

А. М. ИСМУХАМЕДОВА*, И. М. УВАЛИЕВА

*Школа цифровых технологий и искусственного интеллекта,
ВКТУ им. Д. Серикбаева, Усть-Каменогорск, ВКО, Казахстан.*

**E-mail: aigerim.ismukhamedova1@gmail.com*

ЭКСПЕРИМЕНТАЛЬНОЕ ИССЛЕДОВАНИЕ МОДЕЛИ АНАЛИЗА ДАНЫХ ДЛЯ ПОДДЕРЖКИ ПРИНЯТИЯ МЕДИЦИНСКИХ РЕШЕНИЙ

Исмухамедова Айгерим – Школа цифровых технологий и искусственного интеллекта, ВКТУ им. Д. Серикбаева, Усть-Каменогорск, ВКО, Казахстан;

E-mail: aigerim.ismukhamedova1@gmail.com

Увалиева Индира – Школа цифровых технологий и искусственного интеллекта, ВКТУ им. Д. Серикбаева, Усть-Каменогорск, ВКО, Казахстан.

E-mail: indirauvalieva@gmail.com

Эта статья посвящена разработке и анализу моделей машинного обучения и глубокого обучения для повышения эффективности диагностики диабета. В контексте быстро развивающихся технологий обработки данных важно исследовать, как эти методы могут быть применены для точного прогнозирования и улучшения медицинских решений. В нашем исследовании мы используем разнообразные наборы данных, чтобы обучить и проверить модели, опираясь на современные алгоритмы и технологии. Основной акцент сделан на оценку точности, чувствительности и специфичности моделей в контексте диагностики диабета. Результаты исследования показывают значительное улучшение в прогнозировании заболевания, подчеркивая потенциал машинного и глубокого обучения в медицинских приложениях. Эта работа предоставляет новые перспективы для применения вычислительных методов в здравоохранении и может служить отправной точкой для будущих исследований в данной области.

Ключевые слова: распространение диабета, машинное обучение, глубокое обучение, техники моделирования, распределение ресурсов здравоохранения, исследование ВОЗ

А. ИСМУХАМЕДОВА, И. У. ВАЛИЕВА

*Сандық технологиялар және жасанды интеллект мектебі,
Д. Серікбаев атындағы ШҚТУ, Өскемен, ШҚО, Қазақстан*

**E-mail: aigerim.ismukhamedova1@gmail.com*

МЕДИЦИНАЛЫҚ ШЕШІМДЕРДІ ҚОЛДАУ ҮШІН ДЕРЕКТЕРДІ ТАЛДАУ МОДЕЛІН ЭКСПЕРИМЕНТТІК ЗЕРТТЕУ

Исмухамедова Айгерим – Сандық технологиялар және жасанды интеллект мектебі, Д. Серікбаев атындағы ШҚТУ, Өскемен, ШҚО, Қазақстан;

E-mail: aigerim.ismukhamedova1@gmail.com

Увалиева Индира – Сандық технологиялар және жасанды интеллект мектебі, Д. Серікбаев атындағы ШҚТУ, Өскемен, ШҚО, Қазақстан.

E-mail: indirauvalieva@gmail.com

Бұл мақала қант диабетін диагностикалаудың тиімділігін арттыру үшін машиналық оқыту мен терең оқыту модельдерін әзірлеу мен талдауға бағытталған. Деректерді өңдеудің технологиялары дамып келе жатқан дәуірде медициналық шешімдерді дәл болжау және жақсарту үшін әдістерді қолдану маңызды рөл атқарады. Бұл зерттеуде заманауи алгоритмдер мен технологияларға сүйене отырып, модельдерді оқыту және тексеру үшін әртүрлі деректер жиынтығын қолданылды. Қант диабетін диагностикалау контекстіндегі модельдердің дәлдігін, сезімталдығын және ерекшелігін бағалауға баса назар аударылады. Зерттеу нәтижелері медициналық қолданбаларда машиналық және терең оқыту әлеуетін көрсете отырып, ауруды болжаудың айтарлықтай жақсарғанын көрсетеді. Бұл зерттеу жұмысы денсаулық сақтауда есептеу әдістерін қолданудың жаңа перспективаларын ұсынады және осы саладағы болашақ зерттеулердің бастапқы нүктесі бола алады.

Түйін сөздер: қант диабетінің таралуы, машиналық оқыту, терең оқыту, модельдеу техникасы, денсаулық сақтау ресурстарын бөлу, ДДҰ зерттеуі.

A. ISMUKHAMEDOVA, * I. UVALIYEVA

*School of Digital Technologies and Artificial Intelligence, D. Serikbaev EKTU,
Ust-Kamenogorsk, East Kazakhstan Region, Kazakhstan.*

*E-mail: *aigerim.ismukhamedova1@gmail.com*

EMPIRICAL INVESTIGATION OF A DATA ANALYTICS MODEL IN MEDICAL SETTINGS

Ismukhamedova Aigerim – School of Digital Technologies and Artificial Intelligence, D. Serikbaev EKTU, Ust-Kamenogorsk, East Kazakhstan Region, Kazakhstan;

E-mail: aigerim.ismukhamedova1@gmail.com

Uvalieva Indira – School of Digital Technologies and Artificial Intelligence, D. Serikbaev EKTU, Ust-Kamenogorsk, East Kazakhstan Region, Kazakhstan.

