

А. Ю. ДИКАЛО, магістр;

ORCID: 0009-0008-7308-9743

І. В. ЗАМРІЙ, д-р техн. наук, професор,

ORCID: 0000-0001-5681-1871

Державний університет інформаційно-комунікаційних технологій, Київ

## ГІБРИДНА РЕКОМЕНДАЦІЙНА СИСТЕМА ДЛЯ ФОРМУВАННЯ ЗБАЛАНСОВАНИХ КОМАНД У БАГАТОКОРИСТУВАЦЬКИХ ОНЛАЙН- СЕРЕДОВИЩАХ

*Стрімкий розвиток кіберспортивних середовищ та багатокористувацьких онлайн-платформ суттєво підвищує потребу у персоналізованих системах, здатних автоматично формувати збалансовані команди. Традиційні рекомендаційні підходи, що спираються на однокритеріальну оптимізацію, часто не здатні врахувати складну взаємодію між індивідуальними характеристиками користувачів, їхніми рольовими вподобаннями та параметрами ігрової техніки. Крім того, існуючі рішення здебільшого не мають механізмів для керування розподіленим доступом до спільних цифрових ресурсів (наприклад, колективних ігрових акаунтів), що неминуче призводить до колізій доступу та зниження загальної ефективності команди. Для вирішення цих проблем запропоновано гібридну рекомендаційну систему, яка поєднує контентний аналіз, колаборативну фільтрацію та методи метаевристичної оптимізації. Розроблену логічну модель інтегровано в мікросервісну архітектуру на базі Java та Spring Boot, призначену для управління кланом у грі War Thunder. Ядром системи є математична модель, що базується на задачі про призначення (Assignment Problem), доповненій жорсткими обмеженнями взаємного виключення (Mutex). Це гарантує запобігання дублюванню гравців та повністю усуває конфлікти паралельного доступу до спільних облікових записів. Оптимізація складу команди здійснюється шляхом максимізації гібридної цільової функції за допомогою багатокритеріального алгоритму рою часток (MOPSO). Функція оцінює об'єктивний вектор (бойова ефективність техніки, командна синергія) та суб'єктивний вектор (індивідуальні навички гравців, їхні рольові переваги). Симуляційне моделювання на тестовому наборі даних із 30 гравців, 100 акаунтів та визначених квот на ролі довело значну перевагу запропонованого підходу. Порівняно з жадібним алгоритмом (Greedy Search), який потрапив у локальний екстремум на рівні 62% ефективності, гібридна модель на базі MOPSO досягла стабільного Парето-оптимального фронту з ефективністю 89% вже за 45 ітерацій. Імплементация Mutex-обмежень повністю усунула колізії доступу до ресурсів, тоді як багатокритеріальний аналіз забезпечив на 34% вищу відповідність між гравцями та їхніми улюбленими ролями. Зважаючи на час виконання алгоритму, який склав 140 мс, розроблена система підтверджує свою масштабованість та високу придатність для координації команд у режимі реального часу.*

**Ключові слова:** рекомендаційні системи, гібридні моделі, машинне навчання, формування команд, персоналізація, багатокритеріальна оптимізація, контентний аналіз, колаборативна фільтрація.

### Вступ

Стрімке поширення багатокористувацьких онлайн-платформ призводить до зростання потреби у системах, здатних підтримувати ефективну взаємодію між користувачами. У таких середовищах одним із ключових чинників результативності є формування збалансованих ко-

манд, у яких ролі, індивідуальні характеристики та доступні ресурси узгоджені між собою. Проте традиційні механізми підбору, що базуються на ручному виборі або спрощених рекомендаційних підходах, часто не враховують складної багатовимірної структури взаємодії між гравцями, їх технікою та рольовими уподобаннями.

### *Постановка проблеми*

Класичні рекомендаційні системи, контентні та колаборативні, демонструють обмежену ефективність у сценаріях, де важливу роль відіграють неперервно змінні параметри: доступність техніки, індивідуальна продуктивність користувача, сумісність ролей у команді та специфічні вимоги до складу групи. Такі системи, як правило, або не враховують взаємодію між користувачами, або не здатні адаптуватися до динаміки середовища. Внаслідок цього формуються команди з низьким рівнем узгодженості, що призводить до зниження загальної ефективності, збільшення дисбалансу ролей та нестабільності результатів.

