

УДК 004.032.26

Анализ структуры целевого сигнала NR и LTE на основе нейросетевого подхода и методов глубокого обучения

Арефьев А. С., Варыгин А. А., Фокин Г. А.

Санкт-Петербургский государственный университет телекоммуникаций им. проф. М. А. Бонч-Бруевича,
Санкт-Петербург, 193232, Российская Федерация

Постановка задачи: стремительное развитие и уплотнение сетей широкополосного беспроводного доступа четвертого (4G LTE) и пятого (5G NR) поколений определяют необходимость поиска путей повторного использования частот. Известным решением данной проблемы является концепция когнитивного радио. Использование искусственного интеллекта в сетях радиодоступа в целом, и применение нейросетевого подхода с глубоким обучением для распознавания сигналов стандартов LTE и NR в частности, обладают серьезным потенциалом для практической реализации повторного использования частотного ресурса согласно концепции когнитивного радио. **Целью работы** является анализ моделей, методов и алгоритмов, позволяющих распознавать сигналы стандартов NR и LTE на основе записи выборок радиосигналов, полученных с помощью предварительно записанных сигналов NR и LTE в программном обеспечении MatLab. В настоящей работе рассматриваются процедуры сканирования и распознавания участков спектра. Исследованы операции по обучению сети семантической сегментации для идентификации этих сигналов в широкополосной спектрограмме и использованию обученной сети для последующего зондирования спектра и распознавания сигналов стандартов NR и LTE. **Используемым методом** для апробации концепции когнитивного радио является зондирование спектра для получения информации о занятости полос частот в заданном местоположении первичными пользователями, а также выявление участков спектра, доступных для использования вторичными пользователями без вмешательства в работу первичных пользователей в режиме реального времени. Элементом **новизны** работы является использование нейросетевого подхода при анализе целевого сигнала NR и LTE. **Результат:** обученная на основе нейросетевого подхода и методов глубокого обучения модель способна различать сигналы стандартов NR и LTE. **Теоретическая / Практическая значимость:** программная реализация спектрального зондирования реализована с использованием среды MatLab и позволяет выполнять экспериментальную апробацию приемника когнитивного радио при анализе структуры целевого сигнала стандартов NR и LTE на основе нейросетевого подхода и методов глубокого обучения.

Ключевые слова: MatLab, LTE, NR, когнитивное радио, сеть семантической сегментации, глубокое обучение

Источник финансирования: статья подготовлена в рамках прикладных научных исследований СПбГУТ, регистрационный номер 1023031600087-9-2.2.4;2.2.5;2.2.6;1.2.1;2.2.3 в ЕГИСУ НИОКТР.

Библиографическая ссылка на статью:

Арефьев А. С., Варыгин А. А., Фокин Г. А. Анализ структуры целевого сигнала NR и LTE на основе нейросетевого подхода и методов глубокого обучения // Информационные технологии и телекоммуникации. 2024. Т. 12. № 1. С. 16–28. DOI: 10.31854/2307-1303-2024-12-1-16-28. EDN: GEOTKR

Reference for citation:

Arefev A., Varygin A., Fokin G. Analysis of NR and LTE Target Signal Structure Based on Neural Network Approach and Deep Learning Methods. *Telecom IT*. 2024. Vol. 12. Iss. 1. PP. 16–28 (in Russian). DOI: 10.31854/2307-1303-2024-12-1-16-28. EDN: GEOTKR

Введение

Глобальный сетевой трафик продолжает расти из-за увеличивающейся популярности и простоты доступа к беспроводным устройствам. Поиск нового свободного спектра для удовлетворения возрастающих требований к обслуживанию большего количества устройств становится все более сложным и дорогостоящим процессом. Проблема такого рода дефицита может быть связана с традиционной политикой распределения фиксированного радиочастотного спектра, в результате которой большая его часть доставалась лицензированным первичным пользователям, а меньшая – нелицензированным вторичным пользователям. Поскольку значительная часть дорогостоящего частотного ресурса, предоставляемого беспроводным системам, не всегда одновременно используется на различных территориях, статическое распределение спектра в большинстве современных сетей представляется недостаточно эффективным.

Методы статического распределения спектра защищают первичных пользователей от помех, но не реализуют потенциал повторного использования частот вторичными пользователями. В связи со стремительным ростом числа приемопередающих устройств методы статического распределения частот перестают отвечать перспективным требованиям. Концепция динамического управления спектром (ДУС) позволяет вторичным пользователям получать доступ к спектру первичных пользователей, если он не используется в текущий момент времени, или даже использовать спектр совместно с ними, если их передача защищена от помех.

