

УДК 681.3

DOI: [10.26102/2310-6018/2020.29.2.009](https://doi.org/10.26102/2310-6018/2020.29.2.009)

МОДИФИКАЦИЯ ГЕНЕТИЧЕСКОГО АЛГОРИТМА С АДАПТИВНЫМ ПЕРЕКЛЮЧЕНИЕМ КРОССОВЕРА

Ю.А. Асанов, С.Ю. Белецкая, Аль-Саеди Моханад Ридха Ганим
ФГБОУ ВО «Воронежский государственный технический университет»,
Воронеж, Российская Федерация

Резюме: Целью данной работы является разработка модификации адаптивного генетического алгоритма, основанной на переключении кроссовера в соответствии со степенью элитарности индивидуумов популяции. Несмотря на большое число исследований, произведенных в области эволюционных исчислений за последнее время, алгоритмы данного класса и сегодня имеют высокую перспективу модификации. Основной целью исследований является улучшение скорости сходимости алгоритмов (для получения высокопроизводительных методов оптимизации) и увеличение точности полученных решений. В статье для адаптивной настройки оператора кроссовера используются понятия дискретной и непрерывной степени элитарности индивидуумов. Кроме того, оценка элитарности применяется для настройки вероятности мутации. Рассмотренная модификация имеет превосходство на тестовых задачах, которые традиционно используются для анализа эффективности генетических алгоритмов. В качестве тестового набора были использованы квадратичная функция с тремя переменными, функция Розенброка, ступенчатая функция, сложная функция четвертого порядка с шумом и функция Шекеля. Представлены результаты сравнения классических генетических алгоритмов с алгоритмами, использующими рассмотренные стратегии настройки кроссовера и мутации. Проведён анализ результатов вычислительного эксперимента.

Ключевые слова: генетический алгоритм, переключение кроссовера, адаптивная настройка мутации, элитарность, эволюционные исчисления.

Для цитирования: Асанов Ю.А., Белецкая С.Ю., Аль-Саеди Моханад Ридха Ганим. Модификация генетического алгоритма с адаптивным переключением кроссовера. *Моделирование, оптимизация и информационные технологии*. 2020;8(2). https://moit.vivt.ru/wp-content/uploads/2020/05/AsanovSoavtors_2_20_1.pdf DOI: 10.26102/2310-6018/2020.29.2.009

MODIFICATION OF GENETIC ALGORITHM WITH ADAPTIVE CROSSOVER SWITCHING

Y.A. Asanov, S.Y. Beletskaya, Al-Saedi Mohanad Ridha Ganim
Voronezh State Technical University, Voronezh, Russian Federation

Abstract: The aim of this work is to develop a modification of the adaptive genetic algorithm based on switching crossover in accordance with the degree of elitism of individuals in the population. Despite the enormous amount of research done in the field of evolutionary calculus in recent years, algorithms of this class today have a high prospect of modification. The main aim of research is carried out in order to improve the convergence rate of algorithms (to obtain high-performance optimization methods) and increase the accuracy of the solutions obtained. In the article, for the adaptive tuning of the crossover operator, the concepts of discrete and continuous degree of elitism of individuals are used. In addition, an elitism score is used to adjust the probability of a mutation. This modification has a serious advantage superiority in test problems which are traditionally used to analyze the efficiency of genetic algorithms. The test set used was a quadratic function with three variables, a Rosenbrock function, a step function, a complex fourth-order function with noise, and the Shekel function. The results of comparing classical genetic algorithms with algorithms using the considered crossover and mutation tuning strategies are presented. An analysis of the results of a computational experiment is presented.

Keywords: genetic algorithm, switching crossover, adaptive mutation tuning, elitism, evolutionary calculus.

