

СИСТЕМА ПІДТРИМАННЯ ПРИЙНЯТТЯ РІШЕНЬ ДЛЯ ОЦІНЮВАННЯ ТА ПРОГНОЗУВАННЯ СТАНУ СТРАХОВОЇ КОМПАНІЇ

Р.С. ПАНІБРАТОВ

Анотація. Створено систему підтримання прийняття рішень для оцінювання та прогнозування стану страхової компанії за її фінансово-економічними показниками. Оцінювання стану даної установи розглянуто як задачу бінарної класифікації: чи є діяльність компанії ефективною чи ні. Під час дослідження реалізовано шість методів машинного навчання з учителем: метод k -найближчих сусідів, метод опорних векторів, наївний байєсівський класифікатор, випадковий ліс, XGBoost та глибоку нейронну мережу. Створена система дозволяє: виконувати кореляційний аналіз фінансово-економічних показників, перевіряти збалансованість даних, навчати обрану модель та оцінювати якість навчання, прогнозувати стан страхової компанії за обраною моделлю. За найкращими моделями спрогнозовано майбутній стан страхових компаній України.

Ключові слова: страхова компанія, система підтримання прийняття рішень, бінарна класифікація, метод k -найближчих сусідів, метод опорних векторів, наївний байєсівський класифікатор, випадковий ліс, градієнтний бустинг, нейронні мережі.

ВСТУП

Процес формування ринкової економіки будь-якої країни включає в себе надійний страховий захист суб'єктів господарювання. Саме це спонукає до пошуку ефективних засобів мобілізації фінансових ресурсів страхових компаній та їх цілеспрямованого використання. Для забезпечення надійності виконання зобов'язань даний тип установи має ефективно формувати та використовувати фінансові ресурси. Надійний захист суб'єктів господарювання потребує застосування ефективних механізмів мобілізації фінансових ресурсів страхових компаній та їх безпосереднього використання.

Натепер наявні ефективні математичні методи оцінювання фінансових ризиків у страхуванні. Наприклад, стандарт Basel II та Solvency I заохочують розвиток моделей управління та оцінювання ризиків фінансової сфери.

Розрізняють два засоби аналізу ризиків — за позицією факторів ризику та за позицією наслідків ризикової події. За таким підходом математичні методи оцінювання ризиків поділяють на дві групи: методи, що ґрунтуються на аналізі наслідків («високорівневі моделі»), та методи, що ґрунтуються на

аналізі факторів ризику («низькорівневі моделі»). До першої групи належать моделі ВІА, LDA та ІМА. Такі методи не можна використовувати для розподілу ризиків за рівнем критичності та знаходження подій, що ведуть до реалізації ризику. Друга група охоплює такі методи, як регресійний аналіз, байєсівські мережі та методи нечіткої логіки. Ці методи навпаки можуть вирішувати такі завдання, але мають певні обмеження. Так, регресійні моделі гарантують високу точність оцінювання тільки за умови достатньо великих обсягів даних. Байєсівські мережі дозволяють враховувати прямі залежності рівнів ризиків від чинників ризику і залежності між чинниками ризику, але обчислення умовних імовірностей є доволі трудомісткими.

Сьогоднішні теорії інформаційних технологій та бізнес-менеджменту і принципи побудови інтелектуальних систем вимагають того, щоб мета створення системи базувалася на цілеспрямованій та усвідомленій людській діяльності. До нинішніх напрямів розроблення людино-машинних систем належать системи автоматичного керування, експертні системи та системи підтримання прийняття рішень (СППР). Остання є найефективнішим засобом вирішення багатьох завдань [1]. Завдяки їй, особа, що приймає рішення, може, застосовуючи обчислювальні засоби, проектувати, порівнювати та вибрати альтернативні варіанти рішень найрізноманітнішими засобами.

Мета роботи — розроблення та створення СППР, що дозволяє оцінити і прогнозувати майбутній стан страхової компанії за її статистично-економічними даними. Вона розглядалася як задача бінарної класифікації, тобто прогнозування ефективності діяльності компанії.

МАТЕМАТИЧНІ МЕТОДИ ОЦІНЮВАННЯ СТАНУ СТРАХОВОЇ КОМПАНІЇ

Для оцінювання та прогнозування стану страхових компаній реалізовано шість моделей класифікації: k -найближчих сусідів, метод опорних векторів, наївний байєсівський класифікатор, випадковий ліс, XGBoost та багатошаровий перцептрон.

