

# Estimación de frecuencias de señales interferométricas con redes neuronales

## Frequency estimation of interferometric signal with neural network

Presentación: 13 y 14 de septiembre de 2023

### Santiago Cerrotta

Grupo de Fotónica Aplicada, Facultad Regional Delta, Universidad Tecnológica Nacional  
Consejo Nacional de Investigaciones Científicas y Técnicas (CONICET)  
scerrotta@frd.utn.edu.ar

### Eneas N. Morel

Grupo de Fotónica Aplicada, Facultad Regional Delta, Universidad Tecnológica Nacional  
Consejo Nacional de Investigaciones Científicas y Técnicas (CONICET)  
nmorel@frd.utn.edu.ar

### Resumen

Una vez adquirida la señal óptica de la técnica de interferencia de baja coherencia mediante un espectrómetro es necesario realizar un post procesamiento para encontrar la frecuencia de oscilación característica de la señal. Esta señal me brinda información morfológica (espesor, topografía, etc) de la muestra en estudio. En este trabajo se diseñan, entrenan e implementan Redes Neuronales Artificiales que permiten reemplazar herramientas convencionales en el procesamiento de señales oscilantes y en particular el cálculo de la Transformada de Fourier. Se analiza la precisión y los tiempos característicos de estas redes demostrando que son una opción viable para estimar frecuencias de señales oscilatorias.

**Palabras clave:** Interferencia, redes neuronales, estimación de frecuencia, procesamiento señales.

### Abstract

Once the optical signal from the low-coherence interferometry technique is acquired using a spectrometer, post-processing is necessary to find the oscillation frequency. This frequency provides morphological information (thickness, topography, etc.) of the sample under study. In this work, Artificial Neural Networks are designed, trained, and implemented to estimate frequency of oscillating signals replacing the use of the Fourier Transform. The accuracy and characteristic times of these Networks are analyzed.

**Keywords:** Interference, neural networks, frequency estimation, signal processing.

### Introducción

Las Redes Neuronales Artificiales (RNs) se han desarrollado y crecido de una manera considerable en los últimos años captando la atención no solo de la academia, sino también de disciplinas que van desde la medicina hasta las finanzas, interviniendo en problemáticas teóricas y también experimentales. El uso de RNs se suma, sin lugar a duda, al paradigma ya instalado de la interdisciplinariedad. Vivimos en una sociedad con un gran nivel de desarrollo y complejidad y a un ritmo acelerado. El desafío disruptivo actual no pasa tanto por descubrir algo nuevo si no en adaptar el conocimiento existente de una disciplina a solucionar una problemática de otra.

La interferometría es un conjunto de técnicas que basan en el principio de interferencia para la medición de diferentes fenómenos físicos. Son muy utilizadas en aplicaciones que van desde la astronomía hasta la física nuclear pasando por metrología y espectroscopia entre otras. El resultado de superponer dos o más ondas que interfieren entre ellas es un patrón oscilante de intensidades, donde generalmente es en la frecuencia que se codifica la información de relevancia. En particular, la interferometría de baja coherencia en el dominio de las frecuencias (FD-LCI por sus siglas en inglés), es una técnica de metrología óptica que permite la medición de perfilometrías, tomografías, vibraciones, velocidades, etc utilizando como elemento sensor a la luz (Walecki et al., 2005) con gran potencial para aplicaciones industriales (Cerrotta et al, 2023). Para ello se utiliza típicamente un dispositivo conocido como interferómetro de Michelson, una fuente de luz de baja coherencia, esto implica

que la fuente posee un ancho espectral grande y un espectrómetro para adquirir la intensidad de cada longitud de onda o también llamada señal de interferencia (Drexler et al, 2015).

