

Выделение сегментов клиентов для эффективных маркетинговых коммуникаций на базе применения uplift-моделирования

Т.В. Азарнова, Е.В. Ярош

Воронежский государственный университет

Аннотация: Традиционные маркетинговые методы продвижения товаров и услуг ориентируются на широкую аудиторию и не учитывают индивидуальные характеристики потребителей, что может привести к небольшому проценту положительных откликов и даже к отрицательным откликам (потере клиентов). Широкий охват аудитории приводит к увеличению стоимости маркетинговых взаимодействий и не гарантирует достижение целей маркетинговых кампаний. В такой ситуации ставится задача минимизации избыточных расходов за счет более рациональной организации маркетингового взаимодействия, направленной на получение максимальной прибыли от каждого целевого клиента. Для реализации подобной стратегии необходимы инструменты, способные выделить сегменты клиентов, маркетинговое взаимодействие с которыми приведет к положительному отклику. Одной из технологий построения таких инструментов является uplift-моделирование, которое является разделом машинного обучения и считается перспективным направлением в data-driven маркетинге. В рамках данной статьи на базе открытых данных X5 RetailHero Uplift Modeling Dataset, предоставленных компанией X5 Retail Group, проводится сравнительный анализ эффективности различных подходов uplift-моделирования для выделения сегмента клиентов, которые наиболее подвержены целевому воздействию. Для проведения сравнительного анализа используются различные uplift-метрики и визуальные технологии.

Ключевые слова: эффективные маркетинговые коммуникации с клиентами, сегментирование клиентов, методы машинного обучения, uplift-моделирование, uplift-метрики качества.

Введение

Современный этап развития маркетинга и электронной коммерции характеризуется рядом ключевых тенденций, оказывающих существенное влияние на формирование стратегий взаимодействия с потребителями. К наиболее значимым из них можно отнести усиление конкуренции на рынке, стремительный рост объемов обрабатываемых данных и возрастающие ожидания клиентов в отношении персонализации сервиса. Все более важное место в современных маркетинговых стратегиях занимает учет психологических факторов поведения потребителей, так как на принятие покупательских решений значительное влияние оказывают эмоциональные

реакции, когнитивные искажения, а также механизмы социального влияния. Использование этих психологических закономерностей при коммуникации с клиентами позволяет компаниям повышать конверсию и улучшать общую результативность маркетинговых кампаний.

С позиции реакции на маркетинговые воздействия можно выделить четыре поведенческих типа клиентов, различающихся по степени восприимчивости к коммуникациям и потенциального интереса для компании. Для успешного взаимодействия с ними необходимо использовать различные стратегии.

Клиенты, негативно реагирующие на рекламные акции, формируют сегмент «Не беспокоить». Чрезмерная коммуникация с ними может привести к снижению лояльности и отказу от дальнейшего взаимодействия. Для этой группы наиболее рациональной стратегией является ограничение маркетинговых воздействий и концентрация на улучшении клиентского опыта. Группа «Потерянные» включает клиентов, которые не совершат целевое действие вне зависимости от маркетинговых усилий. Это может быть связано с потерей интереса к продукту, переходом к конкурентам или тем, что данные потребители изначально не входят в целевую аудиторию. Вложения в коммуникации с этой категорией не оправдывают себя, поскольку не приводят к успеху. Клиенты, которые совершают целевое действие, независимо от наличия маркетингового воздействия, формируют группу «Лояльные». Это постоянные покупатели, демонстрирующие устойчивую приверженность бренду. Дополнительные затраты на маркетинговое влияние с данным типом клиентов неэффективны. Вместо активного стимулирования важно сосредоточиться на поддержании высокого качества сервиса и развитии программ лояльности, избегая чрезмерного давления, которое может вызвать раздражение. Сегмент «Убеждаемые» представляет собой наиболее ценную группу – именно эти клиенты

совершают целевое действие только при наличии коммуникации [1]. Такие клиенты могут быть заинтересованы в продукте или услуге, но для покупки им необходим дополнительный стимул, которым может стать реклама, персонализированное предложение и др. Таким образом, важной задачей современного маркетинга становится выявление именно этой категории клиентов с целью оптимизации маркетинговых затрат. Для решения данной задачи можно использовать uplift-моделирование – метод машинного обучения, который позволяет не просто оценить вероятность совершения целевого действия клиентом, но и определить прирост вероятности совершения данного действия, вызванный маркетинговым воздействием [2].

Задачи и принципы uplift-моделирования

Uplift-моделирование реализует одномодельный или двухмодельный подход машинного обучения для прогнозирования вероятности некоторого целевого показателя [3].

