

DOI: 10.17323/2587-814X.2024.2.48.66

# Адаптивное управление транспортной инфраструктурой в городской среде с использованием генетического алгоритма вещественного кодирования

**А.С. Акопов**<sup>a</sup> 

E-mail: akopovas@umail.ru

**Е.А. Зарипов**<sup>a,b</sup> 

E-mail: e.a.zaripov@ya.ru

**А.М. Мельников**<sup>a,b</sup> 

E-mail: alexdef2@mail.ru

<sup>a</sup> Центральный экономико-математический институт, Российская академия наук, Москва, Россия

<sup>b</sup> МИРЭА – Российский технологический университет, Москва, Россия

## Аннотация

Управление городским территориальным комплексом обуславливает необходимость разработки эффективной стратегии эволюционного развития транспортной инфраструктуры. Ключевым элементом подобной инфраструктуры является система светофоров, обеспечивающая регулирование транспортных и пешеходных потоков. Улучшение качества управления в интеллектуальной транспортной системе (ИТС), позволяет не только увеличить пропускную способность уличной дорожной сети, но также оказывает существенное влияние на экономику города, уменьшая издержки всех участников дорожного движения. В результате для участников дорожного движения могут быть сокращены расходы на топливо, повышен уровень их социального комфорта и т. д. В данной работе предлагается новый подход к

оптимизации транспортных потоков «умного города», основанный на комбинированном использовании разработанного генетического оптимизационного алгоритма и имитационной модели ИТС. Разработанный оптимизационный алгоритм агрегирован по целевым функционалам с созданной имитационной моделью реального участка уличной дорожной сети г. Москвы со своими перекрестками, пешеходными переходами и др., реализованной в системе AnyLogic. Исследование направлено на создание системы поддержки принятия решений по управлению городской транспортной инфраструктурой, на примере задачи оптимизации длительности фаз регулирующих сигналов светофоров, с целью уменьшения временных затрат на проезд транспортных средств через ключевые узлы городской дорожной сети, оптимизации движения пешеходных потоков и др. Применение предложенного подхода позволяет значительно повысить пропускную способность уличной дорожной сети, уменьшить негативное воздействие автомобильных потоков на окружающую среду за счет оптимизации расхода топлива и сокращения времени ожидания на перекрестках, регулируемых светофорами. Методология исследования включает в себя разработку модифицированного генетического алгоритма, построение имитационной модели транспортных и пешеходных потоков в AnyLogic, проведение ряда оптимизационных экспериментов, демонстрирующих эффективность предложенного подхода в контексте моделирования сложных урбанистических транспортных систем.

**Ключевые слова:** управление городским территориальным развитием, муниципальное управление, интеллектуальные транспортные системы, умный город, генетический алгоритм вещественного кодирования, имитационное моделирование транспортных потоков, управление дорожным движением, AnyLogic

**Цитирование:** Акопов А.С., Зарипов Е.А., Мельников А.М. Адаптивное управление транспортной инфраструктурой в городской среде с использованием генетического алгоритма вещественного кодирования // Бизнес-информатика. 2024. Т. 18. № 2. С. 48–66. DOI: 10.17323/2587-814X.2024.2.48.66

## Введение

Эволюционное развитие транспортной инфраструктуры, в частности, посредством проектирования и внедрения ИТС является важным направлением бизнес-информатики, актуальным для государственных, муниципальных и частных предприятий, отвечающих за создание и поддержание комфортной и безопасной городской среды. В условиях ускоренной урбанизации и постоянного роста численности транспортных средств актуализируется проблематика эффективного управления транспортными и пешеходными потоками. Сложность задачи оптимизации дорожного движения обусловлена многофакторностью и динамичностью процессов, происходящих в урбанистическом пространстве, что требует применения современных методов математического и имитационного моделирования ИТС.

В сфере оптимизации управления светофорами известны различные подходы, в том числе включающие использование генетических оптимизаци-

онных алгоритмов [1–3], методов машинного обучения [4], искусственных нейронных сетей [5], нечеткой логики [2], кластеризации [1, 6]. Однако следует учитывать, что большинство подобных подходов нацелены на исследование поведения агентов в цифровых дорожных сетях, конфигурация которых существенно отличается от реальных городских дорожных сетей [1, 2], либо применяются для случаев с транспортными системами простой структуры – с малым количеством перекрестков и полос [5, 7]. Имитационное моделирование является мощным инструментом для исследования и анализа транспортных систем, позволяя воссоздать и изучить поведение сложных систем в контролируемой виртуальной среде [8]. В частности, применение гибридных алгоритмов, объединяющих преимущества методов роевой [9, 10] и генетической оптимизации [1, 2, 11, 12], открывает новые перспективы для повышения эффективности управления транспортными потоками.

Целью данного исследования является изучение возможностей по улучшению характеристик

объектов городской транспортной инфраструктуры (в частности, светофоров) с использованием предложенных методов эволюционного поиска оптимальных решений. В рамках такого подхода выполнена разработка имитационной (агент-ориентированной) модели реального участка уличной дорожной сети г. Москвы с использованием системы AnyLogic, предложен усовершенствованный *генетический алгоритм вещественного кодирования*, агрегированный по целевым функционалам с созданной имитационной моделью транспортных и пешеходных потоков. Представленный подход направлен на оптимизацию длительности фаз регулирующих сигналов светофоров, в частности, для минимизации временных и материальных затрат транспортных средств на прохождение изучаемого локального участка уличной дорожной сети, а также на улучшение условий движения пешеходных потоков на перекрестках и пешеходных переходах. В результате обеспечивается адаптация управляющих параметров светофоров к текущим условиям дорожного движения, с учетом оптимизации расхода топлива и снижения вредных выбросов в атмосферу. Разработанная имитационная модель многоагентной ИТС, включает элементы уличной дорожной сети (дороги, светофоры, перекрестки, и т. д.), транспортные и пешеходные потоки, состо-

ящие из отдельных агентов — взаимодействующих участников дорожного движения со своими правилами принятия индивидуальных решений. Спроектированная система предназначена для анализа влияния различных стратегий управления длительностью фаз регулирующих сигналов светофоров, влияющих на эффективность транспортных потоков в городских условиях. Исследование вносит вклад в развитие методов эволюционного моделирования городской транспортной инфраструктуры, демонстрируя высокий потенциал генетических оптимизационных алгоритмов в решении актуальных задач урбанистического планирования и муниципального управления.

### 1. Имитационная модель транспортных и пешеходных потоков

В основе предложенного подхода лежит разработка комплексной имитационной модели транспортных потоков, реализованной в среде AnyLogic. В отличие от ранее разработанных систем подобного типа [1, 13], в данной модели выполнено цифровое проектирование реального участка уличной дорожной сети г. Москвы с управляемыми светофорами, транспортными средствами и пешеходными потоками (рис. 1, 2). В качестве ключевых элементов модели выступают:

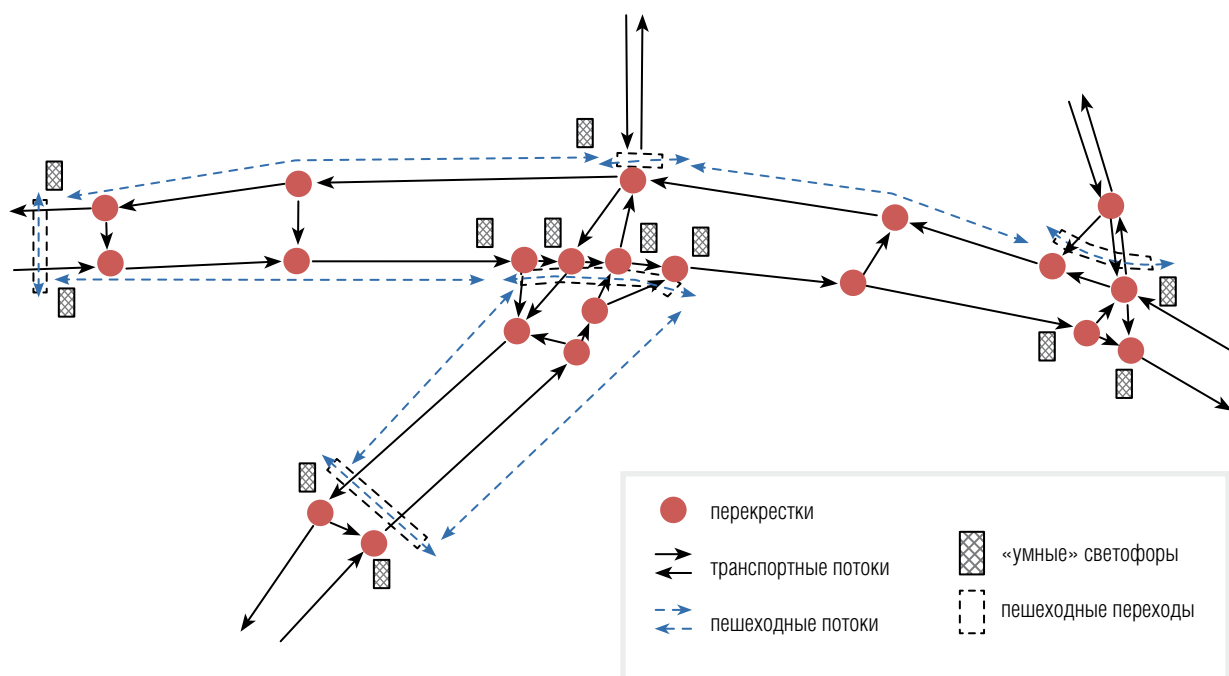


Рис. 1. Спроектированная модель цифрового участка уличной дорожной сети.

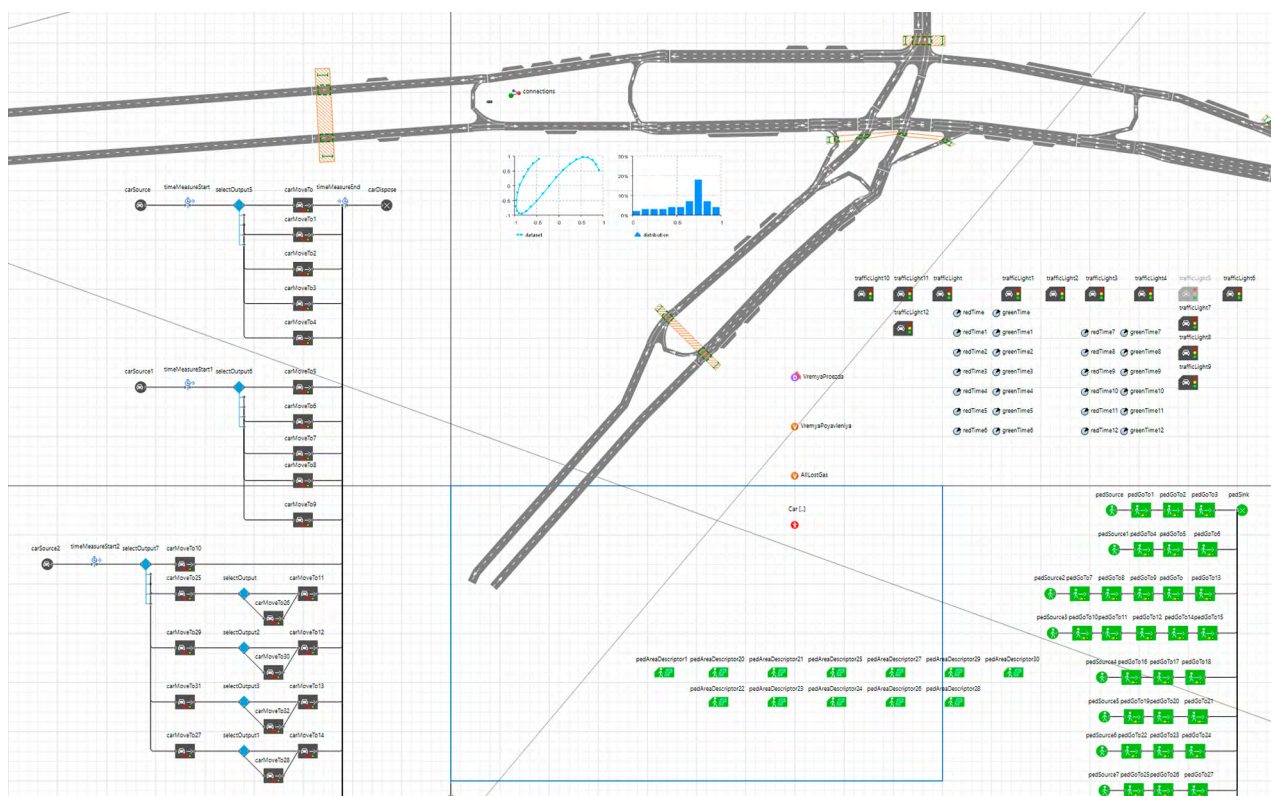


Рис. 2. Реализация цифровой модели участка уличной дорожной сети в среде AnyLogic.

- ♦ **Дорожная инфраструктура:** проектируется (в цифровой среде AnyLogic) реальная геометрия дорог, включая количество полос, направления движения, перекрестки и пешеходные переходы.
- ♦ **Транспортные средства и пешеходы:** моделируются индивидуальное и групповое поведение участников дорожного движения, их скорость, маршруты и взаимодействие с элементами дорожной сети.
- ♦ **Светофорная сигнализация:** моделируется работа светофоров с возможностью изменения их параметров (длительности фаз) для оптимизации трафика.

Для реализации предложенной методологии использовался программный комплекс AnyLogic, позволяющий моделировать сложные транспортные потоки в условиях городской инфраструктуры. Anylogic позволяет качественно комбинировать элементы системной динамики, агент-ориентированного и дискретно-событийного моделирования [13–16]. Интеграция с AnyLogic обеспечивается экспортом имитационной модели в формате jar-файла, что позволяет автоматизировать процесс оценки эффективности работы светофоров и их влияния на транспортные потоки.

Важной особенностью методологии является учет взаимодействия транспортных средств с пешеходными потоками, что обеспечивается за счет использования элементов пространственной разметки и пешеходной библиотеки AnyLogic. Это позволяет моделировать реалистичные сценарии работы транспортной системы и оценивать эффективность предложенных оптимизационных мер в комплексе.

В рамках комплексного подхода к анализу и оптимизации городских транспортных потоков, особое внимание уделяется моделированию взаимодействия между транспортными средствами и пешеходными потоками [1, 12]. Для этого в имитационной модели, разработанной в среде AnyLogic, реализована детализированная схема пешеходных переходов с использованием элементов библиотеки пространственной разметки (Space Markup), что позволяет точно воссоздать условия их функционирования и влияние на общую эффективность дорожного движения. Реализация в цифровой модели участков пешеходных переходов в районе станции метро Юго-Западная представлена на рис. 3.

Структурные элементы моделирования пешеходного движения:




Рис. 3. Реализация в цифровой модели участков пешеходных переходов в районе станции метро Юго-Западная.

- ◆ **Стены (Wall):** функционируют как элементы, ограничивающая область движения пешеходов, создавая условия, максимально приближенные к реальности, где пешеходные потоки не могут произвольно пересекать дорожное полотно, а направляются в зоны пешеходных переходов.
- ◆ **Целевые линии (Targetline):** определяют точки появления и исчезновения пешеходов в модели, а также места их ожидания, включая остановки общественного транспорта, входы в здания и другие ключевые точки пешеходной инфраструктуры.
- ◆ **Многоугольный узел (Area):** используется для детализации области пешеходного перехода, включая его геометрию и специфические условия перемещения пешеходов.

*Логика перемещения пешеходов.* Модель включает

в себя комплекс логических блоков из Пешеходной библиотеки (Pedestrian Library), отвечающих за регулирование движения пешеходов:

- ◆ **Блоки перемещения (pedGoTo):** обеспечивают динамическое управление движением пешеходов, направляя их к заданным целям, включая пешеходные переходы, остановки общественного транспорта и другие важные объекты.
- ◆ **Блоки управления узлами (pedAreaDescriptor):** позволяют задавать правила движения в конкретных зонах, включая доступность пешеходных переходов в зависимости от сигналов светофоров.
- ◆ **Блок удаления (pedSink):** отвечает за удаление пешеходов из модели по достижении ими конечной цели, позволяя анализировать потоки и плотность пешеходного движения.

