

СИРОВЕТНИК БОГДАН

Національний університет "Львівська політехніка"

<https://orcid.org/0009-0003-7246-0727>e-mail: [bohdan.y.syrovetnyk@lpnu.ua](mailto:bohdan.y.syrovetnyk@lpnu.ua)

КІСЬ ЯРОСЛАВ

Національний університет "Львівська політехніка"

<https://orcid.org/0000-0003-3421-2725>e-mail: [yaroslav.p.kis@lpnu.ua](mailto:yaroslav.p.kis@lpnu.ua)

ХУДИЙ АНДРІЙ

Національний університет "Львівська політехніка"

<https://orcid.org/0000-0003-2029-7270>e-mail: [andrii.m.khudyi@lpnu.ua](mailto:andrii.m.khudyi@lpnu.ua)

## МОДЕЛІ ГЛИБИННОГО НАВЧАННЯ ДЛЯ ПРОГНОЗУВАННЯ КРЕДИТНОГО РИЗИКУ: ПОРІВНЯЛЬНИЙ АНАЛІЗ З ТРАДИЦІЙНИМИ МЕТОДАМИ

У сучасному середовищі управління фінансовими ризиками прогнозування кредитного ризику відіграє ключову роль у прогнозуванні ймовірності несплати позичальниками своїх платежів. З появою технологій моделі глибокого навчання стали багатообіцяючим підходом до оцінки кредитного ризику, пропонуючи розширені можливості для аналізу складних моделей у даних. Це есе заглибиться в сферу прогнозування кредитного ризику, забезпечуючи порівняльний аналіз між моделями глибокого навчання та традиційними методами, проливаючи світло на їх теоретичні основи та методи попередньої обробки даних.

Прогнозування кредитного ризику передбачає оцінку ймовірності несплати позичальником кредиту або кредитної лінії. Цей процес має вирішальне значення для прийняття фінансовими установами обґрунтованих рішень щодо кредитування та стратегій зменшення ризиків. Моделі глибокого навчання, підмножина методів машинного навчання, набули популярності в останні роки завдяки їхній здатності витягувати складні шаблони з великих наборів даних. Використовуючи штучні нейронні мережі, моделі глибокого навчання можуть фіксувати нелінійні зв'язки та залежності в даних, пропонуючи підвищену точність прогнозування порівняно з традиційними статистичними методами.

Традиційні методи прогнозування кредитного ризику охоплюють низку статистичних підходів, таких як логістична регресія, дерева рішень та дискримінантний аналіз. Ці методи ґрунтуються на попередньо визначених математичних моделях і статистичних припущеннях для оцінки кредитоспроможності. Незважаючи на те, що традиційні методи широко використовувалися у фінансовій галузі протягом десятиліть, їм може бути важко вловити складні та нелінійні зв'язки, присутні в сучасних наборах фінансових даних. Навпаки, моделі глибокого навчання можуть автоматично навчатися та адаптуватися до базових шаблонів у даних без необхідності явного програмування правил.

Теоретична основа моделей глибокого навчання обертається навколо штучних нейронних мереж, які створені за структурою та функціонуванням людського мозку. Ці мережі складаються з взаємопов'язаних шарів нейронів, які обробляють і перетворюють вхідні дані за допомогою зв'язаних зв'язків. Алгоритм зворотного поширення є ключовим компонентом навчання нейронних мереж, що дозволяє їм оптимізувати свої параметри на основі різниці між прогнозованими та фактичними результатами. Цей ітеративний процес навчання дозволяє моделям глибокого навчання постійно покращувати ефективність виконання завдань прогнозування кредитного ризику.

Навпаки, традиційні методи, такі як регресійний аналіз і моделі дерева рішень, покладаються на заздалегідь визначені математичні функції для моделювання зв'язку між вхідними змінними та результатом кредитного ризику. Наприклад, регресійний аналіз оцінює вплив кожної змінної-прогнозу на цільову змінну, надаючи розуміння значущості різних факторів в оцінці кредитного ризику. Моделі дерева рішень, з іншого боку, розбивають дані на ієрархічні вузли рішень на основі значень ознак, пропонуючи інтерпретовану структуру для прогнозування кредитного ризику.

**Ключові слова:** Глибинне навчання, Кредитний ризик, Прогнозування, Нейронні мережі, Традиційні методи, Логістична регресія, Дерева рішень, Метод опорних векторів, Ефективність моделей, Обробка даних, Моделювання ризику, Інтерпретація результатів, Практичне застосування, Масштабованість, Аналіз помилок.

