

ГЕНДЕРНЫЙ ГЕНЕТИЧЕСКИЙ АЛГОРИТМ С ОБУЧЕНИЕМ В ЗАДАЧЕ ДИНАМИЧЕСКОЙ ОПТИМИЗАЦИИ

© 2020 П. А. Головинский✉

*Воронежский государственный технический университет
ул. 20-летия Октября, 84, 394006 Воронеж, Российская Федерация*

Аннотация. Анализируется подход к оптимизации быстро меняющихся процессов с использованием гендерного генетического алгоритма. Отличие от традиционного генетического алгоритма состоит в разделении искусственной популяции на два пола. Разделение по полу позволяет сочетать быструю приспособляемость к изменениям за счет вариации мужской субпопуляции с фиксацией приспособляемости в женской части популяции. Показано преимущество эффекта метаобучения параметров мутации и дополнительного обучения индивидуумов в форме Болдуина в сравнении с обычным гендерным генетическим алгоритмом и алгоритмом Ламарка при нахождении динамических оптимальных решений. В качестве перспективного применения гендерного генетического алгоритма с эффектом Болдуина отмечена динамика тушения природных пожаров.

Ключевые слова: гендерный генетический алгоритм, эффект Болдуина, динамическая оптимизация.

ВВЕДЕНИЕ

Задача оптимизации является стандартной при нахождении наилучшего решения. В математически ясной форме она выступает в виде поиска экстремума функции многих переменных. Даже при возможности точной постановки, задача не имеет алгоритма гарантированного нахождения абсолютного экстремума. Одним из наиболее успешных методов решения подобных задач является генетический алгоритм (ГА), предложенный Холландом [1], и его многочисленные модификации [2]. ГА построен по аналогии с теорией естественного отбора Дарвина [3] и включает механизмы изменчивости, наследственности и отбора.

Несмотря на многочисленные успехи практического применения ГА, он обладает рядом недостатков, основным из которых можно считать преждевременную сходимость процесса к локальному экстремуму. Это связано с быстрым сокращением генетического разнообразия в процессе отбора. Другой сопутствующей этому явлению проблемой является неспособность алгоритма к переключению механизма адаптации на новые важные цели, при их появлении. Такие динамические задачи характерны для управления различными видами транспорта и развитием чрезвычайных ситуаций и создают запрос на более эффективные модификации ГА, менее подверженные указанным ограничениям.

В популяционной генетике, изучающий природные организмы, в последние десятилетия достигнут существенный прогресс в

✉ Головинский Павел Абрамович
e-mail: golovinski@bk.ru



Контент доступен под лицензией Creative Commons Attribution 4.0 License.

The content is available under Creative Commons Attribution 4.0 License.

понимании механизмов пола и обучения при адаптации видов [4]. Перспективен перенос этих механизмов на искусственные ГА. В настоящей работе описывается гендерный генетический алгоритм (ГГА) с действительными параметрами и обучением особей [5] в приложении к задачам динамической оптимизации со встроенным механизмом метаобучения. Он представляет прикладной интерес, как инструмент для принятия оптимальных решений в условиях быстро меняющейся среды, в первую очередь, при определении расстановки сил и средств тушения лесных пожаров, где ресурсы для решения задачи всегда ограничены, а ситуация развивается быстро.

АНАЛИЗ РЕЗУЛЬТАТОВ ПРЕДШЕСТВУЮЩИХ РАБОТ

В ряде теоретических популяционных моделей предполагается, что половой отбор усиливает совокупный естественный отбор [6, 7]. Благоприятные мутации, возникающие у разных особей, объединяются путем рекомбинации. Бесполовая популяция может фиксировать благоприятные мутации только одну за другой, тогда как сексуальная популяция устанавливает их быстрее, объединяя, благодаря половой фиксации, множество новых полезных мутаций в соответствии с так называемым эффектом Фишера — Мюллера. Совместное давление полового отбора в сочетании с естественным отбором является мощной силой ускорения эволюции. Скорость адаптации увеличивается половыми механизмами, поскольку половой отбор обеспечивает более быстрый адаптивный ответ в изменяющихся условиях, фиксируя полезные мутации. На основе прогресса в понимании скорости адаптации было показано, что эта скорость у половых популяций в два раза выше, чем у бесполовых [8]. Таким образом, теоретические и экспериментальные результаты популяционной генетики указывают на преимущества полового размножения для выживания популяции в быстро меняющейся среде.

