

Интеллектуальное сельское хозяйство с использованием методов машинного обучения и глубокого обучения

В.А. Багно

Российский государственный аграрный университет - МСХА имени К.А. Тимирязева, Санкт-Петербург

Аннотация: Статья посвящена рассмотрению ключевых вопросов, связанных с использованием методов машинного и глубокого обучения в сельском хозяйстве. Отдельное внимание уделено сферами применения данных технологий в различных процессах земледелия и выращивания культур. Кроме того, рассмотрены особенности использования глубокого обучения на практике на примере разработки рекомендательной системы, которая призвана сформировать предложения наиболее подходящих культур для выращивания в определенном регионе в следующем сезоне.

Ключевые слова: сельское хозяйство, урожай, искусственный интеллект, глубокое обучение, прогнозирование, модель, сезон, точность.

Сельское хозяйство - важнейший сектор экономики. В тоже время, необходимо отметить, что рынок агропромышленной продукции нестабилен. Например, засуха или наводнение может существенным образом повлиять на будущие цены сырьевых товаров и серьезно отразиться на стоимости продовольствия. Кроме того, сельское хозяйство - чрезвычайно сложное занятие. Изменение климата, эрозия почвы, утрата биоразнообразия могут подорвать бизнес, равно как и меняющиеся вкусы потребителей. Природная среда, с которой взаимодействует сельское хозяйство, продолжает создавать свои собственные проблемы. Помимо растущего населения, устойчивому агропромышленному комплексу также угрожает урбанизация. И единственный способ удовлетворить растущий спрос на продовольствие - следить за урожаем, окружающей средой и рынком [1].

В данном контексте особого внимания заслуживают такие технологии как искусственный интеллект (ИИ), машинное обучение (ML) и глубокое обучение (DL), которые оказывают существенное влияние на сельскохозяйственную практику. Эти цифровые инновации позволяют внедрять «умные» методы фермерства, которые повышают

производительность, эффективность использования ресурсов и устойчивость благодаря применению широких наборов разнообразных данных для принятия решений. Фермеры могут использовать ML и DL для прогнозирования таких факторов окружающей среды, как погодные условия и вспышки вредителей, управления такими ресурсами, как вода и удобрения, мониторинга здоровья скота и максимизации урожайности [2]. Кроме того, благодаря поддержке принятия решений в режиме реального времени, улучшению взаимодействия с заинтересованными сторонами и распространению знаний, большие языковые модели придают «умному» сельскому хозяйству новое измерение.

О значимости данных технологий для улучшения работы фермеров можно судить по динамике мирового рынка ИИ в сельском хозяйстве, который оценивался в 1,91 млрд долларов США в 2023 году и, по прогнозам, будет расти в среднем на 25,5% в период с 2024 по 2030 год [3] (см. рис. 1).




Рис. 1 Динамика мирового рынка ИИ для сельского хозяйства в разрезе его составляющих [3]

Однако, следует акцентировать внимание на том, что для использования технологий ML и DL необходимо решить несколько

технических проблем. Во-первых, доступность и качество данных. Чтобы делать точные прогнозы необходимо обучать алгоритмы с использованием обширных и разнообразных наборов информации. Во-вторых, выбор алгоритмов и моделей обучения. В-третьих, внедрение и управление системами ML и DL требует наличия технических знаний, которыми фермеры могут не обладать. В-четвертых, проблемы обеспечения совместимости и бесшовной интеграции ML и DL с существующими сельскохозяйственными технологиями.

Таким образом, необходимость решения вышеотмеченных задач, а также высокая научно-практическая значимость технологий AI для сельского хозяйства предопределили выбор темы данной статьи.

Основные области применения ML и DL в сельском хозяйстве описывают в своих трудах В.М. Мошуров, В.Д. Русскин, И.С. Логинов, А.К. Вершинин, I. Wubshet.

