

К. С. Дёмин, И. В. Гермашев

ПОСЛЕДОВАТЕЛЬНЫЙ ОТБОР ПРИЗНАКОВ ДЛЯ КЛАССИФИКАЦИИ ТЕМПЕРАТУРНЫХ АНОМАЛИЙ РАКА МОЛОЧНОЙ ЖЕЛЕЗЫ НА ДАННЫХ РАДИОТЕРМОМЕТРИИ

Ключевые слова: машинное обучение, логистическая регрессия, искусственный интеллект, радиотермометрия, классификация.

Исследовано применение методов машинного обучения при диагностике рака молочной железы. Проводится анализ формирования признакового пространства для классификации температурных аномалий, вызванных раком молочной железы. Для анализа использовался метод формирования признакового пространства, основанный на методе добавления признаков Sequential Floating Forward Selection (SFFB). В качестве набора данных использовались результаты обследования молочных желез, проведённых методом микроволновой радиотермометрии. Для объективной оценки обобщающей способности моделей выборка разделена на обучающую и тестовую части. На тестовых данных, не участвовавших в процессе обучения и отбора признаков, проводилась итоговая верификация результатов. Анализ эффективности метода SFFB проводился с использованием различных вариаций критериев отбора, что позволило многосторонне оценить его гибкость. В частности, оптимизация выполнялась по F1-показателю, а также по комбинированной метрике, агрегирующей ключевые для системы искусственного интеллекта показатели: точность и полнота. Применение алгоритма SFFB позволило сократить размерность признакового пространства без существенного ущерба для качества классификации. Исходный набор, из 70 признаков, сокращен до 14 наиболее информативных и статистически значимых переменных. Такой результат подтверждает эффективность метода SFFB при сокращении размерности и его способность устранять избыточные признаки. Полученные результаты демонстрируют, что даже при значительном уменьшении размерности можно сохранить почти исходный уровень точности классификации, обеспечивая более быстрые вычисления. Кроме того, модели с меньшим количеством признаков обладают гораздо лучшей интерпретируемостью, что является критически важным фактором для принятия обоснованных клинических решений в области медицинской диагностики, где понимание логики классификации часто не менее ценно, чем результат.

K. S. Demin, I. V. Germashev

SEQUENTIAL SELECTION OF SIGNS FOR THE CLASSIFICATION OF TEMPERATURE ANOMALIES OF BREAST CANCER BASED ON RADIOTHERMOMETRY DATA

Keywords: machine learning, logistic regression, artificial intelligence, radiothermometry, classification.

The application of machine learning methods in the diagnosis of breast cancer is investigated. The analysis of the formation of the feature space for the classification of temperature anomalies caused by breast cancer is carried out. The method of feature space formation based on the Sequential Floating Forward Selection (SFFB) feature addition method was used for the analysis. The results of breast examinations performed by microwave radiothermometry were used as a data set. For an objective assessment of the generalizing ability of the models, the sample is divided into training and test parts. The final verification of the results was carried out on the test data that was not involved in the learning and selection process. The effectiveness of the SFFB method was analyzed using various variations of the selection criteria, which allowed a comprehensive assessment of its flexibility. Optimization was performed using the F1 indicator, as well as a combined metric that aggregates key indicators for the artificial intelligence system: accuracy and completeness. The use of the SFFB algorithm made it possible to reduce the dimension of the feature space without significant damage to the classification quality. The initial set of 70 features has been reduced to 14 of the most informative and statistically significant variables. This result confirms the effectiveness of the SFFB method in reducing dimensionality and its ability to eliminate redundant features. The results obtained demonstrate that even with a significant reduction in dimension, it is possible to maintain almost the initial level of classification accuracy, providing faster calculations. In addition, models with fewer features have much better interpretability, which is a critical factor for making informed clinical decisions in the field of medical diagnostics, where understanding the logic of classification is often no less valuable than the result.

Введение

Ключевым этапом построения моделей в машинном обучении является формирование признакового пространства. От адекватности и полноты этого пространства зависят последующие этапы анализа и итоговое качество модели. Эта проблема носит общий характер в разных прикладных областях: от оптимизации транспортных потоков и прогнозирования свойств химических соединений до решения задач медицинской диагностики.

