

## МАШИННОЕ ОБУЧЕНИЕ В ЗАДАЧЕ ПРОГНОЗИРОВАНИЯ ПАРАМЕТРОВ УПРУГОСТИ ТКАНЕИМИТИРУЮЩИХ ФАНТОМОВ МЯГКИХ БИОЛОГИЧЕСКИХ ТКАНЕЙ

Л.И. Семенов<sup>1,2</sup>

semenov.li@phystech.edu

А.Е. Крупнин<sup>1,3</sup>

artkrupnin@gmail.com

К.Г. Антипова<sup>1</sup>

antipova.cg@gmail.com

Т.Е. Григорьев<sup>1,2</sup>

timgrigo@yandex.ru

<sup>1</sup> НИЦ «Курчатовский институт», Москва, Российская Федерация

<sup>2</sup> МФТИ, Москва, Российская Федерация

<sup>3</sup> МГТУ им. Н.Э. Баумана, Москва, Российская Федерация

---

### Аннотация

Гидрогели представляют собой трехмерные полимерные сетки, в которых узлами выступают химические или физические сшивки между макромолекулами. В настоящее время гидрогели на основе полиакриламида являются перспективными материалами для изготовления тканеимитирующих фантомов мягких биологических тканей. Ключевое преимущество таких гидрогелей — возможность регулирования их механических свойств за счет варьирования концентрации сшивателя, т. е. числа сшивок, что позволяет имитировать характеристики различных органов и тканей. Однако подбор концентрации сшивателя для создания фантомов с заданными характеристиками представляет собой сложную задачу, требующую значительных временных и вычислительных ресурсов. Алгоритмы машинного обучения могут определять корреляцию между концентрацией сшивки и параметрами упругости полученного гидрогеля. На основе двух алгоритмов «случайный лес» реализована модель машинного обучения, способная прогнозировать механические свойства тканеимитирующих фантомов. Алгоритмы обучены на основе синтетических данных, полученных в результате проведения численных экспериментов на индентирование в лицензионном программном обеспечении для конечно-элементного анализа *ANSYS Workbench* (Ansys Inc., США), с применением как линейно-упругой модели поведения материала, так и гиперупругих

### Ключевые слова

*Машинное обучение, случайный лес, тканеимитирующие фантомы, гидрогель, полиакриламид, индентирование, конечно-элементное моделирование, модели гиперупругости*

неогуковской модели и модели Муни — Ривлина, а также на данных натуральных экспериментов. Предсказания валидированы с помощью тестовых данных, составивших 30 % всего массива данных и не использованных в обучении алгоритмов, а также на результатах натуральных экспериментов

Поступила 04.03.2025  
Принята 30.06.2025  
© Автор(ы), 2025

---

*Работа выполнена в рамках государственного задания  
НИЦ «Курчатовский институт»*

**Введение.** Материалы, способные воспроизводить механические свойства биологических тканей человека, широко применяют в медицинских исследованиях, позволяя проводить отработку режимов и калибровку нового оборудования, обучать персонал и разрабатывать методы диагностики без использования кадаверных тканей [1]. Проведение испытаний на таких материалах, известных как тканеимитирующие фантомы (tissue-mimicking phantoms), позволяет, с одной стороны, уменьшить или избежать использования реальных органов, с другой, — повысить воспроизводимость экспериментов [2].

В медицинских исследованиях тканеимитирующие фантомы используют для построения моделей поведения тканей человека в условиях, диктуемых методами диагностики или стратегиями лечения заболеваний [3–7]. В частности, их применяют при моделировании траектории движения хирургических и биопсийных игл [8]. Кроме того, эти материалы находят применение в исследованиях, основанных на методах медицинской визуализации (компьютерной томографии [9], магнитно-резонансной томографии [10], однофотонной эмиссионной компьютерной томографии [11], позитронно-эмиссионной томографии [12]). Для обучения медицинского персонала инвазивным процедурам без риска для здоровья пациентов или животных используют фантомы из гидрогелей различной природы, поскольку такие материалы имеют необходимые свойства несжимаемости и вязкоупругости [13].

При разработке тканеимитирующих фантомов мягких биологических тканей широко используют гидрогели на основе природных или синтетических полимеров [14, 15], в частности полиакриламида (ПААМ). Гидрогели удобны для имитации мягких тканей вследствие способности удерживать большое количество воды и воспроизводить механические свойства, приближенные к тканям человека.

Полиакриламидные гидрогели получают свободнорадикальной полимеризацией мономера (акриламида) в присутствии сшивателя (N,N'-ме-

тиленбисакриламида). Такие гели могут имитировать упругость различных мягких тканей и сохранять свойства в течение длительного времени, безопасны при работе. Важная особенность — варьирование механических свойств получаемого гидрогеля в соответствии с концентрацией сшивателя [16]. Фантом кожи с повышенной прочностью на основе ПААм и оксида графена предложен в [17]. Гидрогель из ПААм для изготовления стандартизированных фантомов, имитирующих световые и звуковые свойства живых тканей, описан в [18]. Полученные образцы использованы для тестирования трех различных систем фотоакустической визуализации, что помогло оценить разрешение и глубину визуализации. Кроме того, в [19] ПААм использованы при разработке фантомов здоровых тканей молочной железы и аналогичных тканей, пораженных раковой опухолью. Установлено, что тканеимитирующие фантомы из ПААм совместимы с методами ультразвуковых исследований для локализации границ новообразований.

Определение параметров упругости и исследование особенностей механического поведения гидрогелей являются важными задачами при разработке и испытаниях тканеимитирующих фантомов. Механические свойства этих материалов связаны с математическими моделями, описывающими их поведение при деформации. Так, в [20] применены трехпараметрическая модель Муни — Ривлина и модель Гента второго порядка для исследования механического отклика агарозных гелей. Следует отметить, что параметры, используемые во многих моделях высокого порядка, часто не имеют физического смысла, поскольку определяются эмпирически по результатам одного или нескольких экспериментов или не универсальны для гелей различной природы ввиду ограничений применимости, накладываемых термодинамическими теориями, лежащими в основе модели. На практике для определения механических свойств фантомов мягких тканей чаще прибегают к натурным экспериментам и к конечно-элементному анализу, применение которого позволяет получить достоверные данные при проведении верификации полученных результатов и сократить число испытываемых образцов. Современные экспериментальные методы определения параметров упругости гидрогелей описаны в [21]. Метод конечных элементов в [22] применен в качестве основного инструмента моделирования для анализа деформаций, возникающих в процессе 3D-печати скаффолдов из альгинатных гидрогелей. Экспериментальные методы определения параметров упругости требуют значительных временных ресурсов не только на подготовку образцов и проведение испытаний, но и на подбор технологических параметров получения гидрогелей с заданными механическими свойствами,

в частности концентрации сшивателя. Для решения этой проблемы в настоящее время находят применение алгоритмы машинного обучения, способные предсказывать механические свойства гидрогелей с высокой точностью и скоростью, даже если данные о конкретном образце недоступны. Две нейронные сети для прогнозирования соответствия между механическими свойствами гидрогеля и массовой концентрацией желатина в гидрогеле, варьируемой в диапазоне значений 5...20 %, предложены в [23]. Испытания, данные о которых не использованы при обучении, показали, что модель из двух нейросетей способна предсказывать механический отклик гидрогеля в испытании на индентирование с высокой точностью. Нейронная сеть для выявления зависимости полимерной структуры гидрогеля, смоделированной математически пространственной конфигурацией полимерных цепей и узлов на основе метода SAW (Self-Avoiding Walk), от его механических свойств применена в [24]. Параметры упругости гидрогеля в [25] предсказаны нейронной сетью, обученной на сгенерированных изображениях микроструктуры и результатах численных экспериментов в программном комплексе *Abaqus/Explicit* (Dassault Systemes, Франция).