Когнитивное радио основано на концепции ДУС и обеспечивает эффективное использование спектра, позволяя вторичным пользователям своевременно получать доступ к незанятым частотным диапазонам первичных пользователей.

Термин «когнитивное радио» был предложен Джозефом Митолой и Саймоном Хайкином [1], а первым международным стандартом, реализующим эту технологию, стал IEEE 802.22 [2]. В настоящее время ДУС используется в нескольких стандартах, таких как Zigbee (IEEE 802.15.4) [3] и Wi-Fi (IEEE 802.11) [4]. Когнитивное радио состоит из нескольких подсистем: спектрального зондирования, обучения и принятия решения. Архитектура концепции показана на рисунке 1.

Подсистема мониторинга в реальном масштабе времени определяет свободные участки частотного спектра и/или свободные временные позиции в структуре сигналов, создаваемых действующими средствами связи («белые пятна»). Полученные данные поступают в модуль обучения и далее – в модуль принятия решения, который формирует прогноз зашумленности канала, анализирует скорость объекта, возможность связи с объектом на нужной радиочастоте и разрешает передачу сигналов новым средствам на условиях, исключающих взаимные помехи [5].

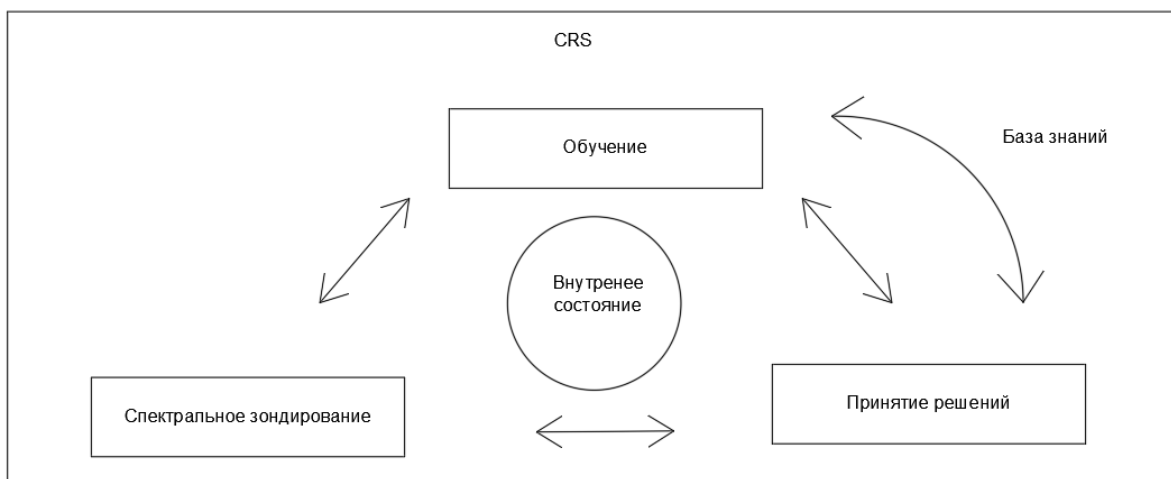


Рис. 1. Концепция системы когнитивного радио

Спектральное зондирование является одним из наиболее важных инструментов когнитивного радио, который предоставляет информацию о занятости полос частот, доступных для вторичных пользователей, в режиме реального времени, не вмешиваясь в работу первичных пользователей. Точное определение занятости полос спектра имеет решающее значение при работе когнитивного радио, поскольку на нем основаны все стратегии вторичной передачи.

Процесс извлечения информации о каналах вручную требует экспертных знаний и является достаточно трудоемким. Для разрешения данной проблемы необходимо прибегнуть к использованию глубоких нейронных сетей, что в совокупности с программным средством MatLab позволяют анализировать частотный ресурс на предмет его текущей занятости.

В настоящей работе выполняется моделирование процедур распознавания сигналов стандартов NR и LTE в заданных участках спектра; рассматривается обучение сети семантической сегментации для идентификации этих сигналов в широкополосной спектрограмме. Сеть семантической сегментации обучается на больших объемах данных в рамках искусственной нейронной сети мониторинга спектра. При обучении применяется технология компьютерного зрения, которое использует технику семантической сегментации при обработке беспроводных сигналов для идентификации объектов и их расположения на изображении. Семантическая сегментация – процедура разделения изображения на отдельные группы пикселей – применяется для распознавания спектрального содержания в широкополосной спектрограмме. Одним из преимуществ беспроводных сигналов в области глубокого обучения является тот факт, что сигналы могут быть заблаговременно сформированы с заданным уровнем шума в среде моделирования MatLab [6]. Существуют модели искажений канала и радиочастот, вследствие чего вместо ручной маркировки сигналов можно генерировать сигналы 5G NR с помощью 5G Toolbox [7] и сигналы LTE с помощью функций LTE Toolbox [8]. Эти сигналы можно пропустить через стандартные модели каналов для создания обучающих данных.

