

АНАЛИЗ ВЛИЯНИЯ ИЗМЕНЕНИЯ КЛИМАТА НА СЕЛЬСКОЕ ХОЗЯЙСТВО С ПОМОЩЬЮ БОЛЬШИХ ДАННЫХ

Изменение климата оказывает значительное влияние на сельское хозяйство, затрагивая урожайность, водопотребление, распространение вредителей и болезней. Использование больших данных открывает новые возможности для анализа и прогнозирования этих эффектов.

Цель исследования — оценить влияние климатических изменений на сельское хозяйство с помощью методов интеллектуального анализа данных.

Материалы и методы. Использовались исторические данные по урожайности, метеопараметрам, данные дистанционного зондирования, методы машинного обучения (случайный лес, нейронные сети), геоинформационные технологии. Разработаны модели прогнозирования урожайности и водопотребности культур, распространения вредителей.

Результаты. На примере пшеницы в РФ установлено, что повышение температуры на 1 °C снижает урожайность на 5–10%, рост осадков — на 10%, увеличивает урожайность на 3–5%. ГИС-анализ показал расширение ареалов теплолюбивых культур на 150–200 км. Прогнозные модели показывают рост водопотребности (на 7–12%) и рисков распространения насекомых-вредителей (на 20–50%) к 2050 г. Предложен комплекс адаптационных мер (селекция засухоустойчивых сортов, капельное орошение, точное земледелие), потенциал которых оценен в 10–25% прироста урожайности.

Глобальное изменение климата является одним из ключевых вызовов для сельского хозяйства в XXI веке. По оценкам экспертов, к 2050 г. рост температуры на 1–3 °C и изменение режима осадков могут привести к падению урожайности основных культур на 10–25% в глобальном масштабе [1]. В то же время прогнозируемый рост населения Земли до 9–10 млрд человек потребует увеличения производства продовольствия на 70–100% [2]. В этих условиях особую актуальность приобретает задача адаптации агросектора к климатическим изменениям на основе внедрения инновационных технологий и аналитических инструментов.

Одним из наиболее перспективных подходов к решению данной проблемы является использование технологий больших данных (Big Data) и интеллектуального анализа данных (Data Mining). Под большими данными в сельском хозяйстве понимают огромные массивы разнородной информации, генерируемой из различных источников: метеорологических станций, сенсорных сетей, дронов, спутников дистанционного зондирования, баз данных агропредприятий и т. д. По оценкам экспертов, общий объем данных, производимых глобальным агросектором, достигает 0,5–1 Эбайт/год и продолжает экспоненциально расти [3].

Интеллектуальный анализ Big Data с помощью методов машинного обучения, прогнозная аналитики, геоинформационных систем (ГИС) открывает качественно новые возможности для выявления скрытых закономерностей, моделирования и

прогнозирования агроклиматических процессов [4]. Это позволяет не только глубже понять механизмы влияния климатических факторов на продуктивность сельхозкультур, но и разрабатывать научно обоснованные стратегии адаптации к изменениям климата на различных уровнях — от отдельных хозяйств до национальных агросистем.

В рамках данного исследования была предпринята попытка комплексной оценки влияния климатических изменений на сельское хозяйство РФ с помощью методов интеллектуального анализа Big Data. Информационную базу исследования составили:

- исторические ряды данных по урожайности основных культур в разрезе регионов РФ за 1995–2020 гг. (источник Росстат);

- архивы метеорологических данных (температура, осадки, индекс засушливости) по сети станций Росгидромета за тот же период;

- данные дистанционного зондирования Земли (продукты MODIS, Landsat) по регионам РФ с 2000 г., характеризующие состояние посевов (NDVI, EVI и др.) и параметры почвенного покрова;

- результаты полевых экспериментов по влиянию климатических факторов (температура, CO₂, озон) на физиологию и продуктивность культур из открытых баз данных (AgMIP, FACE);

- климатические прогнозы по ансамблю моделей CMIP5 на период до 2100 г. в привязке к территории РФ;

- геопространственные данные по географии сельхозугодий, параметрам рельефа, типам почв, гидрографии и др.

