

# **ИНТЕЛЛЕКТУАЛЬНЫЙ СЕТЕВОЙ ЭКРАН ДЛЯ ЗАЩИТЫ ИИ- ПРИЛОЖЕНИЙ SOLIDWALL AI SECURITY GATEWAY**

**Описание функциональных характеристик**

**Листов: 15**

**2026 г.**

## **АННОТАЦИЯ**

Данный документ содержит описание функциональных характеристик программного обеспечения и информацию, необходимую для установки программного обеспечения.

## СОДЕРЖАНИЕ

|            |                                                                       |           |
|------------|-----------------------------------------------------------------------|-----------|
| <b>1</b>   | <b>ВВЕДЕНИЕ.....</b>                                                  | <b>4</b>  |
| <b>1.1</b> | <b>Область применения .....</b>                                       | <b>4</b>  |
| <b>1.2</b> | <b>Краткое описание возможностей .....</b>                            | <b>4</b>  |
| <b>2</b>   | <b>НАЗНАЧЕНИЕ И УСЛОВИЯ ПРИМЕНЕНИЯ .....</b>                          | <b>5</b>  |
| <b>2.1</b> | <b>Функциональные возможности SolidWall AI Security Gateway .....</b> | <b>5</b>  |
| <b>2.2</b> | <b>Преимущества SolidWall AI Security Gateway .....</b>               | <b>9</b>  |
| <b>2.3</b> | <b>Пользователи системы.....</b>                                      | <b>14</b> |

# 1 ВВЕДЕНИЕ

## 1.1 Область применения

Область применения интеллектуального сетевого экрана для защиты ИИ-приложений SolidWall AI Security Gateway (далее – SolidWall AI Security Gateway) — мониторинг состояния защищённости ИИ-приложений.

## 1.2 Краткое описание возможностей

SolidWall AI Security Gateway является интеллектуальным межсетевым экраном прикладного уровня и предназначен для мониторинга трафика ИИ-приложений на наличие интернет-угроз.

SolidWall AI Security Gateway выполняет следующие функции:

- анализ трафика веб-приложений с искусственным интеллектом и обнаружение атак (вторжений);
- блокирование попыток сетевых атак при работе с веб-приложениями с искусственным интеллектом;
- контроль доступа к функциям и журналирование действий пользователей защищаемых приложений с искусственным интеллектом;
- обнаружение подозрительной активности пользователей веб-приложений с искусственным интеллектом;
- автоматическая настройка защитных механизмов «SolidWall AI Security Gateway», версия 1.0 под конкретное защищаемое приложение с искусственным интеллектом (обучение);
- контроль и фильтрацию трафика, включая запросы пользователя к языковым моделям;
- идентификацию и аутентификацию пользователей, являющихся работниками оператора;
- регистрацию событий безопасности (аудит);
- бесперебойное функционирование и восстановление;
- тестирование и контроль целостности;
- управление (администрирование);
- взаимодействие с другими средствами защиты информации.

## 2 НАЗНАЧЕНИЕ И УСЛОВИЯ ПРИМЕНЕНИЯ

SolidWall AI Security Gateway является интеллектуальным межсетевым экраном прикладного уровня и предназначен для мониторинга трафика ИИ-приложений на наличие интернет-угроз.

### 2.1 Функциональные возможности SolidWall AI Security Gateway

SolidWall AI Security Gateway выполняет следующие функции:

- анализ трафика веб-приложений с искусственным интеллектом и обнаружение атак (вторжений);
- блокирование попыток сетевых атак при работе с веб-приложениями с искусственным интеллектом;
- контроль доступа к функциям и журналирование действий пользователей защищаемых приложений с искусственным интеллектом;
- обнаружение подозрительной активности пользователей веб-приложений с искусственным интеллектом;
- автоматическая настройка защитных механизмов «SolidWall AI Security Gateway», версия 1.0 под конкретное защищаемое приложение с искусственным интеллектом (обучение);
- контроль и фильтрацию трафика, включая запросы пользователя к языковым моделям;
- идентификацию и аутентификацию пользователей, являющихся работниками оператора;
- регистрацию событий безопасности (аудит);
- бесперебойное функционирование и восстановление;
- тестирование и контроль целостности;
- управление (администрирование);
- взаимодействие с другими средствами защиты информации.

