

Экспериментальная апробация моделей спектрального зондирования для идентификации сигналов средствами искусственного интеллекта

Г.А. ФОКИН,
д-р техн. наук,

Д.Б. ВОЛГУШЕВ

(Санкт-Петербургский государственный университет телекоммуникаций им. проф. М.А. Бонч-Бруевича,

Санкт-Петербург)
grihafokin@gmail.com

Проведена экспериментальная апробация моделей спектрального зондирования для определения приемником когнитивного радио информации о структуре целевого сигнала на основе нейросетевого подхода. Описывается порядок работы моделей захвата и разметки LTE-сигналов при сканировании радиоэфира аппаратными средствами программно-конфигурируемого радио и программными средствами среды MATLAB. Для идентификации LTE-сигналов используются модели глубокого обучения нейронной сети семантической сегментации изображений спектрограмм.

Спектральное зондирование, искусственный интеллект, программно-конфигурируемое радио, идентификация LTE-сигналов

В современных и перспективных сетях связи под спектральным зондированием подразумевается определение приемником когнитивного радио информации о структуре целевого сигнала [1]. Данный инструмент используется для практической реализации концепции когнитивного радио и развивающегося в ее рамках подхода динамического доступа к спектру. При динамическом доступе к спектру эпизодическое использование участков спектра, изначально выделенных первичным пользователям, возможно вторичными пользователями при условии неактивности первичных пользователей «здесь и сейчас». Для оценки занятости спектра первичными пользователями вторичные пользователи могут использовать методы и средства спектрального зондирования. С развитием методов и средств искусственного интеллекта в задачах спектрального зондирования широко используются глубокие нейронные сети [2], с помощью которых можно решать задачи распознавания параметров сигналов [3] и оценивать отношение сигнал – шум в канале связи [4]. Кроме корреляционного анализа [5] для обнаружения и идентификации параметров сигналов может быть использован инструментарий анализа изображений их спектрограмм [6]. Модели и методы нейронных сетей применяются не только для решения задач спектрального зондирования в области сетей радиосвязи, но и в сфере диагностики и прогнозирования технического состояния агрегатов винтокрылых летательных аппаратов [7], а также управления мехатронным модулем космического назначения [8].

В настоящей работе исследуются модели спектрального зондирования для идентификации сигналов средствами искусственного интеллекта. Цель работы – экспериментальная апробация процесса обучения нейронной сети семантической сегментации на основе синтезированных и принятых из радиоэфира сигналов средствами программно-конфигурируемого радио SDR (Software Defined Radio).

Рассматриваемые в настоящем исследовании модели спектрального зондирования предназначены для реализации процедуры анализа спектра с идентификацией LTE-сигналов в заданной полосе сканирования с использованием методов глубокого обучения, нейронных сетей и семантической сегментации изображений. Модели реализованы в среде MATLAB с использованием пакетов расширения LTE Toolbox, Communications Toolbox, Computer Vision Toolbox, Deep Learning Toolbox. Для идентификации LTE-сигналов в настоящем исследовании используются методы и средства искусственного интеллекта, и в частности семантической сегментации изображений. Анализ и идентификация сигнала осуществляется следующим образом: сначала записывается спектрограмма сигнала, принятого из радиоэфира или синтезированного в LTE Toolbox, затем эта спектрограмма преобразуется в изображение, которое потом анализируется средствами семантической сегментации на наличие LTE-сигналов.

При спектральном зондировании в сетях радиосвязи интересующими объектами являются сигналы различных стандартов, например LTE. В таком случае результатом работы нейронных сетей является локализация этих сигналов в частотно-временной системе координат спектрограммы, а также определение

ние их принадлежности к тому или иному стандарту связи. В данной работе использован метод семантической сегментации изображений спектрограмм радиоэфира для обнаружения и идентификации в них LTE-сигналов в направлении «вниз» (от базовой станции к пользовательскому устройству) в заданной полосе сканирования.

LTE-сигнал на физическом уровне направления «вниз» построен на базе технологии OFDM (Orthogonal Frequency Division Multiplexing) с разносом поднесущих 15 кГц. Для анализа LTE-сигналов методом семантической сегментации изображений необходимо учитывать основные характеристики сигнала – ширину полосы и длительность. Стандартом определены следующие значения ширины полосы сигнала: 1,4; 3; 5; 10; 15; 20 МГц. Формирование частотно-временной ресурсной сетки осуществляется ресурсными блоками. Каждый ресурсный блок занимает в частотной области двенадцать поднесущих, или 180 кГц, а во временной области – семь OFDM-символов (шесть для случая расширенного циклического префикса); длительность ресурсного блока – 0,5 мс. Стандарт определяет два основных типа кадра в зависимости от типа дуплексного канала связи. Для частотного дуплекса используется кадр Type-1, для временного дуплекса – кадр Type-2. Оба типа кадра длительностью 10 мс состоят из десяти подкадров длительностью 1 мс. Подкадры могут быть сконфигурированы для передачи пользовательских или служебных данных. Кадры циклически повторяются, формируя поток данных в направлении «вниз».

Приведем основные частотно-временные характеристики LTE-сигнала для разной ширины полосы канала: ширина полосы канала – 1,4; 3; 5; 10; 15; 20 МГц; длительность кадра – 10 мс; разнос поднесущих – 15 кГц; число поднесущих – 128; 256; 512; 1024; 1536; 2048; число используемых поднесущих – 72; 180; 300; 600; 900; 1200; число ресурсных блоков – 6; 15; 25; 50; 75; 100; ширина занимаемой полосы – 1,08; 2,7; 4,5; 9; 13,5; 18 МГц.

Указанные характеристики одинаковы для обоих типов кадра. Занимаемая ширина полосы меньше ширины полосы канала, так как часть поднесущих по краям спектра не передается, а используется для формирования защитных частотных интервалов между соседними LTE-сигналами.

Приведем примеры изображений спектрограмм с распределением спектральной плотности мощности (СПМ) по частотно-временной ресурсной сетке. Спектрограммы LTE-сигнала для типов кадра Type-1 представлены на рис. 1, *a*, *в*, для Type-2 – на рис. 1, *б*, *г*. Ресурсные блоки могут быть максимально использованы для передачи пользовательских данных (см. рис. 1, *а*, *б*). При низком трафике канала «вниз» частотно-временная сетка может быть заполнена частично (см. рис. 1, *в*, *г*). Некоторые подкадры для типа кадра Type-2 не передаются, так как используются для размещения сигналов канала передачи «вверх» (от пользовательского устройства до базовой станции).

Изображения, подобные примерам на рис. 1, используются в качестве обучающих и исходных данных для нейронной сети с семантической сегментацией изображений. Задача нейронной сети заключается в определении границы спектра LTE-сигнала в канале передачи «вниз» для различных конфигураций ресурсной сетки и для двух типов кадра.

Семантическая сегментация представляет собой процедуру разбиения исходного изображения на группы (сегменты) пикселей, принадлежащих определенному объекту. Результатом этой процедуры являются маски меток изображения. Под маской меток далее понимается массив целых чисел с размерностью, равной размерности исходного изображения, где каждый элемент массива сопоставляется с соответствующим элементом (пиксели) изображения. Классы объектов, которые необходимо локализовать и идентифицировать на изображении, задаются заранее, а элементы маски меток принимают числовое значение, соответствующее одному из этих классов объектов.

Для реализации процедуры семантической сегментации изображений спектрограмм LTE-сигналов в настоящем исследовании используются сверточные нейронные сети. В качестве базовой сети выбрана остаточная сверточная нейронная сеть ResNet50. Сравнительные характеристики различных сверточных нейронных сетей представлены далее.