В контексте медицинской диагностики, где данные характеризуются высокой вариабельностью, шумом и сложной структурой, задача формирования признаков становится особенно значимой. Правильно сконструированные признаки позволяют не только повысить точность диагностических алгоритмов, но и выявить новые, клинически значимые переменные. Современные методы машинного обучения и анализа данных имеют всё более значимую роль для обследований пациентов [1-4]. Качество моделей машинного обучения зависит от того, какие признаки (клинические, лабора-

торные, морфологические, радиологические) используются при обучении [5]. Избыточные или коррелированные признаки снижают точность алгоритмов, увеличивают время обработки данных и усложняют интерпретацию результатов. При решении задач с применением методов машинного обучения важной задачей является формирование признакового пространства. Поэтому оптимизация признакового пространства становится ключевым шагом для построения надёжных и простых в использовании диагностических систем. Методы машинного обучения позволяют ускорить интерпретацию медицинских изображений и клинических показателей, обеспечивая качественную поддержку врачебных решений даже при высокой загрузке медицинских учреждений. Такие интерпретации могут носить только предварительный характер и давать дополнительную информацию врачам либо применяться в массовых обследованиях при диспансеризации для выявления группы риска по различным заболеваниям.

В медицинской диагностике важна не только высокая точность, но и возможность работать в условиях ограниченных ресурсов, включая время, технологические мощности и квалифицированный персонал. В некоторых регионах наблюдается дефицит медицинских кадров, из-за этого растёт нагрузка на имеющийся персонал [6-8]. Также, некоторые виды диагностики, такие как маммография имеет доказанную эффективность, но обладает низкой точностью для ряда групп пациентов, например, до 62÷68 % у женщин с плотной тканью молочной железы [9], а для женщин младше 40 лет вообще не применяется. При этом существуют и другие методы, такие как радиотермометрия, в основе которого содержится принцип измерения температурных полей человека, который доказал эффективность при диагностике рака молочной железы [10]. При этом исследования необходимо интерпретировать врачом-специалистом, но в связи с высокой нагрузкой, необходимо ускорить этот процесс, при этом не снизив точность заключений.

Использование алгоритмов, основанных на наиболее релевантных признаках, позволяет автоматизировать часть рутинных процессов и ускорить получение выводов, снижая нагрузку на врачей. Оптимизация состава признаков обеспечивает возможность выделять наиболее значимые переменные для корректной дифференциации доброкачественных и злокачественных образований, повышая качество клинических решений.

Цель исследования заключается в оценке эффективности критериев оптимизации признакового пространства для повышения точности и скорости автоматизированной классификации температурных аномалий, характерных для рака молочной железы. Особое внимание уделяется выбору оптимальных информативных признаков, которые позволяют максимально эффективно использовать результаты медицинских исследований, снижая вычислительную нагрузку и повышая диагностическую ценность получаемых результатов.

В рамках работы демонстрируется применение современных алгоритмов оптимизации признаков, поз-

воляющих гибко корректировать набор используемых диагностических параметров и избегать локальных минимумов при поиске оптимальной комбинации признаков. В качестве такого метода выбран SFFS (Sequential Floating Forward Selection) [11], который применяется к данным радиотермометрии, полученным с использованием комплекса РТМ-01, предназначенного для регистрации температурных полей органов человека, в частности молочной железы.

Ряд заболеваний молочной железы характеризуется температурными аномалиями [12]. Так, например, доброкачественные образования, такие как локализованный фиброз, липома или грубый послеоперационный рубец характеризуются понижением температуры в нижнем отделе молочной железы. Другие заболевания, например, хронический мастит или киста с воспалением характеризуются повышением температур в аналогичном отделе молочной железы.

Определённые виды рака молочной железы характеризуются ещё более выраженным повышением температуры и метод радиотермометрии позволяет обнаруживать их и по ним определять группы риска наличия злокачественного образования [13, 14]. Конечно, с высокой долей вероятности по этому методу нельзя диагностировать рак, но он позволяет отделить здоровых от потенциальных больных, чтобы уменьшить нагрузку на врачей и проводить дополнительные обследования более точными методами только для группы риска. Поэтому необходима система, которая классифицирует такие температурные аномалии.

