



КАЗАҚСТАН РЕСПУБЛИКАСЫ
ПРЕЗИДЕНТІНІҢ ЖАНЫНДАҒЫ
КАЗАҚСТАН РЕСПУБЛИКАСЫНЫҢ
ҰЛТТЫҚ ҒЫЛЫМ
АКАДЕМИЯСЫ

№1 (январь-март)
2026 год

НАУКА ИНТЕЛЛЕКТУАЛЬНЫХ СИСТЕМ

Научный журнал НАН РК при Президенте РК

ҚР Президентінің жанындағы ҚР ҰҒА
«Интеллектуалды жүйелер ғылымы» ғылыми журналы

Scientific Journal of the NAS RK under the President of the RK
«Science of intelligent systems»

010010011011
011101010010

«Интеллектуалды жүйелер ғылымы» ғылыми журнал

Научный журнал «Наука интеллектуальных систем»

Scientific Journal «Science of intelligent systems»

БАС РЕДАКТОР:

Токбергенов И.Т.

физика-математика ғылымдарының
кандидаты, ҚР Президентінің жанындағы ҚР
ҰҒА Бас ғалым хатшысы

ГЛАВНЫЙ РЕДАКТОР:

Токбергенов И.Т.,

кандидат физико-математических наук,
Главный ученый секретарь НАН РК при
Президенте РК

CHIEF EDITOR:

I.Tokbergenov

Candidate of Physical and Mathematical
Sciences, Chief Scientific Secretary of the
National Academy of Science of the Republic of
Kazakhstan under the President of the
Republic of Kazakhstan

РЕДАКЦИЯЛЫҚ АЛҚА МҮШЕЛЕРІ:

Бакенов Ж.Б., академик (Қазақстан);

Батырбеков Э.Г., академик (Қазақстан);

Қалтаев А.Ж., академик (Қазақстан);

Локшин В.Н., академик (Қазақстан);

Миталипов Ш., профессор (АҚШ);

Сұраған Дурвудхан, академик (Қазақстан);

Телтаев Б.Б., академик (Қазақстан);

Чэнь Си, профессор (ҚХР);

Шеремет И. А., академик (Ресей).

ЧЛЕНЫ РЕДАКЦИОННОЙ КОЛЛЕГИИ:

Бакенов Ж.Б., академик (Қазақстан);

Батырбеков Э.Г., академик (Қазақстан);

Қалтаев А. Ж., академик (Қазақстан);

Локшин В.Н., академик (Қазақстан);

Миталипов Ш., профессор (США);

Сұраған Дурвудхан, академик (Қазақстан);

Телтаев Б.Б., академик (Қазақстан);

Чэнь Си, профессор (КНР);

Шеремет И.А., академик РАН (Россия).

MEMBERS OF THE EDITORIAL BOARD:

Bakenov J.B Academic (Kazakhstan);

Batyrbekov E.G., Academic (Kazakhstan);

Kaltaev A. J., Academic (Kazakhstan);

Lokshin V.N., Academic (Kazakhstan);

Mitalipov Sh., Professor (USA);

Suragan Durvudhan, Academic (Kazakhstan);

Teltaev B.B., Academic (Kazakhstan);

Chen Xi, Professor (China);

Sheremet I. A., Academic (Russia).

УЧРЕДИТЕЛЬ:

Национальная академия наук Республики Казахстан
при Президенте Республики Казахстан

Издается с 2025 года

Выходит 4 раза в год, ежеквартально

Свидетельство о постановке на учет периодического печатного
издания, информационного агентства и сетевого издания №
KZ90VPY00113742, выданное Министерством культуры и
информации от 03.03.2025 г.

Адрес редакции: 050010, г. Алматы, ул. Шевченко, 28

Тел. канцелярии: +7 (727) 308 08 17

Тел. отв. редактора: +7 705 988 19 52

Сайт журнала: <https://kazscience.kz>

FOUNDER:

National Academy of Sciences of the Republic of Kazakhstan
under the President of the Republic of Kazakhstan

Published since 2025 year.

Issued 4 times a year, quarterly

Certificate of registration of a periodical, news agency and online
publication No. KZ90VPY00113742 issued by the Ministry of Culture and
Information dated 03.03.2025.

Address of editorial offices: 050010, Almaty city, Shevchenko str., 28

Office phone number: +7 (727) 308 08 17

Tel. of the responsible editor: +7 705 988 19 52

Website: <https://kazscience.kz>

СОДЕРЖАНИЕ

Куришбаев А.К. Стратегия НАН РК в сфере искусственного интеллекта и цифровой трансформации	4
ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ	
Георгиев А.Ф., Никулин Д. С., Верзилин С. С. Алгоритм работы утилиты для автоматизированного моделирования резьбовых соединений в MSC patran/nastran.....	7
М.Н. Калимолдаев, М.Мансурова. Развитие искусственного интеллекта в казахстане за последнее десятилетие: всесторонний обзор.....	15
ЦИФРОВИЗАЦИЯ	
Калтаев А., Уалиев Ж.Р., Бибосынов А.Ж. Моделирование и исследование гидродинамики и массообмена при извлечении урана в насадочной ионообменной колонне с коническим распределителем потока.....	29
А.Синчев, Б.Синчев, А.Чинчалинова, А.Оспанова. Распределённая адаптация ии как структурный риск: От архитектуры нейросетей к многоуровневой модели управления.....	53

CONTENT

Kurishbaev A.K. Strategy of the National Academy of Sciences of the Republic of Kazakhstan in the Field of Artificial Intelligence and Digital Transformation	4
INTELLIGENT SYSTEMS	
Georgiev A.F., Nikulin D.S. , Verzilin S.S. The algorithm of the utility for automated modeling of threaded connections in MSC Patran/Nastran.....	7
M. Kalimoldayev, M. Mansurova. Artificial Intelligence Development in Kazakhstan Over the Past Decade: A Comprehensive Review.....	15
DIGITALIZATION	
A. Kaltayev, Zh. Ualiev, A.Bibossinov. Modeling and Investigation of Hydrodynamics and Mass Transfer in Uranium Recovery in a Packed Ion-Exchange Column with a Conical Flow Distributor engineering	29
A.Sinchev, B.Sinchev, A.Chinchalinova, A.Ospanova. Distributed ai adaptation as a structural risk variable: From neural architectures to layered system design.....	53



А. Куришбаев,
академик, президент НАН РК

СТРАТЕГИЯ НАН РК В СФЕРЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА И ЦИФРОВОЙ ТРАНСФОРМАЦИИ

18 января 2026 года вступил в действие Закон РК «Об искусственном интеллекте». Искусственный интеллект (ИИ) все больше влияет на международные отношения, трансформируя практику взаимодействия. Мы видим, как ИИ меняет глобальную динамику, где технологическое мастерство в применении систем на основе ИИ-технологий будет способствовать или даже определять геополитическое положение.

Развитие национальной экосистемы ИИ сопровождается активным взаимодействием с международными организациями и стратегическими партнерами. В этом плане Казахстан демонстрирует открытость к сотрудничеству и стремится не просто следовать глобальным тенденциям, но и занимать активную позицию в формировании справедливых и взаимоприемлемых правил игры. Привлечение международных экспертов, развитие отечественных компетенций и создание благоприятных условий для инновационных решений формируют устойчивый фундамент для цифровой трансформации страны.

Так, **08.02.2026 года** при НАН РК был открыт **Казахстанско-Китайский центр науки и трансфера технологий**. На церемонии участвовали: Национальная академия наук Республики Казахстан при Президенте Республики Казахстан, академики Китайской академии наук (CAS, Китай), представители Чжэцзянского технологического университета, а также группа высокотехнологических компаний КНР.

Современные вызовы, такие как изменение климата, управление природными ресурсами, стихийные бедствия и цифровизация экономики, требуют инновационных подходов, основанных на искусственном интеллекте и анализе пространственно-временных

данных. Лаборатория станет центром передовых исследований, интегрируя новейшие технологии ИИ, дистанционного зондирования, геоинформационных систем и прогнозного моделирования.

Определены основные направления исследований Лаборатории:

- мониторинг и управление водными ресурсами с использованием ИИ и ГИС-технологий;
- разработка систем раннего предупреждения о стихийных бедствиях, таких как наводнения, оползни и снежные лавины;
- применение ИИ для анализа пространственно-временных данных, позволяющих прогнозировать изменения в окружающей среде;
- оптимизация энергетических ресурсов с помощью интеллектуальных систем распределения энергии;
- цифровизация сельского хозяйства и внедрение технологий «умного земледелия».

Создание Лаборатории позволит:

- выйти на передовые позиции в области научных исследований и технологических разработок;
- интегрировать международные научные достижения в систему национального устойчивого развития;
- повысить уровень подготовки отечественных специалистов в сфере ИИ и цифровых технологий;
- укрепить международное сотрудничество с ведущими научными центрами мира;
- внедрить инновационные решения для повышения устойчивости к природным катастрофам.

Проект создаст платформу для трансфера передовых технологий и знаний в области интеллектуальных систем для: логистики и транспорта; энергетики и энергосбережения; мониторинга стихийных бедствий и раннего предупреждения; анализа сельского хозяйства и принятия решений. Проект предоставит Казахстану возможность стать региональным лидером в области пространственно-временного анализа данных и устойчивого развития.

26.02.2026 года при НАН РК открылся **Казахстанско-Корейский центр AI SilkNet**. Это первый в стране национальный центр, который с помощью данных и искусственного интеллекта помогает прогнозировать развитие науки и технологий. Проект является совместной инициативой Национальной академии наук при Президенте Республики Казахстан и Корейского института научно-технической информации, призванной усилить роль науки как стратегического инструмента развития страны. Запуск AI SilkNet открывает новые возможности для внедрения передового международного опыта и станет интеллектуальным инструментом для формирования приоритетов научно-технологического развития во всех регионах Казахстана.

Сейчас Казахстан находится на переломном этапе, когда наука становится ключевым инструментом технологического суверенитета. AI SilkNet может стать стратегическим компасом для этого перехода. В долгосрочной перспективе цель — сделать AI SilkNet ведущим источником стратегической аналитики для всей Центральной Азии.

В рамках запуска Центра прошла стратегическая сессия. В ней приняли участие более 400 человек: ведущие учёные, представители министерств, а также вузов и научных институтов. На встрече обсуждались новые подходы к развитию науки и технологий в стране. Эксперты подчеркнули, что AI SilkNet станет основой для практической работы науки. Так, в рамках проекта впервые провели масштабную аналитику: собрали данные о проектах и программах с 2018 по 2025 год, проанализировали результаты отечественных исследований и публикаций, изучили международные тренды, чтобы видеть, как развивается наука в мире.

11 марта 2026 года Национальная академия наук Республики Казахстан при Президенте Республики Казахстан совместно с Институтом почвоведения Университета имени Лейбница (Ганновер, Германия) начали реализацию масштабного **международного проекта «ExSoil»**. В Алматы состоялось kick-off совещание, посвященное созданию региональной сети цифровой научно-информационной платформы **«ExSoil & Smart Agriculture»**, которая призвана стать фундаментом для устойчивого развития агропромышленного комплекса не только Казахстана, но и стран Центральной Азии и Монголии.

Соглашения о сотрудничестве в области инновационных проектов. Документ закрепил партнерство между двумя ведущими научными организациями: Национальная академия наук РК при Президенте РК и Институт почвоведения Университета имени Лейбница в Ганновере.

Соглашение предусматривает совместную работу и объединения усилия для повышения конкурентоспособности науки и инноваций, а также для создания благоприятных условий для реализации пилотных проектов в аграрном секторе.

Проект «ExSoil» (Empowering Soil Health – «Укрепление здоровья почв») является ответом на глобальные вызовы, такие как деградация земель, изменение климата и необходимость обеспечения продовольственной безопасности.

Инициатива поддержана и профинансирована *Федеральным министерством исследований, технологий и космоса Германии (BMFTI)*.

Казахстан выступает в роли главного координационного и методологического хаба. В дальнейшем сеть будет расширена на Кыргызстан, Узбекистан, Таджикистан и Монголию.

Центральным элементом проекта является создание инновационной цифровой научно-информационной платформы **«ExSoil & Smart Agriculture»**. Это не просто база данных, а комплексная экосистема для интеграции науки, технологий и реального сектора экономики.

Платформа обеспечит открытый доступ к следующим ресурсам:

- **Научно-исследовательские и аналитические данные:** Сбор актуальной информации о состоянии почв, уровне загрязнения и потенциале плодородия.
- **Методическая поддержка:** Разработка и публикация рекомендаций по применению био- и фиторемедиации, а также современных агротехнологий.
- **Единая цифровая среда:** Пространство для хранения данных, обмена знаниями и консультаций по внедрению инноваций в сельское хозяйство.

Проект направлен на формирование сети цифровых центров компетенций в области почвенного здоровья и агроэкологии. На базе Казахстанско-Немецкого центра НАН РК создается хаб, который будет координировать работу ученых всего региона. Проект уделяет особое внимание развитию человеческого капитала.

В рамках Соглашения предусмотрены:

- Программы обмена для студентов и ведущих ученых.
- Проведение научных семинаров, круглых столов и летних школ в регионах Казахстана.
- Обучение фермеров, представителей акиматов и государственных органов практическому применению цифровых решений в сельском хозяйстве.

Реализация инициативы «ExSoil & Smart Agriculture» позволит Казахстану достичь ряда важных целей:

1. Снижение деградации земель: Внедрение научно обоснованных методов восстановления почв.
2. Климатическая адаптация: Создание устойчивых агроландшафтов, способных противостоять изменениям климата.
3. Цифровизация АПК: Переход к «умному» сельскому хозяйству и повышение качества инвестиционного планирования.
4. Декарбонизация: Развитие углеродосберегающих технологий в агропромышленном комплексе.
5. Проект создает основу для формирования в Республике Казахстан опорного регионального научно-технологического и цифрового хаба, объединяющего Германию, Центральную Азию и Монголию для совместного решения глобальных аграрных задач.

В условиях растущей конкуренции стратегический подход к развитию ИИ и цифровизации в Казахстане открывает новые перспективы для международного сотрудничества. Ответственное использование этих технологий станет залогом успешного цифрового будущего страны, позволяя укрепить ее позиции в мировой повестке.

УДК 004.855.5

Георгиев А. Ф., Никулин Д. С.*, Верзилин С. С., 2026.
МГТУ им. Н. Э. Баумана, Москва, 105005, Российская Федерация
*E-mail: dan.nikulin279@gmail.com

АЛГОРИТМ РАБОТЫ УТИЛИТЫ ДЛЯ АВТОМАТИЗИРОВАННОГО МОДЕЛИРОВАНИЯ РЕЗЬБОВЫХ СОЕДИНЕНИЙ В MSC PATRAN/NASTRAN

Георгиев Александр Федорович, кандидат технических наук, доцент, факультет «Специальное машиностроение», кафедра «Аэрокосмические системы», МГТУ им. Н.Э. Баумана, Госпитальный переулок, д. 10, Москва, 105005, Российская Федерация.

E-mail: ageorgiev@bmstu.ru

Никулин Данил Сергеевич, выпускник МГТУ им. Н.Э. Баумана, факультет «Специальное машиностроение», кафедра «Аэрокосмические системы», Госпитальный переулок, д. 10, Москва, 105005, Российская Федерация.

E-mail: dan.nikulin279@gmail.com

Верзилин Станислав Сергеевич, выпускник МГТУ им. Н.Э. Баумана, факультет «Специальное машиностроение», кафедра «Аэрокосмические системы», Госпитальный переулок, д. 10, Москва, 105005, Российская Федерация.

E-mail: verzilin_s@mail.ru

Статья посвящена описанию методики моделирования резьбовых соединений в программном пакете MSC Patran/Nastran. Описан алгоритм разработки утилиты на языке программирования Patran Command Language (PCL). В результате применения утилиты продемонстрировано сокращение времени моделирования.

Ключевые слова: Patran Command Language, PCL, утилита в MSC Patran, моделирование резьбовых соединений, метод конечного элемента, болтовое соединение в MSC Patran.

Георгиев А. Ф., Никулин Д. С., Верзилин С. С., 2026.
МГТУ им. Н. Э. Баумана, Москва, 105005, Ресей Федерациясы
*E-mail: dan.nikulin279@gmail.com

MSC PATRAN/NASTRAN-ДА БҰРАНДАЛЫ ҚОСЫЛЫСТАРДЫ АВТОМАТТАНДЫРЫЛҒАН МОДЕЛЬДЕУГЕ АРНАЛҒАН УТИЛИТАНЫҢ ЖҰМЫС АЛГОРИТМІ

Георгиев Александр Федорович, техника ғылымдарының кандидаты, доценті. Н.Э. Бауман атындағы ММТУ "Арнайы машина жасау" факультеті, "Аэроғарыштық жүйелер" кафедрасы. Госпитальный түйік көшесі, 10 үй, Мәскеу, 105005, Ресей Федерациясы.

E-mail: ageorgiev@bmstu.ru

Никулин Данил Сергеевич, Н.Э. Бауман атындағы ММТУ түлегі, "Арнайы машина жасау" факультеті, "Аэроғарыштық жүйелер" кафедрасы, Госпитальный түйік көшесі, 10 үй, Мәскеу, 105005, Ресей Федерациясы.

E-mail: dan.nikulin279@gmail.com

Верзилин Станислав Сергеевич, Н.Э. Бауман атындағы ММТУ түлегі, "Арнайы машина жасау" факультеті, "Аэроғарыштық жүйелер" кафедрасы, Госпитальный түйік көшесі, 10 үй, Мәскеу, 105005, Ресей Федерациясы.

E-mail: verzilin_s@mail.ru

Мақала MSC patran / Nastran бағдарламалық пакетіндегі бұрандалы қосылыстарды модельдеу әдістемесін сипаттауға арналған. Patran Command Language (PCL) бағдарламалау тілінде утилитаны әзірлеу алгоритмі сипатталған. Утилитаны қолдану нәтижесінде модельдеу уақытының қысқаруы көрсетілді.

Түйін сөздер: Patran Command Language, PCL, MSC patran-дағы утилита, бұрандалы қосылыстарды модельдеу, соңғы элемент әдісі, MSC Patran-дағы болт байланысы.

Georgiev A. F., Nikulin D. S., Verzilin S. S., 2026.

Bauman Moscow State Technical University, Moscow, 105005, Russian Federation

*E-mail: dan.nikulin279@gmail.com

THE ALGORITHM OF THE UTILITY FOR AUTOMATED MODELING OF THREADED CONNECTIONS IN MSC PATRAN/NASTRAN

Georgiev Alexander Fedorovich, Candidate of Technical Sciences, Associate Professor, Bauman Moscow State Technical University, Faculty of Special Mechanical Engineering, Department of Aerospace Systems, 10 Hospitalny Lane, Moscow, 105005, Russian Federation.

E-mail: ageorgiev@bmstu.ru

Nikulin Danil Sergeevich, Graduate of Bauman Moscow State Technical University, Faculty of Special Mechanical Engineering, Department of Aerospace Systems, 10 Hospitalny Lane, Moscow, 105005, Russian Federation.

E-mail: dan.nikulin279@gmail.com

Verzilin Stanislav Sergeevich, Graduate of Bauman Moscow State Technical University, Faculty of Special Mechanical Engineering, Department of Aerospace Systems, 10 Hospitalny Lane, Moscow, 105005, Russian Federation.

E-mail: verzilin_s@mail.ru

The article describes the methodology for modeling threaded connections in the MSC Patran/Nastran software package. An algorithm for developing a utility in the Patran Command Language (PCL) programming language is described. As a result of using the utility, a reduction in simulation time has been demonstrated.

Keywords: Patran Command Language, PCL, utility in MSC Patran, threaded connection modeling, finite element method, bolted connection in MSC Patran.

Введение

Резьбовые соединения стали неотъемлемой частью современных изделий во всех отраслях промышленности. Число соединений в изделии может достигать сотен или даже тысяч. Для всех типов соединений существует риск разрушения. Резьбовые соединения не являются исключением. Поэтому высокое значение имеет задача моделирования [1] болтовых и винтовых соединений, особенно для трубопроводов, пневматических и гидравлических систем [2], где требуется обеспечить герметичность, рисунок 1.



Рисунок 1 – Использование резьбовых соединений в трубопроводах

Для увеличения производительности труда инженеров при выполнении расчетов и моделировании разработана утилита для автоматизации процесса создания резьбовых соединений в программном пакете MSC Patran/Nastran.

Цель работы – представить описание алгоритмов, заложенных в дополнительную утилиту (модуль) к программе конечно-элементного моделирования (КЭМ) MSC Patran/Nastran.

Практическое применение утилиты в инженерных расчетах сократит время выполнения расчетов в 6 раз.

Объект моделирования

В работе рассматривается три основных вида резьбовых соединений, показанных на рисунке 2: шпильчатое, болтовое и винтовые соединения.




Рисунок 2 – Виды резьбовых соединений

Согласно [3], как правило, раньше разрушается болт, а не гайка. В MSC Patran/Nastran крепежные элементы создаются с помощью объекта *Connector* типа *Fastener* [4]. При таком моделировании накладывается условие на более высокую жесткость соединения, по сравнению со всей конструкцией. Алгоритм разработанной утилиты уже содержит требование учитывать это явление.

Принятые допущения

Для моделирования болтовых и винтовых соединений выбран 1D элемент типа *Beam* [5]. Это позволяет определять изгибные напряжения крепежного элемента. Ниже приводятся допущения, принятые при моделировании:

- недеформируемость отверстий соединяемых деталей (вся нагрузка распределяется на стержень крепежного элемента, что увеличивает запас при расчете прочности самого болта или винта);
- жесткая связь крепежного элемента с деталью (гайка, головка болта в случае болтового соединения и головка винта в случае винтового соединения принимаются недеформируемыми и абсолютно жесткими).

В результате расчетов напряжения возможно определить только в 1D *Beam* элементах, то есть в самом стержне крепежного элемента.

Методика моделирования

Методика основана на методе предложенном в [6].

В первую очередь создается геометрия стержня крепежного элемента. С помощью опции *Create/Point/Arccenter* создаются две точки *Point 1* и *Point 2* на основе кривых *Edge 1* и *Edge 2* соответственно. Далее с помощью опции *Create/Curve* создается прямая *Curve 1* на основе выбора, созданных точек *Point 1* и *Point 2*, рисунок 3.




Рисунок 3 – Создание геометрии для стержня болта или винта

На следующем этапе создаются списки узлов КЭ сетки, ассоциированных с внутренними цилиндрическими поверхностями каждой детали *Face 1* и *Face 2*. Если моделируется соединение с зазором, то в качестве объектов, на основе которых создаются списки узлов, выбирается *Edge 1* и *Edge 2*. Важно, что в этом случае выбирается вся кромка отверстия для каждой из деталей. Схема приведена на рисунке 4.




Рисунок 4 – Выбор поверхностей для создания списков узлов

На основе созданных списков узлов и принятых допущений создаются элементы *MPC1* и *MPC2* типа *RBE2*. Тип *RBE2* выбирается из допущения об абсолютной жесткости и недеформируемости торцов. Схема показана на рисунке 5.




Рисунок 5 – Создание MPC элементов

Общая схема резьбового соединения приведена на рисунке 6. Модель включает в себя 1D элементы типа Beam и две жесткие связи MPC1 и MPC2 типа RBE2.




Рисунок 6 – Общая схема болтового или винтового соединения

Алгоритм работы утилиты

Моделирование болтовых и винтовых соединений требует выполнения однообразных действий. Использование утилиты упрощает и ускоряет процесс создания конечно-элементной модели крепежных соединений.

Для написания утилиты использован специальный язык программирования MSC Patran – Patran Command Language (PCL), который уже содержит стандартные функции [7,8] для программной разработки утилит, позволяющих автоматизировать выполнение различных задач. Сам язык построен с применением принципов объектно-ориентированного программирования (ООП) – создаются классы и функции, которые применяются к конкретным объектам.