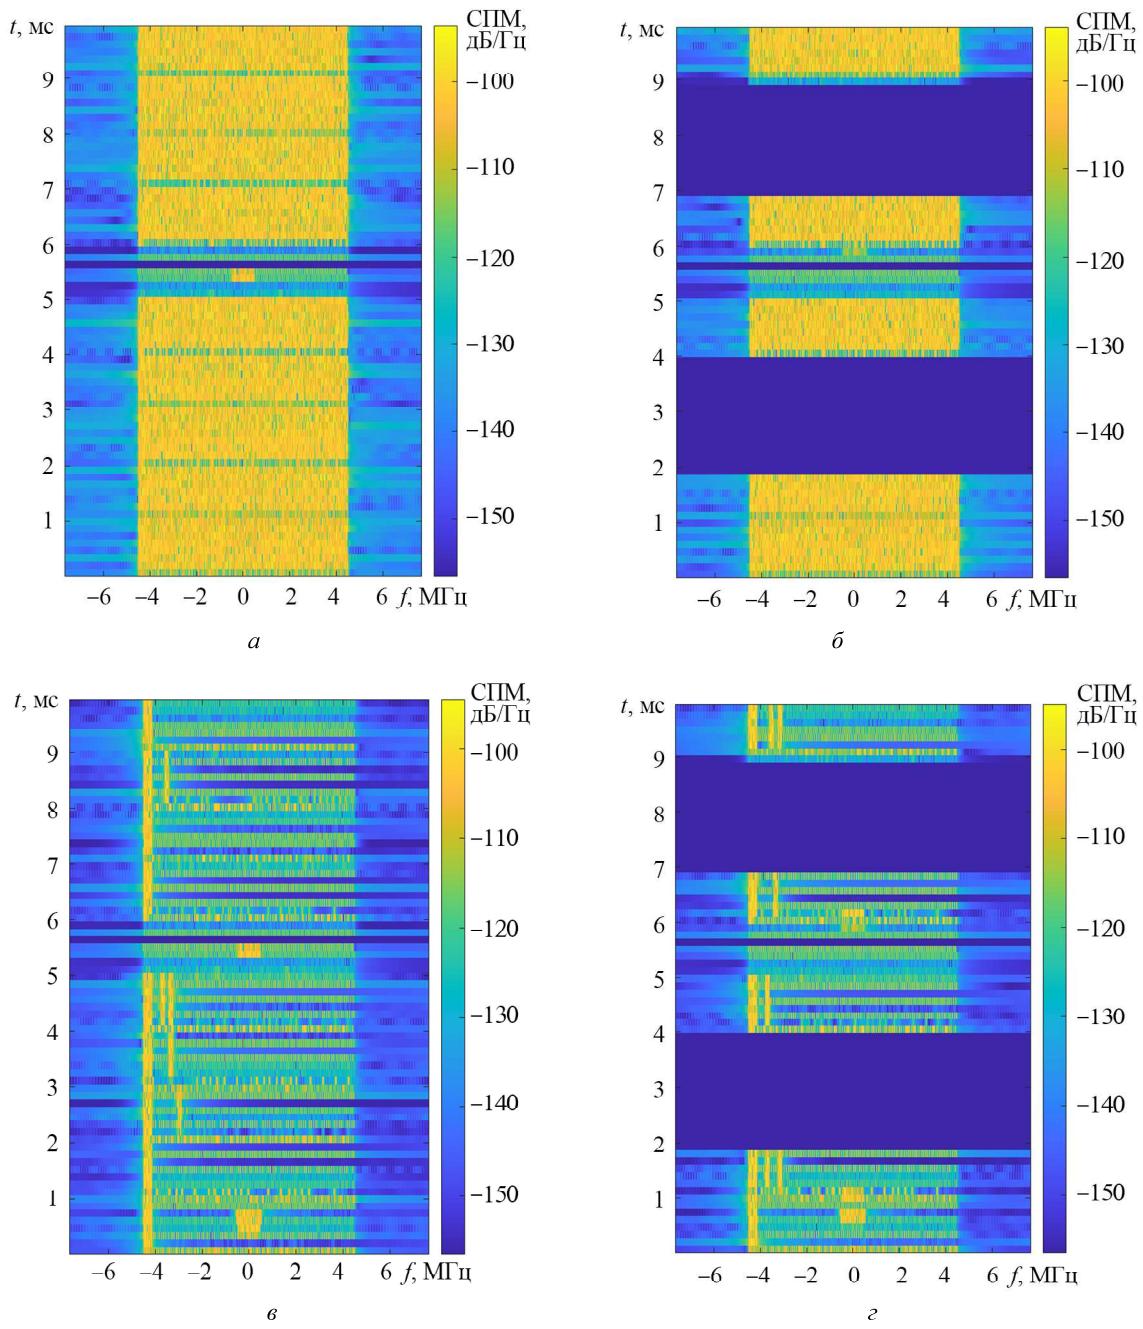


Рис. 1

ResNet50 представляет собой сверточную нейронную сеть глубиной 50 слоев. Один из основных ее элементов – сверточный слой, позволяющий выделять характерные признаки объекта изображения, например границу объекта на изображении. В ResNet50 применяется метод обучения с учителем, когда в качестве входных данных используются изображения с соответствующими масками истинных меток. Сеть ResNet50 обучается формировать прогнозы по входным изображениям, корректируя свои параметры (веса) на основе расхождений между маской полученных меток и маской истинных меток.

Обобщенный процесс обучения нейронной сети для задач идентификации сигналов при спектральном зондировании происходит поэтапно (рис. 2).

В случае семантической сегментации обучающие данные представляют собой изображения с соответствующими масками истинных меток для всех интересующих объектов изображения. Данные в этом наборе должны содержать максимально возможное число примеров изображений интересующего объекта в различных его вариациях. Исходный набор разделяется на две части: данные для обучения и данные для тестирования. Обучающие данные используются для обучения нейронной сети методом прямого и

обратного распространения ошибки. Прямое распространение является стандартным режимом работы нейронной сети, при котором набор входных данных подается на нейронную сеть, а на выходе получают прогноз в виде макси-меток изображения. При обратном распространении задействуется метод градиентного спуска, использующий ошибку, вычисленную на основе предсказанной и истинной меток. При этом на выходе обновляются внутренние параметры всех слоев сети, начиная с последних. В процессе обучения может выполняться несколько циклов прямого и обратного распространения. Тестовый набор данных используется для проверки работы сети. По результатам проверки модель нейронной сети уточняется (структура сети, число слоев). Также в набор обучающих данных добавляются новые, ранее не представленные примеры изображения интересующих объектов. Далее этапы обучения повторяются до достижения требуемой или максимально возможной точности прогноза нейронной сети.

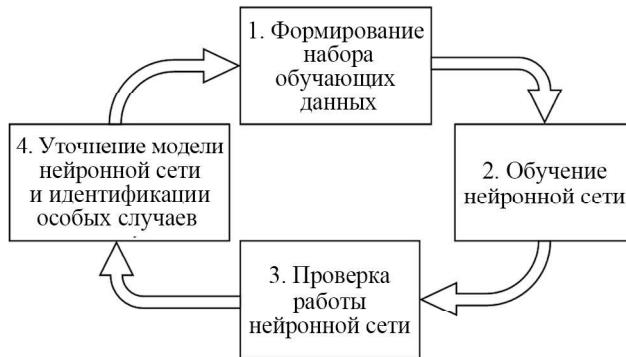


Рис. 2

Экземпляр из набора обучающих данных представляет собой изображение в формате .png спектрограммы LTE-сигнала в полосе частот шириной 61,44 МГц (удвоенная максимальная полоса канала с учетом защитных поднесущих) и длительностью 40 мс (четыре кадра). Изображение описывается массивом RGB-точек размерностью $T \times F$, где $T = 256$ и $F = 256$ число точек (пикселей) по шкалам времени и частоты исходной спектрограммы. Каждому изображению соответствует массив $T \times F$ значений истинных меток. Под меткой далее понимается целое число, которое определяет, к какому классу сигналов относится соответствующий элемент изображения спектрограммы. В данной работе используется два класса сигналов – «LTE» и «шум» с соответствующими метками – 255 и 0.

Для формирования набора обучающих данных используется пакет расширения MATLAB LTE Toolbox, который позволяет создать большой набор данных посредством синтеза сигналов с различными характеристиками и условиями распространения радиоволн.

Приведем параметры LTE-сигнала для формирования набора обучающих данных: конфигурации каналов RMC (Reference Measurement Channel) – R.2, R.6, R.8, R.9; ширина полосы канала BW – 5, 10, 15, 20 МГц; число неиспользуемых транспортных блоков – 0–8; тип кадра (режим дуплекса) – Type-1.

Параметры канала связи для формирования набора обучающих данных: отношение сигнал – шум (SNR) – 10...50 дБ; доплеровский сдвиг частоты – 0...500 Гц; смещение начала кадра – 0...40 мс; смещение по частоте Δf – $(61,44 - BW)/2 \dots + (61,44 - BW)/2$ МГц.