El uso de redes neuronales ya se ha introducido en el campo del procesamiento de señales (Deng, 2008) (LeCun et al., 2007) y en temáticas asociadas a frecuencias, pero hasta la actualidad, son pocos y recientes los trabajos que se centraron en estimar directamente la frecuencia de señales mediante redes neuronales. En (Sajedian & Rho, 2019) se encuentra que mediante una red neuronal sencilla densamente conectada se pueden estimar frecuencias de señales senoidales con presencia de ruido. Esta técnica se analiza en mayor profundidad en (Almayyali & Hussain, 2021) y (Razzaq et al, 2023). Una RN es capaz de realizar la transformada de Fourier, como se destaca en (Rosemarie, 2008), pero no sería el método más eficiente, ya que los algoritmos existentes, en especial la (transformada Rápida de Fourier) tienen gran eficiencia y flexibilidad. La idea es entonces hacer que la red neuronal desarrolle un método para estimar frecuencias a partir de su propio aprendizaje.

Este trabajo propone que mediante la utilización de diferentes RNs es factible estimar la frecuencia de señales interferométricas en distintas etapas del postprocesado. Diseñando, entrenando e implementando diversas RNs, analizando su precisión y tiempos de entrenamiento y ejecución, es posible demostrar que son alternativas eficaces para reemplazar el método convencional de procesado basado en la transformada de Fourier.

## Desarrollo

### Procesado convencional

Una aplicación interesante de FD-LCI es la realización de perfilometrías y/o topografías. En este tipo de situaciones la señal está determinada por una única frecuencia de oscilación, ver Figura 1. Esto puede suceder cuando la reflexión en la muestra proviene de una sola interfase, su superficie. En este caso se estaría midiendo la diferencia de camino óptico (DCO) que se puede poner en términos de la distancia de interés de la muestra  $z_s$  como  $DCO = 2z_s$ . Las mediciones se pueden realizar sin contacto físico con la muestra y con una resolución de algunos micrómetros. En la Ecuación 1 se puede observar una expresión matemática para la intensidad para este tipo de señales:

$$i(k) = S(k)[A_{DC} + A \cos(kDCO + \varphi)] \quad (11)$$

En donde  $S(k)$  es el espectro de la fuente, que se considera gaussiana de 50 nm de ancho,  $A_{DC}$  es el valor de continua de la señal,  $A$  la amplitud de la oscilación,  $k$  la frecuencia espacial que se puede expresar en términos de la longitud de onda  $\lambda$  como  $k = 2\pi/\lambda$  y  $\varphi$  es una fase extra que puede estar presente en la señal.

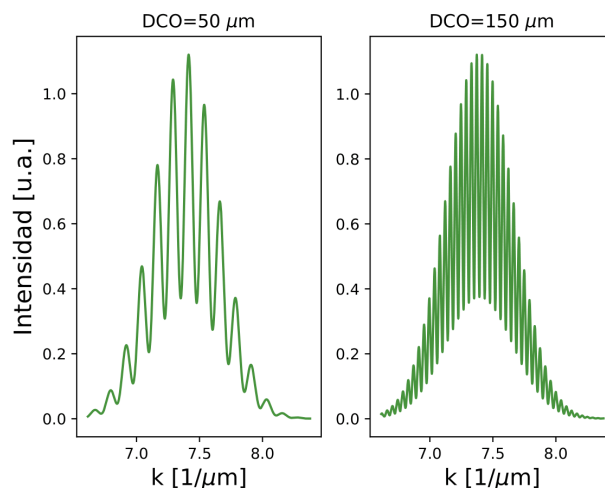


Figura 1: Simulación de dos señales interferométricas detectadas por un espectrómetro con dos frecuencias de oscilación diferentes. Una de 50  $\mu\text{m}$  (izquierda) y otra de 150  $\mu\text{m}$  (derecha) de camino óptico al utilizar una fuente de luz de gaussiana centrada en 850 nm con un ancho de 60 nm.