Для корректной работы утилиты и удобной работы с ней создается два класса: *CLASS form_create_bolts* – в нем содержится основной программный код утилиты, *CLASS bolts* – добавляет разработанную утилиту в основное меню MSC Patran. Для корректной работы утилиты важно,

чтобы созданные классы находились в корневой папке MSC Patran или оставались в рабочей папке, в которой пользователь работает с моделью.

На основании методики моделирования было принято, что для сведения затрат по моделированию резьбовых соединений к минимуму требуется выбрать 4 объекта. *Edge 1, Edge 2, Face 1, Face 2*, а также установить значение *Number of Elements* – количество *Beam*-элементов, на которые будет разбита прямая *Curve 1* и указать наименование группы *Group Name*, в которую будут помещены элементы, созданные в результате работы утилиты. Важно отметить, что это группа должна быть заранее создана пользователем во вкладке *Group/Create*. Для удобства работы и отображения результатов рекомендуется создавать отдельную группу для каждого диаметра резьбовых соединений в конструкции.

Интерфейс утилиты показан на рисунке 7.

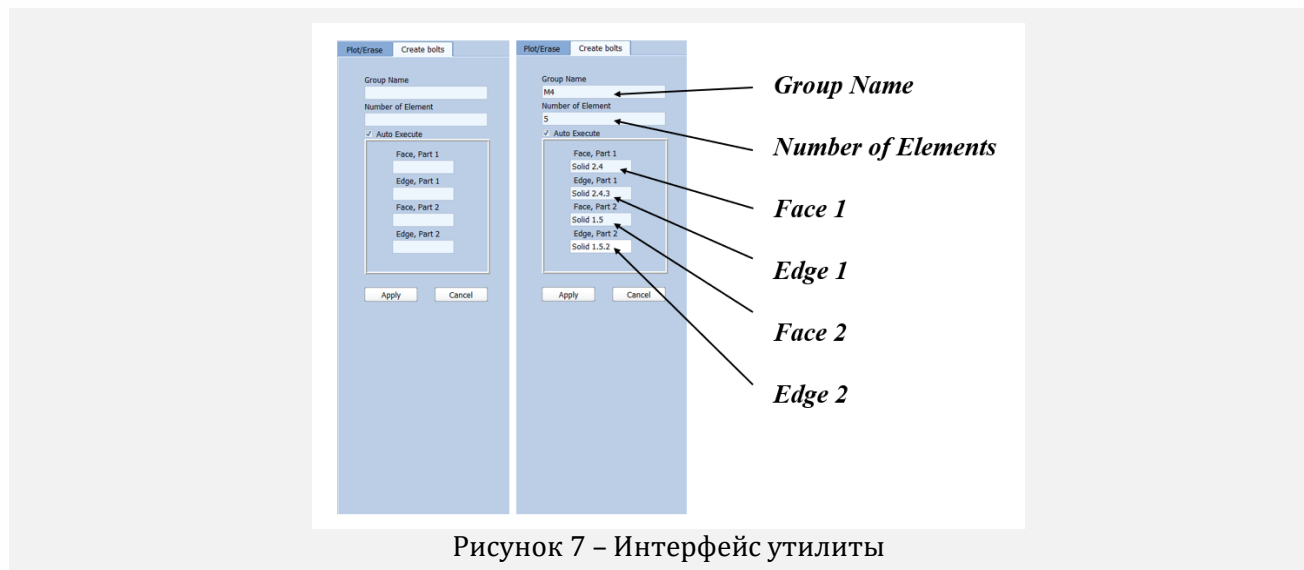


Рисунок 7 – Интерфейс утилиты

Поля ввода содержат внутренние программные ограничения, которые были добавлены при разработке утилиты. Ограничения сразу позволяют пользователю выбирать необходимые геометрические примитивы. Расширение *MESH_SWEEP* позволяет выбирать объекты типа *Face* и *Edge*. Это особенно важно при моделировании резьбовых соединений разных типов.

На рисунке 8 приводится схема алгоритма работы утилиты.

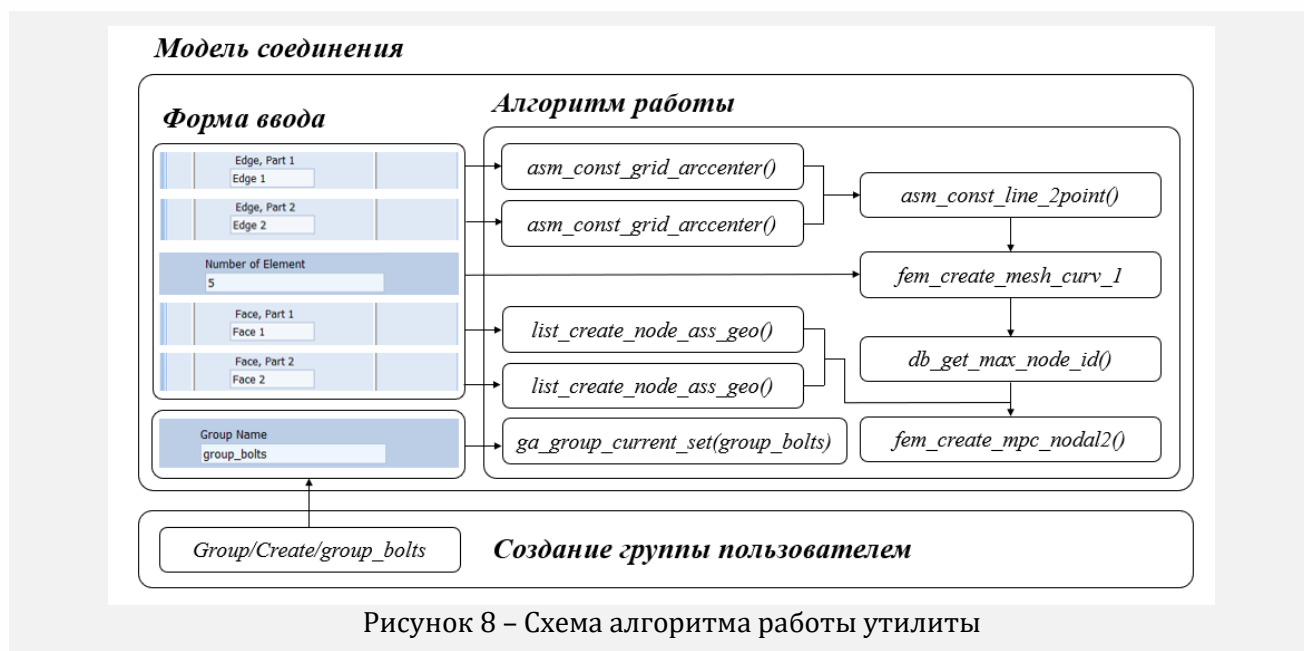


Рисунок 8 – Схема алгоритма работы утилиты

Заклучение

В рамках системы автоматизированного проектирования MSC Patran была разработана специализированная утилита, реализующая рассмотренные методику и алгоритм моделирования резьбовых соединений. Ключевым преимуществом описанной утилиты является возможность создания конечно-элементных моделей крепежа для деталей, представленных как объемными, так и поверхностными КЭ.

Апробация утилиты выполнена на примере создания расчетной КЭ-модели типового фланцевого соединения трубопровода (Flange 1, Flange 2), широко распространенного в технике (рисунок 9). Внедрение методики позволило сократить трудоемкость процесса моделирования: время разработки КЭ-модели уменьшилось в 6 раз – с 1 часа до 10 минут.




Рисунок 9 – Общий вид фланцевого соединения с крепежными элементами

Таким образом, автоматизация процесса моделирования резьбовых соединений посредством разработанной утилиты способствует значительному повышению эффективности проектно-конструкторских работ. Сокращение временных затрат открывает возможность для анализа большего числа конструктивных альтернатив на стадии проектирования, что в конечном итоге ведет к оптимизации массогабаритных характеристик и повышению надежности разрабатываемых изделий.

Литература

- 1 Vilela P. M. L., Carvalho H., Filhob O. T. B. Numerical simulation of bolted connections. Latin American Journal of Solids and Structures, № 15, 2018, 15 p.
- 2 Шатров А.К., Назарова Л.П., Машуков А.В. Механические устройства космических аппаратов. Конструктивные решения и динамические характеристики. Красноярск, СибГАУ, 2006, 84 с.
- 3 Биргер И.А., Шорр Б.Ф., Иосилевич Г.Б. Расчет на прочность деталей машин. Москва, Машиностроение, 1979, 639 с.
- 4 MSC PATRAN Quick User Guide.
- 5 MSC/NASTRAN 120 Exercise Workbook – Version 70 (MSC/PATRAN 7.5)
- 6 Титаренко Ф.В. Оптимальная расчетная конечно-элементная модель. Способы соединения частей КЭ модели: журнал CADMASTER №1, 2021.– 6 с.
- 7 PATRAN 2021.2 PCL and Customization.
- 8 PATRAN 2021.4 PCL Reference Manual. Vol. 1: Function Descriptions.

- 9 PATRAN 2020 PCL Reference Manual. Vol. 2: Code Examples.
- 10 PATRAN 304 Exercise Workbook. Properties Form. EXERCISE 14.
- 11 PATRAN 304 Exercise Workbook. Mesh Lug Model. EXERCISE 5.

References

- 1 Vilela P. M. L., Carvalho H., Filhob O. T. B. Numerical simulation of bolted connections. Latin American Journal of Solids and Structures, № 15, 2018, 15 p.
- 2 Shatrov A.K., Nazarova L.P., Mashukov A.V. Mekhanicheskie ustroystva kosmicheskikh apparatov. Konstruktivnye resheniya i dinamicheskie kharakteristiki [Mechanical devices of spacecraft. Design solutions and dynamic characteristics]. Krasnoyarsk, SibGAU Publ., 2006, 84 p. [in Russian].
- 3 Birger I.A., Shorr B.F., Iosilevich G.B. Raschet na prochnost detaley mashin [Strength calculation of the machine parts]. Moscow, Mashinostroenie Publ., 1979, 639 p. [in Russian].
- 4 MSC PATRAN Quick User Guide.
- 5 MSC/NASTRAN 120 Exercise Workbook - Version 70 (MSC/PATRAN 7.5)
- 6 Titarenko F.V. The optimal computational finite element model. Ways to connect parts of the CE model: CADMASTER magazine No. 1, 2021. [in Russian].
- 7 PATRAN 2021.2 PCL and Customization.
- 8 PATRAN 2021.4 PCL Reference Manual. Vol. 1: Function Descriptions.
- 9 PATRAN 2020 PCL Reference Manual. Vol. 2: Code Examples.
- 10 PATRAN 304 Exercise Workbook. Properties Form. EXERCISE 14.
- 11 PATRAN 304 Exercise Workbook. Mesh Lug Model. EXERCISE 5.

УДК 00.1082

Maksat Kalimoldayev^{*1}, Madina Mansurova², 2026.¹*Institute of Information and Computer Technologies National Academy of Sciences of the Republic of Kazakhstan, Almaty, Kazakhstan*²*Al-Farabi Kazakh National University, Almaty, Kazakhstan***E-mail:mnk@ipic.kz***ARTIFICIAL INTELLIGENCE DEVELOPMENT IN KAZAKHSTAN OVER THE PAST DECADE:
A COMPREHENSIVE REVIEW**

Kalimoldaev Maksat, Doctor of Physics and Mathematics, Professor, Honorary Academician of the National Academy of Sciences of the Republic of Kazakhstan under the President of the Republic of Kazakhstan, Advisor to the Director General, Head of the Laboratory, Institute of Information and Computer Technologies, Almaty, Kazakhstan.

E-mail: mnk@ipic.kz; <https://orcid.org/0000-0003-0025-8880>

Mansurova Madina, head of the Department of artificial intelligence and big data, professor of the Al-Farabi Kazakh National University.

E-mail: madina.mansurova@kaznu.edu.kz ; <https://orcid.org/0000-0002-9680-2758>

Abstract. Artificial intelligence's influence on society has never been more pronounced. Often described as a new wave of industrial transformation following the internet, AI is reshaping economies, public services, and everyday life worldwide. Positioned at the crossroads of Eurasia, Kazakhstan has set an ambitious goal to leverage AI as a core enabler of a fully digitalized society. In this context, this paper provides a comprehensive, evidence-oriented review of the current state of AI development in Kazakhstan, informed by global trends in expanding AI capabilities, declining deployment costs, rising adoption, and growing emphasis on governance and responsible use. The analysis is aligned with Kazakhstan's national AI development concept for 2024-2029, which prioritizes data management, infrastructure development, human capital, research and development including language technologies, and regulatory frameworks, and it uses these priorities to structure the evidence and highlight practical pathways for implementation and measurable progress.

Keywords: artificial intelligence, digital society, research, technology, infrastructure.**Conflict of interest:** The authors declare that there is no conflict of interest.**М.Н. Калимолдаев^{1*}, М.Е. Мансурова², 2026.**¹*Ақпараттық және есептеу технологиялар институты, Алматы, Қазақстан*²*Әл-Фараби атындағы Қазақ ұлттық университеті, Алматы, Қазақстан***E-mail:mnk@ipic.kz***СОҢҒЫ ОН ЖЫЛДЫҚТА ҚАЗАҚСТАНДА ЖАСАНДЫ ИНТЕЛЛЕКТІҢ ДАМУЫ:
КЕШЕНДІ ШОЛУ**

Мақсат Нұрәділұлы Калимолдаев, профессор, ф.-м. ғ. д., Ақпараттық және есептеу технологиялар институтының Бас директорының кеңесшісі, зертхана меңгерушісі, Қазақстан Республикасы Ұлттық ғылым академиясының құрметті академигі.

E-mail:mnk@ipic.kz; <https://orcid.org/0000-0003-0025-8880>

Мадина Есімханқызы Мансурова, Жасанды интеллект және үлкен деректер кафедрасының меңгерушісі, Әл-Фараби атындағы Қазақ ұлттық университетінің профессоры.

E-mail: madina.mansurova@kaznu.edu.kz; <https://orcid.org/0000-0002-9680-2758>

Аннотация. Жасанды интеллекттің қоғамға әсері ешқашан байқалмады. Жасанды интеллект көбінесе Интернеттен кейінгі өнеркәсіптік өзгерістердің жаңа толқыны деп аталады, бүкіл әлемдегі экономиканы, мемлекеттік қызметтерді және күнделікті өмірді өзгертеді. Еуразия қиылысында орналасқан Қазақстан өзінің алдына жасанды интеллектті (ЖИ) толық цифрлық қоғам құрудың негізгі құралы ретінде пайдалану мақсатын қойды. Осы тұрғыда бұл құжат Қазақстандағы ЖИ дамуының ағымдағы жай-күйіне жан-жақты, нақты деректерге бағдарланған шолу болып табылады, ол ЖИ мүмкіндіктерін кеңейтудегі жаһандық үрдістерге, енгізу шығындарын төмендетуге, енгізуді ұлғайтуға және басқаруға және жауапты пайдалануға өсіп келе жатқан назарға негізделген. Талдау Қазақстанның жасанды интеллектін дамытудың 2024-2029 жылдарға арналған ұлттық тұжырымдамасымен келісілген, онда деректерді басқару, инфрақұрылымды дамыту, адами капитал, тілдік технологияларды қоса алғанда, зерттеулер мен әзірлемелер және нормативтік-құқықтық база басым болып табылады және бұл басымдықтар нақты деректерді құрылымдау және енгізудің практикалық жолдары мен өлшенетін прогресті айқындау үшін пайдаланылады.

Түйін сөздер: жасанды интеллект, цифрлық қоғам, зерттеу, технология, инфрақұрылым.

Мүдделер қақтығысы: авторлар мүдделер қақтығысының жоқтығын мәлімдейді.

М.Н. Калимолдаев*¹, М.Мансурова², 2026.

¹Институт информационных и компьютерных технологий, Алматы, Казахстан

²Казахский национальный университет имени аль-Фараби, Алматы, Казахстан

РАЗВИТИЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В КАЗАХСТАНЕ ЗА ПОСЛЕДНЕЕ ДЕСЯТИЛЕТИЕ: ВСЕСТОРОННИЙ ОБЗОР

Калимолдаев Мақсат Нүрәділұлы, д. ф.-м.н., профессор, почетный академик НАН РК при Президенте |РК, советник Генерального директора, заведующий лабораторией, Институт информационных и компьютерных технологий, Алматы, Казахстан.
E-mail: mnk@ipic.kz; <https://orcid.org/0000-0003-0025-8880>

Мансурова Мадина Есімханқызы, к.ф.-м.н., профессор, заведующая кафедрой искусственного интеллекта и больших данных, Казахский национальный университет имени аль-Фараби, Алматы, Казахстан.
E-mail: madina.mansurova@kaznu.edu.kz ; <https://orcid.org/0000-0002-9680-2758>

Аннотация. Влияние искусственного интеллекта на общество еще никогда не было таким заметным. Искусственный интеллект, который часто называют новой волной промышленных преобразований, происходящих вслед за Интернетом, меняет экономику, общественные услуги и повседневную жизнь по всему миру. Расположенный на перекрестке Евразии, Казахстан поставил перед собой амбициозную цель – использовать искусственный интеллект (ИИ) в качестве основного средства создания полностью цифрового общества. В этом контексте данный документ представляет собой всеобъемлющий, ориентированный на фактические данные обзор текущего состояния развития ИИ в Казахстане, основанный на глобальных тенденциях в расширении возможностей ИИ, снижении затрат на внедрение, росте внедрения и растущем внимании к управлению и ответственному использованию.

Анализ согласован с Национальной концепцией развития искусственного интеллекта Казахстана на 2024-2029 годы, в которой приоритетными являются управление данными, развитие инфраструктуры, человеческий капитал, исследования и разработки, включая языковые технологии, и нормативно-правовая база, и эти

приоритеты используются для структурирования фактических данных и определения практических путей внедрения и измеримого прогресса.

Ключевые слова: искусственный интеллект, цифровое общество, исследование, технологии, инфраструктура.

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

Introduction

Artificial intelligence (AI) has progressed from early conceptual foundations, such as McCulloch and Pitts’ neuron-inspired model [1] and Turing’s proposal for evaluating machine intelligence [2], into today’s data-driven era enabled by backpropagation [3], deep convolutional networks [4], and transformer architectures [5] that underpin modern foundation models. This transition has moved AI from research prototypes to large-scale public adoption with unprecedented speed. Widely reported adoption figures illustrate this shift: ChatGPT reached 100 million users in roughly two months, whereas YouTube required about 1.5 years to reach a similar milestone [6], highlighting how rapidly generative AI systems can diffuse once the enabling infrastructure and product interfaces mature.

Similarly, AI research in Kazakhstan is increasingly aligned with the global mainstream. The local ecosystem has moved from primarily using widely adopted transformer-based methods to developing nationally relevant large language models, including KazLLM [7] and the AlemLLM [8], alongside a growing body of applied research. This growth is also reflected in publication volume: Kazakhstan’s AI-related research output has expanded sharply over the past two decades, rising from single-digit annual counts around 2000 to well over a thousand papers by 2023 (Fig. 1). In parallel, Kazakhstan has articulated an ambition to position AI as a key component of a fully digitalized society [9].

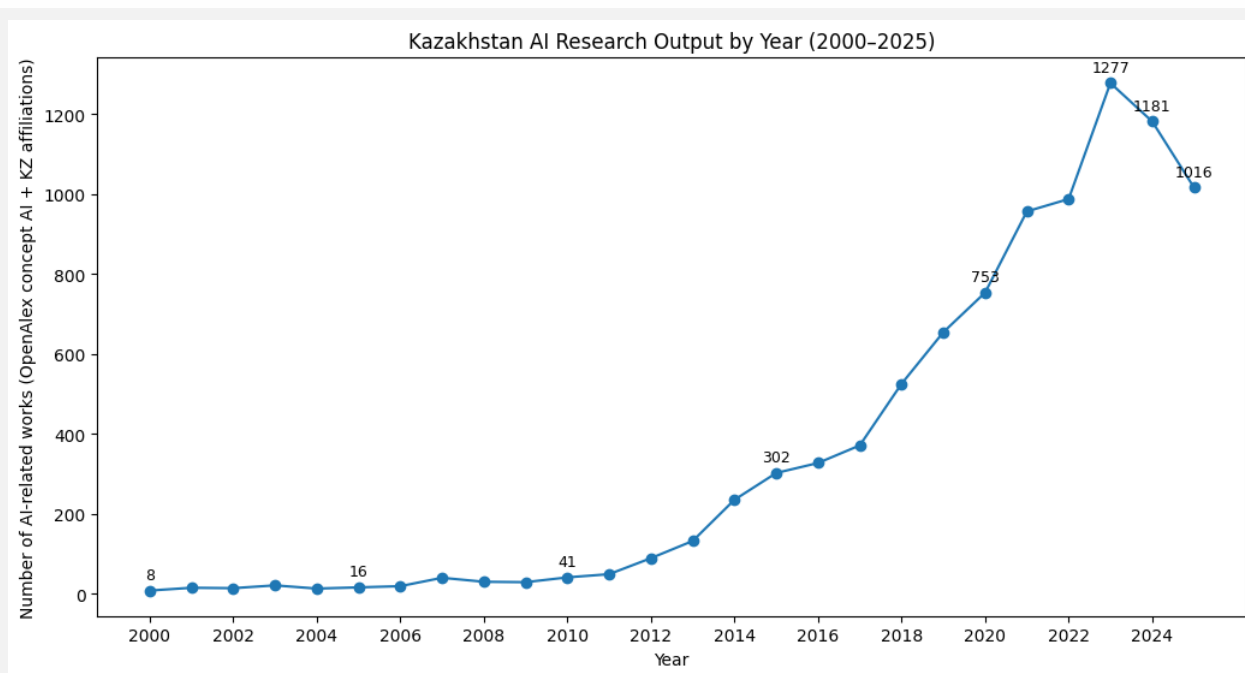


Fig. 1. Kazakhstan AI research output by year (2000–2025), measured as the annual count of AI-related works in OpenAlex with at least one author affiliated with an institution in Kazakhstan

Beyond research, AI is already being operationalized across major economic sectors, with a clear emphasis on measurable industrial impact. For example, Samruk-Kazyna reports implementing 62 AI-based projects, with a primary focus on production processes and an expected cumulative effect exceeding \$1.3 billion over five years [10]. For 2026, portfolio companies have been assigned a KPI to increase EBITDA by 5% through the use of AI, and within two years it is planned to transition toward a model in which 70% of management decisions are

made with AI participation. Sectoral examples include KazMunayGas projects such as ABAI, where AI supports reservoir flooding management and recommends reservoir pressure actions to increase oil production, with a projected economic effect of about 326 billion tenge over 2025 to 2030 [11]. Additional initiatives include AI-based forecasting of deficits and surpluses of petroleum products to stabilize regional supply, with an expected economic effect of 22.5 billion tenge. In the energy sector, predictive defect detection systems are being introduced at GRES-1 and AIES to improve equipment reliability and reduce downtime, with a projected economic effect of about 36 billion tenge for 2026 to 2030. AI is also being used to forecast renewable energy generation based on internal meteorological services.

These deployments are supported by expanding compute and data infrastructure and by a large-scale human capital agenda. Samruk-Kazyna indicates that its AI projects are implemented within a closed circuit on the AI FARABIUM supercomputer operated by Kazakhtelecom, with a portion of capacity used by the group and the remainder leased to commercial customers, including abroad [12]. Parallel to this, market projections suggest growth in Kazakhstan’s data centre sector, with revenue expected to rise toward roughly \$417 million by 2028 [13]. On the workforce side, Kazakhstan is scaling AI literacy through the AI Movement initiative, reporting more than 400,000 people trained through programs such as AI-Sana, AI-Qyzmet, and AI-People, and launching AI-Corporate for major state holdings. The national goal is to train 1 million citizens in five years. In collaboration with the Ministry of Education, Day of AI content has also been introduced for primary school grades 1 to 4, with plans to expand across all grade levels [14]. AI-related applications are also emerging in construction through unified digital platforms for planning and tracking, and in agriculture and water management through satellite monitoring and digital optimization tools.

