Метод оценки канала на основе самоконтроля обучения для системы прохода через шахты с поддержкой IRS

А. В. Милицын

Санкт-Петербургский политехнический университет Петра Великого militsyn_av@spbstu.ru

А. А. Милицын

Санкт-Петербургский политехнический университет Петра Великого

militsyn.aa@edu.spbstu.ru

Р. В. Ершов

Санкт-Петербургский политехнический университет Петра Великого
Um-urii@mail.ru

Чанвэнь Инь

Санкт-Петербургский политехнический университет Петра Великого

in.ch@edu.spbstu.ru

В. С. Карпухин

Санкт-Петербургский политехнический университет Петра Великого
v.karpukhin@electrosystems.ru

В. В. Потехин

Санкт-Петербургский политехнический университет Петра Великого

slava.potekhin@spbstu.ru

Аннотация. Для решения проблем многолучевых замираний, связи без прямой видимости и сложности получения реальных меток из-за сложной обстановки в шахтах предлагается метод оценки канала с помощью интеллектуальной отражающей поверхности (IRS) на основе самоконтролируемого обучения (SSL) для шахтной системы связи. Модель подземной системы связи строится на основе модели подземного канала с замираниями Накагами-г и модели передачи сигнала IRS, а проблемы многолучевых замираний и отсутствия прямой видимости решаются с помощью метода IRS. Предварительная оценка канала осуществляется алгоритмом наименьших квадратов (LS), а затем результаты оценки канала оптимизируются октавной конволюционной (OCT) нейронной сетью в рамках SSL.

Ключевые слова: связь; оценка каналов; подземные интеллектуальные отражающие поверхности; самоконтролируемое обучение

І. Введение

В шахтных системах связи из-за сложности туннелей характеристики распространения камер электромагнитных волн значительно отличаются от характеристик свободном пространстве, электромагнитные волны часто преломляются, отражаются и дифрагируют. Эти факторы приводят к при распространении большим потерям электромагнитных волн внутри шахты, а эффективное расстояние связи значительно сокращается. проблемы заставляют внедрять подземную беспроводную связь для промышленной эксплуатации. Информация о состоянии канала (CSI) является основой технологии связи и важным показателем для оценки качества работы системы связи. Сложная среда в шахтах увеличивает сложность оценки канала, что делает создание беспроводной системы связи, адаптированной к подземным шахтам, большой проблемой [1].

Алгоритм наименьших квадратов (LS) [2] и алгоритм линейной минимальной среднеквадратичной ошибки

(LMMSE) обычно используются для оценки каналов в Когда средах. разреженность неизвестна, часто используется алгоритм отслеживания положительного совпаления. который эффективно улучшить спектральное использование и точность оценки канала. Технология Intelligent Reflecting Surface (IRS) интеллектуально изменяет конфигурацию среды распространения беспроводной связи путем интеграции большого количества недорогих пассивных отражающих элементов на плоской поверхности, что производительность значительно повышает сетей связи [4-7]. Поскольку IRS беспроводных являются пассивными устройствами, которые не могут активно посылать или принимать сигналы, очень сложно напрямую использовать IRS-устройства для оценки каналов [8-9].

Глубокое обучение обеспечивает низкосложностные и высокопроизводительные решения для оценки каналов с помощью IRS [14–15]. В литературе для решения проблемы оценки каналов в системах связи с поддержкой ИРС используются синтетические глубокие нейронные сети и конволюционные нейронные сети (CNN). Глубокое обучение хорошо справляется с оценкой каналов, но в практических приложениях трудно получить реальные метки для контролируемого обучения. Самоконтролируемое обучение (SSL) может эффективно уменьшить зависимость от искусственных меток. Комбинация SSL и IRS удивительно хорошо работает в направлении канала шахтных систем связи.