Подходы к применению ансамбля моделей сверточных нейронных сетей для классификации изображений Artificial Learning EXperiment (AlexNet), «остаточная сеть» ResNet50 (Residual Network) и нейросеть распознавания объектов на изображении VGG16 (Visual Geometry Group) для улучшения общей производительности, обнаружения болезней растений разрабатывают О.В. Тахумова, Э.Э. Смехова, Ю.А. Кривенко, М.С. Боженков, А.Н. Сёмин, Е.А. Скворцов, J. Mardian, C.Champagne, B. Bonsal.

Перспективы и особенности применения машины опорных векторов и алгоритма дерева решений для определения типа культуры на основе микроэлементов и метеорологических характеристик входят в круг научных интересов А.Г. Аксенова, В.С. Тетерина, А.Ю. Овчинникова, Н.С. Панферова, С.А. Пехнова, J. Schiller, S. Stiller.

Несмотря на широкий спектр публикаций и имеющихся на сегодняшний день наработок, ряд вопросов в данной предметной плоскости

требует отдельного внимания. Так, в дальнейшем развитии и обосновании нуждаются методы анализа данных, основанные на изображениях, которые способны показать хорошие результаты, продемонстрировав эффективность в идентификации и классификации различных стрессовых состояний растений на основе только визуальных признаков. Крайне фрагментарно и не системно в современных публикациях освещены стратегии трансферного обучения, которые помогают исследователям добиваться высоких результатов при меньшем объеме данных, адаптируя предварительно обученные DL-модели к конкретной области анализа в деятельности фермеров.

Таким образом, цель статьи заключается в изучении возможностей использования технологий ML и DL в сельском хозяйстве.

Итак, алгоритмы ML и DL играют очень важную роль в принятии решений об уходе за растениями и животными. Они анализируют огромные массивы данных и предсказывают оптимальные условия выращивания, обработки, культивации и т.д. На основе этого разрабатываются индивидуальные решения для повышения урожайности и устойчивости растений [4]. В таблице 1 кратко описаны области применения ML и DL в сельском хозяйстве.

DL — это раздел ML, который использует искусственные нейронные сети для получения знаний и принятия решений на основе обширных наборов данных.

Рассмотрим особенности использования данных технологий в реальной жизни на примере разработки рекомендательной системы, которая призвана сформировать предложения наиболее подходящих культур для выращивания в определенном регионе в следующем сезоне.

Таблица 1

Применение ML и DL в сельском хозяйстве

Применение ML и DL	Описание	Преимущества	Примеры/случаи использования
Точное земледелие	Системы ML и DL анализируют данные с датчиков, спутниковых снимков и беспилотников, чтобы оптимизировать урожайность, следить за состоянием почвы и составлять прогнозы	Максимальный урожай, снижение потребления ресурсов (воды, удобрений, пестицидов) и минимизация воздействия на окружающую среду	Компании Agrosmart и Farmwave предоставляют инструменты для точного земледелия, позволяющие отслеживать урожай и прогнозировать его эффективность
Мониторинг с/х культур и почвы	Беспилотники и датчики, работающие на основе ML и DL, собирают данные в режиме реального времени для оценки состояния посевов и почвы	Раннее обнаружение болезней, вредителей и дисбаланса почвы, что приводит к своевременному вмешательству	Такие платформы, как Arable и Taranis, отслеживают состояние посевов и почвы с помощью передовой аналитики данных
Автоматизированные системы орошения	ML и DL оптимизирует использование воды, основываясь на прогнозах погоды, данных о влажности почвы и потребностях культур	Экономия воды, повышение эффективности выращивания и снижение потерь воды	CropX и NetBeat предлагают интеллектуальные решения для орошения, основанные на данных в реальном времени и предиктивном анализе
Обнаружение вредителей и болезней	Инструменты ML и DL используют распознавание изображений и алгоритмы для раннего обнаружения вредителей и болезней растений	Предотвращение повреждения урожая и сокращение использования вредных пестицидов	Plantix и FarmSense обеспечивают идентификацию болезней и вредителей с помощью технологий распознавания изображений.
Прогнозирование урожайности с/х культур	Модели машинного обучения прогнозируют урожайность на основе исторических данных, погодных условий и состояния полей в режиме реального времени	Улучшение планирования фермы, сокращение отходов и повышение эффективности цепочки поставок	Prospera и aWhere предлагают решения на основе искусственного интеллекта для прогнозирования урожайности с использованием комплексной аналитики данных