Una vez adquirida la señal es necesario realizar diferentes etapas de procesamiento antes de calcular su frecuencia, Figura 2. La señal detectada va modificando su forma a medida que se van aplicando las diferentes etapas del procesado, ver Figura 3. Primero se detecta la señal de FD-LCI, luego se filtran las frecuencias bajas, se identifica la envolvente y divide para finalmente realizar la transformada rápida de Fourier de la señal

oscilante. Este procesado es necesario para poder calcular con mejor precisión la posición del máximo de la transformada de Fourier y así calcular la frecuencia de oscilación (DCO) para obtener la información deseada  $z_s$  (Morel et al, 2012).

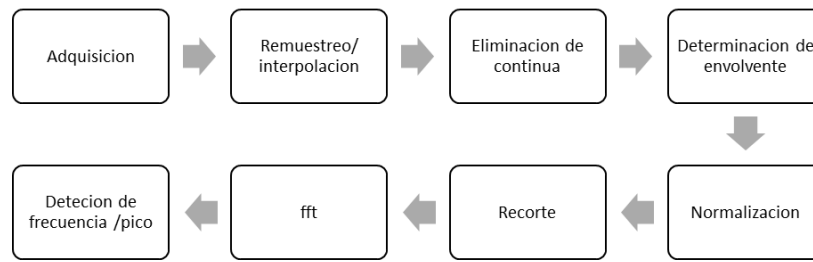


Figura 2: Etapas de procesamiento convencional de la señal interferométrica de FD-LCI.




Figura 3: Esquema de la forma de las señales antes de aplicar la etapa de procesado de recorte (izquierda) y antes de determinar la envolvente.

Para poder comparar los tiempos de ejecución de las distintas RN con la forma convencional de procesar la señal se calcularon los tiempos que demora cada etapa del procesamiento, ver Tabla I.

Tabla I: Tiempo que demora cada etapa de preprocesada para la estimación de frecuencia para la técnica de LCI. Se marcan los órdenes de magnitud ya que \*la precisión de los tiempos depende fuertemente del procesador.

Etapa de procesado	Tiempo [ms]*	Orden de magnitud
Eliminación de continua	1.10	ms
Determinación de envolvente	2.31	ms
Normalización	0.06	decenas de $\mu$ s
Recorte	1.52	ms
FFT	0.08	decenas de $\mu$ s
Detección de pico	0.01	decenas de $\mu$ s

### Procesado con redes neuronales

Se trabajaron con simulaciones con  $z_s$  comprendidas entre 30 a 500  $\mu$ m (es decir DCO de 60 a 1000  $\mu$ m) tomando 30.000 o 100.000 valores equiespaciados en ese rango. Se utilizó una ventana espacial de 2000 muestras y una  $f_m = \frac{1}{k_m} = 9.3$  mm. Esto permite que para la frecuencia mínima (DCO = 60  $\mu$ m) se observen dos ciclos completos de la señal y que la señal de mayor frecuencia tenga 60 muestras por ciclo ya que  $f_{max} \ll f_m$ . Esto permite generar datos de entrada significativos para el aprendizaje de la RN. Para estas condiciones se obtiene una resolución de 8  $\mu$ m. Las operaciones presentes en este capítulo fueron realizadas en una computadora de 2 núcleos y procesador de 2.20 GHz Intel(R) Core(TM) con 8 GB de RAM. Los diseños y entrenamiento de las RN que se proponen.




Figura 4: Muestreo de la señal a procesar para las diferentes redes neuronales. Los puntos 2000 se encuentran separados una distancia  $k_m$  y son los valores de entrada a la red neuronal. El ejemplo en este caso es una señal cosenoidal con un  $z_s$  de  $50 \mu\text{m}$

Para medir el desempeño de las RN implementadas se usó el error cuadrático medio RMSE del subconjunto de testeo entre los valores reales  $Y_{test}$  y los predecidos  $Y_{pred}$  y el error con respecto al peor valor predicho  $RSE_{max}$  sobre todo el conjunto  $Y$  (entrenamiento, validación y testeo).

$$RMSE = \frac{1}{T_{test}} \sqrt{\sum_{i=1}^{T_{test}} (Y_{test_i} - Y_{pred_i})^2}; RSE_{max} = \max \left\{ \sqrt{(Y - Y_{pred})^2} \right\} \quad (2)$$

Para el entrenamiento de todas las RN, a cada conjunto de señales se las separo de modo aleatorio de la siguiente manera: el 72% para entrenamiento, el 18% para validación y el 10% restante para testeo. Se normalizaron los valores para que los outputs estén entre 0 y 1 para un mejor funcionamiento de las RN.

