

УДК 004.056

## РАЗРАБОТКА АЛГОРИТМА ИНТЕРПРЕТАЦИИ МОДЕЛИ «ЧЕРНОГО ЯЩИКА» СВЕРТОЧНОЙ НЕЙРОННОЙ СЕТИ С ПОМОЩЬЮ МЕТОДА ОЦЕНКИ ГРАДИЕНТОВ

Гаврилова В. В. (Университет ИТМО)  
Научный руководитель – Менщиков А. А.  
(Университет ИТМО)

**Введение.** Объяснимость становится актуальной темой исследований благодаря прогрессу в области глубокого обучения. Ежегодно в развитие искусственного интеллекта вкладываются миллионы рублей. Технологическая индустрия старается увеличить количество генеративных моделей искусственного интеллекта. Однако существует проблема, которую следует рассматривать с наибольшим приоритетом: недоверие к искусственному интеллекту. Согласно результатам исследования ВЦИОМ [1], за последний год общее понимание россиян в области искусственного интеллекта достигло 87%. Однако доверие к технологиям искусственного интеллекта составляет лишь 55%. Повысить уровень доверия людей можно за счет объяснимого искусственного интеллекта. Один из методов предоставления объяснительной информации — атрибуция признаков. Её цель — определить вклад входных признаков в результат модели и выявить наблюдения, поддерживающие её решение. Существуют два подхода к атрибуции: «белый ящик» и «чёрный ящик». Методы «белого ящика» предполагают полный доступ к модели и создание точных объяснений, исследуя поток градиентов. Однако на практике такой доступ невозможен из-за соображений безопасности. Интерпретация «чёрного ящика» требуют только доступ на уровне запросов, что позволяет анализировать взаимосвязь между входными признаками и выходами модели.

**Основная часть.** В исследовании решаются следующие задачи:

1. Произведен анализ существующих атак на нейронные сети с низким уровнем интерпретируемости (черные ящики)
2. Произведено исследование существующих методов интерпретации
3. Разработан метод интерпретации черного ящика сверточной нейронной сети
4. Выполнен сравнительный анализ результатов работы разработанного метода с другим методом интерпретации

В результате проведенного исследования был разработан алгоритм интерпретации модели черного ящика сверточной нейронной сети с помощью метода оценки градиента. Целевой моделью является сверточная нейронная сеть (CNN), которая состоит из двух сверточных слоев с размером ядра 5, объединенных тремя полносвязными слоями с размерами 120, 84 и 10 соответственно. Обучение модели осуществлялось с помощью библиотеки PyTorch. Алгоритм вычисляет атрибуты признаков, создавая запросы путём наложения масок на различные варианты объясняемых данных, равномерно распределённых между объясняемыми данными и начальной точкой. Используя сгенерированные запросы, интерпретатор получает набор наблюдений, позволяющий оценить атрибуты признаков.

В качестве данных для обучения и интерпретации были использованы наборы MNIST и ImageNet.

В качестве поискового распределения для метода используется гауссово распределение, а количество запросов  $n$  фиксировано и составляет 5000 для всех тестовых настроек. Отклонение  $\sigma$ , определяющее разброс гауссианы, задано равным 1,0 для MNIST, учитывая полярность распределения значений пикселей. Для ImageNet, где значения пикселей распределены более равномерно,  $\sigma$  установлен на 0,3. Что касается базовой линии  $\hat{x}$ , то нулевая матрица используется при объяснении решений на полутоновых изображениях, в то время как базовая линия для ImageNet зависит от объяснимости экземпляра. Для каждого объясняемого экземпляра из ImageNet базовая линия — это размытая версия самой себя.

Чтобы объективно оценить эффективность интерпретаторов, необходимо оценить качество объяснений по известному методу «оценке через удаление». Процесс оценки следует интуитивной, но эффективной идее: удаление релевантных признаков должно вызывать большее падение уверенности в предсказании. При оценке через удаление пиксели удаляются последовательно в порядке убывания в соответствии с их оценками атрибуции. Тенденция изменения уверенности в предсказании рисует кривую на протяжении всего процесса удаления, а площадь над кривой возмущения (АОРС) рассматривается как метрика для количественной оценки эффективности объяснения. По сравнению с методом интегрированных градиентов (является методом интерпретации белого ящика), предложенный алгоритм достигает схожих результатов, что согласуется с наблюдениями о визуальном сходстве их тепловых карт в качественной оценке. Для более простых тестовых случаев предложенный метод даже добивается лучших результатов, что следует интерпретировать как улучшение, вызванное более гладкой аппроксимацией интеграла пути.

**Выводы.** По результатам исследований был произведен анализ полученных результатов и их сравнение с работами других авторов. Точность интерпретации предложенного алгоритма не уступает точности современных методов интерпретации на наборе данных MNIST и уступает на 0.02% методу интерпретации белого ящика на наборе данных ImageNet.

#### **Список использованных источников:**

1. Национальные приоритеты URL:  
<https://национальныеприоритеты.рф/news/informirovannost-i-doverie-rossiyan-tekhnologiyam-ii-povysilis-za-posledniy-god/#:~:text=Уверенная%20информированность%20о%20технологиях%20искусственного,и%20составил%2055%25>. (дата обращения: 10.06.24).
2. Joakim Edin, «Normalized АОРС: Fixing Misleading Faithfulness Metrics for Feature Attribution Explainability» – 2024 – URL: <https://arxiv.org/abs/2408.08137>

Гаврилова В. В. (автор) Подпись

Менщиков А. А. (научный руководитель) Подпись