

**ОБЗОР И СРАВНИТЕЛЬНЫЙ АНАЛИЗ МЕХАНИЗМОВ
ИСКУССТВЕННОГО ИНТЕЛЛЕКТА**

Сапарова У.А.

Ассистент-преподаватель

Нукусский государственный технический университет

Нукус, Узбекистан

Рейпназаров Е.Н.

Доцент (PhD.)

Ташкентский университет информационных технологий

Ташкент, Узбекистан

***Аннотация:** В статье представлен обзор и сравнительный анализ основных механизмов искусственного интеллекта, применяемых для обработки данных, прогнозирования и оптимизации. Рассматриваются механизмы искусственного интеллекта. Особое внимание уделяется возможностям интеграции различных механизмов в гибридные интеллектуальные системы. В качестве прикладного направления рассматривается использование искусственного интеллекта в современных информационно-коммуникационных сетях для прогнозирования трафика, распределения ресурсов и обеспечения качества обслуживания.*

***Ключевые слова:** Искусственный интеллект, машинное обучение, глубокое обучение, обучение с подкреплением, генеративный ИИ, федеративное обучение, экспертные системы, эволюционные алгоритмы, гибридные модели.*

Искусственный интеллект (ИИ) представляет собой область информационных технологий, ориентированную на создание систем,

способных на основе входных данных формировать прогнозы, генерировать информацию, предоставлять рекомендации и принимать решения.

Развитие методов искусственного интеллекта обусловлено увеличением объёмов доступных данных, совершенствованием вычислительной инфраструктуры и расширением возможностей автоматизированного анализа сложных процессов. Механизмы ИИ применяются в промышленности, медицине, образовании, финансовом секторе, транспорте и телекоммуникациях.

При этом понятие «механизмы искусственного интеллекта» охватывает несколько категорий, которые не всегда являются взаимозаменяемыми. Экспертные системы опираются преимущественно на формализованные правила и знания. Машинное обучение выявляет зависимости на основе данных, глубокое обучение использует многослойные нейронные сети, а обучение с подкреплением ориентировано на последовательный выбор действий с учётом вознаграждения. Федеративное обучение определяет способ организации обучения на распределённых данных, тогда как генеративный ИИ связан с созданием нового содержимого на основе изученных закономерностей.

Следовательно, выбор конкретного механизма должен осуществляться с учётом назначения системы, доступности данных, вычислительных ограничений, требований к достоверности результата и допустимого уровня автономности.

Особую актуальность сравнительный анализ механизмов ИИ приобретает для информационно-коммуникационных систем. В современных телекоммуникационных сетях требуется прогнозировать изменение нагрузки, анализировать состояние каналов, распределять ограниченные ресурсы и обеспечивать требования к качеству обслуживания. Решение этих задач может потребовать не одного

универсального алгоритма, а согласованного применения нескольких механизмов искусственного интеллекта.

Цель исследования - провести сравнительный теоретический анализ основных механизмов искусственного интеллекта, выявить их преимущества и ограничения, а также определить условия целесообразного применения различных подходов.

В данной работе рассматриваются следующие механизмы искусственного интеллекта:

Экспертные системы и логические механизмы. Экспертные системы представляют собой механизмы ИИ, использующие формализованные знания, правила и логический вывод для решения специализированных задач. Обычно такая система включает базу знаний, механизм вывода и интерфейс взаимодействия с пользователем.

Правила могут быть представлены в форме «ЕСЛИ - ТО»:

- ЕСЛИ загрузка сетевого канала превышает установленный порог, ТО сформировать предупреждение.
- ЕСЛИ задержка превышает допустимое значение, ТО рассмотреть изменение параметров обслуживания.

Главное преимущество экспертных систем заключается в понятности и проверяемости правил. Их можно использовать там, где решения должны быть объяснимыми и основанными на заранее определённых условиях. Основным ограничением является необходимость вручную формировать и обновлять правила при изменении среды.

Классическое машинное обучение. Машинное обучение (Machine Learning, ML) позволяет строить модели, которые выявляют закономерности на основе данных. В зависимости от постановки задачи выделяются обучение с учителем, обучение без учителя и другие подходы.

Обучение с учителем применяется для прогнозирования численных значений и классификации объектов. Обучение без учителя используется для кластеризации и выявления скрытой структуры данных.

К основным алгоритмам ML относятся линейная и логистическая регрессия, деревья решений, Random Forest, метод опорных векторов и Gradient Boosting.

Преимущества ML - сравнительно высокая эффективность на структурированных данных, возможность количественной оценки ошибок и применение к широкому кругу практических задач. Ограничения связаны с качеством обучающей выборки, изменением распределения данных и необходимостью правильного выбора признаков.

Глубокое обучение. Глубокое обучение (Deep Learning, DL) является направлением машинного обучения, основанным на использовании многослойных нейронных сетей. Модель последовательно формирует представления данных, позволяющие выявлять сложные зависимости.

