

Исследование эффективного обнаружения сигналов ММО в шахтах на основе глубокого обучения

В. В. Потехин

*Санкт-Петербургский
политехнический университет
Петра Великого*

Slava.Potekhin@spbstu.ru

В. С. Карпухин

*Санкт-Петербургский
политехнический университет
Петра Великого*

v.karpukhin@electrosystems.ru

Али Аббас

*Санкт-Петербургский
политехнический университет
Петра Великого*

abbas.a@edu.spbstu.ru

Р. В. Ершов

*Санкт-Петербургский
политехнический университет
Петра Великого*

Um-urii@mail.ru

Азез Мохаммад

*Санкт-Петербургский
политехнический университет
Петра Великого*

azez.m@edu.spbstu.ru

Хасан Шбиб

*Санкт-Петербургский
политехнический университет
Петра Великого*

shbib.h@edu.spbstu.ru

Аннотация. Предложена эффективная модель обнаружения ММО-сигналов в горных условиях на основе глубокого обучения, состоящая из сети нелинейного отображения и сети коррекции ошибок. Сеть нелинейного отображения отвечает за первоначальное восстановление принятых сигналов в двоичные битовые сигналы, а сеть коррекции ошибок исправляет ошибки, вносимые сетью нелинейного отображения. Сеть нелинейного отображения отвечает за первоначальное восстановление принятых сигналов в двоичные битовые сигналы, а сеть коррекции ошибок исправляет ошибки, вносимые сетью нелинейного отображения, тем самым повышая точность обнаружения сигналов. Эффективность предложенной модели была подтверждена с помощью моделирования, проведенного в шахтной ММО-системе связи. Результаты моделирования показали, что в смоделированной шахтной ММО-системе связи результаты моделирования не столь хороши, как в предложенной модели. Результаты моделирования показывают, что в смоделированной шахтной ММО-среде связи производительность превосходит традиционные приемники при изменении метода модуляции на передатчике, метода кодирования канала и среды канала. Метод представляет собой новое решение проблемы низкой эффективности декодирования интеллектуальных приемников, и его преимущество было доказано в сложной среде интеллектуальных приемников. Было доказано в сложной среде подземной шахты.

Ключевые слова: шахтная коммуникация; интеллектуальный приемник; глубокое обучение; ММО

I. ВВЕДЕНИЕ

В последние годы алгоритмы глубокого обучения широко используются в обработке изображений [1–3], обработке естественного языка [4–6] и других областях. В предыдущих работах некоторые модули в системе были оптимизированы или заменены алгоритмами глубокого обучения, например, оценка канала [7–9], зондирование спектра [10, 11], идентификация модуляции [12, 13] и т. д.

Однако использование алгоритмов глубокого обучения только для разработки отдельных модулей системы связи может не позволить оптимизировать работу всей системы. Поэтому некоторые работы посвящены разработке сквозных интеллектуальных приемников [14–15], которые используют мощные нелинейные способности нейронных сетей в алгоритмах глубокого обучения для замены этапов оценки канала, эквализации и демодуляции в традиционных приемниках, чтобы реализовать цель прямого преобразования полученных сигналов в исходные двоичные данные. Среди них НАО Ye и др. выполнили ряд новаторских работ в этой области, в которых он реализовал оценку канала и обнаружение сигналов с помощью глубокой нейронной сети (DNN). Результаты моделирования показывают, что эта схема может реализовать весь процесс декодирования на стороне приемника системы связи OFDM, а ее производительность сопоставима с производительностью оценщика минимальной среднеквадратичной ошибки. Однако, когда параметры канала сильно меняются, точную оценку канала трудно реализовать, и производительность интеллектуального приемника, разработанного с использованием традиционного способа оценки канала, будет ухудшена. Для решения этой проблемы разработана модель интеллектуального приемника, управляемая данными, которая отличается от традиционного приемника тем, что на вход и выход модели подается принимаемый сигнал и исходные передаваемые двоичные данные, соответственно. Благодаря автономному обучению модель может изучить нелинейную взаимосвязь между входами и выходами с целью распознавания и декодирования сигнала. ZHENG и др. использовали «плотную» нейронную сеть (dense neural network) для извлечения особенностей сигналов на приемном конце, а затем преобразовали эти особенности в исходные двоичные данные с помощью нескольких двоичных классификаторов с общими весами. В частности, выход полностью связанного слоя предсказывается и определяется несколькими двоичными

