



Estimación y minimización de efectos de la interferencia intercanal en sistemas Nyquist-WDM usando técnicas de procesamiento digital de imágenes y aprendizaje automático

Kevin David Martínez Zapata

Trabajo de grado presentado para optar por el título de Ingeniero Electrónico

Tutor

Jhon James Granada Torres, Doctor en Ingeniería Electrónica

Universidad de Antioquia
Facultad de ingeniería
Pregrado en Ingeniería Electrónica
Medellín, Colombia

2024

Cita	Martinez Zapata [1]
Referencia	[1] K. D. Martinez Zapata, “Estimación y minimización de efectos de la interferencia intercanal en sistemas Nyquist-WDM usando técnicas de procesamiento digital de imágenes y aprendizaje automático”, Trabajo de Grado, Ingeniería Electrónica, Universidad de Antioquia, Medellín, Antioquia, 2024.



Grupo de Investigación en Telecomunicaciones Aplicadas (GITA)



Centro de documentación de ingeniería, CENDOI.

Repositorio Institucional: <http://bibliotecadigital.udea.edu.co>

Universidad de Antioquia - www.udea.edu.co

Rector: John Jairo Arboleda Céspedes

Decano: Julio César Saldarriaga Molina

Jefe departamento: Eduard Emiro Rodríguez Ramírez

El contenido de esta obra corresponde al derecho de expresión de los autores y no compromete el pensamiento institucional de la Universidad de Antioquia ni desata su responsabilidad frente a terceros. Los autores asumen la responsabilidad por los derechos de autor y conexos.

Resumen

La interferencia intercanal (ICI) en sistemas Nyquist-WDM sin rejilla fija espectral se da por el reducido espaciado entre canales ópticos, lo que puede conllevar a una degradación de la señal de información y por ende una limitación del sistema de transmisión, siendo difícil de estimar y/o mitigar este efecto sin información de los canales vecinos al canal bajo evaluación. En este trabajo se propusieron dos técnicas basadas en aprendizaje automático para mitigar y estimar la ICI en redes de fibra óptica sin rejilla sin requerir información de canales adyacentes al canal evaluado. La técnica propuesta para mitigar efectos de la ICI fue demodulación no simétrica usando el algoritmo no supervisado DBSCAN, el cual requirió incluir el uso de árboles k-dimensionales para los valores atípicos o ruido residual, permitiendo aumentar el rendimiento en términos de la tasa de error de bit. Por otro lado, el método de estimación de la ICI consiste en tratar los símbolos representados en un diagrama IQ como una imagen usando técnicas de procesamiento digital de imágenes (PDI) y clasificarlos según el porcentaje de traslape espectral mediante una red neuronal convolucional (CNN), siendo la tasa de acierto (accuracy) la métrica elegida para evaluar el rendimiento. Ambas técnicas se validaron experimentalmente en un sistema Nyquist WDM con 3x16 GBaudios modulados en 16-QAM. La técnica de mitigación logró ganancias superiores a 1.2 dB en el límite FEC en comparación con la demodulación convencional, y un rendimiento ligeramente superior para escenarios con un porcentaje de traslape espectral inferior al 6.8% y con una relación de señal a ruido óptico mayor a 32 dB. Por otro lado, la técnica propuesta para la estimación alcanzó una tasa de acierto de ~97% en clasificación binaria (sin traslape y con traslape) y ~76% para clasificación multiclase, siendo superior al rendimiento de la red neuronal convolucional VGG16 preentrenada con más de un millón de imágenes superándola en cada una de las pruebas propuestas (2, 3, 4, 5, 7 y 8 clases). Además, se superó los resultados obtenidos en el estado del arte para la estimación de la ICI en escenarios Nyquist-WDM.

I. Introducción

En la actualidad, las comunicaciones ópticas se utilizan ampliamente en redes de telecomunicaciones a larga distancia, como las redes de fibra óptica submarinas y las redes de área amplia (WAN). También se utilizan en aplicaciones de comunicaciones a corta distancia, como en

centros de datos y redes locales (LAN) [1]. En este contexto, existe la necesidad de interconectar cada vez más dispositivos y tener velocidades de transmisión de datos cada vez mayores, lo que ha influenciado el avance hacia redes con alta capacidad y flexibilidad espectral. Se prevé el uso de sistemas Nyquist-WDM en redes a larga distancia que ya usan WDM debido a su fácil escalamiento, buscando aumentar la eficiencia espectral eliminando incluso la granularidad espectral.

WDM permite dividir en muchos subcanales estrechos que se transmiten en paralelo. Por lo tanto, la duración de los símbolos aumenta y mitiga la interferencia entre símbolos causada por un entorno de desvanecimiento dispersivo en el tiempo. Sin embargo, cuando los símbolos tienen una duración más larga, aumenta la probabilidad de que exista interferencia entre canales transmitidos en paralelo [2]. Existen dos tipos de ICI en las redes de fibra óptica. Primero, la ICI lineal. Esta se debe al espacio reducido entre los canales que genera traslape entre ellos. Estos efectos en señales digitales son similares al ruido blanco gaussiano aditivo (AWGN) visto en un diagrama de constelación. Segundo, la ICI no lineal producto del efecto Kerr. Este efecto se debe a la interacción entre los haces de luz y el material dieléctrico de la fibra, como el vidrio o plástico, que modifica las propiedades de refracción del material dieléctrico alterando la forma en que se propagan las diferentes longitudes de onda en la fibra [3]. Esta variación del índice de refracción es la responsable de las no linealidades de la fibra y de la formación de un espectro no ideal, lo que provoca que el proceso de demodulación por parte del receptor sea más complicado debido a la distorsión y cambios impredecibles en la amplitud y fase de la señal [5].

La ICI se ha tratado de forma convencional usando la ecualización de múltiple-entrada múltiple-salida (MIMO). La ecualización MIMO implica múltiples entradas que son señales recibidas de los múltiples canales procesados de forma simultánea en el receptor incrementando su habilidad para recobrar los mensajes de la señal modulada, aumentar la tasa de transmisión y reducir la tasa de error de bit (BER) [6]. Sin embargo, los requisitos de hardware, la necesidad de conocer con precisión la información de los canales y los efectos no lineales pueden afectar notablemente al proceso de toma de decisiones por parte del receptor. Por esta razón, las técnicas de aprendizaje automático se han convertido en una poderosa herramienta en el área de las telecomunicaciones para abordar el problema de la ICI en las redes de fibra óptica [7].

Gracias a las técnicas de estimación y minimización de la ICI usando aprendizaje automático se ha logrado estimar el espaciamento espectral entre canales. Además, han mostrado una mejora con respecto a las técnicas convencionales usando algoritmos tales como: i) K vecinos más cercanos (KNN), ii) máquina de soporte vectorial (SVM) y iii) K-Means [8].

Ahora, el objetivo es aumentar el valor de estimación bajo diferentes circunstancias del sistema. Por esta razón, se prevé que el uso de técnicas de PDI puede ser prometedor para la interpretación de diagramas IQ, ya que no solo se tendrían 2 características como lo son la fase y cuadratura, sino un conjunto de píxeles, como se muestra en el trabajo previo de estimación del espaciamento espectral usando patrones binarios locales (LBP) [9]. Allí se hace un análisis de texturas de diagramas de constelación procesados como imágenes que posibilita la extracción de características no morfológicas, lo que permite la identificación de patrones ocultos en imágenes a color.

En cuanto a la demodulación, se ha demostrado el buen desempeño de los algoritmos de aprendizaje supervisado en cuanto a la minimización de los efectos de la ICI, pero se pretende explorar técnicas de aprendizaje automático no supervisado adicionales a K-Means que no requieran una etapa de entrenamiento.

Por esta razón, en este trabajo se propone una modificación al algoritmo no supervisado, DBSCAN, basado en agrupamiento espacial que permita minimizar los efectos de la ICI. Además, Se propone un nuevo enfoque que combina una CNN para procesar los datos modulados en 16-QAM como imágenes usando técnicas de PDI permitiendo estimar la ICI. Ambas perspectivas buscan mejorar la toma de decisiones por parte de del receptor permitiendo demodular con mayor precisión e identificar posibles traslapes no deseados entre canales en la fibra óptica y, por lo tanto, mejorar la eficiencia espectral en las comunicaciones ópticas en sistemas Nyquist-WDM.

Este documento cuenta con 6 secciones incluyendo la sección 1 de introducción. En la sección 2 de este documento se presentan los objetivos, general y específicos, referentes a las técnicas de mitigación y estimación de la ICI que se van a usar en este documento. En la sección 3 se tiene el

marco teórico que pretende dar contexto del problema planteado previamente. La sección 4 de este documento es la sección más robusta, donde se encuentran subsecciones referentes al escenario experimental donde se explica de forma detallada de donde surgen los datos usados para validar las técnicas propuestas de mitigación y estimación de la ICI usando de base DBSCAN con la selección de los mejores parámetros y arboles k-dimensionales para clasificar el ruido residual dejado por el algoritmo. También, se expone de forma detallada la técnica basada en DBSCAN y KDTrees para demodulación y el uso de una CNN y técnicas de PDI para la estimación de la ICI, además del proceso de entrenamiento de la red para seleccionar los mejores parámetros y el preprocesamiento de las imágenes que ingresan a la red para ser clasificadas según el porcentaje de traslape espectral. En la sección 5 de este mismo documento se encuentran los resultados y análisis, donde se muestra de forma detallada cada uno de los hallazgos obtenidos con las técnicas propuestas y como se compara con otras técnicas ya propuestas para abordar el mismo problema. Finalmente, en la sección 6 se concluye con los resultados más relevantes encontrados al comparar las técnicas propuestas de mitigación y estimación, así como la utilidad a la hora de implementarlas en redes elásticas/flexibles.

II. Objetivos

A. Objetivo general

- Estimar y minimizar efectos de la interferencia intercanal en sistemas Nyquist-WDM por medio de técnicas de procesamiento digital de imágenes en conjunto con aprendizaje automático para mejorar el desempeño de la transmisión en términos de la tasa de error de bit y la tasa de acierto.

B. Objetivos específicos

- Identificar técnicas basadas en aprendizaje automático ya utilizadas y promisorias para minimizar y estimar la interferencia intercanal en sistemas Nyquist-WDM.
- Adaptar un algoritmo de aprendizaje automático no supervisado que permita una mejora en la demodulación de símbolos modulados en 16-QAM.

- Proponer una técnica de estimación de la interferencia intercanal para símbolos modulados en 16-QAM usando técnicas de procesamiento digital de imágenes en conjunto con redes neuronales profundas.
- Validar el desempeño de las técnicas propuestas para minimizar y estimar los efectos de la interferencia intercanal por medio de métricas como la tasa de error de bit y la tasa de acierto.

