

Вестник НГУЭУ. 2024. № 2. С. 81–100  
Vestnik NSUEM. 2024. No. 2. P. 81–100

Научная статья  
УДК 519.248  
DOI: 10.34020/2073-6495-2024-2-081-100

## ПРИКЛАДНОЙ ПРИЧИННЫЙ ВЫВОД В РЕГИОНАЛЬНЫХ ЭКОНОМИКО-ПОВЕДЕНЧЕСКИХ МОДЕЛЯХ ПРИНЯТИЯ БИЗНЕС-РЕШЕНИЙ

Михайлов Дмитрий Владимирович

*Уральский федеральный университет  
имени первого Президента России Б.Н. Ельцина*

Mikhailovdv86@gmail.com

**Аннотация.** В последнее время обозреватели поведенческого исследования операций испытывают повышенный интерес к моделям на основе причинного вывода, авторами отмечается дефицит обсервационных исследований на национальных рынках недвижимости. Настоящее эмпирическое исследование восполняет этот пробел. Его исследовательские гипотезы касаются пользы включения поведенческих факторов в модели систем принятия решений и оптимизации инструментальной политики компаний. Работа имеет как научное, так и прикладное значение. Новизна состоит в применении продвинутых методов машинного обучения с выходом на оценку условного причинного эффекта.

**Ключевые слова:** поведенческое исследование операций, причинный вывод, неприятие убытков, ценообразование, дисконт, премии

**Для цитирования:** Михайлов Д.В. Прикладной причинный вывод в региональных экономико-поведенческих моделях принятия бизнес-решений // Вестник НГУЭУ. 2024. № 2. С. 81–100. DOI: 10.34020/2073-6495-2024-2-081-100.

Original article

## APPLIED CAUSAL INFERENCE IN REGIONAL ECONOMIC-BEHAVIORAL MODELS OF BUSINESS DECISION MAKING

Mikhailov Dmitry V.

*Ural Federal University named after the First President of Russia B.N. Yeltsin*

Mikhailovdv86@gmail.com

**Abstract.** Recently, behavioral operations research researchers have experienced increased interest in models based on causal inference, and the authors note a dearth of observational studies in national real estate markets. The present study fills this gap. His research hypotheses concern the benefits of incorporating behavioral factors into models of decision-making systems and optimizing the instrumental policies of companies. The work has both scientific and applied significance. The novelty of the work lies in the use of advanced machine learning methods to estimate the conditional causal effect.

© Михайлов Д.В., 2024

**Keywords:** behavioral operations research, causal inference, loss aversion, pricing, discounting, premiums

**For citation:** Mikhailov D.V. Applied causal inference in regional economic-behavioral models of business decision making. *Vestnik NSUEM*. 2024; (2): 81–100. (In Russ.). DOI: 10.34020/2073-6495-2024-2-081-100.

## Введение

Исследователи в области операционного менеджмента традиционно фокусируются на развитии нормативных математических моделей, описывающих бизнес-процессы. Однако в последнее время замечен рост интереса к пониманию того, как на самом деле менеджеры принимают решения на основе изучения данных и факторов, которые влияют на эти решения. Для продвижения в этом направлении большое значение приобретают модели на основе причинного вывода [10]. Тематика систем принятия решений (СПР) не изобилует примерами включения в свои модели достижения поведенческих наук, сведения о практически пригодных системах, интегрированных с поведенческими аспектами, в публикациях отсутствуют [12]. В связи с этим оправдана исследовательская активность в разработке подходов по встраиванию поведенческих факторов в СПР и их обогащению элементами ИИ на основе data-driven. Динамическое ценообразование и другие методы управления доходом становятся критически важными во многих индустриях. В большой степени этому способствует развитие электронной коммерции, которая позволяет продавцам гибко корректировать регулярные цены на товары и услуги в зависимости от сложившейся рыночной ситуации, от периода продвижения, от региональной специфики или от принадлежности покупателя к определенному сегменту [22]. Таким образом, можно говорить о наступлении эры, когда окончательная цена продажи в идеале должна формироваться практически на каждой транзакции или, другими словами, быть персонализированной.

Основная проблема, которая возникает в большинстве сценариев персонализированного ценообразования, – это оценка гетерогенных эффектов: каково влияние вмешательства (скидка/наценка) на интересующий результат (доход или время продажи) в зависимости от набора наблюдаемых характеристик выборки после вмешательства? Во многих таких ситуациях у нас есть множество данных наблюдений, в которых воздействие было выбрано с помощью какой-то неизвестной политики, а возможность проведения А/В-тестов ограничена. Чтобы правильно найти прямую причину и соответствующим образом внести улучшения, нам необходимо обучить модель, контролирующую все возможные скрытые переменные (искажающие факторы), и изучить прямой причинный эффект для данной функции. Это достигается применением инструментов причинно-следственной интерпретации [13].

В то время как статистические отношения фокусируются на том, дает ли знание значения узла информацию о значении другого узла, причинно-следственные связи сосредоточены на том, приведет ли манипулирование значением одного узла к изменению значения другого узла [24]. Очевидно,

что вторая из двух вышеперечисленных концепций кажется более полезной для практики выработки политик ценообразования в СПР. Контрфактическая концепция – оценка того, как выглядел бы мир при изменении одной или нескольких переменных при сохранении всего остального постоянным. Поскольку контрфактические значения не наблюдаемы в датасетах реальных обсервационных наблюдений, истинный причинный эффект невозможно определить без контрфактической оценки. Это то, почему классические методы машинного обучения не могут быть непосредственно применены к решению задачи причинного вывода. Семейство методов, использующих контрфактические значения переменных, называются uplift-моделированием [14].

В последнее время и исследователи, и практики создают более сложные модели, включающие как статистические, так и поведенческие предположения, чтобы оценить влияние контрфактической политики, которая никогда раньше не использовалась. Применимость концепции причинного вывода к разработке моделей индивидуального или фирменного поведения, например, обсуждается в [17]. Причинный вывод тем более представляется воодушевляющим подходом в исследовании операций и операционном менеджменте, поскольку ряд авторов отмечают наличие кризиса моделей класса model-driven в этой сфере [2].

Классические эконометрические модели – инструментальные переменные, разница в разнице, разрыв регрессии – способны произвести оценку прямого эффекта воздействия в целом по всей совокупности наблюдений; в этом случае будет измерен средний эффект воздействия АТЕ. Однако для рекомендательных систем и систем поддержки принятия решения более важно получить оценку не среднего, а условного эффекта воздействия САТЕ [20]. Таким системам важно понимать, на какие субпопуляции клиентов или в каких ситуациях воздействие влияет по-разному. Это все вопросы о неоднородности эффекта воздействия, на которые можно ответить с помощью более продвинутых оценщиков гетерогенных, часто нелинейных, эффектов на основе методов машинного обучения, в частности коллекции методов, собранных в фреймворке EconML [13]. Выявление характеристик ситуаций, при которых клиенты наиболее отзывчивы на вмешательства, может помочь разработать правила для разделения таких ситуаций на группы. Подобные правила – основа для оптимизации политики воздействий, что позволяет максимизировать экономические результаты бизнеса.

