

Deep Learning Coordinated Beamforming

Raúl Hartmam

Abstract—En una red inalámbrica que opera con ondas milimétricas, las enormes pérdidas de propagación obligan a utilizar antenas con arreglos de muchos elementos en las radiobases, para poder enfocar la energía transmitida en forma de haces específicos para cada usuario (beamforming). En el caso de beamforming analógico, el entrenamiento de la red de radiobases para determinar el haz óptimo para cada usuario puede consumir una gran cantidad del tiempo de trama disponible para transmisiones de datos útiles, dado que se requiere realizar un escaneo con todos los haces disponibles. Se propone un modelo de aprendizaje profundo que intenta aprender cuál es el haz óptimo para cada usuario a partir de la señal recibida por las radiobases en su configuración de antena omnidireccional, evitando el barrido de entrenamiento y liberando tiempo de trama para la transmisión de datos útiles, lo que incrementa la tasa efectiva de transmisión de todo el sistema. Se simula el modelo a partir de datos públicos generados por un simulador comercial por trazado de rayos. Para el escenario simulado se compara un modelo de regresión versus un modelo de clasificación.

I. INTRODUCCIÓN

De acuerdo a las referencias [1] generales existen varias aplicaciones de ML/DL/RL en temas de comunicaciones inalámbricas. En la referencia [2] se plantea el uso de aprendizaje profundo para estimar el enfoque de los haces de beamforming a partir de señales piloto en el canal inalámbrico reverso. El abordaje convencional para esta estimación es utilizar los algoritmos clásicos de forzado a cero, máxima verosimilitud y otros. En este trabajo se concluye que con algoritmos de aprendizaje profundo se pueden alcanzar desempeños similares o mejores. El trabajo anterior utiliza como fuente de datos simuladores comerciales basados en trazado de rayos [3], de los que hay ejemplos en [4] de acceso libre para uso académico y benchmarking de diferentes algoritmos de aprendizaje automático [5].

El presente trabajo se plantea reproducir alguna de las simulaciones realizadas en el trabajo [2]. La estructura de tareas desarrollada es la siguiente: 1) Repasar herramientas de aprendizaje automático Keras y Tensorflow 2) Poner en funcionamiento el entorno disponible de la referencia [6]. 3) Reproducir los resultados presentados en el artículo [2].

II. MODELO DEL SISTEMA

A. Entorno de propagación

El trabajo se enmarca en un entorno de propagación inalámbrico del tipo urbano. Las bandas de operación son las llamadas milimétricas, es decir frecuencias mayores a 30 GHz. En particular para el trabajo se emplea la banda de 60 GHz, con uso estandarizado para redes 802.11ad/ay y posiblemente tecnologías celulares de quinta generación (5G).

El modelo simula un despliegue de celdas pequeñas, típicamente en postes de iluminación a alturas del orden de

10 metros y con una separación entre sí del orden de 100 metros. Se consideran usuarios pedestres o vehiculares con velocidades de desplazamiento típicas en cada caso y con antenas omnidireccionales de un solo elemento.

B. Tecnología de transmisión

Cada radiobase presenta un arreglo (array) de antenas en dos dimensiones capaz de enfocar (beamform) sus transmisiones de forma analógica, alterando para ello magnitud y fase de cada elemento del arreglo de forma independiente. Se trata entonces de un sistema de beamforming analógico con una sola cadena de RF por radiobase.

A su vez, como se muestra en la figura 1, existe una unidad central de coordinación de las transmisiones de cada radiobase hacia un usuario en un instante dado. Esa unidad central modula en banda base los símbolos para varias radiobases dentro del alcance del usuario y de acuerdo a la información de canal disponible para cada par de radiobases y usuarios. De esa forma el usuario recibe de forma coherente la señal de varias radiobases, incrementando la cobertura y capacidades del sistema.

