



<https://doi.org/10.17749/2313-7347/ob.gyn.rep.2026.721>

## Применение моделей искусственного интеллекта на мультипараметрических наборах данных для прогнозирования осложнений беременности

В.А. Атамасова<sup>1</sup>, С.Р. Хабибуллина<sup>1</sup>, Ю.П. Фрумкина<sup>2</sup>, Е.И. Соколова<sup>3</sup>,

А.А. Волощук<sup>4</sup>, Е.Г. Шищенкова<sup>2</sup>, А.В. Борисова<sup>5</sup>, П.Ю. Воронина<sup>2</sup>

<sup>1</sup>ФГБОУ ВО «Казанский государственный медицинский университет» Министерства здравоохранения Российской Федерации; Россия, 420012 Казань, ул. Бутлерова, д. 49;

<sup>2</sup>ФГАОУ ВО Первый Московский государственный медицинский университет имени И.М. Сеченова Министерства здравоохранения Российской Федерации (Сеченовский университет); Россия, 119048 Москва, ул. Трубецкая, д. 8, стр. 2;

<sup>3</sup>ФГАОУ ВО «Российский национальный исследовательский медицинский университет имени Н.И. Пирогова» Министерства здравоохранения Российской Федерации; Россия, 117513 Москва, ул. Островитянова, д. 1;

<sup>4</sup>ФГБОУ ВО «Ставропольский государственный медицинский университет» Министерства здравоохранения Российской Федерации; Россия, 355017 Ставрополь, ул. Мира, д. 310;

<sup>5</sup>ФГБОУ ВО «Первый Санкт-Петербургский государственный медицинский университет имени академика И.П. Павлова» Министерства здравоохранения Российской Федерации; Россия, 197022 Санкт-Петербург, ул. Льва Толстого, д. 6–8

*Для контактов: Виктория Алексеевна Атамасова, e-mail: atamasovavika11@gmail.com*

### Резюме

**Цель:** провести сравнительный анализ прогностической эффективности моделей искусственного интеллекта (ИИ) и машинного обучения (МО), разработанных на мультипараметрических наборах данных, для прогнозирования преэклампсии (ПЭ) и акушерских кровотечений.

**Материалы и методы.** Систематический обзор выполнен согласно PRISMA. Поиск проведен в PubMed и Cochrane Central за 2015–2025 гг. Включались исследования с ИИ/МО, использующие  $\geq 2$  предикторов/классов данных и оценивающие ПЭ/эклампсию или

---

Мы предоставляем данную авторскую версию для обеспечения раннего доступа к статье. Эта рукопись была принята к публикации и прошла процесс рецензирования, но не прошла процесс редактирования, верстки, присвоения порядковой нумерации и корректуры, что может привести к различиям между данной версией и окончательной отредактированной версией статьи.

We are providing this an author-produced version to give early visibility of the article. This manuscript has been accepted for publication and undergone full peer review but has not been through the copyediting, typesetting, pagination and proofreading process, which may lead to differences between this version and the final typeset and edited version of the article.

акушерские кровотечения (включая послеродовые). Риск систематической ошибки оценивали с помощью инструмента ROBINS-I (англ. Risk Of Bias In Non-randomized Studies of Interventions; риск систематической ошибки в нерандомизированных исследованиях) и шкалы Ньюкасл–Оттава (англ. Newcastle–Ottawa Scale, NOS).

**Результаты.** В обзор включены 28 исследований (18 по ПЭ, 10 по кровотечениям). Наиболее часто применялись градиентный бустинг, случайный лес, XGBoost и нейросетевые модели. Для ПЭ наилучшие результаты чаще демонстрировали модели, объединяющие материнские факторы риска с показателями артериального давления и компонентами скрининга I триместра (доплерометрия маточных артерий и плацентарные биомаркеры). Для прогнозирования кровотечений наиболее перспективными оказались подходы на базе электронных медицинских карт и предоперационных клинико-лабораторных данных, включая риск-стратификацию у пациенток с предлежанием плаценты (placenta previa) и вращением плаценты (placenta accreta spectrum, PAS). Основным ограничением доказательной базы остаются преобладание ретроспективных дизайнов и дефицит внешней/проспективной валидации, что снижает переносимость моделей между клиниками и во времени.

**Заключение.** Модели ИИ, обученные на мультипараметрических данных мониторинга, способны улучшать прогнозирование ПЭ и акушерских кровотечений, однако клиническое внедрение требует стандартизированной отчетности, внешней проверки и контроля калибровки моделей в реальной практике.

**Ключевые слова:** искусственный интеллект, ИИ, машинное обучение, МО, мультипараметрический мониторинг, преэклампсия, ПЭ, послеродовое кровотечение, электронные медицинские карты, доплерометрия, плацентарные биомаркеры

**Для цитирования:** Атамасова В.А., Хабибуллина С.Р., Фрумкина Ю.П., Соколова Е.И., Волощук А.А., Шишенкова Е.Г., Борисова А.В., Воронина П.Ю. Применение моделей искусственного интеллекта на мультипараметрических наборах данных для прогнозирования осложнений беременности. *Акушерство, Гинекология и Репродукция*. 2026;[принятая рукопись]. <https://doi.org/10.17749/2313-7347/ob.gyn.rep.2026.721>.

## **Application of artificial intelligence models trained on multiparametric datasets for predicting pregnancy complications**

Viktoriya A. Atamasova<sup>1</sup>, Safiya R. Khabibullina<sup>1</sup>, Yulia P. Frumkina<sup>2</sup>, Evgeniia I. Sokolova<sup>3</sup>, Alina A. Voloshuk<sup>4</sup>, Elizaveta G. Shishenkova<sup>2</sup>, Alisa V. Borisova<sup>5</sup>, Polina Yu. Voronina<sup>2</sup>

<sup>1</sup>Kazan State Medical University, Ministry of Health of the Russian Federation;  
Russia, 420012 Kazan, Butlerova Street, 49;

<sup>2</sup>Sechenov University; 8 bldg. 2, Trubetskaya Str., Moscow 119048, Russia;

<sup>3</sup>Pirogov Russian National Research Medical University, Ministry of Health of the Russian Federation; 1 Ostrovityanova Str., Moscow 117513, Russia;

<sup>4</sup>Stavropol State Medical University, Ministry of Health of the Russian Federation; 310 Mira Str., Stavropol 355017, Russia;

<sup>5</sup>Pavlov First Saint Petersburg State Medical University, Ministry of Health of the Russian Federation; 6–8 Lev Tolstoy Str., Saint Petersburg 197022, Russia

*Corresponding author: Viktoriya A. Atamasova, e-mail: atamasovavika11@gmail.com*

## **Abstract**

**Aim:** to compare the predictive performance of artificial intelligence (AI) and machine learning (ML) models trained on multiparametric datasets for the prediction of preeclampsia (PE) and obstetric hemorrhage.

**Materials and Methods.** This systematic review was conducted in accordance with the PRISMA guidelines. PubMed and Cochrane Central databases were searched for studies published between 2015 and 2025. We included studies applying AI/ML with  $\geq 2$  predictors/data modalities and reporting outcomes related to PE/eclampsia or obstetric hemorrhage (including postpartum hemorrhage). Risk of bias was assessed using Risk Of Bias In Non-randomized Studies of Interventions (ROBINS-I) tool and the Newcastle–Ottawa Scale (NOS).

**Results.** Twenty-eight studies were included (18 on PE and 10 on hemorrhage). Most common algorithms were gradient boosting methods, random forests, XGBoost, and neural networks were the most common algorithms. For preeclampsia, stronger performance was more consistently reported when maternal risk factors were combined with blood pressure features and first-trimester screening components (uterine artery Doppler and placental biomarkers). For hemorrhage prediction, models based on electronic health records and preoperative clinical and laboratory variables, including risk stratification in placenta previa/placenta accreta spectrum (PAS), appeared particularly relevant. The evidence base is limited by predominantly retrospective designs and insufficient external/prospective validation, which undermines model transportability across settings and over time.

**Conclusion.** AI supported by multiparametric monitoring shows promise for predicting PE and obstetric hemorrhage; however, real-world implementation requires standardized reporting, external validation, and ongoing calibration monitoring.

**Keywords:** artificial intelligence, AI, machine learning, ML, multiparametric monitoring, preeclampsia, PE, postpartum hemorrhage, electronic health records, uterine artery Doppler, placental biomarkers

**For citation:** Atamasova V.A., Khabibullina S.R., Frumkina Yu.P., Sokolova E.I., Voloshuk A.A., Shishenkova E.G., Borisova A.V., Voronina P.Yu. Application of artificial intelligence models trained on multiparametric datasets for predicting pregnancy complications. *Akusherstvo,*

Основные моменты	Highlights
Что уже известно об этой теме?	What is already known about this subject?
Прогноз преэклампсии (ПЭ) и акушерских кровотечений улучшается при использовании многопараметрических моделей, объединяющих анамнез, клинические данные, лабораторные показатели и инструментальные маркеры.	Prediction of preeclampsia (PE) and obstetric bleeding improves when multiparametric models combine clinical history, laboratory data and instrumental markers.
Для ПЭ наибольшую ценность стабильно показывают показатели артериального давления, материнские факторы риска, доплерометрия маточных артерий и плацентарные биомаркеры ранней беременности.	For PE, blood pressure, maternal risk factors, uterine artery Doppler findings and placental biomarkers are the most consistent contributors.
Большинство опубликованных моделей основаны на ретроспективных выборках, а недостаток внешней и проспективной валидации ограничивает их воспроизводимость и переносимость.	Most published models rely on retrospective datasets, while limited external and prospective validation reduces reproducibility and transportability.
Что нового дает статья?	What are the new findings?
Сопоставлены не только модели прогнозирования ПЭ, но и алгоритмы оценки риска акушерских кровотечений на перипартальном и предоперационном этапах.	Not only models for predicting PE were compared, but also algorithms for assessing the risk of obstetric hemorrhage at the peripartum and preoperative stages.
Показано, что лучшие результаты обычно достигаются при добавлении к клиническому минимуму рутинных лабораторных показателей и для ПЭ – маркеров скрининга I триместра.	Best performance was generally achieved when routine laboratory data and, for PE, first-trimester screening markers were added to basic clinical variables.
Для кровотечений наиболее перспективными выглядят модели на основе электронных медицинских карт и предоперационных данных у пациенток с предлежанием плаценты и вращением плаценты (PAS).	For bleeding, models based on electronic medical records and preoperative data in patients with placenta previa and placenta accreta spectrum (PAS) appear to be the most promising.
Как это может повлиять на клиническую практику в обозримом будущем?	How might it impact on clinical practice in the foreseeable future?
Такие алгоритмы могут дополнить существующие схемы скрининга, помогая точнее выделять пациенток, которым требуется усиленное наблюдение или дообследование.	These algorithms may complement existing screening pathways by identifying women who need intensified surveillance or additional assessment.
Модели риска кровотечения способны улучшить планирование маршрутизации, подготовку компонентов крови, состав мультидисциплинарной команды и готовность операционной.	Bleeding-risk models could improve planning of referral, blood products, multidisciplinary teams and operating-room readiness.
Для внедрения в практику потребуются стандартизированная отчетность, локальная калибровка и независимая проверка моделей до интеграции в цифровые клинические системы.	Implementation will require standardized reporting, local calibration and independent validation before integration into routine digital clinical systems.

## Введение / Introduction

Материнская смертность, связанная с осложнениями, возникающими во время беременности, родов и послеродового периода, остается значимой проблемой здравоохранения, и темпы ее снижения остаются недостаточными [1].

Развитие осложнений беременности как в перинатальном, так и постнатальном периоде зависит от ряда факторов: социальных, биологических, экологических. К биологическим относят возраст, антропометрические показатели, сопутствующие заболевания сердечно-сосудистой и мочеполовой систем, а также генетические предрасположенности к развитию тех или иных состояний – преэклампсии (ПЭ), гестационного диабета и т. д. Наличие множества факторов риска осложнений требует мультидисциплинарного подхода к их профилактике [2]. Наиболее информативным периодом для прогнозирования осложнений беременности является I триместр [3].

Появление технологий искусственного интеллекта (ИИ) дало новый толчок в развитии различных сфер жизнедеятельности человека, в том числе активно изучается применение ИИ в медицине. В лечебной и профилактической работе модели ИИ разрабатываются на большом количестве различных данных. Данные модели помогут врачам быстрее интерпретировать данные пациента, снижая вероятность ошибки, тем самым снижая нагрузку на медицинский персонал [4]. Отдельным разделом в технологии ИИ является машинное обучение (МО), которое позволяет выявлять зависимости между огромным количеством мультипараметрических показателей, которые недоступны врачу. Однако из-за большого объема данных применение данных технологий должно проводиться под контролем врача [5].