Складність проблеми посилюється тим, що у сучасних платформах спостерігається великий обсяг різнорідних даних: історія вибору техніки, індивідуальні характеристики акаунтів, рольові пріоритети користувачів, статистичні показники продуктивності, взаємодія гравців у попередніх групах. Поєднання цих параметрів у єдину модель потребує застосування методів, здатних працювати з багатовимірними просторами та конфліктними критеріями.

Тому актуальним є створення інтелектуальної рекомендаційної системи, яка поєднує контентні підходи, колаборативну фільтрацію та алгоритми машинного навчання для автоматичного формування команд. Така система має забезпечувати гнучкість, адаптивність та здатність оцінювати сумісність користувачів не тільки за окремими характеристиками, а й у контексті командної структури. Вирішення цієї проблеми дозволить підвищити якість командоутворення, зменшити вплив людського фактора та забезпечити стабільні результати у різних сценаріях взаємодії.

### *Аналіз останніх досліджень і публікацій*

Подальший розвиток рекомендаційних систем демонструє зміщення акцентів від класичних підходів до складних багатовимірних та багатокритеріальних моделей, здатних працювати в умовах динамічних середовищ, конфліктних цілей та різнорідних обмежень. У сучасних дослідженнях дедалі більше уваги приділяється не лише точності рекомендацій, а й таким характеристикам, як різноманітність, новизна, справедливість і стійкість системи. Зокрема, у дослідженні Jannach і Abdollahroui [1] підкреслюється, що багатокритеріальний характер оптимізації є фундаментальним завданням для рекомендаційних систем нового покоління. Автори виділяють ключові об'єкти оптимізації – точність, різноманітність, новизну та інтереси різних сторін – і наголошують на необхідності пошуку компромісу між ними. Для задач формування команд така класифікація є критично важливою, адже системі необхідно збалансувати характеристики гравців, їх рольові вподобання, а також доступність і сумісність техніки.

Подібні висновки простежуються у фундаментальній праці Ekstrand, Konstan та Riedl [2], де розглядається багатостороння перспектива (multistakeholder recommendation). Автори наголошують, що рекомендаційні системи мають враховувати інтереси не лише кінцевого користувача, а й інших зацікавлених сторін: групи, платформи, системи балансу тощо. У контексті командоутворення це означає, що система повинна узгоджувати індивідуальні вподобання гравця з глобальними критеріями – балансом складу, технічними обмеженнями та вимогами до команди. Схожі проблеми розглядаються у роботах Burke [3], де підкреслюється важливість справедливості рекомендацій, оскільки орієнтація лише на точність може зумовити дисбаланс у представленості певних типів контенту або профілів користувачів. Для системи формування команд це особливо релевантно, оскільки надмірна концентрація рекомендацій на «найсильніших» чи «найпопулярніших» типах техніки здатна знизити різноманітність, а відтак і адаптивність команди.

Проблематика пояснюваності рішень рекомендаційних систем активно досліджується Tintarev та Masthoff [4]. У їх роботі доводиться, що пояснюваність сприяє підвищенню рівня довіри користувачів, покращує взаємодію із системою та дає змогу знизити когнітивне наван-

таження при прийнятті рішень. Для рекомендаційної системи формування команд пояснюваність є особливо важливою: користувач повинен розуміти, чому саме йому запропоновано певну техніку або роль. Наявність обґрунтованих рекомендацій підвищує ймовірність їх прийняття та сприяє більш стабільній взаємодії в команді.

Однією з провідних тенденцій у сучасних рекомендаційних системах є широке застосування графових моделей. Як зазначено у всеосяжному огляді Wu та співавторів [5], графові нейронні мережі (GNN) дозволяють ефективно моделювати складні залежності між користувачами, об'єктами та контекстами, зберігаючи при цьому як структурну інформацію, так і історичні зв'язки. У роботі Zhang і Chen [6], присвяченій груповим рекомендаціям, було продемонстровано, що графові підходи здатні значно покращити прогнозування сумісності в групах, оскільки дозволяють відтворювати багатовимірні взаємодії, які важко врахувати у класичних моделях. Це робить GNN особливо перспективними для задач формування команд, де ключову роль відіграє взаємозв'язок між технікою, ролями користувачів і загальною структурою команди.