Рабочий процесс для селекции сельскохозяйственных культур на основе DL включает в себя 6 взаимосвязанных этапов:

1. Сбор данных: сбор сельскохозяйственных и генетических данных, которые имеют отношение к целевым культурам, включая факторы окружающей среды, фенотипические признаки, генетические маркеры, а также другую связанную информацию.

2. Предварительная обработка полученных массивов информации: это предполагает их очистку, включая нормализацию, извлечение признаков, дополнение отсутствующих сведений.

3. Построение модели: выбор типа модели и архитектуры нейронной сети, которые будут в большей степени подходить для решения поставленной задачи селекции.

4. Обучение модели: этот этап является очень важным, поскольку от правильности выбора подхода к обучению будет зависеть точность и достоверность полученных результатов. Также на данном этапе проводится оптимизация параметров модели для того, чтобы минимизировать различия между прогнозируемыми выходными данными и наблюдаемыми значениями [5].

5. Оптимизация и отбор генетических параметров: на этом этапе обученная модель DL используется для прогнозирования и оценки характеристик и генетических признаков сельскохозяйственных культур, которые могут выращиваться в изучаемом регионе.

6. Итеративное улучшение: это предполагает повторение этапов обучения, оценки и отбора для улучшения модели и процесса селекции.

На рис. 2 представлен обобщенный алгоритм прогнозирования производства сельскохозяйственных культур.




Рис. 2 Алгоритм прогнозирования производства сельскохозяйственных культур [6]

Основная функция, представленного на рис. 2 алгоритма, заключается в том, чтобы улучшить популяцию сельскохозяйственных культур путем их последовательной оценки и изменения оценок приспособленности популяции в соответствии с производительностью отдельной культуры для условий конкретного региона. Это позволяет выбирать и продвигать наиболее успешные сорта, одновременно распознавая и смягчая такие проблемы, как сорняки, которые могут помешать производству [7]. При наличии другого события условная вероятность благоприятного события отличается от вероятности, приведенной в следующем уравнении:

$$E(B/N) \neq E(N/B)$$

$$E(V/B) = (E(V) \times E(B/V))(E(B))$$

$$d(m, u) = \sum (j = 1)^y [u_i g_i(m) + o]$$

Для автоматической оценки векторов признаков и класса данных прогноза урожая целесообразно использовать следующие уравнения качества.

$$G_{y,c} = \sum_{i=2}^0 \sum_{g=1}^{i=1} H_{ig} (e_i a_g + e_g a_i) F_{ig}$$

где G - означает коэффициент уравнения;

F - представляет собой различные вариации задания: относительный краевой отклик.

Для расчета RER изображение должно обладать соответствующими свойствами формы краев [8]. Фотографии болезней сельскохозяйственных культур и насекомых-вредителей оцениваются по качеству с помощью уравнения качества изображения:

$$o(m) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{m^2}{2}\right)$$
$$h_t = z_t \Theta h_{t-1} + (1 - v_q) \Theta g_q$$
$$w_{(i/j)} = u_{ji} S_j, a_i = \sum_j b_{ji} w_{(i/j)}$$

В качестве основы изображенного на рис. 2 алгоритма предлагаем использовать сеть долгая краткосрочная память (Long short-term memory или LSTM), которая является комбинацией усовершенствованной сети рекуррентной нейронной сети (Recurrent neural network или RNN) и последовательной сети, что позволяет сохранять информацию. Каждый блок LSTM состоит из ячейки, выходного входного шлюза и шлюза забывания. Слой сглаживания используется для выравнивания выходного сигнала LSTM, который затем поступает в полностью подключенную двухслойную архитектуру со скрытыми блоками [9]. На каждом скрытом слое используется дополнительный слой пакетной нормализации с целью стандартизации каждого выхода скрытого слоя, кроме того, для регуляризации добавляется отсев. Каждый скрытый слой активируется функцией выпрямленного линейного блока, которая считается передовой для нейронных сетей.