Таблица 1.

### Структурные блоки модели

Наименование	Функция	Характеристика
pedSource, pedSource1, ..., pedSource9	Установка места появления пешеходов	Необходимы для появления агентов пешеходов
pedGoTo, pedGoTo1, ..., pedGoTo32	Установка пункта назначения пешехода и управление его движением	Необходимы для управления направленности перемещения пешеходов
pedSink	Удаление пешеходов из модели	Необходим для очистки модели от пешеходов, достигших конечного пункта движения
PedAreaDescriptor, pedAreaDescriptor1, ..., pedAreaDescriptor30	Определяют правила перемещения для пешеходов в определенных узлах	Необходимы для управления пешеходными переходами в соответствии с фазами светофоров






Рис. 4. Фрагмент разработанной имитационной модели дорожного движения с применением пешеходной библиотеки AnyLogic.

На рисунке 4 представлена общая логика перемещения пешеходов в модели. В таблице 1 представлены структурные блоки, на которых построена логика перемещения пешеходов и работы пешеходных переходов.

Проблема увеличения уровня загрязненности воздуха, сопряженная с общим ростом мировой экономики и в том числе с ростом количества автомобильного транспорта, давно является глобальной. Улучшение уровня экологии в комбинации с экономическими показателями с помощью

моделирования также является актуальной задачей. В связи с этим, для оценки экологической эффективности транспортной системы в модели внедрена система переменных и элементов системной динамики внутри агентов Car, позволяющая анализировать расход топлива в зависимости от условий движения (рис. 5):

◆ **Переменные расхода топлива и скорости:** моделируют потребление топлива транспортными средствами в реальном времени, учитывая скорость движения и остановки на светофорах.

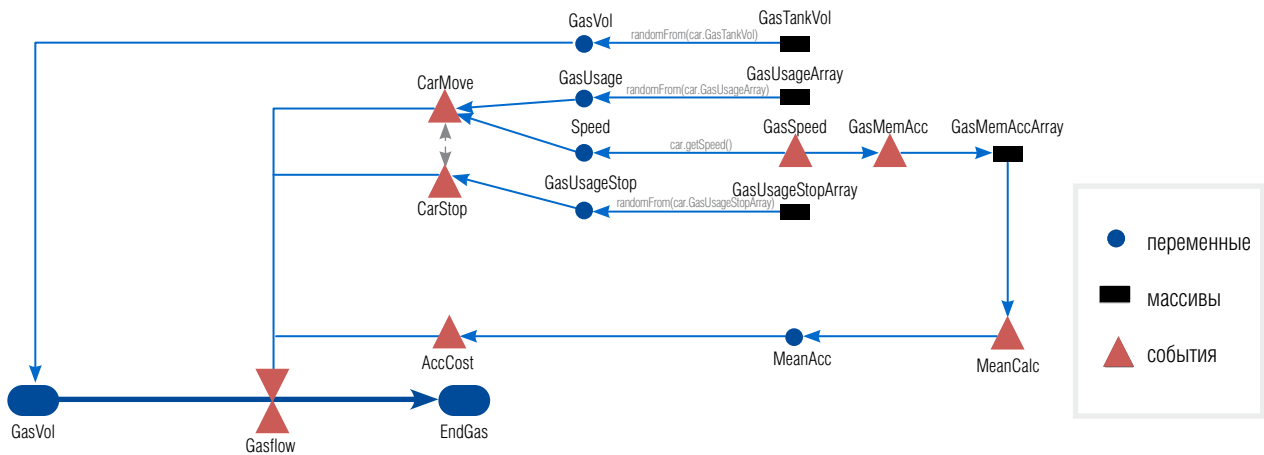


Рис. 5. Переменные, события и элементы системной динамики, принадлежащие агенту.

♦ **События остановки и возобновления движения:** регулируют изменение расхода топлива при остановке и старте транспортного средства, позволяя точнее оценить влияние пробок и частых остановок на экологические показатели.

♦ **Интеграция пешеходных потоков и анализ расхода топлива:** позволяет не только оптимизировать транспортное движение с точки зрения времени проезда, но и улучшить условия для пешеходов и снизить негативное воздействие транспорта на окружающую среду.

В имитационной модели транспортных потоков агенты-автомобили оснащены рядом переменных, отражающих их топливные характеристики и динамику движения. Основные переменные включают объем топлива (GasVol), расход на 100 км (GasUsage), расход в состоянии покоя (GasUsageStop), генерируемые случайно из определенных диапазонов. Системная динамика модели учитывает изменение объема топлива (GasVol1) и общее потраченное топливо (EndGas), регулируемое активностью агента и событиями, контролирующими движение и остановку. Учет ускорения агента через переменную MeanAcc и события SpeedMemAcc и MeanCalc позволяет моделировать экономию топлива при агрессивном ускорении, демонстрируя возможное снижение расхода до 10% [17]. Этот факт был учтен в виде уменьшенного потребления при высоком ускорении. Таким образом, значение расхода топлива определяется по формуле (1), а все переменные и их характеристики представлены в *таблице 2*.

$$\frac{dE}{dt} = \begin{cases} U \cdot S & S > 0, \\ K & S = 0, \\ A \sum_{i=0}^n (a[i+1] - a[i]) / (n-1) < 1,45, & \end{cases} \quad (1)$$

где  $E$  – потраченное топливо;

$U$  – расход топлива агента;

$S$  – скорость агента на момент времени;

$K$  – расход при отсутствии движения;

$A$  – расход топлива на момент ускорения с учетом поправки на агрессивное ускорение;

$a$  – ежесекундные замеры скорости агента после отсутствия движения.

По удалению из модели, значение EndGas потраченного топлива за время прохождения модели конкретного агента добавляется к переменной «Общее потраченное топливо» (AllLostGas).

## 2. Генетический алгоритм для управления светофорами

В основе предложенного подхода – использование *генетического алгоритма вещественного кодирования* [1, 2, 11, 12], модифицированного для задачи оптимизации режимов работы светофорных объектов в урбанистической среде. Алгоритм агрегирован с имитационной моделью ИТС, разработанной в среде AnyLogic, что позволяет учитывать специфику дорожного движения и взаимодействия транспортных потоков с инфраструктурой на конкретных участках дорожной сети.

Таблица 2.

Таблица переменных и их характеристик

Переменная	Описание	Источник значения
GasVol	Объем топлива у агента на момент появления	Случайное значение из GasTankVol
GasUsage	Расход топлива на 100 км	Случайное значение из GasUsageArray
GasUsageStop	Расход топлива в состоянии покоя	Случайное значение из GasUsageStopArray
Speed	Текущая скорость агента	Обновляется через событие CarSpeed
GasVol1	Фактический объем топлива	Изменяется с передвижением агента
GasFlow	Расход топлива	Регулируется событиями CarStop и CarMove
EndGas	Общее потраченное топливо	Изменяется в соответствии с GasFlow
MeanAcc	Среднее ускорение агента	Расчет на основе SpeedMemAccArr

*Инициализация популяции* в генетическом алгоритме начинается с создания двадцати особей, представляющих собой наборы параметров для регулирования светофора, включая времена зеленого и красного сигналов, инициализируемые случайно в заданных интервалах (см. (2)–(4)). Этот этап задает исходное разнообразие решений, критически важное для эффективного поиска в пространстве решений и избегания преждевременной сходимости [18]. Каждая особь моделируется классом с параметрами длительности зеленого и красного сигналов, определяемыми случайно. *Процесс генерации* потенциальных решений основывается на создании особей с разнообразными параметрами через функцию  $Swarm()$ , что способствует широкому исследованию пространства решений (см. (5)). Этот этап необходим для последующих шагов алгоритма, обеспечивая начальную базу для эволюции популяции через отбор, скрещивание и мутацию, направленных на оптимизацию регулирования дорожного движения.

