

# КОМБИНИРОВАННЫЙ МЕТОД ОБНАРУЖЕНИЯ И ПРОТИВОДЕЙСТВИЯ АВТОМАТИЗИРОВАННОМУ СБОРУ ИНФОРМАЦИИ С ВЕБ-РЕСУРСОВ

Статья посвящена вопросу разработки комбинированного метода обнаружения и противодействия автоматизированному сбору информации с веб-ресурсов. Проблема противодействия веб-роботам является важной, согласно отчётом аналитических компаний. Веб-роботы угрожают приватности данных, авторскому праву и несут угрозы работоспособности веб-ресурсов. В данной статье предлагается метод противодействия веб-роботам, использующий комбинированный подход к обнаружению на основе семантических и графовых поведенческих методов. Приводится исследование характеристик обнаружения и алгоритм выбора стратегии реагирования. Результаты применения данного подхода показывают точность обнаружения и противодействия выше 95%.

**Ключевые слова:** веб-роботы; обнаружение веб-роботов; противодействие веб-роботам; безопасность веб-ресурсов.

Menshchikov A. A., Gatchin U. A., Korobeynikov A. G.

# COMBINED DETECTION AND COUNTERACTION METHOD OF AUTOMATED INFORMATION DATA GATHERING FROM WEB RESOURCES

The article is devoted to the development of a combined web-robot detection and counteraction method. The problem of web-robot prevention is important, according to reports from analytical companies. Web robots threaten data privacy, copyright and affect the performance of web resource. This article proposes a new method of web-robot counteraction using a combination of detection approaches based on semantic and graph behavioral methods. A study of the characteristics of the detection method and the algorithm for selecting a response strategy is provided. The results of applying this approach show the accuracy of detection and counteraction above 95%.

**Keywords:** web-robot; web-robot detection; web-robot counteraction; website security.

**Введение.** Веб-роботы – это специализированные средства сбора информации с веб-ресурсов [1]. Значительную долю пользователей веб-ресурсов составляют автоматизированные средства, ведущие несанкционированную деятельность от кражи информации с целью размещения на другом ресурсе до выполнения действий с целью получения выгоды и преимущества над рядовыми пользователями ресурса. В 2018 году OWASP выпустил документ об автоматизированных угрозах,

группируются в сессии, что позволяет строить поведенческий профиль на основе связанных последовательных запросов от каждого пользователя.

На первом этапе происходит сбор данных от веб-сервера. Рассчитываются семантические характеристики каждого из узлов веб-ресурса, а также графовые характеристики на основе построенного графа связности страниц сайта. Основные характеристики приведены в таблице 1.

Таблица 1

#### Основные используемые категории характеристик

Категория	Описание основных признаков
Структурные	Поля HTTP запроса; данные о браузере; количество запросов в сессии; типы файлов; номера ошибок.
Временные	Частота и длительность запросов; распределение запросов в сессии; время прохождения запроса.
Графовые	Степени входов и выходов посещённых вершин; эксцентриситеты; значение мер центральности; значения алгоритма HITS; PageRank пройденных вершин; переходы между несвязанными страницами.
Семантические	Число тематик; число уникальных тематик; подобие тематик в сессии; вариативность тематик; распределение переходов между тематиками.
Поведенческие	Информация об источнике запросов; JavaScript метрики; запросы файлов-детекторов.

где привёл классификацию 21 различного вектора атак на веб-ресурс со стороны автоматизированных средств [2].

Методы обнаружения и противодействия веб-роботам заключаются в поиске характерных признаков роботизированного поведения и сравнения профилей поведения в рамках пользовательских сессий. Характеристиками могут выступать различные параметры, получаемые на уровне клиента, веб-сервера и веб-приложения [3]. На уровне клиента данные собираются посредством JavaScript кода и иного активного содержимого. На уровне веб-сервера собирается статистика по структуре и содержанию HTTP и WebSocket трафика, а также информация об источнике запросов (база GeolIP). На уровне веб-приложения анализируется логика и структура поведения пользователя [4].

