

УДК 004.048:004.8

DOI [https://doi.org/10.15589/znp2025.4\(502\).39](https://doi.org/10.15589/znp2025.4(502).39)ДОСЛІДЖЕННЯ АЛГОРИТМІВ РЕКОМЕНДАЦІЙНИХ СИСТЕМ
НА ОСНОВІ ГЕНЕРАТИВНИХ ЗМАГАЛЬНИХ МЕРЕЖINVESTIGATION OF RECOMMENDER SYSTEM ALGORITHMS
BASED ON GENERATIVE ADVERSARIAL NETWORKSStanislav G. Yakhnenko
stanislav.yakhnenko@outlook.com
ORCID: 0009-0002-0670-110XС. Г. Яхненко,
аспірант*Private Higher Education Establishment “European University”, Kyiv
Приватний вищий навчальний заклад «Європейський університет», м. Київ*

Abstract. Purpose. The aim of the work is to systematize the key challenges of recommender systems and generalize GAN-oriented approaches proposed in modern research to improve the quality of user preference modeling. The article provides a systematic review of modern research that uses generative adversarial networks (GANs) to overcome fundamental limitations of recommender systems.

Method. Based on the analysis of the source database, four key problems were identified: data sparsity, cold start, inefficient formation of negative examples, and various forms of bias in the samples. Classical methods of model enrichment using auxiliary matrices and joint factorization are considered, as well as GAN approaches that model the distribution of interactions or latent representations, in particular IRGAN, CFGAN, CFWGAN-GP, GANMF, ColdGAN, SD-GAR, PURE, FMGAN, and DebiasGAN. The article summarizes the architectural features of these models, including candidate generation, latent profile modeling, the use of an autoencoder as a discriminator, and a feature matching mechanism.

Results. It is shown that the considered GAN-oriented models demonstrate a significant improvement in estimates on sparse data and in scenarios with a minimal number of interactions. Generative approaches, such as ColdGAN, allow restoring the user's «warm state» without involving external information, and the SD-GAR and PURE systems offer alternative mechanisms for generating and interpreting interactions, providing higher ranking accuracy and better behavior on sparse samples. The FMGAN and DebiasGAN models are aimed at eliminating noise, positional bias, and other distortions that affect the quality of data and user signals.

Scientific novelty. The review shows that GAN-oriented approaches offer not only additional enrichment of recommendation models, but also multi-level mechanisms for reconstructing the structure of interactions and latent spatial dependencies. Unlike classical methods, they allow correcting systematic errors in samples, adaptively working in cold start conditions, and ensuring more correct interpretation of implicit signals.

Practical significance. Thanks to competitive learning, generative models provide more flexible mechanisms for restoring missing information, more stable work with sparse and incomplete data, more accurate formation of negative examples, and reduction of biases. Further coordination of classical approaches and GAN-oriented solutions is promising to clarify practical scenarios in which the use of generative models provides a real advantage in building recommendation systems.

Key words: recommendation systems; machine learning; generative adversarial networks; filtering, bias; sparsity.

Анотація. Мета. Метою роботи є систематизація ключових викликів рекомендаційних систем і узагальнення GAN-орієнтованих підходів, що пропонуються в сучасних дослідженнях для підвищення якості моделювання користувацьких уподобань. У статті здійснюється систематизований огляд сучасних досліджень, що застосовують генеративні змагальні мережі (GAN) для подолання фундаментальних обмежень рекомендаційних систем.

Методика. На основі аналізу джерельної бази було виокремлено чотири ключові проблеми: розрідженість даних, холодний старт (cold start), неефективне формування негативних прикладів та різні форми упередженостей у вибірках. Розглядаються класичні методи збагачення моделі за допомогою допоміжних матриць і спільної факторизації, а також GAN-підходи, що моделюють розподіл взаємодій або латентних представлень, зокрема IRGAN, CFGAN, CFWGAN-GP, GANMF, ColdGAN, SD-GAR, PURE, FMGAN і DebiasGAN. У статті узагальнено архітектурні особливості цих моделей, зокрема генерацію кандидатів, моделювання латентних профілів, використання автоенкодера як дискримінатора та механізм feature matching (узгодження ознак).

Результати. Показано, що розглянуті GAN-орієнтовані моделі демонструють суттєве покращення оцінок на розріджених даних та у сценаріях з мінімальною кількістю взаємодій. Генеративні підходи, такі як ColdGAN, дозволяють відновлювати «теплий стан» користувача без залучення зовнішньої інформації, а системи SD-GAR та PURE пропонують альтернативні механізми генерації та інтерпретації взаємодій, забезпечуючи вищу точність ранжування й кращу поведінку на розріджених вибірках. Моделі FMGAN та DeBiasGAN спрямовані на усунення шуму, позиційної упередженості та інших спотворень, що впливають на якість даних і користувацьких сигналів.

Наукова новизна. Проведений огляд показує, що GAN-орієнтовані підходи пропонують не лише додаткове збагачення рекомендаційних моделей, а різномірні механізми реконструкції структури взаємодій і латентних просторових залежностей. На відміну від класичних методів, вони дозволяють виправляти систематичні похибки у вибірках, адаптивно працювати в умовах холодного старту та забезпечувати коректнішу інтерпретацію неявних сигналів.

Практична значимість. Завдяки змагальному навчанню генеративні моделі забезпечують гнучкіші механізми відновлення пропущеної інформації, стабільнішу роботу з розрідженими та неповними даними, точніше формування негативних прикладів і зменшення упередженостей. Перспективним є подальше узгодження класичних підходів і GAN-орієнтованих рішень для уточнення практичних сценаріїв, у яких застосування генеративних моделей забезпечує реальну перевагу при побудові рекомендаційних систем.

