

01

Применение методов машинного обучения для прогнозирования коэффициента оптического поглощения композитной керамики на основе гидроксипатита

© А.Е. Резванова,¹ Б.С. Кудряшов,¹ А.Н. Пономарев^{1,2}

¹ Институт физики прочности и материаловедения СО РАН, 634055 Томск, Россия

² Томский государственный университет систем управления и радиоэлектроники, 634034 Томск, Россия
e-mail: ranast@ispms.ru

Поступило в Редакцию 15 января 2025 г.

В окончательной редакции 15 января 2025 г.

Принято к публикации 15 января 2025 г.

На основе данных эксперимента методами машинного обучения построены модели для прогнозирования коэффициента оптического поглощения керамики на основе гидроксипатита и композитов с добавками 0.1 mass% и 0.5 mass% многостенных углеродных нанотрубок в частотном диапазоне терагерцового излучения от 0.2 до 1.4 THz. Наименьшее значение средней абсолютной ошибки показало моделирование методами адаптивного бустинга (0.951 %), а также с помощью нейронных сетей (0.049 %). Результаты численного моделирования подтверждают, что применение методов машинного обучения позволяет с высокой точностью прогнозировать коэффициент поглощения для керамических материалов с концентрациями углеродных нанотрубок в интервале от 0 mass% до 0.5 mass%. Это открывает возможности для оптимизации состава композитов на основе гидроксипатита для управления их оптическими характеристиками.

Ключевые слова: прогнозирование, регрессионный анализ, машинное обучение, нейронные сети, гидроксипатит, многостенные углеродные нанотрубки, коэффициент поглощения.

DOI: 10.61011/JTF.2025.05.60277.3-25

Введение

Современные исследования в области медицинского материаловедения все чаще обращаются к численным методам моделирования и машинному обучению для анализа и прогнозирования свойств материалов [1,2]. Это обусловлено сложностью и затратностью проведения традиционных экспериментов, а также необходимостью поиска быстрых и эффективных способов изучения поведения материалов. Производство и исследование новых типов имплантатов для замещения поврежденных костных тканей человека, стимулируемое постоянно растущими требованиями с точки зрения биосовместимости и схожестью физико-механических характеристик с костной тканью, обусловило дальнейшие исследования по разработке прогнозных моделей, которые могут оценивать свойства получаемых материалов.

Одним из перспективных объектов исследований является керамика на основе гидроксипатита (ГА, НА) [3,4], широко используемая в биомедицинских приложениях благодаря своей биосовместимости и схожим с костной тканью механическим свойствам [5]. Улучшение характеристик ГА, таких, как коэффициент поглощения электромагнитного излучения в терагерцовом (THz) диапазоне, становится особенно актуальным в контексте разработки новых материалов для сенсорных устройств, экранов и биомедицинских имплантатов [6].

Включение многостенных углеродных нанотрубок (МУНТ, MWCNTs) в композитную керамику на основе ГА позволяет изменить физико-механические свойства материала, приблизив их к свойствам костной ткани [7–9]. Однако экспериментальное исследование влияния различных концентраций добавок МУНТ на оптические свойства композита ГА-МУНТ сопряжено с трудностями, связанными с необходимостью учета большого числа переменных и широкого диапазона частот, подверженностью к ошибкам, возникающим из-за неточностей испытаний, проблем с оборудованием или различий между производителями.

Осознавая эти ограничения, исследователи и специалисты все чаще обращаются к подходам, основанным на моделировании, для прогнозирования физико-механических свойств. Традиционные методы прогнозирования в основном состоят из эмпирических соотношений, разработанных на основе статистического анализа экспериментальных данных, где устанавливаются линейные и нелинейные (полиномиальные) регрессионные модели [10]. В таких моделях аналитические уравнения генерируются посредством регрессионного анализа для определения неизвестных коэффициентов, влияющих на связь между входным параметром и другими переменными.

Методы машинного обучения находят все более широкое применение для прогнозирования свойств матери-

алов, включая их физические, механические, химические и оптические характеристики [11,12]. Машинное обучение успешно используется для анализа механической прочности композитных материалов [13], моделирования термической устойчивости полимеров [14]. В области биомедицинских материалов машинное обучение помогает предсказывать биосовместимость имплантатов [15], параметры адгезии [16], скорость биодеградации [17]. Также данные методы позволяют предсказывать широкий спектр механических свойств материалов, таких, как модуль упругости, пределы прочности на растяжение и сжатие, и т.д. [18,19]. Подобные подходы позволяют существенно ускорить процесс разработки новых материалов, минимизируя затраты на экспериментальную проверку [20]. При этом механические свойства и оптические характеристики, такие, как показатель преломления и коэффициент поглощения, являются взаимосвязанными. Охарактеризовать данную взаимосвязь можно с помощью такого параметра, как пористость, который напрямую влияет как на физико-механические, так и оптические свойства керамических материалов. С уменьшением пористости возрастают микротвердость и прочность на сжатие керамики ГА [4,21]. В работе [22] показана взаимозависимость между пористостью и показателем преломления нанокompозитов типа „полупроводник-изолятор“. Наблюдается снижение показателя преломления при росте пористости нанокompозита. В работе [23] устанавливалась взаимосвязь в том числе между механическими свойствами и коэффициентом поглощения натриево-силикатных стекол с использованием диоксида циркония. Добавки циркония приводят к увеличению плотности и модуля упругости стекол, в то время как коэффициент поглощения уменьшается. Аналогичная картина наблюдается в работе [24], где уплотнение керамики ГА с помощью добавок МУНТ так же привело к снижению коэффициента поглощения. Тем самым определение влияния добавок МУНТ на оптические свойства позволит в дальнейшем установить взаимосвязь между оптическими характеристиками и механическими свойствами в керамике ГА.