Для начала обучения сети семантической сегментации необходимо создать обучающие данные. Далее приводятся особенности моделирования согласно [9].

Определение спектра с помощью глубокого обучения для идентификации сигналов NR и LTE

Обучающие данные представляют собой сигналы с определенными параметрами. Сигнал делится на кадры. Длительность каждого кадра составляет 40 мс, что соответствует 40 субкадрам. Сеть предполагает, что сигнал 5G NR или LTE занимает одну и ту же полосу частот в течение всего времени кадра. При проверке производительность сети генерируются кадры, которые содержат сигналы 5G NR и LTE на различных случайных полосах в пределах заданного диапазона частот.

Частота дискретизации равна 61,44 МГц и достаточна для обработки большинства сигналов. Для мониторинга более широкой полосы можно увеличить частоту дискретизации, повторно создавая обучающие кадры и переобучая сеть.

Обучающие данные в программном обеспечении MatLab создаются при помощи функции `helperSpecSenseTrainingData`. Она использует функцию `helperSpecSenseNRSignal` для генерации сигналов 5G NR и для сигналов LTE – функцию `helperSpecSenseLTESignal`. В таблице 1 указаны параметры, которые задаются для сигнала 5G NR, а в таблице 2 – для сигнала LTE.

Таблица 1 – Переменные параметры сигналов 5G NR

Параметры 5G NR	Значение	Величина
Полоса пропускания	[10 15 20 25 30 40 50]	МГц
Расстояние между поднесущими	[15 30]	кГц
Шаблон блока SSB	[«Случай А» «Случай В»]	
Период SSB	[20]	мс

Таблица 2 – Переменные параметры сигналов LTE

Параметры LTE	Значение	Величина
Опорный канал	[«R.2», «R.6», «R.8», «R.9»]	
Полоса пропускания	[10 5 15 20]	МГц
Тип дуплекса	FDD	

Для добавления искажений в канал используются функции `nrCDLChannel1` и `LteFadingChannel1`. В таблице 3 указаны параметры канала.

Таблица 3 – Переменные параметры канала

Параметры канала	Значение	Величина
Полоса пропускания	[0 40]	дБ
Тип дуплекса	[0 500]	Гц

Создание изображений спектрограмм из сигналов заданной полосы частот осуществляется за счет функции `helperSpecSenseSpectrogramImage`. При расчете спектрограммы применяется быстрое преобразование Фурье длиной

4096 отсчетов. Из полученного изображения спектрограммы генерируются изображения RGB (*аббр. от англ. Red, Green, Blue* – красный, зеленый, синий) разрешением 128×128 пикселей, которое позволяет разместить в памяти достаточно большой пакет изображений во время обучения, обеспечивая при этом достаточно точное представление по времени и частоте.

Функция `helperSpecSenseTrainingData` позволяет запустить процесс загрузки обучающих данных из хранилища данных MatLab, состоящих из трех наборов сигналов: 1) 5G NR; 2) LTE; 3) 5G NR и LTE.

В каждом наборе при имитационном моделировании находится 900 кадров, необходимых для обучения глубокой нейронной сети семантической сегментации, которые имеют разрешение 128×128 и 256×256 пикселей. Если увеличить количество возможных значений параметров системы, увеличится и количество обучающих кадров. В описываемом далее моделировании используются изображения RGB разрешением 128×128 пикселей для обучения сети семантической сегментации с нуля. Изображения с разрешением 256×256 пикселей применяются для трансферного обучения в предварительно обученных сетях семантической сегментации.

Загруженные обучающие данные включают в себя как предварительно обработанные промаркированные данные для LTE и NR, так и неизвестные сигналы в заданном частотном диапазоне.

Аналог тестовых данных – это данные, полученные из прямого радиоэфира путем захвата сигналов LTE и NR с использованием аппаратной части программно-конфигурируемого радио [10, 11].

При обучении используется нейронная сеть, поэтому далее рассмотрим особенности моделирования архитектуры глубокой нейронной сети.

Выбор глубокой нейронной сети

В проводимом согласно [6] моделировании рассматриваются четыре модели глубоких нейронных сетей:

- 1) ResNet-18 [12];
- 2) ResNet-50 [13];
- 3) MobileNet-v2 [14];
- 4) Custom [6].

