

УДК 005.5

DOI: 10.34670/AR.2026.18.11.088

Адаптация гибридного алгоритма прогнозирования: поддержка решений сохранения лояльности клиентов

Игнаткин Максим Андреевич

Магистрант,
Национальный исследовательский
технологический университет «МИСИС»,
119049, Российская Федерация, Москва, Ленинский пр-кт, 4;
e-mail: ignatkin.maxim@gmail.com

Аннотация

Автором представлены итоги исследования, направленного на обоснование и внедрение гибридного алгоритма прогнозирования клиентского оттока в практику современного менеджмента. В эпоху цифровой трансформации экономики приоритеты компаний эволюционировали: модель бесконечного привлечения новых пользователей уступила место стратегии удержания существующей аудитории. Причина — в прямой экономической выгоде: поддержание лояльности текущего клиента требует меньших затрат по сравнению с запуском кампаний по привлечению. Гибридная архитектура ChurnStack, построенная на комбинации адаптивного синтетического сэмплирования ADASYN и ансамбля из CatBoost и XGBoost, обеспечивает коррекцию дисбаланса выборки и повышает достоверность прогнозов. Особую управленческую значимость имеет внедрение модуля интерпретации на основе значений Шепли (SHAP). Значения Шепли — числовые показатели, отражающие вклад каждого признака в итоговое предсказание модели для конкретного объекта. Применение математического аппарата на основе значений Шепли позволяет трансформировать модель из «черного ящика» в прозрачный аналитический инструмент, предоставляя менеджменту возможность формировать персонализированные стратегии удержания на основе конкретных факторов риска для каждого клиента. Экономический эффект от внедрения предложенного метода выражается в минимизации финансовых потерь и потенциальном росте прибыли компании.

Для цитирования в научных исследованиях

Игнаткин М.А. Адаптация гибридного алгоритма прогнозирования: поддержка решений сохранения лояльности клиентов // Экономика: вчера, сегодня, завтра. 2026. Том 16. № 4А. С. 910-915. DOI: 10.34670/AR.2026.18.11.088

Ключевые слова

Современный менеджмент, интеллектуальный анализ данных, бизнес-процесс, принятие решений, экономический эффект, прогнозирование оттока, машинное обучение, управление лояльностью.

Введение

Исторически управление лояльностью строилось по реактивной логике: компания фиксировала отток после того, как клиент уже начал снижать активность, и запускала универсальные кампании удержания. На практике это часто означает решения «по ощущениям»: ориентир на отчеты прошлых периодов и экспертные правила (например, «если клиент не платит 2 месяца — дать скидку»). В цифровой экономике такой подход быстро теряет эффективность: данные становятся высокоразмерными (поведение в приложении, обращения в поддержку, платежные паттерны), а реакции клиентов — нелинейными и зависящими от контекста (канал, конкурентные предложения, сезонность) [Ahmad, 2019]. Анализ научной литературы и открытых практик позволил выделить следующие подходы в рамках решения заявленных проблем: классические статистические методы, стандартные алгоритмы машинного обучения, гибридные системы поддержки принятия решений:

Классические статистические методы (логистическая регрессия, LDA). Их ключевое достоинство это прозрачность: можно явно увидеть, как признак влияет на вероятность оттока. Однако из-за ограниченной формы зависимостей такие модели часто дают высокое смещение (High Bias) и «не видят» сложные, скрытые взаимодействия факторов (например, когда риск резко растет только при одновременном снижении потребления и росте обращений в поддержку) [Al-Shayea, 2019].

Стандартные алгоритмы машинного обучения (Random Forest, градиентный бустинг). Они лучше захватывают нелинейности и взаимодействия, поэтому повышают качество прогноза. Тем не менее, в задаче оттока почти всегда присутствует дисбаланс классов: ушедших клиентов меньше, чем оставшихся. В результате модель может показывать высокую точность, но пропускать значимую долю реальных «уходящих» (низкий Recall), что особенно критично для управленческих решений (бюджет на удержание уходит «не туда») [Bogaert, 2023].

