

<https://doi.org/10.29188/2222-8543-2026-19-2-36-42>

Использование методов машинного обучения в интерпретации результатов урофлоуметрии

КЛИНИЧЕСКОЕ ИССЛЕДОВАНИЕ

И.О. Аванесян¹, Р.В. Строганов¹⁻³, И.О. Грицков^{3,4}, В.С. Афанасьева¹, А.С. Глигорич¹, И.А. Васютин⁵, А.А. Панин⁵, Г.Р. Касян^{1,3}, Д.Ю. Пушкар^{1,3}

¹ Российский университет медицины, Москва, Россия

² Научно-исследовательский институт организации здравоохранения и медицинского менеджмента Департамента здравоохранения города Москвы, Москва, Россия

³ Московский многопрофильный научно-клинический центр им. С.П. Боткина Департамента здравоохранения города Москвы, Москва, Россия

⁴ Российская медицинская академия непрерывного профессионального образования, Москва, Россия

⁵ МИРЭА – Российский технологический университет, Москва, Россия

Контакт: Аванесян Игорь Олегович, avanesyan.sci@gmail.com

Аннотация:

Введение. Урофлоуметрия (УФМ) является ключевым неинвазивным методом оценки функции нижних мочевых путей, однако ее интерпретация может быть субъективной и зависит от опыта врача, что приводит к разным результатам и осложняет диагностику нарушений нижних мочевых путей, связанных с возрастом, травмами и неврологическими заболеваниями.

Цель – продемонстрировать возможность применения машинного обучения в интерпретации УФМ, а также предложить оптимизированные алгоритмы на комбинированных данных и оценить их в проспективных исследованиях.

Материал и методы. Рассмотрены три подхода к классификации временных рядов: случайный лес на числовых признаках, одномерная сверточная нейронная сеть (ResNet-подобная архитектура) и двумерная сверточная сеть с преобразованием в матрицу Грэма (Inception-подобная архитектура). Обучающая выборка: всего 160 записей, тестовая – 40 (20%). Классифицированы 5 нозологий: нормальное мочеиспускание, доброкачественная гиперплазия предстательной железы, стриктура уретры, гиперактивный мочевой пузырь, гипоактивный мочевой пузырь.

Результаты. При использовании случайного леса и одномерной сети была показана точность классификации 77,5 и 87,5% соответственно, для двумерной – 82,5%. Одномерная сеть продемонстрировала наибольшее преимущество в выявлении паттернов кривых УФМ. Модели затруднились в дифференциации доброкачественной гиперплазии предстательной железы и стриктуры уретры из-за сходства обструктивных паттернов.

Заключение. Оценены три метода классификации: случайный лес на числовых признаках (точность классификации – 77,5%), одномерная сверточная ResNet-подобная нейронная сеть (87,5%) и двумерная с преобразованием в матрицу Грэма (82,5%) с использованием Inception-подобной архитектуры. Проведен сравнительный анализ эффективности методов, подтвердивший преимущество одномерных сверточных сетей в выявлении паттернов кривых УФМ, с рекомендациями по оптимизации для клинической практики и проспективных исследований.

Ключевые слова: урофлоуметрия; доброкачественная гиперплазия предстательной железы; стриктура уретры; гиперактивный мочевой пузырь; гипоактивный мочевой пузырь; сверточные нейронные сети.

Для цитирования: Аванесян И.О., Строганов Р.В., Грицков И.О., Афанасьева В.С., Глигорич А.С., Васютин И.А., Панин А.А., Касян Г.Р., Пушкар Д.Ю. Использование методов машинного обучения в интерпретации результатов урофлоуметрии. Экспериментальная и клиническая урология. 2026;19(2):36-42; <https://doi.org/10.29188/2222-8543-2026-19-2-36-42>

<https://doi.org/10.29188/2222-8543-2026-19-2-36-42>

The use of machine learning methods in the interpretation of uroflowmetry results

CLINICAL STUDY

I.O. Avanesyan¹, R.V. Stroganov¹⁻³, I.O. Gritskov^{3,4}, V.S. Afanaseva¹, A.S. Gligorich¹, I.A. Vasyutin⁵, A.A. Panin⁵, G.R. Kasyan^{1,3}, D.Yu. Pushkar^{1,3}

¹ Russian University of Medicine, Moscow, Russia

² Research Institute for Healthcare Organization and Medical Management of Moscow Healthcare Department, Moscow, Russia

³ S.P. Botkin City Clinical Hospital, Moscow, Russia

⁴ Russian Medical Academy of Continuous Professional Education, Moscow, Russia

⁵ MIREA – Russian Technological University, Moscow, Russia

Contacts: Igor O. Avanesyan, avanesyan.sci@gmail.com

Summary:

Introduction. Uroflowmetry (UFM) is a key noninvasive method for assessing lower urinary tract function; however, its interpretation is subjective and depends on the physician's experience, leading to varying results and complicating the diagnosis of lower urinary tract disorders associated with age, injuries, and neurological diseases.

