

МЕТОДИКА ПРОСТРАНСТВЕННОГО ПРОГНОЗИРОВАНИЯ АГРОПРОМЫШЛЕННОГО ПРОИЗВОДСТВА НА ОСНОВЕ ГЕОИНФОРМАЦИОННЫХ СИСТЕМ В РЕСПУБЛИКЕ БЕЛАРУСЬ

А.А. Мозоль, Е.С. Павлов, Р.М. Савицкий*

Аннотация. Настоящая статья посвящена практическому применению математических и статистических моделей пространственного прогнозирования в аграрной экономике с использованием геоинформационных систем (ГИС). Основное внимание уделяется оценке эффективности и точности таких моделей по сравнению с традиционными методами агроэкономического анализа. Рассматриваются примеры успешного применения различных видов пространственных моделей, включая регрессионный анализ с пространственными лагами, геостатистические методы и алгоритмы машинного обучения, для задач прогнозирования урожайности, оптимизации землепользования и оценки агресурсного потенциала. Результаты исследования показывают, что современные ГИС-технологии и методы пространственного анализа являются мощным инструментом для выявления территориальных закономерностей, оценки рисков и формирования стратегий развития аграрного сектора. Вместе с тем их применение требует учета пространственной автокорреляции, качества геоданных, а также профессиональной интерпретации результатов со стороны исследователей и аграрных аналитиков.

Ключевые слова: пространственное прогнозирование, геоинформационные системы, аграрная экономика, урожайность, землепользование, геостатистика, пространственные модели, агресурсный потенциал, почвенно-климатические условия.

JEL-классификация: C41, C82, Q01, Q16, Q18.

DOI: 10.46782/1818-4510-2026-2-37-50

Материал поступил 12.03.2026 г.

Прогнозирование урожайности и эффективности землепользования является одной из центральных задач современной аграрной экономики и территориального планирования. Значимость этой проблемы обусловлена высокой изменчивостью почвенно-климатических условий, усложнением экологических и экономических факторов, а также растущим объемом пространственных данных. Точность прогнозов напрямую влияет на эффективность агро-

технологий, управление ресурсами и формирование стратегий развития сельских территорий, что делает разработку надежных и адаптивных моделей особенно актуальной. В последние годы наблюдается переход от локальных оценок к комплексным пространственным решениям, способным учитывать широкий спектр факторов и обрабатывать большие массивы геоданных. При этом динамика природно-хозяйственных систем требует сочетания классичес-

* Мозоль Алеся Александровна (a.mozol@aol.com), кандидат экономических наук, доцент, Белорусский государственный экономический университет (г. Минск, Беларусь); <https://orcid.org/0009-0005-3624-0860>;

Павлов Евгений Сергеевич (evgeny310805@gmail.com), Белорусский государственный университет информатики и радиоэлектроники (г. Минск, Беларусь); <https://orcid.org/0009-0001-2266-6095>;

Савицкий Руслан Михайлович (savickiy.ruslan@gmail.com), Белорусский государственный университет информатики и радиоэлектроники (г. Минск, Беларусь); <https://orcid.org/0009-0005-5634-638X>

ких статистических методов, обеспечивающих интерпретируемость результатов, с современными инструментами геоинформационного моделирования и машинного обучения, позволяющими выявлять нелинейные и пространственные зависимости.

В рамках исследования предлагается унифицированная модель пространственного прогнозирования, ориентированная на анализ агрегированных агроэкономических показателей с использованием геоинформационных систем. Такой подход позволяет интегрировать разнородные данные – почвенные, климатические, инфраструктурные и экономические – и создавать комплексные пространственные модели, менее подверженные локальным аномалиям и фрагментарности информации. Особое внимание уделяется моделированию пространственной автокорреляции и вариабельности, поскольку именно эти характеристики определяют устойчивость агросистем и риски возникновения кризисных явлений, что подтверждается историческими примерами неурожая и деградации земель. Кроме того, построение прогностической модели невозможно без учета ключевых факторов, таких как качество почв, режим увлажнения, уровень агротехнологий и доступность инфраструктуры, которые системно влияют на продуктивность территорий.

Целью работы является разработка и верификация многомерной пространственной эконометрической модели для прогнозирования агроэкономических показателей на основе сочетания геоданных, статистики сельскохозяйственного производства и ключевых природно-хозяйственных переменных. Исследование основано на данных по регионам Беларуси за период 2021–2022 гг. и направлено не только на построение точечных и интервальных прогнозов, но и на проведение полного статистического и экономико-географического анализа значимости факторов, проверки адекватности модели и оценки ее прогностической силы.

Научная новизна исследования заключается в следующем:

- впервые для условий Республики Беларусь реализован комплексный подход к построению пространственной эконометрической модели (SAR) урожайности, ин-

тегрирующий принципы эконометрики, геостатистики и ГИС-анализа на уровне административных районов;

- разработан и апробирован алгоритм сценарного прогнозирования на языке Python, позволяющий количественно оценивать не только прямые, но и косвенные (распространяющиеся по сети соседства) эффекты от изменений агроэкономических факторов;

- получены количественные оценки силы пространственной зависимости (коэффициент ρ) в аграрном секторе Беларуси, подтверждающие гипотезу о значимой диффузии технологий и эффектах соседства между районами.

Пространственное прогнозирование агроэкономических показателей, таких как урожайность сельскохозяйственных культур, остается одной из центральных задач современной аграрной аналитики, экономики природопользования и территориального планирования. Значимость этой проблемы обусловлена высокой пространственной и временной изменчивостью почвенно-климатических условий, усложнением экологических и экономических факторов, а также экспоненциальным ростом объема доступных геопространственных данных. Точность и детализация прогнозов напрямую влияют на эффективность агротехнологий, оптимизацию ресурсопотребления (воды, удобрений), управление рисками и формирование стратегий регионального развития, что делает разработку надежных, масштабируемых и интерпретируемых моделей особенно актуальной (Анселин, 1988). Современные исследования закономерно эволюционируют от простой пространственной статистики к комплексным системам, сочетающим классические эконометрические подходы, методы геостатистики и передовые алгоритмы машинного обучения, интегрированные в геоинформационные системы (ГИС). Это позволяет не только повысить точность прогнозов, но и адаптировать модели к локальным условиям и динамически меняющейся среде.