Метод k -найближчих сусідів

Метод k -найближчих сусідів — метричний алгоритм для задачі автоматичної класифікації об'єктів або регресії. У випадку задачі класифікації результатом є належність об'єкта до відповідного класу. Об'єкт класифікується множиною голосів його сусідів, причому об'єкт відносять до класу, який є найбільш поширеним серед k -найближчих сусідів. Параметр k — константа і задається користувачем. Вектор ознак без мітки класифікується за допомогою присвоєння мітки, яка найчастіше зустрічається серед k тренувальних зразків, що найближче розташовані до цієї точки.

Для дослідження розглядалися три найближчі сусіди та використовувалася евклідова метрика відстані, оскільки такі параметри забезпечували найвищий результат.

Метод опорних векторів

Метод опорних векторів — метод навчання з учителем, що використовується як для задачі класифікації, так і для регресії. Надається набір навчальних зразків з позначенням належності до одного з двох класів. Алгоритм будує модель, що призначає кожен новий зразок до однієї чи іншої категорії, створюючи її як найімовірніший бінарний лінійний класифікатор. Метод опорних векторів відображає навчальні зразки в точки у просторі, максимізуючи

при цьому ширину проміжку між двома категоріями. Нові зразки у цьому випадку відображаються у той же простір і прогнозується їх належність до певного класу залежно від того, на який бік проміжку вони потрапляють.

У формальному сенсі метод опорних векторів буде гіперплощину або множину гіперплощин у багатовимірному чи нескінченновимірному просторі. Придатне ділення даних досягається за рахунок гіперплощини, що має найбільшу відстань найближчих тренувальних зразків будь-якого класу (функціональна маржа), оскільки чим більша маржа, тим менша узагальнена помилка класифікатора.

Наївний байєсівський класифікатор

Наївний байєсівський класифікатор — простий імовірнісний класифікатор, який ґрунтується на застосуванні теореми Байєса з наївним припущенням щодо незалежності ознак. Для оцінювання параметрів моделей використовується метод максимальної правдоподібності, тобто працюючи з наивною байєсівською моделлю, можна і не знати теорії байєсівської ймовірності і не використовувати байєсівські методи.

Імовірнісна модель класифікатора — це модель вигляду $p(L|F_1, \dots, F_n)$ залежної змінної класу L з невеликою кількістю класів, що залежить від змінних F_1, \dots, F_n .

Використовуючи теорему Байєса, запишемо ймовірність:

$$p(L|F_1, \dots, F_n) = \frac{p(L)p(F_1, \dots, F_n|L)}{p(F_1, \dots, F_n)}.$$

Чисельник являє собою еквівалентність формули спільної ймовірності моделі вигляду $p(L, F_1, \dots, F_n)$, яку можна, використовуючи повторне застосування визначення умовної ймовірності, переписати у вигляді

$$p(L, F_1, \dots, F_n) = p(L)p(F_1|L)p(F_2|L, F_1) \dots.$$

Застосуємо наївні припущення щодо умовної незалежності: нехай кожна ознака F_i умовно незалежна від будь-якої іншої ознаки F_j , якщо $i \neq j$, тобто

$$p(F_i|L, F_j) = p(F_i|L).$$

Звідси спільну модель можна подати так:

$$p(L, F_1, \dots, F_n) = p(L)p(F_1|L)p(F_2|L) \dots p(F_n|L) = p(C) \prod_{i=1}^n p(F_i|L).$$

Відповідно до припущення про незалежності ознак імовірність за міткою класу

$$p(L|F_1, \dots, F_n) = \frac{1}{p(F_1, \dots, F_n)} p(L) \prod_{i=1}^n p(F_i|L).$$

Випадковий ліс

Випадковий ліс — алгоритм машинного навчання, який застосовується для задач регресії та класифікації. Він використовує ансамблеве навчання — метод, що комбінує велику кількість класифікаторів для вирішення складних проблем. Алгоритм випадкового лісу складається з множини дерев рішень. Ліс, згенерований даним алгоритмом, навчається за допомогою беггінгу — ансамблевого металагоритму, що покращує точність алгоритмів машинного навчання за рахунок усереднення результатів [2]. Метод установлює результати на основі прогнозів дерев рішень.

Головна відмінність алгоритму випадкового лісу від алгоритму дерева рішення полягає в тому, що встановлення кореневих вузлів і відокремлення вузлів відбуваються випадково у першому випадку. Метод використовує беггінг для генерації необхідних прогнозів. Беггінг включає використання різних наборів даних з навчальної вибірки частіше ніж один. Навчальна вибірка складається зі спостережень та ознак, що використовуються для прогнозів. Дерева рішень дають різні результати залежно від навчальних даних, що подаються до алгоритму. Результати ранжируються, а прогноз з найвищою оцінкою обирається як кінцевий результат.