El entrenamiento del canal se realiza mediante una secuencia de símbolos conocidos enviados por el usuario en uplink (pilots), uno para cada configuración de códigos de beamforming o en la interpretación geométrica, un pilot por cada orientación del haz de la radiobase. La radiobase registra la señal recibida para cada enfoque y la envía a la unidad central, donde se determina cuál es el enfoque óptimo y el patrón asociado para el arreglo.

La figura de mérito referente a la capacidad del sistema tiene dos componentes. La primera corresponde a la tasa agregada (sum rate) de todos los usuarios, calculada mediante el límite de Shannon y determinada por la ganancia del beamforming óptimo. La segunda componente es proporcional a $(1 - N_{tr}T_p/T_b)$, siendo N_{tr} la cantidad de pilots de entrenamiento en uplink, T_p el tiempo que insume la transmisión de cada pilot y T_b el tiempo de coherencia de beamforming. T_b representa el tiempo en que es necesario volver a aprender el canal debido a la movilidad. Este segundo factor representa entonces la fracción de tiempo efectiva disponible para transmitir datos útiles de usuario, descontando el tiempo de entrenamiento necesario para encontrar el enfoque óptimo de los arreglos en cada radiobase. El tiempo de entrenamiento es proporcional a la cantidad de patrones de enfoque del arreglo de antena, a su vez proporcional a la cantidad de elementos de la antena, que debe ser grande si se requieren ganancias grandes.

De acuerdo a las referencias [5], el tiempo de entrenamiento puede ocupar hasta un 45 % del tiempo de coherencia de

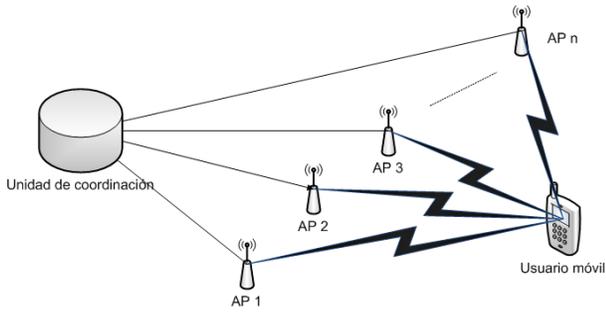


Fig. 1: Sistema de transmisión

beamforming, que en algunos casos puede ser del entorno de 20 ms según la referencia citada.

III. MODELO DE APRENDIZAJE PROFUNDO

De acuerdo a lo anterior, uno de los problemas principales para las comunicaciones en bandas milimétricas y en el caso de beamforming analógico, es el excesivo costo en tiempo en el aire generado por el barrido sobre todos los haces disponibles en la radiobase para encontrar el óptimo para cada móvil. Los diferentes métodos propuestos hasta el momento no hacen uso de la información pasada, es decir que es necesario ejecutar enteramente el algoritmo de entrenamiento sin información anterior.

1) *Sistema propuesto:* El sistema propuesto funciona en dos fases. En la primera fase de entrenamiento se aprende la relación entre la señal recibida de los pilotos y la tasa alcanzable para cada código de beamforming, es decir para cada orientación de los haces, realizando el entrenamiento convencional de barrido. Lo anterior vale para cada radiobase donde se recibió una señal útil.

Se tienen N modelos de aprendizaje, uno por cada radiobase, pero cada modelo recibe como datos de entrada los de todas las radiobases, es decir que los datos de entrada son los mismos para todos los modelos. La entrada al sistema la forman los NK símbolos recibidos en el modo de recepción quasi omni por cada radiobase, siendo N el número de radiobases y K el número de subportadoras OFDM empleados. La normalización de las entradas se hace para todos los datos, para no perder correlaciones entre subportadoras, entre radiobases y entre muestras. La salida del modelo se conforma con las estimaciones de la tasa de datos para cada haz del conjunto de haces. Tomando el máximo sobre el conjunto de haces se puede hallar el haz óptimo. Por cada tiempo de coherencia de haz se tienen $N \cdot K$ entradas complejas y $N \cdot N_{tr}$ tasas para cada haz para cada radiobase. El objetivo del entrenamiento es minimizar el error cuadrático medio de las tasas reales respecto a las estimadas. En la figura 3 se muestra un esquema del esquema de entrenamiento para una radiobase.