Хотя uplift-моделирование в настоящее время довольно широко используется бизнесом, в отечественном домене академической литературы оно пока не получило широкого распространения. Достаточно сказать, что поиск по русскоязычному сегменту e-library выявил лишь две работы по поисковой модели «причинный вывод», которые носят обзорный и информационный характер [1, 3]. Engström et al. [6] применили метод разрыва регрессии, чтобы на обсервационном датасете проанализировать, существует ли причинно-следственная связь между налогооблагаемым доходом и неприятием потерь налогоплательщиками при подаче налоговой декларации. Это единственная работа, которую нам удалось отыскать, авторы которой сумели построить экономико-поведенческую модель и произвести оценку условного причинного эффекта и его доверительных интервалов. В то же

время авторами не представлено никаких тестов, доказывающих надежность и валидность разработанной ими модели.

Основой формирования цен на жилье долгое время считалась гедонистическая модель. Однако в последнее время в потоке научных работ по данной тематике появились заметные изменения: и исследователи, и практики все больше осознают влияние психологических эффектов в этой области [18]. Так, исследователи поведенческих наук уже внесли свой вклад в секторе недвижимости, изучив влияние поведенческих аспектов<sup>1</sup> на ценообразование, торгуемые объемы, предпочтения при выборе домов, ипотеку, цикличность рынка жилья. Общей чертой практически всех рассмотренных поведенческих исследований является то, что в них оценивается средний эффект феноменов на популяцию, что делает невозможным применять эти оценки в рекомендательных системах и СПР.

Фактически вся история наблюдательных исследований поведенческих предубеждений в недвижимости складывалась на основе индивидуальных данных транзакций физических лиц. К рубежу 2020-х гг. было «...мало что известно, склонны ли другие участники рынка, например, застройщики, к таким предубеждениям» [18]. Весьма важным исключением из общего потока работ по этой тематике служит статья Leung, Tsang (2010) [21]. Эта работа отличается тем, что объединяет в своей модели не один феномен, а оба – и неприятие убытков продавцов, и референс-зависимость покупателей, хотя и изучаемых в разных субмоделях. Такой подход гораздо ближе к реальности, потому что субъекты, в зависимости от роли в сделке, преимущественно подвержены разным предвзятостям.

В настоящей работе изучается вопрос формирования застройщиками транзакционных цен на региональных рынках жилой недвижимости. Интересны факторы – фундаментальные и поведенческие, которые помогут управлять бизнесу экономическими результатами за счет политики применения дисконта/премии, выявлению граничных условий, количественной оценке гетерогенности, их ранжированию по важности и значимости.

Таким образом, тестируемые гипотезы настоящей работы:

Г1: Оправдано ли включение поведенческих факторов наряду с факторами региональной экономики в причинные модели доходности и продаваемости?

Г2: Достаточно ли наблюдательного датасета для построения валидированной экономико-поведенческой модели персонализированного ценообразования класса СПР на примере менеджмента в девелопменте?

Г3: Оказывает ли влияние политика применения дисконта/премии на экономическую результативность компании?

## Метод и данные

**Данные.** Для тестирования гипотез используется база данных транзакций жилой площади одного застройщика с 8 городами присутствия в 7 регионах РФ за период 01.01.2020 – 30.03.2023. База данных содержит 12 489

<sup>1</sup> Другие названия поведенческих аспектов, встречающиеся в литературе: эвристики, предвзятости, феномены, предубеждения, эффекты.

уникальных записей по каждой из проданных квартир в многоквартирных домах (объектах) с указанием филиала застройщика и региона РФ. Датасет содержит данные в разрезе квартир, в том числе дата продажи, жилая площадь, канал продажи, способ оплаты, скидка/наценка, доход застройщика от продажи. Кроме того, в каждой записи имеется информация, специфичная для региона: средневзвешенная ставка ипотеки на первичное жилье, среднемесячная зарплата, средняя цена метра жилой площади, доля непроданного жилья к проданному. Дополнительно приводятся данные о начале продаж объекта и о сроке ввода его в эксплуатацию. Данные последних двух групп взяты из общедоступного электронного ресурса «наш.дом.рф». Сводка переменных датасета, которые предполагается использовать при построении модели, представлена в табл. 1.

Таблица 1

**Описание переменных датасета**  
**Description of dataset variables**

Переменная	Тип	Описание	Роль в модели
Площадь	float64	Площадь проданной квартиры, кв. м	кофаундер
ипфил_п	float64	средневзвешенная ставка ипотеки на первичное жилье, сложившаяся по региону на месяц продажи, %	кофаундер
продаваемость	float64	отставание фактически проданной площади от плана продаж по объекту на день продаж, кв. м; < 0 – отставание, > 0 – опережение	$Y_0$ целевая
лист_рег	float64	отношение цены кв. м регулярной цены квартиры к средней цене кв. м по региону на месяц продаж; поведенческий феномен «референс-зависимость»	кофаундер
квм_зп	float64	площадь, которую можно приобрести на среднемесячную зарплату по региону на месяц продажи, кв. м	кофаундер
LOSS_время	float64	время, оставшееся до конца периода продаж объекта (срок ввода в эксплуатацию), дни; поведенческий феномен «неприятие потери»	кофаундер
LOSS_рег	float64	доля непроданного жилья к выставленному на продажу по региону на месяц продажи	кофаундер
предопл	object	1, если оплата через 100 % предоплаты; 0, если нет	кофаундер
И	object	1, если оплата через ипотеку; 0, если нет	кофаундер
В	object	1, если в счет оплаты первое жилье; 0, если нет	кофаундер
Р	object	1, если оплата с рассрочкой; 0, если нет	кофаундер
А_неА	object	1, если продажа через агента; 0, если продажа через застройщика	кофаундер
скидка	object	1, если применен дисконт; 0, если нет	$T_0$ воздействие
наценка	object	1, если применена премия; 0, если нет	$T_1$ воздействие
Доход	float64	Сумма выручки от продажи квартиры застройщиком, руб.	$Y_1$ целевая

В табл. 2 приводится описательная статистика датасета.

Таблица 2

**Описательная статистика датасета**  
**Descriptive statistics of the dataset**

Переменная	count	mean	std	min	25 %	50 %	75 %	max
Площадь	12489	62,873	27,767	14,900	41,940	60,230	78,800	305,020
ипфил_п	12489	56968	0,847	2,760	5,590	5,830	6,140	8,500
продаваемость	12489	-75,549	3767,164	-49334,006	-1834,488	62,822	1738,685	10586,006
лист_рег	12489	1,083	0,237	0,402	0,927	1,059	1,207	3,635
квм_зп	12489	0,570	0,168	0,153	0,459	0,542	0,646	1,590
LOSS_время	12489	600,856	325,408	-1446,000	431,000	634,000	799,000	1539,000
LOSS_рег	12489	0,468	0,074	0,270	0,419	0,453	0,508	0,771
предопл	12489	0,157	0,364	0,000	0,000	0,000	0,000	1,000
И	12489	0,663	0,473	0,000	0,000	1,000	1,000	1,000
В	12489	0,170	0,375	0,000	0,000	0,000	0,000	1,000
Р	12489	0,161	0,367	0,000	0,000	0,000	0,000	1,000
А_неА	12489	0,383	0,486	0,000	0,000	0,000	1,000	1,000
скидка	12489	0,611	0,488	0,000	0,000	1,000	1,000	1,000
наценка	12489	0,031	0,173	0,000	0,000	0,000	0,000	1,000
Доход	12489	6,13E+06	3,07E+06	3,92E+05	4,10E+06	5,60E+06	7,30E+06	4,86E+07

