



ESCUELA TÉCNICA SUPERIOR DE INGENIERÍA DE
TELECOMUNICACIÓN

GRADO EN INGENIERÍA EN SISTEMAS DE
TELECOMUNICACIÓN

TRABAJO FIN DE GRADO

**ESTIMACIÓN DE CANAL MEDIANTE “DEEP
LEARNING” EN SISTEMAS 5G CON MIMO
MASIVO**

Autor: Antonio Melgar González

Tutor: Alejandro de la Fuente Iglesias

Cotutor: Óscar Barquero Pérez

Curso académico 2019/2020

Agradecimientos

En primer lugar me gustaría mostrar mi agradecimiento al proyecto "*Inteligencia artificial aplicada para convertir una red radio de telecomunicaciones en predictiva*" en el marco del programa *Vodafone Campus Lab* que financia parcialmente el trabajo realizado en este TFG.

También quiero agradecer a mi tutor Alejandro por haberme brindado la oportunidad de formar parte del equipo de investigación de este proyecto. También le agradezco la ayuda y recursos que me ha proporcionado para la realización de esta memoria, así como su incuestionable implicación como docente.

Del mismo modo, quiero mostrar mi agradecimiento a mi cotutor Óscar por haberme guiado en mis primeros pasos en *deep learning* y por mostrar su gran implicación atendiendo y resolviendo mis cuestiones.

Sin lugar a dudas, me gustaría seguir trabajando con ellos y seguir aprendiendo de estos dos grandísimos profesionales y personas.

Quiero recordar a mis compañeros y amigos de la universidad (S. Asperilla, J. Cañizares, S. Cobos, F. Delgado, E. García de Paso, D. Gil, J. Pérez, A. Reguilón y S. Sánchez) por los momentos difíciles que hemos compartido a lo largo del grado y de los cuales hemos crecido intelectualmente y como personas. Agradecerles también los buenos momentos que hemos pasado dentro y fuera de las aulas que sin duda superan por goleada los momentos complicados.

También agradecer a mis amigos de toda la vida de Loranca, Villardeciervos y Madrid por todo el apoyo que me han dado y los momentos gratos con los que hemos crecido.

Por último, gracias a mis padres y hermana por la confianza que han depositado en mí y el apoyo incondicional que me han dado en todos los ámbitos de mi vida. En especial, quiero agradecer a mis padres la educación recibida y el esfuerzo diario para dar a sus hijos las oportunidades y el ambiente propicio para desarrollarse como personas.

"A son never forgets"

Resumen

Los datos y pronósticos de las grandes empresas confirman el dominio de las redes inalámbricas en los sistemas de telecomunicaciones actuales y futuros. Además, la necesidad de una sociedad moderna cada vez más conectada exige un mayor rendimiento de los sistemas de comunicaciones y una mejor experiencia de usuario. Por ello, los ojos están puestos en la quinta generación de tecnología móvil (5G) que promete tres servicios fundamentales: eMBB (*enhanced Mobile Broadband*), mMTC (*massive Machine-Type Communications*) y URLLC (*Ultra Reliable Low Latency Communications*).

Este TFG se centra en *Massive MU MIMO*, una de las herramientas determinantes para satisfacer el requisito eMBB de las redes 5G. Concretamente se abordará el estudio de la estimación de canal en sistemas *Massive MIMO*, tan necesaria para lograr el correcto cálculo, mediante distintos algoritmos, de la matriz de precodificación que permite servir a distintos usuarios en el mismo recurso tiempo-frecuencia gracias a la técnica SDMA (*Space Division Multiple Access*).

Se simulará en MATLAB canales de un sistema 5G con *Massive MIMO* y mediante la inserción de pilotos se estimarán los coeficientes de canal desconocidos con un interpolador lineal.

Finalmente, debido al buen funcionamiento de las redes neuronales en la detección de características relevantes de los datos y a su aporte de soluciones a problemas tanto de clasificación como de regresión, se propondrá *deep learning* como técnica avanzada de estimación de canal.

Se mostrará una comparativa entre los resultados obtenidos con un interpolador lineal de orden uno desarrollado en MATLAB y los obtenidos mediante modelos de *deep learning* desarrollados con la librería *Keras* en Python, uno de los lenguajes de programación más populares en *data science*.

Índice de contenidos

Capítulo 1. Introducción	1
1.1. Motivación	1
1.1.1. Tendencia hacia las comunicaciones inalámbricas	1
1.1.2. Métodos para aumentar la capacidad de tráfico	2
1.2. Estructura de la memoria	3
Capítulo 2. Fundamentos teóricos de 5G	4
2.1. Visión global de 5G	4
2.2. Requisitos del estándar IMT-2020.....	5
2.3. Tecnologías clave	5
2.4. Capa física	7
2.4.1. Forma de onda	7
2.4.2. Numerología y estructura de la trama.....	9
2.4.3. Recursos físicos	10
Capítulo 3. Massive MU MIMO	11
3.1. Introducción.....	11
3.2. Massive MU MIMO clave para eMMB en 5G	12
3.2.1. Eficiencia espectral y capacidad del canal.....	12
3.2.2. Capacidad de canal de un sistema SISO	12
3.2.3. Aumento de la potencia de transmisión como método de mejora de la eficiencia espectral en sistemas SISO	13
3.2.4. Massive MU MIMO como método de mejora de la eficiencia espectral	16
3.3. Procesamiento de señal en sistemas MU MIMO.....	19
Capítulo 4. Modelo de canal	23
4.1. Introducción.....	23
4.2. CBSM (Correlation-Based Stochastic Model).....	24
4.2.1. Modelo de canal Rayleigh i.i.d.....	24
4.2.2. Modelo de canal Rayleigh correlado.....	25
4.3. GBSM (Geometry-Based Stochastic Models)	27

4.3.1. Modelo de canal 3D del 3GPP.....	28
Capítulo 5. Estimación de canal.....	34
5.1. Introducción.....	34
5.2. Estimación de canal mediante Interpolación Lineal.....	35
5.3. Estimación de canal mediante Redes Neuronales.....	35
Capítulo 6. Simulaciones y resultados.....	42
6.1. Parámetros de simulación de canal.....	42
6.2. Descripción geométrica del problema.....	43
6.3. Resultados obtenidos mediante Interpolación Lineal.....	46
6.4. Resultados obtenidos mediante Redes Neuronales.....	52
Capítulo 7. Conclusiones y líneas futuras.....	68
7.1. Conclusiones.....	68
7.2. Líneas futuras de investigación.....	69
Bibliografía.....	71
Anexos.....	74
A1. Software utilizado.....	74
A1.1. MATLAB.....	74
A1.2. PYTHON.....	74
A2. Lista de acrónimos.....	76
A3. Lista de símbolos.....	78

Índice de figuras

Figura 1. Aplicaciones soportadas por 5G.	5
Figura 2. Espectro de una señal OFDM.	7
Figura 3. Estructura temporal de dos símbolos OFDM.	8
Figura 4. Eficiencia espectral en función de la SNR, para una propagación LOS y $\overline{\beta} = -15$ dB.	16
Figura 5. Escenario <i>Massive MU MIMO</i>	20
Figura 6. Modelo de canal <i>Rayleigh</i> i.i.d, NLOS, con un gran cantidad de objetos dispersivos rodeando la MS y BS.	25
Figura 7. Parámetros clave del modelo de canal <i>Rayleigh</i> correlado.	26
Figura 8. Representación del <i>nonstationary phenomenon</i> y del <i>near-field effect</i> en un modelo GBSM basado en <i>clusters</i>	28
Figura 9. Procedimiento para la generación de los coeficientes de canal.	29
Figura 10. Definición de parámetros para O2O y para O2I.	30
Figura 11. Procedimiento para la interpolación.	35
Figura 12. Diferencia entre la programación clásica y <i>machine learning</i>	36
Figura 13. Funcionamiento básico de una neurona.	37
Figura 14. Ejemplo ilustrativo de una NN básica, donde el superíndice de los pesos (θ) indica la neurona destino y el subíndice indica la neurona origen.	38
Figura 15. Resumen del entrenamiento de una NN.	41
Figura 16. Conjunto de 64 <i>antenna elements</i> con dos polarizaciones cada uno y agrupados en 16 <i>subarrays</i> : 2 (elevación) x 8 (azimut).	43
Figura 17. Representación tensorial del canal.	44
Figura 18. Distribución de pilotos según la especificación de 5G.	45
Figura 19. Método utilizado en esta memoria para mostrar los canales entre un determinado <i>subarray</i> de la BS y la antena de usuario.	46
Figura 20. Estimación mediante interpolación lineal de un canal CDL-A, DS = 32 ns, Fd = 5 Hz y SNR = 25 dB.	47
Figura 21. Estimación mediante interpolación lineal de un canal CDL-A, DS = 32 ns, Fd = 5 Hz y SNR = 25 dB (figura ampliada).	48
Figura 22. Estimación mediante interpolación lineal de un canal CDL-B, DS = 1148 ns, Fd = 120 Hz y SNR = 25 dB.	50
Figura 23. Estimación mediante interpolación lineal de un canal CDL-C, DS = 363 ns, Fd = 70 Hz y SNR = 25 dB.	51
Figura 24. Estimación mediante interpolación lineal de un canal CDL-C, DS = 363 ns, Fd = 70 Hz y SNR = 10 dB.	52
Figura 25. Modelo de red neuronal de ocho capas.	53
Figura 26. Tensor de canal con pilotos distribuidos según la especificación de 5G y ceros en el resto de posiciones.	55
Figura 27. Lista de 120 subtensores de dimensión 24x28x32 y con 1024 pilotos cada uno.	56
Figura 28. Lista de 3840 matrices de dimensión 24x28 y con 32 pilotos cada una.	57
Figura 29. Modelo de red neuronal con cuatro capas.	58
Figura 30. MSE en función del ciclo.	59

Figura 31. Comparativa de estimaciones de un canal CDL-A, DS = 32 ns, Fd = 5 Hz y SNR = 25 dB.	60
Figura 32. MSE en función del ciclo.	60
Figura 33. MSE en función del ciclo (figura ampliada).....	61
Figura 34. Comparativa de estimaciones de un canal CDL-A, DS = 32 ns, Fd = 5 Hz y SNR = 25 dB.	61
Figura 35. MSE en función del ciclo.	62
Figura 36. MSE en función del ciclo (figura ampliada).....	63
Figura 37. Comparativa de estimaciones de un canal CDL-A, DS = 32 ns, Fd = 5 Hz y SNR = 25 dB.	64
Figura 38. MSE en función del ciclo.	65
Figura 39. Comparativa de estimaciones de un canal CDL-B, DS = 1148 ns, Fd = 120 Hz y SNR = 25 dB.	65
Figura 40. MSE en función del ciclo.	66
Figura 41. MSE en función del ciclo (figura ampliada).....	67
Figura 42. Comparativa de estimaciones de un canal CDL-C, DS = 363 ns, Fd = 70 Hz y SNR = 10 dB.	67

Índice de tablas

Tabla 1. Evolución de las redes móviles.	4
Tabla 2. Numerología del Release-15 5G NR.	9
Tabla 3. Tiempo útil del símbolo OFDM, tiempo del CP, número de símbolos OFDM por slot, número de slots por trama, número de slots por subtrama y duración del slot para <i>Normal</i> y <i>Extended CP</i>	10
Tabla 4. Número mínimo y máximo de RBs y ancho de banda mínimo y máximo en función de la numerología.	10
Tabla 5. Tabla de acrónimos.	76
Tabla 6. Tabla de símbolos.	78

Capítulo 1

Introducción

1.1. Motivación

1.1.1. Tendencia hacia las comunicaciones inalámbricas

Queda lejos el tiempo en el que las conexiones entre teléfonos, computadoras y de Internet eran mayoritariamente cableadas y restringidas a determinadas instituciones como bibliotecas, universidades o empresas. La aparición de las redes inalámbricas, tanto las redes móviles de banda ancha (basadas en los estándares GSM, UMTS, LTE y próximamente 5G) como las redes de área local (Wi-Fi, basado en el estándar IEEE 802.11) o las redes satelitales han fomentado el uso masivo de Internet en cualquier parte, en cualquier momento y por cualquiera.

Según los pronósticos de CISCO, el tráfico de las redes inalámbricas (Wi-Fi y redes celulares móviles) representará el 71% del tráfico total de Internet en 2022; a nivel mundial el tráfico de datos móviles aumentará siete veces entre 2017 y 2022, pasando de representar el 9% al 20% del tráfico IP total y alcanzará los 77,5 exabytes por mes. Este enorme crecimiento de la demanda de ancho de banda se debe principalmente a la irrupción del vídeo de alta calidad en Internet; se estima que el *streaming* de contenido multimedia representará el 82% del tráfico total de Internet en 2022 [1].

También hay que tener en cuenta el enorme aumento del número de dispositivos que harán uso de la red, tanto los dedicados a las comunicaciones personales (smatrphones, *smart TV's*, *tablets*, entre otros), como a la comunicación entre dispositivos, también conocido como *Internet of Things* (IoT). En este último grupo se encuentran los sensores inteligentes y, en general, las aplicaciones *machine-to-machine* (M2M) dedicadas a la vigilancia por vídeo o a la monitorización de la atención médica, por ejemplo.

1.1.2. Métodos para aumentar la capacidad de tráfico

El crecimiento exponencial en la demanda de datos obliga a los ingenieros a buscar soluciones que satisfagan las necesidades de la sociedad moderna. La capacidad de tráfico por unidad de área (C_{area}) es un parámetro importante en las redes celulares; se trata de un indicador de la capacidad de estas para soportar un determinado volumen de transferencia de información. Se define mediante la siguiente fórmula:

$$C_{area}(\text{bit} / \text{s} / \text{km}) = B(\text{Hz}) \cdot D(\text{celda} / \text{km}^2) \cdot EE(\text{bit} / \text{s} / \text{Hz} / \text{celda}) \quad (1.1)$$

donde B es el ancho de banda empleado, D es la densidad celular media y EE es la eficiencia espectral de la celda [2]. Un aumento de cualquiera de estas tres variables supone un incremento de la capacidad de tráfico global del sistema.

Para aumentar D , 5G ha estado desarrollando la tecnología de *small cells* dedicada a escenarios *indoor* comunes y a los denominados escenarios *hotspot*, caracterizados por la aglomeración de usuarios en un determinado área (centros comerciales, estadios de fútbol, entre otros). Estos tipos de escenarios presentan grandes diferencias respecto a los macro escenarios que eran considerados de interés primordial por las anteriores tecnologías de redes móviles. La primera de ellas es el menor radio celular (150 metros, por ejemplo), así como la baja movilidad de usuario soportada (0-30 *km/h*), en comparación con el gran radio celular de los macro escenarios, pudiendo superar incluso los 30 *km*, y la alta movilidad que podían alcanzar los usuarios en dicho entorno (350 *km/h* e incluso más). En segundo lugar, la potencia de transmisión desde las *small cells* es varios órdenes de magnitud menor a las de la estación base de un macro escenario. Por último, las características de propagación de un escenario *indoor/hotspot* son diferentes a las de un macro escenario. Todas estas diferencias suponen un impacto en los parámetros de diseño [3].

En el caso de querer incrementar el ancho de banda disponible B , es necesario suplir las desventajas que supone trabajar con altas frecuencias, como puede ser la enorme degradación de la señal que se convierte en un factor crítico en la banda de *mmWave* (24 *GHz* - 52.6 *GHz*), mediante el diseño de *arrays* de antenas y la técnica de conformado de haz (*beamforming*).

Por otra parte, mejorar la eficiencia espectral (EE) permite incrementar la capacidad de tráfico sin la necesidad de crear nuevas infraestructuras o de comprometer la economía del sistema al afrontar el enorme gasto en licencias

para el uso del espectro en altas frecuencias. Justamente es lo que consigue *Massive Multi-User Multiple-Input Multiple-Output (Massive MU MIMO)*, una de las técnicas más prometedoras de la quinta generación de tecnología móvil (5G).

1.2. Estructura de la memoria

Una vez comprendida la situación de la sociedad moderna en el ámbito de las telecomunicaciones, así como la importancia de las comunicaciones inalámbricas, se pasa a describir el contenido de cada una de las secciones de la presente memoria.

En el *capítulo 2*, se enumeran los requisitos impuestos por el estándar IMT-2020 para la red 5G, del mismo modo, se describen los servicios proporcionados y su capa física. Por otra parte, en el *capítulo 3*, se estudia en profundidad *Massive MU MIMO* como técnica de acceso múltiple por división en el espacio (SDMA, por sus siglas en inglés) para el aumento de la eficiencia espectral. A su vez, se detalla el procesamiento de señal necesario, mediante las matrices de precodificación, para dicho fin.

En el *capítulo 4*, se describen distintos modelos de canal para sistemas *Massive MIMO*, desde los modelos más sencillos hasta modelos con mayor complejidad analítica y computacional pero que a su vez reflejan con una mayor fidelidad las características reales de este tipo de sistemas.

En el *capítulo 5* se explicará de forma teórica dos métodos para la estimación de canal; el primero es una estimación clásica mediante un interpolador lineal, mientras que el segundo consiste en resolver un problema de regresión mediante *deep learning*.

En el *capítulo 6*, se exponen los resultados obtenidos de forma práctica en la simulación y estimación de canales *Massive MIMO* mediante interpolación lineal y mediante *deep learning*.

Finalmente, en el *capítulo 7* se redacta una conclusión sobre los resultados obtenidos y sobre las líneas futuras de investigación.

Capítulo 2

Fundamentos teóricos de 5G

2.1. Visión global de 5G

5G es la quinta generación de tecnología móvil, desarrollada como la evolución (*Tabla 1*) de sus predecesoras: GSM/GPRS, UMTS y LTE.

Tabla 1. Evolución de las redes móviles.¹

	1G	2G	3G	4G	5G
<i>Fecha aproximada de despliegue</i>	1980s	1990s	2000s	2010s	2020s
<i>Velocidad teórica de bajada</i>	2kbps	384kbps	56Mbps	1Gbps	10Gbps
<i>Latencia</i>	N/A	629 ms	212 ms	60-98 ms	< 1 ms

5G surge con el objetivo de suplir las necesidades de la sociedad moderna en el ámbito de las telecomunicaciones. Se puede definir como un conjunto de tecnologías y técnicas, desde la capa física hasta el núcleo de red, que forman un sistema y que permite cubrir los tres grandes servicios en demanda [4]:

- *enhanced Mobile Broadband* (eMBB): banda ancha móvil mejorada.
- *massive Machine-Type Communications* (mMTC): comunicación masiva entre dispositivos.
- *Ultra Reliable Low Latency Communications* (URLLC): comunicaciones ultra fiables y de baja latencia.

Las aplicaciones son diversas (por mencionar unas pocas, vídeo en *streaming*, sistemas autónomos de transporte, *smart cities* o realidad aumentada) y van a requerir de uno o cualquier combinación de los tres servicios mencionados anteriormente, como ejemplifica la *Figura 1*.

¹ Fuente [30], pp. 6.

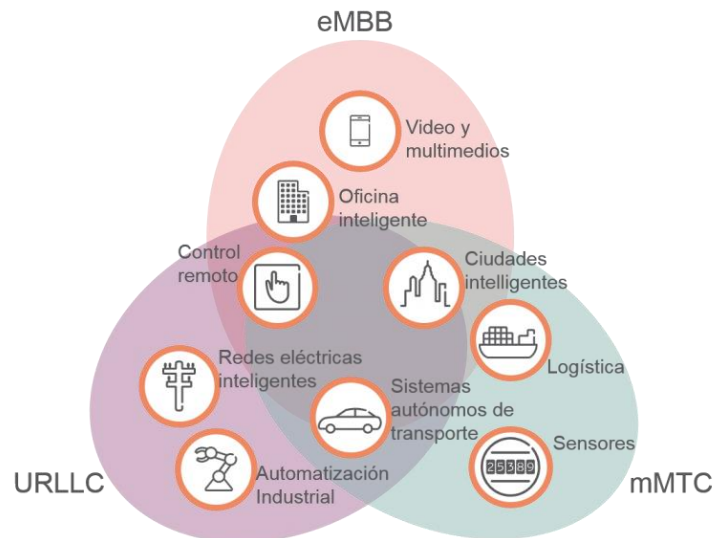


Figura 1. Aplicaciones soportadas por 5G.²

2.2. Requisitos del estándar IMT-2020

La ITU define en el estándar IMT-2020³ una serie de requisitos que debe cumplir 5G, entre los que se incluye una tasa de bit de pico de 20 *Gbit/s*, una tasa de bit experimentada por el usuario de 100 *Mbit/s*, una movilidad máxima permitida de 500 *km/h* para un correcto funcionamiento, una latencia de 1 *ms*, una densidad de conexión de 10⁶ *dispositivos/km²*, una capacidad de tráfico por unidad de área de 10 (*Mbit/s*)/*m²* y una eficiencia espectral y energética tres y cien veces superior, respectivamente, a las de LTE-A.

