

УДК: 004.942

Прогнозирование занятости частотного ресурса в системе когнитивного радио с использованием нейронной сети Колмогорова – Арнольда

Е. Р. Адамовский^{1,а}, Р. П. Богуш^{1,б}, Н. М. Наумович^{2,с}

¹Полоцкий государственный университет имени Евфросинии Полоцкой,
Республика Беларусь, г. Новополоцк, ул. Блохина, д. 29

²Белорусский государственный университет информатики и радиоэлектроники,
Республика Беларусь, г. Минск, ул. П. Бровки, д. 6

E-mail: ^а e.adamovsky@psu.by, ^б bogushr@mail.ru, ^с naumovich@bsuir.by

Получено 15.09.2024, после доработки — 14.11.2024.

Принято к публикации 29.12.2024.

Для систем когнитивного радио актуальным является использование эффективных алгоритмов поиска свободных каналов, которые могут быть предоставлены вторичным пользователям. Поэтому данная статья посвящена повышению точности прогнозирования занятости частотного ресурса системы сотовой связи с использованием пространственно-временных карт радиосреды. Формирование карты радиосреды осуществляется для системы сотовой связи четвертого поколения Long-Term Evolution. С учетом этого разработана структура модели, включающая генерацию данных и позволяющая выполнять обучение и тестирование искусственной нейронной сети для прогнозирования занятости частотных ресурсов, представленных в виде содержимого ячеек карты радиосреды. Описана методика оценки точности прогнозирования. Имитационная модель системы сотовой связи реализована в программной среде MatLab. Разработанная модель прогнозирования занятости частотного ресурса реализована на языке программирования Python. Представлена полная файловая структура модели. Эксперименты выполнены с использованием искусственных нейронных сетей на основе архитектур нейронных сетей Long Short-Term Memory и Колмогорова – Арнольда с учетом ее модификации. Установлено, что при равном количестве параметров нейронная сеть Колмогорова – Арнольда обучается быстрее для данной задачи. Полученные результаты исследований свидетельствуют о повышении точности прогнозирования занятости частотного ресурса системы сотовой связи при использовании нейронной сети Колмогорова – Арнольда.

Ключевые слова: система сотовой связи, Long-Term Evolution, Long Short-Term Memory, искусственные нейронные сети

UDC: 004.942

Prediction of frequency resource occupancy in a cognitive radio system using the Kolmogorov – Arnold neural network

E. R. Adamovskiy^{1,a}, R. P. Bogush^{1,b}, N. M. Naumovich^{2,c}

¹Polotsk State University,

29 Blokhina st., Novopolotsk, Republic of Belarus

²Belarusian State University of Informatics and Radioelectronics,
6 st. P. Brovki, Minsk, Republic of Belarus

E-mail: ^a e.adamovsky@psu.by, ^b bogushr@mail.ru, ^c naumovich@bsuir.by

Received 15.09.2024, after completion — 14.11.2024.

Accepted for publication 29.12.2024.

For cognitive radio systems, it is important to use efficient algorithms that search for free channels that can be provided to secondary users. Therefore, this paper is devoted to improving the accuracy of prediction frequency resource occupancy of a cellular communication system using spatiotemporal radio environment maps. The formation of a radio environment map is implemented for the fourth-generation cellular communication system Long-Term Evolution. Taking this into account, a model structure has been developed that includes data generation and allows training and testing of an artificial neural network to predict the occupancy of frequency resources presented as the contents of radio environment map cells. A method for assessing prediction accuracy is described. The simulation model of the cellular communication system is implemented in the MatLab. The developed frequency resource occupancy prediction model is implemented in the Python. The complete file structure of the model is presented. The experiments were performed using artificial neural networks based on the Long Short-Term Memory and Kolmogorov – Arnold neural network architectures, taking into account its modification. It was found that with an equal number of parameters, the Kolmogorov – Arnold neural network learns faster for a given task. The obtained research results indicate an increase in the accuracy of prediction the occupancy of the frequency resource of the cellular communication system when using the Kolmogorov – Arnold neural network.

Keywords: cellular communication system, Long-Term Evolution, Long Short-Term Memory, artificial neural networks

Citation: *Computer Research and Modeling*, 2025, vol. 17, no. 1, pp. 109–123 (Russian).

