

Мартынова Виталина Михайловна, магистрант,
Кубанский Государственный университет
Martynova Vitalina Mikhaylovna,
Master's student, Kuban State University

**КОНЦЕПТУАЛЬНЫЕ ОСНОВЫ ГИБРИДНОЙ МОДЕЛИ
ПОДДЕРЖКИ ИННОВАЦИОННЫХ РЕШЕНИЙ: ИНТЕГРАЦИЯ
ТЕОРИИ КАНО И МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ
ДЛЯ АНАЛИЗА ЦИФРОВЫХ СЛЕДОВ ПОЛЬЗОВАТЕЛЯ**
**HYBRID MODEL FOR SUPPORTING INNOVATIVE SOLUTIONS
BASED ON THE KANO THEORY AND MACHINE LEARNING
FOR INTERPRETING USERS' DIGITAL FOOTPRINTS**

Аннотация. Предлагается гибридная модель, объединяющая теорию Кано и машинное обучение для анализа цифровых следов и приоритизации характеристик продукта с учетом сегментов и изменения ожиданий; обсуждаются риски и способы валидации эффекта.

Abstract. The paper proposes a hybrid model combining Kano theory and ML to analyze digital footprints and prioritize product features across segments and shifting expectations; it also covers risks and ways to validate impact.

Ключевые слова: Теория Кано, инновационные решения, система поддержки принятия решений, машинное обучение, цифровые следы пользователя, NLP.

Keywords: Kano theory, innovative solutions, decision support system, machine learning, users digital footprints, NLP.

Цифровая экономика изменила не только скорость принятия решений, но и саму природу управленческого знания. Там, где раньше доминировали опыт, интуиция и линейные экстраполяции, сегодня действует иная логика: продукт, сервис и бренд непрерывно отражаются в данных – в кликах, паузах, возвратах, отказах, комментариях, маршрутах по интерфейсу, повторных визитах и незаметных микродействиях, которые пользователь не проговаривает, но которыми «пишет» поведенческий текст. На уровне деклараций бизнес давно перешёл к data-driven подходу, однако на уровне управленческих моделей сохраняется разрыв: богатство цифровых следов не превращается автоматически в богатство интерпретации. Данные собираются, визуализируются и агрегируются, но решения по инновациям по-прежнему часто принимаются в логике упрощённых показателей вовлечённости или в «позднем» режиме – когда рынок уже проголосовал рублём.

Центральная проблема состоит в том, что классические модели оценки ценности функций продукта и качества инноваций создавались для среды, где эмпирическая база добывается опросом, интервью или наблюдением малых выборок, а сами модели предполагают относительно редкие циклы обновления. В цифровой среде эмпирика становится непрерывной, многоканальной и, что особенно важно, неоднородной по своей природе: часть сигналов эксплицитна и выражена словами, часть имплицитна и выражена поведением, а часть носит контекстный характер (устройство, время, сценарий, канал привлечения). В результате менеджер сталкивается с парадоксом: данных много, но они плохо «пришиваются» к управленческим категориям, которые были придуманы для анкеты и фокус-группы. Цель этой статьи – предложить теоретический каркас гибридной системы поддержки инновационных решений, способной соединить теорию Кано как язык ценности и удовлетворённости с методами машинного обучения как инструментом масштабной интерпретации цифровых следов.



Важное уточнение: речь идёт не о замене управлеченческой теории алгоритмами и не о попытке «автоматизировать стратегию». Напротив, предметом анализа становится архитектура перевода теоретических категорий в операциональные признаки данных и обратно – в интерпретируемые инсайты, которые сохраняют смысл для менеджера. Такая система должна быть двуязычной: понимать язык данных и язык ценности.

Теоретический ландшафт, на фоне которого возникает эта задача, хорошо показывает траекторию эволюции управлеченческого мышления. Модели типа importance-performance (важность–удовлетворённость) исходят из предположения, что «важность» и «качество исполнения» линейно складываются в приоритет улучшений. Парадигма Jobs to be Done, напротив, смещает акцент с характеристик продукта на жизненный контекст и цель пользователя, предлагая мощный инструментарий для формулирования проблем, но не всегда давая строгую шкалу для количественной приоритизации функций и их динамики. На этом фоне модель Кано сохраняет редкое для гуманитарно-ориентированных концепций качество: она допускает алгоритмизацию без потери ключевого смысла.