Гибридные системы поддержки принятия решений (ансамбли, стекинг). Современный этап связан с архитектурами, которые объединяют гетерогенные модели и тем самым снижают управленческий риск: ошибка одного алгоритма компенсируется сильными сторонами другого, а итоговый прогноз становится устойчивее к рыночной неопределенности [Wolpert, 1992].

Основная часть

Ключевым ограничением подходов третьего поколения в бизнесе остается эффект «черного ящика» (Black Box): менеджеру важно понимать не только «кто уйдет», но и «почему», и «что делать дальше». Именно поэтому актуальным вектором исследований становится интеграция высокой предсказательной силы моделей с методами объяснимого ИИ (XAI), превращающими прогноз в набор интерпретируемых факторов и рекомендаций для управления. Для решения этих задач предложен гибридный метод ChurnStack — не как отдельный алгоритм, а как многоуровневый бизнес-процесс интеллектуального анализа данных, ориентированный на обоснованные маркетинговые решения. Метод включает три функциональных блока. Поскольку доля оттока клиентов в реальных данных обычно не превышает 20%, возникает эффект смещения модели в сторону доминирующего класса: алгоритм либо недополучает обучающие примеры, либо систематически классифицирует клиентов как лояльных. Применение ADASYN позволяет синтезировать профили пользователей на границе классов. В результате модель учится распознавать самых «трудных» клиентов, чье поведение отличается

от лояльного незначительно, что, по расчетам, повышает Recall на 10–15%. Для устранения систематической ошибки отдельного алгоритма в ChurnStack используется стек — комбинация CatBoost и XGBoost. Экономическая логика в данном объединении связана с тем, что некоррелированные модели (линейно независимые) снижают общую дисперсию ошибки. Это сопоставимо с диверсификацией инвестиционного портфеля: дефекты прогноза одного алгоритма компенсируются точностью другого, обеспечивая стабильность системы в условиях рыночной волатильности. Блок интерпретации (SHAP Integration) трансформирует математический прогноз в прикладной план действий для управления. Используя аппарат теории кооперативных игр (значения Шепли), система разделяет итоговый показатель риска на конкретные детерминанты [Lundberg, 2017]. Вместо абстрактной вероятности пользователь получает перечень факторов оттока (например, снижение объема трафика на 30% и частота обращений в техподдержку). Это позволяет формировать персонализированные предложения, оптимизируя маркетинговый бюджет компании.

В ходе исследования была предпринята попытка обоснования эффективности предлагаемой архитектуры через декомпозицию ошибки ансамбля. Рассмотрим теоретическое обоснование снижения дисперсии ошибки в ансамблевых моделях. По предварительному теоретическому обоснованию и расчетам, использование алгоритма ADASYN в цепочке обработки данных решает одну из главных проблем аналитики оттока. Речь идет о так называемом смещении модели в сторону «мажоритарного класса» — ситуации, когда алгоритм привыкает видеть в основном лояльных клиентов и начинает игнорировать тех редких пользователей, которые собираются уйти. Т.е. модель может всех клиентов записывать в лояльных и при уровне оттока 20% точность модели будет 80%, что полностью бесполезно. Для систем в данной сфере критически важен показатель полноты (Recall) — способность системы корректно идентифицировать клиентов, планирующих расторжение контракта. Как показали расчёты этот показатель возрастает на 10–15% по сравнению с моделями, не использующими адаптивное сэмплирование [He, 2008]. Для управления это означает радикальное сокращение «слепых зон» в клиентской базе. В отличие от стандартных алгоритмов, которые часто демонстрируют высокую общую точность (Accuracy) при низкой способности выявлять реальный отток, ChurnStack обеспечивает интегральный показатель F1-score на 5–7% выше, чем у базовых моделей градиентного бустинга (XGBoost или CatBoost), взятых в отдельности. Это позволяет уменьшить отток, связанный с несвоевременной идентификацией деструктивных изменений в потребительской лояльности. Экономические преимущества метода работы основываются на принципе управления клиентским капиталом: затраты на удержание существующего клиента в 5–7 раз ниже издержек на привлечение нового [Reichheld, 2023]. Согласно исследованиям, увеличение периода удержания клиентов является наиболее прибыльной стратегией с точки зрения возврата инвестиций по сравнению с привлечением новых пользователей или до-продажами. Своевременное прогнозирование оттока на ранней стадии открывает для компании значительный источник дополнительного дохода: практика показала, что точечные предложения позволяют удержать до 47% склонных к уходу клиентов, что ведет к прямому росту выручки и сокращению общего уровня оттока (на примере внедрения в SyriaTel - примерно на 1,5%) [Ahmad, 2019]. Применение метода ChurnStack позволяет реализовать следующие экономические эффекты:

- Оптимизация маркетинговых издержек: Благодаря уменьшению дисперсии ошибки за счёт применения механизма гетерогенного стекинга это приводит к снижению количества ложноположительных срабатываний модели. Т.е. система заметно реже относит действительно

лояльных клиентов к категории потенциально уходящих — а это, одна из самых дорогих аналитических ошибок в CRM-практике.

В результате компания получает возможность более аккуратно распределять ресурсы на удержание аудитории. Маркетинговые стимулы, бонусы и персональные предложения не расходуются впустую на пользователей, которые и без того сохраняют приверженность бренду. Казалось бы, мелочь. Но в масштабах крупной клиентской базы подобная точность постепенно превращается в вполне ощутимую экономию.

- **Максимизация пожизненной ценности клиента:** Своевременное прогнозирование вероятного расторжения договора позволяет компании заранее предпринимать меры по удержанию клиента и продлевать период активного потребления услуг. Это напрямую способствует росту долгосрочной капитализации бизнеса. При этом, как показывает практика, чем дольше клиент взаимодействует с компанией, тем ниже вероятность последующего расторжения договора.

- **Снижение потерь в высококонкурентных сегментах:** Для телекоммуникационного сектора, где ежегодный уровень оттока достигает 20–30%, внедрение предложенного метода выступает критическим фактором сохранения рыночной доли и поддержания операционной устойчивости [Khan, 2023].

Заключение

Таким образом, в ходе исследования был разработан гибридный метод машинного обучения ChurnStack для оптимизации стратегий удержания и повышения экономической эффективности маркетинговых кампаний и дано его описание. Данный метод позволяет решать следующие задачи:

- анализировать экономические препятствия по использованию стандартных моделей прогнозирования в управлении,
- минимизировать управленческие риски,
- использовать технологии интерпретируемого ИИ (SHAP) для формирования персонализированных стратегий удержания,
- оценить возможные экономические последствия реализации предлагаемого метода.

Библиография

1. Ahmad A.K., Jafar A., Aljoumaa K. Customer churn prediction in telecom using machine learning in big data platform // Journal of Big Data. 2019. Vol. 6, no. 1. Pp. 1–24.
2. Al-Shayea Q.K. Artificial Neural Networks in Medical Diagnosis // International Journal of Computer Science Issues. 2019.
3. Bogaert M., Delaere L. Ensemble methods in customer churn prediction: A comparative analysis // Mathematics. 2023. Vol. 11, no. 5. P. 1137.
4. Forbes Business Council. The Economics of Customer Retention in the Digital Age // Forbes. 2024. Electronic resource.
5. He H., Bai Y., Garcia E.A., Li S. ADASYN: Adaptive synthetic sampling approach for imbalanced learning // 2008 IEEE International Joint Conference on Neural Networks. 2008. Pp. 1322–1328.
6. Khan S.A., Niu H., Khan M.A. Machine Learning Based Improved Customer Churn Prediction Model for Telecommunications Industry // 2023 18th International Conference on Emerging Technologies (ICET). IEEE, 2023. Pp. 161–166.
7. Krogh A., Vedelsby J. Neural Network Ensembles, Cross Validation, and Active Learning // Advances in Neural Information Processing Systems. Vol. 7 of NIPS. 1995. Pp. 231–238.
8. Lundberg S.M., Lee S.-I. A Unified Approach to Interpreting Model Predictions // Advances in Neural Information Processing Systems. 2017. Pp. 4765–4774.
9. Reichheld F.F., Scheffer P. The Value of Online Customer Loyalty and the Churn Effect // Harvard Business Review. 2023. Updated Analysis.

10. Wolpert D.H. Stacked generalization // Neural Networks. 1992. Vol. 5, no. 2. Pp. 241–259.
11. Zhang J., Liu Y., Zhang Y. Comparative study of ensemble learning methods for churn prediction in 5G era // IEEE Transactions on Network and Service Management. 2024. Vol. 21, no. 2. Pp. 1102–1115.

