

УДК 004.04

С.А. Эль-Хатиб, А.И. Эль-Хатиб, Ю.А. Скобцов
**СЕГМЕНТАЦИИ ИЗОБРАЖЕНИЙ МЕТОДОМ МУРАВЬИНЫХ
КОЛОНИЙ**

Общая постановка проблемы. Задача сегментации изображений, обработка которых требуется во многих отраслях, является базовой и имеет чрезвычайно важное значение. Результат обработки изображения во многом зависит от степени точности алгоритма сегментации. Алгоритмы сегментации разделяют изображение на отдельные области, число которых зависит от характера задачи [5]. Основная сложность при решении данной задачи – учет различных дополнительных факторов на изображениях: разнообразие фона, вариабельность различных частей изображения, зашумленность. Учитывая данные факторы, в процессе сегментации часто применяют различные подходы, которые зависят от предметной области изображений. Методы сегментации можно разделить на два класса:

- автоматические – не требующие взаимодействия с пользователем;
- интерактивные – использующие пользовательский ввод непосредственно в процессе работы.

Между этими двумя подходами есть принципиальная разница. В первом случае задача сегментации состоит в поиске определенных областей, о которых имеется априорная информация (например, известны цвет, форма областей, принадлежность известным объектам и т.п.). Методы этой группы узко специализированы для каждой конкретной задачи. Сегментация в такой постановке используется, в основном, в задачах машинного зрения (анализ сцен, поиск объектов на изображении и т.п.).

Во втором случае априорная информация о свойствах областей не используется, но на само разбиение изображения обычно накладываются некоторые ограничения (например, все области должны быть однородны по цвету и текстуре). Так как при такой постановке задачи сегментации не используется априорная информация об изображенных объектах, то методы этой группы универсальны и применимы к любым изображениям. В основном, сегментация в этой постановке применяется на начальном этапе решения задачи, для того чтобы получить представление изображения в более удобном виде для дальнейшей обработки.

В последнее время для сегментации все чаще применяются методы искусственного интеллекта. В частности, интересные результаты показали генетические алгоритмы. Одной из причин использования такого подхода является способность генетического алгоритма работать с большим, сложным пространством поиска при минимальной информации о целевой функции. Например, у большинства существующих алгоритмов сегментации цветных изображений есть много параметров, которые необходимо настраивать на конкретный класс изображений. Соответствующее пространство поиска имеет высокую размерность и имеют место сложные взаимодействия между параметрами [6].

Искусственные нейронные сети также применяются при сегментации изображений и в случае оптимальных настроек параметров можно получить неплохие результаты [10]. Наиболее распространенным при решении данной задачи является метод наращивания областей [7].

При сегментации достаточно часто используется алгоритм *k*-средних, который основан на минимизации квадратичной ошибки. Данный алгоритм может неплохо выполнять кластеризацию точек (пикселей) на изображении, но он не может исключить лишнюю информацию, как например шум. Алгоритм *k*-средних выполняет построение *k* различных кластеров [7]. Выбор числа кластеров *k* как правило, базируется на результатах предыдущих исследований либо на основании человеческой оценки. Общая идея алгоритма состоит в том, что для заданного *k* числа кластеров, найти такое множество кластеров, чтобы средние значения в кластерах максимально возможно отличались друг от друга. Поскольку мы этот алгоритм также будем использовать, приведем его краткое описание:

1. Первичное сопоставление объектов кластерам;
2. Выбор центров кластеров (случайным образом или заранее известным способом);
3. Итеративный процесс, который включает в себя новое вычисление кластерных центров, пересчет средних значений координат кластера и перераспределение объектов по кластерам.
4. Условия завершения:
 - стабилизация кластерных центров (между итерациями ни один центр не поменял своего значения);
 - достижение максимального числа итераций алгоритма.

Далее изложена модификация данного алгоритма применительно к сегментации изображений в сочетании с методом муравьиных колоний (Ant Colony Optimization) [9].

Общее описание муравьиных алгоритмов. В последнее десятилетие при решении задач оптимизации все шире используются новые методы, которые фактически примыкают к эволюционным

вычислениям по своей идеологии и основаны на моделировании социального поведения живых организмов. К ним относятся, прежде всего, роевые алгоритмы (PSO -particle swarm optimization [1]), которые, в основном, используются в численной оптимизации; и муравьиные алгоритмы (ACO – ant colony optimization [2]), которые применяются в данной работе и основаны на моделировании поведения муравьиных колоний.

