



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA



UNIVERSITAT POLITÈCNICA DE VALÈNCIA

Dpto. de Comunicaciones

Diseño de estructuras fotónicas de silicio asistido por
aprendizaje profundo

Trabajo Fin de Máster

Máster Universitario en Tecnologías, Sistemas y Redes de
Comunicaciones

AUTOR/A: Lopez Alvarado, Miguel

Tutor/a: Sanchis Kilders, Pablo

Director/a Experimental: Navarro Arenas, Juan

CURSO ACADÉMICO: 2023/2024

Objetivos - El objetivo principal del trabajo es diseñar una estructura fotónica, concretamente un dispositivo de modulación basado en tecnología de óxidos transparentes conductores (TCO del inglés *Transparent Conducting Oxides*) combinada con silicio (Si), prediciendo las características más óptimas con aprendizaje profundo.

Como objetivos específicos:

- Desarrollar una arquitectura de aprendizaje profundo para modelar una guía de onda híbrida TCO/Si en la plataforma de silicio sobre aislante.
- Usar el modelo desarrollado para el diseño de un modulador todo óptico basado en la guía híbrida.

Desarrollo de prototipos y trabajo de laboratorio – Se probaron diferentes configuraciones para la arquitectura de la red neuronal en un ordenador de uso personal, provisto de las capacidades de cómputo necesarias para la tarea. Por otra parte, la interacción de la guía de ondas basada en TCO/Si, se evaluó en un entorno de laboratorio virtual alojado en las instalaciones del Instituto Universitario de Tecnología Nanofotónica.

Resultados – La unión de los modelos de aprendizaje automático y los dispositivos basados en TCOs en estado ENZ, se espera que contribuya al desarrollo de dispositivos optoelectrónicos con tamaños compactos, menor consumo de energía y menor tiempo de conmutación entre todas las tecnologías de modulación fotónica conocidas hasta la fecha.

Líneas futuras – Se plantea realizar una red neuronal capaz de predecir la interacción de una estructura fotónica de guiado de ondas con la forma de un capacitor doble, superando los retos necesarios y recolectando toda la información necesaria para lograrlo.

Abstract – As electronics approach their limits in speed and miniaturization, silicon-integrated photonic emerges as a promising solution. This Master's Thesis (TFM) focuses on designing an all-optical modulator using a combination of transparent conductive oxides (TCOs) and silicon, optimizing its characteristics through deep learning techniques. The project explores the use of TCOs, materials that allow precise adjustments of their permittivity to operate in the regime ENZ (*Epsilon-near-zero*), where the real permittivity approaches zero. This phenomenon enables significant improvements in energy efficiency and modulation speed. The contemplated device is a hybrid TCO/Si device that uses a capacitive structure to vary its complex index, and its optimization has been achieved by applying deep neural networks. Through modelling and creating a neural network, the optimal operating conditions of the device are predicted, maximizing its performance. Simulation has demonstrated the feasibility of the proposed approach. In this way, it is possible to improve the performance of modulation devices, which are key devices for driving the integration of photonic and electronic technologies on silicon platforms, opening a new path in the field of integrated photonics.

Resumen- A medida que la electrónica se acerca a sus límites en velocidad y miniaturización, la fotónica integrada en silicio emerge como una solución complementaria prometedora. Este Trabajo de Fin de Máster (TFM) se enfoca en el diseño de un modulador todo óptico utilizando una combinación de óxidos transparentes conductores (TCOs, del inglés *Transparent Conducting Oxides*) y silicio, optimizando sus características mediante técnicas de aprendizaje profundo. El proyecto explora el uso de TCOs, materiales que permiten ajustes precisos de su permitividad para operar en el régimen ENZ (*Epsilon-near-zero*), donde la permitividad real se aproxima a cero. Este fenómeno permite mejoras significativas en eficiencia energética y velocidad de modulación. El dispositivo contemplado es un dispositivo híbrido TCO/Si que utiliza una estructura capacitiva para variar su índice complejo, y su optimización se ha logrado aplicando redes neuronales profundas. Mediante el modelado y creación de una red neuronal, se predicen las condiciones óptimas de funcionamiento del dispositivo, maximizando su rendimiento. La simulación ha demostrado la viabilidad del enfoque propuesto. De esta forma, es posible mejorar el rendimiento de los dispositivos de modulación, el cual es un dispositivo clave para impulsar la integración de tecnologías fotónicas y electrónicas en plataformas de silicio, abriendo un nuevo camino en el campo de la fotónica integrada.

Autor: Lopez Alvarado, Miguel Avilio, email: mlopalv@teleco.upv.es

Director 1: Sanchis Kilders, Pablo, email: pabsanki@ntc.upv.es

Director 2: Navarro Arenas, Juan, email: juanaar@ntc.upv.es

Fecha de entrega: 05-07-24

LISTA DE ACRÓNIMOS

AZO - Aluminum-doped Zinc Oxide

CdO - Cadmium Oxide

CMOS - Complementary Metal-Oxide Semiconductor

CNNs - Convolutional Neural Networks

CW - Continuous Wave

ENZ - Epsilon-near-zero

FC - Fully-connected

FOM - Figure of Merit

GZO - Gallium-doped Zinc Oxide

ITO - Indium-Tin-Oxide

MAE - Error Absoluto Medio

MSE - Error Cuadrático Medio

NTC - Nanophotonics Technology Center

PCB - Printed Circuit Board

SOI - Silicon On Insulator

TCO - Transparent Conductive Oxides

TFM - Trabajo de Fin de Máster

TM - Transversal Magnética

UPV - Universidad Politécnica de Valencia

LISTA DE FIGURAS

Figura 1: Ejemplo de integración híbrida en la plataforma SOI.

Figura 2: Evolución esperada en la integración fotónica-electrónica en dispositivos para aplicaciones en centros de procesamiento de datos.

Figura 3: Clasificación de diseños asistidos por algoritmos de inteligencia para la optimización de dispositivos fotónicos.

Figura 4: Guía híbrida que constituye el problema físico a predecir mediante un perceptrón multicapa.

Figura 5: Ejemplo de una red neuronal con capas de entrada oculta y de salida.

Figura 6: Forma de la arquitectura de la red neuronal de aprendizaje profundo utilizada, para obtener $n_{eff} + ik_{eff}$.

Figura 7: Código en lenguaje Python utilizando la librería Keras para la creación y compilación de la red neuronal utilizada en el TFM.

Figura 8: Diagrama de flujo del proceso para la creación del conjunto de datos a partir de los parámetros generados aleatoriamente para la guía de onda híbrida.

Figura 9: Resultado de la generación aleatoria de valores para las características n_{TCO} , k_{TCO} , t y el gap .

Figura 10: Histograma de los datos de salida para el conjunto de datos de entrada.

Figura 11: Dataset generado para el entrenamiento de la red neuronal de predicción de índices de refracción efectivos.

Figura 12: Script en Python para la extracción y combinación de datos de archivos ".nef" para la generación del Dataset de entrenamiento de la red neuronal.

Figura 13: Código de entrenamiento de la red neuronal.

Figura 14. Evolución del Error Absoluto Medio (MAE) y el Error Cuadrático Medio (MSE) durante el entrenamiento

Figura 15: Principio de funcionamiento de un dispositivo de modulación todo-óptico basado en una guía de onda TCO/Si.

Figura 16: Extracto del conjunto de datos que representan el índice de refracción en función de T_e y N para un TCO de óxido de cadmio.

Figura 17: (a) Índice de refracción y (b) coeficiente de extinción efectivos de la guía híbrida TCO/Si (con gap y espesor de 20 nm) en representación bidimensional para sus dos variables T_e y N .

Figura 18: Mapa bidimensional de la figura de mérito (FOM) en función de la temperatura electrónica (T_e) y la concentración de portadores (N) para la guía híbrida TCO/Si.

Figura 19: Tipos de moduladores según su arquitectura fotónica.

ÍNDICE

1. Introducción	7
1.1. Fotónica en la plataforma del silicio sobre aislante	7
1.2. Integración híbrida	7
1.3. Introducción al aprendizaje profundo	9
1.4. Aprendizaje profundo en la fotónica.....	9
2. Modelado de guías de ondas híbridas con aprendizaje profundo.....	11
2.1 Estructura de una guía de ondas híbrida y planteamiento del problema a resolver	11
2.2 Arquitectura de la red neuronal.....	12
2.2.1. Aprendizaje profundo y Python	14
2.2.2. Librerías utilizadas	14
2.2.3. Procesamiento de los datos	14
2.2.4. Construcción de la red neuronal.....	15
2.3. Generación de datos	17
2.4 Análisis de los resultados	20
3. Diseño de un modulador todo óptico basado en guías de ondas TCO/Si.....	22
3.1 Los TCOs como material activo	22
3.2 Modelado de Drude extendido de la permitividad del TCO	23
3.3. Cálculo del índice de refracción efectivo de la guía híbrida TCO/Si.....	24
3.4 Evaluación de la figura de mérito para alcanzar un alto rendimiento	26
4. Conclusiones y líneas futuras.....	28
4.1 Conclusiones	28
4.2 Trabajo futuro	29
Y. Referencias.....	30

1. Introducción

1.1. Fotónica en la plataforma del silicio sobre aislante

La investigación y comercialización de la fotónica en la plataforma del silicio sobre aislante (SOI) se ha intensificado en la última década, debido a mejoras tanto en el rendimiento de componentes como en la complejidad de su integración. Esta tecnología trae consigo un gran número de aplicaciones, desde telecomunicaciones hasta sensores. Los factores clave que impulsan el uso de esta plataforma fotónica son las idóneas propiedades de las guías de ondas SOI: bajas pérdidas ópticas, tamaño compacto debido al gran contraste de índice entre el Si y el SiO₂, y la uniformidad en la fabricación, gracias a la madurez del procesamiento que ya existe en el ecosistema de la electrónica CMOS (*Complementary Metal-Oxide Semiconductor*), cuyos procesos se aplican ahora en la fabricación de los circuitos integrados fotónicos de silicio asegurando así su escalabilidad [1].