Для задачі класифікації вибір остаточного результату відбувається за допомогою системи мажоритарного голосування. Вихід, обраний більшістю дерев рішень, стає кінцевим результатом випадкового лісу.

XGBoost

Бустинг — це підхід, що комбінує множину простих моделей у єдину композиційну модель. Із додаванням більш простих моделей загальна модель перетворюється у сильний предиктор. За термінологією бустингу прості моделі називаються слабкими моделями.

Гradientний бустинг перевизначає бустинг як проблему числової оптимізації, у якій задача полягає у мінімізації функції втрат моделі за рахунок слабких моделей з використанням алгоритму gradientного спуску. Оскільки gradientний бустинг ґрунтується на мінімізації функції втрат, можуть використовуватися різні функції втрат, що можна застосовувати для задач регресії, класифікації тощо.

Gradientний бустинг — покорова адитивна модель, що генерує навчальні моделі протягом процесу навчання (додається одне дерево за один крок, дерева, що існують, у моделі не змінюються). Внесок слабкої моделі навчання до ансамблю ґрунтується на оптимізаційному процесі gradientного спуску. Розрахований внесок кожного дерева базується на мінімізації загальної помилки сильної моделі.

XGBoost — один з найбільш популярних варіантів gradientного бустингу. Це ансамблевий алгоритм машинного навчання, який базується на деревах рішень. Він використовує попередньо відсортований алгоритм та алгоритм на основі гістограми для обчислення найкращого поділу. Алгоритм на основі гістограм розбиває точки даних для ознаки на дискретні інтервали і використовує ці інтервали для знаходження значення поділу гістограми.

Багат шаровий персептрон

Це глибока штучна нейронна мережа, що складається із вхідного шару для отримання сигналу, вихідного шару для прийняття рішень або передбачення щодо вхідного сигналу, а між ними — довільна кількість шарів, які являють собою обчислювальну основу багат шарового персептрона.

Архітектура нейронної мережі, що була створена для оцінювання стану страхових компаній, складалася з чотирьох прихованих шарів, де перший шар містив чотири нейрони, решта — вісім. Такої кількості достатньо для вирішення завдання оцінювання. Як функцію активації для прихованих шарів використовувалася функція гіперболічного тангенса:

$$f(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}.$$

Оскільки розглядалася задача бінарної класифікації, то для вихідного шару нейронної мережі використовувалася функція «сигмоїд»:

$$f(x) = \frac{1}{1 + e^{-x}}.$$

Для навчання мережі як алгоритму оптимізації використовувався метод Adam, а для навчання башатозарового перцептрона — методи: batch normalization (пакетне нормування) і dropout (вилучення).

Batch normalization (пакетне нормування). Цей метод дає змогу підвищити продуктивність навчання і стабілізувати роботу штучних нейронних мереж. Суть методу полягає у тому, що деяким шарам нейронної мережі на вхід подаються уже оброблені дані, що мають нульове математичне сподівання та одиничну дисперсію.

За рахунок пакетного нормування досягається більш швидка збіжність моделей, незважаючи на додаткові обчислення. Цей підхід дозволяє кожному шару мережі навчатися більш незалежно від інших шарів. Також виникає можливість використання більш високої швидкості навчання, оскільки пакетне нормування гарантує, що виходи вузлів нейронної мережі не матимуть дуже великих чи малих значень. Крім того, метод є в деякому сенсі окремим механізмом регуляризації: такий підхід привносить у виходи прихованих шарів деякий шум. Моделі стають менш чутливими до початкової ініціалізації ваг.

Нехай навчання моделі проводиться за допомогою пакетів B розмірністю n]:

$$B = \{x_1, \dots, x_n\}.$$

Алгоритм пакетної нормалізації складається з таких кроків:

1. Обчислюється математичне сподівання і дисперсія пакета за формулами:

$$\mu_B = \frac{1}{n} \sum_{i=1}^n x_i; \quad \sigma_B^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \mu_B)^2.$$

2. Нормалізуються дані пакета:

$$\hat{x}_i = \frac{x_i - \mu_B}{\sqrt{\sigma_B^2 + \varepsilon}},$$

де ε — константа, яка використовується для обчислювальної стійкості (налаштовується разом з іншими параметрами).

3. Застосовується операція стиску та зсуву:

$$y_i = \gamma \hat{x}_i + \beta$$

де γ — параметр стиску; β — параметр зсуву.

Ці параметри налаштовуються перед початком навчання мережі.

Dropout (вилучення). Однією з проблем, яка виникає під час будови нейронної мережі, є явище перенавчання. Метод вилучення — один з найбільш поширених засобів уникнення цієї проблеми завдяки простому алгоритму та задовільним результатам [4].