Ключові слова: рекомендаційні системи; машинне навчання; генеративні змагальні мережі; фільтрація; упередження; розрідженість.

ПОСТАНОВКА ЗАДАЧІ

Рекомендаційні системи стали ключовим інструментом персоналізації цифрових сервісів, проте їхня ефективність суттєво обмежується низкою системних проблем. Серед найбільш критичних викликів виділяють розрідженість даних, холодний старт для нових користувачів і нових елементів, динамічність інтересів, що вимагає постійного оновлення моделей, а також упередження популярності, обмежену диверсифікацію та складність забезпечення справедливості й прозорості рекомендацій. Крім того, реальні промислові системи повинні працювати з великими обсягами гетерогенних даних, забезпечувати масштабованість, конфіденційність і здатність коректно працювати за наявності шуму та неякісних даних. Як було доведено С. Раза, М. Рахман, С. Камавал та ін. [Ошибка! Источник ссылки не найден.], традиційні алгоритми колаборативної фільтрації, контентні та гібридні моделі лише частково розв'язують ці проблеми, а глибинні методи також потребують значних обсягів якісних даних і часто схильні до перенавчання. На цьому тлі зростає інтерес до генеративних підходів, зокрема моделей на основі генеративних змагальних мереж, які здатні синтезувати відсутні взаємодії, формувати інформативні негативні приклади та покращувати представлення користувачів і об'єктів, частково пом'якшуючи обмеження традиційних рекомендаційних алгоритмів.

АНАЛІЗ ОСТАННІХ ДОСЛІДЖЕНЬ І ПУБЛІКАЦІЙ

У сучасному науковому просторі представлено значний масив досліджень, спрямованих на розвиток алгоритмів рекомендаційних систем, що інтегрують генеративні змагальні мережі для підвищення їхньої ефективності. Так, у праці Бобаділла Дж., А. Гут'єрреса, Р. Єри, Л. Мартінеса [2] запропоновано метод

побудови синтетичних наборів даних для колаборативної фільтрації на основі генеративних змагальних мереж. Дослідники наголошують, що брак репрезентативних відкритих даних обмежує можливості оцінювання сучасних рекомендаційних алгоритмів, а традиційні набори на кшталт Movielens чи Netflix не охоплюють достатньої варіативності структур, розмірів та рівнів розрідженості. У рамках запропонованого підходу проблема вирішується шляхом навчання GAN на щільних ембедингах користувачів та об'єктів, отриманих через модель DeepMF, що дозволяє уникнути громіздких розріджених векторів і пришвидшує збіжність генератора. Синтетичні зразки, сформовані у щільному просторі, далі перетворюються на дискретне «користувач-об'єкт-оцінка» представлення за допомогою кластеризації «k-means». Такий підхід надає можливість параметризувати майбутній датасет: задавати кількість користувачів, кількість об'єктів, масштаб вибірки та ступінь стохастичної варіативності.

У дослідженні Н. Манаа, Х. Серіді, М. Менджел [3] представлено огляд сучасних підходів до інтеграції GAN у рекомендаційні системи. Автори систематизують напрями застосування: персоналізація через умовні GAN, генерування синтетичних взаємодій для вирішення холодного старту, подолання дисбалансу даних за допомогою Wasserstein-GAN та PacGAN, а також підвищення якості рекомендацій у розріджених вибірках. Окремо розглядаються моделі на основі графових згорток і підходи, що поєднують GAN із матричною факторизацією. Робота виділяє ключові проблеми: нестабільність навчання, «mode collapse», обмежену масштабованість і складність оцінювання генеративних моделей. Автори підкреслюють, що попри потенціал GAN, їх широке впровадження потребує вирішення методологічних і технічних обмежень

Аммар Х. Ходжа, О. Будженіба аналізують можливість застосування WGAN-GP у задачах рекомендацій та перевіряють, чи дає ця архітектура переваги над існуючими GAN-моделями. Запропонована система CFWGAN-GP базується на CFGAN, але замість класичного GAN використовує Wasserstein-метрику з «gradient penalty». Модель успішно протестовано на MovieLens – 100K та MovieLens – 1M: вона демонструє конкурентні результати у найкращих 5 та 20 рекомендаціях (топ-N), однак експерименти не виявили значущого приросту точності порівняно з оригінальною GAN-версією. Додатково показано, що проста багатоміткова нейромережа, навчена на бінарної кросс-ентропії (Binary Cross-Entropy), перевершує всі протестовані GAN-підходи. Таким чином, дослідження ставить під сумнів доцільність використання складних GAN-архітектур у рекомендаційних системах, якщо метою є лише підвищення точності.

Застосування генеративно-змагальних мереж для формування рекомендацій та їх порівняння з нейромережею DSSM висвітлює такий науковець як А. Просветов [5]. Автор пропонує умовний GAN, у якому генератор створює ймовірні майбутні вибори користувача на основі історії взаємодій, а дискримінатор відрізняє реальні приклади від синтетичних. Модель не потребує формування негативних зразків, оскільки їхню роль виконують згенеровані випадки. Архітектура поєднує згорткові, LSTM-шари та проміжний рівень гаусівського шуму. Експерименти з рекомендаціями авіаквитків показали, що GAN забезпечує конверсію 2.34 % проти 2.33 % у DSSM, випереджаючи базову модель та демонструючи конкурентоспроможність у практичному середовищі.

ВІДОКРЕМЛЕННЯ НЕВИРІШЕНИХ РАНІШЕ ЧАСТИН ЗАГАЛЬНОЇ ПРОБЛЕМИ

Хоча окремі дослідження пропонують рішення для розрідженості, генерації латентних представлень, корекції упереджень і оптимізації негативних вибірок, наявні GAN-орієнтовані методи залишаються методологічно неоднорідними та потребують подальшої систематизації.

