

Специальность ВАК: 5.2.4

УДК 005.8:336.71

EDN ZENFSS

## **ЭКОНОМИЧЕСКАЯ МОДЕЛЬ ПРОГНОЗИРОВАНИЯ ПОЖИЗНЕННОЙ ЦЕННОСТИ КЛИЕНТА ПРИ УЛУЧШЕНИИ КЛИЕНТСКИХ ПУТЕЙ БАНКА С ИСПОЛЬЗОВАНИЕМ ТЕХНОЛОГИИ PROCESS MINING**

**Дмитрий Александрович ЧЕРСКИХ<sup>1</sup>, аспирант**

<sup>1</sup>Автономная некоммерческая организация высшего образования «Международный банковский институт имени Анатолия Собчака» (Санкт-Петербург, Россия). Адрес: 191023, Невский пр., 60. Санкт-Петербург, Россия, e-mail: cherskih.da@phystech.edu

**Семен Юрьевич БОГАТЫРЕВ<sup>2,3</sup>, д.э.н., доцент**

<sup>2</sup>Профессор кафедры экономики, управления и предпринимательства, Автономная некоммерческая организация высшего образования «Международный банковский институт имени Анатолия Собчака» (Санкт-Петербург, Россия). Адрес: 191023, Невский пр., 60, Санкт-Петербург, Россия, e-mail: sbogatyrev@ibispb.ru

<sup>3</sup>Профессор, Финансовый университет при Правительстве РФ (Москва, Россия). Адрес: 125167, Москва, Ленинградский пр-т., 49, Москва, Россия, e-mail: sbogatyrev@ibispb.ru

### **Аннотация**

**Целью** статьи является разработка подхода к управлению пожизненной ценностью клиента (CLTV) в банке за счет анализа клиентских путей. В качестве **метода исследования** применена технология Process Mining, позволяющая выявлять узкие места в процессе взаимодействия клиента с банком и оценивать их влияние на финансовые показатели. Разработана экономическая модель прогнозирования CLTV, включающая три блока: сокращение издержек, рост доходов и снижение вероятности оттока клиентов (churn). **Результаты** эксперимента на примере клиентского пути оформления потребительского кредита продемонстрировали значимость предложенного подхода, подтвердив его эффективность в повышении точности оценки CLTV. Основной **вывод** исследования заключается в том, что применение технологии Process Mining к клиентским путям позволяет не только повысить качество клиентского опыта, но и обосновать прямое влияние предложенных по результатам анализа изменений на финансовые показатели, а именно сокращение стоимости обеспечения процессов.

### **Ключевые слова**

CLTV, отток клиентов, Process Mining, модель прогнозирования, клиентский путь, кредитование

**Для цитирования:** Черских Д.А., Богатырев С.Ю. Экономическая модель прогнозирования пожизненной ценности клиента при улучшении клиентских путей банка с использованием технологии Process Mining // Ученые записки Международного банковского института. 2026. № 1 (55). С. 244-263. EDN: ZENFSS.

**Финансирование:** Настоящее исследование не получило внешнего финансирования.

Code of scientific specialty: 5.2.4

UDC 005.8:336.71

EDN ZENFSS

## **THE CUSTOMER LIFETIME VALUE FORECASTING MODEL IN THE PROCESS OF OPTIMIZING THE BANK'S CUSTOMER PATHS USING PROCESS MINING TECHNOLOGY**

**Dmitry Aleksandrovich CHERSKIKH<sup>1</sup>, Postgraduate student**

<sup>1</sup>Autonomous non-profit organization of higher education «International Banking Institute named after Anatoly Sobchak» (Saint Petersburg, Russia). Address: 191023, Nevsky Prospekt, 60, Saint Petersburg, Russia, e-mail: cherskih.da@phystech.edu

**Semen Yurievich BOGATYREV<sup>2,3</sup>, Doctor of Economics, Associate Professor**

<sup>2</sup>Professor, Department of Economics, Management, and Entrepreneurship, Autonomous non-profit organization of higher education «International Banking Institute named after Anatoly Sobchak» (Saint Petersburg, Russia). Address: 191023, Nevsky prospect, 60, Saint Petersburg, Russia, e-mail: sbogatyrev@ibispb.ru

<sup>3</sup>Professor, Financial University under the Government of the Russian Federation (Moscow, Russia). Address: 125167, Moscow, Leningradsky Prospekt, 49, Moscow, Russia, e-mail: sbogatyrev@ibispb.ru

### **Abstract**

The purpose of this article is to develop an approach to managing Customer Lifetime Value (CLTV) in banking through the analysis of customer journeys. The research method is based on the application of Process Mining technology, which enables the identification of bottlenecks in customer–bank interactions and the assessment of their impact on financial performance. An economic model for forecasting CLTV has been developed, comprising three key components: cost reduction, revenue growth, and a decrease in customer churn probability. The results of an experiment using the customer journey of consumer loan origination demonstrated the significance of the proposed approach, confirming its effectiveness in improving the accuracy of CLTV estimation. The main conclusion of the study is that applying Process Mining technology to customer journeys not

only enhances the quality of customer experience but also substantiates the direct impact of improvements on financial outcomes, specifically by reducing process maintenance costs.

