

Научная статья

УДК 004.822, 519.6

<https://doi.org/10.31854/1813-324X-2024-10-5-24-35>

Применение алгоритма стаи серых волков и нейронных сетей для решения дискретных задач

✉ Андрей Анатольевич Лисов, lisov.andrey2013@yandex.ru

Александр Григорьевич Возмилов, vozmiag@rambler.ru

Кирилл Александрович Гундарев, pioneer03.95@mail.ru

Аскар Зайдакбаевич Кулганатов, kulganatov97@gmail.com

Южно-Уральский государственный университет (НИУ),
Челябинск, 454080, Российская Федерация

Аннотация

Актуальность. В последние десятилетия метаэвристические методы оптимизации стали популярными для решения сложных задач, требующих поиска глобальных экстремумов. Алгоритмы, такие как генетический алгоритм (GA), оптимизация колоний муравьев (ACO), оптимизация роя частиц (PSO), а также более современные подходы, как алгоритм косячьей стаи (CSO) и оптимизация стаи серых волков (GWO), демонстрируют высокую эффективность, но их применение зачастую ограничивается условиями непрерывности и дифференцируемости целевых функций. Это представляет собой вызов при решении задач с дискретными данными, где такие требования не соблюдаются. В данном контексте особую актуальность приобретает поиск методов, позволяющих адаптировать метаэвристические алгоритмы для работы с дискретными функциями.

Цель исследования направлена на проверку гипотезы о возможности использования нейронной сети, обученной на ограниченном наборе дискретных данных, в качестве аппроксимации функции, достаточной для корректного выполнения алгоритма GWO при поиске глобального минимума.

Методы. Исследование основано на анализе существующих подходов и экспериментальной проверке гипотезы на двух тестовых функциях: линейной функции и функции Бута, которые широко применяются в качестве стандартов для оценки производительности алгоритмов оптимизации. Для получения результатов проведены численные эксперименты с использованием нейронных сетей в качестве аппроксимирующей модели.

Решение. В ходе экспериментов проведен анализ применимости нейронных сетей для аппроксимации дискретных функций, показавший успешность данного подхода. Было установлено, что нейронные сети могут с высокой точностью аппроксимировать дискретные функции, создавая условия для успешного поиска глобального минимума с использованием алгоритма GWO.

Новизна. Впервые предложена и проверена гипотеза о применении нейронных сетей для аппроксимации целевых функций в задачах метаэвристической оптимизации на дискретных данных. Это направление ранее не получило должного освещения в научной литературе, что придает ценность полученным результатам и подтверждает эффективность предложенного подхода.

Значимость. Результаты исследования открывают новые перспективы для применения алгоритмов, таких как GWO, в задачах оптимизации, основанных на дискретных данных, расширяя возможности метаэвристических методов и способствуя их внедрению в более широкий класс прикладных задач, включая задачи, где применение других методов ограничено.

Ключевые слова: оптимизация, GWO, нейронные сети, метаэвристика, поиск глобального минимума

Ссылка для цитирования: Лисов А.А., Возмилов А.Г., Гундарев К.А., Кулганатов А.З. Применение алгоритма стаи серых волков и нейронных сетей для решения дискретных задач // Труды учебных заведений связи. 2024. Т. 10. № 5. С. 80–91. DOI:10.31854/1813-324X-2024-10-5-24-35. EDN:BEODCG

Original research

<https://doi.org/10.31854/1813-324X-2024-10-5-24-35>

Application of the Gray Wolf Optimization Algorithm and Neural Networks for Solving Discrete Problems

✉ Andrey A. Lisov, lisov.andrey2013@yandex.ru

Alexander G. Vozmilov, vozmiag@rambler.ru

Kirill A. Gundarev, pioneer03.95@mail.ru

Askar Z. Kulganatov, kulganatov97@gmail.com

South Ural State University (NRU),
Chelyabinsk, 454080, Russian Federation

Annotation

Relevance. In recent decades, metaheuristic optimization methods have become popular for solving complex problems that require searching for global extrema. Algorithms such as genetic algorithm (GA), ant colony optimization (ACO), particle swarm optimization (PSO), as well as more modern approaches such as cat pack optimization (CSO) and gray wolf pack optimization (GWO) demonstrate high efficiency, but their application is often limited by the conditions of continuity and differentiability of the objective functions. This is a challenge when solving problems with discrete data, where such requirements are not met. In this context, the search for methods that allow adapting metaheuristic algorithms to work with discrete functions is of particular relevance.

Aim. The study is aimed at testing the hypothesis about the possibility of using a neural network trained on a limited set of discrete data as an approximation of a function sufficient for the correct execution of the GWO algorithm when searching for a global minimum. The implementation of this hypothesis can significantly expand the scope of GWO, making it available for a wider range of problems where functions are defined on discrete sets.

Methods. The study is based on the analysis of existing approaches and experimental verification of the hypothesis on two test functions: a linear function and a Booth function, which are widely used as standards for evaluating the performance of optimization algorithms. Numerical experiments were conducted using neural networks as an approximating model to obtain the results.

Solution. During the experiments, an analysis of the applicability of neural networks for approximating discrete functions was carried out, which showed the success of this approach. It was found that neural networks can approximate discrete functions with high accuracy, creating conditions for a successful search for a global minimum using the GWO algorithm.

Novelty. For the first time, a hypothesis was proposed and tested on the use of neural networks for approximating objective functions in metaheuristic optimization problems on discrete data. This direction has not previously received due coverage in the scientific literature, which adds significance to the obtained results and confirms the effectiveness of the proposed approach.

Practical significance. The results of the study open up new prospects for the application of algorithms such as GWO in optimization problems based on discrete data, expanding the capabilities of metaheuristic methods and facilitating their implementation in a wider class of applied problems, including problems where the use of other methods is limited.

Keywords: optimization, GWO, neural networks, metaheuristics, search for a global minimum

For citation: Lisov A.A., Vozmilov A.G., Gundarev K.A., Kulganatov A.Z. Application of the Gray Wolf Optimization Algorithm and Neural Networks for Solving Discrete Problems. *Proceedings of Telecommunication Universities*. 2024;10(5):80–91. (in Russ.) DOI:10.31854/1813-324X-2024-10-5-24-35. EDN:BEODCG

Введение

Метаэвристические методы оптимизации становятся все более распространенными среди ис-

следователей благодаря своей простоте и расширяемости. Некоторые из них, такие как генетический алгоритм (GA, аббр. от англ. Genetic Algorithm)

[1], оптимизация колоний муравьев (ACO, *аббр. от англ.* Ant Colony Optimization) [2], оптимизация роя частиц (PSO, *аббр. от англ.* Particle Swarm Optimization) [3], алгоритм кошачьей стаи (CSO, *аббр. от англ.* Cat Swarm Optimization) [4] и др. стали часто применяться в прикладных задачах [5–7].

Gray Wolf Optimization (GWO) – это относительно новый алгоритм оптимизации, основанный на социальной иерархии и охотничьем поведении серых волков в природе [8]. Алгоритм довольно популярен и имеет несколько модификаций и улучшений. В исследовании [9], например, предлагается модифицированный алгоритм GWO, в котором используется хороший баланс между разведкой и окружением глобального минимума агентами, модифицированный вариант алгоритма GWO для оптимизации многокритериальных задач [10] и его бинарная версия для решения проблемы выбора признаков [11].

