

# **Актуальные вопросы оценки соответствия интеллектуальных СЗИ (постановка задачи)**

РНВТ-2022, Тематическая секция «Искусственный интеллект – новая основа безопасности критической инфраструктуры государства», Москва, ЦВК «Экспоцентр», 27 апреля 2022 г.


Алексей Марков,  
д.т.н., CISSP, CEN

# План

1. Актуальность
2. Угрозы и контрмеры ИБ в области ИИ
3. Оценка соответствия и системы сертификации
4. Выводы и предложения

# Область определения

- Позиция ISO/IEC: AI == ML
- Интеллектуальные СЗИ – это СЗИ, предназначенные для решения различных задач обеспечения ИБ, создание которых в обязательном порядке связано с использованием специальным образом подготовленных НД, описывающих представительную совокупность примеров решения этих задач (по ТК-164)



# Актуальность

Gartner®

Top 10  
Strategic  
Technology  
Trends



AI Security

## Конвергенция трендов: кибербезопасность .....

### Статистика и прогнозы

- MSM на 2026 г. – Рынок ML & Cybersecurity - 2.83 трлн. \$ >> в 135 раз..
- Gartner 2022 г. - 30% кибератак с использованием ИИ будут составлять состоятельные атаки
- Splunk 2022 г.: 63% организаций используют ML для аналитики по ИБ
- Cylance 2022: 62% хакеров планируют использовать ИИ
- Экспоненциальный рост исследований в вузах (лидеры 4 Пром. рев.)
- ...


### Инциденты ИБ

- Переученные боты, ошибки идентификации

### Регуляторы


- Проработка тематических стандартов MITRE, NIST, ISO/IEC...
- Система сертификации ИИ по эгидой TÜV

AI in Cyber Security Market, by Region (USD Billion)



<https://www.marketsandmarkets.com>

Papers on adversarial machine learning in arXiv.org




# Угрозы и контрмеры ИБ в области ИИ

- Новые классы атак (сопоставительные атаки)
- Эволюция угроз (интеллектуальные атаки)
- Эволюция СЗИ с элементами ИИ (СЗИ NG)
  - Эволюция САЭ и технологий разработки БПО с элементами ИИ

# 1. Атаки на системы ИИ

6

- Атаки на данные (искажение разметки, «черный лебедь»)
- Атаки на алгоритмы (белый ящик, черный ящик, ндв - заимствованные компоненты, бюллетени и БД и т.д.)
- Атака на наличие конфиденциальных данных
- Атаки на среду и др.



# MITRE Adversarial Threat Landscape for Artificial-Intelligence Systems

| Reconnaissance                                                                                                                                                                                                                                                 | Resource Development                                                                                                                                                                                                                                             | Initial Access                                                  | ML Model Access                                                                                                                                          | Execution                 | Persistence                                                  | Defense Evasion           | Discovery                                                                                                  | Collection                                                                      | ML Attack Staging                                                                                                        |
|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------|---------------------------|--------------------------------------------------------------|---------------------------|------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------|
| 5 techniques                                                                                                                                                                                                                                                   | 7 techniques                                                                                                                                                                                                                                                     | 2 techniques                                                    | 4 techniques                                                                                                                                             | 1 technique               | 2 techniques                                                 | 1 technique               | 3 techniques                                                                                               | 2 techniques                                                                    | 4 techniques                                                                                                             |
| <div>Search for Victim's Publicly Available Research Materials</div> <div>Search for Publicly Available Adversarial Vulnerability Analysis</div> <div>Search Victim-Owned Websites</div> <div>Search Application Repositories</div> <div>Active Scanning</div> | <div>Acquire Public ML Artifacts</div> <div>Obtain Capabilities</div> <div>Develop Adversarial ML Attack Capabilities</div> <div>Acquire Infrastructure</div> <div>Publish Poisoned Datasets</div> <div>Poison Training Data</div> <div>Establish Accounts</div> | <div>ML Supply Chain Compromise</div> <div>Valid Accounts</div> | <div>ML Model Inference API Access</div> <div>ML-Enabled Product or Service</div> <div>Physical Environment Access</div> <div>Full ML Model Access</div> | <div>User Execution</div> | <div>Poison Training Data</div> <div>Backdoor ML Model</div> | <div>Evade ML Model</div> | <div>Discover ML Model Ontology</div> <div>Discover ML Model Family</div> <div>Discover ML Artifacts</div> | <div>ML Artifact Collection</div> <div>Data from Information Repositories</div> | <div>Create Proxy ML Model</div> <div>Backdoor ML Model</div> <div>Verify Attack</div> <div>Craft Adversarial Data</div> |

### Full ML Model Access

Summary

Adversaries may gain full "white-box" access to a machine learning model. This means the adversary has complete knowledge of the model architecture, its parameters, and class ontology. They may exfiltrate the model to [Craft Adversarial Data](#) and [Verify Attack](#) in an offline where it is hard to detect their behavior.