Описание набора данных и постановка задачи

В качестве исходной информации используются результаты обследований молочных желез, произведённых на основе комплекса РТМ-01. Данные представляют измерения молочных желез в инфракрасном, который далее называются кожные, и радиодиапазоне, который далее называются внутренние, а также данные, полученные при осмотре пациента врачом. Схема измерения показана на рисунке 1. Полученные температурные измерения преобразованы в набор признаков в работе [15]. В исходном наборе содержится 62 признака, полученных в результате математического моделирования, например, признак MG001 – это манхэттенское расстояние между векторами значений внутренних температур для правой и левой молочной железы, а MG006 – разность средних значений внутренних температур правой и левой желез. Также в исследовании [16] выявлены 8 признаков, полученных при осмотре пациента врачом, которые в определённой степени могут помочь верно классифицировать исходные данные. К таким признакам относятся:

- возраст,
- диаметр молочной железы,
- индекс массы тела,
- гормональная зависимость,
- жалобы на боли в груди,
- количество беременностей,
- количество рожденных детей,
- возраст на момент первых родов.

Именно эти 70 признаков представляют исходный набор признаков.

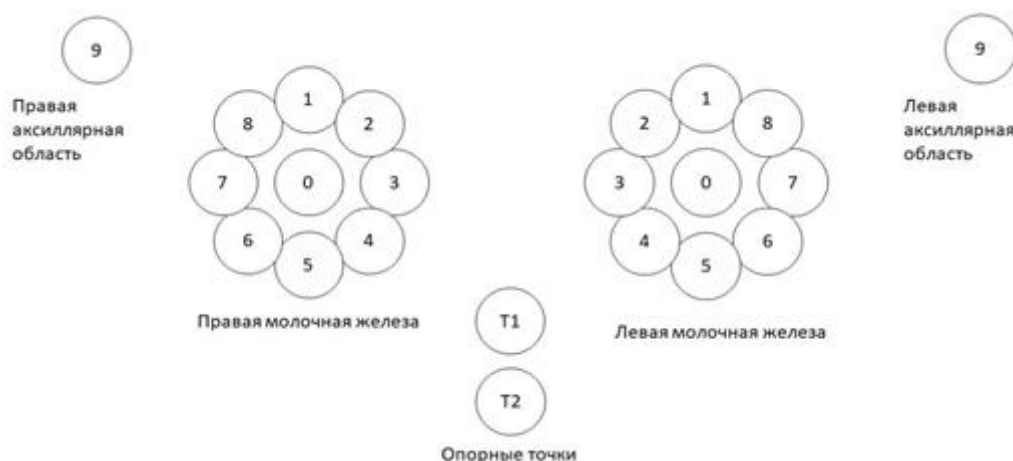


Рис. 1 – Схема измерения молочных желез методом радиотермометрии

Fig. 1 – Breast measurement scheme by radiothermometry

Кроме признаков в наборе данных имеются метки, представляющие заключение врача, который определяет конкретную молочную железу к одной из шести категорий температурных аномалий, которые представлены в таблице 1.

Таблица 1 – Описание категорий состояния молочных желез

Table 1 – Description of breast condition categories

Категория	Краткое описание
0	тепловые изменения не выявлены
1	участок понижения температуры
2	участок повышения температуры
3	высокий уровень и внутренней и кожной температур без локального очага
4	высокий уровень и внутренней и кожной температур с наличие локального очага понижения температуры
5	высокий уровень и внутренней и кожной температур с наличие локального очага повышения температуры

Как отмечено в источнике [12], присвоение первых трех категорий происходит в случаях отсутствия характерных признаков рака молочной железы. Категория № 3 предназначена для пациентов, отнесенных к группе риска. Категория № 4 присваивается при наличии подозрений на онкологическое заболевание. Наконец, категория № 5 резервируется для случаев, когда у пациентов зафиксированы температурные аномалии, однозначно указывающие на наличие острого воспаления.

