

5. Maswada, H.F., Sunoj, V.S.J. & Prasad, P.V.V. (2021). A comparative Study on the Effect of Seed Pre-sowing Treatments with Microwave Radiation and Salicylic Acid in Alleviating the Drought-Induced Damage in Wheat. *J Plant Growth Regulation*, 40, 48–66. <https://doi.org/10.1007/s00344-020-10079-3>.

6. Soran, M. L., et al. (2014). Influence of microwave frequency electromagnetic radiation on terpene emission and content in aromatic plants. *Journal of Plant Physiology*, 171 (15), 1436–1443. <https://doi.org/10.1016/j.jplph.2014.06.013>.

7. Маймистов, В. В. Морфо-физиологические особенности засухоустойчивости высокопродуктивных сортов озимой пшеницы / В. В. Маймистов. – Текст: непосредственный // Научные труды. Юбилейный выпуск, посвященный 95-летию со дня рождения академика П. П. Лукьяненко. – 1996. – С. 238-246.

#### References

1. FAO. 2019. Proactive approaches to drought preparedness - Where are we now and where do we go from here? Rome. - 51 p.

2. Kiseleva, T.N. Formirovanie urozhaya zerna yarovoy pshenitsy v zavisimosti ot predposevnoy obrabotki semyan i fona pitaniya v Kemerovskom NIISKH / T.N. Kiseleva, O.V. Anokhina // Katalog vypusknykh kvalifikatsionnykh rabot Kuzbasskogo gosudarstvennogo agrarnogo universiteta - 2024. – Kemerovo: Kuzbasskiy GAU, 2024. – S. 59-61.

3. Degenkolbe, T., Do, P. T., Kopka, J., et al. (2013). Identification of drought tolerance markers in a diverse population of rice cultivars by expression and metabolite profiling. *PLoS One*, 8 (5), e63637. <https://doi.org/10.1371/journal.pone.0063637>.

4. Petin, V.A. Izmenenie sostava fotosinteticheskikh pigmentov u prorostkov yarovoy myagkoy pshenitsy pod deystviem osmoticheskogo stressa / V. A. Petin, L. P. Khlebova, S. B. Lepekhov // Vestnik Altayskogo gosudarstvennogo agrarnogo universiteta. – 2021. – No. 1. – S. 16-20.

5. Maswada, H.F., Sunoj, V.S.J. & Prasad, P.V.V. (2021). A comparative Study on the Effect of Seed Pre-sowing Treatments with Microwave Radiation and Salicylic Acid in Alleviating the Drought-Induced Damage in Wheat. *J Plant Growth Regulation*, 40, 48–66. <https://doi.org/10.1007/s00344-020-10079-3>.

6. Soran, M. L., et al. (2014). Influence of microwave frequency electromagnetic radiation on terpene emission and content in aromatic plants. *Journal of Plant Physiology*, 171 (15), 1436–1443. <https://doi.org/10.1016/j.jplph.2014.06.013>.

7. Maymistov, V.V. Morfo-fiziologicheskie osobennosti zasukhoustoychivosti vysokoproduktivnykh sortov ozimoy pshenitsy // Nauchnye trudy. Yubileynyy vypusk, posvyashchennyy 95-letiyu so dnya rozhdeniya akademika P.P. Lukyanenko. – 1996. – S. 238-246.



УДК 631.9:004.048

DOI: 10.53083/1996-4277-2025-249-7-9-15

О.С. Крылова, В.К. Каличкин

O.S. Krylova, V.K. Kalichkin

## МАШИННОЕ ОБУЧЕНИЕ ДЛЯ ПРОГНОЗИРОВАНИЯ УРОЖАЙНОСТИ ЯРОВОГО ЯЧМЕНЯ В ЗАВИСИМОСТИ ОТ АГРОКЛИМАТИЧЕСКИХ УСЛОВИЙ

### MACHINE LEARNING FOR FORECASTING SPRING BARLEY YIELD DEPENDING ON AGROCLIMATIC CONDITIONS

**Ключевые слова:** яровой ячмень, прогнозирование урожайности, машинное обучение, агроклиматические условия, лесостепь Приобья.