En la actualidad, existe una gran necesidad de aumentar la velocidad de procesamiento de datos en las sistemas y redes de telecomunicaciones. Son numerosas las aplicaciones actuales que requieren trabajar con tiempos de conmutación cada vez menores para procesar y almacenar información de alta densidad. En la electrónica actual, la resistencia y capacidad de las interconexiones eléctricas limita la frecuencia de trabajo y el consumo de energía. Por ello, la velocidad de los transistores depende sobre todo del tamaño de la puerta del capacitor. A lo largo de los años se ha tratado de mejorar el rendimiento de estos circuitos reduciendo el tamaño de los componentes, pero se cree que se está llegando al límite de la escalabilidad. Por todo esto, la fotónica de silicio representa una tecnología alternativa prometedora al ofrecer velocidades de procesamiento más rápidas y un menor consumo de energía, gracias a la transmisión de datos a través de la luz en lugar de electrones [2].

1.2. Integración híbrida

La fotónica integrada se refiere a las tecnologías y campos de estudio que se centran en la manipulación y control de la luz en la escala de un circuito integrado. En la fotónica integrada la luz es utilizada para transportar información, similar a como los electrones son usados en la electrónica. El motivo principal de usar fotones en lugar de electrones es debido a la alta frecuencia de la luz, alrededor de 200 THz, permitiendo un ancho de banda muy grande para transportar y gestionar grandes cantidades de información. [3].

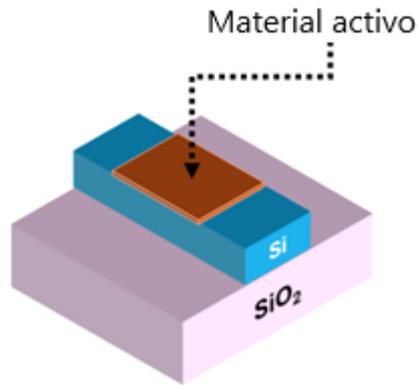


Figure 1. Ejemplo de integración híbrida en la plataforma SOI.

En la tecnología fotónica de dispositivos con integración híbrida, se combinan materiales activos y pasivos en una misma guía de ondas para aprovechar las propiedades únicas de cada uno. En la Figura 1 se muestra un ejemplo de dispositivo fotónico con integración híbrida: la guía de ondas híbrida. Los materiales activos introducen capacidades de modulación y amplificación de la señal óptica, el silicio se utiliza como material pasivo, aprovechando las excelentes propiedades de transmisión de luz mencionadas arriba. Existe una gran selección de materiales con propiedades activas que pueden integrarse en la plataforma SOI. Algunos de los más relevantes en la literatura reciente son los materiales de cambio de fase [4], los óxidos transparentes conductores o los materiales bidimensionales [5] [6]. Cada uno de estos materiales posee un rango de aplicabilidad que depende sensiblemente de la aplicación del dispositivo fotónico que se desea diseñar [7].

La librería actual de materiales fotónicos disponibles permite que las tecnologías de integración híbridas puedan dar lugar a circuitos integrados ópticos de alta densidad y alto rendimiento, con funcionalidades activas avanzadas, a través de procesos de fabricación híbrida de bajo costo que aprovechen el ecosistema CMOS [3] [8].

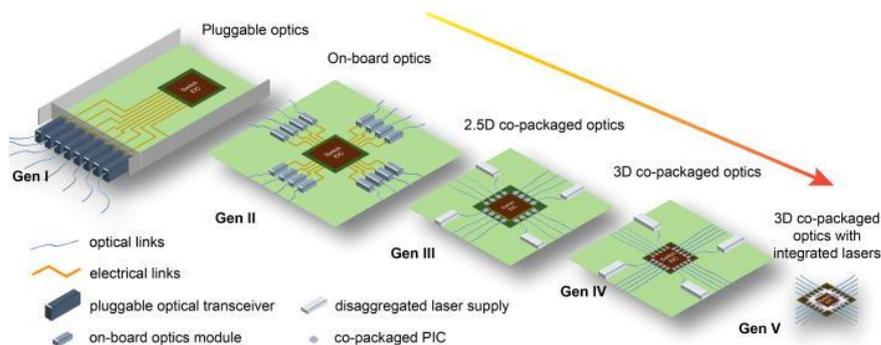


Figura 2. Evolución esperada en la integración fotónica-electrónica en dispositivos para aplicaciones en centros de procesamiento de datos [1].

La figura 2 muestra la evolución esperada en la integración fotónica-electrónica para el desarrollo de dispositivos para aplicaciones en centros de procesamiento de datos. La primera generación es ya

una realidad con transceptores enchufables y pistas de comunicación eléctricas, que se espera que evolucionen a módulos ópticos incorporados en la PCB con láseres integrados [1]. Los dispositivos de quinta generación incluyen la electrónica de control necesaria para manipular las propiedades de los materiales que determinan el comportamiento activo en los dispositivos fotónicos.

1.3. Introducción al aprendizaje profundo

El campo del aprendizaje profundo, una rama revolucionaria dentro de la inteligencia artificial se destaca por su notable capacidad de aprender de forma autónoma representaciones de datos de alta complejidad. Los métodos empleados en el aprendizaje profundo se fundamentan en técnicas que involucran la composición secuencial de modelos no lineales. Estos, capa tras capa, van transformando los datos de entrada en representaciones cada vez más abstractas. Gracias a este proceso jerárquico, el aprendizaje profundo tiene la habilidad de identificar y capturar patrones y características complejas, que a menudo pueden ser imperceptibles para los métodos de análisis tradicionales [9].

El aprovechamiento de esta técnica abre un espacio prometedor para las investigaciones científicas, ofreciendo una vía hacia descubrimientos y avances significativos. Tomando como ejemplo el campo de la fotónica en este Trabajo de Fin de Máster (TFM), el aprendizaje profundo puede ser utilizado para predecir con gran precisión los índices de refracción efectivos y las propiedades deseadas, facilitando así la optimización de la estructura fotónica.

Sin embargo, el uso del aprendizaje profundo como técnica no está exento de desafíos. Entre estos se incluyen la necesidad de disponer de grandes cantidades de datos etiquetados para el entrenamiento y la complejidad inherente a la interpretación de los modelos aprendidos. Estos obstáculos recalcan la importancia de continuar investigando y desarrollando nuevas estrategias que permitan superar tales limitaciones, asegurando así el máximo aprovechamiento de esta tecnología en el avance de diversos campos científicos y tecnológicos.

1.4. Aprendizaje profundo en la fotónica

El aprendizaje profundo ha emergido como una herramienta poderosa que acelera de manera significativa el diseño de estructuras fotónicas que son clave para el desarrollo de dispositivos optoelectrónicos. Estos dispositivos, que deben cumplir con especificaciones altamente precisas, se benefician enormemente de la capacidad de esta técnica para optimizar su desarrollo y personalización, especialmente en ámbitos que exigen una precisión y exactitud rigurosa.

El diseño inverso, por su parte, es una metodología de ingeniería orientada a la creación y mejora de dispositivos, estructuras o sistemas, partiendo de un objetivo de rendimiento específico. Este enfoque metodológico se fundamenta en dos pilares principales: un modelo matemático que detalla la física subyacente y un algoritmo de optimización que busca identificar los parámetros adecuados

para alcanzar el rendimiento deseado. Antes de la inteligencia artificial, este método se apoyaba ampliamente en técnicas tradicionales basadas en principios matemáticos y físicos para modelar la interacción entre diversos parámetros y objetivos [10].

Entre estas técnicas, se encuentran los métodos basados en gradientes, como la optimización adjunta (*adjoint method*) y el método del conjunto de niveles (*level set method*), que se enfocan en calcular el gradiente a los parámetros de diseño. Sucesivamente, los métodos sin gradientes, que incluyen algoritmos evolutivos y de búsqueda, también han sido empleados.

Dado que las ecuaciones de Maxwell presentan una complejidad considerable, se han explorado soluciones alternativas como el aprendizaje profundo para mejorar la eficiencia computacional. La integración de este enfoque con las metodologías tradicionales de diseño inverso representa una unión prometedora, potenciando las ventajas de ambas técnicas para superar limitaciones previas. Estas estrategias han sido aplicadas con éxito en la optimización y diseño de dispositivos fotónicos, marcando un hito en el campo [10].

El potencial del aprendizaje profundo para revolucionar el diseño inverso en la fotónica integrada ha sido demostrado con claridad, por ejemplo, en el desarrollo de divisores de potencia. Esta aplicación ilustra cómo la inteligencia artificial puede superar obstáculos inherentes a los métodos de diseño convencionales, permitiendo una búsqueda más efectiva del espacio de diseño y el logro de rendimientos anteriormente inaccesibles [11].

En la inteligencia artificial residen una variedad de algoritmos artificiales que pueden ayudarnos a realizar diseños de nanoestructuras. Actualmente, los algoritmos de aprendizaje aplicado a las nanoestructuras se clasifican generalmente como dos etapas: (i) técnicas de optimización tradicional y (ii) los modelos de aprendizaje profundo. A finales de la década de los 90s la optimización tradicional llamo la atención del público por varios trabajos a escala de longitud de onda, por ejemplo, un acoplador de guía de ondas, más tarde se implementó una guía de onda de cristal fotónico tipo 'Z' y un divisor en forma de 'Y' [12].

Continuando su desarrollo, ha habido un aumento exponencial en el interés por el aprendizaje profundo y su potencial en estructuras fotónicas artificiales, como puede ser el considerable trabajo en los divisores de banda ancha, metamateriales quirales y redes neuronales, entre muchos otros [12].

