

Научная статья

УДК 621.391

DOI: [10.34759/trd-2021-121-13](https://doi.org/10.34759/trd-2021-121-13)

## СИСТЕМА РАСПОЗНАВАНИЯ МОДУЛЯЦИИ СИГНАЛОВ НА ОСНОВЕ НЕЙРОННОЙ СЕТИ С ИСПОЛЬЗОВАНИЕМ ПЛИС

Александр Александрович Бахтин<sup>1</sup>, Алексей Станиславович Волков<sup>2✉</sup>,

Алексей Викторович Солодков<sup>3</sup>, Игорь Александрович Свиридов<sup>4</sup>

<sup>1,2,3,4</sup>Национальный исследовательский университет «МИЭТ»,

Москва, Зеленоград, Россия

<sup>1</sup>[bah@miec.ru](mailto:bah@miec.ru)

<sup>2</sup>[leshvol@mail.ru](mailto:leshvol@mail.ru)✉

<sup>3</sup>[solodkovaw@gmail.com](mailto:solodkovaw@gmail.com)

<sup>4</sup>[igor@mekatto.com](mailto:igor@mekatto.com)

**Аннотация.** В системах когнитивного радио, в том числе в программно-определяемых радиосистемах важной задачей является распознавание типа модуляции принимаемых сигналов при различных соотношениях сигнал/шум в канале связи. Среди задач радиомониторинга стоит схожий вопрос не только обнаружения фактора выхода в эфир, но и определения конкретного типа сигнально-кодовой конструкции, что требует обязательной достоверной оценки типа и позиционности модуляции.

В статье предложена система для распознавания типа модуляции сигналов на основе нейронной сети с использованием ПЛИС.

Аппаратно-программный комплекс состоит из отладочной платы Digilent Zedboard, трансивера на базе AD9361 и сопроцессора DPU. Классификация типов модуляции происходит при помощи нейронной сети, вычисления которой производятся на конфигурируемом сопроцессоре, реализованном на ПЛИС, что позволяет уменьшить задержку между приемом сигнала и принятием решения о типе модуляции.

Система распознает тип модуляции с достоверностью не менее 0,7 при отношении сигнал/шум около 2 дБ без предварительного установления синхронизации. Показано, что по сравнению с традиционными методами определения типа модуляции и методами на основе статистических характеристик сигнала применение предложенной системы позволит снизить требования соотношения сигнал/шум для систем когнитивного радио и радиомониторинга при большом количестве применяемых типов модуляции сигналов.

**Ключевые слова:** прием радиосигналов, цифровая модуляция, когнитивное радио, нейронные сети, автоматическая классификация сигналов, ПЛИС, Digilent Zedboard, AD9361

**Финансирование:** работа была выполнена при поддержке фонда содействия инновациям в рамках выполнения договора 787ГУЦЭС8-D3/63721

**Для цитирования:** Бахтин А.А., Волков А.С., Солодков А.В., Свиридов И.А. Система распознавания модуляции сигналов на основе нейронной сети с использованием ПЛИС // Труды МАИ. 2021. № 121. DOI: [10.34759/trd-2021-121-13](https://doi.org/10.34759/trd-2021-121-13)

# A NEURAL NETWORK-BASED SIGNAL MODULATION RECOGNITION SYSTEM IMPLEMENTED ON A FPGA

Alexander A. Bakhtin<sup>1</sup>, Alexey S. Volkov<sup>2</sup>✉, Alexey V. Solodkov<sup>3</sup>, Igor A. Sviridov<sup>4</sup>

<sup>1,2,3,4</sup>National Research University of Electronic Technology "MIET",

Moscow, Zelenograd, Russia

<sup>1</sup>[bah@miec.ru](mailto:bah@miec.ru)

<sup>2</sup>[leshvol@mail.ru](mailto:leshvol@mail.ru)✉

<sup>3</sup>[solodkovaw@gmail.com](mailto:solodkovaw@gmail.com)

<sup>4</sup>[igor@mekatto.com](mailto:igor@mekatto.com)

**Abstract.** In cognitive radio systems including software-defined radio, an important task is to recognize modulation type of received signals under various signal-to-noise ratios in the communication channel. The detection of the modulation type in a received data packet can be used in ad hoc networks, as well as to provide dynamic spectrum access.

To solve this problem, there are few common approaches, including the shape detection of the signal constellation, the study of the statistical characteristics of the signal, the use of deep neural networks and others. The use of deep convolutional neural networks leads to higher accuracy for large sets of different types of modulation. In addition, implementing the neural network on an FPGA allows not only changing the weights of the neural network, but also configuring the types and arrangement of layers without replacing the hardware component.

The proposed system consists of hardware and software parts. The hardware part includes a Digilent Zedboard and an AD-FMCOMMS3-EBZ development board (based on an AD9361 configurable radio transceiver connected via an FMC connector). The software

part of the system consists of the Petalinux distribution kit version 2019.1, the Linux industrial I/O driver, developed software for pre-processing the received signal and a trained neural network model.

The developed software part performs the pre-processing of the signals and controls the configurable coprocessor located on the FPGA. The pre-processing consists in normalizing the received signal. Moreover, as the coprocessor does not support the softmax layer of the neural network, the necessary calculations are performed at the post-processing stage.

To train the neural network, a set of samples of radio signals with different types of modulation (dataset) was generated in the Matlab environment. The generated signal samples were transmitted at a 1 GHz carrier frequency over a low noise wireless channel. The carrier frequency was chosen arbitrarily as it does not affect the processing algorithm. Before transmitting the signal, the transceivers were manually calibrated in order to reduce the frequency desynchronization, however, during the transmission; the frequency deviation value was being changed arbitrarily. The received signals were pre-processed and divided into bursts of 1024 samples in the in-phase and quadrature channels. Then AWGN with different power was added to the samples. Thus, samples with various SNR in range -5...15 dB with step 1 dB were formed in the dataset.