Представлены результаты исследования по прогнозированию урожайности ярового ячменя в зависимости от агроклиматических условий года возделывания с помощью методов машинного обучения. Для прогнозирования урожайности культуры ячменя использовали данные, полученные в полевом опыте лаборатории

генофонда растений СибНИИРС – филиала ИЦИГ СО РАН в 2014-2024 гг., расположенного в р.п. Краснообск Новосибирского района Новосибирской области. Агроклиматические ресурсы в годы исследований рассчитаны по данным АМС «Огурцово». Для обучения и тестирования моделей машинного обучения использовали три набора данных, содержащие в различном сочетании признаки и переменную отклика – урожайность ярового ячменя, г/м<sup>2</sup>. В качестве цифровых признаков использовали среднемесячные и среднедекадные тем-

пературы воздуха, °C; среднемесячные и среднедекадные количества осадков, мм; сумму температур воздуха  $\geq 10^{\circ}\text{C}$  за вегетационный период, °C; сумму осадков за осеннее-зимний период (с сентября по март), мм; продолжительность периода вегетации, дней. В качестве категориальных признаков выступали «сорт» и «год исследования». Для построения моделей прогнозирования урожайности ярового ячменя применяли линейную регрессию, линейную регрессию с кросс-валидацией, метод опорных векторов для регрессии (SVR), случайный лес (Random Forest) и гипероптимизированный градиентный бустинг (HGBost). Самая высокая точность прогнозирования урожайности культуры достигнута при реализации модели HGBost на всех наборах данных. Однако наибольшая точность (89,1 %) получена на наборе данных, содержащего среднемесячные значения температуры воздуха и количества осадков, продолжительность периода вегетации культуры, а также категориальные признаки «сорт» и «год исследования». Остальные модели машинного обучения уступали в точности прогнозов урожайности ярового ячменя модели HGBost. Точность прогнозирования не увеличивалась и при изменении структуры данных. Моделирование прогнозов урожайности ярового ячменя показало, что для достижения приемлемой точности работы модели HGBost достаточно минимального количества агроклиматических данных.

**Keywords:** *spring barley, yield forecasting, machine learning, agroclimatic conditions, forest-steppe of Ob River area.*

The research findings on forecasting spring barley yields depending on the agroclimatic conditions of the growing season using machine learning methods are discussed. To forecast barley yields, we used the data

obtained from 2014 through 2024 in the field experiment of the Plant Gene Pool Laboratory of the Siberian Research Institute of Plant Production and Breeding (Branch of the Institute of Cytology and Genetics, Siberian Branch of the Russian Academy of Sciences) located in Krasnoobsk of the Novosibirsk Region. The agroclimatic resources during the years of research were calculated based on the data of the Ogurtsovo Agro-Meteorological Station. To train and test the machine learning models, we used three data sets containing various combinations of characters and the response variable - spring barley yield, g m<sup>2</sup>. The following digital characters were used: average monthly and average ten-day air temperatures, °C; average monthly and average ten-day precipitation amounts, mm; accumulated air temperatures  $\geq 10^{\circ}\text{C}$  during the growing season, °C; total precipitation for the autumn-winter period (from September to March), mm; the duration of the growing season, days. The category characters were "variety" and "year of research". Linear regression, linear regression with cross-validation, support vector machine for regression (SVR), random forest (RandomForest), and hyper-optimized gradient boosting (HGBost) were used to construct models for predicting spring barley yields. The highest accuracy of crop yield forecasting was achieved when implementing the HGBost model in all data sets. However, the highest accuracy (89.1%) was obtained in the data set containing average monthly air temperature and precipitation values, crop growing season duration, and the category characters "variety" and "year of research". The other machine learning models were inferior to the HGBost model regarding the accuracy of spring barley yield forecasts. The forecasting accuracy did not increase even when the data structure was changed. The modeling of spring barley yield forecasts showed that minimum amount of agroclimatic data was sufficient to achieve acceptable accuracy of the HGBost model.

**Крылова Ольга Сергеевна**, аспирант, мл. науч. сотр., Сибирский федеральный научный центр агробиотехнологий РАН, р.п. Краснообск, Новосибирская обл., Российская Федерация, e-mail: olgakrylova775@gmail.com.

