

15. Solving the Job Shop Scheduling Problem with Ant Colony Optimization. Available at: [https://www.researchgate.net/publication/363500511\\_Solving\\_the\\_Job\\_Shop\\_Scheduling\\_Problem\\_with\\_Ant\\_Colony\\_Optimization](https://www.researchgate.net/publication/363500511_Solving_the_Job_Shop_Scheduling_Problem_with_Ant_Colony_Optimization) (accessed 07 November 2024).
16. Zhang F., Mei Y., Nguyen S. and Zhang M. Survey on Genetic Programming and Machine Learning Techniques for Heuristic Design in Job Shop Scheduling, in *IEEE Transactions on Evolutionary Computation*, Feb. 2024, Vol. 28, No. 1, pp. 147-167.
17. Dynamic flexible job shop scheduling method based on improved gene expression programming. Available at: [https://www.researchgate.net/publication/343612768\\_Dynamic\\_flexible\\_job\\_shop\\_scheduling\\_method\\_based\\_on\\_improved\\_gene\\_expression\\_programming](https://www.researchgate.net/publication/343612768_Dynamic_flexible_job_shop_scheduling_method_based_on_improved_gene_expression_programming) (accessed 10 December 2024).
18. Zhang F., Mei Y., Nguyen S. and Zhang M. Evolving Scheduling Heuristics via Genetic Programming With Feature Selection in Dynamic Flexible Job-Shop Scheduling, in *IEEE Transactions on Cybernetics*, April 2021, Vol. 51, No. 4, pp. 1797-1811.
19. Genetic Programming: An Introduction and Tutorial. Available at: [https://wiki.eecs.yorku.ca/course\\_archive/2010-11/W/4403/\\_media/gp1.pdf](https://wiki.eecs.yorku.ca/course_archive/2010-11/W/4403/_media/gp1.pdf) (accessed 07 November 2024).
20. Polikarpova N.I., Tochilin V.N. Primenenie geneticheskogo programmirovaniya dlya realizatsii sistem so slozhnym povedeniem [Application of genetic programming for the implementation of systems with complex behavior], *Nauchno-tekhnicheskiiy vestnik informatsionnykh tekhnologiy, mekhaniki i optiki* [Scientific and technical bulletin of information technologies, mechanics and optics], 2007, No. 39. Available at: <https://cyberleninka.ru/article/n/primenenie-geneticheskogo-programmirovaniya-dlya-realizatsii-sistem-so-slozhnym-povedeniem> (accessed 07 November 2024).

**Обухов Константин Олегович** – Астраханский государственный технический университет; e-mail: kobukhov98@mail.ru; г. Астрахань, Россия; кафедра автоматизированных систем обработки информации и управления; аспирант.

**Квятковская Ирина Юрьевна** – e-mail: i.kvyatkovskaya@astu.org; кафедра высшей и прикладной математики; д.т.н.; профессор.

**Морозов Александр Васильевич** – e-mail: morozov@ilabsltd.com; кафедра автоматизированных систем обработки информации и управления; к.т.н.; доцент.

**Obukhov Konstantin Olegovich** – Astrakhan State Technical University; e-mail: kobukhov98@mail.ru; Astrakhan, Russia; the Department of Automated Information Processing and Control Systems; postgraduate student.

**Kvyatkovskaya Irina Yurievna** – e-mail: i.kvyatkovskaya@astu.org; the Department of Higher and Applied Mathematics; dr. of eng. sc.; professor.

**Morozov Aleksandr Vasil'evich** – e-mail: morozov@ilabsltd.com; the Department of Automated Information Processing and Control Systems; cand. of eng. sc.; associate professor.

УДК 621.37

DOI 10.18522/2311-3103-2024-6-52-64

**З.А. Понимаш, М.В. Потанин**

## **МЕТОД И АЛГОРИТМ ИЗВЛЕЧЕНИЯ ПРИЗНАКОВ ИЗ ЦИФРОВЫХ СИГНАЛОВ НА БАЗЕ НЕЙРОСЕТЕЙ ТРАНСФОРМЕР**

*В последнее время нейросетевые модели стали одним из наиболее перспективных направлений в области автоматического извлечения признаков из цифровых сигналов. Традиционные подходы, такие как статистический, временной, частотный и частотно-временной анализ, требуют значительных экспертных знаний и часто оказываются недостаточно эффективными при работе с нестационарными и сложными сигналами, например, биомедицинскими (ЭКГ, ЭЭГ, ЭМГ) или промышленными сигналами (примером могут служить токограммы). Перечисленные выше методы имеют ряд ограничений, когда требуется анализировать многоканальные данные с изменяющейся частотной структурой, либо когда разметка сигналов слишком трудоёмка или дорогостоящая. Современные архитектуры нейросетей, такие как трансформеры, показали высокую эффективность в автоматическом извлечении признаков из сложных данных. Трансформеры превосходят традиционные свёрточные и рекуррентные нейронные сети по многим ключевым характеристикам.*

кам, особенно в задачах прогнозирования временных рядов, классификации мультимодальных данных и извлечения признаков из последовательностей. Их способность моделировать сложные временные зависимости и нелинейные зависимости в данных делает их идеальными для таких задач, как фильтрация шумов и обработка мультимодальных сигналов. В данной статье предложен метод извлечения признаков из цифровых сигналов, основанный на модифицированной архитектуре трансформера, включающей нелинейный слой после модуля самовнимания. Этот подход позволил улучшить способность модели выявлять сложные и нелинейные зависимости в данных, что особенно важно при работе с биомедицинскими и полученными от промышленных систем сигналами. Приводится описание архитектуры и проведенных экспериментов, демонстрирующих высокие показатели модели при решении задач классификации, прогнозирования и фильтрации сигналов. Ожидается, что данная модель может применяться для широкого спектра приложений, включая диагностику заболеваний и сбоев, прогнозирование параметров сигналов и системное моделирование.

Нейросетевые алгоритмы; трансформеры; извлечение признаков; цифровая обработка сигналов; медицинские сигналы; мультимодальные данные; временные ряды.

