



НАУЧНАЯ СТАТЬЯ

УДК 691.3; 004.852

DOI: 10.52957/2782-1919-2024-5-2-20-38

Предиктивное моделирование эксплуатационных свойств пеностекла с использованием моделей машинного обучения на основе линейной регрессии

С.В. Федосов¹, М.О. Баканов^{2,*}, И.С. Грушко³

Сергей Викторович Федосов

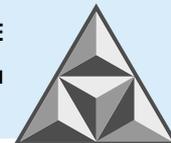
¹Национальный исследовательский Московский государственный строительный университет,
Москва, Российская Федерация
fedosov-academic53@mail.ru

Максим Олегович Баканов

²Ивановская пожарно-спасательная академия ГПС МЧС России», Иваново, Российская Федерация
*mask-13@mail.ru**

Ирина Сергеевна Грушко

³Южно-Российский государственный политехнический университет (НПИ) им. М.И. Платова,
Новочеркасск, Российская Федерация
grushkois@gmail.com



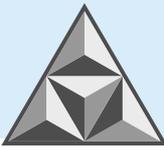
С учетом энергосбережения, строительство требует применения эффективных теплоизоляционных материалов, таких как пеностекло. Рассматривается предиктивное моделирование эксплуатационных свойств пеностекла с использованием моделей машинного обучения. Представлено математическое описание влияния добавок в шихте на свойства пеностекла. Разработано девять составов шихты для синтеза пеностекла и определены основные параметры их микроструктуры. С помощью программной среды Jupyter Notebook и библиотеки SciKit-Learn на языке программирования Python протестированы регрессионные модели. Проанализированы коэффициенты уравнений регрессий и дана оценка погрешности моделирования. Полученные результаты подтверждают эффективность предиктивного моделирования эксплуатационных свойств пеностекла на базе линейной регрессии.

Ключевые слова: пеностекло, микроструктура, эксплуатационные свойства, машинное обучение, регрессионный анализ

Для цитирования:

Федосов С.В., Баканов М.О., Грушко И.С. Предиктивное моделирование эксплуатационных свойств пеностекла с использованием моделей машинного обучения на основе линейной регрессии // *Умные композиты в строительстве*. 2024. Т. 5, вып. 2. С. 20-38.
URL: <https://comincon.ru/ru/nauka/issue/5160/view>

DOI: 10.52957/2782-1919-2024-5-2-20-38



SCIENTIFIC ARTICLE

DOI: 10.52957/2782-1919-2024-5-2-20-38

Predictive modelling of foam glass performance properties using linear regression-based machine learning models

S.V. Fedosov¹, M.O. Bakanov^{2*}, I.S. Grushko³

Sergey V. Fedosov

¹National Research Moscow State University of Civil Engineering, Moscow, Russia

fedosov-academic53@mail.ru

Maksim O. Bakanov

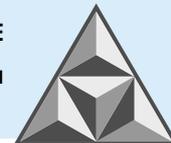
²Ivanovo Fire and Rescue Academy of the State Fire Service of the Ministry of Emergency Situations of Russia, Ivanovo, Russia

*mask-13@mail.ru**

Irina S. Grushko

³Platov South-Russian State Polytechnic University (NPI), Novocherkassk, Russia

grushkois@gmail.com



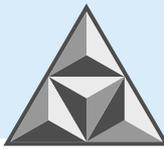
Building construction requires the use of efficient thermal insulation materials such as foam glass in view of energy conservation. The paper considers predictive modelling of the performance properties of foam glass using machine learning models. The paper presents a mathematical description of the additives impact in the charge on the properties of foam glass. Nine charge compositions for foam glass synthesis were developed and their main microstructure parameters were determined. The authors tested the regression models using the Jupyter Notebook software environment and the SciKit-Learn library in the Python programming language. The paper analyses the regression equation coefficients and estimates the modelling error. The obtained results confirm the effectiveness of predictive modelling of foam glass performance properties on the basis of linear regression.

Keywords: foam glass, microstructure, functional properties, machine learning, regression analysis

For citation:

Fedosov, S.V., Bakanov, M.O. &, Grushko, I.S. (2024) Predictive modelling of foam glass performance properties using linear regression-based machine learning models, *Smart Composite in Construction*, 5(2), pp. 20-38. URL: <https://comincon.ru/ru/nauka/issue/5160/view>

DOI: 10.52957/2782-1919-2024-5-2-20-38



ВВЕДЕНИЕ

В сфере строительства важной проблемой является разработка инновационных теплоизоляционных материалов с оптимальными характеристиками [1]. Примером такого материала может служить пеностекло, обладающее низкой теплопроводностью, высокой прочностью и морозостойкостью [2-4]. Физические свойства пеностекла зависят от его структуры, формируемой в процессе синтеза [5-10]. Улучшение структуры пеностекла для достижения требуемых свойств [11-16] возможно, в частности, с использованием математического моделирования [17, 18].

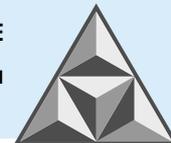
Понятие предиктивной аналитики, известной как «продвинутая аналитика», описывается набором сложных методов, предназначенных для прогнозирования различных параметров (рис. 1). Используя статистические модели, предиктивная аналитика позволяет выявлять закономерности и устанавливать корреляции между параметрами [19], а также прогнозировать физико-химические характеристики. Регрессия является наиболее распространенной и используемой формой предиктивной аналитики. При разработке модели регрессии используется количественная переменная, которую необходимо предсказать. Существует большое количество типов регрессии, включая многомерную линейную и полиномиальную, а также регрессионные деревья. Чтобы успешно применять предиктивную аналитику, необходимо подготовить данные, определить модель прогнозирования и следовать предиктивному процессу. Предиктивные модели могут иметь различные формы и масштабы в зависимости от сложности и применения, для которого они были разработаны.



Рис. 1. Методы продвинутой аналитики

Fig. 1. Advanced analytics methods

На сегодняшний день наблюдается активное развитие области, посвященной предиктивному моделированию сложных технологических процессов [20-24]. Очевидно, успешная реализация этого направления невозможна без использования методов машинного обучения, которые позволяют автоматизировать процесс обучения и улучшать поведение



системы на основе анализа базы данных без явного программирования. Применение методов машинного обучения в предиктивном моделировании дает возможность системам самостоятельно извлекать и использовать закономерности, выявленные из анализа большого набора характеристик. Это позволяет создавать модели, способные предсказывать поведение сложных технологических процессов с высокой точностью.

Используемый статистический подход, включающий регрессионный анализ [25-29], способствует детальному изучению воздействия различных факторов на характеристики композиционного материала или изделия. В данном исследовании рассматривается влияние состава исходного сырья на свойства материала, а также параметры его микроструктуры. Учитывая необходимость оценки совместного влияния факторов при работе со сложными системами стекол, такие методы машинного обучения с учителем, как линейная регрессия, могут быть эффективным инструментом для решения обозначенной проблемы. Они позволяют анализировать множество переменных и их взаимосвязь, а также предсказывать значения целевой переменной. Таким образом, использование методов машинного обучения с учителем может способствовать разработке и оптимизации свойств теплоизоляционных материалов, включая пеностекло с необходимым набором эксплуатационных характеристик.

Цель исследования заключается в выявлении закономерностей формирования структуры пеностекла при температурах ниже 850°C. В работе используются методы машинного обучения с учителем, включая линейную регрессию, для прогнозирования эксплуатационных характеристик материала на основе изменений химического состава исходных компонентов.

Для достижения поставленной цели исследования решаются следующие задачи:

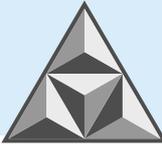
1. Формирование оптимальных составов шихты для создания пеностекла;
2. Оценка параметров микроструктуры, включая фазовый состав, долю кристаллической и аморфной фаз, пористость, толщину межпоровых перегородок, а также эксплуатационные свойства пеностекла (теплопроводность, плотность, механическая прочность и др.);
3. Разработка регрессионных моделей, описывающих влияние химического состава на свойства пеностекла;
4. Проверка разработанных моделей на адекватность и повторяемость результатов;
5. Оценка возможности повышения точности путем учета комбинированного воздействия факторов.