Половой отбор является одним из важных факторов популяционной генетики. Продик-

тованный им ГГА основан на понятиях мужской энергии и женского выбора из популяционной генетики и использует две разные схемы отбора одновременно в рамках одного алгоритма [9]. ГГА привносит гендерную концепцию в ГА из биологического прототипа и имеет видимые преимущества, по сравнению с классическими ГА, благодаря своей гибкости [10, 11]. Кроме того, хотя стандартные ГА имеют много достоинств, большинство из них использует механизм двоичного кодирования переменных [12], что приводит к значительной потере эффективности при поиске решений в многомерных непрерывных пространствах. Это ограничивает использование ГА при построении систем принятия решений, для управления сложными объектами. Очевидная проблема возникает, в частности, за счет того, что переменная может иметь только конечное число дискретных значений, при использовании двоичного представления. Чтобы избежать этих ограничений, были разработаны улучшенные генетические алгоритмы с действительным кодированием, направленные на разрешение проблемы преждевременной конвергенции, в форме дифференциальной эволюции [13, 14], впервые предложенной Сторном и Прайсом [15].

Был развит гендерный генетический алгоритм с адаптивной скоростью мутаций для каждого пола и дополнительным обучением особей с использованием эффекта Болдуина на основе разностной коррекции фитнес-функции с весовыми коэффициентами [16, 17]. При этом проблема сравнительной эффективности генетического алгоритма, гендерного генетического алгоритма, ламарковского гендерного генетического алгоритма и гендерного генетического алгоритма с эффектом Болдуина (БГГА) [18] остается актуальным предметом исследований. Наиболее совершенная версия такого алгоритма [19] использует адаптивную дифференциальную эволюцию. В качестве варианта рассматривался и генетический алгоритм без учета пола, но с эффектом Болдуина в форме градиентного обучения популяции [20], продемонстрировавший способность к решению динамических задач оптимизации на примере синусо-

идальной целевой функции, где наблюдалось превосходство ламарковского алгоритма.

ОПИСАНИЕ АЛГОРИТМА С ЭФФЕТОМ БОЛДУИНА

Как и в других эволюционных алгоритмах, первым шагом ГГА является фаза инициализации. Мы используем случайный алгоритм для разделения эволюционной популяции P на два половых подмножества M (мужское) и F (женское), задавая гендерный символ каждой особи \mathbf{x} в соответствии с величиной параметра p_g :

$$\mathbf{x} \in M, \text{ if } p < p_g, \quad (1)$$

где p — случайное действительное число в интервале $[0,1]$, обозначающее вероятность принадлежности отдельной особи подмножеству M . При практической реализации алгоритма мы полагаем далее $p_g = 0.5$.

Следующий оператор осуществляет кроссовер. Существует много типов кроссоверов с двумя родителями, но ГА с действительным кодированием работает непосредственно с действительными переменными [21]. Для нашего алгоритма мы взяли простой арифметический кроссовер, где новые значения переменных у потомков принимают среднее значение двух выбранных родителей. Берется взвешенная сумма векторных генов двух выбранных родителей с некоторым положительным случайным параметром $\alpha < 1$ для каждого гена. Пусть $\mathbf{x}_i(t)$ является i -й хромосомой поколения t :

$$\mathbf{x}_i = (x_{i1}(t), x_{i2}(t), \dots, x_{in}(t)), \quad (2)$$

где n — длина хромосомы, равная количеству переменных фитнес-функции при действительном кодировании. Далее, пусть M , F будут подмножествами мужских и женских родительских особей с численностью N_m , N_f . Тогда, для каждой пары $i \in M$, $j \in F$ потомство определяется следующим образом:

$$\mathbf{z}_i(t+1) = \mathbf{x}_i(t) + \alpha(\mathbf{x}_i(t) - \mathbf{y}_j(t)), \quad (3)$$

где $\mathbf{x}_i(t)$ и $\mathbf{y}_j(t)$ две случайно выбранные хромосомы, а α — случайный коэффициент, взятый из интервала $[0,1]$.

