

Вареник В. В.

*аспірант кафедри економіки, фінансів та обліку,
Приватний вищий навчальний заклад «Європейський університет»
м. Київ, Україна*

DOI: <https://doi.org/10.36059/978-966-397-611-2-3>

МЕТРИКИ ОЦІНКИ ПРОДУКТИВНОСТІ МОДЕЛЕЙ МАШИННОГО НАВЧАННЯ В СФЕРІ ФІНАНСОВОГО МОНІТОРИНГУ

Одним з головних завдань суб'єктів первинного фінансового моніторингу є здійснення аналізу фінансових операцій клієнтів та виокремлення транзакцій, які можуть свідчити про відмивання коштів або фінансування тероризму. Така діяльність фінансових установ є неможливою без використання системи автоматизації, яка, в свою чергу, залежить від алгоритмів опрацювання транзакцій. Враховуючи бурхливий розвиток штучного інтелекту, широкого розповсюдження набули моделі фінансового моніторингу, засновані на алгоритмах машинного навчання. Рішення про застосування конкретного алгоритму або варіації декількох алгоритмів в системі автоматизації звітної установи напряму залежить від оцінки продуктивності моделі. Відповідно, ефективна робота алгоритмів машинного навчання оцінюється системою метрик, які найбільш доцільно використовувати при аналізі прогностичних даних моделі.

Першочерговим завданням для використання метрик оцінки моделей машинного навчання є визначення чотирьох показників, які показують кореляцію між прогнозними та фактичними результатами і є елементами матриці помилок моделі. До таких показників належать: істинно-позитивний результат (True Positive – TP); істинно-негативний результат (True Negative – TN), хибно-позитивний результат (False Positive – FP) та хибно-негативний результат (False Negative – FN). У сфері боротьби з відмиванням коштів та фінансуванням тероризму показник TP вказує на кількість елементів, які були правильно класифіковані моделлю як «підозрілі». Показник TN ілюструє кількість фінансових операцій без ознак відмивання коштів, які були правильно визначені в моделі машинного навчання. Хибно-позитивні результати ідентифікують транзакцій, які модель класифікувала, як «підозрілі»,

однак насправді дані операції були легальними транзакціями клієнтів фінансової установи. Хибно-негативні елементи вказують на помилку класифікації, яка допустила проведення злочинної фінансової операції. В науковій літературі для цілей продуктивності моделей машинного навчання широко застосовують метрику загальної точності (Average Accuracy), яка є відношенням правильно ідентифікованих елементів до всіх елементів тестового набору даних [1, с. 4]. Однак для цілей фінансового моніторингу метрика загальної точності буде мати обмежену репрезентативність, оскільки елементи «типових» та «підозрілих» фінансових транзакцій є надзвичайно незбалансованими. В результаті, навіть при слабкій ефективності моделі, Average Accuracy буде мати високе значення.

Для забезпечення об'єктивної оцінки якості моделі машинного навчання в сфері фінансового моніторингу використовують метрики точності (Precision) та повноти (Recall). Метрика Precision розраховується як відношення кількості істинно-позитивних результатів до суми істинно-позитивних та хибно-позитивних результатів. Відповідно, метрика точності показує ймовірність належності фінансових транзакцій, які були обрані моделлю в якості «підозрілих», до дійсно підозрілих операцій відмивання коштів або фінансування тероризму. У випадку реалізації в системі автоматизації фінансової установи моделі з низьким значенням Precision, служба фінансового моніторингу звітної установи буде отримувати багато хибних заявок на ручну обробку фінансових операцій, які, в результаті, виявляться легальними транзакціями. Однак, зростання показників метрики точності може свідчити про надмірну обережність моделі, яка ідентифікує лише явні випадки відмивання коштів, залишаючи непоміченими новітні або більш складні нелегальні схеми. Для більш об'єктивного аналізу значення Precision порівнюють зі значенням метрики повноти (Recall), яке визначається, як співвідношення істинно-позитивних результатів до суми істинно-позитивних та хибно-негативних результатів [2, с. 285]. В цілях фінансового моніторингу Recall ідентифікує частку фактичних нелегальних операцій, які вдалося виявити моделі машинного навчання. Високе значення метрики повноти означає, що модель здатна виявляти навіть слабкі ознаки підозрілої фінансової активності клієнтів. Разом з тим, для підвищення значення Recall звітній установі потрібно аналізувати більшу кількість фінансових операцій, що автоматично буде означати зростання кількості хибно-позитивних співпадінь.

