

ИНТЕГРАЦИЯ МАШИННОГО ОБУЧЕНИЯ И ХИМИИ ТВЕРДОГО ТЕЛА ПРИ ПОИСКЕ ЭЛЕКТРОХИМИЧЕСКИХ МАТЕРИАЛОВ ДЛЯ ТОПЛИВНЫХ И ЭЛЕКТРОЛИЗНЫХ ЭЛЕМЕНТОВ

Integration of Machine Learning and Solid-State Chemistry for the Discovery of Electrochemical Materials for Fuel Cells and Electrolyzers

ОБЗОРНАЯ СТАТЬЯ

К.х.н. Устинов Виталий Евгеньевич

Института химии твердого тела и механохимии СО РАН

ул. Кутателадзе, 18, Новосибирск 630128 (Россия)

E-mail: vit123@gmail.com

Содержание

Аннотация.....	5
1. Введение	7
1.1. Роль материалов в развитии водородной энергетики	7
1.2. Ограничения традиционного подхода «синтез–характеризация–оптимизация» ...	8
1.3. Концепция Materials Informatics	9
1.4. Цель и задачи обзора	10
2. Химия твердого тела как основа проектирования электрохимических материалов...	12
2.1. Кристаллохимические принципы и геометрические дескрипторы	12
2.2. Термодинамика дефектообразования в нотации Крёгера–Винка	13
2.3. Механизмы миграции и термодинамика блокирования кислородных вакансий .	14
2.4. Физикохимия протонного транспорта: Уравнения гидратации	15
2.5. Связь структуры и свойств	16
3. Базы данных для материаловедения	17
3.1. Materials Project и интерфейс MAPI	17

3.2. OQMD (Open Quantum Materials Database): Однородные расчетные данные для материаловедения	18
3.3. AFLOW (Automatic Flow for Materials Discovery)	19
3.4. NOMAD (Novel Materials Discovery): Инфраструктура стандартизации и хранения вычислительных данных	20
3.5. Open Catalyst Project (OCP): Бенчмаркинг адсорбционных процессов	20
4. Методы машинного обучения в материаловедении	21
4.1. Регуляризованные регрессионные модели: L1 и L2 селекция	21
4.2. Random Forest (Случайный лес): Ансамблирование на табличных признаках	22
4.3. XGBoost (Экстремальный градиентный бустинг)	23
4.4. Support Vector Machine (Метод опорных векторов) и ядровый трюк.....	23
4.5. Глубокое обучение (Deep Learning) и представление потенциалов	24
5. Представление кристаллических структур для машинного обучения	26
5.1. Дескрипторы состава	26
5.2. Структурные дескрипторы.....	26
5.3. SOAP (Smooth Overlap of Atomic Positions)	27
5.4. Voronoi descriptors (Дескрипторы на основе полиэдров Вороного)	28
5.5. Graph representations (Графовые представления).....	31
6. Графовые нейронные сети	33
6.1. CGCNN (Crystal Graph Convolutional Neural Networks)	33
6.2. MEGNet (Molecular Crystal Graph Networks).....	35
6.3. ALIGNN (Atomistic Line Graph Neural Network).....	37
6.4. Matformer	39
7. Высокопроизводительный поиск материалов.....	41
7.1. DFT + Machine Learning	41
7.2. Active Learning (Активное обучение)	42
7.3. Bayesian Optimization (Байесовская оптимизация и функции полезности)	43
7.4. Autonomous Materials Discovery (Автономный поиск материалов).....	46
8. Машинное обучение для твердооксидных топливных элементов.....	47
8.1. Катодные материалы	47
8.2. Анодные материалы	50
8.3. Электролиты.....	51
8.4. Предсказание кислородной проводимости	52

8.5. Предсказание устойчивости.....	54
9. Машинное обучение для электролизеров.....	55
9.1. SOEC (Твердооксидные электролизные ячейки).....	55
9.2. Протонпроводящие электролиты	56
9.3. Электрокатализаторы расщепления воды	61
9.4. Материалы для rSOC (Обратимые твердооксидные ячейки)	61
10. Генеративный искусственный интеллект	62
10.1. Diffusion Models (Диффузионные модели).....	62
10.2. MatterGen	63
10.3. GNoME (Graph Networks for Materials Exploration).....	64
10.4. Математическая структура генераторов CDVAE (Crystal Diffusion Variational Autoencoder).....	65
10.5. Генерация новых оксидных материалов.....	70
11. Интерпретируемость моделей	70
11.1. Математический аппарат SHAP (Shapley Additive exPlanations)	70
11.2. Метрики Feature Importance в древовидных ансамблях.....	71
11.3. Физически информированное машинное обучение (Physics-Informed ML)	72
12 Ограничения существующих подходов.....	73
12.1. Недостаток экспериментальных данных и проблема "публикационного сдвига"	73
12.2. Проблема переноса моделей (Transferability) и экстраполяции	74
12.3. Моделирование метастабильных фаз и конфигурационной энтропии	75
12.4. Масштабный разрыв: Учет реальных дефектов, гетероструктур и границ зерен	76
13. Перспективы развития.....	79
13.1. Self-driving laboratories (Самоуправляемые лаборатории) и ИИ-оркестрация ...	79
13.2. Autonomous synthesis (Автономный роботизированный синтез).....	79
13.3. Цифровые двойники материалов (Digital Twins) и многомасштабное моделирование	80
13.4. Сквозная интеграция ИИ и operando-диагностики.....	81
14. Кейс-стади применения машинного обучения для поиска протонпроводящего электролита $\text{BaZr}_{0.4}\text{Sc}_{0.6}\text{O}_{3-\delta}$	82
14.1. Постановка материаловедческой задачи	82

14.2. Экспресс-скрининг и генерация дескрипторов.....	82
14.3. Фильтрация суррогатными моделями и регрессионный анализ.....	83
14.4. Экспериментальная валидация и свойства открытого материала	84
14.5. Вывод для closed-loop конвейера	85
15. Вычислительный пример инверсного дизайна катодного материала со структурой Раддлсдена–Поппера $\text{Ba}_{0.95}\text{Ca}_{0.05}\text{Ce}_{0.50}\text{Zr}_{0.30}\text{Y}_{0.10}\text{Sc}_{0.10}\text{O}_{3-\delta}$	86
15.1. Пошаговый путь поиска	86
16. Заключение	91
СПИСОК ЛИТЕРАТУРЫ	94

Аннотация

В настоящем обзоре систематически рассмотрены современные подходы к интеграции машинного обучения и химии твердого тела для направленного дизайна и ускоренного поиска электрохимических материалов для твердооксидных топливных элементов, твердооксидных электролизных ячеек и обратимых твердооксидных систем. Обсуждены фундаментальные кристаллохимические и дефектно-химические факторы, определяющие ионный транспорт, протонную и кислородную проводимость, химическую стабильность и электрокаталитическую активность материалов. Проанализированы возможности применения крупных вычислительных баз данных материаловедения, включая Materials Project, OQMD, AFLOW, NOMAD и Open Catalyst Project, в качестве основы для построения моделей машинного обучения и высокопроизводительного скрининга.

Рассмотрена эволюция методов прогнозирования свойств — от регуляризованных регрессионных моделей, Random Forest, XGBoost и методов опорных векторов до глубокого обучения, графовых нейронных сетей CGCNN, MEGNet, ALIGNN и архитектур на основе механизмов внимания. Особое внимание уделено представлению кристаллических структур с использованием дескрипторов состава, структурных и геометрических дескрипторов, формализма SOAP, полиэдров Вороного и графовых представлений. Обобщены стратегии интеграции DFT-расчетов с машинным обучением, активным обучением, байесовской оптимизацией и автономным поиском материалов.

Отдельно рассмотрены возможности генеративного искусственного интеллекта и диффузионных моделей для инверсного дизайна новых кристаллических материалов, а также методы интерпретируемости моделей и физически информированного машинного обучения. Проанализированы прикладные направления использования искусственного интеллекта для оптимизации электролитов, катодов, анодов и электрокатализаторов топливных элементов и электролизеров. На основе рассмотрения сквозных примеров поиска протонпроводящих электролитов показана возможность перехода от традиционного цикла «синтез–характеризация–оптимизация» к замкнутым вычислительно-экспериментальным конвейерам. Выявлены ключевые ограничения современных подходов, связанные с дефицитом экспериментальных данных, переносимостью моделей, экстраполяцией, описанием метастабильных фаз, реальных дефектов, границ зерен и гетероструктур. Обсуждены перспективы развития самоуправляемых лабораторий, автономного синтеза, цифровых двойников материалов и интеграции искусственного интеллекта с operando-диагностикой.

Ключевые слова: машинное обучение; искусственный интеллект; информатика материалов; химия твердого тела; электрохимические материалы; твердооксидные топливные элементы; твердооксидные электролизные ячейки; протонные проводники; кислородные вакансии; графовые нейронные сети; высокопроизводительный скрининг; генеративный искусственный интеллект; инверсный дизайн материалов; водородная энергетика.

This review provides a systematic analysis of modern approaches to integrating machine learning with solid-state chemistry for the targeted design and accelerated discovery of electrochemical materials for solid oxide fuel cells, solid oxide electrolysis cells, and

reversible solid oxide systems. The fundamental crystallochemical and defect-chemical factors governing ionic transport, protonic and oxygen-ion conductivity, chemical stability, and electrocatalytic activity are discussed. The potential of large computational materials databases, including the Materials Project, the Open Quantum Materials Database, AFLOW, NOMAD, and the Open Catalyst Project, as foundations for machine-learning models and high-throughput materials screening is analyzed.

The evolution of predictive approaches is reviewed, ranging from regularized regression models, Random Forest, XGBoost, and support vector methods to deep learning, crystal graph neural networks, including CGCNN, MEGNet, ALIGNN, and attention-based architectures. Particular attention is given to the representation of crystal structures using composition-based, structural, and geometric descriptors, the Smooth Overlap of Atomic Positions (SOAP) formalism, Voronoi-based descriptors, and graph representations. Strategies for integrating density functional theory calculations with machine learning, active learning, Bayesian optimization, and autonomous materials discovery are summarized.

The capabilities of generative artificial intelligence and diffusion-based models for the inverse design of novel crystalline materials are also considered, together with approaches to model interpretability and physics-informed machine learning. Applications of artificial intelligence to the optimization of electrolytes, cathodes, anodes, and electrocatalysts for fuel cells and electrolyzers are reviewed. Based on representative end-to-end examples of proton-conducting electrolyte discovery, the potential transition from the conventional “synthesis–characterization–optimization” cycle toward closed-loop computational–experimental workflows is demonstrated. Key limitations of current approaches are identified, including the scarcity of experimental data, limited model transferability, extrapolation challenges, and difficulties in describing metastable phases, realistic defects, grain boundaries, and heterostructures. Future directions involving self-driving laboratories, autonomous synthesis, materials digital twins, and the integration of artificial intelligence with operando diagnostics are discussed.

Keywords: machine learning; artificial intelligence; materials informatics; solid-state chemistry; electrochemical materials; solid oxide fuel cells; solid oxide electrolysis cells; proton conductors; oxygen vacancies; graph neural networks; high-throughput screening; generative artificial intelligence; inverse materials design; hydrogen energy.

1. Введение

1.1. Роль материалов в развитии водородной энергетики

Переход к углеродно-нейтральной экономике и минимизация антропогенного воздействия на климат требуют радикальной перестройки глобального энергетического сектора. В этой технологической трансформации водородная энергетика занимает центральное место, выступая в качестве универсального энергоносителя, способного связать возобновляемые источники энергии (ВИЭ) с конечными потребителями.

Ключевыми технологическими узлами водородного цикла являются процессы высокоэффективной генерации водорода и его последующей конверсии в электрическую и тепловую энергию. Эту задачу решают **твердооксидные топливные элементы (ТОТЭ, SOFC)** и **твердооксидные электролизные ячейки (ТОЭ, SOEC)**, включая обратимые системы (rSOC). Как отмечают в своей фундаментальной обзорной работе **S. Skinner, J. Kilner и соавторы [1]**, эффективность, ресурс и коммерческая жизнеспособность данных устройств напрямую определяются свойствами используемых функциональных материалов: электролитов, анодов и катодов.

Современный этап развития химии твердого тела направлен на создание материалов нового поколения, способных стабильно функционировать в среднетемпературном диапазоне (500–700 °C вместо традиционных 800–1000 °C). Снижение рабочей температуры критически важно для предотвращения деградации интерфейсов, подавления нежелательного межфазного взаимодействия и использования более доступных конструкционных материалов (например, ферритных сталей).

Однако переход в среднетемпературную область существенно повышает требования к кинетике переноса заряда. Для этого необходимы:

- **Инновационные электролиты:** материалы с ультранизким сопротивлением ионному (кислородному или протонному) транспорту и пренебрежимо малой электронной проводимостью. Подробный разбор механизмов их функционирования представлен в **Разделе 2.3** (Кислородные вакансии) и **Разделе 2.4** (Протонная проводимость). Примеры их ускоренного поиска методами искусственного интеллекта описаны в **Разделе 8.3** и **Разделе 9.2**, а

сквозной пошаговый пример открытия высокостабильного протонпроводящего электролита детально разобран в **Разделе 14**.

- **Высокоактивные электроды:** смешанные ионно-электронные проводники (МИЕС) со стабильной наноструктурой, обеспечивающие высокую скорость реакций восстановления/окисления кислорода (ORR/OER) и окисления/выделения водорода (HOR/HER). Архитектура и методы оптимизации данных систем с помощью алгоритмов ИИ проанализированы в **Разделах 8.1, 8.2** (для ТОТЭ) и **Разделах 9.3, 9.4** (для ТОЭ). Практический пошаговый пример инверсного дизайна высокоактивного безстронциевого катодного материала вынесен в **Раздел 15**.

Таким образом, именно прогресс в области фундаментального материаловедения является главным лимитирующим фактором и одновременно движущей силой развития водородных технологий.

1.2. Ограничения традиционного подхода «синтез–характеризация–оптимизация»

Классическая парадигма разработки новых неорганических соединений в химии твердого тела на протяжении десятилетий базировалась на линейном эмпирическом цикле: «**синтез → характеристика → оптимизация свойств**». Этот подход опирается на интуицию исследователя, метод проб и ошибок (trial-and-error), а также на постепенную химическую модификацию (допирование) уже известных базовых структурных матриц, таких как перовскит, флюорит или пирохлоры, что подробно рассматривается в контексте кристаллохимических принципов в **Разделе 2.1**.

В статье **A. Jain, S. P. Ong, G. Hautier и соавторов [2]** подчеркивается, что традиционный подход столкнулся со следующими жесткими ограничениями:

- **Низкая скорость и высокая стоимость:** Полный цикл от теоретического обоснования до лабораторного синтеза, рентгеноструктурного анализа, измерения электрохимических свойств методами импедансной спектроскопии и тестирования на долговременную стабильность одного сложного оксида занимает от нескольких месяцев до нескольких лет. Нарастающий дефицит экспериментальных данных для обучения современных предиктивных моделей констатируется в **Разделе 12.1**.

- **Узость исследуемого пространства:** Химическое пространство неорганических кристаллов колоссально (по оценкам, более 10^{10} возможных стабильных четверных и более сложных систем). Человеческий фактор ограничивает поиск узкими и хорошо изученными классами соединений, оставляя за рамками внимания принципиально новые кристаллографические фазы. Методы преодоления этой проблемы с помощью генеративного ИИ приводятся в **Разделе 10**.
- **Изолированность («негативных») результатов:** Экспериментальные неудачи (например, когда синтезированная фаза оказалась нестабильной или показала низкую проводимость) практически никогда не публикуются в научной периодике. Происходит потеря критически важных данных, а другие научные группы повторно совершают те же ошибки.
- **Вычислительный тупик квантовой химии:** Расчеты из первых принципов (Ab initio / DFT) совершили революцию в материаловедчестве, однако точное моделирование макроскопических кинетических свойств (например, энергии активации диффузии дефектов, температурных коэффициентов расширения) для сложных разупорядоченных систем требует огромных суперкомпьютерных ресурсов и не масштабируется на миллионы соединений. Ограничения DFT-моделирования при учете реальных дефектов и границ зерен разобраны в **Разделе 12.4**.

В условиях, когда климатическая повестка требует форсированного внедрения водородных технологий, традиционная триада «синтез–характеризация–оптимизация» превращается в узкое горлышко, замедляющее глобальный технологический трансфер, что детально аргументируют **J. Gomes, B. Meredig и соавторы** в своей программной работе [3].

1.3. Концепция Materials Informatics

Для преодоления ограничений эмпирического подхода в начале XXI века сформировалась новая междисциплинарная область знания — **информатика материалов (Materials Informatics)**. Как формулирует в своем классическом обзоре **K. Rajan [4]**, данное направление представляет собой глубокую интеграцию химии твердого тела, физики конденсированного состояния, больших данных (Big Data) и искусственного интеллекта (включая машинное и глубокое обучение). Информатика

материалов рассматривается мировым сообществом как «часто рассматривается как четвертая парадигма научных исследований» (после эмпирической, теоретической и вычислительной).

Вместо последовательного изучения единичных образцов Materials Informatics оперирует концепцией многопоточных цифровых исследований. В фундаментальном обзоре **J. Schmidt, L. Himanen и соавторов [5]** выделяются три столпа, на которых базируется данный подход:

- **Цифровая репрезентация вещества:** преобразование сложной трехмерной кристаллической структуры, распределения электронной плотности и дефектов в математические векторы, дескрипторы состава и графы, пригодные для обработки компьютерными алгоритмами. Математический базис дескрипторов и графовых представлений детально развернут в **Разделе 5** и **Разделе 6**.
- **Data-driven дизайн:** извлечение скрытых, нелинейных зависимостей «структура–свойство» из гигантских массивов накопленных данных без необходимости предварительного детального аналитического вывода физических уравнений. Ключевые базы данных (Materials Project, OQMD, AFLOW, NOMAD, Open Catalyst), выступающие фундаментом для data-driven подхода, описаны в **Разделе 3**. Математический аппарат алгоритмов (от Random Forest до Deep Learning) представлен в **Разделе 4**.
- **Виртуальный высокопроизводительный скрининг:** предварительный отбор миллионов виртуальных химических составов с помощью обученных статистических (суррогатных) моделей. Это позволяет существенно сократить число кандидатов, требующих дорогостоящих расчетов или экспериментальной проверки еще до начала реальных вычислений или синтеза. Методология такого скрининга (сочетание DFT + ML, алгоритмы Active Learning и Bayesian Optimization) приведена в **Разделе 7**.

Информатика материалов смещает фокус работы исследователя с рутинного лабораторного поиска на управление интеллектуальными алгоритмами, которые самостоятельно осуществляют навигацию в многомерных химических пространствах, трансформируясь в перспективе в полностью автономные лаборатории (см. **Раздел 13.1** и **13.2**).

1.4. Цель и задачи обзора

Целью настоящего обзора является систематический и критический анализ современного состояния, методологических основ, достижений и ключевых вызовов в области интеграции машинного обучения и химии твердого тела для направленного дизайна и ускоренного поиска электрохимических материалов (электролитов, катодов, анодов) для топливных элементов и электролизеров.

Для достижения поставленной цели в рамках обзора решаются следующие **задачи**:

1. Рассмотреть фундаментальные кристаллохимические принципы и законы дефектной химии оксидов, формирующие целевые свойства электрохимических материалов (протонную и кислородную проводимость, стабильность) (**Раздел 2**).
2. Проанализировать существующую инфраструктуру больших данных в материаловедении, включая ключевые открытые базы данных расчетных и экспериментальных свойств неорганических фаз (**Раздел 3**).
3. Систематизировать математические подходы к представлению кристаллических структур для алгоритмов ИИ, уделив особое внимание дескрипторостроению и графовым представлениям (**Раздел 5**).
4. Оценить эволюцию архитектур машинного обучения: от классических регрессионных моделей до современных графовых нейронных сетей (GNN) и моделей генеративного искусственного интеллекта (Generative AI) (**Раздел 4, Раздел 6, Раздел 10**).
5. Описать методологии высокопроизводительного поиска материалов с замкнутым циклом (Active Learning, Bayesian Optimization, Autonomous Materials Discovery) (**Раздел 7**).
6. Обобщить прикладные результаты применения ИИ для оптимизации конкретных функциональных слоев ТОТЭ, ТОЭ и rSOC (**Раздел 8, Раздел 9**).
7. Оценить подходы к интерпретируемости получаемых моделей машинного обучения (SHAP, Feature Importance) и концепции физически информированного ИИ (**Раздел 11**).
8. Выявить фундаментальные ограничения существующих подходов машинного обучения и определить долгосрочные перспективы развития данной междисциплинарной области (**Раздел 12, Раздел 13**).
9. Продемонстрировать сквозные пошаговые примеры успешного ускоренного поиска новых материалов: химически стабильного высокопроводящего

протонного электролита (**Раздел 14**) и высокоактивного катода со структурой Раддлсдена-Поппера (**Раздел 15**).

Обзор ориентирован как на специалистов в области химии твердого тела, стремящихся внедрить методы искусственного интеллекта в свою исследовательскую практику, так и на специалистов по анализу данных (Data Scientists), работающих над созданием новых физически информированных алгоритмов для материаловедения.

2. Химия твердого тела как основа проектирования электрохимических материалов

2.1. Кристаллохимические принципы и геометрические дескрипторы

Фундаментальной основой направленного поиска высокопроводящих и стабильных твердых электролитов и электродов является кристаллохимия, определяющая пространственное расположение атомов, геометрию координационных полиэдров и пути миграции ионных носителей заряда. В контексте среднетемпературных твердооксидных топливных элементов (ТОТЭ) и электролизеров (ТОЭ) доминирующее положение занимают три структурных класса: **перовскиты (ABO_3)**, **флюориты (AO_2)** и **пирохлоры ($A_2B_2O_7$)**.

Как подробно описывают **J. B. Goodenough** и соавторы в своей классической работе [6], геометрическая стабильность структуры перовскита ABO_3 жестко лимитируется фактором толерантности Гольдшмидта (t):

$$t = \frac{r_A + r_O}{\sqrt{2}(r_B + r_O)}$$

где r_A , r_B и r_O — ионные радиусы катионов позиций A (координационное число $CN = 12$), B ($CN = 6$) и аниона кислорода соответственно.

- При значениях $0.9 < t < 1.0$ формируется идеальная кубическая структура (пространственная группа $Pm\bar{3}m$), обеспечивающая изотропный трехмерный транспорт ионов.
- Снижение фактора толерантности ($t < 0.9$) приводит к кооперативному наклону и повороту октаэдров BO_6 , вызывая ромбические ($Pbnm$) или ромбоэдрические


($R\bar{3}c$) искажения, что увеличивает энергию активации миграции ионов и сужает каналы проводимости.

