



## "Generación de Conocimiento

con Integración Científica, Académica, Tecnológica & Cultural para la Justicia, la Libertad y el Bienestar de Nuestros Pueblos"

**7-8-9 / SEP 2022**



UNIVERSIDAD  
**SAN FRANCISCO XAVIER**  
UNIVERSIDAD DIGNA  
BOLIVIA



**30**  
AÑOS

---

### C.29. Tecnologías de la información y comunicación **DRL for Inter-Slice Resource Allocation in 5G Networks**

Autor: Lucas Inglés; [linglesloggia@gmail.com](mailto:linglesloggia@gmail.com)

Profesor/a guía: Claudina Rattaro, [crattaro@fing.edu.uy](mailto:crattaro@fing.edu.uy)

Pablo Belzarena, [belza@fing.edu.uy](mailto:belza@fing.edu.uy)

Facultad de Ingeniería, UdelaR

---

#### Resumen

La creciente demanda de conectividad se refleja en la insondable cantidad de volúmenes de tráfico y la marcada tendencia a extender el alcance de las redes móviles a otros tipos de consumo.

En función de estas necesidades, los sistemas de quinta generación (5G) de redes móviles se presentan como el nuevo paradigma de las redes de comunicación de 3GPP. Ofrecen una plétora de nuevas características, tales como nueva tecnología de acceso de radio y una amplia gama de servicios. Las redes 5G deben permitir la coexistencia de clientes con diferentes requerimientos de servicio, mientras garantiza la autonomía e independencia entre ellos. Tal escenario de simultaneidad aumenta la complejidad para la asignación de recursos, pues se debe considerar restricciones de servicio diferenciales.

El concepto de *Network Slicing* se presenta como la herramienta clave para abordar este problema. Este implica el particionamiento de los recursos de radio en *slices* con el objetivo de cumplir con el nivel de servicio acordado con cada usuario. Tanto la academia como la industria han dedicado numerosos esfuerzos para resolver el problema de cómo asignar los finitos recursos entre las *slices*.

En este trabajo, se aborda el problema de asignación de recursos entre *slices* mediante la incorporación de técnicas basadas en el estado del arte de *Deep Reinforcement Learning*. En donde se obtiene un algoritmo capaz de realizar de manera óptima la asignación de



**"Generación de Conocimiento**  
con Integración Científica, Académica, Tecnológica & Cultural para la Justicia, la Libertad y el Bienestar de Nuestros Pueblos"

**7-8-9 / SEP 2022**



UNIVERSIDAD  
**SAN FRANCISCO XAVIER**  
UNIVERSIDAD DIGNA  
BOLIVIA



**30**  
AÑOS

---

recursos. Además, se realiza un enfoque novedoso en este contexto, al incorporar a este algoritmo la capacidad de realizar configuración adaptativa de las *slices* a nivel de radio.

**Palabras clave:** Redes móviles, 5G, Deep Reinforcement Learning, aprendizaje automático



## “Generación de Conocimiento

con Integración Científica, Académica, Tecnológica & Cultural para la Justicia, la Libertad y el Bienestar de Nuestros Pueblos”

**7-8-9 / SEP 2022**



UNIVERSIDAD  
**SAN FRANCISCO XAVIER**  
UNIVERSIDAD DIGNA  
BOLIVIA



**30**  
AÑOS

## 2. Introducción

Desde finales del siglo pasado, la tecnología ha tenido avances significativos en el campo de las telecomunicaciones, impulsado por los grandes avances en la electrónica y el aumento de la capacidad de cómputo. En la mayoría de los países son más los dispositivos que se conectan a la red que personas habitando. Esto, sumado a los cambios en los patrones de consumo, presenta nuevos desafíos que la red debe afrontar.

Inicialmente las redes móviles brindaban servicio de voz sobre su infraestructura. Estas redes fueron evolucionando en función de las necesidades, acompañados por los avances en la electrónica y nuevas tecnologías de radio, a redes proveedoras de servicios de datos. La cuarta generación de redes móviles implicó un gran cambio en este sentido, al ser la primera red diseñada para proveer servicios de datos. Si bien esta tecnología brinda una solución para la conectividad de dispositivos móviles, las necesidades de la industria apuntan a redes más veloces y flexibles.