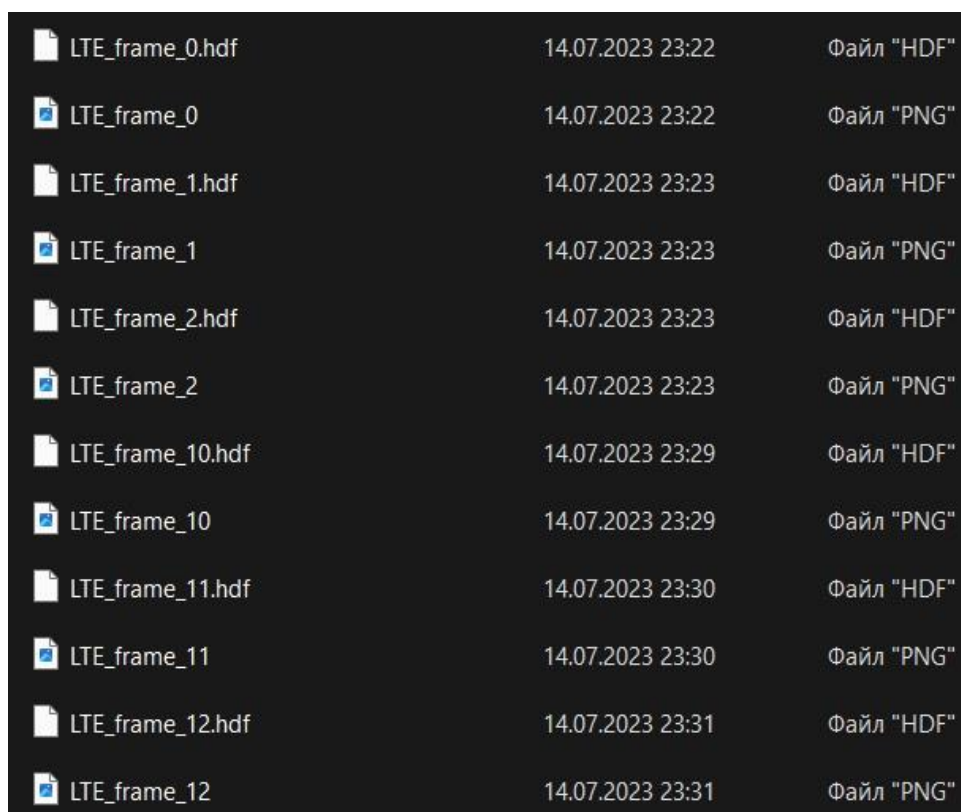
Первые три модели можно распознать как сверточные нейронные сети, предварительно обученные и позволяющие классифицировать изображения по 1000 категорий объектов. При этом входной размер изображения сетей – 224×224 пикселей.

Отличительный признак этих моделей связан с количеством слоев глубины сети: 18 для ResNet-18; 50 для ResNet-50; 53 для MobileNet-v2.

Для обучения сети с нуля в программном коде устанавливается значение Custom. Пользовательская сеть обучается на изображениях RGB размером 128×128 пикселей. На основе выбранных параметров загружаются обучающие данные. Так как в работе используются кадры размером 128×128 пикселей, будет применяться архитектура глубокой нейронной сети Custom.

Функция `imageDatastore` используется для загрузки обучающих изображений со спектрограммой сигналов 5G NR и LTE и позволяет эффективно загружать большую коллекцию изображений с диска. Изображения спектрограмм представляют собой файлы формата `.png`.

С помощью функции `pixelLabelDatastore` загружаются данные изображений меток пикселей спектрограммы. Каждый пиксель помечен как «NR», «LTE», «Noise» или «Unknown». Хранилище данных меток пикселей инкапсулирует данные меток пикселей и идентификатор метки в сопоставление имен классов. Метки пикселей представляют собой файлы формата `.hdf`. Формат обучающих данных представлен на рисунке 2.



LTE_frame_0.hdf	14.07.2023 23:22	Файл "HDF"
LTE_frame_0	14.07.2023 23:22	Файл "PNG"
LTE_frame_1.hdf	14.07.2023 23:23	Файл "HDF"
LTE_frame_1	14.07.2023 23:23	Файл "PNG"
LTE_frame_2.hdf	14.07.2023 23:23	Файл "HDF"
LTE_frame_2	14.07.2023 23:23	Файл "PNG"
LTE_frame_10.hdf	14.07.2023 23:29	Файл "HDF"
LTE_frame_10	14.07.2023 23:29	Файл "PNG"
LTE_frame_11.hdf	14.07.2023 23:30	Файл "HDF"
LTE_frame_11	14.07.2023 23:30	Файл "PNG"
LTE_frame_12.hdf	14.07.2023 23:31	Файл "HDF"
LTE_frame_12	14.07.2023 23:31	Файл "PNG"

Рис. 2. Формат обучающих данных

Просмотр распределения меток классов в наборе данных для обучения осуществляется при помощи функции `countEachLabel`, позволяющей подсчитать количество пикселей по метке классов и построить соответствующий график.

