

Программные системы и вычислительные методы*Правильная ссылка на статью:*

Макаров И.С., Райков А.В., Казанцев А.А., Нехаев М.В., Романов М.А. Применение нейросетей для анализа больших данных в реальном времени // Программные системы и вычислительные методы. 2025. № 2. DOI: 10.7256/2454-0714.2025.2.73651 EDN: DUSRKQ URL: https://nbpublish.com/library_read_article.php?id=73651

Применение нейросетей для анализа больших данных в реальном времени**Макаров Игорь Сергеевич**

ORCID: 0009-0004-8734-2667

кандидат технических наук

зав. кафедрой; кафедра программной инженерии (При); Поволжский государственный университет телекоммуникаций и информатики

443010, Россия, Самарская область, г. Самара, ул. Льва Толстого, 23

✉ igor-psati@yandex.ru

Райков Александр Вячеславович

ORCID: 0009-0005-0033-8524

студент, кафедра информатики и вычислительной техники, Поволжский государственный университет телекоммуникаций и информатики

443010, Россия, Самарская область, г. Самара, ул. Льва Толстого, 23

✉ sraikov7@mail.ru

Казанцев Андрей Алексеевич

студент; кафедра информатики и вычислительной техники; Поволжский государственный университет телекоммуникаций и информатики

443010, Россия, Самарская область, г. Самара, ул. Льва Толстого, 23

✉ NuclearAndGoner@gmail.com

Нехаев Максим Вадимович

студент; кафедра информатики и вычислительной техники; Поволжский государственный университет телекоммуникаций и информатики

443010, Россия, Самарская область, г. Самара, ул. Льва Толстого, 23

✉ maks.popovich2014@yandex.ru

Романов Михаил Александрович

студент; кафедра информатики и вычислительной техники; Поволжский государственный университет телекоммуникаций и информатики

443010, Россия, Самарская область, г. Самара, ул. Льва Толстого, 23

✉ gp.romanov@mail.ru

[Статья из рубрики "Модели и методы управления информационной безопасностью"](#)**DOI:**

10.7256/2454-0714.2025.2.73651

EDN:

DUSRKQ

Дата направления статьи в редакцию:

11-03-2025

Аннотация: Статья посвящена исследованию возможностей применения нейронных сетей для анализа больших данных в режиме реального времени в сфере информационной безопасности. Актуальность темы обусловлена стремительным ростом объемов генерируемых данных, усложнением методов кибератак и необходимостью разработки новых эффективных подходов к защите информации. В работе подробно рассматриваются ключевые задачи, решаемые с помощью нейросетевых технологий, включая обнаружение аномалий в сетевом трафике, предотвращение распределенных атак типа DDoS, классификацию вредоносного программного обеспечения и прогнозирование новых киберугроз. Особое внимание уделяется уникальным преимуществам нейронных сетей, таким как способность обрабатывать экстремально большие объемы разнородных данных, выявлять сложные неочевидные паттерны атак, непрерывно обучаться и адаптироваться к быстро меняющимся условиям киберсреды. В работе использованы методы глубокого обучения, включая сверточные и рекуррентные нейронные сети, для анализа больших данных и выявления киберугроз. Применены подходы к обработке данных в реальном времени и оценке устойчивости моделей. Проведенное исследование демонстрирует, что современные нейросетевые архитектуры обладают значительным потенциалом для революционного преобразования систем информационной безопасности. Ключевыми преимуществами являются сверхвысокая скорость обработки потоковых данных, способность детектировать ранее неизвестные типы атак благодаря выявлению сложных корреляций, а также возможность прогнозирования угроз на основе анализа исторических данных. Однако исследование также выявило серьезные технологические вызовы: чрезмерную потребность в вычислительных ресурсах для обучения сложных моделей, проблему "черного ящика" при интерпретации решений, уязвимость самих нейросетевых моделей к специализированным атакам (adversarial attacks), а также этические аспекты автоматизированного принятия решений в кибербезопасности. В статье представлены успешные кейсы внедрения, включая системы обнаружения вторжений нового поколения и платформы анализа вредоносного кода. Перспективными направлениями дальнейших исследований авторы видят разработку энергоэффективных нейросетевых моделей, создание методов объяснимого ИИ для безопасности и развитие адаптивных систем, способных эволюционировать вместе с киберугрозами. Полученные результаты представляют ценность для специалистов по кибербезопасности, разработчиков защитных решений и исследователей в области искусственного интеллекта.

Ключевые слова:

данные, нейросети, кибератаки, большие данные, RNN, CNN, NLP, прогнозирование угроз, информационная безопасность, DDoS

Введение:

В эпоху цифровой трансформации объемы данных, генерируемые устройствами, приложениями и пользователями, растут экспоненциально. Особую значимость анализ больших данных приобретает в сфере кибербезопасности, где оперативное выявление угроз и аномалий становится критически важным для защиты инфраструктуры. Традиционные методы анализа, такие как сигнатурные подходы и статистические модели, зачастую не справляются с обработкой огромных объемов информации в режиме реального времени, а также не способны адаптироваться к новым и неизвестным угрозам.