Перед менеджерами по продажам застройщика (агентами) стоят противоречащие друг другу требования: с одной стороны, требуется полностью завершить продажи квартир объекта за период с даты открытия продаж до ввода дома в эксплуатацию для соблюдения условий инвестиционного цикла, с другой стороны, продажи должны обеспечить заданный уровень маржинальности. Первое требование можно описать целевой переменной  $Y_0$ , которая представляет отставание фактически проданного объема жилья от плана продаж по объекту на день транзакции. Признаком отставания является отрицательный знак этого параметра и, наоборот, признаком опережения – его положительное значение. Второе требование описывается другим таргетом  $Y_1$ , который отражает величину дохода по каждой транзакции. Таким образом, для выполнения стоящих перед продавцом задач необходима максимизация обеих целевых переменных. Менеджеры по продажам (агенты) действуют в условиях, когда система динамического ценообразования застройщика автоматически генерирует листинговые цены квартир в размере справедливой рыночной цены. Менеджеры (агенты) наделяются полномочиями 1) либо продать по листинговой цене, 2) либо применить наценку к листинговой цене (переменная воздействия  $T_1$ ), повышая доходность, 3) либо дисконт к листинговой цене (переменная воздействия  $T_0$ ), стремясь уложиться в срок продаж. Поэтому актуальным становится вопрос: когда и под влиянием каких факторов применить дисконт/премию на каждой транзакции для общей максимизации обоих таргетов?

С учетом выстроенной системы мотивации менеджеров застройщика на этапе уторговывания с клиентом, каждый из них сталкивается с веро-

ятностью понести убыток, выражающийся в непроданном объеме жилья на момент транзакции, т.е. вероятно возникновение феномена неприятия потерь персоналом. Такой вероятный убыток может быть оценен на уровне объекта, когда на дату транзакции остается слишком мало времени, чтобы успеть выполнить план продаж к концу периода продаж («LOSS\_время»).

Покупатели жилья, в свою очередь, на этапе согласования цены транзакции могут быть подвержены феномену референс-зависимости. В качестве якоря обычно выступает среднерыночная цена квадратного метра по региону, а сам феномен предлагается оценить как отношение удельной цены листинга к удельной среднерыночной цене по региону («лист\_рег»). Поэтому реализация этой когнитивной предвзятости будет сдвигать удельную транзакционную цену от удельной листинговой в сторону снижения к среднерыночной. В данном случае референс-зависимость работает только в сторону снижения.

Поскольку транзакционная цена устанавливается участниками сделки в условиях действия региональных экономических показателей, в модели требуется их контроль, в том числе средневзвешенной ставки ипотеки на первичное жилье («ипфил\_п»), площади, которую можно приобрести на среднемесячную заработную плату («квм\_зп»), а также показателя активности регионального рынка нового жилья («LOSS\_рег»). Эти параметры отражают региональную специфику. Еще одна группа переменных учитывает особенности транзакций в части канала продаж (агент/менеджер) и способа оплаты, которые предположительно могут повлиять на размер эффекта дисконта/премии.

Учитывая, что модель содержит конкурирующие таргеты и взаимоисключающие воздействия, создадим субмодели, а затем сделаем попытку агрегировать полученные правила для формирования единой политики применения дисконта/премии:

$M(T_0, Y_0)$  – субмодель продаваемости при применении дисконта;

$M(T_1, Y_0)$  – субмодель продаваемости при применении премии;

$M(T_0, Y_1)$  – субмодель доходности при применении дисконта;

$M(T_1, Y_1)$  – субмодель доходности при применении премии.

**Инструменты.** Настоящее исследование проводилось с использованием информационных ресурсов статуса Open Source, в том числе сервис Google Sheets, среда Colab Notebooks (free аккаунт Google), библиотек Python: pandas, numpy, seaborn, sklearn, matplotlib, DoWhy [4], EconML [23].

**Метод.** В настоящей работе были использованы методы причинно-следственного анализа. Здесь в качестве вмешательств рассматриваются факт применения скидки и факт применения наценки к регулярной цене (бинарные переменные). Эффект воздействия измеряется по изменению целевых переменных – дохода и продаваемости (непрерывные переменные). Все остальные переменные модели являются потенциальными кофайндерами – величинами, которые могут образовывать ложные корреляции между таргетами и воздействиями. Для получения чистого причинного эффекта необходимо блокировать влияние кофайндеров на таргет и воздействие путем взятия их под контроль, т.е. исключить смещение, которое они вносят в размер причинного эффекта.

Ниже приводится формула (1) записи вышесказанного [20]:

$$E[Y | T = 1] - E[Y | T = 0] = \underbrace{E[Y_1 - Y_0 | T = 1]}_{ATE} + \underbrace{E[Y_0 | T = 1] - E[Y_0 | T = 0]}_{BIAS},$$

где  $E$  – оператор ожидаемого значения;  $Y_1$  – величина таргета после воздействия;  $Y_0$  – величина таргета без воздействия; ATE – средний эффект воздействия по всей совокупности; BIAS – смещение, которое требуется заблокировать, чтобы этот член стал 0;  $T = 1$  – есть воздействие;  $T = 0$  – нет воздействия.

Рекомендуется визуализировать причинную модель в форме направленного ациклического графа, чтобы убедиться, что все кофандеры контролируются, а коллайдеры наоборот исключены из модели. Это гарантирует получение несмещенной оценки причинного эффекта. На рис. 1 представлена структурная модель причинного графа субмодели  $M(T_1, Y_0)$ .

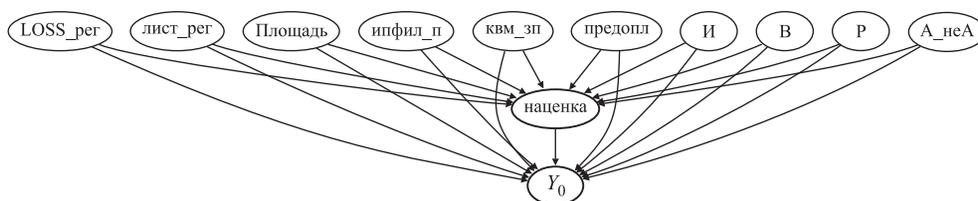


Рис. 1. Направленный ациклический граф субмодели  $M(T_1, Y_0)$

Directed acyclic graph of submodel  $M(T_1, Y_0)$

По сообщениям участников сообщества, по причинному выводу этап разработки структурной модели является самым ответственным и плохо формализуемым. Поэтому для его реализации используют либо знания предметных экспертов, либо методики открытия причин [14]. Пакеты автоматического открытия причин по имеющимся данным не применялись, а граф получили назначением ролей, проверив с предметными специалистами его непротиворечивость. Работа проводилась по этапам, основное содержание которых и последовательность представлены в табл. 3.

Этап 2 идентификации причинного эффекта – анализ причинного графа на предмет отсутствия ложных связей между целевой переменной  $Y$  и переменной воздействия  $T$ . Набор переменных удовлетворяет критерию backdoor, если ни один узел из него не является потомком  $T$  и заблокированы все пути между  $Y$  и  $T$ , которые содержат стрелки в  $T$  [15]. Как видно из рис. 1, все пути потенциальных ложных связей заблокированы, поскольку все переменные на таких путях взяты под контроль.

Этап 3 оценка величины ATE произведена двумя оценщиками – самым простым (линейная регрессия) и одним из продвинутых (причинный лес). Тем не менее получен практически идентичный результат –321 и –319 соответственно. Данный факт лишний раз подтверждает устойчивость созданной причинной модели. Кроме того, можно отметить, что метод причинного леса весьма затратный по машинным ресурсам алгоритм, и на больших датасетах он вряд ли окажется полезным.