Se espera que para la presente y siguiente década, las redes celulares 5G

sean la principal infraestructura desplegada. Además de incorporar mejoras significativas en términos de *throughput*, confiabilidad y cantidad de conexiones, el objetivo de 5G es incorporar una profunda transformación en el ecosistema de las redes móviles.

Para incorporar estas características, 5G introduce el novedoso concepto de *network slicing*, el cual permite dividir a la infraestructura en distintas particiones lógicas denominadas *slices*. Asimismo, cada *slice* puede invocar *virtual network functions* corriendo en la misma infraestructura común, y adaptarlos para cumplir con sus propios requerimientos. Entre las principales características de *Network Slicing* se encuentra la posibilidad de personalizar el servicio a distintos grupos de dispositivos (ver figura 2.1), lo cual permite mayor flexibilidad frente a las tecnologías de radio existentes hasta el momento. Sumado a lo anterior, *Network Slicing* tendrá un importante impacto en el modelo de negocio en el ecosistema de las telecomunicaciones, separando a los proveedores de infraestructura de los inquilinos de la red. Los primeros tendrán el despliegue e infraestructura que provee conectividad a los distintos inquilinos, y

estos últimos podrán hacer uso de su porción, agregar sus propias funcionalidades de red y ser proveedores a usuarios finales.

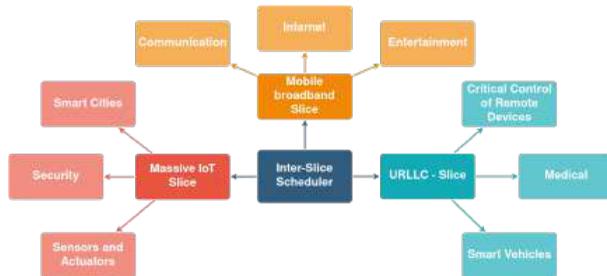


Figura 2.1

Por otra parte, actualmente la comunidad científica y la industria se están inclinando por soluciones basadas en *machine learning*, más específicamente *Reinforcement learning*.

El concepto de *machine learning* está asociado al aprendizaje de datos para realizar predicciones y/o decisiones. Para ello, se basa en probabilidad, estadística y optimización. Puede categorizarse en aprendizaje supervisado, no supervisado y *reinforcement learning*.

El *reinforcement learning* implica obtener una solución (o política) óptima, a partir de la interacción de un *software* al que denominaremos agente que interactúa con el entorno.

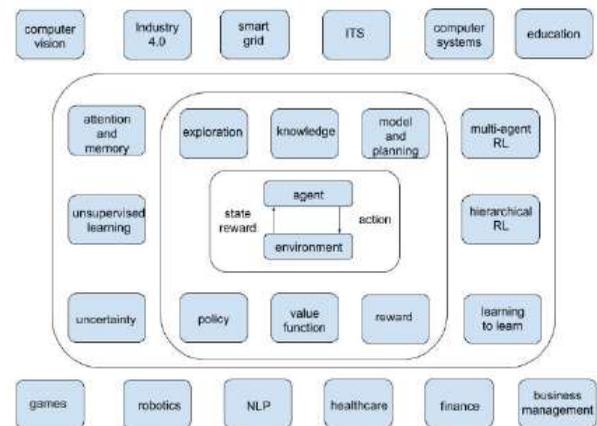


Figura 2.2 extraída de [5]

La obtención de dicha política óptima se dará a través de prueba y error con el entorno, el cual le retribuirá con una recompensa que definirá si dicha interacción es o no conveniente. Es este último método en el cual se desarrollarán las propuestas de esta tesis.

