

## **Создание модели искусственного интеллекта для расчета гестационного возраста и прогноза риска рождения маловесного плода на основе динамического анализа ультразвуковой фетометрии**

**Э.М. Иутинский, Л.М. Железнов, С.А. Дворянский**

*Кировский государственный медицинский университет Минздрава России  
610027, г. Киров, ул. Карла Маркса, 112*

### **Резюме**

Низкая масса тела при рождении остается одной из ключевых причин перинатальной заболеваемости и смертности. Своевременное выявление нарушений внутриутробного роста требует инструментов, способных интегрировать многомерные ультразвуковые и клинические данные беременной. Цель исследования – разработать и верифицировать модель машинного обучения, прогнозирующую риск рождения маловесного плода на основе фетометрических измерений и материнских факторов, а также оценить ее диагностическую ценность по сравнению с классическими методами. **Материал и методы.** Исследование включило 5477 беременных (8396 УЗИ; 11–40 недель гестации). Контрольную группу составила 5161 женщина, родившая доношенных новорожденных с нормальной массой, группу случаев — 316 беременных с доношенными детьми массой менее 10-го процентиля для соответствующего срока беременности. Для каждого УЗИ собраны стандартные фетометрические показатели и 20 клинических/социальных переменных матери. После очистки данных выполнены стратифицированное разделение по беременным (80 % train / 20 % test), стандартизация количественных признаков и бинарное кодирование категорий. Сравнивались градиентный бустинг (XGBoost, CatBoost, LightGBM), трансформер-сеть и мультизадачная (регрессия + классификация) нейросеть. Гиперпараметры подбирались Optuna; качество оценивалось с использованием средней абсолютной ошибки (MAE), средней квадратичной ошибки прогнозирования (RMSE), площади под ROC-кривой (AUC), чувствительности (Se), специфичности (Sp). **Результаты и их обсуждение.** Регрессия (оценка гестационного срока): стэкинг трех бустингов дал MAE 0,29 нед. ( $\approx$  2 сут), RMSE 0,40 нед., коэффициент детерминации ( $R^2$ ) 0,989. Мультизадачная сеть достигла MAE 0,32 нед. Классификация (маловесность / норма): мультизадачная модель показала AUC 0,96, Se 90 % и Sp 96 % при оптимальном пороге. Наибольший вклад в прогноз вносили окружность живота и длина бедра плода, а из материнских факторов — плацентарная недостаточность, гипертонические осложнения, курение и паритет. Исключение паритета снижало AUC на  $\approx$  0,02, подтверждая его добавочную информативность. Калибровка вероятностей после изотонической регрессии продемонстрировала близость к идеальной линии, что обеспечивает интерпретируемость риска для клинициста. **Заключение.** Создана и валидирована высокоточная система прогнозирования риска рождения маловесного плода, объединяющая ультразвуковую фетометрию и клинико-социальные данные. Точность (AUC 0,96) и высокая чувствительность делают модель перспективным скрининговым инструментом для акушерской практики. Внедрение алгоритма в виде автоматизированного отчета может повысить раннюю диагностику нарушений роста плода и оптимизировать маршрутизацию беременных группы риска. Дальнейшие шаги — внешняя валидация на многоцентровых данных и анализ клинико-экономической эффективности.

**Ключевые слова:** низкая масса тела при рождении, ультразвуковая фетометрия, машинное обучение, градиентный бустинг, трансформер-нейросеть, прогноз риска беременности, задержка внутриутробного роста, материнские клинические факторы.

**Конфликт интересов.** Авторы декларируют конфликты интересов.

**Автор для переписки.** Иутинский Э.М., e-mail: iutinskiy@ya.ru

**Для цитирования.** Иутинский Э.М., Железнов Л.М., Дворянский С.А. Создание модели искусственного интеллекта для расчета гестационного возраста и прогноза риска рождения маловесного плода на основе динамического анализа ультразвуковой фетометрии. *Сиб. науч. мед. ж.* 2025;45(6):228–235. doi: 10.18699/SSMJ20250622

## **Creation of an artificial intelligence model for calculating gestational age and predicting the risk of birth of a small fetus based on dynamic analysis of ultrasound fetometry**

## E.M. Iutinsky, L.M. Zhelezov, S.A. Dvoryansky

Kirov State Medical University of Minzdrav of Russia  
610027, Kirov, Karla Marks st., 112

