

- [5] А. Ж. Асамбаев Жасанды интеллект негіздері: Оқулық. Алматы, ЖШС РПБК «Дәуір» 2011 ж. – 136 б

## ОБНАРУЖЕНИЕ И КЛАССИФИКАЦИЯ ВРЕДНОСНОГО ПО С ПРИМЕНЕНИЕМ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

Амангелді Ернұр<sup>1</sup>

<sup>1</sup>Кафедра систем информационной безопасности, факультет информационных технологий, Евразийский национальный университет им. Л.Н. Гумилева, Астана, Казахстан  
E-mail: Salomat423@gmail.com

### Аннотация

В последние годы, искусственный интеллект (ИИ) превратился в мощный инструмент для борьбы со стремительно растущим количеством вредоносных программных обеспечений (ПО). Эта статья представляет краткий обзор возможностей на основе ИИ для автоматизации обнаружения вредоносных программ и классификаций за период с 2018 по 2025 год.

Исследование суммирует главные нейронные архитектуры, ключевые датасеты, практические результаты, существующие сложности и большинство направлений исследований. Особое внимание уделено на сравнение основанных на ИИ подходах со стандартными методами защиты, оценке их преимуществ и ограничениях в реальных сценариях.

С каждым годом, вредоносное программное обеспечение становится более сложным для его обнаружения. Стандартные методы обнаружения основанные на сигнатурах и заранее установленных правил показали неэффективность в идентификации новых, непредвиденных атак, особенно в уязвимостях нулевого дня. Методы статистического анализа легко обходятся через упаковки, обфускации или незначительных изменений кода, что позволяет киберпреступникам генерировать бесконечные вариации уникальных образцов вредоносного ПО [1, 2, 4].

Выходит, что искусственный интеллект, в частности машинное и глубокое обучение стали многообещающей альтернативой. Эти методы могут выявлять сложные зависимости функций, учиться с больших датасетов и адаптироваться к возрастающим типам угроз. К 2024 году больше половины коммерческих продуктов кибербезопасности стали интегрировать компоненты основанные на ИИ, включая облачные антивирусы и EDR системы [2, 9, 10].

**Введение** За последние годы в сфере изучения опознания и идентификации ранее незримых вариантов вредоносных программ значительно улучшились методы машинного обучения (МО) и глубокого обучения (ГО), сверточные нейронные сети (СНС) и гибридные модели при помощи обучения комплексных поведенческих и структурных паттернов из огромных датасетов [1, 2], изучаются графические модели определения структуры вредоносного кода [3].

Сверточные нейронные сети показали свою эффективность в статистическом анализе и конвертации исполняемых файлов в цветовой режим изображений, которые отображаются в оттенках серого цвета или байтовой последовательности для распознавания образов [6], пока рекуррентная нейронная сеть (РНС) и основанные на долгой краткосрочной

памяти (ДКП) сети эффективно работают в анализе таких динамических поведенческих особенностей как системные вызовы [7]. Основанные на трансформных архитектурах исследованы возможности обнаружения запутанных кодов и сложные угрозы при помощи фиксации долгосрочных зависимостей в последовательных данных [10]. Относительно недавние исследования также отметили потенциал возможностей графовых нейронных сетей (ГНС) в моделировании структур кода и обнаружения вирусов [3]. Разработаны тесты для обучения CIC-MalMem [2], EMBER [5], Malimg и Microsoft BIG 2015 [6].

Однако большинство проблем в кибербезопасности остаются в силе: враждебные атаки, запутывание, дисбаланс данных и ход связей моделей значительно снижают уровень надежности и достоверности моделей [1, 2, 4], а также высокие вычислительные требования и ограниченные возможности доступности данных остаются практическим барьером для внедрения систем [1].

Сравнение с традиционными подходами основанных на сигнатурах показывает, что пока МО модели превосходят статистические методы в обнаружениях, они восприимчивы к уклонению от состязательности и требуют постоянной переподготовки [1, 4]. Тем не менее, реальные ИИ приложения все чаще интегрируются в антивирусные обеспечения, системы обнаружения конечных точек и реагирования на них и инструменты сетевой безопасности [9, 10].

