



doi: 10.25005/2074-0581-2024-26-3-478-487

ИСПОЛЬЗОВАНИЕ ТЕХНОЛОГИЙ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ПРИ ПОДБОРЕ ИМПЛАНТАТОВ ДЛЯ АУГМЕНТАЦИОННОЙ МАММОПЛАСТИКИ

Д.К. АТАМАНОВ¹, А.К. САПАКОВА², В.А. ЕГОРОВ¹, О.А. СЕДУХИН³

¹ ООО Лечебно-диагностический центр «АвисМед», Новосибирск, Российская Федерация

² Медицинский научно-образовательный центр Московского государственного университета им. М.В. Ломоносова, Москва, Российская Федерация

³ Huawei Russian Research Institute, ООО «Техкомпания Хуавэй» Россия, Москва, Российская Федерация

Цель: улучшение прогнозирования результатов операций аугментационной маммопластики (АМ).

Материал и методы: исследование основано на ретроспективном анализе данных 265 пациенток, удовлетворённых результатом операции, которым была выполнена АМ. На основании численных параметров и пожеланий пациента (исходные признаки) и параметров установленных имплантатов (целевые признаки) осуществлялось обучение искусственного интеллекта (ИИ).

Результаты: полученная модель машинного обучения продемонстрировала совпадение параметров предлагаемого к установке имплантата с выбором хирурга в 81,5% случаев, что можно считать допустимым показателем для практического применения модели.

Заключение: мы полагаем, что методы машинного обучения могут повысить точность при выборе наиболее подходящего типа и размера имплантата, учитывая широкий спектр индивидуальных параметров и пожеланий пациента.

Ключевые слова: аугментационная маммопластика, подбор имплантатов, искусственный интеллект, машинное обучение.

Для цитирования: Атаманов ДК, Сапакова АК, Егоров ВА, Седухин ОА. Использование технологий искусственного интеллекта при подборе имплантатов для аугментационной маммопластики. *Вестник Авиценны*. 2024;26(3):478-87. <https://doi.org/10.25005/2074-0581-2024-26-3-478-487>

USE OF ARTIFICIAL INTELLIGENCE TECHNOLOGIES IN THE SELECTION OF IMPLANTS FOR AUGMENTATION MAMMOPLASTY

D.K. ATAMANOV¹, A.K. SAPAKOVA², V.A. EGOROV¹, O.A. SEDUKHIN³

¹ «AvisMed» Clinic, Novosibirsk, Russian Federation

² Medical Research and Educational Center of Lomonosov Moscow State University, Moscow, Russian Federation

³ Huawei Russian Research Institute, Moscow, Russian Federation

Objective: To enhance the accuracy of predicting the outcomes of augmentation mammoplasty (AM).

Methods: The study involves a retrospective analysis of data from 265 patients satisfied with the AM results. Artificial intelligence (AI) was trained using numerical variables, such as anthropometric measurements and patient preferences, as input data, and the implant parameters were used as output data.

Results: The machine learning (ML) algorithms supported clinicians in determining the optimal selection of implants in 81.5% of cases, indicating the practical applicability of the model.

Conclusion: The ML approach can improve accuracy in selecting the most appropriate implant type and size, considering a wide range of individual parameters and patient wishes.

Keywords: Augmentation mammoplasty, selection of implants, artificial intelligence, machine learning.

For citation: Atamanov DK, Sapakova AK, Egorov VA, Sedukhin OA. Ispol'zovanie tekhnologiy iskusstvennogo intellekta pri podbore implantatov dlya aagmentatsionnoy mammoplastiki [Use of artificial intelligence technologies in the selection of implants for augmentation mammoplasty]. *Vestnik Avitsenny [Avicenna Bulletin]*. 2024;26(3):478-87. <https://doi.org/10.25005/2074-0581-2024-26-3-478-487>

ВВЕДЕНИЕ

Процесс выбора имплантатов при АМ, с его многочисленными переменными, является непростой задачей в пластической хирургии, требующей комплексного подхода. Решение по подбору имплантата обусловлено обширным спектром параметров, таких как анатомические характеристики (ширина основания молочной железы, расстояние от соска до субмаммарной складки в натяже-

INTRODUCTION

With its numerous variables, the implant selection process for AM is a critical step in plastic surgery that requires a comprehensive approach. A wide range of parameters determines the decision to select an implant, including anatomical characteristics such as the width of the base of the mammary gland, the nipple-inframammary fold distance (M-SIM) measured under

нии) и персональные предпочтения пациентки [1]. Мы полагаем, что оценивать эстетику молочной железы следует в комплексе с талией и бёдрами: именно диспропорция этих трёх величин чаще всего приводит пациентку к пластическому хирургу. Поэтому применение антропометрических показателей, таких как рост, вес, окружности бёдер, талии, груди на уровне сосково-ареолярного комплекса (САК) и субмаммарной складки, играет важную роль в процессе подбора имплантата. Задачей хирурга является соблюдение баланса между анатомическими, антропометрическими характеристиками и желанием пациентки с опорой на собственный опыт и эстетическое чувство.

В исследовании, проведённом в 2016 году, Adams WP, Mckee D проанализировали 5253 статьи, так или иначе связанных с подбором имплантатов молочных желёз. Оценка качества систем подбора имплантатов производилась с помощью инструмента «Методологический индекс нерандомизированных исследований» (Methodological Index for Non-Randomized Studies). В результате были выделены 33 статьи, содержащие различные схемы подбора грудных имплантатов для первичной АМ [2]. Процесс выбора имплантата в данных исследованиях учитывает сочетания различных параметров пациентки, включая измерения молочных желёз, рост, массу тела, ширину грудной клетки, ширину бёдер и другие параметры [2-4]. Тем не менее, в статьях явно не сформулировано, как применять эти переменные для выбора имплантата определённого размера. Adams WP, Mckee D подчёркивают, что существуют разногласия относительно наиболее эффективного метода выбора подходящего размера имплантата, лучше всего соответствующего груди пациентки [2]. Не было предложено чёткого алгоритма, который мог бы быть воспроизведён каждым хирургом на основе переменных, используемых в системах, что делает их реализацию более сложной.