E-mail: indirauvalieva@gmail.com

This article centers around the development and analysis of machine learning and deep learning models aimed at enhancing diabetes diagnosis. In the swiftly evolving landscape of data technologies, it becomes crucial to explore the applications of these methods for accurate predictions and improved medical decision-making. Our research encompasses diverse datasets, leveraging state-of-the-art algorithms and technologies for model training and testing. The primary emphasis lies in evaluating the accuracy, sensitivity, and specificity of models within the realm of diabetes diagnosis. The study results reveal significant advancements in disease prediction, underscoring the potential of machine learning and deep learning in medical applications. This work introduces fresh perspectives on the utilization of computational methods in healthcare and serves as a foundation for prospective research in this domain.

Keywords: diabetes prevalence, machine learning, deep learning, modeling techniques, healthcare resource allocation, WHO study.

Введение. В развитии современного здравоохранения управление и анализ медицинских данных стали иметь решающее значение. Внедрение электронного паспорта здоровья (ЭПЗ) представляет собой шаг к улучшению обработки данных пациентов, предлагая комплексный инструмент для сбора, хранения и обработки медицинской информации. Это нововведение согласуется с Глобальной стратегией цифрового

здравоохранения Всемирной организации здравоохранения (ВОЗ) на 2020-2025 годы [1], [2] которая направлена на повсеместное улучшение здравоохранения с помощью цифровых технологий [3], [4] с упором на равенство [5] и инклюзивность [6]. Несмотря на эти достижения, реализация таких стратегий в различных национальных условиях сопряжена с серьезными проблемами.

Основа создания систем, которые собирают, хранят и анализируют медицинскую информацию от пациентов из разных стран мира, лежит в сфере обширных данных. Обработка этого огромного количества данных, обычно называемых большими данными, дает нам возможность сформулировать методологии для прогнозирования таких факторов, как уровень заболеваемости, смертность, осложнения и многих других [7].

Методы машинного обучения и глубокого обучения с присущей им способностью независимо извлекать ценную информацию из данных предлагают значительное преимущество в прогнозировании, что приводит к их широкому использованию в области медицины, и это подчеркивает важность и высокое значение методов глубокого обучения в здравоохранении [8]–[11]. Анализ историй болезни пациентов и критериев отбора разработанных моделей позволяет прогнозировать заражение, выживаемость и риск критических состояний [12]–[16]. Сравнение 14 различных алгоритмов машинного обучения показало точность более 90% при выявлении людей с диабетом и без него [17]. Исследователи также комбинируют несколько алгоритмов для определения точности прогнозирования диабета [18]–[20].

Несмотря на эффективность моделей машинного обучения в выявлении и прогнозировании заболеваний полезность этих технологий в области прогнозирования диабета остается недостаточно изученной, отчасти из-за используемых алгоритмов. Например, в сфере альтернативных алгоритмов машинного обучения традиционные методы, такие как наивный алгоритм Байеса, логистическая регрессия и машины опорных векторов (SVM), приводят к экспоненциальному росту сложности вычислений из-за увеличения данных, что приводит к неадекватным результатам [7]. Напротив, древовидные алгоритмы предоставляют более надежную альтернативу, смягчая определенные ограничения, с которыми сталкиваются традиционные методы. Ансамблевые методы и алгоритм дерева решений в машинном обучении предлагают подходы к высокоточной диагностике в прогнозировании таких заболеваний как рак молочной железы сердечно-сосудистые заболевания и COVID-19.

Постепенно происходит внедрение цифровых технологий в здравоохранение и важно учитывать как вопросы диагностирования, так и проблемы управления и безопасности данных. В данной статье будет представлена наша методология, которая объединяет различные модели машинного обучения с методами классификации глубокого обучения для прогнозирования наличия диабета. В ходе исследования выполняется задача двоичной классификации с использованием нескольких критериев оценки и настройки гиперпараметров для создания надежных алгоритмов. Благодаря тщательной предварительной обработке данных мы изучим историю болезни пациентов и уровни госпитализации, чтобы повысить прогностические возможности нашей модели в дальнейшем.

Материалы и методы. Исследование состоит из этапов, обеспечивающих воспроизводимость и надежность результатов, а именно:

1. Выбор и подготовка данных:

– исследовательский анализ данных (EDA) проводится для выявления и устранения несоответствий данных, пропущенных значений и выбросов;

– качество данных переоценивается посредством протоколов проверки для обеспечения достоверности и надежности;

– структурированные кадры данных создаются для тестирования и обучения прогнозных моделей с тщательным выбором функций, чтобы сбалансировать информативность и эффективность вычислений.

2. Моделирование:

– описан ряд прогностических моделей, включая, помимо прочего, деревья решений, случайные леса и машины опорных векторов, каждая из которых выбрана с учетом доказанной эффективности при анализе медицинских данных;

– производительность модели строго оценивается по ключевым показателям: точности, баллу F1, прецизионности и полноте, чтобы обеспечить полное понимание предсказательной силы каждой модели.