2) *Datos de entrenamiento, validación y test:* Debido a restricciones en los recursos del hardware disponible para realizar las simulaciones y generar los datos de entrada y procesamiento del modelo, se optó por el siguiente escenario acotado:

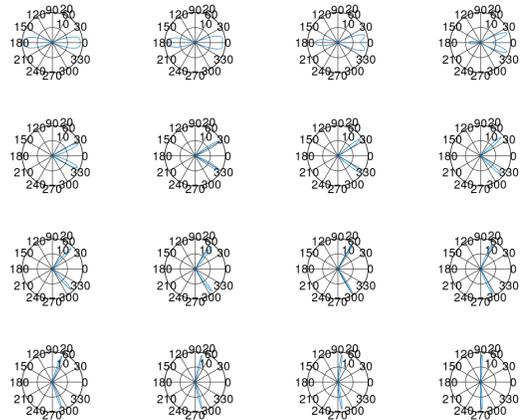


Fig. 2: Patrones de los haces BF para índices 1 a 16

- 1) Antenas de 32 elementos en acimut y omnidireccionales en elevación. Esto restringe la cantidad de haces a predecir a 32. El problema de entrenamiento del beamforming es elegir un sector óptimo dentro de las 32 posibilidades disponibles. El diagrama de radiación para cada caso se muestra en la figura 2.
- 2) Usuarios limitados a una zona rectangular entre 4 estaciones base. De esta manera, para cada estación base intervienen solamente la mitad de los haces que iluminan esta zona. Si bien esta elección es poco realista dado que en una red real los usuarios estarán distribuidos a lo largo de toda la cobertura de la antena, esta simulación permite evaluar el entrenamiento con datos parciales, además de bajar considerablemente los requerimientos de recursos de cálculo.
- 3) Cuatro estaciones base, ubicadas en los vértices de la zona de estudio para generar datos, como se muestra en la figura 4.
- 4) Un solo modelo de predicción. Dado que los modelos generados se entrenan y predicen de forma individual, se modificaron los códigos para realizar el entrenamiento para un solo modelo, a los efectos de reducir los tiempos de cálculo a límites razonables. Sin embargo, las entradas al modelo se mantuvieron en cuatro radiobases, es decir que el modelo predice en base símbolos recibidos por las cuatro radiobases involucradas.
- 5) Se limitaron los caminos estudiados a solo uno, eligiendo el de mayor potencia de señal que probablemente corresponda al camino con línea de vista.
- 6) Se simuló una sola sub portadora OFDM, siendo un sistema de banda angosta. Se pierde la información de propagación asociada a la respuesta en frecuencia.
- 7) Se eliminó el ruido en los scripts de simulación para acotar las variables a estudiar. Se deja para trabajos posteriores el análisis de diferentes condiciones de relación señal a ruido.

