

С.А. Сарманбетов*, А.А. МаксUTOва, Е. Сагидолда, Д.М. Жексебай, Е.Т. Кожагулов

Казахский национальный университет имени аль-Фараби, Алматы, Казахстан

*e-mail: sarmanbetov.sanzhar@gmail.com

КЛАССИФИКАЦИЯ МОДУЛИРОВАННЫХ РАДИОСИГНАЛОВ НА ОСНОВЕ СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ

Аннотация. Работа посвящена исследованию сверточных нейронных сетей для применения в классификации модулированных радиосигналов. Автоматическая классификация сигналов модуляции имеет широкий спектр применения в беспроводной связи. Также, показаны модулированные радиосигналы при различном уровне SNR. В данной работе использовались данные с базы радиомодулированных сигналов DeepSig, созданные с помощью GNU Radio. Исходя из этого, рассмотрена классификация модуляции с помощью сверточных нейронных сетей последнего поколения. В работе показаны графики зависимостей показывающие точности обучения сети, а также матрицы неточностей с различными видами модулированных радиосигналов. Показано, что сверточные нейронные сети последнего поколения являются наиболее подходящими для решения данной проблемы, так как имеют способность быстрого обучения и точного определения.

Ключевые слова: модуляция, сверточные нейронные сети, SNR, GNU Radio.

Введение. Радиосвязь представляет собой уникальную область для обработки сигналов с рядом интересных проблем и возможностью для машинного обучения. В этой области экспертные характеристики и критерии были тщательно разработаны и проанализированы на предмет оптимальности в течение многих лет.

Традиционные методы автоматической классификации модуляции [1-2] можно разделить на две части: методы, основанные на правдоподобии и методы, основанные на признаках. Метод, основанный на правдоподобии, может минимизировать частоту ошибок, но его вычислительная сложность высока, и он не адаптирован к неизвестным условиям канала и помехам между передатчиком и приемником. Методы на основе признаков вычисляют определенные характеристики принятого сигнала, как абсолютная нормализованная мгновенная частота, среднее значение, стандартное отклонение и нарушение нормализованной центрированной амплитуды принятого сигнала. Вычислительная сложность этих методов относительно невысока, но выбор признаков сильно зависит от ручного анализа. Очень сложно найти характеристики, которые могли бы адаптироваться к неидеальным условиям и различать несколько типов модуляции. Из этого следует, что автоматическая классификация модуляции является очень сложной задачей, особенно, когда не имеется предварительная информация о принятых сигналах.

В последние годы глубокое обучение извлекло пользу из нейросетевых элементов, что помогло изучить более детальную информацию входных данных, демонстрируя отличную производительность во многих задачах, таких как классификация и обработка изображений, машинный перевод и т.д. Глубокое обучение, в частности, сверточные нейронные сети (CNN) широко использовались в нескольких областях беспроводной связи и обработки радиосигналов, в регулировании и восстановлении разреженного сигнала, оценке канала, распределении ресурсов и локализации. CNN - это особый тип искусственной нейронной сети, предназначенный в первую очередь для задач компьютерного зрения. Классические CNN часто содержат четыре основных уровня: сверточный слой, слой объединения, полностью связанный входной слой и первый полностью связанный слой. Сверточный слой - «фильтр» проходит по изображению, сканируя несколько пикселей за раз и создавая карту объектов, которая предсказывает класс, к которому принадлежит каждый объект. Слой объединения (понижающая дискретизацию) - уменьшает количество информации в каждой

характеристике, полученной в сверточном слое, сохраняя при этом наиболее важную информацию (обычно существует несколько циклов свертки и объединения). Полностью связанный входной слой (сглаживание) - принимает выходные данные предыдущих слоев, «сглаживает» их и превращает их в единый вектор, который может быть входом для следующего этапа. Первый полностью связанный слой [3-5] принимает входные данные из объектов и применяет веса для предсказания правильной метки. Первый полностью связанный слой дает окончательные вероятности для каждой метки [6-8]. Сверточные нейронные сети обеспечивают частичную устойчивость к изменениям масштаба, смещениям, поворотам, смене ракурса и прочим искажениям.