Розглянемо шар нейронної мережі, що складається з N нейронів.

Даний підхід вимикає нейрон з імовірністю p відповідно, залишає увімкненим з імовірністю $q = 1 - p$, причому ймовірність вимкнення будь-якого нейрона однакова.

Нехай $f(x)$ — функція активації, тоді застосування дропауту для i -го нейрона записується таким чином:

$$U_i = \theta_i f\left(\sum_{j=1}^N w_j x_j + b\right),$$

де w_j — ваги нейрона; b — зміщення; x_j — вхідні дані, а ймовірність $P(\theta_i = 0) = p$. Ця формула використовується під час навчання моделі. Але оскільки на даному етапі нейрон залишається в мережі з імовірністю q , то на етапі тестування потрібно емулювати поведінки нейронної мережі, що була використана під час навчання. Для цього результат вихідного значення функції активації необхідно помножити на коефіцієнт q :

$$U_i = q f\left(\sum_{j=1}^N w_j x_j + b\right).$$

На практиці також використовують техніку зворотного дропауту. На відміну від звичайного методу, множення на коефіцієнт відбувається у процесі навчання, причому цей коефіцієнт дорівнює імовірності того, що нейрон залишиться в мережі. А під час тестування значення нейрона залишається таким самим, як і в методі зворотного поширення помилки.

Тобто вихідне значення i -го нейрона на етапі навчання

$$U_i = \frac{1}{q} \theta_i f\left(\sum_{j=1}^N w_j x_j + b\right),$$

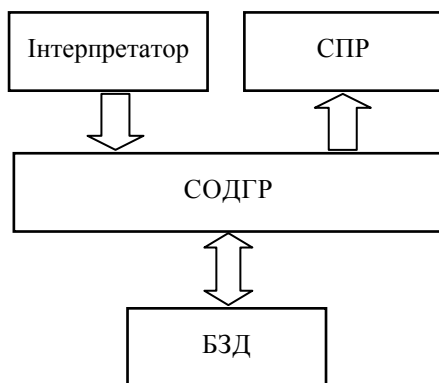
а на етапі тестування

$$U_i = f\left(\sum_{j=1}^N w_j x_j + b\right).$$

АРХІТЕКТУРА І СХЕМА ФУНКЦІОНУВАННЯ СППР

Архітектуру СППР, розроблену для оцінювання стану страхових компаній, зображено на рис. 1.

Компоненти архітектури виконують такі функції:



– інтерпретатор відповідає за безпосереднє завантаження даних джерела інформації. Як дані завантажуються файли формату *.XLSX;

– СОДГР або система оброблення даних та генерації результатів відповідає за візуалізацію даних за допомогою графіків;

– БЗД або база даних і знань відповідає за забезпечення оцінювання стану страхової компанії. Програма відображає значення метрик якості навчання моделей класифікації;

Рис. 1. Архітектура СППР

– СПР або система подання проміжних та остаточних результатів обчислень, дозволяє подавати результати. Програма забезпечує відображення прогнозу майбутнього стану страхової компанії та можливі причини в разі негативної оцінки стану.

Схему роботи СППР показано на рис. 2.