Для решения этой задачи применяется широкий спектр методов. Пространственные эконометрические модели, такие как модели с пространственными лагами (SAR – Spatial Autoregressive Model) и модели с

пространственными ошибками (SEM – Spatial Error Model), являются основным инструментом для учета пространственной зависимости между наблюдаемыми единицами (районами, хозяйствами). Исследование Дж. Лесажа и Р. Келли Паса на данных по урожайности кукурузы в штате Айова (США) демонстрирует, что явное моделирование пространственной автокорреляции через матрицу весов позволяет повысить объясняющую способность модели (R^2) на 25–30% по сравнению с обычной регрессией, игнорирующей пространственный контекст¹. При этом для агроданных характерна выраженная сезонность и цикличность, что требует интеграции методов анализа временных рядов или использования панельных пространственных моделей.

Большое значение в объяснении пространственной вариабельности урожайности имеют природные факторы и данные дистанционного зондирования Земли (ДЗЗ). Продовольственная и сельскохозяйственная организация ООН (FAO) в своих глобальных проектах по оценке земельных ресурсов (Global Land Assessment) использует комплексные модели, которые объясняют 40–60% дисперсии урожайности через интеграцию мультиспектральных спутниковых индексов (например, NDVI – индекс вегетации), цифровых моделей рельефа и климатических параметров. Исследование об использовании статистических моделей для прогнозирования урожайности в зависимости от климатических изменений (Lobell, 2010) показывает, что модели, основанные на машинном обучении и спутниковых данных за вегетационный период, позволяют прогнозировать урожайность пшеницы в ключевых регионах с ошибкой (RMSE) менее 10% за 2–3 месяца до сбора урожая.

В поисках большей точности и возможности работы с высокоразмерными данными исследователи активно обращаются к методам машинного обучения, адаптированным для пространственного анализа. Сравнение таких алгоритмов, как случайный лес (Random Forest) и градиентный бустинг

(Gradient Boosting), в задаче прогноза урожайности сои в Бразилии показало преимущество ансамблевых методов. Значение RMSE для градиентного бустинга оказалось на 18% ниже, а карты прогнозной продуктивности, сформированные на его основе, позволили оптимизировать размещение культур с экономическим эффектом в 12–15% дополнительной рентабельности на уровне хозяйства (Zhang, Wang M., Wang N., 2002). Эксперименты также выявили, что включение производных ГИС-индикаторов (топографический индекс влажности, индекс суровости климата) существенно улучшает точность, тогда как некорректная обработка пространственной автокорреляции в данных для алгоритмов типа РСА может приводить к переобучению и росту ошибки.

Отдельное критически важное направление – это прогнозирование пространственно-временной динамики рисков (засухи, эрозия, засоление), что напрямую связано с устойчивостью агросистем. Наибольшую эффективность в условиях неоднородности и нестационарности демонстрируют гибридные модели, сочетающие геостатистику и машинное обучение. Исследование на данных по деградации земель в Казахстане выявило, что модель географически взвешенной регрессии (GWR) оптимально фиксирует локальные неоднородности влияния факторов, в то время как пространственно-временные модели с латентными эффектами лучше адаптируются к анализу панельных данных благодаря учету не наблюдаемых индивидуальных особенностей регионов (Fotheringham, Brunsdon, Charlton, 2002). Такие модели на 20–30% точнее предсказывают зоны высокого риска в периоды экстремальных явлений, поскольку учитывают не только текущие условия, но и пространственно-временные лаги воздействующих факторов.

Таким образом, современный подход к пространственному прогнозированию в аграрной экономике носит комплексный и междисциплинарный характер. Он основан на следующих ключевых принципах:

- грамотный сбор, интеграция и тщательная предобработка гетерогенных геоданных (согласование пространственных слоев (приведение к единой проекции и разрешению), очистка от выбросов и, что кри-

¹ LeSange J., Pace R.K. 2020. *Interpreting Spatial Econometric Models*. Handbook of Regional Science. Second and Extended Edition. PP. 2201–2218. DOI:10.1007/978-3-662-60723-7_91

тически важно, диагностика и учет пространственной автокорреляции);

- комбинирование методологий (использование как классических пространственно-эконометрических моделей (SAR, SEM, GWR) для проверки теоретических гипотез и оценки структурных зависимостей, так и алгоритмов машинного обучения (градиентный бустинг, нейронные сети) для выявления сложных нелинейных взаимодействий и паттернов в больших данных (Big Data));

- многофакторный пространственный анализ (интеграция почвенных, климатических, гидрологических, экономических (цены, субсидии) и инфраструктурных показателей в единую ГИС-ориентированную модель);

- строгая пространственная статистическая верификация (проверка моделей на значимость (F - и t -критерии с поправками на пространственную зависимость), анализ пространственной автокорреляции остатков (тесты Морана, Лагранжа), сравнение прогнозной точности через пространственную кросс-валидацию (Spatial Cross-Validation) и набор метрик (RMSE, MAPE, индекс пространственного соответствия).

В исследовании в качестве объекта выступает пространственное распределение урожайности зерновых культур (пшеница, ячмень) по административным районам Республики Беларусь, являющееся интегральным индикатором эффективности аграрного производства и природно-ресурсного потенциала. Эмпирическую базу исследования составляют данные, представляющие собой совмещенные во времени и пространстве статистические показатели (урожайность, посевные площади, внесение удобрений) и тематические ГИС-слои (цифровые почвенные карты, растровые климатические данные, векторные слои инфраструктуры), что позволяет проводить комплексный пространственно-временной анализ и строить прогнозные модели на основе репрезентативной панели данных.

