

МЕТОД КОНТЕКСТНО-ЗАЛЕЖНОГО ВИБОРУ XAI ДЛЯ ПРОГНОЗУВАННЯ ВІДТОКУ SAAS-КЛІЄНТІВ

Shash M.S., Zvenyhorodskiy O.S. Method of context-dependent XAI selection for SaaS customer churn prediction. This paper proposes a method for context-dependent selection of Explainable Artificial Intelligence (XAI) methods for customer churn prediction in SaaS platforms. The proposed approach systematizes XAI method selection based on two key dimensions: SaaS monetization model (Freemium, PLG, Enterprise) and churn stage (Early, Mid, Late), forming the SXS-F framework in the form of a decision tree. A comparative analysis of SHAP, LIME, DiCEML, and EBM methods across the proposed dimensions revealed significant differences in fidelity, stability, and practical applicability depending on the context. The results confirm the effectiveness of the context-dependent approach to XAI method selection for enhancing the operational value of churn prediction systems in SaaS environments.

Keywords: churn prediction, XAI, explainable artificial intelligence, SaaS platforms, XAI method selection, machine learning

Шаш М.С., Звенигородський О.С. Метод контекстно-залежного вибору XAI для прогнозування відтоку SaaS-клієнтів. У статті запропоновано метод контекстно-залежного вибору методів пояснюваного штучного інтелекту (XAI) для прогнозування відтоку клієнтів у SaaS-платформах. Запропонований підхід систематизує вибір XAI-методу на основі двох ключових вимірів: моделі монетизації SaaS (Freemium, PLG, Enterprise) та стадії відтоку клієнта (Early, Mid, Late), формуючи фреймворк SXS-F у вигляді дерева рішень. Порівняльний аналіз методів SHAP, LIME, DiCEML та EBM у розрізі запропонованих вимірів показав суттєві відмінності у вірності, стабільності та практичній застосовності залежно від контексту. Результати підтверджують ефективність контекстно-залежного підходу до вибору XAI-методів для підвищення операційної цінності систем прогнозування відтоку у SaaS-середовищі.

Ключові слова: прогнозування відтоку, XAI, пояснюваний штучний інтелект, SaaS, вибір XAI методів, машинне навчання

Вступ

Глобальний ринок SaaS-платформ демонструє стійке зростання, однак разом із масштабуванням загострюється проблема утримання клієнтів. Так середній річний показник відтоку у SaaS-сегменті становить 5–7% для Enterprise рішень, і сягає 20–30% для Freemium продуктів [1]. На відміну від традиційних галузей, де відтік є дискретною подією, у SaaS він розгортається як багатотижневий процес зниження залученості. Клієнт перестає використовувати ключові функції, скорочує частоту сесій і поступово втрачає зв'язок із продуктом задовго до фактичного скасування підписки. Принципова особливість SaaS-середовища полягає у тому, що різні бізнес-моделі (Freemium, Product-Led Growth (PLG) та Sales-Led Enterprise) генерують якісно відмінні сигнали відтоку. Для Freemium критичним є провал онбордингу в перші 14-30 днів, для PLG – зниження product adoption після початкової активації, для Enterprise – зміна пріоритетів на рівні організації-клієнта за 60-90 днів до завершення контракту.

Методи машинного навчання забезпечують технічно високу точність прогнозування відтоку. Так XGBoost та LightGBM досягають AUC до 0.97 [2], однак операційна цінність таких моделей визначається не точністю прогнозу, а здатністю транслювати його у конкретні дії команди утримання. Саме тут виникає фундаментальна проблема – існуючі підходи до застосування методів пояснюваного штучного інтелекту (XAI) у задачах відтоку є контекстно-нейтральними. Один і той самий метод (SHAP, LIME або DiCEML) застосовується незалежно від того, чи йдеться про Freemium-користувача на етапі онбордингу, чи про Enterprise-клієнта напередодні поновлення контракту. Наслідком є «контекстна невідповідність» – технічно коректне пояснення залишається операційно нерелевантним, оскільки не враховує ні тип бізнес-моделі, ні стадію відтоку, ні доступні важелі впливу для менеджера з роботи з клієнтами.

Постановка завдання. Завдання полягає у розробці методу контекстно-залежного вибору ХАІ для прогнозування відтоку клієнтів SaaS-платформ, що систематизує вибір методу пояснення на основі двох ключових вимірів. А саме моделі монетизації (Freemium, PLG, Enterprise) та стадії відтоку клієнта (Early, Mid, Late). Метод представляє результати у вигляді фреймворку SXS-F із деревом рішень для практичного застосування командами утримання клієнтів.

