



**UNIVERSIDAD POLITÉCNICA SALESIANA  
SEDE QUITO  
CARRERA DE TELECOMUNICACIONES**

**DISEÑO DE UNA SINCRONIZACIÓN PARA SEÑAL MULTIPORTADORA  
MEDIANTE UNA RED NEURONAL**

Trabajo de titulación previo a la obtención del  
Título de Ingeniera en Telecomunicaciones

AUTORA: Mónica Alexandra Hernández Padilla.

TUTOR: Milton Napoleón Tipán Simbaña

Quito-Ecuador

2024

## **CERTIFICADO DE RESPONSABILIDAD Y AUTORÍA DEL TRABAJO DE TITULACIÓN**

Yo, Mónica Alexandra Hernández Padilla con documento de identificación N° 1727183822;  
manifiesto que:

Soy la autora y responsable del presente trabajo; y, autorizo a que sin fines de  
lucro la Universidad Politécnica Salesiana pueda usar, difundir, reproducir o publicar de  
manera total o parcial el presente trabajo de titulación.

Quito, 09 de febrero del año 2024

Atentamente,



---

Mónica Alexandra Hernández Padilla

1727183822

**CERTIFICADO DE CESIÓN DE DERECHOS DE AUTOR DEL TRABAJO  
DE TITULACIÓN A LA UNIVERSIDAD POLITÉCNICA SALESIANA**

Yo, Mónica Alexandra Hernández Padilla con documento de identificación N° 1727183822, expreso mi voluntad y por medio del presente documento cedo a la Universidad Politécnica Salesiana la titularidad sobre los derechos patrimoniales en virtud de que soy autora del Artículo Académico: “Diseño de una sincronización para señal multiportadora mediante una red neuronal”, el cual ha sido desarrollado para optar por el título de: Ingeniera en Telecomunicaciones, en la Universidad Politécnica Salesiana, quedando la Universidad facultada para ejercer plenamente los derechos cedidos anteriormente.

En concordancia con lo manifestado, suscribo este documento en el momento que hago la entrega del trabajo final en formato digital a la Biblioteca de la Universidad Politécnica Salesiana.

Quito, 09 de febrero del año 2024

Atentamente,



---

Mónica Alexandra Hernández Padilla

1727183822

## **CERTIFICADO DE DIRECCIÓN DEL TRABAJO DE TITULACIÓN**

Yo, Milton Napoleón Tipán Simbaña con documento de identificación N° 1713583126, docente de la Universidad Politécnica Salesiana, declaro que bajo mi tutoría fue desarrollado el trabajo de titulación: DISEÑO DE UNA SINCRONIZACIÓN PARA SEÑAL MULTIPORTADORA MEDIANTE UNA RED NEURONAL, realizado por Mónica Alexandra Hernández Padilla con documento de identificación N° 1727183822 obteniendo como resultado final el trabajo de titulación bajo la opción proyecto técnico que cumple con todos los requisitos determinados por la Universidad Politécnica Salesiana.

Quito, 09 de febrero del año 2024

Atentamente,



---

Ing. Milton Napoleón Tipán Simbaña MSc.

1713583126

## DEDICATORIA

Este reconocimiento es para mi familia, lo más valioso que tengo, los amo con el alma. Por ustedes estoy aquí, siempre creyeron en mí, jamás los defraudaré, me hacen muy feliz.

Mi mami Mónica, lo doy todo por usted, la mejor amiga que me dio la vida, mi primera maestra, mi primer amor.

Mi papi Renato, a pesar de la distancia, esta niña siempre quiere ser su orgullo, lo quiero.

A mis dos hermanos a quienes admiro, hacen que la existencia sea colorida, los quiero muchísimo, gracias por cada consejo, risa, llanto y mimos.

Sergio, mi figura paterna, mi ejemplo a seguir, fomentaste este amor tan grande por la ciencia.

Miguel, mi apoyo y amistad, cada risa y experiencia es valiosa.

Para la Moni del futuro. Eres invencible, sigue brillando, no te rindas todo tiene solución, exprésate y ama fuerte. Nunca olvides que los sueños si se cumplen, conténtate con cada logro y aprende mucho.

## **AGRADECIMIENTO**

A mi tutor quién con su enseñanza, perseverancia, apoyo y paciencia, hizo posible que esta investigación llegue a su éxito, buscamos la forma de cumplir el objetivo, agradezco por su tiempo dedicado en cada una de mis dudas, conocí su calidad de humano muy amable, admirable y respetable.

