



Международный журнал информационных технологий и энергоэффективности

Сайт журнала:

<http://www.openaccessscience.ru/index.php/ijcse/>



УДК 004

## ОПРЕДЕЛЕНИЕ ПРАКТИЧЕСКОЙ ЗНАЧИМОСТИ И ЭКОНОМИЧЕСКОЙ ЭФФЕКТИВНОСТИ ОПТИМАЛЬНОГО СПОСОБА ВЗАИМОДЕЙСТВИЯ С КЛИЕНТОМ ДЛЯ УВЕЛИЧЕНИЯ ДОХОДНОСТИ МАРКЕТИНГОВЫХ КАМПАНИЙ И СНИЖЕНИЯ ИЗДЕРЖЕК НА НИХ

**Обливальный Н.Д.**

ФГБОУ ВО "Челябинский Государственный Университет", Челябинск, Россия (454001, г. Челябинск, ул. Братьев Кашириных, 129), e-mail: rfrepe@gmail.com

В данном исследовании предметом изучения была задача поиска оптимального способа взаимодействия с клиентами с целью повышения доходности маркетинговых кампаний и снижения издержек. Для достижения этой цели были выполнены следующие задачи: определен универсальный подход к моделированию эффекта коммуникации; обеспечивающий максимальную точность модели; определен универсальный метод Uplift моделирования; проведены A/B тесты подтверждающие практическую ценность методов и рассчитана экономическая эффективность на реальном кейсе. Решение задач было применено в качестве прикладной области телеком провайдера. Практический результат работы представляет собой сервис, который позволяет определить необходимость и оптимальный способ коммуникации с клиентами телеком провайдера, имеющими задолженность.

Ключевые слова: Uplift моделирование, машинное обучение, большие данные, коммуникация с клиентами, доходность маркетинговых кампаний, телеком провайдер, расчет экономической эффективности.

## DETERMINING THE PRACTICAL SIGNIFICANCE AND ECONOMIC EFFICIENCY OF THE OPTIMAL WAY OF INTERACTING WITH THE CLIENT TO INCREASE THE PROFITABILITY OF MARKETING CAMPAIGNS AND REDUCE THEIR COSTS

**Oblivalny N.D.**

Chelyabinsk State University, Chelyabinsk, Russia (454001, Chelyabinsk, Brothers Kashirin str., 129), e-mail: rfrepe@gmail.com

In this study, the subject of the study was the task of finding the optimal way to interact with customers in order to increase the profitability of marketing campaigns and reduce costs. To achieve this goal, the following tasks were performed: a universal approach to modeling the communication effect was determined; providing maximum accuracy of the model; a universal method of Uplift modeling was determined; A/B tests were conducted confirming the practical value of the methods and economic efficiency was calculated on a real case. Problem solving was applied as an application area of a telecom provider. The practical result of the work is a service that allows you to determine the need and the optimal way to communicate with customers of a telecom provider who have debts.

Keywords: Uplift modeling, machine learning, big data, communication with customers, profitability of marketing campaigns, telecom provider, calculation of economic efficiency.

Современные технологии играют важную роль в бизнесе, особенно в сегменте B2C. Взаимодействие с клиентом является ключевым элементом любого бизнеса, нацеленного на увеличение доходов. Правильное взаимодействие мотивирует клиентов на действия, такие как: оформление подписки, покупка товара и т.д. Выбор наиболее эффективного канала связи с клиентом актуален и при планировании бюджета, необходимо грамотно распределить средства и добиться выполнения стратегических целей. Однако информационный шум, вызванный неконтролируемым количеством уведомлений, может снизить внимание клиентов и уменьшить эффективность каналов коммуникации. В связи с этим, данная магистерская диссертация предлагает решение по определению наилучшего способа взаимодействия с клиентами для достижения желаемой эффективности маркетинговых компаний.

### **Методы**

Uplift моделирование - это метод машинного обучения, который используется для определения воздействия на клиентов в маркетинговых кампаниях [2]. В отличие от классических моделей, которые прогнозируют вероятность реакции клиентов на воздействие, uplift моделирование определяет, насколько сильно клиент изменит свое поведение в ответ на воздействие, и измеряет этот эффект в абсолютных числах.

Основным понятием в uplift моделировании является uplift (подъем) - это разница между вероятностью реакции клиента на воздействие и вероятностью реакции на отсутствие воздействия. То есть uplift показывает реальный эффект воздействия на клиента, учитывая его индивидуальные характеристики.

