

УДК 004.89

DOI: [10.26102/2310-6018/2025.50.3.031](https://doi.org/10.26102/2310-6018/2025.50.3.031)

Применение uplift-моделирования в задачах повышения эффективности маркетинговых коммуникаций

Т.В. Азарнова✉, Е.В. Ярош

Воронежский государственный университет, Воронеж, Российская Федерация

Резюме. В условиях высокой конкуренции для крупных современных компаний, производящих массовую продукцию или оказывающих массовые услуги, характерен рост затрат на рекламу, которая не всегда приносит ожидаемый эффект. Возрастает потребность в инструментах точной сегментации аудитории, которая способна повысить эффективность маркетинговых коммуникаций. Традиционные модели предсказания отклика не позволяют определить, изменилось ли поведение клиента именно под влиянием маркетингового воздействия, что снижает возможности конструктивного анализа маркетинговых кампаний. Данная статья направлена на исследование uplift-моделирования как инструмента оценки эффекта прироста положительных откликов от коммуникации и оптимизации таргетинга. Результаты исследования демонстрируют существенное преимущество подхода uplift-моделирования для выявления клиентских сегментов с максимальной чувствительностью к воздействию. Проведенный в рамках статьи сравнительный анализ различных подходов к построению uplift-моделей (таких как SoloModel, TwoModel, Class Transformation, Class Transformation with Regression), базирующийся на использовании специализированных uplift-метрик (uplift@k, Qini AUC, Uplift AUC, weighted average uplift, Average Squared Deviation), демонстрирует сильные и слабые стороны каждого из подходов моделирования. Исследование базируется на открытых данных X5 RetailHero Uplift Modeling Dataset, предоставленных X5 Retail Group для исследования методов uplift-моделирования в контексте ритейла.

Ключевые слова: uplift-моделирование, машинное обучение, маркетинговые коммуникации, таргетинг, оценка отклика, метрики качества uplift-моделей.

Для цитирования: Азарнова Т.В., Ярош Е.В. Применение uplift-моделирования в задачах повышения эффективности маркетинговых коммуникаций. *Моделирование, оптимизация и информационные технологии.* 2025;13(3). URL: <https://moitvvt.ru/ru/journal/pdf?id=2023> DOI: 10.26102/2310-6018/2025.50.3.031

Application of uplift modeling in tasks of increasing the effectiveness of marketing communications

T.V. Azarnova✉, E.V. Yarosh

Voronezh State University, Voronezh, the Russian Federation

Abstract. In the conditions of high competition for large modern companies producing mass products or providing mass services, it is typical to increase advertising costs, which does not always bring the expected effect. There is a growing need for tools for precise audience segmentation, which can increase the effectiveness of marketing communications. Traditional response prediction models do not allow us to determine whether the client's behavior has changed under the influence of marketing impact, which reduces the possibilities of constructive analysis of marketing campaigns. This article is aimed at studying uplift modeling as a tool for assessing the effect of increasing positive responses from communication and targeting optimization. The results of the study demonstrate significant advantages of the uplift modeling approach for identifying client segments with maximum sensitivity to impact. The comparative analysis of various approaches to building uplift models (such as SoloModel, TwoModel, Class Transformation, Class Transformation with Regression), based on the use of

specialized uplift metrics (uplift@k, Qini AUC, Uplift AUC, weighted average uplift, Average Squared Deviation), conducted within the article, demonstrates the strengths and weaknesses of each of the modeling approaches. The study is based on open data X5 RetailHero Uplift Modeling Dataset, provided by X5 Retail Group for the study of uplift modeling methods in the context of retail.

Keywords: uplift modeling, machine learning, marketing communications, targeting, response evaluation, uplift model quality metrics.

For citation: Azarnova T.V., Yarosh E.V. Application of uplift modeling in tasks of increasing the effectiveness of marketing communications. *Modeling, Optimization and Information Technology*. 2025;13(3). (In Russ.). URL: <https://moitvivr.ru/ru/journal/pdf?id=2023> DOI: 10.26102/2310-6018/2025.50.3.031

Введение

Современный этап развития маркетинга и электронной коммерции определяется усилением конкуренции на рынке, стремительным ростом объемов обрабатываемых данных и возрастающими ожиданиями клиентов в отношении персонализации сервиса. Цифровые каналы продвижения становятся основным инструментом, позволяющим адаптировать маркетинг под разные сегменты аудитории. Несмотря на активное использование таких каналов и значительные финансовые вложения, компании все чаще сталкиваются с проблемой низкой эффективности маркетинговых коммуникаций. Массовые рассылки и рекламные кампании не всегда обеспечивают ожидаемый отклик, поскольку не все клиенты восприимчивы к таким воздействиям. Это обуславливает необходимость внедрения более результативных методов сегментации аудитории.