Мы предлагаем оптимизировать процесс подбора грудных имплантатов с помощью технологии ИИ. ИИ – это область науки и технологии, занимающаяся созданием и развитием компьютерных систем, которые способны выполнять задачи, обычно требующие человеческого интеллекта. Это включает в себя (но не ограничивается) такие функции, как восприятие (в том числе распознавание образов и звука), понимание естественного языка, обучение и принятие решений. Определение ИИ достаточно широкое и подразумевает множество подходов и технологий [5]. Машинное обучение – это одна из ключевых областей ИИ, которая позволяет компьютерам «учиться» и адаптироваться к новым данным без явного программирования. В процессе машинного обучения алгоритмы анализируют и обрабатывают большой объём данных, выявляя в них определённые закономерности и образцы. На основании этих закономерностей и образцов алгоритмы машинного обучения могут делать предсказания или принимать решения [6]. На практике термины «искусственный интеллект» и «машинное обучение» применяют как взаимозаменяемые, подавляющее большинство современных интеллектуальных систем основаны на машинном обучении [7].

В медицине наиболее широко изучено применение ИИ в лучевой диагностике. За 2016-2017 гг. было опубликовано около 750 статей, описывающих применение ИИ в медицинской визуализации. Были разработаны модели машинного обучения, которые анализируют маммографию с такой же точностью, как у врачей-рентгенологов. В настоящее время ИИ успешно применяется в диагностике злокачественных новообразований кожи, в определении метастазов рака молочной железы в биоптатах сторожевых лимфоузлов. В эстетической хирургии тоже происходит постепенное внедрение технологий ИИ. Модель машинного обучения была обучена на 165 изображениях женщин, которые предварительно

tension, and the patient's personal preferences [1]. It is crucial to consider the overall harmony of the body when evaluating the aesthetics of the breast. The harmonious balance between the breast, waist, and hips is essential, as an imbalance in these areas often motivates individuals to seek the expertise of a plastic surgeon. Hence, anthropometric parameters such as height, weight, hip, waist, and chest circumference, measured at the nipple-areolar complex (NAC) and below the breast at the level of the inframammary fold, are crucial in selecting implants. The surgeon's responsibility is to balance anatomical and anthropometric characteristics with the patient's preferences while relying on experience and aesthetic sense.

In 2016, Adams WP and Mckee D conducted a study analyzing 5253 articles related to the selection of breast implants. They assessed the quality of implant selection systems using the Methodological Index for Non-Randomized Studies (MINORS), a tool for quality assessment. In total, 33 articles were identified, which contained various methods for selecting breast implants for primary AM [2]. The implant selection process in these studies considers various patient parameters, including breast measurements, height, body weight, chest width, hip width, and other parameters [2-4]. However, the articles do not explicitly explain how to use these variables to choose a specific implant size. The authors emphasize the controversy surrounding the most effective method for selecting the appropriate implant size that best fits the patient's breast [2]. No straightforward algorithm has been proposed that can be universally adopted by every surgeon based on the variables used in the systems, making their implementation more complex.

We propose using AI technology to optimize the process of selecting breast implants. AI is a field of science and technology that involves creating computer systems capable of performing tasks that typically require human intelligence. These tasks include perception (including image and sound recognition), natural language understanding, learning, and decision-making. The definition of AI is quite broad and encompasses various approaches and technologies [5]. ML, a key area of AI, enables computers to "learn" and adapt to new data without explicit programming. During machine learning, algorithms analyze and process large volumes of data, identifying patterns. Based on these patterns, machine learning algorithms can make predictions or decisions [6]. In practice, the terms "artificial intelligence" and "machine learning" are often used interchangeably; the majority of modern AI systems are based on machine learning [7].

In medicine, one of the most extensively researched applications of AI is in radiology diagnostics. From 2016 to 2017, around 750 articles were published detailing the use of AI in medical imaging. ML models have been created to analyze mammograms with the same level of accuracy as human radiologists. AI is successfully employed in diagnosing malignant skin tumors and identifying breast cancer metastases in sentinel lymph node biopsies. AI technologies are also gradually being introduced in aesthetic surgery. For instance, a ML model was trained using 165 images of women previously evaluated by humans. The authors reported that the model accurately classified the attractiveness of the images. Furthermore, AI can predict a person's age based on images of their face, identifying characteristics that contribute to their aging, which can help determine indications for certain anti-aging facial surgeries [8].

были оценены людьми. Авторы сообщают, что модель успешно классифицировала привлекательность изображений. Аналогично, ИИ может успешно предсказывать возраст человека на основе изображений его лица, идентифицируя характеристики, которые вносят вклад в его старение, что может помочь в определении показаний к тем или иным омолаживающим операциям на лице [8].

ЦЕЛЬ ИССЛЕДОВАНИЯ

Улучшение прогнозирования результатов операций АМ.

МАТЕРИАЛ И МЕТОДЫ

В данной работе мы рассматриваем применение технологий ИИ для оптимизации процесса подбора имплантатов. Мы выдвигаем гипотезу о том, что методы машинного обучения могут повысить точность при выборе наиболее подходящего типа и размера имплантата, учитывая широкий спектр индивидуальных параметров пациента. Для реализации цели были поставлены следующие задачи:

- Разработать модель машинного обучения для подбора имплантатов для АМ.
- Оценить точность разработанной модели в сравнении с выбором пластического хирурга.
- Применить полученные данные для оптимизации процесса подбора грудных имплантатов.

Отбор участников исследования проводился среди пациентов клиники, которым была выполнена АМ в период с 2018 по 2023 гг. Было отобрано 265 пациенток с односторонним эстетическим недостатком молочных желёз, то есть с гипомастией без птоза, тубулярной деформации, выраженной асимметрии и других дефектов, удовлетворённых результатом операции и прооперированных одним пластическим хирургом.

Протокол исследования соответствует Хельсинкской декларации Всемирной медицинской ассоциации (2013 г.). Все процедуры в этом исследовании были выполнены в рамках обычной клинической практики, данные были анонимизированы. Все пациентки дали информированное добровольное согласие на обработку своих персональных данных.

Каждой пациентке в предоперационном периоде выполнялись следующие измерения молочных желёз: ширина основания молочной железы, расстояние от соска до субмаммарной складки в натяжении. Также выполнялись измерения антропометрических параметров пациенток: длина окружности груди на уровне ВАК и на уровне субмаммарной складки, длина окружности талии и длина окружности бёдер. Измерялись рост и масса тела пациенток. В ходе предоперационного консультирования уточнялись пожелания пациенток по поводу будущего размера молочных желёз по чашке бюстгалтера (В, С или D) и формы молочных желёз (наполненность верхнего полюса – «пуш-ап эффект» или более естественная форма). Такого алгоритма обычно придерживается пластический хирург при планировании АМ. На основании полученных данных врач подбирает имплантат, имеющий следующие основные параметры: форма (анатомическая или круглая), ширина основания, длина арки, профиль (низкий, средний, высокий или экстравысокий).