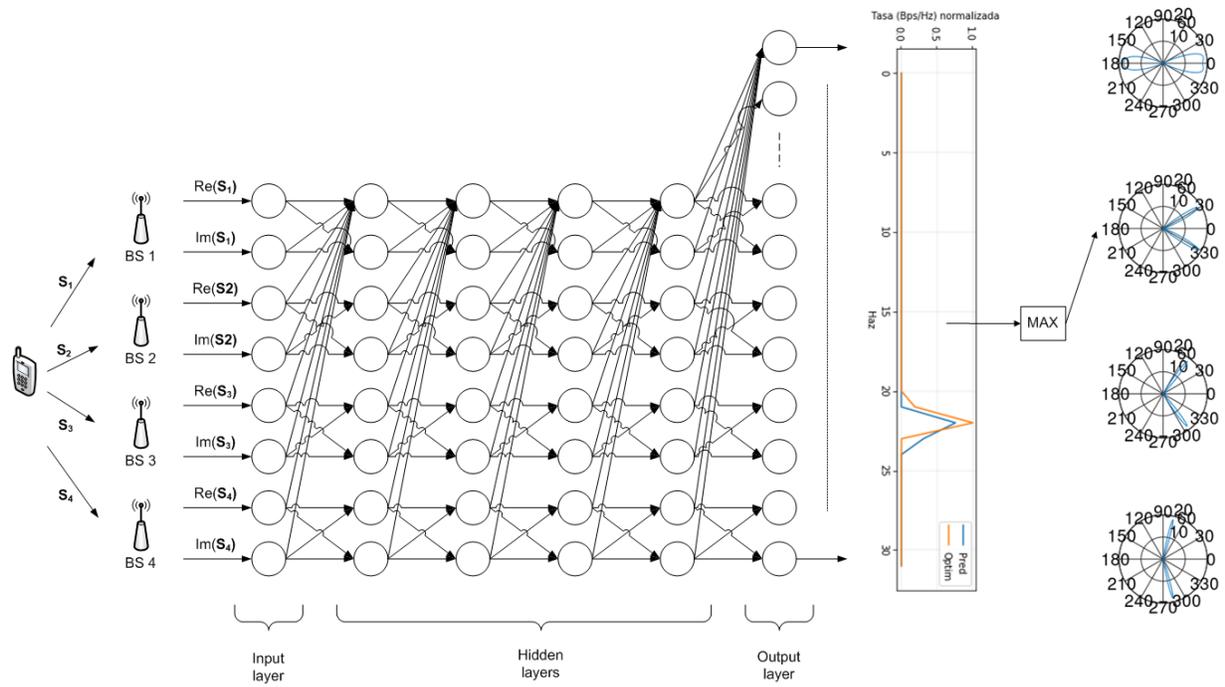


Fig. 3: Modelo DL para una radiobase (no se muestran todas las conexiones)

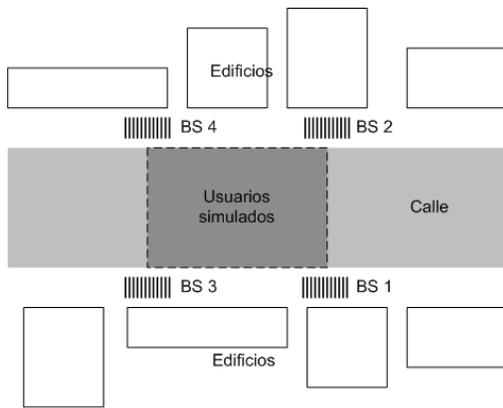


Fig. 4: Escenario simulado

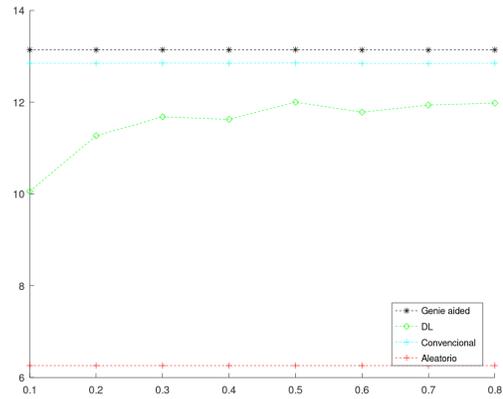


Fig. 5: Capacidades efectivas para diferentes fracciones de datos de entrenamiento

IV. RESULTADOS

A. Ganancia en la capacidad efectiva

Las simulaciones realizadas confirman los resultados vistos en [2] respecto a la mejora en la capacidad general obtenida con los haces predichos en comparación con los haces óptimos y también con una asignación aleatoria de los haces, como se muestra en la figura 5.