For citation: Asanov Y.A., Beletskaya S.Y., Al-Saedi Mohanad Ridha Ghanim. Modification of the genetic algorithm with adaptive crossover switching. *Modeling, optimization and information technology*. 2020;8(2). Available by: https://moit.vivt.ru/wp-content/uploads/2020/05/AsanovSoavtors_2_20_1.pdf DOI: 10.26102/2310-6018/2020.29.2.009 (In Russ.)

Введение

Генетические алгоритмы (ГА) находят широкое распространение при решении задач оптимального проектирования и управления в различных предметных областях. Их применение особенно эффективно при оптимизации сложных систем с алгоритмическими моделями, в которых отсутствуют явные аналитические формулировки критериев оптимальности и ограничений [1, 2, 3].

К настоящему времени было проведено огромное число исследований ГА с целью нахождения оптимального набора операторов и параметров ГА [1]. Выбор настроек операторов оказывает значительное влияние на эффективность ГА. Соответствующие настройки зависят от различных факторов, таких, как модель популяции, решаемая задача и ее представление, используемые стратегии реализации операторов. Огромное число возможных вариантов исключает полный перебор [2].

Существует множество различных модификаций операторов генетического алгоритма (ГА). Каждый оператор должен быть выбран с учетом конкретной задачи для достижения максимальной производительности генетического алгоритма. Также структура ГА предусматривает наличие множества параметров, настройка которых должна производиться с учётом особенностей поставленной задачи, т. к. они могут существенно повлиять на работоспособность алгоритма [1, 2]. Типичный набор параметров алгоритма – размер популяции, вероятность проведения кроссовера, мутации, разрыв поколений (отношение числа потомков к мощности популяции), число поколений. Наибольшее внимание и, следовательно, наибольшее число вариаций получил оператор кроссовера. Его самые популярные модификации – одноточечный, многоточечный, равномерный кроссовер, обмен по частичному совпадению, упорядоченный обмен и др. [5].

Можно выделить два основных подхода к решению задач оптимизации на основе генетических алгоритмов [2]:

1. Операторы и параметры генетического алгоритма устанавливаются изначально на основе априорной информации о задаче и не подвергаются изменению на протяжении всей работы алгоритма.

2. Операторы и параметры адаптивно настраиваются в процессе работы алгоритма на основе текущей информации о ходе оптимизационного процесса.

Наибольшее внимание в современных исследованиях уделяется развитию и практическому использованию второго подхода [6, 7]. Генетические алгоритмы с самоадаптацией, которые настраивают свои параметры и операторы во время выполнения поиска, показывают высокую эффективность и потенциал [8, 9]. В данной статье предлагается стратегия адаптивного переключения оператора кроссовера в генетическом алгоритме в процессе поиска оптимальных вариантов.

Модификация генетического алгоритма на основе стратегии элитарности

Как известно, фундаментальной теоремой теории генетических алгоритмов является теорема схем. Каждой схеме соответствует некоторое подмножество особей в популяции. Теорема схем – это попытка объяснить механизм нахождения оптимальных решений генетическим алгоритмом. Она утверждает, что хорошие (почти оптимальные)

решения могут быть получены с помощью комбинирования схем с короткой определяющей длиной и высокой оценкой [7]. На основе теоремы схем была сформулирована гипотеза о том, что индивидуумы, имеющие множество высоко приспособленных предков в предыдущих поколениях, содержат множество схем с высокой оценкой [2, 5, 7].

Использование данной гипотезы позволяет точнее оценивать индивидуумов по сравнению с подходами, при которых принимается во внимание только приспособленность. В качестве примера предположим, что существует два решения x_1 и x_2 , приспособленность которых равна. В этом случае нет возможности понять, какое решение должно быть выбрано. С другой стороны, если мы применяем гипотезу элит, то решение может быть принято благодаря проверке предков индивидуума.

Применяя данный подход, авторы работ [1, 5, 10] предложили элитарную степень в качестве индивидуальной оценки, а также провели вычислительные эксперименты, в ходе которых показали эффективность данного подхода. Рассмотрим определение степени элитарности и использование данного понятия в генетических алгоритмах.