Прогнозирование оптических свойств керамических композитных материалов на основе ГА с добавлением МУНТ является важной исследовательской задачей, решение которой могло бы способствовать получению широкого массива данных для их применения в экспериментальных исследованиях и дальнейшей разработке керамических материалов ГА-МУНТ. В настоящей работе представлены результаты численного моделирования коэффициента поглощения керамики на основе ГА и композитов с добавлением 0.1 mass% и 0.5 mass% МУНТ в диапазоне частот от 0.2 до 1.4 THz. Для анализа экспериментальных данных применялись методы машинного обучения, включающие линейную и полиномиальную регрессию, адаптивный бустинг (AdaBoost) на основе деревьев решений и искусственные нейронные сети. Настоящая работа нацелена на применение алгоритмов машинного обучения, способных с высокой точностью

обрабатывать нелинейные зависимости коэффициента оптического поглощения от частоты терагерцового излучения в диапазоне от 0.2 до 1.4 THz для построения прогнозных моделей оптических спектров поглощения пористой керамики на основе ГА в зависимости от содержания упрочняющих добавок МУНТ. Это открывает возможности получения широкого массива данных, дополняющих эксперимент, с целью дальнейшей оптимизации состава композитов на основе ГА для управления как оптическими, так и физико-механическими характеристиками.

1. Материалы и методы исследования

Прогнозирование коэффициента поглощения проводилось для керамических материалов на основе данных экспериментальных исследований ГА без добавок и с добавками 0.1 mass% и 0.5 mass% МУНТ, которые применялись для армирования матрицы керамики ГА и контроля ее пористости путем варьирования добавок. Эксперимент проводился методом терагерцовой спектроскопии во временной области на спектрометре T-SPEC (EKSPLA, Эстония) в частотном диапазоне от 0.2 до 1.4 THz по методике, описанной в работе [24]. Исследование выполнялось на цилиндрических образцах, толщина и диаметр которых составляют (3 ± 0.1) и (8 ± 0.05) mm соответственно. Экспериментально полученные спектры коэффициента оптического поглощения в зависимости от частоты THz-излучения представлены на рис. 1, где точками указаны средние значения коэффициента поглощения, а линиями — доверительные интервалы.

Для решения задачи прогнозирования коэффициента поглощения керамического композитного материала, а также выбора оптимальной модели, применялись как классические методы аппроксимации, так и некоторые виды машинного обучения. Стандартными в работе выступали методы регрессионного анализа, такие, как линейная и полиномиальная регрессии. Регрессионный анализ — это набор статистических методов, используемых для изучения влияния одной или нескольких независимых переменных на зависимую переменную. При этом понятия зависимых и независимых переменных отражают лишь математическую зависимость переменных [25]. Для обработки данных, создания регрессионных моделей, а также визуализации и сравнения созданных моделей использовался язык программирования Python и библиотека Scikit-learn, имеющая большое количество встроенных регрессионных методов, а также хорошо интегрируемая с другими библиотеками Python, такими, как NumPy, Pandas и Matplotlib.

Линейная регрессия представляет собой модель зависимости переменной x от одной или нескольких других переменных с линейной функцией зависимости [25–30], и имеет вид (1):