The use of the DPU v3.2 coprocessor allows it to perform necessary computations for the neural network in the FPGA. We decided to use a compact neural network with a small number of Inception modules and fast connections.

The most significant impact on errors in determining modulation at high SNR is the incorrect classification of the 8-PSK and 16-PSK modulations – instead of the first type, the

second is often predicted and vice versa. At low SNR QAM modulations of different orders are erroneously classified as higher order QAMs due to the influence of noise.

Despite this fact, the developed system shows an average accuracy of 90% of successful recognitions for SNR values above 12 dB and 70% and higher for SNR values exceeding 2 dB. The proposed system has great flexibility and a large possibilities for further improvement of performance.

**Keywords:** signal receiving, digital modulation, cognitive radio, neural networks, automatic modulation recognising, FPGA, Digilent Zedboard, AD9361

**Funding:** this work was supported by the Fund for the Promotion of Innovations under the contract 787GUTSES8-D3 / 63721

**For citation:** Bakhtin A.A., Volkov A.S., Solodkov A.V., Sviridov I.A. A neural network-based signal modulation recognition system implemented on a FPGA. *Trudy MAI*, 2021, no. 121. DOI: [10.34759/trd-2021-121-13](https://doi.org/10.34759/trd-2021-121-13)

## Введение

В зарубежной литературе в последние несколько лет наблюдается значительный рост количества публикаций по тематике интеллектуального (когнитивного) радио [1, 2], что свидетельствует о высокой заинтересованности мировой науки и рынка в решениях, позволяющих более эффективно использовать частотный ресурс как с точки зрения времени занятости, так и более высоких скоростей передачи данных. Существуют отдельные публикации и в российских изданиях [3-5], однако малое их количество свидетельствует о недостаточном уровне развития темы когнитивного радио в российской науке.

Для систем когнитивного радио одной из важных задач является обнаружение полезного сигнала и определение его заранее неизвестных параметров, в том числе типа модуляции сигнала для его дальнейшей обработки на стороне приемника [1, 6]. В сетях радиосвязи последних поколений широко применяются системы адаптации радиолинии к условиям распространения радиосигнала и принципы рационального использования спектра. Для этих сетей характерно высокое качество связи и высокая скорость передачи. Это возможно при правильном выборе канала на передачу с минимальными помехами. Возможен сценарий передачи пакета в радиоканал с той модуляцией, которая адекватна текущей помеховой обстановке, без предварительного оповещения приемника о параметрах модуляции в расчете на то, что приемное устройство самостоятельно определит её [6].

Адаптация является еще одним из методов преодоления априорной неопределенности сведений о сигналах и помехах. Среда распространения радиоволн постоянно изменяется: варьируются число лучей и степень затухания в них, изменяется уровень сторонних электромагнитных помех, сигнал может искажаться, могут возникать препятствия на пути распространения и т.д. Задача стоит в том, как выбрать наиболее адекватную модель канала в точке приема на максимально продолжительное время. Выбор оптимальных параметров должен происходить с некоторой периодичностью, либо по факту ухудшения условий распространения [7-9].

Идея использования когнитивного радио и адаптации к условиям передачи также связана с необходимостью динамического доступа к спектру, который позволяет оптимизировать использование доступных полос частот. В случае нового

пользователя, желающего получить доступ к части спектра, критически важным является обеспечение таких условий, при которых качество связи определенных существующих пользователей не будет изменено в худшую сторону. Это приводит к необходимости радиомониторинга интересующей полосы частот, в том числе, сборе информации о типе модуляции передаваемых сигналов, так как от него напрямую зависят другие параметры сигнала (в том числе помехоустойчивость) [10].

### **Существующие методы обнаружения модуляции**

Для решения данной задачи существуют различные подходы, в том числе исследование формы сигнального созвездия, исследование статистических характеристик сигнала, использование глубоких нейронных сетей.

В случае исследования формы сигнального созвездия удается достигнуть высокой точности распознавания, однако точность метода сильно зависит от точности синхронизации по частоте.

Использование статистических характеристик сигналов встречается в научной литературе [11]. Однако в [12] показано, что использование глубоких сверточных нейронных сетей позволяет добиться большей точности для большого набора различных типов модуляции.

Такой подход к проблеме распознавания типа модуляции сигналов позволяет получить высокую скорость обработки сигналов и высокую точность определения типа модуляции при высоком уровне шума в канале. Кроме того, использование в аппаратной платформе ПЛИС позволяет не только изменять веса нейронной сети, но и переконфигурировать ее структуру, то есть изменять типы и расположение слоёв.

Подход, при котором для распознавания типа модуляции сигналов могут быть использованы различные архитектуры нейронных сетей, позволяет не выделять вручную конкретные признаки для классификации, а использовать отсчеты принятого сигнала. Как правило, для повышения точности нейронной сети, отсчеты нормируются [12, 13].

В настоящей работе предложена система распознавания типа модуляции сигнала на основе сверточных нейронных сетей. Это позволяет обеспечить высокую точность распознавания даже в условиях низкого соотношения сигнал/шум в канале и точность свыше 95% для соотношений сигнал/шум (ОСШ) свыше 15 дБ.

### **Предлагаемый алгоритм**

Разрабатываемая система состоит из аппаратной и программной части. Аппаратная часть состоит из отладочной платы Zedboard компании Digilent и мезонинной платы AD-FMCOMMS3-EBZ на базе конфигурируемого радиотрансивера AD9361, соединенных через разъем FMC. Программная часть системы состоит из дистрибутива Petalinux версии 2019.1, драйвера Linux Industrial I/O, разработанного самостоятельно программного обеспечения для предобработки принятого сигнала, а также обученной модели нейронной сети.

