

КЛОНИРОВАНИЕ ПОВЕДЕНИЯ МЕЖДУ ВАРИАНТАМИ ИГР: ДОМЕННАЯ АДАПТАЦИЯ И ПЕРСОНАЛИЗАЦИЯ МОДЕЛИ В ШАХМАТАХ ФИШЕРА

Т. Р. Арсланов^[0009-0002-1110-8503]

Казанский (Приволжский) федеральный университет, г. Казань, Россия

timars-mail@yandex.ru

Аннотация

Клонирование поведения позволяет создавать модели, способные принимать решения так же, как это делает человек. Хотя различные модели успешно предсказывают действия человека в играх, их способность имитировать отдельных игроков снижается при изменении вариантов игры.

В работе исследованы стратегия доменной адаптации и персонализации на примере шахмат Фишера со случайной расстановкой фигур. На базе шахматной модели Maia, протестировано несколько стратегий дообучения. Установлены три ключевых закономерности: старые записи игрока не оказывают влияния; каждая новая запись крайне эффективна; доменная адаптация и персонализация дополняют друг друга – их сочетание дает лучший результат.

Ключевые слова: *игры, искусственный интеллект, моделирование игрока, клонирование поведения, шахматы.*

ВВЕДЕНИЕ

Клонирование поведения (behavioral cloning) – это метод обучения на демонстрациях человеческого поведения, который позволяет ИИ-системам имитировать человеческое принятие решений. Он помогает достичь понимания, как именно играют люди, включая характерные неоптимальные решения. В контексте разработки игр это важно для тестирования баланса, адаптации противников и персонализации игрового опыта [1].

В отличие от методов клонирования поведения, классические методы машинного обучения создают системы, способные показывать высокие результаты в играх. Тем не менее действия таких систем слабо напоминают человеческие [2, 3].

Специализированные модели также имеют определенные ограничения. Например, давно известна проблема применимости полученных навыков в смежных областях [4]. На практике это означает сложности в адаптации к новому контенту, т. е. например поведение модели, обученной на старых игровых картах, не будет соответствовать поведению игроков на новых картах. Понимание того, какие данные необходимы для поддержания качества моделей в новых условиях, имеет прямое практическое значение для игровой индустрии.

Ранее мы предложили схему генерации персонажей, персонализированных под конкретных игроков, в которой такие ИИ-агенты используются как инструмент симуляции и тестирования нового контента [5]. Игровой прототип для проверки возможностей такой системы, создаваемый нами, обладает строго описанным набором правил и механик, в рамках фреймворка FAST-GM [6]. Поэтому в настоящей работе для анализа, какие стратегии адаптации и персонализации позволят быстро подстроить модель под новые условия, мы использовали шахматы с четко формализованными механиками.

Одним из лучших примеров ИИ-моделей игроков является Maia, разработанная для шахмат. В своей работе авторы добились того, что их модель точно предсказывает следующий ход конкретного игрока в 55% случаев [7]. Для этого они использовали двухэтапный подход к дообучению. В ходе первого этапа были использованы результаты игроков, похожих по рейтингу и стилю. В ходе второго этапа было проведено дообучение на малом объеме данных конкретного игрока.

Для шахматных моделей новым контентом будут различные варианты шахмат. Одним из самых популярных являются шахматы Фишера, также известные как шахматы 960 (по числу начальных позиций). Их пространство действий и игровая механика остаются неизменными по сравнению с обычными правилами. В то же время здесь неприменима классическая дебютная теория, что вынуждает игроков вырабатывать новые стратегии.

БЛИЗКИЕ ПО ТЕМАТИКЕ РАБОТЫ

Поведенческое клонирование относится к классу методов имитационного обучения. Помимо него применяют и более сложные системы, в том числе со-

ствязательного имитационного обучения (adversarial imitation learning), где обучение сводится к приближению распределения «состояние–действие» эксперта без явной функции награды [8].