Дискретная степень элитарности определяется следующим образом. Обозначим начальную и текущую популяции как 0 и T , соответственно. Пусть x_i^T ($0 \leq x_i^T \leq Popsize - 1$, где *Popsize* – размер популяции) i -ый индивидуум в поколении T , а $Anc_i^T(j)$ – набор предков индивидуума x_i^T j -ой глубины [10].

Для того, чтобы определить понятие степени элитарности, необходимо определить понятие элиты. Предположим, что в задаче максимизации пригодности индивидуумов в популяции распределены по нормальному закону, с μ и σ – средним и среднеквадратическим отклонением соответственно. В этом случае индивидуумы с пригодностью, большей или равной $\mu + \alpha \times \sigma$, считаются элитными, где α – критерий элитарности (действительное неотрицательное число). Таким образом, степень элитарности для задачи максимизации определяется следующим выражением [1]:

$$E_d(T, i) = \frac{\sum_{j=0}^{level_max} (|Elite_i^T(j)| \times \beta^j)}{\sum_{j=0}^{level_max} (|Anc_i^T(j)| \times \beta^j)}, \quad (1)$$

$$Elite_i^T(j) = \{x_k^{T-j} | x_k^{T-j} \in Anc_i^T(j), \mu_{T-j} + \alpha \times \sigma_{T-j} \leq f(x_k^{T-j})\}$$

где $Elite_i^T(j)$ – набор элитных предков j -ой глубины индивидуума x_i^T , μ_T и σ_T – среднее и среднеквадратическое отклонение для поколения T , $f(x_i^T)$ – пригодность индивидуума, α – критерий элитности, β ($0 \leq \beta \leq 1$) – коэффициент влияния.

Увеличение коэффициента α уменьшает число элитных особей, таким образом, критерий элитарности является неким порогом, ограничивающим количество индивидуумов, которые попадают под понятие элиты. От величины коэффициента β зависит сила влияния предыдущих поколений. Число поколений, используемое при подсчете степени элитарности, ограничивается значением *level_max*. Аналогичным образом степень элитарности определяется и для задач минимизации.

Для применения стратегии переключения кроссовера используется дискретная степень элитарности E_d . В случае, если неравенство (2) выполняется, используется двухточечный кроссовер, иначе равномерный.

$$(E_d(T, i) + E_d(T, j)) \geq D_{th}, \quad (2)$$

где D_{th} – коэффициент, определяемый пользователем ($0 \leq D_{th} \leq 2$) [1].

Но такой подход имеет и недостатки, например, в случае, когда степень элитарности определяется дискретно, с помощью порогового значения, как описано выше, полученное значение может лишь приблизительно дать оценку индивидуумов в каждом поколении. Именно поэтому целесообразно рассмотреть непрерывную величину оценки, основанную на отклонении.

Среднеквадратическое отклонение равно следующему выражению:

$$st_dev^T = \sqrt{\frac{\sum (f(x_i^T) - \bar{f}^T)^2}{N-1}}, \quad (3)$$

где T – текущее поколение, P – популяция, содержащая индивидуумов $x_1^T, x_2^T, \dots, x_N^T$, имеющих приспособленность $f(x)_1^T, f(x)_2^T, \dots, f(x)_N^T$, N – общее число индивидуумов, \bar{f}^T – среднее значение приспособленности, которое определяется в виде:

$$\bar{f}^T = \frac{1}{N} \sum_{i=1}^N f(x_i^T) \quad (4)$$

Среднее отклонение $T_{dev}^T(x_i^T)$ индивидуума x_i^T имеет вид:

$$T_{dev}^T(x_i^T) = \frac{f(x_i^T) - \bar{f}^T}{st_dev^T} \times 10 + 50 \quad (5)$$