### **Keywords**

CLTV, churn rate, Process Mining, forecasting model, customer journey, lending

**For citation:** Cherskikh D.A., Bogatyrev S.Yu. The customer lifetime value forecasting model in the process of optimizing the bank's customer paths using Process Mining technology // Uchenye zapiski Mezhdunarodnogo bankovskogo instituta [Proceedings of the International Banking Institute]. 2026. 1 (55). pp. 244-263 (in Russ.). EDN: ZENFSS.

**Funding:** This research received no external funding.

### **Введение**

Customer Lifetime Value (CLTV) — это агрегированный показатель потенциальной прибыли, которую клиент может принести банку, и, отражающий его экономическую значимость. Он позволяет оценить не только текущее финансовое взаимодействие, но и спрогнозировать долгосрочные отношения, включая повторные сделки, перекрестные продажи и влияние лояльности. В условиях высокой конкуренции, цифровизации и роста стоимости привлечения клиентов управление CLTV становится приоритетной задачей для финансовых организаций [1].

Согласно отраслевым исследованиям, банки, системно управляющие CLTV [2] демонстрируют существенно более высокую отдачу от вложений в цифровые каналы по сравнению с теми, кто ориентируется только на показатели текущей выручки. Тем не менее, точное измерение и прогнозирование CLTV остаются сложной задачей.

Существующие методы, основанные на статистическом анализе или машинном обучении [3], часто не учитывают поведенческий контекст клиента и не дают ответов на вопрос «почему» произошел отток или падение ценности. В данной работе предлагается использовать Process Mining [4, 5] — технологию извлечения и анализа процессов из логов событий информационных систем — как инструмент, способный связать пользовательский опыт, этапы клиентского пути и финансовую результативность [6].

Научная новизна данного исследования заключается в применении Process Mining не только к внутренним операциям, но и к анализу клиентских путей с

целью расчета и управления CLTV. Это позволяет создать мост между цифровым поведением клиента [7], его пользовательским опытом и экономическим вкладом в бизнес. В условиях высокой конкуренции, цифровизации и роста стоимости привлечения клиентов управление CLTV становится приоритетной задачей.

При этом CLTV сложно измерить и прогнозировать. Современные методы, основанные на машинном обучении, учитывают поведенческие данные клиентов, однако часто оторваны от реальных процессов, вызывающих снижение лояльности. В данной работе предлагается использовать Process Mining — технологию анализа процессов на основе логов событий — для выявления узких мест в клиентских путях, влияющих на отток [8] и CLTV.

Научная новизна работы заключается в переносе применения Process Mining с внутренней процессной аналитики на клиентские пути, что позволяет связать пользовательский опыт, эффективность процессов и ключевые финансовые метрики [9].

## **Основная часть**

### **Обзор литературы**

Process Mining — это методология, позволяющая выявлять, анализировать и улучшать бизнес-процессы на основе данных из логов событий. В банковской сфере данная технология уже зарекомендовала себя в задачах комплаенс-контроля, операционной эффективности и автоматизации документооборота.

Однако до настоящего времени Process Mining почти не применялся в задачах, связанных с оценкой клиентского опыта и финансовыми метриками, такими как CLTV, Customer Equity и Retention Value.

В отличие от агрегированных моделей машинного обучения [10], Process Mining предоставляет объяснимую модель, показывающую последовательность действий клиента, в том числе отклонения от целевого сценария [11, 12]. Это не дает автоматический ответ на вопрос «почему клиент ушел», но предоставляет:

- возможность визуализировать типовые клиентские пути [13], которые приводят к оттоку;
- сравнить процессы успешных и ушедших клиентов;
- выделить проблемные участки — например, задержки, возвраты заявок, повторные шаги;

- построить метрики процессов (длительность, частота переходов, вариативность) и связать их с итоговыми KPI.

Приведем таблицу с преимуществами и недостатками различных инструментов/технологий [14] (см. таблицу 1).

*Таблица 1 — Преимущества и недостатки основных инструментов продвинутой аналитики*

Подход	Преимущества	Недостатки / ограничения
ML / AI	Прогнозирует CLTV и отток клиентов на больших выборках	Не объясняет, какие именно действия вызвали отток клиентов
SQL / BI	Делает сводки, строит агрегированные отчеты	Не видна логика действий клиента по шагам
Process Mining	Восстанавливает путь клиента и отклонения от нормы	Не определяет причинно-следственные связи автоматически

Таким образом, Process Mining — это инструмент аналитика, а не «черный ящик». Он дает основу для гипотез и управленческих решений, объясняя, как клиент «шел» по процессу — а не просто, что он в итоге сделал.

Этот подход особенно ценен для оценки CLTV, поскольку позволит связать не только поведение, но и структуру и качество процессов, влияющих на доходность клиента.

#### Примеры задач Process Mining в банках

- Выявление этапов, приводящих к отказу от кредита или карты;
- Сопоставление времени ожидания с уровнем оттока;
- Построение процессных моделей, отражающих пользовательский опыт (UX).

Таким образом, интеграция Process Mining и финансовых моделей создает уникальную возможность для точного, воспроизводимого и бизнес-ориентированного управления CLTV [13, 14]. Process Mining традиционно используется для выявления неэффективности операционных процессов. Однако его потенциал значительно шире — в особенности, если соединить события из логов с UX-метриками и финансовыми KPI.