2.3. Tecnologías clave

- **New spectrum:** con el fin de maximizar el número de recursos en frecuencia, 5G utilizará bandas por encima de los 6 *GHz*. Se empleará anchos de banda de hasta 100 *MHz* para las frecuencias comprendidas entre los 450 *MHz* y 6 *GHz* y de hasta 400 *MHz* para las comprendidas entre los 24 *GHz* y 52.6 *GHz* (*mmWave*) [5].
- **Beamforming:** debido a la operación de los nuevos sistemas en altas frecuencias, es posible implementar paneles con un mayor número de antenas de menor tamaño. En dichas zonas del espectro, la pérdida por propagación de la señal se convierte en un factor limitante a tener en

² Fuente: <https://iotfutura.com/>.

³ Ver "Box 1: Role of IMT 2020 5G and beyond", pp. 4-5 en [30].

cuenta. Por ejemplo, la atenuación debido a la absorción por gases atmosféricos en torno a los 60 GHz es de 10 dB/km, mientras que en la banda de 700 MHz es del orden de 0.01 dB/km [6]. Sin embargo, se puede compensar las pérdidas con el diseño inteligente de *arrays* de antenas y el uso de técnicas de procesado espacial de la señal, en las que se incluye el conformado de haz [7]. Por otra parte, en las bandas por debajo de los 6 GHz, donde las pérdidas por propagación de la señal no es un factor crítico, los sistemas con múltiples antenas pueden emplear el conformado de haz para servir a distintos usuarios en el mismo recurso tiempo-frecuencia mediante técnicas de multiplexación espacial (*Massive MU MIMO*). Tanto la propagación a través del canal, como el hardware de los transceptores o los algoritmos de procesado de señal, son diferentes en función de la banda de frecuencia en la que se trabaje (*mmWave* o por debajo de los 6 GHz) [8].

- ***Slicing and flexibility***: en 5G aparece el concepto de numerología, permitiendo variar el espaciado entre subportadoras (SCS, por sus siglas en inglés), la duración del prefijo cíclico (CP, por sus siglas en inglés) y de los símbolos OFDM (*Orthogonal Frequency Division Multiplexing*) y el número de *slots* por subtrama. Esta flexibilidad resulta interesante para lidiar con distintos escenarios. Por ejemplo, en las bandas de *mmWave*, es posible manejar espaciados entre subportadoras grandes, reduciendo así la latencia al trabajar con símbolos de corta duración. Por otra parte, en bandas por debajo de los 3 GHz, donde no abundan los recursos en frecuencia, es necesario emplear numerologías asociadas con un espaciado entre subportadoras pequeño. Al igual que en escenarios con canales selectivos en frecuencia, el espaciado entre subportadoras y la longitud del CP se debe adaptar al ancho de banda de coherencia del canal. De este modo aparece el concepto de “*Network Slicing*” que consiste en el mantenimiento de diferentes redes lógicas con distinta funcionalidad e independientes en una infraestructura física común; o dicho de otro modo, se puede dividir la red en subredes que manejan aplicaciones de diferente naturaleza.
- ***Dual Connectivity***: permite a un usuario conectarse simultáneamente a dos estaciones base, una es la *Master eNB* (MeNB) y otra es la *Secondary*

eNB (SeNB), que operan en distintas frecuencias y están interconectadas, permitiendo mejorar la capacidad de tráfico de este [9].

- **Mobile Edge Computing:** proporciona servicios de tecnologías de la información y capacidad de *cloud-computing* en el borde de la red móvil, dentro de la red de acceso radio (RAN, por sus siglas en inglés) y muy cerca de los usuarios. El objetivo es reducir la latencia, descargar al núcleo de red y ofrecer una mejor experiencia al usuario [10].

2.4. Capa física

2.4.1. Forma de onda

5G, como se especifica en el *3GPP Release 15*, soporta CP-OFDM (QPSK, 16QAM, 64QAM y 256QAM) tanto en el *downlink* (DL) como en el *uplink* (UL) y DFT-s-OFDM ($\pi/2$ -BPSK, 16QAM, 64QAM y 256QAM) en el UL.

OFDM es un sistema multiportadora muy popular entre las tecnologías de banda ancha actuales como las especializadas en *broadcasting* (DAV, DVB), sistemas cableados (ADSL, PLC), redes inalámbricas de área local (Wi-Fi) o redes móviles (LTE, LTE-A y 5G). Su popularidad se debe a su capacidad para solventar problemas derivados de los canales con memoria que provocan selectividad en frecuencia, así como a la sencillez en su implementación.

Su funcionamiento consiste en modular en QAM o PSK un conjunto de subportadoras ortogonales entre sí con un espaciado óptimo (Δf), entre las consecutivas, igual al inverso del periodo útil del símbolo OFDM (T_u), tal y como muestra la *Figura 2*. De manera que el ancho de banda ocupado por cada una de las subportadoras es menor que el ancho de banda de coherencia del canal, intervalo donde teóricamente el espectro del canal es plano.




Figura 2. Espectro de una señal OFDM.

La señal OFDM banda base se puede expresar en el dominio del tiempo como:

$$X(t) = \sum_{n=-N/2}^{N/2-1} X_n \cdot e^{j2\pi n\Delta f \cdot t} \quad (2.1)$$

donde X_n contiene la información de los símbolos, Δf es el espaciado entre subportadoras adyacentes y N es el número de subportadoras.

En la práctica se trabaja en tiempo discreto y se usa la *Inverse Discrete Fourier Transform* (IDFT) en transmisión para los procesos de modulación y la *Discrete Fourier Transform* (DFT) en recepción para recuperar la información.

Hasta ahora se ha logrado que los símbolos sean transmitidos simultáneamente con un periodo (T_u) mucho mayor que la dispersión temporal máxima del canal (τ_{\max}) o dicho de otra forma, se ha conseguido multiplexar en frecuencia una serie de símbolos mediante subportadoras ortogonales entre sí y ocupando un ancho de banda individual menor al de coherencia del canal; se ha pasado de un canal selectivo en frecuencia a porciones planas del canal. Sin embargo, sigue existiendo interferencia entre símbolos (ISI, por sus siglas en inglés), aunque ya en menor medida, entre los símbolos consecutivos. Para ello, la técnica OFDM añade un tiempo de guarda (T_g), que absorbe la ISI, al comienzo de cada tiempo útil de símbolo (T_u). A la señal transmitida durante el tiempo de guarda se le conoce como CP y coincide con la señal transmitida en la parte final del tiempo útil. De este modo, el periodo del símbolo OFDM consta, como muestra la *Figura 3*, de dos partes: $T_{OFDM} = T_g + T_u$ [11].



Figura 3. Estructura temporal de dos símbolos OFDM.

Al añadir el CP al tiempo útil del símbolo, y suponiendo un canal lineal e invariante en el tiempo (LTI, por sus siglas en inglés), al menos en el tiempo de coherencia para canales móviles, la señal recibida en el receptor pasa de ser una convolución lineal a una convolución circular entre la señal transmitida y la respuesta al impulso del canal:

$$y[n] = h[n] \otimes x[n] = x[n] \otimes h[n] = \sum_l h_l \cdot x[n-l]_N \quad (2.2)$$

donde $y[n]$ es la señal recibida en el receptor, $x[n]$ es la señal OFDM transmitida y $h[n]$ es la respuesta al impulso del canal.

2.4.2. Numerología y estructura de la trama

En la especificación técnica ETSI 138 211 para canales físicos y modulaciones de 5G [12], se define la unidad básica temporal $T_c = 1 / (\Delta f_{\max} \cdot N_f)$, donde $\Delta f_{\max} = 480 \cdot 10^3 \text{ Hz}$ y $N_f = 4096$, empleada para caracterizar temporalmente la estructura de la trama.

5G soporta varias numerologías (μ), cada una está asociada a un SCS y a un tipo de CP, como indica la *Tabla 2*.

Tabla 2. Numerología del Release-15 5G NR.⁴

μ	$\Delta f = 2^\mu \cdot 15(\text{KHz})$	CP type
0	15	Normal
1	30	Normal
2	60	Normal, Extended
3	120	Normal
4	240	Normal

Las transmisiones del UL y del DL están organizadas en tramas de duración $T_f = (\Delta f_{\max} N_f / 100) \cdot T_c = 10 \text{ ms}$; cada trama contiene diez subtramas de duración $T_{sf} = (\Delta f_{\max} N_f / 1000) \cdot T_c = 1 \text{ ms}$. El número de símbolos OFDM por subtrama es $N_{\text{symp}}^{\text{subframe } \mu} = N_{\text{symp}}^{\text{slot}} N_{\text{slot}}^{\text{subframe } \mu}$, donde $N_{\text{symp}}^{\text{slot}}$ depende del tipo de CP y $N_{\text{slot}}^{\text{subframe } \mu} = 2^\mu$ tal y como indica la *Tabla 3*.

⁴ Fuente [12], pp. 9.

Tabla 3. Tiempo útil del símbolo OFDM, tiempo del CP, número de símbolos OFDM por slot, número de slots por trama, número de slots por subtrama y duración del slot para *Normal* y *Extended CP*.⁵

μ	$T_u(\mu_s)$	CP type	$T_{CP}(\mu_s)$	N_{symb}^{slot}	$N_{slot}^{frame\mu}$	$N_{slot}^{subframe\mu}$	$T_{slot}(\mu_s)$
0	66.66	Normal	4.69	14	10	1	1000
1	33.33	Normal	2.34	14	20	2	500
2	16.66	Normal	1.17	14	40	4	250
		Extended	4.16	12			
3	8.33	Normal	0.59	14	80	8	125
4	4.17	Normal	0.29	14	160	16	62.5

2.4.3. Recursos físicos

- **Resource Element (RE):** una subportadora asignada en un símbolo OFDM.
- **Resource Block (RB):** un conjunto de doce REs consecutivos en el dominio de la frecuencia.
- **Resource Grid (RG):** Para cada numerología y portadora se define un RG de $N_{RB}^{\max,\mu} \cdot N_{SC}^{RB}$ subportadoras y $N_{symb}^{subframe,\mu}$ símbolos OFDM.

En 5G se define un número de RBs máximo ($N_{RB}^{\max,\mu}$) y mínimo ($N_{RB}^{\min,\mu}$) con sus correspondientes anchos de banda máximo (BW_{\max}) y mínimo (BW_{\min}), respectivamente, en función de la numerología, tal y como se expone en la *Tabla 4*.

Tabla 4. Número mínimo y máximo de RBs y ancho de banda mínimo y máximo en función de la numerología.

μ	$\Delta f(KHz)$	$N_{RB}^{\min,\mu}$	$BW_{\min}(MHz)$	$N_{RB}^{\max,\mu}$	$BW_{\max}(MHz)$
0	15	20	3.6	275	49.5
1	30	20	7.2	275	99
2	60	20	14.4	275	198
3	120	20	28.8	275	396
4	240	20	57.6	138	397.44

⁵ Fuente [12], pp. 10-11.

Capítulo 3

Massive MU MIMO

3.1. Introducción

Massive MIMO es una tecnología clave para las nuevas generaciones de comunicaciones inalámbricas (5G, entre ellas) que consiste en equipar a la estación base (BS, por sus siglas en inglés) con un gran número de antenas permitiendo la comunicación de diferente información, entre un mismo usuario (*Massive Single-User MIMO*) o entre distintos usuarios (*Massive MU MIMO*) y usando el mismo recurso tiempo-frecuencia (RE) mediante la multiplexación en el espacio (SDMA).

Además de mejorar la eficiencia espectral, el manejo de múltiples antenas dota al sistema de diversidad espacial lo que se traduce en un aumento de la eficiencia energética, permitiendo a una estación móvil (MS, por sus siglas en inglés) transmitir con una menor potencia para comunicarse con la BS, por ejemplo.

Sin embargo, esta memoria está orientada al empleo de la tecnología para obtener ganancias en la eficiencia espectral y, en concreto, a sistemas *Massive MU MIMO*, determinantes para lograr el servicio eMBB en las redes 5G. En este tipo de sistemas se supone un número de antenas en la BS mucho mayor al número de usuarios en una celda (o al menos mucho mayor al número de usuarios que van a ser atendidos en el mismo recurso tiempo-frecuencia), lo que permite trabajar con un mayor grado de libertad para crear haces muy directivos suprimiendo así la interferencia entre usuarios de la misma celda. Así mismo, se supone el uso de la técnica *Time-Division Duplexing* (TDD) que permite manejar el mismo *Channel State Information* (CSI) en el UL y DL (al menos, durante el tiempo de coherencia en escenarios móviles), fundamental para la estimación del canal.

3.2. Massive MU MIMO clave para eMMB en 5G

En este apartado se compararán dos métodos para mejorar la eficiencia espectral del sistema: el primero consiste en aumentar la potencia de transmisión en un sistema *Simple-Input Simple-Output* (SISO), mientras que el segundo consiste en introducir un *array* de antenas en la BS para servir a múltiples usuarios separados espacialmente (sistema MU MIMO). Mediante la comparativa se tomará conciencia del enorme potencial de *Massive MU MIMO* como herramienta de mejora de la eficiencia espectral.

Se comenzará definiendo la eficiencia espectral y la capacidad de canal para comprender la relación que mantienen.

3.2.1. Eficiencia espectral y capacidad del canal

Suponiendo un ancho de banda del canal de B Hz y una representación paso bajo y discreta de la señal, es posible una tasa de transmisión de hasta B muestras complejas y equidistantes por segundo. La eficiencia espectral indica la media del número de bits transmitidos en cada una de las muestras complejas; por tanto, la unidad de medida son los bits por segundo por Hertzio o *bits / s / Hz*.

Un parámetro fundamental en cualquier sistema de comunicación es la capacidad de canal que determina la máxima eficiencia espectral alcanzable, bajo ciertas condiciones, garantizando la fiabilidad (baja tasa de error) del sistema [13].

3.2.2. Capacidad de canal de un sistema SISO

Si se considera un canal sin memoria con una señal de entrada $x \in \mathbb{C}$ y una señal de salida $y \in \mathbb{C}$ obtenida de:

$$y = hx + n + v \quad (3.1)$$

donde $n + v \sim N_{\mathbb{C}}(0, \sigma^2 + \nu^2)$ es la suma del ruido gaussiano blanco de potencia σ^2 con la señal interferente de potencia ν^2 y $h \in \mathbb{C}$ es la respuesta al impulso del canal considerándose conocida en el receptor.⁶ Entonces, la capacidad de canal, si h es determinista, viene dada por:

⁶ Las comunicaciones inalámbricas presentan por naturaleza canales con memoria, debido a la presencia de obstáculos entre los extremos que provocan numerosas reflexiones de la señal

$$C = \log_2 \left(1 + \frac{p_t |h|^2}{\sigma^2 + \nu^2} \right) \frac{\text{bit} / \text{s}}{\text{Hz}} \quad (3.2)$$

donde p_t es la potencia media de la señal de entrada x .

Si h es una realización de la variable aleatoria H , independiente de la señal de entrada y del ruido más interferencia:

$$C = E \left\{ \log_2 \left(1 + \frac{p_t |h|^2}{\sigma^2 + \nu^2} \right) \right\} \frac{\text{bit} / \text{s}}{\text{Hz}} \quad (3.3)$$

La expresión $\frac{p_t |h|^2}{\sigma^2 + \nu^2}$ es conocida como la *signal-to-interference-plus-noise ratio* (SINR) y es la que determina la eficiencia espectral máxima de los sistemas SISO.

3.2.3. Aumento de la potencia de transmisión como método de mejora de la eficiencia espectral en sistemas SISO⁷

Se considera ahora un escenario en el DL, simple pero válido para mostrar las propiedades de un sistema SISO, consistente en dos celdas (*celda 0* y *celda 1*) con una estación móvil activa en cada una de ellas.

La ganancia media de canal desde la BS de la *celda 0* hasta la MS a la que da servicio es representada por β_0^0 , mientras que la ganancia media de canal de la señal interferente desde la BS de la *celda 1* hasta la MS de la *celda 0* es representada por β_1^0 . De forma similar, β_1^1 representa la ganancia media de canal de la señal deseada desde la BS de la *celda 1* hasta la MS de su misma celda, mientras que β_0^1 representa la ganancia media de canal de la señal interferente desde la BS de la *celda 0* hasta la MS de la *celda 1*. Por simplicidad, se asume que las ganancias de canal de las señales deseadas son iguales en ambas celdas ($\beta_0^0 = \beta_1^1$), al igual que las interferentes ($\beta_1^0 = \beta_0^1$). Definimos el ratio

transmitida llegando copias, en distintos instantes temporales, al receptor. Sin embargo, con OFDM (visto en la *sección 2.4.1*) los símbolos son de mucha mayor duración que la dispersión temporal del canal, convirtiendo el canal inalámbrico con memoria en un canal sin memoria. Por otra parte, las señales interferentes pueden ser consideradas como una fuente de ruido aditivo al gaussiano blanco cuando su potencia es mucho menor que la de la señal deseada, condición propia de los sistemas reales bien diseñados.

⁷ Ver "1.3 Ways to Improve the Spectral Efficiency", pp. 172-180 en [2].

$\bar{\beta} = \frac{\beta_1^0}{\beta_0^0} = \frac{\beta_0^1}{\beta_1^1}$, donde $0 \leq \bar{\beta} \leq 1$. Si $\bar{\beta} = 0$ significa que no hay señal interferente, mientras que si $\bar{\beta} = 1$ significa que la potencia de la señal interferente es igual a la deseada, ya que ambas BS transmiten con la misma potencia.

La señal recibida $y_0 \in \mathbb{C}$ en la MS de la *celda 0* es:

$$y_0 = h_0^0 x_0 + h_1^0 x_1 + n_0 \quad (3.4)$$

donde $h_0^0 x_0$ representa la señal deseada recibida, $h_1^0 x_1$ representa la señal interferente recibida, x_0 y x_1 representan el símbolo deseado e interferente respectivamente con potencia media p_i y $n_0 \sim N_{\mathbb{C}}(0, \sigma^2)$ representa el ruido aditivo gaussiano blanco. La respuesta del canal $h_i^0, i = 0, 1$, depende del tipo de propagación.

En el caso *Line of Sight* (LOS), la respuesta del canal se modela como:

$$h_i^0 = \sqrt{\beta_i^0}, i = 0, 1 \quad (3.5)$$

donde β_i^0 puede ser interpretado como el desvanecimiento a gran escala causado por las pérdidas de propagación. Para el caso *Non Line of Sight* (NLOS) la respuesta del canal se modela como:

$$h_i^0 = \mathbb{N}_{\mathbb{C}}(0, \beta_i^0), i = 0, 1 \quad (3.6)$$

donde β_i^0 vuelve a reproducir el efecto del desvanecimiento a gran escala, mientras que el desvanecimiento a pequeña escala está representado por la distribución gaussiana de la respuesta del canal. Ello es debido al *Teorema Central del Límite*, en el que se demuestra que la suma de múltiples variables aleatorias complejas (múltiples reflexiones) provoca una distribución gaussiana de la componente real y compleja del canal y una amplitud distribuida como *Rayleigh* [14].

Para el caso LOS y siguiendo la *ecuación 3.2* la máxima eficiencia espectral alcanzable (capacidad de canal) en el DL de la *celda 0* se calcula como:

$$C_{Los} = \log_2 \left(1 + \frac{p_t |h_0^0|^2}{\sigma^2 + p_t |h_1^0|^2} \right) = \log_2 \left(1 + \frac{p_t \beta_0^0}{\sigma^2 + p_t \beta_1^0} \right) =$$

$$= \log_2 \left(1 + \frac{p_t \frac{\beta_0^0}{\beta_0^0}}{p_t \left(\frac{\sigma^2}{p_t \beta_0^0} + \frac{\beta_1^0}{\beta_0^0} \right)} \right) = \log_2 \left(1 + \frac{1}{\frac{1}{SNR_0} + \bar{\beta}} \right) \frac{bit / s}{Hz} \quad (3.7)$$

donde $SNR_0 = \frac{p_t \beta_0^0}{\sigma^2}$ es la relación señal a ruido (*signal-to-noise ratio*) entre la BS de la celda 0 y la MS a la que da servicio y $\bar{\beta} = \frac{\beta_1^0}{\beta_0^0}$ es el ratio de la ganancia de canal interferente y deseado (definido anteriormente).

Se aprecia en la *ecuación 3.7* que la eficiencia espectral máxima en una propagación LOS queda determinada por la $SINR = \frac{p_t \beta_0^0}{p_t \beta_1^0 + \sigma^2}$. Un método para aumentar la capacidad es, por tanto, aumentar la potencia de transmisión, ya que la pérdida por propagación de la señal interferente suele ser, si el sistema está bien diseñado, mucho mayor que la de la señal deseada ($\beta_1^0 \ll \beta_0^0$). Sin embargo, al ser aumentada infinitamente, la capacidad converge hacia:

$$C_{LoS} = \log_2 \left(1 + \frac{\beta_0^0}{\beta_1^0} \right) = \log_2 \left(1 + \frac{1}{\bar{\beta}} \right) \frac{bit / s}{Hz} \quad p_t \rightarrow \infty \quad (3.8)$$

Es decir, por mucho que se aumente la potencia de transmisión de la señal deseada, del mismo modo aumenta la potencia de transmisión de la señal interferente, como es común en los sistemas reales de comunicaciones que garantizan una calidad de servicio apropiada, hasta converger hacia un valor dependiente de la inversa del ratio de la ganancia de canal interferente y deseado. Por ejemplo, para $\bar{\beta} = -15 \text{ dB}$, lo que significa que el canal interferente provoca un desvanecimiento a gran escala 32 veces mayor de la señal interferente respecto al canal de la señal deseada, la eficiencia espectral máxima converge a $5.03 \text{ bit} / \text{s} / \text{Hz}$.