Для генерации случайного значения  $x$  в интервале  $[a, b]$ , где  $a$  – нижний предел,  $b$  – верхний предел, используется выражение:

$$x = a + (b - a) \cdot Random.nextDouble(). \quad (2)$$

Таким образом, для инициализации параметра  $green$  (длительность фазы зеленого сигнала светофора) из интервала  $[green_{min}, green_{max}]$ , и  $red$  (длительность фазы красного сигнала светофора) из интервала  $[red_{min}, red_{max}]$  используются следующие выражения:

$$green = green_{min} + (green_{max} - green_{min}) \cdot Random.nextDouble(). \quad (3)$$

$$red = red_{min} + (red_{max} - red_{min}) \cdot Random.nextDouble(), \quad (4)$$

где  $green_{min}, green_{max}$  – нижний и верхний пределы для параметра  $green$ ;

$red_{min}, red_{max}$  – нижний и верхний пределы для параметра  $red$ ;

$Random.nextDouble()$  – случайное число в диапазоне  $[0, 1]$ , сгенерированное функцией  $nextDouble()$ .

При этом, начальная популяция особей, содержащих значения вектора искомым переменных  $x_i$ , создается с использованием следующего выражения:

$$P = \{(Swarm(x_i) | i = 1, 2, \dots, N)\}, \quad (5)$$

где  $Swarm(x_i)$  – функция, создающая новую особь со случайно инициализированными параметрами,  $N$  – размер популяции (количество особей в популяции).

*Отбор особей* в генетическом алгоритме оптимизации длительности фаз регулирующих сигналов светофоров осуществляется по критерию минимизации среднего времени проезда транспорта. Инициализация популяции предшествует отбору, где изначально отбор может быть неинформированным. С последующими итерациями, основываясь на обратном значении среднего времени проезда как целевой функции, отбираются наиболее адаптированные особи. Эффективность отбора определяется коэффициентом отбора, задающим долю популяции для скрещивания, и может применяться метод ранжирования для определения приспособленности особей [19]. Этот процесс направляет эволюцию популяции, улучшая ее характеристики и увеличивая вероятность нахождения оптимального решения. Отбор лучших особей является ключевым для дальнейших этапов генетического алгоритма, включая скрещивание и мутацию, что способствует генетическому разнообразию и адаптации популяции к задаче.

*Скрещивание (кроссовер)* в генетическом алгоритме вещественного кодирования, используемом для оптимизации работы светофоров, выполняется методом Панмиксии, обеспечивающим равные шансы каждой особи на участие в репродукции. Этап генерирует потомков с параметрами, определенными в диапазоне значений родителей согласно промежуточной величине, вычисляемой с использованием (6). Процедура скрещивания вносит генетическое разнообразие в популяцию путем комбинации генетического материала отобранных особей, что является ключевым фактором для эффективного поиска оптимальных решений в пространстве параметров светофорного регулирования.

$$Потомок = Родитель1 + \alpha \cdot (Родитель2 - Родитель1). \quad (6)$$

Здесь коэффициент  $\alpha = 0,5 \cdot \text{поисковое пространство}$  (диапазон допустимых значений искомым переменной).

В соответствии с ним каждому члену популяции сопоставляется случайное целое число на отрезке  $[1, N]$ . Будем рассматривать эти числа как номера особей, которые примут участие в скрещивании.



Какие-то члены популяции примут участие в процессе воспроизводства неоднократно с различными особями популяции [12]. Однако он достаточно критичен к численности популяции, поскольку эффективность алгоритма, реализующего такой подход, снижается с ростом численности популяции [12].

Пусть  $G_1$  и  $R_1$  – значения генов первого родителя,  $G_2$  и  $R_2$  – значения генов второго родителя,  $G_{child}$  и  $R_{child}$  – значения генов потомка. Тогда оператор кроссовера для каждого гена выглядит следующим образом:

$$G_{child} = \text{случайное число в интервале между } \min(G_1, G_2) \text{ и } \max(G_1, G_2), \quad (7)$$

$$R_{child} = \text{случайное число в интервале между } \min(R_1, R_2) \text{ и } \max(R_1, R_2), \quad (8)$$

Цель скрещивания заключается в генерации потомков с потенциально превосходящими характеристиками по сравнению с родителями через рекомбинацию генетических стратегий. Этот процесс увеличивает популяционное разнообразие и способствует оптимизации решений. Скрещивание обогащает популяцию новыми генетическими вариациями, необходимыми для адаптации и эволюции в контексте задачи, позволяя алгоритму эффективно исследовать и улучшать стратегии регулирования дорожного движения.

Скрещивание обеспечивает адаптацию генетического алгоритма к оптимизации работы светофоров, учитывая комплексные аспекты управления транспортной сетью. Это подход учитывает взаимозависимость параметров в светофорной сети, требуя интегрированного подхода для оптимизации, что исключает изоляцию настроек отдельных элементов без учета системной динамики. Промежуточная рекомбинация, выбранная для алгоритма, позволяет генерировать потомство с признаками внутри диапазона родительских генотипов, обеспечивая генетическое разнообразие и улучшая адаптацию потомства. Этот метод ускоряет сходимость алгоритма, направляя поиск к оптимальным решениям управления дорожным движением за счет эффективной балансировки между эксплорацией и эксплуатацией поискового пространства, что важно для сложной инфраструктуры городского трафика.

На последующем этапе каждая особь подвергается мутации с целью внесения дополнительного разнообразия в популяцию и избегания преждевре-

менной сходимости к локальным оптимумам. Мутация осуществляется с использованием (9)–(12), гарантируя незначительное изменение параметров с определенной вероятностью [12].

Мутация представляет собой механизм внесения случайных изменений в генетический материал особи, что способствует увеличению генетического разнообразия в популяции и предотвращает преждевременную сходимость алгоритма к локальным оптимумам [20]. В контексте оптимизации параметров светофоров мутация позволяет исследовать новые области пространства поиска, что может привести к открытию более эффективных конфигураций светофоров.

$$\begin{aligned} \text{Новое время сигнала светофора} = \\ = \text{предыдущее значение} \pm \alpha \cdot \delta, \end{aligned} \quad (9)$$

где знаки «+» или «-» выбираются с равной вероятностью;

$\delta$  – коэффициент, равный

$$\delta = \sum_{i=1}^m \alpha(i) 2^{-i}, \quad (10)$$

где

$$\alpha(i) = \begin{cases} \frac{1}{m}, & \text{если } u(0,1) \leq \bar{p}, \\ 0, & \text{если } u(0,1) > \bar{p}. \end{cases} \quad (11)$$

Здесь

$m$  – параметр алгоритма (выбран равным 20);

$u(0, 1)$  – случайное число, равномерно распределенное на интервале  $(0, 1)$ ;

$\bar{p}$  – вероятность мутации.

Новая особь, получившаяся при такой мутации, в большинстве случаев ненамного отличается от старой. Это связано с тем, что вероятность маленького шага мутации выше, чем вероятность большого шага [12].

Если рассматривать формулы отдельно для зеленого –  $G$  и красного  $R$  сигналов светофоров, тогда формулы мутации для каждого гена  $G$  и  $R$  будут выглядеть следующим образом:

$$G_{new} = G_{old} + M \cdot \text{случайное число}, \quad (12)$$

$$R_{new} = R_{old} + M \cdot \text{случайное число}, \quad (13)$$

где:

$$M = 198 \cdot 0,5 \cdot \sum_{i=1}^{20} p_i(0,1), \quad (14)$$

где  $p_i(0, 1)$  – случайные значения, равномерно заданные на интервале  $[0, 1]$  (вероятности мутации для каждого из 20 генов).

Мутация включает случайное изменение времени сигналов светофора в популяции, с изменениями в заданном диапазоне, что влияет на генетический материал различно. Техника мутации заключается в добавлении или вычитании значения к параметрам светофора, основанного на мутационном коэффициенте. Цель мутации – внести разнообразие, избегая локальных оптимумов и улучшая глобальный поиск решений, что может привести к появлению особей с уникальными характеристиками [21]. Мутация способствует генетическому разнообразию, критически важному для эффективности поиска, позволяя адаптироваться к изменениям и исследовать пространство решений, генерируя новые конфигурации для оптимизации работы светофоров в условиях динамичного городского трафика.