Теоретические основы пространственного прогнозирования в аграрной экономике сформировались на стыке региональной науки, экономической географии и эконометрики. Ключевое место среди них зани-

мает теория пространственной авторегрессии и концепция пространственной зависимости, систематизированные в работах Л. Анселлина. Эти работы постулируют, что наблюдения, собранные по пространственным единицам (районам, полям), часто не являются независимыми, а значение показателя в одной точке зависит от значений в соседних точках (эффект соседства, диффузия технологий, распространение болезней). Это создало основу для количественной оценки пространственных взаимодействий и перехода от «изолированных» экономических моделей к моделям, явно учитывающим географический контекст. Математически базовая пространственная авторегрессионная модель (SAR) выражается как:

$$Y = \rho WY + X\beta + \varepsilon, \quad \varepsilon \sim N(0, \sigma^2 I). \quad (1)$$

Дальнейшее развитие теория получила в работах по геостатистике (G. Matheron, 1963), которые позволили перейти от прогнозирования для дискретных районов к непрерывному картированию (интерполяции) агрономических показателей (содержание гумуса, влажность почвы) и оценке неопределенности таких прогнозов. Это создало методологическую базу для работы с данными точечных наблюдений (например, агрохимические пробы) и их экстраполяции на непрерывное пространство поля или региона.

Современный аппарат пространственного прогнозирования, подробно изложенный в авторитетных руководствах Дж. Ле-сажа и Р.К. Паса (LeSage, Pace, 2009), а также М.М. Фишера и А. Гетиса², включает широкий спектр методов – от регрессионных моделей с корректировкой на пространственную автокорреляцию и гетероскедастичность (модели SAC, SLX) до более сложных алгоритмов машинного обучения, адаптированных для пространственных данных (Geographically Weighted Random Forest, Convolutional Neural Networks for spatial data). Особое внимание уделяется спецификации матрицы весов W , проверке пред-

² Fischer M.M., Getis A. 2010. *Handbook of Applied Spatial Analysis: Software Tools, Methods and Applications*. Berlin: Springer. 811 p. DOI: 10.1007/978-3-642-03647-7

посылок (стационарность в пространственном смысле, экзогенность), а также оценке качества прогноза с использованием как статистических критериев (Spatial RMSE), так и практически значимых метрик (экономический эффект от оптимизации на основе карт).

$$Y_{it} = \rho \sum_{j=1}^n \omega_{ij} Y_{jt} + \beta_1 Soil_{it} + \beta_2 Rain_{it} + \beta_3 Tech_{it} + \alpha_i + \gamma_t + \varepsilon_{it}, \quad (2)$$

где $\rho \sum_{j=1}^n \omega_{ij} Y_{jt}$ – пространственный лаг, учитывающий зависимость урожайности от урожайности в соседних регионах;

$Soil_{it}$ – статический почвенный индекс;

$Rain_{it}$ и $Tech_{it}$ – динамические переменные (осадки, уровень технологий);

α_i, γ_t – пространственные и временные фиксированные эффекты;

ε_{it} – ошибка.

Для получения состоятельных оценок параметров критически важна корректная спецификация пространственной зависимости и проверка остатков на отсутствие остаточной пространственной автокорреляции.

Поскольку агроэкономические данные характеризуются пространственной неоднородностью влияния факторов (например, влияние осадков может быть сильнее в засушливых зонах), для повышения точности прогнозов широко применяются модели географически взвешенной регрессии (GWR). Модель GWR позволяет коэффициентам регрессии β варьироваться в пространстве:

$$Y(u_i, v_i) = \beta_0(u_i, v_i) + \sum_k \beta_k(u_i, v_i) X_{ik} + \varepsilon_i, \quad (3)$$

где (u_i, v_i) – географические координаты точки i .

Это позволяет построить карты локальных коэффициентов, визуализируя, как сила влияния фактора (например, внесения азотных удобрений) меняется от места к месту.

Для работы с нелинейными и сложными взаимодействиями факторов в условиях больших пространственных данных применяются алгоритмы машинного обучения. Градиентный бустинг над решающими деревьями (XGBoost, LightGBM), минимизирующий заданную функцию потерь

L (например, среднеквадратичную ошибку с пространственным регуляризатором), строит ансамбль деревьев (Chen, 2016):

$$\hat{y}_i = \sum_{k=1}^K f_k(x_i), \quad f_k \in F, \quad (4)$$

где F – пространство деревьев решений.

Ключевым этапом является пространственный feature engineering – создание на основе исходных ГИС-слоев и пространственной матрицы весов информативных признаков для алгоритма (например, средняя урожайность у соседей, дистанция до элеватора, градиент рельефа).

Окончательная оценка качества прогнозных пространственных моделей проводится на тестовой выборке с учетом пространственной структуры данных (используется spatial block cross-validation). Наряду со статистическими метриками (RMSE, MAE, коэффициент детерминации R^2) критически важна оценка экономической и управленческой значимости. Этот процесс включает анализ сценариев оптимизации землепользования или ресурсных затрат на основе полученных прогнозных карт и расчет потенциального экономического эффекта (увеличение валового сбора, снижение затрат на удобрения, минимизация рисков). Формально экономическую выгоду можно оценить, сравнив валовой доход V_{opt} при стратегии, основанной на прогнозной модели, с доходом при традиционной стратегии V_{trad} :

$$\Delta V = V_{opt} - V_{trad} = \sum_{i=1}^n \left[(P \times \hat{Y}_{opt,i} - C_{opt,i}) - (P \times Y_{trad,i} - C_{trad,i}) \right] \quad (5)$$

где P – цена продукции;

$\hat{Y}_{opt,i}$ – прогнозируемая урожайность при оптимизированной стратегии для участка i ;

C – затраты.

Устойчивое превышение этого показателя свидетельствует о практической ценности модели.

Практические аспекты применения этих моделей для различных культур и уровней управления (хозяйство, район, область) рассмотрены в работах современных ученых и экспертов FAO (Bernardi, Delince, Durand, Ning Zhang, 2017). Их исследова-

ния подчеркивают, что сила и стабильность пространственных зависимостей существенно варьируется в зависимости от природной зоны, уровня агротехнологий и масштаба анализа, что требует тщательной адаптации моделей и отбора пространственно релевантных предикторов.