Таким образом, после первичной консультации хирург имеет набор численных параметров и пожелания пациента (исходные признаки), на основании которых осуществляется выбор формы, объёма и профиля имплантата (целевые признаки). В исследуемой выборке целевые признаки были определены врачом с учё-

PURPOSE OF THE STUDY

Improving the accuracy of predicting the results of AM surgeries.

METHODS

The study explored AI technology to improve the process of selecting breast implants. We believe ML methods can enhance the accuracy of selecting the most suitable implant type and size by considering the patient's parameters. To achieve this, we have set the following objectives:

- Develop a ML model for selecting implants for AM.
- Evaluate the developed model's accuracy compared to the selection made by a plastic surgeon.
- Utilize the gathered data to enhance the breast implant selection process.

The study participants were selected from among female patients who underwent AM at the "AvisMed" Clinic, Novosibirsk, Russia, between 2018 and 2023. A total of 265 patients with the same breast anomalies, such as hypomastia without ptosis, tubular deformity, severe asymmetry, and other defects, were selected. The outcome of the surgery met their expectations, and they underwent the procedure with the same plastic surgeon.

The study was conducted following the World Medical Association Declaration of Helsinki (2013), with all procedures performed as part of routine clinical practice with anonymized data. Furthermore, all participants provided voluntary consent for processing their personal data. Before the surgery, the participant's breast measurements were taken, including the width of the breast base and the distance from the nipple to the inframammary fold under tension.

Additionally, anthropometric measurements such as chest circumference, waist circumference, hip circumference, height, and body weight were recorded. During the preoperative consultation, the patient's preferences for the future size of their breasts based on bra cup size (B, C, or D) and the desired shape of their breasts (using implants that provide fullness in the upper portion with a striking, "push-up" effect or a more natural look) discussed. These preferences were considered in preoperative AM planning. Based on the gathered data, an implant with specific characteristics is selected, including shape (anatomical or round), base width, arc length, and profile (low, moderate, high, or ultra-high).

Subsequently, the surgeon uses the collected numerical variables, such as anthropometric measurements and the patient's preferences, as input data to determine the appropriate shape, volume, and implant profile as output data. The doctor defined the target implant anatomy features in the study sample based on personal experience. Patient satisfaction was subjectively assessed through surveys, evaluating their satisfaction with the AM results and willingness to repeat it. Given that all 265 patients in the sample expressed satisfaction, the relevant target features were automatically selected for ML.

ML involves using datasets, typically represented in the form of spreadsheets, to train a ML algorithm. During this process, computer resources such as the processor carry out complex calculations while the RAM stores and manages the data being processed. The outcome of machine learning is creating a model, which is essentially an algorithm capable of receiving in-

том личного опыта. Удовлетворённость пациентов оценивалась субъективно путём прямого опроса пациентки, довольна ли она результатами операции и готова ли она повторить её. Учитывая факт удовлетворённости всех 265 пациенток выборки, установленные целевые признаки были взяты за эталон для машинного обучения.

Машинное обучение – это процесс, в ходе которого используются наборы данных (представленные в виде электронных таблиц), выполняется некоторая программа (алгоритм машинного обучения) и используются ресурсы компьютера (процессор выполняет вычисления, оперативная память хранит данные). Результатом машинного обучения является модель – алгоритм, который получает данные и выдаёт ответ, опираясь на то, чему он «научился» [7].

Поскольку входные и выходные параметры могут быть представлены как таблицы, мы использовали табличное машинное обучение. Для обучения требуется обучающая выборка данных: набор примеров с эталонными ответами. Веса модели настраиваются таким образом, чтобы для обучающих примеров модель выдавала ответы, как можно более близкие к верным. Далее качество модели проверяется на тестовой выборке данных, которые не использовались при обучении. В качестве исходных признаков мы использовали антропометрические данные и пожелания пациенток. В качестве целевых признаков мы взяли объём имплантата в см³ и профиль (low, middle, high, extra high).

Метод выбора алгоритма

Поскольку данные имеют ограниченный объём, стандартным средством выбора алгоритма является K-Fold кросс-валидация [9]. При этом мы случайно делим все имеющиеся данные на K примерно равных частей (фолдов), и обучаем модель K раз: на i-м шаге мы обучаем модель на всех фолдах кроме i-го и тестируем на i-м фолде. В результате мы получаем K значений метрики качества и усредняем все значения. Полученное число и является оценкой качества алгоритма. Далее выбранный алгоритм мы обучаем на всех данных, получая финальную модель, которая будет применяться по назначению.

Кросс-валидация может дать неверный результат в ряде случаев: 1) когда данные при обучении и при применении по назначению статистически различаются, 2) когда обучающие примеры нельзя считать независимой и одинаково распределённой выборкой [10]. Мы предполагаем, что наши данные не подпадают под описанные случаи, поэтому мы можем применять кросс-валидацию. Мы выбрали 5-кратную кросс-валидацию с 5 фолдами.

Метрика качества

Для объёма имплантата мы выбрали метрику MAE (средняя абсолютная ошибка) как наиболее легко интерпретируемую. Если мы имеем N тестовых примеров и обозначим за y_i эталонный ответ для i-го примера и за y^i предсказание для i-го примера, то метрика MAE для всего тестового набора данных рассчитывается следующим образом:

$$MAE(y, y^i) = \sum_{i=1}^N |y_i - y^i| \quad (1)$$

Для профиля мы выбрали метрику accuracy:

$$Accuracy(y, y^i) = \sum_{i=1}^N (y_i = y^i)$$

Сравниваемые алгоритмы

Мы сравнивали ряд алгоритмов из scikit-learn [11] (метод наименьших квадратов, Ridge-регрессию, Lasso-регрессию, SVR, Random Forest, Gradient Boosting) и библиотеку CatBoost [12].

put data and generating an output based on identifying learned patterns in data [7].

