

DOI: 10.51790/2712-9942-2024-5-2-12

КЛАССИФИКАЦИЯ СОСТОЯНИЯ ФИСТУЛЫ ПАЦИЕНТА, НАХОДЯЩЕГОСЯ НА ГЕМОДИАЛИЗЕ, С ИСПОЛЬЗОВАНИЕМ СПЕКТРАЛЬНЫХ ПРИЗНАКОВ АУДИОСИГНАЛА

С. А. Сазонов^а, Д. В. Горбунов^б

Сургутский государственный университет, г. Сургут, Российская Федерация

^а ✉ s.sazono23@gmail.com, ^б Gorbunov.dv@mail.ru

Аннотация: в современном мире пациентам, состоящим на гемодиализе, необходимо постоянно следить за состоянием своей фистулы либо самостоятельно, либо посещая специалиста. Это может вызывать определенные трудности у человека, так как у каждого может быть свое восприятие состояния артериовенозной фистулы. В статье представлена разработанная автором модель машинного обучения, позволяющего классифицировать фистулу. Также рассмотрены различные методы фильтрации признаков для использования этих обработанных данных в классификации состояния фистулы. Кроме этого, автором предложена новая методика с использованием спектральных признаков, позволяющих более точно определять состояние пациента, находящегося на гемодиализе.

Ключевые слова: артериовенозная фистула, классификация, гемодиализ, спектральный признак, аудиосигнал.

Для цитирования: Сазонов С. А., Горбунов Д. В. Классификация состояния фистулы пациента, находящегося на гемодиализе, с использованием спектральных признаков аудиосигнала. *Успехи кибернетики*. 2024;5(2):103–109. DOI: 10.51790/2712-9942-2024-5-2-12.

Поступила в редакцию: 10.03.2024.

В окончательном варианте: 31.03.2024.

CATEGORIZATION OF FISTULA CONDITION IN HEMODIALYSIS PATIENTS USING SPECTRAL ANALYSIS OF AUDIO SIGNALS

S. A. Sazonov^a, D. V. Gorbunov^b

Surgut State University, Surgut, Russian Federation

^a ✉ s.sazono23@gmail.com, ^b Gorbunov.dv@mail.ru

Abstract: patients on hemodialysis need to constantly monitor the condition of their fistula, either independently or by visiting a doctor. This can be challenging, as each person may perceive the condition of their arteriovenous fistula differently. In this paper, we present a machine learning model to categorize fistula conditions. We considered various feature filtering methods to enhance the accuracy of the categorization. Additionally, we proposed a new method using spectral features, which allows for a more precise determination of the condition of patients undergoing hemodialysis.

Keywords: arteriovenous fistula, categorization, hemodialysis, spectral feature, audio signal.

Cite this article: Sazonov S. A., Gorbunov D. V. Categorization of Fistula Condition in Hemodialysis Patients Using Spectral Analysis of Audio Signals. *Russian Journal of Cybernetics*. 2024;5(2):103–109. DOI: 10.51790/2712-9942-2024-5-2-12.

Original article submitted: 10.03.2024.

Revision submitted: 31.03.2024.

Введение

Одним из самых распространенных заболеваний в наше время является почечная недостаточность. Это прогрессирующее заболевание, которым страдает более 10% населения во всем мире, что составляет 800 миллионов человек [1]. При этой болезни пациенту назначается гемодиализ, в ходе которого ему в большинстве случаев проводят операцию по созданию артериовенозной фистулы. Артериовенозная фистула (АВФ) — это аномальная связь между артерией и веной, которая позволяет получить доступ к сосудистой системе.

На данный момент АВФ считается самым надежным видом сосудистого доступа для организации проведения периодического гемодиализа.