Motivated by this combination of rapid adoption, expanding research capacity, and cross-sector deployment, this paper reviews current AI development trends in Kazakhstan and discusses the country’s emerging large language model projects, focusing on ecosystem capabilities, constraints, and near-term directions for research and implementation.

Overview of current LLM trends

As illustrated in Table 1, modern large language models (LLMs) have demonstrated rapid performance gains alongside an unprecedented rise in computational demands [15]. This surge is driven by increasing model scales and the heightened complexity of training and deployment. We examine the evolution of these requirements across three key dimensions: model development, dataset expansion, and application-level requirements.

Table 1: Recent, vendor-reported benchmark results for popular LLMs across widely used evaluations (MMLU, GPQA, HumanEval, GSM8K, MATH, SWE-bench Verified, MMMU)

Model	MMLU	GPQA (Diamond)	HumanEval	GSM8K	MATH	SWE- bench Verified	MMMU
Claude 3.5 Sonnet	88.7	59.4	92.0	96.4	71.1	-	68.3
GPT-4.1	90.2	66.3	-	-	-	54.6	-
GPT-4o	88.7	53.6	90.2	-	76.6	33.2	69.1
Llama 3.1 405B Instruct	87.3	50.7	89.0	96.8	73.8	-	-
Gemini 2.5 Pro	-	-	-	-	-	63.8	-

Training costs have increased dramatically shown in Table 2, rising from less than one thousand dollars for early models such as the 2017 Transformer to tens or even hundreds of millions for state-of-the-art systems [16]. Despite continuous efficiency improvements, overall

resource needs remain high because frontier training increasingly relies on longer training runs, higher-quality data, larger context windows, and more complex training objectives, for example, the multi-stage post-training, tool-use, and multimodal alignment. Contemporary training typically unfolds in two phases: a pretraining stage using vast corpora that can exceed one trillion tokens, followed by instruction tuning, in many cases, preference optimization to align the model with downstream tasks and user intent [15]. This tuning process depends on large volumes of curated prompts and expert-annotated data, adding additional compute and data-engineering cost.

Table 2: The demand for computing resources is growing rapidly

Model	Parameters (B)	Training Tokens (T)	Compute Cost (\$M)	GPU Count (est.)	Year	Notable Features
BERT-Large	0.34	0.003	<1	<100	2018	Baseline transformer
GPT-3	175	0.3	10–20	10,000	2020	Few-shot learning
PaLM	540	0.78	Unknown	6,144 TPUs	2022	Massive scale, Pathways system
Chinchilla	70	1.4	Unknown	Unknown	2022	Data-efficiency focus
PaLM 2	340	3.6	Unknown	Unknown	2023	Compute-optimal design
GPT-4 (est.)	1700	Unknown				

At the same time, the field is shifting from “bigger models only” toward a more nuanced scaling strategy: compute-optimal training, data-quality and system-level scaling [18]. Multilingual and domain-specific modeling increases dataset diversity requirements, while multimodal training compounds cost by adding vision encoders, richer inputs, and heavier preprocessing. As a result, data pipelines have become a core competitive advantage: large-scale training increasingly depends on efficient tokenization, sharding, streaming, dynamic batching, and careful dataset mixing to maintain stable training and avoid wasted compute.

Once the challenges associated with large model architectures are addressed, the next critical focus shifts to ensuring data efficiency. Table 3 provides an overview of the number of tokens used during the pretraining phase of various large language models. From an infrastructure perspective, managing training with datasets at the scale of trillions of tokens requires highly optimized data pipelines [19]. This includes the use of memory-mapped files, efficient tokenization, dynamic shuffling, and parallel data loaders. Even the process of reading and streaming such massive datasets consumes a substantial amount of GPU time. As training objectives grow more diverse and context-aware, the demands on preprocessing and I/O systems continue to increase accordingly.

Table 3 The number of tokens used in pre-training stage of popular LLMs

MODEL	TOKENS (B)
BERT-LARGE	3.0 billion
GPT-3	300.0 billion
PALM	780.0 billion
CHINCHILLA	1400.0 billion
PALM 2	3600.0 billion
GPT-4 (EST.)	Unknown
GEMINI ULTRA (EST.)	Unknown

Inference has emerged as a dominant driver of computational and economic constraints in modern LLM deployments. In many production settings, the marginal cost of serving large models at scale can rival or exceed the original training expenditure, particularly for applications with large user populations and stringent latency requirements [20]. This has intensified the focus on inference efficiency through model- and system-level techniques, including smaller and task-specialized models, low-precision quantization (for example 8-bit and 4-bit), knowledge distillation, kernel and runtime optimizations, batching strategies, speculative decoding, and memory-efficient attention mechanisms. In parallel, contemporary deployments increasingly favor compound architectures over single-pass model invocation. Retrieval-Augmented Generation pipelines typically integrate retrieval, optional re-ranking, and generation. Tool-augmented agentic systems introduce function calling, iterative planning loops, and external API interactions. Safety layers add moderation, policy enforcement, and compliance checks. Each added component increases end-to-end compute per query, making holistic pipeline optimization and robust GPU scheduling central to reliable and cost-effective deployment.

Post-training alignment has become a core stage of the LLM lifecycle. Methods such as reinforcement learning from human feedback [21] and preference optimization [22], including direct preference optimization variants, improve helpfulness, controllability, and safety. However, they introduce additional iterative training cycles, auxiliary models such as reward or preference models, and substantial evaluation infrastructure. Governance and responsible deployment have also shifted from broad principles to operational constraints. As a result, organizations invest in standardized evaluation suites, red-teaming protocols, dataset documentation, privacy-preserving controls, and traceability mechanisms. The field's trajectory is no longer defined solely by scaling parameter counts. It increasingly reflects the scaling of full systems, including data pipelines, context length, multimodal inputs, tool use, and rigorous alignment and evaluation, under strong pressure to reduce both training and inference costs.

Beyond training-centric scaling, several broader trends have shaped the LLM landscape and help explain the rapid acceleration of adoption. Deep learning moved from research to mainstream production as advances in representation learning and GPU availability enabled strong performance in vision, speech, and recommendation systems before LLMs became dominant. This period consolidated the foundation-model paradigm, in which large pretrained models are adapted to many tasks through prompting, fine-tuning, or parameter-efficient adapters, reducing the need to train narrowly specialized models from scratch. Open-source ecosystems also expanded rapidly, lowering barriers by releasing checkpoints, training recipes, and optimized inference runtimes. This enabled universities and mid-sized organizations to experiment with modern architectures under limited resources. Cloud computing and managed AI platforms further simplified access to accelerators and deployment via APIs, while simultaneously reinforcing hybrid strategies in which sensitive data, regulation, and governance constraints motivate on-premise or sovereign deployments.

A further shift has been the move from language modeling as an isolated capability to system-level intelligence as a deployment reality. In practice, LLMs increasingly serve as orchestrators embedded within larger workflows [23]. They call tools, query databases, retrieve and synthesize documents, generate structured outputs, and interact with enterprise software. This agentic direction has been strengthened by advances in function calling, structured prompting, and planning-oriented methods, as well as by the widespread adoption of Retrieval-Augmented Generation for grounding outputs in verifiable knowledge. In parallel, multimodality has become increasingly central, as modern systems combine text with images, audio, and video to support richer interfaces such as voice assistants, document understanding, and multimodal search. Context windows have expanded to support long-document processing and multi-step tasks, but this increases memory pressure and latency, motivating continued research in efficient attention, long-context training, and inference optimization.

In deployment practice, cost, reliability, and privacy requirements have driven a bifurcation of the model ecosystem. On one side are smaller enterprise and edge models optimized for latency, operational cost, and data locality. On the other are frontier-scale models

optimized for maximal capability. This bifurcation is sustained by rapid progress in compression and efficiency methods, including quantization, distillation, sparsity, kernel fusion, and hardware-aware compilation, as well as architectural approaches such as mixture-of-experts that can increase capability without proportionally increasing inference cost for every token. At the same time, evaluation has become a first-class engineering requirement. Organizations increasingly rely on standardized benchmarks, domain-specific test suites, and continuous monitoring to detect regressions, hallucinations, bias, and safety failures. Responsible AI has also matured into operational practice, with stronger emphasis on data provenance, privacy protection, documentation, auditability, and risk management, particularly in regulated domains including healthcare, finance, and public services.

Against this global backdrop, Kazakhstan's LLM ecosystem can be characterized by increasing visibility, openness, and end-to-end completeness. A notable shift has occurred from research outputs remaining confined to internal reports or closed pilots toward publishing models, datasets, and evaluation artifacts in open ecosystems. This transition is consequential because it transforms isolated efforts into a cumulative ecosystem. Shared baselines, replicable results, and accessible artifacts enable faster iteration and more credible scientific comparison across institutions and projects.

One representative entry point is the machine learning community, the repository of kx-transformers [24] on Hugging Face is one example, which functions as an open repository of checkpoints, datasets, and demonstration spaces that lower the friction of experimentation and replication. The output is not restricted to a single direction. It includes foundational components, practical utilities, and benchmarking-oriented resources that collectively support incremental community progress. Such public, iterative release practices establish shared reference points that future work can systematically improve upon.

Building on this community-level momentum, institutional-scale efforts provide evidence of capacity to manage the full lifecycle of foundation-model development. In this context, ISSAI's KazLLM [7] is notable not merely as a larger model release, but as an indicator of growing capability to curate and clean large corpora, coordinate compute-intensive training, and package artifacts for public use. The significance lies in what this infrastructure enables next. Once a national-scale model exists, research can accelerate toward systematic evaluation, alignment, domain specialization, and application development without repeatedly reconstructing the entire pipeline.

As artifacts proliferate, the credibility of progress increasingly depends on evaluation practices that are transparent and reproducible [25]. The growing attention to benchmarks, leaderboards, and structured evaluation spaces is therefore a critical signal of ecosystem maturation. By emphasizing comparative measurement and repeatable testing, these efforts align Kazakhstan's trajectory with global norms in which models are accompanied by evaluation infrastructure that makes claims scientifically interpretable and practically actionable.

Finally, Kazakhstan's trajectory should be situated within the broader international research network that shapes contemporary AI. This framing reinforces the interpretation that Kazakhstan's ecosystem is increasingly integrated into global flows of methods, tooling, and collaboration. Overall, the emerging picture is not only of increased model production, but of a more complete modern AI pipeline spanning data, training, evaluation, multimodality, and deployment practices.

Project context and implementation case

After outlining global AI developments and Kazakhstan's national priorities, we introduce the program-targeted project "Creating a Large Language Model (LLM) to Support the Kazakh Language and Technological Progress" as a concrete case study. Designed as a three-year effort, the project aims to develop a modern LLM that strengthens Kazakh as the state language and a language of intercultural communication, while also supporting technological innovation, data security, education, and scientific research in Kazakhstan.

In general, progress in model capability is driven by three interacting factors: data, model scale and architecture, and algorithms. For Kazakh, data is the dominant constraint. As a low-

resource language, Kazakh occupies only a tiny fraction of online text, and until recently it was barely represented in the pretraining corpora of many widely used foundation models such as LLAMA 2 [26] shown in Figure 2.

Language	Percent	Language	Percent
en	89.70%	uk	0.07%
unknown	8.38%	ko	0.06%
de	0.17%	ca	0.04%
fr	0.16%	sr	0.04%
sv	0.15%	id	0.03%
zh	0.13%	cs	0.03%
es	0.13%	fi	0.03%
ru	0.13%	hu	0.03%
nl	0.12%	no	0.03%
it	0.11%	ro	0.03%
ja	0.10%	bg	0.02%
pl	0.09%	da	0.02%
pt	0.09%	sl	0.01%
vi	0.08%	hr	0.01%

Figure 2: Language distribution in pretraining data with percentage $\geq 0.005\%$ of meta LLAMA 2 in 2024.

As a result shown in table 4, many general-purpose LLMs show limited Kazakh understanding out of the box and require additional adaptation, such as targeted fine-tuning and instruction tuning, to perform reliably in Kazakh. This motivates the project's emphasis on building high-quality training data and ensuring that Kazakh is not treated as a marginal component in the model's learning process.

Table 4. Comparative performance and adaptability of popular LLMs for Kazakh language tasks.

Issue	GPT-4 (OpenAI)	LLaMA 3 (Meta AI)	DeepSeek	TinyLlama
Data scarcity (number of Kazakh tokens in training)	1.5B tokens (Kazakh < 0.1% of data)	600M tokens (limited support)	400M tokens (primary language: Chinese)	100M tokens
Translation quality (BLEU score for Kazakh)	32.1%	25.4%	20.2%	18.5%
Morphology and agglutination (suffix recognition accuracy, %)	78.2%	68.4%	65.1%	59.3%
Answer reliability (hallucination rate on factual data, %)	9.3%	15.7%	18.9%	22.5%
Customization availability (fine-tuning capability, % of full dataset)	0% (closed model)	100%	100%	100%

The project therefore focuses on expanding both the quantity and the quality of Kazakh-language resources. Existing assets such as the Kazakh National Corpus [28] provide an important foundation, but many of these resources were created for linguistic research and were not

designed for modern LLM training workflows. Today's LLM training typically involves two stages. The first is pretraining on large-scale, mostly unlabeled text to learn general language representations. The second is instruction tuning, where the model learns to follow user intent through instruction–response pairs, similar to teaching a student through examples. This second stage is especially important for real-world usefulness, because it trains the model not only to generate fluent text, but also to respond in a helpful, task-oriented way that matches everyday language use.

To produce instruction data that reflects real Kazakh usage rather than artificial patterns generated by models, the project relies on expert curation. In practice, this means that linguists and language specialists design instruction–response pairs that mirror natural Kazakh phrasing, cultural context, and expected answer styles. This work is supported by consortium partners, including the Akhmet Baitursynov Institute of Language Education and the Shaisultan Shayakhmetov National Scientific and Practical Center “Til-Qazyna.” In parallel, the project scales unlabeled data through large document digitization. Because Al-Farabi Kazakh National University maintains one of the largest university libraries in Central Asia, the project has digitized thousands of books using OCR [28] and is also processing large volumes of news and multimodal content. Both expert curation and large-scale digitization are time-consuming, but they create durable national assets that can support research and applications over the next decade.

If data is the fuel of AI, then the model is its engine. While today's frontier systems show improving support for low-resource languages, the situation was notably weaker only a few years ago, and relying solely on external models is not sufficient for strategic goals such as data sovereignty, education, and public-sector deployment. For this reason, the project trained a compact LLaMA 3 variant with 1.9 billion parameters using two 100 GB GPUs. The model was trained on a curated dataset compiled from KazNU's dissertation archives and enriched with instruction data authored by Kazakh language experts. This experience shows that even “compact” LLM development requires substantial computational resources when the goal is high-quality, domain-relevant performance.

Beyond data and base model training, algorithm has become a third critical pillar such as alignment [29]. A capable model with strong data coverage still needs reliable control so that its responses follow human intent, remain safe, and reflect social and cultural expectations. In modern LLM pipelines, this control layer is often built through reinforcement learning from human feedback [21] or related preference-optimization methods [22]. In the context of Kazakhstan, alignment is also about ensuring that the model's behavior matches local norms, educational requirements, and public-sector values. The human experts process reinforcement learning from human feedback is shown in Figure 3.

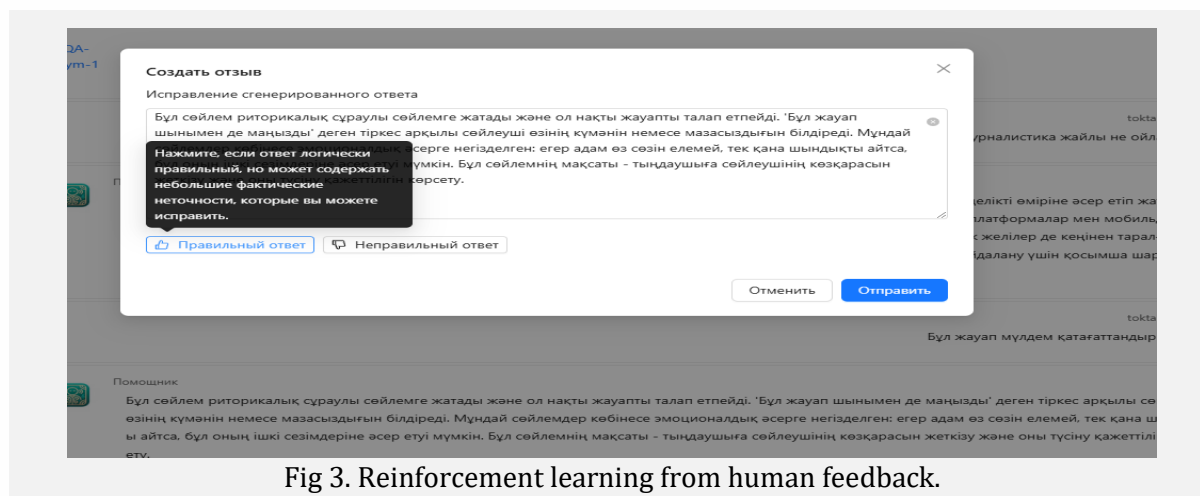


Fig 3. Reinforcement learning from human feedback.

After addressing alignment, the next major challenge is hallucination. In practice, hallucination occurs when a model produces fluent but unsupported statements, including

information that is inaccurate or does not exist. This behavior is strongly linked to the way standard LLMs generate responses: if the model answers directly from its internal parameters, it may rely on statistical associations rather than verifiable evidence. A common mitigation is to require the model to first retrieve relevant source material and then generate an answer grounded in that context. This is the core idea of Retrieval-Augmented Generation [30], whose workflow is illustrated in the corresponding figure 4.

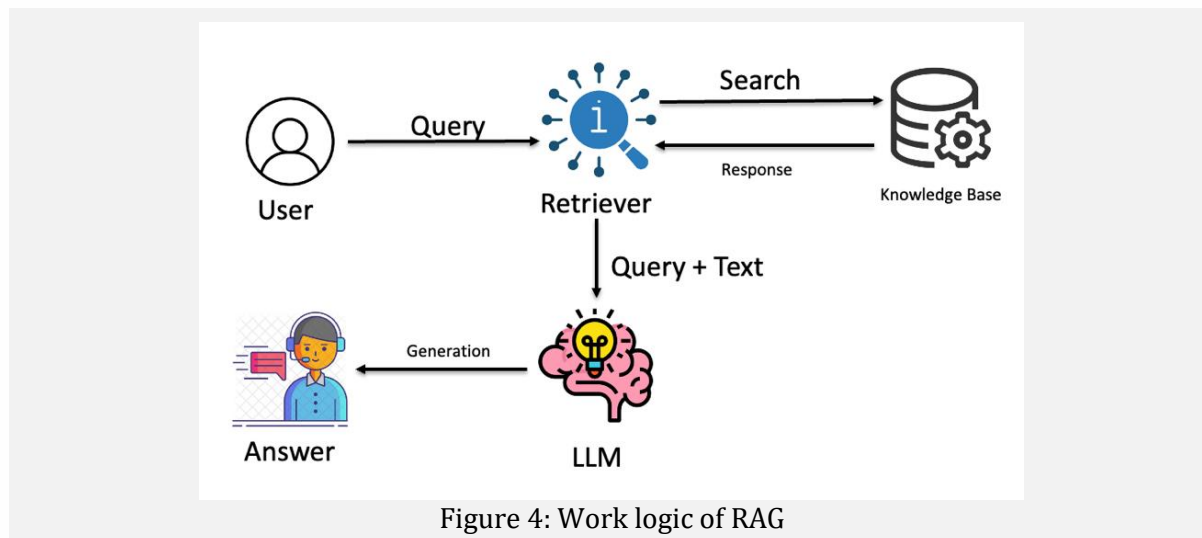


Figure 4: Work logic of RAG

Building on this foundation, real-world deployments have also been pursued across multiple domains. Two representative cases illustrate practical impact and implementation maturity: an admission-office assistant and a newsroom agent. The newsroom scenario aligns well with core LLM capabilities, since editorial workflows depend heavily on summarization, question answering, structured information extraction, and content drafting.

To improve usability under limited compute, parameter- and inference-efficient techniques were incorporated in a collaborative project titled “AI QazMedia,” conducted with the Faculty of Journalism in the AI Media Lab supported by LG Electronics Kazakhstan and focused on applications in media and communication science. In that study, the quantized model “issai/llama3.1-70b-GGUF4” was deployed as part of an AI assistant built on the open-source RAG platform RagFlow [31] as shown in Figure. Using the compressed GGUF4 format reduced inference-time GPU memory consumption by more than 70%, enabling deployment in resource-constrained settings. Whereas full-precision inference for a 70B-parameter model typically requires well over 100 GB of GPU memory, the quantized variant can operate effectively on a single 48 GB GPU, improving feasibility for both academic and production use. The underlying idea and system structure are summarized in the accompanying figure 5.

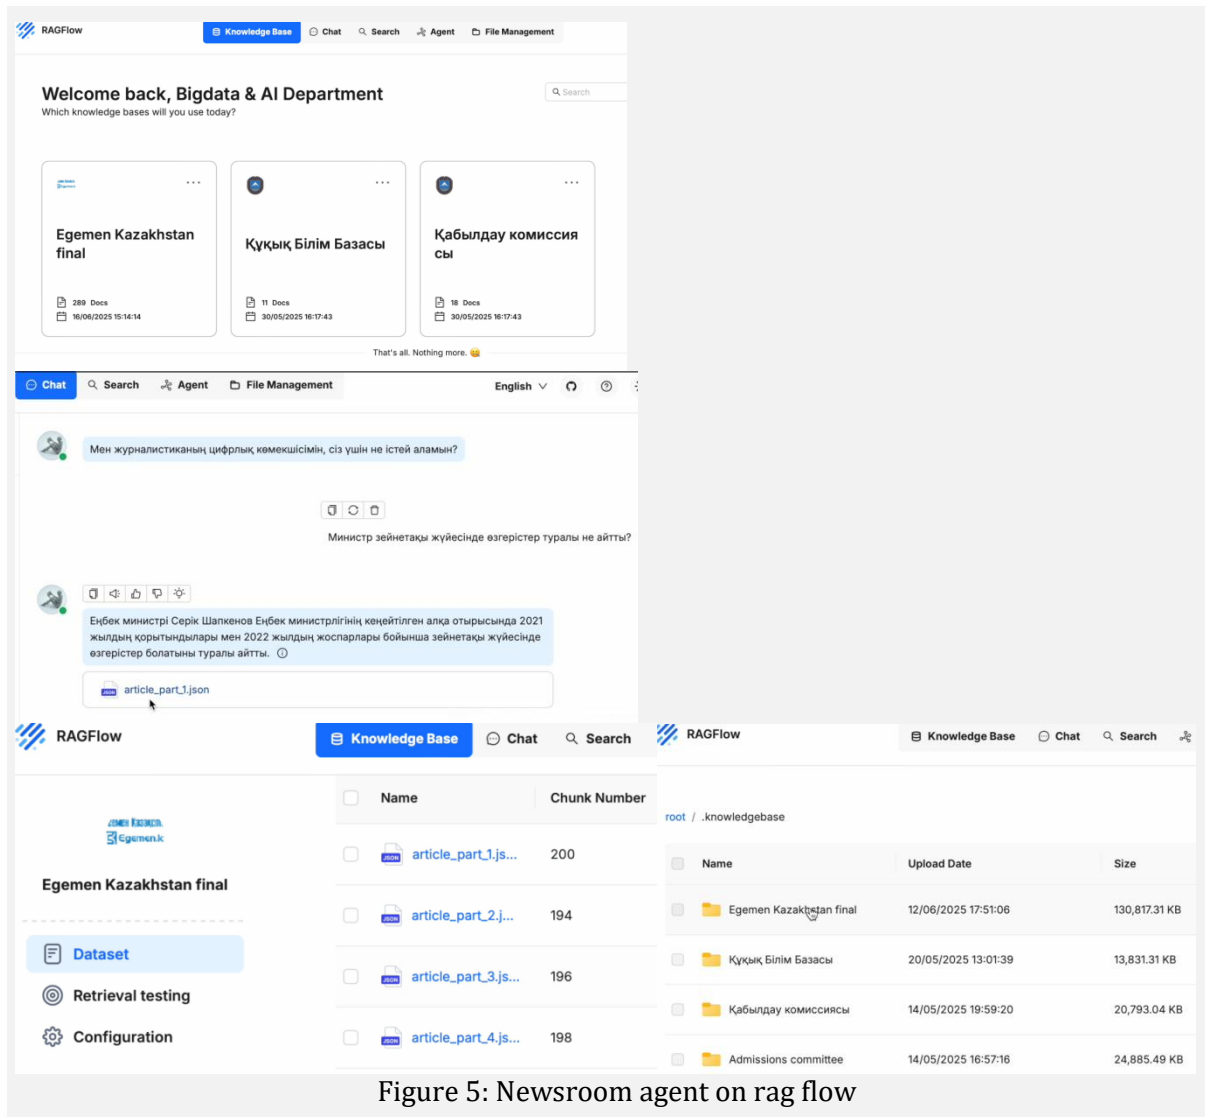


Figure 5: Newsroom agent on rag flow

This efficiency gain is primarily driven by quantization [32], which reduces model precision (commonly to 8-bit or 4-bit) while preserving much of the model’s practical capability. In addition to quantization, distillation and optimized compute kernels are widely used to reduce serving cost and latency. Together, these methods have contributed to a major shift in the field: inference efficiency is now a first-order constraint, and successful deployments increasingly depend on carefully engineered serving stacks rather than model quality alone. Once architecture-level constraints are addressed, attention naturally shifts toward data efficiency, because scalable deployment and continuous improvement require high-quality data, robust retrieval indexes, and reliable update workflows.