La comparación de la tasa de datos efectiva considerando el costo temporal ocupado por el entrenamiento no muestra una ganancia significativa debido a que el costo del entrenamiento convencional es bajo para la cantidad de haces utilizada en la simulación. Se asume que empleando una cantidad de haces mayor sería posible visualizar la ganancia de acuerdo a la referencia, en la que el costo llega a valores de hasta 45 %.

Con la cantidad de haces empleada (32) el costo del método convencional es menor a 10 %.

B. Predicción de los haces

1) *Modelo por regresión:* Además de la mejora en la tasa de datos efectiva, se estimó la precisión de la predicción del haz óptimo mediante DL comparada con el haz óptimo simulado. A partir de la salida original del modelo, que presenta la tasa de datos alcanzable para cada índice del haz, se seleccionaron los haces óptimos y predichos. Una muestra cualitativa del desempeño del modelo se muestra en la figura 6, donde se

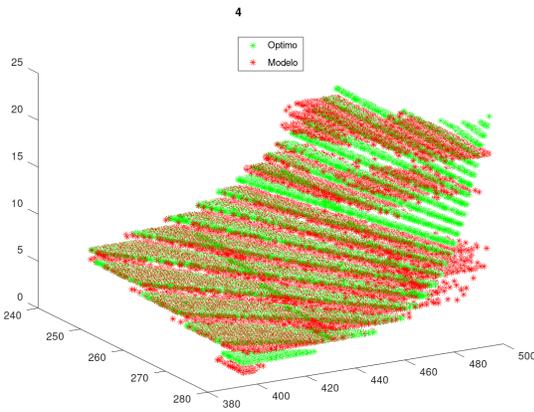


Fig. 6: Vista tridimensional de haces óptimos vs modelo

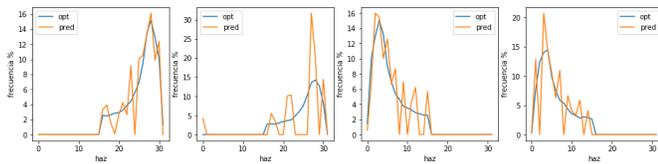


Fig. 7: Histograma de predicciones (regresión)

muestra sobre el plano xy los índices de los haces óptimos y los predichos, para una de las radiobases.

Los resultados muestran un ajuste, pero también se puede observar que para ciertos haces el modelo no predice resultados, generando huecos en la distribución. Estos se observa de mejor manera en la figura 7. Para cada una de las radiobases se muestra en abscisas el índice de haz real y en ordenadas la distribución de los haces predichos por el modelo DL.

La evolución del entrenamiento para cada modelo se muestra en la figura 9. Se puede observar algo frecuente en las pruebas realizadas, que de forma aleatoria algunos de los modelos convergen y otros no. Los órdenes de precisión obtenidos, es decir el número de aciertos del haz correcto sobre el total del grupo de test, se muestran en la tabla I

Tabla I: Precisión modelo de regresión

BS	1	2	3	4	Promedio
Precisión(%)	51	61	56	61	57

Se probaron varias alternativas, concentrándose en el modelo para una sola radiobase para poder incrementar el largo del entrenamiento y experimentar otras variantes. A modo de

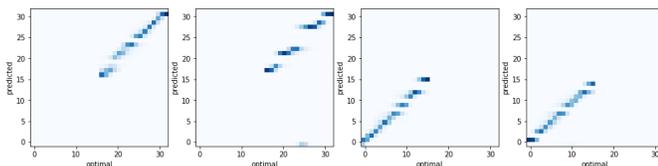


Fig. 8: Haces óptimos vs predichos (regresión)

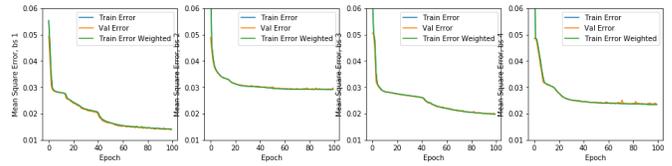


Fig. 9: Errores de entrenamiento vs épocas (regresión)

ejemplo se probó ponderar la función de costo MSE para considerar la distribución desigual de datos de entrada por haz (weighted metrics), pero no se logró mejorar la precisión.