ID: AML.T0044

Tactics: [ML Model Access](#)

Number of case studies: 1

Case study examples ^

Backdoor Attack on Deep Learning Models in Mobile Apps

This provided the researches with full access to the ML model, albeit in compiled, binary form.

## 2. Атаки с использованием ИИ

- Сбор (фильтрация) информации о жертве
- Имперсонация (SET, фишинг и т.д.)
- Несанкционированный доступ (обход CAPTCHA и подбор паролей)
- Проведение атак (VA, Malware, DDoS, crowdturfing/фейки)
- Автоматизация АPT-атак (HiveNet – управление ботнетами)

| Metric \ Model | LSTM   | Markov Chain |
|----------------|--------|--------------|
| Training Speed | Days   | Seconds      |
| Accuracy       | High   | Medium       |
| Availability   | Public | Public       |
| Size           | Large  | Small        |



**DARPA: CTF-соревнования Cyber Grand Challenge 2016**

Участник – система ИИ **Mayhem**


# 3. СЗИ NG. Пример классификации по СВІ

9

- Идентификация, аутентификация, борьба с мошенничеством
- Риск-менеджмент
- Ловушки, Honeypot
- Автоматизация
- Проактивная защита, NDR, SIEM/IPS
- Поведенческий анализ, UEBA
- Mobile/IoT-безопасность
- Безопасность приложений



# 3. СЗИ NG. Пример классификации по CSET



Предотвращение

Выявление

Реагирование

Проактивная защита

| CYBERSECURITY TASK                | UNDERLYING TECHNOLOGY OF NEW AI APPLICATIONS |
|-----------------------------------|----------------------------------------------|
| Fuzzing                           | Deep Learning                                |
| Pentesting                        | Reinforcement Learning                       |
| Bug Triage and Classification     | NLP, Traditional ML Methods                  |
| Vulnerability Severity Assessment | NLP, Traditional ML Methods                  |

| CYBERSECURITY TASK                         | UNDERLYING TECHNOLOGY OF NEW AI APPLICATIONS |
|--------------------------------------------|----------------------------------------------|
| Accurate Detection                         | Deep Learning                                |
| Alert Prioritization                       | Deep Learning                                |
| Adversarial Hardening of Detection Systems | GANs                                         |

| CYBERSECURITY TASK    | UNDERLYING TECHNOLOGY OF NEW AI APPLICATIONS |
|-----------------------|----------------------------------------------|
| Adversary Engagement  | Reinforcement Learning                       |
| Moving Target Defense | Reinforcement Learning                       |

| CYBERSECURITY TASK                | UNDERLYING TECHNOLOGY OF NEW AI APPLICATIONS |
|-----------------------------------|----------------------------------------------|
| Deceptive Document Generation     | NLP, GANs                                    |
| Dynamic Honeypotting              | Reinforcement Learning                       |
| Automated Phishing Response       | NLP, Reinforcement Learning                  |
| Dark Web Threat Intelligence      | NLP                                          |
| Attack Clustering for Attribution | NLP, Traditional ML Methods                  |
| Code De-Anonymization             | NLP                                          |

# Какие могут быть варианты оценки соответствия интеллектуальных СЗИ?




# Оценка соответствия и системы сертификации СЗИ по требованиям БИ

- Сертификация СЗИ
- Аттестация ОИ
- Обязательная сертификация
  - Минобороны России
  - ФСБ России
  - ФСТЭК России
- Добровольная сертификация
  - Банки
  - другие
- Сертификация
  - СЗИ
  - СМИБ



# Примеры вариантов требований

13



# Профильные технические комитеты

14

- ТК-164 «Искусственный интеллект»
- ТК-362 «Защита информации»
- ТК-26 «Криптографическая защита информации»
- ТК-22 «Информационные технологии»
- ТК-122 «Стандарты финансовых операций»
- другие
- ISO/IEC JTC 1/SC 42 Artificial intelligence
- ISO/IEC JTC 1/SC 27 Information security, cybersecurity and privacy protection
- другие

