

<https://doi.org/10.32603/2071-8985-2024-17-10-49-58>

Определение предикторов снижения овариального резерва после бариатрических операций с помощью методов машинного обучения

А. К. Хамитов^{1✉}, А. А. Мелдо¹, З. В. Швеце², С. В. Дора²

¹ Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В. И. Ульянова (Ленина), Санкт-Петербург, Россия

² Первый Санкт-Петербургский государственный медицинский университет им. акад. И. П. Павлова

✉ abulkairhamitov@gmail.com

Аннотация. Проводится анализ влияния бариатрической хирургии на овариальный резерв у женщин, страдающих ожирением, с использованием методов машинного обучения. Исследование охватывает данные 149 пациенток, которые подверглись оперативному вмешательству, с целью выявления взаимосвязи между снижением массы тела и изменениями в репродуктивной функции. Применялись алгоритмы случайного леса и экстремального градиентного бустинга для определения ключевых факторов, влияющих на уровень антимюллерова гормона (АМГ) и нарушение менструального цикла (НМЦ) через 12 мес. после бариатрической операции. Выявленная предсказательная способность моделей (AUC 0.79–0.80) подчеркивает важность применения машинного обучения в анализе взаимосвязей между метаболическими изменениями и репродуктивным здоровьем. Данная статья открывает новые перспективы для дальнейших исследований в области репродуктивной медицины и эндокринологии, а также акцентирует необходимость более глубокого понимания влияния бариатрических операций на женское здоровье.

Ключевые слова: бариатрическая операция, машинное обучение, ожирение, прогноз фертильности, репродуктивная функция, антимюллеров гормон

Для цитирования: Определение предикторов снижения овариального резерва после бариатрических операций с помощью методов машинного обучения / А. К. Хамитов, А. А. Мелдо, З. В. Швеце, С. В. Дора // Изв. СПбГЭТУ «ЛЭТИ». 2024. Т. 17, № 10. С. 49–58. doi: 10.32603/2071-8985-2024-17-10-49-58.

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

Original article

Determining Predictors of Decreased Ovarian Reserve After Bariatric Surgery Using Machine Learning Methods

А. К. Khamitov^{1✉}, А. А. Meldo¹, Z. V. Shvets², S. V. Dora²

¹ Saint Petersburg Electrotechnical University, Saint Petersburg, Russia

² Pavlov First Saint Petersburg State Medical University

✉ abulkairhamitov@gmail.com

Abstract. Devoted to analysing the effect of bariatric surgery on the ovarian reserve in obese women using machine learning methods. The study covers data from 149 female patients who underwent surgical intervention in order to identify the relationship between weight loss and changes in reproductive function. The work applied random forest and extreme gradient boosting algorithms to identify key factors affecting anti-müllerian hormone (AMH) levels and menstrual cycle disruption (MCI) 12 months after bariatric surgery. The revealed predictive ability of the models (AUC 0.79–0.80) highlights the importance of applying machine learning in analysing the relationships between metabolic changes and reproductive health. This work opens new perspectives for further research in reproductive medicine and endocrinology, and emphasises the need for a better understanding of the impact of bariatric surgery on women's health.

Keywords: bariatric surgery, machine learning, obesity, fertility prognosis, antimüllerian hormone

For citation: Determining Predictors of Decreased Ovarian Reserve After Bariatric Surgery Using Machine Learning Methods / A. K. Khamitov, A. A. Meldo, Z. V. Shvets, S. V. Dora // LETI Transactions on Electrical Engineering & Computer Science. 2024. Vol. 17, no. 10. P. 49–58. doi: 10.32603/2071-8985-2024-17-10-49-58.

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

Введение. По данным литературы, в 2020 г. в мире зарегистрировано 2.6 млрд случаев ожирения [1]. Ожидается, что к 2035 г. число лиц с ожирением превысит 4 млрд [1], что свидетельствует о стремительном росте этой проблемы на глобальном уровне. В настоящее время доказано, что ожирение приводит к нарушению репродуктивной функции и у мужчин, и у женщин [2], [3]. У женщин, страдающих ожирением, чаще встречаются нарушения менструального цикла (НМЦ), бесплодие, патологии беременности и родов [4], [5].

Предполагается, что при уменьшении массы тела должно происходить восстановление репродуктивного здоровья женщины [6], [7]. Наибольшую эффективность в лечении ожирения показывают методы бариатрической хирургии [8]. Однако влияние бариатрических операций на фертильность женщин недостаточно изучено. В ряде случаев после проведения подобных операций репродуктивная функция женщин стойко снижается, возникают сложности коррекции гормонального статуса.

Основными показателями фертильности женщин служат менструальная функция и овариальный резерв (показатель индивидуального запаса яйцеклеток в яичнике). Судить об овариальном резерве можно по динамике показателей крови (антимюллерова гормона (АМГ), фолликулостимулирующего гормона (ФСГ), а также по данным ультразвукового исследования (по количеству фолликулов в яичниках) [9], [10]. Целью исследования стало определение значимых факторов, влияющих на развитие негативных событий в гормональном статусе женщин после бариатрических операций.

За последние несколько десятилетий инструменты машинного обучения (Machine Learning, ML) становятся все более популярными среди медицинских исследователей. Различные алгоритмы ML, включая искусственные нейронные сети [11], деревья решений [12], байесовские сети [13] и машины опорных векторов (SVM) [14], широко применяются с целью выявления ключевых характеристик состояния пациента и моделирования развития заболевания после лечения на основе сложной медицинской информации и медицинских наборов данных. Применение различ-

ных методов ML для выделения значимых признаков и классификации в многомерных данных может обеспечить перспективные инструменты для выводов в медицинской практике [15], [16]. Эти подходы используются в медицинских исследованиях для разработки прогностических моделей, что приводит к принятию эффективных и точных решений [17], [18]. Статья посвящена прогнозной аналитике влияния бариатрической хирургии на овариальный резерв с помощью методов машинного обучения.