1. Введение

В настоящее время для систем связи отмечается проблема дефицита спектра, которая вызвана их развитием, распространением и увеличением охвата пользователей (абонентов). В качестве одного из вариантов решения проблемы предлагается принцип динамического доступа к спектру (dynamic spectrum access, DSA), реализацией которого является технология когнитивного радио (cognitive radio, CR) [Adamovskiy, Bohush, Chertkov, 2022] с применением специальных устройств SDR (программно определяемая радиосистема, software-defined radio).

Лицензированные (первичные) пользователи (primary users, PU), как правило, не задействуют выделенный им частотный ресурс полностью во временной и пространственной области. Под частотным ресурсом (радиочастотным спектром) понимают совокупность радиочастот, которые могут быть использованы для функционирования радиоэлектронных устройств. Устройства CR способны оценивать радиочастотную обстановку вокруг себя, обнаруживать свободные в данный момент каналные ресурсы и использовать их для осуществления связи между вторичными пользователями (secondary users, SU), применяя единую координирующую базу данных на определенной территории. В случае необходимости связи между устройствами PU все SU должны незамедлительно освобождать занятые каналы передачи и не создавать дополнительных помех. Такой подход позволяет более полно использовать частотный ресурс, но сопряжен со сложностями обеспечения данных требований на практике.

Динамика изменения доступного частотного ресурса определяется трафиком рассматриваемой системы связи и принципами ее функционирования (используемые частоты и полосы, форма сигналов, мощность передатчиков). Трафик является частично стохастическим процессом и характеризуется определенными закономерностями (суточная периодичность, влияние дня недели), которые могут быть выявлены и использованы для прогнозирования трафика.

Среди искусственных нейронных сетей (ИНС) для задач прогнозирования сетевого трафика используются следующие архитектуры: полносвязные сети (feedforward neural networks, FNN), сверточные сети (convolutional neural networks, CNN) и рекуррентные сети (recurrent neural networks, RNN). Архитектура FNN, или многослойный перцептрон (multilayer perceptron, MLP), предполагает в структуре сети наличие нескольких однонаправленных полносвязных нейронных слоев. Следует отметить, что FNN является универсальным решением для задач прогнозирования, но при этом требует большого количества данных и вычислительных ресурсов для обучения. Архитектура CNN традиционно используется для распознавания образов на изображениях, однако способна выполнять прогнозирование, представляя результаты в виде весов для списка выходных состояний. CNN присущи недостатки, подобные FNN, а также требуется настройка большого числа внутренних параметров для достижения высокой точности. В отличие от FNN архитектура RNN реализует обратные связи между слоями, что позволяет сети запоминать информацию, полученную на предыдущих этапах обучения. Рекуррентная архитектура LSTM (long short-term memory) успешно применяется для задач прогнозирования и классификации на основе больших наборов данных [Xu et al., 2023], в том числе для систем связи [Zhang et al., 2021]. В работе [Fischer, Sterling, Lessmann, 2024] показано, что LSTM превосходит по точности традиционную статистическую модель (autoregressive integrated moving average, ARIMA). Поэтому такая архитектура является наиболее перспективной и применяется для прогнозирования трафика в системах связи.

В работе [Zeng et al., 2020] авторы предлагают архитектуру STC-Net (spatial-temporal cross-domain neural network) на основе гибридных слоев conv-LSTM [Zhang, Patras, 2018] для пространственно-временного анализа беспроводного трафика 5G-сети на сетке 100×100 с использованием следующих входных данных (временных меток): номер недели, номер часа в сутках и тип дня (выходной или рабочий).

В работе [Fu, Wang, 2022] рассмотрена архитектура прогнозирования трафика, аналогичного [Zeng et al., 2020], с одновременным использованием полносвязных, сверточных и LSTM-слоев. Однако в отличие от подхода из [Zeng et al., 2020] прогнозирование осуществлялось для временных рядов, то есть для последовательности данных о трафике за определенный интервал времени в заданной пространственной области. Показано, что предложенная модель демонстрирует более высокую точность по сравнению с другими моделями глубокого обучения, среди которых авторами были отмечены следующие подходы: DenseNet, ARIMA, метод опорных векторов (support vector machine, SVM), а также метод k-ближайших соседей (k-nearest neighbors algorithm, KNN).

Для прогнозирования трафика в системах связи комбинирование различных архитектур ИНС используется для повышения точности. Так, разработчики [Zeng et al., 2020] отмечают, что их модель имеет высокую сложность и требует большого количества времени на обучение. Следовательно, при аналогичной концепции (комбинация CNN, FNN и LSTM) модель [Fu, Wang, 2022] будет обладать аналогичными недостатками.