Since the input and output parameters can be represented as tables, we used tabular data as an input format for the machine learning model. The model was trained using a set of examples with correct answers. The model weights are adjusted to reduce the discrepancy between the correct answers and the model estimate, and model accuracy was evaluated using a separate test sample of data that was not used during the training process. In the study, the participants' body measurements and their preferences were used as input data. The output data for the ML model included the volume of the implant in cubic centimeters and the profile (low, moderate, high, ultra-high).

Algorithm selection

The K-fold cross-validation procedure is a standard method for evaluating and comparing the learning algorithms performance of a machine-learning algorithm on a limited data sample [9]. In the K-fold cross-validation, the dataset is randomly partitioned into K subsets of equal size. Each partition is called a "fold," so when there are K parts, they are called K-folds. One fold is used as a validation set, while the remaining K-1 folds are used as the training set. This process is repeated K times, with each fold used as a validation set and the others as the training set. The final accuracy of the model is computed by taking the mean accuracy of the K-model validation data.

It is important to note that cross-validation may yield inaccurate results in specific scenarios, for instance, when the data used for training differs significantly from the data used for the actual application or when the training examples are not representative of the overall sample [10]. However, given that our data does not align with these scenarios, we have used 5-fold cross-validation for our analysis.

Evaluation metrics

We opted for the mean absolute error (MAE) metric when assessing implant volume as it is conceptually simple and easy to interpret. MAE metric for the entire test dataset is calculated as follows:

$$MAE(y, y^i) = \sum_{i=1}^N |y_i - y^i| \quad (1)$$

where:

N is the total number of examples

y_i represents the actual answer for the i-th example

y^i represents the model-predicted answer for the i-th example

For the implant profile, we chose the accuracy metric:

$$Accuracy(y, y^i) = \sum_{i=1}^N (y_i = y^i)$$

ML algorithms

The study compared different algorithms in the Scikit-learn ML library [11]. The algorithms included ordinary least squares, Ridge regression, Lasso regression, support vector regression (SVR), Random Forest, Gradient Boosting, and the CatBoost library [12].

Model selection for the implant volume prediction

After comparing different models to predict implant volume, we found that to minimize MAE during 5-fold cross-validation, only three of the nine features should be retained: breast width, body weight, and wishes. Among the linear models tested,

Подбор модели на задаче предсказания объёма

По результатам сравнения моделей для предсказания объёма мы обнаружили, что для минимизации ошибки MAE на 5-кратной 5-fold кросс-валидации можно оставить только три признака из девяти: ширина основания молочной железы (breast width), масса тела (weight), пожелания (wishes). При этом наилучшего качества достигает линейная регрессия: 29,2 MAE, другие линейные модели (метод наименьших квадратов, Lasso-регрессия и линейный SVM) достигают практически такой же метрики качества. Ранжирование качества в пределах линейных моделей несущественно (не более 0,5 MAE среди топ-10 моделей). Все более сложные алгоритмы среди протестированных дают более низкое качество, например, наилучшая модель CatBoost дает 29,8 MAE.

Для линейных моделей мы использовали нормализацию входных признаков с помощью StandardScaler. Все признаки являются количественными, и только признак wishes является порядковым со значениями B, C, D. Перед нормализацией мы кодировали их в числа следующим образом: B=0, C=1, D=2. StandardScaler выбирает для каждого i-го признака коэффициенты u_i и s_i , а линейная модель имеет для каждого i-го признака обучаемый вес w_i и общий коэффициент C. Общее количество признаков после отбора обозначим за K.

Общая формула, объединяющая StandardScaler и линейную модель, выглядит следующим образом:

$$\hat{y} = C + \sum_{i=1}^K \omega_i \frac{x_i - u_i}{s_i}$$

Данная формула тоже является линейной, поэтому её можно переписать в следующем виде:

$$\hat{y} = C^* + \sum_{i=1}^K \omega_i^* x_i$$

где

$$\hat{y} = C + \sum_{i=1}^K \frac{\omega_i u_i}{s_i} \quad \omega_i^* = \frac{\omega_i u_i}{s_i}$$

Мы могли бы продолжить перебор алгоритмов и их гиперпараметров, в том числе с помощью алгоритмов подбора гиперпараметров, таких как Optuna [13], а также использовать ансамблирование. Однако мы решили отказаться от этого, потому что все протестированные алгоритмы, кроме самых неудачных, дают примерно одинаковое качество, следовательно представляется маловероятным, что найдётся алгоритм или ансамбль с существенно более высоким качеством.

Незначительные же вариации качества предсказания (менее 1 см³ усреднённой ошибки при определении объёма) несущественны по ряду причин:

1. Несущественны с врачебной точки зрения, в сравнении с погрешностью определения объёма имплантата врачом в тестовых выборках.
2. Лежат в пределах погрешности с учётом небольшого размера датасета.
3. При применении модели по назначению вероятно возникновение так называемого сдвига в распределении данных [13], при котором изменения в распределении параметров пациентов могут повлечь изменения в ранжировании моделей по качеству, что создаёт дополнительный источник неопределённости.

linear regression provided the best quality with a MAE of 29.2. The other linear models, including the least squares method, Lasso regression, and linear SVM, achieved similar quality metrics. The quality ranking within the linear models was insignificant, with the top 10 models differing by no more than 0.5 MAE. After evaluating various algorithms, it was observed that the more complex models generally exhibited lower quality. Specifically, the CatBoost model was considered the best among those tested, yielding a mean absolute error (MAE) of 29.8.

When working with linear models, we utilized feature normalization with the StandardScaler. The dataset comprised entirely of quantitative features (variables) except for the "wishes" feature, which consisted of ordinal qualitative features (variables) with the values B, C, and D. Before normalization, we encoded these values as follows: B=0, C=1, D=2. In the process, the StandardScaler selected coefficients (u_i and s_i) for each feature, whereas the linear model utilized training weight (w_i) and a total coefficient (C) for each feature. We represented the number of features kept after the selection process as K.