II. МЕТОДОЛОГИЧЕСКИ ПРИНЦИПЫ

Общая схема метода оценки канала на основе SSL для шахтной системы связи с поддержкой IRS показана на рис. 1. Модель подземной системы связи строится на основе модели канала с замираниями Накагами-г и модели сигнализации IRS в шахте для создания набора данных, а для имитации помех в реальной среде связи в набор данных добавляется шум. Предварительная оценка канала выполняется с помощью алгоритма LS, а

затем результаты оценки канала оптимизируются с помощью нейронной сети с октавной конверсией (ОСТ) в рамках SSL. Для оценки эффективности оценки канала используется нормализованная средняя квадратическая ошибка (NMSE). Сочетание технологии IRS и метода SSL позволяет решить проблемы многолучевых замираний, отсутствия прямой видимости и сложности получения реальных меток при оценке канала в условиях шахты, что позволяет реализовать высокоточную оценку канала в подземных условиях и повысить качество и надежность связи.

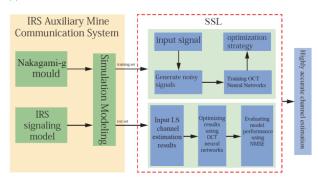


Рис. 1. Общая схема метода оценки канала для системы противоминной связи с использованием разведывательной отражающей поверхности (IRS) на основе самоконтролируемого обучения (SSL)

III. Модель подземной системы связи

А. Накагами-и модель

Из-за сложной подземной среды эффект многолучевости очень значителен, что приводит к большой разнице между подземным беспроводным каналом и внешней средой. Распределение Рэлея подходит для среды с интенсивным рассеянием, но его параметры фиксированы и не могут адаптироваться к изменениям интенсивности различных многолучевых эффектов; распределение Райса подходит для среды с сильными прямыми путями, но плохо работает в шахтной среде без очевидных прямых путей;

Функция плотности вероятности для модели Накагами-г имеет вид:

$$f(a) = \frac{2g^g a^{2g-1}}{\Gamma(g)\Omega} exp\left(-\frac{ga^2}{\Omega}\right) \ a \ge 0$$
 (1)

где а — амплитуда принимаемого многолучевого сигнала; $\Gamma(g)$ — гамма-функция; Ω — средняя мощность.

В. Модель передачи сигналов с использованием интеллектуальных реконфигурируемых поверхностей (IRS)

Предположим, что x_n представляет собой сигнал, падающий на n-й элемент (n=1,2,...,N, где N — количество отражающих элементов IRS) системы IRS, y_n — соответствующий отраженный сигнал, β_n — коэффициент амплитудной регулировки n-го отражающего элемента для падающего сигнала x_n , где $\beta_n \in [0,1]$, φ_n — коэффициент фазовой регулировки n-го отражающего элемента для падающего сигнала x_n , где φ_n $\in [0,2\pi]$. Тогда отраженный сигнал y_n выражается как:

$$y_n = \beta_n exp(j\Phi_n)x_n \tag{2}$$

Путём изменения коэффициента регулировки амплитуды и фазового коэффициента отражающего элемента через контроллер можно управлять амплитудой фазой входящего сигнала данным элементом отражающей поверхности (IRS). Модель передачи сигнала через IRS изображена на рис. 2. Когда поверхность IRS отсутствует, передача ослаблена из-за препятствий между пользователем и базовой станцией. При использовании IRS сигнал может передаваться через промежуточный этап прохождения через IRS, таким образом обходя влияние препятствий на передачу сигнала.

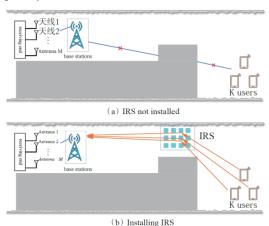


Рис. 2. Модель передачи сигнала IRS

Учитывая, что базовая станция и поверхность с управляемым рассеянием радиоволн (IRS) используют одну антенну и планарную массивную решётку для обслуживания одного антенного пользователя одновременно, и предполагая, что канал от IRS к базовой станции представляет собой матрицу модели канала, получаем следующее выражение для модели канала.

$$G = \sqrt{\frac{^{MN}}{L}} \sum_{l_1=1}^{L} a_{l_1} \, b(\vartheta_r, l_1, \psi_r, l_1) c^T(\vartheta_r, l_1, \psi_r, l_1) \quad (3)$$
 где L обозначает количество путей распространения

где L обозначает количество путей распространения сигнала между IRS и базовой станцией; a_l — затухание сигнала на l-ом пути; b — функция отклика массива антенн в направлении принимаемого сигнала на базовой станции; $\vartheta r, l_1$ — коэффициент усиления или потерь сигнала, достигающего базовой станции после отражения; $\psi r, l_1$ — азимут сигнала на базовой станции; c — функция отклика массива антенн в направлении отражённого сигнала на IRS; $\vartheta t, l_1$ — коэффициент усиления или потерь сигнала, достигающего IRS; $\psi t, l_1$ — азимут сигнала на IRS. Индекс l_1 обозначает номер пути распространения сигнала.