На рисунке 3 изображен график распределения пикселей по меткам классов, полученный в результате имитационного моделирования, на котором видно, что преобладает класс «Noise», а наименьшее значение имеет «Unknown», из чего можно сделать вывод, что спектрограммы зашумлены. Все классы должны иметь одинаковое распределение. В случае с беспроводными сигналами классы в обучающем наборе часто бывают несбалансированными. Сигналы 5G NR могут иметь большую пропускную способность, чем сигналы LTE, и шум заполняет фон. Поскольку обучение смещено в пользу доминирующих классов, дисбаланс в количестве наблюдений в классе может быть пагубным для процесса обучения.

Из подготовленных данных происходит разделение на обучающие, проверочные и тестовые наборы в определенном соотношении. Нейронная сеть использует 80 % сигнальных изображений из набора для обучения, 10 % изображений для проверки и 10 % изображений для тестирования. Функция `helperSpecSensePartitionData` случайным образом разделяет данные изображения и меток пикселей на ранее упомянутые наборы.




Рис. 3. Распределение пикселей по меткам классов

Обучение глубокой нейронной сети

В процессе обучения используется распространенный в сетях семантической сегментации шаблон, где происходит понижение разрешения изображения между сверточным слоем и слоем выпрямительной функции линейной активации (ReLU), которая выводит данные напрямую и преобразует входное значение от 0 до положительной бесконечности: если выходное значение меньше или равно нулю, то выдает ноль. Затем выполняется повышение разрешения выходных данных в соответствии с размером входных данных. Во время этого процесса сеть выполняет операции с использованием нелинейных фильтров, оптимизированных для определенного набора классов, которые необходимо сегментировать.

Сначала определяется входной слой изображения, затем сеть *понижает* разрешение, состоящее из слоев свертки и ReLU. Заполнение слоя свертки выбирается таким образом, чтобы выходной размер слоя свертки был таким же, как и размер входного слоя. Это упрощает построение сети, так как входные и выходные размеры между большинством слоев остаются неизменными по мере продвижения по сети.

Принудительное *понижение* разрешения (downsampling) выполняется с использованием максимального слоя пулинга (пулинг – выбор максимального значения из выборки в нейронных сетях). Создается слой максимального пула

для понижения разрешения входных данных в два раза. При сложении слоев свертки ReLU и максимального пула создается сеть, которая понижает входные данные в 16 раз.

Принудительное *повышение* разрешения (upsampling) выполняется с помощью транспонированного слоя свертки (также обычно называемого слоем «деконволюция»). Когда транспонированная свертка используется для повышения дискретизации, она выполняет процедуру upsampling и фильтрацию одновременно.

Окончательный набор слоев отвечает за классификацию пикселей. Эти слои обрабатывают входные данные, которые имеют те же пространственные размеры (высоту и ширину), что и входное изображение. Эти два слоя объединяются для прогнозирования категориальной метки для каждого пикселя изображения. Чтобы завершить процесс сети семантической сегментации необходимо сложить все слои.

Процесс обучения глубокой нейронной сети, изображенный на рисунке 4, занимает около пяти часов и состоит из 20 этапов и 900 итераций. По оси X показано количество итерацией, по оси Y – процент потерь кадров. Оранжевая линия показывает значение аппроксимации, а синяя линия – реальное значение потерь.