В разработке игр такие методы позволяют персонализировать игровой опыт благодаря поведению конкретных игроков. Обзор подходов к моделированию игроков и типичным источникам данных представлен в работе Яннакиса [9]. Ранее он же вместе с Тогелиусом предложил фреймворк процедурной генерации, основанной на опыте (experience-driven PCG), где генерация и/или адаптация контента опираются на вычислительные модели пользовательского опыта [10, 11].

Наконец, множество работ было посвящено обучению моделей по данным игроков. Так, AlphaStar обучался игре в StarCraft II по человеческим реплеям, после чего дообучался, играя сам с собой [12]. Помимо стратегий также описаны подходы к клонированию поведения игрока в шутерах от первого лица, например в Counter-Strike GO и Doom 2 [13, 14].

МЕТОДОЛОГИЯ

Проанализирована эффективность различных стратегий дообучения модели на базе ответов на пять вопросов:

1. Насколько падает точность предсказаний модели, обученной на стандартных шахматах, при применении к шахматам Фишера?
2. Помогают ли данные игрока из стандартных шахмат предсказывать его ходы в шахматах Фишера?
3. Насколько эффективны данные из нового варианта от других игроков?
4. Дает ли добавление данных конкретного игрока из нового варианта дополнительный выигрыш поверх доменной адаптации?
5. Насколько снижается точность исходной модели после ее адаптации к новым правилам?

В качестве основы выбрана предобученная модель Maia. Для ее обучения авторы использовали более 20 млн человеческих партий с платформы Lichess. Модель принимает на вход позицию на доске и выдает распределение вероятностей по допустимым ходам [7]. Подобный подход – использование низкоуров-

невых действий для моделирования игрока – встречается также у других авторов в контексте видеоигр [15].

Исходная модель проходит дообучение на различных данных: записи партий игрока в обычные шахматы и шахматы Фишера, записи множества игроков о партиях в шахматы Фишера. Все партии также были сыграны в Lichess.

Предполагается, что на практике имеется небольшое число записей игр с новым вариантом для конкретного игрока. Поэтому соответствующим образом были скорректированы размеры наборов данных для дообучения: 150 партий для шахмат Фишера и 500 партий в стандартные шахматы.

Так как миттельшпиль и эндшпиль не отличаются в двух вариантах игры, для проверки эффективности стратегий были отобраны только дебюты из 450 партий, что суммарно дало тестовую выборку в 4100 ходов.

Кроме того, нужно было оценить, насколько ухудшилось предсказание для классических шахмат после дообучения (т. е. происходит ли деградация качества в исходном домене). Для этого была использована выборка в 5000 дебютных ходов из 500 партий.

Размеры выборок для всех конфигураций представлены в табл. 1, выборки не пересекаются между собой. Профиль игрока для тестирования был выбран, исходя из наличия большого числа партий, а также из относительно высокого рейтинга (ELO 1800-2000), в предположении, что к данному моменту у него сформировался определенный стиль игры.

В качестве метрики были выбраны два показателя:

- точность Тор-1: предсказанный моделью ход в точности совпадает со сделанным;
- точность Тор-3: сделанный ход входит в тройку наиболее вероятных предсказаний модели.

В учетом вероятностного характера вывода модели можно утверждать, что три лучших прогноза могут дать более полное представление о том, насколько она приближена к реальному игроку.

Табл. 1. Исходные данные.

Конфигурация	Описание	Данные для дообучения
(a)	базовая модель	нет
(b)	персонализация под стандартную игру	500 партий в стандартные шахматы (целевой игрок)
(c)	доменная адаптация	800 тыс. партий в шахматы Фишера (разные игроки)
(d)	персонализация в шахматах Фишера	150 партий в шахматы Фишера (целевой игрок)
(e)	доменная адаптация + персонализация	800 тыс. партий в шахматы Фишера + 150 партий игрока в шахматы Фишера

РЕЗУЛЬТАТЫ

Результаты тестирования всех выбранных моделей представлены в табл. 2.

Табл. 2. Результаты тестирования.