В зависимости от задачи применяются разные архитектуры: свёрточные нейронные сети - для изображений, рекуррентные сети - для последовательностей, а архитектуры Transformer - для обработки текста и других типов последовательных данных.

Глубокое обучение особенно полезно, когда структура данных сложна и ручное выделение признаков затруднено. При этом обучение крупных моделей может требовать значительных вычислительных ресурсов и большого количества данных. Кроме того, интерпретация внутренних механизмов некоторых нейронных сетей представляет самостоятельную научную задачу.

Обучение с подкреплением. Обучение с подкреплением (Reinforcement Learning, RL) предназначено для задач последовательного

принятия решений. Агент взаимодействует со средой, получает вознаграждение и постепенно формирует политику, направленную на максимизацию суммарной ожидаемой полезности.

В отличие от классического обучения с учителем, здесь не обязательно иметь размеченный правильный ответ для каждого действия. Агент обучается на основе последствий выбранных решений.

RL может использоваться для динамического распределения сетевых ресурсов, управления очередями и выбора управляющих параметров. Вместе с тем качество результата зависит от постановки задачи, функции вознаграждения, исследовательской стратегии и корректности среды обучения.

Генеративный искусственный интеллект. Генеративный ИИ предназначен для создания нового содержимого: текста, изображений, аудио, программного кода и других представлений данных. Большие языковые модели (Large Language Models, LLM) представляют собой одно из основных направлений генеративного ИИ. Их архитектуры и сферы применения рассмотрены в современных обзорных публикациях.

В отличие от классических моделей классификации, которые выбирают класс объекта, генеративная модель формирует последовательность элементов или иной выходной объект на основе выученных закономерностей.

Преимуществами генеративного ИИ являются гибкость взаимодействия с пользователем, способность обрабатывать естественный язык и возможность автоматизировать подготовку текстов, программного кода и аналитических описаний.

К ограничениям относятся возможность формирования ошибочной информации, зависимость качества от запроса и контекста, а также потребность в проверке фактов и защите конфиденциальных данных.

Федеративное обучение. Федеративное обучение (Federated Learning, FL) представляет собой подход к организации совместного обучения, при котором данные остаются у отдельных участников, а для построения общей модели передаются или агрегируются обновления параметров.

Такой подход подходит для распределённых инфраструктур, например сети базовых станций, где локальные данные могут отличаться по структуре и статистическим характеристикам.

Федеративное обучение способно уменьшать необходимость централизованного сбора исходных данных, но само по себе не гарантирует полной конфиденциальности. Дополнительно необходимо учитывать возможность утечки информации через обновления модели, различия между локальными выборками и затраты на обмен данными.

Эволюционные алгоритмы. Эволюционные алгоритмы относятся к методам поиска и оптимизации, использующим принципы отбора, мутации и комбинирования вариантов решения. Они оперируют множеством кандидатов и постепенно формируют более качественные варианты в соответствии с целевой функцией.

Эти методы применяются для задач с большим пространством решений, сложными ограничениями и отсутствием удобного аналитического решения. К их преимуществам относится возможность исследования сложных пространств поиска, а к ограничениям - значительные вычислительные затраты и отсутствие общей гарантии нахождения глобального оптимума.

Эволюционные алгоритмы не обязательно являются обучающими моделями в традиционном смысле: во многих случаях их основная роль состоит именно в поиске оптимального или близкого к оптимальному решения.

Гибридные механизмы и автоматизация машинного обучения.

Гибридные системы объединяют несколько методов для решения связанных подзадач. Например, нейронная сеть может прогнозировать нагрузку, оптимизационный алгоритм - рассчитывать распределение ресурсов, а RL - адаптировать управляющую стратегию.

Автоматизированное машинное обучение (AutoML) дополняет этот процесс средствами автоматического выбора моделей, настройки гиперпараметров и поиска архитектур.

Преимущество гибридных систем заключается в возможности разделить сложную задачу на специализированные компоненты. Однако их проектирование, интеграция и проверка требуют больше усилий, чем использование одного простого алгоритма.

Проведённое сопоставление показывает, что преимущества механизмов ИИ проявляются в зависимости от типа задачи.

Для структурированных данных и задач классификации целесообразно рассматривать классические алгоритмы ML, особенно если важны умеренные вычислительные затраты и возможность объяснения результатов. Если входные данные представляют собой сложные изображения, аудио или последовательности, глубокое обучение может обеспечить более подходящее представление информации.

Для управления объектом, состояние которого изменяется в процессе функционирования, потенциально полезно обучение с подкреплением. Генеративный ИИ более естественно применять для создания содержимого, обработки естественного языка и взаимодействия с пользователем, а не для непосредственной замены специализированной модели прогнозирования.