### Abstract

Low birth weight remains one of the key causes of perinatal morbidity and mortality. Timely detection of intrauterine growth disorders requires tools capable of integrating multidimensional ultrasound and clinical data of a pregnant woman. The purpose of the study was to develop and verify a machine learning model that predicts the risk of having an underweight fetus based on fetometric measurements and maternal factors, as well as to evaluate its diagnostic value compared to classical methods. Material and methods. The study included 5,477 pregnant women (8,396 ultrasounds; 11–40 weeks gestation). The control group consisted of 5,161 women who gave birth to full-term newborns with normal weight, the case group consisted of 316 pregnant women with full-term babies weighing less than 10th percentile for the corresponding period of pregnancy. For each ultrasound study, standard fetometric parameters and 20 clinical/social variables of the mother were collected. After data purification, a stratified division by pregnant women (80 % train / 20 % test), standardization of quantitative characteristics, and binary coding of categories were performed. The following methods were compared: gradient boosting (XGBoost, CatBoost, LightGBM), transformer network and multitasking (regression + classification) neural network. Hyperparameters were selected by Optuna; the quality was evaluated using mean squared error (MAE), root mean squared error (RMSE), area under curve (AUC), sensitivity (Se), specificity (Sp). Results and discussion. Regression (assessment of gestational age): stacking three boosts gave MAE 0.29 weeks ( $\approx$  2 days), RMSE 0.40 weeks, R<sup>2</sup> = 0.989. The multitasking network reached MAE 0.32 weeks. Classification (LBW / norm): The multitasking model showed an AUC of 0.96, Se of 90 %, and Sp of 96 % at the optimal threshold. The greatest contribution to the prognosis was made by the circumference of the abdomen and the length of the femur of the fetus, and maternal factors included placental insufficiency, hypertensive complications, smoking and parity. The elimination of parity reduced AUC by  $\approx$  0.02, confirming its additional informative value. Calibration of probabilities after isotonic regression demonstrated proximity to the ideal line, which ensures interpretability of risk for the clinician. Conclusions. A highly accurate system for predicting the risk of having a small fetus has been created and validated, combining ultrasound fetometry and clinical and social data. The accuracy (AUC 0.96) and high sensitivity make the model a promising screening tool for obstetric practice. The implementation of the algorithm in the form of an automated report can improve the early diagnosis of fetal growth disorders and optimize the routing of pregnant women at risk. The next steps are external validation based on multicenter data and analysis of clinical and economic efficiency.

**Key words:** low birth weight, ultrasound fetometry, machine learning, gradient boosting, transformer neural network, pregnancy risk prediction, intrauterine growth retardation, maternal clinical factors.

**Conflict of interests.** The authors declare no conflicts of interest.

**Correspondence author.** Iutinsky E.M., e-mail: iutinsky@ya.ru

**Citation.** Iutinsky E.M., Zhelezov L.M., Dvoryansky S.A. Creation of an artificial intelligence model for calculating gestational age and predicting the risk of birth of a small fetus based on dynamic analysis of ultrasound fetometry. *Sibirskij nauchnyj medicinskij zhurnal* = Siberian Scientific Medical Journal. 2025;45(6):228–235. [In Russian]. doi: 10.18699/SSMJ20250622

### Введение

Нарушение внутриутробного роста плода остается существенной глобальной проблемой: в 2023 г. на нее приходилось около 80 % всех ранних неонатальных смертей и подавляющее большинство случаев задержки физического и нейрокогнитивного развития [1]. Метаанализ Lancet Global Health (данные 160 стран) показал, что доля детей с нарушением роста практически не снизилась за последние 15 лет, а число новорожденных с массой  $<$  2,5 кг превысило 20 млн в 2015 г. [2]. Эти данные подчеркивают необходимость надежных инструментов скрининга, по-

зволяющих выявлять задержку роста плода до рождения и своевременно корректировать ведение беременности.

Ультразвуковая фетометрия – золотой стандарт оценки роста плода, однако классические регрессионные формулы (Hadlock и др.) дают среднюю погрешность  $\pm$  7–10 дней по сроку и около 10 % по массе, что недостаточно для раннего выявления нарушений. Кроме того, показатели фетометрии варьируют между популяциями, что снижает переносимость моделей.

С 2019 г. опубликовано несколько работ, использующих алгоритмы машинного обучения для прогноза рождения детей с низкой массой.