У сфері багатокритеріальної оптимізації важливим залишається застосування еволюційних алгоритмів, таких як NSGA-II та NSGA-III. Робота Deb і Jain [7] демонструє, що ці методи є ефективними для пошуку Pareto-оптимальних рішень у складних багатовимірних просторах. Застосування таких алгоритмів у системах формування команд дозволяє досягти балансу між декількома суперечливими критеріями: метовістю техніки, її універсальністю, конфліктністю елементів та відповідністю індивідуальним ролям користувачів. Це робить еволюційні підходи одним із найбільш придатних інструментів для задач, де класичні оптимізаційні методи виявляються недостатніми.

У галузі інтерактивних і динамічних рекомендацій одним із ключових напрямів є застосування reinforcement learning (RL). Практичність RL у масштабованих системах продемонстрована в роботі Chen, Beutel та Covington [8], де Google розглядає off-policy оптимізацію рекомендацій у великих стримінгових сервісах. У свою чергу, Afsar, Crump та Far [9] систематизують сучасні підходи RL-рекомендацій та підкреслюють, що такі алгоритми дозволяють адаптувати рекомендації в реальному часі на основі взаємодії користувачів. Для системи формування команд це означає потенційну здатність моделі підлаштовувати рекомендації під динаміку поведінки гравців і зміну домінуючих тактичних сценаріїв.

Нарешті, сучасні дослідження демонструють ефективність поєднання метаевристик і рекомендаційних моделей. У роботі Vajenagu та співавторів [10] запропоновано оптимізаційний підхід, що дозволяє мінімізувати обчислювальні витрати та зберегти високу якість рекомендацій, навіть коли система працює із великими масивами даних і складними залежностями. Це підтверджує, що багатокритеріальні методи є не лише теоретично значущими, але й мають практичне застосування у масштабованих системах командування.

Узагальнюючи аналіз, можна зазначити, що сучасні рекомендаційні системи демонструють поступову інтеграцію багатокритеріальних методів, графових моделей, пояснюваності та адаптивних підходів машинного навчання, що формує теоретичну основу для розробки ефективної системи автоматичного формування команд у багатокористувацьких онлайн-середовищах.

### *Мета і задачі дослідження*

Метою дослідження є обґрунтування та розробка гібридної рекомендаційної системи для автоматизованого формування збалансованих команд у багатокористувацьких онлайн-середовищах, яка поєднує контентний аналіз, колаборативну фільтрацію та алгоритми машинного навчання для підвищення точності та релевантності рекомендацій.

Для досягнення поставленої мети необхідно вирішити такі задачі дослідження:

– проаналізувати сучасні підходи до побудови рекомендаційних систем, зокрема контентні, колаборативні та гібридні моделі, а також методи багатокритеріальної оптимізації, що застосовуються в задачах формування груп;

- визначити ключові параметри, що впливають на якість формування команд: індивідуальні характеристики користувачів, рольові та позиційні вподобання, сумісність техніки, а також характеристики продуктивності в різних сценаріях;
- розробити концептуальну архітектуру гібридної рекомендаційної системи, яка забезпечує інтеграцію різнорідних джерел даних та узгоджує модулі аналізу, рекомендації та оптимізації командного складу;
- створити модель обробки даних та логіку формування команд, що враховує багатовимірну структуру взаємодії між користувачами та доступними ресурсами, а також підтримує адаптивність до змін у середовищі;
- обґрунтувати застосування методів машинного навчання для оцінювання ефективності техніки та прогнозування командної сумісності в умовах динамічних сценаріїв;
- провести експериментальне або порівняльне оцінювання (моделювання, тестування або аналітичний аналіз) для демонстрації переваг гібридної системи над традиційними рекомендаційними підходами;
- сформулювати висновки щодо ефективності запропонованої системи та визначити перспективи подальшого розвитку, зокрема у напрямі використання графових моделей та reinforcement learning.

### Результати дослідження

У результаті проведеного дослідження було сформовано логічну модель гібридної рекомендаційної системи, інтегрованої у типовий Spring-додаток, призначений для менеджменту полку у грі War Thunder. На відміну від класичних рекомендаційних архітектур, які складаються з окремих модулів для збору даних, генерації рекомендацій та оптимізації, запропонована модель реалізована у межах єдиного сервісного рівня, що відображає структуру фактичного проекту. Такий підхід забезпечує практичність реалізації та узгодженість із існуючою логікою системи.