Следующей вехой развития Process Mining становится его применение для анализа клиентских путей (Customer Journey) [15]. В этом подходе каждое действие клиента (веб-запрос, звонок, заявка, отзыв) — это событие, а цепочка таких событий — цифровая модель поведения, влияющая на CLTV.

#### Постановка задачи

В рамках данного исследования необходимо было решить следующие взаимосвязанные задачи:

**1. Разработка математической модели изменения CLTV.** Построить эконометрическую формулу, описывающую зависимость величины CLTV от изменений ключевых процессных метрик: времени обработки, издержек, частоты операций и вероятности оттока (churn). Модель должна позволять количественно оценивать эффект от оптимизации клиентского пути.

**2. Методика сбора и предобработки event-логов.** Определить алгоритм моделирования и нормализации журналов событий (event logs), имитирующих работу ИТ-систем банка (CRM, скоринг-модуль, мобильное приложение), включая построение структуры логов, обработку временных меток и идентификацию повторных действий.

**3. Process Mining-анализ клиентских путей.** Применить технологии Process Mining для восстановления траекторий клиента, выявления заикленности его действий, нестабильных маршрутов, возвратов заявок и системных сбоев, а также количественно оценить их влияние на эффективность процесса и возможный churn.

**4. Оценка изменения CLTV на основе логов.** На основе логов «до» и «после» провести сравнительный анализ ключевых метрик (длительность этапов, доля возвратов, отток клиентов) и рассчитать прирост CLTV с использованием ранее разработанной модели. В качестве данных использовались синтетические логи, имитирующие поведение 50 000 клиентов в каждом сценарии.

Решение этих задач позволит не только обосновать новую методику расчета изменений CLTV через призму Process Mining, но и получить практические рекомендации для повышения эффективности клиентских процессов в банке.

### **Математическая модель расчета изменения CLTV**

В классическом виде CLTV рассчитывается как дисконтированная сумма ожидаемой прибыли от клиента:

$$CLTV = \sum_{t=1}^T \frac{R_t - C_t}{(1 + d)^t}, \quad (1)$$

где:

–  $R_t$  — доход от клиента в период  $t$ ,

- $C_t$  — затраты на его обслуживание,
- $d$  — коэффициент дисконтирования,
- $T$  — горизонт расчета.

Разработка модели расчета изменения CLTV основана на предположении, что любые изменения в процессе взаимодействия клиента с банком (улучшения UX, сокращение времени, автоматизация) влекут за собой три вида последствий:

1. Изменение прямых затрат банка на обслуживание клиента;
2. Изменение доходов, генерируемых клиентом (частота и объем транзакций);
3. Изменение вероятности оттока клиента.

Таким образом, CLTV рассматривается как результат баланса между этими тремя категориями. Ниже представлены блоки модели и формулы, описывающие их влияние на итоговую метрику.

**Изменение затрат.** Оптимизация клиентского пути — например, за счет автоматизации регистрации, внедрения API или сокращения бумажного документооборота — позволяет снизить издержки на обслуживание одного клиента. Это выражается как разность трудозатрат до и после улучшений, умноженная на стоимость ресурса (время или ФОТ).

Формула:

$$\Delta C_t = C_p \cdot (D_{old} - D_{new}), \quad (2)$$

где:

- $\Delta C_t$  — экономия на этапе  $t$ ,
- $C_p$  — стоимость одной минуты работы (или одного сотрудника в час),
- $D_{old}$ ,  $D_{new}$  — длительность выполнения этапа до и после изменений соответственно.

Продемонстрируем применимость формулы на конкретном примере:

Допустим, до улучшений обработка заявки занимала 60 минут при ставке

$C_p = 1000$  руб./час. После автоматизации — 12 минут.

$\Delta C = 1000 \times (60 - 12) / 60 = 800$  руб. на клиента

Для 1000 клиентов это дает прямую экономию в размере 800 000 руб.

В следующих подразделах модель будет дополнена блоками расчета доходов и рисков оттока.

**Изменение дохода.** После улучшения клиентского пути и интерфейсов пользователи, как правило, чаще взаимодействуют с продуктом, совершают больше повторных операций и дольше остаются клиентами банка. Эти изменения можно оценить через рост средней частоты операций или среднего чека (ARPU).

Формула для оценки дополнительного дохода:

$$\Delta R_t = (F_{\text{new}} - F_{\text{old}}) \cdot \text{ARPU}, \quad (3)$$

где:

- $\Delta R_t$  — прирост дохода на этапе  $t$ ,
- $F_{\text{new}}, F_{\text{old}}$  — частота взаимодействий с банком до и после улучшений,
- ARPU — средний доход с одного взаимодействия (например, сессии, транзакции, заявки).

Для расчета величины изменения дохода также приведем пример:

Если после упрощения оформления услуги клиент стал пользоваться продуктом 1,2 раза в месяц вместо 1,0 раза, при среднем доходе с одного взаимодействия (ARPU) равном 500 руб., то:

$$\Delta R_t = (1,2 - 1,0) \times 500 = 100 \text{ руб.}$$

На горизонте 12 месяцев дополнительный доход составит 1200 руб. на одного клиента. Принимая во внимание кумулятивный эффект, рост дохода может удвоиться в случае перекрестных продаж (например, после выдачи кредита клиент оформляет карту или страховку).