Новые тенденции объяснимого искусственного интеллекта (ОИИ), обучение с помощью нескольких шагов, мета-обучение и адаптация моделей в режиме реального времени показывают, что необходимо создать более устойчивые и адаптируемые системы обнаружения вредоносных программ [2, 3, 10]. Исследование нацелено на обобщение недавних достижений и идентификацию будущих направлений на создание интеллектуальных и надежных систем безопасности.

### **Подходы и архитектуры ИИ**

Современные системы обнаружения с возрастанием полагаются на архитектуры ГО способные на обработку как статических так, и динамических возможностей функции ПО. Среди самых частых используемых моделей являются свёрточные нейронные сети (СНС), рекуррентные нейронные сети (РНС), трансформеры и гибридные архитектуры [1][2][10].

СНС используются для анализа бинарных файлов, представляющих изображения или байтовые последовательности. Этот метод доказал свою эффективность в таких датасетах как Malimg и Microsoft BIG 2015, где классификация вредоносных ПО достигла 96.6% точности на основе визуализации PE файлов [6]. РНС хорошо справляется с динамическим анализом, к примеру классификации поведении ПО через последовательности в системных вызовах [7].

С 2020 года трансформерные модели захватили большое внимание в связи с их возможности фиксировать долгосрочные зависимости. Они могут анализировать последовательности вызовов API, токены и поведения в PowerShell или JavaScript скриптах. Благодаря механизмам саморегулирования, трансформерные модели имеют высокий уровень точности даже при наличии помех или небольших изменений [10].

Гибридные модели комбинируют СНС, РНС и трансформерные модели также получили широкое распространение. Эти модели захватывают локальные и глобальные зависимости кода [2]. Кроме того, возрастает интерес к графовым нейронным сетям (ГНС), которые могут анализировать контроль графов, функции вызова графов и других структур [3].

Для обучения этих моделей, были использованы разные датасеты: EMBER [5], CIC-

MalMem [2], Maling [6], а также VirusShare и Drebin (вредоносные программы для Android) [4] являются одними из наиболее распространенных. Однако многие из этих наборов данных устарели, несбалансированы или не отражают возникающие угрозы [2, 6].

### **Проблемы и перспективы**

Несмотря на явный прогресс в использовании основанных на ИИ программ для обнаружения вредоносного ПО, некоторые сложности остаются не решенными. Одной из ключевых проблем является устойчивость модели к методам обхода, такие как упаковка, обфускация, полиморфизм, а также к враждебным атакам, в те моменты когда образцы вредоносного ПО меняются, модифицируются для попыток обхода классификаторов [2, 4].

Вторая проблема это отсутствие возможности интерпретации. ГНС модели, особенно трансформерные, часто не дают объяснения почему какой-либо образец помечен как вредоносный [2, 10]. Такие моменты ограничивают уровень доверия к результатам анализа и усложняют внедрения в критические системы.

Также проблемой является недостаток данных для обучения или их недостоверность. Многие часто используемые датасеты устарели или не справляются с отражением новых типов вредоносных ПО, что сильно влияет на саму модель [2, 6].

Однако, открываются потенциально успешные тенденции. Исследования в методах объяснимого искусственного интеллекта (ОИИ) становятся все популярнее. Методы обучения с несколькими кадрами позволяют моделям хорошо работать даже на небольших или ранее неизвестных наборах данных [2, 10]. На данный момент, изучаются графические модели определения структуры вредоносного кода [3]. Современные исследования работают на повышение устойчивости к обходу и добавлению обновлений в модель в реальном времени без полных переделок.

### **Заключение**

Таким образом, использование ИИ значительно улучшило обнаружение вредоносных ПО и возможностей классификации. Современные архитектуры такие как СНС, РНС и трансформеры предоставляют высокую точность и являются способными к идентификации новых непредвиденных угроз. Однако присутствуют значительные угрозы: адверсариальные атаки, обфускация, нехватка интерпретируемости, ограниченность данных. ИИ модели требуют продолжительной адаптации к новым угрозам и оптимизации к реальным угрозам.

Будущие направления включают в себя развитие разработки ОИИ, обучение на малых выборках, адаптации к работе в реальном времени и графовые подходы. Эти инновации открывают путь от исследовательских прототипов к надежным, масштабным, а главное рабочим решениям в области кибербезопасности. ИИ не заменяет стандартные методы обнаружения, а дополняет их, создавая основу для будущих гибридных платформ кибербезопасности.