Исходя из этого 6 категорий преобразованы в 2 по следующему принципу: категория 0÷2 – отсутствует или слабая тепловая аномалия, обозначим как класс 0; категория 3÷5 – выраженная тепловая аномалия,

обозначим как класс 1.

Таким образом, имеющийся предобработанный набор данных, который обозначим как $X = (x_{ij})_{i=1}^N$, где $X \in \mathbb{R}^{N \times d}$ где $N = 9310$ представляет количество наблюдений, $d = 70$ – количество признаков. Каждому $x_i = (x_{ij})_{j=1}^d$ приписана метка $y_i \in \{0, 1\}$, которая показывает номер класса, отражающей наличие температурных аномалий в молочной железе, $i = 1, \dots, N$. Далее обозначим вектор отбора признаков $s \in \{0, 1\}^d$, где 1 означает, что признак j используется для обучения. Через $x_i^{(s)}$ обозначим вектор x_i , ограниченный выбранными признаками, т.е. $x_i^{(s)} = (x_{ij})_{j \in J(s)}$, $J(s) = \{j \in \{1, \dots, d\} | s_j = 1\}$.

Далее обозначим через $I_k = \{i \in I | y_i = k\}$, где $I = \{1, \dots, N\}$, $k = 0, 1$.

Далее набор данных X разбивается на 2 выборки (обучающую X^{train} и тестовую X^{test}) так, что в каждой сохраняется исходное распределение классов, т.е. проведено разбиение $I_k = I_k^{train} \cup I_k^{test}$ случайным образом так, что $n_k^{train} \approx 0,8n_k$, где $n_k^{train} = |I_k^{train}|$, $n_k = |I_k|$, и $X^{train} = (x_i)_{i \in I^{train}}$, $X^{test} = (x_i)_{i \in I^{test}}$, где $I^{train} = \bigcup_{k=0}^1 I_k^{train}$, $I^{test} = \bigcup_{k=0}^1 I_k^{test}$, $k = 0, 1$.

В итоге получено 2 набора данных $N^{train} = \sum_{k=0}^1 n_k^{train} = 7446$, $N^{test} = N - N^{train} = 1864$. Набор данных X^{train} в дальнейшем называется основным. Тестовый набор N^{test} никак не будет участвовать в процессе оптимизации признаков, а используется только для проверки обобщающей способности модели классификации с оптимизированным набором признаков.

M – модель бинарной классификации.

Необходимо найти такой бинарный вектор s^* , который максимизирует $F1$ -меру модели M , обученной на соответствующем подмножестве признаков j , т.е. получаем следующую задачу оптимизации

$$F1(s) \rightarrow \max_{s \in \{0,1\}^d}, \quad (1)$$

где $F1$ мера вычисляется следующим образом:

$F1 = \frac{2 \times TP}{2 \times TP + FP + FN}$, где TP – число истинно положительных, FP – ложно положительных, FN – ложно отрицательных объектов.

Описание метода оптимизации

Для решения задачи используется метод оптимизации признакового пространства SFFS [11]. Схема работы алгоритма представлена на рисунке 2.

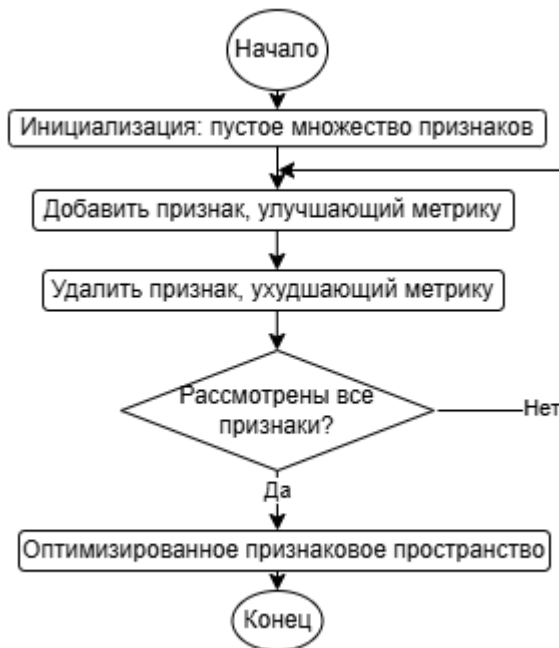


Рис. 2 – Схема работы алгоритма оптимизации признакового пространства SFFS

Fig. 2 – The scheme of the feature space optimization algorithm SFFS

Ключевой особенностью предложенного метода заключается в следующем: двунаправленный поиск – вначале добавляется лучший признак, затем проверяется, можно улучшить метрики удалением из выбранных. Алгоритм останавливается, когда добавление новых признаков не улучшает заданные метрики.