В качестве современных инструментов анализа и разработки стратегии маркетинговых кампаний достаточно часто используются модели, методы и алгоритмы, базирующиеся на технологиях машинного обучения. В статье [1] авторы рассматривают Look-alike модель, предназначенную для выявления клиентов, обладающих характеристиками, схожими с пользователями, уже совершившими целевое действие. Модель позволяет разработать инструменты максимизации вероятности обнаружения клиентов, потенциально заинтересованных в целевом действии. Модель базируется на оценке сходства клиентов с целевой аудиторией. В работе [2] авторы исследуют Response-модель, позволяющую оценить вероятность того, что клиент может совершить целевое действие при наличии маркетингового воздействия. Обучение данной модели осуществляется на основе информации, собранной после проведения рекламных кампаний, что позволяет учитывать реальные отклики потребителей, как положительные, так и отрицательные. Однако, несмотря на более высокую точность по сравнению с look-alike моделями, этот подход не позволяет надежно определить, было ли действие вызвано именно коммуникацией, так как оно могло произойти и без воздействия. Uplift-модели представляют собой продвинутый аналитический инструмент, позволяющий оценить чистый прирост эффективности от маркетинговых коммуникаций. Данный метод сравнивает вероятность совершения покупателем целевого действия с коммуникацией и без нее. Наибольшую эффективность uplift-модели демонстрируют при работе с товарами массового спроса, где высока вероятность совершения покупки без дополнительного стимулирования. В таких случаях применение данного подхода позволяет оптимизировать издержки фирм за счет исключения из кампаний тех потребителей, которые приобрели бы товар и без маркетингового воздействия. Последний подход представляет наибольший интерес и приобретает особую актуальность в контексте повышения эффективности маркетинговых коммуникаций. В отличие от традиционных подходов, uplift-модели фокусируются на выявлении именно той группы потребителей, чье поведение изменится под влиянием

маркетингового воздействия [3]. Развитие методов uplift-моделирования в задачах персонализированного маркетинга было обусловлено недостаточной эффективностью традиционных моделей отклика, таких как логистическая регрессия и деревья решений. Значительный вклад в исследования по данной теме внесла работа¹, в которой систематизированы ключевые этапы построения uplift-моделей. Авторы подробно рассматривают метод Significance-Based Uplift Trees, на базе которого созданы первые программные решения, доступные для применения в бизнес-практике. В статье описаны особенности каждого этапа uplift-моделирования – от отбора признаков и построения моделей до оценки качества и последующего анализа. Применение для uplift-моделирования деревьев решений со специальными критериями на основе дивергенции Кульбака-Лейблера и евклидовой метрики описано в работе [4], авторы работы [5] предложили метод True Lift Modelling, в котором uplift-эффект оценивается за счет добавления в регрессионную модель специальных переменных, отражающих взаимодействие признаков с фактом получения маркетингового воздействия.

Данная работа посвящена дальнейшему исследованию вопросов применения различных uplift-моделей для организации маркетинговых коммуникаций. Анализируется эффективность применения таких моделей как SoloModel, TwoModel, Class Transformation, Class Transformation with Regression. Качество каждой из моделей оценивается по нескольким специализированным uplift-метрикам: uplift@k, Qini AUC, Uplift AUC, weighted average uplift, Average Squared Deviation, которые позволяют получить достаточно комплексное представление о возможности выявления uplift-эффекта. В исследовании используется открытый набор данных X5 RetailHero Uplift Modeling Dataset, предоставленный X5 Retail Group для исследования методов uplift-моделирования в контексте ритейла.

Материалы и методы

Задачи и принципы uplift-моделирования. Uplift-моделирование представляет собой подход в машинном обучении, направленный на разработку алгоритмов, позволяющих определять потребителей, наиболее восприимчивых к внешнему воздействию. Применение данного подхода в маркетинге позволяет повысить эффективность кампаний за счет точной идентификации тех клиентов, чье поведение наиболее вероятно изменится под влиянием коммуникации [6].