Логика Кано построена на том, что удовлетворённость пользователя не является линейной функцией «количества фич». Одна и та же функция может давать разные эффекты: какие-то свойства воспринимаются как базовые и почти не повышают удовлетворённость, но отсутствие вызывает раздражение; какие-то свойства дают пропорциональный эффект «чем лучше, тем больше довольны»; а какие-то создают неожиданную радость – восхищают, хотя их отсутствия обычно не замечают. В классической формулировке это фиксируется через категории базовых, производительных и привлекательных (восхищающих) характеристик, а также через варианты «безразличных» и «обратных» свойств. Важнее даже не перечень категорий, а аксиоматика: биполярность реакции (удовлетворённость/неудовлетворённость), асимметрия ценности и принцип миграции категорий во времени. То, что вчера восхищало, завтра становится «нормой», а затем – базовым ожиданием. Динамика миграции превращает модель Кано из статического классификатора в теорию эволюции пользовательских ожиданий, и именно этот момент особенноозвучен цифровой среде с её быстрыми циклами.

Если сравнивать с Jobs to be Done, модель Кано уступает в глубине объяснения мотивации, но выигрывает в формализуемости. Категории Кано дискретны, а шкалы реакции биполярны, что облегчает постановку задачи для машинного обучения: либо как классификацию, либо как восстановление латентных факторов, соответствующих типам удовлетворённости. Если сравнивать с importance–performance, Кано лучше работает там, где нелинейности критичны: функция может иметь низкую декларируемую «важность», но при этом быть базовой (пока всё работает – её не называют важной, но сбой разрушает опыт). Именно такие нелинейности и провоцируют систематические ошибки в «простых» метриках продукта: рост NPS может не объяснить, почему падает удержание, а рост функциональности – почему усиливается раздражение.

Однако классическая модель Кано, будучи сильной как теория, испытывает методологические ограничения в цифровой реальности. Во-первых, запаздывание: традиционный сбор данных через опросы и интервью редко совпадает по времени с моментом возникновения эмоции и контекста использования. Во-вторых, субъективность и эффект рационализации: пользователь часто не способен корректно объяснить, что именно вызвало удовлетворённость, особенно если речь об имплицитных ожиданиях. В-третьих, трудоёмкость: построение анкеты Кано, сбор выборки, сегментация и интерпретация – дорогостоящий цикл, который плохо масштабируется на десятки функций и быстрые релизы. Наконец, сама анкета Кано хорошо работает с изолированными характеристиками, но хуже – с комплексными сценариями, где ценность возникает на стыке нескольких элементов и контекста.



Эти ограничения не отменяют модель, но подсказывают направление её расширения: смещение эмпирической базы от редких опросов к цифровым следам пользователя. Цифровые следы – это не просто «большие данные», а следы разных типов, каждый из которых по-своему связан с категорией удовлетворённости. Эксплицитные следы – отзывы, обсуждения в сообществах, обращения в поддержку, тексты в чатах, реакции в социальных сетях – по смыслу близки к тому, что анкета Кано пытается добыть напрямую: пользователь вербализует отношение к функции, часто указывая и объект, и оценку, и контекст. Имплицитные следы – кликовые траектории, глубина прокрутки, задержки, частота возвратов, последовательности действий, поведенческие паттерны отказа, изменения в скорости выполнения задачи – не содержат слов, но содержат структуру опыта. Они ставят более сложную задачу: тип удовлетворённости приходится выводить опосредованно, через признаки, которые являются не оценкой, а симптомом.

Именно здесь возникает идея гибридной аналитической системы: связать теоретические категории Кано с цифровыми следами так, чтобы каждая категория получила «операциональное представительство» в данных, а данные, в свою очередь, не превращались в набор бессмысленных корреляций. Сердцевина концепции – перевод между уровнями: от теории к меткам и кластерам, от сигналов к интерпретируемым выводам.

