



АВТОМАТИЗАЦІЯ ГЕНЕРАЦІЇ ПОЯСНЕНЬ ДЛЯ СИСТЕМ ПІДТРИМКИ ПРИЙНЯТТЯ РІШЕНЬ У ФІНАНСОВІЙ СФЕРІ

AUTOMATION OF EXPLANATION GENERATION FOR DECISION SUPPORT SYSTEMS IN THE FINANCIAL SECTOR

Дегтярьов В.В.,
V. Dehtiarov

Сумський Державний Університет, м.Суми, Україна
Sumy State University, Sumy, Ukraine
ORCID: <https://orcid.org/0000-0002-1578-8588>
E-mail: vladyslav.dehtiarov@sommo.io

Copyright © 2026 by author and the journal “Automation of technological and business – processes”.
This work is licensed under the Creative Commons Attribution International License (CC BY).
<http://creativecommons.org/licenses/by/4.0>



DOI: [10.15673/atbp.v18i1.3434](https://doi.org/10.15673/atbp.v18i1.3434)

Анотація. Стаття присвячена актуальній проблемі автоматизації генерації пояснень для автоматизованих систем підтримки прийняття рішень (СППР) у фінансовій сфері. Впровадження машинного навчання у банківський сектор вимагає забезпечення прозорості автоматизованих рішень відповідно до регуляторних вимог. Запропоновано новий метод GPE (Greedy-Prune-Explain - жадібне відсікання з поясненням), який автоматично генерує мінімальні правила типу «ЯКЩО-ТО» для пояснення рішень моделей на основі дерев рішень. На відміну від існуючих модельно-агностичних методів (LIME, SHAP, Anchors), GPE використовує структуру дерева рішень для оптимізації процесу генерації пояснень. Метод працює у три послідовні фази: вилучення повного шляху рішення від кореня до листа, ітеративне відсікання надлишкових умов із збереженням заданого порогу точності та формування фінального пояснення з метриками якості (точність, покриття, складність). Доведено теоретичні гарантії алгоритму: часова складність $O(d^2 \cdot n)$ та гарантована точність пояснень. Експериментальна оцінка проведена на трьох реальних фінансових наборах даних кредитного скорингу загальним обсягом понад 630 000 записів. Результати демонструють прискорення у 34–66 разів порівняно з методом LIME при збереженні точності понад 98% та зменшенні складності пояснень до 1–2 умов. Статистична значущість результатів підтверджена t-тестом ($p < 0,001$) та розміром ефекту за Коеном ($d > 2,0$). Розроблено програмний фреймворк з відкритим кодом та REST API для інтеграції в існуючі бізнес-процеси фінансових установ. Практична значимість полягає у можливості повної автоматизації процесу надання пояснень клієнтам відповідно до вимог Загального регламенту захисту даних (GDPR) та Європейського акта про штучний інтелект (EU AI Act).

Abstract. The paper addresses the urgent problem of automating explanation generation for automated decision support systems (DSS) in the financial sector. The implementation of machine learning in the banking sector requires ensuring transparency of automated decisions in accordance with regulatory requirements. A novel GPE (Greedy-Prune-Explain) method is proposed, which automatically generates minimal IF-THEN rules to explain decisions of decision tree-based models. Unlike existing model-agnostic methods (LIME, SHAP, Anchors), GPE exploits the decision tree structure to optimize the explanation generation process. The method operates in three sequential phases: extraction of the complete decision path from root to leaf, iterative pruning of redundant conditions while maintaining a specified precision threshold, and formation of the final explanation with quality metrics (precision, coverage, complexity). Theoretical guarantees of the algorithm are proven: time complexity $O(d^2 \cdot n)$ and guaranteed explanation precision. Experimental evaluation was conducted on three real-world financial credit scoring datasets with a total volume of over 630,000 records. Results demonstrate 34–66× speedup compared to LIME while maintaining precision above 98% and reducing explanation complexity to 1–2 conditions. Statistical significance of results is confirmed by t-test ($p < 0.001$).



and Cohen's effect size ($d > 2.0$). An open-source software framework with REST API has been developed for integration into existing business processes of financial institutions. The practical significance lies in the ability to fully automate the process of providing explanations to customers in accordance with the General Data Protection Regulation (GDPR) and the European Artificial Intelligence Act (EU AI Act).