Развитие технологий uplift-моделирования применительно к сфере маркетинга связано со стремлением повысить эффективность апробированных в данной области методов машинного обучения, таких как логистическая регрессия и деревья решений. Существенный вклад в систематизацию подходов к построению uplift-моделей внесён авторами работы [4], в которой структурированно, поэтапно описаны основные шаги процесса моделирования, начиная с отбора признаков и настройки параметров моделей, и заканчивая оценкой качества и интерпретацией результатов. В исследовании [4] приводится детальный анализ метода Significance-Based Uplift Trees, на базе которого были создано первое достаточно широко используемое в бизнесе программное обеспечение в сфере uplift-моделирования. В исследовании [5] рассматривается применение в uplift-моделировании деревьев решений с использованием специальных критериев – таких как дивергенция Кульбака-Лейблера и евклидова метрика.

Авторы работы [6] предложили метод True Lift Modelling, в котором uplift-эффект оценивается посредством включения в регрессионную модель дополнительных переменных, отражающих отклик на маркетинговое воздействие.

Uplift-моделирование базируется на вычислении разницы по вероятности отклика на конкретное воздействие (рекламная кампания, скидка) между схожими клиентами целевой группы, подвергшейся воздействию, и контрольной группы, не подвергшейся воздействию. В качестве меры τ_i этой разницы для конкретного клиента i может использоваться метрика causal effect (1):

$$\tau_i = Y_i^1 - Y_i^0, \quad (1)$$

где Y_i^1 – вероятность положительной реакции i -го клиента в случае, если он находится в целевой группе, Y_i^0 – вероятность положительной реакция i -го клиента, если он находится в контрольной группе.

В реальной практике, существует определенная проблема, связанная с тем, что клиент не может одновременно находится в целевой группе (например, ему отправлена рекламная SMS), и в контрольной группе (ему не отправлена рекламная SMS), и поэтому, τ_i напрямую измерить нельзя. В целях решения данной проблемы, используют условное математическое ожидание – Conditional Average Treatment Effect (*CATE*) (2):

$$CATE = E[Y_i^1 | X_i] - E[Y_i^0 | X_i], \quad (2)$$

где X_i – вектор признаков, характеризующих клиента i .

При реализации uplift-моделирования *CATE* вычисляется по формуле:

$$uplift = E[Y_i | X_i = x, W_i = 1] - E[Y_i | X_i = x, W_i = 0], \quad (3)$$

где W_i это индикатор принадлежности к целевой и контрольной группам, $W_i = 1$, если клиент относится к целевой группе, $W_i = 0$, если клиент относится к контрольной группе.

Существует несколько подходов к построению uplift-моделей, в рамках данного исследования рассмотрим четыре подхода:

– SoloModel: модель, обучающаяся на объединенных данных двух групп с включением индикатора принадлежности к контрольной и целевой группам W . Модель предсказывает вероятность отклика, а uplift оценивается как разность предсказаний при $W=1$ и $W=0$;

– TwoModel: подход, при котором отдельно обучаются две модели: одна на подвыборке клиентов с $W=1$, вторая – с $W=0$, после чего uplift рассчитывается как разность между прогнозами данных моделей [4].

– Class Transformation: подход, который базируется на введении в рассмотрение переменной Z_i [7]:

$$Z_i = Y_i \cdot W_i + (1 - Y_i) \cdot (1 - W_i), \quad (4)$$

где Y_i – исходная целевая переменная для i -го клиента, $W_i = \{0,1\}$ – индикатор принадлежности к целевой и контрольной группам;

– Class Transformation with Regression – модификация модели Class Transformation, в основе которой также лежит введение новой целевой переменной Z_i :

$$Z_i = Y_i \frac{W_i - p}{p(1-p)}, \quad (5)$$

где p – вероятность попадания клиента в целевую группу $p = P(W_i = 1 | X_i = x)$, данная вероятность как правило оценивается как доля объектов с $W_i = 1$.

Методы оценки качества uplift-моделей

Особенностью применения uplift-моделирования в сфере маркетинга является то, что оно направлено не на получение прогнозов целевого действия, а на измерение прироста вероятности совершения целевого

действия при условии маркетингового воздействия на клиента. Uplift-моделирование применяется в условиях, когда невозможно одновременно оказывать и не оказывать воздействие на клиента, чтобы посмотреть на разницу в его реакции [1]. Для оценки эффективности данного типа моделей требуются специфические метрики.

Одной из наиболее распространённых метрик для оценки качества uplift-моделей является $\text{uplift}@k$, отражающая прирост отклика среди $k\%$ наблюдений с наивысшими прогнозируемыми значениями uplift. Процесс вычисления метрики $\text{uplift}@k$ включает предварительную сортировку выборки по убыванию предсказанного uplift, после чего определяется разница средних значений отклика между целевой и контрольной группами.