The formula that merges the StandardScaler and the linear model can be expressed as follows:

$$\hat{y} = C + \sum_{i=1}^K \omega_i \frac{x_i - u_i}{s_i}$$

The formula is also linear, which means it can be expressed as follows:

$$\hat{y} = C^* + \sum_{i=1}^K \omega_i^* x_i$$

where:

$$\hat{y} = C + \sum_{i=1}^K \frac{\omega_i u_i}{s_i} \quad \omega_i^* = \frac{\omega_i u_i}{s_i}$$

We considered trying various algorithms and their hyperparameters and using tools like Optuna [13] and ensemble methods. However, we ultimately chose not to do this because most of the algorithms we tested performed similarly in quality. Therefore, it is unlikely that we would find a significantly better algorithm or ensemble. Slight differences in prediction quality, such as less than 1 cm³ average error in determining implant volume, may not be very significant for several reasons:

1. It is insignificant in clinical significance compared to a medical error in determining the volume of test samples.
2. The differences are within the reference accuracy, considering the limited dataset size.
3. When using a model for its intended purpose, changes in patient parameter distribution may cause shifts in model quality rankings, creating additional uncertainty [13].

It is advisable to select the simplest and most easily interpreted model, such as a linear model, given the similar quality of the algorithms.

Dependence of quality on the amount of training data

There is no established method for evaluating the relation-

Кроме того, при приблизительно равном качестве лучше выбрать наиболее простую и легко интерпретируемую модель, и в нашем случае – это линейная модель.

Зависимость качества от количества обучающих данных

На практике нет устоявшегося способа оценки зависимости качества от количества данных для малых выборок. Мы решили использовать следующий метод: имея в сумме 265 примеров, для каждого N от 3 до 262 мы берем N примеров в качестве обучающих, а остальные $265-N$ примеров в качестве тестовых. Мы обучаем линейную модель, использующую все 9 признаков, на обучающих примерах и подсчитываем метрику MAE на тестовых примерах. Полученную метрику мы отмечаем точкой на графике: значение N откладываем по горизонтальной оси, а значение MAE по вертикальной оси. Полный проход N от 3 до 262 мы повторяем 10 раз.

Полученный график показан на рис. 1.

Слева направо увеличивается размер обучающей выборки, но уменьшается размер тестовой выборки. У левой границы обучающая выборка очень маленькая, и её не хватает для качественного обучения, поэтому значения test MAE очень высоки. У правой границы обучающая выборка относительно большая (>200 примеров), но тестовая выборка очень маленькая, поэтому test MAE оценивается с очень большой погрешностью, что вызывает вертикальный разброс значений на графике. В целом по графику можно видеть, что качество модели растёт незначительно с ростом N после значения $N=100$. На 100 и 200 примерах модель даёт примерно одинаковое test MAE. Мы можем прикинуть качество модели при 500-1000 обучающих примеров, проэкстраполировав график вправо. Судя по всему, качество от этого вырастет лишь незначительно.

Подбор модели на задаче предсказания профиля имплантата

Профиль имплантата является категориальным признаком со значениями low, middle, high, extra high. В данном случае подходящей была бы модель классификации с 4 классами, однако такая модель имеет в 4 раза больше признаков, что повышает степень переобучения. Поскольку классы упорядочены, мы решили использовать модель регрессии, кодируя классы числами: low=0, middle=1, high=2, extra high=3. Кроме того, такую модель проще представить в виде формулы, чем модель классификации, поскольку она имеет меньше коэффициентов. Для расчёта метрики ассигасы мы округляем предсказание до целого числа от 0 до 3 и, исходя из числа, определяем класс (low, middle, high, extra high). Однако мы также можем использовать метрику MAE (то есть модуль разности между предсказанным числом и числовым кодом класса).

Однако по обоим метрикам нам не удалось превзойти точность константного предсказания, то есть точность модели, которая предсказывает всегда профиль middle, независимо от используемых признаков. Такая модель достигает точности 64%, поскольку в нашей выборке для 64% пациенток врачом выбран профиль middle.

Из этого можно заключить, что для автоматического предсказания профиля, вероятно, требуются другие данные, помимо имеющихся у нас в табличном виде.

Описание и интерпретация модели

На наших данных наибольшее качество дала модель линейной регрессии. Линейная модель легко интерпретируема, по-

ship between data quality and quantity for limited sample sizes. Our method involves using 265 examples and carrying out the following steps: for each N value from 3 to 262, we use N examples for training and the remaining $265-N$ examples for testing. We train a linear model with nine features using the training examples and then calculate the MAE metric on the test examples. Subsequently, we plot the N value on the horizontal axis and the MAE value on the vertical axis to generate a scatterplot. This procedure is repeated ten times for each N value from 3 to 262, and the resulting scatterplot is displayed (Fig. 1).

The scatterplot demonstrates that as the size of the training set increases from left to right, the size of the test set decreases. When the training sample is limited (on the left side), it is not sufficient for high-quality training, resulting in very high values of MAE. On the other hand, when the training set is relatively large (more than 200 examples) and the test set is minimal, the test MAE is estimated with a significant error, leading to a vertical scatter of values in the graph. The graph shows a slight increase in model quality with an increase in N (number of examples) after $N=100$. For 100 and 200 examples, the model yields approximately the same test MAE. By extrapolating the graph to the right, we can estimate that the quality of the model with 500-1000 training examples will only increase slightly.

Model selection for implant profile prediction

The implant profile is a categorical feature with four values: low, moderate, high, or ultra-high. Initially, using a classification model with four classes seemed appropriate, but this would have led to overfitting. Since the classes are ordered, we used a regression model instead, representing the classes with numbers: low=0, moderate=1, high=2, ultra-high=3. This model is more straightforward to express as a formula and has fewer coefficients than a classification model. To calculate accuracy, we round the prediction to an integer from 0 to 3 and determine the class (low, moderate, high, ultra-high) based on the number. Alternatively, we can use the Mean Absolute Error (MAE) metric.

However, for both metrics, we were unable to exceed the accuracy of a constant model, which always predicts the moderate profile and achieves an accuracy of 64%, as the doctor selected the moderate profile for 64% of patients in our sample.

This suggests that automatic profile prediction requires more data than in tabular form.




Рис. 1 Зависимость качества от количества обучающих данных
Fig. 1 Scatterplot showing the relationship between quality and the amount of training data

сколькo представляет собой числовой коэффициент для каждого признака и одно дополнительное слагаемое.

В нашем случае наилучшее качество даёт использование трёх признаков: breast width, weight, wishes. Эта модель выражается в виде следующей формулы (усреднённые коэффициенты по 5-кратной 5-fold кросс-валидации):

Volume = 34.06 * breast width + 2.84 * weight + 26.81 * wishes – 253

Напомним, что breast width мы измеряем в сантиметрах, weight в килограммах, а wishes преобразуются в число следующим образом: B=0, C=1, D=2.

