

УДК 004.89

## МЕТОДЫ ИНТЕРПРЕТАЦИИ МОДЕЛЕЙ МАШИННОГО ОБУЧЕНИЯ

Хахимов Р.А. (Университет ИТМО)

Научный руководитель – д.т.н., старший научный сотрудник Котельников Е.В.  
(Национальный центр когнитивных разработок Университета ИТМО)

В ходе данной работы рассмотрены вопросы значимости интерпретации моделей, последние достижения в интерпретируемости моделей машинного обучения, затронуты актуальные методы интерпретации, проанализированы основные принципы методов глобальной и локальной интерпретации.

### Введение.

Методы машинного обучения используются для принятия решений, влияющих на отдельных людей, и, как следствие, вызывают много вопросов со стороны общества и исследователей. Можно ли доверять полученной модели? Корректна ли такая модель? Какие факторы наиболее важны? Не получилось ли решение дискриминационным? Что можно сделать, чтобы изменить результат?

### Основная часть.

Основными причинами необходимости интерпретации ML-моделей выступают юридические и этические аспекты, факторы доверия к работе модели, а также потребность в тестировании и улучшении модели. Прикладное применение методов интерпретации моделей машинного обучения наиболее востребовано в тех областях принятия решений, в которых стоимость ошибки чрезвычайно высока, например в здравоохранении и правосудии.

Способы интерпретации моделей машинного обучения делятся на локальные и глобальные. Глобальные методы призваны показать, какие факторы в целом оказывают наибольшее влияние на структуру модели и на ее предсказания. Локальные методы пытаются объяснить то, как было сделано данное конкретное предсказание. Зачастую локальные методы могут быть использованы как основа для более глобальной интерпретации.

### Выводы.

В ходе работы были рассмотрены глобальные методы интерпретации моделей – важность признаков, график частичной зависимости и визуальное исследование переменных, а также локальные методы – локальные суррогатные модели и интерпретация значения Шепли.

Экспериментальное исследование было посвящено сравнению методов интерпретации для модели прогнозирования аренды велосипедов. Были исследованы методы важности каждой функции при прогнозировании аренды велосипедов с помощью метода опорных векторов, график частичной зависимости и визуального исследования переменных. объяснения локальных суррогатных моделей для двух экземпляров набора данных о прокате велосипедов и объяснения Шепли для предсказания аренды велосипедов на один день.

Хахимов Р.А. (автор)

Подпись

Котельников Е.В. (научный руководитель)

Подпись