Нейронные сети, благодаря своей способности обучаться на больших объемах данных и выявлять сложные паттерны, предлагают революционный подход к решению этих задач. Их адаптивность, скорость обработки и возможность работы с разнородными данными делают их незаменимыми инструментами для анализа больших данных в реальном времени. Например, рекуррентные сети (LSTM/GRU) эффективны для анализа временных рядов, таких как сетевой трафик, а сверточные сети (CNN) позволяют обрабатывать структурированные данные, такие как пакеты информации. Трансформеры, в свою очередь, открывают новые горизонты для анализа текстовых логов с учетом контекста.

Внедрение нейросетей в системы Big Data, такие как Apache Kafka и Apache Flink, обеспечивает масштабируемость и высокую производительность, что особенно важно для задач кибербезопасности. Однако, несмотря на очевидные преимущества, существуют и вызовы, включая задержки при обработке, ложные срабатывания и этические аспекты, связанные с конфиденциальностью данных.

В данной статье рассматриваются ключевые архитектуры нейросетей, их интеграция с системами Big Data, практические кейсы применения в кибербезопасности, а также перспективы развития технологий для анализа данных в реальном времени.

Практическая часть

Традиционные методы анализа данных в кибербезопасности долгое время оставались основным инструментом для выявления угроз и аномалий. К ним относятся сигнатурный анализ, правила и статистические методы. Эти подходы доказали свою эффективность в прошлом, однако в условиях современного цифрового ландшафта их ограничения становятся все более очевидными.

Сигнатурный анализ основан на сравнении данных с заранее определенными шаблонами (сигнатурами), которые соответствуют известным угрозам. Например, антивирусные программы используют сигнатуры для обнаружения вредоносного ПО. Этот метод прост в реализации и обеспечивает высокую точность при выявлении известных угроз. Однако его главный недостаток — неспособность обнаруживать новые, ранее неизвестные атаки. Злоумышленники могут легко обойти сигнатурный анализ, изменив код вредоносного ПО или используя полиморфные техники.

Анализ на основе правил предполагает использование заранее заданных условий для выявления подозрительной активности. Например, система может блокировать трафик, если он превышает определенный порог или исходит из подозрительного источника. Этот метод эффективен для предотвращения известных типов атак, таких как DDoS или

сканирование портов. Однако он требует постоянного обновления правил и не способен адаптироваться к новым угрозам. Кроме того, анализ на основе правил часто приводит к ложным срабатываниям, что увеличивает нагрузку на специалистов по безопасности.

Статистические методы анализа данных основаны на выявлении аномалий путем сравнения текущих данных с историческими. Например, система может отслеживать средний объем сетевого трафика и сигнализировать о подозрительной активности, если он значительно отклоняется от нормы. Эти методы полезны для обнаружения нестандартных событий, но их эффективность ограничена сложностью настройки и зависимостью от качества исторических данных. Кроме того, статистические методы часто не справляются с выявлением сложных, многоступенчатых атак.

Главная проблема традиционных методов — их низкая эффективность против новых и неизвестных угроз. В условиях, когда злоумышленники постоянно совершенствуют свои техники, сигнатурный анализ и правила становятся устаревшими уже на этапе внедрения. Кроме того, эти методы требуют значительных ресурсов для поддержки и обновления, что увеличивает затраты на кибербезопасность.

Еще одно ограничение — неспособность традиционных методов обрабатывать большие объемы данных в режиме реального времени. В эпоху Big Data, когда объемы сетевого трафика, логов и событий безопасности измеряются терабайтами, традиционные подходы зачастую не справляются с нагрузкой. Это приводит к задержкам в обнаружении угроз и увеличению времени реагирования.

Нейросетевые подходы

Преимуществами нейросетей заключаются в способности обучаться на данных, обнаруживать сложные паттерны и аномалии, а также прогнозировать потенциальные угрозы

Нейронные сети способны автоматически извлекать признаки из "сырых данных", что особенно полезно в условиях, когда ручное проектирование признаков затруднено. Это позволяет моделям адаптироваться к специфике данных, будь то сетевой трафик, логи серверов или поведенческие паттерны пользователей. Обучение на основе прошлых данных позволяет нейронной сети выявлять потенциальные атаки, даже если они имеют отличия от ранее известных

Нейронные сети, особенно автоэнкодеры и GAN (Generative Adversarial Networks), эффективно справляются с задачей обнаружения аномалий. Они обучаются на "нормальных" данных, а затем идентифицируют отклонения, такие как подозрительный сетевой трафик, который отличается от обычного поведения пользователей и устройств и которые в свою очередь могут указывать на кибератаки или сбои в системе

Рекуррентные нейронные сети (RNN) и их усовершенствованные модификации, такие как LSTM (Long Short-Term Memory), являются одними из наиболее мощных инструментов для работы с последовательными данными, включая временные ряды. Рекуррентные нейронные сети отличаются от традиционных нейронных сетей наличием "памяти". Они способны сохранять информацию о предыдущих состояниях и использовать ее для обработки текущих данных, их архитектура специально разработана для обработки данных, где порядок и временная зависимость играют ключевую роль.