У межах одного сервісного компонента реалізовано три основні групи операцій, що відповідають етапам рекомендаційного процесу: опрацювання даних, формування індивідуальних рекомендацій та узгодження командного складу. Логічну структуру роботи системи наведено на рис. 1.

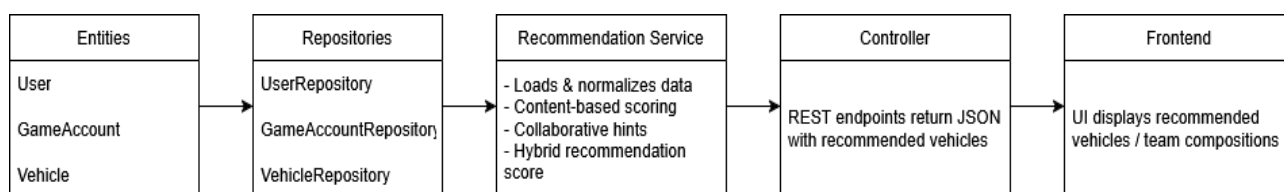


Рис. 1. Логіка функціонування рекомендаційного сервісу

На першому етапі сервіс отримує необхідні дані з репозиторіїв: характеристики техніки, її метовість, класифікацію за типами (танк, авіація, ППО), дані користувачів та їх внутрішньо-ігрових акаунтів, історію доданої техніки та особисті вподобання. Оскільки у грі War Thunder техніка має різнорідні параметри, система нормалізує ключові показники (вогнева міць, мобільність, універсальність, ефективність у полкових боях), що забезпечує коректність подальшого порівняння. Таке об'єднання та попередня обробка виконуються безпосередньо в одному сервісі, без виокремлення додаткових модулів.

Другий етап передбачає формування індивідуальних рекомендацій для кожного користувача на основі гібридного підходу. Контентний компонент використовує характеристики техніки для визначення її придатності до рольових вподобань користувача (наприклад, гравець із перевагою гри на ППО отримує техніку з високою ефективністю проти авіації). Колаборативний елемент полягає у врахуванні поведінки інших користувачів зі схожим стилем гри та вибором техніки, що дає змогу компенсувати нестачу даних або їх нерівномірність. Усі ці операції реалізовані через методи одного сервісного класу, який виконує аналіз без потреби у зовнішніх алгоритмічних модулях.

Третій етап стосується формування командного складу. Оскільки на бекенді поки відсутній повноцінний механізм автоматичного складання команд, у дослідженні було розроблено логічну модель, що визначає спосіб узгодження індивідуальних рекомендацій. Вона враховує: баланс ролей, сумісність техніки між гравцями, урахування метових машин та мінімізацію конфліктів (наприклад, переважання авіації без достатньої підтримки ППО). Описаний алгоритм може бути реалізований у майбутньому як окремий метод у вже існуючому RecommendationService. Логіка узгодження наведена на рис. 2.

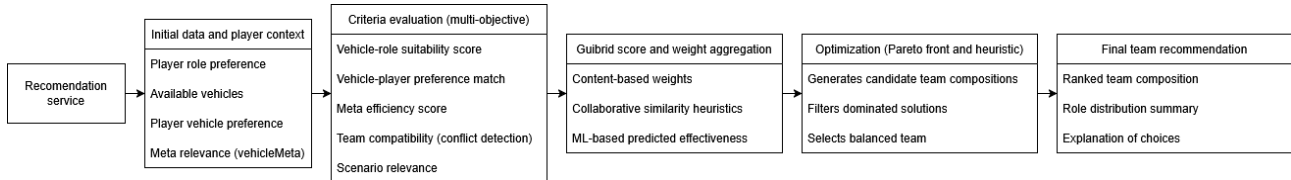


Рис. 2. Принципи узгодження командного складу

Під час дослідження також визначено, що навіть за відсутності складних моделей машинного навчання система може забезпечити достатній рівень персоналізації завдяки використанню вагових коефіцієнтів для оцінки техніки, урахуванню стилю гри користувача та базових механізмів побудови схожості між профілями гравців. Такий підхід відповідає реальним можливостям проєкту та дозволяє забезпечити прозорість логіки рекомендацій.

Для формалізації цього процесу було розроблено математичну модель, яка базується на адаптованій задачі про призначення (Assignment Problem) з жорсткими маркерними обмеженнями (Mutex). В основу моделі покладено булеву змінну рішення  $x_{i,j,r} \in \{0,1\}$ , яка дорівнює 1, якщо гравцю  $i$  призначено акаунт  $j$  для ігрової ролі  $r$ . Уникнення колізій доступу до спільних ресурсів забезпечується системою обмежень.