классификаторами, а выход преобразуется в соответствующие двоичные значения. Результаты моделирования показывают, что глубокий приемник демонстрирует гораздо лучшую производительность по сравнению с обычными приемниками в условиях шума, многолучевых замираний и динамической среды. Приведенные выше исследования показывают, что алгоритмы глубокого обучения обладают большим потенциалом для оптимизации производительности систем связи. Однако с быстрым развитием беспроводных технологий широко разворачивается большое количество мобильных устройств, которые должны поддерживать крупномасштабные соединения и требовать низкой задержки при ограниченных ресурсах спектра. Поэтому интеллектуальные приемники должны эффективно и точно распознавать, и обрабатывать массивные беспроводные сигналы в сложных условиях. Для модели интеллектуального приемника, предложенной в, совместное использование весов позволяет эффективно уменьшить параметры сети и время обучения. Однако с увеличением количества данных восстановления приемника BER системы значительно возрастает. Хотя эту проблему можно решить, обрабатывая входные и выходные данные блоками, обучение сети в разных блоках увеличит время обучения, а одновременное развертывание нескольких сетей может привести к нерациональному использованию вычислительных ресурсов. Поэтому большое теоретическое значение и широкие перспективы применения имеет исследование и разработка модели интеллектуального приемника с высокой точностью и эффективностью. В данном исследовании разработана эффективная модель обнаружения сигнала на основе ММО-связи, которая широко используется в горнодобывающей промышленности. Модель состоит из нелинейной сети отображения и сети коррекции ошибок. Сеть нелинейного отображения осуществляет первоначальное восстановление полученного сигнала в двоичные битовые данные, а сеть коррекции ошибок используется для исправления данных, полученных от сети нелинейного отображения. Экспериментальные результаты показывают, что модель может быть обучена и оптимизирована для достижения эффективного обнаружения сигнала в шахтной среде, а BER модели значительно ниже, чем у традиционной модели.

II. МОДЕЛЬ СИСТЕМЫ ММО И ШАХТНЫЙ БЕСПРОВОДНОЙ КАНАЛ

Основная структура ММО-передатчика показана на рис. 1. Исходные двоичные данные преобразуются в поток символов после кодирования источника и кодирования канала, а затем потоки символов передаются в беспроводной канал с помощью технологии разнесения. Разнообразии — это одна из ключевых технологий системы ММО, которая повышает эффективность и качество системы связи за счет разложения потока символов на несколько потоков символов. К технологиям разнесения в основном относятся пространственно-временное кодирование, пространственно-частотное кодирование и кодирование с циклической задержкой. Среди них пространственно-временное кодирование может реализовать выигрыш в разнообразии и выигрыш в кодировании системы за счет кодирования передаваемых сигналов. В данной работе мы исследуем

пакетный пространственно-временной код STBC и используем схему пространственно-временного кодирования Аламути, когда количество передающих и принимающих антенн равно двум, поток символов $[s_1, s_2]$ будет преобразован в матрицу S с размерностью 2×2 . В первом временном слоте через две антенны передается $[s_1, s_2]$, а в следующем $[-s_2^*, s_1^*]$. Где s_i^* обозначает комплексное сопряжение s_i .

$$s = \begin{bmatrix} s_1 & -s_2^* \\ s_2 & s_1^* \end{bmatrix} \quad (1)$$

В условиях шахты электромагнитные волны, излучаемые передатчиком, часто отражаются, рассеиваются и обходятся верхней плитой, нижней плитой и двумя боковыми стенками туннеля. Поэтому, чтобы точно охарактеризовать условия связи в шахте, выбирается модель канала Накагами. Эта модель может лучше имитировать характеристики распространения электромагнитных волн в сложных средах и, таким образом, обеспечивает более точные результаты моделирования канала.

$$f_R(a) = \frac{2}{\Gamma(m)} \left(\frac{m}{\Omega}\right)^m a^{2m-1} \exp\left(-\frac{ma^2}{\Omega}\right) \quad (2)$$

где $\Gamma(m)$ – Гамма-функция, средняя мощность многолучевого рассеянного поля $\Omega = E(a^2)$, m – коэффициент замирания в канале Накагами, который описывает степень замирания поля распространения из-за процесса рассеяния и многолучевой интерференции.

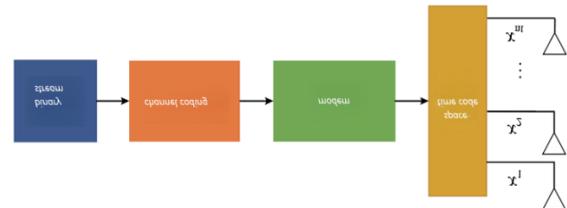


Рис. 1. Базовая структура передатчиков ММО

Пусть число антенн приемника равно 1, а число антенн передатчика равно 2, как указано выше, тогда размерность матрицы усиления канала Накагами H_m равна 1×2 . Каждый элемент $h_{i,j}$ в матрице H_m является случайной величиной, подчиняющейся распределению Накагами, а $h_{i,j}$ обозначает коэффициент усиления канала от i -й антенны приемника к j -й антенне передатчика. Данные, принятые приемником Y_m , имеют вид.

$$Y_m = H_m S + N \quad (3)$$

где N – матрица размерности 1×2 , обозначающая аддитивный гауссовский белый шум (AWGN), а Y_m – данные, полученные приемником за 2 символьных цикла.

III. МОДЕЛЬ ОБНАРУЖЕНИЯ СИГНАЛОВ ММО

Задача модели обнаружения сигнала ММО на основе глубокого обучения – извлечь особенности из принимаемого сигнала и восстановить данные, переданные передатчиком. Базовая структура модели обнаружения сигнала показана на рис. 2. Когда сигнал, принимаемый приемником, равен Y_m , модель обнаружения сигнала реализуется уравнением.