В результате проведенного анализа существующих публикаций было выявлено, что данный алгоритм можно успешно использовать для решения многих инженерных и исследовательских задач. В частности, он может быть применен в качестве функции оптимизации при обучении нейронных сетей и для решения проблем планирования. Тем не менее стоит отметить, что ни в одной из приведенных далее статей не упоминалось о возможности дополнительного использования и, одновременно, улучшения алгоритма GWO. В частности, речь идет о применении не явно заданной функции, как было указано в [8], а нейронной сети, обученной на дискретных данных.

Таким образом, целью этого исследования является проверка гипотезы о том, что даже на ограниченном количестве дискретных данных, не содержащих глобальный минимум, можно обучить нейронную сеть, которая успешно будет использована в качестве исследуемой функции алгоритмом GWO для поиска данного значения. Ведь, как известно, нейронные сети глубокого обучения позволяют решать широкий спектр прикладных задач [12–15], подстраиваясь при помощи внутренних весов под не явно выраженные свойства, признаки и характеристики объектов для предсказания при внесении в систему новых ранее не полученных данных.

1. Исследование применения алгоритма GWO

Цель данного раздела – проверить наличие статей и иных исследований, которые уже высказали идею, озвученную ранее, и проверили ее на практике. Далее будут рассмотрены приложения алгоритма в целях машинного обучения (тренировки нейронных сетей, кластеризации) и инженерного использования (способы применения в распределяющих сетях, в робототехнике). Первые два спосо-

ба будут рассмотрены с точки зрения связки алгоритма GWO и нейронных сетей (НС) для проверки идеи поиска минимума при помощи НС, а остальных приложениях – с целью проверки вида заданной функции, для которой требуется найти оптимум.

1.1. Применение для целей машинного обучения

Алгоритм GWO применялся в различных приложениях машинного обучения. Большинство этих приложений делятся на 4 основные категории:

- 1) выбор признаков;
- 2) обучение нейронных сетей;
- 3) оптимизация машин опорных векторов (SVM, *аббр. от англ.* Support Vector Machines);
- 4) приложения кластеризации.

1.1.1. Выбор признаков

Выбор признаков является ключевым этапом в машинном обучении и анализе данных. Этот процесс направлен на уменьшение числа характеристик, выделение наиболее значимых и устранение лишних, шумных или нерелевантных признаков. Выявление оптимального набора признаков считается сложным из-за огромного пространства поиска.

В [16] был предложен метод-обертка, в котором бинарная версия алгоритма GWO объединяется с методом k -ближайших соседей (k -NN) для оценки потенциальных подмножеств признаков. В дальнейшем, в [17] авторы расширили свою предыдущую работу, проведя всестороннее исследование по применению двух подходов бинарного алгоритма GWO для выбора признаков с различными механизмами обновления.

В работе [18] бинарный алгоритм GWO был использован для классификации рака на основе данных о генной экспрессии. В отличие от предыдущих исследований, здесь автор применил алгоритм дерева решений в качестве оценочного средства, используя k -кратную перекрестную проверку и возвращая уровень точности в качестве значения пригодности.

В исследовании [19] был предложен метод сокращения признаков, который использует алгоритм GWO для поиска подмножества признаков, максимизирующих грубую классификационную функцию пригодности на основе заданного набора данных.

1.1.2. Обучение нейронных сетей

Искусственные нейронные сети (ИНС) представляют собой модели обработки информации, созданные по аналогии с биологическими нервными системами. Благодаря своей способности эффективно выявлять нелинейные зависимости и динамические изменения, ИНС широко используются как в исследовательских, так и в практиче-

ских целях. Однако их производительность существенно зависит от структуры сети и весовых коэффициентов связей между нейронами, которые могут быть оптимизированы с помощью метаэвристических алгоритмов, включая алгоритм GWO.

В исследовании [20] автор применил алгоритм GWO для обучения многослойного перцептрона (MLP, *аббр. от англ. Multilayered Perceptron*), одного из наиболее популярных типов нейронных сетей. В этом исследовании алгоритм GWO использовался для оптимизации весов и смещений в одном скрытом слое MLP.

Подобный подход был реализован в работе [21], где метод обучения на основе алгоритма GWO был протестирован на трех различных наборах данных и сравнен с алгоритмами PSO, гравитационного поиска (GSA, *аббр. от англ. Gravitational Search Algorithm*) и гибридным алгоритмом на основе популяции (PSOGSA).

В исследовании [22] была применена модифицированная версия алгоритма GWO для нейронных сетей с радиальной базисной функцией (RBFN, *аббр. от англ. Radial Basis Function Network*), названная q -гауссовыми радиальными базисными сетями функциональных связей (RBFLN).

1.1.3. Оптимизация машин опорных векторов (SVM)

Алгоритм SVM считается одним из наиболее мощных классификаторов и регрессоров. Этот метод был разработан В. Вапником [23, 24]. Для достижения максимальной производительности алгоритма SVM требуется настройка двух гиперпараметров: параметра штрафа за ошибку "C" и параметров ядра (kernel). Обычно эта задача решается с помощью простого или исчерпывающего поиска по сетке, однако данный метод неэффективен из-за значительного времени, необходимого для оценки всех возможных комбинаций. В ряде публикаций [25–27] для настройки гиперпараметров SVM применялся алгоритм GWO.

1.1.4. Кластеризация

Кластеризация представляет собой важную задачу в машинном обучении и анализе данных, целью которой является разделение данных на несколько групп, обладающих схожими характеристиками. В литературе часто встречаются метаэвристические подходы к кластеризации, предлагаемые в качестве альтернативы классическому алгоритму k -средних, одному из наиболее известных методов кластеризации. Алгоритм k -средних сильно зависит от начального выбора центроидов и склонен попадать в ловушки локальных минимумов. В этом контексте в работах [28, 29] был разработан алгоритм кластеризации на основе GWO, направленный на преодоление недостатков алгоритма k -средних.

1.2. Инженерные приложения

Очень важной областью оптимизации является инженерия. Она имеет множество важнейших приложений, которые напрямую влияют на качество жизни людей. Алгоритм GWO имеет различные адаптации для самых разных инженерных приложений, включая проектирование и настройку регуляторов, проблемы распределения электроэнергии, робототехнику и планирование пути, а также многие другие задачи.

1.2.1. Задачи информационных коммуникаций

Решая проблему покрытия в беспроводной сенсорной сети (WSN, *аббр. от англ. Wireless Sensor Networks*), авторы статьи [30] предложили вариант алгоритма GWO под названием Herds GWO (HGWO) для оптимизации покрытия датчиков WSN. Целевая функция их подхода учитывает перекрытия покрытия и дыры развертывания WSN. По сравнению с GA и классическим алгоритмом GWO, HGWO показал более высокую способность находить качественные решения с точки зрения хорошего покрытия в течение разумного времени вычислений.

В работе [31] разработаны модель и метод для бессерверной архитектуры, которые предусматривают миграцию групп микросервисов на подвижные совокупности устройств туманных вычислений с использованием алгоритма GWO. Этот алгоритм позволяет эффективно определять подходящие группы устройств для последующей миграции типовых микросервисов.