В работе [Kurri, Raja, Periasamy, 2021] авторы используют 4-слойную модель LSTM с целью прогнозирования зашифрованного трафика от нескольких BS LTE на основе временных рядов (32 входных отсчета (с интервалом 1 час) и 1 выходной отсчет). Показано преимущество LSTM по сравнению с ARIMA в среднем на 12 % с использованием следующих метрик: среднеквадратичная ошибка (mean squared error, MSE), средняя абсолютная ошибка (mean absolute error, MAE) и коэффициент детерминации (R^2 -score). Однако достигнутая моделью точность (значение MSE при обучении 0,05) не является идеальным результатом, поскольку входные данные имели достаточно простую предсказуемую структуру. В работе [Fawaz, Mosleh, 2021] для прогнозирования трафика авторы предлагают 4-слойную модель LSTM, но с экспоненциальным сглаживанием и значительно меньшим набором данных для обучения (~100 тыс. записей) по сравнению с [Kurri, Raja, Periasamy, 2021]. Достигнутый уровень ошибки MSE при обучении оказался равен 10^{-5} – 10^{-4} , фактическая средняя точность составила 91 %.

Таким образом, настройка модели LSTM с учетом характера анализируемой информации является сложной оптимизационной задачей, которая определяется множеством как внутренних (входные данные, их количество, конфигурация слоев и другие параметры модели), так и внешних (репрезентативный набор данных для обучения, ограниченные вычислительные ресурсы) факторов.

Система сотовой связи LTE (long-term evolution) имеет особенности формирования трафика между узлами сети. Так, в работе [García, Koo, 2023] произведено сравнение различных подходов к прогнозированию состояния карты радиосреды (radio environment map, REM) LTE на основе реальных данных, на сетке 100×100 : показатель уровня принимаемого сигнала (received signal strength indicator, RSSI), мощность принятого опорного сигнала (reference signal received power, RSRP). По критерию RMSE (root MSE) наилучшую точность продемонстрировали следующие подходы: бэггинг, KNN и регрессионное дерево. Однако в работе [Stepanov et al., 2020] показано, что SVM сопоставим с ними по точности и превосходит по быстродействию, а в работе [Santana et al., 2022] отмечен наивный байесовский классификатор, но их точность ниже, чем у подходов, использующих глубокое обучение, в том числе и LSTM.

Поскольку некоторые аспекты REM могут быть представлены в виде двухмерных изображений, для прогнозирования таких параметров используются также и CNN-модели. В работе [Chaves-Villota, Viteri-Mera, 2023] для анализа параметров покрытия базовых станций (base station, BS) и RSRP использовалась модель DeepREM на основе сверточной сети U-Net и условной генеративной состязательной сети (conditional generative adversarial network, CGAN). Однако такие методы имеют ограниченную область применения.

В работе [Адамовский, Чертков, Богуш, 2022] представлена имитационная модель системы связи четвертого поколения LTE, которая выполняет генерацию данных, отражающих динамику изменения состояния радиосреды в виде соответствующей карты REM. Модель имитирует объекты BS LTE и абонентские устройства (user equipment, UE). Абоненты модели действуют согласно индивидуальному расписанию сеансов связи и перемещений по ячейкам карты, сформированному на основе марковского процесса.

На основе анализа существующих решений для задачи прогнозирования трафика в системах связи можно заключить, что наилучшим подходом в настоящее время является применение сетей LSTM или их модификаций, поскольку они позволяют обеспечить наибольшую точность для больших объемов данных, содержащих неявные паттерны. Однако в 2024 году была предложена новая архитектура ИНС, сеть Колмогорова – Арнольда (Kolmogorov – Arnold network, KAN) [Liu et al., 2024], которая является перспективной: демонстрирует более высокую точность по сравнению с другими нейронными сетями при аналогичном числе параметров для разных задач, а также предлагает визуальную интерпретацию результатов. Основным отличием KAN от известных архитектур является реализация функций активации на ребрах, а не в узлах сети. То есть авторами предлагается обучение функций активации вместо определенных заранее, например таких, как Tanh, ReLU или Softmax.

На текущий момент анализ возможности увеличения точности прогнозирования частотного ресурса современных систем связи с использованием KAN для построения систем когнитивного радио не проводился, поэтому такая задача является актуальной.

