

УДК 004.89:621.391

DOI: 10.31673/2412-9070.2026.318114

М. С. ШАШ, аспірант;

ORCID ID: 0009-0009-3274-5318

О. С. ЗВЕНИГОРОДСЬКИЙ, канд. техн. наук, доцент,

ORCID ID: 0009-0008-6235-1638

Державний університет інформаційно-комунікаційних технологій, Київ

ПОРІВНЯННЯ МЕТОДІВ ПОЯСНЮВАННЯ ШІ ДЛЯ УТРИМАННЯ ТЕЛЕКОМ-АБОНЕНТІВ

У статті розглядається порівняльний аналіз методів пояснюваного штучного інтелекту (ХАІ) для прогнозування відтоку абонентів телекомунікаційних компаній. Відтік абонентів є контрактною подією, що передують поведінковими сигналами за 14–30 днів до розірвання договору або переходу через механізм МNP, утворюючи передвідтоковий поведінковий профіль. Розроблено тривісну класифікаційну схему ТСС-ХАІ (Telecom Customer Churn ХАІ Framework) за вимірами гранулярності пояснення (D1), залежності від моделі (D2) та практичної застосовності (D3) із четвертим телеком-специфічним виміром темпоральної обізнаності. За схемою систематизовано дев'ять ХАІ-методів та проведено їх порівняльний аналіз за вірністю, стабільністю та застосовністю. Показано, що TreeSHAP домінує на дескриптивно-діагностичному рівні, тоді як DiCEML є єдиним підтвердженим прескриптивним методом на телекомунікаційних даних. Виявлено три структурні дослідницькі прогалини: відсутність бенчмаркінгу стабільності SHAP проти LIME на великомасштабних даних; відсутність ХАІ-аналізу з диференціацією за типом пакету послуг; відсутність бенчмаркінгу ЕВМ на задачі відтоку. Запропоновано тришаровий операційний конвеєр ТСС-ХАІ для телекомунікаційних операторів. Наукова новизна полягає у розробці першої спеціалізованої схеми ТСС-ХАІ, що одночасно враховує гранулярність, залежність від моделі, практичну застосовність та телеком-специфічну темпоральність, а також у встановленні багатосервісної прогалини як ключового невирішеного питання. Практичне значення результатів полягає у можливості поетапного впровадження ХАІ-систем відповідно до операційної зрілості оператора, забезпечення вимог статті 22 GDPR та підвищення ефективності команд утримання клієнтів завдяки переходу до прескриптивних пояснень.

Ключові слова: пояснюваний штучний інтелект, відтік абонентів, SHAP, LIME, контрфактуальне пояснення; абонент.

Вступ

У сучасній телекомунікаційній галузі відтік абонентів (customer churn) є однією з ключових загроз для прибутковості компаній. На відміну від інших секторів, відтік у телекомі здебільшого є подією чітко контрактного характеру і фіксується у момент розірвання договору або переходу до конкурента через механізм збереження номера (Mobile Number Portability, MNP). Водночас поведінкові сигнали, що передують цьому рішення, зниження частоти дзвінків, скорочення споживання трафіку, зростання кількості звернень до служби підтримки з'являються за 14–30 днів до фактичного відтоку, утворюючи передвідтоковий поведінковий профіль [1].

Поширення ОТТ-сервісів (Over-the-Top) таких як WhatsApp, Viber, Telegram суттєво скорочує голосовий трафік традиційних операторів, тоді як регуляторний тиск обмежує цінові можливості. Витрати на залучення нового абонента у 5-7 разів перевищують витрати на утримання існуючого, що робить точне та своєчасне прогнозування відтоку стратегічним пріоритетом для операторів [2].

© М. С. Шаш, О. С. Звенигородський, 2026

Машинне навчання (ML) забезпечує високу точність прогнозів відтоку: ансамблеві методи XGBoost та LightGBM досягають показника AUC до 0.97. Однак висока точність прогнозу сама по собі не вирішує проблему утримання абонента. Менеджер з утримання не може діяти на основі числа (наприклад, ймовірності відтоку 0.87), якщо не розуміє, які конкретні фактори спричинили такий прогноз і яких змін достатньо для зниження ризику. Це явище дістало назву «парадоксу точності», коли технічно досконала модель залишається операційно марною без механізмів пояснення [3].