В ролі арбітра між максимізацією метрик точності та повноти застосовується метрика F1-score, яка є відношенням подвійної кількості істинно-позитивних подій до добутку подвійної кількості істинно-позитивних подій, кількості хибно-позитивних подій та кількості хибно-негативних подій [3, с. 6]. Дана метрика досягає максимального значення лише у випадку високих та збалансованих результатів як точності (Precision), так і повноти (Recall). Відповідно, суб'єктам первинного фінансового моніторингу варто порівняти результати значень метрики F1-score для різних моделей машинного навчання та віддати пріоритет впровадження тим моделям, що мають найвищий показник даної метрики. Виключенням можуть бути ситуації, коли фінансова установа оцінює ризик пропущення нелегальної операції занадто високим, що є характерним для операцій з політично-значущими особами, співпадінням з санкційними списками чи фінансуванням тероризму. Для вищевказаних ситуацій, після стратифікації транзакцій відбувається збільшення питомої ваги метрики Recall, враховуючи ризик-апетит фінансової установи.

Іншою важливою метрикою оцінки продуктивності моделі машинного навчання є побудова кривої, що заснована на визначенні площі під робочою характеристикою приймача (Area Under the Receiver Operating Characteristic – AUC-ROC). Крива будується в координатах TPR (відношення коефіцієнту істинно-позитивних співпадінь до метрики повноти) та FPR (коефіцієнт хибно-позитивних співпадінь) [3, с. 6]. Значення кривої може варіюватися від «0,5», що вказує на повну неефективність моделі, до «1,0», що вказує на ідеальну модель для цілей класифікації даних. Однак, враховуючи незбалансованість даних для цілей фінансового моніторингу, AUC-ROC може завищувати фактичну продуктивність моделі, оскільки велика кількість «звичайних» фінансових операцій призводить до зменшення значення коефіцієнту хибно-позитивних співпадінь, який буде завжди близьким до нуля. Відповідно, метрика AUC-ROC може приймати значення, близьке до «1,0», однак модель генеруватиме значну кількість хибно-позитивних сигналів.

Здійснення фінансовою установою комплексного аналізу моделей машинного навчання, використовуючи матрицю помилок та метрики точності, повноти, F1-score та AUC-ROC дозволить об'єктивно оцінити продуктивність моделей та впровадити в систему автоматизації суб'єктів первинного фінансового моніторингу алгоритми, які будуть здійснювати

ефективну ідентифікацію підозрілих транзакцій та враховувати встановлений ризик-апетит установи у сфері фінансового моніторингу.

Література:

1. Zhang, Z. Introduction to machine learning: k-nearest neighbors. *Annals of Translational Medicine*. 2016. №4 (11). P. 218. DOI: <https://doi.org/10.21037/atm.2016.03.37>
2. Hampo J. A. C., Nwokorie E. C., Odii J. N. A Web-Based kNN Money Laundering Detection System. *European Journal of Theoretical and Applied Sciences*. 2023. № 1 (4). P. 277–288. DOI: [https://doi.org/10.59324/ejtas.2023.1\(4\).27](https://doi.org/10.59324/ejtas.2023.1(4).27)
3. Abbad Ur Rehman, H., Lin, C. Y., Mushtaq, Z. Effective K-nearest neighbor algorithms performance analysis of thyroid disease. *Journal of the Chinese Institute of Engineers*. 2021. № 44 (1). P. 77–87. DOI: <https://doi.org/10.1080/02533839.2020.1831967>