



AGENCIA NACIONAL
DE INVESTIGACIÓN
E INNOVACIÓN

Informe final publicable de proyecto Inteligencia Artificial aplicada a redes 5G

Código de proyecto ANII: FMV_1_2019_1_155700

06/06/2022

Resumen del proyecto

El problema abordado es la asignación de recursos en redes 5G. En particular el proyecto trabajó en el desarrollo de una herramienta que permite implementar y simular algoritmos para la asignación de recursos de tiempo y frecuencia en redes 5G. Se puso especial énfasis en el desarrollo de algoritmos que utilicen herramientas de inteligencia artificial ya que por la heterogeneidad de servicios de las redes 5G es necesario que la red aprenda la mejor forma de asignar recursos en diferentes escenarios. Se propusieron nuevos algoritmos asignación de recursos que permiten utilizando inteligencia artificial aprender la asignación óptima de recursos para servicios de muy diferentes requerimientos en cuanto a ancho de banda y latencia. Se desarrolló un simulador de redes 5G, Py5cheSim, que integra funcionalidades que no se encuentran en simuladores de uso público disponibles como la posibilidad de utilizar network slicing en la interfaz de radio. Esta herramienta cuenta con un framework que permite el desarrollo de nuevos algoritmos de asignación de recursos de forma amigable sin la necesidad de conocer en detalle todo el núcleo del simulador. Py5cheSim se licenció bajo licencia de software libre y se encuentra disponible. Por último, durante la ejecución del proyecto se formaron varios recursos humanos en las áreas de investigación abordadas; en particular tres estudiantes de posgrado desarrollaron sus tesis (dos de maestría, una de doctorado) y se dirigieron dos proyectos de fin de carrera.

Ingeniería y Tecnología / Ingeniería Eléctrica, Ingeniería Electrónica e Ingeniería de la Información / Telecomunicaciones / redes móviles celulares

Palabras clave: Redes 5G / Inteligencia Artificial / /

Introducción

Al momento de comenzar el proyecto existían pocas herramienta de simulación de redes 5G, mas pocas aún basadas en software libre o de libre acceso bajo fines académicos. En el proyecto se revisaron y evaluaron varios simuladores disponibles siendo los más populares 5G-LENA [1] y Vienna 5G [2]. Este último en un comienzo parecía ser el más prometedor para los objetivos del proyectos por tratarse de un simulador de código abierto, un simulador a nivel de sistema y con una arquitectura modular que permitía con cierta facilidad mejorarlo o agregar nuevas funcionalidades. Se comenzó con un prototipo de framework para el desarrollo de algoritmos de asignación de recursos sobre Vienna y en paralelo se evaluaron otras alternativas ([1], [3-5]). Tanto Vienna como las demás tenían debilidades a la hora de incorporar técnicas de asignación de recursos y en particular carecían de la posibilidad de utilizar la técnica conocida como network slicing en la interfaz de radio (propuesta en el estándar 5G como una de sus principales novedades). Por este motivo se decidió desarrollar un simulador a nivel de sistema de redes 5G, de código libre y desarrollado en Python. Sobre este simulador finalmente se desarrolló el framework que permite fácilmente diseñar nuevos algoritmos de asignación de recursos y probarlos en diferentes escenarios.

En cuanto a los algoritmos de asignación de recursos en redes 5G, es un tema de constante investigación ya que no está definido por el estándar y la diversidad y heterogeneidad de la red 5G hace que se presenten problemas nuevos en la asignación de recursos que aún no están resueltos y que son nuevos frente a las tecnologías anteriores. Se analizaron diversos problemas importantes que se están investigando en esta área como por ejemplo: la asignación de recursos en sistemas 5G con MIMO masivo, asignación de recursos en 5G con celdas heterogéneas, y la asignación de recursos con requerimientos de ancho de banda y latencia muy diferentes. Sobre este último punto se resolvió concentrar los esfuerzos del proyecto.