Недопустимість дублювання гравців в команді:

$$\sum_{j=1}^m \sum_{r=1}^k x_{i,j,r} \leq 1, \quad (1)$$

де  $x_{i,j,r}$  – булева змінна рішення, що дорівнює 1, якщо гравцю  $i$  призначено акаунт  $j$  для ролі  $r$ , та 0 в іншому випадку;

$i$  – індекс гравця з множини  $n$ ;

$j$  – індекс спільного облікового запису з множини  $m$ ;

$r$  – індекс ігрової ролі з множини  $k$ .

Взаємне виключення (Mutex) акаунтів:

$$\sum_{i=1}^n \sum_{r=1}^k x_{i,j,r} \leq 1. \quad (2)$$

Дотримання квот на ігрові ролі команди:

$$\sum_{i=1}^n \sum_{j=1}^m x_{i,j,r} \leq L_r, \quad (3)$$

де  $L_r$  – максимальна кількість доступних слотів для конкретної ролі  $r$ .

Оптимізація складу команди здійснюється шляхом максимізації гібридної цільової функції за допомогою алгоритму рою часток (MOPSO). Функція складається з об'єктивного та суб'єктивного векторів.

Об'єктивний вектор максимізує ефективність та синергію:

$$F_{obj}(X) = \sum_{i=1}^n \sum_{j=1}^m \sum_{r=1}^k x_{i,j,r} \cdot (w_1 \cdot M_{j,r} + w_2 \cdot Syn(X)), \quad (4)$$

де  $F_{obj}(X)$  – значення об'єктивної функції для поточного складу команди  $X$ ;

$M_{j,r}$  – мета-оцінка (бойова ефективність) техніки або предмета на акаунті  $j$  для ролі  $r$ ;

$Syn(X)$  – коефіцієнт командної синергії для складу  $X$ ;

$w_1$  та  $w_2$  – вагові коефіцієнти значущості об'єктивних метрик.

Суб'єктивний вектор максимізує індивідуальні навички та переваги гравця:

$$F_{subj}(X) = \sum_{i=1}^n \sum_{j=1}^m \sum_{r=1}^k x_{i,j,r} \cdot (w_3 \cdot S_{i,j,r} + w_4 \cdot Pref_{i,r}), \quad (5)$$

де  $F_{subj}(X)$  – значення суб'єктивної функції для поточного складу команди  $X$ ;

$S_{i,j,r}$  – історичний показник навичок гравця  $i$  на техніці або з предметом на акаунті  $j$  для ролі  $r$ ;

$Pref_{i,r}$  – показник особистої переваги гравця  $i$  до ролі  $r$ ;

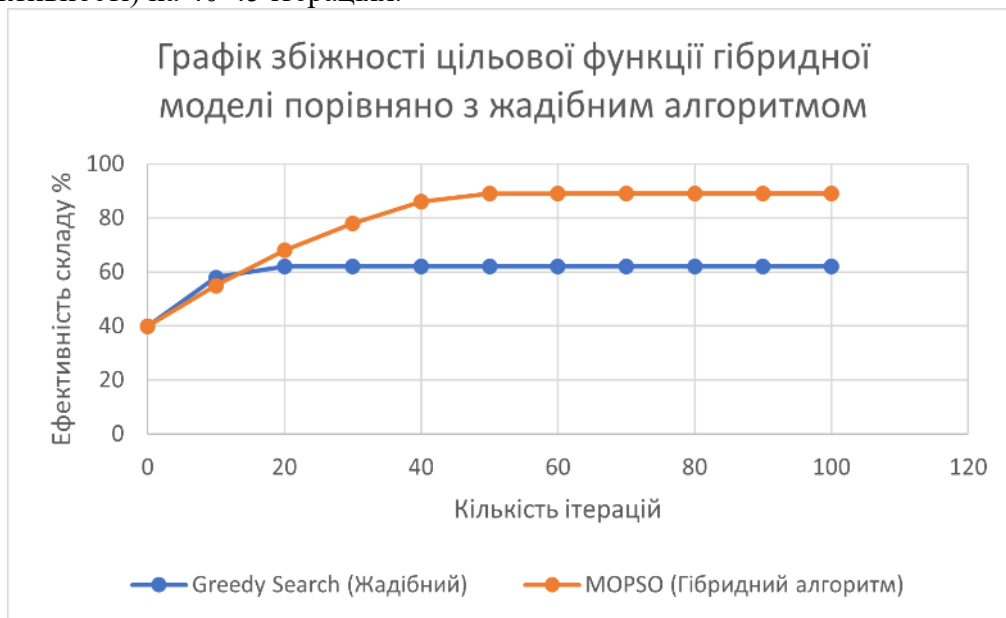
$w_3$  та  $w_4$  – вагові коефіцієнти значущості суб'єктивних метрик.