Материалы и методы. Исходный набор данных содержал информацию о 149 женщинах от 18 до 40 лет, планирующих беременность, которым проводилась бариатрическая операция в качестве метода лечения ожирения. От всех пациенток получено информированное добровольное согласие на участие в исследовании.

Включенным в исследование пациенткам дважды (при первичном обращении и через 12 месяцев после БО) проводилось обследование (клиническое, лабораторное, инструментальное), включающее в себя, в том числе, оценку показателей, определяющих уровень овариального резерва (уровень АМГ, ФСГ в плазме крови, количества антральных фолликулов (КАФ) по данным УЗИ).

Исходная выборка была разделена на два набора данных: первый – для анализа уровня АМГ, который служит маркером овариального резерва, а второй – для предсказания НМЦ.

Мы стремились предсказать снижение уровня АМГ, а также вероятность возникновения НМЦ через 12 мес. после проведения бариатрической операции. Важность выбора 12-месячного интервала объясняется его клинической значимостью, поскольку этот период часто используется для оценки восстановления репродуктивного здоровья и планирования беременности после оперативного вмешательства.

Для анализа был собран и обработан исходный набор данных, который включал 394 предоперационных признака. На этапе подготовки данных были удалены дубликаты и строки с отсутствующими значениями. Однако мы столкнулись с проблемой большого количества пропусков. Так в столбце АМГ – всего 49 из 149 наблю-

дений содержали непустые значения, что значительно усложнило дальнейшую обработку. В связи с этим были использованы строгие критерии отбора признаков: оставлены только те переменные, которые имели более 70 % непустых значений. Пропуски в данных были заменены на средние значения по соответствующей переменной, что позволило минимизировать влияние отсутствующих данных на качество прогноза.

Дополнительно была проведена нормализация данных для обеспечения корректной работы алгоритмов машинного обучения, что служит необходимым шагом для улучшения их предсказательной способности.

Не всегда можно определить, какой алгоритм подходит лучше всего, поэтому учитывалось как можно больше моделей, ориентируясь на так называемые памятки по выбору моделей ML [19], [20]. В качестве алгоритмов машинного обучения используются логистическая регрессия, дерево решений, метод *k*-ближайших соседей, метод опорных векторов, наивный байесовский классификатор, случайный лес, экстремальный градиентный бустинг (XGBoost), многослойный перцептрон.

Для первого набора данных значимость признаков определена на основе экстремального градиентного бустинга (рис. 1, *a*) и случайного леса (рис. 1, *b*), для второго – только на основе случайного леса (рис. 2). Модели выбирались в соответствии с определением их предсказательной силы.

Случайный лес (Random Forest) – это один из популярных ансамблевых методов машинного обучения, основанный на использовании нескольких решающих деревьев. Он принадлежит к классу методов бэггинга (*bagging*) – случайной выборки с возвращением, где основную идею представляет создание множества моделей (в данном случае – решающих деревьев) и их объединение для улучшения точности предсказаний. Случайный лес строится из множества независимых решающих деревьев. В процессе обучения каждое дерево строится на основе случайно выбранного подмножества обучающих данных, а также случайного подмножества признаков на каждом этапе разбиения узлов. Эта случайность позволяет модели быть более устойчивой к переобучению и делать более точные предсказания. Для каждого дерева обучающая выборка создается с помощью метода бэггинга – это означает, что одни и те же объекты могут попадать в выборку несколько раз, а другие – ни разу. Благодаря этому

каждое дерево обучается на разных данных, что снижает вероятность переобучения модели на конкретных примерах. В задаче классификации случайный лес предсказывает класс объекта путем голосования всех деревьев. Каждый элемент прогноза дается отдельным деревом, а окончательный результат – это класс, который получил наибольшее количество голосов. При построении каждого узла дерева случайный лес выбирает случайное подмножество признаков, по которым делается разбиение. Это снижает корреляцию между деревьями, делая ансамбль более стабильным и снижая его склонность к переобучению.

XGBoost (Extreme Gradient Boosting) – это алгоритм машинного обучения, который реализует улучшенную версию градиентного бустинга деревьев решений. Основная идея метода заключается в последовательном построении деревьев решений, где каждое новое дерево пытается скорректировать ошибки предыдущих. В отличие от случайного леса, который строит деревья параллельно, XGBoost строит их последовательно, используя информацию о предсказанных ошибках предыдущих деревьев для улучшения итогового прогноза. Ключевая особенность XGBoost заключается в использовании градиентного бустинга, где каждое новое дерево обучается на остатках (ошибках) предыдущих моделей, таким образом минимизируя сумму ошибок предсказаний. Алгоритм применяет градиентный спуск для оптимизации функции потерь, что делает его эффективным даже на сложных задачах. В XGBoost также используется регуляризация для предотвращения переобучения.

В случайном лесе важность признаков оценивается на основе того, насколько каждый из них улучшает качество разбиения данных на узлах деревьев. Когда модель строит каждое дерево, на каждом узле выбирается признак, который наилучшим образом разделяет данные, минимизируя ошибку (в нашем случае критерий Джини). Важность признака рассчитывается как суммарное улучшение выбранного критерия разбиения на всех узлах дерева, где этот признак использовался. После того как все деревья в ансамбле построены, важность признаков усредняется по всем деревьям. Таким образом, признаки, которые чаще использовались для важных разбиений и давали значительное улучшение точности, получают более высокий балл важности. В XGBoost важность признаков также оценивается на основе их вклада в построение дерева, но с дополни-

тельными особенностями. В XGBoost важность признаков измеряется через три основных метрики. Первая – это gain (прирост), который отражает, насколько сильно каждый признак улучшает критерий разбиения на каждом узле дерева. Чем больше прирост, тем важнее признак. Вторая метрика – weight (вес), отражает, сколько раз признак использовался для разбиения данных на всех деревьях. Признаки, чаще используемые для разбиений, считаются более важными. Третья метрика – cover (покрытие), показывает, насколько часто признак участвует в разбиении большого количества данных. В статье значения нормализуются, чтобы их сумма составляла 1. Полученные результаты от 100 экспериментов были усреднены и выведены на рис. 1.