Теоретически значение $\text{uplift}@k$ может варьироваться в диапазоне от -1 до 1, однако на практике оно, как правило, находится в пределах от 0 до 1, значение определяется параметром k , характеристиками выборки и точностью предсказания модели. Метрика $\text{uplift}@k$ особенно востребована в прикладных задачах, где существует ограничение на размер аудитории, доступной для коммуникации, например, при фиксированном маркетинговом бюджете.

В некоторых случаях требуется метрика, позволяющая оценить качество uplift-модели в виде единого агрегированного показателя, вычисленного на всей тестовой выборке. В данной ситуации можно воспользоваться метрикой $\text{weighted average uplift}$, оценивающей среднее взвешенное значение uplift-эффекта относительно всей выборки:

$$\text{weighted_average_uplift} = \frac{1}{\sum_i N_i^T} \sum_i N_i^T \text{uplift}_i, \quad (6)$$

где N_i^T – размер целевой группы в i -ом перцентиле, uplift_i – величина uplift в i -ом перцентиле.

Значения данной метрики принадлежат промежутку $[0;1)$, чем выше значение (ближе к 1), тем лучше модель дифференцирует клиентов по степени ожидаемой эффективности маркетингового воздействия.

Одним из наиболее информативных инструментов визуального и количественного анализа качества моделей uplift-моделирования является Qini-кривая (Qini curve), иллюстрирующая накопленное различие в откликах между целевой и контрольной группами при последовательном ранжировании объектов по убыванию предсказанного uplift-эффекта [8]. Построение кривой основано на расчёте разницы между вероятностями положительного отклика в целевой группе и в контрольной группе, с поправкой на соотношение размеров групп, по формуле:

$$qini\ curve = Y_t^T - \frac{Y_t^C N_t^T}{N_t^C}, \quad (7)$$

Визуальное представление Qini-кривой представлено на рисунке 1. Для агрегированной количественной оценки используется метрика Qini AUC (Area Under the Qini Curve), представляющая собой площадь под Qini-кривой [9]. Чем выше значение Qini AUC, тем точнее модель упорядочивает клиентов по степени их чувствительности к воздействию и тем больше совокупный прирост откликов, достигаемый за счёт ранжирования.




Рис. 1. – Визуальное представление Qini-кривой

Альтернативной формой визуализации является Uplift-кривая (Uplift curve), также отражающая накопленный эффект маркетингового воздействия. Uplift-кривая строится на основе следующей формулы:

$$uplift\ curve = \left(\frac{Y_t^T}{N_t^T} - \frac{Y_t^C}{N_t^C} \right) (N_t^T + N_t^C), \quad (8)$$

где t – общее число объектов, Y_t^T и Y_t^C – накопленное число положительных откликов в целевой и контрольной группах соответственно, N_t^T , N_t^C – размер целевой и контрольной групп.

Визуальное представление uplift-кривой представлено на рисунке 2. Аналогично Qini AUC, для оценки качества модели используется показатель Uplift AUC, отражающий площадь под uplift-кривой [10]. Более высокие значения Uplift AUC свидетельствуют о высокой способности модели точно выявлять клиентов, склонных изменить поведение в ответ на маркетинговое воздействие.




Рис. 2. – Визуальное представление uplift-кривой

Метрика Average Squared Deviation (ASD) оценивает устойчивость модели и помогает выявить переобучение. Она отражает среднеквадратичное отклонение uplift-прогнозов между обучающей и тестовой выборками по перцентильным группам.

Сравнительный анализ эффективности uplift-моделей

Для проведения вычислительного эксперимента в рамках настоящего исследования использован открытый датасет X5 RetailHero Uplift Modeling Dataset, предоставленный компанией X5 Retail Group. Одним из ключевых каналов стимулирования покупательской активности в X5 Group выступают SMS-рассылки. Для оптимизации затрат требуется более точный таргетинг, ориентированный на клиентов, с высокой вероятностью реагирующих на коммуникацию. Вычислительный эксперимент направлен на выделение сегмента «убеждаемых» клиентов с использованием uplift-моделирования.

Датасет содержит 200039 записей, включающих информацию о клиентах (возраст, пол, даты выпуска и активации карты), данные о покупках (транзакции и товары), а также бинарные признаки воздействия и отклика. Контрольная группа, не получившая маркетингового воздействия, составляет 50,02% выборки; тестовая группа – 49,98%.

Все этапы эксперимента реализованы с использованием языка Python в среде Jupyter Notebook. В качестве базового алгоритма для построения моделей был выбран CatBoost – градиентный бустинг на решающих деревьях, разработанный для эффективной работы с категориальными признаками и малым количеством гиперпараметров. Он обеспечивает высокую точность и стабильность, что делает его актуальным для задач предсказания реакции клиентов на маркетинговое воздействие.