Большинство муравьев являются социальными насекомыми, которые живут колониями от 30 до миллиона особей. При относительно простом поведении каждой отдельной особи муравьиные колонии представляют сложную социальную структуру и способны решать сложные задачи, например, находить оптимальные пути от гнезда до источника пищи. Это привлекло внимание многих исследователей, которые изучали механизмы взаимодействия особей колонии. Среди них, прежде всего, обращает внимание непрямая форма связи между особями, которая была названа «stigmergy» и представляет собой разнесенное во времени взаимодействие, при котором одна особь изменяет некоторую область окружающей среды, а другие особи используют эту информацию в процессе решения задачи. Эта информация (изменение окружающей среды) носит локальный характер – она может быть изменена (и воспринята) только насекомыми, посетившими данный локус – участок среды. «Stigmergy» является не прямой и асинхронной формой коммуникации в которой насекомые изменяют окружающую среду для для передачи информации другим насекомым, которые реагируют на это изменение.

Конкретно, во многих муравьиных колониях «stigmergy» реализуется с помощью специального фермента «феромона», который откладывается муравьем в процессе движения. При этом муравей пометает феромоном посещенный участок среды. Остальные муравьи воспринимают «запах» отложенного феромона и стараются следовать по отмеченному пути. Это порождает асинхронную и не прямую схему коммуникации, где муравьи передают информацию друг другу с помощью феромона. При этом возникает положительная обратная связь – даже малое количество феромона заставляет муравьев идти по помеченному пути и откладывать на нем все большее количество фермента. Адаптивность поведения муравьев основана на восприятии испарений феромона, которое в природе продолжается несколько суток. Можно провести аналогию между распределением феромона в окружающей колонию пространстве и глобальной памятью муравейника, которая носит динамический характер!

В целом, основу поведения муравьиной колонии составляет самоорганизация, обеспечивающая достижения общих целей колонии на основе низкоуровневого взаимодействия. Колония не имеет централизованного управления, и её особенностями являются обмен локальной информацией только между отдельными особями (прямой обмен – пища, визуальные и химические контакты) и наличие непрямого обмена, который и используется в муравьиных алгоритмах.

Муравьиные алгоритмы (МА), как и большинство эволюционных методов основаны на использовании популяции потенциальных решений и обмена информацией между особями популяции. Здесь кооперация между особями (искусственными муравьями) реализуется на основе моделирования явления «stigmergy». При этом каждый агент, называемый искусственным муравьем, ищет решение поставленной задачи, например, поиска кратчайшего пути между двумя узлами графа (к которой можно свести многие реальные задачи). Искусственные муравьи последовательно строят решение задачи, передвигаясь по графу, откладывают феромон и при выборе дальнейшего участка пути учитывают концентрацию этого фермента. Чем больше концентрация феромона в последующем участке, тем больше вероятность его выбора.

Таким образом, искусственный муравей абстрактно может рассматриваться как простой вычислительный агент, который алгоритмически моделирует простое поведение реального муравья (точнее его интересующие нас аспекты).

Выбор следующей дуги графа (вариант решения) выполняется в каждой точке, где муравью необходимо принять решение. В каждой итерации ПМА каждый муравей пошагово строит путь до конечной вершины. При этом в каждой вершине каждый муравей должен выбрать следующую дугу пути. Если муравей k находится в вершине i , он выбирает следующую вершину $j \in N_i^k$ на основе вероятностей перехода

$$p_{ij}^k(t) = \begin{cases} \frac{\tau_{ij}^\alpha(t)}{\sum_{j \in N_i^k} \tau_{ij}^\alpha(t)}, & \text{если } j \in N_i^k \\ 0, & \text{если } j \notin N_i^k \end{cases} \quad (1)$$

Где N_i^k представляет множество возможных вершин, связанных с вершиной i , для муравья k . Если для любого узла i и муравья k $N_i^k \equiv \emptyset$, тогда предшественник узла i включается в N_i^k . Здесь α – положительная константа, которая определяет влияние концентрации феромона. Когда все муравьи построили полный путь от начальной до конечной вершины, удаляются петли в путях, и каждый муравей

помечает свой построенный путь, откладывая для каждой дуги феромон в соответствии со следующей формулой

$$\Delta \tau_{ij}^k(t) \propto \frac{1}{L^k(t)} \quad (2)$$

Здесь $L^k(t)$ – длина пути, построенного k -м муравьем в момент времени t .