Важности признаков обоих методов отображены на рис. 1 и 2: по горизонтали – средние уменьшения неопределенности, а по вертикали – признаки в порядке уменьшения их значимости для моделей. Из пяти выбранных значимых признаков составлялся рейтинг значимости для реализации программы для клиницистов, чтобы врачам было проще пользоваться полученными результатами.

Можно обратить внимание на то, что важность признака зависит от того, как часто он встречается в деревьях, потому бинарные переменные могут проигрывать в важности предикторам с большим числом возможных значений из-за того, что последние встречаются намного чаще на разных уровнях деревьев [21]. Несмотря на подобные упущения и на невозможность интерпретации, полученных признаков с помощью этих методов как причинно-следственные связи или беспристрастные ассоциации, их полезно сообщать, чтобы получить непосредственное представление об основе их предсказаний.

Метрикой для оценки предсказательной способности построенных моделей служит AUC (Area Under the ROC Curve) традиционно используемая для оценки медицинской диагностики [22]. Она измеряет площадь под ROC-кривой (Receiver Operating Characteristic) – графическим представлением зависимости между чувствительностью и специфичностью модели при различных порогах классификации. AUC полезна, когда классы не сбалансированы, как в данном случае. Она также позволяет оценить качество модели независимо от выбранного порога принятия решения, что служит ее преимуществом перед другими метриками – точностью и полнотой [22]. AUC статистически непротиворечива, а также более избирательна, чем точность [23].

Алгоритмы ML включают в себя ряд гиперпараметров, которые должны быть установлены до запуска алгоритмов. В отличие от параметров, узнаваемых в процессе обучения, гиперпараметры определяют структуру алгоритма ML и то, как алгоритм обучается. По причине малого размера набора данных, на которых независимо от остальных выборок подбирались бы гиперпараметры, были выбраны параметры по умолчанию, т. е. задаваемые в используемых программных пакетах на основе рекомендаций или опыта [24]. Подробную информацию о гиперпараметризации алгоритмов можно найти в руководстве пользователя scikit-learn.

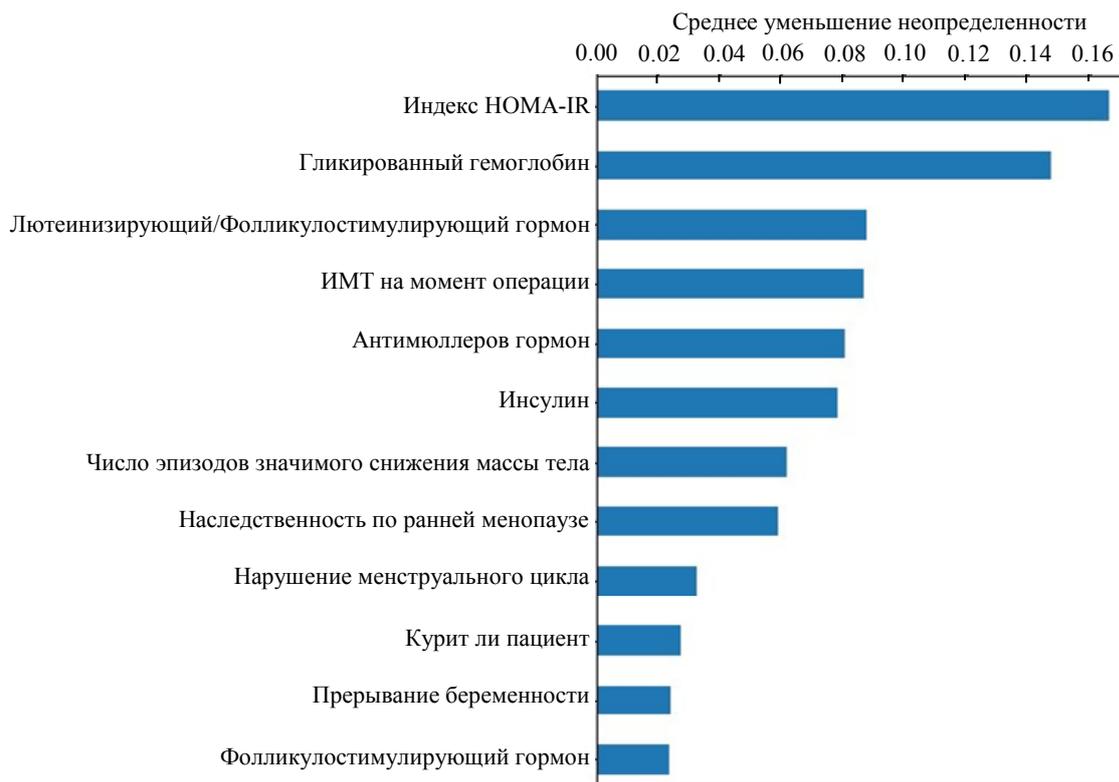
Учитывая, что оценки площади под ROC-кривой (AUC) могут различаться из-за различных методов ее оценки и стохастической природы алгоритмов, проведено случайное разделение каждого из двух наборов данных на обучающую и тестовую выборки в соотношении 67 и 33 % в количестве 100 раз. В каждом эксперименте выборки отправляются на обучение и тестирование соответственно. Арифметические средние полученных результатов для каждой модели представлены в таблице.

Обсуждение результатов. В статье принято считать важными признаками те, среднее уменьшение неопределенности которых больше или равно 0.08.