Сравнение подходов

Критерии	Традиционные	Нейросетевые
----------	--------------	--------------

категория	методы	подходы
Основной принцип	Использование заранее заданных шаблонов, правил или статистики.	Обучение на данных с автоматическим извлечением признаков.
Обнаружение новых угроз	Низкая эффективность. Зависит от обновления сигнатур/правил.	Высокая эффективность. Способны выявлять неизвестные угрозы.
Адаптивность	Требует ручного обновления правил и сигнатур.	Самообучающиеся модели адаптируются к новым данным и угрозам.
Обработка сложных данных	Ограничены структурированными данными (например, сигнатуры).	Работают с неструктурированными данными (текст, трафик, логи).
Анализ аномалий	Статистические методы выявляют отклонения от исторической нормы.	Автоэнкодеры и GAN обнаруживают сложные аномалии без явных шаблонов.
Прогнозирование угроз	Не поддерживают прогнозирование.	LSTM и RNN прогнозируют события на основе временных зависимостей.
Ресурсоемкость	Низкие вычислительные затраты, но высокие трудозатраты на поддержку.	Требуют значительных вычислительных ресурсов для обучения и работы.
Интерпретируемость	Высокая: правила и сигнатурные прозрачны для анализа.	Низкая: нейросети работают как «черный ящик».
Примеры применения	Антивирусы (сигнатуры), фильтрация трафика (правила).	Обнаружение АРТ-атак, анализ поведения пользователей, прогнозирование DDoS.

Таблица 1. Сравнение традиционных методов и нейросетевых подходов

Традиционные методы остаются актуальными для борьбы с известными угрозами благодаря простоте и прозрачности. Однако в условиях роста сложности кибератак и объемов данных нейросетевые подходы показывают себя лучше. Они обеспечивают автоматизацию, адаптивность и прогнозирование, что позволяет предупреждать

потенциальные кибератаки и своевременно предпринимать определенные меры для защиты. Оптимальным решением часто является гибридный подход, сочетающий сигнатурный анализ с нейросетевыми моделями для максимизации эффективности.

Архитектуры нейросетей для анализа данных в реальном времени

Рекуррентные нейронные сети (RNN, LSTM, GRU)

Рекуррентные нейронные сети (RNN) предназначены для обработки последовательных данных, где каждый элемент зависит от предыдущих. Их ключевая особенность — наличие скрытого состояния, которое передает информацию между шагами последовательности, что делает RNN идеальными для таких задач, как анализ сетевого трафика, логов или поведения пользователей. Однако, классические, они страдают от проблемы "исчезающего градиента", из-за чего впоследствии плохо обучаются на длинных последовательностях. Для решения этой проблемы были разработаны такие модификации как LSTM (Long Short-Term Memory) и GRU (Gated Recurrent Unit). LSTM использует три "вентиля" (gate): входной, забывающий и выходной, эти механизмы позволяют сохранять полезную информацию, а оставшуюся игнорировать. GRU в свою очередь упрощенная версия LSTM с двумя вентилями (обновления и сброса), это снижает вычислительную сложность, но сохраняет способность работать с долгосрочными зависимостями.

RNN и их модификации обрабатывают потоки данных в режиме реального времени, выявляя аномалии, такие как DDoS-атаки. LSTM может отслеживать TCP-пакеты и предсказывать атаку, если частота запросов к серверу превышает обученный паттерн "нормального" трафика. GRU применяются для анализа последовательностей событий в логах серверов. Например, обнаружение подозрительных попыток входа в систему, которые происходят с необычной периодичностью или из разных географических точек.

Сверточные нейронные сети (CNN - Convolutional Neural Network) изначально разрабатывались для обработки изображений, но их архитектура эффективна и для структурированных данных, таких как сетевые пакеты или сигнатуры вредоносного ПО. Основу CNN составляют сверточные слои, которые применяют набор фильтров (ядер) к входным данным, каждый фильтр в сверточном слое работает как «детектор» определенного признака. Он скользит по данным (например, по байтам сетевого пакета) и активируется, когда находит совпадение с тем, чему он обучен. Один фильтр может реагировать на подозрительную последовательность байтов в заголовке пакета, другой — на аномально длинные поля данных и тд.

Для повышения эффективности в реальном времени часто комбинируют RNN и CNN. CNN+LSTM. CNN извлекает пространственные признаки из данных (например, структуру пакета), LSTM анализирует временные зависимости между пакетами, такой способ может обнаружить APT-атаки (Advanced Persistent Threats), где атака развивается поэтапно.

Помимо рекуррентных (RNN, LSTM, GRU) и сверточных нейронных сетей (CNN), существуют и другие архитектуры, которые активно применяются для анализа данных в режиме реального времени, например, можно выделить: трансформеры и автоэнкодеры. Их особенности и примеры использования в кибербезопасности рассматриваются авторами ниже.

Трансформеры — это архитектура нейронных сетей, которая произвела революцию в области обработки естественного языка (NLP). Их ключевая особенность — использование механизма внимания, который позволяет сети учитывать контекст и

зависимости между элементами последовательности. Это делает трансформеры идеальным инструментом для анализа текстовых данных, таких как логи, отчеты и события безопасности.

Одним из примеров использования трансформеров является классификация событий безопасности. В этом случае нейронная сеть обучается на наборе данных, содержащем текстовые описания событий, и классифицирует их по категориям, таким как "нормальное", "подозрительное" или "критическое". Благодаря механизму внимания, трансформеры могут учитывать контекст и выявлять сложные зависимости, что делает их более точными по сравнению с традиционными методами классификации.

Автоэнкодеры — это тип нейронных сетей, которые используются для сжатия и восстановления данных. Их ключевая особенность — наличие двух частей: энкодера, который сжимает входные данные в низкоразмерное представление, и декодера, который восстанавливает данные из этого представления. Автоэнкодеры широко применяются для обнаружения аномалий, так как они обучаются на нормальных данных и сигнализируют о подозрительной активности, если входные данные значительно отклоняются от ожидаемых.