Una de las mayores innovaciones en 5G es la compatibilidad de tres servicios diferentes con requisitos particulares de latencia y ancho de banda. Estos son: las comunicaciones masivos de tipo de tipo dispositivo a dispositivo (MMTC), servicios de banda ancha móvil mejorada (eMBB) y comunicaciones de baja latencia ultra confiables (URLLC). Para lograr estos múltiples requisitos de servicio todos los usuarios deben compartir recursos a través de la trama de acceso múltiple por división ortogonal de frecuencia ortogonal (OFDMA). Una de las estrategias propuestas por el estándar 5G para compatibilizar estos servicios en la trama OFDM es la perforación (puncturing), que permite al despachador de recursos asignar servicios eMBB en una escala de tiempo larga y en una escala de tiempo más corta sobrescribir parte de la asignación de eMBB cuando llega un usuario de URLLC. La optimización de este sistema con puncturing plantea un problema desafiante: la asignación óptima depende del tráfico que llega en diferentes escalas de tiempo, lo que obliga al despachador a tomar decisiones de asignación sin conocer las demandas de los usuarios futuros, todo mientras tiene que

satisfacer varias restricciones fuertes. Naturalmente, este problema de asignación de recursos ha atraído mucha atención de la investigación en esta área en los últimos años [6]. Por ejemplo, el desempeño de políticas de asignación de recursos específicas ha sido ampliamente estudiado [7–10]. Por otro lado, algunos trabajos formulan el problema de optimización con puncturing en 5G y buscan heurísticas que se comporten razonablemente bien para escenarios particulares [11, 12]. Otros autores proponen un enfoque de Q-learning o aprendizaje profundo para obtener una solución al problema de la perforación [12, 13]. Un artículo muy reciente e interesante propone la utilización de superficies inteligentes reconfigurables (RIS) para optimizar la coexistencia de eMBB y URLLC [14]. Estos trabajos nos permiten visualizar cómo se comporta la punci3n en determinados escenarios y dar una idea del problema. Destacamos especialmente el artículo [15], donde los autores formalizan el problema de optimización con puncturing y analizan algunos casos prácticos interesantes. Una observaci3n interesante en [15] es que cuando las funciones del problema de optimizaci3n (pérdida, restricciones) no son convexas (por ejemplo, pérdida de umbral) y a medida que crece la carga de tráfico de URLLC, los métodos propuestos para realizar puncturing difieren cada vez más de la soluci3n óptima. Es importante tener en cuenta que, como se analiza por ejemplo en [16], la tasa de error de bit (BER) en los sistemas OFDM sigue un fenómeno similar al umbral con ruido e interferencia. A medida que aumenta el puncturing, se espera ese comportamiento, lo que destaca la relevancia de encontrar políticas que estén bien ajustadas a las pérdidas de umbral. Es importante resaltar que este tipo de problemas de optimizaci3n altamente acoplados con múltiples bases de tiempo y restricciones duras se pueden encontrar en muchos campos además de las comunicaciones inalámbricas. Por ejemplo: en la gesti3n del almacenamiento de energí3a a largo plazo, en la gesti3n de dispositivos IoT, en la programaci3n de microrredes, en el consumo de energí3a para la carga de vehículos eléctricos, etc..

Nuestra propuesta para abordar este problema en el proyecto fue utilizar inteligencia artificial y proponer un mecanismo de aprendizaje en el que el sistema aprende fuera de línea la asignaci3n óptima según el estado de la red. Esta estimaci3n aprendida se usa luego en línea para determinar la asignaci3n óptima.

Además de la técnica de perforaci3n explicada anteriormente, el estándar prevé la posibilidad Network Slicing de extremo a extremo pensando en la asignaci3n de recursos de servicios de distintos requerimientos. Bajo esta idea, se puede definir una Slice para cada tipo de servicio y que el despachador realice una asignaci3n de recursos a dos niveles: interslice e intraslice. En los últimos años han surgido propuestas de mecanismos interslice basados en inteligencia artificial (ver por ejemplo [19,20]) que se justifican por los cambiantes que pueden ser los escenarios en este tipo de redes. En nuestro proyecto también se comenzó a explorar esta área evaluando opciones de mejoras a los algoritmos del estado del arte y/o nuevas propuestas de algoritmos de asignaci3n de recursos interslice basados en inteligencia artificial. Para esta parte del proyecto es clave contar con la herramienta de simulaci3n desarrollada en el proyecto.