**Z.A. Ponimash M.V. Potanin**

### **METHOD AND ALGORITHM FOR EXTRACTING FEATURES FROM DIGITAL SIGNALS BASED ON NEURAL NETWORKS TRANSFORMER**

*Recently, neural network models have become one of the most promising directions in the field of automatic feature extraction from digital signals. Traditional approaches, such as statistical, time-domain, frequency-domain, and time-frequency analysis, require significant expert knowledge and often prove insufficiently effective when dealing with non-stationary and complex signals, such as biomedical signals (ECG, EEG, EMG) or industrial signals (e.g., currentgrams). These methods have several limitations when it comes to analyzing multichannel data with varying frequency structures or when signal labeling is too labor-intensive or expensive. Modern neural network architectures, such as transformers, have demonstrated high efficiency in automatic feature extraction from complex data. Transformers have outperformed traditional convolutional and recurrent neural networks in many key metrics, particularly in tasks involving time series forecasting, multimodal data classification, and feature extraction from sequences. Their ability to model complex temporal dependencies and nonlinear relationships in data makes them ideal for tasks such as noise filtering and multimodal signal processing. This paper proposes a method for feature extraction from digital signals based on a modified transformer architecture that incorporates a nonlinear layer after the self-inspection module. This approach improved the ability of the model to detect complex and nonlinear dependencies in the data, which is particularly important when dealing with biomedical and signals obtained from industrial systems. A description of the architecture and the experiments performed are presented, demonstrating the high performance of the model in solving signal classification, prediction and filtering problems. It is expected that the model can be applied to a wide range of applications including disease and fault diagnosis, signal parameter prediction and system modelling.*

*Neural network algorithms; transformers; feature extraction; digital signal processing; medical signals; multimodal data; time series.*

**Введение.** Интеллектуальная обработка данных активно применяется для анализа сигналов различной природы: биомедицинских, радиотехнических, акустических, промышленных и других. Алгоритмы обработки сигналов обычно состоят из двух модулей: извлечения признаков и принятия решений, часто реализуемого методами машинного обучения, включая нейросети [1] (рис. 1). Решающее правило может быть отдельным блоком, например, функции Хевисайда или более сложные алгоритмы семплирования, такие как top-k, ядерное сэмпирование и обучаемые алгоритмы [2–9]. Для решения задачи классификации применяются метод ближайших соседей, архитектура KAN [10], для задачи восстановления регрессии используют следующие методы, множественная регрессия, ядерный метод SVM, метод Надарая-Ватсона и др.

Задача автоматического извлечения признаков из сигналов особенно актуальна, когда мы говорим о таких сигналах, где с одной стороны очень много сырых данных, а с другой разметка достаточно дорогая. К таким сигналам можно отнести, например, биомедицинские. Такие как электрокардиограммы (ЭКГ), электроэнцефалограммы (ЭЭГ), электромиограммы (ЭМГ), а также некоторые другие сигналы различной природы, например токограммы электродвигателей, ионный ток в ДВС или же акустические сигналы. Задача из-

влечения признаков заключается в преобразовании этих сигналов в набор информативных характеристик, которые могут быть использованы для классификации, прогнозирования или иных задач анализа, чаще всего производится преобразование в вектор фиксированной длины. Современные методы извлечения признаков из сигналов включают разнообразные подходы, основанные на статистическом, временном, частотном или частотно-временном анализе, кроме того, некоторые подходы базируются на методах глубокого обучения, часто методы машинного обучения работают поверх уже извлеченных первичных признаков и извлекают более информативные вторичные признаки.



Рис. 1. Общая схема решения задачи

Современные методы автоматического извлечения признаков включают в себя статистический, временной, частотный и частотно-временной анализ, а также глубокое обучение. Статистические методы, основанные на вычислении среднего, дисперсии и автокорреляции, эффективны для стационарных сигналов, но ограничены в анализе нестационарных данных [12–14]. Частотные методы, такие как БПФ, СПМ и мел-кепстральные коэффициенты показывают высокое качество для сигналов со сложной спектральной структурой (для анализа полигармонических сигналов), но их базисные функции не локализованы во времени, что решается с помощью вейвлет-преобразования. Методы линейного предсказания и информационные метрики, такие как энтропия, также находят широкое применение [15].

Глубокое обучение предоставляет мощные инструменты для автоматического извлечения признаков. Сверточные и рекуррентные нейронные сети позволяют эффективно обрабатывать временные и пространственные данные, выявляя сложные паттерны. Архитектуры трансформеров и вариационные автокодировщики (VAE) демонстрируют высокую производительность в задачах анализа сигналов, улучшая непрерывность и компактность признакового пространства [16–26].

Нейронные сети успешно применяются для работы с биомедицинскими сигналами [16–18], радиотехническими, например, в нейросетевых алгоритмах демодуляции сигналов [19], распознавании речи и идентификации диктора [20–21], а также в задачах анализа временных рядов.

Другим перспективным направлением является применение нейросетей из семейства архитектур «трансформер» [24, 25]. Трансформеры показывают более высокую производительность и скорость обучения, по сравнению, с LSTM, в задачах обработки естественного языка. Кроме того, трансформеры нашли применение и в обработке других временных и псевдо-временных рядов, в частности, анализе цифровых сигналов, демонстрируя высокие результаты в таких задачах, как классификация и сегментация.

Настоящая работа предлагает новый метод автоматического извлечения признаков на основе трансформеров с модифицированными нелинейными слоями. Данная модификация позволяет улучшить качество выделения признаков для задач анализа сигналов и обработки мультимодальных данных, что делает его полезным для широкого спектра приложений, включая медицинские и промышленные системы.

**Постановка задачи.** Задача заключается в разработке метода извлечения признаков из цифровых сигналов, основанного на подходе, аналогичном тому, который используют GPT-подобные модели для генерации текста. В отличие от традиционного подхода, задача прогнозирования временного ряда должна решаться одновременно для двух временных точек,  $t$  и  $t + \Delta t$ , где  $t, \Delta t \in \mathbb{N}$ . Это позволяет учитывать временные зависимости на больших интервалах (в рамках данной работы рассматривается  $t = 0, \Delta t = 1$ ). При этом система должна обеспечивать кодирование признаков во внутренних скрытых слоях, а также решать задачи фильтрации, прогнозирования и классификации временных рядов. Также рассматривается возможность работы с мультимодальными выходными данными, что позволяет использовать метод в различных прикладных сценариях.

Основную задачу можно разделить на ряд подзадач:

1. Составление обучающего набора данных с их пред. Обработкой.
2. Разработка алгоритма извлечения признаков на базе нейронной сети и ее обучение.
3. Тестирование алгоритма и обсуждение результатов.