Mis queridos ingenieros quienes me formaron con sabiduría, cariño, corrección, me vieron crecer; cada semestre se tornaba más interesante. Me siento tan orgullosa de ser parte de la comunidad de las Telecomunicaciones, ustedes hicieron que ame la carrera. No solo son mis mentores son parte de mi familia.

Para los amigos y compañeros que hice en este recorrido, esta experiencia de la universidad fue lo máximo, me divertí mucho, la voy a recordar con tanto amor y nostalgia, parecía este día ser lejano, pero ahora somos ingenieros. Gracias a ustedes logré ser mi mejor versión, ya no le temo al mundo, lo voy a conquistar y no me rendiré.

# DISEÑO DE UNA SINCRONIZACIÓN PARA SEÑAL MULTIPORTADORA MEDIANTE UNA RED NEURONAL

## DESIGN OF A SYNCHRONIZATION FOR MULTICARRIER SIGNAL USING A NEURAL NETWORK

Mónica A. Hernández <sup>1</sup>, Milton N. Tipán <sup>2</sup>

### Resumen

La sincronización de señales multiportadoras juega un papel crucial en el desempeño de la transmisión, en especial para sistemas inalámbricos debido a la no linealidad del canal que produce retardos de la señal. Este artículo, propone el uso de una red neuronal LSTM para sincronización de señales OFDM. Los resultados muestran que es necesario tres capas ocultas de la red neuronal recurrente para una convergencia rápida. Un RMSE de 0.1995 fue obtenido.

**Palabras clave:** LSTM, OFDM, Redes Neuronales, Sincronización

### Abstract

Synchronization of multicarrier signals plays a crucial role in transmission performance, especially for wireless systems due to channel nonlinearity that produces signal delays. This article proposes the use of an LSTM neural network for synchronization of OFDM signals. The results show that three hidden layers of the recurrent neural network are necessary for fast convergence. An RMSE of 0.1995 was obtained.

**Keywords:** LSTM, OFDM, Neural Networks, Synchronization

---

<sup>1</sup>Carrera de Telecomunicaciones, Universidad Politécnica Salesiana, Quito, Ecuador, e-mail: mhernandezp@est.ups.edu.ec

<sup>2</sup>Carrera de Telecomunicaciones, Universidad Politécnica Salesiana, Quito, Ecuador, e-mail: mtipans@ups.edu.ec

## 1. Introducción

La interacción entre la tecnología y el ser humano es fundamentada en la comunicación, para la era digital, este proceso evoluciona a un ritmo acelerado. Es crucial que esta conexión sea eficaz, segura y veloz, por la significativa cantidad de datos que se intercambian. El transporte de información forma un papel crucial, ya sea a través de conexiones cableadas o inalámbricas. Actualmente, las redes móviles, internet de las cosas, juegos en línea, videoconferencias, descarga de archivos consumen ancho de banda [1] [2].

La sincronización de las señales en un sistema de comunicación es crucial, ya que puede realizarse tanto en tiempo como en frecuencia. Esto es fundamental para reducir errores en los símbolos recibidos al pasar la señal por canales, ya sean lineales o no lineales.

Además, las señales multiportadoras, como las utilizadas en la Multiplexación por División de Frecuencias Ortogonales (Orthogonal Frequency-Division Multiplexing, OFDM) o en sistemas basados en ella, experimentan un desvanecimiento profundo de potencia debido a obstáculos en el trayecto.

Este fenómeno puede ocasionar interrupciones en las señales. Si a este desafío se le suma el ruido presente en el canal, la pérdida de información se ve incrementada. En virtud, la sincronización de la señal en estos sistemas de comunicación se vuelve imprescindible [6] [7].

Los problemas de sincronización se pueden mejorar de distintas maneras. Ya sea mediante el ajuste de frecuencia debido al movimiento, señales temporales por pulsos en el transmisor y receptor, en la actualidad, mediante algoritmos de predicción basados en inteligencia artificial.

Existen diversas técnicas para sincronizar señales, y las redes neuronales muestran efectividad para mejorar la predicción en diferentes contextos, tanto en medios guiados como inalámbricos.

Algunas de las principales aplicaciones incluyen el uso de redes neuronales recurrentes, en especial las Redes Neuronales de Memoria de Corto-Largo Plazo (Long Short-Term Memory, LSTM), que sirven para estimar tiempo, la compensación de retardos en condiciones variables de canal, y el aprendizaje por refuerzo cuando el canal experimenta variaciones en el tiempo. [5].

El propósito de este artículo es entrenar una red neuronal LSTM utilizando señales multiportadoras ortogonales con retardos aleatorios generados por un canal. La red entrenada permitirá predecir el retardo ocasionado por un canal en una señal OFDM.

