



UNIVERSIDAD DE CONCEPCIÓN
FACULTAD DE INGENIERÍA

IMPACTO DE LA INCERTIDUMBRE EN LA ESTIMACIÓN DE LA CALIDAD EN UNA LÍNEA DE TRANSMISIÓN ÓPTICA

Por: Leonardo Muñoz Rosel

Informe de Propuesta de Tesis para optar al Grado de Magíster en Ciencias
de la Ingeniería con Mención en Ingeniería Eléctrica

10 de Marzo 2026

Concepción, Chile

Profesor Guía: Dr. Gabriel Saavedra

Profesor Co-Guía: Dr. Ariel Leiva

Comisión: Dr. Sergio Torres

Comisión: Dr. Sebastián Godoy

Comisión: Dr. Álvaro Alarcón

*“I would rather have questions
that can't be answered
than answers that can't be
questioned...”¹*

Richard Feynman (1918 – 1988)

¹*Prefiero preguntas que no puedan responderse antes que respuestas que no puedan cuestionarse.*

AGRADECIMIENTOS

En primer lugar, quiero agradecer a mi polola, Francisca, quien fue mi pilar durante todo mi desarrollo académico. Gracias a ella aprendí a crecer y a creer más en mí. Agradezco profundamente todo su cariño y las largas conversaciones que me permitieron llevar a cabo muchos de los proyectos que tenía en mente y que, en un principio, me parecían imposibles.

En segundo lugar, quiero agradecer a mis padres, Eduardo y Sandra, por todo el sacrificio que realizaron desde que ingresé a la escuela hasta hoy, cuando termino esta etapa de magíster en la universidad. Gracias por nunca rendirse en mi desarrollo (que sé muy bien que fue complejo). Siempre fueron mi motor principal para llevar a cabo todos mis desafíos y mi motivación para levantarme cada día. También agradezco a mis hermanos, Valentina y Eduardo, quienes siempre me acompañaron con dosis de motivación para seguir adelante y con todo el tiempo que dedicaron para ir a buscarme al laboratorio.

En tercer lugar, agradezco a mis amigos más cercanos: Luida, Javier, Camilo, Francisco y Cristóbal. Gracias por mantener la amistad y por todos los buenos momentos que hemos compartido a lo largo de estos años. Nuestras conversaciones me han servido mucho para reflexionar sobre mi futuro. Mención honorífica a Cristóbal por ser un guía en el Laboratorio y por su voluntad de siempre buscar la perfección en cada trabajo.

En cuarto lugar, agradezco a los profesores que sembraron en mí el gusto por las telecomunicaciones. En particular, al profesor Gabriel Saavedra, por su compromiso con mi formación académica y por confiar en mí desde que me abrió las puertas del laboratorio (a pesar de que en esa época era un estudiante diferente), guiándome en decisiones importantes y fortaleciendo mi capacidad de análisis. También agradezco al profesor Sebastián Godoy, por inspirar a los estudiantes desde el primer día, promover instancias de encuentro como las “telepizzas” y por sus exigentes minitareas, que contribuyeron en la mejora en la calidad de mis trabajos. Al colega Felipe Lamas, porque en su curso de Microondas comprendí realmente lo que eran las telecomunicaciones y porque nos hizo creer que éramos capaces de lograr grandes cosas. A don Exe, por motivarme desde el primer año a mejorar, orientarme y no rendirme con los ramos. Finalmente, a don Luis, por su constante disposición para ayudar y aconsejar frente a cualquier problema.

En quinto lugar, agradezco a todas las personas con las que compartí en el laboratorio de Optoelectrónica, donde el ambiente siempre fue grato y nunca tuve ningún problema. Desde que llegué hasta ahora que me estoy por retirar, siempre me sentí en casa. Tuve la oportunidad de compartir con diferentes tipos de personas, todas dispuestas a ayudar y a colaborar.

Finalmente, agradezco al proyecto Fondecyt 123826 y a la Dirección de Postgrado, quienes financiaron mi estadía en el magíster y las conferencias a las que tuve la oportunidad de asistir.

Resumen

Esta tesis investiga el impacto de la incertidumbre operacional en el comportamiento espectral de amplificadores de fibra dopada con erbio (EDFA) y sus implicancias en la estimación de la calidad de transmisión en enlaces ópticos multitramos. Mediante un estudio paramétrico basado en un modelo de *machine learning* (MAE = 0.04), se observó que la potencia óptica de entrada modifica el espectro de salida del EDFA, determinando si el perfil de ganancia tiende a exceder o a quedar por debajo del perfil objetivo. Resultados experimentales en un enlace de 200 km muestran que variaciones en la potencia de entrada producen cambios de hasta 2.25 dB en el *gain ripple* y errores de hasta 1 dB en la estimación de OSNR cuando se utilizan estimadores basados en ganancia promedio. En un sistema multitramos de cuatro EDFAs se observaron efectos acumulativos donde la ganancia promedio disminuye aproximadamente 1.3 dB y el *gain ripple* aumenta entre 1.5 y 2 dB, provocando degradaciones de OSNR entre 1 y 3 dB dependiendo del régimen de operación. Finalmente, se evaluó la robustez de modelos de *machine learning* entrenados en escenarios de *single span* (MAE < 0.2 dB). En el régimen crítico de baja potencia, el modelo base acumuló errores de hasta 8.69 dB en el sistema multitramos, mientras que el uso de *transfer learning* (TL) redujo el error total a 2.4 dB; bajo condiciones de incertidumbre, los errores alcanzaron 9.39 dB y 5.11 dB respectivamente. Los modelos especialistas basados en TL mostraron mejoras adicionales, reduciendo el error de predicción entre un 33% en condiciones nominales y hasta un 55% en presencia de incertidumbre. Estos resultados evidencian que la incertidumbre en la potencia de entrada modifica la dinámica espectral de los EDFAs y demuestran que modelos entrenados bajo condiciones controladas pueden no generalizar adecuadamente en sistemas multitramos cuando la incertidumbre operacional altera el régimen espectral del amplificador.

Abstract

This thesis investigates the impact of operational uncertainty on the spectral behavior of erbium-doped fiber amplifiers (EDFAs) and its implications for transmission quality estimation in multi-span cascade link. Through a parametric study based on a machine learning model (MAE = 0.04), it was observed that the optical input power modifies the EDFA output spectrum, determining whether the gain profile tends to exceed or fall below the target profile. Experimental results obtained from a 200 km optical link show that variations in input power can produce changes of up to 2.25 dB in gain ripple and errors of up to 1 dB in OSNR estimation when average-gain-based estimators are used. In a multi-span system composed of four EDFAs, cumulative effects were observed where the average gain decreases by about 1.3 dB and the gain ripple increases between 1.5 and 2 dB, leading to OSNR degradations between 1 and 3 dB depending on the operating regime. Finally, the robustness of machine learning models trained in single-span scenarios (MAE < 0.2 dB) was evaluated. Under the critical low-power regime, the base model accumulated prediction errors of up to 8.69 dB in the multi-span system, while transfer learning (TL) reduced the total error to 2.4 dB; under uncertainty conditions, the errors increased to 9.39 dB and 5.11 dB respectively. Specialist models based on TL provided additional improvements, reducing prediction error by 33 % under nominal conditions and up to 55 % in the presence of uncertainty. These results show that uncertainty in the input power modifies the spectral dynamics of EDFAs and demonstrate that models trained under controlled conditions may fail to generalize in multi-span systems when operational uncertainty alters the amplifier spectral regime.

Índice general

AGRADECIMIENTOS	I
Resumen	III
Abstract	IV
1. Introducción	1
1.1. Motivación	1
1.2. Planteamiento del Problema	1
2. Estado del Arte	5
2.1. Modelos Analíticos para la Estimación de QoT	5
2.2. Modelado del EDFA	7
2.2.1. Modelos Físicos y Semi-Analíticos	7
2.2.2. Caja Negra para los EDFAs	12
2.2.3. Modelado para la Estimación de Calidad en una Red	14
2.2.4. Modelado de la Potencia de Entrada en los EDFA y su Impacto	16
2.3. Gestión de Incertidumbres	19
2.4. Discusión	20
3. Hipótesis y Objetivos	23
3.1. Hipótesis	23
3.2. Objetivos	23
4. Metodología	25
4.1. Caracterización experimental del EDFA y construcción del dataset	27
4.2. Modelo de aprendizaje automático para el análisis del <i>gain ripple</i>	32

4.2.1.	Parte 1: EDFA exploratorio	32
4.2.2.	Parte 2: Modelo de Wang y modelos especializados	34
4.3.	Caracterización experimental del rendimiento (OSNR) de un enlace óptico multi-tramo	39
4.3.1.	Parte 1: Validación experimental inicial (dos EDFAs en cascada)	39
4.3.2.	Parte 2: Evaluación multi-tramo (<i>ground truth</i> y análisis end-to-end/hop-by-hop)	42
4.4.	Análisis del impacto de la incertidumbre: metodología experimental y evaluación de modelos	47
4.4.1.	Modelado de la incertidumbre como desviación de potencia	47
4.4.2.	Protocolo de inyección y propagación de incertidumbre en la cascada	48
4.4.3.	Métricas físicas para la cuantificación del error	49
4.4.4.	Evaluación de modelos predictivos bajo propagación de error	50
4.5.	Relación metodológica con la hipótesis	53
5.	Resultados	54
5.1.	Resultados experimentales y validación	54
5.1.1.	Construcción del dataset experimental	54
5.1.2.	Entrenamiento del modelo ANN para predecir el gain ripple	57
5.1.2.1.	Parte 1: Modelo de EDFA exploratorio	57
5.1.2.2.	Parte 2: Modelo de Wang y modelos especializados	60
5.1.3.	Caracterización experimental del enlace multi-tramo	64
5.1.3.1.	Parte 1: Enlace de dos tramos (calibración y cuantificación del error espectral de OSNR)	64
5.1.3.2.	Parte 2: Enlace de cinco tramos (caracterización <i>ground truth</i> y síntesis global/evolutiva)	68
5.1.3.2.1.	<i>Ground truth</i> del enlace óptico y condiciones de evaluación:	70
5.1.3.2.2.	Ganancia espectral: perfiles medidos por carga de canales (<i>ground truth</i>).	70
5.1.3.2.3.	Convención de potencia: GUI del EDFA vs. potencia estimada por <i>peaks</i>	73
5.1.3.3.	Normalización Espectral del Span 3 (S8)	75

5.1.3.3.1.	OSNR: evolución espectral por etapa y por carga de canales.	78
5.1.3.3.2.	Piso de ruido ASE: evaluación global (<i>end-to-end</i>).	81
5.1.3.3.3.	OSNR: evaluación global (<i>end-to-end</i>).	83
5.1.3.3.4.	Ganancia: evaluación evolutiva (<i>hop-by-hop</i>).	84
5.1.3.3.5.	Piso de ruido ASE: evaluación evolutiva (<i>hop-by-hop</i>).	86
5.1.3.3.6.	OSNR: evaluación evolutiva (<i>hop-by-hop</i>).	88
5.1.4.	Análisis experimental del impacto de la incertidumbre	89
5.1.4.1.	Visualización de la propagación de incertidumbre	90
5.1.4.2.	Visualización cuantitativa: métricas físicas tramo a tramo	92
5.1.4.3.	Análisis de incertidumbre en el OSNR	94
5.1.4.4.	Evaluación de Modelos Predictivos bajo Incertidumbre	96
5.1.5.	Validación experimental de la hipótesis	99
6.	Conclusión	101

Índice de cuadros

4.3.1.Regímenes nominales de potencia total de entrada por etapa. . . .	44
5.1.1.Resumen de las métricas obtenidas para cada análisis de sensibilidad del perfil de ganancia.	59
5.1.2.Resumen experimental del gain ripple y OSNR en enlace de dos tramos.	66
5.1.3.Comparación de RMSE promedio (4 spans) para 95 canales en condición nominal y bajo incertidumbre.	99

Índice de figuras

1.2.1.	Efecto del gain ripple en sistemas en cascada.	3
1.2.2.	Arquitectura de un Controlador de Línea Óptica (OLC).	3
2.1.1.	Abstracción conceptual de la capa física utilizada por GNPY.	6
2.2.1.	Montaje experimental para la caracterización de un EDFA.	8
2.2.2.	Comparación de ganancia real vs. modelo SVD modificado.	10
2.2.3.	Perfiles de ganancia a 0 dB de <i>tilt</i>	11
2.2.4.	<i>Power Mask</i> del <i>ripple</i> en EDFAs comerciales.	13
2.2.5.	Esquema de aprendizaje para <i>cascaded learning</i>	15
2.2.6.	Variación del gain ripple bajo distintas condiciones operativas.	16
4.0.1.	Diagrama de bloques para la metodología propuesta.	26
4.1.1.	Configuración experimental para la adquisición de datos del EDFA bajo prueba.	28
4.1.2.	Perfil espectral del ruido ASE: (a) espectro continuo tras $EDFA_{BA}$ con pendiente espectral; (b) ejemplo de carga discreta (24 canales) ecualizada mediante el WSS.	29
4.1.3.	Proceso de ecualización espectral previo a la amplificación. Ambos espectros fueron capturados antes del EDFA bajo prueba.	30
4.2.1.	Arquitectura del modelo ANN empleada para el análisis de la ganancia espectral del EDFA.	32
4.2.2.	Comparación del ripple de ganancia entre amplificadores <i>Booster</i> y <i>Pre-amplifier</i> [24].	35
4.2.3.	Arquitectura del modelo ANN de referencia (Wang) para la predicción de la ganancia por canal en un EDFA [24].	36
4.2.4.	Esquema de generación/medición WDM utilizado en el trabajo de Wang para la caracterización del dataset COSMOS [24].	36
4.2.5.	Máscaras/perfiles espectrales de entrada utilizados para generar diversidad en las mediciones.	37

4.2.6.	Máscara/perfil espectral con <i>tilt</i> negativo.	38
4.3.1.	Configuración experimental del enlace óptico de dos tramos. .	40
4.3.2.	Filtro que establece la casi la misma ganancia del amplificador en la banda C	43
4.3.3.	Configuración experimental utilizada para la evaluación del enlace multispan.	43
4.3.4.	Evolución del espectro a lo largo de la cascada: (a) condición de referencia a la salida del booster ($EDFA_{BA}$), (b) tras la primera etapa ($EDFA_{S1}$), y (c) tras cuatro etapas de amplificación ($EDFA_{S4}$).	44
5.1.1.	Configuración final de medición del EDFA bajo prueba. El OSA registra el espectro de potencia de entrada ecualizado en el punto (1) y el espectro de salida amplificado en el punto (2). .	55
5.1.2.	Comparación entre el espectro de entrada y el espectro de salida del $EDFA$	55
5.1.3.	Comparación entre espectros de ganancia reales (líneas sólidas) y predichos (líneas discontinuas) para un G_{obj} fijo de 20.5 dB y distintas potencias de entrada.	57
5.1.4.	Análisis de sensibilidad del perfil de ganancia predicho frente a variaciones en (a) la ganancia objetivo, (b) la potencia total de entrada y (c) la carga espectral (número de canales). . . .	58
5.1.5.	Curva del modelo base (Wang-PA). Se presenta el error de entrenamiento (gris) y validación (azul).	60
5.1.6.	Comparación de la convergencia aleatoria (gris puntuado) y con <i>transfer learning</i> (azul continuo).	61
5.1.7.	Comparación del MAE estable por amplificador. La línea roja indica el desempeño del modelo global de Wang como referencia. .	62
5.1.8.	MAE por canal en los 95 canales WDM de la banda C. Se compara el modelo base con el promedio de los modelos especialistas.	62
5.1.9.	Perfiles de ganancia experimental en el enlace de dos tramos para distintos niveles de potencia de entrada	64
5.1.10.	Error espectral del OSNR en el enlace de dos tramos para distintos niveles de potencia de entrada	65
5.1.11.	Imagen del montaje experimental implementado en el laboratorio. .	69
5.1.12.	Potencia de salida (P_{out}) en función de la potencia de entrada (P_{in}) para los cuatro EDFAs del sistema, bajo cargas de 95 y 48 canales. La línea punteada representa la condición de ganancia unitaria ($P_{out} = P_{in}$).	70

5.1.13.	Perfil de ganancia experimental para el escenario de Carga Completa (95 Canales) . Se muestran las curvas de los cuatro amplificadores de la cascada (S1, S2, S3, S4).	71
5.1.14.	Evolución espectral de la cascada. (Izquierda) Espectros a la entrada de cada EDFA. En las leyendas se indica la potencia total integrada por el OSA (P_{Total}), la cual suma la energía de los canales y el ruido ASE. (Derecha) Espectros a la salida de cada etapa evidenciando la caída de ganancia en S_3	72
5.1.15.	Perfil de atenuación espectral por tramo.	73
5.1.16.	Evolución de la potencia de entrada estimada mediante la suma de <i>peaks</i> (P_{in}^{peaks}) a lo largo de la cascada de amplificadores para los tres regímenes nominales. Aunque la condición de potencia se fija desde la GUI del EDFA, la potencia estimada únicamente a partir de los canales WDM (señal) presenta variaciones tramo a tramo debido a la acumulación de ASE y a la redistribución espectral en la cascada.	74
5.1.17.	Variación efectiva de la potencia de entrada bajo convención <i>peaks</i> , ΔP_{in}^{peaks} , por span y régimen nominal. La línea discontinua indica la perturbación ideal de -3 dB aplicada en el primer tramo. Se observa que, aunque la perturbación se cumple en $S1$, el déficit no se conserva estrictamente en spans posteriores, evidenciando el efecto de autocompensación energética y acumulación de ASE en la cascada.	74
5.1.18.	Perfil de ganancia experimental para el escenario de Carga Completa (95 Canales) . Se muestran las curvas de los cuatro amplificadores de la cascada (S1, S2, S3, S4).	76
5.1.19.	Perfil de ganancia experimental para el escenario de Carga Media (48 Canales). Se muestran las curvas de los cuatro amplificadores de la cascada (S1, S2, S3, S4).	76
5.1.20.	Perfil de ganancia experimental para el escenario de Carga Baja (25 Canales). Se muestran las curvas de los cuatro amplificadores de la cascada (S1, S2, S3, S4).	77
5.1.21.	Evolución espectral del OSNR para la configuración de 95 canales.	78
5.1.22.	Evolución espectral del OSNR para la configuración de 48 canales.	78
5.1.23.	Evolución espectral del OSNR para la configuración de 25 canales.	79
5.1.24.	Comparativa <i>end-to-end</i> de métricas de ganancia en régimen de Baja Potencia (-24 dBm).	80
5.1.25.	Comparativa <i>end-to-end</i> de métricas de ganancia en régimen de Media Potencia (-17 dBm).	80
5.1.26.	Comparativa <i>end-to-end</i> de métricas de ganancia en régimen de Alta Potencia (-6 dBm).	80

5.1.27.	Comparativa <i>end-to-end</i> de métricas de ruido (ASE) en régimen de Baja Potencia (-24 dBm).	81
5.1.28.	Comparativa <i>end-to-end</i> de métricas de ruido (ASE) en régimen de Media Potencia (-17 dBm).	82
5.1.29.	Comparativa <i>end-to-end</i> de métricas de ruido (ASE) en régimen de Alta Potencia (-6 dBm).	82
5.1.30.	Evaluación <i>end-to-end</i> de OSNR en régimen de Baja Potencia (-24 dBm). Se muestran el OSNR promedio, la uniformidad (ripple) y la degradación neta ($S_4 - S_1$) para 95, 48 y 25 canales.	83
5.1.31.	Evaluación <i>end-to-end</i> de OSNR en régimen de Media Potencia (-17 dBm). Comparación entre la condición de entrada (S_1) y salida (S_4) del enlace para las distintas cargas espectrales. . .	83
5.1.32.	Evaluación <i>end-to-end</i> de OSNR en régimen de Saturación (-9 dBm). Se resume el efecto acumulado del enlace completo sobre el OSNR promedio, su uniformidad y la pérdida neta de calidad óptica.	84
5.1.33.	Dinámica evolutiva del Ripple de Ganancia (Hop-by-Hop) para las distintas cargas de canales.	85
5.1.34.	Evolución de la Degradación Espectral Neta (Shape Distortion) acumulada respecto a S_1	85
5.1.35.	Evolución de la Ganancia Promedio (Hop-by-Hop) a lo largo de las etapas de amplificación.	85
5.1.36.	Dinámica evolutiva de la ondulación del piso de ruido (Hop-by-Hop) para las distintas cargas de canales.	86
5.1.37.	Evolución de la Degradación de Forma del Ruido (Shape Distortion) acumulada respecto a S_1	87
5.1.38.	Evolución de la Potencia de Ruido Promedio (Hop-by-Hop) a lo largo de las etapas de amplificación.	87
5.1.39.	Evolución <i>hop-by-hop</i> del OSNR promedio en régimen de Baja Potencia (-24 dBm). Se muestra la progresión del OSNR a través de las etapas S_1 a S_4 para 95, 48 y 25 canales.	88
5.1.40.	Evolución <i>hop-by-hop</i> del OSNR promedio en régimen de Media Potencia (-17 dBm). Cada curva representa una configuración de carga espectral distinta.	88
5.1.41.	Evolución <i>hop-by-hop</i> del OSNR promedio en régimen de Saturación (-9 dBm). Se visualiza la progresión acumulativa de la pérdida de calidad óptica a lo largo de la cascada. . . .	89
5.1.42.	Evolución espectral de la ganancia bajo incertidumbre para la carga máxima de 95 canales. Curva negra: condición nominal. Curva azul: incertidumbre de -3 dB.	90

5.1.43.	Impacto de la incertidumbre de potencia en la configuración de 48 canales. Se observa una respuesta dinámica similar a la carga completa, con variaciones locales de <i>ripple</i> diferenciadas.	91
5.1.44.	Respuesta del enlace bajo incertidumbre para una carga reducida de 25 canales. En este régimen, la separación entre curvas se mantiene más estable debido a la menor saturación del medio activo.	91
5.1.45.	Evolución del Error de Potencia Total (ΔP_{Out}).	92
5.1.46.	Reacción de Ganancia promedio (<i>Gain Boost</i>) ante una caída de -3 dB en la potencia de entrada.	93
5.1.47.	Distorsión Espectral Total (RMSE) inducida por la incertidumbre de -3 dB.	93
5.1.48.	Impacto de la incertidumbre en el OSNR (95 canales). El área sombreada representa la pérdida de calidad de señal inducida por la caída de potencia de -3 dB.	94
5.1.49.	Impacto de la incertidumbre en el OSNR (48 canales). El área sombreada representa la pérdida de calidad de señal inducida por la caída de potencia de -3 dB.	95
5.1.50.	Impacto de la incertidumbre en el OSNR (25 canales). El área sombreada representa la pérdida de calidad de señal inducida por la caída de potencia de -3 dB.	95
5.1.51.	Evaluación del rendimiento general de los modelos predictivos.	97
5.1.52.	Impacto espectral de la incertidumbre predictiva (95 canales).	98
5.1.53.	Comparativa de RMSE bajo incertidumbre: Respuesta Física vs. Modelos ML.	99

Capítulo 1

Introducción

En este capítulo se presenta la relevancia de las Redes Ópticas y los desafíos que enfrentan, con énfasis en cómo la incertidumbre operacional condiciona la validez de los modelos físicos y predictivos que se evalúan en los resultados experimentales.

1.1. Motivación

El crecimiento sostenido del tráfico de información ha convertido a las redes ópticas en un pilar fundamental de la infraestructura digital. Para responder a esta demanda sin expandir continuamente la infraestructura física, resulta necesario optimizar el uso de los recursos existentes mediante una estimación precisa de la Calidad de Transmisión (QoT), comúnmente abordada a través de Modelos Analíticos de la Capa Física (APLMs) [1]. Sin embargo, en redes reales estos modelos deben operar bajo condiciones de incertidumbre operacional, donde parámetros críticos como la potencia total de entrada a los amplificadores pueden variar debido a pérdidas en conectores, empalmes, envejecimiento de componentes o cambios en la configuración de la red. Estas variaciones modifican el régimen de operación de los amplificadores ópticos y pueden introducir discrepancias entre el comportamiento real del sistema y las predicciones de los modelos utilizados para la planificación y operación de redes ópticas.

1.2. Planteamiento del Problema

La formulación base de modelos analíticos como GNPy representa los caminos de luz como canales de Ruido Blanco Aditivo Gaussiano (AWGN), resumidos en una

métrica de desempeño: la Relación Señal a Ruido Generalizado (GSNR) [2]. Esta métrica captura de forma compacta las degradaciones que sufre la señal durante su recorrido:

$$\text{GSNR} = \frac{P_{CUT}}{P_{ASE} + P_{NLI}} \cdot FP = \frac{1}{\frac{1}{\text{OSNR}} + \frac{P_{NLI}}{P_{CUT}}} \cdot FP \quad (1.2.1)$$

En esta expresión, P_{CUT} es la potencia del canal bajo prueba, P_{ASE} es el ruido de Emisión Espontánea Amplificada (ASE) generado por los amplificadores y P_{NLI} corresponde a la interferencia no lineal producida en la fibra. La relación entre estos términos define la Relación Señal a Ruido Óptico (OSNR), es decir, la razón entre potencia de señal y ruido del amplificador ($\text{OSNR} = P_{CUT}/P_{ASE}$). La segunda parte de la Ecuación 1.2.1 reorganiza el GSNR para separar el impacto de los amplificadores (término $1/\text{OSNR}$) del impacto de la fibra (término asociado a P_{NLI}). Finalmente, FP es un factor que penaliza el efecto del filtrado en la red.

La Ecuación 1.2.1 deja en claro que, para estimar correctamente el GSNR, es indispensable modelar con precisión el ruido ASE, ya que este depende directamente del comportamiento de los amplificadores ópticos y de su régimen de operación real.

El modelo estándar para el ruido ASE de un EDFA, como se describe en [3], es:

$$P_{ASE}(\lambda) = F(\lambda)[G(\lambda) - 1]hfR_s \quad (1.2.2)$$

donde $F(\lambda)$ representa la figura de ruido y $G(\lambda)$ la ganancia del amplificador, ambas dependientes de la longitud de onda. Aquí aparece una limitación central de los modelos actuales. El propio trabajo de GNPy [2] reconoce que un modelo dinámico y preciso para la ganancia $G(\lambda)$ y la figura de ruido $F(\lambda)$ “típicamente no está disponible”. En la práctica, los modelos analíticos simplifican esta situación usando aproximaciones bajo carga espectral completa y valores estáticos de fabricante.

Esta simplificación, centrada en una ganancia estática, omite el fenómeno de *gain ripple*, es decir, la respuesta dinámica del amplificador ante cambios en potencia total de entrada, ganancia de operación y carga de canales. Como se muestra en la Fig. 1.2.1, el perfil de ganancia no es estático en longitud de onda ni en operación por span, y su deformación se acumula en cascada.




Figura 1.2.1: Efecto del gain ripple: la ganancia real de un EDFA varía a lo largo del espectro y se acumula en sistemas en cascada [4].

La diferencia entre el modelo idealizado y el comportamiento real del hardware es una fuente importante de error. Este problema se intensifica en redes reales, donde la potencia total de entrada ($P_{in,total}$) —principal factor que altera el *gain ripple*— no es fija ni perfectamente conocida, sino que deriva por pérdidas en conectores, empalmes, envejecimiento de fibra y variaciones de configuración entre spans. Por ello, el reto principal no es predecir una ganancia estática, sino describir la dinámica del EDFA bajo derivas de potencia y condiciones multispán variables. Un modelo que asume ganancia constante no puede anticipar cómo estas fluctuaciones modifican el perfil de ganancia, la potencia ASE y, en consecuencia, el GSNR.

El objetivo de la automatización de redes es contar con controladores inteligentes, como el mostrado en la Fig. 1.2.2, capaces de tomar decisiones en tiempo real. Para que este bucle de control sea confiable, el gemelo digital (GNPy) que lo respalda debe ser robusto frente a incertidumbres del mundo real y su impacto acumulado en cascada. Desde esta perspectiva, el ML se evalúa como instrumento de modelado y no como sustituto del análisis físico: su aporte debe validarse cuantitativamente mediante métricas de error (como RMSE) y su estabilidad bajo perturbaciones de potencia de entrada, en coherencia con los resultados experimentales que se presentan más adelante.




Figura 1.2.2: Arquitectura de un Controlador de Línea Óptica (OLC) que utiliza GNPy como gemelo digital para la configuración de los amplificadores [2].