Механизм мутации вводится для баланса между ускорением сходимости через промежуточную рекомбинацию чтобы предотвратить преждевременную сходимостью к локальным оптимумам, посредством изменения генетической информации без модификации количества генов [22]. Мутация, адаптированная к вещественным особям (т. е. мутация с вещественным кодированием), обеспечивает минимальные, но значимые изменения, позволяя тонкую настройку без риска потери ценных генетических комбинаций. Это способствует выходу из локальных оптимумов и увеличивает генетическое разнообразие, стимулируя исследование новых областей и обнаружение более эффективных решений для оптимизации управления дорожным движением. В комбинации с промежуточной рекомбинацией мутация увеличивает адаптивность и эффективность поиска в сложных задачах регулирования транспортных потоков.

Для оптимизации управления транспортным потоком через светофоры, алгоритм вычисляет целевую функцию (например, среднее время проезда) для каждой особи, а затем исключает наименее успешные, сохраняя размер популяции. Целевая функция отражает эффективность управления и может включать разные параметры, как среднее время проезда или количество прошедших автомобилей. Отбор наиболее перспективных особей для следующего поколения происходит через методы, такие как ранжирование или турнирный отбор [23]. Этот процесс, адаптированный под уникальные условия каждого перекрестка, итеративно уточняет и улучшает попу-

ляцию, приближая к оптимальному решению и позволяя алгоритму адаптироваться к изменениям и исследовать возможные решения.

В разработанном генетическом алгоритме используется стратегия Панмиксии для *скрещивания*, обеспечивающая случайный выбор пар и поддержку генетического разнообразия, что предотвращает преждевременную сходимостью и способствует исследованию широкого пространства решений [24]. Исключение повторного выбора особи в паре усиливает этот эффект. Элитарный отбор гарантирует сохранение высоко приспособленных особей, обогащая популяцию ценными генетическими комбинациями и увеличивая шансы на оптимальные решения [25].

*Итеративный процесс* генетического алгоритма, включающий отбор, скрещивание, мутацию и оценку целевой функции, выполняется многократно, обеспечивая постепенное приближение к оптимальным параметрам управления светофорами. Этапы, отражающие динамику адаптации алгоритма к условиям дорожного движения и улучшение дорожного потока, систематизированы на *рисунке 6*. Данный подход способствует сокращению времени проезда и оптимизации трафика, подтверждая эффективность алгоритма в условиях переменных дорожных условий.

### 3. Результаты оптимизационных экспериментов

В ходе проведенных оптимизационных экспериментов с использованием разработанного генетического алгоритма были получены данные, демонстрирующие изменения ключевых параметров системы регулирования транспортного потока от первой до двадцатой итерации. Детальный анализ результатов позволяет оценить эффективность алгоритма в динамике эволюционного процесса. На *рис. 7–9* представлены итерации генетического алгоритма (динамика сходимости), пронумерованные в формате  $[m, n]$  где  $m$  – номер итерации, а  $n$  – номер популяции, от начальной  $[0, 1]$  до заключительной  $[19, 20]$ . Это указывает на то, что каждый отмеченный на оси абсцисс пункт соответствует новому циклу оптимизации параметров регулирования трафика с использованием новых длительностей фаз регулирующих сигналов светофоров, вычисленных на данной итерации.

*Результат первой итерации:* диапазон среднего времени проезда на начальном этапе эксперимента колебался от 1,627109 до 1,670166 минут, что

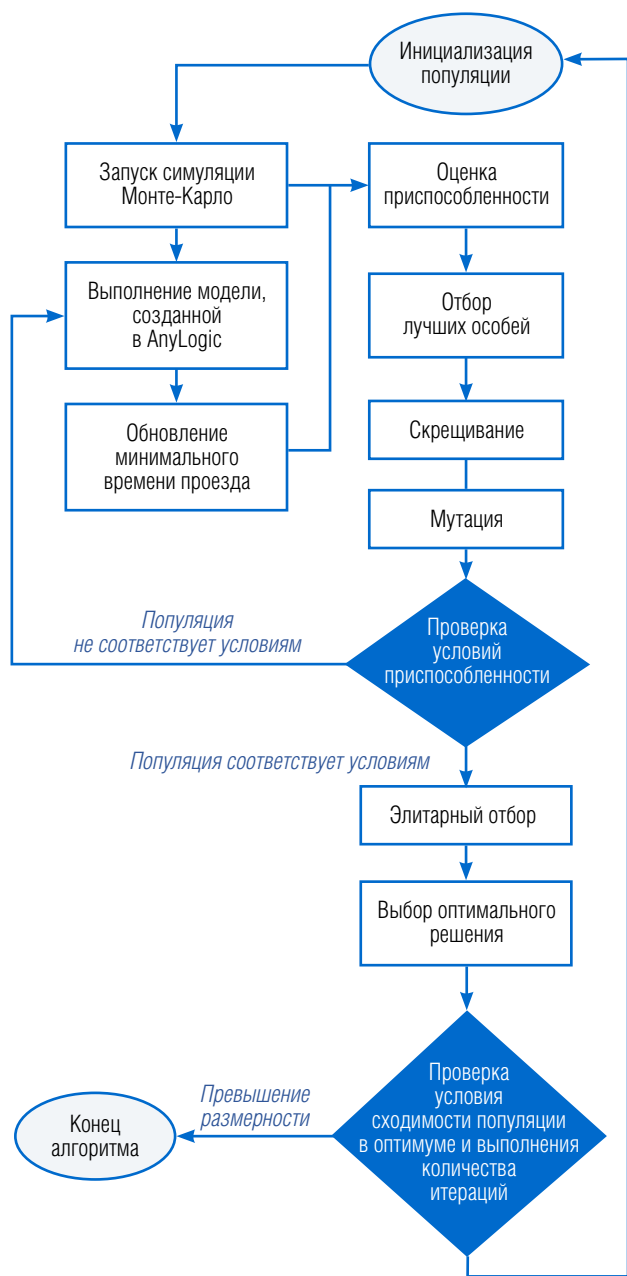


Рис. 6. Средние затраты на топливо при стоимости 60 рублей за литр и общие затраты на топливо для 100 000 транспортных средств, осуществивших проезд.

свидетельствует о начальном разбросе эффективности регуляторных стратегий. Объем затраченного топлива варьировался от 317,595 до 325,999 литров на 10 000 проехавших автомобилей, отражая начальную неоптимальность в расходе топливных ресурсов. Стоимость затраченного топлива находилась в диапазоне от 19 055,7 до 19 559,95615 рублей, указывая на значительные экономические затраты.

Результат последней (двадцатой) итерации: улучшение среднего времени проезда было зафиксировано с незначительным увеличением диапазона до 1,735787–1,746299 минут, что указывает на стабилизацию временных характеристик проезда при одновременном улучшении других параметров. Снижение объема затраченного топлива до 292,144860–293,914192 литров на 10 000 проехавших автомобилей демонстрирует повышение топливной эффективности в результате оптимизации регуляторных механизмов. Экономическая эффективность выразилась в снижении стоимости затраченного топлива до 17 528,69161–17 634,8515 рублей, подтверждая целесообразность использования предлагаемых оптимизационных алгоритмов.

Прямое сравнение результатов первой и двадцатой итерации выявляет положительную динамику в оптимизации транспортных потоков. Значительное снижение объема затраченного топлива и соответствующей стоимости при относительно стабильном среднем времени проезда свидетельствует о повышении топливной и экономической эффективности разработанной системы регулирования. Данные результаты подчеркивают потенциал применения предложенного генетического алгоритма для улучшения параметров интеллектуальных транспортных систем, направленных на минимизацию экологического воздействия и оптимизацию трафика в условиях городской инфраструктуры.

На рисунке 9 ордината слева соответствует средней продолжительности проезда в минутах. При этом, наблюдается уменьшение значения этого показателя на протяжении серии итераций, что свидетельствует об эффективности оптимизационного процесса (сходимости генетического алгоритма). При этом ордината справа отражает объем затраченного топлива для десяти тысяч автомобильных единиц, и это значение этого показателя также уменьшается с течением итераций генетического алгоритма. Следовательно, динамика обеих зависимостей на графике указывает на положительное изменение ключевых метрик: уменьшение временных затрат на проезд и соответствующего потребления топлива. На начальной стадии оптимизации фиксируется максимальное значение среднего времени проезда, в то время как на завершающем цикле максимум не превышает пороговые величины, достигнутые в процессе оптимизации. Последовательное уменьшение объема потребления топлива




Рис. 7. Среднее время проезда и объем потребленного топлива для агрегата из 10 000 транспортных средств, успешно преодолевших заданный маршрут.