Отладочная плата Digilent Zedboard используется для прототипирования устройств на основе системы на кристалле Zynq-7000, в которую входят двухъядерный процессор ARM Cortex-A9 и ПЛИС. Для программирования в том числе доступно 220 блоков DSP48, которые можно считать аппаратной реализацией процедуры умножения с накоплением (MAC), являющейся основной при реализации



операции свертки. Как будет показано далее, именно эта операция является ключевой для выбранной архитектуры сети.

В качестве радиотракта использована плата AD-FMCOMMS3-EBZ – отладочная плата с высокопроизводительным трансивером AD9361, который является наиболее удачным решением для создания программно-определяемых радиосредств [14]. Трансивер предоставляет возможность принимать сигнал по двум независимым каналам, аналогично осуществляется передача сигнала по двум независимым каналам. На рисунке 1 представлена функциональная схема трансивера.

В каждом канале приемной части принимаемый сигнал проходит через МШУ, после чего сигнал переносится на видеочастоту. В трансивере осуществляется автоматическая регулировка усиления, коррекция постоянного смещения и дисбаланса I/Q ветвей, после чего сигнал попадает в АЦП со следующими характеристиками: разрядность 12 бит, 250 мегавыборок/с в каждой ветви.

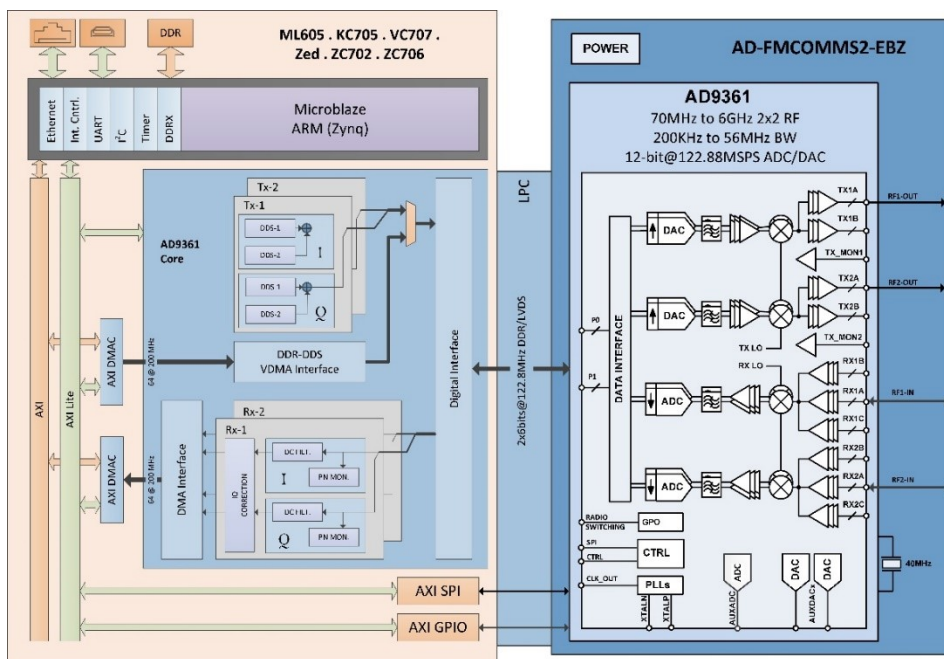


Рисунок 1 – Функциональная схема трансивера

В качестве основы для программного обеспечения выбрана рекомендованная подсистема Industrial I/O Linux, которая предлагает унифицированную среду для связи (чтения и записи) с драйверами, в том числе АЦП. Взаимодействие с подсистемой ПО происходит при помощи библиотеки `libiio`, включенной в дистрибутив `Retalinux`. Библиотека предоставляет функции чтения отсчетов сигналов из буфера, а также содержит методы, позволяющие изменять параметры трансивера (усиление, несущую частоту, ширину полосы и т.д.).

Разработанное программное обеспечение осуществляет предобработку сигналов и управляет конфигурируемым сопроцессором, расположенным на ПЛИС. Предобработка заключается в нормировании принятого сигнала. Кроме того, сопроцессор не поддерживает слой `softmax` нейронной сети, поэтому необходимые вычисления выполняются на этапе постобработки.

Функциональная схема системы представлена на рисунке 2. Принятый сигнал переносится на видеочастоту и поступает в АЦП. Далее, при помощи библиотеки `libiio` из буфера отбираются отсчеты сигнала и выполняется предобработка. После предобработки выборка из 1024 отсчетов для I и Q каналов пересылается в сопроцессор DPU, где выполняются необходимые вычисления для нейронной сети. Выходные данные затем передаются для постобработки, в ходе которой определяется наиболее вероятный тип модуляции для конкретной выборки.

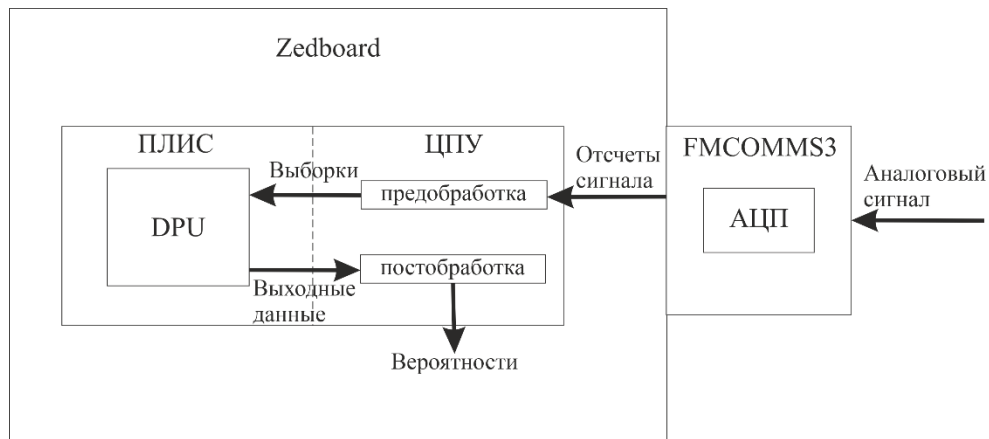


Рисунок 2 – Схема обработки сигнала.