Metodología/diseño del estudio

El proyecto en primer lugar realizó una actualizaci3n del estado del arte en las dos líneas de investigaci3n del proyecto. Por un lado, en simuladores de red 5G y por otro, en algoritmos de asignaci3n de recursos en red 5G.

En cuanto a la primera línea de investigaci3n se eligió al simulador Vienna 5G como candidato y se realizó un primer prototipo del framework que permite implementar algoritmos de asignaci3n de recursos en la interfaz de radio 5G (ver detalles en [DMR2020], proyecto de fin de carrera de Ing. Eléctrica). En particular se implementaron algoritmos de asignaci3n de recursos basados en la técnica de puncturing. De esta primera experiencia surgieron varias debilidades de los simuladores existentes y en particular de Vienna 5G para los objetivos del proyecto. Además de no implementar aspectos relevantes de la tecnología 5G, ninguno de los simuladores existentes permitía integrar dos aspectos que eran vitales para el proyecto: integrar algoritmos de inteligencia artificial para la asignaci3n de recursos en 5G y permitir realizar network slicing en la interfaz de radio de 5G. Por estos motivos, se decidió realizar un simulador de nivel de sistema, de código libre, desarrollado en Python que incluyera los dos aspectos fundamentales mencionados antes: que estuviera preparado para integrar algoritmos de asignaci3n de recursos utilizando técnicas de inteligencia artificial y que permitiera implementar network slicing en la interfaz de radio habilitando a asignar recursos interslices e intraslices. Sobre este software de simulaci3n se desarrolló la nueva versi3n del framework que permite con facilidad incorporar y probar algoritmos de asignaci3n de recursos y en particular algoritmos que contemplen la utilizaci3n de métodos de inteligencia artificial y algoritmos inter e intra slices. La arquitectura del simulador desarrollado y del framework se puede ver en los trabajos [PRB2021-1,PRB2021-2,PIRB2022] y en la tesis de maestría de G. Pereyra [Pereyra2021].

En la segunda línea de investigaci3n como se menciona en los antecedentes se decidió trabajar en algoritmos de inteligencia artificial que permitieran encontrar el óptimo en línea del problema de optimizaci3n de recursos con

puncturing. Este es un problema de optimización altamente complejo porque la asignación de usuarios eMBB y URLLC se da en escalas de tiempo diferentes y la asignación óptima de cada uno de estos servicios depende de la asignación realizada del otro servicio. En particular cuando se hace una asignación eMBB que es de horizonte largo, no se sabe que requerimientos de servicios URLLC van a venir en el futuro y por lo tanto es muy difícil de resolver este problema de optimización salvo para casos muy simplificados. Para decidir ahora la mejor asignación de recursos sin conocer las futuras necesidades de puncturing, proponemos un marco de aprendizaje supervisado en el que se aprende a aproximar ambas políticas de despacho para usuarios eMBB y URLLC. La observación clave es que, aunque la solución óptima para nuestro problema de optimización acoplada no está disponible en línea cuando se hace la asignación eMBB, se puede encontrar después, una vez que han ocurrido los eventos y podemos considerar todos los datos necesarios de un intervalo de tiempo determinado. Si la pérdida por puncturing penaliza la utilidad del usuario eMBB a través de una función de pérdida convexa, el problema resulta ser un problema de optimización convexa, lo que ha dado lugar a numerosas y conocidas soluciones [15]. Pero si la penalización por pérdida no es convexa (por ejemplo, una penalización de umbral, un modelo mucho más adecuado para el enlace de comunicación inalámbrica real [16]), como mencionamos antes, las soluciones propuestas pueden alejarse de ser óptimas. En tales casos, la política óptima tendría que encontrarse probando todos los escenarios de programación posibles, lo que haría imposible encontrarla en línea. Siguiendo las ideas del paradigma de 'aprender a optimizar' (como en [17] y [18]), proponemos un método de aprendizaje estadístico que permite la explotación de las correlaciones de la señal para aproximar soluciones óptimas. El marco de aprendizaje propuesto separa el problema de asignación de recursos en cada escala de tiempo, aunque incorpora información estadística significativa. Esto se logra entrenando dos máquinas de aprendizaje (agentes) que serán los tomadores de decisiones para cada asignación de recursos de cada escala de tiempo. En esta parte estuvo concentrado el trabajo del tesista de doctorado.