ЭКСПЕРИМЕНТАЛЬНАЯ ЧАСТЬ

Для анализа микроструктуры пеностекла использовали метод рентгенофазового анализа (дифрактометр Bruker D2 Phaser) и программы PDXL2 и TOPAS. Пористость и толщину перегородок измеряли с помощью микротомографии (Skyscan-1172); данные обрабатывали с использованием программы STAn.

Химический состав материала пеностекла вычисляли теоретически [29]. Оценку эксплуатационных характеристик образцов (теплопроводность, плотность, прочность на сжатие и изгиб) производили в соответствии с методиками [11-16].

Настоящее исследование посвящено предсказанию эксплуатационных свойств пеностекла, а также параметров его микроструктуры (обозначаемых символами x_n). Пространство, в котором описываются характеристики, называется пространством объектов и обозначается символом X . В данном случае целевой переменной, которую мы стремимся определить, являются процентные доли компонентов шихты, и множество их значений обозначается символом Y . Пространство ответов представляет собой множество вещественных



чисел: $\mathbb{Y} = \mathbb{R}$. Отдельные значения целевой переменной обозначаются символом y . Каждый пример в наборе данных, где имеем информацию об объектах и их соответствующих ответах, называется обучающим примером. Полное множество таких примеров называется обучающей выборкой и обозначается $X = \{(x_1, y_1), \dots, (x_n, y_n)\}$, где x_1, \dots, x_n — объекты обучающей выборки, а n — количество примеров в выборке. Одной из ключевых особенностей обучающих объектов является наличие соответствующих им ответов y_1, \dots, y_n .

Обычно для анализа необходимо описать объекты с помощью набора характеристик, которые называются признаками или факторами. Вектор, который включает все признаки объекта x , называется признаковым описанием этого объекта.

Для получения результата используем матрицу «объекты-признаки» $X \in \mathbb{R}^{n \times d}$, где каждая строка представляет признаковое описание одного из обучающих объектов. Таким образом, строки в матрице соответствуют объектам, а столбцы представляют различные признаки.

Необходимо разработать функцию $a: X \rightarrow \mathbb{Y}$, которая способна предсказывать ответ для любого объекта. Такая функция может быть названа алгоритмом или моделью. Для определения ожиданий от алгоритма необходимо ввести функционал качества, который позволяет оценить эффективность его работы. Если мы хотим минимизировать функционал, его можно назвать функционалом ошибки.

Данные задачи относятся к категории обучения с учителем, а именно — к задаче регрессии, которая характеризуется наличием вещественной целевой переменной.

В области машинного обучения существует широкий спектр алгоритмов (\mathcal{A}), которые могут использоваться для решения различных задач. Одним из простых и хорошо изученных семейств алгоритмов являются линейные модели. Они строятся на основе линейной комбинации признаков, включая свободный коэффициент ω_0 , и используются для предсказания результатов:

$$\mathcal{A} = \{a(x) = \omega_0 + \omega_1 x_1 + \dots + \omega_d x_d \mid \omega_0, \omega_1, \dots, \omega_d \in \mathbb{R}\}, \quad (1)$$

где через x_i обозначается значение i -признака у объекта x . Лучшая из таких моделей может быть выбрана путем минимизации MSE (Mean Squared Error — среднеквадратичная ошибка):

$$\frac{1}{N} \sum_{i=1}^N \left(\omega_0 + \sum_{j=1}^d \omega_j x_{ij} - y_i \right)^2 \rightarrow \min_{\omega_0, \omega_1, \dots, \omega_d}, \quad (2)$$

Здесь x_{ij} обозначает значение j -признака на i -объекте. Обучение — это процесс нахождения оптимального алгоритма. Если модель $a(x)$ имеет дифференцируемые параметры ω , мы можем использовать градиентные методы для оптимизации: начинаем с произвольной точки и движемся в сторону наименьшего значения функционала ошибки (антиградиента). В случае выпуклых функционалов этот метод найдет глобальный минимум, но для невыпуклых функционалов гарантируется только сходимость к локальному минимуму. Как достичь лучшего локального минимума, можно решить различными способами, например, при выборе начального значения или при использовании сложных методов оптимизации. Важно отметить, что дифференцируемые модели, которые поддаются оптимизации, состоят из простых последовательных преобразований данных и не могут полностью заменить сложные структуры или программы с ветвлениями и циклами. В настоящее время существует немного недифференцируемых моделей, которые могут быть эффективно обучены. Однако известны успешные примеры (градиентный бустинг над решающими деревьями), которые позволяют



обучить недифференцируемые модели. Эти модели используются в различных областях и позволяют достичь хороших результатов при анализе сложных данных.

При использовании моделей линейной регрессии происходит комбинирование признаков с определенными коэффициентами для прогностических значений:

$$a(x) = \omega_0 + \sum_{j=1}^d \omega_j x_{ij}. \quad (3)$$

В модели фигурируют параметры, обозначаемые как веса ω_j , где ω_0 упоминается как свободный коэффициент или смещение (bias). В формуле (3) сумма представляет скалярное произведение вектора признаков на вектор весов. Линейные модели имеют простую структуру, что обеспечивает высокую скорость обучения и делает их популярными в работе с большими объемами данных. Кроме того, они имеют небольшое количество параметров, что позволяет контролировать риск переобучения и использовать их с зашумленными данными и небольшими выборками. В линейных моделях предполагается линейная связь между каждым признаком и целевой переменной, а также отсутствие зависимости последней от комбинаций признаков. Это означает, что каждый признак вносит свой вклад в предсказание модели независимо от других признаков, что может быть полезно при работе с данными, где линейные зависимости представлены в хорошем приближении. Однако в случае, когда зависимости более сложные, линейные модели могут быть ограничены в способности хорошо предсказывать целевую переменную.

Для анализа данных использовали методы регрессионного и корреляционного анализов в Jupyter Notebook с применением языка программирования Python и библиотеки SciKit-Learn [30]. Применяли модель множественной линейной регрессии, а для уменьшения ошибок использовали метод градиентного спуска. Данные нормализовали путем центрирования и масштабирования. Оценку ошибок модели в процессе составления коэффициентов проводили с использованием метрики среднеквадратичной ошибки (MSE), финальное качество модели проверялось с помощью корня из среднеквадратичной ошибки (RMSE). Эти метрики позволяют сделать выводы о качестве связи между микроструктурой и свойствами пеностекла.

Для проведения регрессионного анализа требуется создать достаточный набор исходных данных. На предварительном этапе создано девять различных составов пеностекла при одинаковом температурно-временном режиме (см. рис. 2).

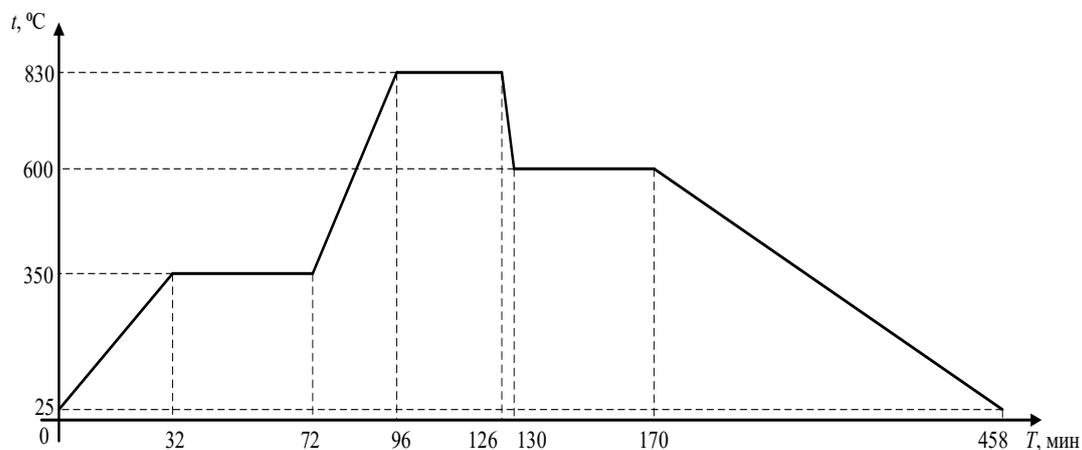
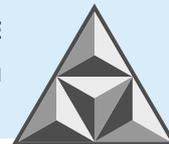


Рис. 2. Температурный режим синтеза образцов пеностекла

Fig. 2. Temperature conditions for synthesis of foam glass



При создании кристаллической фазы в аморфном скелете материала использовали катализаторы кристаллизации, эффективные для данного исследования. Количество составов определялось так, чтобы их было достаточно для построения линейной модели. Один из составов (нулевой) является базовым (табл. 1).