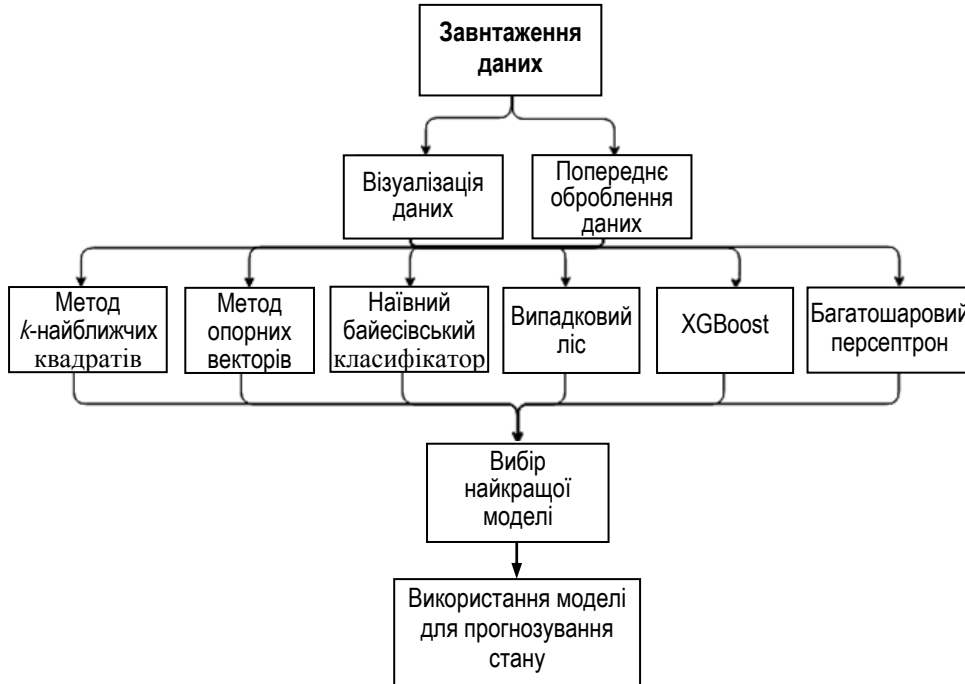


Рис. 2. Схеми функціонування СППР

ДАНІ ДЛЯ ДОСЛІДЖЕННЯ

Для дослідження роботи програми як дані взято основні показники діяльності страхових компаній (у розрізі установ), відповідно до Постановки Кабінету Міністрів України № 835 із сайту Національного банку України. Як навчально-валідаційну вибірку використано показники за 2020 р. (185 компаній), а як тестову вибірку — показники за перше півріччя 2021 року (166 компаній). Мітка оцінки діяльності для навчання моделі заповнювалася у такий спосіб: обчислювалася рентабельність капіталу страхової компанії у відсотках. Якщо цей показник перевищував 10% [5], то компанії присвоювалася оцінка «ефективна», інакше — «неефективна». Кореляційну матрицю фінансових показників та графік страхових компаній за оцінкою діяльності за навчально-валідаційною вибіркою зображено відповідно на рис. 3 і 4.

За кореляційною матрицею видно, що показник збитків до та після оподаткування є некорельованими. Під час дослідження розглядався випадок повної вибірки та скороченої (без урахування збитків). Дані є незбалансованими, оскільки кількість страхових компаній з ефективною діяльністю становить лише 24%.