En este trabajo se presentan tres RN neuronales diseñadas y entrenadas para estimar la frecuencia de la señal en distintas etapas del procesado. Notar que la RN se va complejizando a medida que reemplaza más etapas de preprocesamiento. Para más detalle se recomienda leer el capítulo 11 de (Vorobioff et al, 2022).




Figura 5: Esquema de las arquitecturas de una RN densamente conectada FCN 100-500-250-125-50-25-10 (izquierda) y la RN que contiene una única capa convolucional, seguido de una capa max Pooling y dos capas densamente conectadas de 10 neuronas (derecha).

Yendo de las RN más sencillas a más complejas, se diseñó en primera instancia una RN densamente conectada de 7 capas con numero decreciente de neuronas por capa 1000, 500, 250,125, 50, 25 y 10, como se puede observar en la Figura 5. Donde después de cada capa densamente conectada se utiliza una capa de activación de tangente hiperbólica. Esta RN esta entrenada para estimar frecuencias de señales del tipo  $\cos(k2z_s + \varphi)$  y puede utilizarse antes de la etapa de recorte. Para el entrenamiento de esta RN se usó un conjunto de 100.000 de estas señales cosenoidales desfasadas (Figura 3), 90 epoch, un función de entrenamiento de gradiente descendente estocástico con momento (sgdm), una tasa de aprendizaje de 0.1. Se obtuvo un  $RMSE=2.2 \mu\text{m}$  y  $RSE_{MAX} = 16.5 \mu\text{m}$ . El entrenamiento demoró 27 minutos y el tiempo de 4.8 ms.

En segundo lugar, se diseñó una RN conformada por una capa Convolucional (Figura 5) y se fueron modificando los hiperparámetros para su funcionamiento óptimo. Se eligieron 10 filtros con una dimensión del kernel de 5x1 ya que es una señal unidimensional. Se seteó una cantidad máxima de epoch de 60. Se colocó una capa ReLU seguida de una capa de Max pooling que extrae el máximo valor dentro 5 lugares y se desplaza un

stride de 5, finalmente dos capas densamente conectadas de 10 neuronas para obtener el valor regresivo deseado. Más información de las capas e hiperparametros de las redes convolucionales se puede leer (Kesler et al, 2021).

A esta red se la entrenó con 30000 señales normalizadas del tipo  $S(k) \cos(kDCO + \varphi)$  presente en la Figura 3 y correspondiente a la señal antes de la etapa de la determinación de envolvente. Para el caso en que se tomaron 60 epoch se obtuvo  $RMSE = 2.5 \mu m$  y un  $RMS_{max} = 7.5 \mu m$ , un tiempo de entrenamiento de 18 minutos y un tiempo de ejecución de 2.4 ms. Los resultados obtenidos son altamente positivos ya que se encuentran por debajo de la resolución de la técnica de FD-LCI y permiten reemplazar varias etapas de preprocesado. La etapa de normalización no se puede evitar, es necesario para todas las estimaciones con RN ya que mejora considerablemente los resultados.