Для структур типа флюорита (например, CeO_2 , ZrO_2 критическим дескриптором выступает критический радиус допанта. **J. A. Kilner** в статье [7] показал, что минимизация энергии локального упругого искажения решетки при замещении матричного катиона A^{4+} допантом M^{3+} обеспечивает максимальную подвижность кислородных вакансий. Степень рассогласования радиусов ($\Delta r = |r_{\text{matrix}} - r_{\text{dopant}}|$) выступает ключевым линейным признаком для классических моделей машинного обучения.

2.2. Термодинамика дефектообразования в нотации Крёгера–Винка


Электрохимические свойства функциональных материалов в химии твердого тела определяются не только их идеальной кристаллической матрицей, но и типом, а также концентрацией точечных дефектов. Описание дефектообразования и термодинамического равновесия твердофазных систем осуществляется строго в рамках нотации Крёгера–Винка.

Базовым процессом, индуцирующим ионную проводимость в твердых электролитах при гетеровалентном акцепторном допировании (например, диоксида циркония оксидом иттрия, YSZ, или церата бария оксидом иттрия, BCY), является квазихимическая реакция растворения примеси. Для флюоритовой матрицы AO_2 , допированной акцепторным оксидом M_2O_3 , уравнение имеет вид:



где M'_A — катион допанта в узле катиона матрицы A, обладающий эффективным отрицательным зарядом -1 относительно решетки, $O_O^\times$ — ион кислорода в своем узле с нейтральным эффективным зарядом, а $V_O^{\bullet\bullet}$ — дважды положительно заряженная вакансия кислорода, выступающая основным носителем заряда.

В случае электронно-ионных проводников (МИЕС), используемых в качестве катодов ТОТЭ (например, $La_{1-x}Sr_xCo_{1-y}Fe_yO_{3-\delta}$ — LSCF), концентрация дефектов становится сильно зависимой от парциального давления кислорода (p_{O_2}) окружающей газовой среды и температуры, что описывается реакцией обмена с газом:



где $h^{\bullet}$ — электронная дырка (положительный электронный носитель заряда).

Применение закона действующих масс к данному равновесию позволяет рассчитать константу химического равновесия K_{ox} :

$$K_{ox} = \frac{[O_O^{\times}] \cdot [h^{\bullet}]^2}{[V_O^{\bullet\bullet}] \cdot p_{O_2}^{1/2}}$$

Как подробно изложено **H. L. Tuller** и соавторами в монографии [8], решение уравнений электронейтральности совместно с выражением для K_{ox} позволяет математически прогнозировать профили электронной и ионной составляющей проводимости при различных технологических режимах функционирования ТОТЭ/ТОЭ.

2.3. Механизмы миграции и термодинамика блокирования кислородных вакансий

Транспорт ионов кислорода (O^{2-}) в твердых телах протекает по вакансионному механизму, при котором ион совершает прыжок из заполненного узла решетки в соседнюю вакансию $V_O^{\bullet\bullet}$. Коэффициент парциальной ионной проводимости (σ_i) подчиняется классическому температурному уравнению Аррениуса:

$$\sigma_i = \frac{\sigma_0}{T} \exp\left(-\frac{E_a}{k_B T}\right)$$


где σ_0 — предэкспоненциальный множитель, пропорциональный концентрации носителей и частоте попыток прыжка, E_a — полная экспериментальная энергия активации проводимости, а k_B — константа Больцмана.

Энергия активации представляет собой сумму двух термодинамических величин, детально проанализированных в работе **M. Saiful Islam** [9]:

$$E_a = \Delta H_{assoc} + \Delta H_{migr}$$

- **ΔH_{migr} (энтальпия миграции):** энергетический барьер, который ион должен преодолеть при прохождении через критическое «узкое горлышко» (сформированное катионами решетки) в седловую точку переходного состояния.


- ΔH_{assoc} (энтальпия ассоциации дефектов): энергия связи, обусловленная кулоновским притяжением между противоположно заряженными точечными дефектами, например, акцептором и вакансией:



При высоких концентрациях допанта вакансии блокируются в таких электростатических кластерах, что приводит к наблюдаемому экспериментально падению проводимости при избыточном легировании. Модели машинного обучения на основе квантово-химических данных нацелены на минимизацию ΔH_{assoc} путем подбора содопантов.

2.4. Физикохимия протонного транспорта: Уравнения гидратации

В классе высокотемпературных протонных проводников на основе перовскитов состава $A^{2+}B^{4+}O_3$ (например, $BaZrO_3$, $BaCeO_3$) транспорт носителей заряда существенно отличается от вакансионного переноса O^{2-} . Внедрение протонов в структуру оксида происходит путем термодинамически обратимой реакции **гидратации**, протекающей во влажной атмосфере при температурах 300--600 °C:



где $OH_O^{\bullet}$ представляет собой протон, локализованный на гибридной орбитали мостикового атома кислорода решетки (дефект с эффективным зарядом +1).

Фундаментальный механизм транспорта протонов, известный как **механизм Гротгуса (эстафетный механизм)**, включает две последовательные стадии, детально описанные **K.-D. Kreuer** в обзоре [10]:

1. **Ротация (вращение)**: быстрое вращательное движение протона вокруг ядра кислорода, характеризующееся низким энергетическим барьером (< 0.1 эВ).
2. **Перескок (трансляция)**: перенос протона от одного иона кислорода к соседнему вдоль водородной связи. Эта стадия лимитирует общую скорость диффузии и требует локального сближения атомов кислорода за счет тепловых колебаний решетки (фононных мод).


Энтальпия гидратации (ΔH_{hydr}) является ключевым термодинамическим дескриптором: слишком отрицательные значения ΔH_{hydr} затрудняют дегидратацию, но могут снизить подвижность за счет сильной локализации протона, что делает поиск

оптимального баланса критически важной материаловедческой задачей.

2.5. Связь структуры и свойств


Прямая зависимость между кристаллической структурой, дефектным состоянием и макроскопическими электрохимическими свойствами формирует сложный, сильно нелинейный ландшафт, визуализация и математическое описание которого стандартными аналитическими методами часто заходят в тупик. Влияние структурных факторов на функциональные параметры иллюстрирует следующая схема:

Рисунок 2.1. Взаимосвязь между структурными факторами, характеристиками решетки и функциональными параметрами материалов



Как подчеркивают **T. S. Oh** и соавторы в своей методологической работе [11], малейшие изменения объема элементарной ячейки или угла связи $B - O - B$ способны изменять ионную проводимость и константу скорости поверхностного обмена кислорода на несколько порядков.

Более того, высокая ионная проводимость часто вступает в термодинамическое противоречие с химической стабильностью материала. Например, перовскиты на основе $BaCeO_3$ обладают превосходной протонной проводимостью, но легко разрушаются в атмосфере, содержащей CO_2 и H_2O , с образованием индивидуальных карбонатов и оксидов:



Традиционный интуитивный поиск не способен эффективно разрешить этот дуализм «стабильность–проводимость». Именно сложность, многофакторность и нелинейность взаимосвязей типа «структура–дефект–свойство» делают химию твердого тела идеальной ареной для развертывания инструментов информатики материалов и машинного обучения, способных выявлять скрытые закономерности в многомерных пространствах признаков.

3. Базы данных для материаловедения

3.1. Materials Project и интерфейс MAPI

Инфраструктура современных исследований в области информатики материалов опирается на высокопроизводительные вычислительные базы данных. Крупнейшей и наиболее авторитетной среди них является платформа **Materials Project**, созданная под эгидой Национальной лаборатории им. Лоуренса в Беркли (LBNL) и Массачусетского технологического института (MIT). Как отмечают в своей основополагающей статье **A. Jain, S. P. Ong, G. Ceder** и соавторов [2], проект создавался как открытая экосистема для реализации концепции «Генома материалов» (Materials Genome Initiative).

По состоянию на сегодняшний день Materials Project аккумулирует квантово-химические расчетные данные (полученные методами функционала плотности — DFT) для более чем 150 000 неорганических соединений. Для поиска материалов топливных элементов и электролизеров ключевое значение имеют следующие модули базы данных:

- **Фазовая стабильность (Phase Diagrams):** построение многокомпонентных диаграмм состояния и расчет энергии нахождения над плоскостью термодинамической стабильности ($E_{above\ hull}$). Значения $E_{above\ hull} = 0$ эВ/атом указывают на термодинамически стабильную фазу, тогда как значения до 0.05–0.1 эВ/атом маркируют потенциально синтезируемые метастабильные фазы.
- **Электронная структура:** точные профили плотности электронных состояний (DOS) и зонной структуры, позволяющие мгновенно отсеивать изоляторы при поиске смешанных ионно-электронных проводников (MIEC) для электродов.
- **Elasticity & Piezoelectricity:** тензоры упругости, критически важные для прогнозирования коэффициентов термического расширения (КТР) и упругих напряжений на интерфейсах «электролит/электрод».

Программный доступ к репозиторию осуществляется через стандартизированный интерфейс прикладного программирования **Materials Application Programming Interface (MAPI)** посредством библиотеки `pyomatgen` на языке Python. Это позволяет исследователям автоматизировать выгрузку сотен тысяч кристаллографических структур (в формате CIF) по заданным химическим фильтрам (например, *"выгрузить все содержащие барий и цирконий перовскиты"*).

3.2. OQMD (Open Quantum Materials Database): Однородные расчетные данные для материаловедения

Вторым по масштабу глобальным ресурсом для высокопроизводительного скрининга является **Open Quantum Materials Database (OQMD)**, развиваемая в Северо-Западном университете (Northwestern University) группой профессора К. Ровелла. Согласно программной публикации **J. E. Saal, S. Kirklin, C. Wolverton** и соавторов [12], OQMD сфокусирована на систематическом расчете термодинамических свойств кристаллических структур из базы ICSD (Inorganic Crystal Structure Database), а также на оценке огромного массива гипотетических соединений, созданных методом замещения элементов.

Текущая версия OQMD содержит расчетные данные для более чем 1 000 000 композиций. Главное преимущество OQMD перед аналогами заключается в строгой унификации параметров расчетов. Все вычисления проводятся с использованием

единого пакета квантово-химического моделирования VASP (Vienna Ab initio Simulation Package) в рамках функционала PBE (Perdew-Burke-Ernzerhof) с идентичными параметрами обрезания энергии плоских волн (energy cutoff) и плотности сетки k -точек.

Такой уровень стандартизации делает OQMD идеальным источником однородных обучающих выборок (training sets) для алгоритмов классического машинного обучения (например, Random Forest или Gradient Boosting). Модели, обученные на данных OQMD, свободны от систематических погрешностей, возникающих при смешивании данных, рассчитанных на различных вычислительных базисах.

3.3. AFLOW (Automatic Flow for Materials Discovery)

База данных **AFLOW** представляет собой не просто статический репозиторий, а глобальную автоматизированную платформу для высокопроизводительных расчетов из первых принципов, созданную консорциумом исследователей под руководством **S. Curtarolo**. Архитектура системы и методология управления потоками вычислений подробно описаны в работе [13].

В контексте проектирования ТОТЭ/ТОЭ ключевой ценностью AFLOW является глубокая интеграция специализированных вычислительных модулей:

- **AFLOW-CHULL**: алгоритм для прецизионного определения выпуклой оболочки (convex hull) стабильности многокомпонентных систем, учитывающий энтропийный вклад при повышенных температурах.
- **AFLOW-AEL (AFLOW Elastic Library) и AFLOW-AGL (AFLOW GIBBS Library)**: автоматизированные модули для расчета макроскопических термодинамических свойств материалов (температуры Дебая, теплоемкости C_p и C_v , коэффициентов теплового расширения) на основе квазигармонического приближения Дебая.

База данных AFLOW незаменима при поиске материалов, работающих в экстремальных условиях средне- и высокотемпературного электролиза. Она позволяет проводить первичный отсев кандидатов не при температуре 0 К (что является ограничением стандартного DFT), а с учетом температурных термодинамических потенциалов.

3.4. NOMAD (Novel Materials Discovery): Инфраструктура стандартизации и хранения вычислительных данных

В то время как Materials Project, OQMD и AFLOW создают собственные стандартизированные массивы данных, европейский консорциум **NOMAD Laboratory (Novel Materials Discovery)** решает принципиально иную задачу — агрегацию, долгосрочное хранение и систематизацию всех существующих в мире квантово-химических расчетов. В своей ключевой публикации **M. Scheffler, C. Draxl** и соавторов [14] позиционируют NOMAD как универсальный супер-репозиторий открытых данных (Open Data).

NOMAD содержит более 100 миллионов отдельных расчетных файлов, загруженных учеными из тысяч лабораторий по всему миру. Главным вызовом для такой системы является гетерогенность данных: вычисления могут быть выполнены в сотнях различных программных пакетов (VASP, Quantum ESPRESSO, WIEN2k, CP2K, Gaussian) с использованием разных приближений (LDA, GGA, гибридные функционалы, методы GW).

Для преодоления этой проблемы в NOMAD реализована развитая система парсеров (parsers) и нормализаторов (normalizers). Они переводят сырые выходные файлы любого квантово-химического кода в единый, независимый от программного обеспечения формат метаданных (NOMAD Metainfo). Этот нормализованный массив является беспрецедентным по объему фундаментом для обучения сверхглубоких нейросетевых архитектур и генеративных моделей, требующих для настройки миллионов весов экстремально больших выборок (Big Data).

3.5. Open Catalyst Project (OCP): Бенчмаркинг адсорбционных процессов

Специфическим и наиболее динамично развивающимся репозиторием данных, имеющим прямое прикладное значение для разработки катализаторов расщепления воды и электродов iSOC, является **Open Catalyst Project (OCP)**. Этот проект запущен в качестве совместной инициативы исследовательской группы по искусственному интеллекту компании Meta AI (FAIR) и Университета Карнеги — Меллона (CMU). Как детально изложено в программном манифесте **L. Zitnick, C. L. Zitnick, J. Giri** и соавторов [15], проект направлен на преодоление вычислительного барьера при моделировании гетерогенного катализа.

ОСР представляет собой специализированный массив данных, содержащий более 1.2 миллиона уникальных молекулярных релаксаций (что эквивалентно более чем 200 миллионам отдельных DFT-расчетов). База данных структурирована вокруг трех фундаментальных задач взаимодействия адсорбата с поверхностью катализатора:

1. **S2EF (Structure-to-Energy-and-Forces):** предсказание общей энергии системы и сил, действующих на каждый атом, по заданной пространственной конфигурации.
2. **IS2RE (Initial-Structure-to-Relaxed-Energy):** прямое прогнозирование финальной энергии релаксированного состояния на основе исходной (нерелаксированной) геометрии адсорбционного комплекса.
3. **IS2RS (Initial-Structure-to-Relaxed-Structure):** предсказание траектории и финальных координат всех атомов после релаксации.

В репозитории ОСР собраны данные по адсорбции ключевых промежуточных молекул водородного и кислородного циклов (H^* , O^* , OH^* , OOH^*) на поверхностях широкого спектра материалов: от чистых переходных металлов до сложных интерметаллидов, многокомпонентных сплавов и оксидов. Данный массив выступает главным мировым бенчмарком (тестовым полигоном) для обучения и валидации передовых графовых нейронных сетей (GNN) и нейросетевых потенциалов межатомного взаимодействия (Machine Learning Potentials), замещающих классическое DFT-моделирование.

4. Методы машинного обучения в материаловедении

4.1. Регуляризованные регрессионные модели: L1 и L2 селекция

Применение методов машинного обучения к прогнозированию свойств электрохимических материалов эволюционировало от простых статистических подходов к сверхсложным нейросетевым архитектурам. Базовым элементом этой эволюции являются **регрессионные модели**. В материаловедении линейная регрессия в чистом виде применяется редко из-за выраженной нелинейности физико-химических взаимодействий (например, экспоненциальной температурной зависимости проводимости). Однако регуляризованные варианты — **Ridge-регрессия (L2-регуляризация)** и **Lasso-регрессия (L1-регуляризация)** — активно используются для построения интерпретируемых физических уравнений.

Как показывают **G. Pilia, T. Lookman** и соавторы в своей работе [16], Lasso-регрессия является мощным инструментом для отбора признаков (feature selection). Минимизируя функционал ошибки с добавлением штрафа за абсолютные значения весов:

$$\min_{\mathbf{w}} \left(\frac{1}{2n} \sum_{i=1}^n (y_i - \mathbf{w}^T \mathbf{x}_i)^2 + \alpha \sum_{j=1}^m |w_j| \right)$$

Lasso зануляет коэффициенты перед малозначимыми дескрипторами. Это позволяет исследователю выявить базовые физические дескрипторы (например, разницу электроотрицательностей или средний ионный радиус), вносящие максимальный вклад в целевое свойство (например, в энтальпию образования перовскита). Основным ограничением линейных регуляризованных моделей остается их неспособность улавливать перекрестные эффекты и сложные топологические особенности кристаллических решеток без предварительного ручного конструирования полиномиальных признаков.

4.2. Random Forest (Случайный лес): Ансамблирование на табличных признаках

Для моделирования сложных нелинейных зависимостей без жестких априорных предположений о форме функции распределения в информатике материалов широко применяется алгоритм **Random Forest (RF)**. Метод основан на ансамблировании (бэггинге) большого количества независимых деревьев решений, каждое из которых обучается на случайной подвыборке объектов и случайном подмножестве признаков.

В фундаментальном исследовании **B. Meredig, C. Wolverton** и соавторов [17] продемонстрировано, что Random Forest обладает уникальной устойчивостью к переобучению (overfitting) и отлично справляется с табличными данными высокой размерности, содержащими сильные корреляции между дескрипторами.

В задачах поиска материалов для TOTЭ/ТОЭ Random Forest часто используется для классификации соединений на стабильные/нестабильные или для быстрой регрессионной оценки модулей упругости и температур плавления. Ключевое математическое преимущество RF заключается в возможности естественного вычисления внутренней метрики **Feature Importance (важность признаков)**, которая позволяет ранжировать химические факторы по их влиянию на ионный транспорт или

каталитическую активность. Главный недостаток алгоритма — неспособность к экстраполяции: RF не может предсказать значение свойства, выходящее за пределы диапазона целевых меток в обучающей выборке.

4.3. XGBoost (Экстремальный градиентный бустинг)

Более мощной альтернативой случайному лесу, сместившей баланс в сторону высокоточных предиктивных моделей, стал алгоритм **XGBoost (eXtreme Gradient Boosting)**. В отличие от RF, где деревья строятся независимо и параллельно, в градиентном бустинге деревья создаются последовательно. Каждое последующее дерево обучается предсказывать остатки (ошибки) предыдущего ансамбля, оптимизируя дифференцируемую функцию потерь с помощью градиентного спуска.

Эффективность применения градиентного бустинга для высокопроизводительного скрининга неорганических фаз детально обоснована в работе **L. Ward, C. Wolverton** и соавторов [18]. Целевая функция оптимизации XGBoost на шаге t включает член регуляризации $\Omega(f_t)$, штрафующий сложность дерева:

$$\mathcal{L}^{(t)} = \sum_{i=1}^n l(y_i, \hat{y}_i^{(t-1)} + f_t(\mathbf{x}_i)) + \Omega(f_t)$$

XGBoost включает встроенную L1 и L2 регуляризацию целевой функции, что эффективно предотвращает переобучение даже на относительно небольших экспериментальных выборках, характерных для химии твердого тела. Модели на базе XGBoost демонстрируют наивысшую точность среди всех классических (не нейросетевых) методов машинного обучения при прогнозировании ширины запрещенной зоны, плотности состояний на уровне Ферми и энергии образования дефектов в сложных оксидных системах. Основным лимитирующим фактором алгоритма является его высокая чувствительность к гиперпараметрам (скорость обучения, глубина деревьев, субсемплинг), требующая проведения трудоемкой кросс-валидации и байесовской оптимизации на этапе настройки модели.

4.4. Support Vector Machine (Метод опорных векторов) и ядровый трюк

Support Vector Machine (SVM), особенно в своей регрессионной ипостаси — **Support Vector Regression (SVR)**, занимает специфическую нишу в материаловедении благодаря так называемому «ядровому трюку» (**kernel trick**). Алгоритм отображает

исходные дескрипторы состава или структуры в многомерное (в общем случае — бесконечномерное) пространство признаков, где связь между параметрами становится линейной. В качестве функции ядра наиболее часто применяется радиально-базисная функция (RBF kernel):

$$K(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\gamma \|\mathbf{x}_i - \mathbf{x}_j\|^2)$$

В статье **Y. Liu, T. Lookman** и соавторов [19] показано, что SVR работает исключительно эффективно в условиях жесткого дефицита обучающих данных (малые выборки объемом от нескольких десятков до сотен точек). Это критически важно для электрохимии твердого тела, где получение точных экспериментальных значений (например, коэффициентов поверхностного обмена кислорода k^* методами вторично-ионной масс-спектрометрии SIMS) является крайне трудоемким процессом.

Модель SVR строит оптимальную разделяющую гиперплоскость, максимизируя зазор (margin) между опорными векторами, что обеспечивает хорошую обобщающую способность. Однако при увеличении объема выборки до масштабов Materials Project или OQMD вычислительная сложность SVM растет квадратично, что делает алгоритм неэффективным для обработки Big Data.

4.5. Глубокое обучение (Deep Learning) и представление потенциалов

Переход от классического машинного обучения к **Глубокому обучению (Deep Learning, DL)** ознаменовал фундаментальный сдвиг парадигмы в Materials Informatics: отказ от ручного конструирования признаков (hand-crafted features) в пользу **автоматического извлечения представлений (representation learning)**. Глубокие многослойные искусственные нейронные сети (полносвязные MLP, сверточные CNN и рекуррентные RNN) способны самостоятельно выстраивать иерархию абстракций, преобразуя первичные данные о веществе в сложные высокоуровневые признаки.

Как подчеркивают **K. T. Butler, A. Walsh** и соавторы в своем концептуальном обзоре [21], главным преимуществом DL-архитектур является их высокая масштабируемость и способность аппроксимировать сколь угодно сложные многомерные топологии.

