

ИЗСЛЕДВАНЕ НА МОДЕЛ НА БЕЗЖИЧЕН КАНАЛ ЗА ВРЪЗКА С ИНТЕГРИРАН ИНТЕЛИГЕНТЕН АЛГОРИТЪМ ЗА ПОТИСКАНЕ НА СМУЩЕНИЯТА

Михаил Ангелакис

*Технически университет - Габрово, ул. Х. Димитър 4, Габрово, България
кореспондиращ автор: michalis.agelakis@gmail.com*

RESEARCH ON A WIRELESS COMMUNICATION CHANNEL MODEL WITH AN INTEGRATED INTELLIGENT INTERFERENCE SUPPRESSION ALGORITHM

Mihail Angelakis

*Technical University of Gabrovo, 4 H. Dimitar str., Gabrovo, Bulgaria
Corresponding author: michalis.agelakis@gmail.com*

Abstract

The paper discusses the design of a wireless channel model using a pre-trained AI implementation approach on large-scale wireless channel state datasets. The model training aims to analyze the universal characteristics of wireless channels, which can be applied to a wide range of tasks related to wireless communications - ray behavior prediction, channel condition prediction, localization, etc. The emphasis is on the proposed improved model architecture with the ability to suppress noise plus interference distortions in wireless communication channels.

Keywords: wireless channel; channel modelling; prediction model; interference suppression.

ВЪВЕДЕНИЕ

Бъдещата 6G мрежа се характеризира с интеграция на комуникации, сензори и изкуствен интелект. В сравнение с 2G~5G мрежите, които са ориентирани към свързаност, 6G се очаква да предоставя разнообразни услуги в широк спектър от сценарии. Освен това се налагат строги изисквания по отношение на надеждността, забавянето, пропускателната способност и т.н. [1-4]

Изпълнението на гореспоменатите 6G визии зависи до голяма степен от наличието на точни познания за състоянието на безжичния канал за връзка. Получаването на информация за състоянието на канала (CSI – Channel State Information)

може да изисква обмяна на голям обем от служебна информация в бъдещите 6G мрежи поради използването на множество антени, по-широки честотни ленти и високата мобилност на потребителските устройства (UE – User Equipment) [5,6]. Следователно, получаването на точно и универсално представяне на канала с ограничена служебна информация се очертава като основно и критично предизвикателство при проектирането на физическия слой на 6G мрежите. Въз основа на съществуващите проучвания могат да бъдат идентифицирани три типични категории потенциални подходи като възможни насоки за справяне с това предизвикателство [5-8].

Първият тип включва традиционните методи за определяне на CSI, базирани на модели. По-конкретно се използват специални пилотни сигнали първо за оценка на CSI върху някои специфични ресурсни елементи (RE), а след това се прилагат техники за интерполация или екстраполация на канали, за да се изведат CSI на други RE или за бъдещи моменти [5]. Независимо че този подход е широко възприет в съвременните клетъчни системи, той разчита на точни априорни предположения за модела на канала (напр. пространствено-времева-честотна корелация, разпределение на шума и стационарност), което го прави по своята същност чувствителен към несъответствия в модела. Трудно е да се установи точен и универсален модел на канала, като по този начин значително се влошава производителността на метода, базиран на модели.

Вторият клас подходи се основават на дълбоко обучение. В тази парадигма известните пилотни сигнали, заедно със съответните им получени сигнали, се подават в невронна мрежа, за да се извлекат характеристиките на канала по начин, управляван от данни [7]. Този метод използва дълбоки невронни мрежи, за да изучи присъщите характеристики на безжичните канали, без да разчита на предварителни познания за модела на канала, и е демонстрирал висока производителност по отношение на точността на оценка на канала и прогнозиране в сравнение с традиционните алтернативи [6,8,9]. Въпреки това, възприетите модели на изкуствен интелект и извлечените от тях представяния на каналите обикновено са специфични за задачите и сценариите, което има ограничени възможности за обобщаване към нови задачи или сценарии.

Базирани на големите езикови модели (LLM – Large Language Model), подходите от третия тип целят изграждането на основни модели за представяне на безжични канали, за да се даде възможност за множество задачи на физическия

слой. Основните модели са предварително обучени върху големи набори от данни за безжични канали по начин, независим от задачите, което им дава големи възможности за обобщаване в различни задачи и сценарии [10-13].

