

ПОСЛОЙНАЯ ОБЪЯСНИМАЯ МОДЕЛЬ МАШИННОГО ОБУЧЕНИЯ ДЛЯ РАННЕЙ СТРАТИФИКАЦИИ МАТЕРИНСКОГО РИСКА В УЗБЕКИСТАНЕ

Эсонов Ж.Х.

Эгамбердиев Н.А.

Научный руководитель.

Ташкентский университет информационных технологий
имени Мухаммада Ал-Хоразмий.

Mail: javoxir3001753@gmail.com

<https://doi.org/10.5281/zenodo.21184053>

Аннотация. Материнский риск в Узбекистане распределён неравномерно, а валидированных для страны ML-моделей нет. Предложена послойная объяснимая модель (M1–M5) на основе градиентного бустинга, где каждый слой добавляет источник данных (базовый, клинический, социальный, экологический и динамический). Разработка выполнена на открытых данных DHS, набор материнского риска UCI/Бангладеш и синтетике MaternaUZ ($n = 4\,812$). Дискриминация росла с ROC-AUC 0,66 (M1) до 0,97 (M5), индекс Brier улучшался с 0,21 до 0,06; ведущие факторы по SHAP – анемия, артериальное давление, число беременностей, удалённость от стационара. Модель готова к валидации на реальных данных DMED.

Ключевые слова: материнский риск; машинное обучение; XGBoost; объяснимый ИИ; SHAP; Узбекистан; DHS.

A LAYERED EXPLAINABLE MACHINE-LEARNING MODEL FOR EARLY MATERNAL-RISK STRATIFICATION IN UZBEKISTAN

Abstract. Maternal risk in Uzbekistan is unevenly distributed and no country-validated ML models exist. We propose a layered explainable gradient-boosting model (M1–M5), each layer adding a data source. Developed on open data DHS, the UCI/Bangladesh maternal-risk set and MaternaUZ synthetic data ($n = 4,812$), discrimination rose from ROC-AUC 0.66 (M1) to 0.97 (M5) with Brier improving from 0.21 to 0.06; top SHAP drivers were anaemia, blood pressure, parity and distance-to-hospital.

Keywords: maternal risk; maternal health; risk stratification; explainable machine learning; artificial intelligence; XGBoost; gradient boosting; SHAP; clinical decision support; DHS; MaternaUZ; DMED; Uzbekistan.

I. Введение

Материнская смертность остаётся чувствительным индикатором качества системы здравоохранения, а в Узбекистане её бремя распределено неравномерно: разрыв между столичным регионом и периферией (прежде всего Республикой Каракалпакстан) достигает 3–4 раз.

Значимый вклад вносят не только медицинские, но и контекстные факторы – большие расстояния до стационара, дефицит специалистов, высокая распространённость анемии и экологическое неблагополучие Приаралья.

Машинное обучение применяется для ранней стратификации материнского риска, однако подавляющее большинство моделей разработано на данных стран с высоким доходом и не валидировано для популяции Узбекистана; их прямой перенос ненадёжен.

Дополнительная трудность – малые несбалансированные клинические выборки и низкая цифровая грамотность конечных пользователей, что требует не только точных, но и объяснимых моделей. Цель работы – разработать объяснимую послойную модель ранней стратификации материнского риска, пригодную для условий ограниченных данных.

II. Материалы и методы

Сформирована кумулятивная архитектура из пяти моделей (таблица 1): М1 (8 базовых признаков) – М2 (+клинические) – М3 (+социальные) – М4 (+экологические, Приаралье) – М5 (+динамические). Каждая последующая модель наследует признаки предыдущей и добавляет новый слой данных, что позволяет количественно оценить вклад каждого источника.

Базовый алгоритм – градиентный бустинг деревьев решений (XGBoost). Дисбаланс классов корректировался взвешиванием (scale_pos_weight); для несмещённой оценки применена вложенная 5×5 кросс-валидация, для надёжности вероятностей – изотоническая калибровка, для интерпретации – метод SHAP. Клиническая полезность оценивалась анализом кривых принятия решений.

Данные: DHS (калибровка под популяцию Узбекистана), открытый клинический набор материнского риска (Бангладеш, UCI Machine Learning Repository) и синтетический набор MaternaUZ (n = 4 812; доля «высокого риска» 8,4%). Дискриминация – ROC-AUC с 95% ДИ, различия моделей – тест ДеЛонга. Отчётность построена по TRIPOD+AI.

Таблица 1. Признаки по слоям

Модель	Слой	Признаки (примеры)	Кол-во
М1	базовый	возраст, Нб, АД, удалённость, регион	8
М2	+клинический	ферритин, ИМТ, глюкоза, ЧСС, температура	13
М3	+социальный	образование, доход, дороги	18
М4	+экологический	NDVI, засоление, удалённость от Арала	22
М5	+динамический	тренды Нб и АД во времени	26

III. Результаты

Последовательное добавление слоёв монотонно повышало дискриминацию (рис. 1, таблица 2): ROC-AUC 0,66 – 0,87 – 0,92 – 0,92 – 0,97; индекс Brier улучшался с 0,21 до 0,06.