Преимущества АВФ заключаются в доступности, малом риске заболеваемости, связанной с ее созданием, низком уровне осложнений. Методика формирования подкожной АВФ на предплечье

была разработана и предложена в 1966 году М. J. Brescia и J. E. Cimino. Современная хирургическая техника создания АВФ предполагает различные виды сосудистого анастомоза артерии с веной: бок в конец; конец в конец; конец в бок. Предпочтительным является анастомозирование между веной и артерией по типу «конец вены в бок артерии». Фистула между лучевой артерией и головной веной в области запястья является сосудистым доступом первого выбора. При адекватном созревании она может функционировать годы с минимальным числом осложнений [2].

После успешной операции по формированию АВФ пациент наблюдает характерный шум потока. Так как от данной операции зависит успешность проведения диализной терапии, то важно поддерживать ее функциональность, учитывая возможные последствия. Все методы контроля, известные на текущее время, не позволяют пациенту находиться вне стационара. В настоящее время нет приборов, дающих больному возможность индивидуально проверять состояние фистулы, но идут активные попытки разработать устройство и алгоритмы для инвазионного мониторинга АВФ, которые будут рассмотрены в следующем разделе.

Одной из основных целей контроля состояния фистулы является наблюдение за развитием и прогрессированием стеноза, что увеличивает шанс возникновения тромбоза [3]. Это состояние возникает при травме, в ходе которой активизируется процесс свертывания крови (коагуляция). С помощью специальных клеток, тромбоцитов, организм формирует естественный защитный слой, препятствующий потере крови. Вследствие этого сгустки крови образуются внутри кровеносных сосудов, где они препятствуют нормальному току крови. Одним из способов проверить, достаточен ли кровоток через фистулу, является пальпация и аускультация фистулы, проще говоря, прослушивание так называемого «шума» [10].

Обзор литературы

Перед разработкой методики классификации состояния АВФ нами был проведен анализ различных исследований, которые так или иначе пытались решить данную проблему.

В работе Кейсуки Ота и других исследователей из Городской больницы Гамагори, Япония [4], использовалась CNN (сверточная нейронная сеть) — модель обучения для классификации состояния фистулы. В качестве входных данных были использованы звуки АВФ с частотой 192 кГц / 24 бита. Перед обучением в аудиофайлах был выделен звук фистулы в диапазоне частот 2–750 Гц для удаления посторонних шумов. Также для этих аудиосигналов были использованы сплайновые кривые, из которых извлекают несколько диапазонов выпуклых кривых длительностью 0,5–2 с, в течение которых звука фистулы не наблюдалось. В итоге был получен датасет из 4000 звуков, который классифицировали на 5 категорий (нормальный звук, резкий звук, высокий звук, прерывистый звук и свист). После обучения авторы отмечают, что точность обученной модели составляет 70–93%, и считают, что методы глубокого обучения с высокой точностью могут заменить аускультацию АВФ.

Исследователями из НИУ ВШЭ г. Москвы [5] используются два метода для определения «плохой» и «хорошей» фистулы. Первый метод включает в себя расчет позиции на плоскости «энтропия — сложность», в ходе которого вычисляются две характеристики (энтропии и сложности) для заданного временного ряда. Положение этих характеристик на соответствующей плоскости относительно верхних и нижних теоретических границ определяет тип ряда. Второй метод, предложенный авторами, строит граф понятий-объектов с использованием формального анализа понятий. Такие графы содержат вершины двух типов: соответствующие множеству объектов и содержащие подмножества атрибутов, характеризующих эти объекты. Для построения кластеров был использован алгоритм асинхронного распространения меток. Алгоритм кластеризации Wishart был применен для извлечения данных и успешно классифицирует обработанные данные на три категории: хорошее состояние фистулы, плохое и неопределенное. Также данные предварительно не обрабатывались, за исключением того, что запись проводилась в течение 20–30 секунд и в точке аускультации, расположенной на 2 сантиметра дистальнее артериовенозного анастомоза. Авторы считают, что оба эти подхода, как по отдельности, так и в сочетании, демонстрируют высокую диагностическую эффективность.