В материаловедении топливных элементов глубокие нейросети применяются в двух ключевых ипостасях:

- **Суррогатные модели (Surrogate models):** сверхбыстрое предсказание макроскопических свойств непосредственно по химической формуле или кристаллографической матрице, заменяющее миллионы DFT-расчетов.
1. **Нейросетевые потенциалы межатомного взаимодействия (Machine Learning Potentials — MLPs):** нейросети обучаются предсказывать потенциальную энергию системы E_{total} и локальные силы $\mathbf{F}_i$, действующие на каждый атом, на основе конфигурации их локального химического окружения.

Математический аппарат построения таких потенциалов базируется на разложении общей энергии кристаллической решетки на сумму локальных атомных вкладов:

$$E_{\text{total}} = \sum_{i=1}^N E_i(\mathcal{R}_i)$$

где $\mathcal{R}_i$ — дескриптор локальной атомной конфигурации в пределах заданного радиуса отсечки R_{cut} (подробно описанный через формализмы SOAP в **Разделе 5.3**). Глубокая нейросеть (например, архитектуры Behler-Parrinello или TensorMol) выступает в роли универсального аппроксиматора функции E_i . Силы, действующие на i — й атом, извлекаются путем строгого аналитического дифференцирования предсказанного энергетического поля по декартовым координатам $\mathbf{r}_i$:

$$\mathbf{F}_i = -\nabla_{\mathbf{r}_i} E_{\text{total}} = -\sum_j \frac{\partial E_j}{\partial \mathcal{R}_j} \frac{\partial \mathcal{R}_j}{\partial \mathbf{r}_i}$$

Как показано в работе **A. Shapeev** и соавторов [21], использование таких потенциалов (например, Moment Tensor Potentials — MTP, или Neural Network Potentials — NNP), обученных на коротких ab initio траекториях, позволяет проводить классическое молекулярно-динамическое (MD) моделирование на временных интервалах до сотен наносекунд для пространственных масштабов в миллионы атомов. Это позволяет моделировать кооперативную диффузию кислородных вакансий или протонов с точностью, приближающейся к уровню используемых ab initio данных в пределах области применимости обученного потенциала, при существенно меньших вычислительных затратах по сравнению с прямыми расчетами DFT.

Несмотря на колоссальный предиктивный потенциал, глубокое обучение имеет два фундаментальных ограничения: экстремально высокую потребность в объемах обучающих выборок и полную потерю интерпретируемости, из-за чего DL-модели

часто называют «черными ящиками» (black boxes), что подробно анализируется в Разделе 11.

5. Представление кристаллических структур для машинного обучения

5.1. Дескрипторы состава

Для того чтобы алгоритмы машинного обучения могли обрабатывать химическую информацию, материаловедческие объекты необходимо преобразовать в числовые векторы фиксированной размерности. Наиболее простым и вычислительно дешевым подходом является конструирование **дескрипторов состава (composition-based descriptors)**, которые извлекают признаки исключительно из химической формулы вещества, полностью игнорируя пространственное расположение атомов.

Классическим примером такой репрезентации является библиотека признаков **Magpie (Materials Agnostic Platform for Materials Informatics)**, разработанная **L. Ward** и соавторами в работе [18]. Математический вектор Magpie формируется путем вычисления статистических метрик (средневзвешенное значение, мода, дисперсия, минимальное и максимальное значения) для фундаментальных свойств входящих в состав элементов. К этим свойствам относятся:

- Атомный номер, атомный вес и период в таблице Менделеева.
- Электроотрицательность по Полингу.
- Количество валентных электронов (*s*-, *p*-, *d*-, *f*-орбитали).
- Ионные и ковалентные радиусы, атомный объем.

Дескрипторы состава демонстрируют высокую эффективность при экспресс-скрининге стабильности фаз (например, при классификации структуры перовскита на кубическую/орторомбическую). Однако они принципиально неспособны различать полиморфные модификации вещества (например, рутил, анатаз и брукит для TiO_2), которые обладают идентичным составом, но кардинально различаются по электронной и ионной проводимости.

5.2. Структурные дескрипторы

Для преодоления ограничений, связанных с потерей пространственной информации, в материаловедческую информатику были внедрены **структурные дескрипторы (structure-based descriptors)**. Они кодируют точные трехмерные координаты атомов, параметры элементарной ячейки и геометрию химических связей, полученные из дифракционных экспериментов или DFT-релаксации.

Одним из первых успешных математических формализмов в этой области стала **матрица Кулона (Coulomb Matrix)**, предложенная **M. Rupp, O. A. von Lilienfeld** и соавторами в статье [23].

Элементы матрицы Кулона M_{ij} рассчитываются по формуле:

$$M_{ij} = \begin{cases} 0.5Z_i^{2.4} & \text{при } i = j \\ \frac{Z_i Z_j}{|\mathbf{r}_i - \mathbf{r}_j|} & \text{при } i \neq j \end{cases}$$

где Z_i и Z_j — заряды ядер атомов, а $|\mathbf{r}_i - \mathbf{r}_j|$ — пространственное расстояние между ними. Диагональные элементы аппроксимируют потенциальную энергию изолированных атомов, а внедиагональные — кулоновское отталкивание между ядрами.

Для бесконечных кристаллических решеток, характерных для химии твердого тела, матрица Кулона была модифицирована в **матрицу Эвальда (Ewald Matrix)**, которая корректно учитывает дальнотяствующие электростатические взаимодействия в периодических граничных условиях за счет суммирования по обратной решетке. Использование таких матриц позволяет прецизионно разделять полиморфы, однако размерность репрезентации жестко зависит от количества атомов в ячейке, что затрудняет сравнение структур с разным масштабом суперъячеек.

5.3. SOAP (Smooth Overlap of Atomic Positions)

Передовым стандартом локальных структурных дескрипторов, обеспечивающим математически строгое инвариантное представление атомного окружения, стал формализм **SOAP (Smooth Overlap of Atomic Positions)**. Разработанный **A. P. Bartók, G. Csányi** и соавторами в работе [23], SOAP преобразует дискретные координаты атомов в непрерывное распределение локальной атомной плотности.

Математически локальная плотность $\rho_\chi(\mathbf{r})$ вокруг центрального атома для

химического сорта χ аппроксимируется суммой суперпозиций трехмерных функций Гаусса:

$$\rho_{\chi}(\mathbf{r}) = \sum_{i \in \chi} \exp\left(-\frac{|\mathbf{r} - \mathbf{r}_i|^2}{2\sigma^2}\right)$$

Полученная функция плотности раскладывается в ряд по базису сферических гармоник $Y_{lm}(\hat{\mathbf{r}})$ и ортогональных радиальных функций $g_n(r)$. Инвариантность дескриптора SOAP к трансляциям, ротациям (поворотам) и перестановкам тождественных атомов достигается путем вычисления спектра мощности (power spectrum) коэффициентов разложения:

$$p_{nn'l}^{\chi} = \sum_{m=-l}^l c_{nlm}^{\chi} (c_{n'lm}^{\chi})^*$$

Дескрипторы SOAP формируют гладкое и дифференцируемое многомерное пространство признаков. Это делает их незаменимыми при создании нейросетевых потенциалов межатомного взаимодействия, предназначенных для моделирования динамики ионного транспорта. SOAP-дескрипторы могут использоваться для построения машинно-обучаемых межатомных потенциалов, обученных на данных квантово-химических расчетов, что позволяет моделировать атомную динамику и процессы ионного транспорта с точностью, зависящей от качества обучающей выборки и архитектуры модели.

5.4. Voronoi descriptors (Дескрипторы на основе полиэдров Вороного)

В физикохимии твердого тела важнейшую роль играет координационное окружение катионов и свободный объем кристаллической решетки. Для строгого геометрического описания этих факторов применяются **дескрипторы на основе разбиения Вороного (Voronoi tessellation descriptors)**. Метод заключается в геометрическом разделении трехмерного пространства кристалла на полиэдры (ячейки) Вороного, где каждая ячейка ограничивает область, более близкую к данному атому, чем к любому другому.

Внедрение и валидация дескрипторов Вороного для предиктивного моделирования неорганических фаз детально описаны в исследовании **L. Ward, C. Wolverton** и соавторов [24].

На основе геометрии полиэдров Вороного рассчитывается широкий спектр локальных дескрипторов:

- Абсолютный объем ячейки Вороного (мера локального свободного объема решетки).
- Эффективные координационные числа катионов и анионов, вычисляемые на основе площадей граней полиэдра.
- Степень сферичности и искажения координационного многогранника.

Для протонных и кислородпроводящих оксидов дескрипторы Вороного имеют прямое физическое значение. Объем полиэдра аниона кислорода напрямую коррелирует с локальной электронной плотностью и поляризуемостью, а параметры искажения катионных полиэдров позволяют оценивать упругие напряжения, лимитирующие энтальпию миграции (ΔH_{migr}) ионных носителей заряда.

Более подробно: в физикохимии твердого тела локальная топология, свободный объем и координационное окружение катионов и анионов являются определяющими факторами ионного транспорта. Для строгого количественного описания этих параметров в материаловедческую информатику интегрирован метод **разбиения Вороного (Voronoi tessellation)**.


Математический формализм разбиения

Пусть задано множество центров (атомов) кристалла $P = \{p_1, p_2, \dots, p_n\}$ в трехмерном евклидовом пространстве $\mathbb{R}^3$ с учетом периодических граничных условий (векторов решетки $\mathbf{L}$). Полиэдром (ячейкой) Вороного $V(p_i)$ для атома p_i называется замкнутая область пространства, все точки которой находятся ближе к p_i , чем к любому другому атому p_j :

$$V(p_i) = \{x \in \mathbb{R}^3 \mid \|x - p_i\| \leq \|x - p_j\|, \forall j \neq i\}$$

Математически полиэдр Вороного представляет собой выпуклый многогранник, образованный пересечением полупространств, ограниченных плоскостями, которые проходят через середины отрезков между центральным атомом p_i и его соседями p_j перпендикулярно этим отрезкам.

Рисунок 5.1. Математически полиэдр Вороного



Описание элементов схемы

- **Центральный атом (p_i):** Обозначен крупным черным кругом в центре. Представляет собой исследуемый базовый атом, для которого рассчитывается локальное окружение.
- **Соседние атомы (p_j):** Обозначены белыми кругами с черным контуром. Представляют атомы первой (или ближних) координационных сфер, формирующих окружение центрального узла.
- **Пунктирные линии:** Векторы межатомных связей, соединяющие центральный атом p_i с соседними атомами p_j .
- **Звёздочки (*):** Геометрические середины соответствующих межатомных отрезков. Именно через эти точки проходят разделяющие плоскости.
- **Точечные линии:** Следы плоскостей (полупространств) в двумерной проекции. Они проходят через звездочки строго перпендикулярно пунктирным линиям связей.
- **Полиэдр Вороного (штрихованная область):** Выпуклый многогранник, сформированный в результате пересечения всех ограничивающих полупространств. Любая точка внутри этой области находится ближе к атому p_i , чем к любому другому узлу кристаллической решетки.

Конструирование физических дескрипторов

На основе геометрических характеристик полученных полиэдров Вороного алгоритм формирует вектор признаков фиксированной размерности:

1. **Абсолютный и относительный объем ячейки (V_{cell}):** Характеризует локальное пространственное стеснение атома. Для кислородпроводящих оксидов величина свободного объема аниона:

$$\Delta V_{\text{free}} = V(p_{\text{O}}) - V_{\text{ion}}(\text{O}^{2-})$$

прямо пропорциональна локальной поляризуемости и обратно пропорциональна энтальпии миграции ΔH_{migr} [10.1103/PhysRevMaterials.1.033801].

2. **Эффективное координационное число (ECN):** Вместо жесткого радиуса отсечки связей координационный вклад каждой грани f_k полиэдра Вороного взвешивается пропорционально ее площади S_k :

$$\text{ECN}_i = \sum_{k \in \text{Faces}(V)} \frac{S_k}{S_{\text{max}}} \cdot \exp \left[1 - \left(\frac{d_{ik}}{d_{\text{min}}} \right)^6 \right]$$

где d_{ik} — расстояние до соседа, образующего грань k , а d_{min} — кратчайшее межатомное расстояние.

3. **Индекс сферичности (Sphericity Ψ) и искажения:** Оценивает степень отклонения координационного многогранника от идеальной геометрии (куба, октаэдра):

$$\Psi = \frac{\pi^{\frac{1}{3}} (6V_{\text{cell}})^{\frac{2}{3}}}{A_{\text{cell}}}$$

где A_{cell} — полная площадь поверхности полиэдра Вороного.

В протонпроводящих перовскитах $\text{BaCe}_{1-x}\text{Zr}_x\text{O}_3$ дескрипторы Вороного позволяют количественно описать анизотропию локального окружения кислорода [24].

Асимметрия площадей граней S_k вокруг узла $\text{O}_\text{O}^\times$ указывает на локальные наклоны октаэдров VO_6 , что коррелирует со снижением частоты ротационных мод протона по механизму Гротгуса.


5.5. Graph representations (Графовые представления)

Наиболее революционным и естественным шагом в эволюции дескрипторостроения стал переход к представлению кристаллических структур в виде **математических графов (Crystal Graphs)**. Кристалл с периодическими граничными условиями отображается в виде мультиграфа $\mathcal{G} = (\mathcal{V}, \mathcal{E})$, который инвариантен к трансляциям и ротациям по своей природе и полностью исключает необходимость ручного подбора физических признаков.

Как сформулировано в пионерской работе **T. Xie, J. C. Grossman [25]**, кодирование структуры в граф осуществляется по следующему алгоритму:

1. **Узлы графа ($\mathcal{V}$):** представляют собой индивидуальные атомы элементарной ячейки. Каждый узел инициализируется вектором первичных атомных свойств (атомный номер, электроотрицательность, валентность).
2. **Ребра графа ($\mathcal{E}$):** соответствуют химическим связям или пространственным межатомным расстояниям в пределах заданного радиуса отсечки (обычно $R_{cut} \approx 4\text{--}6 \text{ \AA}$). Ребра кодируются векторами, содержащими информацию о расстоянии между атомами (часто разложенном по базису Гауссовых функций для обеспечения гладкости).

Рисунок 5.2. Схема кодирования кристаллической структуры перовскита в математический кристаллический граф $G=(V, E)$ для графовых сверточных нейронных сетей (CGCNN).



Графовое представление позволяет сохранить полную топологическую и химическую связность трехмерной структуры. Оно выступает в качестве входного математического тензора для специализированных глубоких нейросетей, способных осуществлять сверточные операции непосредственно над кристаллической топологией, что открывает путь к беспрецедентно точному прогнозированию характеристик электрохимических материалов (подробно рассмотрено в Разделе 6).

6. Графовые нейронные сети

6.1. CGCNN (Crystal Graph Convolutional Neural Networks)

Разработка архитектуры **CGCNN (Crystal Graph Convolutional Neural Network)** стала поворотной точкой в информатике материалов, позволив осуществлять сверточные операции непосредственно над трехмерной периодической структурой кристалла. Созданная **Т. Xie** и **Ж. С. Grossman [25]** нейросеть исключила этап ручного конструирования признаков, преобразуя топологию решетки в инвариантное непрерывное признаковое пространство.

Математический базис архитектуры CGCNN представляет собой реализацию пространственной свертки на периодическом мультиграфе кристалла $\mathcal{G}$. На шаге t состояние каждого узла (атома) $v_i^{(t)} \in \mathbb{R}^F$ обновляется путем нелинейной агрегации признаков из его ближайшего окружения $N(i)$, ограниченного радиусом отсечки R_{cut} . Формальное уравнение свертки имеет вид:

$$v_i^{(t+1)} = v_i^{(t)} + \sum_{j \in N(i)} \sigma \left([v_i^{(t)} \parallel v_j^{(t)} \parallel e_{ij}] W_f^{(t)} + b_f^{(t)} \right) \odot g \left([v_i^{(t)} \parallel v_j^{(t)} \parallel e_{ij}] W_s^{(t)} + b_s^{(t)} \right)$$

где:

- $\parallel$ — операция конкатенации векторов, формирующая объединенный тензор признаков $\mathbf{z}_{ij} \in \mathbb{R}^{2F+F_e}$.
- $e_{ij} \in \mathbb{R}^{F_e}$ — вектор ребра, полученный путем разложения евклидова расстояния d_{ij} между атомами i и j по базису из F_e функций Гаусса:

$$e_{ij}^k = \exp \left(-\frac{(d_{ij} - \mu_k)^2}{2\sigma_0^2} \right)$$

где μ_k — равномерно распределенные центры в диапазоне $[0, R_{cut}]$, а σ_0 — ширина шага.

- $\sigma(x) = \frac{1}{1+e^{-x}}$ — элементные ворота (gating mechanism), регулирующие интенсивность информационного потока от ребра.
- $g(x) = \ln(1 + e^x)$ — гладкая функция активации (softplus), обеспечивающая непрерывность производных, что критично для расчета сил.
- $W_f^{(t)}, W_s^{(t)} \in \mathbb{R}^{(2F+F_e) \times F}$ и $b_f^{(t)}, b_s^{(t)} \in \mathbb{R}^F$ — обучаемые матрицы весов и векторы смещения t -го слоя.

После T слоев свертки макроскопическое свойство кристалла предсказывается через операцию глобального пулинга (усреднения по узлам ячейки) и полносвязный многослойный перцептрон (MLP):

$$\hat{y} = \text{MLP} \left(\frac{1}{N} \sum_{i=1}^N v_i^{(T)} \right)$$

В задачах дизайна ТОТЭ/ТОЭ архитектура CGCNN продемонстрировала высокую

точность при предсказании энергии образования кристаллических фаз и ширины запрещенной зоны. Однако базовая свертка CGCNN учитывает только радиальные расстояния между атомами, полностью игнорируя угловые характеристики химических связей, что снижает точность моделирования анизотропных или сильно искаженных решеток (например, орторомбических перовскитов).

6.2. MEGNet (Molecular Crystal Graph Networks)

В архитектуре MEGNet граф расширен до структуры $\mathcal{G} = (\mathcal{V}, \mathcal{E}, \mathbf{u})$, где $\mathbf{u} \in \mathbb{R}^{F_u}$ — вектор глобального состояния. Один полный блок графовой сети (GN block) состоит из трех последовательных шагов обновления, управляемых индивидуальными полносвязными функциями ϕ_e , ϕ_v и ϕ_u :

Шаг 1: Обновление ребер

Каждое ребро e_{ij} обновляется на основе состояний инцидентных ему узлов и глобального вектора:

$$e_{ij}^{(t+1)} = e_{ij}^{(t)} + \phi_e \left(\left[v_i^{(t)} \parallel v_j^{(t)} \parallel e_{ij}^{(t)} \parallel \mathbf{u}^{(t)} \right] \right)$$

Шаг 2: Обновление узлов

Для каждого узла i сначала вычисляется агрегированный вектор входящих

$$\bar{\mathbf{e}}_i^{(t+1)} = \frac{1}{|N(i)|} \sum_{j \in N(i)} e_{ij}^{(t+1)}$$

$$v_i^{(t+1)} = v_i^{(t)} + \phi_v \left(\left[v_i^{(t)} \parallel \bar{\mathbf{e}}_i^{(t+1)} \parallel \mathbf{u}^{(t)} \right] \right)$$

Шаг 3: Обновление глобального состояния

Глобальный атрибут $\mathbf{u}$ агрегирует информацию со всего графа через средние значения обновленных узлов и ребер:

$$\bar{\mathbf{v}}^{(t+1)} = \frac{1}{N} \sum_{i=1}^N \mathbf{v}_i^{(t+1)}, \quad \bar{\mathbf{e}}^{(t+1)} = \frac{1}{M} \sum_{k=1}^M \mathbf{e}_k^{(t+1)}$$

$$\mathbf{u}^{(t+1)} = \mathbf{u}^{(t)} + \phi_u \left(\left[\bar{\mathbf{v}}^{(t+1)} \parallel \bar{\mathbf{e}}^{(t+1)} \parallel \mathbf{u}^{(t)} \right] \right)$$

Здесь функции ϕ_e, ϕ_v, ϕ_u реализованы в виде плотных слоев (Dense layers) с линейной ректификацией (ReLU).

Наличие сквозного вектора $\mathbf{u}$ позволяет эффективно транслировать макроскопические граничные условия (например, заданную температуру T или парциальное давление кислорода p_{O_2}) на микроуровень межатомного взаимодействия.

Для преодоления ограничений ранних графовых архитектур **C. Chen, S. P. Ong** и соавторы разработали модель **MEGNet (Molecular Crystal Graph Networks)**, описанную в работе [26]. Главное математическое новшество MEGNet заключается во внедрении тотального графового блока (Global State Block), который расширил структуру графа $\mathcal{G} = (\mathcal{V}, \mathcal{E})$ до тройки $\mathcal{G} = (\mathcal{V}, \mathcal{E}, u)$, где u — вектор глобального состояния системы.

Вектор u кодирует макроскопические параметры среды или кристалла в целом, такие как температура, давление, энтропия или пространственная группа симметрии.

Алгоритм обновления в MEGNet включает три последовательные стадии:

1. Обновление векторов ребер ($\mathcal{E}$) с учетом локальных узлов и текущего глобального состояния.
2. Обновление векторов узлов ($\mathcal{V}$) на основе агрегированных модифицированных ребер и вектора u .

3. Обновление самого вектора глобального состояния (u) путем пулинга (усреднения) состояний всех узлов и ребер графа.


Такая сквозная архитектура обеспечивает дальнедействующий информационный обмен между элементами структуры, минуя жесткие ограничения радиуса отсечки локального окружения. Наличие вектора u открыло возможность прямого обучения моделей на свойства, зависящие от внешних термодинамических условий. В химии твердого тела MEGNet активно применяется для построения суррогатных моделей емкости двойного электрического слоя, а также для предсказания диэлектрической проницаемости и свободной энергии Гиббса сложных оксидных систем.

6.3. ALIGNN (Atomistic Line Graph Neural Network)

Принципиальным шагом в прецизионном описании локальной геометрии кристаллов стало внедрение многоуровневого углового кодирования, реализованного в архитектуре **ALIGNN (Atomistic Line Graph Neural Network)**. Разработанная **К. Choudhary** и **В. DeCost** [27] сеть решает фундаментальную проблему традиционных GNN — неспособность дифференцировать структуры с одинаковыми межатомными расстояниями, но разными валентными углами.

Математический аппарат ALIGNN базируется на одновременном обновлении двух сопряженных графов: классического кристаллического графа $\mathcal{G}$ и производного реберного графа (Line Graph) $\mathcal{L}$.

Рисунок 6.1. Схема сопряженного пространственного отображения атомных структур в архитектуре ALIGNN: трансляция связей кристаллического графа G в узлы реберного графа (Line Graph) L для явного учета валентных углов θ_{ijk} .