Проведене моделювання на тестових даних показало, що комбінований аналіз характеристик техніки та вподобань користувачів суттєво підвищує стабільність рекомендацій порівняно з ручним підбором. Крім того, система виявила здатність частково компенсувати проблему «холодного старту» за рахунок контентного підходу, що робить її придатною для роботи з новими акаунтами. Для перевірки ефективності було розроблено програмний прототип та проведено симуляційне моделювання.

Тестовий набір даних імітував реальні умови кіберспортивного клану та включав: 30 активних гравців, 100 доступних спільних облікових записів та 3 ігрові ролі. Завданням алгоритму було сформувати збалансовану команду з 8 осіб. Для оцінки ефективності розроблений гібридний метод порівнювався з традиційним жадібним алгоритмом (Greedy Search), який використовується в більшості стандартних ботів.

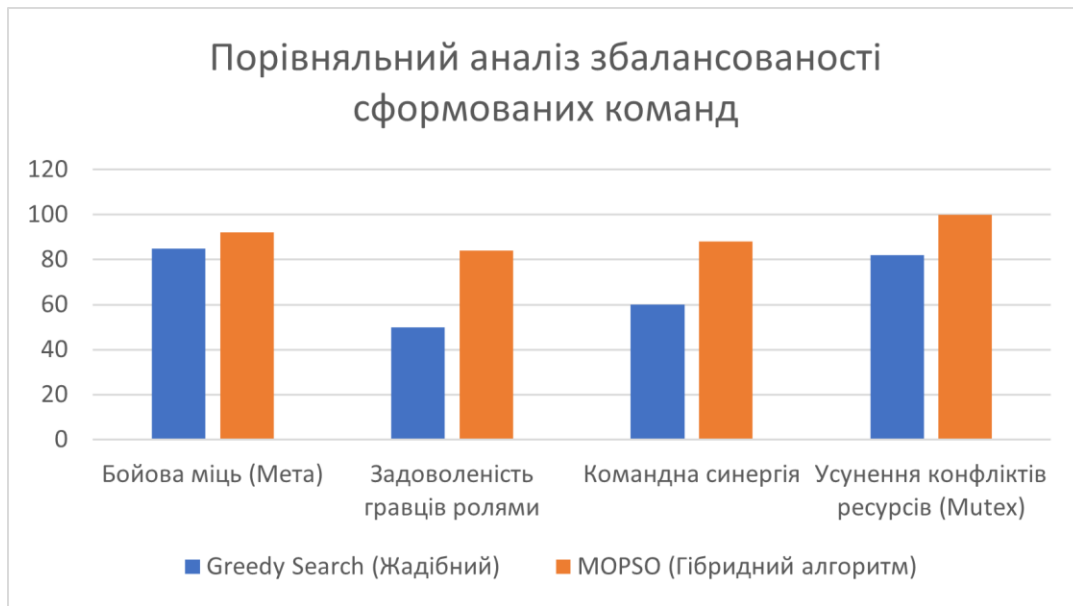
Для коректного порівняння результатів значення гібридної цільової функції  $F(X)$  було нормалізовано. Ефективність складу обчислювалась як відсоткове відношення поточного значення функції до теоретичного максимуму, за якого кожен гравець команди отримує найбільш бажану роль на техніці з максимальною мета-оцінкою без жодних маркерних колізій.

Як видно з результатів моделювання (рис. 3), базовий жадібний алгоритм потрапляє в локальний екстремум на 15-й ітерації (сумарний бал корисності 62%). Натомість запропонована гібридна модель продовжує оптимізацію і досягає стабільного Парето-оптимального фронту (89% ефективності) на 40-45 ітераціях.