**Составление датасета и предварительная обработка данных.** Составление датасета состоит из 2х этапов, на первом этапе подготавливались синтетические данные на основе параметрических моделей сигналов и шума, на втором реальные отфильтрованные сигналы. Параметрическую модель сигнала можно представить следующим образом, вектор  $F$  является случайным вектором частот,  $\Phi$  – фаз,  $A$  – амплитуд,  $a(t)$  – синтезированный сигнал без шума, параметры  $k_{ш}$  и  $K$  также являются случайными,  $\xi$  – шум. На случайные векторы накладываются ограничения исходя из параметрических моделей сигналов, например сигнала ионного тока, моделей биомедицинских сигналов и пр.

$$F = [f_1, f_2, \dots, f_K], \quad (1)$$

$$\Phi = [\phi_1, \phi_2, \dots, \phi_K], \quad (2)$$

$$A = [a_1, a_2, \dots, a_K], \quad (3)$$

$$a(t) = \sum_{k=1}^K A_k \cdot \cos(2 \cdot \pi \cdot F_k + \phi_k), \quad (4)$$

$$s(t) = a(t) + \xi(t), \quad (5)$$

Для извлечения признаков данные обрабатываются следующим образом: сигнал  $s(t)$  нарезается на блоки по 130 отсчетов. Далее для задачи фильтрации на выходе восстанавливается отсчет  $a(t + 130 \cdot T)$ , где  $T$  – период дискретизации. Для задачи прогнозирования мы восстанавливаем отсчет  $s(t + 131 \cdot T)$ . При решении задачи классификации для каждого блока по 130 отсчетов вычисляются фиктивные классы, полученные при помощи алгоритма кластеризации на другом признаковом пространстве. Вычисляется спектральная плотность мощности каждого блока с последующей кластеризацией алгоритмом k-means на 15 кластеров. Для вычисления СПМ используется метод Уэлча с окном Блэкмана. Данная схема изображена на рис. 2.

**Описание алгоритма.** Алгоритм извлечения признаков состоит из блока предобработки сигнала и нейронной сети, архитектура которой приведена на рис. 3.

На вход модифицированного блока поступает исходный сигнал, объединенный с отраженным эмбедингом позиций. Позиция предыдущего состояния является наиболее важной для прогноза, ввиду чего кодирование позиций осуществляется в обратном порядке. Кроме

того, данный подход обладает лучшей обобщающей способностью относительно прямого кодирования, позволяя модели работать с отличающейся при обучении длиной контекста. Модификация блока, изображенного на рис. 4, заключается в добавлении нелинейного слоя, что позволяет выявлять сложные нелинейные зависимости в данных. Нелинейный слой, изображенный на рис. 5, состоит из двух линейных слоев с различными функциями активации для первого слоя, включая возведение в квадрат, синус, логарифм, квадратный корень, которые улучшают способность нейронной сети к обобщению и обучению.

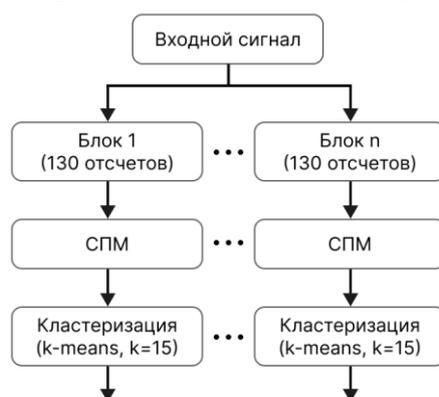


Рис. 2. Схема обработки данных

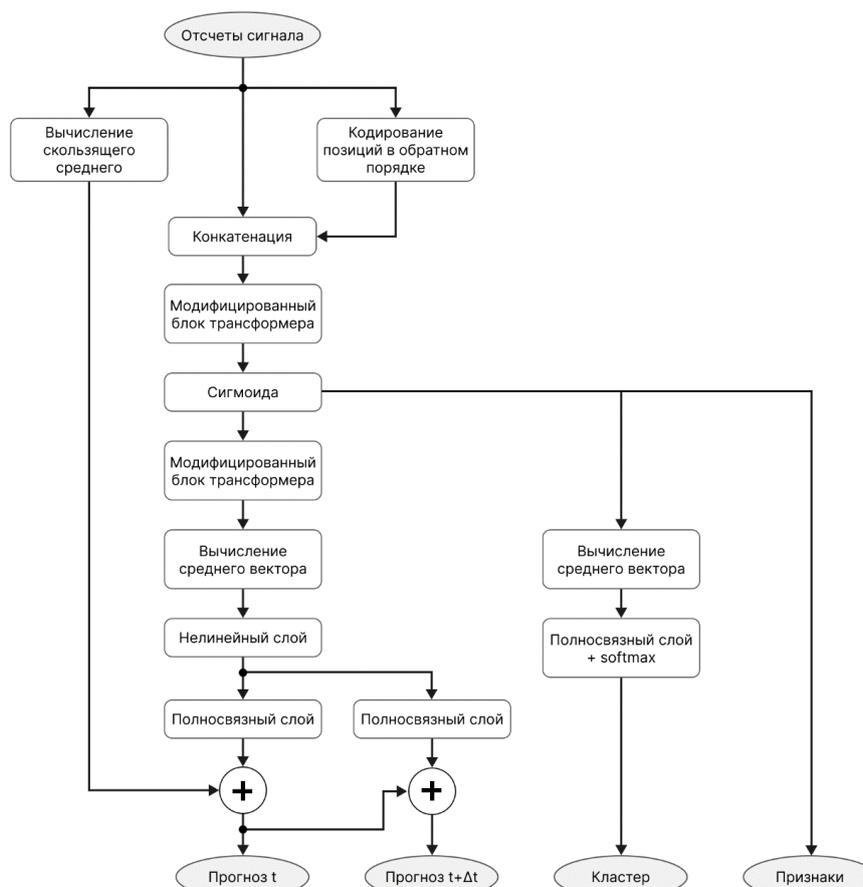


Рис. 3. Архитектура нейронной сети для извлечения признаков

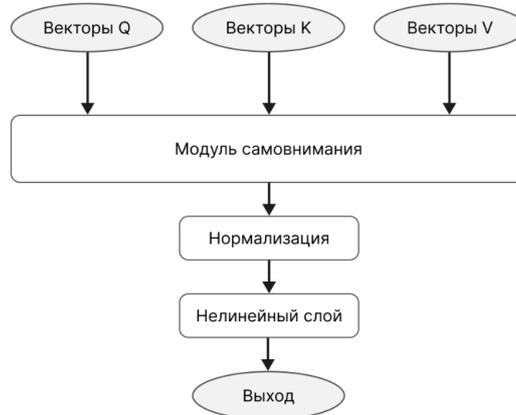


Рис. 4. Модифицированный блок трансформера

После чего, к модифицированному слою применяется сигмоидальная вектор-функция активации для извлечения признаков, участвующих в последующем решении задач прогнозирования, классификации и фильтрации.