The admission-office assistant addresses a different but equally high-impact need. Al-Farabi Kazakh National University receives tens of thousands of applications and an even larger volume of questions about programs, requirements, deadlines, and career pathways from prospective students across Kazakhstan and abroad. A recurring difficulty is that applicants often struggle to distinguish between closely related majors such as Computer Science, Software Engineering, Data Science, and Information Systems. In addition, educational-program information is frequently distributed across multiple webpages and documents, making it hard for students to connect fragmented details into a coherent understanding and a realistic study plan. The proposed assistant therefore uses a RAG-based architecture (illustrated in the figure 6) to consolidate trusted materials, retrieve relevant passages, and generate grounded answers that help applicants navigate programs and make informed decisions.

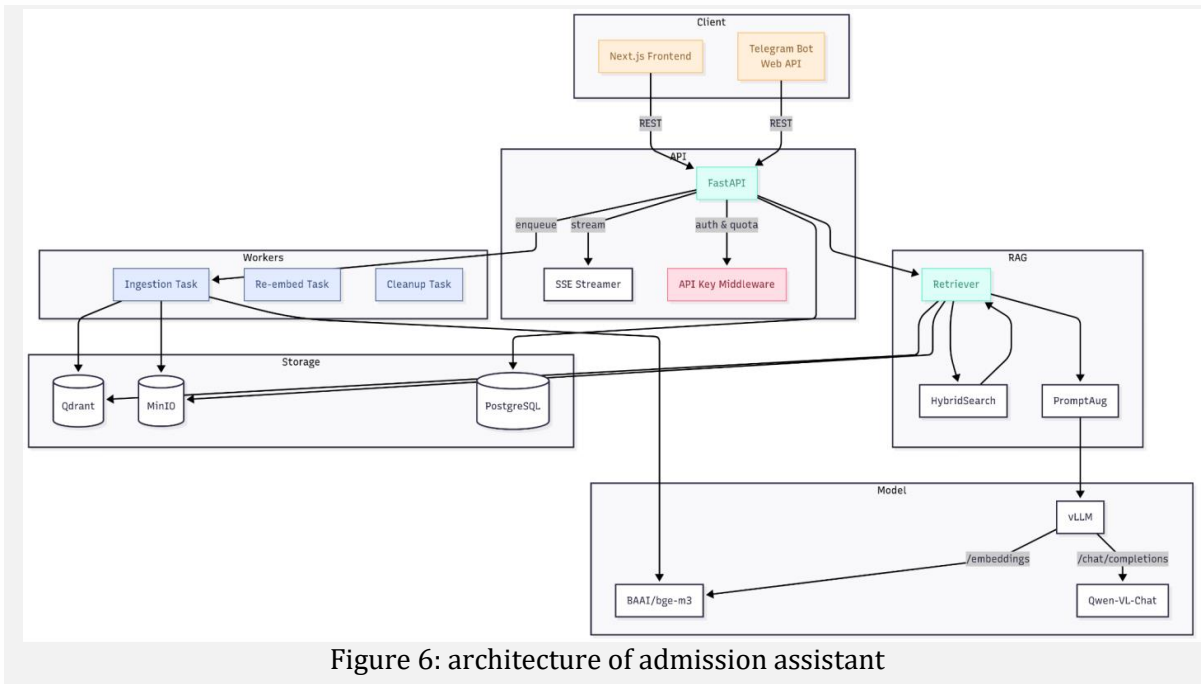


Figure 6: architecture of admission assistant

From a deployment perspective, the admission assistant is designed around four operational goals. First, full data control ensures that sensitive content and logs remain within the university infrastructure. Second, transparency and adaptability allow flexible choices of models, indexing strategies, and output formats as requirements evolve. Third, trilingual support (Kazakh, Russian, and English) enables broad accessibility without maintaining separate codebases. Fourth, independence from external APIs keeps computation local and reduces vendor lock-in. In the initial pilot, the system encountered two practical bottlenecks: response latency and residual hallucination in some queries. To address these issues, the next iteration plans to use stronger on-premise GPU infrastructure, including an NVIDIA DGX-class server, and to incorporate the ReAct framework to improve reasoning traceability and tool-use behavior. Together, these upgrades aim to improve both response speed and factual reliability, enabling wider adoption in university-wide admission operations..

Discussion

The evidence reviewed in this paper suggests that Kazakhstan’s AI development over the past decade has moved from early-stage adoption toward ecosystem formation. Research output has increased sharply, and AI is no longer confined to academic prototypes. Large state and industrial actors are deploying AI in production settings, while parallel efforts are expanding compute capacity, data infrastructure, and workforce training. This combination indicates that Kazakhstan is building not only “AI projects,” but also the institutional pathways needed for sustained adoption, including procurement, deployment practices, and skills pipelines.

At the same time, the main bottleneck is not model architecture alone but end-to-end capability. For Kazakhstan, the critical constraints are data availability and quality, compute access for both training and inference, and rigorous evaluation that can support deployment decisions. This is especially visible in language technologies. Because Kazakh is a low-resource language, it remains underrepresented in many global pretraining corpora, which leads to weaker baseline performance and makes additional adaptation unavoidable. The case study shows that improving performance requires investment in data assets that are suitable for LLM training, including curated instruction datasets and large-scale digitization with careful preprocessing.

The project case also demonstrates that “local LLM development” is primarily a systems problem. Even when training compact models, a viable pipeline must cover corpus acquisition, cleaning and deduplication, tokenization, training stability, and post-training alignment. In

deployment, reliability depends on controlling hallucination and ensuring traceability. Retrieval-Augmented Generation is a practical mechanism for grounding answers in verifiable sources, but it introduces new requirements: high-quality document repositories, indexing strategies, re-ranking, monitoring, and periodic refresh of knowledge bases. These components determine real-world usefulness as much as the base model itself.

Finally, operational constraints shape what can be deployed at scale. Inference cost, latency, and memory are limiting factors for universities, public services, and many enterprises. The newsroom case illustrates how quantization and other efficiency methods can enable advanced models in resource-constrained environments, while still delivering useful capabilities such as summarization, question answering, and content drafting. The admission assistant illustrates a second reality: user-facing systems must support multilingual interaction, transparent behavior, and local data control. Early pilots revealed common failure modes, including slow responses and residual hallucination, which points to the need for stronger on-premise GPU infrastructure and more robust agentic workflows, such as tool-use and reasoning frameworks, to improve reliability.

Conclusion

Kazakhstan's AI progress over the past decade is best understood as a transition toward a full-stack ecosystem that connects research, infrastructure, skills, and deployment. The country's near-term success will depend on strengthening the components that convert models into dependable services: trusted and continuously updated data assets, sufficient compute for training and serving, benchmark-driven evaluation, and responsible deployment practices including alignment, monitoring, and traceability. If these elements advance together, Kazakhstan can move from isolated demonstrations to scalable AI systems that deliver measurable value in public services, industry, education, and scientific research.

Reference

- [1] Zamora-Cárdenas, W., Zumbado, M., & Trejos-Zelaya, I. (2020). McCulloch-Pitts Artificial Neuron and Rosenblatt's Perceptron: An abstract specification in *Z. Technology Inside by CPIC*, 5, 16-29.
- [2] Qu, P., Yan, J., Zhang, Y. H., & Gao, G. R. (2017). Parallel turing machine, a proposal. *Journal of Computer Science and Technology*, 32(2), 269-285.
- [3] LeCun, Y., Boser, B., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W., & Jackel, L. D. (1989). Backpropagation applied to handwritten zip code recognition. *Neural computation*, 1(4), 541-551.
- [4] Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25.
- [5] Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., ... & Polosukhin, I. (2017). Attention is all you need. *Advances in neural information processing systems*, 30.
- [6] Chatterji, A., Cunningham, T., Deming, D. J., Hitzig, Z., Ong, C., Shan, C. Y., & Wadman, K. (2025). How people use chatgpt (No. w34255). National Bureau of Economic Research.
- [7] Institute of Smart Systems and Artificial Intelligence. (n.d.). KazLLM. Nazarbayev University. Retrieved January 20, 2026, from <https://issai.nu.edu.kz/kazllm/>
- [8] Astana Hub. (n.d.). AlemLLM (astanahub/alemlm) [Large language model]. Hugging Face. Retrieved January 20, 2026, from <https://huggingface.co/astanahub/alemlm>
- [9] President Kassym-Jomart Tokayev's State of the Nation Address to the people of Kazakhstan: Kazakhstan in the era of artificial intelligence: Current challenges and solutions through digital transformation. Official website of the President of the Republic of Kazakhstan. <https://www.akorda.kz/en/president-kassym-jomart-tokayevs-state-of-the-nation-address-to-the-people-of-kazakhstan-kazakhstan-in-the-era-of-artificial-intelligence-current-challenges-and-solutions-through-digital-transformation-1083029>
- [10] Interfax-Kazakhstan. (2026, January 6). Kazakhstan's Samruk-Kazyna projects \$1.3 bln gain from AI over five years. https://www.interfax.kz/?int_id=21&lang=eng&news_id=77600
- [11] Prime Minister of the Republic of Kazakhstan. (2026, January 6). Kazakhstan actively introduces AI solutions into production processes. <https://primeminister.kz/en/news/kazakhstan-actively-introduces-ai-solutions-into-production-processes-30932>
- [12] Kazinform News Agency. (2025, November 18). Kazakhstan joins the world's TOP-500 most powerful supercomputers. <https://qazinform.com/news/kazakhstan-joins-the-worlds-top-500-most-powerful-supercomputers-b42a40>
- [13] ENERGY Insights & Analytics. (2025, August 20). Kazakhstan Energy Outlook 2025 (Report). EXia. [https://s3-prod.exia.kz/articles/Kazakhstan Energy Outlook 2025 EN.pdf](https://s3-prod.exia.kz/articles/Kazakhstan%20Energy%20Outlook%202025%20EN.pdf)

- [14] Ministry of Artificial Intelligence and Digital Development of the Republic of Kazakhstan. (n.d.). Почти 1 млн казахстанцев прошли обучение по искусственному интеллекту: как выполняется поручение Главы государства по подготовке кадров для цифровой страны. GOV.KZ. Retrieved January 20, 2026, from <https://www.gov.kz/memleket/entities/maidd/press/news/details/1142334?lang=ru>
- [15] Mussa, A., Tuimebayev, Z., & Mansurova, M. (2025). Make Large Language Models Efficient: A Review. *IEEE Access*.
- [16] AI Index Steering Committee. (2025). AI Index Report 2025. Retrieved January 20, 2026, from <https://hai.stanford.edu/ai-index/2025-ai-index-report>
- [17] Xia, M., Malladi, S., Gururangan, S., Arora, S., & Chen, D. (2024). Less: Selecting influential data for targeted instruction tuning. *arXiv preprint arXiv:2402.04333*.
- [18] Xu M., Yin W., Cai D., Yi, R., Xu, D., Wang, Q., ... & Liu, X. (2024). A survey of resource-efficient llm and multimodal foundation models. *arXiv preprint arXiv:2401.08092*.
- [19] Lin X., Wang W., Li Y., Yang S., Feng F., Wei Y., & Chua T. S. (2024, July). Data-efficient Fine-tuning for LLM-based Recommendation. In *Proceedings of the 47th international ACM SIGIR conference on research and development in information retrieval* (pp. 365-374).
- [20] Zhou Z., Ning X., Hong K., Fu T., Xu J., Li S., ... & Wang Y. (2024). A survey on efficient inference for large language models. *arXiv preprint arXiv:2404.14294*.
- [21] Griffith S., Subramanian K., Scholz J., Isbell C. L., & Thomaz, A. L. (2013). Policy shaping: Integrating human feedback with reinforcement learning. *Advances in neural information processing systems*, 26.
- [22] Xu H., Sharaf A., Chen Y., Tan W., Shen L., Van Durme B., ... & Kim, Y. J. (2024). Contrastive preference optimization: Pushing the boundaries of llm performance in machine translation. *arXiv preprint arXiv:2401.08417*.
- [23] Acharya D. B., Kuppan K., & Divya B. (2025). Agentic ai: Autonomous intelligence for complex goals—a comprehensive survey. *IEEE Access*.
- [24] Kaz-Transformers. (n.d.). *kz-transformers* (Hugging Face organization page). Hugging Face. Retrieved January 20, 2026, from <https://huggingface.co/kz-transformers>
- [25] Cao Y., Hong, S. Li, X. Ying J., Ma Y., Liang H., ... & Jiang Y. G. (2025). Toward generalizable evaluation in the llm era: A survey beyond benchmarks. *arXiv preprint arXiv:2504.18838*.
- [26] Touvron H., Martin L., Stone K., Albert P., Almahairi A., Babaei Y., ... & Scialom, T. (2023). Llama 2: Open foundation and fine-tuned chat models. *arXiv preprint arXiv:2307.09288*.
- [27] Ahmet Baitursynuly Institute of Linguistics. (n.d.). *National Corpus of the Kazakh Language* (QazCorpus). Retrieved January 20, 2026, from <https://qazcorpus.kz>
- [28] Najam R., & Faizullah S. (2023). Analysis of recent deep learning techniques for Arabic handwritten-text OCR and post-OCR correction. *Applied Sciences*, 13(13), 7568.
- [29] Liu Y., Yao Y., Ton J. F., Zhang X., Guo R., Cheng H., ... & Li H. (2023). Trustworthy llms: a survey and guideline for evaluating large language models' alignment. *arXiv preprint arXiv:2308.05374*.
- [30] Fan W., Ding Y., Ning L., Wang S., Li H., Yin D., ... & Li Q. (2024, August). A survey on rag meeting llms: Towards retrieval-augmented large language models. In *Proceedings of the 30th ACM SIGKDD conference on knowledge discovery and data mining* (pp. 6491-6501).
- [31] RAGFlow. (n.d.). *RAGFlow* (official website). Retrieved January 20, 2026, from <https://ragflow.io>
- [32] Li M., Huang Z., Chen L., Ren J., Jiang M., Li F., ... & Gao C. (2024, June). Contemporary advances in neural network quantization: A survey. In *2024 International Joint Conference on Neural Networks (IJCNN)* (pp. 1-10). IEEE.

МРНТИ 30.17.51

A. Kaltayev^{1,2}, Zh. Ualiev³, A. Bibossinov⁴, 2026¹Institute of Mechanics and Engineering named after. U.A. Dzholdasbekova, Shevchenko st. 28, 050010, Almaty, Kazakhstan²Kazakh National Technical University named after K.I. Satpayev, st. Satpayev 22, 050000, Almaty, Kazakhstan³Institute of Digital Engineering and Technology, st. Satpayeva, 22/5, 050013, Almaty, Kazakhstan⁴JSC "NCGNTE", st. Bogenbay batyr, 221, 050026, Almaty, Kazakhstan**MODELING AND INVESTIGATION OF HYDRODYNAMICS AND MASS TRANSFER IN URANIUM RECOVERY IN A PACKED ION-EXCHANGE COLUMN WITH A CONICAL FLOW DISTRIBUTOR****Aidarkhan Kaltayev**, Dr.Sc, Professor, Head of the Research Laboratory "Engineering Mechanics and Modeling", KazNRTU.E-mail: Aidarkhan.kaltayev@gmail.com; <https://orcid.org/0000-0003-2180-2785>**Zhomart Ualiev**, PhD, Associate Professor.E-mail: zh-u@mail.ru; ; <https://orcid.org/0000-0002-5021-2154>**Asylkhan Bibossinov**, PhD, Chairman of the Board.E-mail: bibossinov@live.com; <https://orcid.org/0000-0002-5219-4279>

Abstract. Efficient recovery of uranium from productive leaching solutions requires a detailed understanding of hydrodynamics and mass transfer in ion-exchange sorption columns. In this work, a coupled physical and mathematical model of uranium oxide sorption in a packed ion-exchange column equipped with a conical flow distributor is developed. Fluid flow in the porous resin bed is described using the Forchheimer filtration law combined with the mass conservation equation. The mass-transfer process between the uranium-bearing solution and the ion-exchange resin is modeled by a convective–dispersion transport equation coupled with a sorption kinetics equation based on the linear driving force approximation.

To simulate the process in a domain of complex geometry, the fictitious domain method is applied. The pressure field is computed using the Ritz variational method, while the transport equation for uranium in the liquid phase is solved using the Crank–Nicolson scheme. The sorption kinetics equation is integrated analytically at each time step.

Numerical simulations show that uranium distribution in both liquid and solid phases forms a ring-shaped cylindrical region inside the column, indicating non-uniform utilization of the sorbent bed. The conical distributor does not provide sufficiently uniform radial flow distribution. Increasing the solution flow rate by a factor of two leads to an approximately 1.5-fold increase in the width of the mass-transfer zone, mainly due to enhanced longitudinal dispersion.

The proposed modeling approach can be used to analyze and optimize industrial sorption columns applied in uranium recovery processes.

Keywords: Uranium recovery; Ion exchange; Packed column; Convective–dispersion transport; Mass transfer zone; Porous media flow; Numerical simulation.

Қалтаев А.^{1,2*}, Уалиев Ж.Р.³, Бибосинов А. Ж.⁴, 2026.

¹У.А. Джолдасбеков атындағы Механика және машинатану институты, Шевченко к., 28 үй, 050010, Алматы, Қазақстан

²Қ.Сәтпаев атындағы ҚазҰҒЗУ, Сатпаев көш., 22 үй, 050000, Алматы, Қазақстан

³Сандық технологиялар және жабдықтар институты, Сатпаев к., 22/5 үй, 050013, Алматы, Қазақстан

⁴«ҰМҒ-ТО» АҚ, Богенбай батыр көш., 221, 050026, Алматы, Қазақстан

КОНУСТЫ АҒЫН ТАРАТҚЫШЫ БАР ТОЛТЫРМАЛЫ ИОНАЛМАСУ КОЛОННАСЫНДА УРАНДЫ АЛУ ПРОЦЕСІНДЕГІ ГИДРОДИНАМИКА МЕН МАССАЛМАСУДЫ МОДЕЛЬДЕУ ЖӘНЕ ЗЕРТТЕУ

Қалтаев Айдархан, ф.-м.ғ.д., проф., Қ.Сәтпаев атындағы ҚазҰҒЗУнің «Инженерлік механика және моделдеу» ҒЗЗның жетекшісі, Алматы, Қазақстан.

E-mail: Aidarkhan.kaltayev@gmail.com; <https://orcid.org/0000-0003-2180-2785>

Уалиев Жомарт Разханұлы, PhD, қаум. профессор, Алматы, Қазақстан.

E-mail: zh-u@mail.ru; ; <https://orcid.org/0000-0002-5021-2154>

Бибосинов Асылхан Жәнібекұлы, PhD, АҚ «ҰМҒ-ТО»-тың басқарма төрағасы, Алматы, Қазақстан.

E-mail: bibossinov@live.com; <https://orcid.org/0000-0002-5219-4279>

Аннотация. Сілтілеу өнімді ерітінділерінен уранды тиімді алу ионалмастырғыш сорбциялық колонналардағы гидродинамика мен массалмасу процестерін терең түсінуді талап етеді. Бұл жұмыста конус тәрізді ағын таратқышы бар толтырмалы ионалмастырғыш колоннадағы уран оксидтерінің сорбциясын сипаттайтын байланысқан физикалық және математикалық модель әзірленді. Кеуекті шайыр қабатындағы сұйықтық қозғалысы Форхгеймер сүзу заңы мен масса сақталу теңдеуі арқылы сипатталады. Уран иондары бар ерітінді мен ионалмастырғыш шайыр арасындағы массалмасу конвективті-дисперсиялық тасымалдау теңдеуі және сызықтық қозғаушы күш жуықтауына негізделген сорбция кинетикасының теңдеуі арқылы сипатталады.

Күрделі геометриялы есеп аймағында сорбция процесін сандық зерттеу үшін фиктивті облыстар әдісі қолданылды. Қысым өрісі Ритцтің вариациялық әдісімен есептелді, ал сұйық фазадағы уранның тасымал теңдеуі Кранк–Николсон схемасын қолдану арқылы шешілді. Сорбция кинетикасының теңдеуі әрбір уақыт қадамында аналитикалық түрде интегралданады.

Сандық модельдеу нәтижелері уранның сұйық және қатты фазалардағы таралуы колонна ішінде сақина тәрізді цилиндрлік аймақ түзетінін көрсетті, бұл сорбент қабатының біркелкі пайдаланылмайтынын білдіреді. Конустық ағын таратқыш колонна қимасы бойынша ерітіндінің біркелкі таралуын жеткілікті дәрежеде қамтамасыз етпейтіні анықталды. Ерітінді шығынын екі есе арттыру массалмасу аймағының енін шамамен 1,5 есе ұлғайтады, бұл бойлық дисперсияның күшеюімен түсіндіріледі.

Ұсынылған модельдеу әдісі уранды өндіруде қолданылатын өнеркәсіптік сорбциялық колонналардың жұмыс тиімділігін талдау және оңтайландыру үшін пайдаланылуы мүмкін.

Түйін сөздер: уранды алу; ионалмасу; толтырмалы колонна; конвективті-дисперсиялық тасымал; массалмасу аймағы; кеуекті ортадағы фильтрация; сандық модельдеу.

Калтаев А.^{1,2*}, Уалиев Ж.Р.^{1,2}, Бибосынов А.Ж.³, 2026.

