

ИДЕЯ, ОСНОВНЫЕ РАЗРАБОТКИ И ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ. КОЛМОГорова-АРНОЛЬДА: АНАЛИТИЧЕСКИЙ ОБЗОР

Адылова Фатима Туйчиевна

*Институт математики им. В. И. Романовского АН Республики Узбекистан,
доктор технических наук, профессор, руководитель лаборатории*

fatadilova@gmail.com

Аннотация: Сети Колмогорова-Арнольда (KANs) стали многообещающим достижением в области нейронных сетей, предлагая улучшенную интерпретируемость, эффективность и адаптивность. В этом обзоре рассматриваются различные области применения и разработки KANs которые подчеркивают универсальность и потенциал KANs в улучшении различных приложений машинного обучения. Будущие исследования будут сосредоточены на дальнейшем совершенствовании этих архитектур и изучении их пригодности для различных наборов данных и задач.

Ключевые слова: Сети Колмогорова-Арнольда, прогнозирование временных рядов, классификация изображений, обработка естественного языка.

KOLMOGOROV-ARNOLD NEYRON TARMOQLARI (KANs) NING G'UYASI, ASOSIY ISHLANMALARI VA QO'LLANILISHI: TAHLILIIY SHARH

Adilova Fatima Tuychiyevna

*V. I. Romanovski nomidagi O'zbekiston Respublikasi Fanlar Akademiyasi
Matematika instituti, texnika fanlari doktori, professor, laboratoriya mudiri*

fatadilova@gmail.com

Annotatsiya: Kolmogorov-Arnold tarmoqlari (KANs) neyron tarmoqlar sohasida istiqbolli yutuq sifatida tan olinib, yaxshilangan tushunarlilik, samaradorlik va moslashuvchanlikni taqdim etmoqda. Ushbu sharhda KANs tarmoqlarining turli ishlanmalari va ularning qo'llanilish sohalari ko'rib chiqilgan bo'lib, ularning mashinani o'rganishning turli dasturlarini yaxshilashdagi universalligi va salohiyati ta'kidlanadi. Kelgusidagi tadqiqotlar ushbu arxitekturalarni yanada takomillashtirish va ularning turli ma'lumotlar to'plamlari va vazifalaridagi qo'llanilishlarini o'rganishga yo'naltiriladi.

Kalit so‘zlar: *Kolmogorov-Arnold tarmoqlari, vaqt qatorlarini bashorat qilish, tasvirlarni tasniflash, tabiiy tilni qayta ishlash.*

THE IDEA, MAIN DESIGN AND APPLICATION OF KOLMOGOROV-ARNOLD NEURAL NETWORKS: AN ANALYTICAL REVIEW

Adilova Fatima Tuychievna

V. I. Romanovsky Institute of Mathematics of the Academy of Sciences of the Republic of Uzbekistan, Doctor of Technical Sciences, Professor, Head of the laboratory

fatadilova@gmail.com

Abstract: Kolmogorov-Arnold networks (KANs) have become a promising achievement in the field of neural networks, offering improved interpretability, efficiency and adaptability. This review examines the various application and development areas of KANs, which highlight the versatility and potential of KANs in improving various machine learning applications. Future research will focus on further improving these architectures and exploring their suitability for various datasets and tasks.

Keywords: *Kolmogorov-Arnold networks, time series forecasting, image classification, natural language processing.*

ВВЕДЕНИЕ

Эксперты [1] полагают, что возможности современного ИИ сильно ограничены, и без революционного прорыва предел потенциала ИИ будет достигнут в ближайшее время. Проблема стала особенно заметна после ряда неудач с крупнейшими моделями OpenAI (Orion) и Anthropic (3.5 Opus). Если сравнивать Orion и GPT-4, то можно сделать вывод, что GPT-4 действительно стала большим шагом вперёд по сравнению с GPT-3.5, однако Orion ничего подобного не предлагает. Anthropic столкнулась с аналогичными препятствиями на пути к значительным достижениям, поскольку новая 3.5 Opus не смогла оправдать амбициозные ожидания. Это особенно разочаровало специалистов, учитывая огромные ресурсы, затраченные на её разработку. Опыт обеих компаний ставит под сомнение представление о том, что увеличение объёма данных и вычислительных мощностей неизменно приводит к технологическому прогрессу.