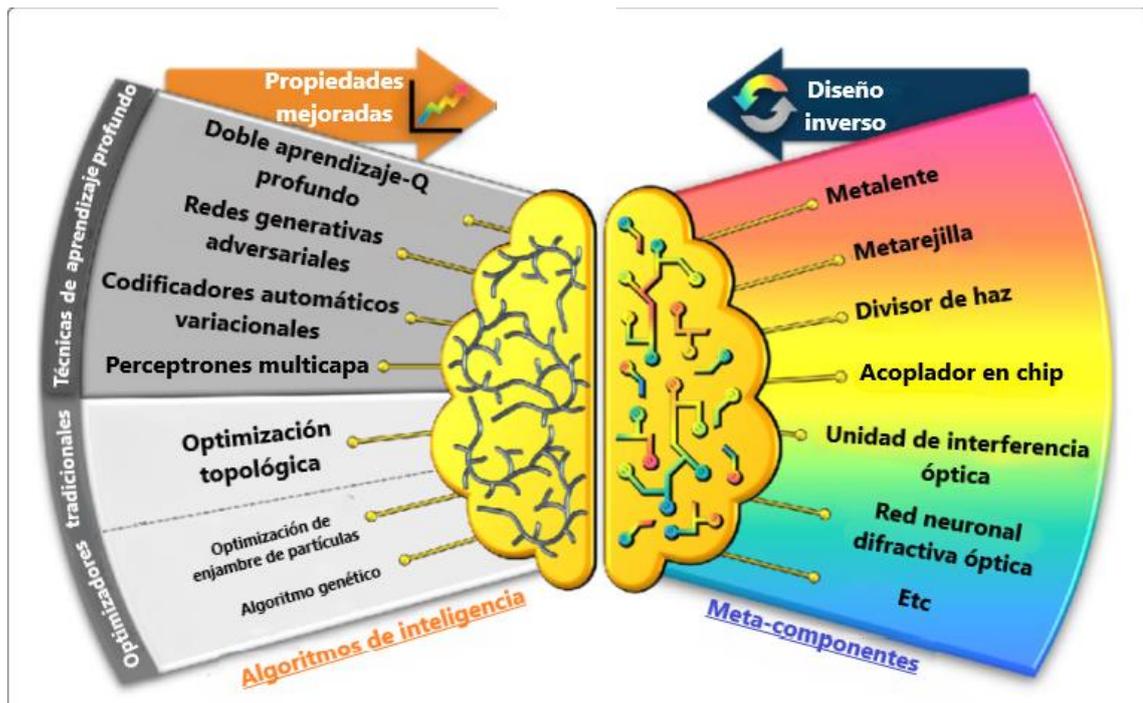


Figura 3. Clasificación de diseños asistidos por algoritmos de inteligencia para la optimización de dispositivos fotónicos.

En la figura 3, resume el estado del arte del uso de las técnicas de aprendizaje profundo para el diseño de dispositivos fotónicos más eficientes. A la izquierda, los algoritmos de aprendizaje incluyen técnicas de aprendizaje profundo basadas en redes neuronales, tales como el doble aprendizaje-Q profundo, las redes generativas adversariales, los codificadores automáticos variacionales y los perceptrones multicapa. También se encuentran algoritmos de aprendizaje tradicionales como la optimización topológica, la optimización de enjambre de partículas y el algoritmo genético. Por el lado derecho de la figura se encuentran los metacomponentes específicos, metalente, metarejilla, divisor de haz, acoplador en chip, unidad de interferencia óptica, red neuronal difractiva óptica, etc.

En este trabajo se empleará la técnica de perceptrones multicapa. Una ventaja de los perceptrones multicapa frente a las técnicas mencionadas, es su capacidad para adaptarse a una amplia variedad de problemas de aprendizaje supervisado y no supervisado, así como a problemas de regresión y clasificación. Esto los hace especialmente útiles en escenarios donde se requiere un enfoque más general y flexible para el análisis de datos, como el problema que proponemos en este TFM.

2. Modelado de guías de ondas híbridas con aprendizaje profundo

2.1 Estructura de una guía de ondas híbrida y planteamiento del problema a resolver

Uno de los objetivos de del TFM consiste en predecir las condiciones de guiado (índice de refracción efectivo del modo fundamental) de la estructura fotónica de la Figura 4.

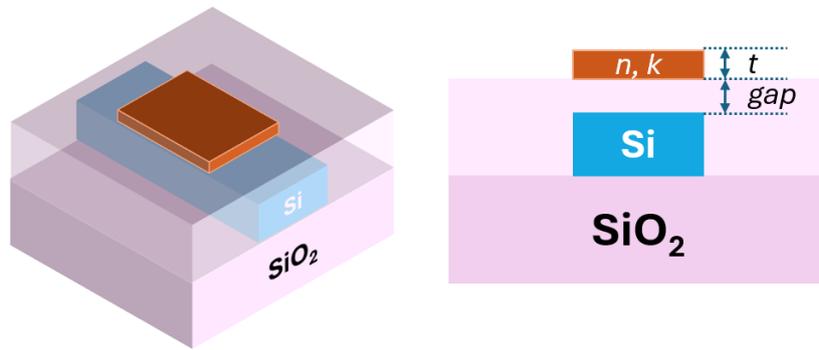


Figura 4. Guía híbrida que constituye el problema físico a predecir mediante un perceptrón multicapa.

Los parámetros para optimizar son el espesor t de la capa de material activo (capa de color ámbar), la separación o gap entre la guía de silicio y el material activo, y el índice de refracción complejo, $n + ik$, del material activo. Las dimensiones de la guía de silicio son 500 nm de anchura y 220 nm de espesor.

2.2 Arquitectura de la red neuronal

En esta sección se detallará como se ha diseñado la arquitectura para la red neuronal, con el fin de predecir el índice de refracción efectivo complejo, $n_{eff} + ik_{eff}$, óptimo en la guía de ondas híbrida. El desarrollo de la red se realiza utilizando Python, un lenguaje de programación conocido por su simplicidad y amplia biblioteca de recursos.

Aclarando que, las redes neuronales son sistemas computacionales con múltiples capas de procesamiento para modelar complejas relaciones en los datos mediante el aprendizaje, permitiéndole a este mejorar su rendimiento en tareas específicas como la predicción, las redes neuronales son la arquitectura sobre la cual se construye el aprendizaje profundo [9].

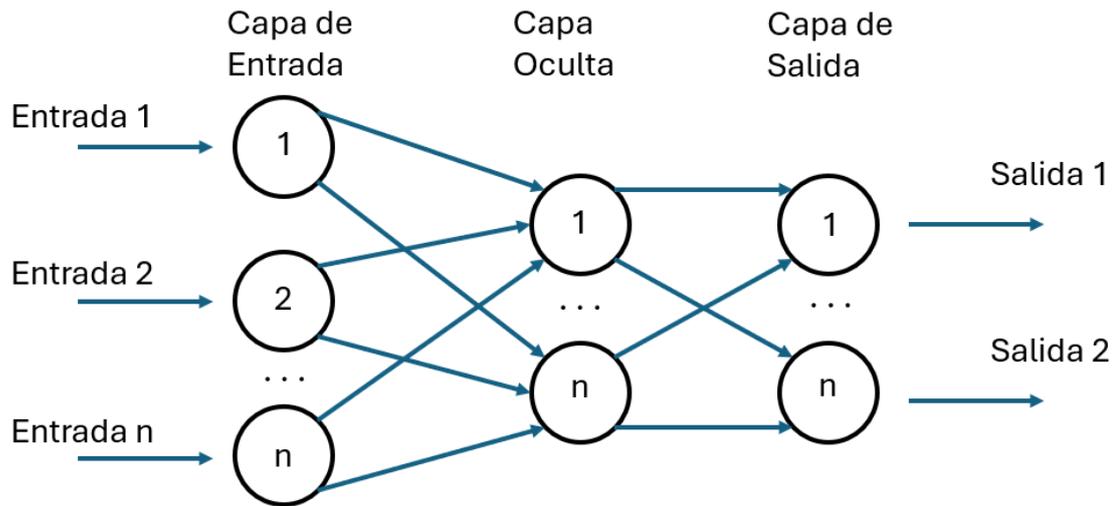


Figura 5. Ejemplo de una red neuronal con capas de entrada, oculta y de salida.

Para este trabajo el modelo utilizado es una red neuronal totalmente conectada o FC (*Fully-connected*), tal y como se muestra en la Figura 5. Este es un tipo de red neuronal donde cada neurona en una capa está conectada a todas las neuronas de la capa siguiente, de forma que la información fluye continuamente desde la capa de entrada, a través de las capas ocultas, hasta llegar a la capa de salida. Los argumentos claves que hacen este tipo de red especialmente adecuada para este trabajo son los siguientes:

- Los datos para este trabajo no poseen una estructura espacial es decir no poseen una relación de disposición geométrica entre sus componentes, como si lo es una imagen donde cada píxel tiene una ubicación específica y suelen estar relacionados entre sí de manera significativa. En este tipo de datos, donde las características visuales como bordes, texturas y formas dependen de la disposición espacial, las redes neuronales convolucionales (CNNs) son especialmente potentes.
- Para nuestro tipo de datos, una red totalmente conectada puede manejar los valores como características independientes, aprendiendo la importancia de cada uno para la predicción de los resultados.
- Las redes totalmente conectadas en construcción son más sencillas y directas que las CNN, brindándonos de una menor carga computacional y menores características en los datos para entrenar el modelo de la manera más efectiva. La escalabilidad y flexibilidad de estas redes nos permiten ajustar la arquitectura (el número de capas y neuronas por capa) para adaptarlo al conjunto de datos que disponemos.

2.2.1. *Aprendizaje profundo y Python*

Python es el lenguaje de elección de la comunidad para el aprendizaje profundo y ciencia de datos debido a bibliotecas especializadas en el área como Keras, Tensorflow y Numpy. La elección de Python es debido a su compatibilidad con Keras, una plataforma de código abierto de alto nivel, así como por su simplicidad y flexibilidad, al ser una librería permite centrarnos en la arquitectura de la red sin preocuparnos por los detalles de bajo nivel.