Для обучения нейронной сети в среде Matlab 2014a был сгенерирован набор образцов радиосигналов с различными типами модуляции (датасет). Функциональная схема генерации сигнала представлена на рисунке 3. Случайный набор бит проходит через модулятор, на выходе которого частота дискретизации сигнала равна 0,25 МГц. После этого сигнал передискретизируется до частоты дискретизации 2 МГц путем вставки нулевых отсчетов и проходит через фильтр типа приподнятый косинус с коэффициентом сглаживания спектра 0,3.




Рисунок 3 – Формирование радиосигналов

Сгенерированные отсчеты сигналов передаются на несущей частоте 1 ГГц по беспроводному каналу связи с низким уровнем шума. Номинал несущей частоты выбран произвольно и не влияет на алгоритм обработки. Перед передачей сигнала осуществляется ручная калибровка трансиверов с целью уменьшить рассинхронизацию по частоте, однако за время передачи значение отклонения по

частоте произвольно изменяется. Максимальное значение отклонения по частоте, зависящее от аппаратной части приемника и передатчика, определяется характеристиками трансивера [14] и равно 3,62 кГц.

Использование при обучении отсчетов сигнала, прошедших через приемо-передающий тракт, позволяет повысить точность системы при работе с реальными (не синтезированными) сигналами.

Принятые отсчеты проходят предобработку и разбиваются на выборки по 1024 отсчета в синфазном и квадратурном каналах. На принятые сигналы в среде Matlab дополнительно накладываются шум типа АБГШ с различной дисперсией, от -5 дБ до 15 дБ по отношению к средней мощности сигнала с шагом 1 дБ. Таким образом, в наборе данных формируются выборки с различными значениями ОСШ. В дальнейшем эти выборки используются для обучения и тестирования нейронной сети.

Имплементация сверточных нейронных сетей с большим количеством слоев на ПЛИС требует большого количества блоков LUT и DSP48 [15].

В представленной системе используется сопроцессор DPU v3.2, который поддерживает в том числе такие слои, как сверточный, полносвязные слои, слои пакетной нормализации (англ. *batch normalisation*) [16].

На рисунке 4 представлена архитектура аппаратной части с использованием сопроцессора DPU, в который входит планировщик (*High Performance Scheduler*), вычислительные ядра (*Processing Engine*), области встроенной памяти (*Global Memory pool*), и модуля отбора инструкций (*Instruction Fetch Unit*).

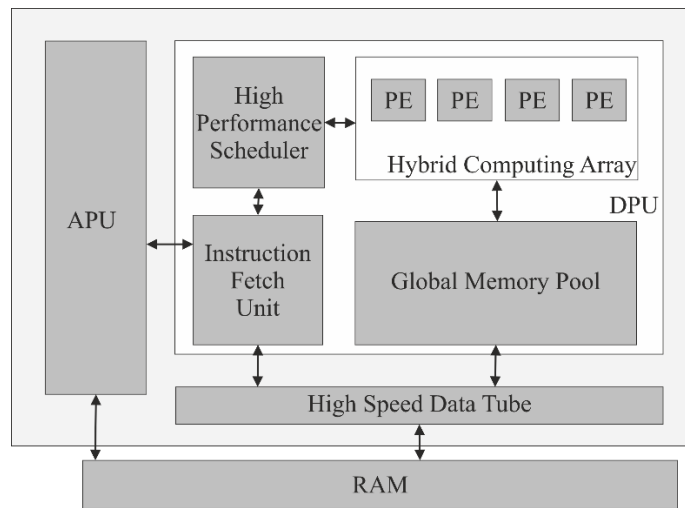


Рисунок 4 – Архитектура аппаратной части DPU

При инициализации DPU сопроцессор получает инструкции из внешней памяти RAM. Инструкции должны быть предварительно сгенерированы при помощи инструментов Xilinx и, по сути, содержат полную информацию о нейронной сети, в том числе о весах. Встроенная память используется для буферизации входных, промежуточных и выходных данных для достижения высокой скорости передачи данных и минимизации задержек. Использование такой встроенной памяти позволяет повторно использовать данные (что крайне актуально для вычислений нейронной сети) без обращения к внешней памяти. Архитектура вычислительных ядер представляет собой конвейер, что повышает скорость вычислений. Кроме того, она максимально эффективно использует ресурсы блоков ПЛИС [17].

Использование сопроцессора DPU позволяет перенести вычисления для нейронной сети на ПЛИС, при этом используя ограниченное количество ресурсов. Количество различных блоков, требуемых для имплементации DPU, зависит от его архитектуры. Для отладочной платы Zedboard наиболее производительной является

архитектура V1152, которая требует 194 блоков DSP48 (специализированных блоков для ЦОС) и 28698 блоков LUT.

Следует отметить, что использование сопроцессора DPU накладывает некоторые ограничения на архитектуру нейронной сети. Так, например, максимальный размер фильтра операции свертки не может превышать размера 16x16, однако разработанная архитектура нейронной сети удовлетворяет этим условиям.

### **Параметры нейронной сети**

Существуют разные архитектуры нейронных сетей, используемых для распознавания типа модуляции сигнала.

Одной из наиболее известных архитектур является VGG. Она была предложена в статье [18]. Для архитектуры свойственно уменьшение размерностей используемых матриц при помощи слоев maxpool и увеличение количества фильтров в два раза после каждого из них. Кроме того, размер фильтров выбирается достаточно малым (3x3), а шаг фильтра устанавливается равным 1.

Проблемой глубоких сетей является то, что с увеличением глубины сети точность сначала увеличивается, а затем быстро ухудшается (т.н. проблема исчезающего градиента). Для решения этой проблемы Microsoft представила сеть с т.н. соединениями быстрого доступа [19]. Они складываются с выходом одного из последующих слоев, при этом пропуская некоторые из них. Таким образом, если все веса слоя равны нулю, то такой слой не влияет на результат работы нейронной сети. Это позволяет строить нейронные сети с большей глубиной слоев.