III. Marco Teórico

A. Redes Nyquist-WDM

Un sistema WDM transmite múltiples canales de información por una misma línea de fibra óptica, teniendo cada uno de esos canales de información una longitud de onda λ_i asociada como se muestra en la figura 1 extraída de [14]. Estos sistemas poseen un transmisor y receptor por cada canal de información que se mande a través de la fibra. Además, poseen un multiplexor a cada lado que une las señales en una misma línea de fibra.

Anteriormente, los sistemas WDM usaban rejillas fijas (Fixed-Grid) con separaciones típicas entre canales de 50 GHz según el estándar de la ITU-T G.694.1. Esta técnica permitió aumentar la

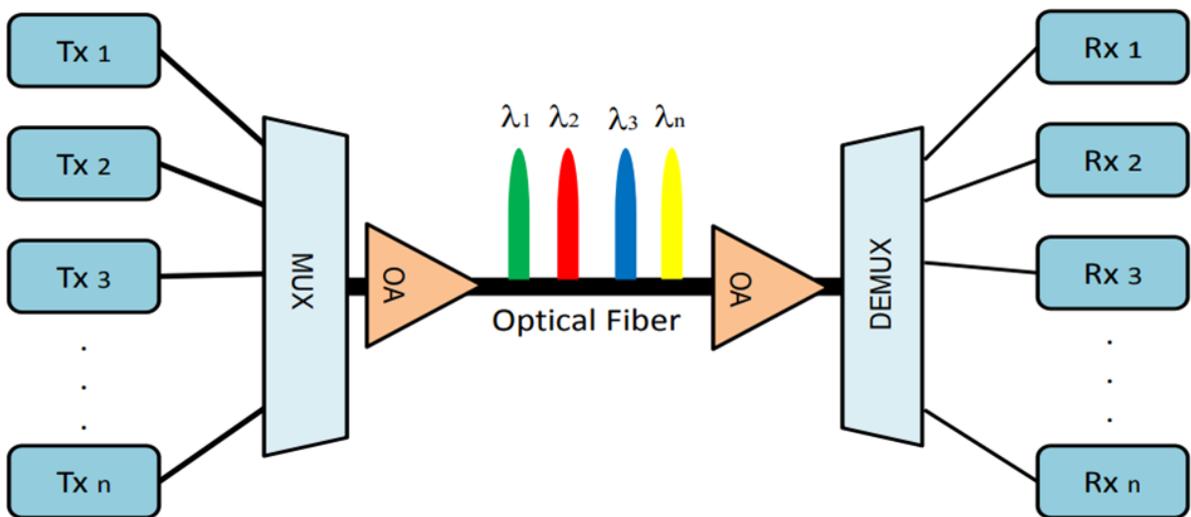


Fig. 1. Configuración de una red WDM. Tx: Transmisor. MUX: Multiplexor. RX: Receptor. OA: Amplificador óptico. λ : Longitud de onda. Extraído de [14].

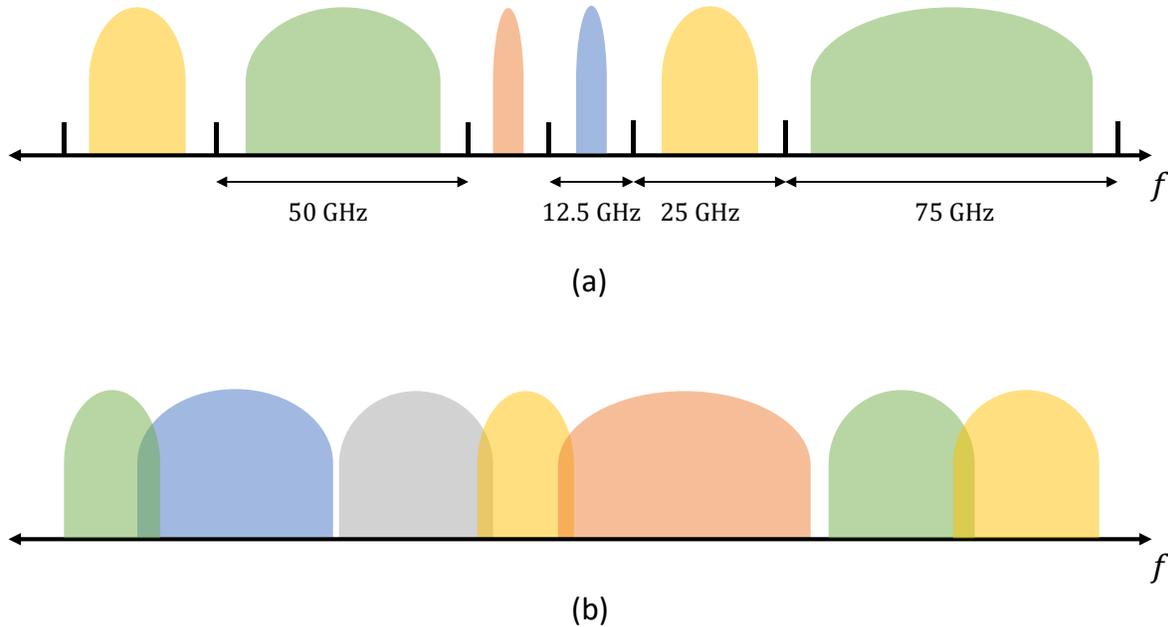


Fig. 2. Red WDM. a) red Flexi-Grid, b) red Grid-less.

capacidad de transmisión de datos en la fibra óptica. Sin embargo, se desperdiciaban muchos recursos espectrales debido a la banda de guarda, por lo que se implementaron las rejillas flexibles (Flexi-Grid). Como se muestra en la figura 2a, una red Flexi-Grid consta de canales con una separación que es múltiplo de 12.5 GHz, permitiendo aprovechar mejor el espectro que una red Fixed-Grid, por lo tanto, es posible introducir más canales a una misma línea de fibra óptica y aumentar la eficiencia espectral [12, 13].

A pesar de que las redes Flexi-Grid aportan cierto dinamismo a los sistemas WDM, es posible llevar la flexibilidad al 100% introduciendo redes sin rejilla (Grid-less) a los sistemas, como se muestra en la figura 2b. Las redes Grid-less eliminan la condición de tener espaciamientos entre canales que sean múltiplos de 12.5 GHz, permitiendo así que se tenga el ancho de banda estrictamente necesario en cada caso y así aprovechar el espectro lo mejor posible, dando como resultado una eficiencia espectral mayor que las redes Flexi-Grid. No obstante, este nivel de flexibilidad da cabida a que los canales se traslapen, introduciendo el problema de la ICI en las redes de fibra óptica.

B. Interferencia intercanal en redes de fibra óptica

La ICI es un fenómeno que ocurre en los sistemas WDM y se refiere a la interferencia no deseada entre canales adyacentes. De [15] se extrae la figura 3 y en allí se describe como en una línea de fibra óptica afectada por la ICI los canales se superponen entre sí una vez salen de los nodos fuente (S). Cuando los diferentes canales ópticos se separan para llegar a sus nodos destino (D), llegan con una parte de los canales adyacentes, por ejemplo, los canales afectados por la ICI que llegan a los nodos D1 y D3. Este fenómeno no aparece en redes Flexi-Grid como la mostrada en la figura 2a, donde los canales están cuidadosamente separados por una banda de guarda para evitar cualquier tipo de interferencia. En este caso, es importante destacar que, si bien reducir el espaciamiento entre canales aumenta la eficiencia espectral, llega un punto en el que esta estrategia comienza a degradar la calidad de las señales transmitidas. Esto no solo afecta negativamente el rendimiento de la red, sino que también puede comprometer la integridad de los datos transmitidos [2, 5].

La ICI se origina debido a varias causas subyacentes. En primer lugar, la dispersión cromática de la fibra provoca que componentes frecuenciales lleguen en tiempos diferentes al receptor, lo que conlleva a cambios no deseados en la fase inicial de la señal enviada [16]. Esto conlleva a que la

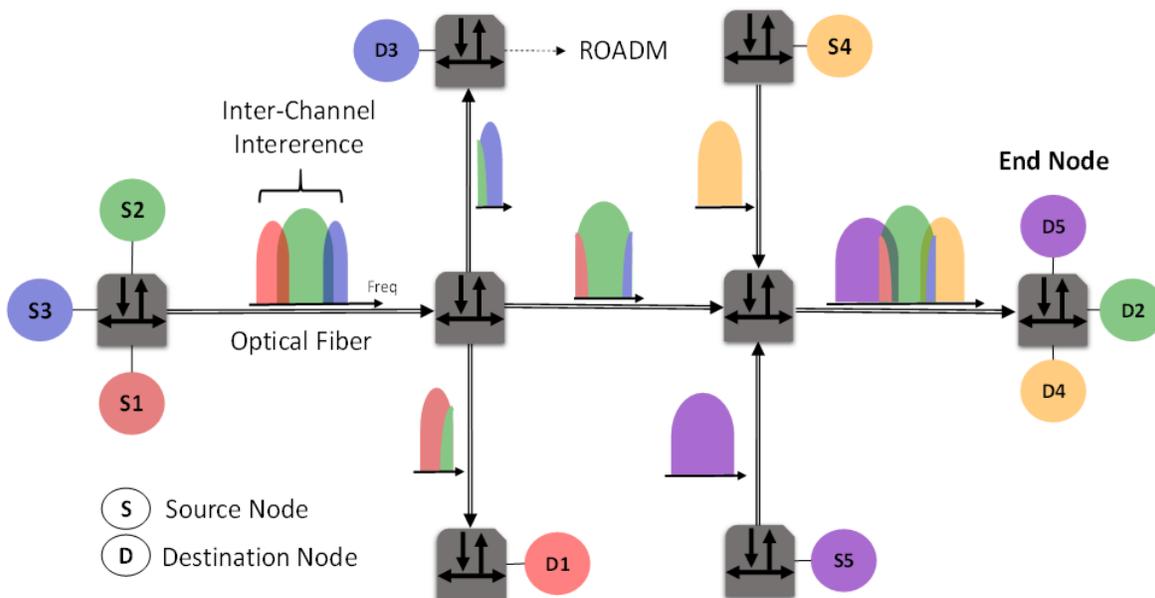


Fig. 3. Diferentes canales ópticos representados por colores, que se transmiten de un nodo fuente (S) a un nodo destino (D). Extraída de [15].

posición de los símbolos sea incorrecta al llegar al receptor, lo que genera que los símbolos recibidos se interpreten de manera incorrecta. Además, las no linealidades de la fibra a altas potencias y las fuentes de ruido como la amplificación espontánea y la dispersión estimulada también pueden contribuir a la ICI, especialmente en sistemas de fibra óptica de alta densidad de canales [17].