2.2.2. *Librerías utilizadas*

El proyecto hace uso de diversas librerías para el análisis de los datos, visualización y modelado de redes neuronales. Entre ellas, destacan:

- NumPy y Pandas para la manipulación de datos.
- Matplotlib y Seaborn para visualización de datos.
- TensorFlow y Keras para la construcción y entrenamiento de la red neuronal.
- Scikit-learn para la división de datos en conjuntos de entrenamiento y pruebas.

2.2.3. *Procesamiento de los datos*

En el entrenamiento de una red neuronal es esencial disponer de datos de entrada y salida, para que esta pueda ajustar sus pesos y sesgos de una manera precisa, pudiendo realizar la tarea de regresión que necesitamos para la predicción de los índices de refracción efectivos.

Se realiza un procesamiento de datos, donde se leen los archivos obtenidos de las simulaciones realizadas y se extraen características necesarias para el posterior entrenamiento de la red.

2.2.3.1. *Datos de entrada y Salida*

Para la selección de los datos de entrada del modelo, se optó por identificar y utilizar aquellos parámetros que son más susceptibles a modificaciones en una estructura fotónica estándar, a la vez que se evita añadir complejidades innecesarias. Los parámetros elegidos, son: n_{TCO} (parte real del índice de refracción), k_{TCO} (coeficiente de extinción), t (espesor del material activo) y el *gap* (separación entre elementos de la guía), tienen una influencia significativa en las propiedades ópticas de las guías de onda. Estos parámetros son fundamentales para el diseño eficiente de un modulador óptico, dada su relevancia directa en el control y manipulación de las señales ópticas. Los datos de entrada son generados a partir de una distribución uniforme.

Los datos de salida del modelo provienen de simulaciones, en las cuales, partiendo de los parámetros de entrada y considerando variables adicionales relacionadas con las características del material, se resuelven las ecuaciones de Maxwell por elementos finitos con un solucionador de modos comercial (FEMSim del paquete de software Synopsys). Como resultado, se obtienen los índices de refracción efectivos, tanto la parte real como la imaginaria. Estos índices establecen una

relación directa entre los parámetros de entrada y el comportamiento físico de la guía de ondas. Por lo tanto, el índice de refracción complejo es el único parámetro de salida necesario para este modelo, capaz de predecir las propiedades de guiado del dispositivo.

2.2.4. Construcción de la red neuronal

En la creación de la estructura fotónica mediante el aprendizaje profundo, se ha desarrollado una red neuronal específica para predecir los índices de refracción efectivos de la guía de onda híbrida TCO/Si, para esto se utilizaron los datos parámetros descritos en el anterior apartado.

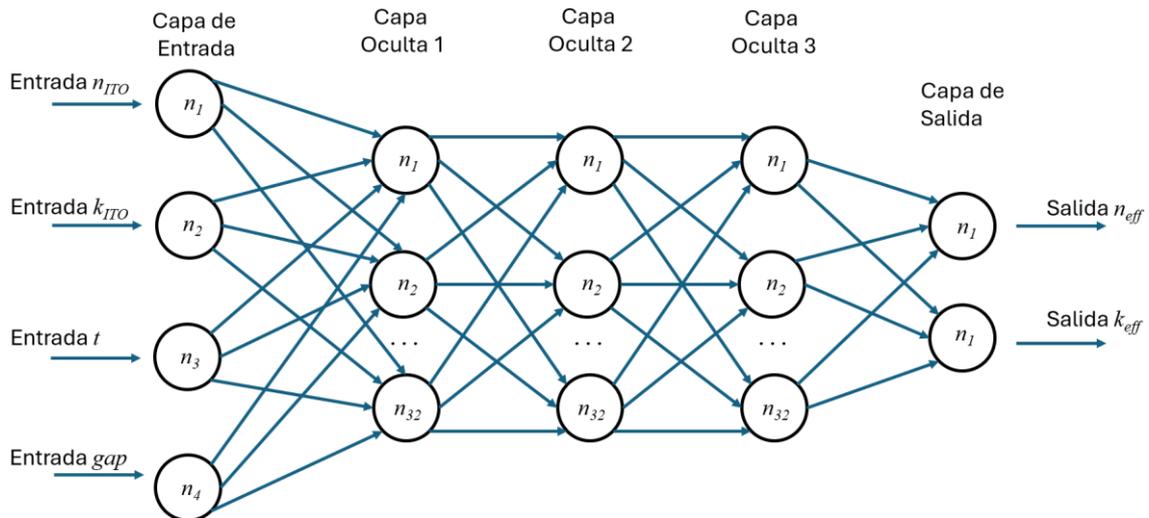


Figura 6. Forma de la arquitectura de la red neuronal de aprendizaje profundo utilizada, para obtener $n_{eff} + ik_{eff}$.

Como se muestra en la Figura 6. La red está compuesta por una arquitectura secuencial que incluye 1 capa de entrada con 4 neuronas correspondiente a los parámetros de la guía de onda, 3 capas ocultas densas con 32 neuronas cada una, seguidas por una capa de salida con 2 neuronas en base a las predicciones del índice efectivo. Estos hiperparámetros fueron ajustados para obtener la mayor precisión posible. La selección de una arquitectura densa o “totalmente conectada” es debido a la naturaleza de los datos y el tipo de problema de regresión, dando la necesidad de capturar interacciones complejas entre los parámetros de entrada y salida.

Para las capas ocultas se utilizó la función de activación ReLU (Unidad lineal rectificadora) debido a su bajo coste computacional. La capa de entrada y salida no requieren de ninguna función de activación.

En este fragmento de código se muestran las instrucciones necesarias para generar en Keras el modelo descrito arriba:

```

# creación del modelo
def build_model():
# Creacion de la capa de entrada, capas ocultas y capa de salida
    model = keras.Sequential([
        layers.Dense(32, activation=tf.nn.relu, input_shape=[len(X_train.keys())]),
        layers.Dense(32, activation=tf.nn.relu),
        layers.Dense(32, activation=tf.nn.relu),
        layers.Dense(2)
    ])

# Algoritmo de optimización
optimizer = tf.keras.optimizers.RMSprop(0.001)

# Se escoge la metrica guia para el algoritmo de optimización
# ademas de las métricas mostradas para el seguimiento de la evaluación
model.compile(loss='mean_squared_error',
              optimizer=optimizer,
              metrics=['mean_absolute_error', 'mean_squared_error'])
return model

# Arreglo para representar un resumen del modelo en interfaz
model = build_model()
model.summary()

```

Figura 7. Código en lenguaje Python utilizando la librería Keras para la creación y compilación de la red neuronal utilizada en el TFM.

En el proceso de entrenamiento, los datos se dividen en un conjunto de entrenamiento y prueba, utilizando una proporción de 20% para pruebas y el 80% para entrenamiento. Este balance permite una evaluación al rendimiento del modelo en datos que no ha visto, garantizando robustez y precisión. El modelo utiliza RMSprop como algoritmo de optimización con una tasa de aprendizaje del 0.001. Se trata de un hiperparámetro que controla cuanto se ajustan los pesos de la red neuronal en respuesta al error calculado cada vez que se actualizan durante el entrenamiento. El incremento de los pesos es pequeño permitiendo una búsqueda más precisa de un valor óptimo.

La red neuronal se evalúa utilizando parámetros como el error cuadrático medio, complementada con el error absoluto medio, proporcionando información sobre la precisión de los entrenamientos y los errores respectivamente. Estas métricas son de suma importancia para ajustar y mejorar el rendimiento del modelo.

2.3. Generación de datos

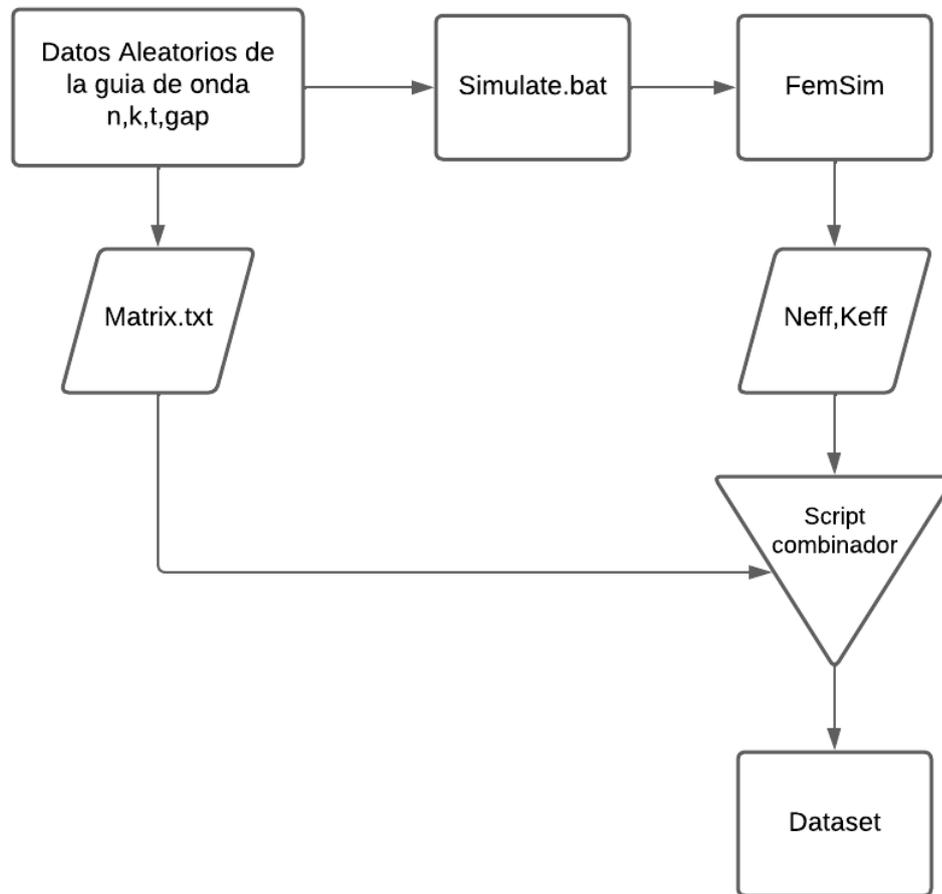


Figura 8. Diagrama de flujo del proceso para la creación del conjunto de datos a partir de los parámetros generados aleatoriamente para la guía de onda híbrida.