Независимо от това, че методите, базирани на LLM, са демонстрирали изключителна производителност при задачи за комуникация на физическия слой, всички съществуващи разработки използват перфектни CSI като входни данни за обучение на модела. В практическите безжични системи, където е внедрен моделът, е невъзможно да се получат перфектните CSI. Вместо това е необходимо да се извърши оценка на канала, за да се получи оцененият CSI от известните пилотни сигнали и свързаните с тях получени аналози. Практическите безжични системи обикновено работят в отворени среди, където предаването на сигнали е подложено на неизвестни смущения и шумове, което води до неизбежни грешки при оценката на канала. Въз основа на тези грешни CSI като входни данни, големият AI модел ще изведе „пристрастен“ представяния на характеристиките, които не съответстват на реалистичното състояние на канала. Следователно, производителността на задачите, които се реализират въз основа на тези представяния на характеристиките, ще бъде значително компрометирана.


За справяне с гореспоменатите предизвикателства тук се разглежда приложението и изследването на архитектура на модел за безжични канали с вградена възможност за потискане на шума и смущенията (NI – Noise & Interference) [14]. В представения дизайн, грубите оценки на каналите първо се получават с помощта на класически алгоритми, като например метода на най-малките квадрати (LS), след което се прилагат два проекционни модула за извличане на NI компонентите съответно в подпространството на канала и неговото ортогонално подпространство. След това се използва мрежа за оценка на NI, който ще бъде

допълнително изваден от получените сигнали. Накрая се използва мрежа за прецизиране и допълване на канала, за да се формира по-чиста версия на оценката на канала, която се подава в екстрактор на параметрите на канала, за да се получи представянето на канала. Модулът за потискане на NI може да бъде обучен независимо или съвместно с екстрактора на параметрите на гръбначната мрежа. И в двата случая, изходните представяния на каналите са в състояние да отразяват характеристиките на безжичните канали по-точно. Както ще бъде показано чрез симулации, моделът на безжични канали с използваната структура за потискане на NI постига подобрена производителност в сравнение със задачата за прогнозиране на канали.

ИЗЛОЖЕНИЕ

А. Структура на системния модел

Както е показано на фиг. 1, разглежда се модел на безжична мрежа, който се състои от модул за потискане на NI, модул за CSI корекция и позиционно кодиране и няколко блока на преобразуващ енкодер. Модулът за потискане на NI се използва за получаване на чиста стойност на оценените CSI от пилотните сигнали и съответните им приети сигнали. Предаването на пилотните сигнали може да бъде подложено на силни смущения и шумове в канала, което води до изкривяване на приетия сигнал. Модулът за CSI корекция и позиционно кодиране кодира CSI семплите в порции, които се обработват допълнително от блокове на преобразуващия енкодер. Той откриват присъщите взаимовръзки и контекстуални модели в данните и извеждат универсално представяне на канала, което е подходящо за различни задачи в даунлинк канала. Модулът за потискане на NI е базиран на [14], а другите модули са възприети от съществуващите модели на безжични канали в литературата (като напр. [13]).



Фиг. 1. Модел на безжичен канал със структура за потискане на шума и смущенията


Разглежда се MIMO-OFDM комуникационна система с N предавателни антени и M приемачи антени. Всеки слот се състои от L OFDM символа, като всеки от тях съдържа K подносещи честоти. По този начин, безжичният канал за дадена продължителност на символа и подносеща честота е $M \times N$. Сред $L \times K$ RE-елементи, за всеки слот се приема, че пилотните RE са заети от пилотни сигнали и се използват за оценка на каналите, а останалите RE (наричани информационни RE) се използват за доставяне на потребителски данни.

Въз основа на известните пилотни сигнали и свързаните с тях получени еквиваленти, първо се прилага LS алгоритъмът, за да се формира първоначална оценка на CSI върху пилотните RE. След това се изгражда мрежа за прецизиране на CSI, за да се генерират CSI във всички RE. С контролирано обучение, мрежата за прецизиране на CSI е в състояние да предложи имплицитна способност за потискане на NI, като по този начин се благоприятства последващата обработка.

За да се възстанови NI по-точно, се въвежда мрежа за оценка на NI. Тази

мрежата използва като входни параметри системната стойност на SINR и NI.