Авторы из Института инженеров по электротехнике и электронике, Аргентина [6], предлагают новый метод, который заключается в реализации линейно-фазового фильтра нижних частот с конечной импульсной характеристикой (частота среза фильтра 3 дБ при 200 Гц), который оценивают и вычитают дрейф базовой линии из звукового сигнала. Затем огибающая фильтруется с помощью фильтра нижних частот 5 Гц, и индекс максимального пика определяется для каждого импульса интервала

(сердцебиение), присутствующего в огибающей. Авторы предполагают, что максимальный пик каждого обнаруженного пульса во временной области соответствует первому систолическому пику пульсовой волны. Принимая это во внимание, максимальный пик используется в качестве контрольной точки, и считается, что фиксированная длительность 400 мс после максимального пика делает все обнаруженные импульсы одинаково длинными. В дальнейшем каждый обнаруженный импульс нормируется по энергии, и полученные данные обучаются в классификаторе SVM (метод опорных векторов). Данные предварительно, до обработки, дискретизируются до 2 кГц. В конце авторы утверждают, что при проведении межпациентного сравнения происходит падение точности классификации, и значимость результатов, и их влияние на медицину требуют дальнейшего изучения.

Марсин Грочовина из Университета Жешува, Польша [7], не предлагает принципиально нового метода, но выводит новые свойства, которые не были учтены в прошлых работах. Первое свойство — это свойство во временной области, основанное на разнице между максимальным и минимальным значениями огибающей сигнала. Чтобы получить сигнал огибающей, его выпрямляют и фильтруют с использованием фильтра нижних частот. После всех преобразований получают уравнение (1), где A_{max} — это максимальное значение огибающей сигнала и A_{min} — минимальное:

$$f_1 = \frac{A_{min}}{A_{max}}. \quad (1)$$

Из этого уравнения можно понять, что его значение для работоспособной фистулы будет выше, чем для суженной фистулы. Второе свойство получается из частотной области, для этого сигнал разделяют на фрагменты, которые соответствуют сердечному ритму. Затем преобразуют в частотную область с помощью быстрого преобразования Фурье. Для устранения утечки спектра использовано временное окно Хэмминга. Значения спектральной амплитуды в пределах этих делений суммируют и рассчитывают уравнение (2), где $FR1 = [125\text{Гц}, 175\text{Гц}]$ и $FR2 = [375\text{Гц}, 425\text{Гц}]$ — это временное окно Хэмминга для аудиосигнала:

$$f_2 = \frac{FR1}{FR2} = \frac{\sum_{f=125}^{175} f f t}{\sum_{f=375}^{425} f f t}. \quad (2)$$

Анализ сигналов, поступающих как от нормальных, так и от стенозированных фистул, показал, что в случае, когда фистулы стенозированы, значение фактора $FR2$ определено выше. Следовательно, значение свойства f_2 будет меньше, когда состояние фистулы будет лучше. После выведения новых свойств автором было проведено обучение при помощи метода k -ближайших соседей с точностью 81% и метода опорных векторов с точностью 85%. В конце исследователь отмечает, что данные методы могут применяться в задаче оценки состояния фистулы и позволяют получить относительно высокий коэффициент точности, но на основании полученных результатов нельзя сказать, какой из применяемых классификаторов будет лучшим.

По результатам анализа рассмотренных работ мы считаем перспективным проанализировать в качестве параметров модели спектральные признаки и Мел-кепстральные коэффициенты и применить модель машинного обучения при помощи метода случайного леса. Для решения этой задачи была выведена следующая схема классификации [10]:

1. Определение набора признаков.
2. Выделение признаков из аудиофайла.
3. Выделение наиболее важных признаков из всех.
4. Классификация обучающего набора.
5. Переобучение модели на выявленных ошибках при классификации на обучающем наборе.