Ключові слова: автоматизація, системи підтримки прийняття рішень, пояснюваний штучний інтелект, дерева рішень, кредитний скоринг, бізнес-процеси.

Keywords: automation, decision support systems, explainable AI, decision trees, credit scoring, business processes.

Вступ

Автоматизація бізнес-процесів у фінансовій сфері досягла значного прогресу завдяки впровадженню систем підтримки прийняття рішень (СППР) на основі машинного навчання [1]. Сучасні банки та фінансові установи використовують автоматизовані системи кредитного скорингу, які обробляють тисячі заявок щодня без участі людини [2].

Однак регуляторні вимоги, зокрема Загальний регламент захисту даних (GDPR, стаття 22) та Європейський акт про штучний інтелект (EU AI Act), вимагають надання клієнтам зрозумілих пояснень автоматизованих рішень [3]. Це створює критичну потребу в автоматизації не лише процесу прийняття рішень, а й процесу генерації пояснень.

Проблема полягає в тому, що існуючі методи пояснення машинного навчання, такі як LIME (Local Interpretable Model-agnostic Explanations) та SHAP (SHapley Additive exPlanations), є надто повільними для інтеграції в автоматизовані бізнес-процеси реального часу. Типовий час генерації пояснення методом LIME становить 500–2000 мс, що неприйнятно для систем, які обробляють сотні заявок на секунду.

Аналіз літературних даних і постановка проблеми

Автоматизовані СППР у фінансовій сфері

Дерева рішень залишаються основою автоматизованих СППР у фінансах завдяки їх інтерпретованості та відповідності регуляторним вимогам [4]. Вони широко застосовуються в системах кредитного скорингу, виявлення шахрайства та оцінки ризиків [5]. Однак глибокі дерева (глибина понад 7 рівнів) генерують шляхи рішень з багатьма умовами, що перевищує когнітивні можливості людини. Дослідження в галузі когнітивної психології показують, що людина здатна одночасно обробляти 7 ± 2 елементи інформації [6].

Існуючі методи пояснення рішень

LIME (локальні інтерпретовані модельно-агностичні пояснення) [7] - найпоширеніший метод, який апроксимує локальну поведінку моделі лінійною функцією. Недоліки методу: висока обчислювальна складність $O(n \cdot k)$, нестабільність пояснень при повторних викликах та ігнорування структури дерева рішень.

SHAP (адитивні пояснення на основі значень Шеплі) [8] обчислює внесок кожної ознаки на основі теоретико-ігрового підходу. Недоліки: експоненціальна складність $O(2^m)$ для точного обчислення та вихід у вигляді числових ваг замість правил.

Anchors [9] генерує правила з гарантіями точності, але має високу обчислювальну складність через стохастичний пошук.

Аналіз літератури показує, що жоден з існуючих методів не забезпечує одночасно: швидкодію менше 10 мс для інтеграції в потокову обробку, детерміновані пояснення для аудиту та використання структури дерева для оптимізації. Це обумовлює актуальність розробки нового методу автоматизації генерації пояснень для СППР на основі дерев рішень.

Мета і завдання дослідження

Мета роботи - розробка та експериментальна оцінка методу автоматизації генерації пояснень для СППР на основі дерев рішень, який забезпечує швидкодію, достатню для інтеграції в бізнес-процеси реального часу.

Завдання дослідження:

1. Розробити трифазний алгоритм GPE для генерації мінімальних пояснень дерев рішень із формальними гарантіями точності.
2. Обґрунтувати теоретичну складність алгоритму та довести гарантії точності.
3. Провести експериментальну оцінку на реальних фінансових даних та порівняти з існуючими методами.
4. Розробити програмний фреймворк для інтеграції в банківські інформаційні системи.

Наукова новизна роботи полягає у розробці нового алгоритму GPE, який вперше забезпечує генерацію пояснень для дерев рішень за час $O(d^2 \cdot n)$ з гарантованою точністю, що дозволяє інтеграцію в автоматизовані бізнес-процеси реального часу.