В архитектуре GoogLeNet [20] предлагается использовать фильтры размером 1x1 с целью уменьшения количества каналов. Кроме того, вводится идея

параллельного использования нескольких фильтров с различными размерами, выходы фильтров затем объединяются. Таким образом достигается выделение признаков в различных масштабах.

Согласно [1] архитектура ResNet превосходит архитектуру VGG в точности распознавания на высоких значениях ОСШ. Работа [21] показывает, что сверточные сети с блоками Inception показывают высокую точность распознавания типа модуляции, когда на вход нейронной сети подаётся диаграмма созвездий.

Учитывая приведенный мировой опыт, при разработке системы было принято решение использовать нейронную сеть с небольшим количеством модулей Inception и соединениями быстрого доступа.

На рисунке 5 представлена используемая в нейронной сети модификация блока Inception.

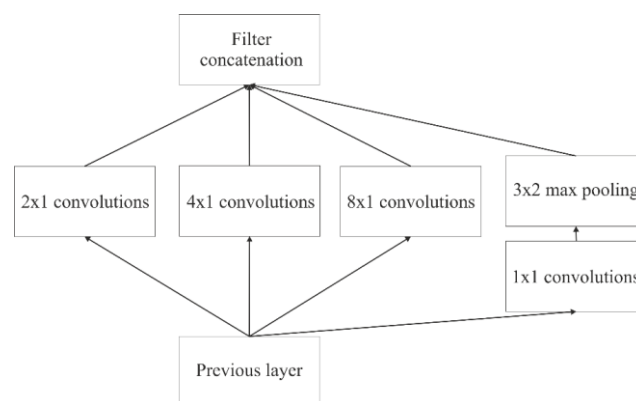


Рисунок 5 – Модифицированный блок Inception

Фильтр 1x1 используется только перед слоем max pooling для уменьшения количества каналов. Использование таких фильтров перед другими блоками позволило бы уменьшить количество весов в нейронной сети, но понизило точность распознавания.

Особенностью DPU ядра является ряд ограничений, в том числе: размер фильтра слоя max pooling должен находиться в диапазоне от 2 до 8 для каждого измерения. По этой причине в предложенной архитектуре второе измерение остается равным 2 до полносвязной части сети.

Архитектура нейронной сети представлен на рисунке 6. За каждым свертки следует функция активация ReLu и слой пакетной нормализации. При обучении перед полносвязными (FC) слоями применяется исключение (англ. *dropout*) для 50% нейронов.

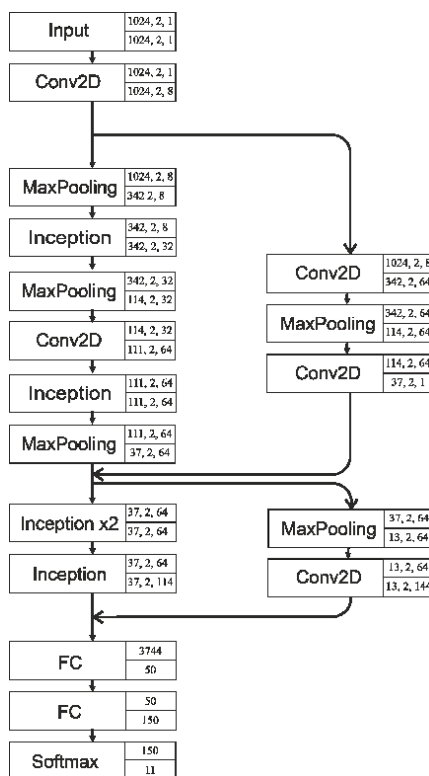


Рисунок 6 – Архитектура использованной нейронной сети

Результаты испытаний приведены на рисунке 7. Нейронная сеть предсказывает тип модуляции с точностью 0,7 и выше при ОСШ выше 2 дБ, 0,9 и выше при ОСШ 10 дБ и 0,95 и выше при ОСШ свыше 12 дБ.



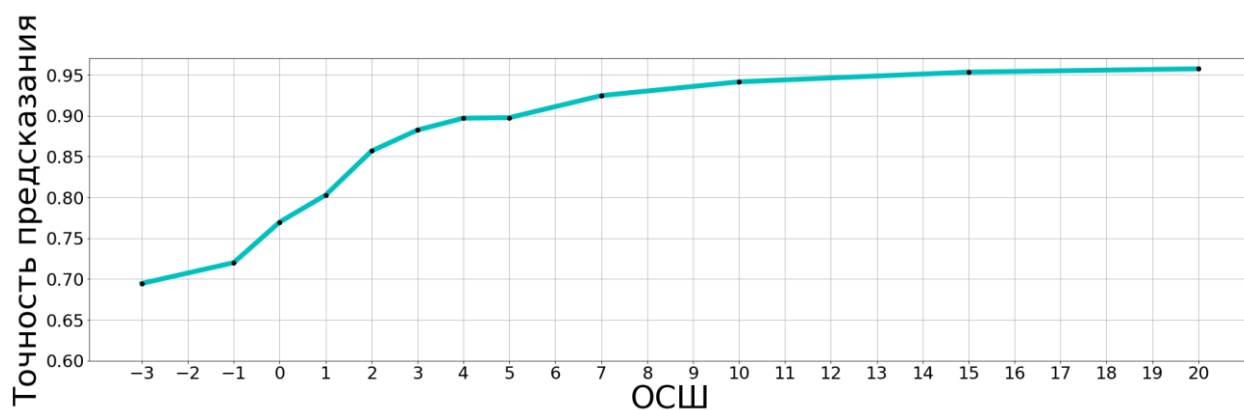


Рисунок 7– Зависимость точности нейронной сети от соотношения сигнал/шум для всех типов модуляций

На рисунке 8 представлена матрица ошибок распознавания. При высоких ОСШ большая часть ошибок происходят из-за неправильного определения модуляций 8-PSK и 16-PSK – вместо первого типа часто предсказывается второй и наоборот. При низких отношениях сигнал/шум модуляции QAM разных порядков могут быть классифицированы как QAM более высокого порядка. Это результат является следствием наложения шума.