При этом метод является эвристическим, поэтому не гарантирует оптимальность решения. Может существовать несколько различных подмножеств признаков, дающих аналогичное или большее значение заданной метрики. Если, например, изменить порядок отбора признаков, то можно прийти к другому результату.

Кроме нахождения F1 меры для её максимизации вычисляются точность и полнота для оценки модели по каждому классу

Полнота вычисляется следующим образом: $Sens_i = \frac{TP_i}{TP_i + FN_i}$. Точность вычисляется следующим образом: $Spec_i = \frac{TN_i}{TN_i + FP_i}$.

В качестве классификатора использовалась логистическая регрессия, которая задавалась следующей формулой:

$$P(Y=1|X) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n)}} \quad (2)$$

где $P(Y=1|X)$ – вероятность того, что объект принадлежит классу 1, $\beta_0, \beta_1, \dots, \beta_n$ – параметры модели, значения которых определяются на этапе обучения. Чтобы определить параметры модели необходимо максимизировать функцию правдоподобия, которая

задается формулой $\ell(\beta) = \sum_{i=1}^N [y_i \ln(P(y_i|x_i)) + (1 - y_i) \ln(1 - P(y_i|x_i))]$, где N – количество примеров в обучающей выборке, $P(y_i|x_i)$ – вероятность того, что i -й объект принадлежит положительному классу.

Также использовался метод кросс-валидации для оценки качества обучения модели классификатора (2).

Более подробно итерации метода SFFS (рис. 2) заключаются в следующем.

Инициализация.

В начале полагается, что $s_j = 0, j = 1, \dots, d$.

Шаг 1.

1) На каждой итерации добавляется в модель (2) по одному признаку в порядке номеров j . Пусть на предыдущей итерации добавлен признак с номером $j-1$. Если $j-1 < d$, то полагается $t = j, T = \emptyset$ – множество номеров признаков – кандидатов на добавление, вычисляется F1-мера $F1_0$ для текущей модели (2). Иначе алгоритм завершается (рассмотрены все признаки)

2) Рассматривается признак с номером t в качестве кандидата на добавление в модель (2). Добавляется признак с номером t , который в совокупности с другими, отобранными признаками на предыдущих итерациях, используется для обучения (2). При обучении используется кросс-валидация и для каждого фолда вычисляется F1-мера. Далее вычисляется средняя F1-мера по фолдам $F1_t$. Если $F1_t > F1_0$, то полагается $T = T \cup \{t\}$.

3) Затем повторяется п. 2 для каждого $t = j + 1, \dots, d$.

4) Если $T \neq \emptyset$, то $t^* = \arg \max_{t \in T} F1_t$, полагается $s_{t^*} = 1$, иначе алгоритм завершается.

Шаг 2.

Шаг удаления запускается только со второй итерации и действует следующим образом:

1) На каждой итерации удаляется по одному признаку с номером t и вновь обучается (2)

2) Если удаление признака с номером t привело к тому, что F1-мера стала выше, чем зафиксирована на предыдущем этапе, то $s_{t^*} = 0$ и далее не участвует в шаге 1.

3) Если удаление не улучшает результат, то алгоритм возвращается к шагу 1.

Результаты работы

На первом этапе построена модель с исходным набором данных $X^{train} = (x_{ij})_{i=1}^{N=6861} \quad j=1 \dots d=70$ для получения значений метрик. Так, при полном наборе признаков модель на основе логистической регрессии показала значения: $F1 = 0.90, Sens = 0.89, Spec = 0.90$ при кросс-валидации.