Выделение признаков

В ходе работы было решено использовать различные спектральные признаки и коэффициенты, такие как:

- спектральный центроид — это мера, которая описывает «центр масс» спектра. Он используется для определения «яркости» или «тембра» звука;
- спектральный спад — это мера, которая описывает скорость уменьшения энергии в спектре после его пика. Это может быть полезно для определения характеристик звука, таких как его «грубость» или «мягкость»;

- спектральная ширина — это мера, которая описывает распределение энергии в спектре. Она может быть использована для определения «широты» или «узости» звука;
- Мел-кепстральные коэффициенты (MFCC). Они представляют собой набор коэффициентов, которые обобщают спектральную информацию звукового сигнала, преобразуя ее в более компактное и управляемое представление.

Данный выбор признаков обоснован тем, что они наиболее часто встречаются в решениях проблем классификации. Также, как известно, спектральные признаки являют собой список значений, поэтому данные были приведены к среднему арифметическому и определено стандартное отклонение к каждому признаку.

Обучение модели

Для обучения модели машинного обучения было решено использовать метод случайного леса.

В работах А. А. Турлая [10], О. С. Зайляповой [8] с соавторами были проверены различные подходы к классификации аудиосигналов. В исследовании А. А. Турлая с соавторами [10] были вычислены различные показатели, такие как среднее арифметическое значение элементов, средняя частота (медиана) и т. д. Впоследствии был выявлен явный волновой характер сигналов и, вычисляя количество пиков (волн) в каждом отдельном сигнале, можно было говорить о состоянии фистулы. В работе Д. А. Федорова с соавторами [9] применено обучение при помощи модели ANN (искусственная нейронная сеть), в котором используют несколько спектральных признаков, таких как спектральный центроид, спад спектра и т. п. По результатам обучения у данного автора была получена модель с точностью 84%. В исследовании О. С. Зайляповой с соавторами [8] были проведены сравнительный анализ различных методик обучения нейронных сетей и выявление самой точной из них. В данной работе сравнивались такие модели обучения, как метод случайного леса, метод опорных векторов, метод линейного дискриминантного анализа и т. д. В заключении автор исследования сообщает, что лучшим является метод случайного леса. Исходя из этой информации было решено использовать данный метод, так как он показал наилучший результат.

Выделение наиболее важных признаков

В ходе формирования признаков для модели машинного обучения было получено 47 позиций. Данное количество признаков вызывало переобучение у модели. Для решения этой проблемы было решено использовать 2 метода фильтрации и 1 встроенный метод. В качестве методов фильтрации был использован F-тест и хи-квадрат (X^2), в качестве встроенного метода использовался включенный в алгоритм машинного обучения метод случайного леса.

F-тест — это статистический тест, который используется для определения того, являются ли две или более групп статистически значимыми или нет. Для вычисления этих признаков можно использовать библиотеку `sklearn`, в которой есть метод `SelectKBest` с атрибутом `f_classif`. После использования этого метода был получен график, представленный на рисунке 1, где отображаются признаки и оценка их значимости.

Рассматривая этот график, можно сделать вывод, что для будущей модели будут важны 45 признаков из 47.

X^2 — это статистический тест, который используется для определения того, есть ли значимая связь между каждым неотрицательным признаком и целевой переменной. Чтобы вычислить данный тест, воспользуемся библиотекой `sklearn`, в которой есть метод `SelectKBest` с атрибутом `chi2`. Для визуализации полученных результатов был построен график, изображенный на рисунке 2. По сравнению с F-тестом, в данном методе было выделено 9 признаков, влияющих на обучение модели, из 47.

Также был использован встроенный в модель метод случайного леса. Важность признака в этом методе вычисляется следующим образом: во время обучения каждого дерева решений каждый раз, когда признак используется для разделения узла, учитывается улучшение качества разделения, которое этот признак обеспечивает. Это улучшение, среднее по всем деревьям леса, является мерой важности признака. В итоге формируется массив, элементы в котором суммируются до 1 и большие значения соответствуют более важным признакам. На рисунке 3 можно наблюдать визуализацию этого массива. Можно сделать вывод, что в целом все признаки могут влиять на обучение модели.