Для полноты картины мы также обучили модели, использующие 0, 1 или 2 признака из перечисленных выше, и ниже приводим их качество (табл.)

Как видно из табл., константное предсказание (строка 2, объём 325 для всех пациентов) даёт MAE=44,12, а использование лишь одного признака weight (строка 4) по формуле $5,7 * \text{weight} + 10$ даёт MAE=33,9, что не слишком сильно отличается от наилучшего результата (строка 1).

Все полученные предсказания покажем на графике (рис. 2). Допустимой ошибкой считается 50 см³, поэтому отметим голубым цветом область, где предсказание и данный врачом ответ отличаются менее чем на 50.

Для 18,5% примеров модель ошибается сильнее, чем на 50 см³. Наибольшее расхождение предсказаний модели и выбора врача возникало в случаях, когда у пациенток с низкой массой тела (значение weight) определялось широкое основание молочной железы (значение breast width). Мы полагаем, что совпадение предсказания объёма имплантата моделью и выбора врача в 81,5% случаев является допустимым для применения модели на практике.

РЕЗУЛЬТАТЫ И ИХ ОБСУЖДЕНИЕ

Экспертная оценка модели

Экспертный анализ модели был проведён пластическим хирургом. В ходе оценки было выявлено, что в 18,5% случаев допущенные моделью ошибки превышали 50 см³. Однако следует отметить, что совпадение прогнозов объёма имплантата, сделанных моделью, с выбором хирурга составило 81,5%, что можно считать допустимым показателем для практического применения модели. Был проведён детальный анализ случаев с наибольшим расхождением между прогнозами модели и выбором хирурга, и было выявлено, что наибольшие расхождения наблюдаются у пациенток с низким показателем массы тела (значение weight), где определяется широкое основание молочной железы (значение breast width). Данные выводы могут быть использованы для дальнейшего усовершенствования модели и улучшения точности её прогнозов.

Проблемы модели на сегодняшний день заключаются в том, что она использует только признаки, описанные в первом разделе. Возможно, что, добавив признаки, мы могли бы повысить качество, как в смысле близости к предсказаниям врача, так и в смысле удовлетворённости пациенток. Однако увеличение числа используемых признаков неизбежно бы повлекло за собой усложнение формулы, уменьшая её применимость на практике. Проблемой также являются большие ошибки модели в некоторых редких случаях. Нельзя допустить, чтобы пациентка пострадала из-за ошибки модели. Поэтому модель можно применять только при соблюдении следующих условий: 1) значения признаков лежат в типичных диапазонах (отсутствие избыточной массы тела, средний рост, ширина основания молочной железы 11,5-12,5 см,

Description and interpretation of the model

Our data analysis shows that the linear regression model produced the best-quality results. This model is advantageous because it assigns a numerical coefficient to each attribute and an additional intercept, which makes it simple and easy to interpret.

In our case, the best quality is achieved using three features: breast width, weight, and wishes. The model is represented by the following formula, where coefficients have been averaged over 5-fold cross-validation:

Volume = 34.06 * breast width + 2.84 * weight + 26.81 * wishes – 253.

It is important to note that breast width is measured in centimeters, weight in kilograms, and wishes are converted into numerical values, with B=0, C=1, and D=2.

To provide a comprehensive overview, we also developed models using 0, 1, or 2 of the features above, and their respective quality is presented in the Table below.

The Table indicates a consistent prediction (line 2, volume 325 for all patients), resulting in a MAE of 44.12. By utilizing only one weight attribute (line 4) based on the formula $5.7 * \text{weight} + 10$, we achieve a MAE of 33.9, which is not significantly different from the best result (line 1).

We present all the received predictions on the scatterplot (Fig. 2). An acceptable error is 50 cm³, so we will highlight the area where the prediction and the doctor's decision differ by less than 50 in blue.

In 18.5% of cases, the model's predictions were more than 50 cm³ inaccurate. The most significant differences between the model's predictions and the doctor's choices were seen in cases where patients with low body weight had a broad mammary gland base. We consider the model's prediction of implant volume to agree with the doctor's selection in 81.5% of cases, which we find acceptable for practical use.

RESULTS AND DISCUSSION

Expert evaluation of the model

A comprehensive analysis of the model found that in 18.5% of cases, the model's errors exceeded 50 cm³. However, it is essential to note that there was an 81.5% agreement between the model's predictions for implant volume and the surgeon's choices, which is considered acceptable for practical use. An in-depth analysis of cases with significant differences between the model's predictions and the surgeon's choices revealed that the most considerable discrepancies occurred in patients with low body weight and a wide breast width.

Currently, the model only uses the features described in the first section, and adding more features could potentially improve the quality of predictions and patient satisfaction. However, increasing the number of features would complicate the formula and reduce its practical applicability. In some rare cases, the model's significant errors pose a challenge. To address these issues, the model should only be used under specific conditions: 1) the patient's characteristics fall within typical ranges (normal body weight, average height, mammary gland base width of 11.5-12.5 cm, and no request for large-volume mammary glands), and 2) the patient meets the same conditions as those in the training set. These findings could be used to enhance the model and improve the accuracy of its predictions.

Таблица Интерпретация модели

Table Model interpretation

Коэф. при breast width Breast width Coeff.	Коэф. при Weight Weight Coeff.	Коэф. при Wishes Wishes Coeff.	Свободный коэф. Intercept	MAE на 5-кратной 5-fold кросс-валидации MAE on 5-fold 5- fold cross-validation
34.06	2.84	26.81	-253	29.24 (best)
не использ. Not used	не использ. Not used	не использ. Not used	325	44.12
59.47	не использ. Not used	не использ. Not used	-385	34.50
не использ. Not used	5.70	не использ. Not used	10	33.90
не использ. Not used	не использ. Not used	51.78	297	39.03
38.53	3.52	не использ. Not used	-330	31.32
48.83	не использ. Not used	33.55	-276	31.56
не использ. Not used	4,58	32.05	54	32.17

отсутствие запроса на избыточный размер молочных желёз), 2) пациентка удовлетворяет тем же условиям, которым удовлетворяли пациентки в обучающей выборке.

ЗАКЛЮЧЕНИЕ

Исследование, направленное на улучшение прогнозирования результатов операций АМ с применением технологий ИИ, открывает новые горизонты в области пластической хирургии. Разработанная модель, хоть и имеет некоторые ограничения на сегодняшний день, демонстрирует большую перспективу для дальнейшего совершенствования.

