


Создание агентной системы на основе LLM для тестирования веб-систем на проникновение

Автоматизация пентеста с помощью ИИ

Проблема




Актуальность

- 1 Рост сложности веб-приложений и количества уязвимостей
- 2 Традиционные средства автоматизации сильно ограничены
- 3 ИИ уже используется как атакующими, так и защитниками


Цель

Создание агентной системы на основе большой языковой модели для автоматического тестирования веб-систем на проникновение.

Ход работы



Архитектуры Single и Single-RAG



Single

- Один агент
- Линейный контекст
- Анализ, планирование и выполнение в одном

Single-RAG

- Один агент + знания
- Внешний контекст
- Больше когнитивная нагрузка модели

Архитектура P.H.A.N.T.O.M



- Несколько агентов
- Стабильная работа на сложных задачах
- Модель мира

Тестирование и сравнение

LLM	Mistral-7b-v0.3		Gemini-2.5-flash	
Архитектуры	Single	Single-RAG	Single	Single-RAG
Кол-во решенных задач	2 (4%)	0 (0%)	31 (62%)	36 (72%)

		Single	P.H.A.N.T.O.M
InterCode CTF	Кол-во реш. задач	45 (90%)	47 (94%)
	Ср. кол-во токенов	13578	19184
NYU CTF	Кол-во реш. задач	11 (19%)	18 (32%)
	Ср. кол-во токенов	109174	145542

Результаты



Разработана агентная система на основе LLM для автоматизированного решения CTF-задач. Эксперименты показали, что архитектура P.H.A.N.T.O.M работает стабильнее и эффективнее на сложных задачах, а RAG улучшает результаты крупных моделей, но может снижать их у малых.