

Адаптивная гипероптимизация параметров в популяционных алгоритмах

А.В. Черников

Московский государственный технологический университет «Станкин»

Аннотация: В статье представлена новая архитектура адаптивной настройки параметров популяционных алгоритмов на основе комбинации обучения с подкреплением, механизмов эволюционного отбора и системы нечеткой логики. Разработанная модель позволяет динамически оптимизировать параметры, такие как скорость мутации, вероятность скрещивания и размер популяции, без необходимости переобучения алгоритма. Практическая апробация проведена на задаче прогнозирования временных рядов городского трафика Пекина. Результаты показали улучшение показателей точности по сравнению с современными аналогами, подтверждая высокую эффективность предложенного подхода в динамически изменяющихся средах.

Ключевые слова: адаптивная настройка параметров, обучение с подкреплением, популяционные алгоритмы, нечеткая логика, гипероптимизация, прогнозирование временных рядов.

Современные крупные производственные и информационные системы характеризуются высокой сложностью и многообразием взаимодействий между элементами [1]. Для таких систем необходимы эффективные методы оптимизации, которые позволяют увеличить производительность и снизить издержки. Традиционные детерминированные подходы, такие как методы условного и безусловного градиента, методы Ньютона и квазиньютоновские методы, часто недостаточно эффективны в связи с высокой нелинейностью задач и большим числом локальных экстремумов.

Предпочтение в таких случаях отдается стохастическим методам оптимизации, в частности популяционным алгоритмам [2, 3], таким, как генетические алгоритмы [4, 5], дифференциальная эволюция [6] и алгоритмы роя частиц [7]. Эти методы используют механизмы естественного отбора и мутации, что позволяет эффективно избегать локальных минимумов.

Практическая эффективность популяционных алгоритмов напрямую зависит от настройки их параметров: скорости мутации, вероятности скрещивания, размера популяции и селективного давления. Неверная

настройка этих параметров может снизить эффективность поиска оптимального решения.

Целью исследования стала разработка адаптивных методов настройки параметров, способных реагировать на изменяющиеся условия задачи.

Был проведен анализ существующих стратегий настройки параметров, выявлены их преимущества и недостатки.

Архитектура предлагаемой модели основана на комбинированном подходе. Каждый агент проводит индивидуальное обучение с подкреплением, формируя локальный опыт взаимодействия с окружающей средой. Это позволяет агенту принимать обоснованные решения на основе истории своих взаимодействий.

Параллельно система нечеткой логики используется для анализа социальных характеристик окружающей среды, таких как уровень доверия, репутация и влияние соседей. Нечеткая система позволяет агентам учитывать неопределенные и изменяющиеся условия окружающей среды.

Предлагаемая архитектура основана на классическом механизме Q-обучения, при котором агент обновляет свою Q-таблицу на основе опыта взаимодействия с окружающей средой. Стандартная формула Q-обучения:

$$\Delta Q = \alpha(r + \gamma \max_{a'} Q'(s', a') - Q(s, a)),$$

где $Q(s, a)$ – текущая оценка ожидаемой суммарной дисконтированной награды при выборе действия a в состоянии s .

После выполнения этого действия агент получает мгновенную награду r и переходит в новое состояние s' . Величина $\max_{a'} Q'(s', a')$ задаёт наилучшую (по текущим оценкам) прогнозируемую ценность следующего шага, то есть оценку «лучшего продолжения» из состояния s' по всем допустимым действиям a' . Коэффициент $\gamma \in [0,1]$ задаёт степень учёта будущих вознаграждений относительно текущего, а $\alpha \in (0,1]$ – скорость

обучения, определяющую, насколько сильно новое наблюдение влияет на прежнюю оценку.

Однако в реальных, динамически изменяющихся системах, стандартное Q-обновление недостаточно гибко отражает качество взаимодействия агента со средой. Поэтому в разработанной модели введён нечеткий модификатор, рассчитываемый на основе социально-средовых факторов: уровня доверия, репутации и влияния.

Этот модификатор влияет как на оценку полученного вознаграждения, так и на процесс выбора действия агентом. Если агент действует в среде с низким уровнем доверия или репутации, его награда масштабируется вниз, а вероятность выбора рискованных действий снижается. В средах с высокой социальной устойчивостью агент, напротив, усиливает обучение от положительного опыта.