Додатковим чинником є регуляторний тиск. Наприклад, стаття 22 Регламенту ЄС GDPR зобов'язує забезпечити пояснення автоматизованих рішень, що впливають на фізичних осіб. Персоналізована пропозиція знижки або зміна тарифного плану на основі ML-прогнозу відтоку прямо підпадає під цю вимогу, що обумовлює актуальність Explainable AI (XAI) у задачах прогнозування відтоку абонентів [4].

Постановка проблеми

Задача прогнозування відтоку абонентів телекомунікаційних компаній є добре дослідженою з точки зору точності ML-моделей. Проте на практиці оператори стикаються з принципово іншою проблемою: як перетворити прогноз відтоку на конкретні дії відділу утримання, щоб утримати абонента. Ця проблема є двовимірною.

По-перше, існуючі методи XAI застосовуються до задачі відтоку телеком-абонентів переважно без урахування специфіки домену: передвідтокової природи відтоку, багатосервісності абонентських пакетів та темпоральної структури CDR-даних (Call Detail Records). Статичні методи пояснення, що обчислюють SHAP-значення лише на “знімку” поточних ознак абонента, пропускають найінформативніший передвідтківий інтервал $[t^* - 30, t^*]$, де t^* - момент зірвання договору або ініціювання MNP-заявки.

По-друге, у літературі відсутня єдина класифікаційна схема XAI-методів, яка б одночасно враховувала рівень деталізації пояснення (локальний, когортний, глобальний), ступінь залежності від архітектури моделі та практичну застосовність для операційних рішень із утримання. Наслідком є те, що порівняльні дослідження SHAP і LIME виконуються без стандартизованих метрик стабільності, а прескриптивні методи (DiCEML) залишаються невалідованими на великомасштабних операторських даних.

Таким чином, завдання роботи полягає у систематизації та порівняльному аналізі методів XAI для задачі прогнозування відтоку абонентів телекомунікаційних компаній із розробкою тривісної класифікаційної схеми TCC-XAI та ідентифікацією критичних дослідницьких прогалин.

Аналіз останніх досліджень і публікацій

Дослідження XAI-методів у задачі прогнозування відтоку клієнтів охоплює кілька напрямів. Теоретичну основу сучасних методів XAI систематизовано у роботах Adadi та Berrada [6], та Arrieta et al. [7], де запропоновано класифікацію за залежністю від моделі (intrinsic vs. post-hoc). Проте ці огляди не враховують специфіку задачі відтоку і не включають практичну застосовність як окремий класифікаційний вимір.

Серед постфактумних методів пояснення найширшого поширення набув SHAP (SHapley Additive exPlanations), теоретично обґрунтований Lundberg та Lee [8]. Özkurt [9] продемонстрував ефективність TreeSHAP на XGBoost-моделі для телекомунікаційного датасету (7043 абоненти, точність 94,12%). Так, тип контракту, щомісячна плата та наявність технічної підтримки були визначені як провідні предиктори відтоку зі значеннями SHAP, що перевищують 0,6. Asif et al. [10] розвинули цей підхід, запропонували ансамбль XAI-Churn TriBoost (XGBoost + CatBoost + LightGBM) на датасеті Espresso з 2 млн. абонентів (AUC-ROC 0,9744), де SHAP-аналіз виявив регулярність використання та частоту поповнення рахунку як найсильніші предиктори відтоку. Теоретичну основу варіантів SHAP – TreeSHAP, KernelSHAP, TimeSHAP – систематизовано у роботі Mosca et al. [11].

Попри домінування SHAP, метод LIME (Local Interpretable Model-agnostic Explanations), запропонований Ribeiro et al. [12], залишається актуальним для локальних пояснень. Asif et al. [10] є однією з небагатьох робіт, де обидва методи застосовано одночасно до телекомунікаційних даних. Özkurt [9] підтвердив, що SHAP перевершує LIME за глобальною узгодженістю. Проте систематичне порівняння стабільності обох методів на великомасштабних телекомунікаційних наборах даних досі відсутнє, незважаючи на існування стабілізованого варіанту SLIME [13].