La Figura 8 muestra el diagrama de bloque utilizado para la generación del conjunto de datos (Dataset) para el entrenamiento de la red neuronal. Comienza con la generación de datos aleatorios para los parámetros: n_{TCO} , k_{TCO} , t y el gap , que se introducen en forma de instrucciones en un script Batch, "Simulate.bat". El archivo "Matrix.txt" contiene los parámetros aleatorios que se utilizaron para generar el Batch.

El script Batch se ejecuta en un servidor de gran capacidad computacional cargado con el software "FEMSim". Los resultados de las simulaciones, que incluyen el índice de refracción efectivo n_{eff} y k_{eff} , se generan y se guardan en múltiples archivos. Un segundo script de Python combinador toma estos resultados y los combina con los datos iniciales de la "Matrix.txt" para crear el "Dataset" final.

Para la generación de los datos utilizados en el script Batch y en el archivo "Matrix.txt", se desarrolló un script en Python que genera de manera aleatoria 4096 resultados para los parámetros n_{TCO} , k_{TCO} , t y el gap . Estos parámetros fueron distribuidos en los siguientes rangos: n_{TCO} y k_{TCO} , en el intervalo $[0, 2]$, el espesor t en el intervalo $[0, 0.1]$ y el gap en el intervalo $[0, 0.2]$, como se muestra en la Figura 9.

	ID	mat_re_n	mat_im_n	t	gap
	0	1.734899	0.993997	0.080181	0.153133
	1	1.648811	0.446738	0.061955	0.176584
	2	1.570922	0.871508	0.043510	0.103313
	3	0.278725	1.845832	0.043443	0.033279
	4	0.375641	1.761542	0.050419	0.166194

	4091	7773	0.032385	0.374998	0.056112
	4092	7774	1.983879	1.274059	0.079262
	4093	7775	1.232643	0.743932	0.091948
	4094	7776	1.418185	1.858256	0.090724
	4095	7777	1.362729	0.935931	0.053336

4096 rows × 5 columns

Figura 9. Resultado de la generación aleatoria de valores para las características n_{TCO} , k_{TCO} , t y el gap .

En la Figura 10 se muestra la distribución de datos generados por las simulaciones FEMSim.

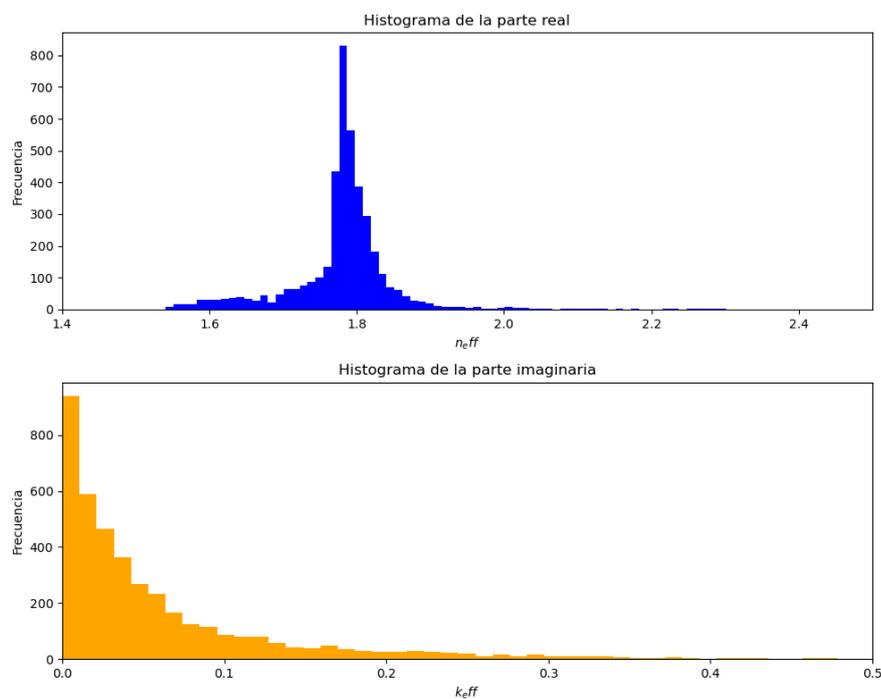


Figura 10. Histograma de los datos de salida para el conjunto de datos de entrada.

Luego, el script combinador toma el archivo “Matrix.txt” y los datos obtenidos de las simulaciones en FEMSim, uniéndolos en una lista ordenada “Dataset”, como se muestra en la Figura 11.

	ID	mat_re_n	mat_im_n	t	gap	re_n	im_n
	0	1.734899	0.993997	0.080181	0.153133	1.775757	0.005876
	1	1.648811	0.446738	0.061955	0.176584	1.779226	0.002279
	2	1.570922	0.871508	0.043510	0.103313	1.684844	0.048582
	3	0.278725	1.845832	0.043443	0.033279	1.780808	0.014241
	4	0.375641	1.761542	0.050419	0.166194	1.727847	0.012441

	4091	7773	0.032385	0.374998	0.056112	0.176418	1.777898
	4092	7774	1.983879	1.274059	0.079262	0.004104	1.764990
	4093	7775	1.232643	0.743932	0.091948	0.043080	1.544802
	4094	7776	1.418185	1.858256	0.090724	0.151357	1.799073
	4095	7777	1.362729	0.935931	0.053336	0.062227	2.017226
	4096	7778	1.362729	0.935931	0.053336	0.062227	2.017226

4096 rows × 7 columns

Figura 11. Dataset generado para el entrenamiento de la red neuronal de predicción de índices de refracción efectivos.

Las columnas representan el conjunto de datos de entrada y salida, el prefijo “mat_” se refiere a “material”, por ende, “mat_re_n” y “mat_im_n” se refiere a la parte real e imaginaria del índice de refracción del material, “t” al espesor del material activo y el “gap” separación entre la guía de silicio y el material activo, para los datos de salida “re_n” y “im_n” parte real e imaginaria del índice de refracción efectivo. Las simulaciones se realizaron considerando el modo fundamental con polarización transversal magnética (TM), dada su mayor interacción con el material activo en longitudes de ondas para telecomunicaciones.

```

# Funcion que toma todos los archivos dentro del directorio y devuelve
una lista ordenada

def file_list(directory, file_extension):
    search_string = os.path.join(directory, f'*.{file_extension}')
    files = glob.glob(search_string)
    files.sort()
    return files

# Ubicacion y extension
folder = r"C:\Users\miguel\Desktop\CODIGO\Modulater_optic\PREDICT_nk-
hybridWG\GENERATE\generate_Miguel\prueba2_4096"
file_extension = '.nef'
files = file_list(folder, file_extension)

# Datos que se extraeran
re_n, im_n, fileID, fileint = [], [], [], []

# Obtén una lista de todos los archivos .nef en la carpeta de datos
files = sorted(glob.glob(os.path.join(folder, '*.nef')))

# Extraer datos de los archivos
fileID, fileint, re_n0, im_n0, re_n1, im_n1 = [], [], [], [], [], []

for fil in files:
    MODE = 0
    # Extraer la id del archivo y convertirlo a entero
    base_filename = os.path.basename(fil)
    filename_without_ext = os.path.splitext(base_filename)[0]

    # Eliminar el 'r' inicial si está presente
    file_id = filename_without_ext[1:] if filename_without_ext.starts-
with('r') else filename_without_ext

    fileID.append(file_id)
    fileint.append(int(file_id))

    # Cargar los datos del archivo
    _mode, _re_n, _im_n = np.loadtxt(fil, delimiter='\t').T

    # Añadir el valor correspondiente al modo TM
    re_n1.append(_re_n[1])
    im_n1.append(_im_n[1])

#Se agregan los resultados de la simulacion al dataset
df_matrix['re_n'] = (re_n1)
df_matrix['im_n'] = (im_n1)

df_matrix

```

Figura 12. Script en Python para la extracción y combinación de datos de archivos “.nef” para la generación del Dataset de entrenamiento de la red neuronal.

El script combinador de la Figura 12, tiene como objetivo automatizar el proceso de lectura de los 4.096 archivos generados de las simulaciones en FEMSim. De todos los datos que estos contengan se extraen únicamente la parte real e imaginaria del índice de refracción efectivo “re_n”, “im_n” del modo de propagación TM y longitud de onda de 1550 nm.

2.4 Análisis de los resultados

En esta sección se presentan y analizan los resultados obtenidos tras el entrenamiento de la red neuronal. Para la evaluación se implementaron métricas de error, se incluyeron el error cuadrático medio (MSE) y el error absoluto medio (MAE), como se muestra en la figura 7. Esto nos proporciona un enfoque cuantitativo de la precisión que es capaz de obtener el modelo entrenado. La ejecución del entrenamiento se muestra en la figura 13.

```
# Clase para mostrar en porcentaje el progreso del entrenamiento
class PrintDot(keras.callbacks.Callback):
    def on_epoch_end(self, epoch, logs):
        if epoch % 100 == 0:
            print(epoch/EPOCHS*100)

EPOCHS = 1500

history = model.fit(
    X_train, y_train, #Datos de entrada y salida.
    epochs=EPOCHS, validation_split = 0.2, verbose=0, # El "0.2", indica
    que el 20% de los datos se utilizaran como datos de validación.
    callbacks=[PrintDot()])
```

Figura 13. Código de entrenamiento de la red neuronal.

El código de entrenamiento entrena el modelo donde se encuentra la arquitectura de la red neuronal durante 1500 épocas, utilizando el 20% de los datos de entrenamiento como validación y cada 100 épocas, muestra el progreso en porcentaje del entrenamiento.