Для обучения использованы конфигурации опорных измерительных каналов RMC стандарта LTE, формируемые функцией `IteRMCDL`. Полосы 1,4 и 3 МГц исключены из конфигураций, так как редко используются операторами связи на практике. Число неиспользуемых транспортных блоков позволяет получить различные варианты заполнения ресурсной сетки: чем больше это значение, тем больше пустых ресурсных блоков будет в итоговом сигнале. В данном случае один транспортный блок соответствует одному подкадру ресурсной сетки. Для всех экземпляров обучающих данных установлен тип кадра Type-1 как наиболее часто используемый на действующих сетях операторов связи. Отношение сигнал – шум позволяет моделировать уровень принимаемого сигнала относительно шума: от слабого сигнала, скрытого шумом при SNR = –10 дБ, до сигнала без шума при SNR = 50 дБ. Доплеровский сдвиг определяет ди-

намику однолучевого канала связи при движении приемного пользовательского устройства. При доплеровском сдвиге 0 Гц импульсная характеристика канала связи не меняется на протяжении всего сеанса связи, что характерно для случая стационарного приемника. При доплеровском сдвиге 500 Гц канал связи меняется достаточно быстро, что соответствует скорости движения приемника порядка 270 км/ч.

Начало сеанса приема пользовательского устройства не синхронизировано с началом кадра сигнала, передаваемого базовой станции. Для учета рассинхронизации в канале «вниз» задается смещение начала кадра относительно начала приема (начала спектрограммы по шкале времени). Смещение принимаемого сигнала относительно центральной частоты (центра спектрограммы) устанавливается в пределах полосы приема 61,44 МГц с учетом ширины полосы сигнала. Каждый экземпляр обучающих данных сохраняется в виде изображения формата .png (см. рис. 1) и соответствующего ему hdf-файла с маской истинных меток. В данной работе формируется набор из 800 экземпляров обучающих данных. Процесс генерации с помощью персонального компьютера на базе Intel Core i7-13700H 2.40 GHz с использованием шести параллельных потоков занимает примерно 7 мин.

В настоящем исследовании используется сверточная нейронная сеть, построенная на базе архитектуры DeepLabv3+ для семантической сегментации изображений. В пакете расширения MATLAB Computer Vision Toolbox данная сверточная нейронная сеть вызывается функцией deeplabv3plus. В пакете расширения MATLAB Deep Learning Toolbox доступен ряд базовых нейронных сетей с семантической сегментацией изображений – MobileNet-v2, ResNet18, ResNet50. Выходной слой классификации элементов изображения для каждой базовой сети модифицирован для задачи формирования маски меток в соответствии с ранее определенными классами – «LTE» и «шум». Каждая базовая сеть обучается на одном и том же наборе обучающих данных.

В таблице представлены сравнительные результаты работы указанных сетей по сформированному ранее набору из 800 экземпляров обучающих данных. В качестве сравнительных метрик выбраны следующие параметры: время обучения T_L ; нормированная матрица несоответствий nCM (матрица ошибок); метрика степени пересечения IoU; счет соответствия BF BFscore (Boundary F1 Score) между предсказанной и истинной сегментацией.

Тип сверточной нейронной сети	nCM, %		IoU	BF BFscore	T_L , мин
MobileNet-v2	98,7	1,3	0,99012	0,99789	30
	2,2	97,8			
ResNet18	98,7	1,3	0,99437	1,00000	11
	1,8	98,2			
ResNet50	98,0	2,0	0,99708	1,00000	92
	1,5	98,5			

Матрица ошибок имеет размерность $N \times N$ (по числу классов сигналов, в данной работе $N = 2$), в которой элемент (i, j) показывает число элементов изображения класса i (истинное значение), классифицированное как элемент класса j (предсказанное значение), где i – индекс строки, j – индекс столбца:

	LTE	Шум
LTE	TP	FP
Шум	FN	TN

Элементы матрицы ошибок для идентификации LTE-сигналов принимают следующие значения: TP (True Positive) обозначает процент правильно классифицированных элементов изображения класса «LTE»; FP (False Positive) – процент элементов изображения класса «шум», интерпретированных как «LTE» (ложное обнаружение LTE-сигнала), FN (False Negative) – процент элементов изображения класса «LTE», интерпретированных как «шум» (пропуск LTE-элемента), TN (True Negative) – процент правильно классифицированных элементов изображения класса «шум». Все значения в матрице ошибок нормированы к общему числу элементов изображения. Метрика IoU вычисляется по значениям матрицы несоответствий nCM и показывает степень пересечения предсказанной маски меток каждого класса объектов изображения (в данной работе – класса спектра LTE-сигнала) и истинной маски меток для этих объектов.

Метрика BFscore показывает, насколько близко предсказанная граница объекта (в данной работе – граница спектра LTE-сигнала) соответствует истинной границе. Например, в таблице для нейронной сети с семантической сегментацией изображений ResNet50 истинный класс сигналов «LTE» корректно спрогнозирован в 98 % случаев (элемент матрицы $nCM_{(1,1)}$ TP при этом равен 98), а в 2 % случаев спрогнозирован некорректно, т. е. классифицирован как «шум» (элемент матрицы $nCM_{(1,2)}$ FP при этом равен 2); истинный класс «шум» интерпретирован как «LTE» в 1,5 % случаев (элемент матрицы $nCM_{(2,1)}$ FN при этом равен 1,5), а в 98,5 % случаев спрогнозирован корректно, т. е. классифицирован как «шум» (элемент матрицы $nCM_{(2,2)}$ TN равен 98,5).

На рис. 3 представлены оценки масок меток трех сверточных нейронных сетей для спектограммы LTE-сигнала в полосе 15 МГц (рис. 3, *a*). При сравнении с маской истинных меток (рис. 3, *б*) более точную оценку границ спектра дают сверточные нейронные сети с архитектурой ResNet, в частности ResNet50. Значение метрики IoU для MobileNet-v2 (рис. 3, *в*) – 0,99012, ResNet18 (рис. 3, *г*) – 0,99437, ResNet50 (рис. 3, *д*) – 0,99708. Значение метрики BFscore для MobileNet-v2 – 0,99789, ResNet18 и ResNet50 – 1.