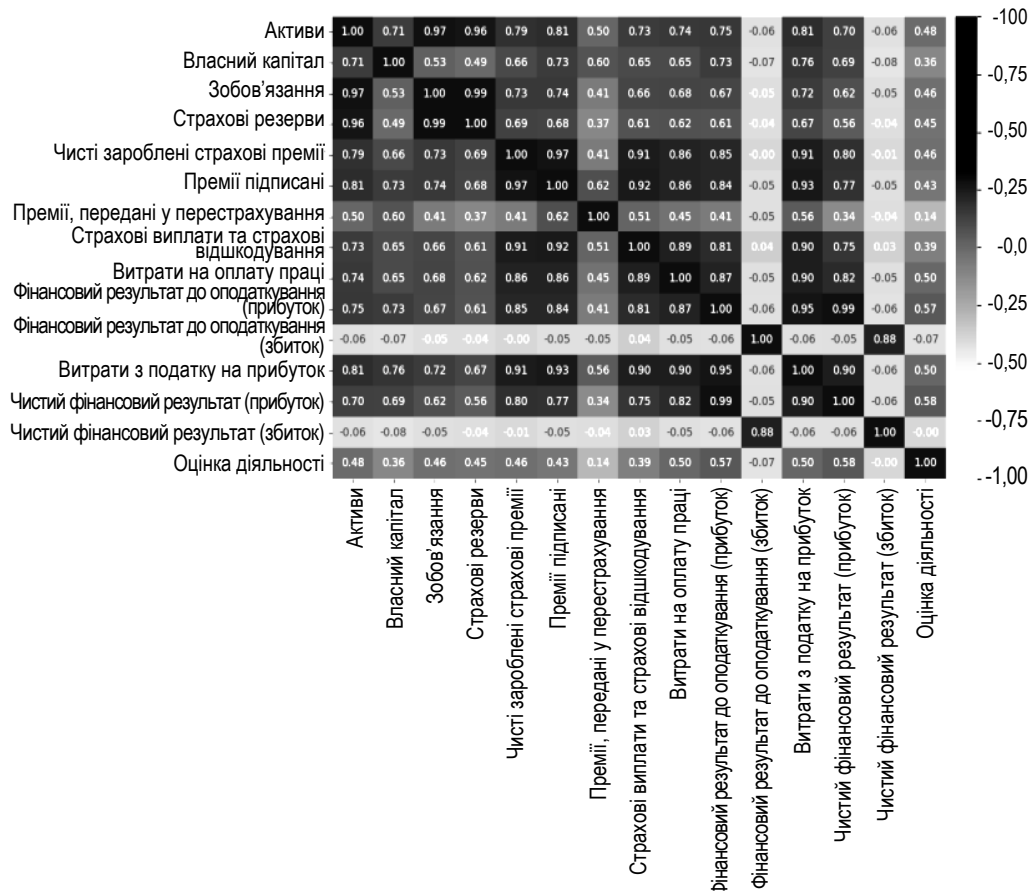


Рис. 3. Кореляційна матриця даних

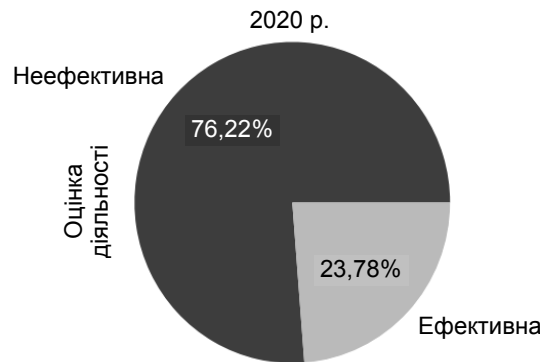


Рис. 4. Графік страхових компаній за оцінкою діяльності за 2020 р.

РЕЗУЛЬТАТИ ДОСЛІДЖЕННЯ

Для проведення дослідів навчально-валідаційна вибірка розбивалася за співвідношенням 60:40. Тренувальна вибірка мала розмірність 111, валідаційна — 74. Для оцінювання якості моделей використовувалися метрики F1-Score, Roc-Auc, Balanced Accuracy.

Результати навчання моделей наведено в табл. 1 і 2. Також будувалася матриця похибок для кожної моделі.

Таблиця 1. Результати навчання моделей класифікації для повного набору даних

| Модель | F1-Score | Roc-Auc | Balanced Accuracy |
|-----------------------------------|----------|---------|-------------------|
| <i>k</i> -найближчих сусідів | 0,91 | 0,92 | 0,92 |
| Метод опорних векторів | 0,76 | 0,81 | 0,94 |
| Наївний байєсівський класифікатор | 0,69 | 0,78 | 0,83 |
| Випадковий ліс | 0,94 | 0,94 | 0,94 |
| XGBoost | 0,91 | 0,94 | 0,94 |
| Багатошаровий перцептрон | 0,91 | 0,92 | 0,92 |

Таблиця 2. Результати навчання моделей класифікації для скороченого набору даних.

| Модель | F1-Score | Roc-Auc | Balanced Accuracy |
|-----------------------------------|----------|---------|-------------------|
| <i>k</i> -найближчих сусідів | 0,91 | 0,94 | 0,94 |
| Метод опорних векторів | 0,86 | 0,9 | 0,9 |
| Наївний байєсівський класифікатор | 0,77 | 0,86 | 0,86 |
| Випадковий ліс | 0,86 | 0,95 | 0,95 |
| XGBoost | 0,88 | 0,96 | 0,96 |
| Багатошаровий перцептрон | 0,95 | 0,98 | 0,99 |

Матриці похибок моделей для випадку повної та скороченої вибірок показано на рис. 5 і 6.