### 3. Objetivos

Las redes 5G deben asegurar la coexistencia de distintos tipos de servicio en una misma infraestructura. Esto genera un escenario de simultaneidad de requerimientos que la red debe afrontar. Los requerimientos pueden darse en forma de *service level agreement (SLA)* donde los dispositivos deben obtener el nivel de servicio acordado con el proveedor. Este nivel de servicio puede expresarse en diferentes requerimientos, sea *throughput, delay, packet loss, etc.* Este conjunto de requerimientos van a

definir la calidad de experiencia de los usuarios finales. Para atender a estas necesidades es fundamental incorporar el concepto de *Network Slicing*, en donde se puede definir distintas *slices* para cumplir con los requerimientos de diferentes grupos de usuarios finales.

Es posible visualizar dos niveles de asignación de recursos en las radio bases de 5G. Por un lado, la asignación de recursos de una misma *slice* entre los usuarios finales, a la cual llamaremos asignación *intra-slice*. Este tipo de asignación tiene una granularidad temporal muy pequeña, pero es posible implementarla a través de diversos métodos ya existentes de las anteriores generaciones de redes móviles. Por otro lado, y desde una perspectiva más global, los recursos de la celda deben ser distribuidos entre las distintas *slices*. Cada una de ellas con sus propios requerimientos de servicio. A dicha asignación entre *slices* la denominaremos asignación *inter-slice* y tiene una granularidad temporal muy superior a la asignación *intra-slice*.

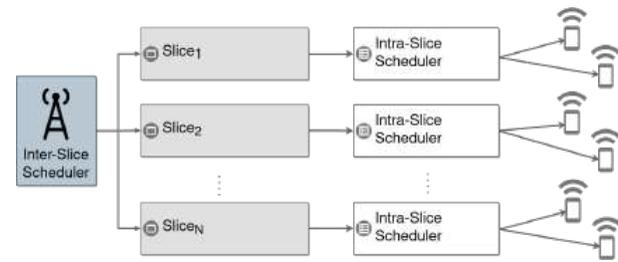


Figura 3.1

La figura 3.1 ilustra el concepto de ambos tipos de asignación.

En este sentido, la asignación *inter-slice* presenta un desafío novedoso, al ser propia de la tecnología 5G y contar con numerosas restricciones. Actualmente existe un considerable esfuerzo por parte de la academia y la industria por obtener un algoritmo eficiente de asignación de recursos *inter-slice*.

En este trabajo de maestría nos enfocamos en el problema de la asignación de recursos *inter-slice* utilizando técnicas de *machine learning*. Además, comparamos las propuestas más relevantes del estado del arte. Y finalmente tomamos lo anterior para formular una propuesta novedosa de asignación en la que se tiene en cuenta la configuración adaptativa de las *slices*. El presente documento expone los resultados obtenidos hasta el momento.

#### 4. Materiales y métodos

Para el desarrollo de la tesis fue importante tener un entorno de simulación de redes 5G que se adapte fielmente al estándar. En este sentido, desarrollamos nuestro trabajo bajo el simulador de código abierto Py5GheSim [4]. Es un simulador de 5G de alto nivel desarrollado en la Facultad de Ingeniería de UdeLaR. Permite el desarrollo de *schedulers* y ofrece grandes prestaciones de flexibilidad y *performance*. Sumado a lo anterior, existen varias líneas de investigación dentro de nuestra facultad, en donde se continúa su desarrollo incorporando nuevas características del estándar. Esta herramienta es de especial utilidad al ser de los pocos simuladores que tienen la capacidad de soportar *Network Slicing*.



Figura 4.1

En el código del simulador, en el marco de la tesis implementamos distintas funcionalidades, tales como la definición de perfiles de tráfico. Hemos introducido distintas distribuciones de tamaño de paquetes y distribuciones de tasas de

arribo, con el objetivo de obtener los escenarios más realistas posible.