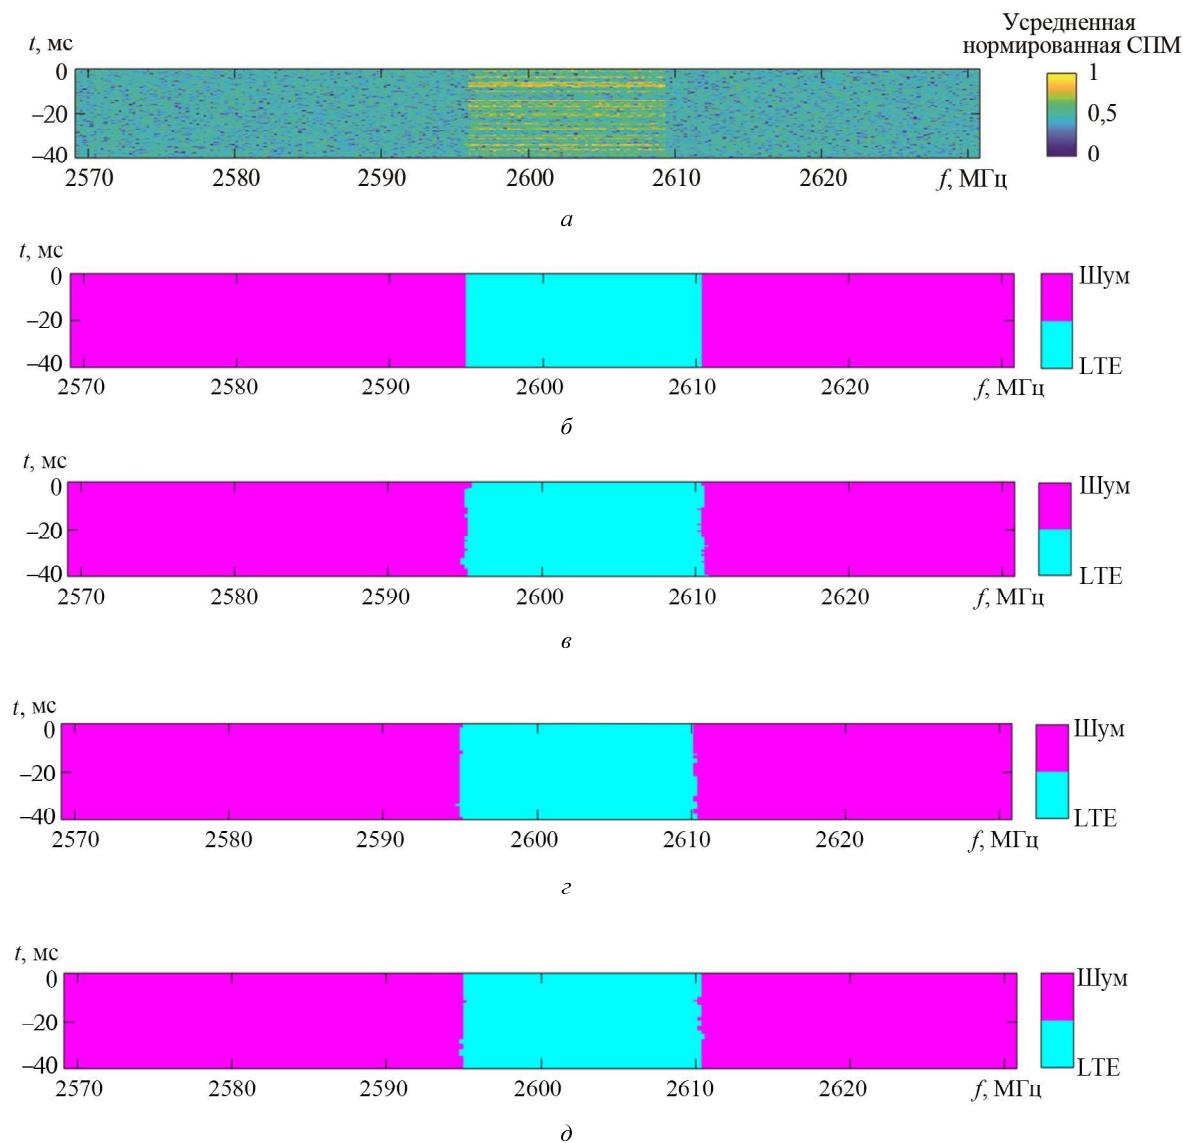


Рис. 3

По значениям метрик IoU и BFscore (см. таблицу, рис. 3) в качестве основной сверточной нейронной сети была выбрана нейронная сеть на базе архитектуры ResNet. Выбор конкретной модификации будет произведен далее по результатам работы с операторскими сигналами из радиоэфира.

Для экспериментальной апробации спектрального зондирования с идентификацией LTE-сигналов в диапазоне работы сетей операторов связи используется SDR-платформа LibreSDR на базе трансивера AD9363 с интерфейсом Ethernet [9]. Также может быть использована SDR-платформа USRP B210 на базе трансивера AD9361 с интерфейсом USB [10–12]. Для конфигурации SDR-платформы LibreSDR и записи сигнала из радиоэфира используется пакет расширения MATLAB Communications Toolbox Support Package for Analog Devices ADALM-Pluto Radio.

Ширина диапазона сканирования определяется выражением $BW_s = f_{stop} - f_{start} + BW_{rx}$. Его границы задаются двумя значениями – нижней $f_{start} + BW_{rx}/2$ и верхней $f_{stop} - BW_{rx}/2$ границей; f_{start} , f_{stop} – минимальное и максимальное значения центральной частоты приема диапазона сканирования, Гц; $BW_{rx} = 30,72$ МГц – ширина полосы приема LibreSDR. Весь диапазон сканирования разбивается на поддиапазоны шириной BW_{rx} с шагом изменения центральной частоты f_{step} . Шаг сканирования задается в пикселях и затем пересчитывается в герцах. Это сделано для удобства дальнейшей обработки спектров и спектрограмм, поскольку в таком случае шаг сканирования становится кратным их размерам. Размер шага – 16 пикселей, или 1,92 МГц.

В каждом поддиапазоне сканирования производится запись десяти выборок сигнала длительностью четыре кадра LTE-сигнала по 10 мс в полосе 30,72 МГц. Для каждой выборки строится спектrogramма с размером быстрого преобразования Фурье, равным 512 точек. Затем полученная спектrogramма преобразуется в RGB-изображение размером 256×256 пикселей. Дополнительно для каждого поддиапазона строится усредненный по всем кадрам спектр для дальнейшей визуализации.

Процедура семантической сегментации выполняется для каждой выборки отдельно, а результаты усредняются по всем выборкам для одного поддиапазона сканирования. Каждый элемент изображения спектrogramмы относится либо к классу «LTE», либо к классу «шум» и описывается двумя вещественными коэффициентами p_{LTE} и $p_{шум}$. Эти коэффициенты определяют вероятность принадлежности элемента изображения к соответствующему классу. Тип класса элемента спектrogramмы выбирается по максимуму из двух коэффициентов: если $p_{LTE} > p_{шум}$, элемент изображения помечается как класс «LTE», в противном случае – класс «шум».

Полученные оценки классов для каждого элемента изображения спектrogramмы объединяются по всем поддиапазонам наложением и усреднением в области наложения, формируя итоговую маску меток изображения спектrogramмы размером 256×256 пикселей. При усреднении в качестве целочисленной метки для класса «LTE» используется 1, а для класса «шум» – 0. На рис. 4 показан пример маски меток для трех соседних поддиапазонов сканирования.

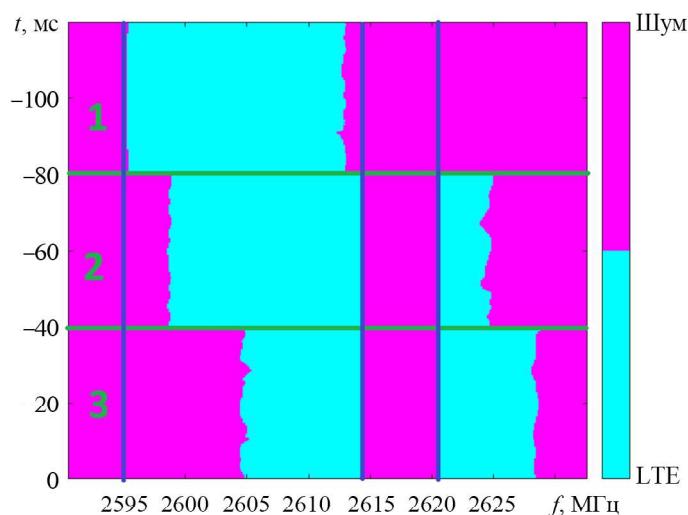


Рис. 4

Из-за амплитудно-частотной характеристики входного тракта SDR-устройства LibreSDR, как и любой другой аппаратной платформы, снижается точность оценки сигналов на границах полосы приема. В поддиапазоне 1 (рис. 4, верхняя маска меток) четко видна левая граница 2595 МГц спектра сигнала с центральной (несущей) частотой 2605 МГц. Этот сигнал наблюдается во всех трех поддиапазонах сканирования, так как поддиапазоны пересекаются (вертикальными линиями на рис. 4 обозначены границы сигнала с центральной частотой 2605 МГц). Однако его левая граница видна только в первом поддиапазоне (поддиапазоны разделены на рис. 4 горизонтальными линиями). В поддиапазонах 2, 3 левая граница уже выпадает из амплитудно-частотной характеристики, поэтому не видна. Правая граница, наоборот, в поддиапазоне 1 не попадает в амплитудно-частотную характеристику, тогда как в поддиапазонах 2, 3 она расположена ближе к центру поддиапазона сканирования. Центральная частота поддиапазона 2 сканирования смешена вправо на 2 МГц, а поддиапазона 3 – еще на 2 МГц. В связи с этим в поддиапазонах 2, 3 видна правая граница сигнала с центральной частотой 2605 МГц, и начинает проявляться соседний сигнал на центральной частоте 2630 МГц. Правая граница сигнала на частоте 2630 МГц не попадает ни в один поддиапазон из трех, а проявится в следующих по мере смещения центральной частоты окнах сканирования по частоте. В полосу приема поддиапазонов 2, 3 попадает соседний сигнал на частоте 2630 МГц. На рис. 4 его правая граница не видна, наблюдается левая граница его спектра. Наложение результатов по поддиапазонам позволяет скомпенсировать эффект амплитудно-частотной характеристики приемного тракта, увеличивая достоверность оценок во всем диапазоне сканирования.

На рис. 5 представлены результаты работы сверточной нейронной сети ResNet50 для диапазона сканирования 2600...2700 МГц. На рис. 5, *а* показан усредненный по всем выборкам и поддиапазонам нормированный спектр мощности всего диапазона сканирования. На рис. 5, *б* показана усредненная спектрограмма диапазона сканирования с оценкой параметров всех обнаруженных LTE-сигналов. Оценка маски меток сигналов для изображения спектрограммы всего диапазона сканирования приведена на рис. 5, *в*. Параметры идентификации – ширина полосы из числа стандартных (например, LTE20 – полоса 20 МГц); центральная частота, МГц; отношение сигнал – шум, дБ.

