


Осмислення галюцинацій: Семантичні бар'єри для ШІ

Від виправлення помилок до керованої уяви:
новий підхід до онтологій та графів знань.



Vagan Terziyan, Svitlana Gryshko, Amit Shukla,
Oleksandr Terziyan, Oleksandra Vitko

Проблема сучасної семантики: Однополярний світ

Проблема 1: Єдина реальність.


Сучасні онтології (RDF/OWL) розраховані на єдину, об'єктивну істину.

Проблема 2: Обмеження контексту.

Мітки типу 'True-in-Context' лише додають теги, але не створюють окремих онтологічних режимів.

Проблема 3: Семантичний колапс.

Змішування фактів і фікції в одному просторі призводить до суперечностей.



Плоский простір знань: Конфлікт між реальністю та уявою.

Галюцинація чи некерована уява?



Когнітивна наука

Люди мислять симуляціями. Ми постійно створюємо "можливі світи" для планування та навчання.

Зміна парадигми

Галюцинації в LLM — це функціональний аналог людської уяви, а не просто помилка.

Мета

Не придушувати уяву, а надати їй семантичні кордони.

Що таке Семантичні бар'єри (Semantic Guardrails)?

Визначення: Формальні обмеження на рівні онтології, які регулюють логічне виведення між різними реальностями.



**Першокласні
об'єкти**

Світи як об'єкти
в графах.



Ізоляція

Відокремлення
фактів від фікції.



Атрибуція

Збереження
походження
висновків.


Метафора:

Це не стіна, що
блокує рух, а
правила
дорожнього руху
для логіки.

Як це працює: Від атомарних триплетів до Світів

Guardrail 1: Atomic Induction


{Subject, Predicate, Object}



- 1. Індукція:** Кожен RDF-триплет автоматично створює свій власний "атомарний світ".
- 2. Структура:** Світи — це не статичні коробки, а динамічні OWL-класи.
- 3. Цілісність:** Якщо граф містить дані зі Світу А, весь граф належить до Світу А. Дані не можуть існувати в порожнечі.


Об'єднання світів: Механіка злиття

A. Guardrail 2: Intra-world Merge



Злиття фактів однієї реальності
= Розширення знань.

B. Guardrail 3: Cross-world Intersection



Злиття різних реальностей =
Створення нового світу-перетину.

Оригінальні світи залишаються чистими. Гібридна реальність існує окремо.

Логіка в ізоляції: Правила виведення

Guardrail 4: Logic in Isolation




Локалізація правил: Правило "Левітація" діє лише в контексті, де магія можлива.

Конструктивне виведення: Результат виконання правила потрапляє в перетин світів ($\text{Rule World} \cap \text{Graph World}$).


Цілісність онтології: Класи та Властивості

Guardrails 5 & 6: Запобігання витoku схеми (Schema Leakage)