Los efectos de la ICI en las comunicaciones ópticas son significativos. La ICI provoca errores de bits y afecta la integridad de la información transmitida. Además, limita la capacidad de transmisión de datos en sistemas WDM dado al poco espaciado frecuencial entre las portadoras. Esto termina generando distorsiones que disminuyen notablemente la eficiencia espectral y dificulta la demodulación [2, 3].

C. Aprendizaje automático en minimización y estimación de efectos de la ICI

Los demoduladores basados en aprendizaje automático ofrecen dos ventajas principales en las transmisiones de fibra óptica, i) pueden mitigar parcialmente las no linealidades deterministas de la fibra, así como como las interacciones estocásticas no lineales de ruido de emisión espontánea amplificada (ASE) de señal no lineal. Esto permite generar regiones de decisión no simétricas como se muestra en la figura 4a. Esta región no simétrica permite demodular el símbolo que está encerrado en la circunferencia de forma correcta, a diferencia de la demodulación convencional

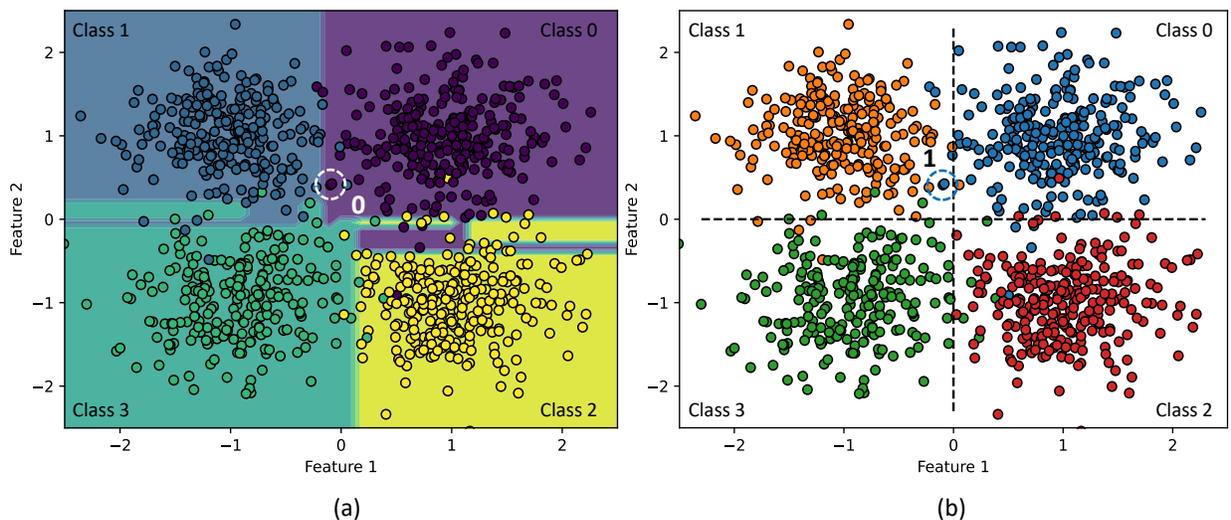


Fig. 4. Cuadrante de un diagrama de constelación 16-QAM. a) regiones de decisión no simétricas basadas en técnicas de aprendizaje automático, b) regiones de decisión simétricas de un demodulador convencional.

basada en fijar límites numéricos simétricos mostrada en la figura 4b, que finalmente, asigna la clase incorrecta al símbolo recibido, y ii) no requieren conocimiento de los parámetros del enlace óptico, lo que las convierte en una herramienta muy útil para redes de fibra óptica [1].

Técnicas de aprendizaje automático como KNN, K-Means y SVM han demostrado ser efectivas para estimar y mitigar efectos de la ICI. Por ejemplo, utilizar el algoritmo KNN en conjunto con una técnica de extracción de características basado en obtener el histograma IQ [8], o, utilizar mapas de calor para identificar patrones ocultos en las imágenes para extraer características que luego serán usadas como entrada de algún algoritmo de clasificación como KNN o SVM [9]. Además, algoritmos como Fuzzy C-Means (FCM) y Gustafson Kessel Means (GKM), basados en lógica difusa, tienen la capacidad de mitigar y estimar los efectos de la ICI mediante la asignación de grados de membresía según la distancia específica de un símbolo a los centroides de grupo. FCM utiliza la distancia euclidiana para analizar grupos de datos circulares, mientras que GKM utiliza la distancia Mahalanobis para analizar diferentes distribuciones de grupos de datos, es decir, escenarios no lineales [18].

Una vez que se ha estimado la ICI con precisión, los demoduladores basados en aprendizaje automático pueden ajustar sus operaciones o parámetros para compensar estos efectos no deseados. Esto permite una demodulación más precisa y una mejora en la calidad de la señal recibida, lo que resulta en un rendimiento de transmisión más confiable en redes de fibra óptica [10], [19].

IV. Metodología

A. Escenario experimental

Se recopiló la información de un sistema experimental 3x16 GBd 16-QAM Nyquist-WDM basado en tres láseres sintonizables con un ancho de línea de 100 KHz. El convertidor digital-análogo (DAC) funciona a 64 GSa/s con un ancho de banda de 14 GHz. Se utiliza un filtro de raíz de coseno elevado con factor de roll-off de 0.1, lo que resulta en un ancho de banda de canal de 17.6 GHz. El conjunto de datos consta de 81 escenarios, cada uno con 100,000 símbolos. Los escenarios tienen diferentes espaciamientos de canal, variando de 15 GHz a 18 GHz para obtener diferentes

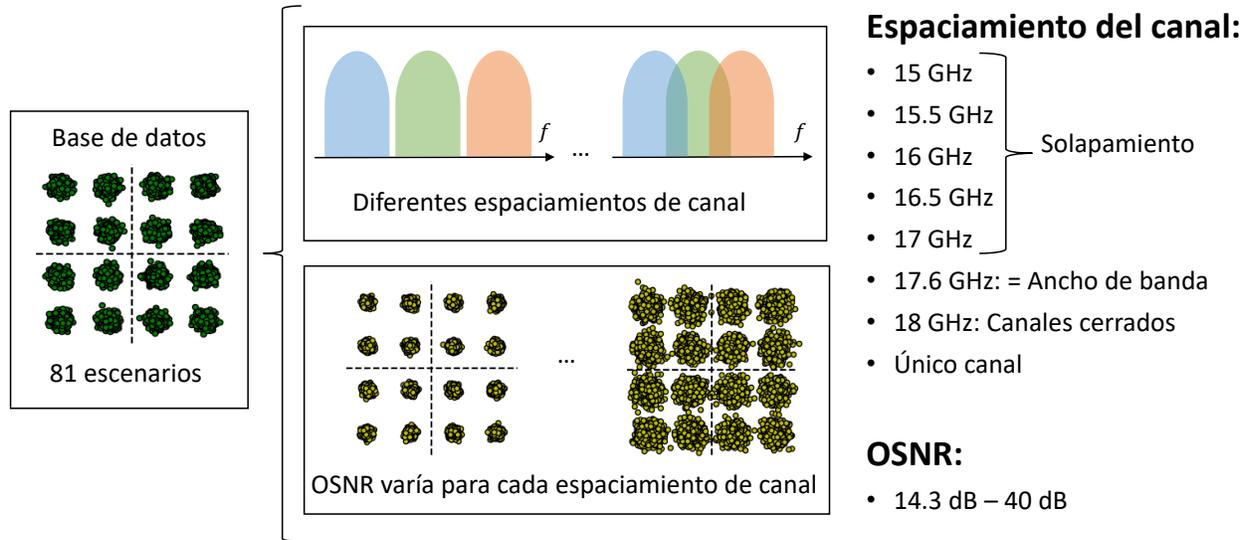


Fig. 5. Composición de la base de datos usada para la mitigación y estimación de la ICI.

porcentajes de traslape espectral: 18 GHz (canales cercanos); 17.6 GHz (0% de traslape espectral); 17 GHz (6.8% de traslape espectral), 16.5 GHz (12.5% de traslape espectral); 16 GHz (18% de traslape espectral); 15.5 GHz (24% de traslape espectral) y 15 GHz (30% de traslape espectral), incluido el caso de un solo canal, y distintos valores de relación señal a ruido óptico (OSNR) que van de 14.3 dB a 40 dB (ver fig. 5). La señal recibida se digitaliza mediante un osciloscopio en tiempo real de 80 GSa/s, donde las cuatro entradas, es decir, I y Q en polarizaciones X e Y, tienen un ancho de banda de 35 GHz cada uno, seguido del DSP fuera de línea en MATLAB®. Se optó por utilizar el BER como métrica de validación para el caso de demodulación, ya que es más relevante que la tasa de acierto al evaluar la capacidad del sistema para corregir errores, siempre que se mantenga por debajo del límite de corrección de errores hacia adelante (FEC). Se implementó la validación cruzada para asegurar la imparcialidad en los resultados de la BER. Para la estimación de la ICI se optó por usar la tasa de acierto como métrica de validación, ya que permite medir el rendimiento del modelo de aprendizaje automático para detectar el traslape espectral de canales adyacentes.

B. Demodulación basada en DBSCAN y KDTrees

Su propósito es una técnica de demodulación basada en el algoritmo de aprendizaje no supervisado DBSCAN y KDTrees. El algoritmo DBSCAN es utilizado para agrupar puntos de datos en conjuntos densos, identificando áreas de alta densidad separadas por regiones menos densas.