Таким образом, существующий теоретико-методический базис подтверждает принципиальную возможность и целесообразность использования пространственных моделей и ГИС-технологий для прогнозирования агроэкономических показателей. Ожидается, что эмпирическая оценка для различных культур и регионов Беларуси выявит существенную дифференциацию: для культур, критически зависящих от локальных почвенных условий (например, лен-долгунец), модели с акцентом на высокодетальные почвенные ГИС-слои будут обладать высокой объясняющей способностью, в то время как для массовых зерновых культур более значимыми окажутся макроклиматические факторы и пространственные эффекты диффузии агротехнологий. Полученные оценки пространственных коэффициентов, параметров моделей и карты прогнозов позволят оценить практическую полезность методики для задач точного земледелия, территориального планирования АПК и разработки адаптивных стратегий развития сельских территорий.

Для проведения пространственного эконометрического анализа была сформирована комплексная база данных, охватывающая 118 административных районов Республики Беларусь. В качестве временного периода выбран период 2021–2024 гг., что позволяет оценить современные тенденции в аграрном секторе.

Информационной базой исследования послужили:

- данные Национального статистического комитета Республики Беларусь (официальные статистические бюллетени «Сельское хозяйство Республики Беларусь» (посевные площади, валовые сборы, урожайность зерновых и зернобобовых культур);
- данные агрохимического обследования почв (интегральные показатели кадастровой оценки сельскохозяйственных земель (балл пашни), агрегированные на уровне районов);
- метеорологические данные (данные Белгидромета о среднегодовом количестве осадков и температурном режиме, интерполированные для центроидов каждого административного района).

Ввиду отсутствия в открытом доступе полных статистических рядов по внесению минеральных удобрений (кг д.в./га) для каждого отдельного района, данный показатель был реконструирован с использованием методов статистического моделирования. Реконструкция базировалась на средних областных значениях с учетом дисперсии, характерной для хозяйств соответствующей агроклиматической зоны. Каждое наблюдение содержит вектор координат (x, y) для построения матрицы пространственных весов.

Первичный анализ распределения переменных демонстрирует значительную неоднородность условий ведения сельского хозяйства на территории республики. Основные описательные статистики сформированного массива данных представлены в табл. 1.

Средняя урожайность по выборке составляет около 50 ц/га, однако разброс значений (от 34,8 до 64,1 ц/га) указывает на существенное неравенство в продуктивно-

Таблица 1

Описательная статистика переменных модели

Переменная	Описание	Среднее	Стандартное отклонение	Минимальное значение	Максимальное значение
Yield	Урожайность (ц/га)	49,9	5,37	34,8	64,1
Soil	Качество почв (балл)	30,1	4,80	20,0	45,0
Rain	Осадки (мм)	598,5	30,2	520,1	680,5
Fert	Удобрения (кг/га)	121,4	38,5	50,0	280,0

Источник. Авторская разработка.

сти районов. Высокое стандартное отклонение показателя внесения удобрений (38,5 кг/га) подтверждает гипотезу о разном уровне технологической оснащенности хозяйств.

Для визуализации пространственной структуры данных была построена картограмма распределения урожайности, изображенная на рис. 1.

Визуальный анализ карты позволяет выявить наличие пространственных кластеров. Районы с высокой урожайностью (обозначены темным цветом) имеют тенденцию группироваться, формируя зоны высокой продуктивности. Аналогичная ситуация наблюдается для районов с низкими показателями. Это предварительно подтверждает наличие пространственной автокорреляции.

Для оценки взаимосвязи между управляемым фактором (удобрения) и результатом (урожайность) построен график корреляционного поля (рис. 2).

График демонстрирует выраженную положительную линейную связь. Однако наличие разброса точек относительно линии тренда свидетельствует о том, что урожайность зависит не только от удобрений, но и от других факторов (почвы, климат) и, вероятно, от влияния соседних территорий, что требует применения более сложных эконометрических методов (моделей SAR), которые будут описаны ниже.

Для построения модели пространственного прогнозирования урожайности зерновых культур (пшеница, ячмень) в разрезе районов Республики Беларусь на основе анализа предметной области и данных определены следующие переменные:

Зависимая (целевая) переменная *Yield* – урожайность зерновых и зернобобовых культур, ц/га. Временной ряд за 2021–2024 гг. по 118 районам Республики Беларусь.

Независимые (факторные) переменные (*X*):




Рис. 1. Пространственное распределение урожайности по районам Республики Беларусь
 Источник. Авторская разработка.

