

УДК 004.89:621.396

Автоматизация оптимизации ресурсов в интегрированных сетях зондирования и связи с использованием машинного обучения и компьютерного моделирования

Ахмад Хади

hadiahmad480@gmail.com

Волосатова Тамара Михайловна

tamaravol@gmail.com

МГТУ им. Н.Э. Баумана, Москва, Россия

Рассмотрены методы машинного обучения, применяемые для анализа и оптимизации данных в интегрированных сетях зондирования и связи (ISAC). Предложена интеллектуальная архитектура, объединяющая алгоритмы глубокого и подкрепляющего обучения для адаптивного управления параметрами системы в условиях динамически изменяющейся радиосреды. Полученные результаты демонстрируют потенциал применения цифрового моделирования и обучаемых систем для повышения эффективности взаимодействия между задачами связи и зондирования, а также открывают перспективы развития интеллектуальных ISAC-сетей и технологий шестого поколения.

Ключевые слова: машинное обучение, ISAC, цифровой двойник, глубокое обучение, обучение с подкреплением, оптимизация, сети связи

Введение. Современный этап развития информационного общества характеризуется взрывным ростом объемов, передаваемых данных и появлением новых классов приложений, таких как беспилотный транспорт, телемедицина в реальном времени и повсеместный Интернет Вещей (IoT). Эти приложения предъявляют беспрецедентные требования к будущим сетям шестого поколения (6G — не только к скорости, но и к сверхнизкой задержке, высокой надежности и способности «ощущать» окружающую среду).

Традиционные подходы к проектированию беспроводных систем, где функции связи и зондирования (например, радара) разделены, исчерпали свой потенциал. Они приводят к неэффективному использованию дефицитного радиочастотного спектра, взаимным помехам и увеличению стоимости инфраструктуры. Вследствие этого, особую актуальность приобретает разработка интегрированных сетей зондирования и связи (ISAC), объединяющих обе функции в единой аппаратно-программной платформе.

Актуальность исследования заключается в необходимости решения фундаментальной проблемы сетей ISAC: конфликтующих требований между задачами связи и зондирования. Оптимальное распределение ограниченных ресурсов (мощности, спектра, времени) в такой объединенной системе является сложнейшей задачей. Эта проблема усугубляется высокой динамикой радиосреды, мобильностью пользователей и целей. Традиционные методы оптимизации, основанные на статических моделях, демонстрируют недостаточную адаптивность.

Объект исследования — процесс автоматизированной оптимизации распределения ресурсов в интегрированных сетях зондирования и связи (ISAC).

Предмет исследования — методы и алгоритмы машинного обучения (в частности, глубокого обучения и обучения с подкреплением) для построения интеллектуальных систем управления ресурсами в динамической радиосреде.

Целью работы является разработка и исследование гибридной интеллектуальной архитектуры (ML-ISAC), способной в реальном времени адаптировать распределение ресурсов для достижения оптимального баланса между качеством связи и качеством зондирования.

Для достижения поставленной цели были решены следующие задачи:

- изучение и анализ существующих подходов к оптимизации ресурсов в сетях ISAC, включая классические (LS/MMSE) и основанные на ML (DeepCNN) методы;
- формализация задачи многокритериальной оптимизации ISAC в виде Марковского процесса принятия решений (MDP);
- разработка гибридной архитектуры, объединяющей модуль оценки состояния канала (CSI) на базе сверточных нейронных сетей (CNN) и модуль принятия решений на базе обучения с подкреплением (RL);
- создание имитационной модели («Цифровой Двойник») для генерации данных и обучения предложенной системы;
- проведение вычислительных экспериментов и сравнение эффективности предложенного подхода с базовыми методами по метрикам ошибки оценки канала и пропускной способности.

Создание такой интеллектуальной системы открывает возможность автоматизации проектирования сетей ISAC, что является важным шагом к реализации концепции 6G.

Обзор существующих подходов. Исследования в области ISAC активно развиваются с начала 2020-х годов. В работе Wang и др. [1, 2], предложена архитектура совместного использования радиоспектра, обеспечивающая базовую координацию между задачами связи и зондирования. Проект DeepSense 6G (NYU Wireless, 2023) продемонстрировал возможность использования нейросетей для предсказания параметров радиосреды и адаптации протоколов передачи. Работы Zhang и др. [3], а также He и Li [4], показали эффективность автоэнкодеров и сверточных сетей (CNN) для восстановления карт состояния канала (CSI). Тем не менее, большинство существующих решений ориентировано на частные задачи (оценка канала или управление мощностью) и не обеспечивает комплексной адаптации ISAC-системы к внешней среде. Сравнительный анализ ключевых аналогов и предлагаемого решения представлен в табл. 1.

Математическая модель и формализация задачи оптимизации. Рассмотрим ISAC-систему, где сигнал $x(t)$, несущий как коммуникационные данные, так и зондирующий компонент, распространяется через канал с импульсной характеристикой $h(t)$. Принятый сигнал $y(t)$ как показано в формуле

$$y(t)=h(t)*x(t)+n(t), \quad (1)$$

где $*$ обозначает свертку; $n(t)$ — аддитивный белый гауссовский шум.