МЕТА ДОСЛІДЖЕННЯ

Метою роботи є систематизація ключових викликів рекомендаційних систем і узагальнення GAN-орієнтованих підходів, що пропонуються в сучасних дослідженнях для підвищення якості моделювання користувацьких уподобань.

ОБ'ЄКТ, ПРЕДМЕТ ТА МЕТОДИ ДОСЛІДЖЕННЯ

Об'єктом дослідження є рекомендаційні системи, що здійснюють прогнозування користувацьких уподобань на основі моделей машинного навчання та колаборативної фільтрації.

Предметом дослідження виступають алгоритми побудови рекомендаційних систем із використанням

генеративних змагальних мереж, а також їхні архітектурні та функціональні особливості, що забезпечують подолання розрідженості даних, холодного старту, систематичних упередженостей та проблеми формування негативних прикладів.

Методи дослідження. Для реалізації дослідження використано аналітично-оглядову методологію, спрямовану на систематизацію та порівняльний аналіз сучасних моделей рекомендаційних систем на основі генеративних змагальних мереж (GAN). Методологічна база включає:

- системний аналіз джерельної бази, що охоплює класичні методи колаборативної фільтрації, гібридні підходи та сучасні GAN-орієнтовані рішення (IRGAN, CFGAN, CFWGAN-GP, GANMF, ColdGAN, SD-GAR, PURE, FMGAN, DebiasGAN);

- структурно-функціональний аналіз архітектур моделей, із виокремленням генеративних та дискримінативних механізмів, стратегій генерації кандидатів, моделювання латентних профілів, використання автоенкодера як дискримінатора та технології feature matching;

- порівняльний критичний аналіз ефективності GAN-підходів щодо подолання чотирьох фундаментальних обмежень рекомендаційних систем: розрідженості, холодного старту, упередженостей у вибірках та формування негативних прикладів;

- узагальнення результатів експериментальних досліджень, спрямоване на визначення реального приросту якості рекомендацій у різних сценаріях, зокрема при мінімальній кількості взаємодій та відсутності зовнішніх ознак.

ОСНОВНИЙ МАТЕРІАЛ

У дослідженнях, присвячених сучасним рекомендаційним системам, послідовно фіксуються чотири ключові обмеження, які визначають точність та стабільність моделей: розрідженість даних, холодний старт, неефективне формування негативних прикладів та систематичні упередженості у вибірках.

Проблему розрідженості даних М. Буадженек зі співавторами [6] визначають як один із ключових викликів колаборативної фільтрації: більшість користувачів взаємодіють лише з обмеженою кількістю об'єктів, що призводить до значної кількості пропусків у матриці «користувач-об'єкт». Така структура ускладнює побудову точних моделей переваг користувачів і характеристик елементів. Окремо підкреслюється, що нові користувачі та нові об'єкти демонструють найнижчу якість прогнозування через повну відсутність історії взаємодій. Для пом'якшення розрідженості застосовано класичний підхід, що передбачає залучення додаткових матриць даних. Використовуються такі джерела, як соціальні зв'язки, тематичні інтереси, теги та атрибути об'єктів. Підкреслюється, що ці матриці містять релевантні кореляції, здатні підсилити базову модель і забезпечити точніше

відновлення латентних факторів навіть за умов мінімальної кількості наявних рейтингів. Для чого виконується спільна факторизація основної матриці взаємодій і допоміжних матриць у єдиному латентному просторі.

Розвиток цього підходу спрямований на масштабованість, оскільки різні джерела даних часто фізично розміщені на окремих кластерах. Запропонована розподілена реалізація поєднує локальні обчислення з обміном спільних латентних факторів, що дозволяє мінімізувати передачу сирих даних і зменшити навантаження на центральні вузли.

Використання кількох джерел інформації дає суттєве підвищення точності прогнозування пропущених значень порівняно з однотабличними моделями. Навіть часткові допоміжні матриці помітно покращують відновлення латентних представлень і зменшують негативний вплив розрідженості. У сукупності це формує типовий класичний підхід до подолання проблеми розріджених матриць у рекомендаційних системах, заснований на збагаченні моделі додатковими джерелами інформації та розширенні стандартної матричної факторизації.

Не дивлячись на ефективність класичних підходів, заснованих на збагаченні моделі додатковими матрицями та спільній факторизації, М. Гао, Дж. Чжан та ін. [7] зазначають, що розрідженість залишається суттєвою через те, що кожен користувач зазвичай взаємодіє лише з малою часткою доступних елементів, що різко обмежує якість реконструкції переваг навіть за наявності допоміжної інформації.

Класичні методи збагачують дані за рахунок допоміжних матриць або контентних ознак, однак вони залишаються обмеженими несумісністю джерел, різною якістю сигналів та значними обчислювальними витратами при масштабуванні. Пропоновані GAN-методи дають принципово інший механізм подолання розрідженості, який не спирається на зовнішні матриці, а відновлює пропущені дані через моделювання самого розподілу взаємодій. У розглянутому дослідженні підкреслюється два ключові напрями.

Перший напрям, у моделях на зразок IRGAN генератор формує кандидати об'єкту, які могли б бути релевантними конкретному користувачу, тоді як дискримінатор відрізняє їх від справжніх взаємодій. Така «minimax» структура дозволяє системі вчитися на обмеженій кількості історичних даних і поступово створювати додаткові «позитивні» приклади там, де матриця надто розріджена. Другий напрям, інша група моделей, таких як CFGAN, CFWGAN-GP та подібні варіанти, працює не з прямою генерацією взаємодій, а з генерацією узгоджених латентних представлень користувачів та елементів. Генератор створює латентні вектори, які відображають структуру переваг у реальних даних, а дискримінатор навчається ідентифікувати, чи відповідають вони справжнім

латентним профілям. Це дає змогу відновити інформацію навіть для користувачів з мінімальною кількістю спостережень, уникаючи деградації якості, характерної для класичних MF-методів під час сильної розрідженості даних.