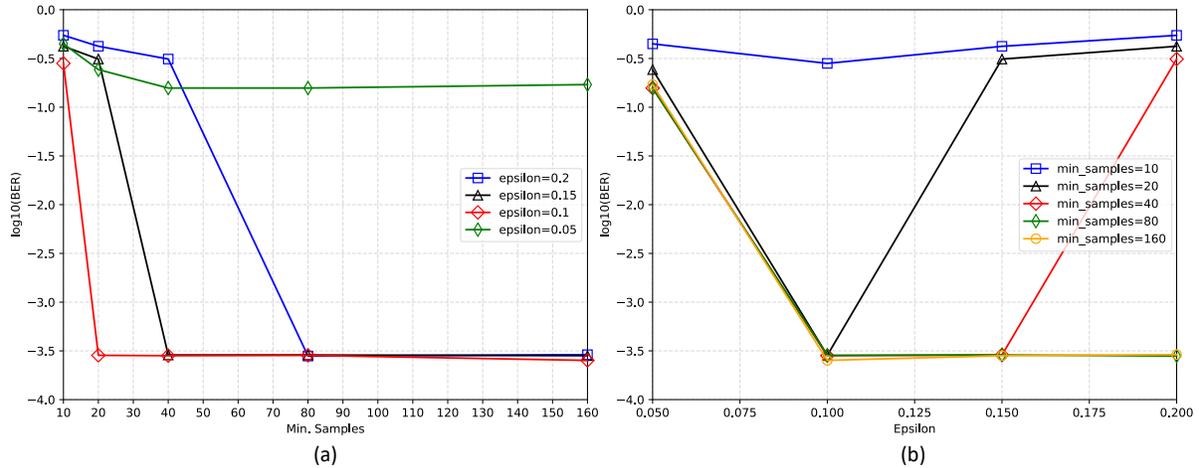


Fig. 6. Selección de los parámetros de DBSCAN. a) BER vs mínimo de muestras para diferentes valores de ϵ , b) BER vs ϵ para diferentes valores del mínimo de muestras.

Funciona definiendo un "vecindario" alrededor de cada punto y clasificando los puntos como núcleos, bordes o ruido en función de la densidad de los puntos en su vecindario. Sus dos parámetros clave son el radio ϵ , que especifica la distancia máxima para que dos puntos se consideren vecinos, y el número mínimo de puntos (MinPts) dentro del vecindario para que un punto sea considerado un núcleo. Las figuras 6a y 6b muestran la selección de los parámetros de minPts y ϵ respectivamente en un escenario de 17 GHz con 32 dB de OSNR, siendo ϵ de 0.1 y un mínimo de muestras superior a 80 muestras los valores adecuados para este conjunto de datos.

En la figura 7, se muestra como el algoritmo DBSCAN logra demodular símbolos basado en la densidad de datos. DBSCAN inicia tomando un punto arbitrario de todo el conjunto de datos y comienza la identificación de clústeres. Un nuevo clúster se forma cuando el punto seleccionado no tiene ninguna clase asignada aún y sus puntos internos tampoco tienen una clase asignada como en la figura 7a. El punto seleccionado debe contener el mínimo de muestras, que en este caso es 3, para considerarse un punto núcleo, de lo contrario, deberá esperar a estar en la vecindad de algún punto núcleo para poder identificarse con alguna clase. En este caso, el punto seleccionado inicialmente es un punto núcleo y a partir de allí comienza la formación de clústeres hasta formar un cuadrante de una constelación 16-QAM como se muestra en la figura 7b. Sin embargo, se ve que hay un punto que no logra estar en la vecindad de ninguna de las 4 clases, y tampoco logra por sí mismo cumplir con la condición del mínimo de puntos en su vecindad, por lo tanto, ese punto termina siendo clasificado como ruido. Ser clasificado como ruido depende en gran medida de la

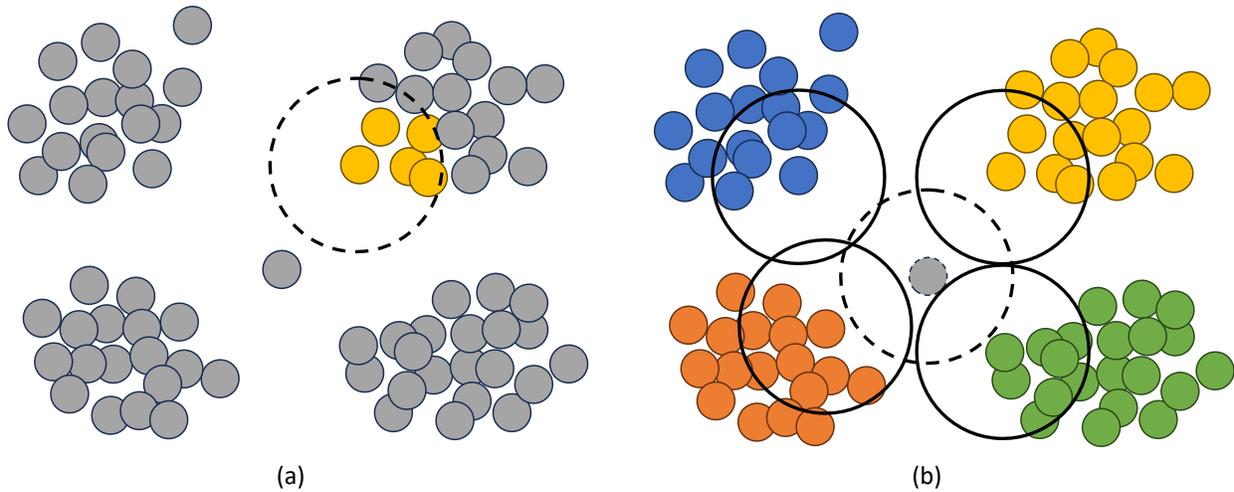


Fig. 7. Cuadrante de diagrama de constelación 16-QAM para demodular con DBSCAN con un MinPts de 3. a) Inicio de la clasificación de DBSCAN, b) generación de ruido residual.

parametrización, ya que una selección de parámetros puede clasificar correctamente los clústeres que se pretenden, puede abarcar más de lo que se quiere o directamente puede ser incapaz de encontrar grupos y dejar todo como ruido residual. Los datos que fueron clasificados como ruido deben ser tratados de alguna forma para clasificarlos ya que todos los símbolos pertenecen a uno de los 16 grupos de símbolos. Por esta razón es que se propuso usar árboles k-dimensionales para abordar el ruido residual que deja el algoritmo.

Un árbol k-dimensional es una técnica que emplea planos perpendiculares a los ejes del sistema coordinado. En este caso, la dimensión del problema es 2 ya que solo se cuenta con las características de fase y cuadratura (In-Phase, Quadrature), por lo que se debe dividir el plano usando rectas perpendiculares a los ejes ya mencionados. En las figuras 8a y 8b se muestra como un árbol 2-dimensional divide un conjunto de datos para encontrar los vecinos de un punto seleccionado. El algoritmo empieza tomando un punto arbitrario y dividiendo el plano por una coordenada igualmente arbitraria, en este caso se divide por la coordenada de fase. Luego, se toman otros dos puntos cualesquiera separados por la línea divisoria que se formó anteriormente y se divide por la otra coordenada, cuadratura, y así sucesivamente hasta tener regiones bien definidas (ver fig. 8a). Si en alguna nueva región formada no hay puntos significa que no se puede sacar una nueva rama de ese nodo particular (ver fig. 8b).

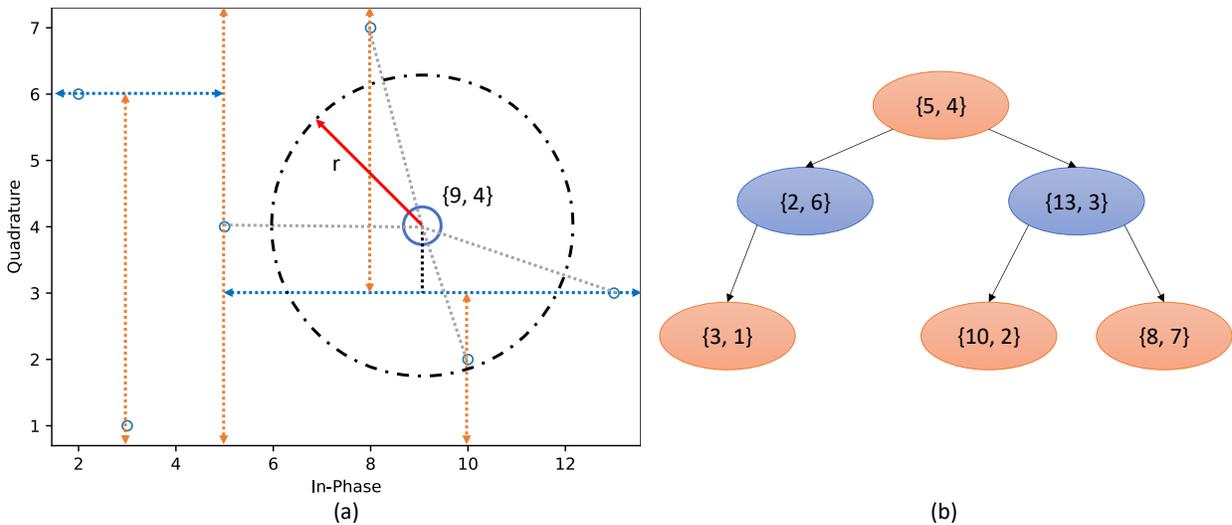


Fig. 8. Creación de un árbol k-dimensional a partir de un conjunto de datos. a) Ejemplificación gráfica de segmentación de un árbol k-dimensional y b) representación en forma de árbol de la segmentación de los datos.

Suponga que se quieren encontrar los vecinos más cercanos del punto $\{9, 4\}$ mostrado en la figura 8a en un radio r definido. Inicialmente, como se dividió por la coordenada de fase en el nodo raíz, se evalúa esa misma coordenada en el punto. Como solo hay un posible candidato a vecino en el nodo raíz, entonces se evalúa que la distancia a ese punto cumple con la condición del radio, si es así, el punto es un vecino. Ahora, en el segundo nivel se evalúa por la coordenada cuadratura y se encuentra con que $3 < 6$, por lo tanto, el punto $\{13, 3\}$ es un nuevo candidato a vecino y se debe hacer la misma evaluación del radio para saber si es vecino. Finalmente, hay un tercer nivel en el árbol y ahora se compara por la coordenada fase nuevamente, dando como resultado que $8 < 10$ y ahora el punto $\{8, 7\}$ es un nuevo candidato a vecino. No obstante, hay un punto aún más cercano que $\{13, 3\}$ que no ha sido considerado. Los árboles k-dimensionales tienen la capacidad de regresar a niveles superiores y verificar si existe la posibilidad de encontrar un vecino un más cercano que el elegido en ese nodo. En este caso, el árbol vuelve al nodo anterior y verifica la distancia que hay desde sí mismo hasta la línea divisoria más cercana en dirección a la coordenada correspondiente, en este caso cuadratura, y si resulta en una distancia más corta que la distancia al punto actual, $\{13, 3\}$, significa que hay un posible vecino más cercano. Al medir las distancias se da cuenta que efectivamente el punto $\{10, 2\}$ es más cercano que $\{13, 3\}$. Esto significa que si el punto $\{13, 3\}$ es vecino, $\{10, 2\}$ debe serlo también si o si, de lo contrario, se evalúa la condición del radio. En este caso, el punto bajo evaluación solo tiene un vecino que cumple con la condición del radio, el punto $\{10, 2\}$, y este va a determinar finalmente la clase a la que pertenece el punto.