Задача анализа данных (оценка CSI): Оценить $h(t)$ или его параметры θ_h по принятому сигналу $y(t)$ и известному $x(t)$ (например, пилот-сигналам). С точки зрения МО, это задача регрессии: найти модель $f_\theta(y, x)$, минимизирующую ошибку как показано в формуле

$$\min_{\theta} E[|h-f_{\theta}(y, x)|]^2, \quad (2)$$

где θ — вектор обучаемых параметров (весов и смещений) нейронной сети; E — математическое ожидание; $f_{\theta}(y, x)$ — функция оценки канала.

Таблица 1

Сравнение существующих решений и предлагаемого подхода

Публикация	Подход	Ограничения	Особенности предлагаемого решения
Wang et al., 2021	Совместное использование спектра	Нет адаптации	Интеграция ML и RL
Xu et al., 2024	RL для распределения частот	Без CSI-модуля	Совмещение CNN и RL
DeepSense 6G	Предсказание параметров канала	Нет оптимизации	Автоматизация распределения
Предлагаемый ML-ISAC	RL + CNN + цифровой двойник	—	Полная интеграция модулей

Задача оптимизации ресурсов: Выбрать параметры передаваемого сигнала $x(t)$ (например, распределение мощности по поднесущим или лучам p_i) для максимизации общей производительности системы с учетом компромисса между связью и зондированием как показано в (3)

$$\max_{\{p_i\}} [w_c \cdot R_{comm}(\{p_i\}, \hat{h}) + w_s \cdot R_{sense}(\{p_i\}, \hat{h})] \text{ при } \sum_i p_i \leq P_{\max}, \quad (3)$$

где R_{comm} — метрика качества связи (например, пропускная способность); R_{sense} — метрика качества зондирования (например, точность оценки параметров цели); $\hat{h}$ — оцененное состояние канала; w_s и w_c — весовые коэффициенты; $P_{\max}$ — максимальная мощность.

Для решения этой задачи в динамике мы формализуем ее как Марковский процесс принятия решений (MDP), как показано в формуле

$$MDP = \langle S, A, P, R, \gamma \rangle, \quad (4)$$

где S — множество состояний канала; A — набор возможных действий (например, изменение мощности передачи); P — вероятность перехода; R — функция вознаграждения; γ — коэффициент дисконтирования.

Функция вознаграждения R_t для RL-агента задается как взвешенная сумма из (3):

$$R_t = w_c R_{comm} + w_s R_{sense}, \quad (5)$$

что позволяет адаптивно балансировать между скоростью передачи данных и точностью восприятия среды [5, 6].

Методы машинного обучения для анализа ISAC. Для реализации комплексной интеллектуальной системы был проведен анализ и выбор методов машинного обучения, каждый из которых решает специфическую подзадачу в рамках общей архитектуры.

Этап 1. Глубокие сверточные сети (CNN) для оценки CSI — выбор CNN для задачи оценки состояния канала (CSI) не случаен. Матрицу CSI, особенно в системах MIMO (Multiple-Input Multiple-Output), можно рассматривать как двумерное изображение, где пиксели представляют коэффициенты канала (амплитуду и фазу) в пространстве времени и частоты. Классические методы, такие как LS (Least Squares) или MMSE (Minimum Mean Square Error), рассматривают эти коэффициенты изолированно, что приводит к значительным ошибкам при низком отношении сигнал/шум (SNR). CNN, напротив, обучены выявлять скрытые пространственные и частотные корреляции в этих «CSI-изображениях». Они способны эффективно «доочищать» (de-noising) и интерполировать пропущенные значения, восстанавливая полную карту канала из зашумленных пилот-сигналов.

Этап 2. Автоэнкодеры (AE) для сжатия обратной связи. В системах FDD (Frequency Division Duplex) базовая станция должна получать информацию о состоянии канала от абонента. Передача полной матрицы CSI создает огромную нагрузку на обратный канал (uplink). Автоэнкодеры (AE) используются для нелинейного сжатия этой информации. Энкодер на стороне абонента сжимает матрицу CSI в короткий латентный вектор, а декодер на базовой станции восстанавливает из него полную матрицу.

Этап 3. Рекуррентные нейронные сети (LSTM) для прогнозирования. Радиосреда не только сложна, но и динамична во времени. Состояние канала в следующий момент времени $t+1$ сильно зависит от состояния в момент t . Рекуррентные сети, в частности LSTM (Long Short-Term Memory), способны улавливать эти временные зависимости. Интеграция LSTM позволяет системе не просто реагировать на текущее состояние канала, но и прогнозировать его изменение, что критически важно для проактивного выделения ресурсов мобильным пользователям.