Але Е. Дервішай, П. Крмонезі [8] показали, що низка попередніх GAN-підходів, таких як IRGAN, CFGAN, тощо, демонструє обмежену ефективність у задачах колаборативної фільтрації через дві фундаментальні проблеми. По-перше, використання бінарного класифікатора як дискримінатора дає занадто слабкий і нерозрізняльний градієнт для високовимірних профілів користувачів, що дає надто слабкий та недостатній для навчання сигнал, істотно ускладнюючи стабільне та точне оновлення параметрів генератора профілів користувачів. По-друге, у класичній постановці колаборативної фільтрації кожному користувачу відповідає лише один спостережуваний профіль у матриці користувач-об'єкт. Для умовних GAN, які потребують кількох прикладів на клас, це створює проблему: модель не має достатньої кількості зразків для стабільного навчання умовної генерації профілів. Через це, для подолання цих обмежень автори пропонують модель GANMF, яка перебудовує архітектуру GAN. Замість бінарного класифікатора в ролі дискримінатора використовується автоенкодер, що відновлює поданий профіль і оцінює різницю між входом і реконструкцією. Ця різниця слугує функцією, яка відображає, наскільки профіль «схожий» на реальний. Завдяки чому дискримінатор надає значно детальніший сигнал для навчання генератора, а також формує більш узгоджене латентне представлення профілів, що покращує розрізнення навіть за дуже високої розмірності та розрідженості даних.

Сам генератор у GANMF реалізовано у вигляді двошарової матричної факторизації: він містить латентні фактори користувачів та елементів і формує профіль шляхом їх добутку. Для збереження залежності між конкретним користувачем і згенерованим профілем модель доповнюється механізмом feature matching, який змушує генератор наближати статистики закодованих реальних профілів у просторі ознак дискримінатора. Це усуває проблему ігнорування умовного входу та забезпечує унікальні профілі для різних користувачів.

У результаті експериментальної роботи дослідниками було встановлено, що GANMF стабільно перевершує як традиційні матричні факторизації (PureSVD, WRMF), так і попередні GAN-підходи – насамперед CFGAN – на трьох стандартних наборах даних (ML-1M, ML-HetRec, LastFM). Особливо помітні покращення спостерігаються для користувачів з малою кількістю взаємодій ≤ 5 , що підтверджує здатність запропонованої архітектури компенсувати інформаційні прогалини завдяки узгодженому латентному простору та адаптивному механізму генерації.

Узагальнюючи викладене, проблема розрідженості даних залишається ключовим обмеженням як для класичних моделей, так і для більшості GAN-підходів, оскільки нестача взаємодій різко знижує якість реконструкції латентних представлень. В такому контексті розрідженість описується як глобальна властивість матриці користувач-об'єкт, де більшість комірок відсутні, але система все ж має певний обсяг історичних взаємодій для більшості елементів.

З. Чень зі співавторами [9] підкреслюють, що розрідженість виникає навіть у великих наборах даних через *user sparsity* (розрідженість користувачів), *item sparsity* (розрідженість елементів чи об'єктів) та *interaction sparsity* (розрідженість взаємодій), тобто через недостатню щільність розподілу спостережень, а не повну їх відсутність. Найбільш яскраво цей ефект проявляється для нових користувачів і нових об'єктів, де кількість спостережень майже дорівнює нулю. Саме цей випадок формує окрему, більш специфічну проблему холодного старту. Яку автори визначають як ситуацію повної або майже повної відсутності інформації, якої було б достатньої для моделювання переваг, що робить неможливим відтворення будь-якого надійного профілю навіть за наявності глобальних структурних закономірностей у даних.

Л. Фернандес, В. Мігейс, І. Перейра та ін. [10] також визначають холодний старт як ситуацію, у якій система рекомендацій не має достатнього обсягу інформації про користувача або товар, щоб надійно моделювати переваги. Вони також підкреслюють, що у сфері цифрового маркетингу ця проблема найчастіше стосується нових або неактивних клієнтів, які здійснили надто мало транзакцій, щоб за їхньою поведінкою можна було виділити стабільні закономірності. Додатково підкреслюючи, що якщо відсутні не лише взаємодії, а й будь-які описові ознаки, випадок класифікується як «frozen-start», тобто повна неможливість побудови персоналізованих рекомендацій.

Для подолання же цього холодного старту в роботі запропоновано гібридний підхід, який поєднує кілька незалежних моделей, здатних компенсувати обмеженість транзакцій. Система інтегрує два контентні методи, що використовують портфель товарів і текстові дескриптори, модель колаборативної фільтрації, побудовану на шаблонах покупок, та підхід Market Basket Analysis, який аналізує асоціативні правила у вибірках транзакцій. Така паралельна структура дозволяє об'єднати різномірні джерела сигналів, зменшуючи ризик деградації якості рекомендацій у випадках, коли наявні дані не містять достатньої кількості спостережень. Крім того, у систему інтегровано часовий спад, що забезпечує перевагу більш актуальним взаємодіям та підсилює релевантність рекомендацій для користувачів із короткою або нерегулярною історією покупок.

Результати експерименту дозволили зафіксувати, що комбінування декількох моделей суттєво покращує точність прогнозування порівняно з кожним окремим підходом. Гібридна система забезпечила значне зростання проценту успіху та зменшення зсувів у рекомендаціях, водночас залишаючись ефективною навіть для користувачів із 1–3 транзакціями. Автори показують, що врахування різних типів сигналів – від контентних характеристик до патернів спільних покупок – дозволяє подолати обмеження холодного старту у випадку, коли класичні методи колаборативної фільтрації не можуть відновити латентні представлення через брак взаємодій.