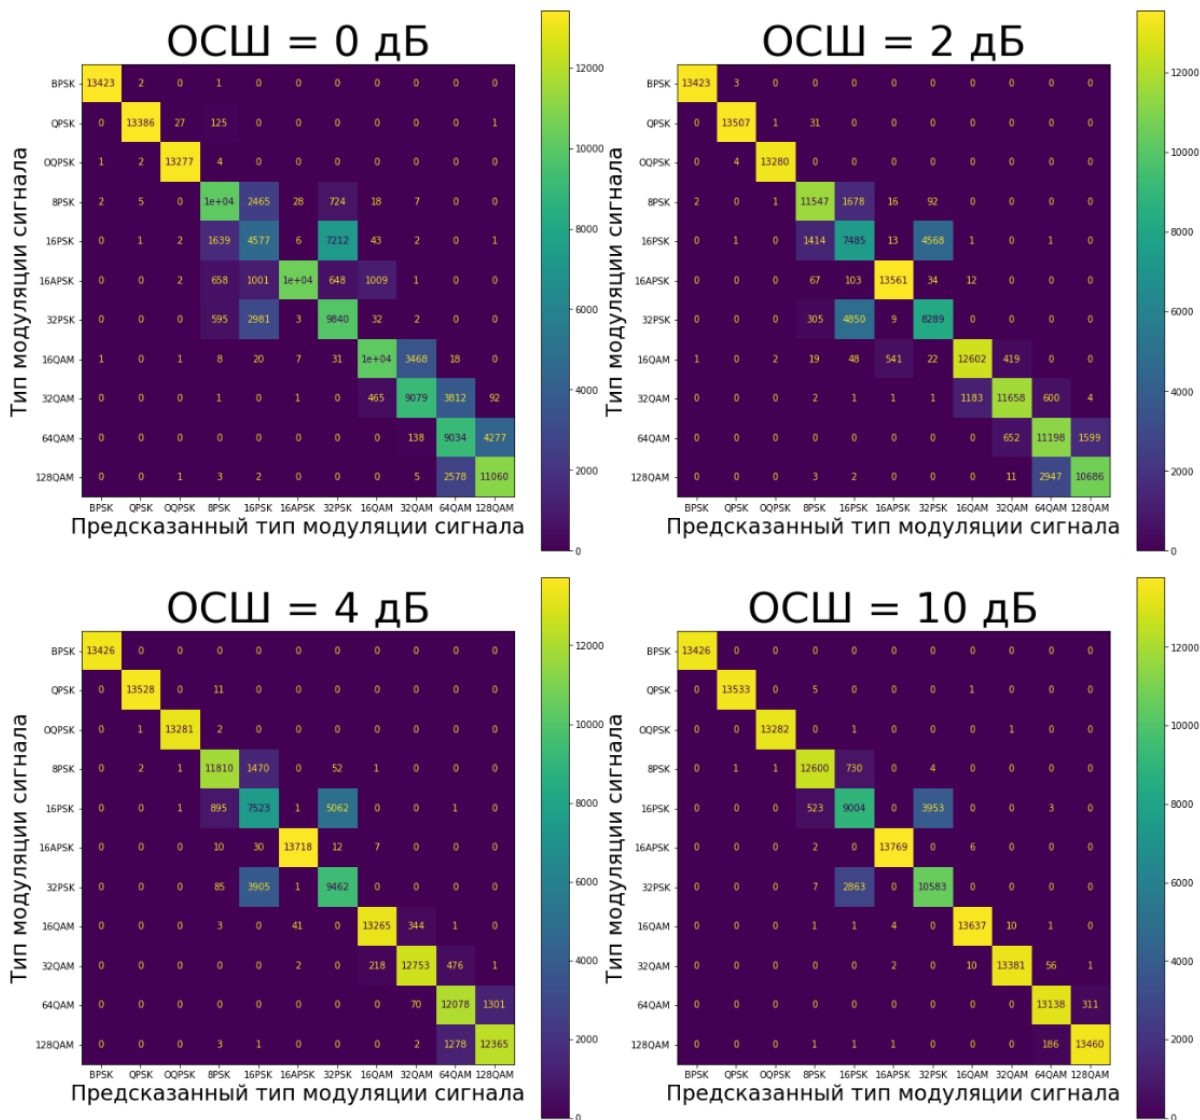


Рисунок 8 – Матрицы ошибок для различных отношений сигнал/шум

### Возможные улучшения

Одним из преимуществ использования нейронных сетей является возможность ее обучения для работы в различных условиях. В том числе, возможно расширение количества типов модуляции путем добавления новых отсчетов в выборку для обучения.

Для повышения точности распознавания типа модуляции системой возможно использование дополнительной нейронной сети для классификации 8-PSK, 16-PSK, 16-APSK и объединение этих типов модуляции в одну группу в первоначальной сети.

Кроме того, использование нейронной сети с меньшим количеством сверточных слоев приведет к уменьшению задержки между принятием сигнала и вынесением решения о его принадлежности к одному из типов модуляции. В случае использования отладочных плат с большим количеством блоков DSP48 (например, Xilinx ZCU102), можно полностью имплементировать нейронную сеть на ПЛИС без использования сопроцессора. Это значительно увеличит потребляемую энергию, однако повысит скорость вычислений.

### **Выводы**

В данной статье представлена разработанная система распознавания типа модуляции сигналов. Система основана на применении сверточной нейронной сети с имплементацией на ПЛИС, что позволяет достичь высокой точности для большого набора поддерживаемых типов модуляции.