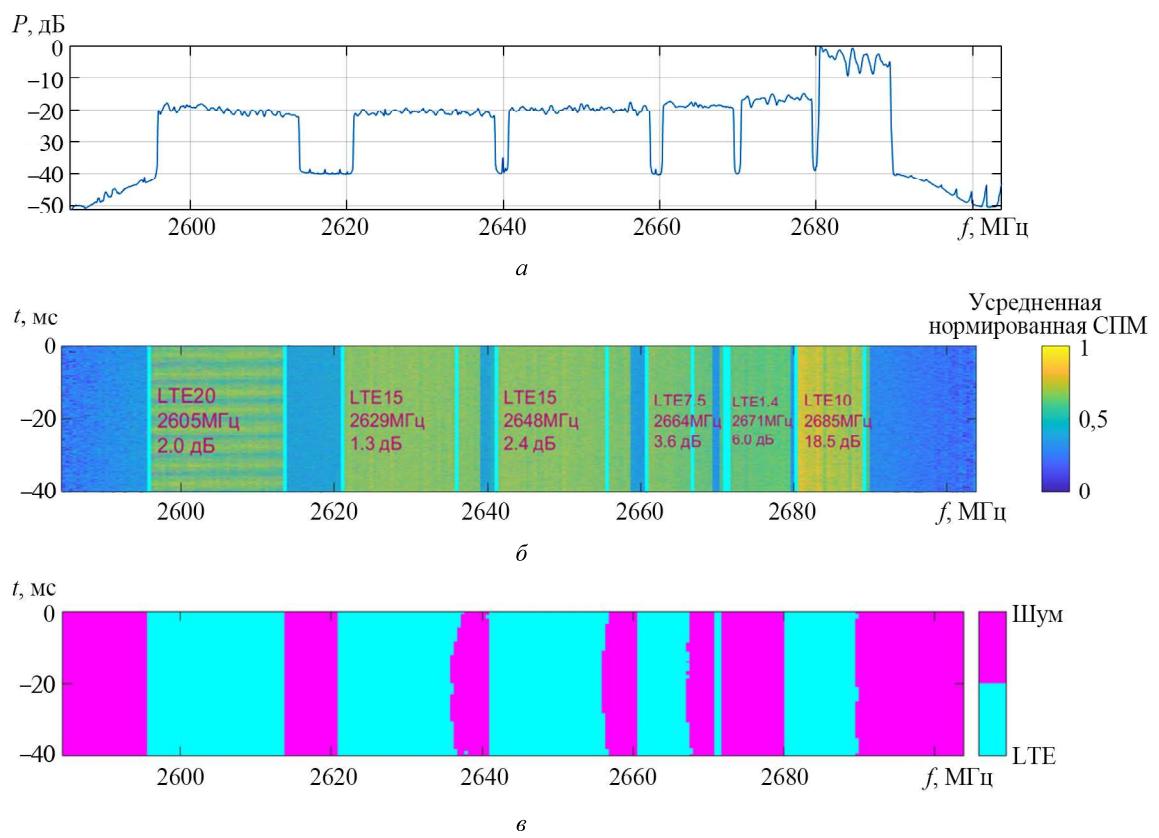


Рис. 5

Для определения спектральных границ каждого LTE-сигнала итоговая маска меток усредняется по времени на интервале четырех кадров LTE-сигнала, т. е. за 40 мс. Усредненные значения, превышающие порог thr , помечаются меткой класса «LTE», равной 1; остальные получают метку класса «шум», равную 0. Значение порога было определено эмпирически и принято равным 0,3.

На рис. 6 представлен график меток для диапазона сканирования 2600...2700 МГц после усреднения мощности, ее нормирования к единице и сравнения с порогом для идентификации LTE-сигналов. Граница перехода классов «шум» → «LTE» из 0 в 1 определяет левую относительно несущей спектральную границу f_L LTE-сигнала. Аналогично граница перехода классов «LTE» → «шум» из 1 в 0 определяет правую спектральную границу f_R LTE-сигнала. Пара соседних границ перехода «шум» → «LTE» и «LTE» → «шум» определяют ширину занимаемой полосы BW_0 одного LTE-сигнала. Каждому обнаруженному LTE-сигналу на спектрограмме назначается ближайшая из числа стандартных полос. Значение центральной частоты f_C определяется как среднее между правой f_R и левой f_L границами $f_C = (f_L + f_R)/2$.

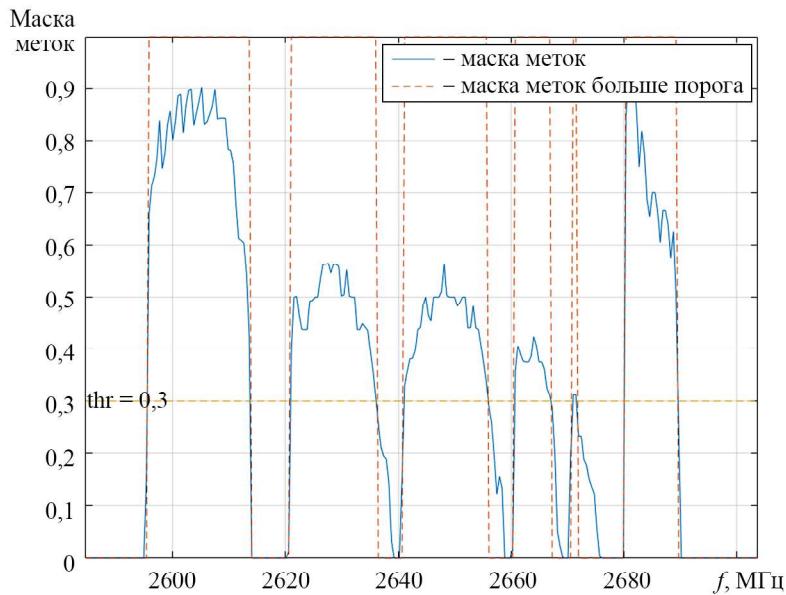


Рис. 6

Отношение сигнал – шум для каждого обнаруженного LTE-сигнала определяется как отношение средней мощности LTE-сигнала в занимаемой им полосе к средней мощности шума по всем полосам в диапазоне сканирования. Из рис. 5, 6 видно, что в случае сигналов с большим частотным разносом (например, сигнал на несущей частоте 2605 МГц) обе границы спектра определены корректно. Одна из границ спектра может определяться с ошибкой при наличии соседнего близко расположенного по частоте сигнала, например, правая граница сигнала на несущей частоте 2629 МГц. Назовем данный набор проанализированных данных набором № 1.

Некорректно определенные границы спектра вносят ошибку и в оценку центральной частоты и отношения сигнал – шум. Для устранения этого недостатка в набор обучающих данных были добавлены экземпляры спектрограмм с двумя LTE-сигналами (набор обучающих данных № 2).

Сигналы могут иметь разную полосу и разнесены по частоте на случайную величину в пределах ширины спектрограммы. На рис. 7 представлен экземпляр усредненной, нормированной к единице спектрограммы с двумя LTE-сигналами.

Приведем результаты работы сверточной нейронной сети ResNet50, обученной по обновленному набору данных, для диапазона сканирования 2600...2700 МГц.

На рис. 8, *a* показан усредненный по всем выборкам и поддиапазонам нормированный спектр мощности всего диапазона сканирования. На рис. 8, *б* показана усредненная спектрограмма диапазона сканирования с оценкой параметров всех обнаруженных LTE-сигналов. Оценка маски меток сигналов

для изображения спектрограммы всего диапазона сканирования приведена на рис. 8, в. На рис. 8, г представлен график меток, усредненных по всему диапазону сканирования (график аналогичен рис. 6).

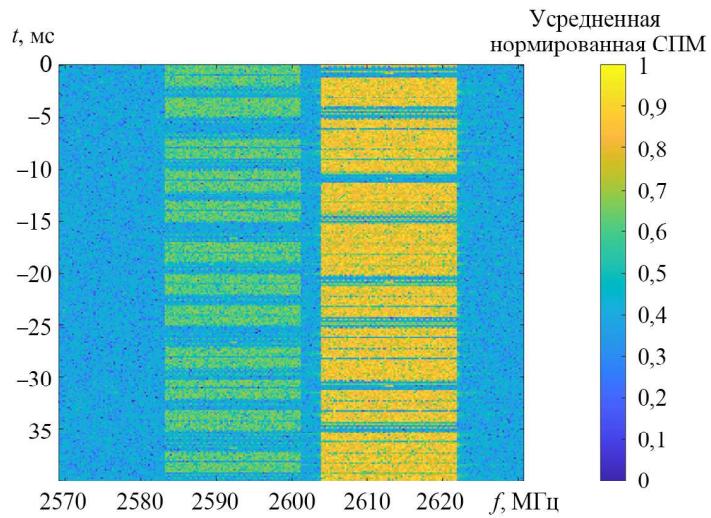


Рис. 7

Из рис. 8 видно, что спектральные границы всех сигналов определяются корректно, за исключением сигнала в районе 2675 МГц, правая граница которого определена с ошибкой. Особенность этого сигнала заключается в наличии в спектре близко расположенного сигнала большей мощности. С учетом нормированного спектра мощности мощность соседнего сигнала выше приблизительно на 15 дБ. При снижении верхней границы диапазона сканирования до 2665 МГц спектральные границы сигнала 2675 МГц определяются более точно, так как сигнал в спектре выше этой несущей частоты очень слабый. Результат работы ResNet50 в диапазоне 2600...2665 МГц иллюстрирует рис. 9. На рис. 9, а показан усредненный по всем выборкам и поддиапазонам нормированный спектр мощности всего диапазона сканирования, на рис. 9, б – усредненная спектрограмма диапазона сканирования с оценкой параметров всех обнаруженных LTE-сигналов. Оценка маски меток сигналов для изображения спектрограммы всего диапазона сканирования приведена на рис. 9, в.