Таким образом, для каждой дуги графа концентрация феромона определяется следующим образом

$$\tau_{ij}(t+1) = \tau_{ij}(t) + \sum_{k=1}^{n_k} \Delta \tau_{ij}^k(t) \quad (3)$$

где n_k – число муравьев.

Из (3) следует, что общая концентрация феромона для данной дуги пропорциональна «качеству» путей, в которые входит эта дуга, поскольку откладываемое количество феромона согласно (3) отражает «качество» соответствующего пути. В данном случае «качество» обратно пропорционально длине пути (числу дуг, вошедших в путь). Но в общем случае может быть использована и другая мера качества (например, стоимость проезда по данному пути или геометрическое расстояние и т.п.). Пусть $x^k(t)$ обозначает решение в момент t , и некоторая функция $f(x^k(t))$ выражает качество решения. Если $\Delta \tau^k$ не пропорционально качеству решения и все муравьи откладывают одинаковое количество феромона ($\Delta \tau_{ij}^1 = \Delta \tau_{ij}^2 = \dots = \Delta \tau_{ij}^{n_k}$), то существует только один фактор, который зависит от длины пути и способствует выбору коротких путей. Это ведет к двум основным способам оценки качества решений, которые используются в МА: 1) неявная оценка, где муравьи используют отличие в длине путей относительно построенных путей другими муравьями; 2) явная оценка, количество феромона пропорционально некоторой мере качества построенного решения. Таким образом, основными элементами МА являются: 1) формула расчета значения вероятности перехода (например, в соответствии с (1)); 2) формула коррекции концентрации феромона для дуги графа (варианта решения) в зависимости от полученного качества решения, например (2, 3). Следуют отметить, что кроме приведенных формул (1-3) используются и другие и существует большое количество вариаций алгоритма, которые более конкретизируются под определенные задачи. Разработано более десятка различных модификаций МА, в которых используются, прежде всего, различные методы вычисления значений вероятностей перехода и коррекции феромона в зависимости от качества построенного решения, например [7]:

- Элитарная муравьиная система;
- MMAS (Max-Min муравьиная система);
- Пропорциональные псевдослучайные правила;
- Ранговая муравьиная система;
- Длительная ортогональная колония муравьев.

Алгоритм сегментации изображений на основе метода муравьиных колоний. Для получения эффективного алгоритма сегментации изображений предложен метод, в котором используется преимущества муравьиного алгоритма и метода k -средних. На первом этапе необходимо установить значение количества кластеров и случайным образом инициализировать их центры. Далее, согласно алгоритму кластеризации k -средних, определяется принадлежность каждого пикселя изображения определенному кластеру. На этом этапе решающую роль играет алгоритм муравьиных колоний. Он определяет связь каждого пикселя с кластерами изображения. Это выполняется согласно значению вероятности, которое обратно пропорционально расстоянию между пикселем, центром кластера и переменной τ , которая представляет уровень феромона. Уровень феромона определяется пропорционально минимальному расстоянию между каждой парой центров кластеров и обратно пропорционально расстоянию между каждым пикселем и его центром. Таким образом, значение уровня феромона растет с увеличением дистанции между центрами кластеров, а также с увеличением компактности пикселей в кластере. При этих же условиях возрастает и вероятность присоединения пикселя к кластеру.

Испарение феромона рассчитывается для того, чтобы ослабить воздействие предыдущих выбранных решений, которые являются менее приоритетными. Аналогично алгоритму k -средних, в распределенном состоянии происходит обновление кластерных центров, путем пересчета среднего значения пикселей в каждом кластере. Это продолжается до тех пор, пока изменение значения кластерного центра существенно не меняется. В отличие от алгоритма k -средних, разработанный метод не останавливается на этом этапе. Процесс кластеризации продолжают выполнять m муравьев, каждый из которых в конечном итоге находит потенциальное решение. Критерий поиска лучшего решения и коррекция уровня феромона соответственно для следующей группы m муравьев являются определяющими для метода. При выполнении критерия остановка кластеризация завершается. Таким образом, находится лучшее решение[3].

