

Разработка ML-инструмента для аннотирования патчей CVE

Выполнил: студент гр.4.207-1
Тихомирова З.В.

Научный руководитель: к.ф.-м.
н., доцент Козлов Д.Ю.

Барнаул, 2026

Введение: актуальность и предметная область

- (1) Common Vulnerabilities and Exposures (V) — единая система учёта уязвимостей
- (2) CVE = запись об уязвимости

- ❑ **360 000+** CVE в NVD (июнь 2026)
- ❑ **34 000+** новых CVE в год
- ❑ CNA обязаны опубликовать запись в течение 24 часов


PUBLISHED

Year	2026	2025	2024	2023
Qtr4	TBA	12,796	11,073	7,876
Qtr3	TBA	11,738	8,591	6,936
Qtr2	TBA	11,701	11,716	7,134
Qtr1	15,176	12,009	8,697	7,015
TOTAL	15,176	48,244	40,077	28,961


RECEIVED

Year	2026	2025	2024	2023
Count	21,530	70,729	52,316	40,051

Введение: актуальность и предметная область




Введение: актуальность и предметная область




Разрабатываемая система — CVE Patch Annotator

Система решает проблему ручного аннотирования патчей безопасности с помощью мультиагентного подхода (12 агентов: 6 LLM-based, 6 детерминированных).


Справа — контекстная диаграмма системы.



Разрабатываемая система – CVE Patch Annotator. Use-Case



Разрабатываемая система — CVE Patch Annotator. ER-диаграмма



Детерминированные (6):

- ❑ A0 Git Provider — клонирует репозиторий, извлекает diff
- ❑ A1 Diff Parser — определяет языки, изменённые строки
- ❑ A2 AST Parser — извлекает изменённые функции (13 языков)
- ❑ A3 Context Expander — находит внешние зависимости
- ❑ A10 Version Tracer — определяет уязвимые версии
- ❑ A12 Report Builder — генерирует CVE Record v5.1

LLM-агенты (6):

- ❑ A4 Unit Analyzer — псевдокод SOURCE—SINK, taint-маркеры
- ❑ A5 Architecture Mapper — граф компонентов, Scope
- ❑ A6 CWE Classifier — гибридный поиск по 944 записям
- ❑ A7 CAPEC Classifier — выбор паттерна из 615 записей
- ❑ A8 CVSS Calculator — LLM-гипотеза + формула FIRST
- ❑ A11 Security Critic — кросс-валидация цепочки

PipelineOrchestrator:

1. 12 агентов выполняются последовательно.
2. Единый алгоритм для всех: проверка, сброс, выполнение, чекпоинт.
3. Атомарное сохранение после каждого агента.

Каскадная инвалидация (DOWNSTREAM_MAP):

1. Изменили CWE — CAPEC, CVSS, critic, report пересчитаны.
2. Изменили architecture — вся цепочка пересчитана.

Восстановление после сбоев:

1. Чекпоинт после каждого агента.
2. При перезапуске — продолжение с места остановки.

```
STEP_ORDER = [  
    ("git", git.run_git),  
    ("diff", diff.run_diff),  
    ("ast", ast.run_ast),  
    ("context", context.run_context),  
    ("unit", unit.run_unit),  
    ("architecture", architecture.run_architecture),  
    ("cwe", cwe.run_cwe),  
    ("capec", capec.run_capec),  
    ("cvss", cvss.run_cvss),  
    ("versions", versions.run_versions),  
    ("critic", critic.run_critic),  
    ("report", report.run_report),  
]  
  
MODEL_MAP = {  
    "git": GitContext, "diff": DiffResult, "ast": ASTResult,  
    "context": ContextResult, "unit": UnitAnalyzerOutput,  
    "architecture": ArchitectureOutput, "cwe": CweResult,  
    "capec": CapecOutput, "cvss": CvssOutput,  
    "versions": VersionTracerOutput, "critic": SecurityCriticOutput,  
    "report": ReportResult,  
}  
  
DOWNSTREAM_MAP = {  
    "cwe": ["capec", "cvss", "critic", "report"],  
    "capec": ["cvss", "critic", "report"],  
    "cvss": ["critic", "report"],  
    "architecture": ["cwe", "capec", "cvss", "critic", "report"],  
    "critic": ["report"],  
    "report": [],  
}
```