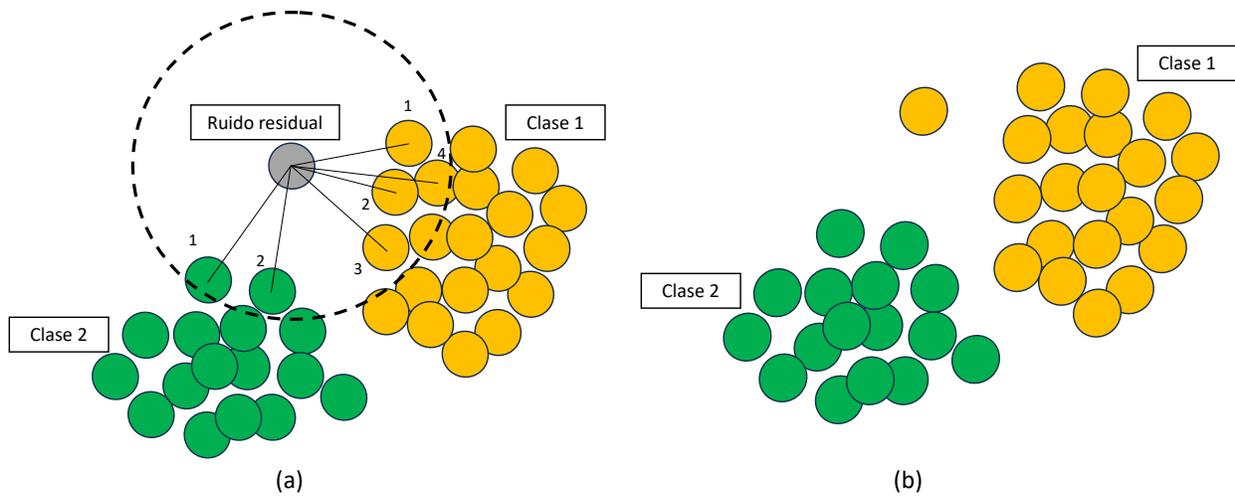


Fig. 9. Clasificación del ruido residual. a) vecinos más cercanos de cada clase, b) asignación de una clase a un punto considerado ruido por BDSCAN.

Este método permite encontrar los vecinos más cercanos de un punto en un radio definido en máximo $2N$ iteraciones, donde N es el alto del árbol. Esto reduce notablemente la complejidad y el tiempo de búsqueda de los vecinos en comparación con el método de fuerza bruta, que consta de evaluar cada uno de los puntos en la región si cumple con la condición.

Los árboles k -dimensionales permiten tratar al ruido residual del DBSCAN usando los datos clasificados del DBSCAN para construir la región o árbol que va a permitir clasificar. De esta forma, a cada punto considerado ruido se le asigna una nueva clase según sus vecinos más cercanos como se muestra en la figura 9. Suponga que ya está construido el árbol y se inició el proceso de búsqueda de vecinos. Según la figura 9a, se encontró que ese punto tiene 6 vecinos y que 4 de ellos pertenecen a la clase amarilla (clase 1) y que solo 2 pertenecen a la clase verde (clase 2), por lo que el ruido residual en este caso se va a clasificar como de la clase 1 como se muestra en la figura 9b. Según lo explicado anteriormente, la decisión se toma en base a la densidad de vecinos de una misma clase que tiene el punto en particular que se está evaluando dentro de un radio r definido.

C. Estimación de la ICI basado en técnicas de PDI y aprendizaje automático

Se propuso una técnica de estimación de la ICI basada en aprendizaje automático, más específicamente en una CNN en conjunto con técnicas de PDI para tratar los símbolos representados en un diagrama IQ como una imagen. La técnica propuesta recoge constelaciones de

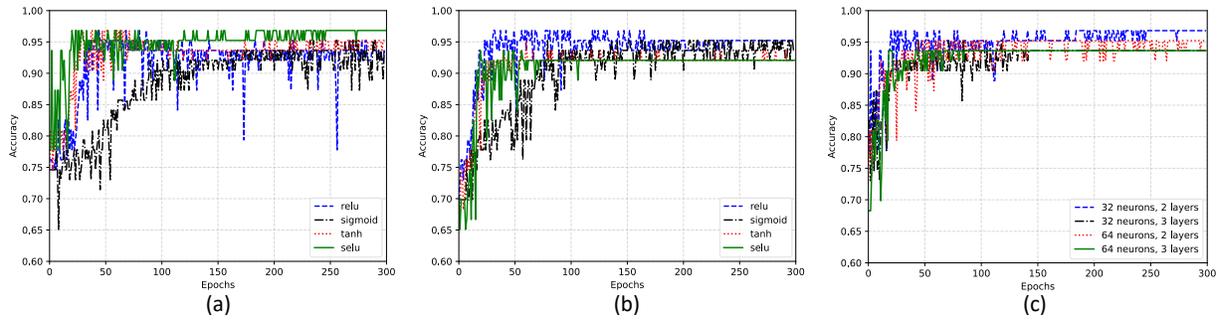


Fig. 10. Tasa de acierto vs número de épocas en un escenario con 2 clases sin considerar 17.6GHz. a) Primera capa de activación ReLU, b) primera capa de activación SeLU y c) primera capa de activación ReLU para diferentes configuraciones de la red.

datos modulados en 16-QAM y las transforma en mapas de calor que posteriormente ingresan a la CNN para ser clasificadas según el porcentaje de traslape espectral.

Una CNN está construida de neuronas que forman las llamadas capas ocultas o capas convolucionales, y las capas de salida que son capas completamente conectadas. Las capas convolucionales se encargan de extraer las características de las imágenes mientras que las capas de salida se encargan de clasificar las imágenes en base a un conjunto de datos de entrenamiento que en este caso es de ~ 800 imágenes de constelaciones con diferentes valores de espaciamiento espectral y OSNR. En la figura 10 se muestra el rendimiento de la CNN en términos de la tasa de acierto para diferentes combinaciones de funciones de activación (ver fig. 10a y 10b) en función del número de épocas. El uso de la función de activación ReLU en la primera capa oculta y SeLU en la segunda alcanza una tasa de acierto del $\sim 97\%$ para la clasificación binaria, siendo la que mejor rendimiento obtuvo en las pruebas donde se usó ReLU en la primera capa.

En la figura 11 se muestra cómo se consideran clases que se van a estimar. Para 2 clases hay la posibilidad de estar traslapado o no traslapado y el escenario de 17.6 GHz puede estar en una de las dos clases o no estar incluido. Para 3 clases se tiene algo similar pero el traslape ahora se divide en normal y mucho traslape. Para 4 clases, el traslape se divide en poco, medio y mucho traslape, además de la clase sin traslape. Para 5 clases es un caso especial donde se considera el escenario de 17.6 GHz por sí solo como una clase a parte de las demás que denota la incertidumbre entre el traslape y no traslape. Finalmente, 7 y 8 clases es cuando se toman todos los posibles espaciamientos como una clase por sí misma cuando no se toma y cuando se toma 17.6 GHz respectivamente.

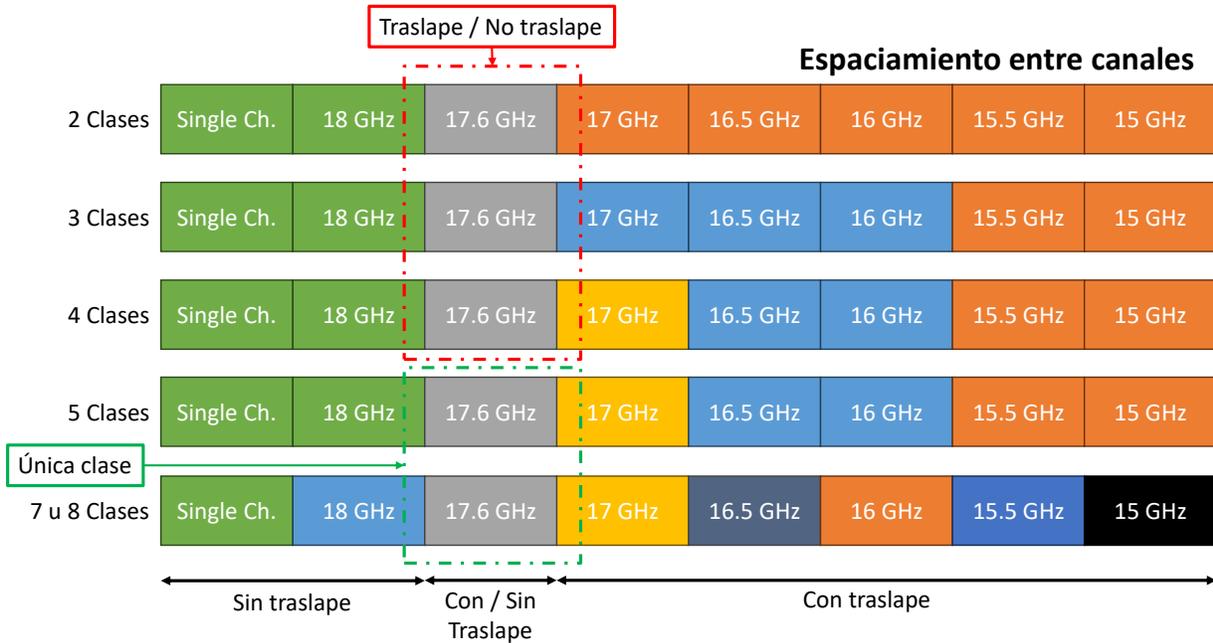


Fig. 11. Grupo de diferentes escenarios de espaciado espectral.

