

УДК 004.056

Роль когнитивных ядер при решении прикладных задач

М. В. Стержанов

Белорусский государственный университет
информатики и радиоэлектроники, Минск

E-mail: sterjanov@bsuir.by

Введение

Понятие когнитивного ядра (КЯ) можно рассматривать как инженерную абстракцию минимальной функциональной конфигурации, которая принимает входные сигналы и целенаправленно преобразует их в действия, опираясь на восприятие, формализацию знаний, рассуждение и обучение [1]. В отличие от монолитных систем КЯ четко задает интерфейсы для подключения модулей памяти, поиска знаний, инструментов и исполнительных агентов, а также каналы прослеживаемости решений [1–4]. Такая модульность упрощает эволюцию систем: от узкоспециализированных решений к более универсальным платформам.

Практическая ценность КЯ проявляется в стандартизации подходов к диагностике, прогнозированию, планированию и управлению, что ускоряет разработку и повышает воспроизводимость прикладных решений [1, 3, 4].

Понятие когнитивного ядра и его свойства

Под КЯ понимается согласованная композиция алгоритмов и представлений, которая поддерживает замкнутый цикл «восприятие → интерпретация → принятие решения → действие → обратная связь → обучение» [1]. Ключевые свойства КЯ включают:

– многоуровневость представлений: от сенсорных признаков и латентных факторов к символическим и причинным структурам, что позволяет наращивать абстракции без потери связности [3, 5, 6, 7];

– адаптивность и перенос: способность оперативно перестраивать поведение при смене среды и целей, в том числе за счет обучения с подкреплением [4, 8, 9];

– обучаемость с разными типами сигналов: с учителем, без учителя, с подкреплением, по инструкциям и через инструментальные действия, что расширяет спектр применимости [4, 5, 8, 10];

– доступ к внешним ресурсам: подключение баз знаний, поисковых индексов, графов знаний и внешней памяти для обогащения контекста [3, 11–13];

– прослеживаемость и верифицируемость: контроль источников, оценка неопределенности и объяснимость, повышающие доверие к результатам [4, 7, 14, 15].

История развития подходов к когнитивным ядрам

1950–1970. Кибернетика и ранний символизм. Ранние системы опирались на четкие символические представления, продукционные правила и логический вывод, системно разделяя восприятие, память и рассуждение [1, 16].

1980–1990. Когнитивные архитектуры. Универсальные архитектуры (ACT-R, Soar) моделировали аспекты человеческого познания, четко различая долговременную и рабочую память, механизмы активации и внимания [17, 18].

1990–2015. Коннекционизм и глубокое обучение. Нейросетевые методы сформировали высокоэффективный перцептивный «фронт-энд», обеспечив масштабируемые представления и значительные прикладные результаты, но одновременно обострив вопросы объяснимости и контроля; существенный импульс придало глубокое обучение с подкреплением [5–9].

2015–н.в. Нейросимволические и гибридные системы. Современные КЯ объединяют глубинное обучение с явными структурами знаний и инструментами (поиск, символьные решатели, симуляторы) [2–4, 10, 11]. Ориентированные на поиск (retrieval) схемы связывают вероятностное предсказание с проверяемыми фактами [11], а агентные подходы интегрируют рассуждение и действие [10].

Принципы построения когнитивных ядер

Рассмотрим основные принципы, которые задают «конституцию» архитектуры [2]:

1. Нейрофункциональная аналогия. Каждый компонент системы проектируется, исходя не из точной биологической реализации, а из функциональной роли, эквивалентной соответствующему отделу головного мозга.

2. Гибрид нейросимволического ядра. Архитектура сочетает символическую память (граф знаний, который можно явно запрашивать и изменять) с нейронными компонентами (например, LLM или глубинные модели восприятия). Символический граф памяти служит каркасом знаний, а нейронные системы обеспечивают интуицию, обобщение и обработку «шумных» или неструктурированных данных. При решении задач обе

части взаимодействуют: память выдает релевантные факты, которые затем запускают нейронную процедуру рассуждения, и наоборот.

3. Радикальная модульность и специализация. Система разбивается на независимые агенты, каждый из которых отвечает за строго определенную функцию (память, планирование, эмоции, пространство, внимание и др.). Такая специализация позволяет улучшать и отлаживать каждый модуль независимо, избегая перегрузки одного узла всем функционалом. Модули обмениваются информацией по строго определенным интерфейсам и протоколам.

