selection operator only and effect of selection pressure is excluded. The lower the selection noise, the larger η and PRR, and vice versa.

For theoretical estimates of PRR values, see Table 1. Note that PRR for probabilistic tournaments can be obtained from PRR for deterministic tournaments at t=2. Values of PRR for ranking SSs based on RWS are bounded from above by $1-\left(\frac{N-1}{N}\right)^N$. Details can be found in [2].

Table 1. Theoretical estimates of PRR values.

Selection scheme	PRR
SUS, SUS scaled	1
RWS, RWS scaled	$1-\left(\frac{N-1}{N}\right)^N$
Deterministic tournament without replacement	$1-\left(\frac{N-k}{N}\right)^t * \left(\frac{N-i}{N}\right), k=\left\lfloor\frac{N}{t}\right\rfloor, i=N-k*t$
Deterministic tournament with partial replacement	$1-\prod_{i=0}^{t-1}\frac{(t-1)*N-i}{t*N-i}$
Deterministic tournament with replacement	$1-\left(\frac{N-1}{N}\right)^N$
Linear ranking based on SUS, $1<\beta\leq 2$	$1-\frac{\beta-1}{4}$
Exponential ranking based on SUS, $0<c<1$	$1-\left(\frac{1-\ln\frac{\alpha-1}{\alpha\ln\alpha}}{\ln\alpha}-\frac{\alpha}{\alpha-1}\right), \alpha=c^N$

The following empirical approach is used in our study of genetic drift. We conduct multiple runs of GA with a SS under analysis; no other genetic operator is used, thus, the population of offspring matches the mating pool. Runs are conducted on a flat fitness function, hence, the effect of selection pressure is eliminated. GA stops when population becomes homogeneous or when allocated time resources are spent. For each run, the number of iterations performed by the algorithm and PRR average over generations are saved. Afterwards, the average and standard deviation of number of iterations and of PRR average are calculated for the runs when the algorithm stops under the population homogeneity condition. Based on these values, η and PRR are estimated.

Our theoretical estimates of PRR are supported by the experiments. We revealed the same effect of scheme specific parameters on both the PRR and η metrics. We confirmed empirically that there is a strong relationship between η and population size N. Moreover, we found that for RWS and RWS scaled SSs as well as for all tournament and linear ranking SSs the value of η increases proportionally to N.

We have also compared selection pressure equivalent schemes to be selection noise equivalent. We found differences in selection noise for most of the known selection pressure equivalent schemes. Therefore, the choice of a SS for a practical problem should be based on the selection pressure as well as on the selection noise scheme characteristics [2].

1. Bäck, T. H. W., Kononova, A. V., Van Stein, B., Wang, H., Antonov, K. A., Kalkreuth, R. T., De Nobel, J., Vermetten, D., De Winter, R., & Ye, F. (2023). Evolutionary algorithms for parameter optimization – Thirty years later. *Evolutionary Computation*, *31*(2), 81–122. https://doi.org/10.1162/evco_a_00325
2. Gulayeva, N., Borrego-Díaz, J., & Sancho-Caparrini, F. (in press). Analysis of selection noise in genetic algorithms. *Soft Computing.*

Національний університет «Києво-Могилянська академія»
Email: glib@ukma.edu.ua, n.bachynskyi@ukma.edu.ua

SIMA (Scalable, Instructable, Multiworld Agent) is a project by Google DeepMind aimed at creating an agent capable of executing natural language instructions across diverse 3D environments. SIMA operates through a single keyboard-and-mouse interface in both commercial video games and research platforms, making it distinct from task-specific AI systems like OpenAI Five or AlphaStar. It processes visual input akin to what a human player sees and executes commands categorized for balanced skill training. SIMA demonstrates an ability to transfer knowledge and perform tasks across environments, though challenges remain in long-term planning and complex physical interactions.

Задача створення узагальненого агента штучного інтелекту, як частковий випадок загального ШІ (AGI, універсального вирішувача задач) є однією з найскладніших задач сучасної науки. Створення такого агента обов'язково включає здатність засвоювати нові навички без спеціального програмування, адаптуватися до незнайомих ситуацій і ухвалювати ефективні рішення. Задоволення цих вимог потребує значних технічних проривів та обчислювальних ресурсів.

Комерційні відеоігри забезпечують візуально багаті середовища для складних завдань, включаючи збір ресурсів, будівництво, планування дій і орієнтацію у просторі. Відеоігри є ефективним середовищем для дослідження універсальних ШІ-агентів, дозволяючи тестувати алгоритми для адаптації, навчання з досвіду та стратегічного мислення. У 2019 році DeepMind представила агента **AlphaStar** [2], який досяг рівня професійних гравців у *StarCraft II*. Агент навчався через імітацію ігор професійних гравців і самостійне тренування, демонструючи довгострокове планування, адаптацію до суперників і управління багатьма юнітами. Тоді ж OpenAI створила **OpenAI Five** [1], агентів, які змагалися в *Dota 2*. Агенти демонстрували командну роботу, адаптацію до стратегій суперників і здатність до співпраці у динамічному середовищі.

Google DeepMind спираючись на багаторічний досвід, представила нового агента – Scalable, Instructable, Multiworld Agent (SIMA) [3]. Цей проєкт є важливим етапом у напрямку розвитку загального штучного інтелекту, відображаючи прогрес, досягнутий у галузі за останні роки.

Основною метою проєкту **SIMA** є створення агента, здатного виконувати мовні інструкції у різноманітних тривимірних середовищах, включаючи комерційні відеоігри та спеціалізовані дослідницькі платформи, використовуючи клавіатуру та мишу. SIMA вирізняється здатністю поєднувати природномовне розуміння з дією, демонструючи високу адаптивність і генералізацію знань у контекстах, що варіюються від реальних симуляцій до міфічних чи науково-фантастичних сценаріїв.