1. Preprocesado de la imagen

Inicialmente, se cuenta con un conjunto de 100k datos como el que se muestra en la figura 12a con fase y cuadratura. Al querer tratar el problema con imágenes, se procede a obtener el mapa de calor de 10.000 símbolos, dando un total de 10 imágenes por cada escenario y se ve como en la figura 12b. El mapa de calor muestra con detalle las zonas donde se concentran más símbolos, que es algo

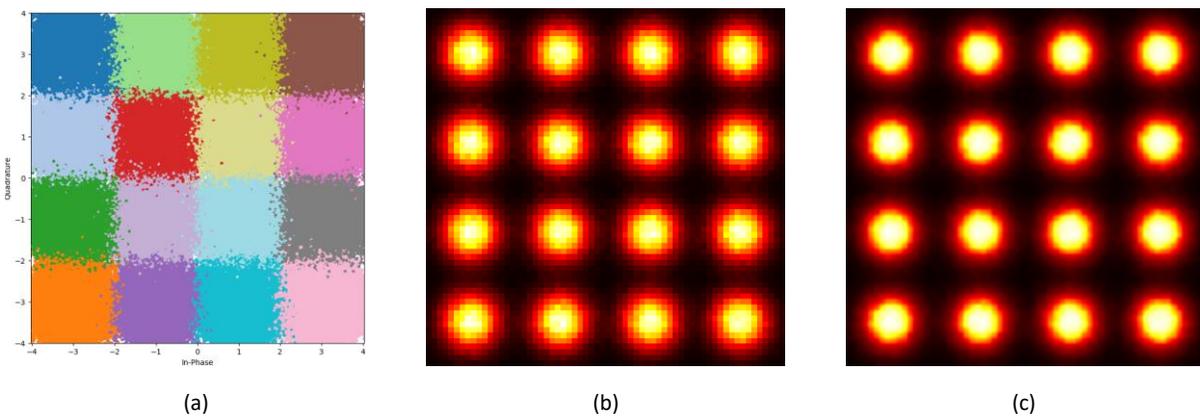


Fig. 12. Preprocesado de la imagen de constelación 16-QAM para ingresar a la CNN. a) Imagen antes del preprocesado, b) imagen de constelación 16-QAM como mapa de calor y c) imagen de calor pasado por un filtro gaussiano con ventana de 15 píxeles.

que se ignora completamente en la figura 12a. Sin embargo, la imagen aún se aprecia muy pixelada por lo que se recurre a un filtro gaussiano para eliminar el ruido gaussiano que presenta la imagen y los detalles incensarios a la hora de ingresar la imagen al modelo de aprendizaje automático (ver fig. 12c). La imagen resultante que se va a ingresar a la red es una imagen más desenfocada que el mapa de calor inicial, pero este desenfoco gaussiano permite que la red extraiga características de forma más eficiente, debido a la mitigación de ruido gaussiano y detalles adicionales que los humanos no podemos ver a simple vista. Sin embargo, el nivel de suavizado debe ser el adecuado para la imagen ya que aplicar un kernel demasiado grande puede derivar en un posible efecto halo. El efecto halo es un error asociado a la falta de información o datos suficientes sobre algo y por ende posee una elevada incertidumbre a la hora de emitir un juicio, en este caso una decisión por parte de la red.

Posterior a la etapa de preprocesamiento, las imágenes resultantes van a la capa de entrada de la CNN divididas en partes más pequeñas como se muestra en la figura 13. Cada una de las imágenes tiene asociada una clase antes de ingresar a la red. Por ejemplo, las imágenes asociadas al espaciamiento de 18 GHz y a canal único van asociadas a la clase X; mientras que los espaciamientos de 17.6 GHz y 17 GHz son de la clase Y; 16.5 GHz y 16 GHz son de clase Z; finalmente 15.5 GHz y 15 GHz son de clase W. Cada una de las imágenes pasa por el proceso de

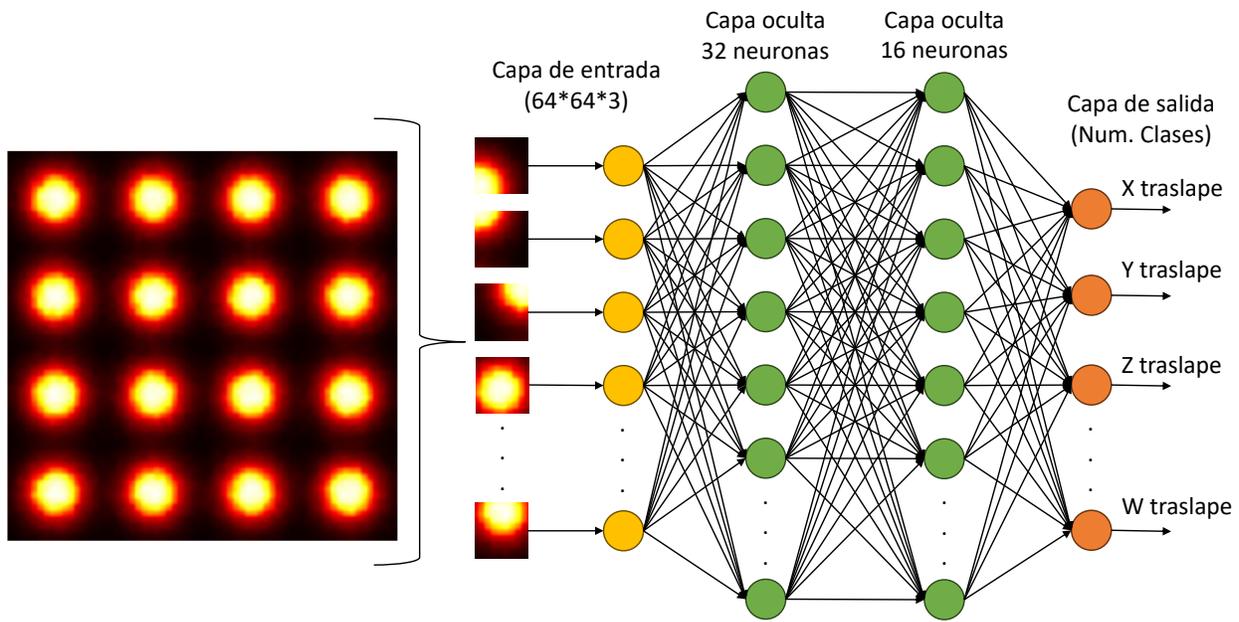


Fig. 13. Proceso de clasificación de la CNN usando constelaciones 16-QAM como mapas de calor.

ser dividida y procesada en la red y finalmente, entregar un resultado que indica la cantidad de traslape que hay en ese conjunto de símbolos recibidos en específico.

V. Resultados y Análisis

A. Mitigación de la ICI basado en DBSCAN y KDTree

Las figuras de la 14a hasta 14g muestran el rendimiento de la demodulación basada en DBSCAN con la mejora aportada por los árboles k-dimensionales en términos del BER en función del OSNR para diferentes valores de espaciamiento entre canales. El BER se calcula contando los errores con una secuencia de 100k símbolos. Además, en este trabajo se compara la demodulación basada en algoritmos como KNN, K-Means, SVM y DT probados en [4, 10, 12]. Las ganancias fueron calculadas en el valor de BER 3.8×10^{-3} que corresponde a un límite FEC. Los resultados muestran una mejoría de la ganancia en comparación a la demodulación convencional para una separación espectral grande, obteniendo ganancias por encima de ~ 1 dB para un único canal (ver fig. 14a) y ~ 1.2 dB para un espaciamiento de 17 GHz (ver fig. 14d). Por otro lado, el rendimiento en términos del BER es mejor que en las demás técnicas para valores de OSNR superiores a los 32 dB hasta 17 GHz, mientras que para espaciamientos de canal inferiores la ganancia en casi nula y el rendimiento es muy similar con respecto a la demodulación convencional (ver fig. 14e a 14g).

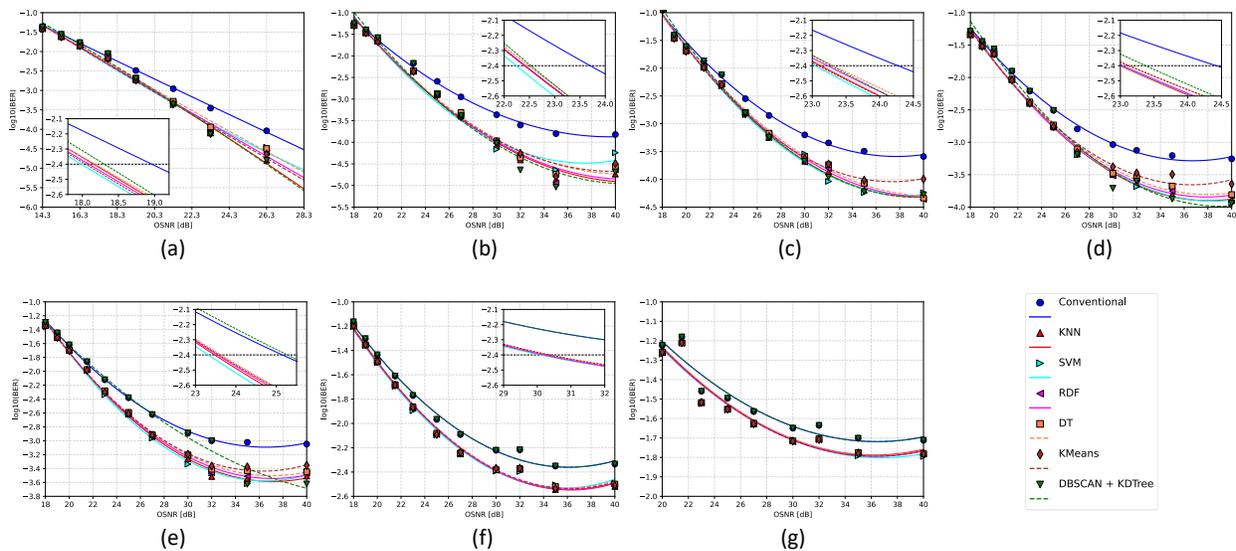


Fig. 14. BER vs OSNR para diferentes valores de espaciamiento espectral. a) canal único, b) 18 GHz, c) 17.6 GHz, d) 17 GHz, e) 16.5 GHz, f) 16 GHz y g) 15.5 GHz.

Esto significa, que para valores altos de OSNR y poco traslape entre canales, se logran minimizar los efectos de la ICI.

B. Estimación de la ICI basado en técnicas de PDI y una CNN

Las figuras 15a hasta 15c muestran el rendimiento en términos de la tasa de acierto de la red neuronal en función del número de épocas de entrenamiento para un conjunto de datos de ~ 800 imágenes, de las cuales el 90% se usó para el entrenamiento de la red. La tasa de acierto se calcula evaluando la cantidad de aciertos que tuvo la red según las etiquetas conocidas previamente de los datos de validación. Las tres etapas de entrenamiento, aunque muy similares en cuanto a la tasa de acierto, el caso donde no se considera el espaciamiento de 17.6 GHz resulta tener el mejor rendimiento con respecto a las demás (ver fig. 15a), además, el comportamiento de la función de pérdida es muy diferente para cada caso. En el caso donde no se considera el espaciamiento de 17.6 GHz la función de pérdida es la más baja de todas a medida que aumenta el número de épocas, estando por debajo de 0.2, mientras que los casos donde si se considera 17.6 GHz como no traslape y traslape llegan a valores de ~ 0.81 y ~ 0.53 , respectivamente (ver fig. 15b y 15c). Esto significa que la red neuronal entrenada sin considerar el espaciamiento de 17.6 GHz está mejor entrenada y más acertadas serán las predicciones en comparación con los otros dos casos, aunque todos logren precisiones por encima del 90%. En este caso, el número de épocas ideal para entrenar la red está entre 50 y 100 antes de que haya un sobreajuste de los datos de entrenamiento.