Наибольший прирост обеспечил клинический слой (М1–М2, $p < 0,001$), наибольшее итоговое качество – динамический слой (М5). Добавление экологического слоя (М4) к социальному (М3) не дало значимого прироста дискриминации ($p = 0,61$), но улучшило пространственную интерпретацию.




Рис. 1. Прирост дискриминации при последовательном добавлении слоёв данных (M1–M5).

Таблица 2. Дискриминация и калибровка

Модель	Признаки	ROC-AUC (95% ДИ)	Brier
M1	8	0,66 (0,62–0,70)	0,21
M2	13	0,87 (0,84–0,90)	0,13
M3	18	0,92 (0,90–0,94)	0,10
M4	22	0,92 (0,90–0,95)	0,10
M5	26	0,97 (0,95–0,98)	0,06

По SHAP ведущий вклад вносили анемия и артериальное давление, далее – число беременностей и удалённость от стационара. Аддитивная природа SHAP позволяет обосновать индивидуальное решение о направлении перед клиницистом. На пороге 0,30 чувствительность составила 0,94 при специфичности 0,78. (Значения предварительные, получены на данных DHS/синтетике.)

Послойная конструкция количественно демонстрирует ценность каждого слоя данных и остаётся прозрачной для клинициста, что критично в условиях низкой цифровой грамотности. Ограничения: результаты получены на данных DHS и синтетике, а композитный прокси-исход не эквивалентен подтверждённым клиническим исходам; высокие значения AUC на малых несбалансированных данных требуют осторожной интерпретации и приоритетной внешней темпоральной валидации.

Заключение

Предложенный послойный объяснимый подход машинного обучения формирует прозрачную и гибкую основу для ранней стратификации материнского риска в Узбекистане. Последовательное расширение признакового пространства от базовых данных к клиническим, социальным, экологическим и динамическим показателям позволяет не только повысить качество прогноза, но и количественно оценить вклад каждого слоя информации.

Рост дискриминационной способности модели от M1 к M5 и улучшение калибровки показывают, что выбранная архитектура способна выявлять клинически значимые закономерности даже в условиях ограниченной и неоднородной доступности данных. При этом использование SHAP делает прогноз интерпретируемым на уровне отдельных факторов риска, что особенно важно для доверия со стороны врачей и практического применения модели в системе поддержки принятия решений.

Наибольший вклад анемии, артериального давления, числа беременностей и удалённости от стационара согласуется с современными клиническими представлениями о факторах, повышающих вероятность неблагоприятных акушерских исходов. Это подтверждает содержательную обоснованность модели и показывает, что алгоритм опирается не на случайные статистические зависимости, а на медицинские интерпретируемые признаки. Вместе с тем полученные результаты следует рассматривать как предварительные, поскольку текущая оценка выполнена на DHS-совместимых данных и синтетическом наборе MaternaUZ, а не на реальных национальных клинических записях.

Поэтому модель пока не должна использоваться как самостоятельный инструмент клинического решения.

Следующим обязательным этапом является внешняя и темпоральная валидация модели на реальных данных DMED с последующей проверкой в формате «человек в контуре», где окончательное решение принимает врач, а алгоритм выполняет функцию объяснимой аналитической поддержки. При успешной валидации предложенный подход может стать основой для создания интерпретируемой системы поддержки принятия врачебных решений, направленной на более раннее выявление беременных с высоким риском осложнений, улучшение маршрутизации пациенток и более адресное использование ресурсов системы охраны материнства в Узбекистане.

Литература

1. World Health Organization. Trends in maternal mortality 2000 to 2020. Geneva: WHO; 2023.
2. Say L, Chou D, Gemmill A, et al. Global causes of maternal death: a WHO systematic analysis. *Lancet Glob Health*. 2014;2(6):e323–e333.
3. Collins GS, Moons KGM, Dhiman P, et al. TRIPOD+AI statement: updated guidance for reporting clinical prediction models that use regression or machine learning methods. *BMJ*. 2024;385:e078378.
4. The DHS Program. Demographic and Health Surveys. Rockville: ICF / USAID. URL: dhsprogram.com
5. Chawla NV, Bowyer KW, Hall LO, Kegelmeyer WP. SMOTE: Synthetic Minority Over-sampling Technique. *J Artif Intell Res*. 2002;16:321–357.
6. Chen T, Guestrin C. XGBoost: A Scalable Tree Boosting System. In: *Proc. 22nd ACM SIGKDD*. 2016. p. 785–794.
7. Lundberg SM, Lee SI. A Unified Approach to Interpreting Model Predictions. In: *Adv. Neural Inf. Process. Syst. (NeurIPS)*. 2017;30:4765–4774.