Была рассмотрена архитектура аппаратно-программного комплекса, которая позволяет обеспечить взаимодействие элементов системы (сoproцессора, основного процессора и трансивера). Кроме того, был рассмотрен сгенерированный набор данных, на котором проводилось обучение.

Разработанная система распознавания модуляции способна принимать сигнал на несущих частотах от 70 МГц до 6 ГГц с занимаемой полосой частот от 200 кГц до 56 МГц и классифицировать 11 типов модуляции (BPSK, QPSK, OQPSK, 8,16-PSK, 16,32,64,128-QAM, 16,32-APSK) с точностью в среднем не менее 75% для отношения

сигнал/шум выше 0 дБ и 90% для отношения сигнал/шум выше 10 дБ при условии, что несущая частота известна приемнику с точностью до остаточной рассинхронизации, но без установления точной синхронизации по фазе в ходе приема сигнала. Установлено, что для рассматриваемых типов модуляции кроме 8-PSK и 16-PSK точность распознавания превышает 75% для каждого типа в отдельности при ОСШ 0 дБ.

### Список источников

1. O'Shea T.J., Roy T., Clancy T.C. Over-the-air deep learning based radio signal classification // IEEE Journal of Selected Topics in Signal Processing, 2018, vol. 12, no. 1, pp. 168-179. DOI:[10.1109/JSTSP.2018.2797022](https://doi.org/10.1109/JSTSP.2018.2797022)
2. Amjad M., Rehmani M.H., Mao S. Wireless multimedia cognitive radio networks: A comprehensive survey // IEEE Communications Surveys & Tutorials, 2018, vol. 20, no. 2, pp. 1056-1103. DOI:[10.1109/COMST.2018.2794358](https://doi.org/10.1109/COMST.2018.2794358)
3. Бычков Е.Д., Коваленко О.Н., Беленков Д.В. Интегрированная модель доступа к частотному спектру узлов в беспроводной сети передачи данных // Динамика систем, механизмов и машин. 2019. Т. 7. № 4. DOI: [10.25206/2310-9793-7-4-192-199](https://doi.org/10.25206/2310-9793-7-4-192-199)
4. Зуев А.В. Распределение канальных ресурсов в когнитивной радиосети на основе аукционного метода управления доступом к среде передачи // Системы управления, связи и безопасности. 2019. № 3. DOI: [10.24411/2410-9916-2019-10302](https://doi.org/10.24411/2410-9916-2019-10302)
5. Шевцов В.А., Бородин В.В., Крылов М.А. Построение совмещенной сети сотовой связи и самоорганизующейся сети с динамической структурой // Труды МАИ. 2016. № 85. URL: <http://trudymai.ru/published.php?ID=66417>

6. Wang Y. et al. Data-driven deep learning for automatic modulation recognition in cognitive radios // IEEE Transactions on Vehicular Technology, 2019, vol. 68, no. 4, pp. 4074-4077. DOI:[10.1109/TVT.2019.2900460](https://doi.org/10.1109/TVT.2019.2900460)
7. Ibnkahla M. Adaptation in wireless communications Taylor & Francis Group, 2009, 485 p.
8. Бородин В.В., Петраков А.М., Шевцов В.А. Анализ эффективности передачи данных в сети связи группировки беспилотных летательных аппаратов // Труды МАИ. 2015. № 81. URL: <http://trudymai.ru/published.php?ID=57894>
9. Бородин В.В., Петраков А.М., Шевцов В.А. Моделирование служебного канала передачи маршрутной информации адаптивной летающей сети связи // Электросвязь. 2016. № 11. С. 41-45.
10. Рембовский А.М. Радиомониторинг. Задачи, методы, средства. – М.: Горячая линия-Телеком, 2010. - 623 с.
11. Аджемов С.С., Кленов Н.В., Терешонок М.В., Чиров Д.С. Методы распознавания видов цифровой модуляции сигналов в когнитивных радиосистемах // Вестник Московского университета. Серия 3. Физика. Астрономия. 2015. №. 6. С. 19-27.
12. O'Shea T.J., Corgan J., Clancy T.C. Convolutional radio modulation recognition networks // International conference on engineering applications of neural networks, Springer, Cham, 2016, pp. 213-226. DOI:[10.1007/978-3-319-44188-7\\_16](https://doi.org/10.1007/978-3-319-44188-7_16)
13. Hazza A. et al. An overview of feature-based methods for digital modulation classification // 2013 1st international conference on communications, signal processing,

- and their applications (ICCSPA), IEEE, 2013, pp. 1-6.  
DOI:[10.1109/ICCSPA.2013.6487244](https://doi.org/10.1109/ICCSPA.2013.6487244)
14. Pu D., Cozma A., Hill T. Four quick steps to production: Using model-based design for software-defined radio // Analog Dialogue, 2015, vol. 49, pp. 1-5.
  15. Tridgell S. Low Latency Machine Learning on FPGAs, Ph.D, Thesis, University of Sydney, Sydney, Australia, 2020.
  16. Xilinx DPU Product Guide. URL:  
[https://www.xilinx.com/support/documentation/ip\\_documentation/dpu/v3\\_2/pg338-dpu.pdf](https://www.xilinx.com/support/documentation/ip_documentation/dpu/v3_2/pg338-dpu.pdf)
  17. Kedia R., Goel S., Balakrishnan M., Paul K., Sen R. Design Space Exploration of FPGA-Based System With Multiple DNN Accelerators // IEEE Embedded Systems Letters, 2021, vol. 13, no. 3, pp. 114-117.
  18. Simonyan K., Zisserman A. Very deep convolutional networks for large-scale image recognition // arXiv preprint: arXiv:1409.1556, 2014.
  19. He K., Zhang X., Ren S., Sun J. Deep residual learning for image recognition // Proceedings of the IEEE conference on computer vision and pattern recognition, 2016, pp. 770-778. DOI:[10.1109/CVPR.2016.90](https://doi.org/10.1109/CVPR.2016.90)
  20. Szegedy C. et al. Going deeper with convolutions // Proceedings of the IEEE conference on computer vision and pattern recognition, 2015, pp. 1-9.  
DOI:[10.1109/CVPR.2015.7298594](https://doi.org/10.1109/CVPR.2015.7298594)
  21. Peng S. et al. Modulation classification based on signal constellation diagrams and deep learning // IEEE transactions on neural networks and learning systems, 2018, vol. 30, no. 3, pp. 718-727. DOI:[10.1109/TNNLS.2018.2850703](https://doi.org/10.1109/TNNLS.2018.2850703)