Бесспорно, что доминирующей на данный момент архитектурой ИИ в области Deep Learning являются трансформеры. Сегодня они используются почти во всех фундаментальных моделях, от Mistral до ChatGPT. Главной проблемой оригинального трансформера является квадратичная вычислительная

сложность алгоритма, из-за чего с ростом размера входной последовательности сильно увеличиваются требования к вычислительным мощностям и памяти. В ответ на этот вызов, в декабре 2023 года была представлена научная работа и архитектура Mamba, которая доказала свою жизнеспособность, а количество её улучшений и попыток объединения с трансформерами (например: Jamba, FalconMamba) растёт с каждым днём [2].

Одним из недавних достижений также является внедрение сетей Колмогорова-Арнольда (KAN). Доказательно обоснованные теоремой представления Колмогорова-Арнольда, KAN стали многообещающей альтернативой традиционным многослойным персептронам (MLP), в отличие от которых имеют фиксированные функции активации в узлах ("нейронах") и обучаемые функции активации на ребрах ("веса"). Это означает, что каждый весовой параметр заменяется одномерной функцией, параметризованной в виде сплайна.

Основными преимуществами KAN являются их интерпретируемость, повышенная точность, эффективность и адаптивность. KAN разработаны так, чтобы отображать более сложные паттерны, иметь меньше шансов на переобучение, лучше справляться с обобщением данных обучения на незнакомые данные.

Целью настоящего аналитического обзора является показать преимущества сетей Колмогорова-Арнольда и области их практического применения. Структура статьи включает три основных раздела: достоинства KAN, виды разных архитектур, их применения, обсуждение ограничений KAN, направления развития KAN.

АНАЛИЗ ЛИТЕРАТУРЫ

Данная статья опирается на несколько публикаций, но, в основном, на статью [3], в которой с помощью динамического графа знаний платформы Vitmaps выделили оригинальные статьи по трендовым исследованиям и новые тенденции развития ключевых концепций и методов в области KAN. Граф знаний выявил статьи о сетях Колмогорова-Арнольда и их различных приложениях, изучив цитируемость, новизну и даты публикаций. Теория и основы приложений KAN подробно изложены в [4,5]. Здесь еще раз отметим, что с точки зрения глубокого обучения KAN,- класс архитектур нейронных сетей, которые основаны на теореме Колмогорова-Арнольда (<https://danielbethell.co.uk/posts/kan/>). В отличие от MLP, которые используют фиксированные функции активации на узловом уровне, они могут использовать обучаемые функции активации на уровне ребер. Это означает, что у KAN каждый весовой

параметр заменяется одномерной функцией, которая параметризуется в виде сплайна. На рисунке 1 приведено принципиальное отличие KAN от MLP.

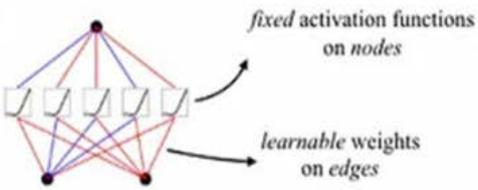
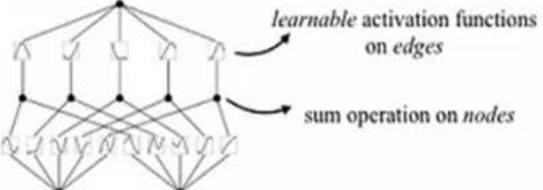
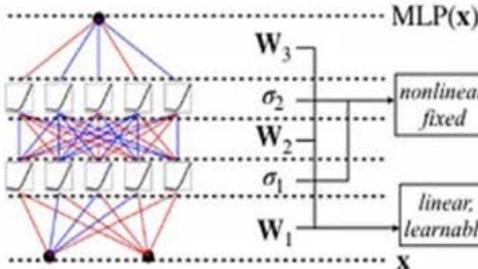
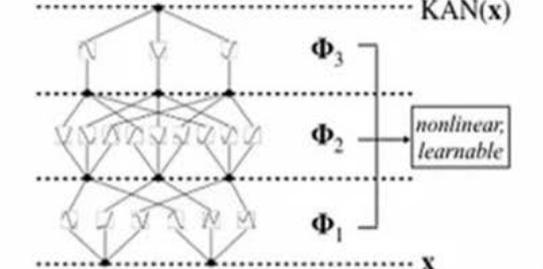
Model	Multi-Layer Perceptron (MLP)	Kolmogorov-Arnold Network (KAN)
Theorem	Universal Approximation Theorem	Kolmogorov-Arnold Representation Theorem
Formula (Shallow)	$f(x) \approx \sum_{i=1}^{N(c)} a_i \sigma(w_i \cdot x + b_i)$	$f(x) = \sum_{q=1}^{2n+1} \Phi_q \left(\sum_{p=1}^n \phi_{q,p}(x_p) \right)$
Model (Shallow)	(a) 	(b) 
Formula (Deep)	$\text{MLP}(x) = (W_3 \circ \sigma_2 \circ W_2 \circ \sigma_1 \circ W_1)(x)$	$\text{KAN}(x) = (\Phi_3 \circ \Phi_2 \circ \Phi_1)(x)$
Model (Deep)	(c) 	(d) 