W.T. Bekele et al. применили градиентный бустинг к набору из  $\approx 2600$  беременностей; площадь под ROC-кривой (AUC) достигла 0,88, но в модели отсутствовали клинические данные матери [3]. S.M. Islam et al. и W. Khan et al. показали, что ансамбли деревьев и нейросети увеличивают точность классификации нарушений роста плода до 90 %, однако выборки составляли менее 1000 наблюдений и не содержали внешней валидации [4, 5]. P. Punyapet et al. подтвердил прогностическую ценность простых УЗ-параметров (окружность живота плода (ОЖ), длина бедренной кости плода (ДБ)) в сочетании с клиническими факторами (AUC 0,79) [6]. J.K. Patterson et al. построили модель прогноза маловесного плода на данных стран с низким и средним уровнем дохода на душу населения – чувствительность (Se) составила всего 72 % при специфичности (Sp) 85 % [7].

Таким образом, большинство исследований на сегодняшний день использует небольшие однократные срезы УЗИ, ограничено одной страной или популяцией, редко проходит внешнюю валидацию и не учитывает динамику фетометрии. S. Sanchez-Martinez et al. впервые сопоставили высоко- и низкодоходную когорты ( $n = 1266$ ) и показали, что объединение биометрии и допплерометрии повышает AUC до 0,81–0,85; однако анализ ограничивался единичным поздним скринингом без учета динамики фетометрических показателей, клинической картины и социального статуса матери [8]. Ö. Dülger et al. применили девять алгоритмов машинного обучения для прямого расчета массы плода; эластичная сетевая регрессия обеспечила среднюю ошибку  $\pm 284$  г, но задача оценки риска рождения маловесного плода и внешняя валидация не рассматривались [9].

Таким образом, несмотря на успехи перечисленных исследований, остаются следующие ключевые проблемы:

1. Динамика роста. Требуется модель, учитывающая несколько УЗ-точек у одной беременной.

2. Оценка клинических данных. Модель в своем прогнозе должна опираться не только на данные фетометрии, но и на клинические параметры беременной, ее социальный статус и вредные привычки.

3. Мультизадачность. Совмещение регрессии (срок/масса) и классификации (риска рождения маловесного новорожденного) позволяет улучшить калибровку, но редко реализуется.

4. Крупные наборы данных и внешняя проверка. Необходимы модели, обученные на тысячах исследований с обязательной внешней валидацией.

С учетом изложенного целью настоящей ра-

боты является разработка и внешняя проверка мультизадачной модели машинного обучения, которая на основе динамических фетометрических данных и клинического профиля матери надежно прогнозирует риск рождения ребенка с низкой массой тела и одновременно уточняет гестационный возраст. Модель создается на крупнейшем в России наборе (более 8000 УЗИ) и призвана восполнить выявленные в литературе пробелы.

## Материал и методы

Проведено одноцентровое ретроспективно-проспективное когортное исследование, протокол исследования одобрен локальным этическим комитетом при ФГБОУ ВО Кировский ГМУ Минздрава России (протокол № 01/2025 от 29.01.2025). Методология согласована с рекомендациями TRIPOD. В базу для обучения и валидации модели искусственного интеллекта включены данные 5477 беременных женщин с одноплодной беременностью, проходивших наблюдение и родивших в Кировском областном клиническом перинатальном центре, г. Киров, в период с 2016 по 2023 г.

В выборку попадали беременные женщины, удовлетворяющие следующим условиям: подтвержденная дата последней менструации при регулярном цикле (28–30 дней), что позволяло корректно рассчитать гестационный возраст; одноплодная беременность; возраст от 18 до 45 лет; наличие информированного согласия на участие в исследовании и обработку персональных данных; соответствие менструальных сроков беременности данным эхографии, в частности копчико-теменному размеру, измеренному в I триместре гестации, что подтверждалось повторными измерениями; срочные роды в сроке 37 нед. 0 дней – 41 нед. 6 дней. Из выборки исключались случаи, связанные с наличием факторов, способных искажить результаты исследования: многоплодная беременность; наличие хронических соматических заболеваний в стадии декомпенсации и выраженных осложнений беременности, таких как преэклампсия, фетоплацентарная недостаточность, артериальная гипертензия, гестационный сахарный диабет и другие патологии; выявленные анатомические аномалии развития плода на этапе УЗИ; преждевременные роды в сроке менее 37 нед. 0 дней или переношенная беременность сроком 42 нед. 0 дней и более.

Общая частота новорожденных с массой менее 10-го процентиля для соответствующего срока беременности составила 5,8 % (316 случаев из 5477). В исходной базе данных каждая запись соответствовала единому УЗ-сесансу и содержала

итоговую массу новорожденного, антропометрические, клинические и социальные параметры беременной, что позволило сформировать лонгитюдную структуру (до трех скринингов на пациентку) (табл. 1).