2. Нейронная сеть Колмогорова – Арнольда

Архитектура KAN реализует систему узлов и ребер аналогично MLP, но ребра KAN содержат параметризованные кривые (сплайны), параметры которых корректируются во время обучения, а узлы суммируют их с полученными в ходе обучения весовыми коэффициентами (рис. 1, а), то есть осуществляют композицию одномерных функций для представления сложной функции f :

$$f(x_1, \dots, x_n) = \sum_{q=1}^{2n+1} \Phi_q \left(\sum_{p=1}^n \varphi_{q,p}(x_p) \right), \quad (1)$$

где $\varphi_{q,p}$ — одномерные функции, которые соответствуют входным данным x_p ; Φ_q — непрерывные функции.




Рис. 1. Элементы архитектуры нейронной сети Колмогорова – Арнольда [Liu et al., 2024]

Авторы оригинальной работы [Liu et al., 2024] приводят сравнение количества необходимых обучаемых параметров KAN и MLP, которое свидетельствует о более высоких требованиях KAN, однако авторы утверждают, что MLP требует большего количества нейронов N на каждом из L слоев для достижения аналогичной точности.

Исходное состояние сети KAN (рис. 1, *а*) предполагает взаимосвязь входных данных x , y и выходных данных $z(x, y)$ по формуле

$$z(x, y) = e^{\sin(\pi x) + y^2}. \quad (2)$$

При этом поддерживается операция обрезки (pruning), которая позволяет удалить из обученной сети ребра и узлы с весами, не превышающими заданный порог (рис. 1, *б*), и оценить фактически достаточный для выбранной задачи размер модели, облегчить и ускорить ее работу, а также обеспечивает визуальную интерпретируемость данных, что показано на рис. 1, *в*.

В работе [Vaca-Rubio et al., 2024] KAN используется для прогнозирования временных рядов спутникового трафика. Авторы сравнивают KAN с MLP и делают заключение о большей эффективности и производительности KAN. Так, 4-слойная сеть MLP с 329 тыс. параметров после обучения смогла достичь $\text{MSE } 6,12 \cdot 10^{-3}$, а 4-слойная сеть KAN со 109 тыс. параметров продемонстрировала $\text{MSE } 5,08 \cdot 10^{-3}$. Аналогично оригинальной статье [Liu et al., 2024] в [Vaca-Rubio et al., 2024] указывается положительное влияние увеличения параметров G (размер сетки сплайнов) и k (порядок полиномов) на точность модели, однако не приводится их влияние на производительность.

В работе [Xu, Chen, Wang, 2024] с помощью KAN (модификации T-KAN и MT-KAN для одномерных и многомерных данных соответственно) также производится прогнозирование временных рядов, при этом операция обрезки (порог $th_{\text{prune}} = 5 \cdot 10^{-2}$) осуществляется в процессе обучения, что способно обеспечить адаптацию сети к данным, сохраняя при этом вычислительную эффективность. Авторы привели сравнение KAN с архитектурами MLP, RNN и LSTM, которое показывает, что модели KAN способны достигать сопоставимой точности относительно других архитектур при меньшем числе параметров.

3. Модель прогнозирования занятости частотного ресурса

Для генерации данных использована имитационная модель системы связи LTE [Chertkov, Bohush, Adamovskiy, 2023], которая позволяет получать файлы данных с заданным шагом (T кадров LTE) со структурой, соответствующей табл. 1. Каждый файл содержит сетку ячеек (REM) размером $X \times Y$, представленных R линиями ресурсных блоков (resource block, RB) в частотной области и 20 слотами (1 кадр LTE) во временной области. Каждая ячейка предоставляется матрицей $R \times 20$ отсчетов, где отсчет отражает занятость частотного ресурса с шириной полосы 180 кГц (1 RB), ограниченного периодом времени 0,5 мс (1 слот). Значение отсчета false означает, что соответствующая ему часть ресурса (слот линии RB) не занята.

Таблица 1. Структура выходного файла имитационной модели

Поле	Размер и тип данных	Пример значений	Описание
rem	$X \times Y$ ячеек по $R \times 20$ bool	5×5 ячеек по 156×20 bool	Сетка REM
frame	uint	2 900 090 000	Номер кадра LTE

Разработана структура модели, включающая получение данных, обучение и тестирование ИНС для прогнозирования занятости частотных ресурсов, представленных в виде содержимого ячеек REM. Модель состоит из следующих основных элементов (рис. 2).

1. Блок чтения файла конфигурации save.mat и выходных файлов имитационной модели LTE, их распаковка в предварительную структуру, представленную в табл. 2.