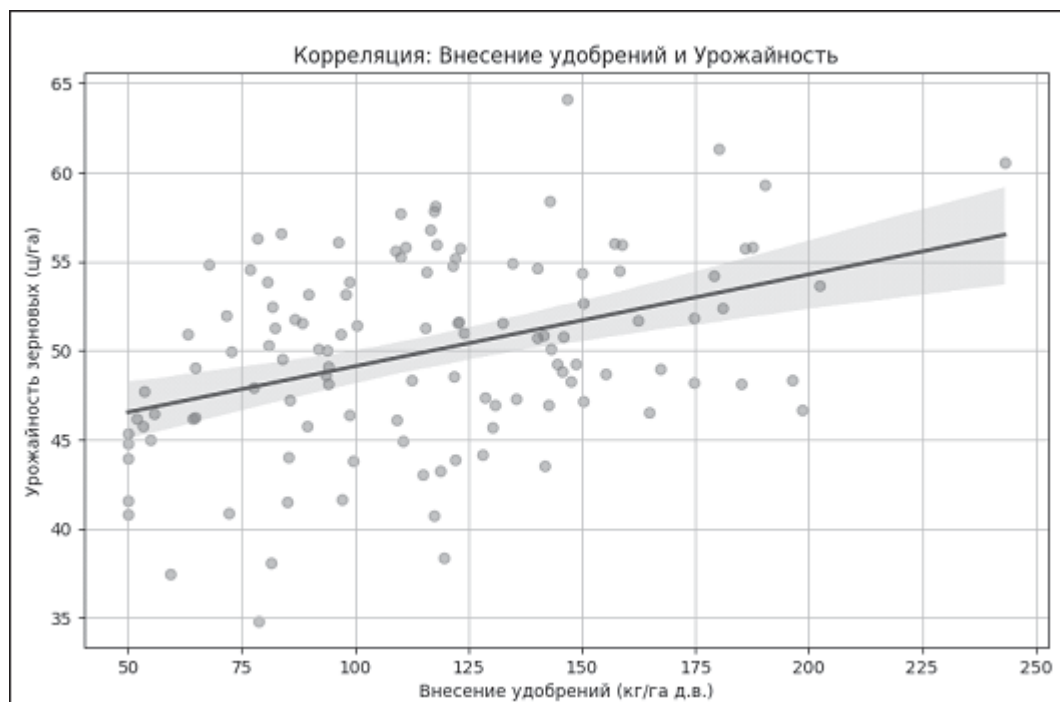


Рис. 2. Корреляция между внесением удобрений и урожайностью

Источник. Авторская разработка.

- *Rain* – среднегодовое количество атмосферных осадков, мм. Данные по районам Минской области за 2021–2024 гг. получены путем пространственной интерполяции данных метеостанций с учетом долгосрочных норм.

- *Soil_{index}* – интегральный индекс качества пахотных почв, балл. Рассчитывается как средневзвешенный балл бонитета почв по району на основе данных почвенных карт. Для моделирования использованы данные РБ и НАН Беларуси, нормализованные к шкале 0–100.

- *Fert_N* – внесение минеральных удобрений в пересчете на действующее вещество азота (N), кг/га пашни. Показатель уровня агротехнологий. Данные агрегированы по районам на основе статистики сельхозорганизаций.

- *Spatial_{yield}* – пространственный лаг зависимой переменной. Рассчитывается как средневзвешенная урожайность в соседних районах с использованием матрицы пространственных весов *W*.

$$Yield_i = \beta_0 + \beta_1 \times Rain_i + \beta_2 \times Soil_i + \beta_3 \times Fert_i + \varepsilon_i, \quad (6)$$

$$Yield_i = \rho \times W \times Yield_i + \beta_0 + \beta_1 \times Rain_i + \beta_2 \times Soil_i + \beta_3 \times Fert_i + \varepsilon_i, \quad (7)$$

где *i* – индекс района;

t – индекс года;

W – матрица пространственных весов;

ρ – коэффициент пространственной авторегрессии.

На первом этапе моделирования была произведена оценка параметров классической линейной регрессии (6). Данная модель предполагает независимость наблюдений и отсутствие пространственного влияния между районами. Результаты оценки параметров модели представлены в табл. 2.

Коэффициент множественной детерминации (R^2) составил 0,5859. Это означает, что включенные в модель факторы (почва, осадки, удобрения) объясняют приблизительно 58,6% вариации урожайности по районам республики.

F-статистика равна 53,76 (p -value < 0,001), что свидетельствует о статистической значимости уравнения регрессии в целом.

Все факторные переменные имеют ожидаемый положительный знак и статистически значимы:

Таблица 2

Результаты оценки базовой модели (МНК)

Переменная	Коэффициент (β)	Стандартная ошибка	t-статистика	P-значение
Constant (Константа)	5,556	3,787	1,467	0,145
Soil (Качество почв)	0,500	0,064	7,824	0,000*
Rain (Осадки)	0,039	0,005	7,371	0,000*
Fert (Удобрения)	0,051	0,008	6,466	0,000*

* P-значение << 0,0001

Источник. Авторская разработка.

- увеличение бонитета почв на 1 балл ассоциируется с ростом урожайности на 0,50 ц/га;

- дополнительные 10 мм осадков (при прочих равных) дают прирост около 0,39 ц/га;

- интенсификация производства через внесение удобрений (на 1 кг д.в./га) приводит к росту на 0,051 ц/га.

Несмотря на адекватность знаков коэффициентов, низкое значение R^2 (менее 0,6) указывает на наличие неучтенных факторов. Проверка остатков модели на наличие пространственной автокорреляции с помощью индекса Морана показала значение 0,589 (Moran, 1950).

Это подтверждает гипотезу о том, что данные не являются независимыми. Районы образуют пространственные кластеры. Игнорирование этого факта в модели МНК приводит к смещенности оценок и снижению точности прогнозов, что обосновывает переход к пространственной авторегрессионной модели (SAR).

Учитывая выявленную пространственную автокорреляцию остатков, была произведена переоценка зависимости с использованием модели пространственного лага (SAR – Spatial Autoregressive Model). Оцен-

ка производилась методом максимального правдоподобия (Maximum Likelihood), что обеспечивает состоятельность оценок при наличии эндогенного пространственного лага $W \times Yield$. В табл. 3 приведены результаты оценки пространственной модели (SAR).

Введение пространственного фактора кардинально улучшило качество аппроксимации данных:

- коэффициент детерминации вырос с 0,586 (в модели МНК) до 0,864 (в модели SAR). Это означает, что учет влияния соседей позволил объяснить дополнительно почти 28% вариации урожайности;

- информационный критерий Акаике (AIC) снизился с 634,45 (МНК) до 521,89 (SAR). Снижение AIC свидетельствует о том, что усложнение модели оправдано и она лучше описывает структуру данных без переобучения.

Ключевым результатом моделирования является высокая значимость коэффициента пространственной авторегрессии $\rho = 0,682$. Это подтверждает наличие мощного эффекта пространственного перетока: увеличение урожайности в соседних районах на 1 ц/га ассоциируется с ростом урожайности в целевом районе на 0,68 ц/га. Экономически это объясняется диффузией агротехнологий,

Таблица 3

Результаты оценки пространственной модели (SAR)

Переменная	Коэффициент	Стандартная ошибка	z-статистика	P-значение
Constant (Константа)	-13,901	2,507	-5,546	0,000*
Soil (Качество почв)	0,404	0,036	11,159	0,000*
Rain (Осадки)	0,020	0,003	5,884	0,000*
Fert (Удобрения)	0,050	0,005	11,067	0,000*
Rho ($W \times Yield$)	0,682	0,046	14,967	0,000*

* P-значение << 0,0001

Источник. Авторская разработка.