4. Иерархическое слоистое построение. Агентная система строится как слоистая архитектура: агенты нижнего уровня взаимодействуют с внешней динамикой (сенсорика, быстрые реакции), агенты среднего уровня интегрируют и агрегируют информацию, а верхний агент выполняет планирование, контроль и управление. Это позволяет абстрагироваться от «шума данных» и давать верхним уровням уже подготовленные, упорядоченные входы. Также обеспечивается механизм глобальных сигналов (например, сигнал тревоги), который может «пробиться» через слои к исполнительным агентам.

5. Всепроницающая наблюдаемость и способность к интроспекции. В архитектуре изначально предусмотрено журналирование всех сообщений между агентами, фиксирование внутренних состояний и метаданных. Кроме того, предусмотрены механизмы «самонаблюдения» – агент (или сам исполнительный агент) может время от времени анализировать журналы событий, выявлять аномалии, переосмысливать решения или корректировать поведение. Это делает систему объяснимой и позволяет вмешиваться в ее функционирование, а также служит механизмом регулирования и безопасности.

Данные принципы не существуют изолированно, а переплетаются – модульность сочетается с иерархией, наблюдаемость поддерживает гибридный дизайн, а нейрофункциональная аналогия направляет специализацию модулей.

Применение когнитивных ядер

Сводный анализ по когнитивным архитектурам фиксирует более 900 проектов в 84 архитектурах [4]. Рассмотрим некоторые важные области применения КЯ.

Робототехника и автономные системы

Автономные робототехнические системы предъявляют сразу несколько требований к когнитивной архитектуре:

– интеграция разнородных модулей: восприятие (камера, лидар, сенсоры), локализация и карты, планирование движения, исполнительные механизмы;

– многоуровневое управление: от нейронных политик для низкоуровневых реакций до символических планировщиков для долгосрочных задач;

– работа в реальном времени с вероятностной оценкой окружения и предсказанием поведения агентов;

– объяснимость и прослеживаемость решений (особенно в корпоративных или военных робототехнических системах);

– обучение с переносом через симуляторы и микромоделли.

КЯ объединяет нейросетевые модули (CNN, трансформеры) для восприятия, алгоритмы SLAM и байесовское планирование для навигации, символический уровень для постановки целей и механизмы извлечения информации для подключения инструкций, регламентов и корпоративных баз знаний [3, 6–9, 11–13].

КЯ в робототехнике формирует иерархическую систему управления, где нижний уровень отвечает за восприятие и реакцию в реальном времени, средний уровень – за траектории и навигацию, а верхний – за постановку и объяснение задач.

В качестве примера рассмотрим работу автономного сервисного робота в складском комплексе. На первом шаге данные камер и лидаров подаются в сверточные и трансформерные модели, что дает роботу возможность распознать стеллажи, проходы, людей. Нейросетевой модуль классифицирует объекты: «человек», «коробка», «погрузчик». Затем алгоритм SLAM строит карту склада. Вероятностная локализация (например, Monte Carlo Localization) учитывает шум сенсоров. После этого система планирует движение к нужному стеллажу и корректирует траекторию в реальном времени при появлении препятствий. Высший уровень КЯ формулирует задачи: «найди стеллаж А23», «забери коробку», «доставь к пункту сортировки». Планировщик может использовать PDDL-подобное представление, где цели и предикаты описаны явно. Робот обращается к корпоративному хранилищу инструкций: «как безопасно перемещать коробку с опасным грузом». Внешняя долговременная память хранит историю предыдущих маршрутов и опыта (например, где чаще бывают загромождения) [11–13]. При выборе маршрута робот балансирует исследование (поиск новых путей) и эксплуатацию (использование уже известных безопасных маршрутов), применяя байесовское планирование [3]. Перед внедрением новых стратегий движения робот тестирует их в цифровом двойнике (симуляторе склада). Микромодель позволяет прогнозировать поведение людей и техники, чтобы снижать вероятность аварий [20].

КЯ сочетает нейросетевое восприятие с символическим планированием и поиском, что дает прозрачность и адаптивность. В отличие от традиционной схемы, которая жестко разделена на слои и плохо адаптируется к неопределенным условиям, КЯ динамически балансирует вероятностные и символические методы, позволяя роботу учиться и переиспользовать опыт. Известна «хрупкость» систем, основанных только на онтологиях, так как неожиданный объект ломает модель. КЯ интегрирует онтологию с нейронными перцептивными модулями и вероятностными фильтрами. КЯ нацелено на промышленное применение, включая объяснимость и соответствие корпоративным регламентам.