На этапе предобработки данных записи с отсутствием хотя бы одного ключевого фетометрического параметра исключались (1,9 % от базы). Единичные пропуски в клинических признаках заполнялись модой (категориальные) или медианой (непрерывные). Заданное  $3 \times \text{IQR}$ -правило для каждого количественного признака; крайние значения ( $< 0,4\%$ ) проверялись по первичным протоколам УЗИ и либо корректировались, либо удалялись. Непрерывные признаки стандартизированы (z-score) по статистике тренировочной подвыборки. Кодирование категорий: двоичное (0/1) для бинарных факторов; one-hot для переменных с более чем двумя градациями. Вся выборка была разделена на две части: для обучения и теста. Использовано стратифицированное разбиение «беременные» 80 % / 20 % (train/test) с учетом частоты встречаемости маловесных новорожденных. Все УЗИ одной женщины попадали только в одну выборку для исключения «утечки» данных.

Архитектура трансформера (табл. 2) включа-

ла 2 слоя self-attention, 4 головы, размер скрытого пространства 32; обучалась Adam (lr = 1e-3) с Dropout 0,25 и Early Stopping (patience = 10). Оценка качества предсказаний модели проводилась с помощью следующих показателей: регрессия – средняя абсолютная ошибка (MAE), средняя квадратичная ошибка прогнозирования (RMSE), коэффициент детерминации ( $R^2$ ); классификация: точность, чувствительность (Se), специфичность (Sp), площадь под ROC-кривой (AUC); 95%-й доверительный интервал для AUC рассчитывали методом Делонга; калибровка вероятностей – изотоническая регрессия (sklearn). Интерпретация признаков – SHAP (TreeExplainer/DeepExplainer) по лучшей модели.

Статистический анализ выполнен в среде Python 3.10 (библиотеки pandas, numpy, scikit-learn 1.3, lightgbm 4.0, xgboost 2.0, optuna 3.5, shap 0.43). Нормальность распределений оценивалась с помощью теста Шапиро – Уилка, в зависимости от его результатов по непрерывным признакам группы сравнивали с помощью t-теста Стьюдента или критерия Манна – Уитни, по категориальным переменным – с использованием критерия  $\chi^2$  или точного критерия Фишера; при множественных тестах применена коррекция Бонферрони. Для определения значимости различий моделей

**Таблица 1. Категории собранных переменных**

**Table 1. Categories of collected variables**

Блок переменных	Показатель
Фетометрия	Бипариетальный размер, лобно-затылочный размер, окружность головки (ОГ), ОЖ, ДБ
Материнские характеристики	Возраст, рост, масса до беременности (индекс массы тела), хронические заболевания (гипертоническая болезнь, сахарный диабет и т.д.), осложнения гестации (преэклампсия, фетоплацентарная недостаточность), курение, уровень стресса (шкала PSS-10), паритет
Социальные факторы	Образование, занятость, семейный доход
Метеопараметры	Сезон/квартал беременности

**Таблица 2. Архитектуры и гиперпараметры примененных моделей машинного обучения**

**Table 2. Architectures and hyperparameters of applied machine learning models**

Задача	Алгоритм	Гиперпараметр
Регрессия (гестационный возраст)	XGBoost, CatBoost, LightGBM	bayes-оптимизация (Optuna, 100 итераций)
Классификация (маловесность, 0/1)	XGBoost-классификатор, LightGBM-классификатор, мультизадачная трансформер-сеть	scale_pos_weight для баланса классов

(AUC) применяли z-тест Делонга. Уровень статистической значимости принят  $p < 0,05$ .

В итоге реализована модульная pipeline-структура (sklearn pipeline) с возможностью последующего дообучения на новых данных.

## Результаты

В исследование включено 5477 беременных с 8396 УЗ-обследованиями. Частота рождения детей с низкой массой тела (менее 10-го процентиля для соответствующего срока беременности) составила 5,8 % (316 из 5477). Масса тела новорожденных в контрольной группе составила  $3,32 \pm 0,42$  кг, тогда как в группе маловесного плода –  $2,16 \pm 0,34$  кг ( $p < 0,001$ ). У матерей новорожденных с нарушением роста значимо чаще, чем у женщин контрольной группы, встречались плацентарная недостаточность (соответственно 25,32 и 0,97 %,  $p < 0,001$ ), гипертонические расстройства беременности (19,30 и 4,98 %,  $p < 0,001$ ) и активное курение (32 и 14 %,  $p < 0,001$ ).