**Каличкин Владимир Климентьевич**, д.с.-х.н., профессор, гл. науч. сотр., Сибирский федеральный научный центр агробиотехнологий РАН, р.п. Краснообск, Новосибирская обл., Российская Федерация, e-mail: vk.kalichkin@gmail.com.

**Krylova Olga Sergeevna**, post-graduate student, Junior Researcher, Siberian Federal Scientific Center of Agro-Biotechnologies of Russian Academy of Sciences, Krasnoobsk, Novosibirsk Region, Russian Federation, e-mail: olgakrylova775@gmail.com.

**Kalichkin Vladimir Klimentevich**, Dr. Tech. Sci., Professor, Chief Researcher, Siberian Federal Scientific Center of Agro-Biotechnologies of Russian Academy of Sciences, Krasnoobsk, Novosibirsk Region, Russian Federation, e-mail: vk.kalichkin@gmail.com.

## Введение

Варьирование урожайности любой сельскохозяйственной культуры во многом зависит от агроклиматических условий года возделывания. Например, в работе [1] показано, что коэффициент вариации урожайности ярового ячменя в конкурсном сортоиспытании за 20 лет наблюдений в зависимости от условий тепло- и влагообеспеченности в Московской области составлял 35,6%. В условиях Оренбургской области

урожайность ярового ячменя изменялась от 0,8 т/га в острозасушливых условиях вегетации до 1,83 т/га – во влажных [2]. Также установлено, что в 49% случаев (почти каждый второй год) урожайность этой культуры в Оренбургской области детерминировалась суммой осадков мая и июня [3]. В Тюменской области в среднем за 2014-2019 гг. коэффициент вариации урожайности различных сортов ячменя в зависимости от температуры воздуха и количества выпадавших

осадков изменялся от 11,9 до 25,7% [4]. Наибольшая чувствительность к теплообеспеченности и недостатку влаги у ячменя наблюдалась в период кущения и трубкования, когда закладываются побеги кущения и идет формирование элементов продуктивности колоса [5].

В то же время урожайность сельскохозяйственных культур является ключевым показателем эффективности земледелия. Природно-климатические условия территории не могут контролироваться человеком, но могут учитываться при прогнозировании возможной урожайности возделываемых культур. В последние годы прогнозирование урожайности сельскохозяйственных культур стало приоритетным направлением исследований в сельскохозяйственной предиктивной аналитике и цифровизации земледелия, играя заметную роль в повышении эффективности сельскохозяйственного производства [6, 7]. Точное и своевременное прогнозирование урожайности сельскохозяйственных культур имеет большое значение для обоснования принятия решений по выбору культур, их сортов и агротехнологий.

В последние годы стали активно развиваться методы прогнозирования урожайности сельскохозяйственных культур с помощью машинного обучения (МО). Методы МО тесно связаны с извлечением информации из эмпирических данных. Совокупность экспериментальных данных представляет собой набор ситуаций и возможных откликов, между которыми существует некоторая неизвестная зависимость. Хотя в моделях МО можно учитывать множество переменных, влияющих на рост и урожайность сельскохозяйственных культур, температура и количество осадков чаще всего применяются в качестве предикторов урожайности. Как правило, в этих моделях используется метеорологическая статистика (например, среднее значение) за вегетационный период (или его часть). Составление прогнозов на основе временных рядов позволяет получать информацию, помогающую решать многие задачи. В МО принято использовать непараметрические, нелинейные и многомерные модели [8-10].

В условиях рискованного земледелия Западной Сибири проблема разработки надежного и точного метода прогнозирования урожайности сельскохозяйственных культур приобретает особую важность вследствие высокого коэффициента вариации урожайности и значительной

доли неурожайных лет. Например, по данным [11], в Новосибирской области в многолетнем цикле 2 года из 10 являются неурожайными. Существенная изменчивость уровней урожайности и асинхронность их циклических колебаний обуславливают значительные экономические риски, которые можно снизить с помощью надежного метода прогнозирования урожайности сельскохозяйственных культур.

**Цель** исследований – разработка моделей МО для прогнозирования урожайности ярового ячменя в зависимости от агроклиматических условий года возделывания.