Таким образом, модифицированная схема Q-обучения позволяет более адекватно адаптироваться к изменяющимся условиям среды и быстрее обучать агентов принимать стратегически выгодные решения.

На уровне популяции агентов реализуются механизмы эволюционного отбора, скрещивания и мутации стратегий, что обеспечивает глобальное улучшение качества решений на основе коллективного поиска. Таким образом, архитектура объединяет локальную адаптацию, социальное восприятие среды и эволюционное развитие.

Разработанная схема гипероптимизации параметров на основе генетического алгоритма позволяет автоматически и динамически выбирать оптимальные значения параметров во время работы алгоритма без дополнительного переобучения. Особое внимание было уделено разработке схемы гипероптимизации параметров на основе генетического алгоритма. Эта схема позволяет алгоритму динамически подбирать оптимальные настройки параметров, таких как скорость мутации, вероятность

скрещивания и размер популяции в процессе функционирования алгоритма, без необходимости его переобучения. Адаптивная схема настройки параметров описывается следующим образом:

$$P_{opt} = \arg \min E[P(t), f(t)]$$

где P_{opt} – оптимальный набор параметров, $f(t)$ – функция оценки текущего состояния алгоритма и его параметров.

Описание разработанного алгоритма

Разработанный алгоритм реализован в виде гибридной многоагентной архитектуры (Fuzzy-Evolutionary Learning for Adaptive Regulation, FELAR), в которой локальное обучение с подкреплением, социально-ориентированная нечёткая фильтрация и популяционный поиск параметров объединены в единый непрерывный цикл адаптации. На каждом шаге агенты получают сенсорные наблюдения, формируют дискретизированное состояние и выбирают действие. Далее выполняется локальное Q-обновление, но вместо «сырого» вознаграждения используется социально модифицированный сигнал, учитывающий доверие и влияние между агентами и тем самым сглаживающий шум и неоднородность данных. В теоретической части вводится формализм социального модификатора, где скрытые социальные переменные приводятся к нормированному виду, а итоговый сигнал награды сохраняет ограниченность и монотонность, что критично для устойчивого поведения Q-процесса в нестационарной среде. Благодаря этому локальная реакция системы остаётся рефлекторной, но при этом коллективная агрегация информации становится более робастной при частичной наблюдаемости и дрейфе распределений.

Ключевая особенность FELAR – вынесенный на стратегический уровень эволюционный контур (рис.1), который периодически пересматривает настройки локального обучения и параметры нечётких правил, выступая мета-регулятором долгосрочной адаптации. Коммуникация

поддерживает два канала: высокочастотный обмен компактными агрегатами ошибок и обновлениями доверия для «социализации» награды, и канал передачи сжатых векторов параметров и фрагментов Q-таблиц при кроссовере для эволюционного слоя. Такая организация позволяет распространять удачные элементы политики по популяции без глобальной остановки системы и без экспоненциального роста сетевого трафика.