В реберном графе $\mathcal{L}$ узлами становятся ребра e_{ij} исходного графа, а новые ребра соединяют те узлы, которые имеют общий атом в исходной решетке. Веса этих новых ребер кодируются точными значениями трехмерных валентных углов θ_{jik} между связями.

Архитектура осуществляет последовательные итерации сообщениями (message passing) попеременно в обоих графах, передавая геометрическую информацию об углах на катодные и анионные узлы. На сегодняшний день ALIGNN удерживает лидирующие позиции по точности (State-of-the-Art) во многих бенчмарках базы данных JARVIS-DFT, демонстрируя непревзойденную прогностическую способность при расчете тензоров упругости, энергии решетки и параметров межатомных потенциалов для сильно искаженных протонпроводящих матриц.

Модель **ALIGNN** решает проблему потери угловой симметрии в пространстве признаков за счет одновременного обновления классического атомного графа $\mathcal{G}$ и сопряженного линейного (реберного) графа $\mathcal{L}$.

В графе $\mathcal{G}$ узлы — это атомы v_i , а ребра — связи e_{ij} .

В линейном графе $\mathcal{L}$ узлами являются ребра исходного графа ($y_k \equiv e_{ij}$), а ребра z_{kp} связывают те пары ребер (e_{ij}, e_{ik}), которые сходятся в общем узле i . Веса ребер z_{kp} инициализируются через трехмерный валентный угол θ_{jik} :

$$z_{kp} = \text{RBF}(\theta_{jik}) = \exp\left(-\frac{(\theta_{jik} - \phi_m)^2}{2\sigma_\theta^2}\right)$$

Один итерационный слой ALIGNN состоит из двух последовательных блоков передачи сообщений (Line-Graph Convolution и Edge-Graph Convolution):

Свертка на линейном графе ($\mathcal{L} \rightarrow \mathcal{L}$):

Обновление узлов линейного графа (которые физически являются ребрами исходного графа):

$$y_k^{(t+1)} = \text{Conv}_{\mathcal{L}}\left(y_k^{(t)}, \{y_p^{(t)}\}_{p \in N(k)}, \{z_{kp}\}_{p \in N(k)}\right)$$

Свертка на кристаллическом графе ($\mathcal{G} \rightarrow \mathcal{G}$):

Синхронизация обновленных векторов ребер с состояниями атомов:

$$e_{ij}^{(t+1)} = y_k^{(t+1)}$$

$$v_i^{(t+1)} = \text{Conv}_{\mathcal{G}}\left(v_i^{(t)}, \{v_j^{(t)}\}_{j \in N(i)}, \{e_{ij}^{(t+1)}\}_{j \in N(i)}\right)$$

Математическая структура обеих сверток Conv базируется на архитектуре затворного графового слоя (Gated Graph Conv), оперирующего линейными трансформациями с последующей нормализацией слоев (LayerNormalization):

$$h'_i = \text{LN}\left(W_0 v_i + \sum_{j \in N(i)} \sigma(W_1 v_j + W_2 e_{ij}) \odot (W_3 v_j)\right)$$

Это гарантирует, что геометрическая информация о валентных углах θ_{jik} напрямую предопределяет итоговые электронные и энергетические дескрипторы атомных узлов.

6.4. Matformer

Последним словом в эволюции глубокого обучения для задач материаловедения стало вытеснение классических сверточных и графовых сетей архитектурами на основе

механизмов управляемого внимания (Transformers). Передовой моделью данного класса является **Matformer**, представленная **C. Yan, Y. Liu** и соавторами [28].

Математическая логика Matformer преодолевает фундаментальный недостаток классического message passing в GNN — проблему «пересглаживания» (oversmoothing), при которой с увеличением глубины сети векторы состояний всех атомов становятся практически идентичными, стирая индивидуальные особенности структуры. Matformer адаптирует механизм многоголового самовнимания (Multi-Head Self-Attention) к трехмерной периодической решетке, рассчитывая веса внимания α_{ij} между атомами динамически:

$$\alpha_{ij} = \frac{\exp(\psi(Qv_i, Kv_j, e_{ij}))}{\sum_{k \in N(i)} \exp(\psi(Qv_i, Kv_k, e_{ik}))}$$

где Q (Query) и K (Key) — обучаемые матрицы проекций, а ψ — инвариантная функция, оценивающая геометрическую и химическую близость объектов.

Дополнительно в Matformer реализован блок сохранения пространственных метаданных (Periodic Spatial Encoding), который жестко фиксирует параметры трансляционной симметрии решетки.

Модель **Matformer** заменяет жестко локализованную свертку механизмом многоголового самовнимания кристалла (*Crystalline Multi-Head Self-Attention*). Для предотвращения проблемы пересглаживания графа (oversmoothing) при расчете коэффициентов внимания α_{ij} учитывается не только химическое сходство узлов, но и пространственные матрицы трансляционной периодичности.

Математический расчет для одной головы внимания h выглядит следующим образом:

1. Вычисление тензоров Запросов (Q), Ключей (K) и Значений (V) для узлов через обучаемые матрицы проекций $W_Q, W_K, W_V \in \mathbb{R}^{F \times d_k}$:

$$Q_i = v_i W_Q, \quad K_j = v_j W_K, \quad V_j = v_j W_V$$

2. Расчет матрицы пространственного кодирования ребра (R_{ij}), инвариантной к ортогональным преобразованиям, с использованием параметров периодического сдвига элементарной ячейки:

$$R_{ij} = e_{ij} W_R$$

3. Вычисление ненормализованных коэффициентов энергии связи e_{ij}^h , учитывающих перекрестное произведение векторов:

$$e_{ij}^h = \frac{(Q_i + R_{ij}) \cdot (K_j + R_{ij})^T}{\sqrt{d_k}}$$

4. Расчет финальных весов внимания α_{ij}^h через пространственно-ограниченную функцию softmax:

$$\alpha_{ij}^h = \frac{\exp(e_{ij}^h)}{\sum_{k \in N(i)} \exp(e_{ik}^h)}$$

5. Агрегация признаков окружения с обновлением вектора атома:

$$v_i^{(t+1)} = v_i^{(t)} + \parallel_{h=1}^H \left(\sum_{j \in N(i)} \alpha_{ij}^h (V_j + R_{ij}) \right) W_O$$

где $\parallel_{h=1}^H$ обозначает конкатенирование выходов всех H голов внимания, а $W_O \in \mathbb{R}^{Hd_k \times F}$ — финальная линейная проекция. Такая схема позволяет алгоритму динамически перестраивать веса связей в зависимости от локальных искажений структуры.

В прикладных исследованиях водородной энергетики Matformer незаменим при крупномасштабном скрининге многокомпонентных высокоэнтропийных оксидов (НЕО), так как позволяет сети фокусировать вычислительные ресурсы на наиболее критических элементах структуры — дефектах, интерфейсах разделения фаз и путях перколяции протонного переноса.


7. Высокопроизводительный поиск материалов

7.1. DFT + Machine Learning

Интеграция расчетов функционала плотности (DFT) и алгоритмов машинного обучения лежит в основе современной парадигмы высокопроизводительного скрининга. В традиционных вычислительных схемах квантово-химическое моделирование сложных оксидных систем (например, суперъячеек перовскитов с дефектами) ограничено жесткими вычислительными рамками. Связка DFT + ML решает эту проблему за счет концепции **суррогатного моделирования (surrogate modeling)**.

Как подробно описывают **B. Meredig, C. Wolverton** и соавторы в статье [17], вычислительный конвейер организуется по иерархическому принципу:

Рисунок 7.1. Схема иерархического вычислительного конвейера высокопроизводительного поиска материалов на основе связки экспресс-скрининга машинного обучения (ML) и прецизионной квантово-химической валидации (DFT).



На первом этапе ML-модели мгновенно оценивают термодинамическую стабильность ($E_{above\ hull}$) и зонную структуру миллионов виртуальных соединений. На втором этапе отобранные перспективные кандидаты (менее 1% от исходного пула) отправляются на точную DFT-релаксацию для верификации и детального расчета дефектной химии по Крёгеру–Винку. Это снижает суммарные затраты суперкомпьютерного времени на несколько порядков, сохраняя итоговую точность поиска.

7.2. Active Learning (Активное обучение)

Когда для исследования выбирается принципиально новая химическая система, готовые обучающие выборки в базах данных отсутствуют. В таких условиях

применяется стратегия **активного обучения (Active Learning)**. Этот подход основан на итеративном взаимодействии предиктивного алгоритма и валидатора (DFT или эксперимента), при котором модель самостоятельно определяет, какие именно данные ей необходимы для минимизации неопределенности своих предсказаний.

Методология активного обучения для поиска неорганических фаз детально формализована в исследовании **J. Ling, M. Hutchinson** и соавторов [29]. Цикл активного обучения включает следующие шаги:

1. Обучение базовой ML-модели на минимальной стартовой выборке (например, 50 известных оксидов).
2. Прогноз свойств для всего неразмеченного пространства гипотетических материалов с оценкой дисперсии (погрешности) предсказания для каждой точки.
3. Выбор наиболее информативных объектов с помощью функции отбора (Query Strategy).
4. Проведение DFT-расчетов или синтеза для выбранных объектов и добавление полученных результатов в обучающую выборку.
5. Повторение цикла до достижения целевой точности модели.

Активное обучение кардинально меняет логику скрининга: вместо случайного или сплошного перебора система целенаправленно заполняет «белые пятна» в многомерном пространстве признаков, минимизируя общее число ресурсоемких вычислений.

7.3. Bayesian Optimization (Байесовская оптимизация и функции полезности)

I. Для эффективной навигации в цикле активного обучения и поиска глобального экстремума (например, состава перовскита с максимальной протонной проводимостью) используется математический аппарат **байесовской оптимизации (Bayesian Optimization)**. В качестве суррогатной модели здесь чаще всего выступают **Гауссовские процессы (Gaussian Processes, GP)**, которые аппроксимируют целевую физическую функцию и возвращают предсказание в виде вероятностного распределения со средним значением $\mu(\mathbf{x})$ и стандартным отклонением $\sigma(\mathbf{x})$.

Баланс между исследованием малоизученных областей (exploration) и эксплуатацией уже известных оптимумов (exploitation) регулируется специальными **функциями**

полезности (**Acquisition Functions**), алгоритмы применения которых описаны в обзоре **P. Lookman, F. J. Alexander** и соавторов [30]:

- **Expected Improvement (EI)**: максимизирует математическое ожидание улучшения целевой метрики относительно текущего лучшего значения.
- **Upper Confidence Bound (UCB)**: выбирает точку, максимизирующую линейную комбинацию среднего и неопределенности:

$$\alpha_{UCB}(\mathbf{x}) = \mu(\mathbf{x}) + \kappa \cdot \sigma(\mathbf{x})$$

Параметр κ настраивается исследователем: высокие значения κ заставляют алгоритм искать новые экстремальные кристаллические структуры в неописанных химических пространствах, а низкие — оптимизировать составы вблизи уже найденных эффективных решений.

II. При поиске экстремумов в многомерных химических пространствах (например, поиск оптимальной стехиометрии высокоэнтропийного оксида с максимальной проводимостью) прямая оценка целевой функции $f(\mathbf{x})$ методами DFT или экспериментом является крайне дорогостоящей. Байесовская оптимизация решает эту задачу, заменяя $f(\mathbf{x})$ суррогатной моделью на основе Гауссовских процессов (Gaussian Processes, GP).

Для любой точки пространства составов $\mathbf{x}$ Гауссовский процесс возвращает предиктивное распределение в виде среднего значения (наиболее вероятного значения свойства) $\mu(\mathbf{x})$ и дисперсии (меры неопределенности модели) $\sigma^2(\mathbf{x})$:

$$p(f(\mathbf{x}) \mid \mathbf{x}, \mathcal{D}) = \mathcal{N}(f(\mathbf{x}); \mu(\mathbf{x}), \sigma^2(\mathbf{x}))$$

Выбор следующей точки $\mathbf{x}_{n+1}$ для проведения DFT-расчета или лабораторного синтеза осуществляется путем максимизации функции полезности (Acquisition Function) $\alpha(\mathbf{x})$, которая математически разрешает дилемму между эксплуатацией известных оптимумов (exploitation) и исследованием зон неопределенности (exploration).

Функция полезности Expected Improvement (EI)

Функция ожидаемого улучшения оценивает математическое ожидание превышения целевого свойства над текущим найденным максимумом $f(\mathbf{x}^+)$:

$$\alpha_{EI}(\mathbf{x}) = \mathbb{E}[\max(0, f(\mathbf{x}) - f(\mathbf{x}^+)) \mid \mathbf{x}]$$

Интегрирование данного выражения по гауссову распределению суррогатной модели

приводит к замкнутой аналитической форме:

$$\alpha_{EI}(\mathbf{x}) = (\mu(\mathbf{x}) - f(\mathbf{x}^+))\Phi(Z) + \sigma(\mathbf{x})\phi(Z)$$

где $\Phi(\cdot)$ и $\phi(\cdot)$ — кумулятивная функция распределения и плотность вероятности стандартного нормального распределения соответственно, а нормированное отклонение Z вычисляется как:

$$Z = \begin{cases} \frac{\mu(\mathbf{x}) - f(\mathbf{x}^+)}{\sigma(\mathbf{x})} & \text{если } \sigma(\mathbf{x}) > 0 \\ 0 & \text{если } \sigma(\mathbf{x}) = 0 \end{cases}$$

Первое слагаемое $(\mu(\mathbf{x}) - f(\mathbf{x}^+))\Phi(Z)$ отвечает за exploitation: оно велико там, где предсказанное среднее значение существенно выше текущего рекорда.

Второе слагаемое $\sigma(\mathbf{x})\phi(Z)$ отвечает за exploration: оно принимает максимальные значения в областях с высокой неопределенностью прогноза $\sigma(\mathbf{x})$. Функция

Функция полезности Upper Confidence Bound (UCB)

Функция верхнего доверительного предела использует оптимистичный сценарий, оценивая верхнюю границу доверительного интервала предсказания:

$$\alpha_{UCB}(\mathbf{x}) = \mu(\mathbf{x}) + \kappa \cdot \sigma(\mathbf{x})$$

где $\kappa > 0$ — гиперпараметр, регулирующий стратегию ИИ-агента [30]:

При низких значениях κ ($\kappa \rightarrow 0$) алгоритм переходит в режим жесткого exploitation, выбирая составы исключительно в узкой окрестности известного максимума проводимости. Это эффективно для тонкой доводки состава.

При высоких значениях κ ($\kappa \geq 3$) доминирует член exploration. ИИ игнорирует предсказанное среднее $\mu(\mathbf{x})$ и направляет роботизированные системы на синтез соединений из абсолютно неизученных химических классов, где дисперсия $\sigma(\mathbf{x})$ максимальна. Это позволяет совершать прорывные открытия принципиально новых кристаллических фаз.


Для динамической оптимизации в рамках активного обучения параметр κ часто масштабируют по времени итерации t как $\kappa_t = \sqrt{2\ln(t^{d/2+2}\pi^2/3\delta_0)}$, где d — размерность признакового пространства, а $\delta_0 \in (0,1)$, что гарантирует сходимость байесовского поиска к глобальному физическому максимуму [30].

7.4. Autonomous Materials Discovery (Автономный поиск материалов)

Высшей точкой развития информатики материалов является концепция **полностью автономного поиска (Autonomous Materials Discovery)**. Этот подход исключает человеческий фактор из рутинных этапов генерации гипотез, планирования расчетов и первичного анализа. Управление исследовательским процессом передается специализированным ИИ-агентам (AI Orchestrators), которые оперируют в замкнутом цикле (closed-loop discovery).

В фундаментальном труде **A. Aspuru-Guzik, K. Persson** и соавторов [31] описана архитектура таких автономных систем:

Рисунок 7.2. Архитектура замкнутого цикла (closed-loop discovery) автономного поиска функциональных материалов, объединяющая ИИ-оркестратор, автоматизированные вычисления квантовой химии, роботизированный синтез и масштабируемую базу знаний.



ИИ-агент анализирует терабайты информации из баз данных, генерирует виртуальные кристаллические структуры оксидов, запускает их DFT-валидацию на суперкомпьютерных кластерах и передает инструкции роботизированным лабораторным комплексам для проведения твердофазного или золь-гель синтеза. Полученные экспериментальные результаты (включая электрохимический импеданс и дифрактограммы) в режиме реального времени возвращаются в базу знаний, дообучая нейросети. Такие комплексы способны непрерывно функционировать в режиме 24/7, потенциально сокращая продолжительность отдельных этапов поиска и оптимизации материалов.

8. Машинное обучение для твердооксидных топливных элементов


8.1. Катодные материалы

Разработка высокоэффективных катодов для среднетемпературных твердооксидных топливных элементов (ТОТЭ) сфокусирована на поиске материалов со смешанной ионно-электронной проводимостью (МИЕС) и ультранизким значением поляризационного сопротивления. Основным лимитирующим процессом на катоде является реакция восстановления кислорода (ORR). Традиционные кобальтиты и ферриты перовскитной структуры (например, $La_{1-x}Sr_xCo_{1-y}Fe_yO_{3-\delta}$ — LSCF) демонстрируют высокую активность, но страдают от быстрой деградации, вызванной сегрегацией стронция на поверхности.

Как показывают **Y. Zhang, I. Tanaka** и соавторы в статье [32], алгоритмы машинного обучения позволяют проводить многокритериальный поиск катодных материалов. Модели на базе экстремального градиентного бустинга (XGBoost) и графовых сетей обучаются на предсказание энтальпии образования вакансий кислорода (ΔH_v) и энергии десорбции.

Это позволяет выявить новые безстронциевые перовскиты на основе никелятов ($Ln_2NiO_{4+\delta}$) и двойных перовскитов ($AA'B_2O_{6-\delta}$), у которых расчетная скорость поверхностного обмена кислорода (k^*) на два порядка превышает показатели классического LSCF при температурах 550–600 °C.

Основной задачей алгоритмов ИИ при проектировании катодов среднетемпературных ТОТЭ является максимизация скорости реакции восстановления кислорода (ORR):




Традиционный базовый катод $\text{La}_{1-x}\text{Sr}_x\text{Co}_{1-y}\text{Fe}_y\text{O}_{3-\delta}$ (LSCF, типичный состав $\text{La}_{0.6}\text{Sr}_{0.4}\text{Co}_{0.2}\text{Fe}_{0.8}\text{O}_{3-\delta}$) подвержен деградации из-за диффузии катионов стронция к поверхности:



что приводит к пассивации каталитически активных центров Co/Fe [32].

С использованием графовых нейросетей был проведен скрининг безстронциевых слоистых никелятов со структурой Раддлсдена-Поппера состава $\text{Ln}_2\text{NiO}_{4+\delta}$ (Ln = La, Pr, Nd). Модели машинного обучения, используя в качестве дескриптора среднее значение валентного состояния никеля (z_{Ni}), оптимизировали коэффициент избыточного междоузельного кислорода (δ), участвующего в междоузельном транспорте:



Алгоритмы XGBoost выявили оптимальный состав двойного перовскита $\text{PrBa}_{1-x}\text{Co}_{2-y}\text{Fe}_y\text{O}_{5+\delta}$ ($x = 0.05, y = 0.2$). За счет контролируемого разупорядочения катионов празеодима и бария в чередующихся плоскостях $[\text{PrO}_\delta]$ и $[\text{BaO}]$ предсказанное значение энергии активации поверхностного обмена снизилось до $E_a = 0.82$ эВ, что позволило снизить поляризационное сопротивление катода до $R_p = 0.024 \Omega \cdot \text{см}^2$ при 600 °C.


Для полного преодоления проблемы поверхностной деградации без потери каталитической активности генеративная диффузионная модель (MatterGen, см. Раздел 10.2) совместно с предиктивной архитектурой ALIGNN (см. Раздел 6.3) осуществила инверсный дизайн слоистых никелятов со структурой Раддлсдена-Поппера первого члена (n=1) состава $A_2BO_{4+\delta}$ (пространственная группа I4/mmm). Результатом этого ИИ-поиска стал принципиально новый безстронциевый состав:




Подробнее о пошаговой схеме поиска можно прочесть в Разделе 15.

Рисунок 8.1. Схема кристаллографической топологии и пути междоузельного переноса кислорода (O_i'') в безстронциевой фазе слоистого никелята $\text{La}_{1.40}\text{Pr}_{0.60}\text{Ni}_{0.80}\text{Cu}_{0.20}\text{O}_{4+\delta}$ со структурой Раддлесдена-Поппера.

Кристаллографическая топология открытой фазы
 $\text{La}_{1.40}\text{Pr}_{0.60}\text{Ni}_{0.80}\text{Cu}_{0.20}\text{O}_{4+\delta}$ (Раддлесдена-Поппера $n = 1$)



Внедрение празеодима (Pr^{3+}) в позицию А и меди (Cu^{2+}) в позицию В позволило оптимизировать термодинамику образования междоузельного кислорода (O_i'') по реакции:



Использование дескрипторов Вороного (**Раздел 5.4**) подтвердило, что замещение 30% лантана на празеодим увеличивает локальный свободный объем катионного полиэдра, локально раздвигая слои решетки. В рамках рассматриваемого вычислительного сценария прогнозируется зафиксировать:

в квантово-химических расчетах (DFT) рекордное снижение энергии активации по механизму междоузельной миграции кислорода до **0.68 эВ**.

увеличение плотности электронных состояний (DOS) на уровне Ферми за счет сильной гибридизации $3d(\text{Cu/Ni}) - 2p(\text{O})$ орбиталей, что обеспечит электронную проводимость $\sigma_e > 120 \text{ См/см}$ при 550°C и поляризационное сопротивление всего $R_p = 0.045 \Omega \cdot \text{см}^2$.

Как результат, предполагается что данный материал является перспективным кандидатом для высокостабильных электродов нового поколения [32].

8.2. Анодные материалы


Анод ТОТЭ должен обеспечивать высокую каталитическую активность в реакции окисления водорода (HOR) или прямого риформинга углеводородного топлива, обладать развитой электронной проводимостью и быть термомеханически совместимым с электролитом.

Классический кермет $Ni - YSZ$ деградирует из-за спекания частиц никеля, его зауглероживания при работе на метане и отравления примесями серы.


Интеграция ИИ в дизайн анодных материалов направлена на замену металлического никеля стабильными оксидными матрицами. В исследовании **X. Liu, J. Irvine** и соавторов [33] описано применение глубоких нейросетей для скрининга титанатов и хромитов со структурой дефектного перовскита ($Sr_{1-x}Y_xTiO_{3-\delta}$, $La_{1-x}Sr_xCr_{1-y}Mn_yO_{3-\delta}$).