Методология uplift-моделирования базируется на получении некоторой количественной оценки разницы в целевом результате клиентов при осуществлении и отсутствии маркетингового взаимодействия с ними. Основной метрикой для данного вида моделирования является causal effect – τ_i , которая вычисляется как разность вероятностей совершения целевого действия:

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

где Y_i^1 – вероятность совершения целевого действия при коммуникации, Y_i^0 – вероятность совершения целевого действия при отсутствии коммуникации.

Однако следует отметить, что невозможно одновременно осуществить коммуникацию и не осуществить ее для одного и того же человека. Так как τ_i напрямую измерить нельзя, на практике используется ее условное математическое ожидание, называемое Conditional Average Treatment Effect (CATE):

¹ Radcliffe N.J., Surry P.D. Real-World Uplift Modelling with Significance-Based Uplift Trees. University of Edinburgh Research Explorer. URL: <https://www.research.ed.ac.uk/en/publications/real-world-uplift-modelling-with-significance-based-uplift-trees> (дата обращения: 13.06.2025).

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

где X_i – признаки объектов, описывающих i -го клиента.

В контексте uplift-моделирования $CATE$ вычисляется следующим образом:

$$uplift = \widehat{CATE} = E[Y_i|X_i = x, W_i = 1] - E[Y_i|X_i = x, W_i = 1_i], \quad (3)$$

где Y_i – реакция клиента, наблюдаемая в результате проведения маркетинговой кампании, $W_i = 1$ – индикатор того, что клиент относится к целевой группе, где была проведена коммуникация, $W_i = 0$ – индикатор того, что клиент относится к контрольной группе, где коммуникация не проводилась.

Обзор основных подходов к построению uplift-моделей. Цель uplift-моделирования состоит в выявлении убеждаемых клиентов. Для этого модель отбирает тех клиентов, у которых предсказанный эффект от взаимодействия является наибольшим. Существует несколько подходов к решению этой задачи, которые могут быть адаптированы под конкретные условия бизнеса.

Подход, известный как Solo model approach или S-learner, представляет собой достаточно простой метод моделирования, базирующийся на построении одной модели. В рамках этого метода модель обучается на данных обеих групп (целевой и контрольной), используя бинарный признак коммуникации с клиентом как дополнительный входной параметр. Для оценки uplift на тестовой выборке каждый объект прогнозируется дважды: сначала с флагом коммуникации = 1, затем с флагом коммуникации = 0. Разница между полученными вероятностями и дает оценку uplift.

Второй подход Two models approach предполагает построение двух независимых моделей. Первая модель обучается на данных целевой группы и предсказывает вероятность целевого действия для клиентов, получивших коммуникацию. Вторая модель строится на данных контрольной группы и оценивает вероятность того же действия для клиентов без воздействия. Uplift для каждого клиента вычисляется как разность между предсказаниями этих двух моделей¹. Плюсы данного метода заключаются в простоте и гибкости, поскольку модели обучаются независимо, минусы – в том, что каждая модель оптимизируется под свою группу, не учитывая напрямую разницу между ними. Это может снизить точность оценки uplift и привести к нестабильным результатам.

Подход T-learner отличается простотой и гибкостью, позволяя независимо обучать модели для контрольной и целевой групп. Однако при обучении целевая функция каждой из моделей ориентирована на точность предсказания в своей группе и не учитывает основную задачу – корректное моделирование разницы между поведением контрольной и целевой групп, что может привести к снижению точности искомого uplift. В результате метод нередко показывает нестабильные результаты на практике.

Подход Class Transformation approach заключается в построении новой целевой переменной [7], которая для каждого отдельного клиента i -го клиента вычисляется по формуле:

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

где Y_i – исходная целевая переменная для i -го клиента, $W_i = \{0,1\}$ – бинарный флаг коммуникации: при $W_i = 1$ клиент принадлежит целевой группе, а при $W_i = 0$ – контрольной группе.

Поскольку обучающая выборка для uplift-моделирования формируется на основе рандомизированного эксперимента, предполагается независимость признаков X и признака воздействия W , а также равномерное распределение объектов между группами.

$$P(W = 1) = P(W = 0) = \frac{1}{2}. \quad (5)$$

В данном случае искомый uplift определяется по формуле:

$$uplift = 2 \cdot P(Z = 1) - 1. \quad (6)$$

Подход Transformed outcome, Class Transformation with Regression (трансформация классов, регрессия) позволяет устранить ограничения метода Class Transformation approach, связанные с его применимостью только для бинарной целевой переменной Y_i и требованием равномерного распределения клиентов между контрольной и целевой группами. В этом методе исходная целевая переменная Y_i трансформируется по следующей формуле:

$$Z_i = Y_i \frac{W_i - p}{p(1-p)}, \quad (7)$$

где Z_i – новая целевая переменная для i -го клиента, W_i – флаг коммуникации i -го клиента, p – вероятность попадания клиента в целевую группу (propensity score): $p = P(W_i = 1 | X_i = x)$, которую можно оценить как долю объектов с $W_i = 1$.

