

УДК 004.8

*Валиуллин Адель Рустамович*

*Аспирант кафедры «Информатики и прикладной математики»*

*Казанский Национальный исследовательский Технологический*

*Университет*

**ИНТЕГРАЦИЯ ОНТОЛОГИЧЕСКИХ БАЗ ЗНАНИЙ В  
ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ: СОВРЕМЕННЫЕ ПОДХОДЫ,  
МОДЕЛИ И ПЕРСПЕКТИВЫ**

**Аннотация.** В статье анализируются современные методы интеграции онтологических баз знаний (ОБЗ) в системы искусственного интеллекта (ИИ). Особое внимание уделяется формальным логико-семантическим моделям, вероятностному представлению знаний и применению графовых нейронных сетей (GNN) в онтологическом контексте. Раскрываются теоретические основы, практические применения и вычислительные ограничения. Обосновываются перспективы автоматического построения онтологий и обеспечения интерпретируемости ИИ-систем. Приведены конкретные примеры из медицины и образования.

**Ключевые слова:** онтология, базы знаний, искусственный интеллект, логика описаний, вероятностные онтологии, графовые нейронные сети, интерпретируемость, объяснимый ИИ.

**Annotation.** The article analyzes modern methods of integrating ontological knowledge bases (OKB) into artificial intelligence (AI) systems. Particular attention is paid to formal logical-semantic models, probabilistic knowledge representation, and the use of graph neural networks (GNN) in the ontological context. The theoretical foundations, practical applications, and computational limitations are revealed. The prospects for automatic ontology construction and ensuring the interpretability of AI systems are substantiated. Specific examples from medicine and education are given.

**Key words:** онтология, базы знаний, искусственный интеллект, логика описаний, вероятностные онтологии, графовые нейронные сети, интерпретируемость, объяснимый ИИ.

## 1 Введение

Современные ИИ-системы характеризуются повышенными требованиями к интерпретируемости и когнитивной совместимости [1]. Традиционные методы машинного обучения, основанные на статистических закономерностях, демонстрируют высокую эффективность, но часто не обеспечивают прозрачность принимаемых решений. Одним из путей преодоления данной проблемы является интеграция онтологических баз знаний — формализованных структур, описывающих предметную область с помощью концептов, свойств и отношений [2].

Целью настоящей работы является системный анализ и обоснование современных формальных подходов к интеграции онтологических баз знаний в архитектуры искусственного интеллекта.

В рамках поставленной цели решаются следующие задачи:

- обобщить логико-семантические и вероятностные модели описания знаний;
- проанализировать возможности графовых нейронных сетей при обучении на онтологиях;
- описать практическое применение в сферах образования и медицины;
- определить перспективные направления развития и существующие ограничения.

## 2 Онтологические базы знаний и их роль в ИИ

В информационном контексте онтология определяется как система концептов и их связей, структурированная для формального описания знаний [3]. ОБЗ реализуются с применением стандартов RDF, RDFS, OWL, и логик описаний, таких как SHOIN(D), лежащих в основе OWL-DL [7]. Эти технологии обеспечивают

автоматическую проверку консистентности знаний, дедуктивный вывод и семантическое обогащение данных.

Интеграция ОБЗ в ИИ позволяет повысить согласованность и логическую интерпретируемость моделей. Согласно [4], подобный подход особенно ценен в экспертных системах, гибридных ИИ-архитектурах и контекстуальной обработке информации.

### 3 Формальные модели интеграции

#### Методы исследования

В исследовании применены методы логико-семантического анализа, формальной логики (логика описаний SHOIN(D)), вероятностного моделирования на основе теоремы Байеса, а также методы анализа графов, включая архитектуры графовых нейронных сетей (Graph Convolutional Networks) [7][8][9]. Методология основана на сопоставлении моделей по параметрам интерпретируемости, гибкости и вычислительной сложности.

#### Логико-семантические подходы

$$C \equiv \forall R.D$$

где: C — Новый концепт, который определяется. Например, "ПрофильОбучающегося".,

R — Роль (отношение) — связь между концептами. Например, "изучает",

D - Целевой концепт, к которому применяется роль. Например, "КурсИИ".

$\forall R.D$  — Универсальное ограничение: все значения роли RRR у объекта CCC должны принадлежать DDD. То есть все курсы, которые изучает обучающийся, должны быть курсами ИИ. [7].

"ОбучающийсяИИ" — это тот, кто изучает только курсы по искусственному интеллекту:

$$\text{ОбучающийсяИИ} \equiv \forall \text{изучает.КурсИИ}$$

### 3.2 Графовые нейронные сети (GNN)

Формула агрегации состояния вершины в GNN:

$$h_v^{(k)} = \sigma \left( \sum_{u \in N(v)} \frac{1}{c_{vu}} W^{(k)} h_u^{(k-1)} \right)$$

где:

$v$  - Узел (вершина) в онтологическом графе — например, концепт "КурсИИ".