#### **Задачи исследований:**

- 1) создать обучающие и тестовые выборки данных урожайности ярового ячменя и агроклиматических условий;
- 2) разработать модели МО для прогнозирования урожайности ярового ячменя и обучить их на разных наборах данных;
- 3) провести оценку точности моделей прогнозирования урожайности ярового ячменя;
- 4) выбрать оптимальный набор данных для прогнозирования урожайности ярового ячменя.

#### **Объекты и методы исследований**

В исследованиях по разработке моделей машинного обучения (МО) для прогнозирования урожайности ярового ячменя использовали данные, полученные в полевом опыте лаборатории генофонда растений СибНИИРС – филиала ИЦИГ СО РАН в 2014-2024 гг. Опытное поле расположено в р.п. Краснообск Новосибирского района Новосибирской области и в соответствии с агроэкологическим районированием относится к лесостепному Приобскому агроландшафтному району [11]. Климат района – умеренно теплый, умеренно увлажненный.

В опыте изучали 62 сорта ярового ячменя разных сроков спелости, районированные по Западно-Сибирскому (10) и Восточно-Сибирскому (11) регионам [12]. Агротехника при проведении опыта – общепринятая для данной зоны. Площадь делянки 1 м<sup>2</sup>, срок посева – первая-вторая декада мая. Норма высева 500 всхожих семян на 1 м<sup>2</sup>. В полевом опыте проводили фенологические наблюдения, учёт урожайности ярового ячменя и продолжительности вегетационного периода. Агроклиматические ресурсы в годы исследований рассчитывали по данным АМС «Огурцово» (источник данных: web-ресурс «<http://www.pogodaiklimat.ru>»).

Количество атмосферных осадков значительно варьировало как по годам, так и по месяцам. Общая сумма осадков с апреля по август изменялась от 150 мм в 2022 г. до 418 мм в 2024 г., то есть количество осадков в наиболее влагообеспеченный год было в 2,8 раза больше, чем в наиболее засушливый. Выпадение атмосферных осадков по месяцам не имело какой-либо циклической или другой систематической зависимости.

Температура воздуха варьировала менее значительно, чем осадки. Наиболее значительно изменялись температуры весенних месяцев. Средняя температура апреля за период исследования изменялась от +1,1°C в 2023 г., что ниже среднемноголетней нормы на 2,5°C, до +8,1°C в 2020 г., что выше нормы на 5,8°C. Средняя температура мая варьировала от +7,0°C в 2018 г. (ниже нормы на 3,9°C) до +15,5°C в 2020 г. (выше нормы на 4,6°C). Средняя температура летних месяцев (июнь, июль и август), как правило, изменялась в пределах от +16 до +20°C, и только на протяжении двух лет (2023 и 2024 гг.) средняя температура июля превысила +20°C и в оба года составляла +21,6°C, что на 2,2°C выше нормы.

Для прогнозирования урожайности ярового ячменя при обучении и тестировании моделей МО использовали разные наборы цифровых и категориальных данных и переменную отклика – урожайность ярового ячменя, г/м<sup>2</sup>:

- набор данных № 1 содержал среднемесячные значения температуры воздуха и количества осадков, продолжительность периода вегетации культуры, а также категориальные признаки «сорт» и «год исследования»;

- набор данных № 2 содержал среднемесячные и среднедекадные значения температуры воздуха, среднемесячные и среднедекадные количества осадков, продолжительность периода вегетации культуры, а также категориальные признаки «сорт» и «год исследования»;

- набор данных № 3 содержал все данные из набора № 1, а также сумму температур  $\geq 10^\circ\text{C}$  за вегетационный период, сумму осадков за осенне-зимний период (октябрь-март), значения среднемесячной температуры воздуха и количества осадков за сентябрь.

Предварительная обработка данных для моделей МО заключалась в удалении отсутствующих значений, поиске выбросов, нормализации данных и преобразовании формата данных. Для

преобразования формата категориальных признаков применяли метод One Hot Encoding. Кроме того, производили оценку тесноты связи между параметрами для включения их в набор данных для МО с помощью корреляционного анализа. Для оценки силы связи между двумя наблюдаемыми величинами использовали шкалу Чеддока.