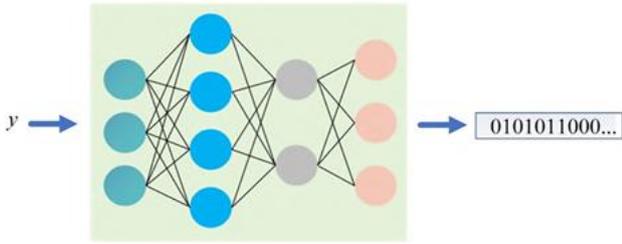


Рис. 2. Модель обнаружения сигналов

$$\bar{x} = f([\text{Re}(Y_m), \text{Im}(Y_m)]; \Theta) \quad (4)$$

В формуле \bar{x} – поток битов информации, восстановленный моделью обнаружения; Θ – набор параметров нейронной сети, используемой моделью обнаружения, который оптимизируется путем задания подходящей функции потерь в процессе обучения. В то же время, поскольку нейронная сеть не может работать с комплексными числами, в качестве входных данных для модели обнаружения извлекаются действительная и мнимая части полученных данных Y_m . В сочетании с уравнением (4), для обученной модели сети длина принимаемого сигнала увеличивается по мере увеличения длины отправляемых данных. Это может привести к увеличению количества признаков в принимаемом сигнале, что затрудняет точное распознавание и извлечение признаков исходной моделью обнаружения сигнала при обработке более длинных входных данных. В результате производительность системы снижается. Выходом из этой ситуации является увеличение сетевых параметров модели обнаружения сигнала, однако это приводит к увеличению временной сложности и ресурсоемкости алгоритма. Другим выходом из ситуации является обработка полученных данных кусками, но в этом случае возникает проблема, что разным кускам соответствуют разные параметры модели, и развертывание нескольких моделей может привести к нерациональному использованию ресурсов. В то же время для обработки необходимо установить разумный размер чанка. Подводя итог, можно сказать, что существующие алгоритмы обнаружения сигналов на основе глубокого обучения имеют проблему низкой эффективности, поэтому в данной работе разработана высокоэффективная модель обнаружения сигналов MIMO, которая состоит из нелинейной сети отображения и сети коррекции ошибок, а ее структура показана на рис. 3.

IV. НЕЛИНЕЙНЫЕ КАРТОГРАФИЧЕСКИЕ СЕТИ

В модели обнаружения сигнала, предложенной в данном исследовании, нелинейное отображение

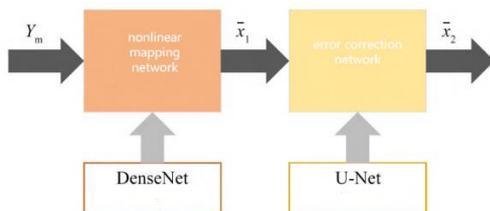


Рис. 3. Структура эффективной модели обнаружения MIMO

Задача сети – преобразовать данные Y_m , полученные на приемном конце, в поток информационных битов x , и сделать восстановленные данные как можно более близкими к информационным битам, отправленным на приемном конце. Выходной сигнал сети нелинейного обнаружения:

$$\bar{x} = f([\text{Re}(Y_m), \text{Im}(Y_m)]; \Theta) \quad (5)$$

В сочетании с уравнением (4) выход нелинейной сети обнаружения может быть преобразован в:

$$\bar{x}_1 = f_1([\text{Re}(H_m S + N), \text{Im}(H_m S + N)]; \Theta_1) \quad (6)$$

Уравнение (5) показывает, что сеть нелинейного отображения восстанавливает битовый поток данных из переданных данных, которым мешает канал. Кроме того, обученная сеть нелинейного отображения способна восстанавливать информацию в нескольких схемах кодирования модуляции без необходимости разработки модели обнаружения для различных схем кодирования модуляции. В сочетании с уравнением (5) можно сделать вывод, что выбор и разработка соответствующей модели нейронной сети напрямую влияют на точность и эффективность обнаружения сигнала. Сеть нелинейного отображения в основном состоит из двух частей: извлечения признаков и отображения признаков, в которой извлечение признаков принимаемого сигнала реализуется плотной нейронной сетью (DenseNet). Традиционная конволюционная нейронная сеть принимает выход слоя $l-1$ y_{l-1} в качестве входа слоя l , что можно выразить следующим образом.

$$y_l = H_l(y_{l-1}) \quad (7)$$

Где $H_l(y_{l-1})$ представляет собой составную функцию, которая состоит из конволюционного слоя, слоя объединения и так далее. По сравнению с традиционной конволюционной нейронной сетью, сеть DenseNet использует концепцию повторного использования признаков. В сети DenseNet каждый слой связан со всеми предыдущими конволюционными слоями. Поэтому в сети DenseNet выход первого слоя:

$$y_l = H_l(y_0, y_1, \dots, y_{l-1}) \quad (7)$$

Сеть DenseNet в основном состоит из DenseBlock и TransitionBlock, которые состоят из нескольких BasicBlock, а DenseBlock, сформированный из трех BasicBlock, показан на рис. 4. Блок DenseBlock использует в качестве входных данных связи признаков, извлеченные из предыдущего слоя сети, что увеличивает повторное использование признаков и уменьшает потерю информации. В то же время, чтобы избежать снижения временной эффективности алгоритма из-за большого количества входных данных, выход DenseBlock не используется напрямую в качестве входа следующего слоя DenseBlock. Для уменьшения размера карты признаков и параметров модели между соседними блоками DenseBlock добавляется переходный блок TransitionBlock. Это позволяет сбалансировать сложность сети и эффективность вычислений, а также улучшить обучаемость модели.