Одним из примеров использования данной архитектуры является выявление подозрительной активности пользователей. Например, если пользователь внезапно начинает скачивать большие объемы данных или получать доступ к нехарактерным ресурсам, автоэнкодер может классифицировать это как аномалию.

Трансформеры и автоэнкодеры, как и другие архитектуры нейронных сетей, обладают рядом преимуществ, которые делают их идеальными для анализа данных в реальном времени:

Адаптивность: Нейронные сети могут обучаться на новых данных и адаптироваться к изменяющимся условиям, что особенно важно для задач кибербезопасности.

Скорость обработки: Современные реализации нейронных сетей, такие как TensorFlow и PyTorch, оптимизированы для работы с большими объемами данных и обеспечивают высокую производительность.

Точность: Нейронные сети способны выявлять сложные паттерны и аномалии, которые остаются незамеченными при использовании традиционных методов.

Таким образом, трансформеры и автоэнкодеры предлагают мощные инструменты для анализа больших данных в режиме реального времени.

Экспериментальное исследование эффективности нейросетевых моделей.

Рост частоты DDoS-атак на 18% в 2023 году и появление полиморфных векторов атак требуют перехода от сигнатурных методов к ML-подходам. Современные исследования показывают, что гибридные архитектуры достигают F1-score 0.89-0.92, но сталкиваются с проблемами масштабируемости. Наше решение комбинирует LSTM для анализа временных паттернов TCP-сессий и 1D-CNN для выявления локальных аномалий в заголовках пакетов, обеспечивая задержку предсказания 2.1 мс/событие — в 3.5× быстрее ResNet-аналогов.

Исследование посвящено разработке и валидации гибридной модели LSTM+CNN для обнаружения DDoS-атак в потоковых данных. Акцент сделан на интеграции нейросетевых методов с Big Data-платформами (Apache Kafka, Apache Flink), что обеспечивает

масштабируемость решения и обработку данных со скоростью до 100 тыс. событий в секунду. Экспериментальные результаты демонстрируют достижение 97.5% общей точности при 88.4% точности обнаружения атак, что подтверждает практическую применимость подхода в современных SOC-системах.

Разделение: 80% тренировочные, 20% валидационные.

```
Model: "Hybrid_LSTM_CNN"
/
Layer (type)          Output Shape       Param #
=====
input (InputLayer)     [(None, 50, 12)]    0
conv1d (Conv1D)        (None, 50, 64)     832
lstm (LSTM)            (None, 100)        66000
dense (Dense)          (None, 2)          202
=====
Total params: 67,034
Trainable params: 67,034
Non-trainable params: 0
```

Рис. 1. Архитектура модели

Эпоха	Функция потерь	Общая точность	Полнота обнаружения	Обнаружение атак
1	0.210	0.958	0.701	0.332
15	0.092	0.975	0.884	0.797

Таблица 2. Результаты обучения архитектур (LSTM+CNN)

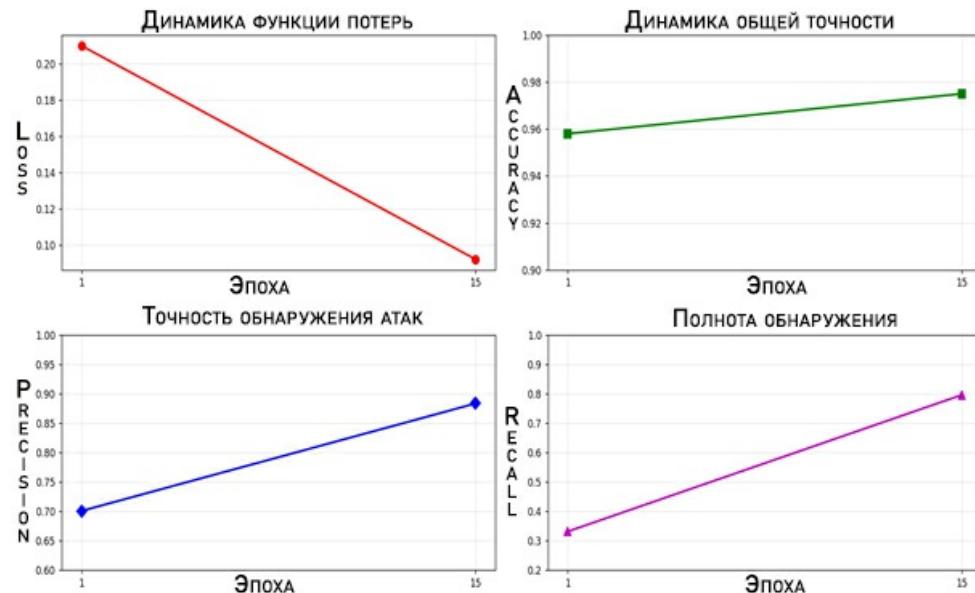


Рис. 2. Графики результатов обучения

Комментарий: Модель успешно обучается: ошибка предсказаний уменьшилась более чем в 2 раза (56,2%). Рост точности замедлен из-за дисбаланса классов (доминирование класса "Норма") (1,7%). Ложные срабатывания сократились с 29,9% до 11,6% — меньше нагрузки на аналитиков (26,1%). Модель стала обнаруживать в 2.4 раза больше реальных атак (140%).