Однако uplift моделирование имеет свои ограничения [6]. Оно может не учитывать другие факторы, которые могут влиять на поведение клиентов, например, экономическую ситуацию или изменения в рынке. Кроме того, этот метод требует большого объема данных и тщательного подбора моделей для достижения точных результатов. Поэтому важно определить их степень влияния на конечный результат, так как при выборе универсального подхода они могут оказать решающее значение.

В рамках данной работы будут рассматриваться три основных метода: метод с использованием двух независимых моделей, метод преобразования класса и метод постоянный на использовании деревьев.

Метод, основанный на использовании двух моделей, является одним из подходов в uplift моделировании. Данный подход позволяет определить причинно-следственные связи между воздействием и поведением клиента. Данный подход состоит из двух моделей: модели прогнозирования вероятности реакции клиента на воздействие и модели прогнозирования вероятности реакции клиента на отсутствие воздействия. Затем uplift рассчитывается как разница между этими двумя вероятностями.

Метод преобразования класса (Class Transformation) в Uplift моделировании представляет собой подход, где целевая переменная изменяется перед обучением модели [5].

Вместо прямого прогнозирования uplift, метод преобразования класса предлагает прогнозировать измененную целевую переменную, которая является функцией от оригинальной целевой переменной и флага коммуникации (бинарный флаг, указывающий, была ли проведена коммуникация с клиентом).

Новый класс равен 1, если мы знаем, что на конкретном наблюдении результат при взаимодействии был бы таким же или лучше, как и в контрольной группе, если бы мы могли знать результат в обеих группах. Иначе новый класс будет равен 0.

Этот подход позволяет учесть влияние коммуникации на целевую переменную и сделать прогнозы на основе измененной целевой переменной.

Методы, основанные на деревьях в Uplift моделировании, являются эффективным и широко используемым подходом [3]. Они позволяют оценить влияние факторов на изменение целевой переменной в зависимости от воздействия на клиента.

Один из таких методов основан на использовании деревьев решений с измененным критерием разбиения. Вместо стандартных критериев, таких как энтропия или критерий Джини, используется дивергенция между распределениями целевой переменной у контрольной и целевой групп. Таким образом, дерево строится таким образом, чтобы максимизировать расстояние между этими распределениями.

Одним из преимуществ метода на основе деревьев с измененным критерием разбиения является возможность эффективной обработки категориальных признаков.

Одним из недостатков этого метода является то, что он может быть чувствителен к выбросам и неустойчив к изменению данных. Кроме того, он может потребовать большого количества данных для получения точных результатов.

В рамках предыдущей статьи «Определение оптимального способа взаимодействия с клиентом для увеличения доходности маркетинговых компаний и снижения издержек на них» были рассмотрены перечисленные методы и определен универсальный [1].

После проведения всех экспериментов можно выделить два метода. Результаты сравнения всех моделей представлены в таблице 1 [4, 8].

Лучшие результаты показал метод преобразования класса. Вторым по точности оказался метод с использованием двух независимых моделей. Оба подхода использовали в качестве классификатора XGBoost [7].

Для получения достоверных данных о качестве данных подходов для каждого из них было проведено А/В тестирование на реальных должниках телеком провайдера.

#### **А/В тестирование лучших методов**

Эксперименты с использованием А/В тестирования были поставлены на должниках телеком провайдера. Для этого были отобраны имеющие задолженность абоненты на начало месяца. Для каждого должника была собрана информация для получения прогноза, и определено значение uplift от взаимодействия с ним. В данном случае взаимодействием был звонок с напоминанием о задолженности.

Тестирование было проведено на двух лучших методах. Первым тестировался подход с использованием двух независимых моделей. Для этого были отобраны должники на начало месяца и разделены на 4 группы: «Убеждаемые», «Не беспокоить», «Лояльные» и «Потерянные». Каждая группа определяется по значению Uplift. На рисунке 1 представлено распределение должников по группе.

Лучшие результаты показал метод преобразования класса. Вторым по точности оказался метод с использованием двух независимых моделей. Оба подхода использовали в качестве классификатора XGBoost [7].

Для получения достоверных данных о качестве данных подходов для каждого из них было проведено А/В тестирование на реальных должниках телеком провайдера.