Методи і матеріали досліджень

Формальна постановка задачі

Нехай задано:

- T - навчене дерево рішень глибини d
- $X \in \mathbb{R}^{n \times m}$ - навчальні дані (n записів, m ознак)
- $x \in \mathbb{R}^m$ - екземпляр для пояснення
- τ - поріг точності (типово $\tau = 0,95$)



Задача: знайти мінімальне правило $R = \{c_1, c_2, \dots, c_k\}$ таке, що:

1. R правильно класифікує x як T(x)
2. Точність $P(R) \geq \tau$
3. Кількість умов k мінімізована

Алгоритм GPE

GPE (Greedy-Prune-Explain) - трифазний алгоритм генерації мінімальних пояснень:

Фаза 1 - GREEDY (Вилучення шляху):

Витягуємо повний шлях рішення R від кореня до листа для екземпляра x. Обхід дерева виконується за $O(d)$.

Фаза 2 - PRUNE (Відсікання):

Ітеративно видаляємо умови з R, зберігаючи точність $\geq \tau$:

Алгоритм 1. Фаза PRUNE

Вхід: R - початкове правило, X - фонові дані, τ - поріг точності

Вихід: R' - мінімальне правило

```

1: while |R| > 1 do
2:   for кожної умови c ∈ R do
3:     обчислити precision(R \ {c}, X)
4:   end for
5:   c ← argmax precision(R \ {c})
6:   if precision(R \ {c}) ≥ τ then
7:     R ← R \ {c}
8:   else
9:     break
10:  end if
11: end while
12: return R

```

Фаза 3 - EXPLAIN (Формування пояснення):

Генеруємо пояснення з метриками якості: точність, покриття, складність.

Теоретичні гарантії

Теорема 1 (Часова складність). Алгоритм GPE має часову складність $O(d^2 \cdot n)$, де d - глибина дерева, n - розмір фонових даних.

Доведення. Фаза GREEDY виконує один обхід дерева за $O(d)$. Фаза PRUNE виконує не більше d ітерацій, на кожній ітерації перевіряється не більше d умов, кожна перевірка потребує $O(n)$. Загальна складність: $O(d) + O(d \cdot d \cdot n) = O(d^2 \cdot n)$. ■

Теорема 2 (Гарантія точності). GPE гарантує $\text{precision}(R) \geq \tau$ для всіх згенерованих пояснень.

Доведення. Алгоритм видаляє умову лише якщо точність залишкового правила не падає нижче порогу τ (рядок б).

Набори даних

Експерименти проведено на трьох реальних фінансових наборах даних:

Таблиця 1. Характеристики експериментальних наборів даних

Набір даних	Записів	Ознак	Позит. клас (%)	Джерело
German Credit	1 000	20	30%	UCI Repository
Credit Card Default	30 000	23	22%	UCI Repository
Lending Club	600 000	15	18%	Kaggle

Програмна реалізація

Розроблено Python-фреймворк з використанням бібліотек scikit-learn та NumPy. Експерименти проведено на комп'ютері з процесором Apple M1, 16 ГБ RAM. Кожен експеримент повторено 100 разів для забезпечення статистичної значущості.

Результати досліджень

Порівняння швидкодії

Таблиця 2 містить результати порівняння часу генерації пояснень.

Таблиця 2. Порівняння часу генерації пояснень

Метод	German	Credit Card	Lending Club	Середнє
LIME	487	612	1243	781
Anchors	1523	2341	4567	2810
GPE	8,2	12,4	18,7	13,1



GPE демонструє прискорення: 59× на German Credit, 49× на Credit Card Default та 66× на Lending Club порівняно з LIME.

Якість пояснень

Таблиця 3. Метрики якості пояснень

Метод	Точність (%)	Складність (умов)	Стабільність (%)
LIME	89,2	5,3	72,4
Anchors	95,1	3,8	94,2
GPE	98,4	1,7	100,0

Статистична значущість

Результати статистичного аналізу:

- t-тест для порівняння часу: $p < 0,001$
- Розмір ефекту за Коеном: $d > 2,0$ (великий ефект)
- 95% довірчий інтервал для прискорення: [48×, 72×]

Масштабованість

GPE демонструє майже лінійну залежність часу від розміру даних: 2 мс (1К записів), 5 мс (10К), 12 мс (100К), 19 мс (600К), що підтверджує теоретичну оцінку $O(d^2 \cdot n)$.