$$Y = b_0 + b_1x_1 + b_2x_2 + \dots + b_kx_k, \quad (1)$$

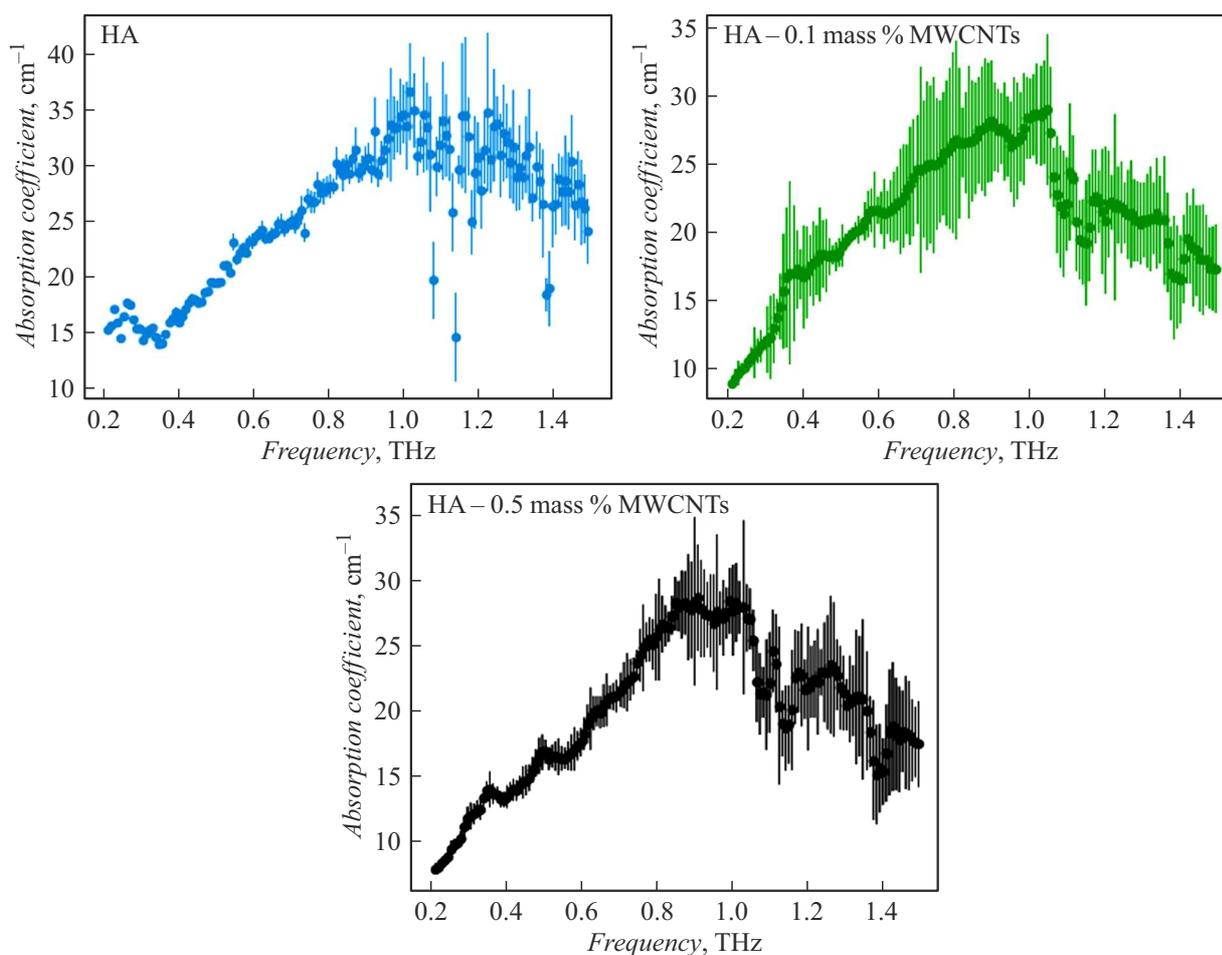


Рис. 1. Экспериментальные данные коэффициента поглощения керамических материалов на основе ГА.

где b_j — параметры (коэффициенты) регрессии, x_i — регрессоры (факторы модели).

На практике взаимосвязь между двумя переменными очень часто бывает нелинейной, а попытка использовать линейную регрессию может привести к значительной вычислительной ошибке [30].

Способом учета нелинейной связи между переменными является полиномиальная регрессия, согласно уравнению (2) [26]:

$$Y_i = b_0 + b_1x_i + b_2x_i^2 + \dots + b_nx_i^n + \varepsilon, \quad (i = 1, 2, \dots, n) + \varepsilon, \quad (2)$$

где b_j — параметры (коэффициенты) регрессии, x_i — регрессор (фактор модели), ε — количество факторов модели, n — степень регрессии.

Когда увеличивается значение степени n , модель лучше соответствует нелинейности оцениваемых данных, но на практике применяется степень не более 4–5. За пределами этой точки модель становится слишком гибкой и „подгоняет“ данные, что приводит к большой погрешности для данных, на которых модель не „обучалась“ [30,31]. Чтобы компенсировать недостатки обычных линейных и нелинейных регрессионных моделей,

в работе введены методы машинного обучения (МО) в качестве сильного претендента на прогнозирование свойств керамических материалов. Одним из таких методов является адаптивный бустинг (AdaBoost), основанный на случайном лесе решений (Random Forest), который использует множество решающих деревьев для улучшения точности и обобщающей способности модели [32]. Базовым элементом леса решений является решающее дерево, представляющее собой древовидную структуру, где каждый узел соответствует признаку, а ветви — значениям признаков, при этом „листья“ дерева представляют классы для классификации или числовые значения для регрессии [33,34]. AdaBoost — это ансамблевый алгоритм обучения, который использует итерационный подход для повышения точности прогнозирования путем обучения на ошибках предыдущих деревьев. Данный метод для каждого дерева присваивает веса таким образом, что наименее точные значения получают больший вес, а наиболее точные — теряют [32–35].

Наиболее популярным и перспективным методом МО является искусственная нейронная сеть (ИНС), представляющая собой математическую модель, которая построена аналогично биологическим нейронам. ИНС