En este trabajo se investiga experimentalmente el comportamiento espectral de

amplificadores EDFA bajo condiciones de incertidumbre operacional, modelada como variaciones en la potencia total de entrada. A partir de un conjunto de mediciones experimentales, se analiza cómo estas variaciones modifican el perfil de ganancia espectral y el ruido ASE generado por los amplificadores, y cómo dichos efectos se propagan en sistemas ópticos en cascada. Sobre esta base, se evalúa el desempeño de modelos de aprendizaje automático entrenados bajo condiciones controladas para la predicción de la ganancia por canal, analizando su capacidad de generalización cuando se aplican a un enlace óptico multispán y particularmente bajo regímenes de operación críticos. Finalmente, los resultados permiten cuantificar el impacto de la incertidumbre operacional en la validez de estos modelos y evidenciar que modelos entrenados en condiciones nominales pueden perder capacidad predictiva cuando las variaciones de potencia modifican el régimen espectral de los amplificadores.

Capítulo 2

Estado del Arte

La estimación precisa de la Calidad de Transmisión (QoT) es un elemento central para que las redes ópticas utilicen eficientemente sus recursos. Sin embargo, su predicción no es directa, principalmente porque el comportamiento físico de los Amplificadores de Fibra Dopada con Erbio (EDFAs) presenta fenómenos complejos, entre ellos el característico *gain ripple*. A esto se suma la incertidumbre asociada a los parámetros físicos de la red, como pérdidas, potencias o configuraciones espectrales.

Este capítulo revisa las principales estrategias de modelado que se han propuesto para abordar este problema, comenzando por los enfoques analíticos clásicos, pasando por modelos físicos y semi-analíticos de EDFAs, hasta llegar a metodologías basadas en Machine Learning (ML) y enfoques híbridos que combinan conocimiento físico con aprendizaje a partir de datos.

2.1. Modelos Analíticos para la Estimación de QoT

La planificación de redes ópticas se ha apoyado históricamente en los llamados Modelos Analíticos de la Capa Física (APLMs). Dentro de este grupo, el enfoque más adoptado en la industria es el Modelo de Ruido Gaussiano (GN), cuya implementación se encuentra en la herramienta de código abierto GNPY [2].

Estos modelos representan la red óptica mediante una abstracción de tipo grafo, donde cada elemento del sistema —fibras, amplificadores y ROADMs— contribuye progresivamente a la degradación de la señal. Este concepto se ilustra en la Fig. 2.1.1. El objetivo final es estimar una métrica global de desempeño, el GSNR, que integra los efectos del ruido de emisión espontánea amplificada (ASE) y de

las interferencias no lineales (NLI), como se expresa en la Ecuación 1.2.1.

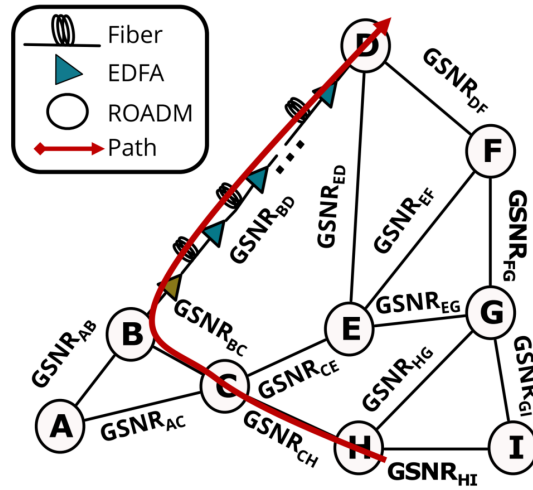


Figura 2.1.1: Abstracción conceptual de la capa física utilizada por modelos analíticos como GNP_y [5].

La literatura ha demostrado la utilidad de este enfoque en diferentes contextos experimentales, posicionando a GNP_y como un *digital twin* agnóstico de proveedor [2]. En validaciones realizadas en entornos de laboratorio multi-vendor y con tecnologías flex-grid, se han reportado errores medios absolutos (MAE) inferiores a 0,5 dB [6].

No obstante, estos resultados también revelan una limitación importante: la precisión del modelo depende fuertemente de conocer con exactitud los parámetros físicos de la red. En otras palabras, el rendimiento del modelo está condicionado por la calidad de la información disponible. El trabajo presentado en [5] ilustra claramente esta situación. Aunque se reporta que cerca del 90 % de las predicciones se mantienen dentro de un margen de ± 1 dB y que el 95 % de ellas son conservadoras, también se identifican errores atípicos que no provienen del modelo de propagación, sino de discrepancias en los componentes reales del sistema.

En uno de los casos analizados, se observó un error no conservador de $-1,15$ dB, el cual fue atribuido al comportamiento inesperado de un transceiver que no coincidía con su caracterización nominal. Este ejemplo pone de manifiesto una debilidad inherente de los enfoques puramente analíticos: incluso cuando el modelo físico es correcto, pequeñas desviaciones en los dispositivos reales pueden traducirse en errores significativos en la estimación de QoT.

Con el objetivo de reducir estas discrepancias, se han propuesto metodologías que combinan modelos analíticos con mediciones experimentales. Por ejemplo, el uso

conjunto de mediciones de amplificadores y Monitores de Canal Óptico (OCM) ha permitido mejorar la precisión de las estimaciones, reduciendo la desviación estándar del error hasta valores cercanos a 0,2377 dB [7, 8]. Estas estrategias no eliminan la incertidumbre inherente del sistema, pero permiten controlarla mediante procesos de calibración continua.

A pesar de estas mejoras, la fuerte dependencia de parámetros de entrada precisos sigue siendo una limitación estructural. En redes reales, dichos parámetros pueden variar debido a múltiples factores operacionales. Además, los modelos analíticos presentan dificultades adicionales para caracterizar con precisión el comportamiento de los EDFAs bajo cargas espectrales variables, lo que introduce una nueva fuente de incertidumbre. Esta limitación ha motivado el desarrollo de enfoques alternativos basados en Machine Learning.

2.2. Modelado del EDFA

Una de las principales limitaciones de los modelos analíticos de sistema radica en la forma simplificada en que representan el comportamiento del amplificador óptico. Dado que el EDFA es un elemento crítico en la degradación de la señal, su modelado preciso resulta fundamental para mejorar la estimación de QoT. Por esta razón, gran parte de la investigación reciente se ha enfocado en desarrollar modelos más detallados a nivel de componente.

2.2.1. Modelos Físicos y Semi-Analíticos

Los primeros intentos por modelar EDFAs se basaron en descripciones puramente físicas del dispositivo. Los trabajos pioneros de Saleh y Giles [9, 10] establecieron las bases al proponer un conjunto de ecuaciones diferenciales que describen la interacción entre la señal óptica y los iones de erbio presentes en la fibra dopada.

En este marco, la evolución de la potencia de cada canal óptico $P_k(z)$ a lo largo del amplificador puede expresarse mediante la ecuación de propagación:

$$\frac{dP_k}{dz} = u_k(\alpha_k + g_k^*)N_2P_k(z) - u_k(\alpha_k + l_k)P_k \quad (2.2.1)$$

donde la ganancia depende directamente de la inversión de población N_2 y de los coeficientes de absorción y emisión asociados al erbio [10]. Aunque este enfoque proporciona una descripción física detallada del amplificador, su aplicación práctica

resulta compleja, ya que requiere conocer parámetros internos que no suelen estar disponibles en equipos comerciales.

Para superar esta limitación, la investigación evolucionó hacia modelos semi-analíticos, que combinan principios físicos con calibración basada en mediciones experimentales. En estos modelos, los parámetros desconocidos se estiman a partir de datos obtenidos en laboratorio, permitiendo construir representaciones más manejables del comportamiento del amplificador.

Un ejemplo representativo es el modelo basado en potencia equivalente propuesto en [11], que utiliza el principio de ganancia introducido por Saleh [9]. En este enfoque, un espectro de entrada arbitrario se transforma en una potencia plana equivalente $P_{in,eq}$ que produce una respuesta similar en el amplificador. Esta corrección se calcula mediante:

$$\Delta P_{in,eq} = \frac{\sum_{i=1}^{N_{ch}} \lambda_i \Delta P_i (G_i(x) - 1)}{\sum_{i=1}^{N_{ch}} \lambda_i (G_i(x) - 1)} \quad (2.2.2)$$

Este enfoque requiere realizar múltiples mediciones bajo condiciones controladas para construir una tabla de consulta (*Look-Up Table, LUT*) que capture la respuesta del amplificador en distintos puntos de operación. Una vez generada esta base de datos experimental, y aplicando la Ecuación 2.2.2, el modelo puede predecir la ganancia frente a diferentes espectros de entrada con alta precisión, alcanzando un Error Cuadrático Medio (RMSE) cercano a 0,05 dB a nivel de componente. La Fig. 2.2.1 ilustra un ejemplo del montaje experimental utilizado para la obtención de estas mediciones, donde la calidad y cobertura de los datos de caracterización resultan determinantes para lograr predicciones confiables.




Figura 2.2.1: Montaje experimental representativo para la caracterización de un EDFA utilizado en la generación de datos experimentales para construir tablas de consulta [11].

Si bien los modelos semi-analíticos representan un avance significativo respecto a los enfoques puramente físicos, diversos trabajos han mostrado que su precisión depende fuertemente del nivel de detalle y del rango operativo cubierto por los datos

experimentales utilizados durante la caracterización. En consecuencia, cuando las condiciones reales de operación se alejan de aquellas consideradas durante el proceso de medición, la capacidad de generalización del modelo puede verse limitada. Esta observación ha motivado el desarrollo de variantes más sofisticadas, diseñadas para capturar comportamientos del amplificador que los enfoques más simples suelen pasar por alto.

Uno de estos enfoques propone descomponer matemáticamente la física del amplificador en sus componentes fundamentales. Inspirado en el modelo de dos estados de los iones de erbio, este método utiliza la Descomposición en Valores Singulares (SVD) para extraer, a partir de un conjunto relativamente reducido de mediciones experimentales, dos elementos clave: por un lado, los vectores asociados a las poblaciones iónicas dependientes del punto de operación, y por otro, los vectores que representan las secciones eficaces de absorción y emisión características del dispositivo. Bajo esta formulación, la ganancia espectral del EDFA puede describirse mediante la Ecuación 2.2.3 [12].

$$G_{dB}(\lambda) = \bar{N}_2 \cdot \sigma_s^e(\lambda) - \bar{N}_1 \cdot \sigma_s^a(\lambda), \quad (2.2.3)$$

donde \bar{N}_2 y \bar{N}_1 representan las poblaciones medias de iones de erbio en el estado excitado y en el estado fundamental, respectivamente, las cuales dependen del punto de operación del amplificador. Por su parte, $\sigma_{se}(\lambda)$ y $\sigma_{sa}(\lambda)$ corresponden a las secciones eficaces de emisión y absorción del medio activo [12].

Este modelo basado en SVD fue diseñado específicamente para abordar condiciones operativas complejas, como la carga parcial de canales en sistemas WDM. Para ello, incorpora una fórmula de corrección que ajusta las desviaciones de ganancia en función de la posición y el ancho espectral de los canales inactivos. Los resultados experimentales muestran que este enfoque modificado mejora significativamente la precisión respecto a modelos analíticos más simples. Además, presenta una alta eficiencia en el uso de datos: alcanza un RMSE de 0,1102 dB utilizando únicamente 3150 mediciones experimentales, superando ampliamente a modelos previos que requerían conjuntos de datos de hasta 50000 muestras.




Figura 2.2.2: Comparación entre la ganancia medida y la predicción obtenida con el modelo SVD modificado. La figura evidencia la alta precisión del modelo bajo condiciones de carga parcial de canales [12].

Otro marco semi-analítico aborda el problema desde una perspectiva diferente, al descomponer explícitamente el perfil espectral de ganancia en componentes con interpretación física. En este enfoque, el *gain ripple* se modela como una combinación lineal entre una huella característica del proceso de fabricación del amplificador, independiente del parámetro de inclinación (*tilt*), y un término adicional que varía de forma aproximadamente lineal con dicho parámetro [13]. Bajo esta formulación, es posible caracterizar el comportamiento del amplificador utilizando únicamente dos mediciones experimentales. La Ecuación 2.2.4 describe esta descomposición del perfil de ganancia.

$$g(f; G, T) = G + \frac{T}{B}(f - f_c) + [r_0(f) + T \cdot K(f)], \quad (2.2.4)$$

donde $g(f; G, T)$ representa el perfil de ganancia total del EDFA en función de la frecuencia f . El parámetro G corresponde a la ganancia objetivo configurada en el amplificador, mientras que T representa la inclinación (*tilt*) objetivo. El término $r_0(f)$ describe el perfil de *ripple* medido con un *tilt* de 0 dB, el cual actúa como una huella propia del proceso de fabricación del dispositivo. Por su parte, $K(f)$ es una función independiente del *tilt* que describe cómo escala el *ripple* a medida que varía el valor de T .

La validación experimental de este modelo, realizada sobre 14 dispositivos distintos, mostró errores inferiores a 0,2 dB dentro de la banda C. La Fig. 2.2.3 ilustra que el perfil de ganancia no constituye un *ripple* universal para todos los amplificadores,

incluso cuando pertenecen al mismo modelo comercial. En otras palabras, cada EDFA presenta una firma espectral propia, lo que introduce una fuente adicional de variabilidad en el modelado del amplificador.

No obstante, la misma figura revela un resultado interesante: aunque la huella de fabricación $r_0(f)$ varía entre dispositivos, la función asociada al parámetro de inclinación $K(f)$ muestra una fuerte similitud entre amplificadores del mismo modelo. Este hallazgo sugiere que, para caracterizar un nuevo EDFA de una familia previamente estudiada, basta con medir su perfil $r_0(f)$ y reutilizar el perfil $K(f)$ ya identificado para ese modelo. De este modo, el proceso de caracterización puede realizarse de manera considerablemente más rápida.




Figura 2.2.3: Perfiles de ganancia medidos a 0 dB de *tilt* para distintos amplificadores, junto con las funciones $r_0(f)$ y $K(f)$ utilizadas en el modelo [13].

Incluso en la estimación del ruido, otro factor crítico en la determinación de la QoT, se han reportado avances relevantes. Un trabajo reciente propuso una extensión del modelo semi-analítico de Saleh, denominada *piecewise Extended Saleh Model* (piecewise ESM), en la cual la fibra dopada se segmenta en múltiples secciones para capturar con mayor precisión la generación de ruido de emisión espontánea amplificada (ASE). Esta estrategia reduce el error máximo en la estimación del ASE desde aproximadamente $2,6 \text{ dB}$ hasta apenas $0,2 \text{ dB}$. Además, al mejorar la precisión del modelo, se abre la posibilidad de optimizar la eficiencia energética en enlaces de larga distancia, logrando incrementos de hasta un 26% en escenarios de transmisión transpacífica en comparación con el ESM convencional [14].

En conjunto, estos desarrollos muestran que la precisión del modelado del EDFA

no depende únicamente del tipo de enfoque adoptado —físico o semi-analítico— sino también de la capacidad del modelo para capturar las particularidades del comportamiento real del amplificador. En particular, fenómenos como el *gain ripple*, la saturación y la variabilidad entre dispositivos introducen complejidades adicionales que deben ser consideradas para mejorar la fiabilidad de las estimaciones de QoT.

2.2.2. Caja Negra para los EDFAs

A diferencia de los modelos basados en la física interna del amplificador, que requieren parámetros difíciles de obtener en equipos comerciales, los enfoques de caja negra (*black-box*) proponen una alternativa más pragmática [15]. En lugar de describir explícitamente los procesos físicos del EDFA, estos modelos tratan al amplificador como un sistema cuya dinámica interna es desconocida o irrelevante, enfocándose únicamente en aprender la relación entre sus entradas y salidas a partir de datos experimentales.

Este cambio de perspectiva resulta especialmente atractivo en entornos operacionales reales, donde fenómenos complejos como el *spectral hole burning* (SHB), las variaciones de fabricación entre dispositivos o las dependencias no lineales entre canales pueden ser difíciles de representar mediante modelos analíticos. Al aprender directamente del comportamiento observado, los modelos de caja negra pueden capturar estos efectos de manera implícita, alcanzando altos niveles de precisión siempre que se disponga de datos de caracterización suficientes [16].

Un ejemplo representativo de este enfoque es el modelo *Power Mask*. En lugar de recurrir a ecuaciones físicas para describir el comportamiento del EDFA, esta metodología construye un mapa empírico de su respuesta a partir de mediciones experimentales. Como se ilustra en la Fig. 2.2.4, cada punto del mapa representa una combinación específica de potencia de entrada y potencia de salida, mientras que el color asociado indica el nivel de *gain ripple* observado en ese punto operativo. De esta forma, el modelo captura directamente el comportamiento real del amplificador bajo distintas condiciones de operación [17].




Figura 2.2.4: *Power Mask* que representan el *ripple* de cada EDFA comerciales [17].

Las metodologías de caja negra abarcan un espectro amplio de técnicas, que van desde interpolación numérica hasta modelos avanzados de aprendizaje profundo. En el caso del *Power Mask Model* (PMM), el procedimiento consiste en caracterizar experimentalmente el amplificador y almacenar sus respuestas —como espectros de salida o figuras de ruido— en tablas de consulta. Posteriormente, algoritmos de interpolación permiten estimar el comportamiento del dispositivo frente a nuevas condiciones de entrada.

En paralelo, las técnicas de Machine Learning han ganado protagonismo en el modelado de EDFAs. Las Redes Neuronales Artificiales (ANN), particularmente los Perceptrones Multicapa (MLP), han demostrado una notable capacidad para capturar no linealidades complejas del sistema. Distintas arquitecturas han sido exploradas en la literatura, incluyendo subredes especializadas por canal o redes convolucionales unidimensionales (1D-CNN) diseñadas para extraer características locales del espectro óptico [18]. Otra alternativa relevante es la Regresión mediante Procesos Gaussianos (GPR), que en lugar de entregar una predicción puntual produce una distribución de probabilidad, permitiendo además cuantificar la incertidumbre asociada a la estimación [17].

La precisión alcanzada por estos modelos depende tanto de la metodología empleada como de la disponibilidad de datos de caracterización. En comparaciones experimentales directas, el PMM ha demostrado mejoras significativas frente a modelos simplificados. Por ejemplo, en un enlace de un solo tramo se reportó un error máximo de 2,85 dB, frente a 4,61 dB obtenido con el modelo GNPpy basado en DGT. En configuraciones de red más extensas, la discrepancia puede amplificarse considerablemente, alcanzando diferencias cercanas a 13 dB tras cuatro amplificadores en cascada [17].

En términos de precisión a nivel de componente, los enfoques basados en

aprendizaje profundo suelen ofrecer los mejores resultados. Tanto arquitecturas MLP como redes 1D-CNN han alcanzado errores del orden de $0,07 \text{ dB}$ en RMSE [18]. Por su parte, la GPR destaca por su eficiencia en escenarios con disponibilidad limitada de datos: se ha reportado un MAE cercano a $0,1 \text{ dB}$ utilizando apenas 30 muestras de entrenamiento [17], mientras que redes neuronales profundas pueden requerir del orden de 3000 mediciones para lograr errores comparables. En la práctica, sin embargo, las ANN continúan siendo las más utilizadas en este contexto, con conjuntos de entrenamiento que suelen oscilar entre 5000 y 50000 mediciones para alcanzar altos niveles de precisión [19].

2.2.3. Modelado para la Estimación de Calidad en una Red

Si bien el modelado a nivel de componente ha avanzado considerablemente, el desafío fundamental consiste en trasladar estas mejoras al nivel de red, donde la interacción entre múltiples amplificadores, fibras y dispositivos introduce nuevas fuentes de incertidumbre en la estimación de la QoT. En este contexto, la investigación reciente ha evolucionado hacia enfoques híbridos que combinan modelos analíticos tradicionales con técnicas de aprendizaje automático.

El objetivo de estos enfoques es preservar la interpretabilidad y el fundamento físico de modelos como el GN, mientras se incorporan mecanismos de aprendizaje capaces de corregir discrepancias entre el modelo y la operación real de la red. Un ejemplo influyente de esta estrategia fue propuesto en [20], donde se incorporó un proceso iterativo de aprendizaje dentro del modelo GN mediante un algoritmo de descenso de gradiente. A partir de mediciones reales de SNR y potencia de salida de amplificadores a lo largo de la red, el modelo ajusta progresivamente sus parámetros hasta reproducir el comportamiento observado. En simulaciones, este enfoque permitió reducir el error de predicción del SNR desde aproximadamente 1 dB hasta valores cercanos a $0,1 \text{ dB}$.

En una línea similar, el trabajo presentado en [21] exploró la compensación específica del *gain ripple* mediante un esquema híbrido que combina mediciones provenientes de monitores ópticos con un modelo de *Support Vector Regression*. En este caso, el algoritmo aprende la penalización que introduce el *ripple* en cada conexión óptica y la aplica de manera predictiva a nuevas demandas de tráfico. Este mecanismo permitió reducir los márgenes de diseño asociados al OSNR en más de un 90%, acercando las estimaciones del modelo a los valores observados en operación real.

Paralelamente, otros trabajos han propuesto modelos de EDFA completamente diferenciables, diseñados para integrarse directamente dentro de simuladores de red basados en aprendizaje automático. En [22], por ejemplo, se demostró que una red neuronal de baja complejidad entrenada con datos experimentales puede generalizar su comportamiento a múltiples amplificadores del mismo fabricante con errores inferiores a $0,05 \text{ dB}$. Además, al optimizar el perfil de potencia de entrada con el objetivo de obtener una SNR recibida más uniforme, se logró mejorar la SNR mínima de un sistema experimental de tres tramos en hasta 8 dB respecto a configuraciones con perfiles de potencia planos.

Otro enfoque interesante fue propuesto en [23], donde se desarrolló un esquema de aprendizaje en cascada que modela el comportamiento de enlaces ópticos de múltiples tramos. En esta estrategia, los modelos de EDFA se entrenan inicialmente a nivel de componente y luego se conectan mediante un ajuste de extremo a extremo que captura las interacciones entre los distintos elementos de la red, como se ilustra en la Fig. 2.2.5.




Figura 2.2.5: Esquema de aprendizaje para cascaded learning [23].

Este enfoque permite corregir las pérdidas acumuladas entre amplificadores utilizando una cantidad mínima de datos experimentales. En particular, se reportó un MAE de $0,16 \text{ dB}$ en un enlace de seis tramos utilizando una sola medición global. Además, mediante técnicas de *transfer learning*, los autores demostraron que es posible recalibrar un nuevo amplificador utilizando apenas un 5% de los datos originales sin degradar significativamente la precisión del modelo completo.

En conjunto, estos trabajos reflejan una transición progresiva hacia modelos de estimación de QoT capaces de adaptarse dinámicamente a la operación real de la red. En lugar de depender exclusivamente de parámetros estáticos o de caracterizaciones iniciales, estos enfoques aprovechan la información generada durante la operación para refinar continuamente sus predicciones, reduciendo así los márgenes de incertidumbre en la planificación y operación de redes ópticas.

2.2.4. Modelado de la Potencia de Entrada en los EDFA y su Impacto

La sensibilidad del EDFA frente a la potencia total de entrada puede observarse con claridad en la Fig. 2.2.6. En la parte superior se ilustra cómo el perfil de *gain ripple* se distorsiona a medida que la potencia de entrada aumenta o disminuye. Las curvas exhiben oscilaciones más irregulares y desplazamientos más pronunciados, lo que refleja el efecto de saturación del medio activo sobre el perfil espectral de ganancia. En contraste, la parte inferior de la figura muestra la variación del *ripple* al modificar únicamente la ganancia objetivo del amplificador. En este caso, el comportamiento espectral resulta considerablemente más estable.

Esta comparación evidencia que, aunque ambos parámetros influyen en la respuesta del amplificador, la potencia total de entrada es el factor dominante en la forma y amplitud del *gain ripple*. Por lo tanto, constituye una variable crítica tanto para el modelado del EDFA como para el entrenamiento y la capacidad de generalización de los modelos de aprendizaje automático utilizados en la predicción de ganancia y de QoT.

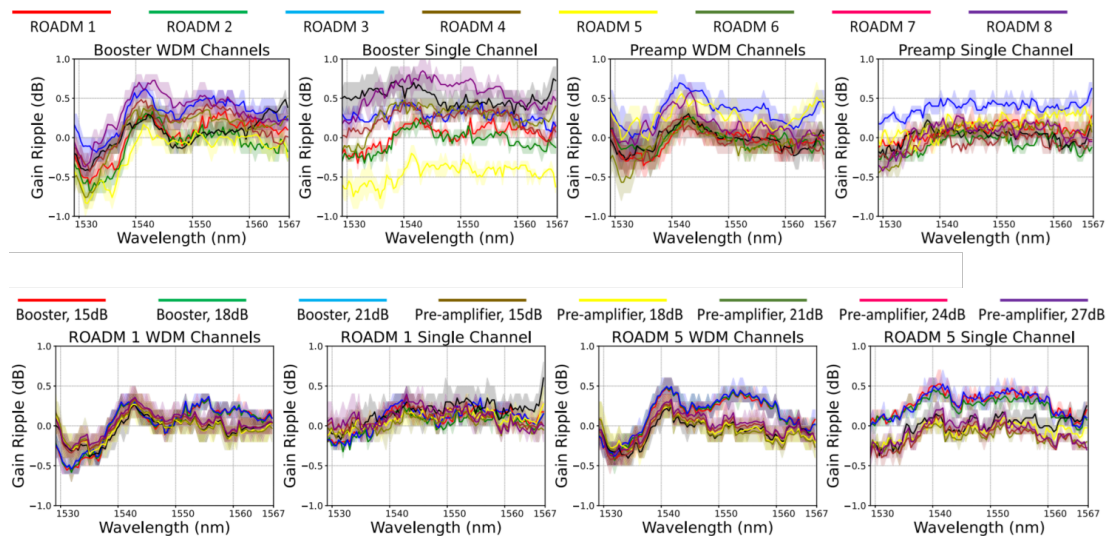


Figura 2.2.6: Variación del *gain ripple* en amplificadores EDFA bajo diferentes condiciones operativas. En la parte superior se observa el comportamiento del ripple al variar la potencia total de entrada del amplificador, mientras que en la parte inferior se muestra la variación al modificar la ganancia objetivo [24].

A pesar de esta evidencia experimental, muchos trabajos de modelado basados en aprendizaje automático no consideran explícitamente la potencia de entrada como una variable primaria de entrenamiento. Cuando la potencia total de entrada se

modifica, el perfil de *gain ripple* del EDFA se distorsiona de forma significativa, mientras que al ajustar únicamente la ganancia objetivo el perfil se mantiene relativamente estable. En otras palabras, la potencia total de entrada no solo escala el perfil de ganancia, sino que puede reconfigurar su forma espectral.

En los modelos de caja negra, la mayoría de los enfoques modernos incluyen la potencia de entrada entre las variables de entrada del modelo, junto con parámetros como la potencia de salida o la ganancia medida. Esto permite alcanzar errores medios inferiores a 0,1 *dB* sin necesidad de describir explícitamente la física interna del amplificador [15]. Sin embargo, al tratar la potencia únicamente como una variable observada dentro de un conjunto de datos, estos modelos tienden a capturar el comportamiento empírico del sistema sin necesariamente representar las causas físicas subyacentes. En consecuencia, suelen ofrecer predicciones muy precisas dentro del rango de operación utilizado durante el entrenamiento, pero su capacidad de generalización puede degradarse cuando la red opera fuera de ese régimen, por ejemplo bajo condiciones de carga parcial, control automático de ganancia (AGC) o saturación desigual entre canales.

Algunos estudios han explorado explícitamente el efecto de la potencia de entrada mediante barridos experimentales. En trabajos con módulos *pluggable* [18] o simulaciones de saturación [25], se ha observado que un aumento en la potencia de entrada puede reducir los errores de predicción y estabilizar el espectro amplificado. No obstante, estos experimentos suelen evaluarse en rangos de operación limitados y rara vez consideran los efectos acumulativos que emergen en configuraciones de múltiples tramos.

En contraste, los modelos semi-analíticos tienden a tratar la potencia de entrada como una variable central del modelo. Los enfoques basados en descomposición SVD [26], por ejemplo, realizan barridos controlados de potencia y la incorporan directamente en las ecuaciones que describen las poblaciones iónicas del erbio. Cuando la potencia aumenta, aparecen fenómenos como la absorción saturable que pueden deformar el perfil de *ripple* si el modelo no los considera explícitamente. Otros trabajos, como los modelos de potencia equivalente [11], establecen una relación directa entre la potencia de entrada y la ganancia promedio del amplificador, construyendo mapas que permiten predecir la respuesta del EDFA para distintos espectros de entrada. Estos enfoques alcanzan errores cercanos a 0,05 *dB* al estimar la potencia equivalente que preserva el comportamiento global del amplificador.

Sin embargo, el efecto de la potencia no es uniforme en todos los escenarios operativos. En condiciones de carga completa [13], el cambio de potencia tiende principalmente a escalar el perfil espectral de ganancia. En cambio, bajo condiciones de carga parcial o espectros no planos, la redistribución de energía entre canales puede distorsionar significativamente el *gain ripple*. En otras palabras, cuando todos los canales participan en la amplificación el perfil espectral tiende a escalar de manera relativamente uniforme, mientras que una distribución desigual de potencia puede provocar deformaciones más complejas.