Finalmente, en el marco de Network Slicing luego de revisado el estado del arte se decidió implementar la propuesta [19] en nuestra herramienta de simulación. Los autores de [19] proponen una asignación de recursos interslice basada en deep reinforcement learning. Este algoritmo asigna recursos tiempo frecuencia a cada Slice pero no explota otras novedades del estándar como la posibilidad de que cada Slice maneje diferente numerología [21], posibilidad que no es tenida en cuenta por varias de las propuestas revisadas. En esta línea de mejora (incorporar al aprendizaje la mejor numerología a utilizar por la Slice) se comenzó a trabajar y se continuará una vez culminado el proyecto.

Resultados, análisis y discusión

En cuanto a la primera línea de investigación, se logró obtener un simulador y un framework para la asignación de recursos en redes 5G que si bien se encuentran en una primera versión, ya es operativo y se encuentra disponible para ser utilizado en [Py5cheSim]. Basados en esta herramienta de software (Py5cheSim), se realizaron además 3 publicaciones, dos en conferencias y una versión extendida en una revista [PRB2021-1, PRB2021-2, PIRB2022]. El simulador está desarrollado en Python, basado en eventos discretos, y como ya se mencionó es el primero (de los simuladores de libre acceso) que permite simular network slicing a nivel de la interfaz de radio. Implementa la mayoría de las funcionalidades previstas para las redes 5G, algunas de ellas en una versión muy simple. Actualmente un proyecto de fin de carrera (de estudiantes de Ing. Eléctrica e Ing. en Sistemas de Comunicación) está trabajando en mejorar algunas de las funcionalidades de Py5cheSim, en particular están abordando el modelo de canal y el modelo de MIMO. Una vez culminado este proyecto (noviembre de 2022) se liberará una nueva versión del simulador.

En cuanto a los algoritmos de asignación de recursos en redes 5G, como se mencionó anteriormente se utilizaron algoritmos de aprendizaje para resolver en línea el problema de optimización de asignación de recursos de usuarios eMBB y URLLC con puncturing. Se diseñaron dos algoritmos de aprendizaje. Uno tradicional utilizando Support Vector Machines y otro utilizando Deep Learning. En ambos casos se obtuvieron muy buenos resultados, mejorando en ciertos escenarios de interés a los algoritmos del estado del arte existentes hasta el momento. De este trabajo quedan varias líneas de investigación a continuar. En particular se seguirá trabajando en extender este problema a un escenario con múltiples celdas heterogéneas y además como problema de aprendizaje del óptimo de un sistema con restricciones. Hay mucho trabajo para continuar investigando en el área. Sobre este trabajo se envió un paper a una revista importante del área y el mismo se encuentra en revisión [RBBL2022].

En cuanto a los algoritmos interslice, si bien aún no se cuentan con resultados novedosos, un estudiante de maestría está enfocado en esta línea y se espera que en los próximos meses se logren resultados publicables.

Complementariamente a lo anterior, se abordó una versión simplificada del problema de estimación del estado del canal; problema fundamental a la hora de realizar la asignación de recursos. Se exploraron técnicas de aprendizaje automático basado en datos en grafos para un data set real. En particular se probaron Random Dot Product Graphs y Graph Neural Networks obteniendo resultados prometedores [RLC2021]. En esta área se continuará trabajando una vez culminado el proyecto.