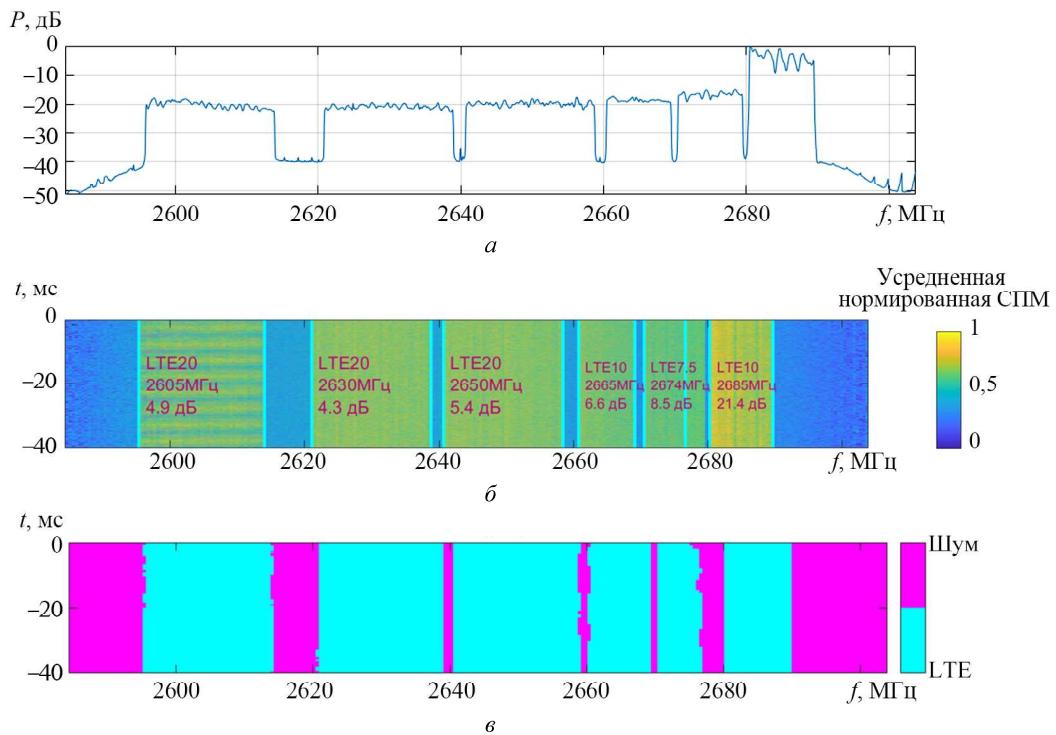


Рис. 8 (Начало)

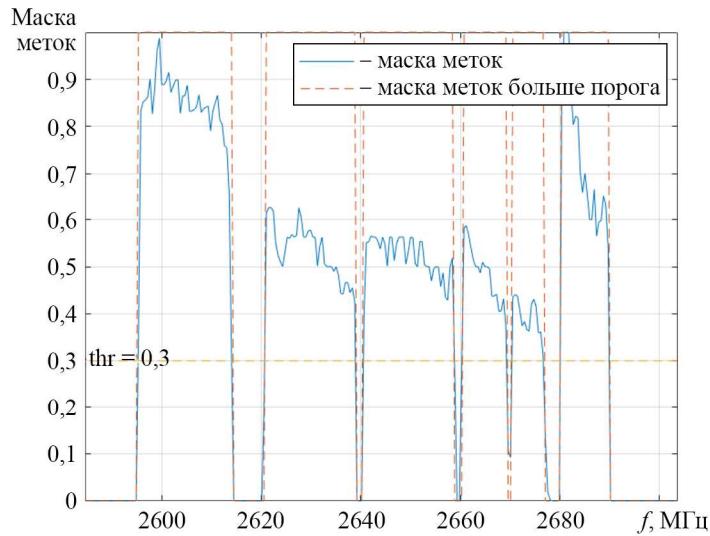


Рис. 8 (Окончание)