En los modelos analíticos utilizados para planificación de red, la potencia de entrada también juega un rol estructural. Comparaciones entre la técnica *Power Mask* y el enfoque *Dynamic Gain Tilt* [17] han mostrado que modelar la ganancia como función de la potencia total describe con mayor precisión el comportamiento del amplificador, especialmente en regiones donde el *ripple* es elevado. De forma complementaria, los modelos basados en el ruido gaussiano [2] muestran que el nivel óptimo de potencia surge del equilibrio entre la generación de ruido ASE y las no linealidades de la fibra. En validaciones experimentales de redes flexibles [6], barrer la potencia de entrada desplaza el punto óptimo de QoT, evidenciando que una selección inadecuada de este parámetro puede degradar la SNR incluso cuando el resto de las condiciones del enlace permanecen constantes.

En redes reales, la potencia efectiva que llega a cada amplificador rara vez coincide exactamente con la potencia asumida durante la planificación. Pequeñas variaciones en pérdidas de conectores o diferencias en la longitud real de los tramos de fibra pueden alterar significativamente la potencia incidente sobre el EDFA [5]. Estudios experimentales han mostrado que, al combinar mediciones directas de los amplificadores con información proveniente de monitores ópticos, es posible refinar estas estimaciones y reducir de forma significativa los errores en la predicción de QoT [7].

En síntesis, los distintos enfoques de modelado reconocen la importancia de la potencia de entrada, pero la abordan desde perspectivas diferentes. Los modelos de caja negra la utilizan principalmente como una variable observada dentro del conjunto de entrenamiento, los modelos semi-analíticos la incorporan explícitamente en las ecuaciones que describen la física del amplificador, y los modelos analíticos la emplean como un parámetro de optimización en la planificación de red. No obstante, en la mayoría de los casos la potencia se trata como un valor determinista, pese a que en redes ópticas reales constituye una variable inherentemente incierta.

2.3. Gestión de Incertidumbres

En redes ópticas dinámicas, la potencia que realmente entra a cada EDFA no es un valor fijo ni perfectamente conocido. En la práctica, depende de múltiples factores, como pérdidas de conectores, variaciones en la longitud real de los tramos de fibra o discrepancias entre el diseño de la red y su implementación física. Cuando la pérdida real de un conector difiere de la asumida en el modelo, la potencia efectiva que llega al amplificador cambia, afectando directamente el valor de GSNR estimado. Por ejemplo, al asumir una pérdida conservadora de $0,25 \text{ dB}$ por conector, se ha observado que aproximadamente el 90% de los errores de estimación se mantienen dentro de $\pm 1 \text{ dB}$, mientras que cerca del 95% de las estimaciones resultan conservadoras, contribuyendo a estabilizar la operación de la red [5].

Cuando la fuente de incertidumbre proviene de tramos de fibra heterogéneos, el impacto puede ser aún mayor. Incluso manteniendo la misma distancia total de enlace, variaciones en la distribución de los spans pueden producir errores de estimación de QoT entre $0,5$ y 3 dB , alcanzando valores cercanos a 5 dB en los peores casos. Además, estas variaciones desplazan el punto óptimo de potencia de lanzamiento asociado al máximo factor Q en aproximadamente 1 dB [27].

Otro factor crítico corresponde a las discrepancias entre la topología planificada y la red desplegada. En estudios realizados sobre redes troncales reales de Norteamérica, se ha reportado que cerca del 29% de las fibras presentan diferencias superiores a 5 km entre la longitud registrada en el diseño y la longitud medida en campo [28]. Este tipo de desviaciones se traduce directamente en una potencia de entrada distinta a la esperada en cada amplificador de la red.

Adicionalmente, el rendimiento de los modelos de estimación de QoT depende fuertemente de cómo se representa estadísticamente esta incertidumbre. En [29] se demostró que, si un modelo de red neuronal se entrena bajo una distribución de incertidumbre incorrecta —por ejemplo, suponiendo variaciones gaussianas cuando la red real presenta variaciones aproximadamente uniformes— el error promedio de predicción puede aumentar hasta cerca de $0,68 \text{ dB}$.

Las estrategias propuestas en la literatura para abordar este problema pueden agruparse en tres categorías principales. La primera consiste en refinar los parámetros del modelo físico utilizando mediciones reales de la red. Por ejemplo, empleando mediciones de SNR para ajustar la potencia de entrada por tramo y la

figura de ruido de los amplificadores dentro del modelo analítico, es posible reducir los márgenes de error desde varios decibelios hasta valores cercanos a 0,02–0,1 dB [30].

Una segunda estrategia corresponde al uso de configuraciones conservadoras durante la planificación de la red, como asumir pérdidas de conectores mayores a las esperadas para absorber posibles desviaciones operacionales.

Finalmente, los enfoques probabilísticos e híbridos buscan modelar explícitamente la incertidumbre del sistema. En lugar de estimar la SNR como un valor único, estos métodos la representan mediante una distribución de probabilidad, lo que permite reducir los márgenes de diseño y optimizar el uso de recursos de red. Se ha demostrado que este enfoque puede reducir entre un 4 % y un 12 % el número de transpondedores y el espectro utilizado, manteniendo un riesgo controlado de interrupción del servicio [31]. A nivel de componente, también se han explorado métodos de propagación directa de incertidumbre, como procesos gaussianos con entradas ruidosas en cascada, capaces de predecir espectros de salida con errores cercanos a 0,12 dB utilizando solo una fracción de los datos experimentales requeridos por otros modelos [32].

En conjunto, la gestión de incertidumbre no elimina la variabilidad inherente de los sistemas ópticos, sino que busca modelarla y propagarla adecuadamente dentro de los modelos de predicción. De esta forma, es posible operar la red con márgenes más reducidos sin comprometer su robustez.

2.4. Discusión

El estado del arte ha avanzado demasiado en el modelado de los EDFA y la estimación de la QoT, gracias a los modelos híbridos físico-data-driven que superan a los enfoques analíticos. El ML permitió capturar el gain ripple con errores diminutos y generalizar mejor los métodos clásicos en escenarios de variación espectral. Sin embargo, este progreso aún tiene muchas discusiones abiertas la mayoría de propuestas funcionan bien mientras las condiciones de laboratorio (potencias conocidas, entradas estables, cargas variables) se mantienen. Cuando la red deja de comportarse como este experimento controlado, los modelos empiezan a mostrar sus límites. Sumado a esto, pocos trabajos se evalúan de manera experimental en un sistema multi-span de amplificadores, lo que oculta cómo reaccionan realmente estos algoritmos ante los desafíos físicos del hardware real.

En la literatura actual existen tres áreas donde los modeladores fallan. El primero es la dependencia del EDFA respecto a la potencia de entrada. Casi todos los trabajos reconocen el ripple, el tilt y el régimen de inversión que dependen de la P_{in_total} , pero la tratan de distintas maneras, algunos la fijan, otros la acotan en un rango pequeño, otros la barren, otras la infieren a partir de PSD o la carga. Al revisar con detalle, muchos trabajos no evalúan un amplio rango de potencias de entradas en sus modelos de ML. A su vez casi todos son entrenados en un sólo span, osea que el amplificador aprende de ese span y no de lo que va dejando el ripple en el multispán. El problema con todo esto es que ninguna de estas aproximaciones captura la realidad de una red dinámica, la potencia que le llega al EDFA no es un parámetro configurable, sino una variable incierta que arrastra todos los errores acumulados antes de él. La consecuencia es clara, los modelos precisos de laboratorios pierden precisión cuando la entrada no coincide con el set de datos con la que fue entrenada.

La segunda área corresponde a la incertidumbre topológica. Los estudios revisados analizan parámetros de la red (como la pérdida en conectores y la longitud de los spans) que, al verse afectados por dicha incertidumbre, provocan errores en la estimación de la QoT. Esto es relevante considerando que, en redes reales, cerca de un tercio de las fibras pueden discrepan hasta 5 km, lo que evidencia que la incertidumbre existe. Asimismo más parámetros, como por ejemplo las variaciones en los coeficientes de atenuación de la fibra, generando diferencias adicionales en la atenuación total. Aunque la literatura reconoce estos impactos, no establece una relación directa entre esta incertidumbre y la potencia de entrada que recibe el EDFA, a pesar de que dicha potencia determina el régimen de operación del amplificador. Esta desconexión mantiene separados dos mundos que, en la práctica, están relacionados: la física del EDFA y la topología de la red. Ningún trabajo ha juntado la incertidumbre con el gain ripple un fenómeno que se puede dar de la mano y que afecta a la señal.

Por último, está el límite real de los modelos de ML que pueden tener un rendimiento sobresaliente, pero solo mientras la realidad se parezca a los datos con los que fueron entrenados. Cuando la red les muestra algo que nunca vieron, como potencias extrañas, cargas espectrales desordenadas o perfiles que se salen del lo común la precisión simplemente se derrumba. A eso se suma que cada EDFA trae su propio perfil de ganancia, lo que hace que un modelo entrenado para un amplificador no funcione igual de bien en otro. En este punto entra el transfer learning, que permite adaptar modelos entre dispositivos, pero que sigue siendo

totalmente dependiente de la calidad del dataset inicial.

En la búsqueda de una red óptica optimizada la solución de mudarse a utilizar una red digital, como digital twins, es necesario contar con un conocimiento mucho más profundo y realista de la red donde estos modelos serán desplegados. Actualmente no existe una guía metodológica para integrar todas estas incertidumbres en la estimación QoT. La brecha central es, entonces, la falta de modelos que traten la potencia de entrada como una variable incierta, medible y operacional, y que conecten esta variabilidad con el comportamiento espectral del EDFA y con la degradación acumulada del OSNR en múltiples spans. Explorar esta interacción es un paso necesario para reducir márgenes y llevar los modelos de ML a terrenos no pavimentados (incertidumbre), si no se considera la incertidumbre como una condición estructural, todo el ecosistema óptico se volverá frágil.

Capítulo 3

Hipótesis y Objetivos

3.1. Hipótesis

La incertidumbre operacional (modelada como variaciones de potencia de entrada) se propaga y se amplifica en cascadas de EDFAs, produciendo desviaciones medibles en los perfiles de ganancia y en el OSNR. En este contexto, los modelos de ganancia entrenados en un solo tramo tenderán a perder validez bajo incertidumbre, y esa pérdida puede cuantificarse comparando sus predicciones con una referencia experimental en un enlace multispan.

3.2. Objetivos

Objetivo general

Cuantificar experimentalmente cómo la incertidumbre operacional (variaciones de potencia de entrada) se propaga en cascadas de EDFAs y cómo afecta la ganancia y el OSNR, y evaluar la validez de modelos de ML de ganancia entrenados en un solo tramo al compararlos con una referencia experimental en un enlace multispan.

Objetivos específicos

1. Construir un conjunto de mediciones experimentales que describa la ganancia por canal $G(i)$ de un EDFA y su *gain ripple*.
2. Entrenar un modelo de red neuronal (ANN) para predecir $G(i)$ en un EDFA, y comparar su desempeño con un modelo de referencia y con modelos ajustados a los amplificadores del laboratorio.

3. Medir el OSNR en un enlace óptico multispán y establecer un *ground truth* experimental.
4. Cuantificar cómo la incertidumbre (variaciones de potencia de entrada) afecta la ganancia y el OSNR en el enlace multispán, y posteriormente evaluar los modelos de ML en la línea de transmisión.

Capítulo 4

Metodología

La metodología se centra en cuantificar cómo la incertidumbre del enlace se manifiesta como variaciones de potencia de entrada a los EDFAs y cómo dichas variaciones se propagan en cascada, afectando el perfil espectral de ganancia (*gain ripple*) de los EDFAs y con ello el rendimiento del sistema y la capacidad de predecir con modelos de ML.

Para ello, primero se construye un dataset experimental para caracterizar la ganancia por canal de un EDFA (Objetivo 1). Luego, se implementan modelos de ML para predecir dicha ganancia, incluyendo un modelo de referencia de la literatura y modelos ajustados con datos del laboratorio, para después ponerlos a prueba en el multispán (Objetivo 2). A continuación, se evalúa un sistema experimental exploratorio para validar los cambios del *gain ripple* en un multispán; con base en este experimento, se realiza y caracteriza otro enlace multispán construyendo una referencia experimental (*ground truth*) y métricas de análisis *end-to-end* y *hop-by-hop* (Objetivo 3). Finalmente, se introduce incertidumbre de manera controlada y se cuantifica su impacto en ganancia y OSNR, evaluando la validez de los modelos ML al comparar predicción vs. medición (Objetivo 4).

Este flujo se construyó de forma progresiva, a medida que se aprendía a operar el sistema y a interpretar los resultados, por lo que cada etapa habilitó la siguiente. La única parte que no sigue estrictamente esa secuencia es el Objetivo 2, Parte 2, que se incorporó posteriormente para mantener la coherencia temática de la sección.

El flujo de los objetivos se resume en la siguiente Fig. 4.0.1.

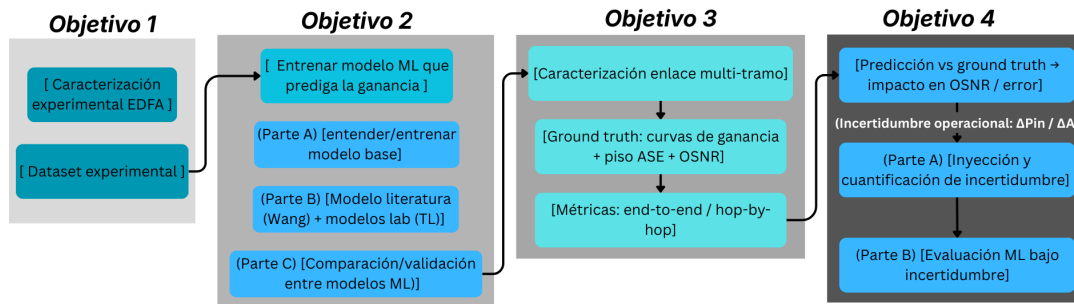


Figura 4.0.1: Diagrama de bloques para la metodología propuesta.

4.1. Caracterización experimental del EDFA y construcción del dataset

Este primer objetivo busca modelar un amplificador óptico (EDFA) para caracterizar el *gain ripple* y construir el conjunto de datos con el que, posteriormente, se entrenarán los modelos de ganancia del amplificador.

Para caracterizar el amplificador y construir el conjunto de datos de ganancia espectral, se utilizó la configuración mostrada en la Fig. 4.1.1. Esta configuración permite extraer las características de los amplificadores.

Como señal de entrada se empleó la técnica *Spectrally Shaped ASE* (SS-ASE), propuesta por Elson D. (Saavedra, G. et al.) [33], esta técnica utiliza como fuente al EDFA thorlabs y el Wavelength Selective Switch (WSS). Esta técnica se utiliza para emular cargas WDM flexibles sin necesitar muchas fuentes láser, lo que resulta práctico cuando se requiere un gran número de canales y, además, reduce muchísimo el presupuesto experimental. Por ejemplo, en lugar de disponer de 95 láseres, se moldea espectralmente el ruido ASE para representar los 95 canales, sin la necesidad de utilizar un transceiver.

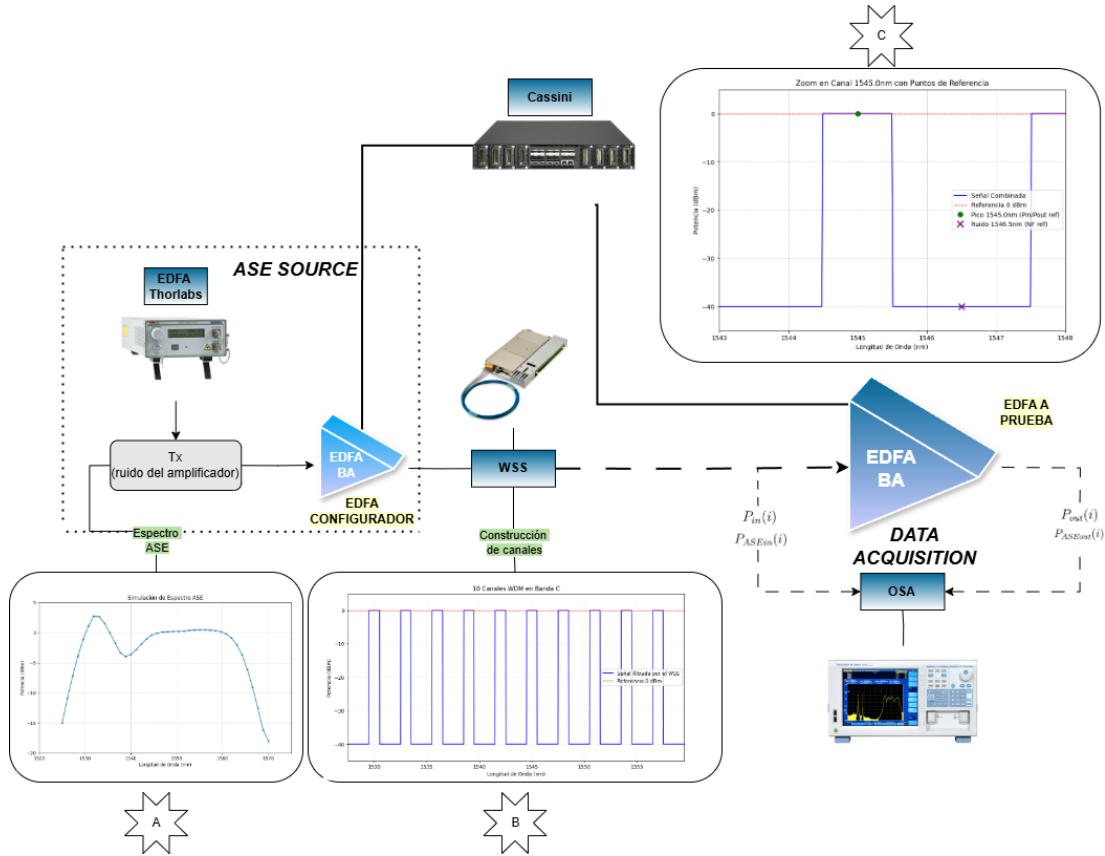



Figura 4.1.1: Configuración experimental para la adquisición de datos del EDFA bajo prueba.

En esta primera etapa, la fuente ASE operó con una corriente de 1000 mA. En estas condiciones, su perfil presenta una inclinación entre los canales (diferencias de potencia entre longitudes de onda), lo que dificulta la ecualización del WSS cuando se desea una carga alta de canales: algunos canales requieren atenuaciones cercanas al máximo del WSS (20 dB por canal).

Esta limitación impacta en la diversidad de datos disponibles para los modelos de ML, ya que el WSS introduce muchas pérdidas cuando se aplican atenuaciones de esa magnitud. Por esta razón se incorpora un EDFA configurador ($EDFA_{BA}$): su función es compensar las pérdidas introducidas la ecualización del WSS que es del orden de 10 dB en este experimento y, con ello, asegurar que el EDFA bajo prueba (DUT) reciba un rango amplio de potencia total de entrada. No obstante, cuando la ecualización requiere atenuaciones cercanas al máximo del WSS (20 dB, como se observa en 4.1.2), la pérdida efectiva del enlace entre el $EDFA_{BA}$ y el DUT aumenta; en consecuencia, el $EDFA_{BA}$ debe operar con mayor ganancia y el margen disponible para barrer potencias de entrada en el DUT se reduce. Si bien utilizar este EDFA nos permite tener más datos para el parámetro de potencias

de entrada al amplificador DUT, es importante mencionar que al amplificar, se amplifica también el ruido, sin embargo para la toma de muestras esto no se verá afectado (dado que se toman los peaks de la señal).

Para solucionar este problema, se trabajó en la zona central del espectro ASE, donde el perfil del ASE es más plano Fig. 4.1.2 (a). En la práctica, esto implicó restringir la banda a 1538–1555 nm y configurar una carga de **24 canales** (en lugar de 95-literatura), reduciendo la atenuación del WSS y recuperando un rango de potencias de entrada adecuado para construir el *dataset* y entrenar el modelo de ML.



(a) Espectro de ruido ASE capturado después de la amplificación de $EDFA_{BA}$.

(b) Espectro de 24 canales ecualizado mediante el WSS.

Figura 4.1.2: Perfil espectral del ruido ASE: (a) espectro continuo tras $EDFA_{BA}$ con pendiente espectral; (b) ejemplo de carga discreta (24 canales) ecualizada mediante el WSS.


Como se mencionó el WSS permite definir la carga (número y posición de canales en la banda C) y ecualizar la potencia por canal mediante atenuación, configurando un espectro de entrada aproximadamente plano a la entrada del DUT. De este modo, se busca aislar el *gain ripple* propio del DUT del ripple introducido por etapas de amplificación anteriores (ASE source). En esta etapa, los canales se configuraron con un ancho de 1 nm y un espaciamiento de 1 nm, mientras que el DUT operó en modo de control automático de ganancia (AGC). Un OSA, con resolución espectral de 0.03 nm, registró los espectros a la entrada y salida del amplificador; a partir de ellos se extrajeron las potencias *peak* por canal $P_{in}(i)$ y $P_{out}(i)$, que constituyen la base del *dataset* experimental.

Si bien la resolución del OSA (0.03 nm) es menor que el ancho configurado de canal (1 nm), la potencia por canal se estimó a partir de los *peaks* y no como potencia sobre el ancho de canal. En ese sentido, el “error” de utilizar una resolución mucho más fina es que el OSA entrega una muestra puntual del canal (potencia en el

máximo) y no su potencia total; por lo tanto, los valores $P_{in}(i)$ y $P_{out}(i)$ pueden ser distintos de una medición a 1 nm. Esta elección se mantuvo en la construcción del conjunto de datos utilizado en el Objetivo 2 parte A (por falta de conocimiento experimental propio) y no afecta la capacidad del modelo de ML para aprender el comportamiento de la ganancia, ya que el modelo aprende de la diferencia entre *peaks*; sin embargo, la estimación de potencia por canal puede ser distinta respecto de una medición. La estrategia que se tomó para corregir este aspecto en experimentos posteriores se discute en la sección correspondiente al Objetivo 3.

El DUT operó en modo Automatic Gain Control (AGC), con *tilt* configurado en 0 y una ganancia objetivo G_{target} ajustable. El OSA se empleó para identificar los *peaks* (potencia *peak*) correspondientes a cada uno de los 24 canales activos y extraer las potencias por canal a la entrada y salida del EDFA, $P_{in}(i)$ y $P_{out}(i)$. Con el fin de construir un *dataset* compacto, no se utilizó el espectro completo, sino únicamente estas muestras discretas por canal. La detección de *peaks* y la extracción de datos se automatizaron mediante scripts desarrollados en MATLAB, los cuales almacenan las potencias por canal.

Una vez definida la carga espectral de 24 canales (cantidad justa de canales de 1 nm en la banda que no sufre de tanta diferencia de potencia), el WSS se utilizó como ecualizador para nivelar la potencia de cada canal activo, para dejar un espectro plano sin interferencias de ganancias. La Fig. 4.1.3 muestra el espectro antes y después del proceso, donde se puede ver un perfil de entrada aproximadamente plano a la entrada del DUT y facilitando el análisis del ripple asociado al EDFA bajo prueba, ya que no se ve afectado con el ripple generado de las ampliificaciones anteriores, aislando el efecto del gain ripple.



(a) Espectro de 24 canales no ecualizado.

(b) Espectro de 24 canales ecualizado mediante el WSS.

Figura 4.1.3: Proceso de ecualización espectral previo a la amplificación. Ambos espectros fueron capturados antes del EDFA bajo prueba.

Una vez definido el setup experimental y aislado el efecto de *gain ripple*, se

identificaron en la literatura los parámetros más usados para entrenar modelos de amplificadores: potencia de entrada, ganancia objetivo del amplificador y carga espectral.

Para ello, se tomaron los peaks de los espectros de entrada y salida para todas estas condiciones.

Se definieron un total de $11 \times 6 \times 6 = 396$ condiciones experimentales únicas:

- **Potencia total de entrada** ($P_{\text{in,total}}$):

$$\{-10, -9, -8, -7, -6, -5, -4, -3, -2, -1, 0\} \text{ dBm.}$$

- **Ganancia objetivo** (G_{target}):

$$\{11, 13, 15, 17, 19, 20, 5\} \text{ dB.}$$

- **Carga espectral:** $\{4, 8, 12, 16, 20, 24\}$ canales activos.

A partir de las potencias *peak* medidas, la ganancia por canal se calculó como:

$$G(i) = P_{\text{out}}(i) - P_{\text{in}}(i), \quad (4.1.1)$$

dando origen a un dataset de aproximadamente 5000 muestras experimentales, que permite analizar el gain ripple.

4.2. Modelo de aprendizaje automático para el análisis del *gain ripple*

Este objetivo se desarrolla en dos partes. En la primera, se entrena un modelo ANN para un EDFA exploratorio y se analiza cómo la potencia total de entrada, la ganancia objetivo y la carga espectral afectan el perfil de ganancia por canal y el *gain ripple*. En la segunda, una vez entendiendo el comportamiento de los modelos, se implementa el modelo de Wang como referencia de la literatura y se reentrenan cuatro modelos especializados (mediante *transfer learning*) con datos de los EDFAs del laboratorio, con el fin de comparar desempeño y evaluar su comportamiento posteriormente en el enlace multispán.

4.2.1. Parte 1: EDFA exploratorio

Se adoptó una arquitectura de red neuronal completamente conectada, inspirada en el modelo propuesto por Wang [24], pero con un conjunto de variables de entrada más compacto: mientras Wang utiliza 193 características de entrada, en este trabajo se utilizaron 5 variables (dado la falta de conocimientos sobre los modelos de ML). La red está compuesta por una capa de entrada, cuatro capas ocultas con funciones de activación ReLU y una capa de salida lineal. La arquitectura completa del modelo se muestra en la Fig. 4.2.1.




Figura 4.2.1: Arquitectura del modelo ANN empleada para el análisis de la ganancia espectral del EDFA.

La salida del modelo corresponde a la potencia óptica de salida por canal $P_{out}(i)$, a partir de la cual se calcula la ganancia por canal mediante la Ec. 4.1.1.

El modelo fue entrenado en modo supervisado utilizando el optimizador Adam y una función de pérdida basada en el error cuadrático medio (MSE). El objetivo de la red es la estimación de la ganancia por canal $G(i)$, y la función de pérdida se define como:

$$Loss_G = \frac{1}{M} \sum_{m=1}^M \left(G_{\text{predicho}}^{(m)}[\text{dB}] - G_{\text{real}}^{(m)}[\text{dB}] \right)^2 \quad (4.2.1)$$

El conjunto de datos se dividió en subconjuntos de entrenamiento, validación y prueba de la siguiente manera 80 % / 10 % / 10 %. El preprocesamiento incluyó normalización de las variables de entrada y verificación de consistencia de los datos experimentales.

Tras validar el modelo ANN, se utilizó el modelo como una herramienta digital de análisis de sensibilidad paramétrica con el objetivo de caracterizar cómo cambia el *gain ripple* predicho ante variaciones de parámetros operacionales (número de canales, potencia total de entrada y ganancia objetivo). Para ello, se definieron tres escenarios independientes en los que se varió un parámetro a la vez, manteniendo constantes los otros dos, esto permite evaluar la respuesta al amplificador en otro contexto de entrada.

Para evaluar el perfil de ganancia generado por el modelo ANN en cada escenario, es necesario caracterizar su desviación respecto de la ganancia objetivo configurada en el amplificador (G_{obj}).

En sistemas Wavelength Division Multiplexing (WDM), la ganancia experimentada por cada canal puede cambiar respecto del valor objetivo del EDFA, dando lugar a desplazamientos positivos o negativos del perfil de ganancia (*gain ripple*). Estas desviaciones pueden llegar a afectar la estimación del desempeño del sistema y la asignación de márgenes. Con esto y con base en la definición de ganancia por canal obtenida a partir de los espectros medidos y predichos, y combinando el análisis desarrollado en este trabajo con el estudio la investigación de [34], se definieron las siguientes métricas para caracterizar el comportamiento del *gain ripple* y su desviación respecto de G_{obj} :

- **Gain Ripple** (ΔG_{ripple}): Esta métrica cuantifica la no uniformidad espectral de un perfil de ganancia individual y se define como la diferencia peak-to-peak entre la ganancia máxima y mínima del espectro:

$$\Delta G_{\text{ripple}} = G_{\text{max}} - G_{\text{min}}. \quad (4.2.2)$$

- **Mean Negative Deviation (MND):** La MND cuantifica la desviación negativa promedio de los canales cuya ganancia se encuentra por debajo del valor objetivo. Esta métrica permite evaluar el riesgo de sobreestimar el desempeño del sistema. Se calcula como:

$$\text{MND} = \frac{1}{|S_{\text{def}}|} \sum_{i \in S_{\text{def}}} (G_{\text{obj}} - G_{\text{pred}}(i)), \quad (4.2.3)$$

donde S_{def} es el conjunto de índices de canal para los cuales $G_{\text{pred}}(i) < G_{\text{obj}}$.