Для оценки изменений в поведении клиентов под влиянием маркетингового воздействия были реализованы и обучены четыре модели: SoloModel, TwoModel, Class Transformation и Class Transformation with Regression. По результатам работы моделей рассчитаны значения uplift для каждого клиента, определены ключевые метрики качества, а также проведён сравнительный анализ эффективности подходов на обучающей (таблица №1) и тестовой (таблица № 2) выборках.

Наилучшие значения по всем метрикам на обучающей и тестовой выборках продемонстрировала модель Class Transformation. Базовая модель SoloModel показала значительно более низкие результаты, она использовалась в анализе в качестве референтной точки для сравнения с более сложными подходами.

Таблица №1

Значения метрик uplift-моделей (обучающая выборка)

	Uplift@10%	Qini AUC	Uplift AUC	Weighted Avg Uplift	Avg Squared Deviation
SoloMode	0,154	0,037	0,058	0,030	0,000
TwoModel	0,456	0,146	0,223	0,035	0,000
ClassTransformation	0,568	0,191	0,268	0,062	0,000
ClassTransformationReg	0,326	0,138	0,173	0,065	0,000

Таблица №2

Значения метрик uplift-моделей (тестовая выборка)

	Uplift@10%	Qini AUC	Uplift AUC	Weighted Avg Uplift	Avg Squared Deviation
SoloMode	0,081	0,006	0,010	0,033	0,002
TwoModel	0,086	0,012	0,018	0,036	0,041
ClassTransformation	0,120	0,018	0,027	0,037	0,058
ClassTransformationReg	0,083	0,016	0,022	0,035	0,017

На рисунке 3 представлены результаты сравнительного анализа.

Для оценки качества моделей и визуального анализа их предсказательной способности за пределами обучающих данных дополнительно были построены uplift-кривые на тестовой выборке (рис.4). На графике видно, что модель Class Transformation сохраняет преимущество

по величине кумулятивного uplift на значительной части тестовой выборки. Uplift-кривая данной модели демонстрирует наибольший прирост откликов вплоть до первых 40 000 клиентов.




Рис. 3. – Результаты сравнительного анализа различных моделей




Рис. 4. – Uplift-кривые uplift-моделей (тестовая выборка)

Литература (References)

1. Radcliffe N.J. Using control groups to target on predicted lift: building and assessing uplift models. *Direct Mark Analytics Journal*. 2007; pp. 14–21
2. Devriendt F., Moldovan D., Verbeke W. A literature survey and experimental evaluation of the state-of-the-art in uplift modeling: a stepping stone toward the development of prescriptive analytics. *Big Data*. 2018;6(1): pp. 13–41. URL: doi.org/10.1089/big.2017.0104
3. Ibragimov B., Vakhrushev A. Uplift modelling via gradient boosting. In: *Proceedings of the 30th ACM SIGKDD Conference on Knowledge Discovery and Data Mining: KDD 2024, 25–29 August 2024, Barcelona, Spain*. New York: Association for Computing Machinery; 2024. pp. 1177–1187. URL: doi.org/10.1145/3637528.3672019
4. Radcliffe N., Surry P. Real-World Uplift Modelling with Significance-Based Uplift Trees. *Stochastic Solutions White Paper*. 2011. P. 33.
5. Rzepakowski P., Jaroszewicz S. Decision trees for uplift modeling with single and multiple treatments. *Knowledge and Information Systems*. 2012;32(2): pp. 303–327.
6. Lo V. The True Lift Model: A novel data mining approach to response modeling in database marketing. *ACM SIGKDD Explor Newsl*. 2002;4(2): pp. 78–86.
7. Jaskowski M., Jaroszewicz S. Uplift modeling for clinical trial data. *ICML Workshop on Clinical Data Analysis*. 2012. pp. 79–95.
8. Gutierrez P., Gerardy J-Y. Causal inference and uplift modelling: a review of the literature. In: *Proceedings of the ICML Workshop on Real World Experiment Design and Active Learning: 34th International Conference on Machine Learning (ICML 2017), 11 Aug 2017, Sydney, Australia*. PMLR: *Proceedings of Machine Learning Research*; 2017. pp. 1–14.



9. Devriendt F., Guns T., Verbeke W. Learning to rank for uplift modeling. IEEE Trans Knowl Data Eng. 2020;32(10). URL: doi.org/10.48550/arXiv.2002.05897

10. Betlei A., Diemert E., Amini M-R. Uplift Modeling with Generalization Guarantees. In: Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining, 14 Aug 2021, Singapore, Singapore. The Association for Computing Machinery; 2021, pp. 55–66.

Дата поступления: 18.06.2025

Дата публикации: 29.07.2025