3. Определение лучшей модели:

– Проводится сравнительный анализ с целью определения наиболее эффективной модели с помощью систематического анализа показателей производительности и их согласования с конкретными нюансами набора данных.

4. Оптимизация модели: точность модели повышается за счет систематического процесса оптимизации с использованием методов поиска по сетке для точной настройки гиперпараметров в пределах возможных вычислительных границ.

5. Применение глубокого обучения:

– развертываются ансамблевые модели и нейронные сети, выбранные из-за их способности моделировать сложные нелинейные отношения, присущие медицинским данным;

– гиперпараметры тщательно выбираются с учетом их влияния на производительность, при этом особое внимание уделяется возможности обобщения и предотвращения переобучения.

6. Получение и анализ результатов:

– для обеспечения надежности результаты получены из рандомизированного набора данных;

– ключевые параметры, влияющие на диагноз, определяются посредством анализа важности признаков, что обеспечивает интерпретируемость модели;

– производится сотрудничество с экспертами в предметной области, что обеспечивает клиническую значимость анализа данных;

– по возможности проводятся дополнительные испытания с использованием наборов данных из медицинских учреждений для проверки применимости модели в реальных условиях.

Выбор данных основан на протоколах диагностики и лечения, которые устанавливают систематические рекомендации, определяющие медицинский диагноз и лечение. Эти протоколы соответствуют стандартам ВОЗ и предлагают основу для выявления

сахарного диабета с помощью различных показателей, таких как симптомы, уровень глюкозы и другие клинические тесты. Наша методология включает извлечение и анализ комплексного набора данных из базы данных MIMIC III. Набор данных разделен на демографические данные, историю болезни, параметры здоровья, медикаментозную терапию, записи пациентов, детали госпитализации, результаты лабораторных исследований и информацию о лечении. Каждая категория тщательно обрабатывается для обеспечения целостности и актуальности данных.

Первоначальное обучение модели использует обширный набор показателей: от лабораторных тестов до данных осмотра пациентов. Мы намеренно позволяем моделям автономно обучаться на основе полного набора данных для выявления скрытых корреляций. Перед обучением мы проводим подготовку данных, включая очистку с целью удаления дубликатов и аномалий.

Атрибуты данных, использованные в этом исследовании, общедоступны, и их можно найти в обзоре схемы базы данных MIMIC. Данные из таблиц «chartevents», «noteevents», «labevents» и «microbiologyevents» дают представление о состоянии пациента и реакции на лечение. Консолидация данных о пациентах и заболеваниях имела решающее значение для установления корреляций, необходимых для эффективного обучения модели.

После подготовки данных мы используем комбинацию машинного обучения и ансамблевых методов для определения оптимальной модели. Выбор этих методов оправдан их надежностью при обработке многомерных данных и проверенной репутацией в анализе медицинских данных.

Подготовка и анализ данных. Данные для работы были извлечены из базы данных MIMIC-III, включающей медицинские записи множества пациентов. В качестве фокуса исследования были выбраны записи, связанные с диабетическими пациентами. Для обучения использовались все данные, включая демографические данные, истории болезней, результаты анализов, записи о приемах лекарств и госпитализациях. Отсутствие конкретики относительно диабета по данным для обучения на наш взгляд является ключевым условием поиска дополнительных скрытых зависимостей и новых прогностических параметров.

Очистка данных включает в себя удаление неполных или некорректных записей, например, если запись пациента не содержала ключевой информации о диагнозе или лечении, она исключалась из анализа. Обработка пропущенных значений очень важна в случаях, когда данные были не введены (например, отсутствие информации о возрасте или поле пациента), применялись методы импутации или такие записи исключались из анализа для поддержания точности данных.

Мы использовали стандартизацию числовых данных, которая включает в себя применение таких методов, как Z-преобразование, для унификации масштабов числовых данных. Например, показатели лабораторных анализов были стандартизированы для обеспечения сопоставимости результатов.

Также важным пунктом является преобразование категориальных данных. Кодирование категориальных данных, таких как пол или раса, с использованием методов типа one-hot encoding было осуществлено для обеспечения их корректной обработки моделями машинного обучения. Предварительная обработка данных

является важным шагом, так как необходима для устранения искажений и ошибок, которые могут негативно сказаться на точности и надежности моделей машинного обучения. Стандартизация и преобразование данных обеспечили однородность и сопоставимость данных, что критически важно для анализа и интерпретации результатов. Эти шаги позволили обеспечить высокое качество данных, что является ключевым фактором для достижения точных и значимых результатов в исследовании.

Сам процесс выбора моделей происходил на основе характеристик данных (например, размера выборки, количества признаков, типа задачи) были выбраны модели, подходящие для задачи классификации диабета. Использовались модели деревьев решений, случайного леса и AdaBoost. Деревья решений предпочтительны для интерпретируемости, случайный лес - для устойчивости к переобучению, а AdaBoost - для улучшения производительности слабых классификаторов. Случайный лес был выбран за его способность эффективно работать с большими наборами данных и обрабатывать большое количество признаков, а также за его устойчивость к переобучению.