Se concluye, por tanto, que aumentar la potencia de transmisión permite aumentar la eficiencia espectral hasta un determinado valor, definido por el cociente entre la ganancia de canal de la señal interferente y la ganancia de canal de la señal deseada ($\bar{\beta}$). A partir de dicho valor, la eficiencia espectral permanece constante independientemente del crecimiento de la potencia, como se muestra en la *Figura 4*.




Figura 4. Eficiencia espectral en función de la SNR, para una propagación LOS y $\bar{\beta} = -15$ dB.⁸

El escenario estudiado en este último apartado ha sido en el DL, los resultados son igualmente aplicables para el UL (teniendo en cuenta que la potencia de transmisión en el DL suele ser mayor a la del UL), ya que un sistema SISO implica el uso de una única antena tanto en la BS como en la MS.

El cálculo de la capacidad de canal para una propagación NLOS sigue un procedimiento similar al estudiado para el caso LOS. Sin embargo, la ecuación a la que se llega es más compleja y menos intuitiva, por ello se ha elegido la propagación LOS como ejemplo para ilustrar las limitaciones de mejora en la eficiencia espectral mediante el aumento de la potencia de transmisión.

3.2.4. Massive MU MIMO como método de mejora de la eficiencia espectral

Una forma de obtener ganancia en la eficiencia espectral es mediante el modelo de canal MIMO con un único usuario (SU MIMO). En dicho sistema, la capacidad de canal máxima alcanzable es aproximadamente $\min(M_t, M_r)$ veces la capacidad de un sistema SISO (ecuación 3.2), donde M_t y M_r es el número de antenas en transmisión y en recepción respectivamente.

Sin embargo, para obtener dicha ganancia de capacidad en un sistema SU MIMO es necesario el empleo de múltiples antenas tanto en la BS como en la MS,

⁸ Gráfica obtenida tras modificaciones del código de MATLAB disponible en: https://github.com/emilbjornson/massivemimobook/blob/master/Code/section1_figure9.m.

además de una condición favorable en la propagación de la señal que produzca canales ortogonales e independientes entre sí en el espacio. Estas condiciones son difíciles de alcanzar en los sistemas actuales. Los dispositivos móviles no pueden contener muchas antenas debido a su pequeño tamaño y a otros aspectos como el ahorro de energía; por otra parte, la separación entre sus antenas no puede ser muy grande lo que conduce a situaciones en la que los distintos canales presentan correlación y son difícilmente separables espacialmente, como puede ser en un escenario con línea de visión directa (LOS).

Por estos motivos, las nuevas generaciones de sistemas de comunicaciones apuestan por MIMO con múltiples usuarios (MU MIMO). Aún con el uso de una única antena en las estaciones móviles (pueden tener más), es posible agrupar distintos usuarios con el fin de formar un *array* de antenas virtual y obtener así enormes ganancias en la eficiencia espectral. Además, este método presenta la ventaja de que la BS puede seleccionar usuarios fácilmente separables en el espacio, con canales ortogonales, y así no depender de condiciones de propagación óptimas para alcanzar su máximo potencial (como es el caso de los sistemas SU MIMO).

Se considera ahora un escenario de un sistema MU MIMO en el UL, con una celda y una BS contenida en ella. La BS está constituida por un *array* de M antenas y da servicios a K usuarios en la celda. El coeficiente de canal desde el k-usuario hasta la m-antena está representado por $h_{k,m}$, que es igual a un valor complejo que reproduce el desvanecimiento a pequeña escala y un factor de atenuación como consecuencia del desvanecimiento a gran escala:

$$h_{k,m} = g_{k,m} \sqrt{\beta_{k,m}} \quad (3.9)$$

donde $g_{k,m}$ y $\beta_{k,m}$ representan el coeficiente de desvanecimiento a pequeña y gran escala respectivamente. El coeficiente de desvanecimiento a pequeña escala se considera una variable i.i.d (independiente e idénticamente distribuido) entre distintas antenas y usuarios, mientras que el coeficiente de desvanecimiento a gran escala es el mismo entre un usuario y las distintas antenas de BS pero independiente entre distintos usuarios.

La matriz del canal H queda, por tanto, definida como:

$$H = \begin{pmatrix} h_{1,1} & \cdots & h_{1,K} \\ \vdots & \ddots & \vdots \\ h_{M,1} & \cdots & h_{M,K} \end{pmatrix} = G\beta^{1/2} \quad (3.10)$$

donde

$$G = \begin{pmatrix} g_{1,1} & \cdots & g_{1,K} \\ \vdots & \ddots & \vdots \\ g_{M,1} & \cdots & g_{M,K} \end{pmatrix} \quad \beta = \begin{pmatrix} \beta_{1,1} & & \\ & \ddots & \\ & & \beta_{K,K} \end{pmatrix} \quad (3.11)$$

La señal recibida en el UL es, por tanto:

$$y = Hx + n \quad (3.12)$$

donde $y \in \mathbb{C}^{M \times 1}$ es la señal que llega a la BS, $x \in \mathbb{C}^{K \times 1}$ es el vector de símbolos de los distintos usuarios con potencia media de transmisión p_t , $n \in \mathbb{C}^{M \times 1}$ es el vector ruido aditivo gaussiano blanco con matriz de covarianza igual a la matriz identidad y $H \in \mathbb{C}^{M \times K}$ es la matriz de canal definida en la ecuación 3.10.

Teniendo en cuenta las asunciones del escenario tratado, se llega a la siguiente fórmula de capacidad de canal de un sistema MU MIMO [15]:

$$C = \sum_{k=1}^K \log_2(1 + M \cdot p_t \cdot \beta_k) \frac{\text{bit} / s}{\text{Hz}} \quad (3.13)$$

donde M es el número de antenas de la BS, K es el número de usuarios multiplexados espacialmente, p_t es la potencia de transmisión en el UL y β_k es el coeficiente de desvanecimiento de gran escala definido en la ecuación 3.11.

De la ecuación 3.13 se puede deducir, en primer lugar, que la capacidad de un sistema MU MIMO depende del número de antenas en la estación base. Al aumentar el número de antenas es más fácil separar la información de los distintos usuarios en recepción, siendo procesados como si de un canal SISO se tratase. En segundo lugar, la capacidad total del sistema es el sumatorio de las capacidades de los K usuarios, donde la capacidad del usuario k dependen de su propia SNR ($M \cdot p_t \cdot \beta_k$). Este hecho difiere de los sistemas SU MIMO donde la capacidad alcanzable, en condiciones de propagación favorables, resulta de la multiplicación de un escalar ($\min(M_t, M_r)$) con la capacidad de su equivalente SISO.

Como se ha comentado, un parámetro importante en la capacidad de un sistema MU MIMO es el número de antenas de la BS. Es más, la capacidad alcanzable mostrada en la *ecuación 3.13* es cierta suponiendo que el número de antenas de la BS (M) es mucho mayor que el número de usuarios a los que sirve (K). Cuanto más grande sea dicha diferencia más fácil será separar espacialmente los distintos flujos de información de cada usuario en recepción. Del mismo modo, la BS estará más capacitada para crear haces más directivos en el DL, logrando separar mejor a los usuarios en el espacio y reducir, de este modo, la interferencia entre éstos. Por ello, los sistemas modernos trabajan con *Massive MU MIMO*, que consiste en equipar a la BS de una gran cantidad de antenas (hasta cientos).

Por último, se debe destacar que frente al aumento en la potencia de transmisión (p_i) que presenta un valor de convergencia en la mejora de la capacidad de canal, el potencial de *Massive MU MIMO* es ilimitado en este aspecto. La capacidad de canal se verá aumentada cuantas más antenas se usen en la BS y cuantos más usuarios sean servidos en el mismo recurso tiempo-frecuencia. El límite de esta tecnología puede estar impuesto por factores físicos (tamaño de antena y BS) y/o económicos.

3.3. Procesamiento de señal en sistemas MU MIMO

Hasta ahora se ha ilustrado al lector sobre la importancia de la tecnología *MU Massive MIMO* como método para conseguir mejorar la eficiencia espectral y así satisfacer el servicio eMBB en las redes 5G. En este apartado se explicará el procesamiento de señal necesario en este tipo de sistemas para servir a diferentes usuarios en el mismo recurso tiempo-frecuencia.

La multiplexación espacial consiste en generar un conjunto de L capas no interferentes entre los distintos usuarios. El número máximo de capas no interferentes entre sí es $L_{\max} = \min(M, K)$, donde M es el número de antenas en la BS y K es el número de usuarios multiplexados espacialmente (en sistemas *Massive MU MIMO* se supone que $M \gg K$). L_{\max} es alcanzable cuando los canales están incorrelados (propio de los sistemas *Massive MU MIMO* donde la BS selecciona K usuarios con buena separación espacial) y cuando se paraleliza (ortogonaliza) convenientemente el canal.

Se supone ahora un escenario *Massive MU MIMO* en el DL con M antenas en la BS y K usuarios, con una única antena cada uno, multiplexados

espacialmente, como ejemplifica la *Figura 5*. Se supone también, por simplicidad, un canal invariante en el tiempo y plano en frecuencia, además de un perfecto conocimiento del canal tanto en transmisión como en recepción.




Figura 5. Escenario *Massive MU MIMO*.⁹

La señal recibida (sin aplicar ningún tipo de procesamiento) en el receptor es:

$$y = Hx + n \rightarrow \begin{pmatrix} y_1 \\ \vdots \\ y_K \end{pmatrix} = \begin{pmatrix} h_{11} & \dots & h_{1M} \\ \vdots & \ddots & \vdots \\ h_{K1} & \dots & h_{KM} \end{pmatrix} \begin{pmatrix} x_1 \\ \vdots \\ x_M \end{pmatrix} + \begin{pmatrix} n_1 \\ \vdots \\ n_K \end{pmatrix} \quad (3.14)$$

donde $y \in \mathbb{C}^{K \times 1}$ es un vector donde cada posición representa la señal recibida en el k ($k = 1 \dots K$) usuario, $x \in \mathbb{C}^{M \times 1}$ es un vector con los símbolos enviados por cada m ($m = 1 \dots M$) antena de la BS, $n \in \mathbb{C}^{K \times 1}$ representa el vector de ruido gaussiano blanco aditivo a cada k usuario y, finalmente, $H \in \mathbb{C}^{K \times M}$ es la matriz con los coeficientes de canal, donde el elemento $h_{k,m}$ representa el coeficiente de canal desde la antena m de la BS hasta el k usuario.

Como se observa en la *ecuación 3.14*, la señal recibida por cada usuario (vector y) es una combinación de todas las señales enviadas desde cada antena m de la BS (una combinación de señal deseada con señales interferentes), por ejemplo la señal recibida por el $k = 1$ usuario es $y_1 = (h_{11}x_1 + h_{12}x_2 + \dots + h_{1M}x_M)$.

A continuación, por simplicidad en el cálculo, se supone que $M = K$; es decir, que el número de antenas en la BS es igual al número de usuarios. Se sabe que esto no es cierto en sistemas *Massive MU MIMO*, donde $M \gg K$ ayuda a

⁹ Fuente: <https://www.sharetechnote.com/>.

crear haces con una gran directividad, suprimiendo así la interferencia entre usuarios. Sin embargo, la suposición de una matriz cuadrada ayudará a comprender mejor el mecanismo para ortogonalizar canales. Dicho esto y suponiendo, como hemos comentado antes, que la BS conoce perfectamente el estado del canal, mediante un procesamiento de la señal transmitida es posible crear canales ortogonales entre los usuarios para que a cada uno le llegue su información de interés. Este procesamiento se conoce como precodificación. Si la matriz de precodificación es W , la señal recibida pasa a ser:

$$y = HWx + n \rightarrow \begin{pmatrix} y_1 \\ \vdots \\ y_K \end{pmatrix} = \begin{pmatrix} h_{11} & \dots & h_{1M} \\ \vdots & \ddots & \vdots \\ h_{K1} & \dots & h_{KM} \end{pmatrix} \begin{pmatrix} w_{11} & \dots & w_{1M} \\ \vdots & \ddots & \vdots \\ w_{K1} & \dots & w_{KM} \end{pmatrix} \begin{pmatrix} x_1 \\ \vdots \\ x_M \end{pmatrix} + \begin{pmatrix} n_1 \\ \vdots \\ n_K \end{pmatrix} \quad (3.15)$$

Como se ha supuesto que tanto H como W son matrices cuadradas (de dimensión $K \times K = M \times M$), una elección inteligente de W sería la inversa de H .

La señal recibida se convierte en:

$$y = HH^{-1}x + n = Ix + n \rightarrow \begin{pmatrix} y_1 \\ \vdots \\ y_K \end{pmatrix} = \begin{pmatrix} 1 & 0 & 0 \\ 0 & \ddots & 0 \\ 0 & 0 & 1 \end{pmatrix} \begin{pmatrix} x_1 \\ \vdots \\ x_K \end{pmatrix} + \begin{pmatrix} n_1 \\ \vdots \\ n_K \end{pmatrix} \quad (3.16)$$

donde I es la matriz identidad. De este modo, la señal correspondiente a cada k usuario es su símbolo de interés (x_k) con el ruido aditivo gaussiano.

Este método para ortogonalizar los canales se le conoce como ZF (*Zero Forcing*) y consiste en calcular W como la inversa del canal (H^{-1}). Sin embargo, como se ha mencionado anteriormente, en sistemas *Massive MU MIMO* la BS está equipada con un número de antenas (M) mucho mayor al número de usuarios (K) a los que sirve en el mismo recurso tiempo-frecuencia. En este caso, la matriz de precodificación de ZF pasa a ser la *pseudoinversa de Moore-Penrose* ($W_{ZF} = (H^H H)^{-1} H^H$).

Además de ZF existen otras técnicas de precodificación como puede ser, entre otras, MMSE (*Minimum Mean Squared Error*), cada una con sus pros y contras [16]. Si cada usuario posee más de una antena, es necesario, realizar otro procesamiento de la señal en recepción, lo mismo ocurre para el UL.

Para dar por concluida esta sección, se debe enfatizar en la importancia del conocimiento del canal tanto en transmisión como en recepción para poder

crear canales ortogonales permitiendo separar en el espacio a los usuarios. Este conocimiento se logra mediante la estimación, insertando pilotos en determinadas subportadoras y cada cierto tiempo. Una mala estimación del canal, provoca que en la *ecuación 3.16*, $\mathbf{H}\mathbf{H}^H \neq \mathbf{I}$ obteniendo un vector de señal de salida (y) con interferencia entre símbolos.

Los posteriores capítulos tratarán sobre el modelado de canal en sistemas MIMO y su correspondiente estimación.

Capítulo 4

Modelo de canal

4.1. Introducción

La evaluación de las prestaciones de un sistema de telecomunicación en función de sus parámetros y bloques que lo constituyen puede llevarse a cabo de forma experimental mediante prototipos del sistema o con simulaciones. Las primeras fases de desarrollo del sistema están caracterizadas por la necesidad de continuas pruebas y cambios, mientras que las etapas finales consisten en pequeños ajustes de algunos parámetros. Debido a factores económicos se suele descartar el análisis mediante prototipos de los sistemas durante las primeras etapas. Por este motivo, resulta interesante el estudio de las prestaciones de un sistema mediante simulaciones.

Previo al análisis mediante la simulación del sistema de comunicaciones, es necesario el modelado de canal. El modelo de canal empleado debe representar con la mayor exactitud posible los efectos del canal real sobre las señales que lo atraviesan. Además de la importancia de la fidelidad del modelo respecto a la realidad, debe ser lo más sencillo y con el menor coste computacional posible. En el caso de las comunicaciones inalámbricas de banda ancha, el modelo de canal debe simular los efectos del multitrayecto (desvanecimiento a pequeña escala), las pérdidas por propagación de la señal (desvanecimiento a gran escala) y otros como el desvanecimiento de la señal debido a la presencia de obstáculos (*shadow fading*). En los sistemas MIMO es necesario, además, considerar las propiedades geométricas del canal: ángulo de llegada y salida, ángulo de incidencia en los obstáculos, geometría del *array* de antenas empleado (lineal, rectangular, cilíndrico, esférico), entre otras.

En este capítulo se estudiarán dos modelos de canal: el *Correlation-Based Stochastic Model* (CBSM) y el *Geometry-Based Stochastic Model* (GBSM). El primero es un modelo empleado a nivel teórico debido a su simplicidad analítica y computacional, mientras que el segundo es un modelo complejo pero que a su vez representa con una mayor fidelidad las propiedades de los sistemas reales

MIMO. Por ello, a nivel práctico, para el estudio de las prestaciones, es preferible recurrir a dicho modelo.

4.2. CBSM (Correlation-Based Stochastic Model)

Se considera un sistema MIMO con K usuarios, cada uno con una única antena, que se comunican en el UL y de forma simultánea con la BS, equipada con M antenas. Si además se supone NLOS, el modelo de canal puede ser representado por la matriz $H \in \mathbb{C}^{M \times K}$:

$$H = \begin{pmatrix} h_{1,1} & \cdots & h_{1,K} \\ \vdots & \ddots & \vdots \\ h_{M,1} & \cdots & h_{M,K} \end{pmatrix} = G\beta^{1/2} \quad (4.1)$$

donde $\beta = \text{diag} \{ \beta_1, \beta_1, \dots, \beta_K \}$ representa el desvanecimiento a gran escala, con $\beta_k = \gamma d_k^{-\alpha} \xi_k$. γ es una constante que guarda relación con la ganancia de la antena y la frecuencia central de trabajo, d_k es la distancia entre el k ($k=1,2,\dots,K$) usuario y la BS, α es el exponente de pérdida por propagación de la señal y ξ_k expresa el *shadow fading* entre el k usuario y la BS. $G \in \mathbb{C}^{M \times K}$ representa el desvanecimiento a pequeña escala del canal.

En función de la matriz G , el modelo de canal CBSM se puede clasificar en un modelo de canal *Rayleigh i.i.d* o en un modelo de canal *Rayleigh correlado*.

4.2.1. Modelo de canal Rayleigh i.i.d

La matriz G del modelo de canal *Rayleigh i.i.d* contiene elementos incorrelados tanto entre usuarios como entre antenas. Cada elemento de la matriz G es un número complejo cuya parte real e imaginaria, según el *Teorema Central del Límite* [14], sigue una distribución gaussiana ($g_{m,k} \sim N_{\mathbb{C}}(0,1)$, $m=1,\dots,M$ y $k=1,\dots,K$) y una amplitud distribuida como *Rayleigh*. Este modelo es válido en un escenario donde tanto la MS como la BS están rodeadas de muchos objetos dispersivos, en comparación con el número de antenas M del *array*, que provocan una enorme cantidad de reflexiones de la señal transmitida, tal y como muestra la *Figura 6*.




Figura 6. Modelo de canal *Rayleigh* i.i.d, NLOS, con un gran cantidad de objetos dispersivos rodeando la MS y BS.¹⁰

Una característica importante de este tipo de canal es su condición de propagación favorable que permite crear canales ortogonales entre las distintas MS, maximizando la capacidad del sistema y minimizando la interferencia entre usuarios:

$$\frac{1}{M} h_k^H h_{k'} \approx \begin{cases} 0, & k \neq k' \\ 1, & k = k' \end{cases} \quad (4.2)$$

Además, en el caso de disponer de un *array* de antenas en la MS, debido a esta condición, también es posible la multiplexación espacial de forma eficiente entre la BS y un único usuario.

4.2.2. Modelo de canal *Rayleigh* correlado

En la mayoría de escenarios reales el menor entorno dispersivo y el insuficiente espaciado entre antenas provocan la necesidad de considerar la correlación de la señal entre las distintas antenas transmisoras y receptoras. En el modelo de canal *Rayleigh* correlado el vector de desvanecimiento a pequeña escala del k usuario ($g_k \in \mathbb{C}^{M \times 1}$ para $k = 1 \dots K$) está compuesto por la multiplicación de la matriz de correlación y un vector gaussiano complejo:

$$g_k = R_k v_k, \quad k = 1 \dots K \quad (4.3)$$

donde $R_k \in \mathbb{C}^{M \times N_{path}}$ es la matriz de correlación y $v_k \sim N_{\mathbb{C}}(0, I_{N_{path}})$ expresa la ganancia y rotación en fase de cada componente multitrayecto. Suponiendo un *array* de antenas lineal, R_k es:

¹⁰ Fuente [2], pp. 183.

$$R_k = \left[r(\theta_{k,1}), r(\theta_{k,2}), \dots, r(\theta_{k,N_{path}}) \right] \quad (4.4)$$

donde $r(\theta_{k,n}) \in \mathbb{C}^{M \times 1}$ es el vector de correlación del n componente multitrayecto:

$$r(\theta_{k,n}) = [1, e^{(j2\pi d_a/\lambda)\sin(\varphi_{k,n})}, \dots, e^{(j2\pi d_a/\lambda)(M-1)\sin(\varphi_{k,n})}]^T \quad (4.5)$$

donde d_a es la distancia entre antenas adyacentes, λ es la longitud de onda y φ_n es el ángulo de llegada (AoA, por sus siglas en inglés) del n componente multitrayecto.