Из анализа современной литературы [9] сверточная нейронная сеть и ее модификации считаются лучшими по точности и скорости алгоритмов нахождения объектов. Начиная с 2012 года, нейросети занимают первые места на известном международном конкурсе по распознаванию образов ImageNet [10]. На сегодняшний день нерешенной задачей является применение современных моделей нейронных сетей для решения классификаций типов модуляции с разными уровнями соотношения сигнал / шум (SNR).

Целью данной работы является классификация типов модуляции с разными уровнями соотношения сигнал / шум (SNR) с помощью разных архитектур сверточных нейронных сетей для повышения точности классификации.

Экспериментальная часть. Данные показанные в этой работе были взяты из ресурса DeepSig [11-12]. DeepSig содержит небольшие стандартные наборы данных, которые могут использоваться для воспроизводимых исследований и экспериментов. Набор данных создан с помощью GNU Radio, состоящий из радиосигналов, модулированных разными типами модуляции и также охваченными значением отношений сигнал/шум (SNR). Рассматриваются 11 типов модуляций, а именно 8PSK, AM-DSB, AM-SSB, BPSK, CPFSK, GFSK, PAM4, QAM16, QAM64, QPSK и WBFM.

Обучение сетей. Во время обучения нейросети размер мини-пакета устанавливается равным 128. Количество эпох обучения сети CNN-Net составляет 120. Общее количество классов 11, размер батча составляет 1024. Прежде чем обучать данные, разделим их на обучающую и тестовую выборку. Обучающий набор признаков – это то, что предоставляется нашей модели вместе с ответами в ходе обучения. Модель должна выучить соответствие признаков цели. Тестовый набор признаков используется для оценки обученной модели. Когда она обрабатывает тестовый набор, то не видит правильных ответов и должна прогнозировать, опираясь только на доступные признаки. Ответы для тестовых данных известны и можно сравнить с ними полученные результаты прогнозирования. Тестовая выборка составила 20% исходных данных с коэффициентом валидации 5%. Размеры выборок после их разделения: X_train (129648, 2, 128), X_test (32412, 2, 128), labels_train (129648, 2), labels_test (32412, 2), y_train (129648,), y_test (32412,).

Для переменной ответа использовался LabelBinarizer (). Label Binarizer - это класс SciKit Learn, который принимает категориальные данные в качестве входных данных и возвращает массив NumPy. В отличие от Label Encoder, он кодирует данные в фиктивные переменные, указывающие наличие конкретной метки или ее отсутствие. Было проведено кодирование данных столбца с использованием Label Binarizer. После применения данного кодирования размеры переменной составили: y_train (129648, 11), y_test(32412, 11).

В данной работе использовался классический полносвязанный слой, с добавлением BatchNormalization слоя для повышения точности, который нормализует данные путем вычитания среднего и стандартизации, при обучении некоторых параметров, позволяющих сети обучать представление нормализации между ненормализованным и полностью нормализованным данными. Модули начального уровня представляют собой типичные сверточные нейронные сети (CNN), которые состоят из сложных сверточных слоев в сочетании с максимальным объединением и отключением.