Обозначим множество предков индивидуума x_i^T , поколения j , как $Arc_i^T(j)$. Обозначим максимальное число поколений, которые будут рассматриваться в ходе подсчета элитарной степени индивидуума, как $level_max$, а также определим коэффициент влияния β . Тогда степень элитарности $E_c(T, i)$ равна:

$$E_c(T, i) = \frac{\sum_{j=0}^{level_max} \sum_{x_k^{T-j} \in Arc_i^T(j)} T_{dev}^{T-j}(x_k^{T-j}) \times \beta^j}{100 * \sum_{j=0}^{level_max} |Arc_i^T(j)| \times \beta^j} \quad (6)$$

В дальнейшем будем называть величину $(E_d(T, i))$ дискретной степенью элитарности, а величину $E_c(T, i)$ непрерывной степенью элитарности.

Как следует из гипотезы элит, индивидуумы с высоким показателем степени элитарности наиболее вероятно содержат большое количество хороших схем [5]. С другой стороны, как известно, вероятность разрушения схем зависит от генетических операторов и параметров. Например, при использовании двухточечного кроссовера вероятность разрушения схем ниже, чем при использовании однородного кроссовера [1]. Кроме того, вероятность разрушения возрастает с увеличением вероятности мутации. С увеличением вероятности разрушения схем алгоритм приближается к случайному поиску. Исходя из этих соображений, целесообразно использовать подход, основанный на переключении кроссовера в процессе работы алгоритма на основе степени элитарности. В работе [5] рассматривается подход, основанный на дискретной степени элитарности. Рассмотрим стратегию, основанную на непрерывной степени элитарности с дополнительной настройкой вероятности мутации.

Адаптивное переключение кроссовера осуществляется в соответствии с суммой степеней элитарности предков. Предположим, что применяются два типа кроссовера – двухточечный и равномерный. В данном случае двухточечный алгоритм будет использоваться, когда степень элитарности больше значения $Rand(0,2)$, в противном случае будет применен равномерный кроссовер.

Двухточечный кроссовер будет выбран в случае выполнения неравенства:

$$\frac{E_c(T,i)+E_c(T,j)-2E_{min}}{E_{max}-E_{min}} \geq Rand(0,2), \quad (8)$$

где $E_c(T, i)$, $E_c(T, j)$ – степень элитарности для i -го и j -го решения, соответственно, E_{min} , E_{max} – минимальное и максимальное значение степени элитарности всей популяции в текущем поколении.

Далее рассмотрим адаптивную регулировку вероятности мутации в генетическом алгоритме. Пусть T_m – порог регулировки мутации, который задаётся пользователем. В случае, если степень элитарности индивидуума выше этого порога, то вероятность мутации будет равна значению p_{me} , иначе p_{mn} . Значения p_{me} и p_{mn} являются входными параметрами алгоритма, причём $p_{me} < p_{mn}$. Ожидается, что индивидуумы, прошедшие порог T_m , будут сохраняться. Для других индивидуумов процесс поиска решений продолжается.

Результаты вычислительных экспериментов

Была исследована эффективность генетических алгоритмов, использующих рассмотренные стратегии настройки кроссовера и мутации. Эксперименты проводились для сравнения ГА с дискретной и непрерывной степенью элитарности, в качестве контрольного примера был использован простой генетический алгоритм. Вычислительный эксперимент был проведён при помощи программы Greffenstettes GENESIS 5.0. Данная программа основана на простом генетическом алгоритме, она широко применяется в исследовательских целях. В рамках данной работы ГА на основе непрерывной и дискретной степени элитарности реализованы в виде отдельных приложений. Простой генетический алгоритм представлен программой GENESIS.