Рис. 8. Средние затраты на топливо при стоимости 60 рублей за литр и общие затраты на топливо для 100 000 транспортных средств, осуществивших проезд.




Рис. 9. Среднее время проезда в итерациях генетической оптимизации транспортных потоков.

является результатом влияния двух определяющих факторов: минимизации времени проезда через рассматриваемый участок уличной дорожной сети и снижения топливной нагрузки.

На *рисунке 10* показано среднее время проезда на различных итерациях генетического алгоритма. Последовательное улучшение значения данного целевого показателя от первой до двадцатой итерации свидетельствует о сходимости генетического алгоритма и возможности минимизации времени проезда транспортных средств через оптимизацию длительности фаз регулирующих сигналов светофоров. Подобная динамика подтверждает повышение пропускной способности и эффективности городской дорожной сети, демонстрируя преимущества применения эволюционных методов в оптимизации урбанистических транспортных системах. Процесс снижения среднего времени проезда, наблюдаемый в течение серии итераций, отражает улучшение качества регулирования дорожного трафика за счет точной настройки рабочих циклов светофоров. Эффективность генетического алгоритма в этом контексте подкрепляется его способностью к поиску оптимальных решений в многопараметрическом пространстве управленческих решений, учитывая многообразие условий и динамику городского движения. Эволюционное улучшение системы управ-

ления светофорами основано на механизмах отбора, скрещивания и мутации, способствующих итеративному уточнению и оптимизации параметров на основе оценки их влияния на общую эффективность транспортной системы. Генетический алгоритм, демонстрируя устойчивую сходимость, позволяет обеспечить адаптивное управление светофорами для снижения временных затрат участников дорожного движения и повышения общей эффективности использования транспортной инфраструктуры.

Адаптивное управление светофорами с использованием предложенного генетического алгоритма способствует существенному сокращению времени проезда и объема топливных затрат, как это демонстрируют результаты оптимизационных экспериментов. Это проявляется в снижении среднего времени проезда (для ансамбля агентов – транспортных средств) с 1,86 минут до 1,62 минуты, т. е. на 14,8%, что также сопровождается заметным уменьшением расхода топлива на 33,6%, т.е. с 363,98 до 272,49 литров на каждые 10 000 автомобильных единиц. Это свидетельствует об эффективности алгоритма и его валидности для комплексной транспортной оптимизации в условиях мегаполиса.

Учитывая масштабируемость и мультипараметрическую адаптивность разработанного генетического алгоритма, целесообразна его интеграция с






Рис. 10. Среднее время проезда в итерациях генетической оптимизации транспортных потоков.

современными ИТС, что будет способствовать улучшению трафика в городе (устранению дорожных заторов, повышению уровня социального комфорта участников дорожного движения, экономии затрат на топливо и т. д.).

С другой стороны, в перспективе необходимо учитывать дополнительные характеристики ИТС, такие как интенсивность трафика и метеорологические условия, для повышения точности и адаптивности оптимизационного алгоритма. Такая интеграция может стать следующим шагом в разработке стратегий по улучшению экологической устойчивости и повышению качества жизни в городских условиях, включая привлечение инвестиций в городскую инфраструктуру и туризм.

Оптимизация длительности фаз регулирующих сигналов светофоров вносит вклад не только в экономию топлива, но и в снижение уровня выбросов вредных веществ, содействуя формированию экологически чистой и комфортной городской среды.

Это повышает привлекательность города, как для его жителей, так и для туристов, и способствует общей урбанизации пространства.

Таким образом, разработанная система обеспечивает новые возможности для создания и совершенствования продуктов в сфере ИТС, предлагая эффективные решения для муниципалитетов и частных операторов городской инфраструктуры. Дальнейшие исследования и разработки в данной области могут способствовать эволюционной трансформации транспортной инфраструктуры, обеспечивая ее максимальное соответствие увеличивающимся потребностям современного городского общества.

### Заключение

В заключение исследования следует подчеркнуть значимость разработанного подхода для оптимизации транспортных потоков в урбанистической среде

и его применимость в системах поддержки принятия решений для муниципальных и государственных предприятий, отвечающих за эволюционное развитие транспортной инфраструктуры. Реализация такого подхода применительно к реальному участку дорожной сети г. Москвы, основанного на использовании предложенного генетического оптимизационного алгоритма, позволила существенно повысить эффективность регулирования транспортных и пешеходов потоков, способствуя уменьшению времени ожидания транспортных средств на регулируемых перекрестках.

Применение разработанного генетического алгоритма, агрегированного с предложенной имитационной моделью ИТС, реализованной в AnyLogic, демонстрирует важность интеграции современных алгоритмических и модельных подходов в разработку и усовершенствование ИТС. Исследование подтвердило гипотезу о возможности значительного повышения эффективности управления дорожным движением за счет адаптивного регулирования дли-

тельностью фаз светофоров с учетом состояния текущего трафика. Важным результатом работы стало выявление перспективных направлений дальнейших исследований, включая анализ и оптимизацию транспортной инфраструктуры на макроуровне, разработку многофункциональных моделей управления трафиком, способных адаптироваться к изменениям в дорожной сети и потребностям различных участников дорожного движения.

Дальнейшие исследования будут направлены на изучение ИТС с более сложной (многоуровневой, многосвязной) конфигурацией уличных дорожных сетей в масштабе «умного» города и применение гибридных алгоритмов, использующих методы речевого интеллекта, генетической оптимизации и машинного обучения. ■

### Благодарности

Исследование выполнено за счет гранта Российского научного фонда (проект № 23-11-00080).

### Литература

1. Akopov A.S., Beklaryan L.A. Traffic improvement in Manhattan road networks with the use of parallel hybrid biobjective genetic algorithm // *IEEE Access*. 2024. Vol. 12. P. 19532–19552. <https://doi.org/10.1109/ACCESS.2024.3361399>
2. Akopov A.S., Beklaryan L.A., Thakur M. Improvement of maneuverability within a multiagent fuzzy transportation system with the use of parallel biobjective real-coded genetic algorithm // *IEEE Transactions on Intelligent Transportation Systems*. 2022. Vol. 23. No. 8. P. 12648–12664. <https://doi.org/10.1109/TITS.2021.3115827>
3. Akopov A.S., Beklaryan L.A., Beklaryan A.L. Simulation-based optimisation for autonomous transportation systems using a parallel real-coded genetic algorithm with scalable nonuniform mutation // *Cybernetics and Information Technologies*. 2021. Vol. 21. No. 3. P. 127–144. <https://doi.org/10.2478/cait-2021-0034>
4. Tong W., Pan Z., Liu K., Yali Y., Xiumin W., Huawei H., Wu D.O. Multi-agent deep reinforcement learning for urban traffic light control in vehicular networks // *IEEE Transactions on Vehicular Technology*. 2020. Vol. 69. No. 8. P. 8243–8256. <https://doi.org/10.1109/TVT.2020.2997896>
5. Aljuboori A.F., Hamza A., Alasady Y. Novel intelligent traffic light system using PSO and ANN // *Journal of Advanced Research in Dynamical and Control Systems*. 2019. Vol. 11. P. 1528–1539.
6. Rashid H., Ashrafi M.J.F., Azizi M., Heydarinezhad M.R. Intelligent traffic light control based on clustering using Vehicular Ad-hoc Networks // *Proceedings of the 2015 7th Conference on Information and Knowledge Technology (IKT), Urmia, Iran*. 2015. P. 1–6. <https://doi.org/10.1109/IKT.2015.7288801>
7. Мясников В.В., Агафонов А.А., Юмаганов А.С. Детерминированная прогнозная модель управления сигналами светофоров в интеллектуальных транспортных и геоинформационных системах // *Компьютерная оптика*. 2021. Т. 45. № 6. С. 917–925. <https://doi.org/10.18287/2412-6179-CO-1031>
8. Веремчук Н.С. Элементы имитационного моделирования в вопросах оптимизации дорожного движения // *Вестник кибернетики*. 2022. Т. 4. № 48. С. 23–28. <https://doi.org/10.34822/1999-7604-2022-4-23-28>
9. Kennedy J., Eberhart R. Particle Swarm Optimization // *Proceedings of IEEE International Conference on Neural Networks*. 1995. Vol. 4. P. 1942–1948. <https://doi.org/10.1109/ICNN.1995.488968>
10. Shi Y., Eberhart R.C. A modified particle swarm optimizer // *Proceedings of IEEE International Conference on Evolutionary Computation*. 1998. P. 69–73. <https://doi.org/10.1109/ICEC.1998.699146>
11. Herrera F., Lozano M., Gradual distributed real-coded genetic algorithms // *IEEE Transactions on Evolutionary Computation*. 2000. Vol. 4. No. 1. P. 43–63. <https://doi.org/10.1109/4235.843494>
12. Панченко Т.В. Генетические алгоритмы. Астрахань: АГУ, 2007.