В программной реализации алгоритм начинается с определения уровня феромона τ и задания эвристической информации η для каждого пикселя. Затем, каждый муравей определяет принадлежность пикселя кластера с вероятностью P , которая рассчитывается из выражения (4)

$$P_i(X_n) = \frac{[\tau_i(X_n)]^\alpha [\eta_i(X_n)]^\beta}{\sum_{j=0}^K [\tau_j(X_n)]^\alpha [\eta_j(X_n)]^\beta}, \quad (4)$$

где: $P_i(X_n)$ - вероятность принадлежности пикселя (X_n) кластеру i ; $\tau_i(X_n)$ и $\eta_i(X_n)$ - информация о феромоне и эвристическая переменная принадлежности пикселя X_n кластеру i соответственно; α и β - константные параметры, которые определяют относительное влияние феромона и эвристической информации; K – количество кластеров.

Эвристическая информация $\eta_i(X_n)$ вычисляется согласно выражению (5):

$$\eta_i(X_n) = \frac{k}{CDist(X_n, CC_i) * PDist(X_n, PC_i)}, \quad (5)$$

где: X_n – пиксель номер n ; CC_i – i -тый спектральный кластерный центр; PC_i – i -тый пространственный центр кластера; $CDist(X_n, CC_i)$ – расстояние между (X_n, CC_i) согласно цветовым характеристикам пикселей; $PDist(X_n, PC_i)$ – эвклидово расстояние между (X_n, PC_i), согласно расположения пикселя на изображении; k – константа, которая используется для балансировки значения η с τ .

При этом значение уровня феромона на начальном этапе устанавливается равным 1, поэтому на первой итерации он не оказывает влияние на вероятность перехода.

Предположим, что определено m –муравьев для кластеризации изображения. Каждый муравей находит свое индивидуальное решение задачи. После того, как m муравьев сегментировали изображение, выбирается лучшее решение для текущей итерации, для него корректируется уровень феромона и происходит обновление всех центров кластеров согласно выбранному лучшему решению. На следующей итерации инициализация муравьев происходит согласно предыдущему опыту. На каждой итерации каждый из m муравьев находит индивидуальное решение, которое корректируется согласно собственным эвристическим знаниям и общим лучшим решением, найденным всеми муравьями. Это повторяется, пока будет найдено решение, удовлетворяющее всем заданным условиям.

Общее решение из m индивидуальных решений выбирается по 2 параметрам:

1. Эвклидово расстояние между кластерными центрами, исходя из цветовых характеристик. Оно характеризует разбиение с точки зрения обособленности кластеров.
2. Суммы эвклидовых расстояний между центром кластера и каждым его пикселем согласно цветовым и пространственным характеристикам. Они определяют характеристики разбиения согласно критерия подобия и компактности кластеров.

Чтобы выбрать глобальное лучшее решение из всех построенных локальных необходимо, чтобы выполнялись следующие условия:

1. Эвклидово расстояние между кластерами, с точки зрения цветовых характеристик, должно быть велико, соответственно кластеры будут отличными друг от друга.
2. Сумма эвклидовых расстояний между центром кластера и каждым его пикселем, согласно цветовым характеристикам, должна быть маленькой, соответственно кластер будет более однородным.
3. Сумма эвклидовых расстояний между центром кластера и каждым его пикселем, согласно пространственным характеристикам, должна быть маленькой, соответственно кластеры будут более компактными.

Для того чтобы выполнить первое условие, мы для каждого муравья рассчитывается расстояние между каждой парой центров кластеров и сортируются эти значения по возрастанию. Затем выбирается минимальное среди всех муравьев и на основе сравнения, выбирается максимальный $[MinMax(k)]$.

При выполнении пунктов 2 и 3 необходимо:

1. Подсчитать суммы расстояний между кластерными центрами и их пикселями.
2. Отсортировать эти значения по возрастанию.
3. Выбрать максимальное и минимальное значение для каждого муравья.