Otro método de representar g_k , tal vez de forma más intuitiva, es:

$$g_k = \sum_{n=1}^{N_{path}} v_{k,n} [1, e^{(j2\pi d_a/\lambda)\sin(\varphi_{k,n})}, \dots, e^{(j2\pi d_a/\lambda)(M-1)\sin(\varphi_{k,n})}]^T \quad (4.6)$$

donde $v_{k,n} \in \mathbb{C}$ expresa la ganancia y la rotación en fase del n componente multitrayecto del k usuario. De esta forma, se interpreta g_k , como la suma de N_{path} componentes multitrayecto independientes, cada uno con su propia ganancia y rotación en fase ($v_{k,n}$) y su AoA ($\varphi_{k,n}$).

Debido a la poca presencia de objetos dispersivos y generalmente situados alrededor de la MS, ya que la BS suele colocarse a una mayor altitud, es razonable pensar que los AoA de los distintos componentes multitrayecto ($v_{k,n}$) siguen la misma distribución: $\varphi_n = \varphi + \sigma_\varphi$. Donde φ es un ángulo determinista y σ_φ es una desviación aleatoria denominada desviación angular estándar (ASD, por sus siglas en inglés), ver *Figura 7*.




Figura 7. Parámetros clave del modelo de canal *Rayleigh* correlado.¹¹

¹¹ Fuente [2], pp. 237.

La matriz de desvanecimiento a pequeña escala G , es por tanto, el conjunto de los g_k ($k=1..K$) canales individuales de cada MS e independientes entre sí, siempre que exista una buena separación espacial entre usuarios.

Para un *array* de antenas rectangular, el vector de correlación del n ($n=1..N_{path}$) componente multitrayecto toma la siguiente expresión:

$$r(\theta_{k,n}, \phi_{k,n}) = [1, e^{(j2\pi d_a/\lambda)\sin(\theta_{k,n})}, \dots, e^{(j2\pi d_a/\lambda)(M-1)\sin(\theta_{k,n})}]^T \times [1, e^{(j2\pi d_a/\lambda)\sin(\phi_{k,n})}, \dots, e^{(j2\pi d_a/\lambda)(M-1)\sin(\phi_{k,n})}] \quad (4.7)$$

donde $\theta_{k,n}$ y $\phi_{k,n}$ es el azimut de llegada (AoA, por sus siglas en inglés) y la elevación de llegada (EoA, por sus siglas en inglés) respectivamente. Nótese que el acrónimo "AoA" tiene distinto significado en función del tipo de *array* (lineal o rectangular), refiriéndose en ambos casos al mismo ángulo (azimut) pero especificándose en el caso de un *array* rectangular para distinguirlo del ángulo de elevación.

El modelo de canal *Rayleigh* correlado introduce información angular de los distintos usuarios, dichos parámetros son sumamente importantes para el estudio de la separación espacial e interferencia entre usuarios.

4.3. GBSM (Geometry-Based Stochastic Models)

El modelo GBSM con un mayor grado de complejidad que los modelos CBSM, permite reproducir las propiedades de los sistemas *Massive MIMO* para crear un modelo de canal más acorde con la realidad. Alguna de estas propiedades son el *nonstationary phenomenon* en el que las MSs pueden observar distintos conjuntos de objetos dispersivos (*clusters*) en distintos instantes temporales, el *near-field effect* debido a las ondas electromagnéticas de geometría esférica de las MSs próximas a la BS y en general una mayor exactitud en la descripción de ángulos de salida y llegada, así como la relación entre el conjunto de los rayos reflejados en un *cluster*, ver *Figura 8*.

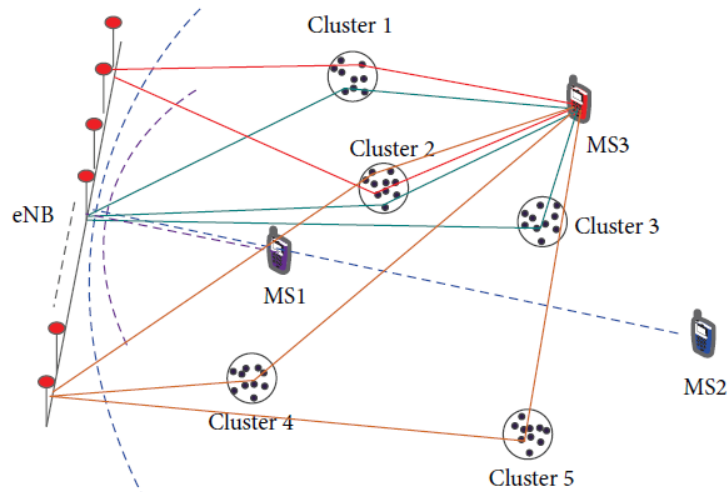


Figura 8. Representación del *nonstationary phenomenon* y del *near-field effect* en un modelo GBSM basado en *clusters*.¹²

Existen dos modelos GBSM en función de si evalúa o no el ángulo de elevación: el modelo de canal 2D para *arrays* lineales y el modelo de canal 3D para *arrays* de dos dimensiones como pueden ser los rectangulares, cilíndricos o esféricos.

En esta memoria se describirá alguno de los aspectos más importantes del modelo de canal 3D ya que se ha trabajado con dicho modelo en las simulaciones que se presentarán en el *capítulo 6*. Además, el modelo 2D es similar salvo porque este último queda restringido a la dimensión de azimut.

4.3.1. Modelo de canal 3D del 3GPP

El 3GPP ha desarrollado recientemente un modelo de canal 3D basado en la extensión de los modelos 2D a 3D de los proyectos WINNERII/WINNER+ [17, 18] pero añadiendo algunos parámetros de altura y distancia en función de la elevación. Es un modelo basado en *clusters* al igual que lo son los modelos COST-259, 273, 2100 o WINNERII, entre otros.

Un resumen del procedimiento para la generación de los coeficientes del canal está mostrado en la *Figura 9*.

¹² Fuente [33], pp. 4.

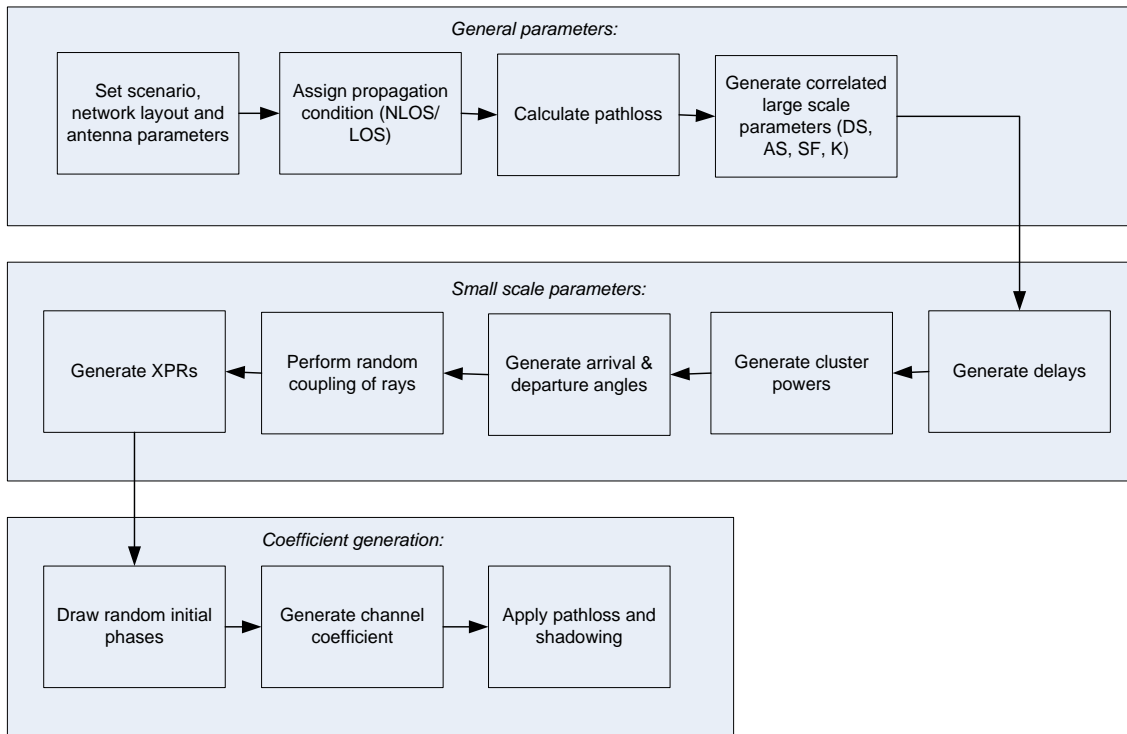


Figura 9. Procedimiento para la generación de los coeficientes de canal.¹³

El primer bloque define los parámetros generales, entre los que se encuentran los referentes al desvanecimiento a gran escala. El primer paso en el modelado de canal 3D es la elección del entorno; el 3GPP describe cuatro escenarios llamados 3D-UMi (*Urban Micro cell with high User-Equipment density*), 3D-UMa (*Urban Macro cell with high User-Equipment density*), 3D-UMa-H (*Urban Macro cell with one high-rise per sector and 300m ISD*) y 3D-RMa (*Rural Macro cell*), cada uno con sus propias características como la movilidad de los usuarios, la altura a la que se encuentra el terminal móvil, la potencia de transmisión de la BS, la distancia entre BSs (ISD, por sus siglas en inglés), entre otros [19, 20]. Además se tiene que especificar si el escenario es *outdoor-to-outdoor* (O2O) o *outdoor-to-indoor* (O2I), ya que condicionará otros parámetros: probabilidad de LOS, pérdidas por penetración, entre otros. A continuación se especifica la condición LOS o NLOS, así como el modelo de antena y su diagrama de radiación (asociado a una ecuación de campo electromagnético) [20]. El *pathloss* se calcula en función de la frecuencia central y de parámetros (distancias, alturas, pérdida por penetración en edificios, entre otros) dependientes del escenario O2O/O2I

¹³ Fuente [20], pp. 31.

como muestra la *Figura 10*, del tipo de propagación LOS/NLOS y del entorno (3-D UMi, 3D-UMa, 3D-UMa-H, 3-D-RMa)¹⁴.




Figura 10. Definición de parámetros para O2O y para O2I.¹⁵

Otros parámetros son el *Shadow Fading* (SF) que sigue una distribución log-normal y cuya desviación típica (σ_{SF}) depende del entorno, el *Delay Spread* (DS) que afecta directamente a la varianza de la distribución estadística de los distintos *cluster delays*, el *Angular Spread* (AS) que, del mismo modo, modifica la varianza de la distribución estadística de los ángulos de llegada y salida de los distintos *path component* a un *cluster*, el *K-Factor* (para el caso LOS), entre otros.

Una vez definidos los parámetros a gran escala, es necesario hacer lo propio con los de pequeña escala. El primer paso en este bloque es generar los *cluster delays* (τ_n) para todo n ($n=1..N$) *cluster*:

$$\tau'_n = -r_\tau DS \ln(X_n) \quad (4.8)$$

donde r_τ es el *delay distribution proportionaly factor* y $X_n \sim \text{uniform}(0,1)$. Además, se normaliza restando el *delay* mínimo y ordenándolos de forma ascendente:

$$\tau_n = \text{sort}(\tau'_n - \min(\tau'_n)) \quad (4.9)$$

En el caso de una propagación LOS, es necesario un escalado mediante la constante (C_τ), calculada como:

$$C_\tau = 0.7705 - 0.0433K + 0.0002K^2 + 0.000017K^3 \quad (4.10)$$

donde $K[\text{dB}]$ es el *K-Factor*. Por tanto, τ_n^{LOS} pasa a ser:

¹⁴ Las fórmulas para calcular el *pathloss* están disponibles en "7.4 *Pathloss, LOS probability and penetration modelling*" en [20].

¹⁵ Fuente [20], pp. 24.

$$\tau_n^{LOS} = \frac{\tau_n}{C_\tau} \quad (4.11)$$

En el segundo paso hay que calcular los *cluster powers* (P_n) determinados por:

$$P'_n = \exp\left(-\tau_n \frac{r_\tau - 1}{r_\tau DS}\right) \cdot 10^{\frac{-Z_n}{10}} \quad (4.12)$$

donde $Z_n \sim N(0, \zeta^2)$ es el *cluster shadowing term*. Además, se normaliza para que la suma total de todas las *cluster powers* sea igual a uno:

$$P_n = \frac{P'_n}{\sum_{n=1}^N P'_n} \quad (4.13)$$

En el caso de una propagación con LOS es necesario, de nuevo, un ajuste.¹⁶

A continuación, se generan los ángulos de llegada y salida tanto en azimut como en elevación. Como ejemplo, para el *Azimuth angle Of Arrival* (AOA) se sigue la siguiente metodología:

$$\phi'_{n, AOA} = \frac{2(ASA / 1.4) \sqrt{-\ln(P_n / \max(P_n))}}{C_\phi} \quad (4.14)$$

donde ASA es el *Azimuth Angle Spread of Arrival* y C_ϕ para el caso NLOS (C_ϕ^{NLOS}) es un factor de escalado relacionado con el número de *clusters*¹⁷, y para una propagación con LOS se calcula como:

$$C_\phi^{LOS} = C_\phi^{NLOS} \cdot (1.1035 - 0.028K - 0.002K^2 + 0.0001K^3) \quad (4.15)$$

Seguidamente, se añade un signo a los ángulos multiplicándolos por una variable aleatoria X_n con una distribución uniforme discreta $\{-1,1\}$, y se le suma un componente $Y_n \sim N(0, (ASA / 7)^2)$ para proporcionar aleatoriedad:

$$\phi_{n, AOA} = X_n \phi'_{n, AOA} + Y_n + \phi_{LOS, AOA} \quad (4.16)$$

¹⁶ Ver "7.5 Fast fading model", pp. 33-34 en [20].

¹⁷ Ver "Table 7.5-2: Scaling factors for AOA, AOD generation".

donde $\phi_{LOS,AOA}$ es la dirección de la LOS “virtual”. De nuevo, en el caso de existir LOS, hay que tener en cuenta factores de escala.¹⁸ Finalmente, para calcular el AOA del m ($m=1..M$) *path component* del *cluster* n se suma un offset que depende de su posición de llegada¹⁹:

$$\phi_{n,m,AOA} = \phi_{n,AOA} + C_{ASA} \alpha_m \quad (4.17)$$

donde C_{ASA} es el *cluster* ASA.²⁰ La generación del *Azimuth angle Of Departure* (AOD) sigue un procedimiento similar, y está descrito junto a la del *Zenith angle OF Arrival* (ZOA) y *Zenith angle OF Departure* (ZOD) en el TR 38.901 [20]. En el siguiente paso se acoplan de forma aleatoria los ángulos de azimut y elevación calculados anteriormente y los XPR (*Cross-Polarization Ratio*). El XPR k para el *path component* m y el *cluster* n se calcula como:

$$k_{n,m} = 10^{X/10} \quad (4.18)$$

donde $X \sim N(\mu_{XPR}, \sigma_{XPR}^2)$.²¹

Por último, se generan los coeficientes de canal. Para ello se asigna una fase aleatoria $\{\Phi_{n,m}^{\theta\theta}, \Phi_{n,m}^{\theta\phi}, \Phi_{n,m}^{\phi\theta}, \Phi_{n,m}^{\phi\phi}\}$ a cada *path component* m del *cluster* n y para cuatro combinaciones de polarización diferentes $\{\theta\theta, \theta\phi, \phi\theta, \phi\phi\}$. La distribución para las fases iniciales es uniforme entre $(-\pi, \pi)$. Como ejemplo, para los *weakest clusters* ($n=3,4,\dots,N$), los coeficientes de canal se calculan como:

$$\begin{aligned} H_{u,s,n}^{NLOS}(t) = & \sqrt{\frac{P_n}{M}} \sum_{m=1}^M \begin{bmatrix} F_{rx,u,\theta}(\theta_{n,m,ZOA}, \phi_{n,m,AOA}) \\ F_{rx,u,\phi}(\theta_{n,m,ZOA}, \phi_{n,m,AOA}) \end{bmatrix}^T \begin{bmatrix} \exp(j\Phi_{n,m}^{\theta\theta}) & \sqrt{k_{n,m}^{-1}} \exp(j\Phi_{n,m}^{\theta\phi}) \\ \sqrt{k_{n,m}^{-1}} \exp(j\Phi_{n,m}^{\phi\theta}) & \exp(j\Phi_{n,m}^{\phi\phi}) \end{bmatrix} \\ & \times \begin{bmatrix} F_{tx,s,\theta}(\theta_{n,m,ZOD}, \phi_{n,m,AOD}) \\ F_{tx,s,\phi}(\theta_{n,m,ZOD}, \phi_{n,m,AOD}) \end{bmatrix} \exp\left(j2\pi \frac{\hat{r}_{rx,n,m}^T \overline{d}_{rx,u}}{\lambda_0}\right) \\ & \exp\left(j2\pi \frac{\hat{r}_{tx,n,m}^T \overline{d}_{tx,s}}{\lambda_0}\right) \exp\left(j2\pi \frac{\hat{r}_{rx,n,m}^T \overline{v}}{\lambda_0} t\right) \end{aligned} \quad (4.19)$$

donde $F_{rx,u,\theta}$ y $F_{rx,u,\phi}$ son las ecuaciones de onda electromagnética de la antena receptora u aplicados a la dirección de las coordenadas esféricas $\bar{\theta}$ y $\bar{\phi}$,

¹⁸ Ver “7.5 Fast fading model”, pp. 34-36 en [20].

¹⁹ Ver “Table 7.5-6”, en [20].

²⁰ Ver “Table 7.5-3: Ray offset angle within a cluster, given for rms angle spread normalized to 1”, en [20].

²¹ Ver “Table 7.5-6”, en [20].

respectivamente. Del mismo modo, $F_{tx,s,\theta}$ y $F_{tx,s,\phi}$ lo son para la antena transmisora s . Los campos vienen dados en un sistema de coordenadas denominado *Global Coordinate System (GCS)*.²² $\hat{r}_{rx,n,m}$ es el vector unitario esférico con *azimuth arrival angle* $\phi_{n,m,AOA}$ y *elevation arrival angle* $\theta_{n,m,ZOA}$, definido como:

$$\hat{r}_{rx,n,m} = \begin{bmatrix} \sin \theta_{n,m,ZOA} \cos \phi_{n,m,AOA} \\ \sin \theta_{n,m,ZOA} \sin \phi_{n,m,AOA} \\ \cos \theta_{n,m,ZOA} \end{bmatrix} \quad (4.20)$$

$\hat{r}_{tx,n,m}$ es el vector unitario esférico con *azimuth departure angle* $\phi_{n,m,AOD}$ y *elevation departure angle* $\theta_{n,m,ZOD}$, definido como:

$$\hat{r}_{tx,n,m} = \begin{bmatrix} \sin \theta_{n,m,ZOD} \cos \phi_{n,m,AOD} \\ \sin \theta_{n,m,ZOD} \sin \phi_{n,m,AOD} \\ \cos \theta_{n,m,ZOD} \end{bmatrix} \quad (4.21)$$

También, $\bar{d}_{rx,u}$ es el vector de localización de la antena receptora u , mientras que $\bar{d}_{tx,s}$ es el vector de localización de la antena transmisora s . $k_{n,m}$ es el *cross polarization power ratio* en unidades naturales, λ_0 es la longitud de onda de la frecuencia central de la portadora y \bar{v} es un vector de velocidad que afecta directamente a la frecuencia *Doppler*. Para los dos *strongest clusters* ($n=1,2$), hay que incorporar otros factores y operaciones; lo mismo sucede para el caso LOS, en el que la ecuación para la generación de canal ($H_{u,s,l}^{LOS}(t)$) varía respecto a la ecuación 4.19.²³ Finalmente, se aplica el *pathloss* y *shadowing* (parámetros de desvanecimiento a gran escala) a los coeficientes de canal generados.

En el TR 38.901 se puede encontrar, además, unos modelos de canal CDL (*Cluster Delay Line*) predefinidos con tres perfiles distintos para el caso NLOS (CDL-A, B, C) y dos para el caso LOS (CDL-D, E). Cada uno de estos modelos ha sido generado siguiendo el procedimiento desarrollado en esta sección y cuenta con sus propias características como son el número de *clusters*, el *Normalize Delay*, el *Power Cluster* y los ángulos de llegada y salida. Además, es posible escalar dichos modelos a un DS y AS deseado según el escenario de trabajo. Valores típicos del DS y AS para los escenarios UMA y UMi aparecen en el documento.

²² Ver "7.1 Coordinate system", pp. 14-19 en [20].

²³ Ver "7.5 Fast fading model", pp. 36-38 en [20].