The aim is to demonstrate the possibility of applying machine learning in the interpretation of UFM, as well as to propose optimized algorithms based on combined data and evaluate them in prospective studies.

Material and methods. Three approaches to time series classification were considered: random forest on numerical features, a one-dimensional convolutional neural network (ResNet-like architecture), and a two-dimensional convolutional network with transformation into a Gram matrix (Inception-like architecture). Training sample: a total of 160 records, test sample – 40 (20%). Five nosologies were classified: normal urination, benign prostatic hyperplasia, urethral stricture, overactive bladder, hyposensory bladder.

Results. For random forest, classification accuracy: for the one-dimensional network – 77.5% and 87.5%, for the two-dimensional – 82.5%. The one-dimensional network demonstrated the greatest advantage in identifying UFM curve patterns. The models had difficulty differentiating benign prostatic hyperplasia and urethral stricture due to the similarity of obstructive patterns.

Conclusion. Three classification methods were evaluated: random forest on numerical features (classification accuracy 77.5%), one-dimensional convolutional ResNet-like neural network (87.5%), and two-dimensional with transformation into a Gram matrix (82.5%), using an Inception-like architecture. A comparative analysis of the methods' effectiveness was conducted, confirming the advantage of one-dimensional convolutional networks in identifying UFM curve patterns, with recommendations for optimization in clinical practice and prospective studies.

Key words: uroflowmetry; benign prostatic hyperplasia; urethral stricture; overactive bladder; underactive bladder; convolutional neural networks.

For citation: Avanesyan I.O., Stroganov R.V., Gritskov I.O., Afanaseva V.S., Gligorich A.S., Vasyutin I.A., Panin A.A., Kasyan G.R., Pushkar D.Yu. The use of machine learning methods in the interpretation of uroflowmetry results. *Experimental and Clinical Urology*. 2026;19(2):36-42; <https://doi.org/10.29188/2222-8543-2026-19-2-36-42>

ВВЕДЕНИЕ

Урофлоуметрия (УФМ) – неинвазивный метод оценки функции нижних мочевых путей (НМП), измеряющий скорость потока мочи во время мочеиспускания. Этот тест ключевой в урологии для диагностики заболеваний, ассоциированных с дисфункцией НМП [1]. Несмотря на простоту, интерпретация субъективна и зависит от опыта врача, вызывая межнаблюдательную вариабельность.

Значимость проблемы подчеркивается растущей распространенностью нарушений НМП, связанных с возрастом, травмами, неврологическими заболеваниями и послеоперационными осложнениями [2–4]. Субъективность интерпретации УФМ приводит к неоднозначным результатам, что усложняет стандартизацию подходов и сравнение данных между клиниками. В итоге это влияет на эффективность терапии, включая фармакологическое лечение, хирургические вмешательства и реабилитацию, повышая риск осложнений и повторных обращений.

В последние годы наблюдается тенденция к интеграции машинного обучения (МО) и искусственного интеллекта (ИИ) для автоматизации анализа данных УФМ, что может снизить субъективность и повысить диагностическую точность [5]. МО позволяет обрабатывать многомерные данные, включая числовые параметры и временные ряды. U. Ishfaq и соавт. показывают, что логистическая регрессия, деревья решений, машины опорных векторов, случайный лес и глубокие нейронные сети демонстрируют потенциал в задаче многоклассовой классификации [6]. Тенденция к снижению инвазивности проявляется в разработке неин-

вазивных подходов, например, анализе акустических сигналов мочеиспускания с использованием нейронных сетей [7].

Помимо традиционных методов, для решения задач классификации временных рядов могут использоваться сверточные нейронные сети со специализированными архитектурами, такими как ResNet и Inception [8, 9].