Основные функции системы:

- защита от основных видов атак на AI-приложения из перечней OWASP LLM Top-10 Risks и OWASP Top-10 for Agentic Applications, в том числе от атак инъекций запросов к LLM (prompt injection), нарушения ограничений LLM (jailbreak), утечек чувствительной информации;
- защита от основных видов атак на веб-приложения из перечня OWASP Top-10, от логических атак на AI-приложения, в том числе от атак на механизмы аутентификации и контроля сессий, а также атак на бизнес-логику;
- полнофункциональная защита API (функционал API Gateway) с возможностью создания и корректировки моделей, вручную или автоматически, включая определение форматов данных и методов взаимодействия, не поддерживаемых стандартом Open API;

- отражение переборных атак и ботов, сочетающее позитивную модель, рейт-лимитинг, анализ поведения пользователей при обращении к AI-специфичной функциональности приложения;
- противодействие «умному DoS-у» (целевым атакам на уровне приложений (L7) на исчерпание ресурсов LLM моделей), учитывающее особенности функционирования больших языковых моделей;
- контроль действий пользователей на основе анализа и хранения легитимных транзакций, а также использования механизмов контроля бизнес-логики (анализ последовательностей обращений к AI-специфичным функциям, UBA и т. п.).

Функциональные возможности SolidWall AI Security Gateway определены следующим составом:

- возможность осуществлять мониторинг сетевого трафика для отправителей информации, получателей информации и всех операций передачи контролируемой SolidWall AI Security Gateway информации к веб-серверу и от веб-сервера;
- возможность обеспечить, чтобы в сетевом экране мониторинг распространялся на все операции перемещения через SolidWall AI Security Gateway информации к веб-серверу и от веб-сервера;
- возможность поддержки контроля и анализа запросов и ответов по протоколу передачи гипертекста определенных версий;
- возможность поддержки контроля и анализа сообщений, отправляемых веб-браузером веб-серверу и содержащих текстовый контент определенных кодировок и нетекстовый контент определенных типов (изображения, аудиоинформация, видеоинформация, программы);
- возможность поддержки контроля и анализа специальных маркеров взаимодействия (куки) определенных типов, отправляемых веб-сервером веб-браузеру и возвращаемых веб-браузером веб-серверу, содержащих персонифицированную информацию сеанса взаимодействия пользователя с веб-сервером, основываясь на определенных атрибутах куки;
- возможность помечать разрешённым информационный поток, базируясь на устанавливаемом администратором SolidWall AI Security Gateway наборе правил фильтрации, основанных на идентифицированных атрибутах;
- возможность помечать запрещённым информационный поток, базируясь на устанавливаемом администратором SolidWall AI Security Gateway наборе правил фильтрации, основанных на идентифицированных атрибутах;
- возможность осуществлять проверку наличия фрагментов мобильного кода в запросах пользователей к сайту и (или) иному ИИ-приложению на ввод данных путем поиска в таких запросах определенных фрагментов регулярных выражений (тегов, команд в формате языков мобильного кода), используемых при инициализации мобильного кода или выполнения нежелательных действий;