13. Бекларян А.Л., Бекларян Л.А., Акопов А. С. Имитационная модель интеллектуальной транспортной системы «умного города» с адаптивным управлением светофорами на основе нечеткой кластеризации // Бизнес-информатика. 2023. Т. 17. № 3. С. 70–86. <https://doi.org/10.17323/2587-814X.2023.3.70.86>
14. Акопов А.С., Бекларян Л.А. Моделирование динамики дорожно-транспортных происшествий с участием беспилотных автомобилей в транспортной системе «умного города» // Бизнес-информатика. 2022. Т. 16. № 4. С. 19–35. <https://doi.org/10.17323/2587-814X.2022.4.19.35>
15. Зарипов Е. А., Петрунев Е.А. Разработка нейронной сети для моделирования поведения учебного процесса // Искусственные общества. 2023. Т. 18. № 1. <https://doi.org/10.18254/S207751800024453-7>
16. Мельников А. М. Агентная имитационная модель цикла сна и бодрствования // Искусственные общества. 2023. Т. 18. № 2. <https://doi.org/10.18254/S207751800024523-4>
17. Bakhit P.R., Said D., Radwan L. Impact of acceleration aggressiveness on fuel consumption using comprehensive power based fuel consumption model // Civil and Environmental Research. 2015. Vol. 7. P. 148–156.
18. Diaz-Gomez, P. A., Hougen, D. Initial population for genetic algorithms: A metric approach // Proceedings of the 2007 International Conference on Genetic and Evolutionary Methods, Las Vegas, Nevada, USA. 2007. P. 43–49.
19. Jebari K. Selection Methods for Genetic Algorithms // International Journal of Emerging Sciences. 2013. Vol. 3. P. 333–344.
20. Marsili-Libelli S., Alba P. Adaptive mutation in genetic algorithms // Soft Computing. 2000. Vol. 4. P. 76–80. <https://doi.org/10.1007/s005000000042>
21. De Falco I., Cioppa A.D., Tarantino E. Mutation-based genetic algorithm: Performance evaluation // Applied Soft Computing. 2002. Vol. 1. P. 285–299. [https://doi.org/10.1016/S1568-4946\(02\)00021-2](https://doi.org/10.1016/S1568-4946(02)00021-2)
22. Deb K., Deb D. Analysing mutation schemes for real-parameter genetic algorithms // International Journal of Artificial Intelligence and Soft Computing. 2014. Vol. 4. P. 1–28. <https://doi.org/10.1504/IJAISC.2014.059280>
23. Eremeev A. Modeling and analysis of genetic algorithm with tournament selection // Lecture Notes in Computer Science. 2000. Vol. 1829. P. 84–95 [https://doi.org/10.1007/10721187\\_6](https://doi.org/10.1007/10721187_6)
24. Umbarkar A.J., Sheth P.D. Crossover operators in genetic algorithms: a review // Journal on Soft Computing. 2015. Vol. 6. No. 1. P. 1083–1092. <https://doi.org/10.21917/ijsc.2015.0150>
25. Mashohor S., Evans J. R., Arslan T. Elitist selection schemes for genetic algorithm based printed circuit board inspection system // Proceedings of the 2005 IEEE Congress on Evolutionary Computation, Edinburgh, UK. 2005. Vol. 2. P. 974–978. <https://doi.org/10.1109/CEC.2005.1554796>

## Об авторах

### Акопов Андраник Сумбатович

д.т.н., проф.; проф. РАН;

главный научный сотрудник, лаборатория динамических моделей экономики и оптимизации, Центральный экономико-математический институт, Российская академия наук, Россия, 117418, г. Москва, Нахимовский проспект, д. 47;

E-mail: akopovas@umail.ru

ORCID: 0000-0003-0627-3037

### Зарипов Евгений Андреевич

младший научный сотрудник, лаборатория динамических моделей экономики и оптимизации, Центральный экономико-математический институт, Российская академия наук, Россия, 117418, г. Москва, Нахимовский проспект, д. 47;

аспирант, ассистент кафедры инструментального и прикладного программного обеспечения, МИРЭА – Российский технологический университет, Россия, 119454, г. Москва, проспект Вернадского, д. 78;

E-mail: e.a.zaripov@ya.ru

ORCID: 0000-0003-1472-650X

### Мельников Алексей Михайлович

младший научный сотрудник, лаборатория динамических моделей экономики и оптимизации, Центральный экономико-математический институт, Российская академия наук, Россия, 117418, г. Москва, Нахимовский проспект, д. 47;

аспирант, МИРЭА – Российский технологический университет, Россия, 119454, г. Москва, проспект Вернадского, д. 78;

E-mail: alexdef2@mail.ru

ORCID: 0009-0008-0335-9197

# Adaptive control of transportation infrastructure in an urban environment using a real-coded genetic algorithm

**Andranik S. Akopov**<sup>a</sup>

E-mail: akopovas@umail.ru

**Evgeny A. Zaripov**<sup>a,b</sup>

E-mail: e.a.zaripov@ya.ru

**Alexey M. Melnikov**<sup>a,b</sup>

E-mail: alexdef2@mail.ru

<sup>a</sup> Central Economic and Mathematical Institute, Russian Academy of Sciences, Moscow, Russia

<sup>b</sup> MIREA – Russian Technological University, Moscow, Russia

## Abstract

The management of urban areas requires the development of an effective strategy for the evolution of transportation infrastructure to ensure the smooth flow of traffic and pedestrians. A crucial component of this infrastructure is the traffic light system, which plays a vital role in traffic control and traffic safety. Improving the efficiency of traffic control systems in intelligent transportation systems (ITS) has a significant impact on a city's economy. As a result, the cost of fuel for road users can be reduced, and their level of social comfort can be improved, among other benefits. This paper proposes a novel approach to optimizing traffic flows in smart cities, based on the combined use of the genetic optimization algorithm and the ITS simulation model we developed. The proposed method aims to enhance the efficiency of existing traffic control systems and achieve optimal traffic flow patterns, thereby contributing to a more sustainable and efficient urban environment. The optimization algorithm shown here aggregates the objective functions using a simulation model of a real region of the Moscow road network. The model includes intersections, pedestrian crossings and other features that are implemented in the AnyLogic system. The research aims to create a decision-support system for managing urban transport infrastructure. This system will be used to optimize the duration of traffic light phases in order to minimize the time vehicles spend passing through key nodes in the urban road network. It will also optimize pedestrian flow, reducing the impact of traffic on the environment and improving fuel efficiency. By applying this approach, the capacity of the street network can be significantly increased. Additionally, the negative effects of traffic flow on the environment can be reduced by optimizing fuel use and reducing waiting times at intersections managed by traffic lights. The research methodology involves the development of a hybrid evolutionary search algorithm, the creation of a simulation model for transportation and pedestrian flows in the AnyLogic and a series of optimization experiments that demonstrate the effectiveness of the proposed approach when applied to the modeling of complex urban transportation systems.