Разрабатываемая система — CVE Patch Annotator. Ключевые особенности

- ★ **Семантическое абстрагирование** — код превращается в псевдокод, downstream-агенты работают с семантикой, а не синтаксисом.
- ★ **Каскадная инвалидация** — изменил CWE — CAPEC, CVSS, critic и report пересчитались автоматически.
- ★ **Чекпоинты** — после каждого агента состояние сохраняется. Упал сервер — продолжили с места остановки.
- ★ **Состояние пайплайна** — конструктор.
- ★ **Human-in-the-Loop** — два режима: override (запись значения) и retry (перезапуск агента с обратной связью). Аудит всех изменений.
- ★ **Развёртывание одной командой** — docker compose up -d.
- ★ **Гибридный поиск CWE** — три метрики одновременно: смысл (pgvector) + слова (tsvector) + пересечение текстов (Jaccard).

- ★ **CAPEC не случаен** — каждый кандидат получает вердикт MATCH/DISQUALIFIED. Все DISQUALIFIED, тогда генерируется CAPEC-GENERIC.
- ★ **CVSS**: две фазы — LLM-гипотеза + математическое ядро FIRST. Score определяет Architecture Mapper, не LLM.
- ★ Создание отчетов в формате CVE Record v5.1.

Разрабатываемая система – CVE Patch Annotator. Технологический стек

Язык
программирования
и веб-фреймворк



База данных и поиск

Alembic



LLM и прокси

LangChain, OpenRouter API



Веб-интерфейс

*HTMX, Alpine.js, Jinja2,
PicoCSS*



Синтаксический
анализ

tree-sitter, unidiff



 Langfuse



Бенчмарк (30 записей GitHub Advisory Database):

- CWE: 60% точных (18 из 30), 63% с учётом близких категорий
- CAPEC: 63% (11 записей)
- CVSS (RMSE): 1.46 (13 записей)

Анализ ошибок CVSS:

- Score — определяется верно (A5 работает корректно)
- Attack Vector — систематически завышается
- Privileges Required — систематически занижается

Совместимость с Vulnogram протестирована.

No	Repository	Commit	Real CWE ID	Parents of Real CWE ID		Predicted CWE ID	Real CAPEC ID	Predicted CAPEC ID
				CWE ID	CWE ID			
1	https://github.com/ebrowsen/flatbrowser	497c5900a0505924630180360096168a5934	CWE-863	CWE-285, CWE-284	CWE-284		CAPEC-126	CAPEC-126
2	https://github.com/ebrowsen/flatbrowser	7c2c9a11031302b6168a5934	CWE-22	CWE-706	CWE-22		CAPEC-126	CAPEC-126
3	https://github.com/ebrowsen/flatbrowser	847408d4135e5c3592a6dea2b0ca36617400	CWE-400	CWE-464	CWE-22		CAPEC-126	CAPEC-126
4	https://github.com/ebrowsen/flatbrowser	62110740b0a77a6c0407030405063681ee44	CWE-639	CWE-463, CWE-284	CWE-285		CAPEC-242	CAPEC-242
5	https://github.com/YPO3/hypoc3	94850a082a010a8a113a608129a99b30f0e	CWE-862	CWE-285, CWE-284	CWE-228		CAPEC-116	CAPEC-481
6	https://github.com/YPO3/hypoc3	6290a08441aee075981c323280448c0457c8	CWE-862	CWE-285, CWE-284	CWE-863		CAPEC-141	CAPEC-141
7	https://github.com/YPO3/hypoc3	97a8a4317602023181da00cd	CWE-501	CWE-410	CWE-20		CAPEC-209	CAPEC-592
8	https://github.com/YPO3/hypoc3	594472470f72a0542508750473747f389798	CWE-862	CWE-285, CWE-284	CWE-863		CAPEC-191	CAPEC-191
9	https://github.com/YPO3/html-sanitizer	8a3490446464457ca903e3c8ca03d85594103754	CWE-79	CWE-74	CWE-79		CAPEC-116	CAPEC-481
10	https://github.com/microsoft/ps-core	80c0c09182c904165800c	CWE-862	CWE-285, CWE-284	CWE-863		CAPEC-116	CAPEC-481
11	https://github.com/microsoft/ps-core	367734644646518049d915951c3693502	CWE-89	CWE-843, CWE-74	CWE-89		CAPEC-464	CAPEC-464
12	https://github.com/microsoft/ps-core	8944855671d07430a01480a005148015183	CWE-89	CWE-843, CWE-74	CWE-89		CAPEC-147	CAPEC-227
13	https://github.com/microsoft/ps-core	ec12c440b0a091eb4110378903698e03007	CWE-22	CWE-706	CWE-22		CAPEC-126	CAPEC-126