Медицинские модели МО в акушерстве основываются на сердечном ритме, его вариабельности, артериальном давлении (АД) в динамике, уровне глюкозы, показаниях фетального мониторинга и др. Комбинация подобных данных позволяет сформировать комплекс показателей, которые служат для прогнозирования тех или иных состояний, а их прогностическая ценность прямо зависит от объема данных [6].

Разработку модели МО проводят в 2 этапа: обучающий и тестовый. Первым этапом модель обучают на определенных данных, подбирают параметры и определяют наиболее информативные признаки. Вторым этапом на новых данных тестируют разработанную модель, тем самым определяя ее эффективность и точность [7].

Показатели эффективности модели включают в себя точность, достоверность, чувствительность и специфичность, прогностическую ценность, коэффициенты вероятности и ROC-анализ, который является ключевым в оценке эффективности модели [8].

За последние 5–10 лет в мире опубликовано большое количество исследований о применении ИИ в прогнозировании акушерских осложнений, однако они все рассматривают широкий диапазон осложнений без детальной оценки влияния отдельных алгоритмов на развитие конкретных неблагоприятных исходов, что затрудняет интерпретацию полученных результатов.

**Цель:** провести сравнительный анализ прогностической эффективности моделей ИИ и МО, разработанных на мультипараметрических наборах данных, для прогнозирования ПЭ и акушерских кровотечений.

## **Материалы и методы / Materials and Methods**

Этот систематический обзор был проведен в соответствии с рекомендациями по проведению систематических обзоров и метаанализов (PRISMA).

Выполнен поиск публикаций в базах данных PubMed и Cochrane Central. Поиск проводился за период с 2015 по 2025 гг. Язык публикаций: английский.

### **Критерии включения / Inclusion criteria**

#### *Популяция / Population*

- беременные на различных сроках гестации;
- роженицы в послеродовом периоде.

#### *Интервенция / Intervention*

Исследования с применением методов ИИ или МО, включая нейросети и методы глубокого обучения. Модель должна использовать более одного предиктора.

#### *Исходы / Outcomes*

Преэклампсия и эклампсия или акушерские кровотечения, включая послеродовые кровотечения различной этиологии.

#### *Тип данных / Data type*

Исследования, рассматривающие многофакторный подход к мониторингу беременных, под которым понимается применение как минимум 2 различных классов данных, лабораторных показателей или записи из электронных медицинских карт (ЭМК).

#### *Дизайн исследования / Study design*

Ретроспективные, проспективные исследования, однокогортные, сравнительные исследования.

### **Критерии исключения / Exclusion criteria**

Исследования, не включающие беременных или родильниц, либо рассматривающие осложнения плода или новорожденного без анализа материнских осложнений.

Работы, посвященные задачам классификации или распознавания, не связанным с прогнозированием осложнений беременности, а также исследования других исходов, не входящих в заранее определенный перечень.

Отсутствие ИИ или предиктивной модели.

Отсутствие мультипараметрического набора данных, используемого для обучения моделей ИИ.

Обзорные статьи, метаанализы, протоколы, редакционные статьи и конференционные тезисы без достаточного объема данных.

### **Поисковая стратегия / Search strategy**

В PubMed использовали словосочетания и термины предметных медицинских рубрик (англ. Medical Subject Headings, MeSH Terms) и ключевых слов "Artificial Intelligence", "Machine Learning", "Pregnancy Complications", "Pregnancy", "Pre-Eclampsia", "Postpartum Hemorrhage", а также свободные термины в полях названия и аннотации, включая "Deep Learning", "maternal sepsis" и "puerperal sepsis". Термины внутри каждой смысловой группы объединяли оператором OR, а группы между собой – оператором AND.

Для Cochrane Library использовали аналогичный подход: MeSH-дескрипторы, связанные с машинным обучением, искусственным интеллектом, беременностью и осложнениями беременности, дополняли поиском свободных слов в названии, аннотации и ключевых словах. В частности, использовали термины multiparametric, predict\* и sepsis для расширения поиска публикаций, посвященных прогнозированию акушерских осложнений с применением многопараметрических моделей.

Ниже приведен конечный поисковый запрос, применяемый в базах данных.

**PubMed:** (("Artificial Intelligence"[MeSH Terms] OR "Machine Learning"[MeSH Terms] OR "Deep Learning"[Title/Abstract]) AND ("Pregnancy Complications"[MeSH Terms] OR "Pregnancy"[MeSH Terms]) AND ("Pre-Eclampsia"[MeSH Terms] OR "Postpartum Hemorrhage"[MeSH Terms] OR "maternal sepsis"[Title/Abstract] OR "puerperal sepsis"[Title/Abstract])

### **Cochrane Library:**

- #1 MeSH descriptor: [Machine Learning] explode all trees
- #2 MeSH descriptor: [Artificial Intelligence] explode all trees
- #3 (multiparametric): ti, ab, kw
- #4 (predict\*): ti, ab, kw
- #5 MeSH descriptor: [Pregnancy Complications] explode all trees
- #6 MeSH descriptor: [Pregnancy] explode all trees
- #7 MeSH descriptor: [Pre-Eclampsia] explode all trees
- #8 MeSH descriptor: [Postpartum Hemorrhage] explode all trees
- #9 (sepsis): ti, ab, kw
- #10 (#1 OR #2 OR #3) AND (#5 OR #6 OR #7 OR #8)

### **Отбор исследований / Study selection**

Найденные записи в базах данных экспортировались в менеджер библиографии Zotero (Digital Scholar / Corporation for Digital Scholarship, USA). Определялись и удалялись

дубликаты из разных баз данных и поочередно проводился скрининг по названию и аннотации, затем переходили к анализу полного текста статьи и оценивали на соответствие критериям включения.

### **Извлечение данных / Data extraction**

По каждой записи анализировались и извлекались данные о дизайне исследования, численности выборки, периода беременности, в котором проводился прогноз, модель МО и используемые параметры, а также результаты. Риск систематической ошибки оценивали с помощью инструмента ROBINS-I (англ. Risk Of Bias In Non-randomized Studies of Interventions; риск систематической ошибки в нерандомизированных исследованиях) и шкалы Ньюкасл–Оттава (англ. Newcastle–Ottawa Scale, NOS).

### **Синтез данных / Data synthesis**

Проводился нарративный синтез по включенным исследованиям. Результаты представлены в отдельных разделах, посвященные прогнозированию ПЭ и кровотечения.

## **Результаты / Results**

По вышеуказанным запросам было найдено 385 публикаций. После удаления дубликатов ( $n = 72$ ) осталось 313 публикаций. На этапе скрининга были определены как не соответствующие критериям включения 245 записей. К полнотекстовой оценке были приняты 68 публикаций, после чего в итоговый обзор были включены 28 публикаций, посвященных применению ИИ в прогнозировании развития ПЭ (18 публикаций) и кровотечений (10 публикаций) (**рис. 1**).

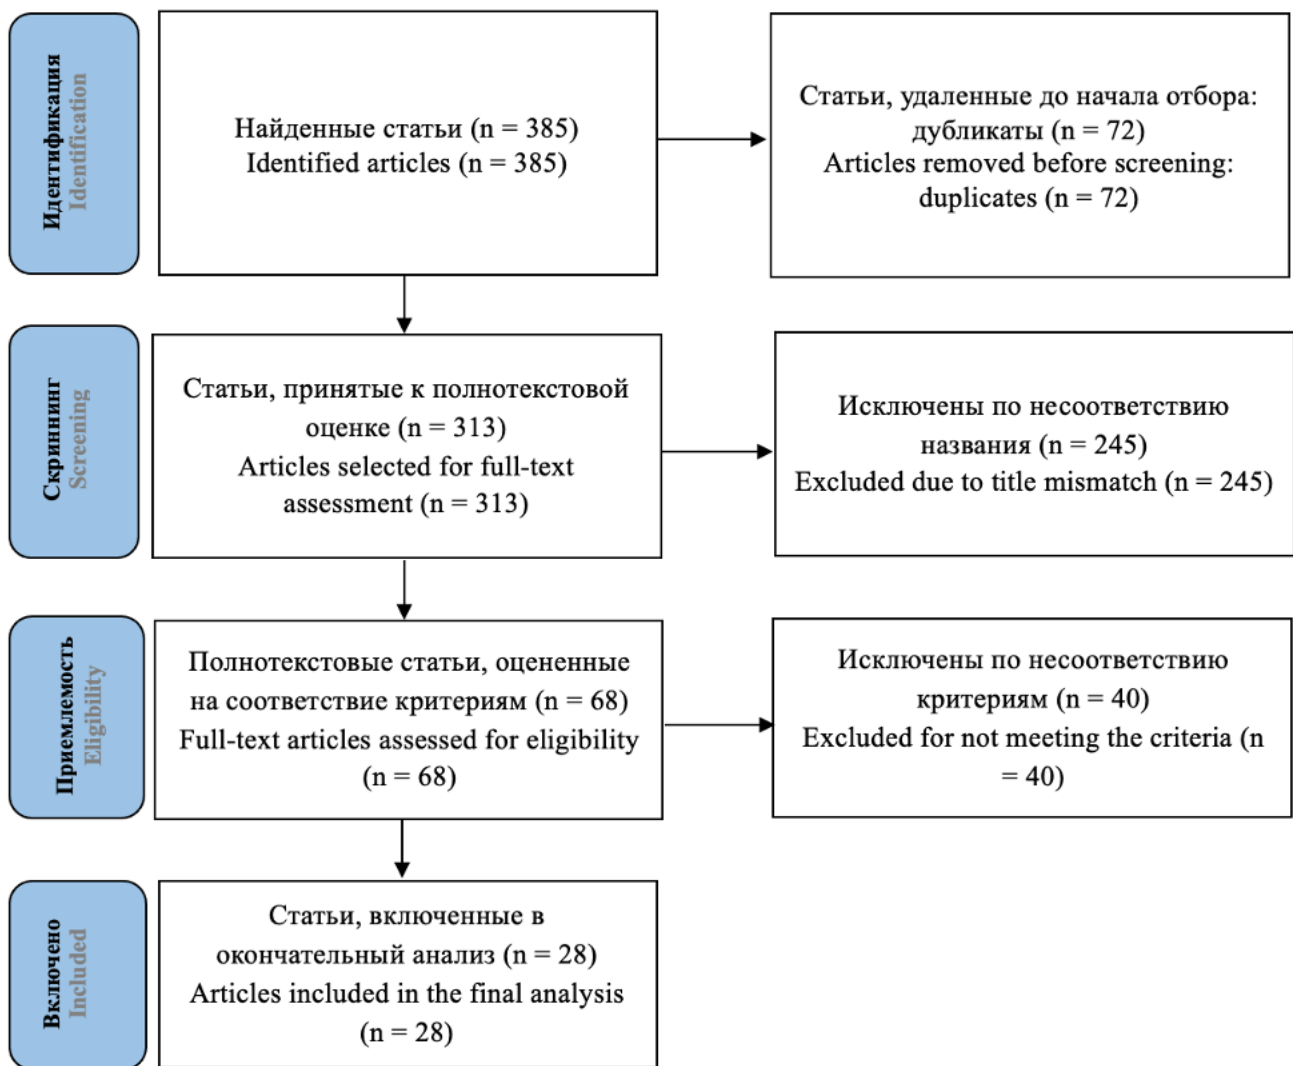


Рисунок 1. Диаграмма PRISMA отбора публикаций.

Figure 1. PRISMA flow diagram for publication selection.

Нарративный синтез отобранных публикаций разделен на 2 раздела: первый посвящен прогнозированию ПЭ (табл. 1), второй – прогнозированию кровотечений (табл. 2).

### Общая характеристика включенных исследований, посвященных преэклампсии / General characteristics of the included preeclampsia studies

В исследованиях, посвященных прогнозированию ПЭ, рассматривались различные данные, начиная от скрининга в I триместре (АД, доплерография кровотока плаценты, плацентарные биомаркеры) до моделей на основе медицинских карт.

Дизайн в большинстве случаев являлся ретроспективным исследованием на данных ЭМК, лабораторных данных и административных баз (например, страховых). Также встречались проспективные работы. Объем выборок характеризовался широкой вариацией. Наиболее часто используемым показателем качества была площадь под ROC-кривой (англ.

area under curve, AUC), также для некоторых моделей использовали частоту выявления (англ. detection rate).