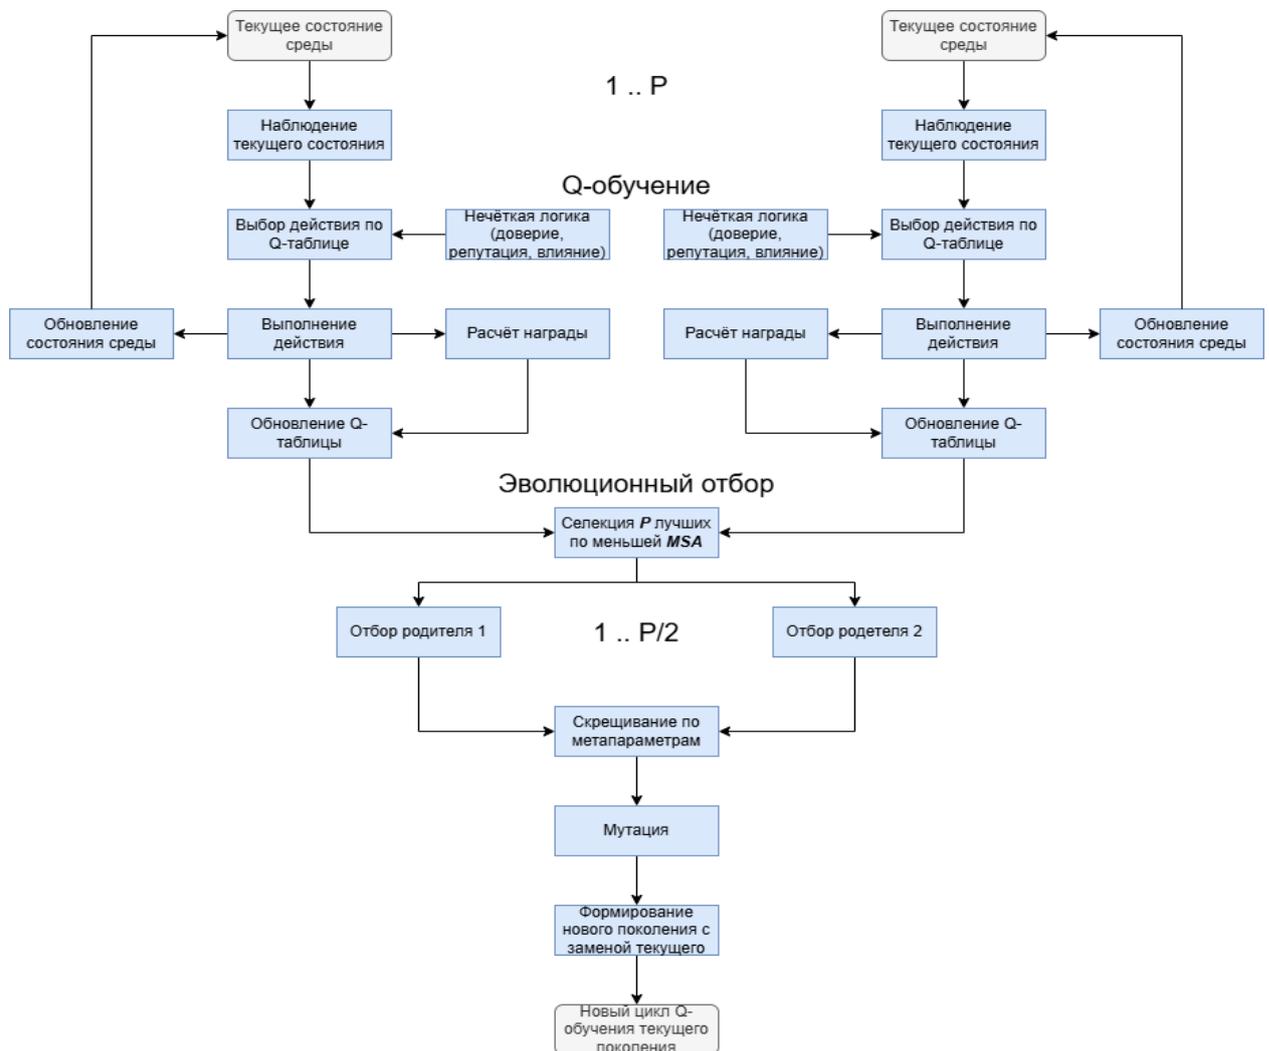


Рис.1. – Архитектура модели FELAR

Гипероптимизация реализуется генетическим алгоритмом, встроенным в FELAR потоковым образом – каждая «особь-конфигурация» представляет набор гиперпараметров локального Q-обучения, такие как темп обучения,

дисконтирование, параметр исследования в ε -жадной политике и длина окна состояния. Для оценки пригодности каждая конфигурация запускает полный цикл обучения локальной популяции агентов на обучающем интервале, затем лучший агент проверяется на валидации. В качестве критерия используется значение квадратичной ошибки, т.е. чем она меньше, тем выше пригодность, после чего выполняются отбор и формирование нового поколения с сохранением элиты. Кроссовер усредняет непрерывные координаты родителей, а дискретный параметр наследуется от одного из них. Мутация вносит гауссово смещение в непрерывные параметры и с малой вероятностью изменяет дискретную координату, при этом значения проецируются в допустимые диапазоны, сохраняя компактность области поиска. В вычислительном плане локальный шаг имеет линейную стоимость по мощности пространства действий, а расчёт нечёткого модификатора остаётся константным. Эволюционная процедура запускается асинхронно и редко, поэтому её амортизированная стоимость пренебрежимо мала и не попадает в критический путь принятия решения. В результате достигается квазилинейная масштабируемость по числу агентов и сенсоров при сохранении устойчивости к концептуальному дрейфу и быстрым возмущениям.