SINR изчислителния модул се използва за оценка на средния SINR за всеки слот. Оцененият SINR позволява на мрежата за оценка на NI да научи „нивото на изкривявания“ за средата, като по този начин улеснява оценката на NI. SINR-модулът използва като входни данни получените сигнални символи на всеки слот и свързаните с тях модулационни формати. В практическите комуникационни системи, модулационните формати обикновено са известни както за предавателя, така и за приемника.



Фиг. 2. Сравнение на диаграмите на съзвездията на сигналите за случаи на висока (а) и ниска (б) стойност на SINR


Както е показано на фиг. 2 за QPSK модулация, в диаграмата на съзвездията се наблюдава значителна вариация в зависимост от SINR. При висок SINR, разпределението на приетите състояния на сигнала се оформя главно от коефициентите на канала по подносещи честоти, времевите моменти и приемните антени, образувайки ясна структура на съзвездията. За разлика от това, при нисък SINR, шумът и смущенията доминират, което кара приетите състояния да се свият в един клъстер и да размият съзвездията.

В модела за потискане на NI, мрежата за прецизиране на CSI, мрежата за оценка на NI и SINR изчислителния модул са обучими модули. Мрежата за прецизиране на CSI и SINR изчислителния модул се обучават с помощта на стандартни контролирани методи с нормализирана средноквадратична грешка (NMSE). Мрежата за оценка на NI се обучава на

два етапа. В първата стъпка мрежата за оценка на NI се обучава с помощта на маркиран NI, следвайки контролиран метод за обучение, за да се минимизира NMSE. След като мрежата за оценка на NI е обучена в продължение на няколко кръга, този модул ще бъде обучен съвместно с мрежата за CSI, за да се минимизира грешката при реконструкция на CSI върху всички RE.

Б. Конфигуриране на симулационен модел

За създаване на CSI набор от данни както за обучение, така и за оценка, е използван генераторът на безжични канали с отворен код DeepMIMO [15]. Използват се данни, събрани от сценарии на хипотетична зона на покритие, за да се обучи и оцени модела. Базовата станция (BS) с 32 антени е разположена на фиксирано място, а 80 000 едноантенни потребителски устройства (UE) са разпределени на случаен принцип в дадена област. Използвани са 60 000 CSI семпли между BS-UE за обучение на модела.



Фиг. 3. Сценарий за оценка в хипотетична зона на покритие

На фиг. 3 е показан пример, в който „BS“ е базовата станция, а потребителските устройства са разпределени в областта „UE мрежа“ (т.е. мрежа от потребителските устройства). Всеки слот за предаване се състои от 14 OFDM символа и всеки символ обхваща 32 подносещи честоти. 3-тият и 10-ият OFDM символи се използват за предаване на пилот-

ни сигнали, вмъкнати с разстояние от 6 подносещи честоти. Другите RE във всеки слот са заети от потребителския трафик.

За да се оцени конкретно приносът на модула за потискане на NI, екстракторът на характеристики на канала не е обучен. Вместо това се използват директно параметрите от предварително обучена LWM (Large Wireless Model) [13]. Това гарантира, че подобрението в производителността идва от модула за потискане на NI, а не от ефектите на преобучение.

Разглежда се задача за прогнозиране на канали, която има за цел да предскаже CSI върху съседни подносещи честоти въз основа на съществуващия CSI върху 32 подносещи честоти. За сравнение е реализирано симулационно изследване с четири конкуриращи се решения, избрани като еталони:

1) LS плюс линейна интерполация (LI) (LS+LI): при този подход, LS оценката на канали се прилага първо за оценка на CSI върху RE, които носят пилотни сигнали, а след това се използва алгоритъм за линейна интерполация за получаване на пълните CSI за всички RE.

2) LMMSE: използва се за възстановяване на CSI на всички RE. Това е широко възприет подход в 5G BS и UE.

3) Метод, базиран на преобразуване: при този метод, LS алгоритъмът първо се използва за оценка на канала, за да се получат CSI за пилотните RE, след което се разгръща мрежа, базирана на преобразуване, за да се възстанови пълният CSI за всички RE.


4) Перфектен CSI: това съответства на идеален случай, при който CSI за пилотните RE са перфектно известни. Този случай се използва за демонстриране на горната граница на производителността.

