Incorporating remote sensing data in crop model to monitor crop growth and predict yield in regional area, *Proc. SPIE*, 2006, V. 6411, Article 64111C, DOI: 10.1117/12.692756.
21. Han J., Zhang Z., Cao J. et al., Prediction of winter wheat yield based on multi-source data and machine learning in China, *Remote Sensing*, 2020, V. 12, No. 2, Article 236, DOI: 10.3390/rs12020236.
22. Huete A., Didan K., Miura T. et al., Overview of the radiometric and biophysical performance of the MODIS vegetation indices, *Remote Sensing of Environment*, 2002, V. 83, pp. 195–213, DOI: 10.1016/S0034-4257(02)00096-2.
23. Jennewein J. S., Lamb B. T., Hively W. D. et al., Integration of satellite-based optical and synthetic aperture radar imagery to estimate winter cover crop performance in cereal grasses, *Remote Sensing*, 2022, V. 14, No. 9, Article 2077, DOI: 10.3390/rs14092077.
24. Jiang J., Shu Y., Wang J., Long M., Transferability in deep learning: A survey, *https://arxiv.org/*, arXiv:2201.05867, 2022, 64 p., https://arxiv.org/abs/2201.05867.
25. Jin X., Li Z., Feng H. et al., Estimation of maize yield by assimilating biomass and canopy cover derived from hyperspectral data into the AquaCrop model, *Agricultural Water Management*, 2020, V. 227, Article 105846, DOI: 10.1016/j.agwat.2019.105846.
26. Jones J. W., Hoogenboom G., Porter C. H. et al., The DSSAT cropping system model, *European J. Agronomy*, 2003, V. 18, pp. 235–265, DOI: 10.1016/S1161-0301(02)00107-7.

27. Khaki S., Wang L., Crop yield prediction using deep neural networks, *Frontiers in Plant Science*, 2019, V. 10, Article 621, 10 p., DOI: 10.3389/fpls.2019.00621.
28. Lee W. S., Alchanatis V., Yang C. et al., Sensing technologies for precision specialty crop production, *Computers and Electronics in Agriculture*, 2010, V. 74, No. 1, pp. 2–33, DOI: 10.1016/j.compag.2010.08.005.
29. Liu L., Cao R., Chen J. et al., Detecting crop phenology from vegetation index time-series data by improved shape model fitting in each phenological stage, *Remote Sensing of Environment*, 2022, V. 277, Article 113060, DOI: 10.1016/j.rse.2022.113060.
30. Liu F., Jiang X., Wu Z. et al., Attention mechanism-combined LSTM for grain yield prediction in China using multi-source satellite imagery, *Sustainability*, 2023, V. 15, No. 12, Article 9210, DOI: 10.3390/su15129210.
31. Liu X., Yang H., Ata-Ul-Karim S. T. et al., Screening drought-resistant and water-saving winter wheat varieties by predicting yields with multi-source UAV remote sensing data, *Computers and Electronics in Agriculture*, 2025, V. 234, Article 110213, DOI: 10.1016/j.compag.2025.110213.
32. Lobell D. B., Burke M. B., On the use of statistical models to predict crop yield responses to climate change, *Agricultural and Forest Meteorology*, 2010, V. 150, pp. 1443–1452, DOI: 10.1016/j.agrformet.2010.07.008.
33. Lu B., Dao P. D., Liu J. et al., Recent advances of hyperspectral imaging technology and applications in agriculture, *Remote Sensing*, 2020, V. 12, No. 16, Article 2659, DOI: 10.3390/rs12162659.
34. Lyu Y., Wang P., Bai X. et al., Machine learning techniques and interpretability for maize yield estimation using time-series images of MODIS and multi-source data, *Computers and Electronics in Agriculture*, 2024, V. 222, Article 109063, DOI: 10.1016/j.compag.2024.109063.
35. Ma X., Zhu X., Xie Q. et al., Monitoring nature's calendar from space: Emerging topics in land surface phenology and associated opportunities for science applications, *Global Change Biology*, 2022, V. 28, No. 24, pp. 7186–7204, DOI: 10.1111/gcb.16436.
36. Ma Y., Liang S. Z., Myers D. B. et al., Subfield-level crop yield mapping without ground truth data: A scale transfer framework, *Remote Sensing of Environment*, 2024, V. 315, Article 114427, DOI: 10.1016/j.rse.2024.114427.
37. Manin A. A., Sokolov S. V., Novikov A. I. et al., Kalman filter adaptation to disturbances of the observer's parameters, *Inventions*, 2021, V. 6, No. 4, Article 80, DOI: 10.3390/inventions6040080.
38. Manin A. A., Sukhanov A. V., Sokolov S. V. et al., Kalman filter adaptive to constant perturbations of the observable object parameters, *Proc. 5th Intern. Scientific Conf. "Intelligent Information Technologies for Industry"* (*IITI'21*), Lecture Notes in Networks and Systems, 2022, V. 330, pp. 527–538, DOI: 10.1007/978-3-030-87178-9_52.
39. Marais Sicre C., Fieuzal R., Baup F., Contribution of multispectral (optical and radar) satellite images to the classification of agricultural surfaces, *Intern. J. Applied Earth Observation and Geoinformation*, 2020, V. 84, Article 101972, DOI: 10.1016/j.jag.2019.101972.