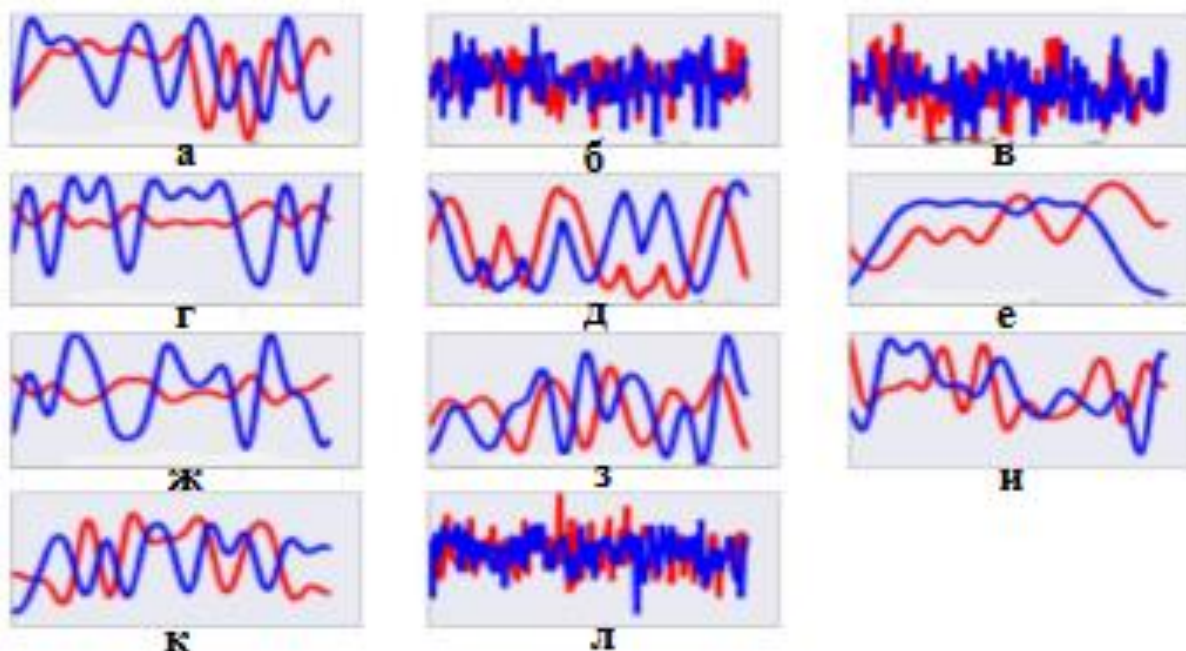


Рисунок 1. Примеры из базы данных DeepSig модулированных сигналов
а) график времени модуляции 8PSK, б) график времени модуляции AM-DSB,
в) график времени модуляции AM-SSB, г) график времени модуляции BPSK,
д) график времени модуляции CPFSK, е) график времени модуляции GFSK, ж) график времени
модуляции PAM4, з) график времени модуляции QAM16, и) график времени модуляции QAM64, к)
график времени модуляции QPSK, л) график времени модуляции WBFM.

На рисунке 2 показана архитектура, которая использована, в обобщенном виде с помощью keras. Определение самой модели можно разбить на несколько характеристик: количество слоев, типы этих слоев, количество единиц (нейронов) в каждом слое, функции активации каждого слоя, размер ввода и вывода.

Существует много типов слоев для моделей глубокого обучения. Convolutional и pooling layers используются в CNN, которые классифицируют или выполняют обнаружение объектов.

На рисунке 3 показан график сравнения точностей проверки и обучения.

Dense layers являются наиболее распространенными и популярными типами слоя - это просто обычный слой нейронной сети, в котором каждый из ее нейронов связан с нейронами предыдущего и следующего слоя. Каждый из них имеет функцию активации, которая определяет выход нейронов на основе входных данных и весов синапсов.

Dropout layers - это просто слои регуляризации, которые случайным образом сбрасывают некоторые входные единицы до 0. С ее помощью можно снизить вероятность переобучения нейронной сети. В построении модели были использованы несколько Dense layers и Dropout layers. Число нейронов в каждом слое варьировался от 11 и 640.

Самыми распространенными функциями активации являются ReLU (Rectified Linear Unit), сигмоидная функция и линейная функция. В нашей модели были использованы несколько разных функций.

Всего было использовано 497 515 параметров модели. Обучаемые параметры: 496 875. Необучаемые параметры: 640.

Layer (type)	Output Shape	Param #	Connected to
input_5 (InputLayer)	(None, 2, 128)	0	
reshape_5 (Reshape)	(None, 1, 2, 128)	0	input_5[0][0]
conv2d_29 (Conv2D)	(None, 1, 2, 128)	16512	reshape_5[0][0]
conv2d_31 (Conv2D)	(None, 1, 2, 128)	32896	reshape_5[0][0]
conv2d_33 (Conv2D)	(None, 1, 2, 128)	16512	reshape_5[0][0]
max_pooling2d_5 (MaxPooling2D)	(None, 1, 2, 128)	0	reshape_5[0][0]
conv2d_30 (Conv2D)	(None, 1, 2, 64)	49216	conv2d_29[0][0]
conv2d_32 (Conv2D)	(None, 1, 2, 64)	32832	conv2d_31[0][0]
conv2d_34 (Conv2D)	(None, 1, 2, 64)	32832	conv2d_33[0][0]
conv2d_35 (Conv2D)	(None, 1, 2, 128)	16512	max_pooling2d_5[0][0]
batch_normalization_17 (Batch Normalization)	(None, 1, 2, 64)	256	conv2d_30[0][0]
batch_normalization_18 (Batch Normalization)	(None, 1, 2, 64)	256	conv2d_32[0][0]
batch_normalization_19 (Batch Normalization)	(None, 1, 2, 64)	256	conv2d_34[0][0]
batch_normalization_20 (Batch Normalization)	(None, 1, 2, 128)	512	conv2d_35[0][0]
concatenate_5 (Concatenate)	(None, 1, 2, 320)	0	batch_normalization_17[0][0] batch_normalization_18[0][0] batch_normalization_19[0][0] batch_normalization_20[0][0]
flatten_5 (Flatten)	(None, 640)	0	concatenate_5[0][0]
dropout_4 (Dropout)	(None, 640)	0	flatten_5[0][0]
dense_8 (Dense)	(None, 360)	230760	dropout_4[0][0]
dense_9 (Dense)	(None, 120)	43320	dense_8[0][0]
dense_10 (Dense)	(None, 64)	7744	dense_9[0][0]
dense_11 (Dense)	(None, 11)	715	dense_10[0][0]