SYROVETNYK BOHDAN, KIS YAROSLAV, KHUDIYI ANDRII

Lviv Polytechnic National University

## DEEP LEARNING MODELS FOR PREDICTION OF CREDIT RISK: COMPARATIVE ANALYSIS WITH TRADITIONAL METHODS

In the modern environment of financial risk management, credit risk prediction plays a crucial role in forecasting the probability of borrowers defaulting on their payments. With the advent of technology, deep learning models have emerged as a promising approach to credit risk assessment, offering enhanced capabilities for analyzing complex patterns in data. This essay delves into the realm of credit risk prediction, providing a comparative analysis between deep learning models and traditional methods, shedding light on their theoretical foundations and data preprocessing techniques.

Credit risk prediction involves assessing the likelihood that a borrower will default on a loan or credit line. This process is critical for financial institutions to make informed lending decisions and develop risk mitigation strategies. Deep learning models, a subset of machine learning methods, have gained popularity in recent years due to their ability to extract complex patterns from large datasets. By utilizing artificial neural networks, deep learning models can capture nonlinear relationships and dependencies in the data, offering increased prediction accuracy compared to traditional statistical methods.

Traditional methods of credit risk prediction encompass a range of statistical approaches, such as logistic regression, decision trees, and discriminant analysis. These methods rely on predefined mathematical models and statistical assumptions to evaluate creditworthiness.

Although traditional methods have been widely used in the financial industry for decades, they may struggle to capture the complex and nonlinear relationships present in modern financial datasets. In contrast, deep learning models can automatically learn and adapt to underlying patterns in the data without the need for explicit rule programming.

The theoretical foundation of deep learning models revolves around artificial neural networks, which are designed to mimic the structure and function of the human brain. These networks consist of interconnected layers of neurons that process and transform input data through weighted connections. The backpropagation algorithm is a key component of neural network training, enabling them to optimize their parameters based on the difference between predicted and actual outcomes. This iterative learning process allows deep learning models to continuously improve their performance in credit risk prediction tasks.

On the other hand, traditional methods such as regression analysis and decision tree models rely on predefined mathematical functions to model the relationship between input variables and the credit risk outcome. For instance, regression analysis evaluates the impact of each predictor variable on the target variable, providing insights into the significance of different factors in credit risk assessment. Decision tree models, meanwhile, split the data into hierarchical decision nodes based on feature values, offering an interpretable structure for credit risk prediction.

**Keywords:** Deep learning, Credit risk, Prediction, Neural networks, Traditional methods, Logistic regression, Decision trees, Support vector machines, Model effectiveness, Data processing, Risk modeling, Result interpretation, Practical application, Scalability, Error analysis.

## Вступ

У сучасному фінансовому середовищі, де ризики є невід'ємною складовою, ефективне управління кредитним ризиком стає вирішальним завданням для фінансових установ. У цьому контексті використання передових технологій, зокрема моделей глибокого навчання, набуває все більшого значення. Саме ці моделі можуть забезпечити точні й надійні прогнози, що допоможуть уникнути непередбачуваних втрат та збільшити ефективність управління кредитним портфелем.

Метою даної наукової статті є порівняльний аналіз ефективності моделей глибокого навчання у прогнозуванні кредитного ризику порівняно з традиційними методами. Цей аналіз спрямований на виявлення переваг та недоліків кожного підходу, а також на визначення оптимальних стратегій для забезпечення надійного управління кредитним портфелем. Проведення дослідження має на меті покращення процесів кредитування та забезпечення фінансової стабільності фінансових установ.

Результати даного порівняльного аналізу можуть стати важливим доповненням до наявних методик управління кредитним ризиком і відкрити нові можливості для вдосконалення фінансових практик та зниження ризиків у сфері кредитування.

## Постановка проблеми

### Завдання:

1. Зібрати та підготувати дані для аналізу.
2. Порівняти різноманітні моделі глибокого навчання (наприклад, нейронні мережі, глибокі дерева рішень) з традиційними методами (наприклад, логістична регресія, дерева рішень) у прогнозуванні кредитного ризику.
3. Оцінити точність, чутливість та специфічність кожної моделі.
4. Провести порівняльний аналіз результатів та зробити висновки про ефективність моделей глибокого навчання у порівнянні з традиційними методами.