Федеративное обучение актуально тогда, когда данные распределены между несколькими участниками и их централизованный

сбор нежелателен. Эволюционные алгоритмы могут быть полезны при поиске решений в сложных оптимизационных задачах.

В таблице 1 приведено качественное сопоставление рассматриваемых механизмов по основному назначению, преимуществам и ограничениям.

Таблица 1. Сравнительные характеристики механизмов искусственного интеллекта.

Механизм	Основное назначение	Преимущества	Основные ограничения
Экспертные системы	Решения по заданным правилам	Интерпретируемость, предсказуемость	Ручное обновление правил
ML	Прогнозирование и классификация	Эффективность на структурированных данных	Зависимость от данных и признаков
DL	Анализ сложных зависимостей	Работа с изображениями, текстом и последовательностями	Высокие вычислительные требования
RL	Последовательное управление	Учёт долгосрочных последствий решений	Сложность обучения и настройки вознаграждения
Генеративный ИИ	Создание нового содержимого	Гибкость и широкий спектр задач	Возможность ошибок и недостоверных ответов

FL	Совместное обучение на распределённых данных	Снижение необходимости централизованного сбора данных	Коммуникационные затраты и риски конфиденциальности
Эволюционные алгоритмы	Поиск и оптимизация решений	Применимость к сложным пространствам поиска	Вычислительные затраты, отсутствие гарантии глобального оптимума
Гибридные системы	Комплексное решение нескольких задач	Объединение взаимодополняющих возможностей	Сложность интеграции и проверки

Таким образом, отдельные механизмы решают разные задачи и не могут ранжироваться по одному универсальному критерию. Выбор необходимо проводить на основе целевого показателя, условий применения и допустимых ограничений.

В статье представлен обзор и сравнительный анализ основных механизмов искусственного интеллекта: экспертных систем, машинного и глубокого обучения, обучения с подкреплением, генеративного ИИ, федеративного обучения, эволюционных алгоритмов и гибридных моделей. Рассмотрены их принципы функционирования, преимущества, ограничения и возможные области применения.

Установлено, что выбор механизма ИИ должен определяться характером исходной задачи, доступностью данных, необходимой интерпретируемостью и допустимыми вычислительными затратами. Для сложных технических систем перспективно применение гибридных архитектур, которые сочетают прогнозирование, оптимизацию и адаптивное управление.

В телекоммуникациях подобные подходы могут использоваться для прогнозирования сетевого трафика, распределения радиоресурсов, управления очередями и повышения эффективности обслуживания. Дальнейшие исследования целесообразно направить на экспериментальное сравнение гибридных моделей с традиционными алгоритмами, а также на оценку их устойчивости, вычислительной сложности и способности соблюдать ограничения качества обслуживания.

СПИСОК ИСПОЛЬЗОВАННОЙ ЛИТЕРАТУРЫ

1. OECD. Explanatory Memorandum on the Updated OECD Definition of an AI System. OECD Artificial Intelligence Papers. 2024. No. 8. DOI: 10.1787/623da898-en.
2. Goodfellow I., Bengio Y., Courville A. Deep Learning. Cambridge, MA: MIT Press, 2016.
3. Sutton R. S., Barto A. G. Reinforcement Learning: An Introduction. 2nd ed. Cambridge, MA: MIT Press, 2018.
4. McMahan B., Moore E., Ramage D., Hampson S., Aguera y Arcas B. Communication-Efficient Learning of Deep Networks from Decentralized Data // Proceedings of the 20th International Conference on Artificial Intelligence and Statistics. 2017. Vol. 54. P. 1273–1282.
5. Baratchi M., Wang C., Limmer S., van Rijn J. N., Hoos H., Bäck T. et al. Automated machine learning: past, present and future // Artificial Intelligence Review. 2024. Vol. 57. Article 122. DOI: 10.1007/s10462-024-10726-1.
6. Kumar P. Large language models (LLMs): survey, technical frameworks, and future challenges // Artificial Intelligence Review. 2024. Vol. 57. Article 260. DOI: 10.1007/s10462-024-10888-y.
7. Schwalbe G., Finzel B. A comprehensive taxonomy for explainable artificial intelligence: a systematic survey of surveys on methods and concepts // Data

Mining and Knowledge Discovery. 2024. Vol. 38. P. 3043–3101. DOI: 10.1007/s10618-022-00867-8.

8. Jiao L., Zhao J., Wang C., Liu X., Liu F., Li L. et al. Nature-Inspired Intelligent Computing: A Comprehensive Survey // Research. 2024. Vol. 7. Article 0442. DOI: 10.34133/research.0442.

9. Russell S., Norvig P. Artificial Intelligence: A Modern Approach. 4th ed. Pearson, 2021. ISBN: 978-0-13-461099-3.

10. National Institute of Standards and Technology. Artificial Intelligence Risk Management Framework (AI RMF 1.0). NIST AI 100-1. 2023. DOI: 10.6028/NIST.AI.100-1.