## **Список литературы**

- [1] Bensaoud, A., Kalita, J., Bensaoud, M. (2024). A survey of malware detection using deep learning. <https://doi.org/10.48550/arXiv.2407.19153>
- [2] Tayyab, U.-e.-H., Khan, F. B., Durad, M. H., Khan, A., Lee, Y. S. (2022). A survey of the recent

- trends in deep learning-based malware detection. *Journal of Cybersecurity and Privacy*, 2(4), 800–829. <https://doi.org/10.3390/jcp2040041>
- [3] Bilot, T., El Madhoun, N., Al Agha, K., Zouaoui, A. (2023). A survey on malware detection with graph representation learning. *ACM Computing Surveys*, 56(11), 1–36. <https://doi.org/10.1145/3664649>
- [4] Ucci, D., Aniello, L., Baldoni, R. (2019). Survey of machine learning techniques for malware analysis. *Computers Security*, 81, 123–147. <https://doi.org/10.1016/j.cose.2018.11.001>
- [5] Anderson, H. S., Roth, P. (2018). EMBER: An open dataset for training static PE malware machine learning models. *arXiv:1804.04637*. <https://doi.org/10.48550/arXiv.1804.04637>
- [6] Ni, S., Qian, Q., Zhang, R. (2018). Malware identification using visualization images and deep learning. *Computers Security*, 77, 871–885. <https://doi.org/10.1016/j.cose.2018.03.048>
- [7] Kolosnjaji, B., Zarras, A., Martinez, G., Eckert, C. (2018). Deep learning for classification of malware system call sequences. In *Proc. 26th European Signal Processing Conference (EUSIPCO)* (pp. 533–537). <https://doi.org/10.23919/EUSIPCO.2018.8553102>

## БІЛІМДІ ЦИФРЛАНДЫРУ ЖАҒДАЙЫНДА МАТЕМАТИКАЛЫҚ ҰҒЫМДАР ҚҰРЫЛЫМЫН МОДЕЛЬДЕУ

Әлдібаева Тұрағалды Әбіләкімқызы<sup>1</sup>, Кенжебаева Майра Өтенқызы<sup>2</sup>

<sup>1</sup>Алматы гуманитарлы-экономикалық университеті, Алматы қ., Қазақстан Республикасы  
E-mail: turash67@mail.ru

<sup>2</sup>Алматы гуманитарлы-экономикалық университеті, Алматы қ., Қазақстан Республикасы  
E-mail: maikent@mail.ru

Жалпы білімді цифрландыру негізгі әдебиеттерге сүйенетін болсақ, 1) білім ортасын трансформациялауға; 2) танымдық технологияларды дамытуға; 3) оқытуды дербестендіруге; 3) цифрлық сауаттылықты дамытуға; 4) пәнішілік байланысты жүзеге асыруға мүмкіндік береді. Нәтижесінде қандай да болмасын математикалық білімді мазмұндық және процессуалдық тұрғыда байытуға болады. Білім ортасын трансформациялау кезінде білімді цифрландыру оқу материалын ұсыну және ассимиляциялау тәсілін түбегейлі өзгертіп отырады. Бұл әсіресе математикаға қатысты, онда абстрактілі ұғымдар визуалды түсіндіруді қажет етеді. Осы бағытта М. Х. Чанкаев, Х. А. Гербеков, М. А. Сурхаев жазған «Цифрлық технологияларды енгізу және дамыту жағдайындағы математикалық білім» атты мақалада математикалық білімді жаңа цифрлық болмысқа бейімдеу қажеттігі атап көрсетіледі [1].

Танымдық технологияларды дамыту Н.П.Пучковтың пірінше интерактивтік модельдеу, виртуалды болмыс, жасанды интеллект сияқты заманауи цифрлық құралдар математикалық нысандарды визуализациялау мен манипуляциялау үшін бірегей мүмкіндіктер береді [2]. Оқытуды дербестендіру жағдайында цифрлық платформалар әрбір оқушының танымдық ерекшеліктері мен дайындық деңгейін ескере отырып, жеке білім беру траекторияларын жасауға мүмкіндік береді. Бұл мәселе «Цифрландыру дәуіріндегі математика және математикалық білім» атты үлкен жинақта жан-жақты талқыланып, дербестендірілген оқытудың қажеттілігі негізделген [3]. Цифрлық сауаттылықты қалыптастыру