Por último, se analizó la señal presente en la ecuación 1, que corresponde a la etapa previa a la eliminación de continua. Se probaron varios diseños de RN, la complejidad de la arquitectura para este tipo de señal incremento considerablemente. El diseño que mejor precisión logró fue para una RN de más de 40 capas. Esta configuración posee 7 capas convolucionales donde la cantidad de filtros fue duplicándose, con un tamaño de 2x1 para la primera capa, seguido de 4x1 para las intermedias y de 3x1 para las últimas dos, el paso de stride fue de 2x1 para la primera capa convolucional y de 3x1 para las restantes. Entre capa y capa se tomó la función de activación de tangente hiperbólica, se usó también etapas de batchnormalization y de dropout. Finalmente se colocaron capas densamente conectadas de 5000-5000-1000-1000-500-500-250-64-32-16-8-1 (Vorobioff et al, 2022). Para el entrenamiento el conjunto de señales de 100.000 señales, la función de optimización del sgdm y se obtuvo un  $RMSE = 3.3 \mu m$  y un  $RSE_{max} = 104.4 \mu m$ , un tiempo de ejecución de 18.3 ms y un tiempo de entrenamiento de 1218 minutos. Como se puede observar en la Figura 6, se obtienen en general valores muy próximos a los esperados, salvo por 3 valores que se obtienen predicciones con un alto error y se observa un incremento continuo del error para el extremo de mayores  $z_s$  pero que se encuentran dentro del error aceptable. La RN tiene un óptimo desempeño para la mayoría de los valores de DCO, existe una muy baja probabilidad de predicción del  $z_s$  con gran error.

En la Tabla II se puede observar un resumen de los rendimientos de las RN diseñadas.

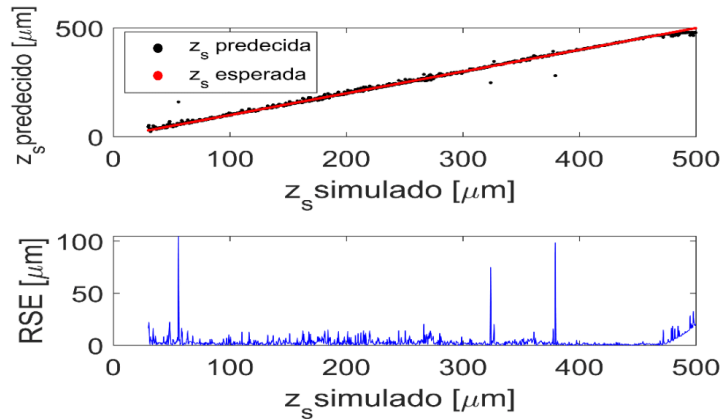


Figura 6: Predicciones y error absoluto de la red con 7 capas convolucional para señales típicas de FD-LCI.

Tabla II: Resumen de los resultados de las redes neuronales presentada detallando tiempos de entrenamiento y ejecución

Señal	# señales	epoch	Red Neuronal	RMSE [ $\mu m$ ]	RSEmax [ $\mu m$ ]	Tiempo entrenam [minutos]	Tiempo ejecución [ms]
$\cos(kDCO + \varphi)$	100.000	90	FCN 100-500-250-125-	2.2	16.5	27	4.8
$s(k) \cos(kDCO + \varphi)$	30.000	60	Conv-Relu-MaxPool-FCN 10-10	2.5	7.5	18	2.4
$s(k)[A_{Dc} + A \cos(kDCO + \varphi)]$	100.000	60	7 Conv	6.3	104.3	1218	18.4

## Conclusiones

Se presentaron 3 diseños de RN para estimar frecuencias de distintos tipos de señales oscilantes que se desprenden del procesado de una señal de FD-LCI convencional. Se analizó su precisión y tiempos característicos, tanto de entrenamiento como de ejecución. Se mostró que el uso de redes neuronales del tipo densamente conectadas como convolucionales son una alternativa interesante para reducir el preprocesado necesario y reemplazar el uso de la transformada de Fourier para calcular la información de interés en la técnica de FD-LCI.