Capítulo 5

Estimación de canal

5.1. Introducción

En las radiocomunicaciones móviles es indispensable conocer el canal tanto para la demodulación, como para el diseño de ecualizadores que permitan suprimir el efecto de este sobre las señales transmitidas. Además, en sistemas con *Massive MIMO* es necesario calcular la matriz de precodificación, para servir a usuarios mediante SDMA, partiendo de un conocimiento del canal.

Típicamente el conocimiento del canal se viene adquiriendo mediante la inserción de pilotos en determinadas subportadoras (si de sistemas OFDM se trata) y cada cierto tiempo dependiendo de parámetros como el ancho de banda de coherencia (intervalo en el que el canal puede considerarse plano en frecuencia) y el tiempo de coherencia (intervalo en el que el canal puede considerarse temporalmente invariante). Además, es necesario estimar los valores desconocidos del canal entre los pilotos; para ello, los sistemas de comunicaciones vienen implementando el método de interpolación lineal.

Actualmente, se investigan otros métodos de estimación basados en inteligencia artificial que permitan obtener mejores resultados que la tradicional interpolación lineal. La mejora de resultados puede materializarse en un mayor parecido del canal estimado con el real, en el uso de una menor cantidad de pilotos (recursos) para la obtención de estimaciones similares/superiores o en la estimación de canales que permitan maximizar/minimizar algún parámetro de la red (tasa de transmisión, consumo de potencia, entre otros).

En este capítulo se explica en qué consiste la interpolación lineal y la estimación mediante redes neuronales (NN, por sus siglas en inglés). En el siguiente capítulo, se mostrarán los resultados obtenidos en la estimación de canales *Massive MIMO* mediante ambos métodos.

5.2. Estimación de canal mediante Interpolación Lineal

La interpolación lineal de orden uno es el método clásico de estimación de los canales móviles, consiste en unir con una recta las muestras conocidas o, en este caso, los pilotos adyacentes de forma que los valores estimados del canal consisten en los infinitos puntos pertenecientes a dichas rectas. Sin embargo, los modelos de canal empleados para trabajar con computadoras son modelos discretos, por ello la interpolación lineal con la que se trabaja, incluyendo esta memoria, es discreta.

El procedimiento para interpolar linealmente un canal discreto queda resumido en la *Figura 11*.




Figura 11. Procedimiento para la interpolación.

El primer bloque convierte los pilotos $x[n]$ en un canal intermedio $x_b[n]$ con ceros en las posiciones que se quiere estimar. El segundo bloque convoluciona el canal $x_b[n]$ con un interpolador lineal (de orden uno, en este caso) para obtener el canal estimado $x_i[n]$.

5.3. Estimación de canal mediante Redes Neuronales

El aprendizaje máquina (*machine learning*) es un campo de la ciencia de la computación y una rama de la inteligencia artificial (AI, por sus siglas en inglés) que consiste en crear reglas para resolver un problema de clasificación o de regresión, a partir de unos datos de entrenamiento y su respuesta a dicho problema. Esta es la diferencia principal respecto a la programación clásica, en la que el programador se encarga de crear unas reglas que posteriormente son aplicadas a unos datos de entrada para obtener una respuesta, tal y como muestra la *Figura 12*.




Figura 12. Diferencia entre la programación clásica y *machine learning*.

Para trabajar con *machine learning* son necesarias tres cosas: datos de entrenamiento, ejemplos de la respuesta esperada y una forma de medir la discrepancia entre la respuesta esperada y la proporcionada por el algoritmo. Un modelo de *machine learning* trata de aprender, a través de ejemplos consistentes en datos de entrenamiento y su correspondiente etiqueta (respuesta conocida al problema), representaciones útiles de los datos de entrada (de la misma naturaleza que los datos de entrenamiento) para facilitar la correcta solución al problema.

Las redes neuronales (NN, por sus siglas en inglés) son un método de *machine learning* que consiste en combinar un conjunto de datos de entrada y un conjunto de parámetros de tal forma que permitan predecir una determinada respuesta a un problema de clasificación o de regresión.

El aprendizaje profundo (*deep learning*) es una mejora de las NNs clásicas que consiste en emplear numerosas capas con el fin de crear nuevas transformaciones de los datos de entrada según van atravesando las distintas capas que forman la red, y que aportan, de forma creciente, mayor información para la correcta respuesta al problema. El *deep* se debe al empleo de múltiples capas para la solución al problema, a diferencia de las NNs clásicas que emplean, generalmente, dos o tres capas. Adicionalmente, *deep learning* hace referencia al nuevo paradigma de entrenamiento de las NNs: nuevos métodos de optimización para el entrenamiento, mayor capacidad de cómputo gracias a la GPUs (*Graphics Processing Unit*), mayores bases de datos, nuevas arquitecturas (redes convolucionales, recurrentes, por ejemplo), entre otros. Hasta mediados de la primera década de los 2000s, no se disponía de estos elementos por lo que la utilización de las NNs quedaba restringida a ámbitos académicos o industriales muy concretos, principalmente por lo carencia de capacidad de cómputo para su entrenamiento.

En cada capa de la red neuronal existen neuronas, que son el elemento funcional básico [21]. El funcionamiento es el siguiente: a cada neurona llegan una serie de entradas ($x = [x_0, \dots, x_N]^T$) que se combinan de forma lineal, ponderadas por unos pesos ($\theta = [\theta_0, \dots, \theta_N]^T$). La salida de cada neurona vendrá dada por una transformación no lineal de dicha combinación lineal, que se llama función de activación ($\sigma()$), tal y como se ilustra en la *Figura 13*.




Figura 13. Funcionamiento básico de una neurona.

Generalmente, las funciones de activación más usadas son la función sigmoide, $\sigma(z) = 1/(1 + e^{-z})$, y la tangente hiperbólica, $\sigma(z) = (e^z - e^{-z})/(e^z + e^{-z})$. En los últimos años se ha empezado a usar con mucho éxito la función de activación ReLU (*Rectified Linear Unit*), $\sigma(z) = \max(0, z)$.

Las NNs contienen tres tipos de capas: la capa de entrada que recibe los datos de entrada a la red, la capa de salida que produce la respuesta de la red y unas capas intermedias denominadas capas ocultas. La combinación de diferentes neuronas, con todas las neuronas interconectadas entre sí, entre cada par de capas, recibe el nombre de *MultiLayer Perceptron* (MLP). El funcionamiento básico del MLP, y de cualquier NN en general, se puede entender como la propagación del flujo de información por la red de la entrada a la salida. En el siguiente ejemplo, se muestra los cálculos completos para obtener la salida de la última neurona.

Se supone una MLP muy básica con una capa de entrada con dos neuronas y una capa de salida con una única neurona. Los datos de entrada son un vector con dos elementos ($x = [x_1, x_2]^T$) y el dato de salida es un único elemento (\hat{y}), tal y como muestra la *Figura 14*.




Figura 14. Ejemplo ilustrativo de una NN básica, donde el superíndice de los pesos (θ) indica la neurona destino y el subíndice indica la neurona origen.

La salida \hat{y} se calcula, por tanto, como:

$$\hat{y} = \sigma\left(\theta_A^O \cdot \sigma\left(\theta_1^A x_1 + \theta_2^A x_2\right) + \theta_B^O \cdot \sigma\left(\theta_1^B x_1 + \theta_2^B x_2\right)\right) \quad (5.1)$$

El aprendizaje se resume en encontrar unos pesos que permitan mapear correctamente los datos de entrenamiento con sus correspondientes etiquetas ($\hat{y} = y$). Además, para saber si la NN, empleando unos determinados pesos, está funcionando correctamente, es necesario medir el error entre su estimación y la verdadera solución al problema. De ello se encarga la función de coste que, generalmente, en problemas de regresión calcula el MSE (*Mean Square Error*) entre la respuesta estimada por la NN (\hat{y}), a partir de los datos de entrenamiento, y las correctas etiquetas (y).

En el ejemplo anterior, suponiendo que se trata de un problema de regresión en el que se quiere estimar la etiqueta \hat{y} a partir de los datos de entrada $x = [x_1, x_2]^T$, la función de coste ($J(\underline{\theta})$) calcula el MSE de la siguiente forma:

$$J(\underline{\theta}) = \frac{1}{N} \sum_{n=0}^{N-1} |y_n - \hat{y}_n|^2 \quad (5.2)$$

donde N es el número de datos de entrenamiento asociados a N etiquetas (y_n). El ejemplo propuesto consiste en un dato de entrenamiento ($x = [x_1, x_2]^T$) asociado a una etiqueta (y), es decir, $N = 1$.

Como se ha visto en la *ecuación 5.2*, la función de coste calcula el MSE, que es siempre positivo, dados unos pesos ($\underline{\theta}$); por lo que lo ideal sería que el MSE calculado fuera cero, que es lo mismo que $y_n = \hat{y}_n$ para todos los datos de entrada. Por tanto, el optimizador de la red neuronal va a tratar de encontrar unos pesos que permitan obtener una función de coste mínima.

La forma analítica de minimizar una función genérica ($f(\underline{v})$) es encontrando un \underline{v} que satisfaga que el gradiente de la función evaluado en \underline{v} sea cero ($\nabla f(\underline{v})=0$) y que además sea el mínimo global. Por tanto, volviendo a las redes neuronales, la solución analítica al problema es resolver el sistema de ecuaciones para encontrar unos pesos ($\underline{\theta}$) que satisfagan $\nabla J(\underline{\theta})=0$ y que además coincida con el mínimo global (puede haber mínimos locales). Sin embargo, alcanzar la solución analítica solamente es posible cuando la función es dependiente de pocas variables ($\underline{\theta}$ contiene pocos elementos). En las redes neuronales reales el número de pesos es del orden de decenas de miles o incluso de millones, por ello la solución analítica queda completamente descartada.

En su lugar, se puede emplear la información que nos aporta la definición de gradiente: dada una función genérica $f(\underline{v})$ donde $\underline{v}=[v_1, v_2, \dots, v_n]$, el gradiente de la función en un punto genérico $\underline{v}_p=[v_1=p_1, \dots, v_n=p_n]$, es $\nabla f(\underline{v}_p)$ y se trata de un vector que indica la dirección en la cual la función $f(\underline{v})$ aumenta más rápidamente. Por tanto, la solución al problema va a ser encontrar el mínimo global de la función de coste mediante múltiples actualizaciones de los pesos ($\sum_{i=1}^I \underline{\theta}_{i-1} \rightarrow \underline{\theta}_i$ donde I es el número de actualizaciones) que permitan un “desplazamiento” por la función en una dirección que minimice a esta. Esta dirección será la opuesta al gradiente de la función evaluada en cada vector de pesos previo a la actualización ($-\nabla J(\underline{\theta}_{i-1})$). En esta idea se basa el algoritmo de optimización de descenso por gradiente (*gradient descent*).

Además, en redes neuronales se suele seleccionar lotes (*batch*) aleatorios de los datos de entrada y realizar múltiples actualizaciones en función de la función de coste evaluada en los pesos de ese lote:

$$\underline{\theta}_i = \underline{\theta}_{i-1} - \eta \cdot \nabla J(\underline{\theta}_{i-1}) \quad (5.3)$$

donde $\underline{\theta}_i$ son los pesos actualizados, $\underline{\theta}_{i-1}$ son los pesos a actualizar calculados en la iteración previa y η es un parámetro que indica la proporción del

desplazamiento en dirección contraria al gradiente, en NNs es conocida como tasa de aprendizaje (*learning rate*).

La tasa de aprendizaje es un parámetro importante, ya que una tasa de aprendizaje muy pequeña supone realizar muchas iteraciones para encontrar un mínimo, corriendo el riesgo extra de quedarse estancado en un mínimo local, mientras que una tasa de aprendizaje grande puede desembocar en pesos con posiciones aleatorias en la curva que impiden encontrar el mínimo global. Por ello la elección de la tasa de aprendizaje dependerá del problema a tratar (mínimos locales y globales de la función de coste, por ejemplo).

Otro parámetro importante de las NNs es, como se ha mencionado, el tamaño de lote (*batch size*). Un tamaño de lote igual al tamaño de los datos de entradas provocará una actualización de los pesos más precisa pero el coste computacional será enorme si se dispone de una gran cantidad de datos de entrada, ya que habría que guardarlos todos en la memoria. Mientras que un tamaño de lote más pequeño será menos preciso pero, del mismo modo, tendrá un menor coste computacional. Si el tamaño de lote es menor que el de los datos de entrenamiento, la actualización de los pesos se hará varias veces en el mismo ciclo, cada iteración. Mientras que si del tamaño de lote es igual al tamaño de los datos de entrenamiento, se realizará una actualización de los pesos por cada ciclo.

Por último, hay que mencionar que en la práctica para calcular el gradiente se utiliza un algoritmo denominado *backpropagation* que consiste en aplicar la regla de la cadena:

$$f'(g(x)) = f'(g(x)) \cdot g'(x) \quad (5.4)$$

que empieza en la última capa y se propaga hasta la primera en la que se resuelve el cálculo del gradiente de la función de coste ($\nabla J(\theta)$).

Un resumen del entrenamiento de una NN, explicado en esta sección, está ilustrado en la *Figura 15*.

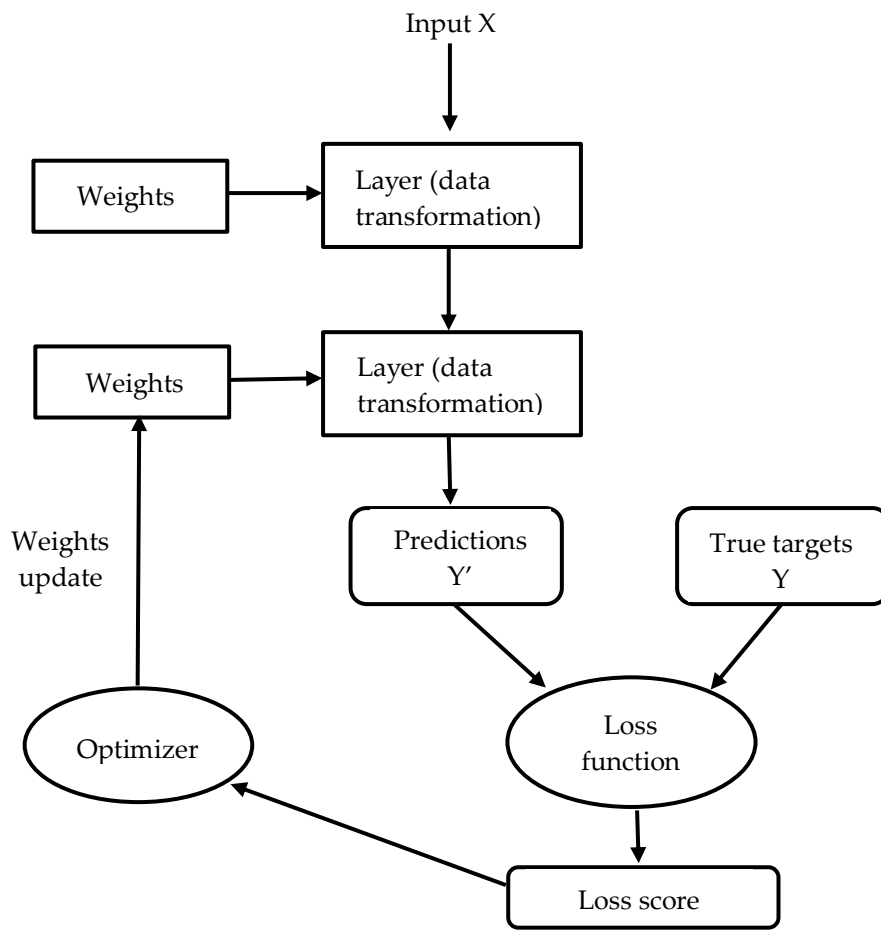


Figura 15. Resumen del entrenamiento de una NN.

Capítulo 6

Simulaciones y resultados

6.1. Parámetros de simulación de canal

Se ha trabajado con canales *Massive MIMO* generados por medio de la *5G Toolbox* de MATLAB²⁴ según el procedimiento descrito en la sección “4.3.1. Modelo de canal 3D del 3GPP”. Los coeficientes de canal generados están normalizados y se corresponden al desvanecimiento a pequeña escala. Sin embargo, a los pilotos se les ha aplicado externamente un ruido gaussiano blanco con SNRs variantes en el rango 0-50 *dBs*, que simula los posibles efectos de las figuras de ruido y de los parámetros propios (distancia entre MS y BS, altura de la MS y BS, entre otros) del *pathloss* y *shadowing*.

A continuación, se enumeran las características más relevantes de los canales simulados:

- *Downlink*.
- Numerología 5G: $\mu = 1$.
- SCS: 30 *KHz*.
- Número de RBs: 24 (288 REs).
- Ancho de banda: 8.64 *MHz*.
- Tiempo de simulación: 10 *ms* (una trama, 280 símbolos OFDM).
- Frecuencia de portadora: 3.5 *GHz*.
- Canales NLOS: CDL-A, CDL-B, CDL-C.
- Canales LOS: CDL-D, CDL-E.
- *Delay Spread*: 32 (*short-delay profile*), 363 (*normal-delay profile*), 1148 (*long-delay profile*) *ns*.
- Frecuencia *Doppler*: 5, 70, 120 *Hz*.
- SNR: rango 0-50 *dB*.
- *K-Factor* (para LOS): 9.
- BS compuesta por 16 *subarrays* con cuatro antenas y dos polarizaciones cada uno (ver *Figura 16*).

²⁴ Ver: <https://es.mathworks.com/products/5g.html>.

- MS compuesto por una única antena.
- Diagrama de radiación de cada antena basado en el TR 38.901.²⁵
- Distancia entre antenas: $\lambda/2$.




Figura 16. Conjunto de 64 *antenna elements* con dos polarizaciones cada uno y agrupados en 16 *subarrays*: 2 (elevación) x 8 (azimut).

6.2. Descripción geométrica del problema

Los canales generados, con las características enumeradas en la anterior sección, son tensores con tres ejes: el primero es el eje frecuencial, el segundo es el eje temporal y el tercero es el eje de enlace entre un determinado *subarray* de la BS y la única antena de la MS (usuario).

El eje frecuencial es de dimensión 288, ya que se ha simulado 24 RBs lo que equivale a 288 subportadoras o REs (ver sección “2.4.3. Recursos físicos”); todo ello supone un ancho de banda de 8.64 MHz. El eje temporal es de dimensión 280, ya que se ha simulado una trama de 10 ms en la que, debido a la numerología $\mu = 1$, se alberga un total de 280 símbolos OFDM ($14 \frac{\text{símbolos OFDM}}{\text{slot}} \times 2 \frac{\text{slot}}{\text{subtrama}} \times 10 \frac{\text{subtramas}}{\text{trama}}$). El tercer eje es de dimensión 32, ya que se ha simulado la comunicación entre la BS consistente en 16 *subarrays* con dos polarizaciones y un usuario con una única antena.

²⁵ Ver “Table 7.3-1: Radiation power pattern of a single antenna element”, pp. 22 en [20].

Cada elemento del tensor de tres ejes con dimensiones $288 \times 280 \times 32$, corresponde a un coeficiente de canal ($h_{f,t,a} \in \mathbb{C}$, $f = 1, 2, \dots, 288$, $t = 1, 2, \dots, 280$, $a = 1, 2, \dots, 32$). La Figura 17 representa la estructura de un canal.




Figura 17. Representación tensorial del canal.²⁶

Cada canal tiene un total de 2580480 ($288 \times 280 \times 32$) coeficientes; sin embargo, en la realidad se dispone de un pequeño porcentaje de ellos, calculados a partir de los denominados pilotos, que sirven de punto de partida para la estimación del resto de coeficientes.

Además, los pilotos recibidos están contaminados con ruido. De forma analítica, para un único piloto:

$$y_{f_o, t_o, a_o} = x_{f_o, t_o, a_o} h_{f_o, t_o, a_o} + n \quad (6.1)$$

donde $x_{f_o, t_o, a_o} \in \mathbb{C}$ es un símbolo (piloto) transmitido en una determinada subportadora, instante temporal (símbolo OFDM) y entre un determinado subarray de la BS y la antena del usuario, además es conocido en el receptor; $y_{f_o, t_o, a_o} \in \mathbb{C}$ es la señal recibida, $h_{f_o, t_o, a_o} \in \mathbb{C}$ es el coeficiente de canal y n es el ruido aditivo gaussiano blanco $n \sim N_{\mathbb{C}}(0, \sigma^2)$. El coeficiente de canal calculado ($\tilde{h}_{f_o, t_o, a_o} \in \mathbb{C}$) será por tanto:

²⁶ Cada uno de estos tensores ha sido generado mediante realizaciones independientes.

$$\tilde{h}_{f_o,t_o,a_o} = \frac{y_{f_o,t_o,a_o}}{x_{f_o,t_o,a_o}} = \frac{x_{f_o,t_o,a_o} h_{f_o,t_o,a_o} + n}{x_{f_o,t_o,a_o}} \quad (6.2)$$

Cuanto mayor sea el cociente entre la potencia del piloto (x_{f_o,t_o,a_o}) y la potencia del ruido (σ^2), mayor será el parecido entre \tilde{h}_{f_o,t_o,a_o} y h_{f_o,t_o,a_o} . El mismo procedimiento sigue la deducción del resto de los coeficientes de canal donde viajan el resto de pilotos.