После трансформации на основе новой целевой переменной Z_i обучается модель регрессии с использованием среднеквадратичной ошибки (MSE):

$$MSE = \frac{1}{n} \sum_{i=0}^n (Z_i - \hat{Z}_i)^2. \quad (8)$$

Важно отметить, что предсказания такой модели являются оценкой условного математического ожидания новой целевой переменной, которая совпадает с искомым causal effect:

$$E = [Z_i | X_i = x] = \tau_i. \quad (9)$$

Методы оценки качества uplift-моделей. В отличие от классических моделей прогнозирования, ориентированных на точность предсказаний, uplift-моделирование направлено на измерение прироста эффективности от маркетингового воздействия. Поскольку невозможно одновременно наблюдать реакцию одного и того же клиента в условиях наличия и отсутствия воздействия, требуется использование специализированных метрик, отражающих особенности данной методологии.

Одной из наиболее широко используемых метрик для оценки качества uplift-моделей является uplift@k, отражающая прирост отклика среди $k\%$ наблюдений с наивысшими прогнозными значениями uplift. Расчет метрики основан на предварительной сортировке выборки по убыванию предсказанного uplift и вычислении разности долей откликнувшихся между целевой и контрольной группами в верхней части выборки:

$$uplift@k = response\ rate@k_{(treatment)} - response\ rate@k_{(control)}, \quad (10)$$

где $response\ rate@k = mean(Y@k)$, $Y@k$ – значения отклика для $k\%$ выборки.

Теоретически значение метрики может находиться в диапазоне от -1 до 1 , однако на практике оно, как правило, варьируется в пределах от 0 до 1 в зависимости от параметра k , характеристик выборки и точности модели.

В ряде случаев возникает необходимость в метрике, выраженной в виде единого значения, рассчитанного на всей тестовой выборке. Для этого применяется показатель weighted average uplift:

$$weighted\ average\ uplift = \frac{1}{\sum_i N_i^T} \sum_i N_i^T uplift_i, \quad (11)$$

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

Практически значимый диапазон метрики для задач uplift-моделирования составляет $[0,1)$, где более высокие значения соответствуют лучшему разделению клиентов по uplift-эффекту.

Одним из ключевых подходов визуальной и количественной оценки качества моделей uplift-моделирования является Qini-кривая (Qini-curve). Она отражает накопленную разницу в откликах между целевой и контрольными группами при последовательном ранжировании объектов по убыванию предсказанного uplift-эффекта [8]. Qini-кривая строится на основе следующей формулы:

$$qini\ curve = Y_t^T - \frac{Y_t^C N_t^T}{N_t^C}, \quad (12)$$

где Y_t^T – накопленное число положительных откликов в treatment группе, Y_t^C – накопленное число положительных откликов в control-группе, N_t^T , N_t^C – размер treatment и control групп.

Для агрегированной количественной оценки используют Qini AUC (Area Under the Qini Curve) – метрику, представляющую собой площадь под Qini-кривой [9]. Значение Qini AUC позволяет оценить совокупный прирост откликов, полученный за счет ранжирования клиентов с опорой на uplift-прогноз. Чем выше Qini AUC, тем точнее модель ранжирует клиентов по ожидаемой чувствительности к воздействию.

Uplift-кривая (Uplift curve) представляет собой еще один способ визуализации накопленного эффекта от воздействия. Она строится аналогично Qini-кривой, однако ее значение представляет собой не скорректированный разницей размеров групп uplift, а абсолютную разность между накопленными откликами treatment и control групп. Uplift-кривая строится на основе следующей формулы:

$$uplift\ curve = \left(\frac{Y_t^T}{N_t^T} - \frac{Y_t^C}{N_t^C} \right) (N_t^T + N_t^C), \quad (13)$$

где t – общее число объектов, Y_t^T и Y_t^C – накопленное число положительных откликов в treatment и control-группе соответственно, N_t^T , N_t^C – размер treatment и control групп.