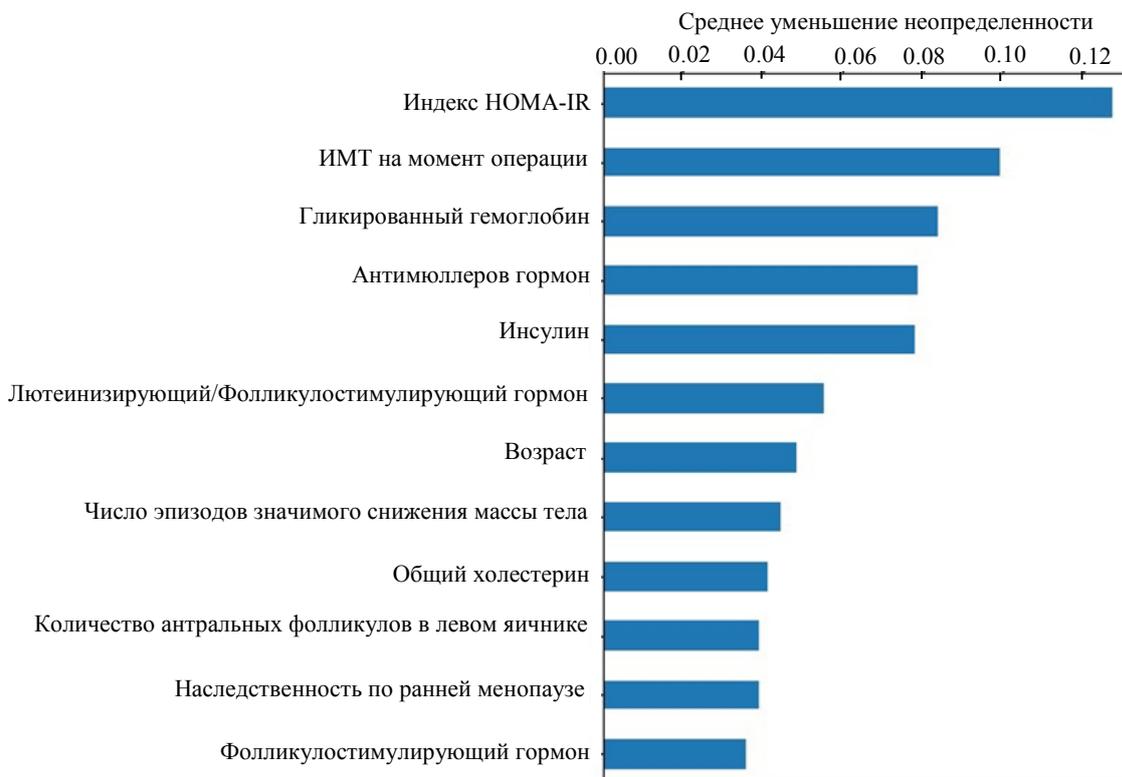
Среди ключевых факторов, связанных со снижением уровня АМГ после бариатрической операции, основными предикторами служат индекс НОМА-IR, гликированный гемоглобин, отношение показателей лютеинизирующего и фолликулостимулирующего гормона, ИМТ на момент операции и исходный уровень АМГ для модели XGBoost (рис. 1, а). Модель случайного леса выделила несколько иные признаки: индекс НОМА-IR, ИМТ на момент операции и гликированный гемоглобин (рис. 1, б).

Анализ второго набора данных, касающегося предсказания НМЦ, выявил следующие значимые факторы для модели случайного леса: количество антральных фолликулов (КАФ) в левом яичнике, индекс НОМА-IR, антимюллеров гормон и наследственность по ранней менопаузе (рис. 2).

Важно отметить, что результаты моделей машинного обучения, основанные на значимости признаков, позволяют выявить ключевые ассоциации между метаболическим и репродуктивным статусами, однако они не могут быть интерпрети-



a



b

Рис. 1. Наиболее важные признаки для первого набора данных:
a – экстремальный градиентный бустинг; *b* – случайный лес
 Fig. 1. The most important features: *a* – extremal gradient busting; *b* – random forest