Total params: 481,131
 Trainable params: 480,491
 Non-trainable params: 640

Рисунок 2. Начальная архитектура используемой сверточной нейронной сети

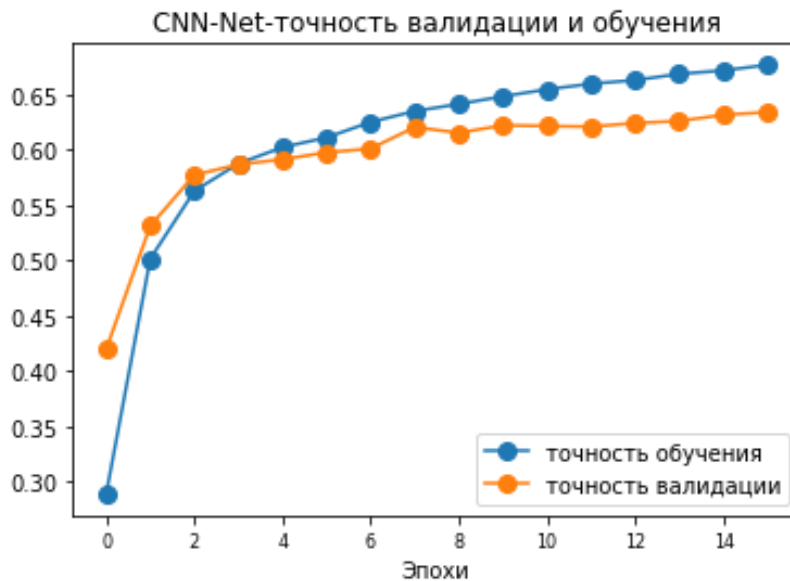


Рисунок 3. Сравнительный график точности проверки и точности обучения

С увеличением эпох видно, что точность для тестовых данных не опускается ниже производительности тренировочного набора, значит, переобучения нет. Модель способна правильно классифицировать 61% данных, при этом точность модели равна 60.94%.

На рисунке 4 показано построение матрицы неточностей для всех тестовых данных.

Как видно на матрице неточностей модель смогла правильно идентифицировать верно большинство классов. Наиболее верно были предсказаны классы модуляции AM-SSB, QAM64 более 80%, также PAM4, QAM16 более 60%. Но при этом модель неверно предсказала наиболее часто с 8PSK, AM-DSB до 40%.




Рисунок 4. Матрица начального замешательства CNN и точность всех тестовых данных

На рисунке 5 показан график матрицы ошибки при $SNR = 0$.