С учетом изложенного определение механических свойств гидрогелей является актуальной проблемой в сфере биомедицинских технологий. Создание модели машинного обучения для прогнозирования механических свойств гидрогелей на основе концентрации сшивателя позволит значительно сократить число натурных испытаний и упростить процесс получения гидрогелей для разработки фантомов мягких тканей. Для решения этой задачи предложена модель машинного обучения, основанная на двух последовательно работающих алгоритмах «случайный лес» (СЛ). Модель может определять соответствие между параметрами упругости гидрогелей из ПААм и концентрацией сшивателя. При обучении алгоритмов использованы синтетические данные, сгенерированные в результате проведения численных испытаний в конечно-элементном комплексе *ANSYS Workbench* (Ansys Inc., США), и результаты натурального эксперимента. Первый алгоритм, обученный на синтетических данных, предсказывает силовые реакции, возникающие при индентировании гидрогеля, в зависимости от диаметра сферического индентора, глубины его вдавливания и параметров упругости образца. Второй алгоритм, обученный на данных натуральных экспериментов, предсказывает концентрации сшивающего агента на основе силовой реакции, полученной от первого алгоритма, диаметра сферического индентора и глубины вдавливания. Таким образом, при последовательной работе двух алгоритмов устанавливается связь между параметрами

упругости гидрогеля и концентрациями сшивающего агента. Для описания механического поведения материала в численных экспериментах использованы линейно-упругая модель (для малых деформаций) и нелинейные гиперупругие модели (неогуковская и двухпараметрическая модель Муни — Ривлина). Гиперупругие модели выбраны на основе того, что параметры этих моделей имеют связь с модулем сдвига и не требуют проведения дополнительных испытаний, в отличие от моделей более высоких порядков. Предсказания алгоритмов валидированы в соответствии с 30 % зарезервированных данных, не использованных при обучении, и на результатах натуральных экспериментов.

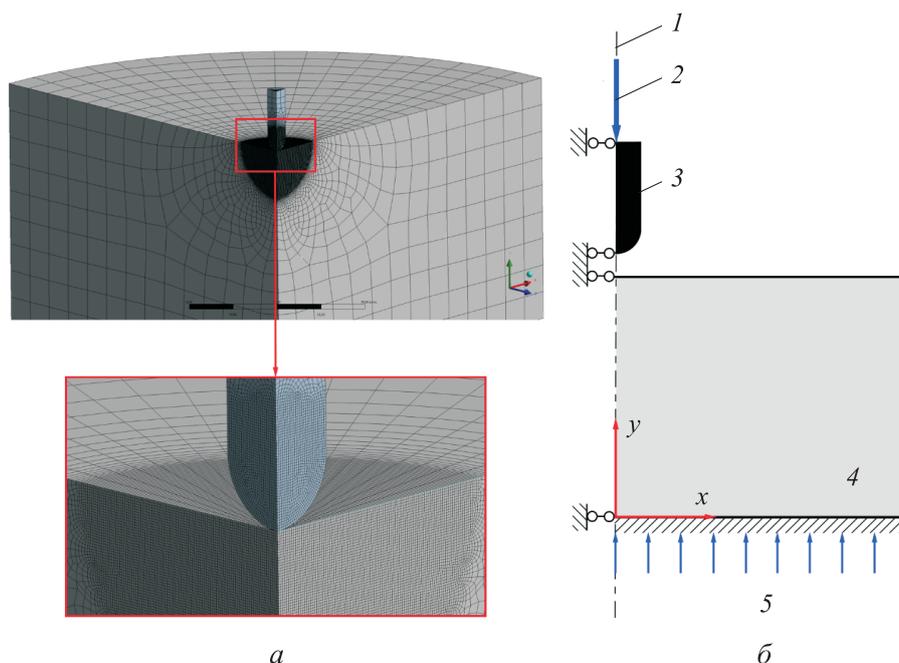
**Материалы и методы решения задач, принятые допущения.** *Конечно-элементное моделирование.* Проведение серии численных экспериментов на индентирование позволило получить необходимый объем данных для обучения первого алгоритма СЛ. Численные эксперименты реализованы с помощью метода конечных элементов в программном комплексе *Ansys Workbench* (Ansys Inc., США). Контактная задача решена в осесимметричной постановке, тип конечного элемента (КЭ) PLANE182. Такой подход уменьшает число используемых КЭ, что позволяет сократить время проведения одного расчета. При построении сетки КЭ (рис. 1, а) число элементов и узлов составило 10 019 и 10 216 с учетом сгущения в зоне контакта. Такая особенность сетки позволяет моделировать образцы достаточно большого размера, чтобы не учитывать влияние краевых эффектов, без потери точности и эффективности расчета. Контактная задача решена с применением расширенного метода Лагранжа в предположении отсутствия трения. Это итеративный алгоритм, который оптимизирует взаимодействие между поверхностями, минимизируя проникание одной поверхности в другую, что важно для точных результатов при моделировании деформаций и напряжений. В экспериментах использованы два сферических индентора диаметрами 5 и 10 мм. Вдавливание проведено на глубину, равную радиусу индентора. Материал индентора предполагали абсолютно жестким. Для воспроизведения свойств гидрогеля, кроме линейно-упругой модели материала, использованы неогуковская модель и двухпараметрическая модель Муни — Ривлина.

Неогуковская модель гиперупругого материала — одна из простейших моделей для описания поведения гидрогелей. В случае несжимаемого материала упругий потенциал может быть представлен в виде  $W = (G/2)(I_1 - 3)$ , где  $G$  — модуль сдвига;  $I_1 = \lambda_1^2 + \lambda_2^2 + \lambda_3^2$  — первый инвариант тензора меры деформации Коши — Грина [26].

Модель Муни — Ривлина является расширением неогуковской модели и одной из наиболее используемых моделей для описания гиперупругого поведения материалов. В случае несжимаемого материала упругий потенциал двухпараметрической модели имеет вид

$$W = C_{01} (I_1 - 3) + C_{10} (I_2 - 3),$$

где  $C_{01}$ ,  $C_{10}$  — определяемые экспериментально константы материала;  $I_1 = \lambda_1^2 + \lambda_2^2 + \lambda_3^2$ ,  $I_2 = \lambda_1^2 \lambda_2^2 + \lambda_1^2 \lambda_3^2 + \lambda_2^2 \lambda_3^2$ ,  $I_1$ ,  $I_2$  — первый и второй инварианты тензора меры деформации Коши — Грина [26]. Модуль сдвига связан с константами модели:  $G = 2(C_{10} + C_{01})$ . Поскольку гидрогели — несжимаемые материалы, коэффициент Пуассона в расчетах принят равным  $\mu = 0,49$ . Значения модулей упругости и сдвига выбраны в диапазоне 0,5...300 и 0,16...100 кПа соответственно, что коррелирует с аналогичными значениями для мягких тканей человека [27].



**Рис. 1.** Объемное представление

сетки конечных элементов (а) и схема численного эксперимента (б):

1 — ось симметрии; 2 — приложенное перемещение; 3 — индентор; 4 — образец;  
5 — область вычисления силовой реакции

Граничные условия, использованные при решении контактной задачи, показаны на рис. 1, б. Нижняя поверхность образца закреплена по всем степеням свободы, применена плоская осевая симметрия, ось которой сов-

падает с осью координат  $y$ . К верхней поверхности индентора приложено линейное перемещение  $U$ . Силовая реакция, возникающая при индентировании, вычисляется на нижней поверхности образца. Для автоматизации процесса проведения численных экспериментов написан скрипт на языке APDL (Ansys Parametric Design Language), позволяющий в процессе расчета вычислять силовые реакции в каждом узле нижней поверхности образца, суммировать их и записывать в отдельный csv-файл, из которого будут формироваться выборки для обучения алгоритмов СЛ.