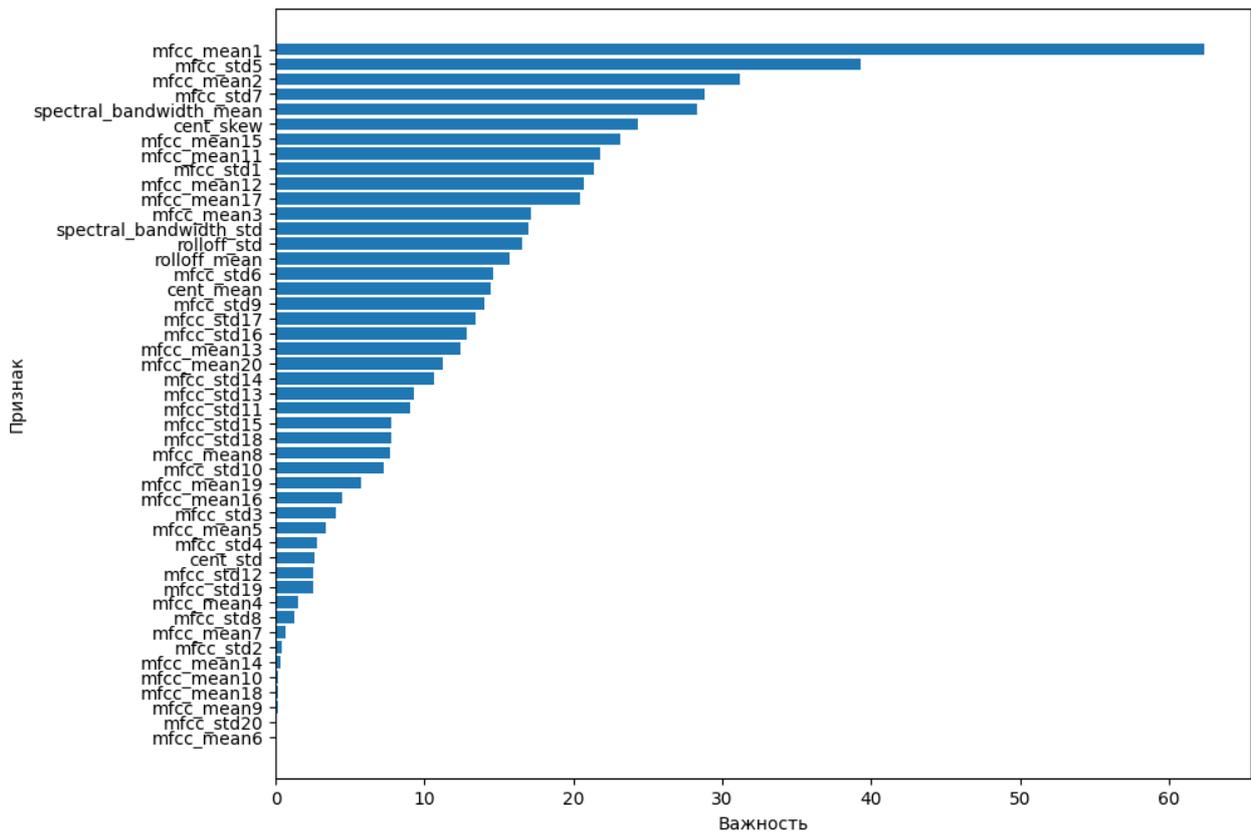


Рис. 1. Значимость признаков при использовании F-теста

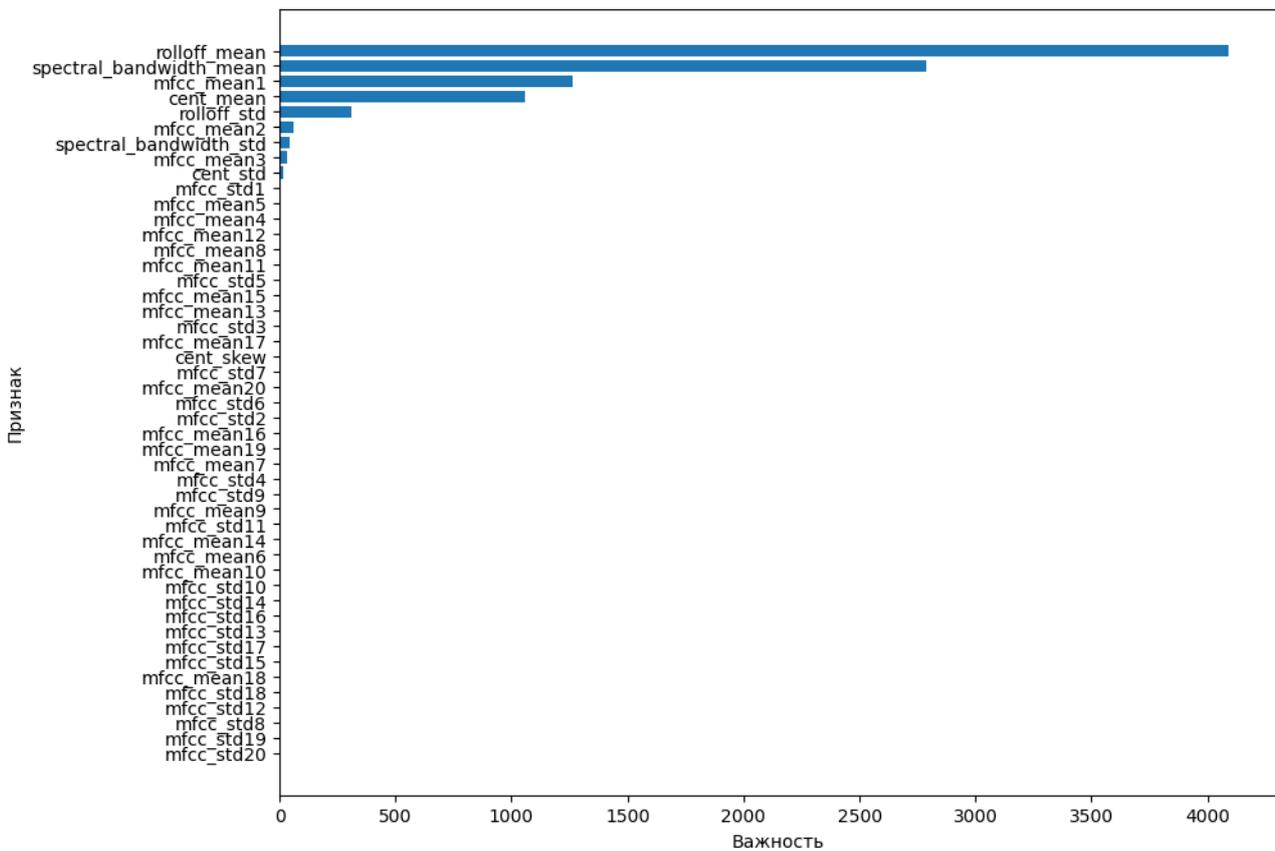


Рис. 2. Значимость признаков при использовании χ^2

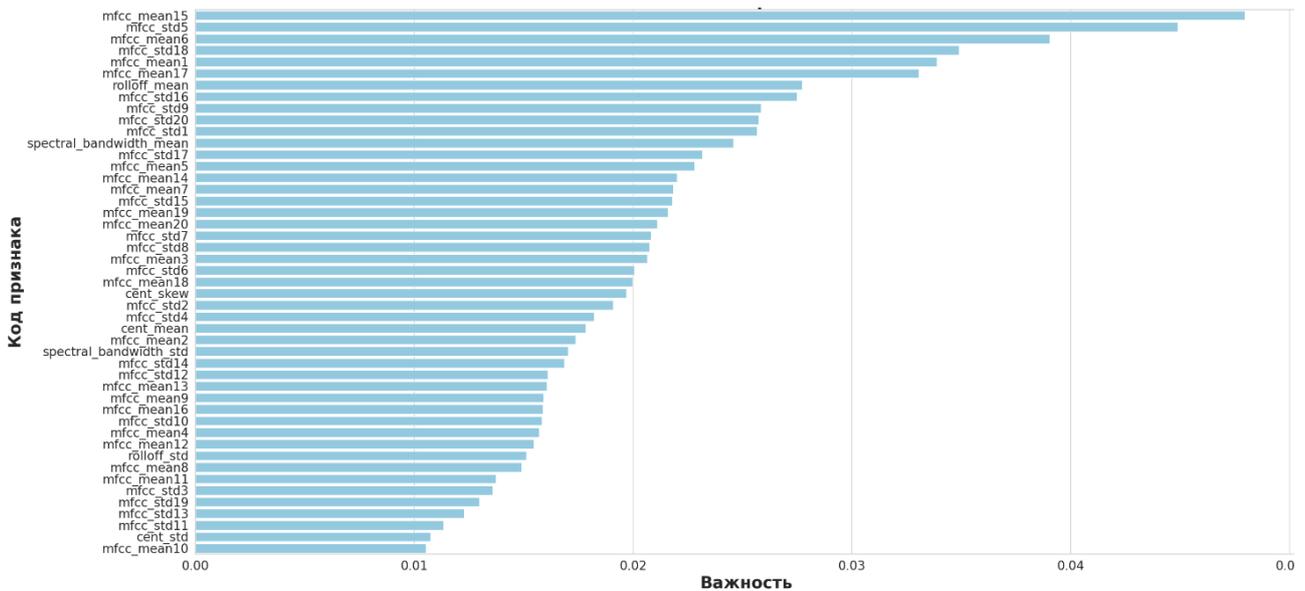


Рис. 3. Значимость признаков при использовании встроенного метода в *RandomForest*

Исходя из полученных выше результатов было решено провести серию экспериментов, которые могли бы выявить наиболее значимые признаки из всех методов, тем самым уменьшив количество признаков, необходимых для улучшения точности модели. Суть экспериментов