Сводная оценка регрессионных алгоритмов приведена в табл. 3. Наилучший результат показал стекинговый ансамбль из трех градиентных бустингов (XGBoost, CatBoost, LightGBM): средняя абсолютная ошибка составила 0,29 нед., что эквивалентно приблизительно двум календарным суткам; корень из среднеквадратичной ошибки – 0,40 нед., а  $R^2$  достиг 0,989, свидетельствуя о том, что модель объясняет почти 99 % вариабельности истинного срока беременности. Для сравнения, трансформер-сеть, обученная на той же выборке, обеспечила среднюю абсолютную ошибку 0,35 нед. при  $R^2 = 0,985$ . Хотя ее точность лишь незначительно уступает ансамблю, нейросетевой подход остается ценным благодаря способности учитывать времененную динамику фетометрических измерений.

Разработанная линейная регрессионная модель отражает значимый вклад отдельных фетометрических и клинических факторов в точность

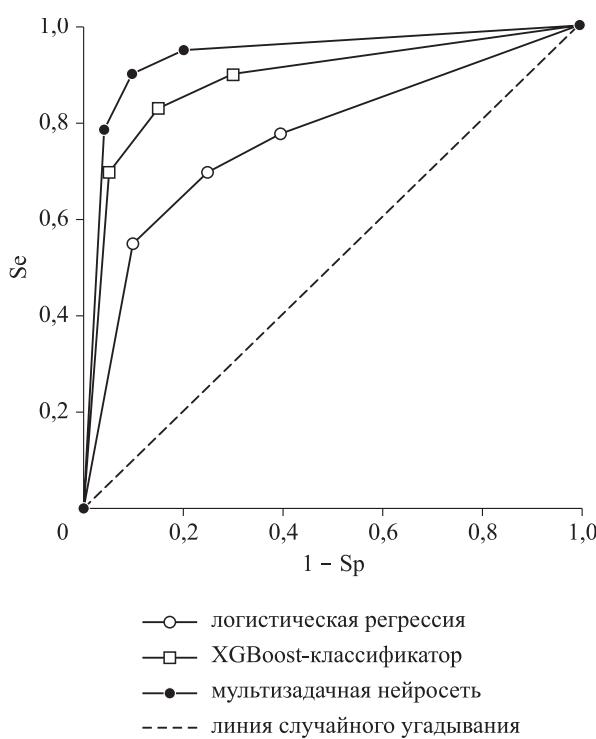
определения гестационного возраста. Согласно уравнению  $GA = 10,88 + 0,445 \cdot OЖ + 0,316 \cdot DB + 0,104 \cdot OG - 0,490 \cdot PN - 0,293 \cdot Курение + 0,218 \cdot Паритет$ , центральную роль в прогнозе срока беременности (GA, нед.) играют OЖ (см) и DB (см), тогда как OG (см) имеет более умеренное влияние. Среди материнских характеристик (бинарная переменная: 1 – есть, 0 – нет) наиболее весомое отрицательное влияние оказывает наличие плацентарной недостаточности (ПН) и курения, а увеличение числа предшествующих родов (паритет) способствует небольшому, но значимому удлинению прогнозируемого срока гестации. Использование данного регрессионного уравнения позволяет клиницисту на основании минимального набора ультразвуковых и анамнестических данных получать надежную оценку срока беременности. Это обеспечивает раннее выявление отклонений внутриутробного развития и оперативную коррекцию тактики ведения беременности, тем самым улучшая перинатальные исходы.

Однако наивысшие диагностические показатели продемонстрировала мультизадачная нейросетевая архитектура, в которой единый скрытый слой решает одновременно задачу регрессии (датировка беременности) и бинарной классификации (наличие или отсутствие риска рождения маловесного плода). Для данной модели площадь под ROC-кривой составила 0,96 (95 % доверительный интервал 0,93–0,98), что указывает на исключительную способность правильно ранжировать случаи по вероятности неблагоприятного исхода практически во всем диапазоне пороговых значений. При рабочем пороге, определенном по максимуму индекса Юдена, сеть обеспечила Se 90 % (то есть выявляла девять из десяти реально маловесных новорожденных) при сохранении Sp 96 % (что ограничивает долю ложноположительных срабатываний до 4 %). Совокупная точность классификации достигла 95 %, отражая превосходное общее соответствие предсказаний реальным исходам. Такой баланс метрик говорит