*Получение образцов гидрогелей на основе ПААм.* Экспериментальные образцы гидрогелей из ПААм получены методом свободнорадикальной полимеризации [28]. В 20%-ный раствор мономера, акриламида, добавляли сшиватель (N-N'-метиленабисакриламид) и систему-инициатор (персульфат аммония + N,N,N'N'-тетраметилэтилендиамин). Итоговые образцы для испытаний на индентирование имели форму цилиндра диаметром 50 мм и высотой 30 мм. Образцы для испытаний на одноосное растяжение в форме лопаток с размерами рабочей части 10 × 20 мм сразу после синтеза вырубали ножом. Затем образцы погружали в деионизованную воду для удаления непрореагировавших компонентов, а также для достижения ими равновесной степени набухания. Испытания проводили для равновесно набухших образцов. Размер образца варьировался в зависимости от степени его сшивки (чем более сшит образец, тем менее он набухает). Для каждой степени сшивки изготавливали соответствующую размерам набухшего образца оснастку для проведения испытаний [29]. В рамках настоящей работы получены образцы с концентрациями сшивки  $\alpha = \{0,5; 0,7; 1; 1,5; 2; 4; 5; 9; 11 \%$  }.

**Постановка натуральных экспериментов.** *Индентирование.* Вторым алгоритмом СЛ обучен на основе данных, полученных в результате проведения испытаний на индентирование образцов ПААм. Эксперименты выполнены на универсальной испытательной машине *Instron 5965* (Illinois Tool Works Inc., США) при температуре 23 °С и постоянной скорости деформирования 1 мм/мин. Зарегистрирована зависимость силовой реакции  $F$  от глубины вдавливания  $U$ .

*Одноосное растяжение.* Для определения модулей упругости проведена серия испытаний на одноосное растяжение. Эксперименты проводили на универсальной испытательной машине *Instron 5965* (Illinois Tool Works Inc., США) при температуре 23 °С и постоянной скорости деформирования 1 мм/мин. Зарегистрирована зависимость напряжения от относительной деформации. Модуль Юнга для каждого образца определяли по наклону

начального участка кривой зависимости напряжений от деформаций. Полученные результаты представлены ниже (выборка — по трем образцам):

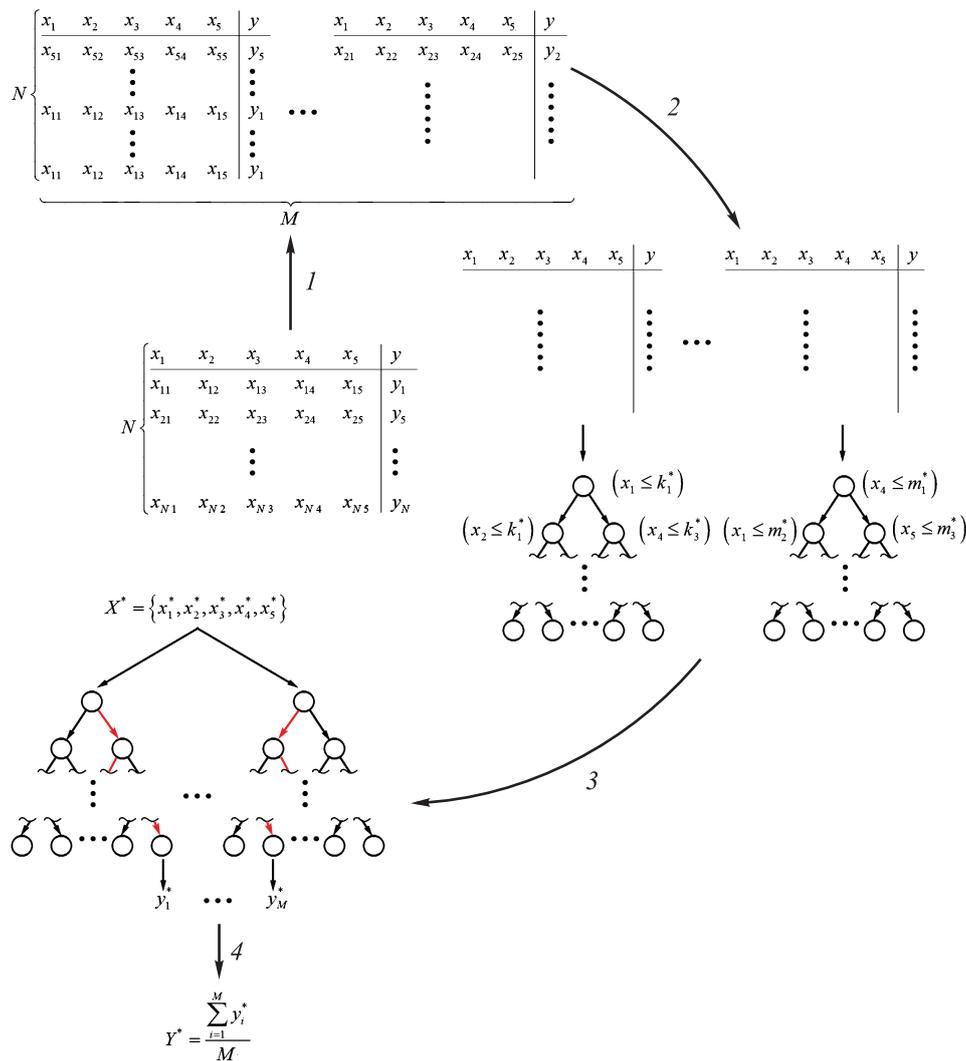
Концентрация швивателя, % ...	0,5	1	1,5	2	4	5	9	11
Модуль Юнга, кПа .....	16 ± 2	19 ± 2	31 ± 3	56 ± 7	75 ± 5	105 ± 44	157 ± 5	196 ± 23

**Алгоритм «случайный лес».** Алгоритм машинного обучения СЛ — один из наиболее эффективных и удобных инструментов для решения задач классификации и регрессии [30]. Алгоритм СЛ представляет собой ансамблевый метод, в основе которого лежит построение множества алгоритмов решающего дерева и усреднение результатов их предсказаний для получения окончательного прогноза.

Решающие деревья — семейство моделей машинного обучения, применяемых для предсказания целевой переменной на основе последовательности решающих правил (предикатов). Структурно любое дерево состоит из корня (входной вершины), узлов (ветвлений) и листовых вершин, в которых хранятся предсказания. Каждое решающее дерево обучается на подмножестве, полученном случайной выборкой с возвращением из исходного массива. Таким образом, возможно как повторение элементов исходных данных, так и отсутствие некоторых элементов в новой выборке. Такой подход необходим для обеспечения уникальности каждого дерева, что в свою очередь снижает вероятность переобучения модели.

В контексте задачи регрессии алгоритм СЛ можно представить в виде схемы (рис. 2). На первом этапе проиллюстрировано разделение исходной обучающей выборки на подмножества с возвращениями, где один и тот же элемент может быть выбран несколько раз. Начальный массив данных представлен в виде таблицы из пяти признаков ( $X_1, X_2, X_3, X_4, X_5$ ) и  $N$  наблюдений. Каждому наблюдению и его признакам ставится в соответствие целевое значение  $y$ . После завершения разделения получено  $M$  таблиц с таким же числом наблюдений, как и в исходном массиве, но расположенных в случайном порядке и с повторениями. На втором этапе на основе каждой подвыборки обучается  $M$  уникальных решающих деревьев методом сравнения признаков в наблюдениях с пороговыми значениями ( $k^*, t^*$ ) предикатов. На третьем этапе всем решающим деревьям подается на вход новый вектор признаков  $X^*$ , после чего алгоритмы, работая параллельно, выносят независимые предсказания ( $y_1^*, y_M^*$ ). На четвертом этапе происходит усреднение значений, полученных от решающих деревьев, и вынесение окончательного предсказания модели  $Y^*$ .

В рамках работы использованы два алгоритма СЛ, реализованные с помощью библиотеки программного обеспечения sklearn. При обучении первого алгоритма применяли синтетические данные, полученные в результате проведения численных экспериментов на индентирование. Вторым алгоритмом обучен на основе экспериментальных данных, полученных по результатам натуральных экспериментов по индентированию образцов из гидрорагеля с варьированием концентрации сшивающего агента в пределах 0,5...11 %.