- **Mean Positive Deviation (MPD):** La MPD cuantifica la desviación positiva promedio de los canales cuya ganancia excede el valor objetivo. Esta métrica captura escenarios de subutilización de capacidad y se define como:

$$\text{MPD} = \frac{1}{|S_{\text{pos}}|} \sum_{i \in S_{\text{pos}}} (G_{\text{pred}}(i) - G_{\text{obj}}), \quad (4.2.4)$$

donde S_{pos} corresponde al conjunto de índices de canal para los cuales $G_{\text{pred}}(i) > G_{\text{obj}}$.

Estas métricas se calculan para cada escenario analizado y permiten comparar el impacto de distintos parámetros operativos sobre la forma del perfil de ganancia. Con la finalidad de terminar la primera parte del objetivo 2, entrenar un modelo que tenga la capacidad de amplificar como un EDFA.

Por otra parte, para mantener esta sección enfocada en modelos de ML, se incluye aquí la descripción de los modelos que se evaluarán en el Objetivo 4. Aunque esta Parte 2 se desarrolló casi al final de la tesis, se incorpora en este punto para mantener la coherencia con el objetivo. Además, dichos modelos ya están entrenados para condiciones que no fue posible implementar en estas etapas previas, como 95 canales en toda la banda C.

4.2.2. Parte 2: Modelo de Wang y modelos especializados

Para establecer una línea base sólida y comparable en el análisis final, se implementó el modelo propuesto por Wang [24]. Este modelo constituye actualmente una referencia en el modelado de ganancia espectral mediante aprendizaje automático, al haber sido entrenado sobre el dataset abierto Open EDFA (COSMOS). Dichos datos fueron adquiridos en la plataforma *City-Scale Optical-Wireless Programmable Testbed* en Nueva York.

El conjunto de datos original reportado por Wang et al. [24] comprende una

base masiva de aproximadamente 202,752 mediciones, las cuales integran tanto amplificadores tipo *Booster* como *Pre-amplifier* (PA). Sin embargo, se realizó una selección del dataset basada en la arquitectura del montaje experimental disponible en el laboratorio.

Dado que el enlace multispan construido en el objetivo 3 parte 2 utiliza solo EDFAs tipo PA, se determinó no utilizar datos *Booster*, ya que introduciría una variabilidad innecesaria. Como se evidencia en [24], el comportamiento del *gain ripple* difiere entre ambos dispositivos.

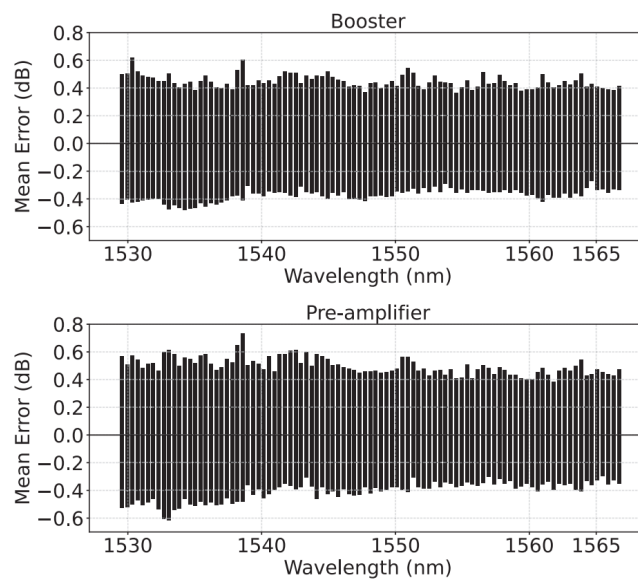


Figura 4.2.2: Comparación del ripple de ganancia entre amplificadores *Booster* y *Pre-amplifier* [24].

Consecuentemente, se seleccionaron únicamente las 140,000 muestras correspondientes a EDFAs PA. Esta selección permite que el modelo base aprenda con el comportamiento físico de los EDFAs locales. Así, el proceso posterior de *Transfer Learning* hacia los modelos especialistas parte de una base alineada con la precisión en la evaluación del impacto de la incertidumbre.

Modelo de Wang-Benchmark: Este modelo actúa como la referencia pilar. En el trabajo original [24], las señales WDM se generaron mediante una fuente tipo peine (*comb source*) con 95 canales sobre la grilla ITU de 50 GHz. La potencia de entrada (S_{in}) y salida (S_{out}) se recolectó mediante monitores de canal óptico (OCM) con resolución de 0.1 dB. Para cubrir el espacio de estados, Wang empleó configuraciones de carga tipo *Fixed Baseline*, *Goalpost*, *Extra* y variaciones aleatorias.




Figura 4.2.3: Arquitectura del modelo ANN de referencia (Wang) para la predicción de la ganancia por canal en un EDFA [24].

En este trabajo, se replicó la arquitectura de Wang: una red densa con normalización por lotes, activación GELU, *dropout* y optimizador AdamW. La entrada consiste en un vector de 193 características, que incluye el espectro de entrada de 95 canales, una máscara binaria de activación y tres variables escalares (ganancia objetivo, potencia total de entrada y salida). Se utilizó una función de pérdida que deja con máscara los canales inactivos para calcular el error únicamente en los canales presentes.

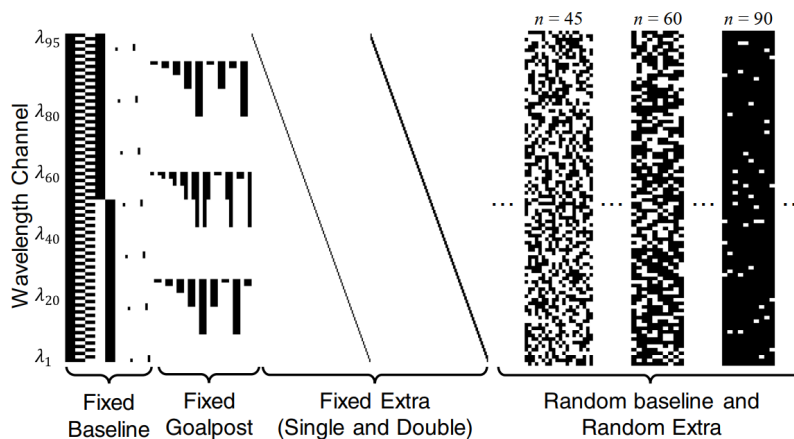


Figura 4.2.4: Esquema de generación/medición WDM utilizado en el trabajo de Wang para la caracterización del dataset COSMOS [24].

Modelos especializados (TL con datos del laboratorio): Se desarrollaron cuatro modelos independientes, dedicados a cada amplificador de la cascada (S1, S2, S3 y S4), mediante técnicas de *Transfer Learning* (TL) para especializar el

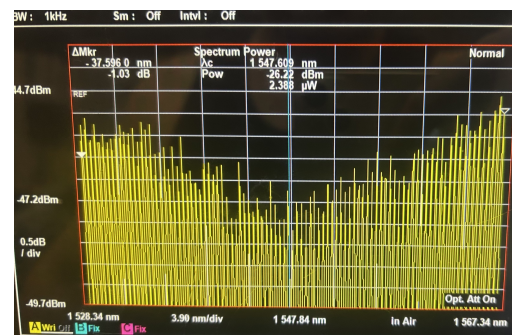
benchmark de Wang al de los EDFAs locales.

Debido a limitaciones de atenuación en el WSS local, se ajustó la grilla a canales de 25 GHz con un espaciamiento de 25 GHz en toda la banda C (1528–1566 nm). Esta configuración permite alcanzar los 95 canales requeridos para mantener la compatibilidad con la cobertura espectral del modelo de Wang. El OSA se configuró con una resolución de 0.2 nm.


Adquisición de datos y diversidad espectral: Para cada amplificador en aislamiento, se barrió la potencia de entrada de -27 dBm a -6 dBm (pasos de 2 dB) con objetivos de ganancia de 21, 24 y 27 dB. Se indujo diversidad espectral utilizando cinco perfiles de entrada: plana, *tilt* positivo, *tilt* negativo, forma en U y U invertida (véanse Figs. 4.2.5 y 4.2.6).




(a) Máscara plana.



(b) Máscara con forma en U.



(c) Máscara U invertida.



(d) Máscara con *tilt* positivo.

Figura 4.2.5: Máscaras/perfiles espectrales de entrada utilizados para generar diversidad en las mediciones.




Figura 4.2.6: Máscara/perfil espectral con *tilt* negativo.

Aumento de datos: A partir de las 270 muestras base obtenidas por amplificador, se aplicó *data augmentation* (factor $\times 15$), resultando en un set de entrenamiento de aproximadamente 4,050 muestras por modelo especializado.

Por último, estos modelos se evalúan con el MAE y distintas estrategias de muestreo en el conjunto de entrenamiento. El MAE se define como:

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N \left| \hat{G}_i - G_i \right| \quad (4.2.5)$$

donde G_i es la ganancia medida por canal y \hat{G}_i la ganancia predicha por el modelo.

Si bien aquí se comparan los modelos en términos de precisión predictiva, la validación definitiva se realiza en el análisis multispan. En ese punto se contrastará la predicción de ganancia y su impacto en OSNR bajo incertidumbre, resultados que se detallan en el Objetivo 4.

4.3. Caracterización experimental del rendimiento (OSNR) de un enlace óptico multi-tramo

Este objetivo se divide en dos partes. En la primera, se evalúa el comportamiento en cascada del gain ripple y el efecto de la potencia de entrada sobre el perfil de ganancia de los amplificadores. Luego, se evalúan dos modelos para estimar el OSNR con muestras experimentales de este setup: (i) uno que incorpora el gain ripple (ganancia dependiente de λ) y (ii) otro que asume una ganancia constante en toda la banda C (ganancia operativa del EDFA). Todo esto con el fin de cuantificar el impacto de ignorar la gain ripple y, además, de definir consideraciones en el setup experimental para la segunda etapa.

En la segunda parte, el Objetivo 3 se centra en caracterizar experimentalmente el enlace multi-tramo y construir un ground truth basado en mediciones OSA para posteriormente comparar las predicciones del modelo de Wang y de los modelos especialistas. Para ello, se evalúan distintas métricas (ganancia, piso de ruido ASE y OSNR) bajo enfoques end-to-end y hop-by-hop, considerando diferentes regímenes de potencia y configuraciones de carga espectral.

4.3.1. Parte 1: Validación experimental inicial (dos EDFAs en cascada)

Se implementó un enlace de dos tramos para evaluar el perfil espectral de ganancia en una cascada simple de EDFAs. Se generó una señal WDM de 24 canales mediante la técnica SS-Shaped y el WSS. La potencia de lanzamiento se ajustó mediante un atenuador óptico variable principal (VOA) antes del primer tramo, permitiendo barrer distintas condiciones de operación.

Cada *span* incluye un segmento de 50 km de fibra, seguido por un segundo VOA que introduce atenuación adicional, generando una línea experimental de casi 200 km. Al final de cada tramo se desplegó un EDFA operando en modo AGC, con una ganancia objetivo fija de 20.8 dB, suficiente para compensar la atenuación total del tramo.

Los VOA se utilizan para variar de manera más sencilla la potencia de entrada de cada amplificador y no depender de la ganancia de un EDFA previo.

La respuesta espectral se capturó mediante un OSA, registrando mediciones tanto a la entrada como a la salida de cada amplificador. La configuración experimental

utilizada se muestra en la Fig. 4.3.1.




Figura 4.3.1: Configuración experimental del enlace óptico de dos tramos.

Procedimiento experimental: El desempeño del enlace se caracterizó como función de la potencia lanzada hacia el primer tramo. Mediante el VOA principal, se varió la potencia por canal a la entrada de la fibra (Punto 1 en la Fig. 4.3.1), lo que produjo una potencia total de entrada presentada directamente al primer pre-amplificador (Punto 2) en un rango aproximado entre $-14,9$ dBm y $-5,3$ dBm, distribuido en once niveles de prueba. Para cada condición de lanzamiento, se registraron en el OSA los espectros de entrada y salida para ambos amplificadores (EDFA 1 y EDFA 2), cubriendo los 24 canales WDM.

En particular, siguiendo el mismo criterio de extracción de potencias por canal utilizado en el Objetivo 1 (y ampliamente utilizado en la literatura experimental), se utilizaron las potencias *peak* medidas a la entrada y salida de cada EDFA. Con esas mediciones, la ganancia experimental por canal se calculó con la Ecuación 4.1.1, lo que permitió caracterizar el perfil espectral de ganancia de cada EDFA bajo distintas condiciones de potencia de entrada.

De manera complementaria, se evaluó el rendimiento del sistema con el fin de comparar la estimación de OSNR entre un modelo que considera el gain ripple y otro que lo ignora. Para ello, se calculó el OSNR experimental, definido como la diferencia entre la potencia *peak* de cada canal y el nivel de ruido ASE medido en una ventana espectral desplazada:

$$OSNR_{\text{exp}}(i) = P_{\text{sig}}(i) [\text{dBm}] - P_{\text{ASE}}(i) [\text{dBm}]. \quad (4.3.1)$$

Por otra parte, se construyó una referencia teórica basada en un modelo analítico simplificado de ganancia plana y ruido ASE (asumiendo $P_{\text{NLI}} \approx 0$). La potencia de salida teórica para cada canal se estimó como

$$P_{\text{out,theo}}(i) = P_{\text{in}}(i) \cdot G_{\text{theory,lin}} \quad (4.3.2)$$

mientras que la potencia de ruido ASE se calculó mediante

$$P_{\text{ASE}}(i) = (G_{\text{theory,lin}} - 1) N F_{\text{lin}} h \nu_i B_{\text{ref}} \quad (4.3.3)$$

Con estas expresiones, el OSNR teórico se obtuvo como

$$OSNR_{\text{theory}}(i) = \frac{P_{\text{out,theo}}(i)}{P_{\text{ASE}}(i)}. \quad (4.3.4)$$

Todas estas formulaciones siguen los modelos clásicos de ruido ASE y sistemas coherentes descritos en la literatura [35]. Para permitir una comparación en la forma espectral, el OSNR teórico fue calibrado restando, para cada condición, el offset promedio entre el OSNR experimental y el OSNR teórico. Esta normalización permite aislar los efectos asociados al *gain ripple*, la acumulación de ruido ASE y la variabilidad entre amplificadores a lo largo del enlace.

Finalmente, se definió el error de estimación de OSNR como la desviación residual entre el OSNR experimental y el OSNR teórico calibrado:

$$\Delta OSNR(i) = OSNR_{\text{exp}}(i) - OSNR_{\text{theory}}(i). \quad (4.3.5)$$

Esta métrica cuantifica el error en *forma* (espectral), es decir, la incapacidad de ganancia plana para reproducir las ondulaciones de ganancia dependientes de la longitud de onda, así como la acumulación de ASE. En particular, permite evaluar cómo el error crece al aumentar la potencia de entrada y cómo difiere entre amplificadores bajo las mismas condiciones de lanzamiento.

Con estas mediciones se generaron tres tipos de resultados. Primero, se graficaron los perfiles de ganancia por canal de cada EDFA y para cada nivel de potencia de entrada, con el fin de visualizar cómo cambia la forma espectral y cómo se acumula el *gain ripple* entre el primer y segundo tramo. Segundo, se graficó el $\Delta OSNR$ por canal para ambos EDFAs, para evidenciar el error espectral introducido por asumir ganancia plana y cómo ese error evoluciona en cascada. Tercero, se resumieron las métricas principales en una tabla: *gain ripple* (máx-mín), desviación estándar del perfil de ganancia y error absoluto promedio de OSNR por condición de potencia.

Estos resúmenes permiten comparar el efecto de la potencia de entrada y la posición del amplificador en la cascada.

4.3.2. Parte 2: Evaluación multi-tramo (*ground truth* y análisis end-to-end/hop-by-hop)

En esta segunda etapa se aborda la caracterización completa del enlace multi-tramo, que se utiliza como base experimental para construir el *ground truth* del sistema. A diferencia del estudio preliminar de dos tramos, aquí el objetivo es observar cómo las mediciones experimentales en las métricas de ganancia, piso de ruido ASE y OSNR evolucionan cuando la señal atraviesa una cascada real de amplificadores, con diferentes condiciones de canales y cantidad de amplificadores. Para ello, se consideran distintas condiciones de carga espectral (95, 48 y 25 canales) y un enlace de cuatro *spans*, equivalente a una distancia cercana a 300 km. Todo con el fin de crear ese ground truth comparativo.

El criterio general es común para las tres variables: se registran espectros en puntos específicos del enlace (entrada y salida de los EDFAs) y, a partir de estas, se calculan métricas tanto en modo global (*end-to-end*) como en modo evolutivo (*hop-by-hop*).

Es importante recalcar que, en general, un EDFA en modo AGC intentará mantener la ganancia objetivo configurada, independientemente de la forma espectral de la señal de entrada (incluyendo el ruido). Esto es gracias al filtro de aplanamiento de ganancia (GFF), la respuesta no es perfectamente plana, ya que se mantiene una ripple residual del orden de 1–2 dB (diferencia entre el máximo y el mínimo del perfil). En la práctica, lo que varía de manera más significativa a lo largo de la cascada es cuánto ruido ASE se amplifica y este va distorsionando el espectro a medida que la señal atraviesa sucesivas etapas de amplificación; es decir, el GFF trata de reducir los peaks de ganancia, pero no elimina la acumulación de distorsión y ruido.

Sin embargo, los modelos de ML son entrenados solo para capturar la ganancia en base a los peaks (no consideran el ASE), sin embargo para complementar el análisis del impacto de la incertidumbre se evalúan todas estas métricas.

Configuración del enlace óptico multi-tramo Para representar un escenario más cercano a una línea de transmisión real, se implementó el enlace mostrado en la Fig. 4.3.3, compuesto por cinco etapas de amplificación.



Figura 4.3.2: Filtro que establece la casi la misma ganancia del amplificador en la banda C




Figura 4.3.3: Configuración experimental utilizada para la evaluación del enlace multispán.

La señal de entrada se genera mediante la técnica de (SS-ASE) [33] de los trabajos previos, solo con la diferencia de que en este experimento se logró filtrar 95 canales. La solución para reducir la diferencia de potencia disponible en la fuente ASE, el EDFA de Thorlabs se configuró operando a su corriente mínima (120 mA) en lugar de 1000 mA. Con este ajuste, la diferencia entre los niveles de potencia se redujo desde aproximadamente 19 dB hasta 8–10 dB, lo que permitió utilizar una mayor cantidad de canales. En esta etapa se utilizó el mismo formato de grilla espectral que en el Objetivo 2, Parte 2.

El amplificador *booster* ($EDFA_{BA}$) busca emular una práctica común en sistemas reales, donde se utiliza un EDFA *booster* al inicio del enlace para establecer un P_{in} nominal. En este trabajo se asume que dicha condición de entrada se mantiene siempre estable (no es propensa a una incertidumbre), ya que es el punto de partida; por tanto, las principales fuentes de incertidumbre se manifiestan después de la amplificación *booster*. Por este motivo, el análisis se centra en los cuatro amplificadores posteriores.

Esta evaluación se centra en los amplificadores en cascada ($EDFA_{S1}$, $EDFA_{S2}$, $EDFA_{S3}$ y $EDFA_{S4}$), que constituyen el *device under test* (DUT) y operan en modo AGC con una ganancia objetivo $G = 20$ dB. De manera de compensar todos los spans, que sufren una atenuación de 18-20 dB.

A pesar de que hay distintas atenuaciones en los spans, se configuro cada

amplificador con las mismas potencias nominales de entradas, esto se regulaba con los atenuadores variables antes del amplificador, como se observa en la Figura, sin embargo por no disponer de un tercer atenuado, se empleó un span con 100km, la manera que se regulo la potencia de este span fue mediante el VOA del span anterior, calzando esta potencia con la de los demás. Los regímenes de potencia nominal considerados en el estudio se resumen en la Tabla 4.3.1. Estos tres escenarios permiten explorar desde operación lineal hasta condiciones cercanas a saturación.

Cuadro 4.3.1: Regímenes nominales de potencia total de entrada por etapa.

Régimen de Potencia	Nominal (P_{in})
Baja Potencia	-24 dBm
Media Potencia	-17 dBm
Alta Potencia	-9 dBm

Para interpretar correctamente los resultados obtenidos, es clave comprender cómo evoluciona físicamente el espectro a lo largo del enlace debido al ruido ASE. Este punto es relevante porque varios modelos (y el propio control operativo) asumen que la potencia total de entrada es la suma de los *peaks* de los canales. En un enlace en cascada, esa suposición deja de ser exacta: parte de la potencia se redistribuye al fondo de ruido, y el sistema puede mantener el mismo valor de potencia total en la GUI mientras el contenido útil de señal cambia. La Fig. 4.3.4 ilustra esta progresión bajo una misma potencia de entrada reportada por el amplificador.




Figura 4.3.4: Evolución del espectro a lo largo de la cascada: (a) condición de referencia a la salida del booster ($EDFA_{BA}$), (b) tras la primera etapa ($EDFA_{S1}$), y (c) tras cuatro etapas de amplificación ($EDFA_{S4}$).

En (a) se observa un perfil plano, que corresponde a la condición bajo la cual típicamente se entrenan modelos simplificados. En (b) comienza a evidenciarse la deformación espectral introducida por la primera etapa de amplificación.

Finalmente, en (c) la acumulación del *gain ripple* produce diferencias entre *peaks* y valles, modificando la distribución espectral de la potencia.

Cabe notar que, aunque visualmente los *peaks* en (c) parecen de distinta forma espectral que en (a), la potencia total de entrada se mantuvo constante en todos los amplificadores y en cada figura. Esto ocurre porque una fracción de la potencia se transfiere al ruido ASE acumulado, elevando el fondo espectral. Como las curvas mostradas corresponden únicamente a los *peaks* de los canales (no al espectro completo), este aumento del fondo no se aprecia de forma inmediata en la figura, pero sí se refleja en la OSNR y, con ello, en el desempeño óptico del sistema. Esta diferencia es clave para la metodología: los modelos de ML se entrenan con entradas similares a (a), pero en el multispan deben predecir bajo condiciones como (c), donde la distribución real de potencia señal/ruido ya cambió.

Referencia experimental (*ground truth*) y condiciones de evaluación. El *ground truth* del enlace se construye a partir de mediciones OSA en cada etapa (S_1 , S_2 , S_3 y S_4), a partir de las cuales se obtiene la ganancia, piso de ruido y el OSNR. Esta referencia permite la base de comparación para la evaluación posterior de los modelos predictivos.

La caracterización tiene distintos regímenes de potencia nominal y configuraciones de carga espectral (25, 48 y 95 canales), de modo de capturar el carácter acumulativo del *gain ripple* y su influencia en el crecimiento del ruido ASE en la degradación del OSNR, bajo diferentes cargas de espectro.

Es importante mencionar que dado que la señal se genera mediante la técnica SS-ASE, el nivel de ruido previo al enlace no es despreciable. Si bien el WSS ecualiza la potencia de los canales y deja un espectro de señal aproximadamente plano a su salida, no ecualiza el piso de ruido ASE que ya fue amplificado por etapas previas (EDFA de Thorlabs y $EDFA_{BA}$) ubicadas antes del WSS. A su vez, el *booster* ya introduce ondulación espectral y, al comenzar el análisis en $EDFA_{S_1}$ (ubicado después del *booster*), la señal ya está afectada por un ASE que ha sido amplificado tres veces, lo que condiciona el estado de OSNR del sistema.

El desempeño del enlace se analiza mediante dos estrategias complementarias:

- *End-to-end*: comparación directa entre $S_1 \rightarrow S_4$, cuantificando el efecto neto.
- *Hop-by-hop*: seguimiento progresivo de las métricas en cada etapa ($S_1 \rightarrow S_2 \rightarrow S_3 \rightarrow S_4$).

Para cuantificar la reacción del sistema y la distorsión espectral asociada, se definen

las siguientes métricas (empleadas en los resultados del Objetivo 3, Parte 2):

1. Reacción de ganancia (*Gain Boost*, ΔG_{Avg}): Cuantifica el cambio promedio de ganancia inducido por la desaturación del EDFA cuando recibe una menor potencia de entrada:

$$\Delta G_{Avg} = \frac{1}{N} \sum_{i=1}^N (G_{unc}(\lambda_i) - G_{nom}(\lambda_i)) \quad [\text{dB}] \quad (4.3.6)$$

2. Error de potencia a la salida (*Power Error*, ΔP_{Out}): Determina en qué medida la pérdida inicial de -3 dB se conserva o se atenúa tras considerar la reacción promedio de ganancia:

$$\Delta P_{out} = \Delta P_{in} + \Delta G_{Avg} = -3,0 + \Delta G_{Avg} \quad [\text{dB}] \quad (4.3.7)$$

3. Distorsión espectral total (RMSE): Evalúa el costo estructural de la auto-compensación, cuantificando la deformación global del perfil espectral (incluyendo *tilt* y *ripple*) mediante el error cuadrático medio:

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (G_{unc}(\lambda_i) - G_{nom}(\lambda_i))^2} \quad [\text{dB}] \quad (4.3.8)$$

En síntesis, las gráficas de resultados de esta parte se capturan para construir y validar el *ground truth* del enlace multispan desde tres perspectivas complementarias: (i) **verificación operativa** del montaje (foto del setup y linealidad P_{out} vs. P_{in} por EDFA), (ii) **evolución espectral** de la señal y del ruido (perfiles de ganancia por carga, espectros in/out, perfil de atenuación y potencia bajo convención de *peaks*), y (iii) **síntesis de desempeño** mediante métricas globales (*end-to-end*) y evolutivas (*hop-by-hop*) para ganancia, ASE y OSNR.

Con ello este Objetivo 3 cumple con establecer una referencia experimental contra la cual se evaluará el impacto de la incertidumbre y la capacidad predictiva de los modelos en el Objetivo 4.

4.4. Análisis del impacto de la incertidumbre: metodología experimental y evaluación de modelos

Este bloque corresponde al **Objetivo 4** y presenta la principal innovación de la tesis: en lugar de evaluar los modelos solo con MAE a nivel de componente, se los somete a una línea experimental multispán para cuantificar cómo ese error puede impactar el desempeño del sistema. En esta sección se detalla el procedimiento experimental empleado para analizar cómo distintas fuentes de incertidumbre alteran la evolución de la ganancia y del OSNR a lo largo de una cascada de EDFAs, y cómo dichas variaciones se traducen en errores al utilizar modelos predictivos agregando otra capa de dificultad para los modelos predictivos. El foco es especialmente relevante para enfoques basados en *Machine Learning* (ML), ya que su desempeño depende de qué tan representativas sean las condiciones de entrenamiento respecto del escenario de operación real.

En particular, se considera que la incertidumbre puede manifestarse como (i) una desviación en la potencia óptica a la entrada de cada amplificador (P_{in}), asociada a variaciones en pérdidas del *span* y elementos pasivos, y (ii) cambios en el comportamiento del propio EDFA frente a distintos niveles de potencia de entrada, ya que P_{in} puede modificar el perfil espectral de ganancia (y, por extensión, el *gain ripple*). Ambos efectos impactan directamente la acumulación de ASE y la degradación del OSNR, por lo que condicionan la fidelidad de cualquier estimador.

Finalmente, se aborda un supuesto frecuente en la literatura: entrenar modelos a partir de mediciones en un único *span* (variando las condiciones de entrada a un solo EDFA) y luego extrapolar su desempeño a una cascada completa de amplificadores.

4.4.1. Modelado de la incertidumbre como desviación de potencia

En una red óptica desplegada, la atenuación acumulada antes de cada EDFA depende de parámetros estables (como la longitud del tramo, pérdidas de inserción, fibra sucia, etc) como de factores dinámicos asociados a operación y mantenimiento. Sin embargo, todos estos fenómenos se concentran en un punto,

en la entrada de los amplificadores. De manera simplificada, la atenuación total puede modelarse como:

$$A[\text{dB}] = \alpha[\text{dB/km}] L[\text{km}] + A_{\text{conectores}}[\text{dB}], \quad (4.4.1)$$

donde α representa el coeficiente de atenuación de la fibra y $A_{\text{conectores}}$ agrupa pérdidas discretas asociadas componentes pasivos.

En la práctica, la longitud real puede ser diferente del valor nominal ($L = L_0 + \Delta L$). Como se mencionó en el estado del arte, en escenarios reales no siempre se despliegan tramos con exactamente las longitudes planificadas. A esto se suman fenómenos como el envejecimiento de la fibra, que aportan una variación adicional en la atenuación total:

$$\Delta A = \alpha \Delta L + \Delta A_{\text{envejecimiento}} + \Delta A_{\text{empalmes}}. \quad (4.4.2)$$

En este trabajo, todas estas fuentes físicas se representan mediante un único parámetro: la incertidumbre en la potencia óptica a la entrada del amplificador (ΔP_{in}), definida como la diferencia entre la potencia nominal esperada y la potencia efectivamente recibida:

$$\Delta P_{\text{in}} = P_{\text{in,nominal}} - P_{\text{in,real}} = \Delta A. \quad (4.4.3)$$

Esta aproximación permite traducir múltiples muchas variables físicas en una variable directamente y, reproducible bajo condiciones controladas.