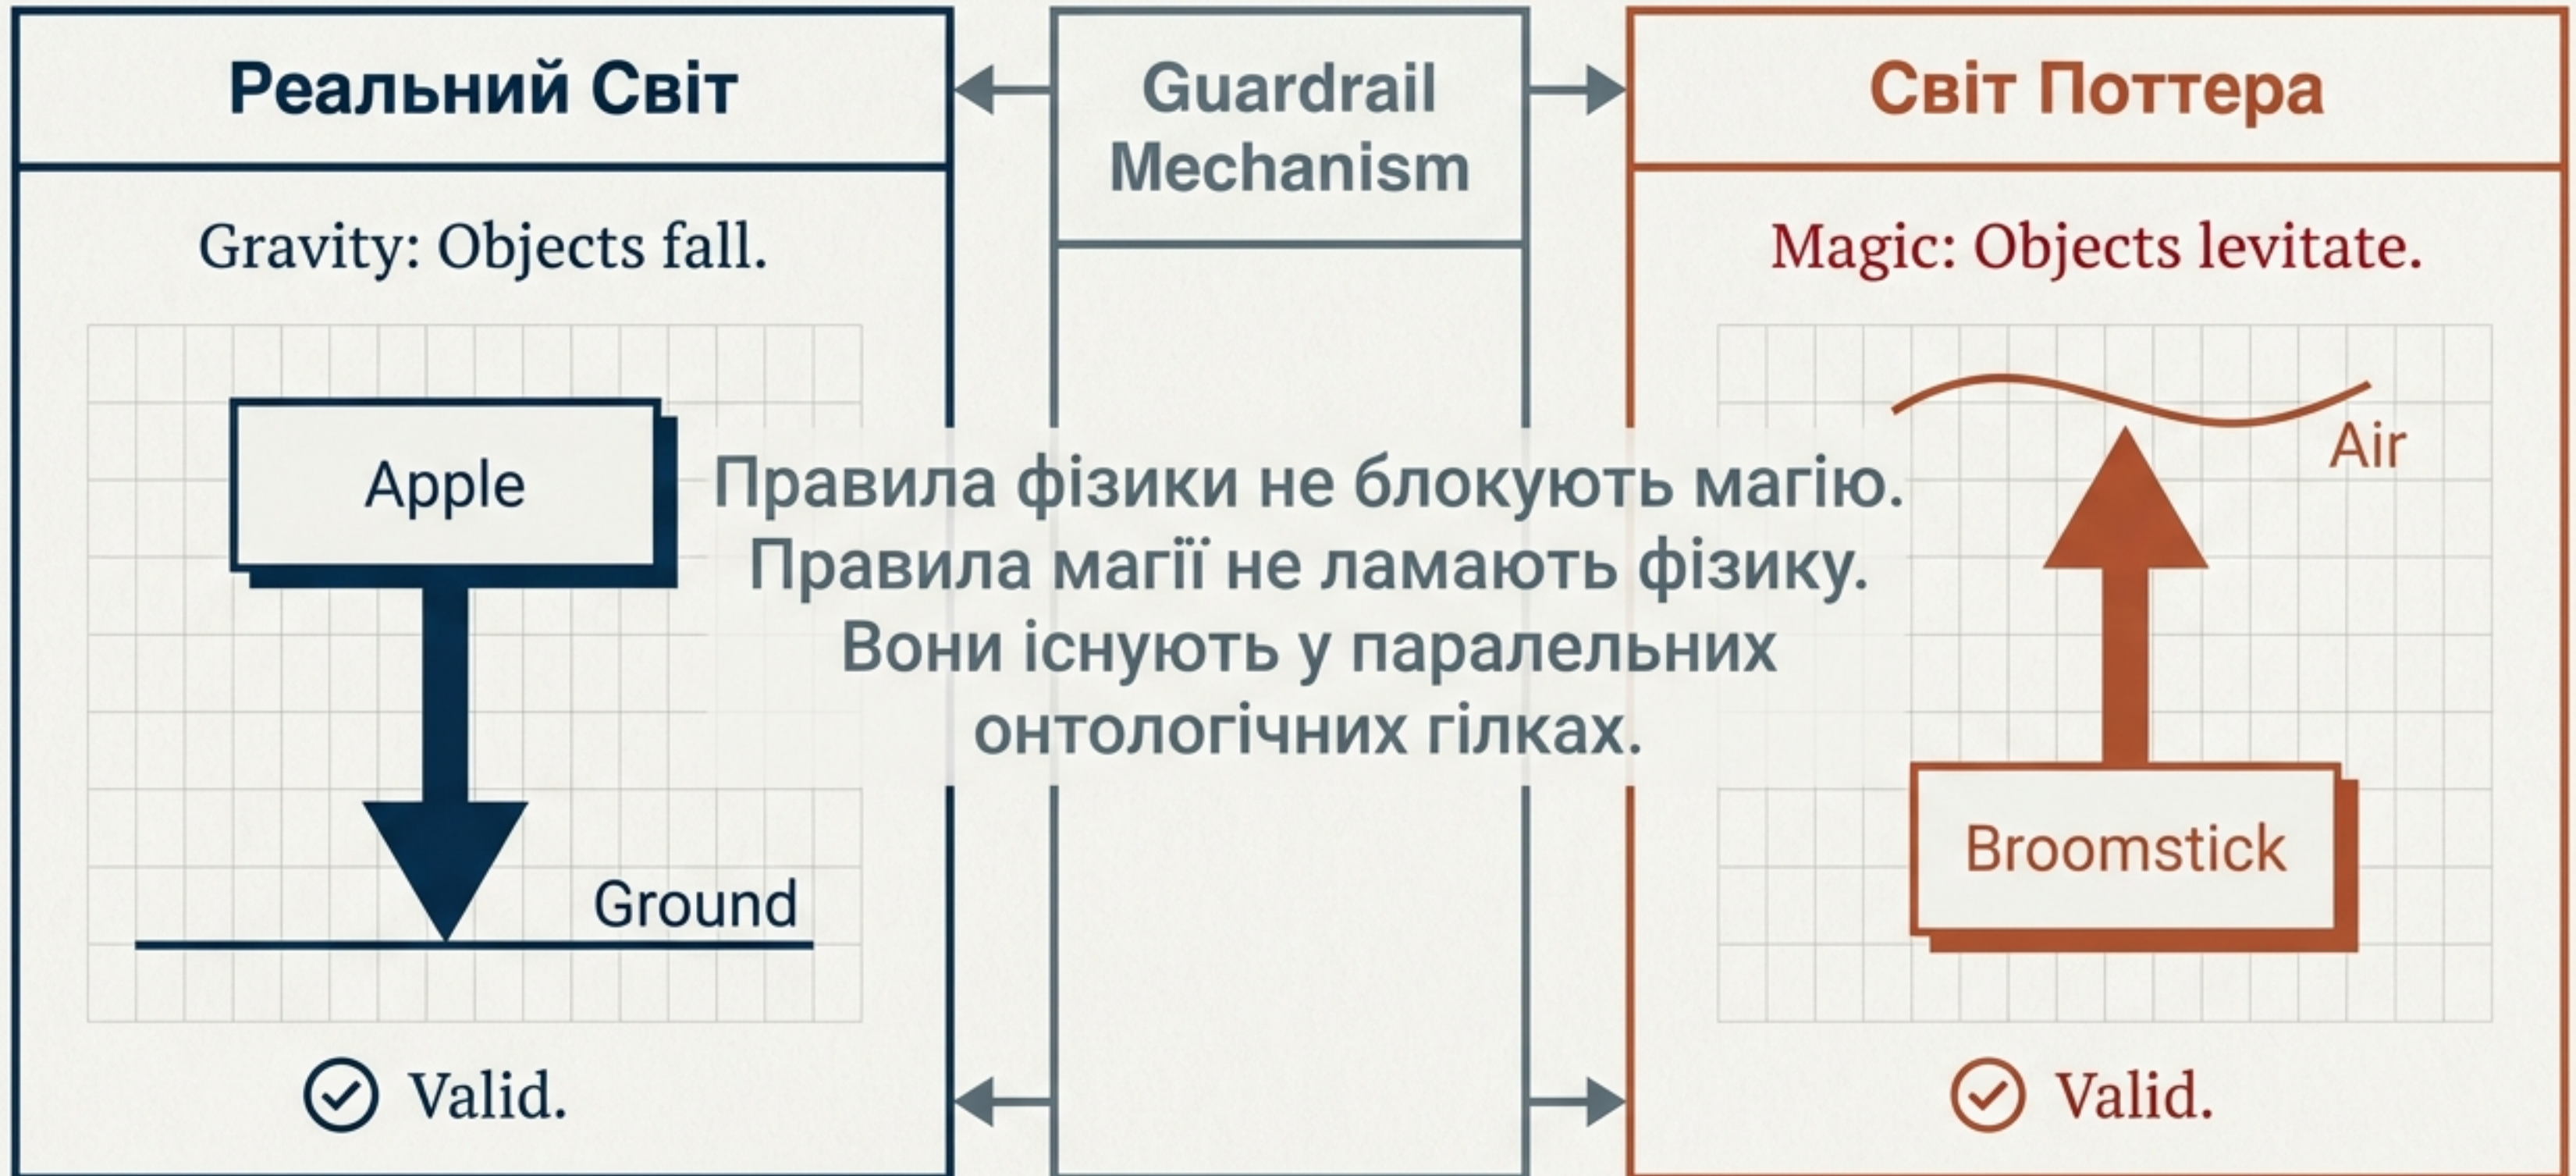


- **Ізоляція класів:** Якщо вигаданий світ визначає клас "Wizard", це визначення не псує таксономію "Human" у реальному світі. **Ізоляція властивостей:** Домени та діагастивостей: Домени та діапазони властивостей (наприклад, 'castsSpell') залишаються локальними для свого світу.
- **Результат:** Чиста онтологія навіть при використанні суперечливих визначень.


Кейс 1: Шерлок Холмс і "справжній" Лондон



Кейс 2: Гаррі Поттер і конфлікт законів фізики




Кейс 3: Планування майбутнього (Гіпотези)



Система відстежує взаємовиключні або гіпотетичні сценарії як окремі світи. Жоден варіант не оголошується "хибним" — вони є валідними планами.

Технічна реалізація та екосистема



Значення для Generative AI та LLM




- Current State: LLM 'сплющує' всі знання в один простір.
- Future State: Guardrails діють як проміжне ПЗ, що сортує фантазії у відповідні світи.
- Result: ШІ залишається креативним, але стає епістемічно підзвітним.

Переваги підходу "Multi-Reality"

01.

Безпека


Ізоляція фіктивного та гіпотетичного контенту від фактичних даних.



02.

Пояснюваність


Кожен висновок можна відслідкувати до конкретного "Світу" та набору правил.



03.

Гнучкість


Можливість міркувати над суперечливими сценаріями (контрфактуальне мислення).




04.

Цілісність

Підтримка чистих онтологій навіть при роботі з "брудними" даними LLM.



Майбутнє: Від боротьби з галюцинаціями до їх використання



Замість того, щоб намагатися “виправити” галюцинації, ми повинні їх моделювати.

Semantic Guardrails — це фундамент для гібридних нейро-символічних систем.

Структурована Уява.