На відміну від цього П.-Л. Лай, С.-Ю. Чень та ін. [11] розглядають проблему холодного старту як задачу реконструкції уподобань користувача без залучення будь-якої побічної інформації. Якщо гібридні підходи відновлюють профіль нового користувача шляхом інтеграції різномірних сигналів (контентних ознак, транзакційних патернів, асоціативних правил), то запропонована модель ColdGAN ґрунтується на концептуально іншій ідеї. Вона не використовує жодних зовнішніх характеристик користувачів або товарів, а повністю покладається на здатність генеративної мережі відтворити «теплий стан» за обмеженим набором початкових взаємодій. У межах ColdGAN користувацькі рейтинги теплих користувачів (який має багато рейтингових взаємодій), розглядаються як повні «ідеальні» стани, тоді як модель штучно відтворює їхні холодні версії за допомогою спеціально розробленої часозалежної функції відновлення. Ця функція з різною ймовірністю відкидає рейтинги залежно від часу їх формування, що дозволяє зберегти найбільш інформативні взаємодії та водночас наблизити теплий профіль до реалістичного стану нового користувача.

Після цього пари «холодний-теплий» використовуються для тренування двох мереж: генеративна мережа G намагається відновити теплий стан на основі холодного, тоді як «мережа-розрізнявач» D навчається відмежовувати справжні та синтезовані профілі. Додатковий критерій релевантних елементів підсилює здатність моделі зосереджуватися на значущих для конкретного користувача товарах та зменшує ризик «mode collapse», що є типовою проблемою змагальних генеративних моделей. На етапі рекомендації модель використовує лише генеративну мережу: холодний вхідний вектор нового користувача подається до G, яка генерує прогнозовану теплу поведінку. Далі система ранжує товари за отриманими значеннями та формує найкращі рекомендації. Автори оцінюють модель на MovieLens 1M та Amazon Gift Cards, де тестова вибірка формувалася з перших десяти взаємодій кожного користувача, що дозволяє моделювати реальні умови холодного старту.

Результати демонструють, що ColdGAN перевищує точність інших існуючих методів. На наборі даних MovieLens 1M модель досягає наступних результатів у п'ятірці найкращих рекомендацій: прецизійність = 0.3625, повнота = 0.0430 та NDCG = 0.1124. Що істотно більше за показники найближчих конкурентів:

Таблиця 1. Порівняння з іншими методами.

Модель	Прецизійність	Повнота	NDCG
CGAN	0,2973	0,0280	0,0800
DAE	0,2432	0,0202	0,0783
CDAE	0,2404	0,0264	0,0610
RAGAN	0,1582	0,0121	0,0649
MF	0,0522	0,0038	0,0087

* Джерело – [11].

Ще однією з проблем рекомендаційних систем, що досліджувалася Б. Джин, Д. Ліан, З. Ліу зі співавторами [12], є неефективність формування негативних прикладів у моделях, що працюють з неявним зворотним зв'язком. У роботі підкреслюється, що брак якісних негативних вибірок і значні витрати часу на їх генерацію у GAN-орієнтованих підходах (зокрема в IRGAN) обмежують точність ранжування та масштабованість моделі. Також зауважується, що існуючі генератори часто не здатні достатньо точно наблизитися до оптимального розподілу, що призводить до зниження ефективності дискримінатора, який у підсумку виявляється слабким у задачі найкращих k рекомендацій.

Щоб подолати ці обмеження, пропонується архітектура Sampling-Decomposable Generative Adversarial Recommender (SD-GAR). Вона ґрунтується на теоретичному аналізі розбіжності між реальним і оптимальним генераторами та на використанні нормованої вибірки по значимості (importance sampling) для компенсації цієї різниці. Ключова ідея полягає у впровадженні розкладного механізму генерації негативних прикладів, що дозволяє формувати кожен з них за $O(1)$ часу та водночас підвищує якість навчання дискримінатора. Реалізація підходу передбачає поділ процесу вибірки на два етапи: спочатку вибирається латентний стан, а потім елемент із розподілу, пов'язаного з цим станом. Для обох рівнів попередньо створюються alias-таблиці, що забезпечують швидке семплювання.

Оптимізація генератора виконується в почерговому режимі й передбачає використання аналітичних розв'язків замість методів типу «policy gradient», що дає стабільнішу й менш ресурсомістку процедуру навчання. Дискримінатор використовує ваги, отримані через вибірку за значимістю (importance sampling), що дає змогу компенсувати відхилення вибірки від теоретично оптимальної. Результати експериментів засвідчують, що за показником NDCG у найкращих 50, за п'яти наборами даних (CiteULike, Gowalla,

MovieLens, Amazon, Echonest) SD-GAR перевищує IRGAN у середньому на понад 12 % (у середньому 0.16154 для SD-GAR проти 0.14432 для IRGAN) та приблизно на 10 % – порівняно з найкращими відомими базовими підходами. Крім того, час формування негативних прикладів скорочується до двадцяти разів на великих наборах даних, а навчання дискримінатора відбувається суттєво швидше.

Інший погляд на проблему негативних прикладів, представлений у роботі І. Чжоу, Ц. Сюй та ін. [13], виходить з принципово іншого твердження: сама практика трактування непозначених взаємодій як негативних є некоректною і призводить до систематичних похибок. Автори підкреслюють, що у реальних рекомендаційних системах більшість «нульових» записів не є ознакою нецікавості, а відображають відсутність експозиції, що руйнує передумови класичних негативних вибірок. На цій основі вони пропонують модель PURE, яка переносить задачу навчання у позитивно-непозначений контекст. Її дискримінатор будується не на припущенні про наявність негативних прикладів, а на PU ризик мінімізаторі, що дозволяє розділяти релевантні та нерелевантні пари без насильного присвоєння негативних міток.