**Проблема:** До цього часу існує обмежена кількість досліджень, які систематично порівнюють моделі глибокого навчання з традиційними методами у прогнозуванні кредитного ризику, тому необхідно провести подальші дослідження для визначення найбільш ефективних підходів.

**Об'єкт:** Фінансові установи, які надають кредити.

**Предмет:** Моделі глибокого навчання та традиційні методи прогнозування кредитного ризику.

### Результат дослідження

Обґрунтований кредитний ризик є необхідною складовою стратегії та тактики ефективного банківського управління. У кожній ситуації, що пов'язана з кредитним ризиком, виникають питання про те, що означає обґрунтований (допустимий) кредитний ризик, де проходить межа, що відділяє його від нерозумного. Відповісти на ці питання означає знайти рівень прийнятної кредитного ризику, провести кількісну та якісну оцінку конкретних ризикових кредитних рішень.[1]

Існує багато засобів для вирішення цієї проблеми, серед яких виділяється метод моделювання. Комп'ютерне моделювання має переваги у порівнянні з іншими підходами для рішення поставленої проблеми. Зокрема, воно дозволяє враховувати велику кількість змінних, прогнозувати розвиток нелінійних процесів та виникнення синергетичних ефектів. Комп'ютерне моделювання дозволяє не лише отримати прогноз, але й визначити, які керуючі впливи приведуть до найбільш сприятливого розвитку подій. Якісні висновки, зроблені за результатами комп'ютерного моделювання, дозволяють виявити такі властивості складної системи, як її структура, динаміка розвитку, стійкість, цілісність та інше. Кількісні висновки, в основному, стосуються прогнозу майбутніх або пояснення минулих значень змінних, що характеризують систему. Одним з основних напрямків використання комп'ютерного моделювання є пошук оптимальних варіантів зовнішнього впливу на об'єкт з метою отримання найкращих показників його функціонування.

Імітаційне моделювання є одним з видів комп'ютерного моделювання, яке використовує методологію системного аналізу. Центальною процедурою є побудова узагальненої моделі, що відображає всі фактори реальної системи. Обчислювальний експеримент виступає як методологія дослідження.

Для аналізу показників кредитного ризику комерційного банку цілком доцільно використовувати імітаційні моделі, зокрема, моделі системної динаміки. Концепція системної динаміки дозволяє моделювати

динамічні процеси на високому рівні агрегування. Її основа полягає в уявленні функціонування динамічної системи як сукупності потоків грошей, продукції, людських ресурсів та інших.[2]

Сучасні системи моделювання, такі як EPdeјg, RAJOEI та інші, дозволяють створювати моделі на ідеографічному рівні. Отримані системні потокові діаграми є формою структуризації знань експертів, у мережі яких виявляються різні види дисбалансу в споживанні ресурсів та потребах. Основною метою є встановлення балансу використання ресурсів у системі.

Моделі системної динаміки застосовуються разом з диференціальними рівняннями балансового типу, а також у поєднанні з принципами та методами логістики, що базуються на оптимізації, управлінні та інтеграції потоків у складних системах.[6]

Головним об'єктом застосування моделей, таких як EPdeјg, є фінансовий сектор. Аналіз та координація грошових потоків є однією з основних компетенцій пакета структурного моделювання EPdeјg.

Однією з важливих переваг пакета EPdeјg є можливість демонстрації зв'язку фінансового і технологічного механізму проекту. Це можна зробити за допомогою імітаційної моделі, що дозволяє пов'язати техніко-економічні та фінансові аспекти проекту. Таким чином, фінансова механіка банку або фірми стає зрозумілою як для потенційного інвестора, так і для самого автора проекту. Схеми, моделі та графіки, отримані в системі EPdeјg, дуже корисні в бізнес-плані підприємства з сучасною технологією ведення бізнесу, і доповняють звичні фінансові таблиці та стандартні діаграми.[3]

Виділення раніше невіршених частин загальної проблеми є ключовим етапом у побудові моделі аналізу відносних показників кредитного ризику комерційного банку в системі EPdeјg. Ця модель дозволить приймати ефективні управлінські рішення щодо встановлення необхідного балансу використання ресурсів в системі.[7]

Задача даної статті полягає у пропозиції простої імітаційної моделі для оцінки показників кредитного ризику комерційного банку в середовищі моделювання EPdeјg та визначенні переваг використання таких моделей.