Finalmente, se realizó difusión de este proyecto realizando un video donde se explican las características del proyecto y lo que se hizo en el mismo para un público general. El video se encuentra disponible en youtube [video] y además, se realizó divulgación del proyecto y del video en Ingeniería DeMuestra 2021. El video también es accesible de la web del proyecto: <https://iie.fing.edu.uy/investigacion/grupos/artes/es/proyectos/inteligencia-artificial-aplicada-a-redes-5g/>

Conclusiones y recomendaciones

El proyecto desarrolló una herramienta de simulación de redes 5G que permite simular diferentes escenarios de este tipo de redes. El simulador cuenta además con un framework que facilita a un usuario implementar y probar nuevos algoritmos de asignación de recursos en particular algoritmos que integren herramientas de inteligencia artificial y algoritmos que realicen asignación de recursos inter e intra slices en la interfaz de radio. Estas características del simulador y el framework no las poseen a la fecha otras herramientas de simulación de redes 5G en particular herramientas de código abierto. Este implementa la mayoría de las funcionalidades previstas para las redes 5G, muchas de ellas que se prevé continuarán en las redes 6G por lo que se espera que sea escalable para los futuros estándares.

El proyecto ha realizado avances importantes para resolver problemas de optimización con restricciones de dos escalas de tiempo en línea. En el enfoque de aprendizaje propuesto, usamos el estado del sistema y las correlaciones estadísticas para entrenar a dos agentes supervisados, uno para cada política en cada escala de tiempo. Nuestra propuesta consta de una fase de aprendizaje fuera de línea, en la que entrenamos a los agentes de aprendizaje con el estado del sistema y las asignaciones óptimas obtenidas de datos históricos fuera de línea. Los agentes supervisados luego aplican en línea las asignaciones óptimas aprendidas. Como ya mencionamos, la optimización de recursos 5G con puncturing es en general un reto, y pocos casos de interés es posible de resolver directamente. La coexistencia de URLLC y eMBB implica una degradación de las comunicaciones de eMBB al reasignar los recursos de los usuarios de eMBB a los usuarios de URLLC para satisfacer la demanda de URLLC. Resolvimos el problema de optimización que surge de la coexistencia antes mencionada, enfocándonos en maximizar una utilidad basada en el rendimiento para los usuarios de eMBB y al mismo tiempo satisfacer las demandas de URLLC. La eficacia del enfoque propuesto se demostró a través de una variedad de escenarios. Utilizamos diferentes escenarios realistas para probar el desempeño de la propuesta, logrando resultados por encima de las soluciones del estado del arte actuales. Pudimos aproximarnos a las soluciones óptimas en línea, incluso en escenarios no convexos en los que las técnicas del estado del arte no se aproximan bien a la solución óptima. En todos los escenarios, nuestros agentes se desempeñan mejor que las heurísticas comparadas, logrando un aumento de hasta un 50 % en la utilidad de los usuarios de eMBB con respecto a las conocidas propuestas de vanguardia.

En trabajos futuros planeamos analizar otros algoritmos de aprendizaje, modificando restricciones y desarrollando ingeniería de características, para encontrar aproximaciones de políticas aún mejores. También sería interesante explorar la posibilidad de implementar un entrenamiento combinado de ambos agentes de aprendizaje, introduciendo en la función de pérdida una penalización por divergencia de utilidad. Esto puede permitir explotar el conocimiento del dominio para lograr mejores resultados en problemas particulares. También queda abierta una línea de investigación más general sobre cómo incorporar las restricciones de la optimización al problema de aprendizaje. En la versión realizada estas restricciones se imponen al problema de aprendizaje pero en ese terreno hay espacio para mejorar los algoritmos.