2) *Modelo de clasificación:* Considerando los resultados de precisión del modelo regresivo, se probó además un modelo de clasificación, con una clase por cada haz del arreglo y considerando la entropía cruzada como función de costo. Con este modelo se alcanzan resultados levemente mejores en cuanto a precisión, aunque aún se mantienen "huecos" en haces para los que el modelo no genera predicciones, como se muestra en las figuras 10 y 11. La evolución de la precisión por épocas se muestra en la figura 12.

La precisión obtenida con el modelo de clasificación es levemente superior a la del modelo de regresión, como se muestra en la tabla II.

Tabla II: Precisión modelo de clasificación

BS	1	2	3	4	Promedio
Precisión(%)	48	64	69	57	60

V. CONCLUSIONES

Las conclusiones preliminares para los dos resultados propuestos son: 1) Se logró reproducir aproximadamente las simulaciones presentadas en el artículo de referencia, en condiciones de simulación limitadas 2) La predicción de haces requiere más análisis para poder incrementar la precisión del modelo 3) El modelo de clasificación mostró un desempeño levemente superior al de regresión.

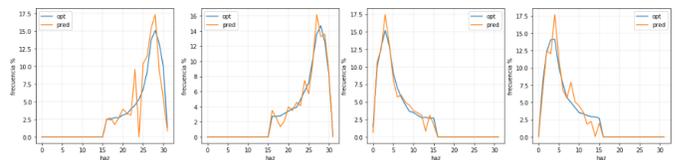


Fig. 10: Histograma de predicciones (clasificación)

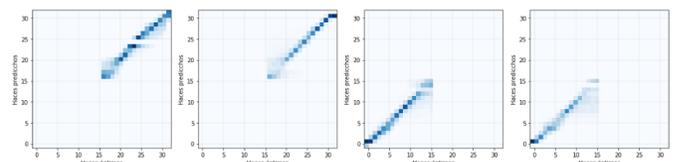


Fig. 11: Haces óptimos vs predichos (clasificación)

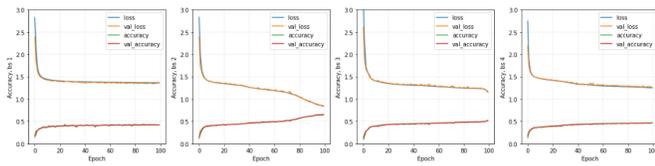


Fig. 12: Evolución de la precisión vs épocas (clasificación)

REFERENCES

- [1] Qian Mao, Fei Hu, Qi Hao, “Deep Learning for Intelligent Wireless Networks: A Comprehensive Survey,” in *IEEE Communications Surveys and Tutorials*, Vol 20, Issue 4, 2018.
- [2] Ahmed Alkhateeb, Sam Alex, Paul Varkey, Ying Li, Qi Qu, and Djordje Tujkovic, “Deep Learning Coordinated Beamforming for Highly-Mobile Millimeter Wave Systems,” in *IEEE Access*, Vol6, 2018.
- [3] “Wireless InSite 3D Wireless Prediction Software,” in <https://www.remcom.com>, 2019.
- [4] “Deepmimo a generic deep learning dataset for millimeter wave and massive mimo applications,” in <http://www.deepmimo.net>, 2019.
- [5] Ahmed Alkhateeb, “DeepMIMO: A Generic Deep Learning Dataset for Millimeter Wave and Massive MIMO Applications,” in *Proc. of Information Theory and Applications Workshop (ITA)*, 2019.
- [6] “Deeplearning coordinatedbeamforming,” in <https://github.com/WSLCL/>, 2019.