Крупное проспективное исследование Z. Ansbacher-Feldman с соавт. (n = 60789) посвящено нейросетевому прогнозированию развития ПЭ по данным I триместра. На первом этапе модель обучали на основе демографических данных и анамнеза, затем ее дополняли данными I триместра: уровнем среднего АД (англ. mean arterial pressure, MAP) и значением индекса пульсации маточной артерии (англ. uterine artery pulsatility index, UtAPI), содержанием плацентарного фактора роста (англ. placental growth factor, PIGF) и ассоциированного с беременностью белка-А плазмы (англ. pregnancy-associated plasma protein-A, PAPP-A). Наличие в модели таких параметров как биомаркеры и доплеровское исследование повысило качество прогнозирования преждевременной ПЭ: AUC увеличилась с 0,816 до 0,909, а выявляемость при 10 % ложноположительных результатах (англ. false positive rate, FPR) поднялась с 53,3 % до 75,3 %. Для риска ПЭ независимо от срока дебюта улучшение было более умеренным (AUC 0,770 → 0,817; выявляемость 41,3 % → 52,9 %). Авторы сделали акцент на вкладе этнической принадлежности в прогнозе ПЭ [9].

Похожий подход был продемонстрирован в другом исследовании. М.М. Gil с соавт. (исследование PREVAL, n = 10110; скрининг в 11–13 недель) оценивали модель МО на комбинации материнских факторов + САД (систолическое АД) + UtAPI + PIGF (и в расширенных вариантах добавляли PAPP-A). Для ранней ПЭ (< 34 недель) при 10 % позитивных результатах скрининга выявляемость составила 84,4 % при AUC ~0,92; для преждевременной ПЭ (< 37 недель) выявляемость была 77,8 % (AUC ~0,913), а для всей ПЭ – 55,7 % (AUC ~0,846). По сути, модель МО в этой когорте показала сопоставимые результаты с конкурирующей «классической» моделью риска, что ценно именно как независимая проверка [10].

В когорте беременных из Китая эффективность аналогичного подхода, основанного на скрининге I триместра, повышали за счет перебора нескольких алгоритмов. В проспективной когорте Т. Li с соавт. (включены 4644 беременных из 5116) данные собирали в 11–13 недель, а в модель включали материнские характеристики, САД, UtAPI, PAPP-A и PIGF. Среди сравниваемых алгоритмов (логистическая регрессия, Extra Trees, Gaussian Process, stacking и др.) лучшими по предсказанию преждевременной ПЭ были комплексные подходы: для «voting classifier» AUC достигала 0,884 при выявляемости 62,5 % на уровне 10 % FPR. Для «всей ПЭ» показатели были скромнее – AUC ~0,83, выявляемость около 51 % при 10 % FPR, что типично и для других работ (ранняя/преждевременная ПЭ «предсказывается» лучше, чем ПЭ в целом) [11].

В другом ретроспективном исследовании, посвященном скринингу I триместра, Н. Liang с соавт. разрабатывали модель, повышающую точность за счет дополнительных лабораторных и воспалительных индексов (внутренняя выборка  $n = 100$ , внешняя валидация  $n = 70$ ; прогноз до 12 недель) и сравнивали логистическую регрессию, метод опорных векторов (англ. support vector machine, SVM), «случайный лес» (англ. random forest) и нейросетевой подход. После отбора признаков в модель вошли плацентарные и сосудистые маркеры (PIGF, UtAPI), параметры коагуляции – D-димер, активированное частичное тромбопластиновое время (АЧТВ) и воспалительные индексы – отношение нейтрофилов к лимфоцитам (англ. neutrophil-to-lymphocyte ratio, NLR), отношение тромбоцитов к лимфоцитам (англ. platelet-to-lymphocyte ratio, PLR) и др. Лучший результат показала нейросеть: AUC = 0,917 на внутреннем тестировании и 0,838 на внешней проверке. Важно, что при малом размере выборки такие цифры требуют осторожной интерпретации, но сама тенденция понятна: добавление маркеров плацентарной функции и маркеров системной реакции повышает информативность [12].

Интересный частный случай применения моделей, основанных на мультипараметрических данных мониторинга I триместра, представлен исследованием, где проблема была в сопоставимости измерений. В работе Z. Zhao с соавт. авторы столкнулись с тем, что PIGF измеряли на разных платформах – платформа одномолекулярного ультрачувствительного иммуноанализа (англ. Single Molecule Array, SiMoA) и Elecsys, и предложили калибровку значения PIGF с помощью простой нейросетевой регрессии на небольшом калибровочном наборе. Основная прогностическая модель строилась как «случайный лес» на 14 признаках (материнские факторы, АД, PIGF и др.) с разделением по наборам данных. При обучении на объединенном наборе данных, полученным из двух платформ, AUC составила ~0,76; на независимом тест-наборе AUC снижалась примерно до 0,71. Для I триместра отдельно анализировали подвыборку (65 случаев ПЭ и 190 контролей), где AUC также была на уровне ~0,70–0,76 в зависимости от схемы валидации. Практический вывод здесь очень прикладной: качество предсказания может заметно зависеть от того, насколько аккуратно сведены данные из разных лабораторных систем [13].

Исследование V.P. Kovacheva с соавт. ( $n = 1125$ ) было посвящено оценке вклада генетической предрасположенности в прогноз ПЭ. В I триместре модели показывали умеренную дискриминацию (AUC ~0,74 на XGBoost), а ближе к родам клинические переменные давали AUC ~0,91. Добавление полигенного компонента не показало существенного преимущества [14].

Некоторые работы, посвященные прогнозированию ПЭ во II–III триместрах, демонстрируют, что в обычной клинической практике уже накоплено достаточно данных для прогнозирования без каких-либо других дополнительных параметров. В ретроспективном

исследовании Y.X. Li с соавт. использовали ЭМК и 38 клинических параметров, доступных при первом визите во II триместре (ранний II триместр). Из нескольких алгоритмов лучшим оказался градиентный бустинг (XGBoost): AUC = 0,955 при высокой общей точности (0,920) и чувствительности порядка 0,789. Наиболее информативными оказались вполне рутинные клинические показатели: среднее АД (МАР), индекс массы тела (ИМТ) и уровень глюкозы натощак. Авторы также пробовали упрощенную модель на данных, сообщаемых пациентами, с AUC ~0,83, что важно для внедрения [15].

Если фокус смещается на поздние формы ПЭ, во II и III триместрах начинает играть роль динамика лабораторных показателей. В работе J.H. Jhee с соавт. (n = 11006) прогнозировали позднюю ПЭ (после 34 недель), используя данные с 14–17 недель и до 34 недель. В модель включали ряд рутинных показателей (САД, азот мочевины, креатинин, тромбоциты, калий, лейкоциты, кальций, протеинурия). Среди сравниваемых методов наилучший результат показал вариант градиентного бустинга (C-statistic = 0,924), превосходя логистическую регрессию и ряд других алгоритмов [16].

Отдельная и клинически перспективная линия исследований – прогнозирование по наиболее ранним признакам до дебюта ПЭ. В многоцентровом ретроспективном исследовании S. Chen с соавт. (6 больниц; 1965 беременностей: 144 ранней ПЭ, 363 поздней ПЭ, 231 преждевременной ПЭ и 1458 контролей; данные ранней беременности, медиана около 12–13 недель) строили модели отдельно для различных подтипов ПЭ (ранняя ПЭ, поздняя ПЭ и ПЭ на ранних сроках беременности) на сочетании клинических факторов (в первую очередь, САД и ИМТ) и лабораторных индикаторов. Для ранней ПЭ ключевыми оказались, помимо ИМТ/АД, мочева кислота, моноциты и соотношение АСТ/АЛТ (аспартатаминотрансфераза/аланинаминотрансфераза), а также анамнестические маркеры, например, вспомогательные репродуктивные технологии (ВРТ). Во внешней валидационной выборке (англ. external validation set, EV set) добавление лабораторных показателей повышало качество модели по сравнению с «клиническим минимумом»: для ранней ПЭ AUC составляла около 0,86 (против ~0,79 у клинической модели), при чувствительности ~72 % и специфичности ~85 %; для поздней ПЭ AUC также была около 0,86 (против ~0,83 у клинической модели) при чувствительности ~70 % и специфичности ~85 %. Для преждевременной ПЭ ансамблевая модель обеспечивала чувствительность около 63 % при специфичности ~85 % во внешней валидационной выборке [17].

Проспективные данные первородящих позволяют оценить, как растет качество прогноза по мере накопления наблюдений. В исследовании Y.C. Lin с соавт. (n = 1857, первородящие) прогнозировали тяжелую ПЭ/эклампсию на 3 визитах: 6–13 недель, 16–21 неделя и 22–29 недель. AUC последовательно увеличивалась (0,72 → 0,75 → 0,77). Среди

наиболее значимых по вкладу признаков постоянно фигурировали ИМТ и показатели АД, а из биомаркеров особенно выделялись PIGF и эндоглин [18]. Практически это подчеркивает очевидное, но важное: по мере роста гестационного срока и количества измерений прогноз становится точнее, а ключевые параметры ограничиваются рутинно измеряемыми при наблюдении беременности.

Крупные когорты, основанные на рутинно собираемых факторах риска, показывают, что приемлемое качество прогноза может быть достигнуто и без сложных биомаркеров. В исследовании S.A. Tiruneh с соавт. (ретроспективная когорта,  $n = 48250$ ; данные 2016–2021 гг.; признаки из материнских характеристик и анамнеза) сравнивали логистическую регрессию, XGBoost и «случайный лес». Лучший результат показал «случайный лес» ( $AUC = 0,84$ ), далее шли XGBoost ( $AUC = 0,77$ ) и логистическая регрессия ( $AUC = 0,75$ ). Наиболее важными предикторами оказались первородство, ИМТ в начале беременности, анамнез ПЭ, возраст матери, семейный анамнез гипертензии, хроническая артериальная гипертензия (АГ) и диабет [19].

В другой работе те же авторы выполнили проверку на более позднем потоке данных. В темпоральной валидации S.A. Tiruneh с соавт. использовали уже более поздний период (июль 2021 – декабрь 2022;  $n = 12549$ ; 431 случай ПЭ) и оценили те же модели на новом потоке пациенток. Здесь AUC снизилась, составив около 0,76 для логистической регрессии, 0,75 для XGBoost и 0,71 для «случайного леса», т. е. переносимость на последующие годы оказалась ограниченной, что очень типично для моделей на рутинных данных и подчеркивает необходимость постоянного контроля качества при внедрении [20].

Вариант динамического прогнозирования, когда риск обновляется на каждом визите, представлен в работе I.-L. Shyu с соавт. ( $n = 2444$ ; данные с  $\geq 10$  недель; анализировали 19698 визитов, 350 случаев ПЭ). Модели обучали на типичных для амбулаторного наблюдения параметрах (гестационный срок, масса тела, АД, анамнез, лабораторные признаки), балансировали классы и оценивали несколько алгоритмов. Лучший результат дал XGBoost с  $AUC = 0,921$ ; среди ведущих предикторов постоянно были диастолическое/систолическое АД и глюкоза мочи. С клинической точки зрения, это удобная концепция – риск можно пересчитывать после каждого посещения, а не один раз в начале беременности [21].

Похожие идеи временного прогнозирования развиваются и в более сложных математических формах. В исследовании V.W. Eberhard с соавт. ( $n = 66425$ ; ретроспективная когорта 2015–2023 гг.) применяли модель выживаемости на основе глубокого обучения, которая формирует временные траектории риска (по сути, обновляемый прогноз, «когда» может развиваться ПЭ). Дискриминация была на уровне AUC около 0,78, сопоставимо с

традиционными подходами выживаемости, но добавлялась интерпретируемость траекторий и возможность группировать пациенток по типу риска [22].

В более поздней работе тех же авторов (другой дизайн) В.W. Eberhard с соавт. построили серию моделей на 8 сроках беременности (14, 20, 24, 28, 32, 34, 36, 38 недель) на большой когорте ( $n = 101357$ ; 3 клиники, 2015–2023 гг.) и проверили переносимость на внешней проспективной когорте первородящих. Внутри системы здравоохранения AUC обычно лежала в диапазоне примерно 0,71–0,80 (в зависимости от срока), но при внешней проверке падала до 0,57–0,70. Этот результат хорошо иллюстрирует, что даже при большой выборке и высоких показателях внутренней валидации внешний перенос остается главным испытанием для моделей на ЭМК [23].