Es así que, para la obtención de resultados y la propuesta de trabajo, definimos una celda con tres grandes grupos de usuarios, llamados eMBB-1, eMBB-2 y URLLC. Los primeros dos abrevian *enhanced Mobile Broadband* y sus requerimientos tienen un bajo nivel de exigencia hacia la red. Como referencia, un SLA para ver contenido multimedia en alta calidad, puede ser de 5 Mbps. Para eMBB-1 se define un SLA de 2.5Mbps de *throughput* medio mientras que para eMBB-2 un SLA de 7 Mbps de *throughput* medio. Por otra parte, el grupo de usuarios URLLC por *ultra-reliable low latency communications* define a un grupo de usuarios con altos niveles de requerimientos de *throughput*. Este tipo de usuarios está orientado a aplicaciones en la industria que impliquen manejo “instantáneo” de dispositivos a distancia. Para cada grupo de usuarios definimos una slice con los requerimientos que se observan en la tabla 4.1.

Slice	SLA (Mbps)
eMBB-1	2.5
eMBB-2	7
URLLC	16

tabla 4.1

Slice	Tasa de arribos medio (ms)	Tamaño de paquetes medio (bytes)
eMBB-1	6	6000
eMBB-2	25	8000
URLLC	60	100000

Para la obtención de la asignación de recursos *inter-slice* óptima, utilizamos técnicas de *Reinforcement Learning* conjuntamente con redes neuronales, más precisamente *Deep Q-Learning (DQN)*. Este método nos permite obtener un modelo a partir de una numerosa cantidad de experiencias simuladas, que predice la asignación óptima.

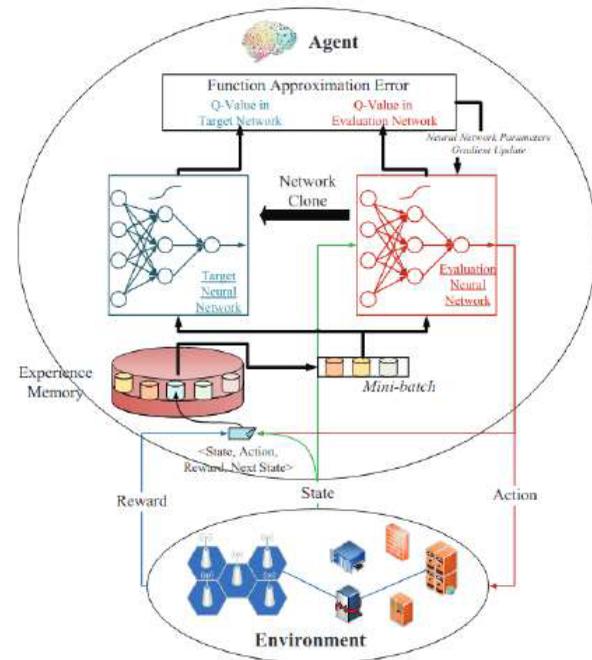


Figura 4.2 extraída de [6]

Utilizar redes neuronales para predecir la función de asignación tiene la virtud de poder obtener modelos que generalicen en entornos de mayor número de estados.

Para la obtención del modelo, el trabajo de tesis se basa fuertemente en el trabajo en [6]. De allí hemos tomado la tupla estado-acción-recompensa como se muestra en la siguiente tabla:

Estado	El número de paquetes arribados en una ventana de tiempo.
Acción	Asignar una distribución de ancho de banda a las <i>slices</i> .
Recompensa	La suma ponderada de la eficiencia espectral de cada <i>slice</i> y la cantidad de usuarios que satisfacen los requerimientos SLA de cada <i>slice</i> .

Tabla 4.2

A partir de lo mencionado anteriormente, se realizaron simulaciones de tráfico y asignación, en base a las cuales nuestro modelo fue aprendiendo una política que maximiza la recompensa de la tabla 4.2. En el caso de DRL, el agente comienza explorando de manera aleatoria la recompensa para distintas acciones. A medida que el tiempo de simulación evoluciona, la acción tomada tiende a ser determinada por el mismo modelo. Es así

que, a través de la experiencia de episodios de asignación, es posible obtener una asignación precisa.

## 5. Resultados parciales y discusión

Se obtuvo un modelo capaz de predecir la asignación entre *slices* que maximiza la recompensa considerada. Como el tamaño y tasa de arribo de paquetes son procesos estacionarios, la asignación de recursos tenderá a seguir una misma distribución. En la figura 5.1 se puede observar en media la distribución de recursos para cada *slice*.