В процессе настройки гиперпараметров использовались методы, такие как сеточный поиск (Grid Search) или случайный поиск (Random Search), для определения оптимальных гиперпараметров моделей.

В качестве используемых гиперпараметров были выбраны следующие:

- для случайного леса были количество деревьев, глубина дерева и критерии разделения;
- в AdaBoost важными гиперпараметрами были количество итераций и скорость обучения.

Настройка гиперпараметров критически важна для улучшения производительности модели и предотвращения как переобучения, так и недообучения. Использование встроенных функций моделей машинного обучения для оценки важности признаков, например атрибута `feature_importances_` в случайном лесе. Примеры: Выявление наиболее важных признаков для предсказания диабета, таких как уровень глюкозы в крови, ИМТ, возраст, пол. Понимание важности признаков помогает интерпретировать модели и сосредотачиваться на наиболее значимых аспектах данных.

Результаты и обсуждение. Для оценки производительности моделей использовались такие метрики, как точность, F1-оценка, полнота и прецизионность. Это позволяет сравнивать модели как в целом, так и по отдельным аспектам классификации. Для реализации исследования были загружены все необходимые библиотеки: `pandas`, `numpy`, `matplotlib`, `seaborn`, `sklearn`.

Далее были выполнены следующие шаги:

ШАГ 1. Загрузка обработанные данные по диабету из таблицы «Заболевания» и обезличенные данные по пациентам из таблицы «Пациенты». Так же соединили эти данные по ключевым столбцам. Получили итоговый датафрейм размерностями:

- Number of Patients with Diabetes : (552336, 13)
- Number of Patients without Diabetes : (15969, 13)
- Number of Final balanced Dataframe : (31938, 13)

ШАГ 2. Импорт необходимых библиотек. Код начинается с импорта классов из библиотеки `sklearn`, используемых для кросс-валидации и различных алгоритмов классификации.

ШАГ 3. Установка начального состояния генератора случайных чисел. `random_state = 2` обеспечивает воспроизводимость результатов, задавая исходное состояние для генератора случайных чисел.

ШАГ 4. Создание списка классификаторов. В список `classifiers` добавляются различные алгоритмы классификации, включая `DecisionTreeClassifier` и ансамблевые методы, такие как `AdaBoostClassifier`, `RandomForestClassifier`, `ExtraTreesClassifier` и `GradientBoostingClassifier`.

ШАГ 5. Используем кросс-валидацию с пятью разбиениями (`kfold = 5`), код оценивает каждый классификатор на обучающем наборе данных `X_train` с ответами `y_train`, используя метрику “точность” (`accuracy`).

ШАГ 6. Для каждого классификатора вычисляются средняя точность и стандартное отклонение результатов кросс-валидации.

ШАГ 7. Создается столбчатая диаграмма, которая показывает среднюю точность (среднее значение кросс-валидационных оценок) для каждого алгоритма с указанием стандартного отклонения ошибок. На рисунке 1 представлена диаграмма кросс-валидации.

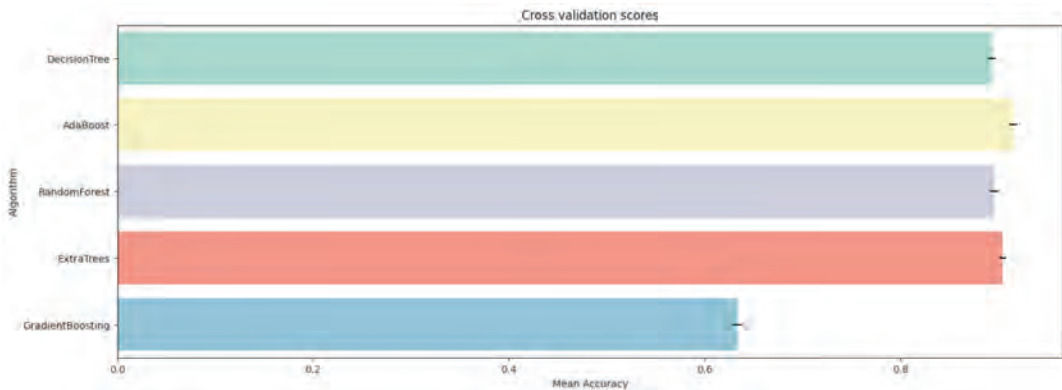


Рисунок 1 – Диаграмма результатов кросс-валидации для каждого из алгоритмов.

Диаграмма показывает, что `GradientBoostingClassifier` имеет самую высокую среднюю точность, в то время как `DecisionTreeClassifier` имеет самую низкую. Это говорит о том, что модели, основанные на ансамблевом обучении, в целом превосходят простой `DecisionTreeClassifier`, вероятно, благодаря их способности лучше обобщать и уменьшать переобучение.

На рисунке 2 представлена количественная оценка пяти различных алгоритмов классификации. Показатели производительности агрегируются на основе процедур перекрестной проверки, которые играют важную роль в оценке надежности каждой модели. Рассматриваемые метрики — это средняя точность (`CrossValMeans`) и соответствующая стандартная ошибка (`CrossValerrors`), полученные на основе оценок перекрестной проверки.