**Таблица 1 – Сравнение всех методов uplift моделирования**

Методы	f1 (целевой группы)	uplift@20%	AUQC
Две независимые модели	0.553	0.6594	0.3484
Две зависимые модели (зависимое представление данных)	0.53	0.0597	0.0903
Две зависимые модели (перекрестная зависимость)	0.051	0.0368	0.0846
<b>Class transformer (XGBoost)</b>	<b>0.58</b>	<b>0.855</b>	<b>0.3618</b>
Class transformer (CatBoost)	0.56	0.851	0.3472
Class transformer (LogReg)	0.51	0.832	0.3295
Decision Tree Classifier (Kullback-Leibler)	0.1	0.048	0.081
Decision Tree Classifier (Euclidean Distance)	0.23	0.136	0.102
Decision Tree Classifier (DDP)	0	0.02	0.078
Decision Tree Classifier (CTS)	0.28	0.15	0.067
Random Forest Classifier (Kullback-Leibler)	0.19	0.03	0.118
Random Forest Classifier (Euclidean Distance)	0.09	0.075	0.119
Random Forest Classifier (DDP)	0.11	0.08	0.115
Random Forest Classifier (CTS)	0.05	0.04	0.073

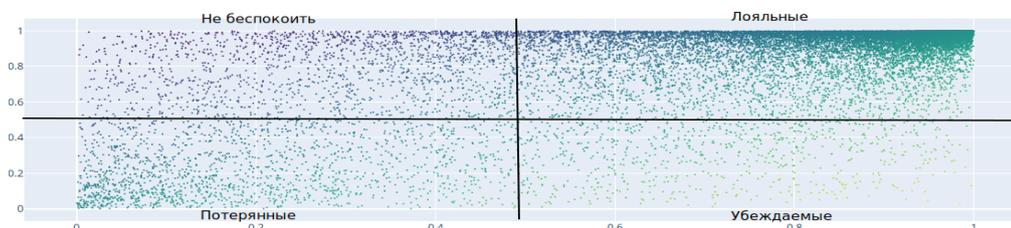
Источник: анализ автора

#### **А/В тестирование лучших методов**

Эксперименты с использованием А/В тестирования были поставлены на должниках телеком провайдера. Для этого были отобраны имеющие задолженность абоненты на начало месяца. Для каждого должника была собрана информация для получения прогноза, и определено значение uplift от взаимодействия с ним. В данном случае взаимодействием был звонок с напоминанием о задолженности.

Тестирование было проведено на двух лучших методах. Первым тестировался подход с использованием двух независимых моделей. Для этого были отобраны должники на начало

месяца и разделены на 4 группы: «Убеждаемые», «Не беспокоить», «Лояльные» и «Потерянные». Каждая группа определяется по значению Uplift. На рисунке №1 представлено распределение должников по группе.



**Рисунок 1 – Распределение должников по группам uplift**

*Источник: анализ автора*

Должники распределяются по группам по следующим условиям:

- Убеждаемые = uplift целевой >0.5 и uplift контрольной <= 0.5
- Лояльные = uplift целевой > 0.5 и uplift контрольной > 0.5
- Потерянные = uplift целевой < 0.5 и uplift контрольной < 0.5
- Не беспокоить = uplift целевой <= 0.5 и uplift контрольной > 0.5

Процент распределения должников по группам представлен в таблице №2

**Таблица 2. Процент распределения должников по группам uplift в апреле**

Группы	Процент от всех должников
Не беспокоить	10,66%
Потерянный	5,41%
Лояльный	74,12%
Убеждаемый	9,81%

*Источник: анализ автора*

По итогам первого А/В тестирования метода использования двух независимых моделей эффект от использования подтвердился. Результаты эксперимента представлены в таблице 3.

Как видно из таблицы 3 группа «Убеждаемые» имеет значимо больший процент при звонке, а группа «Не беспокоить» наоборот при звонке имеет меньшую конверсию в оплату. Остальные две группы не имеют статистической значимости.

Данные результаты подтверждают корректность работы модели и показывают на реальных данных прирост конверсии в оплату задолженности у должников.

В следующий календарный месяц было произведено тестирование второго метода с преобразованием класса. Распределение между группами Uplift имело похожее распределение. В таблице 4 процент распределения должников по группам uplift.

**Таблица 3 – Результаты А/В теста подхода с использованием двух независимых полей**

Группы	Конверсия в оплату		Доверительный интервал		Значимость
	А (звонок)	В (без звонка)	1	2	
<b>Убеждаемые</b>	30,65%	17,81%	-21,97%	-3,72%	Значимое
<b>Потерянные</b>	14,02%	10,57%	-8,08%	1,18%	Незначимое
<b>Лояльные</b>	64,73%	63,35%	-3,76%	1%	Незначимое
<b>Не беспокоить</b>	20,45%	25,48%	0,4%	10,03%	Значимое

*Источник: анализ автора*

**Таблица 4 – Процент распределения должников по группам uplift в мае**

Группы	Процент от всех должников
<b>Не беспокоить</b>	8,92%
<b>Потерянный</b>	7,65%
<b>Лояльный</b>	72,04%
<b>Убеждаемый</b>	11,39%

*Источник: анализ автора*

Результаты А/В тестирования метода с преобразованием класса представлены в таблице 5.