В статье рассматриваются способы классификации с помощью моделей на основе случайных лесов, а также сверточных нейронных сетей с ResNet- и Inception-подобной архитектурой.

Цель исследования – продемонстрировать возможность применения МО в интерпретации УФМ, предложить оптимизированные алгоритмы на комбинированных данных и оценить их в проспективных исследованиях. Это стандартизирует диагностику заболеваний НМП, улучшит прогнозирование терапии и интегрирует ИИ в урологическую практику.

МАТЕРИАЛЫ И МЕТОДЫ

Сбор данных осуществляли путем ретроспективного анализа историй болезней, с дальнейшим извлечением диагнозов и формированием электронных таблиц. Диагнозы доброкачественной гиперплазии предстательной железы (ДГПЖ) и стриктура уретры устанавливали на основании ультразвуковой диагностики, уретроцистоскопии и данных анамнеза, а гиперактивного и гипоактивного мочевого пузыря – с помощью инвазивного уродинамического исследования. Сформирован набор урофлоуграм, состоящий из графиков и их числовых показателей. ■

Математическую и статистическую обработку данных, собранных в процессе исследования, выполняли с помощью программных пакетов Microsoft Excel и Stat-Tech.

В качестве исходных данных использовали результаты 200 УФМ. Показатели были взяты из базы данных 66 урологического отделения ГБУЗ «Московский многопрофильный научно-клинический центр им. С.П. Боткина». Каждой нозологии были присвоены классы, а именно: 0 – нормальное мочеиспускание; 1 – ДГПЖ; 2 – стриктура уретры; 3 – гиперактивный мочевой пузырь (ГАМП); 4 – гипоактивный мочевой пузырь. Статистические показатели для этих данных представлены в табл. 1.

В качестве тестовой выборки использовали случайные 20% данных общего числа урофлоуграмм ($n=40$). Распределение классов в тестовой выборке следующее: нормальное мочеиспускание – 5 случаев, ДГПЖ – 6, стриктура уретры – 10, ГАМП – 10, гипоактивный мочевой пузырь – 9 случаев.

Для оценки качества результатов классификации на тестовой выборке использовались метрики: общая точность (доля правильных предсказаний, 0–100%), коэффициент Каппа Коэна (от -1 до 1), macro-recall (средняя чувствительность, 0–100%), macro-precision (средняя доля правильно предсказанных положительных объектов из всех объектов, предсказанных как положительные, 0–100%), macro-F1 (гармоническое среднее precision и recall, 0–100%). Коэффициент Каппа Коэна предпочтителен, поскольку он учитывает случайные совпадения, делая оценку согласия более надежной в данных с нарушенным количественным балансом классов. В многоклассовых задачах классификации коэффициент легко обобщается и учитывает

все типы ошибок на основе матрицы несоответствий [9].

В процессе работы исследованы несколько подходов для классификации, использующих различные методы МО и различные варианты входных данных.

Первый метод основан на применении **алгоритмов случайного леса (Random Forest)** для классификации по числовым признакам кривых УФМ. Данный метод основан на совместном использовании нескольких более простых классификаторов, каждый из которых представляет собой дерево решений. Деревья независимо определяют принадлежность к тому или иному классу на основании простых правил, заранее определенных в процессе создания классификатора, а затем, их прогнозы объединяются для получения единственного, более точного результата. Каждое дерево обучается на случайной подвыборке из исходного набора данных и случайном подмножестве признаков, что позволяет снизить переобучение и повысить обобщающую способность модели в целом.

Второй метод использует в качестве классификатора **одномерную сверточную нейронную сеть (ResNet-подобная сеть)**, обрабатывающую данные временных рядов напрямую, что позволяет модели выявлять паттерны кривой временного ряда. Их изначальным предназначением является обработка изображений, но одномерный вариант можно использовать для анализа последовательных данных. Основным преимуществом сверточных нейронных сетей является способность находить скрытые закономерности и сложные взаимосвязи во входных данных без необходимости использования числовых показателей. При использовании данного метода в качестве временного ряда использовались числовые значения графиков УФМ.