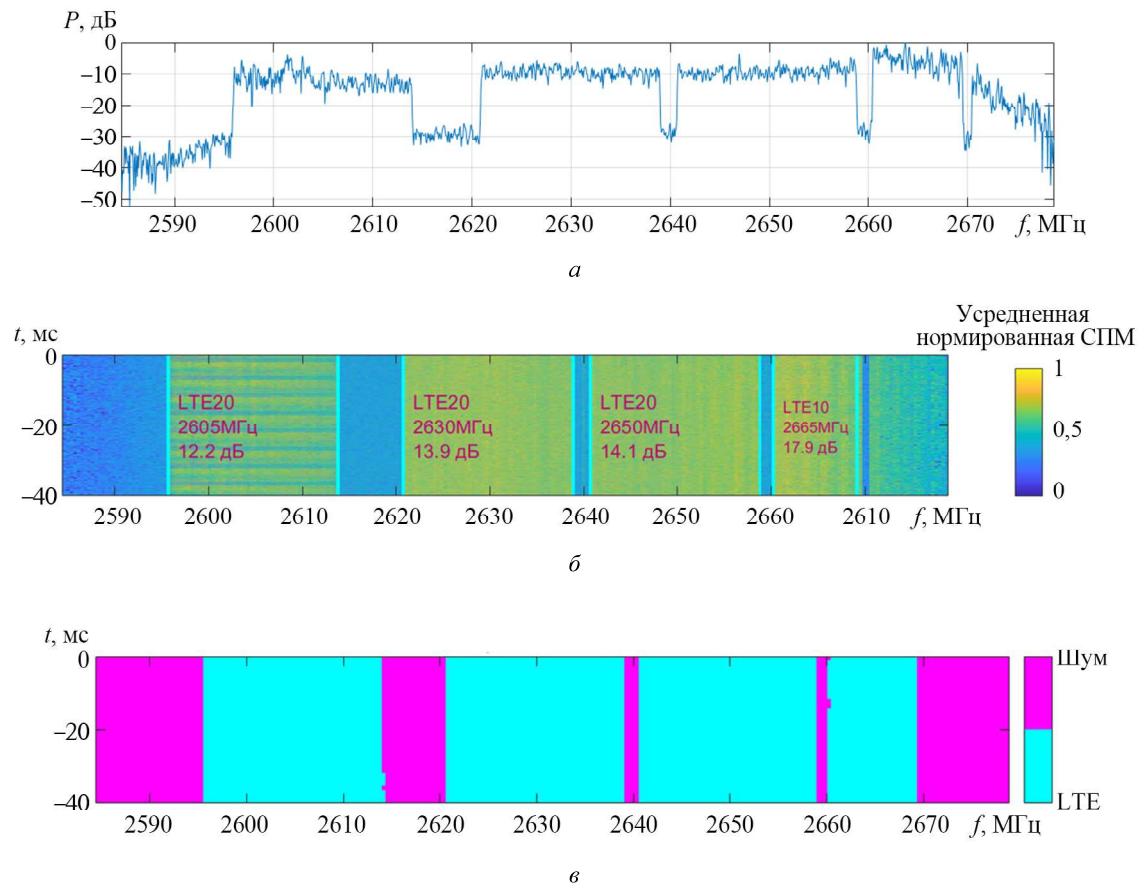
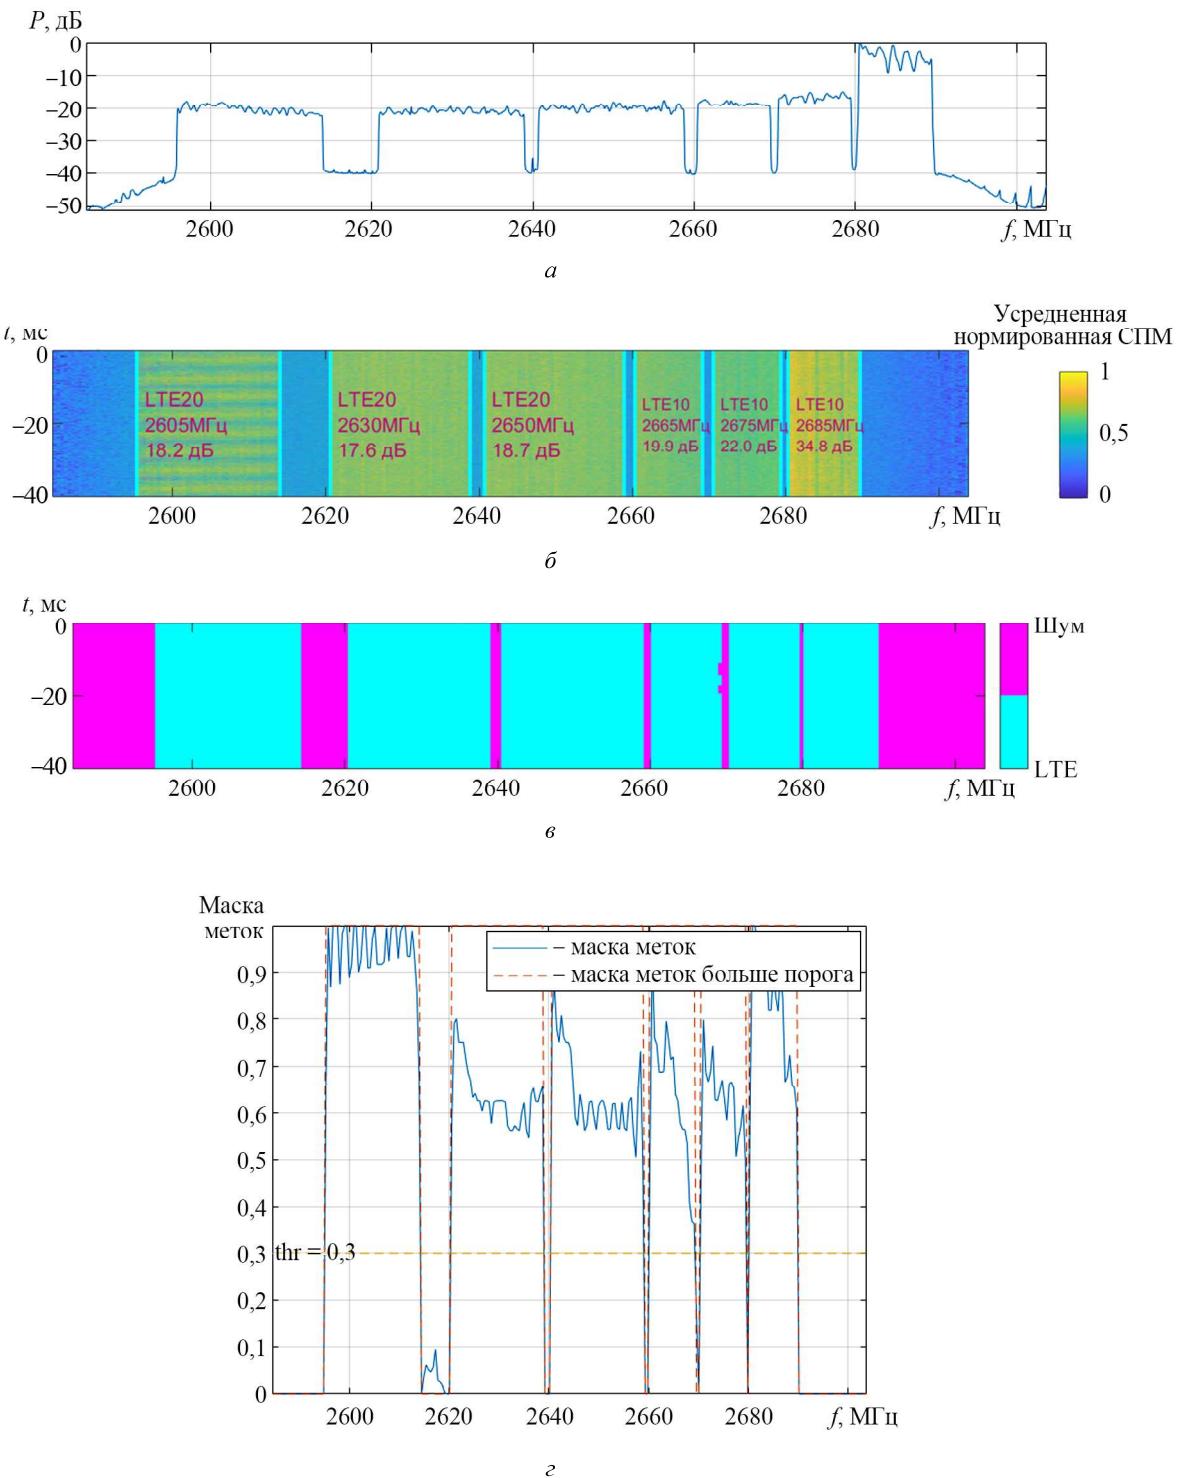


Рис. 9

Для устранения недостатка работы ResNet50 по различению смежных разноуровневых сигналов в набор обучающих данных был добавлен особый случай, описывающий ситуацию, при которой один из двух близко расположенных в спектре сигналов имеет значительно больший уровень (набор обучающих данных № 3).

На рис. 10 представлены результаты работы ResNet50 в диапазоне сканирования 2600...2700 МГц с обновленным набором обучающих данных.

На рис. 10, *а* показан усредненный по всем выборкам и поддиапазонам нормированный спектр мощности всего диапазона сканирования, на рис. 10, *б* – усредненная спектрограмма диапазона сканирования с оценкой параметров всех обнаруженных LTE-сигналов. Оценка маски меток сигналов для изображения спектрограммы всего диапазона сканирования приведена на рис. 10, *в*. На рис. 10, *г* представлен график меток, усредненных по всему диапазону сканирования.



Из рис. 10 видно, что спектральные границы всех сигналов определяются корректно. Оценки центральной частоты и отношения сигнал – шум также скорректировались.

Для сравнения на рис. 11 показаны результаты работы сети ResNet18, обученной по самому полному набору обучающих данных № 3. На рис. 11, *a* показан усредненный по всем выборкам и поддиапазонам нормированный спектр мощности всего диапазона сканирования, аналогичный рис. 10, *a*; на рис. 11, *б* – усредненная спектrogramма диапазона сканирования с оценкой параметров всех обнаруженных LTE-сигналов. Оценка маски меток сигналов для изображения спектrogramмы всего диапазона сканирования приведена на рис. 11, *в*. На рис. 11, *г* представлен график меток, усредненных по всему диапазону сканирования.