40. Muruganantham P., Wibowo S., Grandhi S. et al., A systematic literature review on crop yield prediction with deep learning and remote sensing, *Remote Sensing*, 2022, V. 14, No. 9, Article 1990, DOI: 10.3390/rs14091990.
41. Novikov A. I., Vovchenko N. G., Sokolov S. V. et al., Improving the quality of automated VIS-grading of Scots pine seeds using fuzzy logic algorithm, *IOP Conf. Series: Earth and Environmental Science*, 2021, V. 875, Article 012032, DOI: 10.1088/1755-1315/875/1/012032.
42. Novikova T. P., Tylek P., Petrishchev E. P., Novikov A. I. et al., Higher plant seed container germination success predicted by smart farming optical RGB approach, *Scientific Reports*, 2026, V. 16, Article 13021, DOI: 10.1038/s41598-026-42258-9.
43. Pei J., Tan S., Zou Y. et al., The role of phenology in crop yield prediction: Comparison of ground-based phenology and remotely sensed phenology, *Agricultural and Forest Meteorology*, 2025, V. 361, Article 110340, DOI: 10.1016/j.agrformet.2024.110340.
44. Peng B., Guan K., Tang J. et al., Towards a multiscale crop modelling framework for climate change adaptation assessment, *Nature Plants*, 2020, V. 6, No. 4, pp. 338–348, DOI: 10.1038/s41477-020-0625-3.
45. Radočaj D., Plaščak I., Jurišić M. (2025a), Fusion of Sentinel-2 phenology metrics and saturation-resistant vegetation indices for improved correlation with maize yield maps, *Agronomy*, 2025, V. 15, No. 6, Article 1329, DOI: 10.3390/agronomy15061329.
46. Radočaj D., Plaščak I., Jurišić M. (2025b), A comparative assessment of regular and spatial cross-validation in subfield machine learning prediction of maize yield from Sentinel-2 phenology, *Eng*, 2025, V. 6, No. 10, Article 270, DOI: 10.3390/eng6100270.
47. Radočaj D., Jurišić M., Plaščak I., Galić L., Satellite remote sensing for crop yield prediction: A review, *Agriculture*, 2026, V. 16, No. 4, Article 417, DOI: 10.3390/agriculture16040417.
48. Segarra J., Buchaillot M. L., Araus J. L., Kefauver S. C., Remote sensing for precision agriculture: Sentinel-2 improved features and applications, *Agronomy*, 2020, V. 10, No. 5, Article 641, DOI: 10.3390/agronomy10050641.

49. Shahhosseini M., Hu G., Huber I., Archontoulis S. V., Coupling machine learning and crop modeling improves crop yield prediction in the US Corn Belt, *Scientific Reports*, 2021, V. 11, No. 1, Article 1606, DOI: 10.1038/s41598-020-80820-1.
50. Sokolov S. V., Novikov A. I., Adaptive estimation of UVs navigation parameters by irregular inertial-satellite measurements, *Intern. J. Intelligent Unmanned Systems*, 2021, V. 9, No. 4, pp. 274–282, DOI: 10.1108/IJIUS-10-2019-0056.
51. Sokolov S., Novikov A., Polyakova M., Adaptive stochastic filtration based on the estimation of the covariance matrix of measurement noises using irregular accurate observations, *Inventions*, 2021, V. 6, No. 1, Article 10, DOI: 10.3390/inventions6010010.
52. Sokolov S., Khatlamadzhiyan A., Novikov A. et al., Terminal stochastic filtering of nonlinear dynamic processes: The case of invariant immersion, *Proc. 6th Intern. Scientific Conf. "Intelligent Information Technologies for Industry"* (*IITI'22*), Lecture Notes in Networks and Systems, 2023, V. 566, pp. 369–379, DOI: 10.1007/978-3-031-19620-1_35.
53. Trevisiol F., Mandanici E., Pagliarani A., Bitelli G., Evaluation of Landsat-9 interoperability with Sentinel-2 and Landsat-8 over Europe and local comparison with field surveys, *ISPRS J. Photogrammetry and Remote Sensing*, 2024, V. 210, pp. 55–68, DOI: 10.1016/j.isprsjprs.2024.02.021.
54. van Klompenburg T., Kassahun A., Catal C., Crop yield prediction using machine learning: A systematic literature review, *Computers and Electronics in Agriculture*, 2020, V. 177, Article 105709, DOI: 10.1016/j.compag.2020.105709.
55. Wang X., Huang J., Feng Q., Yin D., Winter wheat yield prediction at county level and uncertainty analysis in main wheat-producing regions of China with deep learning approaches, *Remote Sensing*, 2020, V. 12, No. 11, Article 1744, DOI: 10.3390/rs12111744.
56. Zhang Z., Yang J., Sun H. et al., MCVI-SANet: A lightweight semi-supervised model for LAI and SPAD estimation of winter wheat under vegetation index saturation, *https://arxiv.org/*, arXiv:2512.18344, 2025, 33 p., https://arxiv.org/abs/2512.18344.
57. Zhou W., Liu Y., Ata-Ul-Karim S. T. et al., Integrating climate and satellite remote sensing data for predicting county-level wheat yield in China using machine learning methods, *Intern. J. Applied Earth Observation and Geoinformation*, 2022, V. 111, Article 102861, DOI: 10.1016/j.jag.2022.102861.