Таблица 1. Химический состав оксидов в анализируемых пробах

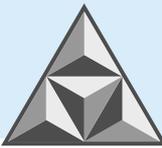
Table 1. Chemical composition of oxides in the analyzed samples

№ образца	Оксидный состав, мас%							
	SiO ₂	TiO ₂	Al ₂ O ₃	Fe ₂ O ₃	MnO	MgO	CaO	Na ₂ O
0	63.13	0.27	8.17	3.56	0.04	3.16	6.73	11.50
1	62.96	0.25	7.49	3.27	0.03	2.90	6.16	11.30
2	62.84	0.25	7.48	3.26	0.04	2.89	6.15	11.28
3	62.28	0.25	7.42	3.23	0.50	2.88	7.13	11.19
4	61.88	0.25	7.29	3.18	0.04	2.84	8.53	11.00
5	62.57	0.25	7.45	3.25	0.04	3.19	7.17	11.25
6	61.88	0.25	7.29	3.18	0.04	3.12	8.53	11.00
7	62.57	0.25	7.45	3.25	0.04	2.90	7.17	11.25
8	61.88	0.25	7.29	3.18	0.04	2.84	8.53	11.00
№ образца	Оксидный состав, мас%							
	K ₂ O	P ₂ O ₅	BaO	SO ₃	V ₂ O ₅	Cr ₂ O ₃	B ₂ O ₃	ZrO ₂
0	1.40	0.04	0.04	0.02	0.01	0.01	1.90	–
1	1.29	0.03	0.04	0.02	–	0.77	3.48	–
2	1.28	0.04	0.05	0.03	0.02	0.97	3.48	–
3	1.29	0.04	0.05	0.03	0.02	–	3.45	0.30
4	1.25	0.04	0.04	0.03	0.02	–	3.40	0.29
5	1.29	0.04	0.05	0.03	0.02	0.02	3.46	–
6	1.25	0.04	0.04	0.03	0.02	–	3.40	–
7	1.29	0.04	0.05	0.03	0.02	0.31	3.46	–
8	1.25	0.04	0.04	0.03	0.02	0.29	3.40	–

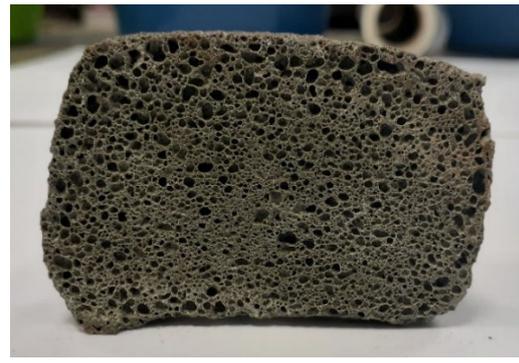
Базовый состав включал только основные компоненты, без катализаторов кристаллизации и модификаторов. Дополнительно нами было добавлено четыре компонента, каждый как минимум с двумя уровнями, повторенными дважды для повышения надежности результатов. Общее количество составов равнялось 9. Различные дополнительные компоненты использовали для изучения их воздействия на материал, особенно влияние катализатора кристаллизации. К примеру, сочетания оксида хрома в количествах 0.75 и 1.00 г рассмотрены для оценки влияния; кроме того, диапазоны варьирования выбирали узкими для корректного применения теории линеаризации.

Для подготовки образцов использовали следующие процедуры. Сначала золошлаковую смесь и стеклобой измельчали в щековой дробилке, а затем – в фарфоровом барабане с мелющими телами. После отсева с использованием сита 0.08 материал размещали на вращающиеся валки. Размер зерен подбирали с учетом стандартов и требований заводов-производителей. Сырьевые компоненты взвешивали на электронных весах, смешивали, увлажняли, упаковывали и формовали в цилиндры с использованием гидравлического пресса.

Процесс синтеза изображен на рис. 3. Начальные образцы вводили в печь при 25°C, нагревали до 350°C (10°C/мин) и выдерживали 40 мин. Затем нагревали до 830°C (20°C/мин) и выдерживали 30 мин, после чего температуру снижали до 600°C и выдерживали 40 мин. Отжиг происходит с охлаждением до 25°C. Предложенный режим формирует материал с качественной пористой структурой. Рис. 3, б демонстрирует результирующий образец.



а



б

Рис. 3. Общий вид пеностекла: а – перед термической обработкой; б – после термической обработки

Fig. 3. General view of foam glass: a – before heat treatment; b – after heat treatment

В лаборатории изучены свойства пеностекла (теплопроводность, плотность, прочность на сжатие и изгиб, в направлении, перпендикулярном лицевой поверхности, и под центральной нагрузкой) и определены параметры его микроструктуры (качественный и количественный состав фаз, процент кристаллической и аморфной фаз, уровень пористости, толщина межпоровой перегородки). Табл. 2 содержит диапазоны изменения и средние значения указанных выше параметров для различных потенциальных применений моделей. Каждое среднее значение произведено как арифметическое среднее параметра (4) по девяти составам:

$$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i = \frac{1}{N} (x_1 + \dots + x_N), \quad (4)$$

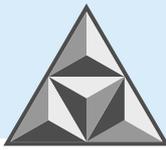
где x_i – исходный вектор признаков; \bar{x} – среднее значение вектора признаков.

Таблица 2. Диапазоны изменений эксплуатационных свойств и параметров микроструктуры

Table 2. Ranges of changes in operational properties and microstructure parameters

Параметр	max	min	mean value
Теплопроводность, Вт·м ⁻¹ ·град ⁻¹	0.17	0.11	0.14
Плотность, кг·м ⁻³	900.13	658.50	791.62
Прочность при сжатии, МПа	29.70	7.52	18.01
Прочность на растяжение при изгибе, МПа	0.90	0.34	0.61
Прочность при растяжении перпендикулярно лицевой поверхности, МПа	19.44	9.78	14.01
Прочность при действии сосредоточенной нагрузки, МПа	27.31	6.64	15.40
Пористость, %	77.30	56.10	70.19
Толщина межпоровых перегородок, мм	0.36	0.17	0.29
Количественные значения кристаллических фаз, %	21.54	0.60	4.39
Количество аморфной фазы, %	43.30	8.36	25.42
Кварц SiO ₂ , %	10.80	5.30	7.59
Пироксен (диопсид) Ca(Mg,Fe)(Si ₂ O ₆), %	72.40	44.80	62.03
Кристаллит SiO ₂ , %	15.50	1.90	6.37
Нефелин Na ₃ K(AlSiO ₄) ₄ , %	6.70	1.30	4.29
Эсколаит Cr ₂ O ₃ , %	10.10	0.00	2.73
Волластонит Ca(SiO ₃), %	37.70	0.00	16.92

Проведенный исследовательский анализ включал химический состав и эксплуатационные характеристики. Результаты были объединены в файл *.csv и загружены в среду Jupyter Notebook с применением языка программирования Python.



Для построения регрессионных моделей представлены два варианта исследования. В первом варианте проанализировано воздействие химического состава на эксплуатационные характеристики материала. Как независимая переменная использовалось процентное содержание компонентов (см. табл. 1). Теплопроводность, плотность, прочность при сжатии, изгибе, растяжении перпендикулярно поверхности и при действии сосредоточенной нагрузки были использованы в качестве зависимых переменных.