**Таблица 5 – Результаты А/В теста подхода с использованием метода преобразования класса**

Группы	Конверсия в оплату		Доверительный интервал		Значимость
	А (звонок)	В (без звонка)	1	2	
<b>Убеждаемые</b>	26,13%	9,52%	-24,23%	-9%	Значимое
<b>Потерянные</b>	9,41%	8,19%	-5,03%	2,59%	Незначимое
<b>Лояльные</b>	67,82%	68,66%	-1,43%	3,12%	Незначимое
<b>Не беспокоить</b>	16,85%	22,93%	0,77%	11,38%	Значимое

*Источник: анализ автора*

По итогам второго тестирования также подтвердилась теория взаимодействия с группами Uplift. Второй подход показал на реальных данных чуть больший прирост по

конверсии в оплату. Сравнение прироста конверсии по итогам двух тестов представлен в таблице 6.

**Таблица 6 – Сравнение прироста конверсии по итогам А/В тестирования**

Группы	Две независимые модели	Class transformer
Убеждаемые	12,84%	16,61%
Потерянные	3,45%	1,22%
Лояльные	1,38%	0,84%
Не беспокоить	5,03%	6,08%

*Источник: анализ автора*

По итогам А/В теста можно сделать вывод о том, что получившиеся модели действительно имеют практический эффект. Они определяют группу людей, с которыми коммуникация будет наиболее эффективна, и группу людей, с которыми нет практической ценности взаимодействовать.

#### **Экономическая эффективность модели.**

Для того, чтобы оценить экономическую эффективность, нужно определить, как именно модель будет влиять на текущую ситуацию. Ранее был описан основной эффект от использования Uplift моделирования на должниках.

Ключевым эффектом является сокращение выборки должников, с которыми нужно взаимодействовать для достижения оплаты задолженности. Получается за счет прогноза модели мы можем отобрать процент должников, с которыми нужно взаимодействовать.

По результатам проведенных тестов известно, что в среднем в каждом месяце всего 10% должников, с которыми нужно взаимодействовать. В данной ситуации мы можем сэкономить ресурс операторов и сократить количество звонков на 90%.

Вторым эффектом от использования Uplift является увеличение конверсии в целевое действие. В рассматриваемой прикладной задаче этот эффект наблюдается, но имеет совсем небольшие значения. С помощью модели можно увеличить конверсию в оплату у групп «Не беспокоить» на 5% и «Убеждаемые» на 13%. В абсолютных значениях (от общей конверсии) прирост составляет  $5\%*10\%$  (доля группы «Не беспокоить») +  $13\%*10\%$  (доля группы «Убеждаемые») = 1.8%.

Итоговый эффект от применения Uplift моделирования будет складываться из экономии на неэффективных звонках и увеличении возврата задолженности.

Обзвоном должников занимается отдельная группа операторов. Она состоит из 9 операторов. В месяц данная группа успевает обзвонить от 84%-92% должников. Если группа успевает поговорить с 85% должников, то часть операторов перенаправляется на другие типы обзвонив. Чаще всего на холодные обзвоны.

Для расчета стоимости обзвона должников необходимо определить стоимость одного оператора в месяц. Зарплата оператора составляет 32 000 рублей. С учетом налогов и накладных расходов один оператор обходится компании в  $32000*30\%+32000*60\%+32000 = 60$

800 рублей. В данной группе работает 9 человек и в месяц на них затрачивается 547 200 рублей.

Итоговая стоимость обзвона с применением и без применения Uplift моделирования показана в таблице 7.

**Таблица 7 – Стоимость обзвона должников**

Подход	Стоимость обзвона всех должников	Процент обзвона должников	Стоимость обслуживания процесса	Стоимость обзвона
Без применения Uplift	р.547 200	85%	р.0,00	р.465 120
С применением Uplift	р.547 200	10%	р.8 938	р.63 658

Источник: анализ автора

Для расчета увеличения процента оплаты от применения Uplift модели потребуется определить количество должников, вернувшихся за счет модели. Взяв процент прироста конверсии и умножив его на количество должников и на среднюю стоимость тарифа компании, мы получим экономический эффект от увеличения конверсии, 60 750 рублей.