Канал между IRS и пользователем может быть представлен следующим образом:

$$h_k = \sqrt{\frac{N}{L_k}} \sum_{l_2=1}^{L_k} a_k, l_2(\vartheta_r, l_1, \psi_r, l_1)$$
 (4)

Где: lk — количество путей распространения сигнала между k-м (k=1,2,...,K) пользователем и IRS; α_{kl_2} — усиление сигнала на первом приходящем пути l_2 у k-го пользователя.

Сигнал, принятый в p-й (p=1,2,...,P, где P – общее число субкадров) субкадре узла базовой станции, может быть представлен следующим образом

$$Y_p \triangleq \sum_{k=1}^K H_k \, \Phi_p \, X_p + W_p \tag{5}$$

где: Hk — каскадный канал размером $M \times N$ для k-го пользователя; Φp — матрица фазового сдвига IRS для p-го кадра; Xp — вектор переданного сигнала; Wp — аддитивный гауссовский белый шум.

На основании ортогональности последовательности направляющей частоты принятый сигнал Yp может быть преобразован в вектор принятого сигнала для k-го пользователя:

$$Y_k = H_k \Phi_p X_p + \nu_p \tag{6}$$

где *vk* – вектор шума.

Во время фазы обучения оригинальный принятый сигнал Yk используется для генерации сигнала с наложением шума и подается на вход нейронной сети для тренировки. Для оценки Hk.

$$H_{LS} = Y_k Q^H (QQ^H)^{-1} (7)$$

где: HLS — оценка канала, полученная с помощью оценщика методом наименьших квадратов (Least Squares, LS); Q — матрица различных схем отражения. Однако алгоритм LS рассматривает канал как определенную, но неизвестную константу и не учитывает пространственные характеристики канала. Поэтому в данной работе используется нейронная сеть ОСТ для оптимизации результатов оценки методом LS.

IV. НЕЙРОННЫЕ СЕТИ ОСТ В РАМКАХ АРХИТЕКТУРЫ SSL

А. Проектирование нейронной сети ОСТ

Основная идея ОСТ заключается в прямой обработке как высокочастотных, так и низкочастотных компонентов. Низкочастотный компонент захватывает основные тренды и вариации, а высокочастотный компонент детально отображает нюансы, такие как края и мутации, которые могут быть утрачены при традиционной свёртке. ОСТ захватывает как грубые признаки, так и тонкости канала, предоставляя комплексную информацию о канале, что обеспечивает более точную оценку состояния канала.

Нейронная сеть ОСТ состоит из двух подсетевых модулей h1 и h2, каждый из которых содержит несколько свёрточных слоёв, каждый из которых оснащён функцией активации ReLU и нормализацией батча (Batch Normalization, BN), как показано на рис. 3.

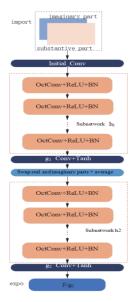


Рис. 3. Структура нейронной сети октавной свертки (ОСТ)

Функция активашии ReLU увеличивает выразительные способности модели, вводя нелинейности, в то время как BN ускоряет обучение и улучшает стабильность и обобщающие свойства модели. Каждый подсеть-модуль сопровождается остаточными модулями g1 и g2, которые используют функцию активации Tanh и служат главным образом для того, чтобы позволить сети изучать более сложные признаки и сглаживать выходной сигнал сети, где слой свертки отвечает за извлечение признаков.

Комплексная матрица A разлагается на два канала с действительными и мнимыми частями и используется в качестве входа в нейронную сеть ОСТ: $Y = [Re\ \{A\}, Im\ \{A\}]Y = [Re\ \{A\}, Im\{A\}]$. Чтобы сеть могла в полной мере использовать глобальную информацию оригинальной матрицы AA, каналы подвергаются линейному преобразованию, а действительные и мнимые части YY меняются местами, чтобы получить $Y_U = [Im\ \{A\}, Re\ \{A\}]YU = [Im\ \{A\}, Re\ \{A\}]$, который усредняется с выходом первого остаточного модуля.