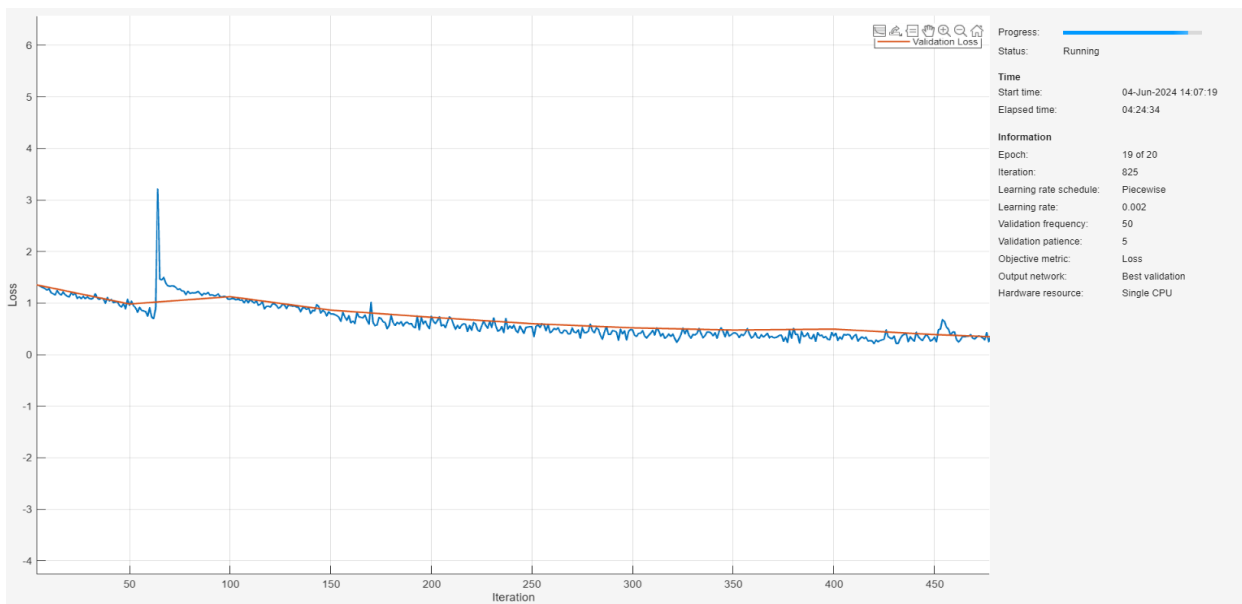
При обучении сети на начальных итерациях процент потерь кадров больше, с увеличением количества итераций значение потерь стабилизируется и не превышает 0,3 %. После обучения нейронной сети следует проверить ее эффективность.

Тестирование глубокой нейронной сети


Для проверки эффективности распознавания сигналов используются фрагменты записи, содержащие сигналы 5G NR и LTE. Функция `semanticseg` используется для получения пиксельных оценок изображений спектрограммы в тестовом наборе данных, а функция `evaluateSemanticSegmentation` – для вычисления различных метрик оценки качества результатов семантической сегментации.

На рисунке 5 изображена матрица неопределенности: по оси X – класс искомого сигнала, по оси Y – распознанных сигналов, по диагонали показан процент распознанных сигналов. Затем разделяем тестовые данные на захваченные и сгенерированные наборы и повторяем тот же процесс, рассматривая только кадры с захваченными данными в тестовом наборе. На рисунке 6 изображена нормализованная матрица неопределенности.

Матрица неопределенности показывает, что сеть путает сигналы NR с сигналами «Noise» или «Unknown». Изучение перехваченных сигналов показывает, что сигналы с префиксом файла CF3550 имеют очень низкое отношение сигнал/шум и сеть испытывает трудности с их правильной идентификацией.



а)



б)

Рис. 4. Процесс обучения нейронной сети начальных (а) и конечных (б) итераций

True Class	LTE	95.1%	2.8%	2.1%	0.0%
	NR	2.7%	92.6%	4.7%	0.0%
	Noise	3.3%	7.6%	89.2%	0.0%
	Unknown				
	Predicted Class	LTE	NR	Noise	Unknown

Рис. 5. Матрица неопределенности для всех тестовых кадров

True Class	LTE	99.9%	0.1%	0.0%	
	NR	0.2%	89.6%	7.3%	
	Noise	0.0%	0.3%	98.0%	
	Unknown	0.0%	0.1%	0.5%	
	Predicted Class	LTE	NR	Noise	Unknown

Рис. 6. Нормализованная матрица неопределенности

На рисунке 7 изображена идентификация сигналов 5G NR и LTE в спектрограмме с учетом и без учета названия файла с префиксом CF3550.