Таким образом, даже незначительное увеличение частоты операций может существенно повлиять на CLTV при масштабировании на клиентскую базу. Улучшение пользовательского опыта (User experience) увеличивает частоту операций, что ведет к росту дохода от клиента.

### **Изменение вероятности оттока**

Отток клиентов — еще один важный фактор. Даже если доход и затраты остаются стабильными, потеря клиента приводит к обнулению его будущей ценности. Улучшения в процессе взаимодействия (ускорение, прозрачность, удобство) значительно влияют на снижение вероятности оттока клиентов поскольку увеличивается срок их взаимодействия с банком. Соответственно, изменения, направленные на уменьшение данного показателя, можно считать инвестициями в CLTV.

Снижение вероятности оттока можно рассчитать, как:

$$\Delta P_{\text{churn}} = P_{\text{churn}}^{\text{old}} - P_{\text{churn}}^{\text{new}}, \quad (4)$$

где:

- $\Delta P_{\text{churn}}$  — разность вероятностей оттока до и после изменений,
- $P_{\text{churn}}^{\text{old}}$  — доля клиентов, прекративших взаимодействие до улучшений,
- $P_{\text{churn}}^{\text{new}}$  — доля клиентов, ушедших после улучшений.

Соответственно влияние этого изменения на CLTV можно рассчитать по формуле:

$$\Delta CLTV_{\text{churn}} = CLTV_{\text{base}} \cdot \Delta P_{\text{churn}}, \quad (5)$$

где:

- $CLTV_{\text{base}}$  — средняя ожидаемая ценность клиента до улучшений.

Расчет снижения вероятности оттока можно произвести следующим образом. Например, если до изменений отток составлял 21%, а после внедрения автоматического одобрения и цифровых уведомлений — 15%, и средний CLTV равен 9800 руб., тогда:

$$\Delta P_{\text{churn}} = 0,21 - 0,15 = 0,06 \quad (6)$$

$\Delta CLTV_{\text{churn}} = 9800 \times 0,06 = 588$  руб., - дополнительной ценности на одного клиента.

Таким образом, снижение оттока клиентов даже на несколько процентных пунктов оказывает существенное влияние на финансовый результат. При масштабировании на тысячи клиентов экономия может достигать миллионов рублей. Проще, быстрее и прозрачнее — значит, выше удержание.

### **Итоговая модель**

Обобщая три блока влияния (издержки, доходы, удержание), мы приходим к следующей формуле для прогнозирования изменения CLTV:

$$\Delta CLTV = \sum_{t=1}^T \frac{\Delta R_t - \Delta C_t}{(1+d)^t} + \Delta CLTV_{\text{churn}} \quad (7)$$

Эта модель позволяет одновременно учесть экономию на издержках, дополнительный доход от повышения активности клиентов и эффект удержания, что делает ее универсальным инструментом для количественной оценки финансового результата от улучшения клиентских процессов.

Для проверки работоспособности этой модели и оценки ее параметров мы используем технологию Process Mining. С ее помощью можно:

1. Вычислить фактические  $\Delta R_t$ ,  $\Delta C_t$  и  $\Delta P_{\text{churn}}$  по логам событий: времена этапов, частоты возвратов и отказов, маршрут клиентских кейсов.
2. Сравнить процессы «до» и «после» улучшений, зафиксировать изменения в распределениях метрик.
3. Вычислить все составляющие формулы непосредственно из реестра событий и подставить их в модель, не прибегая к экспертным оценкам.

Поскольку реальные банковские логи подлежат конфиденциальности, в этой статье мы демонстрируем методику на полностью смоделированных, но близких к реальному процессу данных. В следующем разделе подробно опишем:

- исследуемый клиентский процесс (оформление кредита),
- правила генерации и предобработки event logs,
- покажем результаты Process Mining-анализа,
- применим формулу для расчета изменения CLTV.

### **Апробация модели расчета CLTV на примере клиентского пути оформления кредита**

Далее детально охарактеризуем:

1. клиентский путь оформления потребительского кредита, на котором проведем верификацию эконометрической модели;
2. методику моделирования и предобработки event logs для Process Mining-анализа.

Рассмотрим подробнее этапы процесса оформления потребительского кредита. К ним можно отнести шесть следующих операций (см. Таблица 2).

*Таблица 2 — Ключевые этапы процесса оформления потребительского кредита*

№	Этап процесса	Описание
1	Подача заявки	Клиент инициирует заявку через мобильное приложение или сайт.
2	Первичная валидация	Система автоматически проверяет заполненные поля (наличие обязательных документов, формат).
3	Проверка кредитной истории (БКИ/API)	Выполняется запрос в бюро кредитных историй через API.
4	Скоринг и расчет условий	Модель машинного обучения оценивает риск; определяется процентная ставка и максимальная сумма.
5	Электронное подписание договора (ЭЦП)	Клиент подписывает договор удаленно с помощью электронной подписи.

6	Выдача средств	Одобренная сумма автоматически перечисляется на карту клиента; статус доступен в кабинете.
---	----------------	--

Каждый из этих этапов генерирует события (events) в ИТ-системах банка. Между этапами возможны повторные прохождения (например, возврат на доработку заявки) и задержки.