Ключевым элементом предлагаемой модели является блок машинного обучения, реализующий ансамблевый алгоритм случайного леса (Random Forest) для прогнозирования урожайности культур по комплексу климатических и агротехнических факторов. Математически модель Random Forest представляет собой взвешенную сумму решающих деревьев:

$$\hat{y} = \sum_{i=1}^N w_i \times f_i(X),$$

где: $\hat{y}$ — прогнозируемое значение урожайности, N — число деревьев в ансамбле; w_i — вес i -го дерева, $f_i(X)$ — прогноз i -го дерева по набору входных признаков X .

Обучение модели производится на размеченной выборке с известными историческими значениями урожайности и факторов внешней среды. Каждое дерево строится на случайном подмножестве данных и

признаков, что обеспечивает высокую обобщающую способность и устойчивость алгоритма к шумам и пропускам в исходных данных [4].

Для повышения точности прогнозов урожайности на больших территориях использовался гибридный подход, сочетающий глобальные климатические модели (GCM) и локальные модели машинного обучения. На первом шаге выполнялся даунскейлинг прогнозов GCM с помощью методов статистической коррекции (квантильное отображение, множественная регрессия):

$$T_{scaled} = a_0 + a_1 \times TGCM + a_2 \times Altitude + \dots + a_n \times X_n$$

$$P_{scaled} = b_0 \times PGCMb_1 \times Pb_{scaled} \times eb_3 \times Latitude + \dots + b_n \times X_n$$

где: T_{scaled} , P_{scaled} — скорректированные значения температуры и осадков; $TGCM$, $PGCM$ — прогнозы GCM; X_n — дополнительные предикторы (высота, широта, расстояние до моря и др.); a_n , b_n — настроечные коэффициенты.

Затем даунскейлинговые прогнозы использовались в качестве входов локальных моделей урожайности на основе алгоритма случайного леса. Такой двухэтапный подход позволил повысить корреляцию между фактической и прогнозной урожайностью с 0,6–0,7 для «сырых» прогнозов GCM до 0,8–0,9 для гибридных моделей [5].

Другим важным аспектом повышения надежности прогнозирования агроклиматических рисков является учет неопределенности исходных данных и моделей. Для количественной оценки неопределенности применялись методы ансамблевого прогнозирования и байесовской статистики. В частности, была построена байесовская сеть (Bayesian Network) для вероятностного прогноза урожайности пшеницы с узлами «климат», «погода», «агротехника», «генотип», «урожайность». Условные вероятности каждого узла рассчитывались на основе обучающей выборки и экспертных оценок:

$$P(Y|C, W, A, G) = P(Y, C, W, A, G) / P(C, W, A, G),$$

где: $P(Y|C, W, A, G)$ — вероятность урожайности при заданных состояниях климата, погоды, агротехники, генотипа; $P(Y, C, W, A, G)$ — совместная вероятность всех переменных; $P(C, W, A, G)$ — маргинальная вероятность родительских узлов.

Выведение прогнозных распределений урожайности осуществлялось методами приближенного байесовского вывода (MCMC, вариационный вывод). В результате удалось не только получать точечные прогнозы урожаев, но и оценивать их ожидаемую вариабельность, что критически важно для обоснования инвестиций в адаптационные мероприятия и агрострахование [6].

Перспективным направлением развития методов прогнозирования влияния климата на сельское хозяйство является комбинированное использование физических и вероятностных моделей на основе теории бесшовной предсказуемости (Seamless Predictability). Основная идея подхода заключается в интеграции процессных моделей агроэкосистем (имитирующих физиологию растений, динамику

почвенных процессов, формирование урожая) и стохастических моделей погоды и климата на основе байесовских динамических сетей (Dynamic Bayesian Networks). Согласно теореме Байеса, апостериорная вероятность всех переменных модели рассчитывается по формуле:

$$P(X_t, Y_t, Z_t | I_t) = P(I_t | Y_t) \times P(Y_t | X_t, Z_t) \times P(X_t | X_{t-1}) \times P(Z_t) / P(I_t)$$

X_t — вектор состояния динамической системы в момент t (содержание воды и питательных веществ в почве, биомасса растений и др.); Y_t — вектор наблюдаемых переменных (урожайность, вегетационные индексы); Z_t — вектор внешних воздействий (агротехнологии, сценарии климата); I_t — вектор данных наблюдений (данные мониторинга полей); $P(A|B)$ — условная вероятность A при известном B .