2. Блок чтения опорного файла расписания пользователей week.mat, который содержит таблицу соответствия абсолютного номера дня (от начала генерации) следующим его параметрам: день недели (понедельник-воскресенье), тип дня (рабочий, выходной, праздничный), номер недели месяца (1–4).




Рис. 2. Схема модели для прогнозирования канальных ресурсов на основе нейронной сети Колмогорова – Арнольда

Таблица 2. Предварительная структура данных

Поле	Размер и тип данных	Диапазон значений	Описание
status	20 bool	0 или 1 (false или true)	Статусы слотов линии RB
line	uint	1 ... 156	Номер линии RB
sample	uint	1 ... 864	Номер отсчета в рамках суток
numday	uint	1 ... 336	Номер дня от начала генерации

Набор входных и выходных данных для прогнозирующей модели состоит из элементов, которые представлены в табл. 3. Входные данные рассчитываются на основе полей line, sample, numday и содержания файла week.mat, а выходные данные соответствуют полю status (см. табл. 2).

Таблица 3. Структура набора данных для обучения прогнозирующей модели

Входные данные					Выходные данные
День недели	Тип дня	Номер недели в текущем месяце	Номер отсчета в рамках суток	Номер линии RB	Статусы слотов линии RB




Рис. 3. Пример содержимого ячейки карты радиосреды имитационной модели LTE, где черный цвет соответствует наличию сигнала: в зоне I — сигналы восходящей линии, в зоне II — сигналы нисходящей линии, в зонах III сигналы не передаются

3. Блок выделения из полученных на предыдущем шаге записей, ассоциированных с линиями RB, в которых осуществляется передача данных между BS и UE. Для рассматриваемой имитационной модели LTE каждую ячейку REM можно разделить на три зоны: восходящая линия связи (uplink) от UE к BS (рис. 3, зона I), нисходящая линия связи (downlink) от BS к UE (рис. 3, зона II) и свободная область (рис. 3, зоны III), в которой при заданных параметрах модели передача данных не осуществляется. Белым цветом обозначены области, где сигналы BS и UE не передаются, черным цветом помечены области, в которых моделью зафиксирована мощность в текущий момент времени в выбранной ячейке.

Интерес представляют зона I и зона II, которые передаются на следующий этап обработки. Выполняется операция удаления из обучающих данных тех записей, которые относятся ко всем зонам III. В результате размер данных уменьшается на 60 %, что способно сократить время обучения ИНС и повысить точность прогнозирования занятости частотного ресурса, поскольку в таком случае модели не потребуется обучаться на входных данных, выходные данные которых заранее известны со 100 % точностью. Следовательно, их включение в обучающий набор нецелесообразно.

4. Блок комбинирования и разделения полученных данных на следующие выборки: обучающую (60 %), тестовую (20 %) и валидационную (20 %).

5. Блок инициализации модели KAN, ее обучения, тестирования и сохранения в файл весов для последующего использования в имитационной модели системы связи LTE.

Структура обучающих данных приведена на рис. 4, визуально показан пример нескольких пар входных (5 чисел) и выходных (20 чисел) значений.

4. Программная реализация модели прогнозирования

Разработанная модель прогнозирования занятости частотного ресурса реализована на языке программирования Python 3.10. В качестве основы реализации KAN был адаптирован программный код из репозитория [Team-daniel, 2024], использующий фреймворк машинного обучения PyTorch. Имитационная модель LTE и подготовка входных данных реализованы в программной среде MatLab 2023.




Рис. 4. Типы обучающих и выходных данных

Ключевым этапом в генерации обучающего датасета является совмещение расписания пользователей из опорного файла `week.mat` и данных, полученных в результате распаковки выходных файлов имитационной модели системы связи LTE (листинг 1), структура которых отражена в табл. 2.

Листинг 1. Подготовка предварительной структуры представления обучающего набора данных

```

sch = load('week.mat').schedule; % загрузка опорного файла расписания
for j = 1 : 156 % цикл по каждой линии RB
    line = data(:, j); % копирование записей на одной линии RB
    Xline = zeros(length(line), 5); % инициализация промежуточных массивов
    Yline = zeros(length(line), 20);
    for i = 1 : length(line) % цикл по каждой записи
        Yline(i, :) = line(i).status; % запись статуса ресурсов
        Xline(i, :) = [sch(1, line(i).day); % запись дня недели, типа дня, номера недели,
            sch(2, line(i).day); sch(3, line(i).day);
            line(i).sample; line(i).line]; % суточного отсчета и номера линии
    end % конец цикла по записям
    tempY = [tempY; Yline]; % добавление записи в предварительную
    tempX = [tempX; Xline]; % структуру и конец цикла по линиям RB
end

```

Веса модели KAN после обучения сохраняются в бинарный файл и в дальнейшем могут быть использованы для выполнения прогнозирования с помощью специального скрипта на языке

Python. Данный скрипт выполняет загрузку весов, получает на вход данные в виде структуры, представленной в табл. 3, и осуществляет вывод результатов работы модели в консоль.