Обговорення результатів

Переваги методу GPE

Експериментальні результати підтверджують теоретичні переваги GPE:

1. Швидкодія. Прискорення у 34–66 разів порівняно з LIME дозволяє інтеграцію в бізнес-процеси реального часу. Час генерації < 20 мс достатній для обробки 50+ заявок на секунду.
2. Якість. Точність 98,4% перевищує LIME (89,2%) та Anchors (95,1%). Складність 1,7 умови відповідає когнітивним можливостям людини [6].
3. Стабільність. 100% детермінованість пояснень критична для аудиту та відповідності регуляторам.

Практичне застосування

Розглянемо сценарій впровадження GPE у банку, що обробляє 50 000 кредитних заявок на добу:

Приклад пояснення для клієнта:

Вхідні дані: річний дохід 45 000 грн, співвідношення боргу 0,48, кредитний рейтинг 620.

Автоматично згенероване пояснення:

«Шановний клієнте! Ваша заявка на кредит відхилена. Основна причина: співвідношення вашого боргу до доходу (48%) перевищує максимально допустимий поріг (40%).»

Відповідність регуляторним вимогам

GPE забезпечує відповідність: GDPR (стаття 22 - право на пояснення), EU AI Act (прозорість AI), Basel III (документування рішень).

Обмеження методу

1. GPE розроблено для дерев рішень; для ансамблевих методів потрібна адаптація.
2. Точність залежить від репрезентативності фонових даних.
3. Поріг τ впливає на компроміс між складністю та точністю.

Висновки

У роботі представлено метод GPE (Greedy-Prune-Explain) для автоматизації генерації пояснень у системах підтримки прийняття рішень фінансової сфери.

Основні результати:

1. Розроблено трифазний алгоритм GPE, який генерує мінімальні пояснення для дерев рішень за час $O(d^2 \cdot n)$ з гарантованою точністю $\geq \tau$.
2. Експериментально підтверджено прискорення у 34–66 разів порівняно з LIME при точності понад 98% та складності 1–2 умови.
3. Статистична значущість результатів підтверджена ($p < 0,001$, Cohen's $d > 2,0$).
4. Розроблено програмний фреймворк з відкритим кодом для інтеграції в банківські системи.

Напрямки подальших досліджень: розширення на ансамблеві методи, інтеграція з системами виявлення шахрайства, проведення користувацького дослідження.

Програмна реалізація: `pip install gpe-framework`

Список використаних джерел

1. Arrieta A. B., Diaz-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. DOI: 10.1016/j.inffus.2019.12.012.



2. Lessmann S., Baensens B., Seow H.-V., Thomas L. C. Benchmarking state-of-the-art classification algorithms for credit scoring: An update of research. *European Journal of Operational Research*. 2015. Vol. 247, No. 1. P. 124–136. DOI: 10.1016/j.ejor.2015.05.030.
3. Rudin C. Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. *Nature Machine Intelligence*. 2019. Vol. 1, No. 5. P. 206–215. DOI: 10.1038/s42256-019-0048-x.
4. Guidotti R., Monreale A., Ruggieri S. et al. A survey of methods for explaining black box models. *ACM Computing Surveys*. 2019. Vol. 51, No. 5. Art. 93. DOI: 10.1145/3236009.
5. Bhatore S., Mohan L., Reddy Y. R. Machine learning techniques for credit risk evaluation: a systematic literature review. *Journal of Banking and Financial Technology*. 2020. Vol. 4. P. 111–138. DOI: 10.1007/s42786-020-00020-3.
6. Cowan N. The magical mystery four: How is working memory capacity limited, and why? *Current Directions in Psychological Science*. 2010. Vol. 19, No. 1. P. 51–57. DOI: 10.1177/0963721409359277.
7. Ribeiro M. T., Singh S., Guestrin C. "Why should I trust you?": Explaining the predictions of any classifier. *Proc. 22nd ACM SIGKDD Int. Conf. Knowledge Discovery and Data Mining*. San Francisco, 2016. P. 1135–1144. DOI: 10.1145/2939672.2939778.
8. Lundberg S. M., Lee S.-I. A unified approach to interpreting model predictions. *Advances in Neural Information Processing Systems*. Vol. 30. Long Beach, 2017. P. 4765–4774.
9. Ribeiro M. T., Singh S., Guestrin C. Anchors: High-precision model-agnostic explanations. *Proc. AAAI Conf. Artificial Intelligence*. Vol. 32, No. 1. New Orleans, 2018. P. 1527–1535. DOI: 10.1609/aaai.v32i1.11491.
10. Ладанюк А. П., Власенко Л. О. Інтелектуальні системи підтримки прийняття рішень в автоматизованих системах управління. *Автоматизація технологічних і бізнес-процесів*. 2022. Т. 14, № 1. С. 4–12. DOI: 10.15673/atbp.v14i1.2298.