**Рис. 2.** Схема алгоритма СЛ:

- 1 — создание подмножеств обучающих данных;
- 2 — построение решающих деревьев;
- 3 — получение прогнозов от всех деревьев;
- 4 — усреднение прогнозов для окончательного предсказания

**Способ взаимодействия алгоритмов машинного обучения.** Схема двух алгоритмов машинного обучения СЛ показана на рис. 3. Для первого алгоритма сгенерированы три независимые обучающие выборки с разными параметрами упругости гидрогеля в соответствии с моделями поведения материала в численных экспериментах: для линейно-упругой модели — модуль Юнга  $E$ , для неогуковской — модуль сдвига  $G$ , для двухпараметрической модели Муни — Ривлина — константы материала  $C_{01}$ ,  $C_{10}$ . Кроме того, в каждой обучающей выборке первого алгоритма есть признаки: глубина вдавливания  $U$  и диаметр индентора  $D$ . Целевым значением, предсказываемым алгоритмом, является силовая реакция  $F$ . В массиве экспериментальных данных, полученных для обучения второго алгоритма, признаками являются глубина  $U$ , диаметр использованного индентора  $D$  и силовая реакция  $F$ . Целевое значение — концентрация сшивателя  $\alpha$ . Для исследованных образцов параметр  $\alpha$  принимал следующие значения, %: 0,5; 0,7; 1; 1,5; 2; 4; 5; 9; 11. После завершения обучения второй алгоритм может использовать силовые реакции, полученные от первого алгоритма, тем самым устанавливая соответствие между параметрами упругости и концентрацией сшивателя гидрогеля.

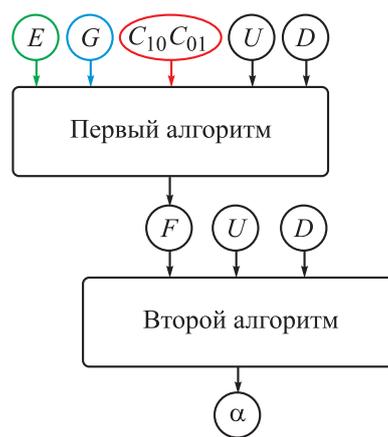


Рис. 3. Схема взаимодействия алгоритмов

Для повышения качества предсказаний проведена оптимизация гиперпараметров подбором «настроек» модели. Для первого и второго алгоритмов использованы гиперпараметры, приведенные ниже:

Число решающих деревьев .....	400
Максимальная глубина деревьев .....	11
Минимальное число объектов:	
для расщепления узла .....	2
в конечных узлах .....	2
Число признаков для выбора	
расщепления .....	$\log_2 x$
	( $x$ — общее число признаков)

*Число решающих деревьев* — число базовых алгоритмов решающего дерева, использованное при построении модели. *Максимальная глубина деревьев* — гиперпараметр, определяющий длину максимального пути

от корневого узла до листового во всех решающих деревьях модели. *Минимальное число объектов для расщепления узла* — гиперпараметр, который определяет минимальное число объектов, необходимое для разделения внутреннего узла дерева. Минимальное число предсказываемых значений, содержащихся в листовых узлах каждого дерева, определяется *минимальным числом объектов в конечных узлах*. *Число признаков для выбора расщепления* — гиперпараметр, который контролирует максимальное число признаков (глубину вдавливания  $U$ , диаметр индентора  $D$  и др.), рассматриваемых при каждом разбиении узла в дереве. Таким образом, после обучения первый алгоритм способен строить зависимости силовой реакции от глубины вдавливания для гидрогелей с параметрами упругости, соответствующими мягким тканям.

Все выборки данных разделены случайным образом в соотношении 70 : 30 % для обучения алгоритмов и валидации полученных предсказаний. Кроме того, для валидации предсказаний второго алгоритма из обучающей выборки удалены результаты испытаний образца с концентрацией шивателя 1,5 %.

**Результаты предсказаний первого алгоритма.** После обучения первый алгоритм показал высокую точность предсказаний при малых перемещениях индентора. Результаты натуральных экспериментов и предсказания алгоритма приведены на рис. 4. Проиллюстрированы испытания гидрогелей с концентрациями шивателя  $\alpha = \{1; 2; 4; 9 \%$ . Наименьшее отклонение от экспериментальных данных наблюдали при использовании модели Муни — Ривлина для генерации обучающей выборки. Это может быть связано с низкой точностью линейно-упругой и неогуковской моделей при возникновении в материале больших деформаций. Метрики оценки качества регрессионной модели первого алгоритма для всех моделей поведения материала, использованных в численных экспериментах для составления обучающей выборки, приведены ниже. Метрики рассчитаны на основе данных, не использованных при обучении:

– средняя абсолютная ошибка  $MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$  определяет абсо-

лютное отклонение предсказаний  $\hat{y}_i$  от истинных значений  $y_i$ ;

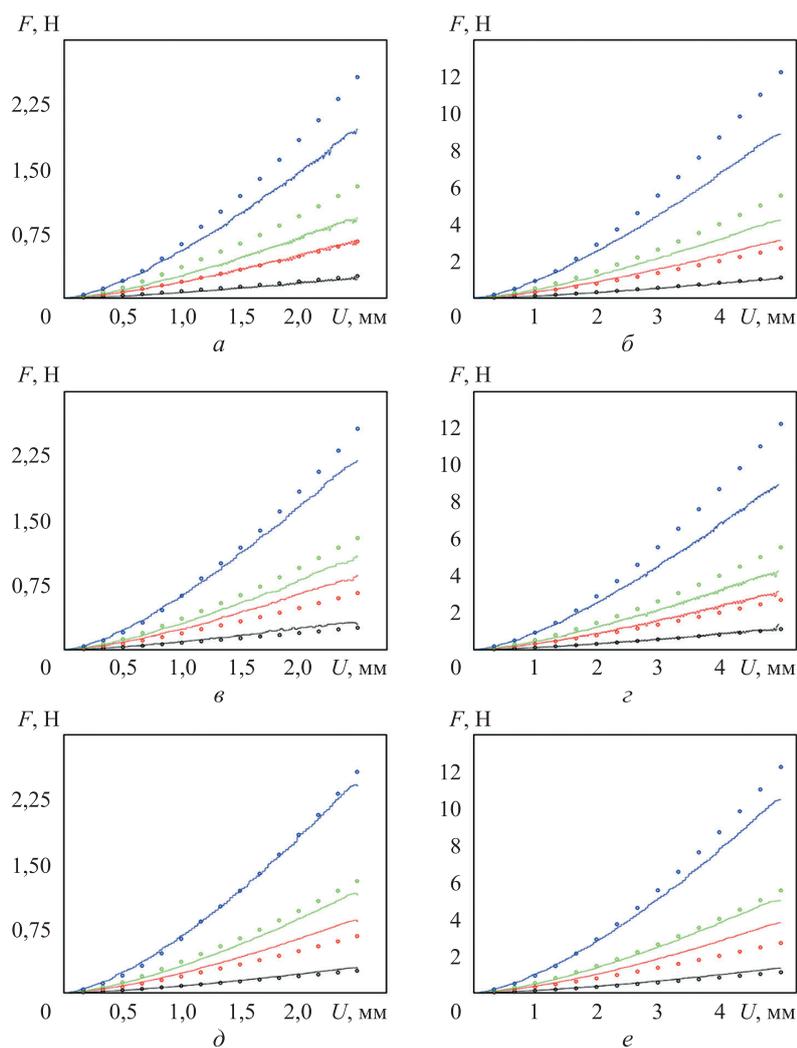
– средняя квадратичная ошибка  $MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$  измеряет сред-

нее значение квадратов ошибок;

– корень из средней квадратичной ошибки  $RMSE = \sqrt{MSE}$  определяет стандартное отклонение ошибок предсказания;

– коэффициент детерминации  $R^2 = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$  ( $\bar{y}$  —

среднее значение целевой переменной) позволяет оценить долю объясненной дисперсии, т. е. насколько модель лучше, чем среднее значение.