## 2. Materiales y Métodos

### 2.1. Sincronización de una señal OFDM


La técnica de multiplexación ortogonal es usada en medios de comunicación. En este tipo de modulación

los datos se transmiten como subportadoras, es robusta ante problemas de propagación multitrayecto. La sincronización debe ser tanto en tiempo como en frecuencia, los errores deforman a los símbolos recibidos o la interferencia en canales complejos.

Las Secuencia Binaria Pseudoaleatorios (Pseudorandom Binary Sequence, PRBS), es utilizada para generar la sincronización en los símbolos OFDM como se muestra en la figura 1, esta se genera mediante polinomios [6].

$$g(x) = x^7 + x^5 + x^4 + x^2 + 1 \quad (1)$$

La PRBS usa la creación de secuencias pseudoaleatorias para retroalimentar la generación de bits con el polinomio 1 .



**Figura 1.** Señal OFDM sintética con la PRBS para sincronización

### 2.2. Red Neuronal LSTM

El entrenamiento de las redes artificiales selecciona un modelo que se ajuste a requisitos, seguido de la implementación de métodos para evaluar y validar su rendimiento. LSTM es un tipo de red neuronal recurrente; posee una memoria extensa que permite aprender de eventos significativos en el pasado.


Estas neuronas tienen la capacidad de leer, escribir y descartar información almacenada. La red puede tomar decisiones de conservar o eliminar datos; la regresión lineal muestra la predicción del modelo neuronal.

Está compuesto de tres compuertas: entrada, olvido y salida como se observa en la figura 2 [4].

- Compuerta de entrada: mide la importancia de nueva información para actualizar
- Compuerta de olvido: decide cuanta información almacenada de datos pasados que deben eliminarse



- Compuerta de salida: examina los datos actuales sean visibles



**Figura 2.** Arquitectura LSTM

$\sigma$  es la regresión logística, describe la cantidad de información que se deja pasar, donde 0 es bloquear y 1 es dejar pasar, la función tanh sirve para cambiar la escala de datos entre -1 y 1.

$$m_t = f_t \cdot m_{t-1} + i_t \cdot M_t \quad (2)$$

La memoria a largo plazo como en la ecuación 2 ( $m_t$ ) con datos actuales se describe mediante la Ecuación 2.

Se toman datos de olvido ( $f_t$ ) y de entrada ( $i_t$ ). ( $f_t$ ) es un valor en el rango de 0 a 1, donde 0 implica mantener todo y 1 es eliminar todo en ( $m_{t-1}$ ), y ( $i_t$ ) actúa como la compuerta de entrada que decide con la función tangente hiperbólica (tanh), crea un vector de valores ( $M_t$ ), almacenando así los valores necesarios para la actualización de la memoria.

$$h_t = o_t \cdot \tanh \cdot m_t \quad (3)$$

La memoria a corto plazo 3 con datos actuales describe a la Ecuación 3.


Se seleccionan datos de la capa de olvido ( $o_t$ ) y de salida. ( $h_t$ ) representa la información antigua guardada en la memoria de corto plazo. La función tangente hiperbólica (tanh) crea un vector de valores ( $m_t$ ), que representa el nuevo estado de la celda [10].

### 2.3. Configuración de la simulación

Para llevar a cabo la investigación, se efectuó una simulación utilizando el software Python 3.9, una máquina con Windows 11 de 8 GB, sistema operativo de 64 bits y procesador x64.

Se generó una señal multiportadora OFDM hermítica sin sincronización, con un prefijo cíclico del (25%), utilizando símbolos modulados digitalmente en 4-QAM y aplicando una IFFT de 64. Para simular un entorno realista, se introdujeron 1000 retardos aleatorios con distribución uniforme en la señal OFDM, emulado así

un canal no lineal. Para cada uno de estos retardos, generó un símbolo OFDM de 80 muestras, 16 prefijos cíclico y 64 símbolos 4-QAM como se muestra en la figura 3 un símbolo OFDM.



**Figura 3.** Arquitectura de una red neuronal de LSTM para regresión.

Los datos se normalizaron utilizando zscore y se dividieron en conjuntos de entrenamiento (80%), validación (10%) y prueba (10%).

La red neuronal consta de una capa de entrada, capas ocultas de 25 unidades y una capa de salida completamente conectada. Se utilizó el algoritmo de entrenamiento ADAM con un máximo de 60 épocas, empleando la función de activación ReLU.

### 3. Resultados y Discusión

Los símbolos generados en OFDM tienen una longitud de 16 muestras de prefijo cíclico más 64 de datos 4-QAM, dando un total de 80 muestras. En la figura 4 se muestra la señal sintética generada de un símbolo OFDM a transmitir por el canal.