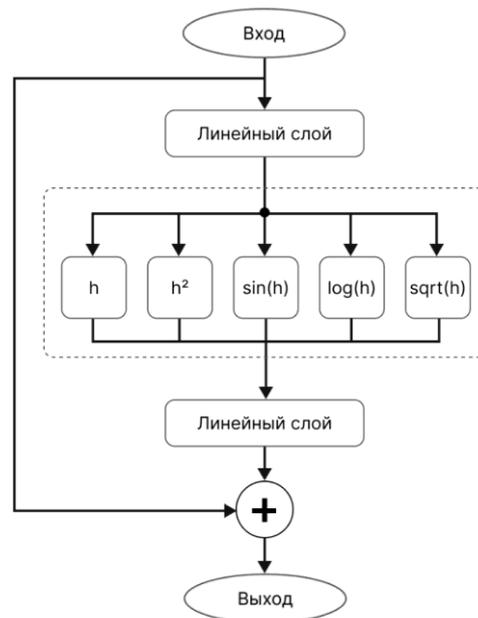


Рис. 5. Архитектура нелинейного слоя

Нелинейный слой реализует следующую функцию:

$$h = W_h \cdot x + B_h, \quad (6)$$

$$H = [h, h^2, \sin(h), \log(h), \text{sqrt}(h)]^T, \quad (7)$$

$$y = x + W_{out} \cdot H, \quad (8)$$

где  $x$  – вектор входа,  $h$  – выход скрытого слоя,  $W_h$  и  $B_h$  – матрица весовых коэффициентов и вектор смещения в скрытом слое соответственно,  $H$  – выход после расширения пространства признаков нелинейными функциями,  $y$  – выход нейронной сети,  $W_{out}$  – матрица весовых коэффициентов нелинейного слоя.

В выражении (6), вычисляется аргумент для нелинейных функций, в (7) вычисляются сами функции, а в выражении (8), то с какими весами их учитывать, данные слои можно соединять как последовательно, так и параллельно.

При необходимости кодирования в признаковом пространстве целостных мультимодальных образов, архитектуру, изображенную на рис. 3 можно масштабировать. На рис. 6 представлена алгоритм, способный обучаясь без учителя кодировать многоканальные сигналы и тексты одновременно в единый образ.

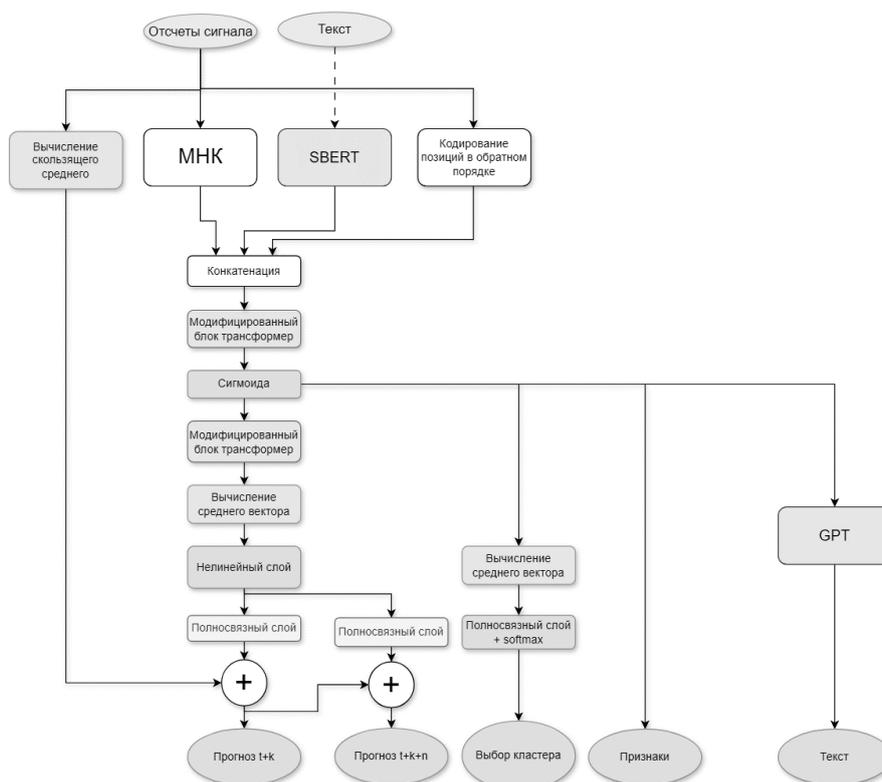


Рис. 6. Мультимодальная версия (кодирование многоканальных сигналов и текстов)

В текущей модификации возможна работа с многоканальными сигналами и текстами одновременно. На входе многоканальные сигналы обрабатываются при помощи метода независимых компонент (МНК), а текст с помощью SBERT. МНК используется для декорреляции многоканальных сигналов, этот метод также помогает уменьшить число каналов, аналогично тому, как метод главных компонент (МГК) применяют для уменьшения размерности пространства признаков. Декорреляция каналов в большинстве случаев ускоряет сходимость алгоритма обучения. SBERT используется для представления текста в виде вектора.

Выходы с МНК и SBERT конкатенируются и передаются в модифицированный блок трансформера, за которым следует слой представляющий собой сигмоидальную функцию активации. При таком подходе система кодирует признаки в скрытом слое, а выходы решают такие же задачи, как и основная архитектура (фильтрацию, прогнозирование и классификацию), кроме того, на выходе воссоздается входной текст, делается это при помощи архитектуры GPT-2, для генерации можно использовать предварительно обученную сеть GPT, например (для русского языка) `rugpt3small_based_on_gpt2`, также можно получать градиенты с выхода GPT для обучения модифицированного блока трансформера, который и производит извлечение признаков. Что позволяет обучить этот

блок кодировать и текстовую информацию, наряду с необходимыми данными для решения задач фильтрации, прогнозирования и классификации, формируя обобщенные, целостные мультимодальные образы в признаковом пространстве.

Процесс оптимизации нейронной сети включает в себя минимизацию ошибки прогнозирования, фильтрация и классификации, что приводит к формированию признаков на скрытом слое.

Изначально алгоритм извлечения признаков обучался на синтезированных данных. После предварительного обучения системы на синтетических данных, на втором этапе нейросеть может быть обучена на реальных сигналах. В таком случае полученный сигнал принимается за идеальный  $a(t)$ , а сигнал  $s(t)$ , вычисляется по формуле из выражения (5).