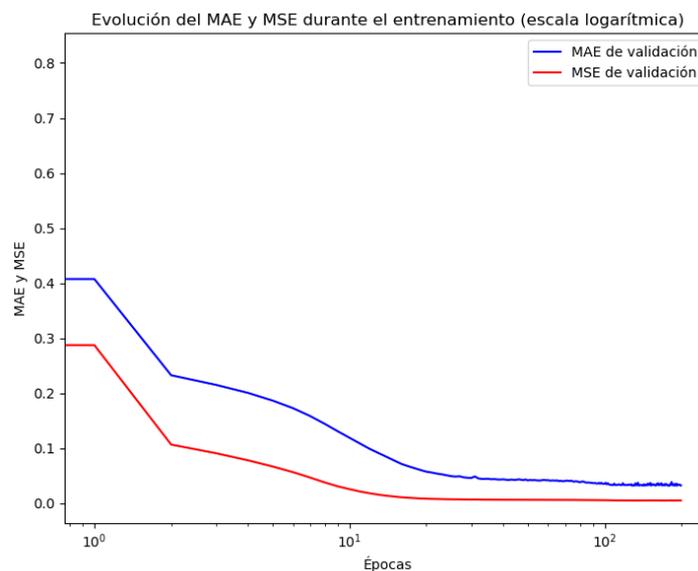


Figura14. Evolución del Error Absoluto Medio (MAE) y el Error Cuadrático Medio (MSE) durante el entrenamiento.

La figura 14, muestra la disminución del MAE y MSE para un periodo de 200 épocas, llegando a valores muy bajos en las últimas pruebas, esto significa:

- MAE: Este calcula la media de las diferencias absolutas entre las predicciones y los valores reales del índice de refracción efectivo. Un MAE bajo indica que las predicciones realizadas por el modelo están muy cerca de los valores reales.
- MSE: Este mide el promedio de los cuadrados de los errores entre las predicciones y los valores reales. Esto se utiliza para penalizar los errores grandes, asegurando que las

predicciones sean las más precisas posibles. Un MSE bajo indica una desviación en los resultados baja.

3. Diseño de un modulador todo óptico basado en guías de ondas TCO/Si

3.1 Los TCOs como material activo

Los materiales basados en óxidos transparentes conductores (TCOs, del inglés *transparent conducting oxides*) son uno de los candidatos con mayor potencial para el desarrollo de dispositivos fotónicos de altas prestaciones, permitiendo el desarrollo de dispositivos ultracompactos, con longitudes activas del orden del micrómetro, junto con una alta eficiencia energética y altas velocidades de operación.

La integración de TCOs en dispositivos fotónicos tiene un alto potencial debido a sus características optoelectrónicas únicas [1]. El aspecto más destacado es el efecto ENZ (*epsilon-near-zero*) — el cual ocurre cuando el material verifica que $|\text{Re}\{\epsilon\}| < 1$ para cierto conjunto de longitudes de onda — en la región espectral del infrarrojo cercano. Puesto que la permitividad ϵ puede reducirse a magnitudes próximas a cero, cualquier pequeño cambio en la constante dieléctrica del TCO introduce cambios significativos en el índice de refracción y la velocidad de fase del medio. A través de su condición ENZ, el índice de refracción de los óxidos transparentes conductores puede sintonizarse mediante excitación óptica o mediante la aplicación de un campo eléctrico externo, los cuales pueden alterar su concentración de portadores. Otro aspecto interesante del efecto ENZ es que puede potenciar el efecto de ciertas estructuras fotónicas diseñadas para confinar la luz, alcanzado órdenes de confinamiento sub-longitud de onda, que permiten una gran interacción materia-luz [2]. De esta forma, es posible conseguir propiedades ópticas no lineales, con tiempos de respuesta por debajo del picosegundo, que ofrecen la posibilidad de romper los límites intrínsecos en la velocidad de conmutación y la eficiencia energética de los dispositivos de modulación actuales.

Existen varios TCOs con efecto ENZ que operan en el infrarrojo, tales como el ITO (del inglés *indium-tin-oxide*), una aleación ternaria óxido de indio y estaño cuya aplicación es prevalente en la industria electrónica actual; el ZnO dopado con elementos del tercer grupo: ZnO dopado con aluminio (AZO) ó ZnO dopado con galio (GZO). El óxido de cadmio, CdO, ofrece las mayores prestaciones en dispositivo ENZ aunque presenta elevados índices de toxicidad.

Sin embargo, pese a las prometedoras características fotónicas que ofrece esta familia de materiales, son pocas las publicaciones que hayan demostrado un dispositivo integrado tipo no lineal en guías de onda híbridas de TCO/Si [5]. Esto se debe a las dificultades tanto en el diseño de la estructura fotónica como en la fabricación de las capas delgadas de TCO, que requieren de una calibración precisa de las propiedades optoelectrónicas del material [13].

En el Instituto Universitario de Tecnología Nanofotónica (NTC) de la UPV, uno de los principales esfuerzos de investigación hacia el desarrollo de tecnologías basadas en materiales disruptivos con TCOs tiene ya antecedentes en el desarrollo de moduladores por efecto de electro-absorción y dispositivos de modulación todo-ópticos que operan de manera no lineal absorbiendo la radiación fotónica que se propaga por la guía de ondas [2] [13] [14]. En este TFM utilizaremos las técnicas de aprendizaje automático para agilizar el diseño de estructuras fotónicas en guía híbrida TCO/Si destinadas a operar como dispositivos de modulación todo-ópticos.

3.2 Modelado de Drude extendido de la permitividad del TCO

Para la realización de esta tarea partiremos de resultados previos que fueron publicados en el grupo de investigación liderado por Pablo Sanchis Kilders (NTC-UPV) en el artículo “Ultrafast all-optical phase switching enabled by epsilon-near-zero materials in silicon” [2] publicado en Optics Express (2022).

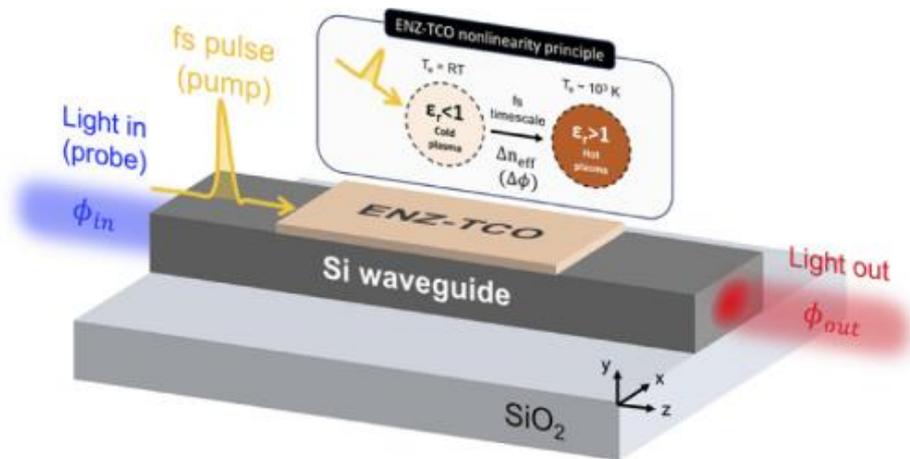


Figura 15. Principio de funcionamiento de un dispositivo de modulación todo-óptica basado en una guía de onda TCO/Si [2].

El material TCO absorbe la potencia de un pulso óptico de bombeo polarizado en TM, de modo que la temperatura electrónica aumenta y se logra una fuerte modulación en la parte real del índice efectivo mientras que se minimiza el cambio de la parte imaginaria. De este modo, se induce un cambio de fase óptica en una señal de prueba de onda continua (CW) desencadenada por la señal de bombeo. Tras la excitación, los electrones calientes sufren un proceso de relajación hasta la temperatura de reposo del dispositivo.

En la publicación [2] se exploran los mecanismos físicos que ocurren durante la excitación del dispositivo de modulación todo-óptico. Una explicación esquemática del principio de funcionamiento queda recogida en la Figura 15. El modelo propuesto se basa en la no linealidad óptica inducida por transiciones intrabanda. El modelo distingue entre la temperatura de los átomos de la red (T_l) y la temperatura de los electrones (T_e). Cuando se absorbe la radiación fotónica la

temperatura electrónica puede elevarse a miles de Kelvin, que será mayor en función de la potencia óptica absorbida por el TCO. La dependencia entre la temperatura electrónica y la permitividad dieléctrica del material está expresada en el modelo de Drude para electrones libres.

$$\varepsilon(\omega) = \varepsilon_{\infty} - \frac{\omega_p^2}{\omega^2 + i\Gamma\omega} \quad (1)$$

donde ω_p y Γ vienen expresados como:

$$\omega_p^2 = \frac{Ne^2}{\langle m_e^* \rangle \varepsilon_0}; \Gamma = \frac{e}{\mu \langle m_e^* \rangle} \quad (2)$$

Aquí ε_{∞} es la permitividad de alta frecuencia, ω_p es la frecuencia de plasma y Γ es la frecuencia de amortiguamiento, ε_0 es la permitividad del vacío, e es la carga del electrón, μ es la movilidad electrónica y N es la concentración de portadores del TCO (que está relacionada con el nivel de dopaje del material).

Los parámetros N y μ pueden manipularse durante la fabricación del material. Por otra parte, la masa efectiva electrónica (m_e^*) es el parámetro que introduce la dependencia con la temperatura electrónica en el modelo de Drude.

El cálculo de la $\langle m_e^* \rangle$ en función de la temperatura electrónica está fuera del alcance de los objetivos previstos para este TFM.

3.3. Cálculo del índice de refracción efectivo de la guía híbrida TCO/Si

En este trabajo emplearemos las técnicas de aprendizaje automático para optimizar el dispositivo multicapa de la Figura 15 mediante modelo entrenado en la sección 2. El parámetro crítico de optimización escogido para la optimización de los dispositivos es la concentración de portadores N .