Таблица 1. Средние показатели урофлоуметрии при различных нарушениях мочеиспускания
Table 1. Average uroflowmetry values for various urination disorders

Признак Диагноз	Нормальное мочеиспускание, $n=25$ Normal urination, $n=25$	ДГПЖ, $n=30$ ВРН, $n=30$	Стриктура уретры, $n=50$ Urethral stricture, $n=50$	ГАМП, $n=50$ ОАВ, $n=50$	Гипоактивный мочевой пузырь, $n=45$ Underactive bladder, $n=45$
Время мочеиспускания, с Total urination, sec	18,51±4,44	68,59±16,80	69,96 ±1 5,74	13,32 ±3,20	86,62±20,96
Максимальная скорость потока мочи, мл/с Qmax, ml/sec	27,39±4,43	8,87±2,19	7,03±1,63	33,96±4,65	10,43±2,62
Средняя скорость потока мочи, мл/с Qavg, ml/sec	21,57±7,59	4,54±2,00	3,70±1,40	23,56±4,79	5,58±2,15
Время до максимального потока, мл/с Time to Qmax, ml/sec	5,67±2,05	23,48±9,71	22,73 ±8,82	4,28 ±1,63	29,01±11,39
Объем мочеиспускания, мл Total urination volume, ml	375,32±86,09	286,17±64,64	243,86±60,03	185,24 ±43,64	447,42±92,61
Время ожидания начала мочеиспускания, с Waiting time for urination to begin, sec	6,24±2,26	73,69±29,35	88,81±39,74	4,54±1,93	90,19±38,46

Примечание. Здесь и далее: ДГПЖ – доброкачественная гиперплазия предстательной железы; ГАМП – гиперактивный мочевой пузырь
Note. Here and further: BPH – benign prostatic hyperplasia; OAB – overactive bladder

Третий метод использует **преобразование одномерного временного ряда в двумерное представление (матрицу Грэма) (Inception-подобная сеть)**, что открывает возможность использования существующих глубоких сверточных архитектур для повышения качества обучения модели МО. Исходные данные преобразуются в изображение с помощью метода Gramian Angular Field, заключающегося в представлении одномерных временных рядов в полярных координатах и построении на их основе матрицы Грэма [11–13].

Второй и третий методы, представляющие наибольший интерес, были реализованы следующими архитектурами: Inception-подобная (рис. 1, А), ResNet-подобная (рис. 1, Б) соответственно.

РЕЗУЛЬТАТЫ

Сравнение эффективности применяемых методов на тестовой выборке из 40 записей показало высокую точность классификации урофлоуметрических данных для всех трех подходов. Классический метод случайного леса, базирующийся на числовых признаках, продемонстрировал точность классификации – 77,5%. Визуализация производительности алгоритма случай-

ного леса для классификации урофлоуграмм представлена на рис. 2, А, где по вертикали представлены фактические значения классов, по горизонтали – предсказанные, а каждый элемент матрицы показывает количество пересечений фактического и предсказанного значения. Как видно из матрицы, алгоритм допустил наибольшее количество ошибок в классификации ДГПЖ и ГАМП. При классификации ДГПЖ допущено 4 ошибки, а при ГАМП – 3.

Наилучший результат был достигнут с использованием одномерной сверточной нейронной сети, показавшей точность классификации на уровне 87,5%, что свидетельствует о преимуществе глубокого обучения в выявлении сложных закономерностей в кривых урофлоуграмм, не всегда очевидных при ручном анализе или использовании числовых параметров. Результат классификации представлен в виде матрицы несоответствия на рис. 2, Б. Из матрицы видно, что модель справилась с классификацией ДГПЖ и ГАМП лучше, чем алгоритм случайного леса, количество ошибок снизилось на 2 для обоих классов.

Меньшую точность классификации показал метод с преобразованием исходных данных кривых в двумерное представление в сочетании с двумерной




Рис. 1. Архитектурные блоки: А – Inception-блок; Б – ResNet-блок
Fig. 1. Architectural blocks: А – Inception-block; Б – ResNet-block




Рис. 2. Матрицы несоответствий: А – случайный лес; Б – ResNet-подобная сеть; В – Inception
 Примечание: Норма – нормальное мочеиспускание; ДГПЖ – доброкачественная гиперплазия предстательной железы; Стриктура – стриктура уретры; ГАМП – гиперактивный мочевой пузырь; ГМП – гипоактивный мочевой пузырь
 Fig. 2. Confusion matrices: А – random forest; Б – ResNet-like network; В – Inception-like network
 Note: Normal – normal urination; BPH – benign prostatic hyperplasia; Stricture – urethral stricture; OAB – overactive bladder; OAB – underactive bladder

сверточной нейронной сетью. Полученный результат в 82,5% точности классификации может объясняться как избыточностью дополнительных преобразований, так и недостаточным объемом обучающей выборки для эффективного обучения двумерной архитектуры. Полученные результаты отражены в матрице несоответствия на рис. 2, В. Модель допустила ошибки в классификации стриктуры уретры и ГАМП, которых не было допущено моделью, использованной во втором методе. Количество ошибок составило 1 и 3 для стриктуры уретры и ГАМП соответственно.