Совместное распределение вероятностей всех переменных находится путем рекурсивного применения теоремы Байеса и численных методов интегрирования (фильтры частиц). В результате обеспечивается сквозная связь между локальными особенностями агроэкосистем, описываемыми физически обоснованными моделями, и глобальными закономерностями климата, представленными в виде стохастических моделей [7].

Интеграция и предобработка разнородных массивов данных осуществлялись в единой геоинформационной среде на базе СУБД PostgreSQL и ГИС-платформы QGIS. Для выявления статистических взаимосвязей между климатическими переменными и урожайностью культур применялись методы корреляционно-регрессионного анализа, главных компонент, случайного леса, опорных векторов и др. Пространственное моделирование и картирование агроклиматических характеристик выполнялись средствами геостатистики (кригинг, IDW). Для прогнозирования динамики урожайности, фенологии культур, водопотребности, рисков распространения вредителей использовались имитационные динамические модели (DSSAT, APSIM) и алгоритмы машинного обучения (нейронные сети, деревья решений, байесовские сети).

Анализ временных рядов урожайности пшеницы в основных зернопроизводящих регионах РФ (Краснодарский край, Ростовская область, Поволжье, Западная Сибирь) за 1995–2020 гг. показал наличие статистически значимых ($p < 0,05$) отрицательных трендов, величина которых варьирует от минус 0,8–2,5 ц/га за десятилетие [5]. Сопоставление динамики урожайности со значениями индекса засухливости $SPEI$ выявило тесную корреляционную зависимость ($r = -0,78–0,92$), указывающую на определяющее влияние засухи на продуктивность культуры. Регрессионные модели показывают, что рост летних температур на 1 °C приводит к снижению урожайности пшеницы на 5–10%, в то время как увеличение количества осадков на 10% обеспечивает прирост урожайности на 3–5%. Ансамблевые климатические прогнозы предполагают усиление засушливости (рост $SPEI$ на 0,3–0,8) и увеличение повторяемости экстремальных засух ($SPEI < -2$) на юге европейской части РФ и в Поволжье на 10–15% к середине XXI века, что может привести к дальнейшему падению урожайности зерновых на 15–25% [6].

ГИС-анализ пространственно-временной динамики теплообеспеченности территории РФ показал

существенный сдвиг изотерм суммы активных температур (CAT) на север и восток страны за последние 30 лет. Так, изотерма CAT 1000 °C, ограничивающая ареал возделывания теплолюбивых культур (кукуруза, подсолнечник, соя), продвинулась на 150–200 км в северном и на 200–250 км в восточном направлении. Потепление климата уже привело к расширению посевных площадей данных культур в Нечерноземной зоне РФ на 20–30% и повышению их урожайности на 10–15% [7]. В то же время в южных регионах РФ при сохранении текущих темпов потепления (0,4–0,6 °C/10 лет) к 2050 г. ожидается сокращение ареалов возделывания зерновых культур на 15–20% из-за роста засухливости и снижения урожайности.

Прогнозные оценки на основе динамических имитационных моделей показывают, что изменение климата существенно повлияет на водопотребность и режим орошения сельхозкультур. При реализации сценария RCP8.5 к середине века прогнозируется увеличение сезонной суммарной водопотребности на 7–12% для зерновых и на 10–15% для пропашных культур в южных регионах РФ [6]. Это потребует увеличения объемов водозабора для орошения на 1,3–2,8 км³/год и приведет к росту затрат сельхозпроизводителей на 12–18%. Для адаптации к этим изменениям необходимы внедрение водосберегающих технологий полива (капельное орошение, дождевание) и повышение КПД оросительных систем. Компьютерное моделирование показывает, что комплексная модернизация мелиоративной инфраструктуры может компенсировать до 70% прогнозируемого роста водопотребности и обеспечить прирост урожайности на 15–20% [7].