следующая: перед каждым экспериментом нужно было в произвольном порядке перемешать значения признаков, далее обучать модель, добавляя по одному признаку из списка, и получать точность и количество признаков, которые использовались в обучении. Обучение продолжается до тех пор, пока не найдется самая высокая точность из всех. В итоге было проведено 3 серии экспериментов для каждого из методов. Исходя из полученных данных, были выделены результаты, которые обладали высокой точностью и меньшим количеством признаков. По итогам экспериментов была сформирована таблица, в которой отражаются результаты.

Таблица

Результаты экспериментов

Признаки	Random Forest	F-тест	X^2	Итого
mfcc_mean1	1	1	1	3
mfcc_mean2	0	0	1	1
mfcc_mean6	1	0	0	1
mfcc_mean15	1	0	0	1
mfcc_mean17	1	0	0	1
mfcc_std5	1	1	1	3
mfcc_std18	1	0	0	1
cent_mean	0	0	1	1
rolloff_mean	1	0	1	2
rolloff_std	0	0	1	1
spectral_bandwidth_mean	0	0	1	1

По данной таблице были выбраны более часто встречающиеся признаки, и в итоге был сформирован список из 3 признаков. В ходе проверки этих признаков было выяснено, что один из признаков негативно влиял на обучение модели, в итоге этот признак был исключен.