- возможность пометать запрещённым информационный поток, если в нём обнаружен запрос пользователя к сайту и (или) иному ИИ-приложению на ввод данных, содержащий выявленный мобильный код;
- возможность пометать разрешённым информационный поток, основываясь на результатах проверок;
- возможность пометать запрещённым информационный поток, основываясь на результатах проверок;
- возможность пометать разрешённым информационный поток, если значения атрибутов безопасности, установленные взаимодействующими средствами защиты информации для контролируемого сетевого трафика, указывают на отсутствие нарушений безопасности информации;
- возможность пометать запрещённым информационный поток, если значения атрибутов безопасности, установленные взаимодействующими средствами защиты информации для контролируемого сетевого трафика, указывают на наличие нарушений безопасности информации;
- возможность поддержки контроля и анализа фрагментированных запросов и ответов при доступе к веб-серверу;
- возможность поддержки контроля и анализа запросов и ответов при доступе к веб-серверу, подвергшихся сжатию;
- возможность поддержки отправления и получения данных пользователя информационной системы (в том числе куки – фрагменты информации, содержащие данные пользователя) способом, защищенным от несанкционированного раскрытия;
- возможность поддержки отправления и получения данных пользователя информационной системы (в том числе куки – фрагменты информации, содержащие данные пользователя) способом, защищенным от нарушения целостности;
- возможность пометать запрещённым неразрешенного информационного потока по протоколу передачи гипертекста одним или несколькими способами: блокирование запроса по протоколу передачи гипертекста;
- пометка запрещённым взаимодействия с конкретным сетевым адресом;
- пометка запрещённым сессии на уровне конкретного приложения;
- пометка запрещённым взаимодействия на уровне конкретного пользователя приложения;
- отправка управляющего сигнала на иной SolidWall AI Security Gateway для пометки запрещённым неразрешенного информационного потока;
- возможность уведомления (оповещения) администратора SolidWall AI Security Gateway о выполненной пометке запрещённым неразрешенного информационного потока по протоколу передачи гипертекста;
- возможность снятия пометки о блокировке информационных потоков администратором SolidWall AI Security Gateway, установленной ранее;

- возможность поддержки виртуализации внешнего представления приложений веб-сервера на уровне трансляции сетевых портов;
- возможность уведомления (оповещения) пользователя информационной системы о выполненной пометке о блокировке неразрешенного информационного потока по протоколу передачи гипертекста;
- возможность поддержки виртуализации внешнего представления приложений веб-сервера на уровне трансляции унифицированных идентификаторов ресурсов;
- возможность определения виртуализированных (видимых для веб-браузера) сетевых портов приложений и их сопоставления с реальными (видимыми для веб-сервера) сетевыми портами приложений;
- возможность определения виртуализированных (видимых для веб-браузера) идентификаторов ресурсов и их сопоставления с реальными (видимыми для веб-сервера) унифицированными идентификаторами ресурсов;
- возможность обеспечения перехода в режим аварийной поддержки, который предоставляет возможность возврата SolidWall AI Security Gateway к штатному режиму функционирования;
- возможность тестирования (самотестирования) функций безопасности SolidWall AI Security Gateway (контроль целостности исполняемого кода SolidWall AI Security Gateway);
- возможность согласованно интерпретировать управляющие команды, атрибуты сетевого трафика и иные данные, получаемые от взаимодействующих с SolidWall AI Security Gateway средств защиты информации других видов;
- поддержка правил интерпретации данных, получаемых от взаимодействующих с SolidWall AI Security Gateway средств защиты информации других видов;
- возможность завершения работы или восстановления (для предусмотренных сценариев сбоев) штатного режима функционирования SolidWall AI Security Gateway;
- возможность читать информацию из записей аудита уполномоченным администраторам;
- возможность выбора совокупности событий, подвергающихся аудиту, из совокупности событий, в отношении которых возможно осуществление аудита;
- возможность оповещения уполномоченных лиц о критичных видах событий безопасности, в том числе сигнализация о событиях безопасности, связанных с обнаружением неразрешенных информационных потоков по протоколу передачи гипертекста;
- возможность выборочного просмотра данных аудита (поиск, сортировка, упорядочение данных аудита);
- возможность аутентификации администратора SolidWall AI Security Gateway до разрешения любого действия (по администрированию), выполняемого при посредничестве SolidWall AI Security Gateway от имени этого администратора;
- возможность идентификации администратора SolidWall AI Security Gateway до разрешения любого действия (по администрированию), выполняемого при посредничестве SolidWall AI Security Gateway от имени этого администратора;