# Примеры стандартов в области ИИ, релевантных ИБ

15

- По линии ISO/IEC JTC 42 – 11 стандартов, в разработке 26
  - ISO/IEC TR 24028:2020 IT— Artificial intelligence — Overview of trustworthiness in artificial intelligence
  - ISO/IEC AWI TR 5469 Artificial intelligence — Functional safety and AI systems
  - ISO/IEC DIS 23894 IT— Artificial intelligence — Risk management
  - ISO/IEC AWI TS 29119-11 IT — Artificial intelligence — Testing for AI systems — Part 11:
  - ...
- По линии ISO/IEC JTC 27
  - ISO/IEC AWI 27562 Security and privacy in artificial intelligence use cases
  - ISO/IEC DTR 27563 Impact of security and privacy in artificial intelligence
  - ....

## ■ gost.ru – 11 стандартов

### РЕЗУЛЬТАТЫ ПОИСКА

Найдено: 11 документов

| Обозначение ГОСТ                    | Наименование                                                                                                                                                                                                                                 |
|-------------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| <a href="#">ГОСТ Р 59276-2020</a>   | Системы искусственного интеллекта. Способы обеспечения доверия. Общие положения                                                                                                                                                              |
| <a href="#">ГОСТ Р 59277-2020</a>   | Системы искусственного интеллекта. Классификация систем искусственного интеллекта                                                                                                                                                            |
| <a href="#">ГОСТ Р 59900-2021</a>   | Системы искусственного интеллекта. Типовые требования к контрольным выборкам исходных данных для испытания систем искусственного интеллекта в образовании                                                                                    |
| <a href="#">ГОСТ Р 59920-2021</a>   | Системы искусственного интеллекта. Системы искусственного интеллекта в сельском хозяйстве. Требования к обеспечению характеристик эксплуатационной безопасности систем автоматизированного управления движением сельскохозяйственной техники |
| <a href="#">ГОСТ Р 59921.2-2021</a> | Системы искусственного интеллекта в клинической медицине. Часть 2. Программа и методика технических испытаний                                                                                                                                |
| <a href="#">ГОСТ Р 59921.3-2021</a> | Системы искусственного интеллекта в клинической медицине. Часть 3. Управление изменениями в системах искусственного интеллекта с непрерывным обучением                                                                                       |
| <a href="#">ГОСТ Р 59921.4-2021</a> | Системы искусственного интеллекта в клинической медицине. Часть 4. Оценка и контроль эксплуатационных параметров                                                                                                                             |
| <a href="#">ГОСТ Р 59921.5-2022</a> | Системы искусственного интеллекта в клинической медицине. Часть 5. Требования к структуре и порядку применения набора данных для обучения и тестирования алгоритмов                                                                          |

# Пример системы сертификации систем машинного обучения TÜV

16


Требования:

- фактическое функционирование (РДВ)
- надежность обученной машины
- безопасность ПО
- соответствие требованиям сферы применения ПО (НДВ)
- обеспечение защиты и конфиденциальности данных
- этические аспекты взаимодействия машины и человека



# Пример сертификации интеллектуального СЗИ по линии **Common Criteria**

- UEBA (machine learning) LogPoint SIEM



# Выводы и предложения

- Отсутствие нормативной и методической базы в области применения технологии ИИ в области ИБ создает угрозы различного уровня вплоть до глобального
- Вопрос создания подсистемы, регулирующей ИБ интеллектуальных систем защиты, вопрос времени по объективным причинам
- Чем быстрее будут исследованы вопросы применения ИИ в области ИБ, тем быстрее страна получит стратегическое преимущество в глобальном ИПБ
- В ряде систем сертификации средств защиты информации это можно сделать различными способами
- Вопросы стандартизации могут лежать на стыке работы различных ТК
- Очевидна важность гармонизации международной нормативной базы в области ИИ и ИБ, а также разработки отечественных НПА и методических документов
- Чрезвычайно актуальным является исследование эффективности применения технологий ИИ в области оценки соответствия (аудита, анализа защищенности, сертификационных и аттестационных испытаний и др).

**СПАСИБО ЗА  
ВНИМАНИЕ!**

Марков Алексей Сергеевич  
[a.markov@npo-echelon.ru](mailto:a.markov@npo-echelon.ru)