Se pretende obtener la relación entre la temperatura electrónica, el índice efectivo del dispositivo y la concentración de portadores. El índice efectivo del dispositivo se emplea para predecir el comportamiento del dispositivo de modulación (cambio de fase y pérdidas en la señal de prueba) en dos escenarios:

1. En reposo, a temperatura ambiente, $T_e = 300$ K
2. En operación, $T_e > 300$ K.

Para obtener el índice efectivo, primero se ha de obtener el índice de refracción del TCO en función de T_e y N . Los detalles del modelo y los parámetros utilizados para obtener la relación entre la temperatura electrónica y la permitividad compleja del material pueden ser consultados en el

artículo [2]. En este trabajo tomaremos directamente resultados previamente calculados del modelo de Drude en función de T_e y N . En la Figura 16 se representan algunas de las curvas previamente calculadas. El Dataset completo se compone de más de un centenar de estas curvas para obtener suficiente resolución en la representación.

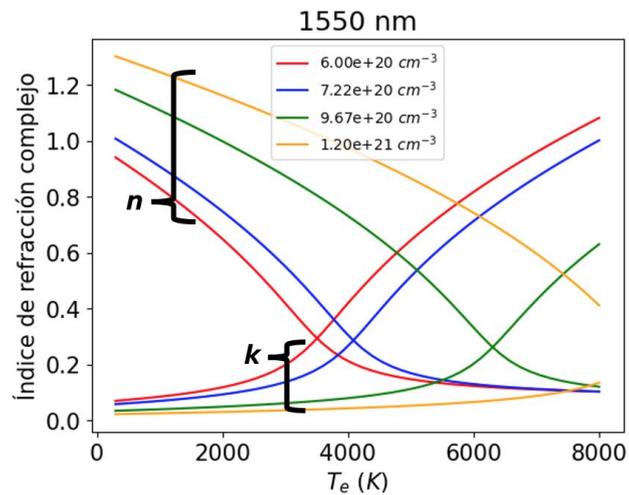


Figura 16. Extracto del conjunto de datos que representan el índice de refracción en función de T_e y N para un TCO de óxido de cadmio.

Estos valores se han obtenido de los resultados intermedios de una de las publicaciones del grupo [2], donde pueden consultarse valores y métodos, y son reproducidos aquí con el permiso de los autores.

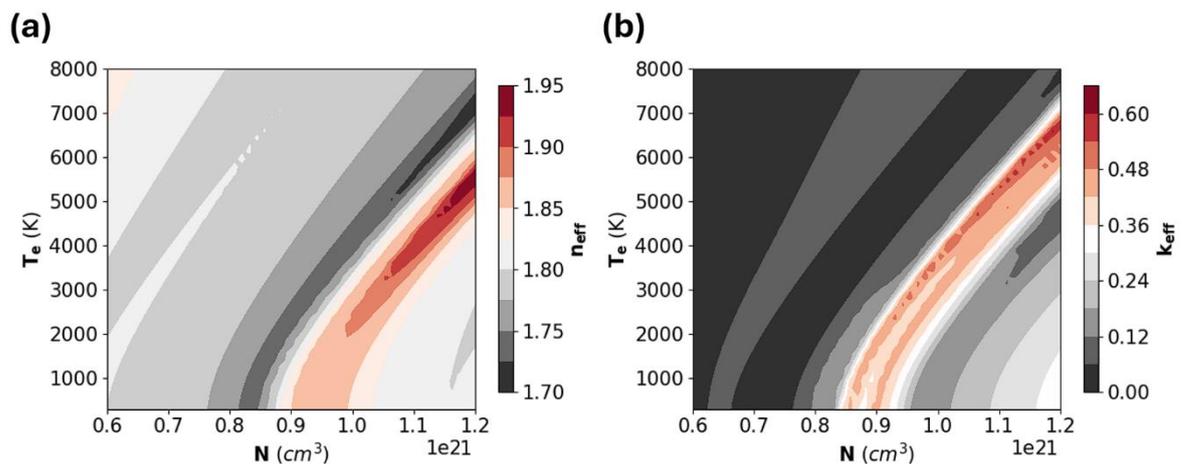


Figura 17. (a) Índice de refracción y (b) coeficiente de extinción efectivos de la guía híbrida TCO/Si (con gap y espesor de 20 nm) en representación bidimensional para sus dos variables T_e y N .

Ahora, mediante el modelo entrenado en el apartado 2, podemos obtener el índice efectivo en función de T_e y N . Para ello, simplemente alimentamos el modelo con los parámetros del gap, el

espesor de TCO y su índice de refracción. En este caso escogemos gap de 20 nm y espesor de 20 nm, estos valores se escogieron por ser óptimos para mejorar el confinamiento en la capa del TCO como ya se ha demostrado en la publicación [2]. De esta forma obtenemos los mapas de índice de refracción de la Figura 17.

En esta figura se aprecian un aspecto esencial del comportamiento del dispositivo; para un cierto valor de N y T_e , tanto el coeficiente de extinción como el índice de refracción aumentan drásticamente (región roja de los mapas bidimensionales). Este comportamiento, que nuestro modelo de aprendizaje automático ha logrado reproducir satisfactoriamente, es el efecto ENZ del material TCO que se manifiesta en el dispositivo de la publicación [2].

3.4 Evaluación de la figura de mérito para alcanzar un alto rendimiento

Mediante los resultados obtenidos en el apartado anterior del índice de refracción efectivo de la guía híbrida TCO/Si se puede ahora optimizar una estructura de tipo modulador de fase. Un modulador de fase debe cumplir varias propiedades para optimizar el cambio de fase con las menores pérdidas ópticas. A continuación, se describen estas propiedades y se introduce una figura de mérito (FOM, del inglés *figure of merit*) para su análisis:

- Alto cambio en el índice de refracción: El material activo, en este caso el TCO, debe presentar un cambio significativo en su índice de refracción cuando se aplica la señal de control (en este caso un pulso óptico que eleva la temperatura electrónica de la capa delgada de TCO). Este cambio en el índice de refracción (Δn_{eff}) es crucial para lograr un cambio de fase elevado y por tanto la posibilidad de reducir significativamente la longitud del dispositivo. En la sección anterior se ha demostrado que existe un conjunto de parámetros N , T_e que dan lugar un Δn_{eff} grande.
- Bajas pérdidas ópticas: El coeficiente de extinción efectivo κ_{eff} debe ser lo más bajo posible en el rango de longitudes de onda de operación para conseguir bajas pérdidas ópticas.

Para realizar el análisis se introduce una figura de mérito adimensional:

$$FOM = \frac{n_{\text{eff}}(T_e, N) - n_{\text{eff}}(T_e = 300, N)}{k_{\text{eff}}(T_e, N) - k_{\text{eff}}(T_e = 300, N)} \quad (3)$$

Esta FOM representa el cambio de fase logrado por unidad de pérdida óptica y se puede calcular con los resultados del apartado anterior.

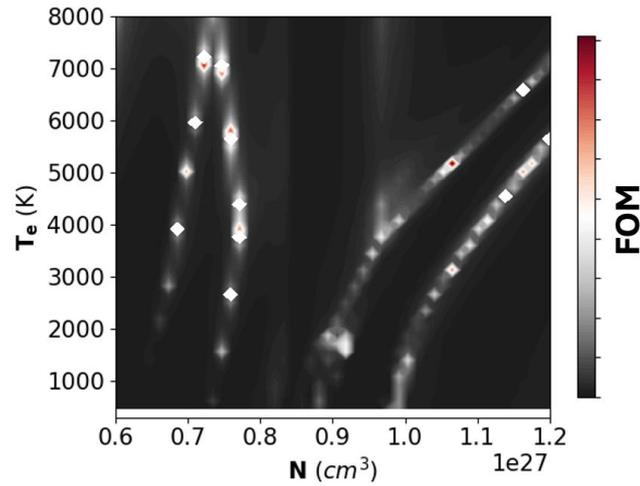


Figura 18. Mapa bidimensional de la figura de mérito (FOM) en función de la temperatura electrónica (T_e) y la concentración de portadores (N) para la guía híbrida TCO/Si.

En la Figura 18 se presenta el mapa bidimensional de la FOM. De este mapa se puede extraer la información de la temperatura electrónica T_e a la que se debe excitar el plasma electrónico con una concentración N para obtener el cambio de fase más eficiente (con las menores pérdidas). Las trazas blancas de la Figura 18 representan las configuraciones óptimas del dispositivo. Los valores extremales (puntos rojos en el mapa), o spikes, son debidos a los errores de la red neuronal pero que, en cualquier caso, siguen la tendencia general de las trazas que dan la configuración del dispositivo.

4. Conclusiones y líneas futuras

4.1 Conclusiones

Mediante este TFM se ha mostrado que un modelo de aprendizaje profundo genérico multicapa de una estructura fotónica en guía híbrida puede reproducir fenómenos físicos que resultan relevantes y de interés para el desarrollo de dispositivos fotónicos. El modelo generado se ha utilizado para reproducir el comportamiento de una guía de ondas híbrida en tecnología TCO/Si. Los resultados obtenidos muestran que la red neuronal es capaz de predecir el índice de refracción efectivo con una baja magnitud de error.

Comparando nuestros resultados con un estudio realizado previamente [2], se observa que el modelo de red neuronal creada ofrece mejoras en el aspecto de eficiencia computacional y reducción de tiempo en simulaciones. Mientras que los métodos tradicionales que se basan en la resolución de las ecuaciones de Maxwell pueden tardar en generar esta cantidad de datos un día o más, el entrenamiento de la red neuronal dura pocos minutos.

En este trabajo se destacan los moduladores basados en TCOs como una de las tecnologías fotónicas integradas emergentes más prometedoras. Esta tecnología se encuentra conceptualmente dentro del ámbito de la plasmónica [5], y ha atraído considerable atención debido a sus mejoras respecto a las tecnologías basadas solo silicio y otras alternativas como la familia de materiales III-V. Los TCOs en la región ENZ permiten una mayor eficiencia energética y una respuesta no lineal más pronunciada, aspectos cruciales para aplicaciones que requieren alta velocidad de conmutación y bajo consumo de energía (por ejemplo, la comunicación cuántica).