$u \in N(v)$  - Соседние узлы  $u$ , связанные с  $v$  — например, связанные темы или зависимости между курсами.

$h_u^{(k)}$  — вектор признаков вершины  $v$  на  $k$ -ом слое,

$h_u^{(k-1)}$  - Представление соседнего узла  $u$  с предыдущего слоя.

$N(v)$  — множество соседей,

$c_{vu}$  — коэффициент нормализации,

$W^{(k)}$  — обучаемая матрица весов на  $k$ -том слое,

$\sigma$  — функция активации (например, ReLU) [8].

### 3.3 Вероятностные онтологии

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)}$$

где:  $A$  — Гипотеза о концепте, который нужно определить, например: «Пользователь интересуется курсами по машинному обучению»,

$B$  - Наблюдаемое событие / признак, например: «Пользователь посещал страницы с терминами из онтологии "машинное обучение"»

$P(A)$  - Априорная вероятность гипотезы  $A$  — насколько вероятен сам концепт без дополнительной информации (например, доля студентов, изучающих машинное обучение)

$P(B)$  - Априорная вероятность наблюдаемого признака  $B$  — насколько часто встречается событие  $B$  (например, упоминание машинного обучения в данных пользователя)

$P(B|A)$  - Условная вероятность появления признака  $B$  при условии, что гипотеза  $A$  верна — например, вероятность того, что пользователь интересуется машинным обучением и посещает соответствующие страницы

$P(A|B)$  – Апостериорная(условная) вероятность гипотезы  $A$  при условии наблюдения  $B$  — то, что нужно найти: насколько вероятно, что пользователь изучает машинное обучение, если он проявляет активность, связанную с этим направлением [9].

## 4 Практическое применение

### Образование

В рамках цифровых инициатив, таких как "Цифровая образовательная среда", онтологические модели курсов применяются для адаптивных образовательных траекторий [5].

### Медицина

Системы поддержки принятия решений на основе онтологии SNOMED CT позволяют учитывать клиническую неопределённость и обеспечивать интерпретируемость в диагностике [6].

## 5 Перспективы и вызовы

высокая вычислительная сложность логического вывода (PSPACE-полные задачи);

необходимость регулярного обновления онтологий;

трудности интерпретации гибридных архитектур ИИ.

Перспективные направления:

автоматическое построение онтологий (NLP и машинное обучение);

объяснимый ИИ (XAI);

масштабируемая семантическая интеграция с Big Data.

Научная новизна

Научная новизна исследования состоит в комплексной систематизации и сравнительном анализе различных подходов к интеграции ОБЗ в ИИ. Показано, что графовые нейронные сети способны не только учитывать структуру связей, но и усиливать семантическое обобщение, что является важным аспектом explainable AI [4][8].

[Онтологическая база знаний] → [Логическая модель (OWL-DL)] → [Reasoner] → [Онтологический граф → GNN → выходные данные]

6 Заключение

Интеграция онтологических баз знаний в ИИ-системы является ключевым направлением повышения интерпретируемости, адаптивности и когнитивной прозрачности. Применение логик описаний, GNN и вероятностных моделей позволяет строить интеллектуальные системы нового поколения, способные к логически обоснованному выводу, устойчивому обучению и обобщению знаний. Дальнейшее развитие требует как теоретического укрепления, так и активного внедрения в образовательную и медицинскую практику.

Список литературы

1. Журавлёв Ю. И. Машинное обучение и интеллектуальный анализ данных. — М. : Физматлит, 2020. — 228 с.
2. Захаров С. В., Четверикова И. С. Онтологии и онтологическое моделирование. — М. : МГУ, 2018. — 147 с.
3. Глушков В. М., Зиновьев Д. А. Семантические технологии в информационных системах. — СПб. : Питер, 2021. — 204 с.

4. Russell S., Norvig P. Artificial Intelligence: A Modern Approach. — 4th ed. — Boston : Pearson, 2020. — 1152 p.
5. Орлов С. П. Семантические модели в образовательной аналитике // Образовательная среда. — 2022. — № 2. — С. 42–51.
6. Stegwee R. A., Visser H. Use of SNOMED CT in clinical decision support // Health Information Science and Systems. — 2020. — Vol. 8. — P. 1–9. — DOI: 10.1007/s13755-020-00108-2.
7. Baader F. et al. The Description Logic Handbook. — 2nd ed. — Cambridge : Cambridge University Press, 2017.
8. Kipf T. N., Welling M. Semi-Supervised Classification with Graph Convolutional Networks // ICLR, 2017. — arXiv:1609.02907.
9. Costa P. C. G. et al. PR-OWL: A Bayesian Ontology Language for the Semantic Web // ICAI, 2005. — P. 1–7.