На основе этих данных были получены уравнения регрессии, которые описывают зависимость между химическим составом и эксплуатационными свойствами материала.

Оценку корреляции между переменными производили с использованием метода Пирсона (5). Для этого дана корреляционная матрица (рис.4), которая позволила определить степень взаимосвязи между независимыми и зависимыми параметрами. Результирующее значение равно [-1, 1], где -1 означает идеальную отрицательную корреляцию, а +1 означает идеальную положительную корреляцию; 0 означает, что две переменные не имеют линейной корреляции. Это позволило выявить наиболее значимые факторы, оказывающие влияние на эксплуатационные свойства пеностекла.

$$r = \frac{\sum_{i=1}^n (x_i - \bar{X})(y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{X})^2 \sum_{i=1}^n (y_i - \bar{Y})^2}}, \tag{5}$$

где x_i – значения переменной X ;

y_i – значения переменной Y ;

\bar{X} – среднее выборочное по X ;

\bar{Y} – среднее выборочное по Y .

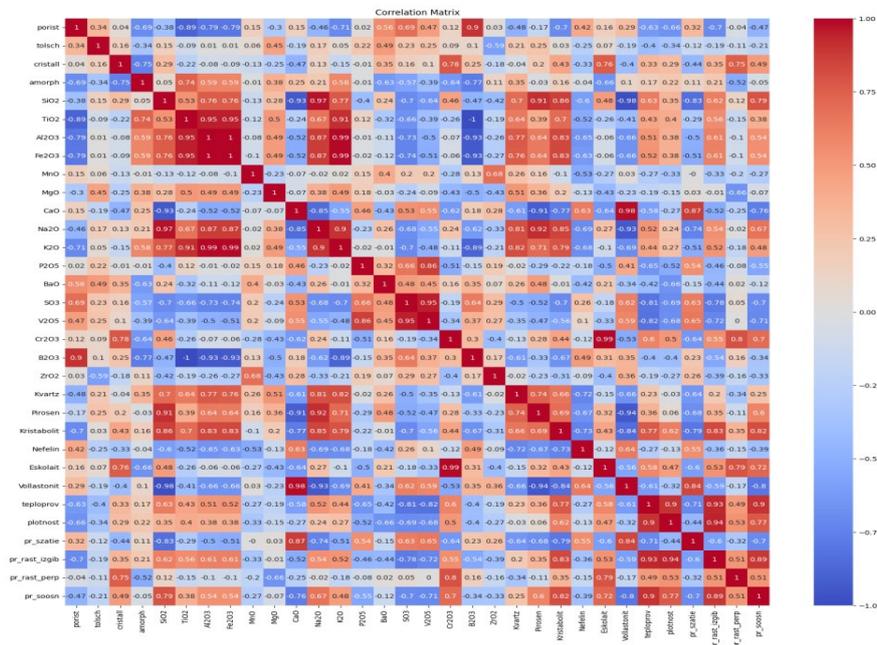
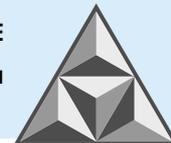


Рис. 4. Корреляционная матрица степени взаимосвязи между независимыми и зависимыми параметрами

Fig. 4. Correlation matrix of the relationship degree between independent and dependent parameters

Для стандартизации вектора независимых переменных применено стандартное отклонение с использованием функции StandardScaler из библиотеки SciKit-Learn. Для настройки регрессионной модели использована функция SGDRegressor из sklearn.linear_model (6-8). Этот метод позволяет без участия человека подобрать коэффициенты модели с помощью градиентного спуска.



При этом определяется стандартизация (z):

$$z = \frac{x_i - \bar{x}}{\sigma}; \quad (6)$$

$$\bar{x} = \frac{1}{N} \sum_{i=1}^N (x_i); \quad (7)$$

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2}, \quad (8)$$

где x_i – исходный вектор признаков,

\bar{x} – среднее значение вектора признаков,

σ – стандартное отклонение.

Задаем целевую метрику для минимизации (используется среднеквадратичная ошибка MSE) и определяем параметры градиентного спуска: скорость обучения η_0 (например, 0.01) и критерий останова через параметр tol (например, 0.0001). Алгоритм SGDRegressor завершит процесс обновления коэффициентов модели, если изменение MSE станет меньше 0.0001.

Путем последовательного подбора гиперпараметров в SciKit-Learn определены значения для зависимых параметров. Для каждого параметра использовали коэффициенты регрессионных моделей, учитывающие влияние каждой независимой переменной и их комбинации без квадратичных зависимостей. В итоге получены 12 моделей, соответствующих зависимым параметрам.

Сценарий №2 включал в себя получение уравнений регрессии, описывающих связь химического состава с микроструктурой и ее влияние на эксплуатационные характеристики образца. На первом этапе независимыми параметрами были процентные доли компонентов, согласно табл. 1. Зависимыми параметрами последовательно служили пористость, толщина межпоровой перегородки, количество кристаллической и аморфной фаз, кварца, пироксена, кристобалита, нефелина, эсколаита, волластонита. Для моделирования использованы нормализованные данные вектора из сценария №1 с аналогичными гиперпараметрами SGDRegressor. Этап завершился созданием 20 моделей, соответствующих микроструктуре, и удвоением зависимых параметров.

На втором этапе исследования использовались параметры пористости, толщины перегородки, содержание фаз кварца, пироксена. Зависимые параметры включали теплопроводность, плотность, прочность и др. Создано 12 моделей с данными, нормализованными через стандартное отклонение в SciKit-Learn. Оптимизирована регрессионная модель с SGDRegressor и гиперпараметрами, разработано 32 модели.

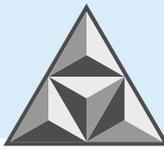
Для каждой созданной модели были определены значения RMSE, которые представляют собой корень из средней квадратичной ошибки, рассчитанный по традиционной математической формуле:

$$RMSE(a, X) = \sqrt{\frac{1}{N} \sum_{i=1}^N (a(x_i) - \hat{y}_i)^2}, \quad (9)$$

где N – количество экспериментальных данных, равное числу представленных образцов;

y_i – значение зависимой переменной y , которое было экспериментально получено для i -образца и является образцовым значением;

\hat{y}_i – значение зависимой переменной y для i -образца с использованием модели.



Результаты измерений RMSE были преобразованы в относительные величины погрешности δ :

$$\delta = \frac{RMSE}{y_{max}} \cdot 100\%, \quad (10)$$

где y_{max} – верхняя граница значений зависимой переменной y , полученная путем анализа результатов измерений по всем образцам в выборке.

Также была проведена проверка моделей на воспроизводимость; коэффициенты рассчитывались минимум пять раз для оценки стабильности результатов (в пределах $\pm 10\%$).

РЕЗУЛЬТАТЫ И ИХ ОБСУЖДЕНИЕ

На основе разработанных моделей (12 для Сценария №1 и 32 для Сценария №2) приведены формулы, используемые для предварительной проверки соответствия результатов принципу согласованности с теоретическими положениями и известными связями, описывающими термохимические превращения. При составлении формул использованы обозначения:

$$x_{\text{комп}} = f(v_{\text{комп}}) = \frac{v_{\text{комп}} - u}{\sigma}, \quad (11)$$

где $v_{\text{комп}}$ – доля конкретного компонента (оксида);

u – среднее значение химического состава, рассчитанное по всем значениям;

σ – стандартное отклонение исходных данных от среднего по составу.