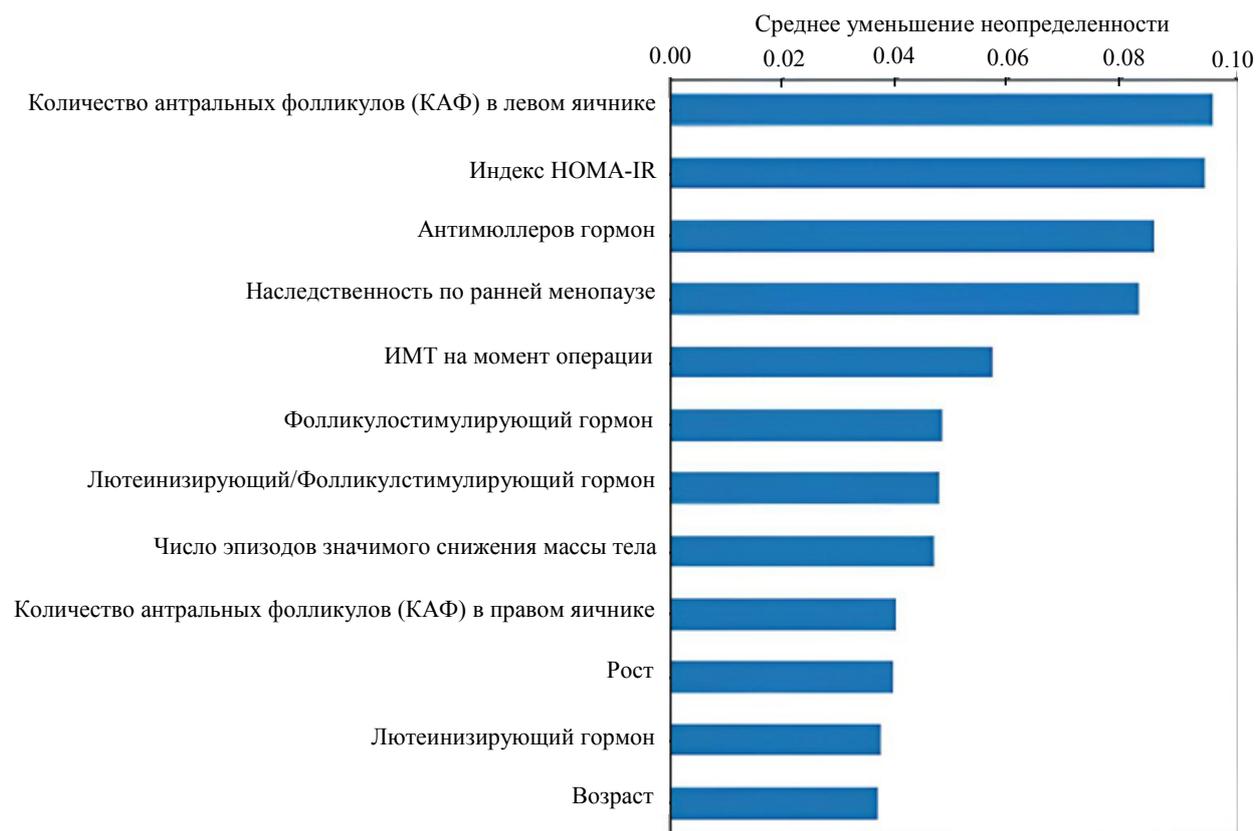


Рис. 2. Наиболее важные признаки случайного леса для второго набора данных
Fig. 2. Most important features of the random forest for the second dataset

рованы как прямые причинно-следственные связи. Эти выводы открывают новые возможности для дальнейших исследований, направленных на изучение влияния метаболических нарушений на репродуктивную функцию и разработку персонализированных подходов к лечению пациенток, планирующих беременность после бариатрической хирургии.

Средние значения AUC
Average AUC values

Модель	АМГ	НМЦ
Логистическая регрессия	0.69	0.67
Метод k-ближайших соседей	0.77	0.65
Метод опорных векторов	0.62	0.50
Наивный байесовский классификатор Бернулли	0.51	0.69
Дерево решений	0.70	0.70
Случайный лес	0.79	0.80
Экстремальный градиентный бустинг (XGB)	0.80	0.73
3-слойный перцептрон с 100 нейронов в каждом слое	0.67	0.63

Результаты экспериментов (см. таблицу) показали, что наилучшими моделями для прогноза послеоперационного снижения уровня антимюллера гормона (АМГ) и наличия нарушения мен-

струального цикла (НМЦ) оказались случайный лес и экстремальный градиентный бустинг. Средние значения метрики AUC для случайного леса составили 0.79 для набора данных с АМГ и 0.80 для НМЦ. Модель экстремального градиентного бустинга продемонстрировала AUC на уровне 0.80 и 0.73 соответственно для этих же данных.

Также метод k-ближайших соседей показал AUC, равный 0.77 для данных с АМГ, однако для второго набора метрика равна 0.65.

Наивный байесовский классификатор, метод опорных векторов и многослойный перцептрон продемонстрировали сравнительно низкую точность, особенно в задаче предсказания уровня АМГ. Это может свидетельствовать о том, что эти модели требуют более глубокой настройки гиперпараметров, которая недоступна из-за малой выборки в нашем случае. Таким образом, хотя большинство традиционных моделей показали приемлемые результаты, они уступают более сложным методам, которые лучше учитывают многомерность данных и сложность взаимодействия признаков.

Заключение. В современных исследованиях в области репродуктивного здоровья и влияния на него различных медицинских вмешательств,

например бариатрической хирургии, методы машинного обучения (МО) недостаточно используются. Это связано с ограничениями количества и структурности данных, получаемых из различных медицинских учреждений, что в свою очередь может быть связано с организационными особенностями здравоохранения. Так, например, анализ крови на АМГ не входит в стандарт оказания медицинской помощи при планировании бариатрических операций, с этим связано ограниченное количество данных в нашем исследовании. Сведения об уровне АМГ до и после операции, используемые в данной статье, в определенном смысле уникальными. Перспективу разработки темы представляет пополнение набора данных для улучшения эффективности моделей.

Исходя из литературных сведений, медицинские исследования вообще и в области эндокринологии-репродуктологии в частности, основаны на традиционных статистических методах и анализах. Методы МО могут предоставить ценные инструменты для анализа сложных взаимосвязей между различными факторами и предсказания определенных клинических событий. Потенциал инструментов МО в качестве поддержки принятия клинических решений при выявлении факторов риска и прогнозировании исхода заболевания был изучен на примере, связанном с бариатрической хирургией.

Результаты исследования позволили прийти к более полному пониманию влияния бариатрических операций на репродуктивное здоровье женщин – выявить прогностические факторы, влияющие на развитие неблагоприятных событий в гормональном статусе, что имеет значение при выборе наиболее эффективных методов лечения ожирения у женщин, планирующих беременность.

Ограничения данных исследований связаны преимущественно с характеристиками набора данных. Во-первых, существует неясность в отношении применимости разработанных моделей для более длительных периодов наблюдения. Хотя 12-месячный интервал выбран на основе кли-

нической значимости в контексте планирования беременности, результаты могут не отражать долгосрочные изменения в репродуктивной функции или другие клинические параметры. Это ограничивает возможность обобщения выводов на более продолжительные временные рамки и другие аспекты здоровья пациенток.

Во-вторых, в статье использовано значительное количество признаков (25 столбцов), что может повлиять на интерпретацию результатов моделей машинного обучения. Несмотря на использование методов предобработки данных и выбора наиболее значимых переменных, остается риск переобучения моделей, особенно при небольшом размере выборки (149 пациенток). Это может привести к чрезмерной адаптации моделей к специфическим особенностям конкретного набора данных, снижая их способность к интерпретации новых.

Третье ограничение связано с возможным риском систематической ошибки. Например, пропуски в данных, несмотря на предпринятые меры по их заполнению средними значениями, могут влиять на точность модели и приводить к искаженным результатам. Кроме того, отсутствие информации о некоторых ключевых факторах, которые могут влиять на репродуктивную функцию (например, данные о гормональном фоне, других сопутствующих заболеваниях), также может ограничивать точность прогноза.