	CrossValMeans	CrossValerrors	Algorithm
0	0.893585	0.004231	DecisionTree
1	0.915459	0.004543	AdaBoost
2	0.896046	0.004023	RandomForest
3	0.904589	0.003482	ExtraTrees
4	0.633432	0.004944	GradientBoosting

Рисунок 2 – Сравнительная производительность алгоритмов классификации

Переменные:

- *CrossValMeans*: Средняя точность моделей, определённая через перекрестную проверку, отражающая пропорцию корректно классифицированных наблюдений.
- *CrossValerrors*: Стандартная ошибка средней точности, где меньшие значения указывают на высокую стабильность моделей.

Выводы:

- *AdaBoost* выделяется с наивысшей средней точностью (0,915459) и низкой стандартной ошибкой (0,004543), обозначая высокую стабильность.
- *GradientBoosting* показывает ниже среднюю точность (0,633432) и выше стандартную ошибку (0,004944), что может свидетельствовать о его менее предсказуемой производительности.
- *DecisionTree*, *RandomForest* и *ExtraTrees* демонстрируют умеренную точность, при этом *DecisionTree* имеет наибольшую стандартную ошибку, указывающую на inconsistency.

На основании этих данных, *AdaBoost* рекомендуется для дальнейшего усовершенствования, в то время как *GradientBoosting* требует дополнительного анализа для определения соответствия сложности модели и возможной корректировки параметров.

Оптимизация Гиперпараметров:

Используя *EstimatorSelectionHelper*, мы автоматизировали подбор гиперпараметров и оценку моделей через Grid Search и перекрестную проверку. Процесс включал инициализацию помощника с моделями и параметрами, выполнение Grid Search, суммирование результатов в сводную таблицу и оценку производительности моделей по средним оценкам и стандартному отклонению. Подбор параметров включал оптимизацию таких гиперпараметров, как *max_depth* для *DecisionTreeClassifier* и *learning_rate* для *AdaBoostClassifier*. Результатом стала таблица, ранжирующая модели по производительности и настроенным гиперпараметрам, способствующая выбору наиболее эффективных решений для классификации.

	estimator	min_score	mean_score	max_score	std_score	learning_rate	max_depth	max_features
41	GradientBoostingClassifier	0.910952	0.914678	0.917058	0.00266821	NaN	9	auto
37	GradientBoostingClassifier	0.874507	0.876104	0.877888	0.00138689	NaN	7	auto
39	GradientBoostingClassifier	0.866804	0.870875	0.874319	0.0030996	NaN	9	sqrt
40	GradientBoostingClassifier	0.861732	0.866491	0.873943	0.00533642	NaN	9	auto
36	GradientBoostingClassifier	0.799361	0.809569	0.81796	0.00770064	NaN	7	auto
38	GradientBoostingClassifier	0.797577	0.802774	0.812324	0.00676151	NaN	9	sqrt
33	GradientBoostingClassifier	0.787808	0.793037	0.803119	0.00713072	NaN	5	auto
35	GradientBoostingClassifier	0.792316	0.79504	0.798892	0.00280016	NaN	7	sqrt
32	GradientBoostingClassifier	0.714071	0.723402	0.739339	0.011324	NaN	5	auto
34	GradientBoostingClassifier	0.724497	0.730603	0.739245	0.00628198	NaN	7	sqrt
31	GradientBoostingClassifier	0.70928	0.715386	0.71858	0.00431883	NaN	5	sqrt
29	GradientBoostingClassifier	0.677156	0.687927	0.694345	0.00766274	NaN	3	auto
30	GradientBoostingClassifier	0.66269	0.671301	0.681007	0.00751782	NaN	5	sqrt
17	RandomForestClassifier	0.664475	0.669798	0.67894	0.00649393	NaN	9	NaN
16	RandomForestClassifier	0.661845	0.668671	0.678753	0.00727648	NaN	9	NaN
28	GradientBoostingClassifier	0.646158	0.651919	0.659215	0.00543959	NaN	3	auto
27	GradientBoostingClassifier	0.631881	0.643653	0.652452	0.0086575	NaN	3	sqrt
24	ExtraTreesClassifier	0.639019	0.643966	0.652076	0.00578036	NaN	9	NaN
25	ExtraTreesClassifier	0.641368	0.645062	0.651418	0.00451417	NaN	9	NaN
15	RandomForestClassifier	0.630378	0.638111	0.649258	0.00807682	NaN	7	NaN
14	RandomForestClassifier	0.634135	0.639959	0.649164	0.00658507	NaN	7	NaN
3	DecisionTreeClassifier	0.63282	0.640522	0.645501	0.00552365	NaN	9	NaN
26	GradientBoostingClassifier	0.626245	0.630315	0.636295	0.00431974	NaN	3	sqrt

Рисунок 3 – Таблица моделей и подобранных гиперпараметров

Таблица демонстрирует результаты оптимизации гиперпараметров для алгоритмов классификации с помощью Grid Search. Для каждого алгоритма указаны следующие показатели: минимальная, средняя и максимальная точность, стандартное отклонение этих точностей, а также подобранные гиперпараметры. GradientBoostingClassifier показал высокую среднюю точность при максимальной глубине 9 и параметре max_features 'auto' или 'sqrt', что свидетельствует о важности сложности модели при контроле за переобучением. Значения NaN в столбцах гиперпараметров означают их неприменимость к определённым моделям.