**Обсуждение результатов.** Для решения задачи регрессии, предсказания промежуточных значений сигнала, были протестированы 3 нейронные сети, двуслойная полносвязная сеть, двуслойная KAN [27] и два нелинейных слоя из данной работы. По метрике средний квадрат ошибки (MSE) (табл. 1) получены следующие результаты: 0.053 для полносвязной, 0.012 для KAN и 0.006 для данной архитектуры. Что показывает преимущество нелинейного слоя перед слоями KAN в решении вышеописанной задачи.

Ниже показаны примеры решения задач прогнозирования и фильтрации сигнала. На рис. 7 показан пример работы алгоритма на задаче фильтрации сигнала, до обучения сети, на рисунке виден сдвиг фазы и отсутствие ВЧ составляющей, основной вклад в фильтрацию вносит скользящее среднее, с АЧХ вида  $K(\omega) = \left| \frac{\sin(\omega k)}{\omega k} \right|$ .

Таблица 1

Сравнение моделей по метрикам качества

Метрика / Задача	Полносвязная сеть	KAN	Наша модель
MSE (регрессия)	0.053	0.012	<b>0.006</b>
R2 (фильтрация)	-	-	0.81
R2 (прогнозирование)	-	-	0.78
F1 (классификация)	-	-	0.91

Фильтрация сигнала представляет собой процесс удаления шума из исходного сигнала для восстановления его истинной формы. В данном случае целью было сравнение отфильтрованного сигнала с оригинальным сигналом без шума. Средняя метрика R2 для задачи фильтрации составила 0.81. Коэффициент детерминации (R2) измеряет степень соответствия предсказаний алгоритма реальным значениям. Значение 0.81 указывает на то, что 81% дисперсии в исходном сигнале без шума объясняется отфильтрованным сигналом.

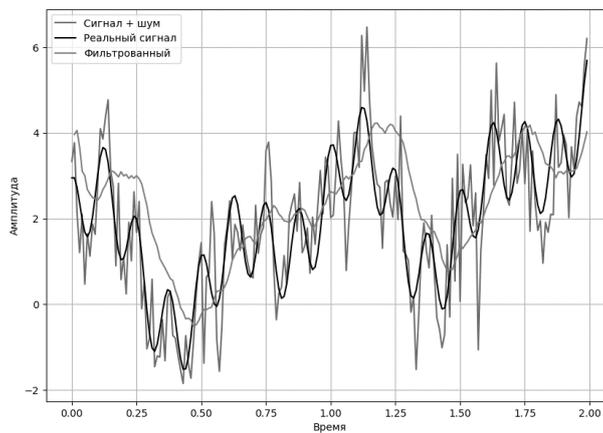


Рис. 7. Задача фильтрации сигнала, до обучения сети

После обучения нейронной сети был устранен фазовый сдвиг и добавлена ВЧ составляющая, результат представлен на рис. 8. На рис. 9, показан сигнал с шумом до фильтрации, на рис. 10 – после.

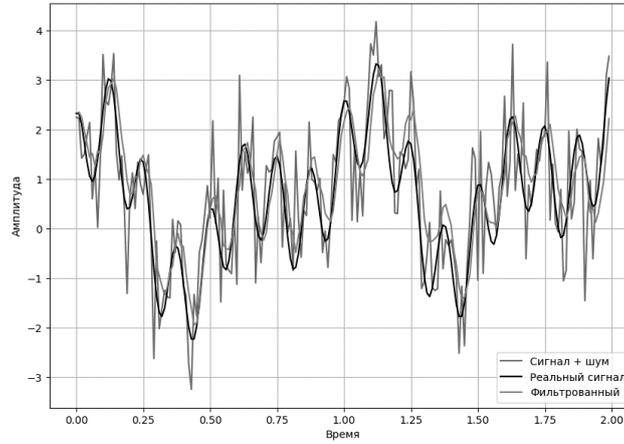


Рис. 8. Задача фильтрации сигнала, после обучения сети

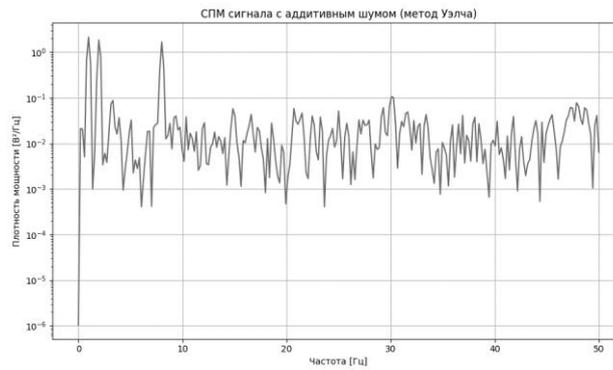


Рис. 9. Спектральная плотность мощности аддитивной смеси сигнала с шумом

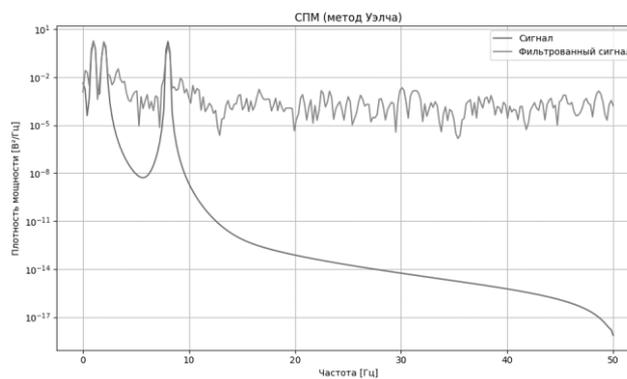


Рис. 10. Спектральная плотность мощности исходного и фильтрованного сигналов

На рис. 11 представлен результат работы на задаче прогнозирования сигнала. В данном случае прогнозируемый сигнал, это зашумленный сигнал нестационарный по мат. ожиданию (с трендом). На рис. 12, показано прогнозирование сигнала со сложным спектральным составом.