Дослідницькі платформи, такі як *Construction Lab*, *Playhouse*, *ProcTHOR* і *WorldLab*, пропонують контрольовані умови з реалістичною фізичною взаємодією для моделювання повсякденних

завдань, таких як пошук об’єктів чи прибирання. Завдання в цих середовищах характеризуються невизначеністю, великим простором можливих дій і відсутністю чітких алгоритмів вирішення, що робить їх інтелектуальними задачами для агента, які вимагають адаптації, аналізу та ухвалення рішень у змінних умовах.

Тренування агента SIMA здійснювалося за допомогою навчання з учителем, використовуючи записи ігрових сесій реальних людей, доповнені метаданими. При цьому агент отримував лише зображення, рендерене (візуалізує середовище через віртуальну камеру) грою (таке саме, яке бачить звичайний гравець), а також інструкцію, задану природною мовою, яку необхідно виконати. Для забезпечення рівномірного навчання команди були вручну кластеризовані за логічними категоріями дій. Додатково були створені з нуля трансформерні моделі, результати яких передаються до нейронної мережі, що генерує дії клавіатури та миші. Навчання агента базується на повторенні поведінки, заснованої на записах дій людини.

Оцінювання агента SIMA ускладняються відсутністю загальних критеріїв успіху, обмеженим доступом до даних середовищ у комерційних іграх та високою вартістю завантаження завдань. Для оцінки використовуються різні методи. Результати роботи агента на сімох середовищах, детально описані у [3, 16], показують, що агент SIMA здатен виконувати широкий спектр завдань в різноманітних середовищах, хоча і залишається чималий простір для покращень. Зрозуміло, що важливою є і оцінка вміння агента до узагальнення.

Порівняння агента **SIMA** проведено з базовими моделями та модифікаціями для оцінки його продуктивності у різних середовищах. Він демонстрував високу ефективність, особливо у zero-shot сценаріях, де потрібно переносити знання в середовища, на яких не навчався. Агенти без попередньо навчених енкодерів показують суттєво нижчу продуктивність, що підкреслює важливість використання перетренованих моделей. Модифікація без мовного компонента значно поступається продуктивності, підтверджуючи критичну роль мови. Основний агент SIMA демонстрував кращу продуктивність (67%), ніж спеціалізовані агенти, що засвідчує позитивне перенесення навичок між середовищами.

SIMA також перевищує базові моделі. Агент без попереднього навчання показав значно гірші результати. Модель без мовного компонента показала низьку продуктивність, що засвідчує активне використання агентом мовних інструкцій, а не лише ймовірнісних поведінкових шаблонів.

У роботі [3, 20] приведено результат порівняння роботи агента і з продуктивністю роботи людини. Хоча люди і показують кращий результат ніж агенти, проте і їхня точність складає лише 60%. Ми вважаємо цей показник дуже важливим, адже завдання, які виконувалися не були чисто механічними, де машина легко може перевершити людину. Вони виражали досить комплексні і

нетривіальні завдання (інтелектуальні задачі). Порівняння показало наскільки насправді агент наблизився до людської продуктивності, тобто по даному критерію результати можна вважати кращими ніж при абсолютній оцінці, адже продуктивність агента склала приблизно 50% від продуктивності людини.

SIMA — проєкт, спрямований на створення агента, здатного пов'язувати мовні інструкції з поведінкою у насичених 3D-середовищах. Хоча агент демонструє перенесення навичок між середовищами, включаючи zero-shot навчання, але багато завдань залишаються недосяжними. Майбутні дослідження зосереджені на масштабуванні до нових середовищ, підвищенні стійкості агентів, використанні якісніших моделей та розробці точних методів оцінювання, що зробить SIMA важливою платформою для дослідження AGI.

SIMA демонструє значний прогрес у перенесенні навичок між середовищами та виконанні базових дій у нових умовах без попереднього навчання (zero-shot). Водночас багато завдань залишаються недосяжними, що вказує на необхідність подальших досліджень. Цей проєкт відкриває перспективи для створення універсального ШІ, здатного розв'язувати складні завдання в симульованих середовищах.

Список літератури

1. Berner, C., Brockman [та ін.] (2019). Dota 2 with Large Scale Deep Reinforcement Learning. *https://doi.org/10.48550/arXiv.1912.06680*.

2. Mathieu, M., Ozair, S. [та ін.] (2023). AlphaStar Unplugged: Large-Scale Offline Reinforcement Learning. *https://doi.org/10.48550/arXiv.2308.03526*.

3. Team, S., Raad [та ін.] (2024). Scaling Instructable Agents Across Many Simulated Worlds. *https://doi.org/10.48550/arXiv.2404.10179*.

МЕТОДИ ШВИДКОГО ВИЯВЛЕННЯ ПОДІБНОСТЕЙ НА ЗОБРАЖЕННЯХ З БПЛА
Божок А.И.,Панченко Т.В..

METHODS FOR FAST DETECTION OF SIMILARITIES IN IMAGES FROM UAV
Bozhok A.V., Panchenko T.V.
Київський національний університет імені Тараса Шевченка / Taras Shevchenko National University of Kyiv
01601, Київ, вул. Володимирська, 64/13, тел. (044) 239-33-33, E-mail: artembozh@gmail.com

This research focuses on developing rapid methods for detecting similarities between images captured by Unmanned Aerial Vehicles and sections of orthophoto plans. The primary objective is to determine the degree of similarity to facilitate the localization of drones in the absence of GPS signals.