Использованные параметры ГА: число индивидуумов – 50, вероятность кроссовера – 0.6, разрыв поколений – 1.0, метод селекции – сохранение элитных особей, использована кодировка Грея, максимальное число поколений – 1000. Для ГА с дискретной элитарной схемой: критерий элиты α – 0.2, коэффициент влияния элиты β – 0.5, порог D_{th} – 1.5. Вероятность мутации для ПГА и ГА с дискретной степенью элитарности – 0.001, для непрерывной: p_{me} – 0.001, p_{mn} – 0.01, порог T_m – 0.5. Начальные значения решений устанавливаются случайным образом.

Для сравнения рассмотренных модификаций со стандартным генетическим алгоритмом используется набор тестовых функций De Jong'a [1,5]. Для каждой задачи было произведено десять испытаний для каждого алгоритма, в ходе которых были найдены лучшие решения и средние отклонения, а также были найдены средние значения числа поколений, которые необходимы для достижения данного решения.

Набор тестовых функций De Jong'a широко применяется для оценки эффективности генетических алгоритмов. Тестирование рассмотренных вариантов проводилось на 5 задачах:

1. Квадратичная функция:

$$f_1(X) = \sum_{i=1}^3 x_i^2$$

$$-5.12 \leq x_i \leq 5.12$$

$$\min(f_1) = f_1(0, \dots, 0) = 0$$

2. Функция Розенброка:

$$f_2(X) = \sum_{i=1}^2 (100 * (x_{i+1} - x_i^2)^2 + (x_i - 1)^2)$$

$$-5.12 \leq x_i \leq 5.12$$

$$\min(f_2) = f_2(1, \dots, 1) = 0$$

3. Ступенчатая функция:

$$f_3(X) = 30 + \sum_{i=1}^5 |x_i|$$

$$-5.12 \leq x_i \leq 5.12$$

$$\min(f_3) = f_3([-5.12, -5), \dots, [-5.12, -5)) = 0$$

4. Функция четвертой степени с шумом:

$$f_4(X) = \sum_{i=1}^{30} ix_i^4 + gauss(0,1)$$

$$-1.28 \leq x_i \leq 1.28$$

$$\min(f_4) = f_4(0, \dots, 0) = 0$$

5. Функция Шекеля:

$$\frac{1}{f_5(X)} = \frac{1}{K} + \sum_{j=1}^{25} \frac{1}{c_j + \sum_{i=1}^2 (x_i - a_{ij})^6}$$

$$(a_{ij}) = \begin{pmatrix} -32 & -16 & 0 & 16 & 32 & -32 & \dots & 0 & 16 & 32 \\ -32 & -32 & -32 & -32 & -32 & -16 & \dots & 32 & 32 & 32 \end{pmatrix}$$

$$K = 500;$$

$$f_5(a_{1j}, a_{2j}) \approx c_j = j$$

$$\min(f_5) = f_5(-32, -32) \approx 1$$

Результаты вычислительных экспериментов приведены в таблице 1. В проведённых экспериментах помимо предложенных адаптивных генетических алгоритмов было использовано два стандартных генетических алгоритма с различными операторами кроссовера – двухточечным и равномерным. Решения закодированы

десятибитным кодом Грея (значения каждой переменной преобразованы в формат числа с плавающей запятой двойной точности). Так как были рассмотрены только задачи минимизации, наименьшие значения признаны лучшими.

В таблице использованы следующие обозначения: « E_c » – генетический ГА, основанный на непрерывной степени элитарности (« $p_{me} < p_{mn}$ » – алгоритм с адаптивной настройкой вероятности мутации, « $p_{me} = p_{mn}$ » – алгоритм с фиксированной вероятностью мутации), « E_d » – ГА, основанный на дискретной степени элитарности, «двухточечный» – простой ГА с двухточечным кроссинговером и «равномерный» – ГА с равномерным кроссинговером.