Для количественной оценки используется площадь под кривой – метрика Uplift AUC [10]. Высокое значение Uplift AUC указывает на способность модели точно выявлять клиентов, подверженных воздействию.

Метрика Average Squared Deviation (ASD) оценивает устойчивость uplift-модели путем измерения среднеквадратичного отклонения между предсказанными значениями uplift на обучающей и тестовой выборках по перцентильным группам. Высокое значение ASD указывает на возможное переобучение, тогда как низкое – свидетельствует о стабильности и хорошей обобщающей способности модели.

Результаты и обсуждение

Для проведения вычислительного эксперимента в рамках исследования используется X5 RetailHero Uplift Modeling Dataset – открытый набор данных, предоставленный X5 Retail Group для анализа методов uplift-моделирования в контексте ритейла. В качестве одного из основных каналов стимулирования покупательской активности X5 Group использует SMS-рассылки. Для сокращения затрат на данный вид рекламы необходимы инструменты более точного таргетинга, способного выстраивать ориентацию на тех клиентов, которые с высокой вероятностью откликнутся на коммуникацию. В рамках вычислительного эксперимента ставится задача разработки подобного инструмента, базирующегося на методах uplift-моделирования.

Рассматриваемый набор данных содержит 200039 записей, отражающих информацию о клиентах (возраст, пол, даты выпуска и активации карты), истории покупок (уникальные транзакции и товары), а также бинарные признаки воздействия (treatment) и отклика (target). Контрольная группа, не получившая маркетингового воздействия, составила 50,02 % выборки, тестовая группа соответственно – 49,98 %.

Все этапы исследования реализованы на базе программного обеспечения, разработанного на языках программирования Python в среде Jupyter.

Для выявления изменений в поведении клиентов под влиянием коммуникации были реализованы и обучены четыре основные uplift-модели: SoloModel, TwoModel, Class Transformation, Class Transformation with Regression. По каждой модели рассчитаны значения uplift для каждого клиента, найдены ключевые метрики качества моделей и выполнен сравнительный анализ эффективности различных подходов на обучающей выборке (Таблица 1) и на тестовой (Таблица 2).

Таблица 1 – Значения метрик uplift-моделей (обучающая выборка)

Table 1 – Evaluation metrics of uplift models (train set)

	Uplift@10%	Qini AUC	Uplift AUC	Weighted Avg Uplift	Avg Squared Deviation
SoloModel	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)

Table 2 – Evaluation metrics of uplift models (test set)

	Uplift@10%	Qini AUC	Uplift AUC	Weighted Avg Uplift	Avg Squared Deviation
SoloModel	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

Более высокие результаты по всем метрикам на обучающей и тестовой выборках продемонстрировала модель ClassTransformation. Базовая модель SoloModel показала существенно более низкие результаты, она включена в анализ в качестве референтной точки при сравнении с более сложными архитектурами.

Для визуального анализа эффективности моделей дополнительно были построены Qini-кривые (Рисунок 1). Наибольший прирост откликов на значительной части тестовой выборки (вплоть до 40000 клиентов) демонстрирует модель ClassTransformation, Qini-кривая данной модели существенно превышает уровень случайного распределения.




Рисунок 1 – Qini-кривые uplift-моделей (тестовая выборка)
Figure 1 – Qini curves of uplift models (test set)

На Рисунке 2 представлена агрегация предсказанных uplift-значений модели ClassTransformation по перцентилям. График демонстрирует способность модели эффективно ранжировать клиентов по степени восприимчивости к маркетинговому воздействию. Наибольший прирост отклика наблюдается в первом перцентиле, где uplift достигает 0,12, что свидетельствует о высокой концентрации убеждаемых клиентов среди лидирующих по прогнозу. По мере перехода к последующим перцентилям прирост значительно снижается, а в диапазоне 50–80 становится близким к нулю, что указывает на отсутствие значимого эффекта от воздействия. Модель позволяет с высокой точностью выделять наиболее перспективные группы клиентов, обеспечивая таргетирование с максимальным ожидаемым эффектом.




Рисунок 2 – Uplift-значения по перцентилям (ClassTransformation)
Figure 2 – Uplift by percentile (ClassTransformation)

Полученные результаты метрик и визуального анализа модели ClassTransformation демонстрируют хороший баланс между точностью предсказания и обоснованной интерпретацией результатов, что позволяет на базе данной модели строить эффективные инструменты персонализированного таргетинга при исследовании маркетинговых коммуникаций.