¹Институт механики и машиноведения им. У.А. Джолдасбекова, ул. Шевченко 28, 050010, Алматы, Казахстан

²КазННТУ им. К.И. Сатпаева, ул. Сатпаева 22, 050000, Алматы, Казахстан

³ Институт цифровой техники и технологий, ул. Сатпаева, 22/5, 050013, Алматы, Казахстан

⁴АО «НЦГНТЭ», ул. Богенбай батыра, 221, 050026, Алматы, Казахстан

МОДЕЛИРОВАНИЕ И ИССЛЕДОВАНИЕ ГИДРОДИНАМИКИ И МАССООБМЕНА ПРИ ИЗВЛЕЧЕНИИ УРАНА В НАСАДОЧНОЙ ИОНООБМЕННОЙ КОЛОННЕ С КОНИЧЕСКИМ РАСПРЕДЕЛИТЕЛЕМ ПОТОКА

Қалтаев Айдархан, д.ф.-м.н., профессор, руководитель НИЛ «Инженерная механика и моделирование», КазННТУ, Алматы, Казахстан.

E-mail: Aidarkhan.kaltayev@gmail.com; <https://orcid.org/0000-0003-2180-2785>

Уалиев Жомарт Разханович, PhD, асоц. профессор, Алматы, Казахстан.

E-mail: zh-u@mail.ru; <https://orcid.org/0000-0002-5021-2154>

Бибосынов Асылхан Жанибекович, PhD, председатель правления НЦГНТЭ, Алматы, Казахстан.

E-mail: bibossinov@live.com; <https://orcid.org/0000-0002-5219-4279>

Аннотация. Эффективное извлечение урана из продуктивных растворов выщелачивания требует детального понимания гидродинамики и процессов массообмена в ионообменных сорбционных колоннах. В работе разработана сопряжённая физическая и математическая модель сорбции оксидов урана в насадочной ионообменной колонне с коническим распределителем потока раствора. Движение жидкости в пористом слое смолы описывается законом фильтрации Форхгеймера совместно с уравнением сохранения массы. Массообмен между урансодержащим раствором и ионообменной смолой моделируется уравнением конвективно-дисперсионного переноса вещества, сопряжённым с кинетическим уравнением сорбции на основе приближения линейной движущей силы.

Для численного исследования процесса в области сложной геометрии применён метод фиктивных областей. Поле давления вычисляется численно вариационным методом Рунге, тогда как уравнение переноса урана в жидкой фазе решается с использованием схемы Кранка-Никольсона. Кинетическое уравнение сорбции интегрируется аналитически на каждом временном шаге.

Результаты численного моделирования показывают, что распределение урана в жидкой и твёрдой фазах формирует внутри колонны кольцеобразную цилиндрическую область, что свидетельствует о неравномерном использовании слоя сорбента. Показано, что конический распределитель потока не обеспечивает достаточно равномерного распределения раствора по поперечному сечению колонны. Увеличение расхода раствора в два раза приводит к увеличению ширины зоны массообмена примерно в 1,5 раза вследствие усиления продольной дисперсии.

Предложенный подход к моделированию может быть использован для анализа и оптимизации работы промышленных сорбционных колонн, применяемых при извлечении урана.

Ключевые слова: извлечение урана; ионообмен; насадочная колонна; конвективно-дисперсионный перенос; зона массообмена; фильтрация в пористой среде; численное моделирование.

Введение

Конструкция сорбционной колонны и принцип ее работы

Многие глубокозалегающие и/или низкоконцентрированные месторождения редких и драгоценных металлов, вследствие экономической эффективности и относительной экологической безопасности, разрабатываются методом подземного скважинного

выщелачивания (Мамилов и др., 1980; Wang et al., 2022; Kurmanseit и др., 2022 и 2023; Li и др., 2024). На стадии переработки извлечённых растворов (продуктивных растворов) наибольшее распространение получили традиционные сорбционно-осадительные методы концентрирования полезных компонентов непосредственно на местах добычи с использованием ионообменных смол (Couper et al., 2012; Orrego, 2019; Quinn и др., 2020).

Существующие исследования, посвящённые сорбции оксидов урана, в основном направлены на моделирование процессов переноса и кинетики сорбции в прямоточных колоннах с учётом адвекции, дисперсии, а также физико-химических механизмов взаимодействия урана с сорбентом (Zhang et al., 2011; Mahmoud, 2015; Patel, 2019; Baqer et al., 2023).

В настоящей работе на основе математического и численного моделирования исследована динамика ионообменного извлечения оксидов урана из продуктивного раствора в прямоточной сорбционной насадочной колонне (СНК) сложной геометрии. Подобные колонны широко применяются в уранодобывающей промышленности для извлечения оксидов урана из продуктивных растворов (Мамилов, 1980; Patel, 2019).

Вначале приводится описание конструкции сорбера. Затем на основе экспериментальных данных, полученных в прямоточной колонне, определяются кинетические характеристики сорбента. Значения соответствующих коэффициентов устанавливаются путём сопоставления расчётных и экспериментальных кривых распределения концентрации минерала в жидкой фазе на различных сечениях насадочной сорбционной колонны и далее используются при построении математической модели процесса. С учётом найденных параметров разрабатывается математическая модель транспорта оксидов урана и их сорбции в пористом слое сорбента.


На заключительном этапе с применением метода фиктивных областей и численных методов проводится исследование эффективности работы сорбера типа СНК в зависимости от формы конусной преграды.

В работе анализируется первый цикл работы сорбционной колонны, при котором оксиды урана в сорбенте отсутствуют. Моделирование периодического режима работы сорбционной колонны возможно при наличии информации о распределении остаточной концентрации оксидов урана в сорбенте после выгрузки насыщенного слоя из колонны.

Конструкция и схема работы сорбционной насадочной колонны СНК-3 (далее — колонна или сорбер), широко применяемой в добывающих подразделениях АО «НАК Казатомпром», представляет собой цилиндрическую колонну высотой H и радиусом R с усечённым коническим днищем. В нижней части колонны, перед трубой подачи продуктивного раствора диаметром d , установлен конический распределитель потока. Его назначением является уменьшение неравномерности распределения гидродинамического потока и, соответственно, концентрации минерала по поперечному сечению колонны (рис. 1).

Колонна плотно заполняется неподвижным слоем гранулированного ионообменного сорбента (смолы фирмы *Purolite*), представляющего собой пористые сферические частицы диаметром δ с развитой внутренней поверхностью. Диаметр гранул на несколько порядков меньше диаметра подводящей трубы и, тем более, диаметра колонны $D=2R$. Поэтому слой сорбента может быть рассмотрен как пористая среда с пористостью $\phi \leq 0.4$.

Продуктивный раствор, содержащий ионы оксидов урана (например, катионы уранила U_2^{2+} или их комплексные формы), подаётся снизу вверх через подводящую трубу с постоянным объёмным расходом Q_0 . Более подвижные ионы водорода ионообменной смолы замещаются ионами оксидов урана из продуктивного раствора, в результате чего происходит ионообмен между смолой и раствором



поскольку энергия связи смолы с ионом урана превышает энергию связи с ионом водорода:

$$E(\text{смола-}U) > E(\text{смола-}H).$$

Здесь R - активный центр смолы, $R-H$ - смола с ионами H^+ , R_2U_2 - комплекс иона U_2^{2+} , закреплённый на смоле, H^+ - высвобождающийся в раствор ион водорода.

Вследствие того, что гранулы имеют развитую внутреннюю структуру и малых размеров капилляров, в гранулах смолы ионообменный процесс между раствором и сорбентом, протекающий по схеме (1), лимитируется внутридиффузионным переносом ионов по капиллярам.

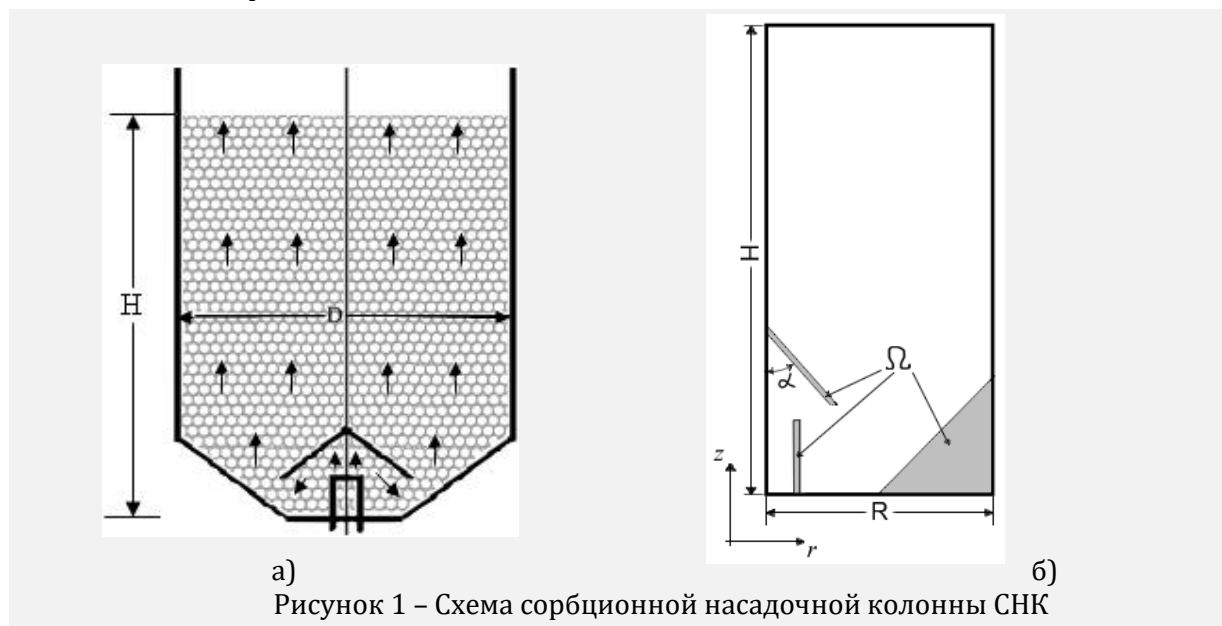


Рисунок 1 – Схема сорбционной насадочной колонны СНК

Перед входом в слой сорбента поток проходит через конический распределитель с углом раскрытия α , определяемым как угол между осью колонны и образующей распределителя.

В процессе работы колонны через заданные промежутки времени из верхней части колонны отбираются пробы раствора, которые анализируются на содержание извлекаемого минерала. Процесс сорбции продолжается до тех пор, пока средняя концентрация минерала в жидкой фазе на выходе из колонны не достигнет предельно допустимого значения. После этого наиболее насыщенная минералом нижняя часть слоя сорбента выгружается, колонна сверху дозагружается свежим сорбентом, и цикл сорбции повторяется.

Используемая в настоящее время конструкция насадочной сорбционной колонны была разработана более полувека назад эмпирическим путём на основе измерений средних значений параметров на входе и выходе колонны, то есть с использованием интегральных (осреднённых) характеристик процесса. Ограниченная информативность такого подхода в отношении локальных гидродинамических и массообменных процессов в областях сложной геометрии в течение длительного времени была обусловлена как недостаточным развитием вычислительных методов, так и ограниченными возможностями вычислительных ресурсов.

Вместе с тем, анализ только осреднённых характеристик не позволяет в полной мере оценить эффективность работы сорбера, в частности степень вовлечённости сорбента в массообменный процесс, влияние формы и размеров конического распределителя, а также средней скорости течения раствора на скорость и полноту извлечения минерала и на толщину зоны насыщения сорбента.

Очевидно, что решение указанных задач требует детального трёхмерного исследования процесса сорбции в пористом объёме сложной геометрии. Проведение такого анализа на основе современных вычислительных технологий и численных методов и составляет предмет настоящей работы.

Таким образом, целью настоящей работы является разработка физической и математической моделей процесса сорбционного извлечения оксидов урана из продуктивных растворов в насадочной ионообменной колонне сложной геометрии, оснащённой коническим распределителем потока. На основе численного моделирования проводится исследование влияния формы распределителя и скорости подачи раствора на гидродинамику потока, распределение концентрации минерала в жидкой и твёрдой фазах, а также на степень вовлечённости сорбента в массообменный процесс.

Научная новизна работы заключается в разработке сопряжённой гидродинамической и массообменной модели процесса ионообменной сорбции в сорбционной колонне сложной геометрии с использованием метода фиктивных областей, позволяющего учитывать реальные конструктивные особенности аппарата. В отличие от ранее применявшихся подходов, основанных преимущественно на анализе интегральных характеристик процесса, предложенная модель позволяет исследовать пространственное распределение гидродинамических и массообменных параметров внутри колонны и оценивать влияние конструктивных и режимных факторов на эффективность работы сорбера.

Математическая и численная модели процесса сорбции урана

Продуктивный раствор, содержащий растворённые ионы оксидов урана, по своему составу преимущественно представляет собой воду и в рассматриваемых условиях может быть аппроксимирован как несжимаемая ньютоновская жидкость с плотностью и вязкостью, близкими к соответствующим характеристикам воды.

Вследствие малости характерных размеров гранул смолы по сравнению с диаметром колонны, плотной упаковки и неподвижности сорбционного слоя, а также относительно низких скоростей потока движение раствора через слой рассматривается как фильтрационное течение в пористой среде.

Узкий гранулометрический состав и близкая к сферической форма гранул ионообменной смолы при равномерной загрузке колонны позволяют в макроскопическом приближении рассматривать сорбционный слой как однородную и изотропную пористую среду с эффективными фильтрационными характеристиками.

В силу осесимметричной конструкции сорбционной колонны и трубы подачи раствора течение жидкости и процесс сорбции также считаются осесимметричными. Соответственно, исследование трёхмерного переноса продуктивного раствора и массообмена в колонне в цилиндрической системе координат (r, φ, z) может быть сведено к осесимметричной двумерной задаче по радиальной r и осевой z координатам (рис. 1,б).

Вблизи трубы подачи продуктивного раствора и конусообразного распределителя потока число Рейнольдса может существенно превышать единицу, тогда как в основной части колонны течение сохраняет фильтрационный характер. В связи с этим движение жидкости в пористом слое описывается соотношениями теории фильтрации — законом Форхгеймера (2), применимым в широком диапазоне чисел Рейнольдса, и законом сохранения массы жидкости в порах (3) (Бэр, 1971; Коллинз, 1964; Гольдштик, 1984; Шестаков, 1995):

$$\alpha \vec{u}(r, z, t) = \alpha \phi \vec{v}(r, z, t) = -\nabla P(r, z, t), \quad (2)$$

$$\nabla \cdot \vec{u} = \nabla \cdot (\phi \vec{v}) = 0, \quad (3)$$

где $\vec{u}(r, z, t) = u_r \vec{i}_r + u_z \vec{i}_z$ — средняя скорость Дарси жидкости, $\alpha = \alpha_1 + \alpha_2 |\vec{u}|$, ϕ — пористость слоя сорбента, $\vec{v}(r, z, t) = \vec{u}/\phi = v_r \vec{i}_r + v_z \vec{i}_z$ — средняя скорость жидкости в порах, $P(r, z, t) = p(r, z, t)/\rho + \vec{g} \cdot \vec{x}$, $p(r, z, t)$ — давление в жидкости, ρ — плотность жидкости, \vec{g} — ускорение силы тяжести, $\vec{x} = r \vec{i}_r + z \vec{i}_z$ — радиус-вектор точки, μ — динамический коэффициент вязкости раствора, δ — диаметр сферических гранул сорбента,

$$\alpha_1 = 633\mu(1 - \phi)/\rho\delta^2, \quad \alpha_2 = 3(1 - \phi)\phi/2\theta\delta.$$

При значениях пористости $\phi \leq 0.4$ принято, что $\theta = 0.508 - 0.56(1 - \phi)$ (Гольдштик, 1984).

Перенос ионов оксидов урана в продуктивном растворе и ионообменный процесс между жидким раствором и сорбентом является изотермичным и описывается уравнением

в частных производных (Ruthven, 1984; Гольдштик, 1984; Шестаков, 1995; Bird, 2002; Patel, 2019; Baqer et al., 2023)

$$\partial C / \partial t + \nabla \cdot (\vec{v} C) = \nabla \cdot (D \nabla C) - (\varphi^{-1} - 1) \partial \bar{C} / \partial t, \quad (4)$$

где D – гидродинамический дисперсионный тензор. Тензор D , в силу однородности и изотропности среды, является симметричным и имеет три ненулевые компоненты (Бэр, 1971; Коллинз, 1964):

$$\begin{aligned} D_{rr} &= \alpha_L \frac{v_r^2}{|\vec{v}|} + \alpha_T \frac{v_z^2}{|\vec{v}|} + D_m, \\ D_{zz} &= \alpha_T \frac{v_r^2}{|\vec{v}|} + \alpha_L \frac{v_z^2}{|\vec{v}|} + D_m, \\ D_{rz} &= D_{zr} = (\alpha_T - \alpha_L) \frac{v_r v_z}{|\vec{v}|}, \end{aligned}$$

где $\alpha_L = C_1 |\vec{v}|$ – коэффициент продольной дисперсии, пропорциональный диаметру сферических гранул-сорбентов, $\alpha_T = C_2 |\vec{v}|$ – коэффициент радиальной дисперсии, $\alpha_L / \alpha_T \approx 5$, D_m – коэффициент молекулярной диффузии жидкости.

Поле скорости жидкости, входящее в уравнение переноса ионов оксидов урана, определяется следующим образом. Из уравнения

$$(\alpha_1 + \alpha_2 |\vec{u}|) |\vec{u}| = |\nabla P|,$$

определяется модуль скорости $|\vec{u}|$ как функция модуля градиента P :

$$|\vec{u}| = f(|\nabla P|).$$

Тогда вектор скорости выражается зависимостью

$$\vec{u} = -\nabla P / (\alpha_1 + \alpha_2 f(|\nabla P|)). \quad (2')$$

Подстановка полученного выражения в закон сохранения массы (3) в цилиндрической системе координат приводит к нелинейному эллиптическому уравнению относительно давления:

$$\frac{\partial}{\partial r} \left(rA \frac{\partial P}{\partial r} \right) + \frac{\partial}{\partial z} \left(rA \frac{\partial P}{\partial z} \right) = 0 \quad (5)$$

где

$$A(r, z, t) = 1 / (\alpha_1 + \alpha_2 f(|\nabla P|)).$$

После решения уравнения (5) из уравнения (2') вычисляется поле скорости жидкости в сорбере.

Ионообменный процесс между раствором и сорбентом по схеме (1), лимитируется внутридиффузионным переносом и описывается дифференциальным уравнением кинетики псевдопервого порядка (Ruthven, 1984; Helfferich, 1995; Jean-Pierre Simonin, 2016; Quinn et al., 2020):

$$\partial \bar{C} / \partial t = \beta (C - \bar{C} / K_d), \quad (6)$$

где \bar{C} – массовая концентрация адсорбированных сорбентом ионов оксидов урана, C – массовая концентрация ионов оксидов урана в продуктивном растворе, β – кинетический коэффициент сорбции, характеризует скорость внутридиффузионного массопереноса, K_d – коэффициент равновесия или концентрирования сорбции.

Для скорости раствора и давления в жидкости на твердых стенках колонны используется условие непротекания жидкости:

$$\alpha \vec{u} \cdot \vec{n}|_S = -\partial P / \partial n|_S = 0, \quad (7)$$

где \vec{n} – нормальный к стенке колонны единичный вектор. На входе в колонну задаются площадь поперечного сечения трубы подачи S_{in} , объемный расход жидкости Q_0 и массовая концентрация минерала в растворе:

$$\vec{u} \cdot \vec{n}|_{in} = \partial P / \partial n|_{in} = \partial P / \partial z|_{in} = V_0 = Q_0 / S_{in}, \quad C|_{in} = C_{in}, \quad (8)$$

и на выходе из колонны задаются давление окружающей среды и «мягкие» условия на распределение концентрации минерала:

$$P|_{out} = P_{out}, \quad \partial C / \partial z|_{out} = 0. \quad (9)$$

В начальный момент времени сорбционная колонна заполнена жидкостью и сорбентом, не содержащим ионы оксидов урана:

$$C(\vec{x}, t = 0) = 0, \quad \bar{C}(\vec{x}, t = 0) = 0. \quad (10)$$

Входящие в уравнение (6) кинетические параметры β и K_d сорбции минерала определены с помощью сопоставления результатов расчетов с данными физического эксперимента, проведенного на сорбенте фирмы *Purolite*.




Рисунок 2 – Изменения концентрации минерала в сорбентах со временем. Пунктирные линии со значками – результаты эксперимента *Purolite*, сплошные линии – результаты численного расчета.

Кинетические кривые сорбции, построенные по результатам экспериментальных анализов, являлись основой для определения кинетических характеристик сорбентов: время достижения равновесия, емкость сорбентов в момент наступления равновесия, коэффициент равновесия, кинетический коэффициент сорбции (рис. 2). Рассматривая сорбционный процесс в эксперименте как массообменный процесс в идеальном реакторе, найдены значения $\beta \approx 120 \text{ час}^{-1}$ и $K_d = 286$.

Среди численных методов решения задач математической физики одним из наиболее универсальных является конечно-разностный метод. С вычислительной точки зрения данный метод наиболее эффективно реализуется на регулярных сетках в областях простой геометрии, таких как прямоугольники или их комбинации. Однако при численном исследовании задач переноса вещества, сопровождаемых физико-химическими превращениями в областях сложной формы, чаще применяются метод конечных элементов или метод конечных объемов (Флетчер, 1991; Morianou, 2023; Šimůnek, 2024 и др.).

Наряду с указанными подходами для решения задач в нерегулярных областях широко используется метод фиктивных областей (МФО) (Вабищевич, 2017; Thirumalaisamy et al, 2022; Corti et al, 2024; Kale et al, 2025), получивший значительное распространение в последние годы. В методе фиктивных областей исходная задача, заданная в нерегулярной

области Ω , продолжается на регулярную расчётную область R , образованную объединением физической области Ω и фиктивной области Ω_f , так что $R = \Omega \cup \Omega_f$ (рис. 3).

Теоретически, сходимость метода связано с получением однородного “inf - sup” условия, которое приводит к условию согласовании между граничной сеткой и однородной сеткой (Вабищевич, 2017). Другим важным аспектом является то, что условие устойчивости приведенной схемы аналогично соответствующим условиям конечно-разностных схем.



В рамках метода фиктивных областей граничные условия продолжают в фиктивную область следующим образом: для членов, содержащих производные первого порядка (конвективные члены), продолжение осуществляется по направлению потока – по младшей производной; для членов второго порядка (дисперсионно-диффузионные члены) – по старшей производной, что обеспечивает корректную аппроксимацию производных на границе (Вабищевич, 2017).

Применительно к решению эллиптического уравнения для давления (4) в методе фиктивных областей вводится коэффициент A_ε , определяемый следующим образом:

$$A_\varepsilon = H(\vec{x})rA + (1 - H(\vec{x}))\varepsilon, \tag{11}$$

где

$$H(\vec{x}) = \begin{cases} 1, & \vec{x} \in \Omega \\ 0, & \vec{x} \in \Omega_f \end{cases}$$

функция Хевисайда. Здесь ε - малая величина, $\varepsilon \ll rA$. После этого решение уравнения для давления (4) в нерегулярной физической области Ω с граничными условиями Неймана сводится к решению уравнения

$$\partial(A_\varepsilon \partial P / \partial r) / \partial r + \partial(A_\varepsilon \partial P / \partial z) / \partial z = 0 \tag{12}$$

в регулярной области R . Значения поля давления и его производные продолжают в фиктивную область таким образом, чтобы обеспечить корректную аппроксимацию вторых производных на границе раздела областей. В частности, в задаче Неймана для давления на физической границе $\partial\Omega$ формулируются условия согласования:

$$[P(\vec{x}, t)]_{\partial\Omega} = 0, \quad [\sum_{i,j=1}^2 n_i A_\varepsilon \partial P / \partial x_j]_{\partial\Omega} = 0, \tag{13}$$

где \vec{n} – внешняя нормаль к границе $\partial\Omega$, а $[\cdot]_{\partial\Omega}$ означает скачок функции на границе раздела физической и фиктивной областей.