Помимо данных характеристик предлагается использовать информацию о структуре и содержании защищаемого веб-ресурса, что позволит связать поведение пользователя с той средой, с которой он взаимодействует.

**Методы противодействия.** Для применения сценариев противодействия веб-роботам необходимо осуществить процедуру обнаружения. Запросы от пользователей

Для расчёта данных характеристик в рамках сессии строятся комбинации из средних и медианных значений параметров каждого запроса, а также изучается их распределение и среднеквадратическое отклонение значений.

На втором этапе происходит формирование профиля для легитимных пользователей и веб-роботов. Рассчитываются сессионные характеристики, учитывающие распределение значений параметров каждого из запросов в рамках сессии. На основе данных характеристик, а также достоверной информации о происхождении сессии формируется классификационная модель. На третьем этапе происходит процедура идентификации сессий [5]. Для каждой сессии вычисляется результат комбинации решений о принадлежности пользователя к роботизированным сессиям по приведённой формуле, а также происходит выбор подходящего сценария реагирования.

$$\sum_{i=1}^n p_i \times P(y = 1 | \text{using } i^{\text{th}} \text{ method}) \quad (1)$$

Весовой параметр  $p_i$  подбирается экспертным образом, где  $\sum_{i=1}^n p_i = 1$ .  $n$  – количество используемых методов обнаружения

и противодействия,  $у$  – результат классификации (равен 1, если сессия отнесена к роботизированной).  $P$  – вероятность отнесения сессии к роботизированной.

На четвёртом этапе происходит реагирование (рисунок 1) и формируется сообщение об инциденте.



Выбор процедуры реагирования состоит из следующих шагов:

1. Определение коэффициента ущерба от пропуска веб-робота (ошибка первого рода);
2. Определение коэффициента ущерба от неверной классификации легитимного пользователя (ошибка второго рода);
3. Выбор порогов срабатывания трёх сценариев реагирования экспертыным методом (блокировка, ограничение лимитов действий, проверка на основе CAPTCHA [6]).

Величина ущерба напрямую связана с используемыми стратегиями противодействия. Например, в случае использования противодействия в виде показа CAPTCHA, ошибки второго рода несут небольшой репутационный ущерб веб-ресурсу по сравнению с использованием стратегии блокировки по IP адресу. Ущерб от пропуска веб-робота зависит от данных, расположенных на веб-ресурсе, их стоимости и объема недополученной прибыли в связи с кражей информации и возможным появлением ресурсов-агрегаторов. Структура всех подсистем, за действованных в реализации процессов обнаружения и противодействия приведена на рисунке 2.

Мониторинг является отдельным этапом и осуществляется непрерывно. Каждый запрос пользователя к веб-ресурсу отражается в логах веб-сервера. При обнаружении роботизированной сессии создаётся отчёт, содержащий логи запросов данной сессии, вероятность обнаружения и средние статистиче-

ские характеристики. Также, периодически происходит формирование отчёта о результатах обнаружения.

Результаты. Для проведения эксперимента использовалась система обнаружения и противодействия веб-роботам, использующая комбинацию метода обнаружения, осно-

ванного на анализе семантики страниц и запросов, а также метода, основанного на анализе поведения пользователей в сочетании с графом связности страниц веб-ресурса. В качестве входных данных использовались публичные датасеты [7], содержащие логи веб-сервера порталов MSNBC, NASA, а также данные нескольких веб-ресурсов в сети интернет. Общее количество анализируемых сессий составило 258431, точность обнаружения и противодействие предлагаемого метода на основе размеченных данных после применения проверки на тестовом и валидационном множествах, а также проведении 10-ти проходной перекрестной проверки результатов составила 95%. Для классификации использовались несколько различных моделей: Gradient Boosting, XGboost, Multilayer perceptron. В сравнении с результатами существующих методов, не учитывающих семантические и графовые характеристики, увеличение точности составило от 5 до 10%.