Имплементация прогнозирующей модели в имитационную модель системы связи LTE реализуется путем системного вызова скрипта с набором параметров, который формируется на основе команд листинга 1. Полученный результат, представленный в текстовом виде, преобразуется в массив логических значений, производится сравнение прогноза и текущего состояния модели (листинг 2).

Листинг 2. Функция для получения результата прогноза модели KAN

function predict = PredictKAN(inp)	% объявление функции
[~, ans] = system(inp);	% системный вызов Py-скрипта
ans(1) = ''; ans(length(ans)) = '';	% удаление лишних символов
ans(length(ans)) = '';	
ans = strsplit(ans, ' ');	% разделение строки на 20 символов
predict = ones(1, 20);	% инициализация результирующего массива
for i = 1 : 20	% цикл по каждому элементу
predict(i) = str2num(ans{i});	% преобразование каждого символа в число
end	% завершение цикла по элементам и возврат
end	в основную программу результата

Модель KAN была инициализирована и обучена со следующими параметрами: $G = 60$, $k = 3$, метрика оценки потерь MSE, длительность обучения — 300 эпох. Использован оптимизатор LBFGS (limited-memory Broyden – Fletcher – Goldfarb – Shanno) [Liu, Nocedal, 1989], выбранный авторами оригинальной реализации KAN.

Адекватность сопоставления моделей разных архитектур обеспечена подбором конфигураций слоев, при которых количество обучаемых параметров моделей оказалось бы равным. Так, для KAN подобрана конфигурация слоев {5, 10, 20}, а для LSTM — {5, 57, 20}.

Файловая система проекта представлена на рис. 5. Исходные файлы проекта представлены в репозитории GitHub [EgorAdamovsky, 2024] с лицензией MIT. Скрипт `prereq.m` выполняет обработку выходных файлов имитационной модели LTE (REM-*.zip) и формирует файлы для обучения в папке `out/`. Затем скрипт `train-kan.py` выполняет обучение модели KAN, сохранение ее весов в файл `model-kan.ckpt` и результатов обучения (файл `mse-kan.txt`). Скрипт `test-kan.py` производит проверку точности обученной модели KAN. Аналогичные файлы предусмотрены для работы с моделью LSTM.

5. Результаты экспериментов

В качестве используемого критерия оценки работы прогнозирующих моделей наиболее часто применяется MSE (среднеквадратичная ошибка):

$$\text{MSE} = \frac{1}{M} \cdot \sum_{i=0}^N (y_{\text{val}} - y_{\text{pred}})^2, \quad (3)$$

где y_{pred} — выходные данные прогнозирующей модели, y_{val} — фактические данные, M — размер данных.

Имитационной моделью LTE были сформированы данные в виде файлов, которые содержат REM, зафиксированные с периодом $T = 10\,000$ кадров LTE за 12 месяцев моделируемого периода. Размер выходных данных имитационной модели составил 400 тыс. записей.

На рис. 6 показаны внешний вид KAN после обучения (рис. 6, а) и ее уменьшенная версия после операции обрезки (рис. 6, б), в результате которой были удалены узлы, обладающие




Рис. 5. Файловая система проекта

низкими весовыми коэффициентами, слабо влияющими на результат работы модели. Входные слои показаны внизу (5 узлов), а выходные показаныверху (20 узлов). Цвет линий отражает величину весовых коэффициентов.

Из рис. 6 видно, что наибольшее влияние среди входных данных на прогнозируемые статусы слотов оказывает пятый входной узел, который соответствует номеру линии RB. Этот параметр определяет форму распределения занятых слотов в линии RB, которая в значительной степени зависит от того, в какой зоне (I–III) она располагается. Следовательно, KAN обеспечивает высокую интерпретируемость данных.