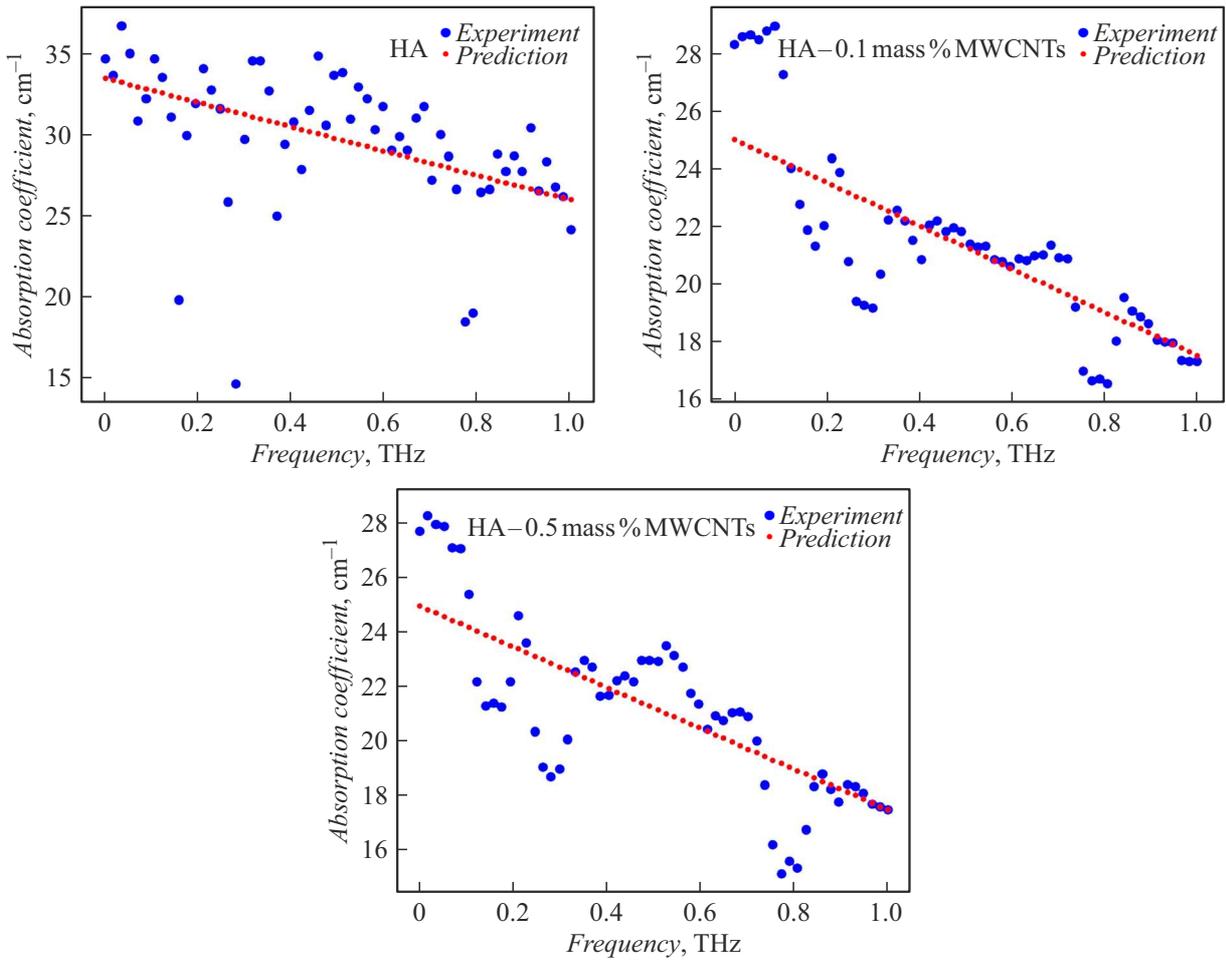


Рис. 2. Аппроксимация данных методом линейной регрессии.

состоит из множества простых элементов — искусственных нейронов, которые объединяются в сложные структуры для решения разнообразных задач, таких как классификация, регрессия, обработка изображений и т.д. [36]. Многослойный перцептрон — это один из самых базовых типов нейронных сетей, состоящий из нескольких слоев нейронов [37], а именно — входного слоя, который получает входные данные; далее срабатывает второй слой, получающий сигналы от первого, этот слой также производит преобразование сигналов и их дальнейшую передачу третьему слою и т.д. При этом функция потерь оценивает разницу между предсказанными выходами и реальными значениями. Данный метод позволяет моделировать функции практически любой степени сложности, в зависимости от количества используемых входных и выходных элементов, а также числа скрытых слоев и количества нейронов в них [38,39].

В настоящей работе для создания нейронной сети использовались библиотеки TensorFlow и Keras. Основными элементами нейронной сети являются искусственные нейроны и функции активации. Функции активации вводят модели в нелинейность, наиболее используемыми из которых являются:

1) сигмоида (Sigmoid) превращает любое входное значение в диапазон от 0 до 1, который используется в моделях, где требуется предсказывать вероятность и описывается выражением (3) [36]:

$$\sigma(x) = \frac{1}{1 + e^{-x}}; \tag{3}$$

2) гиперболический тангенс (Tanh), в отличие от предыдущей функции, превращает любое входное значение в диапазон от -1 до 1, что позволяет центрировать выходные значения вокруг нуля и ускоряет процесс обучения по сравнению с сигмоидой (4) [36]:

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}; \tag{4}$$

3) ReLU (Rectified Linear Unit) позволяет избежать проблемы затухания градиента для положительных значений, при этом не требует больших вычислений, но может „вымерзнуть“ нейроны, если градиенты становятся нулями и больше никогда не обновляются (5) [37]:

$$eLU(x) = \max(0, x); \tag{5}$$

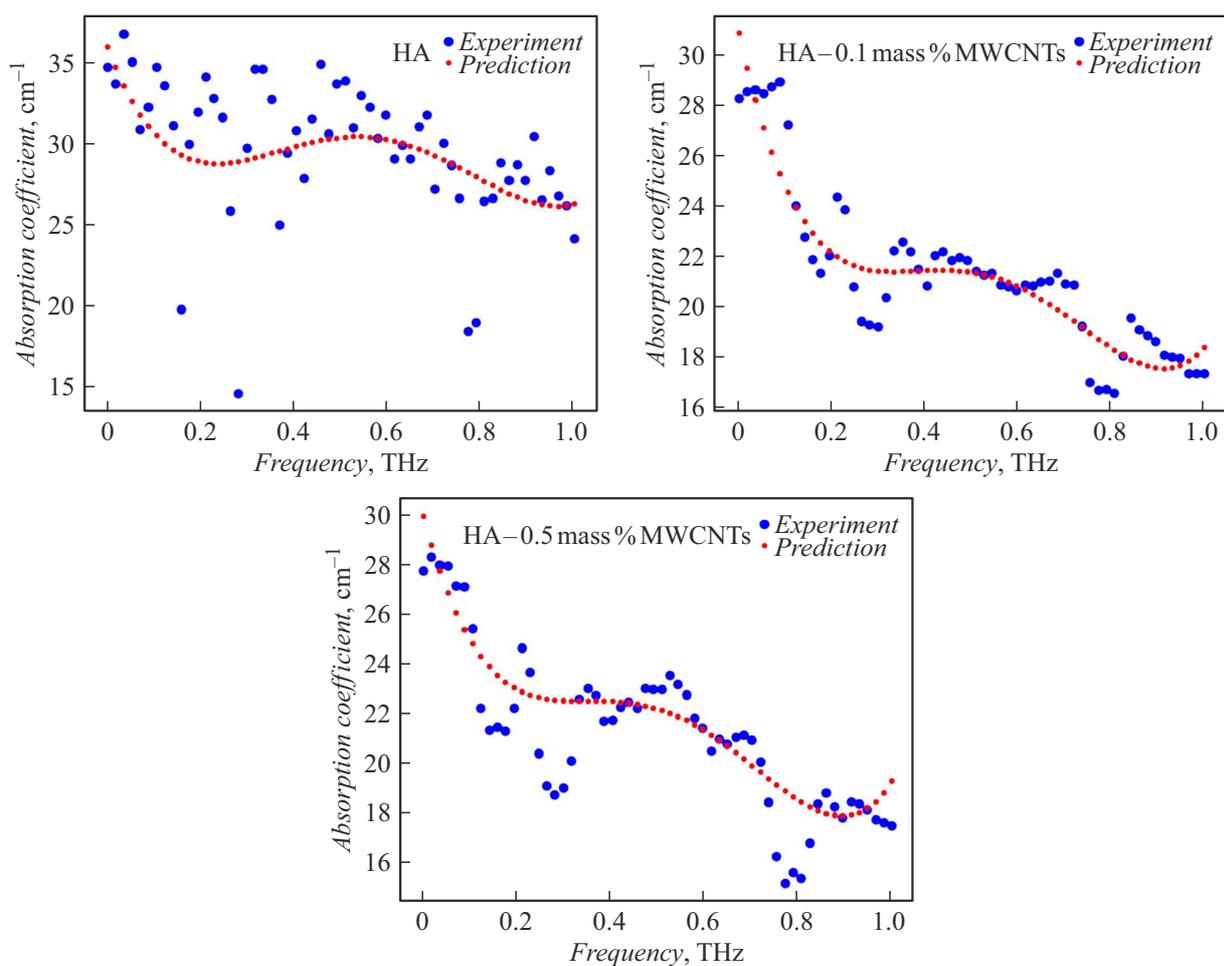


Рис. 3. Аппроксимация данных методом полиномиальной регрессии.

4) Leaky ReLU — данная функция активации снижает риск „вымерзания“ нейронов, позволяя получать небольшие отрицательные значения, благодаря введению дополнительного коэффициента, что незначительно усложняет более простой вид (6) [36]:

$$\text{LeakyReLU}(x) = \{\alpha \cdot x, \text{ if } x < 0, \text{ otherwise}\}. \quad (6)$$

Для сравнения моделей использовалась метрика средней абсолютной ошибки в процентах (MAPE) (7):

$$M = \frac{1}{n} \sum_{t=1}^n \frac{|Y_t - \hat{Y}_t|}{Y_t} \cdot 100\%, \quad (7)$$

где Y_t и \hat{Y}_t — фактические и прогнозируемые значения целевой переменной для t -го объекта выборки, n — общее число тестовой выборки [40].

С помощью данной метрики можно сравнивать эффективность моделей на разных обучающих выборках. Величина MAPE < 5% свидетельствует о приемлемой точности прогноза показателя [41]. Значение MAPE в диапазоне от 10% до 25% указывает на меньшую точность, но достаточную для прогнозирования данных,

а MAPE, превышающее 25%, выходит за рамки допустимой точности и не позволяет использовать данные для предсказания [42,43].

2. Прогнозирование коэффициента поглощения керамического материала

Для проверки точности моделей экспериментальные данные зависимости коэффициента поглощения от частоты были разделены на обучающие и тестовые из принципа Парето с соотношением 80% на 20% соответственно. На рис. 2 представлены результаты обучения экспериментальных данных с помощью линейной регрессии.

Данная модель продемонстрировала значение MAPE 7.293%, что говорит о недостаточной точности предсказаний коэффициента оптического поглощения. Высокая ошибка обусловлена нелинейной зависимостью между дескрипторами и зависимой переменной, тем самым делая метод линейной регрессии непригодным для дальнейшего применения. На рис. 3 представлены