Тем не менее, важно отметить, что решалась актуальная клиническая проблема на данных реальной практики. Устранение указанных ограничений послужит дальнейшим исследованиям, направленным на повышение точности моделей и применимости полученных выводов к принятию врачебных решений и формированию новых клинических стандартов. В свою очередь, интеграция методов машинного обучения в клиническую практику может позволить не только повысить точность диагностики и персонализированного лечения, но и поспособствовать исследованию данных и поиску наиболее важных признаков для прогнозирования.

Список литературы

1. World Obesity Federation, World Obesity Atlas 2023. URL: https://www.worldobesityday.org/assets/downloads/World_Obesity_Atlas_2023_Report.pdf (дата обращения: 24.05.2024).
2. Kopelman P. G. Obesity as a medical problem // Nature. 2000. Vol. 404. P. 635–643. doi: 10.1038/35007508.

3. Pasquali R., Patton L., Gambineri A. Obesity and infertility // Current Opinion in Endocrinol. Diabetes and Obesity. 2007. Vol. 14, no. 6. P. 482–487. doi: 10.1097/MED.0b013e3282f1d6cb.

4. Role of obesity in female reproduction / W. Yong, J. Wang, Y. Leng, L. Li, H. Wang // Int. J. Med. Sci. 2023. Vol. 20, no. 3. P. 366–375. doi: 10.7150/ijms.80189.

5. Lei R., Chen S., Li W. Advances in the study of the correlation between insulin resistance and infertility // *Frontiers in Endocrinol. (Lausanne)*. 2024. Vol. 15. P. 1288326. doi: 10.3389/fendo.2024.1288326.
6. Infertility improvement after medical weight loss in women and men: A review of the literature / P. Pavli, O. Triantafyllidou, E. Kapantais, N. F. Vlahos, G. Valsamakis // *Int. J. Mol. Sci.* 2024. Vol. 25, no. 3. P. 1909. doi: 10.3390/ijms25031909.
7. Lv B., Xing C., He B. Effects of bariatric surgery on the menstruation- and reproductive-related hormones of women with obesity without polycystic ovary syndrome: a systematic review and meta-analysis // *Surg. Obes. and Relat. Dis.* 2022. Vol. 18, no. 1. P. 148–160. doi: 10.1016/j.soard.2021.09.008.
8. Bariatric surgery versus non-surgical treatment for obesity: a systematic review and meta-analysis of randomised controlled trials / V. L. Gloy, M. Briel, D. L. Bhatt, S. R. Kashyap, P. R. Schauer, G. Mingrone, H. C. Bucher, A. J. Nordmann // *BMJ*. 2013. Vol. 347. P. 1–16. doi: 10.1136/bmj.f5934.
9. Anti-mullerian hormone levels increase after bariatric surgery in obese female patients with and without polycystic ovary syndrome / M. Buyukkaba, S. Turgut, M. M. Ilhan, I. Ekinci, İ. Yaylım, S. U. Zeybek, S. Turan, E. Tasan, O. Karaman // *Hormone and Metabolic Research*. 2022. Vol. 54, no. 3. P. 194–198. doi: 10.1055/a-1756-4798.
10. Effect of sleeve gastrectomy bariatric surgery-induced weight loss on serum AMH levels in reproductive aged women / Sh. Bhandari, I. Ganguly, M. Bhandari, P. Agarwal, A. Singh, N. Gupta, A. Mishra // *Gynecological Endocrinol.* 2016. Vol. 32, no. 10. P. 799–802. doi: 10.3109/09513590.2016.1169267.
11. Lisboa P. J., Taktak A. F. G. The use of artificial neural networks in decision support in cancer: a systematic review // *Neural networks*. 2006. Vol. 19, no. 4. P. 408–415.
12. Development of a decision tree to assess the severity and prognosis of stable COPD / C. Esteban, I. Arostegui, J. Moraza, M. Aburto, J. M. Quintana, J. Pérez-Izquierdo, S. Aizpiri, A. Capelastegui // *Eur. Resp. J.* 2011. Vol. 38, no. 6. P. 1294–1300.
13. Prognostic Bayesian networks I: rationale, learning procedure, and clinical use / M. Verduijn, N. Peek, P. M. J. Rosseel, E. de Jonge, B. A. J. M. de Mol // *J. of Biomed. Informatics*. 2007. Vol. 40, no. 6. P. 609–618. doi: 10.1016/j.jbi.2007.07.003.
14. Barakat N., Bradley A. P., Barakat M. N. H. Intelligent support vector machines for diagnosis of diabetes mellitus // *IEEE Trans. on Inf. Technol. in Biomed.* 2010. Vol. 14, no. 4. P. 1114–1120. doi: 10.1109/TITB.2009.2039485.
15. Liu H., Motoda H. *Computational methods of feature selection*. Boca Raton, FL, USA: CRC Press, 2007. P. 81.
16. Prediction of acute kidney injury after liver transplantation: machine learning approaches vs. logistic regression model / H. C. Lee, S. B. Yoon, S. M. Yang, W. H. Kim, H. G. Ryu, C. W. Jung, K. S. Suh, K. H. Lee // *J. of Clin. Med.* 2018. Vol. 7, no. 11. P. 428. doi: 10.3390/jcm7110428.
17. Artificial intelligence in healthcare: past, present and future / F. Jiang, Y. Jiang, H. Zhi, Y. Dong, H. Li, S. Ma, Y. Wang, Q. Dong, H. Shen, Y. Wang // *Stroke and Vascular Neurol.* 2017. Vol. 2, no. 4. P. 230–243.
18. Global evolution of research in artificial intelligence in health and medicine: a bibliometric study / B. X. Tran, G. T. Vu, G. H. Ha, Q.-H. Vuong, M.-T. Ho, T.-T. Vuong, V.-P. La, M.-T. Ho, K.-C. P. Nghiem, H. L. T. Nguyen, C. A. Latkin, W. W. S. Tam, N.-M. Cheung, H.-K. T. Nguyen, C. S. H. Ho, R. C. M. Ho // *J. of Clin. Med.* 2019. Vol. 8, no. 3. P. 360. doi: 10.3390/jcm8030360.
19. Azure M. Machine learning algorithm cheat sheet for Azure Machine Learning designer. URL: <https://learn.microsoft.com/en-us/azure/machine-learning/algorithm-cheat-sheet?view=azureml-api-1> (дата обращения: 19.10.2024).
20. Mahesh B. Machine learning algorithms – a review // *Int. J. of Sci. and Res. (IJSR)*. 2020. Vol. 9, no. 1. P. 381–386.
21. Understanding variable importances in forests of randomized trees / G. Louppe, L. Wehenkel, A. Sutera, P. Geurts // *Advances in Neural Inf. Proc. Systems*. 2013. Vol. 26. P. 1–9.
22. Huang J., Ling C. X. Using AUC and accuracy in evaluating learning algorithms // *IEEE Trans. on Knowledge and Data Engin.* 2005. Vol. 17, no. 3. P. 299–310. doi: 10.1109/TKDE.2005.50.
23. Ling C. X., Huang J., Zhang H. AUC: a statistically consistent and more discriminating measure than accuracy // *IJCAI'03. Proc. of the 18th Int. joint Conf. on Artificial Intelligence*. 2003. San Francisco, CA: United States. Vol. 3. P. 519–524.
24. Scikit-learn: Machine learning in Python / F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot, É. Duchesnay // *J. of Machine Learning Res.* 2011. Vol. 12. P. 2825–2830.