Выход второго остаточного модуля вычитается из оригинального ввода, чтобы получить конечный выход. Нейронная сеть ОСТ использует только сверточные слои вместо полносвязных, что уменьшает количество параметров и снижает накладные расходы сети. Параметры нейронной сети ОСТ показаны в табл. 1. Initial_Conv — это первый сверточный слой, в котором нейронная сеть обрабатывает входные данные и используется для расширения числа каналов входных данных до необходимого количества каналов, требуемого сетью.

ТАБЛИЦА І. ПАРАМЕТРЫ НЕЙРОННОЙ СЕТИ ОСТ

Layer type	Number of output channels	Convolution kernel size
Initial_Conv	128	(3, 3)
OctConv	32	(3, 3)
BN	64	-
Residual module(Cony)	64	(3, 3)

В. Реализация алгоритма SSL

В практических приложениях незапятнанные данные легче получить, чем помеченные. SSL способен использовать большое количество непомеченных данных для создания учебных образцов путем генерации сигналов с наложением шума для эффективной тренировки модели. Из-за сложности горнодобывающей обстановки очень трудно получить реальную CSI в виде меток. В этой статье мы предлагаем метод SSL, чтобы избежать зависимости от реальных меток, используя принятые сигналы и их зашумленные версии в качестве учебных данных.

SSL делится на две части: обучение и тестирование, как показано на рис. 4. Входом фазы обучения является зашумленный сигнал $Y + \varepsilon$, а выходом - очищенный сигнал \dot{Y} . Нейронная сеть обучается путем минимизации потерь между принятым сигналом и его зашумленной версией. Входом фазы тестирования является предварительный результат оценки канала с помощью оценщика LS, а выходом - оптимизированный результат оценки канала IRS с помощью нейронной сети ОСТ \dot{H} .

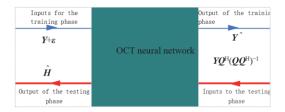


Рис. 4. Структура нейронной сети октавной свертки (ОСТ)

Суть метода SSL заключается в автоматической генерации помеченных данных путем проектирования предшествующих задач, которые сильно коррелируют с оценкой канала. Предварительная задача в данной работе заключается в очистке принятого сигнала от шума.

В фазе обучения сигнал Y получается из модели коммуникационной системы, а шум ϵ генерируется из заранее определенного распределения шума, которым обычно является гауссовский шум. Шум ϵ добавляется к сигналу Y, чтобы получить $Y+\epsilon$. Тренировочный набор данных состоит из оригинального сигнала Y и его зашумленной версии $Y+\epsilon$.

Этапы тренировки модели:

- **Ввод:** Сигнал $Y + \epsilon$. Соответствующая метка это оригинальный принятый сигнал без помех.
- Обновление параметров: Использует стохастический градиентный спуск вместе с подходящей скоростью обучения для итерационного обновления параметров сети.
- **Итерации:** Весь процесс тренировки разбит на несколько циклов, каждый цикл обрабатывает небольшие партии данных.
- Инъекция шума: На каждой итерации в данные вводится новый шум, чтобы усилить обобщающую способность и устойчивость модели.
- Оценка потерь: В качестве функции потерь используется среднеквадратичная ошибка для

оценки отклонения выходных данных модели от меток.

Этапы тестирования модели:

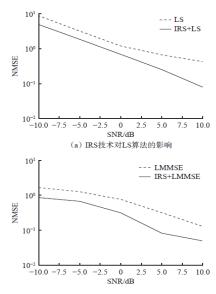
- Закрепление модели: По завершении тренировки параметры модели фиксируются и не будут обновляться.
- **Ввод данных:** Предварительные результаты оценки канала, полученные с помощью алгоритма наименьших квадратов (LS).
- Очистка: Итерационный процесс, в котором используется нейронная сеть ОСТ для дополнительной оптимизации результатов оценки LS и получения итоговых результатов оценки канала

V. Анализ моделирования

Для проведения моделирования использовались языки программирования MATLAB и Python. Набор данных канала системы подземной связи с поддержкой IRS был сгенерирован в среде MATLAB 2022a, всего было создано 96 000 данных, которые были разделены на обучающее множество и тестовое множество в соотношении 4:1. Параметры моделирования были образом: vстановлены следующим количество рефлекторных элементов IRS равно 64, количество антенн базовой станции составляет 16, количество пользователей – 6, отношение сигнал-шум (SNR) варьируется от -10 до 10 дБ с шагом 1 дБ, а модель замирания беспроводного канала шахты – канал Накагами-м.