References

1. A. B. Arrieta, N. Díaz-Rodríguez, J. Del Ser et al., "Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI," *Information Fusion*, vol. 58, pp. 82–115, 2020. DOI: 10.1016/j.inffus.2019.12.012.
2. S. Lessmann, B. Baensens, H.-V. Seow, and L. C. Thomas, "Benchmarking state-of-the-art classification algorithms for credit scoring: An update of research," *European Journal of Operational Research*, vol. 247, no. 1, pp. 124–136, 2015. DOI: 10.1016/j.ejor.2015.05.030.
3. C. Rudin, "Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead," *Nature Machine Intelligence*, vol. 1, no. 5, pp. 206–215, 2019. DOI: 10.1038/s42256-019-0048-x.
4. R. Guidotti, A. Monreale, S. Ruggieri et al., "A survey of methods for explaining black box models," *ACM Computing Surveys*, vol. 51, no. 5, Art. 93, 2019. DOI: 10.1145/3236009.
5. S. Bhatore, L. Mohan, and Y. R. Reddy, "Machine learning techniques for credit risk evaluation: a systematic literature review," *Journal of Banking and Financial Technology*, vol. 4, pp. 111–138, 2020. DOI: 10.1007/s42786-020-00020-3.
6. N. Cowan, "The magical mystery four: How is working memory capacity limited, and why?" *Current Directions in Psychological Science*, vol. 19, no. 1, pp. 51–57, 2010. DOI: 10.1177/0963721409359277.
7. M. T. Ribeiro, S. Singh, and C. Guestrin, ""Why should I trust you?": Explaining the predictions of any classifier," in *Proc. 22nd ACM SIGKDD Int. Conf. Knowledge Discovery and Data Mining*, San Francisco, CA, USA, 2016, pp. 1135–1144. DOI: 10.1145/2939672.2939778.
8. S. M. Lundberg and S.-I. Lee, "A unified approach to interpreting model predictions," in *Advances in Neural Information Processing Systems*, vol. 30, Long Beach, CA, USA, 2017, pp. 4765–4774.
9. M. T. Ribeiro, S. Singh, and C. Guestrin, "Anchors: High-precision model-agnostic explanations," in *Proc. AAAI Conf. Artificial Intelligence*, vol. 32, no. 1, New Orleans, LA, USA, 2018, pp. 1527–1535. DOI: 10.1609/aaai.v32i1.11491.
10. A. P. Ladaniuk and L. O. Vlasenko, "Інтелектуальні системи підтримки прийняття рішень в автоматизованих системах управління" ["Intelligent decision support systems in automated control systems"], *Автоматизація технологічних і бізнес-процесів*, vol. 14, no. 1, pp. 4–12, 2022. DOI: 10.15673/atbp.v14i1.2298. [in Ukrainian].

Отримана в редакції 05.02.2026. Прийнята до друку 16.02.2026. Розміщено в інтернеті 30 березня 2026.
Received 05 February 2026. Approved 16 February 2026. Available in Internet 30 March 2026