Уменьшенная по порогу th_{prune} модель показала падение точности на 2,7 % при сокращении числа параметров на 40 % (конфигурация слоев после операции обрезки — {5, 6, 20}). Уменьшение времени обработки данных составило 60 % для полученной модели. Величина $th_{prune} = 0,1$ выбрана как наибольшее значение, не приводящее к значительному падению эффективности прогнозирования. Последующее увеличение значения th_{prune} резко снижает точность модели KAN. Таким образом, для повышения быстродействия в когнитивных системах с большими объемами пользователей может быть использована операция обрезки KAN с небольшой потерей точности.




Рис. 6. Схемы моделей нейронной сети Колмогорова–Арнольда: количество узлов на каждом слое и визуальное представление значений связей между ними до и после операции обрезки

Фактическая точность прогнозирования занятости частотного ресурса P измерялась путем бинаризации выходных данных моделей y_{pred} по порогу th_{bin} и подсчета отношения корректно предсказанных отсчетов ко всем анализируемым отсчетам в количестве S_{val} по сравнению с валидационными данными y_{val} :

$$P = 100 \% \cdot \left[1 - \frac{\sum_{i=1}^{S_{\text{val}}} |y_{\text{val}} - y_{\text{pred}}(th_{\text{bin}})|}{S_{\text{val}}} \right]. \quad (4)$$

Значение $th_{\text{bin}} = 0,5$ (рис. 7) определено согласно формуле

$$th_{\text{bin}} = \min(\text{MSE}(y_{\text{val}}, y_{\text{pred}} > th)), \quad (5)$$

где $th = 0,4 \dots 0,6$.




Рис. 7. Зависимость фактической точности прогнозирующей модели KAN от порога th_{bin}

На рис. 8 приведено сравнение среднеквадратичных ошибок для KAN и LSTM за первые 150 эпох из 300, в течение которых значение MSE убывает с наибольшей скоростью.

Из рис. 8 следует, что модель KAN при равном количестве параметров обучается быстрее и точнее, чем модель LSTM. Также KAN демонстрирует значение ошибки MSE, меньшее в 1,4 раза по сравнению с LSTM при обучении.




Рис. 8. Потери моделей нейронных сетей Long Short-Term Memory и Колмогорова–Арнольда в метрике MSE при обучении в первые 150 эпох

Таблица 4. Результаты тестирования моделей прогнозирования на основе различных архитектур

Архитектура	MSE при обучении	Фактическая точность, %
KAN, $th_{bin} = 0,5$	0,0987	84,544
KAN после обрезки, $th_{prune} = 0,1$, $th_{bin} = 0,5$	—	81,859
LSTM, $th_{bin} = 0,5$	0,1279	74,120

Результирующие метрики MSE и фактическая точность прогнозирования занятости частотного ресурса представлены в табл. 4.

Из табл. 4 следует, что KAN при обучении достигает меньшего значения MSE, чем LSTM, а также демонстрирует большую фактическую точность на валидационных данных (преимущество составило 10,4 %).

6. Заключение

В работе показана возможность увеличения точности прогнозирования занятости частотного ресурса системы сотовой связи с целью повышения эффективности реализации технологии когнитивного радио. Для этого разработана прогнозирующая модель, представлено описание алгоритма создания и внедрения прогноза, который включает такие основные шаги, как формирование обучающего набора на основе выходных данных имитационной модели системы связи LTE, обучение и тестирование на основе искусственных нейронных сетей. Достигнутая точность прогнозирующей модели на базе LSTM составила 74,12 %, а применение сети Колмогорова – Арнольда увеличивает точность до 84,54 %. Таким образом, обеспечивается выигрыш до 10,4 %. Продemonстрирована возможность увеличения скорости работы модели Колмогорова – Арнольда на 60 % за счет сокращения числа параметров на 40 % путем выполнения операции обрезки. Следует отметить, что при этом незначительно уменьшается ее результирующая точность, которая оценивается в данном случае значением 81,86 %, однако точность прогнозирования выше

по сравнению с полученной для архитектуры LSTM. Таким образом, применение нейронной сети Колмогорова – Арнольда позволит повысить точность прогнозирования занятости частотного ресурса, что является важным результатом для создания систем когнитивного радио.