### **Модели на административных и страховых данных: популяционный масштаб ценой клинической детализации / Models on administrative and insurance data: population scale at the cost of clinical detail**

Отдельную группу составляют модели, обученные на крупных административных базах данных, где клиническая глубина меньше, но объем выборки существенно больше. В работе R. Bennett с соавт. применяли нейросетевую модель из 3 источников данных: Texas PUDF (360943 родов, 14375 ПЭ), Оклахома PUDF (84632 родов, 721 ПЭ) и MOMI (31431 беременность, 2743 ПЭ). Качество (AUC) было умеренным и сильно зависело от базы данных: около 0,663 (Техас), 0,635 (Оклахома) и 0,765 (MOMI). В MOMI авторы отдельно подчеркивали возможность максимально раннего прогноза с учетом «скачков» АД в первые 14 недель. Это, по сути, модель «популяционного риска», полезная для стратификации, но не всегда заменяющая клинический скрининг с биомаркерами [24].

В исследовании Н. Sufriyana с соавт. использовали национальную страховую базу Индонезии (nested case-control: 3318 случаев ПЭ/эклампсии и 19883 контроля), из 95 признаков отобрали 17 и обучили «случайный лес». Внешнюю проверку организовали как географическую и темпоральную. Наилучшее качество наблюдалось при прогнозе за 9–12 месяцев до события: AUC = 0,88 (географическая валидация) и 0,86 (темпоральная). Это интересный пример того, как даже «административные» признаки несут сигнал риска задолго до клинической манифестации, но интерпретация таких моделей должна учитывать ограниченность клинических деталей [25].

### **Модели для дифференциальной диагностики гипертензивных расстройств / Models for differential diagnosis of hypertensive disorders**

Отдельного внимания заслуживает работа Y. Chen с соавт., в которой решалась задача дифференциальной диагностики между гестационной гипертензией и ПЭ на основе базовых клинических и лабораторных показателей. Внутренняя когорта включала 1157 женщин (424

ПЭ и 733 гестационная гипертензия), внешняя когорта состояла из 478 женщин. Среди 7 алгоритмов лучшими были XGBoost и AdaBoost; для XGBoost AUC достигала ~0,763 на внутренней валидации и 0,843 на внешнем тесте. В качестве значимых предикторов выделялись тиреотропный гормон (ТТГ), возраст, средний объем эритроцитов (англ. mean corpuscular volume, MCV), триглицериды, D-димер, альбумин и мочевая кислота. Для практики это сигнал о том, что стандартные лабораторные панели и эндокринные маркеры могут помочь в стратификации внутри «серой зоны» гипертензивных расстройств [26].

### **Заключение по прогнозированию преэклампсии / Conclusion on preeclampsia prediction**

Если обобщить именно результаты (без учета авторских интерпретаций в разделах «обсуждение»), то по включенным в настоящий обзор исследованиям довольно стабильно повторяются 3 вывода.

Артериальное давление и его производные – систолическое (САД) и диастолическое артериальное давление (ДАД) почти всегда входят в число сильнейших предикторов. Это видно и в моделях I триместра [9–11], и в динамических моделях по визитам, и в моделях по рутинным данным [17, 19, 21].

Плацентарные маркеры и UtAPI дают наиболее заметный прирост для ранней/преждевременной ПЭ [9–12].

Рутинные лабораторные панели (мочевая кислота, тромбоцитарные показатели, АСТ/АЛТ и др.) могут ощутимо улучшать ранний прогноз, особенно если модель нацелена на раннюю ПЭ (англ. early-onset preeclampsia, EOPE) и использует мультипараметрический профиль, а не один маркер [16, 17].

При этом на уровне результатов четко видно: там, где есть внешняя проверка (другая клиника, другой период времени), качество часто становится ниже, чем при внутренней оценке [20, 23]. Такое снижение качества типично для моделей, валидированных на внешних данных: они хорошо учатся на своем потоке данных и хуже переносятся на другой, если не предусмотрены механизмы адаптации и контроля.

**Таблица 1.** Применение искусственного интеллекта в прогнозировании преэклампсии (ПЭ).

**Table 1.** Applications of artificial intelligence in preeclampsia (PE) prediction.

Исследование [ссылка] Study [reference]	Дизайн / источник Design / source	Выборка (n) Sample (n)	Срок прогноза Prediction horizon	Модель Model	Параметры Parameters	Результаты Results	Валидация Validation	Качество Quality
Liang H. et al., 2025 [12]	Ретроспективное, одноцентровое (Китай) Retrospective, single-center (China)	100 (50 ПЭ / 50 контроль) + внешняя выборка 70 (35 / 35) 100 (50 PE / 50 controls) + external set 70 (35 / 35)	I триместр (ранняя беременность) First trimester (early pregnancy)	Нейронная сеть (NNET) после LASSO-отбора Neural network (NNET) after LASSO selection	12 признаков: PlGF, UtAPI, СРБ, NLR, другие биохимические и гематологические показатели, а также АД 12 features: PlGF, UtAPI, CRP, NLR, other biochemical and hematological markers, and BP	AUC = 0,917; внешняя валидация: AUC = 0,838 AUC = 0.917; external validation: AUC = 0.838	Внешняя (независимая) + внутреннее сравнение 7 моделей External (independent) + internal comparison of 7 models	ROBINS-I: серьезный риск ROBINS-I: serious risk
Shyu I.-L. et al., 2025 [21]	Ретроспективное, больничная информационная система (Тайвань) Retrospective, hospital information system (Taiwan)	2444	≥ 10 нед; по визитам ≥ 10 weeks; per-visit prediction	XGBoost	Возраст, ИМТ, АД, факторы риска, анамнез Age, BMI, BP, risk factors, medical history	AUC = 0,921; точность – 0,912; чувствительность – 0,858; специфичность – 0,926 AUC = 0.921; accuracy – 0.912; sensitivity – 0.858; specificity – 0.926	Внутренняя (70 / 30), SMOTE Internal (70 / 30), SMOTE	ROBINS-I: умеренный риск ROBINS-I: moderate risk

Исследование [ссылка] Study [reference]	Дизайн / источник Design / source	Выборка (n) Sample (n)	Срок прогноза Prediction horizon	Модель Model	Параметры Parameters	Результаты Results	Валидация Validation	Качество Quality
Eberhard B.W. et al., 2024 [22]	Ретроспективная когорта, 2 третичных центра (США) Retrospective cohort, 2 tertiary centers (USA)	66425	Динамический на протяжении беременности Dynamic prediction throughout pregnancy	DeepHit (глубокая модель выживаемости) DeepHit (deep survival)	Высокомерные предикторы из ЭМК с учетом времени High-dimensional time-aware EHR predictors	AUC = 0,78 (сопоставимо с моделью Cox) AUC = 0.78 (comparable to the Cox model)	Внутренняя оценка Internal evaluation	ROBINS-I: умеренный риск ROBINS-I: moderate risk
Chen Y. et al., 2025 [26]	Ретроспективное, ЭМК; дифференциальная диагностика гестационной гипертензии и ПЭ Retrospective, EHR; differential diagnosis of gestational hypertension vs PE	1157 (гестационная гипертензия – 733; ПЭ – 424) 1157 (gestational hypertension – 733; PE – 424)	Госпитальный этап Hospital stage	XGBoost	7 признаков: ТТГ, возраст, MCV, ТГ, D-димер, альбумин, мочевая кислота 7 features: TSH, age, MCV, TG, D-dimer, albumin, uric acid	AUC: обучающая выборка – 0,930; проверочная выборка – 0,763; тестовая выборка – 0,843 AUC: train 0.930; val 0.763; test 0.843	5-кратная кросс-валидация + разделение на обучающую, проверочную и тестовую выборки 5-fold cross-validation + train / val / test	ROBINS-I: серьезный риск ROBINS-I: serious risk

Исследование [ссылка] Study [reference]	Дизайн / источник Design / source	Выборка (n) Sample (n)	Срок прогноза Prediction horizon	Модель Model	Параметры Parameters	Результаты Results	Валидация Validation	Качество Quality
Bennett R. et al., 2022 [24]	Ретроспективные реестры / административные данные (США) Retrospective registries / administrative data (USA)	Texas 360943; Оклахома 125652; МОМ1 32361 Texas 360943; Оклахома 125652; МОМ1 32361	Ранняя беременность по данным выписки / кодам Early pregnancy based on discharge data / codes	Глубокая нейронная сеть с учетом значимости ошибок Cost-sensitive deep neural network	Диагнозы, процедуры, демография; анализ важности признаков Diagnoses, procedures, demographics; feature-importance analysis	AUC: Texas 0,663; Оклахома 0,649; МОМ1 0,710 AUC: Texas 0.663; Oklahoma 0.649; МОМ1 0.710	Внешняя проверка на независимых наборах External validation on independent datasets	ROBINS-I: умеренный риск ROBINS-I: moderate risk
Li T. et al., 2024 [11]	Проспективная когорта (Китай) Prospective cohort (China)	5116, включены; финально 4644 (ПЭ 210) 5116, enrolled; final analysis 4644 (PE 210)	11–13 <sup>+6</sup> недель 11–13 <sup>+6</sup> weeks	Voting Classifier (ансамбль) Voting Classifier (ensemble)	Материнские факторы + СрАД + UtAPI + PlGF + PAPP-A Maternal factors + MAP + UtAPI + PlGF + PAPP-A	Преждевременная ПЭ: AUC = 0,856; DR при 10 % FPR – 0,625 Preterm PE: AUC = 0.856; DR at 10 % FPR – 0.625	5-кратная кросс-валидация; разделение на обучающую и тестовую выборки 8:2 5-fold cross-validation; train-test split 8:2	NOS: 7/9 NOS: 7/9

Исследование [ссылка] Study [reference]	Дизайн / источник Design / source	Выборка (n) Sample (n)	Срок прогноза Prediction horizon	Модель Model	Параметры Parameters	Результаты Results	Валидация Validation	Качество Quality
Kovacheva V.P. et al., 2024 [14]	Ретроспективная когорта, ЭМК + генетика (США) Retrospective cohort, EHR + genetics (USA)	1125	До 14 нед; отдельно перед родоразрешением Up to 14 weeks; separately before delivery	XGBoost	Клинические факторы риска; дополнительно полигенный показатель риска для САД Clinical risk factors; plus SBP polygenic risk score	AUC: ранняя беременность – 0,74; поздняя – 0,91 AUC: early pregnancy – 0.74; late pregnancy – 0.91	Внутренняя оценка Internal evaluation	ROBINS-I: умеренный риск ROBINS-I: moderate risk
Sufriyana H. et al., 2020 [25]	Ретроспективное «случай-контроль» на страховой базе (Индонезия) Retrospective nested case-control study using an insurance database (Indonesia)	3318 ПЭ / эклампсия + 19883 контроль 3318 PE / eclampsia + 19883 controls	Лучший период: 9–12 мес до исхода Best prediction window: 9–12 months before the outcome	Random Forest	Демография + анамнез / диагнозы; исходно 95 признаков, в модели 17 Demographics + history / diagnoses; 95 initial features, 17 retained in the model	Внешняя валидация: AUC = 0,88 (географическая) и 0,86 (темпоральная) External validation: AUC = 0.88 (geographic) and 0.86 (temporal)	Внешняя (географическая и темпоральная) External (geographic and temporal)	ROBINS-I: серьезный риск ROBINS-I: serious risk

Исследование [ссылка] Study [reference]	Дизайн / источник Design / source	Выборка (n) Sample (n)	Срок прогноза Prediction horizon	Модель Model	Параметры Parameters	Результаты Results	Валидация Validation	Качество Quality
Zhao Z. et al., 2024 [13]	Проспективное, малая выборка (Китай) Prospective study, small sample size (China)	Simoa – 72; Elecsys – 106; Fusion – 65; I триместр – 52 Simoa – 72; Elecsys – 106; Fusion – 65; first-trimester subset – 52	I триместр; также данные вне ранней беременности First trimester; also data beyond early pregnancy	Random Forest	PIGF + САД/АД + ИМТ + анамнез; SMOTE на основе метода K-средних PIGF + SBP/BP + BMI + history; K-means SMOTE	AUC около 0,739; для раннего прогноза – 0,702–0,763 AUC about 0.739; for early prediction – 0.702–0.763	10-кратная кросс-валидация, многократные прогоны 10-fold cross-validation, repeated runs	NOS: 6/9
Tiruneh S.A. et al., 2024 [19]	Ретроспективный анализ когорты (Австралия) Retrospective cohort analysis (Australia)	48250	От ранней беременности до родов From early pregnancy to delivery	Random Forest, XGBoost и др. Random Forest, XGBoost, etc.	Возраст, ИМТ, паритет, предшествующая ПЭ, хроническая гипертензия, сахарный диабет и др. Age, BMI, parity, prior PE, chronic hypertension, diabetes, etc.	AUC: Random Forest – 0,84; XGBoost – 0,77; логистическая регрессия – 0,74 AUC: Random Forest – 0.84; XGBoost – 0.77; logistic regression – 0.74	Внутренняя (обучающая / тестовая выборки) Internal (train / test)	ROBINS-I: умеренный риск ROBINS-I: moderate risk