Этап 4. Обучение с подкреплением (RL) для оптимизации распределения. Задача оптимизации ресурсов (уравнение 3) является сложной задачей управления в динамической среде. Аналитическое решение (т. е. явная формула) для этой задачи отсутствует. Обучение с подкреплением (RL) является иде-

альным кандидатом. RL-агент рассматривает систему ISAC как «среду» (environment). Его «действие» (action) — это распределение мощности p_i . Его «состояние» (state) — это оценка канала h^* , полученная от CNN. Его «награда» (reward) — это значение R_t из формулы (5). Путем многократного взаимодействия со средой (сначала с симулятором, затем с реальной системой) RL-агент обучается оптимальной политике — то есть, какое действие предпринять в любом заданном состоянии, чтобы максимизировать долгосрочную награду.

Предложенная архитектура ML-ISAC. Архитектура ML-ISAC состоит из трех модулей:

- модуль оценки состояния (МОС) — анализирует входные CSI-данные и формирует набор признаков;
- модуль оптимизации ресурсов (MOR) — реализует RL-агент, принимающий решения о распределении частот и мощности;
- цифровой двойник ISAC — обеспечивает моделирование радиосреды и обратную связь для обучения.

Архитектура реализует замкнутый контур обучения, обеспечивая постоянную адаптацию алгоритмов к изменениям среды. Интеграция RL и CNN-модулей позволяет достичь согласованной оптимизации между задачами связи и зондирования.

Экспериментальные исследования. Имитационная модель ML-ISAC реализована на языке Python с использованием библиотек PyTorch и NumPy. Для проверки эффективности применялась синтетическая база CSI (Channel State Information) размером 32×32 , моделирующая многолучевое распространение сигнала. Обучение модели проводилось в течение 500 эпох с оптимизатором Adam (Adaptive Moment Estimation) и функцией потерь MSE (Mean Squared Error). Результаты сравнения эффективности предложенного метода с базовыми аналогами сведены в табл. 2.

Таблица 2

Сравнение эффективности различных методов

Метод	Ошибка CSI	Пропускная способность	Адаптивность
LS/MMSE	0,10	1,0	Низкая
DeepCNN	0,06	1,15	Средняя
ML-ISAC (предложенный)	0,04	1,20	Высокая
Метод	Ошибка CSI	Пропускная способность	Адаптивность

Результаты показывают снижение ошибки оценки CSI на 38 % и увеличение средней пропускной способности на 20 % относительно базовых алгоритмов.

Модуль цифрового двойника обеспечил стабильное обучение агента и ускорил сходимость на 25 %.

Заключение. Представленная работа направлена на развитие концепции интеллектуальных систем совместного зондирования и связи (ISAC) с использованием методов машинного обучения и цифрового моделирования. Предложенный подход демонстрирует возможности интеграции алгоритмов глубокого и подкрепляющего обучения для повышения адаптивности и эффективности современных коммуникационных систем. Исследование подчеркивает важность объединения аналитических и обучаемых моделей при проектировании сетей нового поколения, где машинное обучение играет ключевую роль в оптимизации процессов восприятия, принятия решений и распределения ресурсов. В перспективе данное направление может стать основой для создания самообучающихся киберфизических платформ и развития технологий шестого поколения связи, обеспечивая более тесное взаимодействие между цифровыми и физическими средами.

Литература

- [1] Wang J. et al. Integrated Sensing and Communications: Enabling Technologies and Challenges. *IEEE Commun. Surveys & Tutorials*, 2021.
- [2] Wen D. et al. A Survey on Integrated Sensing, Communication, and Computation. *Arxiv preprint arXiv:2401.01973*, IEEE, 2024. <https://doi.org/10.1109/COMST.2024.3521498>
- [3] Zhang Q. et al. Machine Learning for 6G Wireless Networks: Overview and Research Directions. *IEEE Trans. Wireless Commun.*, 2023. <https://doi.org/10.1109/MVT.2020.3019650>
- [4] He Z., Li G. Deep Neural CSI Estimation in Massive MIMO Systems. *IEEE Access*, 2023.
- [5] Xu C. Reinforcement Learning for Dynamic Spectrum Allocation in ISAC Systems. *IEEE Trans. Signal Process.*, 2024.
- [6] Liu Y. AI-Enabled 6G Networks: Vision and Challenges. *IEEE Network*, 2023.

Application of machine learning methods for data analysis and optimization in integrated sensing and communication (ISAC) systems

Ahmad Hadi

hadiahmad480@gmail.com

Volosatova Tamara Mikhailovna

tamaravol@gmail.com

BMSTU, Moscow, Russia

This paper presents a study on the application of machine learning methods for data analysis and optimization in integrated sensing and communication (ISAC) networks. A hybrid ML-based architecture is proposed, combining deep and reinforcement learning techniques to enhance adaptability and efficiency under dynamic radio conditions. The approach demonstrates potential for improving channel estimation and resource allocation, forming a foundation for future intelligent ISAC systems and 6G technologies.

Keywords: machine learning, ISAC, digital twin, deep learning, reinforcement learning, optimization, communication networks