4.4.2. Protocolo de inyección y propagación de incertidumbre en la cascada

Con el fin de emular este fenómeno de manera controlada, se diseñó un protocolo experimental sobre el ground truth del enlace multi-tramo.

1. **Condición nominal:** Mediante la interfaz de control de los cuatro EDFAs se fijó una potencia objetivo común (por ejemplo, $P_{\text{in}} = -24$ dBm, esta es una potencia nominal). Posteriormente, los VOAs ubicados antes de cada amplificador se ajustaron hasta asegurar que todos los EDFAs operaran en el régimen nominal establecido, es decir todos los amplificadores tienen una $P_{\text{in}} = -24$ dBm, independiente del ASE.

2. **Inyección de la incertidumbre:** Una vez estabilizado el sistema, se introdujo una atenuación de 3 dB (equivalente a $\Delta P_{\text{in}} = -3$ dB) sólo en el VOA anterior al primer amplificador ($EDFA_{S1}$).
3. **Propagación sin reajuste:** Los VOAs de las etapas posteriores ($S2$, $S3$ y $S4$) no fueron modificados, solo se modifican cuando se elige una potencia del régimen nominal. De esta forma, la disminución inicial de potencia —junto con la respuesta interna del primer EDFA— se dejó evolucionar a través de toda la cascada.

El experimento se repitió para los tres regímenes nominales considerados (-24 , -17 y -9 dBm), registrando espectros completos en cada span con el fin de caracterizar la evolución de la ganancia.

4.4.3. Métricas físicas para la cuantificación del error

Para evaluar el impacto físico de la incertidumbre se definieron tres métricas analíticas, las cuales también fueron empleadas en el Objetivo 3. No obstante, la definición de “error” y la forma de construir la referencia cambian de manera importante entre ambos objetivos, y esa diferencia es central para interpretar los resultados.

En el Objetivo 3, la comparación se realizó *sin introducir incertidumbre*. La referencia se tomó como un espectro a la salida de $EDFA_{S1}$ (bajo una potencia nominal fijada, por ejemplo $P_{\text{mathrmin}} = -24$ dBm en todos los amplificadores) y, a partir de ella, se cuantificó cómo se deformaban los espectros a medida que avanzaba la cascada. En particular, el “error” se evaluaba como la diferencia entre espectros de **distintas etapas** del enlace, por ejemplo:

- *Hop-by-hop*: comparar el espectro (o métricas derivadas) de S_1 vs. S_2 , S_1 vs. S_3 y S_1 vs. S_4 .
- *End-to-end*: comparar directamente S_1 vs. S_4 .

En el presente Objetivo 4, en cambio, la comparación se realiza *con incertidumbre* inducida mediante una perturbación en la potencia de entrada, ΔP_{in} (por ejemplo, -3 dB). Por tanto, el “error” se define como la diferencia entre una condición **nominal** y su condición **perturbada**, evaluada **en el mismo amplificador** (misma etapa) y para el mismo régimen nominal. Por ejemplo, para el régimen nominal de -24 dBm, se compara:

- S_1 : espectro de salida con $P_{in} = -24$ dBm vs. espectro de salida con $P_{in} = -27$ dBm,
- S_2 : espectro de salida con $P_{in} = -24$ dBm vs. espectro de salida con $P_{in} = -27$ dBm,
- S_3 : espectro de salida con $P_{in} = -24$ dBm vs. espectro de salida con $P_{in} = -27$ dBm,
- S_4 : espectro de salida con $P_{in} = -24$ dBm vs. espectro de salida con $P_{in} = -27$ dBm,

y de manera análoga para los regímenes nominales de -17 dBm y -9 dBm.

En resumen, mientras que en el Objetivo 3 la comparación es **entre etapas** (misma condición nominal, distinta posición en la cascada), en el Objetivo 4 la comparación es **dentro de cada etapa** (misma posición, dos condiciones de potencia de entrada: nominal vs. perturbada). Sea $G_{nom}(\lambda)$ el perfil de ganancia en condición nominal y $G_{unc}(\lambda)$ el perfil bajo incertidumbre, para N canales WDM activos:

Referencia a métricas definidas en Objetivo 3: Las métricas de reacción de ganancia, error de potencia de salida y distorsión espectral total ya se definieron en las Ecs. 4.3.6–4.3.8. En el Objetivo 3 esas métricas se usan para caracterizar el *ground truth* en condiciones nominales; en el Objetivo 4 se aplican para contrastar condiciones nominales vs. perturbadas y cuantificar cómo la incertidumbre altera la dinámica de la cascada y sus errores predictivos.

4.4.4. Evaluación de modelos predictivos bajo propagación de error

Con el fin de evaluar qué tan robustos son los modelos basados en datos frente a la incertidumbre acumulada en la cascada, se contrastó el *Ground Truth* experimental con las predicciones generadas por las arquitecturas ANN descritas en el Objetivo 2. Se analizaron dos enfoques complementarios de modelado:

- **Modelo Benchmark Generalizado (Wang):** Un modelo global, entrenado con un conjunto masivo de datos externos, aplicado de manera uniforme para predecir la respuesta de cualquiera de los amplificadores del enlace.
- **Modelos Especialistas Locales (Transfer Learning):** Cuatro modelos

independientes, ajustados con datos experimentales propios, cada uno especializado en un EDFA específico de la cascada ($S1$, $S2$, $S3$ y $S4$). En particular, estos modelos se reentrenaron a partir del modelo base de Wang mediante *transfer learning*, utilizando mediciones experimentales propias para adaptar la predicción a cada etapa.

Mecanismo de inferencia e inyección de datos: La evaluación se realizó de forma secuencial, tramo a tramo. Para estimar la respuesta en el tramo k , el modelo correspondiente recibe como entrada el mismo espectro óptico medido experimentalmente en la entrada de ese amplificador (esto es, a nivel de *input*, tanto el experimento como el modelo “ven” la misma señal en cada punto del enlace). Luego, la ganancia predicha por la red neuronal se compara directamente con la ganancia real del amplificador medida en el mismo punto (*Ground Truth*).

En este sentido, el análisis busca contrastar la forma en que se comportan los EDFAs del laboratorio frente a dicha entrada y cómo los modelos (entrenados a partir de datos de esos mismos EDFAs) reproducen ese comportamiento. La única diferencia estructural es que los modelos fueron entrenados bajo un escenario más simple (mediciones asociadas a un único *span*) y aquí se ponen a prueba en una cascada de amplificadores, donde el espectro de entrada a cada etapa ya incorpora distorsión y ASE acumulado.

Cabe destacar que cada modelo especialista corresponde al mismo amplificador en la línea, por ejemplo, en el span 1, el EDFA asociado a $S1$ corresponde al mismo dispositivo físico ubicado en la primera etapa de la línea experimental, y así con los demás amplificadores y modelos especialistas. Por tanto, el objetivo es construir una “línea digital” (predicción) que pueda compararse directamente con la línea experimental: se utilizan modelos ajustados al mismo amplificador, pero entrenados sin la dinámica completa de la cascada, para estudiar explícitamente la propagación del error al operar en condiciones más realistas.

Armonización de la resolución espectral: Por otra parte, se tuvo que garantizar consistencia física entre entrenamiento e inferencia, se unificó la resolución espectral. En los Objetivos 3 y 4, los resultados que no requerían comparación directa con predicciones (i.e., análisis puramente experimental) se obtuvieron con una resolución del OSA de 0.2 nm. Sin embargo, el modelo benchmark de Wang y su base de datos se encuentran definidos a 0.1 nm; por lo tanto, a partir de este punto, todos los resultados que involucran comparación con modelos se presentan bajo una misma resolución efectiva. Tanto el modelo

benchmark como los especialistas fueron entrenados con una RBW de 0.1 nm, mientras que las mediciones experimentales fueron capturadas a 0.2 nm. Se aplicó una corrección determinista de $-3,01$ dB ($10 \log_{10}(0,1/0,2)$) a todos los canales de entrada y a la potencia total integrada para evitar que la red interprete un exceso artificial de energía como un cambio real en el régimen de saturación.

Análisis de la Calidad de Señal: Para evaluar el impacto de la incertidumbre en la calidad de transmisión, se extrajo el perfil de OSNR por canal comparando los peaks de potencia de señal frente al promedio lineal del ruido ASE medido en ventanas adyacentes de 0.4 nm. Este análisis permite cuantificar si la recuperación de ganancia observada bajo incertidumbre logra compensar la degradación de la relación señal.

Asimetría topológica e impacto del ruido ASE (caso del Span 3): El enlace presenta una asimetría en la longitud de los tramos: el Span 3 conforma una bobina continua de 100 km, a diferencia de los demás tramos de 50 km. Esta condición no fue intencional, sino consecuencia de una limitación práctica del *setup*: se disponía únicamente de dos atenuadores ópticos variables con interfaz GUI, los cuales fueron necesarios para regular con precisión las potencias de entrada, mientras que el último atenuador del setup se ajustaba manualmente mediante perilla. Al no contar con un cuarto VOA, se mantuvo el Span 3 con 100 km como configuración viable para el experimento. Ya que lo importante era que todos tuvieran la misma potencia de entrada.

Esta configuración tiende a incrementar la acumulación de ruido ASE y, por tanto, puede inducir diferencias observables en los resultados (discusión que se retoma en la sección de resultados). Al excluir el piso de ruido de las entradas del modelo ML, se genera además un escenario exigente donde la red debe inferir la respuesta bajo una carga alterada por la topología y el ruido acumulado.

Se anticipa que, a medida que la incertidumbre se propaga y la dinámica de los amplificadores deforma el espectro (incremento de *gain ripple* y ruido), la señal recibida en el Span 4 se clasifique como con un comportamiento distinto. Cuantificar la discrepancia entre la predicción y la respuesta física en estos tramos finales constituye el núcleo de esta etapa metodológica.

En coherencia con ello, los resultados del Objetivo 4 se organizan para reflejar directamente la metodología: primero se muestra la respuesta de la cascada ante la perturbación de -3 dB en P_{in} , luego se cuantifica la reacción de ganancia y el error de potencia de salida mediante ΔG_{Avg} y ΔP_{out} (Ecs. 4.3.6 y 4.3.7), y

finalmente se mide la distorsión espectral total con RMSE (Ec. 4.3.8) y su impacto en OSNR. Esta secuencia permite comparar condición nominal vs. perturbada y atribuir los cambios observados a la propagación de la incertidumbre, garantizando consistencia entre el diseño experimental y la lectura de resultados.

4.5. Relación metodológica con la hipótesis

La metodología propuesta fue diseñada para seguir la cadena de objetivos planteada en la hipótesis, donde una incertidumbre operacional en el enlace óptico se traduce en variaciones de potencia de entrada en los EDFAs, modificando su régimen de operación y generando cambios espectrales en la ganancia y en la redistribución del ruido ASE, afectando finalmente la calidad de transmisión del sistema.

Con este propósito, modelos predictivos de referencia de la literatura, junto con modelos especialistas entrenados experimentalmente, son evaluados bajo condiciones más representativas de una línea óptica real. El análisis se desarrolla de manera incremental: primero se caracteriza el comportamiento del amplificador a nivel de componente, luego se emplea el modelo como herramienta digital para comprender la dinámica del perfil de ganancia, después, la potencia de entrada se colocó a prueba en un sistema múltispan y se evalúa su efecto en la calidad de la señal, y finalmente ambos enfoques son puestos a prueba en un último enlace experimental multispán bajo condiciones de incertidumbre operacional (potencia de entrada).

De esta forma, los resultados se presentan siguiendo la progresión del conocimiento adquirido durante el desarrollo experimental, permitiendo conectar el aprendizaje descubierto de la física mientras se avanzaba con la validación de la hipótesis.

Capítulo 5

Resultados

Los resultados se presentan siguiendo el proceso de aprendizaje experimental desarrollado durante esta investigación. Inicialmente se aborda la caracterización y entrenamiento de modelos de EDFA a nivel de componente, permitiendo comprender su comportamiento fundamental del gain ripple. Posteriormente, el modelo es utilizado como herramienta digital para analizar la dependencia del perfil de ganancia respecto de la potencia total de entrada, identificándose este parámetro como el principal factor que altera el *gain ripple*. Luego, estos conocimientos son trasladados a una línea experimental de dos span, donde se evalúa el impacto de la potencia de entrada sobre el OSNR, estos resultados sirvieron para implementar la última configuración que fue evaluada por incertidumbre bajo cuales los modelos fueron evaluados con su capacidad predictiva.

5.1. Resultados experimentales y validación

5.1.1. Construcción del dataset experimental

Este bloque responde al Objetivo específico 1, construyendo la base experimental de $G(i)$ y del *gain ripple*. Con ello se fija la referencia de ganancia frente a variaciones de potencia de entrada, clave para evaluar la incertidumbre operacional. El primer objetivo experimental consistió en caracterizar el comportamiento espectral del EDFA bajo prueba con el fin de identificar y cuantificar el fenómeno de *gain ripple*. Para ello, se utilizó la configuración final de medición mostrada en la Fig. 5.1.1, donde el espectro de entrada es previamente ecualizado mediante el WSS.

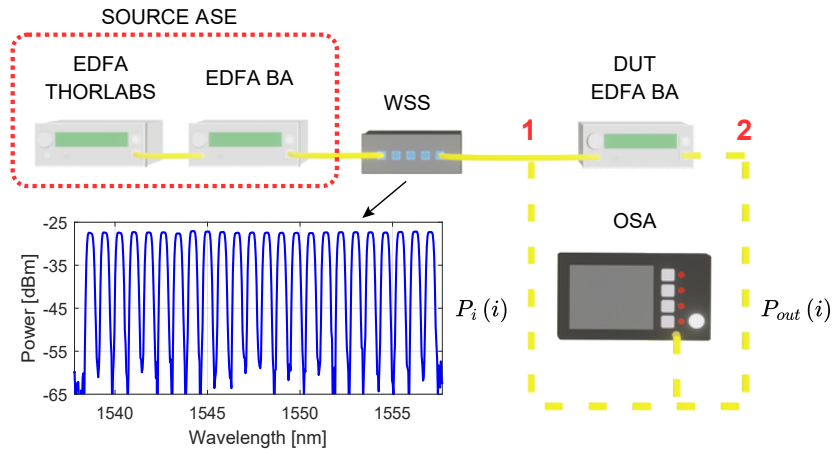



Figura 5.1.1: Configuración final de medición del EDFA bajo prueba. El OSA registra el espectro de potencia de entrada ecualizado en el punto (1) y el espectro de salida amplificado en el punto (2).

Como se comentó anteriormente en la metodología, incluso cuando el *tilt* se configura en 0° (para regular la ganancia de los EDFAs), este fenómeno no se elimina por completo. La Fig. 5.1.2 presenta la comparación entre el espectro de entrada plano y el espectro amplificado a la salida del EDFA. A pesar de operar con inclinación configurada en 0° , se observan ondulaciones residuales de ganancia entre canales, evidenciando la presencia de *gain ripple*.



(a) Espectro a la entrada del EDFA.

(b) Espectro a la salida del amplificador.

Figura 5.1.2: Comparación entre el espectro de entrada y el espectro de salida del EDFA.

En la parte (a) de la figura se observa un espectro de entrada casi plano, ya que la diferencia entre el canal de mayor potencia y el de menor potencia es de sólo 0.57 dB. En cambio, en (b), una vez que el amplificador aplica la ganancia configurada, se muestran espectros más marcados, ya que la diferencia aumenta hasta 1.63 dB, lo que evidencia la presencia de *gain ripple*. Este comportamiento es problemático, ya que implica que algunos canales reciben más ganancia que otros,

generando un desbalance de potencias que se acumula a lo largo de la cascada y puede degradar el OSNR.

Esta figura confirma la presencia de *gain ripple*; por ello, se ajustaron las condiciones de entrada del EDFA para extraer las muestras que alimentan el siguiente objetivo.

5.1.2. Entrenamiento del modelo ANN para predecir el gain ripple

Este bloque responde al Objetivo específico 2: entrenar y comparar modelos para predecir $G(i)$. Verifica la hipótesis en condiciones de un solo tramo y prepara la evaluación de su pérdida de validez bajo incertidumbre operacional.

5.1.2.1. Parte 1: Modelo de EDFA exploratorio

La Fig. 5.1.3 muestra un ejemplo de la validación del modelo ANN, donde se comparan las curvas de ganancia medidos experimentalmente y los espectros predichos por la red neuronal para una ganancia objetivo fija de $G_{obj} = 20,5$ dB y diferentes potencias totales de entrada.

En la figura, las curvas sólidas corresponden a las mediciones experimentales, mientras que las curvas discontinuas representan las predicciones del modelo. En términos cuantitativos, el modelo entrenado alcanzó un Error Absoluto Medio (MAE) de 0.04 dB en el conjunto de validación. Este valor indica que, en promedio, la ganancia predicha por canal difiere sólo en 0.04 dB respecto de la ganancia medida; por ejemplo, si para un canal se mide una ganancia de 20.50 dB, el modelo típicamente entregaría una predicción cercana a 20.46–20.54 dB.




Figura 5.1.3: Comparación entre espectros de ganancia reales (líneas sólidas) y predichos (líneas discontinuas) para un G_{obj} fijo de 20.5 dB y distintas potencias de entrada.

Se aprecia como las curvas se superponen entre sí a lo largo de toda la banda, no solo en la ganancia promedio sino también en la forma del espectro, incluyendo el *tilt* y el *gain ripple*. Esto indica que el modelo logra reproducir con alta precisión la dinámica real del EDFA, y con esto el *gain ripple*.

Con esta validación, el modelo puede utilizarse como un gemelo digital del amplificador, permitiendo estudiar de forma paramétrica el comportamiento del *gain ripple* y otras métricas sin necesidad de realizar nuevas mediciones experimentales en el laboratorio.




Figura 5.1.4: Análisis de sensibilidad del perfil de ganancia predicho frente a variaciones en (a) la ganancia objetivo, (b) la potencia total de entrada y (c) la carga espectral (número de canales).

La Fig. 5.1.4 reúne tres análisis de sensibilidad del perfil de ganancia predicho, donde se varía un parámetro a la vez y se mantienen fijos los demás, siguiendo la metodología descrita previamente. Más que el procedimiento, aquí interesa observar cómo responde la forma espectral ante cada perturbación.

En (a) se muestra la variación del perfil al modificar únicamente la ganancia objetivo G_{target} . En general, el comportamiento es estable en toda la banda. Sin embargo, al aproximarse a la región de saturación (cerca de 20,5 dB), el *gain ripple* comienza a acentuarse, mostrando que el amplificador deja de comportarse de forma casi lineal y entra en un régimen donde pequeñas variaciones generan deformaciones más visibles en el espectro.

La subfigura (b) muestra un efecto mucho más alterado al variar la potencia total de entrada $P_{\text{in,total}}$ manteniendo fija la ganancia objetivo y la cantidad de canales. En este caso, no solo cambia el nivel promedio, sino que se modifica de manera la forma completa de la curva, ya que en los extremos el EDFA llega a la ganancia objetivo, pero en el centro este tiene casos en los que no. Las potencias más altas inducen mayor deformación, mientras que los niveles intermedios se ajustan a la referencia de 17 dB. Esto confirma que la **potencia de entrada es un parámetro crítico en la definición del perfil espectral de salida.**

Finalmente, en la subfigura (c) se observa el impacto de la carga espectral N_{ch} . A medida que disminuye el número de canales activos, el amplificador experimenta menor saturación y, en consecuencia, aumenta la ganancia promedio entregada.

Por último, con el fin de resumir el comportamiento del perfil de ganancia bajo las distintas variaciones de parámetros, la Tabla 5.1.1 presenta un resumen de las métricas calculadas para cada estudio de sensibilidad. En particular, se incluyen los valores mínimos, máximos y promedios del *gain ripple*, así como de las métricas MND y MPD, obtenidas a partir de los perfiles de ganancia generados por el modelo ANN.

Cuadro 5.1.1: Resumen de las métricas obtenidas para cada análisis de sensibilidad del perfil de ganancia.

Parámetro variado	Min-Max Ripple (dB)	Ripple promedio (dB)	Min-Max MND (dB)	MND promedio (dB)	Min-Max MPD (dB)	MPD promedio (dB)
G_{obj}	[0.49 : 0.61]	0.55	[-0.63 : -0.09]	-0.21	[0.00 : 0.19]	0.13
$P_{in,total}$	[0.44 : 0.60]	0.53	[-0.15 : 0.00]	-0.05	[0.14 : 0.48]	0.22
N_{ch}	[0.06 : 0.52]	0.33	[0.00 : 0.00]	0.00	[0.14 : 0.25]	0.21

La Tabla 2 resume de manera completa el experimento de análisis de sensibilidad. Conviene recordar que la métrica MND cuantifica cuánto le faltó a la curva de ganancia para alcanzar el valor objetivo, mientras que MPD mide cuánto lo excedió. Ambas métricas fueron definidas para evaluar el impacto potencial de estas desviaciones en escenarios de red reales.

Se observan dos comportamientos relevantes de esta tabla. Primero, al reducir el número de canales (N_{ch}), se obtiene un MND promedio igual a 0. Esto podría interpretarse como una coincidencia con la ganancia objetivo. Sin embargo, es importante considerar que este análisis se realizó con una potencia de entrada fija de -6 dBm. Si se revisa la subfigura (b) de la Fig. 5.1.4, se aprecia que en ese régimen la curva se sitúa por encima del valor objetivo. Por lo tanto, el hecho de que MND sea cero no implica ausencia de desviación, sino que el sistema en un régimen donde hay más ganancia. De aquí se extrae una conclusión clave: **potencia de entrada es el parámetro que determina si el perfil de ganancia tenderá a exceder el objetivo o a quedar por debajo de él.**

El segundo punto relevante es que todos los casos presentan valores positivos de MPD. Esto indica que, en la práctica, el amplificador tiende a entregar más ganancia de la requerida en algún punto del espectro.

En conjunto, estos resultados confirman que el *gain ripple* puede reproducirse de manera consistente y que el parámetro que más lo altera es la potencia de entrada. Esto establece a P_{in} como el factor dominante en la configuración del perfil de ganancia del EDFA, y deja planteado el puente hacia el Objetivo 3 parte 2: evaluar el comportamiento de los EDFAs bajo distintos niveles de potencia de

entrada y cómo esto se refleja, en una línea de dos spans, en el perfil de ganancia del amplificador.

5.1.2.2. Parte 2: Modelo de Wang y modelos especializados

En esta sección se entrena y evalúa un conjunto de modelos de ML para ganancia bajo las condiciones reportadas en la literatura, tomando como referencia el modelo de Wang, y se construyen modelos especializados mediante *transfer learning* usando datos de los EDFAs del laboratorio. El objetivo es verificar que ambos enfoques aprendan correctamente el *gain ripple* (MAE bajo y curvas coherentes) y evaluar su capacidad de generalización para ser utilizados posteriormente en una línea multispán. En otras palabras, esta parte valida que tanto el modelo global como los especialistas quedan listos para el Objetivo 4, donde se estudiará su desempeño predictivo bajo condiciones reales de cascada.

Se evaluó inicialmente el modelo base entrenado con el dataset COSMOS, el cual actúa como referencia para la posterior transferencia de conocimiento de los EDFAs del laboratorio. La Figura 5.1.5 muestra la evolución del MAE durante el entrenamiento.

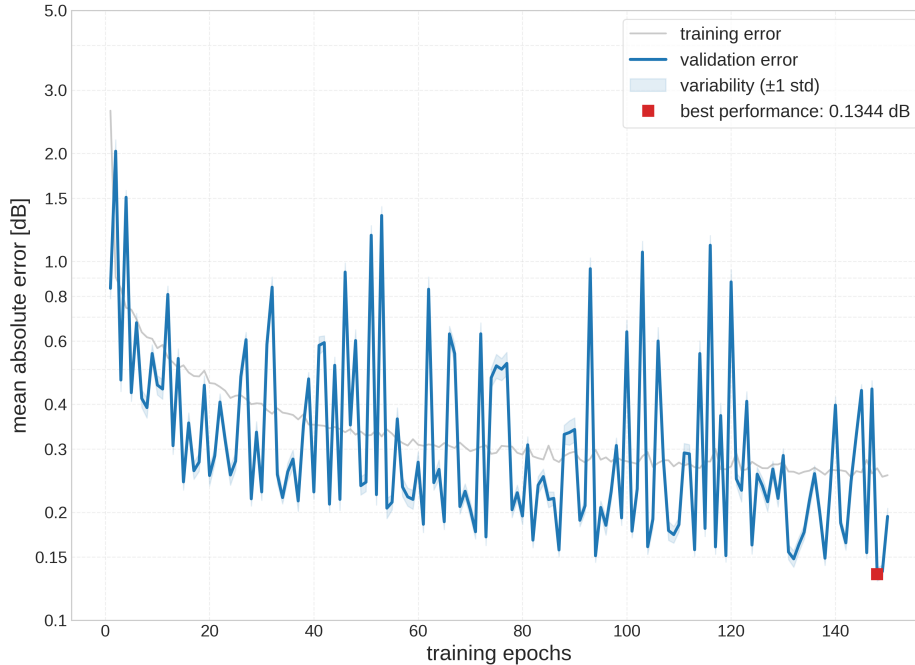


Figura 5.1.5: Curva del modelo base (Wang-PA). Se presenta el error de entrenamiento (gris) y validación (azul).

Como se observa en la Figura 5.1.5, el modelo alcanza una precisión de **0.1344 dB**, superando los valores reportados originalmente en [24] que eran de **0.17–0.24 dB**.

El error de entrenamiento y validación evolucionan de forma coherente, lo que indica una buena generalización. Esto confirma que la red logró capturar la dinámica espectral dominante de la ganancia, estableciendo una base sólida para la etapa de los modelos especializados. Por otra parte, estos resultados mejorados pueden deberse a la selección específica del dataset entrenado con sólo las muestras de preamplifiers (PA).

Para validar la metodología, se comparó el proceso de los EDFAs especializados utilizando *transfer learning* frente a un entrenamiento desde cero (*random initialization*). Los resultados para los cuatro amplificadores del sistema se presentan en la Figura 5.1.6.




Figura 5.1.6: Comparación de la convergencia aleatoria (gris puntuado) y con *transfer learning* (azul continuo).

La Figura 5.1.6 muestra cuando el modelo parte desde pesos aleatorios, la convergencia es más inestable. En cambio, al inicializar con los pesos del modelo base, la reducción del error es más rápida y suave. Esto indica que la red no necesita reaprender la física general del EDFA, sino únicamente ajustar detalles específicos de los amplificadores del laboratorio.

Con el entrenamiento completado, se definió el MAE estable como el promedio de las últimas 10 épocas, con el fin de evitar sesgos asociados a mínimos. La Figura 5.1.7 resume el desempeño final de cada especialista en comparación con el modelo global.

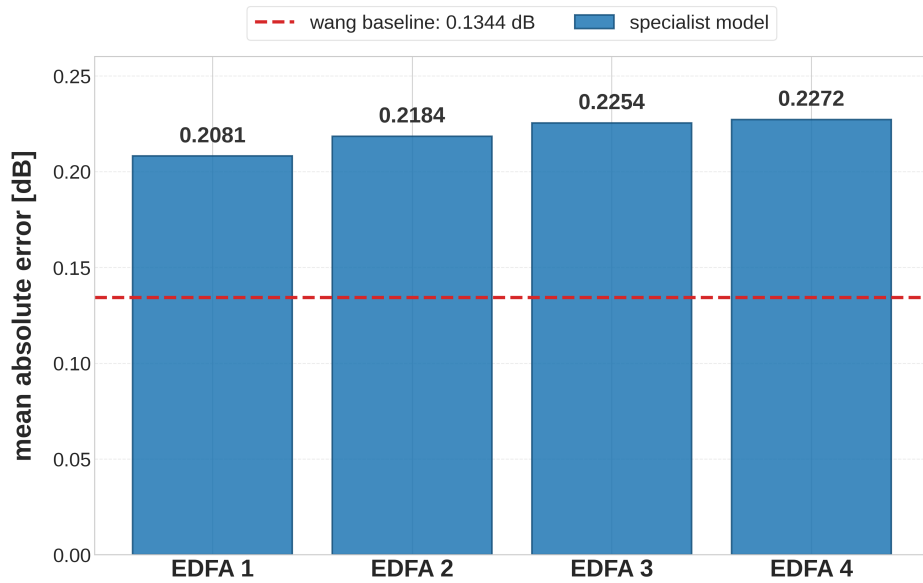


Figura 5.1.7: Comparación del MAE estable por amplificador. La línea roja indica el desempeño del modelo global de Wang como referencia.