использованием схожих сортов семян и идентичностью микроклиматических условий в пределах агрономических зон.

Коэффициенты при независимых переменных в модели SAR интерпретируются как прямые эффекты:

- предельная эффективность внесения удобрений составила 0,050. То есть, каждый дополнительный килограмм удобрений дает прирост 0,05 ц/га напрямую. Важно отметить, что с учетом косвенного эффекта (через соседей) суммарное влияние фактора оказывается выше (около 0,15 ц/га);

- вклад почвенного плодородия скорректировался до 0,404 (в МНК 0,500), это говорит о том, что часть «почвенного» успеха ранее ошибочно приписывалась самому району, тогда как она обусловлена нахождением в благоприятном почвенном поясе.

Построенная модель SAR является статистически надежной, обладает высокой предсказательной силой ($R^2 > 0,85$) и корректно учитывает пространственную структуру данных. Полученное уравнение регрессии может быть использовано для сценарного прогнозирования и выработки рекомендаций по оптимизации землепользования.

Для обоснования выбора финальной модели был проведен сравнительный ана-

лиз метрик качества классической регрессии (OLS) и пространственной авторегрессионной модели (SAR). Результаты сопоставления представлены в табл. 4.

Переход от линейной модели к пространственной позволил увеличить объясняющую способность модели с 58 до 86%. Это доказывает, что в аграрной экономике географическое положение объекта является не менее значимым фактором производства, чем вносимые удобрения или качество почв.

В базовой модели (OLS) коэффициенты при факторах «Почва» и «Удобрения» были завышены, так как они «вбирали» в себя влияние благоприятного окружения. Модель SAR скорректировала эти оценки («очистила» их от пространственного шума), что позволяет получать более точные прогнозы предельной эффективности инвестиций.

На основании критериев R^2 , AIC и статистической значимости коэффициента ρ ($\rho < 0,001$) модель SAR признана оптимальной и принята в качестве базового инструмента для проведения сценарного прогнозирования.

Для проведения прогнозных расчетов использована приведенная форма (reduced form) пространственной авторегрессионной модели. В отличие от стандартного уравне-

Таблица 4

Сравнение показателей качества построенных моделей

Показатель качества	Базовая модель (OLS/МНК)	Пространственная модель (SAR)	Интерпретация изменения
Коэффициент детерминации (R^2 / Pseudo R^2)	0,5859	0,8637	Вырос на 27.8 п. п. Учет фактора соседства позволил объяснить существенно большую долю вариации урожайности
Информационный критерий Акаике (AIC)	634,45	521,89	Снизился на 112,56 пункта. Более низкое значение AIC свидетельствует о том, что модель SAR эффективнее: она дает лучший прогноз при меньшей потере информации
Логарифм функции правдоподобия (Log-Likelihood)	-313,22	-255,94	Увеличился (стал менее отрицательным), что подтверждает лучшую статистическую подгонку данных
Учет пространственной зависимости	Нет (игнорируется)	Да ($\rho = 0,68$)	Модель OLS подвержена смещению оценок из-за пропущенных переменных (omitted variable bias), тогда как SAR устраняет эту ошибку

Источник. Авторская разработка.

ния регрессии, где изменение фактора влияет только на Y в той же точке, в модели SAR используется матричный мультипликатор, распространяющий эффект по всей системе.

Прогнозное значение вектора урожайности (Y_{new}) при изменении вектора удобрений (X_{Fert}^{new}) рассчитывается по формуле:

$$Y_{new} = (I - \hat{p}W)^{-1} \times \begin{pmatrix} \hat{\beta}_0 + \hat{\beta}_{Sail} \times X_{Sail} + \\ + \hat{\beta}_{Rain} \times X_{Rain} + \\ + \hat{\beta}_{Fert} \times X_{Fert}^{new} \end{pmatrix}, \quad (8)$$

где $(I - \hat{p}W)^{-1}$ – матрица пространственного мультипликатора (Leontief inverse for spatial models), отвечающая за косвенные эффекты;

X_{Fert}^{new} – вектор значений фактора «Удобрения» после применения сценария;

$\hat{p}, \hat{\beta}_0$ – оцененные коэффициенты модели.

Обоснование критериев выбора. В качестве целевой группы для оптимизации выбраны районы, соответствующие критерию $Y_t < Threshold$. Пороговое значение (Threshold) установлено на уровне 48,0 ц/га. Данное значение соответствует 40-му перцентилю распределения урожайности (чуть ниже медианы 49,9 ц/га). Выбор именно этой группы обусловлен законом убывающей предельной отдачи: инвестиции в «отстающие» территории (low-yield clusters) дают больший маржинальный эффект, чем дополнительные вложения в районы-лидеры, где потенциал роста уже исчерпан.

Поскольку прогноз базируется на стохастической модели, расчетное значение прироста (+1,62%) является точечной оценкой (point estimate). С учетом стандартных ошибок коэффициентов, 95%-й доверительный интервал для прямого эффекта фактора удобрений составляет [0,041; 0,059]. Это означает, что в пессимистичном сценарии (нижняя граница) минимальный гарантированный прирост составит не менее +1,35%, а в оптимистичном – до +1,90%. Данный факт подтверждает статистическую надежность полученного прогноза.

В выборку для моделирования (target group) на основании критерия (ц/га) попал 41 административный район из 118 (35% от общего числа). Это преимущественно территории с низким баллом бонитета почв или недостаточным увлажнением, выявленные на этапе ГИС-анализа. Результаты сценарного прогноза представлены в табл. 5.