Эксперименты и результаты

Практическая апробация разработанной модели агентов была выполнена на реальной задаче прогнозирования временных рядов городского трафика на данных Пекина.

Исходный массив «Beijing Traffic» [8] представляет собой высокочастотный лонгитюдный срез городской дорожной сети в пределах 4-ой кольцевой автодороги Пекина (рис.2). Данные формировались бортовыми GPS-трекерами общественного и частного транспорта. Трекеры передавали координаты и мгновенную скорость на момент замера, а сервер

картографического провайдера агрегировал наблюдения в разрезе «дорожный сегмент × пятиминутный слот».

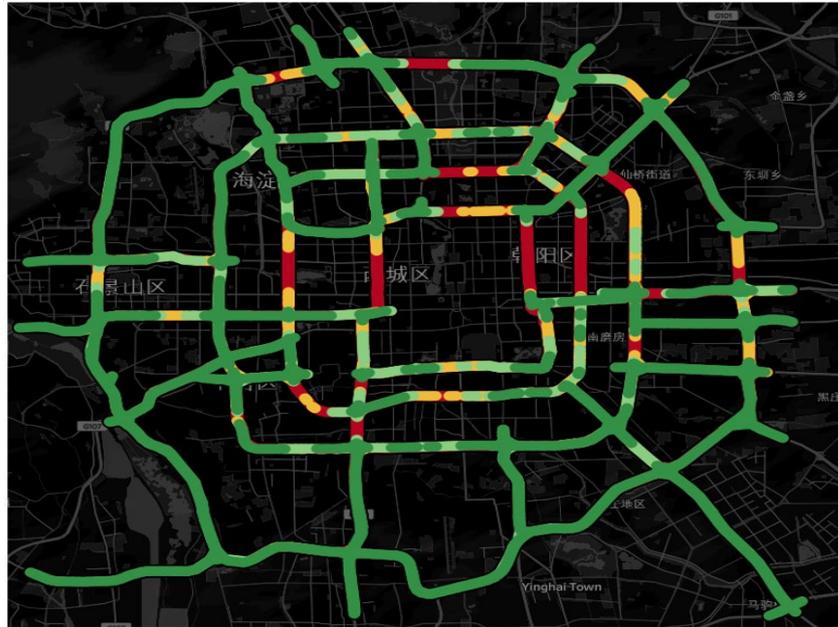


Рис. 2. – Смоделированная карта Пекина

В этом наборе данные представлены в форме матрицы $X \in RT \times N$, где T – количество временных отметок, N – число параллельных сенсоров. Трафик Пекина характеризуется большой N и коротким T .

Исследование включало оценку методов по метрикам среднеквадратичной ошибки (СКО):

$$\text{СКО} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

и средней абсолютной ошибки (САО):

$$\text{САО} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|,$$

где y_i – фактические значения временных рядов, \hat{y}_i – прогнозные значения, n – количество наблюдений.

Эксперименты (таблица 1) показали превосходство предложенных методов адаптивной настройки параметров по точности и устойчивости в сравнении с современными негибридными аналогами, такими как модель ARIMA – интегрированная модель авторегрессии – скользящего среднего [9], StemGNN – многомерная модель прогнозирования временных рядов на основе графов [10], доказав эффективность разработанного подхода. Результаты разработанной модели, а также моделей для сравнения [11] приведены в таблице 1.

Таблица №1.

Результаты экспериментов на задаче «Трафик Пекина»

Модель	СКО	САО
ARIMA [11]	9.184	4.640
StemGNN [11]	8.575	4.294
GW-Net [11]	7.754	3.564
FELAR	7.740	4.035

Разработанная модель FELAR показала схожие результаты с GW-Net – нейронная сеть для прогнозирования временных рядов на графах [11], превзойдя её по СКО, но уступив САО.

Нечёткая логика и социальная коррекция вознаграждения в FELAR могут приводить к более сглаженным прогнозам, уменьшая риск больших промахов СКО, но одновременно оставляя небольшой систематический сдвиг или «плато» ошибок на большинстве точек, что ухудшает САО.