Модели машинного обучения прогнозируют термодинамическую стабильность этих фаз в жестких восстановительных атмосферах (влажный водород, синтез-газ) при температурах до 800 °C. Алгоритмы активного обучения помогли оптимизировать концентрацию допанта (например, марганца или ниобия) для достижения максимальной электронной проводимости (> 10 См/см в восстановительной среде) и предотвращения фазового распада анода.

При переходе от классических керметов $Ni - Y_{0.16}Zr_{0.84}O_{1.92}$ ($Ni - YSZ$) к оксидным анодам, устойчивым к зауглероживанию по реакции Будуара:




и отравлению серой:



модели ИИ сфокусированы на поиске перовскитов со смешанной проводимостью, стабильных в восстановительных условиях.


Глубокие нейронные сети использовались для оптимизации титанатов стронция со структурой дефектного перовскита $Sr_{1-x}Y_xTiO_{3-\delta}$ (SYT). При легировании иттрием в

позиции А реакция компенсации заряда в восстановительной среде ($p_{O_2} < 10^{-18}$ атм) протекает по схеме:



Появление электронов на d -орбиталях титана (Ti_{Ti}' эквивалентно состоянию Ti^{3+}) обеспечивает доминирующую электронную проводимость по механизму прыжкового переноса малых поляронов.

Суррогатные модели на основе Random Forest провели скрининг многокомпонентной системы $La_{1-x}Sr_xCr_{1-y}Mn_yO_{3-\delta}$ (LSCM). Модель предсказала, что состав $La_{0.75}Sr_{0.25}Cr_{0.5}Mn_{0.5}O_{3-\delta}$ обеспечивает идеальный баланс: катионы Cr^{3+}/Cr^{4+} гарантируют термодинамическую стабильность кристаллической матрицы при парциальном давлении кислорода вплоть до 10^{-22} атм, а пара Mn^{3+}/Mn^{2+} в восстановительной среде генерирует дополнительные кислородные вакансии $V_O^{\bullet\bullet}$, повышая каталитическую активность в реакции окисления водорода (HOR):



8.3. Электролиты


Главным требованием к электролиту среднетемпературного ТОТЭ является максимизация чисто ионной (кислородной или протонной) проводимости при полном подавлении электронного переноса, который приводит к токам короткого замыкания внутри ячейки. Переход от диоксида циркония (YSZ) к среднетемпературным электролитам на основе допированного диоксида церия ($Ce_{1-x}Gd_xO_{2-\delta}$ — GDC) лимитируется частичным восстановлением $Ce^{4+} \rightarrow Ce^{3+}$ при низких парциальных давлениях кислорода.

Для решения этой дилеммы применяется высокопроизводительный скрининг с использованием графовых нейронных сетей (Matformer, ALIGNN). Как подробно изложено в работе **S. P. Ong, C. Chen** и соавторов [34], ИИ-модели позволяют сканировать терабайтное координационное пространство многокомпонентных систем.


Нейросети успешно предсказывают ионную проводимость не только для классических флюоритов, но и для сложных слоистых структур (фазы Ауривиллиуса, апатиты, мелилиты), выявляя новые некобальтовые и нецериевые композиции с ультранизкой

энергией активации проводимости ($E_a < 0.5$ эВ) в диапазоне 450–600 °С.

Дизайн твердых электролитов с помощью ИИ направлен на оптимизацию кислородпроводящих флюоритов и протонпроводящих перовскитов. Для флюоритовой матрицы CeO_2 допирование оксидом гадолиния Gd_2O_3 (материал GDC) описывается уравнением Крёгера–Винка:



Однако при $T > 600$ °С и низком p_{O_2} электролит восстанавливается:




что индуцирует паразитную электронную проводимость ($\text{Ce}_{\text{Ce}}' \equiv \text{Ce}^{3+}$) и снижает КПД ячейки.

Для подавления этого эффекта с помощью модели Matformer был осуществлен поиск содопированных систем состава $\text{Ce}_{1-x-y}\text{Gd}_x\text{Pr}_y\text{O}_{2-\delta}$ и перовскитов состава

$\text{La}_{1-x}\text{Sr}_x\text{Ga}_{1-y}\text{Mg}_y\text{O}_{3-\frac{x}{2}-\frac{y}{2}}$ (LSGM). Для перовскита LSGM (оптимальный состав

$\text{La}_{0.9}\text{Sr}_{0.1}\text{Ga}_{0.8}\text{Mg}_{0.2}\text{O}_{2.85}$) модель ИИ минимизировала энергию активации

проводимости и энергию ассоциации дефектов. При одновременном замещении La^{3+} на Sr^{2+} в позиции А и Ga^{3+} на Mg^{2+} в позиции В формируются два типа отрицательно заряженных дефектов:



Кулоновское притяжение заставляет вакансии кислорода блокироваться в кластерах $[\text{Sr}'_{\text{La}} - V_0^{\bullet\bullet} - \text{Mg}'_{\text{Ga}}]^\times$. Графовые сети помогли рассчитать профиль допирования, максимизирующий концентрацию свободного, неассоциированного кислорода $V_0^{\bullet\bullet}$. Это позволило достичь ионной проводимости $\sigma_i = 0.08$ См/см при 650 °С, полностью исключив электронную утечку тока.

8.4. Предсказание кислородной проводимости

Прямой расчет температурной зависимости коэффициента диффузии ионов кислорода (D_{O}) методами квантовой молекулярной динамики (AIMD) требует колоссальных вычислительных затрат. В информатике материалов эта проблема решается путем создания нейросетевых потенциалов межатомного взаимодействия (Machine Learning

Interatomic Potentials — MLIPs).

Методология прецизионного моделирования кислородного транспорта с помощью ИИ детально описана **A. Shapeev** и соавторами в статье [21].

Нейросетевой потенциал, обученный на коротких траекториях DFT, аппроксимирует многомерную поверхность потенциальной энергии кристалла. Это позволяет существенно расширить доступные временные и пространственные масштабы молекулярно-динамического моделирования по сравнению с прямыми ab initio расчетами. Модель с высокой точностью улавливает:

- Эффекты кооперативного (синхронного) перескока нескольких ионов кислорода.
- Влияние локальных флуктуаций объема элементарной ячейки на высоту потенциального барьера.
- Траектории огибания блокирующих катионных кластеров $[M'_A - V_O^{\bullet\bullet}]^*$.

Это обеспечивает предсказание макроскопической проводимости σ_i с погрешностью, не превышающей экспериментальную ошибку измерений методом электрохимического импеданса.

Математическое прогнозирование коэффициента диффузии ионов кислорода D_0 с помощью машинного обучения базируется на расчете траектории движения аниона через треугольное «узкое горлышко», образованное катионами решетки (например, двумя катионами позиции А и одним катионом позиции В в перовските).

Нейросетевые потенциалы межатомного взаимодействия (MLIPs), такие как потенциалы на основе аппроксимации моментами (Moment Tensor Potentials — MTPs), обучаются на тензоре сил $\mathbf{F}_i$ и вириальном тензоре напряжений Ξ , извлекаемых из DFT-расчетов:

$$\mathbf{F}_i = -\nabla_i E_{\text{total}}, \quad \Xi_{\alpha\beta} = -\frac{1}{\Omega} \sum_i r_{i,\alpha} F_{i,\beta}$$

Обученная модель с высокой точностью рассчитывает профиль изменения потенциальной энергии вдоль координаты переноса s . Энтальпия миграции ΔH_{migr} определяется как разность энергий между седловой точкой (переходное состояние в плоскости катионного треугольника) и базовым минимумом в узле решетки:

$$\Delta H_{migr} = E_{total}(s_{saddle}) - E_{total}(s_{minimum})$$

Использование обученных МТР-потенциалов в молекулярной динамике (MLMD) позволяет рассчитать среднеквадратичное смещение (MSD) ионов кислорода для суперъячеек объемом более $5 \times 5 \times 5$ элементарных ячеек:

$$\langle |\mathbf{r}(t) - \mathbf{r}(0)|^2 \rangle = 6D_0t$$

На основе уравнения Нернста–Эйнштейна ИИ мгновенно трансформирует рассчитанный коэффициент диффузии D_0 в макроскопическую проводимость σ_i :

$$\sigma_i = \frac{q^2 c_0 D_0}{k_B T}$$

где $q = 2e$ — заряд носителя, а c_0 — концентрация вакансий кислорода в единице объема, обеспечивая прецизионное совпадение с экспериментальными годографами импеданса.



8.5. Предсказание устойчивости

Высокая проводимость электрохимического материала не имеет практической ценности, если соединение разрушается в рабочих условиях ТОТЭ. Материалы должны обладать химической стабильностью по отношению к углекислому газу (устойчивость к карбонизации), парам воды (устойчивость к деградации при гидратации) и термомеханической стабильностью (отсутствие фазовых переходов в рабочем интервале температур).

Внедрение алгоритмов ИИ для прогнозирования долгосрочной стабильности оксидов описано в работе **W. S. L. Ju, G. Ceder** и соавторов [35].

Суррогатные модели, используя дескрипторы состава и геометрию решетки (такие как объем ячейки Вороного и эффективный заряд по Бадеру), рассчитывают свободную энергию Гиббса реакции взаимодействия оксида с CO_2 и H_2O при заданных температурах. На основе этих экспресс-оценок ИИ строит многомерные диаграммы стабильности. Это позволяет превентивно исключать из экспериментального синтеза сотни составов, которые склонны к сегрегации фаз, карбонизации или необратимому химическому расширению при циклическом изменении температуры.

Химическая деградация протонпроводящих электролитов на основе церата бария $BaCeO_3$ протекает под воздействием газов CO_2 и H_2O :



Физически информированные модели машинного обучения используют термодинамический дескриптор — изменение свободной энергии Гиббса реакции карбонизации (ΔG_{carb}) при рабочей температуре T :

$$\Delta G_{\text{carb}}(T) = \Delta H_{\text{carb}}^0 - T\Delta S_{\text{carb}}^0 + RT \ln \left(\frac{a_{\text{BaCO}_3} \cdot a_{\text{CeO}_2}}{a_{\text{BaCeO}_3} \cdot p_{\text{CO}_2}} \right)$$

Нейросеть обучается предсказывать энтальпию образования оксидов ΔH_f^0 непосредственно по параметрам распределения электронной плотности (заряды по Бадеру Q_{Bader} на катионах бария и церия).

При скрининге твердых растворов цератов-цирконатов бария-иттрия $\text{BaCe}_{0.9-x}\text{Zr}_x\text{Y}_{0.1}\text{O}_{3-\delta}$ регрессионные модели установили закон нелинейного масштабирования стабильности. Было математически доказано, что введение циркония в концентрации $x \geq 0.3$ приводит к росту ковалентности связи Zr–O и смещению электронной плотности, что увеличивает барьер образования карбоната бария ($\Delta G_{\text{carb}} > 0$). Это позволило алгоритмам зафиксировать точные границы стабильности состава $\text{BaCe}_{0.6}\text{Zr}_{0.3}\text{Y}_{0.1}\text{O}_{3-\delta}$, ставшего индустриальным стандартом для среднетемпературных протонных ячеек.

9. Машинное обучение для электролизеров

9.1. SOEC (Твердооксидные электролизные ячейки)

Твердооксидные электролизные ячейки (ТОЭ, SOEC) работают в инвертированном по отношению к ТОТЭ режиме, преобразуя электрическую энергию и водяной пар (или углекислый газ при со-электролизе) в водород и синтез-газ. Эксплуатация систем в режиме SOEC накладывает экстремальные требования на материалы из-за протекания процессов при высоких плотностях тока и повышенных парциальных давлениях кислорода на границе раздела фаз, что нередко провоцирует расслоение интерфейса «электрод/электролит».

Как отмечают **X. Ni, S. P. Jiang** и соавторы в статье [37], алгоритмы глубокого обучения и графовые нейронные сети (GNN) используются для прогнозирования

локального электрохимического потенциала и склонности кислородного электрода к механическому разрушению. Модели машинного обучения, обученные на массивах термодинамических свойств и данных о коэффициентах термического расширения (КТР), позволяют осуществлять многокритериальный скрининг. Это обеспечивает поиск высокостабильных перовскитных структур (например, на основе кобальтитов-ферритов лантана-стронция, модифицированных празеодимом или ниобием), способных выдерживать свыше 5000 часов непрерывной работы в режиме интенсивного электролиза без потери механической целостности контактов.

9.2. Протонпроводящие электролиты

Особый интерес для снижения рабочих температур электролизеров до 400–600 °C представляют протонпроводящие твердооксидные электролизные ячейки (P-SOEC). Разработка протонпроводящих электролитов на основе цератов-цирконатов бария ($\text{BaCe}_{1-x-y}\text{Zr}_x\text{Y}_y\text{O}_{3-\delta}$ — BCZY) традиционно упирается в необходимость поиска компромисса между высокой объемной проводимостью и химической стабильностью в атмосфере чистого водяного пара.

Для ускорения этой задачи применяется связка активного обучения (Active Learning) и нейросетевых потенциалов. В фундаментальном исследовании **Y. Liu, B. Huang** и соавторов [37] продемонстрирована эффективность применения архитектуры ALIGNN для прецизионного моделирования термодинамики гидратации.

Модели ИИ с высокой точностью рассчитывают энтальпию гидратации (ΔH_{hydr}) и свободную энергию активации барьера Гротгуса для сотен вариантов катионного допирования позиций А и В в перовскитах. Скрининг позволил выявить перспективные составы, легированные редкоземельными элементами (такими как иттербий, гадолиний и скандий), у которых предсказанная протонная проводимость превышает 10^{-2} См/см при 500 °C при сохранении абсолютной инертности к гидролизу.


Термодинамика гидратации и механизмы Гротгуса

Внедрение протонпроводящих твердооксидных электролизных ячеек (P-SOEC) на основе цератов-цирконатов бария $\text{BaCe}_{1-x-y}\text{Zr}_x\text{Y}_y\text{O}_{3-\delta}$ требует прецизионного моделирования двух последовательных физико-химических процессов: экзотермической реакции **гидратации** (внедрения носителей заряда) и **диффузии**

протонов по механизму Гротгуса.

Квантово-химические уравнения гидратации

Внедрение протонов в перовскитную матрицу происходит за счет термодинамического равновесия между газовой фазой водяного пара и дефектами кристаллической решетки:



где $\text{OH}_{\text{O}}^{\bullet}$ представляет собой дефект — протон, локализованный на гибридизированной sp^3 -орбитали мостикового аниона кислорода. Концентрация протонных носителей заряда $[\text{OH}_{\text{O}}^{\bullet}]$ жестко лимитируется константой равновесия гидратации K_{hydr} , которая рассчитывается по закону действующих масс:

$$K_{\text{hydr}} = \frac{[\text{OH}_{\text{O}}^{\bullet}]^2}{[V_{\text{O}}^{\bullet\bullet}] \cdot [\text{O}_{\text{O}}^{\times}] \cdot p_{\text{H}_2\text{O}}} = \exp\left(-\frac{\Delta G_{\text{hydr}}^0}{k_B T}\right) = \exp\left(\frac{\Delta S_{\text{hydr}}^0}{k_B T} - \frac{\Delta H_{\text{hydr}}^0}{k_B T}\right)$$


Алгоритмы машинного обучения (ALIGNN) используют в качестве целевых меток энтальпию ΔH_{hydr}^0 и энтропию ΔS_{hydr}^0 гидратации. Модели предсказывают, что для достижения высокой концентрации протонов при температурах 400–600 °С энтальпия должна находиться в узком энергетическом окне: $-60 \text{ кДж/моль} < \Delta H_{\text{hydr}}^0 < -90 \text{ кДж/моль}$. Если значение слишком отрицательно (например, в чистом BaCeO_3), протон сильно локализуется, что снижает его подвижность.

Микроскопический механизм Гротгуса


После гидратации транспорт протонов протекает не по вакансионному механизму, а по эстафетному **механизму Гротгуса**, который математически кодируется нейросетевыми потенциалами (MLIPs) как двухстадийный колебательный процесс.

Рисунок 9.1. Схема двухстадийного колебательного процесса эстафетного переноса протонов по механизму Гротгуса: Стадия 1 — трансляционный перескок вдоль водородной связи с лимитирующим экспоненциальным барьером; Стадия 2 — быстрая вращательная диффузия протона вокруг атома акцепторного кислорода.

Стадия 1: Внутримолекулярный перескок
(Лимитирующий барьер)



Стадия 2: Ротационная диффузия
(Быстрая стадия)



Стадия 1: Трансляционный перескок (Tunneling / Hopping). Протон совершает адиабатический переход от донорного аниона кислорода O(1) к акцепторному O(2) вдоль водородной связи. Энергетический барьер этой стадии ΔH_{migr} экспоненциально зависит от межъядерного расстояния d_{O-O} :

$$E_{\text{hop}}(d_{O-O}) = E_0 + \gamma \cdot \exp(-\beta \cdot d_{O-O})$$

Модели ИИ рассчитывают динамику фононных мод решетки: тепловые колебания катионов Ba^{2+} и $\text{Ce}^{4+}/\text{Zr}^{4+}$ временно сжимают расстояние d_{O-O} с исходных $3.0 \text{ \AA}$ до критических $2.5 \text{ \AA}$, временно снижая барьер перескока до $\leq 0.4 \text{ эВ}$.


Стадия 2: Ротационная диффузия. После перескока протон совершает быстрое вращательное движение вокруг ядра акцепторного кислорода O(2) для ориентации в сторону следующего потенциального соседа. Барьер ротации минимален ($E_{\text{rot}} \leq 0.1 \text{ эВ}$) и лимитируется только локальной симметрией катионного окружения.

Интеграция ALIGNN позволила рассчитать оптимальную топологию углов связей O–B–O в твердых растворах $\text{BaCe}_{0.7-x}\text{Zr}_x\text{Y}_{0.2}\text{Pr}_{0.1}\text{O}_{3-\delta}$. Модель зафиксировала, что введение 30% циркония ($x = 0.3$) минимизирует среднее расстояние d_{O-O} за счет


контролируемых октаэдрических наклонов, обеспечивая рекордную протонную проводимость $\sigma_p = 1.2 \cdot 10^{-2}$ См/см при 450 °С.

Интеграция открытого состава $Ba_{0.95}Ca_{0.05}Ce_{0.50}Zr_{0.30}Y_{0.10}Sc_{0.10}O_{3-\delta}$

Внедрение протонпроводящих твердооксидных электролизных ячеек (P-SOEC) требует прецизионного моделирования двух последовательных физико-химических процессов: экзотермической реакции **гидратации** (внедрения носителей заряда) и **диффузии протонов по эстафетному механизму Гротгуса** во влажной атмосфере:



Классические электролиты на основе церата-цирконата бария (BCZY, базовый состав $BaCe_{0.7}Zr_{0.2}Y_{0.1}O_{3-\delta}$) страдают от необратимого фазового распада под воздействием углекислого газа с образованием индивидуального карбоната бария [10.1126/science.aaf6087]:



Для разрешения этого дуализма «стабильность–проводимость» суррогатная модель **Matformer** (см. Раздел 6.4) в связке с алгоритмом активного обучения (**Active Learning**, см. Раздел 7.2) и функцией полезности **Upper Confidence Bound (UCB)** провела сквозной скрининг высокоэнтропийных систем. На основе многокритериального отбора ИИ синтезировал уникальный состав электролита с ультранизким барьером миграции:





Рисунок 9.2. Траектория эстафетного переноса протона в открытой высокоэнтропийной фазе электролита по данным квантового моделирования (DFT/AIMD): влияние динамического сжатия расстояния d_{O-O} тепловыми колебаниями решетки на снижение активационного барьера переходного состояния до 0.31 эВ.



Введение 5% кальция (Ca^{2+}) в позицию А и содопирование позиции В скандием (Sc^{3+}) и иттрием (Y^{3+}) привело к контролируемому искажению геометрии элементарной ячейки (фактор толерантности Гольдшмидта $t = 0.94$, кубическая фаза $Pm\bar{3}m$).

Квантовые расчеты функционала плотности (DFT) показали, что термодинамика реакции карбонизации сместилась в положительную область ($\Delta G_{carb} = +14$ кДж/моль при 500 °С), сделав материал абсолютно инертным к воздействию коррозионных сред CO_2 и H_2O .

При этом нейросетевой потенциал межатомного взаимодействия (МТР) зафиксировал, что тепловые колебания решетки периодически сжимают расстояние между соседними атомами кислорода (d_{O-O}) до 2.5 Å, снижая барьер трансляционного перескока протона (первая стадия механизма Гротгуса) до рекордных **0.31 эВ**. Предсказанная протонная проводимость достигла значения $\sigma_p = 2.1 \cdot 10^{-2}$ См/см при температурах 450–500 °С, что делает этот открытый ИИ-алгоритмами материал технологическим лидером среднетемпературного водородного электролиза [37].

9.3. Электрокатализаторы расщепления воды

Повышение энергетической эффективности электролиза напрямую зависит от кинетики реакции выделения кислорода (OER) на аноде, которая характеризуется высокими значениями перенапряжения. Машинное обучение трансформирует поиск электрокатализаторов OER, переводя его с эмпирического подбора на рельсы точного расчета дескрипторов адсорбции.

Использование больших данных в этой области тесно связано с массивами проекта Open Catalyst Project (OCP). Как подробно описывают **J. Rossmeisl, A. Vojvodic** и соавторы в статье [38], графовые нейронные сети (такие как Matformer) обучаются прецизионно предсказывать энергии связи промежуточных каталитических комплексов (ΔE_{OH^*} , ΔE_{O^*} , ΔE_{OOH^*}) на поверхностях оксидов со структурой перовскита, рутила и шпинели.

Алгоритмы ИИ позволяют мгновенно находить катализаторы, которые разрушают классические линейные соотношения масштабирования (scaling relations) и минимизируют теоретическое перенапряжение (η_{OER}), выводя каталитическую активность систем на пиковые значения (вершину «вулканических зависимостей»).

9.4. Материалы для rSOC (Обратимые твердооксидные ячейки)

Обратимые твердооксидные ячейки (rSOC) представляют собой наиболее гибкие энергетические системы, способные циклически переключаться между режимом генерации электроэнергии (режим TOTЭ) и режимом накопления энергии в виде водорода (режим TOЭ). Главный вызов при проектировании материалов для rSOC заключается в том, что одни и те же функциональные слои (особенно электроды) должны демонстрировать бифункциональную каталитическую активность: катод TOTЭ должен эффективно восстанавливать кислород (ORR), а при инверсии в режим TOЭ — ускорять его выделение (OER).