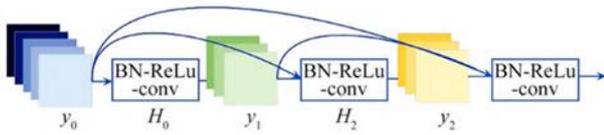


Рис. 4. Плотная блочно-модульная структура

Модель сети показана на рис. 5. Полученные сигналы сначала вводятся в конволюционный слой с 300 каналами и размером 7×7 для первоначального выделения признаков. Полученный сигнал сначала вводится в конволюционный слой 7×7 с 300 каналами для первоначального выделения признаков, а затем в плотную нейронную сеть для глубокого выделения признаков, где K в TransitionBlock(K) означает количество конволюционных ядер в переходном слое, а TransitionBlock(K) состоит из слоя Batchnormalization, слоя ReLu, слоя Maximum Pooling и конволюционного слоя. В сети используются два плотных блока, DenseBlock1 состоит из 2 слоев BasicBlock, а DenseBlock2 – из 3 слоев BasicBlock.

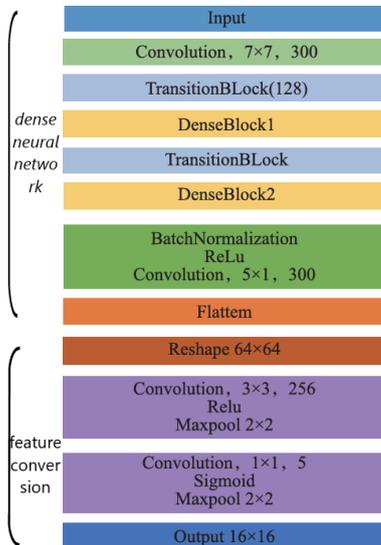


Рис. 5. Структура сети нелинейного отображения

В то же время, чтобы преобразовать полученные данные в двоичный поток битов, в модели нелинейной сети отображения для признаков, извлеченных из сети DenseNet, разработана структура преобразования признаков, показанная на рис. 5. Сначала признаки, извлеченные из плотной нейронной сети, преобразуются в двумерную матрицу признаков, которая является основой для последующей генерации двумерных матричных данных. Затем матрица признаков подается на два конволюционных слоя + пулинг, где пулинг-слой используется для уменьшения размерности. Следует отметить, что эти два сверточных слоя играют разные роли: первый используется для извлечения признаков, в то время как количество ядер свертки второго установлено на 1, чтобы трехмерные признаки могли быть преобразованы в двумерные в процессе извлечения признаков. Таким образом осуществляется преобразование признаков в бинарную матрицу.

Кроме того, в отличие от функции активации Softmax, используемой в выходном слое в литературе [20], в данной работе используется функция активации Sigmoid. По сравнению с функцией активации Softmax, в процессе автономного обучения нет необходимости преобразовывать двоичные данные, отправленные отправителем, в одноточечные метки, что позволяет сэкономить время обработки сети. В то же время преобразование одноточечных меток в двоичные данные во время онлайн-вычислений также увеличит время обработки сети. Поэтому выбор сигмоидальной функции активации может не только упростить обработку, но и повысить вычислительную эффективность сети.

V. СЕТИ КОРРЕКЦИИ ОШИБОК

Сеть коррекции ошибок предназначена для оптимизации битового потока данных, выводимых из сети нелинейного отображения, и повышения точности обнаружения сигнала за счет оптимизации сети коррекции ошибок. Сеть коррекции ошибок предназначена для оптимизации битового потока данных, выводимых из сети нелинейного отображения, и повышения точности обнаружения сигнала за счет оптимизации сети коррекции ошибок. Битовый поток данных, оптимизированный сетью коррекции ошибок, выглядит следующим образом.

$$\bar{x}_2 = f_2(\bar{x}_1; \Theta_2) \quad (8)$$

где \bar{x}_2 – выходные данные сети коррекции ошибок, а \bar{x}_1 – данные битового потока, восстановленные сетью нелинейного отображения. Θ – набор параметров сети. Структура сети коррекции ошибок показана на рис. 6, которая аналогична структуре классической сети U-net [23], где левая часть является структурой кодирования, а структура кодирования реализует извлечение признаков, и может эффективно распознавать признаки в двоичных битовых данных. Каждый слой структуры кодирования состоит из двух незаполненных сверток размером 3×3 , затем корректирующего линейного блока (ReLU) и слоя максимального объединения размером 2×2 с шагом 2. Слой объединения используется для понижающей дискретизации. Этот объединяющий слой используется для понижающей дискретизации, а количество каналов признаков удваивается на шаге понижающей дискретизации. В правой части рисунка показана структура декодирования, которая выполняет повышающую дискретизацию для восстановления информации о признаках. Каждый слой структуры декодирования состоит из апсэмплинга, за которым следует свертка 2×2 , а затем он подается на две свертки 3×3 , за которыми следует корректирующий линейный блок (ReLU). Кроме того, в сети U-net имеется прыгающая структура, которая предназначена для объединения поверхностных и глубоких признаков с целью дальнейшего повышения способности сети к извлечению признаков. В последнем слое U-сетевой сети задается свертка размером 1×1 , с помощью которой выполняется отображение размерности для сопоставления 256 компонентов вектора признаков с необходимым количеством классов. Функция активации последнего слоя такая же, как и в сети нелинейного отображения, используется сигмоидальная функция активации.