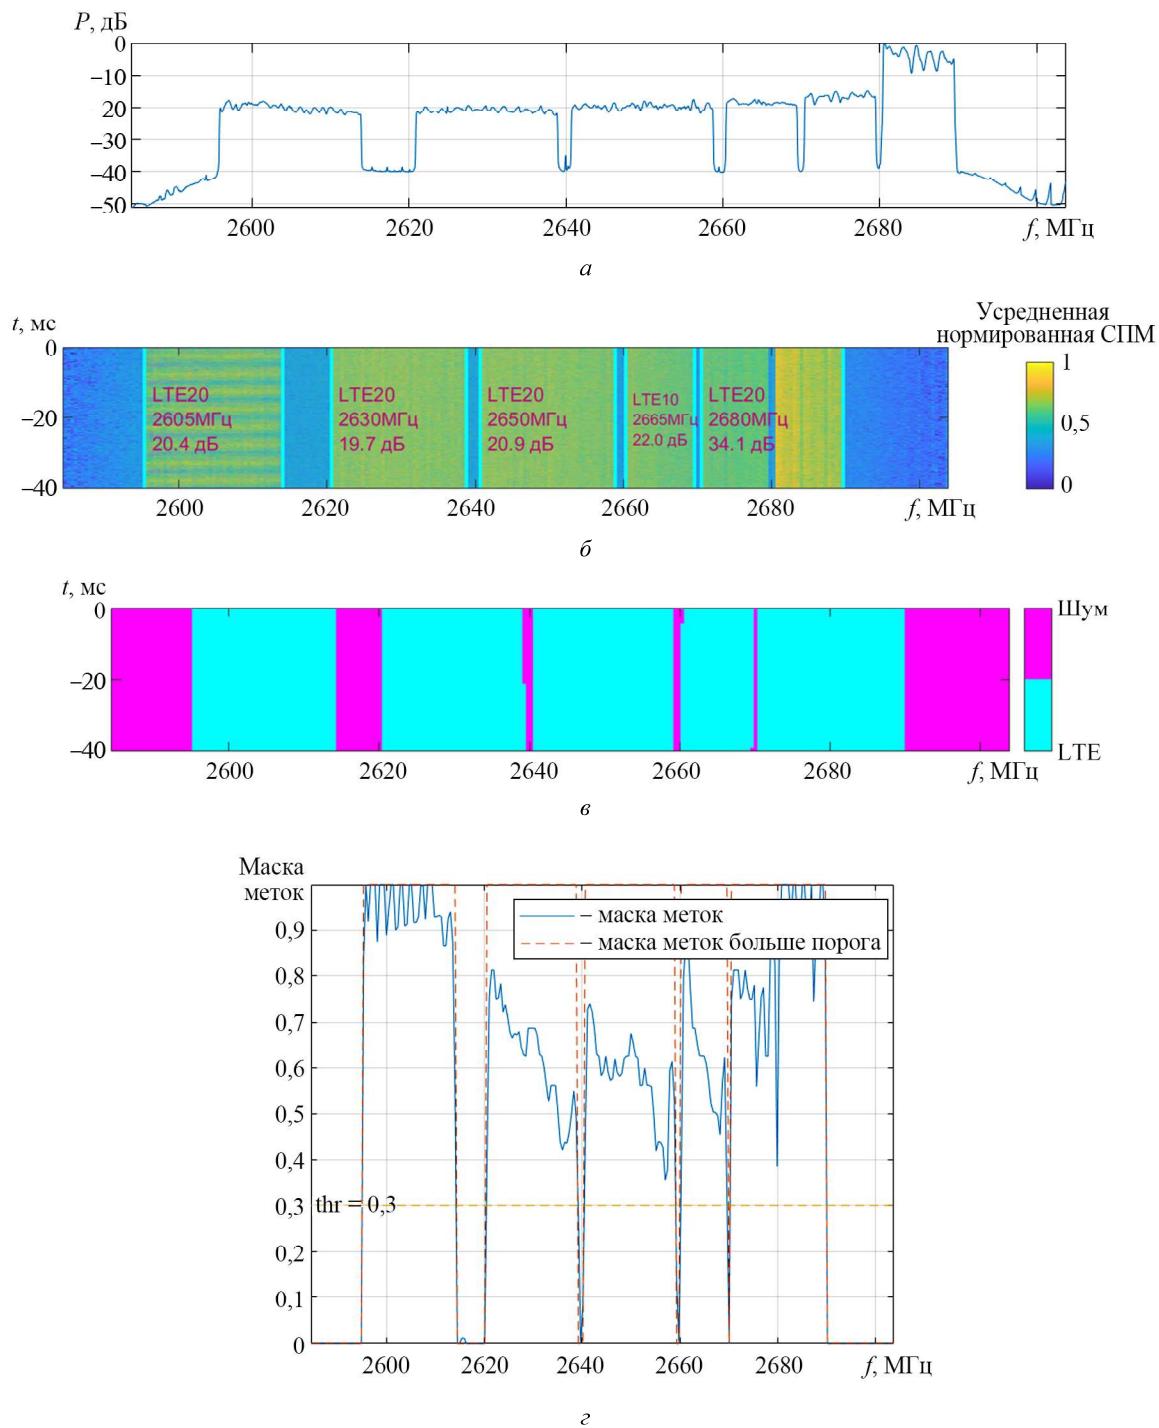


Рис. 11

Как видим (см. рис. 11), результаты, полученные с помощью сети ResNet18, схожи с результатами, полученными сетью ResNet50. Однако при этом сеть не различила два близко расположенных

LTE-сигнала в диапазоне 2670...2690 МГц. Таким образом, сеть ResNet50 показывает лучшие результаты при решении задачи идентификации LTE-сигналов в заданном диапазоне сканирования, существенный недостаток по сравнению с ResNet18 – время обучения сети.

Экспериментально апробированный комплекс моделей спектрального зондирования, работающий на основе искусственного интеллекта, может быть использован для практической реализации идентификации параметров сигналов при панорамном анализе радиоэфира в сетях когнитивного радио.

Рассмотренная нейронная сеть ResNet50 может быть использована для обнаружения и идентификации сигналов других стандартов. Для этого необходимо модифицировать выходной слой классификации элементов изображения, расширив перечень классов, а также добавить в набор обучающих данных экземпляры спектрограмм сигналов соответствующих стандартов.

Описанный в настоящей работе процесс обучения нейронной сети семантической сегментации на основе синтезированных и принятых из радиоэфира сигналов был экспериментально апробирован на LTE-сигналах базовых станций операторов. Была продемонстрирована возможность оперативной идентификации несущей частоты и ширины LTE-сигналов при панорамном анализе радиоэфира в сетях когнитивного радио.

Научная 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.

СПИСОК ЛИТЕРАТУРЫ

1. *Ivanov A. et al.* Probabilistic Spectrum Sensing Based on Feature Detection for 6G Cognitive Radio: A Survey // IEEE Access. 2021. Vol. 9. P. 116994–117026.
2. *Syed S.N. et al.* Deep Neural Networks for Spectrum Sensing: A Review // IEEE Access. 2023. Vol. 11. P. 89591–89615.
3. *Alhazmi M.H. et al.* 5G Signal Identification Using Deep Learning // Proc. of the 29th Wireless and Optical Communications Conference, May 1–2, 2020, Newark, USA. P. 1–5.
4. *Ngo T., Kelley B., Rad P.* Deep Learning Based Prediction of Signal-to-Noise Ratio (SNR) for LTE and 5G Systems // Proc. of the 8th International Conference on Wireless Networks and Mobile Communications, Oct. 27–29, 2020, Reims, France. P. 1–6.
5. *Tekbiyik K. et al.* Spectrum Sensing and Signal Identification with Deep Learning Based on Spectral Correlation Function [Electronical Resource]. URL: <https://arxiv.org/abs/2003.08359> (дата обращения: 25.09.2024).
6. *Zhang M., Diao M., Guo L.* Convolutional Neural Networks for Automatic Cognitive Radio Waveform Recognition // IEEE Access. 2017. Vol. 5. P. 11074–11082.
7. Бельский А.Б., Есипович О.А., Сафоклов Б.Б. Экспериментальное апробирование применения искусственных нейронных сетей в системах диагностики для оценки и прогнозирования технического состояния агрегатов винтокрылых летательных аппаратов // Изв. вузов. Авиационная техника. 2024. № 1. С. 109–115.
8. Фуртат И.Б. и др. Адаптивное нейросетевое управление универсальным мехатронным модулем космического назначения // Изв. вузов. Авиационная техника. 2023. № 3. С. 41–50.
9. Фокин Г.А., Рютин К.Е. Экспериментальная апробация SDR-платформы LibreSDR // Сб. докл. 79-й Науч.-техн. конф. Санкт-Петербургского НТО РЭС им. А.С. Попова, посвященная Дню радио, г. Санкт-Петербург, 22–26 апр. 2024. СПб.: СПбГЭТУ «ЛЭТИ», 2024. С. 174–177.
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.
11. Фокин Г.А. и др. Модельно-ориентированное проектирование на основе SDR // Системы управления и информационные технологии. 2015. № 2 (60). С. 94–99.
12. Фокин Г.А., Волгушев Д.Б., Харин В.Н. Использование SDR технологии для задач сетевого позиционирования. Формирование опорных сигналов LTE // Т-Comm: Телекоммуникации и транспорт. 2022. № 5. С. 28–47.

Поступила в редакцию 25.10.24

После доработки 10.11.24

Принята к публикации 10.11.24

Experimental Validation of Spectral Sensing Models for Identification of Signals by Means of Artificial Intelligence

G.A. FOKIN AND D.B. VOLGUSHEV

Bonch-Bruevich Saint Petersburg State University of Telecommunications, Saint Petersburg

The paper is devoted to experimental validation of spectral sensing models for determining the information on the structure of a target signal by a cognitive radio receiver based on a neural network approach. The operating procedure of the LTE signal capture and marking models is described when scanning the radio airwaves using the hardware of a software defined radio board and software tools of the MATLAB environment. Deep learning models of a neural network of semantic segmentation of spectrogram images are used to identify the LTE signals.

Spectral sensing, artificial intelligence, software-defined radio, LTE signals identification