**Этапы исследования**  
**Research stages**

№ этапа	Наименование этапа	Информационный ресурс	Заграченное машинное время, с
1	Представление проблемы в виде причинного графа субмоделей	DoWhy [4]	< 1
2	Идентификация причинного эффекта субмоделей; метод backdoor	DoWhy [4]	< 1
3	Оценка среднего причинного эффекта АТЕ субмоделей с оценщиками на основе линейной регрессии и CausalForestDML	DoWhy [4], EconML [23]	< 1,356
4	Валидация причинного эффекта всех субмоделей проведением тестов опровержения: 1) Add Unobserved Common Cause, 2) Replace Treatment with Placebo, 3) Remove a Random Subset, 4) Add Random Common Cause	DoWhy [4], EconML [23]	87–112
5	Рандомное разделение датасета на обучающий и тестовый набор в соотношении 1 : 5	sklearn	< 1
6	Расчет условного среднего эффекта воздействия CATE для субмоделей с применением 6 оценщиков: Slearner, Tlearner, Xlearner, DRlearner, LinearDML, CausalForestDML	EconML [23]	0,16; 0,22; 0,53; 1,71; 7,81; 3,30
7	Выбор лучшего оценщика через метрику ожидаемого ответа и расчет доверительных интервалов	EconML [23]	< 1
8	Расчет дерева CATE и политик для каждой субмодели с лучшим оценщиком	EconML [23]	293–346
9	Агрегация единых правил применения скидки/премии из субмоделей	–	–

Важным элементом исследования стал этап 4 – валидация причинной модели. Для этого в причинном анализе предусмотрены тесты опровержения. Проведены 4 таких теста. Тест 1) просто добавляет к набору переменных рандомный некоррелированный кофаундер и пересчитывает АТЕ. После пересчета ожидается неизменность. Тест показал небольшое изменение эффекта с  $-319$  до  $-324$ , что вполне допустимо. Тест 2) заменяет переменную воздействия на шум, при этом ожидается нулевой АТЕ. В нашем случае изменение АТЕ – с  $-319$  до  $+85$ , что, конечно, далеко от идеального, но также приемлемо с учетом изменения знака эффекта и его перехода через 0. Так как предполагается, что причинная модель лишена неконтролируемых кофаундеров, тест 4) не должен сместить оценку эффекта. В нашем же случае наблюдается серьезное изменение: АТЕ меняется с  $-319$  до  $-30$ . Это говорит о том, что модель несовершенна и имеются ложные ненаблюдаемые переменные, которые не учтены при формировании набора. И, наконец, тест 3) удаляет случайный поднабор данных и пересчитывает АТЕ, чтобы сделать вывод о степени генерализации оценщика. Ожидается, что пересчет на поднаборе не должен сильно отличаться от оригинала. Изме-

нение АТЕ на этом тесте составляет с  $-319$  до  $-262$ , что является средним результатом. Следует отметить, что  $p$ -value на всех тестах  $\sim 0,2$ , что не может считаться статистически значимым результатом и обусловлено небольшим размером датасета.

Большинство авторов тематики причинного вывода сходятся во мнении, что пока отсутствуют разумные критерии выбора типа оценщика для каждого датасета априори [14, 20]. Это вынуждает применять конвейеры с несколькими типами оценщиков и затем выбирать лучший из них на основе подходящих метрик. На этапе 6 нами применен именно такой подход с 6 оценщиками разных типов. Алгоритмы оценщиков подробно описываются, например, в [5, 11, 19]. Все оценщики обучались на датасете с кросс-валидацией  $cv = 5$ ; затем с помощью функции GridSearch были выбраны лучшие гиперпараметры каждой из моделей.

Для выбора лучшего оценщика на этапе 7 была применена метрика ожидаемого ответа, которая успешно работает с непрерывными таргетами. В основе этой метрики лежит модифицированная uplift-кривая зависимости величины ожидаемого эффекта от доли наблюдений, подвергшихся воздействию. Рассматривается падение этой метрики на тестовом датасете по отношению к обучающему датасету. Хорошим признаком является меньшая разница. В нашем случае расчет показывает серьезное падение метрики всех оценщиков, кроме линейного DML (249 на обучающем и 240 на тестовом наборе). Хотя по производительности он уступает, например, оценщику DRLearner. Еще одним способом оценки качества модели может служить метод расчета доверительных интервалов эффекта. Высокое качество модели можно оценить по доле доверительных интервалов, содержащих 0: чем меньше таких интервалов, тем качественнее модель. Была произведена оценка доверительных интервалов эффекта оценщика LinearDML. Доля доверительных интервалов с нулем по всем наблюдениям составила 0,4 %, что может считаться очень хорошим результатом.

В пакете EconML имеются два инструмента, способные 1) интерпретировать условные средние эффекты воздействия, т.е. объяснить самые большие различия в реакции на вмешательство; 2) интерпретировать политику, т.е. пытаться отделить ответивших (подгруппы с положительным эффектом) от тех, кто не ответил (подгруппы с отрицательным эффектом). Эти инструменты применены на этапе 8 для каждой из субмоделей. В качестве параметров для изучения гетерогенности переменных воздействия на основе их значимости для модели выбраны следующие переменные: «LOSS\_reg», «LOSS\_время», «лист\_reg», «квм\_зп», «Площадь». Глубина деревьев задается двухуровневой.

## Результаты и обсуждение

**АТЕ.** Сначала рассмотрим результаты расчета АТЕ, как если бы каждая из переменных была воздействием. Для примера в табл. 4 приведены отсортированные по причинной значимости ( $p$ -value) переменные датасета для субмодели  $M(T_1, Y_0)$ .

Таблица 4

**Прямые причинные эффекты для субмодели  $M(T_1, Y_0)$**   
**Direct causal effects for submodel  $M(T_1, Y_0)$**

feature	feature_value	point	stderr	zstat	p_value	ci_lower	ci_upper
LOSS_per	num	-20488.502741	927.499277	-22.090047	3.939847e-108	-22306.367921	-18670.637562
квм_зп	num	-5978.292483	860.911488	-6.944143	3.807647e-12	-7665.647993	-4290.936973
LOSS_время	num	1.430234	0.218352	6.550126	5.748864e-11	1.002272	1.858196
Площадь	num	-6.055858	1.064660	-5.688069	1.284843e-08	-8.142553	-3.969163
И	1v0	425.715006	95.513600	4.457114	8.307043e-06	238.511789	612.918222
Р	1v0	456.309961	155.639411	2.931841	3.369595e-03	151.262320	761.357602
лист_per	num	-1294.185360	504.261636	-2.566496	1.027319e-02	-2282.520006	-305.850714
предопл	1v0	228.934795	128.278869	1.784665	7.431569e-02	-22.487169	480.356758
В	1v0	74.989553	44.052441	1.702279	8.870305e-02	-11.351645	161.330750
инфил_п	num	310.788048	186.933430	1.662560	9.640054e-02	-55.594743	677.170838
A_неА	1v0	-38.703992	33.304302	-1.162132	2.451819e-01	-103.979225	26.571241
наценка	1v0	-80.478750	127.336439	-0.632017	5.273760e-01	-330.053585	169.096085

Среди самых влиятельных на причинный эффект переменных можно отметить два региональных и два поведенческих фактора. Из параметров транзакции самым ценным модель считает площадь квартиры. Параметры группы способа оплаты разделились по важности, поэтому из исследования гетерогенности были исключены.