Рисунок 1. Сравнение MLP и KAN [6]

Преимущества KAN

Интерпретируемость: одним из ключевых преимуществ сетей KAN является их интерпретируемость. В отличие от традиционных нейронных сетей, KAN можно интуитивно визуализировать, что облегчает понимание того, как они делают прогнозы. Кроме того, KAN может взаимодействовать с пользователями-людьми осмысленным образом. В области символьной регрессии KAN могут помочь ученым открывать новые математические законы: визуализируя и интерпретируя функции в KAN, ученые могут получить представление о математических взаимосвязях, лежащих в основе их данных.

Повышенная точность и эффективность: нейронные сети KAN продемонстрировали способность обеспечивать высокую точность в различных задачах, превосходя традиционные нейронные сети. Это во многом объясняется их уникальной архитектурой, которая позволяет с большей эффективностью фиксировать сложные закономерности и взаимосвязи в данных. Кроме того, KAN способны достигать сопоставимой или превосходящей производительности при меньшем количестве параметров по сравнению с традиционными нейронными сетями.

Адаптивность: KAN обладают высокой степенью адаптивности и их

можно применять для решения широкого спектра задач, включая прогнозирование временных рядов, классификацию изображений, обработку естественного языка и квантовые вычисления. Эта адаптивность делает KAN универсальным инструментом в области машинного обучения.

Сравнение с традиционными нейронными сетями: По сравнению с традиционными нейронными сетями, такими как многослойный персептрон, KAN обладают рядом преимуществ. Как упоминалось выше, они более интерпретируемы, точны, эффективны и адаптируемы. Более того, использование обучаемых функций активации на ребрах представляет собой значительный отход от традиционных нейронных сетей, которые обычно используют фиксированные функции активации. KAN представляют собой значительный шаг вперед в архитектуре нейронных сетей, предлагая ряд преимуществ по сравнению с традиционными моделями. Их интерпретируемость, повышенная точность и эффективность, а также адаптивность делают их перспективным инструментом для широкого спектра применений в машинном обучении и искусственном интеллекте.

Применение KAN. Прогнозирование временных рядов

В статье [7] исследуется применение двух вариантов KAN для прогнозирования временных рядов: T-KAN и MT-KAN. T-KAN предназначен для обнаружения смещения во временных рядах и может объяснить нелинейные взаимосвязи между прогнозами и предыдущими временными шагами с помощью символической регрессии, что делает его легко интерпретируемым в динамично меняющихся условиях. С другой стороны, MT-KAN повышает эффективность прогнозирования за счет эффективного выявления и использования сложных взаимосвязей между переменными в многомерных временных рядах.

Для экспериментов использовали набор данных финансовых временных рядов из-за их сложности и непредсказуемости, высокой волатильности и отсутствия постоянной периодичности. Этот набор данных содержит ежедневные данные OCLV (open, high, close, low, volume) за период с 4 января 2012 года по 22 июня 2022 года (<https://ca.finance.yahoo.com/>). Основной целью было предсказать предполагаемую волатильность каждой акции, но поскольку истинную волатильность невозможно наблюдать непосредственно, её аппроксимировали реализованной волатильностью. Как T-KAN, так и MT-KAN реализованы с использованием параметризации на основе сплайнов для одномерных функций. Для наборов данных брали 21-ступенчатое окно с четырьмя такими окнами (всего 84 шага) в качестве входных данных для прогнозирования волатильности на следующие 21 день. Структуру сети строили по оригиналу статьи KAN: простая двухслойная архитектура с 5 скрытыми

нейронами, т.е. [84, 5, 21]. Для MT-KAN группируют 5 переменных для ввода, в результате чего получается структура [84*5, 5, 21*5]. Такая конфигурация позволяет MT-KAN более эффективно моделировать и прогнозировать взаимосвязи между несколькими временными рядами. Количество этапов обучения приняли равным 20, за которыми следует этап сокращения с пороговым значением 5×10^{-2} , а затем еще 20 итераций обучения. Модели сравнили с классическими моделями, включая MLP], RNN и LSTM. Эта стратегия позволяет нам лучше оценить повышение производительности KAN по сравнению с хорошо зарекомендовавшими себя архитектурами прогнозирования временных рядов. Общепринятые показатели оценки включают среднеквадратичную ошибку (MSE), среднюю абсолютную ошибку (MAE) и среднеквадратичную ошибку корня (RMSE). В таблице 1 приведены результаты эксперимента.