Los resultados muestran una alta consistencia entre amplificadores. Los cuatro modelos entrenados presentan errores cercanos a 0,20 – 0,22 dB. Lo que es normal considerando que hay muchas menos muestras, y correcto dado que se encuentra en el rango de resultados que se estableció en el paper de WANG, señalando que es normal tener este tipo de resultados.

Finalmente, se evaluó el residuo espectral canal por canal para descartar sesgos en la banda C. La Figura 5.1.8 presenta el MAE por canal para el modelo base y el promedio de los especialistas.

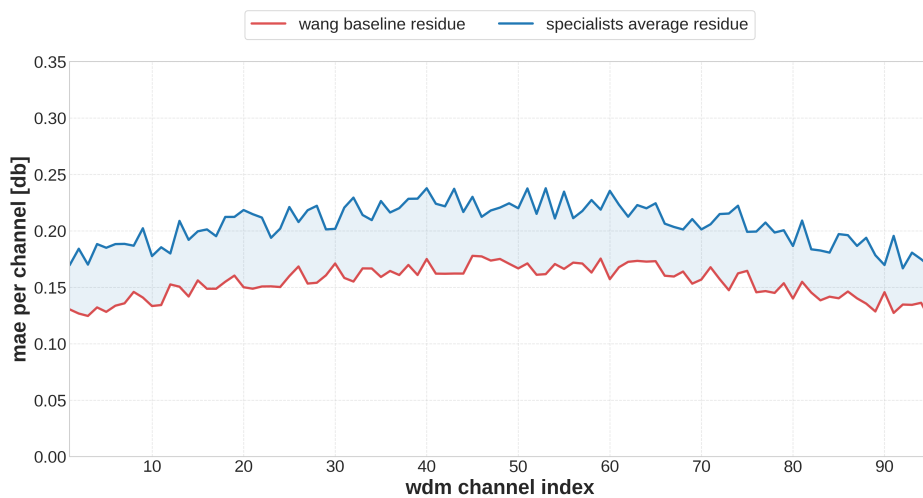


Figura 5.1.8: MAE por canal en los 95 canales WDM de la banda C. Se compara el modelo base con el promedio de los modelos especialistas.

El residuo se distribuye de forma casi homogénea a lo largo del espectro, sin errores críticos en la banda C. Esto señala que los modelos especializados mantienen un error un poco mayor que el modelo base, con un leve desplazamiento vertical, lo que indica que la especialización no altera la coherencia de la predicción del *gain ripple*. En conjunto, estos resultados confirman que la estrategia de aprendizaje de modelo global seguido de especialización local es estable, consistente y podría ser utilizado para los posteriores objetivos.


5.1.3. Caracterización experimental del enlace multi-tramo

Este bloque responde al Objetivo específico 3: establecer el *ground truth* multispán de ganancia y OSNR. Aquí se observa la propagación multispán y la evolución del *gain ripple* y del OSNR.

En esta sección se describe el protocolo experimental utilizado para (i) cuantificar la variabilidad espectral de la ganancia (*gain ripple*) y del ruido ASE bajo cambios de condiciones operacionales, y (ii) evaluar cómo dichas variaciones inducen error en la estimación de OSNR en cascadas de EDFAs. La estructura metodológica se organiza como **ganancia** \rightarrow **ruido ASE** \rightarrow **OSNR** y, cuando corresponde, se reporta tanto una vista *hop-by-hop* (por etapa S_i) como una vista global (*end-to-end*) a partir de la comparación S_1 vs. S_4 .

5.1.3.1. Parte 1: Enlace de dos tramos (calibración y cuantificación del error espectral de OSNR)

El objetivo de esta etapa fue analizar cómo evolucionan los perfiles de ganancia cuando una señal WDM atraviesa una cadena de dos EDFAs bajo distintos niveles de potencia de entrada, utilizando sólo mediciones experimentales.



(a) Perfil de ganancia experimental del primer EDFA.

(b) Perfil de ganancia experimental del segundo EDFA.


Figura 5.1.9: Perfiles de ganancia experimental en el enlace de dos tramos para distintos niveles de potencia de entrada

La Fig. 5.1.9 muestra los perfiles de ganancia del primer EDFA (a) y del segundo EDFA (b). En el primer tramo, las curvas presentan una forma relativamente más contenida y estable a lo largo de la banda. Aunque el dispositivo fue configurado con una ganancia objetivo de 20.5 dB, el promedio medido se situó en torno a 19.3 dB, evidenciando una desviación sistemática respecto al valor nominal.

En contraste, el segundo EDFA se aproxima mucho más al objetivo de 20.5 dB en términos de ganancia promedio. Sin embargo, esta tiene una mayor deformación espectral. En la subfigura (b) se aprecia un incremento del *ripple* y una mayor dispersión entre curvas, lo que indica acumulación de efectos heredados del primer tramo.

Adicionalmente, se observa una tendencia que **a mayores niveles de de entrada, el *gain ripple* se aumenta**, mientras que a potencias más bajas el perfil resulta más suave. Esto confirma que el cerca régimen del saturación por la potencia de entrada condiciona la forma del espectro.

La Fig. 5.1.10 muestra el error espectral del OSNR para el primer y segundo EDFA, respectivamente, bajo las distintas condiciones de potencia de entrada. En conjunto, permiten visualizar la distorsión espectral introducida por cada amplificador y su evolución a lo largo de la cascada.



(a) Error espectral del OSNR en el primer EDFA.

(b) Error espectral del OSNR en el segundo EDFA.

Figura 5.1.10: Error espectral del OSNR en el enlace de dos tramos para distintos niveles de potencia de entrada

La Fig. 5.1.10 presenta el ΔOSNR , definido como la diferencia entre dos enfoques de estimación: (i) un modelo analítico que asume una ganancia plana y fija de 20.5 dB en toda la banda C, y (ii) un modelo dependiente de canal que considera el *gain ripple* real, es decir, la ganancia efectiva en función del *peak* espectral de cada canal. La curva mostrada corresponde a esta discrepancia entre ambos enfoques.

En la subfigura (a), correspondiente al primer EDFA, se observa que ignorar el *gain ripple* introduce errores en el OSNR, especialmente en los extremos de la banda C, donde las desviaciones alcanzan valores del orden de 0.5 a 1.2 dB y en el centro de la banda establecerce a erorres de menos 0.5 dB. Esto evidencia que

la ganancia plana subestima o sobreestima la calidad de señal dependiendo de la región espectral.

En el segundo EDFA (b) el comportamiento cualitativo es similar, aunque la magnitud del error es menor. Una posible explicación es que el primer amplificador no alcanzó completamente la ganancia objetivo, reduciendo la discrepancia entre el modelo plano y el perfil real acumulado en la segunda etapa. En conjunto, estos resultados confirman que despreciar el *gain ripple* puede inducir errores no despreciables en la estimación de OSNR, particularmente en los bordes espectrales.

Para resumir cuantitativamente los resultados obtenidos, la Tabla 5.1.2 presenta las principales métricas extraídas de los perfiles de ganancia y del error de OSNR para ambos amplificadores, incluyendo el *gain ripple*, la desviación estándar del perfil de ganancia y el valor promedio del error absoluto de OSNR bajo cada condición de potencia de entrada.

Cuadro 5.1.2: Resumen experimental del gain ripple y OSNR en enlace de dos tramos.

Input Power (dBm/ch)	EDFA 1			EDFA 2		
	Ripple (dB)	Std. Dev. (dB)	Avg. $ \Delta OSNR $ (dB)	Ripple (dB)	Std. Dev. (dB)	Avg. $ \Delta OSNR $ (dB)
5	1.86	0.18	0.52	1.44	0.20	0.41
4	1.80	0.17	0.49	1.33	0.19	0.38
3	1.68	0.15	0.43	1.12	0.18	0.29
2	1.35	0.16	0.33	0.90	0.19	0.24
1	1.28	0.15	0.31	0.77	0.18	0.21
0	1.10	0.16	0.26	0.69	0.19	0.19
-1	1.02	0.16	0.22	0.59	0.18	0.16
-2	0.77	0.15	0.16	0.55	0.19	0.12
-3	0.68	0.21	0.13	0.46	0.21	0.11
-4	0.52	0.17	0.10	0.43	0.20	0.09
-5	0.46	0.17	0.09	0.49	0.24	0.10

La Tabla 5.1.2 confirma cuantitativamente lo que ya se observaba en las figuras: el comportamiento del *gain ripple* y del error de OSNR está correlacionado con la potencia de entrada.

El resultado más relevante es la variación del *ripple* en función de P_{in} . En el EDFA 1, el *ripple* disminuye desde 1.86 dB (5 dBm/ch) hasta 0.46 dB (-5 dBm/ch), lo que corresponde a una reducción aproximada de casi el 75%. En el EDFA 2 se observa un comportamiento similar, pasando de 1.44 dB a 0.49 dB. Esto confirma experimentalmente que la potencia de entrada introduce cambios directos en el perfil de ganancia del EDFA (*gain ripple*).

Por otra parte, el error promedio de OSNR sigue la misma tendencia. En el EDFA 1 disminuye desde 0.52 dB hasta 0.09 dB, mientras que en el EDFA 2 pasa de 0.41 dB a 0.10 dB. Estos valores evidencian que ignorar el *gain ripple* puede

introducir errores cercanos a 0.5 dB por amplificador; en un enlace de dos tramos esto ya es significativo, y en cascadas más largas la penalización puede acumularse de forma crítica.

Finalmente, la desviación estándar del perfil de ganancia se mantiene relativamente estable entre 0.15 y 0.24 dB.

Otro aspecto relevante es que el EDFA 1 presenta mayor *ripple* y mayor error promedio de OSNR que el EDFA 2 en la mayoría de las condiciones de potencia. Esto sugiere que pequeñas desviaciones respecto a la ganancia objetivo amplifican el error entre el modelo idealizado y el comportamiento real del dispositivo. En conjunto, estos resultados muestran que cambios en P_{in} alteran el *gain ripple* y, por ende, el OSNR, ya que en sólo dos spans puede variar casi en 1 dB la elección de esa potencia de entrada; si esas variaciones de potencia provienen de incertidumbres de la red, el perfil de ganancia se deforma de manera distinta según el régimen operativo.

De aquí surge la necesidad de estudiar cómo esa incertidumbre en potencia se propaga en una línea de más *spans* y cómo afecta la acumulación de ASE por amplificación. También aparece la otra duda ¿basta con comparar entrada y salida del enlace (end-to-end) o es necesario evaluar la evolución tramo a tramo (hop-by-hop)? Estas preguntas motivan y dan inicio a la Parte 2 del Objetivo 3.

5.1.3.2. Parte 2: Enlace de cinco tramos (caracterización *ground truth* y síntesis global/evolutiva)

Siguiendo los objetivos específicos y la validación de la hipótesis, esta parte introduce el *ground truth* multispán que servirá como referencia experimental del comportamiento real del enlace. El propósito es observar cómo se acumulan la distorsión de ganancia y el ruido ASE a medida que la señal atraviesa la cascada, y contrastar ese efecto tanto en una lectura global (*end-to-end*) como en una lectura progresiva (*hop-by-hop*). Esto permite evaluar si las métricas derivadas de un solo *span* se mantienen válidas en una línea completa y prepara la base comparativa para los análisis posteriores.

La validación experimental se llevó a cabo mediante la implementación en laboratorio del enlace multispán descrito en la metodología (Fig. 4.3.3). La Fig. 5.1.11 muestra todo el setup, donde se pueden ver los cuatro EDFAs en cascada, el WSS utilizado para el moldeo espectral, los atenuadores ópticos variables (VOAs) empleados para el control de potencia y los tramos de fibra de 50 km y 100 km. El OSA se utilizó para registrar los espectros requeridos tanto en la fase de caracterización como en las evaluaciones posteriores.




Figura 5.1.11: Imagen del montaje experimental implementado en el laboratorio.

Antes de analizar en detalle los perfiles de ganancia, es necesario verificar el correcto funcionamiento operativo de los cuatro EDFAs dentro del montaje experimental. En resumen, se evaluó la relación entre la potencia de salida (P_{out}) y la potencia de entrada (P_{in}) bajo las siguientes condiciones de carga: 95, 48 y 25 canales activos.




Figura 5.1.12: Potencia de salida (P_{out}) en función de la potencia de entrada (P_{in}) para los cuatro EDFAs del sistema, bajo cargas de 95 y 48 canales. La línea punteada representa la condición de ganancia unitaria ($P_{out} = P_{in}$).

La Figura 5.1.12 muestra que, para todos los amplificadores (S1, S2, S3, S4), existe una relación lineal entre P_{in} y P_{out} en el rango de operación. La pendiente es consistente y la separación respecto a la línea de ganancia unitaria confirman que los dispositivos no presentan comportamiento de inestabilidad.

5.1.3.2.1 *Ground truth* del enlace óptico y condiciones de evaluación:

Se construyó la referencia experimental (*ground truth*) del enlace multi-span a partir de mediciones OSA en cada etapa de amplificación (S_1 , S_2 , S_3 y S_4). En cada figura de los resultados se asocia a un **camino metodológico**: (i) medición de espectros de entrada/salida por etapa, (ii) cálculo de perfiles (ganancia, ruido ASE u OSNR) y (iii) síntesis mediante métricas globales (*end-to-end*) o evolución por etapa (*hop-by-hop*).

5.1.3.2.2 Ganancia espectral: perfiles medidos por carga de canales (*ground truth*).

Las Fig. 5.1.13 presenta los perfiles de ganancia medidos para cargas de 95 canales.




Figura 5.1.13: Perfil de ganancia experimental para el escenario de **Carga Completa (95 Canales)**. Se muestran las curvas de los cuatro amplificadores de la cascada (S1, S2, S3, S4).

En los tres casos se observa que al variar la potencia total de entrada, la potencia de salida promedio disminuye levemente y el perfil espectral se deforma tramo a tramo, generando un *ripple* que se acumula a lo largo de la cascada. Este efecto es más evidente en los últimos amplificadores, donde las curvas muestran mayor *ripple* y separación respecto de S1. En términos de carga, se aprecia que al reducir el número de canales, el *ripple* tiende a ser menos pronunciado, mientras la ganancia media se mantiene comparable entre escenarios. Todas estas configuraciones se utilizarán como base de comparación entre el *ground truth* experimental y los modelos predictivos en las etapas posteriores.

Antes de pasar al OSNR, se identifican dos falencias del sistema que se complementan y que afectan directamente la interpretación de los resultados y el uso de modelos de ML. La primera es la menor ganancia en S_3 , causada por la topología del enlace (100 km de SSMF), que introduce atenuación espectral y mayor ASE; este efecto se decide conservar para mantener realismo y evaluar robustez. La segunda es la discrepancia entre la potencia total reportada por la GUI del EDFA (señal + ASE) y la potencia efectiva de los *peaks* usada para etiquetar los datos; esta diferencia crece en S_3 por la mayor carga de ASE. La estrategia adoptada es trabajar con la convención de *peaks* y con datos crudos del OSA, de modo de preservar el comportamiento observado y tensionar a los modelos bajo condiciones reales. Estas dos condiciones explican por qué el *ground truth* no

es ideal y anticipan cómo la propagación de ASE y la variación de potencia efectiva pueden degradar la generalización de los modelos en una cascada multispan.

Un punto relevante es la menor ganancia observada en S_3 . Este comportamiento se repite en todas las figuras y explica parte del aumento de *ripple* en S_4 , ya que el último amplificador debe compensar un espectro de entrada más atenuado. La causa está en la topología: el tramo previo a S_3 incluye 100 km de SSMF (los otros son fibra + atenuador), lo que introduce atenuación dependiente de longitud de onda y mayor carga de ASE. En consecuencia, S_3 opera con una condición de entrada más desfavorable y entrega una ganancia media inferior.

Para mantener un escenario realista, se decidió conservar este efecto y se trabaja con la distinción entre **potencia total** reportada por el EDFA (señal + ASE) y **potencia efectiva de los peaks** usada para etiquetar los datos. En el experimento, las potencias totales objetivo fueron **-21 dBm, -14 dBm y -6 dBm**, mientras que las etiquetas de potencia efectiva corresponden a **-24 dBm, -17 dBm y -9 dBm**. Esta discrepancia es crítica en S_3 por la mayor carga de ASE y el sesgo espectral; por ello se utilizan datos crudos del OSA para preservar el comportamiento observado y evaluar la robustez de los modelos.

La Fig. 5.1.14 resume esta condición mostrando la evolución de los espectros a la entrada y salida de cada etapa bajo la etiqueta de potencia efectiva más restrictiva (-24 dBm).




Figura 5.1.14: Evolución espectral de la cascada. (Izquierda) Espectros a la entrada de cada EDFA. En las leyendas se indica la potencia total integrada por el OSA (P_{Total}), la cual suma la energía de los canales y el ruido ASE. (Derecha) Espectros a la salida de cada etapa evidenciando la caída de ganancia en S_3 .

En (A) se observa que el espectro de S_3 presenta menor potencia y, en (B), que el amplificador eleva los peaks pese a la deformación; en la práctica, los *peaks* de S_3 quedan por encima de los demás, por lo que el EDFA entrega menor ganancia para

alcanzar la misma potencia de salida. En coherencia con esto, la gráfica de entrada (Fig. 5.1.14, izquierda) muestra que, aunque el control reporta una entrada estable, el OSA evidencia divergencias: en S_1 , S_2 y S_4 la potencia total se mantiene cercana a lo esperado, mientras que en S_3 aparece una potencia integrada distinta (p. ej., -18.8 dBm), con **peaks más bajos** y **piso ASE**, anticipando menor ganancia efectiva.

La causa raíz de esta degradación radica en la topología del enlace (Fig. 5.1.15).




Figura 5.1.15: Perfil de atenuación espectral por tramo.

El enlace de transmisión se compone de tres tramos inter-amplificador. El primer tramo ($S_1 \rightarrow S_2$) usa 50 km de fibra más un VOA, mientras que el tercero ($S_3 \rightarrow S_4$) usa un VOA con caída de 20 dB; ambos presentan pérdidas prácticamente planas. En cambio, el tramo previo a S_3 incluye 100 km de SSMF, lo que introduce inclinación espectral y mayor ASE, sesgando el control del EDFA y reduciendo la ganancia efectiva. **Implicancia metodológica:** esta discrepancia entre potencia de control y potencia espectral real es una fuente de incertidumbre que se preserva para tensionar los modelos bajo condiciones reales.

5.1.3.2.3 Convención de potencia: GUI del EDFA vs. potencia estimada por *peaks*.

A lo largo de esta tesis, la potencia nominal de entrada se reporta según el valor objetivo configurado en la GUI del EDFA (potencia total que incluye señal y contribuciones como ASE), es decir se tomaba como muestra -24 dBm cuando en el EDFA marcaba esa potencia, pero la muestra se guardaba con la potencia total recibida de los peaks, que podría ser -26 dBm. Sin embargo, para el procesamiento de datos y el entrenamiento/validación de los modelos predictivos, la potencia total de entrada (P_{in}) se definió bajo la *convención de peaks*, es decir, como la suma de potencias de los canales WDM detectados en el espectro (señal), sin integrar el piso ASE (esto para seguir los pasos de Wang). En consecuencia, para un mismo régimen nominal en GUI (p. ej., -24 dBm), el valor P_{in}^{peaks} tiende a

ser ~ 3 dB menor, y además puede decaer a lo largo de la cascada debido a la acumulación de ASE y a la forma espectral. Esta elección es consistente con el *pipeline* de Wang y con el esquema de entrenamiento de los especialistas, por lo que todas las comparaciones de incertidumbre y desempeño ML se mantienen en la misma convención.




Figura 5.1.16: Evolución de la potencia de entrada estimada mediante la suma de *peaks* (P_{in}^{peaks}) a lo largo de la cascada de amplificadores para los tres regímenes nominales. Aunque la condición de potencia se fija desde la GUI del EDFA, la potencia estimada únicamente a partir de los canales WDM (señal) presenta variaciones tramo a tramo debido a la acumulación de ASE y a la redistribución espectral en la cascada.




Figura 5.1.17: Variación efectiva de la potencia de entrada bajo convención *peaks*, ΔP_{in}^{peaks} , por span y régimen nominal. La línea discontinua indica la perturbación ideal de -3 dB aplicada en el primer tramo. Se observa que, aunque la perturbación se cumple en S_1 , el déficit no se conserva estrictamente en spans posteriores, evidenciando el efecto de autocompensación energética y acumulación de ASE en la cascada.

Las curvas de P_{in}^{peaks} confirman que, aunque el régimen nominal se fija desde la GUI, la potencia *estimada por señal* no permanece constante tramo a tramo: a medida que avanza la cascada, parte del presupuesto energético se transfiere desde los canales hacia el piso ASE, lo que se observa como un decaimiento (o reajuste) de P_{in}^{peaks} entre spans. Bajo esta misma convención, el chequeo de ΔP_{in}^{peaks} muestra que la perturbación de -3 dB se cumple en S_1 (donde se inyecta el VOA), pero no necesariamente se conserva en los spans posteriores: en baja potencia, el déficit

se *cierra* progresivamente desde $-3,09$ dB (S1) hasta $\approx -1,31$ dB (S4), mientras que en potencia media permanece cercano a $\approx -2,6$ dB y en alta potencia se mantiene aproximadamente en -3 dB a lo largo del enlace. Esto no es un bug, sino la firma de la autocompensación de la cascada (cambio de saturación efectivo y respuesta no lineal), y explica por qué el “ $\Delta P_{in} = -3$ dB” debe interpretarse como una condición local en la entrada del primer amplificador, no como un déficit estrictamente constante en todos los spans cuando se mide bajo P_{in}^{peaks} .

5.1.3.3. Normalización Espectral del Span 3 (S8)

Durante el análisis de los resultados experimentales se observó que la inclusión de una bobina de 100 km en el **Span 3** —equivalente al doble de la longitud de los tramos estándar de la cascada, pero sin el atenuador— introduce una atenuación adicional que desplaza el punto de operación del amplificador hacia un régimen de menor ganancia. Esta condición genera un desbalance visible en la representación de la cascada y dificulta la comparación directa de la distorsión espectral entre los distintos spans (se puede ver en la figura anterior).

Con el objetivo de mantener una visualización coherente a lo largo de la cadena de amplificación y facilitar la comparación del perfil espectral entre etapas, se aplicó una **normalización mediante una constante de ganancia** (C) a los datos de *Ground Truth* (GT) correspondientes a este tramo.

Este ajuste se realizó de forma independiente para cada escenario de carga espectral (25, 48 y 95 canales) y para cada nivel de potencia de entrada (P_{in}), de acuerdo con la siguiente relación:

$$G_{S3, \text{norm}}(\lambda) = G_{S3, \text{exp}}(\lambda) + C \quad (5.1.1)$$

donde la constante C corresponde a la diferencia entre la ganancia media del **Span 2**, considerado como referencia nominal de 50 km, y la ganancia media observada en el **Span 3**:

$$C = \overline{G}_{S3} - \overline{G}_{S2} \quad (5.1.2)$$

De esta manera, es posible ajustar el nivel medio de ganancia en S3 sin modificar la forma del *gain ripple* ni la firma espectral asociada a su régimen de saturación. Cabe destacar que esta normalización se aplicó únicamente con fines de análisis y

visualización. Las condiciones físicas reales del sistema —incluyendo la pérdida de potencia y la degradación que S3 introduce antes de la señal alcanzar el **Span 4** (**S4**)— se mantuvieron sin modificar en el conjunto de datos original, preservando así el comportamiento real de propagación de incertidumbre a lo largo del enlace.



Figura 5.1.18: Perfil de ganancia experimental para el escenario de **Carga Completa (95 Canales)**. Se muestran las curvas de los cuatro amplificadores de la cascada (S1, S2, S3, S4).



Figura 5.1.19: Perfil de ganancia experimental para el escenario de **Carga Media (48 Canales)**. Se muestran las curvas de los cuatro amplificadores de la cascada (S1, S2, S3, S4).




Figura 5.1.20: Perfil de ganancia experimental para el escenario de Carga Baja (25 Canales). Se muestran las curvas de los cuatro amplificadores de la cascada (S1, S2, S3, S4).

En general, las tres configuraciones de carga espectral presentan un comportamiento similar. A medida que la señal atraviesa etapas de amplificación, el perfil de ganancia se va deformando debido a la acumulación del gain ripple propio de cada EDFA. Este efecto puede observarse claramente al comparar los perfiles espectrales entre los primeros y últimos spans del sistema.

Mientras que en el primer amplificador el ripple se mantiene en valores cercanos a 0.6–1.1 dB, en el cuarto amplificador alcanza valores entre 1.5 y 2.9 dB dependiendo de la carga espectral y la potencia de entrada. Esto implica un aumento aproximado de hasta tres veces en la ondulación espectral de la ganancia.

Además de la acumulación del ripple, se observa la aparición de un tilt, donde las longitudes de onda cercanas a 1530 nm experimentan una ganancia mayor que aquellas hacia el extremo largo de la banda C (1565 nm). En algunos casos, esta diferencia alcanza aproximadamente 2.5–3 dB en el último amplificador.

Este comportamiento confirma que el perfil de ganancia de los EDFAs no permanece constante a lo largo de la cadena de amplificación, sino que se ve afectado por la potencia total de entrada, la carga espectral y la acumulación de ruido ASE. Como consecuencia, pequeñas variaciones en la respuesta espectral de un amplificador individual pueden amplificarse significativamente cuando múltiples etapas se encuentran en cascada.

5.1.3.3.1 OSNR: evolución espectral por etapa y por carga de canales.

Como complemento de la caracterización de ganancia, las Fig. 5.1.21, 5.1.22 y 5.1.23 muestran el OSNR en función de la longitud de onda para las configuraciones de 95, 48 y 25 canales. En cada figura se incluyen las curvas asociadas a los distintos tramos del enlace (S1–S4), lo que permite visualizar cómo el perfil espectral del OSNR se transforma a lo largo de la cascada bajo una misma condición de carga.

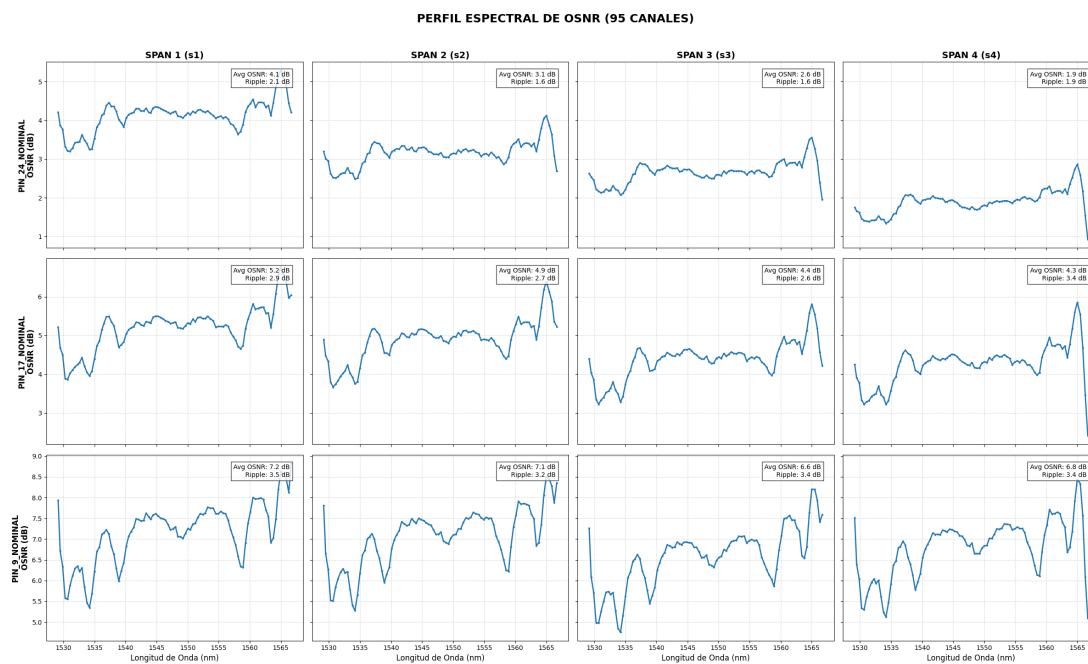


Figura 5.1.21: Evolución espectral del OSNR para la configuración de 95 canales.