Модульное тестирование:

- 173 теста (pytest), покрытие кода 51%
 - детерминированные компоненты: Pydantic-схемы и модели — 100%, парсеры — до 82%
 - LLM-агенты: тесты отказоустойчивости (пустой вход, сбой LLM, rate limit)

Ручное системное тестирование:

- полный цикл через веб-интерфейс и CLI
- Загрузка коммита => 12 агентов => HITL-корректировка => экспорт CVE Record

CVE Patch Annotator Analyses + New

LOC-2026-00101

Clone Promote Stop Back

Status Results Export

Status: **COMPLETED** · Current report · Saved: 19:28:37 Continue Pipeline

Git Provider	DONE	Run
Diff Parser	DONE	Run
AST Parser	DONE	Run
Context Expander	DONE	Run
Unit Analyzer	DONE 2/2 Functions	Run
Architecture Mapper	DONE	Run
CWE Classifier	DONE CWE-416	Run
CAPEC Classifier	DONE	Run
CVSS Calculator	DONE 4.0 (Medium)	Run
Version Tracer	DONE 0 versions	Run
Security Critic	DONE	Run
Report Builder	DONE	Run

CVE Patch Annotator v1.0 · ML-powered CVE annotation pipeline

LOC-2026-00101 Clone Promote Stop Back

Status Results Export

Commit Info

SHA	43c08ec...
Author	Pieter Eendebak
Date	2026-05-24T18:17:38+02:00
Message	gh-149449: Fix use-after-free in '_PyUnicode_GetNameCAP' (#150323) Co-authored-by: Kumar Aditya <kumaraditya@python.org>
Files changed	4

Metadata

CVE-ID	Local ID
CVE-YYYY-NNNNN	LOC-2026-00101
Analyst	Discovery
loemome	External

Save Metadata

CWE Classification **DONE**

Selected	CWE-416
Confidence	MEDIUM 0.50
Cosine / BM25 / Jaccard	0.612 / 0.005 / 0.790

Candidates (5) >
Edit CWE >

Заключение и выводы

Разработана система CVE Patch Annotator:

- 12 агентов: от git-коммита до CVE Record v5.1
- гибридный retrieval (pgvector + tsvector + Jaccard)
- Human-in-the-Loop с каскадной инвалидацией
- веб-интерфейс + CLI + Docker

Результаты:

- 173 теста, бенчмарк на 30 записях
- CVE Record v5.1 совместим с Vulnogram
- развёртывание одной командой

Система сокращает время рутинного анализа, оставляя эксперту содержательную работу.

Спасибо за внимание!

Интересные вопросы

1. Почему точность CWE 60%, а не 90%?
2. Почему самописный оркестратор, а не LangGraph?
3. Почему монолит, а не микросервисы?
4. Чем ваша система лучше Vulnogram?
5. Что будет, если LLM «придумает» несуществующий CWE?