Исследование [ссылка] Study [reference]	Дизайн / источник Design / source	Выборка (n) Sample (n)	Срок прогноза Prediction horizon	Модель Model	Параметры Parameters	Результаты Results	Валидация Validation	Качество Quality
Tiruneh S.A. et al., 2025 [20]	Темпоральная валидация в той же сети (Австралия) Same network temporal validation (Australia)	Разработка 48250; валидация 12549 Development 48250; validation 12549	Ранняя беременность Early pregnancy	Логистическая регрессия и XGBoost Logistic regression and XGBoost	Демография и анамнез: возраст, ИМТ, хроническая гипертензия, сахарный диабет и др. Demographics and history: age, BMI, chronic hypertension, diabetes mellitus, etc.	AUC во временной валидации: логистическая регрессия – 0,76; XGBoost – 0,75; Random Forest – 0,70 AUC in temporal validation: logistic regression – 0.76; XGBoost – 0.75; Random Forest – 0.70	Темпоральная (другой период) Temporal validation (different period)	ROBINS-I: умеренный риск ROBINS-I: moderate risk
Gil M.M. et al., 2024 [10]	Проспективная неинтервенционная когорта (Испания) Prospective non-interventional cohort (Spain)	10110	11–13 <sup>+6</sup> недель 11–13 <sup>+6</sup> weeks	Полносвязная нейронная сеть Neural network (fully connected)	Материнские факторы + СрАД + UtAPI + PIGF (+/- PAPP-A) Maternal factors + MAP + UtAPI + PIGF (+/- PAPP-A)	DR для преждевременной ПЭ – 72,7 % при 10 % SPR; AUC для всех случаев ПЭ – 0,848; AUC для преждевременной ПЭ – 0,912 DR for preterm PE – 72.7 % at 10 % SPR; AUC for all PE – 0.848; AUC for preterm PE – 0.912	Внешняя (новая страна / популяция) External (new country / population)	NOS: 8/9

Исследование [ссылка] Study [reference]	Дизайн / источник Design / source	Выборка (n) Sample (n)	Срок прогноза Prediction horizon	Модель Model	Параметры Parameters	Результаты Results	Валидация Validation	Качество Quality
Li Y.X. et al., 2021 [15]	Ретроспективное, ЭМК (Китай) Retrospective, EHR (China)	3759	Ранний II триместр Early second trimester	XGBoost	38 признаков ЭМК; ключевые: FPG, СрАД, ИМТ 38 EHR features; key predictors: FPG, MAP, BMI	AUC = 0,955; точность – 0,905 AUC = 0.955; accuracy – 0.905	Внутренняя + темпоральная Internal + temporal	ROBINS-I: серьезный риск ROBINS-I: serious risk
Jhee J.H. et al., 2019 [16]	Ретроспективная когорта (Корея), ЭМК Retrospective cohort (Korea), EHR	11006	От раннего II триместра до 34 нед From early second trimester to 34 weeks	Stochastic Gradient Boosting	14 предикторов: АД, лабораторные показатели, моча и др. 14 predictors: BP, laboratory parameters, urine tests, etc.	C-статистика – 0,924; точность – 0,973; FPR – 0,009 C-statistic – 0.924; accuracy – 0.973; FPR – 0.009	Внутренняя (70 / 30) Internal (70 / 30)	ROBINS-I: серьезный риск ROBINS-I: serious risk
Eberhard B.W. et al., 2025 [23]	Ретроспективное, 3 госпиталя (США) + внешняя nuMoM2b Retrospective, 3 hospitals (USA) + external nuMoM2b cohort	101 357 + внешняя nuMoM2b 101,357 + external nuMoM2b	8 временных точек: 14–36 нед 8 time points: 14–36 weeks	Несколько моделей; лучшие AUC варьировали Multiple models; best AUC values varied	Стандартные данные ЭМК и витальные параметры Routine EHR data and vital signs	Внутренняя AUC = 0,71–0,80; внешняя AUC = 0,57–0,70 Internal AUC = 0.71–0.80; external AUC = 0.57–0.70	Внешняя + мультиточечные модели External validation + multi-timepoint models	ROBINS-I: умеренный риск ROBINS-I: moderate risk

Исследование [ссылка] Study [reference]	Дизайн / источник Design / source	Выборка (n) Sample (n)	Срок прогноза Prediction horizon	Модель Model	Параметры Parameters	Результаты Results	Валидация Validation	Качество Quality
Ansbacher-Feldman Z. et al., 2022 [9]	Когортное скрининговое исследование (Великобритания) Cohort screening study (United Kingdom)	60789	11–13 <sup>+6</sup> недель 11–13 <sup>+6</sup> weeks	Искусственная нейронная сеть (2 скрытых слоя) Artificial neural network (2 hidden layers)	Материнские факторы + СрАД + UtAPI + PIGF + PAPP-A; анализ влияния расы Maternal factors + MAP + UtAPI + PIGF + PAPP-A; race-effect analysis	Все случаи ПЭ: AUC = 0,817; DR = 0,529; преждевременная PE: AUC = 0,909; DR = 0,753 All PE: AUC = 0.817; DR = 0.529; preterm PE: AUC = 0.909; DR = 0.753	Внутренняя: обучение / подбор / валидация Internal: train / tune / val	NOS: 8/9
Chen S. et al., 2025 [17]	Ретроспективное мультицентровое (6 больниц, Китай) Retrospective multicenter study (6 hospitals, China)	144 EOPE; 363 LOPE; 231 преждевременная ПЭ; 1458 контроль 144 EOPE; 363 LOPE; 231 preterm PE; 1458 controls	Ранняя беременность Early pregnancy	Ансамбль моделей (GBM + SVM и др.) Model ensemble (GBM + SVM, etc.)	ИМТ, SBP, ВРТ, привычная потеря беременности + UA, АЛТ, АСТ/АЛТ, МО и др. BMI, SBP, IVF, recurrent pregnancy loss + UA, ALT, AST/ALT, MO, etc.	EOPE: чувствительность 72,2 %, специфичность 85,3 %; LOPE: чувствительность – 69,6 %, специфичность – 85,3 % EOPE: sensitivity – 72.2 %, specificity – 85.3 %; LOPE: sensitivity – 69.6 %, specificity – 85.3 %	Внешняя выборка + cross-validation External validation set + cross-validation	ROBINS-I: умеренный риск ROBINS-I: moderate risk

Исследование [ссылка] Study [reference]	Дизайн / источник Design / source	Выборка (n) Sample (n)	Срок прогноза Prediction horizon	Модель Model	Параметры Parameters	Результаты Results	Валидация Validation	Качество Quality
Lin Y.C. et al., 2024 [18]	Проспективная когорта nuMoM2b, вторичный анализ Prospective nuMoM2b cohort, secondary analysis	1857	3 визита: 60–136, 160–216, 230–286 дней 3 visits: days 60–136, 160–216, and 230–286	Модели на ЭМК / опросниках Models based on EHR and questionnaires	Клинические данные по визитам; без сложных биомаркеров Visit-based clinical data; without complex biomarkers	AUC = 0,72 (визит 1), 0,75 (визит 2), 0,77 (визит 3) для sPE/E AUC = 0.72 (visit 1), 0.75 (visit 2), 0.77 (visit 3) for sPE/E	Внутренняя оценка по визитам Internal visit-based evaluation	NOS: 7/9

**Примечание:** ПЭ – преэклампсия; EOPE – ранняя преэклампсия; LOPE – поздняя преэклампсия;; sPE/E – тяжелая преэклампсия/эклампсия; ИМТ – индекс массы тела; АД – артериальное давление; СрАД – среднее артериальное давление; САД – систолическое артериальное давление; ЭМК – электронные медицинские карты; PIGF – плацентарный фактор роста; UtAPI – индекс пульсации маточной артерии; PAPP-A – ассоциированный с беременностью белок плазмы А; СРБ – С-реактивный белок; NLR – отношение нейтрофилов к лимфоцитам; ТТГ – тиреотропный гормон; MCV – средний объем эритроцитов; TG – триглицериды; UA – мочевая кислота; АЛТ – аланинаминотрансфераза; АСТ – аспартатаминотрансфераза; МО – моноциты; ВРТ – вспомогательные репродуктивные технологии; AUC – площадь под ROC-кривой; DR – частота выявления; FPR – частота ложноположительных результатов; SPR – частота положительного скринингового результата; SMOTE – метод синтетического увеличения выборки для миноритарного класса; LASSO – метод наименьшего абсолютного сжатия и отбора признаков; NNET – нейронная сеть; SVM – метод опорных векторов; GBM – градиентный бустинг; XGBoost – экстремальный градиентный бустинг; Random Forest – случайный лес; ансамблевый метод классификации, основанный на построении множества решений; Voting Classifier – классификатор голосования, ансамблевая модель, объединяющая прогнозы нескольких алгоритмов; DeepHit – нейросетевая модель анализа выживаемости для прогнозирования времени наступления события; Stochastic Gradient Boosting – стохастический градиентный бустинг; Fusion – комбинированная аналитическая платформа/панель признаков; модель Cox – модель пропорциональных рисков Кокса; FPG – глюкоза плазмы натощак; nuMoM2b – исследование исходов беременности у первородящих: наблюдение за будущими матерями; MOMI – база данных Magee Obstetric Medical and Infant; Simoa – платформа Single Molecule Array; Elecsys – иммуноаналитическая система Elecsys; NOS – шкала Ньюкасл–Оттава; ROBINS-I – инструмент оценки риска систематической ошибки в нерандомизированных исследованиях вмешательств.

**Note:** PE – preeclampsia; EOPE – early-onset preeclampsia; LOPE – late-onset preeclampsia; sPE/E – severe preeclampsia/eclampsia; BMI – body mass index; BP – blood pressure; MAP – mean arterial pressure; SBP – systolic blood pressure; EHR – electronic health records; PIGF – placental growth factor; UtAPI – uterine artery pulsatility index; PAPP-A – pregnancy-associated plasma protein A; CRP – C-reactive protein; NLR – neutrophil-to-lymphocyte ratio; TSH – thyroid-stimulating hormone; MCV – mean corpuscular volume; TG

– triglycerides; UA – uric acid; ALT – alanine aminotransferase; AST – aspartate aminotransferase; MO – monocytes; IVF – in vitro fertilization; AUC – area under the ROC curve; DR – detection rate; FPR – false positive rate; SPR – screen-positive rate; SMOTE – synthetic minority oversampling technique; LASSO – least absolute shrinkage and selection operator; NNET neural network; SVM – support vector machine; GBM – gradient boosting machine; XGBoost – extreme gradient boosting; ; Random Forest – ensemble classification method based on the construction of multiple decision trees; Voting Classifier – an ensemble classifier that combines predictions from multiple algorithms; DeepHit – a neural survival-analysis model for time-to-event prediction; Stochastic Gradient Boosting – stochastic gradient boosting; Fusion – a combined analytical platform/feature panel; Cox model – Cox proportional hazards model; FPG – fasting plasma glucose; nuMoM2b – Nulliparous Pregnancy Outcomes Study: Monitoring Mothers-to-Be; MOMI – Magee Obstetric Medical and Infant database; Simoa – Single Molecule Array platform; Elecsys – Elecsys immunoassay system; NOS – Newcastle–Ottawa Scale; ROBINS-I – Risk Of Bias In Non-randomized Studies of Interventions.

## **Общая характеристика включенных исследований, посвященных кровотечению / General characteristics of the included bleeding-related studies**

Аналогично публикациям по прогнозированию ПЭ, в отобранных публикациях по кровотечениям преобладают ретроспективные разработки моделей на данных ЭМК и стандартных клинико-лабораторных показателях; существенно реже встречаются проспективные дизайны. Временной горизонт прогноза почти всегда привязан к периоду родоразрешения: либо до начала родов/потуг, либо предоперационно перед кесаревым сечением, либо с использованием интра- и ранних послеродовых данных.

