

ОБЪЯСНИМЫЙ ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ И МЕТОД SHAP КАК ОСНОВА ПРОЗРАЧНОГО ПРОГНОЗИРОВАНИЯ В АГРОПРОМЫШЛЕННОМ КОМПЛЕКСЕ РЕСПУБЛИКИ БЕЛАРУСЬ

Клименко И. В.

Кафедра экономической информатики,

Белорусский государственный университет информатики и радиоэлектроники

Минск, Республика Беларусь

E-mail: znachnamail@gmail.com

В статье рассматривается применение методов объяснимого искусственного интеллекта (ХАИ) в контексте цифровой трансформации агропромышленного комплекса Республики Беларусь. Раскрываются возможности интерпретации сложных моделей машинного обучения с использованием методов PDP, ICE, LIME, Permutation Importance и особенно SHAP, позволяющего количественно оценивать вклад факторов в прогноз. На примере прогнозирования урожайности пшеницы и анализа молочных удоев показано, как объяснимость повышает доверие к цифровым решениям и способствует управляемости производственных процессов. Сформулированы рекомендации по институционализации ХАИ в национальных информационных системах АПК.

ВВЕДЕНИЕ

Цифровая трансформация АПК Беларуси рассматривается как ключ к росту эффективности, конкурентоспособности и устойчивости как отрасли, так и национальной экономики. В данный момент внедряются элементы точного земледелия, мониторинг животных, облачные отраслевые ИС, однако прогресс неравномерен из-за кадровых и инфраструктурных ограничений, а также технологического отставания и низкой скорости внедрения инноваций [1]. Нормативную рамку внедрения цифровизации формируют Декрет № 8 и Госпрограмма «Цифровое развитие Беларуси», задающие стратегические ориентиры обновления сектора [2].

Главным барьером внедрения цифровых решений выступает недоверие управленцев и работников к «чёрным ящикам»: в прогнозах непрозрачных моделей людям сложно обнаруживать взятую логику, что снижает готовность к их применению [3]. В этих условиях раскрывается необходимость внедрения объяснимого ИИ (ХАИ): он раскрывает логику сложных моделей без заметной потери точности и превращает их из закрытого механизма в инструмент совместного анализа, дополняющий профессиональную экспертизу [1; 3].

ОСНОВНАЯ ЧАСТЬ

Методы объяснимого искусственного интеллекта различаются по степени детализации анализа и нередко используются совместно, поскольку дают разные углы понимания поведения модели. Так, PDP (Partial Dependence Plot) отображает, как в среднем изменяется прогноз при варьировании одного из факторов, например уровня влажности или кислотности почвы, при прочих равных условиях. ICE (Individual Conditional Expectation) показывает подобную зависимость, но уже для

каждого отдельного наблюдения – то есть для конкретного поля, хозяйства или региона, что позволяет учитывать индивидуальные особенности. LIME (Local Interpretable Model-Agnostic Explanations) строит простую приближенную модель вокруг конкретного решения, помогая понять, почему алгоритм сделал именно этот выбор. Permutation Importance оценивает важность признаков, случайно перемешивая их значения и проверяя, насколько сильно при этом падает точность модели [3].

Особое место среди методов объяснимости занимает SHAP (Shapley Additive Explanations), основанный на теории кооперативных игр. Он разлагает прогноз модели на вклады отдельных факторов, выраженные в тех же единицах, что и сам результат. Это позволяет не только определить важные признаки, но и количественно оценить их влияние: например, насколько температура или уровень осадков изменили ожидаемую урожайность. Для управленцев такой подход особенно ценен, поскольку делает возможным осмысленный количественный анализ решений.

Метод сопровождается наглядными визуализациями – beeswarm, summary bar, dependence и waterfall графиками, показывающими, как каждый фактор влияет на прогноз. Такие инструменты уже применяются в аграрных исследованиях: от выбора оптимальных культур до прогнозирования неисправностей техники и оценки производительности труда [4-8].

Использование SHAP требует осторожности и понимания его ограничений. При высокой корреляции признаков (например, температуры и влажности) метод может ошибочно распределять вклад между ними, так как классические варианты, такие как Kernel SHAP, подставляют нереалистичные комбинации данных. Для повышения достоверности применяются Conditional SHAP и

группировка связанных признаков [9]. Кроме того, SHAP объясняет корреляции внутри модели, но не причинно-следственные связи, что требует подтверждения выводов экспериментами или каузальным анализом [10-11].

Практическое применение методов объяснимого искусственного интеллекта наглядно демонстрирует анализ SHAP, используемый для интерпретации прогностических моделей в сельском хозяйстве. В исследовании по прогнозированию урожайности яровой пшеницы в Алтайском крае (2001–2024 гг.) модель XGBoost, обученная на 18 метео- и агротехнических факторах, показала высокую точность ($R^2 = 0,95$; $MAE = 0,13$ т/га) [6]. SHAP выявил ключевые детерминанты: количество осадков, паровой предшественник и дозы удобрений. Оптимальное увлажнение (596 мм) повышало прогноз на +1,19 т/га, дефицит влаги (317 мм) снижал на -0,77 т/га. Это позволило обосновать решения по севообороту и нормам удобрений.