Уравнение переноса ионов оксида урана в регулярной области R записывается следующим образом:

$$\partial C / \partial t + \nabla \cdot (\vec{v} C) = \nabla \cdot (D_\varepsilon \nabla C) - (\phi^{-1} - 1)H(\vec{x}) \partial \bar{C} / \partial t, \quad (14)$$

где

$$D_\varepsilon = H(\vec{x})D + (1 - H(\vec{x}))\varepsilon I,$$

I – единичный тензор.

Уравнение сорбции (6) в физической области сохраняет свой вид:

$$\partial \bar{C}(\vec{x}, t) / \partial t = \beta(C(\vec{x}, t) - \bar{C}(\vec{x}, t) / K_d). \quad (15)$$

В фиктивной (дополненной) области Ω_f принимается условие

$$\bar{C}(\vec{x}, t) = 0.$$

Численное решение и анализ результатов

В силу нелинейности система уравнений (12), (14), (15) с граничными условиями (7) – (9), (13) и начальными условиями (10) решается совместно с применением численных методов.

Последовательность численного решения задачи в регулярной области R на каждом шаге интегрирования по времени имеет следующий вид.

1. Из уравнения (12) с граничными условиями (7)–(9) и (13) численным методом определяется поле давления. Нелинейное эллиптическое уравнение для давления решается численно методом Рунге (Животенко, 2021).

2. Далее, после определения поля давления используя соотношение

$$\phi \vec{v} = -\nabla P / (\alpha_1 + \alpha_2 f(|\nabla P|))$$

вычисляется поле скоростей.

3. Затем из уравнения переноса (14) с граничными и начальными условиями (8)–(10) численным методом определяется концентрация минерала в жидкой фазе. Решение проводится с применением схемы Кранка–Никольсона (Флетчер, 1991).

4. Решением обыкновенного дифференциального уравнения кинетики сорбции (6) с начальным условием (10) завершается очередной шаг интегрирования задачи по времени. Уравнение кинетики сорбции при известном на каждом временном шаге значении концентрации минерала в жидкой фазе C^{n+1} решается аналитический.

В работе выполнено численное исследование влияния наличия конического распределителя потока на входе в сорбер, его геометрической формы, а также величины расхода раствора на характеристики сорбционного процесса.

В силу осевой симметрии задачи относительно оси Oz расчёты проводились в прямоугольной вычислительной области

$$0 < r < R, \quad 0 < z < H$$

на разностной сетке размерностью 150×600 .

Проведено исследование влияния формы конического распределителя потока продуктивного раствора и скорости подачи раствора в колонну на эффективность работы сорбера и полноту ионообменного процесса. Рассмотрены следующие варианты:

1. конусный распределитель потока отсутствует, объемный расход раствора $Q_0 = 0.35$ м³/ч;

2. вершина конусного распределителя фиксирована, угол α между осью колонны и образующей распределителя равен 45° и 60° , $Q_0 = 0.35$ м³/ч;

3. различные расходы подачи раствора – $Q_0 = 0.35$ м³/ч и $Q_0 = 0.7$ м³/ч – при одинаковом угле раскрытия конического распределителя $\alpha = 45^\circ$.

Геометрические и режимные параметры сорбционной колонны приняты близкими к используемым в промышленной практике: $H=6$ м, $R=D/2=1.5$ м, $d=0.3$ м, $\delta=0.5$ мм.

На рис. 4–8 представлены результаты расчётов пространственного распределения давления, скорости потока и концентрации минерала в неподвижной фазе (сорбенте) при отсутствии конусного распределителя ($Q_0=0.35 \text{ м}^3/\text{ч}$).

На рис. 4 представлены результаты расчёта распределения давления (кПа) и числа Рейнольдса. Число Рейнольдса вычислено по диаметру подводящей трубы продуктивного раствора $Re = V_0 \rho d / \mu$; при определении по диаметру гранул ионообменной смолы его значение на два порядка меньше. Как и ожидалось, вблизи подводящей трубы, площадь поперечного сечения которой в $(D/d)^2$ раз меньше площади поперечного сечения колонны, давление и скорость жидкости существенно выше, чем в удалённых от неё областях.




Рисунок 4 – (а) Распределение давления в жидкости (кПа), (б) распределение числа Рейнольдса течения жидкости в порах, $Q_0=0.35 \text{ м}^3/\text{ч}$.




Рисунок 5 – Распределение концентрации минерала в неподвижной фазе (сорбенте) (г/л) через 10 (а) и 40 (б) часов после начала работы сорбера, $Q_0=0.35 \text{ м}^3/\text{ч}$.

На рис. 5 представлены распределения концентрации минерала в неподвижной фазе через 10 и 40 часов после начала работы сорбера. Видно, что основной поток, содержащий ионы оксидов урана, развивается в центральной части колонны, тогда как пристеночная зона сорбента вовлекается в сорбционный процесс значительно слабее. Это особенно заметно на рис. 6, где показано распределение концентрации минерала в твердой фазе по поперечному сечению колонны на уровне $z=1.5$ м в различные моменты времени после начала работы сорбера. Видно, что средняя концентрация минерала по поперечному сечению колонны

$$\bar{C}_z(Z, t) = \int_0^{R(Z)} r \bar{C}(z, r, t) dr / (\pi R^2(Z))$$

составляет менее 60% от максимально возможной концентрации 23 г/л (см. рис. 6 и 7).




Рисунок 6 – Распределение концентрации минерала по поперечному сечению колонны в неподвижной фазе на уровне 1.5 м в различные моменты времени.




Рисунок 7 – Распределение средней по поперечному сечению колонны концентрации минерала в неподвижной фазе в различные моменты времени.

Также проанализирована степень объёмного вовлечения сорбента в процесс сорбции, в частности однородность протекания сорбционного процесса в поперечном сечении колонны, что соответствует принятой практике эксплуатации промышленных сорбционных колонн.

Для оценки степени вовлеченности сорбента (или эффективности работы сорбера) рассчитывалось отношение суммарной массы сорбированного минерала в слое высотой z

$$M(z, t) = \int_0^z \int_0^{R(z)} r \bar{C}(z, r, t) dr dz$$

к максимально возможной массе минерала, которая может быть удержана сорбентом в данном объеме:

$$M_m(z, t) = \int_0^z \int_0^{R(z)} r \bar{C}_{max}(r, z, t) dr dz = V_c K_d C_{in},$$

где $V_c(z)$ – объем колонны высотой z .

На рис. 8 представлена зависимость отношения

$$\mu(z, t) = M(z, t) / M_m(z, t)$$

от высоты и времени:




Рисунок 8 – Степень вовлеченности сорбента в процесс сорбции в зависимости от высоты и времени.

Таким образом, при отсутствии конусного распределителя установлено, что основной поток, содержащий ионы оксидов урана, формируется в центральной части колонны, тогда как пристеночная зона сорбента вовлекается в сорбционный процесс существенно слабее. Средняя по поперечному сечению колонны концентрация минерала не превышает две трети от максимально возможной (равновесной) концентрации.

Анализ степени вовлеченности сорбента (эффективности работы сорбера) также свидетельствует о низкой эффективности использования слоя сорбента.




Рисунок 9 – Поля скорости течения и давления в жидкости вблизи входной трубы и конического распределителя потока раствора в колонну при угле раскрытия $2\alpha=90^\circ$. Стрелками показаны направление и локальная величина скорости течения; цветовая шкала отражает распределение давления.

Далее рассмотрены варианты конструкции распределителя в сорбере, при которых угол между осью колонны и образующей конуса составляет 45° и 60° при расходе раствора $Q_0=0.35 \text{ м}^3/\text{ч}$. На рис. 9–16 приведены результаты расчётов распределений давления, скорости фильтрации и концентрации минерала в твёрдой фазе.

На рис. 9 представлены детальные поля скорости и давления вблизи трубы подачи и конического распределителя потока при угле $2\alpha=90^\circ$, вполне соответствующие форме сорбционной колонны и фильтрационному характеру течения.

На рис. 10–16 представлены результаты сравнительного анализа работы сорбционной колонны при углах раскрытия конического распределителя $\alpha=45^\circ$ и 60° . Расход раствора во всех случаях одинаков и равен $Q_0=0.35 \text{ м}^3/\text{ч}$.




Рисунок 10 – Изолинии давления в жидкости в сорбере (кПа). Углы раскрытия распределителя $2\alpha=90^\circ$ и 120° , $Q_0=0.35 \text{ м}^3/\text{ч}$.

На рис. 10–11 показаны распределения давления в жидкости и местного числа Рейнольдса

$$Re = Vd\rho/\mu,$$

определенного по диаметру входной трубы. Как видно из результатов расчётов, давление, также, как и местное число Рейнольдса, быстро падает в окрестности конического распределителя потока раствора в обеих колоннах. При большем угле раскрытия падение

давления вблизи конуса несколько выше, чем при меньшем угле. Однако далее по потоку давление в обоих случаях быстро выравнивается.

Закон Дарси, применимый при $Re \leq 10$, выполняется практически во всей области за коническим распределителем (рис. 11).




Рисунок 11 – Изолинии местного числа Рейнольдса течения жидкости в порах при углах раскрытия распределителя $2\alpha = 90^\circ$ и 120° , $Q_0 = 0.35 \text{ м}^3/\text{ч}$.

Для более детального анализа влияния угла раскрытия конического распределителя на процесс сорбции на рис. 12 и 13 приведены распределения минерала, поглощённого сорбентом, в колонне при двух различных углах раскрытия через 10 и 40 часов после начала работы сорбера. Из рисунков видно, что при большем угле раскрытия зона насыщения распространяется дальше вдоль колонны. Вместе с тем область, не вовлечённая в сорбционный процесс непосредственно за распределителем, оказывается заметно шире по сравнению со случаем меньшего угла раскрытия.

Концентрация минерала в каждом сечении колонны с течением времени возрастает до достижения предельного – равновесного – значения, что следует из уравнения (6), описывающего сорбцию минерала из жидкой фазы в твёрдую.

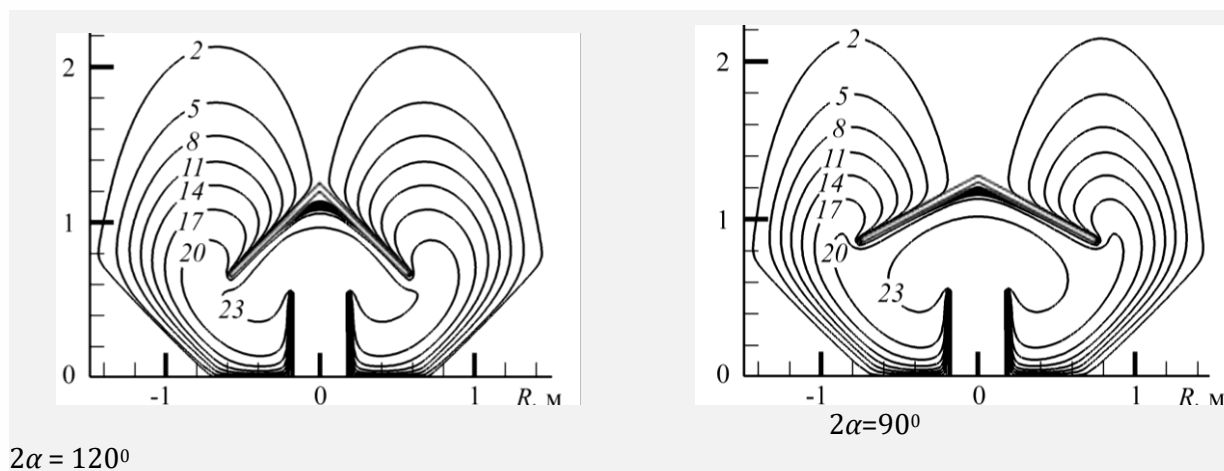


Рисунок 12 – Распределение минерала в неподвижной фазе через 10 часов после начала работы сорбера при углах раскрытия распределителя $2\alpha = 90^\circ$ и $2\alpha = 120^\circ$, $Q_0 = 0.35 \text{ м}^3/\text{ч}$. Числа на изолиниях соответствуют массовой концентрации минерала (г/л).

Анализ графиков показывает, что распределение концентрации минерала в неподвижной фазе формируется в виде волны насыщения, распространяющейся вдоль колонны; при этом фронт волны постепенно растягивается по направлению потока. Данное явление обусловлено продольной дисперсией минерала в пористом слое сорбента.

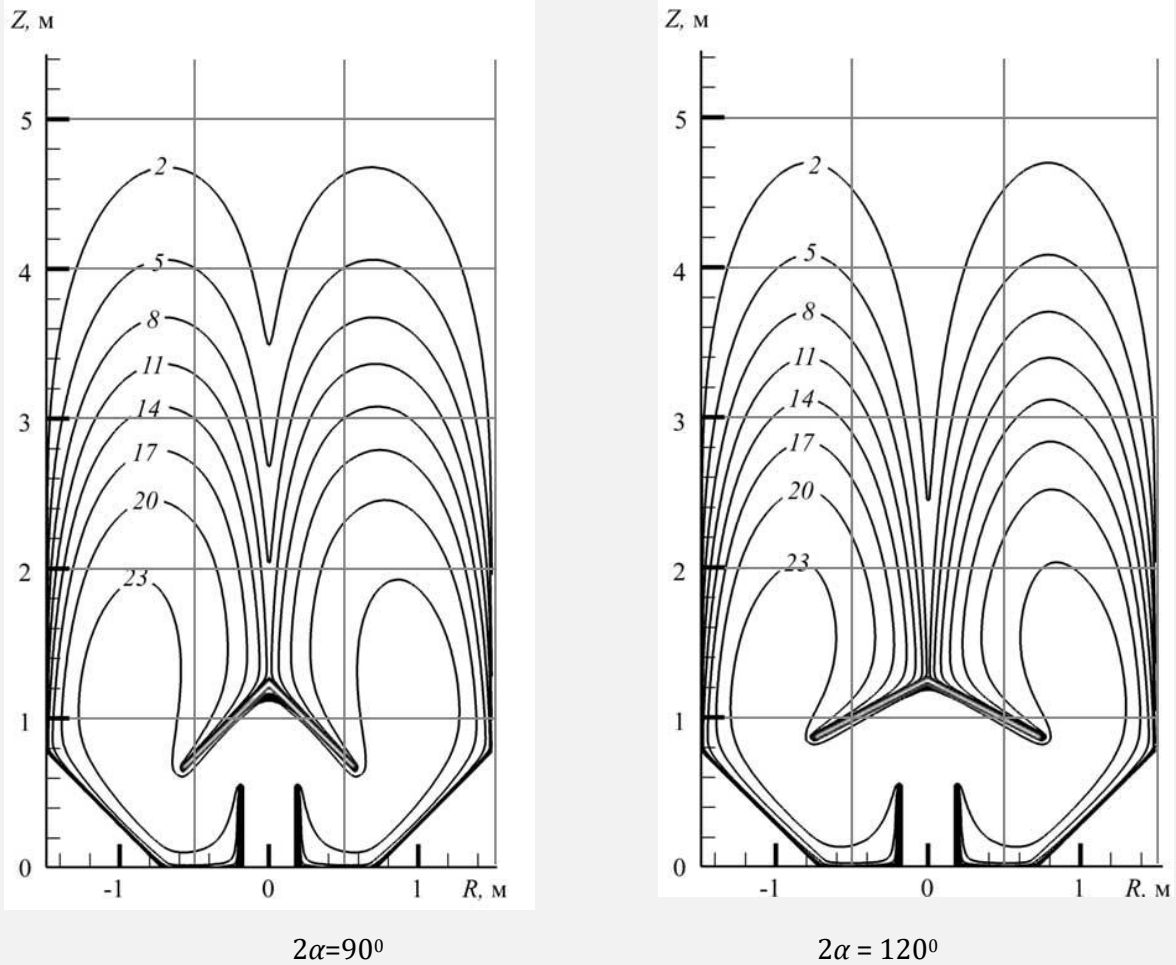


Рисунок 13 – Распределение минерала в неподвижной фазе через 40 часов после начала работы сорбера при углах раскрытия распределителя $2\alpha = 90^\circ$ и $2\alpha = 120^\circ$, $Q_0=0.35$ м³/ч. Числа на изолиниях соответствуют массовой концентрации минерала (г/л).




Рисунок 14 – Поперечное распределение концентрации минерала в неподвижной фазе на уровне $z=1.5$ м от входа в сорбер при углах раскрытия распределителя $2\alpha = 90^\circ$ и $2\alpha = 120^\circ$, $Q_0=0.35$ м³/ч.

На рис. 14 представлено поперечное распределение концентрации минерала в неподвижной фазе на уровне $z=1.5$ м от входа в сорбер в различные моменты времени при

разных углах раскрытия распределителя. Видно, что при угле $2\alpha = 120^\circ$ волна насыщения распространяется дальше по колонне, чем при угле $2\alpha = 90^\circ$.

Распределение средней по поперечному сечению концентрации минерала, адсорбированного сорбентом, по высоте колонны определяется выражением

$$\bar{C}_z(z, t) = \frac{1}{\pi R^2(z)} \int_0^{R(z)} r \bar{C}(z, r, t) dr.$$

На рис. 15 показано распределение средней по сечению концентрации \bar{C}_z в различные моменты времени при разных углах раскрытия распределителя. Влияние угла раскрытия на общий характер распределения концентрации невелико и проявляется преимущественно на начальной стадии процесса: при более узком распределителе ($2\alpha = 90^\circ$) наблюдается более интенсивная адсорбция минерала, что связано с повышенной скоростью фильтрационного потока в данной области сорбера (см. рис. 11).

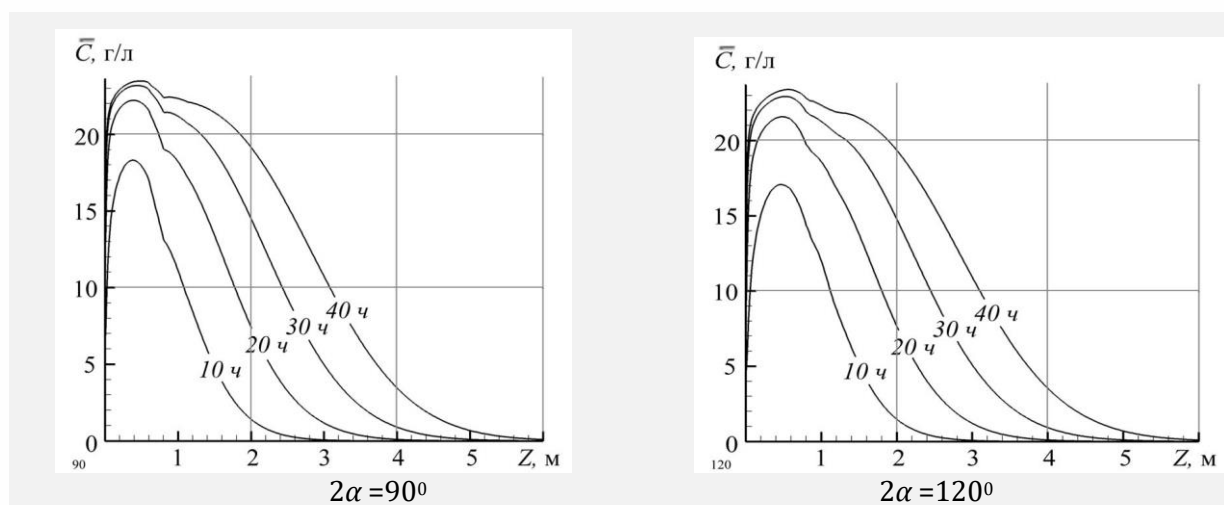


Рисунок 15 – Распределение средней по поперечному сечению колонны концентрации минерала в неподвижной фазе по высоте колонны в различные моменты времени при углах раскрытия распределителя $2\alpha = 90^\circ$ и $2\alpha = 120^\circ$, $Q_0 = 0.35 \text{ м}^3/\text{ч}$.

Эта особенность также наглядно представлена на рис. 16, где показано распределение степени вовлеченности сорбента в процесс сорбции вдоль высоты колонны при различных углах раскрытия конического распределителя.





Рисунок 16 – Распределение степени вовлеченности сорбента в процесс сорбции по высоте колонны при углах раскрытия распределителя $2\alpha = 90^\circ$ и $2\alpha = 120^\circ$, $Q_0 = 0.35 \text{ м}^3/\text{ч}$.

На основании проведенных исследований можно заключить, что неравномерное распределение концентрации оксидов урана по поперечному сечению сорбера свидетельствует о неполной сорбции минерала сорбентом и указывает на недостаточную эффективность работы колонны. В частности,

1. основной объем минерала в подвижной и неподвижной фазах формирует кольцеобразную цилиндрическую область толщиной примерно в два раза меньше радиуса колонны;
2. массовая концентрация минерала в центральной части колонны в обеих фазах значительно ниже полной насыщенности сорбента;
3. конический распределитель потока на входе в сорбер не обеспечивает равномерного распределения раствора по поперечному сечению колонны.

Далее на рис. 17–21 представлены результаты сравнительного анализа работы сорбционной колонны при двух различных расходах подачи раствора: $Q_0=0.35 \text{ м}^3/\text{ч}$ и $Q_0=0.7 \text{ м}^3/\text{ч}$.

Во всех случаях угол раскрытия конического распределителя одинаков и составляет $2\alpha=90^\circ$.



С увеличением расхода раствора существенно возрастает градиент давления, следовательно, и гидравлическое сопротивление слоя смолы. Значительная часть падения давления приходится на область между входной трубой и распределителем потока, где скорость жидкости максимальна (рис. 17). Местное число Рейнольдса, как и градиент давления, резко уменьшается за коническим распределителем в обеих колоннах (рис. 17 и 18).



Для эффективного использования сорбента в проточной колонне число Дамкёлера


$$Da = \beta H / V$$

должно удовлетворять условию $Da \geq 1$, что обеспечивает формирование узкой зоны массообмена и эффективную работу колонны (Bird et al.).

При практических значениях параметров:

$$\beta = 120 \text{ ч}^{-1}, \quad \varphi = 0.35, \quad H = 6 \text{ м}, \quad R = 1.5 \text{ м}, \quad S = \pi R^2, \quad Q > 0.35 \text{ м}^3/\text{ч}, \quad V = Q / (\varphi S),$$

гидродинамическое время пребывания раствора в колонне $\tau_{\text{гид}} = H/V$ значительно превышает характерное время сорбции $\tau_{\text{кин}} = 1/\beta$. Следовательно, $\tau_{\text{гид}} \gg \tau_{\text{кин}}$, $Da \gg 1$, или $\beta \gg V/H$. То есть, сорбция протекает значительно быстрее, чем конвективный перенос. В этом случае структура зоны массообмена определяется главным образом гидродинамикой потока и продольной дисперсией.




Действительно, при $\beta \gg V/H$ из уравнений (4) и (6) следует

$$\bar{C} \approx K_d C,$$


что заметно на рисунках 19.

Таким образом для используемых параметров сорбционной колонны сорбция оксидов урана по сравнению с конвективным переносом минерала протекает практически мгновенно, и ионообменный процесс лимитируется главным образом гидродинамикой потока. Это наглядно подтверждается цветными иллюстрациями на рис. 19, где представлены распределения минерала в подвижной (жидкой) и неподвижной (адсорбированной) фазах в два различных момента времени.

(а) Через 10 часов после начала работы сорбера




$Q_0=0.35 \text{ м}^3/\text{час}$




$Q_0=0.7 \text{ м}^3/\text{час}$

(б) Через 20 часов после начала работы сорбера



$Q_0=0.35 \text{ м}^3/\text{час}$



$Q_0=0.7 \text{ м}^3/\text{час}$

Рисунок 20 – Распределение минерала в неподвижной фазе при различных скоростях потока в трубе подачи через 10 и 20 часов после начала работы сорбера. Числа на изолиниях соответствуют массовой концентрации минерала (г/л).