Информация об авторах

Хамитов Абулкаир Кайратович – магистрант кафедры вычислительной техники СПбГЭТУ «ЛЭТИ».
E-mail: abulkairhamitov@gmail.com

Мелдо Анна Александровна – д-р мед. наук, профессор кафедры вычислительной техники СПбГЭТУ «ЛЭТИ».
E-mail: anna.meldo@yandex.ru

Швец Злата Викторовна – ординатор по специальности «Эндокринология» кафедры терапии факультетской с курсом эндокринологии, кардиологии с клиникой им. акад. И. П. Павлова ФГБОУ ВО ПСПбГМУ им. И. П. Павлова Минздрава России, ул. Льва Толстого, 6–8, Санкт-Петербург, Россия, 197101).

E-mail: shvetszlata31@gmail.com

<http://orcid.org/0009-0007-9218-8133>

Дора Светлана Владимировна – д-р мед. наук, профессор кафедры терапии факультетской с курсом эндокринологии, кардиологии с клиникой имени Г.Ф. Ланга ФГБОУ ВО ПСПбГМУ им. И. П. Павлова Минздрава России, ул. Льва Толстого, 6–8, Санкт-Петербург, Россия, 197101.

E-mail: doras2001@mail.ru

<http://orcid.org/0000-0002-8249-6075>

Вклад авторов:

Хамитов А. К. – изучение литературы, преобразование данных, обучение моделей машинного обучения, подготовка текста.

Мелдо А. А. – руководство научной работой, разработка концепции, аннотация, заключение, редактирование текста.

Швец З. В. – сбор материала, формирование медицинской базы данных, предоставление материала для исследования, подготовка текста.

Дора С. В. – организация сбора материала, формулировка целевых направлений исследования, редактирование текста.

References

- World Obesity Federation, World Obesity Atlas 2023. URL: https://www.worldobesityday.org/assets/downloads/World_Obesity_Atlas_2023_Report.pdf (data obrashheniya: 24.05.2024).
- Kopelman P. G. Obesity as a medical problem // *Nature*. 2000. Vol. 404. P. 635–643. doi: 10.1038/35007508.
- Pasquali R., Patton L., Gambineri A. Obesity and infertility // *Current Opinion in Endocrinol. Diabetes and Obesity*. 2007. Vol. 14, no. 6. P. 482–487. doi: 10.1097/MED.0b013e3282f1d6cb.
- Role of obesity in female reproduction / W. Yong, J. Wang, Y. Leng, L. Li, H. Wang // *Int. J. Med. Sci*. 2023. Vol. 20, no. 3. P. 366–375. doi: 10.7150/ijms.80189.
- Lei R., Chen S., Li W. Advances in the study of the correlation between insulin resistance and infertility // *Frontiers in Endocrinol. (Lausanne)*. 2024. Vol. 15. P. 1288326. doi: 10.3389/fendo.2024.1288326.
- Infertility improvement after medical weight loss in women and men: A review of the literature / P. Pavli, O. Triantafyllidou, E. Kapantais, N. F. Vlahos, G. Valsamakis // *Int. J. Mol. Sci*. 2024. Vol. 25, no. 3. P. 1909. doi: 10.3390/ijms25031909.
- Lv B., Xing C., He B. Effects of bariatric surgery on the menstruation- and reproductive-related hormones of women with obesity without polycystic ovary syndrome: a systematic review and meta-analysis // *Surg. Obes. and Relat. Dis*. 2022. Vol. 18, no. 1. P. 148–160. doi: 10.1016/j.soard.2021.09.008.
- Bariatric surgery versus non-surgical treatment for obesity: a systematic review and meta-analysis of randomised controlled trials / V. L. Gloy, M. Briel, D. L. Bhatt, S. R. Kashyap, P. R. Schauer, G. Mingrone, H. C. Bucher, A. J. Nordmann // *BMJ*. 2013. Vol. 347. P. 1–16. doi: 10.1136/bmj.f5934.
- Anti-mullerian hormone levels increase after bariatric surgery in obese female patients with and without polycystic ovary syndrome / M. Buyukkaba, S. Turgut, M. M. Ilhan, I. Ekinci, İ. Yaylim, S. U. Zeybek, S. Turan, E. Tasan, O. Karaman // *Hormone and Metabolic Research*. 2022. Vol. 54, no. 3. P. 194–198. doi: 10.1055/a-1756-4798.
- Effect of sleeve gastrectomy bariatric surgery-induced weight loss on serum AMH levels in reproductive aged women / Sh. Bhandari, I. Ganguly, M. Bhandari, P. Agarwal, A. Singh, N. Gupta, A. Mishra // *Gynecological Endocrinol*. 2016. Vol. 32, no. 10. P. 799–802. doi: 10.3109/09513590.2016.1169267.
- Lisboa P. J., Taktak A. F. G. The use of artificial neural networks in decision support in cancer: a systematic review // *Neural networks*. 2006. Vol. 19, no. 4. P. 408–415.
- Development of a decision tree to assess the severity and prognosis of stable COPD / C. Esteban, I. Arostegui, J. Moraza, M. Aburto, J. M. Quintana, J. Pérez-Izquierdo, S. Aizpiri, A. Capelastegui // *Eur. Resp. J*. 2011. Vol. 38, no. 6. P. 1294–1300.
- Prognostic Bayesian networks I: rationale, learning procedure, and clinical use / M. Verduijn, N. Peek, P. M. J. Rosseel, E. de Jonge, B. A. J. M. de Mol // *J. of Biomedical Informatics*. 2007. Vol. 40, no. 6. P. 609–618. doi: 10.1016/j.jbi.2007.07.003.
- Barakat N., Bradley A. P., Barakat M. N. H. Intelligent support vector machines for diagnosis of diabetes mellitus // *IEEE Trans. on Inf. Technol. in Biomed*. 2010. Vol. 14, no. 4. P. 1114–1120. doi: 10.1109/TITB.2009.2039485.
- Liu H., Motoda H. *Computational methods of feature selection*. Boca Raton, FL, USA: CRC Press, 2007. P. 81.