La distribución de pilotos, implementada de forma externa a los canales generados mediante la *5G Toolbox*, es una de las estipuladas por el estándar 5G para 32 *antenna ports*.²⁷ Consiste en enviar pilotos en cuatro símbolos OFDM consecutivos y en dos subportadoras consecutivas. Reiterando dicho envío cada RB (12 subportadoras o REs), cada slot temporal (0.5 ms o 14 símbolos OFDM) y en todas las dimensiones del tercer eje. Dicha distribución se representa en la *Figura 18*.

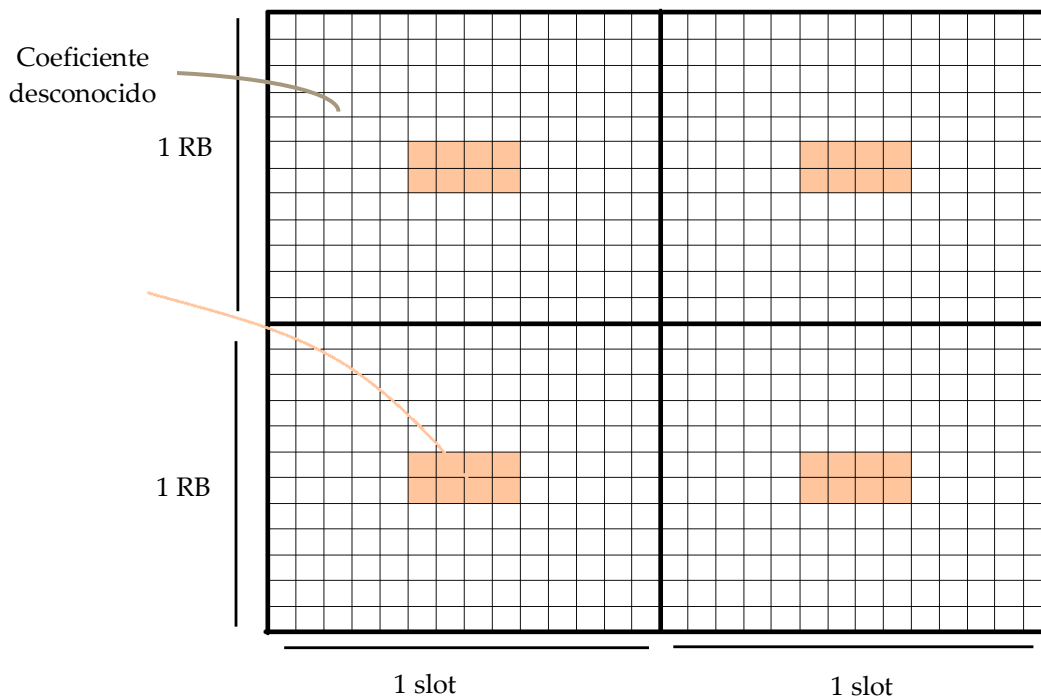


Figura 18. Distribución de pilotos según la especificación de 5G.

En las siguientes secciones se presentarán los resultados obtenidos en la estimación de los coeficientes desconocidos a partir los coeficientes de canal

²⁷ Ver: https://www.sharetechnote.com/html/5G/5G_CSI_RS.html.

calculado mediante los pilotos ($\tilde{h}_{f,t,a}$) y a través de dos técnicas diferentes: interpolación lineal de orden uno y regresión con *deep learning*.

6.3. Resultados obtenidos mediante Interpolación Lineal

En esta sección se presenta los resultados obtenidos en la estimación de canal mediante interpolación lineal de orden uno entre los coeficientes deducidos a partir de los pilotos (ver *ecuación 6.2*); también servirá para representar gráficamente alguna de las características de los distintos canales *Massive MIMO* simulados.

Las representaciones de los canales mostrados a continuación, se corresponden con el valor absoluto de todos los coeficientes del primer eje del tensor, es decir, con las 288 subportadoras (REs) de cuatro símbolos OFDM distintos, separados en una subtrama (1 *ms* o 28 símbolos OFDM) entre los adyacentes, y de un enlace entre un determinado *subarray* de la BS y la antena del usuario (ver *Figura 19*). Tanto el primer símbolo OFDM representado como el enlace han sido elegidos al azar.

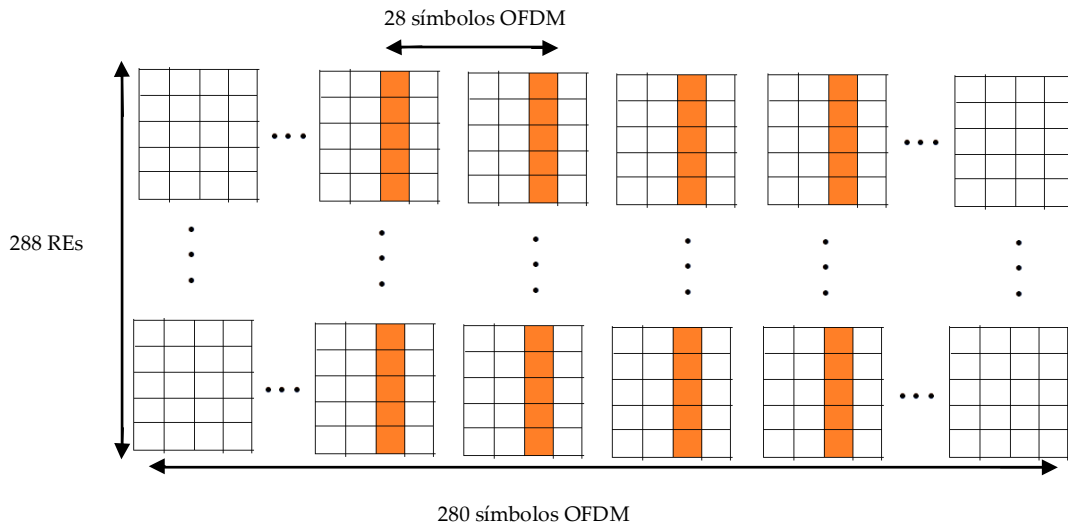


Figura 19. Método utilizado en esta memoria para mostrar los canales entre un determinado *subarray* de la BS y la antena de usuario.

El primer canal representado en la *Figura 20* y en la *Figura 21* (figura ampliada) corresponde a un CDL-A con un DS de 32 *ns* (*short-delay profile*), se puede observar en la planitud frecuencial del canal. La frecuencia *Doppler* es de

5 Hz por lo que el tiempo de coherencia en el que el canal puede considerarse invariante en el tiempo es:

$$T_{ch} = \frac{1}{3fd} \quad (6.3)$$

donde fd es la frecuencia *Doppler*. En este caso $T_{ch} \approx 67ms$ es muy superior al tiempo que pasa entre el primer y último símbolo OFDM representado (cuatro subtramas, 4 ms). Por ello, como puede observarse, el canal no varía prácticamente nada entre los distintos símbolos. La SNR de los pilotos utilizados es de 25 dB, por lo que sumado a la buena densidad de pilotos tanto en frecuencia como en tiempo para este caso concreto, supone una buena estimación de canal.

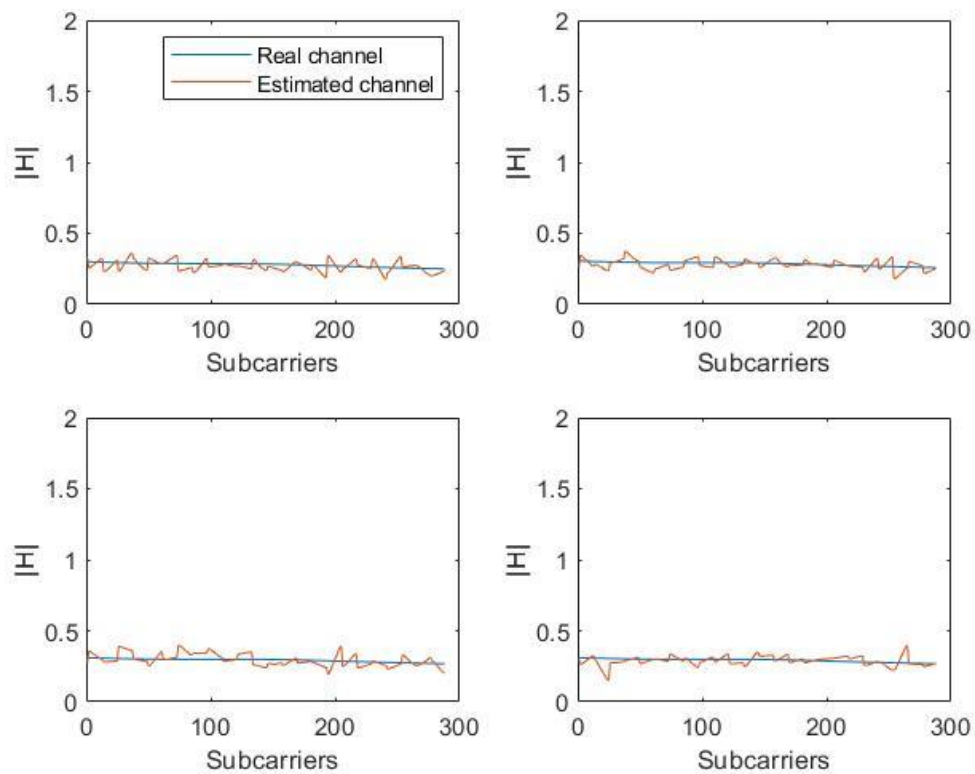


Figura 20. Estimación mediante interpolación lineal de un canal CDL-A, DS = 32 ns, Fd = 5 Hz y SNR = 25 dB.

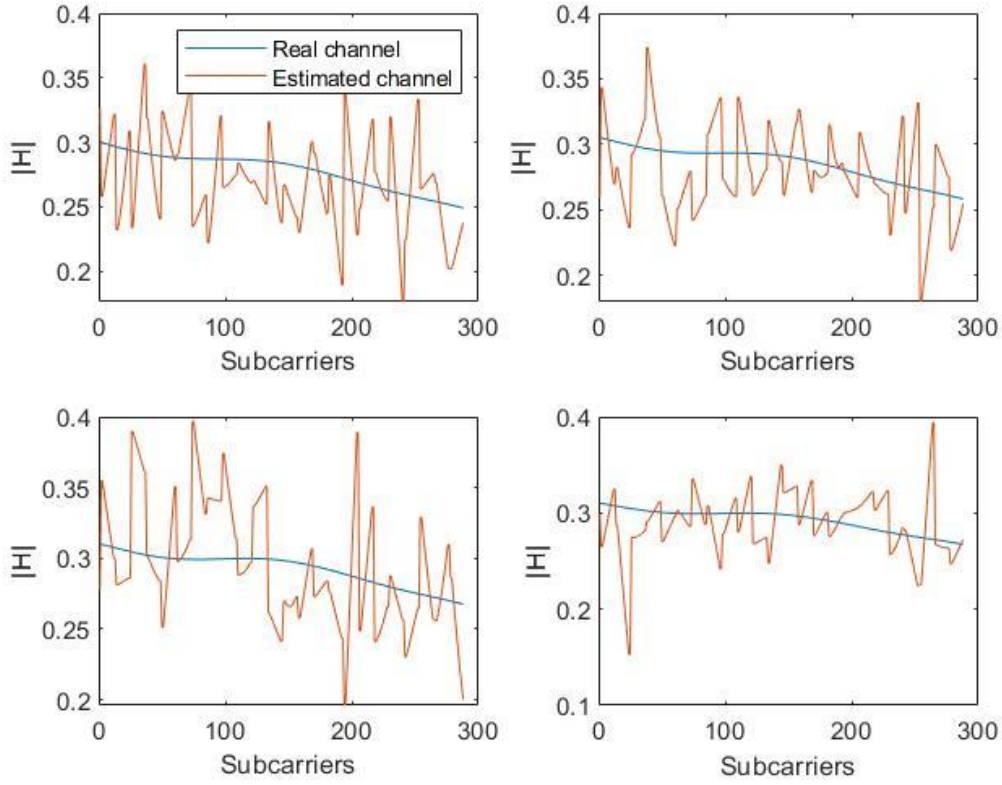


Figura 21. Estimación mediante interpolación lineal de un canal CDL-A, DS = 32 ns, Fd = 5 Hz y SNR = 25 dB (figura ampliada).

Hay que mencionar que la densidad temporal de pilotos utilizada según la especificación de 5G es suficiente, ya que hay pilotos cada *slot* (0.5 ms) y el peor de los casos estudiados es una frecuencia *Doppler* igual a 120 Hz ($T_{ch,min} \approx 2.8ms$).

Sin embargo, en frecuencia el ancho de banda entre los pilotos adyacentes es de 300 KHz (30 KHz x 10 subportadoras) mientras que el ancho de banda de coherencia para un CDL-A y un DS de 1148 ns es de:

$$B_{ch,min} = \frac{1}{3\tau_{max,scaled}} \approx 30KHz \quad (6.4)$$

donde $\tau_{max,scaled} = \tau_{nmax,CDL-A} \cdot DS = 9.6586 \cdot DS \approx 11\mu s$ es la dispersión temporal máxima escalada y $\tau_{nmax,CDL-A}$ es el *normalized delay* máximo.²⁸ Algo parecido sucede para un DS de 363 ns donde $B_{ch} \approx 96KHz$ ($\tau_{max,scaled} \approx 3.5\mu s$). Del mismo modo, en CDL-B, C y con un DS de 363 ns y 1148 ns el ancho de banda de coherencia del canal, donde se puede considerar plano, es menor que el ancho de banda entre pilotos adyacentes. Por ello, teóricamente la distribución de pilotos

²⁸ Ver "Table 7.7.1-1. CDL-A - Table 7.7.1-5. CDL-E", pp. 64-66 en [20].

empleada es suficientemente densa para un DS de 32 *ns*, pero insuficiente para un DS de 363 *ns* o 1148 *ns*. En estos dos últimos casos, la estimación de canal mediante interpolación lineal podría verse afectada negativamente.

El siguiente canal representado en la *Figura 22* corresponde a un CDL-B con un DS de 1148 *ns* (*long-delay profile*). La dispersión temporal máxima en este caso es de $\tau_{\max, scaled} = \tau_{n\max, CDL-B} \cdot DS = 4.7834 \cdot DS \simeq 5.5 \mu s$, por tanto el ancho de banda de coherencia es $B_{ch} \simeq 60.7 KHz$. Por ello se puede observar una notable selectividad en frecuencia a lo largo de las subportadoras, al contrario de lo que sucedía con el canal representado en la *Figura 20*.²⁹ La frecuencia *Doppler* es de 120 *Hz*, por tanto el tiempo de coherencia del canal es $T_{ch} \simeq 2.8 ms$. Este tiempo de coherencia es menor al del anterior canal, por ello se observa una mayor variación entre los coeficientes de canal de las subportadoras de los distintos símbolos OFDM.

El MSE del módulo de los coeficientes de canal calculado en esta memoria es:

$$MSE = \frac{1}{4} \sum_{k=1}^4 \left(\frac{1}{288} \sum_{i=1}^{288} \left\| \hat{h}_{f_i, t_k, a_o} - h_{f_i, t_k, a_o} \right\|^2 \right) \quad (6.5)$$

donde \hat{h}_{f_i, t_k, a_o} son los coeficientes de canal estimado y h_{f_i, t_k, a_o} son los coeficientes del canal real para cada una de las 288 subportadoras ($f_i, i = 1 \dots 288$), los cuatro símbolos OFDM representados ($t_k, k = 1 \dots 4$) y un determinado enlace (a_o).³⁰

En este caso, la SNR vuelve a ser de 25 *dBs*, sin embargo el MSE es de $4.9e-3$, mientras que el MSE de los canales de la *Figura 20* (y *Figura 21*) es de $6.4597e-4$. Esta diferencia se debe a que, como se ha comentado anteriormente, el canal de la *Figura 22* tiene un ancho de banda de coherencia menor al ancho de banda que hay entre los pilotos adyacentes. Es decir, la densidad de pilotos

²⁹ Hay que recordar que se está representando 288 subportadoras que ocupan un total de 8.64 *MHz*; por ello, en la *Figura 20*, sabiendo que al ser un canal CDL-A con un DS de 32 *ns*, el ancho de banda de coherencia es de 1.07 *MHz*, se puede deducir la existencia de aproximadamente nueve canales planos (8.64 / 1.07) en la representación. Por otro lado, para un canal CDL-B con un DS de 1148 *ns* donde el ancho de banda de coherencia es de 60.7 *KHz*, se puede deducir la existencia de aproximadamente 143 canales planos (8.64 *MHz* / 60.7 *KHz*).

³⁰ Los coeficientes de canal son números complejos, por tanto tienen módulo y fase. En esta memoria se está comparando los resultados obtenidos en la estimación de canal mediante el MSE del módulo de los coeficientes. No se ha incluido el MSE de la fase por ser redundante, ya que, por norma general, en las simulaciones presentadas, el MSE de la fase reacciona del mismo modo que el MSE del valor absoluto, es decir son dependientes.

especificada en la distribución utilizada no es teóricamente suficiente para canales con este tipo de características.

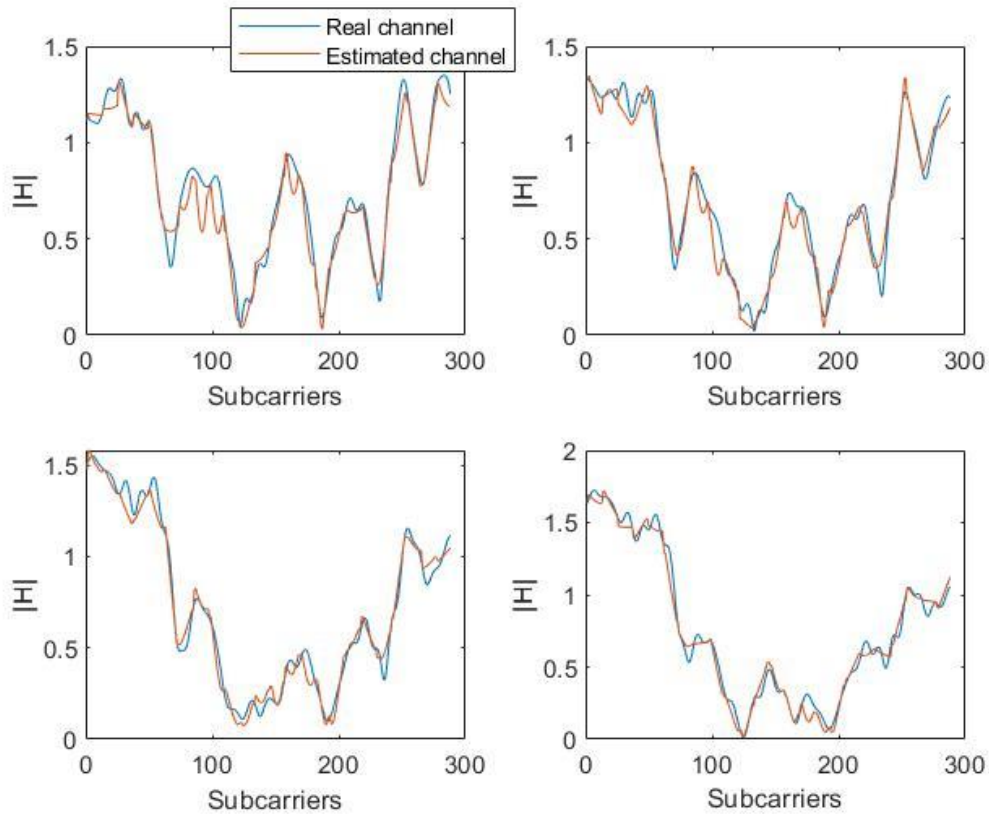


Figura 22. Estimación mediante interpolación lineal de un canal CDL-B, DS = 1148 ns, Fd = 120 Hz y SNR = 25 dB.

La Figura 23 corresponde a un CDL-C con un DS de 363 ns (*normal-delay profile*) y una frecuencia Doppler de 70 Hz. La dispersión máxima del canal es $\tau_{\max, \text{scaled}} = \tau_{n\max, \text{CDL-C}} \cdot DS = 8.6523 \cdot DS \approx 3.14 \mu\text{s}$ y por tanto, el ancho de banda de coherencia es de $B_{ch} \approx 106.13 \text{ KHz}$. Por otra parte, el tiempo de coherencia es $T_{ch} \approx 4.76 \text{ ms}$, por lo que se trata de un canal con una selectividad temporal y frecuencial intermedia entre el canal representado en la Figura 20 (el menos selectivo) y el canal representado en la Figura 22 (el más selectivo). La SNR de los pilotos es de nuevo 25 dBs; el MSE calculado es de $1.2e-3$, un valor intermedio entre el MSE del canal menos selectivo ($6.4597e-4$) y el del canal más selectivo ($4.9e-3$).