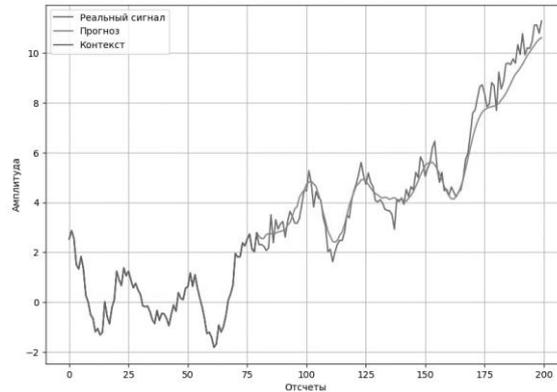


Рис. 11. Задача прогнозирования сигнала (нестационарный сигнал с линейным трендом)

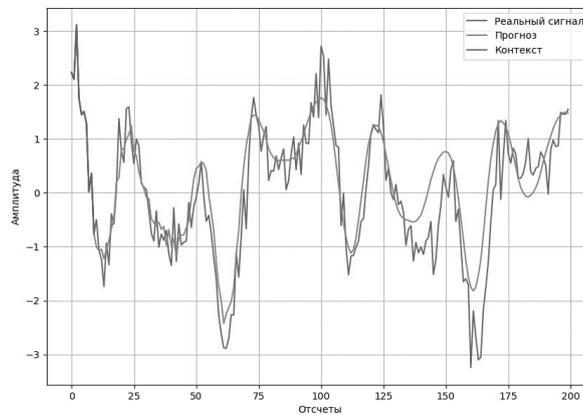


Рис. 12. Задача прогнозирования сигнала (нестационарный сигнал со сложным спектральным составом)

Средняя метрика R2 для задачи прогнозирования составила 0.78, что указывает на то, что 78% дисперсии в предсказанном сигнале объясняется реальными данными. Это является хорошим показателем, демонстрирующим способность модели эффективно предсказывать будущее поведение сигнала. Кроме того, F1-метрика для задачи классификации составила 0.91. F1-метрика представляет собой гармоническое среднее между точностью и полнотой, и значение 0.91 указывает на высокую точность и полноту классификации.

Таким образом, результаты, представленные на рис. 4 и 5, демонстрируют высокую эффективность алгоритмов в задачах фильтрации и прогнозирования сигналов. Средние значения метрик R2 и F1 подтверждают успешное выполнение поставленных задач, что свидетельствует о высокой точности и надежности разработанных методов.

**Заключение.** В данной статье подробно описан метод и алгоритм автоматического извлечения признаков из цифровых сигналов на базе нейросетей трансформер. В качестве задач для обучения алгоритма были выбраны задачи, которые возможно решать с помощью обучения без учителя, такие как задача прогнозирования, фильтрации предварительно зашумленного сигнала, а также классификации (где классы были получены при решении задачи кластеризации на другом признаковом пространстве, в данной работе использовались спектры)

Рассмотренная модификация архитектуры трансформера, включая добавление нелинейного слоя после модуля самовнимания, позволила значительно улучшить способность модели к выявлению сложных и нелинейных зависимостей в данных. Кодирование

позиций в обратной последовательности и разнообразие функций активации в нелинейном слое улучшили обобщающую способность модели. Также была рассмотрена модификация нейросети для работы с мультимодальными входами.

Были получены следующие результаты, для задачи фильтрации метрика R2 составила 0.81, для задачи прогнозирования 0.78, и для задачи классификации F1 мера 0.91. Также на задаче регрессии на сети из двух нелинейных слоев, описанных в данной работе, ошибка MSE составила 0.006, в то время как на двуслойной полносвязной сети 0.053, а на KAN 0.012.

Излеченные признаки с применением данного алгоритма могут быть использованы в последствии для классификации медицинских сигналов, таких как ЭЭГ, ЭКГ, речевой сигнал, данные сейсмографов и так далее. А также для предсказания параметров сигналов и систем, например, для выбора начальных условий при моделировании отраженного сигнала.

#### БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. *Галушкин А.И.* Синтез многослойных систем распознавания образов. – 1974. – 368 с.
2. *Jiang A. Q., Sablayrolles A., Roux A., Mensch A., Savary B., Bamford C., Singh Chaplot D., et al.* Mixtral of Experts. – URL: <https://arxiv.org/abs/2401.04088> (дата обращения: 22.10.2024).
3. *Bai J., Bai S., Chu Y., Cui Z., Dang K., Deng X., Fan Y., Ge W., et al.* Qwen Technical Report. – URL: <https://arxiv.org/abs/2309.16609> (дата обращения: 21.10.2024).
4. *Yang A., Yang B., Hui B., Zheng B., Yu B., Zhou C., Li C., Li C., Liu D., et al.* Technical Report. – URL: <https://arxiv.org/abs/2407.10671> (дата обращения: 21.10.2024).
5. *Mnih V., Badia A. P., Mirza M., Graves A., Lillicrap T. P., Harley T., Silver D., Kavukcuoglu K.* Asynchronous Methods for Deep Reinforcement Learning. – URL: <https://arxiv.org/abs/1602.01783> (дата обращения: 22.10.2024).
6. *Jin Y., Li D., A Y., Shi J., Hao P., Sun F., Zhang J., Fang B.* RobotGPT: Robot Manipulation Learning from ChatGPT. – URL: <https://arxiv.org/abs/2312.01421> (дата обращения: 19.10.2024).
7. *Fan A., Lewis M., Dauphin Y.* Hierarchical Neural Story Generation. – URL: <https://arxiv.org/abs/1805.04833> (дата обращения: 20.10.2024).
8. *Holtzman A., Buys J., Du L., Forbes M., Choi Y.* The Curious Case of Neural Text Degeneration. – URL: <https://arxiv.org/abs/1904.09751> (дата обращения: 20.10.2024).
9. *Meister C., Vieira T., Cotterell R.* If beam search is the answer, what was the question?. – URL: <https://arxiv.org/abs/2010.02650> (дата обращения: 21.10.2024).
10. *Liu Z., Wang Y., Vaidya S., Ruehle F., Halverson J., Soljacic M., Hou T. Y., Tegmark M.* KAN: Kolmogorov-Arnold Networks // arXiv preprint. – URL: <https://arxiv.org/abs/2404.19756> (дата обращения: 20.10.2024).
11. *Sinii V., Nikulin A., Kurenkov V., Zisman I., Kolesnikov S.* In-Context Reinforcement Learning for Variable Action Spaces // arXiv preprint. – URL: <https://arxiv.org/abs/2312.13327> (дата обращения: 22.10.2024).
12. *Понимаиш З.А.* Распознавание радиотехнических сигналов с помощью нейронных сетей. – URL: <https://habr.com/ru/articles/318832/> (дата обращения: 20.10.2024).
13. *Ахмед А.Ф., Абдуллах Х.Н., Албакер Б.М.* Классификация сигналов ЭКГ на основе цифровой обработки сигналов, технического выбора функций и радиочастотного классификатора // RENSIT/РЭНСИТ. – 2024. – Т. 16, № 1. – DOI: 10.17725/rensit.2024.16.053.
14. *Дейч А.М.* Методы идентификации динамических объектов. – 1979.
15. *McLean S.M.* Fast algorithms for linear prediction and system identification filters with linear phase // IEEE Transactions on Acoustics, Speech, and Signal Processing. – 1982. Dec. – DOI: 10.1109/TASSP.1982.1163987.
16. *Алексеев Д.М., Шумилин А.С., Минюк А.Н., Понимаиш З.А.* Система автоматического поиска участков эпилептической активности в составе облачной платформы хранения, систематизации и обработки медицинских данных // Современные наукоемкие технологии. – 2019. – Режим доступа: <http://www.top-technologies.ru/ru/article/view?id=37371> (дата обращения: 18.06.2024).
17. *Алексеев Д.М., Шумилин А.С., Минюк А.Н., Понимаиш З.А.* Ансамбль классификаторов: реализация, оценка эффективности и интеграция в облачную платформу хранения, систематизации и обработки медицинских данных // Современные наукоемкие технологии. – 2019. – № 9. – С. 20-25.
18. *Алексеев Д.М., Минюк А.Н., Понимаиш З.А., Шумилин А.С.* Разработка и описание структуры и функционала облачной платформы хранения, систематизации и обработки медицинских данных: интеграция системы автоматического поиска участков эпилептической активности // Системы управления и информационные технологии. – 2019. – № 3 (77). – С. 52-55.