Таблица 1 – Лучшие решения и поколения, на которых они были получены
Table 1 – The best solutions and the generations on which they were obtained

	Решения	Число поколений	Среднее отклонение
f1			
$E_c(p_{me} < p_{mn})$	8.120×10^{-5}	137	8.014×10^{-24}
$E_c(p_{me} = p_{mn})$	7.361×10^{-5}	190	7.862×10^{-20}
E_d	9.515×10^{-5}	219	4.534×10^{-22}
Двухточечный	1.492×10^{-4}	437	6.985×10^{-24}
Однородный	9.737×10^{-5}	202	9.824×10^{-25}
f2			
$E_c(p_{me} < p_{mn})$	1.625×10^{-3}	353	1.506×10^{-7}
$E_c(p_{me} = p_{mn})$	5.083×10^{-3}	568	5.039×10^{-5}
E_d	8.631×10^{-3}	620	1.142×10^{-4}
Двухточечный	2.094×10^{-2}	174	5.028×10^{-4}
Однородный	1.907×10^{-2}	287	1.712×10^{-3}
f3			
$E_c(p_{me} < p_{mn})$	4.011×10^{-1}	156	4.556×10^{-1}
$E_c(p_{me} = p_{mn})$	2.871×10^{-1}	312	1.933×10^{-1}
E_d	2.650×10^{-1}	342	1.897×10^{-1}
Двухточечный	1.329×10^{-1}	386	1.042×10^{-2}
Однородный	1.422×10^{-1}	315	2.140×10^{-2}
f4			
$E_c(p_{me} < p_{mn})$	-1.130×10^{-2}	294	5.890×10^{-1}
$E_c(p_{me} = p_{mn})$	1.142×10^{-2}	308	6.321×10^{-1}
E_d	-1.015×10^{-1}	297	2.245×10^{-1}
Двухточечный	1.119×10^{-1}	322	1.080×10^{-1}
Однородный	-1.288×10^{-1}	307	4.340×10^{-1}
f5			
$E_c(p_{me} < p_{mn})$	9.980×10^{-1}	241	1.974×10^{-6}
$E_c(p_{me} = p_{mn})$	9.989×10^{-1}	152	2.250×10^{-3}
E_d	9.980×10^{-1}	215	2.993×10^{-5}
Двухточечный	1.844×10^{-1}	143	1.200×10^{-1}
Однородный	5.289×10^{-1}	162	8.714×10^{-1}

Для функций f2, f4, f5 рассмотренные в данной работе алгоритмы показали лучшие результаты. Задача f3 наиболее точно была решена с помощью неадаптивного ГА. На задаче f1 эффективность методов приблизительно одинакова. На основе

проведенных испытаний можно сделать вывод о том, что в большинстве случаев генетический алгоритм на основе непрерывной и дискретной степени элитарности превосходит в эффективности стандартный ГА. Также можно утверждать, что использование адаптивной настройки вероятности мутации дает прирост производительности.

Заключение

Таким образом, адаптивное переключение кроссовера и настройка вероятности мутации в соответствии с пригодностью индивидуума позволяет проводить более гибкий поиск в области решения. Кроме того, многие практические задачи оптимизации имеют те же характеристики, что и тестовые задачи De Jong'a, что указывает на применимость на практике рассмотренного метода.