### **Модели на данных ЭМК в общей популяции / Models based on general population EHR data**

Самую крупную когорту представили J.M. Westcott с соавт.: 30867 родов, из них 2185 эпизодов кровотечения (определение включало оценочную кровопотерю > 1000 мл или необходимость трансфузии/дополнительного вмешательства). Авторы сравнили несколько алгоритмов и показали, что градиентный бустинг деревьев решений дает очень высокую дискриминацию: AUC = 0,979 при чувствительности 0,763 и общей точности 98,1 %. Отдельно важный практический момент: модель, ограниченная признаками, доступными до начала второго периода родов, почти не теряла качество (AUC = 0,955; чувствительность 0,737; точность 97,7 %), что ближе к реальному «прогнозу заранее», а не к постфактум-классификации [27].

S. Krishnamoorthy с соавт. анализировали 11000 случаев, включая 1042 случая послеродового кровотечения (англ. postpartum hemorrhage, PPH), и использовали большой набор признаков (149 параметров). Гибридная модель на основе многоуровневого автокодировщика после оптимизации гиперпараметров показала очень высокие показатели (AUC = 0,983), чувствительность – 98,88 %, специфичность – 96,96 %, общая точность классификации – 97,15 %. При этом клинически существенным ограничением остается то, что в публикации признаки описаны агрегировано, без ясной привязки к моменту, когда они становятся доступными врачу, поэтому интерпретировать это именно как ранний прогноз сложнее [28].

### **Естественные роды: от базовых факторов к интерпретируемым моделям / Vaginal birth: from basic factors to interpretable models**

В работе M. Akazawa с соавт. рассмотрены 9894 вагинальных родов (PPH > 1000 мл; n = 188). Авторы ограничились 11 клиническими переменными (возраст, паритет, рост/масса тела, срок гестации, масса плода, применение окситоцина, способ родоразрешения и др.) и сравнили несколько подходов. Наилучший результат оказался умеренным (AUC = 0,708; общая точность классификации = 0,686), причем разница между «сложными» моделями и логистической

регрессией не была драматичной [29]. Для практики это звучит так: на минимальном клиническом наборе факторов можно получить лишь среднюю дискриминацию, и многое упирается в то, насколько «богаты» входные данные.

Z. Song с соавт. использовали значительно более крупный материал и сделали акцент на интерпретации. В разработочной выборке было 24833 вагинальных родов (1623 случаев РРН), внешняя валидация проведена еще на 3099 случаях. РРН определяли как кровопотерю > 500 мл в течение 24 часов после родов с измерением по взвешиванию и учетом простыней/прокладок [30]. Среди нескольких алгоритмов лучшим оказался XGBoost: AUC = 0,894 на внутренней валидации и 0,880 на внешней (при очень высокой AUC на обучении 0,997, что само по себе намекает на риск переобучения). Авторы стартовали с 34 факторов и сократили их до 15 наиболее значимых, где фигурировали масса тела новорожденного, длительность периодов родов, преждевременный разрыв плодных оболочек (англ. premature rupture of membranes, PROM) и ряд организационно-акушерских параметров [30].

S. Holcroft с соавт. представили более «полевой» вариант: наблюдательное исследование типа «случай–контроль», анализ данных 430 родов в Северной Руанде (81 случай РРН), где исход (раннее РРН) определяли как кровопотерю > 500 мл в первый час после родов или необходимость переливания крови. Для прогноза использовали факторы, которые можно собрать до или в начале родов (страховой статус, многоплодие, дородовое кровотечение, внутриутробная гипоксия плода, гемоглобин в родах, возраст и др.). Среди сравниваемых моделей выбрали метод «случайного леса»; средняя чувствительность составила 80,7 %, специфичность – 71,3 %, частота ошибок классификации – 12,19 % [31]. Важно, что в этой работе лидировали очень «земные» предикторы, такие как уровень гемоглобина и возраст, т. е. модель формализовала уже используемые клинические признаки [31].

### **Кесарево сечение, placenta previa и PAS: предоперационный риск и «мульти-modalность» / Caesarean section, placenta previa, and PAS: preoperative risk and "multimodality"**

Отдельный класс исследований посвящен ситуации, когда кровотечение ожидается во время кесарева сечения (особенно при placenta previa/PAS), и врач заинтересован в предоперационной стратификации риска.

M. Akazawa и K. Hashimoto рассмотрели 48 пациенток с placenta previa (тяжелое кровотечение определяли как  $\geq 2000$  мл; таких было 26). Модель строили мульти-modalно: табличные данные – 9 параметров, включая уровень гемоглобина (англ. hemoglobin, Hb), количество лейкоцитов (англ. white blood cell count, WBC), количество тромбоцитов (англ. platelet

count, PLT) в сочетании с магнитно-резонансной томографией (МРТ) в T2-взвешенном режиме плаценты. Мультиmodalный вариант дал общую точность классификации = 0,680 и AUC = 0,735, превосходя табличную модель (AUC = 0,576) и модель только по МРТ (общая точность классификации = 0,537). Интересно, что и «человек-эксперт» на тех же данных показывал примерно сопоставимую точность (0,614), т. е. преимущество мультиmodalности здесь есть, но на фоне очень малого размера выборки и без внешней валидации выводы остаются осторожными [32].

М. Li с соавт. разработали интерпретируемую модель для РРН у пациенток с placenta previa при кесаревом сечении: всего 845 случаев с внутренним разделением на обучающую (n = 403) и тестовую (n = 174) подвыборки и внешней валидацией (n = 268). РРН определяли как кровопотерю  $\geq 1000$  мл в течение 24 часов. Входные данные были строго предоперационные: лабораторные тесты в пределах недели до операции и ультразвуковая оценка PAS. Лучшей оказалась модель градиентного бустинга: AUC = 0,880 на тестовой выборке и 0,810 на внешней. Среди наиболее весомых факторов выделялись D-димер, ультразвуковые признаки PAS, нейтрофилы, протромбиновое время и тромбоциты, что хорошо «стыкуется» с клинической логикой риска кровотечения [33].

М. Wang с соавт. пошли по другой траектории: вместо бинарного исхода они предсказывали количественный объем кровопотери при кесаревом сечении. Это ретроспективная выборка 6144 операций (после очистки – 5468 записей), где использовали пред- и интраоперационные данные ЭМК, включая клинические параметры, записи анестезиологов и лабораторные показатели. Среди 6 моделей лучше всех показал себя метод «случайного леса» в регрессии: средняя абсолютная ошибка (англ. mean absolute error, MAE) составила 21,7 мл, а корень из средней квадратической ошибки (англ. root mean squared error, RMSE) – 33,75 мл (авторы интерпретировали это как ошибку порядка 5,4 % и 9,3 %). По перестановочной важности ключевыми оказались кальций (Ca), Hb, WBC, PLT, натрий (Na) и калий (K) [34]. Для практики это звучит полезно: простые и рутинные лабораторные показатели могут быть не только «фоном», но и рабочими маркерами для ожидаемой кровопотери.

Наконец, S. Miller с соавт. рассматривали PAS как ключевой источник массивной кровопотери при placenta previa, сравнив группу тяжелого PAS (n = 33) и placenta previa без PAS (n = 21). Образцы крови собирались проспективно, в среднем в III триместре (около 33–36 недель). Авторы проверили, добавляет ли метаболомика/липидомика что-то к клиническим факторам, используя регрессию эластичной сети (англ. elastic net) с многократно повторяемой кросс-валидацией. Результат получился прагматичным: клинические характеристики сами по себе дали

AUC = 0,685, липидомика – 0,699, метаболомика – 0,711, а комбинирование не улучшило качество (AUC = 0,69), т. е. в этом материале «омикс» данные представляют исследовательский интерес, но пока не дает прорыва по сравнению с нормальной клиникой [35].

### Мультицентровая оценка алгоритмов прогнозирования PPH / Multicenter evaluation of PPH prediction algorithms

C. Susanu с соавт. провели проспективное мультицентровое исследование на 203 пациентках (68 случаев PPH). При сравнении нескольких алгоритмов наилучшие результаты показал наивный байесовский классификатор (англ. Naïve Bayes): общая точность классификации – 0,95, специфичность – 0,97, чувствительность – 0,76, AUC = 0,76 [36]. Эти данные показывают, что даже на относительно небольшой проспективной выборке можно получить клинически полезную модель, однако ее дискриминационная способность остается умеренной (табл. 2).

**Таблица 2.** Применение искусственного интеллекта в прогнозировании кровотечения.

**Table 2.** Application of artificial intelligence in hemorrhage prediction.

Исследование, [ссылка] Study, [reference]	Дизайн / выборка Design / sample	Этап прогнозирования Prediction stage	Модель и параметры Model and parameters	Основные результаты Main results	Качество Quality
Krishnamoorthy S. et al., 2022 [28]	Ретроспективное, N = 11000; PPH = 1042 Retrospective, N = 11000; PPH = 1042	Перипартум Peripartum	OBCSA-OSAE; 149 клинических признаков OBCSA-OSAE; 149 clinical features	AUC = 98,33; точность – 97,15 AUC = 98.33 accuracy – 97.15	ROBINS-I: серьезный риск ROBINS-I: serious risk
Westcott J.M. et al., 2022 [27]	Ретроспективная когорта, N = 30867; кровотечение = 2185 Retrospective cohort, N = 30867; hemorrhage = 2185	До родов; отдельно до 2-го периода родов Before delivery; separately before the second stage of labor	GBM; 123 признака и укороченная модель на 28 признаках GBM; 123 features and a reduced 28-feature model	AUC = 0,979 и 0,955 (до 2-го периода) AUC = 0.979 and 0.955 (before the second stage)	ROBINS-I: умеренный риск ROBINS-I: moderate risk
Akazawa M. et al., 2021 [29]	Ретроспективное; естественные роды, N = 9894; PPH = 188 Retrospective; vaginal births, N = 9894; PPH = 188	При поступлении / в ходе родов At admission / during labor	ML + нейросеть; 11 клинических переменных ML + neural network; 11 clinical variables	Лучшая модель: AUC = 0,708; точность – 0,686 Best model: AUC = 0.708; accuracy – 0.686	ROBINS-I: серьезный риск ROBINS-I: serious risk
Song Z. et al., 2025 [30]	Ретроспективное мультицентровое; N = 24833, внешняя валидация N = 3099 Retrospective multicenter; N = 24833, external validation N = 3099	Перинатально: беременность + первые 24 ч после родов Perinatal: pregnancy + first 24 h postpartum	XGBoost + SHAP; 34 фактора, затем 15 ключевых XGBoost + SHAP; 34 factors, then 15 key factors	AUC = 0,894 (внутренняя), 0,880 (внешняя) AUC = 0.894 (internal), 0.880 (external)	ROBINS-I: серьезный риск ROBINS-I: serious risk

Исследование, [ссылка] Study, [reference]	Дизайн / выборка Design / sample	Этап прогнозирования Prediction stage	Модель и параметры Model and parameters	Основные результаты Main results	Качество Quality
Holcroft S. et al., 2024 [31]	Случай-контроль, N = 430; PPH = 81 Case-control, N = 430; PPH = 81	До родов / в начале родов Before delivery / at labor onset	Random Forest; Hb в родах, возраст и др. Random Forest; intrapartum Hb, age, etc.	Чувствительность 80,7; специфичность 71,3 Sensitivity 80.7; specificity 71.3	NOS: 6/9 NOS: 6/9
Wang M. et al., 2024 [34]	Ретроспективное; кесарево сечение, N = 6144, в анализе 5468 Retrospective; cesarean section, N = 6144, analyzed 5468	Пре- и интраоперационно Pre- and intraoperatively	RF-регрессия; 27 показателей (клинические, лабораторные, анестезиологические) RF regression; 27 variables (clinical, laboratory, anesthetic)	MAE = 21,7; RMSE = 33,75; значимые предикторы: Ca, Hb, WBC, PLT, Na, K MAE = 21.7; RMSE = 33.75; significant predictors: Ca, Hb, WBC, PLT, Na, K	ROBINS-I: умеренный риск ROBINS-I: moderate risk
Susanu C. et al., 2024 [36]	Проспективное мультицентровое, N = 203; PPH = 68 Prospective multicenter, N = 203; PPH = 68	Перинатально Perinatal	Naive Bayes (лучшая модель) Naive Bayes (best model)	Точность – 0,95; Чувствительность 0,76; специфичность 0,97; AUC = 0,76 Accuracy – 0.95; Sensitivity 0.76; specificity 0.97; AUC = 0.76	NOS: 6/9 NOS: 6/9
Akazawa M. et al., 2023 [32]	Ретроспективное; placenta previa, N = 48; $\geq 2000$ мл = 26 Retrospective; placenta previa, N = 48; $\geq 2000$ mL = 26	Предоперационно Preoperatively	Мультимодальная модель глубокого обучения (табличные данные + МРТ) Multimodal deep learning model (tabular data + MRI)	Точность – 0,68; AUC = 0,74 Accuracy – 0.68; AUC = 0.74	ROBINS-I: серьезный риск ROBINS-I: serious risk
Li M. et al., 2025 [33]	Ретроспективное; placenta previa + КС, N = 845, внешняя валидация N = 268 Retrospective; placenta previa + CS, N = 845, external validation N = 268	Предоперационно Preoperatively	Gradient Boosting; D-димер, УЗИ-признаки PAS, нейтрофилы, ПВ, PLT Gradient boosting; D-dimer, ultrasound signs of PAS, neutrophils, PT, PLT	AUC = 0,880 (тестовая выборка), 0,810 (внешняя валидация) AUC = 0.880 (test), 0.810 (external)	ROBINS-I: умеренный риск ROBINS-I: moderate risk