Предварительную обработку данных, а также построение и обучение моделей МО проводили в среде Google Colab с помощью стандартных библиотек Python (Pandas, Numpy, Scikit-Learn и др.). Для прогнозирования урожайности применяли модели МО: линейная регрессия, линейная регрессия с кросс-валидацией, метод опорных векторов для регрессии (SVR), случайный лес (Random Forest) и гипероптимизированный градиентный бустинг (HGBBoost). Для построения моделей данные были разделены в соотношении 80:20, где 80% использовали для обучения моделей, а оставшиеся 20% – для тестирования их качества.

Оценку предсказательной точности моделей МО проводили с помощью метрик MAE (средняя абсолютная ошибка), RMSE (среднеквадратичная ошибка) и  $R^2$  (коэффициент детерминации).

### Результаты и их обсуждение

Результаты анализа производительности моделей МО показали, что наиболее высокая точность прогнозирования при обучении на всех наборах данных наблюдалась у модели HGBBoost: от 88,7% на наборе данных № 2 до 89,1% на наборе данных № 1 (табл.).

Второй по точности результат показала модель Random Forest. При обучении на всех наборах данных ее показатели точности были незначительно ниже, чем у модели HGBBoost – 83,7-83,8%. На третьем месте по точности была модель SVR. Точность прогнозирования этим методом для всех наборов данных была около 73%.

Наиболее низкая точность прогнозирования отмечалась у модели линейной регрессии, она была одинаковой для наборов данных № 1 и 2 (72,2%) и на 0,2% ниже для набора данных № 3. При использовании метода линейной регрессии с кросс-валидацией для набора данных № 1 точность прогнозирования снизилась на 3,4%, для набора № 3 – на 5,2%, а для набора данных № 2 увеличилась на 1,6%.



**Результаты оценки точности моделей прогнозирования урожайности ярового ячменя**

Модель	Набор данных № 1			Набор данных № 2			Набор данных № 3		
	MAE, г/м <sup>2</sup>	RMSE, г/м <sup>2</sup>	R <sup>2</sup>	MAE, г/м <sup>2</sup>	RMSE, г/м <sup>2</sup>	R <sup>2</sup>	MAE, г/м <sup>2</sup>	RMSE, г/м <sup>2</sup>	R <sup>2</sup>
Линейная регрессия	101,7	126,7	0,722	101,8	126,7	0,722	101,9	126,8	0,720
Линейная регрессия с кросс-валидацией	99,2	126,7	0,688	99,3	126,7	0,738	99,6	127,1	0,682
SVR	95,5	125,4	0,727	98,6	124,8	0,730	95,5	125,7	0,729
Random Forest	79,0	96,6	0,838	79,7	96,9	0,837	79,8	96,8	0,837
HGBoost	63,4	79,2	0,891	64,1	80,6	0,887	64,5	80,1	0,889

Из данных таблицы следует, что использование для обучения моделей МО набора данных № 1 несколько повышает точность прогнозирования урожайности по сравнению с двумя другими наборами данных. Можно констатировать, что оптимальный набор данных для прогнозирования урожайности ярового ячменя содержал среднемесячные значения температуры воздуха и количества осадков с апреля по август, а также значения продолжительности периода вегетации и категориальные признаки «сорт» и «год исследования».

Добавление к этому набору данных среднедекадных значений температуры воздуха и осадков не дало увеличения точности прогнозов урожайности ярового ячменя, однако при этом значительно усложнило сбор и обработку данных для прогнозирования. Не дало увеличения точности прогнозов урожайности культуры и использование в качестве обучающих признаков данных о температуре воздуха и осадках за сентябрь, что, вероятно, объясняется коротким вегетационным периодом ярового ячменя.

Также было показано, что использование в качестве обучающих признаков данных о сумме температур  $\geq 10^{\circ}\text{C}$  за вегетационный период и данных о сумме осадков за осенне-зимний период (с октября по март) не сопровождалось увеличением точности прогнозов урожайности ярового ячменя.