Конфигурация	Описание	Топ-1	Топ-3
(a)	базовая модель	30.61%	55.55%
(b)	персонализация под стандартную игру	30.17%	55.44%
(c)	доменная адаптация	40.03%	69.57%
(d)	персонализация в шахматах Фишера	37.35%	65.34%
(e)	доменная адаптация + персонализация	41.08%	70.56%

Конфигурация (b), дообученная на 500 партиях целевого игрока в стандартные шахматы, не показала улучшения по сравнению с базовой моделью. Этот нулевой (или даже немного отрицательный) результат означает, что паттерны игрока, усвоенные на стандартных шахматах, не обобщаются на шахматы Фишера. Несмотря на идентичные правила движения фигур, распределения позиций различаются настолько сильно, что моделирование игрока не переносится между вариантами.

Это может противоречить интуиции. На наш взгляд, наиболее вероятным объяснением является доминирование дебютной теории. В стандартных шахматах дебюты часто представляют собой заученные варианты, из-за чего стиль игры сводится к выбору предпочтительных дебютов. Дальнейшее дообучение на стандартных шахматах приводит к переобучению на любимые дебюты конкретного игрока.

Конфигурация (c), дообученная на 800 тыс. партий в шахматы Фишера от разных игроков, существенно повысила точность прогноза. Записи матчей других игроков обеспечили наибольший прирост, подтвердив, что адаптация даже к слабо отличающемуся варианту необходима.

Конфигурация (d), дообученная всего на 150 партиях целевого игрока в шахматы Фишера, также дала значительный прирост точности. Персонализация достигла сопоставимых результатов, даже с учетом меньшего числа данных по сравнению с доменной адаптацией.

Комбинированный подход конфигурации (e) превзошел обе отдельные стратегии, что указывает на взаимодополняющий характер доменной адаптации и персонализации. Подобный подход, требующий дополнительного обучения после доменной адаптации, согласуется с результатами, полученными другими авторами в смежных областях машинного обучения [16].

Дополнительно мы оценили, как дообучение на данных шахмат Фишера влияет на качество предсказаний в стандартных шахматах. Результаты для тех же конфигураций (a)–(e) на выборке из 5000 дебютных ходов (500 партий) приведены в табл. 3. Из таблицы видно, что адаптация и персонализация к шахматам Фишера (c), (d) приводят к небольшому падению точности в стандартных шахматах относительно базовой модели, что указывает на частичную деградацию качества в исходном домене после дообучения.

Табл. 3. Результаты тестирования на стандартных шахматах после дообучения.

Конфигурация	Описание	Топ-1	Топ-3
(a)	базовая модель	48.08%	76.08%
(b)	персонализация под стандартную игру	53.50%	83.90%
(c)	доменная адаптация	45.62%	75.68%
(d)	персонализация в шахматах Фишера	47.82%	75.42%
(e)	доменная адаптация + персонализация	46.98%	75.90%

Интерес представляет факт, что персонализация адаптированной под шахматы Фишера модели (e) несколько компенсирует изначальную деградацию несмотря на то, что ее применение к базовой модели также ухудшает результат. При этом персонализация на стандартных шахматах (b) ожидаемо улучшает показатели, в соответствии с результатами авторов Maia.

ЗАКЛЮЧЕНИЕ

Исследован перенос модели для клонирования поведения от стандартных шахмат к шахматам Фишера, с помощью сравнения стратегий доменной адаптации и персонализации игрока. Ключевым выводом является необходимость двухэтапного подхода к адаптации модели, так как игровой стиль может не переноситься из-за особенностей того или иного варианта игры. С другой стороны, сочетания общих и персонализированных данных позволили добиться максимального результата даже при относительной ограниченности выборки конкретного игрока.

С практической точки зрения эти результаты означают, что при добавлении нового контента модель игрока требует балансировки двух показателей: качества в новом домене и совместимости с исходным доменом. В пайплайне тестирования контента это можно использовать так: сначала выполнить доменную адаптацию на данных множества игроков для новой версии контента, затем провести быструю персонализацию на небольшом числе партий конкретного иг-

рока. После каждого шага нужно измерить показатели в новом и старом доменах. Это позволит контролировать снижение точности на старом контенте и надежнее применять агентов для симуляции прохождения и проверки новых элементов.