Исследование, [ссылка] Study, [reference]	Дизайн / выборка Design / sample	Этап прогнозирования Prediction stage	Модель и параметры Model and parameters	Основные результаты Main results	Качество Quality
Miller S. et al., 2025 [35]	<p>Перспективный сбор; PAS = 33, placenta previa = 21</p> <p>Prospective collection; PAS = 33, placenta previa = 21</p>	<p>III триместр; забор крови примерно на 33–36-й неделе</p> <p>Third trimester; blood sampling at about 33–36 weeks</p>	<p>Эластическая сеть клинические данные ± метаболомика ± липидомика</p> <p>Elastic net; clinical data ± metabolomics ± lipidomics</p>	<p>AUC: клиника – 0,685; метаболомика – 0,711; комбинированная модель – 0,69</p> <p>AUC: clinical – 0.685; metabolomics – 0.711; combined model – 0.69</p>	<p>NOS: 5/9</p> <p>NOS: 5/9</p>

**Примечание:** N – объем выборки; PPH – послеродовое кровотечение; OBCSA – оппозиционный бинарный алгоритм поиска вороны; OSAE – оптимальный многослойный автокодировщик; AUC – площадь под ROC-кривой; ROBINS-I – риск систематической ошибки в нерандомизированных исследованиях вмешательств; ML – машинное обучение; GBM – градиентный бустинг; XGBoost – экстремальный градиентный бустинг; SHAP – аддитивные объяснения Шепли; Hb – гемоглобин; Random Forest — случайный лес; ансамблевый метод классификации, основанный на построении множества решений; MAE – средняя абсолютная ошибка; RMSE – корень из среднеквадратичной ошибки; Ca – кальций; WBC – количество лейкоцитов; PLT – количество тромбоцитов; Na – натрий; K – калий; MPT – магнитно-резонансная томография; PAS – спектр нарушений приращения плаценты; ПВ – протромбиновое время; КС – кесарево сечение; Naive Bayes – наивный байесовский классификатор; NOS – шкала Ньюкасла-Оттавы.

**Note:** N – sample size; PPH – postpartum hemorrhage; OBCSA – oppositional binary crow search algorithm; OSAE – optimal stacked autoencoder; AUC – area under the curve; ROBINS-I – Risk Of Bias In Non-randomized Studies of Interventions; ML – machine learning; GBM – gradient boosting machine; XGBoost – Extreme Gradient Boosting; SHAP – Shapley Additive exPlanations; Random Forest – ensemble classification method based on the construction of multiple decision trees; MAE – mean absolute error; RMSE – root mean squared error; Ca – calcium; WBC – white blood cell count; PLT – platelet count; Na – sodium; K – potassium; MRI – magnetic resonance imaging; PAS – placenta accreta spectrum; PT – prothrombin time; CS – cesarean section; Naive Bayes – naive Bayes classifier; NOS – Newcastle-Ottawa Scale.

## Обсуждение / Discussion

Проведенный систематический обзор хорошо иллюстрирует главный парадокс современных моделей ИИ: при наличии больших объемов клинических и лабораторных данных алгоритмы действительно способны идентифицировать риск осложнений раньше врача, однако ни одна модель пока не способна демонстрировать стабильный результат в период длительного использования. Наш обзор включает в себя 28 статей, 18 из которых посвящены ПЭ, а 10 – акушерским кровотечениям, что уже позволяет нам сделать выводы о типичных подходах, сильных и слабых сторонах доказательной базы.

Во многих исследованиях, посвященных ПЭ, прослеживаются 2 стратегии подхода к данному состоянию. Первая наиболее логичная и очевидная: скрининг в I триместре с использованием материнских факторов риска, артериального давления (САД), доплерометрии

маточных артерий (UtAPI) и плацентарных биомаркеров (в первую очередь PlGF, иногда PAPP-A). Именно по вышеуказанным параметрам модели ИИ показывают наиболее значимые цифры: для ранней ПЭ качество обычно выше, чем для ПЭ с дебютом в различные периоды, что ожидаемо, поскольку ранние формы теснее связаны с плацентарным компонентом и легче идентифицируются по маркерам плацентарной дисфункции. Данный факт также согласуется с результатами других исследований [9–11], включая и те, в которых не использовались модели ИИ/МО [37]. В исследовании PREVAL проводилась внешняя проверка в отношении прогностической значимости параметра PlGF. Проверка показала сопоставимую значимость [10].

Важным фактом, который транслируется во многих исследованиях, является то, что расширение лабораторных параметров значимо улучшает прогноз по сравнению с параметрами, предусмотренными стандартными клиническими анализами [9, 17]. В то же время сами алгоритмы (нейросети, бустинг, ансамбли) часто оказываются вторичны по сравнению с набором входных данных: при одинаковых предикторах разница между моделями нередко умеренная, а иногда простые подходы показывают сопоставимые результаты [20].

Вторая стратегия в отношении ПЭ связана с моделями МО, основанными на ЭМК и рутинных данных (анамнез, диагнозы, визиты, витальные показатели и стандартные лабораторные тесты). Подобный подход позволяет значимо масштабировать его применение, а также избежать использования дорогих биомаркеров. Однако обратной стороной является то, что после проверок AUC часто находится в диапазоне умеренной дискриминации [11, 20]. В клинической практике данного факта может быть достаточно для углубленного обследования.

Отдельного обсуждения заслуживает направление динамического прогнозирования, при котором модель обновляет прогноз после каждого последующего визита. Это наиболее применимо в реальной практике: новые данные (АД, масса тела, анализ мочи/крови) действительно меняют риск «онлайн». Примером служит модель I.-L. Shyu с соавт. (2025), где риск пересчитывался по визитам и качество оставалось высоким в рамках внутренней проверки [21]. Более сложные варианты, включая модели временных траекторий риска, также показывают перспективность концепции [22, 23].

Важным замечанием является то, что при внешней проверке качество множества моделей нередко снижается. Это видно и для временной проверки в пределах одной системы, и для переноса на внешнюю когорту [20, 23]. Практический вывод здесь скучный, но важный: внедрение модели без постоянного контроля (повторная калибровка, мониторинг качества, проверка на новых потоках) почти гарантированно приведет к ухудшению предсказаний со временем.

С клинической точки зрения наибольшая ценность раннего прогнозирования ПЭ напрямую связана с возможностью профилактики и изменения тактики ведения. Классический пример мировой литературы: профилактика низкими дозами ацетилсалициловой кислоты, начатая в ранние сроки у женщин высокого риска, снижает частоту ранней/преждевременной ПЭ [38]. Поэтому именно модели, работающие в I триместре, потенциально имеют самый большой «прикладной выход»: они могут помочь точнее выбрать женщин, которым профилактика и усиленное наблюдение принесут максимальную пользу [9, 10].

Касательно прогноза кровотечений картина более неоднородная и часто определяется временем, когда делается прогноз. В большинстве включенных работ прогноз практически всегда привязан к периоду родоразрешения: до начала родов/потуг, предоперационно перед кесаревым сечением или с использованием интра- и ранних послеродовых данных. Это логично с позиции доступности параметров, но создает методологический риск: чем ближе к событию берутся признаки, тем легче модели «угадать» исход.

Наиболее впечатляющие метрики получены в крупных ретроспективных исследованиях на данных ЭМК. В работе J.M. Westcott с соавт. (2022) при использовании широкого набора переменных из ЭМК модель градиентного бустинга демонстрировала крайне высокую дискриминацию. При этом важно, что авторы отдельно оценили вариант с ограничением признаков данными, доступными до второго периода родов, и качество снижалось незначительно [27].

Отдельное клинически значимое направление исследований касается кесарева сечения при предлежании плаценты, где врач заранее ожидает высокий риск массивной кровопотери и нуждается в предоперационной стратификации риска. Здесь интересен подход M. Li с соавт. (2025): строго предоперационные лабораторные данные и ультразвуковая оценка PAS позволяли получать высокие значения AUC, причем с падением качества на внешней выборке, что опять подчеркивает тему переносимости, но все же демонстрирует реальный потенциал для практики [33]. По сути, такие модели могут быть инструментом для принятия решений о маршрутизации пациентки, подготовке крови, выборе уровня стационара и привлечении мультидисциплинарной команды.

Мультимодальные решения выглядят перспективно, но ограничены малым объемом выборки и отсутствием внешней проверки. Поэтому результаты вроде AUC около 0,7 в работе M. Akazawa и K. Hashimoto (2023) воспринимаются скорее как пилотное исследование, чем как готовая клиническая технология [32].

Интересно, что попытки добавить «омикс»-данные (метабомика/липидомика) в прогноз массивной кровопотери при PAS, по крайней мере в имеющихся данных, не дали явного преимущества над клиническими факторами [35]. Это важный «приземляющий» результат: биомаркеры высокого уровня могут быть перспективны, но на текущем этапе рутинная клиника часто дает сопоставимую информативность, особенно когда речь идет о крайне небольших выборках.

Наконец, проспективные данные по кровотечениям немногочисленны и чаще показывают более умеренную дискриминацию. Примером может служить работа C. Susapu с соавт. (2024), где даже при хороших значениях точности AUC оставалась на уровне умеренного прогноза. Это подчеркивает, что хорошие результаты ретроспективных моделей не всегда воспроизводятся в реальной клинической практике [36].

Если обобщить все включенные исследования, складывается довольно практичный вывод: качество прогноза сильнее всего определяют время, когда собираются признаки, и клиническая составляющая этих признаков. Использование признаков, полученных непосредственно перед исходом, повышает метрики качества, но снижает ценность модели как инструмента раннего прогнозирования. В этом случае особую ценность имеют исследования, в которых авторы отдельно показывают положительный результат для более раннего мониторинга риска [21, 27, 33].

## **Заключение / Conclusion**

Данные современных исследований демонстрируют, что алгоритмы ИИ, обученные на мультипараметрических наборах (ЭМК, витальные показатели, лабораторные маркеры, ультразвуковое исследование/доплерография и др.), способны улучшать прогнозирование риска ПЭ и акушерских кровотечений по сравнению с традиционными моделями, особенно при учете динамики показателей во времени. При этом ключевое ограничение большинства работ предсказуемо: недостаток внешней и проспективной валидации, из-за чего при переносе между клиниками качество и калибровка нередко ухудшаются. Следовательно, следующий этап развития направления должен быть смещен к мультицентровым проспективным исследованиям клинического эффекта и стандартизированной оценке риска смещения по современным расширениям для ИИ-моделей.

<b>ИНФОРМАЦИЯ О СТАТЬЕ</b>	<b>ARTICLE INFORMATION</b>
Поступила: 31.01.2026.	Received: 31.01.2026.
В доработанном виде: 27.04.2026.	Revision received: 27.04.2026.
Принята к печати: 13.05.2026.	Accepted: 13.05.2026.
Опубликована: 18.05.2026.	Published: 18.05.2026.
<b>Вклад авторов</b>	<b>Author's contribution</b>

Все авторы принимали равное участие в сборе, анализе и интерпретации данных.	All authors participated equally in the collection, analysis and interpretation of the data.
Все авторы прочитали и утвердили окончательный вариант рукописи.	All authors have read and approved the final version of the manuscript.
<b>Конфликт интересов</b>	<b>Conflict of interests</b>
Авторы заявляют об отсутствии конфликта интересов.	The authors declare no conflict of interests.
<b>Финансирование</b>	<b>Funding</b>
Авторы заявляют об отсутствии финансовой поддержки.	The authors declare no funding.
<b>Комментарий издателя</b>	<b>Publisher's note</b>
Содержащиеся в этой публикации утверждения, мнения и данные были созданы ее авторами, а не издательством ИРБИС (ООО «ИРБИС»). Издательство ИРБИС снимает с себя ответственность за любой ущерб, нанесенный людям или имуществу в результате использования любых идей, методов, инструкций или препаратов, упомянутых в публикации.	The statements, opinions, and data contained in this publication were generated by the authors and not by IRBIS Publishing (IRBIS LLC). IRBIS Publishing disclaims any responsibility for any injury to peoples or property resulting from any ideas, methods, instructions, or products referred in the content.
<b>Права и полномочия</b>	<b>Rights and permissions</b>
ООО «ИРБИС» обладает исключительными правами на эту статью по Договору с автором (авторами) или другим правообладателем (правообладателями). Использование этой статьи регулируется исключительно условиями этого Договора и действующим законодательством.	IRBIS LLC holds exclusive rights to this paper under a publishing agreement with the author(s) or other rightsholder(s). Usage of this paper is solely governed by the terms of such publishing agreement and applicable law.