В статье [32] была рассмотрена проблема задержки и снижения коэффициента доставки пакетов, возникающая вследствие недостаточного учета пропускной способности и производительности сети. Для решения этой проблемы в базовой модели маршрутизации предложен гибридный алгоритм оптимизации, сочетающий алгоритмы Firefly и GWO, которая улучшает производительность за счет эффективного сочетания локальной и глобальной оптимизации поиска.

1.2.2. Проектирование и настройка регуляторов

В данном разделе рассмотрено применение алгоритма GWO для настройки параметров различных типов регуляторов: интегрального (И), пропорционально-интегрального (ПИ), и пропорционально-интегрально-дифференциального (ПИД).

В статье [33] авторы использовали алгоритм GWO для оптимизации параметров ПИ-регулятора в замкнутой системе регулирования давления. Экспериментальные результаты показали, что алгоритм GWO превосходит другие оптимизаторы, такие как GA и PSO.

В исследовании [34] алгоритм GWO был применен для настройки параметров ПИД-регулятора в

системе магнитной левитации для управления подъемом металлического шара. По сравнению с классическим методом настройки Циглера – Николса, алгоритм GWO продемонстрировал более высокую эффективность.

1.2.3. Проблемы с распределением электроэнергии

Распределение электроэнергии является классом задач оптимизации, характеризующимся высокой степенью нелинейности и невыпуклости, а также ограничениями, связанными с поиском оптимального распределения нагрузки для управления и планирования текущих ресурсов. Эта задача представляет собой специфический тип оптимизации, сложность которого возрастает с увеличением числа планируемых системных блоков. Первоначальное применение оптимизатора GWO для решения этой задачи было предложено в [35]. В работе [36] было разработано еще одно приложение, в котором использовалась диспетчеризация выбросов с применением алгоритма GWO.

1.2.4. Робототехника и планирование пути

В технологиях робототехники был предложен многокритериальный подход GWO для оптимизации планирования пути робота [37]. В качестве минимизации использовались две цели, которые управляют расстоянием и плавностью пути. Они выполнили ряд симуляций в различных статических средах. Результаты моделирования показали, что предложенный подход позволил обеспечить роботу оптимальный путь для достижения цели, не сталкиваясь с препятствиями.

Схожую работу провели в [38]: авторы предложили алгоритм GWO для решения проблемы планирования траектории движения беспилотных боевых летательных аппаратов. Они рассмотрели три случая проблем с планированием пути в разных измерениях. Цель состоит в том, чтобы найти безопасный путь, избегая опасных зон и минимизируя затраты на топливо.

1.2.5. Планирование

Для сварочного производства в работе [39] предложили многоцелевой дискретный алгоритм GWO для оптимизации планирования процесса сварки с целью минимизировать время ремонта и общую нагрузку на машину.

Итак, результаты анализа публикаций показали, что ранее идея данной статьи не была описана и проверена на практике, поэтому можно приступить к проведению экспериментов.

2. Материалы и методы

2.1. Оптимизатор GWO

Алгоритм GWO – это типичный алгоритм роевого интеллекта, основанный на иерархии лидерства

(рисунок 1) и механизме охоты серых волков в природе. Серые волки считаются высшими хищниками; средний размер группы у них 5–12 особей. В иерархии алгоритма GWO альфа (α) считается наиболее доминирующим членом группы. Волки бета (β) и дельта (δ) подчиняются α и помогают контролировать большинство волков – омега (ω). Волки ω занимают самое низкое положение в иерархии.

Математическая модель охотничьего механизма серых волков состоит из следующих процессов:

- 1) поиск, преследование и приближение к добыче (окружение добычи);
- 2) окружение и изнурение добычи (охота);
- 3) нападение на добычу.




Рис. 1. Иерархия в стае серых волков (доминирование уменьшается сверху вниз)

Fig. 1. Hierarchy of Grey Wolf (Dominance Decreases from Top Down)

Окружение добычи. Во время охоты серые волки окружают добычу, что математически можно записать так:

$$\vec{D} = |\vec{C} \cdot \vec{X}_p(t) - \vec{X}(t)|, \quad (1)$$

$$\vec{X}(t+1) = \vec{X}_p(t) - \vec{A} \cdot \vec{D}, \quad (2)$$

где t – текущая итерация; $\vec{X}_p$ – вектор положения добычи; $\vec{X}$ – вектор положения серого волка; $\vec{A}$ и $\vec{C}$ – векторы коэффициентов:

$$\vec{A} = 2 \vec{a} \cdot \vec{r}_1 - \vec{a}, \quad (3)$$

$$\vec{C} = 2 \cdot \vec{r}_2, \quad (4)$$

где a – линейно уменьшающийся коэффициент от 2 до 0 в ходе итераций; r_1 и r_2 – случайные векторы из диапазона $[0; 1]$.

Охота. Обычно руководят стаей α и β , а δ участвует время от времени. Лучшие решения-кандидаты – α , β , и δ , хорошо знают о потенциальном местонахождении добычи. Остальные поисковые агенты (ω) обновляют свои позиции в соответствии с позицией трех лучших поисковых агентов. Аналитически описанный процесс можно представить в следующем виде:

$$\begin{aligned} \vec{D}_\alpha &= |\vec{C}_1 \cdot \vec{X}_\alpha - \vec{X}|, \\ \vec{D}_\beta &= |\vec{C}_2 \cdot \vec{X}_\beta - \vec{X}|, \\ \vec{D}_\delta &= |\vec{C}_3 \cdot \vec{X}_\delta - \vec{X}|. \end{aligned} \quad (5)$$

Вектор позиции ω -волка можно вычислить при помощи выражений:

$$\begin{aligned}\vec{X}_1 &= \vec{X}_\alpha - \vec{A}_1 \cdot \vec{D}_\alpha, \\ \vec{X}_2 &= \vec{X}_\beta - \vec{A}_2 \cdot \vec{D}_\beta, \\ \vec{X}_3 &= \vec{X}_\delta - \vec{A}_3 \cdot \vec{D}_\delta, \\ \vec{X} &= \frac{\vec{X}_1 + \vec{X}_2 + \vec{X}_3}{3}.\end{aligned}\quad (6)$$

$$\vec{X} = \frac{\vec{X}_1 + \vec{X}_2 + \vec{X}_3}{3}.\quad (7)$$

Серые волки заканчивают охоту, нападая на добычу, когда она перестает двигаться.

Нападение на добычу. Чтобы математически смоделировать приближение добычи, мы уменьшаем значение $\vec{a}$. При этом диапазон колебаний также уменьшается на $\vec{a}$. Другими словами, $\vec{A}$ – это случайная величина в интервале $[-a; a]$, где a уменьшается от 2 до 0 в ходе итераций. Когда случайные значения $\vec{A}$ находятся в диапазоне $[-1; 1]$, следующая позиция поискового агента может быть между его текущей позицией и позицией добычи. Когда $|A| < 1$, волки нападают на добычу и происходит уточнение положения глобального минимума исследуемой функции.