Финальная настройка моделей проводилась с учётом оптимальных гиперпараметров, найденных ранее. Процедуры включали импорт метрической библиотеки, инициализацию и обучение классификаторов, предсказание результатов и расчёт стандартных метрик, таких как точность, прецизионность, полнота и F1-оценка. Результаты для каждой модели представлены на рисунке 4.

Диаграмма показывает, что модель GradientBoostingClassifier имеет самую высокую точность в тестовом наборе данных, а также высокие оценки по другим метрикам, что делает ее предпочтительной моделью для реальных приложений.

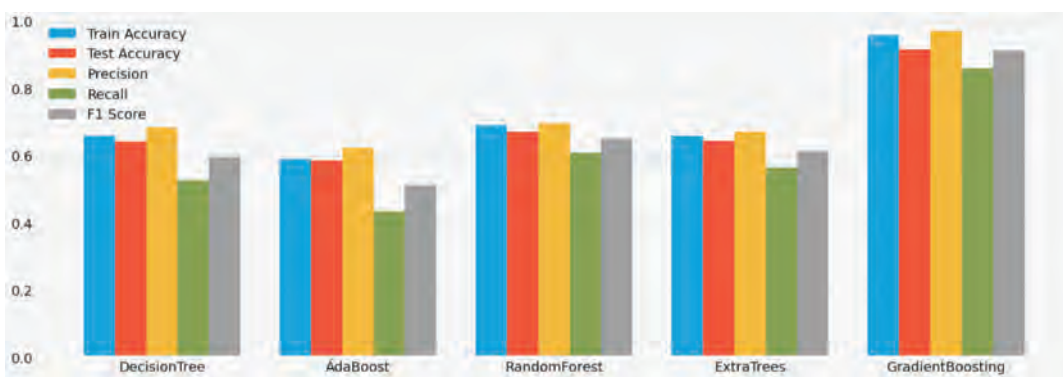


Рисунок 4 – Таблица моделей и подобранных гиперпараметров

Результаты в консоли, которые показывают точность, показатель F1, полноту и прецизионность, равные 1.0, скорее всего, являются результатом прогнозирования в наборе обучающих данных (trainprediction), где модель уже видела все ответы, и это уже приводит к переобучению. Однако в реальной ситуации важно посмотреть на результаты тестового набора данных (прогноза), который представляет собой новые данные, не задействованные в обучении модели.

Заключение. В заключение данного исследования следует отметить, что внедрение методов машинного и глубокого обучения в медицинскую диагностику диабета представляет собой значительный шаг вперед в области прецизионной медицины. Результаты нашего исследования демонстрируют, что с применением современных алгоритмов машинного обучения можно добиться высокой точности, чувствительности и специфичности в прогнозировании диабета, что в свою очередь способствует улучшению качества медицинского обслуживания и повышению эффективности процесса принятия клинических решений. Однако необходимо подчеркнуть, что для достижения оптимальных результатов требуется тщательная подготовка и предварительная обработка данных, а также учет специфических характеристик конкретной клинической ситуации. В целях дальнейшего совершенствования моделей и их применения в клинической практике, предлагается продолжить исследования в данной области, включая анализ больших объемов данных и разработку алгоритмов, способных адаптироваться к изменяющимся условиям и характеристикам пациентов. Таким образом, данный проект вносит значительный вклад в развитие методов искусственного интеллекта в медицине и открывает новые перспективы для их применения в диагностике и лечении хронических заболеваний.

Благодарность. Исследование выполнено при финансовой поддержке Министерства науки и высшего образования Республики Казахстан по проекту № AP19679525 «Программный комплекс для диагностики клинических и гемато-логических синдромов для электронного паспорта здоровья».

ЛИТЕРАТУРА

1 Всемирная организация здравоохранения. Глобальная стратегия ВОЗ в области цифрового здравоохранения на 2020-2025 годы [Global'naya strategiya VOZ v oblasti tsifrovogo zdavookhraneniya na 2020-2025 gody]. Женева, стр. 1-60, 2021. Доступно: <https://www.evidentiq.com/resources/the-who-global-strategy-on-digital-health-what-you-need-to-know/> (дата обращения: 27.10.2023).

2 ВОЗ. Crowell Health Solutions Blog - WHO Announces Global Initiative Focused on Digital Health [Krouell Khels Solyushns Blog - VOZ ob'yavlyayet global'nyuyu initsiativu, napravlennuyu na tsifrovoe zdavookhranenie]. Доступно: <https://www.crowellhealthsolutionsblog.com/2023/08/who-announces-global-initiative-focused-on-digital-health>.