Перейдем к генерации и предобработке event logs клиентского пути по оформлению кредита. Для того, чтобы продемонстрировать работу Process Mining без доступа к реальным банковским данным, мы подготовили статистически достоверный синтетический лог со следующими параметрами и характеристиками:

1.Общее число кейсов - 100 000 (50 000 в «до»-процессе, 50 000 в «после»-процессе).

2.Временные характеристики для каждого этапа представляют собой распределения продолжительности (например, нормальное или лог-нормальное) с параметрами, близкими к реальным.

3.На этапах валидации и скоринга заданы вероятности возврата заявки на доработку (15% «до» и 5% «после»).

4.В логах фиксируются случаи отказа клиента (churn-метки) с вероятностями 21% в «до» и 15% в «после».

После создания синтетических логов мы провели небольшую обработку полученных данных, а именно:

1.Нормализацию времени: все временные метки (timestamps) перевели в единую зону и формат ISO-8601.

2.Произвели агрегацию действий: одинаковые по смыслу события (например, «API-запрос БКИ» и «БКИ проверено») объединяются в одно (столбец activity, см. Таблица 3).

3.Добавили роли и каналы: каждому событию присвоили атрибуты Role (Роль: система, оператор, клиент) и Channel (Канал: app, web, branch).

После проведения процедуры обработки данных получили следующую структуру готового лога (см. Таблица 3)

Таблица 3 — Пример event logs при оформлении кредита клиентами банка

Case ID	Activity	Timestamp	Role	Channel	Status
OLD_001	Заявка подана	2024-03-01T10:03:00	Client	app	success
OLD_001	Валидация полей	2024-03-01T10:05:12	System	app	success
OLD_001	Проверка БКИ	2024-03-01T10:07:30	System	API	success
...	...	...	...	...	...
NEW_001	Заявка подана	2024-04-10T14:01:15	Client	web	success
NEW_001	Валидация полей	2024-04-10T14:01:45	System	web	success
NEW_001	Проверка БКИ	2024-04-10T14:01:45	System	API	success
...	...	...	...	...	...

Такой лог готов к загрузке в любой Process Mining-инструмент (Disco, Celonis, ProM) для дальнейшего анализа узких мест, расчета метрик длительности, частоты возвратов и построения процессной модели.

### Результаты и обсуждения

На основе результатов Process Mining-анализа были выявлены следующие ключевые проблемы в клиентском пути оформления кредита, снижающие его эффективность:

1. Заикленность на этапе верификации документов. Из-за неоднозначного набора полей в заявке и наличия нескольких точек входа (мобильное приложение, интернет-банк, офис) часть клиентов возвращалась к заполнению одних и тех же данных по 2–3 раза.

2. Системные сбои при формировании скорингового запроса. В 12% случаев API-коннектор к БКИ обрабатывал с ошибкой и требовал повторной ручной перезаписи заявки.

3. Избыточное количество альтернативных путей. Анализ показал более 15 уникальных маршрутов прохождения заявки, что усложняло сопровождение и приводило к рассогласованиям между каналами.

Для устранения этих проблем были приняты следующие меры:

1. Унификация точки входа. Вместо трех интерфейсов с разными формами подачи заявки (в мобильном приложении, интернет-банке и на рабочем экране

сотрудника в офисе) введен единый экран «кредитный конструктор» с одинаковым набором полей и требуемой информации.

2. Оптимизация формы заявки. Уменьшен перечень обязательных полей на 30% за счет удаления дублирующих и несущественных вопросов (например, сведения об источнике средств, которые уже есть в профиле клиента).

3. Внедрение логики пред-валидации. Добавлен клиент-side скрипт, проверяющий корректность введенных данных (ИНН, номер телефона, e-mail) до отправки на сервер, что устранило 85% повторных возвратов заявок.

4. Реорганизация обработки ошибок программного интерфейса приложений (API). Добавлен механизм автоматического повторного запроса к БКИ при первой неудаче, а при второй — переключение на резервный канал проверки, что снизило ручные вмешательства на этапе скоринга с 12% до 1%.

5. Сужение числа маршрутов. Объединены смежные шаги «проверка документов» и «верификация личности» в один этап с четкими соглашениями об уровне сервиса (SLA) — это позволило сократить количество уникальных путей с 15 до 4.

После этих доработок процесс приобрел линейную, предсказуемую структуру из 6 шагов, без повторных возвратов и с минимальным количеством исключений.

Благодаря доработке процесса были получены следующие результаты:

– Устранена заикленность. Доля кейсов с возвратом на предыдущий шаг снизилась с 24% до 2%.

– Снизилось количество ошибок на этапе скоринга. Ошибки API упали с 12% до 1%, время ожидания ответа от БКИ сократилось в 3 раза.

– Упрощенные маршруты. 95% клиентов проходят весь путь по одному из четырех стандартных сценариев вместо ранее множества нестабильных вариаций.

– Снижение оттока клиентов. За счет уменьшения числа ошибок и возвратов клиентов на предыдущие этапы удержание выросло, что подтвердилось снижением показателя churn rate на 6 п.п. (с 21% до 15%).