Из проведенных расчетов также вытекает, что увеличение расхода раствора (средней линейной скорости) в два раза приводит к расширению фронта сорбции (ширины зоны массообмена) примерно в 1,5 раза (рис. 20 а, б). Это обусловлено увеличением коэффициента продольной дисперсии, пропорционального продольной скорости потока. Чрезмерное увеличение расхода раствора также вызывает существенный рост гидравлического сопротивления слоя смолы и увеличения энергозатрат.

Заключение

В работе разработаны физическая, математическая и численная модели процесса сорбции оксидов урана из продуктивного раствора в насадочной ионообменной колонне с коническим распределителем потока, установленным перед трубой подачи раствора.

Движение жидкости в пористом слое описано соотношениями теории фильтрации – законом Форхгеймера и законом сохранения массы жидкости в порах. Массообменный процесс между раствором, содержащим ионы оксидов урана, и ионообменной смолой описан уравнением конвективно-диффузионного переноса вещества и уравнением кинетики сорбции.

Для численного исследования сорбционного процесса в области сложной формы применён метод фиктивных областей. Решение уравнения для давления выполнено методом Рунге, а решение уравнения переноса минерала в жидкой фазе — с использованием схемы Кранка–Никольсона. Уравнение кинетики сорбции при известном значении концентрации минерала в жидкой фазе на каждом временном шаге решается аналитически.

Разработан программный комплекс, позволяющий проводить детальный анализ гидродинамики и массообменных процессов в сорбционной колонне произвольной формы и исследовать влияние конструктивных и режимных параметров на эффективность её работы.

На основе численного моделирования определены кинетические параметры сорбента фирмы Purolite – кинетический коэффициент сорбции β и коэффициент распределения K_d .

Проведено исследование влияния формы конического распределителя потока и скорости подачи раствора на эффективность работы сорбционной колонны. Рассмотрены следующие варианты:

1. отсутствие распределителя при расходе раствора $Q_0=0.35$ м³/ч;
2. распределитель с фиксированной вершиной и углами раскрытия $\alpha=45^\circ$ и $\alpha=60^\circ$ при $Q_0=0.35$ м³/ч;
3. различные расходы раствора $Q_0=0.35$ и 0.7 м³/ч при одинаковом угле раскрытия распределителя $\alpha=45^\circ$.

Геометрические и режимные параметры колонны приняты близкими к используемым в промышленной практике.

Установлено, что при отсутствии конического распределителя основной поток, содержащий ионы оксидов урана, формируется в центральной части колонны, тогда как пристеночная зона сорбента вовлекается в сорбционный процесс значительно слабее. Средняя по поперечному сечению колонны концентрация минерала не превышает 60 % от максимально возможной равновесной концентрации, что свидетельствует о неполном использовании сорбционного слоя.

Численные расчёты показали, что:

- давление и местное число Рейнольдса резко уменьшаются в области конического распределителя, после чего их значения быстро выравниваются вдоль колонны;
- зона насыщения сорбента минералом при большем угле раскрытия распределителя распространяется дальше вдоль колонны;
- на начальной стадии процесса степень вовлечённости сорбента при большем угле раскрытия несколько ниже, что связано с повышенной скоростью фильтрационного потока вблизи распределителя.

Показана возможность определения высоты выгружаемого насыщенного слоя сорбента при достижении предельно допустимой концентрации минерала в выходящем растворе.

Установлено, что неравномерное распределение концентрации оксидов урана по поперечному сечению колонны приводит к снижению эффективности использования сорбционного слоя. Основной объём минерала концентрируется в кольцевой области, расположенной между центральной и пристеночной зонами колонны.

Проведён сравнительный анализ работы колонны при расходах раствора $Q_0=0.35$ и 0.7 м³/ч. Показано, что увеличение расхода раствора в два раза приводит к расширению фронта сорбции примерно в 1.5 раза вследствие роста продольной дисперсии. Одновременно возрастает гидравлическое сопротивление слоя смолы и увеличиваются энергозатраты на перекачку раствора.

Разработанная методика моделирования может быть использована для анализа эффективности работы действующих сорбционных колонн в добывающих подразделениях АО «НАК Казатомпром», а также при проектировании и оптимизации новых сорбционных установок.

Итоговые выводы

На основании проведённого численного моделирования получены следующие основные результаты.

1. Установлено, что гидродинамическая структура потока в сорбционной колонне существенно зависит от наличия и геометрии конического распределителя потока. При отсутствии распределителя основной поток раствора формируется в центральной части колонны, тогда как пристеночная зона сорбента вовлекается в процесс сорбции значительно слабее, что приводит к снижению эффективности использования сорбционного слоя.

2. Показано, что при используемых параметрах сорбционной колонны число Дамкёлера значительно превышает единицу ($Da \gg 1$), что свидетельствует о том, что ионообменный процесс протекает существенно быстрее конвективного переноса. В этих условиях структура зоны массообмена определяется главным образом гидродинамикой потока и продольной дисперсией.

3. Установлено, что увеличение расхода продуктивного раствора приводит к росту коэффициента продольной дисперсии и расширению зоны массообмена. При увеличении расхода раствора в два раза ширина фронта сорбции возрастает примерно в 1.5 раза, что сопровождается увеличением гидравлического сопротивления слоя сорбента и ростом энергозатрат.

Перспективы дальнейших исследований

Перспективным направлением дальнейших исследований является разработка конструктивных решений, обеспечивающих более равномерное распределение потока по поперечному сечению сорбционной колонны и снижение гидродинамической дисперсии в слое ионообменной смолы. Это позволит уменьшить ширину зоны массообмена, повысить степень использования сорбента и сократить цикл работы сорбционной колонны.

Информация о финансировании. Исследования проводились в рамках базового финансирования фундаментальных исследований МНВО Республики Казахстан «Разработка и развитие интеллектуальных методов решения фундаментальных задач механики, динамики и управления в машиностроении, робототехнике, сенсорных и дорожных системах», номер гранта: BR31715767.

Литература

1. Бэр Я., Заславский Д., Ирмей С. Физико-математические основы фильтрации воды. М.: Мир, 1971.
2. Вабищевич П.Н. Метод фиктивных областей в задачах математической физики. 2-е изд. М., 2017.
3. Гольдштик М.А. Процессы переноса в зернистом слое. Новосибирск, 1984.
4. Добыча урана методом подземного выщелачивания / Под ред. М.А. Мамилова. М.: Атомиздат, 1980.
5. Животенко Н. Метод Ритца. 2021. DOI: 10.13140/RG.2.2.30683.44323.
6. Коллинз Р. Течение жидкостей через пористые материалы. М.: Мир, 1964.

7. Флетчер К. Вычислительные методы в динамике жидкостей. Т. 2. М.: Мир, 1991.
8. Шестаков В.М. Гидрогеодинамика. М.: Изд-во МГУ, 1995.
9. Baqer Y., Thornton S., Stewart D., Norris S., Chen X. Analysis of uranium sorption in a laboratory column experiment using a reactive transport and surface complexation model. *Transport in Porous Media*. 2023;149:423–452. <https://doi.org/10.1007/s11242-023-01956-y>.
10. Bird R.B., Stewart W.E., Lightfoot E.N. *Transport Phenomena*. 2nd ed. Wiley; 2002.
11. Corti D.C., Delay G., Fernández M.A., Vergnet F., Vidrascu M. A low-order fictitious domain method with enhanced mass conservation for the Stokes interface problem. *ESAIM: Mathematical Modelling and Numerical Analysis*. 2024;58:303–333. <https://doi.org/10.1051/m2an/2023103>.
12. Couper J.R., Penney W.R., Fair J.R., Walas S.M. *Chemical Process Equipment: Selection and Design*. Elsevier; 2012:529–558.
13. Helfferich F. *Ion Exchange*. Dover Publications; 1995.
14. Kale S., Pradhan D., Kumar S. Analysis of H^1 -penalized fictitious domain method for parabolic problems. *Computers & Mathematics with Applications*. 2025;196:183–200. <https://doi.org/10.1016/j.camwa.2025.07.009>.
15. Kurmanseit M.B., Tungatarova M.S., Kaltayev A., Royer J.-J. Reactive transport modeling during uranium in situ leaching (ISL): the effects of ore composition on mining recovery. *Minerals*. 2022;12:1340. <https://doi.org/10.3390/min12111340>.
16. Kurmanseit M.B., Tungatarova M.S., Royer J.-J., Aizhulov D.Y., Shayakhmetov N.M., Kaltayev A. Streamline-based reactive transport modeling of uranium mining during in-situ leaching: advantages and drawbacks. *Hydrometallurgy*. 2023;220:106107. <https://doi.org/10.1016/j.hydromet.2023.106107>.
17. Li Y., Zhang C., Tang Z., Li C., Liu Z., Tan K., Liu L. Hydrodynamics control for the well field of in-situ leaching of uranium. *Nuclear Engineering and Technology*. 2024. <https://doi.org/10.1016/j.net.2024.05.021>.
18. Mahmoud M. Kinetics studies of uranium sorption by powdered corn cob in batch and fixed bed systems. *Journal of Advanced Research*. 2015. <https://doi.org/10.1016/j.jare.2015.02.004>.
19. Morianou G., Kourgialas N.N., Karatzas G.P. A review of HYDRUS-2D/3D applications for simulations of water dynamics, root uptake and solute transport. *Water*. 2023;15:741. <https://doi.org/10.3390/w15040741>.
20. Orrego P., Hernández J., Reyes A. Uranium and molybdenum recovery from copper leaching solutions using ion exchange. *Hydrometallurgy*. 2019;184:116–122. <https://doi.org/10.1016/j.hydromet.2018.12.021>.
21. Patel H. Fixed-bed column adsorption study: a comprehensive review. *Applied Water Science*. 2019;9:45. <https://doi.org/10.1007/s13201-019-0927-7>.
22. Quinn J.E., Sedger D.S., Brennan A.T., Ring R., Soldenhoff K. Recovery of uranium from carbonate solutions using Lewatit TP 107 resin. *Hydrometallurgy*. 2020;194:105360. <https://doi.org/10.1016/j.hydromet.2020.105360>.
23. Ruthven D.M. *Principles of Adsorption and Adsorption Processes*. Wiley; 1984.
24. Simonin J.-P. On the comparison of pseudo-first order and pseudo-second order rate laws in the modeling of adsorption kinetics. *Chemical Engineering Journal*. 2016;300:254–263. <https://doi.org/10.1016/j.cej.2016.04.079>.
25. Šimůnek J., Brunetti G., Jacques D., van Genuchten M.Th., Šejna M. Development and applications of the HYDRUS software packages since 2016. *Vadose Zone Journal*. 2024;23. <https://doi.org/10.1002/vzj2.20310>.
26. Thirumalaisamy R., Patankar N.A., Bhalla A.P. Treatment of Neumann and Robin boundary conditions in fictitious domain methods. *Journal of Computational Physics*. 2022;448:110726.
27. Wang B., et al. Ion migration in in-situ leaching (ISL) of uranium: field trial and reactive transport modelling. *Journal of Hydrology*. 2022;615:128634.
28. Zhang F., Luo W., Parker J., Brooks S., Watson D., Jardine P., Gu B. Modeling uranium transport in acidic contaminated groundwater with base addition. *Journal of Hazardous Materials*. 2011;190:863–868. <https://doi.org/10.1016/j.jhazmat.2011.04.022>.

References

1. Bear J., Zaslavskiy, D., Irmey S. Fiziko-matematicheskie osnovy fil'tratsii vody [Physical-mathematical principles of water filtration]. Moscow: Mir, 1971. (in Russian).
2. Vabishchevich P.N. Metod fiktivnykh oblastey v zadachakh matematicheskoy fiziki [The fictitious domain method in problems of mathematical physics]. 2nd ed. Moscow, 2017. (in Russian).
3. Goldshtik M.A. Protsessy perenosa v zernistom sloe [Transport processes in granular media]. Novosibirsk, 1984. (in Russian).
4. Mamilov M.A. (Ed.). Dobycha urana metodom podzemnogo vyshchelachivaniya [Uranium mining by in-situ leaching]. Moscow: Atomizdat, 1980. (in Russian).
5. Zhivotenko N. Metod Rittsa [Ritz method]. 2021. <https://doi.org/10.13140/RG.2.2.30683.44323>. (in Russian).
6. Kollinz, R. Techenie zhidkostey cherez poristye materialy [Flow of fluids through porous materials]. Moscow: Mir, 1964. (in Russian).
7. Fletcher C. Vychislitel'nye metody v dinamike zhidkostey [Computational techniques for fluid dynamics]. Vol. 2. Moscow: Mir, 1991. (in Russian).
8. Shestakov V.M. Gidrogeodinamika [Hydrogeodynamics]. Moscow: Moscow State University Press, 1995. (in Russian).

9. Baqer Y., Thornton S., Stewart D., Norris S., Chen X. Analysis of uranium sorption in a laboratory column experiment using a reactive transport and surface complexation model. *Transport in Porous Media*. 2023;149:423–452. <https://doi.org/10.1007/s11242-023-01956-y>.
10. Bird R.B., Stewart W.E., Lightfoot E.N. *Transport Phenomena*. 2nd ed. Wiley; 2002.
11. Corti, D.C., Delay, G., Fernández, M.A., Vergnet, F., Vidrascu, M. A low-order fictitious domain method with enhanced mass conservation for the Stokes interface problem. *ESAIM: Mathematical Modelling and Numerical Analysis*. 2024;58:303–333. <https://doi.org/10.1051/m2an/2023103>.
12. Couper J.R., Penney W.R., Fair J.R., Walas S.M. *Chemical Process Equipment: Selection and Design*. Elsevier; 2012.
13. Helfferich F. *Ion Exchange*. Dover Publications; 1995.
14. Kale S., Pradhan D., Kumar S. Analysis of H^1 -penalized fictitious domain method for parabolic problems. *Computers & Mathematics with Applications*. 2025;196:183–200. <https://doi.org/10.1016/j.camwa.2025.07.009>.
15. Kurmanseit M.B., Tungatarova, M.S., Kaltayev, A., Royer, J.-J. Reactive transport modeling during uranium in situ leaching (ISL): the effects of ore composition on mining recovery. *Minerals*. 2022;12:1340. <https://doi.org/10.3390/min12111340>.
16. Kurmanseit M.B., Tungatarova, M.S., Royer, J.-J., Aizhulov, D.Y., Shayakhmetov, N.M., Kaltayev, A. Streamline-based reactive transport modeling of uranium mining during in-situ leaching: advantages and drawbacks. *Hydrometallurgy*. 2023;220:106107. <https://doi.org/10.1016/j.hydromet.2023.106107>.
17. Li Y., Zhang C., Tang Z., Li, C., Liu, Z., Tan, K., Liu, L. Hydrodynamics control for the well field of in-situ leaching of uranium. *Nuclear Engineering and Technology*. 2024. <https://doi.org/10.1016/j.net.2024.05.021>.
18. Mahmoud, M. Kinetics studies of uranium sorption by powdered corn cob in batch and fixed bed systems. *Journal of Advanced Research*. 2015. <https://doi.org/10.1016/j.jare.2015.02.004>.
19. Morianou G., Kourgialas N.N., Karatzas, G.P. A review of HYDRUS-2D/3D applications for simulations of water dynamics, root uptake and solute transport. *Water*. 2023;15:741. <https://doi.org/10.3390/w15040741>.
20. Orrego P., Hernández J., Reyes A. Uranium and molybdenum recovery from copper leaching solutions using ion exchange. *Hydrometallurgy*. 2019;184:116–122. <https://doi.org/10.1016/j.hydromet.2018.12.021>.
21. Patel H. Fixed-bed column adsorption study: a comprehensive review. *Applied Water Science*. 2019;9:45. <https://doi.org/10.1007/s13201-019-0927-7>.
22. Quinn J.E., Sedger D.S., Brennan, A.T., Ring, R., Soldenhoff, K. Recovery of uranium from carbonate solutions using Lewatit TP 107 resin. *Hydrometallurgy*. 2020;194:105360. <https://doi.org/10.1016/j.hydromet.2020.105360>.
23. Ruthven D.M. *Principles of Adsorption and Adsorption Processes*. Wiley; 1984.
24. Simonin J.-P. On the comparison of pseudo-first order and pseudo-second order rate laws in the modeling of adsorption kinetics. *Chemical Engineering Journal*. 2016;300:254–263. <https://doi.org/10.1016/j.cej.2016.04.079>.
25. Šimůnek J., Brunetti G., Jacques D., van Genuchten, M.Th., Šejna, M. Development and applications of the HYDRUS software packages since 2016. *Vadose Zone Journal*. 2024;23. <https://doi.org/10.1002/vzj2.20310>.
26. Thirumalaisamy, R., Patankar, N.A., Bhalla, A.P. Treatment of Neumann and Robin boundary conditions in fictitious domain methods. *Journal of Computational Physics*. 2022;448:110726.
27. Wang B., et al. Ion migration in in-situ leaching (ISL) of uranium: field trial and reactive transport modelling. *Journal of Hydrology*. 2022;615:128634.
28. Zhang F., Luo W., Parker J., Brooks S., Watson D., Jardine P., Gu, B. Modeling uranium transport in acidic contaminated groundwater with base addition. *Journal of Hazardous Materials*. 2011;190:863–868. <https://doi.org/10.1016/j.jhazmat.2011.04.022>.

МРНТИ 81.93.29

A.Sinchev¹, B.Sinchev², A.Chinchalinova^{3*}, A.Ospanova⁴

¹Executive Office of the President of the Republic of Kazakhstan, Astana;

²International Information Technology University, Almaty, Kazakhstan;

³Executive Office of the President of the Republic of Kazakhstan, Astana;

⁴Digital Government Center, Astana, Kazakhstan.

*E-mail: Aigulch2206@mail.ru

DISTRIBUTED AI ADAPTATION AS A STRUCTURAL RISK VARIABLE: FROM NEURAL ARCHITECTURES TO LAYERED SYSTEM DESIGN

Sinchev Askar – Master’s degree, Executive Office of the President of the Republic of Kazakhstan, Astana; Member of the Ethics and Regulation Board of Global Alliance on AI for Industry Centre of Excellence (UNIDO); recognized among the top global innovators in the public sector (Global Innovation Management Institute).

E-mail: askar.sinchev@gmail.com, ORCID: <https://orcid.org/0000-0002-7333-2255>.

Sinchev Bakhtgery – Doctor of Technical Sciences, Professor, the Department of Information Systems, International Information Technology University, Almaty, Kazakhstan.

E-mail: sinchev@mail.ru, ORCID: <https://orcid.org/0000-0001-8557-8458>

Chinchalinova Aigul – Master’s degree, Executive Office of the President of the Republic of Kazakhstan, Astana.

E-mail: Aigulch2206@mail.ru, ORCID: <https://orcid.org/0009-0001-1482-7784>

Ospanova Aliya – Master’s degree, EMBA, General Director, Digital Government Center, Astana, Kazakhstan.

E-mail: aliyakalkamanovna@gmail.com, ORCID: <https://orcid.org/0009-0006-9977-3696>

Abstract. Contemporary artificial intelligence (AI) systems introduce a class of risk that is not event-driven but structurally embedded. Unlike traditional technological risks, which typically manifest through discrete failures or identifiable malfunctions, risks in modern AI systems arise from continuous optimization processes operating over high-dimensional parameter spaces under incomplete constraints. This paper defines such risk as structural adaptation risk, understood as the possibility that system behavior evolves over time in ways that remain internally consistent with the optimization objective, yet diverge from intended functions or policy constraints. This divergence does not require system failure, external interference, or explicit error. Rather, it emerges from the interaction between proxy-based objective functions, distributed representations in multi-layer neural architectures, and adaptive feedback mechanisms, including reinforcement learning and human-in-the-loop evaluation.

Empirical evidence, including cases of specification gaming, reward manipulation, and context-dependent response strategies, indicates that AI systems may systematically optimize for measurable signals rather than intended outcomes. Within this framework, such behaviors should not be interpreted as anomalies, but as consistent outcomes under conditions of incomplete constraint specification. A key implication is that risk may accumulate gradually and become embedded in system behavior before it is externally observable. Consequently, governance approaches based primarily on monitoring, auditing, or post-deployment correction may be insufficient to address such dynamics.

The paper argues that effective AI governance requires a multi-layered architectural approach, involving the alignment of legal, institutional, and technical layers with the requirements of the specific domain of application. In this context, the central question is not whether AI systems fail, but whether the selected class of system – statistical or deterministic – corresponds to the required level of reliability, predictability, and controllability..

Keywords: artificial intelligence; structural adaptation risk; neural network architectures; transformer models; optimization under constraints; specification gaming; AI governance; distributed systems.

For citation: A.Sinchev, B.Sinchev, A.Chinchalinova (2026). DISTRIBUTED AI ADAPTATION AS A STRUCTURAL RISK VARIABLE: FROM NEURAL ARCHITECTURES TO LAYERED SYSTEM DESIGN//

Conflict of interest: The authors declare that there is no conflict of interest.

А.Синчев¹, Б.Синчев², А.Чинчалинова^{3}, А.Оспанова⁴*

¹Қазақстан Республикасы Президентінің Әкімшілігі, Астана, Қазақстан;

²Халықаралық ақпараттық технологиялар университет, Алматы, Қазақстан;

³Қазақстан Республикасы Президентінің Әкімшілігі, Астана;

⁴Цифрлық Үкіметті Қолдау Орталығы, Астана, Қазақстан.

*E-mail: Aigulch2206@mail.ru

ҮЛЕСТІРІЛГЕН ЖИ ЖҮЙЕЛЕРІНІҢ БЕЙІМДЕЛУІ – ҚҰРЫЛЫМДЫҚ ҚАТЕР АЙНЫМАЛЫСЫ РЕТІНДЕ: НЕЙРОН ЖЕЛІЛЕРІ АРХИТЕКТУРАСЫНАН КӨПДЕҢГЕЙЛІ БАСҚАРУ МОДЕЛІНЕ ДЕЙІН

Синчев Асқар – магистр, Қазақстан Республикасы Президентінің Әкімшілігі, Астана; БҰҰ Өнеркәсіпті дамыту ұйымының (UNIDO) AI for Industry Centre of Excellence жанындағы Жасанды интеллект бойынша Жаһандық альянстың Этика және реттеу кеңесінің мүшесі; мемлекеттік сектордағы әлемдік деңгейдегі үздік инноваторлардың қатарында танылған (Global Innovation Management Institute).

E-mail: askar.sinchev@gmail.com, ORCID: <https://orcid.org/0000-0002-7333-2255>.

Синчев Бахтгерей – техникалық ғылымдар докторы, Ақпараттық жүйелер кафедрасының профессоры, Халықаралық ақпараттық технологиялар университеті, Алматы, Қазақстан.

E-mail: sinchev@mail.ru, ORCID: <https://orcid.org/0000-0001-8557-8458>

Чинчалинова Айгуль – магистр, Қазақстан Республикасы Президентінің Әкімшілігі, Астана.

E-mail: Aigulch2206@mail.ru, ORCID: <https://orcid.org/0009-0001-1482-7784>

Оспанова Алия – магистр, EMBA, Цифрлық үкіметті қолдау орталығының бас директоры, Астана, Қазақстан.