Якісно новий напрям представлено контрфактуальними поясненнями [14]. Oprea та Bâra [15] реалізували DiCEML на телекомунікаційному датасеті Telco Customer Churn. Там Balanced Random Forest (recall 0,72) поєднується з DiCEML через змішане цілочислове лінійне програмування (MILP). Результати демонструють конкретні прескриптивні сценарії для відділів утримання клієнтів. Водночас реалізація обмежена стандартним датасетом із 7043 абонентами без урахування великомасштабних операторських даних із CDR-послідовностями.

Загальний огляд Shahabikargar et al. [1], що охоплює понад 150 публікацій, підтверджує домінування XGBoost та Random Forest для табличних даних відтоку й фіксує телекомунікаційний сектор як найбільш досліджений домен. Водночас порівняльні огляди XAI-методів із урахуванням специфіки багатосервісних телекомунікаційних пакетів (мобільний + інтернет + ТБ) у наявній літературі відсутні.

Таким чином, аналіз літератури виявляє три невирішені проблеми: (1) відсутність стандартизованого порівняння стабільності SHAP та LIME; (2) відсутність XAI-аналізу з диференціацією за типом пакету послуг; (3) відсутність бенчмаркінгу EBM на задачі відтоку.

Мета і задачі дослідження

Метою роботи є аналіз та порівняння методів пояснюваного штучного інтелекту для прогнозування відтоку абонентів телекомунікаційних компаній шляхом розробки класифікаційної схеми ТСС-XAI та виявлення критичних прогалів у сучасній літературі.

Для досягнення поставленої мети визначено такі задачі дослідження:

1. Розробити класифікаційну схему ТСС-XAI (гранулярність × залежність від моделі × практична застосовність).
2. Систематизувати наявну XAI-літературу відповідно до вимірів ТСС-XAI.
3. Порівняти методи SHAP, LIME, DiCEML та EBM за вірністю, стабільністю та практичною застосовністю.
4. Ідентифікувати та пріоритизувати дослідницькі прогалини, специфічні для телекомунікаційного контексту.
5. Сформулювати рекомендації щодо розгортання XAI-систем у телекомунікаційних компаніях.

Основна частина

У задачах пояснення прогнозів відтоку абонентів метод XAI характеризується трьома незалежними властивостями: рівнем деталізації пояснення, ступенем залежності від архітектури моделі та практичною застосовністю для прийняття рішень щодо утримання. Формально, нехай M - навчена модель прогнозування відтоку, $x \in R^m$ - вектор ознак абонента, $\hat{y} = M(x) \in [0,1]$ - прогнозована ймовірність відтоку. Тоді метод пояснення E визначається як функція:

$$E(M, x) \rightarrow \varphi, \quad (1)$$

де φ - пояснення, що належить до одного з рівнів гранулярності. Схема ТСС-XAI (Telecom Customer Churn XAI Framework) класифікує метод E за трьома осями:

– D1 (гранулярність): локальний (instance-level) – пояснення для конкретного абонента, x_i когортний (segment-level) – агрегація по підмножині, $S \subseteq X$ – глобальний (model-level) – характеристика поведінки моделі на всій множині X ;

– D2 (залежність від моделі): внутрішньо інтерпретовані методи (intrinsic, наприклад, EBM); постфактумні агностичні (post-hoc agnostic, наприклад, LIME, DiCEML); постфактумні специфічні (post-hoc specific, наприклад, TreeSHAP, TimeSHAP);

– D3 (практична застосовність): описувальний рівень (Чому?) – визначає причинні ознаки, але не вказує на спосіб зміни прогнозу; діагностичний рівень (Хто? Яка закономірність?) – ідентифікує ризикові сегменти; прескриптивний рівень (Що робити?) – генерує мінімальні зміни ознак абонента, що переводять прогноз з «відтік» у «утримання»:

$$\varphi^* = \arg \min \|\delta\| \quad \text{таке що} \quad M(x_i + \delta) < \theta, \quad (2)$$

де θ – порогове значення ймовірності відтоку, δ – вектор мінімальних змін ознак.