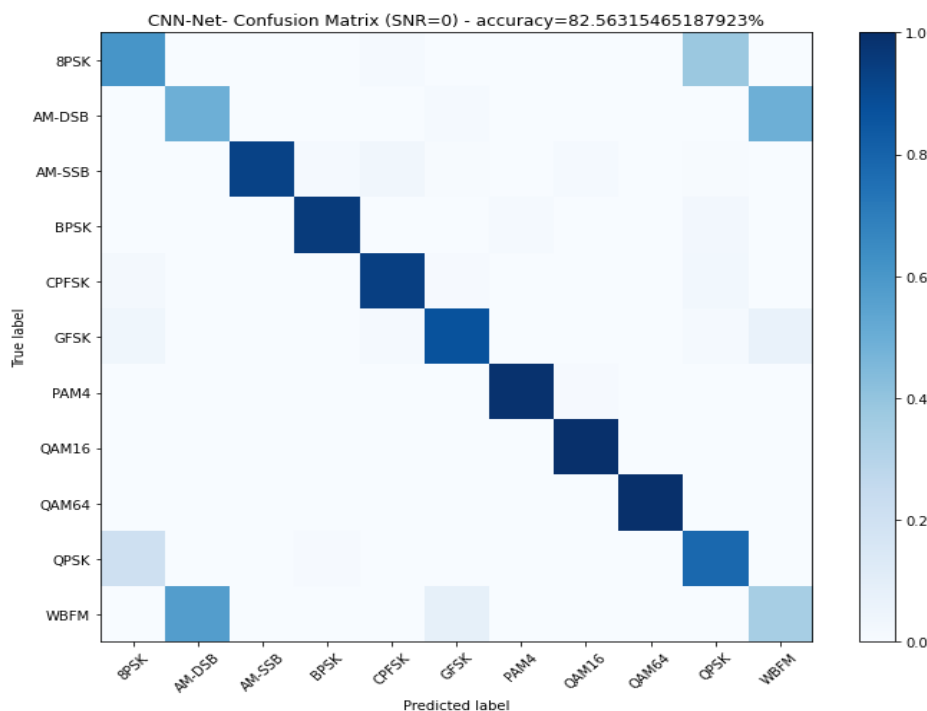


Рисунок 5. Матрица начальной ошибки CNN для $SNR = 0$

При $SNR = 0$ показатели confusion matrix улучшились, модель верно предсказала классы модуляции AM-SSB, BPSK, CPFSK, GFSK, PAM4, QAM16, QAM64 более 80%, также QPSK, 8PSK более 60%.

На рисунке 6 показан график зависимости точности от отношения сигнал / шум.




Рисунок 6. График зависимости точности классификации и отношения SNR

Точность классификации сначала быстро возрастает по мере увеличения SNR в пределах -20dB до 20dB, что согласуется с нашим теоретическим анализом. При SNR=18dB, точность классификации составляет 92%, следовательно, метод классификации модуляции на основе CNN эффективен даже при низком уровне SNR.

Заключение. В данной статье была проведена работа метода классификации модулированных радиосигналов на основе сверточной нейронной сети CNN. Хотя эти результаты не являются сравнением существующих классификаторов модуляции, основанных на лучших экспертных характеристиках, результаты демонстрируют, что для примеров с низким SNR, CNN представляет собой мощный, вероятно, современный подход точности к классификации модуляции. Сигналы с различными соотношениями сигнал/шум при низком уровне показала максимальный результат 92%. Этот подход может легко масштабироваться до дополнительных классов модуляции и должен рассматриваться как сильный кандидат для систем DSA и CR [13-15], которые полагаются на надежную классификацию радиоизлучателей с низким отношением сигнал/шум.