Категории Кано можно переосмыслить как целевые переменные в задачах обучения с учителем, где модель получает примеры функций и их принадлежность к типу (базовая, производительная, привлекательная и т. д.), либо как семантические кластеры в обучении без учителя, где алгоритм обнаруживает устойчивые группы паттернов и затем эти группы интерпретируются в терминах теории. Оба подхода не взаимоисключающие: в зрелой системе они дополняют друг друга. Обучение с учителем даёт управляемость и метрики точности, но требует разметки; обучение без учителя помогает обнаружить неожиданные структуры, но требует строгой процедуры интерпретации и проверки.

Концептуальный пайплайн такой системы в наиболее общем виде начинается со сбора и сегментации цифровых следов. Важно подчеркнуть, что сегментация здесь – не декоративный этап, а элемент теории: ожидания и «тип удовлетворённости» зависят от контекста. Одна и та же функция может быть базовой для опытного пользователя и привлекательной для новичка, производительной для одного сегмента и безразличной для другого. Поэтому сегментация должна опираться не только на социально-демографические признаки, но и на поведенческую зрелость, частоту использования сценариев, источник трафика, устройство, региональный контекст, тариф/план и другие переменные, определяющие «норму ожиданий».

Далее следует интеллектуальная обработка, и здесь проявляется принципиальная двукаanalность. Эксплицитные данные разумно анализировать методами NLP: извлекать упоминания функций, объектов интерфейса и сценариев, проводить тематическое моделирование, а также связывать оценочные выражения с конкретными аспектами продукта. Одной «тональности текста» обычно недостаточно: пользователь может писать негативно о ситуации, но позитивно о функции, или наоборот. Поэтому ключевую роль играет аспектно-ориентированный анализ тональности, который позволяет связать эмоцию не с текстом в целом, а с конкретной характеристикой. Это критично для логики Кано, поскольку категория относится к функции, а не к общему настроению.

Имплицитные данные требуют других инструментов: анализ временных рядов, последовательностей действий, моделирование воронок, выделение типовых траекторий, а также кластеризация пользователей и сценариев по поведенческим паттернам. Здесь полезны методы, которые умеют «понимать» порядок и контекст событий: от классических марковских моделей и скрытых марковских процессов до современных подходов на основе эмбеддингов



последовательностей. Смысл не в модности архитектуры, а в том, чтобы восстановить структуру опыта: где возникает трение, где пользователь ускоряется, где возвращается, где бросает задачу, какие микроошибки повторяются.

Третий шаг – семантическое сопоставление выявленных паттернов с категориями Кано. Это самый теоретически чувствительный участок системы, потому что здесь легко скатиться в грубую подгонку: «если жалуются – значит базовая», «если хвалят – значит привлекательная». На практике сопоставление требует многомерного критерия. Базовые характеристики часто проявляются через всплески обращений при сбоях, рост отказов после регрессий, раздражение в текстах поддержки при исчезновении «само собой разумеющегося». Производительные – через устойчивую связь качества исполнения с измеримыми показателями удовлетворённости и успеха сценария: чем быстрее, точнее, удобнее, тем больше завершений, повторов, рекомендаций, конверсия или удержание. Привлекательные – через асимметричный эффект: при наличии возникает диспропорциональный рост позитивных реакций или вовлечения в определённые сценарии, при отсутствии же не фиксируется симметричного падения, пока пользователь не узнает о возможности.

Чтобы избежать натяжек, система должна удерживать в явном виде критерии принятия решения о категории, а не только выдавать метку. Это означает, что вывод должен сопровождаться «обоснованием» в терминах наблюдаемых сигналов: какие именно паттерны поведения и какие именно фрагменты текста, с какой устойчивостью и на каких сегментах, привели к классификации. Тем самым теория Кано не исчезает, а превращается в интерпретационный слой, дисциплинирующий статистику.

Завершающий шаг – формирование динамической карты приоритетов и интерпретируемых инсайтов для менеджера. В классической практике карта приоритетов строится как список функций с их типом и рекомендациями. В гибридной системе карта должна быть живой: показывать миграцию категорий во времени, различия по сегментам, чувствительность к изменениям продукта, а также неопределённость вывода. Иначе говоря, менеджеру нужна не просто «категория», а прогноз последствий действий: что будет, если улучшить базовую функцию; какой прирост даст усиление производительной; как проверить, является ли привлекательная функция действительно «вау-фактором» или эффектом новизны; не превращается ли она уже в ожидание.

