

АЛГОРИТМЫ ОБРАБОТКИ СЛАБОСТРУКТУРИРОВАННЫХ ДАННЫХ КИБЕРРАЗВЕДКИ

*Вульфин А.М., Кириллова А.Д., Луцкович А.И.
Уфимский университет науки и технологий, Уфа*

Ключевые слова: киберразведка, большая языковая модель, слабоструктурированные данные, RAG, инцидент, MISP.

Аннотация. В работе предложены алгоритмы обнаружения и анализа слабоструктурированных данных киберразведки на основе больших языковых моделей и архитектуры Retrieval-Augmented Generation. Разработана модульная система, включающая агенты сбора информации из OSINT-источников, модуль семантической векторизации на базе Qdrant и модель Saiga-Llama3-8B-Instruct для генерации ответов. Эксперименты на датасете из 10000 документов киберразведки показали BERTScore $F1 = 0,89$, экспертную оценку 3,98/5 и метрику RAGAS = 0,82 при 20-кратном ускорении обработки по сравнению с ручным анализом.

ALGORITHMS FOR PROCESSING SEMI-STRUCTURED CYBER THREAT INTELLIGENCE DATA

*Vulfin A.M., Kirillova A.D., Lutskovich A.I.
Ufa University of Science and Technology, Ufa*

Keywords: cyber threat intelligence, large language model, semi-structured data, RAG, incident, MISP.

Abstract. The paper proposes algorithms for detecting and analyzing semi-structured cyber threat intelligence data based on large language models and the Retrieval-Augmented Generation architecture. A modular system was developed that includes agents for collecting information from OSINT sources, a semantic vectorization module based on Qdrant, and the Saiga-Llama3-8B-Instruct model for generating responses. Experiments on a dataset of 10000 cyber intelligence documents showed a BERTScore $F1 = 0.89$, an expert score of 3.98/5, and a RAGAS metric of 0.82 with a 20-fold acceleration in processing compared to manual analysis.

Современный ландшафт угроз характеризуется экспоненциальным ростом объемов данных киберразведки (cyber threat intelligence, CTI). При этом значительная часть полезной информации (до 80%) поступает из слабоструктурированных источников: форумов, социальных сетей, Telegram-каналов, отчетов об инцидентах и бюллетеней. Существующие TI-платформы (MISP, OpenCTI, коммерческие решения) эффективно работают со структурированными данными, но обрабатывают менее 30% доступного слабоструктурированного контента [1]. Ручной анализ одного документа занимает в среднем 6 минут, что делает невозможной обработку больших потоков данных в реальном времени [2].

Применение больших языковых моделей (LLM) [3] предоставляет новые возможности для автоматизации процесса анализа слабоструктурированных данных. Однако прямое использование LLM сопряжено с риском «галлюцинаций», что недопустимо в задачах кибербезопасности. Кроме того, модели необходимо снабжать актуальной информацией из внутренних и внешних источников, сохраняя при этом конфиденциальность корпоративных данных.

Для преодоления этих ограничений перспективной является технология Retrieval-Augmented Generation (RAG) [4], которая комбинирует семантический поиск по векторной базе данных с генерацией ответа LLM. Такой подход обеспечивает фактическую обоснованность ответов и позволяет интегрировать разнородные источники информации.

Предлагаемая система анализа данных СТИ включает в себя LLM с механизмом RAG как часть системы управления данными СТИ. Целью ее создания является повышение эффективности анализа слабоструктурированных данных из различных источников с использованием развернутой платформы MISP.

Система построена на микросервисной архитектуре с использованием агентного подхода к сбору данных. Выделены следующие компоненты:

1. **Агенты сбора данных** реализованы на Python с использованием BeautifulSoup, Scrapy и Bot API. Каждый агент ориентирован на определенный тип источника (веб-сайты, API, RSS, Telegram) и работает асинхронно.

2. **Модуль предварительной обработки** нормализует текст (очистка от HTML, детекция языка), выполняет сегментацию на фрагменты размером 700 токенов с перекрытием 100 токенов и извлекает именованные сущности (IoC, домены, IP-адреса, хеши) с помощью регулярных выражений и моделей spaCy.