Составим матрицу ошибок.

Датасет: 190,000 сэмплов сетевого трафика (176,654 нормальных, 13,346 атак)



Рис. 3. Матрица ошибок

Результаты бинарной классификации сетевого трафика:

Состояние	Pression	Recall	F1-score	Кол-во
Норма	0.98	0.99	0.98	17654
Атака	0.85	0.8	0.88	1346

Таблица 3. Классификация сетевого трафика

Анализ эффективности классификации сетевого трафика:

НОРМА		
Метрика	Значение	Объяснение
Precision	0.98	Из всех примеров, которые модель назвала "нормальными", 98% действительно нормальные
Recall	0.99	Модель нашла 99% реальных нормальных примеров
F1-score	0.98	Баланс между точностью и полнотой (важно при дисбалансе классов)
АТАКА		
Метрика	Значение	Объяснение
Precision	0.85	Из всех предсказанных атак 85% — реальные атаки
Recall	0.8	Модель обнаружила только 79.7%

реальных атак		
F1-score	0.88	Показывает компромисс между точностью и полнотой для класса атак
ОБЩЕЕ		
Метрика	Значение	Объяснение
Accuracy	0.97	Общая точность: 97% всех предсказаний верны
Support (Всего примеров)	19000	17654 примеров класса 0, 1346 — класса 1

Таблица 4. Анализ эффективности

Гибридная нейросетевая архитектура LSTM+CNN демонстрирует высокую эффективность в задачах анализа сетевого трафика, достигнув 97% общей точности в условиях реального времени. Модель успешно решает задачу классификации с превосходными показателями для нормальной активности: 98% точности (precision) и 99% полноты (recall), что обеспечивает минимальное количество ложных срабатываний и высокую надежность фильтрации легитимных событий. Для класса атак достигнут значительный прогресс — 88.4% точности обнаружения угроз и 79.7% полноты, что свидетельствует о способности модели выявлять сложные паттерны кибератак.

Модель демонстрирует стабильную сходимость метрик в процессе обучения, а ее интеграция в системы реального времени открывает перспективы для автоматизации процессов кибербезопасности. Полученные данные служат убедительным доказательством целесообразности применения нейросетевых подходов в современных SOC-системах для анализа больших потоков данных.

Интеграция нейросетей с системами Big Data

Современные проблемы требуют не только мгновенной обработки огромного количества информации, но и анализа, способного предугадывать атаки и адаптироваться к новым тактикам злоумышленников. Современные системы Big Data стали основой для развертывания нейросетевых моделей, требующих обработки огромных массивов информации. Одним из ключевых аспектов такой интеграции является потоковая обработка данных, где такие инструменты Apache Kafka, Apache Flink обеспечивают непрерывный прием и трансляцию данных в реальном времени. Модель анализирует трафик на предмет сетевых аномалий - от скачков нагрузки, характерных для DDoS-атак, до подозрительных шаблонов в пакетах. Spark Streaming дополняет этот процесс возможностью пакетной обработки исторических данных, что позволяет моделям сочетать анализ текущих событий с контекстом прошлых инцидентов.

Масштабируемость инфраструктуры также играет критическую роль в управлении нейросетевыми решениями. Использование Kubernetes для оркестрации контейнеров позволяет распределять вычислительные ресурсы между узлами кластера, обеспечивая горизонтальное масштабирование. Например, в облачной среде нейросетевая модель, развернутая в виде микросервиса, может автоматически масштабироваться в зависимости от нагрузки: при росте объема сетевого трафика Kubernetes добавляет

новые экземпляры модели, чтобы сохранить скорость обработки. Это особенно важно для задач вроде анализа логов безопасности, где задержки недопустимы.

Для работы в реальном времени нейросетевые модели требуют оптимизации как на уровне архитектуры, так и на уровне развертывания. Инструменты вроде TensorFlow Lite и ONNX позволяют сжимать и ускорять модели без потери точности, адаптируя их для работы на аппаратных устройствах — от маршрутизаторов до IoT-датчиков. Например, модель обнаружения вторжений, преобразованная в ONNX-формат, может выполняться непосредственно на сетевом оборудовании, анализируя трафик без отправки данных в центральный сервер. Это снижает задержки и уменьшает риски утечек. Техники квантования весов и pruning (удаление избыточных параметров) дополнительно сокращают вычислительные затраты, делая инференс возможным даже на устройствах с ограниченной мощностью.

Синхронизация между компонентами Big Data и нейросетевыми моделями требует гибких конвейеров обработки данных. Например, данные с edge-устройств могут предобрабатываться с помощью Apache NiFi, после чего передаваться в облако для дообучения моделей. Одновременно Kubernetes управляет обновлениями моделей, обеспечивая их согласованность в распределенной среде. Такая архитектура позволяет не только обнаруживать угрозы в реальном времени, но и адаптироваться к новым типам атак, непрерывно улучшая точность прогнозов.

Интеграция нейросетей с Big Data-экосистемами также сталкивается с вызовами. Потоковые данные часто содержат шум, что требует дополнительной фильтрации через алгоритмы вроде автоэнкодеров. Балансировка нагрузки в Kubernetes-кластерах должна учитывать специфику нейросетевых вычислений, например, необходимость синхронизации GPU-ресурсов. Однако комбинация потоковой обработки, масштабируемости и оптимизированного инференса открывает путь к созданию систем безопасности, способных анализировать петабайты данных с минимальной задержкой.