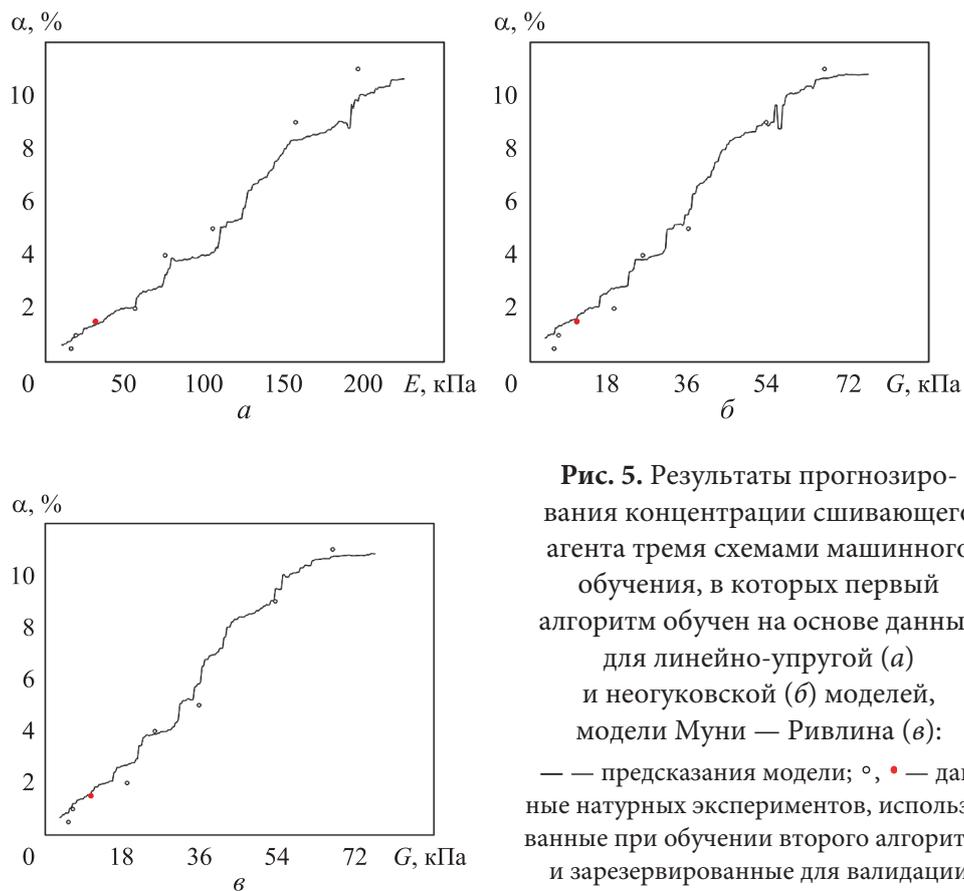


**Рис. 4.** Сопоставление результатов натуральных экспериментов (°) и предсказаний (—) алгоритма, обученного на линейно-упругой модели при диаметре индентора 5 (а) и 10 мм (б), неогуковской модели при диаметре индентора 5 (в) и 10 мм (г), модели Муни — Ривлина при диаметре индентора 5 (д) и 10 мм (е) для  $\alpha = 1$  (°, —), 2 (°, —), 4 (°, —) и 9 % (°, —)

**Метрики оценки качества регрессионной модели первого алгоритма СЛ**

	<i>MAE</i>	<i>MSE</i>	<i>RMSE</i>	$R^2$
Линейно-упругая .....	0,0335	0,0028	0,0533	0,9998
Неогуковская .....	0,0393	0,0041	0,0642	0,9997
Муни — Ривлина .....	0,0430	0,0055	0,0740	0,9997

**Результаты предсказаний второго алгоритма.** Работая последовательно, два алгоритма машинного обучения способны предсказывать концентрацию сшивающего агента, необходимую для получения тканеимитирующего фантома с заданными механическими свойствами. Первый алгоритм предсказывает силовые реакции, возникающие при индентировании гидрогеля, второй — концентрации сшивателя на основе силовых реакций, определенных первым алгоритмом. Результаты прогнозирования трех схем машинного обучения показаны на рис. 5. Точками обозначены данные о соответствии между концентрацией сшивающего агента и модулями упругости первого и второго рода, установленными в процессе натуральных экспериментов на одноосное растяжение. Красным маркером показаны



**Рис. 5.** Результаты прогнозирования концентрации сшивающего агента тремя схемами машинного обучения, в которых первый алгоритм обучен на основе данных для линейно-упругой (*a*) и неогуковской (*b*) моделей, модели Муни — Ривлина (*v*):  
 — — предсказания модели;  $\circ$ ,  $\bullet$  — данные натуральных экспериментов, использованные при обучении второго алгоритма и зарезервированные для валидации предсказаний модели соответственно

параметры гидрогеля с концентраций шшивателя 1,5 %, данные о котором исключены из обучающей выборки второго алгоритма. Следует отметить, что при обучении второго алгоритма использованы только данные о силовых реакциях, возникающих при индентировании гидрогелей, а соответствие концентрации шшивателя параметрам упругости необходимо для оценки адекватности предсказаний модели. Метрики оценки качества регрессионной модели второго алгоритма в постановке, аналогичной метрикам первого алгоритма, приведены ниже:

<i>MAE</i>	<i>MSE</i>	<i>RMSE</i>	<i>R<sup>2</sup></i>
0,4032	0,8039	0,8966	0,9584

Наиболее стабильной оказалась третья схема, в которой первый алгоритм обучен с помощью модели Муни — Ривлина. Она показывает наименьшее число аномалий прогнозирования и менее склонна к эффекту переобучения.

**Обсуждение полученных результатов.** Предложенная модель машинного обучения, основанная на двух алгоритмах СЛ, позволяет предсказывать параметры упругости тканеимитирующих фантомов на основе концентрации шшивателя с высокой точностью. Первый алгоритм успешно предсказывает силовую реакцию при индентировании гидрогеля на основе его механических свойств, второй — концентрацию шшивателя по силовой реакции. Наиболее устойчивые результаты получены при использовании гиперупругой модели Муни — Ривлина, что указывает на ее адекватность при описании поведения гидрогелей в условиях больших деформаций.

**Заключение.** Продемонстрированы возможности алгоритмов машинного обучения в качестве альтернативного метода определения механических свойств тканеимитирующих фантомов на примере гидрогелей из ПААм. Реализована система, состоящая из двух алгоритмов СЛ, для прогнозирования механического отклика фантомов в испытаниях на индентирование и для определения концентрации шшивающего агента в гидрогеле с заданными параметрами упругости. Для обучения алгоритмов проведено более 700 численных испытаний с применением различных моделей поведения материала, а также натурные испытания образцов гидрогеля из ПААм с варьированием концентрации шшивателя (0,5...11 %).

### Благодарности

*Авторы выражают благодарность ресурсному центру «Полимер» и ресурсному центру аддитивных и виртуальных технологий ОРЦ КК НИБКС-ПТ за исследование механического поведения образцов и за помощь в изготовлении экспериментальной установки.*