Отдельного разговора заслуживают методологические нюансы, без которых система будет теоретически красивой, но практически бесполезной. Во-первых, проблема редких категорий. «Восхищающие» функции в реальных данных встречаются нечасто: их либо мало, либо они быстро перестают быть редкими, либо их эффект проявляется в узких сегментах. Это создаёт дефицит размеченных примеров и дисбаланс классов. Поэтому для таких случаев концептуально оправдано использование few-shot и zero-shot подходов, где модель опирается на перенос знаний, семантические представления и качественные описания функций. Здесь важно не впасть в иллюзию универсальности: перенос возможен, но его нужно калибровать и проверять на домене конкретного продукта, иначе «вау-эффект» будет подменён стилистическими маркерами текста.

Во-вторых, связка тональности и аспектов должна быть не декоративной, а структурной. Для теории Кано критично не просто знать, что пользователь недоволен, а понимать, чем именно: скоростью, надёжностью, прозрачностью, стоимостью, эстетикой, предсказуемостью результата. Одна и та же эмоция может относиться к разным аспектам и вести к разным управлеченческим решениям. Негатив к базовой функции – сигнал риска, негатив к привлекательной – часто сигнал неверной коммуникации или несоответствия ожиданий, а не «провала основы». Поэтому аспектный анализ здесь не украшение, а механизм привязки эмоции к объекту.



В-третьих, необходимо учитывать миграцию категорий. Если система обучается на исторических данных и не обновляет представление, она будет «консервировать» прошлые ожидания. Теоретически это означает, что модель должна быть чувствительна к дрейфу концепта: распределение реакций меняется, и та же функция может переехать из привлекательных в производительные, а затем в базовые. Практически это ведёт к требованиям мониторинга качества, периодической переоценки, а иногда и к явному вводу времени как переменной, влияющей на классификацию.

Сильная сторона предлагаемой гибридной архитектуры – возможность верификации, но и здесь нельзя ограничиться привычной для data science проверкой метрик. Валидация должна идти по двум траекториям: точность классификации и управляемая релевантность инсайтов. Первая проверяется стандартно: разметка экспертами, межэкспертное согласие, оценка качества модели по метрикам вроде F_1 , precision/recall, калибровка вероятностей, устойчивость к смене сегментов. Вторая – сложнее: даже идеально классифицированная категория может оказаться бесполезной, если она не приводит к решениям, улучшающим продукт. Поэтому необходимы прикладные проверки: A/B-эксперименты, измерение эффекта от приоритизации, сравнение с контрольной группой решений, принятых без системы, а также ретроспективная проверка предсказаний на последующих релизах. В определённом смысле конечная метрика – это не точность «угадать категорию», а способность предсказывать, какие инвестиции в функции приведут к росту удовлетворённости, удержания и ценности для пользователя.

Но чем мощнее система, тем важнее критика её ограничений. Первый риск – «прокрустово ложе» теории, когда сложный спектр эмоций, ожиданий и контекстов насильно втискивается в несколько категорий. Кано полезна как инструмент, но не исчерпывает психологию пользователя. В гибридной системе этот риск усиливается: алгоритм любит чёткие метки и уверенные границы, а реальность любит смешанные состояния. Отсюда следует методологический вывод: система должна уметь выражать неопределенность, допускать смешанные принадлежности и хранить признаки, позволяющие спорить с классификацией. Слишком «чистые» результаты обычно подозрительны.

Второй риск – технологический, связанный с bias. Цифровые следы отражают не «пользователя вообще», а того, кто оставляет следы в данном канале и в данной конфигурации продукта. Активные пользователи оставляют больше данных и тем самым получают больше «голоса»; новые пользователи могут быть недопредставлены; часть сегментов выражает себя преимущественно через поддержку, часть – через соцсети, часть – молчит и уходит. Алгоритм, обученный на такой картине, может закрепить несправедливость: усиливать функции для уже «слышимых» групп и игнорировать тихие, но важные сегменты. Поэтому в гибридной модели необходимы процедуры балансировки, проверки справедливости по сегментам, а также осознанная политика по тому, какие данные считаются репрезентативными.