Следует подчеркнуть, что полученные улучшения носили устойчивый характер и сохранялись не только на обучающей, но и на тестовой выборке, что указывает на хорошую обобщающую способность подхода и отсутствие эффекта «подгонки» под данные обучения. Применение адаптивной настройки параметров популяционных алгоритмов позволило не просто приблизить значения ошибок к целевым показателям, но и добиться точности прогнозирования, сопоставимой, а в ряде случаев и превосходящей уровень,

ожидаемый по фактическим значениям временных рядов (рис.3). Важно, что достигнутый эффект воспроизводился при различных настройках эксперимента и не зависел от единичных удачных запусков.

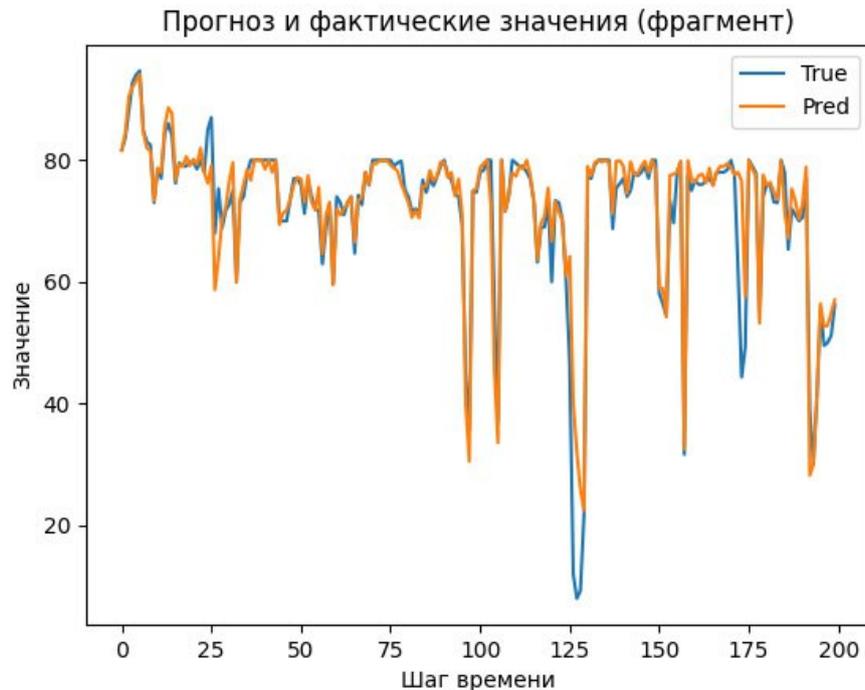


Рис.3. – 2D график прогноза и фактического значения

Заключение

В отличие от существующих решений, разработанный метод обеспечивает динамическую адаптацию модели в процессе функционирования без необходимости полного переобучения при изменении характеристик среды или входных данных. Это существенно снижает трудозатраты и вычислительные издержки на сопровождение систем, повышает их надёжность и обеспечивает более оперативный отклик на внешние возмущения и дрейф параметров.

Проведённые исследования подтвердили высокую эффективность и устойчивость предложенной гибридной модели, объединяющей обучение с подкреплением, эволюционные методы и нечёткую логику в едином контуре



адаптации. Существенное снижение ключевых метрик ошибок, включая СКО и САО, относительно базового уровня, свидетельствует о заметном повышении качества прогнозирования и практической применимости предложенного решения в задачах анализа и прогнозирования временных рядов.

Литература

1. Skiena S. S. The data science design manual. Springer, 2017. 456 p.
2. Knowles J. D., Corne D. W. Approximating the nondominated front using the Pareto archived evolution strategy // *Evolutionary computation*. 2000. V. 8. №2. pp. 149-172.
3. Wang L., Wang T., Luo Y. Improved non-dominated sorting genetic algorithm (NSGA)-II in multi-objective optimization studies of wind turbine blades // *Applied Mathematics and Mechanics*. 2011. V. 32. №6. pp. 739-748.
4. Emmerich M. T. M., Deutz A. H. A tutorial on multiobjective optimization: fundamentals and evolutionary methods // *Natural computing*. 2018. V. 17. pp. 585-609.
5. Анохин М.Н., Березняк С.А., Бланко Л.М.Л. Организация пространственной группировки сигналов в ассоциативных процессах искусственных нейронных сетей // *Инженерный вестник Дона*, 2014, №1. URL: ivdon.ru/ru/magazine/archive/n1y2014/2230.
6. Shi Y., Zhu W., Xiang Y., Feng Q. Condition-based maintenance optimization for multi-component systems subject to a system reliability requirement // *Reliability Engineering & System Safety*. 2020. V. 202. URL: [sciencedirect.com/science/article/pii/S0951832020305433](https://www.sciencedirect.com/science/article/pii/S0951832020305433).
7. Kochergin V., Plotnikov D., Ilinykh A., Glushkov S. Optimization of technical monitoring processes // *Transportation Research Procedia*. 2021. V. 54. pp. 166-172.