Таблица 1

Сравнение эффективности прогнозирования моделями T-KAN, MT-KAN с базовыми моделями машинного обучения [7]

Модель	Конфигурация	MSE	MAE	RMSE	Параметры
MLP	[84,5,21]	0.0465	0.1774	0.2141	551
MLP	[84,50,21]	0.0002	0.0122	0.0157	5321
MLP	[84,200,21]	<u>8.92e-5</u>	0.0072	0.0088	21221
MLP	[84,5,5,21]	0.0504	0.1798	0.2230	581
MLP	[84,50,50,21]	0.0001	0.0103	0.0130	7871
RNN	[84,5,21]	0.0541	0.1737	0.2282	166
RNN	[84,50,21]	0.0001	0.0079	0.0098	3721
RNN	[84,200,21]	<u>8.03e-5</u>	<u>0.0069</u>	0.0083	44821
RNN	[84,5,5,21]	0.0497	0.1691	0.2185	226
RNN	[84,50,50,21]	0.0001	0.0079	0.0098	8821
LSTM	[84,5,21]	0.0132	0.0737	0.1105	286
LSTM	[84,50,21]	<u>6.69e-5</u>	<u>0.0066</u>	<u>0.0078</u>	11671
LSTM	[84,200,21]	<u>6.52e-5</u>	<u>0.0064</u>	<u>0.0075</u>	166621
LSTM	[84,5,5,21]	0.0136	0.0777	0.1124	526
LSTM	[84,50,50,21]	<u>6.67e-5</u>	<u>0.0066</u>	<u>0.0076</u>	32071
T-KAN	[84,5,21]	<u>6.91e-5</u>	<u>0.0069</u>	<u>0.0078</u>	193
MT-	[84*5,5,21*5]	6.37e-5	0.0062	0.0075	2132

Из таблицы 1 видно, что с точки зрения количества параметров эффективность моделей, основанных на KAN, очевидна. Например, у T-KAN всего 193 параметра, что значительно меньше, чем у сопоставимой модели LSTM с конфигурацией [84, 50, 21], которая имеет 11 671 параметр. Аналогично, MT-KAN с его конфигурацией [84*5, 5, 21*5] превосходит другие модели по производительности при использовании 2132 параметров. Это доказывает тот факт, что модели на базе KAN могут достигать высокой точности при меньшем

количестве параметров. Однако, реализация KAN обычно требует в 10 раз больше времени для обучения по сравнению с MLP с таким же количеством параметров. Эта неэффективность возникает из-за того, что различные функции активации KAN не могут в полной мере использовать пакетную обработку.

Fast KAN

Для того, снять этот недостаток, Z. Li [8] заменил B-сплайны 3-го порядка гауссовыми радиальными базисными функциями. В результате появился FastKAN, работающий значительно быстрее, чем оригинальный KAN. Подчеркнем, что Fast KAN представляет собой усовершенствование KAN за счет использования особого функционального подхода, который создал еще один вид нейронной сети.

Wav-KAN

Wav-KAN - новый тип нейронной сети, который улучшает методы изучения и понимания данных [9]. Традиционные модели обучения не всегда отличаются четкостью, скоростью и эффективностью. Wav-KAN решает эти проблемы с помощью вейвлет-функций - математических инструментов, которые разбивают данные на различные частотные составляющие. Это позволяет нейронной сети сосредоточиться как на важных деталях, так и на общих тенденциях в данных:

- Вейвлеты: работают как зум-объектив, фиксируя как общую картину, так и мелкие детали;
- Эффективность: Wav-KAN быстрее и разумнее извлекает уроки из данных, избегая ненужной сложности;
- Адаптивность: Wav-KAN приспосабливается к структуре данных;
- Потенциал: Этот подход может привести к созданию более совершенных и понятных систем искусственного интеллекта в различных отраслях.