**Субмодель  $M(T_0, Y_1)$ .** Результат для этой субмодели представлен на рис. 2.

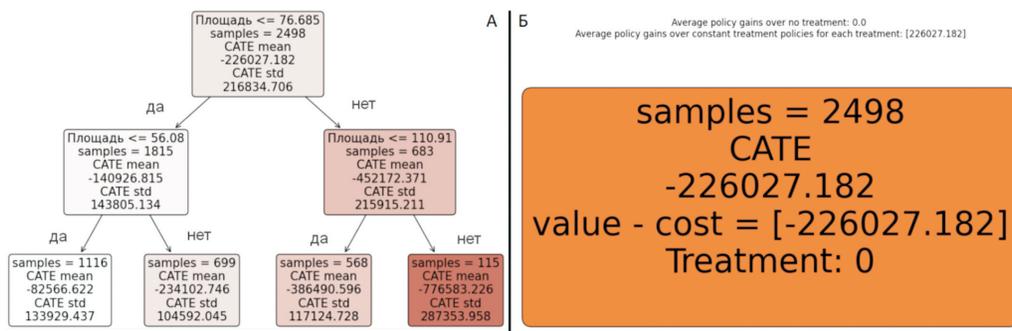


Рис. 2. Субмодель  $M(T_0, Y_1)$ : Панель А: Дерево интерпретации CATE.

Панель Б: Дерево интерпретации политики

Submodel  $M(T_0, Y_1)$ : Panel A: CATE interpretation tree. Panel B: Policy Interpretation Tree

Дерево политики демонстрирует, что применение скидки не дает добавления дохода ни при каких обстоятельствах, что интуитивно вполне объяснимо: любая скидка ведет к снижению доходности; соответственно «дерево» политик превратилось в «лист». В среднем снижение доходности в ответ на дисконт составляет 226 тыс. руб. на каждый случай. Из дерева интерпретации видно, что этот отрицательный эффект неравномерен в зависимости от площади квартиры. Применение скидки к квартирам площадью менее 76 кв. м снижает падение дохода до 141 тыс. руб., а когда дисконт применяли к квартирам площадью менее 56 кв. м, то размер падения снижается дальше до 82 тыс. руб. С другой стороны, когда дисконт применялся к квартирам площадью более 76 кв. м, то отрицательный эффект усиливается почти в два раза до 452 тыс. руб., а его применение в случаях больших квартир площадью более 111 кв. м приводит к драматическому снижению до 777 тыс. руб. на каждый случай (хотя их доля всего 5 %). Из этих данных можно заключить, что эффект дохода в зависимости от скидки наиболее чувствителен к параметру «площадь» по сравнению с остальными потенциальными факторами гетерогенности – «LOSS\_рег», «лист\_рег», «квм\_зп», т.е. он эластичен лишь от потребительских свойств квартир, но не от поведенческих факторов и от факторов региональной экономики. Начинать думать о применении дисконта применительно к площади квартиры можно лишь на площадях менее 76 кв. м, а лучше менее 56 кв. м.

**Субмодель  $M(T_0, Y_0)$ .** Результат для этой субмодели представлен на рис. 3.

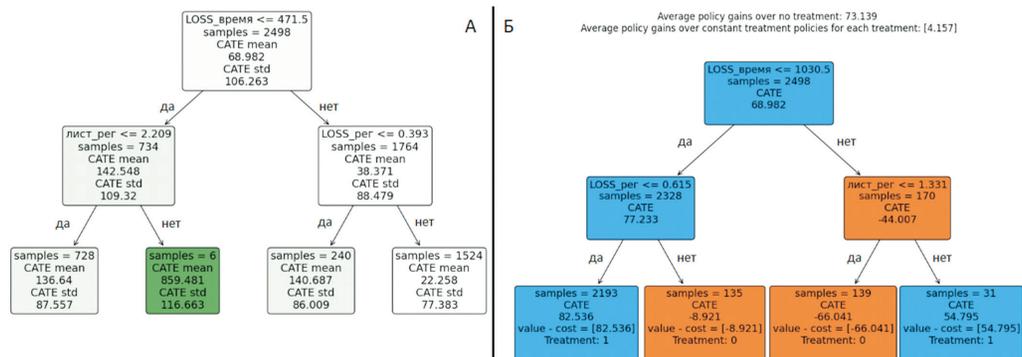


Рис. 3. Субмодель  $M(T_0, Y_0)$ : Панель А: дерево интерпретации CATE. Панель Б: Дерево интерпретации политики

Submodel  $M(T_0, Y_0)$ : Panel A: CATE interpretation tree. Panel B: Policy Interpretation Tree

Как видно из рис. 3, картина в этой субмодели более разнообразна, чем в предыдущей и связана с вовлечением в гетерогенность продаваемости как поведенческих факторов, так и факторов, отражающих региональную специфику. Эффект применения дисконта, как и ожидалось, положительным образом влияет на продаваемость – в среднем отставание от графика продаж сокращается на 68,9 кв. м на каждый случай. Основным фактором разнообразия в этом эффекте выступает переменная «LOSS\_время» – остаток времени продаж объекта до его сдачи в эксплуатацию. Продаваемость становится выше средней, когда скидка применяется к транзакциям объектов, до срока окончания продаж которых остается менее 1030 дней. Видимо, это тот временной порог, когда продавцы начинают испытывать «страх» не уложиться в период продаж и пытаются активно применять дисконт. С другой стороны, дерево CATE показывает, что максимальный положительный эффект на продаваемость оказывает применение скидки, когда остаточный срок продаж достигает 491 день. Таким образом, очевидно, что раннее использование этого инструмента не приводит к большой пользе и встает вопрос о корректировке сложившейся практики менеджеров (агентов). Аналогичная картина складывается в отношении параметра региональной экономики «LOSS\_рег» – доля непроданного жилья в регионе. Менеджеры (агенты) начинают применять дисконт при доле непроданного жилья менее 0,61, тогда как максимально полезный эффект от скидок может быть получен только на значениях этого параметра менее 0,39. Еще один поведенческий аспект референс-зависимость «лист\_рег» проявляется в сегменте премиальных квартир. Хотя менеджеры (агенты) начинают «ощущать» его на уровне 1,33 и стимулировать продажи дисконтами, по хорошему он начинает проявляться выраженным позитивным эффектом на продаваемость лишь в сегменте премиальных квартир на уровне 2,2.

**Субмодель  $M(T_1, Y_0)$ .** Результат для этой субмодели предложен на рис. 4.

Без сюрпризов в среднем премия замедляет продаваемость на 55 кв. м. Сложившаяся практика менеджеров (агентов) – начинать применять премию к квартирам площадью менее 58 кв. м. Тем не менее субмодель об-

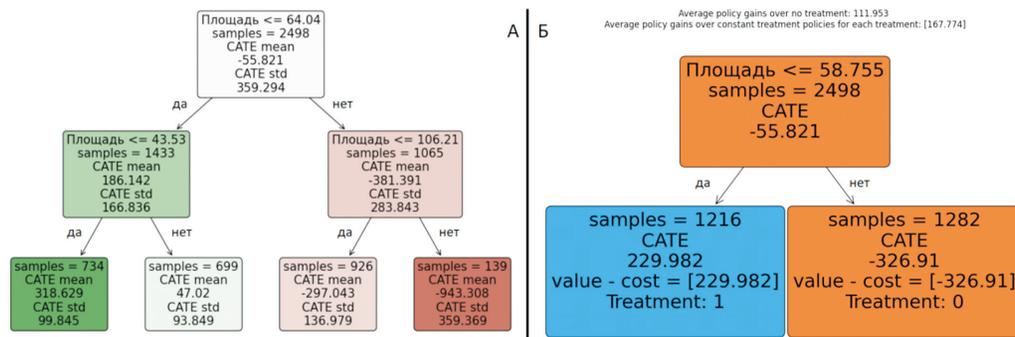


Рис. 4. Субмодель  $M(T_1, Y_0)$ : Панель А: дерево интерпретации CATE.