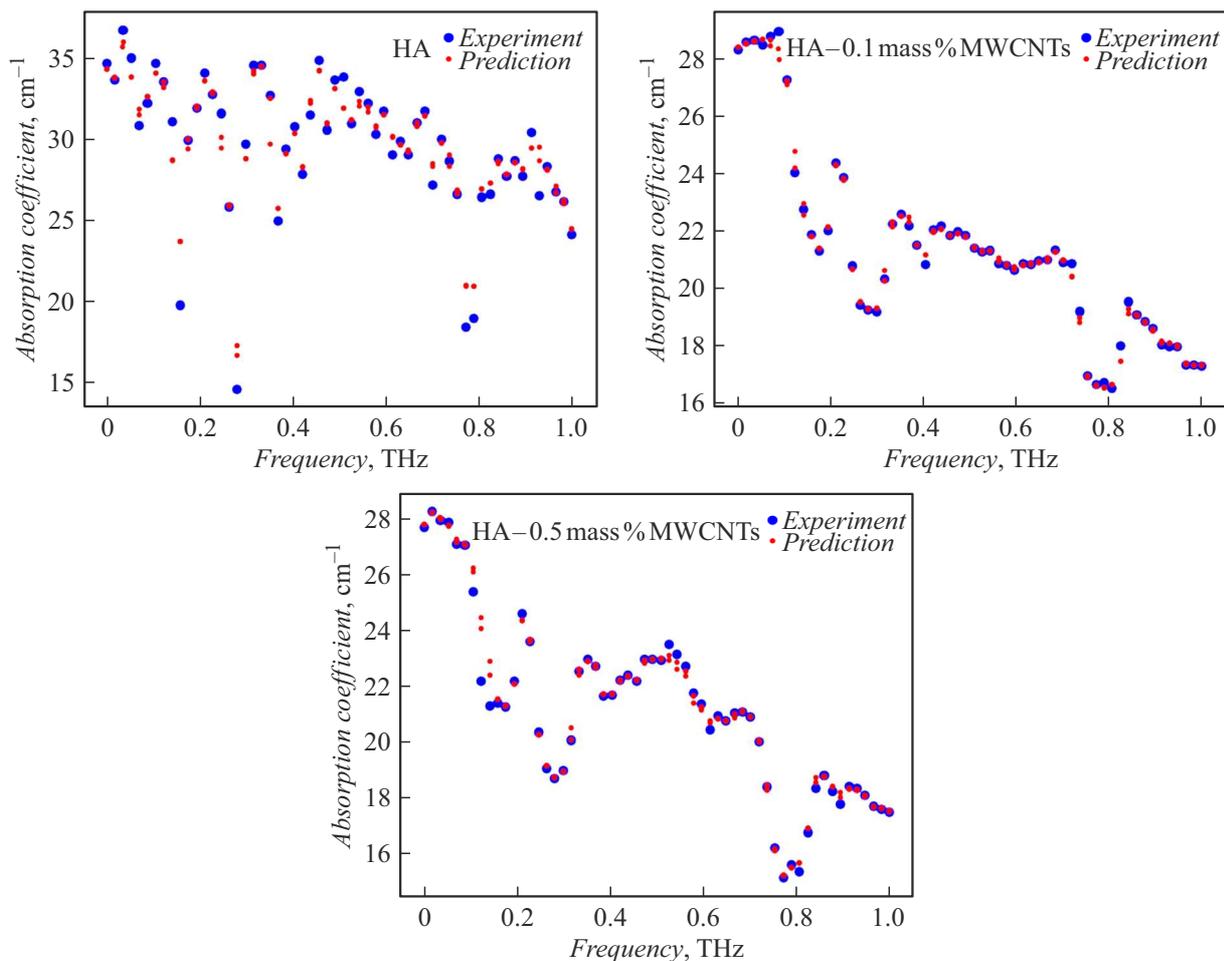


Рис. 4. Прогнозирование коэффициента поглощения методом адаптивного бустинга.

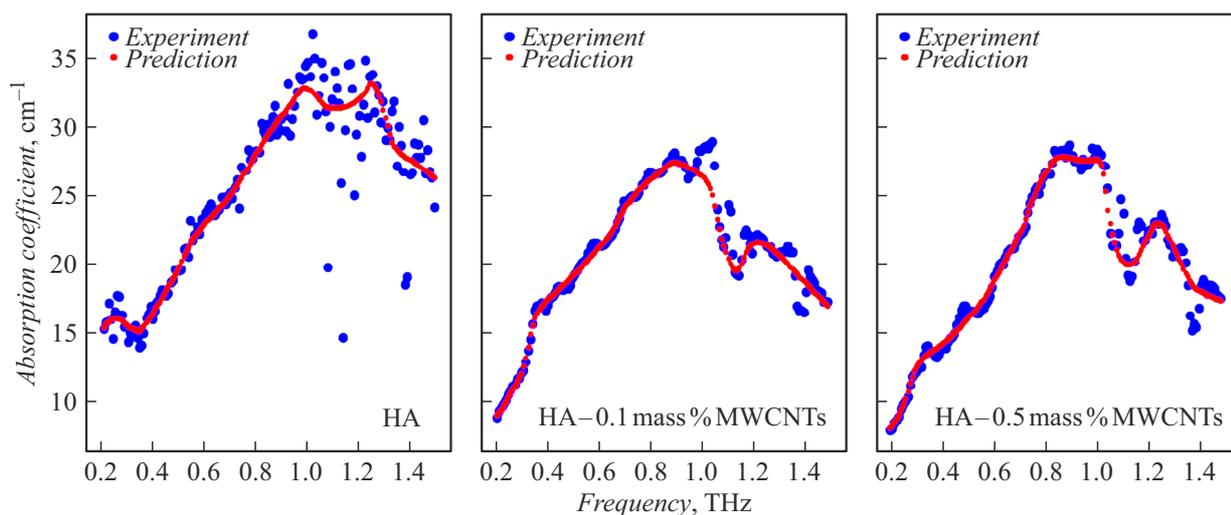


Рис. 5. Результат предсказания нейросетевой модели.

результаты обучения данных с помощью полиномиальной регрессии.

Данная модель продемонстрировала значение MAPE 2.228 %, что является более приемлемым результатом по сравнению с данными линейной регрессии. Результаты

обучения коэффициента поглощения были получены также с помощью метода адаптивного бустинга, который в качестве дополнения данных использовался для повышения точности прогнозирования методом леса решений (рис. 4).

Сравнение значений MAPE прогнозных моделей

Модель	MAPE, %
Линейная регрессия	8.118
Полиномиальная регрессия	7.293
Адаптивный бустинг	0.951
Нейронная сеть	0.049

Результаты значений MAPE, полученные для модели адаптивного бустинга (0.951 %), показывают существенно более высокую точность прогнозирования по сравнению с методом полиномиальной регрессии, что делает данный метод пригодным для решений таких задач.