### Выводы

Наилучшие результаты прогнозирования урожайности ярового ячменя в зависимости от агроклиматических условий года возделывания показала модель HGBoost на всех наборах данных, с некоторым увеличением точности на наборе данных № 1 (89,1%). На втором месте по

производительности была модель Random Forest. Эта модель оказалась практически не чувствительной к структуре и объему данных и имела одинаковую точность на всех наборах данных (84%). Наименьшая точность прогнозирования была получена при реализации модели линейной регрессии с кросс-валидацией (68,2%).

Оптимальный набор данных для прогнозирования урожайности ярового ячменя содержал среднемесячные значения температуры воздуха и количества осадков за период с апреля по август, продолжительность периода вегетации и категориальные признаки «сорт» и «год исследования».

Добавление к перечисленным признакам среднедекадных значений температуры воздуха и количества осадков, суммы эффективных температур ( $\geq 10^{\circ}\text{C}$ ) за вегетационный период, суммы осадков за осенне-зимний период (октябрь-март), а также данных о погодных условиях за сентябрь не дало увеличения точности прогнозов урожайности, поэтому использование указанных данных для прогнозирования урожайности ярового ячменя не является целесообразным.

### Библиографический список

1. Влияние агрометеорологических изменений климата на зерновую продуктивность ярового ячменя в условиях Нечерноземной зоны РФ / О. В. Левакова, И. А. Дедушев, Л. М. Ерошенко, М. М. Ромахин [и др.]. – DOI 10.18470/1992-1098-2022-1-128-135. – Текст: непосредственный // Юг России: экология, развитие. – 2022. – Т. 17, № 1 (62). – С. 128-135.
2. Митрофанов Д. В. Воздействие агрометеорологических условий, минеральных удобрений

ний, предшественников и влажности почвы на урожайность зерна ярового ячменя в степной зоне Южного Урала / Д. В. Митрофанов, Т. А. Ткачёва. – DOI 10.32786/2071-9485-2021-04-09. – Текст: непосредственный // Известия Нижневолжского агроуниверситетского комплекса: наука и высшее профессиональное образование. – 2021. – № 4 (64). – С. 84-97.

3. Камалеев, Р. Д. Зависимость урожайности ярового ячменя от метеорологических условий в центральной зоне Оренбургской области / Р. Д. Камалеев, О. С. Гречишкина. – DOI 10.32786/2071-9485-2023-02-18. – Текст: непосредственный // Известия Нижневолжского агроуниверситетского комплекса: наука и высшее профессиональное образование. – 2023. – № 2 (70). – С. 160-167.

4. Якубышина, Л. И. Влияние климатического потенциала Тюменской области на экологическую пластичность сортов ярового ячменя / Л. И. Якубышина, О. А. Шахова. – Текст: непосредственный // Вестник Мичуринского государственного аграрного университета. – 2022. – № 1 (68). – С. 50-54.

5. Влияние агрометеорологических условий на урожай зерна ярового ячменя в условиях Среднего Поволжья / А. А. Бишарев, С. Н. Шевченко, Е. В. Мадьякин [и др.]. – Текст: непосредственный // Известия Самарского научного центра Российской академии наук. – 2018. – Т. 20, № 2-4. – С. 667-670.

6. Абрамов, Н. В. Цифровые технологии – новые вызовы и решения в продуцировании агроэкосистем / Н. В. Абрамов, С. А. Семизоров, М. Ф. Трифонова. – Текст: непосредственный // Известия Международной академии аграрного образования. – 2023. – Вып. 65. – С. 73-79.

7. Darra, N., Anastasiou, E., Kriezi, O., et al. (2023). Can yield prediction be fully digitized? A systematic review. *Agronomy*, 13 (9). R. 2441. <https://doi.org/10.3390/agronomy13092441>.

8. Разработка программы анализа и прогнозирования урожайности сельскохозяйственных культур / В. К. Каличкин, Д. С. Федров, О. К. Альсова, К. Ю. Максимович. – DOI 10.53859/02352451\_2022\_36\_0\_0. – Текст: непосредственный // Достижения науки и техники АПК. – 2022. – Т. 36, № 1. – С. 51-56.