Эти результаты демонстрируют, что выявление и устранение структурных недостатков, снижающих эффективность клиентского пути, приводит к росту ключевых метрик скорости, качества UX и, в конечном счете, на CLTV, что мы и продемонстрируем в следующем процессе.

## Ключевые метрики и детализированный расчет изменения CLTV

В этом разделе мы фиксируем, как ключевые показатели клиентского пути, а именно средняя длительность этапов и доля возвратов изменились после внедрения улучшений, выявленных с помощью Process Mining, и рассчитываем итоговое изменение CLTV на примере 50 000 клиентов. Все метрики (время, возвраты) получены из тех же смоделированных event-log'ов, на основе которых мы выявляли узкие места (см. раздел 5).

Для проведения дальнейших расчетов зададим значения основным показателям:

1. ARPU (Average Revenue Per User) = 500 рублей. Выбран как характерный уровень маржи банка с одной успешной выдачи кредита (с учетом процентного дохода и комиссий).

2. CLTV(base) = 9 800 рублей. Базовая дисконтированная прибыль от клиента при прежних процессных параметрах (рассчитана по классической формуле CLTV с churn rate равным 21% и частотой 1,8 выдачи в год).

Эти два показателя являются отправной точкой: ARPU показывает доход с единичной операции, CLTV(base) – агрегированную ценность клиента до улучшений.

Теперь произведем расчеты метрик по тому же event-log'у, что и ранее: для каждого из 50 000 кейсов мы усредняем длительность этапов и рассчитываем долю возвратов (см. Таблица 4). Кейс считается «возвратом», если по логам после этапа заявка уходит на повторное прохождение этапа или завершается без выдачи.

*Таблица 4 — Ключевые метрики клиентского пути «до» и «после» изменений*

Этап	Ср. длит. «до», мин	Ср. длит. «после», мин	$\Delta D$ , мин	Возвраты «до», %	Возвраты «после», %
Валидация полей	8,2	1,5	6,7	24,2	2,0
Проверка БКИ (API)	2,1	0,7	1,4	12,0	1,0
Скоринг	15,4	2,3	13,1	14,8	4,7
Подписание (ЭЦП)	5,2	1,1	4,1	6,2	1,5

Выдача средств	3,8	0,4	3,4	0,0	0,0
----------------	-----	-----	-----	-----	-----

Средняя длительность показывает, сколько минут в среднем занимает каждый этап до и после.

Доля возвратов – процент кейсов, в которых заявка «заворачивается» на повторный обход этапа или отменяется.

Теперь, когда значение всех метрик в процессах «до» и «после» известны можно произвести расчет изменения затрат.

Для каждого этапа клиентского пути экономия трудозатрат на одного клиента составляет:

$$\Delta C_t = C_p \cdot \Delta D_t, C_p = \frac{1000 \text{ руб./ч}}{60 \text{ мин.}} \approx 16,7 \text{ руб./мин.} \quad (8)$$

Суммируем по всем этапам:

$$\sum_{t=1}^5 \Delta C_t = (6,7 + 1,4 + 13,1 + 4,1 + 3,4) \text{ мин} \times 16,7 \frac{\text{руб.}}{\text{мин.}} \approx 818 \text{ руб.} \quad (9)$$

Также рассчитаем прирост доли успешных операций и получаемого за счет этого дополнительно дохода. Поскольку ARPU привязан к успешной выдаче, прирост успешных операций оцениваем по снижению возвратов чего?:

$$\begin{aligned} \delta &= 1 - \frac{\sum \text{Возвраты «после»}}{\sum \text{Возвраты «до»}} = \\ &= 1 - \frac{2,0 + 1,0 + 4,7 + 1,5 + 0}{24,2 + 12,0 + 14,8 + 6,2 + 0} \approx 0,84 \end{aligned} \quad (10)$$

Следовательно дополнительный доход:

$$\Delta R = \delta \times \text{ARPU} = 0,839 \times 500 \text{ Р} \approx 420 \text{ руб. на клиента} \quad (11)$$

При этом у нас снизилась и доля оттока, с 21% до 15%:

$$\Delta P_{churn} = 0,21 - 0,15 = 0,06. \quad (12)$$

В связи с чем мы имеем следующее изменение CLTV:

$$\begin{aligned} \Delta CLTV_{churn} &= CLTV_{base} \times \Delta P_{churn} = \\ &= 9800 \times 0,06 = 588 \text{ руб. на клиента.} \end{aligned} \quad (13)$$

Теперь, зная все три ключевых показателя, рассчитаем итоговое изменение CLTV на одного клиента (горизонт T=1, ставка d=0,01):

$$\begin{aligned} \Delta CLTV &= \sum_{t=1}^T \frac{\Delta R_t - \Delta C_t}{(1+d)^t} + \Delta CLTV_{churn} \approx \\ &\approx 420 + 818 + 588 = 1826 \text{ руб. на клиента} \end{aligned} \quad (14)$$

Значит, для всей выборки в 50 000 клиентов:

$$\Delta CLTV_{total} = 50\,000 \times 1826 = 91,3 \text{ млн руб.} \quad (15)$$

За счет ускорения этапов и уменьшения возвратов и оттока суммарная ценность клиентской базы в размере 50 000 человек в денежном эквиваленте выросла на **91,3 млн рублей**.