## References

1. O'Shea T.J., Roy T., Clancy T.C. Over-the-air deep learning based radio signal classification, *IEEE Journal of Selected Topics in Signal Processing*, 2018, vol. 12, no. 1, pp. 168-179. DOI:[10.1109/JSTSP.2018.2797022](https://doi.org/10.1109/JSTSP.2018.2797022)
2. Amjad M., Rehmani M.H., Mao S. Wireless multimedia cognitive radio networks: A comprehensive survey, *IEEE Communications Surveys & Tutorials*, 2018, vol. 20, no. 2, pp. 1056-1103. DOI:[10.1109/COMST.2018.2794358](https://doi.org/10.1109/COMST.2018.2794358)
3. Bychkov E.D., Kovalenko O.N., Belenkov D.V. *Dinamika sistem, mekhanizmov i mashin*. 2019, vol. 7, no. 4. DOI: [10.25206/2310-9793-7-4-192-199](https://doi.org/10.25206/2310-9793-7-4-192-199)
4. Zuev A.V. *Sistemy upravleniya, svyazi i bezopasnosti*, 2019, no. 3, DOI: [10.24411/2410-9916-2019-10302](https://doi.org/10.24411/2410-9916-2019-10302)
5. Shevtsov V.A., Borodin V.V., Krylov M.A. *Trudy MAI*, 2016, no. 85. URL: <http://trudymai.ru/eng/published.php?ID=66417>
6. Wang Y. et al. Data-driven deep learning for automatic modulation recognition in cognitive radios, *IEEE Transactions on Vehicular Technology*, 2019, vol. 68, no. 4, pp. 4074-4077. DOI:[10.1109/TVT.2019.2900460](https://doi.org/10.1109/TVT.2019.2900460)
7. Ibnkahla M. *Adaptation in wireless communications Taylor & Francis Group*, 2009, 485 p.
8. Borodin V.V., Petrakov A.M., Shevtsov V.A. *Trudy MAI*, 2015, no. 81. URL: <http://trudymai.ru/eng/published.php?ID=57894>
9. Borodin V.V., Petrakov A.M., Shevtsov V.A. *Elektrosvyaz'*, 2016, no. 11, pp. 41-45.

10. Rembovskii A.M. *Radiomonitoring. Zadachi, metody, sredstva* (Radiomonitoring. Objectives, methods, means), Moscow, Goryachaya liniya-Telekom, 2010, 623 p.
11. Adzhemov S.S., Klenov N.V., Tereshonok M.V., Chirov D.S. *Vestnik Moskovskogo universiteta. Seriya 3. Fizika. Astronomiya*, 2015, no. 6, pp. 19-27.
12. O'Shea T.J., Corgan J., Clancy T.C. Convolutional radio modulation recognition networks, *International conference on engineering applications of neural networks*, Springer, Cham, 2016, pp. 213-226. DOI:[10.1007/978-3-319-44188-7\\_16](https://doi.org/10.1007/978-3-319-44188-7_16)
13. Hazza A. et al. An overview of feature-based methods for digital modulation classification, *2013 1st international conference on communications, signal processing, and their applications (ICCSPA)*, IEEE, 2013, pp. 1-6. DOI:[10.1109/ICCSPA.2013.6487244](https://doi.org/10.1109/ICCSPA.2013.6487244)
14. Pu D., Cozma A., Hill T. Four quick steps to production: Using model-based design for software-defined radio, *Analog Dialogue*, 2015, vol. 49, pp. 1-5.
15. Tridgell S. *Low Latency Machine Learning on FPGAs, Ph.D*, Thesis, University of Sydney, Sydney, Australia, 2020.
16. *Xilinx DPU Product Guide*. URL: [https://www.xilinx.com/support/documentation/ip\\_documentation/dpu/v3\\_2/pg338-dpu.pdf](https://www.xilinx.com/support/documentation/ip_documentation/dpu/v3_2/pg338-dpu.pdf)
17. Kedia R., Goel S., Balakrishnan M., Paul K., Sen R. Design Space Exploration of FPGA-Based System With Multiple DNN Accelerators, *IEEE Embedded Systems Letters*, 2021, vol. 13, no. 3, pp. 114-117.
18. Simonyan K., Zisserman A. *Very deep convolutional networks for large-scale image recognition*, arXiv preprint: arXiv:1409.1556, 2014.



19. He K., Zhang X., Ren S., Sun J. Deep residual learning for image recognition, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 770-778. [DOI:10.1109/CVPR.2016.90](https://doi.org/10.1109/CVPR.2016.90)
20. Szegedy C. et al. Going deeper with convolutions, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2015, pp. 1-9. DOI:[10.1109/CVPR.2015.7298594](https://doi.org/10.1109/CVPR.2015.7298594)
21. Peng S. et al. Modulation classification based on signal constellation diagrams and deep learning // *IEEE transactions on neural networks and learning systems*, 2018, vol. 30, no. 3, pp. 718-727. DOI:[10.1109/TNNLS.2018.2850703](https://doi.org/10.1109/TNNLS.2018.2850703)

Статья поступила в редакцию 02.12.2021; одобрена после рецензирования 05.12.2021; принята к публикации 21.12.2021

The article was submitted on 02.12.2021; approved after reviewing on 05.12.2021; accepted for publication on 21.12.2021.