Модель на данном этапе её развития не является абсолютным показателем стандарта, она не учитывает всех анатомических особенностей женщин. Однако при её совершенствовании путём добавления значимых и исключения незначимых признаков, возможно уменьшить ошибку модели, что упрощает процесс подбор имплантата, учитывая большое количество и вариабельность предлагаемых разными авторами критериев подбора. Необходимо увеличить выборку и добавить пациенток других хирургов, так как выбор имплантата в каждом случае может различаться у разных врачей. На данном этапе своего развития модель могла бы служить подспорьем для начинающих хирургов, являясь своего рода «вторым мнением».

Перспективным направлением развития данной модели является дальнейшее уменьшение ошибки хирурга при выборе имплантата, а также оптимизация эстетического результата. Это может быть достигнуто путём дополнительного анализа анатомических особенностей пациенток и интеграции полученной информации в модель. Многообещающим является разработка и внедрение системы компьютерного зрения, позволяющей пациенткам в режиме реального времени оценить предполагаемый объём и размер имплантата. Это не только даст пациентке больше контроля и понимания процесса, но и облегчит работу хирурга, предоставляя дополнительные инструменты для визуализации и планирования. Расширение выборки данных путём включения информации от разных хирургов может привести к более универсальной и надёжной модели. Различия в выборе имплантатов

CONCLUSION

The study focuses on improving the prediction of breast augmentation surgical outcomes using AI technology, which could lead to advancements in plastic surgery. The developed model currently has some limitations but shows excellent potential for further improvement.

The proposed model at this stage does not represent the reference standard as it does not consider all anatomical variations in women. However, refining the model by including significant features and excluding insignificant ones may help reduce the model's error. Additionally, the model refining could streamline the implant selection process, considering the comprehensive selection criteria proposed by various authors. Increasing the sample size and including patients from multiple surgeons is vital, as the selection of implants may differ among different doctors.




Рис. 2 Анализ предсказаний модели

Fig. 2 Scatterplot of the surgeon-selected implant versus model-predicted implant volume

между врачами могут быть учтены и использованы для дальнейшего обучения модели. Разработанная модель и её будущие интеграции способны улучшить не только точность выбора имплантата, но и уровень удовлетворённости пациенток, обеспечивая им больше информации и контроля над процессом предоперационного планирования.

Currently, the model could serve as a valuable resource for novice surgeons, offering a "second opinion".

An area with great potential for the model's development is to minimize further surgeons' errors in choosing an implant and improve the aesthetic results by further analyzing patients' anatomical parameters and integrating this information into the model. Developing and implementing a computer vision system allowing patients to assess the expected volume and size of the implant in real time is also promising. This gives the patient more control and understanding of the process and makes the surgeon's job easier by providing additional visualization and planning tools. Expanding the data sample to include information from different surgeons might lead to a more broadly applicable and reliable model. Differences in implant selection among physicians could be incorporated into further model training. The developed model and its future integrations can enhance the accuracy of implant selection and patient satisfaction by providing them with more information and control over the preoperative planning process.

ЛИТЕРАТУРА

- Hillard C, Fowler JD, Barta R, Cunningham B. Silicone breast implant rupture: A review. *Gland Surg.* 2017;6(2):163-8. <https://doi.org/10.21037/gf.2016.09.12>
- Adams WP, Mckee D. Matching the implant to the breast. *Plast Reconstr Surg.* 2016;138(5):987-94. <https://doi.org/10.1097/prs.0000000000002623>
- Charles-de-Sá L, de Aguiar Valladão T, Vieira DML, Aboudib JH. Anthropometric aspects in the breast augmentation. *Aesthetic Plast Surg.* 2020;44(5):1498-507. <https://doi.org/10.1007/s00266-020-01853-5>
- Hidalgo DA, Spector JA. Breast augmentation. *Plast Reconstr Surg.* 2014;133(4):567e-583e. <https://doi.org/10.1097/PRS.0000000000000033>
- Hamet P, Tremblay J. Artificial intelligence in medicine. *Metabolism.* 2017;69S:S36-S40. <https://doi.org/10.1016/j.metabol.2017.01.011>
- Сафронов ИД. Теоретические основы в модели машинного обучения. *Вестник науки.* 2023;63(6):1050-3.
- Сёмин ПО. Правовые аспекты искусственного интеллекта и смежных технологий: права на контент, созданный с помощью машинного обучения. *Журнал Суда по интеллектуальным правам.* 2022;2:21-32.
- Murphy DC, Saleh DB. Artificial Intelligence in plastic surgery: What is it? Where are we now? What is on the horizon? *Ann R Coll Surg Engl.* 2020;102(8):577-80. <https://doi.org/10.1308/rcsann.2020.0158>
- Bates S, Hastie T, Tibshirani R. Cross-validation: what does it estimate and how well does it do it? *Journal of the American Statistical Association.* 2023. Available from: <https://www.tandfonline.com/doi/full/10.1080/01621459.2023.2197686> [Accessed 5th March 2024]. <https://doi.org/10.1080/01621459.2023.2197686>
- Rabinowicz A, Rosset S. Tree-based models for correlated data. *The Journal of Machine Learning Research.* 2022;23(258):1-31. <https://doi.org/10.48550/arXiv.2102.08114>
- Pedregosa F, Varoquaux G, Gramfort A, Michel V, Thirion B, Grisel, et al. Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research.* 2011;12:2825-30. <https://doi.org/10.48550/arXiv.1201.0490>
- Prokhorenkova LO, Prałat P, Raigorodskii A. Modularity in several random graph models. *Electronic Notes in Discrete Mathematics.* 2017;61:947-53. <https://doi.org/10.1016/j.endm.2017.07.058>
- Candela JQ, Sugiyama M, Schwaighofer A, Lawrence N. *Dataset shift in machine learning.* USA: The MIT Press; 2009. 229 p. <https://doi.org/10.7551/MITPRESS/9780262170055.001.0001>