Por otro lado, en las figuras 16a hasta 16c muestran el rendimiento de la red en función del número de clases comparado con la red neuronal convolucional VGG16 de Google ya preentrenada. La tasa de acierto obtenida de la CNN propia es superior a la de la red VGG16 en todos los escenarios

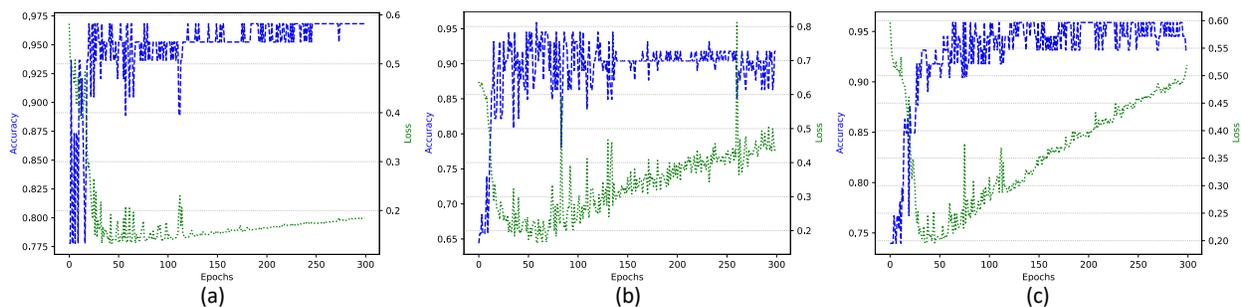


Fig. 15. Etapa de entrenamiento de la red neuronal convolucional para 2 clases. a) Sin considerar 17.6 GHz, b) 17.6 GHz tomado como un caso sin traslape y c) 17.6 GHz tomado como un caso con traslape.

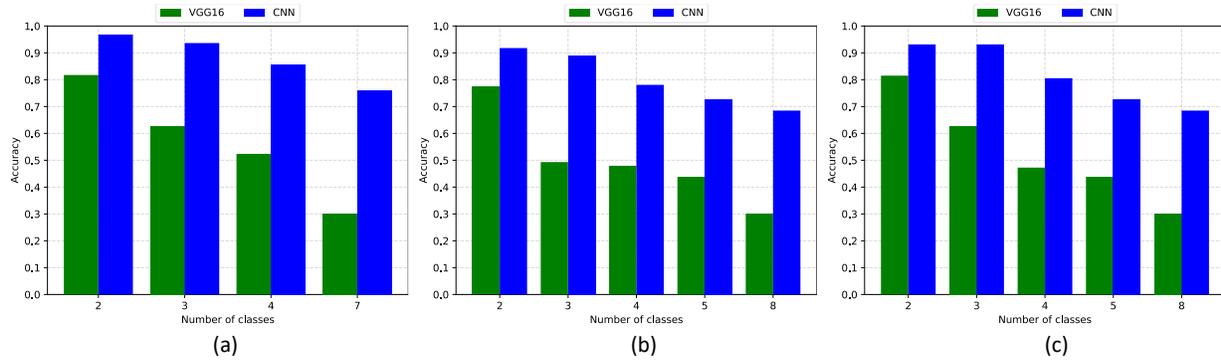


Fig. 16. Tasa de acierto de la CNN propuesta vs la red VGG16 preentrenada de Google en función del número de clases. a) Sin considerar 17.6 GHz, b) 17.6 GHz tomado como un caso sin traslape y c) 17.6 GHz tomado como un caso con traslape.

propuestos, llegando hasta $\sim 97\%$ en el caso de clasificación binaria sin considerar el espaciamiento de 17.6 GHz (ver fig. 16a), y $\sim 91\%$ en los demás casos considerando el espaciamiento de 17.6 GHz (ver fig. 16b y 16c). La tasa de acierto de ambas redes va en caída a medida que aumenta el número de clases, siendo de $\sim 76\%$ y $\sim 69\%$ para 7 y 8 clases respectivamente para la CNN propia, y de $\sim 30\%$ para VGG16, incluso siendo superior al 80% para 4 clases. Esto significa que hay una mejoría significativa en el rendimiento al considerar los parámetros adecuados para la red y que es posible estimar la ICI fiablemente.

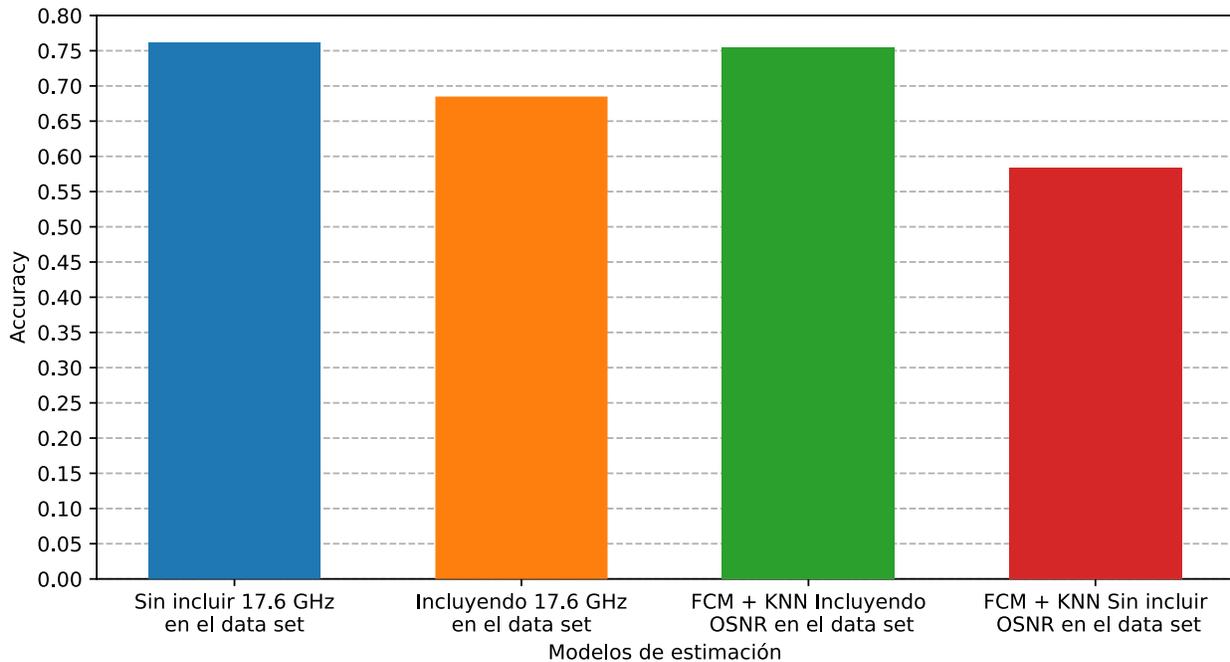


Fig. 17. Comparación de la técnica utilizada para estimar la ICI con FCM + KNN para clasificación multiclase.

Además, la técnica que se escogió en este caso se puede comparar con la técnica descrita en la referencia [11] basada en el algoritmo difuso Fuzzy C-Means + KNN para la estimación de la ICI bajo el mismo escenario experimental descrito en este documento. La figura 17 muestra el rendimiento en términos de la tasa de acierto de las técnicas basadas e en CNN y FCM + KNN para una clasificación multiclase. La técnica de FCM + KNN se evaluó considerando el espaciamiento de 17.6 GHz en la base de datos y bajo la posibilidad de incluir el OSNR como entrada, lo cual brinda más información a la hora de tomar las decisiones. Los resultados de la tasa de acierto son del ~75% y ~57% para los escenarios donde se incluyó y no se incluyó el OSNR como entrada, respectivamente. Mientras que la nueva técnica descrita en este documento basada en una CNN, sin considerar el OSNR como entrada a la red, alcanza valores por encima del 76% y 67% sin incluir e incluyendo el escenario de 17.6 GHz a la base de datos, respectivamente. Esto significa que la técnica basada en CNN tiene, en general, un mejor rendimiento en términos de la tasa de acierto para la clasificación multiclase siendo agnóstica al ruido del sistema.

Finalmente, se comparó la misma técnica de FCM + KNN, pero ahora para la clasificación binaria, o sea, el caso donde solo se obtiene si hay traslape o no hay traslape que es el caso más sencillo. En la figura 18 se muestra el rendimiento en términos de la tasa de acierto de las dos técnicas

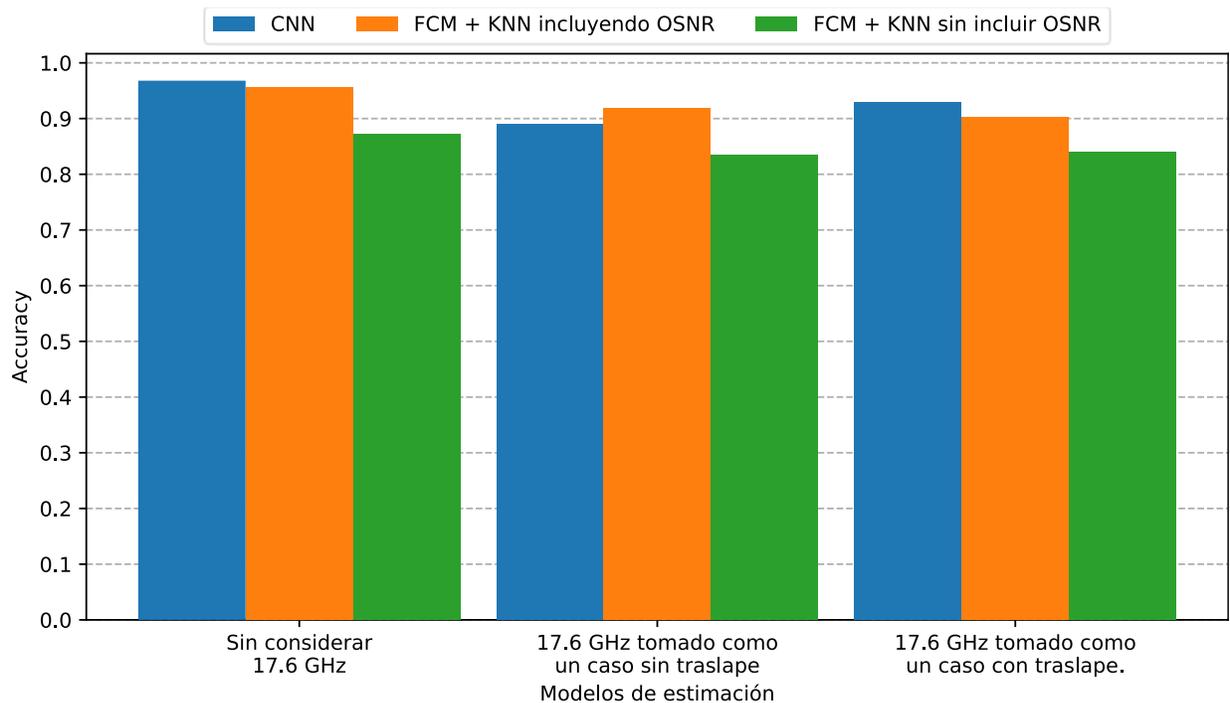


Fig. 18. Comparación de la técnica utilizada para estimación de la ICI con FCM + KNN para clasificación binaria.