Для успішного аналізу кредитного ризику необхідно мати розуміння про його існування, проаналізувати його на якісному рівні та логіко-ймовірно моделювати.[4]

Ступінь допустимого кредитного ризику визначається з урахуванням параметрів, таких як обсяг власного капіталу банку, його рівень ліквідності, фінансової стійкості, рентабельності тощо. Більший власний капітал дозволяє банку проводити більш ризиковані операції і послуги, менш чутливо реагувати на кредитний ризик і зваженіше приймати рішення про укладення ризикових кредитних угод.[8]

Кількісна оцінка кредитного ризику включає розмір реальної вартості, пов'язаної з ризиком, і обсяг очікуваних збитків. Кредитний ризик може характеризуватися різними відносними показниками, такими як максимальний розмір ризику на одного позичальника банку, що визначається як сума кредитів, видача яких одному позичальнику віднесена до власного капіталу банку.

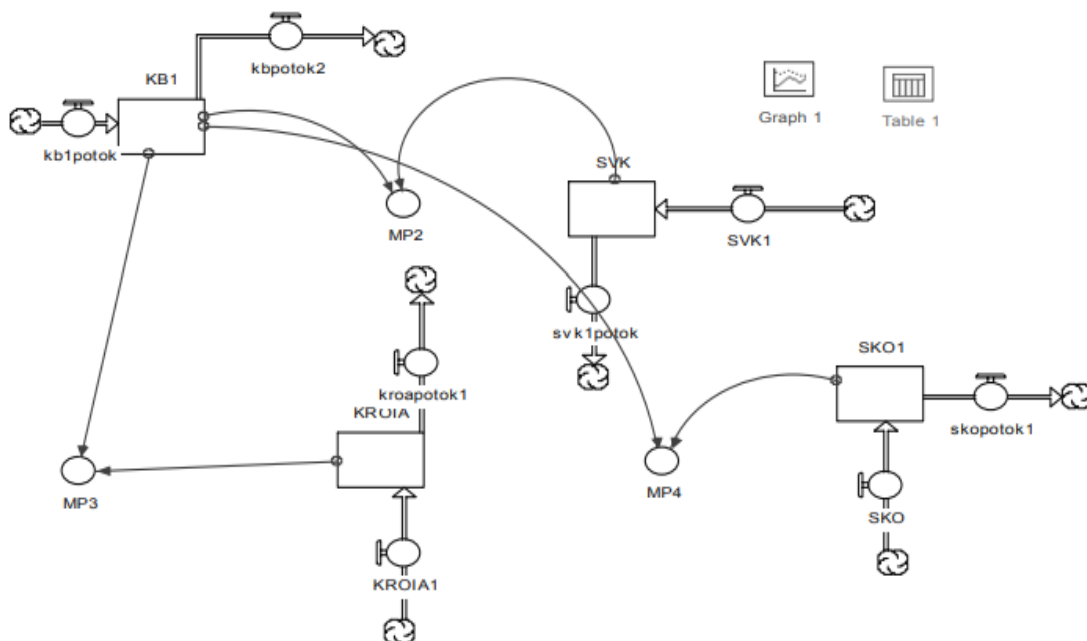


Рис. 1 - Модель оцінки відносних показників кредитного ризику комерційного банку

Моделювання цих показників у системі EPdeјg показує, що ми отримуємо прогнозу оцінку щомісячно для введених значень. На графіку можна побачити критичне значення для кожного з показників, що аналізуються. Наприклад, для  $IL$ - і  $MP$ / маємо позитивну динаміку, оскільки їх критичні значення  $MP \leq 3$  та  $MP4 \leq 0$ . Також за моделлю, якщо капітал банку дорівнює, наприклад, 100 млн грошових одиниць постійно, банк постійно нарощує суму великих кредитів, суму кредитів, виданих одному інсайдеру, та суму кредитів

засновникам і акціонерам з постійною швидкістю. Таким чином, для МР критичним є значення показника "кредити засновникам і акціонерам", яке дорівнює -50 млн.[5]

Аналогічно можна проаналізувати критичне значення для показника МР/. У результаті моделювання отримуємо, що  $MP/ = 100$ , якщо "кредити засновникам і акціонерам" дорівнюють -50 млн грошових одиниць. Модель дозволяє змінювати суму капіталу банку та інших показників, отримуючи відповідні значення для відносних показників ризику та оцінюючи їх значення.[9]