VI. МЕТОДЫ ОБУЧЕНИЯ МОДЕЛЕЙ

Модель обнаружения сигнала, разработанная в данном исследовании, состоит из сети нелинейного отображения и сети коррекции ошибок. На этапе автономного обучения сначала обучается сеть нелинейного отображения. На вход сети нелинейного отображения подаются данные, полученные приемником, а на выход – исходные двоичные битовые данные, переданные передатчиком. Затем обучается сеть коррекции ошибок, и выходом сети коррекции ошибок являются исходные двоичные биты, отправленные передатчиком.

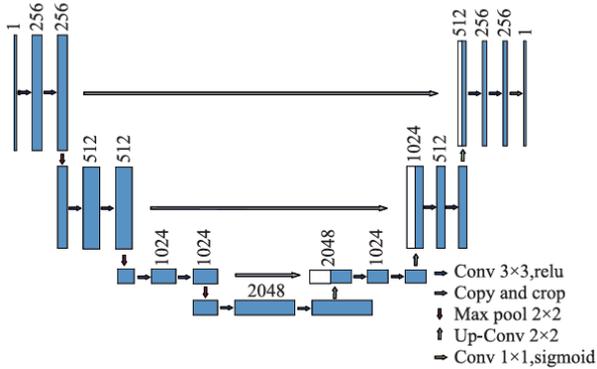


Рис. 6. Структура сети коррекции ошибок

На входе – двоичные битовые данные, восстановленные нелинейной сетью отображения, а на выходе – исходные двоичные битовые данные, отправленные отправителем.

Выбор разумной функции потерь является одним из ключевых факторов, обеспечивающих эффективное обучение нейронных сетей. В процессе обучения сети нелинейного отображения и сети коррекции ошибок бинарная функция потерь кросс-энтропии выбирается следующим образом.

$$Loss = -\frac{1}{m} \sum_{i=1}^m y_i \ln \hat{y}_i + (1 - y_i) \ln (1 - \hat{y}_i) \quad (9)$$

где m – количество выборок, которое представляет собой длину двоичных данных, восстановленных нейронной сетью; y_i – исходные двоичные данные отправителя; \hat{y}_i – фактические выходные данные нейронной сети.

Когда модель обнаружения сигнала обучена и развернута в режиме онлайн, сигналы, полученные приемником, вычисляются в режиме онлайн по уравнениям (7) и (8), а восстановленные двоичные биты выдаются на выходе.

VII. МОДЕЛИРОВАНИЕ И АНАЛИЗ ЭКСПЕРИМЕНТАЛЬНЫХ РЕЗУЛЬТАТОВ

В данном исследовании мы анализируем работу модели обнаружения сигнала в условиях канала Накагами и используем коэффициент битовых ошибок (BER) в качестве метрики для оценки эффективности алгоритма. Влияние различного количества двоичных битов, различных параметров канала Накагами, различных схем кодирования канала и различных режимов модуляции на производительность модели обнаружения сигнала

исследуется в системе связи MIMO. Система MIMO построена с использованием среды моделирования Matlab, а принимаемые данные и соответствующие им двоичные данные передатчика генерируются в канале Накагами. Модель обнаружения сигнала была построена на языке Python, а наборы данных были разделены на обучающий, проверочный и тестовый наборы в соотношении 8:1:1 при различных экспериментальных сценариях. Скорость обучения была установлена на 0,0001 в сети нелинейного отображения и сети коррекции ошибок.

VIII. ПРОИЗВОДИТЕЛЬНОСТЬ МОДЕЛЕЙ ОБНАРУЖЕНИЯ СИГНАЛА ПРИ РАЗЛИЧНОЙ ДЛИНЕ ДАННЫХ ВОССТАНОВЛЕНИЯ

Для удобства изложения модель обнаружения сигнала приемника глубины, предложенная в, и модель обнаружения интеллектуального приемника, предложенная в данном исследовании, заменены соответствующими аббревиатурами TR, DR и IR, соответственно. В данном исследовании моделируются двоичные биты длиной 64, 128 и 256 бит, а модель обнаружения сигнала, предложенная в данном исследовании, сравнивается с моделью, описанной в литературе. В среде моделирования подробные наборы данных генерируются следующим образом, например, для восстановления длины данных 64 передатчик случайным образом генерирует 64-битные двоичные данные, которые затем кодируются (7,4) кодом Хэмминга и модуляцией BPSK для генерации 64-битного набора данных. Поток символов длиной 112 генерируется кодом (7,4) Хэмминга и модуляцией BPSK, а количество антенн передатчика и приемника устанавливается равным 2. Символьный поток преобразуется в символ длины 2×112 после кодирования Аламути, и передаваемый сигнал проходит через канал Накагами, в котором параметр канала $m=0,95$, что представляет собой реальную обстановку в шахте. Приемник рассчитан на прием сигналов с частотой дискретизации, в 8 раз превышающей символьную, т. е. 8 выборок на символ, причем время первой выборки случайным образом сдвигается на 1/8 периода символа. В результате длина данных каждой принятой выборки составляет 3600.