Третий риск – управляемый и, возможно, самый коварный: синдром «чёрного ящика». Когда решения становятся продуктом сложной модели, менеджер может потерять стратегическое видение и превратиться в оператора рекомендаций. Теоретически это означает деградацию ответственности: если решение принято «по модели», то виноватой оказывается модель, а не управленец. Практически это ведёт к тому, что организация перестаёт учиться – потому что обучение заменяется делегированием. Противоядие здесь не в отказе от алгоритмов, а в требовании интерпретируемости и встраивании системы в управляемый цикл так, чтобы она была оппонентом, а не авторитетом. Менеджер должен получать не только ответ, но и основания, альтернативы и сценарные последствия.

Этический контекст в подобной системе не является приложением «для галочки», потому что цифровые следы – это всегда следы человека, пусть и обезличенные.



Ответственность начинается с принципов минимизации данных и целевого использования: собирать не «на всякий случай», а под конкретные управлеченческие гипотезы; хранить ограниченно; обеспечивать безопасность и соблюдение требований регулирования. Но этика не исчерпывается приватностью. Вторая проблема – манипуляция восприятием: если мы научились точно понимать, какие функции вызывают восхищение, появляется соблазн проектировать не ценность, а зависимость, подменять долгосрочное благо краткосрочной стимуляцией. Третья – прозрачность. В системах поддержки инноваций прозрачность (в широком смысле explainable AI) становится не просто удобством, а этическим императивом: человек должен иметь возможность понять, почему система рекомендует то или иное, на каких данных основан вывод, где границы применимости и какие альтернативные объяснения существуют.

В заключение стоит подчеркнуть: гибридная модель, объединяющая теорию Кано и машинное обучение, не является очередной «надстройкой над аналитикой». Она претендует на роль теоретического моста между классическим менеджментом и data science, где теория задаёт смысловые координаты, а алгоритмы обеспечивают масштаб и чувствительность к динамике. Такой мост особенно важен в эпоху, когда инновации часто рождаются не в виде единичного прорыва, а в виде серии микроулучшений и переосмыслений пользовательского опыта, и когда цена ошибки в приоритизации возрастает из-за скорости рынка.

Перспективы развития этой концепции лежат в нескольких направлениях. Во-первых, культурно-зависимые версии модели: ожидания «базового» и «восхищающего» различаются между рынками, а цифровые следы отражают нормы поведения, которые нельзя переносить механически. Во-вторых, интеграция с теориями открытых инноваций и экосистемного развития продукта, где ценность создаётся не только внутри интерфейса, но и в сети партнёров, API, интеграций, сообществ и контента. В-третьих, формирование стандартов интерпретируемости для управлеченческих систем: не общих деклараций, а конкретных требований к обоснованию рекомендаций, к мониторингу дрейфа, к проверкам справедливости, к процедурам валидации управлеченческого эффекта. В этом смысле предложенный каркас может служить фундаментом для прикладного алгоритма диссертационного исследования: он задаёт строгую рамку того, как теория становится данными, а данные – решением, не разрушая смысл по пути.

Список литературы:

1. Кано, Н. Аттрактивное качество и обязательное качество / Н. Кано, Н. Сераку, Ф. Такахаши, С. Іудзи // Журнал Японского общества контроля качества. – 1984.
2. Бергер, К. Практическое руководство по модели Кано: Как понять, что действительно хотят ваши клиенты / К. Бергер. – М.: Альпина Паблишер, 2021.
3. Кристенсен, К.М. Дilemma инноватора: Как из-за новых технологий погибают сильные компании / К.М. Кристенсен. – М.: Альпина Паблишер, 2021.
4. Вурм, Б. Исследование цифровых следовых данных в информационных системах: основы, методы и приложения / Б. Вурм, Я. Мендлинг. – Шам: Springer Nature Switzerland, 2026.
5. Симонова, Б. Разнообразные аспекты данных цифровых следов / Б. Симонова, Р.Д. Галлиерс // Кембриджское руководство по качественному цифровому исследованию. – Кембридж: Cambridge University Press, 2023.
6. Гудфеллоу, Я. Глубокое обучение / Я. Гудфеллоу, И. Бенджио, А. Курвилль. – М.: ДМК Пресс, 2022.
7. Молина, М. Объяснимый искусственный интеллект (XAI): Концепции, таксономии, возможности и тенденции в ответственных ИИ / М. Молина, А.Х. Мартин // Информационные Fusion. – 2025.