19. *Shilian Zheng, Xiaoyu Zhou, Shichuan Chen, Peihan Qi, and Xiaoniu Yang*. DemodNet: Learning Soft Demodulation from Hard Information Using Convolutional Neural Network. – 2020.
20. *Zahorian S.A., Zimmer A.M., and Meng F.* Vowel Classification for Computer based Visual Feedback for Speech Training for the Hearing Impaired in ICSLP. – 2002.
21. *Понимаи З.А.* Разработка алгоритма классификации сигналов на основе нейронных сетей. – 2018. – Режим доступа: <https://hub.lib.sfedu.ru/repository/material/800841304/> (дата обращения: 18.06.2024).
22. *Fernandez, Santiago, Graves Alex, Schmidhuber Jürgen*. Sequence labelling in structured domains with hierarchical recurrent neural networks // Proceedings of IJCAI. – 2007.
23. *Turker I., Serkan K., Levent E., Askar M., Gabbouj M.* Real-Time Motor Fault Detection by 1D Convolutional Neural Networks // IEEE Transactions on Industrial Electronics. – 2016.
24. *Yihong D., Ying P., Muqiao Y., Songtao L., Qingjiang S.* Signal Transformer: Complex-valued Attention and Meta-Learning for Signal Recognition. – <https://doi.org/10.48550/arXiv.2106.04392>. – 2021. – Режим доступа: <https://arxiv.org/abs/2106.04392> (дата обращения: 18.06.2024).
25. *Jiang Albert Q., Sablayrolles Alexandre, Mensch Arthur, Bamford Chris, Devendra Singh Chaplot, Diego de las Casas, et al.* Mistral 7B. 10.10.23. – <https://doi.org/10.48550/arXiv.2310.06825> (дата обращения: 18.06.2024).
26. *Понимаи З.А., Носко В.И.* Алгоритм ранжирования текстов на базе сверточной нейронной сети // Матер. Всероссийской научно-технической конференции с международным участием: в 2 т. – Ростов-на-Дону; Таганрог: Изд-во ЮФУ, 2022.
27. *Ziming Liu, Yixuan Wang, Sachin Vaidya, Fabian Ruehle, James Halverson, Marin Soljačić, Thomas Y. Hou, Max Tegmark*. KAN: Kolmogorov-Arnold Networks. – <https://doi.org/10.48550/arXiv.2404.19756>. 2021. – Режим доступа: <https://arxiv.org/abs/2404.19756> (дата обращения: 25.10.2024).

## REFERENCES

1. *Galushkin A.I.* Sintez mnogosloynnykh sistem raspoznavaniya obrazov [Synthesis of multilayer systems for pattern recognition], 1974, 368 p.
2. *Jiang A.Q., Sablayrolles A., Roux A., Mensch A., Savary B., Bamford C., Singh Chaplot D., et al.* Mixtral of Experts. Available at: <https://arxiv.org/abs/2401.04088> (accessed 22 October 2024).
3. *Bai J., Bai S., Chu Y., Cui Z., Dang K., Deng X., Fan Y., Ge W., et al.* Qwen Technical Report. Available at: <https://arxiv.org/abs/2309.16609> (accessed 21 October 2024).
4. *Yang A., Yang B., Hui B., Zheng B., Yu B., Zhou C., Li C., Li C., Liu D., et al.* Technical Report. Available at: <https://arxiv.org/abs/2407.10671> (accessed 21 October 2024).
5. *Mnih V., Badia A. P., Mirza M., Graves A., Lillicrap T. P., Harley T., Silver D., Kavukcuoglu K.* Asynchronous Methods for Deep Reinforcement Learning. Available at: <https://arxiv.org/abs/1602.01783> (accessed 22 October 2024).
6. *Jin Y., Li D., A Y., Shi J., Hao P., Sun F., Zhang J., Fang B.* RobotGPT: Robot Manipulation Learning from ChatGPT. Available at: <https://arxiv.org/abs/2312.01421> (accessed 19 October 2024).
7. *Fan A., Lewis M., Dauphin Y.* Hierarchical Neural Story Generation. Available at: <https://arxiv.org/abs/1805.04833> (accessed 20 October 2024).
8. *Holtzman A., Buys J., Du L., Forbes M., Choi Y.* The Curious Case of Neural Text Degeneration. Available at: <https://arxiv.org/abs/1904.09751> (accessed 20 October 2024).
9. *Meister C., Vieira T., Cotterell R.* If beam search is the answer, what was the question?. Available at: <https://arxiv.org/abs/2010.02650> (accessed 21 October 2024).
10. *Liu Z., Wang Y., Vaidya S., Ruehle F., Halverson J., Soljacic M., Hou T. Y., Tegmark M.* KAN: Kolmogorov-Arnold Networks, *arXiv preprint*. Available at: <https://arxiv.org/abs/2404.19756> (accessed 20 October 2024).
11. *Sinii V., Nikulin A., Kurenkov V., Zisman I., Kolesnikov S.* In-Context Reinforcement Learning for Variable Action Spaces, *arXiv preprint*. Available at: <https://arxiv.org/abs/2312.13327> (accessed 22 October 2024).
12. *Ponimash Z.A.* Raspoznavanie radiotekhnicheskikh signalov s pomoshch'yu neyronnykh setey [Recognition of radio-technical signals using neural networks]. Available at: <https://habr.com/ru/articles/318832/> (accessed 20 October 2024).
13. *Akhmed A.F., Abdullakh Kh.N., Albaker B.M.* Klassifikatsiya signalov EKG na osnove tsifrovoy obrabotki signalov, tekhnicheskogo vybora funktsiy i radiochastotnogo klassifikatora [ECG Signal Classification Based on Digital Signal Processing, Feature Selection, and Radio Frequency Classifier], *RENSIT/RENSIT* [RENSIT], 2024, Vol. 16, No. 1. DOI: 10.17725/rensit.2024.16.053.
14. *Deych A.M.* Metody identifikatsii dinamicheskikh ob"ektov [Methods for identifying dynamic objects], 1979.