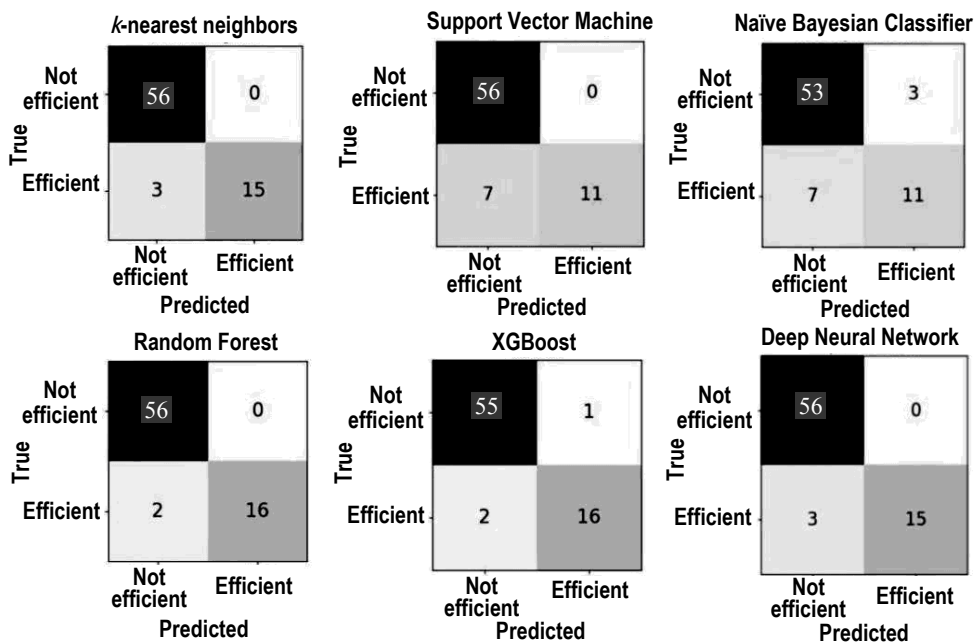


Рис. 5. Матриці похибок моделі за повного набору даних

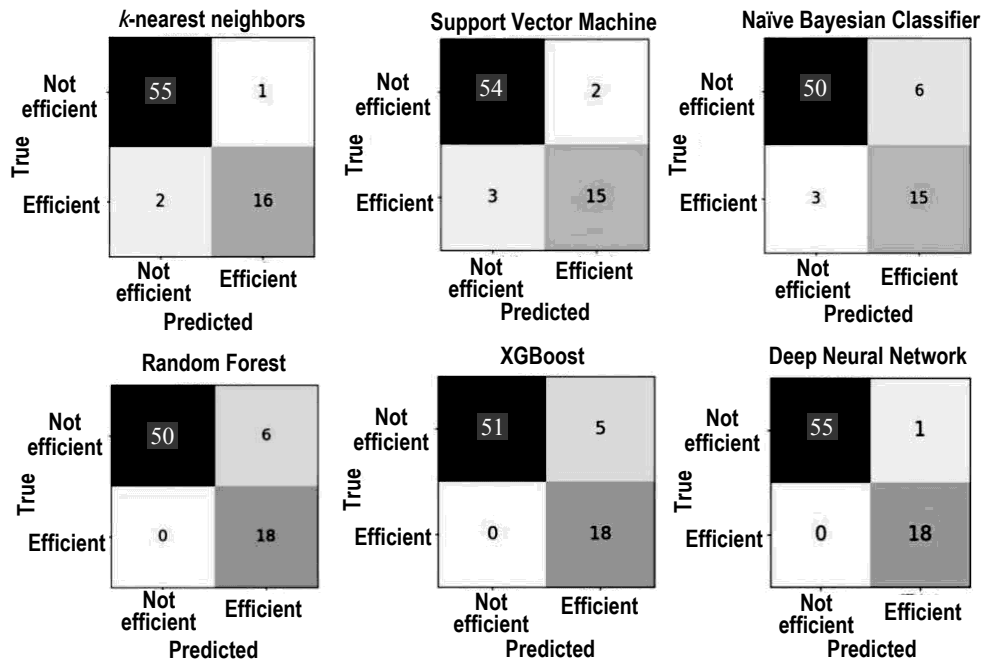


Рис. 6. Матриці похибок моделі за скороченого набору даних

Діаграму розподілу страхових компаній за прогножною оцінкою стану зображено на рис. 7.




Рис. 7. Графік страхових компаній за спрогнозованою оцінкою діяльності

За результатами таблиць можна бачити, що модель випадкового лісу показала найкращі результати серед усіх моделей. За скороченого набору даних метрики якості усіх моделей покращилися. Водночас багатосаровий перцептрон продемонстрував майже ідеальні результати — його точність становила 99%. За матрицями наочно видно, що за повного набору даних найкращі результати має модель випадкового лісу. За скороченого набору даних для моделі *k*-найближчих сусідів, опорних векторів та наївного байєсівського класифікатора зменшилася кількість помилково-негативних оцінок, але збільшилася кількість помилково-позитивних оцінок. При цьому модель випадкового лісу, XGBoost та нейронної мережі взагалі не містили помилково-негативних оцінок. Для скороченого набору даних багатосаровий перцептрон показав майже безпомилкові результати. Тому, вибираючи

найкращу модель для оцінювання та прогнозування страхових компаній, користувач має вирішити чи вводити показники збитків під час навчання моделей чи не вводити.

ВИСНОВКИ

Створено систему підтримання прийняття рішення, що дозволяє оцінити та спрогнозувати стан страхової компанії за її фінансово-економічними показниками. Для оцінювання та прогнозування стану страхових компаній реалізовано шість моделей класифікації: k -найближчих сусідів, метод опорних векторів, наївний байєсівський класифікатор, випадковий ліс, XGBoost та багат шаровий перцептрон. За результатами дослідження зроблено висновок, що у випадку повної вибірки модель випадкового лісу показала найкращі результати. Водночас багат шаровий перцептрон показав майже ідеальні результати, навчаючись за скороченою вибіркою. Тому, вибираючи найкращу модель для оцінювання та прогнозування страхових компаній, потрібно прийняти рішення щодо того, чи використовувати показники збитків під час навчання моделей чи не використовувати, оскільки вони некорельовані.