Реалізація моделі передбачає поєднання PU критерію для дискримінатора та генератора, здатного відтворювати неперервний розподіл користувачів і товарів у латентному просторі. На відміну від дискретного семплювання, характерного для IRGAN, у PURE штучні користувачі та товари породжуються безпосередньо у вигляді латентних векторів, що підвищує виразність генератора та усуває обмеження, пов'язані зі списковим відбором елементів. У результаті експериментів показано, що PURE забезпечує стабільне підвищення точності на всіх трьох наборах даних. За показниками точності у найкращих п'яти рекомендацій та NDCG у найкращих п'яти, модель випереджає базові алгоритми, включно з PU-GMF, IRGAN та CFGAN.

На базі даних Movielens – 100k PURE досягає точності 0.3901 та NDCG 0.4112, що перевищує результати PU-GMF (0.3697, 0.3996) і IRGAN (0.3750, 0.4009). На Movielens – 1M перевага зберігається: точність становить 0.7523, а NDCG 0.7094, тоді як PU-GMF отримує 0.7394 та 0.6963, а IRGAN – лише 0.2713 і 0.3052.

Найбільший приріст зафіксовано на розрідженому наборі Yelp: PURE досягає 0.5830 за точністю та 0.5365 за NDCG, перевищуючи PU-GMF (0.5666, 0.5196) і значно випереджаючи IRGAN (0.2207, 0.3136).

Таким чином, SD-GAR демонструє ефективність у межах вдосконаленої схеми з негативними прикладами, тоді як PURE забезпечує більший приріст точності в задачах ранжування завдяки іншій постановці проблеми та кращій поведінці на розріджених даних.

Поряд із вже розглянутими обмеженнями в рекомендаційних системах послідовно фіксується ще одна суттєва проблема – різні форми упередженостей (bias), що впливають на точність модельних оцінок.

3. Лю та В. Ло [14] розглядають проблему упередження у рекомендаційних системах як ключовий фактор зниження точності моделей. У роботі підкреслюється, що зібрані дані взаємодій користувачів містять різні типи зміщень, зокрема «exposure bias» та позиційну упередженість (position bias). Такі викривлення спотворюють реальний розподіл переваг користувачів і ускладнюють точне навчання моделей, особливо коли використовуються імпліцитні дані, де всі відсутні інтеракції помилково трактуються як негативні.

Для розв'язання цієї проблеми вони пропонують модель FMGAN, що поєднує генеративно-змагальну архітектуру з фільтр-розширеною (Filter-enhanced) MLP-структурою (Multi-Layer Perceptron). Основна ідея полягає у фільтрації історії взаємодій до побудови представлень користувача, щоб зменшити шум, зумовлений викривленнями, та покращити узгодженість даних перед навчанням. Реалізація рішення включає генератор G , що використовує користувацькі та предметні вектори представлення, умовний вектор s та фільтр, побудований через перехід в частотну область за допомогою DFT (Discrete Fourier transform). Фільтр є навчальною комплексною матрицею K , яка модулює спектр вхідного сигналу та дозволяє приглушувати шумові компоненти. Після зворотного перетворення FFT (Fast Fourier Transform) формується очищений вектор уподобань, який подається на MLP для формування списку імовірнісних оцінок.

Окремо описується структура дискримінатора D , побудованого як лінійна MLP-структура, що відрізняє реальні списки взаємодій від синтезованих та надає градієнтні сигнали для вдосконалення генератора. Навчання здійснюється у змагальному режимі з використанням двох складових функції втрат: змагальної та MSE, що забезпечує стабільність оптимізації та стримує надмірне відхилення згенерованих оцінок від реальних даних. Результати експериментів на Movielens 100K / 1M і Ciao демонструють помітне зростання точності порівняно з MLP та попередніми GAN-орієнтованими підходами. На Movielens 100K модель FMGAN показує приріст точності у найкращих п'яти рекомендаціях: прецизійність зростає з 0.421 до 0.467, повнота – з 0.139 до 0.154, NDCG – з 0.449 до 0.496, а MRR – з 0.657 до 0.698.

Аналогічне поліпшення спостерігається й на Movielens 1M, де прецизійність підвищується з 0.402 до 0.435, а решта метрик також демонструють стабільний приріст. На високорозрідженому наборі Ciao модель також перевершує MLP: прецизійність збільшується з 0.061 до 0.070, повнота – з 0.071 до 0.081, NDCG – з 0.086 до 0.092, MRR – з 0.146 до 0.153.

На відміну від цієї роботи, де основний акцент було зроблено на зменшенні шуму та викривлень у векторах взаємодій за допомогою фільтрації, К. Ву, Ф. Ву та І. Хуан [15] зосереджуються на іншій формі систематичного спотворення – позиційній упередженості у новинних рекомендаціях. Ця упередженість виникає через різну видимість новин залежно від їхнього місця на сторінці, що безпосередньо впливає на ймовірність кліку. У статті показано, що моделі, навчені на таких даних, відтворюють не реальні інтереси користувачів, а переважно ефект позиції, що знижує точність рекомендаційних систем. Щоб усунути вплив позиційної упередженості, автори пропонують метод DebiasGAN, який містить два компоненти моделювання: модель, що враховує реальну позицію новини, та модель, у якій позиція задається випадковим чином.

Перший компонент відображає вплив фактичного місця показу на поведінку користувача, тоді як другий дозволяє оцінити умовно неупереджені оцінки переходів. Обидва компоненти формують представлення новин на основі єдиного механізму опрацювання тексту та використовують увагу, орієнтовану на поточну новину, щоб урахувати внесок попередніх переглядів у формування інтересів.