Полученный набор признаков позволил повысить точность модели с 89% до 93.87%.

Заключение

Построенная модель на основе метода случайного леса позволила на обучающей выборке, состоящей из 490 записей, проводить классификацию с точностью 93.87%. Также была разработана методика, которая позволяет из большого количества признаков выделить наиболее важные из них, тем самым не вызывая переобучения модели.

Нами также продолжается работа по увеличению обучающей выборки посредством новых аудиозаписей АВФ. Также в дальнейшем планируется проверить разработанную методику на других методах машинного обучения.

ЛИТЕРАТУРА

1. Kovesdy C. P. Epidemiology of Chronic Kidney Disease: an Update 2022. *Kidney International Supplements*. 2022;12(1):7–11. DOI: 10.1016/j.kisu.2021.11.003.
2. Коннер К. Сосудистый доступ для гемодиализа. *Нефрология*. 2009;13(4):9–17. Режим доступа: <https://cyberleninka.ru/article/n/sosudistyuy-dostup-dlya-gemodializa>.
3. Николаев Е. Н., Мазайшвили К. В., Лобанов Д. С., Демина А. В., Блохина А. В. Современное состояние проблемы тромбоза сосудистого доступа у больных на гемодиализе. *Вестник СурГУ. Медицина*. 2019;3:8–14. Режим доступа: <https://cyberleninka.ru/article/n/sovremennoe-sostoyanie-problemy-tromboza-sosudistogo-dostupa-u-bolnyh-na-gemodialize>.
4. Ota K., Nishiura Y., Ishihara S., Adachi H., Yamamoto T., Hamano T. Evaluation of Hemodialysis Arteriovenous Bruit by Deep Learning. *Sensors*. 2020;20:4852. DOI: 10.3390/s20174852.
5. Gromov V. A., Zvorykina E. I., Beschastnov Y. N., Sohrab M. *Date-Driven Approach for Identifying State of Hemodialysis Fistulas: Entropy-Complexity and Formal Concept Analysis*. Режим доступа: <https://arxiv.org/abs/2309.14399>.
6. Munguía M., Vásquez P., Mattsson E., Mandersson B. Acoustical Detection of Venous Stenosis in Hemodialysis Patients Using Principal Component Analysis. *Annual International Conference of the IEEE Engineering in Medicine and Biology; 2010*. P. 3654–3657. DOI: 10.1109/IEMBS.2010.5627439.
7. Grochowina M., Leniowska L. Comparison of SVM and k-NN Classifiers in the Estimation of the State of the Arteriovenous Fistula Problem. *Federated Conference on Computer Science and Information Systems*. 2015;5:249–254. DOI: 10.15439/2015F194.
8. Зайляпова О. С., Заикин П. В., Федоров Д. А. Модели исследования звуковых данных артериовенозной фистулы. *Наука, образование, инновации: актуальные вопросы и современные аспекты: сб. ст. XV Международ. научно-практич. конф. в 2 ч. Ч. 1*. Пенза: Наука и Просвещение (ИП Гуляев Г.Ю.); 2022. С. 55–57. Режим доступа: https://elibrary.ru/download/elibrary_50055026_53743111.pdf.
9. Федоров Д. А., Назина Н. Б., Кучин И. А. Преобразование и анализ сигнала АВ-фистулы в информационной системе мониторинга сосудистого доступа у больных на гемодиализе. *Современная наука и молодые ученые: Сб ст. XIII Международ. научно-практич. конф.* Пенза: МЦНС «Наука и просвещение»; 2023. С. 48–57. Режим доступа: <https://naukaip.ru/wp-content/uploads/2023/06/МК-1741.pdf>.
10. Турлай А. А., Заикин П. В., Назина Н. Б. Применение методов машинного обучения и анализа данных при оценке состояния фистулы. *Вестник кибернетики*. 2019;4:61–65. Режим доступа: <https://elibrary.ru/item.asp?id=42316208>.