2.2. Проверка гипотезы

Для проверки гипотезы было проведено два эксперимента. В первом эксперименте использовался датасет (от англ. Dataset – набор данных), основанный на простой линейной функции первого порядка, не содержащий точки с глобальным минимумом. Целью нейронной сети было обнаружение этой зависимости. Затем нейронная сеть была интегрирована в алгоритм поиска GWO в качестве неявно заданной функции.

Во втором эксперименте условия были аналогичны первому, за исключением того, что исследуемая функция была функцией Бута, используемой для проверки алгоритмов оптимизации. В обоих экспериментах датасеты содержали ограниченное количество данных и не имели точки глобального минимума, что усложняло задачу прогнозирования нейронной сети и повышало чистоту эксперимента.

Весь код, использованный в исследовании, доступен на GitHub одного из авторов (https://github.com/AnLiMan/Grey_Wolf_Optimization). Код написан на языке программирования Python с использованием фреймворка Tensorflow и выполнен на платформе Google Colab.

2.2.1. Датасет линейной функции

Используемый в данной работе датасет, частично отображенный в таблице 1, представляет из себя функцию:

$$Y = 0,5 \cdot A + 2 \cdot B + C, \quad (8)$$

где A, B, C – случайные целые числа.

Из уравнения (1) можно понять, что глобальный минимум функции находится в точке (0;0;0). Датасет имеет размерность – 184 строки, 4 колонки (порядковый номер не включен), не содержит точки (0;0;0) и был создан в «Excel», а после переведен в формат «.csv».

ТАБЛИЦА 1. Датасет линейной функции для обучения нейронной сети

TABLE 1. Dataset of Linear Function for Training Neural Network

№ п/п	A	B	C	Y
1	18	8	0	25
2	10	24	17	70
3	9	13	21	51,5
4	24	25	7	69
...	...	...	...	...
183	24	19	3	53

2.2.2. Датасет функции Бута

Функция Бута в прикладной математике относится к тестовым функциям, которые известны как искусственные ландшафты и являются полезными для оценки характеристик алгоритмов оптимизации наряду с функциями Растригина, Розенброка, Гольдштейна – Прайса и др., она может быть выражена следующим образом:

$$f(x, y) = (x + 2y - 7)^2 + (2x + y - 5)^2. \quad (9)$$

Глобальный минимум функции находится в точке $f(1;3) = 0$. Датасет (таблица 2) имеет размерность – 232 строки, 3 колонки (порядковый номер не включен), не содержит точки (1;3) и также, как и первый, был создан в редакторе «Excel» и после переведен в формат «.csv». Данные помещены в репозиторий «Grey_Wolf_Optimization» под названием «Boot_dataset.csv».

ТАБЛИЦА 2. Датасет для нейронной сети на основе функции Бута

TABLE 2. Dataset for a Neural Network Based on the Booth Function

№ п/п	x	y	f
1	0	0	74
2	0,1	0,1	66,98
3	0,2	0,2	60,32
4	0,3	0,3	54,02
...	...	...	...
231	8,4	-11,2	441,36

2.2.3. Алгоритм работы и модели нейронной сети

Алгоритм работы кода достаточно прост и линеен, поэтому проще отобразить его в виде списка требуемых шагов, а не блок-схемы.

Шаг 1. Инициализация и настройка.

Настройка параметров и гиперпараметров нейронной сети, таких как batch size, оптимизатора (в данном случае "Adam"), функции потерь (MSE,

аббр. от англ. Mean Squared Error), количество эпох обучения и т. д.:

- подключение Google Диска для сохранения и загрузки обученной модели.

Шаг 2. Подключение дополнительных библиотек:

- TensorFlow для работы с нейронными сетями;
- Keras для управления фреймворком TensorFlow;
- Math для работы с математическими функциями;
- Scikit-learn для вычисления метрик полученной модели;
- Matplotlib для построения графиков;
- NumPy для работы с массивами;
- Pandas для работы с датасетом.

Шаг 3. Обработка данных:

- проверка целостности csv-датасета;
- определение размерности и меток данных.

Шаг 4. Преобразование данных.

Преобразование входных данных в массив NumPy: независимые переменные X (в случае с линейной функцией это множество из переменных A, B, C , в случае с функцией Бута – это переменные x, y) и зависимая переменная Y .

Шаг 5. Разделение данных на тренировочную и тестовую выборки в соотношении, заданном настройками из пункта 1.

Шаг 6. Преобразование train_X в тензор TensorFlow с помощью `tf.convert_to_tensor`.

Шаг 7. Нормализация данных.

Нормализация исходных значений в диапазоне $[-1; 1]$ для улучшения сходимости и вычисления градиентов при обучении нейронной сети.

Шаг 8. Задание модели нейронной сети.

Определение архитектуры нейронной сети, включая количество скрытых слоев, нейронов в каждом из них и функции активации (ReLU, tanh, sigmoid и др.) для этого слоя.

Шаг 9. Обучение нейронной сети:

- обучение нейронной сети на тренировочных данных;
- сохранение обученной модели на Google Диск;
- загрузка сохраненной модели для последующего использования.

Шаг 10. Проверка точности предсказаний.

Оценивается точность предсказаний нейронной сети на тестовой выборке, которая не участвовала в процессе обучения.

Вычисление глобального минимума при помощи алгоритмов НС и GWO происходит в программной функции ниже, которая расположена в самом низу модифицированного кода GWO, где `Loading_model` – обученная модель нейронной сети, а метод «predict» возвращает значение Y при заданном X :

```
def obj(x):  
    print("Вычисление позиции омеги...")  
    return Loading_model.predict(x)
```

Таким образом, алгоритм GWO может свободно запрашивать любые значения в рамках пространства поиска для своих целей оптимизации, чтобы найти глобальный минимум неявно заданной функции.

3. Результаты

На рисунке 2а изображен график, отображающий предсказанные значения НС и реальные значения на обучающей и тестовой выборках. Красная линия разделяет тренировочную ("train") и тестовую ("test") части выборки. Ось x отражает номер пакета данных для анализа (каждая строка датасета без зависимой переменной). Анализ графика показывает, что НС эффективно предсказывает значения функции, демонстрируя высокую степень точности, фактически повторяя истинное значение функции. Рисунок 2с представляет собой увеличенное представление результатов предсказаний на тестовой выборке.

Полученная модель НС легла в основу исходной функции для алгоритма GWO. Границы поиска соответствовали границам исходного датасета, но это не жесткий параметр и может свободно варьироваться.

После 15-ти итераций алгоритм вывел следующее решение (текст, генерируемый программой):

```
-----Итоговое решение-----  
A = 0 B = 0,428539 C = 0  
Лучший счет = [[0,107]]
```

Это довольно близко к точке $(0;0;0)$ и при этом практически соответствует глобальному минимуму функции по мнению НС (согласно параметру «Лучший счет»). Однако важно отметить, что первый датасет – это простая линейная функция, которую легко предсказать и без помощи НС. Главная цель первого эксперимента – отладка процессов и кода.

Для более корректной проверки был проведен 2-й эксперимент с датасетом на основе функции Бута. В результате были получены графики, показанные на рисунках 2b и 2d. На рисунке 2b красная линия разделяет тренировочную и тестовую выборки. Результаты прогнозирования значений функции Бута на тестовой выборке, показанные на рисунке 2d, показывают, что в этот раз НС справилась хуже, чем при прогнозировании значений линейной функции.