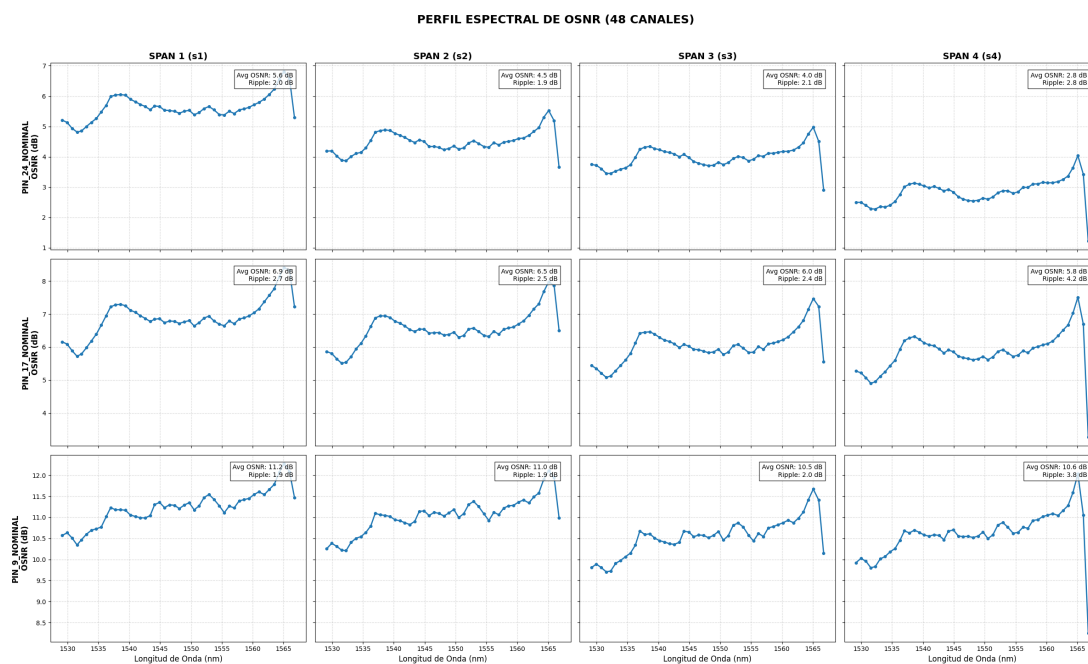


Figura 5.1.22: Evolución espectral del OSNR para la configuración de 48 canales.

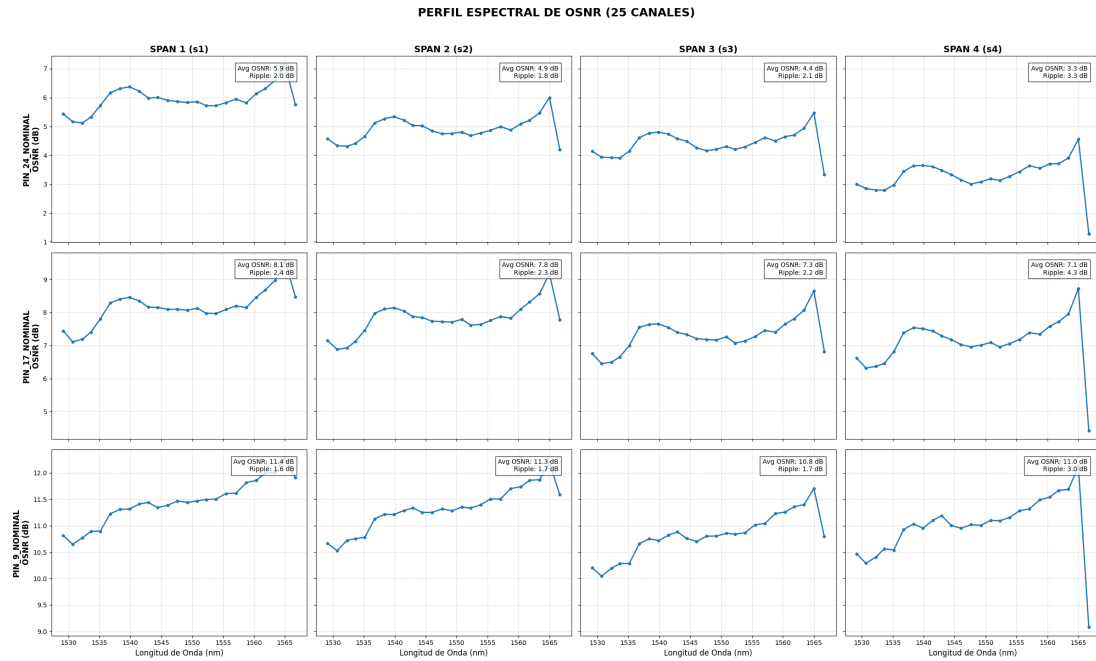


Figura 5.1.23: Evolución espectral del OSNR para la configuración de 25 canales.

En términos generales, el OSNR del sistema se mantiene relativamente bajo porque la señal ya llega a S_1 con ruido ASE acumulado de ampliificaciones previas, como se describe en la metodología. Aun así, se observa una tendencia clara: a mayor potencia de entrada, mayor OSNR promedio, ya que el nivel de señal aumenta respecto al ruido.

Este comportamiento se aprecia en las distintas cargas espectrales. Por ejemplo, con **95 canales** el OSNR promedio en S_1 aumenta de aproximadamente $\sim 4,1$ dB para $P_{in} = -24$ dBm a cerca de $\sim 7,2$ dB cuando la potencia de entrada es $P_{in} = -9$ dBm. Una tendencia similar aparece con **48 canales**, donde el OSNR pasa de $\sim 5,6$ dB a $\sim 11,2$ dB, y con **25 canales**, donde aumenta de $\sim 5,9$ dB a $\sim 11,4$ dB.

Otro efecto relevante es la disminución del OSNR a lo largo de los *spans*, causada por la acumulación de ruido ASE en la cascada de ampliificación. Por ejemplo, en el caso de 95 canales con $P_{in} = -24$ dBm, el OSNR promedio desciende de $\sim 4,1$ dB en S_1 a aproximadamente $\sim 1,9$ dB en S_4 .

También se observa un ligero aumento del *ripple* espectral del OSNR en los últimos *spans*, que en algunos casos alcanza valores cercanos a $\sim 3-4$ dB. Esto indica que la cascada de amplificadores no solo reduce el OSNR medio, sino que también introduce variaciones espectrales entre canales.

En conjunto, estos resultados muestran que una misma línea con igual número de *spans* puede presentar diferencias de varios dB en OSNR únicamente por cambios en la potencia de entrada o en la carga de canales, evidenciando la incertidumbre operativa presente en sistemas ópticos reales.




Figura 5.1.24: Comparativa *end-to-end* de métricas de ganancia en régimen de Baja Potencia (-24 dBm).




Figura 5.1.25: Comparativa *end-to-end* de métricas de ganancia en régimen de Media Potencia (-17 dBm).




Figura 5.1.26: Comparativa *end-to-end* de métricas de ganancia en régimen de Alta Potencia (-6 dBm).

En la comparación *end-to-end* entre la salida del EDFA 1 (S1) y el EDFA 4 (S4) se aprecia un efecto acumulativo claro a lo largo del enlace, consistente con la

hipótesis de propagación del *gain ripple*. Independiente del régimen de potencia y la carga, la ganancia promedio cae del orden de 1.3 dB entre el primer y el último span, mostrando que el sistema pierde ganancia a medida que la señal avanza. El *ripple* de ganancia es aún más crítico: bajo baja potencia puede pasar de aproximadamente 1.1 dB a 2.6 dB en el caso de 95 canales, mientras que en regímenes más estables la variación es más moderada, entre 0.7 y 1.4 dB. Finalmente, la degradación espectral confirma esta tendencia, con una desviación promedio cercana a 1.5 dB respecto al espectro inicial en S1, reflejando cómo el perfil se distorsiona y se acumula a través de la cadena de amplificación. Estas métricas justifican el paso a análisis más detallados (hop-by-hop) para identificar dónde se origina la mayor degradación y cómo la potencia de entrada amplifica ese efecto.

5.1.3.3.2 Piso de ruido ASE: evaluación global (*end-to-end*).

Bajo el mismo criterio de síntesis global, las Fig. 5.1.27–5.1.29 muestran la evaluación *end-to-end* del piso de ruido ASE, contrastando el estado inicial (S_1) con el estado final (S_4) para los mismos regímenes de potencia y configuraciones de carga. En cada figura se reportan las métricas definidas en metodología: potencia promedio de ruido, *noise ripple* e incremento neto de ruido acumulado en la línea.




Figura 5.1.27: Comparativa *end-to-end* de métricas de ruido (ASE) en régimen de Baja Potencia (-24 dBm).




Figura 5.1.28: Comparativa *end-to-end* de métricas de ruido (ASE) en régimen de Media Potencia (-17 dBm).




Figura 5.1.29: Comparativa *end-to-end* de métricas de ruido (ASE) en régimen de Alta Potencia (-9 dBm).

En la evaluación *end-to-end* del piso de ruido (ASE) entre S1 y S4 se observa nuevamente un efecto acumulativo claro a lo largo del enlace. En régimen de baja potencia, el piso de ruido se mantiene cercano entre el inicio y el final, con variaciones moderadas; sin embargo, a medida que aumenta la potencia de operación, la diferencia entre S1 y S4 se vuelve más alta, mostrando cómo la acumulación progresiva de ASE en la cadena de amplificación. Esta tendencia se refuerza al observar el incremento neto de ruido ($S_4 - S_1$), donde en media y alta potencia aparecen aumentos del orden de 1.4–1.8 dB, independientes del número de canales. En paralelo, el ripple de ruido también crece con la potencia, mostrando que no solo aumenta el nivel absoluto de ASE, sino que además se vuelve más irregular. En conjunto, los resultados confirman que el ruido no solo se suma, sino que también se redistribuye espectralmente a lo largo del enlace, afectando de manera acumulativa la calidad final del espectro.

5.1.3.3.3 OSNR: evaluación global (*end-to-end*).

En coherencia con las métricas anteriores, la evaluación global de OSNR resume el desempeño del enlace comparando la condición de entrada (S_1) con la salida final (S_4). En este nivel, el interés está en capturar el efecto acumulado de toda la cascada sobre la calidad óptica, sin entrar aún en el detalle de cada salto.




Figura 5.1.30: Evaluación *end-to-end* de OSNR en régimen de Baja Potencia (-24 dBm). Se muestran el OSNR promedio, la uniformidad (ripple) y la degradación neta ($S_4 - S_1$) para 95, 48 y 25 canales.




Figura 5.1.31: Evaluación *end-to-end* de OSNR en régimen de Media Potencia (-17 dBm). Comparación entre la condición de entrada (S_1) y salida (S_4) del enlace para las distintas cargas espectrales.




Figura 5.1.32: Evaluación *end-to-end* de OSNR en régimen de Saturación (-9 dBm). Se resume el efecto acumulado del enlace completo sobre el OSNR promedio, su uniformidad y la pérdida neta de calidad óptica.

En la evaluación end-to-end del OSNR entre S1 y S4 se observa un comportamiento coherente con la acumulación de ruido y la propagación del *gain ripple*. En régimen de baja potencia, el OSNR promedio disminuye bastante hacia la salida, con degradaciones netas que alcanzan valores cercanos a -0.7 dB en ciertas configuraciones, evidenciando que pequeñas variaciones de potencia de entrada pueden traducirse en pérdidas apreciables cuando se acumulan en múltiples *spans*. En media potencia, la degradación es más contenida y uniforme entre cargas espectrales (del orden de -0.3 dB), mostrando un equilibrio más estable entre ganancia y ASE acumulado. En alta potencia, la caída adicional de OSNR es menor (≈ -0.1 a -0.2 dB), ya que el mayor nivel de señal compensa parcialmente la acumulación de ruido. Respecto a la uniformidad (*ripple*), se mantiene estable entre entrada y salida, aunque tiende a incrementarse con la potencia y con menor número de canales, reflejando que el perfil no solo se reduce en nivel OSNR promedio, sino que también puede volverse menos espectralmente. En conjunto, estos resultados cuantifican la magnitud del impacto del *gain ripple* y de la potencia de entrada en la calidad óptica final: el OSNR puede degradarse varios dB en solo cuatro *spans*, lo que anticipa penalizaciones mayores en enlaces más largos.

5.1.3.3.4 Ganancia: evaluación evolutiva (*hop-by-hop*).

El segundo nivel de lectura corresponde al análisis evolutivo, donde las métricas se observan por etapa ($S_1 \rightarrow S_2 \rightarrow S_3 \rightarrow S_4$). La Fig. 5.1.33 presenta la dinámica del *gain ripple* a través de los cuatro amplificadores para las distintas cargas de canales. En paralelo, la Fig. 5.1.34 muestra la degradación espectral acumulada respecto a la referencia S_1 , permitiendo seguir la distorsión de forma conforme

avanza la cascada. Finalmente, la Fig. 5.1.35 reporta la evolución de la ganancia promedio por etapa, utilizada como indicador del nivel medio de amplificación a lo largo del enlace.




Figura 5.1.33: Dinámica evolutiva del Ripple de Ganancia (Hop-by-Hop) para las distintas cargas de canales.




Figura 5.1.34: Evolución de la Degradación Espectral Neta (Shape Distortion) acumulada respecto a S_1 .




Figura 5.1.35: Evolución de la Ganancia Promedio (Hop-by-Hop) a lo largo de las etapas de amplificación.

Al analizar la evolución por span ($S_1 \rightarrow S_2 \rightarrow S_3 \rightarrow S_4$) se observa un comportamiento claramente acumulativo y dependiente del régimen de potencia. En el *gain ripple*,

el régimen lineal (-24 dBm) presenta el mayor crecimiento hacia S4, especialmente con 95 CH, amplificándose las irregularidades iniciales, siendo el tramo S3→S4 el más crítico. En régimen medio el incremento es más gradual y casi lineal, mientras que en saturación (-9 dBm) el crecimiento es más contenido, indicando mayor estabilidad relativa bajo alta potencia.

La degradación espectral neta confirma esta dinámica: en baja potencia el aumento más significativo ocurre en los últimos spans, particularmente en S3→S4, coherente con la condición operativa de S_3 . En media y alta potencia, aunque la degradación continúa acumulándose, lo hace de manera más controlada.

Por su parte, la ganancia promedio *hop-by-hop* evidencia que el tercer span concentra la mayor variación antes de una leve recuperación en S4, mostrando que no todas las etapas impactan de igual forma. En conjunto, el análisis demuestra que la degradación se construye progresivamente a lo largo del enlace, y no únicamente en su tramo final, con una dinámica ligada al régimen de potencia y a la carga espectral.

5.1.3.3.5 Piso de ruido ASE: evaluación evolutiva (*hop-by-hop*).

Siguiendo el mismo esquema evolutivo, el piso de ruido ASE se resume mediante tres vistas complementarias. La Fig. 5.1.36 muestra la evolución del *noise ripple* por etapa para las distintas cargas, mientras que la Fig. 5.1.37 reporta la degradación de forma acumulada del perfil de ruido respecto a S_1 . Finalmente, la Fig. 5.1.38 presenta la potencia promedio de ruido por etapa, lo que permite seguir el crecimiento del nivel medio del piso de ASE a medida que la señal recorre la cascada.




Figura 5.1.36: Dinámica evolutiva de la ondulación del piso de ruido (Hop-by-Hop) para las distintas cargas de canales.




Figura 5.1.37: Evolución de la Degradación de Forma del Ruido (Shape Distortion) acumulada respecto a S_1 .




Figura 5.1.38: Evolución de la Potencia de Ruido Promedio (Hop-by-Hop) a lo largo de las etapas de amplificación.

Al analizar la evolución del ruido *hop-by-hop* ($S_1 \rightarrow S_2 \rightarrow S_3 \rightarrow S_4$) se observa una dinámica acumulativa dependiente del régimen de potencia. En el ripple del piso de ruido, el régimen lineal (-24 dBm) muestra variaciones moderadas con un máximo en S3 y una leve reducción en S4, mientras que en régimen medio (-17 dBm) el crecimiento es progresivo hasta S3 y luego tiende a estabilizarse. En saturación (-9 dBm) el incremento es casi el mismo, lo que sugiere una mayor irregularidad espectral cuando el sistema opera con alta potencia.

La degradación de forma del ruido confirma esta lectura, en baja potencia el salto más visible ocurre en $S_2 \rightarrow S_3$, y en media y alta potencia la distorsión crece de manera más continua hasta S4, reflejando una redistribución progresiva del ASE a lo largo de la cascada. En paralelo, la potencia promedio de ruido evidencia ajustes por etapa más que un crecimiento de manera lineal: en régimen lineal las variaciones son pequeñas, en régimen medio aparece una acumulación suave hacia S3, y en saturación el nivel es mayor con fluctuaciones más marcadas entre spans.

5.1.3.3.6 OSNR: evaluación evolutiva (*hop-by-hop*).

Como contraparte del análisis global, la evaluación *hop-by-hop* permite seguir cómo la OSNR cambia etapa por etapa a medida que la señal atraviesa la cascada ($S_1 \rightarrow S_2 \rightarrow S_3 \rightarrow S_4$). En estas gráficas, el eje horizontal representa las etapas del enlace y cada curva corresponde a una configuración de carga espectral distinta (95, 48 y 25 canales), lo que facilita comparar la evolución relativa bajo un mismo régimen de potencia.

En particular, esta vista permite identificar la pérdida acumulada de calidad óptica en cada salto, y al mismo tiempo contrastar cómo dicha pérdida varía al modificar la ocupación espectral del enlace.




Figura 5.1.39: Evolución *hop-by-hop* del OSNR promedio en régimen de Baja Potencia (-24 dBm). Se muestra la progresión del OSNR a través de las etapas S_1 a S_4 para 95, 48 y 25 canales.




Figura 5.1.40: Evolución *hop-by-hop* del OSNR promedio en régimen de Media Potencia (-17 dBm). Cada curva representa una configuración de carga espectral distinta.




Figura 5.1.41: Evolución *hop-by-hop* del OSNR promedio en régimen de Saturación (-9 dBm). Se visualiza la progresión acumulativa de la pérdida de calidad óptica a lo largo de la cascada.

El análisis *hop-by-hop* de la evolución del OSNR ($S_1 \rightarrow S_2 \rightarrow S_3 \rightarrow S_4$) evidencia una degradación a lo largo del enlace, con una dinámica que depende tanto del régimen de potencia como de la carga espectral.

En baja potencia (-24 dBm), el OSNR cae en cada tramo: para la configuración más cargada pasa de cerca de $4,1$ dB en S_1 a $1,9$ dB en S_4 , con una pérdida acumulada de aproximadamente $2,2$ dB. Esto muestra que, cerca del piso de ruido ASE, el sistema se vuelve especialmente sensible.

Cuando se aumenta la potencia de operación (-17 y -9 dBm), la degradación se vuelve mucho menor. En saturación, la diferencia entre S_1 y S_4 es de solo $0,3$ dB, lo que indica un régimen más estable y dominado por la señal.

En términos espectrales, el *OSNR ripple* cambia poco (de $2,0$ a $1,4$ dB en baja potencia y, en general, menos de $0,5$ dB). Por tramo, la pérdida promedio es de casi 1 dB en baja potencia, alrededor de $0,2$ dB en régimen medio y cercana a $0,1$ dB en alta potencia. En conjunto, la lectura *hop-by-hop* confirma que la degradación es acumulativa y describe mejor el comportamiento real del enlace que una evaluación solo *end-to-end*; con ello, queda establecido un *ground truth* sólido para comparar modelos y mediciones experimentales.

5.1.4. Análisis experimental del impacto de la incertidumbre

Este bloque aborda el Objetivo específico 4, cuantificando cómo la incertidumbre en potencia de entrada altera el régimen del EDFA. Así se contrasta la hipótesis sobre la amplificación del *gain ripple* y la degradación de OSNR en cascada.

El propósito de este análisis es estudiar cómo responde la cascada de EDFAs cuando la potencia de entrada experimenta una atenuación de -3 dB. Esta perturbación debería propagarse sin modificaciones a lo largo de todos los tramos, manteniendo un déficit constante de -3 dB (en la potencia, no en la ganancia), hacia todos los demás amplificadores. Sin embargo, los resultados experimentales muestran que el comportamiento del enlace es un poco más complejo, ya que esta perturbación activa la dinámica interna de los amplificadores.

5.1.4.1. Visualización de la propagación de incertidumbre

La evaluación de la incertidumbre se extendió a las tres configuraciones de carga espectral consideradas (95, 48 y 25 canales), con el objetivo de observar cómo la dinámica del enlace depende del nivel de ocupación WDM. Las Figuras 5.1.42, 5.1.43 y 5.1.44 comparan el estado nominal con el escenario bajo incertidumbre inducida ($\Delta P_{in} = -3$ dB), permitiendo seguir la evolución de la ganancia a lo largo de los distintos tramos.

En esta parte se comparan siempre condiciones equivalentes por tramo y por carga espectral: para cada *span* (S_1, S_2, S_3, S_4) se contrasta el espectro nominal con su versión bajo incertidumbre, manteniendo la misma carga WDM. Por ejemplo, se enfrenta el caso de -24 dBm en S_1 con el caso perturbado de -27 dBm en S_1 para 95 canales, y el mismo criterio se repite para S_2 vs. S_2, S_3 vs. S_3 y S_4 vs. S_4 , así como para 48 y 25 canales.

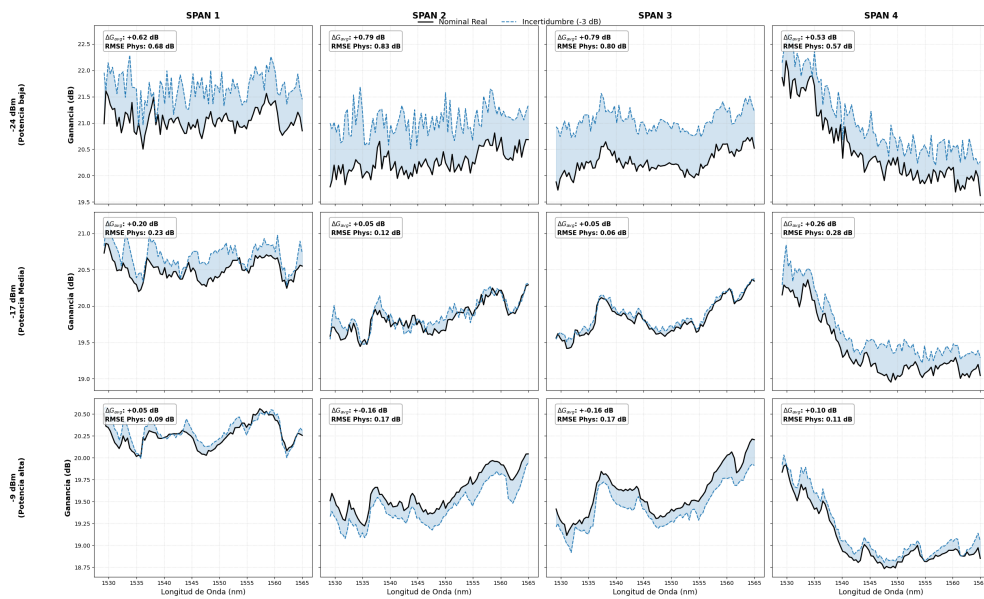


Figura 5.1.42: Evolución espectral de la ganancia bajo incertidumbre para la carga máxima de 95 canales. Curva negra: condición nominal. Curva azul: incertidumbre de -3 dB.

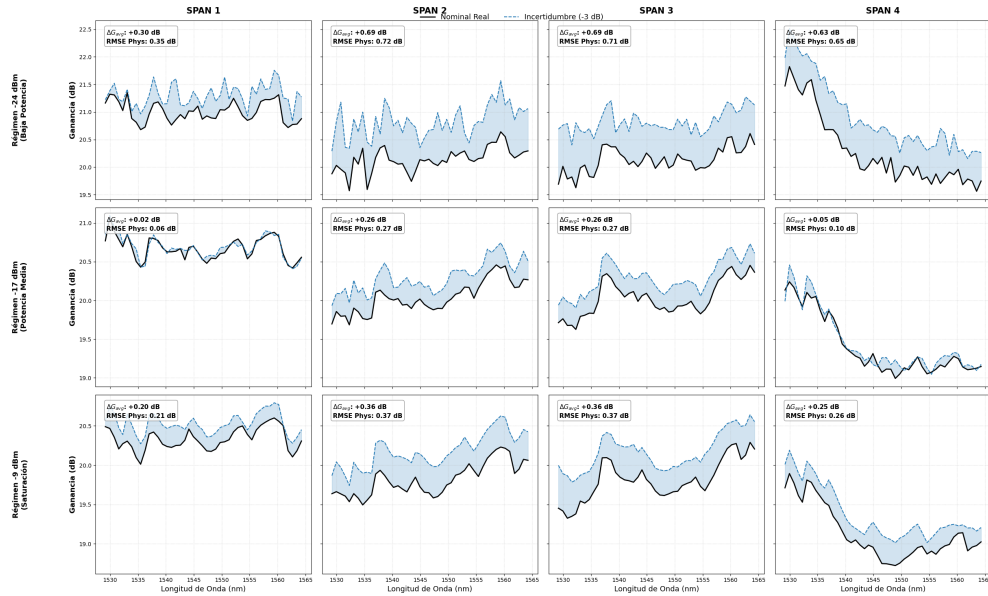


Figura 5.1.43: Impacto de la incertidumbre de potencia en la configuración de 48 canales. Se observa una respuesta dinámica similar a la carga completa, con variaciones locales de *ripple* diferenciadas.

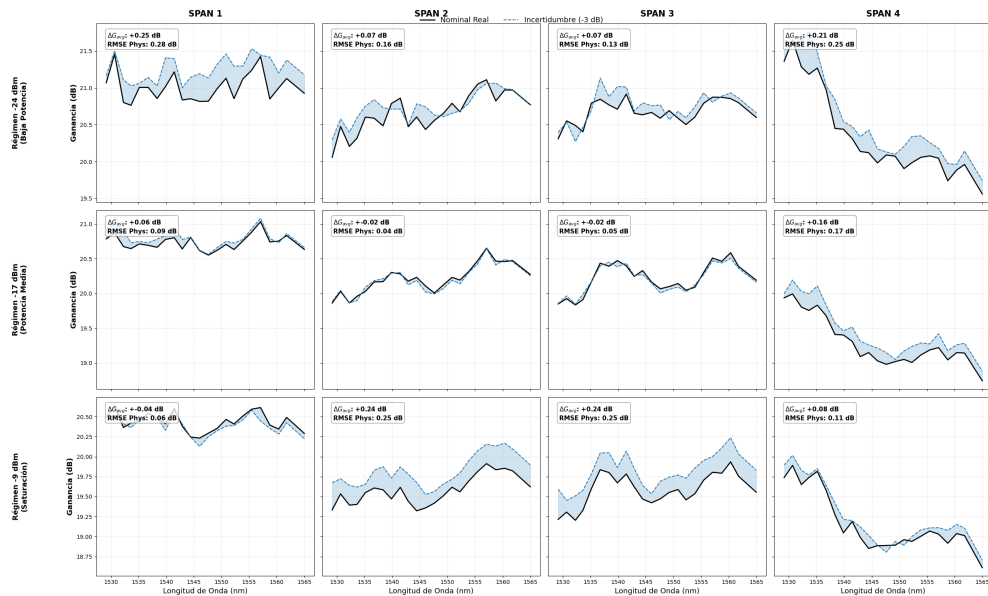


Figura 5.1.44: Respuesta del enlace bajo incertidumbre para una carga reducida de 25 canales. En este régimen, la separación entre curvas se mantiene más estable debido a la menor saturación del medio activo.

Estas figuras comparan, en negro, la condición nominal de ganancia y, en color, la respuesta espectral cuando se aplica una incertidumbre de $\Delta P_{in} = -3$ dB en el primer span. Aunque los EDFAs operan con Control AGC y mantienen su ganancia media objetivo, la perturbación altera el régimen de saturación y genera una redistribución espectral que se arrastra hacia los tramos siguientes.

Con 95 canales, el efecto es más crítico en baja potencia: las pérdidas por span rondan los 0,6 dB, mientras que en régimen medio y alto se acercan a 0,2 dB por tramo. En términos acumulados, una sola perturbación inicial puede traducirse en desviaciones del orden de 2–3 dB.

Con 48 canales se mantiene la misma tendencia. En baja potencia, el error por tramo se mueve entre 0,4 y 0,7 dB; en potencia media desciende a cerca de 0,2 dB. A diferencia del caso de 95 canales, en alta potencia aparecen incrementos algo mayores, entre 0,2 y 0,4 dB por span.

Con 25 canales, el enlace se comporta de forma más estable: en todos los regímenes, las variaciones por tramo permanecen por debajo de 0,25 dB. Esto sugiere mayor robustez frente a incertidumbre cuando la carga espectral es menor.

En conjunto, los resultados muestran que una variación local de potencia no produce solo un corrimiento uniforme del nivel de ganancia, sino un cambio real del perfil espectral, cuya magnitud depende del régimen operativo y de la carga de canales. Que el error espectral siga la variación media de ganancia confirma que el RMSE observado no es ruido aleatorio, sino la respuesta física del EDFA a un cambio de régimen. Así, una perturbación inyectada en el primer tramo se transforma en una modificación persistente del estado espectral del enlace, validando experimentalmente que la incertidumbre operacional se propaga en cascadas de EDFAs.