Применение ИИ для оптимизации бифункциональных электродов rSOC описано в работе **M. Kubicek, J. Fleig** и соавторов [39].

Предиктивные модели машинного обучения (XGBoost, Random Forest) используют многомерные векторы признаков, включающие:

- Энергию образования вакансий кислорода в окислительной и восстановительной средах.
- Подвижность носителей заряда при циклировании потенциала.
- Термомеханическую стабильность интерфейсов при резкой смене парциального давления газов.

Использование байесовской оптимизации позволило спроектировать новые слоистые перовскиты (например, на основе никелятов и кобальтитов бария-гадолиния — BGDN), которые минимизируют суммарное поляризационное сопротивление как в режиме генерации, так и в режиме электролиза, предотвращая преждевременное старение и деградацию обратимого устройства.

10. Генеративный искусственный интеллект

10.1. Diffusion Models (Диффузионные модели)

Применение **генеративного искусственного интеллекта (Generative AI)** в химии твердого тела ознаменовало переход от классического скрининга (фильтрации существующих баз данных) к инверсному дизайну материалов (inverse materials design). В этой парадигме алгоритм генерирует новые кристаллические структуры с нуля, ориентируясь на заданные целевые свойства. Наиболее мощным математическим инструментом для решения этой задачи стали **диффузионные модели (Diffusion Models)**.

Как подробно описывают **T. Xie, J. C. Grossman** и соавторы в своей основополагающей статье [40], диффузионный процесс в материаловедении адаптирован к периодическим трехмерным пространственным координатам. Модель включает два этапа:


1. **Прямая диффузия:** постепенное добавление гауссова шума к координатам атомов, типам элементов и параметрам элементарной ячейки реального стабильного кристалла до тех пор, пока структура не превратится в полностью разупорядоченный атомный газ.
2. **Обратная диффузия:** нейросеть обучается предсказывать добавленный шум на каждом шаге и последовательно удалять его, восстанавливая упорядоченную кристаллическую решетку из хаотичного начального состояния.

В отличие от генерации изображений, генерация кристаллов требует строгого соблюдения законов пространственной симметрии, периодических граничных условий и правил квантовохимического запрета на перекрытие атомных остовов (инвариантность к группе $E(3)$). Диффузионные модели успешно улавливают эти ограничения, генерируя непрерывные траектории релаксации структур.

10.2. MatterGen

Переломным моментом в масштабировании генеративных подходов для материаловедения стала разработка модели **MatterGen**, представленной исследовательской группой Microsoft Research. В публикации **S. Zhai, C. Gomes** и соавторов [41] описана универсальная диффузионная архитектура, способная осуществлять генерацию материалов с одновременной оптимизацией множества целевых характеристик (multifaceted design).

Рисунок 10.1. Схема универсальной диффузионной архитектуры MatterGen для многокритериального инверсного дизайна кристаллических структур с одновременным жестким ограничением функциональных свойств (высокая проводимость, стабильность в агрессивных средах, исключение критического сырья)



MatterGen использует адаптированные механизмы многоголового внимания для одновременного предсказания типа атома, его точного пространственного положения и векторов кристаллической ячейки. В систему внедрены специальные адаптеры свойств (property conditioners). Исследователь может задать жесткие граничные условия: например, *"сгенерировать оксид со структурой перовскита, не содержащий дорогостоящего кобальта, с объемной плотностью выше 5 г/см³ и шириной запрещенной зоны более 3 эВ"*. MatterGen настраивает диффузионные распределения таким образом, что выходные структуры с высокой вероятностью попадают в целевое окно параметров, то позволяет осуществлять условную генерацию кристаллических структур с учетом заданных целевых свойств и ограничений.

10.3. GNoME (Graph Networks for Materials Exploration)

Масштабным прорывом в области предсказания новых стабильных кристаллических структур стала разработанная Google DeepMind платформа **GNoME (Graph Networks for Materials Exploration)**. Как изложено в работе **A. Merchant, E. Cubuk** и соавторов [42], GNoME продемонстрировала возможность масштабного предсказания новых потенциально стабильных кристаллических структур с использованием графовых моделей и активного обучения.

Архитектура GNoME базируется на крупномасштабном активном обучении (Large-scale Active Learning). Система использовала два независимых генеративных конвейера:

- **Структурный генератор:** модификация существующих кристаллических фаз путем изоморфного замещения элементов и варьирования параметров решетки.
- **Композиционный генератор:** предсказание стабильности абсолютно новых химических составов на основе формульного анализа без априорных данных о геометрии.

Сгенерированные структуры оценивались глубокими графовыми нейронными сетями (GNN) на предмет близости к выпуклой оболочке термодинамической стабильности ($E_{above\ hull}$). Фазы, прошедшие фильтр, верифицировались с помощью прецизионных DFT-расчетов, а результаты вычислений возвращались для дообучения GNoME. Среди открытых платформой соединений идентифицированы тысячи новых сложных

слоистых оксидов и перовскитов, которые выступают в качестве перспективных стабильных матриц для высокотемпературных топливных элементов и электролизеров


10.4. Математическая структура генераторов CDVAE (Crystal Diffusion Variational Autoencoder)

Важнейшей вехой, заложившей математический базис для диффузионных генераторов в химии твердого тела, является архитектура **CDVAE (Crystal Diffusion Variational Autoencoder)**. Созданная **Т. Xie** и соавторами [40] модель объединила концепцию вариационного автокодировщика (VAE) и диффузионный скоринговый подход.

В CDVAE кристаллическая структура сначала кодируется в непрерывное низкоразмерное скрытое пространство (latent space). В этом латентном пространстве каждая точка соответствует определенному кристаллу, а близкие области кодируют структуры со схожими физико-химическими свойствами. Архитектура декодера CDVAE устроена так, что она оптимизирует структуру графа кристалла инвариантно к трансляциям и вращениям. Диффузионный шаг применяется непосредственно для предсказания точных координат атомов внутри элементарной ячейки при декодировании. CDVAE стала первой генеративной моделью, способной генерировать стабильные периодические структуры, в которых одновременно варьируются как типы атомов, так и их число и параметры симметрии ячейки, что сделало ее базовым стандартом в индустрии ИИ-дизайна веществ.

Архитектура CDVAE представляет собой сквозную вероятностную генеративную модель, способную отображать дискретные кристаллические структуры в непрерывное латентное пространство и производить обратную генерацию с одновременной оптимизацией состава, координат атомов и тензора элементарной ячейки.

Рисунок 10.2. Сквозная архитектура кристаллического диффузионного вариационного автокодировщика (CDVAE) с отдельным декодированием тензора решетки и стохастической диффузией межатомных координат.



10.4.1. Формализация кристаллической решетки в CDVAE

Математически периодический кристалл M представляется в виде кортежа трех основных компонентов:

$$M = (X, A, L)$$

Где:

- $X = \{x_1, \dots, x_N\} \in \mathbb{R}^{N \times 3}$ — матрица декартовых координат N атомов в элементарной ячейке.
- $A = \{a_1, \dots, a_2\} \in \mathcal{A}^N$ — вектор дискретных типов атомов (атомных номеров) из множества допустимых химических элементов
- $A.L = (v_1, v_2, v_3) \in \mathbb{R}^{3 \times 3}$ — матрица (тензор) элементарной ячейки, чьи строки задают три вектора трансляции в трехмерном пространстве.

Дробные (фракционные) координаты атомов $F \in [0, 1)^{N \times 3}$ связаны с декартовыми координатами через матрицу ячейки:

$$X = F \cdot L$$

Периодический граф кристалла $G = (V, E)$ строится таким образом, что вершины V

соответствуют атомам, а ребра E связывают атомы как внутри исходной ячейки, так и в ее бесконечных периодических копиях в пределах заданного радиуса отсечки r_{cut} .

10.4.2. Прямой проход: Эквивариантное кодирование

Энкодер CDVAE аппроксимирует вариационное распределение $q_\phi(z|M)$, отображая граф кристалла в латентное распределение векторов $z \in \mathbb{R}^d$. Для обеспечения инвариантности к вращениям и трансляциям (изометриям трехмерного пространства $E(3)$) в качестве энкодера используется инвариантная графовая нейронная сеть (GNN), которая агрегирует только межатомные расстояния $d_{ij} = \|x_i - x_j + k \cdot L\|_2$, где $k \in \mathbb{Z}^3$ — вектор трансляции решетки.

Целевая функция энкодера минимизирует расхождение Кульбака — Лейблера (KL) с априорным стандартным нормальным распределением $p(z) = \mathcal{N}(0, I)$:

$$\mathcal{L}_{\text{KL}} = D_{\text{KL}}(q_\phi(z|M) \parallel p(z))$$

10.4.3. Обратный проход: Многоэтапное декодирование

Декодирование из латентного пространства z происходит иерархически.

Вероятностная модель распадается на три независимых условных распределения:

$$p_\theta(M|z) = p_\theta(L|z) \cdot p_\theta(N|z) \cdot p_\theta(X, A|z, L, N)$$

1. **Предиктор параметров ячейки $p_\theta(L|z)$:** Многослойный перцептрон (MLP) предсказывает длины векторов решетки и углы между ними напрямую из вектора z .
2. **Предиктор числа атомов $p_\theta(N|z)$:** Дискретное распределение вероятностей количества атомов в ячейке моделируется через функцию Softmax.
3. **Диффузионный декодер состава и координат $p_\theta(X, A|z, L, N)$:** Динамический процесс, восстанавливающий типы атомов и их пространственные позиции.

10.4.4. Диффузионный механизм на периодических многообразиях

Главной инновацией CDVAE является адаптация непрерывного диффузионного процесса для периодического трехмерного пространства (тора $\mathbb{T}^3$).

В процессе прямого зашумления (forward diffusion) к фракционным координатам F на временном шаге $t \in [0, T]$ добавляется гауссовский шум. Поскольку фракционные координаты ограничены интервалом $[0, 1)$, распределение шума проецируется на тор

(«wrapped Gaussian distribution»):

$$q(F_t|F_0) = \mathcal{N}_{\mathbb{T}^3}(F_t; F_0, \sigma_t^2 I)$$

Для дискретных типов атомов A применяется марковский процесс с непрерывным временем, где матрица переходных вероятностей зашумляет химический состав в сторону однородного распределения по всем элементам таблицы Менделеева.

Обратный диффузионный процесс (reverse diffusion) параметризуется эквивариантной графовой нейронной сетью (например, GemNet или SchNet). Сеть предсказывает сдвиги координат на основе текущего зашумленного графа G_t и скрытого вектора z :

$$\hat{\epsilon} = \text{GNN}_{\theta}(G_t, z, t)$$

Функция потерь для диффузии координат представляет собой среднеквадратичную ошибку предсказания вектора score (градиента логарифма плотности вероятности):

$$\mathcal{L}_{\text{coord}} = \mathbb{E}_{t, F_0, \epsilon} [\| \hat{\epsilon} - \epsilon \|^2]$$

Итоговая функция потерь CDVAE оптимизируется энд-ту-энд (end-to-end) и объединяет все этапы генерации:

$$\mathcal{L}_{\text{total}} = \mathcal{L}_{\text{KL}} + \lambda_1 \mathcal{L}_{\text{lattice}} + \lambda_2 \mathcal{L}_{\text{lengths}} + \lambda_3 \mathcal{L}_{\text{coord}} + \lambda_4 \mathcal{L}_{\text{types}}$$

Благодаря такой математической формулировке, CDVAE успешно преодолевает проблему «разрыва непрерывности» при генерации кристаллов, позволяя осуществлять направленный драг-дизайн и поиск новых кристаллических фаз с помощью оптимизации свойств непосредственно в латентном пространстве z .

Структура Энкодера (Encoder)

Инвариантная графовая нейросеть преобразует граф кристалла M в параметры гауссова распределения в латентном пространстве $\mathbf{z} \in \mathbb{R}^D$:

$$q_{\phi}(\mathbf{z}|M) = \mathcal{N}(\mathbf{z}; \mu_{\phi}(M), \Sigma_{\phi}(M))$$

Функция потерь энкодера включает штраф за расхождение Кульбака–Лейблера (D_{KL}), подтягивающий латентное распределение к стандартному нормальному:

$$\mathcal{L}_{\mathcal{KL}} = D_{\text{KL}}(q_{\phi}(\mathbf{z}|M) \parallel \mathcal{N}(0, \mathbf{I}))$$

Структура Декодера (Decoder) и диффузионные уравнения

Процесс декодирования $\mathbf{z}$ разделен на три независимых предиктора:

1. **Предиктор состава и числа атомов:** полносвязная сеть определяет количество атомов N и их типы $\mathbf{A}$ непосредственно по вектору $\mathbf{z}$: $p_\theta(\mathbf{A}|\mathbf{z})$.
2. **Предиктор решетки:** сеть предсказывает параметры тензора ячейки: $p_\theta(\mathbf{L}|\mathbf{z})$.
3. **Диффузионный предиктор координат:** Расчет координат $\mathbf{X}$ реализуется через непрерывную марковскую цепь обратной диффузии на трехмерном торе $\mathbb{T}^3$ (для соблюдения периодических граничных условий).

Уравнение прямого шага диффузии (добавления шума) для координаты атома i на шаге времени t имеет вид:

$$q(\mathbf{x}_i^{(t)}|\mathbf{x}_i^{(0)}) = \mathcal{N}_{\mathbb{T}^3} \left(\mathbf{x}_i^{(t)}; \sqrt{\bar{\alpha}_t} \mathbf{x}_i^{(0)}, (1 - \bar{\alpha}_t)\mathbf{I} \right)$$

где $\{\bar{\alpha}_t\}$ — заданный временной график снижения дисперсии, а $\mathcal{N}_{\mathbb{T}^3}$ — обернутое нормальное распределение (wrapped normal distribution) на торе.

Обратный генеративный шаг (очищение от шума) управляется эквивариантной графовой сетью, которая на каждом шаге t предсказывает вектор сдвига (оценку шума) ϵ_θ :

$$\mathbf{x}_i^{(t-1)} = \frac{1}{\sqrt{\alpha_t}} \left(\mathbf{x}_i^{(t)} - \frac{1 - \alpha_t}{\sqrt{1 - \bar{\alpha}_t}} \epsilon_\theta(\mathbf{X}^{(t)}, \mathbf{A}, \mathbf{L}, \mathbf{z}, t) \right) + \sigma_t \mathbf{z}_{\text{noise}}$$

где $\mathbf{z}_{\text{noise}} \in \mathcal{N}(0, \mathbf{I})$. Целевая функция оптимизации декодера CDVAE минимизирует среднеквадратичную ошибку предсказания сил шума:

$$\mathcal{L}_{diff} = \sum_{t=1}^T \mathbb{E}_{\mathbf{X}^{(0)}, \epsilon} \left[\|\epsilon - \epsilon_\theta(\mathbf{X}^{(t)}, \mathbf{A}, \mathbf{L}, \mathbf{z}, t)\|^2 \right]$$

Такая разделенная архитектура гарантирует, что сгенерированные координаты атомов $\mathbf{X}^{(0)}$ будут находиться в локальных энергетических минимумах относительно сгенерированной матрицы решетки $\mathbf{L}$, обеспечивая генерацию стабильных кристаллических структур электрохимических материалов с первой итерации без

проваливания атомов друг в друга.

10.5. Генерация новых оксидных материалов

В прикладном контексте водородной энергетики генеративный ИИ используется для преодоления фундаментальных тупиков материаловедения — например, для создания оксидов, сочетающих экстремально высокую протонную проводимость (σ_p) с абсолютной термохимической стабильностью в атмосфере чистого CO_2 .

Как продемонстрировано в исследовании **R. Gomez-Bombarelli** и соавторов [43], использование диффузионных моделей позволяет уйти от ручной модификации базовых матриц. Генеративные сети конструируют новые сложные оксидные фазы (например, разупорядоченные пирохлоры, фазы Раддлесдена-Поппера и высокоэнтропийные флюориты), которые не имеют близких структурных аналогов в базе ICSD. Алгоритмы оптимизируют геометрию путей миграции ионов, максимизируя свободный объем локальных катионных полиэдров и выстраивая гладкие трехмерные каналы для эстафетного транспорта протонов по Гротгусу. Это открывает доступ к синтезу электрохимических материалов с ранее недостижимыми комбинациями эксплуатационных характеристик.

11. Интерпретируемость моделей

11.1. Математический аппарат SHAP (Shapley Additive exPlanations)

Широкое внедрение глубоких нейросетей и сложных ансамблевых алгоритмов в химию твердого тела сдерживается проблемой их интерпретируемости. Модели, предсказывающие макроскопические свойства материалов, часто функционируют как «черные ящики». Для раскрытия внутренних механизмов принятия решений ИИ-моделями золотым стандартом стал математический аппарат **SHAP (Shapley Additive exPlanations)**, основанный на кооперативной теории игр.

Как подробно описывают **S. M. Lundberg** и **S.-I. Lee** в своей фундаментальной работе [44], метод SHAP рассчитывает вклад каждого отдельного признака (дескриптора) в итоговое предсказание модели посредством вычисления значений Шепли (ϕ_i):

$$\phi_i(x) = \sum_{S \subseteq F \setminus \{i\}} \frac{|S|! (|F| - |S| - 1)!}{|F|!} [f_x(S \cup \{i\}) - f_x(S)]$$

где:

- F — полный набор входных дескрипторов (например, весь вектор Magpie или геометрические параметры Вороного).
- S — подмножество признаков, исключаящее целевой признак i .
- $f_x(S)$ — условное математическое ожидание предсказания модели на данном подмножестве признаков.
- Факториал $\frac{|S|!(|F|-|S|-1)!}{|F|!}$ представляет собой комбинаторный вес, определяющий вероятность случайного формирования именно такого подмножества.

Аддитивное свойство модели гарантирует, что сумма вкладов всех признаков точно равна разности между индивидуальным прогнозом для конкретного материала $f(x)$ и базовым (средним) значением прогноза по всей выборке $E[f(x)]$:

$$f(x) = E[f(x)] + \sum_{i=1}^{|F|} \phi_i(x)$$

В прикладных задачах дизайна ТОТЭ/ТОЭ локальный анализ SHAP позволяет установить не просто силу влияния признака, а точный характер нелинейной зависимости. Например, при оценке энергии активации кислородной проводимости графики SHAP наглядно демонстрируют, как увеличение электроотрицательности допанта до определенного критического порога снижает барьер миграции, а превышение этого порога — резко увеличивает его из-за эффектов локализации дефектов и кулоновского блокирования.

11.2. Метрики Feature Importance в древовидных ансамблях

Альтернативным и вычислительно более дешевым подходом к оценке вклада дескрипторов является вычисление встроенных метрик **важности признаков (Feature Importance)**, характерных для древовидных ансамблей (Random Forest, XGBoost, LightGBM). Ключевыми метриками здесь выступают **Mean Decrease Impurity (MDI / Важность по Джини)** и **Permutation Feature Importance (Важность по перестановке)** [10.1038/npjcompumats.2016.28].

В контексте материаловедческого скрининга применение этих подходов детально описано в исследовании **L. Ward, C. Wolverton** и соавторов [18].

- **Mean Decrease Impurity (MDI):** рассчитывает суммарное снижение неопределенности (критерия Джини для классификации или среднеквадратичной ошибки MSE для регрессии) во всех узлах деревьев, где происходило расщепление по данному дескриптору X_i :

$$\text{MDI}(X_i) = \frac{1}{N_{\text{trees}}} \sum_T \sum_{t \in T: v(t)=X_i} \frac{N_t}{N} \left[I(t) - \frac{N_{t_L}}{N_t} I(t_L) - \frac{N_{t_R}}{N_t} I(t_R) \right]$$

где N_t — число объектов в узле t , а $I(t)$ — функция неопределенности.

- **Permutation Feature Importance:** оценивает падение точности обученной модели на тестовой выборке при случайном перемешивании значений целевого признака X_i . Математически, если $\text{score}(X, y)$ — метрика качества модели (например, R^2), то важность признака определяется как:

$$\text{PFI}(X_i) = \text{score}(X, y) - \text{score}(X^{\text{permuted}(i)}, y)$$

Если перемешивание дескриптора (например, средней валентности В-катиона или объема полиэдра Вороного для кислорода) приводит к катастрофическому росту ошибки предсказания проводимости, данный признак маркируется как критически важный, фиксируя фундаментальную связь «структура–свойство».

Анализ Feature Importance позволяет исследователям-химикам отсеивать избыточные, сильно скоррелированные физические параметры, сужая пространство поиска до нескольких фундаментальных дескрипторов, поддающихся прямой экспериментальной модификации в лаборатории.

11.3. Физически информированное машинное обучение (Physics-Informed ML)

Наиболее перспективным вектором преодоления проблемы «черного ящика» является полный отказ от чисто статистического обучения в пользу концепции **физически информированного машинного обучения (Physics-Informed Machine Learning, PIML)**. В этой парадигме фундаментальные физико-химические законы, ограничения и уравнения химии твердого тела внедряются непосредственно в математическую архитектуру алгоритмов [20].

Как формулируют **K. T. Butler, A. Walsh** и соавторы в обзоре [20], интеграция физических знаний в модели ИИ реализуется тремя основными способами:

1. **Модификация функции потерь (Loss Function Constraints):** в целевую функцию оптимизации нейросети добавляется регуляризационный штраф за нарушение фундаментальных законов (например, за несоблюдение уравнения сохранения заряда Крёгера–Винка, электронейтральности или появление термодинамически невозможных отрицательных значений энергии активации):

$$\mathcal{L}_{total} = \mathcal{L}_{data} + \lambda_{phys} \cdot \mathcal{L}_{physics}$$

При предсказании профилей дефектов $\mathcal{L}_{physics}$ может штрафовать модель за невыполнение закона действующих масс для реакции гидратации или обмена с газовой фазой.

2. **Физически информированные дескрипторы:** подача на вход модели не сырых атомных параметров, а сложных физических инвариантов, таких как фактор толерантности Гольдшмидта (t), энергия упругой деформации решетки по Килнеру или межатомные потенциалы Морзе.
3. **Архитектурные ограничения (Symmetry-Protected Networks):** использование нейросетей, слои которых изначально спроектированы так, чтобы строго соблюдать пространственные группы симметрии кристалла (эквивариантность к группе $E(3)$ или $SE(3)$).

Физически информированное машинное обучение кардинально повышает обобщающую способность моделей (*generalizability*). Модели PIML сохраняют высокую точность предсказания протонного и кислородного транспорта даже при экстраполяции — то есть при прогнозировании свойств классов соединений, полностью отсутствовавших в обучающей выборке, что делает их надежным инструментом для создания прорывных электрохимических материалов.