Figura 5.1

Es importante mencionar que el modelo obtenido aplica al escenario descrito, en donde se cuenta con las 3 *slices* con los requerimientos definidos. Sin embargo es rápidamente adaptable a nuevos entornos más complejos.

Asimismo, es posible combinar distintas técnicas de redes neuronales para obtener distintos desempeños, lo cual se continúa estudiando actualmente.



## 6. Conclusiones y trabajo futuro

Se han obtenido resultados muy positivos al momento: utilizando técnicas básicas de DRL es posible obtener una asignación muy eficiente.

El trabajo de investigación continúa en curso. Se espera investigar distintas técnicas que puedan mejorar la velocidad de aprendizaje del algoritmo.

Sumado a lo anterior, se está trabajando en una modificación del problema planteado, al cual se le incorporará la posibilidad de realizar configuración adaptativa de los parámetros de las *slices*. El problema puede ser formulado de la siguiente forma:

$$\text{argmax}_{(w,s)} E\{R(w, s, d)\}$$

$$\text{s.t.: } \begin{aligned} w &= (w_1, \dots, w_N) \\ s &= (s_1, \dots, s_N) \\ d &= (d_1, \dots, d_N) \end{aligned}$$

$$\begin{aligned} w_i &\sim \text{ith slice bandwidth} \\ s_i &\sim \text{ith slice numerology} \\ d_i &\sim \text{ith user traffic model} \end{aligned}$$

El estándar no especifica cómo realizar esta asignación, por lo que da libertad al

proveedor de elegir su propio sistema de asignación. En este sentido, el trabajo abarca temas muy aplicables en el campo de las redes móviles. A su vez, su posible implementación en la industria motiva el desarrollo y la exploración de este tipo de estudios.

## Bibliografía

- [1] Caballero, P., Banchs, A., De Veciana, G., & Costa-Pérez. (2017). Multi-tenant radio access network slicing: Statistical multiplexing of spatial loads. 2022
- [2] Li, R., Zhao, Z., Sun, Q., Chih-Lin, I., Yang, C., Chen, X., ... & Zhang, H.. (2018). Deep reinforcement learning for resource management in network slicing. 2022, Sitio web: <https://ieeexplore.ieee.org/abstract/document/8540003/>
- [3] Banchs, A., de Veciana, G., Sciancalepore, V., & Costa-Perez. (2020). Resource allocation for network slicing in mobile networks. 2022 .Sitio web: <https://ieeexplore.ieee.org/abstract/document/9272281>
- [4] Pereyra, G., Rattaro, C., & Belzarena, P. (2021). A 5G multi-Slice cell capacity framework. In *ACM SIGCOMM 2021*



**"Generación de Conocimiento**  
con Integración Científica, Académica, Tecnológica & Cultural para la Justicia, la Libertad y el Bienestar de Nuestros Pueblos"

**7-8-9 / SEP 2022**



UNIVERSIDAD  
**SAN FRANCISCO XAVIER**  
UNIVERSIDAD DIGNA  
BOLIVIA



**30**  
AÑOS

### *Networking Networking Women*

#### *Professional Development Workshop*

*(N2Women'21), online, 23-27 aug, pp 1-3.*

ACM.

[5] Li, Y. (2017). Deep reinforcement learning: An overview. *arXiv preprint arXiv:1701.07274*.

[6] Li, R., Zhao, Z., Sun, Q., Chih-Lin, I., Yang, C., Chen, X., ... & Zhang, H. (2018). Deep reinforcement learning for resource management in network slicing. *IEEE Access*, 6, 74429-74441.

### Financiamiento

La maestría es financiada por la agencia nacional de investigadores (ANII, <https://www.anii.org.uy/>), en el período de marzo 2021 a marzo 2023.

### Agradecimientos

A mis tutores Claudina Rattaro y Pablo Belzarena por acompañarme en el proceso de investigación y motivarme a continuar en esta línea.