После 15-ти итераций алгоритм GWO вывел следующее решение:

```
-----Итоговое решение-----  
A = 1,0399 B = 2,975219  
Лучший счет = [[0,164]]
```




Рис. 2. График предсказанного НС и реального значения на обучающей и тестовой выборке (а, б) и только на тестовой выборке (с, д) на основе линейной функции (слева) и функции Бута (справа)

Fig. 2. Plot of Predicted NN and Actual Value on Training and Test Set (a, b) and Only on Test Set (c, d) Based on Linear Function (Left) and Booth Function (Right)

Напомним, что глобальный минимум функции находится в точке (1;3). Видно, что улучшенный алгоритм GWO хорошо справился со своей задачей как при работе с простыми, так и со сложными функциями даже на ограниченном количестве данных. Это позволяет констатировать, что ранее выдвинутая гипотеза имеет право на существование, и идея может быть применена при решении задач иного характера.

4. Обсуждение

Важно отметить одну ключевую особенность алгоритма GWO. Подобно многим другим метаэвристическим методам, он основывается на стохастическом подходе, то есть использует случайные факторы для поиска решений. Это приводит к тому, что результаты могут варьироваться от запуска к запуску, что сказывается на стабильности финального результата. В настоящем исследовании также наблюдалась эта черта: хотя алгоритм несколько раз практически достигал глобального минимума в точке (0;0;0) в рамках первого эксперимента, чаще всего он сходил на другой точке, которая и была зафиксирована в разделе «Результаты». Похожая картина наблюдалась и во втором эксперименте, что подтверждает случайную природу его поведения.

Особенность алгоритма GWO также заключается в его способе поиска решения. Подробный анализ показал, что целевое решение обычно дости-

гается на 4–5 итерации из 15. Однако это не повод уменьшать их количество, так как параметр $\hat{A}$ (определяющий соотношение между разведкой и окружением добычи) постепенно уменьшается с каждой итерацией, что влияет на процесс поиска. Сокращение количества итераций может снизить эффективность алгоритма, так как на ранних этапах он преимущественно сосредотачивается на поиске, а на более поздних – на более точном нападении на добычу.

Существуют подходы для улучшения этого аспекта. Один из вариантов – использование дополнительного количества итераций, что повышает шансы на более стабильное достижение глобального минимума. Другой вариант – воспользоваться усовершенствованием из исследования [40], в котором предложено изменить структуру алгоритма для улучшения его стабильности и эффективности.

Заключение

В работе был рассмотрен алгоритм оптимизации стаи серых волков (GWO), адаптированный для решения задач аппроксимации функций, заданных дискретными данными, посредством нейронных сетей (НС). Показано, что предложенный подход эффективно обучает нейронные сети для выполнения функции аппроксимации, что, в свою очередь, делает возможным применение метаэвристических алгоритмов даже в условиях, где структура данных не является непрерывной и

гладкой. Экспериментальные результаты подтвердили, что данная методика обеспечивает высокую точность при поиске глобального минимума, даже если в исходных данных отсутствуют значения, указывающие на глобальный минимум функции. Таким образом, алгоритм GWO в сочетании с нейронными сетями продемонстрировал способность решать задачи глобальной оптимизации на дискретных данных, показывая потенциально широкий спектр применения в реальных условиях.

Результаты исследования также указывают на то, что нейронные сети могут выполнять роль аппроксиматоров функций для метаэвристических алгоритмов в условиях ограниченного объема информации. Это расширяет области применения algo-

ритмов оптимизации, позволяя использовать их в задачах, где доступные данные неполны или представлены в виде дискретных точек, как, например, в сценариях управления сложными технологическими процессами или анализа данных IoT.

Будущие исследования могут быть направлены на расширение применения метаэвристических методов для задач с более сложными функциями и дополнительными ограничениями. Также перспективным является изучение гибридных моделей, совмещающих различные подходы искусственного интеллекта, для дальнейшего улучшения эффективности и точности решений в задачах оптимизации на сложных дискретных наборах данных.

Список источников

1. Bonabeau E., Dorigo M., Theraulaz G. Swarm Intelligence: From Natural to Artificial Systems. 1999. DOI:10.1093/oso/9780195131581.001.0001
2. Dorigo M., Birattari M., Stutzle T. Ant colony optimization // IEEE Computational Intelligence Magazine. 2006. Vol. 1. Iss. 4. PP. 28–39. DOI:10.1109/MCI.2006.329691
3. Kennedy J., Eberhart R. Particle swarm optimization // Proceedings of the International Conference on Neural Networks (Perth, Australia, 27 November – 01 December 1995). IEEE, 1995. PP. 1942–1948. DOI:10.1109/ICNN.1995.488968
4. Chu S.C., Tsai P.W., Pan J.S. Cat Swarm Optimization // Proceedings of the 9th Pacific Rim International Conference on Artificial Intelligence (Guilin, China, 7–11 August 2006). Lecture Notes in Computer Science. Berlin, Heidelberg: Springer, 2006. Vol. 4099. PP. 854–858. DOI:10.1007/978-3-540-36668-3_94
5. Johnson J.M., Rahmat-Samii Y. Genetic algorithm optimization and its application to antenna design // Proceedings of IEEE Antennas and Propagation Society International Symposium and URSI National Radio Science Meeting (Seattle, USA, 20–24 June 1994). IEEE, 1994. Vol. 1. PP. 326–329. DOI:10.1109/APS.1994.407746
6. Afshar A., Massoumi F., Afshar A., Mariño M.A. State of the Art Review of Ant Colony Optimization Applications in Water Resource Management // Water Resources Management. 2015. Vol. 29. PP. 3891–3904. DOI:10.1007/s11269-015-1016-9
7. Parsopoulos K.E., Vrahatis M.N. Particle swarm optimization and intelligence: advances and applications. Advances and applications. Information Science Reference. 2010. 328 p. DOI:10.13140/2.1.3681.1206
8. Mirjalili S., Mirjalili S.M., Lewis A. Grey wolf optimizer // Advances in Engineering Software. 2014. Vol. 69. PP. 46–61. DOI:10.1016/j.advengsoft.2013.12.007
9. Mittal N., Singh U., Sohi B. Modified Grey Wolf Optimizer for Global Engineering Optimization // Applied Computational Intelligence and Soft Computing. 2016. Vol. 2016. P. 7950348. DOI:10.1155/2016/7950348
10. Mirjalili S., Saremi S.M., Mirjalili L.D., Coelho S. Multi-objective grey wolf optimizer: A novel algorithm for multicriterion optimization // Expert Systems with Applications. 2016. Vol. 47. PP. 106–119. DOI:10.1016/j.eswa.2015.10.039
11. Hu P., Pan J.S., Chu S.C. Improved Binary Grey Wolf Optimizer and Its application for feature selection // Knowledge-Based Systems. 2020. Vol. 195. P. 105746. DOI:10.1016/j.knosys.2020.105746
12. Vozmilov A., Andreev L., Lisov A. Development of an Algorithm for the Program to Recognize Defects on the Surface of Hot-Rolled Metal // Proceedings of the International Conference on Industrial Engineering, Applications and Manufacturing (ICIEAM, Sochi, Russian Federation, 16–20 May 2022). IEEE, 2022. PP. 1004–1008. DOI:10.1109/ICIEAM54945.2022.9787116
13. Лисов А.А. Разработка системы электронного дифференциала для электромобилей на основе нейросети глубокого обучения // Инновационные транспортные системы и технологии. 2024. Т. 10. № 3. С. 351–367. DOI:10.17816/transsyst634127. EDN:DFDXJO
14. Лисов А.А., Кулганатов А.З., Панишев С.А. Акустическое обнаружение транспортных средств аварийных служб с использованием сверточных нейронных сетей // Инновационные транспортные системы и технологии. 2023. Т. 9. № 1. С. 95–107. DOI:10.17816/transsyst20239195-107. EDN:MAGRJH
15. Возмилов А.Г., Лисов А.А., Урманов В.Г., Синева Г. Н. Определение вида заболеваний, поражающих листья картофеля, с использованием алгоритмов машинного обучения // Вестник НГИЭИ. 2023. № 3(142). С. 7–16. DOI:10.24412/2227-9407-2023-3-7-16. EDN:BXWBRC
16. Emary E., Zawbaa H.M., Grosan C., Hassenian A.E. Feature Subset Selection Approach by Gray-Wolf Optimization // Proceedings of the First International Afro-European Conference for Industrial Advancement (AECIA, Belfast, UK, 2–4 September 2024). Advances in Intelligent Systems and Computing. Cham: Springer, 2015. Vol. 334. PP. 1–13. DOI:10.1007/978-3-319-13572-4_1
17. Emary E., Zawbaa H.M., Hassanien A.E. Binary grey wolf optimization approaches for feature selection // Neurocomputing. 2016. Vol. 172. PP. 371–381. DOI:10.1016/j.neucom.2015.06.083