При использовании оптимизатора SFFS для задачи (1) удалось сократить признаковое пространство с 70 до 22 признаков. В результате остались температурные признаки, а также 3 признака на основе данных осмотра пациента. При этом значения метрик стали немного выше, чем значения у модели с полным набором признаков: $F1 = 0.92, Sens = 0.92, Spec = 0.92$. На рисунке 3 демонстрируются показатели метрик в процессе оптимизации признакового пространства для модели оптимизатора с целевой метрикой F1.

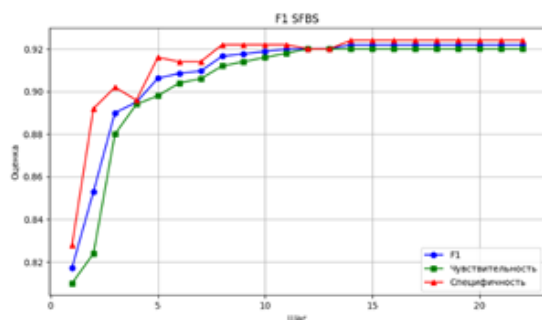


Рис. 3 – Значения метрик на разных этапах модели оптимизации SFFB с целевой метрикой F1

Fig. 3 – Metric values at different stages of the SFFB optimization model with the F1 target metric

Исходя из рисунка 3 видно, что результаты работы модели оптимизации практически не изменяются после первых 14 наиболее эффективных признаков, а оставшиеся лишь на доли процентов повышают метрики модели классификации. Поэтому принято решение использовать именно их как оптимизированный набор признаков.

Для проверки обобщающей способности полученной модели с оптимизированным набором признаков проведена оценка значений метрик на ранее отделённом тестовом наборе X^{test} , который не участвовал в процессе оптимизации признакового пространства. Модель с 14-ю оптимизированными признаками показала результаты: $F1 = 0.85$, $Sens = 0.88$, $Spec = 0.89$. Для более наглядного ознакомления с результатами представлена таблица 2, где первые две строки представляют метрики для модели, обученной на полном наборе признаков, 3 и 4 строка соответственно, метрики модели с оптимизированным признаковым пространством.

Таблица 2 – Результаты метрик для разных наборов признаков

Table 2 – Metric results for different feature sets

Набор признаков	F1	Полнота	Точность
70	0.9	0.89	0.91
70 (на тестовых данных)	0.85	0.86	0.91
14 (наиболее эффективные)	0.92	0.92	0.92
14 (на тестовых данных)	0.85	0.88	0.89

Исходя из полученных результатов можно сделать вывод, что модель оптимизации SFFB имеет достаточную эффективность и может использоваться для оптимизации признакового пространства, в частности медицинских данных.

Заключение

Проведенное исследование подтвердило высокую эффективность метода Sequential Floating Forward Selection для оптимизации признакового пространства в задаче медицинской диагностики. Анализ на наборе данных микроволновой радиотермометрии показал, что применение SFFB позволяет радикально

сократить размерность признаков с 70 до 14 наиболее эффективных, при этом значение метрик практически не изменилось. Таким образом, метод SFFB продемонстрировал высокую эффективность и способность успешно устранять избыточные признаки. Ключевым практическим результатом работы является демонстрация того, что значительное сокращение размерности не ухудшает диагностическую точность, а также обеспечивает важные преимущества: повышение скорости вычислений и улучшение интерпретируемости модели. Это делает метод SFFB ценным инструментом для построения эффективных и надежных диагностических систем, где критически важны как точность, так и прозрачность принятия решений.