ЛИТЕРАТУРА

1. Hatta K, Matsuda K, Wakabayashi S, Koide T. On-the-fly crossover adaptation of genetic algorithms. *Proc IEE/IEEE Genetic Algorithms in Engineering Systems: Innovations and Applications*. 1997:197-202.
2. Гладков Л.А., Курейчик В.В., Курейчик В.М. Генетические алгоритмы: учебное пособие. М.: Физматлит. 2006.
3. Белецкая С.Ю., Боковая Н.В. Технология оптимального проектирования развивающихся производственных систем. *Системы управления и информационные технологии*. 2008;2-2(32):223-226.
4. Liles W.C., Wiegand R.P. Introduction to Schema Theory: A survey lecture of pessimistic & exact schema theory. Computer Science Department, George Mason University. 2002.
5. Hatta K. Adaptive choice of crossover type in genetic algorithms. 1998:900-909.
6. Coello Carlos. An updated survey of GA-based multiobjective optimization techniques. *ACM Computing Surveys*. 2000;32(2):109-143.
7. Alshraideh M., Mahafzah B. A MultiplePopulation Genetic Algorithm for Branch Coverage Test Data Generation. *Software Quality Control*. 2011;19(3):489-513.
8. Rashedi E., Nezamabadi-pour H., Saryazdi S. GSA: A Gravitational Search Algorithm. 2009;179(13):2232-2248.
9. Zhang C. and Wang H.-P., Mixed-discrete nonlinear optimization with simulated annealing. *Engineering Optimization*. 1993;21(4):277-291.
10. Xue C, Dong L, Li G. An Improved Immune Genetic Algorithm for the Optimization of Enterprise Information System based on Time Property[J]. *Journal of Software*. 2011;6(3):436-443.

REFERENCES

1. Hatta K, Matsuda K, Wakabayashi S, Koide T. On-the-fly crossover adaptation of genetic algorithms. *Proc IEE/IEEE Genetic Algorithms in Engineering Systems: Innovations and Applications*. 1997:197-202.
2. Gladkov L.A., Kureychik V.V., Kureychik V.M. Genetic algorithms: schoolbook. М.: Fizmatlit. 2006.
3. Beletskaya S.Yu., Bokovaya N.V. Optimal design technology for developing production systems. *Management Systems and Information Technology*. 2008;2-2(32):223-226.
4. Liles W.C., Wiegand R.P. Introduction to Schema Theory: A survey lecture of pessimistic & exact schema theory. Computer Science Department, George Mason University. 2002.
5. Hatta K. Adaptive choice of crossover type in genetic algorithms. 1998:900-909.

6. Coello Carlos. An updated survey of GA-based multiobjective optimization techniques. *ACM Computing Surveys*. 2000;32(2):109-143.
7. Alshraideh M., Mahafzah B. A MultiplePopulation Genetic Algorithm for Branch Coverage Test Data Generation. *Software Quality Control*. 2011;19(3):489-513.
8. Rashedi E., Nezamabadi-pour H., Saryazdi S. GSA: A Gravitational Search Algorithm. 2009;179(13):2232-2248.
9. Zhang C. and Wang H.-P., Mixed-discrete nonlinear optimization with simulated annealing. *Engineering Optimization*. 1993;21(4):277-291.
10. Xue C, Dong L, Li G. An Improved Immune Genetic Algorithm for the Optimization of Enterprise Information System based on Time Property[J]. *Journal of Software*. 2011;6(3):436-443.

ИНФОРМАЦИЯ ОБ АВТОРЕ / INFORMATIONS ABOUT AUTHORS

Асанов Юрий Анатольевич, аспирант, кафедра систем автоматизированного проектирования и информационных систем, Воронежский государственный технический университет, Воронеж, Российская Федерация.
e-mail: asanovjura@mail.ru

Yuri A. Asanov, graduate student, department of computer-aided design and information systems, Voronezh State Technical University, Voronezh, Russian Federation.

Белецкая Светлана Юрьевна, доктор технических наук, профессор, кафедра систем автоматизированного проектирования и информационных систем, Воронежский государственный технический университет, Воронеж, Российская Федерация.
e-mail: su_bel@mail.ru

Svetlana Yu. Beletskaya, Doctor of Technical Sciences, Professor, department of computer-aided design and information systems, Voronezh State Technical University, Voronezh, Russian Federation.

Аль-Саеди Моханад Ридха Ганим, аспирант, кафедра систем автоматизированного проектирования и информационных систем, Воронежский государственный технический университет, Воронеж, Российская Федерация.

Al-Saedi Mohanad Ridha Ghanim, graduate student, department of computer-aided design and information systems, Voronezh State Technical University, Voronezh, Russian Federation.