3 Международный союз электросвязи (ITU). ITU - Rol' Global'noj strategii tsifrovogo zdavookhraneniya 2020 [ITU - The Role of the Global Digital Health Strategy 2020]. Доступно: <https://www.itu.int/net4/wsis/forum/2023/Agenda/Session/334>.

4 Всемирная организация здравоохранения (WHO). Health Policy Watch - Digital Health - Big WHO Ambitions But Progress Lags. Доступно: <https://healthpolicy-watch.news/digital-health-big-who-goals-slow-progress/>.

5 Xue P., Bai A.Y., Jiang Y., Qiao Y.L. WHO global strategy on digital health and its implications to China. Journal of Medical Internet Research, 2022, vol. 56, no. 2, pp. 218-221. doi: 10.3760/cma.j.cn112150-20210616-00589.

6 Всемирная организация здравоохранения (WHO). Digital health. Доступно: https://www.who.int/health-topics/digital-health#tab=tab_1.

7 Bagheri A.B. et al. Potential applications of artificial intelligence and machine learning on diagnosis, treatment, and outcome prediction to address health care disparities of chronic limb-threatening ischemia. Seminars in Vascular Surgery, 2023, vol. 36, no. 3, pp. 454-459. doi: 10.1053/j.semvascsurg.2023.06.003.

9 Xu L., Magar R., Barati Farimani A. Forecasting COVID-19 new cases using deep learning methods // Comput. Biol. Med. – 2022. – Vol. 144. – P. 105342. – DOI: 10.1016/j.compbimed.2022.105342.

10 Khanna V.V., Chadaga K., Sampathila N., Prabhu S., R.C.P. A machine learning and explainable artificial intelligence triage-prediction system for COVID-19 // Decision Analytics Journal. – 2023. – Vol. 7. – P. 100246. – DOI: 10.1016/j.dajour.2023.100246.

11 Rafique Q. et al. Reviewing methods of deep learning for diagnosing COVID-19, its variants and synergistic medicine combinations // Comput. Biol. Med. – 2023. – Vol. 163. – P. 107191. – DOI: 10.1016/j.compbimed.2023.107191.

12 Rakhshan S.A., Nejad M.S., Zaj M., Ghane F.H. Global analysis and prediction scenario of infectious outbreaks by recurrent dynamic model and machine learning models: A case study on COVID-19 // Comput. Biol. Med. – 2023. – Vol. 158. – P. 106817. – DOI: 10.1016/j.compbimed.2023.106817.

13 Elhadary M. et al. Revolutionizing chronic lymphocytic leukemia diagnosis: A deep dive into the diverse applications of machine learning // Blood Rev. – 2023. – P. 101134. – DOI: 10.1016/j.blre.2023.101134.

14 Zhou L., Zhao C., Liu N., Yao X., Cheng Z. Improved LSTM-based deep learning model for COVID-19 prediction using optimized approach // Eng. Appl. Artif. Intell. – 2023. – Vol. 122. – P. 106157. – DOI: 10.1016/j.engappai.2023.106157.

15 Rajesh K., Sangeetha V. Application of data mining methods and techniques for diabetes diagnosis // Int. J. Eng. Innov. Technol. (IJEIT). 2012. Sep.

16 Sarwar M.A., Kamal N., Hamid W., Shah M.A. Prediction of diabetes using machine learning algorithms in healthcare // 24th International Conference on Automation and Computing (ICAC). Newcastle Upon Tyne, United Kingdom, 2018. Pp. 1-6.

17 Lama L., Wilhelmsson O., Norlander E., Gustafsson L., Lager A., Tynelius P. Machine learning for prediction of diabetes risk in middle-aged Swedish people // *Heliyon*. 2021. Vol. 7, No. 7.

18 Bibault J.E., Giraud P., Burgun A. Big Data and machine learning in radiation oncology: Current state of the art and future perspectives // *Cancer Lett*. 2016. Vol. 382, No. 1. Pp. 110-117. DOI: 10.1016/J.CANLET.2016.05.033.

19 Zheng Jian, Xu Cencen, Zhang Ziang, Li Xiaohua. Electric load forecasting in smart grids using Long-Short-Term-Memory based Recurrent Neural Network // 2017 51st Annual Conference on Information Sciences and Systems (CISS). IEEE, 2017. Pp. 1-6. DOI: 10.1109/CISS.2017.7926112.

20 Zhou L., Pan S., Wang J., Vasilakos A.V. Machine learning on big data: Opportunities and challenges // *Neurocomputing*. 2017. Vol. 237. Pp. 350-361. DOI: 10.1016/j.neucom.2017.01.026.

REFERENCES

1 Vsemirnaya organizaciya zdavoohraneniya. Global'naya strategiya VOZ v oblasti cifrovogo zdavoohraneniya na 2020-2025 gody [Global'naya strategiya VOZ v oblasti tsifrovogo zdavoohraneniya na 2020-2025 gody]. Zheneva, str. 1-60, 2021. Dostupno: <https://www.evidentiq.com/resources/the-who-global-strategy-on-digital-health-what-you-need-to-know/> (data obrashcheniya: 27.10.2023).