Локальная мутация означает выбор определенного хромосомного вектора для локальной мутации. В качестве оператора мутации мы примем операцию, когда все координаты хромосомы изменяются на случайные величины из заданного небольшого диапазона. Мутированный вектор $\mathbf{x}'_i(t)$ вычисляется с использованием соотношения

$$\mathbf{x}'_i(t) = \mathbf{x}_i(t) + \mathbf{r}, \quad (4)$$

где \mathbf{r} — случайный вектор, который называется мутацией, будет малым: $|\mathbf{x}_i(t)| \gg |\mathbf{r}|$. Мы используем мутацию, в которой случайный вектор подчиняется распределению вероятности Гаусса.

Мы применяем пропорциональный отбор по приспособленности для мужских особей, где уровень пригодности связан с вероятностью выбора каждой отдельной хромосомы:

$$p_i = \frac{f_i}{\sum_{j=1}^{N_m} f_j}. \quad (5)$$

Здесь f_i — приспособленность i -й особи, и N_m — число особей в мужской подгруппе. Целевая функция $f(\mathbf{x})$ задается параметрами \mathbf{x} , выбранными для оптимизации. В качестве альтернативы для женских особей мы используем простой случайный выбор.

Для направления адаптации за счет индивидуальной приобретенной приспособленности, мы вводим связанный с обучением эффект Болдуина [16, 17, 22]. Обучение достигается с помощью метода Ньютона — Рафсона на основании формулы

$$\tilde{\mathbf{x}} = \mathbf{x} - H^{-1} \nabla f(\mathbf{x}) \quad (6)$$

с матрицей Гессе H , который за один шаг находит точный максимум квадратичной функции.

Мы принимаем адаптивную генетическую стратегию, согласно которой частота мутаций у женщин p_f и у мужчин p_m снижается постепенно и монотонно во время генетического процесса. Индивидуальный уровень мутаций у женщин и мужчин адаптивно регулируется эволюционным поколением t в соответствии с формулой

$$p_{f,m} = p_{f,m0} \exp(-a_{f,m} t / t_{\max}), \quad (7)$$

```

Начальные параметры: размер популяции  $N$ , максимальное количество поколений  $t_{max}$ , параметры мутаций –  $pm_0$ ,  $pf_0$ ,  $am$ ,  $af$ 
1: Begin
2:  $t:=0$ ;
3: Initialize[ $P(0)$ ]; (Создание начальной популяции  $P(0)$  размером  $N$  при  $t=0$ )
4: while( $t < t_{max}$ ) do
5: [ $P(t)$ , Gender]:=GD[ $P(t)$ ]; (Определение пола индивидуумов в популяции  $P(t)$ )
6: ( $pf$ ,  $pm$ ):=Rate[ $pf_0$ ,  $pm_0$ ,  $am$ ,  $af$ ,  $t$ , Gender]; (Определение скорости мутаций на основе поколения и пола)
7:  $PM(t)$ :=Mutation[ $P(t)$ ,  $pf$ ,  $pm$ , Gender]; (Мутации в популяции  $P(t)$  с учетом пола для создания модифицированной популяции  $PM(t)$ )
8:  $PL(t)$ :=Learn[ $P(t)$ , Fit( $t$ )]; (Одношаговая поправка Ньютона – Рафсона для получения обученной популяции  $PL(t)$ )
9: Fit( $t$ ):= Fitness[ $PL(t)$ ]; (Вычисление приспособленности Fit( $t$ ) обученной популяции)
11:  $P(t+1)$ :=Selection/Mate[ $PM(t)$ , Fit( $t$ ), Gender]; (Сохранение элитных особей, половой отбор и скрещивание в популяции  $PM(t)$  для получения популяции  $P(t+1)$ )
12:  $t:=t+1$ ;
13: end while
14: End

```

где p_{f0} и p_{m0} — начальная частота мутаций в женской и мужской подгруппах, а a_f и a_m — положительные константы.