### **Выводы**

В статье предложен структурированный подход к прогнозированию и управлению CLTV в банковской сфере на основе анализа клиентских путей с использованием технологии Process Mining. В отличие от традиционных моделей, основанных на агрегированных поведенческих признаках, данный подход позволяет учитывать конкретные этапы взаимодействия клиента с банком, измерять их влияние на отток клиентов, затраты и доходы и получать персонализированные финансовые оценки.

Построенная модель учитывает три блока: изменение затрат (снижение времени и трудоемкости), изменение дохода (рост частоты операций) и изменение оттока (повышение лояльности). На основе этой модели проведен эксперимент с логами событий по процессу оформления кредита и дебетовых карт, что позволило подтвердить применимость и воспроизводимость подхода.

Были достигнуты следующие ключевые результаты:

- Благодаря сокращению суммарной длительности ключевых этапов процесса с 34, до 5,5 минут (–84 %) мы получили экономию операционных затрат  $\approx 818$  руб. на одного клиента ( $\approx 16$  руб/мин  $\times 29,2$  мин).

- Снижение доли отказов (churn rate) с 21 % до 15 % (–6 п.п.) обеспечило дополнительную ценность  $\approx 588$  руб. на клиента.

- Совокупный эффект ускорения, уменьшения возвратов и снижения показателя churn rate дал прирост CLTV  $\approx 190$  руб. на клиента, или  $\approx 9,5$  млн руб. на базу из 50 000 клиентов.

- Предложенная методика (сбор логов, Process Mining-анализ, расчет CLTV-модели) может быть адаптирована к большому количеству других цифровых продуктов, каналов обслуживания и сегментов клиентской базы.

Таким образом, научная новизна данного исследования заключается в:

- Интеграции процессных (время этапов, частота возвратов, churn rate) и финансовых (ARPU, дисконтированная прибыль) метрик в единую эконометрическую модель  $\Delta CLTV$ .

– Разработке алгоритма от синтеза и предобработки event-логов до расчета денежного эффекта от изменений клиентского пути на основании Process Mining-метрик.

– Расширении сферы применения Process Mining: демонстрация его использования для диагностики и финансовой оценки модификаций клиентских траекторий (CLTV, churn rate), а не только для операционной оптимизации.

Предложенная модель имеет ряд ограничений, которые следует учитывать при интерпретации результатов:

– Зависимость от качества логов: модель опирается на точность и полноту логов событий. Отсутствие некоторых действий или агрегирование данных может исказить результаты.

– Сфокусированность на розничном сегменте: текущая реализация протестирована на физических лицах. Применение к сегменту среднего и малого бизнеса или крупным корпоративным клиентам требует адаптации.

– Отсутствие учета сезонности и влияния маркетинговых мероприятий: модель предполагает устойчивое поведение клиентов. На практике сезонные колебания, например, маркетинговые акции, летний сезон, праздники могут временно менять отток клиентов или доходность.

– Неполная оценка косвенных эффектов: такие как вирусный эффект, влияние лояльных клиентов на репутацию и приток новых заявок — в модель пока не включены.

Можно выделить следующие направления для дальнейших исследований:

1. Расширение модели на сегмент корпоративных клиентов;
2. Интеграция дополнительных поведенческих и эмоциональных метрик (например, NPS, пользовательские отзывы);
3. Построение панельных моделей CLTV с учетом макроэкономических факторов и сезонности;
4. Автоматизация обновления логов и их потоковой обработки в реальном времени (stream processing);
5. Разработка визуальных дашбордов CLTV для бизнес-подразделений банка.
6. Проведение А/В-тестов с выделением контрольной и фокусной групп для подтверждения факта того, что улучшение ключевых метрик и прирост

CLTV, связано именно с реализацией предложенных мер, а не другими факторами, например, такими как сезонность, маркетинговые компании и т.д.

#### Список литературы

1. **Seyedin B., Ramazani M., Bodaghi Khajeh Noubar H., Alavimatin Y.** Customer lifetime value analysis in the banking industry with an emphasis on brand equity // *International Journal of Nonlinear Analysis and Applications*. 2021. Vol. 12, No. 2. P. 991–1004.
2. **Furrer O.** Driving Customer Equity: How Customer Lifetime Value Is Reshaping Corporate Strategy // *International Journal of Service Industry Management*. 2002. Vol. 13, No. 1. P. 107–111.
3. **Roy G., Shen S.** Customer lifetime value prediction using machine learning techniques and its impact on FinTech // *Advances in Science, Engineering and Technology*. 2025. P. 248–253.
4. **van der Aalst W. M. P.** *Process Mining: Data Science in Action*. – Springer, 2018. P. 15–21.
5. **Tang W., Matzner M.** Creating Humanistic Value with Process Mining for Improving Work Conditions: A Sociotechnical Perspective // *Proceedings of the Forty-First International Conference on Information Systems*. India: Association for Information Systems, 2020. – P. 1–9.
6. **Gupta S., Lehmann D. R.** *Managing Customers as Investments*. Wharton, 2005. – P. 15–17.
7. **Дубко А. В.** Какими бывают карты клиентского опыта // *Управление продажами*. 2020. № 4. С. 320–330.
8. **Scherer M.** Predicting Churn Rate in Companies // *Artificial Intelligence and Soft Computing*. ICAISC 2023. *Lecture Notes in Computer Science*. 2023. P. 170–175.
9. **Дашук Э. В.** Перспективы использования Process Mining для оптимизации бизнес-процессов организации // *Экономика. наука. инноватика: материалы II Международной научно-практической конференции, приуроченной 100-летию ГОУ ВПО «Донецкий национальный технический университет»*, Донецк, 19 марта 2021 года. – Донецк: Донецкий национальный технический университет, 2021. – С. 585–588.
10. **Куцулым Д. В., Жребец Э. В.** Управление клиентским опытом в эпоху Big Data // *Форум молодых ученых*. 2020. № 10 (50). С. 303–310.
11. **van der Aalst W. M. P., Song M.** Mining Social Networks: Uncovering Interaction Patterns in Business Processes // In: *Desel J., Pernici B., Weske M.* (eds). *International Conference on Business Process Management (BPM 2004)*. Vol. 3080 of *Lecture Notes in Computer Science*. Berlin: Springer-Verlag, 2004. P. 244–260.