Додатково введено четвертий вимір D4 – телеком-темпоральність, що оцінює здатність методу враховувати часову структуру CDR-послідовностей і передвідтокову поведінку абонента. Результати картування дев'яти XAI-методів за схемою TCC-XAI наведено у таблиці 1.

Таблиця 1

Матриця TCC-XAI в класифікації методів XAI для задачі відтоку телеком-абонентів

Метод	D1 гранулярність	D2 Залежність від моделі	D3 Застосовність	Телеком-темпоральність
TreeSHAP	Локальний + Глобальний	Постфактумний, специфічний	Дескриптивна / Діагностична	Середня
KernelSHAP	Локальний + Глобальний	Постфактумний, агностичний	Дескриптивна / Діагностична	Низька
LIME / SLIME	Локальний	Постфактумний, агностичний	Дескриптивна	Низька
EBM	Локальний + Глобальний	Внутрішній	Дескриптивна / Діагностична	Середня
DiCEML	Локальний	Постфактумний, агностичний	Прескриптивна	Середня
PDP	Глобальний	Постфактумний, агностичний	Діагностична	Низька
TimeSHAP	Локальний	Постфактумний, специфічний	Дескриптивна	Дуже висока
GenAI-XAI	Локальний	Постфактумний, LLM-доповнений	Прескриптивна	Висока

Аналіз методів XAI. TreeSHAP є найпоширенішим варіантом SHAP у літературі з відтоку, який забезпечує точні значення Шеплі для ансамблів дерев (XGBoost, LightGBM, CatBoost) із обчислювальною складністю $O(TLD^2)$, що робить його придатним для виробничих систем операторів. Özkurt [9] застосував TreeSHAP на XGBoost до датасету Kaggle Telco Customer Churn і визначив Contract type, MonthlyCharges та TechSupport як провідні предиктори із значеннями SHAP > 0,6. Абоненти на місячних контрактах без технічної підтримки класифіковані як група найвищого ризику. Asif et al. [10] застосували SHAP у складі

XAI-Churn TriBoost на даних Espresso (2 млн. абонентів): SHAP force plot та waterfall plot виявили REGULARITY (+0,21) та REVENUE (+0,06) як найсильніші предиктори відтоку.

LIME генерує локальні пояснення, навчаючи лінійну модель-сурогат на збуреннях навколо конкретного екземпляра. Метод застосовний до будь-якої моделі, включно з нейронними мережами. Критична проблема - це нестабільність результатів між запусками. Наприклад, вибір ядра сусідства суттєво впливає на вихідні пояснення. SLIME пропонує механізм зниження дисперсії [13], однак жодне з досліджень не порівнює стабільність LIME та SHAP із використанням метрики Jaccard@k на телекомунікаційних даних.

DiCEML відповідає на питання “які мінімальні зміни характеристик абонента переводять прогноз “відтік” на “утримання””. Orgea та Vâra [15] реалізували DiCEML через MILP на датасеті Telco: перехід із місячного на дворічний контракт разом зі зниженням щомісячної плати переводив прогноз у “без відтоку”; активація лише OnlineBackup без зміни умов контракту залишала ймовірність відтоку на рівні 66%. Аудит справедливості виявив системні упередження щодо абонентів пенсійного віку ($DI = 0,529$).

EVM (Explainable Boosting Machine, InterpretML) базується на узагальнених адитивних моделях (GAM) і одночасно досягає точності ансамблевих моделей при повній внутрішній інтерпретованості. Asif et al. [10] є єдиною роботою, що згадує EVM у переліку методів, але без порівняльного оцінювання. Порівняльний аналіз основних методів наведено у таблиці 2.

Таблиця 2

Порівняльний аналіз основних XAI-методів для задачі відтоку телеком-абонентів

Критерій	TreeSHAP	LIME	DiCEML	EVM
Вірність пояснення	Висока	Середня	Висока	Висока
Стабільність	Висока	Низька	Висока	Висока
Застосовність D3	Дескриптивна	Дескриптивна	Прескриптивна	Діагностична
Залежність від моделі	Специфічна (дерева)	Агностична	Агностична	Внутрішня
GDPR-аудит	Так	Ні (без SLIME)	Так	Так
Телеком-темпоральність	Середня	Низька	Середня	Середня

Специфіка телекомунікаційного домену. Телекомунікаційний домен має три особливості, що суттєво впливають на вибір та інтерпретацію XAI-методів.