- возможность осуществления идентификации пользователя до разрешения передачи через SolidWall AI Security Gateway информационного потока, ассоциированного с этим пользователем, к веб-серверу (от веб-сервера);
- возможность осуществления аутентификации пользователя до разрешения передачи через SolidWall AI Security Gateway информационного потока, ассоциированного с этим пользователем, к веб-серверу (от веб-сервера);
- поддержка определенных ролей по управлению SolidWall AI Security Gateway;
- анализ трафика ИИ-приложений и обнаружение атак (вторжений);
- пометка попыток сетевых атак при работе с ИИ-приложениями;
- информирование о проведении следующего вида атак на ИИ-приложение:
  - всевозможные виды инъекций (SQL injection, OS injection, RCE, XPath-injection, XXE);
  - реализация атак на обратный путь в директориях и на включение удаленных или локальных файлов (Directory traversal, Remote/Local File Inclusion);
  - межсайтовый скриптинг (XSS);
  - межсайтовая подделка запросов (CSRF);
  - реализация атак, эксплуатирующих небезопасные настройки ИИ-приложений (security misconfiguration);
  - реализация переборных атак (bruteforce);
  - «умный» DoS (application-level DoS);
  - реализация атак, эксплуатирующих недостатки системы аутентификации (фиксация сессии, кража сессии, отсутствие таймаута и т. п.);
  - реализация атак на механизмы авторизации (Insecure Direct Object References, Missing Function Level Access Control);
  - автоматизированный обход приложения, массовое скачивание информации, использование сканеров уязвимостей (web scraping, automation);
- обнаружение подозрительной активности пользователей ИИ-приложений.

## 2.2 Преимущества SolidWall AI Security Gateway

SolidWall AI Security Gateway имеет следующие преимущества:

- Интерфейс управления:
  - Управление осуществляется по протоколу HTTP с использованием специализированного веб-интерфейса.
  - В целях интеграции с другими решениями, управление может осуществляться также с использованием REST API.
  - Обеспечение возможности мониторинга и управления конфигурациями для нескольких защищаемых приложений из общего интерфейса.

- Редактирование конфигурации подсистемы захвата трафика (обратный-прокси) с использованием графического интерфейса.
  - Возможность загрузки SSL-сертификатов в графическом интерфейсе Системы.
  - Поддержка регулярных выражений (wildcard) для доменных имен защищаемых приложений в настройках защиты.
  - Ограничение доступа пользователей только к определенным группам приложений (режим Multitenancy).
  - Поддержка графического отображения и редактирование правил защиты AI-приложений, отдельно для каждого типа атак на LLM из перечней OWASP LLM Top-10 Risks и OWASP Top-10 for Agentic Applications, с возможностью настройки реакции на каждый тип атаки независимо – блокировка, маркирование потенциально вредоносных запросов, отправка на капчу и др.
  - Веб-интерфейс обеспечивает версию каждой из конфигурационных настроек системы: в т. ч. базовых конфигурационных настроек, настроек модулей анализа, моделей нормального функционирования приложений, правил принятия решений.
  - Интерфейс поддерживает механизмы аутентификации и авторизации пользователей. Ролевая модель предусматривает разграничение доступа для трех групп: администраторы (можно выполнять любые действия), аналитики (можно менять только настройки безопасности), операторы (только мониторинг и работа с событиями безопасности).
  - Действия пользователей веб-интерфейса, включая внесенные изменения, сохраняются во внутреннем журнале аудита системы.
- Работа с использованием негативных методов обнаружения атак на AI-приложения:
- Наличие предобученного классификатора вредоносных запросов Yandex LLM Censor.
  - Наличие набора встроенных сигнатур для атак из перечня OWASP LLM Top-10 Risks в комплекте поставки.
  - Создание аномальных последовательностей (цепочек) действий при взаимодействии с AI-эндпоинтами, для моделирования нежелательного поведения.
- Противодействие переборным атакам и повторяющимся запросам:
- Возможность ограничения количества запросов, направляемых приложению в единицу времени.
  - Возможность индивидуальной настройки параметров противодействия переборным атакам для отдельных эндпоинтов, реализующих функциональность AI агентов или использующих LLM.
  - Детектирование бот-активности по аномальному превышению медианного времени задержки ответа AI-приложения по сравнению с историческими данными.
- Работа на основе позитивных моделей приложения