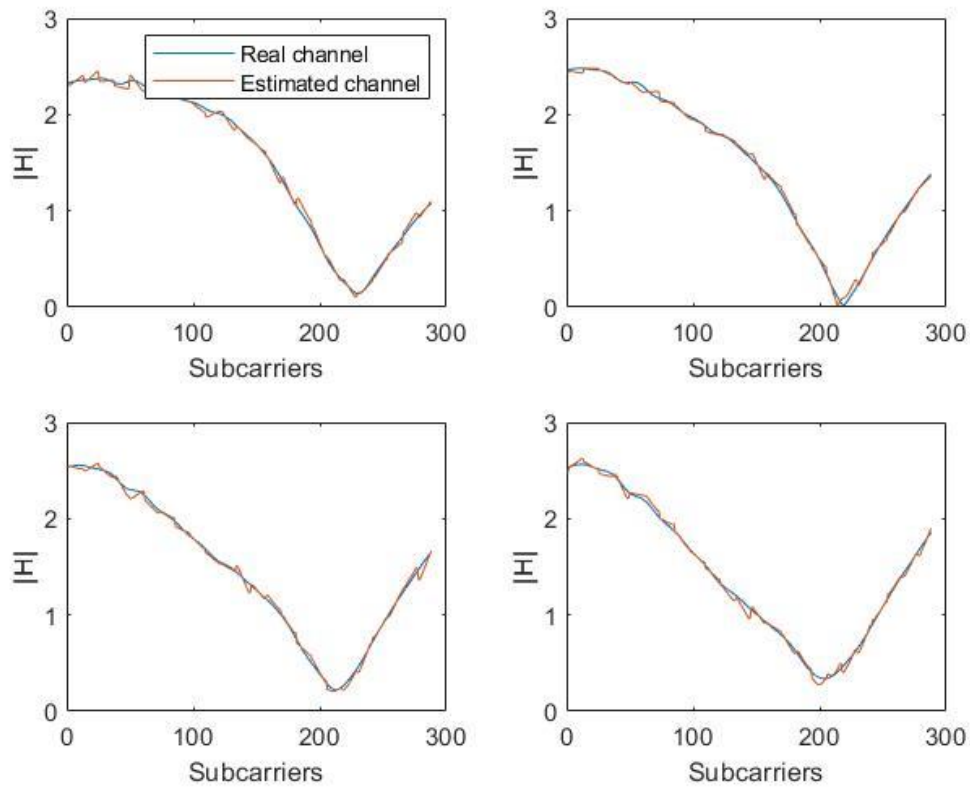


Figura 23. Estimación mediante interpolación lineal de un canal CDL-C, $DS = 363 \text{ ns}$, $Fd = 70 \text{ Hz}$ y $SNR = 25 \text{ dB}$.

Por último, en la *Figura 24* se muestra la interpolación de un canal CDL-C, con un DS de 363 ns y una frecuencia *Doppler* de 70 Hz , igual que en el caso anterior. Por ello, este canal tiene el mismo tiempo y ancho de banda de coherencia del canal representado en la *Figura 22*. Sin embargo, esta vez los pilotos del canal tienen una SNR de 10 dB , la peor de los canales representados hasta el momento; por este motivo, el MSE calculado es el de mayor valor ($2.07e-2$).




Figura 24. Estimación mediante interpolación lineal de un canal CDL-C, $DS = 363 \text{ ns}$, $Fd = 70 \text{ Hz}$ y $SNR = 10 \text{ dB}$.

En la próxima sección, mediante NNs se tratará de minimizar el MSE y mejorar los resultados obtenidos con interpolación.

6.4. Resultados obtenidos mediante Redes Neuronales

Los resultados finales presentados en esta memoria han sido obtenidos mediante una MLP (*Multilayer Perceptron*) con las siguientes características:

- Ocho capas (ver *Figura 25*).
- Función de activación ReLU.
- Inicializador de pesos: *Glorot normal* para la sexta capa y la capa de entrada y *He normal* para el resto.
- Función de coste: MSE.
- Optimizador: RMSprop (*Root Mean Square propagation*).
- Tasa de aprendizaje: 0.01.
- Datos de entrada con 66 elementos (*features*).
- Etiquetas de dimensión 2.
- 1e6 datos de entrenamiento.

- Tamaño de lote (*batch size*): 512.
- 5e4 datos de validación.
- Número de ciclos (*epochs*): 1000.

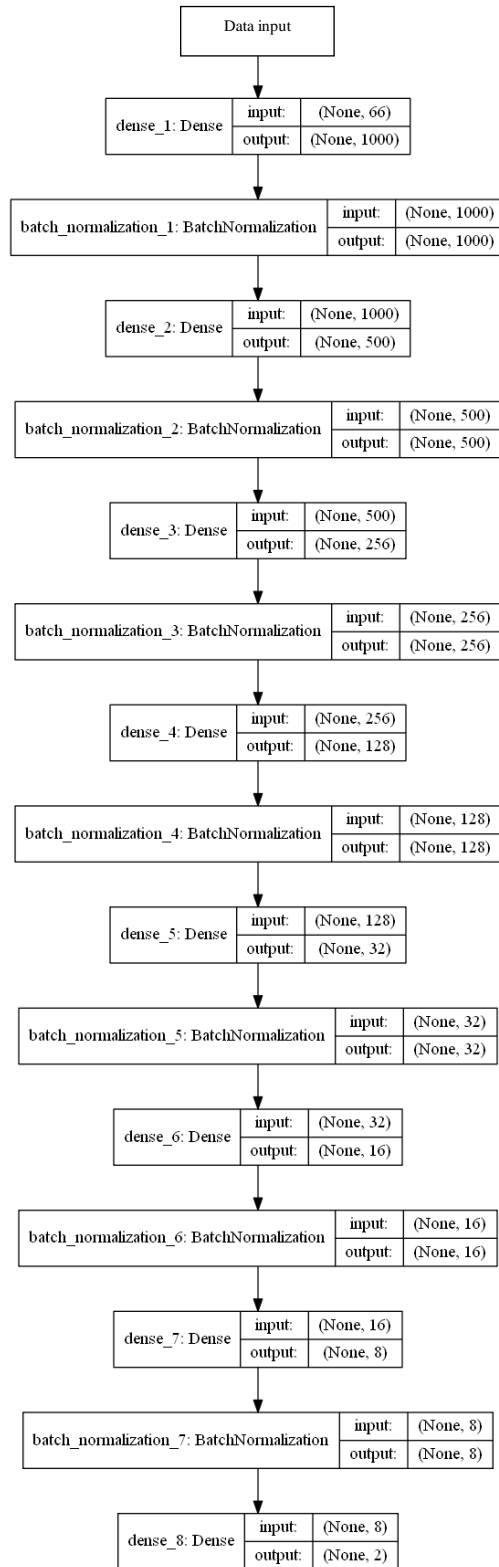


Figura 25. Modelo de red neuronal de ocho capas.

Se ha tratado de elegir un número de neuronas por cada capa lo suficientemente grande para responder correctamente al problema de regresión tratado en esta memoria. Generalmente, exceder el número óptimo de neuronas en cada capa no perjudica al rendimiento de la red neuronal [22]; aunque, evidentemente, mayor será el coste computacional. Además, se ha trabajado con una arquitectura decreciente respecto al número de neuronas entre las capas sucesivas, ya que no se ha encontrado evidencias de que otro tipo de arquitectura (el número de neuronas se mantiene constante entre capas o el número de neuronas crece entre las sucesivas capas) destaque por su rendimiento. Eso sí, debido a la mejora en el rendimiento de las redes neuronales, se ha elegido un número de neuronas en la primera capa oculta muy superior al tamaño del vector de entrada [22].

La inicialización de los pesos tiene que seguir una distribución estadística que debe ser elegida cuidadosamente para evitar la simetría entre neuronas de una misma capa. Es decir, se debe evitar que coincidan los pesos de las neuronas de una determinada capa para que no computen las mismas respuestas de los datos de entrada y no se les aplique una actualización idéntica. Por ello, se ha trabajado con dos inicializaciones distintas: la primera es la denominada *Glorot normal* que sigue una distribución $N(0, 2 / (fan_in + fan_out))$ donde *fan_in* es el número de entradas a la neurona y *fan_out* es el número de salidas de la neurona; la segunda inicialización es la denominada *He normal* que sigue una distribución $N(0, 2 / fan_in)$.³¹ Ambas inicializaciones de los pesos han demostrado dar buenos resultados en múltiples problemas [23, 24].

La función de coste elegida, al tratarse de un problema de regresión, calcula el MSE. El optimizador utilizado es el RMSprop que está basado en el algoritmo de descenso por gradiente, se recomienda dejar intactos sus parámetros por defecto salvo la tasa de aprendizaje que puede ser modificada libremente.³²

La tasa de aprendizaje es probablemente el hiperparámetro más importante en el diseño de una red neuronal. Las tasas típicas para entradas normalizadas, cuyos valores oscilan dentro del intervalo (0,1), son menores que uno y mayores que 10^{-6} . Algunos autores han propuesto métodos para adaptar la tasa de aprendizaje en función de la red neuronal a la que se aplique; por ejemplo, usar una tasa de aprendizaje que provoque una actualización promedia

³¹ Ver: <https://keras.io/initializers/>.

³² Ver: <https://keras.io/optimizers/>.

de los pesos del orden de 10^{-3} la magnitud del peso [25]. En esta memoria se ha empleado una tasa de aprendizaje de 0.01 por ser un valor que generalmente funciona bien para redes neuronales estándar [22].

El tamaño de lote (*batch size*) elegido es de 512, un valor que se ha considerado aceptable para el coste computacional y que permite una gran cantidad de actualizaciones de los pesos en cada ciclo, dado el millón de datos de entrenamiento del que se dispone.

Hay que mencionar que, en este problema, ha resultado imposible realizar una búsqueda exhaustiva de los hiperparámetros óptimos. Debido a que se carece de los recursos computacionales necesarios al tratarse de una red neuronal con un tiempo de entrenamiento de alrededor de las siete horas.

Por otra parte, uno de los principales retos de este problema es ser capaz de obtener un modelo de datos compatible con un entrenamiento supervisado para regresión.

Para ello, se construyó un tensor de canal de dimensiones $288 \times 280 \times 32$ con los pilotos³³ distribuidos según la especificación de 5G (ver *Figura 18*) y rellena de ceros en las posiciones donde no hay pilotos (coeficientes a estimar), tal y como se ilustra en la *Figura 26*.




Figura 26. Tensor de canal con pilotos distribuidos según la especificación de 5G y ceros en el resto de posiciones.

³³ En esta sección cuando se menciona piloto, en realidad se hace referencia al coeficiente de canal calculado a partir del piloto; pero por simplicidad se ha aplicado esta nomenclatura.

En un primer momento se probó dividiendo el tensor de la *Figura 26* en “subtensores” de dimensiones $24 \times 28 \times 32$, tal y como ilustra la *Figura 27*. De forma que se obtuvo una lista de 120 subtensores. Cada uno de ellos con un total de 1024 pilotos y ceros en el resto de posiciones.




Figura 27. Lista de 120 subtensores de dimensión $24 \times 28 \times 32$ y con 1024 pilotos cada uno.

Para el modelo de datos de entrenamiento, se extrajo de cada subtensor los 1024 pilotos y se dividió cada piloto en parte real e imaginaria. Por lo tanto, el vector de características tuvo dimensión (2051), 2048 elementos pertenecían a la parte real e imaginaria de los pilotos del subtensor que contiene al coeficiente que se quiere estimar. Los tres elementos restantes correspondían con la posición, en el canal real simulado ($288 \times 280 \times 32$, *Figura 17*), del coeficiente a estimar (número de subportadora, número de símbolo OFDM y enlace entre la antena de usuario y el *subarray* de la BS). El vector de etiquetas tuvo dimensión dos, un elemento representa la parte real y el otro la parte imaginaria del coeficiente real que se quiere estimar.

Este modelo resultó inapropiado, ya que dentro de un subtensor, 21504 ($24 \times 28 \times 32$) coeficientes compartían las 2048 primeras posiciones del vector de características, difiriendo únicamente en los tres elementos que indican la posición. Además no se disponía de una gran cantidad de subtensores (120 únicamente). Este modelo de datos no permitía a la red neuronal encontrar patrones para estimar correctamente.

Por ello, se cambió de estrategia y se dividió el tensor de canal con pilotos y ceros de la *Figura 26* en matrices de dimensión 24×28 para cada una de las 32

dimensiones del tercer eje. Se obtuvo una lista con un total de 3840 matrices, cada una con 32 pilotos y ceros en el resto de posiciones, tal y como se ilustra en la *Figura 28*.

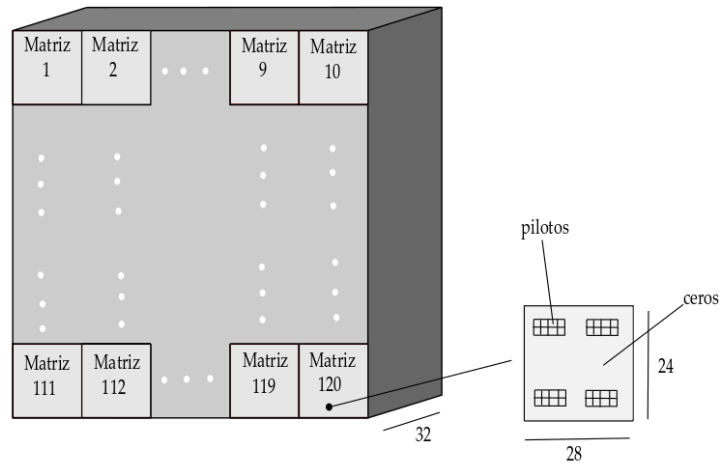


Figura 28. Lista de 3840 matrices de dimensión 24x28 y con 32 pilotos cada una.

Para este nuevo modelo de datos de entrenamiento se extrajo de cada matriz los 32 pilotos y se volvió a dividir cada piloto en parte real e imaginaria. Por lo tanto, el vector de características pasó a tener dimensión 66, donde los 64 primeros elementos corresponden a la parte real e imaginaria de los pilotos de la matriz que contiene al coeficiente a estimar. Los últimos dos elementos corresponden a la posición (subportadora y símbolo OFDM) del coeficiente a estimar en el canal real simulado ($288 \times 280 \times 32$, *Figura 17*). Además, dichas posiciones fueron normalizadas, para suavizar el contraste con los coeficientes de los pilotos, dividiendo entre el valor máximo que pueden tomar (288 para la posición que indica la subportadora y 280 para la posición que indica el símbolo OFDM). El vector de etiquetas contiene de nuevo dos elementos, uno es la parte real y el otro la parte imaginaria del coeficiente que se quiere estimar, obtenido del canal real simulado (*Figura 17*).

Este nuevo modelo de datos reduce el número de coeficientes que comparten pilotos en su vector de características. Se ha pasado de un total de 21504 coeficientes del anterior modelo a 672 (24×28) coeficientes que comparten pilotos. Este es el modelo de datos adoptado para la presentación de resultados en esta memoria. Aunque no es el modelo idóneo, ya que las matrices solamente contienen los pilotos del eje temporal y frecuencial, sin tener en cuenta la

correlación espacial que viene marcada por el tercer eje del tensor. Este detalle será revisado en un futuro, pero no se aplica a esta memoria.

Una vez explicado el modelo de datos utilizado en la memoria se pasa a presentar algunos de los resultados obtenidos. En un primer momento se creó un modelo de red neuronal con las características descritas al comienzo de la sección salvo por el número de capas y neuronas en cada una, como muestra la *Figura 29*; el número de ciclos, 50 ciclos; el número de datos de entrada, 1e5 datos; y el número de datos de validación, 5e3 datos.

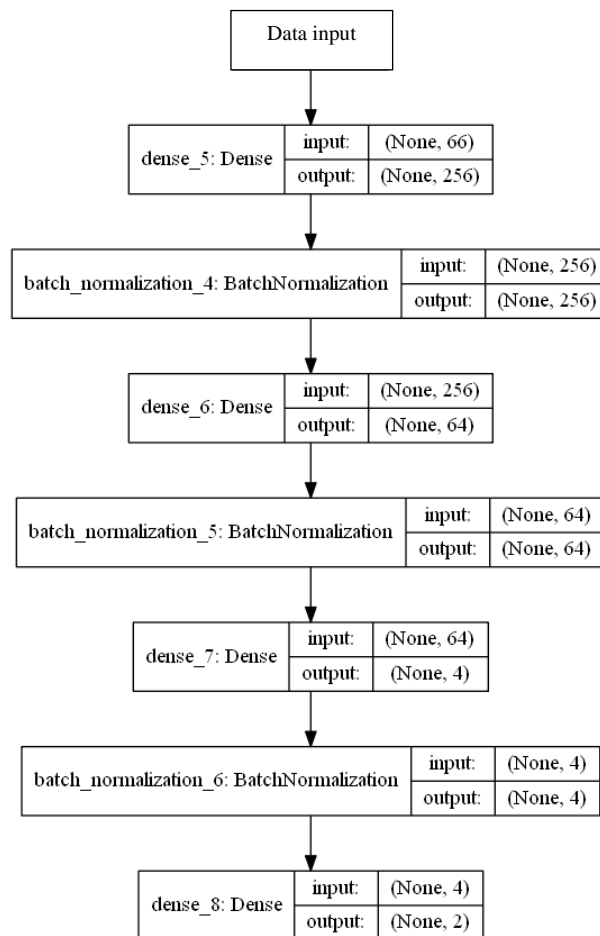


Figura 29. Modelo de red neuronal con cuatro capas.

En la *Figura 30* se representa una comparativa entre el MSE para los datos de entrenamiento frente a los datos de validación en función del ciclo (*epoch*) para un canal CDL-A con un DS de 32 ns, una frecuencia *Doppler* de 5 Hz y una SNR de 25 dB.




Figura 30. MSE en función del ciclo.

En la *Figura 31*, se muestra una comparativa entre la estimación mediante interpolación lineal y mediante dicho modelo de red neuronal. Se obtiene un MSE del valor absoluto del canal de $5.69e-4$ para la interpolación lineal y de $1.3e-3$ para la estimación mediante NN. Se aprecia que el estimador mediante MLP no es insesgado, tiene una media que se desvía del valor medio del canal real; al contrario sucede con el interpolador donde los valores fluctúan en torno al valor medio del canal real. Además, la forma de onda estimada mediante la red neuronal adopta un patrón similar a la de una interpolación lineal de orden cero.




Figura 31. Comparativa de estimaciones de un canal CDL-A, $DS = 32 \text{ ns}$, $F_d = 5 \text{ Hz}$ y $SNR = 25 \text{ dB}$.

Con el fin de mejorar los resultados obtenidos en la *Figura 31* y observando en la *Figura 30* que el valor del MSE decaía, aunque lentamente, con el aumento de los ciclos, se decidió aumentar este último a 500. En la *Figura 32* y en la *Figura 33* se representa una comparativa entre el MSE para los datos de entrenamiento frente a los datos de validación en función del ciclo para un CDL-A con un DS de 32 ns , una frecuencia *Doppler* de 5 Hz y una SNR de 25 dB .




Figura 32. MSE en función del ciclo.




Figura 33. MSE en función del ciclo (figura ampliada).

En la *Figura 34*, se muestra de nuevo una comparativa entre la estimación mediante interpolación lineal y mediante la NN entrenada con 500 ciclos. Se obtiene un MSE del valor absoluto del canal de $1.52e-3$ para la interpolación lineal y de $1.56e-3$ para la estimación mediante NN.




Figura 34. Comparativa de estimaciones de un canal CDL-A, $DS = 32 \text{ ns}$, $F_d = 5 \text{ Hz}$ y $SNR = 25 \text{ dB}$.

Los MSEs de estas dos estimaciones son similares; sin embargo, con el fin de que la estimación mediante red neuronal superase definitivamente a la

interpolación lineal y observando que con este modelo el MSE se reducía muy lentamente con el transcurso de los ciclos (*Figura 33*), se optó por crear un modelo con los parámetros descritos al comienzo de la sección. Se aumentó el número de ciclos, de datos de entrenamiento y de datos de validación a 1000, 1e6 y 5e4 respectivamente. Además, se cambió al modelo de capas representado en la *Figura 25*.

En la *Figura 35* y en la *Figura 36* se representa una comparativa entre el MSE para los datos de entrenamiento frente a los datos de validación en función del ciclo y aplicando el nuevo modelo para un CDL-A con un DS de 32 ns, una frecuencia Doppler de 5 Hz y una SNR de 25 dB. Se observa que el MSE es más pequeño que en las anteriores figuras en las que aplicábamos otro modelo distinto.




Figura 35. MSE en función del ciclo.




Figura 36. MSE en función del ciclo (figura ampliada).

En la *Figura 37*, se muestra una comparativa entre la estimación mediante interpolación lineal y mediante el nuevo modelo de red neuronal. Se obtiene un MSE del valor absoluto del canal de $7.97e-4$ para la interpolación lineal y de $5.92e-4$ para la estimación mediante NN. El estimador mediante MLP sigue sin ser insesgado, tiene una media que se desvía ligeramente del valor medio del canal real. Sin embargo, la forma de onda del canal estimado mediante MLP se ajusta muy bien a la forma real del canal, al contrario que el canal interpolado. Por ello, se obtiene un MSE menor que el obtenido con un interpolador lineal.