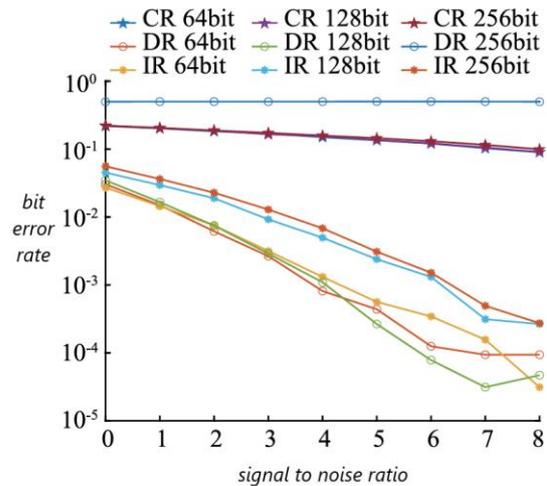


Рис. 7. Сравнение производительности моделей обнаружения сигнала при различной длине восстанавливаемых данных

Сравнение производительности модели при различной длине восстановленных данных показано на рис. 7. Как видно из рис. 7, производительность обычного приемника стабильна при увеличении длины восстановленных данных, но его точность обнаружения самая низкая в условиях шахты. Модель обнаружения сигналов DR, предложенная в, сохраняет высокую точность при длине восстановленных данных 64 и 128 бит, и ее точность намного выше, чем у обычного приемника, но когда количество восстановленных двоичных данных увеличивается до 256 бит, обнаружение сигналов становится неточным. Это явление указывает на то, что способность к извлечению признаков модели обнаружения сигналов, предложенной в, снижается по мере увеличения длины восстановленных данных. Для модели IR, предложенной в данном исследовании, наибольшая точность достигается при длине восстановленных данных 128 бит, BER ИК-модели постепенно увеличивается, но ее точность близка к литературным данным и намного лучше, чем эффективность декодирования традиционного приемника. Когда восстановленные данные достигают 256 бит, предложенная модель обнаружения сигнала по-прежнему способна точно обнаружить сигнал. Это говорит о том, что по сравнению с глубокой моделью приемника интеллектуальная модель приемника, предложенная в данном исследовании, имеет более высокую эффективность обнаружения, может восстановить больше данных за один процесс онлайн вычислений и не требует обработки данных по частям, что экономит аппаратные ресурсы компьютера.

IX. ПРОИЗВОДИТЕЛЬНОСТЬ МОДЕЛЕЙ ОБНАРУЖЕНИЯ СИГНАЛА В РАЗЛИЧНЫХ УСЛОВИЯХ ШАХТНОГО БЕСПРОВОДНОГО КАНАЛА

В эксперименте исходная двоичная длина передатчика установлена в 256 бит, а параметры канала Накагами – в $m=0,5$, $m=0,95$ и $m=2$. Результаты моделирования показаны на рис. 8. BER обычного приемника уменьшается с увеличением параметра канала m , а BER ИК-модели, предложенной в данной работе, значительно ниже, чем у обычного приемника. Кроме того, BER ИК-модели сохраняется на одном уровне при различных параметрах канала Накагами, что говорит о том, что предложенная ИК-модель имеет отличную производительность в канале Накагами, и на ее эффективность декодирования не влияет параметр канала m . Результаты показаны на рис. 8, из которых видно, что BER обычного приемника уменьшается с увеличением параметра канала m , а BER предложенной ИК-модели значительно ниже, чем у обычного приемника

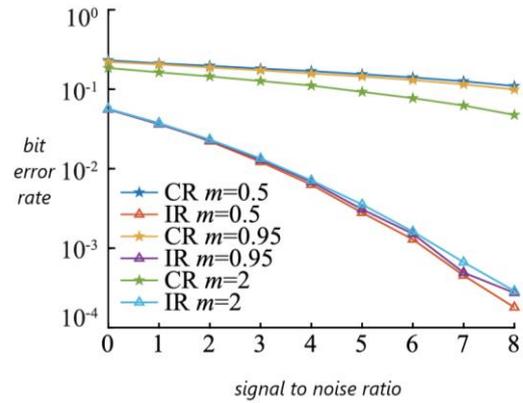


Рис. 8. Сравнение эффективности моделей обнаружения сигнала при различных параметрах канала Накагами

Передатчик посылает двоичные данные длиной 256 бит, а параметр канала Накагами $m=0,95$, что указывает на реальную обстановку в шахте. В передатчике используется модуляция BPSK, QPSK и 16QAM. Результаты моделирования показаны на рис. 9, и BER обычного приемника увеличивается с ростом порядка модуляции. При том же режиме модуляции эффективность декодирования предложенной ИК-модели выше, чем у обычного приемника. При этом модель обнаружения сигнала с модуляцией 16QAM достигает более низкого BER, чем обычный приемник с модуляцией BPSK. Основываясь на этом экспериментальном явлении, ИК-модель обнаружения сигнала, предложенная в данной работе, может быть использована для разработки подходящего метода модуляции в шахтной MIMO-системе связи, чтобы повысить эффективность передачи информации при сохранении более высокой точности декодирования.