Результаты эффективности различных моделей представлены в табл. 2.

Рассчитаны метрики: общая точность (accuracy), коэффициент Каппа Коэна (Cohen's Kappa), macro-recall, macro-precision и macro-F1 (табл. 3).

Интерпретация коэффициента Каппа Коэна (по шкале Landis and Koch, 1977): для случайного леса и Inception-подобной сети – существенное согласие (входит в интервал 0,61–0,80); для ResNet-подобной сети – почти идеальное согласие (входит в интервал 0,81–1,00).

ОБСУЖДЕНИЕ

Последние достижения в области функциональной урологии все чаще подчеркивают клиническую пользу искусственного интеллекта. Сравнивая полученные результаты с существующими исследованиями, можно отметить сходство с другими работами, посвященными применению ИИ в урологии. В исследовании Н. Sigva и соавт. продемонстрирована модель нейронной сети, которая показала выдающиеся диагностические возможности автоматизированной оценке УФМ: точность составила 92,5%, чувствительность – 90,0%, специфичность – 94,0%, а площадь под кривой ROC – 0,96 [14]. В исследовании Ö.B. Yücel и соавт. детские урологи классифицировали кривые УФМ на 5 паттернов в соответствии с классификацией International Children's Continence Society, а именно колоколообразные, башенные, платообразные, прерывистые, прерывистые колеблющиеся. Модель искусственного интеллекта продемонстрировала точность классификации 85,8% [15]. М.С. Choo и соавт. для разработки автоматизированной системы интерпретации результатов УФМ применили 4 алгоритма машинного обучения: логистическую регрессию, дерево решений, метод опорных векторов и алгоритм случайного леса и 2 алгоритма глубокого обучения: сверточную нейронную сеть и рекуррентную нейронную сеть. Данная модель автоматической интерпретации достигла точности классификации 88,9% для мужчин и 90,8% для женщин [16]. Также стоит отметить, что существует опыт создания моделей, которые используют данные не только уродинамического исследования, но иные источники

Таблица 2. Доля корректных предсказаний для каждого класса
Table 2. The proportion of correct predictions for each class

Класс Class	Случайный лес, % Random forest, %	ResNet-подобная сеть, % ResNet-like network, %	Inception-подобная сеть, % Inception-like network, %
Нормальное мочеиспускание Normal urination	100	80	100
ДГПЖ BPH	33,3	66,7	66,7
Стриктура уретры Urethral stricture	90	100	90
ГАМП OAB	70	90	70
Гипоактивный пузырь Underactive bladder	88,9	88,9	88,9

Таблица 3. Метрики качества результатов классификации на тестовой выборке
Table 3. Quality metrics for classification results on a test sample

Модель Model	Общая точность, % Accuracy, %	Коэффициент Каппа Козна Cohen's Kappa	Macro-recall, %	Macro-precision, %	Macro-F1, %
Случайный лес Random forest	77,5	0,713	76	83	75
ResNet-подобная сеть Resnet-like network	87,5	0,840	85	89	86
Inception-подобная сеть Inception-like network	82,5	0,778	83	85	82

информации. В работе Н. Shin и соавт. продемонстрирован опыт моделей, которые учитывали такие характеристики, как размер предстательной железы, параметры мочеиспускания и результаты анкетирования. Две модели были оценены с помощью ROC-анализа, показатели 0,826 и 0,819 соответственно [17]. Ряд авторов заявляют о создании моделей для оценки мочеиспускания на основе звуковых сигналов [7, 18, 19]. V.F. Tsai и соавт. разработали вибрационный урофлоуметр с интегрированным искусственным интеллектом. Точность постановки диагноза составила 97% [20].

Анализ современных работ подтверждает, что модели искусственного интеллекта демонстрируют высокую диагностическую ценность и хорошие перспективы для интеграции в урологическую практику.