- Наличие готовых моделей валидации запросов и ответов на наличие чувствительной информации для типового AI-приложения в комплекте поставки.
  - Возможность гибкой настройки различных типов моделей для каждого из защищаемых AI-приложений, в том числе:
    - модели валидации протокола HTTP;
    - модели синтаксического анализа запросов и ответов с поддержкой различных видов сжатия, кодирования и способов передачи данных с различными уровнями вложенности (в частности, XML, JSON, BASE64, GZIP, SOAP, Zstd, Brotli, Protocol Buffers);
    - модели проверки соответствия XML-подобных форматов данных заданным схемам XSD, загружаемым в виде файлов в интерфейсе AI Security Gateway;
    - модели источников – определение характеристик источника на основе параметров запроса;
    - модели определения логических действий (бизнес-действий) в приложении, параметров логических действий и их значений, последовательностей действий (цепочек), проверки успешности действий;
    - модели защиты от переборных атак и атак типа «умный DoS» на уровне отдельных логических действий и произвольных параметров действия;
    - модели пользователей, их идентификации, аутентификации и контроля сессий.
  - Наличие готовых моделей валидации протокола HTTP и синтаксического анализа запросов для типового веб-приложения в комплекте поставки.
  - Наличие автоматического алгоритма оценки отклонения параметров действий AI-приложения от статистической нормы.
- Обнаружение аномалий и значимых событий:
- Возможность обнаружения аномалий или чувствительных данных как в HTTP-запросах, так и в HTTP-ответах.
  - Возможность обнаружения аномалий AI моделей следующих типов: инъекции вредоносных запросов к LLM (prompt injection), нарушение ограничений LLM (jailbreak), фишинг и социальная инженерия (deception), токсичный и нежелательный контент (toxic content), признаки мошенничества (fraud&scam), утечка чувствительных данных (раздельно персональные данные, корпоративная политика, финансовые данные, потенциальное нарушение закона, медицинские данные), и другие.
  - Возможность обнаружения аномалий работы приложения на основе сопоставления значений параметров HTTP-запросов/ответов с сигнатурами атак на AI-приложения и веб-приложения.

- Возможность обнаружения аномалий или значимых данных в работе приложения на основе настроенных позитивных моделей приложения (совпадение с моделью или наоборот – отклонение от неё).
  - Обнаружение аномалий и значимых параметров непосредственно внутри вложенных данных, передаваемых по протоколу HTTP без ограничений на количество уровней вложенности.
  - Возможность обнаружения аномалий, свидетельствующих о возможных попытках атак, осуществляемых «методом грубой силы» (bruteforce).
- Подавление ложных срабатываний:
- Наличие функции упрощенного («быстрого») подавления ложных срабатываний оператором SolidWall AI Security Gateway непосредственно при просмотре описания выявленной аномалии.
  - Возможность тонкой настройки подавления ложных срабатываний различных механизмов определения аномалий в привязке к отдельным параметрам запроса/ответа или бизнес-действиям.
- Принятие решений:
- Управление правилами принятия решений на основе данных об источнике (IP-адрес, пользователь, ID сессии) и цели HTTP-транзакции (приложение, бизнес-действие), а также обнаруженных в ней аномалиях или значимых данных.
  - Поддерживаются следующие возможные решения: блокировать HTTP-транзакцию, пропустить HTTP-транзакцию, пометить HTTP-транзакцию, модифицировать ответ, добавить значение источника в список (черный, белый или серый, в зависимости от заданной политики).
  - Управление правилами принятия решений (создание, удаление, перегруппировка) с помощью графического конфигуратора через интерфейс управления.
- Мониторинг и аудит событий информационной безопасности:
- Выводится обобщенная статистика по следующим параметрам: статусы HTTP-ответа сервера, текущей пропускной способности (входящий/исходящий трафик), задержки обработки запросов приложением, уровня враждебности среды.
  - Сообщения об обнаруженных и/или заблокированных атаках на приложения выводятся в агрегированном виде, агрегация происходит по приложениям, типам обнаруженных аномалий и времени возникновения аномалий.
  - Для событий безопасности агрегируется информация об источниках атак, в том числе по географическому распределению источников по странам, по номерам автономных систем.