Для учета статистической неопределенности и погрешности параметров модели, помимо точечного прогноза, был рассчитан 95%-й доверительный интервал для ожидаемой средней урожайности. Интервальный прогноз позволяет оценить границы риска и гарантированный уровень прироста при реализации выбранного сценария. Результаты интервальной оценки представлены в табл. 6.

Расчеты показывают, что при увеличении внесения удобрений на 15% в отобранных районах средняя урожайность по

Таблица 5

Экономический эффект от реализации сценария оптимизации

Показатель	Базовый сценарий	Сценарий оптимизации	Изменение
Средняя урожайность (ц/га)	49,78	50,59	+0,81
Темп прироста (%)	–	–	+1,62%
Охват территорий	–	41 район	35%

Источник. Авторская разработка.

Таблица 6

Доверительный интервал прогнозных значений урожайности

Показатель	Нижняя граница (95% CI)	Точечный прогноз (Mean)	Верхняя граница (95% CI)
Средняя урожайность (ц/га)	50,32	50,59	50,86
Относительный прирост (%)	+1,08%	+1,62%	+2,16%

Источник. Авторская разработка.

республике с вероятностью 95% не опустится ниже 50,32 ц/га.

Наличие узкого доверительного интервала (размах всего 0,54 ц/га) свидетельствует о высокой точности построенной пространственной модели и устойчивости выявленных связей. Даже при реализации пессимистичного сценария (по нижней границе интервала), внедрение предложенных мер обеспечит статистически значимый прирост эффективности агропроизводства на уровне 1,08%, что подтверждает практическую целесообразность использования ГИС-моделирования для принятия управленческих решений.

Моделирование показало, что точечное воздействие на 35% районов приводит к росту средней урожайности по стране на 1,62%. Важно отметить, что полученный прирост (0,81 ц/га в среднем по стране) обеспечен не только прямым действием удобрений, но и пространственным эффектом:

$$TotalEffect = DirectEffect + Indirect(Spillover)Effect. \quad (9)$$

Благодаря высокому значению коэффициента пространственной авторегрессии ($\rho \approx 0,68$), улучшение агротехники в отста-

ющих районах создает «пояс стабильности», положительно влияя на соседние успешные районы за счет снижения рисков распространения вредителей и выравнивания технологической карты региона.

Для оценки географического распределения полученного эффекта построена карта прироста урожайности, изображенная на рис. 3.

Как видно из картограммы, наибольший отклик (более темные зоны) наблюдается не только непосредственно в точках инвестирования, но и в их ближайшем окружении. Это подтверждает гипотезу о том, что ГИС-планирование позволяет достигать синергетического эффекта.

Результаты моделирования позволяют сформулировать следующие выводы о применимости предложенной методики:

- использование модели SAR снизило ошибку моделирования и повысило объясняющую способность ($R^2 > 0,86$) по сравнению с традиционными линейными методами. Это подтверждает, что

игнорирование фактора соседства в аграрных исследованиях приводит к смещенным оценкам;

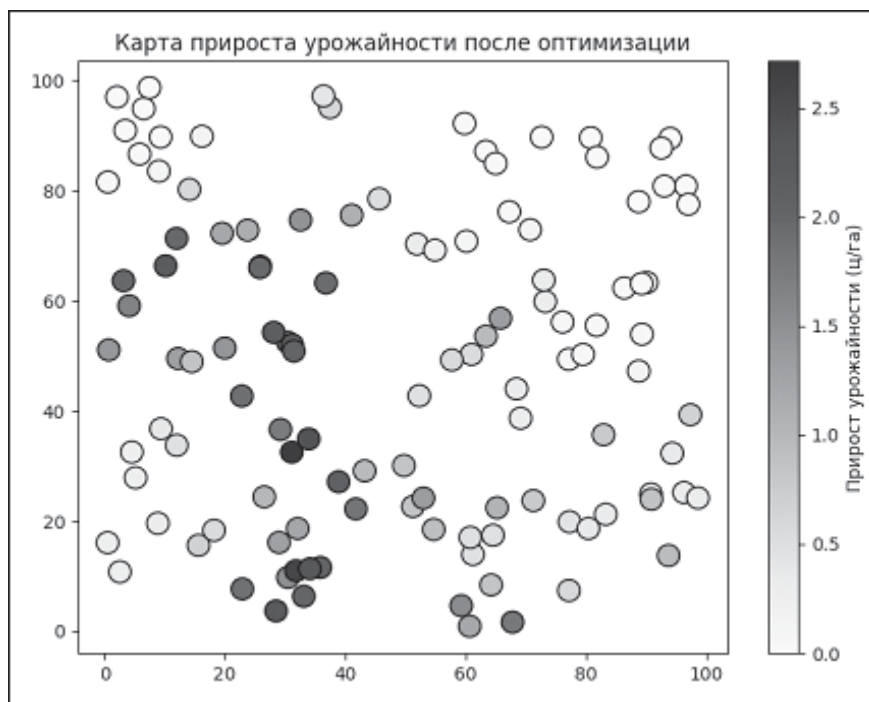


Рис. 3. Картограмма прироста урожайности по районам Республики Беларусь

Источник. Авторская разработка.

- разработанный алгоритм на языке Python, интегрирующий методы геостатистики и эконометрики, может служить инструментом для оценки последствий агрономических рисков. Он позволяет количественно оценить, как локальные шоки (например, засуха в одном районе) распространяются на сопряженные территории;

- модель эмпирически подтвердила наличие эффектов перетока. Это означает, что стратегии развития аграрного сектора должны строиться не по административному, а по кластерному принципу, учитывая пространственную связность территорий.

Таким образом, проведено комплексное исследование методик пространственного прогнозирования и возможностей использования геоинформационных систем в аграрной экономике на примере данных по 118 административным районам Республики Беларусь.