## ЛИТЕРАТУРА

- [1] Armstrong S.A., Jafary R., Forsythe J.S., et al. Tissue-mimicking materials for ultrasound-guided needle intervention phantoms: a comprehensive review. *Ultrasound Med. Biol.*, 2023, vol. 49, iss. 1, pp. 18–30.  
DOI: <https://doi.org/10.1016/j.ultrasmedbio.2022.07.016>
- [2] Liu D., Jiang P., Wang Y., et al. Engineering tridimensional hydrogel tissue and organ phantoms with tunable springiness. *Adv. Funct. Mater.*, 2023, vol. 33, iss. 17, art. 2214885. DOI: <https://doi.org/10.1002/adfm.202214885>
- [3] Guntur S.R., Kim S.-C., Choi M.-J. A cost-effective reusable tissue mimicking phantom for high intensity focused ultrasonic liver surgery. *Bioengineering*, 2022, vol. 9, iss. 12, art. 786. DOI: <https://doi.org/10.3390/bioengineering9120786>
- [4] Payne A.H., Goodrich K.C., Kholmovski E.G., et al. Isolated kidney phantom for development of biothermal vascular models with application to high intensity focused ultrasound therapy. *Med. Phys.*, 2008, vol. 35, iss. 10, pp. 4426–4434.  
DOI: <https://doi.org/10.1118/1.2975226>
- [5] Filippou A., Louca I., Damianou C. Characterization of a fat tissue mimicking material for high intensity focused ultrasound applications. *J. Ultrasound*, 2023, vol. 26, no. 2, pp. 505–515. DOI: <https://doi.org/10.1007/s40477-022-00746-4>
- [6] Tajik M., Akhlaqi M.M., Gholami S. Advances in anthropomorphic thorax phantoms for radiotherapy: a review. *Biomed. Phys. Eng. Express*, 2022, vol. 8, no. 5, art. 052001. DOI: <https://doi.org/10.1088/2057-1976/ac369c>
- [7] Zhong X., Cao Y., Zhou P. Thermochromic tissue-mimicking phantoms for thermal ablation based on polyacrylamide gel. *Ultrasound Med. Biol.*, 2022, vol. 48, iss. 8, pp. 1361–1372. DOI: <https://doi.org/10.1016/j.ultrasmedbio.2022.03.021>
- [8] Wang Y., Tai B.L., Yu H., et al. Silicone-based tissue-mimicking phantom for needle insertion simulation. *J. Med. Devices*, 2014, vol. 8, iss. 2, art. 021001.  
DOI: <https://doi.org/10.1115/1.4026508>
- [9] Ali A.M., Hogg P., Johansen S., et al. Construction and validation of a low cost paediatric pelvis phantom. *Eur. J. Radiol.*, 2018, vol. 108, pp. 84–91.  
DOI: <https://doi.org/10.1016/j.ejrad.2018.09.015>
- [10] Zhao M., Zhou M., Cao X., et al. Stable tissue-mimicking phantoms for longitudinal multimodality imaging studies that incorporate optical, CT, and MRI contrast. *J. Biomed. Opt.*, 2023, vol. 28, iss. 4, art. 046006.  
DOI: <https://doi.org/10.1117/1.JBO.28.4.046006>
- [11] Negus I.S., Holmes R.B., Jordan K.C., et al. Technical note: development of a 3D printed subresolution sandwich phantom for validation of brain SPECT analysis. *Med. Phys.*, 2016, vol. 43, iss. 9, pp. 5020–5027. DOI: <https://doi.org/10.1118/1.4960003>
- [12] O'Doherty J., Sammut E., Schleyer P., et al. Feasibility of simultaneous PET-MR perfusion using a novel cardiac perfusion phantom. *European J. Hybrid Imaging*, 2017, vol. 1, no. 1, art. 4. DOI: <https://doi.org/10.1186/s41824-017-0008-9>

- [13] Tan Z., Dini D., Baena F.R., et al. Composite hydrogel: a high fidelity soft tissue mimic for surgery. *Mater. Des.*, 2018, vol. 160, pp. 886–894.  
DOI: <https://doi.org/10.1016/j.matdes.2018.10.018>
- [14] Sánchez-Cid P., Jiménez-Rosado M., Romero A., et al. Novel trends in hydrogel development for biomedical applications: a review. *Polymers*, 2022, vol. 14, iss. 15, art. 3023. DOI: <https://doi.org/10.3390/polym14153023>
- [15] Антипова К.Г., Крупнин А.Е., Храпцова Е.А. и др. Фантомы мягких биологических тканей на основе полиакриламида: получение и свойства. *Гены и клетки*, 2022, т. 17, № 3, с. 13.
- [16] Reinhardt-Hervás C., Rico A., Rodríguez J. Crosslinker concentration effect on the poroviscoelastic relaxation of polyacrylamide hydrogels using depth-sensing indentation. *Polym. Test.*, 2021, vol. 100, art. 107265.  
DOI: <https://doi.org/10.1016/j.polymertesting.2021.107265>
- [17] Xiao Y., Chen Q., Yang Z., et al. Asymmetric and skin-mimicking hydrogels with wide temperature tolerance and superior elasticity for high-performance strain sensors. *ACS Omega*, 2023, vol. 8, iss. 49, pp. 46676–46684.  
DOI: <https://doi.org/10.1021/acsomega.3c05779>
- [18] Hariri A., Palma-Chavez J., Wear K.A., et al. Polyacrylamide hydrogel phantoms for performance evaluation of multispectral photoacoustic imaging systems. *Photoacoustics*, 2021, vol. 22, art. 100245. DOI: <https://doi.org/10.1016/j.pacs.2021.100245>
- [19] Avci Yayla I.I., Bilal M., Salmaslıoğlu A., et al. Ultrasound phantom with solids mimicking cancerous tissue for needle breast biopsy. *Turk. J. Chem.*, 2022, vol. 46, no. 5, pp. 1493–1503. DOI: <https://doi.org/10.55730/1300-0527.3454>
- [20] Upadhyay K., Subhash G., Spearot D. Hyperelastic constitutive modeling of hydrogels based on primary deformation modes and validation under 3D stress states. *Int. J. Eng. Sci.*, 2020, vol. 154, art. 103314.  
DOI: <https://doi.org/10.1016/j.ijengsci.2020.103314>
- [21] Lee D., Zhang H., Ryu S. Elastic modulus measurement of hydrogels. In: Mondal M. (eds). *Cellulose-Based Superabsorbent Hydrogels. Polymers and Polymeric Composites: a Reference Series*. Cham, Springer, 2018, pp. 1–21.  
DOI: [https://doi.org/10.1007/978-3-319-76573-0\\_60-1](https://doi.org/10.1007/978-3-319-76573-0_60-1)
- [22] Vila Pouca M.C.P., Cerqueira M.R.G., Ferreira J.P.S., et al. Simulating 3D printing on hydrogel inks: a finite element framework for predicting mechanical properties and scaffold deformation. *Finite Elem. Anal. Des.*, 2024, vol. 230, art. 104098.  
DOI: <https://doi.org/10.1016/j.finel.2023.104098>
- [23] Abdolazizi K.P., Linka K., Sprenger J., et al. Concentration-specific constitutive modeling of gelatin based on artificial neural networks. *Proc. Appl. Math. Mech.*, 2021, vol. 20, iss. 1, art. e202000284. DOI: <https://doi.org/10.1002/pamm.202000284>
- [24] Zhu J.-A., Jia Y., Lei J., et al. Deep learning approach to mechanical property prediction of single-network hydrogel. *Mathematics*, 2021, vol. 9, iss. 21, art. 2804.  
DOI: <https://doi.org/10.3390/math9212804>

- [25] Shokrollahi Y., Dong P., Gamage P., et al. Finite element-based machine learning model for predicting the mechanical properties of composite hydrogels. *Appl. Sci.*, 2022, vol. 12, iss. 21, art. 10835. DOI: <https://doi.org/10.3390/app122110835>
- [26] Белкин А.Е., Даштиев И.З., Костромицких А.В. Определение параметров упругости полиуретана при больших деформациях по результатам испытаний образцов на кручение и растяжение. *Известия высших учебных заведений. Машиностроение*, 2016, № 8, с. 3–10.  
DOI: <https://doi.org/10.18698/0536-1044-2016-8-3-10>
- [27] Liu J., Zheng H., Poh P., et al. Hydrogels for engineering of perfusable vascular networks. *Int. J. Mol. Sci.*, 2015, vol. 16, no. 7, pp. 15997–16016.  
DOI: <https://doi.org/10.3390/ijms160715997>
- [28] Bootsma K., Dimbath E., Berberich J., et al. Materials used as tissue phantoms in medical simulation. In: *Studies in Mechanobiology, Tissue Engineering and Biomaterials*. Berlin, Heidelberg, Springer, 2017, pp. 1–48. DOI: [https://doi.org/10.1007/8415\\_2016\\_1](https://doi.org/10.1007/8415_2016_1)
- [29] Antipova C.G., Krupnin A.E., Zakirov A.R., et al. A comprehensive mechanical testing of polyacrylamide hydrogels: the impact of crosslink density. *Polymers*, 2025, vol. 17, iss. 6, art. 737. DOI: <https://doi.org/10.3390/polym17060737>
- [30] Breiman L. Random forests. *Mach. Learn.*, 2001, vol. 45, no. 1, pp. 5–32.  
DOI: <https://doi.org/10.1023/A:1010933404324>

**Семенов Леонид Игоревич** — лаборант-исследователь научно-образовательного отдела Курчатовского комплекса НБИКС-природоподобных технологий НИЦ «Курчатовский институт» (Российская Федерация, 123182, Москва, пл. Академика Курчатова, д. 1); магистр физтех-школы природоподобных, плазменных и ядерных технологий им. И.В. Курчатова МФТИ (Российская Федерация, 123098, Москва, ул. Максимова, д. 4).

