

Исследование и оценка методов противодействия атакам, реализуемым на этапе проектирования систем, основанных на искусственном интеллекте

Ерыпалов К.И (Национальный Исследовательский Университет ИТМО)

**Воробьева Алиса Андреевна, кандидат технических наук, факультет информационных технологий, доцент
(Национальный Исследовательский Университет ИТМО)**

В представленной работе рассмотрены и проанализированы основные виды атак на обучающие наборы данных систем, основанные на искусственном интеллекте. Изучены и применены на практике методы защиты от данных атак. Сформированы выводы о наиболее опасных видах атак и наиболее эффективных методах противодействия.

Введение.

В настоящее время активное развитие получили информационные технологии, основанные на методах искусственного интеллекта (ИИ). Методы машинного обучения применяются во многих сферах современной жизни: в банках для оценки кредитных рисков, в промышленности для управления производством и минимизации потерь, в медицине для улучшения качества диагностирования, в маркетинге для предсказания действий покупателей, в биометрических технологиях. В 2020-2021 годах атаки злоумышленников были направлены в том числе и на такие системы. В аналитических отчетах отмечают, что один из трендов развития систем информационной безопасности направлен на развитие технологий защиты, основанных на ИИ, а также обеспечение безопасности информационных систем, основанных на искусственном интеллекте. Данные факты обуславливают актуальность данного исследования.

Основная часть.

Исследование заключается в поиске оптимальных методов защиты от атак на модель, основанную на ИИ. В работе рассмотрены три основных типа атак, реализуемых на этапе проектирования систем: внедрение данных (у злоумышленника отсутствует доступ к алгоритму, происходит внедрение состязательных примеров в обучающий набор данных с целью компрометации целевой модели), модификация данных (отсутствует доступ к самому алгоритму, но присутствует к обучающим данным, что позволяет модифицировать данные обучающей выборки для изменение целевой модели до использования данных в процессе обучения) и логическое искажение (злоумышленник может вмешиваться в алгоритм обучения, получая полный контроль над моделью). Проанализированы методы противодействия указанным атакам: создание генеративно-состязательной сети, скрытие градиента и сжатие признаков. Проведены эксперименты по оценке точности модели до реализации каждого из типов атак, после реализации атак и после применения указанных методов противодействия. Проведено сравнение полученных данных, результаты экспериментов проанализированы, сделаны выводы о том, какой вред могут нанести атаки и какие способы противодействия наиболее эффективны и рациональны.

Вывод

Проведены теоретические и экспериментальные исследования возможных атак на системы, основанные на искусственном интеллекте, и методов противодействия. По результатам исследования атаки проранжированы по степени опасности для системы, определены наиболее эффективные методы борьбы.