Por último, hay que destacar que el proyecto permitió formar recursos humanos a nivel de doctorados y maestrías en un tema altamente relevante tecnológicamente y en particular para el Uruguay. Se desarrollaron también algoritmos novedosos y se dejaron diversas líneas de investigación abiertas para abordar en proyectos futuros. Se publicaron 5 artículos en conferencias y revistas del área. En los próximos meses se realizará una presentación de los resultados del proyecto en la DINATEL (organismo que mostró interés en la realización del proyecto y encargado de las políticas públicas en la materia).

Referencias bibliográficas

- [1] M. Mezzavilla, M. Zhang, M. Polese, R. Ford, S. Dutta, S. Rangan, and M. Zorzi, "End-to-end simulation of 5g mmwave networks," *IEEE Communications Surveys Tutorials*, vol. 20, no. 3, pp. 2237–2263, 2018.
- [2] M. K. Müller, F. Ademaj, T. Dittrich, A. Fastenbauer, B. R. Elbal, A. Nabavi, L. Nagel, S. Schwarz, and M. Rupp, "Flexible multi-node simulation of cellular mobile communications: the Vienna 5G System Level Simulator," *EURASIP Journal on Wireless Communications and Networking*, vol. 2018, no. 1, p. 17, Sep. 2018.
- [3] G. Nardini, D. Sabella, G. Stea, P. Thakkar, and A. Virdis, "Simu5g—an omnet++ library for end-to-end performance evaluation of 5g networks," *IEEE Access*, vol. 8, pp. 181 176–181 191, 2020.
- [4] Y. Kim, J. Bae, J. Lim, E. Park, J. Baek, S. I. Han, C. Chu, and Y. Han, "5g k-simulator: 5g system simulator for performance evaluation," in *2018 IEEE International Symposium on Dynamic Spectrum Access Networks (DySPAN)*, 2018, pp. 1–2.
- [5] S. M. A. Zaidi, M. Manalastas, H. Farooq, and A. Imran, "Syntheticnet: A 3gpp compliant simulator for ai enabled 5g and beyond," *IEEE Access*, vol. 8, pp. 82 938–82 950, 2020.
- [6] Popovski, P., Trillingsgaard, K.F., Simeone, O., Durisi, G.: 5g wirelessnetwork slicing for embb, urllc, and mmtc: A communication-theoretic view. *Ieee Access* 6, 55765–55779 (2018)
- [7] Pedersen, K., Pocovi, G., Steiner, J., Maeder, A.: Agile 5g scheduler for improved e2e performance and flexibility for different network implementations. *IEEE Communications Magazine* 56(3) (2018)
- [8] Pedersen, K.I., Pocovi, G., Steiner, J., Khosravirad, S.R.: Punctured scheduling for critical low latency data on a shared channel with mobile broadband. In: *2017 IEEE 86th Vehicular Technology Conference* (2017)
- [9] Pocovi, G., Pedersen, K., Mogensen, P.: Joint link adaptation and scheduling for 5g ultra-reliable low-latency communications. *IEEE Access* 6 (2018)
- [10] Esswie, A.A., Pedersen, K.I.: Multi-user preemptive scheduling for critical low latency communications in 5g networks. In: *2018 IEEE Symposium on Computers and Communications (ISCC)* (2018)
- [11] Bairagi, A.K., Munir, M.S., Alsenwi, M., Tran, N.H., Hong, C.S.: A matching based coexistence mechanism between embb and urllc in 5g wireless networks. In: *Proceedings of the 34th ACM/SIGAPP Symposium on Applied Computing. SAC '19, NY, USA* (2019)
- [12] Alsenwi, M., Tran, N.H., Bennis, M., Pandey, S.R., Bairagi, A.K., Hong, C.: Intelligent resource slicing for embb and urllc coexistence in 5g and beyond: A deep reinforcement learning based approach. *ArXiv abs/2003.07651* (2020)
- [13] Elsayed, M., Erol-Kantarci, M.: Ai-enabled radio resource allocation in 5g for urllc and embb users. In: *IEEE 2nd 5G World Forum* (2019)
- [14] Almekhlafi, M., Arfaoui, M.A., Elhattab, M., Assi, C., Ghayeb, A.: Joint resource allocation and phase shift optimization for ris-aided embb/urllc traffic multiplexing. *IEEE Transactions on Communications* (2021)
- [15] Anand, A., de Veciana, G., Shakkottai, S.: Joint scheduling of urllc and embb traffic in 5g wireless networks. *IEEE/ACM Transactions on Networking* 28(2), 477–490 (2020)
- [16] Otsuka, H., Tian, R., Senda, K.: Transmission performance of an ofdm-based higher-order modulation scheme in multipath fading channels. *Journal of Sensor and Actuator Networks* 8(2), 19 (2019)
- [17] Bengio, Y., Lodi, A., Prouvost, A.: Machine learning for combinatorial optimization: a methodological tour d'horizon. *European Journal of Operational Research* 290(2), 405–421 (2021)
- [18] Eisen, M., Zhang, C., Chamon, L.F., Lee, D.D., Ribeiro, A.: Learning optimal resource allocations in wireless systems. *IEEE Transactions on Signal Processing* 67(10), 2775–2790 (2019)
- [19] R. Li, Z. Zhao, Q. Sun, C.-L. I, C. Yang, X. Chen, M. Zhao, and H. Zhang, "Deep reinforcement learning for resource management in network slicing," *IEEE Access*, vol. 6, pp. 74 429–74 441, 2018.
- [20] Y. Abiko, T. Saito, D. Ikeda, K. Ohta, T. Mizuno and H. Mineno, "Flexible Resource Block Allocation to Multiple Slices for Radio Access Network Slicing Using Deep Reinforcement Learning," in *IEEE Access*, vol. 8, pp. 68183-68198, 2020
- [21] 3GPPTS38.201, "NR; Physical Layer; General Description," V0.0.0, May 2017.
- [RBBL2022] Martin Randall; Gonzalo Belcredi; Pablo Belzarena; Federico Larroca. Learning to Solve Decision Problems over two Timescales: An Application to 5G Puncturing. Submitted to *Wireless Personal Communications*.
- [DMR2020] Enzo Davyt, Alexis Muzante, Martín Rizzo; A5iGnator : Framework para la implementación de algoritmos de asignación de recursos en 5G; Proyecto de Fin de Carrera de Ing. Eléctrica. Nov 2020