Медицина и клиническая поддержка решений

Клиническая практика требует от интеллектуальных систем:

- обоснованности и прозрачности (каждая рекомендация должна быть верифицирована источниками – руководствами, базами лекарственных взаимодействий, клиническими исследованиями);
- интеграции разнородных данных (визуальные данные МРТ/КТ, текстовые записи врачей, биохимические анализы, геномика, базы лекарств);
- калиброванных прогнозов риска (например, вероятность осложнения при выборе определенной терапии);
- причинно-следственного анализа, а не просто корреляций.

КЯ обеспечивает это за счет:

- машинного зрения (обработка снимков, выявление патологий);
- NLP-модулей (извлечение симптомов и заключений из текстов историй болезни);
- вероятностных графовых моделей (оценка риска осложнений);
- уровня извлечения информации (поиск в клинических руководствах, онтологиях, базах лекарственных взаимодействий [3, 4, 11]);
- решающего слоя с причинными представлениями и калиброванными прогнозами [7, 14, 15].

В качестве примера рассмотрим пациента с жалобами на боль в груди и одышку. На первом шаге машинное зрение анализирует ЭКГ и КТ-снимок грудной клетки с целью выявления признаков возможной ишемии и легочного застоя. NLP-модуль обрабатывает записи врача для извлечения симптомов «одышка при нагрузке», «боли в груди», «повышенное давление». Затем следует интеграция в граф знаний: Узел «ишемическая болезнь сердца (ИБС)» связывается с «боли в груди + ЭКГ-аномалии». Узел «сердечная недостаточность» связывается с «одышка + легочный застой». Модель риска рассчитывает вероятности: ИБС = 0,72, сердечная недостаточность = 0,55. Затем происходят поиск и обоснование: система запрашивает рекомендации ESC (European Society of Cardiology). Система сверяет

назначения с базами лекарственных взаимодействий (например, осторожность при одновременном применении бета-блокаторов и антиаритмиков). После этого система формирует сценарии. Назначить нагрузочный тест + эхокардиографию (с опорой на рекомендации ESC). Начать терапию низкими дозами бета-блокаторов (с учетом взаимодействий). Вероятность улучшения состояния в течение шести месяцев при соблюдении терапии – 0,65 (с интервалом доверия $\pm 0,1$). На заключительном шаге система сообщает врачу: «Рекомендуется нагрузочное тестирование, так как вероятность ИБС выше 70 %. Основание: ESC Guidelines, отчет по пациенту. Для назначения терапии учтено лекарственное взаимодействие.

В отличие от нейросетевых решений, которые могут диагностировать по снимку, но не объясняют решение, КЯ комбинирует зрение, текст, вероятностные модели и дает обоснование со ссылками. Экспертные системы (например, старые CDS) основаны на жестких правилах («если-то») и не адаптируются к контексту. КЯ использует динамический граф знаний и вероятностные выводы, позволяя учитывать сложные комбинации факторов. Оно строит причинно-следственные модели и сценарные прогнозы, что повышает клиническую ценность рекомендаций.

КЯ связывает машинное зрение, обработку естественного языка и вероятностные модели риска; слой извлечения информации обеспечивает доступ к клиническим руководствам, онтологиям и базам лекарственных взаимодействий [3, 4, 11]. Решающий слой опирается на причинно-следственные представления и калиброванные прогнозы с верифицируемыми ссылками [7, 14, 15]. Исторически показательна интеграция поиска, онтологий и доказательств в проекте Watson [2].

Образование и персонализированное обучение

Когнитивное ядро в обучении обеспечивает:

- гибкую адаптацию: система динамически перестраивает траекторию обучения под конкретного учащегося;
- диагностику знаний: обновляет вероятности усвоения каждой темы на основе поведенческих и когнитивных индикаторов;
- объяснимость: педагог и ученик видят, почему именно предлагаются те или иные задания;
- интеграцию открытых источников: подключение учебных материалов, научных статей, видео и практических кейсов через модуль поиска;
- персонализированную мотивацию: эмоциональные и когнитивные сигналы используются для подбора стиля и уровня сложности заданий.