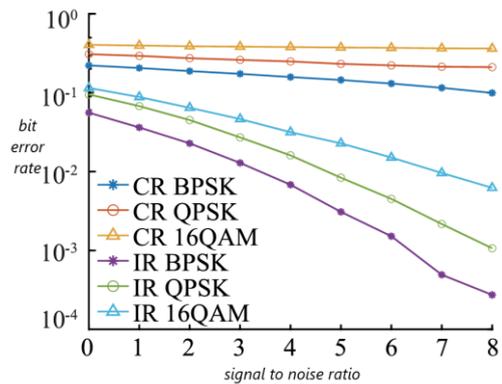


Рис. 9. Сравнение производительности моделей обнаружения сигнала при различных методах модуляции

X. ВЛИЯНИЕ РАЗЛИЧНЫХ МЕТОДОВ КОДИРОВАНИЯ КАНАЛОВ НА ПРОИЗВОДИТЕЛЬНОСТЬ МОДЕЛЕЙ ОБНАРУЖЕНИЯ СИГНАЛОВ

Исходное двоичное число задано равным 256 битам, а в качестве шахтного беспроводного канала используется канал Накагами с коэффициентом замираний $m=0,95$. Передатчик использует режимы модуляции BPSK, QPSK и 16QAM соответственно, а эффективность модели обнаружения сигнала проверяется с помощью (7, 4) циклических кодов и (15, 8) циклических кодов в каждом

режиме модуляции. Результаты моделирования представлены на рис. 10, где (1) обозначает циклический код (7, 4), а (2) – циклический код (15, 8). Наблюдая рис. 10, можно обнаружить, что предложенная ИК-модель превосходит обычный приемник в различных режимах кодирования канала, а ИК-модель имеет более низкий BER в том же режиме модуляции и при том же отношении сигнал/шум. Более подробно, ИК-модель не зависит от кодирования канала для BPSK и QPSK модуляции в одном и том же режиме модуляции. Для модуляции 16QAM производительность приемника ухудшается при изменении метода кодирования. При увеличении порядка модуляции объем информации, передаваемой каждым передаваемым сигналом, возрастает, что затрудняет восстановление исходных двоичных данных. Кроме того, изменения в методе кодирования канала также влияют на производительность приемника. Когда соотношение информационных битов и битов четности меняется, модель должна правильно декодировать в соответствии с новой схемой кодирования и исправлять возникающие ошибки. Это является проблемой для способности модели к декодированию.

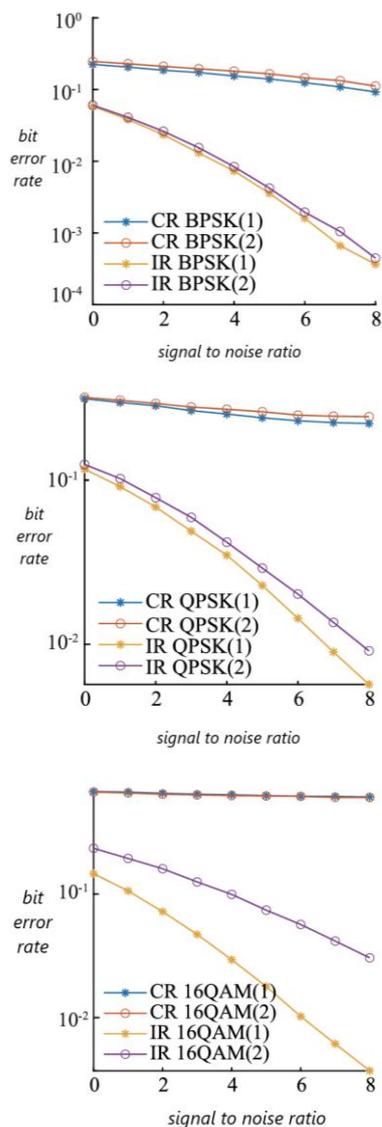


Рис. 10. Сравнение производительности моделей обнаружения сигнала при различных кодировках канала

XI. ЗАКЛЮЧЕНИЕ

В данном исследовании разработана эффективная модель обнаружения сигналов, позволяющая оптимизировать низкую эффективность существующих моделей обнаружения сигналов. Модель состоит из сети нелинейного отображения и сети коррекции ошибок. Сеть нелинейного отображения использует сеть DenseNet для выделения признаков принимаемых сигналов, а сеть коррекции ошибок использует сеть U-net для побитовой корректировки восстановленных данных из сети нелинейного отображения. Экспериментальные результаты показывают, что предложенная модель имеет более низкий BER в моделируемой шахтной MIMO-системе связи. Модель сохраняет высокую точность даже при изменении модуляции и кодирования канала. По сравнению с глубоким приемником, предложенным в литературе, данная модель имеет более высокую эффективность обнаружения. В дальнейшем планируется провести полевые on-line испытания для оценки эффективности разработанной модели обнаружения сигналов в реальных приложениях.

