



Технологии,  
которые работают.

**Медведев Михаил  
Александрович**

*м.н.с., руководитель проектов,  
Представительство ЦК НИИ «Технологии  
доверенного взаимодействия» (НГТУ НЭТИ)*

**nstu.ru**

**Алгоритмы  
машинного обучения  
для семантической  
контент-фильтрации  
и защиты  
конфиденциальной  
информации**

# Семантическая контент-фильтрация с помощью ML?

- Семантический анализ не просто поиск ключевых слов, а понимание смысла и контекста текста.
- Машинное обучение (ML) – использование моделей, способных «учиться» отличать конфиденциальную/запрещенную информацию от нейтральной.
- Защита конфиденциальности – выявление и сокрытие персональных данных, коммерческих секретов и других чувствительных сведений.

## Преимущества использования семантической контент-фильтрации с помощью ML?

- Адаптивность к новым формам выражения;
- Меньше ложных срабатываний по сравнению с простыми фильтрами на ключевых словах;
- Возможность учитывать контекст.

# Основные проблемы

Сложность контекста – многообразие языковых форм, неоднозначных терминов, культурных нюансов.

Объемы данных – постоянный рост информации требует высокопроизводительных решений и больших наборов данных для обучения.

Правовые и этические аспекты – соблюдение законов о персональных данных и обеспечение прозрачности принятия решений ИИ.

Точность и ложные срабатывания – найти баланс между блокировкой необходимой информации (ложноположительные результаты) и пропуском опасной (ложноотрицательные результаты).



# Глобальная проблема: Мультикультурный и многоязычный контент

Компаниям приходится фильтровать сообщения на разных языках, учитывая культурные нюансы и смешанную лексику.

Одна и та же фраза может иметь разные значения в разных странах или профессиональных сообществах.

Сложность распознавания скрытых смыслов (сарказм, жаргон, эвфемизмы) возрастает в условиях многоязычной среды.



# Модель угроз. Внешние факторы:

## Кибератаки и целенаправленные взломы

- Обход традиционных фильтров. Злоумышленники шифруют вредоносный код или используют малоизвестные уязвимости. Семантические фильтры на базе ML могут помочь выявлять аномалии в содержании, даже если подпись или сигнатура атаки еще не известна
- Фокус на конфиденциальной информации. Хакеры нацелены на конкретные документы или утечки персональных данных. ML-модели могут определять паттерны, характерные для попыток получить доступ к таким данным

## Вредоносные вложения

- Динамическое определение угроз. ML-модели можно обучить выявлять новые тенденции и схемы, используемые злоумышленниками, без необходимости вручную обновлять правила

## Фишинг

- Анализ текста веб-страниц. Семантические фильтры могут обнаруживать поддельные адреса, ссылки или нетипичные формулировки, указывающие на попытку мошенничества

# Модель угроз. Внутренние факторы:

## Намеренные действия сотрудников

- Кража или продажа чувствительных данных с целью личной выгоды
- Целенаправленная отправка конфиденциальной информации за пределы организации
- Саботаж при увольнении или конфликте с руководством

## Ненамеренные утечки

- Неправильная настройка доступа к общим папкам и документам
- Слабое понимание внутренней политики безопасности

## Человеческие уязвимости

- Подверженность фишингу и социальной инженерии (сотрудник может неосознанно открыть «дыру» в системе)
- Сложные или неоднозначные инструкции по работе с данными, приводящие к ошибкам

# Основные нормативные акты РФ, регулирующие защиту данных и информационную безопасность:



Федеральный закон «О персональных данных» от 27.07.2006 № 152-ФЗ



Федеральный закон «О защите детей от информации, причиняющей вред их здоровью и развитию» от 29 декабря 2010 г. № 436-ФЗ



Федеральный закон «Об информации, информационных технологиях и о защите информации» от 27 июля 2006 г. № 149-ФЗ



Федеральный закон «О безопасности критической информационной инфраструктуры Российской Федерации» от 26.07.2017 N 187-ФЗ

# Алгоритмы машинного обучения для семантической контент-фильтрации. Традиционные методы:

Классификация на основе ключевых слов и регулярных выражений:

- Ключевые слова:
  - Создание списка «стоп-слов» (запрещенных выражений, терминов)
  - Автоматический поиск совпадений в тексте
  - Простота настройки – достаточно дополнить файл со словами, и фильтр заработает
- Регулярные выражения:
  - Использование паттернов поиска для шаблонных данных:
    - Форматы номеров банковских карт (16 цифр, разделенных пробелами или дефисами)
    - Адреса электронной почты (шаблоны вида \*@mail.ru)

Недостатки:

1. Отсутствие учета контекста:

- Система «видит» только точные совпадения, игнорируя смысл.
- Возможны ложные срабатывания (например, слово «паспорт» в безобидном контексте).
- Пропуск тонких смыслов, сарказма, эзопова языка, когда конфиденциальная информация зашифрована намеками.