Список литературы (References)

- Адамовский Е. Р., Чертков В. М., Богуш Р. П. Модель формирования карты радиосреды для когнитивной системы связи на базе сотовой сети LTE // Компьютерные исследования и моделирование. — 2022. — Т. 14, № 1. — С. 127–146.
- Adamovskiy E. R., Chertkov V. M., Bogush R. P. Model' formirovaniya karty radiosredy dlya kognitivnoy sistemy svyazi na baze sotovoy seti LTE [Model for building of the radio environment map for cognitive communication system based on LTE] // Computer Research and Modeling. — 2022. — Vol. 14, No. 1. — P. 127–146 (in Russian).
- Adamovskiy Ya. R., Bohush R. P., Chertkov V. M. Constructing radio environment map model for a cognitive communication system based on LTE // Digital Technologies in Education, Science and Industry (DTESI 2022). — 2022.
- Chaves-Villota A., Viteri-Mera C. DeepREM: deep-learning-based radio environment map estimation from sparse measurements // IEEE Access. — 2023. — No. 11. — P. 48697–48714.
- Chertkov V. M., Bohush R. P., Adamovskiy Ya. R. User data separation model in an LTE-based cognitive communication system // Information and Control Systems. — 2023. — No. 5. — P. 43–54.
- EgorAdamovsky. LTE-prediction. — <https://github.com/EgorAdamovsky/lte-prediction> (accessed: 14.11.2024).
- Fawaz W. A., Mosleh H. A. Cellular traffic prediction based on an intelligent model // Mobile Information Systems. — 2021. — No. 1. — P. 1–15.
- Fischer T., Sterling M., Lessmann S. Fx-spot predictions with state-of-the-art transformer and time embeddings // Expert Systems with Applications. — 2024. — No. 249 (B).
- Fu Y., Wang X. Traffic prediction-enabled energy-efficient dynamic computing resource allocation in CRAN based on deep learning // IEEE Open Journal of the Communications Society. — 2022. — No. 3. — P. 159–175.
- García C., Koo I. Extremely randomized trees regressor scheme for mobile network coverage prediction and REM construction // IEEE Access. — 2023. — No. 11. — P. 65170–65180.
- Kurri V., Raja V., Periasamy P. Cellular traffic prediction on blockchain-based mobile networks using LSTM model in 4G LTE network // Peer-to-Peer Networking and Applications. — 2021. — No. 14. — P. 1088–1105.
- Liu D. C., Nocedal J. On the limited memory method for large scale optimization // Mathematical Programming B. — 1989. — Vol. 45. — P. 503–528. — DOI: 10.1007/BF01589116
- Liu Z., Wang Y., Vaidya S., Ruehle F., Halverson J., Soljačić M., Hou T. Y., Tegmark M. Kan: Kolmogorov – Arnold networks // arXiv preprint. — 2024. — arXiv:2404.19756
- Santana Y. H., Plets D., Alonso R. M., Nieto G. G., Martens L., Joseph W. Radio environment map of an LTE deployment based on machine learning estimation of signal levels // IEEE, Bilbao, Spain. — 2022. — P. 1–6.
- Stepanov N., Alekseeva D., Ometov A., Lohan E. S. Applying machine learning to LTE traffic prediction: comparison of bagging, random forest, and SVM // 12th International Congress on Ultra Modern Telecommunications and Control Systems and Workshops. — IEEE, Brno, Czech Republic, 2020. — P. 119–123.
- Team-daniel. KAN. — <https://github.com/team-daniel/KAN> (accessed: 14.09.2024).
- Vaca-Rubio C. J., Blanco L., Pereira R., Caus M. Kolmogorov – Arnold networks (kans) for time series analysis // arXiv preprint. — 2024. — arXiv:2405.08790
- Xu K., Chen L., Wang S. Kolmogorov – Arnold networks for time series: bridging predictive power and interpretability // arXiv preprint. — 2024. — arXiv:2406.02496

- Xu N., Wang W., Fulneček J., Kabot O., Mišák S., Wang L.* TBMF framework: A transformer-based multilevel filtering framework for PD detection // IEEE Transactions on Industrial Electronics. — 2023. — Vol. 71, No. 4. — P. 4098–4107.
- Zeng Q., Qiang S., Geng C., Hua D., Chao L., Ge S.* Traffic prediction of wireless cellular networks based on deep transfer learning and cross-domain data // IEEE Access. — 2020. — No. 8. — P. 172387–172397.
- Zhang C., Dang S., Shihada B., Alouini M.* Dual attention-based federated learning for wireless traffic prediction // IEEE INFOCOM 2021 – IEEE Conference on Computer Communications. — IEEE, Vancouver, BC, Canada, 2021. — P. 1–10.
- Zhang C., Patras P.* Long-term mobile traffic forecasting using deep spatio-temporal neural networks // The Eighteenth ACM International Symposium on Mobile Ad Hoc Networking and Computing, Los Angeles CA USA. — 2018. — P. 231–240.