Заключение

Результаты проведенного в рамках исследования анализа показали, что применение uplift-моделирования позволяет не только измерять эффект маркетинговых кампаний, но и повышать их эффективность за счет идентификации клиентских сегментов с наибольшим приростом откликов при взаимодействии. Рассмотренные инструменты на основе моделей Uplift способны автоматизировать процесс оценки эффекта от маркетинговых коммуникаций и могут послужить основой принятия решений о целесообразности взаимодействия с конкретными клиентами. Комплексный сравнительный анализ подходов SoloModel, TwoModel, Class Transformation, Class Transformation with Regression uplift-моделирования в маркетинговой практике, позволяет сделать рекомендации по наиболее перспективным из них с позиции простоты реализации и качества результатов относительно метрик uplift@k, Qini AUC, Uplift AUC, weighted average uplift, Average Squared Deviation.

СПИСОК ИСТОЧНИКОВ / REFERENCES

1. Popov A., Iakovleva D. Adaptive Look-Alike Targeting in Social Networks Advertising. *Procedia Computer Science*. 2018;136:255–264. <https://doi.org/10.1016/j.procs.2018.08.264>
2. Hanssens D.M., Parsons L.J., Schultz R.L. Response Models in Marketing. In: *Market Response Models: Econometric and Time Series Analysis*. Dordrecht: Springer; 1990. P. 3–26. https://doi.org/10.1007/978-94-009-1073-7_1
3. 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):13–41. <https://doi.org/10.1089/big.2017.0104>
4. Rzepakowski P., Jaroszewicz S. Decision Trees for Uplift Modeling with Single and Multiple Treatments. *Knowledge and Information Systems*. 2012;32(2):303–327. <https://doi.org/10.1007/s10115-011-0434-0>
5. Lo V.S.Y. The True Lift Model: A Novel Data Mining Approach to Response Modeling in Database Marketing. *ACM SIGKDD Explorations Newsletter*. 2002;4(2):78–86. <https://doi.org/10.1145/772862.772872>
6. Ibragimov B., Vakhrushev A. Uplift Modelling via Gradient Boosting. In: *KDD '24: Proceedings of the 30th ACM SIGKDD Conference on Knowledge Discovery and Data Mining, 25–29 August 2024, Barcelona, Spain*. New York: Association for Computing Machinery; 2024. P. 1177–1187. <https://doi.org/10.1145/3637528.3672019>
7. Jaskowski M., Jaroszewicz S. Uplift Modeling for Clinical Trial Data. In: *ICML 2012: Proceedings of the 29th International Conference on Machine Learning, 26 June – 1 July 2012, Edinburgh, Scotland, UK*. 2012. P. 79–95.
8. Gutierrez P., Gérardy J.-Y. Causal Inference and Uplift Modelling: A Review of the Literature. In: *PAPIs 2016: Proceedings of the 3rd International Conference on Predictive APIs and Apps, 11–12 October 2016, Boston, USA*. PMLR; 2017. P. 1–13.

9. Devriendt F., Van Belle J., Guns T., Verbeke W. Learning to Rank for Uplift Modeling. *IEEE Transactions on Knowledge and Data Engineering*. 2022;34(10):4888–4904. <https://doi.org/10.1109/TKDE.2020.3048510>
10. Betlei A., Diemert E., Amini M.-R. Uplift Modeling with Generalization Guarantees. In: *KDD '21: Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining, 14–18 August 2021, Virtual Event, Singapore*. New York: Association for Computing Machinery; 2021. P. 55–65. <https://doi.org/10.1145/3447548.3467395>

ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

Азарнова Татьяна Васильевна, доктор технических наук, профессор, профессор Воронежского государственного университета, Воронеж, Российская Федерация.
e-mail: ivdas92@mail.ru

Tatyana V. Azarnova, Doctor of Engineering Sciences, Professor, Professor of Voronezh State University, Voronezh, the Russian Federation.

Ярош Елизавета Валентиновна, студентка, Воронежский государственный университет, Воронеж, Российская Федерация.
e-mail: yarosh.elizabeth@gmail.com

Elizaveta V. Yarosh, student of Voronezh State University, Voronezh, the Russian Federation.

Статья поступила в редакцию 09.07.2025; одобрена после рецензирования 25.07.2025; принята к публикации 31.07.2025.

The article was submitted 09.07.2025; approved after reviewing 25.07.2025; accepted for publication 31.07.2025.