**Крупнин Артур Евгеньевич** — и.о. руководителя ресурсного центра аддитивных и виртуальных технологий, младший научный сотрудник лаборатории полимерных материалов НИЦ «Курчатовский институт» (Российская Федерация, 123182, Москва, пл. Академика Курчатова, д. 1); старший преподаватель кафедры «Прикладная механика» МГТУ им. Н.Э. Баумана (Российская Федерация, 105005, Москва, 2-я Бауманская ул., д. 5, стр. 1).

**Антипова Кристина Георгиевна** — канд. физ.-мат. наук, младший научный сотрудник лаборатории полимерных материалов НИЦ «Курчатовский институт» (Российская Федерация, 123182, Москва, пл. Академика Курчатова, д. 1).

**Григорьев Тимофей Евгеньевич** — канд. физ.-мат. наук, заместитель руководителя по научной работе Курчатовского комплекса НБИКС-природоподобных технологий НИЦ «Курчатовский институт» (Российская Федерация, 123182, Москва, пл. Академика Курчатова, д. 1); директор физтех-школы природоподобных, плазменных и ядерных технологий им. И.В. Курчатова МФТИ (Российская Федерация, 123098, Москва, ул. Максимова, д. 4).

**Просьба ссылаться на эту статью следующим образом:**

Семенов Л.И., Крупнин А.Е., Антипова К.Г. и др. Машинное обучение в задаче прогнозирования параметров упругости тканеимитирующих фантомов мягких биологических тканей. *Вестник МГТУ им. Н.Э. Баумана. Сер. Естественные науки*, 2025, № 6 (123), с. 38–59. EDN: XFPURH

**MACHINE LEARNING FOR PREDICTING MECHANICAL PROPERTIES OF TISSUE-MIMICKING PHANTOMS OF SOFT BIOLOGICAL TISSUES**

**L.I. Semenov**<sup>1,2</sup>

semenov.li@phystech.edu

**A.E. Krupnin**<sup>1,3</sup>

artkrupnin@gmail.com

**K.G. Antipova**<sup>1</sup>

antipova.cg@gmail.com

**T.E. Grigoriev**<sup>1,2</sup>

timgrigo@yandex.ru

<sup>1</sup> NRC Kurchatov Institute, Moscow, Russian Federation

<sup>2</sup> MIPT, Moscow, Russian Federation

<sup>3</sup> BMSTU, Moscow, Russian Federation

---

**Abstract**

Hydrogels appear to be the three-dimensional polymer networks, where the chemical or physical crosslinks between macromolecules are acting as the nodes. Currently, polyacrylamide-based hydrogels are the promising materials in obtaining the soft biological tissue-mimicking phantoms. A key advantage of these hydrogels is their ability to control mechanical properties by varying the crosslinker concentration, i.e., the number of crosslinks, which makes it possible to simulate characteristics of various organs and tissues. However, selecting the crosslinker concentration to create phantoms with the specified characteristics is a complex task requiring significant time and computational resources. The machine learning algorithms are able to determine correlation between the resulting hydrogel crosslink concentration and the elastic properties. A machine learning model based on two random forest algorithms is implemented being capable of predicting mechanical properties of the tissue-mimicking phantoms. The algorithms are trained using synthetic data obtained from the numerical indentation experiments in the licensed finite element analysis

**Keywords**

*Machine learning, random forest, tissue-mimicking phantoms, hydrogel, polyacrylamide, indentation, finite element simulation, hyperelasticity models*

software *ANSYS Workbench* (Ansys Inc., USA) using the linear-elastic material behavior model, neo-Hookean and Mooney — Rivlin hyperelasticity models, as well as data from the full-scale experiments. Predictions were validated using the test data, which constituted 30 % of the entire data set and were not used in the algorithm learning, as well as results of the full-scale experiments

Received 04.03.2025

Accepted 30.06.2025

© Author(s), 2025

*The work was performed within the State Assignment of the NRC Kurchatov Institute*

## REFERENCES

- [1] Armstrong S.A., Jafary R., Forsythe J.S., et al. Tissue-mimicking materials for ultrasound-guided needle intervention phantoms: a comprehensive review. *Ultrasound Med. Biol.*, 2023, vol. 49, iss. 1, pp. 18–30. DOI: <https://doi.org/10.1016/j.ultrasmedbio.2022.07.016>
- [2] Liu D., Jiang P., Wang Y., et al. Engineering tridimensional hydrogel tissue and organ phantoms with tunable springiness. *Adv. Funct. Mater.*, 2023, vol. 33, iss. 17, art. 2214885. DOI: <https://doi.org/10.1002/adfm.202214885>
- [3] Guntur S.R., Kim S.-C., Choi M.-J. A cost-effective reusable tissue mimicking phantom for high intensity focused ultrasonic liver surgery. *Bioengineering*, 2022, vol. 9, iss. 12, art. 786. DOI: <https://doi.org/10.3390/bioengineering9120786>
- [4] Payne A.H., Goodrich K.C., Kholmovski E.G., et al. Isolated kidney phantom for development of biothermal vascular models with application to high intensity focused ultrasound therapy. *Med. Phys.*, 2008, vol. 35, iss. 10, pp. 4426–4434. DOI: <https://doi.org/10.1118/1.2975226>
- [5] Filippou A., Louca I., Damianou C. Characterization of a fat tissue mimicking material for high intensity focused ultrasound applications. *J. Ultrasound*, 2023, vol. 26, no. 2, pp. 505–515. DOI: <https://doi.org/10.1007/s40477-022-00746-4>
- [6] Tajik M., Akhlaqi M.M., Gholami S. Advances in anthropomorphic thorax phantoms for radiotherapy: a review. *Biomed. Phys. Eng. Express*, 2022, vol. 8, no. 5, art. 052001. DOI: <https://doi.org/10.1088/2057-1976/ac369c>
- [7] Zhong X., Cao Y., Zhou P. Thermochromic tissue-mimicking phantoms for thermal ablation based on polyacrylamide gel. *Ultrasound Med. Biol.*, 2022, vol. 48, iss. 8, pp. 1361–1372. DOI: <https://doi.org/10.1016/j.ultrasmedbio.2022.03.021>
- [8] Wang Y., Tai B.L., Yu H., et al. Silicone-based tissue-mimicking phantom for needle insertion simulation. *J. Med. Devices*, 2014, vol. 8, iss. 2, art. 021001. DOI: <https://doi.org/10.1115/1.4026508>
- [9] Ali A.M., Hogg P., Johansen S., et al. Construction and validation of a low cost paediatric pelvis phantom. *Eur. J. Radiol.*, 2018, vol. 108, pp. 84–91. DOI: <https://doi.org/10.1016/j.ejrad.2018.09.015>

