

Модели машинного обучения для предсказания ухода пользователей

Курбанов Рауф Эльшад оглы

Санкт-Петербургский государственный университет
Математико-механический факультет
Кафедра Системного программирования

Научный руководитель: д. ф.-м. н., профессор А. Н. Терехов
Рецензент: технический директор ООО "Лаборатория Анализа Данных" А. Г. Натекин

Санкт-Петербург
2015г.

Актуальность задачи



Существующие решения

Решения в телекоммуникационной сфере:

- Формат данных специфичен для области
- Пространство признаков мало
- Сложно переиспользовать

Решения, основанные на модели:

- Посвящены применению модели, а не решению задачи
- Жертвуют точностью предсказаний за счёт универсальности
- Упускают специфику задачи оттока

Постановка задачи

- Цель работы
 - Описать решение проблемы ухода с помощью машинного обучения на примере данных крупного интернет-провайдера
- Постановка задачи
 - Провести подготовку данных о пользователях широкополосного доступа в интернет
 - Сравнить наиболее подходящие модели для предсказания ухода и выбрать лучшую для нашей задачи.
 - Реализовать прототип системы для предсказания ухода абонентов

Подготовка данных

- 257 столбцов
- 6 500 000 записей
- 176 000 пользователей
- 90 000 пользователей активных хотя бы 9 месяцев

Номер договора	Номер месяца	Количество дней с предыдущего платежа	Информация об абоненте	...
:	:	:	:	:

Построение признаков

Для каждого параметра X строится следующий какскад признаков:


- $X.diff$: плавающие разности соседних значений признака X
- $X.sum.3$: плавающие суммы значений признака X за 3 дня
- $X.max.3$ плавающий максимум значений признака X за 3 дня
- $X.mean.3$: плавающее среднее значения признака X за 3 дня
- $X.mean3.d$: плавающее среднее трёх соседних значений $X.diff$
- $X.max.3.d$: плавающий максимум трёх соседних значений $X.diff$

Результаты классификации


Модель	ACC	PREC	RECALL	F1	AUC
xgboost	0.99350	0.99893	0.99986	0.99652	0.99993
gbm	0.99757	0.98829	0.99038	0.98933	0.99757
random forest	0.99890	0.99839	0.99199	0.99518	0.99589

Сравнение моделей

ROC-кривые



Интерпретация модели



Реализация

В разработанной системе были реализованы следующие функции:

- Параллелизм на этапе обучения
- Оптимизированная работа с разреженными данными
- Автоматизация кросс-валидации гиперпараметров

Результаты

В ходе работы были получены следующие результаты:

- Проведена обработка данных о пользователях широкополосного доступа в интернет
- По результатам исследования выбрана и модифицирована эффективная модель для предсказания оттока
- Реализован и протестирован на реальных данных прототип системы для предсказания ухода абонентов для интернет-провайдера