REFERENCES

- [1] W. A. Gardner and C. M. Spooner, "Signal interception: performance advantages of cyclic-feature detectors," *Communications, IEEE Transactions on*, vol. 40, no. 1, pp. 149-159, 1992.
- [2] J. Mitola III and G. Q. Maguire Jr, "Cognitive radio: making software radios more personal," *Personal Communications, IEEE*, vol.6, no. 4, pp. 13-18, 1999
- [3] C. Nvidia, "Compute unified device architecture programming guide," 2007.
- [4] T. W. Rondeau, "Application of artificial intelligence to wireless communications," PhD thesis, Virginia Tech, 2007.
- [5] M. D. Zeiler, D. Krishnan, G. W. Taylor, and R. Fergus, "Deconvolutional networks," in *Computer Vision and Pattern Recognition (CVPR)*, 2010. IEEE Conference on, IEEE, 2010, pp. 212-215.
- [6] H. Lee, A. Battle, et al., "Efficient sparse coding algorithms," in *Advances in neural information processing systems*, 2006, pp.801-808.
- [7] C. Clancy, J. Hecker, E. Stuntebeck, and T. O'Shea, "Applications of machine learning to cognitive radio networks," *Wireless Communications, IEEE*, vol. 14, no. 4, pp. 47-52, 2007.
- [8] K. Kim, I. A. Akbar, et al., "Cyclostationary approaches to signal detection and classification in cognitive radio," in *New frontiers in dynamic spectrum access networks*, 2007. DySPAN 2007, IEEE, 2007, pp. 212-215.
- [9] H. Lv, X. Zhou, J. Huo, J. Yuan. Joint OSNR monitoring and modulation format identification on signal amplitude histograms using convolutional neural network. *Optical Fiber Technology*, Volume 61, January 2021, 102455
- [10] D. Mishkina, N. Sergievskiy, J. Matas. Systematic evaluation of convolution neural network advances on the Imagenet. *Computer Vision and Image Understanding*, Volume 161, 2017, Pages 11-19.
- [11] E. Blossom, "Gnu radio: tools for exploring the radio frequency spectrum," *Linux journal*, vol. 2004, no. 122, p. 4, 2004.
- [12] P. J. Kolodzy, "Dynamic spectrum policies: promises and challenges," *CommLaw Conspectus*, vol. 12, p. 147, 2004.
- [13] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," in *Advances in neural information processing systems*, 2012, pp. 1097-1105.
- [14] T. Tieleman and G. Hinton, "Lecture 6.5-rmsprop: divide the gradient by a running average of its recent magnitude," *COURSERA: Neural Networks for Machine Learning*, vol. 4, p. 2, 212.
- [15] T. O'Shea, "Gnu radio channel simulation," in *GNU Radio Conference 2013*, 2013.

С.А. Сарманбетов*, А.А. Максұтова, Е. Сагидолда, Д.М. Жексебай, Е.Т. Кожагулов
Әл-Фараби атындағы Қазақ ұлттық университеті, Алматы, Қазақстан
*e-mail: sarmanbetov.sanzhar@gmail.com

МОДУЛЯЦИЯЛАНҒАН РАДИОСИГНАЛДАРДЫ ҮЙІРТКІЛІ НЕЙРОНДЫҚ ЖЕЛІ НЕГІЗІНДЕ ЖІКТЕУ

Андатпа. Жұмыс модуляцияланған радиосигналдарды жіктеуде қолдану үшін үйірткілі нейрондық желіні зерттеуге арналған. Модуляциялық сигналдарды автоматты түрде жіктеу сымсыз қосымшалардың алуан түрлілігіне ие. Сондай-ақ әр түрлі SNR деңгейлеріндегі модуляцияланған радио сигналдар көрсетілген. Бұл жұмыста GNU Radio көмегімен құрылған DeepSig радио модуляцияланған сигналдар базасының деректері пайдаланылды. Осыған сүйене отырып, соңғы буын үйірткілі нейрондық желілерді қолдана отырып модуляцияны жіктеу қарастырылады. Жұмыста желіні оқытудың дәлдігін көрсететін тәуелділік графиктері, сондай-ақ модуляцияланған радио сигналдардың әртүрлі типтерімен дәлсіздіктер матрицалары көрсетілген. Соңғы буынның үйірткілі нейрондық желілері бұл мәселені шешуге ең қолайлы екендігі көрсетілген, нейрондық желі тез үйренуге және дәл анықтауға қабілетті.

Негізгі сөздер: модуляция, үйірткілі нейрондық желі, SNR, GNU Radio.

S.A. Sarmanbetov*, A.A. Maksutova, Y. Sagidolda, D.M. Zhexebai, Y.T. Kozhagulov
al-Farabi Kazakh National University, Almaty, Kazakhstan
*e-mail: sarmanbetov.sanzhar@gmail.com

CLASSIFICATION OF MODULATED RADIOSIGNALS BASED ON CONVOLUTIONAL NEURAL NETWORKS

Abstract. The work is devoted to the study of convolutional neural networks for use in the classification of modulated radio signals. Automatic classification of modulation signals has a wide variety of wireless applications. Also shown are modulated radio signals at different SNR levels. In this work, we used data from the DeepSig base of radio modulated signals, created using GNU Radio. Based on this, the classification of modulation using the latest generation convolutional neural networks is considered. The work shows graphs of dependences showing the accuracy of training the network, as well as matrices of inaccuracies with various types of modulated radio signals. It is shown that convolutional neural networks of the latest generation are the most suitable for solving this problem, since they have the ability to quickly learn and accurately determine.

Keywords: modulation, convolutional neural networks, SNR, GNU Radio.