Аналіз останніх досліджень. У сучасних дослідженнях прогнозування відтоку клієнтів за допомогою машинного навчання дедалі більше уваги приділяється не лише підвищенню точності моделей, а й забезпеченню їхньої пояснюваності. Розвиток методів пояснюваного штучного інтелекту (ХАІ) відкрив можливості для побудови систем, здатних не лише ідентифікувати клієнтів із ризиком відтоку, але й обґрунтовувати прийняті рішення у спосіб, зрозумілий для бізнесу. Проте більшість досліджень застосовують ХАІ-методи без урахування специфіки SaaS-середовища: моделі монетизації та стадії відтоку клієнта. Це суттєво знижує операційну цінність отриманих пояснень.

Серед постфактумних методів пояснення найширшого поширення набув SHAP (SHapley Additive exPlanations). Lundberg та Lee [3] теоретично обґрунтували метод на апараті кооперативної теорії ігор, забезпечивши виконання аксіом локальної точності, відсутності та узгодженості. Özkurt [4] продемонстрував ефективність TreeSHAP на XGBoost-моделі для телекомунікаційного датасету, визначивши тип контракту та щомісячну плату як провідні предиктори відтоку зі значеннями SHAP, що перевищують 0.6. Asif et al. розвинули цей підхід у складі ансамблю ХАІ-Churn TriBoost на даних 2 млн абонентів, де SHAP force plot та waterfall plot виявили регулярність використання як найсильніший предиктор відтоку (AUC-ROC 0.9828). Проте жодне з цих досліджень не розглядає, як змінюються SHAP-пояснення залежно від типу SaaS-моделі монетизації.

Метод LIME (Local Interpretable Model-agnostic Explanations), запропонований Ribeiro et al. [5], генерує локальні пояснення шляхом навчання лінійної моделі-сурогату на збуреннях навколо конкретного екземпляра i , на відміну від TreeSHAP, застосовний до будь-якої архітектури моделі. Özkurt [4] підтвердив, що SHAP перевершує LIME за глобальною узгодженістю, тоді як LIME ефективніший для локальних пояснень окремих екземплярів. Критичною проблемою LIME залишається нестабільність результатів між запусками: вибір ядра сусідства суттєво впливає на вихідні пояснення, що унеможливує його використання як аудиторського сліду для GDPR [10] без стабілізуючих механізмів на кшталт SLIME.

Якісно новий напрям представлено контрфактуальними поясненнями. Oprea та Bâra [6] є єдиною роботою, що реалізує DiCEML для прогнозування відтоку. Balanced Random Forest поєднується з DiCEML через змішане цілочислове лінійне програмування, генеруючи конкретні прескриптивні сценарії – зміну типу контракту та рівня щомісячної плати. Ці сценарії достатні для переведення прогнозу з класу «відтік» у клас «утримання». Принципова відмінність від SHAP та LIME полягає у тому, що DiCEML не пояснює причину прогнозу, а безпосередньо відповідає на питання «що саме повинен зробити менеджер?». Водночас жодного SaaS-застосування DiCEML у наявній літературі не виявлено.

Explainable Boosting Machine (EBM, InterpretML), що базується на узагальнених адитивних моделях (GAM) із попарними взаємодіями, одночасно досягає точності ансамблевих моделей і забезпечує повну внутрішню інтерпретованість без постфактумного наближення. Adadi та Berrada [7] та Arrieta et al. [8] визначають EBM як провідний метод подолання протиріччя між точністю та інтерпретованістю. Проте порівняльного бенчмаркінгу EBM із TreeSHAP-на-XGBoost на даних відтоку жодна розглянута робота не представляє.

Загальний огляд Shahabikargar et al. [9], що охоплює понад 150 публікацій, підтверджує домінування XGBoost та Random Forest для табличних даних відтоку, однак фіксує суттєву прогалину: жодне дослідження не розглядає вибір ХАІ-методу як функцію від типу SaaS-бізнес-моделі та стадії відтоку клієнта. Саме ця прогалина (відсутність контекстно-залежного підходу до вибору ХАІ) і є центральною невирішеною проблемою, на усунення якої спрямована дана робота.