Эффективность вейвлет-сети Колмогорова-Арнольда в управлении данными большой размерности и четкое понимание поведения модели делают его перспективным инструментом для широкого спектра применений, начиная от научных исследований и заканчивая промышленным внедрением. В таблице 2 обобщены основные преимущества сетей TKAN для обработки временных рядов.

Таблица 2

Основные характеристики TKAN [3]

Свойство	Описание
Повышенная точность и эффективность	TKAN предназначены для многоступенчатого прогнозирования временных рядов, что обеспечивает повышенную точность и эффективность.

Управление памятью	ТКАН включают в свою архитектуру управление памятью, что имеет решающее значение для обработки последовательных данных. Эта функция позволяет фиксировать долгосрочные зависимости в данных.
Адаптивность	ТКАН может адаптироваться к структуре данных, что приводит к более высокой скорости обучения и повышению надежности по сравнению с традиционными RNN.
Интерпретируемость	ТКАН применяет функции активации к соединениям между узлами. Эти функции могут обучаться и адаптироваться во время обучения, что делает ТКАН более понятными, чем традиционные RNN.

DeepOKAN

DeepOKAN представляет собой новую версию нейронных операторов, разработанных для вычислительной механики. Отличительной особенностью DeepOKAN является использование гауссовых радиальных базисных функций (RBF) вместо B-сплайнов. Эта модификация привела к заметному увеличению скорости вычислений при сохранении эффективности и точности модели. Было замечено, что для достижения сопоставимой точности в DeepOKANs требуется меньше обучаемых параметров, чем в современных сетях DEEPONET на основе MLP. Этот подход особенно полезен в современном цифровом инженерном проектировании, которое часто требует дорогостоящего повторного моделирования для различных сценариев. Способность нейронных сетей делать прогнозы делает их подходящими заменителями для получения информации о качестве проекте. Тем не менее, лишь немногие нейронные сети способны эффективно обрабатывать сложные инженерные сценарии. DeepOKAN - один из таких сетей [10].

KAN в обработке изображений

Набор данных EuroSAT M.Cheon [11] предлагает новый подход к интеграции сети KAN с различными предварительно обученными сверточными нейронными сетями (CNN) для задач классификации сцен дистанционного зондирования с использованием набора данных EuroSAT. Методология предназначена для замены традиционных MLP на KAN с целью повышения эффективности классификации. Были использованы различные модели на базе CNN, включая VGG16, MobileNetV2, EfficientNet, ConvNeXt, ResNet101 и Vision Transformer (ViT), и их производительность была оценена в сочетании с KAN. Используемые наборы данных из EuroSAT показаны на рисунке 2.



Рисунок 2. Примеры наборов данных из EuroSAT, использованных в эксперименте [11]

Эксперименты показали, что сеть KAN достигла высокой точности при меньшем количестве периодов обучения и параметров, чем другие модели. В частности, модель ConvNeXt в сочетании с KAN продемонстрировала наиболее высокую производительность, достигнув точности в 94% в начальную эпоху, которая увеличилась до 96% и оставалась неизменной в последующие эпохи.

Использование набора данных EuroSAT предоставило надежный испытательный стенд для исследования пригодности KAN для задач классификации с помощью дистанционного зондирования. Это исследование особенно актуально в контексте стремительного развития спутниковых технологий и распространения изображений дистанционного зондирования земли с высоким разрешением. Интеграция данных с нескольких спутников во временные ряды облегчила выявление конкретных событий и тенденций, тем самым улучшив наше понимание глобальных климатических и экологических изменений.

UKAN: для сегментации и создания медицинских изображений

UKAN, -это новый подход к сегментации и созданию медицинских изображений, который представляет собой модификацию архитектуры U-Net, известную в различных визуальных приложениях, включая модели сегментации

изображений [12].

В модели U-CAN установленный конвейер U-Net модифицируется и перепроектируется путем интеграции выделенных слоев KAN в токенизированное промежуточное представление. Превосходство U-KAN подтверждается строгими критериями сегментации медицинских изображений, которые демонстрируют, что он обеспечивает более высокую точность при меньших затратах на вычисления.

Кроме того, U-KAN был исследован в качестве альтернативного средства прогнозирования шума U-Net в диффузионных моделях. Диффузионные модели генерируют высококачественные данные путем постепенного внесения шума в набор данных, а затем обращают этот процесс вспять. Они используются для создания новых, отличительных изображений, звуков или других типов данных, и потому считаются высокоэффективным инструментом генеративных моделей, предлагающего универсальный подход к созданию новых высококачественных выборок данных, полученных на основе изученных закономерностей на известных данных.