- [10] Zhao M., Zhou M., Cao X., et al. Stable tissue-mimicking phantoms for longitudinal multimodality imaging studies that incorporate optical, CT, and MRI contrast. *J. Biomed. Opt.*, 2023, vol. 28, iss. 4, art. 046006.  
DOI: <https://doi.org/10.1117/1.JBO.28.4.046006>
- [11] Negus I.S., Holmes R.B., Jordan K.C., et al. Technical note: development of a 3D printed subresolution sandwich phantom for validation of brain SPECT analysis. *Med. Phys.*, 2016, vol. 43, iss. 9, pp. 5020–5027. DOI: <https://doi.org/10.1118/1.4960003>
- [12] O’Doherty J., Sammut E., Schleyer P., et al. Feasibility of simultaneous PET-MR perfusion using a novel cardiac perfusion phantom. *European J. Hybrid Imaging*, 2017, vol. 1, no. 1, art. 4. DOI: <https://doi.org/10.1186/s41824-017-0008-9>
- [13] Tan Z., Dini D., Baena F.R., et al. Composite hydrogel: a high fidelity soft tissue mimic for surgery. *Mater. Des.*, 2018, vol. 160, pp. 886–894.  
DOI: <https://doi.org/10.1016/j.matdes.2018.10.018>
- [14] Sánchez-Cid P., Jiménez-Rosado M., Romero A., et al. Novel trends in hydrogel development for biomedical applications: a review. *Polymers*, 2022, vol. 14, iss. 15, art. 3023. DOI: <https://doi.org/10.3390/polym14153023>
- [15] Antipova K.G., Krupnin A.E., Khramtsova E.A., et al. Polyacrylamide-based soft biological tissue phantoms: preparation and properties. *Geny i kletki [Genes & Cells]*, 2022, vol. 17, no. 3, p. 13 (in Russ.).
- [16] Reinhardt-Hervás C., Rico A., Rodríguez J. Crosslinker concentration effect on the poroviscoelastic relaxation of polyacrylamide hydrogels using depth-sensing indentation. *Polym. Test.*, 2021, vol. 100, art. 107265.  
DOI: <https://doi.org/10.1016/j.polymertesting.2021.107265>
- [17] Xiao Y., Chen Q., Yang Z., et al. Asymmetric and skin-mimicking hydrogels with wide temperature tolerance and superior elasticity for high-performance strain sensors. *ACS Omega*, 2023, vol. 8, iss. 49, pp. 46676–46684.  
DOI: <https://doi.org/10.1021/acsomega.3c05779>
- [18] Hariri A., Palma-Chavez J., Wear K.A., et al. Polyacrylamide hydrogel phantoms for performance evaluation of multispectral photoacoustic imaging systems. *Photoacoustics*, 2021, vol. 22, art. 100245. DOI: <https://doi.org/10.1016/j.pacs.2021.100245>
- [19] Avci Yayla I.I., Bilal M., Salmaslıoğlu A., et al. Ultrasound phantom with solids mimicking cancerous tissue for needle breast biopsy. *Turk. J. Chem.*, 2022, vol. 46, no. 5, pp. 1493–1503. DOI: <https://doi.org/10.55730/1300-0527.3454>
- [20] Upadhyay K., Subhash G., Spearot D. Hyperelastic constitutive modeling of hydrogels based on primary deformation modes and validation under 3D stress states. *Int. J. Eng. Sci.*, 2020, vol. 154, art. 103314.  
DOI: <https://doi.org/10.1016/j.ijengsci.2020.103314>
- [21] Lee D., Zhang H., Ryu S. Elastic modulus measurement of hydrogels. In: Mondal M. (eds). *Cellulose-Based Superabsorbent Hydrogels. Polymers and Polymeric Composites: a Reference Series*. Cham, Springer, 2018, pp. 1–21.  
DOI: [https://doi.org/10.1007/978-3-319-76573-0\\_60-1](https://doi.org/10.1007/978-3-319-76573-0_60-1)

- [22] Vila Pouca M.C.P., Cerqueira M.R.G., Ferreira J.P.S., et al. Simulating 3D printing on hydrogel inks: a finite element framework for predicting mechanical properties and scaffold deformation. *Finite Elem. Anal. Des.*, 2024, vol. 230, art. 104098. DOI: <https://doi.org/10.1016/j.finel.2023.104098>
- [23] Abdolazizi K.P., Linka K., Sprenger J., et al. Concentration-specific constitutive modeling of gelatin based on artificial neural networks. *Proc. Appl. Math. Mech.*, 2021, vol. 20, iss. 1, art. e202000284. DOI: <https://doi.org/10.1002/pamm.202000284>
- [24] Zhu J.-A., Jia Y., Lei J., et al. Deep learning approach to mechanical property prediction of single-network hydrogel. *Mathematics*, 2021, vol. 9, iss. 21, art. 2804. DOI: <https://doi.org/10.3390/math9212804>
- [25] Shokrollahi Y., Dong P., Gamage P., et al. Finite element-based machine learning model for predicting the mechanical properties of composite hydrogels. *Appl. Sci.*, 2022, vol. 12, iss. 21, art. 10835. DOI: <https://doi.org/10.3390/app122110835>
- [26] Belkin A.E., Dashtiev I.Z., Kostromitskikh A.V. Determining polyurethane elastic parameters at large strains using torsion and tensile test results. *Izvestiya vysshikh uchebnykh zavedeniy. Mashinostroenie* [BMSTU Journal of Mechanical Engineering], 2016, no. 8, pp. 3–10 (in Russ.). DOI: <https://doi.org/10.18698/0536-1044-2016-8-3-10>
- [27] Liu J., Zheng H., Poh P., et al. Hydrogels for engineering of perfusable vascular networks. *Int. J. Mol. Sci.*, 2015, vol. 16, no. 7, pp. 15997–16016. DOI: <https://doi.org/10.3390/ijms160715997>
- [28] Bootsma K., Dimbath E., Berberich J., et al. Materials used as tissue phantoms in medical simulation. In: *Studies in Mechanobiology, Tissue Engineering and Biomaterials*. Berlin, Heidelberg, Springer, 2017, pp. 1–48. DOI: [https://doi.org/10.1007/8415\\_2016\\_1](https://doi.org/10.1007/8415_2016_1)
- [29] Antipova C.G., Krupnin A.E., Zakirov A.R., et al. A comprehensive mechanical testing of polyacrylamide hydrogels: the impact of crosslink density. *Polymers*, 2025, vol. 17, iss. 6, art. 737. DOI: <https://doi.org/10.3390/polym17060737>
- [30] Breiman L. Random forests. *Mach. Learn.*, 2001, vol. 45, no. 1, pp. 5–32. DOI: <https://doi.org/10.1023/A:1010933404324>

**Semenov L.I.** — Research Assistant, Kurchatov Complex of NBICS-Nature-Like Technologies, Scientific and Educational Department, NRC Kurchatov Institute (ploshchad Akademika Kurchatova 1, Moscow, 123182 Russian Federation); Master, Kurchatov School of Natural, Plasma, and Nuclear Technologies n.a. I.V. Kurchatov, MIPT (Maksimova ul. 4, Moscow, 123098 Russian Federation).

**Krupnin A.E.** — Acting Head of the Resource Center for Additive and Virtual Technologies, Polymer Laboratory, NRC Kurchatov Institute (ploshchad Akademika Kurchatova 1, Moscow, 123182 Russian Federation); Senior Lecturer, Department of Applied Mechanics, BMSTU (2-ya Baumanskaya ul. 5, str. 1, Moscow, 105005 Russian Federation).

**Antipova K.G.** — Cand. Sc. (Phys.-Math.), Junior Researcher, Polymer Laboratory, NRC Kurchatov Institute (ploshchad Akademika Kurchatova 1, Moscow, 123182 Russian Federation)

**Grigoriev T.E.** — Cand. Sc. (Phys.-Math.), Deputy Head for Scientific Work of the Kurchatov Complex of NBICS-Nature-Like Technologies, NRC Kurchatov Institute (ploshchad Akademika Kurchatova 1, Moscow, 123182 Russian Federation); Head of the Kurchatov School of Natural, Plasma, and Nuclear Technologies n.a. I.V. Kurchatov, MIPT (Maksimova ul. 4, Moscow, 123098 Russian Federation).

**Please cite this article in English as:**

Semenov L.I., Krupnin A.E., Antipova K.G., et al. Machine learning for predicting mechanical properties of tissue-mimicking phantoms of soft biological tissues. *Herald of the Bauman Moscow State Technical University, Series Natural Sciences*, 2025, no. 6 (123), pp. 38–59 (in Russ.). EDN: XFPURH