Генетический алгоритм на основе пола с эффектом Болдуина обобщен в псевдокоде, описанном в Листинге.

Эффект Болдуина является полностью дарвиновским по своему механизму, используя обученные особи для определения степени их приспособленности, но скрещивая хромосомы, имевшиеся до проведения обучения. В противоположность этому, еще до Дарвина Ламарк предположил, что организмы сами контролируют эволюцию, и полученные полезные физические характеристики фенотипа могут быть переданы обратно в генотип организма. Нереалистичная в биологии эволюция Ламарка становится работоспособным понятием в ГА, т. к. обратное сообщение от фенотипа к генотипу является достаточно простой компьютерной процедурой. Влияние ламаркизма, так же как и эффекта Болдуина, состоит в заметном увеличении общей эффективности генетического алгоритма. В ламарковской версии алгоритма, и отбор и спаривание осуществляются с участием обученной популяции.

РЕЗУЛЬТАТЫ ЧИСЛЕННЫХ РАСЧЕТОВ И ИХ ОБСУЖДЕНИЕ

Мы рассмотрим пример, демонстрирующий преимущество БГА по сравнению с другими версиями генетического алгоритма. Нашей задачей является сравнение четырех различных зависящих от времени моделей ГА с использованием возмущенной целевой функции Растригина [23]:

$$f_R(x, y) = -[20 + x^2 + y^2 - 10(\cos 2\pi x + \cos 2\pi y)] \quad (8)$$

для которой координаты $(x_{max}, y_{max}) = (0, 0)$ и значение

$$f_R(x_{max}, y_{max}) = 0. \quad (9)$$

Зависящая от времени радиальная функция возмущения принимается в виде

$$g(x, y, t) = A_0(-\lambda t / t_{max}) \exp\left(-\frac{(x - a_x)^2 + (y - a_y)^2}{2\sigma^2}\right), \quad (10)$$

где λ — масштабный коэффициент скорости изменения амплитуды возмущения во времени, σ — параметр ширины функции, a_x и a_y — координаты положения максимума.

Чтобы выявить более высокую гибкость БГА в отношении селективного давления, были выполнены тестовые расчеты с использованием следующего набора параметров:

размер популяции генетического алгоритма $N=100$, параметры адаптации: $p_{f_0}=0.2$, $p_{m_0}=0.3$, $a_f=4$, $a_m=3$ и максимальное эволюционное поколение $t_{\max}=15$. Количество экспериментов для усреднения по ансамблю реализаций взято равным 500.

Сравнение результатов численных экспериментов с разными алгоритмами для статической целевой функции, представленных на рис. 1, показывает, что наиболее эффективным способом адаптации является гендерно-генетический алгоритм с обучением индивидуумов в популяции. Сопоставление работы компьютерного алгоритма Ламарка и алгоритма Болдуина демонстрирует некоторое превосходство алгоритма Ламарка.

Оценим способность БГА продолжать функционировать при локальном возмущении среды [23], т. е. эффективность алгоритма в решении проблемы «погони за двумя зайцами». На рис. 2 показана динамика адаптации для БГА применительно к функции Растри-

гина и возмущающей функции $g(x, y, t)$ из уравнения (10) при $\sigma^2=1/40$. Скорость изменения среды регулируется параметром λ . Значения параметра $\lambda=0.1, 0.5, 1$ соответствуют кривым в последовательности сверху вниз. Сплошная и пунктирная линии отслеживают убывающий максимум функции возмущения в окрестности точки $(1, 0)$. Линия из точек указывает на смещение погони от максимума функции возмущения в точке $(1, 0)$ к максимуму функции Растригина в точке с координатами $(0, 0)$. Бифуркация погони с переключением преследования цели возникает при параметре $\lambda=0.8$. В ламарковском ГА бифуркация наблюдается при $\lambda=0.9$, т. е. при более заметных изменениях целевой функции по сравнению с БГА. Это объясняется сравнительно более быстрым истощением генетического разнообразия в ламарковском ГА, и, как следствие, замедлением реакции алгоритма на изменения в фитнес-функции. Тот же эффект бифуркации наблюдается при $\lambda=0.9$