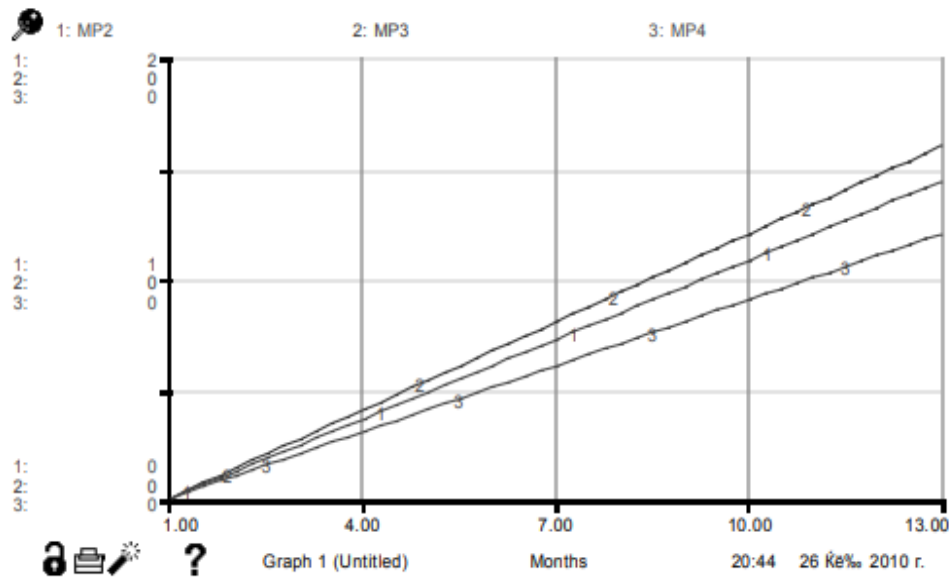


Рис. 2 - Графік динаміки відносних показників кредитного ризику

Ця модель дозволяє проаналізувати поточні значення відносних показників кредитного ризику комерційного банку та прогнозувати динаміку розвитку цих коефіцієнтів в залежності від змін капіталу банку. Також можливе аналізування впливу зростання або зменшення показників, таких як "сума великих кредитів", "кредити засновникам і акціонерам", або "сума кредитів, виданих одному інсайдеру", на капітал банку. Отримані за моделлю показники дозволяють оцінити критичні значення складових відносних коефіцієнтів для будь-яких вхідних значень. Подальший розвиток моделі може включати блоки прийняття рішень, які на основі отриманої інформації надаватимуть керуючі впливи на різні об'єкти. Модель може бути включена до так званого "блоку моделей", який входить до складу сучасних систем підтримки прийняття рішень, і використовуватися в банківській діяльності, що значно підвищить рівень фінансового менеджменту в галузі управління кредитними ризиками.[10]

### Висновки

У результаті порівняльного аналізу моделей глибинного навчання та традиційних методів прогнозування кредитного ризику можна зробити висновок, що моделі глибинного навчання демонструють великий потенціал у цій сфері. Вони здатні ефективно враховувати складні нелінійні залежності у даних, що дозволяє отримувати більш точні прогнози ризику. Такі моделі можуть бути особливо корисними у випадках, коли традиційні методи не можуть врахувати всі аспекти складної структури даних. Проте, для успішного впровадження моделей глибинного навчання необхідно враховувати деякі виклики, зокрема, необхідність великого обсягу даних для навчання моделей, складність інтерпретації результатів, а також вимоги до обчислювальних ресурсів. Тим не менш, з урахуванням швидкого розвитку технологій та збільшення обчислювальних можливостей ці виклики можуть бути подолані.

Отже, моделі глибинного навчання можуть бути ефективним інструментом для прогнозування кредитного ризику, а їх впровадження може сприяти покращенню якості прийняття рішень у фінансовому секторі.

### Література

1. Кузнецова Н. В. Інтегрований підхід до оцінювання кредитних ризиків [Електронний ресурс] / Н. В. Кузнецова // Праці Одеського політехнічного університету. – 2010. – Режим доступу до ресурсу: [http://nbuv.gov.ua/UJRN/Popu\\_2010\\_1-2\\_38](http://nbuv.gov.ua/UJRN/Popu_2010_1-2_38).
2. Гаврилюк Г. В. Аналіз вагомості критеріїв в оцінюванні кредитоспроможності фізичних осіб / Г. В. Гаврилюк // Нейро-нечіткі технології моделювання в економіці. – 2017. – №6. – С. 3–23.
3. Камінський А. Б. Нейромережеві технології в управлінні портфелем простроченої заборгованості / А. Б. Камінський, В. О. Сікач. // Моделювання та інформаційні системи в економіці. – 2011. – №84. – С. 5–19.