Итоговый экономический эффект будет рассчитываться как разница между подходами и добавлением суммы увеличению конверсии в оплату, которая равна  $465120 - 63658 + 60750 = 462212$  рублей.

Как видно из расчетов при учете сокращения штата данные инвестиции на проект окупаются в первый же месяц. Но в реальности компания не стала прибегать к данному способу. Штат операторов не был сокращен, но был изменен бизнес-процесс.

В начале каждого месяца все 9 человек работают с должниками и после завершения необходимого количества номеров группа операторов переключалась на холодные звонки и на выявление адресов. В таком случае экономический эффект от применения Uplift модели не совсем корректно брать за снижение издержек.

Получается, что фактический прирост в погашении задолженности у должников составил всего 1,8% или 60 750 рублей.

Перейдем к расчету инвестиционных показателей: NPV, IRR, ROI, PI и DPP.

NPV (Net Present Value) или чистая приведенная стоимость – это текущая стоимость будущих денежных потоков инвестиционного проекта, рассчитанная с учетом дисконтирования, за вычетом инвестиций (1).

$$NPV = \sum_{t=0}^n \frac{CF_t}{(1 + R)^m}, (1)$$

где:

n, t — количество временных периодов,

m — количество периодов,

CF — денежный поток (Cash Flow),

R — стоимость капитала (ставка дисконтирования, Rate. Она складывается из ключевой ставки ЦБ РФ, уровня инфляции и рискованности проекта:  $7,25\% + 8,13\% + 7\% = 22,38\%$  по данным за 25 мая 2023 года).

NPV = 319 237 рубль. Таким образом, NPV проекта больше нуля. Это говорит о выгодности проекта.

Следующим исследуемым инвестиционным показателем будет IRR. IRR - это внутренняя норма доходности показывает процент, при котором приведенная стоимость всех денежных потоков инвестиционного проекта равна нулю, рассчитывается по формуле (2).

$$0 = \sum_{t=0}^n \frac{CF_t}{(1 + IRR)^t}$$

где:

CF t — денежные потоки от проекта в момент времени t;

n — количество периодов времени;

IRR — внутренняя норма доходности.

IRR = 19%. Таким образом, IRR больше ежемесячной ставки дисконтирования, что еще раз подтверждает выгодность реализации проекта.

Следующим на очереди будет показатель PI. PI - это отношение суммы прибыли к абсолютной величине инвестиций. Он показывает количество прибыли, которое удастся получить за каждую вложенную единицу средств. Формула для расчетов PI выглядит следующим образом (3):

$$PI = \frac{\sum_{n=1}^N \frac{NCF_n}{(1+R)^n}}{\sum_{n=1}^N \frac{I_n}{(1+R)^n}} = \frac{NPV}{I_0}, (3)$$

где:

CF n - чистый дисконтированный денежный поток в n периоде;

I n - начальные инвестиции в n периоде (или суммарные инвестиции);

R – ставка дисконтирования;

NPV (Net present value) – чистый дисконтированный (приведенный) доход.

$$PI = \frac{319\,237,40 \text{ руб.}}{239\,020 \text{ руб.}} = 1,34$$

Так как PI больше единицы, то проект выгоден.

Следующим рассматриваемым показателем является ROI. ROI — коэффициент окупаемости. Этот показатель демонстрирует прибыльность или убыточность той или иной инвестиции, измеряется в процентах. Чтобы его рассчитать, потребуется знать две вещи: доход от вложений и их размер. Формула для расчетов выглядит следующим образом (4):

$$ROI = \frac{\text{Доход от вложений} - \text{Расходы вложений}}{\text{Размер вложений}} \times 100\% (4)$$
$$ROI = \frac{729\,000 - 346\,276}{239\,020} \times 100 = 116,12\%$$

Так как ROI больше 100 процентов, то проект выгоден.

В конце будет рассмотрен дисконтированный период окупаемости DPP. Главное отличие от простой формулы срока окупаемости – это дисконтирование денежных потоков и приведение будущих денежных поступлений к текущему времени. Формула для расчета DPP выглядит следующим образом (5):

$$DPP = \min n, \text{ при котором } \sum_{t=1}^n \frac{CF_t}{(1+R)^t} > IC, (5)$$

где:

DPP (Discounted Payback Period) – дисконтированный срок окупаемости инвестиций;

$CF_t$  — денежные потоки от проекта в момент времени  $t$ ;

$n$  — количество периодов времени;

$R$  - ставка дисконтирования;

IC (Invest Capital) – первоначальные инвестиционные затраты в проекте.