За всички гореспоменати сравнителни изследвания и предложената схема, входните данни са едни и същи, а изходните данни са възстановените CSI за всички RE за всеки слот. Тези изходни данни се подават към екстрактора на характеристики на канала, за да се получи

универсално представяне на CSI, което се обработва допълнително от олекотен ResNet [16] модел, за да се получат крайните резултати от прогнозирането на канала.


В. Резултати от симулацията

Оценка на производителността при прогнозиране на даунлинк канали, сравняваща разглеждания метод с други решения, е представена на фиг. 4, където броят на подносещите честоти, които трябва да бъдат предсказани е 16, а процентът на обучителни извадки е 50%. Както се очаква, нормализираната средноквадратична грешка (NMSE) за всички подносещи честоти намалява с увеличаване на SINR. Това е така, тъй като повишеният SINR води до по-точна оценка на канала, което от своя страна дава по-прецизни представяния на каналите и по този начин подобрява производителността на прогнозирането на низходящите (даунлинк) канали. Традиционните методи, базирани на модели (т.е. LS+LI, LMMSE), се представят по-лоши в целия диапазон на изменение на SINR, тъй като предварително зададеният модел не успява точно да съпостави различните условия на канала. За разлика от това, методът, базиран на преобразуване, е в състояние да постигне значително подобряване в производителността в сравнение с методите, базирани на модели, което се постига чрез ефективно извличане на времево-честотно-пространствените корелации, които са критични за завършването на CSI оценката. Независимо от това, остава значителна разлика в производителността между метода, базиран на преобразуване, и случая с перфектен CSI. Чрез интегриране на механизма „шум с интерференция“ (NI) в оценката на канала, разглежданият метод е в състояние да генерира предсказване на каналите, което добре отразява истинските канали, като по този начин превъзхожда всички други решения в задачата за даунлинк канала.



Фиг. 4. Определяне на средноквадратичната грешка (NMSE) в зависимост от SINR


Фиг. 5 и фиг. 6 представят определяне на NMSE за различни методи по отношение на броя на прогнозираните подносещи честоти и броя на обучителните извадки за даунлинк канала съответно, за стойност на SINR 8dB.



Фиг. 5. Определяне на средноквадратичната грешка (NMSE) в зависимост от броя на прогнозираните подносещи честоти

Както е показано на фиг. 5 и фиг. 6, разглежданият метод постоянно постига най-ниската NMSE грешка при прогнозиране на канала, демонстрирайки своята адаптивност. Предсказванията за каналите, получени от предложения метод, съдържат по-богати и по-дискриминационни характеристики на канала, което улеснява по-лесното и по-ефективно откъм данни обучение, като по този начин

се минимизира рискът от пренапасване с ограничени етикетирани извадки.



Фиг. 6. Определяне на средноквадратичната грешка (NMSE) в зависимост от процента на извадки за обучение

Освен гореспоменатото, разглежданият метод показва по-големи подобрения в производителността при благоприятни условия, като например когато има по-малко подносещи честоти за прогнозиране или когато са налични повече извадки за обучение. Тези резултати подчертават силния потенциал на разглеждания метод за сценарии за високопрецизна комуникация в бъдещи 6G системи, като например ултранадеждна комуникация с ниска латентност (URLLC) и масивно MIMO предаване, където точното познаване на канала е от жизненоважно значение.

ЗАКЛЮЧЕНИЕ

В този доклад беше разгледан модел на основата на безжичен канал с вградена структура за потискане на шума и смущенията, който е способен да извлича точни и универсални представяния на каналите с ограничен капацитет за служебна информация в несъвършена среда с шум и смущения. Резултатите от симулацията демонстрират неговото превъзходство в овластяването на задачи в даунлинк канала при различни симулационни настройки, подчертавайки силния му потенциал за подобряване на произ-

водителността на предаване и точността на отчитане, както и за преодоляване на недостига на етикетирани данни в бъдещите 6G системи.

Благодарности: този доклад и изследванията в него са реализирани по проект „Съвременни методи и AI решения за защитено предаване на данни в широко-лентови комуникационни мрежи“, договор НИП 2025-14/2025 г. към УЦНИТ при ТУ – Габрово.