А. Влияние технологий IRS на оценку канала

Чтобы подтвердить эффект воздействия IRS на оценку подземного канала, алгоритмы LS и LMMSE были использованы для оценки канала в среде с IRS и без нее соответственно, и результаты представлены на рис. 5. Моделирование показало, что внедрение технологии IRS способно эффективно снизить ошибку оценки канала как в алгоритме LS, так и в алгоритме LMMSE.



Puc. 5. Сравнение производительности алгоритмов до и после внедрения технологии IRS

В. Проверка производительности нейронной сети ОСТ

Для проверки производительности нейронной сети ОСТ проанализированы потери при обучении, время выполнения и количество параметров.

Отношение сигнал/шум (SNR) установлено равным 0, и обе нейронные сети, ОСТ и традиционный CNN, обучались течение 100 циклов. Результаты В представлены на рис. 6. Как видно из графика, с увеличением количества циклов обучения скорость сходимости обеих нейронных сетей увеличивается. При этом значение потерь у нейронной сети ОСТ заметно ниже, чем у обычного CNN, что свидетельствует о лучшей аппроксимации данных ОСТ-сеткой при условиях обучения одинаковых И большей эффективности в обработке тренировочных данных.

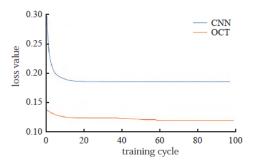


Рис. 6. Сравнение производительности алгоритмов до и после внедрения технологии IRS

Результаты моделирования демонстрируют, что нейронная сеть ОСТ обладает высокой вычислительной эффективностью и способна улучшить общую производительность оценки канала для систем связи.

VI. ЗАКЛЮЧЕНИЕ

В комбинации с технологией IRS построена модель системы беспроводной связи для шахт, что решает проблему многолучевого затухания и отсутствия прямой видимости.

Использование нейронной сети ОСТ в рамках архитектуры SSL позволило оптимизировать предварительные результаты оценки канала, что устраняет проблему труднодоступности реальных меток в условиях шахты и повышает точность оценки канала.

Результаты моделирования показывают, что:

- (1) Внедрение технологии IRS может эффективно уменьшить погрешность оценки канала.
- (2) Значение потерь у нейронной сети ОСТ значительно ниже, чем у CNN, а эффект аппроксимации данных лучше; вычислительная эффективность ОСТ-сети высока, что позволяет улучшить общую производительность оценки канала в системе связи; в условиях ограниченных вычислительных ресурсов ОСТ-сеть поддерживает низкое количество параметров и потребление памяти.

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.
- [3] 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.
- [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] 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.
- [7] Ma X, Gao Z, Gao F, et al. Model-driven deep learning based channel estimation and feedback for millimeter-wave massive hybrid MIMO systems [J]. IEEE Journal on Selected Areas in Communications, 2021, 39(8): 2388-2406
- [8] Nguyen L V, Swindlehurst A L, Nguyen D H N. SVM based channel estimation and data detection for one-bit massive MIMO systems [J]. IEEE Transactions on Signal Processing, 2021,69:2086-2099
- [9] Tekbıyık 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] 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.
- [11] Ovchinnikova Elena 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.
- [12] Njoku J N, Morocho-Cayamcela M E, Lim W. CGDNet: efficient hybrid deep learning model for robust automatic modulation recognition [J]. IEEE Networking Letters, 2021, 3(2):47-51
- [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] Sayedi, H. (2018). Real-time bidding in computational advertising: A review of the literature. Journal of Interactive Advertising, 18(1), 45-59. DOI: 10.1080/15248476.2018.1448485