Панель Б: Дерево интерпретации политики

Submodel  $M(T_1, Y_0)$ : Panel A: CATE interpretation tree. Panel B: Policy Interpretation Tree

наружила сегменты, в которых эффект изменяет знак на положительный. Если начать применять премию к квартирам площадью менее 64 кв. м, то эффект становится положительным и равным 186 кв.м, если же наценку делать на цену еще меньших квартир менее 43 кв. м, то можно получить еще более значительное увеличение положительного эффекта до 318 кв. м. Данный факт поддерживает мнение о гипертрофированном спросе покупателей на квартиры небольшой площади (чем компактнее, тем более востребованы) вплоть до ажиотажного спроса, когда покупатели, обнаружив тренд на повышение цены, начинают скупку наличного жилья. И, напротив, наценка на квартиры площадью более 64 кв. м в разы замедляет продаваемость, не говоря уж о квартирах больших, чем 106 кв. м: в этом сегменте замедление продаваемости приближается к 1000 кв. м.

**Субмодель  $M(T_1, Y_1)$ .** Результат для этой субмодели представлен на рис. 5.

Дерево политики свидетельствует о том что средний эффект премии на доходность положительный и составляет 563 тыс. руб. на случай. При этом встречаются транзакции, когда премия применяется к квартирам площадью менее 33,1 кв. м, что приводит к отрицательной доходности.

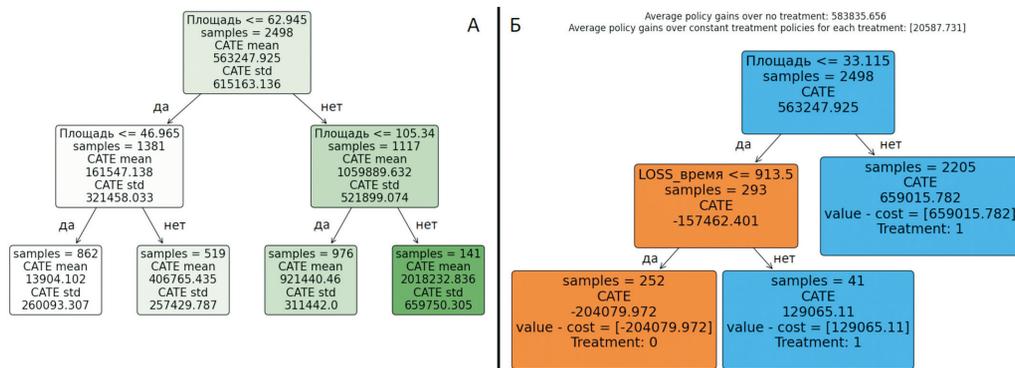


Рис. 5. Субмодель  $M(T_1, Y_1)$ : Панель А: дерево интерпретации CATE.

Панель Б: Дерево интерпретации политики

Submodel  $M(T_1, Y_1)$ : Panel A: CATE interpretation tree. Panel B: Policy Interpretation Tree

Из дерева SATE следует, что повышение эффекта премии на доход выше среднего можно добиться, применяя наценку на квартиры площадью более 62,9 кв. м, и воздерживаясь от ее применения в отношении квартир меньшей площади.

**Агрегация субмоделей.** Итог агрегации уточненных правил применения дисконтов/премий для максимизации экономических результатов приведен в табл. 5.

Таблица 5

**Экономические результаты при применении инструментов персонализированной политики**

**Economic results when using personalized policy instruments**

		Экономические результаты	
		Доход	Продаваемость
Инструменты	Дисконт	Площадь < 76 кв. м	LOSS_время < 491 дня LOSS_per < 0,39 Лист_per > 2,2
	Премия	Площадь < 63 кв. м	Площадь < 64 кв. м

С точки зрения повышения доходности дисконт необходимо применять к квартирам площадью менее 76 кв. м, а премию – к квартирам более 63 кв. м. Диапазон (63; 76) кв. м является зоной неопределенности, в которой лучше воздержаться от применения обоих инструментов. С точки зрения продаваемости целесообразнее ориентироваться на дисконт больше, чем на премию. При этом определены следующие зоны для назначения скидок: 1) остаточный срок продаж составляет менее 491 день, доля непроданного жилья по региону менее 0,39; отношение удельной цены листинга к среднерыночной цене по региону более 2,2.

**Обсуждение.** Учитывая рекомендацию о необходимости обогащения тематики поведенческих аспектов в недвижимости исследованиями национальных рынков [9], была выполнена работа в отношении не затронутого такими исследованиями рынка жилой недвижимости Российской Федерации (РФ). В отличие от вышеупомянутых статей [1, 3] нами выполнено полноценное эмпирическое обсервационное исследование на датасете кросс-секционных реальных данных российского девелопера с применением нескольких методов причинного вывода. Развивая подход Leung, Tsang (2010) [21], разработана модель, включающая одновременно два феномена. Кроме того, работу можно рассматривать как новый вклад в эту тему с позиций изучения поведения персонала корпораций в отличие от большинства публикаций, преимущественно посвященных изучению транзакций физических лиц. Данное исследование является кросс-секционным, что добавляет ему веса в надежности полученных оценок по сравнению

с большинством предшествующих работ, использующих датасеты моногородов. Как отмечают X. Zhang et al. (2021) [25], многоцентровые исследования в отличие от одноцентровых обеспечивают более диверсифицированную выборку и более сильную обобщаемость (внешнюю валидность). На фоне ограниченного круга национальных рынков недвижимости с опцией presale настоящая работа, используя особенность рынка РФ, относится к пока узкой нише исследований этого сектора.

Кроме того, она может считаться новым вкладом в поток литературы по операционному менеджменту, добавляя к нему исследование, включающее поведенческие факторы в механизм ценообразования и управления доходом и преодолевая дефицит исследовательской активности по тематике поведенческого исследования операций (BOR). Все исследования, перечисленные в обзоре этой тематики, оперируют лишь классическими эконометрическими методами, тогда как авторами использовались и более продвинутые методики машинного обучения с выходом на оценку условного причинного эффекта. Существенным отличием от предыдущего является также этап валидации причинной модели различными методами опровержения.

К слабостям нашей работы следует отнести несбалансированность датасета по воздействиям. Хотя авторы причинного вывода упоминают о толерантности причинных моделей к несбалансированности [14], некоторый скепсис по этому поводу все же остается. Балансировка же не могла быть произведена ввиду небольшого объема датасета. Еще одним серьезным недостатком проведенного исследования может быть признана фрагментированность и репрезентация в форме четырех субмоделей и последующей, по сути ручной, увязкой граничных условий. Главным же предметом беспокойства является экспертный способ построения причинного графа.