ЛИТЕРАТУРА

- [1] K. Trichias, A. Kaloxylos and C. Willcock, "6G Global Landscape: A Comparative Analysis of 6G Targets and Technological Trends," 2024 Joint European Conference on Networks and Communications & 6G Summit (EuCNC/6G Summit), Antwerp, Belgium, 2024, pp. 1-6.
- [2] C. Antón-Haro, K. Trichias, C. De Majo, A. Kaloxylos and J. Beriere, "6G Smart Networks and Services: Global Strategies, Main Work Directions & Future Outlook," 2024 Joint European Conference on Networks and Communications & 6G Summit (EuCNC/6G Summit), Antwerp, Belgium, 2024, pp. 1115-1120.
- [3] Paulo Sergio Rufino Henrique; Ramjee Prasad, "6G The Road to the Future Wireless Technologies 2030," in 6G The Road to the Future Wireless Technologies 2030, River Publishers, 2021, pp.i-xxvi.
- [4] R. Kunst, E. Pignaton, T. Zhou and H. Hu, "Application of future 6G technology to support heavy data traffic in highly mobile networks," 2020 First International Conference of Smart Systems and Emerging Technologies (SMARTTECH), Riyadh, Saudi Arabia, 2020, pp. 144-148.
- [5] D. S. S, R. M. Peri and V. N. Kumar, "AI-Driven Predictions for Channel State Information in next generation networks," 2025 International Conference on Sensors and Related Networks (SENNET) Special Focus on Digital Healthcare(64220), Vellore, India, 2025, pp. 1-4.
- [6] X. Lei, D. Zhang, S. Shi and L. Wei, "Optimized Design For Over-the-Air Computation System with Imperfect Channel State Information," 2025 5th International Conference on Sensors and Information Technology, Nanjing, China, 2025, pp. 811-816.
- [7] R. Talak, S. Karaman and E. Modiano, "Improving Age of Information in Wireless Networks With Perfect Channel State Information," in IEEE/ACM Transactions on Networking, vol. 28, no. 4, pp. 1765-1778, Aug. 2020.
- [8] S. Li, D. Tuninetti and N. Devroye, "The Fading Gaussian Broadcast Channel with Channel State Information and Output Feedback," 2020 IEEE International Symposium on Information Theory (ISIT), Los Angeles, CA, USA, 2020, pp. 1474-1479.
- [9] S. Zhang, S. Zhang, Y. Mao, L. Yeung, B. Clerckx, and T. Q. S. Quek, "Transformer-based channel prediction for rate-splitting multiple access-enhanced vehicle-to-everything communication," IEEE Trans. Wireless Commun., vol. 23, no. 10, pp. 12717-12730, Oct. 2024.
- [10] Y. Sheng, K. Huang, L. Liang, P. Liu, S. Jin, and Y. Li, "Beam prediction based on large language models," arXiv preprint arXiv:2408.08707, Feb. 2025.
- [11] Y. Zhu, L. Yu, L. Shi, J. Zhang, and G. Liu, "Multi-modal large models based beam prediction: An example empowered by DeepSeek," arXiv preprint arXiv:2506.0592, Jun. 2025.
- [12] T. Yang, P. Zhang, M. Zheng, Y. Shi, L. Jing, and J. Huang, "WirelessGPT: A generative pre-trained multi-task learning framework for wireless communication," IEEE Net., early access, Jun. 2025.
- [13] S. Alikhani, G. Charan, and A. Alkhateeb, "Large wireless model (LWM): A foundation model for wireless channels," arXiv preprint arXiv:2411.08872, Apr. 2025.
- [14] Y. Niu, Z. Wei, L. Wang, H. Wu and Z. Feng, "Interference Management for Integrated Sensing and Communication Systems: A Survey," in IEEE Internet of Things Journal, vol. 12, no. 7, pp. 8110-8134, 1 April, 2025.
- [15] A. Alkhateeb, "DeeepMIMO: A generic deep learning dataset for millimeter wave and massive MIMO applications," in Proc. IEEE Inf. Theory Appl. Workshop (ITA), San Diego, CA, USA, Feb. 2019, pp. 1-8.
- [16] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," Proc. IEEE Conf. Comput. Vis. Pattern Recognit. (CVPR), Las Vegas, NV, USA, 2016, pp. 770-778.