Заключение. В данной статье предлагается комбинированный метод обнаружения и противодействия автоматизированному сбору информации с веб-ресурсов, основанный на изучении семантических характеристик страниц веб-ресурса, а также графа связности его страниц. Приводятся основные характеристики обнаружения, а также принцип комбинирования результатов обнаружения на основе нескольких методов. Описывается предлагаемая схема комплексной системы обнаружения и противодействия веб-

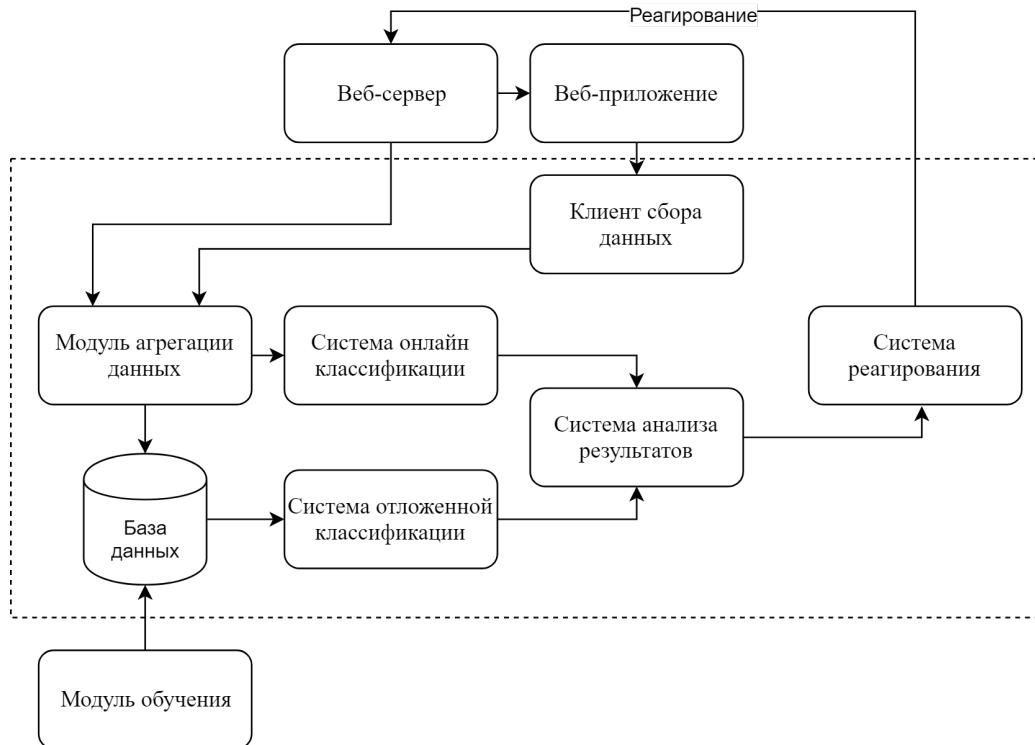


Рис. 2. Структура системы реагирования

роботам, алгоритм выбора сценария реагирования и экспериментальные результаты тестирования системы, использующей предлагаемый метод. Результаты позволяют гово-

рить о теоретической и практической значимости данного подхода, а также применимости для задачи нейтрализации автоматизированных угроз.