15. *McLean S.M.* Fast algorithms for linear prediction and system identification filters with linear phase, *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 1982. Dec. DOI: 10.1109/TASSP.1982.1163987.
16. *Alekseev D.M., Shumilin A.S., Minyuk A.N., Ponimash Z.A.* Sistema avtomaticheskogo poiska uchastkov epilepticheskoy aktivnosti v sostave oblachnoy platformy khraneniya, sistematizatsii i obrabotki meditsinskikh dannykh [Automatic search system for epileptic activity areas as part of a cloud platform for storing, systematizing and processing medical data], *Sovremennye naukoemkie tekhnologii* [Modern science-intensive technologies], 2019. Available at: <http://www.top-technologies.ru/ru/article/view?id=37371> (accessed 18 June 2024).
17. *Alekseev D.M., Shumilin A.S., Minyuk A.N., Ponimash Z.A.* Ansambli' klassifikatorov: realizatsiya, otsenka effektivnosti i integratsiya v oblachnyuyu platformu khraneniya, sistematizatsii i obrabotki meditsinskikh dannykh [Ensemble of classifiers: implementation, efficiency evaluation and integration into a cloud platform for storing, systematizing and processing medical data], *Sovremennye naukoemkie tekhnologii* [Modern science-intensive technologies], 2019, No. 9, pp. 20-25.
18. *Alekseev D.M., Minyuk A.N., Ponimash Z.A., Shumilin A.S.* Razrabotka i opisaniye struktury i funktsionala oblachnoy platformy khraneniya, sistematizatsii i obrabotki meditsinskikh dannykh: integratsiya sistemy avtomaticheskogo poiska uchastkov epilepticheskoy aktivnosti [Development and description of the structure and functionality of a cloud platform for storing, systematizing and processing medical data: integration of a system for automatic search for areas of epileptic activity], *Sistemy upravleniya i informatsionnye tekhnologii* [Control Systems and Information Technologies], 2019, No. 3 (77), pp. 52-55.
19. *Shilian Zheng, Xiaoyu Zhou, Shichuan Chen, Peihan Qi, and Xiaoniu Yang.* DemodNet: Learning Soft Demodulation from Hard Information Using Convolutional Neural Network, 2020.
20. *Zahorian S.A., Zimmer A.M., and Meng F.* Vowel Classification for Computer based Visual Feedback for Speech Training for the Hearing Impaired in ICSLP, 2002.
21. *Ponimash Z.A.* Razrabotka algoritma klassifikatsii signalov na osnove neyronnykh setey [Development of a signal classification algorithm based on neural networks], 2018. Available at: <https://hub.lib.sfedu.ru/repository/material/800841304/> (accessed 18 June 2024).
22. *Fernandez, Santiago, Graves Alex, Schmidhuber Jürgen.* Sequence labelling in structured domains with hierarchical recurrent neural networks, *Proceedings of IJCAI*, 2007.
23. *Turker I., Serkan K., Levent E., Askar M., Gabbouj M.* Real-Time Motor Fault Detection by 1D Convolutional Neural Networks, *IEEE Transactions on Industrial Electronics*, 2016.
24. *Yihong D., Ying P., Muqiao Y., Songtao L., Qingjiang S.* Signal Transformer: Complex-valued Attention and Meta-Learning for Signal Recognition. <https://doi.org/10.48550/arXiv.2106.04392>, 2021. Available at: <https://arxiv.org/abs/2106.04392> (accessed 18 June 2024).
25. *Jiang Albert Q., Sablayrolles Alexandre, Mensch Arthur, Bamford Chris, Devendra Singh Chaplot, Diego de las Casas, et al.* Mistral 7B. 10.10.23. Available at: <https://doi.org/10.48550/arXiv.2310.06825> (accessed 18 June 2024).
26. *Ponimash Z.A., Nosko V.I.* Algoritm ranzhirovaniya tekstov na baze svertochnoy neyronnoy seti [Text ranking algorithm based on a convolutional neural network], *Mater. Vserossiyskoy nauchno-tekhnicheskoy konferentsii s mezhunarodnym uchastiem* [Proceedings of the All-Russian scientific and technical conference with international participation]: in 2 vol. Rostov-on-Don; Taganrog: Izd-vo YuFU, 2022.
27. *Ziming Liu, Yixuan Wang, Sachin Vaidya, Fabian Ruehle, James Halverson, Marin Soljačić, Thomas Y. Hou, Max Tegmark.* KAN: Kolmogorov-Arnold Networks. <https://doi.org/10.48550/arXiv.2404.19756>. 2021. Available at: <https://arxiv.org/abs/2404.19756> (accessed 25 October 2024).

**Понимаш Захар Алексеевич** – Южный федеральный университет; e-mail: [ponimashz@mail.ru](mailto:ponimashz@mail.ru); г. Таганрог, Россия; тел.: +79885464739; аспирант; генеральный директор ООО «ФракталТех».

**Потанин Марат Владимирович** – МИРЭА - Российский технологический университет; e-mail: [potaninmt@mail.ru](mailto:potaninmt@mail.ru); г. Москва, Россия; тел.: +79777999950; магистрант.

**Ponimash Zahar Alekseevich** – Southern Federal University; e-mail: [ponimashz@mail.ru](mailto:ponimashz@mail.ru); Taganrog, Russia; phone: +79885464739; graduate student; general director of FractalTech LLC.

**Potinin Marat Vladimirovich** – MIREA – Russian Technological University; e-mail: [potaninmt@mail.ru](mailto:potaninmt@mail.ru); Moscow, Russia; phone: +79777999950; master's student.