**Keywords:** urban planning and development, municipal management, intelligent transportation systems, smart city, real-coded genetic algorithms, traffic flow simulation, traffic control, AnyLogic

**Citation:** Akopov A.S., Zaripov E.A., Melnikov A.M. (2024) Adaptive control of transportation infrastructure in an urban environment using a real-coded genetic algorithm. *Business Informatics*, vol. 18, no. 2, pp. 48–66. DOI: 10.17323/2587-814X.2024.2.48.66

## References

1. Akopov A.S., Beklaryan L.A. (2024) Traffic improvement in Manhattan road networks with the use of parallel hybrid biobjective genetic algorithm. *IEEE Access*, vol. 12, pp. 19532–19552. <https://doi.org/10.1109/ACCESS.2024.3361399>
2. Akopov A.S., Beklaryan L.A., Thakur M. (2022) Improvement of maneuverability within a multiagent fuzzy transportation system with the use of parallel biobjective real-coded genetic algorithm. *IEEE Transactions on Intelligent Transportation Systems*, vol. 23, no. 8, pp. 12648–12664. <https://doi.org/10.1109/TITS.2021.3115827>
3. Akopov A.S., Beklaryan L.A., Beklaryan A.L. (2021) Simulation-based optimization for autonomous transportation systems using a parallel real-coded genetic algorithm with scalable nonuniform mutation. *Cybernetics and Information Technologies*, vol. 21, no. 3, pp.127–144. <https://doi.org/10.2478/cait-2021-0034>
4. Tong W., Pan Z., Liu K., Yali Y., Xiumin W., Huawei H., Wu D.O. (2020) Multi-agent deep reinforcement learning for urban traffic light control in vehicular networks. *IEEE Transactions on Vehicular Technology*, vol. 69, no. 8, pp. 8243–8256. <https://doi.org/10.1109/TVT.2020.2997896>
5. Aljuboori A.F., Hamza A., Alasady Y. (2019) Novel intelligent traffic light system using PSO and ANN. *Journal of Advanced Research in Dynamical and Control Systems*, vol. 11, pp. 1528–1539.
6. Rashid H., Ashrafi M.J.F., Azizi M., Heydarinezhad M.R. (2015) Intelligent traffic light control based on clustering using Vehicular Ad-hoc Networks. Proceedings of the 2015 7th Conference on Information and Knowledge Technology (IKT), Urmia, Iran, pp. 1–6. <https://doi.org/10.1109/IKT.2015.7288801>
7. Myasnikov V.V., Agafonov A.A., Yumaganov A.S. (2021) A deterministic predictive traffic signal control model in intelligent transportation and geoinformation systems. *Computer Optics*, vol. 45, no. 6, pp. 917–925 (in Russian). <https://doi.org/10.18287/2412-6179-CO-1031>
8. Veremchuk N.S. (2022) Elements of simulation modeling in issues of traffic optimization. *Proceedings in Cybernetics*, vol. 4, no. 48, pp. 23–28 (in Russian). <https://doi.org/10.34822/1999-7604-2022-4-23-28>
9. Kennedy J., Eberhart R. (1995) Particle swarm optimization. Proceedings of *IEEE International Conference on Neural Networks*, vol. 4, pp. 1942–1948. <https://doi.org/10.1109/ICNN.1995.488968>
10. Shi Y., Eberhart R.C. (1998) A modified particle swarm optimizer. Proceedings of *IEEE International Conference on Evolutionary Computation*, pp. 69–73. <https://doi.org/10.1109/ICEC.1998.699146>
11. Herrera F., Lozano M. (2000) Gradual distributed real-coded genetic algorithms. *IEEE Transactions on Evolutionary Computation*, vol. 4, no. 1, pp. 43–63. <https://doi.org/10.1109/4235.843494>
12. Panchenko T.V. *Genetic algorithms*. Astrakhan: Astrakhan Tatishchev State University, 2007 (in Russian).
13. Beklaryan A.L., Beklaryan L.A., Akopov A.S. (2023) Simulation model of an intelligent transport system of a “smart city” with adaptive control of traffic lights based on fuzzy clustering. *Business Informatics*, vol. 17, no. 3, pp. 70–86. <https://doi.org/10.17323/2587-814X.2023.3.70.86>
14. Akopov A.S., Beklaryan L.A. (2022) Simulation of rates of traffic accidents involving unmanned ground vehicles within a transportation system for the “smart city”. *Business Informatics*, vol. 16, no. 4, pp. 19–35. <https://doi.org/10.17323/2587-814X.2022.4.19.35>
15. Zariipov E., Petrunev E. (2023) Development of a neural network for modeling the behavior of the educational process. *Artificial Societies*, vol. 18, no. 1 (in Russian). <https://doi.org/10.18254/S207751800024453-7>
16. Melnikov A. (2023) Agent-based modeling of the sleep-wake cycle. *Artificial Societies*, vol. 18, no. 2 (in Russian). <https://doi.org/10.18254/S207751800024523-4>
17. Bakhit P.R., Said D., Radwan L. (2015) Impact of acceleration aggressiveness on fuel consumption using comprehensive power-based fuel consumption model. *Civil and Environmental Research*, vol. 7, pp. 148–156.
18. Diaz-Gomez P.A., Hougen D. (2007) Initial population for genetic algorithms: A metric approach. Proceedings of the 2007 International Conference on Genetic and Evolutionary Methods, Las Vegas, Nevada, USA, pp. 43–49.
19. Jebari K. (2013) Selection methods for genetic algorithms. *International Journal of Emerging Sciences*, vol. 3, pp. 333–344.
20. Marsili-Libelli S., Alba P. (2000) Adaptive mutation in genetic algorithms. *Soft Computing*, vol. 4, pp. 76–80. <https://doi.org/10.1007/s005000000042>
21. De Falco I., Cioppa A.D., Tarantino E. (2002) Mutation-based genetic algorithm: Performance evaluation. *Applied Soft Computing*, vol. 1, pp. 285–299. [https://doi.org/10.1016/S1568-4946\(02\)00021-2](https://doi.org/10.1016/S1568-4946(02)00021-2)
22. Deb K., Deb D. (2014) Analyzing mutation schemes for real-parameter genetic algorithms. *International Journal of Artificial Intelligence and Soft Computing*, vol. 4, pp. 1–28. <https://doi.org/10.1504/IJAISC.2014.059280>
23. Eremeev A. (2000) Modeling and analysis of genetic algorithm with tournament selection. *Lecture Notes in Computer Science*, vol. 1829, pp. 84–95 [https://doi.org/10.1007/10721187\\_6](https://doi.org/10.1007/10721187_6)



24. Umbarkar A.J., Sheth P.D. (2015) Crossover operators in genetic algorithms: A review. *Journal on Soft Computing*, vol. 6, no. 1, pp. 1083–1092. <https://doi.org/10.21917/ijsc.2015.0150>
25. Mashohor S., Evans J.R., Arslan T. (2005) Elitist selection schemes for genetic algorithm based printed circuit board inspection system. *Proceedings of the 2005 IEEE Congress on Evolutionary Computation, Edinburgh, UK*, vol. 2, pp. 974–978. <https://doi.org/10.1109/CEC.2005.1554796>

### About the authors

#### **Andranik S. Akopov**

Dr. Sci. (Tech.), Professor; Professor of the Russian Academy of Sciences;

Chief Researcher, Laboratory of Dynamic Models of Economy and Optimization, Central Economics and Mathematics Institute, Russian Academy of Sciences, 47, Nachimovky Ave., Moscow 117418, Russia;

E-mail: akopovas@umail.ru

ORCID: 0000-0003-0627-3037

#### **Evgeny A. Zaripov**

Junior Researcher, Laboratory of Dynamic Models of Economy and Optimization, Central Economics and Mathematics Institute, Russian Academy of Sciences, 47, Nachimovky Ave., Moscow 117418, Russia;

Postgraduate student, Assistant at the Department of Instrumental and Applied Software, MIREA – Russian University of Technology, 78, Vernadsky Ave., Moscow 119454, Russia;

E-mail: e.a.zaripov@ya.ru

ORCID: 0000-0003-1472-650 X

#### **Alexey M. Melnikov**

Junior Researcher, Laboratory of Dynamic Models of Economics and Optimization, Central Economic and Mathematical Institute, Russian Academy of Sciences, 47, Nakhimovsky Ave., Moscow 117418, Russia;

Postgraduate student, MIREA – Russian University of Technology, 78, Vernadsky Ave., Moscow 119454, Russia;

E-mail: alexdef2@mail.ru

ORCID: 0009-0008-0335-9197