2. Требуется постоянное ручное обновление правил:

- Новые формулировки, сленг, иносказания, когда каждый раз нужно дополнять и корректировать списки.
- При большом объеме данных усложняется поддержка и проверка на актуальность.
- Безоперационная пауза: если ответственные лица забыли обновить «стоп-слова», фильтр перестает реагировать на свежие угрозы.


3. Невозможность обрабатывать неоднозначность:

- Слова-омонимы, смешение языков, сокращения, когда фильтр часто не справляется.
- Переход на другой язык или простой «звездочкой» в слове («п\*спорт») обходят фильтр.

# Алгоритмы машинного обучения для семантической контент-фильтрации. Современные методы:

1. Глубокое обучение: предобученные эмбединги (BERT, GPT)

- Модель «учится» на огромных датасетах, формируя контекстные представления слов (эмбединги).
- При решении прикладной задачи (фильтрация, классификация) модель дообучается на конкретном датасете.




## 2. Методы полусупервизированного и обучение без учителя

- **Проблема разметки:** часто не хватает размеченных данных для всех сценариев (профессиональные термины, конфиденциальная лексика).
- **Полусупервизированный подход:**
  - Использует небольшое количество размеченных данных + большое количество неразмеченного материала.
  - Модель извлекает закономерности и постепенно улучшает свои прогнозы.
- **Обучение без учителя:**
  - Фокус на поиске скрытых шаблонов.
  - Полезно для предварительной сегментации данных, система группирует документы по сходной тематике, а эксперт уточняет категории.

# Наши разработки




Реализован НИР «Разработка методики проверки, анализа и актуализации белых и черных списков фильтрации на основании семантической модели контента», в разработке находится ПО, реализующего модели и методики проверки, анализа и актуализации белых и черных списков фильтрации на основании семантической модели контента в рамках выполнения проектов программы развития ЦК НТИ «Технологии доверенного взаимодействия».




Основная цель разработки: повышение точности семантической контент-фильтрации входящего трафика с использованием машинного обучения.

**Взаимодействие математических моделей на основании разработанных методик проверки, анализа и актуализации белых и черных списков фильтрации на основании семантической модели контента. Модуль формирования семантической модели:**




# Взаимодействие математических моделей на основании разработанных методик проверки, анализа и актуализации белых и черных списков фильтрации на основании семантической модели контента. Модули проверки, анализа и актуализации:




# Результаты моделирования

- Дискретно-событийная имитация (AnyLogic):
  - Среднее время обработки в разных модулях: ~96–4500 сек (зависит от сложности и объема трафика). Особенностью такого разброса во времени является неравномерное труднопредсказуемое количество поступающих заявок, так как заявки, неуспешно прошедшие проверку, отправляются на дополнительный анализ и актуализацию, который может проводиться многократно в отношении одной заявки.
  - Линейное распределение времени, высокое соответствие теоретическим моделям.
- Эффективность:
  - Стабильная работа, предсказуемые задержки, готовность к реальной эксплуатации.
  - Минимизация ложноположительных и ложноотрицательных результатов.


# Результат моделирования процесса формирования семантической модели в программной системе AnyLogic



Распределение времени поступления трафика





● плотность вероятности 96.31




● распределение 96.31

Распределение времени поступления сущностей и множеств семантической модели и данных из модуля актуализации




● плотность вероятности 4,392.17




● распределение 4,392.17


Распределение времени поступления множеств семантической модели и данных из модуля проверки




● плотность вероятности 4,500.88



● распределение 4,500.88



● плотность вероятности 4,523.6




● распределение 4,523.6



Распределение времени поступления множеств семантической модели и данных из модуля анализа

# Пример построения семантической модели контента



# Численные результаты работы модели

- Точность классификации ~90%
- Устойчивость к ошибкам ~85%
  
- Модуль формирования семантической модели: среднее время нахождения агента ~96,31с. (диапазон от 8,38-171,38с.)
- Модуль проверки: среднее время нахождения агента ~4392,17с. (диапазон от 1,6-8747,88с.)
- Модуль анализа: среднее время нахождения агента ~4500,88с. (диапазон от 3,8-9011,86с.)
- Модуль актуализации: среднее время нахождения агента ~4523,6с. (диапазон от 2,3-9034,5с.)

# Планы и перспективы развития

1

Расширение языковых моделей – поддержка нескольких языков, учет культурных и региональных особенностей при формировании черных/белых списков.

2

Интеграция с корпоративными системами. Доработка API и обеспечение совместимости с имеющимися SIEM/CRM/ERP-платформами.



Технологии,  
которые работают.

**Медведев Михаил  
Александрович**

*м.н.с., руководитель проектов,  
Представительство ЦК НИИ «Технологии  
доверенного взаимодействия» (НГТУ НЭТИ)*

**nstu.ru**

**Алгоритмы  
машинного обучения  
для семантической  
контент-фильтрации  
и защиты  
конфиденциальной  
информации**