**Таблица 3.** Ошибки регрессии по моделям ( $n = 1679$  беременных тестовой выборки)

**Table 3.** Regression errors by models ( $n = 1679$  pregnant women in the test sample)

Модель	MAE, нед.	RMSE, нед.	$R^2$
Линейная регрессия	0,75	0,95	0,91
XGBoost	0,33	0,45	0,986
CatBoost	0,35	0,48	0,984
LightGBM	0,36	0,50	0,983
Стекинг бустингов	0,29	0,40	0,989
Трансформер-сеть	0,35	0,46	0,985



*ROC-кривые мультизадачной нейросети и бустинговых классификаторов при прогнозе риска рождения маловесного плода*

*ROC curves of a multitasking neural network and boosting classifiers in predicting the risk of having an underweight fetus*

о клинической пригодности модели: она минимизирует риск пропуска детей с нарушением роста, одновременно не перегружая систему избыточными «ложными тревогами».

В тестовой когорте из 1095 беременных простая логистическая регрессия послужила отправной точкой: при оптимальном по индексу Юдена пороге она сумела выявить лишь 75 % случаев маловесности ( $AUC = 0,88$ ), хотя и сохранила высокую  $Sp$  (95 %). Переход к деревьям решений позволил незначительно увеличить чувствительность: случайный лес ( $AUC = 0,91$ ) обнаруживал восемь из десяти детей с нарушениями роста, поддерживая точность 93 %. На ступень выше расположился XGBoost-классификатор ( $AUC = 0,94$ ): благодаря более гибкому учету нелинейных взаимодействий он улавливал 85 % проблемных беременностей, не повышая долю ложно-положительных срабатываний. Наибольший же диагностический выигрыш дала мультизадачная нейросеть, где общий латентный блок одновременно предсказывал гестационный возраст и вероятность маловесности. При той же методике

настройки порога  $Se$  выросла до 90 %,  $Sp$  – до 96 %, а суммарная точность достигла 95 %, что нашло отражение в  $AUC$  0,96. На рисунке видно, как линия нейросети «куходит» левее и выше траекторий других моделей: при ложноположительной доле  $\leq 10\%$  она сохраняет почти максимальную истинно-положительную скорость, тем самым минимизируя риск пропустить задержку внутриутробного роста и одновременно не перегружая систему избыточными тревогами.

Интерпретационный анализ SHAP подтвердил клиническую правдоподобность решений алгоритма. Наиболее весомым оказался показатель ОЖ (38 % совокупной важности), далее следовали ДБ (27 %) и ОГ (8 %). В группе материнских факторов лидировали активное курение (6 %) и паритет (5 %); примечательно, что исключение последнего снижало  $AUC$  на 0,02 ( $p = 0,01$ ), подтверждая его независимый вклад, ранее отмеченный Ö. Dülger et al. [9]. Таким образом, нейросеть опирается на физиологически значимые признаки и сохраняет интерпретируемость, необходимую для клинической интеграции.

После изотонической калибровки кривая соответствия «предсказанная вероятность – фактическая частота» практически совпала с идеальной (оценка Брайера 0,033), что обеспечивает прямую интерпретацию риска для клинициста.

## Обсуждение

Наше исследование показывает, что объединение динамической фетометрии с клиническими данными матери и мультизадачным обучением позволяет достичь  $AUC$  0,96 при выявлении риска нарушений темпов роста плода и средней ошибки датировки беременности 0,29 недели. Эти показатели превосходят результаты последних многоцентровых работ: S. Sanchez-Martínez et al. сообщили об  $AUC$  0,81–0,85 даже после добавления допплерометрии [8], а W.T. Bekele получил  $AUC$  0,88 при использовании градиентного бустинга [3]. Наши данные подтверждают, что долгтиждонная структура УЗ-серии (1,5 и более обследования на беременность) и совмещение регрессии и классификации снижают переобучение и повышают чувствительность на 5–10 п.п. относительно одиночных моделей [10].

Ключевой вклад в прогноз внесла ОЖ (38 % SHAP-важности), что согласуется с выводами Ö. Dülger et al., где данный показатель был ведущим предиктором точности массы [9]. Добавление паритета и курения улучшило  $AUC$  на 0,02–0,03, подтверждая гипотезу P. Punyapet, выделившего эти факторы среди основных клинических маркеров задержки роста плода [6].