Однако стоит отметить ограничения исследования. Результаты получены для одного игрока; необходима проверка на нескольких игроках различного уровня. Кроме того, протестирована только Maia, в основе которой лежит остаточная нейронная сеть. Другие архитектуры могут демонстрировать иную картину переноса.

В дальнейшем мы планируем провести подобный эксперимент на прототипе реальной видеоигры, где различие между вариантами может быть гораздо более существенным.

ЛУДОГРАФИЯ

Blizzard Entertainment. (2010). Starcraft 2 [Windows, MacOS]. Blizzard Entertainment.

Duplessis, T. (2010). Lichess [Web]. <https://lichess.org>

Valve, Hidden Path Entertainment. (2012). Counter-Strike: Global Offensive [Windows, Linux, MacOS, Xbox 360, Playstation 3]. Valve.

СПИСОК ЛИТЕРАТУРЫ

1. *Ingram B. et al.* Play-style Identification and Player Modelling for Generating Tailored Advice in Video Games // *AIIDE*. 2025. Vol. 21, No. 1. P. 258–268.
2. *McIlroy-Young R. et al.* Aligning Superhuman AI with Human Behavior: Chess as a Model System // *Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. Virtual Event CA USA: ACM. 2020. P. 1677–1687.
3. *McIlroy-Young R. et al.* Learning Models of Individual Behavior in Chess // *Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*. Washington DC USA: ACM. 2022. P. 1253–1263.
4. *Taylor M.E., Stone P.* Transfer Learning for Reinforcement Learning Domains: A Survey // *Journal of Machine Learning Research*. 2009. No. 10. P. 1633–1685.
5. *Арсланов Т.Р.* Генеративные методы для создания адаптивных игровых персонажей в играх-сервисах // *Электронные библиотеки*. 2025. Т. 28.

№ 3. С. 468–483.

6. Кузурасова В.В. Формальный подход к пространственно-временному моделированию игровых систем // Ученые записки Казанского университета. Серия Физико-математические науки. 2024. Т. 166, № 4. С. 532–554.

7. Tang Z. et al. Maia-2: A Unified Model for Human-AI Alignment in Chess // Advances in Neural Information Processing Systems. 2024. Vol. 37. P. 20919-20944.

8. Ho J., Ermon S. Generative Adversarial Imitation Learning // Advances in Neural Information Processing System. 2016. Vol. 29.

9. Yannakakis G.N., Togelius J. Player Modeling // Artificial Intelligence and Games. 2025. P. 315–335.

10. Yannakakis G.N., Togelius J. Experience-Driven Procedural Content Generation // IEEE Transactions on Affective Computing. 2011. Vol. 2, No. 3. P. 147–161.

11. Togelius J. et al. Search-Based Procedural Content Generation: A Taxonomy and Survey // IEEE Transactions on Computational Intelligence and AI in Games. 2011. Vol. 3, No. 3. P. 172–186.

12. Vinyals O. et al. Grandmaster level in StarCraft II using multi-agent reinforcement learning // Nature. 2019. Vol. 575, No. 7782. P. 350–354.

13. Pearce T., Zhu J. Counter-Strike Deathmatch with Large-Scale Behavioural Cloning // 2022 IEEE Conference on Games (CoG). 2022. P. 104–111.

14. Spick R. et al. Behavioural Cloning in VizDoom // arXiv. 2024. No. 2401.03993. P. 1–13.

15. Xia R. Y., Gow J., Lucas S. Play Style Identification Using Low-Level Representations of Play Traces in MicroRTS // 2025 IEEE Conference on Games (CoG). 2025. P. 1–4.

16. Gururangan S. et al. Proceedings of the 58th annual meeting of the association for computational linguistics. 2020. P. 8342–8360.