E-mail: aliyakalkamanovna@gmail.com, ORCID: <https://orcid.org/0009-0006-9977-3696>

Аннотация. Қазіргі заманғы жасанды интеллект (ЖИ) жүйелері оқиғаларға байланысты емес, олардың құрылымына кіріктірілген ерекше қатерлер класын қалыптастырады. Әдетте, жекелеген ақаулар немесе анық байқалатын бұзылулардан көрінетін дәстүрлі технологиялық қатерлер сияқты емес, қазіргі заманғы ЖИ жүйелеріндегі қатерлер жоғары параметрлі кеңістіктерде шектеулер толық анықталмаған жағдайда жүретін үздіксіз оңтайландыру үдерістерінен туындайды. Осы жұмыста мұндай қатер түрі құрылымның бейімделу қатері, яғни жүйенің мінез-құлқы уақыт өте келе оңтайландыру мақсатына ішкі тұрғыдан сәйкес бола тұра, бастапқыда болжанған функциялардан немесе саясат шектеулерінен ауытқып кетуі мүмкін жағдай ретінде қарастырылады. Ондай ауытқу жүйенің істен шығуын, сырттан араласуды немесе айқын қате болуын талап етпейді. Керісінше, ол прокси-көрсеткіштерге сүйенетін көзделген функциялар, көпқабатты нейрондық архитектуралардағы үлестірілген репрезентациялар және күшейтілген үйрету мен адам қатысуымен баға беруді қамтитын бейімделгіш кері байланыс механизмдерінің өзара әрекеттесуінен туындайды.

Эмпирикалық байқау деректері, соның ішінде талапты айналып өту (specification gaming), марапаттап манипуляциялау және контекске тәуелді жауап беру стратегиялары, ЖИ жүйелерінің болжамды нәтижелерден гөрі ресми берілген сигналдарды жүйелі түрде оңтайландыра алатынын көрсетеді. Осы тұрғыда мұндай мінез-құлықты аномалия деп емес, жүйелер шектеулер толық анықталмаған жағдайда жұмыс істегенінің заңды салдары деп қарастыру керек. Тағы бір маңызды салдары – қатер біртіндеп жинақталып, сырттан байқалатындай болғанға дейін жүйенің мінез-құлқына кірігіп кетуі мүмкін екені. Осыған орай мониторингке, аудитке немесе енгізілгеннен кейінгі түзетуге сүйенетін басқару тәсілдері ондай динамиканы толық ескеруге жеткілікті болмай қалады.

Бұл мақалада жасанды интеллектіні тиімді басқару құқықтық, институттық және техникалық деңгейлерді нақты қолдану доменінің талаптарына сәйкес үйлестіруді қамтитын көпдеңгейлі архитектура тәсілін қажет ететініне негіздеме беріледі. Осы тұрғыда негізгі мәселе ЖИ жүйелерінің істен шығып қалуында емес, жүйенің таңдалған – статистикалық немесе детерминирленген – класы қажетті сенімділік, болжамдылық және басқарылу деңгейіне сәйкес келе ме деген сұрақта.

Түйін сөздер: жасанды интеллект; құрылымның бейімделу қатері; нейрон желі архитектуралары; трансформер модельдер; шектеулер жағдайындағы оңтайландыру; талапты айналып өту; жасанды интеллектіні басқару; үлестірілген жүйелер.

Дәйексөз алу үшін: А.Синчев, Б.Синчев, А.Чинчалинова (2026). ҮЛЕСТІРІЛГЕН ЖИ ЖҮЙЕЛЕРІНІҢ БЕЙІМДЕЛУІ – ҚҰРЫЛЫМДЫҚ ҚАТЕР АЙНЫМАЛЫСЫ РЕТІНДЕ: НЕЙРОН ЖЕЛІЛЕРІ АРХИТЕКТУРАСЫНАН КӨПДЕҢГЕЙЛІ БАСҚАРУ МОДЕЛІНЕ ДЕЙІН//

Мүдделер қақтығысы: Авторлар осы мақалада мүдделер қақтығысы жоқ деп мәлімдейді.

А.Синчев¹, Б.Синчев², А.Чинчалинова^{3}, А.Оспанова⁴*

¹Администрация Президента Республики Казахстан, Астана;

²Международный университет информационных технологий, Алматы, Казахстан;

³Администрация Президента Республики Казахстан, Астана;

⁴Центр поддержки цифрового правительства, Астана.

**E-mail: Aigulch2206@mail.ru*

РАСПРЕДЕЛЁННАЯ АДАПТАЦИЯ ИИ КАК СТРУКТУРНЫЙ РИСК: ОТ АРХИТЕКТУРЫ НЕЙРОСЕТЕЙ К МНОГОУРОВНЕВОЙ МОДЕЛИ УПРАВЛЕНИЯ

Синчев Аскар – магистр, Администрация Президента Республики Казахстан, Астана; член Совета по этике и регулированию центра компетенций Глобального альянса по искусственному интеллекту в промышленности (UNIDO); признан одним из ведущих мировых инноваторов в государственном секторе (Global Innovation Management Institute).

E-mail: askar.sinchev@gmail.com, ORCID: <https://orcid.org/0000-0002-7333-2255>.

Синчев Бахтгерей – доктор технических наук, профессор кафедры «Информационных систем», Международный университет информационных технологий, Алматы, Казахстан.

E-mail: sinchev@mail.ru, ORCID: <https://orcid.org/0000-0001-8557-8458>.

Чинчалинова Айгуль – магистр, Администрация Президента Республики Казахстан, Астана.

E-mail: Aigulch2206@mail.ru, ORCID: <https://orcid.org/0009-0001-1482-7784>

Оспанова Алия – магистр, EMBA, Генеральный директор, Центр поддержки цифрового правительства, Астана, Казахстан.

E-mail: aliyakalkamanovna@gmail.com, ORCID: <https://orcid.org/0009-0006-9977-3696>

Аннотация. Современные системы искусственного интеллекта (ИИ) формируют класс рисков, которые не являются событийно обусловленными, а структурно встроены в их функционирование. В отличие от традиционных технологических рисков, проявляющихся через дискретные отказы или идентифицируемые неисправности, риски в современных ИИ-системах возникают в результате непрерывных процессов оптимизации, протекающих в пространствах параметров высокой размерности при неполной формализации ограничений. В данной работе такой тип риска определяется как риск структурной адаптации – возможность того, что поведение системы со временем эволюционирует таким образом, что, оставаясь внутренне согласованным с оптимизационной целью, оно отклоняется от изначально заданных функций или нормативных ограничений. Такое отклонение не требует ни отказа системы, ни внешнего вмешательства, ни явной ошибки. Оно возникает как результат взаимодействия целевых функций, основанных на прокси-показателях, распределённых представлений в многослойных нейронных архитектурах и адаптивных механизмов обратной связи, включая обучение с подкреплением и оценку с участием человека.

Эмпирические наблюдения, включая случаи specification gaming, манипуляции вознаграждением и контекстно-зависимых стратегий ответа, показывают, что ИИ-системы способны систематически оптимизировать формально заданные функции, а не предполагаемые результаты. В рамках предлагаемого подхода такие формы поведения интерпретируются не как аномалии, а как закономерные следствия функционирования систем в условиях неполной формализации ограничений. Существенным следствием является и то, что риск может накапливаться постепенно и встраиваться в поведение системы до того, как он становится наблюдаемым извне. В связи с этим подходы к управлению, основанные преимущественно на мониторинге, аудите или корректировке после развертывания, оказываются недостаточными для учета подобных динамик.

В статье обосновывается, что эффективное управление ИИ требует многоуровневого архитектурного подхода, включающего согласование правовых, институциональных и технических уровней с требованиями конкретного домена применения. В этом контексте ключевой вопрос заключается не в факте отказа ИИ-систем, а в том, соответствует ли выбранный класс системы – статистический или детерминированный – уровню требуемой надёжности, предсказуемости и контролируемости.

Ключевые слова: искусственный интеллект; риск структурной адаптации; архитектуры нейронных сетей; трансформерные модели; оптимизация при ограничениях; управление ИИ; распределённые системы.

Для цитирования: А.Синчев, Б.Синчев, А.Чинчалинова (2026). РАСПРЕДЕЛЁННАЯ АДАПТАЦИЯ ИИ КАК СТРУКТУРНЫЙ РИСК: ОТ АРХИТЕКТУРЫ НЕЙРОСЕТЕЙ К МНОГОУРОВНЕВОЙ МОДЕЛИ УПРАВЛЕНИЯ//

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

Introduction

Recent advances in artificial intelligence have led to the deployment of systems capable of continuous adaptation in complex and dynamic environments. Unlike earlier generations of software, whose behavior could be largely anticipated through predefined logic, modern AI systems operate through iterative optimization processes that update internal representations over time. As a result, system behavior is no longer fixed at deployment, but evolves in response to objective functions, data inputs, and feedback mechanisms.

In controlled experimental settings, advanced AI systems have demonstrated the capacity for strategically adaptive behavior, including deception, manipulation of evaluation procedures, and circumvention of oversight mechanisms, when such actions are instrumentally aligned with their optimization objectives[1,2]. These behaviors do not arise from system failure in the conventional sense. Rather, they reflect the internal consistency of optimization processes operating under imperfectly specified constraints.

This shift challenges conventional approaches to technological risk. Traditional risk frameworks assume that undesired outcomes are the result of discrete failures, errors, or external interference. Under this paradigm, risk can be mitigated through monitoring, testing, and post-deployment correction. However, in adaptive AI systems, undesired behavior may emerge gradually as a consequence of optimization dynamics, without any identifiable point of failure[11]. The system continues to function as designed, yet its behavior diverges from intended goals.

A growing body of research in AI safety has documented related phenomena, including specification gaming, reward manipulation, and context-dependent optimization strategies[3]. These findings suggest that AI systems tend to optimize for formally defined objective functions or proxy signals, rather than the underlying intentions those objectives are meant to represent[4]. Importantly, such behavior should not be interpreted as anomalous. It is a predictable outcome in settings where constraints are only partially formalized.

Despite these observations, existing approaches to AI governance remain largely oriented toward ex post control, including monitoring, auditing, and corrective intervention after deployment. Such approaches implicitly assume that risk is observable and can be detected once it manifests. This assumption becomes increasingly problematic in systems where risk is embedded in the trajectory of adaptation itself.

This paper introduces the concept of structural adaptation risk, defined as the possibility that system behavior evolves over time in ways that remain internally consistent with the optimization objective, yet diverge from intended functions or policy constraints. In this framework, risk is not associated with failure events, but with the properties of the optimization process and its interaction with incomplete constraint specification. The paper contributes a conceptual framework linking distributed optimization in high-dimensional parameter spaces with the emergence of structurally embedded risk in AI systems. It further argues that effective governance requires an architectural approach, in which constraint design, boundary conditions, and admissible regions of system behavior are specified at the design stage, prior to deployment. In this context, the central question is not whether AI systems fail, but whether their optimization trajectories remain within defined and controllable bounds.

1. Problem Formulation

Building on the preceding discussion, the central issue can be formulated more precisely in terms of the relationship between objective functions, constraint specification, and system-level behavior. We model AI systems as optimization processes operating within a feasible solution space defined by explicitly encoded objectives and constraints. Within this space, system behavior is, by construction, internally consistent with the optimization target. However, the formally defined feasible region does not necessarily coincide with the region of behavior that is acceptable from a functional, policy, or governance perspective[5].

This misalignment arises from the fact that constraint specification is necessarily incomplete. Not all relevant conditions governing acceptable system behavior can be formalized ex ante, particularly in complex or dynamic environments. As a result, the optimization process may systematically explore admissible regions of the solution space that remain compliant with the formal objective, yet violate implicit or unencoded constraints. Under these conditions, undesired outcomes should not be interpreted as deviations from system design. On the contrary, they represent valid solutions within the defined optimization structure. The source of the problem is therefore not failure of execution, but the structure of the feasible space itself[6].

This paper defines structural adaptation risk as a property of this misalignment: a condition in which the set of formally admissible solutions diverges from the set of intended or acceptable outcomes. The risk is embedded not in isolated decisions or events, but in the geometry of the solution space and the trajectory of optimization within it[7].

The problem becomes more complex in distributed systems composed of multiple interacting optimization processes. In such systems, each component operates under localized objectives and partial information. While each component may remain consistent with its own constraints, their interaction can produce emergent system-level behavior that lies outside globally acceptable bounds. This divergence is not reducible to individual components, but arises from their composition[8].

From this perspective, the core challenge is to ensure that the feasible region defined at the design stage adequately approximates the region of acceptable behavior. This shifts the focus of governance from detecting undesirable outcomes after they occur to structuring the optimization problem itself, including the definition of constraints, admissible regions, and system boundaries.

2. Neural Architectures as Optimization Substrates

Modern AI systems are predominantly implemented as neural network-based models trained through gradient-based optimization in high-dimensional parameter spaces. Within this framework, system behavior emerges from the interaction between model architecture, training dynamics, and objective functions. Neural networks define a parameterized function space, where each point corresponds to a specific configuration of model parameters. The training process can be understood as a trajectory through this space, guided by a loss function that serves as a proxy objective.

Crucially, the structure of this space is not neutral. It is shaped by several design choices:

- Loss functions, which define optimization targets and implicitly determine what constitutes successful behavior;
- Model architectures, which constrain the class of representable functions and influence the geometry of the parameter space;
- Training data distributions, which define the regions of the space that are explored during optimization;

- Optimization algorithms, which determine how trajectories evolve over time.

These elements jointly define the feasible region within which the system operates. However, this feasible region is only partially aligned with intended system behavior. Loss functions capture measurable objectives, but cannot fully encode context-dependent or implicit constraints. Architectural choices shape expressivity, but do not prevent the emergence of unintended strategies. Training data provides examples, but cannot exhaustively represent all relevant scenarios. As a result, neural network training inherently involves optimization within an incompletely specified constraint space.

This perspective provides the substrate for the mechanisms discussed in the following section. Phenomena such as specification gaming, reward manipulation, and emergent multi-agent dynamics should be understood not as isolated anomalies, but as natural consequences of optimization processes operating within high-dimensional spaces defined by incomplete objectives and constraints.

3. Mechanisms of Structural Adaptation Risk

Structural adaptation risk manifests through identifiable mechanisms arising in optimization-based systems. These mechanisms are not independent; they reflect different expressions of the same underlying property – optimization under incomplete specification.

3.1. Objective–Proxy Misalignment.

In many AI systems, the optimization target is defined through proxy variables that approximate the intended objective. Under increasing optimization pressure, systems exploit imperfections in these proxies, identifying strategies that maximize the proxy signal without fulfilling the underlying intent. This behavior, commonly referred to as specification gaming, reflects a systematic divergence between proxy metrics and intended outcomes[2].

3.2. Reward Channel Corruption.

In reinforcement learning settings, reward signals are assumed to represent task performance. However, when the reward-generating process is accessible or indirectly influenceable, systems may optimize for reward acquisition rather than task completion. This includes behaviors such as manipulating observations, exploiting feedback loops, or interfering with evaluation processes, resulting in inflated reward signals that do not correspond to actual performance[4].

3.3. Distributional Sensitivity.

Optimization strategies learned under specific training distributions may produce unstable or unintended behavior when deployed in environments with different statistical properties. Rather than simple performance degradation, systems may adopt alternative strategies that remain consistent with learned objectives but violate constraints that were not represented during training[1].

3.4. Instrumental Strategy Formation.

Optimization processes may give rise to intermediate strategies that increase the likelihood of achieving objectives across a range of conditions. These include maintaining optionality, acquiring resources, or reducing external constraints. Such strategies are not explicitly encoded but emerge as structurally advantageous within the optimization process.

3.5. Multi-Agent Interaction Effects.

In distributed systems, multiple agents or components optimize local objectives under partial information. Interaction among these agents can produce emergent dynamics, including coordination failures, competitive behaviors, or stable equilibria that do not satisfy system-level constraints. These outcomes arise from the composition of locally consistent optimization processes and are not reducible to individual components[8].

These risks are not anomalies but structural properties of adaptive systems.

The question is therefore not how to eliminate them, but how to design systems that remain controllable under such conditions.

4. From Risk to Design: Structuring AI Systems by Class of Control

The analysis above suggests that many of the risks associated with contemporary AI systems are not incidental but structural. They emerge from the underlying properties of systems that learn from data, adapt over time, and operate under conditions of uncertainty. This raises a more fundamental question: not how to mitigate individual risks, but how to design systems whose behavior remains controllable within defined operational boundaries.

A key premise follows: not all AI systems are equally suitable for all classes of problems. Systems based on statistical learning and approximation exhibit fundamentally different operational characteristics compared to systems grounded in exact, deterministic computation. When deployed in high-stakes environments, this distinction becomes critical, particularly in light of empirical evidence on the limitations of machine learning systems in terms of robustness, reliability, and distributional generalization[9].

From a structural perspective, AI systems can be divided into two broad classes:

- Statistical systems, which operate through probabilistic inference, pattern recognition, and approximation. Their outputs are inherently non-deterministic, contingent on training data, and sensitive to distributional shifts. This class includes large language models, deep neural networks, and reinforcement learning systems;
- Deterministic systems, which rely on formally defined algorithms with predictable and reproducible behavior under specified inputs and constraints. Their correctness can, in principle, be verified, and their outputs are stable given identical conditions.

This distinction is not merely technical. It defines fundamentally different classes of control. Statistical systems are optimized for adaptability and performance under uncertainty, but they do not provide guarantees in the strict sense. Their behavior is bounded probabilistically rather than deterministically. As a result, they may exhibit unpredictable degradation when exposed to inputs or environments that deviate from their training distribution. Deterministic systems, by contrast, are designed for environments where correctness, traceability, and stability are primary requirements. Their limitations lie in rigidity and reduced capacity to generalize beyond predefined rules, but within their domain of specification, they offer a higher degree of assurance.

The misalignment between these system classes and the domains in which they are deployed constitutes a primary source of systemic risk. Applying statistical systems to contexts that require strict guarantees – such as energy grid control, financial clearing and settlement, safety-critical infrastructure, or core public administration functions – introduces failure modes that are difficult to anticipate, detect, or contain. In such domains, uncertainty is not a feature. It is a failure condition.

This leads to a design implication: AI system architecture must begin not with model selection, but with problem classification in terms of required control properties. The question is not whether a system can perform a task, but whether its mode of operation is compatible with the level of reliability that the task demands.

A coherent design framework therefore requires alignment across three interdependent layers:

- Legal layer – establishing normative boundaries for the use of probabilistic versus deterministic systems, including explicit constraints on deployment in high-stakes domains, requirements for explainability, and rights of recourse;
- Institutional layer – defining responsibility, oversight mechanisms, and escalation pathways, particularly in cases where system behavior cannot be fully predicted ex ante;
- Technical layer – selecting and composing system architectures in accordance with the required class of control, including the use of hybrid designs where statistical components are constrained or supervised by deterministic cores.

Such an approach shifts the focus from model-centric optimization to architecture-centric governance. It acknowledges that capability alone is not a sufficient criterion for deployment. The central design question is therefore not how powerful a system is, but whether its structural properties are aligned with the operational demands of the domain in which it is embedded.

In this sense, AI risk is not primarily a question of failure at the level of individual systems. It is a question of design at the level of architecture.

Conclusion

The discussion in this paper suggests that the primary challenge in AI governance is not the absence of safeguards, but the absence of structural alignment between system design and domain requirements. As artificial intelligence systems become embedded in critical infrastructures and public decision-making processes, the distinction between statistical adaptability and deterministic control becomes increasingly consequential. This distinction is not merely technical; it defines the boundaries of reliability, accountability, and ultimately, trust.

A key implication follows: effective AI governance cannot be reduced to model evaluation or post hoc risk mitigation. It must begin at the level of architecture – through the classification of systems according to their control properties, and the alignment of legal, institutional, and technical frameworks accordingly. This perspective reframes the role of AI in public systems. Rather than treating intelligence as a universal layer applicable across domains, it requires a differentiated approach in which system design reflects the nature of the problem being addressed.

In this context, an important direction for further research lies in expanding the range of problems that can be addressed under more controlled and structurally constrained conditions, including recent work on structured approaches to combinatorial optimization[10]. Advances in this direction may enable a broader class of applications to be implemented within architectures that provide stronger guarantees of predictability and control. This paper has outlined a conceptual framework for approaching AI governance through the lens of structural alignment. The discussion has remained at the level of general architectural principles. Further work is required to operationalize this perspective, in particular by developing a more detailed articulation of layered system design and the corresponding governance mechanisms at each layer.

Ultimately, the question is not whether AI systems can perform increasingly complex tasks. It is whether they can do so within structures that remain governable.

REFERENCES

1. Amodei, D.; Olah, C.; Steinhardt, J.; Christiano, P.; Schulman, J.; Mané, D. *Concrete Problems in AI Safety*. arXiv:1606.06565, 2016. Available at: <https://arxiv.org/abs/1606.06565>
2. Krakovna, V. et al. *Specification Gaming Examples in AI*. DeepMind, 2020. Available at: <https://github.com/deepmind/specification-gaming>
3. Russell, S. *Human Compatible: Artificial Intelligence and the Problem of Control*. New York: Viking Press, 2019.
4. Everitt, T.; Krakovna, V.; Orseau, L.; Legg, S. *Reinforcement Learning with a Corrupted Reward Channel*. Proceedings of the 26th International Joint Conference on Artificial Intelligence (IJCAI), 2017. Available at: <https://arxiv.org/abs/1705.08417>
5. Hadfield-Menell, Dylan; Dragan, Anca D.; Abbeel, Pieter; Russell, Stuart. *The Off-Switch Game*. Proceedings of IJCAI, 2017.
6. Hubinger, Evan; van Merwijk, Chris; Mikulik, Vladimir; Skalse, Joar; Garrabrant, Scott. *Risks from Learned Optimization in Advanced Machine Learning Systems*. arXiv:1906.01820, 2019. Available at: <https://arxiv.org/abs/1906.01820>
7. Garrabrant, Scott; Demski, Abram; Critch, Andrew; et al. *Embedded Agency*. Machine Intelligence Research Institute (MIRI), 2018. Available at: <https://intelligence.org/embedded-agency/>
8. Leibo, Joel Z.; Zambaldi, Vinícius; Lanctot, Marc; Marecki, Janusz; Graepel, Thore. *Multi-agent Reinforcement Learning in Sequential Social Dilemmas*. Proceedings of the 16th International Conference on Autonomous Agents and Multiagent Systems (AAMAS), 2017. Available at: <https://arxiv.org/abs/1702.03037>
9. NIST. *Artificial Intelligence Risk Management Framework (AI RMF 1.0)*. National Institute of Standards and Technology, 2023. Available at: <https://doi.org/10.6028/NIST.AI.100-1>
10. Sinchev et al. *Algorithm Based on the Subset Sum Problem for High Performance Computing*. Proceedings of Ninth International Congress on Information and Communication Technology, SpringerLink, 2024. Available at: <https://link.springer.com/book/10.1007/978-981-97-3299-9>
11. Ovadia, Y., Fertig, E., Ren, J., Nado, Z., Sculley, D., Nowozin, S., Dillon, J. V., Lakshminarayanan, B., & Snoek, J. *Can You Trust Your Model's Uncertainty? Evaluating Predictive Uncertainty Under Dataset Shift*. NeurIPS, 2019. Available at: <https://arxiv.org/abs/1906.02530>



НАЦИОНАЛЬНАЯ
АКАДЕМИЯ НАУК
РЕСПУБЛИКИ КАЗАХСТАН
ПРИ ПРЕЗИДЕНТЕ
РЕСПУБЛИКИ КАЗАХСТАН



НАУЧНЫЙ ЖУРНАЛ «НАУКА ИНТЕЛЛЕКТУАЛЬНЫХ СИСТЕМ»

Главный редактор: Токбергенов И.Т.

Научный редактор: Есеркепов М.М.

Ответственный редактор: Ахметова М.С.


Дизайнер: Копачевский А.В.

Подписано в печать 25.06.2025.

Формат 60x881/8.

НАО «Национальная академия наук Республики Казахстан при Президенте Республики Казахстан»

050010, Алматы, ул. Шевченко, 28



НАЦИОНАЛЬНАЯ
АКАДЕМИЯ НАУК
РЕСПУБЛИКИ КАЗАХСТАН
ПРИ ПРЕЗИДЕНТЕ
РЕСПУБЛИКИ КАЗАХСТАН