1) Модель регрессии была построена для анализа влияния содержания конкретного химического соединения на количество кристаллической фазы в исходном составе. Важность увеличения содержания Cr_2O_3 в шихте для увеличения количества кристаллической фазы в итоговом образце отражена в модели:

$$\begin{aligned} K(x_{\text{компи}}) = & 6.88 \cdot x_{\text{Cr}_2\text{O}_3} - 3.19 \cdot x_{\text{CaO}} + 2.33 \cdot x_{\text{MgO}} + 2.22 \cdot x_{\text{ZrO}_2} + 2.22 \cdot x_{\text{P}_2\text{O}_5} - \\ & - 1.95 \cdot x_{\text{K}_2\text{O}} - 1.79 \cdot x_{\text{BaO}} + 1.72 \cdot x_{\text{V}_2\text{O}_5} + 1.17 \cdot x_{\text{SO}_3} - 1.04 \cdot x_{\text{Na}_2\text{O}} + 0.72 \cdot x_{\text{SiO}_2} + \\ & + 0.67 \cdot x_{\text{TiO}_2} - 0.66 \cdot x_{\text{B}_2\text{O}_3} + 0.25 \cdot x_{\text{Al}_2\text{O}_3} + 0.08 \cdot x_{\text{Fe}_2\text{O}_3} + 0.002 \cdot x_{\text{MnO}} + 4.39. \end{aligned} \quad (12)$$

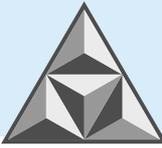
2) Данная модель выявляет превалирующее влияние снижения доли Cr_2O_3 в исходном составе на увеличение количества кристаллической фазы в конечном образце:

$$\begin{aligned} A(x_{\text{компи}}) = & -4.58 \cdot x_{\text{Cr}_2\text{O}_3} + 2.53 \cdot x_{\text{CaO}} + 1.65 \cdot x_{\text{K}_2\text{O}} - 1.56 \cdot x_{\text{SO}_3} - 1.53 \cdot x_{\text{V}_2\text{O}_5} - \\ & - 1.30 \cdot x_{\text{MgO}} - 1.14 \cdot x_{\text{P}_2\text{O}_5} - 1.03 \cdot x_{\text{B}_2\text{O}_3} + 0.93 \cdot x_{\text{TiO}_2} - 0.86 \cdot x_{\text{BaO}} - 0.81 \cdot x_{\text{SiO}_2} + \\ & + 0.75 \cdot x_{\text{Fe}_2\text{O}_3} + 0.66 \cdot x_{\text{Al}_2\text{O}_3} + 0.34 \cdot x_{\text{Na}_2\text{O}} - 0.17 \cdot x_{\text{ZrO}_2} + 0.06 \cdot x_{\text{MnO}} + 25.42. \end{aligned} \quad (13)$$

3) Модель регрессии, которая анализирует взаимосвязь между содержанием эсколаита Cr_2O_3 и долями химических соединений в исходной смеси, включая их комбинации. В данной модели подчеркивается ключевая роль увеличения содержания Cr_2O_3 во всех комбинациях для формирования эсколаита:

$$\begin{aligned} n_{\text{эсколаит}}(x_{\text{компи}}, x_{\text{компи}}, x_{\text{компи}}) = & (2.17 \cdot x_{\text{BaO}} \cdot x_{\text{Cr}_2\text{O}_3} + 1.90 \cdot x_{\text{V}_2\text{O}_5} \cdot x_{\text{Cr}_2\text{O}_3} + 1.86 \cdot x_{\text{SO}_3} \cdot x_{\text{Cr}_2\text{O}_3} + \\ & + 1.82 \cdot x_{\text{P}_2\text{O}_5} \cdot x_{\text{Cr}_2\text{O}_3} + 1.82 \cdot x_{\text{MnO}} \cdot x_{\text{Cr}_2\text{O}_3} + 1.73 \cdot x_{\text{K}_2\text{O}} \cdot x_{\text{Cr}_2\text{O}_3} + 1.72 \cdot x_{\text{Na}_2\text{O}} \cdot x_{\text{Cr}_2\text{O}_3} + \\ & + 1.72 \cdot x_{\text{Al}_2\text{O}_3} \cdot x_{\text{Cr}_2\text{O}_3} + 1.72 \cdot x_{\text{Fe}_2\text{O}_3} \cdot x_{\text{Cr}_2\text{O}_3} + 1.71 \cdot x_{\text{B}_2\text{O}_3} \cdot x_{\text{Cr}_2\text{O}_3} + 1.70 \cdot x_{\text{MgO}} \cdot x_{\text{Cr}_2\text{O}_3} + \\ & + 1.70 \cdot x_{\text{SiO}_2} \cdot x_{\text{Cr}_2\text{O}_3} + 1.68 \cdot x_{\text{TiO}_2} \cdot x_{\text{Cr}_2\text{O}_3} + 1.68 \cdot x_{\text{Cr}_2\text{O}_3} + 1.23 \cdot x_{\text{CaO}} \cdot x_{\text{Cr}_2\text{O}_3} + 26.94) \cdot 10^{-1}. \end{aligned} \quad (14)$$

4) В данной модели подчеркивается важность снижения пористости и толщины межпоровых перегородок при увеличении теплопроводности материала:



$$\lambda(z_{\text{парам.}i}, z_{\text{парам.}i}, z_{\text{парам.}j}) = (-2.47 \cdot \Pi \cdot d - 2.14 \cdot d - 1.94 \cdot \Pi - 1.67 \cdot d \cdot n_{\text{пироксен}} - 1.42 \cdot d \cdot n_{\text{кварц}} + 1.40 \cdot n_{\text{кристобалит}} \cdot n_{\text{нефелин}} - 1.36 \cdot \Pi \cdot n_{\text{пироксен}} - 1.27 \cdot \Pi \cdot n_{\text{кварц}} - 1.26 \cdot n_{\text{кристобалит}} \cdot n_{\text{воластонит}} + 1.18 \cdot A \cdot n_{\text{кристобалит}} + 1.16 \cdot A - 1.08 \cdot n_{\text{эсכולант}} \cdot n_{\text{воластонит}} + 1.03 \cdot A \cdot n_{\text{нефелин}} + 1.01 \cdot n_{\text{кристобалит}} + 0.99 \cdot n_{\text{пироксен}} \cdot n_{\text{кристобалит}} + 88.14) \cdot 10^{-3}, \quad (15)$$

где Π – пористость;

d – толщина межпоровой перегородки;

n_x – количество компонента x кристаллической фазы.

Ниже дополнительно представлены некоторые примеры моделей, вызвавших особый интерес авторов и требующие дополнительного анализа.

1) Модель регрессии, которая учитывает связь между содержанием конкретного химического соединения в исходной смеси и уровнем пористости материала:

$$\Pi(x_{\text{компи}}) = 2.62 \cdot x_{\text{BaO}} - 2.24 \cdot x_{\text{Cr}_2\text{O}_3} - 2.02 \cdot x_{\text{ZrO}_2} + 1.67 \cdot x_{\text{B}_2\text{O}_3} - 1.59 \cdot x_{\text{TiO}_2} - 1.07 \cdot x_{\text{P}_2\text{O}_5} - 0.98 \cdot x_{\text{MgO}} - 0.90 \cdot x_{\text{Al}_2\text{O}_3} - 0.82 \cdot x_{\text{Fe}_2\text{O}_3} + 0.68 \cdot x_{\text{Na}_2\text{O}} + 0.64 \cdot x_{\text{CaO}} + 0.40 \cdot x_{\text{SO}_3} + 0.28 \cdot x_{\text{K}_2\text{O}} - 0.18 \cdot x_{\text{V}_2\text{O}_5} + 0.09 \cdot x_{\text{SiO}_2} - 0.04 \cdot x_{\text{MnO}} + 70.19. \quad (16)$$