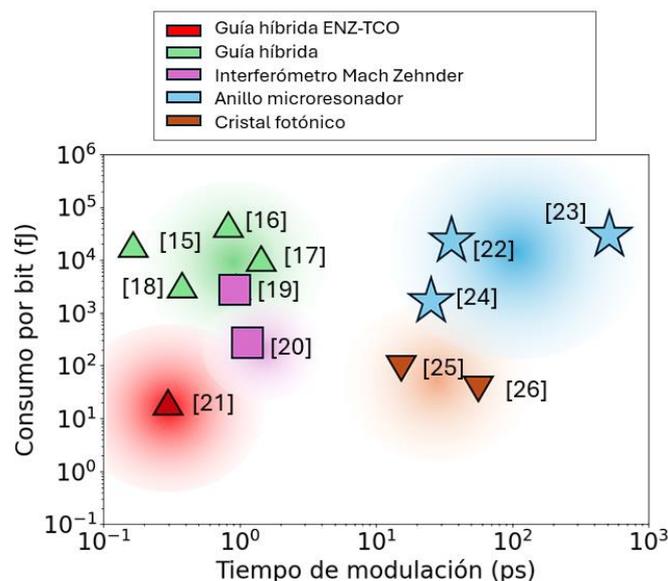


Figura 19. Tipos de moduladores según su arquitectura fotónica.

En la Figura 19 se comparan distintos tipos de moduladores todo-ópticos según su arquitectura fotónica y basados en tecnología III-V y silicio, comparándolas con los moduladores TCO/Si usando simplemente una guía híbrida. La comparación se realiza en términos de consumo energético por bit (energía requerida para cambiar el estado del modulador) y el tiempo necesario para realizar la modulación, aspectos que vienen determinados tanto por la tecnología como la arquitectura fotónica. Esta representación gráfica posiciona a los moduladores basados en TCOs en la región ENZ como una elección superior para aplicaciones avanzadas en comunicaciones, debido a sus prestaciones.

Además, entre las arquitecturas fotónicas mostradas en la Figura 19, la arquitectura de guía híbrida destaca por su menor tamaño en el chip en comparación con otras como las interferométricas o los cristales fotónicos. Por lo tanto, los TCOs como material ENZ permiten una integración más compacta, optimizando así el espacio en el chip. Se ha demostrado específicamente que esta tecnología puede reducir la longitud del dispositivo a escalas de 1 μm , con un consumo energético similar al de las guías de onda plasmónicas pero con significativamente menores pérdidas [21].

Por último, se ha estudiado también la aplicabilidad del modelo de red neuronal para aprovechar las propiedades optoelectrónicas únicas de los TCOs y obtener un rendimiento óptimo de un dispositivo de modulación basado en una guía híbrida TCO/Si.

4.2 Trabajo futuro

Durante el trabajo realizado se estudió también la posibilidad de diseñar una estructura fotónica similar a la presentada, pero con la forma de un capacitor doble. La idea era explorar la viabilidad de esta configuración con el fin de mejorar aún más el rendimiento del dispositivo de modulación con una estructura más compleja. Sin embargo, no se encontró la forma en la cual el modelo pudiera predecir correctamente los datos y durante el desarrollo del doble capacitor surgieron desafíos como la falta de suficientes datos de entrenamiento y la mayor complejidad de las interacciones entre los dos capacitores.

A pesar de los desafíos, el trabajo futuro se propone orientarlo a superar las limitaciones actuales y mejorar la arquitectura de la red neuronal para el diseño del doble capacitor. Para ello, será necesario generar un conjunto de datos lo suficientemente extenso y correcto, incluyendo más parámetros de entrada, y explorar el uso de otras técnicas como las redes neuronales convolucionales (CNNs). Teniendo estas consideraciones se prevé posible lograr la configuración óptima para el doble capacitor.

Y. Referencias

- [1] N. Margalit, C. Xiang, S. M. Bowers, A. Bjorlin, R. Blum, J. E. Bowers, *Perspective on the future of silicon photonics*, Appl. Phys. Lett., vol. 118, no. 22, pp. 220501, May. 2021.
- [2] J. Navarro-Arenas, J. Parra, and P. Sanchis, *Ultrafast all-optical phase switching enabled by epsilon-near-zero materials in silicon*, Opt. Express, vol. 30, no. 9, pp. 14518–14529, Apr. 2022.
- [3] G. Lifante, *Integrated Photonics: Fundamentals*. 2003.
- [4] Z. Gong, F. Yang, L. Wang, R. Chen, J. Wu, C. P. Grigoropoulos, J. Yao, *Phase change materials in photonic devices*, J. Appl. Phys., vol. 129, no. 3, pp. 030902, Jan. 2021.
- [5] J. Wu, Z. T. Xie, Y. Sha, H. Y. Fu, and Q. Li, *Epsilon-near-zero photonics: infinite potentials*, Photonics Res., vol. 9, no. 8, pp. 1616-1644, 2021.
- [6] Z. Tang, S. Chen, D. Li, X. Wang, A. Pan, *Two-dimensional optoelectronic devices for silicon photonic integration*, J. Materiomics, vol. 9, no. 3, pp. 551-567, May 2023.
- [7] S. Shekhar, W. Bogaerts, L. Chrostowski, J. E. Bowers, M. Hochberg, R. Soref, B. J. Shastri, et al., *Roadmapping the next generation of silicon photonics*, Nat. Commun., vol. 15, pp. 751, Jan. 2024.
- [8] S. J. Ben Yoo, *Hybrid integrated photonic platforms: opinion*, Opt. Mater. Express, vol. 11, no. 10, pp. 3528-3534, Oct. 2021.
- [9] Goodfellow, I., Bengio, Y., & Courville, A. *DeepLearning*. MIT Press. 2016.
- [10] Z. Pan and X. Pan, *Deep Learning and Adjoint Method Accelerated Inverse Design in Photonics: A Review*, Photonics, vol. 10, no. 7, pp. 852, Jul. 2023.
- [11] M. H. Tahersima, K. Kojima, T. Koike-Akino, D. Jha, B. Wang, C. Lin, K. Parsons, et al., *Deep Neural Network Inverse Design of Integrated Photonic Power Splitters*, Sci. Rep., vol. 9, pp. 1368, Feb. 2019.
- [12] N. Wang, W. Yan, Y. Qu, S. Ma, S. Z. Li, M. Qiu, *Intelligent designs in nanophotonics: from optimization towards inverse creation*, PhotonIX, vol. 2, pp. 22, Oct. 2021.
- [13] J. Navarro-Arenas, J. Parra, P. Sanchis, *Comparative Performance Evaluation of Transparent Conducting Oxides With Different Mobilities for All-Optical Switching in Silicon*, IEEE Journal of Quantum Electronics, vol. 59, no. 3, pp. 0600207, June 2023.
- [14] J. Navarro-Arenas, J. Parra, P. Sanchis, *Complex-valued trainable activation function hardware using a TCO/silicon modulator*, Optical Materials Express, vol. 13, no. 10, pp. 2869-2881, Oct. 2023.
- [15] Y. Li, A. Bhattacharyya, C. Thomidis, T. D. Moustakas, and R. Paiella, “*Ultrafast all-optical switching with low saturation energy via intersubband transitions in GaN/AlN quantum-well waveguides*,” Opt. Express, vol. 15, no. 26, pp. 17922, Dec. 2007.
- [16] N. Iizuka, K. Kaneko, and N. Suzuki, “*All-optical switch utilizing intersubband transition in GaN quantum wells*,” IEEE J. Quantum Electron., vol. 42, no. 8, pp. 765–771, Aug. 2006.

- [17] T. Simoyama et al., “*Absorption dynamics in all-optical switch based on intersubband transition in InGaAs–AlAs–AlAsSb coupled quantum wells*,” IEEE Photon. Technol. Lett., vol. 19, no. 8, pp. 604–606, Apr. 2007.
- [18] G. W. Cong, R. Akimoto, K. Akita, T. Hasama, and H. Ishikawa, “*Low-saturation-energy-driven ultrafast all-optical switching operation in (CdS/ZnSe)/BeTe intersubband transition*,” Opt. Express, vol. 15, no. 19, pp. 12123, Sep. 2007.
- [19] S. Nakamura, K. Tajima, and Y. Sugimoto, “*Experimental investigation on high-speed switching characteristics of a novel symmetric Mach-Zehnder all-optical switch*,” Appl. Phys. Lett, vol. 65, pp. 283, 1994.
- [20] H. J. S. Dorren et al., “*All-optical logic based on ultrafast gain and index dynamics in a semiconductor optical amplifier*,” IEEE J. Sel. Top. Quantum Electron., vol. 10, no. 5, pp. 1079–1092, Sep. 2004.
- [21] E. Li and A. X. Wang, “*Femto-Joule All-Optical Switching Using Epsilon-Near-Zero High-Mobility Conductive Oxide*” IEEE J. Sel. Top. Quantum Electron., vol. 27, no. 2, March/April 2021.
- [22] T. A. Ibrahim et al., “*All-optical switching in a laterally coupled microring resonator by carrier injection*,” IEEE Photon. Technol. Lett., vol. 15, no. 1, pp. 36–38, Jan. 2003.
- [23] V. R. Almeida, C. A. Barrios, R. R. Panepucci, and M. Lipson, “*All optical control of light on a silicon chip*,” Nature, vol. 431, no. 7012, pp. 1081–1084, Oct. 2004.
- [24] J. S. Pelc et al., “*Picosecond all-optical switching in hydrogenated amorphous silicon microring resonators*,” Opt. Express, vol. 22, no. 4, pp. 3797, Feb. 2014.
- [25] C. Husko et al., “*Ultrafast all-optical modulation in GaAs photonic crystal cavities*,” Appl. Phys. Lett., vol. 94, no. 2, pp. 021111, Jan. 2009.
- [26] T. Tanabe et al., “*Fast all-optical switching using ion-implanted silicon photonic crystal nanocavities*,” Appl. Phys. Lett., vol. 90, no. 3, pp. 031115, Jan. 2007.