Se concluyó que la mejor opción para estimar la DCO de una señal de FD-LCI es mantener las etapas de preprocesado de eliminación de continua y normalización y usar una red neuronal con una capa convolucional. Teniendo en cuenta los tiempos de ejecución de las la Tabla I y la Tabla II, se observa que teniendo ya entrenada la RN se puede estimar la frecuencia de una señal de FD-LCI aproximadamente 2 ms más rápido. En caso de otras aplicaciones donde, la señal oscilatoria sea más sencilla (como senos o cosenos) usar redes densamente conectadas es una muy buena opción.

Los resultados obtenidos se basan en señales de interferencia de baja coherencia, pero fácilmente se pueden implementar para otro ámbito donde se desea analizar la frecuencia de señales similares o inclusive tomar la estructura de las redes neuronales propuestas y modificarlas para optimizar su rendimiento en la aplicación deseada.

## Referencias

- Almayyali, H. R., & Hussain, Z. M. (2021). Deep learning versus spectral techniques for frequency estimation of single tones: Reduced complexity for software-defined radio and iot sensor communications. *Sensors*, 21(8). <https://doi.org/10.3390/s21082729>
- Cerrotta, S., Morel, E. N., & Torga, J. R. (2015). Scanning Optical Coherence Tomography Applied to the Characterization of Surfaces and Coatings. *Procedia Materials Science*, 9, 142–149. <https://doi.org/10.1016/j.mspro.2015.04.018>
- Cerrotta, S., Torga, J. R., & Morel, E. N. (2023). Long-range frequency domain low-coherence interferometry detector for industrial applications. *JOSA A*, 40(4), C16-C21.
- Deng, L. (2008). Expanding the scope of signal processing. *IEEE Signal Processing Magazine*, 25(3). <https://doi.org/10.1109/MSP.2008.920380>
- Drexler, W., & Fujimoto, J. G. (Eds.). (2015). *Optical coherence tomography: technology and applications* (Vol. 2). Berlin: Springer.
- Kesler E., Cerrotta S., Dimensiones, filtros y operaciones de la Redes Neuronales Convolucionales, github, (2022). Disponible en <https://github.com/UTN-GFA/UTN-GFA.github.io>.
- LeCun, Y., Chopra, S., Ranzato, M. A., & Huang, F. J. (2007). Energy-based models in document recognition and computer vision. *Proceedings of the International Conference on Document Analysis and Recognition, ICDAR, 1(Icdar)*, 337–341. <https://doi.org/10.1109/ICDAR.2007.4378728>
- Razaq, H. S., & Hussain, Z. M. (2023). Instantaneous Frequency Estimation of FM Signals under Gaussian and Symmetric  $\alpha$ -Stable Noise: Deep Learning versus Time–Frequency Analysis. *Information*, 14(1), 18.
- Rosemarie, V. (2008). Discrete Fourier Transform computation using neural networks. *Proceedings - 2008 International Conference on Computational Intelligence and Security, CIS 2008, 1*, 120–123. <https://doi.org/10.1109/CIS.2008.36>
- Sajedian, I., & Rho, J. (2019). Accurate and instant frequency estimation from noisy sinusoidal waves by deep learning. *Nano Convergence*, 6(1), 2–6. <https://doi.org/10.1186/s40580-019-0197-y>
- Vorobioff, J., Cerrotta, S., Morel, N. E., & Amadio, A. (2022). *Inteligencia Artificial y Redes Neuronales. Fundamentos, Ejercicios y Aplicaciones Con Python y Matlab.*. Buenos Aires. Obtenido de <https://ria.utn.edu.ar/handle/20.500.12272.6113>.
- Walecki, W. J., Lai, K., Pravdivtsev, A., Souchkov, V., Van, P., Azfar, T., Wong, T., Lau, S. H., & Koo, A. (2005). Low-coherence interferometric absolute distance gauge for study of MEMS structures. *Reliability, Packaging, Testing, and Characterization of MEMS/MOEMS IV*, 5716, 182. <https://doi.org/10.1117/12.590013>