Adaptation of a Hybrid Forecasting Algorithm: Decision Support for Customer Loyalty Retention

Maksim A. Ignatkin

Master's Student,
National University of Science and Technology "MISIS",
119049, 4, Leninskiy ave., Moscow, Russian Federation;
e-mail: ignatkin.maxim@gmail.com

Abstract

The author presents the results of a study aimed at substantiating and implementing a hybrid algorithm for forecasting customer churn into the practice of modern management. In the era of digital transformation of the economy, the priorities of companies have evolved: the model of endless attraction of new users has given way to a strategy of retaining the existing audience. The reason lies in direct economic benefit: maintaining the loyalty of a current customer requires lower costs compared to launching acquisition campaigns. The hybrid architecture ChurnStack, built on a combination of adaptive synthetic sampling ADASYN and an ensemble of CatBoost and XGBoost, ensures the correction of sample imbalance and increases the reliability of forecasts. Of particular managerial significance is the implementation of an interpretation module based on SHAP values. SHAP values are numerical indicators reflecting the contribution of each feature to the final model prediction for a specific object. The application of the mathematical apparatus based on SHAP values allows transforming the model from a "black box" into a transparent analytical tool, providing management with the opportunity to form personalized retention strategies based on specific risk factors for each customer. The economic effect of implementing the proposed method is expressed in the minimization of financial losses and the potential growth of company profits.

For citation

Ignatkin M.A. (2026) Adaptatsiya gibridnogo algoritma prognozirovaniya: podderzhka resheniy sokhraneniya loyalti klientov [Adaptation of a Hybrid Forecasting Algorithm: Decision Support for Customer Loyalty Retention]. *Ekonomika: vchera, segodnya, zavtra* [Economics: Yesterday, Today and Tomorrow], 16 (4A), pp. 910-915. DOI: 10.34670/AR.2026.18.11.088

Keywords

Modern management, data mining, business process, decision-making, economic effect, churn forecasting, machine learning, loyalty management.

References

1. Ahmad, A.K., Jafar, A., & Aljoumaa, K. (2019). Customer churn prediction in telecom using machine learning in big data platform. *Journal of Big Data*, 6(1), 1-24.
2. Al-Shayea, Q.K. (2019). Artificial Neural Networks in Medical Diagnosis. *International Journal of Computer Science*

Issues.

3. Bogaert, M., & Delaere, L. (2023). Ensemble methods in customer churn prediction: A comparative analysis. *Mathematics*, 11(5), 1137.
4. Forbes Business Council. (2024). The Economics of Customer Retention in the Digital Age. Forbes. Electronic resource.
5. He, H., Bai, Y., Garcia, E.A., & Li, S. (2008). ADASYN: Adaptive synthetic sampling approach for imbalanced learning. In 2008 IEEE International Joint Conference on Neural Networks (pp. 1322-1328). IEEE.
6. Khan, S.A., Niu, H., & Khan, M.A. (2023). Machine Learning Based Improved Customer Churn Prediction Model for Telecommunications Industry. In 2023 18th International Conference on Emerging Technologies (ICET) (pp. 161-166). IEEE.
7. Krogh, A., & Vedelsby, J. (1995). Neural Network Ensembles, Cross Validation, and Active Learning. In *Advances in Neural Information Processing Systems* (Vol. 7, pp. 231-238). NIPS.
8. Lundberg, S.M., & Lee, S.-I. (2017). A Unified Approach to Interpreting Model Predictions. In *Advances in Neural Information Processing Systems* (pp. 4765-4774).
9. Reichheld, F.F., & Schefter, P. (2023). The Value of Online Customer Loyalty and the Churn Effect. *Harvard Business Review*. Updated Analysis.
10. Wolpert, D.H. (1992). Stacked generalization. *Neural Networks*, 5(2), 241-259.
11. Zhang, J., Liu, Y., & Zhang, Y. (2024). Comparative study of ensemble learning methods for churn prediction in 5G era. *IEEE Transactions on Network and Service Management*, 21(2), 1102-1115.