На рис. 3 представлена архитектура LSTM.




Рис. 3 Архитектура нейронной сети LSTM [10]

Охарактеризуем представленную на рис. 3 архитектуру более подробно.

Структура модели

Количество слоев: 3 слоя LSTM, затем плотный слой

Скрытые единицы: 128 (для каждого слоя LSTM)

Функция активации: Tanh для ячеек LSTM, нелинейная функция активации (Rectified Linear Unit или ReLU) для плотных слоев

Выходной слой: Плотный слой с активацией softmax для многоклассовой классификации

Функция потерь: Категориальная перекрестная энтропия

Оптимизатор: Adam

Гиперпараметры

Для модели LSTM настраиваются следующие параметры

Скорость обучения: 0,001 (со скоростью затухания 0,92 каждые 12

эпох)

Размер партии: 36

Эпохи: 120 (с ранней остановкой на основе точности валидации)

Отсев: 0,4 (применяется после каждого слоя LSTM для уменьшения перегрузки)

Повторяющееся выпадение: 0,3 (применяется внутри ячеек LSTM)

Инициализация весов: единая инициализация Ксавье (Xavier) для всех слоев

Процесс обучения

Модель LSTM обрабатывает последовательности входных данных, где временные зависимости имеют решающее значение для точной классификации.

Модель обучается с помощью критериев ранней остановки на основе потерь при валидации, а контрольные точки сохраняются для восстановления наилучшей модели.

Особое внимание при использовании алгоритма прогнозирования производства с/х культур должно быть уделено критериям валидации. По мнению автора, полагаться только на общую точность оценки достоверности классификатора недостаточно, поэтому для проверки необходимо использовать различные параметры.

Достоверность - объясняет надежность классификатора, она рассчитывается путем отношения истинно положительных результатов к сумме истинно положительных и ложноположительных результатов.

Отзыв - в основном предоставляет информацию о совершенстве классификатора. Она определяется как отношение истинно положительных результатов к сумме истинно положительных и ложноотрицательных результатов для каждого класса.

F1-score — это среднее гармоническое значение весовых

коэффициентов precision и recall в диапазоне от 1,0 до 0,0, где 1,0 - хороший показатель F1, а 0,0 - худший.

Общая точность — это отношение суммы всех правильно классифицированных точек обучающих данных к общему количеству точек обучающих данных.

Резюмируя полученные результаты, отметим, что сельскохозяйственный сектор сталкивается с многочисленными рисками и неопределенностями из-за меняющихся климатических условий и рыночных тенденций, что приводит к значительным производственным потерям и нерациональному использованию ресурсов.

Инструменты искусственного интеллекта, такие как машинное и глубокое обучение имеют большой потенциал для сельскохозяйственной отрасли. Они предлагают современные методы точной обработки изображений и анализа данных, позволяя решать различные задачи в области производства продуктов питания и выращивания животных, такие как прогнозирование затрат, профилактика бесплодия и управление посевами, рекомендации по пестицидам, сокращение ручного труда и т.д.

В статье рассмотрен практический пример использования глубокого обучения для прогнозирования производства с/х культур в определенном регионе.