При построении модели с помощью нейронной сети использовался класс GridSearchCV библиотеки Keras. Для нейросетевой модели выполнялся подбор гиперпараметров от 1 до 5 скрытых слоев и от 16 до 128 нейронов с шагом 32 в каждом слое. Для каждого слоя подобраны функции активации: 'relu', 'tanh', 'sigmoid', 'selu'. Результаты обучения представлены на рис. 5.

При предсказании оптического спектра поглощения продемонстрировано значение MAPE = 0.049 %, что указывает на наибольшую точность нейросетевого прогнозирования по сравнению с другими методами (см. таблицу).

Как следует из таблицы, статистические показатели рассмотренных моделей отражают заметное преимущество методов МО по сравнению с классическими регрессионными моделями [37]. Это можно объяснить способностью методов МО точно прогнозировать свойства сложных композитных материалов, где связь между структурой и коэффициентом оптического поглощения является крайне нелинейной.

Заключение

В работе проведено численное моделирование коэффициента поглощения керамики на основе ГА и композитов с добавлением МУНТ в диапазоне частот 0.2–1.4 ТГц для прогнозирования оптических параметров с концентрациями МУНТ от 0 mass% до 0.5 mass%. На основе анализа экспериментальных данных с использованием методов МО получены качественные и количественные зависимости коэффициента поглощения от частоты излучения при добавлении различных концентраций МУНТ. Проведена оценка применимости различных методов МО, таких, как линейная и полиномиальная регрессии, адаптивный бустинг (AdaBoost), а также ИНС, оптимальные гиперпараметры для которой были подобраны с помощью класса GridSearchCV. Обучение нейронной сети проводилось на нормированных и ненормированных данных, где при нормализации точность модели значительно снижалась. Для сравнения регрессионных моделей использовалась метрика средней абсолютной ошибки в процентах (MAPE), наименьшее значение

которой было достигнуто обработкой нейронной сетью и составило 0.049 %. Результаты моделирования показали, что применение методов машинного обучения позволяет не только эффективно анализировать поведение материалов, но и с высокой точностью прогнозировать коэффициент поглощения в керамических материалах на основе ГА с концентрациями МУНТ в интервале от 0 mass% до 0.5 mass%. Это открывает возможности для оптимизации состава композитов на основе ГА для управления их оптическими характеристиками.

Полученные результаты имеют прикладное значение для разработки новых материалов с регулируемыми свойствами в области биомедицины, радиоэлектроники и других высокотехнологичных отраслей. Перспективным направлением дальнейших исследований является применение более сложных алгоритмов машинного обучения для учета дополнительных факторов, влияющих на свойства материалов, а также экспериментальная проверка полученных моделей.

Финансирование работы

Работа выполнена в рамках государственного задания ИФПМ СО РАН, номер темы FWRW-2022-0002.

Конфликт интересов

Авторы заявляют, что у них нет конфликта интересов.

Список литературы

- [1] K. Stergiou, C. Ntakolia, P. Varytis, E. Koumoulos, P. Karlsson, S. Moustakidis. *Comput. Mater. Sci.*, **220**, 112031 (2023). DOI: 10.1016/j.commat.2023.112031
- [2] A. Stoll, P. Benner. *GAMM Mitteilungen*, **44** (1), E202100003 (2021). DOI: 10.1002/gamm.202100003
- [3] M. Rahman, Y. Li, C. Wen. *J. Magnes. Alloys.*, **8** (3), 929 (2020). DOI: 10.1016/j.jma.2020.05.003
- [4] M.S. Barabashko, M.V. Tkachenko, A.A. Neiman, A.N. Ponomarev, A.E. Rezvanova. *Appl. Nanosci.*, **10**, 2601 (2020). DOI: 10.1007/s13204-019-01019-z
- [5] C. Feng, K. Zhang, R. He, G. Ding, M. Xia, X. Jin, C. Xie. *J. Adv. Ceram.*, **9**, 360 (2020). DOI: 10.1007/s40145-020-0375-8
- [6] P. Bawuah, D. Markl, D. Farrell, M. Evans, A. Portieri, A. Anderson, D. Goodwin, R. Lucas, J.A. Zeitler. *J. Inf. Millim. Te. W.*, **41**, 450 (2020). DOI: 10.1007/s10762-019-006590
- [7] S. Cho, J. Kim, S.-B. Lee, M. Choi, D.-H. Kim, I. Jo, H. Kwon, Y. Kim. *Compos. Part A Appl. Sci. Manuf.*, **139**, 106138 (2020). DOI: 10.1016/j.compositesa.2020.106138
- [8] S.M. Taromsari, M. Salari, R. Bagheri, M.A.F. Sani. *Compos. B. Eng.*, **175**, 107181 (2019). DOI: 10.1016/j.compositesb.2019.107181
- [9] C. Gao, P. Feng, S. Peng, C. Shuai. *Acta Biomater.*, **61**, 1 (2017). DOI: 10.1016/j.actbio.2017.05.020
- [10] С.А. Михайлов. *Диффузное загрязнение водных экосистем. Методы оценки и математические модели* (Экология, Барнаул, 2000)