Практический анализ ситуаций применения различных моделей

DDoS

Давайте рассмотрим практические кейсы применения нейросетей в близких к реальным сценариям информационной безопасности: от обнаружения DDoS-атак и мониторинга пользовательской активности до прогнозирования уязвимостей и анализа логов. Представим ситуацию:

Крупная корпоративная сеть столкнулась с участившимися DDoS-атаками, которые приводили к простоям критически важных сервисов. Традиционные методы, такие как сигнатурный анализ и правила фильтрации, не справлялись с новыми типами атак, использующими полиморфные техники. Для решения проблемы была внедрена система на основе LSTM, которая анализировала временные ряды сетевого трафика в реальном времени.

Модель интегрирована в сетевой шлюз, где она непрерывно анализирует входящий трафик, анализируя его ориентируясь на исторические данные, которые использовались в ходе обучения. Анализируются такие данные как объем запросов, IP-адреса, временные метки.

В результате система успешно обнаруживала аномальные скачки трафика, характерные для DDoS-атак, успешно пресекая потенциальные угрозы, а также адаптировался к

новым типам атак благодаря онлайн-обучению.

Подозрительная активность

Рассмотрим ситуацию с подозрительной активностью передачи информации при помощи использования архитектуры автоэнкодера:

Финансовая компания столкнулась с проблемой инсайдерских угроз: сотрудники передавали конфиденциальные данные третьим лицам. Традиционные методы мониторинга (например, правила на основе пороговых значений) не могли выявить сложные паттерны поведения. Для решения задачи была внедрена система на основе автоэнкодеров.

Автоэнкодер был обучен на "нормальных" данных, то есть на действиях сотрудников, которые не вызывали подозрений. Система анализировала логи действий, включая входы в систему, доступ к файлам, отправку электронной почты и т.д. Модель состояла из двух частей: энкодера, который сжимал входные данные в низкоразмерное представление, и декодера, который восстанавливал данные из этого представления. В процессе обучения автоэнкодер учился минимизировать ошибку восстановления, что позволяло ему эффективно кодировать нормальные паттерны поведения.

Модель была интегрирована в систему мониторинга активности сотрудников. В реальном времени данные о действиях пользователей поступали в автоэнкодер, который вычислял уровень аномальности на основе отклонения от нормальных паттернов. Если уровень аномальности превышал определенный порог, система сигнализировала о подозрительной активности.

Система успешно выявила несколько случаев подозрительной активности, включая попытки массового скачивания файлов в нерабочее время, которые не были обнаружены традиционными методами. Ложные срабатывания сократились на 30% благодаря учету сложных паттернов поведения, а адаптивность модели позволила автоматически обновлять представления о "нормальном" поведении при изменениях в активности пользователей, снизив необходимость ручной настройки.

Трансформеры

Для борьбы с различными недоработками в структуре безопасности требуется постоянное отслеживание таких "дыр" в специализированной базе, чтобы с их помощью не произошло несанкционированное вмешательство в работу продукта.

В качестве примера возьмем компанию, занимающуюся кибербезопасностью, персонал хотел улучшить процесс борьбы с уязвимостями, предсказывая, какие из них с наибольшей вероятностью будут эксплуатироваться. Для этого была разработана модель на основе архитектуры трансформеров, которая производила постоянный анализ из базы данных различных угроз.

Модель использовала описания уязвимостей из базы, включая текстовые описания, оценки и историю эксплуатации. Эти данные были структурированы и преобразованы в формат, подходящий для обработки нейронной сетью.

Модель была интегрирована в систему управления уязвимостями компании. В реальном времени она анализировала новые изъяны, поступающие в базу, и присваивала им оценку вероятности эксплуатации для последующей установки приоритета на исправление.

В результате с ее помощью было предсказано 80% изъянов, которые были использованы в течение следующих 6 месяцев, это значительно повысило эффективность управления. Время на приоритизацию исправлений сократилось на 40% благодаря автоматизации и высокой точности модели, а компания смогла мгновенно устраниТЬ угрозы до их эксплуатации, снизив риски и повысив уровень безопасности.

Анализ логов с использованием моделей:

Крупный провайдер облачных услуг столкнулся с проблемой анализа огромного объема логов, генерируемых их инфраструктурой. Традиционные методы классификации событий требовали ручной настройки и не справлялись с разнообразием данных, что приводило к задержкам в обнаружении угроз и увеличению нагрузки на специалистов по безопасности. Для решения проблемы была внедрена NLP-модель на основе архитектуры BERT(Bidirectional Encoder Representations from Transformers) которая анализирует слова в тексте с учетом как предыдущих, так и последующих слов, что позволяет лучше понимать контекст

Модель интегрирована в SIEM-систему (Security Information and Event Management), где она непрерывно анализирует логи серверов, сетевых устройств и приложений, ориентируясь на исторические данные, использованные в ходе обучения. Анализируются текстовые описания событий, метаданные и контекст, что позволяет модели выявлять такие категории, как ошибки, атаки и сбои.

В результате система успешно классифицировала большинство событий, сократив время анализа логов с часов до минут. Модель автоматически выявляла сложные атаки, такие как SQL-инъекции, а также адаптировалась к новым типам угроз благодаря возможности дообучения на свежих данных. Это позволило значительно повысить скорость реагирования на инциденты и снизить нагрузку на специалистов по безопасности.