9. Elbasi, E., Zaki, C., Topcu, A. E., et al. (2023). Crop Prediction Model Using Machine Learning Algorithms. *Applied Sciences*, 13 (16), 9288. <https://doi.org/10.3390/app13169288>.

10. Momenpour, S.E., Bazgeer, S., Moghbel, M. (2024). A bibliometric analysis of the literature on crop yield prediction: insights from previous findings and prospects for future research. *Int J Biometeorol.* 68, 829–842 (2024). <https://doi.org/10.1007/s00484-024-02628-2>.

11. Адаптивно-ландшафтные системы земледелия Новосибирской области / РАСХН Сиб. отделение. СибНИИЗХим. – Новосибирск, 2002. – 388 с. – Текст: непосредственный.

12. Государственный реестр селекционных достижений, допущенных к использованию (по состоянию на 31.05.2024 г.). – URL: <https://gossortrf.ru/publication/reestry.php>. (дата обращения: 30.03.2025). – Текст: электронный.

## References

1. Levakova O.V. Vliyanie agrometeorologicheskikh izmeneniy klimata na zernovuyu produktivnost yarovogo yachmenya v usloviyakh Nechernozemnoy zony RF / O.V. Levakova, I.A. Dedushev, L.M. Eroshenko, M.M. Romakhin, A.N. Eroshenko, N.A. Eroshenko, M.A. Boldyrev, O.V. Gladysheva // *Yug Rossii: ekologiya, razvitie*. – 2022. – Т. 17. – No. 1 (62). – S. 128-135. – DOI 10.18470/1992-1098-2022-1-128-135.

2. Mitrofanov D.V. Vozdeystvie agrometeorologicheskikh usloviy, mineralnykh udobreniy, predshestvennikov i vlazhnosti pochvy na urozhaynost zerna yarovogo yachmenya v stepnoy zone Yuzhnogo Urala / D.V. Mitrofanov, T.A. Tkacheva // *Izvestiya NV AUK*. – 2021. – No. 4 (64). – S. 84-97. – DOI 10.32786/2071-9485-2021-04-09.

3. Kamaleev R.D. Zavisimost urozhaynosti yarovogo yachmenya ot meteorologicheskikh usloviy v tsentralnoy zone Orenburgskoy oblasti / R.D. Kamaleev, O.S. Grechishkina // *Izvestiya Nizhnevolzhskogo agrouniversitetskogo kompleksa: nauka i vysshee professionalnoe obrazovanie*. – 2023. – No. 2 (70). – S. 160-167. – DOI 10.32786/2071-9485-2023-02-18.

4. Yakubysheva L.I. Vliyanie klimaticheskogo potentsiala Tyumenskoy oblasti na ekologicheskuyu plastichnost sortov yarovogo yachmenya / L.I. Yakubysheva, O.A. Shakhova // *Vestnik Michurinskogo gosudarstvennogo agrarnogo universiteta*. – 2022. – No. 1 (68). – S. 50-54.

5. Bisharev A.A. Vliyanie agrometeorologicheskikh usloviy na urozhay zerna yarovogo yachmenya v usloviyakh Srednego Povolzhya / A.A. Bisharev, S.N. Shevchenko, E.V. Madyakin, I.A. Kalyakulina, M.A. Dyuldina, T.V. Dvortsova //

Izvestiya Samarskogo nauchnogo tsentra Rossiyskoy akademii nauk. – 2018. – T. 20. – No. 2-4. – S. 667-670.

6. Abramov N.V. Tsifrovye tekhnologii – novye vyzovy i resheniya v produtsirovani agroekosistem / N.V. Abramov, S.A. Semizorov, M.F. Trifonova // Izvestiya MAAO. – 2023. – Vyp. 65. – S. 73-79.

7. Darra, N., Anastasiou, E., Kriezi, O., et al. (2023). Can yield prediction be fully digitized? A systematic review. *Agronomy*. 13 (9). R. 2441. <https://doi.org/10.3390/agronomy13092441>.

8. Kalichkin V.K. Razrabotka programmy analiza i prognozirovaniya urozhaynosti selskokhozyaystvennykh kultur / V.K. Kalichkin, D.S. Fedrov, O.K. Alsova, K.Yu. Maksimovich // Dostizheniya nauki i tekhniki APK. – 2022. – T. 36. – No. 1. – S. 51-56. – DOI: 10.53859/02352451\_2022\_36\_0\_0.