Литература

1. Сабитов Б.Р. Использование алгоритмов машинного обучения для построения линейных моделей задач сельского хозяйства // Наука и инновационные технологии. 2023. № 2 (27). С. 217-222.
2. Lei J. Research on the improvement path of international competitiveness of China's agricultural product supply chain from the perspective of machine learning // Expert Systems. 2022. Volume 41, Issue 5. pp. 34-39.
3. Shemin T. John, Pradip Sarkar Machine learning deployment for

energy monitoring of Internet of Things nodes in smart agriculture // International Journal of Communication Systems. 2024. Volume 37, Issue 15. pp. 179-185.

4. Линкина А.В., Елсуков В.Д., Тришин А.А. Использование моделей машинного обучения при решении задач в отрасли органического сельского хозяйства // Вестник Воронежского государственного университета инженерных технологий. 2023. Т. 85. № 4 (98). С. 133-138.

5. Кондратьев А.А., Березин С.Б. Применение нейронных сетей для обнаружения аномалий в развитии растений // International Journal of Open Information Technologies. 2023. Т. 11. № 7. С. 47-52.

6. Singh H., Yadav P. Localization in WSN-Assisted IoT Networks Using Machine Learning Techniques for Smart Agriculture // International Journal of Communication Systems. 2024. № 56. pp. 110-119.

7. Боровой Д.А., Ступина М.В., Садовая И.В. Применение искусственного интеллекта и мобильных технологий для эффективного мониторинга урожайности зерновых культур // Молодой исследователь Дона. 2024. Т. 9. № 3 (48). С. 18-22.

8. Mahmood A., Kumar A. Tiwari Contemporary machine learning applications in agriculture: Quo Vadis? // Concurrency and Computation: Practice and Experience. 2022. Volume 34, Issue 15. pp. 76-82.

9. Baiardi A., Naghi A. A. The effect of plough agriculture on gender roles: A machine learning approach // Journal of Applied Econometrics. 2024. Volume 39, Issue 7. pp. 20-29.

10. Clay D. E., Brugler S. Will artificial intelligence and machine learning change agriculture: A special issue // Agronomy Journal. 2024. Volume 116, Issue 3. pp. 65-72.

References

1. Sabitov B.R. Nauka i innovacionnye tekhnologii. 2023. No. 2 (27). pp. 217-222.

2. Lei J. Research on the improvement path of international competitiveness of China's agricultural product supply chain from the perspective of machine learning. *Expert Systems*. 2022. Volume 41, Issue 5. pp. 34-39.
3. Shemin T. John, Pradip Sarkar Machine learning deployment for energy monitoring of Internet of Things nodes in smart agriculture. *International Journal of Communication Systems*. 2024. Volume 37, Issue 15. pp. 179-185.
4. Linkina A.V., Elsukov V.D., Trishin A.A. Vestnik Voronezhskogo gosudarstvennogo universiteta inzhenernyh tekhnologij. 2023. Vol. 85. No. 4 (98). pp. 133-138.
5. Kondratjev A.A., Berezina S.B. *International Journal of Open Information Technologies*. 2023. Vol. 11. No. 7. pp. 47-52.
6. Singh H., Yadav P. Localization in WSN-Assisted IoT Networks Using Machine Learning Techniques for Smart Agriculture. *International Journal of Communication Systems*. 2024. № 56. pp. 110-119.
7. Borovoj D.A., Stupina M.V., Sadovaya I.V. Molodoj issledovatel' Dona. 2024. Vol. 9. No. 3 (48). pp. 18-22.
8. Mahmood A., Kumar A. Tiwari Contemporary machine learning applications in agriculture: Quo Vadis? *Concurrency and Computation: Practice and Experience*. 2022. Volume 34, Issue 15. pp. 76-82.
9. Baiardi A., Naghi A. A. The effect of plough agriculture on gender roles: A machine learning approach. *Journal of Applied Econometrics*. 2024. Volume 39, Issue 7. pp. 20-29.
10. Clay D. E., Brugler S. Will artificial intelligence and machine learning change agriculture: A special issue. *Agronomy Journal*. 2024. Volume 116, Issue 3. pp. 65-72.

Дата поступления: 18.03.2025

Дата публикации: 10.07.2025