2 VOZ. Crowell Health Solutions Blog - WHO Announces Global Initiative Focused on Digital Health [Krouell Khels Solyushns Blog - VOZ ob'yavlyayet global'nyu initsiativu, napravlennuyu na tsifrovoe zdavoohranenie]. Dostupno: <https://www.crowellhealthsolutionsblog.com/2023/08/who-announces-global-initiative-focused-on-digital-health>.

3 Mezhdunarodnyj soyuz elektrosvyazi (ITU). ITU - Rol' Global'noj strategii tsifrovogo zdavoohraneniya 2020 [ITU - The Role of the Global Digital Health Strategy 2020]. Dostupno: <https://www.itu.int/net4/wsis/forum/2023/Agenda/Session/334>.

4 Vsemirnaya organizaciya zdavoohraneniya (WHO). Health Policy Watch - Digital Health - Big WHO Ambitions But Progress Lags. Dostupno: <https://healthpolicy-watch.news/digital-health-big-who-goals-slow-progress/>.

5 Xue P., Bai A.Y., Jiang Y., Qiao Y.L. WHO global strategy on digital health and its implications to China. *Journal of Medical Internet Research*, 2022, vol. 56, no. 2, pp. 218-221. doi: 10.3760/cma.j.cn112150-20210616-00589.

6 Vsemirnaya organizaciya zdavoohraneniya (WHO). Digital health. Dostupno: https://www.who.int/health-topics/digital-health#tab=tab_1.

7 Bagheri A.B. et al. Potential applications of artificial intelligence and machine learning on diagnosis, treatment, and outcome prediction to address health care disparities of chronic limb-threatening ischemia. *Seminars in Vascular Surgery*, 2023, vol. 36, no. 3, pp. 454-459. doi: 10.1053/j.semvasesurg.2023.06.003.

9 Xu L., Magar R., Barati Farimani A. Forecasting COVID-19 new cases using deep learning methods // *Comput. Biol. Med.* – 2022. – Vol. 144. – P. 105342. – DOI: 10.1016/j.combiomed.2022.105342.

10 Khanna V.V., Chadaga K., Sampathila N., Prabhu S., R.C.P. A machine learning and explainable artificial intelligence triage-prediction system for COVID-19 // *Decision Analytics Journal*. – 2023. – Vol. 7. – P. 100246. – DOI: 10.1016/j.dajour.2023.100246.

11 Rafique Q. et al. Reviewing methods of deep learning for diagnosing COVID-19, its variants and synergistic medicine combinations // *Comput. Biol. Med.* – 2023. – Vol. 163. – P. 107191. – DOI: 10.1016/j.combiomed.2023.107191.

12 Rakhshan S.A., Nejad M.S., Zaj M., Ghane F.H. Global analysis and prediction scenario of infectious outbreaks by recurrent dynamic model and machine learning models: A case study on COVID-19 // *Comput. Biol. Med.* – 2023. – Vol. 158. – P. 106817. – DOI: 10.1016/j.compbimed.2023.106817.

13 Elhadary M. et al. Revolutionizing chronic lymphocytic leukemia diagnosis: A deep dive into the diverse applications of machine learning // *Blood Rev.* – 2023. – P. 101134. – DOI: 10.1016/j.blre.2023.101134.

14 Zhou L., Zhao C., Liu N., Yao X., Cheng Z. Improved LSTM-based deep learning model for COVID-19 prediction using optimized approach // *Eng. Appl. Artif. Intell.* – 2023. – Vol. 122. – P. 106157. – DOI: 10.1016/j.engappai.2023.106157.

15 Rajesh K., Sangeetha V. Application of data mining methods and techniques for diabetes diagnosis // *Int. J. Eng. Innov. Technol. (IJEIT)*. 2012. Sep.

16 Sarwar M.A., Kamal N., Hamid W., Shah M.A. Prediction of diabetes using machine learning algorithms in healthcare // *24th International Conference on Automation and Computing (ICAC)*. Newcastle Upon Tyne, United Kingdom, 2018. Pp. 1-6.

17 Lama L., Wilhelmsson O., Norlander E., Gustafsson L., Lager A., Tynelius P. Machine learning for prediction of diabetes risk in middle-aged Swedish people // *Heliyon*. 2021. Vol. 7, No. 7.

18 Bibault J.E., Giraud P., Burgun A. Big Data and machine learning in radiation oncology: Sostoyanie tekhniki i budushchie perspektivy // *Cancer Lett.* 2016. Vol. 382, No. 1. Pp. 110-117. DOI: 10.1016/J.CANLET.2016.05.033.

19 Zheng Jian, Xu Cencen, Zhang Ziang, Li Xiaohua. Electric load forecasting in smart grids using Long-Short-Term-Memory based Recurrent Neural Network // *2017 51st Annual Conference on Information Sciences and Systems (CISS)*. IEEE, 2017. Pp. 1-6. DOI: 10.1109/CISS.2017.7926112.

20 Zhou L., Pan S., Wang J., Vasilakos A.V. Machine learning on big data: Opportunities and challenges // *Neurocomputing*. 2017. Vol. 237. Pp. 350-361. DOI: 10.1016/j.neucom.2017.01.026.