В качестве примера рассмотрим учащегося вуза, изучающего теорию вероятностей. На первом шаге проходит анализ ответов в тестах: система фиксирует не только правильность, но и время ответа, частоту ошибок

определенного типа. Система формирует графовую модель. Узел «условная вероятность» получает низкий уровень усвоения ($p = 0,35$). Узел «правило умножения событий» – высокий уровень ($p = 0,82$). Система обновляет вероятности после каждого ответа. Распознавание неверных стратегий: например, ученик постоянно путает условную вероятность с полной вероятностью.

Затем система формирует индивидуальный план обучения для данного учащегося. Например, вставить дополнительные задачи на условные вероятности, предложить задачу из реального мира («как оценить вероятность выигрыша в двухэтапной лотерее»).

Система обращается к внешним ресурсам: находит адаптированные видео с объяснением теоремы Байеса, подбирает практические примеры из открытых библиотек. Система демонстрирует повышенную объяснимость. Ученику говорится: «Мы даем тебе больше задач на условную вероятность, так как три из последних пяти ответов были ошибочными». Учителю сообщается: «Вероятность усвоения темы «условная вероятность» = 0,35, рекомендуем повторение».

Таким образом, в отличие от традиционных систем управления обучением (LMS) система отслеживает динамику когнитивного состояния, формирует вероятностную модель знаний и дает адаптивные рекомендации. В отличие от адаптивных систем обучения (например, ALEKS, Coursera), которые используют ограниченные статистические алгоритмы адаптации, КЯ интегрирует перцептивные модули, граф знаний и внешние ресурсы, позволяя выйти за рамки заранее подготовленного образовательного контента. ИИ-преподаватели на базе LLM могут отвечать на вопросы, но не хранят долговременную модель знаний ученика. КЯ поддерживает персонализированную долговременную память, отслеживает эволюцию знаний и адаптирует задания на горизонте недель и месяцев [1, 5, 11, 14, 15].

Финансовая аналитика и принятие решений

Финансовая сфера предъявляет жесткие требования к системам поддержки решений:

- прослеживаемость (каждое решение должно быть объяснено с указанием источников данных и логики вывода);
- калиброванные прогнозы (вероятности и риски должны быть количественно обоснованы, а не являться «черным ящиком»);
- мультидоменная интеграция (рыночные котировки, отчетность компаний, макроэкономические показатели, регуляторные публикации и даже новостные потоки).

Когнитивное ядро обеспечивает это через гибридный нейросимволический подход:

– нейронные модули анализируют большие объемы неструктурированных данных (новости, отчетность на естественном языке, тональность комментариев);

– символическая часть (граф знаний) формирует причинно-следственные связи: «рост процентных ставок → снижение привлекательности долгосрочных облигаций», «ухудшение отчетности компании → рост вероятности снижения рейтинга»;

– временные модели и вероятностные графы отслеживают динамику факторов, связывая текущие изменения с вероятностью будущих сценариев.

Рассмотрим задачу оценки перспектив акций крупного банка в условиях изменения ключевой ставки. На первом шаге осуществляется сбор данных (нейронные агенты): интерес представляют потоки новостей об изменении денежно-кредитной политики, финансовая отчетность банка, сообщения регулятора. После этого система переходит к шагу интеграции и интерпретации на основе графовой памяти. Например, узел «ключевая ставка ↑» связан с узлом «стоимость фондирования ↑», узел «стоимость фондирования ↑» связан с узлом «снижение маржи банков». Третьим шагом является построение вероятностной модели. Для примера приведем три сценария с указанием их вероятности. Сценарий А: ставка повышена на 1 % → вероятность падения прибыли банка на 15–20 % (вероятность 0,65). Сценарий В: ставка без изменений → прибыль стабильна, рост акций в пределах 2–3 % (вероятность 0,25). Сценарий С: ставка понижается → рост прибыли банка на 10–12 % (вероятность 0,10). Четвертым шагом является формирование прогноза. Приведем пример отчета, созданного КЯ: «С высокой вероятностью (>60 %) текущая денежно-кредитная политика приведет к сокращению рентабельности банковского сектора. Основные факторы риска: рост стоимости фондирования и увеличение доли просроченных кредитов. Рекомендуется рассмотреть хеджирование позиций». Отметим обоснованность и прослеживаемость всех доводов. В отчете система указывает конкретные источники: протокол ЦБ, квартальный отчет банка, последние кредитные рейтинги, рыночные индикаторы.