### Литература

1. Menshchikov A. et al. A study of different web-crawler behaviour //2017 20th Conference of Open Innovations Association (FRUCT). – IEEE, 2017. – Pp. 268-274.
2. OWASP Automated threat Handbook 2018. URL: <https://www.owasp.org/images/3/33/Automated-threat-handbook.pdf> (дата обращения: 03.06.2019).
3. Zabihimayvan M. et al. A soft computing approach for benign and malicious web robot detection // Expert Systems with Applications. – 2017. – Vol. 87. – Pp. 129-140.
4. Doran D., Morillo K., Gokhale S. S. A comparison of web robot and human requests //Proceedings of the 2013 IEEE/ACM international conference on advances in social networks analysis and mining. – ACM, 2013. – Pp. 1374-1380.
5. Hamidzadeh J., Zabihimayvan M., Sadeghi R. Detection of Web site visitors based on fuzzy rough sets //Soft Computing. – 2018. – Vol. 22. – №. 7. – Pp. 2175-2188.
6. Bursztein E., Martin M., Mitchell J. Text-based CAPTCHA strengths and weaknesses //Proceedings of the 18th ACM conference on Computer and communications security. – ACM, 2011. – Pp. 125-138.
7. UC Irvine Machine Learning Repository. URL: <https://archive.ics.uci.edu/ml/index.php> (дата обращения: 03.06.2019).

### References

1. Menshchikov A. et al. A study of different web-crawler behaviour //2017 20th Conference of Open Innovations Association (FRUCT). – IEEE, 2017. – Pp. 268-274.
2. OWASP Automated threat Handbook 2018. Available at: <https://www.owasp.org/images/3/33/Automated-threat-handbook.pdf> (accessed: 03 June 2019).
3. Zabihimayvan M. et al. A soft computing approach for benign and malicious web robot detection // Expert Systems with Applications. – 2017. – Vol. 87. – Pp. 129-140.

4. Doran D., Morillo K., Gokhale S. S. A comparison of web robot and human requests //Proceedings of the 2013 IEEE/ACM international conference on advances in social networks analysis and mining. – ACM, 2013. – Pp. 1374-1380.
5. Hamidzadeh J., Zabihimayvan M., Sadeghi R. Detection of Web site visitors based on fuzzy rough sets //Soft Computing. – 2018. – Vol. 22. – №. 7. – Pp. 2175-2188.
6. Bursztein E., Martin M., Mitchell J. Text-based CAPTCHA strengths and weaknesses //Proceedings of the 18th ACM conference on Computer and communications security. – ACM, 2011. – Pp. 125-138.
7. UC Irvine Machine Learning Repository. Available at: <https://archive.ics.uci.edu/ml/index.php> (accessed: 03 June 2019).

---

**МЕНЩИКОВ Александр Алексеевич**, аспирант, Университет ИТМО. 197101, г. Санкт-Петербург, Кронверкский пр., 49. E-mail: menshikov@corp.ifmo.ru

**ГАТЧИН Юрий Арменакович**, доктор технических наук, профессор, Университет ИТМО. 197101, г. Санкт-Петербург, Кронверкский пр., 49. E-mail: gatchin@mail.ifmo.ru

**КОРОБЕЙНИКОВ Анатолий Григорьевич**, доктор технических наук, профессор, заместитель директора по науке, Санкт-Петербургский филиал Федерального государственного бюджетного учреждения науки Института земного магнетизма, ионосферы и распространения радиоволн им. Н.В.Пушкова Российской академии наук. 199034, г. Санкт-Петербург, Менделеевская линия, 3. E-mail: korobeynikov\_a\_g@mail.ru

**MENSHCHIKOV Alexander**, postgraduate student, St. Petersburg National Research University of Information Technologies, Mechanics and Optics. 197101, St. Petersburg, Russia. Kronverksky pr., 49. E-mail: menshikov@corp.ifmo.ru

**GATCHIN Yurij**, Dr.Sc., Professor, St. Petersburg National Research University of Information Technologies, Mechanics and Optics. 197101, St. Petersburg, Russia. Kronverksky pr., 49. E-mail: gatchin@mail.ifmo.ru

**KOROBEYNIKOV Anatoly**, Dr.Sc., Professor, Deputy Director for Science, Pushkov Institute of Terrestrial Magnetism, Ionosphere and Radio Wave Propagation of the Russian Academy of Sciences (IZMIRAN). 199034, St. Petersburg, Russia. Mendeleevskaya liniya, 3. E-mail: korobeynikov\_a\_g@mail.ru