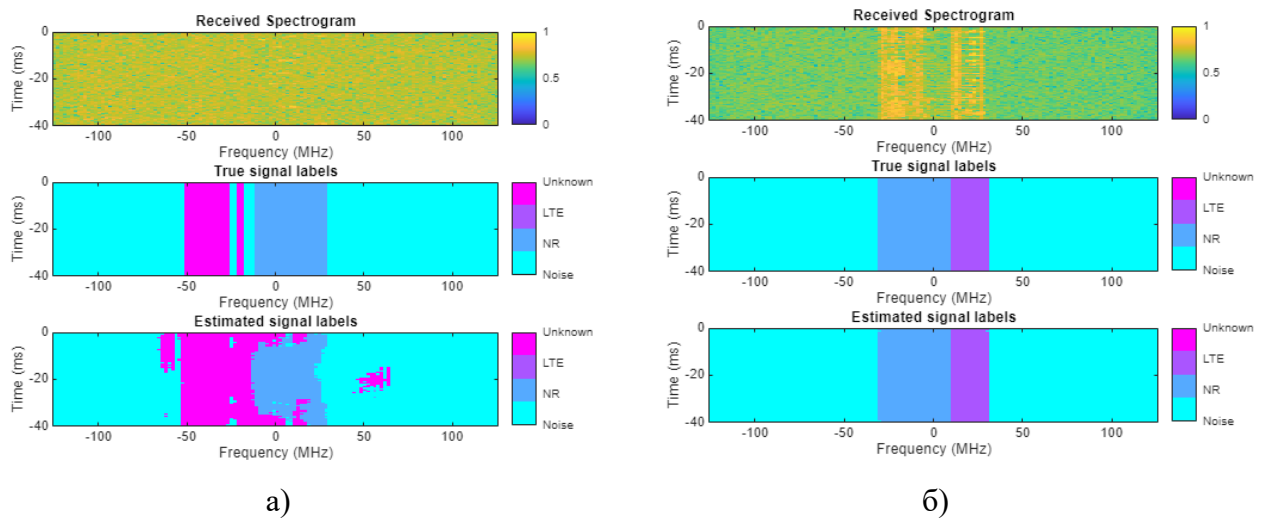


Рис. 7. Идентификация сигналов 5G NR и LTE в спектрограмме с учетом (а) и без учета (б) названия файла с префиксом CF3550

Можно заметить, что в спектрограмме без учета названия файла с префиксом CF3550 видно четкое разделение сигналов NR и LTE. Маркированная спектрограмма, изображенная на рисунке 8, демонстрирует, что большую часть полосы частот занимает «Noise», а также, что полоса частоты сигнала NR больше, чем LTE.




Рис. 8. Маркированная спектрограмма

На данном этапе завершается процесс анализа структуры целевого сигнала NR и LTE на основе нейросетевого подхода и методов глубокого обучения.

Выводы и перспективы исследования

Выполненное имитационное моделирование показало, что обученная сеть может различать сигналы NR и LTE на основе данных, полученных из среды MatLab. Сеть может быть не в состоянии правильно идентифицировать каждый захваченный сигнал. В таких случаях необходимо улучшать обучающие данные, генерируя более показательные синтетические сигналы, или захватывать сигналы из радиоэфира и включать их в обучающую выборку. Результаты, полученные после обучения, могут отличаться от приведенных в данном моделировании для разных сетей из-за случайных начальных условий.

В дальнейших исследованиях планируется реализация глубокого обучения семантической сегментации с использованием платы LibreSDR при работе с сигналами из радиоэфира.

Литература

1. Haykin S. Cognitive Radio: Brain-Empowered Wireless Communications // IEEE Journal on Selected Areas in Communications. 2005. Vol. 23. Iss. 2. PP. 201–220. DOI: 10.1109/JSAC.2004.839380
2. IEEE Standard – Information Technology-Telecommunications and Information Exchange between Systems-Wireless Regional Area Networks-Specific Requirements-Part 22: Cognitive Wireless RAN MAC and PHY specifications: Policies and Procedures for Operation in the Bands that Allow Spectrum Sharing where the Communications Devices May Opportunistically Operate in the Spectrum of Primary Service. URL: <https://standards.ieee.org/ieee/802.22/5896/>
3. IEEE Standard for Low-Rate Wireless Networks. URL: <https://standards.ieee.org/ieee/802.15.4/7029/>
4. IEEE Standard for Information Technology – Telecommunications and Information Exchange between Systems Local and Metropolitan Area Networks. Specific Requirements. Part 11: Wireless LAN Medium Access Control (MAC) and Physical Layer (PHY) Specifications. URL: <https://standards.ieee.org/ieee/802.11/5536/>
5. Коротченко В. Д., Левченко С. А., Роенков Д. Н. Перспективы и особенности внедрения когнитивного радио на железнодорожном транспорте // Научно-техническая конференция Санкт-Петербургского НТО РЭС им. А. С. Попова, посвященная дню радио. 2020. № 75. С. 202–204. EDN: ZKLWOD
6. Syed S. N., Lazaridis P. I., Khan F. A., Ahmed Q. Z., Hafeez M. et al. Deep Neural Networks for Spectrum Sensing: A Review // IEEE Access. 2023. Vol. 11. PP. 89591–89615. DOI: 10.1109/ACCESS.2023.3305388. EDN: PUAYON
7. Spectrum Sensing with Deep Learning to Identify 5G and LTE Signals. URL: <https://www.mathworks.com/help/comm/ug/spectrum-sensing-with-deep-learning-to-identify-5g-and-lte-signals.html> (дата обращения 04.07.2024)
8. 5G Toolbox. URL: <https://www.mathworks.com/products/5g.html> (дата обращения 04.07.2024)
9. LTE Toolbox. URL: <https://www.mathworks.com/products/lte.html> (дата обращения 04.07.2024)