REFERENCES

- Hillard C, Fowler JD, Barta R, Cunningham B. Silicone breast implant rupture: A review. *Gland Surg.* 2017;6(2):163-8. <https://doi.org/10.21037/gf.2016.09.12>
- Adams WP, Mckee D. Matching the implant to the breast. *Plast Reconstr Surg.* 2016;138(5):987-94. <https://doi.org/10.1097/prs.0000000000002623>
- Charles-de-Sá L, de Aguiar Valladão T, Vieira DML, Aboudib JH. Anthropometric aspects in the breast augmentation. *Aesthetic Plast Surg.* 2020;44(5):1498-507. <https://doi.org/10.1007/s00266-020-01853-5>
- Hidalgo DA, Spector JA. Breast augmentation. *Plast Reconstr Surg.* 2014;133(4):567e-583e. <https://doi.org/10.1097/PRS.0000000000000033>
- Hamet P, Tremblay J. Artificial intelligence in medicine. *Metabolism.* 2017;69S:S36-S40. <https://doi.org/10.1016/j.metabol.2017.01.011>
- Safronov ID. Teoreticheskie osnovy v modeli mashinnogo obucheniya [Theoretical basics in machine learning model]. *Vestnik nauki.* 2023;63(6):1050-3.
- Syomin PO. Pravovye aspekty iskusstvennogo intellekta i smezhnykh tehnologiy: prava na kontent, sozdannyi s pomoshch'yu mashinnogo obucheniya [Legal aspects of artificial intelligence and related technologies: Rights to content created using machine learning.]. *Zhurnal Suda po intellektual'nym pravam.* 2022;2(36):21-32.
- Murphy DC, Saleh DB. Artificial Intelligence in plastic surgery: What is it? Where are we now? What is on the horizon? *Ann R Coll Surg Engl.* 2020;102(8):577-80. <https://doi.org/10.1308/rcsann.2020.0158>
- Bates S, Hastie T, Tibshirani R. Cross-validation: what does it estimate and how well does it do it? *Journal of the American Statistical Association.* 2023. Available from: <https://www.tandfonline.com/doi/full/10.1080/01621459.2023.2197686> [Accessed 5th March 2024]. <https://doi.org/10.1080/01621459.2023.2197686>
- Rabinowicz A, Rosset S. Tree-based models for correlated data. *The Journal of Machine Learning Research.* 2022;23(258):1-31. <https://doi.org/10.48550/arXiv.2102.08114>
- Pedregosa F, Varoquaux G, Gramfort A, Michel V, Thirion B, Grisel, et al. Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research.* 2011;12:2825-30. <https://doi.org/10.48550/arXiv.1201.0490>
- Prokhorenkova LO, Prałat P, Raigorodskii A. Modularity in several random graph models. *Electronic Notes in Discrete Mathematics.* 2017;61:947-53. <https://doi.org/10.1016/j.endm.2017.07.058>
- Candela JQ, Sugiyama M, Schwaighofer A, Lawrence N. *Dataset shift in machine learning.* USA: The MIT Press; 2009. 229 p. <https://doi.org/10.7551/MITPRESS/9780262170055.001.0001>

И СВЕДЕНИЯ ОБ АВТОРАХ

Атаманов Дмитрий Константинович, врач-пластический хирург, ООО Лечебно-диагностический центр «АвисМед»
 ORCID ID: 0000-0001-8878-1398
 E-mail: dmi.atamanov@yandex.ru

Сапакова Амина Камзаевна, младший научный сотрудник, Медицинский научно-образовательный центр Московского государственного университета им. М.В. Ломоносова
 ORCID ID: 0009-0000-1094-8725
 E-mail: dr.amina.sapakova@mail.com

Егоров Вадим Анатольевич, доктор медицинских наук, заведующий отделением пластической хирургии, ООО Лечебно-диагностический центр «АвисМед»
 ORCID ID: 0009-0009-6275-5701
 E-mail: vadime899@mail.ru

Седухин Олег Андреевич, ведущий специалист, Huawei Russian Research Institute
 E-mail: sedol1339@gmail.com

Информация об источнике поддержки в виде грантов, оборудования, лекарственных препаратов

Финансовой поддержки со стороны компаний-производителей лекарственных препаратов и медицинского оборудования авторы не получали

Конфликт интересов: отсутствует

✉ АДРЕС ДЛЯ КОРРЕСПОНДЕНЦИИ:

Атаманов Дмитрий Константинович
 врач-пластический хирург, ООО Лечебно-диагностический центр «АвисМед»

630005, Российская Федерация, г. Новосибирск, ул. Красный проспект, 86
 Тел.: +7 (913) 2004138
 E-mail: dmi.atamanov@yandex.ru

И AUTHORS' INFORMATION

Atamanov Dmitriy Konstantinovich, Plastic Surgeon, «AvisMed» Clinic

ORCID ID: 0000-0001-8878-1398
 E-mail: dmi.atamanov@yandex.ru

Sapakova Amina Kamzaevna, Junior Researcher, Medical Research and Educational Center of Lomonosov Moscow State University

ORCID ID: 0009-0000-1094-8725
 E-mail: dr.amina.sapakova@mail.com

Egorov Vadim Anatolievich, Doctor of Medical Sciences, Plastic Surgeon, Head of Plastic Surgery Department, «AvisMed» Clinic

ORCID ID: 0009-0009-6275-5701
 E-mail: vadime899@mail.ru

Sedukhin Oleg Andreevich, Leading Expert, Huawei Russian Research Institute

E-mail: sedol1339@gmail.com

Information about support in the form of grants, equipment, medications

The authors did not receive financial support from manufacturers of medicines and medical equipment

Conflicts of interest: The authors have no conflicts of interest

✉ ADDRESS FOR CORRESPONDENCE:

Atamanov Dmitriy Konstantinovich
 Plastic Surgeon, «AvisMed» Clinic

630005, Russian Federation, Novosibirsk, Krasnyy prospekt str., 86
 Tel.: +7 (913) 2004138
 E-mail: dmi.atamanov@yandex.ru

ВКЛАД АВТОРОВ

Разработка концепции и дизайн исследования: АДК, ЕВА
 Сбор материала: САК
 Статистическая обработка данных: САК, СОА
 Анализ полученных данных: АДК, СОА
 Подготовка текста: САК, СОА
 Редактирование: АДК, ЕВА
 Общая ответственность: ЕВА

AUTHOR CONTRIBUTIONS

Conception and design: ADK, EVA
 Data collection: SAK
 Statistical analysis: SAK, SOA
 Analysis and interpretation: ADK, SOA
 Writing the article: SAK, SOA
 Critical revision of the article: ADK, EVA
 Overall responsibility: EVA

Поступила 16.02.24
Принята в печать 29.08.24

Submitted 16.02.24
Accepted 29.08.24