Каждый раз выбранное значение получает дополнительный приоритет, а самое приоритетное является лучшим. После того как выбрано лучшее решение обновляется значение уровня феромона согласно выражению (6)

$$\tau_i(X_n) \leftarrow (1 - \rho)\tau_i(X_n) + \sum_i \Delta\tau_i(X_n) \quad (6)$$

где ρ – коэффициент испарения ($0 \leq \rho \leq 1$), который воздействует на ранее установленный уровень феромона. Благодаря этому коэффициенту усиливается влияние более поздних приоритетных решений и ослабляется более ранних. Параметр $\Delta\tau_i(X_n)$ в выражении (3) – разница уровня феромона, которая добавляется к предыдущей успешным муравьем. Она вычисляется согласно выражения:

$$\Delta\tau_i(X_n) = \begin{cases} \frac{Q * \text{Min}(k')}{\text{AvgCDist}(k',i) * \text{AvgPDist}(k',i)}, & \text{если } X_n \subset : \text{кластеру } i \\ 0, & \text{в другом случае} \end{cases} \quad (7)$$

где Q – положительная константа, которая связана с количеством добавленного муравьями феромона, $\text{Min}(k')$ – минимальное из цветовых дистанций между каждыми двумя центрами кластеров, найденное муравьем k' (самым успешным муравьем). $\text{AvgCDist}(k',i)$ – среднее значение цветовых расстояний и $\text{AvgPDist}(k',i)$ – среднее значение пространственных евклидовых расстояний между каждым пикселем и центрами (цветовым и пространственным) для самого успешного муравья.

$\text{Min}(k')$ – причина увеличения феромона при большей отдаленности кластеров. $\text{AvgCDist}(k',i)$ и $\text{AvgPDist}(k',i)$ – причины увеличения уровня феромона при большей однородности и компактности кластера.

Смешанный алгоритм муравьиных колоний и k -средних далее представлен пошагово:

1. Инициализируем основные параметры алгоритма: значение уровня феромона на первом этапе полагаем равным 1, количество кластеров K , количество муравьев m .
2. Инициализируем m муравьев для K случайно выбранных центров кластеров.
3. Пусть каждый муравей связывает каждый пиксель X_n с одним из кластеров i случайным образом, с вероятностью $P_i(X_n)$ согласно (4).
4. Вычисляем новые центры кластеров. Если новые центры совпадают с предыдущими, то переходим к следующему шагу, если нет, переходим к пункту 3.
5. Сохраняем лучшее решение из всех найденных m муравьями.
6. Обновляем уровень феромона для каждого пикселя согласно 3 и 4
7. Корректируем общее лучшее решение исходя из найденных индивидуальных решений каждого муравья.
8. Если выполняется критерий останова, то переходим к следующему шагу. В обратном случае – переходим к пункту 3.
9. Поиск общего лучшего решения.

Полученные результаты. Для оценки качества работы разработанного алгоритма произведено тестирование на трех группах по 10 изображений в каждой:

Группа 1 – простые изображения (например изображения на которых расположены статичные объекты без фона), среднее число градаций серого не превышает 10-20.

Группа 2 – изображения средней сложности, на которых присутствует до 50 разных градаций серого. Объекты менее отделены от фона, чем в предыдущей группе. Исходные изображения и результаты обработки приведены в приложении

Группа 3 – сложные изображения, на которых представлено до 200 градаций серого. Объекты отделены от фона значительно в меньшей степени, чем в предыдущих двух группах. Исходные изображения и результаты обработки приведены в приложении

Выходными параметрами системы помимо сегментированного изображения также являются:

- время выполнения алгоритма;
- количество итераций, пройденных алгоритмом.

Далее представлены графики зависимостей всех вышеперечисленных выходных параметров от заданного пользователем количества муравьев для трех групп изображений.




Рис. 5. Зависимость времени выполнения алгоритма от количества муравьев для изображений группы 1




Рис. 6. Зависимость времени выполнения алгоритма от количества муравьев для изображений группы 2



Рис. 7 - Зависимость времени выполнения алгоритма от количества муравьев для изображений группы 3




Рис.8 – Результаты работы алгоритма для изображений группы 2




Рис.9 – Результаты работы алгоритма для изображений группы 2




Рис.10 – Результаты работы алгоритма для изображений группы 3

Для получения сравнительной характеристики нашего алгоритма и генетического, были проведены экспериментальные исследования. Для сравнения результатов была взята модификация ГА [4], несколько схожая с рассмотренной в статье [6].

Изображения имеют следующие параметры (256x256), полутоновые. Для алгоритмов использованы следующие параметры:

ГА:

- размер популяции – 50;
- максимальное количество итераций – 70;
- вероятность кроссинговера – 0.7;
- вероятность мутации – 0.01.