Рис. 1. Значения статической целевой функции в зависимости от номера поколения: сплошная линия — результаты работы ГА, точками отмечен результат для ГГА, пунктирная линия — ГГА с эффектом Болдуина, штрих-пунктирная линия — ламарковский ГГА [Fig. 1. The static objective function depending on the generation number: the solid line is the GA results, the dots indicate the results for the GGA, the dash-dotted line indicates the GGA with the Baldwin effect, and the dashed line represents the Lamarckian GGA]




Рис. 2. Значение динамической целевой функции в процессе оптимизации в зависимости от номера поколения

[Fig. 2. The dynamic objective function in the optimization process depending on the generation number]

в простом ГА. Для ГГА точка бифуркации равна 0.8, как и для БГГА, но с гораздо более низкой скоростью адаптации.

Сравнение результатов ГА и ГГА с алгоритмами Болдуина и Ламарка показывает, что алгоритм Болдуина является наиболее эффективным в этом наборе. Он не только отслеживает динамическую целевую функцию, но и обеспечивает своевременное переключение и оптимизацию при появлении нового максимума целевой функции. Алгоритм Ламарка [20] имеет преимущество только при плавном изменении целевой функции, не требующем быстрого переключения на новую цель. Таким образом, БГГА является одним из наиболее перспективных подходов к поиску оптимальных решений в сложных задачах реального времени.

ЗАКЛЮЧЕНИЕ

В комплексном наборе тестов было показано, что БГГА имеет серьезные преимущества в отношении адаптивности селекцион-

ного давления. В классической концепции ГА на селекционное давление может влиять только размер турнирной группы. Напротив, при использовании БГГА селекционное давление можно регулировать более точно благодаря возможностям комбинирования различных концепций отбора. Таким образом, пользователь БГГА может лучше настроить алгоритм в соответствии с потребностями решаемой задачи оптимизации. Кроме того, потенциал оптимизации, содержащийся в популяции БГГА, может использоваться в большей степени, поскольку взаимодействие между тенденциями уменьшения разнообразия и факторами его поддержки может быть отрегулировано более точно.

Основные компоненты, которые мы использовали при построении БГГА, уже были известны ранее, однако высокая эффективность и надежность всего алгоритма достигается только при совместном использовании действительного кодирования, гендерной селекции, равномерного дифференциального кроссовера, адаптивной частоты мутаций,

эффекта Болдуина и элитного резервирования. Отличие предложенной нами модификации БГА от предшествующих работ состоит в использовании метаобучения на статической целевой функции для получения оптимальных параметров адаптации скорости мутаций с учетом пола и использовании одношагового метода Ньютона — Рафсона при обучении индивидуумов в популяции. Полученные результаты, подтверждающие эффективность БГА в задачах динамической оптимизации, позволяют рассматривать его в качестве эффективного инструмента оптимизации для решения проблемы распределения ресурсов при тушении лесных пожаров. Для этого необходимо совместить его с разрабатываемой нами моделью лесных пожаров, основанной на технологиях искусственного интеллекта.