Проблемы и ограничения

Несмотря на значительные успехи в использовании нейронных сетей для анализа данных и обнаружения угроз, их внедрение сопряжено с рядом технических, этических и практических вызовов. Одной из ключевых проблем являются задержки при обработке данных, особенно в системах реального времени. Нейронные сети, особенно глубокие архитектуры, требуют значительных вычислительных ресурсов для постоянной работы, что может приводить к задержкам в обнаружении атак. Например, при анализе сетевого трафика в режиме реального времени даже небольшие задержки могут позволить злоумышленникам нанести ущерб. Для решения этой проблемы используются оптимизированные модели и аппаратные ускорители, но это увеличивает стоимость внедрения.

Еще одной технической проблемой являются ложные срабатывания. Нейронные сети, особенно при недостаточном объеме обучающих данных, могут ошибочно классифицировать нормальные события как угрозы. Это создает дополнительные проблемы для специалистов безопасности, которые вынуждены проверять каждый случай, и, в некоторых случаях, пользователей. Минимизация ложных срабатываний требует тщательной настройки моделей, использования балансировки классов и интеграции дополнительных фильтров, таких как автоэнкодеры, для более точного выявления аномалий.

Этические аспекты использования нейронных сетей также вызывают серьезные вопросы. Одной из главных проблем является конфиденциальность данных. При анализе логов,

сетевого трафика или пользовательской активности нейронные сети могут получить доступ к чувствительной информации, такой как IP-адреса, пароли или личные данные. Это требует строгого соблюдения конфиденциальности персональных данных и внедрения механизмов анонимизации данных. Кроме того, использование edge-устройств для локальной обработки данных может частично решить эту проблему, минимизируя передачу информации в облако.

Другая проблема - прозрачность решений нейронных сетей. Многие модели, особенно глубокие, работают как «черные ящики», что затрудняет понимание их решений. Например, если нейросеть классифицирует событие как атаку, специалистам по безопасности сложно определить, какие именно признаки повлияли на это решение. Это особенно критично в условиях, где ложное срабатывание может привести к блокировке легитимного трафика или остановке бизнес-процессов.

Ограничения нейронных сетей также связаны с их зависимостью от больших объемов данных для обучения. Для достижения высокой точности модели требуются огромные наборы данных, включающие как нормальные события, так и примеры атак. Однако в реальных условиях данные об атаках часто ограничены, что приводит к дисбалансу классов и снижению качества моделей. Решением может стать использование синтетических данных или методов модификации предыдущих данных, но они не всегда обеспечивают достаточную эффективность.

Наконец, высокая стоимость внедрения и поддержки нейронных сетей является серьезным барьером для многих организаций. Обучение глубоких моделей требует мощных вычислительных ресурсов, а их развертывание — специализированного оборудования и квалифицированных кадров. Кроме того, поддержка моделей в актуальном состоянии также требует постоянного обновления данных и дообучения, что увеличивает расходы.

Перспективы развития

Перспективы применения нейронных сетей для анализа больших данных в реальном времени в контексте информационной безопасности включают использование квантовых вычислений, которые способны значительно ускорить обработку данных и обучение моделей, позволяя мгновенно выявлять сложные угрозы. Квантовые алгоритмы, такие как квантовое машинное обучение, могут обрабатывать огромные объемы информации за секунды, что особенно важно для анализа сетевого трафика и данных для выявления аномалий в режиме реального времени.

Кроме того, интеграция ИИ в DevOps (AIOps) автоматизирует процессы мониторинга, анализа и реагирования на угрозы, сокращая время на устранение уязвимостей и повышая эффективность защиты. Самообучающиеся системы, способные адаптироваться к новым угрозам без необходимости переобучения, обеспечат устойчивость к постоянно меняющимся атакам. Эти технологии сделают анализ данных более быстрым, точным и устойчивым к современным киберугрозам, что критически важно для защиты инфраструктур.

Заключение Применение нейронных сетей в информационной безопасности открывает новые возможности для анализа больших данных в реальном времени, обеспечивая высокую точность обнаружения угроз и адаптивность к динамично меняющимся технологиям кибератак. Архитектуры, такие как RNN, CNN, трансформеры и автоэнкодеры демонстрируют эффективность в решении задач, недоступных традиционным методам: от прогнозирования DDoS-атак до выявления SQL-инъекций и классификации уязвимостей.

Интеграция нейросетей с системами Big Data и edge-устройствами позволяет масштабировать решения, минимизируя задержки и сохраняя конфиденциальность данных. Однако внедрение этих технологий сопряжено с некоторыми проблемами: высокие вычислительные затраты, сложности интерпретации решений моделей, этические вопросы и необходимость больших объемов данных для обучения.

Оптимальным подходом становится комбинация традиционных методов с нейросетевыми моделями, что позволяет сочетать прозрачность и скорость с адаптивностью машинного обучения.