3. **Векторная база данных Qdrant**: для семантического индексирования используются эмбединги BGE-small-en-v1.5. Поиск выполняется по методу HNSW с квантизацией для ускорения.

4. **Модуль генерации ответов (RAG)**: базовая LLM – Saiga-Llama3-8B-Instruct, адаптированная для русскоязычных задач. При запросе система извлекает из векторной БД наиболее релевантные фрагменты и передает их в модель вместе с промптом. Для инференса применяется vLLM с тензорным параллелизмом.

5. **Интеграционный слой** обеспечивает совместимость с форматами STIX/MISP, а также API для взаимодействия с внешними системами (SIEM, TI-платформы).

Система развернута на сервере с 4×Tesla V100, 128 ГБ видеопамяти, 256 ГБ RAM. Оркестрация контейнеров – Kubernetes, мониторинг – Prometheus/Grafana.

Система прошла оценку (табл. 1) на специально созданном наборе данных. В него вошли 10 тыс. документов, собранных за 2022-2023 годы из четырех категорий источников: бюллетени FinCERT (2500), отчеты НКЦКИ (2000), Telegram-каналы (3000) и специализированные форумы (2500). Для каждого документа экспертами (8 специалистов с опытом 5-15 лет) подготовлено по 5 вопросов и эталонных ответов.

Табл. 1. Метрики качества по категориям документов

Категория	BERT F1	RAGAS	Экспертная оценка	Время, с	Индикатор компрометации, %
FinCERT	0,91	0,86	4,2	15,2	93
НКЦКИ	0,89	0,84	4,0	16,4	91
Telegram	0,87	0,81	3,8	18,3	87
Форумы	0,85	0,78	3,7	19,0	84
Общее	0,89	0,82	3,98	17,1	89

Система обрабатывает документ в среднем за 17,1 секунды, что в 20 раз быстрее ручного анализа (6,2 мин). Сравнение с альтернативными методами (табл. 2) показывает преимущество предложенного подхода.

Табл. 2. Сравнение с альтернативными методами

Метод	Время на док.	Стоимость/1К, \$	Точность, %
Ручной анализ	6,2 мин	500	95
Keyword Extract	2,3 мин	50	65
GPT-3.5 без RAG	45 с	2.5	72
Предложенная система	17,1 с	0.12	89

Масштабируемость: при увеличении числа GPU с 1 до 4 производительность растет с 210 до 690 документов в час (эффективность 85%). Анализ затрат на основе цен AWS показывает операционные расходы \$1200 в месяц при обработке 1 млн документов, что в 8-40 раз ниже коммерческих аналогов. Экономическая эффективность: ROI 340-738%, срок окупаемости 8-12 месяцев.

Разработанные алгоритмы и архитектура системы позволяют автоматизировать до 95% процессов обработки слабоструктурированных данных threat intelligence, сохраняя высокое качество анализа (BERTScore $F1 = 0,89$, экспертная оценка 3,98/5). Достигнуто 20-кратное ускорение обработки, обеспечена совместимость со стандартами STIX/MISP.

Список литературы

1. ENISA. Threat Intelligence Platforms: Technical Guidelines 2023 [Электронный ресурс]. – Режим доступа: <https://www.enisa.europa.eu>.
2. ISC2. Cybersecurity Workforce Study 2024 [Электронный ресурс]. – Режим доступа: <https://www.isc2.org>.
3. Gholami Y. Large Language Models (LLMs) for Cybersecurity: A Systematic Review // World Journal of Advanced Engineering Technology and Sciences. 2024, vol. 13, pp. 057-069.
4. Singh J.P., Agrawal S. Automating Threat Intelligence Analysis with Retrieval Augmented Generation (RAG) for Enhanced Cybersecurity Posture // International Journal of Science and Research. 2024, vol. 13(5), pp. 251-255.

Сведения об авторах:

Вульфин Алексей Михайлович – д.т.н., профессор кафедры вычислительной техники и защиты информации (ВТиЗИ);

Кириллова Анастасия Дмитриевна – к.т.н., доцент кафедры ВТиЗИ;

Луцкович Андрей Иванович – старший преподаватель кафедры ВТиЗИ.