2) Модель регрессии, учитывающая взаимосвязь между содержанием определенного химического соединения в изначальной смеси и количеством кварца в конечном образце:

$$n_{\text{кварц}}(x_{\text{компи}}) = (5.01 \cdot x_{\text{MgO}} + 3.06 \cdot x_{\text{ZrO}_2} + 3.04 \cdot x_{\text{MnO}} - 2.98 \cdot x_{\text{CaO}} + 2.61 \cdot x_{\text{BaO}} + 2.56 \cdot x_{\text{Na}_2\text{O}} + 2.32 \cdot x_{\text{SiO}_2} + 1.95 \cdot x_{\text{K}_2\text{O}} - 1.92 \cdot x_{\text{Cr}_2\text{O}_3} + 1.54 \cdot x_{\text{Al}_2\text{O}_3} + 1.48 \cdot x_{\text{Fe}_2\text{O}_3} - 0.74 \cdot x_{\text{SO}_3} + 0.68 \cdot x_{\text{TiO}_2} - 0.62 \cdot x_{\text{V}_2\text{O}_5} - 0.49 \cdot x_{\text{B}_2\text{O}_3} - 0.30 \cdot x_{\text{P}_2\text{O}_5} + 75.24) \cdot 10^{-1}. \quad (17)$$

3) Модель регрессии, учитывающая взаимосвязь между теплопроводностью материала и различными параметрами его микроструктуры:

$$\lambda(z_{\text{парам.}i}) = (0.45 \cdot n_{\text{эсכולант}} - 0.45 \cdot \Pi + 0.44 \cdot n_{\text{кристобалит}} - 0.43 \cdot d - 0.29 \cdot n_{\text{воластонит}} + 0.18 \cdot A + 0.17 \cdot K + 0.07 \cdot n_{\text{пироксен}} - 0.05 \cdot n_{\text{кварц}} + 0.03 \cdot n_{\text{нефелин}} + 7.95) \cdot 10^{-2}. \quad (18)$$

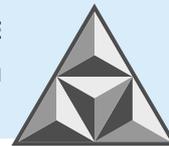
4) Модель регрессии, учитывающая влияние отдельных параметров микроструктуры на плотность материала:

$$\rho(z_{\text{парам.}i}) = (4.34 \cdot n_{\text{эсכולант}} - 4.06 \cdot \Pi - 3.28 \cdot n_{\text{кварц}} + 2.64 \cdot A + 2.16 \cdot n_{\text{кристобалит}} - 1.07 \cdot n_{\text{пироксен}} - 0.64 \cdot n_{\text{воластонит}} + 0.44 \cdot n_{\text{нефелин}} + 0.28 \cdot d + 0.05 \cdot K + 79.16) \cdot 10. \quad (19)$$

В табл. 3 представлены результаты расчета значений относительной приведенной погрешности δ .

Сравнение зависимых переменных и варианты учета факторов в таблице показали, что моделирование теплопроводности имеет наибольшие погрешности. Учет химического состава и их сочетаний снижает ошибку на 19.48%. Двухэтапный регрессионный анализ помогает точнее прогнозировать эксплуатационные параметры.

В результате исследований разработаны регрессионные модели, позволяющие оценить влияние параметров химического состава шихты на эксплуатационные свойства пеностекла. Разработанные модели обладают высокой точностью прогнозирования плотности и прочности при сжатии и растяжении с погрешностью $\leq 1\%$. Проверка разработанных уравнений подтвердила их соответствие теоретическим представлениям и логическим связям, описывающим термохимические процессы в системе. Это означает, что модели удовлетворяют основным принципам и концепциям, принятым в данной области исследований. Продолжительный анализ повторяемости расчета коэффициентов регрессии показал, что полученные результаты являются достаточно стабильными и надежными в



рамках рассматриваемой области знаний. Это говорит о том, что модели можно применять для прогнозирования свойств системы.

Анализ расчетной ошибки прогнозирования выявил необходимость использования двухэтапного регрессионного анализа. Этот метод включает вывод уравнений, отражающих влияние химического состава на структуру образца, и последующее определение влияния структуры на его свойства.

Таблица 3. Коэффициент ошибки регрессионных моделей, разработанных в исследовании

Table 3. Error coefficient of regression models developed under the study

Прогнозируемый параметр	Относительная ошибка моделей регрессии (%)			
	Сценарий №1		Сценарий №2	
	Эффект отдельных факторов на переменные	Эффект независимых переменных в отдельности и их комбинаций	Эффект отдельных факторов на переменные	Эффект независимых переменных в отдельности и их комбинаций
Теплопроводность	32.47	19.48	33.06	29.52
Плотность	1.26	1.05	2.39	0.02
Прочность при сжатии	9.14	9.05	5.23	0.30
Прочность на растяжение при изгибе	9.67	6.22	9.11	7.00
Прочность при растяжении, перпенд. лиц. поверхности	1.38	0.63	2.82	0.42
Прочность при действии сосредоточ. нагрузки	7.95	7.44	2.33	0.01
Пористость			0.81	0.56
Толщина межпоровых перегородок			18.61	11.11
Количественные значения кристаллических фаз			4.05	0.81
Количество аморфной фазы			1.18	0.61
Кварц SiO ₂			6.50	6.24
Пироксен (диопсид) Ca(Mg,Fe)(Si ₂ O ₆)			1.84	1.79
Кристаллит SiO ₂			2.52	1.55
Нефелин Na ₃ K(AlSiO ₄) ₄			3.81	1.28
Эсколаит Cr ₂ O ₃			4.01	3.19
Волластонит Ca(SiO ₃)			2.35	2.18

Полученные данные позволяют оценить необходимую плотность и прочность образца с учетом параметров структуры. Также рекомендуется учитывать влияние сочетания компонентов при расчете толщины перегородок и теплопроводности строительного материала. Погрешность прогнозирования теплопроводности составляет примерно 20%, что достаточно для предварительных оценок, но требует расширения обучающей выборки.

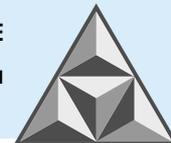
ВЫВОДЫ

После анализа ранжирования коэффициентов в регрессионных моделях выявлено:

1. Основное воздействие на характеристики пеностекла оказывает Cr₂O₃. Эсколаит, формирующийся в структуре материала, влияет его на теплопроводность, плотность и, как результат, на прочностные свойства.

2. Увеличение содержания MgO в шихте в сочетании с другими компонентами оказывает прямое влияние на показатели прочности материала.

3. Содержание BaO в шихте, особенно в сочетании с CaO, оказывает влияние на ряд характеристик материала. Увеличение уровня BaO приводит к снижению теплопроводности,



плотности и механических свойств материала. Это объясняется тем, что BaO обеспечивает формирование пористой структуры материала, причем эффект BaO на пористую структуру превышает воздействие Cr_2O_3 .

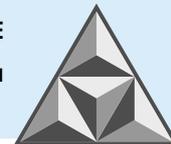
4. Существенное воздействие на прочность материала при сжатии оказывает CaO. Этот результат проявляется при взаимодействии CaO с другими составляющими смеси, что помогает компенсировать отрицательное воздействие Cr_2O_3 на механические характеристики материала. Увеличение концентрации CaO в смеси приводит к повышению содержания кристаллической фазы и снижению доли аморфной фазы в материале. Это свидетельствует о преобладающем влиянии CaO на структуру материала.

Разработанные модели машинного обучения на основе линейной регрессии представляют собой мощный инструмент, который позволяет анализировать экспериментальные данные не только для проверки существующих зависимостей, но и выявления скрытых и неочевидных взаимосвязей. Благодаря этим моделям появляется возможность оценить влияние взаимодействия различных факторов на эксплуатационные свойства пеностекла.

Использование моделей машинного обучения на основе линейной регрессии способствует установлению взаимосвязей между различными параметрами исследуемого материала. Они позволяют выявить важные факторы и определить их влияние на конечные характеристики пеностекла. Более того, эти модели позволяют реализовать предиктивное моделирование для оценки и предсказания потенциальных эффектов, которые могут проявляться при варьировании выявленных факторов.