### **Заключение**

В результате проведенного исследования было выявлено, что поведенческие факторы наряду с факторами региональной экономики являются важнейшими предикторами в моделях, на которых может быть основан механизм персонализированного ценообразования. Причинная модель была построена лишь на основе датасета наблюдений реальных транзакций без дополнительных допущений и гипотез, что открывает новые перспективы операционного менеджмента в классе моделей data-driven. Результаты такого моделирования демонстрируют функционал причинной модели для анализа существующей практики менеджмента, выявления граничных условий и формирования новой политики применения инструментов дисконта/премии для максимизации экономических результатов. Это подтверждает сделанные нами гипотезы. Работа имеет как научное, так и прикладное значение. С одной стороны, она восполняет дефицит поведенческих исследований и эмпирических исследований причинных моделей на национальных рынках жилой недвижимости. С другой стороны, она указывает практикам на материальный эффект поведенческих предвзятостей персонала, избыточных «холостых выстрелов» (ненужного применения инструмен-

тов без ответа), указывает точки приложения для внесения корректировки в бизнес-процессы компании и упорядочения инструментальной политики менеджмента.

Перечисленные слабости настоящей работы должны побудить будущих исследователей тематики к поиску новых принципов моделирования и конструирования причинного графа на более обширных датасетах.

### Список источников

1. *Георги М.Ю.* Методы извлечения причинности из данных наблюдений в практике искусственного интеллекта // Известия Южного федерального университета. Технические науки. 2023. № 3 (233). С. 125–134.
2. *Михайлов Д.В., Тарасьев А.М.* Системы поддержки принятия решений в контексте девелопмента: критический анализ публикаций // Весенние дни науки. Сборник докладов международной конференции студентов и молодых ученых. Екатеринбург, 2023. С. 69–73.
3. *Орлова Е.В.* Критический анализ методов моделирования причинных связей // Стратегическое планирование и развитие предприятий: материалы XXIV Всероссийского симпозиума. Москва, 11–12 апреля 2023 г. / под ред. чл.-корр. РАН Г.Б. Клейнера. М.: ЦЭМИ РАН, 2023. С. 618–622. DOI: 10.34706/978-5-8211-0814-2-s3-16. EDN: WPGODU.
4. *Amit Sharma, Emre Kiciman.* DoWhy: An End-to-End Library for Causal Inference. 2020. URL: <https://arxiv.org/abs/2011.04216>.
5. *Athey S. & Imbens G.* Recursive partitioning for heterogeneous causal effects. Proceedings of the National Academy of Sciences. 2016.
6. *Engström P. & Nordblom K. & Stefánsson A.* Loss aversion and indifference to tax rates: Evidence from tax filing data // Journal of Economic Behavior & Organization, Elsevier, 2022. Vol. 200(C). Pp. 287–311.
7. *Green J. & White M.H., II.* Machine Learning for Experiments in the Social Sciences. Cambridge University Press, Elements Series in Experimental Political Science. 2023.
8. *Helen X.H., Bao and Charlotte C. Meng.* Loss Aversion and Housing Studies // Journal of Real Estate Literature. 2017. Vol. 25, no. 1. Pp. 49–75.
9. *Helen X.H. Bao & Rufus Saunders.* Reference dependence in the UK housing market, Housing Studies 2023. Vol. 38. no. 7. Pp. 1191–1219. DOI: 10.1080/02673037.2021.1935767.
10. *Ho, Teck-Hua et al.* OM forum—Causal inference models in operations management // Manufacturing & Service Operations Management 19.4. 2017. Pp. 509–525.
11. *Künzel, Sören R. et al.* Metalearners for estimating heterogeneous treatment effects using machine learning // Proceedings of the national academy of sciences 116.10. 2019. Pp. 4156–4165.
12. *Lausberg C. & Krieger P.* Decision Support Systems in Real Estate: History, Types and Applications // Decision Support Systems: Types, Advantages and Disadvantages / ed. F.J. Roberts, 1-77. Hauppauge/NY: Nova. 2021.
13. Microsoft Research. EconML: A Python Package for ML-Based Heterogeneous Treatment Effects Estimation. URL: <https://github.com/microsoft/EconML>, 2019. Version 0.x.
14. *Molok A.* Causal Inference and Discovery in Python: Unlock the secrets of modern causal machine learning with DoWhy, EconML, PyTorch and more. Packt Publishing, 2023.
15. *Pearl J., Glymour M., Jewell N.P.* Causal inference in statistics: A primer. Wiley. 2016.
16. *Zhao, Yan, Xiao Fang, David Simchi-Levi.* Uplift modeling with multiple treatments and general response types. Proceedings of the 2017 SIAM International Conference on Data Mining. Society for Industrial and Applied Mathematics, 2017.

17. *Athey Susan*. 21. The Impact of Machine Learning on Economics. The Economics of Artificial Intelligence: An Agenda, edited by Ajay Agrawal, Joshua Gans and Avi Goldfarb, Chicago: University of Chicago Press, 2019. Pp. 507–552. URL: <https://doi.org/10.7208/9780226613475-023> (дата обращения: 20.01.2024).
18. *Bao H.X.H., Meng C.C. & Wu J.* Reference dependence, loss aversion and residential property development decisions // *J. Hous and the Built Environ.* 2021. Vol. 36. Pp. 1535–1562. URL: <https://doi.org/10.1007/s10901-020-09803-y> (дата обращения: 20.01.2024).
19. *Chernozhukov V., Chetverikov D., Demirer M., Duflo E., Hansen C., Newey W., Robins J.* (2016). Double/Debiased Machine Learning for Treatment and Causal Parameters. arXiv preprint. URL: <https://doi.org/10.48550/ARXIV.1608.00060> (дата обращения: 20.02.2024).
20. *Facure M.A.* (2020). Causal Inference for The Brave and True. URL: <https://matheus-facure.github.io/python-causality-handbook/landing-page.html> (дата обращения: 20.02.2024).
21. Leung Tin Cheuk and Tsang Kwok Ping, Anchoring and Loss Aversion in the Housing Market: Implications on Price Dynamics (November 29, 2010). URL: <http://dx.doi.org/10.2139/ssrn.1716826> (дата обращения: 20.01.2024).
22. *Levin Y., Nediak M. & Bazhanov A.* Quantity Premiums and Discounts in Dynamic Pricing. *Operations Research*, 2014. 62 (4), 846–863. URL: <http://www.jstor.org/stable/24540665> (дата обращения: 05.02.2024).
23. *Patrick Blöbaum, Peter Götz, Kailash Budhathoki, Atalanti A. Mastakouri, Dominik Janzing.* DoWhy-GCM: An extension of DoWhy for causal inference in graphical causal models. 2022. URL: <https://arxiv.org/abs/2206.06821> (дата обращения: 25.02.2024).
24. *Sharma A., Kiciman E.* Getting Started with Causal Inference: URL: <https://causalinference.gitlab.io/> (дата обращения: 25.12.2023).
25. *Xuan Zhang, Wai Ching Lam, Fan Liu, Mengdan Li, Lin Zhang, Weifeng Xiong, Xiaohan Zhou, Ran Tian, Chongya Dong, Chen Yao, David Moher, Zhaoxiang Bian.* A Cross-sectional literature survey showed the reporting quality of multicenter randomized controlled trials should be improved // *Journal of Clinical Epidemiology*, 2021. Vol. 137. Pp. 250–261. ISSN 0895-4356. URL: <https://doi.org/10.1016/j.jclinepi.2021.05.008> (дата обращения: 20.11.2023).