Вложения окупятся уже в первый месяц. Выясним точный период окупаемости:

$$DPP = 5 \text{ мес.} + \left(1 - \frac{246\,374 - 239\,020}{47\,630} \times 30\right) \approx 25 \text{ дней}$$

Период окупаемости составляет 5 месяцев и 25 дней. Такой продолжительный срок объясняется тем, что мы не учитываем экономию за счет сокращения штата и извлечение выгоды для компании за счет перенаправления ресурсов на другие процессы.

После подсчета всех экономических показателей можно сделать вывод о выгодности реализации проекта. Все ключевые показатели указывают на положительный результат при внедрении модели в текущий бизнес-процесс.

### **Заключение**

В рамках исследования подходов к Uplift моделированию были определены универсальные подходы. Универсальным подходом стал метод преобразования класса. Но не менее высокие результаты показал метод с использованием двух независимых моделей. Оба метода являются универсальными, так как при условии дисбаланса между контрольной и целевой группой метод с использованием двух независимых моделей будет показывать результаты лучше, чем метод преобразования класса.

Оба алгоритма были проверены в реальных условиях при помощи A/B тестирования. По результатам тестирования была подтверждена ценность Uplift моделирования в работе с должниками телеком провайдера.

На основе проведенных тестов оценен экономический эффект от применения модели. Все инвестиции, вложенные в формирование универсального подхода к uplift моделированию окупаются за 6 месяцев.

Результаты данной работы были приняты для дальнейшего использования в провайдере для работы с должниками и другими задачами, связанными с взаимодействиями с клиентами.

### **Список литературы**

1. Обливальный Н.Д., Определение оптимального способа взаимодействия с клиентом для увеличения доходности маркетинговых кампаний и снижения издержек на них. Международный журнал информационных технологий и энергоэффективности, [s.l.], v.

- 8, n. 4(30), p. 084-091, апр. 2023. Issn 2500-1752. Режим доступа: <http://www.openaccessscience.ru/index.php/ijcse/article/view/327>., свободный
2. Artem Betlei, Eustache Diemert, Massih-Reza Amini. Uplift Modeling with Generalization Guarantees, 2021.
  3. Henrik Karlsson, Linda Wanstrom. Uplift Modeling: Identifying Optimal Treatment Group Allocation and Whom to Contact to Maximize Return on Investment, 2019.
  4. LogisticRegression documentation. - Режим доступа: <https://scikit-learn.org/stable/index.html>, свободный.
  5. Robin M. Gubela, Stefan Lessmann. Interpretable Multiple Treatment Revenue Uplift Modeling, 2021.
  6. Ta-Wei Huang, Eva Ascarza. When Less is More: Using Short-term Signals to Overcome Systematic Bias in Long-run Targeting, 2022.
  7. Xgboost documentation. - Режим доступа: <https://xgboost.readthedocs.io/en/stable/>, свободный.
  8. Catboost documentation. - Режим доступа : <https://catboost.ai/en/docs/>, свободный.

## References

1. Oblivny N.D., Determining the optimal way to interact with the client to increase the profitability of marketing campaigns and reduce their costs. International Journal of Information Technology and Energy Efficiency, [s.l.], v. 8, n. 4(30), p. 084-091, Apr. 2023. Issn 2500-1752. Access mode: <http://www.openaccessscience.ru/index.php/ijcse/article/view/327>., free
  2. Artem Betlei, Eustache Diemert, Massih-Reza Amini. Uplift Modeling with Generalization Guarantees, 2021.
  3. Henrik Karlsson, Linda Wanström. Uplift Modeling: Identifying Optimal Treatment Group Allocation and Whom to Contact to Maximize Return on Investment, 2019.
  4. LogisticRegression documentation. - Access mode: <https://scikit-learn.org/stable/index.html>, free.
  5. Robin M. Gubela, Stefan Lessmann. Interpretable Multiple Treatment Revenue Uplift Modeling, 2021.
  6. Ta-Wei Huang, Eva Ascarza. When Less is More: Using Short-term Signals to Overcome Systematic Bias in Long-run Targeting, 2022.
  7. Xgboost documentation. - Access mode: <https://xgboost.readthedocs.io/en/stable/>, free.
  8. Catboost documentation. - Access mode: <https://catboost.ai/en/docs/>, free.
-