Литература

1. Yala A, Lehman C, Schuster T, Portnoi T, Barzilay R (2019) A deep learning mammography-based model for improved breast cancer risk prediction. *Radiology* 292:60–66.
2. Дёмин К.С., Гермашев И.В. Использование методов машинного обучения при диагностике рака молочной железы // *Digital Diagnostics*. 2024. Т. 5, № 3. С. 578–591. DOI: <https://doi.org/10.17816/DD625866>.
3. Naji, M., Filali, S., Aarika, K., Benlahmar, E., Abdelouahid, R., & Debauche, O. (2021). Machine Learning Algorithms For Breast Cancer Prediction And Diagnosis, 487-492. <https://doi.org/10.1016/j.procs.2021.07.062>.
4. Rahman, R., Saha, D., Dkhar, W., Malli, S., & Abraham, N. (2025). Development of a machine learning predictive model for early detection of breast cancer. *F1000Research*. <https://doi.org/10.12688/f1000research.161073.1>.
5. Andreas Holzinger et al. «Why imaging data alone is not enough: AI-based integration of imaging, omics, and clinical data» *European Journal of Nuclear Medicine and Molecular Imaging* (2019): 1-9. <https://doi.org/10.1007/s00259-019-04382-9>.
6. Титор С.Е. Государственное распределение выпускников медицинских вузов как форма устранения кадрового голода в сфере здравоохранения. *Вестник университета*. 2025;(4):221-229. <https://doi.org/10.26425/1816-4277-2025-4-221-229>.
7. Nella Renton, & Grant R. Muddle. (2024). Healthcare worker shortages in Papua New Guinea and the need to focus on employee engagement. *Journal of Management and Science*, 14(1), 57 - 60. <https://doi.org/10.26524/jms.14.7>.
8. Malematja, D., Nkosi, E., & Nene, S. (2025). The impact of insufficient resources on the quality-of-service delivery at a primary healthcare clinic in Limpopo. *Curationis*, 48. <https://doi.org/10.4102/curationis.v48i1.2696>.
9. Freer, Phoebe E. "Mammographic breast density: impact on breast cancer risk and implications for screening." *Radiographics : a review publication of the Radiological Society of North America, Inc* vol. 35,2 (2015): 302-15. doi:10.1148/rg.352140106.
10. Caferova S, Uysal F, Balci P, Saydam S, Canda T. Efficacy and safety of breast radiothermometry in the differential diagnosis of breast lesions. *Contemp Oncol (Pozn)*. 2014;18(3):197-203. doi:10.5114/wo.2014.42721.
11. Pudil, Pavel, Jana Novovičová, and Josef Kittler. "Floating search methods in feature selection." *Pattern recognition letters* 15.11 (1994): 1119-1125.
12. Техника проведения РТМ-обследования молочных желез http://www.radiometry.ru/radiometry/books/up-load/536/tech_2008.pdf (дата обращения 20.11.2025). Электронный ресурс: <http://software.schneider-electric.com/products/simsci/design/pro-ii/>.
13. Лосев, А. Г., Е. А. Мазепа, and Т. В. Замечник. "О некото-

рых характерных признаках в диагностике патологии молочных желез по данным микроволновой радиотермометрии." Современные проблемы науки и образования 6 (2014): 254-254.

14. Алхасан, Алаа, and Елена Алексеевна Мазепа. Исследование зависимости температурных данных ртм-диагностики от возрастных факторов и типа фигуры // Математическая физика и компьютерное моделирование 28.1 (2025): 14-26.
15. Losev A.G., Levshinskiy V.V. Data Mining of Microwave Radiometry Data in the Diagnosis of Breast Cancer Mathematical Physics and Computer Simulation. Vol. 20 No. 5 2017 pp. 49-62 DOI 10.15688/mpcm.jvolsu.2017.5.6.
16. Демин, К. С. Применение методов машинного обучения для выявления риска развития рака молочной железы / К. С. Демин, И. В. Гермашев // Математические методы в технологиях и технике. – 2024. – № 7. – С. 84-87.