ЗАКЛЮЧЕНИЕ

Оценены три метода классификации: случайный лес на числовых признаках (точность 77,5%), одномерная сверточная ResNet-подобная нейронная сеть (87,5%) и двумерная с преобразованием в матрицу Грэма (82,5%) с использованием Inception-подобной архитектуры. Сравнение эффективности методов подтвердило преимущество одномерных сверточных сетей в выявлении паттернов кривых УФМ, с рекомендациями по оптимизации для клинической практики и проспективных исследований. Проведенное исследование показывает потенциал использования ИИ в урологической практике. ■

ЛИТЕРАТУРА/REFERENCES

- Singla S, Garg R, Singla A, Sharma S, Singh J, Sethi P. Experience with uroflowmetry in evaluation of lower urinary tract symptoms in patients with benign prostatic hyperplasia. *J Clin Diagn Res.* 2014;8(4):NC01–NC03. <https://doi.org/10.7860/JCDR/2014/7909.4271>.
- Panicker JN, Fowler CJ, Kessler TM. Lower urinary tract dysfunction in the neurological patient: clinical assessment and management. *Lancet Neurol.* 2015;14(7):720–32. [https://doi.org/10.1016/S1474-4422\(15\)00070-8](https://doi.org/10.1016/S1474-4422(15)00070-8).
- Lucke-Wold B, Vaziri S, Scott K, Busl K. Urinary dysfunction in acute brain injury: A narrative review. *Clin Neurol Neurosurg.* 2020;189:105614. <https://doi.org/10.1016/j.clineuro.2019.105614>.
- Neurogenic Bladder and Neurogenic Lower Urinary Tract Dysfunction. StatPearls. URL: <https://www.ncbi.nlm.nih.gov/books/NBK560617/> (дата обращения: 02.11.2025).
- Arslan F, Algorabi O, Ozkan OC, Turkan YS, Namli E, Genc YE, et al. Artificial Intelligence-Based Analysis of Uroflowmetry Patterns in Children: A Machine Learning Perspective. *Neurourol Urodyn.* 2025;44(8):1575–82. <https://doi.org/10.1002/nau.70139>.
- Ishfaq U, Shabbir D, Khan J, Ullah Khan H, Naseer S, Irshad A, et al. Empirical analysis of machine learning algorithms for multiclass prediction. *Wireless Communications and Mobile Computing.* 2022; Article ID 7451152, 12 pages. <https://doi.org/10.1155/2022/7451152>.
- Alvarez ML, Arjona L, Jojoa-Acosta M, Bahillo A. Flow prediction in sound-based uroflowmetry. *Scient Rep.* 2025;15(1):643. <https://doi.org/10.1038/s41598-024-84978-w>.
- He K, Zhang X, Ren S, Sun J. Deep residual learning for image recognition. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA, 2016. P. 770–8. <https://doi.org/10.1109/CVPR.2016.90>.
- Szegedy C, Liu W, Jia Y, Sermanet P, Reed S, Anguelov D, et al. Going deeper with convolutions. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Boston, MA, USA, 2015. P.1–9. <https://doi.org/10.1109/CVPR.2015.7298594>.
- Cohen J. A coefficient of agreement for nominal scales. *Educational Psychol Measur.* 1960;20(1):37–46.
- Molina-Tenorio Y, Prieto-Guerrero A, Rodriguez-Colina E, Vázquez-Toledo L A, Olvera-Guerrero OA. Gramian angular field and convolutional neural networks for real-time multiband spectrum sensing in cognitive radio networks. *Sensors.* 2025;25(12):3580.