Метою роботи є підвищення операційної цінності систем прогнозування відтоку клієнтів SaaS-платформ шляхом розробки методу контекстно-залежного вибору ХАІ-методів. Задача полягає у побудові фреймворку SXS-F, який систематизує вибір методу пояснення на основі двох ключових вимірів - моделі монетизації SaaS (Freemium, PLG, Enterprise) та стадії відтоку клієнта (Early, Mid, Late). Метод представляє результати у вигляді дерева рішень, придатного для безпосереднього застосування командами утримання клієнтів.

Виклад основного матеріалу дослідження

У задачах прогнозування відтоку клієнтів SaaS-платформ мета полягає у побудові моделі, здатної не лише передбачити ймовірність відтоку, але й надати операційно релевантне пояснення, придатне для конкретних дій команди утримання. Формально, нехай маємо набір даних із n спостережень, кожне з яких представлено вектором ознак $x_i \in R^m$ та цільовою змінною $y_i \in \{0,1\}$:

$$D = \{(x_i, y_i)\}_{i=1}^n \quad (1)$$

де $y_i = 1$ означає відтік клієнта, де $y_i = 0$ - утримання. Мета моделі – знайти функцію f , що апроксимує залежність між вхідними ознаками та ймовірністю відтоку:

$$\hat{y}_i = f_{\theta}(x_i) \in [0,1] \quad (2)$$

де θ – параметри моделі, що навчаються шляхом мінімізації бінарної крос-ентропії:

$$L(\theta) = -\frac{1}{n} \sum_{i=1}^n [y_i \log \log f_{\theta}(x_i) + (1 - y_i) \log \log (1 - f_{\theta}(x_i))] \quad (3)$$

Фреймворк двовимірної матриці контексту SXS-F. Центральною ідеєю запропонованого методу є те, що вибір ХАІ-методу E для конкретного клієнта x_i є функцією не лише від моделі f , але й від контексту розгортання C :

$$E^* = OpVal(E, f, x_i, C) \quad (4)$$

де $OpVal$ - операційна цінність пояснення, $C = (M, S)$ – контекст, що визначається моделлю монетизації $M \in \{Freemium, PLG, Enterprise\}$ та стадією відтоку $S \in \{Early, Mid, Late\}$.

Матриця SXS-F систематизує оптимальний вибір ХАІ-методу для кожної комбінації (M, S) і наведена у таблиці 1.

Дерево рішень SXS-F. Запропонований метод реалізується у вигляді дерева рішень, що дозволяє CSM або ML-інженеру обрати оптимальний ХАІ-метод на основі двох послідовних запитань про контекст розгортання. Схема дерева наведена на рис. 1.