СПИСОК ИСТОЧНИКОВ

1. **Sejdinović B.** Modern Thermal Insulation and Sound Insulation Materials // *Lecture Notes in Networks and Systems*. 2023. Vol. 539. P. 218-233. https://doi.org/10.1007/978-3-031-17697-5_19.
2. **Davraz M., Kору M., Akdağ A.E., Kılınçarslan Ş., Delikanlı, Y.E. et al.** g additives and usage rates in the production of ultra-light foam glass // *J. Therm. Analys. Calorimetr.* 2022. Vol. 147. P. 3567-3576. <https://doi.org/10.1007/s10973-021-10781-8>.
3. **Bashiri A., Amirhosseini A., Mirkazemi S. M. Ghanbari H.** Effect of Temperature and Water Glass Addition on the Microstructure and Physical Properties of Soda-Lime Foam Glass // *Glass Phys. Chem.* 2021. Vol. 47. P. 83-90. <https://doi.org/10.1134/S1087659621020024>.
4. **Semukhin B.S., Votinov A.V., Kazmina O.V.** Properties of Foamglass with Fullerene-like Mesostructure // *Rus. Phys. J.* 2020. T. 63. № 4. P. 710-712.
5. **Латынцева Е.А., Подойникова Я.Р., Безрукова Т.А., Муртазина А.А.** Влияние сырья на свойства пеностекла и перспективы развития // *Строительные материалы и изделия*. 2020. Т. 3. № 1. С. 44-48.
6. **Сорокин Д.С., Береговой В.А., Капустин А.Е.** Пористые гранулированные материалы на основе природных силицитов // *Инженерный вестник Дона*. 2019. № 2(53). С. 44.
7. **Zhimalov A.A., Nikishonkova O.A., Spiridonov Yu.A., Kosobudskii I.D.** Physical-Chemical Studies of Gaizes as Alternative Raw Materials for the Production of Foam Glass and Foam Materials // *Glass and Ceramics*. 2019. Vol. 75. P. 387-390. <https://doi.org/10.1007/s10717-019-00091-9>.
8. **Liu H., Tang M., Wang Z., Liu W. et al.** Optimized mechanical properties and thermal insulation capacity of foam glass through $\text{K}_2\text{Ti}_6\text{O}_{13}$ whiskers addition // *J. Austral. Ceram. Soc.* 2022. Vol. 58. P. 1241-1248. <https://doi.org/10.1007/s41779-022-00761-y>.
9. **Vedyakov I., Vaskalov V., Maliavski N., Nezhikov A. et al.** Granular Foam-Glass-Ceramic Thermal Insulation Based on Natural Quartz Sand // *Lect. Notes Civ. Eng.* 2023. Vol. 282. P. 395-405. https://doi.org/10.1007/978-3-031-10853-2_37.
10. **Федосов С.В., Bakanov M.O.** Теоретические и прикладные основы процессов высокотемпературной термической обработки при производстве теплоизоляционного пеностекла // *Устойчивое развитие региона: архитектура, строительство, транспорт*. Мат. VII Межд. науч.-практ. конф. Тамбов, 2020. С. 40-43.

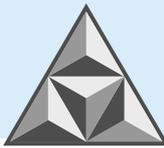


11. ГОСТ 7076-99 Материалы и изделия строительные. Метод определения теплопроводности и термического сопротивления при стационарном тепловом режиме. М.: ГУП ЦППБ, 2000. 27 с.
12. ГОСТ EN 1602-2011 Изделия теплоизоляционные, применяемые в строительстве. Метод определения кажущейся плотности. М.: Стандартинформ, 2012. 8 с.
13. ГОСТ 33949-2016 Изделия из пеностекла теплоизоляционные для зданий и сооружений. М.: Стандартинформ, 2019. 15 с.
14. ГОСТ 17177-94 Материалы и изделия строительные теплоизоляционные. Методы испытаний. М.: ИПК Изд. стандартов, 2002. 40 с.
15. ГОСТ EN 1607-2011 Изделия теплоизоляционные, применяемые в строительстве. Метод определения прочности при растяжении перпендикулярно к лицевым поверхностям. М.: Стандартинформ, 2012. 11 с.
16. ГОСТ EN 12430-2011 Изделия теплоизоляционные, применяемые в строительстве. Метод определения прочности при действии сосредоточенной нагрузки. М.: Стандартинформ, 2012. 16 с.
17. **Fedosov S.V., Bakanov M.O.** Modelling of Temperature Field Distribution of the Foam Glass Batch in Terms of Thermal Treatment of Foam Glass // *Int. Journ. Comput. Civ. Struct. Eng.* 2017. Vol. 13, no. 3. P. 112-118.
18. **Федосов С.В., Баканов М.О., Домнина К.Л.** Математическое моделирование технологических процессов получения теплоизоляционных ячеистых композитов // *Изв. Кыргыз. гос. техн. ун-та им. И. Раззакова*. 2020. № 3(55). С. 207-213.
19. **Гутьеррес, Д.Д.** Inside BIG DATA. Руководство по предиктивной аналитике: Платформа для бизнес-аналитики TIBCO Spotfire. 2017. Режим доступа: <http://www.spotfiretibco.ru/wpcontent/uploads/2017/09/InsideBIGDATA.pdf>. Дата доступа: 01.02.2024.
20. **Omar N.S., Hatem W.A., Najy H.I.** Predictive modeling for developing maintenance management in construction projects // *Civ. Eng. J.* 2019. Vol. 5. no. 4. P. 892-900.
21. **Moein M.M., Saradar, A., Rakhmati K., Musavinedzhad S.Kh.G. et al.** Predictive models for concrete properties using machine learning and deep learning approaches: rev. // *J. Build. Eng.* 2023. Vol. 63. P. 105444.
22. **Mater, Ya., Kamel M., Karam A., Bakhum E.** ANN-Python prediction model for the compressive strength of green concrete // *Constr. Innovation*. 2023. Vol. 23. no. 2. P. 340-359.
23. **Amin M.N. et al.** Prediction model for rice husk ash concrete using AI approach: Boosting and bagging algorithms // *Structures*. Elsevier, 2023. Vol. 50. P. 745-757. <https://doi.org/10.1016/j.istruc.2023.02.080>.
24. **Nazar S., Tszyn Ya., Amin M.N., Khan K. et al.** Machine learning interpretable-prediction models to evaluate the slump and strength of fly ash-based geopolymer // *J. Mat. Res. Tech.* 2023. Vol. 24. P. 100-124. <https://doi.org/10.1016/j.jmrt.2023.02.180>.
25. **Fransson E., Eriksson F., Erhart P.** Efficient construction of linear models in materials modeling and applications to force constant expansions // *Npj Comput Mater.* 2020. Vol. 6. P. 135. <https://doi.org/10.1038/s41524-020-00404-5>.
26. **Chore H. S., Shelke, N. L.** Prediction of compressive strength of concrete using multiple regression model. *Struct. Eng. Mechan.* 2013. Vol. 45(6). P. 837-851. <https://doi.org/10.12989/SEM.2013.45.6.837>.
27. **Obianyo I.I., Anosike-Francis E.N., Ihekwe G.O. et al.** Multivariate regression models for predicting the compressive strength of bone ash stabilized lateritic soil for sustainable building. *Constr. Build. Mat.* 2020. Vol. 263. P. 120677. <https://doi.org/10.1016/j.conbuildmat.2020.120677>.
28. **Jin R., Chen Q., Soboyejo A.B.O.** Non-linear and mixed regression models in predicting sustainable concrete strength // *Construction and Building Materials*. 2018. V. 170. P. 142-152. <https://doi.org/10.1016/j.conbuildmat.2018.03.063>.
29. **Матвеев М.А., Матвеев Г.М., Френкель Б.Н.** Расчеты по химии и технологии стекла. *Справ. пособие* // М.: Изд. лит. по строительству, 1972. 240 с.
30. **Pedregosa F. et al.** Scikit-learn: Machine Learning in Python // *J. Mach. Learn. Res.* 2011. Vol. 12. P. 2825-2830.