ЛИТЕРАТУРА/REFERENCES

- <https://doi.org/10.3390/s25123580>.
12. Abojeji ST, Wang X, Chen Y, Ahmad I, Li L, Liu Z, et al. Feature fusion of gramian angular field deep learning EEG-based Epileptic Seizure Classification. 17th International Convention on Rehabilitation Engineering and Assistive Technology (i-CREATE). IEEE, 2024. P. 1–6. <https://doi.org/10.1109/i-CREATE62067.2024.10776422>.
 13. Elmir Y, Himeur Y, Amira A. ECG classification using deep CNN and Gramian angular field. IEEE Ninth International Conference on Big Data Computing Service and Applications (BigDataService). IEEE, 2023; P. 137–41. <https://doi.org/10.48550/arXiv.2308.02395>.
 14. Şığva H, Duran A M, Deniz B, Körpe K, Sevim M. Artificial intelligence-assisted uroflowmetry and automated evaluation of lower urinary system symptoms. *Urologia*. 2026;93(2):275–84. <https://doi.org/10.1177/03915603251406813>.
 15. Yücel ÖB, Tekin A, Tiryaki S, Mutlu O, Mert A, Ulman İ. Artificial intelligence for objective assessment of pediatric uroflowmetry curves. *Urology*. 2025;206:125–30. <https://doi.org/10.1016/j.urology.2025.08.022>.
 16. Choo MS, Ryu HY, Lee S. Development of an automatic interpretation algorithm for uroflowmetry results: application of artificial intelligence. *Int Neurourol J*. 2022;26(1):69. <https://doi.org/10.5213/inj.2244052.026>.
 17. Shin H, Ko KJ, Park WJ, Han DH, Yeom I, Lee KS. Machine learning models for the noninvasive diagnosis of bladder outlet obstruction and detrusor underactivity in men with lower urinary tract symptoms. *Int Neurourol J*. 2024;28(Suppl. 2):S74. <https://doi.org/10.5213/inj.2448360.180>.
 18. Lee HJ, Aslim EJ, Balamurali BT, Ng LYS, Kuo TLC, Lin CMY, et al. Development and validation of a deep learning system for sound-based prediction of urinary flow. *Eur Urol Focus*. 2023;9(1):209–15. <https://doi.org/10.1016/j.euf.2022.06.011>.
 19. Song MH, Song J, Jung J, Lee S, Lee YJ. Comparison of sound-based urinary flow prediction methods and validation with a large clinical sample. 25th International Congress on Sound and Vibration 2018: Hiroshima Calling, ICSV 2018. International Institute of Acoustics and Vibration, IIAV, 2018/ P. 3605–11.
 20. Tsai VE, Tsai YC, Yang SS, Li MW, Pong YH, Tsai YT. An emerging trend of at-home uroflowmetry – designing a new vibration-based uroflowmeter with artificial intelligence pattern recognition of uroflow curves and comparing with other technologies. *Diagnostics*. 2025;15(14):1832. <https://doi.org/10.3390/diagnostics15141832>.

Сведения об авторах:

Аванесян И.О. – студент ФГБОУ ВО «Российский университет медицины» Минздрава России, Москва, Россия; РИНЦ Author ID: 1268300, <https://orcid.org/0009-0009-8542-4243>

Строганов Р.В. – к.м.н., ассистент кафедры урологии ФГБОУ ВО «Российский университет медицины» Минздрава России, ведущий специалист ГБУ «Научно-исследовательский институт организации здравоохранения и медицинского менеджмента» Департамента здравоохранения города Москвы, врач-уролог урологического отделения № 66 ГБУЗ «Московский многопрофильный научно-клинический центр им. С.П. Боткина», Москва, Россия; РИНЦ Author ID: 1074224, <https://orcid.org/0000-0002-5529-1787>

Грицков И.О. – младший научный сотрудник ГБУЗ «Московский многопрофильный научно-клинический центр им. С.П. Боткина», преподаватель кафедры медицинской техники ФГБОУ ДПО «Российская медицинская академия непрерывного профессионального образования» Минздрава России, Москва, Россия; РИНЦ Author ID: 1175027, <https://orcid.org/0000-0002-4708-1683>

Афанасьева В.С. – студент ФГБОУ ВО «Российский университет медицины» Минздрава России, Москва, Россия; <https://orcid.org/0009-0005-7160-2062>

Глигорич А.С. – студент ФГБОУ ВО «Российский университет медицины» Минздрава России, Москва, Россия; <https://orcid.org/0009-0005-9342-6434>

Васютин И.А. – магистрант кафедры индустриального программирования Института перспективных технологий и индустриального программирования, МИРЭА – Российский технологический университет, Москва, Россия; <https://orcid.org/0009-0003-0878-2430>

Панин А.А. – магистрант кафедры индустриального программирования Института перспективных технологий и индустриального программирования, МИРЭА – Российский технологический университет, Москва, Россия; <https://orcid.org/0009-0003-5745-4142>

Касян Г.Р. – д.м.н., профессор кафедры урологии ФГБОУ ВО «Российский университет медицины» Минздрава России, Москва, Россия; РИНЦ Author ID: 686514, <https://orcid.org/0000-0001-7919-2217>