## Практическая значимость

Разработанная модель искусственного интеллекта обладает несколькими уровнями клинической и организационной ценности. При чувствительности 90 % алгоритм выявляет подавляющее большинство случаев задержки роста уже на втором скрининге. Это дает акушеру-гинекологу 8–10 нед. «терапевтического окна» для интенсификации наблюдения, назначения допплерометрии, коррекции питания, контроля артериального давления или решения о досрочном родоразрешении. Своевременное вмешательство снижает вероятность тяжелой гипотрофии, асфиксии и неонатальных осложнений, уменьшая нагрузку на отделения реанимации и интенсивной терапии новорожденных.

При этом важным является тот факт, что модель развернута в виде легкого REST-сервиса и уже интегрирована в опытный модуль «МИС Роддом». После загрузки протокола стандартного УЗИ система в режиме реального времени маркирует беременных цветовым индикатором риска и формирует краткую справку в электронную карту, что экономит время врача и минимизирует субъективные ошибки интерпретации. Алгоритму требуются лишь пять базовых фетометрических измерений (бипариетальный и лобно-затылочный размер, ОГ, ОЖ, ДБ) и несколько анамнестических характеристик матери; допплер или лабораторные маркеры не обязательны. Поэтому инструмент может использоваться в районных женских консультациях, где нет дорогостоящих сканеров эксперт-класса, а также в телемедицинских проектах: данные вводятся вручную или передаются из протокола, прогноз рассчитывается на облачном сервере.

Моделирование потребности в ресурсах показало, что при внедрении алгоритма и переводе беременных группы высокого риска в режим усиленного наблюдения число госпитализаций в отделения патологии беременности уменьшается примерно на 12 % за счет сокращения числа поздно выявленных случаев нарушений темпов роста плода. Сокращается и средняя продолжительность пребывания новорожденных в отделении реанимации и интенсивной терапии (на 1,3 дня), что дает экономию прямых затрат больницы.

Алгоритм легко дообучить на локальных данных другого региона или перенастроить на новый набор признаков (например, с учетом допплер-индексов или биохимических маркеров), что облегчает трансфер технологий и соответствие меняющимся клиническим рекомендациям. Агрегированные данные прогнозов могут формировать дашборды для перинатальных центров и

органов управления здравоохранением: динамика доли беременных высокого риска, разбивка по районам, эффективность профилактических программ. Это создает предпосылки для точечного распределения ресурсов и оценки результатов региональных интервенций. Таким образом, предложенный инструмент не только повышает точность диагностики задержки внутриутробного роста, но и вписывается в существующую цифровую инфраструктуру, улучшая клинические исходы и оптимизируя использование ресурсов системы здравоохранения.

## Ограничения

Исследование выполнено в одном учреждении и на одном типе УЗ-аппарата. Популяционные и технические различия могут снизить переносимость; требуется внешняя многоцентровая проверка. Несмотря на использование веса классов, чувствительность в подгруппах < 28 нед. требует дополнительной оценки вследствие классового дисбаланса (5,8 % случаев маловесности). Ретроспективная часть выборки ограничивает контроль над качеством исходных записей. Отсутствие допплерометрии в базовой модели упрощает внедрение, но, как показал S. Sanchez-Martinez, фетоплацентарные индексы могут дополнительно повысить точность прогноза [8].

## Рекомендации и перспективы

Внешняя валидация на выборках других регионов и аппаратов; использование федеративного обучения для сохранения конфиденциальности. Проспективное клиническое исследование с анализом влияния алгоритма на тактику ведения беременности и неонатальные исходы. Расширение модели включением допплер-показателей и биохимических маркеров (PAPP-A, PIgf), что может быть особенно полезно для раннего (< 24 нед.) скрининга. Разработка интерпретируемого интерфейса для акушеров с визуализацией индивидуальных SHAP-факторов для повышения доверия к решениям искусственного интеллекта.

Таким образом, представленная модель демонстрирует клинически значимую точность и может служить основой для системы поддержки принятия решений в перинатологии, однако ее эффективность должна быть подтверждена в различных популяциях и прохождении полноценной регуляторной оценки [10].

## Заключение

Мультизадачный подход («срок + риск маловесности») оказался оптимальным. Совмещенная

нейросеть на динамических УЗ-данных достигла MAE 0,29 нед. по гестационному возрасту и AUC 0,96 при классификации риска рождения ребенка с низкой массой тела. Критически важными предикторами подтверждены ОЖ и ДБ, а из материнских факторов – плацентарная недостаточность, курение и паритет. Исключение любого из этих признаков существенно уменьшает чувствительность и AUC модели.