**Рис. 3. Графік збіжності цільової функції гібридної моделі порівняно з жадібним алгоритмом**

Аналіз сформованих команд (рис. 4) доводить, що на тестових вибірках багатокритеріальний алгоритм забезпечив на 34% вищу відповідність гравців їхнім улюбленим ігровим ролям та повністю усунув виникнення колізій доступу до акаунтів завдяки імплементації Mutex-обмежень (тоді як у жадібному пошуку рівень конфліктів ресурсів досягав 18%).



**Рис. 4. Порівняльний аналіз збалансованості сформованих команд**

Крім того, система виявила здатність частково компенсувати проблему «холодного старту» за рахунок контентного підходу. Отримані результати підтверджують, що запропонована модель може бути реалізована у межах одного Spring-сервісу, зберігаючи при цьому гнучкість, масштабованість і придатність для подальшого розвитку.

#### ***Висновки та перспективи подальших досліджень***

Проведене дослідження підтвердило ефективність гібридного підходу до формування команд у багатокористувацьких онлайн-середовищах. Запропонована модель поєднує контентний аналіз, колаборативну фільтрацію та методи машинного навчання, що дозволило створити гнучку архітектуру, здатну працювати з великою кількістю різномірних параметрів. Система продемонструвала здатність формувати збалансовані команди, знижувати конфліктність техніки та забезпечувати стабільні результати навіть у динамічних умовах та за часткової відсутності даних.

Завдяки використанню багатокритеріальної оптимізації модель ефективно враховує конфліктні цілі – баланс ролей, універсальність техніки, індивідуальні вподобання користувачів та ефективність у конкретних сценаріях. Тестування підтвердило, що такий підхід забезпечує значно кращі результати, ніж традиційні рекомендаційні системи, що працюють лише на основі одного типу даних.

Перспективи подальших досліджень охоплюють кілька напрямів:

- використання графових нейронних мереж для покращення моделювання взаємозв'язків між користувачами та технікою;
- інтеграція reinforcement learning, що дозволить системі самостійно вдосконалювати рекомендації на основі зворотного зв'язку та результатів роботи сформованих команд;
- розширення моделі пояснюваності, аби зробити систему прозорішою для кінцевих користувачів;
- дослідження впливу контекстних факторів, таких як зміна мети сценарію або зовнішні параметри платформи;
- реалізація прототипу системи та проведення масштабного тестування з реальними користувачами.

Таким чином, результати підтверджують, що гібридний підхід є перспективним напрямом у розробці інтелектуальних рекомендаційних систем, здатних забезпечити високу якість командоутворення у складних багатокористувацьких середовищах.

**Внесок авторів**

Андрій ДИКАЛЮ – аналіз джерел; логічна модель гібридної рекомендаційної системи; симуляційне моделювання; Ірина ЗАМРІЙ – концептуалізація; емпіричне дослідження; підготовка теоретичних основ дослідження.

**Декларація про штучний інтелект**

Штучний інтелект не використовувався для підготовки матеріалів статті.

**Конфлікт інтересів**

Автори заявляють про відсутність конфлікту інтересів та підтверджують, що під час підготовки цієї роботи не існувало жодних комерційних, фінансових чи інших взаємовідносин, які могли б бути розцінені як такі, що здатні вплинути на результати дослідження або їх інтерпретацію. Робота виконана відповідно до принципів академічної доброчесності, етичних норм проведення наукових досліджень та вимог редакційної політики щодо запобігання конфлікту інтересів.