Пушкар Д.Ю. – д.м.н., профессор, академик РАН, заведующий кафедрой урологии ФГБОУ ВО «Российский университет медицины» Минздрава России, Москва, Россия; РИНЦ Author ID: 417122, <https://orcid.org/0000-0002-6096-5723>

Вклад авторов:

Аванесян И.О. – концепция и дизайн исследования, написание текста, 15%
 Строганов Р.В. – концепция и дизайн исследования, 10%
 Грицков И.О. – редактирование текста, 5%
 Афанасьева В.С. – получение данных для анализа, 5%
 Глигорич А.С. – обработка полученных данных, 5%
 Васютин И.А. – реализация методов машинного обучения, написание текста, 15%
 Панин А.А. – реализация методов машинного обучения, редактирование текста, 15%
 Касян Г.Р. – концепция и дизайн исследования, критический обзор, 15%
 Пушкар Д.Ю. – научное руководство, 15%

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

Финансирование. Исследование выполнено при поддержке Автономной некоммерческой организации «Московский центр инновационных технологий в здравоохранении» в рамках гранта № 0703-2/23 от 16 июня 2023 года.

Статья поступила: 12.02.2026

Результаты рецензирования: 17.03.2026

Исправления получены: 04.04.2026

Принята к публикации: 15.04.2026

Information about authors:

Avanesyan I.O. – student, Russian University of Medicine, Moscow, Russia; RSCI Author ID: 1268300, <https://orcid.org/0009-0009-8542-4243>

Stroganov R.V. – PhD, Associate Department of Urology, Russian University of Medicine; Leading Specialist, Research Institute for Healthcare Organization and Medical Management of Moscow Healthcare Department, Urologist, Department of Urology №66, S.P. Botkin City Clinical Hospital, Moscow, Russia; RSCI Author ID: 1074224, <https://orcid.org/0000-0002-5529-1787>

Gritskov I.O. – junior researcher, S.P. Botkin City Clinical Hospital, Lecturer, Department of Medical Equipment, Russian Medical Academy of Continuous Professional Education, Moscow, Russia; RSCI Author ID: 1175027, <https://orcid.org/0000-0002-4708-1683>

Afanaseva V.S. – student, Russian University of Medicine, Moscow, Russia; <https://orcid.org/0009-0005-7160-2062>

Gligorich A.S. – student, Russian University of Medicine, Moscow, Russia; <https://orcid.org/0009-0005-9342-6434>

Vasyutin I.A. – Master's degree student, Department of Industrial Programming, Institute of Advanced Technologies and Industrial Programming, MIREA – Russian Technological University, Moscow, Russia; <https://orcid.org/0009-0003-0878-2430>

Panin A.A. – Master's degree student, Department of Industrial Programming, Institute of Advanced Technologies and Industrial Programming, MIREA – Russian Technological University, Moscow, Russia; <https://orcid.org/0009-0003-5745-4142>

Kasyan G.R. – Dr. Sci., Professor, Department of Urology Russian University of Medicine, Moscow, Russia; RSCI Author ID: 686514, <https://orcid.org/0000-0001-7919-2217>

Pushkar D.Yu. – MD, Dr. Sci. (Med.), Professor, Academy of the RAS, Head, Department of Urology, Russian University of Medicine, Moscow, Russia; RSCI Author ID: 417122, <https://orcid.org/0000-0002-6096-5723>

Authors' contributions:

Avanesyan I.O. – concept and design research, text writing, 15%
 Stroganov R.V. – concept and design of research, 10%
 Gritskov I.O. – editing and proofreading, 5%
 Afanaseva V.S. – obtaining data, 5%
 Gligorich A.S. – processing of obtained data, 5%
 Vasyutin I.A. – implementation of machine learning methods, text writing, 15%
 Panin A.A. – implementation of machine learning methods, editing and proofreading, 15%
 Kasyan G.R. – concept and design research, critical review, 15%
 Pushkar D.Yu. – scientific supervision, 15%

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

Financing. The study was supported by the Autonomous Non-Profit Organization «Moscow Center for Innovative Technologies in Healthcare» under grant No. 0703-2/23 dated June 16, 2023.

Received: 12.02.2026

Peer review: 17.03.2026

Corrections received: 04.04.2026

Accepted for publication: 15.04.2026