КОНФЛИКТ ИНТЕРЕСОВ

Авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

СПИСОК ЛИТЕРАТУРЫ

1. *Holland, J. H.* Adaptation in Natural and Artificial Systems : book / J. H. Holland. – University of Michigan Press, 1975. – 232 p.
2. *Lance, C.* The Practical Handbook of Genetic Algorithms Applications : book / C. Lance. – Second edition. – Boca Raton: Chapman and Hall, 2001. – 535 p.
3. *Darwin, C.* On the Origin of Species by Means of Natural Selection : book / C. Darwin. – London: John Murray, 1859. – 486 p.
4. *Kim, Y.* Rate of adaptive peak shifts with partial genetic robustness / Y. Kim // Evolution. – 2007. – V. 61. – P. 847–856. <https://doi.org/10.1111/j.1558-5646.2007.00166.x>
5. *Hinton, G.* How learning can guide evolution / G. Hinton, S. Nowlan // Computers Systems. – 1987. – V. 1. – P. 495–502.
6. *Long, T. A. F.* The effect of sexual selection on offspring fitness depends on the nature of genetic variation / T. A. F. Long, A. F. Agrawal, L. Rowe // Current Biology. – 2012. – V. 22. – P. 204–208. [doi: 10.1016/j.cub.2011.12.020](https://doi.org/10.1016/j.cub.2011.12.020)
7. *Hartfield, M.* Current hypotheses for the evolution of sex and recombination / M. Hartfield, P. D. Keightley // Integrative Zoology. – 2012. – V. 7. – P. 192–209. [doi: 10.1111/j.1749-4877.2012.00284.x](https://doi.org/10.1111/j.1749-4877.2012.00284.x)
8. *Park, S.-C.* Rate of adaptation in sexuals and asexuals: A solvable model of the Fisher-Muller effect / S.-C. Park, J. Krug // Genetics. – 2013. – V. 195. – P. 941–955. <https://doi.org/10.1534/genetics.113.155135>
9. *Miller, G. F.* Exploiting mate choice in evolutionary computation: sexual selection as a process of search, optimization, and diversification / G. F. Miller // Lecture Notes in Computer Science, Fogarty T.C. (eds) Evolutionary Computing. AISB EC. – Berlin: Springer. – 1994. – V. 885. – P. 65–79. https://doi.org/10.1007/3-540-58483-8_6
10. *Goh, K. S.* Sexual selection for genetic algorithms / K. S. Goh, A. Lim, B. Rodrigues // Artificial Intelligence. – 2003. – V. 19. – P. 123–152. <https://doi.org/10.1023/A:1022692631328>
11. *Wagner, S.* SexualGA: Gender-specific selection for genetic algorithms / S. Wagner, M. Affenzeller // Proceedings of the 9th World Multi-Conference on Systemics, Cybernetics and Informatics (WMSCI). – 2005. – V. 4. – P. 76–81.
12. *Goldberg, D. E.* Genetic Algorithms in Search, Optimization, and Machine Learning : book / D. E. Goldberg. – Boston: Addison-Wesley Longman Publishing Co, 1989. – 432 p.
13. *Chen, Li.* Real coded genetic algorithm optimization of long term reservoir operation / Li Chen // JAWRA. – 2003. – V. 39. – P. 1157–1165. <https://doi.org/10.1111/j.1752-1688.2003.tb03699.x>
14. *Ali, M. Z.* An improved class of real-coded genetic algorithms for numerical optimization / M. Z. Ali [et al] // Neurocomputing. – 2018. – V. 275. – P. 155–166. <https://doi.org/10.1016/j.neucom.2017.05.054>
15. *Storn, R.* Differential evolution – a simple and efficient heuristic for global optimization over continuous spaces / R. Storn, K. Price // Journal of Global Optimization. – 1997. – V. 11. – P. 341–359. <https://doi.org/10.1023/A:1008202821328>

16. Zhang, M. A novel sexual adaptive genetic algorithm based on two-step evolutionary scenario of Baldwin effect and analysis of global convergence / M. Zhang, S. Zhao, X. Wang // GEC '09: Proceedings of the first ACM/SI-GEVO Summit on Genetic and Evolutionary Computation. – 2009. – P. 737–744. <https://doi.org/10.1145/1543834.1543935>
17. Zhang, M. A novel sexual adaptive genetic algorithm based on Baldwin effect for global optimization / M. Zhang // International Journal of Intelligent Computing and Cybernetics. – 2011. – V. 4. – P. 207–227. <https://doi.org/10.1145/1543834.1543935>
18. Holzinger, A. Darwin, Lamarck, or Baldwin: applying evolutionary algorithms to machine learning techniques / A. Holzinger, [et al.] // IEEE/WIC/ACM International Joint Conferences on Web Intelligence (WI) and Intelligent Agent Technologies (IAT), Warsaw. – 2014. – P. 449–453. <https://doi.org/10.1109/WI-IAT.2014.132>
19. Zhao, F. A hybrid algorithm based on self-adaptive gravitational search algorithm and differential evolution / F. Zhao [et al.] // Expert Systems with Applications. – 2018. V. 113. – P. 515–530. <https://doi.org/10.1016/j.eswa.2018.07.008>
20. Fernando, C. Meta-learning by the Baldwin effect / C. Fernando [et al.] // GECCO '18 Proceedings of the Genetic and Evolutionary Computation Conference Companion. – 2018. – P. 1313–1320. <https://doi.org/10.1145/3205651.3208249>
21. Ali, M. Z. An improved class of real-coded genetic algorithms for numerical optimization / M. Z. Ali [et al.] // Neurocomputing. – 2018. – V. 275. – P. 155–166. <https://doi.org/10.1016/j.neucom.2017.05.054>
22. Baldwin, J. M. A new factor in evolution / J. M. Baldwin // American Naturalist. – 1896. – V. 30. – P. 441–451. <https://www.jstor.org/stable/2453130>
23. Растрингин, Л. А. Системы экстремального управления : книга / Л. А. Растрингин. – М. : Наука, 1974. – 630 с.
24. Stieglitz, N. Adaptation and inertia in dynamic environments / N. Stieglitz, T. Knudsen, M. C. Becker // Strategic Management Journal. – 2015. – V. 37. – P. 1854–1864. <https://doi.org/10.1002/smj.2433>