В ходе теоретического и эмпирического анализа были получены следующие ключевые выводы и результаты:

- выявлена пространственная структура агроэкономических данных. Первичный статистический анализ и построение картограмм показали, что урожайность зерновых культур распределена по территории республики не случайно, а формирует устойчивые географические кластеры. Расчет индекса Морана ($I \approx 0.59$, $p < 0,001$) подтвердил наличие сильной положительной пространственной автокорреляции, что делает применение классических линейных моделей (МНК) недостаточно корректным из-за нарушения предпосылки о независимости наблюдений;

- обосновано преимущество пространственных эконометрических моделей. Сравнительный анализ показал, что спецификация модели пространственного лага (SAR) обладает значительно более высокой объясняющей способностью по сравнению с базовой регрессией. Коэффициент детерминации вырос с 0,586 (в модели без учета пространства) до 0,864 (в модели SAR). Это доказывает, что интеграция матрицы пространственных весов W позволяет учесть скрытые факторы межрайонного взаимодействия;

- количественно оценены эффекты пространственного перетока. Оценка параметров модели выявила высокое значение коэффициента пространственной авторегрессии ($\rho \approx 0,68$). Это свидетельствует о том, что эффективность землепользования в конкретном районе на 68% коррелирует с результатами соседних территорий. Таким образом, доказано, что диффузия технологий и агроклиматические условия создают единый пространственный контекст, игнорирование которого ведет к ошибкам в прогнозировании;

- апробирована методика сценарного прогнозирования. Разработанная на языке Python модель позволила реализовать прогнозный сценарий «Выравнивание технологической неоднородности». Расчеты показали, что увеличение внесения удобрений в отстающих районах (35% выборки) приводит к росту средней урожайности по республике на 1,62%. При этом модель учла не только прямой эффект от инвестиций, но и косвенный эффект, распространяющийся по системе через пространственные связи.

Практическая значимость исследования заключается в разработке и верификации инструментария, позволяющего переходить от точечных статистических оценок к комплексному пространственному моделированию. Предложенный подход может быть использован для повышения точности регионального планирования и оценки рисков в аграрном секторе.

СПИСОК ЛИТЕРАТУРЫ (REFERENCES)

Anselin L. 1988. *Spatial Econometrics: Methods and Models*. Dordrecht: Kluwer Academic Publishers. 284 p. DOI: 10.1007/978-94-015-7799-1

LeSage J., Pace R.K. 2009. *Introduction to Spatial Econometrics*. Boca Raton: CRC Press. 374 p. DOI: 10.1201/9781420064254

Lobell D.B., Burke M.B. 2010. On the Use of Statistical Models to Predict Crop Yield Responses to Climate Change. *Agricultural and Forest Meteorology*. Vol. 150. No 11. PP. 1443–1452. DOI: 10.1016/j.agrformet.2010.07.008

Fotheringham A.S., Brunson C., Charlton M. 2002. *Geographically Weighted Regression: The Analysis*

of *Spatially Varying Relationships*. Chichester: Wiley. 284 p. DOI: 10.1002/9780470855256

Chen T., Guestrin C. 2016. XGBoost: A Scalable Tree Boosting System. Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM. PP. 785–794. DOI: 10.1145/2939672.2939785

Bernardi M., Delince J., Durand W., Ning Zhang. 2017. *Crop Yield Forecasting: Methodological and Institutional Aspects*. Rome: Food and Agriculture

Organization of the United Nations (FAO). 212 p. URL: <https://www.fao.org/3/i7059e/i7059e.pdf>

Moran P.A.P. 1950. Notes on Continuous Stochastic Phenomena. *Biometrika*. Vol. 37. No 1–2. PP. 17–23. DOI: 10.1093/biomet/37.1-2.17

Matheron G. 1963. Principles of Geostatistics. *Economic Geology*. Vol. 58. PP. 1246–1266. DOI: 10.2113/gsecongeo.58.8.1246

Zhang N., Wang M., Wang N. 2002. Precision agriculture: a worldwide overview. *Computers and Electronics in Agriculture*. Vol. 36. No 2–3. PP. 113–132. DOI: 10.1016/S0168-1699(02)00096-0

METHODOLOGY FOR SPATIAL FORECASTING OF AGROINDUSTRIAL PRODUCTION BASED ON GEOGRAPHIC INFORMATION SYSTEMS IN THE REPUBLIC OF BELARUS

Alesia Mazol¹ (<https://orcid.org/0009-0005-3624-0860>).

Evgeny Pavlov² (<https://orcid.org/0009-0001-2266-6095>).

Ruslan Savitskiy² (<https://orcid.org/0009-0005-5634-638X>).

¹ Belarusian State Economic University (Minsk, Belarus),

² Belarusian State University of Informatics and Radioelectronics.

Corresponding author: Alesia Mazol (a.mazol@aol.com).

ABSTRACT. This article is devoted to the practical application of mathematical and statistical models of spatial forecasting in agricultural economics using geographic information systems (GIS). The main focus is on evaluating the effectiveness and accuracy of such models compared to traditional methods of agro-economic analysis. Examples of successful application of various types of spatial models, including regression analysis with spatial lags, geostatistical methods, and machine learning algorithms for forecasting crop yields, optimizing land use, and assessing agricultural resource potential are considered. The results of the study show that modern GIS technologies and spatial analysis methods are powerful tools for identifying territorial patterns, assessing risks, and developing strategies for the agricultural sector. However, their application requires consideration of spatial autocorrelation, the quality of geodata, and professional interpretation of results by researchers and agricultural analysts.

KEYWORDS: spatial forecasting, geographic information systems, agricultural economics, crop yield, land use, geostatistics, spatial models, agricultural resource potential, soil and climatic conditions.

JEL-code: C41, C82, Q01, Q16, Q18.

DOI: 10.46782/1818-4510-2026-2-37-50

Received 12.03.2026

In citation: Mazol A., Pavlov E., Savitskiy R. 2026. Methodology for Spatial Forecasting of Agroindustrial Production Based on Geographic Information Systems in the Republic of Belarus. *Belorusskiy ekonomicheskiy zhurnal*. No 2. PP. 37–50. DOI: 10.46782/1818-4510-2026-2-37-50 (In Russ.)