BEHAVIORAL CLONING ACROSS GAME VARIANTS: DOMAIN ADAPTATION AND PLAYER PERSONALIZATION IN CHESS960

T. R. Arslanov^[0009-0002-1110-8503]

Kazan (Volga region) Federal University, Kazan, Russia

timars-mail@yandex.ru

Abstract

Behavioral cloning allows creating models capable of making decisions in the same way humans do. Although various models successfully predict human actions in games, their ability to imitate individual players decreases when game variants change. In this work, we explore domain adaptation and personalization strategies using Fischer Random Chess with random piece placement. Using the Maia chess model presented by Tang et al., we tested several fine-tuning strategies. The results revealed three key patterns: old player records have no impact; each new record is highly effective; domain adaptation and personalization complement each other - their combination yields the best result.

Keywords: *games, artificial intelligence, player modeling, behavioral cloning, chess.*

REFERENCES

1. Ingram B. et al. Play-style Identification and Player Modelling for Generating Tailored Advice in Video Games // AIIDE. 2025. Vol. 21, No. 1. P. 258–268.
2. McIlroy-Young R. et al. Aligning Superhuman AI with Human Behavior: Chess as a Model System // Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. Virtual Event CA USA: ACM. 2020. P. 1677–1687.
3. McIlroy-Young R. et al. Learning Models of Individual Behavior in Chess // Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. Washington DC USA: ACM. 2022. P. 1253–1263.
4. Taylor M.E., Stone P. Transfer Learning for Reinforcement Learning Domains: A Survey // Journal of Machine Learning Research. 2009. No. 10. P. 1633–1685.
5. Arslanov T.R. Generative Methods for Creating Adaptive Playable Characters

in Service Games // Russian Digital Libraries Journal. 2025. Vol. 28, No. 3. P. 468–483.

6. Kugurakova V.V. A formal approach to spatio-temporal modeling of game systems // Uchenye Zapiski Kazanskogo Universiteta. Seriya Fiziko-Matematicheskie Nauki. 2024. Vol. 166, No. 4. P. 532–554.

7. Tang Z. et al. Maia-2: A Unified Model for Human-AI Alignment in Chess // Advances in Neural Information Processing Systems. 2024. Vol. 37. P. 20919-20944.

8. Ho J., Ermon S. Generative Adversarial Imitation Learning // Advances in Neural Information Processing System. 2016. Vol. 29.

9. Yannakakis G.N., Togelius J. Player Modeling // Artificial Intelligence and Games. 2025. P. 315–335.

10. Yannakakis G.N., Togelius J. Experience-Driven Procedural Content Generation // IEEE Transactions on Affective Computing. 2011. Vol. 2, No. 3. P. 147–161.

11. Togelius J. et al. Search-Based Procedural Content Generation: A Taxonomy and Survey // IEEE Transactions on Computational Intelligence and AI in Games. 2011. Vol. 3, No. 3. P. 172–186.

12. Vinyals O. et al. Grandmaster level in StarCraft II using multi-agent reinforcement learning // Nature. 2019. Vol. 575, No. 7782. P. 350–354.

13. Pearce T., Zhu J. Counter-Strike Deathmatch with Large-Scale Behavioural Cloning // 2022 IEEE Conference on Games (CoG). 2022. P. 104–111.

14. Spick R. et al. Behavioural Cloning in VizDoom // arXiv. 2024. No. 2401.03993. P. 1–13.

15. Xia R. Y., Gow J., Lucas S. Play Style Identification Using Low-Level Representations of Play Traces in MicroRTS // 2025 IEEE Conference on Games (CoG). 2025. P. 1–4.

16. Gururangan S. et al. Proceedings of the 58th annual meeting of the association for computational linguistics. 2020. P. 8342–8360.

СВЕДЕНИЯ ОБ АВТОРЕ



АРСЛАНОВ Тимур Рузелевич – аспирант Институт информационных технологий и интеллектуальных систем Казанского федерального университета. Направление исследований: фундаментальные аспекты создания видеоигр с высокой реиграбельностью.

Timur Ruzelevich ARSLANOV – postgraduate student at the Institute of Information Technologies and Intelligent Systems of Kazan Federal University. Research interests: fundamental aspects of creating video games with high replayability.

email: timars-mail@yandex.ru

ORCID: 0009-0002-1110-8503

Материал поступил в редакцию 23 апреля 2026 года