Таким образом, в отличие от чисто статистических моделей КЯ формирует причинно-следственные объяснения, связывает данные с источниками и указывает вероятность сценариев. КЯ сочетает правила и обучение на данных, адаптируясь к изменяющимся рыночным условиям и интегрируя новые знания. КЯ использует динамическое моделирование и вероятностные графы, что позволяет предлагать стратегии, а не только отчетность [11, 14, 15].

Ограничения, риски и требования к верификации

Рассмотрим основные ограничения, препятствующие широкому применению КЯ в реальном секторе:

– галлюцинации и вымышленные факты. При использовании подсистемы извлечения информации КЯ может синтезировать «убедительные, но ложные» связи, если источники противоречивы или неполны [14, 15];

– сдвиги домена (domain shift). Модель, обученная на одних данных (например, медицинских исследованиях до 2022 г.), может ошибаться при интерпретации новых практик или лекарств [4];

– невозпроизводимость результатов. Стохастические компоненты (нейросети, случайные выборки в планировании) делают работу КЯ непредсказуемой: одно и то же задание может дать разные ответы [14];

– скрытая предвзятость (bias). Данные могут содержать систематические перекосы (например, недопредставленность женщин в клинических исследованиях или компаний из развивающихся рынков в финансовых данных) [4, 15].

Приведем примеры возможных рисков использования:

медицинский: неверный диагноз или рекомендация терапии из-за искаженных данных;

финансовый: некорректный прогноз рынка может привести к убыткам;

социальный: предвзятые алгоритмы обучения могут усиливать неравенство;

операционный: автономный робот может принять опасное решение (например, неверно оценить траекторию в реальной среде).

Сформулируем минимальный набор инженерных практик для верификации работы КЯ:

1. Обязательный доступ к проверяемым источникам. Retrieval проводится с указанием ссылок и номеров версий. Вводится запрет на использование неподтвержденных данных в критических решениях.

2. Явное моделирование неопределенности. Байесовские и причинные модели должны возвращать не только прогноз, но и доверительный интервал. Например: «вероятность осложнений = 0,68, интервал доверия $\pm 0,12$ ».

3. Аудит данных и версий моделей. Каждое решение должно быть воспроизводимо: запись версии модели, набора данных и параметров. Аудит позволяет выявить, была ли ошибка вызвана обновлением модели.

4. Тесты на исторических данных (off-policy) и ретроспективное тестирование стратегий (backtesting). Проверка на исторических данных перед реальным применением (например, стратегия в биржевой торговле должна пройти тест на данных 2015–2023 гг.). А/В-тесты позволяют сравнивать несколько стратегий на ограниченных выборках.

5. Контроль безопасности и приватности. Выполняется за счет шифрования на всех уровнях, анонимизации и псевдонимизации персональных данных и соблюдения международных стандартов и регуляций GDPR/НІРАА. Важными являются ограничение доступа к персональным данным в механизмах поиска, а также постоянный мониторинг и защита от утечек.

6. Механизмы остановки и деэскалации. Встроенные механизмы аварийной остановки (kill switch) позволяют немедленно прекратить работу системы при обнаружении ошибки, аномального поведения или угрозы безопасности. Приоритет оператора в случае конфликта – это правило, по которому любое решение человека-оператора имеет высший приоритет и автоматически отменяет действия системы, если возникает противоречие.

7. Человек в цикле. В сценариях высокой ответственности (медицина, оборона, финансы) решения должны подтверждаться экспертами [4, 14, 15].

8. Многоуровневая независимая верификация. Использование внешних независимых систем для проверки рекомендаций. Например, медицинское КЯ проверяется сразу двумя системами: собственной моделью и сторонним справочником.

Заключение

Когнитивные ядра формируют инженерный каркас для построения надежных интеллектуальных систем. Историческое развитие – от символических архитектур к гибридным и retrieval-усиленным – постепенно снимает противоречие между масштабируемостью и объяснимостью [1–16, 2, 4, 6, 9, 10, 11]. Для промышленного внедрения критичны верифицируемость, безопасность и управляемость знаниями [4, 7–15]. Перспективы развития связаны с интеграцией микромоделей, причинного вывода и внешней памяти в агентных контурах «рассуждение-и-действие» [3, 4, 10, 12–20].