U-KAN, - альтернатива MLP и альтернатива U-Net для прогнозирования шума в диффузионных моделях. Адаптивность и эффективность U-KAN также подчеркивают его как превосходную альтернативу U-Net для прогнозирования шума в диффузионных моделях.

KAN для объяснимого NLP

В.А. Galitsky [13] обсуждает применение сети Колмогорова-Арнольда для объяснимой обработки естественного языка (NLP), уделяя особое внимание контексту непрерывных эмбедингов (вставок) слов. Создание встраиваемых слов является обычной практикой в обработке естественного языка, с использованием методов Word2Vec, GloVe (Global Vectors for Word Representation) и моделей на основе трансформеров, таких как BERT и GPT.

В исследовании также обсуждается матрица расстояний word2vec, состоящая из глаголов и соответствующих существительных. Глаголы упорядочены по расстоянию до главного глагола, причем наименьшее расстояние соответствует наиболее близким глаголам, а наибольшее - наиболее отдаленным глаголам в рамках данного семантического семейства глаголов для типов движения.

Этот подход к формированию непрерывных вставок слов с использованием KAN обеспечивает новый метод для фиксации семантических связей между словами в непрерывном векторном пространстве, тем самым позволяя моделям NLP эффективно понимать и обрабатывать текст на естественном языке.

Система постепенного обучения - iKAN

iKAN - это новая система инкрементального обучения (IL) для распознавания активности человека с помощью носимых датчиков (human activity recognition HAR), которая решает две проблемы одновременно: катастрофическое забывание и неравномерный ввод данных [14]. iKAN является пионером IL в области сетей Колмогорова-Арнольда, которые заменяют многослойные персептроны в качестве классификатора. Чтобы адаптировать KAN для HAR, iKAN использует ветви функций, зависящие от конкретной задачи, и уровень перераспределения функций.

В отличие от существующих методов IL, iKAN фокусируется на расширении ветвей извлечения признаков для учета новых входных данных от различных датчиков, сохраняя при этом согласованные размеры и количество выходных данных классификатора. Платформа iKAN продемонстрировала рост эффективности обучения в шести общедоступных наборах данных HAR.

Последний показатель составил 84,9% (взвешенный балл F1), при этом средний показатель прироста составил 81,34%. Это значительно превосходит два существующих метода поэтапного обучения, а именно EWC (51,42%) и повторный опыт (59,92%). Подход iKAN представляет собой многообещающий способ поэтапного обучения в сценариях HAR.

МЕТОДОЛОГИЯ

В процессе исследования использовались статистические, аналитические, сравнительные методы анализа.

ОБСУЖДЕНИЕ И РЕЗУЛЬТАТЫ

В обзоре литературы представлено исследование сетей Колмогорова-Арнольда (KANs), -новой архитектуры нейронных сетей, которая стала многообещающей альтернативой традиционным многослойным персептронам (MLP). Рассматриваются различные области применения и достижения KAN, подчеркивается их универсальность и потенциал для улучшения приложений машинного обучения.

Подчеркивается инновационный характер KAN и потенциал для революционизирования различных областей машинного обучения. Интерпретируемость и эффективность сетей KAN делают их ценным дополнением к инструментарию алгоритмов машинного обучения, особенно для задач, связанных с большими наборами данных и сложными нелинейными взаимосвязями.

Но KAN пока остаются формирующейся моделью, поэтому необходимы дальнейшие исследования для изучения их устойчивости к различным наборам данных и совместимости с другими архитектурами глубокого обучения.

Сравнительная таблица различных вариантов использования сетей Колмогорова-Арнольда (KAN), их областей применения, преимуществ и недостатков [3]