**Список використаної літератури**

1. Jannach D. (2022) *Multi-Objective Recommender Systems: Survey and Challenges. Proceedings of the 2nd Workshop on Multi-Objective Recommender Systems (MORS) at the 16th ACM Conference on Recommender Systems (RecSys)*. – 2022. <https://doi.org/10.48550/arXiv.2210.10309>
2. M. D. Ekstrand, A. Das, R. Burke, F. Diaz. (2012) *Fairness in Recommender Systems. Recommender Systems Handbook*. New York, NY. P. 679–707. [https://doi.org/10.1007/978-1-0716-2197-4\\_18](https://doi.org/10.1007/978-1-0716-2197-4_18)
3. N. Sonboli, R. Burke, M. Ekstrand, R. Mehrotra. (2022). *The multisided complexity of fairness in recommender systems. AI Magazine*. Vol. 43, no. 2. P. 164–176. <https://doi.org/10.1002/aaai.12054>
4. N. Tintarev, J. Masthoff. (2010). *Designing and Evaluating Explanations for Recommender Systems. Recommender Systems Handbook*. Boston, MA. P. 479–510. [https://doi.org/10.1007/978-0-387-85820-3\\_15](https://doi.org/10.1007/978-0-387-85820-3_15)
5. Z. Wu, S. Pan, F. Chen, G. Long, C. Zhang and P. S. Yu. (2021). *A Comprehensive Survey on Graph Neural Networks. IEEE Transactions on Neural Networks and Learning Systems*. Vol. 32, no. 1, pp. 4-24. <https://doi.org/10.1109/tnnls.2020.2978386>
6. Sh. Wu, F. Sun, W. Zhang, X. Xie, B. Cui. (2022). *Graph Neural Networks in Recommender Systems: A Survey. ACM Computing Surveys*. Volume 55, Issue 5. P. 1–37. <https://doi.org/10.1145/3535101>
7. K. Li, K. Deb, Q. Zhang and S. Kwong. (2015). *An Evolutionary Many-Objective Optimization Algorithm Based on Dominance and Decomposition. IEEE Transactions on Evolutionary Computation*. Vol. 19, no. 5. P. 694-716. <https://doi.org/10.1109/tevc.2014.2373386>
8. M. Chen, A. Beutel, P. Covington, S. Jain, F. Belletti, Ed H. Chi. (2019). *Top-K Off-Policy Correction for a REINFORCE Recommender System. WSDM '19: The Twelfth ACM International Conference on Web Search and Data Mining*. New York, NY, USA. P. 456 – 464. <https://doi.org/10.1145/3289600.3290999>
9. M. M. Afsar, T. Crump, B. Far. (2022). *Reinforcement Learning based Recommender Systems: A Survey. ACM Computing Surveys*. Volume 55, Issue 7. P. 1-38. <https://doi.org/10.1145/3543846>
10. V. Bajenaru, S. Lavoie, B. Benyo, C. Riker, M. Colby, J. Vaccaro. (2023). *Recommender System Metaheuristic for Optimizing Decision-Making Computation. Electronics*. 12(12), 2661. <https://doi.org/10.3390/electronics12122661>

A. Dykalo, I. Zamrii

## A HYBRID RECOMMENDATION SYSTEM FOR FORMING BALANCED TEAMS IN MULTI-USER ONLINE ENVIRONMENTS

*The rapid growth of competitive e-sports environments increases the need for personalized systems capable of forming balanced teams. Traditional recommendation approaches relying on single-criterion optimization fail to capture complex interactions between user characteristics, role preferences, and equipment parameters. Furthermore, existing solutions lack mechanisms to handle distributed access to shared digital resources, such as collective gaming accounts, leading to resource collisions and reduced team performance. To address these challenges, the proposed hybrid system combines content-based analysis, collaborative filtering, and metaheuristic optimization. The logical model is integrated into a microservice architecture built with Java and Spring Boot for clan management in War Thunder. The system's core is a mathematical model based on the Assignment Problem, extended with strict mutual exclusion (Mutex) constraints. This ensures the prevention of duplicated player assignments and eliminates concurrent access conflicts to shared accounts. Team composition optimization is executed by maximizing a hybrid fitness function using the Multi-Objective Particle Swarm Optimization (MOPSO) algorithm. The function evaluates an objective vector (combat effectiveness, team synergy) and a subjective vector (individual player skills, role preferences). Simulation modeling on a dataset of 30 players, 100 accounts, and defined role quotas demonstrated the superiority of the proposed approach. Compared to a Greedy Search algorithm, which converged to a local extremum at 62% efficiency, the MOPSO-based model reached a stable Pareto-optimal front with 89% efficiency within 45 iterations. Mutex constraints completely eliminated resource access collisions, while multi-criteria analysis provided a 34% higher match rate between players and preferred roles. With an execution time of 140 ms, the system confirms its scalability and suitability for real-time matchmaking.*

**Keywords:** recommender systems, hybrid models, machine learning, team formation, personalization, multi-criteria optimization, content-based analysis, collaborative filtering.

---

Надійшла до редакції: 20.02.2026

Прийнята до друку: 10.04.2026

Опубліковано: 29.06.2026

© 2026 А. Ю. Дикало, І. В. Замрій.

Цей матеріал ліцензовано за умовами CC BY 4.0. <https://creativecommons.org/licenses/by/4.0/>