### Литература / References:

1. World Health Organization, United Nations Children's Fund, United Nations Population Fund, World Bank Group, United Nations Population Division. Trends in maternal mortality 2000 to 2017: estimates by WHO, UNICEF, UNFPA, World Bank Group and the United Nations Population Division. *Geneva: World Health Organization*, 2019. Available at: <https://www.who.int/publications/i/item/9789241516488>. [Accessed: 15.01.2026].
2. Zhang Y., Ding W., Wu T. et al. Pregnancy with multiple high-risk factors: a systematic review and meta-analysis. *J Glob Health*. 2025;15:04027. <https://doi.org/10.7189/jogh.15.04027>.
3. Edwards P., Wright G. Obesity in pregnancy. *Obstet Gynaecol Reprod Med*. 2020;30(10):315–20. <https://doi.org/10.1016/j.ogrm.2020.07.003>.
4. Briganti G., Le Moine O. Artificial intelligence in medicine: today and tomorrow. *Front Med (Lausanne)*. 2020;7:27. <https://doi.org/10.3389/fmed.2020.00027>.
5. Sanchez P., Voisey J.P., Xia T. et al. Causal machine learning for healthcare and precision medicine. *R Soc Open Sci*. 2022;9(8):220638. <https://doi.org/10.1098/rsos.220638>.
6. Frizzell J.D., Liang L., Schulte P.J. et al. Prediction of 30-day all-cause readmissions in patients hospitalized for heart failure: comparison of machine learning and other statistical approaches. *JAMA Cardiol*. 2017;2(2):204–9. <https://doi.org/10.1001/jamacardio.2016.3956>.

7. Sivakumar M., Parthasarathy S., Padmapriya T. Trade-off between training and testing ratio in machine learning for medical image processing. *Peer J Comput Sci.* 2024;10:e2245. <https://doi.org/10.7717/peerj-cs.2245>.
8. Plevris V., Solorzano G., Bakas N.P., Ben Seghier M.E.A. Investigation of performance metrics in regression analysis and machine learning-based prediction models. In: 8th European Congress on Computational Methods in Applied Sciences and Engineering (ECCOMAS 2022), 2022 Jun 5–9; Oslo, Norway. *CIMNE*, 2022. <https://doi.org/10.23967/eccomas.2022.155>.
9. Ansbacher-Feldman Z., Syngelaki A., Meiri H. et al. Machine-learning-based prediction of pre-eclampsia using first-trimester maternal characteristics and biomarkers. *Ultrasound Obstet Gynecol.* 2022;60(6):739–45. <https://doi.org/10.1002/uog.26105>.
10. Gil M.M., Cuenca-Gómez D., Rolle V. et al. Validation of machine-learning model for first-trimester prediction of pre-eclampsia using cohort from PREVAL study. *Ultrasound Obstet Gynecol.* 2024;63(1):68–74. <https://doi.org/10.1002/uog.27478>.
11. Li T., Xu M., Wang Y. et al. Prediction model of preeclampsia using machine learning based methods: a population based cohort study in China. *Front Endocrinol (Lausanne).* 2024;15:1345573. <https://doi.org/10.3389/fendo.2024.1345573>.
12. Liang H., Zhao X., Zhang Y. et al. A comprehensive first-trimester predictive model for preeclampsia based on multi-indicators and machine learning: a retrospective single-center study. *Medicine (Baltimore).* 2025;104(47):e45555. <https://doi.org/10.1097/MD.00000000000045555>.
13. Zhao Z., Dai J., Chen H. et al. A prospective study on risk prediction of preeclampsia using bi-platform calibration and machine learning. *Int J Mol Sci.* 2024;25(19):10684. <https://doi.org/10.3390/ijms251910684>.
14. Kovacheva V.P., Eberhard B.W., Cohen R.Y. et al. Preeclampsia prediction using machine learning and polygenic risk scores from clinical and genetic risk factors in early and late pregnancies. *Hypertension.* 2024;81(2):264–72. <https://doi.org/10.1161/HYPERTENSIONAHA.123.21053>.
15. Li Y.X., Shen X.P., Yang C., et al. Novel electronic health records applied for prediction of pre-eclampsia: machine-learning algorithms. *Pregnancy Hypertens.* 2021;26:102–9. <https://doi.org/10.1016/j.preghy.2021.10.006>.
16. Jhee J.H., Lee S., Park Y. et al. Prediction model development of late-onset preeclampsia using machine learning-based methods. *PLoS One.* 2019;14(8):e0221202. <https://doi.org/10.1371/journal.pone.0221202>.

17. Chen S., Li J., Zhang X. et al. Predicting preeclampsia in early pregnancy using clinical and laboratory data via machine learning model. *BMC Med Inform Decis Mak.* 2025;25(1):178. <https://doi.org/10.1186/s12911-025-02999-5>.
18. Lin Y.C., Mallia D., Clark-Sevilla A.O. et al. A comprehensive and bias-free machine learning approach for risk prediction of preeclampsia with severe features in a nulliparous study cohort. *BMC Pregnancy Childbirth.* 2024;24(1):853. <https://doi.org/10.1186/s12884-024-06988-w>.
19. Tiruneh S.A., Rolnik D.L., Teede H.J., Enticott J. Prediction of pre-eclampsia with machine learning approaches: leveraging important information from routinely collected data. *Int J Med Inform.* 2024;192:105645. <https://doi.org/10.1016/j.ijmedinf.2024.105645>.
20. Tiruneh S.A., Rolnik D.L., Teede H.J., Enticott J. Temporal validation of machine learning models for pre-eclampsia prediction using routinely collected maternal characteristics: a validation study. *Comput Biol Med.* 2025;191:110183. <https://doi.org/10.1016/j.combiomed.2025.110183>.
21. Shyu I.-L., Liu C.-F., Tsai Y.-C. et al. Machine learning predictive system to predict the risk of developing pre-eclampsia. *BMJ Health Care Inform.* 2025;32(1):e101151. <https://doi.org/10.1136/bmjhci-2024-101151>.
22. Eberhard B.W., Gray K.J., Bates D.W., Kovacheva V.P. Deep survival analysis for interpretable time-varying prediction of preeclampsia risk. *J Biomed Inform.* 2024;156:104688. <https://doi.org/10.1016/j.jbi.2024.104688>.
23. Eberhard B.W., Cohen R.Y., Wheeler N. et al. Development and validation of an interpretable longitudinal preeclampsia risk prediction using machine learning. *PLoS One.* 2025;20(6):e0323873. <https://doi.org/10.1371/journal.pone.0323873>.
24. Bennett R., Mulla Z.D., Parikh P. et al. An imbalance-aware deep neural network for early prediction of preeclampsia. *PLoS One.* 2022;17(4):e0266042. <https://doi.org/10.1371/journal.pone.0266042>.
25. Sufriyana H., Wu Y.-W., Su E.C.-Y. Artificial intelligence-assisted prediction of preeclampsia: development and external validation of a nationwide health insurance dataset of the BPJS Kesehatan in Indonesia. *EBioMedicine.* 2020;54:102710. <https://doi.org/10.1016/j.ebiom.2020.102710>.
26. Chen Y., Shi X., Wang Z., Zhang L. Machine learning-based management of hypertensive disorders in pregnancy: analysis of differences in key risk factors between gestational hypertension and pre-eclampsia and construction of a pre-eclampsia prediction model. *Eur J Med Res.* 2025;30(1):1135. <https://doi.org/10.1186/s40001-025-03407-4>.
27. Westcott J.M., Hughes F., Liu W. et al. Prediction of maternal hemorrhage using machine learning: retrospective cohort study. *J Med Internet Res.* 2022;24(7):e34108. <https://doi.org/10.2196/34108>.

28. Krishnamoorthy S., Liu Y., Liu K. A novel oppositional binary crow search algorithm with optimal machine learning based postpartum hemorrhage prediction model. *BMC Pregnancy Childbirth*. 2022;22(1):560. <https://doi.org/10.1186/s12884-022-04775-z>.
29. Akazawa M., Hashimoto K., Noda K., Yoshida K. Machine learning approach for the prediction of postpartum hemorrhage in vaginal birth. *Sci Rep*. 2021;11(1):22620. <https://doi.org/10.1038/s41598-021-02198-y>.
30. Song Z., Lin H., Shao M., et al. Integrating SHAP analysis with machine learning to predict postpartum hemorrhage in vaginal births. *BMC Pregnancy Childbirth*. 2025;25(1):529. <https://doi.org/10.1186/s12884-025-07633-w>.
31. Holcroft S., Karangwa I., Little F. et al. Predictive modelling of postpartum haemorrhage using early risk factors: a comparative analysis of statistical and machine learning models. *Int J Environ Res Public Health*. 2024;21(5):600. <https://doi.org/10.3390/ijerph21050600>.
32. Akazawa M., Hashimoto K. A multimodal deep learning model for predicting severe hemorrhage in placenta previa. *Sci Rep*. 2023;13(1):17320. <https://doi.org/10.1038/s41598-023-44634-1>.
33. Li M., Su X., Liao W., et al. Development and validation of an interpretable machine learning-based prediction model of postpartum hemorrhage in placenta previa following cesarean section: a multicenter study. *Reprod Sci*. 2025;32(9):3062–73. <https://doi.org/10.1007/s43032-025-01937-0>.
34. Wang M., Yi G., Zhang Y. et al. Quantitative prediction of postpartum hemorrhage in cesarean section on machine learning. *BMC Med Inform Decis Mak*. 2024;24(1):166. <https://doi.org/10.1186/s12911-024-02571-7>.
35. Miller S., Lyell D., Maric I. et al. Predicting placenta accreta spectrum disorder through machine learning using metabolomic and lipidomic profiling and clinical characteristics. *Obstet Gynecol*. 2025;145(6):721–31. <https://doi.org/10.1097/AOG.0000000000005922>.
36. Susanu C., Hărăbor A., Vasilache I.-A. et al. Predicting intra- and postpartum hemorrhage through artificial intelligence. *Medicina (Kaunas)*. 2024;60(10):1604. <https://doi.org/10.3390/medicina60101604>.
37. Silasi M., Azzi M., Potchileev S. et al. Placental biomarker testing for evaluation of suspected preeclampsia. *Clin Chem*. 2025;71(5):548–58. <https://doi.org/10.1093/clinchem/hvaf024>.
38. Rolnik D.L., Nicolaides K.H., Poon L.C. Prevention of preeclampsia with aspirin. *Am J Obstet Gynecol*. 2022;226(2):S1108–S1119. <https://doi.org/10.1016/j.ajog.2020.08.045>.

#### **Сведения об авторах / About the authors:**

**Атамасова Виктория Алексеевна / Viktoriya A. Atamasova.** E-mail: [atamasovavikal1@gmail.com](mailto:atamasovavikal1@gmail.com). ORCID: <https://orcid.org/0009-0008-0309-028X>.

**Хабибуллина Сафия Рустемовна / Safiya R. Khabibullina.** ORCID: <https://orcid.org/0009-0002-5761-6669>.

**Фрумкина Юлия Павловна / Yulia P. Frumkina.** ORCID: <https://orcid.org/0009-0002-3551-9825>.

**Соколова Евгения Ивановна / Evgeniia I. Sokolova.** ORCID: <https://orcid.org/0009-0000-0831-7123>.

**Волощук Алина Александровна / Alina A. Voloshuk.** ORCID: <https://orcid.org/0009-0002-8840-997X>.

**Шишенкова Елизавета Глебовна / Elizaveta G. Shishenkova.** ORCID: <https://orcid.org/0009-0009-8102-7128>.

**Борисова Алиса Владимировна / Alisa V. Borisova.** ORCID: <https://orcid.org/0009-0007-6699-6938>.

**Воронина Полина Юрьевна / Polina Yu. Voronina.** ORCID: <https://orcid.org/0009-0008-8695-074X>.