16. Prediction of acute kidney injury after liver transplantation: machine learning approaches vs. logistic regression model / H. C. Lee, S. B. Yoon, S. M. Yang, W. H. Kim, H. G. Ryu, C. W. Jung, K. S. Suh, K. H. Lee // *J. of Clin. Med.* 2018. Vol. 7, no. 11. P. 428. doi: 10.3390/jcm7110428.

17. Artificial intelligence in healthcare: past, present and future / F. Jiang, Y. Jiang, H. Zhi, Y. Dong, H. Li, S. Ma, Y. Wang, Q. Dong, H. Shen, Y. Wang // *Stroke and Vascular Neurol.* 2017. Vol. 2, no. 4. P. 230–243.

18. Global evolution of research in artificial intelligence in health and medicine: a bibliometric study / B. X. Tran, G. T. Vu, G. H. Ha, Q.-H. Vuong, M.-T. Ho, T.-T. Vuong, V.-P. La, M.-T. Ho, K.-C. P. Nghiem, H. L. T. Nguyen, C. A. Latkin, W. W. S. Tam, N.-M. Cheung, H.-K. T. Nguyen, C. S. H. Ho, R. C. M. Ho // *J. of Clin. Med.* 2019. Vol. 8, no. 3. P. 360. doi: 10.3390/jcm8030360.

19. Azure M. Machine learning algorithm cheat sheet for Azure Machine Learning designer. URL: <https://learn.microsoft.com/en-us/azure/machine-learning/algorithm-cheat-sheet?view=azureml-api-1> (data obrashhenija: 19.10.2024).

20. Mahesh B. Machine learning algorithms – a review // *Int. J. of Sci. and Res. (IJSR)*. 2020. Vol. 9, no. 1. P. 381–386.

21. Understanding variable importances in forests of randomized trees / G. Louppe, L. Wehenkel, A. Sutera, P. Geurts // *Advances in Neural Inf. Proc. Systems*. 2013. Vol. 26. P. 1–9.

22. Huang J., Ling C. X. Using AUC and accuracy in evaluating learning algorithms // *IEEE Trans. on Knowledge and Data Engin.* 2005. Vol. 17, no. 3. P. 299–310. doi: 10.1109/TKDE.2005.50.

23. Ling C. X., Huang J., Zhang H. AUC: a statistically consistent and more discriminating measure than accuracy // *IJCAI'03. Proc. of the 18th Int. joint Conf. on Artificial Intelligence*. 2003. San Francisco, CA: United States. Vol. 3. P. 519–524.

24. Scikit-learn: Machine learning in Python / F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot, É. Duchesnay // *J. of Machine Learning Res.* 2011. Vol. 12. P. 2825–2830.

Information about the authors

Abalkair K. Khamitov – Master's student of the Department of Computer Technology of Saint Petersburg Electrotechnical University.

E-mail: abulkairhamitov@gmail.com

Anna A. Meldo – Dr Sci. (Med.), Professor of the Department of Computer Tehcnology of Saint Petersburg Electrotechnical University.

E-mail: anna.meldo@yandex.ru

Zlata V. Shvets – Resident in the specialty «Endocrinology» of the Department of Therapy of the Faculty with the course of endocrinology, cardiology with the clinic named after Acad. I. P. Pavlov FGBOU VO PSPbGMU named after I. P. Pavlov of the Ministry of Health of Russia, 6–8 Lev Tolstoy St., St. Petersburg.

E-mail: shvetzla-ta31@gmail.com

<http://orcid.org/0009-0007-9218-8133>

Svetlana V. Dora – Dr Sci. (Med.), Professor of the Department of Faculty Therapy with a course of endocrinology, cardiology with G. F. Lang Clinic, I. P. Pavlov St. Petersburg State Medical University of the Russian Ministry of Health, 6–8 Lev Tolstoy St., St. Petersburg.

E-mail: doras2001@mail.ru

<http://orcid.org/0000-0002-8249-6075>

Author contribution statement:

Khamitov A. K – literature review, data preprocessing, training of machine learning models, text preparation.

Meldo A. A. – supervision of scientific work, conceptualization, annotation, conclusion, text editing.

Shvets Z. V. – collection of material, formation of medical database, provision of material for research, text preparation.

Dora S. V. – organization of material collection, formulation of target areas of research, text editing.

Статья поступила в редакцию 29.06.2024; принята к публикации после рецензирования 22.10.2024; опубликована онлайн 25.12.2024.

Submitted 29.06.2024; accepted 22.10.2024; published online 25.12.2024.