References

1. Titor S.E. Gosudarstvennoe raspredelenie vipusnikov meditsinskikh vuzov kak forma ustraneniya kadrovogo goloda v sfere zdavookhraneniya. Vestnik universiteta. 2025;(4):221-229. <https://doi.org/10.26425/1816-4277-2025-4-221-229>
2. Nella Renton, & Grant R. Muddle. (2024). Healthcare worker shortages in Papua New Guinea and the need to focus on employee engagement. Journal of Management and Science, 14(1), 57 - 60. <https://doi.org/10.26524/jms.14.7>
3. Malematja, D., Nkosi, E., & Nene, S. (2025). The impact of insufficient resources on the quality-of-service delivery at a primary healthcare clinic in Limpopo. Curationis, 48. <https://doi.org/10.4102/curationis.v48i1.2696>.
4. Freer, Phoebe E. "Mammographic breast density: impact on breast cancer risk and implications for screening." Radiographics: a review publication of the Radiological Society of North America, Inc vol. 35,2 (2015): 302-15. doi:10.1148/rg.352140106
5. Caferova S, Uysal F, Balci P, Saydam S, Canda T. Efficacy and safety of breast radiothermometry in the differential diagnosis of breast lesions. Contemp Oncol (Pozn). 2014;18(3):197-203. doi:10.5114/wo.2014.42721
6. Yala A, Lehman C, Schuster T, Portnoi T, Barzilay R (2019) A deep learning mammography-based model for improved breast cancer risk prediction. Radiology 292:60–66.
7. Dyomin KS, Germashev IV. Using Machine Learning Methods for Breast Cancer Diagnosis. Digital Diagnostics // Digital Diagnostics. 2024. Т. 5, № 3. C. 578–591. DOI: <https://doi.org/10.17816/DD625866>
8. Naji, M., Filali, S., Aarika, K., Benlahmar, E., Abdelouahid, R., & Debauche, O. (2021). Machine Learning Algorithms For Breast Cancer Prediction And Diagnosis, 487-492. <https://doi.org/10.1016/j.procs.2021.07.062>.
9. Rahman, R., Saha, D., Dkhar, W., Malli, S., & Abraham, N. (2025). Development of a machine learning predictive model for early detection of breast cancer. F1000Research. <https://doi.org/10.12688/f1000research.161073.1>.
10. Andreas Holzinger et al. «Why imaging data alone is not enough: AI-based integration of imaging, omics, and clinical data» European Journal of Nuclear Medicine and Molecular Imaging (2019): 1-9. <https://doi.org/10.1007/s00259-019-04382-9>.
11. Pudil, Pavel, Jana Novovičová, and Josef Kittler. "Floating search methods in feature selection." Pattern recognition letters 15.11 (1994): 1119-1125.
12. Техника проведения РТМ-обследования молочных желез http://www.radiometry.ru/radiometry/books/upload/536/tech_2008.pdf (дата обращения 20.11.2025). Электронный ресурс: <http://software.schneider-electric.com/products/simsci/design/pro-ii/>
13. Losev A. G., Ye. A. Mazepa, T. V. Zamechnik. "O nekotorykh kharakternikh priznakakh v diagnostike patologii molochnikh zhelez po dannim mikrovolnovoi radiotermometrii." Sovremennye problemi nauki i obrazovaniya 6 (2014): 254-254.
14. Alkhasan A., Mazepa E.A. Investigation of the Dependence of RTM Diagnostic Temperature Data on Age Factors and Body Type Mathematical Physics and Computer Simulation. Vol. 28 No. 1 2025, pp. 14-26.
15. Losev A.G., Levshinskiy V.V. Data Mining of Microwave Radiometry Data in the Diagnosis of Breast Cancer Mathematical Physics and Computer Simulation. Vol. 20 No. 5 2017 pp. 49-62 DOI 10.15688/mpcm.jvolsu.2017.5.6
16. Demin, K. S. Primenenie metodov mashinnogo obucheniya dlya viyavleniya riska razvitiya raka molochnoi zhelezi / K. S. Demin, I. V. Germashev // Matematicheskie metody v tekhnologiyakh i tekhnike. – 2024. – № 7. – С. 84-87.

© **К. С. Дёмин** – аспирант каф. Математического анализа и теории функций (МАТФ), Волгоградский государственный университет (ВолГУ), Волгоград, Россия, diominkirill@yandex.ru; **И. В. Гермашев** – д.т.н., проф. каф. МАТФ, ВолГУ, germashev@volsu.ru.

© **K. S. Demin** – PhD-student at the Mathematical Analysis and Theory of Functions (MATF) Department, Volgograd State University (VolSU), Volgograd, Russia, diominkirill@yandex.ru; **I. V. Germashev** – Doctor of Sciences (Technical Sci.), Professor of the MATF department, VolSU, germashev@volsu.ru.

Дата поступления рукописи в редакцию – 22.12.25.

Дата принятия рукописи в печать – 12.01.26.