10. Фокин Г. А., Буланов Д. В., Волгушев Д. Б. Модельно-ориентированное проектирование систем радиосвязи на основе ПКР // Вестник связи. 2015. № 6. С. 26–30. EDN: XDCTPR

11. Фокин Г. А., Лаврухин В. А., Волгушев Д. А., Киреев А. В. Модельно-ориентированное проектирование на основе SDR // Системы управления и информационные технологии. 2015. № 2 (60). С. 94–99. EDN: TWKVQB

12. resnet18. URL: <https://www.mathworks.com/help/deeplearning/ref/resnet18.html> (дата обращения 04.07.2024)

13. resnet50. URL: <https://www.mathworks.com/help/deeplearning/ref/resnet50.html> (дата обращения 04.07.2024)

14. mobilenetv. URL: <https://www.mathworks.com/help/deeplearning/ref/resnet50.html> (дата обращения 04.07.2024)

**Статья поступила 19 сентября 2024 г.
Одобрена после рецензирования 28 сентября 2024 г.
Принята к публикации 07 октября 2024 г.**

Информация об авторах

Арефьев Алексей Сергеевич – магистрант (группа Р-32м) Санкт-Петербургского государственного университета телекоммуникаций им. проф. М. А. Бонч-Бруевича

Варыгин Александр Андреевич – магистрант (группа Р-32м) Санкт-Петербургского государственного университета телекоммуникаций им. проф. М. А. Бонч-Бруевича

Фокин Григорий Алексеевич – доктор технических наук, профессор, профессор кафедры беспроводных технологий и систем Санкт-Петербургского государственного университета телекоммуникаций им. проф. М. А. Бонч-Бруевича. E-mail: fokin.ga@sut.ru

Analysis of NR and LTE Target Signal Structure Based on Neural Network Approach and Deep Learning Methods

A. Arefev, A. Varygin, G. Fokin

The Bonch-Bruevich Saint Petersburg State University of Telecommunications,
St. Petersburg, 193232, Russian Federation

Purpose: the rapid development and consolidation of broadband wireless access networks of the fourth 4G LTE and fifth 5G NR generations determine the need to find ways to reuse frequencies. A well-known solution to this problem is the concept of cognitive radio. The use of artificial intelligence in radio networks in general and the use of a neural network approach with deep learning for recognizing signals of LTE and NR standards in particular have serious potential for the practical implementation of frequency resource reuse according to the concept of cognitive development. **The aim of the work:** is to analyze models, methods and algorithms that allow recognizing signals of the NR and LTE standards based on recording samples of radio signals obtained using pre-recorded NR and LTE signals in MatLab software. In this paper, the procedures for scanning and recognizing sections of the spectrum are considered. The operations of training a semantic segmentation network for the identification of these signals in a broadband spectrogram and the use of a trained network for subsequent spectrum sensing and recognition of signals of the NR and LTE standards are investigated. **Methods:** the method used to test the concept of cognitive radio is spectrum sensing, which results in information about the occupancy of frequency bands in a given location by primary users, and the identification of spectrum sections available for use by secondary users without interfering with the work of primary users in real time. The **novelty** of the work is the use of a neural network approach in the analysis of the target NR and LTE signal. **Results:** the model, trained on the basis of a neural network approach and deep learning methods, is able to distinguish between signals of the NR and LTE standards. **Theoretical / Practical relevance:** the software implementation of spectral sensing is implemented using an extension package in the MatLab environment and allows for experimental testing of a cognitive radio receiver when performing procedures for analyzing the structure of the target signal of the NR and LTE standards based on a neural network approach and deep learning methods.

Key words: MatLab, LTE, NR, cognitive radio, semantic segmentation network, deep learning.

Funding: the article was prepared within the framework of applied scientific research SPbSUT, registration number 1023031600087-9-2.2.4;2.2.5;2.2.6;1.2.1;2.2.3 in the information system (<https://www.rosrid.ru/information>).

Information about Authors

Arefev Aleksey – B. Sc., Master Student of R-32m Group (The Bonch-Bruevich Saint Petersburg State University of Telecommunications)

Varygin Aleksandr – B. Sc., Master Student of R-32m Group (The Bonch-Bruevich Saint Petersburg State University of Telecommunications)

Fokin Grigory – Doctor of Technical Sciences, Associate Professor, Professor of the Department of Wireless Technologies and Systems (The Bonch-Bruevich Saint Petersburg State University of Telecommunications). E-mail: fokin.ga@sut.ru