Ключовим елементом DebiasGAN є застосування змагального навчання до прихованих представлень обох моделей. Дискримінатор намагається розрізнити вектори, сформовані моделлю з реальною позицією, та вектори, отримані за умовно випадкової позиції. Натомість негативні градієнти змушують обидві моделі зближувати структуру своїх представлень, завдяки чому друга модель навчається відтворювати інтереси користувача без прив'язки до позиції новини. Загальна оптимізація моделі формулюється через об'єднану функцію втрат, що містить дві компоненти передбачення переходів і додатковий змагальний термін із коефіцієнтом α .

Результати експериментів на наборах News і Uniform дозволяють пересвідчитись, що DebiasGAN перевершує як стандартні моделі новинних рекомендацій, так і існуючі методи позиційного зменшення упередження. На наборі News значення NDCG зростає з 22.21 до 22.97, а на Uniform – з 38.66 до 39.80. Покращення спостерігається і за іншими метриками, включно з AUC та MRR. Вищий приріст на наборі Uniform пояснюється тим, що тестові дані в ньому не містять позиційної упередженості, тому модель, здатна її компенсувати, демонструє суттєво кращі результати.

Узагальнюючи результати обох досліджень, можна відзначити, що вони демонструють два різні підходи до усунення систематичних спотворень у рекомендаційних системах. У моделі FMGAN основна увага приділена покращенню якості вхідних даних шляхом фільтрації та придушення шуму у векторах взаємодій, що дає змогу підвищити точність передбачень

у сценаріях з імпліцитними даними та високою розрідженістю. У той же час DeBiasGAN спрямована на компенсацію поведінкових ефектів користувачів, насамперед позиційної упередженості, через узгодження прихованих представлень моделей з реальною та випадковою позицією показу. Обидва підходи покращують точність рекомендацій, проте роблять це на різних рівнях: FMGAN впливає на структуру та якість даних, тоді як DeBiasGAN коригує формування представлень, забезпечуючи інваріантність до спотворень, пов'язаних із механізмом подання інформації.

ВИСНОВКИ

Узагальнюючи розглянуті підходи, можна зазначити, що розрідженість даних, холодний старт, неефективне формування негативних прикладів і різні форми упередженостей залишаються базовими обмеженнями рекомендаційних систем. Класичні методи частково пом'якшують ці проблеми завдяки використанню додаткової інформації та розширеним схемам факторизації, однак їхня ефективність суттєво залежить від якості наявних ознак і узгодженості зовнішніх джерел даних. Натомість

GAN-орієнтовані моделі пропонують інший рівень вирішення обмежень: вони не стільки доповнюють дані, скільки реконструюють структуру взаємодій та латентних просторових залежностей, а також дозволяють виправляти систематичні похибки у вибірках. Завдяки змагальному навчанню такі підходи забезпечують гнучкіші механізми відновлення пропущеної інформації, адаптивну роботу в умовах холодного старту та коректнішу інтерпретацію неявних сигналів, демонструючи перспективність для задач, де класичні моделі стикаються зі структурними обмеженнями вихідних даних.

Подальші дослідження можуть бути спрямовані на узгодження підходів до роботи з розрідженими та неповними даними, формування негативних прикладів і зменшення упередженостей, оскільки наявні моделі охоплюють ці проблеми окремими механізмами. Перспективним також є аналіз взаємодії між класичними методами та GAN-орієнтованими рішеннями, порівняння їхніх припущень і обмежень, а також уточнення практичних сценаріїв, у яких застосування генеративних підходів забезпечує реальну перевагу.

REFERENCES

- [1] Raza, S., Rahman, M., Kamawal, S., Toroghi, A., Raval, A., Navah, F., & Kazemeini, A. (2024). A comprehensive review of recommender systems: Transitioning from theory to practice. *arXiv*. <https://doi.org/10.48550/arXiv.2407.13699>
- [2] Bobadilla, J., Gutiérrez, A., Yera, R., & Martínez, L. (2023). Creating synthetic datasets for collaborative filtering recommender systems using generative adversarial networks. *arXiv*. <https://doi.org/10.48550/arXiv.2303.01297>
- [3] Manaa, N., Seridi, H., & Mendjel, M. S. M. (2024). Advancements in recommender systems through the integration of generative adversarial networks. *International Journal of Informatics and Applied Mathematics*, 6(2), 35–45. Retrieved November 10, 2025, from https://www.researchgate.net/publication/286571390_A_new_active_labeling_method_for_deep_learning
- [4] Ammar Khodja, H., & Boudjeniba, O. (2022). Application of WGAN-GP in recommendation and questioning the relevance of GAN-based approaches. *arXiv*. <https://doi.org/10.48550/arXiv.2204.12527>
- [5] Prosvetov, A. V. (2019). GAN for recommendation system. *Journal of Physics: Conference Series*, 1405(1), 012005. <https://doi.org/10.1088/1742-6596/1405/1/012005>
- [6] Bouadjenek, M. R., Pacitti, E., Servajean, M., Masseglia, F., & El Abbadi, A. (2018). A distributed collaborative filtering algorithm using multiple data sources. *arXiv*. <https://doi.org/10.48550/arXiv.1807.05853>
- [7] Gao, M., Zhang, J., Yu, J., Li, J., Wen, J., & Xiong, Q. (2020). Recommender systems based on generative adversarial networks: A problem-driven perspective. *arXiv*. <https://doi.org/10.48550/arXiv.2003.02474>
- [8] Dervishaj, E., & Cremonesi, P. (2022). GAN-based matrix factorization for recommender systems. *arXiv*. <https://doi.org/10.48550/arXiv.2201.08042>
- [9] Chen, Z., Gan, W., Wu, J., Hu, K., & Lin, H. (2023). Data scarcity in recommendation systems: A survey. *arXiv*. <https://doi.org/10.48550/arXiv.2312.10073>
- [10] Fernandes, L., Miguéis, V., Pereira, I., & Oliveira, E. (2023). Towards hyper-relevance in marketing: Development of a hybrid cold-start recommender system. *Applied Sciences*, 13(23), 12749. <https://doi.org/10.3390/app132312749>
- [11] Lai, P.-L., Chen, C.-Y., Lo, L.-W., & Chen, C.-C. (2020). ColdGAN: Resolving cold start user recommendation by using generative adversarial networks. *arXiv*. <https://doi.org/10.48550/arXiv.2011.12566>
- [12] Jin, B., Lian, D., Liu, Z., Liu, Q., Ma, J., Xie, X., & Chen, E. (2020). Sampling-decomposable generative adversarial recommender. *arXiv*. <https://doi.org/10.48550/arXiv.2011.00956>
- [13] Zhou, Y., Xu, J., Wu, J., Taghavi Nasrabadi, Z., Korpeoglu, E., Achan, K., & He, J. (2020). GAN-based recommendation with positive-unlabeled sampling. *arXiv*. <https://doi.org/10.48550/arXiv.2012.06901>
- [14] Liu, Z., & Luo, W. (2023). FMGAN: A filter-enhanced MLP debias recommendation model based on generative adversarial network. *Applied Sciences*, 13(13), 7975. <https://doi.org/10.3390/app13137975>
- [15] Wu, C., Wu, F., & Huang, Y. (2021). DeBiasGAN: Eliminating position bias in news recommendation with adversarial learning. *arXiv*. <https://doi.org/10.48550/arXiv.2106.06258>