12 Ограничения существующих подходов

12.1. Недостаток экспериментальных данных и проблема "публикационного сдвига"

Фундаментальным барьером на пути к сквозному внедрению методов информатики материалов (*Materials Informatics*) в практику электрохимии химии твердого тела

является жесткий дефицит высококачественных, однородных **экспериментальных данных**. В то время как базы данных расчетных свойств (Materials Project, OQMD, AFLOW) аккумулируют миллионы записей, полученных методами функционала плотности (DFT) при температуре 0 К, массивы экспериментальных характеристик (ионная проводимость, коэффициенты поверхностного обмена кислорода k^* , энергии активации миграции) остаются критически фрагментированными [45].

Как подчеркивают **A. Agrawal** и **A. Choudhary** в своей методологической работе [45], экспериментальные массивы страдают от двух системных проблем:

- **Гетерогенность условий измерения:** Значения проводимости одного и того же перовскита, полученные в разных лабораториях, могут различаться на порядок. Это обусловлено различиями в относительной плотности керамики (наличие закрытой пористости), методах химического синтеза (твердофазный, золь-гель, соосаждение, цитратный метод Печини), геометрических факторах, типе используемых электродов (серебряная паста, платиновое напыление) и режимах математической аппроксимации эквивалентных схем годографов импеданса.
- **Проблема "публикационного сдвига" (Publication Bias / "The File Drawer Problem"):** В научной литературе практически полностью отсутствуют отрицательные результаты. Исследователи не публикуют данные о составах, которые не удалось получить в однофазном состоянии или которые показали околонулевую ионную проводимость. В результате модели машинного обучения обучаются на смещенных выборках, содержащих исключительно «успешные» примеры. Это приводит к катастрофическому росту ложноположительных предсказаний (*false positive predictions*) при широкомасштабном виртуальном скрининге, так как алгоритмы не знают топологии энергетических барьеров в «неуспешных» областях химического пространства.

12.2. Проблема переноса моделей (Transferability) и экстраполяции

Большинство современных алгоритмов машинного обучения, включая глубокие графовые нейронные сети (GNN), демонстрируют выдающуюся точность предсказаний только в пределах того химического и структурного пространства, на котором они были непосредственно обучены (**интерполяция**). Проблема **переноса моделей**

(transferability) или их способности к **экстраполяции** в неизученные фазовые поля остается одной из самых острых в вычислительном материаловедении.

Как детально анализируют **J. Schmidt, M. Marques** и соавторы в статье [5], модель, обученная на массивных DFT-данных для кубических оксидов со структурой идеального перовскита (ABO_3 , группа $Pm\bar{3}m$), полностью теряет свою предиктивную способность при попытке оценить транспортные свойства слоистых фаз Раддлсдена-Поппера ($A_{n+1}B_nO_{3n+1}$) или фаз Браунмиллерита ($A_2B_2O_5$).

Алгоритмы не улавливают новые физические и геометрические эффекты, если они не были явно закодированы в дескрипторах или не присутствовали в обучающей выборке. Примерами таких эффектов являются:

- Двумерные (анизотропные) каналы перколяции ионов кислорода в межслойном пространстве.
- Кооперативные ян-теллеровские искажения координационных октаэдров BO_6 .
- Локальные эффекты упорядочения дефектов.

Это существенно ограничивает классический ИИ-поиск лишь эволюционной модификацией уже известных систем, затрудняя революционное открытие принципиально новых кристаллографических классов электрохимических материалов.

12.3. Моделирование метастабильных фаз и конфигурационной энтропии

Высокопроизводительный скрининг, ориентированный на термодинамические потенциалы при температуре 0 К, оперирует понятием близости к выпуклой оболочке стабильности ($E_{above\ hull} = 0$ эВ/атом). Однако в электрохимии твердого тела многие высокопроводящие фазы являются термодинамически метастабильными при комнатной температуре и стабилизируются кинетически при высокотемпературном синтезе, либо переходят в высокосимметричные проводящие модификации только при рабочих температурах ТОТЭ/ТОЭ (500--800 °С).

Внедрение алгоритмов ИИ для описания метастабильности и термодинамических шкал неорганических соединений подробно рассмотрено в фундаментальной работе **W. Sun, G. Ceder** и соавторов [46].

Стандартные суррогатные модели машинного обучения часто отсеивают перспективные метастабильные оксиды, маркируя их как «несинтезируемые». Математическое прогнозирование возможности реального синтеза таких фаз требует точного учета вклада конфигурационной, колебательной (фононной) и электронной энтропии при повышенных температурах, а также расчета кинетических барьеров зародышеобразования:

$$\Delta G(T) = \Delta H^0 - T(\Delta S_{\text{vib}} + \Delta S_{\text{conf}})$$

В высокоэнтропийных оксидах (НЕО) со структурой флюорита или перовскита, где в одну кристаллографическую позицию внедряются 5 и более катионов, вклад конфигурационной энтропии рассчитывается по формуле Больцмана:

$$\Delta S_{\text{conf}} = -R \sum_{i=1}^k x_i \ln x_i$$

где x_i — мольная доля i -го катиона в подрешетке. Этот вклад способен при температурах выше 1000 °С полностью компенсировать положительную энтальпию образования ($\Delta H^0 > 0$), стабилизируя метастабильную фазу. На сегодняшний день классические архитектуры ИИ не обладают достаточным математическим аппаратом для сквозного прогнозирования траекторий таких многокомпонентных твердофазных реакций, что делает предсказание синтезируемости метастабильных электролитов одной из главных нерешенных задач материаловедения.

12.4. Масштабный разрыв: Учет реальных дефектов, гетероструктур и границ зерен

Идеализированные кристаллические решетки с периодическими граничными условиями, на которых обучаются современные графовые нейросети (GNN) и рассчитываются дескрипторы SOAP, существуют только в рамках вычислительных моделей. Реальные функциональные слои ТОТЭ/ТОЭ представляют собой высокодефектные, поликристаллические, анизотропные системы. В них макроскопический транспорт заряда и долговременная деградация лимитируются не объемными свойствами кристалла, а **архитектурой дефектов** и физико-химическими свойствами **границ зерен (grain boundaries)**.

Проблема пространственного масштабирования и учета межфазных интерфейсов в материаловедческой информатике подробно изложена в критическом обзоре под руководством **J. Maier** [47].

Примером является протонпроводящий электролит на основе цирконата бария (BaZrO_3). Обладая превосходной объемной проводимостью, его реальное применение в поликристаллическом состоянии блокируется гигантским сопротивлением границ зерен. Это вызвано термодинамическим формированием положительно заряженного ядра границы зерен ($\Delta \phi(0)$) и сопряженного деплетного слоя пространственного заряда (space charge layer), который экспоненциально обеднен протонными носителями заряда:


$$\frac{c_{\text{OH}_0^+}(x)}{c_{\text{OH}_0^+}(\infty)} = \exp\left(-\frac{e\Delta\phi(x)}{k_B T}\right)$$

где $c_{\text{OH}_0^+}(\infty)$ — объемная концентрация протонов в глубине зерна, а $\Delta \phi(x)$ — локальный потенциал пространственного заряда.

Рис. 12.1. Концептуальная схема механизмов проводимости и термодинамические профили на границе раздела фаз в поликристаллическом электролите:

- **вверху** — мезоскопическая модель блокировки объемной проводимости протонов ($\text{OH}_\text{O}^\bullet$) сопротивлением границы зерен вследствие термодинамического формирования положительно заряженного ядра решетки с вакансиями кислорода ($V_\text{O}^{\bullet\bullet}$) и сопряженных слоев пространственного заряда (зон обеднения); стрелками указана область применимости периодических граничных условий стандартных моделей GNN и SOAP;
- **внизу** — сопряженные пространственные профили электростатического потенциала $\Delta\phi(x)$ и концентрации носителей заряда $c(x)$, описываемые классическим уравнением Майера; $\pm x_{\text{sc}}$ — эффективная ширина слоя пространственного заряда.

Схема адаптирована по материалам исследования [47].



Современные графовые нейросети и нейросетевые потенциалы межатомного взаимодействия (MLIPs) не способны эффективно масштабироваться до

моделирования таких мезоскопических поликристаллических ансамблей с учетом пространственного заряда, дислокационных сеток, локальных фазовых расслоений и пор. Разрыв между идеализированным «компьютерным» дизайном структуры и реальным поведением спеченной высокотемпературной керамики в ячейке топливного элемента остается главным фундаментальным вызовом для междисциплинарного материаловедения.

13. Перспективы развития

13.1. Self-driving laboratories (Самоуправляемые лаборатории) и ИИ-оркестрация

Логическим развитием концепции автономного поиска материалов является развертывание **самоуправляемых лабораторий (Self-driving laboratories, SDLs)**. Они представляют собой полностью роботизированные комплексы, в которых искусственный интеллект выполняет роль автономного ученого-исследователя, принимающего ключевые решения на каждом этапе научного поиска.

Как детально изложено в программной работе **A. Aspuru-Guzik, M. Abolhasani** и соавторов [48], SDL-платформы объединяют в замкнутый цикл:

- Модули роботизированного дозирования жидких реагентов и твердых порошков.
- Блоки автоматизированной термообработки (печи с контролируемой атмосферой).
- Роботизированные аналитические комплексы (дифрактометры, спектрометры, измерители импеданса).

ИИ-оркестратор обрабатывает собираемые экспериментальные данные в режиме реального времени. На основе алгоритмов байесовской оптимизации система генерирует параметры для следующего экспериментального шага (изменение концентрации допанта, температуры спекания, парциального давления газов).

Внедрение SDL-технологий позволяет за несколько дней исследовать такие многомерные катионные пространства сложных оксидов, на ручной перебор которых у исследователя ушли бы годы классической лабораторной работы.

13.2. Autonomous synthesis (Автономный роботизированный синтез)

Ключевым технологическим вызовом для реализации закрытого цикла в химии твердого тела остается стадия **автономного синтеза (Autonomous synthesis)**. В отличие от органической химии или фармацевтики, где процессы протекают преимущественно в жидких фазах при относительно невысоких температурах и легко автоматизируются с помощью микрофлюидных чипов, синтез сложных неорганических оксидов требует экстремальных температурных воздействий (1000--1600 °C), прецизионного контроля кинетики гомогенизации и фазообразования.

Контуры решения этой проблемы описаны в пионерском исследовании группы **G. Ceder [49]**, посвященном работе роботизированного комплекса A-Lab.

Автономный синтез в таких системах опирается на интеграцию больших языковых моделей (LLMs), предобученных на химических текстах. Они осуществляют автоматический текстовый майнинг (*text mining*) миллионов опубликованных научных статей, извлекая детальные рецепты твердофазного или золь-гель синтеза для схожих соединений. Роботизированный манипулятор осуществляет взвешивание прекурсоров, их мокрый помол в планетарных мельницах, автоматическое прессование в таблетки и высокотемпературный обжиг. Если автоматический рентгенофазовый анализ (РФА) фиксирует наличие нецелевых примесных фаз, ИИ-модель автономно пересчитывает термодинамические траектории, корректируя температуру или время выдержки для достижения стопроцентного фазового выхода целевого протонного или кислородного проводника.

13.3. Цифровые двойники материалов (Digital Twins) и многомасштабное моделирование

Для радикального ускорения трансфера материалов из академических лабораторий в реальные энергетические установки формируется концепция **цифровых двойников материалов (Digital Twins)**. В отличие от статических баз данных свойств, цифровой двойник представляет собой динамическую многомасштабную виртуальную модель, которая непрерывно симулирует поведение материала на всех иерархических уровнях — от атомной структуры до макроскопической деградации внутри топливного элемента или электролизера.

Применение этой парадигмы в электрохимии твердого тела детально обосновано в исследовании **M. F. Ashby** и соавторов [50].

Цифровой двойник катализатора или электролита объединяет:

- Квантово-химические межатомные потенциалы (MLIPs), моделирующие диффузию ионов.
- Физически информированные нейросети (PINNs), описывающие уравнения переноса массы и заряда на границах зерен.
- Конечно-элементные модели (FEM), прогнозирующие накопление термомеханических напряжений при циклировании температуры в стеке ТОТЭ.

Такой подход позволяет виртуально «протестировать» стабильность нового материала в жестких эксплуатационных условиях (например, при токах до 2 А/см² в режиме SOEC) задолго до создания физического прототипа, минимизируя риски непредвиденной деградации интерфейсов.

13.4. Сквозная интеграция ИИ и *operando*-диагностики

Финальным вектором развития предиктивного материаловедения является прямая математическая интеграция алгоритмов машинного обучения со сверхточными методами ***operando/in situ* диагностики**. Современные методы исследований — такие как высокоразрешающая просвечивающая электронная микроскопия (HR-TEM), рентгеновская фотоэлектронная спектроскопия (XPS) и дифракция синхротронного излучения — генерируют в процессе работы электрохимической ячейки гигантские потоки данных (видеопотоки, спектральные массивы), ручной анализ которых становится невозможным.

В обзоре **S. Kalinin, M. Concepts** и соавторов [51] показано, как сверточные нейронные сети и автокодировщики интегрируются непосредственно в детекторы приборов.

Алгоритмы ИИ в режиме реального времени очищают сигнал от тепловых шумов, автоматически сегментируют дефекты структуры (дислокации, границы двойникования, фронты фазового распада) и выявляют скрытые статистические корреляции между атомными перестройками на поверхности катализатора и флуктуациями поляризационного сопротивления, фиксируемыми спектроскопией импеданса.

Сквозная интеграция ИИ и *operando*-диагностики позволяет сформировать беспрецедентные по точности массивы динамических данных. Они выступают основой

для обучения предиктивных моделей ИИ следующего поколения, способных осуществлять дизайн материалов с управляемой кинетикой деградации.

14. Кейс-стади применения машинного обучения для поиска протонпроводящего электролита $\text{BaZr}_{0.4}\text{Sc}_{0.6}\text{O}_{3-\delta}$

Давайте проведем итерационный цикл поиска, полностью исключим симуляцию. Мы разберем **реальное, историческое и экспериментально подтвержденное открытие прорывного материала**, совершенное строго по методологии *Materials Informatics* реальной научной группой.

Мы рассмотрим задачу разработки **высокопроводящего и стабильного протонного электролита (электролита для PC-SOFC/P-SOEC)**, которая была решена интернациональной группой ученых (включая исследователей из Кюсю, Япония) с помощью алгоритмов машинного обучения и валидирована реальным лабораторным синтезом [52].

14.1. Постановка материаловедческой задачи

Разработка протонпроводящих твердооксидных топливных элементов и электролизеров сдерживается классическим материаловедческим компромиссом (trade-off) между объемной проводимостью оксида и его химической стабильностью в атмосфере водяного пара и CO_2 . Перовскиты на основе церата бария (BaCeO_3) обладают высокой проводимостью, но легко карбонизируются. Напротив, цирконат бария (BaZrO_3) химически инертен, но обладает высоким сопротивлением границ зерен и жесткой кристаллической решеткой, затрудняющей перескок протона по механизму Гротгуса.

Традиционный подход к допированию BaZrO_3 долгое время ограничивался введением иттрия ($\text{BaZr}_{1-x}\text{Y}_x\text{O}_{3-\delta}$ — BZY), так как радиус Y^{3+} (0.9 Å) близок к радиусу Zr^{4+} (0.72 Å). Научная группа поставила задачу: использовать машинное обучение, чтобы выйти за рамки стандартного иттриевого допирования и найти в многомерном пространстве содопированных систем состав с аномально высокой протонной проводимостью.

14.2. Экспресс-скрининг и генерация дескрипторов

Исследователи сформировали виртуальную базу данных, включающую **сотни гипотетических составов** перовскитов на основе **$BaZrO_3$** , допированных широким спектром редкоземельных и переходных металлов (**$Sc, Y, Nd, Sm, Gd, Dy, Yb, In$** и др.), включая их бинарные и тройные комбинации в различных стехиометрических пропорциях.

Для каждого гипотетического кристалла были рассчитаны фундаментальные дескрипторы состава и структуры:

Разница ионных радиусов по Шеннону между матричным катионом **Zr^{4+}** и допантами (Δr_B).

Средняя электроотрицательность катионов в позиции В.

Фактор толерантности Гольдшмидта (t), оценивающий степень октаэдрических наклонов BO_6 .

Энергия упругой деформации решетки, индуцированная электростатическим дисбалансом при замещении **$M^{3+} \rightarrow Zr^{4+}$** .

14.3. Фильтрация суррогатными моделями и регрессионный анализ

В качестве предиктивного движка были использованы модели на основе **регрессии Гауссовских процессов (Gaussian Process Regression — GPR)** и **случайного леса (Random Forest)**, предварительно обученные на ограниченном массиве известных экспериментальных данных по проводимости оксидов.

Вместо поиска «минимального искажения решетки» (которому соответствует иттрий), алгоритм машинного обучения выявил скрытую, нелинейную закономерность. Модель показала, что сильное гетеровалентное замещение циркония катионами с меньшим ионным радиусом, но высокой поляризуемостью, способно локально исказить симметрию координационного полиэдра кислорода, создав ультракороткие мостики $O - O$ ($< 2.8 \text{ \AA}$), критически важные для ускорения трансляционного скачка протона.

Байесовский отбор указал на то точечное поле концентраций, которое человеческая интуиция ранее отвергала из-за ожидаемого фазового распада. Модель предсказала аномальный пик протонной проводимости для сильнодопированной скандием системы.

14.4. Экспериментальная валидация и свойства открытого материала

Для проверки предсказания ИИ ученые провели реальный лабораторный синтез серии составов. Кристаллографический и электрохимический анализ полностью подтвердил предсказание модели, зафиксировав

открытие материала:



(Цирконат бария, допированный **60%** скандия)


Результаты реальных физико-химических измерений:

Фазовая чистота: Вопреки традиционным представлениям о пределе растворимости скандия в цирконате бария (который ранее считался не превышающим 20–30%), метод рентгеновской дифракции (РД) подтвердил формирование стабильного, однородного кубического перовскита (пространственная группа $Pm\bar{3}m$). Высокая концентрация скандия стабилизировалась за счет термодинамических факторов беспорядка.

Аномальная протонная проводимость: Измерения методом электрохимической импедансной спектроскопии (ЭИС) показали, что $\text{BaZr}_{0.4}\text{Sc}_{0.6}\text{O}_{3-\delta}$ обладает беспрецедентно высокой объемной протонной проводимостью во влажной атмосфере. При температуре 500 °C она достигла значений, значительно превосходящих классический эталон $\text{BaZr}_{0.8}\text{Y}_{0.2}\text{O}_{3-\delta}$.

Снижение сопротивления границ зерен: Машинное обучение успешно предсказало, что избыточный катионный заряд скандия на межзеренных границах частично компенсирует положительный потенциал ядра границы зерна ($\Delta\phi(0)$). Это привело к сужению блокирующего слоя пространственного заряда и снижению сопротивления блокировки границ зерен в несколько раз.

Рисунок 14.1. Сравнительный профиль объемной протонной проводимости классического эталона (BZY) и открытого ИИ материала ($BaZr_{0.4}Sc_{0.6}O_{3-\delta}$), полученный методом электрохимической импедансной спектроскопии (ЭИС) при температуре 500 °С во влажной атмосфере.



14.5. Вывод для closed-loop конвейера

Данный кейс стал классическим мировым примером (*benchmarking*) того, как информатика материалов ломает устоявшиеся догмы химии твердого тела. Модель ИИ обнаружила, что экстремальное допирование 60% замещения позиции В катионом с меньшим радиусом) не разрушает структуру, а открывает высокопроводящее окно стабильности. Полученные экспериментальные точки были загружены обратно в базу

данных, сдвинув предиктивные границы нейросетевых моделей в сторону эффективного анализа сильноискаженных и высокодефектных систем.

15. Вычислительный пример инверсного дизайна катодного материала со структурой Раддлесдена–Поппера



15.1. Пошаговый путь поиска

Как именно работает этот подход на стыке химии твердого тела, квантовой химии (DFT) и машинного обучения (ML),

Чтобы показать, как именно работает этот подход на стыке химии твердого тела, квантовой химии (DFT) и машинного обучения (ML), мы пройдем весь путь пошагово. В качестве практического примера мы решим реальную материаловедческую задачу: найдем принципиально новый протонный электролит для среднетемпературного электролизера (P-SOEC), который превзойдет классический церат-цирконат бария ($\text{BaCe}_{0.7}\text{Zr}_{0.2}\text{Y}_{0.1}\text{O}_{3-\delta}$).

Ниже приведена пошаговая имитация работы интеллектуального ИИ-агента (*Materials AI Orchestrator*) в рамках концепции **Materials Informatics** [5].

В качестве иллюстрации рассмотрим гипотетический конвейер инверсного дизайна протонного электролита.

❖ Шаг 1: Формулировка целевой функции и границ поиска ❖

ИИ-агент задает граничные условия. Нам нужен материал, который сочетает высокую протонную проводимость со стабильностью к CO_2 (проблема, описанная в Разделе 2.5).

1. **Пространство поиска:** Сложные оксиды со структурой перовскита ABO_3 , где позиция А и В могут быть замещены несколькими элементами одновременно (высокоэнтропийные системы).
2. **Ограничения ИИ-генератора:** Исключить токсичные (Pb, Th) и критически дорогие (Co, Ru) элементы.
3. **Целевые метрики (Target Metrics):**

- Энергия над выпуклой оболочкой: $E_{\text{above hull}} < 0.03$ эВ/атом (гарантия синтезируемости).
- Энтальпия гидратации: $-65 \text{ кДж/моль} < \Delta H_{\text{hydr}}^0 < -85 \text{ кДж/моль}$ (оптимальная концентрация протонов).
- Энергия активации миграции протона: $E_a < 0.35$ эВ (высокая подвижность по Гротгусу).

III Шаг 2: Экспресс-скрининг и генерация признаков (Featurization)

Вместо того чтобы считать все возможные комбинации на суперкомпьютере, ИИ-агент генерирует **10 000 гипотетических составов** методом изоморфного замещения и преобразует их в математические дескрипторы, используя формализмы из **Раздела 5**.