18. Vosooghifard M., Ebrahimpour H. Applying Grey Wolf Optimizer-based decision tree classifier for cancer classification on gene expression data // Proceedings of the International Conference on Computer and Knowledge Engineering (ICCKE, Mashhad, Iran, 29 October 2015). IEEE, 2015. PP. 147–151. DOI:10.1109/ICCKE.2015.7365818
19. Yamany W., Emary E., Hassanien A.E. New Rough Set Attribute Reduction Algorithm Based on Grey Wolf Optimization // Proceedings of the 1st International Conference on Advanced Intelligent System and Informatics (AIS, 28–30 November 2015, Beni Suef, Egypt). Advances in Intelligent Systems and Computing. Cham: Springer, 2015. Vol. 407. PP. 241–251. DOI:10.1007/978-3-319-26690-9_22
20. Mirjalili S. How effective is the Grey Wolf optimizer in training multi-layer perceptrons // Applied Intelligence. 2015. Vol. 43. PP. 150–161. DOI:10.1007/s10489-014-0645-7
21. Mosavi M.R., Khishe M., Ghamgosar A. Classification of sonar data set using neural network trained by gray wolf optimization // Neural Network World. 2016. Vol. 26. Iss. 4. PP. 393–415. DOI:10.14311/NNW.2016.26.023
22. Muangkote N., Sunat K., Chiewchanwattana S. An improved grey wolf optimizer for training q-Gaussian Radial Basis Functional-link nets // Proceedings of the International Computer Science and Engineering Conference (ICSEC, Khon Kaen, Thailand, 30 July – 01 August 2014). IEEE, 2014. PP. 209–214. DOI:10.1109/ICSEC.2014.6978196
23. Vapnik V. The nature of statistical learning theory. New York: Springer, 2015.
24. Vapnik V.N. An overview of statistical learning theory // IEEE Transactions on Neural Networks. 1999. Vol. 10. Iss. 5. PP. 988–999. DOI:10.1109/72.788640
25. Eswaramoorthy S., Sivakumaran N., Sekaran S. Grey wolf optimization-based parameter selection for support vector machines // Compel: International journal for computation and mathematics in electrical and electronic engineering. 2016. Vol. 35. Iss. 5. PP. 1513–1523.
26. Mustafa Z., Sulaiman M.H., Kahar M.N.M. Training LSSVM with GWO for price forecasting // Proceedings of the International Conference on Informatics, Electronics & Vision (ICIEV, Fukuoka, Japan, 15–18 June 2015). IEEE, 2015. DOI:10.1109/ICIEV.2015.7334054
27. Mustafa Z., Sulaiman M.H., Kahar M.N.M. LS-SVM hyperparameters optimization based on GWO algorithm for time series forecasting // Proceedings of the 4th International Conference on Software Engineering and Computer Systems (ICSECS, Kuantan, Malaysia, 19–21 August 2015). IEEE, 2015. PP. 183–188. DOI:10.1109/ICSECS.2015.7333107
28. Kumar V., Chhabra J.K., Kumar D. Grey Wolf Algorithm-Based Clustering Technique // Journal of Intelligent Systems. 2017. Vol. 26. Iss. 1. PP. 153–168. DOI:10.1515/jisys-2014-0137
29. Zhang S., Zhou Y. Grey Wolf Optimizer Based on Powell Local Optimization Method for Clustering Analysis // Discrete Dynamics in Nature and Society. 2015. Vol. 1. P. 481360. DOI:10.1155/2015/481360
30. Dao T.K., Shieh C.S., Nguyen T.T., Wang H.Y. Enhanced Diversity Herds Grey Wolf Optimizer for Optimal Area Coverage in Wireless Sensor Networks // Proceedings of the Tenth International Conference on Genetic and Evolutionary Computing, ICGEC, Fuzhou City, China, 7–9 November 2016). Advances in Intelligent Systems and Computing. Cham: Springer, 2016. Vol. 536. PP. 174–182. DOI:10.1007/978-3-319-48490-7_21
31. Волков А.Н. Динамические туманные вычисления и бессерверная архитектура: на пути к зеленым ИКТ // Труды учебных заведений связи. 2024. Т. 10. № 3. С. 24–34. DOI:10.31854/1813-324X-2024-10-3-24-34. EDN:QOELMJ
32. Abdullah H.M., Kumar A.S., Ahmed A.A., Mosleh M.A. Hybrid optimization based on spectrum aware opportunistic routing for cognitive radio ad hoc networks // Informatics and Automation. 2023. Vol. 22. Iss. 4. PP. 880–905. DOI:10.15622/ia.22.4.7. EDN:VPRGZW
33. Li S.X., Wang, J.S. Dynamic Modeling of Steam Condenser and Design of PI Controller Based on Grey Wolf Optimizer // Mathematical Problems in Engineering. 2015. Vol. 1. P. 120975. DOI:10.1155/2015/120975
34. Yadav S., Verma S.K., Nagar S.K. Optimized PID Controller for Magnetic Levitation System // IFAC-PapersOnLine. 2016. Vol. 49. Iss. 1. PP. 778–782. DOI:10.1016/j.ifacol.2016.03.151
35. Wong L.I., Sulaiman M.H., Mohamed M.R., Hong M.S. Grey Wolf Optimizer for Solving Economic Dispatch Problems // Proceedings of the International Conference on Power and Energy (PECon, Kuching, Malaysia, 01–03 December 2014). IEEE, 2014. PP. 150–154. DOI:10.1109/PECON.2014.7062431
36. Song H.M., Sulaiman M.H., Mohamed M.R. An Application of Grey Wolf Optimizer for Solving Combined Economic Emission Dispatch Problems // International Review on Modelling and Simulations. 2014. Vol. 7. Iss. 5. PP. 838–844. DOI:10.15866/iremos.v7i5.2799
37. Tsai P.W., Dao T.K. Robot Path Planning Optimization Based on Multiobjective Grey Wolf Optimizer // Proceedings of the Tenth International Conference on Genetic and Evolutionary Computing, ICGEC, Fuzhou City, China, 7–9 November 2016). Advances in Intelligent Systems and Computing. Cham: Springer, 2016. Vol. 536. PP. 166–173. DOI:10.1007/978-3-319-48490-7_20
38. Zhang S., Zhou Y., Li Z., Pan W. Grey wolf optimizer for unmanned combat aerial vehicle path planning // Advances in Engineering Software. 2016. PP. 121–136. DOI:10.1016/j.advengsoft.2016.05.015
39. Lu C., Xiao S., Li X., Gao L. An effective multi-objective discrete grey wolf optimizer for a real-world scheduling problem in welding production // Advances in Engineering Software. 2016. Vol. 99. PP. 161–176. DOI:10.1016/j.advengsoft.2016.06.004
40. Mittal N., Singh U., Sohi B.S. Modified Grey Wolf Optimizer for Global Engineering Optimization // Applied Computational Intelligence and Soft Computing. 2016. Vol. 2016. P. 4598. DOI:10.1155/2016/7950348