СПИСОК ВИКОРИСТАНОЇ ЛІТЕРАТУРИ

- [1] Raza, S., Rahman, M., Kamawal, S., Toroghi, A., Raval, A., Navah, F., & Kazemeini, A. (2024). A comprehensive review of recommender systems: Transitioning from theory to practice. *arXiv*. <https://doi.org/10.48550/arXiv.2407.13699>
- [2] Bobadilla, J., Gutiérrez, A., Yera, R., & Martínez, L. (2023). Creating synthetic datasets for collaborative filtering recommender systems using generative adversarial networks. *arXiv*. <https://doi.org/10.48550/arXiv.2303.01297>
- [3] Manaa, N., Seridi, H., & Mendjel, M. S. M. (2024). Advancements in recommender systems through the integration of generative adversarial networks. *International Journal of Informatics and Applied Mathematics*, 6(2), 35–45. URL: https://www.researchgate.net/publication/286571390_A_new_active_labeling_method_for_deep_learning
- [4] Ammar Khodja, H., & Boudjeniba, O. (2022). Application of WGAN-GP in recommendation and questioning the relevance of GAN-based approaches. *arXiv*. <https://doi.org/10.48550/arXiv.2204.12527>
- [5] Prosvetov, A. V. (2019). GAN for recommendation system. *Journal of Physics: Conference Series*, 1405(1), 012005. <https://doi.org/10.1088/1742-6596/1405/1/012005>
- [6] Bouadjenek, M. R., Pacitti, E., Servajean, M., Maseglia, F., & El Abbadi, A. (2018). A distributed collaborative filtering algorithm using multiple data sources. *arXiv*. <https://doi.org/10.48550/arXiv.1807.05853>
- [7] Gao, M., Zhang, J., Yu, J., Li, J., Wen, J., & Xiong, Q. (2020). Recommender systems based on generative adversarial networks: A problem-driven perspective. *arXiv*. <https://doi.org/10.48550/arXiv.2003.02474>
- [8] Dervishaj, E., & Cremonesi, P. (2022). GAN-based matrix factorization for recommender systems. *arXiv*. <https://doi.org/10.48550/arXiv.2201.08042>
- [9] Chen, Z., Gan, W., Wu, J., Hu, K., & Lin, H. (2023). Data scarcity in recommendation systems: A survey. *arXiv*. <https://doi.org/10.48550/arXiv.2312.10073>
- [10] Fernandes, L., Miguéis, V., Pereira, I., & Oliveira, E. (2023). Towards hyper-relevance in marketing: Development of a hybrid cold-start recommender system. *Applied Sciences*, 13(23), 12749. <https://doi.org/10.3390/app132312749>
- [11] Lai, P.-L., Chen, C.-Y., Lo, L.-W., & Chen, C.-C. (2020). ColdGAN: Resolving cold start user recommendation by using generative adversarial networks. *arXiv*. <https://doi.org/10.48550/arXiv.2011.12566>
- [12] Jin, B., Lian, D., Liu, Z., Liu, Q., Ma, J., Xie, X., & Chen, E. (2020). Sampling-decomposable generative adversarial recommender. *arXiv*. <https://doi.org/10.48550/arXiv.2011.00956>
- [13] Zhou, Y., Xu, J., Wu, J., Taghavi Nasrabadi, Z., Korpeoglu, E., Achan, K., & He, J. (2020). GAN-based recommendation with positive-unlabeled sampling. *arXiv*. <https://doi.org/10.48550/arXiv.2012.06901>
- [14] Liu, Z., & Luo, W. (2023). FMGAN: A filter-enhanced MLP debias recommendation model based on generative adversarial network. *Applied Sciences*, 13(13), 7975. <https://doi.org/10.3390/app13137975>
- [15] Wu, C., Wu, F., & Huang, Y. (2021). DebiasGAN: Eliminating position bias in news recommendation with adversarial learning. *arXiv*. <https://doi.org/10.48550/arXiv.2106.06258>

© Яхненко С. Г.

Дата надходження статті до редакції: 25.11.2025

Дата затвердження статті до друку: 12.12.2025

Опубліковано: 30.12.2025

Стаття поширюється на умовах ліцензії CC BY 4.0