- [11] G. Genty, L. Salmela, J.M. Dudley, D. Brunner, A. Kokhanovskiy, S. Kobtsev, Sergei K. Turitsyn. *Nat. Photonics*, **15** (2), 91 (2021). DOI: 10.1038/s41566-020-00716-4
- [12] I.A. Hodashinsky, I.V. Filimonenko, K.S. Sarin. *Optoelectron. Instrument. Proc.*, **53**, 379 (2017). DOI: 10.3103/S8756699017040100
- [13] M. Liu, H. Li, H. Zhou, H. Zhang, G. Huang. *Compos. Commun.*, **49**, 101988 (2024). DOI: 10.1016/j.coco.2024.101988
- [14] P. Xu, H. Chen, M. Li, W. Lu. *Adv. Theory Simul.*, **5** (5), 2100565 (2022). DOI: 10.1002/adts.202100565
- [15] S.V. Chaudhari, J. Sristi, R. Gopal, M. Amutha, V. Akshaya, P. Vijayalakshmi. *Scientific Temper.*, **15** (01), 1619 (2024). DOI: 10.58414/SCIENTIFICTEMPER.2024.15.1.08
- [16] R. Ghosh, S. Chanda, D. Chakraborty. *MEP*, **95**, 64 (2021). DOI: 10.1016/j.medengphy.2021.08.002
- [17] A. Zarei, A. Farazin. *J. Aust. Ceram. Soc.*, **1** (2024). DOI: 10.1007/s41779-024-01084-w
- [18] K. Guo, Z. Yang, C.H. Yu, M.J. Buehle. *Mater. Horizon*, **8** (4), 1153 (2021). DOI: 10.1039/D0MH01451F
- [19] W.B. Chaabene, M. Flah, M.L. Nehdi. *Constr. Build. Mater.*, **260**, 119889 (2020). DOI: 10.1016/j.conbuildmat.2020.119889
- [20] Е.О. Хазиева, Н.М. Щелкачев, А.О. Типеев, Р.Е. Рыльцев. *ЖЭТФ*, **164** (6), 980 (2023). DOI: 10.31857/S004445102312012X
- [21] D.M. Liu. *Ceram. Int.*, **23** (2), 135 (1997). DOI: 10.1016/S0272-8842(96)00009-0
- [22] L.A. Golovan, V.Y. Timoshenko, P.K. Kashkarov. *Phys. Usp.*, **50** (6), 595 (2007). DOI: 10.1070/PU2007v050n06ABEH006257
- [23] E.A. Abdel Wahab, K.S. Shaaban, E.S. Yousef. *OQE*, **52**, 1 (2020). DOI: 10.1007/s11082-020-02575-3
- [24] A.E. Rezvanova, B.S. Kudryashov, A.N. Ponomarev, A.I. Knyazkova, V.V. Nikolaev, Y.V. Kistenev. *Nanosystems: Phys. Chem. Math.*, **14** (5), 530 (2023). DOI: 10.17586/2220-8054-2023-14-5-530-538
- [25] Н.Р. Дрейпер. *Прикладной регрессионный анализ* (Рипол Классик, 1973)
- [26] Электронный ресурс. TensorFlow. Режим доступа: <https://www.tensorflow.org/?hl=ru> (дата обращения: 14.11.2024).
- [27] Электронный ресурс. Keras. Режим доступа: <https://keras.io/> (дата обращения: 14.11.2024).
- [28] С.Г. Сандомирский. *Актуальные вопросы машиноведения*, **7**, 339 (2018).
- [29] Z. Du, Y. Hu, N.A. Buttar. *Sci. Hortic.*, **260**, 108886 (2020). DOI: 10.1016/j.scienta.2019.108886
- [30] Электронный ресурс. Scikit-learn Machine Learning in Python. Scikit-learn, Режим доступа: <https://scikit-learn.org/stable/index.html> (дата обращения: 14.11.2024).
- [31] W.C. Yang, J.Y. Yang, R.C. Kim. *Adv. Mater. Sci. Eng.*, **2023** (1), 7069987 (2023). DOI: 10.1155/2023/7069987
- [32] S. Kwak, J. Kim, H. Ding, X. Xu, R. Chen, J. Guo, H. Fu. *J. Mater. Res. Technol.*, **18**, 520 (2022). DOI: 10.1016/j.jmrt.2022.02.108
- [33] A.G. Priya Varshini, K. Anitha Kumari, V. Vijayakumar. *Electronics*, **10** (10), 1195 (2021). DOI: 10.3390/electronics10101195
- [34] C. Zhang, Y. Ma. *Ensemble machine learning* (Springer, NY, 2012), v. 144.
- [35] F. Kibrete, T. Trzepiecinski, H.S. Gebremedhen, D.E. Woldemichael. *J. Compos. Sci.*, **7**, 364 (2023). DOI: 10.3390/jcs7090364
- [36] Н.Е. Бабушкина, А.А. Рачев. *Инновационные технологии в машиностроении, образовании и экономике*, **27** (2), 12 (2020).
- [37] Д.В. Ширшова, А.Т. Хананова, Э.Ф. Хидиятуллина. *Фундаментальная и прикладная наука: состояние и тенденции развития*. Сб. статей V Междунар. научно-практической конф., **60** (2020).
- [38] С. Хайкин. *Нейронные сети: полный курс*, 2-е издание (Издат. дом Вильямс, 2008)
- [39] Ю.В. Андронов, В.Н. Мельников, А.В. Стрекалов. *Геология, геофизика и разработка нефтяных и газовых месторождений*, **9**, 18 (2015).
- [40] А.С. Балыков, Е.А. Каледина, С.В. Володин. *Нанотехнологии в строительстве: научный интернет-журнал*, **15** (2), 171 (2023). DOI: 10.15828/2075-8545-2023-15-2-171-186
- [41] А.М. Колесников, И.И. Митричев. *Успехи в химии и химической технологии*, **37** (4 (266)), 10 (2023).
- [42] D.A. Swanson. *IREF*, **5** (1), 1 (2015).
- [43] S. Kumar, T. Kaur. *Energy Proced.*, **90**, 587 (2016). DOI: 10.1016/j.egypro.2016.11.227