Головинский Павел Абрамович — д.ф.-м.н., профессор кафедры инноватики и строительной физики Воронежского государственного технического университета
E-mail: golovinski@bk.ru
ORCID iD: <https://orcid.org/0000-00027527-0297>

GENDER GENETIC ALGORITHM WITH LEARNING IN THE DYNAMIC OPTIMIZATION PROBLEM

© 2020 P. A. Golovinski 

Voronezh State Technical University
 84, 20-letiya Oktyabrya Str, 394006 Voronezh, Russian Federation

Abstract. The article analyses an approach to the optimization of fast-changing processes using a gender-based genetic algorithm. The suggested algorithm differs from the traditional genetic algorithm in that it divides an artificial population into two groups according to their gender. This separation allows combining the rapid adaptability of the population resulting from variations in the male subpopulation with the fixed adaptability of the female population. The article demonstrates that the meta-learning effect based on the mutation parameters in combination with individual learning, i.e. the Baldwin effect, is more effective for finding dynamic optimal solutions than the classic gender-based genetic algorithm and the Lamarckian genetic algorithm. The dynamics of extinguishing natural fires is considered as a promising application of the developed gender-based genetic algorithm with the Baldwin effect.

Keywords: gender-based genetic algorithm, Baldwin effect, dynamic optimization.

CONFLICT OF INTEREST

The authors declare the absence of obvious and potential conflicts of interest related to the publication of this article.

REFERENCES

1. *Holland J. H.* Adaptation in Natural and Artificial Systems : book. University of Michigan Press. 1975. 232 p.

2. *Lance C.* The Practical Handbook of Genetic Algorithms Applications : book. – Second edition. Boca Raton, Chapman and Hall. 2001. 535 p.

3. *Darwin C.* On the Origin of Species by Means of Natural Selection : book. London, John Murray. 1859. 486 p.

4. *Kim Y.* Rate of adaptive peak shifts with partial genetic robustness. *Evolution*. 2007. V. 61. P. 847–856. <https://doi.org/10.1111/j.1558-5646.2007.00166.x>

5. *Hinton G., Nowlan S.* How learning can guide evolution. *Computers Systems*. 1987. V. 1. P. 495–502.

6. *Long T. A. F., Agrawal A. F., Rowe L.* The effect of sexual selection on offspring fitness depends on the nature of genetic variation. *Current Biology*. 2012. V. 22. P. 204–208. doi: 10.1016/j.cub.2011.12.020

7. *Hartfield M., Keightley P. D.* Current hypotheses for the evolution of sex and recombination. *Integrative Zoology*. 2012. V. 7. P. 192–209. doi: 10.1111/j.1749-4877.2012.00284.x

8. *Park S.-C., Krug J.* Rate of adaptation in sexuals and asexuals: A solvable model of the Fisher-Muller effect. *Genetics*. 2013. V. 195. P. 941–955. <https://doi.org/10.1534/genetics.113.155135>