МА:

- размер популяции – 10;
- максимальное количество итераций – 30;
- скорость испарения феромона – 0.4;
- $\alpha = 0.1$;
- $\beta = 0.4$.




Рис. 11 – Сравнительный анализ результатов сегментации изображений разными методами
 (а) – Исходное изображение; (б) – сегментированное изображение с помощью [4];
 (в) – сегментированное изображение разработанным алгоритмом

Таблица 1

Сравнение параметров алгоритмов сегментации

Параметр/Алгоритм	ГА	МА
Время сегментации, с	14.391	5.821
Сходимость, итерация	30	10
Значение порога	163	205

Показанные результаты доказывают, что наш метод превосходит методы, основанные на ГА. На всех наборах тестовых изображений муравьиный алгоритм всегда показывал гораздо лучшую сходимость, особенно на начальных этапах обработки. В некоторых случаях, значение порога не изменяется на протяжении большого числа итераций, но возможен резкий скачок вследствие специфики поиска источника пищи особями. Время работы превосходит более ранние, генетические алгоритмы, почти в 3 раза. Весьма интересный подход рассмотрен в [9]. В дальнейших исследованиях планируется провести сравнительный анализ разработанного алгоритма и представленного в вышеуказанной статье.

Выводы. Показано применение муравьиных алгоритмов к решению задачи сегментации на примере различных изображений. Полученные экспериментальные данные подтверждают эффективность этого класса алгоритмов – результаты по качеству не уступают эволюционным методам сегментации изображений и превосходят их по быстродействию .

ЛИТЕРАТУРА

1. M.Dorigo. Optimization, learning and natural algorithms.PhD. thesis.Politecnico di Milano, 1992.
2. S.N.Sivanandam, S.N.Deepa. Introduction to genetic algorithms. Springer-Verlag Berlin Heidelberg.-2008.
3. Engelbrecht A.P. Computational intelligence: introduction.John Wiley&Sons Ltd.-2007.-597p.
4. 12. G. Chen, H.F. Zuo, 2-D maximum entropy method of image segmentation based on genetic algorithm, Journal of Computer-Aided Design &Computer Graphics14 (6) (2002) 530–534.
5. R.C. Gonzalez and R.E.Woods, Digital Image Processing, Addison-Wesley, Reading, MA, 1992.
6. Bhanu, B. and Lee, S., 1994, Genetic Learning for Adaptive Image Segmentation, Kluwer Academic Press.
7. N.R. Pal and S.K. Pal, A review on image segmentation techniques, Pattern Recognition, vol. 26, pp. 1277-1294, 1993.
8. Dorigo,M., Stzle,T.: Ant Colony Optimization. MIT Press, Cambridge (2004).
9. Huizhi Cao,Peng Huang, Shuqian Luo, A Novel Image Segmentation Algorithm Based on Artificial Ant Colonies, Medical Imaging and Informatics Second International Conference, MIMI 2007, Beijing, China, August 14-16, 2007, Revised Selected papers
10. Z. Iscan, “Segmentation Of Ultrasound Images by Using Artificial Neural Networks,” M.Sc. Thesis (in Turkish), Istanbul Technical University, Institute of Science & Technology, 2005.

СКОБЦОВ Юрий Александрович, доктор технических наук, профессор, заведующий кафедрой “Автоматизированные системы управления” Донецкого национального технического университета, ведущий научный сотрудник института прикладной математики и механики НАНУ.

Научные интересы: техническая и медицинская диагностика, искусственный интеллект, интеллектуальные САПР, обработка и распознавание медицинских изображений, нейронные сети, эволюционные вычисления и их применение.

ЭЛЬ-ХАТИБ Самер Аднан Ибрагим – аспирант кафедры Автоматизированных систем управления Донецкого Национального Технического Университета.

Научные интересы: искусственный интеллект, обработка и распознавание изображений, эволюционные вычисления, программирование и СУБД.

ЭЛЬ-ХАТИБ Аднан Ибрагим Исса – кандидат технических наук, доцент кафедры ПО университета El-Margab, Хомс, Ливийская Арабская Народная Социалистическая Джамахирия.

Научные интересы: искусственный интеллект, обработка и распознавание изображений, генетические алгоритмы, параллельные вычисления.