12. Демушкина К. М. Анализ возможностей инструментов реализации технологии Process Mining // Известия Самарского научного центра Российской академии наук. 2023. Т. 25, № 4 (114). С. 114–118.
13. Чачис Д. Ю. Использование данных для визуализации клиентских путей // Вестник науки. 2024. Т. 1, № 11 (80). С. 893–896.
14. Koosha H., Albadvi A. Customer lifetime valuation using real options analysis // Journal of Marketing Analytics. 2015. Vol. 3. P. 122–134.
15. Попов А. В. Управление клиентским опытом в процессе цифровой трансформации // Маркетинговые коммуникации. 2020. № 3. С. 200–208.

### References

1. Seyedin B., Ramazani M., Bodaghi Khajeh Noubar H., Alavimatin Y. Customer lifetime value analysis in the banking industry with an emphasis on brand equity // International Journal of Nonlinear Analysis and Applications. 2021. Vol. 12, No. 2. P. 991–1004.
2. Furrer O. Driving Customer Equity: How Customer Lifetime Value Is Reshaping Corporate Strategy // International Journal of Service Industry Management. 2002. Vol. 13, No. 1. P. 107–111.
3. Roy G., Shen S. Customer lifetime value prediction using machine learning techniques and its impact on FinTech // Advances in Science, Engineering and Technology. 2025. P. 248–253.
4. van der Aalst W. M. P. Process Mining: Data Science in Action. Springer, 2018. P. 15–21.
5. Tang W., Matzner M. Creating Humanistic Value with Process Mining for Improving Work Conditions: A Sociotechnical Perspective // Proceedings of the Forty-First International Conference on Information Systems. India: Association for Information Systems, 2020. P. 1–9.
6. Gupta S., Lehmann D. R. Managing Customers as Investments. Wharton, 2005. P. 15–17.
7. Dubko A. V. Kakimi byvayut karty klientskogo opyta // Upravlenie prodazhami. 2020. No. 4. P. 320–330.
8. Scherer M. Predicting Churn Rate in Companies // Artificial Intelligence and Soft Computing. ICAISC 2023. Lecture Notes in Computer Science. 2023. P. 170–175.
9. Dashuk E. V. Perspektivy ispolzovaniya Process Mining dlya optimizatsii biznes-protsessov organizatsii // Ekonomika. Nauka. Innovatika: materialy II Mezhdunarodnoy nauchno-prakticheskoy konferentsii, priurochennoy 100-letiyu GOU VPO “Donetskiy natsionalnyy tekhnicheskiy universitet”, Donetsk, 19 marta 2021 goda. – Donetsk: Donetskiy natsionalnyy tekhnicheskiy universitet, 2021. – P. 585–588.

10. **Kutsulym D. V., Zhrebets E. V.** Upravlenie klientskim opytom v epokhu Big Data // Forum molodykh uchenykh. – 2020. – No. 10 (50). – P. 303–310.
11. **van der Aalst W. M. P., Song M.** Mining Social Networks: Uncovering Interaction Patterns in Business Processes // In: Desel J., Pernici B., Weske M. (eds). International Conference on Business Process Management (BPM 2004). – Vol. 3080 of Lecture Notes in Computer Science. – Berlin: Springer-Verlag, 2004. – P. 244–260.
12. **Demushkina K. M.** Analiz vozmozhnostey instrumentov realizatsii tekhnologii Process Mining // Izvestiya Samarskogo nauchnogo tsentra Rossiyskoy akademii nauk. – 2023. – Vol. 25, No. 4 (114). – P. 114–118.
13. **Chachis D. Yu.** Ispolzovanie dannykh dlya vizualizatsii klientskikh putey // Vestnik nauki. – 2024. – Vol. 1, No. 11 (80). – P. 893–896.
14. **Koosha H., Albadvi A.** Customer lifetime valuation using real options analysis // Journal of Marketing Analytics. 2015. Vol. 3. P. 122–134.
15. **Popov A. V.** Upravlenie klientskim opytom v protsesse tsifrovoy transformatsii // Marketingovye kommunikatsii. 2020. No. 3. P. 200–208.