Перша – контрактна природа відтоку та MNP. Механізм MNP робить перехід до конкурента значно простішим, утворюючи передвідтокове поведінкове вікно $[t^* - 30, t^*]$. Нехай для абонента і визначено послідовність CDR-спостережень $x^{(1)} = (x_1^{(1)}, x_2^{(1)}, \dots, x_t^{(1)})$, де кожен вектор $x_t^{(1)} \in R^m$ містить частоту дзвінків, обсяг трафіку та кількість скарг. Статичні методи пояснення пропускають цей найінформативніший інтервал. TimeSHAP обчислює темпоральне значення Шеплі Φ_t для кожного кроку t , дозволяючи ідентифікувати момент перетину критичного порогу ризику.

Друга – багатосервісність абонентських пакетів. Сучасні оператори пропонують пакетні рішення “мобільний + Інтернет + ТБ”. Ризик відтоку для абонента пакетної послуги якісно відрізняється від ризику для абонента лише мобільного зв'язку, а відповідні SHAP-значення мо-

жуть суттєво відрізнятися між сегментами. Жодне з розглянутих досліджень не аналізує, як змінюються ХАІ-пояснення залежно від типу пакету послуг.

Третя – взаємна кореляція ознак. Тип контракту, пакет послуг та щомісячна плата є взаємно корельованими: абоненти пакетних пропозицій мають систематично вищу щомісячну плату, що може спотворювати розподіл значень Шеплі між цими ознаками.

Операційний конвеєр ТСС-ХАІ та дослідницькі прогалини. На основі проведеного аналізу пропонується тришаровий конвеєр розгортання ХАІ для телекомунікаційних операторів.

Рівень 1 (готовий до впровадження) – XGBoost або LightGBM із TreeSHAP, це глобальний дашборд важливості ознак і локальні SHAP force plots для відділу утримання абонентів. Значення SHAP зберігаються разом із прогнозами, формуючи аудиторський слід для статті 22 GDPR.

Рівень 2 (середньострокова перспектива) – додавання DiCEML-шару. Менеджер з утримання отримує конкретний сценарій дій (зміну тарифного плану, активацію пакетної послуги, коригування умов контракту). На цьому рівні доцільне впровадження EBM як внутрішньо інтерпретованого базового методу.

Рівень 3 (перспективні напрями) – інтеграція Bi-LSTM із TimeSHAP на CDR-даних для темпоральної локалізації передвідтокового ризику та GenAI-шар для генерації персоналізованих повідомлень утримання [16].

Виявлено та пріоритизовано три структурні дослідницькі прогалини:

1. Відсутність систематичного порівняльного аналізу стабільності SHAP та LIME на великомасштабних телекомунікаційних наборах даних із використанням метрики Jaccard@k. Ця прогалина є критичною з регуляторної точки зору: нестабільні пояснення LIME без стабілізуючих механізмів не можуть слугувати аудиторським слідом для GDPR.

2. Відсутність ХАІ-аналізу з урахуванням багатосервісності абонентів. Абоненти пакетних пропозицій демонструють якісно інші патерни відтоку, а SHAP-значення та DiCEML-рекомендації можуть суттєво відрізнятися між моно- та мультисервісними сегментами.

3. Відсутність бенчмаркінгу EBM на задачі відтоку абонентів. Якщо EBM досягає точності, порівнянної з XGBoost, при збереженні внутрішньої інтерпретованості, це усуває необхідність постфактумних наближень і спрощує дотримання GDPR для операторів.

Висновки та перспективи

У роботі розроблено тривісну класифікаційну схему ТСС-ХАІ (гранулярність × залежність від моделі × практична застосовність) із четвертим телеком-специфічним виміром темпоральної обізнаності, що враховує передвідтокову природу відтоку абонентів. Ця схема є першим спеціалізованим класифікаційним інструментом для ХАІ-методів у задачі прогнозування відтоку в телекомунікаційному секторі.