У подальших дослідженнях доцільно розглянути задачу побудови комерційної системи підтримання прийняття рішень з функціями ретроспективного аналізу попередніх сесій використання системи, а також адаптації моделей, що використовуються для класифікації досліджуваних об'єктів.

ЛІТЕРАТУРА

1. О.С. Олексюк, *Системи підтримки прийняття фінансових рішень*. К.: Наук. думка, 1998, 508 с.
2. J. Ali, R. Khan, N. Ahmad, and I. Maqsood, "Random Forests and Decision Trees", *International Journal of Computer Science Issues (IJCSI)*, vol. 9, no. 3, pp. 272–278, 2012.
3. S. Ioffe and C. Szegedy, "Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift", *ICML*, vol. 37, pp. 448–456, 2015.
4. N. Srivatsava et al., "Dropout: A Simple Way to Prevent Neural Networks from Overfitting", *Journal of Machine Learning Research*, vol. 15, pp. 1929–1958, 2014.
5. А.А. Шірінян та Л.В. Шірінян, "Показники ефективності страхового ринку України з позицій власників страхових компаній", *Ефективна економіка*, № 10, 2019. doi: 10.32702/2307-2105-2019.10.172

Надійшла 12.01.2022

INFORMATION ON THE ARTICLE

Roman S. Panibratov, ORCID: 0000-0002-8604-4420, Institute for Applied System Analysis of the National Technical University of Ukraine "Igor Sikorsky Kyiv Polytechnic Institute", Ukraine, e-mail: roman.panibratov@gmail.com

СИСТЕМА ПОДДЕРЖКИ ПРИНЯТИЯ РЕШЕНИЙ ДЛЯ ОЦЕНИВАНИЯ И ПРОГНОЗИРОВАНИЯ СОСТОЯНИЯ СТРАХОВОЙ КОМПАНИИ /
Р.С. Панибратов

Аннотация. Создано систему поддержки принятия решений для оценивания и прогнозирования состояния страховой компании за её финансово-экономическими показателями. Оценивание состояния данного учреждения рассмотрено как задачу бинарной классификации: является ли деятельность страховой компании эффективной или нет. Во время исследования реализованы шесть методов машинного обучения с учителем: метод k -ближайших соседей, метод опорных векторов, наивный байесовский классификатор, случайный лес, XGBoost и глубокая нейронная сеть. Созданная система позволяет: выполнить корреляционный анализ финансово-экономических показателей, проверять сбалансированность данных, обучать выбранную модель и оценивать качество обучения, прогнозировать состояние страховой компании по выбранной модели. По лучшим моделям спрогнозировано будущее состояние страховых компаний Украины.

Ключевые слова: страховая компания, система поддержки принятия решений, бинарная классификация, метод k -ближайших соседей, метод опорных векторов, наивный байесовский классификатор, случайный лес, градиентный бустинг, нейронные сети.

DECISION SUPPORT SYSTEM FOR ESTIMATING AND FORECASTING STATE OF INSURANCE COMPANY / R.S. Panibratov

Abstract. The decision support system was created for estimating and forecasting the state of an insurance company according to its financial and economic indicators. The task of estimating the state of this type of an institution was considered as a problem of a binary classification: whether the company's activity is efficient or not. During the research, six supervised machine learning methods were implemented: k -nearest neighbors, support vector machine, naive Bayes classifier, random forest, XGBoost and deep neural network. The created system allows the following: to perform correlation analysis of financial and economic indicators, to check the balance of data, to perform training of the selected model and to estimate quality of training, to predict the state of the insurance company according to the selected model. According to the best model, the future state of insurance companies in Ukraine was predicted.

Keywords: insurance company, decision support system, binary classification, k -nearest neighbors, support vector machine, naive Bayes classifier, random forest, gradient boosting, neural networks.

REFERENCES

1. O.S. Oleksiuk, *Financial Decision Support Systems*, (in ukr.). Kyiv: Naukova Dumka, 1998, 508 p.
2. J. Ali, R. Khan, N. Ahmad, and I. Maqsood, "Random Forests and Decision Trees", *International Journal of Computer Science Issues (IJCSI)*, vol. 9, no. 3, pp. 272–278, 2012.
3. S. Ioffe and C. Szegedy, "Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift", *ICML*, vol. 37, pp. 448–456, 2015.
4. N. Srivatsava et al., "Dropout: A Simple Way to Prevent Neural Networks from Overfitting", *Journal of Machine Learning Research*, vol. 15, pp. 1929–1958, 2014.
5. A.A. Shirinyan and L.V. Shirinyan, "Efficiency indicators of ukrainian insurance market from the position of owners of insurance companies", *Efektivna ekonomika*, vol. 10, 2019. doi: 10.32702/2307-2105-2019.10.172