References

1. Bonabeau E., Dorigo M., Theraulaz G. *Swarm Intelligence: From Natural to Artificial Systems*. 1999. DOI:10.1093/oso/9780195131581.001.0001
2. Dorigo M., Birattari M., Stutzle T. Ant colony optimization. *IEEE Computational Intelligence Magazine*. 2006;1(4):28–39. DOI:10.1109/MCI.2006.329691

3. Kennedy J., Eberhart R. Particle swarm optimization. *Proceedings of the International Conference on Neural Networks*, 27 November – 01 December 1995, Perth, Australia. IEEE; 1995. p.1942–1948. DOI:10.1109/ICNN.1995.488968
4. Chu S.C., Tsai P.W., Pan J.S. Cat Swarm Optimization. *Proceedings of the 9th Pacific Rim International Conference on Artificial Intelligence*, 7–11 August 2006, Guilin, China. *Lecture Notes in Computer Science*, vol.4099. Berlin, Heidelberg: Springer; 2006. p.854–858. DOI:10.1007/978-3-540-36668-3_94
5. Johnson J.M., Rahmat-Samii Y. Genetic algorithm optimization and its application to antenna design. *Proceedings of IEEE Antennas and Propagation Society International Symposium and URSI National Radio Science Meeting*, 20–24 June 1994, Seattle, USA, vol.1. IEEE; 1994. p.326–329. DOI:10.1109/APS.1994.407746
6. Afshar A., Massoumi F., Afshar A., Mariño M.A. State of the Art Review of Ant Colony Optimization Applications in Water Resource Management. *Water Resources Management*. 2015;29:3891–3904. DOI:10.1007/s11269-015-1016-9
7. Parsopoulos K.E., Vrahatis M.N. Particle swarm optimization and intelligence: advances and applications. *Advances and applications*. Information Science Reference; 2010. 328 p. DOI:10.13140/2.1.3681.1206
8. Mirjalili S., Mirjalili S.M., Lewis A. Grey wolf optimizer. *Advances in Engineering Software*. 2014;69:46–61. DOI:10.1016/j.advengsoft.2013.12.007
9. Mittal N., Singh U., Sohi B. Modified Grey Wolf Optimizer for Global Engineering Optimization. *Applied Computational Intelligence and Soft Computing*. 2016;2016:7950348. DOI:10.1155/2016/7950348
10. Mirjalili S., Saremi S.M., Mirjalili L.D., Coelho S. Multi-objective grey wolf optimizer: A novel algorithm for multicriterion optimization. *Expert Systems with Applications*. 2016;47:106–119. DOI:10.1016/j.eswa.2015.10.039
11. Hu P., Pan J.S., Chu S.C. Improved Binary Grey Wolf Optimizer and Its application for feature selection. *Knowledge-Based Systems*. 2020;195:105746. DOI:10.1016/j.knsys.2020.105746
12. Vozmilov A., Andreev L., Lisov A. Development of an Algorithm for the Program to Recognize Defects on the Surface of Hot-Rolled Metal. *Proceedings of the International Conference on Industrial Engineering, Applications and Manufacturing, ICIEAM, 16–20 May 2022, Sochi, Russian Federation*. IEEE; 2022. p.1004–1008. DOI:10.1109/ICIEAM54945.2022.9787116
13. Lisov A.A. Development of an electronic differential system for electric vehicles based on deep neural network. *Modern Transportation Systems and Technologies*. 2024;10(3):351–367. (in Russ.) DOI:10.17816/transsyst634127. EDN:DFDXJO
14. Lisov A.A., Kulganatov A.Z., Panishev S.A. Using convolutional neural networks for acousticbased emergency vehicle detection. *Modern Transportation Systems and Technologies*. 2023;9(1):95–107. (in Russ.) DOI:10.17816/transsyst20239195-107. EDN:MAGRJH
15. Vozmilov A.G., Lisov A.A., Urmanov V.G., Sineva G.N. Determination of the type of potato leaves diseases with using machine learning. *Bulletin NGIEI*. 2023;3(142):7–16. (in Russ.) DOI:10.24412/2227-9407-20233-7-16. EDN:BXWBRC
16. Emary E., Zawbaa H.M., Grosan C., Hassenian A.E. Feature Subset Selection Approach by Gray-Wolf Optimization. *Proceedings of the First International Afro-European Conference for Industrial Advancement, AECLA, 2–4 September 2024, Belfast, UK. Advances in Intelligent Systems and Computing*, vol.334. Cham: Springer; 2015. p.1–13. DOI:10.1007/978-3-319-13572-4_1
17. Emary E., Zawbaa H.M., Hassanien A.E. Binary grey wolf optimization approaches for feature selection. *Neurocomputing*. 2016;172:371–381. DOI:10.1016/j.neucom.2015.06.083
18. Vosooghifard M., Ebrahimpour H. Applying Grey Wolf Optimizer-based decision tree classifier for cancer classification on gene expression data. *Proceedings of the International Conference on Computer and Knowledge Engineering, ICCKE, 29 October 2015, Mashhad, Iran*. IEEE; 2015. p.147–151. DOI:10.1109/ICCKE.2015.7365818
19. Yamany W., Emary E., Hassanien A.E. New Rough Set Attribute Reduction Algorithm Based on Grey Wolf Optimization. *Proceedings of the 1st International Conference on Advanced Intelligent System and Informatics, AISI, Beni Suef, Egypt, 28–30 November 2015. Advances in Intelligent Systems and Computing*, vol.407. Cham: Springer; 2015. p.241–251. DOI:10.1007/978-3-319-26690-9_22
20. Mirjalili S. How effective is the Grey Wolf optimizer in training multi-layer perceptrons. *Applied Intelligence*. 2015;43:150–161. DOI:10.1007/s10489-014-0645-7
21. Mosavi M.R., Khishe M., Ghamgosar A. Classification of sonar data set using neural network trained by gray wolf optimization. *Neural Network World*. 2016;26(4):393–415. DOI:10.14311/NNW.2016.26.023
22. Muangkote N., Sunat K., Chiewchanwattana S. An improved grey wolf optimizer for training q-Gaussian Radial Basis Functional-link nets. *Proceedings of the International Computer Science and Engineering Conference, ICSEC, Thailand, 30 July – 01 August 2014, Khon Kaen*. IEEE; 2014. p.209–214. DOI:10.1109/ICSEC.2014.6978196
23. Vapnik V. *The nature of statistical learning theory*. New York: Springer, 2015.
24. Vapnik V.N. An overview of statistical learning theory. *IEEE Transactions on Neural Networks*. 1999;10(5):988–999. DOI:10.1109/72.788640
25. Eswaramoorthy S., Sivakumaran N., Sekaran S. Grey wolf optimization-based parameter selection for support vector machines. *Compel: International journal for computation and mathematics in electrical and electronic engineering*. 2016;35(5):1513–1523.
26. Mustafa Z., Sulaiman M.H., Kahar M.N.M. Training LSSVM with GWO for price forecasting. *Proceedings of the International Conference on Informatics, Electronics & Vision, ICIEV, 15–18 June 2015, Fukuoka, Japan*. IEEE; 2015. DOI:10.1109/ICIEV.2015.7334054
27. Mustafa Z., Sulaiman M.H., Kahar M.N.M. LS-SVM hyperparameters optimization based on GWO algorithm for time series forecasting. *Proceedings of the 4th International Conference on Software Engineering and Computer Systems, ICSECS, 19–21 August 2015, Kuantan, Malaysia*. IEEE; 2015. p.183–188. DOI:10.1109/ICSECS.2015.7333107
28. Kumar V., Chhabra J.K., Kumar D. Grey Wolf Algorithm-Based Clustering Technique. *Journal of Intelligent Systems*. 2017;26(1):153–168. DOI:10.1515/jisys-2014-0137