Картування дев'яти ХАІ-методів за вимірами ТСС-ХАІ показало, що TreeSHAP домінує в літературі на описивно-діагностичному рівні застосовності. DiCEML є єдиним підтвердженим прескриптивним методом на телекомунікаційних даних, однак обмежений стандартними датасетами без урахування багатосервісних пакетів. SHAP демонструє високу вірність та стабільність, LIME – нестабільність між запусками без механізмів типу SLIME, EBM – потенціал усунення протиріччя точність–інтерпретованість.

Запропоновано тришаровий операційний конвеєр впровадження ХАІ для телекомунікаційних операторів. Перший рівень базується на TreeSHAP і є готовим до негайного впровадження. Другий рівень передбачає інтеграцію DiCEML та EBM для переходу до прескриптивних пояснень. Третій рівень охоплює TimeSHAP та GenAI для темпоральної локалізації ризику відтоку та автоматизованої генерації стратегій утримання. Кожен рівень відповідає конкретній операційній зрілості оператора.

Перспективами подальших досліджень є емпіричне порівняння SHAP, LIME та EBM на публічних телекомунікаційних наборах даних із метрикою Jaccard@k, а також стратифікований ХАІ-аналіз за типом пакету послуг абонента. Окремим напрямом є інтеграція Bi-LSTM

з TimeSHAP для CDR-послідовностей з фокусом на передвідтоковому вікні 14–30 днів. Крім того, актуальним є А/В-тестування ХАІ-пояснень на реальних результатах утримання відділами по утриманню абонентів.

Внесок авторів

Максим ШАШ – концептуалізація, розробка класифікаційної схеми ТСС-ХАІ, аналіз літератури, систематизація методів, підготовка порівняльних таблиць, оформлення рукопису; Олександр ЗВЕНИГОРОДСЬКИЙ – наукове керівництво, перевірка та редагування рукопису.

Декларація про штучний інтелект

Штучний інтелект у підготовці цієї статті не використовувався.

Конфлікт інтересів

Автори заявляють про відсутність конфлікту інтересів та підтверджують, що під час підготовки цієї роботи не існувало жодних комерційних, фінансових або інших взаємовідносин, які могли б вплинути на результати дослідження або їх інтерпретацію.

Список використаної літератури

1. Shahabikargar M., Beheshti A., Zhang X., Foo J., Jolfaei A. A comprehensive survey on customer churn analysis studies. *Journal of Information and Telecommunication*. 2026. Vol. 10, No. 1. P. 24–70.
2. Talaat F. M., Aljadani A. AI-driven churn prediction in subscription services: addressing economic metrics, data transparency, and customer interdependence. *Neural Computing and Applications*. 2025. Vol. 37. P. 8651–8676. <https://doi.org/10.1007/s00521-025-11027-6>
3. Arrieta A. B., Díaz-Rodríguez N., Del Ser J. et al. Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. *Information Fusion*. 2020. Vol. 58. P. 82–115. <https://doi.org/10.1016/j.inffus.2019.12.012>
4. Wachter S., Mittelstadt B., Russell C. Counterfactual Explanations without Opening the Black Box: Automated Decisions and the GDPR. *Harvard Journal of Law & Technology*. 2018. Vol. 31, No. 2. P. 841–887.
5. Alboukaey N. et al. Dynamic behavior based churn prediction in mobile telecom. *Expert Systems with Applications*. 2020. Vol. 162. Article 113779. <https://doi.org/10.1016/j.eswa.2020.113779>
6. Adadi A., Berrada M. Peeking Inside the Black-Box: A Survey on Explainable Artificial Intelligence (XAI). *IEEE Access*. 2018. Vol. 6. P. 52138–52160. <https://doi.org/10.1109/ACCESS.2018.2870052>
7. Arrieta A. B. et al. Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges. *Information Fusion*. 2020. Vol. 58. P. 82–115.
8. Lundberg S. M., Lee S.-I. A unified approach to interpreting model predictions. *Advances in NeurIPS*. 2017. Vol. 30. P. 4765–4774.
9. Özkurt C. Transparency in Decision-Making: The Role of Explainable AI (XAI) in Customer Churn Analysis. *Information Technology and Economics in Business*. 2025. Vol. 2, No. 1. P. 1–11. <https://doi.org/10.69882/ADBA.ITEB.2025011>
10. Asif D., Arif M. S., Mukheimer A. A data-driven interpretable approach to telecom customer churn analysis using XAI-Churn TriBoost. *Results in Engineering*. 2025. Vol. 26. Article 104629. <https://doi.org/10.1016/j.rineng.2025.104629>
11. Mosca E., Szigeti F., Tragianni S., Gallagher D., Groh G. SHAP-Based Explanation Methods: A Review for NLP Interpretability. *Proceedings of COLING 2022*. 2022. P. 4593–4603.
12. Ribeiro M. T., Singh S., Guestrin C. "Why should I trust you?": Explaining the predictions of any classifier. *Proceedings of the 22nd ACM SIGKDD*. 2016. P. 1135–1144. <https://doi.org/10.1145/2939672.2939778>