СПИСОК ЛИТЕРАТУРЫ

- [1] Khalifa N E, Loey M, Mirjalili S. A comprehensive survey of recent trends in deep learning for digital images augmentation [J]. Artificial Intelligence Review, 2021:1-27.
- [2] Karnauhov A.M., Kozhubaev Yu.N., Ilin A.E., Ivanov V.V. Controlling of the digital transformation oil and gas industry // XI International Scientific and Practical Conference Innovative Technologies in Environmental Science and Education (ITSE-2023) E3S Web of Conferences. – 2023. V. 431, 05031 <https://doi.org/10.1051/e3sconf/202343105031>. LI Jiangtao, ZHANG Kanghui, SHA Te. Lightweight deep learning model compression strategy for coal foreign object recognition [J]. Coal Engineering, 2023, 55(S1):220-224.
- [3] Shankar V, Parsana S. An overview and empirical comparison of natural language processing (NLP) models and an introduction to and empirical application of autoencoder models in marketing [J]. Journal of the Academy of Marketing Science, 2022:1-27.
- [4] Krotova S.Yu., Remizova I.V., Ovchinnikova E.N., Ilin A.E. Basic methods of developing an expert system to assess the efficiency of power supply networks // Proceedings of International Scientific Conference «Fundamental and Applied Scientific Research in the Development of Agriculture in the Far East» (AFE-2022). E3S Web of Conferences. AFE-2022. 2023. V. 371, 03050. <https://doi.org/10.1051/e3sconf/202337103050>.
- [5] Sun T X, Liu X Y, Qiu X P, et al. Paradigm shift in natural language processing [J]. Machine Intelligence Research, 2022, 19(3):169-183.
- [6] Meera S, Geerthik S. Natural language processing [J]. Artificial Intelligent Techniques for Wireless Communication and Networking, 2022:139-153
- [7] Kozhubaev Yu.N., Ovchinnikova E.N., Krotova S.Yu., Ivanov V.Yu., Ruide Y. Energy efficient indoor wireless communication techniques based on BLE technology // Ural Environmental Science Forum “Sustainable Development of Industrial Region” (UESF-2023). E3S Web of Conferences. 2023. V. 389, 07011. <https://doi.org/10.1051/e3sconf/202338907011>. HU
- [8] NG Yuan, HE Yigang, WU Yuting, et al. Deep learning for compressed sensing based sparse channel estimation in FDD massive MIMO systems [J]. Journal on Communications, 2021, 42(8):61-69
- [9] Muratbakeev E.H., Kozhubaev Y.N., Yao Y., Shehzad U. Symmetrical Modeling of Physical Properties of Flexible Structure of Silicone Materials for Control of Pneumatic Soft Actuators. Symmetry 2024, 16, 750. <https://doi.org/10.3390/sym16060750>. Tekbiryik K, Akbunar Ö, Ekti A R, et al. Spectrum sensing and signal identification with deep learning based on spectral correlation function [J]. IEEE Transactions on Vehicular Technology, 2021, 70(10):10514-10527.

- [10] HOU Zhengjun, YAO Zhi, YANG Tao, et al. Dynamic Spectrum Access for Cognitive Radio with Energy Harvesting Based on Deep Reinforcement Learning [J]. *Radio Communications Technology*, 2023, 49(2):239-247
- [11] Jdid B, Hassan K, Dayoub I, et al. Machine learning based automatic modulation recognition for wireless communications: a comprehensive survey [J]. *IEEE Access*, 2021(9):57851-57873.
- [12] Ovchinnikova E.N., Kozhubaev Y.N., Ivanov V.Y., Pechinskaya L.I. Information Technology in Foreign Language Distance Teaching to Students of Technical Specialties *European Journal of Contemporary Education*. 2023. №12. pp. 948-961. <https://doi.org/10.13187/ejced.2023.3.948>.
- [13] Kozhubaev Yu.N., Ovchinnikova E.N., Krotova S., Ilin A.E., Sabbgan A. Controlling a combined polymer fuel cell and directional battery system maintaining efficiency at the optimum point // *Ural Environmental Science Forum “Sustainable Development of Industrial Region” (UESF-2023)*. E3S Web of Conferences. 2023. V. 389, 02014. <https://doi.org/10.1051/e3sconf/202338902014>.
- [14] Novak D, Kozhubaev Yu., Nikonova E., Pivkina N. Bricolage as an Alternative Way of Solving Educational Problems. *International Journal of Media and Information Literacy* Issued since 2016. 9(2): 401-412. DOI: 10.13187/ijmil.2024.2.401.
- [15] ZHAO Z, Vuran M C, Guo F, et al. Deep-waveform: a learned OFDM receiver based on deep complex-valued convolutional networks [J]. *IEEE Journal on Selected Areas in Communications*, 2021, 39(8):2407-2420