- Возможность автоматического оповещения пользователей системы о событиях безопасности с использованием электронной почты, гибкая настройка оповещений из Веб-интерфейса.
- Возможность настройки выгрузки данных по отдельным заданным логическим действиям.
- Возможность автоматической генерации отчетов в формате «\*.PDF», содержащих статистику событий информационной безопасности за заданные промежутки времени, в том числе регулярные отчеты с периодичностью «раз в сутки», «раз в неделю», «раз в месяц».
- Возможность передачи данных в режиме реального времени в систему мониторинга и корреляции событий информационной безопасности (SIEM).

## 2.3 Пользователи системы

В SolidWall AI Security Gateway присутствуют встроенные группы, описанные в таблице 1.

**Таблица 1.** Пользователи системы

| Группа        | Назначение                                                                                                                                                                                                                                                                                                                                                                                         |
|---------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Администратор | Все члены группы обладают неограниченными правами и полный доступ ко всем функциям веб-интерфейса                                                                                                                                                                                                                                                                                                  |
| Аналитик      | Все члены группы обладают ограниченными правами: <ul style="list-style-type: none"> <li>– просмотр и редактирование данных в разделах «Обзор», «События», «Правила», «Приложения», за исключением безвозвратного удаления событий безопасности, и только в рамках приложений, к которым имеют доступ;</li> <li>– генерирование отчетов и настройка уведомлений для своей учетной записи</li> </ul> |
| Оператор      | Все члены группы имеют ограниченный интерфейс (отсутствует раздел «Настройка»).<br>Обладают правом на просмотр информации, связанной с приложениями, без права редактирования                                                                                                                                                                                                                      |

Администратором SolidWall AI Security Gateway является пользователь, в обязанности которого входят:

- поддержание работоспособности технических средств;
- планирование архитектуры SolidWall AI Security Gateway;
- установка (инсталляция), эксплуатация и поддержание функционирования SolidWall AI Security Gateway (в т. ч. планирование требуемых аппаратных ресурсов);
- мониторинг журналов;
- настройка профилей и политик SolidWall AI Security Gateway с учетом особенностей, защищаемых ИИ-приложений;
- взаимодействие с аналитиками SolidWall AI Security Gateway.

Аналитиком SolidWall AI Security Gateway является пользователь, в обязанности которого входят:

- настройка профилей и политик SolidWall AI Security Gateway с учетом особенностей, анализируемых ИИ-приложений;
- мониторинг и анализ событий безопасности;
- принятие решений о реагировании на зафиксированные события;
- проверка (тестирование) корректности функционирования SolidWall AI Security Gateway при внедрении новых версий, защищаемых ИИ-приложений;

- взаимодействие с подразделением, эксплуатирующим ИИ-приложение при анализе сообщений об ошибках (особенно в отношении ложных срабатываний);
- взаимодействие с Администратором SolidWall AI Security Gateway.

Роль «Оператор» назначается пользователю SolidWall AI Security Gateway, в обязанности которого входят:

- регулярный мониторинг состояния защищаемых приложений;
- взаимодействие с аналитиками и/или администратором в случае нештатных ситуаций.