Использование KAN	Область	Преимущества	Недостатки
Прогноз временных рядов	Машинное обучение Прогнозная аналитика	Усовершенствованное прогностическое моделирование, динамическое изучение паттернов активации, превосходит MLP по точности и интерпретируемости	Требует тщательной оптимизации количества узлов и размеров сетки
Подбор данных и решение PDE	Математика, Физика	Может достигать сопоставимой или более высокой точности, чем крупные MLP, что полезно в открытии математических и физических законов	Необходимы исследования для изучения их надежности в различных наборах данных
Классификация изображений	Компьютерное зрение, Дистанционное зондирование	Интегрируется с предварительно обученными моделями CNN для задач классификации сцен дистанционного зондирования, обеспечивает высокую точность при меньшем количестве периодов обучения и параметров	Обладает значительным потенциалом для дальнейшей разработки и оптимизации
Сегментация медицинских изображений	Медицинская визуализация, Компьютерное зрение	Расширяет существующий конвейер U-Net за счет интеграции выделенных слоев KAN, обеспечивая более высокую точность при меньших затратах на вычисления	Необходимы исследования для разработки более сложных решений, с передовыми архитектурами
Аппроксимация нелинейной функции	Математика, Машинное обучение	Точная аппроксимация сложных нелинейных функций превосходит MLP по точности и интерпретируемости	Необходимы исследования для изучения их надежности в различных наборах данных

Внедрение сетей Колмогорова-Арнольда может сопряжено с рядом проблем: сети особенно хорошо подходят для анализа сложных нелинейных

взаимосвязей данных и, таким образом, имеют широкий спектр применения в различных областях, как показано в таблице 4. Начиная с финансового прогнозирования и заканчивая персонализированной медициной, где KAN дают аналитику и оптимизационные решения. В области здравоохранения у KAN есть потенциал произвести революцию в геномном анализе и разработке лекарств. Благодаря своей универсальности KAN переосмысливают анализ данных в различных областях, предлагая бесценные инструменты для принятия обоснованных решений и оптимизации процессов.

Таблица 4

Различные проблемы при внедрении сетей Колмогорова-Арнольда (KANs) [13]

Проблемы, возникающие при внедрении KAN	Описание
Сложность	В KAN линейные веса заменяются одномерными функциями, параметризованными сплайном, что увеличивает сложность модели и делает процесс обучения более интенсивным с точки зрения вычислений и времени
Настройка параметров	Производительность KAN сильно зависит от выбора параметров, - количество узлов и размер сетки. Поиск оптимального набора параметров может оказаться сложной задачей
Переобучение	Хотя KAN менее подвержены переобучению, но уязвимы, если не будут должным образом регуляризованы, особенно при работе с данными большой размерности
Интерпретируемость	Хотя KAN лучше поддаются интерпретации, понимание их внутренней работы остаётся сложной задачей, особенно для непростых моделей
Отсутствие предварительно подготовленных моделей	В отличие от архитектур, таких как CNN или RNNs, немного предварительно обученных моделей KAN. Поэтому часто приходится обучать свои модели с нуля, что может занимать много времени и ресурсов
Ограниченные исследования	Поскольку KAN - относительно новая область, сегодня доступно мало ресурсов или исследований по сравнению с более устоявшимися архитектурами нейронных сетей

Отметим потенциал использования сетей Колмогорова-Арнольда в городских исследованиях, которые включает в себя анализ сложных, многогранных данных в различных областях: управление дорожным движением, мониторинг окружающей среды, техническое обслуживание инфраструктуры и здравоохранение. В условиях стремительной урбанизации концепция "умных

городов" стала многообещающим решением для решения сложных задач, стоящих перед современной городской средой. В основе развития "умного города" лежит интеграция передовых технологий, в частности Интернета вещей (IoT), с целью повышения эффективности, устойчивости и благоустроенности городов.

Сети KAN помогают умным городам решать множество городских задач благодаря своей способности обрабатывать и интерпретировать объемные и сложные наборы данных, генерируемые датчиками Интернета вещей. Используя KAN, градостроители и политики могут получить представление о различных аспектах городской жизни, включая транспортные схемы, состояние окружающей среды, энергопотребление и здравоохранение. Такой подход, основанный на данных, позволяет принимать обоснованные решения и активно управлять городскими ресурсами.

Одним из основных применений KANs в умных городах является прогнозная аналитика: техническое обслуживание критически важной инфраструктуры, оптимизация распределения ресурсов, упреждающие меры для решения возникающих проблем, таких как транспортные потоки, структура энергопотребления, уровень образования отходов и показатели использования услуг.

Еще одной областью, в которой KAN демонстрируют значительный потенциал, является оптимизация городских служб: маршрутов общественного транспорта и планирования сбора отходов и заканчивая динамичной настройкой сетей распределения энергии, мониторинг окружающей среды, управление инфраструктурой, исследования состояния здоровья в городах и социологические исследования.