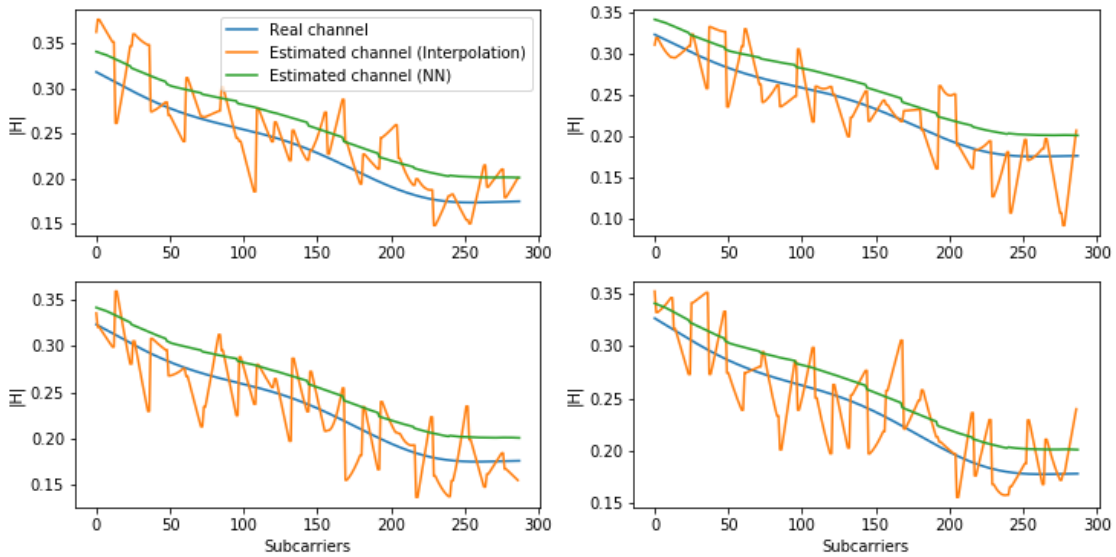


Figura 37. Comparativa de estimaciones de un canal CDL-A, $DS = 32 \text{ ns}$, $F_d = 5 \text{ Hz}$ y $SNR = 25 \text{ dB}$.

En la *Figura 38* se representa una comparativa entre el MSE para los datos de entrenamiento frente a los datos de validación en función del ciclo y aplicando el nuevo modelo a un canal CDL-B con un DS de 1148 ns , una frecuencia *Doppler* de 120 Hz y una SNR de 25 dB . Se observa que para este tipo de canal, el MSE tiende a bajar muy rápidamente hasta en torno el ciclo 250 y a partir de este, continúa el descenso más lentamente. También, se observa que la gráfica no termina de converger en el ciclo 1000, así que para este tipo de canal es probable que con un entrenamiento con más ciclos se siga consiguiendo mejores resultados.




Figura 38. MSE en función del ciclo.

En la *Figura 39* se muestra la comparativa entre las estimaciones mediante interpolación lineal y mediante redes neuronales. En esta ocasión, el interpolador lineal obtiene un mejor resultado de MSE con un $2.3e-2$ frente al $9.7e-2$ obtenido por la estimación mediante MLP.




Figura 39. Comparativa de estimaciones de un canal CDL-B, $DS = 1148 \text{ ns}$, $F_d = 120 \text{ Hz}$ y $SNR = 25 \text{ dB}$.

En la *Figura 40* (*Figura 41*, ampliada) se muestra una comparativa entre el MSE para los datos de entrenamiento frente a los datos de validación en función del ciclo y para un canal CDL-C con un DS de 363 ns , una frecuencia *Doppler* de 70 Hz y, esta vez, una SNR de 10 dB . Se observa que el MSE tiende a converger cuando el número de ciclos se hace grande; por ello, para este tipo de canal con una SNR peor que la de los anteriores, es probable que funcione mejor otro modelo de red neuronal.




Figura 40. MSE en función del ciclo.




Figura 41. MSE en función del ciclo (figura ampliada).

En la *Figura 42*, se muestra la comparativa entre las estimaciones; el interpolador lineal obtiene de nuevo un menor MSE de $3.5e-2$ frente al $1.1e-1$ obtenido mediante MLP.

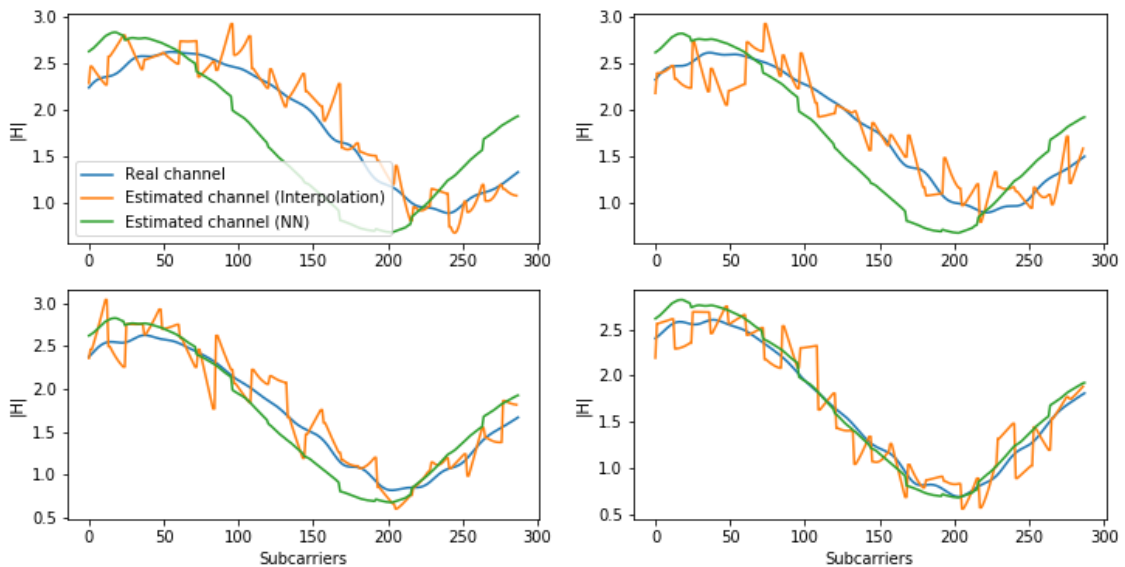


Figura 42. Comparativa de estimaciones de un canal CDL-C, $DS = 363 \text{ ns}$, $F_d = 70 \text{ Hz}$ y $SNR = 10 \text{ dB}$.

Capítulo 7

Conclusiones y líneas futuras

7.1. Conclusiones

A través de las redes inalámbricas circula la mayor parte del tráfico IP, además la sociedad moderna demanda comunicaciones fiables, seguras, con un gran ancho de banda, baja latencia y más. Por ello se ha desarrollado 5G que promete tres servicios fundamentales: eMBB, mMTC y URLLC. 5G se apoya en tecnologías clave para satisfacer estos servicios: *new spectrum, beamforming, slicing and flexibility, dual connectivity, mobile edge computing*.

Es posible mejorar la capacidad de tráfico global aumentando el número de estaciones base o aumentando el espectro disponible. Sin embargo, *Massive MU MIMO* permite la mejora mediante el aumento de la eficiencia espectral; sin necesidad de crear nueva infraestructura y sin elevar enormemente el coste del sistema.

El aumento de la potencia de transmisión en la estación base permite mejorar la capacidad de canal hasta un límite determinado por el cociente entre la ganancia de canal interferente y la ganancia de canal deseado ($\bar{\beta}$). Sin embargo, el potencial de *Massive MU MIMO* es ilimitado y la capacidad de canal mejorará con el aumento del número de antenas que forman el *array* y con el aumento del número de usuarios a los que se sirve en el mismo recurso tiempo-frecuencia.

Por ello, *Massive MU MIMO* es una de las tecnologías más prometedoras para satisfacer el servicio eMBB de 5G.

En radiocomunicaciones móviles es indispensable tener conocimiento del canal, tanto para la demodulación como para el diseño de ecualizadores o para optimizar algún parámetro de la red (tasa de transmisión, por ejemplo). Además, en sistemas MIMO es necesario conocer el canal para calcular la matriz de precodificación, permitiendo así la comunicación entre distintos usuarios mediante multiplexación espacial (SDMA).

El modelo de canal 3D del 3GPP para sistemas *Massive MIMO* representa con mayor fidelidad, respecto a los modelos teóricos tradicionales (modelo de canal *Rayleigh* correlado, entre otros), tanto las características como algunos de los fenómenos que aparecen en los canales reales de este tipo de sistemas (*nonstationary phenomnom* y *near-field effect*, entre otros).

El conocimiento de canal tradicionalmente se viene adquiriendo mediante la inserción de símbolos conocidos (pilotos) en algunas subportadoras (frecuencia) y símbolos OFDM (tiempo) y la posterior estimación de los coeficientes desconocidos mediante la interpolación lineal.

El canal estimado debe ajustarse lo máximo posible al canal real, un gran desajuste entre estos provocará la interferencia entre los distintos usuarios servidos mediante SDMA en sistemas MU MIMO. Por ello, es de interés mejorar la estimación lograda por los mencionados interpoladores lineales.

Una de las líneas posibles para dicha mejora es aplicar inteligencia artificial (*machine learning, deep learning*). En esta memoria se ha comparado los resultados obtenidos mediante interpolación lineal con los resultados obtenidos mediante redes neuronales. En algunos casos, en concreto con canales poco variantes temporalmente y con poca selectividad frecuencial, se ha obtenido resultados positivos. En otros casos, con canales con alta selectividad temporal y frecuencial, la estimación mediante interpolación lineal ha superado a la estimación mediante redes neuronales.

Sin embargo, aún queda mucho por estudiar y probar; *deep learning* tiene el suficiente potencial para mejorar en cualquier situación una estimación mediante interpolación lineal.

7.2. Líneas futuras de investigación

Los resultados presentados en la estimación de canal mediante redes neuronales forman parte de la primera fase del proyecto de investigación "*Inteligencia artificial aplicada para convertir una red radio de telecomunicaciones en predictiva*" en el marco del programa *Vodafone Campus Lab*.

Aún queda mucho recorrido por delante para lograr que la estimación mediante redes neuronales supere a la lograda mediante interpolación lineal en cualquier tipo de escenarios, independientemente del tipo de canal (selectividad temporal y frecuencial, SNR, entre otros).

A día de hoy, algunas de las líneas futuras de investigación para lograr una red neuronal consistente son:

- Aplicar técnicas para reducir el sobreajustamiento (*dropout*, entre otras) para que la red responda mejor a los datos de test.
- Estudiar los hiperparámetros observando cómo influyen en la estimación y ajustarlos para minimizar el MSE.
- Trabajar con redes neuronales convolucionales (CNN, por sus siglas en inglés) que permitan considerar la estructura de los canales. Al contrario de lo que sucede con la red neuronal presentada, en la que los datos de entrada consisten en vectores con pilotos y posiciones rompiendo, de este modo, la estructura del canal (tensor con tres ejes).
- Entrenar redes neuronales que generalicen correctamente, es decir, que respondan positivamente independientemente del tipo de canal (más o menos selectivo, con mejor o peor SNR, entre otras características). En lugar de tener que entrenar distintas redes para cada tipo de canal.

Bibliografía

- [1] «Cisco Visual Networking Index: Forecast and Trends, 2017–2022.,» CISCO, 2019.
- [2] E. Björnson, J. Hoydis y L. Sanguinetti, *Massive MIMO Networks: Spectral, Energy, and Hardware Efficiency*, 2017.
- [3] S. Chen y J. Zhao, «The Requirements, Challenges, and Technologies for 5G of Terrestrial Mobile Telecommunication,» *IEEE Communications Magazine*, 2014.
- [4] H. Ji, S. Park, J. Yeo, Y. Kim, J. Lee y B. Shim, «Ultra-Reliable and Low-Latency Communications in 5G Downlink: Physical Layer Aspects,» *IEEE Wireless Communications*, 2018.
- [5] S. Parkvall, E. Dahlman, A. Furuskär y M. Frenne, «NR: The New 5G Radio Access Technology,» *IEEE Communications Standards Magazine*, 2017.
- [6] «ATENUACIÓN DEBIDA A LOS GASES ATMOSFÉRICOS,» *Rec. UIT-R P.676-11*, 2016.
- [7] «Hybrid Beamforming for Massive MIMO Phased Array Systems,» *MathWorks*, 2017.
- [8] E. Björnson, L. V. d. Perre, S. Buzzi y E. G. Larsson, «Massive MIMO in Sub-6 GHz and mmWave: Physical, Practical, and Use-Case Differences,» *IEEE Wireless Communications*, 2019.
- [9] R. P. Antonioli, G. C. Parente, C. F. M. e. Silva, E. B. Rodrigues, T. F. Maciel y F. R. P. Cavalcanti, «Dual Connectivity for LTE-NR Cellular Networks,» 2017.
- [10] Y. C. Hu, M. Patel, D. Sabella, N. Sprecher y V. Young, «Mobile Edge Computing: A key technology towards 5G,» ETSI (European Telecommunications Standards Institute), 2015.
- [11] J. M. H. Rábanos, L. M. Tomás y J. M. R. Salís, «2.7.4. Modulación digital con multiportadora,» de *Comunicaciones móviles*, Madrid, Editorial Universitaria Ramón Areces, 2015, pp. 89-93.

- [12] «5G NR: Physical channels and modulation,» ETSI TS 138 211 - 3GPP TS 38.211 , Sophia Antipolis Cedex - FRANCE, 2018.
- [13] A. R. C. Lechtaler y R. J. Fusario, Teleinformática para Ingenieros en Sistema de Información, Reverté, s.a, 1999.
- [14] C. B. Hugo Alvarado, «EL SIGNIFICADO DEL TEOREMA CENTRAL DEL LÍMITE: EVOLUCIÓN HISTÓRICA A PARTIR DE SUS CAMPOS DE PROBLEMAS».
- [15] L. Lu, G. Y. Li, A. L. Swindlehurst, A. Ashikhmin y M. Rui Zhang, «An Overview of Massive MIMO: Benefits and Challenges,» *IEEE JOURNAL OF SELECTED TOPICS IN SIGNAL PROCESSING*, VOL. 8, NO. 5, 2014.
- [16] E. Björnson, Mats Bengtsson y B. Ottersten, «Optimal Multiuser Transmit Beamforming: A Difficult Problem with a Simple Solution Structure,» *IEEE Signal Processing Magazine*, 2014.
- [17] «WINNER II Channel Models, Deliverable D1. 1.2 V1.2, IST-4-027756,» 4 Feb. 2008.
- [18] «WINNER+ Final Channel Models, Deliverable D5.3 V1.0,» 30. Jun. 2010.
- [19] 3. T. 3. V1.3.0, «3rd Generation Partnership Project; Technical Specification Group Radio Access Network; Study on 3D channel model for LTE (Release 12),» 2013.
- [20] «5G; Study on channel model for frequencies from 0.5 to 100 GHz (3GPP TR 38.901 version 14.0.0 Release 14),» 2017.
- [21] M. A. Nielsen, Neural Networks and Deep Learning, Determination Press, 2015.
- [22] Y. Bengio, «Practical Recommendations for Gradient-Based Training of Deep Architectures,» 2012.
- [23] X. Glorot y Y. Bengio, «Understanding the difficulty of training deep feedforward neural networks».
- [24] K. He, X. Zhang, S. Ren y J. Sun, «Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification,» 2015.

- [25] G. Hinton, «A Practical Guide to Training Restricted Boltzmann Machines,» Department of Computer Science, University of Toronto, August 2, 2010.
- [26] MathWorks, «MATLAB WebSite,» 2019. [En línea]. Available: <https://es.mathworks.com/products/matlab.html>.
- [27] MathWorks, «MATLAB WebSite,» 2019. [En línea]. Available: <https://es.mathworks.com/products/5g.html>.
- [28] «Python WebSite,» 2019. [En línea]. Available: <https://www.python.org>.
- [29] «Keras WebSite,» 2019. [En línea]. Available: <https://keras.io>.
- [30] «Setting the Scene for 5G: Opportunities and Challenges,» ITU, Geneva, 2018.
- [31] B. Mondal, T. A. Thomas, E. Visotsky, F. W. Vook, A. Ghosh, Y.-H. Nam, Y. Li, C. Zhang, M. Zhang, Q. Luo, Alcatel-Lucent, Y. Kakishima y K. Kitao, «3D Channel Model in 3GPP».
- [32] F. Chollet, Deep Learning with Python, Manning, 2018.
- [33] K. Zheng, S. Ou y a. X. Yin, «Massive MIMO Channel Models: A Survey,» *International Journal of Antennas and Propagation*, 2014.

Anexos

A1. Software utilizado

Este proyecto ha sido desarrollado con MATLAB y Python. A continuación se hará una pequeña introducción de estos.

A1.1. MATLAB

MATrix LABoratory (MATLAB) combina un entorno de escritorio perfeccionado para el análisis iterativo y los procesos de diseño con un lenguaje de programación que expresa las matemáticas de matrices y *arrays* directamente [26].

MATLAB permite el manejo de *Toolbox* que se desarrollan de forma profesional, pasan pruebas rigurosas y están totalmente documentadas.

La *5G Toolbox* proporciona funciones conformes a estándares y ejemplos de referencia para el modelado, la simulación y la verificación de sistemas de comunicaciones 5G [27]. En esta memoria se ha empleado para la simulación y análisis de canales CDL de sistemas *Massive MIMO*.

Además, MATLAB se usa en diversos campos de estudio, algunos de ellos son:

- Comunicaciones inalámbricas.
- Análisis de datos.
- Procesamiento de señal
- Finanzas cuantitativas y gestión de riesgos.
- Robótica.
- Visión artificial.
- *Deep Learning*.

Por todo esto, MATLAB es una herramienta fundamental tanto para el ámbito académico como para el profesional.

A1.2. PYTHON

Python es un lenguaje de programación interpretado, de tipado dinámico, multiplataforma y completamente gratuito, cuya filosofía hace hincapié en una sintaxis que permita un código legible [28].

Python consta de numerosas bibliotecas que dan soporte a funcionalidades en diversos campos de conocimiento. Para el desarrollo de *deep learning* de esta memoria, se ha empleado la biblioteca Keras [29].

Otras aplicaciones son:

- Desarrollo de software.
- Desarrollo de aplicaciones web.
- Aplicaciones de negocios.
- Análisis de datos.
- Educación (introducción a la programación).

A2. Lista de acrónimos

Tabla 5. Tabla de acrónimos.

Acrónimo	Correspondencia
3GPP	3rd Generation Partnership Project
AoA	Angle of Arrival
AoA	Azimuth of Arrival
AOA	Azimuth angle Of arrival
AOD	Azimuth angle Of Departure
AS	Angular Spread
ASD	Angular Standard Deviation
AWGN	Additive White Gaussian Noise
BS	Base Station
CBSM	Correlation-Based Stochastic Model
DS	Delay Spread
eMBB	enhanced Mobile Broadband
ETSI	European Telecommunications Standards Institute
GBSM	Geometry-Based Stochastic Model
GPRS	General Packet Radio Service
GSM	Global System for Mobile communications
IMT	International Mobile Communications
IP	Internet Protocol
ISD	Inter Site Distance
ISI	InterSymbol Interference
ITU	International Telecommunication Union
LTE	Long Term Evolution
MATLAB	MATrix LABoratory
mMTC	massive Machine-Type Communications
MU MIMO	Multi-User Multiple-Input Multiple-Output
PSK	Phase Shift Keying
QAM	Quadrature Amplitude Modulation
RAN	Radio Access Network
RB	Resource Block
RE	Resource Element
RG	Resource Grid
SCS	SubCarrier Spacing
SDMA	Space Division Multiple Access
SF	Shadow Fading
SINR	Signal to Interference plus Noise Ratio
SISO	Simple-Input Simple-Output
SNR	Signal to Noise Ratio

TDD	Time-Division Duplexing
TFG	Trabajo Fin de Grado
UE	User Equipment
UMTS	Universal Mobile Telecommunications System
URLLC	Ultra Reliable Low Latency Communications
XPR	Cross-Polarization Ratio
ZOA	Zenith angle OF Arrival
ZOD	Zenith angle OF Departure

A3. Lista de símbolos

Tabla 6. Tabla de símbolos.

Símbolo	Significado
T_c	Unidad básica temporal
T_f	Tiempo de trama
T_{sf}	Tiempo de subtrama
T_u	Tiempo útil de símbolo
T_g	Tiempo de guarda
$N_{symb}^{subframe\mu}$	Número de símbolos OFDM por subtrama en función de la numerología
N_{symb}^{slot}	Número de símbolos OFDM por slot
$N_{slot}^{subframe}$	Número de <i>slots</i> por subtrama
$N_{RB}^{\max,\mu}$	Número máximo de RBs en función de la numerología
$N_{RB}^{\min,\mu}$	Número mínimo de RBs en función de la numerología
N_{SC}^{RB}	Número de subportadoras por RB
τ_{\max}	Dispersión temporal máxima