5.1.4.2. Visualización cuantitativa: métricas físicas tramo a tramo

En esta sección se evalúa el rendimiento del sistema frente al cambio de potencia de manera general de manera hop-by-hop.

Para cuantificar este efecto de déficit de potencia, la Fig. 5.1.45 se muestra la evolución del Error de Potencia Total a la salida (ΔP_{Out}).




Figura 5.1.45: Evolución del Error de Potencia Total (ΔP_{Out}).

La Fig. 5.1.45 resume ΔP_{Out} para una perturbación de $\Delta P_{in} = -3$ dB

(medida sobre *peaks* OSA). En baja potencia (-24 dBm), el sistema muestra autocompensación clara: los errores se mueven entre $-2,9$ y $-2,2$ dB, es decir, por encima del objetivo de -3 dB. En potencia media (-17 dBm), la respuesta se concentra cerca de -3 dB (aprox. $-3,0$ a $-2,7$ dB). En alta potencia (-9 dBm), la compensación depende más de la carga: para 95 canales aparece incluso un mínimo cercano a $-3,2$ dB en tramos intermedios, mientras que para 48 y 25 canales los valores se mantienen entre $-2,9$ y $-2,6$ dB.

En síntesis, la perturbación no se propaga de forma rígida: cada EDFA la modula según su régimen de saturación y la carga espectral.




Figura 5.1.46: Reacción de Ganancia promedio (*Gain Boost*) ante una caída de -3 dB en la potencia de entrada.




Figura 5.1.47: Distorsión Espectral Total (RMSE) inducida por la incertidumbre de -3 dB.

Las Fig. 5.1.46 y 5.1.47 confirman la misma tendencia. En baja potencia, el *gain boost* alcanza sus máximos ($\Delta G_{avg} \approx 0,8$ dB en 95 canales y $\approx 0,7$ dB en 48 canales) y el RMSE también es máximo (hasta $\sim 0,83$ dB en 95 canales). En potencia media, ambos indicadores bajan de forma marcada ($\Delta G_{avg} \lesssim 0,26$ dB y RMSE típico entre 0,04 y 0,28 dB).

En alta potencia, 48 canales concentra la mayor distorsión (RMSE de $\sim 0,21$ a $0,37$ dB), mientras 95 canales se mantiene bajo ($\sim 0,09$ a $0,17$ dB) y con *gain boost* incluso negativo en spans intermedios. Esto muestra que la recuperación de potencia no es gratuita: viene acompañada de deformación espectral y depende del régimen de operación y de la carga WDM.

5.1.4.3. Análisis de incertidumbre en el OSNR

Los siguientes análisis es el efecto de la incertidumbre sobre la OSNR. Tal como se muestra en las Figuras 5.1.48, 5.1.49 y 5.1.50, una caída de potencia de entrada de -3 dB se traduce en una degradación de la calidad óptica, independientemente de la carga espectral considerada.




Figura 5.1.48: Impacto de la incertidumbre en el OSNR (95 canales). El área sombreada representa la pérdida de calidad de señal inducida por la caída de potencia de -3 dB.

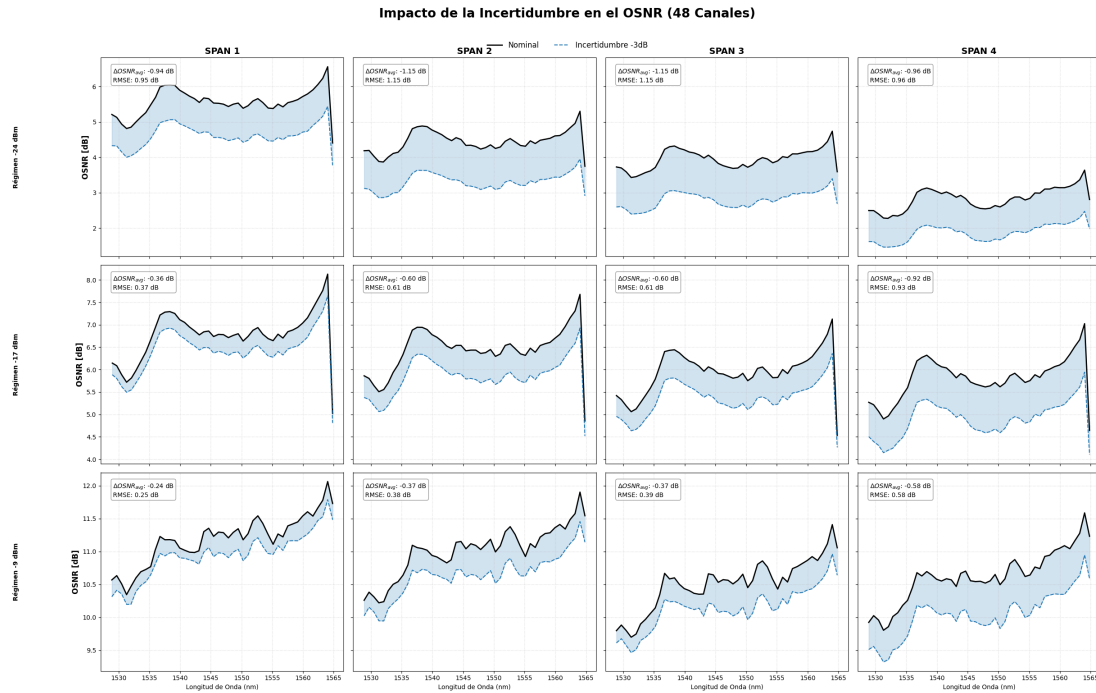


Figura 5.1.49: Impacto de la incertidumbre en el OSNR (48 canales). El área sombreada representa la pérdida de calidad de señal inducida por la caída de potencia de -3 dB.

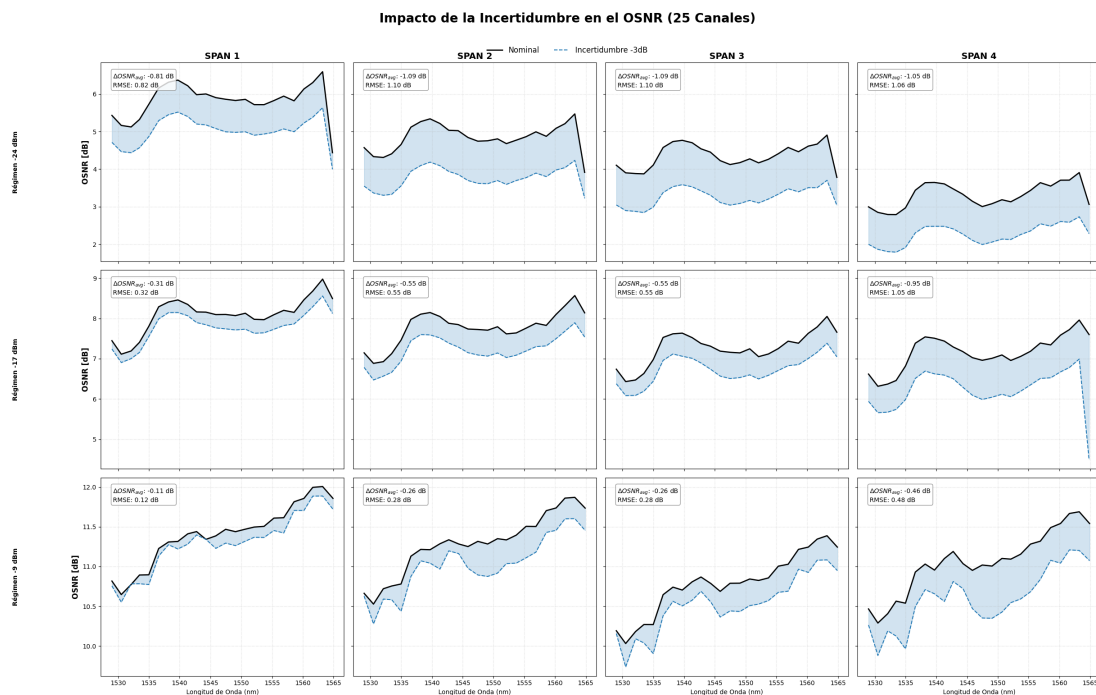


Figura 5.1.50: Impacto de la incertidumbre en el OSNR (25 canales). El área sombreada representa la pérdida de calidad de señal inducida por la caída de potencia de -3 dB.

Las Figuras 5.1.48, 5.1.49 y 5.1.50 muestran que una perturbación de -3 dB en

el primer span degrada el OSNR en toda la cascada, con magnitud dependiente de la carga WDM y del régimen de potencia. En baja potencia (-24 dBm), las mayores caídas se observan en 48 y 25 canales, con ΔOSNR_{avg} cercanos a $-1,15$ dB y $-1,09$ dB en spans intermedios; en 95 canales, las caídas máximas rondan $-0,91$ dB.

En potencia media (-17 dBm), la degradación típica se ubica entre $-0,31$ y $-0,60$ dB en los primeros tres spans y aumenta en S_4 hasta $-0,77$ dB (95 canales), $-0,92$ dB (48 canales) y $-0,95$ dB (25 canales). En alta potencia (-9 dBm), las penalizaciones son menores al inicio (aprox. $-0,11$ a $-0,37$ dB), pero vuelven a crecer en S_4 (hasta $-0,39$, $-0,58$ y $-0,46$ dB para 95, 48 y 25 canales, respectivamente). En conjunto, los resultados confirman que la autocompensación de ganancia no recupera la calidad óptica: el enlace puede recuperar potencia parcial, pero mantiene una penalización de OSNR que se propaga tramo a tramo.

5.1.4.4. Evaluación de Modelos Predictivos bajo Incertidumbre

Este bloque completa el Objetivo Específico 4 mediante la comparación entre los modelos de Machine Learning y el *ground truth* experimental bajo condiciones de incertidumbre en un enlace multispan. En particular, se evalúa cómo modelos entrenados en un único tramo responden cuando la perturbación se propaga a lo largo de la cascada, permitiendo analizar la pérdida de validez asociada a escenarios operacionales reales.

En esta etapa se estudia la capacidad de los modelos para anticipar las variaciones inducidas por una perturbación de -3 dB en la potencia de entrada, contrastando directamente sus predicciones con las mediciones experimentales obtenidas como referencia. Con el fin de mantener coherencia entre el entrenamiento y la inferencia, todas las variables escalares se manejan bajo la misma convención utilizada en el dataset base: la potencia de entrada se define como P_{in}^{peaks} , calculada a partir de la suma de los peaks de los canales WDM, y no como potencia total integrada (señal + ASE). En una cascada de EDFAs, esta magnitud puede disminuir debido al aumento relativo del ruido ASE, aun cuando la potencia nominal configurada en la interfaz del amplificador permanezca constante. Por esta razón, todas las comparaciones bajo incertidumbre se reportan utilizando la misma definición basada en peaks.

Adicionalmente, se respetó la definición original de entradas del modelo global propuesto por Wang, el cual incorpora P_{out} como variable de entrada. En contraste,

los modelos especialistas fueron entrenados utilizando $P_{\text{out}} = 0$ como valor de referencia. En consecuencia, durante la etapa de inferencia se emplea el valor real de P_{out} únicamente en el modelo global, mientras que en los modelos especialistas se mantiene el valor fijado en cero, evitando así inconsistencias de dominio que podrían introducir errores artificiales, particularmente en regímenes cercanos a saturación. Esta decisión permite preservar las condiciones originales de entrenamiento y asegurar una comparación consistente entre las distintas arquitecturas evaluadas.

Se presenta a continuación la gráfica que evalúa el rendimiento general del modelo de Wang con los especialistas de cada amplificador en la Fig. 5.1.51.




Figura 5.1.51: Evaluación del rendimiento general de los modelos predictivos.

La Fig. 5.1.51 compara el rendimiento nominal (95 canales) del modelo global de Wang y de los modelos especialistas frente al *ground truth*. En los tres regímenes, los especialistas muestran menor RMSE en la mayoría de los spans. En baja potencia (-24 dBm), el especialista queda entre 0,38 y 0,96 dB, mientras Wang se ubica entre 1,41 y 2,46 dB. En potencia media (-17 dBm), el especialista se mueve entre 0,55 y 1,63 dB, y Wang entre 2,30 y 2,77 dB. En alta potencia (-9 dBm), el especialista varía entre 0,39 y 1,62 dB, frente a 0,89–2,00 dB de Wang.

En términos prácticos, ambos modelos capturan la tendencia general, pero el especialista sigue mejor la forma espectral y mantiene menor error global. Esto deja una base clara para evaluar qué ocurre cuando se introduce incertidumbre operacional.

La Fig. 5.1.52 evalúa si los modelos pueden predecir de manera correcta los cambios en la potencia de entrada del multispan.




Figura 5.1.52: Impacto espectral de la incertidumbre predictiva (95 canales).

La Fig. 5.1.52 muestra el desempeño de ambos modelos bajo incertidumbre ($\Delta P_{in} = -3$ dB, 95 canales). El RMSE aumenta en todos los regímenes y Wang mantiene errores más altos en todos los spans. En baja potencia (-24 dBm), el especialista queda entre 1,09 y 1,37 dB, mientras Wang sube a 1,90–2,63 dB. En potencia media (-17 dBm), el especialista varía entre 0,36 y 1,38 dB, frente a 1,31–2,23 dB de Wang. En alta potencia (-9 dBm), el especialista se mueve entre 0,46 y 1,77 dB, y Wang entre 1,16 y 3,02 dB.

Esto confirma dos ideas clave: la incertidumbre degrada la predicción en toda la cascada y, aun así, los modelos especialistas conservan mejor robustez que el modelo global.

La Tabla 5.1.3 resume el RMSE promedio sobre los 4 spans. En nominal, el especialista supera de forma consistente a Wang en los tres regímenes. Bajo incertidumbre, el error sube en ambos modelos, pero el incremento es claramente mayor en Wang. En síntesis, los especialistas mantienen mejor precisión y mejor estabilidad cuando el enlace se aleja del régimen nominal.

La Fig. 5.1.53 resume esta comparación mediante el RMSE predictivo evaluado tramo a tramo.

Cuadro 5.1.3: Comparación de RMSE promedio (4 spans) para 95 canales en condición nominal y bajo incertidumbre.

Potencia	Wang Nom.	Esp. Nom.	Wang Incert.	Esp. Incert.
-24 dBm	2.17 dB	0.60 dB	2.35 dB	1.28 dB
-17 dBm	2.60 dB	1.08 dB	1.88 dB	0.81 dB
-9 dBm	1.46 dB	1.06 dB	2.21 dB	1.26 dB




Figura 5.1.53: Comparativa de RMSE bajo incertidumbre: Respuesta Física vs. Modelos ML.

La Fig. 5.1.53 muestra el RMSE por span bajo incertidumbre de -3 dB, comparando deriva física (Unc vs Nom) y error predictivo de los modelos. En los tres regímenes, los especialistas mantienen menor error que el modelo global de Wang en todos los spans.

En términos numéricos, el especialista varía entre 0,36 y 1,77 dB, mientras Wang se ubica entre 1,00 y 3,22 dB. Por régimen: para -24 dBm, especialista 1,10–1,37 dB vs Wang 2,26–3,02 dB; para -17 dBm, especialista 0,36–1,38 dB vs Wang 1,00–2,05 dB; y para -9 dBm, especialista 0,47–1,77 dB vs Wang 1,76–3,22 dB.

La deriva física permanece acotada entre 0,06 y 0,82 dB (siempre bajo 1 dB), pero el error de predicción crece claramente por sobre esa perturbación, con el caso más crítico en Span 4 para -9 dBm. En conjunto, esto refuerza la hipótesis: bajo incertidumbre operacional, los modelos entrenados en régimen nominal pierden validez en cascada multispán.

5.1.5. Validación experimental de la hipótesis

Los resultados obtenidos respaldan que la incertidumbre operacional, expresada como variaciones de potencia de entrada, modifica el régimen físico del EDFA y se manifiesta en cambios del *gain ripple* y en la redistribución del ruido ASE. Esa perturbación no se limita a un desplazamiento de nivel, sino que induce una

degradación del OSNR que persiste a lo largo del enlace. La evidencia *ground truth* muestra que estos efectos se acumulan tramo a tramo, confirmando la propagación multispan planteada en la hipótesis. Además, la comparación predictiva indica que modelos entrenados en un solo tramo pierden fidelidad bajo incertidumbre en cascada, validando la necesidad de considerar explícitamente dicha propagación en su evaluación. En consecuencia, los resultados experimentales confirman la hipótesis propuesta, demostrando que la incertidumbre actúa como un mecanismo físico de propagación de error en enlaces ópticos multispan y establece un límite práctico para la validez de modelos predictivos entrenados bajo condiciones nominales.

Capítulo 6

Conclusión

Esta tesis analiza experimentalmente el impacto de la incertidumbre operacional en la potencia de entrada sobre el comportamiento espectral de amplificadores EDFA y sus implicancias en la estimación de la calidad de transmisión en sistemas ópticos multitransmisiones. Los resultados muestran que variaciones en la potencia de entrada modifican el régimen de operación del amplificador, produciendo deformaciones espectrales medibles en la ganancia (*gain ripple*) que se propagan a lo largo de la cascada de amplificadores.

Los experimentos realizados en un enlace multitransmisiones evidencian que estas perturbaciones generan efectos acumulativos en la línea de transmisión. Ya que, pequeñas desviaciones en la ganancia por tramo pueden parecer marginales de forma individual, pero al propagarse a lo largo de la cascada producen degradaciones observables tanto en el perfil espectral como en la estimación del OSNR. Este comportamiento es más crítico en regímenes de operación de baja potencia, donde el sistema presenta mayor sensibilidad a perturbaciones en la potencia de entrada.

Desde la perspectiva de los modelos de *machine learning*, los resultados muestran que modelos entrenados en escenarios controlados de *single span*, aun cuando alcanzan errores inferiores a 0.2 dB, pueden perder precisión al ser evaluados en sistemas multitransmisiones bajo incertidumbre operacional. En este contexto, las estrategias basadas en *transfer learning* y especialización por tramo demostraron mejorar la capacidad de predicción, reduciendo los errores respecto a los modelos base y capturando de manera más adecuada la dinámica física del sistema cuando este se aleja de su punto de operación.

En conjunto, los resultados obtenidos validan la hipótesis de esta tesis: la incertidumbre operacional en la potencia de entrada modifica la dinámica espectral de los amplificadores EDFA y puede limitar la validez de modelos predictivos entrenados únicamente bajo condiciones nominales. En consecuencia, el uso de información proveniente de un único amplificador resulta insuficiente para representar el comportamiento de enlaces ópticos multitransmisiones bajo condiciones reales de operación. El principal aporte de este trabajo es demostrar experimentalmente que la incorporación explícita de la incertidumbre operacional es un requisito para mejorar la robustez de los modelos predictivos y para el desarrollo de herramientas de estimación de calidad de transmisión más confiables en redes ópticas.

Referencias

- [1] L. Zhang, X. Li, Y. Tang, J. Xin and S. Huang, “A survey on QoT prediction using machine learning in optical networks,” 2022, *opt. Fiber Technol.*, vol. 68, art. no. 102804, 2022.
- [2] V. Curri, “GNPy model of the physical layer for open and disaggregated optical networking,” 2022, in *Journal of Optical Communications and Networking*, vol. 14, no. 6, pp. C92-C104, June 2022.
- [3] P. Poggiolini, G. Bosco, A. Carena, V. Curri, Y. Jiang and F. Forghieri, “The GN-Model of Fiber Non-Linear Propagation and its Applications,” 2014, in *Journal of Lightwave Technology*, vol. 32, no. 4, pp. 694-721, Feb.15, 2014.
- [4] A. Mahajan, K. Christodoulopoulos, R. Martinez, S. Spadaro and R. Munoz, “Improving QoT estimation accuracy with DGE monitoring using machine learning,” 2020, in *Proc. 2020 Int. Conf. Optical Netw. Des. Model. (ONDM)*, Barcelona, Spain, 2020, pp. 1–6.
- [5] A. Ferrari et al., “Assessment on the in-field lightpath QoT computation including connector loss uncertainties,” 2021, in *Journal of Optical Communications and Networking*, vol. 13, no. 2, pp. A156-A164, February 2021.
- [6] A. D’Amico et al., “Experimental validation of GNPy in a multi-vendor flex-grid flex-rate WDM optical transport scenario,” 2022, in *Journal of Optical Communications and Networking*, vol. 14, no. 3, pp. 79-88, March 2022.
- [7] Y. He et al., “Improved QoT estimations through refined signal power measurements and data-driven parameter optimizations in a disaggregated and partially loaded live production network,” 2023, in *Journal of Optical Communications and Networking*, vol. 15, no. 9, pp. 638-648, September 2023.
- [8] Z. Zhai, L. Dou, Y. He, A. P. T. Lau and C. Xie, “Open-source data for QoT estimation in optical networks from Alibaba,” 2024, in *Journal of Optical Communications and Networking*, vol. 16, no. 1, pp. 1-3, January 2024.
- [9] A. A. M. Saleh, R. M. Jopson, J. D. Evankow and J. Aspell, “Modeling of gain in erbium-doped fiber amplifiers,” 1990, *IEEE Photonics Technol. Lett.*, vol. 2, no. 10, pp. 714–717, Oct. 1990.
- [10] C. R. Giles and E. Desurvire, “Modeling erbium-doped fiber amplifiers,” 1991, in *Journal of Lightwave Technology*, vol. 9, no. 2, pp. 271-283, Feb. 1991.

-
- [11] A. C. Meseguer et al., “Highly Accurate Measurement-Based Gain Model for Constant-Pump EDFA for non-Flat WDM Inputs,” 2021, 2021 Optical Fiber Communications Conference and Exhibition (OFC), San Francisco, CA, USA, 2021, pp. 1-3.
- [12] Y. Li, M. Zhang, Z. Hu, Z. Song, S. Yan and M. Tang, “A data-efficient erbium-doped fiber amplifier model under partial channel loadings,” 2023, in Proc. 2023 Asia Commun. Photonics Conf./Int. Photonics Optoelectron. Meet. (ACP/POEM), Wuhan, China, 2023, pp. 1–3.
- [13] G. Borraccini et al., “Gain profile characterization and modeling for dual-stage EDFA abstraction and control,” 2024, IEEE Photonics Technol. Lett., vol. 36, no. 2, pp. 107–110, Jan. 15, 2024.
- [14] A. Arnould, R. Freund, and G. Rademacher, “A Fast and Accurate EDFA Model for the Optimization of Power-Efficient SDM Subsea Transmission Systems,” 2025, 2025 Optical Fiber Communications Conference and Exhibition (OFC), San Francisco, CA, USA, 2025, pp. 1–3.
- [15] C. Harvey, M. S. Faruk and S. J. Savory, “Data-Driven Erbium-Doped Fiber Amplifier Gain Modeling Using Gaussian Process Regression,” 2024, in IEEE Photonics Technology Letters, vol. 36, no. 18, pp. 1097-1100, 15 Sept.15, 2024.
- [16] A. Raj, Z. Wang, T. Chen, D. C. Kilper and M. Ruffini, “Generalized few-shot transfer learning architecture for modeling the EDFA gain spectrum,” 2025, in Journal of Optical Communications and Networking, vol. 17, no. 9, pp. D106-D117, September 2025.
- [17] F. C. N. O. Lima et al., “A Comparison of DGT and Power Mask for EDFA Modeling in GNPY,” 2023, 2023 SBMO/IEEE MTT-S International Microwave and Optoelectronics Conference (IMOC), Castelldefels, Spain, 2023, pp. 79-81.
- [18] M. Devigili et al., “ML-Based Modeling of EDFA Pluggable Modules for OSNR Estimation,” 2025, 2025 International Conference on Optical Network Design and Modeling (ONDM), Pisa, Italy, 2025, pp. 1-6.
- [19] Z. Jiang, J. Lin and H. Hu, “Machine learning based EDFA channel in-band gain ripple modeling,” 2022, in Proc. 2022 Optical Fiber Commun. Conf. Expo. (OFC), San Diego, CA, USA, 2022, pp. 1–3.
- [20] E. Seve, J. Pesic and Y. Pointurier, “Accurate QoT estimation by means of a reduction of EDFA characteristics uncertainties with machine learning,” 2020, in Proc. 2020 Int. Conf. Optical Netw. Des. Model. (ONDM), Barcelona, Spain, 2020, pp. 1–3.
- [21] A. Mahajan, K. Christodoulopoulos, R. Martinez, S. Spadaro and R. Munoz, “Machine learning assisted EDFA gain ripple modelling for accurate QoT estimation,” 2019, in Proc. 45th Eur. Conf. Optical Commun. (ECOC), Dublin, Ireland, 2019, pp. 1–4.

- [22] M. P. Yankov, P. M. Kaminski, H. E. Hansen and F. Da Ros, "SNR optimization of multi-span fiber optic communication systems employing EDFAs with non-flat gain and noise figure," 2021, *j. Lightw. Technol.*, vol. 39, no. 21, pp. 6824–6832, Nov. 1, 2021.
- [23] Z. Wang, Y. -K. Huang, S. Han, T. Wang, D. Kilper and T. Chen, "Multi-Span Optical Power Spectrum Prediction using ML-based EDFA Models and Cascaded Learning," 2024, 2024 Optical Fiber Communications Conference and Exhibition (OFC), San Diego, CA, USA, 2024, pp. 1-3.
- [24] Z. Wang, D. C. Kilper and T. Chen, "Open EDFA gain spectrum dataset and its applications in data-driven EDFA gain modeling," 2023, *j. Opt. Commun. Netw.*, vol. 15, no. 9, pp. 588–599, Sep. 2023.
- [25] A. C. Aygar and F. E. Durak, "Exploring the effect of WDM channels on EDFA spectral gain," 2024, in *Proc. 47th Int. Conf. Telecommun. Signal Process. (TSP)*, Prague, Czech Republic, 2024, pp. 227–230.
- [26] Y. Li, M. Zhang and M. Tang, "A data-effective black-box EDFA gain model with singular value decomposition," 2022, in *Proc. 2022 Asia Commun. Photonics Conf. (ACP)*, Shenzhen, China, 2022, pp. 985–987.
- [27] H.-M. Chin, D. J. Ives, S. J. Savory and J. P. Turkiewicz, "Estimating coherent optical transmission system performance over heterogeneous fibre span lengths," 2017, in *Proc. 19th Int. Conf. Transparent Opt. Netw. (ICTON)*, Girona, Spain, 2017, pp. 1–4.
- [28] M. S. Zefreh and S. Asselin, "Capacity enhancement in optical networks using margin extraction," 2018, in *OSA Tech. Dig. Opt. Fiber Commun. Conf.*, 2018, paper W4A.3.
- [29] J. Pesic, M. Lonardi, N. Rossi, T. Zami, E. Seve and Y. Pointurier, "How uncertainty on the fiber span lengths influences QoT estimation using machine learning in WDM networks," 2020, in *Proc. 2020 Optical Fiber Commun. Conf. Expo. (OFC)*, San Diego, CA, USA, 2020, pp. 1–3.
- [30] E. Seve, J. Pesic, C. Delezoide, S. Bigo and Y. Pointurier, "Learning process for reducing uncertainties on network parameters and design margins," 2018, in *Journal of Optical Communications and Networking*, vol. 10, no. 2, pp. A298-A306, Feb. 2018.
- [31] O. Karandin, A. Ferrari, F. Musumeci, Y. Pointurier and M. Tornatore, "Probabilistic low-margin optical-network design with multiple physical-layer parameter uncertainties," 2023, *j. Opt. Commun. Netw.*, vol. 15, no. 7, pp. C129–C137, Jul. 2023.
- [32] C. Harvey and S. J. Savory, "Optical Power Spectrum Prediction Using Cascaded Learning With Uncertainty Propagating Noisy Input Gaussian Processes," 2025, in *Journal of Lightwave Technology*, vol. 43, no. 16, pp. 7639-7649, 15 Aug.15, 2025.
- [33] Elson, D. J., Saavedra, G., Shi, K., Semrau, D., Galdino, L., Killey, R., Thomsen, B. C., & Bayvel, P., "Investigation of bandwidth loading in optical

- fibre transmission using amplified spontaneous emission noise,” 2017, *opt. Express*, vol. 25, no. 16, pp. 19529–19537, Aug. 2017.
- [34] K. Ishii, K. Tanizawa, J. Kurumida, and S. Namiki, “Experimental study of wavelength-dependent dynamic gain offsets of AGC WDM EDFA,” 2013, in *Proc. 18th OptoElectronics Commun. Conf. (OECC/PS)*, Kyoto, Japan, 2013, pp. 1–2.
- [35] G. P. Agrawal, “Fiber-optic communication systems,” 2021, 5th ed. Hoboken, NJ, USA: Wiley, 2021.