Одно из негативных последствий потепления климата — повышение рисков распространения вредителей и болезней сельхозкультур. Энтомологические модели, основанные на нейросетевых алгоритмах обучения, прогнозируют расширение ареалов и рост вредоносности насекомых (колорадский жук, хлопковая совка, тли) на 20–50% в зерновом поясе РФ к 2050 г. [5]. ГИС-анализ показывает увеличение числа поколений вредителей за сезон на 2–3 и продвижение на 200–400 км к северу зон, благоприятных для их перезимовки. В этих условиях потребуются увеличение кратности обработок пестицидами на 25–40% и использование новых средств защиты растений, что приведет к удорожанию технологий возделывания на 15–20%. Для снижения химической нагрузки необходимы биологизация систем защиты растений и внедрение превентивных мер на основе фитосанитарного прогнозирования.

Обобщение результатов компьютерного моделирования позволяет оценить суммарные потери урожайности основных культур в РФ под воздействием прогнозируемых климатических изменений на уровне 9–28% в период до 2050 г. Наиболее уязвимыми регионами являются юг европейской части РФ, Поволжье, Западная Сибирь, где падение продуктивности может достичь 15–25% без принятия адаптационных мер. В то же время в Нечерноземье, на Урале и Дальнем Востоке прогнозируется рост биоклиматического потенциала на 5–15%, связанный с улучшением теплообеспеченности и увлажнения [7].

Для минимизации климатических рисков и использования новых возможностей необходимо масштабное внедрение таких инновационных технологий адаптации, как:

- селекция новых сортов и гибридов, устойчивых к засухе, жаре, болезням и вредителям;
- модернизация мелиоративных систем, переход на водосберегающие режимы орошения и фертигацию;
- цифровая трансформация АПК, внедрение систем точного земледелия и интеллектуального управления агротехнологиями;
- развитие систем агрострахования с учетом климатических рисков;
- диверсификация структуры посевных площадей и севооборотов, сдвиг ареалов культур на север и восток.

Моделирование показывает, что комплексная реализация адаптационных мер позволит компенсировать до 50–70% прогнозируемых потерь урожайности и обеспечить прирост производства зерна на 10–25% к 2050 г. [6]. При этом в структуре посевов ожидается увеличение доли засухоустойчивых и жаростойких культур (кукуруза, сорго, просо, нут), расширение площадей под масличными и зернобобовыми. Оптимизация системы удобрений и химизации с помощью технологий точного земледелия позволит на 15–20% повысить окупаемость средств интенсификации и минимизировать экологические риски. Экономия оросительной воды за счет водосберегающих технологий орошения составит 20–25%, что эквивалентно приросту irrigated crop yields by 10–15%.

Красюкова Н.Л.,
профессор кафедры государственного и муниципального управления
Финансовый университет при Правительстве Российской Федерации,
Россия
Krasnyukova@fa.ru

Фарманов Т.Х.,
профессор
Ташкентский государственный аграрный университет, Узбекистан
farmonov@rambler.ru

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Easterling W., Apps M. Assessing the Consequences of Climate Change for Food and Forest Resources: A View from the IPCC // Climatic Change. 2005; 70: 165–189.
2. Olesen J.E., Bindi M. Consequences of climate change for European agricultural productivity, land use and policy // European Journal of Agronomy. 2002; 16(4): 239–262.
3. Ewert F. et al. Crop modelling for integrated assessment of risk to food production from climate change // Environmental Modelling & Software. 2015; 72: 287–303.
4. Feng P. et al. Machine learning-based integration of remotely-sensed drought factors can improve the estimation of agricultural drought in South-Eastern Australia // Agricultural Systems. 2019; 173: 303–316.
5. Hoffman A.L. et al. Simulating the Effects of Climate Change on Rice Production in the Philippines Using Neural Networks and Bayesian Models // Global Environmental Change. 2021; 69: 102322.
6. Kadiyala M.D.M. et al. A Bayesian Framework to Assess Uncertainties in the Impacts of Climate Change on Yield and Adaptation Strategies in Rice // Scientific Reports. 2021; 11: 8932.
7. Peng B. et al. Dynamic Bayesian Network-Based Probabilistic Climate Model Ensemble Averaging for Seamless Crop Yield Prediction // Journal of Agricultural and Food Engineering. 2021; 1(1): 11.