13. Shankaranarayana S. M., Runje D. ALIME: Autoencoder Based Approach for Local Interpretability. In: *Artificial Intelligence and Soft Computing*. 2019. P. 454–463.
14. Verma S., Dickerson J., Hines K. Counterfactual explanations for machine learning: A review. <https://doi.org/10.48550/arXiv:2010.10596>.
15. Oprea S.-V., Bâra A. Customer-Centric Decision-Making with XAI and Counterfactual Explanations for Churn Mitigation. *Journal of Theoretical and Applied Electronic Commerce Research*. 2025. Vol. 20, No. 129. <https://doi.org/10.3390/jtaer20020129>
16. Houssam M., Jraifi A. GenAI Meets Explainability: Turning Churn Predictions into Personalized Retention Strategies. *Statistics, Optimization and Information Computing*. 2026. Vol. 15. P. 2286–2302. <https://doi.org/10.19139/soic-2310-5070-3151>

M. Shash, O. Zvenyhorodskyi

COMPARATIVE ANALYSIS OF EXPLAINABLE AI METHODS FOR TELECOM SUBSCRIBER RETENTION

This paper presents a comparative analysis of Explainable Artificial Intelligence (XAI) methods applied to customer churn prediction in telecommunications companies. Subscriber churn is a contractual event preceded by behavioural signals occurring 14–90 days prior to contract termination or Mobile Number Portability (MNP) initiation, forming a distinctive pre-portability behavioural profile. A triaxial classification framework, TCC-XAI (Telecom Customer Churn XAI Framework), is developed along three dimensions: explanation granularity (D1), model dependency (D2), and practical applicability for retention (D3), supplemented by a fourth telecom-specific dimension of temporal awareness. Nine XAI methods are systematized within the framework and comparatively evaluated in terms of fidelity, stability, and actionability. TreeSHAP is shown to dominate at the descriptive-diagnostic applicability level, while DiCEML remains the only confirmed prescriptive method validated on telecommunications data. Three structural research gaps are identified: the absence of SHAP-versus-LIME stability benchmarking on large-scale telecom datasets; the absence of XAI analysis differentiated by subscriber service bundle type; and the absence of EBM benchmarking on churn prediction tasks. A three-layer operational TCC-XAI deployment pipeline for telecommunications operators is proposed. The scientific novelty of the study lies in the development of the first specialized TCC-XAI framework that simultaneously accounts for granularity, model dependency, practical applicability, and telecom-specific temporality, as well as in the identification of the multi-service gap as a critical unresolved research problem. The practical significance of the results consists in enabling the incremental deployment of XAI systems aligned with the operator's operational maturity, ensuring compliance with Article 22 of the GDPR, and improving the effectiveness of customer retention teams through the transition to prescriptive explanations.

Keywords: explainable artificial intelligence, customer churn, SHAP, LIME, counterfactual explanations, customer retention, subscriber retention.

Надійшла до редакції: 09.02.2026

Прийнята до друку: 30.03.2026

Опубліковано: 29.06.2026

© 2026 М. С. Шаш, О. С. Звенигородський.

Цей матеріал ліцензовано за умовами CC BY 4.0. <https://creativecommons.org/licenses/by/4.0/>