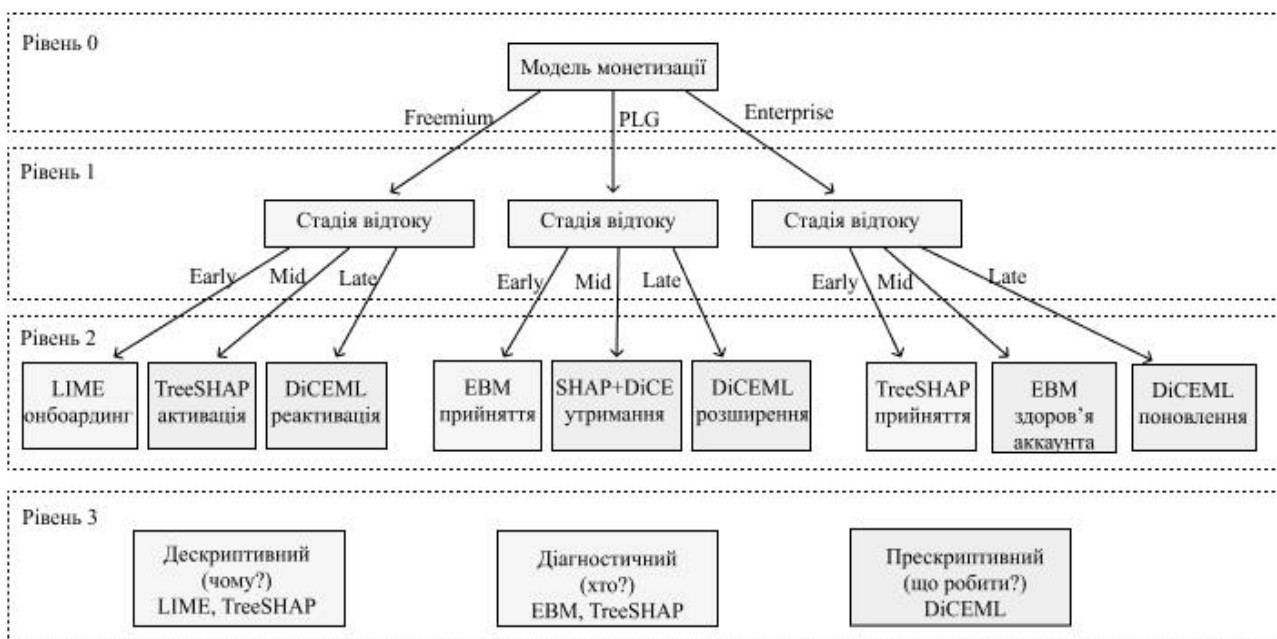


Рис. 1. демонструє дерево рішень SXS-F, що систематизує вибір ХАІ-методу залежно від контексту SaaS-розгортання

Таблиця 1

Матриця SXS-F для вибіру ХАІ-методу за контекстом

Модель \ Стадія	Early (0–60 днів)	Mid (2–12 міс.)	Late (12+ міс.)
Freemium	LIME (локальний, онбординг)	TreeSHAP (активація функцій)	DiCEML (реактивація)
PLG	EBM (adoption-патерни)	TreeSHAP + DiCEML	DiCEML (expansion)
Enterprise	TreeSHAP (глобальний)	EBM (account health)	DiCEML (renewal)

Нижче на рис. 2 наведено Python-реалізацію ключових кроків фреймворку SXS-F: навчання XGBoost-моделі, генерація SHAP force plot та DiCEML контрфактуального пояснення для одного клієнта SaaS-платформи.

```

1 import pandas as pd
2 import xgboost as xgb
3 import shap
4 import dice_ml
5 from sklearn.model_selection import train_test_split
6
7 # 1. Завантаження та підготовка SaaS-даних
8 df = pd.read_csv("saas_churn.csv")
9 features = ["days_since_login", "feature_depth", "plan_tier", "onboarding_complete", "support_tickets", "monthly_charge"]
10 X = df[features]
11 y = df["churn"]
12
13 X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)
14
15 # 2. Навчання моделі XGBoost
16 model = xgb.XGBClassifier(n_estimators=200, max_depth=6, learning_rate=0.05, use_label_encoder=False,
17 ..... eval_metric="logloss", random_state=42)
18 model.fit(X_train, y_train)
19
20 # 3. SHAP-пояснення для конкретного клієнта (Early Freemium churn)
21 explainer = shap.TreeExplainer(model)
22 client = X_test.iloc[0] # клієнт із ризиком відтоку
23
24 shap_values = explainer.shap_values(client)
25 # Виводить force plot: які ознаки підвищують/знижують ризик
26 shap.force_plot(explainer.expected_value, shap_values[0], client, matplotlib=True)
27
28 # 4. DiCEML контрфактуальне пояснення (прескриптивний рівень D3)
29 # Визначаємо змінювані ознаки для Freemium-клієнта
30 data_interface = dice_ml.Data(dataframe=pd.concat([X_train, y_train], axis=1),
31 ..... continuous_features=["days_since_login", "monthly_charge", "support_tickets"],
32 ..... outcome_name="churn")
33
34 model_interface = dice_ml.Model(model=model, backend="sklearn")
35 exp = dice_ml.Dice(data_interface, model_interface, method="random")
36
37 # Генерація мінімальних змін що переводять прогноз у "утримання"
38 cf = exp.generate_counterfactuals(client, total_CFs=3, desired_class="opposite",
39 ..... features_to_vary=["days_since_login", "onboarding_complete", "plan_tier"])
40 cf.visualize_as_dataframe()

```

Рис. 2. Python-реалізація ключових кроків фреймворку SXS-F

Результат виконання коду демонструє два рівні пояснення відповідно до фреймворку SXS-F: SHAP force plot відповідає дескриптивному рівню D3 (виявляє, що onboarding_complete=0 та days_since_login=45 є провідними факторами ризику), тоді як DiCEML генерує прескриптивний сценарій: конкретні мінімальні зміни (onboarding_complete=1, перехід на вищий plan_tier), достатні для переведення прогнозу клієнта з класу «відтік» у клас «утримання».