Схожие результаты получены в проекте «цифрового двойника» молочной фермы, где ансамбль моделей (SVR, AdaBoost, ANN) применялся для прогноза удоя и оценки экологической эффективности [7]. SHAP показал, что месяц лактации снижает удои, тогда как состав и энергетическая насыщенность рациона её повышают. Избыток азота увеличивает концентрацию мочевины в молоке, а рост удоя и массы животного, наоборот, снижает её уровень, что позволяет оперативно корректировать кормление и повышать эффективность производства.

Выводы

Таким образом, объяснимый искусственный интеллект меняет подход к цифровому анализу и управлению в аграрной сфере. Он делает работу моделей прозрачной и воспроизводимой, превращая алгоритмы из «чёрных ящиков» в понятные инструменты принятия решений.

Для агропромышленного комплекса Беларусь метод SHAP служит связующим звеном между точностью и управляемостью аналитических систем, позволяя интерпретировать прогнозы через вклад факторов и повышая доверие к цифровым решениям. Практические примеры, такие как прогноз урожайности, анализ молочной продуктивности и техническая диагностика, подтверждают, что объяснимость делает ИИ-системы более надёжными и полезными.

Внедрение XAI требует институциональной поддержки: разработки стандартов объясимости, включения таких методов в национальные информационные системы и подготовки специалистов. Расширение образовательных модулей по XAI в рамках программы «Цифровое разви-

тие Беларусь» обеспечит формирование кадровой базы для осмысленной и прозрачной цифровой трансформации агропромышленного комплекса страны.

1. Проблемы и перспективы цифровизации аграрной экономики в Республике Беларусь / К. В. Павлов, И. В. Зенькова, И. А. Позднякова [и др.] // Вестник УГНТУ. Наука, образование, экономика. Серия экономика. – № 2 (44). – 2023. – С. 7–13.
2. Сырокваш, Н. А. О развитии цифровизации АПК Беларусь / Н. А. Сырокваш, О. Л. Сапун // Актуальные проблемы инновационного развития агропромышленного комплекса Беларусь: сб. науч. тр. по материалам XIV Междунар. науч.-практ. конф., Горки, 30–31 мая 2022 г. : в 2 ч. / [редкол. : И. В. Шафранская (отв. ред.) и др.]. – Горки. – 2023. – Ч. 2. – С. 54–58.
3. Шевская, Н. В. Объяснимый искусственный интеллект и методы интерпретации результатов [Электронный ресурс]. – Режим доступа: <https://moitvvt.ru/ru/journal/pdf?id=1005>. – Дата доступа: 12.09.2025.
4. Akkem, Y. Role of Explainable AI in Crop Recommendation Technique / Y. Akkem, S. K. Biswas, A. Varanasi // I. J. Intelligent Systems and Applications. – 2025. – Vol. 1. – P. 31–52.
5. Suresh, S. E., Venkateswara Reddy K. Explainable AI for Predictive Maintenance in Smart Agricultural Facilities / S. E. Suresh // International Journal of Research Publication and Reviews. – 2025. – Vol. 6, Issue 5. – P. 11806–11808.
6. Интерпретируемая модель машинного обучения для прогнозирования урожайности яровой пшеницы / В. К. Каличкин, В. И. Усенко, А. А. Гаркуша [и др.] // Российская сельскохозяйственная наука. – 2025. – № 2. – С. 59–66.
7. Engineering-Oriented Explainable Machine Learning and Digital Twin Framework for Sustainable Dairy Production and Environmental Impact Optimisation / R. Xing, B. Li, S. Dora [et al.] // Algorithms. – 2025. – 18(10):670. – Mode of access: <https://www.mdpi.com/1999-4893/18/10/670>. – Date of access: 20.10.2025.
8. A Proactive Predictive Model for Machine Failure Forecasting / O. O. Ajayi, A. M. Kurien, K. Djouani [et al.] // Machines. – 2025. – 13(8):663. – Mode of access: <https://www.mdpi.com/2075-1702/13/8/663>. – Date of access: 20.10.2025.
9. Aas, K. Explaining individual predictions when features are dependent: more accurate approximations to Shapley values / K. Aas, M. Jullum, A. Løland // Artificial Intelligence. – 2021. – Vol. 298. Article 103502. – Mode of access: <https://arxiv.org/pdf/1903.10464.pdf>. – Date of access: 20.10.2025.
10. Takefuji, Y. Reevaluating feature importance in machine learning: concerns regarding SHAP interpretations in the context of the EU artificial intelligence act / Y. Takefuji // Water Research. – 2025. – Vol. 280. Article 123514. – Mode of access: <https://doi.org/10.1016/j.watres.2023.123514>. – Date of access: 20.10.2025.
11. Be careful when interpreting predictive models in search of causal insights (blog article) / E. Dillon, J. LaRiviere, S. M. Lundberg [et al.] // Tech Community Microsoft (SHAP documentation). – Mode of access: https://shap.readthedocs.io/en/latest/example_notebooks/overviews/Be%20careful%20when%20interpreting%20predictive%20models%20in%20search%20of%20causal%20insights.html. – Date of access: 20.10.2025.