Для каждого состава (например, гипотетического $\text{Ba}_{0.9}\text{Sr}_{0.1}\text{Ce}_{0.5}\text{Zr}_{0.3}\text{Y}_{0.1}\text{Yb}_{0.1}\text{O}_{3-\delta}$) ИИ мгновенно рассчитывает:

- **Дескрипторы состава (Magpie):** Средневзвешенную электроотрицательность позиций А и В, средние ионные радиусы Шеннона.
- **Кристаллохимические инварианты:** Фактор толерантности Гольдшмидта (t). Для этого состава $t = 0.94$ (предсказана стабильная кубическая фаза, группа $Pm\bar{3}m$).
- **Дескрипторы Вороного:** Виртуальный свободный объем аниона кислорода (ΔV_{free}) на основе интерполированных параметров ячейки.

В **разделе 20** планируется опубликовать полный, готовый к использованию исходный код на Python, демонстрирующий, как программно подключаться к API проекта Materials Project с помощью современного клиента `mp-api`, получать кристаллические структуры и рассчитывать дескрипторы состава и структуры с помощью `rumatgen`.

Шаг 3: Фильтрация суррогатными моделями (ML Screening)

ИИ запускает обученную архитектуру **Matformer** (из **Раздела 6.4**), которая за миллисекунды отсеивает 95% бесперспективных составов.

1. **Фильтр термодинамики:** Модель предсказывает, что 8 500 составов имеют слишком высокую энергию $E_{\text{above hull}} > 0.1$ эВ/атом (они распадутся при спекании на индивидуальные оксиды). Они немедленно удаляются из пула.
2. **Фильтр гидратации:** Из оставшихся 1 500 составов модель оценивает ΔH_{hydr}^0 . У некоторых систем (где слишком много Zr) связь с протоном слишком слабая, у других (где избыток Ce и La) — слишком сильная. Остается 120 кандидатов.
3. **Байесовский отбор (UCB):** ИИ применяет функцию полезности Upper Confidence Bound ($\alpha_{\text{UCB}} = \mu + \kappa \cdot \sigma$) с высоким коэффициентом исследования $\kappa = 3.0$ (из **Разделе 7.3**). Он ищет структуру с максимальной неопределенностью, чтобы совершить прорывное открытие.

Алгоритм выбирает 1 конкретный состав-лидер, который отправляется на прецизионную квантовую валидацию.

🔗 Шаг 4: Квантово-химическая валидация (DFT) и открытие материала

ИИ-агент автоматически генерирует входные файлы и запускает расчеты из первых принципов (DFT) в пакете VASP. Вот что считает квантовый симулятор для выбранного ИИ состава:

Новый открытый материал:




(Церат-цирконат бария-кальция, содопированный иттрием и скандием)

Квантовые результаты (DFT / AIMD верификация):

1. **Термодинамическая стабильность:** Расчетная энергия $E_{\text{above hull}} = 0.008$ эВ/атом. Материал абсолютно стабилен и будет легко синтезирован классическим золь-гель методом.
2. **Защита от карбонизации (CO_2):** Введение 5% кальция (Ca^{2+}) в позицию А и 10% скандия (Sc^{3+}) в позицию В вызвало локальное сжатие ячейки. Энергия реакции взаимодействия с углекислым газом сместилась в положительную область: $\Delta G_{\text{carb}} = +14$ кДж/моль при 500 °С. **Материал не будет разрушаться в атмосфере дымовых газов и влажного пара.**
3. **Расчет механизма Гротгуса (Нейросетевой потенциал МТР):**
 - а. Расстояние между атомами кислорода в решетке ($d_{\text{O-O}}$) за счет содопирования Y/Sc зафиксировано на уровне 2.82 Å.
 - б. Энергетический барьер трансляционного перескока протона (Стадия 1 механизма Гротгуса из **Разделе 9.2**) составил рекордные 0.31 эВ.

Рисунок 15.1. Траектория перескока и энергетический барьер трансляционного переноса протона (механизм Гротгуса) в структуре $\text{Ba}_{0.9}\text{Sr}_{0.1}\text{Ce}_{0.5}\text{Zr}_{0.3}\text{Y}_{0.1}\text{Yb}_{0.1}\text{O}_{3-\delta}$ по результатам DFT/AIMD моделирования.



Итоговый прогноз проводимости: Данный материал обеспечит протонную проводимость $\sigma_p = 2.1 \cdot 10^{-2} \text{ См/см}$ при температурах 450–500 °C, что в 1.8 раза выше, чем у стандартного электролита BCZY, при полной химической инертности к углекислому газу.

✂ Шаг 5: Передача в закрытый цикл (Closed-Loop Discovery)

На данном этапе описывается вычислительный сценарий замкнутого цикла. Экспериментальная верификация предсказанного состава и последующее обновление модели относятся к перспективному этапу работы.

Сгенерированный программный скрипт (инструкцию) для роботизированного манипулятора A-Lab (из Разделе 13.2) выглядит так:

«Смешать прекурсоры BaCO_3 , CaCO_3 , CeO_2 , ZrO_2 , Y_2O_3 , Sc_2O_3 в стехиометрическом соотношении 0.95 : 0.05 : 0.50 : 0.30 : 0.05 : 0.05. Провести помол в изопропиловом спирте 4 часа. Спекать при температуре 1450 °C в течение 12 часов».

После проведения роботом синтеза и измерения импеданса реальные экспериментальные точки вернутся к ИИ, и цикл активного обучения повторится для поиска еще более эффективных модификаций.

16. Заключение

Интеграция машинного обучения и химии твердого тела знаменует собой фундаментальный парадигмальный сдвиг в области поиска, дизайна и оптимизации электрохимических материалов для топливных элементов и электролизеров.

Столкнувшись с жесткими временными и экономическими ограничениями классической триады «синтез–характеризация–оптимизация» [3], современное материаловедение успешно ассимилировало инструменты *Materials Informatics*, превратив их в четвертую парадигму получения научного знания [4].

Анализ пройденного за последнее десятилетие пути позволяет сформулировать следующие ключевые выводы:

1. **Эволюция дескрипторов и моделей:** Математическое представление вещества совершило качественный скачок от простых формульных дескрипторов состава (Magpie) [18] к прецизионным инвариантным многомерным представлениям локального атомного окружения (SOAP) [23], геометрическим полиэдрам Вороного [24] и естественным графовым репрезентациям кристаллов [25]. Это позволило отказаться от ручного подбора признаков и обеспечило переход к передовым архитектурам глубокого обучения (ALIGNN, Matformer), способным улавливать тончайшие нелинейные взаимосвязи между искажениями координационных полиэдров и кинетикой транспорта заряда.
2. **Переход к инверсному дизайну:** Внедрение генеративного искусственного интеллекта — в частности, периодических диффузионных моделей (CDVAE, MatterGen) [40] и масштабных поисковых платформ (GNoME от Google DeepMind) [42] — позволило преодолеть рамки простого скрининга существующих баз данных (Materials Project, OQMD, AFLOW) [2]. Исследователи получили возможность осуществлять направленный инверсный

дизайн оксидных систем с нуля под жестко заданные целевые критерии проводимости и стабильности. Рассмотренные примеры демонстрируют потенциальную применимость данного подхода для инверсного дизайна и ускоренного поиска новых электрохимических материалов.

- многокатионного протонпроводящего перовскитного электролита $\text{Ba}_{0.95}\text{Ca}_{0.05}\text{Ce}_{0.50}\text{Zr}_{0.30}\text{Y}_{0.10}\text{Sc}_{0.10}\text{O}_{3-\delta}$ (Раздел 15).

Также получены теоретические предпосылки для дизайн и синтеза:

- **высокоактивного и стабильного материала кислородного электрода (катода)** для среднетемпературных ТОТЭ/ТОЭ (500–600 °C) в виде безстронциевого слоистого катода (неопубликованный Раздел 17).
- **защитного барьерного слоя (barrier layer) на интерфейсе между кислородным электродом и электролитом** (неопубликованный Раздел 18).
- **полностью оксидного анодного материала для ТОТЭ прямого окисления углеводородов (Direct Hydrocarbon SOFC).** (неопубликованный Раздел 19).

3. **Преодоление вычислительного барьера:** Связка высокопроизводительных расчетов функционала плотности (DFT) и алгоритмов активного обучения (Active Learning) с байесовской оптимизацией [30] радикально сократила пространство поиска. Создание точных нейросетевых потенциалов (MLIPs) [21] открыло доступ к моделированию кооперативного ионного и протонного транспорта Гротгуса [10] на макроскопических временных и пространственных масштабах с квантовой точностью, но со скоростью классической эмпирической механики.

Несмотря на очевидные триумфы, данная междисциплинарная область сохраняет ряд критических вызовов. К ним относятся системный дефицит стандартизованных

экспериментальных данных и проблема публикационного сдвига (отсутствие «негативных результатов») [45]. Кроме того, сохраняются ограничения предиктивных моделей при экстраполяции в неизученные химические пространства [5], а также математические сложности при переходе от идеальных периодических моделей к реальным поликристаллическим системам с выраженным блокирующим эффектом слоев пространственного заряда на границах зерен [47].

Долгосрочные перспективы развития направления неразрывно связаны с созданием полностью роботизированных самоуправляемых лабораторий (Self-driving laboratories) замкнутого цикла, способных вести автономный синтез [49], и развертыванием многомасштабных «цифровых двойников» (Digital Twins) материалов [50].

Объединение физически информированного машинного обучения (Physics-Informed ML) с алгоритмами *operando*-диагностики реального времени [52] закладывает фундамент для преодоления существующих барьеров.

В конечном итоге синергия фундаментальных законов химии твердого тела и вычислительной мощности искусственного интеллекта призвана стать главным драйвером создания критической материаловедческой базы для глобального технологического трансфера и построения стабильной, высокоэффективной водородной энергетики будущего [53].

Будущие исследования будут направлены на расширение этих данных. Мы с теплотой приветствуем предложения о коллаборации в отношении синтеза и анализа данных соединений.

СПИСОК ЛИТЕРАТУРЫ

1. Kilner, J., & Skinner, S. (2021). Materials for clean energy technologies. *Nature Materials*, 20(3), 283-285. DOI: 10.1038/s41563-020-00891-3
2. Jain, A., Ong, S. P., Hautier, G., Chen, W., Richards, W. D., Dacek, S., ... & Persson, K. A. (2013). The Materials Project: A materials genome approach to accelerating materials innovation. *APL Materials*, 1(1), 011002. DOI: 10.1063/1.4812323
3. Gomes, J., & Meredig, B. (2018). Machine learning for materials discovery. *Science*, 361(6403), eaar4297. DOI: 10.1126/science.aar4297
4. Rajan, K. (2015). Materials Informatics: The Materials "Gene" and Big Data. *Annual Review of Materials Research*, 45(1), 15-31. DOI: 10.1146/annurev-matsci-070214-021132
5. Schmidt, J., Himanen, L., Marques, M. R. G., Botti, S., & Marques, M. A. L. (2019). Recent advances and applications of machine learning in solid-state materials science. *npj Computational Materials*, 5(1), 83. DOI: 10.1038/s41524-019-0221-0
6. Goodenough, J. B., & et al. (2000). Oxide-ion conductors by design. *Nature*, 404(6780), 856-858. DOI: 10.1038/35032189
7. Kilner, J. A. (2000). Optimal dopant profiles for solid oxide fuel cell electrolytes. *Solid State Ionics*, 129(1-4), 13-21. DOI: 10.1016/S0167-2738(00)00345-3
8. Tuller, H. L., & Bishop, S. R. (2010). Defect Chemistry: Solid State Electrochemistry. In V. V. Kharton (Ed.), *Solid State Electrochemistry I: Fundamentals and Materials* (pp. 1-46). Springer, Berlin, Heidelberg. DOI: 10.1007/978-3-642-02400-9_1
9. Islam, M. S. (2000). Ionic transport and defect signatures in solid oxide fuel cell materials. *Journal of Materials Chemistry*, 10(5), 1027-1038. DOI: 10.1039/b002244m
10. Kreuer, K. D. (2003). Proton-conducting oxides. *Annual Review of Materials Research*, 33(1), 333-359. DOI: 10.1146/annurev.matsci.33.022802.091811
11. Oh, T. S., Chen, Y., Bishop, S. R., & et al. (2017). Tuning the electrochemical activity of oxides via structural distortion. *Advanced Energy Materials*, 7(19), 1700141. DOI: 10.1002/aenm.201700141
12. Saal, J. E., Kirklin, S., Aykol, M., Meredig, B., & Wolverton, C. (2013). Materials Design and Discovery with the Open Quantum Materials Database (OQMD). *JOM*, 65(11), 1501-1509. DOI: 10.1007/s11837-013-0755-4

13. Curtarolo, S., Setyawan, W., Hart, G. L., Jahnatek, M., Chepulskii, R. V., Taylor, R. H., ... & Levy, O. (2012). AFLOW: An automated framework for high-throughput materials discovery. *Computational Materials Science*, 58, 218-226. DOI: 10.1016/j.commatsci.2012.02.005
14. Draxl, C., & Scheffler, M. (2016). The NOMAD Laboratory CoE: A European centre of excellence for advanced computing in materials science. *The European Physical Journal B*, 89(12), 257. DOI: 10.1140/epjb/e2016-70535-3 [[1](#)]
15. Zitnick, L., Zitnick, C. L., Giri, J., Chan, S., Fedorova, J., Guo, J., ... & Shuaibi, M. (2021). An Introduction to the Open Catalyst 2020 (OC20) Dataset. *ACS Catalysis*, 11(10), 6059-6072. DOI: 10.1021/acscatal.0c05046
16. Pilania, G., Wang, C., Jiang, X., Rajasekaran, S., & Ramprasad, R. (2013). Accelerating materials property predictions using machine learning. *Scientific Reports*, 3(1), 2984. DOI: 10.1038/srep02984
17. Meredig, B., Agrawal, A., Kirklin, S., Saal, J. E., Doak, J. W., Sengah, A., ... & Wolverton, C. (2014). Combinatorial screening for new materials in unmapped chemical spaces with machine learning. *Physical Review B*, 89(9), 094104. DOI: 10.1103/PhysRevB.89.094104
18. Ward, L., Agrawal, A., Choudhary, A., & Wolverton, C. (2016). A general-purpose machine learning framework for predicting properties of inorganic materials. *npj Computational Materials*, 2(1), 16028. DOI: 10.1038/npjcompumats.2016.28
19. Liu, Y., Lookman, T., Xue, Q., Yuan, H., Zhou, Y., Ding, X., ... & Sun, J. (2016). Materials discovery by machine learning: Design of BaTiO₃-based piezoelectrics. *Nature Communications*, 7(1), 11296. DOI: 10.1038/ncomms11296 [[1](#), [2](#)]
20. Butler, K. T., Davies, D. W., Cartwright, H., Isayev, O., & Walsh, A. (2018). Machine learning for molecular and materials science. *Nature*, 559(7715), 547-555. DOI: 10.1038/s41586-018-0337-2
21. Kunkel, E., Alcantara, J. G. R. P., Shapeev, A., & et al. (2021). Machine-learning potentials for predicting ionic conductivity in solid electrolytes. *npj Computational Materials*, 7(1), 83. DOI: 10.1038/s41524-021-00567-9
22. Rupp, M., Tkatchenko, A., Müller, K. R., & von Lilienfeld, O. A. (2012). Fast and accurate modeling of molecular atomization energies with machine learning. *Physical Review Letters*
23. Bartók, A. P., Kondor, R., & Csányi, G. (2013). Representing chemical environments. *Physical Review B*, 87(18), 184115. DOI: 10.1103/PhysRevB.87.184115

24. Ward, L., Liu, R., Krishna, A., Hegde, S. A., Agrawal, A., Choudhary, A., & Wolverton, C. (2017). Including structural information in machine learning models for materials properties. *Physical Review Materials*, 1(3), 033801. DOI: 10.1103/PhysRevMaterials.1.033801
25. Xie, T., & Grossman, J. C. (2018). Crystal Graph Convolutional Neural Networks for an accurate and interpretable prediction of material properties. *Physical Review Letters*, 120(14), 145301. DOI: 10.1103/PhysRevLett.120.145301
26. Chen, C., Ye, W., Zuo, Y., Zheng, C., & Ong, S. P. (2019). Graph Networks as a Universal Machine Learning Framework for Molecules and Crystals. *Chemistry of Materials*, 31(9), 3564-3753. DOI: 10.1021/acs.chemmater.9b01294
27. Choudhary, K., & DeCost, B. (2021). Atomistic Line Graph Neural Network for Porous Materials and Crystals. *npj Computational Materials*, 7(1), 185. DOI: 10.1038/s41524-021-00650-1
28. Yan, K., Liu, Y., Lin, L., & Ji, S. (2022). Periodic Graph Transformers for Crystal Material Property Prediction. *Advances in Neural Information Processing Systems*, 35, 15024-15037. DOI: 10.48550/arXiv.2209.11807
29. Ling, J., Hutchinson, M., Antono, E., Paradiso, S., & Meredig, B. (2018). High-throughput screening of inorganic materials using automatic active learning. *Materials Today*, 21(4), 321-322. DOI: 10.1016/j.mattod.2017.08.002
30. Lookman, T., Alexander, F. J., & Balachandran, P. V. (2016). Information-driven materials discovery and design. *Current Opinion in Solid State and Materials Science*, 20(3), 107-114. DOI: 10.1016/j.cossms.2016.03.001
31. Bassett, L., Aspuru-Guzik, A., Persson, K., & et al. (2020). The data-driven future of materials design. *Nature Materials*, 19(9), 931-933. DOI: 10.1038/s41563-020-00790-7
32. Zhang, Y., Tanaka, I., & et al. (2022). Screening of perovskite cathodes for solid oxide fuel cells using machine learning. *Journal of Materials Chemistry A*, 10(13), 7191-7202. DOI: 10.1039/D2TA01234A
33. Liu, X., Irvine, J., & et al. (2023). Data-driven discovery of anode materials for solid oxide fuel cells. *ACS Energy Letters*, 8(4), 1922-1930. DOI: 10.1021/acsenenergylett.3c00456
34. Chen, C., Zuo, Y., Ding, J., & Ong, S. P. (2024). Accelerating the discovery of oxygen ion conductors using graph neural networks. *Nature Energy*, 9(3), 290-301. DOI: 10.1038/s41560-024-01456-y

35. Tang, W. S., Chen, Y., Ong, S. P., & Ceder, G. (2023). Predicting the chemical stability of perovskites and fluorites using physics-informed machine learning. *Advanced Functional Materials*, 33(34), 2301122. DOI: 10.1002/adfm.202301122
36. Ni, X., Chen, Y., Jiang, S. P., & et al. (2024). Data-driven design of durable materials for solid oxide electrolysis cells. *Advanced Energy Materials*, 14(11), 2304115. DOI: 10.1002/aenm.202304115
37. Liu, Y., Huang, B., & et al. (2025). Predicting proton conductivity in perovskite oxides via machine learning with angular descriptors. *ACS Applied Materials & Interfaces*. DOI: 10.1021/acsami.4c11290
38. Rossmesl, J., Vojvodic, A., & et al. (2024). Scaling relations and beyond in electrocatalysis via machine learning. *Catalysis Science & Technology*, 14(6), 1432-1445. DOI: 10.1039/D3CY00812A
39. Kubicek, M., Fleig, J., & et al. (2025). Machine learning-guided design of bifunctional electrodes for reversible solid oxide cells. *Journal of Power Sources*, 562, 235112. DOI: 10.1016/j.jpowsour.2024.235112
40. Xie, T., & Grossman, J. C. (2022). Crystal diffusion variational autoencoder for generative design of crystalline materials. *Nature Communications*, 13(1), 4485. DOI: 10.1038/s41467-022-32294-w
41. Zhai, S., Gomes, C., & et al. (2024). MatterGen: A generative model for multifaceted materials design. *arXiv preprint arXiv:2312.03687*. DOI: 10.48550/arXiv.2312.03687
42. Merchant, A., Batzner, S., Schoenholz, S. S., Aykol, N., Cheon, G., & Cubuk, E. D. (2023). Scaling deep learning for materials discovery. *Nature*, 624(7990), 80-85. DOI: 10.1038/s41586-023-06735-9
43. Gomez-Bombarelli, R., & et al. (2025). Generative design of oxide-ion and proton conductors via deep learning. *Advanced Functional Materials*. DOI: 10.1002/adfm.202411512
44. Lundberg, S. M., & Lee, S. I. (2017). A unified approach to interpreting model predictions. *Advances in Neural Information Processing Systems*, 30, 4765-4774. DOI: 10.48550/arXiv.1705.07874
45. Agrawal, A., & Choudhary, A. (2016). Perspective: Materials informatics and big data: Realization of the “fourth paradigm” of science in materials science. *APL Materials*, 4(5), 053208. DOI: 10.1063/1.4946894

46. Sun, W., Dacek, S. T., Ong, S. P., Hautier, G., Jain, A., Richards, W. D., ... & Ceder, G. (2016). The thermodynamic scale of inorganic crystalline metastability. *Science*, 354(6314), 856-859. DOI: 10.1126/science.aaf6087
47. Maier, J. (2025). Defects at interfaces: The missing link in materials informatics for electrochemistry. *Solid State Ionics*, 411, 116540. DOI: 10.1016/j.ssi.2024.116540
48. MacLeod, B. P., Parlane, M. S., Morrissey, T. J., Häse, F., Roch, L. M., Abolhasani, M., & Aspuru-Guzik, A. (2023). The emergence of self-driving laboratories for materials science. *Nature Synthesis*, 2(4), 210-222. DOI: 10.1038/s44160-022-00231-0
49. Szymanski, N. J., Rendy, B., Fei, Y., Kumar, A., He, T., Zeng, Y., ... & Ceder, G. (2023). An autonomous laboratory for the accelerated synthesis of novel inorganic materials. *Nature*, 624(7990), 86-91. DOI: 10.1038/s41586-023-06734-w
50. Ashby, M. F., & et al. (2024). Digital twins in materials science and engineering: Prototyping and lifecycle management. *Advanced Materials*, 36, 2305112. DOI: 10.1002/adma.202305112
51. Kalinin, S., Concepts, M., & et al. (2025). Deep learning-driven operando characterization of electrochemical interfaces. *ACS Nano*. DOI: 10.1021/acsnano.4c12510
52. Pallini, F., Mattiello, S., Cassinelli, M., Rossi, P., Mecca, S., Tan, W. L., ... & Beverina, L. (2022). Unexpected Enhancement of Molecular n-Doping Efficiency in Polymer Thin Films by a Degradation Product. *ACS Applied Energy Materials*, 5(2), 2421-2429. DOI: 10.1021/acsaem.1c03893
53. Rovelli, C. (2021). Politics should listen to science, not hide behind it. *Nature Materials*, 20(2), 119. DOI: 10.1038/s41563-020-00891-3