Поступила в редакцию 02.03.2024

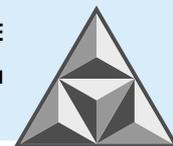
Одобрена после рецензирования 30.05.2024

Принята к опубликованию 10.06.2024



REFERENCES

1. **Sejdinović, B.** (2023) Modern Thermal Insulation and Sound Insulation Materials, *Lecture Notes in Networks and Systems*, (539), pp. 218-233. https://doi.org/10.1007/978-3-031-17697-5_19.
2. **Davraz, M., Koru, M., Akdağ, A.E., Kılıncarslan, Ş. & Delikanlı, Y.E. et al.** (2022) An investigation of foaming additives and usage rates in the production of ultra-light foam glass, *J. Therm. Analys. Calorimetr.*, (147), pp. 3567-3576. <https://doi.org/10.1007/s10973-021-10781-8>.
3. **Bashiri, A., Amirhosseini, A., Mirkazemi, S.M. & Ghanbari, H.** (2021) Effect of Temperature and Water Glass Addition on the Microstructure and Physical Properties of Soda-Lime Foam Glass, *Glass Phys. Chem.*, (47), pp. 83-90. <https://doi.org/10.1134/S1087659621020024>.
4. **Semukhin, B.S., Votinov, A.V. & Kazmina, O.V.** (2020) Properties of Foamglass with Fullerene-like Mesostructure, *Rus. Phys J.*, 63 (4), pp. 710-712 (in Russian).
5. **Latyntseva, E. A., Podoynikova, Ya. R., Bezrukova, T.A. & Murtazina, A.A.** (2020) Influence of raw materials on the properties of foam glass and development prospects, *Constr. Mat. Prod.*, 3 (1), pp. 44-48 (in Russian).
6. **Sorokin, D.S., Beregovoy, V.A. & Kapustin, A.E.** (2019) Porous granular materials based on natural silicites // *Engineering Journal of the Don*, 2(53), p. 44 (in Russian).
7. **Zhimalov, A.A., Nikishonkova, O.A., Spiridonov, Yu.A., Kosobudskii, I.D. & Vikulova, M.A.** (2019) Physical-Chemical Studies of Gaizes as Alternative Raw Materials for the Production of Foam Glass and Foam Materials, *Glass and Ceramics*, (75), pp. 387-390. <https://doi.org/10.1007/s10717-019-00091-9>.
8. **Liu, H., Tang, M., Wang, Z., Liu, W., Ma, Y. et al.** (2022) Optimized mechanical properties and thermal insulation capacity of foam glass through $K_2Ti_6O_{13}$ whiskers addition, *J. Austral. Ceramic Soc.*, (58), pp. 1241-1248. <https://doi.org/10.1007/s41779-022-00761-y>.
9. **Vedyakov, I., Vaskalov, V., Maliavski, N., Nezhikov, A. & Vedyakov, M.** (2023) Granular Foam-Glass-Ceramic Thermal Insulation Based on Natural Quartz Sand, *Lect. Not. Civ. Eng.*, (282), pp. 395-405. https://doi.org/10.1007/978-3-031-10853-2_37.
10. **Fedosov, S.V. & Bakanov, M.O.** "Theoretical and applied principles of high-temperature heat treatment processes in the production of thermal insulating foam glass" // *Ustojchivoe razvitie regiona: arhitektura, stroitel'stvo, transport [Sustainable development of the region: architecture, construction, transport]*. Mat. VII Mezhd. nauch.-prakt. konf. Tambov [Mat. VII Int. Sci. Pract. Conf. Tambov], 2020, pp. 40-43 (in Russian).
11. GOST 7076-99 *Construction materials and products. Method for determining thermal conductivity and thermal resistance under stationary thermal conditions*. M.: State Unitary Enterprise TsPPb, 2000 (in Russian).
12. GOST EN 1602-2011 *Thermal insulation products used in construction. Method for determining apparent density*. M.: Standartinform, 2012 (in Russian).
13. GOST 33949-2016 *Heat-insulating foam glass products for buildings and structures*. M.: Standartinform, 2019 (in Russian).
14. GOST 17177-94 *Heat-insulating construction materials and products. Test methods*. M.: IPK Publ. House of Standards, 2002 (in Russian).
15. GOST EN 1607-2011 *Thermal insulation products used in construction. Method for determining tensile strength perpendicular to face surfaces*. M.: Standartinform, 2012 (in Russian).
16. GOST EN 12430-2011 *Thermal insulation products used in construction. Method for determining strength under concentrated load*. M.: Standartinform, 2012 (in Russian).
17. **Fedosov, S.V. & Bakanov, M.O.** (2017) Modelling of Temperature Field Distribution of the Foam Glass Batch in Terms of Thermal Treatment of Foam Glass, *Int. J. Comput. Civ. Struct Eng.*, 13(3), pp. 112-118.
18. **Fedosov, S.V., Bakanov, M.O. & Domnina, K.L.** (2020) Mathematical modeling of technological processes for producing heat-insulating cellular composites, *News of the Kyrgyz. State Techn. Un-t im. I. Razzakova*, 3(55), pp. 207-213 (in Russian).
19. **Gutierrez, D.D.** Inside BIG DATA. Guide to Predictive Analytics: TIBCO Spotfire Business Intelligence Platform. 2017. Available at: <http://www.spotfiretibco.ru/wpcontent/uploads/2017/09/InsideBIGDATA.pdf>. (in Russian) (accessed 12.02.2024).
20. **Omar, N.S., Hatem, W.A. & Najy, H.I.** (2019) Predictive modeling for developing maintenance management in construction projects, *Civ. Eng. J.*, 5(4), pp. 892-900.



21. **Moein, M.M., Saradar, A., Rakhmati K., Musavinedzhad S.Kh.G. & Bristow J. et al.** (2023) Predictive models for concrete properties using machine learning and deep learning approaches: rev., *J. Build. Eng.*, (63), p. 105444.
22. **Mater, Ya., Kamel M., Karam A. & Bakhum E.** (2023) ANN-Python prediction model for the compressive strength of green concrete, *Constr. Innovation*, 23(2), pp. 340-359.
23. **Amin, M.N., Ivtikhar, B., Khan K., Javed M.F. & AbuArab A.M. et al.** (2023) Prediction model for rice husk ash concrete using AI approach: Boosting and bagging algorithms, *Structures*, (50), pp. 745-757. <https://doi.org/10.1016/j.istruc.2023.02.080>.
24. **Nazar, S., Tszyn Ya., Amin, M.N., Khan K. & Ashraf M. et al.** (2023) Machine learning interpretable-prediction models to evaluate the slump and strength of fly ash-based geopolymers, *J. Mat. Res. Techn.*, (24), pp. 100-124. <https://doi.org/10.1016/j.jmrt.2023.02.180>.
25. **Fransson, E., Eriksson, F. & Erhart, P.** (2020) Efficient construction of linear models in materials modeling and applications to force constant expansions, *Npj Comput. Mater.*, (6), p. 135. <https://doi.org/10.1038/s41524-020-00404-5>.
26. **Chore, H.S. & Shelke, N.L.** (2013) Prediction of compressive strength of concrete using multiple regression model, *Struct. Eng. Mechan.*, 45(6), pp. 837-851. <https://doi.org/10.12989/SEM.2013.45.6.837>.
27. **Obianyo, I.I., Anosike-Francis, E.N., Ihekwe, G.O., Geng, Ya. & Jin, R. et al.** (2020) Multivariate regression models for predicting the compressive strength of bone ash stabilized lateritic soil for sustainable building, *Constr. Build. Mat.*, (263), p. 120677. <https://doi.org/10.1016/j.conbuildmat.2020.120677>
28. **Jin, R., Chen, Q. & Soboyejo, A.B.O.** (2018) Non-linear and mixed regression models in predicting sustainable concrete strength, *Constr. Build. Mat.*, (170), pp. 142-152. <https://doi.org/10.1016/j.conbuildmat.2018.03.063>.
29. **Matveev, M.A., Matveev, G.M. & Frenkel, B.N.** *Calculations on chemistry and glass technology*: Ref. man. M.: Constr. Liter. Publ. House, 1972 (in Russian).
30. **Pedregosa, F., Varoquaux G., Gramfort A., Mishel V. & Bertrand T. et al.** (2011) Scikit-learn: Machine Learning in Python, *J. Mach. Learn. Res.*, (12), pp. 2825-2830.

Received 02.03.2024

Approved after reviewing 30.05.2024

Accepted 10.06.2024