29. Zhang S., Zhou Y. Grey Wolf Optimizer Based on Powell Local Optimization Method for Clustering Analysis. *Discrete Dynamics in Nature and Society*. 2015;1:481360. DOI:10.1155/2015/481360
30. Dao T.K., Shieh C.S., Nguyen T.T., Wang H.Y. Enhanced Diversity Herds Grey Wolf Optimizer for Optimal Area Coverage in Wireless Sensor Networks. *Proceedings of the Tenth International Conference on Genetic and Evolutionary Computing, ICGEC, 7–9 November 2016, Fuzhou City, China. Advances in Intelligent Systems and Computing, vol.536*. Cham: Springer; 2016. p.174–182. DOI:10.1007/978-3-319-48490-7_21
31. Volkov A.N. Dynamic Fog Computing Towards Green ICT. *Proceedings of Telecommunication Universities*. 2024;10(3): 24–34. (in Russ.) DOI:10.31854/1813-324X-2024-10-3-24-34. EDN:QOELMJ
32. Abdullah H.M., Kumar A.S., Ahmed A.A., Mosleh M.A. Hybrid optimization based on spectrum aware opportunistic routing for cognitive radio ad hoc networks. *Informatics and Automation*. 2023;22(4):880–905. DOI:10.15622/ia.22.4.7. EDN:VPRGZW
33. Li S.X., Wang, J.S. Dynamic Modeling of Steam Condenser and Design of PI Controller Based on Grey Wolf Optimizer. *Mathematical Problems in Engineering*. 2015;1:120975. DOI:10.1155/2015/120975
34. Yadav S., Verma S.K., Nagar S.K. Optimized PID Controller for Magnetic Levitation System. *IFAC-PapersOnLine*. 2016;49(1):778–782. DOI:10.1016/j.ifacol.2016.03.151
35. Wong L.I., Sulaiman M.H., Mohamed M.R., Hong M.S. Grey Wolf Optimizer for Solving Economic Dispatch Problems. *Proceedings of the International Conference on Power and Energy, PECon, 01–03 December 2014, Kuching, Malaysia*. IEEE; 2014. p.150–154. DOI:10.1109/PECON.2014.7062431
36. Song H.M., Sulaiman M.H., Mohamed M.R. An Application of Grey Wolf Optimizer for Solving Combined Economic Emission Dispatch Problems. *International Review on Modelling and Simulations*. 2014;7(5):838–844. DOI:10.15866/iremos.v7i5.2799
37. Tsai P.W., Dao T.K. Robot path planning optimization based on multiobjective grey wolf optimizer. *Proceedings of the Tenth International Conference on Genetic and Evolutionary Computing, ICGEC, 7–9 November 2016, Fuzhou City, China. Advances in Intelligent Systems and Computing, vol.536*. Cham: Springer; 2016. p.166–173. DOI:10.1007/978-3-319-48490-7_20
38. Zhang S., Zhou Y., Li Z., Pan W. Grey wolf optimizer for unmanned combat aerial vehicle path planning. *Advances in Engineering Software*. 2016. p.121–136. DOI:10.1016/j.advengsoft.2016.05.015
39. Lu C., Xiao S., Li X., Gao L. An effective multi-objective discrete grey wolf optimizer for a real-world scheduling problem in welding production. *Advances in Engineering Software*. 2016;99:161–176. DOI:10.1016/j.advengsoft.2016.06.004
40. Mittal N., Singh U., Sohi B.S. Modified Grey Wolf Optimizer for Global Engineering Optimization. *Applied Computational Intelligence and Soft Computing*. 2016;2016:4598. DOI:10.1155/2016/7950348

Статья поступила в редакцию 18.07.2024; одобрена после рецензирования 13.10.2024; принята к публикации 16.10.2024.

The article was submitted 18.07.2024; approved after reviewing 13.10.2024; accepted for publication 16.10.2024.

Информация об авторах:

ЛИСОВ
Андрей Анатольевич

аспирант кафедры «Электропривод, мехатроника и электромеханика»
Южно-Уральского государственного университета (Научно-исследовательского
университета)
 <https://orcid.org/0000-0001-7282-8470>

ВОЗМИЛОВ
Александр Григорьевич

доктор технических наук, профессор, старший научный сотрудник кафедры
«Электропривод, мехатроника и электромеханика» Южно-Уральского госу-
дарственного университета (Научно-исследовательского университета)
 <https://orcid.org/0000-0002-1292-3975>

ГУНДАРЕВ
Кирилл Александрович

аспирант кафедры «Колесные и гусеничные машины» Южно-Уральского
государственного университета (Научно-исследовательского университета)
 <https://orcid.org/0009-0004-8358-1329>

КУЛГАНАТОВ
Аскар Зайдакбаевич

аспирант кафедры «Электрические станции, сети и системы
электрообеспечения» Южно-Уральского государственного университета
(Научно-исследовательского университета)
 <https://orcid.org/0000-0002-7576-7949>

Авторы сообщают об отсутствии конфликтов интересов.

The authors declare no conflicts of interests.