mencionadas anteriormente. FCM + KNN tiene una tasa de acierto del $\sim 95.6\%$ sin incluir al espaciamiento de 17.6 GHz en la base de datos e incluyendo el OSNR a la entrada, mientras que el rendimiento baja hasta $\sim 87\%$ al no incluir el OSNR. Por otro lado, la CNN alcanza una tasa de acierto del $\sim 97\%$ sin incluir el OSNR, superando a FCM + KNN incluso cuando lo incluye. El rendimiento se reduce cuando se incluye el espaciamiento de 17.6 GHz en la base de datos, pero la tendencia se mantiene como la descrita anteriormente, excepto en el caso donde se considera 17.6 GHz como traslape, donde el algoritmo difuso supera a la CNN por $\sim 3\%$. La CNN tiene un rendimiento superior en todos los casos donde no se incluye el OSNR e incluso es mejor en 2 de 3 casos donde se incluye el OSNR. Esto significa que la técnica basada en PDI + CNN logra estimar la ICI con un rendimiento igual o superior a las técnicas ya propuestas.

VI. Conclusiones

Se propusieron dos técnicas para demodular y estimar la ICI las cuales fueron validadas experimentalmente en un sistema Nyquist WDM de 3 canales modulados en 16-QAM a 16 GBaudios. La demodulación basada en DBSCAN y KDTrees mostró mejoría en el BER en la mayoría de los casos con respecto a la demodulación convencional, obteniendo ganancias superiores a ~ 1.2 dB el límite FEC. Aunque el rendimiento de DSBCAN y KDTrees es similar en comparación con otras demodulaciones basadas en aprendizaje automático, esta técnica logra un rendimiento ligeramente superior que las demás técnicas para escenarios donde el traslape espectral es inferior al 6.8%. Esto convierte a la demodulación basada en DBSCAN y KDTrees en una opción atractiva para la demodulación en situaciones donde la disponibilidad de un conjunto de datos de entrenamiento es limitada o inexistente. Por otro lado, la técnica basada en una CNN y PDI para la estimación de la ICI logró una tasa de acierto por encima del $\sim 97\%$ clasificación binaria, o sea, para identificar si hay traslape o no entre canales adyacentes, y $\sim 76\%$ para clasificación multiclase, donde cada espaciamiento de canal descrito en la sección 2 es una clase independiente. Esta técnica logró un rendimiento promedio superior al $\sim 30\%$ con respecto a la CNN preentrenada de Google, VGG16. Además, la técnica propuesta para la estimación obtuvo mejores resultados que la técnica propuesta en la referencia [11] basada en el algoritmo de agrupamiento difuso Fuzzy C-Means más KNN para la mayoría de los casos propuestos, siendo la técnica propuesta agnóstica al nivel de ruido del sistema, mientras FCM + KNN requiere conocer el nivel del ruido del sistema para lograr

una tasa de acierto superior al 90%. Esto convierte la estimación basada en una CNN y PDI en una herramienta robusta y eficaz en la estimación de la ICI en escenarios donde se desconoce el nivel de ruido del sistema. Por lo tanto, ambas técnicas, tanto la de mitigación como la de estimación de la ICI, serían útiles de implementar en redes ópticas elásticas/flexibles. Finalmente, la complejidad computacional asociada a estas técnicas es un tema que debe explorarse a futuro.

Referencias bibliográficas

- [1] A. Amari, X. Lin, O. A. Dobre, R. Venkatesan and A. Alvarado, "A Machine Learning-Based Detection Technique for Optical Fiber Nonlinearity Mitigation," in *IEEE Photonics Technology Letters*, vol. 31, no. 8, pp. 627-630, 15 April 2019, doi: 10.1109/LPT.2019.2902973.
- [2] Y. Li and L. J. Cimini, "Interchannel interference of OFDM in mobile radio channels," *Globecom '00 - IEEE. Global Telecommunications Conference. Conference Record (Cat. No.00CH37137)*, San Francisco, CA, USA, 2000, pp. 706-710 vol.2, doi: 10.1109/GLOCOM.2000.891231.
- [3] M. Sheik-Bahae, J. Wang and E. W. Van Stryland, "Nondegenerate optical Kerr effect in semiconductors," in *IEEE Journal of Quantum Electronics*, vol. 30, no. 2, pp. 249-255, Feb. 1994, doi: 10.1109/3.283767.
- [4] J. J. G. Torres et al., "Mitigation of time-varying distortions in Nyquist-WDM systems using machine learning", *Opt. Fiber Technol.*, vol. 38, pp. 130-135, Nov. 2017.
- [5] P. Fuxjager, D. Valerio and F. Ricciato, "The myth of non-overlapping channels: interference measurements in IEEE 802.11," *2007 Fourth Annual Conference on Wireless on Demand Network Systems and Services*, Obergurgl, Austria, 2007, pp. 1-8, doi: 10.1109/WONS.2007.340486.
- [6] V. M. Guevara, H. Cordova. "Modelamiento y simulación de sistemas mimo", 2010.
- [7] X. Pan, X. Wang, B. Tian, C. Wang, H. Zhang and M. Guizani, "Machine-Learning-Aided Optical Fiber Communication System," in *IEEE Network*, vol. 35, no. 4, pp. 136-142, July/August 2021, doi: 10.1109/MNET.011.2000676.
- [8] A. E. Pérez, J. J. Granada Torres, and N. G. González, "KNN-based Demodulation in gridless Nyquist-WDM Systems affected by Interchannel Interference," in *OSA Advanced Photonics*

Congress (AP) 2019 (IPR, Networks, NOMA, SPPCom, PVLED), OSA Technical Digest (Optica Publishing Group, 2019), paper SpTh1E.3.

- [9] A. E. Pérez, O. D. V. Bonett, S. E. Ralph, and J. J. G. Torres, "Spectral spacing estimation in gridless nyquist-wdm systems using local binary patterns," in 2021 IEEE Photonics Conference (IPC). IEEE, 2021, pp. 1–2.
- [10] A. E. Pérez et al., "Training Approaches in Supervised Learning for ICI Mitigation in Gridless Nyquist-WDM", in IEEE Photonics Conference (IPC), pp. 1-2, Sep. 2020.
- [11] Alejandro Escobar Pérez, Neil Guerreiro Gonzalez, Jhon James Granada Torres, "Spectral overlapping estimation based on machine learning for gridless Nyquist-wavelength division multiplexing systems," *Opt. Eng.* 59(7) 076116 (28 July 2020) <https://doi.org/10.1117/1.OE.59.7.076116>.
- [12] Singh, M., Malhotra, J., Rajan, M. M., Dhasarathan, V., & Aly, M. H. "Performance evaluation of 6.4 Tbps dual polarization quadrature phase shift keying Nyquist-WDM superchannel FSO transmission link: Impact of different weather conditions." *Alexandria Engineering Journal*, 59(2), 977-986, 2020, doi: 10.1016/j.aej.2020.03.031.
- [13] J. Pan, C. Liu, T. Detwiler, A. J. Stark, Y. -T. Hsueh and S. E. Ralph, "Inter-Channel Crosstalk Cancellation for Nyquist-WDM Superchannel Applications", in *Journal of Lightwave Technology*, vol. 30, no. 24, pp. 3993-3999, Dec.15, 2012, doi: 10.1109/JLT.2012.2208732.
- [14] J. J. Granada-Torres, A. M. Cárdenas-Soto, y N. Guerrero-González, "Redes ópticas elásticas: un nuevo paradigma en las futuras redes de telecomunicaciones", *Respuestas*, vol. 20, n.º 2, pp. 6–22, jul. 2015.
- [15] Alejandro Escobar Pérez, David Zabala-Blanco, Cesar A. Azurdia Meza, Neil Guerrero González, and Jhon J. Granada Torres, "Training strategies to minimize interchannel interference effects using supervised learning in gridless Nyquist-WDM systems," *Appl. Opt.* 60, 8939-8948 (2021).
- [16] P. Zumba, P. Cabrera, E. Coronel, "Chromatic dispersion analysis in a WDM-PON network using FBG compensators," in *IEEE Latin America Transactions*, vol. 14, no. 6, pp. 2817-2822, June 2016, doi: 10.1109/TLA.2016.7555260.

- [17] R. -J. Essiambre, G. Kramer, P. J. Winzer, G. J. Foschini and B. Goebel, "Capacity Limits of Optical Fiber Networks," in *Journal of Lightwave Technology*, vol. 28, no. 4, pp. 662-701, Feb.15, 2010, doi: 10.1109/JLT.2009.2039464.
- [18] A. E. Pérez, N. G. González, S. E. Ralph, and J. J. Granada Torres, "Spectral Spacing Estimation using Fuzzy Logic and KNN algorithms in Gridless Nyquist-WDM Systems," in *OSA Advanced Photonics Congress 2021*, OSA Technical Digest (Optica Publishing Group, 2021), paper SpTh1D.7.
- [19] A. E. Pérez, N. G. González, and J. J. Granada Torres, "Inter-Channel Interference Estimation based on IQHistograms including Machine Learning," in *OSA Advanced Photonics Congress (AP) 2020 (IPR, NP, NOMA, Networks, PVLED, PSC, SPPCom, SOF)*, L. Caspani, A. Tauke-Pedretti, F. Leo, and B. Yang, eds., OSA Technical Digest (Optica Publishing Group, 2020), paper SpTh2I.6.