Список использованных источников

1. Goodfellow, I. Deep Learning / I. Goodfellow, Y. Bengio, A. Courville. – Cambridge, MA : MIT Press, 2016.

2. Graves, A. Neural Turing Machines / A. Graves, G. Wayne, I. Danihelka // arXiv:1410.5401. – 2014. – URL: <https://arxiv.org/pdf/1410.5401> (date of access: 24.09.2025).

3. Doshi-Velez, F. Towards a rigorous science of interpretable machine learning / F. Doshi-Velez, B. Kim // arXiv:1702.08608. – 2017. – URL: <https://arxiv.org/abs/1702.08608> (date of access: 24.09.2025).

4. Kotseruba, I. 40 years of cognitive architectures: core cognitive abilities and practical applications / I. Kotseruba, J. K. Tsotsos // Artificial Intelligence Review. – 2018. – Vol. 53, no. 1. – P. 17–94. – DOI: 10.1007/s10462-018-9646-y.

5. LeCun, Y. Deep learning / Y. LeCun, Y. Bengio, G. Hinton // Nature. – 2015. – Vol. 521. – P. 436–444.
6. Attention Is All You Need / A. Vaswani, N. Shazeer, N. Parmar [et al.] // Advances in Neural Information Processing Systems (NeurIPS), Long Beach, CA, USA, 4–9 Dec. 2017. – Long Beach, 2017. – P. 5998–6008.
7. Koller, D. Probabilistic Graphical Models: Principles and Techniques / D. Koller, N. Friedman. – Cambridge, MA : MIT Press, 2009.
8. Human-level control through deep reinforcement learning / V. Mnih, K. Kavukcuoglu, D. Silver [et al.] // Nature. – 2015. – Vol. 518. – P. 529–533.
9. Retrieval-Augmented Generation for Knowledge-Intensive NLP / P. Lewis, E. Perez, A. Piktus [et al.] // Advances in Neural Information Processing Systems (NeurIPS), Vancouver, BC, Canada, 6–12 Dec. 2020. – Vancouver, 2020. – P. 9459–9474.
10. On the opportunities and risks of foundation models / R. Bommasani, D. A. Hudson, E. Adeli [et al.] // arXiv:2108.07258. – 2021. – URL: <https://arxiv.org/abs/2108.07258> (date of access: 24.09.2025).
11. Royse, C. The Cognitive Core: An Integrated Cognitive Architecture / C. Royse, B. Caudill // ResearchGate. – 2025. – URL: https://www.researchgate.net/publication/392774960_The_Cognitive_Core_An_Integrated_Cognitive_Architecture (date of access: 02.10.2025). – DOI: 10.13140/RG.2.2.24838.08003.
12. Hybrid computing using a neural network with dynamic external memory / A. Graves, G. Wayne, M. Reynolds [et al.] // Nature. – 2016. – Vol. 538. – P. 471–476.
13. Ha D., Schmidhuber J. World Models // arXiv:1803.10122. – 2018. – URL: <https://arxiv.org/abs/1803.10122> (date of access: 24.09.2025).
14. A survey of methods for explaining black box models / R. Guidotti, A. Monreale, S. Ruggieri [et al.] // ACM Computing Surveys. – 2018. – Vol. 51, no. 5. – Article 93.
15. ReAct: Synergizing Reasoning and Acting in Language Models / S. Yao, Y. Yang, Y. Cui [et al.] // Intern. Conf. on Learning Representations (ICLR), Kigali, Rwanda, 1–5 May 2023. – Kigali, 2023.
16. Newell, A. Unified Theories of Cognition / A. Newell. – Cambridge, MA : Harvard University Press, 1990.
17. Anderson, J. R. How Can the Human Mind Occur in the Physical Universe? / J. R. Anderson. – Oxford : Oxford University Press, 2007.
18. Russell, S. Artificial Intelligence: A Modern Approach / S. Russell, P. Norvig. – 4th ed. – Boston : Pearson, 2020.
19. Sutton, R. S. Reinforcement Learning: An Introduction / R. S. Sutton, A. G. Barto. – 2nd ed. – Cambridge, MA : MIT Press, 2018.
20. Pearl, J. The Book of Why: The New Science of Cause and Effect / J. Pearl, D. Mackenzie. – New York : Basic Books, 2018.