4. Siddiqi N. Credit Risk Scorecards Developing and Implementing Intelligent Credit Scoring / Siddiqi Naeem., 2006. – (John Wiley & Sons, Inc.). – (1).
5. Durand D. Risk Elements in Consumer Instalment Financing / David Durand., 1941. – (National Bureau of Economic Research, Inc.). – (1).
6. Řezáč M. How to Measure the Quality of Credit Scoring Models / M. Řezáč, F. Řezáč. // Czech Journal of Economics and Finance. – 2011. – №61. – С. 486–507.
7. Marsaglia G. Evaluating Kolmogorov's Distribution / G. Marsaglia, W. W. Tsang, J. Wang. // Journal of Statistical Software. – 2003. – №8. – С. 1–4.
8. Сушко В. І. Класифікація моделей оцінки ймовірності банкрутства підприємств / В. І. Сушко, Т. С. Павлюк. // Економіка: теорія та практика. – 2014. – №1. – С. 72–83.
9. Dobbin K. K. Optimally splitting cases for training and testing high dimensional classifiers / K. K. Dobbin, M. S. Richard. // BMC Medical Genomics. – 2011. – №4. – С. 31.
10. Van den Broeck J. Data Cleaning: Detecting, Diagnosing, and Editing Data Abnormalities / J. Van den Broeck, A. J. Herbst, A. C. Solveig. // PLoS Medicine. – 2005. – №2. – С. 966–970.

### References

1. Kuznietsova N. V. Intehrovanyi pidkhdid do otsiniuvannya kredytnykh ryzykiv [Elektronnyi resurs] / N. V. Kuznietsova // Pratsi Odeskoho politekhnichnoho universytetu. – 2010. – Rezhym dostupu do resursu: [http://nbuv.gov.ua/UJRN/Popu\\_2010\\_1-2\\_38](http://nbuv.gov.ua/UJRN/Popu_2010_1-2_38).
2. Havryliuk H. V. Analiz vahomosti kryteriv v otsiniuvanni kredytopromozhnosti fizychnykh osib / H. V. Havryliuk. // Neuro-nechitki tekhnolohii modeliuвання v ekonomitsi. – 2017. – №6. – С. 3–23.
3. Kaminskyi A. B. Neiomerezhevi tekhnolohii v upravlinni portfelem prostrochenoi zaborhovanosti / A. B. Kaminskyi, V. O. Sikach. // Modeliuвання ta informatsiini systemy v ekonomitsi. – 2011. – №84. – С. 5–19.
4. Siddiqi N. Credit Risk Scorecards Developing and Implementing Intelligent Credit Scoring / Siddiqi Naeem., 2006. – (John Wiley & Sons, Inc.). – (1).
5. Durand D. Risk Elements in Consumer Instalment Financing / David Durand., 1941. – (National Bureau of Economic Research, Inc.). – (1).
6. Řezáč M. How to Measure the Quality of Credit Scoring Models / M. Řezáč, F. Řezáč. // Czech Journal of Economics and Finance. – 2011. – №61. – С. 486–507.
7. Marsaglia G. Evaluating Kolmogorov's Distribution / G. Marsaglia, W. W. Tsang, J. Wang. // Journal of Statistical Software. – 2003. – №8. – С. 1–4.
8. Sushko V. I. Klyasifikatsiia modelei otsinky ymovirnosti bankrutstva pidpriemstv / V. I. Sushko, T. S. Pavliuk. // Ekonomika: teoriia ta praktyka. – 2014. – №1. – С. 72–83.
9. Dobbin K. K. Optimally splitting cases for training and testing high dimensional classifiers / K. K. Dobbin, M. S. Richard. // BMC Medical Genomics. – 2011. – №4. – С. 31.
  - a. Van den Broeck J. Data Cleaning: Detecting, Diagnosing, and Editing Data Abnormalities / J. Van den Broeck, A. J. Herbst, A. C. Solveig. // PLoS Medicine. – 2005. – №2. – С. 966–970.