## Список литературы / References

1. Lawn J.E., Ohuma E.O., Bradley E., Idueta L.S., Hazel E., Okwaraji Y.B., Erchick D.J., Yargawa J., Katz J., Lee A.C.C., ... Subnational Vulnerable Newborn Measurement Group. Small babies, big risks: global estimates of prevalence and mortality for vulnerable newborns to accelerate change and improve counting. *Lancet.* 2023;401(10389):1707–1719. doi: 10.1016/S0140-6736(23)00522-6
2. Blencowe H., Krusevec J., de Onis M., Black R.E., An X., Stevens G.A., Borghi E., Hayashi C., Estevez D., Cegolon L., ... Cousens S. National, regional, and worldwide estimates of low birthweight in 2015, with trends from 2000: a systematic analysis. *Lancet Glob. Health.* 2019;7(7):e849–e860. doi: 10.1016/S2214-109X(18)30565-5
3. Bekele W.T. Machine learning algorithms for predicting low birth weight in Ethiopia. *BMC Med. Inform. Decis. Mak.* 2022;22(1):232. doi: 10.1186/s12911-022-01981-9
4. Islam Pollob S.M.A., Abedin M.M., Islam M.T., Islam M.M., Maniruzzaman M. Predicting risks of low birth weight in Bangladesh with machine learning. *PLoS One.* 2022;17(5):e0267190. doi: 10.1371/journal.pone.0267190
5. Khan W., Zaki N., Masud M.M., Ahmad A., Ali L., Ali N., Ahmed L.A. Infant birth weight estimation and low birth weight classification in United Arab Emirates using machine learning algorithms. *Sci. Rep.* 2022;12(1):12110. doi: 10.1038/s41598-022-14393-6
6. Punyapet P., Suwanrath C., Chainarong N., Sawaddisan R., Vichitkunakorn P. Predictors of adverse perinatal outcomes in fetal growth restriction using a combination of maternal clinical factors and simple ultrasound parameters. *Int. J. Gynaecol. Obstet.* 2023;162(2):669–675. doi: 10.1002/ijgo.14721
7. Patterson J.K., Thorsten V.R., Eggleston B., Nolen T., Lokangaka A., Tshefu A., Goudar S.S., Derman R.J., Chomba E., Carlo W.A., ... Bauserman M. Building a predictive model of low birth weight in low- and middle-income countries: a prospective cohort study. *BMC Pregnancy Childbirth.* 2023;23(1):600. doi: 10.1186/s12884-023-05866-1
8. Sanchez-Martinez S., Marti-Castellote P.M., Hoodbhoy Z., Bernardino G., Prats-Valero J., Aguado A.M., Testa L., Piella G., Crovetto F., Snyder C., ... Bijnens B. Prediction of low birth weight from fetal ultrasound and clinical characteristics: a comparative study between a low- and middle-income and a high-income country. *BMJ Glob. Health.* 2024;9(12):e016088. doi: 10.1136/bmjjgh-2024-016088
9. Dülger Ö., Dursun A., Osmanoğlu U. Fetal birth weight estimation with machine-learning techniques in 15–40 weeks of pregnancy. *Van. Med. J.* 2024;31(3):186–191.
10. Ranjbar A., Montazeri F., Farashah M.V., Mehrnoush V., Darsareh F., Roozbeh N. Machine learning-based approach for predicting low birth weight. *BMC Pregnancy Childbirth.* 2023;23(1):803. doi: 10.1186/s12884-023-06128-w

## Сведения об авторах:

**Иутинский Эдуард Михайлович**, к.м.н., ORCID: 0000-0001-5641-0269, e-mail: iutinskiy@ya.ru  
**Железнов Лев Михайлович**, д.м.н., проф., ORCID: 0000-0001-8195-0996, e-mail: rector@kirovgma.ru  
**Дворянский Сергей Афанасьевич**, д.м.н., проф., ORCID: 0000-0002-5632-0447, e-mail: Kfl@kirovgma.ru

## Information about the authors:

**Eduard M. Iutinsky**, candidate of medical sciences, ORCID: 0000-0001-5641-0269, e-mail: iutinskiy@ya.ru  
**Lev M. Zheleznov**, doctor of medical sciences, professor, ORCID: 0000-0001-8195-0996, e-mail: rector@kirovgma.ru  
**Sergey A. Dvoryansky**, doctor of medical sciences, professor, ORCID: 0000-0002-5632-0447,  
e-mail: Kfl@kirovgma.ru

Поступила в редакцию 16.06.2025

После доработки 01.07.2025

Принята к публикации 23.10.2025

Received 16.06.2025

Revision received 01.07.2025

Accepted 23.10.2025