[PRB2021-1] Gabriela Pereyra, Claudina Rattaro, Pablo Belzarena; A 5G multi-Slice cell capacity framework; ACM SIGCOMM 2021 Networking Networking Women Professional Development Workshop (N2Women'21), online, 23-27 aug, page 1–3- 2021

[PRB2021-2] Gabriela Pereyra, Claudina Rattaro, Pablo Belzarena; Py5cheSim : A 5G Multi-Slice Cell Capacity Simulator; 2021 XLVII Latin American Computing Conference (CLEI), San José, Costa Rica, 25-29 oct, page 1–8 – 2021

[PIRB2022] Gabriela Pereyra, Lucas Inglés, Claudina Rattaro, Pablo Belzarena; An open source multi-slice cell capacity framework; CLEI Electronic Journal, Volume 25, Number 2, page 1–21 – May. 2022

[Pereyra2021] Gabriela Pereyra; Scheduling in 5G networks : Developing a 5G cell capacity simulator; Tesis de Maestría en Ing. Eléctrica, Set 2021.

[RLC2021] Claudina Rattaro, Federico Larroca, Germán Capdehourat ; Predicting wireless RSSI using machine learning on graphs 2021 IEEE URUCON, Montevideo, Uruguay, 24-26 nov, page 372–376 – 2021

[Py5cheSim] <https://github.com/ClaudinaRattaro/Py5cheSim>

[video] https://youtu.be/L81q935K_58

Licenciamiento

Reconocimiento-Compartir Igual 4.0 Internacional. (CC BY-SA)