Таблиця 2

Порівняльний аналіз ХАІ-методів у розрізі SXS-F

Метод	Вірність	Стабільність	D3 рівень	Freemium	PLG	Enterprise
TreeSHAP	Висока	Висока	Дескр./Діагн.	Mid	Mid	Early/Mid
LIME	Середня	Низька	Дескриптивний	Early	-	-
DiCEML	Висока	Висока	Прескриптивний	Late	Mid/Late	Late
EBM	Висока	Висока	Діагн./Дескр.	-	Early	Mid

Висновки

У роботі розроблено метод контекстно-залежного вибору XAI для прогнозування відтоку клієнтів SaaS-платформ – фреймворк SXS-F, що систематизує вибір методу пояснення на основі моделі монетизації (Freemium, PLG, Enterprise) та стадії відтоку (Early, Mid, Late) у вигляді дерева рішень. Порівняльний аналіз показав, що TreeSHAP є оптимальним для Mid-стадії відтоку, DiCEML – єдиним прескриптивним методом для Late-стадії, а EBM – пріоритетним для Early-стадії PLG-моделі. Розроблений фреймворк може бути адаптований для телекомунікацій, стрімінгових платформ та e-commerce. Подальші дослідження варто спрямувати на емпіричне порівняння методів на публічних SaaS-наборах даних та A/B-тестування XAI-пояснень на реальних результатах утримання клієнтів.

Список використаної літератури:

1. Lakshmi A. J. та ін. Cloud Computing and Deep Learning for Customer Churn Prediction in SaaS Platforms. *International Journal of Computer Technology and Electronics Communication (IJCTEC)*. 2026. Vol. 9, No. 1. P. 75–80. URL: <https://doi.org/10.15680/IJCTECE.2026.0901012>.
2. Gellanki G. N., Dasari K., Goona G. S., Alapana K. K. Customer Churn Prediction Using Machine Learning. *American Journal of Management and IOT Medical Computing*. 2026. Vol. 5, No. 1. P. 104–111. URL: <https://www.ajmimc.com/>.
3. Lundberg S. M., Lee S.-I. A unified approach to interpreting model predictions. *Advances in Neural Information Processing Systems (NeurIPS 2017)*. 2017. Vol. 30. P. 4765–4774. URL: <https://proceedings.neurips.cc/paper/2017/hash/8a20a8621978632d76c43dfd28b67767-Abstract.html>.
4. 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. URL: <https://doi.org/10.69882/ADBA.ITEB.2025011>.
5. Ribeiro M. T., Singh S., Guestrin C. "Why should I trust you?": Explaining the predictions of any classifier. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. 2016. P. 1135–1144. URL: <https://doi.org/10.1145/2939672.2939778>.
6. 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. URL: <https://doi.org/10.3390/jtaer20020129>.
7. Adadi A., Berrada M. Peeking Inside the Black-Box: A Survey on Explainable Artificial Intelligence (XAI). *IEEE Access*. 2018. Vol. 6. P. 52138–52160. URL: <https://doi.org/10.1109/ACCESS.2018.2870052>.
8. Arrieta A. B., Díaz-Rodríguez N., Del Ser J. та ін. Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. *Information Fusion*. 2020. Vol. 58. P. 82–115. URL: <https://doi.org/10.1016/j.inffus.2019.12.012>.
9. Shahabikargar M., Fabian L., Nesterenko V. та ін. A comprehensive survey on customer churn analysis studies. *Journal of Information and Telecommunication*. 2023. Vol. 7, No. 1. P. 45–72. URL: <https://doi.org/10.1080/25765299.2023.2193636>.
10. 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. URL: <https://doi.org/10.2139/ssrn.3063289>.

Автори статті

Шаш Максим – аспірант, Державний університет інформаційно-комунікаційних технологій, Київ, Україна.
ORCID: 0009-0009-3274-5318

Звенигородський Олександр – кандидат технічних наук, доцент, Державний університет інформаційно-комунікаційних технологій, Київ, Україна.
ORCID:0009-0008-6235-1638

Authors of the article

Shash Maksym – postgraduate, State University of Information and Communication Technologies, Kyiv, Ukraine.
ORCID: 0009-0009-3274-5318

Zvenyhorodskiy Oleksandr – Candidate of Sciences (technical), Associate Professor, State University of Information and Communication Technologies, Kyiv, Ukraine.

ORCID: 0009-0008-6235-1638

Надійшла до редакції: 29.04.2026

Прийнята до друку: 04.05.2026

Опубліковано: 25.05.2026

© 2026 Шаш М.С., Звенигородський О.С.

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