9. *Miller G. F.* Exploiting mate choice in evolutionary computation: sexual selection as a process of search, optimization, and diversification. *Lecture Notes in Computer Science*, Fogarty T. C. (eds) *Evolutionary Computing*. AISB EC. Berlin, Springer. 1994. V. 885. P. 65–79. https://doi.org/10.1007/3-540-58483-8_6

10. *Goh K. S., Lim A., Rodrigues B.* Sexual selection for genetic algorithms. *Artificial Intelligence*. 2003. V. 19. P. 123–152. <https://doi.org/10.1023/A:1022692631328>

11. *Wagner S., Affenzeller M.* SexualGA: Gender-specific selection for genetic algorithms. *Proceedings of the 9th World Multi-Conference on*

 Golovinski Pavel A.
 e-mail: golovinski@bk.ru

Systemics, Cybernetics and Informatics (WMS-CI). 2005. V. 4. P. 76–81.

12. *Goldberg D. E.* Genetic Algorithms in Search, Optimization, and Machine Learning : book. Boston, Addison-Wesley Longman Publishing Co. 1989. 432 p.

13. *Chen Li.* Real coded genetic algorithm optimization of long term reservoir operation. JAWRA. 2003. V. 39. P. 1157–1165. <https://doi.org/10.1111/j.1752-1688.2003.tb03699.x>

14. *Ali M. Z. [et al]* An improved class of real-coded genetic algorithms for numerical optimization. Neurocomputing. 2018. V. 275. P. 155–166. <https://doi.org/10.1016/j.neucom.2017.05.054>

15. *Storn R., Price K.* Differential evolution – a simple and efficient heuristic for global optimization over continuous spaces. Journal of Global Optimization. 1997. V. 11. P. 341–359. <https://doi.org/10.1023/A:1008202821328>

16. *Zhang M., Zhao S., Wang X.* A novel sexual adaptive genetic algorithm based on two-step evolutionary scenario of Baldwin effect and analysis of global convergence. GEC '09: Proceedings of the first ACM/SIGEVO Summit on Genetic and Evolutionary Computation. 2009. P. 737–744. <https://doi.org/10.1145/1543834.1543935>

17. *Zhang M.* A novel sexual adaptive genetic algorithm based on Baldwin effect for global optimization. International Journal of Intelligent Computing and Cybernetics. 2011. V. 4. P. 207–227. <https://doi.org/10.1145/1543834.1543935>

18. *Holzinger A. [et al.]* Darwin, Lamarck, or Baldwin: applying evolutionary algorithms to machine learning techniques. IEEE/WIC/ACM

International Joint Conferences on Web Intelligence (WI) and Intelligent Agent Technologies (IAT), Warsaw. 2014. P. 449–453. <https://doi.org/10.1109/WI-IAT.2014.132>

19. *Zhao F. [et al.]* A hybrid algorithm based on self-adaptive gravitational search algorithm and differential evolution. Expert Systems with Applications. 2018. V. 113. P. 515–530. <https://doi.org/10.1016/j.eswa.2018.07.008>

20. *Fernando C. [et al.]* Meta-learning by the Baldwin effect. GECCO '18 Proceedings of the Genetic and Evolutionary Computation Conference Companion. 2018. P. 1313–1320. <https://doi.org/10.1145/3205651.3208249>

21. *Ali M. Z. [et al.]* An improved class of real-coded genetic algorithms for numerical optimization. Neurocomputing. 2018. V. 275. P. 155–166. <https://doi.org/10.1016/j.neucom.2017.05.054>

22. *Baldwin J. M.* A new factor in evolution. American Naturalist. 1896. V. 30. P. 441–451. <https://www.jstor.org/stable/2453130>

23. *Rastrigin L. A.* Systems of Extreme Control : book. Moscow, Nauka. 1974. 630 p. (in Russian)

24. *Stieglitz N., Knudsen T., Becker M. C.* Adaptation and inertia in dynamic environments. Strategic Management Journal. 2015. V. 37. P. 1854–1864. <https://doi.org/10.1002/smj.2433>

Golovinski Pavel A. — DSc in Physics and Mathematics, Professor, Department of Innovation Studies and Structural Physics, Voronezh State Technical University.

E-mail: golovinski@bk.ru

ORCID iD: <https://orcid.org/0000-00027527-0297>