9. Elbasi, E., Zaki, C., Topcu, A. E., et al. (2023). Crop Prediction Model Using Machine

Learning Algorithms. *Applied Sciences*, 13 (16), 9288. <https://doi.org/10.3390/app13169288>.

10. Momenpour, S.E., Bazgeer, S., Moghbel, M. (2024). A bibliometric analysis of the literature on crop yield prediction: insights from previous findings and prospects for future research. *Int J Biometeorol.* 68, 829–842 (2024). <https://doi.org/10.1007/s00484-024-02628-2>.

11. Adaptivno-landshaftnye sistemy zemledeliya Novosibirskoy oblasti / RASKHN Sib. otделение. SiBNII ZKhim. – Novosibirsk, 2002. – 388 s.

12. Gosudarstvennyy reestr selektsionnykh dostizheniy, dopushchennykh k ispolzovaniyu (po sostoyaniyu na 31.05.2024 g.). – URL: <https://gossortrf.ru/publication/reestry.php>. (data obrashcheniya 30.03.2025).

*Выражаем глубокую признательность за предоставленные данные А.Я. Сотнику, к.с.-х.н., ведущему научному сотруднику лаборатории генофонда растений СибНИИРС – филиала ИЦИГ СО РАН.*



УДК 635.654:632.954(571.13)

DOI: 10.53083/1996-4277-2025-249-7-15-19

Е.С. Гольцман, Н.А. Рендов,  
Е.В. Некрасова, С.И. Мозылева  
E.S. Goltsman, N.A. Rendov,  
E.V. Nekrasova, S.V. Mozyleva

## ВОЗМОЖНЫЕ СРОКИ ГЕРБИЦИДНОЙ ОБРАБОТКИ ПОСЕВОВ ГОРОХА СОРТА САНТАНА В ЮЖНОЙ ЛЕСОСТЕПИ ОМСКОЙ ОБЛАСТИ

### POSSIBLE TIMING OF HERBICIDE TREATMENT OF PEA CROPS OF THE SANTANA VARIETY IN THE SOUTHERN FOREST-STEPPE OF THE OMSK REGION

**Ключевые слова:** горох, гербицид, аммофос, выживаемость, доля сорных растений, урожайность зерна.

Приводятся данные исследований, полученные на учебно-опытном поле Омского ГАУ в 2020-2024 гг. Почва опытного участка лугово-черноземная среднесиловатая, малогумусовая среднесуглинистая. Сорт гороха Сантана высевался с нормой 1 млн всхожих зерен на 1 га. Опыты закладывались на 2 фонах: без удобрений и с внесением аммофоса ( $N_{12}P_{52}$ ) локально при посеве. Обработку посевов гербицидом Гермес, МД (0,8 л/га) проводили в фазу образования 2-3 настоящих листьев, а затем через 5 и 10 сут. после 1-й обработки. Расход рабочей жидкости составлял 200 л/га. Повторность в опыте 4-кратная, площадь деланки 60 м<sup>2</sup>. Четыре из 5 лет исследований характеризовались как засушли-

вые, и только в 2024 г. ГТК был равен 1,67. Результаты исследований показали, что при сдвигании срока обработки посевов гороха гербицидом показатели выживаемости и урожайности зерна гороха снижались, а доля сорной растительности в агрофитоценозе, наоборот, увеличивалась. Выживаемость растений гороха колебалась по годам от 59,0 до 62,0% при 1-й обработке посевов гороха и постепенно снижалась при последующих обработках через 5 и 10 сут. Доля сорных растений при обработке в фазу 2-3 настоящих листьев составляла 6,49 и 6,98% в зависимости от фона удобрения и возрастала до 7,09 и 7,42% при обработке через 10 дней. Урожайность зерна гороха на удобренном фоне при 1-й обработке гербицидом составила 3,28 т/га и снижалась при более поздних обработках до 3,20-3,03 т/га. Внесение аммофоса обеспечивало прибавку урожайности зерна на 0,10-0,17 т/га.