Se generaron 1000 retardos para este símbolo; en la figura 5 se muestra una de esas señales para un retardo de muestras. Estos retardos solo pueden variar dentro de la longitud del prefijo cíclico, asumiendo que el canal no lineal logra retardar en un canal inalámbrico. Estas señales, así como sus retardos, fueron utilizados para entrenar a la red neuronal, con un 80% para entrenamiento y 20% para prueba. La red LSTM convergía de manera lenta desde 80.5 hasta 60.4 en 60 épocas cuando las redes LSTM ocultas tenían 65, 25, 8 neuronas.

Luego, se procedió a variar para mejorar su convergencia, logrando que esta sea más rápida con 80, 45, 8 neuronas respectivamente. La figura 6 presenta la convergencia del entrenamiento de la red neuronal, sufre una caída drástica en la época 7 para obtener un valor muy cercano a 0, esto representa tener una buena predicción de datos de retardo.




Figura 4. Señal OFDM sin retardos




Figura 5. Símbolo OFDM con retardo de 7 muestras




Figura 6. Error vs Épocas

Finalmente, para probar la red neuronal se procedió a ingresar una señal con un retardo de 15, y la red predijo que el retardo era de 14.56, por lo que su Error Cuadrático Medio (Root Mean Square Error, RMSE), para los 16 retardos fue de  $rmse = 0.1995$ .

## 4. Conclusiones

Una red neuronal basada en LSTM fue entrenada para predecir retardos en una señal OFDM. Se necesitaron tres capas ocultas con 80, 45 y 8 neuronas respectivamente para lograr una convergencia rápida. Se obtuvo un error cuadrático medio de 0.1995.

Los resultados fueron restringidos a una IFFT de  $N = 64$ . Se espera que, para valores mayores, exista igual convergencia cuando se realicen estudios futuros al respecto. Este estudio abre la posibilidad de utilizar redes neuronales para la sincronización de señales multiportadoras en aplicaciones en tiempo real, debido a su rápida convergencia.

## 5. Referencias

### Referencias

- [1] R. G. Fernández Martínez, *Video espontáneo: herramienta de comunicación, de cambio social y de control ciudadano en la era digital*, Alicante: El taller digital, 2018.
- [2] A. García Padilla, M. Dawod Alhammadi y J. M. Días Hernández, «Modelo de canal de radio multitrayecto para comunicaciones inalámbricas de banda ancha,» *Telemática*, vol. 17, n<sup>o</sup> 1, pp. 15-27, 2018.
- [3] W. Rivas Asanza y B. Mazón Olivo, «Redes neuronales artificiales aplicadas al reconocimiento de patrones,» *Redes*, vol. 3, n<sup>o</sup> 7, pp. 12-31, 2018.
- [4] Matlab, «MathWorks,» *Matlab*, 2023. [En línea]. Available: <https://la.mathworks.com/help/deeplearning/ug/long-short-term-memory-networks.html>. [Último acceso: 15 01 2024].
- [5] J. Torres, *DEEP LEARNING Introducción práctica con Keras*, Barcelona: Marcombo, 2019.
- [6] ETSIAN, JEPER and DIENA, "Boletín técnico de ingeniería," Ministerio de defensas, vol. XVI, p. 69, 2019.
- [7] A. Rojano Aguilar, R. Salazar Moreno, L. Miranda y W. Ojeda Bustamante, «Algoritmo ADAM en la inteligencia artificial,» *Sexto Congreso Nacional de Riego, Drenaje y Biosistemas*, n<sup>o</sup> 21005, pp. 1-8, 2021.

- [8] Matlab, «MathWorks,» *Matlab*, 2023. [En línea]. Available: <https://la.mathworks.com/help/deeplearning/ug/sequence-to-one-regression-using-deeplearning.html> [Último acceso: 18 01 2024].
- [9] O. F. Erazo De la Cruz, V. F. Miramán Pérez y J. E. Mora Arroyo, «Detección de espectro de banda ancha: Sub-Nyquist para redes Radio Cognitiva: Compleción de matrices mediante valores semilla,» vol. 17, n° 1, pp. 126-145, 19 01 2021.
- [10] S. Vergara, G. Farías, E. Fabregas y J. Vega, «Resultados preliminares sobre la detección de anomalías en fusión con Deep Learning,» 13º CONGRESO LATINOAMERICANO DE GENERACIÓN Y TRANSMISIÓN DE ENERGÍA ELÉCTRICA, Vienna, 2019.