8. Zhang Ch., Zhang Y., Shao Q., Feng J., Li B., Lv Y., Piao X., Yin B. BJTТ: A Large-scale Multimodal Dataset for Traffic Prediction. 2024. URL: <https://chyazhang.github.io/BjTT/>.

9. Маловецкая Е. В., Мозалевская А. К. Возможности применения моделей АRIMA при построении прогнозных значений вагонопотоков // Т-Comm-Телекоммуникации и Транспорт. 2023. Т. 17. №1. С. 33-41.

10. Cao D., Wang Y., Duan J., Zhang C., Zhu X., Huang C., Tong Y., Xu B., Bai J., Tong J., Zhang Q. Spectral temporal graph neural network for multivariate time-series forecasting // Advances in neural information processing systems. 2020. V. 33. pp. 17766-17778.

11. Cai Z., Jiang R., Yang X., Wang Z., Guo D., Kobayashi H., Song X., Shibasaki R. Memda: forecasting urban time series with memory-based drift adaptation. 2023 URL: arxiv.org/pdf/2309.14216.

12. Wang Z., Jiang R., Xue H., Salim F.D., Song X., Shibasaki R., Hu W., Wang S. Learning spatio-temporal dynamics on mobility networks for adaptation to open-world events // Artificial Intelligence. 2024. V. 335. URL: doi.org/10.1016/j.artint.2024.104120.

References

1. Skiena S. S. The data science design manual. Springer, 2017. 456 p.
2. Knowles J. D., Corne D. W. Evolutionary computation. 2000. V. 8. №2. pp. 149-172.
3. Wang L., Wang T., Luo Y. Applied Mathematics and Mechanics. 2011. V. 32. №6. pp. 739-748.
4. Emmerich M. T. M., Deutz A. H. Natural computing. 2018. V. 17. pp. 585-609.
5. Anohin M.N., Bereznyak S.A., Blanko L.M.L. Inzhenernyj vestnik Dona, 2014, №1. URL: ivdon.ru/ru/magazine/archive/n1y2014/2230



6. Shi Y., Zhu W., Xiang Y., Feng Q. Reliability Engineering & System Safety. 2020. V. 202. URL: [sciencedirect.com/science/article/pii/S0951832020305433](https://www.sciencedirect.com/science/article/pii/S0951832020305433).

7. Kochergin V., Plotnikov D., Ilinykh A., Glushkov S. Transportation Research Procedia. 2021. V. 54. pp. 166-172.

8. Zhang Ch., Zhang Y., Shao Q., Feng J., Li B., Lv Y., Piao X., Yin B. BJT: A Large-scale Multimodal Dataset for Traffic Prediction. 2024. URL: <https://chyazhang.github.io/BjTT/>.

9. Maloveckaya E. V., Mozalevskaya A. K. T-Comm-Telekommunikacii i Transport. 2023. V. 17. №1. pp. 33-41.

10. Cao D., Wang Y., Duan J., Zhang C., Zhu X., Huang C., Tong Y., Xu B., Bai J., Tong J., Zhang Q. Advances in neural information processing systems. 2020. V. 33. pp. 17766-17778.

11. Cai Z., Jiang R., Yang X., Wang Z., Guo D., Kobayashi H., Song X., Shibasaki R. Memda: forecasting urban time series with memory-based drift adaptation. 2023 URL: arxiv.org/pdf/2309.14216.

12. Wang Z., Jiang R., Xue H., Salim F.D., Song X., Shibasaki R., Hu W., Wang S. Artificial Intelligence. 2024. V. 335. URL: doi.org/10.1016/j.artint.2024.104120.

Авторы согласны на обработку и хранение персональных данных.

Дата поступления: 21.01.2026

Дата публикации: 28.02.2026