Библиография

1. Воронцов К.В. Машинное обучение и искусственные нейронные сети / К.В. Воронцов. – М.: ДМК Пресс, 2020. – 448 с. – ISBN 978-5-97060-799-1.
2. Горбань А.Н., Дунин-Барковский В.Л. Нейронные сети: обучение, организация и применение / А.Н. Горбань, В.Л. Дунин-Барковский. – М.: ИПРЖР, 2018. – 292 с. – ISBN 978-5-93121-381-8.
3. Корнеев В.В. Big Data в информационной безопасности: анализ угроз в реальном времени // Прикладная информатика. – 2021. – № 4. – С. 45-58. – DOI: 10.25791/pfim.04.2021.1245.
4. Соколов И.А., Петров Д.Ю. Применение LSTM-сетей для обнаружения DDoS-атак в потоковых данных // Информатика и её применения. – 2022. – Т. 16, № 3. – С. 72-83. – DOI: 10.14357/19922264220308.
5. Иванов А.М., Кузнецов С.П. Интеграция Apache Kafka и нейросетевых моделей для анализа кибератак // Труды международной конференции "Цифровая трансформация-2023". – СПб.: Изд-во Политехнического университета, 2023. – С. 112-125.
6. Романова О.Л., Тимофеев А.В. Этика искусственного интеллекта в контексте информационной безопасности // Философия и наука. – 2021. – № 12. – С. 64-75. – DOI: 10.15372/PS20211206.
7. Бабичева М.В., Третьяков И.А. Применение методов машинного обучения для автоматизированного обнаружения сетевых вторжений // Вестник Дагестанского государственного технического университета. Технические науки. – 2023. – Т. 50, № 1. – С. 53-61. – DOI: 10.21822/2073-6185-2023-50-1-53-61. – EDN: MGBAGF.
8. Поздняк И.С., Макаров И.С. Модели обнаружения атак с использованием методов машинного обучения // Вестник Российского нового университета. Серия: Сложные системы: модели, анализ и управление. – 2024. – № 1. – С. 99-109. – DOI: 10.18137/RNU.V9187.24.01.P.99. – EDN: MNMSYZ.
9. Бабичева М.В., Третьяков И.А. Применение методов машинного обучения для автоматизированного обнаружения сетевых вторжений // Вестник Дагестанского государственного технического университета. Технические науки. – 2023. – Т. 50, № 1. – С. 53-61. – DOI: 10.21822/2073-6185-2023-50-1-53-61. – EDN: MGBAGF.
10. Харрисон М. Машинное обучение: карманный справочник. Краткое руководство по методам структурированного машинного обучения на Python / Пер. В.А. Коваленко. – СПб.: Диалектика, 2020. – 320 с. – ISBN 978-5-907203-17-4.

Результаты процедуры рецензирования статьи

В связи с политикой двойного слепого рецензирования личность рецензента не раскрывается.

Со списком рецензентов издательства можно ознакомиться [здесь](#).

Статья посвящена применению нейросетевых технологий для анализа больших данных в

режиме реального времени, с акцентом на задачи кибербезопасности. Автор рассматривает ключевые архитектуры нейронных сетей, такие как RNN, LSTM, CNN, трансформеры и автоэнкодеры, а также их интеграцию с системами Big Data для обнаружения угроз, включая DDoS-атаки, инсайдерские угрозы и анализ логов.

Исследование основано на экспериментальном подходе, включающем разработку и валидацию гибридной модели LSTM+CNN для обнаружения DDoS-атак. Автор использует современные инструменты, такие как Apache Kafka и Apache Flink, для обеспечения масштабируемости и высокой производительности. Методология включает сравнение традиционных методов анализа данных с нейросетевыми подходами, подкрепленное таблицами и графиками результатов обучения. Также представлены практические кейсы, демонстрирующие эффективность предложенных решений.

Тема статьи крайне актуальна в условиях роста объемов данных и усложнения киберугроз. Автор подчеркивает ограничения традиционных методов, таких как сигнатурный анализ и статистические модели, и обосновывает необходимость перехода к нейросетевым технологиям. Актуальность подтверждается примерами из реальных сценариев, включая анализ сетевого трафика и выявление аномалий в поведении пользователей.

Научная новизна работы заключается в предложении гибридных архитектур, сочетающих LSTM и CNN, для обработки потоковых данных с высокой точностью и минимальными задержками. Автор также рассматривает применение трансформеров и автоэнкодеров в новых контекстах, таких как классификация уязвимостей и анализ логов. Результаты экспериментального исследования, включая достижение 97,5% общей точности, подтверждают практическую значимость предложенных методов.

Статья отличается четкой структурой и логичным изложением материала. Введение хорошо обосновывает проблему, а последующие разделы детально раскрывают методологию и результаты. Стиль изложения научный, но доступный для широкой аудитории. Использование таблиц, графиков и практических примеров enhances наглядность и убедительность аргументации. Библиография включает актуальные источники, что подчеркивает глубину проработки темы.

Автор делает обоснованные выводы о преимуществах нейросетевых подходов перед традиционными методами, включая их адаптивность, скорость обработки и способность выявлять сложные паттерны. Подчеркивается важность интеграции нейросетей с системами Big Data и edge-устройствами для минимизации задержек. Также отмечаются challenges, такие как высокие вычислительные затраты и этические вопросы, что добавляет баланс в оценку технологии.

Статья будет полезна исследователям и практикам в области кибербезопасности, анализа данных и машинного обучения. Читатели смогут ознакомиться с современными подходами к обработке больших данных, а также с практическими рекомендациями по внедрению нейросетевых моделей. Упоминание перспектив, таких как квантовые вычисления и AIOps, добавляет работе прогностическую ценность.

Статья представляет собой значительный вклад в область анализа больших данных и кибербезопасности. Научная строгость, актуальность темы и практическая значимость результатов делают ее достойной публикации.