ЗАКЛЮЧЕНИЕ

Сети Колмогорова-Арнольда и их варианты, такие как Wav-KAN, DeepOKAN и TKAN, продемонстрировали значительный потенциал в широком спектре областей, включая анализ временных рядов, классификацию изображений, обработку естественного языка и новые приложения для интернета вещей в умных городах и городских исследованиях.

Несмотря на многообещающие результаты, продемонстрированные на данный момент, необходимы дальнейшие исследования, чтобы всесторонне понять сильные и слабые стороны этих вариантов KAN и изучить их неиспользованный потенциал в растущих областях развития умных городов и городских исследований. Интеграция KAN в эти области является многообещающей, учитывая их уникальные свойства и способность

анализировать сложные нелинейные взаимосвязи в данных, генерируемых датчиками Интернета вещей и городскими системами.

По мере развития исследований в этой области становится все более очевидным, что KAN готовы играть все более важную роль в области машинного обучения и искусственного интеллекта. Их преобразующий потенциал в изменении того, как мы воспринимаем и конструируем нейронные сети, делает их интересной областью исследований. Путь к раскрытию и использованию всего потенциала KANs находится на начальной стадии, наполненный ожиданиями.

Более того, сравнительные исследования между KAN и другими моделями машинного обучения в контексте интернета вещей "умный город" и городских исследований могут дать бесценную информацию об их относительной производительности и пригодности для различных задач. Поскольку сфера KAN продолжает развиваться, можно предположить, что эти сети станут незаменимыми инструментами для продвижения машинного обучения и искусственного интеллекта, особенно в динамичной и сложной городской среде.

СПИСОК ИСПОЛЬЗОВАННОЙ ЛИТЕРАТУРЫ

1. <https://overclockers.ru/blog/cool-gadgets/show/191098/Vse-bol-she-ekspertov-govoryat-o-skorom-zakate-ery-II-i-shlopyvanii-myl-nogo-puzyrya-umnyh-algoritmov>
2. Albert Gu, Tri Dao Mamba: Linear-Time Sequence Modeling with Selective State Spaces arXiv:2312.00752v2 [cs.LG] 31 May 2024.
3. Bochra Hadj Kilani Kolmogorov-Arnold Networks: Key Developments and Uses <https://doi.org/10.32388/7NNCAA>
4. Yuntian Hou, Di Zhang A comprehensive survey on Kolmogorov- Arnold networks (KAN) arXiv:2407.11075v4 [cs.LG] 27 Aug 2024.
5. Ziming Liu, Yixuan Wang, Sachin Vaidya, Fabian Ruehle KAN: Kolmogorov–Arnold Networks arXiv:2404.19756v1 [cs.LG] 30 Apr 2024.
6. J. Liu et al. Kolmogorov-Arnold networks for symbolic regression and time series prediction. *Journal of Machine Learning Research*, 25(2):95–110, 2024.
7. Kunpeng Xu, Lifei Chen, Shengrui Wang Kolmogorov-Arnold networks for time series: bridging predictive power and interpretability arXiv:2406.02496v1 [cs.LG] 4 Jun 2024.
8. Ziyao Li Kolmogorov-Arnold Networks are Radial Basis Function Networks arXiv:2405.06721v1.
9. Bozorgasl, Z., & Chen, H. (2024). Wav-KAN: Wavelet Kolmogorov-Arnold networks. arXiv:2405.12832. <https://arxiv.org/abs/2405.12832>

10. Diab W. Abueidda, Panos Pantidis, Mostafa E. Mobasher† DEEPOKAN: deep operator network based on Kolmogorov- Arnold networks for mechanics problems

<https://doi.org/10.48550/arXiv.2405.19143>

11. Cheon, M. (2024). Kolmogorov-Arnold Network for Satellite Image Classification in Remote Sensing. <https://arxiv.org/abs/2406.00600>.

12. Galitsky, B. A. (2024). Kolmogorov-Arnold Network for Word-Level Explainable Meaning Representation.

<https://www.preprints.org/manuscript/202405.1981>

13. Chenxin Li, Xinyu Liu, Wuyang Li, Cheng Wang, Hengyu Liu, Yifan Liu, Zhen Chen, Yixuan Yuan U-KAN Makes Strong Backbone for Medical Image Segmentation and Generation <https://doi.org/10.48550/arXiv.2406.02918>

14. Mengxi Liu, Sizhen Bian, Bo Zhou, Paul Lukowicz iKAN: Global Incremental Learning with KAN for Human Activity Recognition Across Heterogeneous Datasets <https://doi.org/10.48550/arXiv.2406.01646>.