## References

1. Georgi M.Ju. Metody izvlechenija prichinnosti iz dannyh nabljudenij v praktike iskusstvennogo intellekta [Methods for extracting causality from observational data in the practice of artificial intelligence], *Izvestija Juzhnogo federal'nogo universiteta. Tehnicheskie nauki* [News of the Southern Federal University. Technical science], 2023, no. 3 (233), pp. 125–134.
2. Mihajlov D.V., Taras'ev A.M. Sistemy podderzhki prinjatija reshenij v kontekste developmenta: kriticheskij analiz publikacij [Decision support systems in the context of development: critical analysis of publications]. *Vesennie dni nauki. Sbornik dokladov mezhdunarodnoj konferencii studentov i molodyh uchenyh.* Ekaterinburg, 2023. Pp. 69–73.
3. Orlova E.V. Kriticheskij analiz metodov modelirovanija prichinnyh svjazej [Critical analysis of methods for modeling causal relationships]. *Strategicheskoe planirovanie i razvitie predpriyatij: materialy XXIV Vserossijskogo simpoziuma.* Moskva, 11–12 aprelja 2023 g. / pod red. chl.-korr. RAN G.B. Klejnera. Moscow, CJeMI RAN, 2023. Pp. 618–622. DOI: 10.34706/978-5-8211-0814-2-s3-16. EDN: WPGODU.
4. Amit Sharma, Emre Kiciman. DoWhy: An End-to-End Library for Causal Inference. 2020. Available at: <https://arxiv.org/abs/2011.04216>.

5. Athey S. & Imbens G. Recursive partitioning for heterogeneous causal effects. *Proceedings of the National Academy of Sciences*. 2016.
6. Engström P. & Nordblom K. & Stefánsson A. Loss aversion and indifference to tax rates: Evidence from tax filing data, *Journal of Economic Behavior & Organization*, Elsevier, 2022, vol. 200(C), pp. 287–311.
7. Green J. & White M.H., II. *Machine Learning for Experiments in the Social Sciences*. Cambridge University Press, Elements Series in Experimental Political Science. 2023.
8. Helen X.H. Bao and Charlotte C. Meng. Loss Aversion and Housing Studies. *Journal of Real Estate Literature*, 2017, vol. 25, no. 1, pp. 49–75.
9. Helen X.H. Bao & Rufus Saunders. Reference dependence in the UK housing market, *Housing Studies*, 2023, 38(7): 1191–1219. DOI: 10.1080/02673037.2021.1935767.
10. Ho, Teck-Hua et al. OM forum—Causal inference models in operations management. *Manufacturing & Service Operations Management* 19.4, 2017, pp. 509–525.
11. Künzel, Sören R. et al. Metalearners for estimating heterogeneous treatment effects using machine learning. *Proceedings of the national academy of sciences* 116.10, 2019, pp. 4156–4165.
12. Lausberg C. & Krieger P. *Decision Support Systems in Real Estate: History, Types and Applications*. *Decision Support Systems: Types, Advantages and Disadvantages*, ed. F.J. Roberts, 1–77. Hauppauge/NY: Nova. 2021.
13. Microsoft Research. *EconML: A Python Package for ML-Based Heterogeneous Treatment Effects Estimation*. Available at: <https://github.com/microsoft/EconML>, 2019. Version 0.x.
14. Molak A. *Causal Inference and Discovery in Python: Unlock the secrets of modern causal machine learning with DoWhy, EconML, PyTorch and more*. Packt Publishing, 2023.
15. Pearl J., Glymour M., Jewell N.P. *Causal inference in statistics: A primer*. Wiley. 2016.
16. Zhao, Yan, Xiao Fang, David Simchi-Levi. “Uplift modeling with multiple treatments and general response types. *Proceedings of the 2017 SIAM International Conference on Data Mining*. Society for Industrial and Applied Mathematics, 2017.
17. Athey Susan. 21. *The Impact of Machine Learning on Economics*. *The Economics of Artificial Intelligence: An Agenda*, edited by Ajay Agrawal, Joshua Gans and Avi Goldfarb, Chicago: University of Chicago Press, 2019, pp. 507–552. Available at: <https://doi.org/10.7208/9780226613475-023> (accessed: 20.01.2024).
18. Bao H.X.H., Meng C.C. & Wu J. Reference dependence, loss aversion and residential property development decisions. *J Hous and the Built Environ*. 2021, 36: 1535–1562. Available at: <https://doi.org/10.1007/s10901-020-09803-y> (accessed: 20.01.2024).
19. Chernozhukov V., Chetverikov D., Demirer M., Duflo E., Hansen C., Newey W., Robins J. (2016). *Double/Debiased Machine Learning for Treatment and Causal Parameters*. arXiv preprint. Available at: <https://doi.org/10.48550/ARXIV.1608.00060> (accessed: 20.02.2024).
20. Facure M.A. (2020). *Causal Inference for The Brave and True*. Available at: <https://matheusfacure.github.io/python-causality-handbook/landing-page.html> (accessed: 20.02.2024).
21. Leung Tin Cheuk and Tsang Kwok Ping, *Anchoring and Loss Aversion in the Housing Market: Implications on Price Dynamics* (November 29, 2010). Available at: <http://dx.doi.org/10.2139/ssrn.1716826> (accessed: 20.01.2024).
22. Levin Y., Nediak M. & Bazhanov A. Quantity Premiums and Discounts in Dynamic Pricing. *Operations Research*, 2014, 62 (4), 846–863. Available at: <http://www.jstor.org/stable/24540665> (accessed: 05.02.2024).
23. Patrick Blöbaum, Peter Götz, Kailash Budhathoki, Atalanti A. Mastakouri, Dominik Janzing. *DoWhy-GCM: An extension of DoWhy for causal inference in graphical causal models*. 2022. Available at: <https://arxiv.org/abs/2206.06821> (accessed: 25.02.2024).

24. Sharma A., Kiciman E. Getting Started with Causal Inference: Available at:<https://causalinference.gitlab.io/> (accessed: 25.12.2023).
25. Xuan Zhang, Wai Ching Lam, Fan Liu, Mengdan Li, Lin Zhang, Weifeng Xiong, Xiaohan Zhou, Ran Tian, Chongya Dong, Chen Yao, David Moher, Zhaoxiang Bian, A Cross-sectional literature survey showed the reporting quality of multicenter randomized controlled trials should be improved. *Journal of Clinical Epidemiology*, 2021, vol. 137, pp. 250–261, ISSN 0895-4356, Available at:<https://doi.org/10.1016/j.jclinepi.2021.05.008> (accessed: 20.11.2023).

**Сведения об авторе:**

**Д.В. Михайлов** – аспирант, кафедры анализа систем и принятия решений, Уральский федеральный университет имени первого Президента России Б.Н. Ельцина, Екатеринбург, Российская Федерация.

**Information about the author:**

**D.V. Mikhailov** – Graduate Student, Department of Systems Analysis and Decision-making, Ural Federal University named after the First President of Russia B.N. Yeltsin, Yekaterinburg, Russian Federation.

<i>Статья поступила в редакцию</i>	<i>04.03.2024</i>	<i>The article was submitted</i>	<i>04.03.2024</i>
<i>Одобрена после рецензирования</i>	<i>18.04.2024</i>	<i>Approved after reviewing</i>	<i>18.04.2024</i>
<i>Принята к публикации</i>	<i>24.04.2024</i>	<i>Accepted for publication</i>	<i>24.04.2024</i>